



Digital Mapping of Soil Quality Using Satellite Imagery and Machine Learning Algorithms (A Case Study of Lushan, Guilan Province, Iran)

Samira Hemmati¹ | Kamran Moravej² | Ahmad Golchin³ | Mir Naser Navidi⁴ |
Mohammad Sadegh Askari⁵

1. Department of Soil Science, Faculty of Agriculture, University of Zanjan, Zanjan, Iran. E-mail: s.hemmati@znu.ac.ir

2. Department of Soil Science, Faculty of Agriculture, University of Zanjan, Zanjan, Iran. E-mail: kmoravej@znu.ac.ir

3. Department of Soil Science, Faculty of Agriculture, University of Zanjan, Zanjan, Iran. E-mail:

agolchin2011@yahoo.com

4. Corresponding Author, Soil and Water Research Institute, Agricultural Research Education and Extension Organization (AREEO), Karaj, Iran, Email: nasernavidi@yahoo.com

5. Department of Soil Science, Faculty of Agriculture, University of Zanjan, Zanjan, Iran. E-mail: askari@znu.ac.ir

Article Info

Article type: Research Article

Article history:

Received: Feb. 4, 2026

Revised: March. 12, 2026

Accepted: Apr. 25, 2026

Published online: May. 2026

Keywords:

*Digital soil mapping,
Random forest,
Remote sensing,
Soil assessment,
Spatial modeling*

Soil quality is a fundamental indicator for assessing ecosystem sustainability and land productivity, and it is influenced by a combination of natural and anthropogenic factors. This study aimed to analyze the spatial variability of the soil quality index (SQI) at the regional scale using the random forest (RF) machine learning algorithm and multiple linear regression (MLR) based on environmental variables in the lands of the Loshan region in Guilan Province. For this purpose, 76 soil samples were collected from the 0–30 cm soil layer, and soil physical, chemical, and biological properties were measured using standard laboratory methods. In addition, remote sensing-based indices, including normalised difference vegetation index (NDVI), normalised difference water index (NDWI), normalised difference moisture index (NDMI), normalized difference built-up index (NDBI), the bare soil index (BSI), and land surface temperature (LST), were derived as environmental auxiliary variables. The SQI was calculated using both the total data set (TDS) and minimum data set (MDS) approaches, combined with fuzzy scoring functions. The results showed that the random forest model predicted the spatial variability of SQI with higher accuracy ($R^2 = 0.75$) than multiple linear regression ($R^2 = 0.53$). Moreover, spectral indices particularly NDVI, NDWI and BSI played the most important roles in explaining the spatial variation of soil quality. This study demonstrates that the proposed digital soil quality mapping framework can serve as an effective tool for sustainable land management, soil conservation, and supporting decision-making in precision agriculture.

Cite this article: Hemmati, S., Moravej, K., Golchin, A., Navidi, M.N., Askari, M. S., (2026) Digital Mapping of Soil Quality Using Satellite Imagery and Machine Learning Algorithms (A Case Study of Lushan, Guilan Province, Iran), *Iranian Journal of Soil and Water Research*, 57 (3), 611-630. <https://doi.org/10.22059/ijswr.2026.410504.670095>

© The Author(s).

Publisher: University of Tehran Press.

DOI: <https://doi.org/10.22059/ijswr.2026.410504.670095>



EXTENDED ABSTRACT

Objective

Soil quality, as a fundamental pillar of sustainable agricultural production systems and the maintenance of soil ecosystem functions, plays a decisive role in food security, environmental sustainability, and the sustainable management of natural resources. In recent decades, increasing anthropogenic pressures resulting from land-use change, unsustainable exploitation, overgrazing, improper tillage practices, and inefficient use of agricultural inputs have led to a gradual decline in soil quality across many regions of the country. Therefore, quantitative and spatial monitoring of soil quality and the identification of its driving factors are considered essential prerequisites for sustainable land management planning and precision agriculture. The Soil Quality Index (SQI) provides an integrated framework for the simultaneous incorporation of soil physical, chemical, and biological properties, enabling quantitative assessment of the functional health status of soils across different spatial scales. The main objective of this study was to assess soil quality and map its spatial distribution in the study area by applying the SQI and integrating field-based soil data with remote sensing information and advanced machine-learning models.

Methods

A total of 76 composite soil samples were collected from the 0–30 cm soil layer. A suite of physical, chemical, and biological properties, including soil texture, bulk density, aggregate stability, water-dispersible clay, pH, electrical conductivity, soil organic carbon, total nitrogen, available phosphorus and potassium, soluble calcium and magnesium, cation exchange capacity, calcium carbonate equivalent, microbial respiration, microbial biomass carbon, metabolic quotient (qCO_2), and microbial quotient (MQ), were measured. Soil organic carbon stock was also calculated as a key indicator of soil ecosystem functioning. To derive environmental covariates, Sentinel-2 satellite imagery was obtained from Google Earth Engine and processed to extract spectral indices including NDVI, NDWI, NDMI, and BSI, as well as land surface temperature (LST). These variables were used as auxiliary predictors in digital soil quality mapping. Principal component analysis (PCA) combined with correlation analysis was applied to reduce the number of indicators and to determine the minimum data set (MDS). The PCA results indicated that several principal components with eigenvalues >1 explained most of the data variance; accordingly, soil organic carbon, bulk density, available phosphorus, magnesium, and pH were selected as key indicators. In parallel, the total data set (TDS), comprising all measured indicators, was used to compute SQI. Indicator scoring was performed using fuzzy membership functions according to the response type of each variable (more-is-better, less-is-better, or optimum range), and indicator weights in the TDS and MDS approaches were derived based on factor analysis and the proportion of variance explained by principal components, respectively. The SQI was ultimately calculated as a weighted additive index for each sampling point. For spatial prediction of SQI, multiple linear regression (MLR) and random forest (RF) models were employed.

Findings

The results showed that the mean SQI obtained from the TDS approach was slightly higher than that derived from the MDS approach. However, the very strong correlation between SQI values obtained from the two approaches indicates that, despite the substantial reduction in the number of input variables, the MDS approach was able to reproduce the spatial pattern of soil quality with acceptable accuracy. The wider range of SQI values under the MDS approach reflects its higher sensitivity in discriminating different soil quality levels and identifying areas with more severe limitations. These findings confirm the efficiency of the MDS approach as a cost-effective and practical method for regional-scale soil quality monitoring. Model performance evaluation further demonstrated that the random forest algorithm outperformed multiple linear regression in both TDS and MDS scenarios, yielding higher coefficients of determination and lower prediction errors. This superiority highlights the greater capability of machine-learning algorithms to capture complex and nonlinear relationships between soil quality indices and environmental covariates. In contrast, the multiple linear regression model, due to its reliance on linear assumptions, showed limited ability to represent the inherent complexity of soil quality controlling processes. Accordingly, the application of machine-learning approaches, particularly random forest, is recommended for digital soil quality mapping in heterogeneous landscapes. Variable importance analysis in the random forest model revealed that moisture- and vegetation-related spectral indices, including NDWI, NDVI, NDMI, and the bare soil index (BSI), contributed most to explaining the spatial variability of soil quality. These results emphasize the key role of soil moisture conditions and vegetation cover in regulating soil biological and chemical properties and, ultimately, soil quality. Higher NDVI and NDWI values were generally associated with increased soil organic carbon content,

enhanced microbial activity, and improved structural stability, whereas higher BSI values reflected more exposed and degraded soil surfaces, which were directly linked to soil quality degradation. Therefore, remote sensing indices can serve as rapid, cost-effective, and efficient tools for spatial monitoring of soil quality at regional scales.

Soil quality maps indicated that a considerable proportion of the study area falls within moderate to low soil quality classes, highlighting the need for implementing conservation-oriented management strategies at the watershed scale. In contrast, areas under sustainable land-use systems such as olive orchards, particularly in low-slope and downslope positions, exhibited higher soil quality. This pattern confirms the positive role of permanent vegetation cover, reduced tillage intensity, and increased organic matter inputs in improving soil quality. Accordingly, the adoption of conservation management practices, including residue management, enhancement of surface cover, reduction of intensive tillage, optimized irrigation management, and erosion control, is recommended as effective strategies for improving soil quality in the region.

Conclusion

Overall, the findings demonstrate that integrating the Soil Quality Index with remote sensing data and machine-learning algorithms provides an efficient framework for regional-scale assessment and digital mapping of soil quality. The MDS approach can be recommended as a practical, cost-effective, and reliable alternative to the TDS approach for soil quality monitoring, while the random forest algorithm, due to its superior predictive performance, represents a robust tool for supporting management decision-making in soil conservation, precision agriculture, and sustainable land-use planning. This integrated approach can serve as a scientific basis for policy-making related to soil and water resources management at local and regional scales.

Funding

This research did not receive any specific grant from funding agencies in the public, commercial, or not-for-profit sectors.

Authorship contribution

For research articles with several authors, a short paragraph specifying their individual contributions must be provided. The following statements should be used “Conceptualization, S.H., K.M, M.N and A.G.; methodology, S.H., K.M, N.N, A.G and M.A.; software, S.H, M.N.; validation, A.G., K.M, M.N. and M.A.; formal analysis, S.H.; investigation, S.H. , A.G; resources, S.H, M.A.; data curation, S.H, M.N, A.G, K.M and M.A; writing—original draft preparation, S.H.; writing—review and editing, S.H, K.M, A.G, M.N.; visualization, A.G, M.A, M.N.; supervision, K.M.; project administration, S.H, K.M, M.N.; funding acquisition, S.H.,K.M. All authors have read and agreed to the published version of the manuscript

All authors contributed equally to the conceptualization of the article and writing of the original and subsequent drafts.

Declaration of Generative AI and AI-assisted technologies in the writing process

The authors did not use any artificial intelligence tools in preparing this manuscript.

Data availability statement

Data available on request from the authors.

Acknowledgements

The authors would like to thank all participants in the present study.

Ethical considerations

The authors avoided data fabrication, falsification, and plagiarism, and any form of misconduct.

Conflict of interest

The authors declare no conflict of interest.

تهیه نقشه رقومی کیفیت خاک با استفاده از تصاویر ماهواره‌ای و الگوریتم‌های یادگیری ماشین (مطالعه موردی: لوشان، استان گیلان)

سمیرا همتی^۱ | کامران مروج^۲ | احمد گلچین^۳ | میرناصر نویدی^۴ | محمدصادق عسکری^۵

۱. گروه خاکشناسی، دانشکده کشاورزی، دانشگاه زنجان، زنجان، ایران. رایانامه: s.hemmati@znu.ac.ir

۲. گروه خاکشناسی، دانشکده کشاورزی، دانشگاه زنجان، زنجان، ایران. رایانامه: kmoravej@znu.ac.ir

۳. گروه خاکشناسی، دانشکده کشاورزی، دانشگاه زنجان، زنجان، ایران. رایانامه: agolchin2011@yahoo.com

۴. نویسنده مسئول، مؤسسه تحقیقات خاک و آب، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران. nasernavidi@yahoo.com

۵. گروه خاکشناسی، دانشکده کشاورزی، دانشگاه زنجان، زنجان، ایران. رایانامه: askari@znu.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	کیفیت خاک یکی از شاخص‌های بنیادین در ارزیابی پایداری اکوسیستم‌ها و بهره‌وری اراضی به شمار می‌رود و تحت تأثیر مجموعه‌ای از عوامل طبیعی و انسانی قرار دارد. هدف این پژوهش، تحلیل تغییرات مکانی شاخص کیفیت خاک در مقیاس منطقه‌ای با استفاده از الگوریتم یادگیری ماشین جنگل تصادفی (RF) و رگرسیون خطی چندمتغیره (MLR) با استفاده از متغیرهای محیطی در اراضی منطقه لوشان در استان گیلان بود. بدین منظور، تعداد ۷۶ نمونه خاک از عمق ۰ تا ۳۰ سانتی‌متر برداشت شد و ویژگی‌های فیزیکی، شیمیایی و زیستی خاک با استفاده از روش‌های معمول اندازه‌گیری گردید. علاوه بر این، شاخص‌های سنجش‌ازدور شامل شاخص گیاهی تفاوت نرمال شده (NDVI)، شاخص تفاوت نرمال شده آب (NDWI)، شاخص اختلاف رطوبت نرمال شده (NDMI)، شاخص تفاوت نرمال شده مناطق ساخته‌شده (NDBI)، شاخص خاک برهنه (BSI) و دمای سطح زمین (LST) به‌عنوان متغیرهای کمکی محیطی استخراج شدند. شاخص کیفیت خاک (SQI) با استفاده از دو رویکرد مجموعه کامل داده‌ها (TDS) و مجموعه حداقل داده‌ها (MDS) و به‌کمک توابع نمره‌دهی فازی محاسبه گردید. نتایج نشان داد مدل جنگل تصادفی با دقت بالاتری ($R^2=0.75$) نسبت به رگرسیون خطی چندمتغیره ($R^2=0.53$)، قادر به پیش‌بینی تغییرات مکانی SQI بوده و ضرایب تعیین بالاتری را ارائه می‌دهد. همچنین شاخص‌های طبیعی، به‌ویژه NDVI، NDWI و BSI بیشترین نقش را در تبیین تغییرات کیفیت خاک ایفا کردند. این مطالعه نشان می‌دهد رویکرد پیشنهادی نقشه‌برداری دیجیتال کیفیت خاک می‌تواند به‌عنوان ابزاری کارآمد در مدیریت پایدار اراضی، حفاظت خاک و پشتیبانی از تصمیم‌گیری‌های کشاورزی دقیق مورد استفاده قرار گیرد.
تاریخ دریافت: ۱۴۰۴/۱۱/۱۵	
تاریخ بازنگری: ۱۴۰۴/۱۲/۲۱	
تاریخ پذیرش: ۱۴۰۵/۲/۵	
تاریخ انتشار: خرداد ۱۴۰۵	
واژه‌های کلیدی: ارزیابی خاک، نقشه‌برداری دیجیتال خاک، سنجش‌ازدور، جنگل تصادفی، مدلسازی مکانی	

