



Improving Spatial Prediction of Soil Salinity Using an Ensemble Machine Learning Model in Arid Regions of Eastern Iran

Morteza Akbari¹, Sedigheh Maleki², Maliheh Pourali³, Abdolhossein Boali¹

¹ Department of Desert and Arid Zones Management, Faculty of Natural Resources and Environment, Ferdowsi University of Mashhad, Mashhad, Iran

² Department of Soil Sciences, College of Agriculture, Shiraz University, Shiraz, Iran

³ Department of Geography, Faculty of Literature and Humanities, Ferdowsi University of Mashhad, Mashhad, Iran

ARTICLE INFO

Article History:

Received: 30 May 2026

Revised: 19 August 2026

Accepted: 21 August 2026

Available Online:

23 August 2026

Keywords:

Soil Salinity

Land Degradation

Artificial Intelligence

Ecosystem Sustainability

Remote Sensing

ABSTRACT

Soil salinity is a major environmental hazard in arid regions, directly affecting soil and water resource productivity and ecosystem sustainability. This study aimed to develop and optimize an ensemble machine learning model for improving the spatial prediction of soil salinity and identifying the key environmental factors controlling its distribution in the Mahvelat Plain, Khorasan Razavi Province, Iran. A total of 137 soil samples were collected, and electrical conductivity of the saturated soil extract (EC_e) was measured. In addition, 32 auxiliary variables, including remote sensing spectral indices, topographic features, geological information, land use data, and groundwater quality parameters, were used in the modeling process. Four machine learning models, including Random Forest (RF), Support Vector Machine (SVM), Boosted Regression Tree (BRT), and Generalized Linear Model (GLM), along with a combined model, were developed and evaluated. The results showed that the combined model outperformed the individual models, achieving the highest prediction accuracy ($R^2 = 0.81$, RMSE = 5.14, and MAE = 4.11). Among the individual models, SVM showed the best performance ($R^2 = 0.76$). Highly saline areas were mainly concentrated in the central, western, and northwestern parts of the study area, particularly around Playa Bajestan, with an overall increase in salinity from east to west. Groundwater quality parameters, especially HCO_3^- , SAR, and TDS, were the most influential predictors. The combined model also showed a greater ability to estimate extreme salinity values, reaching 21 dS/m. Overall, the proposed framework provides an accurate and reliable approach for soil salinity mapping and sustainable soil resource management.

*Corresponding author: Morteza Akbari & Sedigheh Maleki. E-mail address: m-akbari@um.ac.ir, s.maleki@saadi.shirazu.ac.ir

How to cite this article: Akbari, M., Maleki, S., Pourali, M., & Bolai, A. (2026). Improving Spatial Prediction of Soil Salinity Using an Ensemble Machine Learning Model in Arid Regions of Eastern Iran. *Journal of Geography and Environmental Hazards*, ?(?), ?-?. <https://doi.org/10.22067/geoh.2026.99019.1669>



©2026 The author(s). This is an open access article distributed under Creative Commons Attribution 4.0 International License (CC BY 4.0)

Extended Abstract

Introduction

Nowadays, soil salinity has become an escalating environmental crisis that directly threatens global food security. In arid regions, the gradual accumulation of salts degrades both the physical and chemical properties of soil, posing a serious obstacle to agricultural production. The Mahvelat Plain in eastern Iran is one such area. It is an important agricultural zone well known for its intensive pistachio cultivation. However, the region's hot and dry climate, together with its proximity to the Bajestan playa, creates conditions that strongly favor salinization. The present study attempts to bridge the gap between traditional soil sampling and predictive digital soil mapping using an advanced ensemble machine learning approach. According to official reports, 424 million hectares of topsoil and 833 million hectares of cultivated soils in the world are affected by salt. Despite the increasing availability of remote sensing and environmental covariates, accurately characterizing the spatial heterogeneity of soil salinity in arid agricultural landscapes remains challenging because salinity is controlled by complex interactions among soil, groundwater, topography, climate, and land-use conditions. Therefore, integrating multiple machine learning algorithms within an ensemble framework may provide a more robust approach for improving prediction accuracy and reducing the limitations associated with relying on a single predictive model.

Material and Methods

Soil salinity values have previously been assessed through laboratory analyses, which have often been time-consuming and costly. Due to the limitations of past scientific methods, alternative techniques such as geostationary and remote sensing are currently being used to predict soil salinity in unsampled areas. Also, the integration of digital soil mapping techniques and machine learning to estimate soil properties has also expanded the application of these methods in soil salinity prediction. The study was conducted in the Mahvelat Plain. A total of 137 soil samples were collected to determine the electrical conductivity of the saturated paste extract (EC_e). To account for spatial complexity, 32 environmental covariates were selected. These included spectral remote sensing data, terrain attributes derived from a digital elevation model (DEM), geological maps, and groundwater chemical analyses. Four different models were trained initially: random forest (RF), support vector machine (SVM), boosted regression trees (BRT), and generalized linear model (GLM). Afterwards, a stacking ensemble model was developed using a five-fold cross-validation framework to generate the final salinity prediction map.

Results and Discussion

Model evaluation of model performance clearly showed that the stacking ensemble approach was superior. This model achieved high statistical accuracy, with an R^2 of 0.81 and an RMSe of 5.14, thereby outperforming each of the individual RF, SVM, BRT, and GLM models. The spatial distribution map revealed a clear salinity gradient, with values increasing progressively from the eastern part toward the western and northwestern parts of the plain. According to the variable importance analysis, soil salinity in the study area is mainly governed by subsurface hydro geochemical conditions. In particular, the strong correlations observed for HCO_3^- -SAR and TDS indicate that groundwater quality is the primary factor driving soil degradation in this plain. Unlike single models, the ensemble framework proved notably more capable of capturing extreme salinity, which is of particular concern for agricultural management. The ensemble approach outperformed all individual models, achieving an R^2 of 0.81, RMSe of 5.14 dS m⁻¹, and MAE of 4.11 dS m⁻¹. The final salinity map revealed high values in the western and northwestern parts of the plain near the Bajestan playa. Variable importance analysis identified groundwater hydro geochemical parameters, particularly bicarbonate (HCO_3^-), sodium adsorption ratio (SAR), and total dissolved solids (TDS), as the primary predictors. Notably, the ensemble model substantially improved the estimation of extreme salinity values exceeding 21 dS m⁻¹ compared to any single model.

Conclusion

The results confirmed that ensemble machine learning techniques can markedly improve the accuracy of soil salinity mapping in arid regions. By capturing the nonlinear interactions between groundwater quality and soil surface properties, the proposed framework offers a practical and reliable tool for site-specific soil management. For pistachio farmers and regional policymakers in Iran, this tool can help identify priority areas for drainage and desalination interventions, thereby supporting more sustainable agricultural development in salt-affected environments. Overall, the proposed approach can serve as an efficient tool for the intelligent management of water and soil resources in saline lands, particularly in pistachio-growing regions of the country. On the other hand, the results of this research showed that despite the extreme spatial and temporal variability of salinity, the use of remote sensing data and auxiliary variables in the framework of machine learning can predict soil salinity patterns with optimal accuracy. The resulting spatial information can also provide a scientific basis for prioritizing field investigations, optimizing irrigation and drainage practices, and allocating soil reclamation resources to areas with the greatest salinity risk. Furthermore, the proposed framework is transferable to other salt-affected arid and semi-arid agricultural regions where sufficient soil observations and environmental covariates are available, providing a scalable approach for supporting sustainable land and water management.



دسترسى آزاد

نشریه علمی جغرافیا و مخاطرات محیطی

DOI: 10.22067/GEOEH.2026.99019.1669

مقاله پژوهشی



بهبود پیش‌بینی مکانی شوری خاک با مدل ترکیبی یادگیری ماشین در مناطق خشک شرق ایران

مرتضی اکبری^{۱*}، صدیقه ملکی^{۲*}، ملیحه پورعلی^۳، عبدالحسین بوعلی^۱

^۱گروه مدیریت مناطق خشک و بیابانی، دانشکده منابع طبیعی و محیط زیست، دانشگاه فردوسی مشهد، مشهد، ایران
^۲گروه علوم خاک، دانشکده کشاورزی، دانشگاه شیراز، شیراز، ایران
^۳گروه جغرافیا، دانشکده ادبیات و علوم انسانی، دانشگاه فردوسی مشهد، مشهد، ایران

