

## Digital Mapping of Soil Texture Particles with Machine Learning Models and Environmental Covariates

P. Khosravani<sup>1</sup>, M. Baghernejad<sup>2\*</sup>, A.A. Moosavi<sup>2</sup>, S.R. FallahShamsi<sup>3</sup>

1 and 2- Department of Soil Science, College of Agriculture, Shiraz University, Shiraz, Iran

(\* - Corresponding Author Email: [majidbaghernejad@yahoo.co.uk](mailto:majidbaghernejad@yahoo.co.uk))

3- Department of Natural Resources and Environmental Engineering, College of Agriculture, Shiraz University, Shiraz, Iran

Received: 12-09-2023  
Revised: 13-11-2023  
Accepted: 26-11-2023  
Available Online: 27-11-2023

### How to cite this article:

Khosravani, P., Baghernejad, M., Moosavi, A.A., & FallahShamsi, S.R. (2024). Digital mapping of soil texture particles with machine learning models and environmental covariates. *Journal of Water and Soil*, 37(6), 923-942. (In Persian with English abstract). <https://doi.org/10.22067/jsw.2023.84413.1331>

### Introduction

Understanding the particle size distribution (PSD) is of great importance for plant growth and soil management. In recent years, the science of soil has witnessed a significant increase in digital soil mapping (DSM) activities. In this regard, machine learning models (ML) have emerged as an alternative and tool for DSM, which are mainly used for data mining and pattern recognition purposes, and are now widely used for regression and classification tasks in all fields of science. Hence, this study was undertaken to spatially model sand, silt, and clay particles utilizing machine learning models such as Random Forest (RF), Support Vector Regression (SVR), and the Co-Kriging geostatistical model. Additionally, auxiliary variables with high spatial resolution were incorporated into the analysis. This investigation was conducted in a section of the Marvdasht plain, located in Fars province.

### Materials and Methods

The present study was conducted in a part of Marvdasht plain located between 35.82°41'52" to 1.07°57'52" east longitude and 35.02°48'29" to 14.72°2'30" north latitude, and 40 km north of Shiraz with an area of about 50,000 hectares. After determining the study area boundaries, the positions of 200 sampling points were determined using the R software and the conditioned Latin hypercube sampling method. In other words, for soil feature modeling, 200 samples were taken from two depths of zero to 30 and 30 to 60 centimeters in the study area. Then, the samples were transferred to the laboratory, dried, and passed through a 2 mm sieve. Finally, the soil texture components were measured by the hydrometer method. The environmental variables used in this study are a wide range of representatives of soil-forming factors that were prepared as much as possible from sources with minimum cost and high accessibility. In total, 75 environmental variables were prepared, and the raster format related to all environmental variables, including 39 elevation and altitude variables and 36 remote sensing measurement variables, was extracted. Finally, the factor-tuning inflation variance and Boruta algorithm were used to select the optimal variables.

### Results

The minimum amount of clay was measured at 10.21% and 10.45%, respectively, and the maximum amount was 32.65% and 36.35% at the surface and subsurface depths. The average amount of clay in all samples was 37.91% and 35.61%. The average amount of sand was measured at 25.65% and 26.02% at the surface and subsurface depths, respectively. The maximum amount of sand was observed in the northern and higher parts of the study area and was



©2023 The author(s). This is an open access article distributed under [Creative Commons Attribution 4.0 International License \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/), which permits use, sharing, adaptation, distribution and reproduction in any medium or format, as long as you give appropriate credit to the original author(s) and the source.

<https://doi.org/10.22067/jsw.2023.84413.1331>

equal to 54.68% and the minimum amount was predicted in the low-lying areas of the study area. Low-lying areas and sedimentary plains in the central part of the study area contained high amounts of silt. Four depth variables valley depths (VD), texture (TE), topographic wetness index (TWI), and clay index (CI) related to geomorphometric parameters and the normalized difference vegetation index (NDVI) variable related to remote sensing indices were selected as optimal variables. The RF model with  $R^2$  of 54.0% and 36.0% for predicting sand, 48.0% and 64.0% for predicting silt, and 52.0% and 49.0% for predicting clay at both surface and subsurface depths performed better than the SVR and Co-Kriging models. The most effective variable in predicting the spatial distribution of soil particles was VD with relative importance of 60% and 65% for predicting sand at the surface and subsurface depths, 70% for predicting silt at the surface depth, and 70% and 65% for predicting clay at both surface and subsurface depths, respectively. Only TE and TWI variables were more important than VD for predicting silt at subsurface depth. These results show that topographic variables are effective in the spatial variation of soil particles. Unlike clay, the highest amount of sand in both depths was observed in the northern part and the highest part of the study area, and the lowest amount was predicted in the low-lying areas of the study area.

## Conclusion

In general, with the aim of this research, maps of the spatial distribution of soil texture components were prepared at both surface and subsurface depths using machine learning and geostatistical approaches along with environmental covariates in a part of Marvdasht plain. Among the selected environmental covariates, topographic attributes, especially the valley depth (VD), had the highest effect in justifying the spatial prediction of soil texture components. Also, the results of comparing the performance of machine learning models supported the higher efficiency of the RF model than other models. Therefore, the approach used in this study to prepare a map of soil texture components can be useful as a guide for mapping useful soil features in areas with similar climatic and topographic conditions.

**Keywords:** Co-Kriging, Digital soil mapping, Machine learning, Random Forest, Soil particle size distribution

مقاله پژوهشی

جلد ۳۷، شماره ۶، بهمن-اسفند ۱۴۰۲، ص. ۹۴۲-۹۲۳

## نقشه برداری رقومی اجزای بافت خاک با استفاده از رویکردهای یادگیری ماشین و متغیرهای محیطی

پگاه خسروانی<sup>۱</sup> - مجید باقرنژاد<sup>۱\*</sup> - سید علی اکبر موسوی<sup>۲</sup> - سید رشید فلاح شمسی<sup>۳</sup>

تاریخ دریافت: ۱۴۰۲/۰۶/۲۱

تاریخ پذیرش: ۱۴۰۲/۰۹/۰۵

### چکیده

بافت به عنوان یکی از ویژگی‌های موثر بر وضعیت هیدرولوژیکی و مکانیکی خاک از اهمیت ویژه‌ای برای رشد گیاهان برخوردار است. بنابراین، مطالعه حاضر با هدف مدل‌سازی مکانی ذرات خاک شامل شن، سیلت و رس با استفاده از مدل‌های یادگیری ماشین جنگل تصادفی (RF)، رگرسیون بردار پشتیبان (SVR) و مدل زمین‌اماری کوکریجینگ (Co-Kriging) و نقشه مدل رقومی ارتفاع و تصاویر ماهواره‌ای با وضوح مکانی بالا در دشت مرودشت استان فارس انجام گرفت. مطالعات میدانی شامل حفر ۲۰۰ پروفیل مشاهداتی براساس روش نمونه‌برداری ابر مکعب لاتین (cLHS) و نمونه‌برداری از دو عمق، سطحی (۳۰ سانتی‌متر) و زیرسطحی (۶۰-۳۰ سانتی‌متر) بود. طیف وسیعی از متغیرهای کمکی با دسترسی آسان شامل پارامترهای توپوگرافی و شاخص‌های سنجش از دور به عنوان پیش‌بینی کننده‌های محیطی با وضوح مکانی ۳۰ متر تهیه گردید. مناسب‌ترین متغیرهای کمکی با استفاده از آزمون هم‌خطی توسط شاخص تورم واریانس (VIF) و سپس رویکرد انتخاب متغیر باروتا انتخاب شد. نتایج نشان داد که مدل RF نسبت به مدل‌های SVR و Co-Kriging دارای عملکرد بهتر و دقت بیشتر برای پیش‌بینی هر سه ذره شن، سیلت و رس است. ضریب تبیین ( $R^2$ ) پیش‌بینی شده برای رس در عمق سطحی و زیر سطحی به ترتیب ۰/۵۲ و ۰/۴۹، برای سیلت ۰/۴۸ و ۰/۶۴ و برای شن ۰/۵۴ و ۰/۳۶ درصد محاسبه شد. همچنین متغیر عمق دره مهم‌ترین متغیر در پیش‌بینی توزیع مکانی شن، سیلت و رس شناسائی شد. تهیه نقشه توزیع مکانی اندازه ذرات خاک حاصل می‌تواند منبع مهمی از اطلاعات برای مدیریت کارآمد منابع زمین و نظارت بر محیط‌زیست باشد. به‌طور کلی رویکرد مورد استفاده در این تحقیق به دلیل استفاده از منابع اطلاعاتی با دسترسی آسان و ارزان می‌تواند به عنوان راهنمایی برای تهیه نقشه‌های مدیریت‌پذیر خاک در دشت‌های کشاورزی کشور با قابلیت به‌روز رسانی در حداقل زمان ممکن مورد استفاده قرار گیرد.

**واژه‌های کلیدی:** توزیع اندازه ذرات خاک، جنگل تصادفی، کوکریجینگ، نقشه‌برداری رقومی، یادگیری ماشین

### مقدمه

بالایی برخوردار است (Parent et al., 2021). بنابراین، به‌طور مستقیم کیفیت خاک را کنترل کرده و برای تصمیم‌گیری‌های مدیریتی بسیار پرکاربرد می‌باشد (de Jesus Duarte et al., 2019). PSD همچنین نقش کلیدی برای درک پیدایش و توزیع خاک ایفا کرده و با استفاده از آن می‌توان درجه پدوژنتیک و نرخ هوازدگی را تخمین زد (Lucas et al., 2019). تغییرپذیری عمودی و افقی بافت خاک توسط بسیاری از

بافت خاک به عنوان یکی از شاخص‌های مهم کیفیت خاک بر روی بسیاری از خصوصیات فیزیکی، شیمیایی، بیولوژیکی، هیدرولوژیکی و مکانیکی خاک مؤثر است (Hossain et al., 2018). آگاهی از توزیع اندازه ذرات خاک<sup>۳</sup> (PSD) برای رشد گیاه و مدیریت خاک از اهمیت

۱ و ۲- گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه شیراز، شیراز، ایران  
\* - نویسنده مسئول: (Email: majidbaghernejad@yahoo.co.uk)  
۳- گروه مهندسی منابع طبیعی و محیط‌زیست، دانشگاه شیراز، شیراز، ایران

متقابل متعدد ساده نیست و چالش‌های بیشتری دارد. در مناطق ناهمگن، مدل تغییرات مکانی (یعنی واریوگرام) نیز نمی‌تواند تغییرات تدریجی و ناگهانی در تغییرات خاک را ثبت کند. در نهایت، اگر حجم نمونه و یا تعداد مکان‌های پیش‌بینی زیاد باشد، مدل‌های زمین‌آماري از لحاظ محاسباتی ضعیف هستند (Paramasivam, 2019). بنابراین در اغلب موارد داده‌های خاک و تقاضای کاربر، انطباق با این مفروضات را به یک کار چالش برانگیز تبدیل می‌کند.