استناد: همتی؛ سمیرا، مروج؛ کامران، گلچین؛ احمد، نویدی؛ میرناصر، عسکری؛ محمدصادق، (۱۴۰۵) تهیه نقشه رقومی کیفیت خاک با استفاده از تصاویر ماهواره‌ای و الگوریتم‌های یادگیری ماشین (مطالعه موردی: لوشان، استان گیلان)، *مجله تحقیقات آب و خاک ایران*، ۵۷ (۳)، ۶۱۱-۶۳۰



<https://doi.org/10.22059/ijswr.2026.410504.670095>

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijswr.2026.410504.670095>

مقدمه

خاک به‌عنوان یکی از بنیادی‌ترین منابع طبیعی، نقش کلیدی در عملکرد بوم سازگان، پشتیبانی از تولید غذایی و پایداری اکولوژیکی ایفا می‌کند. ارزیابی وضعیت کیفیت خاک و پایش تغییرات آن در مقیاس‌های بزرگ جغرافیایی از اهمیت بالایی برخوردار است، زیرا کاهش کیفیت خاک پیامدهای جدی در عملکرد کشاورزی، چرخه‌های بیوژئوشیمیایی و امنیت غذایی دارد (Tauqeer et al., 2022). روش‌های سنتی ارزیابی کیفیت خاک که بر نمونه‌برداری میدانی و آزمایشگاهی متکی هستند، اگرچه دقیق‌اند، اما هزینه‌بر، زمان‌بر و فاقد پوشش فضایی مناسب هستند. این محدودیت‌ها، پژوهشگران را به سمت استفاده از فناوری‌های نوین مانند سنجش از دور^۱ (RS)، سیستم‌های اطلاعات جغرافیایی^۲ (GIS) و الگوریتم‌های یادگیری ماشین سوق داده است تا بتوانند ارزیابی‌های مکانی و زمانی گسترده‌تر و کارآمدتری ارائه کنند (Budak et al., 2023; North et al., 2022).

سنجش از دور با فراهم آوردن داده‌های چندطیفی و سری‌های زمانی از ماهواره‌هایی مانند Sentinel-2 و Landsat، امکان استخراج شاخص‌های طیفی را برای تحلیل ویژگی‌های زمین فراهم کرده است. شاخص‌های طیفی مانند شاخص گیاهی تفاوت نرمال شده (NDVI)^۳، شاخص تفاوت نرمال شده آب^۴ (NDWI)، شاخص اختلاف رطوبت نرمال شده^۵ (NDMI) و دیگر نسبت‌های بانندی، اطلاعات ارزشمندی درباره پوشش گیاهی، رطوبت سطحی، و ویژگی‌های ساختاری سطح زمین ارائه می‌دهند که به‌طور غیرمستقیم با فرآیندهای خاک و خصوصیات آن مرتبط هستند (Zeyliger et al., 2022; Wang et al., 2018). مطالعات اخیر نیز نشان داده‌اند که این شاخص‌ها می‌توانند با مقادیر آزمایشگاهی پارامترهای خاک مانند رطوبت، مواد آلی و ترکیب ذرات خاک همبستگی معنی‌دار داشته باشند و به‌عنوان ورودی‌های موثر در مدل‌های پیش‌بینی مورد استفاده قرار گیرند (Sedaghat et al., 2022). به‌ویژه، کاربرد شاخص‌های طیفی در ارزیابی ویژگی‌های مرتبط با کیفیت خاک در سال‌های اخیر موضوع توجه فزاینده‌ای بوده است. بررسی‌های اخیر نشان داده‌اند که استفاده از شاخص‌های طیفی ترکیبی به همراه خصوصیات خاک می‌تواند باعث افزایش دقت تخمین ویژگی‌هایی مانند رطوبت سطحی شود، که این امر نشان‌دهنده پتانسیل بالای داده‌های RS در کاربردهای خاک‌شناسی است (et al., 2024; Dindaroglu et al., 2022 Metwaly).

هم‌زمان با توسعه داده‌های سنجش از دور، رویکردهای داده‌محور در قالب نقشه‌برداری رقومی خاک^۶ (DSM) به‌عنوان جایگزینی کارآمد برای روش‌های سنتی معرفی شده‌اند (McBratney et al., 2003). در این رویکرد، مجموعه‌ای از کوواریات‌های محیطی شامل متغیرهای توپوگرافی، اقلیمی، کاربری اراضی و شاخص‌های طیفی به‌عنوان متغیرهای پیش‌بینی‌کننده مورد استفاده قرار می‌گیرند و روابط پیچیده میان این متغیرها و ویژگی‌های خاک با بهره‌گیری از الگوریتم‌های یادگیری ماشین مدل‌سازی می‌شود (Rangzan et al., 2025).

الگوریتم‌هایی نظیر جنگل تصادفی^۷ (RF) و ماشین بردار پشتیبان^۸ (SVM) به دلیل توانایی بالا در مدل‌سازی روابط غیرخطی و مدیریت داده‌های چندبعدی، نسبت به روش‌های آماری کلاسیک عملکرد بهتری در پیش‌بینی ویژگی‌های خاک از خود نشان داده‌اند (Shafizadeh-Moghadam, 2022). مطالعات پیشین نشان داده‌اند که ترکیب شاخص‌های طیفی سنجش از دور با متغیرهای محیطی در چارچوب مدل‌های یادگیری ماشین می‌تواند دقت برآورد ویژگی‌هایی نظیر رطوبت خاک، کربن آلی، هدایت الکتریکی و شاخص‌های ترکیبی کیفیت خاک را به‌طور معنی‌داری افزایش دهد (Rangzan et al., 2025; Metwaly et al., 2024). برای مثال، استفاده از داده‌های خاک به‌همراه شاخص‌های طیفی توانسته است در مدل‌سازی مکانی حاصل‌خیزی و سلامت خاک نتایج قابل‌قبولی ارائه دهد، به‌گونه‌ای که مدل‌های یادگیری ماشین مانند جنگل تصادفی نسبت به رگرسیون خطی^۹ (MLR) عملکرد بهتری در پیش‌بینی پارامترهای خاک نشان داده‌اند (Halder et al., 2021).

Moharana et al., (2024) نشان دادند که ادغام داده‌های سنجش از دور با الگوریتم جنگل تصادفی در مناطق خشک، منجر به

1. Remote Sensing
2. Geographic Information System
3. Normalised Difference Vegetaion Index
4. Normalised Difference Water Index
5. Normalised Difference Moisture Index
6. Digital Soil Mapping
7. Random Forest
8. Supportive Vector Machine
9. Multiple Linear Regression

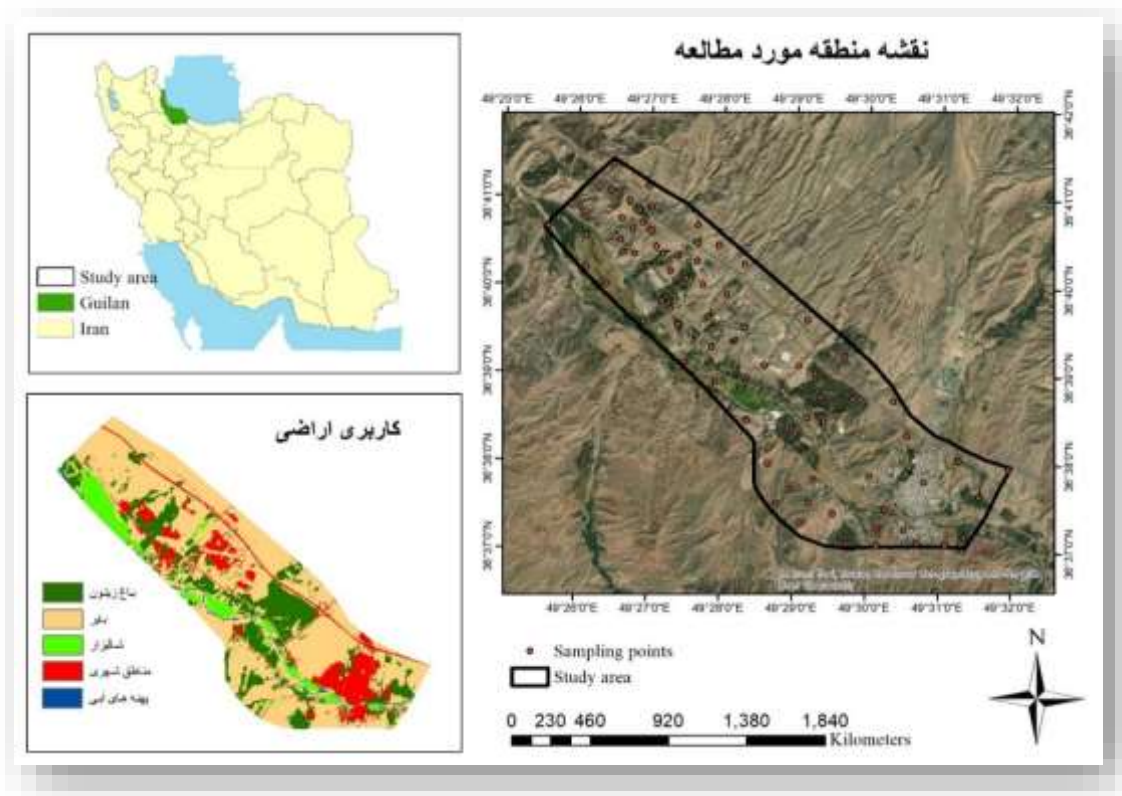
برآورد رضایت‌بخش شاخص کیفیت خاک شده و متغیرهای توپوگرافی و اقلیمی نقش غالبی در کنترل الگوی مکانی کیفیت خاک دارند. این نتایج بر ظرفیت بالای داده‌های سنجش از دور و مدل‌های یادگیری ماشین در پایش غیرتهاجمی و کم‌هزینه کیفیت خاک در مقیاس‌های منطقه‌ای تأکید می‌کند. (Barikloo et al., 2024) با بهره‌گیری از رویکرد نقشه‌برداری دیجیتال خاک، نشان دادند که ادغام الگوریتم‌های یادگیری ماشین با روش‌های زمین‌آماری می‌تواند به‌طور معناداری دقت برآورد و پهنه‌بندی شاخص کیفیت خاک را افزایش دهد. در مطالعه‌ای دیگر (Fathizad et al., 2020) تغییرات مکانی و زمانی شاخص کیفیت خاک را در مناطق خشک ایران بررسی کردند. آن‌ها از ۲۰۱ نمونه خاک سطحی (۰ تا ۲۰ سانتی‌متر) در دشت یزد-اردکان استفاده نموده و کربن آلی خاک، رسانایی الکتریکی، جرم مخصوص ظاهری، پایداری خاکدانه‌ها و فلزات سنگین خاک را مورد تجزیه و تحلیل قرار دادند. شاخص کیفیت خاک با استفاده از روش شاخص وزنی محاسبه شد و پیش‌بینی توزیع مکانی شاخص کیفیت خاک، با استفاده از یک مدل جنگل تصادفی بر اساس مجموعه‌ای از متغیرهای کمکی صورت گرفت. بر اساس نتایج، مدل آن‌ها قابلیت پیش‌بینی خوبی را نشان داد و به $R^2 = 0.69$ در منطقه مورد مطالعه دست یافت. (Maleki et al., 2022) در پژوهشی با استفاده از خواص فیزیکی و شیمیایی ۲۲۳ نمونه خاک سطحی (عمق ۰ تا ۳۰ سانتی‌متر)، دو نوع شاخص کیفیت خاک افزایشی وزنی و نمورو را با استفاده از مجموعه داده‌های TDS و MDS ارزیابی کردند. سپس از مدل جنگل تصادفی برای پیش‌بینی تغییرات مکانی شاخص‌های کیفیت خاک استفاده نمودند. یافته‌های آن‌ها نشان داد که مدل جنگل تصادفی عملکرد رضایت‌بخشی را برای نقشه‌برداری شاخص کیفیت خاک در باغ‌های زعفران و پسته نشان می‌دهد و به‌طور مؤثر عوامل توپوگرافی و آب‌های زیرزمینی را در بر می‌گیرد. امامی و همکاران (۱۴۰۴) با به‌کارگیری نقشه‌برداری رقومی خاک و الگوریتم‌های مختلف یادگیری ماشین، توزیع مکانی ویژگی‌های خاک شامل کربن آلی خاک و میانگین وزنی قطر خاکدانه‌ها را پیش‌بینی کردند. نتایج نشان داد مدل‌های Cubist و KNN با ترکیب داده‌های سنجش‌از‌دور و توپوگرافی، بالاترین دقت پیش‌بینی را ارائه می‌دهند.