اطلاعات مقاله	چکیده
تاریخچه مقاله:	شوری خاک یکی از مخاطرات عمده محیطی در مناطق خشک است که مستقیماً بر بهره‌وری منابع خاک و آب و پایداری اکوسیستم تأثیر می‌گذارد. این مطالعه با هدف توسعه و بهینه‌سازی یک مدل یادگیری ماشین گروهی برای بهبود پیش‌بینی مکانی شوری خاک و شناسایی عوامل محیطی کلیدی کنترل‌کننده توزیع آن در دشت مِه ولات، استان خراسان رضوی، ایران انجام شد. هدایت الکتریکی عصاره گل اشباع (EC_e) در ۱۳۷ نمونه خاک اندازه‌گیری شد. ۳۲ متغیر کمکی، شامل؛ شاخص‌های طیفی سنجش از دور، توپوگرافی، زمین‌شناسی، کاربری اراضی و پارامترهای کیفیت آب‌های زیرزمینی، در فرآیند مدل‌سازی استفاده شد. چهار مدل یادگیری ماشین، شامل جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM)، درخت رگرسیون تقویت‌شده (BRT) و مدل خطی تعمیم‌یافته (GLM)، به همراه یک مدل ترکیبی، توسعه داده و ارزیابی شدند. نتایج نشان داد که مدل ترکیبی نسبت به مدل‌های منفرد عملکرد بهتری داشته است ($R^2 = 0.81$, $RMSE = 5.14$, $MAE = 4.11$). به ویژه نسبت به مدل (SVM) با ($R^2 = 0.76$). نقشه نهایی شوری نشان داد که مناطق بسیار شور عمدتاً در بخش‌های مرکزی، غربی و شمال غربی منطقه، به ویژه در اطراف پلایا بجستان، متمرکز بوده و افزایش شوری از شرق به غرب مشاهده شده است. پارامترهای کیفی آب زیرزمینی، به ویژه HCO_3^- ، SAR و TDS، بیشترین سهم را در پیش‌بینی شوری خاک داشته‌اند. مدل ترکیبی همچنین توانایی بیشتری در تخمین مقادیر شدید شوری نشان داد (تا ۲۱ دسی‌زیمنس بر متر). در مجموع، چارچوب پیشنهادی یک رویکرد دقیق و قابل اعتماد برای نقشه‌برداری شوری خاک و مدیریت پایداری منابع خاک ارائه می‌دهد.
کلمات کلیدی:	
شوری خاک	
تخریب سرزمین	
هوش مصنوعی	
پایداری اکوسیستم	
سنجش از دور	

مقدمه

شوری خاک یکی از مهم‌ترین چالش‌های محیط زیستی در مناطق خشک و نیمه خشک جهان است که به طور مستقیم بهره‌وری منابع آب و خاک، عملکرد محصولات زراعی و پایداری اکوسیستم را تحت تأثیر قرار می‌دهد (Basak et al., 2022; Akbari, Sarbazi, Sibevei & Fadaie, 2024). بر اساس داده‌های منتشر شده از سوی فائو^۱ ۴۲۴ میلیون هکتار از خاک‌های سطحی و ۸۳۳ میلیون هکتار از خاک‌های تحت کشت دنیا، تحت تأثیر نمک می‌باشند که از خاک‌های سطحی ۸۵ درصد شور، ۱۰ درصد سدیمی و ۵ درصد شور سدیمی و از خاک‌های زیرین ۶۲ درصد شور، ۲۴ درصد سدیمی و ۱۴ درصد شور سدیمی گزارش شده‌اند (FAO, 2024). در واقع این تخمین‌ها در بهترین حالت برآوردی تجربی است، زیرا با توجه به ذات پیچیده و پویایی زمانی و مکانی شوری خاک مقادیر مطلق آن دائماً در حال تغییر است (Maleki, Pouyan, Khoshoui, Tiefenbacher & Pourghasemi, 2024). در مناطق خشک ایران، اقلیم خشک (بارندگی کم و تبخیر بالا) به همراه توپوگرافی، اصلی‌ترین عوامل طبیعی مؤثر در شوری خاک محسوب می‌شوند (Akbari, Ownegh, Asgari, Sadoddin & Khosravi 2016a; Akbari, Modarres & Alizadeh Noughani, 2020). در این مناطق، املاح به سمت فرورفتگی‌های بزرگ به ویژه در دشت‌های کویری (پلایاها) منتقل شده و به دلیل تبخیر و ترقق بالا، در خاک تجمع می‌یابند. سازندهای زمین شناسی مانند گنبد‌های نمکی و نهشته‌های تبخیری نیز از دیگر عوامل طبیعی شوری خاک در برخی مناطق هستند (Akbari, Ownegh, Asgari, Sadoddin & Khosravi, 2016b). با توجه به شرایط یادشده، وجود شوری بالای خاک در محیط‌های خشک ایران امری غیرمنتظره نیست. در سال‌های اخیر، شوری ثانویه به دلیل فعالیت‌های انسانی از جمله کمبود زیرساخت‌های زهکشی مناسب و آبیاری با آب‌های شور تحت مدیریت ناکارآمد، افزایش یافته‌است (Hassani, Azapagic & Shokri, 2020). خاک‌های متأثر از نمک تهدیدی قابل توجه برای تولید محصولات کشاورزی می‌باشند و می‌توانند بهره‌وری کشاورزی را در مقیاس‌های منطقه‌ای، ملی و حتی محلی کاهش دهند (Arnous & Green, 2015; Rahimi, Afzali, Farhadi, & Alamolhoda, 2021). ایجاد بیابان‌ها در مقیاس بزرگ نیز نتیجه شوری خاک بوده که به عنوان یکی از عوامل اصلی تخریب سرزمین، تعادل اکولوژیکی را مختل می‌کند (Al-Refahi, Karimi, Mahmoudabadi & Akbari., ; Golestani, Ghahfarokhi, Esfandiarpour & Shirani, 2023). (2025).

روش‌های سنتی برای ارزیابی مقادیر شوری خاک شامل تحلیل‌های آزمایشگاهی زمان بر و پرهزینه‌اند. با توجه به محدودیت‌های روش‌های سنتی، تکنیک‌های جایگزینی مانند ژئواستاتیک^۲ (Brunner, Li, Kinzelbach & Li, 2007) و سنجش از دور (Dong, Wu, Luo, Sun & Xia, 2019; Nabiollahi et al., 2021; Maleki et al., 2024; Boali & Akbari, 2026) برای پیش‌بینی شوری خاک در مناطق نمونه برداری نشده استفاده می‌شود. همچنین ادغام تکنیک‌های نقشه‌برداری دیجیتال خاک^۳ و یادگیری ماشین برای تخمین ویژگی‌های خاک نیز باعث گسترش کاربرد این روش‌ها در پیش‌بینی شوری خاک شده است (Mousavi, Karimi, Maleki, Safari & Taghizadeh, 2023; Ye et al., 2026; Li et al., 2026). در مورد استفاده از ادغام متغیرهای محیطی با یادگیری ماشین برای پیش‌بینی شوری خاک، حق و همکاران (Haq, Shahbaz, Asif, Ouahada & Hamam, 2023) مطالعه‌ای در پاکستان انجام دادند که از پنج مدل یادگیری ماشین (رگرسیون جنگل تصادفی^۴، رگرسیون آدابوست^۵، رگرسیون درخت تصمیم^۶، رگرسیون حداقل مربعات جزئی^۷ و رگرسیون ریج^۸) همراه با داده‌های سنجش از دور استفاده کرده‌اند. یافته‌های آن‌ها نشان داد که مدل جنگل تصادفی از نظر دقت پیش‌بینی بهتر از سایر مدل‌ها عمل کرده است. به طور مشابه، شیائو و همکاران (Xiao et al., 2023) اثربخشی سه مدل یادگیری ماشین جنگل تصادفی، ماشین بردار پشتیبان^۹

1- Food and Agriculture Organization (FAO)

2- Geostatic

3- DSM

4- Random Forest (RF)

5- Ada Boost

6- Decision Tree

7- Partial Least Squares

8- Ridge Regression

9- Support Vector Machine (SVM)

و بوستینگ گرادیان شدید^۱ را در پیش‌بینی شوری خاک در منطقه خشک شمال غربی چین ارزیابی کردند. آنان در پژوهش خود نشان دادند مدل بوستینگ گرادیان و به دنبال آن جنگل تصادفی نسبت به رگرسیون بردار پشتیبان، به ویژه زمانی که متغیرهای ورودی خاصی استفاده می‌شد، عملکرد بهتری داشته‌اند. این یافته‌ها اهمیت انتخاب مناسب‌ترین مدل یادگیری ماشین بر اساس متغیرهای ورودی را برای پیش‌بینی دقیق پارامترهای شوری خاک برجسته می‌کند.

با وجود پیشرفت‌های قابل توجه در کاربرد مدل‌های منفرد یادگیری ماشین برای پیش‌بینی شوری خاک، اغلب این مدل‌ها با محدودیت‌هایی مانند نوسان عملکرد در شرایط داده‌ای متفاوت، حساسیت بالا به نویز و توان محدود در استخراج روابط پیچیده و غیرخطی میان متغیرهای محیطی مواجه‌اند (Boali, Asgari, Behbahani, Salmanmahiny & Naimi, 2024a). در سال‌های اخیر، استفاده از مدل‌های ترکیبی^۲ به عنوان رویکردی مناسب برای غلبه بر این محدودیت‌ها مطرح شده است، اما اغلب مطالعات موجود یا صرفاً به ترکیب‌های ساده مبتنی بر میانگین‌گیری پرداخته‌اند یا ارزیابی جامعی از سازوکارهای بهبود دقت ارائه نکرده‌اند (Boali, Kariminejad & Hosseinalizadeh, 2024b). نوآوری اصلی پژوهش حاضر، در ارائه یک مدل ترکیبی بهینه‌سازی شده با ساختار چند لایه است. در لایه اول، از چهار الگوریتم یادگیری ماشین شامل جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM)، درختان تقویت شده (BRT) و مدل خطی تعمیم یافته (GLM) به صورت موازی بر روی داده‌های محیطی، توپوگرافی و سنجش از دور آموزش داده می‌شوند. در لایه دوم، از الگوریتم بهینه‌سازی برای تنظیم بهینه فرامترهای هر سه مدل استفاده می‌شود تا عملکرد هر مدل به حداکثر دقت ممکن برسد. در لایه سوم، خروجی‌های سه مدل بهینه‌سازی شده با استفاده از روش ترکیبی که یک فرامدل یادگیری رگرسیون خطی را به عنوان ترکیب‌کننده نهایی به کار می‌گیرد، تلفیق می‌شوند. این ساختار سلسله‌مراتبی امکان بهره‌گیری همزمان از نقاط قوت هر سه مدل را فراهم می‌کند و با کاهش واریانس و بایاس، دقت پیش‌بینی را در مقایسه با مدل‌های منفرد به طور معناداری افزایش می‌دهد (Boali, Kariminejad & Akbari, 2026). همچنین، این مدل قادر است اثرات متقابل پیچیده بین متغیرهای محیطی را بهتر شناسایی کند؛ مسئله‌ای که در بسیاری از پژوهش‌های پیشین نادیده گرفته شده یا به صورت محدود بررسی شده است.


