



## 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)

G. Rezaie<sup>1</sup>, F. Sarmadian<sup>id\*2</sup>, A. Mohammadi Torkashvand<sup>3</sup>, J. Seyedmohammadi<sup>4</sup>, M. Marashi Aliabadi<sup>5</sup>

Received: 02-01-2023

Revised: 06-02-2023

Accepted: 13-02-2023

Available Online: 13-02-2023

### How to cite this article:

Rezaie, G., Sarmadian, F., Mohammadi Torkashvand, A., 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). *Journal of Water and Soil*, 37(2), 315-331. (In Persian with English abstract). <http://doi.org/10.22067/jsw.2023.80369.1238>

### Introduction

Knowledge of the spatial distribution of soil salinity and soil organic carbon (SOC) leads to obtaining valuable information that is effective in decision-making for agricultural activities. More than a third of the world's land is affected by salt, which threatens the growth and production of crops, and prevents the development of sustainable agriculture. The high electrical conductivity (EC) content in soils poses significant challenges in arid and semi-arid regions, greatly impacting agricultural production. Saline and sodic soils often exhibit high levels of sodium which is a key characteristic. The presence of sodium ions leads to the destabilization of soil aggregates and the dispersion of soil particles resulting in the closure of soil pores. Consequently, unfavorable changes occur in the soil physical, chemical, and biological properties increasing its susceptibility to water and wind erosion. Additionally, high sodium levels can lead to the decomposition of soil organic carbon (SOC). SOC is crucial for water retention, cation exchange, and nutrient availability, making its reduction in agricultural soils a significant threat to sustainable soil management. Therefore, the investigation of soils in terms of EC and SOC contents and their spatial distribution is of great importance to support decision-makers in agricultural development planning to reduce challenges related to food security in arid and semi-arid regions.

### Materials and Methods

This study was conducted with the aim of investigating the EC and SOC in topsoil (0-30 cm) and subsoil (30-60 cm) layers using four machine learning (ML) algorithms namely, random forest (RF), decision tree (DTr), support vector regression (SVR) and artificial neural network (ANN) performed in Qazvin Plain. The study area includes a part of agricultural lands and natural areas of Alborz and Qazvin provinces, between the Nazarabad and Abyek cities in Iran. This region with an area of 60,000 hectares is located at latitude 35° 54' to 36° 54' to the north and 50° 15' to 50° 39' to the east. This research was carried out in four stages including (i) soil sampling and measuring the physical and chemical properties of the soil and preparation of environmental covariates from a digital elevation model (DEM) with spatial resolution 12.5 m and Landsat 8 satellite imagery with spatial

1- Ph.D. Student of Soil Genesis, Classification and Soil Evaluation of the Soil Science Department, Islamic Azad University, Science and Research Branch, Tehran, Iran

2- Professor, Soil Science Department, Faculty of Agricultural, University College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran

(\*- Corresponding Author Email: [fsarmad@ut.ac.ir](mailto:fsarmad@ut.ac.ir))

3- Professor of the Soil Science Department, Science and Research Branch, Islamic Azad University, Tehran, Iran

4- Assistant Professor, Soil and Water Research Institute, Agricultural Research, Education and Extension Organization (AREEO), Karaj, Iran

5- Assistant Professor of the Soil Science Department, Science and Research Branch, Islamic Azad University, Tehran, Iran

DOI: [10.22067/jsw.2023.80369.1238](https://doi.org/10.22067/jsw.2023.80369.1238)

resolution 30 m by SAGA GIS and ENVI software, (ii) spatial modeling of soil EC and SOC in the topsoil and subsoil layers by the RF, SVR, ANN, and DTr ML algorithms, (iii) evaluating the efficiency of the ML algorithms and determining the relative importance of environmental covariates, and (iv) preparation of spatial prediction maps of EC and SOC in the topsoil (0-30 cm) and subsoil (30-60 cm) layers in the study area.

## Results and Discussion

The result of the spatial prediction maps of EC showed that the studied area has non-saline to very saline soils up to a depth of 60 cm. It is also possible that the EC equivalent shows a decreasing trend in soil salinity with a depth from 6.05 to 5.55 ds/m from the topsoil to the subsoil layer. The highest amount of SOC was observed in the surface layer equal to 3.3%. Globally SOC content decreased from the surface (average of 0.84%) to depth (average of 0.4%). The high spatial variability of SOC showed that the soils of the study area are affected by management activity.

Environmental covariates were extracted as a proxy of topography and remote sensing indices including elevation, diffuse Insolation (Diffuse), Multi-Resolution Index of Valley Bottom Flatness (MrVBF), Normalized Differences Vegetation Index (NDVI), SAGA wetness index (SWI) and wind Effect (WE) were used as representatives of soil formation factors. The topography parameters, including the elevation, diffuse insolation, and Multi-Resolution Index of Valley Bottom Flatness, were most closely related to EC and SOC variations in each topsoil and subsoil layer. Elevation can be justified around 50% and 35% of EC and 28.56% and 29.47% of SOC variations in the topsoil and subsoil layers, respectively, followed by the diffuse variable can succeed to justified 19.7% and 25.1% of EC and 27.28% and 27.67% of SOC spatial variations in the topsoil and subsoil layers, respectively.

The results confirmed that the RF was recognized as outperforming the ML model for predicting EC in the topsoil ( $R^2=0.74$ ,  $RMSE=0.36$ , and  $nRMSE=0.07$ ), as well as predicting SOC in topsoil and subsoil layers ( $R^2=0.90$  and  $R^2=0.80$ ), followed by the DTr for predicting EC ( $R^2=0.77$ ,  $RMSE=0.9$ , and  $nRMSE=0.17$ ) in the subsoil layer in comparison other models.

## Conclusion

The RF (Random Forest) and DTr (Decision Tree) models incorporating topographic parameters demonstrated satisfactory accuracy in predicting the variation of topsoil and subsoil electrical conductivity (EC) and soil organic carbon (SOC) in the study area. Topography plays a crucial role in soil formation, and elevation-based topographic attributes are commonly used as key predictors in digital soil mapping projects. The variability in topography influences water flow and sedimentation processes which, in turn, affects soil development and the spatial distribution of soil properties. The resulting soil maps can be valuable tools for decision-making programs related to soil management in the region.

**Keywords:** Environmental covariates, Soil properties mapping, Spatial modeling, Topsoil and subsoil variations

## مقاله پژوهشی

جلد ۳۷، شماره ۲، خرداد-تیر ۱۴۰۲، ص. ۳۳۱-۳۱۵

## نقشه برداری رقومی تغییرات سطحی و زیرسطحی کربن آلی و شوری خاک در بخشی از اراضی دشت قزوین (مطالعه موردی: مناطق آبیگ و نظر آباد)

گردآفرین رضایی<sup>۱</sup> - فریدون سرمیدیان<sup>۲\*</sup> - علی محمدی ترکشوند<sup>۳</sup> - جواد سید محمدی<sup>۴</sup> - مریم مرعشی علی آبادی<sup>۵</sup>

تاریخ دریافت: ۱۴۰۱/۱۰/۱۲

تاریخ بازنگری: ۱۴۰۱/۱۱/۱۷

تاریخ پذیرش: ۱۴۰۱/۱۱/۲۴

## چکیده

آگاهی از توزیع مکانی شوری و کربن آلی خاک منجر به دستیابی به اطلاعات ارزشمندی می‌گردد که در اتخاذ تصمیمات مدیریتی برای فعالیت‌های کشاورزی موثر است. این مطالعه با هدف بررسی تغییرات مکانی قابلیت هدایت الکتریکی (EC) به عنوان بیانگر وضعیت شوری خاک و کربن آلی خاک (SOC) در دو لایه سطحی (صفر تا ۳۰ سانتی‌متر) و زیرسطحی (۳۰-۶۰ سانتی‌متر) با استفاده از چهار الگوریتم یادگیری ماشین جنگل تصادفی (RF)، درخت تصمیم (DTr)، رگرسیون بردار پشتیبان (SVR) و شبکه عصبی مصنوعی (ANN) در دشت قزوین انجام شد. بدین منظور، از ۲۷۸ خاکرغ مطالعاتی نمونه برداری گردید و پس از عبور از الک دو میلی‌متر، مقادیر EC و SOC آنها اندازه‌گیری گردید. متغیرهای کمکی مستخرج از مدل رقومی ارتفاع و ماهواره لندست ۸، شامل ارتفاع (Elevation)، تابش پخشیدگی (Diffuse)، شاخص همواری کف دره با درجه تفکیک بالا (MrVBF)، شاخص تفاوت پوشش گیاهی نرمال شده (NDVI)، شاخص خیسی ساگا (SWI) و شاخص جهت باد (WE) به عنوان نمایندگان عوامل خاکسازي مورد استفاده قرار گرفتند. نتایج نشان داد که مدل RF برای پیش‌بینی EC خاک در لایه سطحی با  $R^2$  برابر با ۰/۷۴ و RMSE ۰/۳۶ و  $nRMSE$  ۰/۰۷ و همچنین پیش‌بینی کربن آلی در هر دو لایه سطحی و زیر سطحی با  $R^2$  به ترتیب برابر با ۰/۹۰ و ۰/۸۰ و به دنبال آن مدل DTr برای پیش‌بینی شوری خاک در لایه زیرسطحی با  $R^2$  ۰/۷۷ و RMSE ۰/۹ و  $nRMSE$  ۰/۱۷ نسبت به سایر مدل‌ها دارای صحت بالاتری بودند. همچنین، متغیرهای توپوگرافی شامل ارتفاع، شدت تابش پخشیدگی و شاخص همواری کف دره با درجه تفکیک بالا بیشترین ارتباط را با تغییرات شوری و کربن آلی خاک در هر دو لایه سطحی و زیرسطحی داشتند. به طور کلی مدل‌های RF و DTr به همراه متغیرهای توپوگرافی توانستند تغییرات شوری و کربن آلی سطحی و زیرسطحی خاک را با صحت قابل قبول در منطقه مورد مطالعه ارائه نمایند؛ که نقشه‌های تهیه شده می‌توانند برای اعمال تصمیم‌های مدیریتی لازم در مورد خاک‌های منطقه مورد استفاده قرار گیرند.

**واژه‌های کلیدی:** تغییرات سطحی و عمقی، متغیرهای محیطی، مدلسازی رقومی، نقشه‌برداری ویژگی‌های خاک

۱- دانشجوی دکتری پیدایش و رده بندی و ارزیابی خاک، گروه علوم و مهندسی خاک، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

۲- استاد گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشکدگان کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران

\*- نویسنده مسئول: (Email: [fsarmad@ut.ac.ir](mailto:fsarmad@ut.ac.ir))

۳- استاد گروه علوم و مهندسی خاک، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

۴- استادیار پژوهشی، موسسه تحقیقات خاک و آب، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران

۵- استادیار گروه علوم و مهندسی خاک، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

## مقدمه

بیش از یک سوم اراضی جهان تحت تاثیر شوری قرار دارند که رشد و عملکرد محصولات را تهدید می‌کند و مانع از توسعه کشاورزی پایدار می‌شوند (Zhao et al., 2020). شوری خاک یکی از بزرگترین چالش‌ها در مناطق خشک و نیمه‌خشک است که به شدت بر تولیدات کشاورزی تاثیر می‌گذارد (Halima et al., 2019).