با وجود پیشرفت‌های اخیر، همچنان خلأ پژوهشی در زمینه توسعه چارچوب‌های یکپارچه که بتوانند به‌طور هم‌زمان از توان شاخص‌های طیفی، متغیرهای محیطی و الگوریتم‌های یادگیری ماشین برای مدل‌سازی دقیق شاخص‌های کیفیت خاک بهره بگیرند، وجود دارد؛ به‌ویژه در مقیاس‌های منطقه‌ای که ناهمگنی مکانی خاک و تنوع کاربری اراضی بالاست. از این‌رو، هدف این پژوهش توسعه یک چارچوب منسجم برای مدل‌سازی و نقشه‌برداری رقومی شاخص‌های کیفیت خاک با استفاده از متغیرهای محیطی حاصل از داده‌های سنجش از دور ماهواره Sentinel-2 و الگوریتم یادگیری ماشین جنگل تصادفی و همچنین رگرسیون خطی چندگانه است. در این مطالعه تلاش می‌شود ضمن مقایسه عملکرد مدل‌ها، نقش نسبی شاخص‌های طیفی و متغیرهای محیطی در بهبود دقت پیش‌بینی شاخص‌های کیفیت خاک تبیین گردد. این پژوهش بر این فرضیه استوار است که داده‌های سنجش از دور در کنار مدل‌های پیشرفته یادگیری ماشین، می‌توانند روابط پیچیده و غیرخطی بین ویژگی‌های خاک، شاخص‌های طیفی و عوامل محیطی را آشکار کرده و شاخص کیفیت خاک را در مقیاس ناحیه‌ای برآورد کنند.

مواد و روش‌ها

مشخصات منطقه مورد مطالعه

منطقه مورد مطالعه با وسعتی حدود ۳۰۰۰ هکتار، در محدوده لوشان از توابع شهرستان رودبار در استان گیلان واقع در شمال ایران قرار دارد. این منطقه در سامانه مختصات UTM، در زون ۳۹ بین نقاط ۳۶ درجه و ۳۶ دقیقه و ۳۶ درجه و ۴۲ دقیقه شمالی و ۴۹ درجه و ۲۵ دقیقه و ۴۹ درجه و ۳۲ دقیقه شرقی قرار دارد (شکل ۱). براساس داده‌های ایستگاه‌های هواشناسی، میانگین بارندگی سالانه این منطقه ۲۷۳ میلی‌متر و میانگین دمای سالانه حدود ۱۷ درجه سلسیوس و میانگین رطوبت نسبی ۶۰ درصد است. ارتفاع منطقه بین ۲۷۰ تا ۵۸۰ متر از سطح دریا متغیر است. خاک منطقه در رده انتی سول قرار دارد. اقلیم منطقه لوشان از نوع نیمه خشک است که مهم‌ترین ویژگی غالب آن بارش کم و خشکی هوا است. این منطقه دارای انواع مختلف کاربری اراضی از جمله شالیزار، باغ‌های زیتون، پهنه‌های آبی، مناطق شهری و زمین‌های بایر است.



شکل ۱. منطقه مورد مطالعه، نقاط نمونه‌برداری و کاربری اراضی منطقه

ارزیابی کیفیت خاک

انتخاب ویژگی‌های مؤثر بر کیفیت خاک

به منظور ارزیابی کیفیت خاک منطقه مورد مطالعه، مجموعه‌ای از ویژگی‌های فیزیکی، شیمیایی و زیستی خاک به عنوان مجموعه کامل داده‌ها (TDS) انتخاب و اندازه‌گیری شد (Chaudhry et al., 2024; Rangzan et al., 2025). در این راستا، تعداد ۷۶ نمونه خاک در مهر ماه سال ۱۴۰۳ به صورت تصادفی از عمق صفر تا ۳۰ سانتی‌متر برداشت گردید. نمونه‌ها برای انجام آزمایش‌های فیزیکی و شیمیایی هواخشک شدند و نمونه‌های مربوط به مطالعات زیستی با رعایت شرایط استریل و زنجیره سرد جمع‌آوری و تا زمان انجام آزمایش‌ها در دمای ۴ درجه سلسیوس نگهداری شدند.

برای تحلیل کیفیت خاک، مجموعه‌ای از ویژگی‌های فیزیکی، شیمیایی و زیستی به عنوان شاخص‌های مؤثر در نظر گرفته شد (Reynolds et al., 2009). آزمایش‌های فیزیکی شامل تعیین بافت خاک (درصد رس، سیلت و شن) با استفاده از روش هیدرومتری با قرائت کامل (Gee et al., 1986)، تعیین جرم مخصوص ظاهری با روش کلوخه و پارافین (Blake and Hartge, 1986)، اندازه‌گیری پایداری خاکدانه‌ها (MWD) از طریق روش الک تر (Kemper et al., 1986)، و تعیین مقدار رس قابل انتشار در آب (DC) با استفاده از روش هیدرومتری بود (Gee et al., 1986). اندازه‌گیری واکنش خاک در نسبت ۱:۱ خاک به آب با استفاده از pH متر انجام شد (Knudsen et al., 1982). قابلیت هدایت الکتریکی (EC) از طریق عصاره اشباع اندازه‌گیری شد (Rhoades, 1982). مقدار کربن آلی باروش واکلی و بلک (Walkley and Black, 1934)، نیتروژن کل با روش کج‌دال (Bremner and Mulvaney, 1982)، و فسفر قابل جذب با روش اولسن اندازه‌گیری شدند (Olsen et al., 1954). غلظت سدیم (Na) و پتاسیم قابل جذب (K) در عصاره اشباع با استفاده از فلیم‌فتومتر (Knudsen et al., 1982)، و مقادیر کلسیم (Ca) و منیزیم (Mg) محلول در عصاره اشباع با استفاده از روش کمپلکسومتری (Page et al., 1989)، تعیین شد. ظرفیت تبادل کاتیونی (CEC) با روش استخراج با استات سدیم یک مولار در پ-هاش ۸/۲ اندازه‌گیری شد (Bower et al., 1952).

برای ارزیابی ویژگی‌های زیستی خاک، تنفس میکروبی خاک (BR) از طریق تیتراسیون (Anderson, 1982)، کربن زیست‌توده



میکروبی (MBC) با روش تدخین-استخراج (Beck, et al., 1997) تعیین گردیدند. همچنین نسبت میکروبی (MQ) به صورت نسبت کربن زیست توده میکروبی به کربن آلی خاک و ضریب متابولیک میکروبی (qCO_2) نیز به عنوان میزان دی اکسید کربن تولید شده ناشی از تنفس هر واحد زیست توده میکروبی در واحد زمان محاسبه گردید و با واحد $mgCO_2-C\ g^{-1}C_{mic}\ h^{-1}$ گزارش شد (Anderson et al., 2010).

ذخیره کربن آلی کل (CS) با استفاده از رابطه ۱ محاسبه شد (Poplau and Don, 2013):

$$C_S = SOC \times BD \times D \times 10^4 \quad \text{رابطه (۱)}$$

که در این رابطه، C_S ذخیره کربن آلی خاک بر حسب کیلوگرم بر هکتار، (SOC) کربن آلی خاک بر حسب درصد، (BD) جرم مخصوص ظاهری خاک بر حسب گرم بر سانتیمتر مکعب و (D) عمق خاک بر حسب متر می باشد.

تعیین حداقل ویژگی های مؤثر بر کیفیت خاک

به منظور کاهش تعداد متغیرها و شناسایی ویژگی های کلیدی مؤثر بر کیفیت خاک، از تجزیه به مؤلفه های اصلی (PCA) استفاده شد. این روش با حفظ بیشترین واریانس موجود در داده ها، تعداد متغیرهای مستقل را کاهش داده و ویژگی هایی را که بیشترین نقش را در تبیین تغییرات کیفیت خاک دارند، انتخاب می کند (Rahmanipour et al., 2014; Doran and Parkin, 1994).

نمره دهی ویژگی های مؤثر بر کیفیت خاک

به منظور یکسان سازی مقیاس ویژگی های خاک با واحدهای مختلف، از توابع عضویت فازی برای نمره دهی استفاده شد. در این روش، مقادیر هر ویژگی به بازه صفر (کمترین مطلوبیت برای کیفیت خاک) تا یک (بیشترین مطلوبیت) تبدیل شدند (Qi et al., 2009; Bandyopadhyay and Maiti, 2021). برای متغیرهایی که افزایش یا کاهش مقدار آن ها باعث بهبود کیفیت خاک می شد، به ترتیب از توابع سیگموئیدی مجانب بالایی و پایینی و برای متغیرهایی با دامنه بهینه مشخص، از تابع زنگوله ای شکل استفاده شد. نمره دهی ویژگی ها بر اساس رابطه (۲) انجام گرفت:

$$MF_X = \frac{1}{[1 + (\frac{x-b_1}{d})^2]} \quad x < b_1$$

$$MF_X = 1 \quad b_1 < x < b_2$$

$$MF_X = \frac{1}{[1 + (\frac{x-b_2}{d})^2]} \quad x > b_2$$

رابطه (۲)

در این رابطه؛

$MF(x)$: تابع عضویت متغیر X

b_1 و b_2 به ترتیب حدود آستانه پایینی^۲ و حدود آستانه بالایی^۳

وزن دهی ویژگی های مؤثر بر کیفیت خاک

وزن ویژگی های خاک برای مجموعه MDS بر اساس درصد واریانس تبیین شده توسط مؤلفه های اصلی محاسبه شد. در مواردی که ویژگی ها با یکدیگر همبستگی نداشتند، وزن هر ویژگی برابر با نسبت واریانس تبیین شده آن مؤلفه به مجموع واریانس تجمعی مؤلفه های انتخاب شده بود. در صورت وجود همبستگی بین ویژگی ها، واریانس مؤلفه مربوطه بر تعداد ویژگی های همبسته تقسیم و سپس نرمال سازی شد (Masto et al., 2008).

برای مجموعه TDS، وزن هر ویژگی بر اساس سهم مشترک (COM) حاصل از تحلیل عاملی (FA) و نسبت سهم هر ویژگی به مجموع سهم کل ویژگی ها محاسبه شد (Shukla and Lal, 2006; Huang et al., 2021).

