



Assessment of Spatial Distribution of Surface and Subsurface Soil Salinity Using a Digital Mapping Approach (A Case Study in Dehloran County)

Sahereh Safarlaki¹ | Azadeh Safadoust^{1*} | Mahmood Rostaminia² |
Seyedeh Bahareh Azimi³

1. Department of Soil Science and Engineering, College of Agriculture, Bu-Ali Sina University, Hamadan, Iran.

2. Department of Soil and Water, Agriculture Faculty, Ilam University, Ilam, Iran.

3. Department of Environment, Research Group of Environmental Assessment and Risk, Research Center for Environment and Sustainable Development (RCESD), Tehran, Iran

Correspond E-mail: safadoust@basu.ac.ir

Article Info

Article type:

Research Article

Article history:

Received: 16 May. 2025

Revised: 22 Jun. 2025

Accepted: 27 Jun. 2025

Published online: 01 Jan. 2026

Keywords:

Environmental variables,

Random forest,

Soil salinity,

Topography.

Abstract

Accurate spatial data on soil property distribution is crucial for monitoring of land resources, informed management practices, and robust environmental modeling, especially in arid and semi-arid regions. This study aimed to develop a spatial prediction model for soil salinity in the Meymeh Plain, Dehloran Province. The Random Forest (RF) algorithm was employed to investigate spatial variations in soil salinity within the surface (0–30 cm) and subsurface (30–60 cm) soil layers. Soil samples were collected from 100 sites, analyzed for electrical conductivity (EC), and the spatial variability of soil salinity was modeled using random forest (RF) analysis. Seven environmental variables of Greenery, Diffuse Radiation, Valley Bottom Flatness Index, Normalized Difference Vegetation Index, Salinity Index, Wind Direction Index, and Brightness were selected based on the Variance Inflation Factor, including parameters from a digital elevation model and Sentinel-2 satellite reflectance data. The model used 80% of the data for calibration and 20% for validation, with performance assessed through root mean square error (RMSE), coefficient of determination (R^2), and concordance correlation coefficient (CCC). The RF model showed high prediction accuracy for surface EC and relatively acceptable results for subsurface layers. The R^2 for the surface layer was 0.92, and for the subsurface layer was 0.37; the RMSE for the surface and subsurface layers was 0.22; and the CCC for the surface layer was 0.82 and for the subsurface layer was 0.97. Overall, topographic derivatives demonstrated a greater influence on predicting soil salinity in both surface and subsurface layers compared to remote sensing data. The multi-resolution valley bottom flatness index with high spatial resolution was identified as the most important predictor of soil salinity, highlighting the impact of topographic factors in the study area.

Cite this article: Safarlaki, S., Safadoust, A., Rostaminia, M., Azimi, S.B. (2025). Assessment of Spatial Distribution of Surface and Subsurface Soil Salinity Using a Digital Mapping Approach: A Case Study in Dehloran County. *Journal of Range & Watershed Management*, 78 (4), 513-528. DOI: <http://doi.org/10.22059/jrwm.2025.395192.1832>



EXTENDED ABSTRACT

Introduction: High-resolution spatial information on the distribution of soil properties plays a vital role in accurately monitoring land resources, making informed decisions for land use management, and building reliable environmental models. Such detailed data not only enhances our understanding of soil variability and health but also underpins essential ecohydrological processes that influence vegetation dynamics, water retention, and nutrient cycling. These insights are crucial for the development of sustainable land management strategies, especially in the context of increasing environmental stresses such as climate change, land degradation, and desertification. In particular, regions characterized by arid and semi-arid climates face unique challenges, including limited water availability and a higher susceptibility to salinization. Soil salinity, one of the most widespread forms of land degradation in dryland regions, negatively affects agricultural productivity, soil structure, and long-term land usability. Addressing this issue requires a deep understanding of the spatial variability of salinity across different soil layers and depths. Accurate prediction and mapping of soil salinity can guide targeted intervention strategies, optimize land use practices, and support effective resource allocation to mitigate the adverse effects on crop yields and ecosystem services. This study aimed to develop a robust spatial prediction model of soil salinity for the Miameh Plain in Dehloran County, a region that exemplifies the environmental and agricultural challenges common in arid landscapes. By leveraging advanced geospatial techniques and machine learning methods, specifically the Random Forest (RF) model, the research sought to generate high-resolution salinity maps for both surface and subsurface soil layers. These maps provide valuable insights into the distribution and severity of soil salinity, which are essential for implementing site-specific soil management practices and planning long-term mitigation efforts.

Methodology: The study area is located in southwestern Iran, about 7 kilometers from Dehloran city in southeastern Ilam Province. It spans geographic coordinates from 32°33'22.32" to 32°40'21.33" N latitude and 47°15'38.89" to 47°10'22.54" E longitude. Elevation ranges from 124 to 167 meters above sea level, covering approximately 3,000 hectares. Land slopes range from 0 to 5%, with most areas between 0 and 1%. The terrain is primarily oriented southward and eastward. The region has a Ustic moisture regime and a Hyperthermic temperature regime. Soil profiles feature an Ochric surface horizon and subsurface Cambic, Calcic, and Gypsic horizons. This study aimed to develop a spatial prediction model for soil salinity in the Meymeh Plain using the Random Forest (RF) machine learning algorithm. Soil samples were collected from 100 sites at two depths (0–30 cm and 30–60 cm) and analyzed for electrical conductivity (EC). The RF model was used to map spatial variations in EC across both layers. Seven environmental variables were selected to support the model, including indices such as Greenery, Diffuse Radiation, Valley Bottom Flatness, NDVI, Salinity Index, Wind Direction Index, and Brightness. These variables were derived from a digital elevation model (DEM) and Sentinel-2 satellite reflectance data and selected based on the Variance Inflation Factor (VIF) to reduce multicollinearity. The dataset was split into two subsets: 80% for model calibration and 20% for validation. Model performance was assessed using root mean square error (RMSE), coefficient of determination (R^2), and concordance correlation coefficient (CCC). All modeling was conducted using RStudio software.

Findings: The Random Forest (RF) model demonstrated strong predictive performance for soil electrical conductivity (EC) in the surface layer, with a coefficient of determination (R^2) of 0.80, indicating a high level of model accuracy. In contrast, its performance for the subsurface layer was more moderate, yielding an R^2 value of 0.37, which reflects a reduced but still informative level of predictability at greater soil depths. The root mean square error (RMSE) was 0.22 for both surface and subsurface layers. In terms of model agreement, the concordance correlation coefficient (CCC) further supported the disparity in performance between layers. The CCC for the surface layer was 0.92, denoting excellent agreement between observed and predicted values. However, the CCC for the subsurface layer dropped significantly to 0.97, indicating a much weaker correspondence in predictions for deeper soil strata. Among the suite of predictor variables used, topographic derivatives emerged as more influential in predicting soil salinity than remote sensing indices. Notably, the multi-resolution valley bottom flatness (MRVBF) index, derived from digital elevation data, was identified as the most important predictor across both soil layers. This emphasizes the significant role that landscape position and terrain-driven water accumulation play in controlling spatial patterns of salinity, particularly in arid environments.

Conclusion: The study highlights the effectiveness of the RF model in predicting surface soil salinity with high accuracy, while its performance in subsurface layers remains moderate and suggests the need for further refinement or integration of additional predictors at depth. The findings underscore the critical influence of topographic variables, especially the MRVBF index, in governing the spatial distribution of soil salinity in the Miameh Plain. This suggests that terrain-based modeling offers valuable insights for soil salinity assessment, particularly in arid and semi-arid landscapes where topography strongly influences hydrological and salinization processes. These results provide a valuable foundation for site-specific soil management and salinity mitigation strategies in similar dryland regions.

Keywords: *Environmental variables, random forest, soil salinity, topography*

Conflicts of interest: The authors of this article declared no conflict of interest regarding the authorship or publication of this article.



دوره ۷۸ (۴)

شاپا الکترونیکی: ۷۷۹۵-۲۴۲۳

نشریه مرتع و آبخیزداری



ارزیابی توزیع مکانی شوری خاک سطحی و زیرسطحی با استفاده از رویکرد نقشه برداری رقومی (مطالعه موردی در شهرستان دهلران)

ساهره صفرلکی^۱ | آزاده صفادوست^{۱*} | محمود رستمی نیا^۲ | سیده بهاره عظیمی^۳

۱. گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان، ایران

۲. گروه آب و خاک، دانشکده کشاورزی، دانشگاه ایلام، ایلام، ایران

۳. گروه پژوهشی ارزیابی و مخاطرات محیط زیست، پژوهشکده محیط زیست و توسعه پایدار، سازمان حفاظت محیط زیست، تهران، ایران

رایانامه: safadoust@basu.ac.ir

چکیده

اطلاعات مقاله

نوع مقاله:

مقاله پژوهشی

تاریخ دریافت: ۱۴۰۴/۰۲/۲۶

تاریخ بازنگری: ۱۴۰۴/۰۴/۰۱

تاریخ پذیرش: ۱۴۰۴/۰۴/۰۶

تاریخ انتشار: ۱۴۰۴/۱۰/۱۱

کلیدواژه‌ها:

توپوگرافی،

جنگل تصادفی،

شوری خاک،

متغیر محیطی.