کربن آلی خاک (SOC) نقش مهمی در ظرفیت نگهداری آب، تبادل کاتیون-آنیون و در دسترس بودن مواد غذایی دارد که باعث رشد گیاه می‌شود. بنابراین، کاهش محتوای SOC در خاک‌های کشاورزی به طور کلی تهدیدی بزرگ برای پایداری کشت خاک در نظر گرفته می‌شود (Žižala et al., 2019). فرآیندهایی مانند زهکشی<sup>۱</sup> و تیغه کشی<sup>۲</sup> بسته به نوع خاک، سیلاب و شوری می‌توانند منجر به اکسیداسیون مستقیم SOC شوند (Holmquist et al., 2018). بنابراین، بررسی خاک‌ها از نظر شوری و کربن آلی و توزیع مکانی آن برای حمایت از تصمیم‌گیرندگان در برنامه‌ریزی توسعه کشاورزی برای کاهش چالش‌های مربوط به امنیت غذایی در اراضی متاثر از نمک از اهمیت بالایی برخوردار است. این در حالی است که گزارش وضعیت منابع خاک جهان (FAO and ITPS., 2015) اشاره می‌کند که اطلاعات در مورد میزان و ویژگی‌های خاک‌های آسیب دیده از نمک بسیار پراکنده است.

در سال‌های اخیر تعداد زیادی از مطالعات شوری خاک (Corwin, Wang et al., 2021; Ma et al., 2020) و محتوای کربن آلی (Zhou et al., 2019; Gholizadeh et al., 2019; Lamichhane et al., 2019) مبتنی بر سنجش از دور انجام شده است. حسنی و همکاران (Hassani et al., 2020) با استفاده از مدل‌های یادگیری ماشین<sup>۴</sup> (ML) و مجموعه‌ای از داده‌های اقلیمی، توپوگرافی، خاک و سنجش از دور<sup>۵</sup> (RS) به پیش‌بینی مکانی خاک‌های شور و سدیمی در عمق خاک و با دوره‌های زمانی مختلف در مقیاس جهانی پرداختند. تقدسی و همکاران (Taghadosi et al., 2018) با استفاده از تصاویر سنتینل ۱ و با کمک مدل رگرسیون بردار پشتیبان<sup>۶</sup> (SVM) به پیش‌بینی شوری خاک با R2 برابر با ۰/۹۷ و RMSE برابر با ۰/۳۵ در اراضی با خطر شوری شدید پرداختند. حمزه‌پور و همکاران

(Hamzhepour et al., 2019) مطالعه‌ای با هدف ارزیابی برهمکنش و تاثیر نسبی متغیرهای محیطی انتخاب شده بر تغییرات مکانی SOC انجام دادند. نتایج نشان داد تعامل قابل توجهی بین متغیرهای EVI، Sand، Wetness و تغییرات SOC وجود دارد. عبدالعماد و همکاران (Abd-Elmabod et al., 2019) به بررسی گسترش شهرسازی و تاثیر آن بر پتانسیل کشاورزی و ذخایر کربن آلی با استفاده از داده‌های ماهواره ای چندزمانی و تکنیک‌های سنجش از دور در دلتای نیل پرداختند. نتایج حاکی از آن بود که گسترش شهری منجر به از دست رفتن ذخایر SOC و تغییر خاک‌های حاصلخیز کشاورزی به خاک‌های شور و با زهکشی ضعیف شده است.

آگاهی از توزیع مکانی شوری و SOC برای دستیابی به اطلاعات در اتخاذ تصمیمات مدیریتی برای کشاورزی پایدار موثر است. در اکثر مطالعات انجام شده به روش کمی، سنسورهای سنجش از دور برای برآورد شوری خاک در سطح به کار گرفته شده‌اند، این در حالی است که شوری خاک زیر سطحی بر رشد گیاه تاثیر گذار است زیرا مانع از جذب رطوبت و مواد مغذی توسط ریشه می‌شود (Tripathi and Tiwari, 2021). العزیز و همکاران (AbdEl Aziz et al., 2018) اعلام کردند که اراضی دارای EC بین ۲/۲۵ تا ۵ دسی‌زیمنس بر سانتی‌متر از ۱۷ درصد در سال ۱۹۹۱ به ۳۷ درصد در سال ۲۰۰۶ افزایش یافت. سوالیم و همکاران (Swileam et al., 2019) نقشه‌های رطوبت و شوری خاک را در عمق ۳۰ و ۶۰ سانتی‌متری خاک تهیه کردند و نشان دادند، که ضریب همبستگی بین شوری و رطوبت لایه سطحی و زیر سطحی به ترتیب ۰/۴۸ و ۰/۶۸ بود. اولیاکولف و همکاران (Avliyakov et al., 2020) با استفاده از داده‌های سنجش از دور و تکنیک آنالیز نقشه‌بردار زاویه طیفی<sup>۷</sup> (SAM) با دقت کلی ۲۴/۷۴ درصد نقشه خاک‌های متاثر از نمک را در اعماق مختلف تهیه کردند. اردکانی و وحدتی (Ardakani and Vahdati, 2017) تغییرات SOC و شوری خاک را در بین سال‌های ۲۰۰۸ تا ۲۰۱۲ در استان یزد مورد بررسی قرار داده و نتیجه گرفتند که در طی این مدت محتوای کربن آلی اراضی کشاورزی افزایش یافته و مساحت اراضی شور کاهش یافته است. با این حال، مطالعات بسیار کمی به بررسی همزمان تغییرات سطحی و زیر سطحی تغییرات مکانی قابلیت هدایت الکتریکی<sup>۸</sup> (EC) به عنوان بیانگر وضعیت شوری خاک و محتوای کربن آلی خاک در

- 1- Soil Organic Carbon
- 2- drainage
- 3- diking
- 4- Machine Learning
- 5- Remote Sensing
- 6- Support Vector Machine
- 7- Spectral angle mapper
- 8- Electrical conductivity

کشور شامل رسوبات آبرفتی و کوهرفتی مربوط به دوره کواترنر بیشتر متمرکز در بخش‌های شمالی و مرکزی منطقه و کفه‌های گلی و نمکی عمدتاً در بخش‌های جنوبی منطقه می‌باشد. خاک‌های منطقه در سه رژیم رطوبتی زیریک خشک، اریدیک ضعیف و آکوئیک و حرارتی ترمیک واقع شده‌اند (Rahmani et al., 2022) و از نظر رده‌بندی در سه رده اریدی، سولز، انتی سولز و اینسپتی سولز قرار دارند (Soil survey staff, 2017).

### روند اجرای تحقیق

**شکل ۲** روندنمای اجرای تحقیق را در ۴ مرحله نشان می‌دهد: ۱. حفر نقاط نمونه برداری و اندازه‌گیری خصوصیات فیزیکی و شیمیایی خاک و تهیه متغیرهای کمکی، ۲. مدل سازی پراکنش مکانی EC و درصد SOC در لایه سطحی و زیر سطحی توسط مدل‌های یادگیری ماشین RF، SVR، ANN و DTr. ۳. اعتبارسنجی کارایی مدل‌ها و تعیین اهمیت نسبی متغیرهای محیطی و ۴. تهیه نقشه پیش‌بینی توزیع مکانی سطحی و زیر سطحی EC و SOC در منطقه مورد مطالعه

### نمونه برداری و تجزیه و تحلیل آزمایشگاهی

مطالعات میدانی در مقیاس حدواسط نیمه تفصیلی تا اجمالی (طی یک دوره ۶ سال) انجام شد و براساس روش طبقه‌بندی تصادفی در نهایت ۲۷۸ خاکرخ مشاهداتی مورد مطالعه واقع گردید (شکل ۱-ج). نقاط مشخص گردیده تا عمق ۱۵۰ سانتی متری یا بالاتر از لایه محدودکننده حفر و براساس راهنمای تشریح صحرائی خاک‌ها تشریح و از کلیه افق‌های ژنتیکی قابل شناسایی نمونه برداری شد. پس از نمونه برداری و شماره گذاری، نمونه‌های خاک به آزمایشگاه منتقل شد. پس از هوا خشک شدن و عبور تمامی نمونه‌ها از الک دو میلی متر، مقدار قابلیت هدایت الکتریکی خاک (EC) در عصاره گل اشباع (Rhoades, 1982) به عنوان بیانگر وضعیت شوری خاک و کربن آلی خاک به روش واکلی بلک (Jackson, 1975) برای تمامی نمونه‌ها اندازه‌گیری شد. در نهایت میانگین وزنی EC و SOC برای اعماق ۰-۳۰ و ۳۰-۶۰ سانتی متری محاسبه شد.

### متغیرهای محیطی و انتخاب آن‌ها

در نقشه برداری رقومی خاک، توزیع مکانی کربن آلی و شوری خاک و روابط آنها با عوامل تشکیل دهنده خاک، از جمله خواص خاک، مواد مادری، اقلیم، موجودات زنده، پستی و بلندی و زمان براساس مدل مکانی اسکورپن که توسط مک برتنی و همکاران (McBratney et al., 2003) ارائه شده، توضیح داده می‌شود.

اراضی کشاورزی پرداخته اند. اکثر مطالعاتی مبتنی بر تغییرات سطحی ویژگی‌های خاک از جمله کربن آلی و شوری در سطح معطوف بوده (Taati et al., 2020; Khazaie et al., 2017) و در کمتر مطالعاتی به بررسی همزمان تغییرات سطحی و زیر سطحی آنها پرداختند. با توجه به اینکه جمله شوری یک ویژگی دینامیک خاک است و تغییرات آن در دوره‌های مختلف زمانی از سطح به عمق متغیر است. با توجه به تاثیر متقابل شوری و کربن آلی بر روی سایر ویژگی‌های خاک و همچنین سایر کارکردهای اصلی خاک اهمیت این بررسی فزونی می‌یابد. از دیگر سو، با توجه به اینکه بخش عمده منطقه مورد مطالعه تحت کشت گیاهان یکساله می‌باشد که نفوذ و توسعه ریشه آن‌ها تا اعماق زیرسطحی نیز گسترش می‌یابد، درک و اطلاع از تغییرات مقادیر شوری و کربن آلی خاک می‌تواند بر مدیریت تغذیه، حفظ حاصلخیزی و افزایش عملکرد محصولات زراعی موثر باشد. بنابراین جهت پوشش بیشتر اطلاعات در این زمینه مطالعه حاضر با اهداف (۱) تهیه نقشه پیش‌بینی مکانی شوری و کربن آلی خاک در دو لایه سطحی (۰-۳۰ سانتی متری) و زیر سطحی (۳۰-۶۰ سانتی متری) با استفاده از چهار الگوریتم یادگیری ماشین جنگل تصادفی<sup>۱</sup> (RF)، درخت تصمیم<sup>۲</sup> (DTr)، رگرسیون بردار پشتیبان<sup>۳</sup> (SVR) و شبکه عصبی مصنوعی<sup>۴</sup> (ANN)، و (۲) شناسایی مهمترین متغیرهای کمکی محیطی تاثیرگذار بر روی پیش بینی مکانی شوری و کربن آلی خاک در دو عمق سطحی و زیرسطحی مورد نظر در بخشی از اراضی دشت قزوین که تحت کشت و برداشت دائمی بوده و از توان تولید قابل توجهی در تولید محصولات کشاورزی برخوردار است طراحی گردید.