رویکردهای یادگیری ماشین<sup>۵</sup> (ML)، به‌عنوان ابزاری مفید برای DSM می‌باشند (Padarian et al., 2019)، و تکنیک‌های ML به دسته بزرگی از الگوریتم‌های مبتنی بر داده‌های غیرخطی اشاره می‌کنند که عمدتاً برای اهداف داده‌کاوی و تشخیص الگو به کار می‌روند، و اکنون اغلب برای کارهای رگرسیون و طبقه‌بندی در همه زمینه‌های علم استفاده می‌شوند (Wang et al., 2020). بر خلاف روش‌های زمین‌آماري که معمولاً برای برآورده کردن مفروضات تغییر مشاهدات اصلی لازم است، الگوریتم‌های ML فرضی را از توزیع مشاهدات ایجاد نمی‌کنند. الگوریتم‌های ML همچنین می‌توانند تعداد زیادی متغیرهای همبسته متقابل را به‌عنوان پیش‌نمایش اداره کنند (Wadoux et al., 2020). با ظهور الگوریتم‌های ML مبتنی بر داده در علم خاک پیش‌بینی ویژگی‌های خاک مانند مدل‌سازی طبقات خاک (Poppiel et al., 2019)، ذخایر کربن خاک (Gomes et al., 2019) و بافت خاک (Malone & Searle, 2021) افزایش یافته است. در همین راستا مطالعاتی توسط محققین داخلی برای توسعه‌ی کاربرد الگوریتم‌های یادگیری ماشین در نقشه‌برداری خاک‌ها صورت پذیرفت که در آن صحرایی و همکاران (Sahraei et al., 2022) با استفاده از مدل‌های ماشین‌بردار پشتیبان و جنگل تصادفی اقدام به تهیه‌ی نقشه‌های رقومی اجزای بافت خاک در بخشی از اراضی دشت خوزستان نمودند و نتایج ایشان بیانگر کارایی بالاتر مدل جنگل تصادفی نسبت به ماشین‌بردار پشتیبان بود. همچنین در مطالعه دیگری که موسوی و همکاران (Mousavi et al., 2021) در ارزیابی کارایی مدل‌های یادگیری ماشین در پیش‌بینی وضعیت شوری خاک در اعماق سطحی و زیرسطحی پرداختند و نتیجه گرفتند که دو مدل کبویست و جنگل تصادفی نسبت به سایر مدل‌های یادگیری ماشین مورد استفاده از کارایی بالاتری برخوردار بودند بنابراین با توجه به پتانسیل بالای الگوریتم‌های یادگیری ماشین در مدلسازی و تفسیر روابط خاک-زمین‌نما به‌عنوان ابزاری کارا در سایر دشت‌های کشاورزی کشور نیز نیاز به ارزیابی کارایی آن‌ها احساس می‌شود (Mousavi et al., 2021).

از آنجایی که محصولات زراعی گندم، جو، کلزا و یونجه به‌عنوان

فرآیندها و عوامل مرتبط با پدوژنز مانند جابه‌جایی عمودی ذرات<sup>۱</sup> در پروفیل خاک، حذف سطحی، تجمع و مواد مادری کنترل می‌شود (Zhang et al., 2023).

علی‌رغم اهمیت ویژگی‌های خاک مرتبط با PSD، کمبود اطلاعات مکانی در مورد آن‌ها در بسیاری از کاربری‌های اراضی وجود دارد (Chen et al., 2021). بنابراین، به‌روز رسانی و گسترش پایگاه‌های داده PSD خاک که به‌طور خاص برای برنامه‌های مدل‌سازی طراحی شده‌اند، حیاتی است. در سال‌های اخیر، علم خاک شاهد افزایش قابل توجهی در فعالیت‌های نقشه‌برداری رقومی خاک<sup>۲</sup> (DSM) بوده است. این امر ناشی از همگرایی چندین عامل همزمان از جمله، تقاضای زیادی برای اطلاعات کمی و مکانی خاک، انباشتگی پایگاه‌های اطلاعاتی ویژگی‌های خاک اندازه‌گیری شده همراه با متغیرهای محیطی کاملاً شناخته‌شده، و توسعه مدل‌های عددی ترکیبی با استفاده از منابع کامپیوتری برای استخراج این ذخایر داده‌های خاک است (Arrouays et al., 2020).

چارچوب DSM با توسعه‌ی مدل فاکتوریل ینی (Jenny, 1941) توسط مک براتنی و همکاران (McBratney et al., 2003) با عنوان مدل اسکورپین<sup>۳</sup> رسمیت یافت، که در آن با استفاده از روش‌های آماری و ریاضیاتی مختلف و کمی‌سازی متغیرهای محیطی (نمایندگان فاکتورهای خاکسازي) اقدام به پیش‌بینی مکانی خصوصیات یا کلاس‌های خاک می‌شود.

به‌طور متعارف، پیش‌بینی مکانی خاک در چارچوب مدل‌های زمین‌آماري تعبیه شده است (Ma et al., 2019) که در آن نمونه‌ای از یک ویژگی خاک به‌عنوان مجموع ترکیب خطی متغیرهای محیطی و یک باقیمانده هم‌بسته (تصادفی) مدل‌سازی می‌شود. مدل‌های زمین‌آماري اغلب در نقشه‌برداری خاک مورد استفاده قرار می‌گیرند زیرا دارای مزایای متعددی هستند (Radočaj et al., 2022). اول، امکان تفسیر فرآیندهای فیزیکی زیربنایی ارائه شده توسط مدل را فراهم می‌کند. ثانیاً، مدل‌سازی با توجه به همبستگی مکانی داده‌ها انجام می‌شود. این ویژگی برای متغیرهایی مانند خاک که از مکانی دیگر متفاوت است اما بین مکان‌ها همبستگی نشان می‌دهد، بسیار حائز اهمیت می‌باشد. سوم امکان اندازه‌گیری عدم قطعیت مدل‌سازی وجود دارد. در بسیاری از شرایط مانند یک تصمیم‌گیری پیش‌بینی تنها معیار نیست و نیاز به نقشه‌های عدم قطعیت می‌باشد. نقشه‌برداری زمین‌آماري خاک، همچنین، دارای محدودیت‌های متعددی است. به‌عنوان مثال داده‌ها باید دارای توزیع نرمال، ثابت (میانگین و واریانس با واحد ثابت) و همسانگرد<sup>۴</sup> باشند (Paramasivam, 2019). همچنین مدل‌سازی رابطه غیرخطی بین یک ویژگی یا کلاس خاک و متغیرهای کمکی

4- isotropic  
5- Machine Learning

1- Lessivage  
2- Digital Soil Mapping  
3- scorpan

### نمونه برداری و مطالعات آزمایشگاهی

پس از تعیین منطقه مورد مطالعه، موقعیت ۲۰۰ نقطه نمونه برداری در منطقه توسط نرم افزار R نسخه ۳٫۱٫۳ با استفاده از روش ابرمکعب لاتین مشروط و دسته‌ای از متغیرهای محیطی مستخرج از مدل رقومی ارتفاع و داده‌های سنجش از دور (عمق دره، شاخص بافت پستی و بلندی، شاخص خیزی توپوگرافی، شاخص رس و شاخص تفاضلی پوشش گیاهی نرمال شده) تعیین گردید (Minasny et al., 2006). به عبارت بهتر، برای مدل سازی ویژگی های خاک، ۲۰۰ نمونه از دو عمق صفر تا ۳۰ و ۳۰ تا ۶۰ سانتی متر در منطقه مطالعاتی برداشته شدند. سپس نمونه‌ها به آزمایشگاه منتقل شده، هوا خشک گردیده و از الک دو میلی متر عبور داده شدند. در نهایت، اجزای بافت خاک به روش هیدرومتر، اندازه گیری گردید.

### مراحل تحقیق

روند تهیه نقشه اجزای بافت خاک در منطقه مطالعاتی در پنج گام اصلی طراحی شد که شامل: ۱- نمونه برداری و جمع آوری اطلاعات خاک و متغیرهای محیطی از منطقه مطالعاتی، ۲- مدل سازی اجزای بافت خاک با استفاده از متغیرهای محیطی، روش های یادگیری ماشین و زمین آماری، ۳- اعتبارسنجی کارایی مدل ها در منطقه مطالعاتی، ۴- تهیه نقشه پیش بینی اجزای بافت خاک براساس بهترین مدل مکان مینا، ۵- تعیین مهمترین فاکتورهای محیطی در پیش بینی اجزای بافت خاک.