دشت مهورات به دلیل اهمیت بالایی اقتصادی و کشاورزی آن و در عین حال آسیب‌پذیری قابل توجه آن در برابر شوری خاک به عنوان منطقه مورد مطالعه در نظر گرفته شده است. این منطقه با اقلیم گرم و خشک و شرایط زمین ریخت شناسی خاص، مستعد تجمع املاح و بروز فرآیندهای شورشدگی ثانویه است (Maleki, Fathizad, Karimi, Taghizadeh-Mehrjardi & Pourghasemi, 2023). وابستگی بخش عمده‌ای از معیشت محلی به کشاورزی، به ویژه باغات پسته که حساسیت بالایی به تنش شوری دارند، ضرورت پایش دقیق و پیش‌بینی پذیر شوری خاک را دوچندان می‌سازد. علاوه بر این، کمبود داده‌های میدانی منسجم، تغییرات مکانی-زمانی شدید شوری و نبود مدل‌های پیش‌بینی دقیق در این ناحیه، شکاف دانشی مهمی ایجاد کرده است. از این رو انجام پژوهشی مبتنی بر مدل‌های یادگیری ماشین و توسعه یک چارچوب ترکیبی بهینه‌سازی شده، می‌تواند به ارائه نقشه‌های دقیق تر شوری و مدیریت هوشمند منابع خاک در دشت مهورات کمک کند و در نهایت پایداری تولیدات کشاورزی منطقه را تقویت نماید.

منطقه مطالعاتی

منطقه مطالعاتی در شرق ایران و در شهرستان مهورات استان خراسان رضوی واقع شده است. مساحت مهورات تقریباً ۲۰۴۷۱ هکتار بوده و در محدوده جغرافیایی ۵۸° ۳۴' تا ۳۵° ۰۱' شمالی و ۵۸° ۳۳' تا ۵۸° ۴۶' شرقی قرار گرفته است (شکل ۱). میانگین بارندگی و دمای سالیانه به ترتیب ۱۹۳ میلی متر و ۱۷/۳ درجه سانتی گراد می‌باشد. رژیم رطوبتی و حرارتی خاک به ترتیب اریدیک خشک و ترمیک است. دشت مهورات یکی از مناطق مهم کشاورزی استان خراسان رضوی به ویژه تولید پسته است که پلاهای بجستان در نزدیکی آن قرار دارد (Maleki et al., 2023). ارتفاع از سطح آب‌های آزاد منطقه مطالعاتی بین ۷۹۳ تا ۲۰۰۰ متر می‌باشد.

1- Extreme Gradient Boosting (XGB)

2- Ensemble Models



شکل ۱- موقعیت منطقه مطالعاتی به همراه نقاط نمونه برداری خاک در دشت مهولات استان خراسان رضوی

Fig. 1. Location of the study area and soil sampling points in the Mahvelat Plain, Khorasan Razavi Province

مواد و روش‌ها

پژوهش حاضر، به منظور بررسی و مدل‌سازی شوری خاک، از تلفیق داده‌های زمینی و سنجش از دور استفاده شد. داده‌های زمینی شامل ۱۳۷ نمونه خاک برداشت شده از نقاط مختلف منطقه ی مورد مطالعه بود که میزان شوری هر نمونه خاک در عصاره گل اشباع اندازه گیری گردید (Page, Miller & Keeney, 1982).

علاوه بر بازدیدهای میدانی و نمونه‌های جمع آوری شده، مجموعه‌ای جامع از شاخص‌ها و لایه‌های مختلف سنجش از دور و محیطی مورد استفاده قرار گرفت. شاخص‌های طیفی شامل MSI، S1، RVI، OSAVI، NDVI، NDSI، BI، NDWI، که هرکدام بیانگر ویژگی‌های مختلف پوشش گیاهی و وضعیت رطوبت و تنش‌های محیطی خاک هستند و از تصاویر ماهواره لندست ۸ (OLI/TIRS sensors) با قدرت تفکیک مکانی ۳۰ متر و در بستر گول ارث انجین استخراج گردیدند. همچنین، لایه‌های مربوط به زمین شناسی و کاربری اراضی به منظور لحاظ کردن تأثیر ساختار زمین و تغییرات کاربری بر شوری خاک استفاده شدند. داده‌های توپوگرافی شامل پارامترهایی نظیر Slope، Hillshade، Curvature، Convergence، Aspect، Texture، TPI و TRI بوده‌اند که بیانگر ویژگی‌های هندسی و شکل زمین هستند. افزون بر این، متغیرهای مربوط به آب‌های زیرزمینی شامل EC و TDS، SAR، pH، HCO_3^- ، Cations، Anion نیز مورد بهره‌برداری قرار گرفتند تا اثر ترکیب شیمیایی و ویژگی‌های هیدروشیمیایی بر الگوی شوری بررسی شود (جدول ۱). ترکیب این داده‌ها در محیط سامانه اطلاعات جغرافیایی و نرم افزارهای تحلیلی، پایه ای برای مدل‌سازی و تحلیل مکانی شوری خاک فراهم نمود.

پیش‌پردازش داده‌ها

پیش از اجرای مدل‌های یادگیری ماشین، داده‌ها به منظور افزایش پایداری و قابلیت مقایسه بین متغیرها مورد پیش‌پردازش قرار گرفتند. ابتدا تمامی متغیرهای ورودی از نظر وجود مقادیر گمشده، داده‌های پرت و ناسازگاری‌های احتمالی بررسی شدند. با توجه به کنترل کیفی داده‌ها در مرحله نمونه‌برداری و تهیه لایه‌های محیطی، هیچ مقدار گمشده‌ای در مجموعه داده نهایی وجود نداشت. برای شناسایی داده‌های پرت از روش فاصله بین چارکی (Interquartile Range; IQR) استفاده شد و نمونه‌هایی که خارج از محدوده قرار داشتند مورد بررسی قرار گرفتند. از آنجا که این مقادیر عمدتاً ناشی از تغییرات واقعی مکانی شوری خاک بودند و حذف آن‌ها می‌توانست موجب از دست رفتن اطلاعات ارزشمند شود، در مجموعه داده حفظ شدند. در ادامه، به

منظور حذف اثر تفاوت مقیاس متغیرها، تمامی متغیرهای پیوسته پیش از اجرای مدل‌ها با استفاده از استانداردسازی Z-score (با میانگین صفر و انحراف معیار یک) نرمال‌سازی شدند.

جدول ۱- متغیرهای کمکی مورد استفاده برای تهیه نقشه شوری خاک در دشت مہولات استان خراسان رضوی

Table 1- Auxiliary variables used for soil salinity mapping in the Mahvelat Plain, Khorasan Razavi Province.

معیار	شاخص	تعریف و فرمول شاخص	رفرنس
Criterion	Index	Definition & Index Formula	Reference
توپوگرافی Topography	Slope	شیب نشان دهنده‌ی میزان افزایش یا کاهش ارتفاع نسبت به فاصله در یک جهت خاص است. Slope indicates the rate of increase or decreases in elevation relative to distance in a specific direction.	(Gallant & Dowling, 2003)
	Aspect	جهتِ خطِ بیشترین شیب نزول (یعنی جهتی که در آن بیشترین کاهش ارتفاع رخ می‌دهد) The direction of the line of steepest descent (i.e., the direction in which the greatest decrease in elevation occurs)	
	Curvature	میزان انحراف یک قوس یا منحنی از خط راست The amount of deviation of an arc or curve from a straight line	
	Convergence	نواحی همگرا را به صورت کانال (مجرای جریان) و نواحی واگرا را به صورت پشته (برآمدگی) برجسته می‌کند. It highlights convergent areas as channels (flow paths) and divergent areas as ridges (elevations)	
	Analytical hillshade	زاویه بین سطح و پرتوهای نور تابشی The angle between the surface and the incoming light rays	(Tarini, Cignoni & Montani, 2006)
	Topographic roughness index (TRI)	اندازه گیری میزان ناهمواری سطح زمین Measurement of the degree of roughness	(Moore, Gessler, Nielsen & Peterson, 1993)
	Topographic position index (TPI)	تفاوت بین مقدار ارتفاع یک سلول و میانگین ارتفاع همسایگی اطراف آن سلول The difference between the elevation value of a cell and the average elevation of its surrounding neighborhood	(Weiss, 2001)
سنجش از دور Remote Sensing	Terrain surface texture (Texture)	ناهمواری‌های هندسی موجود در سطح Roughness's present on the surface	(Iwahashi & Pike, 2007)
	Salinity Index (SI)	$\sqrt{B2 \times B4}$	(Allbed, Kumar & Aldakheel, 2014)
	Normalized Difference Salinity Index (NDSI)	$(B4-B8A)/(B4+B8A)$	(Richardson, Duigan & Berlyn, 2002)
	Normalized Difference Water Index (NDWI)	$(B8A-B11)/(B8A+B11)$	
	Brightness Index (BI)	$\sqrt{(B4^2 + B3^2 + B2^2)} / 3$	(Ray, Singh, Dutta & Panigrahy, 2002)
	Moisture Stress Index (MSI)	SWIR1/B8	(Rock, Vogelmann, Williams, Vogelmann & Hoshizaki, 1985)
	Optimized Soil-Adjusted Vegetation Index (OSAVI)	$(B8 - B4)/(B8 + B4 + 0.16)$	(Rondeaux, Steven & Baret, 1996)
	Normalized Difference Vegetation Index (NDVI)	$(B8A-B4)/(B8A+B4)$	(Rouse, Haas, Scheel & Deering, 1974)
	Ratio Vegetation Index (RVI)	$(B8/B4)$	(Jordan, 1969)