### مواد و روش‌ها

#### منطقه مورد مطالعه

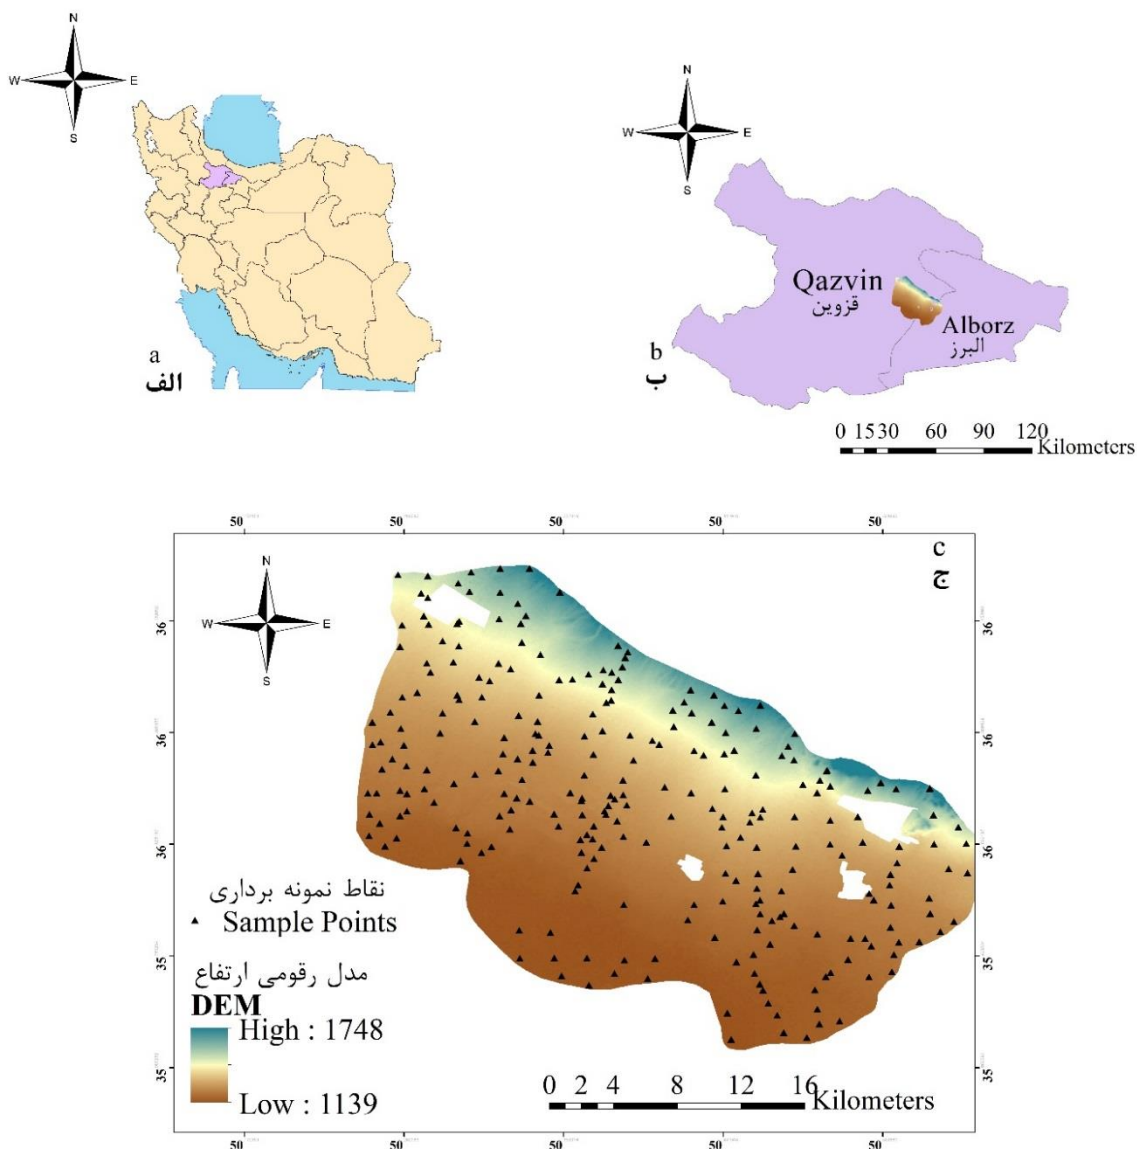
منطقه مورد بررسی شامل بخشی از اراضی کشاورزی و عرصه‌های طبیعی استان‌های البرز و قزوین، حدفاصل شهرستان‌های نظرآباد و آبیک قرار است. این منطقه با مساحت ۶۰۰۰۰ هکتار در عرض جغرافیایی ۵۴° ۳۵' تا ۵۴° ۳۶' شمالی و طول جغرافیایی ۱۵° ۵۰' تا ۳۹° ۵۰' شرقی واقع شده است (شکل ۱-الف، ب-۱ و ج-۱). حداقل و حداکثر ارتفاع در این منطقه به ترتیب ۱۱۴۰ متر و ۱۷۴۷ متر نسبت به دریای آزاد است. این منطقه دارای اقلیم خشک و نیمه خشک براساس روش کوپن است. واحدهای فیزیوگرافی منطقه مورد مطالعه شامل تپه و فلات در قسمت شمال، دشت دامنه‌ای قسمت مرکز و اراضی پست در جنوب می‌باشد. مواد مادری تشکیل دهنده خاک‌های منطقه بر اساس نقشه زمین شناسی (۱:۱۰۰۰۰۰) سازمان زمین شناسی

3- Support Vector Regression

4- Artificial Neural Network

1- Random Forest

2- Decision Tree

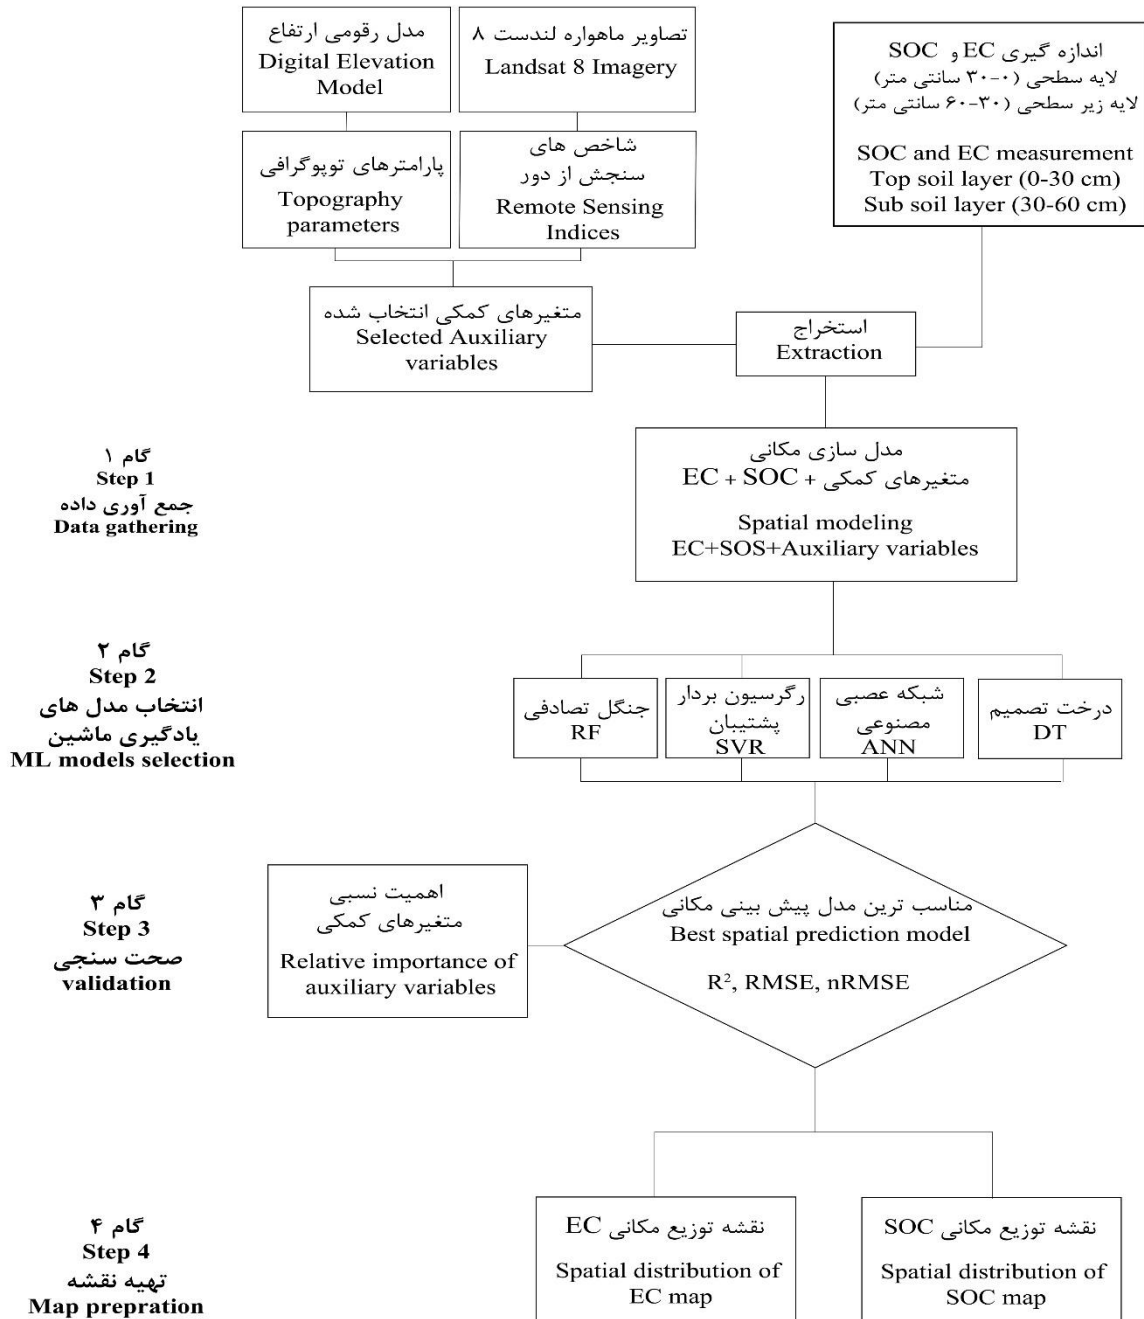


شکل ۱- الف. نقشه استان‌های قزوین و البرز؛ ب و ج. منطقه مورد مطالعه و پراکنش مکانی نقاط نمونه‌برداری شده  
 Figure 1- A. Qazvin and Alborz provinces B. The study area and spatial distribution of soil samples

کنتراست انجام شد. در این تحقیق متغیرهای محیطی مورد استفاده براساس مطالعات پیشین صورت پذیرفته توسط رحمانی و همکاران (Mousavi *et al.*, 2022) و خاموشی و همکاران (Khamoshi *et al.*, 2017) در منطقه مورد مطالعه، برای پیش‌بینی مکانی EC و SOC انتخاب شدند (جدول ۱).