اطلاعات مکانی دقیق درباره توزیع ویژگی‌های خاک برای نظارت بر منابع اراضی، مدیریت آگاهانه و مدل‌سازی‌های محیطی، به‌ویژه در مناطق خشک و نیمه خشک، حیاتی است. این مطالعه به منظور توسعه یک مدل پیش‌بینی مکانی برای شوری خاک در دشت میمه، شهرستان دهلران، با استفاده از الگوریتم یادگیری ماشین جنگل تصادفی (RF) جهت بررسی تغییرات مکانی شوری خاک در لایه سطحی و زیرسطحی انجام شده است. نمونه‌های خاک از ۱۰۰ نقطه جمع‌آوری، قابلیت هدایت الکتریکی (EC) آنها اندازه‌گیری و تغییرات مکانی شوری خاک با استفاده از مدل RF مدل‌سازی شد. هفت متغیر محیطی شامل شاخص سبزیگی، شدت تابش پخشیده، شاخص همواری کف دره، شاخص تفاضلی پوشش گیاهی نرمال شده، شاخص شوری، شاخص اثر باد و درخشندگی بر اساس روش جنگل تصادفی از مدل رقومی ارتفاع و داده‌های ماهواره‌ای سنتتیل ۲ بودند. این مدل با استفاده از ۸۰ درصد از داده‌ها برای آموزش و ۲۰ درصد برای اعتبارسنجی طراحی شد و کارایی آن از طریق آماره‌های ریشه دوم میانگین مربعات خطا (RMSE)، ضریب تعیین (R^2) و ضریب همبستگی تطابق (CCC) ارزیابی گردید. مدل RF دقت پیش‌بینی بالایی برای EC در خاک سطحی و نسبتاً قابل قبولی برای لایه زیرسطحی نشان داد؛ به گونه‌ای که به ترتیب مقادیر R^2 برابر با ۰/۸۰ و ۰/۳۷ و مقادیر CCC برابر ۰/۹۲ و ۰/۹۷ برای لایه سطحی زیرسطحی بدست آمد. به طور کلی مشتقات توپوگرافی هم در خاک سطحی و هم زیرسطحی نسبت به داده‌های سنجش از دور نقش بیشتری در پیش‌بینی شوری خاک نشان دادند؛ و از طرفی شاخص همواری کف دره با درجه وضوح بالا به عنوان مهم‌ترین پیش‌بینی کننده شوری خاک شناسایی شد که نشان از تأثیر بالای متغیرهای وابسته به فاکتورهای توپوگرافی در تغییرپذیری وضعیت شوری در خاک‌های منطقه مطالعاتی دارد. نتایج این مطالعه می‌تواند در مدیریت پایدار اراضی شور، کشاورزی دقیق، برنامه‌ریزی منابع آب و پایش تغییرات شوری خاک مورد استفاده قرار گیرد.

استناد: صفرلکی، ساهره، صفادوست، آزاده، رستمی نیا، محمود، عظیمی، سیده بهاره (۱۴۰۴). ارزیابی توزیع مکانی شوری خاک سطحی و زیرسطحی با استفاده از رویکرد نقشه برداری رقومی

(مطالعه موردی در شهرستان دهلران). نشریه مرتع و آبخیزداری، ۷۸ (۴)، ۵۲۸-۵۱۳.

DOI: <http://doi.org/10.22059/jrwm.2025.395192.1832>



© نویسندگان.

ناشر: انتشارات دانشگاه تهران.

۱. مقدمه

شوری خاک به تجمع املاح و نمک‌های محلول در خاک اطلاق می‌شود که یکی از معضلات زیست‌محیطی و کشاورزی در سطح جهانی است. این پدیده تأثیرات منفی گسترده‌ای بر پوشش گیاهی، امنیت غذایی، سلامت محیط زیست و پایداری اکوسیستم‌ها دارد. شوری خاک به‌ویژه در مناطق خشک و نیمه‌خشک به عنوان یکی از چالش‌ها و محدودیت‌های اصلی در افزایش تولید محصولات کشاورزی شناخته می‌شود (Tully et al., 2019; Zhao et al., 2020). تأثیرات منفی شوری شامل کاهش تعرق گیاهان، اختلال در فرآیندهای زیستی و زیست‌محیطی و به‌طور خاص، کاهش رشد گیاهان است (D'Odorico et al., 2013). علاوه بر این، شوری می‌تواند بر فعالیت‌های میکروبی خاک اثر منفی گذاشته و موجب کاهش فعالیت‌های میکروبی و تنفس میکروبی شود (Liu et al., 2023). این اختلالات میکروبی منجر به کاهش باروری خاک و افت کیفیت خاک می‌گردد (Rath & Rousk, 2015). بیابان‌زایی نیز از دیگر پیامدهای شوری خاک است که به‌ویژه در مناطق خشک و نیمه‌خشک باعث تخریب محیط زیست و تهدید منابع آب و خاک می‌شود (D'Odorico et al., 2021; Perri et al., 2020; Taghizadeh-Mehrjardi et al., 2021). علاوه بر این، کاهش کربن آلی خاک به‌عنوان یکی از تبعات شوری می‌تواند فرآیندهای زیستی مهمی نظیر جذب آب و مواد مغذی توسط گیاهان را تحت تأثیر قرار دهد و به بحران‌های زیست‌محیطی دامن بزند (Wang et al., 2021).

بر اساس مطالعات مختلف، بیش از یک‌سوم اراضی جهان تحت تأثیر شوری خاک قرار دارند و این مسئله به‌ویژه در مناطق خشک و نیمه‌خشک به یکی از چالش‌های اساسی در توسعه کشاورزی پایدار و امنیت غذایی تبدیل شده است (Zhao et al., 2020; Hirich et al., 2024). شوری خاک در این مناطق می‌تواند مانع از رشد گیاهان زراعی و کاهش تولیدات کشاورزی گردد و از آنجا که بخش بزرگی از منابع غذایی جهان به کشاورزی وابسته است، این مشکل تهدیدی جدی برای امنیت غذایی به شمار می‌آید. در این راستا، بررسی شوری خاک و توزیع مکانی آن برای تصمیم‌گیری‌های مدیریتی در برنامه‌ریزی کشاورزی و سایر فعالیت‌های مرتبط، اهمیت بسیاری داشته و درک پراکنش مکانی ویژگی‌های خاک و مدیریت صحیح آن برای حفظ پایداری تولید کشاورزی ضروری است (Perri et al., 2018). با توجه به گسترش شوری در اراضی مختلف از بیابان‌ها گرفته تا اراضی کشاورزی و مناطق ساحلی، نیاز به دستیابی به اطلاعات مکانی دقیق از ویژگی‌های خاک بیش از پیش احساس می‌شود. این اطلاعات می‌تواند برای برنامه‌ریزی کاربری اراضی، جنگلداری، کشاورزی و حفاظت از محیط زیست بسیار حائز اهمیت باشد. یکی از روش‌های نوین و مؤثر برای بررسی و پیش‌بینی شوری خاک، نقشه‌برداری رقومی خاک است (Minasny et al., 2008; El Sebai et al., 2007). نقشه‌برداری رقومی خاک به معنای ایجاد و جمع‌آوری سیستم‌های اطلاعات مکانی خاک با استفاده از داده‌های میدانی، آزمایشگاهی و مدل‌های استنتاج مکانی است که می‌تواند برای مدیریت منابع خاک و برنامه‌ریزی کشاورزی استفاده شود (Lagacherie & McBratney, 2006). این روش با بهره‌گیری از تکنیک‌های ریاضی و آماری، امکان پیش‌بینی دقیق‌تر پراکنش ویژگی‌های مختلف خاک مانند شوری را فراهم می‌آورد (Hartemink & McBratney, 2008). همچنین به عنوان ابزاری برای ارائه اطلاعات مکانی دقیق، می‌تواند در تصمیم‌گیری‌های مدیریتی جهت رسیدگی به مشکلات زیست‌محیطی و کشاورزی بسیار مؤثر باشد. این روش از روابط بین داده‌های محیطی و ویژگی‌های خاک برای پیش‌بینی الگوهای مکانی تغییرات خاک استفاده می‌کند و به‌ویژه از مدل‌های عددی و روش‌های یادگیری ماشین^۱، برای تجزیه و تحلیل داده‌ها بهره می‌برد؛ که در این راستا می‌توان از انواع روش‌های داده‌کاوی^۲ استفاده کرد. در حقیقت داده‌کاوی یک حوزه میان رشته‌ای و در حال رشد سریع است که با بهره‌گیری از حوزه‌های مختلف مانند پایگاه داده‌ها، آمار، یادگیری ماشین و سایر زمینه‌های مرتبط، اطلاعات و دانش ارزشمند را از حجم گسترده‌ای از داده‌ها استخراج می‌کند (Manteghi et al., 2024; Mousavi et al., 2024).