شاخص نسبت پوشش گیاهی		مواد مادری Parent Material
Geology map	نقشه زمین‌شناسی	
(Zinck, 1989; Toomanian, Jalalian, Khademi, Karimian Eghbal & Papritz, 2006)	-	Land use map نقشه کاربری اراضی
(Nasrian, Akbari, Faridhosseini & Neamatollahi, 2022)	-	HCO ₃ ⁻ , Anion, Cations, EC, pH, SAR, and TDS
		کیفیت آب Water Quality

مدل‌های یادگیری ماشین

به منظور پیش‌بینی و مدل‌سازی مکانی شوری خاک، از چهار الگوریتم یادگیری ماشین شامل جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM)، درختان تقویت شده (BRT) و مدل خطی تعمیم یافته (GLM) استفاده شد. پارامترهای مدل‌ها بر اساس مقادیر پیشنهادی در مطالعات پیشین، مستندات رسمی الگوریتم‌ها و اجرای نظام‌مند چندین آزمایش اولیه (trial-and-error) تعیین شدند. در هر مرحله، عملکرد مدل‌ها با استفاده از شاخص‌های ضریب تعیین (R^2)، ریشه میانگین مربعات خطا (RMSE) و میانگین قدر مطلق خطا (MAE) ارزیابی شد و مجموعه پارامترهایی که بهترین تعادل بین دقت پیش‌بینی، قابلیت تعمیم و جلوگیری از بیش‌برازش را فراهم کردند، به عنوان تنظیمات نهایی انتخاب شدند.

مدل RF به عنوان یک الگوریتم یادگیری گروهی مبتنی بر bagging، با تجميع پیش‌بینی‌های مجموعه‌ای از درختان تصمیم، پایداری مدل را افزایش می‌دهد (Breiman, 2001). در این مدل تعداد درختان برابر با ۵۰۰ و حداکثر عمق درختان بر روی ۱۰ تنظیم گردید تا از بیش‌برازش جلوگیری شود. حداقل تعداد نمونه‌های مورد نیاز برای تقسیم یک گره روی ۵ و حداقل تعداد نمونه در برگ‌ها روی ۱ در نظر گرفته شد. پارامتر نیز برای تعیین حداکثر تعداد ویژگی‌های مورد بررسی در هر تقسیم، برابر با 'sqrt' انتخاب شد. مدل ماشین بردار پشتیبان (SVM) با به کارگیری توابع هسته^۱، روابط غیرخطی پیچیده بین متغیرهای کمکی و شوری خاک را از طریق یافتن ابرصفحه ی بهینه با بیشترین حاشیه مدل‌سازی می‌کند. در مدل SVM از تابع هسته رادیال پایه استفاده شد که توانایی بالایی در مدل‌سازی روابط غیرخطی دارد (Liu et al., 2021; Bargam et al., 2024). پارامتر تنظیم کننده برای کنترل تعادل بین حداقل کردن خطا و حداکثر کردن حاشیه، بر روی ۱ تنظیم گردید. پارامتر گاما، که شعاع تأثیر تابع RBF را مشخص می‌کند، به صورت خودکار با مقدار 'scale' تعیین شد.

مدل BRT با رویکرد تقویت گرادیان، درختان تصمیم را به صورت متوالی برای کاهش خطای مدل‌های پیشین بهینه سازی می‌نماید که منجر به افزایش دقت پیش‌بینی می‌گردد (Bandak, Boali, Yaghobi & Taghizadeh-Mehrjardi, 2025). در این مدل تعداد درختان برابر با ۳۰۰ و نرخ یادگیری بر روی ۰/۰۵ تنظیم شد تا از همگرایی پایدار اطمینان حاصل گردد. عمق درختان نیز مانند RF، بر روی ۱۰ تعیین شد. به منظور جلوگیری از بیش‌برازش، از پارامتر subsample با مقدار ۰/۸ برای نمونه گیری تصادفی بخشی از داده‌ها در هر مرحله استفاده گردید. نهایتاً، مدل خطی تعمیم یافته (GLM)، به عنوان یک چارچوب انعطاف پذیر با استفاده از تابع پیوند، روابط احتمالی بین متغیرهای مستقل و پاسخ را برآورد می‌کند (Yin et al., 2024). در این مدل توزیع نرمال برای متغیر پاسخ شوری خاک فرض شد و تابع پیوند هویت به کار گرفته شد، که معادل یک مدل رگرسیون خطی معمولی (OLS) است. در صورت نیاز به استفاده از توزیع‌های دیگر مانند گاما یا پواسون، این انتخاب بر اساس تحلیل اکتشافی داده‌ها و مناسبت آماری صورت خواهد گرفت.

ارزیابی عملکرد مدل‌ها

عملکرد نهایی هر یک از مدل‌های یادگیری ماشین با استفاده از معیارهای ارزیابی استاندارد در حوزه رگرسیون، شامل ریشه میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE) و ضریب تعیین (R^2) مورد سنجش قرار گرفت (Bandak, Boali, Komaki, Ghorbani & Alinejad, 2026). این معیارها بر روی مجموعه داده آزمون که در فرآیند آموزش مدل‌ها لحاظ

نشده بود، محاسبه شدند تا ارزیابی بی طرفانه‌ای از توانایی تعمیم‌پذیری و دقت پیش‌بینی هر مدل به دست آید. مقایسه مقادیر این معیارها به ما امکان شناسایی بهترین مدل را برای پیش‌بینی دقیق شوری خاک در منطقه مورد مطالعه می‌دهد. به طور کلی، در تکنیک‌های یادگیری ماشین، نمونه‌های مشاهداتی به صورت تصادفی به دو گروه تقسیم می‌شوند، به طوری که ۷۰ درصد برای آموزش مدل و ۳۰ درصد باقی مانده برای اعتبارسنجی در نظر گرفته می‌شود (John et al., 2020). این گروه اعتبارسنجی برای ارزیابی عملکرد مدل با استفاده از اعتبارسنجی متقابل بوت استرپینگ ۱۰ تکرار مورد استفاده قرار می‌گیرد (Sharififar & Sarmadian, 2023).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_i - Z_i^*)^2} \quad (1)$$

$$R^2 = \left[\frac{\sum_{i=1}^n (Z_i - \bar{Z})(Z_i^* - \bar{Z}^*)}{\sqrt{\sum_{i=1}^n (Z_i - \bar{Z})^2} \sqrt{\sum_{i=1}^n (Z_i^* - \bar{Z}^*)^2}} \right]^2 \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Z_i - Z_i^*| \quad (3)$$

جایی که n , Z_i^* , Z_i , $\bar{Z}^*$, $\bar{Z}$ به ترتیب تعداد مشاهدات، مقادیر مشاهده شده، مقادیر پیش‌بینی شده، میانگین مقادیر مشاهده شده و پیش‌بینی شده هستند.

مدل ترکیبی

در این پژوهش، به منظور افزایش دقت پیش‌بینی و کاهش نوسان عملکرد مدل‌های منفرد، یک مدل ترکیبی بهینه‌سازی شده مبتنی بر یادگیری ماشین برای پیش‌بینی شوری خاک در دشت مہولات طراحی شد. در این چارچوب، چهار مدل جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM)، درختان تقویت شده (BRT) و مدل خطی تعمیم یافته (GLM) به عنوان یادگیرنده‌های پایه به کار گرفته شدند تا با بهره‌گیری از تنوع ساختاری آن‌ها، طیفی از روابط خطی و غیرخطی بین متغیرهای محیطی، توپوگرافی و سنجش از دور با شوری خاک پوشش داده شود. مدل ترکیبی بر اساس رویکرد Stacking Ensemble با استفاده از پکیج glmnet توسعه یافت. به منظور جلوگیری از نشت اطلاعات (Data Leakage)، تولید متافچرها بر اساس فرآیند اعتبارسنجی متقابل پنج‌تایی انجام شد. بدین صورت که در هر تکرار، داده‌های آموزشی به پنج زیرمجموعه تقسیم شدند؛ در هر مرحله، چهار زیرمجموعه برای آموزش هر یک از مدل‌های پایه (GLM، BRT، SVM، RF) و زیرمجموعه باقیمانده صرفاً برای تولید پیش‌بینی مورد استفاده قرار گرفت. این فرآیند پنج بار تکرار شد تا برای تمامی نمونه‌های مجموعه آموزش، پیش‌بینی‌هایی تولید شود که همواره توسط مدلی ایجاد شده بودند که آن نمونه را در مرحله آموزش مشاهده نکرده بود (Out-of-Fold Predictions). سپس پیش‌بینی‌های خارج از نمونه حاصل از چهار مدل پایه به عنوان متافچرهای ورودی مدل فراگیر مبتنی بر رگرسیون منظم شده (glmnet) مورد استفاده قرار گرفتند. پس از آموزش مدل فراگیر، هر یک از مدل‌های پایه مجدداً با استفاده از کل داده‌های آموزشی بازآموزی شدند و پیش‌بینی‌های حاصل از آن‌ها برای داده‌های آزمون به مدل فراگیر وارد شد تا پیش‌بینی نهایی شوری خاک تولید گردد. در این ساختار، مدل‌های درختی (RF و BRT) مسئول استخراج الگوهای غیرخطی و تعاملات پیچیده بین متغیرها، SVM مسئول شناسایی ساختارهای با حاشیه بهینه در فضای ویژگی‌ها، و GLM مسئول مدل‌سازی روابط خطی و فراهم‌سازی تفسیرپذیری بیشتر بودند و مدل فراگیر با وزن دهی بهینه به هر یک از این منابع اطلاعاتی، خطای کلی پیش‌بینی را کاهش می‌دهد. به طور کلی، مدل ترکیبی پیشنهادی با تلفیق نقاط قوت مدل‌های منفرد و کاهش اثر ضعف‌های آن‌ها، موجب افزایش پایداری پیش‌بینی در برابر تغییرات داده‌ای و نویز، بهبود دقت مکانی نقشه‌های شوری و ارتقای قابلیت استفاده از نتایج در مدیریت خاک دشت مہولات خواهد شد.