متغیرهای توپوگرافی از مدل رقومی ارتفاع (آلوس پالزار<sup>۱</sup>) با وضوح ۱۲/۵ متر در نرم افزار SAGA GIS مستخرج و متغیرهای سنجش از دور از میانگین تصاویر مربوط به فصل‌های تابستان، پاییز و زمستان (ماه‌های شهریور تا بهمن) طی سال‌های ۱۳۹۵ تا ۱۴۰۰ ماهواره لندست ۸ (با شماره ردیف و گذر به ترتیب ۳۵ و ۱۶۵ با قدرت مکانی ۳۰ متر) با استفاده از نرم افزار ENVI نسخه ۵،۳،۵ تهیه شدند. ابتدا کلیه پیش پردازش‌های لازم از جمله تصحیحات رادیومتری و بهبود

1- ALOS PALSAR



شکل ۲- روندنمای پیش بینی مکانی شوری و کربن آلی خاک  
Figure 2- Flowchart of soil salinity and organic carbon spatial prediction

جدول ۱- متغیرهای کمکی مورد استفاده در پیش‌بینی EC و SOC  
Table 1- Auxiliary variables used in predicting EC and SOC

منبع Source	متغیر کمکی Auxiliary variables	نماد Symbol	شرح Description	نماینده عامل خاکساز Scorpan
	ارتفاع Elevation	Elevation		توپوگرافی R
	شدت تابش پخشیده Diffuse Insolation	Diffuse	تابش مستقیم انعکاس یافته از سطوح Direct radiation reflected from surfaces	توپوگرافی-اقلیم r-c
مدل رقمی ارتفاع Digital elevation model	شاخص خیسب ساگا SAGA Wetness Index	SWI	شاخص رطوبت توپوگرافی بر اساس حوضه آبریز اصلاح شده	توپوگرافی-اقلیم r-c
	شاخص جهت باد Wind Effect	WE	مناطق در معرض باد با توجه به جهت باد	توپوگرافی-اقلیم r-c
	شاخص همواری کف دره با درجه تفکیک بالا Multi-Resolution Index of Valley Bottom Flatness	MrVBF	اندازه‌گیری همواری و پستی Flatness and postural measurement	توپوگرافی r-c
سنجش از دور Remote sensing	شاخص تفاوت پوشش گیاهی نرمال شده Normalized Differences Vegetation Index	NDVI	$NDVI = \frac{NIR-RED}{NIR+RED}$	موجودات-خاک r-c

مجموعه داده‌ها

به صورت تصادفی ۸۰ درصد برای آموزش و ۲۰ درصد برای ارزیابی مدل‌ها تقسیم گردیدند. درجه اهمیت هر یک از متغیرهای محیطی در مدل‌های یادگیری ماشین مورد استفاده طبق تابع اهمیت متغیر (varImp<sup>۲</sup>) در بسته caret انجام گردید. همچنین جهت حصول پایداری نتایج در برازش مدل‌ها از رویکرد ۱۰ گام ۱۰ تکرار استفاده گردید. نحوه دقیق عملکرد مدل‌ها در پیش‌بینی ویژگی‌های ذکر شده به شرح ذیل ارائه شده است:

جنگل تصادفی (RF)

جنگل تصادفی که توسط بریمن (Breiman, 2001) توسعه یافته است، یک روش یادگیری ماشین است که به طور گسترده برای طبقه‌بندی و رگرسیون استفاده می‌شود. یک درخت تصمیم منفرد به دلیل واریانس و سوگیری بالای آن طبقه‌بندی و رگرسیون ضعیفی را ارائه می‌دهد. در حالی که RF تمایل به تولید مدل‌های قوی دارد زیرا می‌تواند مشکلات یاد شده را با استفاده از مجموعه‌ای از درختان کاهش دهد. RF هزاران درخت دوتایی تصادفی را برای ایجاد جنگل تصادفی تولید می‌کند. هر درخت براساس یک نمونه بوت استرپ، با استفاده از روش درختان طبقه‌بندی و رگرسیون (CART)<sup>۳</sup> با زیرمجموعه تصادفی از متغیرهای انتخاب شده در هر گره رشد می‌کند. برای هر درختی که بر روی یک نمونه بوت استرپ رشد می‌کند، نرخ خطای خارج از کیسه (OOB)<sup>۴</sup> با استفاده از مشاهدات خارج از بوت استرپ محاسبه

بر اساس تعریف ارائه شده در جدول ۱، SWI یکی از شاخص‌های ژئومورفومتری مستخرج از مدل رقمی ارتفاع می‌باشد و همانطور که از نامش مشخص است، شبیه به «شاخص خیسب توپوگرافی» است، اما بر اساس یک حوضه آبریز اصلاح شده محاسبه می‌شود که به مقدار کمتری بیانگر میزان جریان می‌باشد. در نتیجه برای سلول‌های (پیکسل‌های) واقع در موقعیت‌های پست زمین‌نما با فاصله عمودی کم تا شبکه آبراهه یا کانال مجاور، رطوبت خاک را با پتانسیل واقعی‌تری در مقایسه با شاخص استاندارد خیسب توپوگرافی محاسبه می‌نماید؛ که اینجا محل تفاوت دو شاخص خیسب ساگا و شاخص خیسب توپوگرافی می‌باشد، همانطور که در نرم‌افزار SAGA GIS این دو شاخص در دو ماژول مجزا تهیه می‌گردند. در رابطه روبه رو معادله ریاضی محاسبه شاخص خیسب ساگا (SWI) ارائه شده است (Boehner et al., 2002).

$$SWI = \left( \frac{MSCA}{\tan \beta} \right)$$

در اینجا: SWI شاخص خیسب ساگا، MSCA = حوضه آبخیز اصلاح شده و  $\tan \beta$  تانژانت زاویه شیب بر حسب رادیان می‌باشد.

مدل‌سازی مکانی

چهار مدل جنگل تصادفی، ماشین بردار پشتیبان، درخت تصمیم و شبکه عصبی مصنوعی با استفاده از بسته‌های تخصصی random Forest, svmKernlab, nnet, caret و کد نویسی در نرم‌افزار R-studio نسخه ۴٫۱٫۱ برای پیش‌بینی توزیع مکانی EC و SOC در دو عمق سطحی و زیر سطحی مورد استفاده قرار گرفت. به طور کلی

3- Classification and Regression Tree  
4- Out Of Bag

1- Function  
2- Variable importance



کننده ماشین بردار پشتیبان و ب: مدل رگرسیون بردار پشتیبان. برای حل مسائل طبقه‌بندی داده‌ها در کلاس‌های مختلف از مدل ماشین بردار پشتیبان و برای حل مسائل پیش‌بینی از مدل SVR استفاده می‌شود. منظور از رگرسیون به دست آوردن ابر صفحه‌ای است که با داده‌های داده شده برازش می‌کند. فاصله از هر نقطه در این ابر صفحه نشان‌دهنده خطای آن نقطه خاص است (Shabani et al., 2020).

### صحت‌سنجی

فرایند اعتبارسنجی مدل‌های تولید شده با استفاده از ۲۰٪ از کل داده‌ها، انجام گرفت. برای این منظور، مقادیر برآورد شده برای هر نمونه از زیرمجموعه‌ای مستقل تعیین شد. صحت مدل‌ها با استفاده از شاخص‌های آماری ضریب تعیین ( $R^2$ )، میانگین ریشه مربعات خطا ( $RMSE$ ) و میانگین ریشه مربعات خطای نرمال شده ( $nRMSE$ ) برآورد شد. رتبه بندی 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 ( $R^2 = 0.41 - 0.6$ ) و ضعیف ( $R^2 < 0.4$ ) (Rossel and McBratney, 2009).  $RMSE$  یک معیار پرکاربرد برای تخمین تفاوت بین مقادیر پیش‌بینی شده توسط یک مدل و مقادیر اندازه‌گیری شده است. همچنین  $RMSE$  مقیاسی از اندازه خطا را برآورد می‌کند که به مقادیر پرت حساس است و توسط معادله ۲ محاسبه می‌شود. همچنین مقادیر  $nRMSE$  (معادله ۳) کمتر از ۰/۱ نشان دهنده پیش‌بینی عالی، بین ۰/۱ و ۰/۲ خوب، بین ۰/۲ تا ۰/۳ متوسط و بیشتر از ۰/۳ ضعیف خواهد بود (Wallach et al., 2006).

$$R^2 = \frac{\sum_{i=1}^N (\gamma_i - \bar{\gamma})(\hat{\gamma}_i - \bar{\hat{\gamma}})}{\sum_{i=1}^N (\gamma_i - \bar{\gamma})^2 \sqrt{\sum_{i=1}^N (\hat{\gamma}_i - \bar{\hat{\gamma}})^2}} \quad \text{معادله ۱}$$

$$RMSE = \frac{\sqrt{\sum (\gamma_i - \hat{\gamma}_i)^2}}{N} \quad \text{معادله ۲}$$

در اینجا  $\gamma_i$  داده اندازه‌گیری شده و  $\hat{\gamma}_i$  مقدار پیش‌بینی شده است. همچنین  $\bar{\gamma}$  میانگین داده‌های اندازه‌گیری شده و  $\bar{\hat{\gamma}}$  میانگین داده‌های پیش‌بینی شده است. همچنین  $N$ ، تعداد داده‌ها است (Batista et al., 2020).

$$nRMSE = \frac{RMSE}{\text{Mean}} \quad \text{معادله ۳}$$

می‌شود. برای اجرای مدل RF کاربر باید دو پارامتر پیش‌بینی، تعداد درختان در جنگل ( $n_{tree}$ ) و تعداد متغیرهای قابل استفاده در انتهای هر گره ( $m_{try}$ ) را بهینه کند تا خطای OOB را به حداقل برساند و عملکرد مدل خوبی را به دست آورد.

### درخت تصمیم (DTr)

مدل درختی تصمیم‌گیری طبقه‌بندی، یک روش ناپارامتری است که قادر به پیش‌بینی متغیرهای کمی یا متغیرهای طبقه‌بندی شده بر اساس مجموعه‌ای از متغیرهای پیش‌بینی کننده کمی و کیفی است. ایجاد درخت تصمیم شامل دو مرحله است. مرحله اول شامل ایجاد و رشد درخت با پیوند و انشعاب و مرحله دوم، مرحله توقف و هرس می‌باشد. هدف از مرحله دوم به حداقل رساندن خطای پیش‌بینی است فرایند طبقه‌بندی یک ویژگی از ریشه درخت شروع می‌شود، داده‌های آزمون ارزیابی شده و شاخه مناسب برای نتیجه انتخاب می‌شود و تا زمانی که یک برگ ظاهر شود این فرایند ادامه می‌یابد. با ظاهر شدن برگ ادعا می‌شود که آن ویژگی متعلق به کلاس نامگذاری شده توسط برگ است. روش درخت تصمیم برای طبقه‌بندی کاربری اراضی دارای مزایای قابل توجه است زیرا بین ویژگی‌ها و طبقات انعطاف‌پذیری و توانایی مدیریت روابط غیر خطی در این مدل وجود دارد، بنابراین دقت طبقه‌بندی را افزایش می‌دهد (Osmani et al., 2018).