^۱. Machine learning

^۲. Data mining methods

یکی از مدل‌های پیشرفته و موفق در این زمینه، مدل جنگل تصادفی^۱ (RF) است. این مدل با ترکیب مجموعه‌ای از درخت‌های تصمیم‌گیری، به پیش‌بینی دقیق و پایدار تغییرات ویژگی‌های خاک، مانند شوری، می‌پردازد (Zhao et al., 2024). مدل‌های مختلف نقشه‌برداری رقومی خاک، از جمله RF، روش‌های فازی، شبکه عصبی مصنوعی، رگرسیون درختی و رگرسیون لجستیک به منظور تحلیل و پیش‌بینی ویژگی‌های خاک به کار گرفته می‌شوند (Grunwald, 2009; Hartemink & McBratney, 2008). در سال‌های اخیر، مطالعات فراوانی در زمینه شوری خاک با بهره‌گیری از فناوری سنجش از دور انجام شده است (Wang et al., 2021; Corwin, 2021). با این حال، ارزیابی دقیق وضعیت خاک همچنان با چالش‌های متعددی مواجه است؛ چرا که برخی از پارامترهای کلیدی خاک، حتی در صورت تغییر، بازتاب طیفی اندکی از خود نشان می‌دهند و تشخیص آن‌ها از طریق داده‌های سنجش از دور دشوار است (Leitão et al., 2018). همچنین کارایی مدل‌های یادگیری ماشین در پیش‌بینی و نقشه‌برداری ویژگی‌های خاک در بسیاری از پژوهش‌ها به نحو مطلوبی گزارش شده است (Suleymanov et al., 2021). حسنی^۲ و همکاران (۲۰۲۲) با استفاده از مدل یادگیری ماشین نظارت شده و مجموعه‌ای از داده‌های اقلیمی، توپوگرافی، خاک و سنجش از دور^۳ به پیش‌بینی مکانی خاک‌های شور و سدیمی در پنج عمق خاک (۰، ۱۵، ۳۰، ۶۰ و ۱۰۰ سانتی‌متر) و بازه‌های زمانی متفاوت در مقیاس جهانی پرداختند. روش RF با ایجاد الگوهای غیرخطی بین داده‌ها، قادر به مدل‌سازی روابط پیچیده بین متغیرهای مستقل و وابسته است و دقت پیش‌بینی ویژگی‌های خاک در نواحی نمونه‌برداری را افزایش می‌دهد. با این حال ممکن است نتایج این روش دچار بیش برآزش شوند و متغیرهای کمکی محیطی با توزیع تصادفی، به دلیل ایجاد نویز، دقت مدل‌سازی را کاهش دهند (اسدی و همکاران، ۲۰۱۹؛ پولادی^۴ و همکاران، ۲۰۱۹). در پژوهش دیگری تریپاتی و تیواری^۵ (۲۰۲۱) همبستگی بالایی بین پراکنش مکانی شوری خاک با شاخص پوشش گیاهی^۶ (NDVI) و متعاقباً فاکتورهای توپوگرافی نظیر ارتفاع نسبی^۷، ارتفاع نسبت به شبکه زهکشی^۸ و خیزی توپوگرافی^۹ مشاهده نمودند. همچنین پنگ^{۱۰} و همکاران (۲۰۱۹) در مطالعه‌ای به منظور تخمین شوری خاک با استفاده از فاکتورهای توپوگرافی و داده‌های سنجش از دور، از میان ۱۵ فاکتور توپوگرافی بررسی شده، همبستگی بالایی بین مدل رقومی ارتفاع و فاصله شبکه آبراهه با شوری خاک (در سطح اطمینان ۹۹٪) نشان دادند. سایر فاکتورها مانند موقعیت نسبی شیب^{۱۱} و فاصله عمودی تا آبراهه^{۱۲} نیز همبستگی معنی‌داری در سطح ۹۵٪ داشتند، که نشانگر تأثیر سطوح هموار منطقه بر شوری خاک بود.

شهرستان دهلران به عنوان یکی از نواحی خشک و نیمه‌خشک کشور، با معضل جدی شوری خاک مواجه است؛ پدیده‌ای که به طور مستقیم موجب کاهش بهره‌وری کشاورزی و محدودیت در استفاده پایدار از منابع خاک و آب در منطقه می‌گردد. پژوهش حاضر با هدف مدل‌سازی و ارزیابی مکانی شوری خاک در اراضی دشت میمه انجام شده و در آن از ترکیب داده‌های سنجش از دور، شاخص‌های توپوگرافی استخراج شده از مدل رقومی ارتفاع (DEM) و الگوریتم یادگیری ماشین جنگل تصادفی (Random Forest) استفاده شده است. هدف اصلی مطالعه، تهیه نقشه‌های دقیق از پراکنش مکانی شوری در لایه‌های سطحی و زیرسطحی خاک است تا اطلاعاتی کاربردی برای مدیریت مزرعه، برنامه‌ریزی آبیاری، اصلاح خاک و بهینه‌سازی عملکرد گیاهان زراعی، به‌ویژه گیاهان یک‌ساله، فراهم گردد. ضرورت انجام این پژوهش از آن‌جا ناشی می‌شود که درک دقیق از الگوی مکانی و شدت شوری خاک در مناطق حساس، نقش کلیدی در تصمیم‌گیری‌های مدیریتی و اجرای راهکارهای کنترلی در سطح مزرعه دارد. در شرایط فعلی، نبود نقشه‌های به‌روز و دقیق از پراکنش شوری، روند برنامه‌ریزی‌های بهره‌برداری از اراضی کشاورزی را با چالش‌های جدی مواجه کرده است. نوآوری تحقیق حاضر در استفاده همزمان از الگوریتم جنگل تصادفی، داده‌های سنجش از دور و متغیرهای توپوگرافی به منظور پیش‌بینی دقیق شوری خاک در یک منطقه

1. Random forest

2. Hassani

3. Remote Sensing

4. Pouladi

5. Tripathi & Tiwari

6. Normalized Difference Vegetation Index

7. Relative Elevation

8. Elevation Relative to Drainage Network

9. Topographic Wetness

10. Peng

11. Relative Slope Position

12. Vertical Distance to Stream

خاص اقلیمی (دشت میمه) نهفته است. این رویکرد، نسبت به روش‌های سنتی، توان بالاتری در مدل‌سازی روابط پیچیده بین متغیرهای محیطی و شوری خاک دارد و می‌تواند به‌عنوان الگویی کارآمد در سایر مناطق خشک و نیمه‌خشک نیز مورد استفاده قرار گیرد.

۲. مواد و روش‌ها

۲-۱. منطقه مورد مطالعه

منطقه مورد مطالعه در ناحیه جنوب غربی ایران و در فاصله هفت کیلومتری شهر دهلران، در جنوب شرقی استان ایلام واقع شده است. منطقه در حد واسط مختصات جغرافیایی $32^{\circ}40'21''N$ تا $32^{\circ}33'22''N$ و $47^{\circ}15'38''E$ تا $47^{\circ}10'22''E$ واقع گردیده است (شکل ۱-الف و شکل ۱-ب). ارتفاع متوسط محدوده اراضی از سطح دریای آزاد بین ۱۲۴ تا ۱۶۷ متر و مساحت اراضی حدود ۳۰۰۰ هکتار است. شیب اراضی بین صفر تا ۵ درصد متغیر و سطح غالب اراضی در دامنه‌ی شیب بین صفر تا ۲ درصد قرار دارد؛ همچنین جهت شیب غالباً جنوبی و شرقی می‌باشد. رژیم رطوبتی این منطقه بر اساس روش نیوهال و نقشه رژیم‌های حرارتی و رطوبتی خاک‌های ایران به‌ترتیب یوستیک^۱ و هایپرترمیک^۲ است. افق مشخصه سطحی اُکریک و افق‌های مشخصه‌ی زیرسطحی کمیک، کلسیک و جیپسیک بیشترین تاثیر را در میزان تکامل خاک‌های منطقه دارند. میانگین بارندگی سالانه منطقه حدود ۲۷۷/۳ میلی‌متر و میانگین سالانه دمای آن حدود ۲۶/۳ درجه سانتی‌گراد می‌باشد (اداره کل هواشناسی استان ایلام).

از اراضی ۲۵۰۰ هکتاری واقع در قسمت شرقی رود خانه میمه، تعداد ۸۰ نمونه سطحی و زیرسطحی و از اراضی ۵۰۰ هکتاری قسمت غربی، ۲۰ نمونه سطحی و زیرسطحی به روش نمونه‌برداری ابر مکعب لاتین مشروط^۳ برداشت شد (شکل ۱-ج). در مجموع، ۱۰۰ نمونه سطحی و زیرسطحی جمع‌آوری گردید. پس از ثبت مختصات جغرافیایی محل برداشت نمونه‌ها، نقشه‌ای از موقعیت برداشت نمونه‌ها تهیه شد (شکل ۱). نمونه‌های خاک پس از انتقال به آزمایشگاه و انجام عملیات آماده‌سازی، شامل خشک شدن در هوا، کوبیدن و عبور از الک دو میلی‌متری، برای اندازه‌گیری قابلیت هدایت الکتریکی در عصاره گل اشباع (Rhoades et al., 1982) مورد استفاده قرار گرفتند. این پارامتر به‌عنوان شاخص وضعیت شوری خاک محاسبه شد.