### متغیرهای محیطی و انتخاب آن‌ها

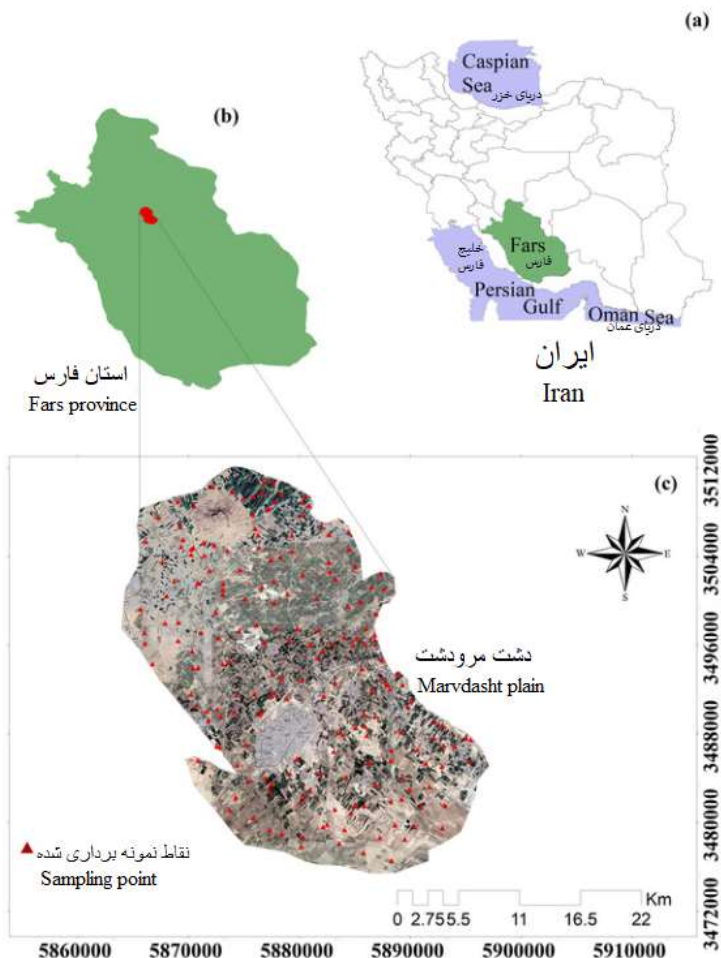
به منظور شناسایی عوامل کنترل کننده اجزای بافت خاک در هر لایه، متغیرهای مختلفی براساس مدل اسکورین (خاک، اقلیم، موجودات زنده، مواد مادری، پستی و بلندی، سن و موقعیت مکانی) انتخاب شدند (Mc Bratney et al., 2003). متغیرهای محیطی استفاده شده در این پژوهش شامل مجموعه گسترده‌ای از نمایندگان فاکتورهای خاکساز هستند که تا حد ممکن از منابع با حداقل هزینه و با دسترسی بالا تهیه گردیدند. این متغیرها برحسب فراوانی و امکان تهیه آن‌ها شامل مشتقات اولیه و ثانویه مدل رقومی ارتفاع، شاخص های سنجش از دور بودند. متغیرهای محیطی پستی و بلندی از مدل رقومی ارتفاع با استفاده از نرم افزار SAGA GIS نسخه ۴٫۷ استخراج شدند. جهت بررسی تغییرپذیری مکانی اجزای بافت خاک از تصویر ماهواره لندست ۸ مربوط به بازه‌ی زمانی مطالعات میدانی مرداد ماه ۱۴۰۰ با قدرت تفکیک مکانی ۳۰ متر استفاده گردید همچنین قبل از استخراج شاخص های مورد نظر تصحیحات رادیومتری بر روی تصاویر انجام گردید. در نهایت شاخص های سنجش از دور نیز در محیط نرم افزار ENVI نسخه ۵/۳ تهیه گردیدند.

اصلی ترین محصولات در الگوی کشت این دشت می باشند، بنابراین به عنوان یک منطقه استراتژیک در تولید محصولات کشاورزی لحاظ می - شود و سالانه به صورت پیوسته تحت کشت می باشد دریافت اطلاعات دقیق از وضعیت پراکنش مکانی ویژگی های کلیدی و تأثیرگذار بر روی کیفیت و مدیریت خاک به ویژه بافت خاک بسیار مهم و ضروری می - باشد. همچنین به دلیل نبود نقشه های خاک که بیانگر وضعیت تغییرات اجزای بافت خاک در منطقه می باشد بنابراین پژوهش حاضر با هدف افزایش اطلاعات در مورد ۱. تهیه نقشه های پیش بینی مکانی PSD خاک ۲. مقایسه مدل های یادگیری ماشین RF و SVR با مدل زمین آماری کوکریجینگ و ۳. شناسایی مهمترین متغیرهای پیش ران PSD در دو عمق سطحی (۳۰ سانتی متر) و زیر سطحی (۶۰-۳۰ سانتی متر) در بخشی از اراضی دشت مرودشت استان فارس انجام شد.

### مواد و روش ها

#### منطقه مورد مطالعه

در پژوهش حاضر منطقه مورد مطالعه واقع در شهرستان مرودشت در فاصله‌ی ۴۰ کیلومتری شمال شهر شیراز مرکز استان فارس قرار دارد، که دارای مساحت حدود ۵۰ هزار هکتار بخشی از منطقه دشت مرودشت می باشد و در موقعیت طول های جغرافیایی ۳۵،۸۲' ۴۱' ۵۲° تا ۱،۰۷' ۵۷' ۵۲° شرقی و عرض های جغرافیایی ۳۵،۰۲' ۴۸' ۲۹° تا ۱۴،۷۲' ۲' ۳۰° شمالی واقع شده است (شکل ۱-پ). متوسط ارتفاع از سطح دریای آزاد نیز ۱۶۰۰ متر می باشد. براساس طبقه بندی ماهرل (Mahler, 1970) منطقه مطالعاتی دارای سه واحد فیزیوگرافی اصلی شامل کوهستان، دشت های دامنه ای و دشت های رسوبی بوده که براساس طبقه بندی ارائه شده توسط زینک (Zinck et al., 2015) از نظر ژئومورفولوژی در سه واحد زمین نمای اصلی شامل کوهستان، دشت های دامنه ای و دشت قرار می گیرد. برای تعیین اقلیم منطقه مطالعاتی از داده های دوره آماری ۳۰ ساله هواشناسی (۱۳۷۱-۱۴۰۰) توسط ایستگاه سد درودزن (سازمان هواشناسی کشور، ۱۳۹۸) استفاده شد. میانگین بارندگی سالانه برای این منطقه ۲۸۷/۶۳ میلی متر و میانگین دمای سالانه نیز ۱۷/۸۰ درجه سلسیوس می باشد. رژیم های رطوبتی و حرارتی خاک های منطقه مطالعاتی به ترتیب زیریک و ترمیک است و این خاک ها در دوره رده اصلی انتی سول و اینسپتی سول قرار دارند. مواد مادری اصلی خاک در منطقه مورد مطالعه رسوبات آبرفتی، سنگ آهک، شیل و مارن خاکستری است که قدمت آن ها به دوره کواترنر می رسد. اطلاعات زمین شناسی از نقشه های زمین شناسی ۱:۱۰۰۰۰۰ رقومی شده ایران جمع آوری شده است (Geology, 2010).



شکل ۱- منطقه مورد مطالعاتی و محل‌های نقاط نمونه‌برداری  
Figure 1- The location of study area and sampling points

جدول ۱- متغیرهای محیطی قابل استفاده برای پیش‌بینی اجزای بافت خاک

Table 1- The applied environmental covariates for predicting soil texture particles

References منابع	Covariates متغیرهای محیطی	Abbreviation علامت اختصاری	Formula فرمول	Source منشاء
U.S. Geology Survey 2014	Normalized different vegetation index شاخص نرمال شده گونه‌های مختلف گیاهی	NDVI	$(NIR+Red)/(NIR-Red)$	RS سنجش از دور
U.S. Geology Survey 2014	Renormalized difference vegetation index شاخص مجدد نرمال شده گونه‌های مختلف گیاهی	RDVI	$(NIR+Red+L)/(NIR-Red)$	RS سنجش از دور
U.S. Geology Survey 2014	Band 2 of Landsat 8 باند ۲ لندست ۸	Blue آبی	Landsat 8 image individual band تصویر لندست ۸ باند فردی	RS سنجش از دور
U.S. Geology Survey 2014	Band 3 of Landsat 8 باند ۳ لندست ۸	Green سبز	Landsat 8 image individual band تصویر لندست ۸ باند فردی	RS سنجش از دور
U.S. Geology Survey 2014	Band 4 of Landsat 8 باند ۴ لندست ۸	Red قرمز	Landsat 8 image individual band تصویر لندست ۸ باند فردی	RS سنجش از دور