### شبکه عصبی مصنوعی (ANN)

شبکه‌های عصبی مصنوعی گروهی از الگوریتم‌های غیرخطی و مبتنی بر داده‌های عمومی هستند که پس از قرار گرفتن در معرض تغییرات ناگهانی پایدار می‌مانند و می‌توانند در محیط‌های غنی از داده، آموزش داده و تولید شوند (Esfandiarpour-Boroujeni et al., 2020). ساختارهای شبکه عصبی مصنوعی (ANN) از مجموعه‌های به هم پیوسته نورون‌ها تشکیل شده‌اند که همبستگی‌های غیرخطی بین هر متغیر را تخمین می‌زنند. متغیرهای محیطی به عنوان نورون‌های ورودی ابتدا به یک یا چند لایه از نورون‌های پنهان و سپس به نورون‌های خروجی که متغیر هدف خاک هستند متصل می‌شوند (Heung et al., 2016).

### ماشین بردار پشتیبانی (SVM)

ماشین بردار پشتیبانی یکی از روش‌های یادگیری ماشین معرفی شده توسط بوسر و همکاران (Boser et al., 1992) است که براساس نظریه یادگیری آماری توسعه داده شده است. مدل‌های ماشین بردار پشتیبانی به دو پروه اصلی تقسیم می‌شوند. الف: مدل‌های طبقه‌بندی

جدول ۲- توصیف آماری شوری و کربن آلی در دو لایه سطحی (۰-۳۰ سانتی متر) و زیر سطحی (۳۰-۶۰ سانتی متر)

ویژگی های خاک Soil properties	حداقل Minimum	واحد Unit	حداکثر Maximum	میانگین Mean	انحراف معیار Standard deviation
لایه سطحی (۰-۳۰ سانتی متر) Top soil later (0-30 cm)					
هدایت الکتریکی (EC) Electrical conductivity (EC)	0.14	دسی زیمنس بر متر dS/m	151.11	6.05	17.02
کربن آلی خاک (SOC) Soil Organic Carbon (SOC)	0.11	درصد %	3.3	0.84	0.49
لایه زیر سطحی (۳۰-۶۰ سانتی متر) Subsoil layer (30-60 cm)					
هدایت الکتریکی (EC) Electrical conductivity (EC)	0.08	دسی زیمنس بر متر dS/m	107.85	5.55	14.43
کربن آلی خاک (SOC) Soil Organic Carbon (SOC)	0.02	درصد %	2.09	0.4	0.29

## نتایج

### توصیف آماری

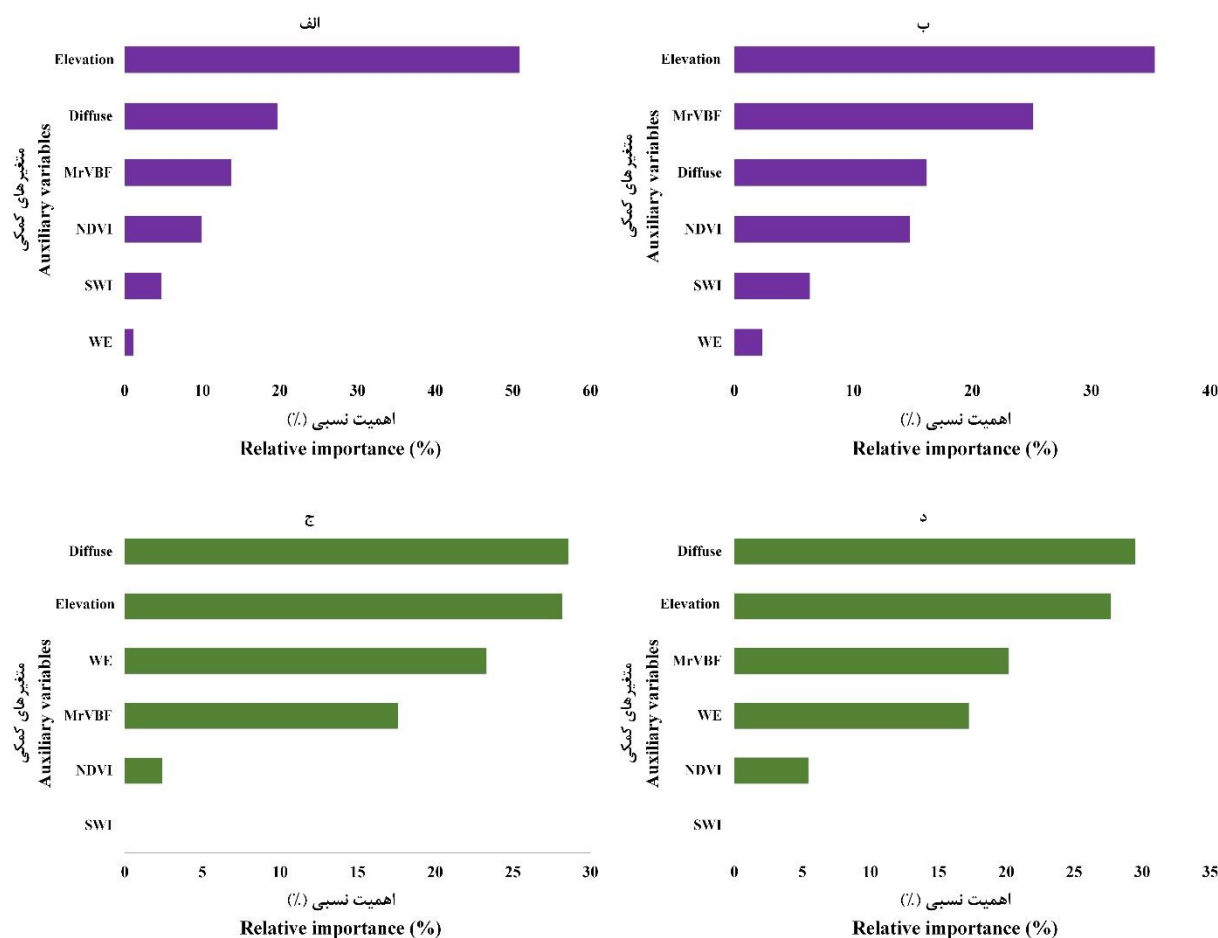
۲۸/۵۶ و ۲۹/۴۷ و متغیر Diffuse ۲۸/۱۵ و ۲۷/۶۷ درصد از تغییرات SOC (شکل ۳-ج و ۳-د) را در لایه سطحی و زیر سطحی را نشان دادند. همچنین MrVBF با ۱۹/۷ و ۲۰/۶ درصد اهمیت نسبی برای پیش بینی EC در لایه سطحی و زیر سطحی، سومین متغیر کمکی مهم بود. به طوری که مقادیر بالای EC در منطقه مورد مطالعه با مقادیر بالای MrVBF منطبق بود.

متغیرهای توپوگرافی به عنوان تاثیرگذارترین متغیرهای پیش بینی کننده برای پیش بینی هر دو متغیر EC و SOC در دو عمق سطحی و زیر سطحی مورد مطالعه شناسایی شدند. به طور کلی توپوگرافی یکی از مهمترین عوامل تشکیل خاک است و متغیرهای توپوگرافی مبتنی بر DEM معمولاً به عنوان پیش بینی کننده های کلیدی برای رقومی کردن نقشه های خاک استفاده می شوند. پستی و بلندی ها با کنترل جریان آب و رسوبگذاری به نوبه خود بر توسعه خاک و توزیع مکانی خواص خاک تاثیر می گذارند (Zhou et al., 2020). مطابق با یافته های تقی زاده و همکاران (Taghizadeh et al., 2021) متغیرهای DEM و MrVBF مهمترین متغیرهای کمکی در پیش بینی EC خاک سطحی و زیر سطحی شناسایی شدند (شکل ۴). ژو و همکاران (Zhou et al., 2020) نیز در مطالعه خود اعلام کردند که متغیرهای توپوگرافی دارای همبستگی بیشتری نسبت به سایر متغیرهای کمکی مورد استفاده با محتوای SOC و نیتروژن خاک داشتند. ژو و همکاران (Zhou et al., 2019) نیز تاکید کردند که متغیرهای توپوگرافی به عنوان مهم ترین متغیرهای پیش بینی کننده SOC در یک منطقه در یک بازه زمانی بیست ساله شناسایی شدند. در همین راستا محمودزاده و همکاران (Mahmoudzade et al., 2020) نیز نتایج مشابهی را در پیش بینی SOC در غرب ایران گزارش نمودند.

خلاصه آماری مقادیر سطحی و زیر سطحی EC و کربن آلی خاک در جدول ۲ ارائه شده است. مقادیر حداقل و حداکثر EC در هر دو لایه سطحی و زیر سطحی نشان داد که منطقه مورد مطالعه دارای خاک های غیر شور تا بسیار شور تا عمق ۶۰ سانتی متری است. همچنین، میانگین مقادیر EC روند کاهشی را در شوری خاک با عمق از ۶/۰۵ به ۵/۵۵ دسی زیمنس بر متر از لایه سطحی به لایه زیر سطحی نشان داد. این یافته ها با نتایج فتحی زاده و همکاران (Fathizadeh et al., 2020) منطبق است. میانگین SOC از سطح به عمق به ترتیب برابر با ۰/۸۴ و ۰/۴ درصد است. این در حالی است که بیشترین مقدار SOC در لایه سطحی و برابر با ۳/۳ درصد مشاهده شد. براساس طبقه بندی ویلدینگ (Wilding, 1984) کلاس تغییرپذیری EC و SOC در هر دو لایه سطحی و زیر سطحی در کلاس حداکثر (بیش از ۳۵) قرار دارد. تغییرپذیری زیاد SOC و EC خاک نشان داد که خاک های منطقه مورد مطالعه تحت تاثیر مدیریت، متغیرهای محیطی و تخریب قرار دارند (Mahmoudzadeh et al., 2020).