۲-۲. نمونه‌برداری و تهیه متغیرهای محیطی

در نقشه‌برداری رقومی خاک، توزیع مکانی شوری خاک و ارتباط آن با عوامل مختلف تشکیل‌دهنده خاک، شامل ویژگی‌های خاک، مواد مادری، اقلیم، موجودات زنده، توپوگرافی و زمان، بر اساس مدل مکانی اسکورپن (مک براتنی^۴ و همکاران، ۲۰۰۳) تبیین می‌شود. در این پژوهش، متغیرهای توپوگرافی از مدل رقومی ارتفاع با وضوح ۱۲/۵ متر در نرم افزار SAGA GIS ۵.۰۰ نسخه ۵ استخراج شدند. همچنین متغیرهای سنجش از دور با استفاده از تصاویر ماهواره‌ی سنتینل ۲ مربوط به فصل پاییز (تاریخ ۸ آبان ۱۴۰۱) و با استفاده از نرم افزار ENVI 5.3 پردازش شدند. ابتدا پیش پردازش‌های لازم شامل تصحیحات رادیومتری و بهبود وضوح زمینه و حذف نویز تصاویر اعمال گردید. متغیرهای محیطی مورد استفاده برای پیش‌بینی مکانی شوری خاک با استناد به مطالعات پیشین انجام شده در منطقه مورد مطالعه انتخاب شدند (Khamoshi et al., 2018; Mousavi et al., 2021; Rahmani et al., 2021; Rezaie et al., 2023) (جدول ۱).

۲-۳. روند نمای کلی پژوهش

روند کلی پژوهش و مراحل انجام آن به ترتیب شامل موارد زیر بود: (۱) جمع‌آوری داده‌های خاک با استفاده از نمونه‌برداری به روش ابرمکعب لاتین مشروط، (۲) استخراج شاخص‌های سنجش از دور و پارامترهای توپوگرافی از تصاویر ماهواره سنتینل ۲ مربوط به تاریخ ۸


^۱ . Ustic

^۲ . Hyperthermic


^۳ . Conditional Latin Hypercube Sampling

^۴ . McBratney

آبان ۱۴۰۲ و مدل رقومی ارتفاع با تفکیک مکانی ۱۲/۵ متر، (۳) انتخاب متغیرهای محیطی بهینه، (۴) مدل سازی مکانی داده ها با استفاده از مدل RF و (۵) تهیه نقشه پیش بینی مکانی شوری خاک بر اساس مدل پیش بینی کننده مکانی و ارزیابی دقت مدل ها در پیش بینی شوری خاک در اعماق سطحی و زیر سطحی (Mousavi et al., 2021) (شکل ۲).



شکل ۱. موقعیت اراضی محدوده مطالعاتی و نقاط نمونه برداری: الف: موقعیت منطقه مطالعاتی در کشور ایران، ب: استان ایلام، شهرستان دهلران، ج: محل نقاط نمونه برداری شده از محدوده اراضی میمه واقع در جنوب شهر دهلران در دو قسمت ضلع شرقی و غربی رودخانه میمه



شکل ۲. نمای ساده از روند کلی انجام پژوهش

۲-۴. مدل سازی مکانی و انتخاب متغیرهای محیطی

در این پژوهش، از الگوریتم یادگیری ماشین غیر خطی جنگل تصادفی به عنوان یکی از روش های داده کاوی (بریمن^۱، ۲۰۰۱؛ مسعودی^۲ و همکاران، ۲۰۲۳)، برای مدل سازی مکانی شوری سطحی و زیر سطحی خاک استفاده گردید. تمامی مراحل مدل سازی پیش بینی مکانی شوری خاک بر اساس رویکرد داده کاوی جنگل تصادفی از بسته Random forest در نرم افزار RStudio 1.1.4 استفاده شد. RF که توسط بریمن (۲۰۰۱) توسعه یافته است، یک روش یادگیری ماشین است که به طور گسترده برای اهداف طبقه بندی و رگرسیون استفاده می شود. یک درخت تصمیم منفرد به دلیل واریانس و سوگیری بالای آن، طبقه بندی و رگرسیون ضعیفی را ارائه می دهد. در حالی که RF تمایل به تولید مدل های

^۱. Breiman

^۲. Masoudi

قوی دارد زیرا می‌تواند مشکلات یاد شده را با استفاده از مجموعه‌ای از درختان کاهش دهد. RF هزاران درخت دوتایی تصادفی را برای ایجاد RF تولید می‌کند. برای اجرای مدل RF کاربر باید دو پارامتر پیش‌بینی، تعداد درختان در جنگل (ntree) و تعداد متغیرهای قابل استفاده در انتهای هر گره (mtry) را بهینه کند تا خطای خارج از سبد^۱ (OOB) را به حداقل برساند و عملکرد مدل خوبی را به دست آورد.

۲-۵. ارزیابی کارایی مدل‌های یادگیری ماشین

فرآیند اعتبارسنجی مدل با استفاده از ۲۰٪ از کل داده‌ها به عنوان مجموعه آزمون انجام شد. برای این منظور، مقادیر برآورد شده برای هر نمونه از یک زیر مجموعه مستقل ارزیابی گردید. دقت مدل با استفاده از شاخص‌های آماری ضریب تعیین (R^2) (معادله ۱)، ضریب همبستگی تطابقی (معادله ۲) (CCC) و میانگین ریشه مربعات خطا (RMSE) (معادله ۳) برآورد شد. بر اساس نظر راسل و مک برایتنی^۲، (۲۰۰۸) رتبه‌بندی مقادیر ضریب تعیین (معادله ۱) برای پیش‌بینی ویژگی‌های خاک عبارت است از: خیلی خوب ($R^2 > 0/81$)، خوب ($R^2 = 0/61 - 0/81$)، متوسط ($0/41 \leq R^2 \leq 0/61$) و ضعیف ($R^2 < 0/41$) و RMSE (معادله ۲) نیز معیاری پرکاربرد برای تخمین تفاوت بین مقادیر پیش‌بینی شده توسط مدل و مقادیر اندازه‌گیری شده به کار می‌رود و همچنین مقیاسی از اندازه خطا را ارائه می‌دهد که به مقادیر پرت حساس است (Wallach et al., 2006).

$$R^2 = 1 - \frac{\sum_{i=1}^n (K_m - K_p)^2}{\sum_{i=1}^n (K_m - \bar{K}_m)^2} \quad \text{(رابطه ۱)}$$

$$CCC = \frac{2r\sigma_{K_m}\sigma_{K_p}}{\sigma_{K_m}^2 + \sigma_{K_p}^2 + (\bar{P}_i - \bar{O}_i)^2} \quad \text{(رابطه ۲)}$$

$$RMSE = \sqrt{\frac{1}{N} \sum (K_p - K_m)^2} \quad \text{(رابطه ۳)}$$

در معادله‌های ۱، ۲ و ۳، n تعداد نمونه‌های مشاهداتی، K_p مقدار مشاهده‌شده برای نمونه i ، K_m مقدار پیش‌بینی‌شده برای نمونه i ، $\bar{K}_m$ میانگین مقادیر مشاهده‌شده، r ضریب همبستگی بین مقادیر پیش‌بینی شده و مشاهده‌شده و K_m و K_p به ترتیب واریانس مقادیر پیش‌بینی‌شده و مشاهده‌شده است (Batista et al., 2020). مقدار R^2 و CCC هرچه به ۱ نزدیک‌تر باشد، نشان‌دهنده دقت بیشتر مدل در پیش‌بینی مقادیر واقعی است؛ و مقدار RMSE هرچه کمتر باشد، بیانگر خطای پیش‌بینی کمتر و صحت بیشتر مدل است.

۳. یافته‌های پژوهش

۳-۱. خلاصه آماری شوری خاک

خلاصه آماری شوری خاک سطحی در عمق ۰-۳۰ سانتی‌متری و خاک زیرسطحی در عمق ۳۰-۶۰ سانتی‌متری در جدول ۱ ارائه شده است. بر اساس نتایج، مقدار میانگین و میانه شوری خاک‌های مورد پژوهش به ترتیب ۳/۷ و ۳/۶۷ دسی‌زیمنس بر متر در لایه سطحی است. حداقل مقدار شوری خاک ۰/۹۹ دسی‌زیمنس بر متر و حداکثر مقدار این پارامتر ۶/۳۶ دسی‌زیمنس بر متر برای لایه سطحی و مقدار میانگین و میانه شوری خاک به ترتیب ۳/۱ و ۳/۶۱ دسی‌زیمنس بر متر، حداقل مقدار شوری خاک ۱/۰۹ دسی‌زیمنس بر متر و

۱. Out-of-bag error

۲. Rossel & McBratney

حداکثر مقدار این پارامتر ۶/۰۲ دسی‌زیمنس بر متر در لایه زیر سطحی به دست آمد. بررسی ضریب تغییرات (CV) به منظور سنجش میزان پراکندگی نسبی داده‌ها نشان داد که این شاخص در لایه سطحی معادل ۲۰/۹۴ درصد و در لایه زیرسطحی ۱۸/۴۳ درصد است. از آنجا که مقادیر CV بین ۱۵ تا ۲۵ درصد قرار دارند، می‌توان نتیجه گرفت که تغییرپذیری شوری خاک در هر دو عمق در محدوده متوسط قرار دارد (Wilding, 1985). این میزان از تغییرپذیری حاکی از اثرگذاری قابل توجه عوامل محیطی، از جمله توپوگرافی، نوع کاربری اراضی و کیفیت مدیریت زراعی قرار است (Guo et al., 2015; Corwin & Lesch, 2005).