U.S. Geology Survey 2014	Band 5 of Landsat 8 باند ۵ لندست ۸	Near infrared نزدیک به فرورسرخ	Landsat 8 image individual band تصویر لندست ۸ باند فردی	RS سنجش از دور
U.S. Geology Survey 2014	Band 6 of Landsat 8 باند ۶ لندست ۸	Short-wave infrared-1 فرورسرخ کوتاه موج - ۱	Landsat 8 image individual band تصویر لندست ۸ باند فردی	RS سنجش از دور
U.S. Geology Survey 2014	Band 7 of Landsat 8 باند ۷ لندست ۸	Short-wave infrared-2 فرورسرخ کوتاه موج - ۲	Landsat 8 image individual band تصویر لندست ۸ باند فردی	RS سنجش از دور
U.S. Geology Survey 2014	Wetness brightness difference index شاخص تفاوت روشنایی رطوبت	WBDI	$(NIR-SWIR)/(NIR+SWIR)$	RS سنجش از دور
U.S. Geology Survey 2014	Normalized difference salinity index شاخص نرمال شده تفاوت شوری	NDSI	$(Green-SWIR)/(Green+SWIR)$	RS سنجش از دور
U.S. Geology Survey 2014	Normalized difference moisture index شاخص نرمال شده تفاوت رطوبت	NDMI	$(NIR-SWIR)/(NIR+SWIR)$	RS سنجش از دور
U.S. Geology Survey 2014	Brightness Index شاخص روشنایی	BI	$(Red+Green+Blue)/3$	RS سنجش از دور
U.S. Geology Survey 2014	Gypsum Index شاخص گچ	GI	$(SWIR1-SWIR2)/(SWIR1+SWIR2)$	RS سنجش از دور
U.S. Geology Survey 2014	Clay Index شاخص خاک رس	CI	$(SWIR1-SWIR2)/(SWIR1+SWIR2)$	RS سنجش از دور
U.S. Geology Survey 2014	Carbonate Index شاخص کربنات	CI	$(SWIR1-SWIR2)/(SWIR1+SWIR2)$	RS سنجش از دور
U.S. Geology Survey 2014	Ratio Vegetation Index شاخص نسبت گیاهی	RVI	Red / NIR	RS سنجش از دور
U.S. Geology Survey 2014	Enhanced Vegetation Index شاخص گیاهی تقویت شده	EVI	$G \times (NIR-Red) / (NIR+C1 \times Red-C2 \times Blue+L)$	RS سنجش از دور
U.S. Geology Survey 2014	Green-Red Vegetation Index شاخص گیاهی سبز-قرمز	GVI	$(Green-Red)/(Green+Red)$	RS سنجش از دور
U.S. Geology Survey 2014	Differenced Vegetation Index شاخص تفاوت گیاهی	DVI	NIR-Red	RS سنجش از دور
U.S. Geology Survey 2014	Infrared Percentage Vegetation Index شاخص درصد گیاهی مادون قرمز	IPVI	$(NIR-SWIR)/(NIR+SWIR)$	RS سنجش از دور
U.S. Geology Survey 2014	Iron Oxide Ratio نسبت اکسید آهن	IOR		RS سنجش از دور
U.S. Geology Survey 2014	Soil Adjusted Vegetation Index شاخص گیاهی تنظیم شده برای خاک	SVI	$(NIR-Red) / (NIR+Red+L)$	RS سنجش از دور
U.S. Geology Survey 2014	Modified Soil Adjusted Vegetation Index شاخص گیاهی تنظیم شده تغییر یافته برای خاک	MSAVI	$(2 \times NIR+1 - (2 \times NIR+1)^2 - 8 \times (NIR-Red)) / ((2 \times NIR+1)^2 - 8 \times (NIR-Red))$	RS سنجش از دور
U.S. Geology Survey 2014	Perpendicular Vegetation Index شاخص گیاهی عمودی	PVI	$(Green-Red)/(Green+Red)$	RS سنجش از دور
U.S. Geology Survey 2014	Structure Insensitive Pigment Index شاخص حساس به ساختار پیگمان	SIPI		RS سنجش از دور
U.S. Geology Survey 2014	Modified Normalized Difference Water Index شاخص آب تفاوت نرمال شده تغییر یافته	MNDVI	$(Green-SWIR)/(Green+SWIR)$	RS سنجش از دور
U.S. Geology Survey 2014	Enhanced Vegetation Index شاخص گیاهی تقویت شده	EVI	$G \times (NIR-Red) / ((NIR+C1 \times Red-C2 \times Blue+L))$	RS سنجش از دور
U.S. Geology Survey 2014	Soil Adjusted Vegetation Index شاخص گیاهی تنظیم شده برای خاک	SAVI		RS سنجش از دور

U.S. Geology Survey 2014	Bare Soil Index شاخص خاک بی‌پوشان	BSI		RS سنجش از دور
U.S. Geology Survey 2014	Index-Based built-up Index شاخص ساخت‌های مبتنی بر ایندکس	IBI		RS سنجش از دور
U.S. Geology Survey 2014	Enhanced Vegetation Index 2 شاخص گیاهی تقویت‌شده ۲	EVI 2	$(NIR-Red)/(NIR+2.4 \times Red+1) 2.5 \times$	RS سنجش از دور
U.S. Geology Survey 2014	Visible Atmospherically Resistance Index Green شاخص مقاومت اتمسفری قابل رؤیت - سبز	VARIgreen	$(Green-Red)/(Green+Red-Blue)$	RS سنجش از دور
U.S. Geology Survey 2014	Green Normalized Difference Vegetation Index شاخص گیاهی نرمال شده تفاوت سبز	GNDVI	$(NIR-Green)/(NIR+Green)$	RS سنجش از دور
U.S. Geology Survey 2014	Tasseled cap wetness رطوبت تسلد کپ	TCW		RS سنجش از دور
U.S. Geology Survey 2014	Tasseled cap greenness سبزی تسلد کپ	TCG		RS سنجش از دور
U.S. Geology Survey 2014	Normalized Ratio Vegetation Index شاخص نرمال شده نسبت گیاهی	NRVI	NIR/Red	RS سنجش از دور
Olaya (2004)	Wind Effect تاثیر باد	WE		DEM نقشه رقومی ارتفاع
Olaya (2004)	Analytical Hillshading تظلیل تحلیلی	AH		DEM نقشه رقومی ارتفاع
Olaya (2004)	Aspect جهت	Aspect		DEM نقشه رقومی ارتفاع
Olaya (2004)	Catchment Area منطقه‌ی آبگیر	CA		DEM نقشه رقومی ارتفاع
Olaya (2004)	Catchment Slope شیب حوضه	CS		DEM نقشه رقومی ارتفاع
Olaya (2004)	Channel Direction جهت رودخانه یا راهروی آبی	CD		DEM نقشه رقومی ارتفاع
Olaya (2004)	Channel Network Base Level سطح پایه شبکه رودخانه	CNBL		DEM نقشه رقومی ارتفاع
Olaya (2004)	Channel Network Distance فاصله شبکه رودخانه	CND		DEM نقشه رقومی ارتفاع
Olaya (2004)	Channel Network شبکه رودخانه	CN		DEM نقشه رقومی ارتفاع
Olaya (2004)	Closed Depressions تسلیمات بسته یا تسلیمات بسته‌شونده	CD		DEM نقشه رقومی ارتفاع
Olaya (2004)	Convergence Index شاخص همگرایی	CI		DEM نقشه رقومی ارتفاع
Olaya (2004)	Diffuse Insolation تسشع پراکنده	Diffuse		DEM نقشه رقومی ارتفاع
Olaya (2004)	Direct Insolation تسشع مستقیم	DI		DEM نقشه رقومی ارتفاع
Olaya (2004)	Flow Directions جهت جریان	FD		DEM نقشه رقومی ارتفاع
Olaya (2004)	Geomorphons ژئومورفونز	Geomorphons		DEM نقشه رقومی ارتفاع
Olaya (2004)	Landforms زمین شکل‌ها	Landforms		DEM نقشه رقومی ارتفاع
Olaya (2004)	LS Factor فاکتور طول و شیب	LS Factor		DEM نقشه رقومی ارتفاع



Olaya (2004)	Mass Balance Index شاخص تعادل جرم	MBI	DEM نقشه رقومی ارتفاع
Olaya (2004)	Modified Catchment Area ناحیه آبگیر تغییر یافته	MCA	DEM نقشه رقومی ارتفاع
Olaya (2004)	MRRTF	MRRTF	DEM نقشه رقومی ارتفاع
Olaya (2004)	Plan Curvature انحنای مسطح	PC	DEM نقشه رقومی ارتفاع
Olaya (2004)	Relative Slope Position موقعیت نسبی شیب	RSP	DEM نقشه رقومی ارتفاع
Olaya (2004)	Slope Height ارتفاع شیب	SH	DEM نقشه رقومی ارتفاع
Olaya (2004)	Slope شیب	Slope	DEM نقشه رقومی ارتفاع
Olaya (2004)	Standardized Height ارتفاع استاندارد	SH	DEM نقشه رقومی ارتفاع
Olaya (2004)	Stream Power Index شاخص توان جریان	SPI	DEM نقشه رقومی ارتفاع
Olaya (2004)	Surface Area مساحت سطح	SA	DEM نقشه رقومی ارتفاع
Olaya (2004)	Watershed Basins حوضه آبخیز	WB	DEM نقشه رقومی ارتفاع
Olaya (2004)	Wind Exposition جهت باد	WE	DEM نقشه رقومی ارتفاع
Olaya (2004)	Valley depth (m) عمق دره	VD	DEM نقشه رقومی ارتفاع
Olaya (2004)	Multiresolution index of valley bottom flatness شاخص همواری دره با درجه وضوح بالا	MRVBF	DEM نقشه رقومی ارتفاع
Olaya (2004)	Normalized Height ارتفاع نرمال شده	NH	DEM نقشه رقومی ارتفاع
Olaya (2004)	Midslope position موقعیت میانی انحدار	MS	DEM نقشه رقومی ارتفاع
Olaya (2004)	Terrain surface texture بافت سطح زمین	TE	DEM نقشه رقومی ارتفاع
Olaya (2004)	Slope gradient شیب افقی	SG	DEM نقشه رقومی ارتفاع
Olaya (2004)	Vertical Distance to Channel Network فاصله عمودی تا شبکه رودخانه	VDCN	DEM نقشه رقومی ارتفاع
Olaya (2004)	Solar radiation or insolation تابش خورشیدی	SROI	DEM نقشه رقومی ارتفاع
Olaya (2004)	Convexity خمیدگی	Convexity	DEM نقشه رقومی ارتفاع
Olaya (2004)	Topographic Wetness Index شاخص توپوگرافیک رطوبت	TWI	DEM نقشه رقومی ارتفاع

LAB=laboratory analysis، پستی و بلندی، R=relief، موجودات زنده، O=organism، خاک، S= soil properties، ویژگی خاک، DEM=Digital elevation model، نقشه رقومی ارتفاع، RS=Remote sensing، سنجش از دور.

متناسب با اندازه سلولی متغیرهای به دست آمده از تصاویر ماهواره‌ای یکسان شد. تعداد بالای متغیرهای محیطی باعث ایجاد هم‌بستگی زیاد

در مجموع، ۷۵ متغیر محیطی تهیه شد **جدول ۱** که در نهایت فرمت رستری مربوط به تمام متغیرهای محیطی با اندازه سلول ۳۰ متر،

منزله نرمال بودن توزیع داده‌ها به‌عنوان مبنا قرار گرفت.