محاسبه شاخص های کیفیت خاک

در نهایت، شاخص کیفیت خاک برای هر نمونه با استفاده از شاخص تجمعی وزن دار (SQI_w) محاسبه شد (Doran and Parkin, 1994):

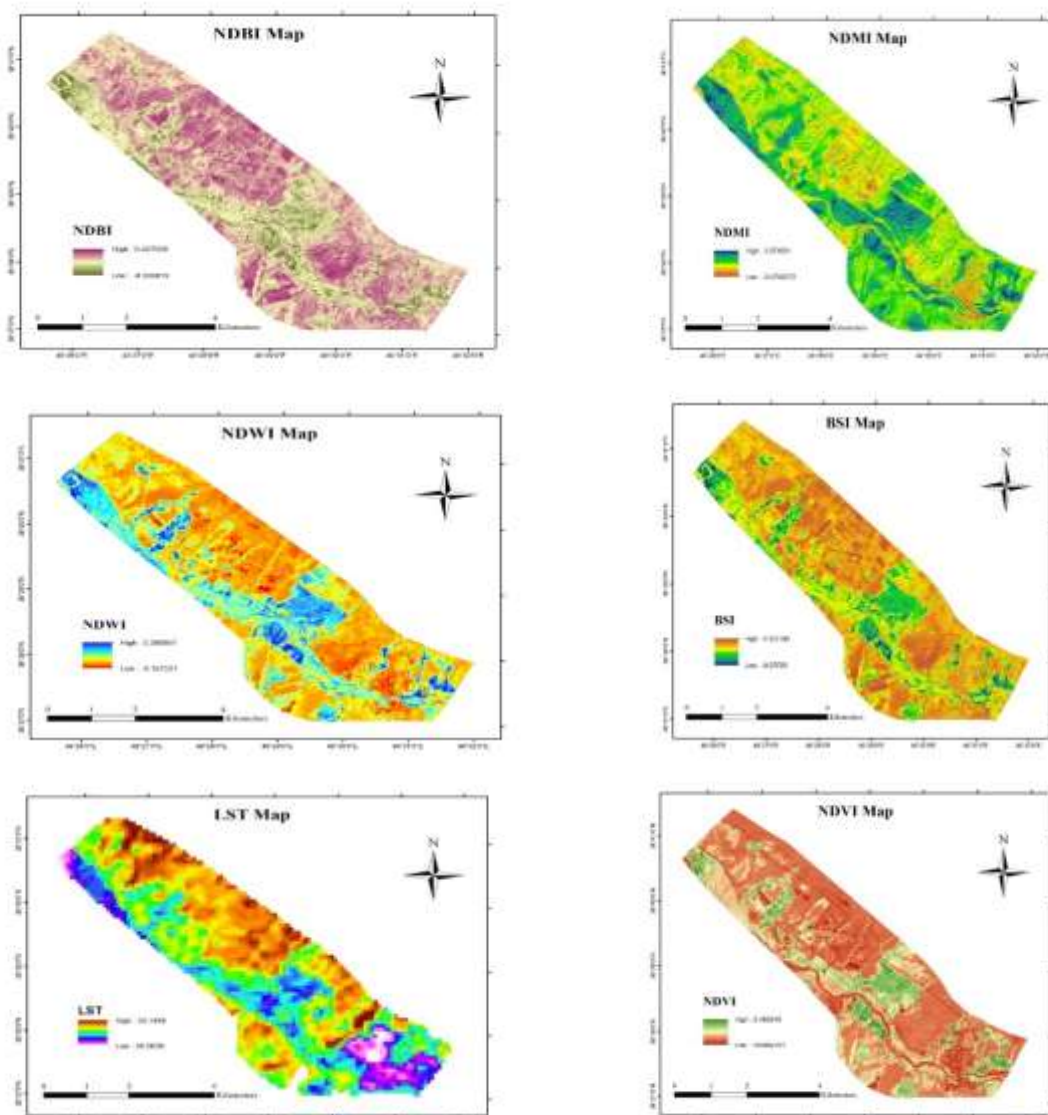
$$SQI_w = \sum_{i=1}^n W_i N_i \quad \text{رابطه (۳)}$$

در این رابطه W_i وزن تعلق یافته به هر ویژگی خاک، N_i مقدار تعلق یافته به هر ویژگی و n تعداد ویژگی های مورد نظر است.

مدل‌سازی کیفیت خاک با استفاده از متغیرهای محیطی

استخراج شاخص‌های طیفی و داده‌های ماهواره‌ای

به منظور استخراج داده‌های طیفی، از تصاویر ماهواره‌ای سنتینل ۲ استفاده شد که به دلیل قدرت تفکیک مکانی و طیفی مناسب، در برآورد ویژگی‌های پوشش زمین، تغییرات کاربری اراضی و شاخص‌های زیست‌محیطی کاربرد گسترده‌ای دارند (Dindaroglu et al., 2022). در این پژوهش تصاویر سری زمانی سال هدف (۲۰۲۴) از محیط گوگل ارث انجین^۱ (GEE) دریافت و پس از اعمال تصحیحات رادیومتریک، اتمسفری و فیلتر ابر، شاخص‌های طیفی مورد نیاز شامل شاخص تفاوت نرمال شده پوشش گیاهی (NDVI)، شاخص تفاوت نرمال شده آب (NDWI)، شاخص اختلاف رطوبت نرمال شده (NDMI)، شاخص تفاوت نرمال شده مناطق ساخته شده (NDBI)^۲ و شاخص خاک برهنه^۳ (BSI) محاسبه شدند (جدول ۱ و شکل ۲). علاوه بر شاخص‌های طیفی، دمای سطح زمین^۴ (LST) به عنوان یکی از پارامترهای کلیدی محیطی استخراج شد. LST بیانگر شرایط حرارتی سطح زمین بوده و نقش مهمی در فرآیندهایی نظیر رطوبت خاک، تبخیر-تعرق، فعالیت میکروبی و پایداری مواد آلی ایفا می‌کند (Li et al., 2022).



شکل ۲. نقشه متغیرهای محیطی منطقه مورد مطالعه

1. Google Earth Engine
2. Normalized Difference Built-up Index
3. Bare Soil Index
4. Land Surface Temperature

جدول ۱. شاخص‌های طیفی مورد استفاده در این پژوهش

indicates	Acronyms	Formulas
Normalised Difference Vegetation Index	NDVI	$(NIR - Red) / (NIR + Red)$
Normalised Difference Water Index	NDWI	$(Green - NIR) / (Green + NIR)$
Normalised Difference Moisture Index	NDMI	$(NIR - SWIR) / (NIR + SWIR)$
Normalised Difference Built-Up Index	NDBI	$(SWIR - NIR) / (SWIR + NIR)$
Bare Soil Index	BSI	$((Red + SWIR) - (NIR + Blue)) / ((Red + SWIR) + (NIR + Blue))$

تشکیل پایگاه داده و مدل‌سازی پیش‌بینی شاخص‌های کیفیت خاک

کلیه داده‌های خاک و شاخص‌های طیفی در قالب یک پایگاه داده مکانی یکپارچه سازمان‌دهی شدند. مطابق با اندازه پیکسل پیشنهادی برای نقشه‌برداری نیمه‌تفصیلی (McBratney et al., 2003)، تمامی متغیرهای محیطی به نقشه‌های رستری با قدرت تفکیک مکانی ۳۰ متر تبدیل شدند و مقادیر آن‌ها برای نقاط نمونه‌برداری خاک استخراج گردید.

در مرحله بعد، پس از آماده‌سازی داده‌های خاک و متغیرهای محیطی، طراحی، کالیبراسیون و اجرای مدل‌های پیش‌بینی مبتنی بر روابط خاک-زمین‌نما انجام شد. به‌منظور شناسایی مؤثرترین پیش‌بینی‌کننده‌ها و افزایش قابلیت تفسیر نتایج، از الگوریتم‌های یادگیری ماشین شامل جنگل تصادفی (RF) و رگرسیون خطی چندگانه (MLR) استفاده گردید (Shafizadeh-Moghadam et al., 2022). در فرآیند مدل‌سازی، مقادیر شاخص کیفیت خاک محاسبه‌شده برای هر نقطه نمونه‌برداری به‌عنوان متغیر وابسته متغیرهای محیطی به‌عنوان متغیرهای مستقل به مدل‌ها وارد شدند. سپس بر اساس روابط استخراج‌شده، پیش‌بینی مکانی شاخص‌های کیفیت خاک انجام و نقشه‌های رقمی مربوطه تهیه گردید. کلیه مراحل مدل‌سازی در محیط نرم‌افزار R و با استفاده از بسته‌های نرم‌افزاری موجود در آن انجام شد.

ارزیابی صحت مدل‌ها

به‌منظور ارزیابی دقت و مقایسه عملکرد مدل‌ها، داده‌ها به‌صورت تصادفی به دو بخش آموزش (۷۰ درصد) و اعتبارسنجی (۳۰ درصد) تقسیم شدند. مدل‌ها با داده‌های آموزشی آموزش داده شده و صحت پیش‌بینی آن‌ها با استفاده از داده‌های اعتبارسنجی بررسی گردید.

ارزیابی عملکرد مدل‌ها با استفاده از شاخص‌های آماری شامل ضریب تعیین (R^2) و جذر میانگین مربعات خطا (RMSE) انجام شد:

$$RMSE = \sqrt{(1/n) * \sum (y_i - \hat{y}_i)^2} \quad \text{رابطه (۴)}$$

$$R^2 = 1 - (\sum (y_i - \hat{y}_i)^2) / (\sum (y_i - \bar{y})^2) \quad \text{رابطه (۵)}$$

در این روابط \hat{y}_i و y_i مقادیر پیش‌بینی شده و واقعی، \bar{y} و $Oava$ میانگین مقادیر پیش‌بینی شده و واقعی و n تعداد مشاهدات می‌باشد. به‌طور کلی، مقادیر کمتر RMSE و مقادیر بالاتر R^2 نشان‌دهنده دقت بالاتر مدل در پیش‌بینی شاخص‌های کیفیت خاک بوده و بر این اساس بهترین مدل برای تهیه نقشه نهایی انتخاب شد.

نتیجه و بحث

تجزیه به مولفه‌های اصلی

نتایج شاخص‌های ارزیابی شده برای مجموعه حداقل داده‌ها بر اساس تحلیل همبستگی و تحلیل مؤلفه‌های اصلی با استفاده از روش چرخش واریانس در جدول (۲) نشان داده شده است. در تحلیل مؤلفه‌های اصلی، پنج مولفه اول با مقدار ویژه بیشتر از یک محاسبه شد که ۹۰٪/۸۸ از تغییرات داده‌های اصلی را توضیح دادند و می‌توانند برای تعیین MDS استفاده شوند. هریک از این پنج مولفه به ترتیب ۴۰/۳۱، ۱۹/۱۷، ۱۶/۷۳، ۷/۹۸ و ۶/۶۸ درصد از واریانس کل را توجیه می‌کنند، در حالی که مولفه‌های باقی‌مانده واریانس نسبتاً کوچک‌تری دارند و در توضیح میزان تغییرات مشارکت بسیار کمی دارند (جدول ۲). بردارهای ویژه پس از چرخش واریانس نشان دادند که در مولفه اول

درصد کربن آلی، ذخیره کربن، نیتروژن کل و ضریب متابولیک دارای وزن زیادی هستند و همه آن‌ها همبستگی قابل توجهی ($r > 0.6$) با یکدیگر داشتند (جدول ۲)، بنابراین آن‌ها به‌عنوان متغیرهای تکراری در نظر گرفته شدند و از بین آن‌ها فقط کربن آلی به‌عنوان MDS انتخاب شد. در مولفه دوم جرم مخصوص ظاهری به‌عنوان ویژگی با بیشترین وزن انتخاب شد (جدول ۲). در مولفه سوم فسفر و منیزیم به‌عنوان ویژگی‌هایی با بیشترین وزن انتخاب شدند. اگرچه این ویژگی‌ها دارای همبستگی بالایی با یکدیگر بودند ($r > 0.6$)، اما به‌دلیل این‌که هر یک از آن‌ها از عوامل مهم اثرگذار بر کیفیت خاک بودند، هر دو ویژگی به‌عنوان MDS در نظر گرفته شدند (جدول‌های ۲ و ۳). در مولفه چهارم پتاسیم قابل جذب و در مولفه پنجم نیز اسیدیت به‌عنوان MDS در نظر گرفته شدند (جدول ۲).

بررسی پژوهش‌های پیشین نشان می‌دهد که مجموعه حداقل داده‌ها برای ارزیابی کیفیت خاک، وابستگی بالایی به شرایط اقلیمی، مدیریتی و کاربری اراضی دارد و از منطقه‌ای به منطقه دیگر متفاوت است. به‌عنوان نمونه، در پژوهشی با هدف تعیین کیفیت خاک در منطقه سی‌دشت استان گیلان درصد رس، درصد سیلت، جرم مخصوص ظاهری، کربن آلی، فسفر قابل دسترس و واکنش خاک را به‌عنوان مجموعه حداقل داده‌ها معرفی شده است (سمیع خشک اسطلخی و همکاران، ۱۴۰۴) اما در پژوهشی مشابه در دشت نیشابور، شاخص‌هایی نظیر قابلیت هدایت الکتریکی، ماده آلی، فسفر و پتاسیم قابل استفاده و نیتروژن کل بیشترین نقش را در تبیین تغییرات کیفیت داشتند (مقامی مقیم و همکاران، ۱۴۰۲).