بر اساس نتایج بدست آمده، در حدود ۷۵ درصد خاک‌های منطقه بر اساس طبقه‌بندی نشریه ۲۰۵ موسسه تحقیقات خاک و آب، در کلاس خاک‌های غیر شور قرار می‌گیرد، در حالی که ۲۵ درصد از نمونه خاک‌های منطقه در طبقه خاک‌های نسبتاً شور دسته‌بندی شده‌اند. امینی^۱ و همکاران (۲۰۱۸) نیز بر اساس مرز شوری خاک ۴ دسی‌زیمنس بر متر به عنوان مرز بین خاک‌های شور و غیر شور، خاک‌های مورد مطالعه را در دسته خاک‌های غیر شور قرار دادند. پژوهش‌های مشابه، از جمله زاو و همکاران (۲۰۲۰) نشان دادند که افزایش شوری خاک عمدتاً ناشی از افزایش یون‌های سدیم محلول است که منجر به افزایش پی اچ خاک و همچنین تخریب خاکدانه‌ها می‌گردد. این یافته‌ها نشان‌دهنده تأثیر ترکیبات یونی بر پایداری و ویژگی‌های فیزیکی خاک در منطقه مورد مطالعه است که می‌تواند در مدیریت بهینه خاک و بهبود بهره‌وری زراعی منطقه مفید باشد (Zhou et al., 2020).

جدول ۱. خلاصه آماری هدایت الکتریکی (EC) خاک در دو لایه سطحی و زیرسطحی

افراستگی	چولگی	ضریب تغییرات	انحراف معیار	میان	میانگین	حداکثر	حداقل	لایه خاک
				(dS m ⁻¹)	(dS m ⁻¹)	(dS m ⁻¹)	(dS m ⁻¹)	(cm)
۳۶۴	۰.۱۹	۲۰.۹۴	۰.۷۹	۳.۶۷	۳.۷	۶.۳۶	۰.۹۹	۰-۳۰ cm
۵.۲۴	۰.۰۷	۱۸.۴۳	۰.۲۷	۳.۶۱	۳.۱	۶.۰۲	۱.۰۹	۳۰-۶۰ cm

به‌منظور بررسی ویژگی‌های توزیع داده‌ها در دو لایه خاک، تحلیل آماری شاخص‌های چولگی و کشیدگی (افراستگی) انجام گرفت. نتایج این تحلیل در جدول مربوطه ارائه شده است. مقدار چولگی در لایه‌های سطحی و زیرسطحی به ترتیب ۰/۱۹ و ۰/۰۷ محاسبه شد که هر دو مقدار به صفر نزدیک بوده و نشان‌دهنده توزیعی نسبتاً متقارن و فاقد انحراف قابل توجه به راست یا چپ هستند. با توجه به معیارهای معرفی‌شده توسط دوان و اسوارد^۲ (۲۰۱۱)، این مقادیر حاکی از آن است که توزیع داده‌ها در هر دو عمق مورد بررسی، از نظر چولگی تقریباً نرمال می‌باشد. در مقابل، مقادیر کشیدگی به ترتیب برابر با ۳/۶۴ در لایه سطحی و ۵/۲۴ در لایه زیرسطحی به دست آمد که از مقدار معیار نرمال (یعنی ۳) فراتر بوده و حاکی از توزیعی با قله‌های باریک‌تر و دمه‌های سنگین‌تر نسبت به توزیع نرمال است. این نوع کشیدگی می‌تواند نشان‌دهنده وجود داده‌های پرت یا ناهنجار در نمونه‌ها باشد؛ عاملی که می‌تواند بر نتایج تحلیل‌های آماری بعدی، از جمله مدل‌سازی‌های رگرسیونی یا تحلیل واریانس، اثرگذار باشد. بر این اساس، ارزیابی نرمال بودن داده‌ها پیش از انجام تحلیل‌های استنباطی و در صورت لزوم، اعمال تبدیل‌های آماری مناسب جهت نرمال‌سازی داده‌ها، توصیه می‌شود (DeCarlo, 1997).

۳-۲. انتخاب متغیرهای محیطی کمکی

بر اساس نتایج آنالیز حساسیت و با استفاده از رویکرد اهمیت متغیر انجام شده توسط مدل RF، هفت متغیر شامل شاخص همواری کف دره با درجه تفکیک بالا^۳، شدت تابش پخشیده^۴، شاخص تفاضلی پوشش گیاهی نرمال شده^۵، شاخص شوری^۶، درخشندگی^۷، سبزیگی^۸،

1. Amini

2. Doane & Seward

3. Multi-Resolution Index of Valley Bottom Flatness

4. Diffuse Insolation

5. Normalized Difference Vegetation Index)

6. Salinity Index

7. Brightness

8. Greens

تعدیل کننده اثر خاک و پوشش گیاهی^۱، به عنوان لایه‌های محیطی منتخب در پیش‌بینی شوری خاک سطحی و زیرسطحی در منطقه مورد مطالعه انتخاب شدند (جدول ۲).

جدول ۲. متغیرهای کمکی مورد استفاده در پیش‌بینی مکانی شوری خاک منطقه مورد مطالعه

نماینده عامل خاکساز	شرح	نماد	متغیر کمکی	منبع
توپوگرافی - اقلیم	بخشی از تابش مستقیم انعکاس یافته از سطوح شیبدار و در نواحی صاف از طریق گرد و غبار و بخار آب اتمسفر می‌باشد	Diffuse	شدت تابش پخشیده	مدل رقومی ارتفاعی
توپوگرافی - اقلیم	ارزیابی و شناسایی همواری و ویژگی‌های زمین‌شناسی کف دره‌ها	MrVBF	شاخص همواری کف دره با درجه تفکیک بالا	
مواد مادری - خاک	$= (NIR-RED)/(NIR+RED)$	NDVI	شاخص تفاضلی پوشش گیاهی نرمال شده	
مواد مادری - خاک	$= \sqrt{(B2+B3+B4)^2}$	SI1	شاخص شوری	
موجودات زنده - خاک	$= \sqrt{(B2+B3+B4)^2}$	Brightness	درخشندگی	سنجش از دور
موجودات زنده - خاک	$= B3/B4$	Greens	سبزیگی	
موجودات زنده - خاک	$= (B5+B4+0.5)/(B5-B4) (1+0.5)$	SAVI	تعدیل کننده اثر خاک و پوشش گیاهی	

۳-۳. ارزیابی مدل‌سازی شوری خاک

در این پژوهش، مدل‌سازی مکانی شوری خاک (هدایت الکتریکی) با بهره‌گیری از هفت متغیر محیطی کلیدی (مطابق جدول ۱) و با استفاده از الگوریتم RF به‌عنوان یکی از روش‌های پرکاربرد یادگیری ماشین انجام شد. دلیل انتخاب این الگوریتم، توانایی بالای آن در مدل‌سازی روابط غیرخطی، مقاومت در برابر بیش‌برازش و قابلیت پردازش تعاملی میان متغیرهای پیچیده محیطی است. نتایج حاصل از مدل‌سازی برای لایه سطحی خاک حاکی از عملکرد مناسب مدل RF با ضریب تعیین (R^2) برابر با ۰/۸۰، میانگین مربعات خطا (RMSE) برابر با ۰/۲۲ و ضریب همبستگی تطابقی (CCC) برابر با ۰/۹۹ بود. این مقادیر نشان‌دهنده توان بالای الگوریتم در شناسایی الگوهای مکانی شوری خاک در عمق سطحی است؛ موضوعی که در مطالعات مشابه نیز تأیید شده است (Fathizad et al., 2020). در لایه زیرسطحی، مدل RF با R^2 معادل ۰/۳۷، RMSE برابر با ۰/۲۲ و CCC برابر با ۰/۹۷، عملکرد نسبتاً قابل قبولی ارائه داد. کاهش دقت مدل در این عمق می‌تواند ناشی از افزایش تأثیر عوامل زیرسطحی نظیر حرکت عمقی آب، دینامیک املاح و ناهمگنی بیشتر بافت خاک باشد که توسط متغیرهای سطحی به‌خوبی تبیین نمی‌شوند (Wang et al., 2021). با وجود این، نتایج به‌دست‌آمده همچنان نشان‌دهنده کارآمدی نسبی الگوریتم RF در پیش‌بینی شوری در لایه‌های عمیق‌تر است.