### متغیرهای کمکی و اهمیت آنها

اهمیت متغیرهای کمکی استفاده شده برای پیش بینی EC و SOC در لایه سطحی (۰-۳۰ سانتی متر) و لایه زیر سطحی (۳۰-۶۰ سانتی متر) در شکل ۳ نشان داده شده است. متغیر Elevation و Diffuse به عنوان پیش بینی کننده های مهم EC و SOC در هر دو لایه سطحی و زیر سطحی تعیین شدند. متغیر ارتفاع ۵۰ و ۳۵ درصد و متغیر Diffuse ۱۹/۷ و ۲۵/۱ درصد از تغییرات EC (شکل ۳-الف و ۳-ب) را در لایه سطحی و زیر سطحی تبیین نمودند. متغیر Elevation



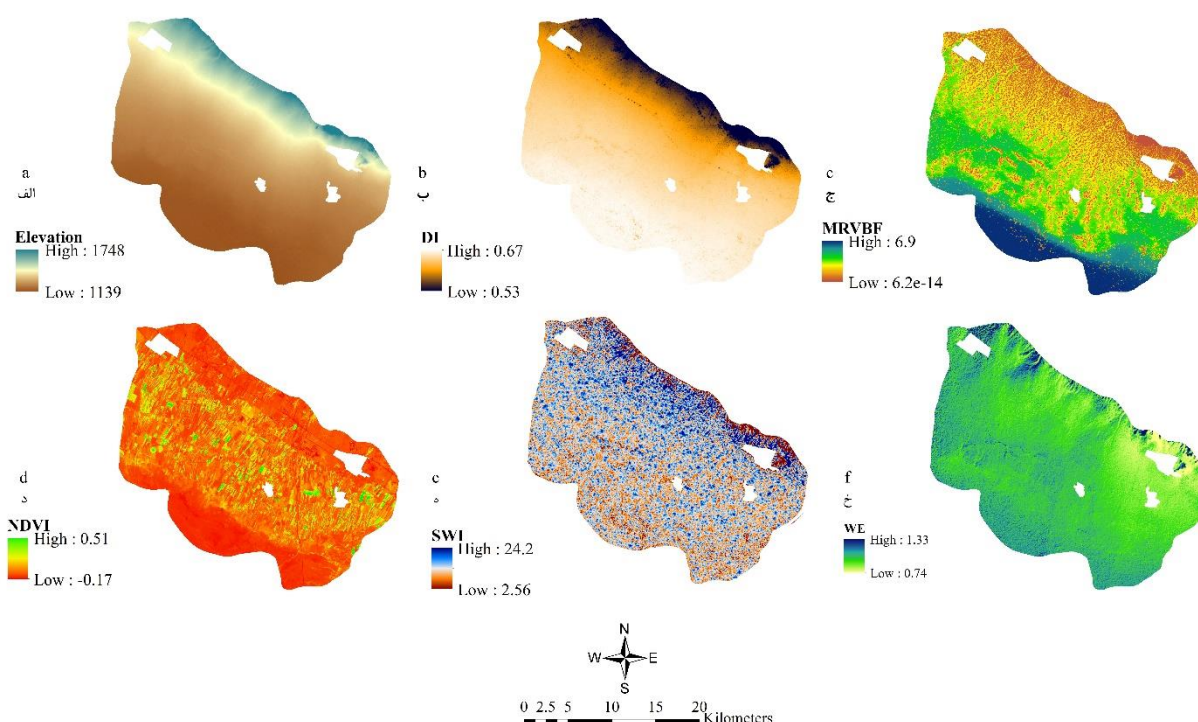
شکل ۳- اهمیت نسبی متغیرهای کمکی برای پیش‌بینی الف: EC لایه سطحی (۰-۳۰ سانتی‌متر) براساس مدل RF، ب: EC لایه زیرسطحی (۳۰-۶۰ سانتی‌متر) براساس مدل RF، ج: SOC لایه سطحی (۰-۳۰ سانتی‌متر) براساس مدل RF، د: SOC لایه زیر سطحی (۳۰-۶۰ سانتی‌متر) براساس مدل RF

Figure 3- The relative importance of auxiliary variables for predicting a: EC of the top layer (0-30 cm) based on the RF model, b: EC of the sub soil layer (30-60 cm) based on the RF model, c: SOC of the top soil layer (0-30 cm) based on the RF model, d: SOC of the sub soil layer (30-60 cm) based on the RF model

را برای پیش‌بینی EC داشت. به‌طور کلی هر دو مدل RF و DTr با  $R^2$  بیش از ۰/۷ در هر دو لایه سطحی و زیر سطحی دارای صحت خیلی خوب برای پیش‌بینی EC بودند. مدل ANN با  $R^2$  ۰/۶۴ و ۰/۶۸ برای لایه‌های سطحی و زیر سطحی دارای عملکرد خوب برای پیش‌بینی EC بود و مدل SVR عملکرد متوسط داشت. همچنین نتایج پیش‌بینی SOC در اعماق مورد مطالعه بیانگر این است که مدل RF در پیش‌بینی کربن آلی خاک در هر دو لایه سطحی و زیر سطحی دارای بیشترین صحت با مقادیر  $R^2$  برابر با ۰/۸۹ و ۰/۹ و برابر با ۰/۱ و ۰/۰۳ بود. با توجه به راسل و مکبرتنی (Rossel and McBratney, 2009) سایر مدل‌ها با  $R^2$  کمتر از ۰/۴ عملکرد ضعیفی در پیش‌بینی کربن آلی خاک داشتند.

#### ارزیابی عملکرد مدل‌های یادگیری ماشین

عملکرد چهار مدل RF، ANN، DTr و SVR با استفاده از متغیرهای کمکی منتخب برای پیش‌بینی EC و SOC در دو لایه سطحی و زیر سطحی (۰-۳۰ و ۳۰-۶۰ سانتی‌متر) با استفاده از شاخص‌های ارزیابی  $R^2$ ، RMSE و nRMSE در جدول ۳ ارائه شده است. نتایج پیش‌بینی EC در لایه سطحی نشان داد که مدل RF دارای بیشترین میزان صحت با مقادیر  $R^2$  به ترتیب برابر با ۰/۷۴ و ۰/۷۲ و RMSE به ترتیب برابر با ۰/۳۶ و ۰/۸۲ دسی‌زیمنس بر متر می‌باشند. این در حالی است که در لایه زیر سطحی مدل DTr با مقادیر  $R^2$  و RMSE برابر با ۰/۷۷ و ۰/۹ دسی‌زیمنس بر متر بیشترین صحت



شکل ۴- توزیع مکانی متغیرهای کمکی انتخاب شده الف: ارتفاع، ب: تابش پخشیده، ج: شاخص همواری کف دره با درجه تفکیک بالا، د: شاخص تفاوت پوشش گیاهی نرمال شده، ه: شاخص خیزی ساگا، خ: شاخص اثر باد

Figure 4- Spatial distribution of selected auxiliary variables a: Elevation, b: Diffuse Insolation, c: Multi-Resolution Index of Valley Bottom Flatness, d: Normalized Differences Vegetation Index, e: SAGA Wetness Index, and f: Wind Effect

مکانی هدایت الکتریکی است.

مطابق با نتایج مطالعه حاضر، در مطالعه‌ای که توسط گومز و همکاران (Gomes *et al.*, 2020) برای پیش‌بینی محتوای SOC انجام شد نتایج تایید کردند که مدل RF در هر پنج عمق مورد مطالعه نسبت به سایر الگوریتم‌های مورد بررسی شامل (کوبیست، GLMB، SVR) بالاترین مقدار ضریب تعیین و کمترین خطا را داشته است. مقایسه دو مدل RF و SVR برای پیش‌بینی EC توسط وو و همکاران (Wu *et al.*, 2018) نشان داد که مدل RF با  $R^2$  بالاتر و RMSE کمتر دارای صحت بیشتری برای پیش‌بینی EC خاک است. برخلاف نتایج مطالعه حاضر که نشان می‌دهد پیش‌بینی ویژگی‌های EC و SOC توسط هر چهار مدل یادگیری ماشین RF، DTr، SVR و ANN در لایه زیر سطحی دارای صحت بیشتر و خطای کمتر است، نتایج مطالعه دی آنتا و همکاران (de Anta *et al.*, 2020) نشان داد که پیش‌بینی SOC توسط مدل RF در عمق ۰-۳۰ سانتی‌متری دارای صحت بیشتری نسبت به عمق ۰-۵۰ سانتی‌متری بود. با همچنین نتایج مشابهی توسط نبی‌اللهی و همکاران (Nabiollahi *et al.*, 2017) و ژانگ و همکاران (Zhang *et al.*, 2017) گزارش شد.

مقایسه میانگین انحراف نسبی بین مقادیر مشاهده شده و پیش‌بینی شده برحسب درصد (nRMSE) برای ویژگی‌های EC و SOC نشان می‌دهد که مقادیر nRMSE محاسبه شده توسط مدل RF نسبت به سایر مدل‌ها کمتر است. بنابراین پیش‌بینی EC خاک در لایه سطحی و SOC در لایه زیر سطحی با nRMSE برابر با ۰/۰۷ با درجه دقت عالی و پیش‌بینی توزیع EC در لایه زیر سطحی و SOC در لایه سطحی با درجه دقت خوب انجام شده است (Wallach *et al.*, 2006). هنگل و همکاران (Hengle *et al.*, 2004) بیان کردند که nRMSE از ۰/۷ دقت پیش‌بینی غیرقابل قبولی دارد. بنابراین  $R^2$  دو محدودیت اصلی دارد که نمی‌تواند سوگیری پیش‌بینی‌های ضرایب و همچنین قابلیت اعتماد مدل رگرسیون را تعیین. به‌عنوان مثال با وجود چند نقطه تاثیرگذار یا پرت،  $R^2$  ممکن است برای مدلی با مقادیر خطای کوچک (مدل‌های مناسب) کم و یا برای مدلی با مقادیر خطای بزرگ (مدل‌های برازش ضعیف) زیاد محاسبه شود (Khaledian and Miller, 2020). ماشالا با و همکاران (Mashalaba *et al.*, 2020) گزارش کردند که صحت پیش‌بینی مدل RF در عمق زیر سطحی با nRMSE برابر با ۱۶٪ بیشتر از عمق سطحی برای پیش‌بینی توزیع

جدول ۳- نتایج اعتبار سنجی پیش‌بینی مکانی شوری و کربن آلی خاک با استفاده از مدل‌های یادگیری ماشین  
Table3- Validation results of spatial prediction of soil salinity and organic carbon using machine learning models