نتایج و بحث

آماره‌های توصیفی مربوط به هدایت الکتریکی خاک استخراج و در جدول ۲ ارائه گردیده است. تحلیل داده‌ها حاکی از آن است که میانگین هدایت الکتریکی خاک در منطقه مورد مطالعه ۱۰/۰۹ دسی زیمنس بر متر است که به طور کلی بیانگر شرایط شور در منطقه است. دامنه تغییرات این پارامتر بین ۰/۵۶ تا ۴۹/۳۰ بود که نشان دهنده نشان دهنده ناهمگنی قابل توجه شوری خاک در منطقه، از شرایط غیرشور تا شوری بسیار زیاد است. چنین دامنه گسترده‌ای از تغییرات می‌تواند متأثر از عوامل مختلفی از جمله شرایط هیدروژئوشیمیایی، نوع کاربری اراضی و شیوه‌های مدیریت آبیاری باشد. شوری خاک عمدتاً از طریق ایجاد تنش اسمزی و بروز سمیت یونی خاص بر رشد و عملکرد محصولات کشاورزی تأثیر می‌گذارد.


جدول ۲- توصیف آماری هدایت الکتریکی خاک در دشت مہولات استان خراسان رضوی

Table 2- Descriptive statistics of soil EC in the Mahvelat Plain, Khorasan Razavi Province

ضریب تغییرات Coefficient of Variation	انحراف معیار Standard Deviation	میان Median	میانگین Mean	حداکثر Maximum	حداقل Minimum	پارامتر Parameter
79.18	7.99	8.02	10.09	49.30	0.56	EC (dS m ⁻¹)

ارزیابی شوری خاک با استفاده از مدل‌های یادگیری ماشین

با وجود این که نقشه‌های حاصل از مدل‌های GLM، RF، BRT و SVM از نظر دامنه مقدار و شدت تفکیک مکانی تا حدی متفاوت‌اند، اما همگی در کلیت الگوی مکانی شوری همسو هستند و امکان شناسایی نواحی مستعد شوری و نیز مناطق با شرایط نسبتاً بهتر را فراهم می‌کنند. تفاوت بین مدل‌ها ناشی از ماهیت الگوریتم، نحوه یادگیری رابطه بین متغیرها و همچنین میزان حساسیت هر روش به تغییرات داده‌های ورودی محسوب می‌شود. به طور کلی نتایج حاصل از چهار مدل یادگیری ماشین نشان دهنده نواحی با شوری بالاتر در نواحی جنوبی منطقه قرار دارند (شکل ۲). با در نظر گرفتن معیارهای ارزیابی عملکرد مدل‌ها، مدل SVM با ضریب تبیین بالا ($R^2=76$) و کمترین ریشه میانگین مربعات خطا ($5/91$) و میانگین قدر مطلق خطا ($4/71$)، بالاترین عملکرد را داشته است. همچنین مدل GLM با ضریب تبیین پایین ($R^2=0/44$) و کمترین ریشه میانگین مربعات خطا ($7/60$) و میانگین قدر مطلق خطا ($6/08$)، پایین‌ترین عملکرد را داشته است (جدول ۳). این یعنی SVM توانسته است تغییرات شوری خاک را با دقت بیشتری نسبت به سایر مدل‌ها برآورد کند. در نتیجه عملکرد خوب SVM نشان می‌دهد این مدل غیرخطی با کرنل مناسب، توانسته است رابطه بین متغیرهای کمکی (داده‌های ماهواره‌ای، توپوگرافی، کیفیت آب آبیاری و ...) و شوری را به خوبی یاد بگیرد. مقادیر بالاتر RMSe ($7/60$) مدل GLM قابل انتظار است، زیرا روابط بین شوری و متغیرهای محیطی اغلب غیرخطی و پیچیده است و مدل خطی قادر به مدل‌سازی آن نیست. شوری خاک معمولاً توزیع مکانی غیرخطی و ناپیوسته دارد، به ویژه در مناطقی با کشاورزی فشرده و زهکشی متغیر SVM با استفاده از تابع کرنل (RBF) می‌تواند مرزهای پیچیده بین کلاس‌های شوری را بیاموزد. اگرچه مدل SVM بهترین عملکرد را بر اساس معیارهای آماری R^2 ، RMSe و MAE نشان داد، ارزیابی عدم قطعیت پیش‌بینی و تحلیل توزیع مکانی خطاها می‌تواند اطلاعات بیشتری درباره قابلیت اعتماد نقشه‌های شوری خاک فراهم کند. بنابراین، در مطالعات آینده پیشنهاد می‌شود از روش‌هایی مانند تحلیل باقیمانده‌های مکانی و برآورد عدم قطعیت پیش‌بینی برای بررسی تغییرپذیری خطاهای مدل در مناطق مختلف استفاده شود.



شکل ۲- ارزیابی شوری خاک با استفاده از مدل‌های یادگیری ماشین. الف- مدل RF ب- مدل BRT پ- مدل SVM و ت- مدل GLM.
Fig. 2. Evaluation of soil salinity using machine learning models. (a) RF model, (b) BRT model, (c) SVM model, and (d) GLM model.


جدول ۳- ارزیابی عملکرد مدل‌های یادگیری ماشین

Table 3- Comparison of machine learning model performance

MAE (Test)	MAE (Train)	RMSe (Test)	RMSe (Train)	R ² (Test)	R ² (Train)	Methods
6.08	5.80	7.60	7.10	0.44	0.50	GLM
4.71	4.10	5.91	5.20	0.76	0.82	SVM
5.54	5.0	6.93	6.10	0.69	0.75	BRT
5.39	4.90	6.74	6.0	0.74	0.80	RF

با بررسی پراکندگی داده‌های شوری در منطقه مورد مطالعه (شکل ۳) مشخص شد که علیرغم وجود حدود ۲۱ درصد از نمونه‌های خاک با شوری بیشتر از ۱۶ دسی زیمنس بر متر، تنها ۱۰ نمونه مربوط به کلاس شوری بالای ۲۱ دسی زیمنس بر متر (با دامنه گسترده ۲۱ تا ۴۹ دسی زیمنس بر متر) می‌باشند. در مقابل، بخش عمده داده‌های آموزش مدل‌های یادگیری ماشین (۳ مدل مورد استفاده) در محدوده ۱ تا ۲۲ دسی زیمنس بر متر متمرکز شده‌اند. این عدم تعادل توزیعی یکی از دلایل اصلی عملکرد نسبتاً ضعیف مدل‌ها در برآورد مقادیر بالاتر از ۲۱ است. به عبارت دیگر، مدل‌های یادگیری ماشین که ذاتاً برای کمینه‌سازی خطای کلی طراحی شده‌اند، در فرآیند آموزش به دلیل تعداد اندک نمونه‌های با شوری بسیار بالا، فرصت کافی برای یادگیری الگوی حاکم بر این مقادیر را نمی‌یابند و تمایل دارند که برآورد خود را به سمت میانگین داده‌های اکثریت (یعنی محدوده پایین و متوسط شوری) سوق دهند. این پدیده که به نام رگرسیون به سمت میانگین در مدل‌های مبتنی بر خطا شناخته می‌شود، باعث می‌شود مقادیر شدید (بالاتر از ۲۱ دسی زیمنس بر متر) با سوگیری منفی برآورد شوند. همچنین، پراکندگی زیاد نمونه‌های با شوری بالای ۲۱ (از ۲۱ تا ۴۹ دسی زیمنس بر متر) و فاصله عددی قابل توجه آن‌ها از محدوده غالب داده‌ها، سبب

می‌شود که آموزش مؤثر مدل را با چالش مواجه سازد. بنابراین، عملکرد ضعیف تر مدل‌ها در این بازه نه به دلیل نقص ذاتی الگوریتم‌ها، بلکه ناشی از ماهیت آماری داده‌ها و توزیع نامتوازن نمونه‌ها در فضای ویژگی است. برای بهبود برآورد چنین مقادیر حدی در ادامه از مدل ترکیبی جهت برآورد دقیق‌تر مقادیر شوری استفاده شده است.