یافته‌های پژوهش حاضر با نتایج مسعودی و همکاران (۲۰۲۳) و نتایج نوار و موزان^۲ (۲۰۱۷) همخوانی دارد؛ در این مطالعات نیز مدل RF به‌عنوان روشی دقیق و پایدار در پیش‌بینی ویژگی‌های خاک، به‌ویژه شوری سطحی، معرفی شده است. افزون بر این، موسوی و همکاران (۲۰۲۱) در مطالعه‌ای بر روی دشت قزوین، تغییرات مکانی شوری خاک را در پنج عمق مختلف (۵-، ۱۵-، ۳۰-، ۶۰-، ۱۵۰- سانتی‌متر) بررسی کرده و با بهره‌گیری از روش انتخاب متغیر RF-RFE، ده متغیر محیطی کلیدی را شناسایی نمودند. نتایج آن مطالعه نشان داد که داده‌های سنجش از دور، شاخص‌های توپوگرافی و متغیرهای اقلیمی، نقش تعیین‌کننده‌ای در مدل‌سازی مکانی شوری خاک ایفا می‌کنند؛ یافته‌ای که با نتایج این پژوهش نیز همسو است.

در مجموع، نتایج این تحقیق نشان می‌دهد که ترکیب داده‌های محیطی با الگوریتم‌های مبتنی بر یادگیری ماشین، به‌ویژه جنگل تصادفی، ابزاری توانمند برای پایش و پیش‌بینی مکانی شوری خاک در سطوح مختلف عمقی فراهم می‌سازد. با توجه به انعطاف‌پذیری و

^۱. Soil adjusted vegetation index


^۲. Nawar & Mouazen

دقت این روش‌ها، می‌توان آن‌ها را در سایر مناطق خشک و نیمه‌خشک کشور نیز تعمیم داد.

۳-۴. توزیع مکانی شوری

بر اساس نتایج حاصل از مدل‌سازی مکانی و تحلیل‌های آماری، میانگین و میانه هدایت الکتریکی (EC) در منطقه مورد مطالعه به ترتیب در لایه سطحی برابر با $3/7$ و $3/67$ دسی‌زیمنس بر متر و در لایه زیرسطحی معادل $3/61$ و $3/07$ دسی‌زیمنس بر متر اندازه‌گیری شد. این مقادیر بیانگر وجود سطوح نسبتاً بالای شوری در بخش‌های مختلف منطقه بوده و نشان‌دهنده اهمیت بررسی دقیق الگوهای فضایی شوری در مدیریت پایدار منابع خاک و آب است.

نقشه‌های تولیدشده از توزیع مکانی شوری (شکل ۳-الف برای لایه سطحی و شکل ۳-ب برای لایه زیرسطحی) الگوهای پراکنشی مشخصی را آشکار ساختند که تطابق قابل توجهی با مشاهدات میدانی و واحدهای فیزیوگرافی منطقه دارند. تحلیل فضایی داده‌ها نشان داد که بیشترین مقادیر شوری عمدتاً در نواحی جنوبی و شرقی رودخانه واقع شده‌اند؛ در حالی که کمترین سطوح شوری در مناطق شمالی و شمال غربی محدوده مورد مطالعه مشاهده شد. این الگو نشان‌دهنده نقش فاکتورهای فیزیوگرافی نظیر شیب، ارتفاع و موقعیت توپوگرافیک در توزیع شوری خاک است، که با یافته‌های مطالعات پیشین در مناطق خشک و نیمه‌خشک مشابه همخوانی دارد (Corwin & Lesch, 2005; Abd El Kader Douaoui & Walter, 2006).



(ب)

(الف)

شکل ۳. توزیع مکانی شوری در منطقه مورد مطالعه در دو لایه سطحی (الف) و زیر سطحی (ب)

در بررسی ارتباط میان متغیرهای توپوگرافی و شوری خاک، شاخص همواری کف دره با درجه تفکیک بالا (MRVBF) به عنوان یکی از مهم‌ترین شاخص‌ها شناسایی شد. نتایج تحلیل نشان داد که مقادیر بالاتر شوری اغلب در مناطقی با مقادیر بالای MRVBF متمرکز

شده‌اند (شکل ۴). این شاخص، به دلیل توانایی بالای آن در شناسایی مناطق پست و تجمع رواناب، می‌تواند بیانگر محل‌های تمرکز املاح و در نتیجه، نواحی با پتانسیل بالای شوری باشد (Gallant & Dowling, 2003). این یافته حاکی از آن است که شاخص‌های توپوگرافی نه تنها در تحلیل‌های اکتشافی شوری خاک مؤثر هستند، بلکه می‌توانند به عنوان متغیرهای پیش‌بینی‌کننده کلیدی در مدل‌سازی‌های رقومی خاک مورد استفاده قرار گیرند (Grunwald, 2009; Fathizad et al., 2020).


در مجموع، نتایج این بخش نشان می‌دهد که الگوی مکانی شوری خاک به شدت تحت تأثیر ویژگی‌های فیزیوگرافی منطقه است و استفاده از شاخص‌های مشتق شده از مدل ارتفاع رقومی می‌تواند نقشی مؤثر در تبیین این الگوها ایفا کند. این موضوع در چارچوب مدیریت دقیق اراضی شور، انتخاب مناسب گیاهان مقاوم و برنامه‌ریزی کاربری زمین از اهمیت بالایی برخوردار است.

۳-۵. متغیرهای کمکی و اهمیت آن‌ها

اهمیت نسبی متغیرهای محیطی منتخب در پیش‌بینی شوری و تبیین تغییرات مکانی آن در دو عمق ۳۰-۳ سانتی‌متر (سطحی) و ۶۰-۳۰ سانتی‌متر (زیرسطحی) در شکل‌های ۴-الف و ۴-ب ارائه شده است. بر اساس نتایج حاصل از مدل‌سازی با الگوریتم RF، در لایه سطحی، شاخص MRVBF با سهم ۳۶/۵۴ درصد، شاخص سبزینگی با ۳۰/۵۸ درصد و شدت تابش پخشیده با ۲۰/۷۱ درصد، به عنوان مهم‌ترین متغیرهای پیش‌بینی‌کننده شوری خاک شناسایی شدند. این سه متغیر در مجموع ۸۷/۸۳ درصد از تغییرات شوری سطحی خاک را توجیه کرده‌اند، که بیانگر نقش غالب آن‌ها در تبیین الگوی مکانی شوری در این عمق است.

در عمق زیرسطحی (۳۰-۶۰ سانتی‌متر)، شاخص MRVBF همچنان بیشترین اهمیت را داشته و سهم ۲۴/۳ درصدی را به خود اختصاص داده است. پس از آن، شاخص درخشندگی با ۲۰/۴ درصد، شدت تابش پخشیده با ۱۸/۸ درصد و شاخص شوری طیفی با ۱۶/۱ درصد در پیش‌بینی شوری این لایه نقش کلیدی ایفا کرده‌اند. مجموع سهم این چهار متغیر برابر ۷۹/۶ درصد بوده که نشان‌دهنده تأثیر قابل توجه آن‌ها در مدل‌سازی شوری زیرسطحی است.

این نتایج نشان می‌دهد که شاخص‌های توپوگرافی و پارامترهای سنجش از دور، به ویژه MRVBF، شاخص‌های طیفی پوشش گیاهی و تابش، ابزارهای قدرتمندی در پیش‌بینی دقیق تغییرات شوری در هر دو لایه خاک محسوب می‌شوند (Gallant & Dowling, 2003; Fathizad et al., 2020; Wang et al., 2021).



شکل ۴. اهمیت نسبی متغیرهای کمکی در پیش‌بینی شوری (EC) در لایه سطحی (الف) و لایه زیرسطحی (ب)

به عبارتی این نتایج نشان‌دهنده اهمیت ویژه متغیرهای توپوگرافی در تبیین الگوی مکانی شوری خاک در منطقه مورد مطالعه می‌باشند. به طور کلی توپوگرافی از جمله عوامل کلیدی تشکیل خاک محسوب می‌شود و متغیرهای توپوگرافی مبتنی بر مدل ارتفاع رقومی معمولاً به عنوان پیش‌بینی‌کننده‌های کلیدی در تهیه نقشه‌های رقومی خاک مورد استفاده قرار می‌گیرند.

۴. بحث و نتیجه‌گیری

در این پژوهش، الگوی توزیع مکانی شوری خاک در دو عمق سطحی و زیرسطحی با استفاده از تلفیق داده‌های سنجش از دور و مدل رقومی ارتفاعی (DEM) مدل‌سازی شد. یافته‌ها نشان داد که داده‌های سنجش از دور و شاخص‌های توپوگرافی به عنوان مهم‌ترین عوامل پیش‌بینی در تهیه نقشه‌های شوری خاک عمل می‌کنند. این نتایج با مطالعه پنگ و همکاران (۲۰۱۹) که تأثیر وضعیت توپوگرافیکی را بر تغییرپذیری ویژگی‌های خاک بررسی کرده بود، همسویی دارد. تحلیل‌های انجام شده نشان داد که شاخص‌های مشتق شده از DEM، به ویژه MRVBF، همبستگی معنی‌داری با توزیع مکانی شوری خاک دارند. این یافته با نتایج وانگ و همکاران (۲۰۲۱) که در منطقه‌ای مشابه به بررسی روابط بین شاخص‌های توپوگرافی و شوری خاک پرداخته بودند، مطابقت دارد. مطالعه مذکور نیز نشان داده بود که شاخص MRVBF می‌تواند تا ۶۵ درصد از تغییرات شوری خاک را تبیین کند.