### مدل‌سازی یادگیری ماشین (سناریو ۲)

براساس فراوانی مدل‌های یادگیری ماشین که در مدل‌سازی ویژگی‌های خاک قابل استفاده می‌باشند، در تحقیق حاضر تلاش شده است تا کارایی این مدل‌ها در مدل‌سازی اجزای بافت خاک در دو عمق مورد نظر در منطقه مطالعاتی، مورد ارزیابی قرار گیرد و در نهایت از بین مدل‌های پیش‌بینی کننده و متغیرهای محیطی بهینه انتخاب شده، بهترین مدل پیش‌بینی کننده اجزای بافت خاک به همراه متغیرهای محیطی بهینه انتخاب شده برای به‌دست آوردن ویژگی مورد پژوهش در منطقه مطالعاتی نیز استفاده گردید. مدل جنگل تصادفی ( *Bi et al., 2004*) یکی از مدل‌های یادگیری ماشین مبتنی بر سامانه‌های درختی است که امروزه به‌عنوان یکی از پرکارترین الگوریتم‌ها در نقشه برداری رقومی خاک محسوب می‌شود ( *Beriman, 2001*)، نحوه آموزش مدل جنگل تصادفی، به‌گونه‌ای است که در آن هر درخت به‌وسیله روش جایگزینی با تکرار از میان مجموعه‌ای از درختان به‌صورت تصادفی انتخاب و آموزش می‌بیند و زیرمجموعه‌های پیش‌بینی کننده نیز بر اساس قوانین تقسیم گره به‌صورت تصادفی انتخاب می‌گردند.

بین آن‌ها می‌شود که نتیجه آن، کاهش سرعت محاسبات و کاهش صحت و اعتبار مدل‌های پیش‌بینی کننده می‌باشد. برای مدل‌سازی تغییرات اجزای بافت خاک در نقشه‌برداری رقومی، علاوه بر داده‌های مشاهداتی نیاز به داده‌های کمکی مشتق شده از مدل رقومی ارتفاع و تصاویر ماهواره‌ای نیز می‌باشد. بدین منظور ۳۹ متغیر پستی و بلندی و ۳۶ متغیر سنجش از دور استخراج گردید. با توجه به حجم زیاد داده‌های موجود برای استفاده در فرآیند مدلسازی، به‌عنوان متغیرهای پیش‌بینی کننده از روش فاکتور تورم واریانس و الگوریتم باروتا در نرم افزار SPSS (V.20) برای انتخاب مناسب‌ترین مجموعه داده از میان کل متغیرهای محیطی تهیه شده و انتخاب متغیرهای محیطی بهینه برای اجرای مدل با ارائه کمترین خطا ضروری می‌باشد.

### مدل‌سازی مکانی

#### مدل‌سازی زمین‌آمار (سناریو ۱)

سناریو اول صورت پذیرفته در پژوهش حاضر به بررسی روش زمین‌آمار برای برآورد اطلاعات اجزای بافت خاک در اعماق سطحی (۰-۳۰ و ۳۰-۶۰ Cm) در منطقه مورد مطالعه پرداخته شد. تمامی آنالیزهای مورد استفاده در این بخش توسط نرم‌افزار Arc GIS نسخه 10.8 بخش Geostatistical Analyst براساس روش کو-کریجینگ (Co-Kriging) صورت پذیرفت و متغیرهای محیطی منتخب برای پیش‌بینی PSD با این روش در جدول ۲ ارائه شده است. همچنین متغیرهای محیطی یا کمکی (Covariates) برای استفاده در روش کوکریجینگ به روش همبستگی پیرسون انتخاب گردیدند. قابل اشاره است که قبل از انجام برازش روش‌های زمین‌آماري بهتر است که از نرمال بودن توزیع داده‌ها اطمینان حاصل شود که در این پژوهش مقادیر چولگی بین ۱+ تا ۱- و افراستگی بین ۳+ تا ۳- به

جدول ۲- متغیرهای منتخب برای روش زمین‌آماري کوکریجینگ

Table 2- The selected covariates for Co-Kriging geostatistics method

Soil properties ویژگی‌های مورد مطالعاتی	Depths اعماق	Covariates 1 متغیر محیطی ۱	Covariates 2 متغیر محیطی ۲	Covariates 3 متغیر محیطی ۳
Sand شن	0-30	Watershed Basins حوضه‌های آبخیز	MRRTF	Valley depth عمق دره
	30-60	Valley depth عمق دره	Watershed Basins حوضه‌های آبخیز	
Silt سیلت	0-30	Watershed Basins حوضه‌های آبخیز	Valley depth عمق دره	MRRTF
	30-60	Watershed Basins حوضه‌های آبخیز	Slope شیب	Valley depth عمق دره
Clay رس	0-30	Convergence index شاخص همگرایی	Watershed Basins حوضه‌های آبخیز	Valley depth عمق دره
	30-60	Valley depth عمق دره	Watershed Basins حوضه‌های آبخیز	Slope شیب

متوسط، میزان  $2 \leq RPD < 3$  دارای دقت رضایت بخش، میزان ۳  $RPD < 4$  دارای دقت خوب و میزان  $RPD \geq 4$  دارای دقت عالی می باشد (Sørensen et al., 2004).

## نتایج و بحث

### خلاصه آماری اجزای بافت خاک

خلاصه آماری اجزای بافت خاک اندازه گیری شده در دو عمق سطحی و زیر سطحی منطقه مورد مطالعه در جدول ۳ ارائه شده است. کمترین میزان رس به ترتیب با ۱۰/۲۱ و ۱۰/۴۵ و بیشترین میزان آن ۶۵/۳۲ و ۶۳/۳۶ درصد در عمق سطحی و زیر سطحی اندازه گیری شد. میانگین رس در تمام نمونه ها ۳۷/۹۱ و ۳۵/۶۱ درصد است. میانگین شن در عمق سطحی ۲۵/۶۵ و در عمق زیر سطحی ۲۶/۰۲ درصد اندازه گیری شد. به طوری که بیشترین میزان آن در عمق سطحی و برابر با ۶۸/۵۴ درصد و کمترین مقدار آن در عمق زیر سطحی و برابر با ۳/۷۶ درصد است. بیشترین و کمترین مقدار سیلت در عمق زیر سطحی و به ترتیب برابر با ۷۶/۱۳ و ۴/۹۱ با میانگین ۳۸/۳۷ درصد است. براساس طبقه بندی (Wilding, 1985) تغییرپذیری شن در منطقه مورد مطالعه زیاد (بیش از ۳۵ درصد) بوده و رس و سیلت دارای تغییرپذیری متوسط (۱۳-۳۵ درصد) می باشند. زراعت پیشه و همکاران (Zeraatpisheh et al., 2020) نیز میانگین رس در استان فارس را ۳۷/۹ درصد و تغییرپذیری آن را متوسط (۲۰/۱ درصد) گزارش کردند. تشیع و همکاران (Tashayo et al., 2020) نیز گزارش کردند که میانگین شن در مرودشت استان فارس بیشتر از رس و سیلت است.

### انتخاب متغیرهای کمکی محیطی

مناسب ترین متغیرهای کمکی با استفاده از آزمون هم خطی توسط شاخص تورم واریانس (VIF) و سپس رویکرد انتخاب متغیر باروتا انتخاب شدند و در جدول ۴ و شکل ۲ ارائه شده است. چهار متغیر عمق دره (VD)، بافت (TE)، شاخص رطوبت پستی و بلندی (TWI) و شاخص رس (CM) مربوط به پارامترهای ژئومورفتری و متغیر شاخص تفاضلی پوشش گیاهی نرمال شده (NDVI) مربوط به شاخص های سنجش از دور می باشند (جدول ۴). جابجایی ذرات ریز خاک ارتباط نزدیکی با توپوگرافی منطقه مورد مطالعه دارد (Swain et al., 2021). مصلح و همکاران (Mosleh et al., 2016) و موسوی و همکاران (Mousavi et al., 2019) بیان نمودند که پارامترهای استخراج شده از مدل رقومی ارتفاع می توانند به عنوان متغیرهای محیطی مناسب در مدل سازی کلاس و خصوصیات خاک محسوب شوند.

در حین فرآیند اجرای مدل RF، تعداد درختان در هر جنگل (ntree) و تعداد متغیرهای مورد استفاده برای رشد هر درخت (mtry)، به عنوان مهم ترین پارامترهای تنظیمی مدل RF می باشند. در این تحقیق جهت بهینه سازی فاکتورهای اصلی و تنظیم کننده کارکرد مدل RF به ترتیب تعداد درختان (ntree) با فاصله هر ۵۰ عدد در دامنه ۱۰۰ تا ۱۰۰۰ درخت با فاصله ۱۰۰ عدد درخت و تعداد متغیرهای محیطی قابل استفاده برای رشد هر درخت بر اساس حداقل مقدار خطا RMSE بر اساس بسته تخصصی "random forest" در محیط نرم افزار R تعیین گردیدند (Friedman & Meulman, 2003). مدل دیگر مورد استفاده در این پژوهش رگرسیون ماشین بردار پشتیبان می باشد، این روش الگوریتمی است که رابطه میزان ورودی و خروجی یک سیستم را از روی نمونه های موجود و یا داده های آموزش، تخمین می زند (Bi et al., 2004). تمامی فرآیندهای مدل سازی در محیط نرم افزار Rstudio 1.0.136 صورت پذیرفت.