شکل ۳- پراکنش تعداد نمونه‌های خاک در کلاس‌های مختلف شوری خاک

Fig. 3. Frequency distribution of soil samples in different salinity classes

ارزیابی شوری خاک براساس مدل ترکیبی

نتایج ارزیابی عملکرد مدل ترکیبی نشان داد که این مدل با ضریب تعیین بالا ($R^2=0.81$)، کمترین ریشه میانگین مربعات خطا ($RMSE=5.14$) و میانگین قدر مطلق خطا ($MAE=4.11$)، بهترین عملکرد را در پیش‌بینی شوری خاک ارائه داد. در مدل Stacking، وزن مدل‌های پایه به صورت ثابت تعیین نشد، بلکه توسط مدل فراگیر مبتنی بر رگرسیون منظم‌شده (glmnet) و در طی فرآیند آموزش، بر اساس پیش‌بینی‌های خارج از نمونه (Out-of-Fold Predictions) به طور خودکار برآورد گردید. بر این اساس، ضرایب یادگرفته‌شده برای مدل‌های جنگل تصادفی، ماشین بردار پشتیبان، درختان تقویت‌شده و مدل خطی تعمیم‌یافته به ترتیب برابر با 0.312 ، 0.335 ، 0.214 و 0.137 به دست آمد که بیانگر سهم نسبی هر مدل پایه در تولید پیش‌بینی نهایی هستند. نقشه شوری خاک پیش‌بینی شده توسط مدل ترکیبی الگوی مکانی مشابه اما با دقت بالاتری نسبت به سایر مدل‌ها را نشان داد. بر این اساس، مناطق با شوری بالاتر عمدتاً در بخش‌های مرکزی تا غربی و شمال غربی منطقه مطالعاتی متمرکز بوده و مناطق شرقی با مقادیر کمتری از شوری مشخص می‌شوند. این توزیع مکانی با ویژگی‌های جغرافیایی و هیدرولوژیکی منطقه، همخوانی دارد، به طوری که براساس مطالعات قبلی و بررسی نقشه کاربری اراضی منطقه (Maleki et al., 2024) در بخش‌های جنوبی منطقه مطالعاتی تجمع باغات پسته و اراضی کشاورزی دیده می‌شود. مقادیر شوری پیش‌بینی شده در سرتاسر دشت مهورات در بازه ای بین $2/39$ تا $49/48$ متغیر بود. این بازه وسیع نشان دهنده تنوع در شدت شوری در نواحی مختلف منطقه است که مدل ترکیبی توانسته است این تفاوت‌ها را به خوبی تفکیک کند. مقایسه مقادیر حداکثر و حداقل شوری با نتایج مدل‌های پایه (BRT, GLM, SVM, RF) و همچنین مطالعات پیشین در منطقه، نشان دهنده همگرایی نتایج و تأیید اعتبار پیش‌بینی‌های مدل ترکیبی است.



شکل ۴- نقشه شوری خاک براساس مدل ترکیبی


Fig. 4. Soil salinity map derived from the combined model

از دیگر سو نقشه تهیه شده بیانگر افزایش هدایت الکتریکی عصاره اشباع از سمت شرق به غرب منطقه مورد پژوهش می‌باشند. نواحی شرقی منطقه مطالعه شامل اراضی زراعی است که در آن‌ها آبیاری ممتد طی سال‌های متمادی سبب شسته شدن نمک‌ها از سطح خاک و انتقال آن‌ها به لایه‌های زیرین گردیده است. افزون بر این، سطح شوری با حرکت به سمت مرکز پلائی بستان که در غرب منطقه مطالعه واقع شده است، افزایش می‌یابد. دلیل این امر زهکشی محدود و نرخ بالای تبخیر-تعرق به شمار می‌رود که موجب تجمع تدریجی نمک‌ها در خاک در طول زمان و در نتیجه ایجاد سطوح بالاتر شوری می‌گردد. با توجه به اقلیم خشک این منطقه، در نتیجه، تبخیر آب شور باعث ایجاد تبلور نمک‌ها در سطح گردیده است. پژوهش‌های متعددی نقش شرایط اقلیمی و موقعیت قرارگیری اراضی کشاورزی در حاشه پلایا را در نوسانات شوری خاک مورد تأیید قرار داده‌اند (Bannari & Al-Ali, 2020; Li et al., 2022; Maleki et al., 2022; Golestani et al., 2023).

اهمیت متغیرهای تاثیرگذار بر شوری خاک براساس مدل ترکیبی

بر اساس تحلیل مدل ترکیبی ارائه شده در شکل ۵، متغیرهای مرتبط با آب زیرزمینی (به‌ویژه HCO_3 ، SAR، TDS، pH و Anion) بیشترین تأثیر را در پیش بینی شوری خاک دارند و نقش آن‌ها به مراتب برجسته‌تر از عوامل توپوگرافی و ژئومورفولوژیکی (مانند زمین‌شناسی، خصوصیات توپوگرافی، و شاخص‌های سنجش از دور) است. این یافته، اهمیت کلیدی پارامترهای هیدروژئوشیمیایی به‌ویژه HCO_3 را در تعادل نمکی و مدیریت پایدار خاک تأکید می‌کند. در سال‌های اخیر، تغییرات منابع آب زیرزمینی و افزایش شورابه‌ها، همراه با آبیاری، باعث افزایش میانگین شوری خاک سطحی شده و اکوسیستم منطقه دچار دگرگونی عمده‌تأ منفی گردیده است. این تغییرات مکانی-زمانی شدید، از عوامل مؤثر در تغییر کاربری اراضی از کشاورزی به باغداری محسوب می‌شوند.

باین‌حال، اقدامات مدیریتی کشاورزان شامل استفاده از بهبود دهنده‌ها، کودهای شیمیایی و اصلاح‌کننده‌های خاک، در برخی نقاط موجب کاهش شوری شده است. همچنین مطالعات هانگ و همکاران (Hong, Yong & Tiyp, 2011) در چین نشان داد که سطح بالای آب زیرزمینی، تبخیر و روش‌های آبیاری، مهمترین عوامل افزایش شوری هستند.



شکل ۵- اهمیت متغیرهای تاثیرگذار بر شوری خاک براساس مدل ترکیبی

Fig. 5. Importance of variables influencing soil salinity based on the ensemble model

علی رغم تغییرپذیری قابل توجه مقادیر هدایت الکتریکی در منطقه مورد مطالعه، نتایج تحلیل اهمیت متغیرها موید این است که قدرت تفکیک مکانی تصاویر ماهواره‌ای لندست ۸ برای ثبت این تغییرات مناسب بوده و شاخص‌های طیفی استخراج شده از این تصاویر ارتباط قابل قبولی با شوری خاک نشان داده‌اند.

از آنجا که پایش شوری خاک به منظور شناسایی و ارزیابی خاک‌های شور و مدیریت آن‌ها بر اساس موقعیت مکانی از اهمیت بالایی برخوردار است، بهره‌گیری از داده‌های سنجش از دور می‌تواند نقش مؤثری در کاهش هزینه‌ها و صرفه جویی در زمان ایفا کند. با این حال، به دلیل تغییرپذیری زیاد شوری خاک در مقیاس‌های مکانی مختلف، انتظار می‌رود که رفتار بازتاب‌های طیفی در برآورد هدایت الکتریکی همواره از الگوی یکنواختی پیروی نکند. استفاده از روش‌های کم هزینه و داده‌های در دسترس، امکان پایش مستمر را فراهم کرده و به کشاورزان در شناسایی مناطق هم پتانسیل تولید کمک میکند. این رویکرد، تصمیم‌گیری آگاهانه در مدیریت اراضی و اجرای اقدامات مؤثر برای حفظ و بهبود سلامت خاک را تسهیل می‌نماید.

نتیجه‌گیری

یافته‌های این پژوهش به وضوح نشان داد که شوری خاک در دشت مہولات نتیجه تعامل پیچیده‌ای از عوامل اقلیمی (خشکی و تبخیر بالا)، کیفیت آب زیرزمینی به ویژه مقادیر بالای SAR، HCO_3^- و TDS، ویژگی‌های توپوگرافی و تأثیرات انسانی از جمله روش‌های آبیاری، نوع کاربری اراضی و مدیریت کشاورزی است. در این میان، نتایج مدل ترکیبی توسعه یافته در این پژوهش تأکید کرد که پارامترهای کیفیت آب زیرزمینی به ویژه نقش بسیار تعیین کننده‌تر از متغیرهای صرفاً توپوگرافی یا پوشش گیاهی در توزیع مکانی شوری دارند که لزوم توجه ویژه به پایش کیفیت آب زیرزمینی را در برنامه‌های مدیریتی دوچندان می‌سازد. با وجود آنکه نتایج مدل ترکیبی، اهمیت نسبی متغیرهای کیفیت آب زیرزمینی را در تبیین الگوی مکانی شوری خاک برجسته می‌سازد، تعمیم این یافته به اولویت‌بندی قطعی عوامل مدیریتی و نسبت دادن الگوهای مشاهده‌شده به سازوکارهای علی، مستلزم تفکیک دقیق اثرات مستقل و برهم‌کنش‌های متقابل متغیرها و نیز اعتبارسنجی نتایج در مقیاس‌های زمانی و مکانی متفاوت است. با توجه به این که عوامل اقلیمی و زمین ریخت شناسی به عنوان بخشی از خصوصیات ذاتی منطقه، عملاً غیرقابل تغییر هستند، تمرکز راهکارهای مقابله با شوری باید بر بهبود عوامل فنی و مدیریتی معطوف گردد.