در این تحقیق، استفاده از تصاویر ماهواره‌ای سنتینل ۲ همراه با الگوریتم‌های یادگیری ماشین، دقت قابل توجهی در پیش‌بینی شوری خاک نشان داد. این نتیجه با یافته‌های هوا^۱ و همکاران (۲۰۱۹) که از تلفیق داده‌های راداری و طیفی برای پایش شوری خاک استفاده کرده بودند، همخوانی کامل دارد. مطالعه آنها نشان داده بود که ترکیب باندهای مرئی و مادون قرمز نزدیک (NIR) می‌تواند دقت طبقه‌بندی شوری خاک را تا ۱۵ درصد نسبت به روش‌های متعارف افزایش دهد. نتایج این پژوهش همچنین با کارهای تقی زاده مهرجردی و همکاران (۲۰۲۰) که از مدل‌سازی رقومی خاک برای پیش‌بینی شوری در مناطق خشک و نیمه‌خشک استفاده کرده بودند، قابل مقایسه است. این محققان نیز به اهمیت تلفیق داده‌های سنجش از دور و شاخص‌های توپوگرافی در بهبود دقت مدل‌ها تأکید کرده بودند. مطالعه آنها نشان داده بود که استفاده همزمان از این داده‌ها می‌تواند ضریب تعیین (R^2) مدل را تا ۰/۲۵ واحد افزایش دهد. براساس نظر ژو و همکاران (۲۰۲۰) پستی و بلندی‌ها، با کنترل جریان آب و فرآیندهای رسوبگذاری، تأثیر چشمگیری بر توسعه خاک و توزیع مکانی ویژگی‌های آن دارند. نتایج مطالعه حاضر هم‌راستا با یافته‌های تقی‌زاده مهرجردی و همکاران (۲۰۲۱) است که نشان دادند متغیرهای توپوگرافی از جمله شاخص همواری کف دره با درجه تفکیک بالا از مهم‌ترین متغیرهای کمکی در پیش‌بینی EC خاک در لایه‌های سطحی و زیرسطحی هستند. مطالعات متعددی از جمله پژوهش‌های الحاق^۲ و همکاران (۲۰۱۷)، پریاسمی و شنموگام^۳ (۲۰۱۷) و الکساکیس^۴ و همکاران (۲۰۱۸) به بررسی بازتاب‌های زمینی در محدوده‌های مرئی و مادون قرمز نزدیک پرداخته‌اند. این مطالعات نشان داده‌اند که چنین بازتاب‌هایی علاوه بر کاربرد گسترده در پایش پوشش‌های گیاهی با استفاده از شاخص‌های طیفی مانند NDVI (رایینسون^۵ و همکاران، ۲۰۱۷)، برای شناسایی و مدل‌سازی شوری خاک نیز موثر هستند. اسفاو و ارگاو^۶ (۲۰۱۸) با استفاده از شاخص‌های گیاهی مبتنی بر بلندهای مادون قرمز نزدیک و قرمز، مانند NDVI و RVI، و همچنین شاخص‌های مرتبط با خط خاک مانند MSAVI، موفق به مدل‌سازی مؤثر شوری خاک شدند. علاوه بر این، متغیرهای مرتبط با ارتفاع و شاخص رطوبت توپوگرافیکی نیز به عنوان عوامل کلیدی در پیش‌بینی شوری خاک شناسایی شدند. بررسی نتایج نشان داد که شاخص‌های توپوگرافی بیشترین تأثیر را در مدل‌های مکانی پیش‌بینی شوری دارند. همچنین مشخص شد شاخص‌های مبتنی بر باندهای مرئی و مادون قرمز نزدیک و شاخص‌های خط خاک، نقش مهمی در بهبود عملکرد مدل ایفا می‌کنند. استفاده از الگوریتم RF دقت بالایی در پیش‌بینی شوری خاک ارائه داد و تأیید کرد که

¹. Hoa

². Elhag

³. Periasamy & Shanmugam

⁴. Alexakis

⁵. Robinson

⁶. Asfaw & Argaw

روش‌های داده‌کاوی، ابزارهای مؤثری برای تحلیل ویژگی‌های خاک هستند (Allbed & Kumar, 2013; Wang et al., 2021). نقشه‌های توزیع مکانی در لایه‌های سطحی و زیر سطحی نشان دادند که بخش‌های مرکزی و جنوبی منطقه دارای شوری بالاتری هستند. همچنین در برخی نقاط، شوری عمق زیرسطحی بیشتر از عمق سطحی بود که احتمالاً ناشی از انتقال عمقی املاح است. شاخص‌های ارزیابی مدل مانند ضریب تعیین، ضریب همبستگی تطابق و ریشه میانگین مربعات خطا برای هر دو عمق سطحی و زیرسطحی عملکرد مناسبی نشان دادند. دقت مدل برای عمق سطحی اندکی بالاتر از عمق زیرسطحی بود، که می‌تواند ناشی از حساسیت بیشتر داده‌های سنجش از دور نسبت به ویژگی‌های سطح خاک باشد (Wang et al. 2021). به نظر می‌رسد عامل اصلی شوری خاک در منطقه مورد مطالعه، منبع آبیاری آن باشد؛ چرا که رودخانه‌ی مورد استفاده دارای شوری بالایی است. همچنین، افزایش دمای منطقه، به‌ویژه در فصول خشک سال، موجب انتقال املاح به لایه‌های سطحی خاک می‌شود و این امر فرایند شوری را تشدید می‌کند. مجموع، نتایج این مطالعه مؤید آن است که ترکیب داده‌های سنجش از دور و پارامترهای توپوگرافی به کمک الگوریتم‌های یادگیری ماشین مانند RF، می‌تواند به عنوان روشی کارآمد و مقرون‌به‌صرفه برای پایش و پیش‌بینی شوری خاک در مقیاس‌های وسیع مورد استفاده قرار گیرد. پیشنهاد می‌شود در مطالعات آتی از داده‌های سری زمانی و تصاویر چندفصلی استفاده گردد تا روندهای زمانی تغییر شوری نیز مورد بررسی قرار گیرد و ضمن بررسی کمی و مدل‌سازی آب منطقه مورد مطالعه در عمق‌های پایین از سایر الگوریتم‌های یادگیری ماشین به منظور پیش‌بینی تغییرات مکانی شوری خاک در منطقه استفاده گردد.

References

- Abd El Kader Douaoui, H. N., & Walter, C. (2006). Detecting salinity hazards within a semiarid context by means of combining soil and remote-sensing data. *Geoderma*, 134(1-2), 217-230.
- Allbed, A., & Kumar, L. (2013). Soil salinity mapping and monitoring in arid and semi-arid regions using remote sensing technology: a review. *Advances in remote sensing*, 2(4), 373-385.
- Amini, D., Tavakoli, M., & Rostaminy, M. (2018). Mapping spatial variability of soil salinity using remote sensing data and geostatistical analysis: A case of Shadegan, Khuzestan. *Environmental Erosion Research Journal*, 7(4), 24-43.
- Alexakis, D. D., Daliakopoulos, I. N., Panagea, I. S., & Tsanis, I. K. (2018). Assessing soil salinity using WorldView-2 multispectral images in Timpaki, Crete, Greece. *Geocarto International*, 33(4), 321-338.
- Asadi, Y., Ezimand, K., Keshtkar, H., & Alavipanah, S.K. (2019). A Survey of Landscape Metrics and Land-use/land-cover Structures on Urban Heat Islands Surface: A Case Study on Urmia City, Iran. *Desert*, 24(2), 293-306.
- Asfaw, E., Suryabagavan, K. V., & Argaw, M. (2018). Soil salinity modeling and mapping using remote sensing and GIS: The case of Wonji sugar cane irrigation farm, Ethiopia. *Journal of the Saudi Society of Agricultural Sciences*, 17(3), 250-258.
- Batista, F. (2020). Geostatistical analysis of soil properties of the karstic sub-horizontal plain of the Yucatan Peninsula. *Tropical and Subtropical Agroecosystems*, 24, 09.
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Corwin, D. L., & Lesch, S. M. (2005). Apparent soil electrical conductivity measurements in agriculture. *Computers and Electronics in Agriculture*, 46(1-3), 11-43.
- Corwin, D. L. (2021). Climate change impacts on soil salinity in agricultural areas. *European Journal of Soil Science*, 72(2), 842-862.
- D'Odorico, P., Bhattachan, A., Davis, K. F., Ravi, S., & Runyan, C. W. (2013). Global desertification: Drivers and feedbacks. *Advances in water resources*, 51, 326-344.
- Elhag, M., & Bahrawi, J. A. (2017). Soil salinity mapping and hydrological drought indices assessment in arid environments based on remote sensing techniques. *Geoscientific Instrumentation, Methods and Data Systems*, 6(1), 149-158.
- El Sebai, T., Lagacherie, B., Soulas, G., & Martin-Laurent, F. (2007). Spatial variability of isoproturon mineralizing activity within an agricultural field: geostatistical analysis of simple physicochemical and microbiological soil parameters. *Environmental Pollution*, 145(3), 680-690.
- Fathizad, H., Ardakani, M. A. H., Sodaiezhadeh, H., Kerry, R., & Taghizadeh-Mehrjardi, R. (2020). Investigation of the spatial and temporal variation of soil salinity using random forests in the central desert of Iran. *Geoderma*, 365, 114233.