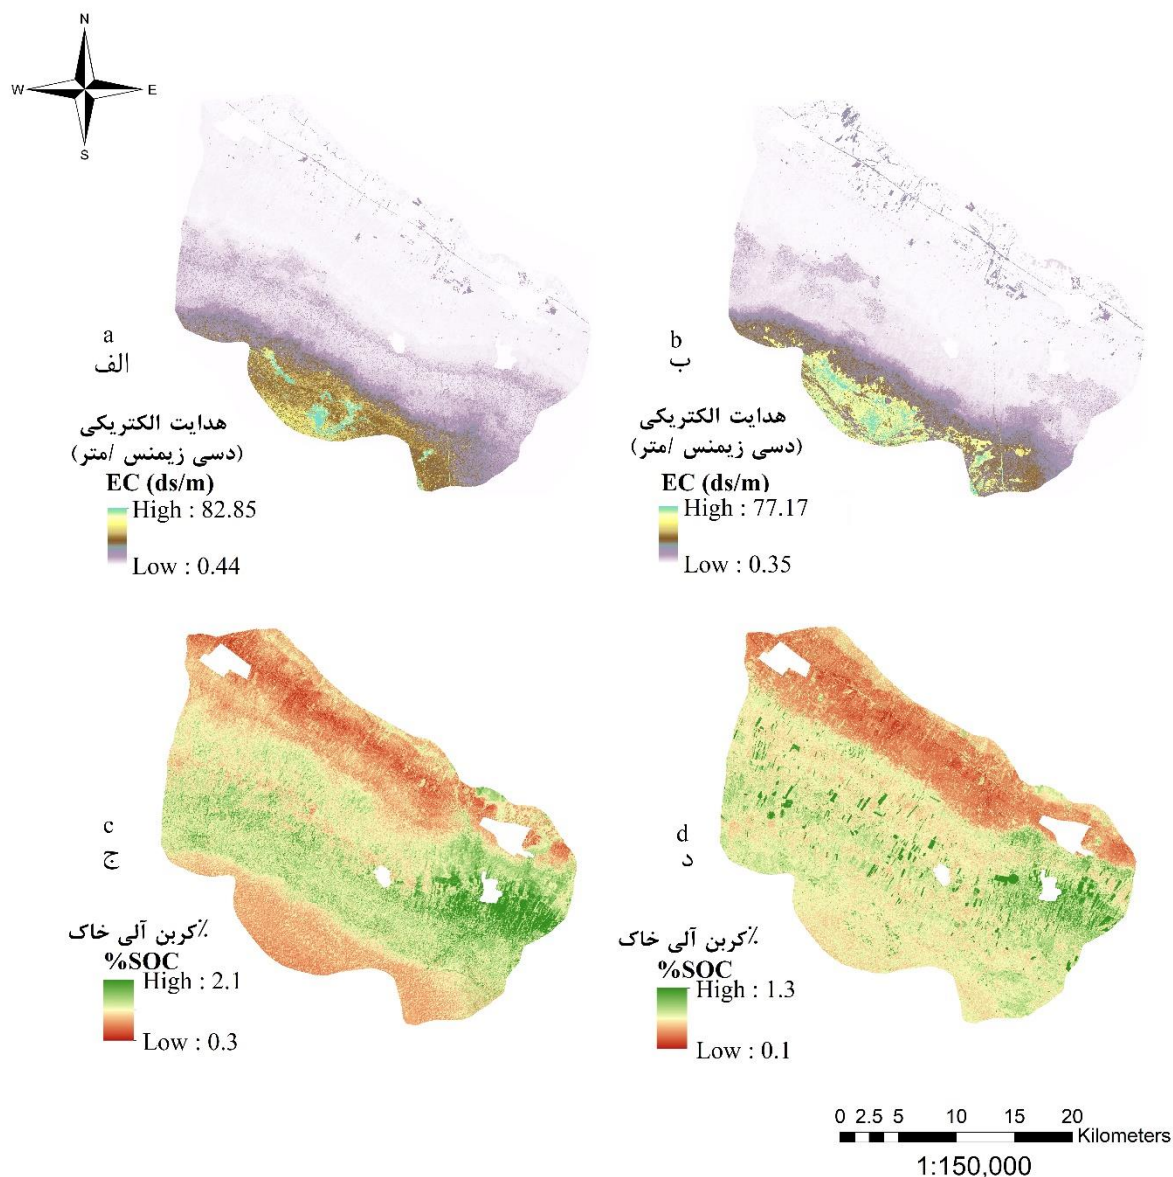
مدل یادگیری ماشین ML model	ویژگی خاک Soil Properties	هدایت الکتریکی EC		کربن آلی SOC		
		عمق Depth	۳۰-۰ 0-30	۶۰-۳۰ 30-60	۳۰-۰ 0-30	۶۰-۳۰ 30-60
جنگل تصادفی RF	R <sup>2</sup>		0.74	0.75	0.9	0.8
	RMSE		0.36	0.4	0.1	0.3
	nRMSE		0.7	0.19	0.12	0.7
درخت تصمیم DTr	R <sup>2</sup>		0.72	0.77	0.34	0.44
	RMSE		0.82	0.9	0.21	0.35
	nRMSE		0.15	0.17	0.25	0.81
شبکه عصبی مصنوعی ANN	R <sup>2</sup>		0.64	0.68	0.24	0.47
	RMSE		0.1	0.11	0.73	0.33
	nRMSE		0.34	0.6	0.35	0.78
ماشین بردار پشتیبان SVR	R <sup>2</sup>		0.4	0.45	0.22	0.32
	RMSE		0.16	1.36	0.81	0.31
	nRMSE		0.35	0.21	0.42	0.95

ارتفاع بیشتر (دارای واحدهای فیزیوگرافی تپه و فلات) و در قسمت مرکز و جنوب ارتفاع کم است بنابراین در قسمت با ارتفاع کمتر میزان EC بیشتر است. به طوری که در ارتفاعات (۱۷۴۸ متر) مقدار EC تا مقادیر کمتر از ۱ (dS/m) و در ارتفاعات کم شامل اراضی پست با سطح آب زیرزمینی بالا (۱۱۳۹ متر) مقدار EC به بیش از ۸۰ (dS/m) نیز می‌رسد که با مشاهدات میدانی و وضعیت واحدهای فیزیوگرافی منطقه منطبق می‌باشد. همچنین در قسمت شمال شرق، شرق و مرکز منطقه مورد مطالعه بیشترین محتوای SOC مشاهده شد که به علت وجود کاربری کشت آبی، دیم و همچنین وجود مراتع غیر شور می‌باشد در حالی که در قسمت جنوب و جنوب شرق، به علت وجود دشت‌های شور و عدم وجود پوشش گیاهی، SOC کاهش یافته است. به طور کلی SOC در لایه سطحی تجمع یافته و با افزایش عمق خاک از میزان آن کاسته می‌شود که موسوی و همکاران (Mousavi et al., 2022) و همکاران (Fu et al., 2021) نیز نتایج مشابهی را گزارش کردند. به نظر می‌رسد در منطقه مورد مطالعه وجود رژیم‌های حرارتی ترمیک و رطوبتی آکوئیک سبب برقرار شدن جریان موئینگی شده و املاح محلول از عمق به سطح به خصوص در فصول خشک سال انتقال می‌یابند (Mousavi et al., 2021).

بیشترین تغییرات R<sup>2</sup> برای پیش‌بینی EC و SOC در هر دو لایه سطحی و زیر سطحی توسط مدل RF برابر با ۱٪ محاسبه شد که نشان‌دهنده تنوع کم در پیش‌بینی است. نتایج این مطالعه تأیید می‌کند که مدل RF یک الگوریتم یادگیری ماشین قدرتمند برای پیش‌بینی است که با نتایج ناوار و معز (Nawar and Mouaze, 2017) مطابقت دارد.

#### تغییر پذیری مکانی EC و SOC

حداقل و حداکثر EC در لایه سطحی به ترتیب ۰/۴۴ و ۸۲/۸۵ (شکل ۵-الف) و در لایه زیر سطحی به ترتیب ۰/۳۵ و ۷۷/۱۷ (شکل ۵-ب) دسی‌زیمنس بر متر مشاهده گردید. در بخش‌های شمالی، شمال شرق و شمال غرب به سمت مرکز منطقه مورد مطالعه میزان EC کم بوده و بیشترین مقدار خطر و محدودیت شوری در مناطق جنوب و جنوب شرقی پیش‌بینی شد. بیشترین و کمترین مقدار SOC پیش‌بینی شده در لایه سطحی ۰/۳ و ۲/۱ (شکل ۵-ج) و زیر سطحی به ترتیب برابر با ۰/۱ و ۱/۳ (شکل ۵-د) درصد مشاهده گردید. با توجه به شکل ۴-الف و ۵-الف و ۵-ب در منطقه مورد مطالعه بین تغییرات ارتفاعی و مقادیر EC پیش‌بینی شده روند عکسی وجود داشت. با توجه به تشریح واحدهای فیزیوگرافی در بخش مواد و روش‌ها قسمت شمال منطقه



شکل ۵- توزیع مکانی الف: EC در لایه سطحی با استفاده از مدل RF، ب: EC در لایه زیر سطحی با استفاده از مدل RF، ج: SOC در لایه سطحی با استفاده از مدل RF، د: SOC در لایه زیر سطحی با استفاده از مدل RF

Figure 5- Spatial distribution a: EC in the top soil layer using the RF model, b: EC in the sub soil layer using the RF model, c: SOC in the top soil layer using the RF model, d: SOC in the sub soil layer using the RF model

### نتیجه گیری

متغیرهای پیش‌بینی کننده EC و SOC در هر دو لایه سطحی و زیرسطحی بودند. که این نتیجه بیانگر این است که در منطقه مورد مطالعه متغیرهای کمکی که نماینده تغییرات توپوگرافی در منطقه مطالعاتی هستند نسبت به شاخص‌های سنجش از دور از پیش‌ران‌های قوی‌تری برای پیش‌بینی این دو ویژگی مورد مطالعه (EC و SOC) بودند.

دو مدل یادگیری ماشین RF و DTr نسبت به مدل‌های ANN و

این تحقیق با هدف بررسی تغییرات مکانی سطحی (۰-۳۰ سانتی-متری) و زیر سطحی (۳۰-۶۰ سانتی-متری) EC و SOC توسط چهار مدل یادگیری ماشین (RF, SVR, ANN, DTr) در دشت قزوین انجام شد. از میان شش متغیر کمکی توپوگرافی و سنجش از دور مورد استفاده، پارامترهای Diffuse, elevation و MrVBF مهمترین

اراضی این منطقه برای کشت محصولات موجود در الگوی کشت منطقه نسبت به سایر بخش‌های منطقه باشد. در پایان از دیدگاه کاربردی نقشه‌های EC و SOC تهیه شده در این مطالعه می‌تواند به عنوان اطلاعات پایه برای کاهش اثرات منفی شوری خاک و همچنین اتخاذ تصمیمات مدیریتی برای افزایش بهره‌وری توان حاصلخیزی خاک‌ها در اراضی مورد مطالعه قرار گیرد.

SVR نتایج دقیق‌تری را در تهیه نقشه پیش‌بینی مکانی EC و SOC در هر دو لایه سطحی و زیر سطحی داشتند. همچنین نتایج پراکنش مکانی EC نشان داد که بخش جنوب و جنوب شرق منطقه هم در سطح و هم در عمق دارای شوری بسیار زیاد بوده که محدودیت جدی برای کلبه کاربری‌های زراعی و باغی در منطقه مورد مطالعه می‌باشد. این در حالی است که مقدار SOC در شرق و مرکز منطقه مورد مطالعه تجمع بیشتری دارد و این نتیجه می‌تواند بیانگر وجود تناسب بالاتر