وزن ویژگی‌های خاک نیز برای دو مجموعه TDS و MDS در جدول ۲ نشان داده شده است. نتایج نشان داد که کربن آلی بالاترین وزن (۰/۰۴۳) و کلسیم کمترین وزن (۰/۰۲۶) را در مجموعه TDS دارد. همچنین، کربن آلی و اسیدیت به ترتیب بالاترین (۰/۴۰۳) و پایین‌ترین (۰/۰۶۷) وزن را در مجموعه MDS دارند. این نتایج تأیید می‌کند که کربن آلی بیشترین تأثیر را در مقایسه با سایر عوامل بر TDS و MDS دارد.

جدول ۲. ارزش ویژه به دست آمده از طریق تجزیه به مولفه‌های اصلی

متغیرها	مولفه ۱	مولفه ۲	مولفه ۳	مولفه ۴	مولفه ۵
ارزش ویژه	۹/۲۱۲	۴/۴۱	۳/۱۴۹	۱/۱۲۵	۱/۵۲۸
درصد واریانس	۴۰/۳۱۳	۱۹/۱۷۳	۱۶/۷۳۵	۷/۹۸	۶/۶۸۹
درصد واریانس تجمعی	۴۰/۳۱۳	۵۹/۴۸۶	۷۶/۲۲	۸۴/۲	۹۰/۸۸۹
رس	-۰/۶۳۵	۰/۶۴۲	-۰/۳۱۹	۰/۲۰۱	-۰/۳۶۴
سیلت	-۰/۵۶۴	۰/۳۱۹	۰/۵۰۱	-۰/۳۷۶	-۰/۸۴۶
شن	۰/۸۱۹	-۰/۵۲	-۰/۳۲۲	-۰/۵۷۶	-۰/۳۹۹
رس قابل انتشار در آب	-۰/۵۵۴	۰/۶۳۸	-۰/۴۹۷	-۰/۳۶۷	-۰/۳۹۶
جرم مخصوص ظاهری	-۰/۴۵۸	-۰/۸۲۸	-۰/۳۴۳	۰/۴۱۲	-۰/۲۳۶
میانگین ورنی قطر خاکدانه	۰/۵۷۶	۰/۳۸۳	-۰/۴۳۹	-۰/۴۳۲	-۰/۳۵۸
کربن آلی	۰/۹۲۷	۰/۴۴۶	-۰/۲۱۸	-۰/۴۷۶	۰/۲۱۹
ذخیره کربن	-۰/۹۲۵	۰/۳۶۱	۰/۳۱۵	-۰/۳۳۶	-۰/۴۷۱
نیتروژن کل	-۰/۸۴۹	۰/۳۴۳	-۰/۴۱۱	-۰/۳۹۵	-۰/۴۴۳
فسفر قابل جذب	۰/۳۹۹	۰/۳۲۷	-۰/۷۴۶	-۰/۴۲۳	۰/۲۰۷
پتاسیم قابل جذب	-۰/۳۰۲	۰/۳۲۹	-۰/۵۱۷	۰/۶۲۲	۰/۴۰۴
سدیم	۰/۶۷۵	۰/۴۷۶	-۰/۳۸۵	۰/۵۳۹	۰/۲۲۵
کلسیم	۰/۳۲۲	-۰/۱۱۹	۰/۶۴۹	۰/۱۱۱	-۰/۴۲۲
منیزیم	-۰/۵۵۷	-۰/۲۲۸	-۰/۷۰۵	۰/۴۸۶	-۰/۳۸۸
نسبت جذب سدیم	-۰/۲۱۸	۰/۳۶۲	۰/۶۳۶	-۰/۴۶۴	-۰/۴۷۴
کربنات کلسیم معادل	-۰/۴۳۲	-۰/۶۱۷	۰/۵۹۴	۰/۴۲۵	-۰/۳۳۵
واکنش خاک	-۰/۳۴۶	۰/۲۱۱	۰/۳۸۱	-۰/۳۴۱	۰/۶۸
قابلیت هدایت الکتریکی	۰/۷۴۲	۰/۴۵۴	۰/۵۴۶	-۰/۳۹۹	-۰/۱۱۹
ظرفیت تبادل کاتیونی	-۰/۵۸	۰/۷۱۲	-۰/۳۰۳	-۰/۲۱۷	۰/۴۱۷
کربن زیست‌توده	۰/۶۳۴	۰/۵۸۹	۰/۴۴۶	۰/۲۶۳	-۰/۳۲۵
تنفس میکروبی	۰/۷۷۴	۰/۵۷۲	۰/۲۶۶	-۰/۴۱۷	-۰/۳۹۶
ضریب متابولیک	-۰/۹۰۶	-۰/۵۹۸	-۰/۳۶۵	۰/۲۲۸	-۰/۳۴۷
نسبت میکروبی	۰/۷۹۱	۰/۴۴۴	-۰/۲۴۴	-۰/۱۹۸	-۰/۳۷۷

اعداد برجسته (بولد) به‌عنوان بیشترین وزن در نظر گرفته شدند و اعدادی که زیر آن‌ها خط کشیده شده است به‌عنوان MDS انتخاب شده‌اند. اعداد برجسته و ایتالیک مولفه‌های انتخاب شده را نشان می‌دهند.

جدول ۳. همبستگی بین ویژگی‌های دارای بیشترین وزن

ذخیره کربن	نسبت میکروبی	منیزیم	پتاسیم قابل جذب	فسفر قابل جذب	واکنش خاک	نیترژن کل	کربن آلی	جرم مخصوص ظاهری
۱								۱
	۱						۰/۰۳	کربن آلی
		۱				۱	*۰/۹۲	نیترژن کل
				۱	۱	۰/۲۳-	۰/۱۸-	واکنش خاک
					۱	۰/۱۱	۰/۲۴	فسفر قابل جذب
			۱	۰/۲۰-	۰/۰۸	۰/۳۴	۰/۳۱	پتاسیم قابل جذب
		۱	۰/۰۴	*۰/۷۱	*۰/۶۵-	۰/۲۸	۰/۳۲۴	منیزیم
	۱	۰/۲۸-	۰/۲۵-	۰/۱۱-	۰/۲۰	*۰/۹۴-	*۰/۷۶-	نسبت میکروبی
۱	*۰/۸۳-	۰/۴۵	۰/۲۴	۰/۴۲	۰/۱۷-	*۰/۹۲	*۰/۹۶	ذخیره کربن

* نشان‌دهنده تفاوت معنی‌دار در سطح احتمال ۰/۰۵ است.

شاخص‌های کیفیت خاک

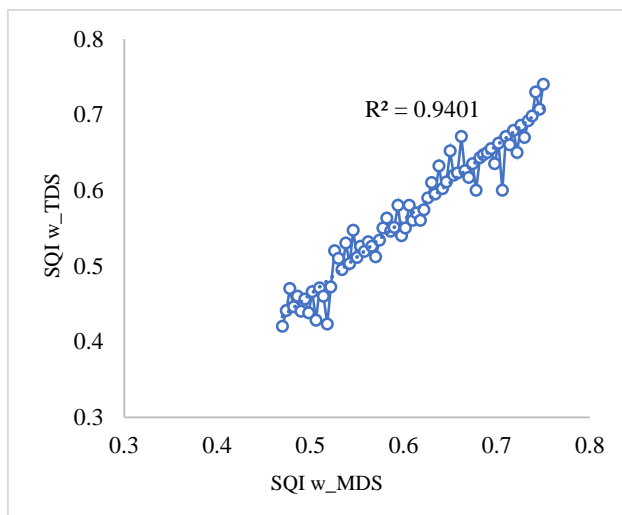
نتایج نشان می‌دهد که شاخص کیفیت خاک محاسبه‌شده با استفاده از رویکرد مجموعه داده کامل دارای میانگین بالاتری (۰/۶۱) نسبت به رویکرد حداقل مجموعه داده (۰/۵۶) است که بیانگر توان بیشتر TDS در بازنمایی جامع وضعیت کیفیت خاک از طریق در نظر گرفتن طیف کامل تری از شاخص‌های فیزیکی، شیمیایی و زیستی می‌باشد (جدول ۴). با این حال، همخوانی نسبی مقادیر شاخص کیفیت خاک در دو رویکرد نشان می‌دهد که کاهش تعداد شاخص‌ها در روش MDS منجر به افت قابل توجهی در دقت برآورد کیفیت خاک نمی‌شود. از سوی دیگر، دامنه تغییرات وسیع‌تر SQI در روش MDS (۰/۳۴ تا ۰/۷۸) در مقایسه با TDS (۰/۴۷ تا ۰/۷۵) بیانگر حساسیت بالاتر این رویکرد در تفکیک مکانی سطوح مختلف کیفیت خاک و شناسایی نواحی دارای محدودیت‌های شدیدتر است؛ به‌ویژه آنکه کاهش مقدار حداقل SQI در MDS نشان می‌دهد انتخاب شاخص‌های کلیدی از طریق روش‌های آماری مانند تحلیل مؤلفه‌های اصلی، موجب برجسته شدن عوامل محدودکننده اصلی کیفیت خاک می‌شود. به‌طور کلی، نتایج این مطالعه حاکی از آن است که اگرچه رویکرد TDS برای ارزیابی جامع و دقیق کیفیت خاک مناسب‌تر است، رویکرد MDS با حفظ دقت قابل قبول، توان تفکیک‌پذیری بالاتر و صرفه‌جویی در زمان و هزینه، می‌تواند به‌عنوان جایگزینی کارآمد و کاربردی برای پایش کیفیت خاک و پشتیبانی از تصمیم‌گیری در مدیریت پایدار اراضی مورد استفاده قرار گیرد (Hemmati et al., 2023).

جدول ۴. مقادیر شاخص‌های کیفیت خاک

SQI	Mean	Min	Max
SQI _{w_TDS}	۰/۶۱	۰/۴۷	۰/۷۵
SQI _{w_MDS}	۰/۵۶	۰/۳۴	۰/۷۸

همبستگی بین شاخص‌های کیفیت خاک با مجموعه کامل و حداقل داده‌ها

نتایج حاصل از تحلیل رگرسیونی نشان می‌دهند که ارتباط قوی و معنی‌داری بین روش‌های مختلف محاسبه شاخص کیفیت خاک وجود دارد. ضریب تبیین بین دو مجموعه TDS و MDS برابر ۰/۹۴ است (شکل ۳). این ضریب نشان می‌دهد که با اطمینان ۰/۹۴ می‌توان از مجموعه MDS به‌جای TDS استفاده نمود. این موضوع بیانگر آن است که روش MDS، با وجود استفاده از تعداد متغیرهای کمتر، قادر است نتایج قابل اعتمادی ارائه دهد و به‌عنوان جایگزینی برای روش TDS در مطالعات ارزیابی کیفیت خاک به کار گرفته شود. این کار علاوه بر صرفه‌جویی در زمان موجب کاهش هزینه در مطالعات می‌شود (Nabiollahi et al., 2018; Zeraatpisheh et al., 2020). در واقع به رغم آن که روش انتخاب معیار TDS تمامی پارامترهای خاک را لحاظ نموده و نتایج بسیار قابل قبولی را ارائه می‌دهد، به منظور تسهیل در پژوهش انتخاب معیار MDS پیشنهاد می‌شود زیرا ضمن بهره‌گیری از ویژگی‌های کمتر، نتایجی مشابه روش TDS را نشان می‌دهد.



شکل ۳. بررسی ارتباط بین شاخص‌های مختلف کیفیت خاک

کلاس‌بندی کیفیت خاک

شاخص‌های کیفیت خاک مطابق طبقه‌بندی کیفیت خاک به روش کی و همکاران (۲۰۰۹) (جدول ۵) که SQI را در دامنه صفر تا ۱ نمره‌دهی می‌کند و معمولاً به چهار کلاس کلی تقسیم می‌شود (کلاس I: عالی، کلاس II: خوب، کلاس III: متوسط، و کلاس IV: ضعیف)، طبقه‌بندی شدند.