### اعتبارسنجی نتایج مدل سازی

فرآیند اعتبارسنجی مدل های یادگیری ماشین و زمین آماری مورد استفاده با استفاده از ۲۰ درصد کل داده ها صورت پذیرفت و صحت مدل ها با استفاده از شاخص های آماری ضریب تبیین ( $R^2$ )، ریشه نرمال شده میانگین مربعات خطا (nRMSE) و درصد اختلاف نسبی (RPD) محاسبه شد (روابط ۱، ۲ و ۳) (Rosset & McBratney, 2008).

$$R^2 = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (1)$$

$$nRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2}}{\bar{O}} \quad (2)$$

$$RPD = \frac{SD}{RMSE} \times 100 \quad (3)$$

که در روابط بالا، n تعداد نقاط نمونه برداری،  $O_i$  مقدار مشاهداتی،  $\bar{O}$  میانگین مقادیر مشاهداتی و  $P_i$  مقدار تخمین زده شده متغیر، SD انحراف استاندارد مقادیر مشاهداتی RMSE ریشه دوم میانگین مربعات خطا.

RPD پایین تر نشان دهنده تطابق بهتر بین مقادیر مشاهداتی و پیش بینی شده است. مقادیر RPD را می توان برای طبقه بندی دقت یک روش پیش بینی به صورت زیر استفاده کرد: میزان  $RPD > 1$  دقت ضعیف، میزان  $1 \leq RPD < 2$  دقت

جدول ۳- خلاصه آماری اجزای بافت خاک در منطقه مطالعاتی در دو عمق سطحی و زیرسطحی

Table 3- Statistical summary of Soil Texture Particles in study area at surface and subsurface depths

اجزای بافت خاک Soil texture	اعماق Depths	میانگین Mean	حداقل Min	حداکثر Max	انحراف معیار SD	ضریب تغییرات % CV
Sand	0-30	25.6	8.50	68.54	11.2	0.45
شن	30-60	26.0	3.76	66.06	12.58	0.48
Silt	0-30	36.4	10.13	70.66	10.7	0.29
سیلت	30-60	38.3	4.91	76.13	10.69	0.30
Clay	0-30	37.9	10.21	65.32	9.78	0.25
رس	30-60	35.6	10.45	63.36	9.90	0.25

CV: Coefficient of variation, SD: Standard deviation, Max: Maximum, Min: Minimum

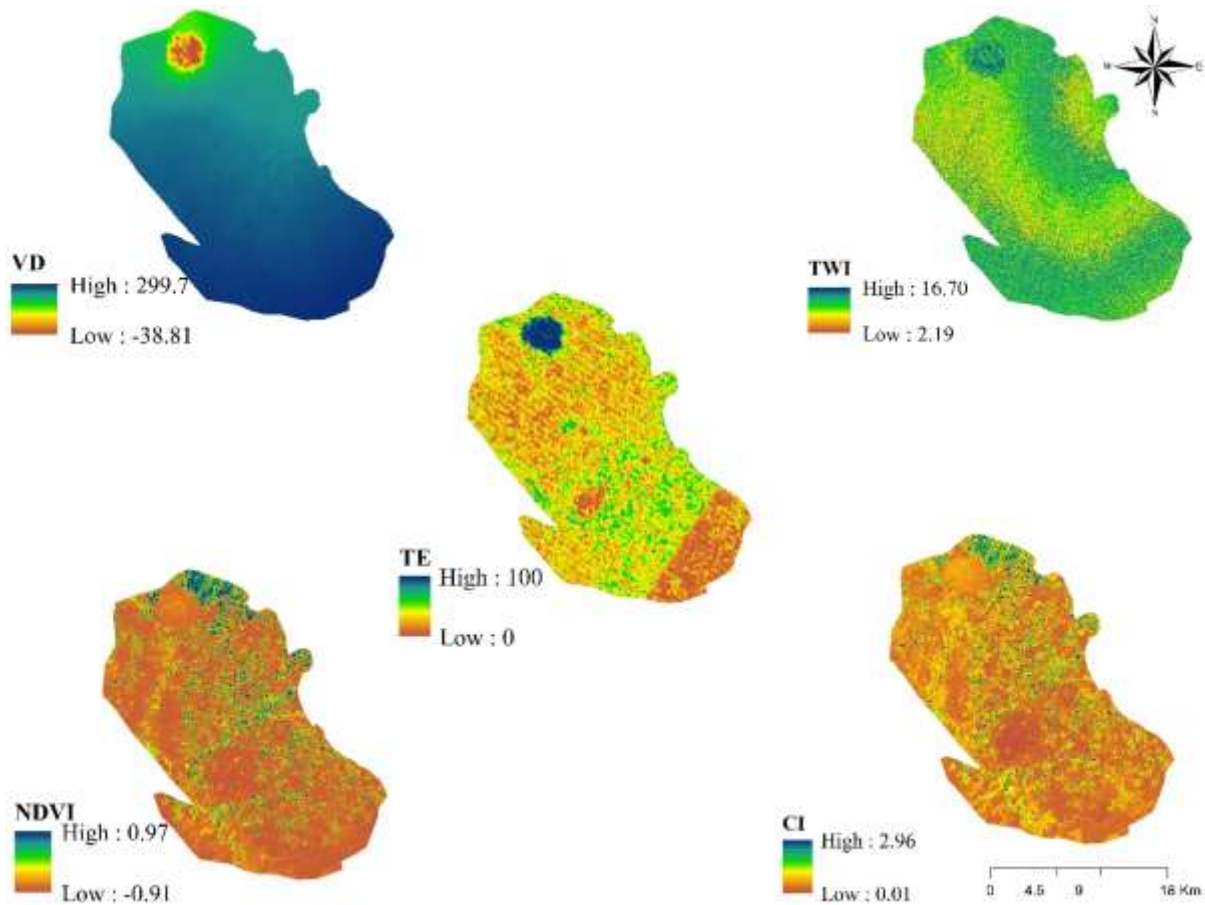
جدول ۴- متغیرهای کمکی محیطی مورد استفاده در پیش‌بینی مکانی اجزای بافت خاک

Table 4- Environmental covariates used in Soil Texture Particles spatial prediction

فاکتور خاک‌ساز (scorpan) Soil Forming Factor	نماد Symbol	متغیر کمکی محیطی Environmental variable	منبع Source
پستی و بلندی Topography (r)	VD	عمق دره Valley depth	
پستی و بلندی Topography (r)	TE	شاخص بافت پستی و بلندی Terrain surface texture	مدل رقومی ارتفاع
پستی و بلندی Topography (r)	TWI	شاخص خیسسی پستی و بلندی Topographic wetness Index	Digital elevation model
پستی و بلندی Topography (r)	CI	شاخص رس Clay Index	
زیستی Organism (O)	NDVI	شاخص تفاضلی پوشش گیاهی نرمال شده Normalized differences vegetation index	داده های سنجنش از دور Remote sensing

r و O به ترتیب نشانگر فاکتورهای پستی و بلندی و زیستی در مدل scorpan هستند.

r, p represents topography and organism factors in the scorpan model, respectively.



شکل ۲- متغیرهای کمکی محیطی مورد استفاده در پیش‌بینی مکانی اجزای بافت خاک  
Figure 2- Environmental covariates used in Soil Texture Particles spatial prediction

و  $0.64$ ، برای SVR به ترتیب برابر با  $0.10$  و  $0.06$ ، و برای Co-Kriging به ترتیب برابر با  $0.02$  و  $0.01$  در دو عمق سطحی و زیر سطحی به دست آمد. برای پیش‌بینی رس نیز مدل RF با  $R^2$   $0.52$  و  $0.49$  بهترین عملکرد را دارد. مقایسه نتایج nRMSE و RPD نشان داد که مدل RF برای پیش‌بینی رس (nRMSE به ترتیب برابر با  $0.16$  و  $0.27$  و  $1 \leq RPD < 2$ ) دارای عملکرد متوسط و دقت متوسط مشابه با پیش‌بینی سیلت (nRMSE به ترتیب برابر با  $0.19$  و  $0.24$  و  $1 \leq RPD < 2$ ) بود و دقت رضایت بخش و شن (nRMSE به ترتیب  $0.32$  و  $0.42$  و  $1 \leq RPD < 2$ ) نیز عملکردی شبیه دو ویژگی دیگر از خود نشان داد (Wallach et al., 2006; Sørensen et al., 2004) که می‌تواند به علت تغییرپذیری کمتر رس نسبت به سیلت و شن باشد (جدول ۵). به‌طور کلی پیش‌بینی شن و رس در عمق سطحی دارای دقت بالاتر نسبت به عمق زیرسطحی است که با نتایج لوئیرو و همکاران (Loiseau et al., 2019) مطابقت داشت.

همچنین مطالعات مختلف گزارش نمودند که داده‌های سنجش از دور در سطح جهانی و محلی در مطالعات نقشه‌برداری رقومی خاک موفق بوده است (Hengl et al., 2017). چن و همکاران (Chen et al., 2022) نشان دادند که استفاده از مدل باروتا برای انتخاب متغیرهای محیطی کمکی نسبت به سایر مدل‌های انتخاب متغیر منجر به خطا (RMSE) کمتر برای پیش‌بینی کربن آلی خاک شد.