با توجه به غیرقابل تغییر بودن عوامل اقلیمی و زمین‌ریخت‌شناسی، تمرکز راهکارهای مقابله با شوری باید بر بهبود عوامل فنی و مدیریتی معطوف گردد. مقایسه نقشه شوری با دقت ۰/۸۱ با نقشه کاربری اراضی نشان می‌دهد که در مناطقی با شوری بالا ($EC > 16 \text{ dS m}^{-1}$)، الگوی کاهش سطح زیر کشت باغات پسته محسوس است. استفاده از داده‌های سنجنش‌ازدور و یادگیری ماشین می‌تواند پهنه‌های همگن شوری را شناسایی کرده و زمینه را برای اجرای روش‌های اصلاحی هدفمند مانند آبشویی کنترل‌شده، کاربرد اصلاح‌کننده‌های شیمیایی، تغییر الگوی کشت و جایگزینی محصولات مقاوم به شوری فراهم سازد.

به‌کارگیری راهبردهای مدیریتی مکان‌مبنا به جای رویکردهای یکنواخت، برای مهار پیشرفت شوری و تضمین پایداری تولیدات کشاورزی در دشت مہولات ضروری است. پیشنهاد می‌شود در مطالعات آینده، به منظور افزایش دقت پیش‌بینی شوری خاک در مقیاس‌های فصلی و سالانه، از رویکردهای ترکیبی یادگیری عمیق استفاده گردد. در این راستا، شبکه‌های عصبی پیچشی (CNN) قابلیت استخراج خودکار ویژگی‌های مکانی-طیفی را از تصاویر ماهواره‌ای چندزمانه (مانند لندست ۸ و سنتینل-۲) دارند و شبکه‌های حافظه طولانی-کوتاه‌مدت (LSTM) برای مدل‌سازی وابستگی‌های زمانی داده‌های سری‌زمانی شوری مناسب هستند. ترکیب این دو معماری در قالب مدل‌های CNN-LSTM می‌تواند الگوهای مکانی-زمانی شوری را با دقت بالاتری نسبت به مدل‌های سنتی یادگیری ماشین برآورد کند. داده‌های ورودی مورد نیاز شامل سری‌های زمانی تصاویر ماهواره‌ای (فصلی یا ماهانه)، متغیرهای هواشناسی (دما، تبخیر و تعرق، بارندگی، رطوبت نسبی) و اندازه‌گیری‌های میدانی هدایت الکتریکی خاک در بازه‌های زمانی منظم (مثلاً هر فصل) است. همچنین ارزیابی عملکرد این مدل‌ها با معیارهایی نظیر R^2 ، RMSE و MAE توصیه می‌شود. در نهایت، بررسی آثار اقتصادی و اجتماعی به‌کارگیری نقشه‌های شوری حاصل از مدل ترکیبی در باغات پسته، می‌تواند به درک جامع‌تری از کارایی عملی این رویکرد منجر شود.

سپاسگزاری

پژوهش حاضر حاصل نتایج بخشی از طرح پژوهشی با کد طرح ۶۴۳۰۷ در دانشگاه فردوسی مشهد بوده است. بدینوسیله از تمامی کسانی که در انجام این پژوهش ما را یاری رسانده‌اند، صمیمانه سپاسگزاری می‌شود.

References

- Akbari, M., Modarres, R., & Alizadeh Noughani, M. (2020). Assessing early warning for desertification hazard based on E-SMART indicators in arid regions of northeastern Iran. *Journal of Arid Environments*, 174, 104086. <https://doi.org/10.1016/j.jaridenv.2019.104086>
- Akbari, M., Ownegh, M., Asgari, H. R., Sadoddin, A., & Khosravi, H. (2016a). "Desertification Risk Assessment and Management Program." *Global Journal of Environmental Science and Management*, 2 (4), 365–80. <https://doi.org/10.22034/gjesm.2016.02.04.006>
- Akbari, M., Ownegh, M., Asgari, H. R., Sadoddin, A., & Khosravi, H. (2016b). Design and Development of Early Warning System for Desertification and Land Degradation. *Environmental Resources Research*, 4(2), 111-130. <https://doi.org/10.22069/ijerr.2017.11207.1152>
- Akbari, M., Sarbazi, M., Sibevei, A., & Fadaie, S. (2024). Desertification Risk Assessment and Providing Management Strategies using the DPSIR-M Model in Khorasan Razavi province. *Journal of Geography and Environmental Hazards*, 13(2), 210-239. [In Persian] <https://doi.org/10.22067/geoh.2023.83917.1404>
- Allbed, A., Kumar, L., & Aldakheel, Y. Y. (2014). Assessing soil salinity using soil salinity and vegetation indices derived from IKONOS high-spatial resolution imageries: Applications in a date palm dominated region. *Geoderma*, 230–231, 1–8. <https://doi.org/10.1016/j.geoderma.2014.03.025>
- Al-Refahi, M., Karimi, A., Mahmoudabadi, E., & Akbari, M. (2025). Evaluation of Soil Salinity Zonation Using Remote Sensing and Geostatistical Methods in the Alluvial Plain Lands of the Tigris River, Iraq. *Journal of Geography and Environmental Hazards*, 14(4), 85-104. [In Persian] <https://doi.org/10.22067/geoh.2025.93856.1579>
- Arnous, M. O., & Green, D. R. (2015). Monitoring and assessing waterlogged and salt-affected areas in the Eastern Nile Delta region, Egypt, using remotely sensed multi-temporal data and GIS. *Journal of Coastal Conservation*, 19, 369–391. <https://doi.org/10.1007/s11852-015-0380-2>

- Bandak, S., Boali, A., Komaki, C. B., Ghorbani, K., & Alinejad, M. (2026). Machine learning-based estimation and spatial mapping of soil phosphorus and potassium using sentinel-2 and environmental covariates. *Scientific Reports*. <https://doi.org/10.1038/s41598-026-59967-w>
- Bandak, S., Boali, A., Yaghobi, S., & Taghizadeh-Mehrjardi, R. (2025). Ensemble machine learning approaches for estimating soil texture components in loess soils of Golestan Province. *Earth Science Informatics*, 18(2), 396. <https://doi.org/10.1007/s12145-025-01897-8>
- Bannari, A., & Al-Ali, Z. M. (2020). Assessing climate change impact on soil salinity dynamics between 1987 and 2017 in arid landscapes using Landsat TM, ETM+, and OLI data. *Remote Sensing*, 12(17), 2794. <https://doi.org/10.3390/rs12172794>
- Bargam, B., Boudhar, A., Kinnard, C., Bouamri, H., Nifa, K. & Chehbouni, A. (2024). Evaluation of the support vector regression (SVR) and the random forest (RF) models' accuracy for streamflow prediction under a data-scarce basin in Morocco. *Discover Applied Sciences*, 6, 306. <https://doi.org/10.1007/s42452-024-05994-z>
- Basak, N., Rai, A. K., Barman, A., Mandal, S., Sundha, P., Bedwal, S., Kumar, S., Yadav, R. K., & Sharma, P. C. (2022). Salt-affected soils: Global perspectives. In *Soil health and environmental sustainability: Application of geospatial technology* (pp. 107–129). Springer. https://doi.org/10.1007/978-3-031-09270-1_6
- Boali, A., & Akbari, M. (2026). Analysis of early warning signals of desertification hazard using time series of remote sensing-based indices (Case study: Mashhad County, Razavi Khorasan Province, Iran). *Geography and Environmental Hazards*, 15(2), 44–62. [In Persian] <https://doi.org/10.22067/geoh.2026.97882.1652>
- Boali, A., Asgari, H. R., Mohammadian Behbahani, A., Salmanmahiny, A., & Naimi, B. (2024a). Remotely sensed desertification modeling using an ensemble of machine learning algorithms. *Remote Sensing Applications: Society and Environment*, 34, 101149. <https://doi.org/10.1016/j.rsase.2024.101149>
- Boali, A., Kariminejad, N., & Akbari, M. (2026). Spatial modeling of soil organic carbon using satellite imagery and machine learning for sustainable land management. In: Pourghasemi, H.R., Maleki, S. (Eds.), *The Soil Nexus: Understanding Ecosystem Dynamics and Digital Innovations*. Elsevier. <https://doi.org/10.1016/B978-0-443-45286-4.00005-5>
- Boali, A., Kariminejad, N., & Hosseinalizadeh, M. (2024b). Enhancing wind erosion risk assessment through remote sensing techniques. *PLoS ONE*, 19(10), e0308854. <https://doi.org/10.1371/journal.pone.0308854>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Brunner, P. H., Li, H. T., Kinzelbach, W., & Li, W. P. (2007). Generating soil electrical conductivity maps at the regional level by integrating measurements on the ground and remote sensing data. *International Journal of Remote Sensing*, 28(15), 3341–3361. <https://doi.org/10.1080/01431160600928641>
- Dong, W., Wu, T., Luo, J., Sun, Y., & Xia, L. (2019). Land parcel-based digital soil mapping of soil nutrient properties in an alluvial-diluvial plain agricultural area in China. *Geoderma*, 340, 234–248. <https://doi.org/10.1016/j.geoderma.2019.01.018>
- FAO. (2024). *Global status of salt-affected soils: Main report*. FAO. <https://doi.org/10.4060/cd3044en>
- Gallant, J. C., & Dowling, T. I. (2003). A multiresolution index of valley bottom flatness for mapping depositional areas. *Water Resources Research*, 39(12), 1347. <https://doi.org/10.1029/2002WR001426>
- Golestani, M., Ghahfarokhi, Z., Esfandiarpour, I., & Shirani, H. (2023). Evaluating the spatiotemporal variations of soil salinity in Sirjan Playa, Iran, using Sentinel-2A and Landsat-8 OLI imagery. *Catena*, 231, 107375. <https://doi.org/10.1016/j.catena.2023.107375>
- Haq, Y. U., Shahbaz, M., Asif, S., Ouahada, K., & Hamam, H. (2023). Identification of soil types and salinity using MODIS Terra data and machine learning techniques in multiple regions of Pakistan. *Sensors*, 23(19), 8121. <https://doi.org/10.3390/s23198121>
- Hassani, A., Azapagic, A., & Shokri, N. (2020). Predicting long-term dynamics of soil salinity and sodicity on a global scale. *Proceedings of the National Academy of Sciences*, 117(52), 33017–33027. <https://doi.org/10.1073/pnas.2000925117>