جدول ۵. درجه بندی کیفیت خاک در دو روش TDS و MDS

SQI Model	Indicator Method	SQI Grade			
		I	II	III	IV
IQI	TDS	$IQI_{TDS} > 0.76$	$0.76 > IQI_{TDS} > 0.66$	$0.66 > IQI_{TDS} > 0.56$	$0.56 > IQI_{TDS}$
	MDS	$IQI_{MDS} > 0.78$	$0.78 > IQI_{MDS} > 0.68$	$0.68 > IQI_{MDS} > 0.58$	$0.58 > IQI_{MDS}$

همان‌طور که در جدول ۴ مشاهده شد، مقادیر کیفیت خاک با استفاده از مدل SQI w_TDS بین ۰/۴۷ تا ۰/۷۵ و با استفاده از مدل SQI w_MDS بین ۰/۳۴ تا ۰/۷۸ متغیر است. بر اساس کلاس‌بندی کیفیت خاک (Qi et al., 2009)، این مقادیر بین کلاس‌های II تا IV قرار می‌گیرند (جدول ۶). نتایج نشان داد با استفاده از روش TDS، تقریباً ۱۶/۸ درصد از اراضی منطقه مطالعاتی در کلاس II، ۳۸/۶۲ درصد در کلاس III و ۴۴/۵۸ درصد در کلاس IV قرار می‌گیرد. همچنین مشاهده شد با استفاده از روش MDS، ۱۴ درصد از اراضی منطقه مطالعاتی در کلاس II، ۳۲/۳۴ درصد در کلاس III، و ۵۳/۶۴ درصد در کلاس IV قرار گرفته است (جدول ۵).

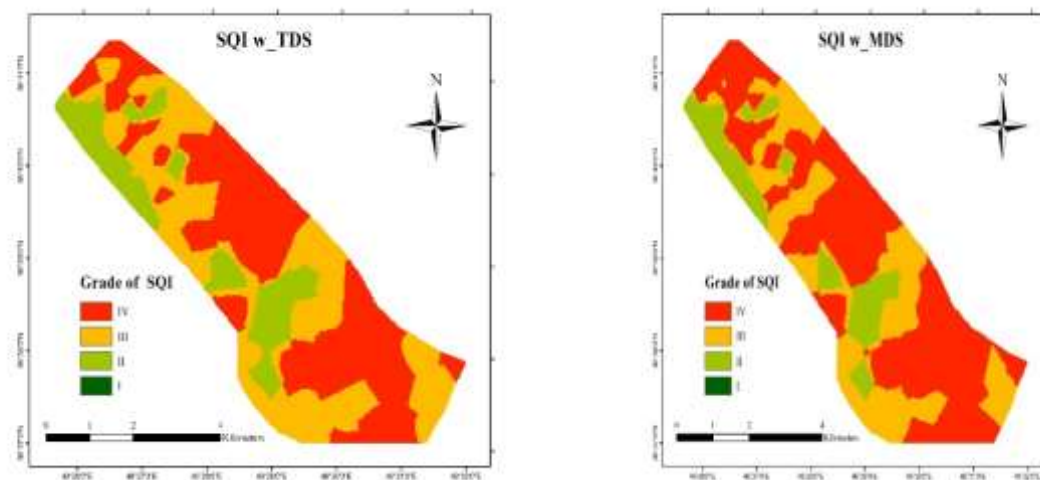
جدول ۶. تقسیم‌بندی درجه کیفیت خاک در مدل‌های مختلف

GRADE	SQI w_TDS (ha)	SQI w_TDS (%)	SQI w_MDS (ha)	SQI w_MDS (%)
I	*	*	*	*
II	۴۸۵/۹۶	۱۶/۸	۴۱۳/۱۳	۱۴
III	۱۱۱۷/۵۱	۳۸/۶۲	۹۵۲/۹۱	۳۲/۳۴
IV	۱۲۸۹/۶۵	۴۴/۵۸	۱۵۸۰/۴۸	۵۳/۶۴

نقشه توزیع مکانی شاخص‌های کیفیت خاک در شکل ۴ نشان داده شده است. بررسی همزمان نقشه شاخص‌های کیفیت خاک به‌دست آمده برای منطقه مورد مطالعه و نقشه کاربری اراضی نشان داد که بخش عمده اراضی این منطقه به‌طور کلی در کلاس‌های کیفیت متوسط تا ضعیف (کلاس‌های III و IV) قرار دارند. در مقابل، اراضی تحت کاربری زیتون‌کاری، به‌ویژه در مناطق کم‌شیب و بخش‌های

پایین دست حوضه، از کیفیت خاک خوب برخوردار هستند (شکل ۴). این نتایج بیانگر نقش تعیین کننده پوشش گیاهی و کاربری های پایدار زمین، نظیر زیتون کاری، در بهبود و حفظ کیفیت خاک می باشد. در مقابل، بهره برداری های ناپایدار، مدیریت نامناسب اراضی و بی توجهی به عامل شیب زمین، موجب تشدید فرسایش خاک و در نهایت کاهش کیفیت آن شده است. بر این اساس، به کارگیری راهبردهای مدیریتی مبتنی بر اصول اکولوژیکی و استفاده از ابزارهای نوین، از جمله مدل سازی و نقشه برداری دیجیتال خاک، به عنوان رویکردهایی کارآمد برای حفاظت از سلامت خاک و دستیابی به پایداری نظام های کشاورزی، امری ضروری به نظر می رسد.

علاوه بر این، اختلاف ناچیز بین مساحت اراضی تحت کلاس های مختلف کیفیت خاک با استفاده از دو مجموعه TDS و MDS نشان داد که روش های مبتنی بر مجموعه داده حداقل، با وجود کاهش تعداد متغیرهای ورودی، توانسته اند با دقت قابل قبولی الگوی توزیع مکانی کیفیت خاک را بازتاب دهند (جدول ۶ و شکل ۴). این یافته ها کارایی روش MDS را به عنوان گزینه ای اقتصادی، کارآمد و عملی برای پایش و ارزیابی کیفیت خاک در مقیاس های وسیع تأیید می کند (Andrews et al., 2004; Rahmanipour et al., 2014).



شکل ۴. نقشه شاخص های کیفیت خاک طبقه بندی شده بر اساس روش کای و همکاران (۲۰۰۹)

مدل سازی شاخص های کیفیت خاک با استفاده از متغیرهای محیطی

مقایسه ارزیابی عملکرد مدل ها

کیفیت خاک با استفاده از شاخص های طیفی و عوامل محیطی (شکل ۲)، توسط مدل های جنگل تصادفی و رگرسیون خطی چندمتغیره، مدل سازی شد (شکل ۵). نتایج نشان می دهد که در هر دو شاخص SQI_{w_TDS} و SQI_{w_MDS} ، مدل جنگل تصادفی نسبت به رگرسیون خطی چندمتغیره از عملکرد بهتری برخوردار است، به طوری که مقادیر RMSE کمتر و R^2 بالاتری را در مراحل مدل سازی و برآورد ارائه کرده است (جدول ۷).

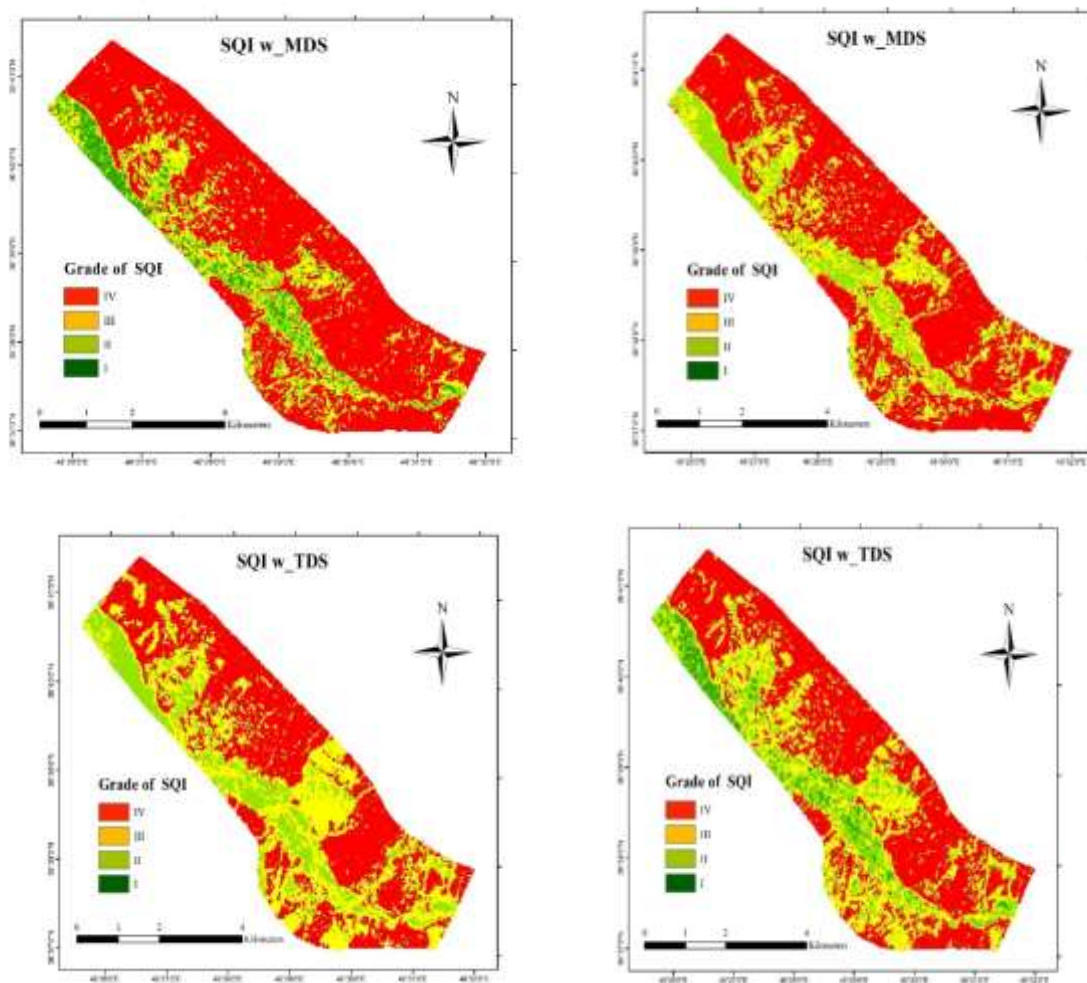
به طور مشخص، در سناریوی SQI_{w_MDS} ، مدل جنگل تصادفی مقدار R^2 برابر با ۰/۷۴ در مرحله مدل سازی و ۰/۷۲ در مرحله برآورد را نشان داده است که حاکی از قدرت تبیین مناسب این مدل در پیش بینی شاخص کیفیت خاک است. در مقابل، مدل رگرسیون خطی چندمتغیره در هر دو شاخص عملکرد ضعیف تری داشته و در هیچ یک از سناریوها مقدار R^2 بالاتر از ۰/۵۵ را کسب نکرده است. ضعیف ترین عملکرد این مدل مربوط به سناریوی SQI_{w_TDS} در مرحله برآورد مشاهده شد، به طوری که مقدار RMSE به عدد ۰/۰۸۹ افزایش یافته که نشان دهنده خطای پیش بینی نسبتاً بالا می باشد.

برتری مدل جنگل تصادفی را می توان به ماهیت غیرخطی و ساختار انعطاف پذیر این الگوریتم نسبت داد که امکان مدل سازی روابط پیچیده و تعاملات بین متغیرهای ورودی را فراهم می کند (Li et al., 2004). در مقابل، رگرسیون خطی چندمتغیره بر فرض وجود روابط خطی بین متغیرهای مستقل و وابسته استوار است و در نتیجه، توانایی محدودی در بازنمایی پیچیدگی ذاتی کیفیت خاک دارد. این یافته با مطالعات پیشین هم خوانی دارد که کیفیت خاک را پدیده ای چندعاملی، غیرخطی و متأثر از برهم کنش عوامل مختلفی نظیر ویژگی های فیزیکی و شیمیایی خاک، شرایط توپوگرافی، پوشش گیاهی، مدیریت زراعی و اقلیم معرفی کرده اند (Hu et al., 2025; Metwaly et al., 2025).

این یافته‌ها بیانگر نقش تعیین‌کننده شاخص‌های طیفی در تبیین و پیش‌بینی کیفیت خاک در منطقه مورد مطالعه است. از منظر کاربردی، به‌کارگیری مدل‌های پیشرفته‌ای همچون جنگل تصادفی می‌تواند مزایای قابل‌توجهی در برنامه‌ریزی‌های حفاظت خاک، ارزیابی پایداری اراضی و کشاورزی دقیق به همراه داشته باشد. این مدل نه تنها توانایی تحلیل داده‌های بزرگ و پیچیده را دارد، بلکه قادر است به‌طور خودکار متغیرهای کلیدی را شناسایی کرده و تعامل‌های غیرخطی بین آن‌ها را مدل‌سازی کند. در مقابل، مدل رگرسیون خطی چندمتغیره بیشتر برای تحلیل‌های مقدماتی و ساده مناسب است و برای کاربردهای مدیریتی و تصمیم‌گیری‌های مبتنی بر داده‌های پیچیده، کارایی محدودی دارد. در نهایت، انتخاب مدل مناسب باید بر اساس ماهیت داده‌ها، هدف مدل‌سازی و منابع در دسترس انجام گیرد؛ با این حال، بر پایه شواهد عددی و نتایج این پژوهش، مدل جنگل تصادفی می‌تواند برای پیش‌بینی کیفیت خاک در منطقه مورد مطالعه استفاده شود.