#### مقایسه ارزیابی عملکرد مدل‌ها

عملکرد مدل‌های یادگیری ماشین جنگل تصادفی (RF) و رگرسیون بردار پشتیبان (SVR) و مدل زمین‌آماري کوکریجینگ (Co-kriging) با استفاده از سه شاخص آماری  $R^2$ ، nRMSE و RPD محاسبه شد (جدول ۵). مقادیر  $R^2$  برای پیش‌بینی شن در عمق سطحی توسط مدل RF، SVR و Co-Kriging به ترتیب  $0.54$ ،  $0.16$  و  $0.16$  و برای عمق زیرسطحی به ترتیب  $0.36$ ،  $0.15$  و  $0.06$  درصد محاسبه شد. برای پیش‌بینی سیلت میزان  $R^2$  برای RF به ترتیب برابر با  $0.48$

جدول ۵- نتایج اعتبارسنجی مدل زمین آماری و مدل‌های یادگیری ماشین برای اجزای بافت خاک در عمق سطحی و زیرسطحی در منطقه مورد مطالعه

Table 5- Validation results of the geostatistics model and machine learning models for Soil Texture Particles at surface and subsurface depth in the study areas

ویژگی Property	بهترین مدل پیش‌بینی کننده The best predictive model	عمق Depth (cm)	R <sup>2</sup>	nRMSE	PRD
نتایج اعتبارسنجی در منطقه مطالعاتی					
Sand شن	RF	0-30	0.54	0.32	1.35
		30-60	0.36	0.42	1.15
	SVR	0-30	0.16	0.62	0.70
		30-60	0.15	0.86	0.56
	Co-kriging	0-30	0.16	0.97	0.45
		30-60	0.06	0.87	0.55
Silt سیلت	RF	0-30	0.48	0.19	1.47
		30-60	0.64	0.24	1.21
	SVR	0-30	0.10	0.32	0.90
		30-60	0.06	0.34	0.83
	Co-kriging	0-30	0.002	0.86	0.34
		30-60	0.01	0.90	0.31
Clay رس	RF	0-30	0.52	0.16	1.67
		30-60	0.49	0.27	1.01
	SVR	0-30	0.08	0.27	0.95
		30-60	0.11	0.27	1.03
	Co-kriging	0-30	0.04	0.46	0.56
		30-60	0.07	0.66	0.42

تعیین (R<sup>2</sup>) و ضریب همبستگی تطابق لین<sup>۳</sup> (CCC) به ترتیب از ۶/۹۵ تا ۸/۷۴، ۸/۹ تا ۱۱/۳، ۴۲ تا ۴۶ و ۵۶ تا ۵۹ درصد متغیر بود. همچنین تومساواش و همکاران (Tu'msavas et al., 2019) RPD ۳/۲۵ و ۳/۵۱ را برای پیش‌بینی شن و سیلت گزارش کردند.

#### اهمیت متغیرهای محیطی

تجزیه و تحلیل متغیرهای مهم در پیش‌بینی مدل‌های ML می‌تواند بینش‌هایی در مورد ماهیت مجموعه داده مورد استفاده ارائه دهد و در عین حال به افزایش کارایی پیش‌بینی‌های ML نیز کمک کند. بررسی ویژگی‌ها همچنین امکان تخصیص امتیازها به چندین ورودی را فراهم می‌کند تا مهم‌ترین تغییرات در مدل‌سازی را شناسایی کند. اهمیت متغیرهای محیطی استفاده شده برای پیش‌بینی تغییرات مکانی ذرات خاک در اعماق سطحی و زیرسطحی توسط مدل RF در شکل ۳ نشان داده شده است. بر این اساس VD با ۶۰ و ۶۵ درصد برای پیش‌بینی شن در عمق سطحی و زیر سطحی، ۷۰ درصد برای پیش‌بینی سیلت در عمق سطحی و ۷۰ و ۶۵ درصد برای پیش‌بینی رس در هر دو عمق سطحی و زیر سطحی دارای بیشترین اهمیت است. تنها برای پیش‌بینی سیلت در عمق زیرسطحی متغیرهای TE و TWI دارای اهمیت بیشتری نسبت به VD می‌باشند (شکل ۳). این نتایج نشان

شهریاری و همکاران (Shahriari et al., 2019) نیز اعلام کردند که مدل RF نسبت به مدل‌های زمین‌آماري دارای عملکرد بهتری برای پیش‌بینی شن، سیلت و رس است. مدل جنگل تصادفی می‌تواند روابط غیرخطی بین متغیرهای محیطی و ویژگی‌های خاک را به خوبی در حین فرآیند مدل‌سازی و پیش‌بینی لحاظ نماید همچنین قادر است تا با مدیریت داده‌های پرت از بروز بیش‌برازش و کم‌برازش جلوگیری نماید (Azizi et al., 2023; Khosravani et al., 2023a). نتایج موسوی و همکاران (Mousavi et al., 2020) نیز بیانگر دقت بالای مدل RF برای پیش‌بینی ویژگی‌های سطحی خاک شامل کرن‌آلی، کرنات کلسیم معادل، رس و سیلت نسبت به روش کریجینگ معمولی است. نتایج صحرائی و همکاران (Sahraei et al., 2022) نیز نشان داد که مدل RF نسبت به مدل ماشین بردار پشتیبان<sup>۱</sup> (SVM) دارای عملکرد بهتر برای پیش‌بینی اجزای بافت خاک است. آنها اعلام کردند که مدل SVM به لحاظ تغییرپذیری نسبت به مدل‌های پیچیده‌تر مانند RF، عدم قطعیت بیشتری را نشان می‌دهند، بنابراین مدل RF نسبت به مدل SVM دقت بالاتری را برای پیش‌بینی ذرات خاک دارا می‌باشد. نتایج ژانگ و همکاران (Zhang et al., 2023) نیز نشان داد که میزان رس خاک و تنوع آن با عمق خاک افزایش می‌یابد. به طوری که میانگین خطای مطلق<sup>۲</sup> (MAE)، ریشه میانگین مربعات خطا (RMSE)، ضریب

3- Lin's Concordance Correlation Coefficient

1- Support Vector Machine  
2- Mean Absolute Error

مقدار رس در مناطق شمالی و افزایش آن در مناطق جنوبی شده است. مشاهده‌ی این الگوی پراکنش برای رس با نمودارهای اهمیت نسبی آن (شکل ۳ ب و شکل ۲) همراستا هست به طوری که شاخص VD بالاترین میزان اهمیت بیشترین نقش را در تعیین الگوی پراکنش مکانی رس ایفا نموده است، نتایج مشابهی نیز توسط (Ließ *et al.*, 2012) گزارش شد و بیان نمودند که مقدار رس در زمین نما با افزایش ارتفاع و شیب کاهش و با انحنای شیب افزایش می‌یابد.

الگوی تغییرات مکانی شن (عمق سطحی و زیرسطحی) و سیلت (عمق سطحی) براساس شکل ۴ روند مشابهی را نشان داد. بیشترین کمترین مقدار شن پیش‌بینی شده در عمق سطحی ۱۵/۱۴ و ۵۴/۲۴ و زیر سطحی به ترتیب برابر با ۱۴/۴۶ و ۵۵/۱۷ (شکل ۴ ب و ث) و برای سیلت در عمق سطحی برابر ۱۷/۲۳ و ۷۳/۶۰ (شکل ۴ الف) درصد مشاهده گردید. برخلاف رس بیشترین مقدار شن در هر دو عمق در قسمت شمالی و مرتفع‌ترین قسمت منطقه مورد مطالعه مشاهده گردید و کمترین مقدار آن در نواحی پست منطقه مورد مطالعه مشاهده گردید. این نتایج در حالی است که طبق (شکل ۴ ت) روند تغییرات سیلت در عمق زیرسطحی به الگوی رس مشابه‌تر می‌باشد. مناطق پست و همچنین دشت‌های رسوبی در قسمت مرکزی منطقه مورد مطالعه حاوی مقادیر زیادی سیلت بودند. بنابراین می‌توان بیان نمود که این تغییرات در دو عمق سطحی و زیرسطحی برای اجزای بافت خاک تا حد زیادی متاثر از توالی فرآیندهای فرسایش و رسوب بوده که توزیع نامنظمی از اجزای بافت را از سطح به عمق نشان می‌دهد. در همین راستا ویلکی و همکاران (Wilcke *et al.*, 2008) ارتباط قوی بین اجزای بافت خاک و ارتفاع در منطقه‌ی مطالعاتی خود توصیف نمود و بیان نمود که یک همبستگی مثبت بین پارامترهای وابسته به ارتفاع با شن و متعاقباً همبستگی منفی با مقدار رس وجود دارد. همچنین نتایج مشابهی توسط سایر محققین (Gessler *et al.*, 2000; Ziadat, 2005; Riza *et al.*, 2021; Mousavi *et al.*, 2023) در مورد ارتباط بین اجزای بافت خاک و تغییرات ارتفاع مشاهده شده است. فرآیندهای توپوگرافی، با کنترل فرآیندهای فرسایش و رسوب بر روی مقادیر پراکنش مکانی اجزای بافت خاک مؤثر هستند و همچنین در مناطق مرتفع (قله و شانه شیب) بیشترین مقدار شن و در مناطق پای شیب بیشترین مقدار رس وجود دارد.


این نقشه‌ها می‌توانند به عنوان متغیرهای کمکی در سایر برنامه ریزی‌های مربوط به مدیریت اراضی از قبیل تعیین آب قابل استفاده و حاصلخیزی خاک مورد استفاده قرار گیرند (Ostovari *et al.*, 2021).

می‌دهد که متغیرهای توپوگرافی بر تغییرات مکانی ذرات خاک مؤثر می‌باشند. این یافته با نتایج تقی زاده مهرجردی و همکاران (Taghizadeh-Mehrjardi *et al.*, 2016; Maleki *et al.*, 2023; ) (Khosravani *et al.*, 2023b) و پهلوان راد و اکبری مقدم، (Pahlavan-Rad & Akbarimoghaddam, 2018) منطبق می‌باشد. توپوگرافی بر توزیع اندازه ذرات خاک عمدتاً با کنترل جریان آب و حمل و نقل ذرات خاک تأثیر می‌گذارد (Mahmoudzadeh *et al.*, 2020). ژانگ و همکاران (Zhang *et al.*, 2019) دریافتند که خاک سطحی به شدت در معرض کنترل‌های توپوگرافی قرار دارد. در مطالعه حاضر VD مهمترین عامل توپوگرافی است که توزیع ذرات خاک را تحت تأثیر قرار داده است. VD بیانگر فاصله عمودی در سطح پایه شبکه کانال است، بنابراین عامل مهمی برای تعیین کمیت کنترل توپوگرافی در فرایندهای هیدرولوژیکی است (Lee *et al.*, 2020). پهلوان راد و اکبری مقدم، (Pahlavan-Rad & Akbarimoghaddam, 2018) فاصله تا شبکه آبراهه<sup>۱</sup> را مهمترین متغیر در پیش‌بینی رس شناسایی کردند. جان و همکاران (John *et al.*, 2020) متغیرهای محیطی TWI و حوزه آبریز را مهمترین متغیرهای برای پیش‌بینی ویژگی‌های خاک معرفی کردند. دهروماراجان و هگده (Dharumarajan & Hegde, 2022) نیز شاخص همواری کف دره با درجه تفکیک بالا<sup>۲</sup> (MrVBF) را به عنوان مهمترین متغیر در پیش‌بینی توزیع مکانی ذرات خاک معرفی کردند. کایا و باشاقیت (Kaya & Başayigit, 2021) بیان کردند که مدل رقومی ارتفاع و مشتقات آن مهمترین متغیرهای محیطی در پیش‌بینی توزیع ذرات خاک است.