- Gallant, J. C., & Dowling, T. I. (2003). A multiresolution index of valley bottom flatness for mapping depositional areas. *Water resources research*, 39(12).
- Grunwald, S. (2009). Multi-criteria characterization of recent digital soil mapping and modeling approaches. *Geoderma*, 152(3-4), 195-207.
- Guo, Y., Huang, J., Shi, Z., & Li, H. (2015). Mapping spatial variability of soil salinity in a coastal paddy field based on electromagnetic sensors. *PLoS one*, 10(5), e0127996.
- Hartemink, A. E., & McBratney, A. (2008). A soil science renaissance. *Geoderma*, 148(2), 123-129.
- 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.
- Hoa, P. V., Giang, N. V., Binh, N. A., Hai, L. V. H., Pham, T. D., Hasanlou, M., & Tien Bui, D. (2019). Soil salinity mapping using SAR sentinel-1 data and advanced machine learning algorithms: A case study at Ben Tre Province of the Mekong River Delta (Vietnam). *Remote Sensing*, 11(2), 128.
- Hirich, E. H., Bouizgarne, B., Zouahri, A., Ibn Halima, O., & Azim, K. (2022). How Does Compost Amendment Affect Stevia Yield and Soil Fertility?. *Environmental Sciences Proceedings*, 16(1), 46.
- Khamoshi, S. E., Sarmadian, F., & Keshavarzi, A. (2018). Digital soil mapping using random forests model in Abyek, Qazvin province. *Iranian Journal of Soil Research*, 32(3), 393-402. (in Persian)
- Lagacherie, P., & Mcbratney, A. B. (2006). Spatial soil information systems and spatial soil inference systems: perspectives for digital soil mapping. *Developments in soil science*, 31, 3-22.
- Leitão, P., M. Schwieder, F. Pötzschner, J., R. Pinto, A., M. Teixeira, F. Pedroni, M. Sanchez, C. Rogass, S. van der Linden, & Bustamante, M. (2018). From sample to pixel: multi-scale remote sensing data for upscaling aboveground carbon data in heterogeneous landscapes. *Ecosphere*. 9-8: e02298.
- Liu, L., Wu, Y., Yin, M., Ma, X., Yu, X., Guo, X., & Guo, W. (2023). Soil salinity, not plant genotype or geographical distance, shapes soil microbial community of a reed wetland at a fine scale in the Yellow River Delta. *Science of The Total Environment*, 856, 159136.
- Manteghi, S., Moravej, K., Mousavi, S. R., Delavar, M. A., & Mastinu, A. (2024). Digital soil mapping for soil types using machine learning approaches at the landscape scale in the arid regions of Iran. *Advances in Space Research*, 74(1), 1-16.
- Masoudi, R., Mousavi, S. R., Rahimabadi, P. D., Panahi, M., & Rahmani, A. (2023). Assessing data mining algorithms to predict the quality of groundwater resources for determining irrigation hazard. *Environmental monitoring and assessment*, 195(2), 319.
- McBratney, A. B., Santos, M. M., & Minasny, B. (2003). On digital soil mapping. *Geoderma*, 117(1-2), 3-52.
- Mousavi, S. R., Jahandideh Mahjenabadi, V. A., Khoshru, B., & Rezaei, M. (2024). Spatial prediction of winter wheat yield gap: agro-climatic model and machine learning approaches. *Frontiers in Plant Science*, 14, 1309171.
- Mousavi, S. R., Sarmadian, F., Omid, M., & Bogaert, P. (2021). Digital modeling of three-dimensional soil salinity variation using machine learning algorithms in arid and semi-arid lands of Qazvin plain. *Iranian Journal of Soil and Water Research*, 52(7), 1915-1929. (In Persian)
- Minasny, B., & McBratney, A. B. (2010). Methodologies for global soil mapping. *Digital soil mapping: bridging research, environmental application, and operation*, 429-436.
- Minasny, B., McBratney, A. B., & Lark, R. M. (2008). Digital soil mapping technologies for countries with sparse data infrastructures. *Digital soil mapping with limited data*, 15-30.
- Nawar, S., & Mouazen, A. M. (2017). Comparison between random forests, artificial neural networks and gradient boosted machines methods of on-line Vis-NIR spectroscopy measurements of soil total nitrogen and total carbon. *Sensors*, 17(10), 2428.
- Periasamy, S., & Shanmugam, R. S. (2017). Multispectral and microwave remote sensing models to survey soil moisture and salinity. *Land Degradation & Development*. 28(4), 1412-1425.
- Peng, J., Biswas, A., Jiang, Q., Zhao, R., Hu, J., Hu, B., & Shi, Z. (2019). Estimating soil salinity from remote sensing and terrain data in southern Xinjiang Province, China. *Geoderma*, 337, 1309-1319.
- Perri, S., Suweis, S., Holmes, A., Marpu, P. R., Entekhabi, D., & Molini, A. (2020). River basin salinization as a form of aridity. *Proceedings of the National Academy of Sciences*, 117(30), 17635-17642.
- Pouladi, N., Möller, A. B., Tabatabai, S., & Greve, M. H. (2019). Mapping soil organic matter contents at field level with Cubist, Random Forest and kriging. *Geoderma*, 342, 85-92.

- Rossel, R. V., & McBratney, A. B. (2008). Diffuse reflectance spectroscopy as a tool for digital soil mapping. In *Digital soil mapping with limited data* (pp. 165-172). Dordrecht: Springer Netherlands.
- Robinson, N. P., Allred, B. W., Jones, M. O., Moreno, A., Kimball, J. S., Naugle, D. E., & Richardson, A. D. (2017). A dynamic Landsat derived normalized difference vegetation index (NDVI) product for the conterminous United States. *Remote sensing*, 9(8), 863.
- Rahmani, A., Sarmadian, F., & Arefi, H. (2022). Digital mapping of top-soil thickness and associated uncertainty using machine learning approach in some part of arid and semi-arid lands of Qazvin Plain. *Iranian Journal of Soil and Water Research*, 53(3), 585-602. (in Persian)
- Rath, K. M., & Rousk, J. (2015). Salt effects on the soil microbial decomposer community and their role in organic carbon cycling: a review. *Soil Biology and Biochemistry*, 81, 108-123.
- Rezaie, G., Sarmadian, F., Torkashvand, A. M., Seyedmohammadi, J., & Marashi Aliabadi, M. (2023). Digital Mapping of Surface and Subsurface Soil Organic Carbon and Soil Salinity Variation in a Part of Qazvin Plain (Case Study: Abyek and Nazarabad Regions). *Water and Soil*, 37(2), 315-331. (in Persian)
- Rhoades, J. D. (1982). Cation exchange capacity. *Methods of soil analysis: Part 2 chemical and microbiological properties*, 9, 149-157.
- Suleymanov, A., Abakumov, E., Suleymanov, R., Gabbasova, I., & Komissarov, M. (2021). The soil nutrient digital mapping for precision agriculture cases in the trans-ural steppe zone of Russia using topographic attributes. *ISPRS International Journal of Geo-Information*, 10(4), 243.
- 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.
- Tripathi, A., & Tiwari, R. K. (2021). A simplified subsurface soil salinity estimation using synergy of SENTINEL-1 SAR and SENTINEL-2 multispectral satellite data, for early stages of wheat crop growth in Rupnagar, Punjab, India. *Land Degradation & Development*, 32(14), 3905-3919.
- Tully, K., Gedan, K., Epanchin-Niell, R., Strong, A., Bernhardt, E. S., BenDor, T., Mitchell, M., Kominoski, J., Jordan, T.E., Neubauer, S.C. & Weston, N. B. (2019). The invisible flood: The chemistry, ecology, and social implications of coastal saltwater intrusion. *BioScience*, 69(5), 368-378.
- Wallach, D., Makowski, D., Jones, J. W., & Brun, F. (2006). Working with dynamic crop models: evaluation, analysis, parameterization, and applications. Elsevier.
- Wang, J., Peng, J., Li, H., Yin, C., Liu, W., Wang, T., & Zhang, H. (2021). Soil salinity mapping using machine learning algorithms with the Sentinel-2 MSI in arid areas, China. *Remote Sensing*, 13(2), 305.
- Wilding, L. P. (1985). Spatial variability: its documentation, accommodation and implication to soil surveys. 166-189.
- Zhao, C., Zhang, H., Song, C., Zhu, J. K., & Shabala, S. (2020). Mechanisms of plant responses and adaptation to soil salinity. *The innovation*, 1(1): 100017.
- Zhao, S., Ayoubi, S., Mousavi, S. R., Mireei, S. A., Shahpouri, F., Wu, S. X., & Tian, C. Y. (2024). Integrating proximal soil sensing data and environmental variables to enhance the prediction accuracy for soil salinity and sodicity in a region of Xinjiang Province, China. *Journal of Environmental Management*, 364, 121311.
- Zhou, T., Geng, Y., Chen, J., Pan, J., Haase, D., & Lausch, A. (2020). High-resolution digital mapping of soil organic carbon and soil total nitrogen using DEM derivatives, Sentinel-1 and Sentinel-2 data based on machine learning algorithms. *Science of The Total Environment*, 729, 138244.