## منابع

1. Abd El-Aziz, S.H., Gameh, M.A., & Ghallab, A. (2018). Applications of geographic information systems in studying changes in groundwater quality and soil salinity in Sohag Governorate. *Eurasian Journal of Soil Science*, 7(3), 213-223. <https://doi.org/10.18393/ejss.416675>.
2. Abd-Elmabod, S.K., Fitch, A.C., Zhang, Z., Ali, R.R., & Jones, L. (2019). Rapid urbanisation threatens fertile agricultural land and soil carbon in the Nile delta. *Journal of Environmental Management*, 252, 109668. <https://doi.org/10.1016/j.jenvman.2019.109668>
3. Ardakani, M.A., & Vahdati, A.R. (2018). Monitoring of organic matter and soil salinity by using IRS-LissIII satellite data in the Harat plain, of Yazd province. *Desert* 23(1): 1-8
4. Avliyakov, M.A., Kumari, M., Rajabov, N.O., & Durdiev, N.K. (2020). Characterization of soil salinity and its impact on wheat crop using space-borne hyperspectral data. *Geoinformation Support of Sustainable Development of Territories*, 26(Part 3), 271-285.
5. Batista, F. (2020). Geostatistical analysis of soil properties of the karstic sub-horizontal plain of the Yucatan Peninsula. *Tropical and Subtropical Agroecosystems*, 24, 09.
6. Boehner, J., Koethe, R., Conrad, O., Gross, J., Ringeler, A., & Selige, T. (2002): *Soil regionalisation by means of Terrain analysis and process parameterisation*. In: Micheli, E., Nachtergaele, F., Montanarella, L. [Ed.]: *Soil Classification 2001*. European Soil Bureau, Research Report No. 7, EUR 20398 EN, Luxembourg. pp.213-222.
7. Boser, B.E., Guyon, I.M., & Vapnik, V.N. (1992). *A training algorithm for optimal margin classifiers*. In *Proceedings of the Fifth Annual Workshop on Computational Learning Theory*, Association for Computing Machinery, pp. 144-152.
8. Breiman, L. (2001). Random forests: *Machine Learning* 45(1): 5-32. <https://doi.org/10.1023/A:1010933404324>.
9. Corwin, D.L. (2021). Climate change impacts on soil salinity in agricultural areas. *European Journal of Soil Science*, 72(2), 842-862. <https://doi.org/10.1111/ejss.13010>
10. de Anta, R.C., Luís, E., Febrero-Bande, M., Galiñanes, J., Macías, F., Ortíz, R., & Casás, F. (2020). Soil organic carbon in peninsular Spain: influence of environmental factors and spatial distribution. *Geoderma*, 370, 114365.
11. Esfandiarpour-Boroujeni, I., Shahini-Shamsabadi, M., Shirani, H., Mosleh, Z., Bagheri-Bodaghabadi, M., & Salehi, M.H. (2020). Assessment of different digital soil mapping methods for prediction of soil classes in the Shahrekord plain, Central Iran. *Catena*, 193, 104648
12. FAO and ITPS. (2015). *Status of the World's Soil Resources (SWSR) – Main Report*. Food and Agriculture Organization of the United Nations and Intergovernmental Technical Panel on Soils, Rome, Italy.
13. Fathizad, H., Ali Hakimzadeh Ardakani, M., 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.
14. Fu, T., Gao, H., & Liu, J. (2021). Comparison of different interpolation methods for prediction of soil salinity in arid irrigation region in northern China. *Agronomy* 11(8): 1535. <https://doi.org/10.3390/agronomy11081535>
15. Gholizadeh, A., Žižala, D., Saberioon, M., & Borůvka, L. (2018). Soil organic carbon and texture retrieving and mapping using proximal, airborne and Sentinel-2 spectral imaging. *Remote Sensing of Environment* 218: 89-103. <https://doi.org/10.1016/j.rse.2018.09.015>
16. Gomes, L.C., Faria, R. M., de Souza, E., Veloso, G.V., Schaefer, C.E.G., & Fernandes Filho, E.I. (2019). Modelling and mapping soil organic carbon stocks in Brazil. *Geoderma*, 340, 337-350. <https://doi.org/10.1016/j.geoderma.2019.01.007>.
17. Halima, O.I., Azzouzi, M.E., Douaik, A., Azim, K., & Zouahri, A. (2019). Organic and inorganic remediation of soils affected by salinity in the Sebkhha of Sed El Mesjoune–Marrakech (Morocco). *Soil and Tillage Research*, 193, 153-160. <https://doi.org/10.1016/j.still.2019.06.003>.
18. Hamzhepour, N., Shafizadeh-Moghadam, H., & Valavi, R. (2019). Exploring the driving forces and digital mapping of soil organic carbon using remote sensing and soil texture. *Catena*, 182, 104141. <https://doi.org/10.1016/j.catena.2019.104141>

19. 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.2013771117>
20. 17-Hengl, T., Heuvelink, G.B.M., & Stein, A. (2004). A generic framework for spatial prediction of soil variables based on regression-kriging. *Geoderma*, 120, 75–93. <https://doi.org/10.1016/j.geoderma.2003.08.018>
21. Heung, B., Ho, H.C., Zhang, J., Knudby, A., Bulmer, C.E., Schmidt, M.G. (2016). An overview and comparison of machine-learning techniques for classification purposes in digital soil mapping. *Geoderma* 265: 62-77. <https://doi.org/10.1016/j.geoderma.2015.11.014>
22. Holmquist, J. R., Windham-Myers, L., Bliss, N., Crooks, S., Morris, J.T., Megonigal, J. P., & Woodrey, M. (2018). Accuracy and precision of tidal wetland soil carbon mapping in the conterminous United States. *Scientific Reports*, 8(1), 1-16. <https://doi.org/10.1038/s41598-018-26948-7>
23. Jackson, M.L. (1967). *Soil Chemical Analysis-Prentice Hall Inc.* Englewood Cliffs, NJ, USA.
24. 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).
25. Khaledian, Y., & Miller, B.A. (2020). Selecting appropriate machine learning methods for digital soil mapping. *Appl. Math Model* 81: 401–418. <https://doi.org/10.1016/j.apm.2019.12.016>.
26. Khazaie, E., Bostani, A. A., & Davatgar, N. (2017). Geostatic and GIS evaluation of spatial variability of nitrogen, phosphorus, potassium, and cation exchange capacity in agro-industrial land of Sharif Abad in Qazvin. *Iranian Journal of Soil Research*, 31(2), 195-213. <http://doi.org/10.22092/ijrs.2017.11310>.
27. Lamichhane, S., Kumar, L., & Wilson, B. (2019). Digital soil mapping algorithms and covariates for soil organic carbon mapping and their implications: A review. *Geoderma*, 352, 395-413. <https://doi.org/10.1016/j.geoderma.2019.05.031>
28. Ma, G., Ding, J., Han, L., Zhang, Z., & Ran, S. (2021). Digital mapping of soil salinization based on Sentinel-1 and Sentinel-2 data combined with machine learning algorithms. *Regional Sustainability*, 2(2), 177-188. <https://doi.org/10.1016/j.regsus.2021.06.001>
29. Mahmoudzadeh, H., Matinfar, H. R., Taghizadeh-Mehrjardi, R., & Kerry, R. (2020). Spatial prediction of soil organic carbon using machine learning techniques in western Iran. *Geoderma Regional*, 21, e00260. <https://doi.org/10.1016/j.geodrs.2020.e00260>
30. Mashalaba, L., Galleguillos, M., Seguel, O., & Olivares, J. (2020). Predicting spatial variability of selected soil properties using digital soil mapping in a rainfed vineyard of central Chile. *Geoderma Regional*, 22, e00289 <https://doi.org/10.1016/j.geodrs.2020.e00289>
31. McBratney, A., Santos, M.M., & Minasny, B. (2003). On digital soil mapping. *Geoderma*, 117, 3–52. [https://doi.org/10.1016/S0016-7061\(03\)00223-4](https://doi.org/10.1016/S0016-7061(03)00223-4)
32. 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 with English abstract)
33. Mousavi, S. R., Sarmadian, F., Omid, M., & Bogaert, P. (2022). Three-dimensional mapping of soil organic carbon using soil and environmental covariates in an arid and semi-arid region of Iran. *Measurement*, 201, 111706. (In Persian with English abstract)
34. Nabiollahi, K., Eskandari, S., Taghizadeh-Mehrjardi, R., Kerry, R., & Triantafyllis, J. (2019). Assessing soil organic carbon stocks under land-use change scenarios using random forest models. *Carbon Management*, 10(1), 63-77. <https://doi.org/10.1016/j.measurement.2022.111706>
35. 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. <https://doi.org/10.3390/s17102428>
36. Osmani, M., Osmani, F., & Pourhoseingholi, M.A. (2019). Comparison of decision tree and logistic regression for prediction of functional dyspepsia and gastroesophageal reflux disease in tehran province using rome iii. *Modern Care Journal*, 16(4).
37. 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 with English abstract)
38. Rhoades, J.D. (1982). Cation exchangeable capacity. In: Page, A.L., Miller, R.H., Keeney, D.R. (Eds.), *Methods of Soil Analysis: Part 2. Chemical and Microbiological Properties. Agronomy Monograph*, 9, 149–157.
39. Rossel, R.A.V. & McBratney, A.B. (2009). Diffuse reflectance spectroscopy as a tool for digital soil mapping. In: *Digital soil mapping with limited data*.
40. Shabani, S., Samadianfard, S., Sattari, M. T., Mosavi, A., Shamshirband, S., Kmet, T., & Várkonyi-Kóczy, A.R. (2020). Modeling pan evaporation using Gaussian process regression K-nearest neighbors' random forest and support vector machines; comparative analysis. *Atmosphere*, 11(1), 66. <https://doi.org/10.3390/atmos11010066>
41. Swileam, G.S., Shahin, R.R., Nasr, H.M., & Essa, K.S. (2019). Assessment of soil variability using electrical



- resistivity technique for normal alluvial soils, Egypt. *Plant Archives*, 19(1), 905-912.
42. Taati, A., Sarmadian, F., Motaghian, H., & Mousavi, S.R. (2020). Mapping Features of Surface and Depth, Soil Profiles by Using Geostatistical Techniques in Part of Qazvin Plain. *Human & Environment*, 18(1), 67-81.
  43. Taghadosi, M.M., Hasanlou, M., & Eftekhari, K. (2019). Soil salinity mapping using dual-polarized SAR Sentinel-1 imagery. *International Journal of Remote Sensing*, 40(1), 237-252. <https://doi.org/10.1080/01431161.2018.1512767>
  44. Taghizadeh-Mehrijardi, 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. <https://doi.org/10.1016/j.geoderma.2020.114793>
  45. 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. <https://doi.org/10.1002/ldr.4009>
  46. Wallach, D., Makowski, D., Jones, J.W., & Brun, F. (2006). *Working with dynamic crop models: evaluation, analysis, parameterization, and applications*. Elsevier.
  47. 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. <https://doi.org/10.3390/rs13020305>
  48. Wilding, L.P. (1985). *Spatial variability: its documentation, accommodation, and implication to soil surveys*. In: Soil Spatial Variability, Las Vegas NV, pp. 166-194.
  49. Wu, W., Zucca, C., Muhaimed, A. S., Al-Shafie, W. M., Fadhil Al-Quraishi, A. M., Nangia, V., & Liu, G. (2018). Soil salinity prediction and mapping by machine learning regression in C entral M esopotamia, I raq. *Land Degradation & Development*, 29(11), 4005-4014. <https://doi.org/10.1002/ldr.3148>
  50. Zhang, H., Wu, P., Yin, A., Yang, X., Zhang, M., & Gao, C. (2017). Prediction of soil organic carbon in an intensively managed reclamation zone of eastern China: A comparison of multiple linear regressions and the random forest model. *Science of the Total Environment*, 592, 704-713. <https://doi.org/10.1016/j.scitotenv.2017.02.146>
  51. 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. <https://doi.org/10.1016/j.xinn.2020.100017>
  52. 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. <https://doi.org/10.1016/j.scitotenv.2020.138244>
  53. Zhou, Y., Hartemink, A.E., Shi, Z., Liang, Z., & Lu, Y. (2019). Land use and climate change effects on soil organic carbon in North and Northeast China. *Science of the Total Environment*, 647, 1230-1238. <https://doi.org/10.1016/j.scitotenv.2018.08.016>
  54. Žížala, D., Minařík, R., & Zádorová, T. (2019). Soil organic carbon mapping using multispectral remote sensing data: Prediction ability of data with different spatial and spectral resolutions. *Remote Sensing*, 11(24), 2947. <https://doi.org/10.3390/rs11242947>.