- Hong-wei, W., Yong-hong, F., & Tiyp, T. (2011). The research of soil salinization human impact based on remote sensing classification in oasis irrigation area. *Procedia Environmental Sciences*, 10(2), 2399–2405. <https://doi.org/10.1016/j.proenv.2011.09.373>
- Iwahashi, J., & Pike, R. J. (2007). Automated classifications of topography from DEMs by an unsupervised nested-means algorithm and a three-part geometric signature. *Geomorphology*, 86(3–4), 409–440. <https://doi.org/10.1016/j.geomorph.2006.09.012>
- John, K., Isong, I. A., Kebonye, N. M., Ayito, E. O., Agyeman, P. C., & Afu, S. M. (2020). Using machine learning algorithms to estimate soil organic carbon variability with environmental variables and soil nutrient indicators in an alluvial soil. *Land*, 9(12), 487. <https://doi.org/10.3390/land9120487>
- Jordan, C. F. (1969). Derivation of leaf-area index from quality of light on the forest floor. *Ecology*, 50(4), 663–666. <http://dx.doi.org/10.2307/1936256>
- Karimpour Reyhan, M., Momeni, H., & Shahsavar, A. (2024). Analyzing the regional relations of urban peripherals with the center of Zanjan province. *Geography and Regional Future Studies*, 1(3), 14–29. [In Persian] <https://doi.org/10.30466/grfs.2024.54960.1026>
- Karimpour Reyhan, M., & Shahsavar, A. (2023). *Land-use planning: A conceptual approach*. Tahan Gostar Publishing. [In Persian]
- Lämternicht, G. (2019). *Spatial land-use planning: Capacity and feasibility for sustainable land-resource management* (M. Karimpour Reyhan, S. Sharif Jahed, P. Amiri, & A. Shahsavar, Trans.; 2nd ed.). Tehran: University of Tehran Press [In Persian]
- Li, W., Gao, S., Mu, X., Wen, Y., Javed, T., & Wang, Z. (2026). Exploring the driving forces of soil salinity reduction using random forest and SHAP in water-saving oasis irrigation areas. *Irrigation Science*, 44(1), 25. <https://doi.org/10.1007/s00271-025-01045-6>
- Li, X., Li, Y., Wang, B., Sun, Y., Cui, G., & Liang, Z. (2022). Analysis of spatial-temporal variation of the saline-sodic soil in the west of Jilin Province from 1989 to 2019 and influencing factors. *Catena*, 217, 106492. <https://doi.org/10.1016/j.catena.2022.106492>
- Liu, D., Zhang, Y., Zhang, J., Xiong, L., Liu, P., Chen, H., & Yin, J. (2021). Rainfall estimation using measurement report data from time-division long-term evolution networks. *Journal of Hydrology*, 600, 126530. <https://doi.org/10.1016/j.jhydrol.2021.126530>
- Maleki, S., Fathizad, H., Karimi, A., Taghizadeh-Mehrjardi, R., & Pourghasemi, H. R. (2023). Monitoring of spatiotemporal changes of soil salinity and alkalinity in eastern and central parts of Iran. In *Computers in Earth and Environmental Sciences* (Chap. 40, pp. 547–561). Elsevier. <https://doi.org/10.1016/B978-0-323-89861-4.00011-7>
- Maleki, S., Pouyan, S., Khoshoui, M. M., Tiefenbacher, J. P., & Pourghasemi, H. R. (2024). Detecting soil salinization, sodicity, and alkalization hazards within cultivated lands using digital soil mapping approaches. In *Advanced tools for studying soil erosion processes* (pp. 435–460). Elsevier. <https://doi.org/10.1016/B978-0-323-90957-2.00018-X>
- Moore, I. D., Gessler, P. E., Nielsen, G. A. E., & Peterson, G. A. (1993). Soil attribute prediction using terrain analysis. *Soil Science Society of America Journal*, 57(2), 443–452. <https://doi.org/10.2136/sssaj1993.03615995005700020026x>
- Mousavi, A., Karimi, A., Maleki, S., Safari, T., & Taghizadeh-Mehrjardi, R. (2023). Digital mapping of selected soil properties using machine learning and geostatistical techniques in Mashhad Plain, northeastern Iran. *Environmental Earth Sciences*, 82(9), 234. <https://doi.org/10.1007/s12665-023-11050-z>
- Nabiollahi, K., Taghizadeh-Mehrjardi, R., Shahabi, A., Heung, B., Amirian-Chakan, A., Davari, M., & Scholten, T. (2021). Assessing agricultural salt-affected land using digital soil mapping and hybridized random forests. *Geoderma*, 385, 114858. <https://doi.org/10.1016/j.geoderma.2020.114858>
- Nasrian, A., Akbari, M., Faridhosseini, A., & Neamatollahi, E. (2022). Spatio-temporal Monitoring of Groundwater Changes on Desertification Intensity in Agricultural Areas in Dargaz Plain, Khorasan Razavi Province. *Desert Ecosystem Engineering*, 7(21), 75–90. [In Persian] <https://doi.org/10.22052/deej.2018.7.21.49>

- Page, A. L., Miller, R. H., & Keeney, D. R. (1982). *Methods of soil analysis: Part 2. Chemical and microbiological properties* (2nd ed.). ASA, SSSA, CSSA.
- Rahimi, B., Afzali, M., Farhadi, F., & Alamolhoda, A. (2021). Reverse osmosis desalination for irrigation in a pistachio orchard. *Desalination*, 516, 115236. <https://doi.org/10.1016/j.desal.2021.115236>
- Ray, S. S., Singh, J. P., Dutta, S., & Panigrahy, S. (2002). Analysis of within field variability of crop and soil using field data and spectral information as a pre-cursor to precision crop management. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 34(7), 302-307.
- Richardson, A. D., Duigan, S. P., & Berlyn, G. P. (2002). An evaluation of noninvasive methods to estimate foliar chlorophyll content. *New Phytologist*, 153(1), 185-194.
- Rock, B. N., Vogelmann, J. E., Williams, D. L., Vogelmann, A. F., & Hoshizaki, T. (1985). Plant responses to stress may have spectral signatures that could be used to map, monitor, and measure forest damage. *Remote Detection of Forest Damage*, 36(7), 439-445. <https://doi.org/10.2307/1310339>
- Rondeaux, G., Steven, M., & Baret, F. (1996). Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*, 55(2), 95-107. [https://doi.org/10.1016/0034-4257\(95\)00186-7](https://doi.org/10.1016/0034-4257(95)00186-7)
- Rouse, J. W., Haas, R. H., Scheel, J. A., & Deering, D. W. (1974). Monitoring Vegetation Systems in the Great Plains with ERTS. *Proceedings, 3rd Earth Resource Technology Satellite (ERTS) Symposium*, 1, 48-62. <https://ntrs.nasa.gov/citations/19740022614>
- Sharififar, A., & Sarmadian, F. (2023). Coping with the imbalanced data problem in digital mapping of soil classes. *European Journal of Soil Science*, 74(3), e13368. <https://doi.org/10.1111/ejss.13368>
- Tarini, M., Cignoni, P., & Montani, C. (2006). Ambient occlusion and edge cueing to enhance real time molecular visualization. *IEEE Transactions on Visualization and Computer Graphics*, 12(5), 1237-1244. <https://doi.org/10.1109/TVCG.2006.115>
- Toomanian, N., Jalalian, A., Khademi, H., Karimian Eghbal, M., & Papritz, A. (2006). Pedodiversity and pedogenesis in Zayandeh-rud Valley, Central Iran. *Geomorphology*, 81(3), 376-393. <https://doi.org/10.1016/j.geomorph.2006.04.016>
- Weiss, A. (2001). *Topographic position and landforms analysis*. In Proceedings of the ESRI International User Conference. San Diego, CA, USA
- Xiao, C., Ji, Q., Chen, J., Zhang, F., Li, Y., Fan, J., Hou, X., Yan, F., & Wang, H. (2023). Prediction of soil salinity parameters using machine learning models in an arid region of northwest China. *Computers and Electronics in Agriculture*, 204, 107512. <https://doi.org/10.1016/j.compag.2023.107512>
- Ye, L., Lin, X., Huang, L., Ji, K., Drost, T. A., Wan, W., & Zuo, J. (2026). Digital mapping of soil fauna abundance and diversity using Sentinel-1/2 and environmental attributes. *Soil and Tillage Research*, 255, 106796. <https://doi.org/10.1016/j.still.2025.106796>
- Yin, W., Hu, Q., Liu, J., He, P., Zhu, D., & Boali, A. (2024). Assessing Climate and Land-Use Change Scenarios on Future Desertification in Northeast Iran: A Data Mining and Google Earth Engine-Based Approach. *Land*, 13(11), 1802. <https://doi.org/10.3390/land13111802>
- Zinck, J. A. (1989). *Physiography and soils. Lecture Notes for Soil Students, Soil Science Division, Soil Survey Courses*. International Institute for Geo-Information Science and Earth Observation (ITC), Enschede, The Netherlands.