جدول ۷. مقایسه عملکرد مدل‌های یادگیری ماشین و رگرسیون خطی در برآورد شاخص‌های کیفیت خاک

شاخص	مدل	مدل‌سازی		برآورد	
		R ²	RMSE	R ²	RMSE
_TDS w_SQI	رگرسیون خطی چند متغیره	۰/۵۲	۰/۰۸۳	۰/۵۵	۰/۰۸۹
	جنگل تصادفی	۰/۷۶	۰/۰۵۰	۰/۷۰	۰/۰۶۵
MDS w_SQI	رگرسیون خطی چند متغیره	۰/۵۵	۰/۰۸۰	۰/۵۷	۰/۰۸۵
	جنگل تصادفی	۰/۷۴	۰/۰۵۳	۰/۷۲	۰/۰۵۸




شکل ۵. مدل‌سازی شاخص کیفیت خاک با استفاده از الگوریتم‌های MLR (شکل‌های a و b) و RF (شکل‌های c و d)

مهم‌ترین عوامل محیطی موثر بر کیفیت خاک با استفاده از مدل RF

نتایج نشان می‌دهد متغیرهای محیطی شامل NDVI، NDWI، BSI، NDMI، NDBI و LST به ترتیب با ۰/۲۷، ۰/۲۵، ۰/۱۸، ۰/۱۷، ۰/۱۱ و ۰/۰۴ درصد در روش TDS و با ۰/۲۶، ۰/۲۵، ۰/۲۷، ۰/۱۸، ۰/۱۵، ۰/۱۲ و ۰/۰۹ درصد در روش MDS، در برآورد کیفیت خاک اثرگذار بودند (شکل ۵). بنابراین می‌توان اعلام نمود متغیرهای محیطی شامل NDVI، NDWI، BSI و NDMI به ترتیب مهم‌ترین عوامل محیطی موثر بر کیفیت خاک با استفاده از مدل جنگل تصادفی برآورد شدند و می‌توان از آن‌ها به‌عنوان متغیر کمکی برای تعیین شاخص کیفیت خاک در منطقه مورد مطالعه استفاده نمود.

استفاده از شاخص‌های طیفی در پردازش تصاویر ماهواره‌ای بسیار مهم است. آن‌ها می‌توانند با بهینه‌سازی اختلاف بازتاب بین سطوح آب و زمین، تشخیص و تجزیه و تحلیل ویژگی‌های خاص پوشش زمین را بهبود بخشند. نتایج مطالعات اخیر نیز نشان داده است که ارتباط قابل توجهی بین شاخص‌های طیفی و ویژگی‌های موثر بر کیفیت خاک وجود دارد و شاخص‌هایی نظیر NDVI، BSI و NDMI به‌عنوان متغیرهای محیطی مهم و اثرگذار بر کیفیت خاک معرفی شده‌اند (Tudorescu et al., 2024; Zeraatpisheh et al., 2022; Yang et al., 2020). برای نمونه Yang et al., (2020) به منظور نقشه‌برداری توزیع مکانی محتوای کربن آلی خاک از متغیرهای کمکی محیطی استفاده نمودند و از مدل جنگل تصادفی برای تعیین متغیرهای پیش‌بینی‌کننده مهم و موثر برای پیش‌بینی کربن آلی خاک سطحی استفاده کردند. نتایج پیش‌بینی با استفاده از رویکرد اعتبارسنجی متقابل نشان داد NDVI جزء شاخص‌های کلیدی در تحلیل کیفیت خاک، سلامت گیاهی و توان اکولوژیکی است و نقش مهمی در مدل‌های پیش‌بینی عملکرد اکوسیستم دارد. همچنین تحقیقات میدانی و مطالعات نقشه‌برداری خاک نشان داده‌اند که ارتباط قابل توجهی بین BSI و ویژگی‌های موثر بر کیفیت خاک وجود دارد و به‌طور مشخص، SOC با افزایش NDVI افزایش و با افزایش BSI کاهش می‌یابد (Tudorescu et al., 2024).



شکل ۶. متغیرهای محیطی موثر بر کیفیت خاک با استفاده از مدل جنگل تصادفی

نتیجه‌گیری کلی

نتایج این پژوهش نشان داد که کیفیت خاک در منطقه مورد مطالعه تحت تأثیر همزمان عوامل فیزیکی، شیمیایی، زیستی و شرایط محیطی قرار دارد و الگوی توزیع مکانی آن به‌شدت ناهمگن است. مقایسه دو رویکرد مجموعه داده کامل و مجموعه حداقل داده بیانگر آن بود که اگرچه روش TDS به دلیل در نظر گرفتن طیف وسیع‌تری از شاخص‌ها، تصویر جامع‌تری از وضعیت کیفیت خاک ارائه می‌دهد، اما روش MDS نیز با کاهش چشمگیر تعداد متغیرها، توانست با دقت قابل قبول و همبستگی بسیار بالا با TDS، الگوی مکانی کیفیت خاک را بازنمایی کند. این موضوع کارایی روش MDS را به‌عنوان رویکردی اقتصادی، سریع و کاربردی برای پایش کیفیت خاک در مقیاس‌های منطقه‌ای تأیید می‌کند. نتایج مدل‌سازی نشان داد که الگوریتم جنگل تصادفی نسبت به رگرسیون خطی چندمتغیره از توان پیش‌بینی بالاتری برخوردار است که بیانگر ماهیت غیرخطی، پیچیده و چندعاملی فرآیندهای کنترل‌کننده کیفیت خاک می‌باشد. شناسایی شاخص‌های طیفی NDVI، NDWI، BSI و NDMI به‌عنوان مهم‌ترین متغیرهای محیطی مؤثر بر کیفیت خاک، نقش کلیدی شرایط رطوبتی، پوشش گیاهی و میزان بهره‌نگی سطح خاک را در شکل‌گیری الگوی کیفیت خاک برجسته می‌سازد. نتایج مکانی شاخص کیفیت خاک نشان داد بخش قابل توجهی از اراضی منطقه در کلاس‌های کیفیت متوسط تا ضعیف قرار دارند، در حالی که کاربری‌های پایدار نظیر باغ‌های زیتون از کیفیت خاک مطلوب‌تری برخوردارند. بر این اساس، تلفیق شاخص کیفیت خاک با داده‌های سنسور از دور و مدل‌های یادگیری ماشین می‌تواند به‌عنوان ابزاری کارآمد برای برنامه‌ریزی مدیریت پایدار اراضی، کاهش تخریب خاک، افزایش بهره‌وری کشاورزی و حمایت از

تصمیم‌گیری‌های مبتنی بر داده در مقیاس منطقه‌ای مورد استفاده قرار گیرد. چنین رویکردی نه تنها امکان پایش مستمر و به‌روز کیفیت خاک را فراهم می‌کند، بلکه می‌تواند به‌طور مستقیم در کاهش فرسایش، بهبود حاصلخیزی و ارتقای امنیت غذایی نقش‌آفرین باشد.

ملاحظات اخلاقی

حامی مالی

حمایت مالی از این پژوهش از طرف دانشگاه زنجان، دانشکده کشاورزی در قالب پژوهانه پایان‌نامه دانشجویی نویسنده اول و همچنین پژوهانه برای سایر نویسندگان انجام شده است.

مشارکت نویسندگان

نویسندگان به‌طور مساوی در کلیه مراحل طراحی و انجام پژوهش، گردآوری داده‌ها، تجزیه و تحلیل آماری داده‌ها، تحلیل و تفسیر اطلاعات و نتایج، تهیه پیش‌نویس مقاله، بررسی و کنترل نتایج، اصلاح، بازبینی و نهایی‌سازی مقاله مشارکت داشتند.

اعلامیه هوش مصنوعی مولد و فناوری‌های مبتنی بر هوش مصنوعی در فرایند نگارش

نویسندگان از ابزارهای هوش مصنوعی برای نگارش این مقاله استفاده ننموده‌اند.

بیانیه دسترسی به داده‌ها

داده‌هایی پژوهش حاضر از طریق درخواست از نویسندگان قابل دسترسی است.

سپاسگزاری

از همه کسانی که ما را در نوشتن این مقاله یاری نمودند، کمال تشکر را داریم.

پیروی از اصول اخلاق پژوهش

نویسندگان اصول اخلاقی را در انجام و انتشار این پژوهش علمی رعایت نموده‌اند و این موضوع مورد تأیید همه آنهاست.

تعارض منافع

بنا بر اظهار نویسندگان این مقاله تعارض منافع ندارد.

منابع

- امامی، نازنین سادات؛ چاوشی، الهام؛ ایوبی، شمس‌الله؛ هنرجو، ناصر و زراعت پیشه، مجتبی (۱۴۰۴). نقشه‌برداری رقومی ویژگی‌های فیزیکی و شیمیایی خاک با استفاده از برخی الگوریتم‌های یادگیری ماشین و متغیرهای محیطی در منطقه فریدن، استان اصفهان. مهندسی زراعی, 48(2), 205-229. doi: 10.22055/agen.2025.48843.1761
- سمیع خشک اسطخعی، فاطمه؛ یغمائیان مهابادی، نفیسه؛ ابریشم کش، سپیده و مصلحت جو، عطاله (۱۴۰۲). ارزیابی روش‌های نمره‌دهی و وزن‌دهی ویژگی‌های خاک برای تعیین کیفیت آن در کاربری‌های مختلف. پژوهش‌های خاک doi: 355-375, 37(4), 10.22092/ijsr.2024.361794.700
- مقامی مقیم، فرشته؛ کریمی، علی رضا؛ باقری بداغ آبادی، محسن و امامی، حجت. (۱۴۰۱). ارزیابی نقش سامانه‌های مدیریتی مختلف بر شاخص کیفیت خاک با استفاده از عملکرد محصول (مطالعه موردی: دشت نیشابور). آب و خاک doi: 95-112, 36(1), 10.22067/jsw.2022.74026.1120

REFERENCES

- Anderson, J. P. (1982). Soil respiration. *Methods of soil analysis: part 2 chemical and microbiological properties*, 9, 831-871.
- Andrews, S. S., Karlen, D. L., & Cambardella, C. A. (2004). The soil management assessment framework: a quantitative soil quality evaluation method. *Soil Science Society of America Journal*, 68(6), 1945-1962.
- Bandyopadhyay, S., & Maiti, S. K. (2021). Different soil factors influencing dehydrogenase activity in mine degraded lands—State-of-art review. *Water, Air, & Soil Pollution*, 232(9), 360.
- Barikloo, A., Alamdari, P., Rezapour, S. and Taghizadeh-Mehrjardi, R., 2024. Digital mapping of soil quality index to evaluate orchard fields using random forest models. *Modeling Earth Systems and Environment*, pp.1-17.



- Blake G.R., Hartage K.H. (1986) Bulk density. In: Klute, A. (Ed.), *Method of Soil Analysis, Part I. Physical and Mineralogical Methods: Agronomy Monograph no. 9*, second ed., pp. 363–375.
- Bower, C. A., Reitemeier, R. F., & Fireman, M. (1952). Exchangeable cation analysis of saline and alkali soils. *Soil science*, 73(4), 251-262.
- Bremner J. M., Mulvaney C. S (1982) Nitrogen-total. *Methods of soil analysis, part 2 chemical and microbiological properties*, 9, 595-624
- Budak, M., Günal, E., Kılıç, M., Çelik, İ., Sırrı, M. and Acir, N., 2023. Improvement of spatial estimation for soil organic carbon stocks in Yuksekova plain using Sentinel 2 imagery and gradient descent–boosted regression tree. *Environmental Science and Pollution Research*, 30(18), pp.53253-53274.
- Bui, E. N., Searle, R. D., Wilson, P. R., Philip, S. R., Thomas, M., Brough, D., ... & Van Gool, D. (2020). Soil surveyor knowledge in digital soil mapping and assessment in Australia. *Geoderma Regional*, 22, e00299.
- Chaudhry, H., Vasava, H.B., Chen, S., Saurette, D., Beri, A., Gillespie, A., Biswas, A., 2024. Evaluating the soil quality index using three methods to assess soil fertility, 2024 *Sensors* 24 (3), 864. <https://doi.org/10.3390/s24030864>.
- Dindaroglu, T., Tunguz, V., Babur, E., Alkharabsheh, H. M., Seleiman, M. F., Roy, R., & Zakharchenko, E. (2022). The use of remote sensing to characterise geomorphometry and soil properties at watershed scale. *International Journal of Global Warming*, 27(4), 402-421.
- Doran J.W., and Parkin B.T. (1994). Defining and assessing soil quality. In: Doran, J.W., Coleman, D.C., Bezdicsek, D.F., Stewart, B.A. (Eds.), *Defining Soil Quality for a Sustainable Environment*. Soil Science Society of America, Inc., Madison, WI, USA, pp. 3–21. Special Publication. Number 35.
- Emami, N. S. , Chavoshi, E. , Ayoubi, S. , Honarjoo, N. and Zeraatpisheh, M. (2025). Digital mapping of soil physical and chemical properties using some machine learning algorithms and environmental variables in the Fereydan region, Isfahan Province. *Agricultural Engineering*, 48(2), 205-229. doi: 10.22055/agen.2025.48843.1761. (In Persian).
- Fathizad, H., Ardakani, M.A.H., Heung, B., Sodaiezadeh, H., Rahmani, A., Fathabadi, A., Scholten, T. and Taghizadeh-Mehrjardi, R., 2020. Spatio-temporal dynamic of soil quality in the central Iranian desert modeled with machine learning and digital soil assessment techniques. *Ecological Indicators*, 118, p.106736.
- Gee, G.W. and Bauder J.M. (1986). Particle-size analysis. In *Methods of Soil Analysis, Part 1, Physical and Mineralogical Methods*. Agronomy Monograph No. 9 (2nd edition), American Society of Agronomy, Madison, WI. Pp 383-411.
- Geng, Y., Shi, K., Xie, M., Ni, H., Zhu, Q., ... & Bourennane, H. (2025). Fine-resolution baseline maps of soil nutrients in farmland of Jiangxi Province using digital soil mapping and interpretable machine learning. *Catena*, 249, 108635.
- Halder, B., Bandyopadhyay, J., & Banik, P. (2021). Monitoring the effect of urban development on urban heat island based on remote sensing and geo-spatial approach in Kolkata and adjacent areas, India. *Sustainable Cities and Society*, 74, 103186.
- Hemmati, S., Yaghmaeian, N., Farhangi, M. B., & Sabouri, A. (2023). Soil quality assessment of paddy fields (in Northern Iran) with different productivities: Establishing the critical limits of minimum data set indicators. *Environmental Science and Pollution Research*, 30(4), 10286-10296.
- Huang, W., Zong, M., Fan, Z., Feng, Y., Li, S., Duan, C. and Li, H., 2021. Determining the impacts of deforestation and corn cultivation on soil quality in tropical acidic red soils using a soil quality index. *Ecological Indicators*, 125, p.107580.
- Kempen, B., Dalsgaard, S., Kaaya, A. K., Chamuya, N., Ruipérez-González, M., Pekkarinen, A., & Walsh, M. G. (2019). Mapping topsoil organic carbon concentrations and stocks for Tanzania. *Geoderma*, 337, 164-180.
- Kemper W.D. and Rosenau R.C. (1986). Aggregate stability and size distribution. In: Klute A (ed). *Methods of Soil Analysis. Part a: Physical and Mineralogical Methods*. American Society of Agronomy. Soil Science Society of America, Madison, WI. Pp 425–442.
- Knudsen D., Peterson G.A. and Pratt P.F. (1982). Lithium, sodium and potassium. p. 225-246. In: A.L. Page (ed) *Methods of Soil Analysis. Part 2*. American Society of Agronomy. Madison, WI.
- Kumaraperumal, R., Pazhanivelan, S., Geethalakshmi, V., Nivas Raj, M., Muthumanickam, D., Kaliaperumal, R., ... & Tarun Kshatriya, T. V. (2022). Comparison of machine learning-based prediction of qualitative and quantitative digital soil-mapping approaches for Eastern Districts of Tamil Nadu, India. *Land*, 11(12), 2279.

- Li, C., Wang, Y., Gao, Z., Sun, B., Xing, H. and Zang, Y., 2022. Identification of Typical Ecosystem Types by Integrating Active and Passive Time Series Data of the Guangdong–Hong Kong–Macao Greater Bay Area, China. *International Journal of Environmental Research and Public Health*, 19(22), p.15108.
- Li, Z., Zhu, C., & Gold, C. (2004). *Digital terrain modeling: principles and methodology*. CRC press.
- Liu, Y., Meng, Q., Zhang, L., & Wu, C. (2022). NDBSI: A normalized difference bare soil index for remote sensing to improve bare soil mapping accuracy in urban and rural areas. *Catena*, 214, 106265.
- Maghami Moghim, F., Karimi, A., Bagheri Bodaghabadi, M. and Emami, H. (2022). Evaluating the Role of Different Management Systems on Soil Quality Index Using Crop Yield (Case Study: Neyshabour Plain, Iran). *Water and Soil*, 36(1), 95-112. doi: 10.22067/jsw.2022.74026.1120. (In Persian).
- Maleki, S., Zeraatpisheh, M., Karimi, A., Sareban, G., & Wang, L. (2022). Assessing variation of soil quality in agroecosystem in an arid environment using digital soil mapping. *Agronomy*, 12(3), 578.
- McBratney, A. B., Santos, M. M., & Minasny, B. (2003). On digital soil mapping. *Geoderma*, 117(1-2), 3-52.
- Metwaly, M.M., Metwalli, M.R., Abd-Elwahed, M.S. and Zakarya, Y.M., 2024. Digital mapping of soil quality and salt-affected soil indicators for sustainable agriculture in the Nile Delta region. *Remote Sensing Applications: Society and Environment*, 36, p.101318.
- Moharana, P. C., Jena, R. K., Yadav, B., Naitam, R., Kumar, N., Pradhan, U. K., & Sharma, G. K. (2024). Digital soil mapping algorithm for soil quality assessment and monitoring: a case study in desert ecosystem of India. In *Remote sensing of soils* (pp. 229-245). Elsevier.
- Nabiollahi, K., Taghizadeh-Mehrjardi, R., & Eskandari, S. (2018). Assessing and monitoring the soil quality of forested and agricultural areas using soil-quality indices and digital soil-mapping in a semi-arid environment. *Archives of Agronomy and soil science*, 64(5), 696-707.
- North, H., Amies, A., Dymond, J., Belliss, S., Pairman, D., Drewry, J., Schindler, J. and Shepherd, J., 2022. Mapping bare ground in New Zealand hill-country agriculture and forestry for soil erosion risk assessment: An automated satellite remote-sensing method. *Journal of Environmental Management*, 301, p.113812.
- Olsen S.R., Cole C.V., Watanabe F.S. and Dean L.A. (1954). Estimation of Available Phosphorous in Soils by Extraction with Sodium Bicarbonate; U.S. Department of Agriculture: Washington, D.C., USDA Circ. 939.
- Page A.L., Miller R.H., and Keeney D.R.(1982). *Methods of Soil Analysis, part2, chemical and microbiological properties*. American Society of Agronomy, Inc. Soil Science Society of Aamerica, Madison, WI.
- Poeplau, C., & Don, A. (2013). Sensitivity of soil organic carbon stocks and fractions to different land-use changes across Europe. *Geoderma*, 192, 189-201.
- Qi, Y., Darilek, J.L., Huang, B., Zhao, Y., Sun, W., Gu, Z., 2009. Evaluating soil quality indices in an agricultural region of Jiangsu Province, China. *Geoderma* 149 (3–4), 325–334
- Rahmanipour, F., Marzaioli, R., Bahrami, H.A., Fereidouni, Z., Bandarabadi, S.R., 2014. Assessment of soil quality indices in agricultural lands of Qazvin Province, Iran. *Ecol. Indicators* 40, 19–26
- Rangzan, K., Abdehvand, Z. Z., Mousavi, S. R., & Karimi, D. (2025). Spatial analysis of soil quality in agricultural land using machine learning and environmental covariates: A case study of Khuzestan Province. *Soil and Tillage Research*, 252, 106591.
- Reynolds W.D., Drury C.F., Tan C.S., Fox C.A. and Yang X.M. (2009). Use of indicators and pore volume function characteristics to quantify soil physical quality. *Geoderma*, 152: 252-263
- Rhoades, J.D. (1982). Soluble salts. In: Page AL (ed) *Methods of soil analysis, part II*, 2nd ed., ASA, Monograph No. 9, Madison, WI, pp 167–179. <https://doi.org/10.2134/agronmonogr9.2.2ed.c10>
- Rostaminia, M., Rahmani, A., Mousavi, S. R., Taghizadeh-Mehrjardi, R., & Maghsodi, Z. (2021). Spatial prediction of soil organic carbon stocks in an arid rangeland using machine learning algorithms. *Environmental Monitoring and Assessment*, 193(12), 815.
- Samie Khoshk Estalkhi, F. , Yaghmaeian Mahabadi, N. , Abrishamkesh, S. and Maslahatjou, A. (2024). Evaluation of Scoring and Weighting Methods for Soil Characteristics to Determine Soil Quality in Different Land Uses. *Iranian Journal of Soil Research*, 37(4), 355-375. doi: 10.22092/ijsr.2024.361794.700. (In Persian).
- Sánchez-Ruiz, S., Piles, M., Sánchez, N., Martínez-Fernández, J., Vall-llossera, M., & Camps, A. (2014). Combining SMOS with visible and near/shortwave/thermal infrared satellite data for high resolution soil



- moisture estimates. *Journal of Hydrology*, 516, 273-283.
- Sedaghat, A., Shahrestani, M. S., Noroozi, A. A., Nosratabad, A. F., & Bayat, H. (2022). Developing pedotransfer functions using Sentinel-2 satellite spectral indices and Machine learning for estimating the surface soil moisture. *Journal of Hydrology*, 606, 127423.
- Serrano, J., Shahidian, S., & Marques da Silva, J. (2019). Evaluation of normalized difference water index as a tool for monitoring pasture seasonal and inter-annual variability in a Mediterranean agro-silvo-pastoral system. *Water*, 11(1), 62.
- Shafizadeh-Moghadam, H., Minaei, F., Talebi-khiavi, H., Xu, T., & Homaei, M. (2022). Synergetic use of multi-temporal Sentinel-1, Sentinel-2, NDVI, and topographic factors for estimating soil organic carbon. *Catena*, 212, 106077.
- Shukla, M. K., Lal, R., & Ebinger, M. (2006). Determining soil quality indicators by factor analysis. *Soil and tillage research*, 87(2), 194-204.
- 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, 114793.
- Tauqeer, H. M., Turan, V., Farhad, M., & Iqbal, M. (2022). Sustainable agriculture and plant production by virtue of biochar in the era of climate change. In *Managing plant production under changing environment* (pp. 21-42). Singapore: Springer Nature Singapore.
- Tudorescu, A. M., Negru, C., Mocanu, B. C., & Pop, F. (2024). Quality sustaining vegetation index for natural resources monitoring using satellite images. *Engineering Science and Technology, an International Journal*, 59, 101847.
- Walkley A. and Black I.A. (1934). An examination of Degtjareff method for determining soil organic matter and a proposed modification of the chromic acid titration method. *Soil Science*, 37: 29-37.
- Wang, B., Waters, C., Orgill, S., Gray, J., Cowie, A., Clark, A. and Li Liu, D., 2018. High resolution mapping of soil organic carbon stocks using remote sensing variables in the semi-arid rangelands of eastern Australia. *Science of the Total Environment*, 630, pp.367-378.
- Yang, L., He, X., Shen, F., Zhou, C., Zhu, A. X., Gao, B., ... & Li, M. (2020). Improving prediction of soil organic carbon content in croplands using phenological parameters extracted from NDVI time series data. *Soil and Tillage Research*, 196, 104465.
- Zeraatpisheh, M., Bakhshandeh, E., Hosseini, M., & Alavi, S. M. (2020). Assessing the effects of deforestation and intensive agriculture on the soil quality through digital soil mapping. *Geoderma*, 363, 114139.
- Zeyliger, A.M., Muzalevskiy, K.V., Zinchenko, E.V. and Ermolaeva, O.S., 2022. Field test of the surface soil moisture mapping using Sentinel-1 radar data. *Science of the Total Environment*, 807, p.151121.