### توزیع مکانی ذرات خاک


با توجه به اینکه مدل RF نسبت به دو مدل SVM و Cokriging از دقت بالاتری برای پیش‌بینی اجزای بافت خاک برخوردار بود بنابراین نقشه‌های توزیع مکانی ذرات خاک توسط مدل RF در شکل ۴ نشان داده شده است. براساس شکل ۴ حداقل و حداکثر رس در عمق سطحی به ترتیب ۲۰/۹۳ و ۵۲/۵۷ و در عمق زیر سطحی به ترتیب ۲۰/۴۲ و ۵۴/۹۴ (شکل ۴ پ و ج) درصد مشاهده گردید. کمترین مقدار رس در هر دو عمق سطحی و زیر سطحی در قسمت شمال منطقه مورد مطالعه پیش‌بینی شد. در حالی که بیشترین مقدار آن در بخش غرب، مرکز تا جنوب وجود دارد.

چنین به نظر می‌رسد که پایین بودن مقدار رس در بخش‌های شمالی وابسته به تأثیر فرآیندهای فرسایش و رسوب به همراه اثر توپوگرافی می‌باشد، به طوری که مناطق مرتفع و با ارتفاع بیشتر در بخش شمالی بوده که تلفیق اثر توپوگرافی و انتقال املاح منجر به کاهش



شکل ۳- نمودار اهمیت متغیرهای محیطی برای پیش‌بینی الف. شن، ب. سیلت و پ. رس در عمق سطحی و زیر سطحی  
 Figure 3- Diagram of importance of environmental variables for predicting a. sand, b. silt and c. clay at surface and subsurface depth





شکل ۴- نقشه توزیع الف) سیلت سطحی، ب) شن سطحی، پ) رس سطحی، ت) سیلت زیرسطحی (ث) شن زیرسطحی، ج) رس زیرسطحی پیش‌بینی شده توسط مدل RF

Figure 4- The distribution map of Sand, Silt and Clay predicted in the surface and subsurface depth by the RF model (From top right to bottom left).

خاک و پوشش رویشی) کنترل می‌شود، داده‌های مشتق شده از مدل رقومی ارتفاع همراه با داده‌های سنجهش از دور در عملکرد مدل برای پیش‌بینی با دقت و صحت بیشتر مؤثر بود. به طوری که متغیر VD به عنوان مهمترین متغیر در پیش‌بینی توزیع مکانی ذرات خاک در منطقه مورد مطالعه شناسایی شد. برای افزایش دقت پیش‌بینی، می‌توان در مطالعات آبی از سایر منابع متغیرهای کمکی مانند متغیرهای آب و هوایی و داده‌های راداری استفاده کرد. همچنین رویکرد مورد استفاده در این تحقیق می‌تواند به عنوان راهنمایی برای تهیه نقشه‌های مدیریت پذیر خاک مورد استفاده قرار گیرد.

## نتیجه‌گیری

پژوهش حاضر با هدف کلی تهیه نقشه‌های اجزای بافت خاک (رس، سیلت و شن) و شناسایی مهمترین فاکتورهای پیش‌ران آن‌ها در بخشی از اراضی دشت مروست با کمک مدل‌های یادگیری ماشین و زمین آماری انجام گردید. مدل RF نسبت به مدل SVR و Co-Kriging در پیش‌بینی شن، سیلت و رس در هر دو عمق سطحی (۳۰ سانتی‌متر) و زیر سطحی (۶۰-۳۰ سانتی‌متر) عملکرد بهتری داشت. با توجه به پاسخ طیفی خاک که توسط عوامل متعددی (مانند رطوبت خاک، مواد آلی، زبری سطح، اثرات جوی، اثرات ساختاری، مدیریت

## منابع

1. Arrouays, D., McBratney, A., Bouma, J., Libohova, Z., Richer-de-Forges, A.C., Morgan, C.L., & Mulder, V.L. (2020). Impressions of digital soil maps: The good, the not so good, and making them ever better. *Geoderma Regional*, 20, e00255. <https://doi.org/10.1016/j.geodrs.2020.e00255>
2. Azizi, K., Garosi, Y., Ayoubi, S., & Tajik, S. (2023). Integration of Sentinel-1/2 and topographic attributes to predict the spatial distribution of soil texture fractions in some agricultural soils of western Iran. *Soil and Tillage Research*, 229, 105681. <https://doi.org/10.1016/j.still.2023.105681>
3. Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32. <https://doi.org/10.1023/A:1010933404324>
4. Bi, D., Li, Y.F., Tso, S.K., & Wang, G.L. (2004). Friction modeling and compensation for haptic display based on support vector machine. *IEEE Transactions on Industrial Electronics*, 51(2), 491-500. <https://doi.org/10.1109/TIE.2004.825277>

5. Dharumarajan, S., & Hegde, R. (2022). Digital mapping of soil texture classes using Random Forest classification algorithm. *Soil Use and Management*, 38(1), 135-149. <https://doi.org/10.1111/sum.12668>
6. de Jesus Duarte, S., Glaser, B., & Pellegrino Cerri, C.E. (2019). Effect of biochar particle size on physical, hydrological and chemical properties of loamy and sandy tropical soils. *Agronomy*, 9(4), 165. <https://doi.org/10.3390/agronomy9040165>
7. Chen, T.L., Shi, Z.L., Wen, A.B., Yan, D.C., Guo, J., Chen, J.C., & Chen, R.Y. (2021). Multifractal characteristics and spatial variability of soil particle-size distribution in different land use patterns in a small catchment of the Three Gorges Reservoir Region, China. *Journal of Mountain Science*, 18(1), 111-125. <https://doi.org/10.1007/s11629-020-6112-5>
8. Chen, Y., Ma, L., Yu, D., Zhang, H., Feng, K., Wang, X., & Song, J. (2022). Comparison of feature selection methods for mapping soil organic matter in subtropical restored forests. *Ecological Indicators*, 135, 108545. <https://doi.org/10.1016/j.ecolind.2022.108545>
9. Faé, G.S., Montes, F., Bazilevskaya, E., Añó, R.M., & Kemanian, A.R. (2019). Making soil particle size analysis by laser diffraction compatible with standard soil texture determination methods. *Soil Science Society of America Journal*, 83(4), 1244-1252. <http://doi.org/10.2136/sssaj2018.10.0385>
10. Friedman, J.H., & Meulman, J.J. (2003). Multiple additive regression trees with application in epidemiology. *Statistics in Medicine*, 22(9), 1365-1381. <https://doi.org/10.1002/sim.1501>
11. Gessler, P.E., Chadwick, O.A., Chamran, F., Althouse, L., & Holmes, K. (2000). Modeling soil-landscape and ecosystem properties using terrain attributes. *Soil Science Society of America Journal*, 64(6), 2046-2056. <https://doi.org/10.2136/sssaj2000.6462046x>
12. Geology.com/news/2010/freelansatimages-from-USGS-2. <http://glovis.usgs.gov>.
13. 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>
14. Hengl, T., Mendes de Jesus, J., Heuvelink, G.B., Ruiperez Gonzalez, M., Kilibarda, M., Blagotić, A., & Kempen, B. (2017). SoilGrids250m: Global gridded soil information based on machine learning. *PLoS One*, 12(2), e0169748. <https://doi.org/10.1371/journal.pone.0169748>
15. Hossain, M.S., Rahman, G.M., Alam, M.S., Rahman, M.M., Solaiman, A.R.M., & Mia, M.B. (2018). Modelling of soil texture and its verification with related soil properties. *Soil Research*, 56(4), 421-428. <https://doi.org/10.1071/sr17252>
16. Jenny, H. (1994). *Factors of soil formation: a system of quantitative pedology*. Courier Corporation.
17. John, K., Abraham Isong, I., Michael Kebonye, N., Okon Ayito, E., Chapman Agyeman, P., & Marcus Afu, S. (2020). Using machine learning algorithms to estimate soil organic carbon variability with environmental variables and soil nutrient indicators in an alluvial soil. *Land*, 9(12), 487. <https://doi.org/10.3390/land9120487>
18. Kaya, F., & Başaviğit, L. (2022). Spatial prediction and digital mapping of soil texture classes in a Floodplain using multinomial Logistic regression. In *Intelligent and Fuzzy Techniques for Emerging Conditions and Digital Transformation: Proceedings of the INFUS 2021 Conference, held August 24-26, 2021. Volume 2* (pp. 463-473). Springer International Publishing. [https://doi.org/10.1007/978-3-030-85577-2\\_55](https://doi.org/10.1007/978-3-030-85577-2_55).
19. Khosravani, P., Baghernejad, M., Moosavi, A.A., & FallahShamsi, S.R. (2023). Digital mapping to extrapolate the selected soil fertility attributes in calcareous soils of a semiarid region in Iran. *Journal of Soils and Sediments*, 23(11), 4032-4054. <https://doi.org/10.1007/s11368-023-03548-1>
20. Khosravani, P., Baghernejad, M., Moosavi, A.A., & Rezaei, M. (2023). Digital mapping and spatial modeling of some soil physical and mechanical properties in a semi-arid region of Iran. *Environmental Monitoring and Assessment*, 195(11), 1367. <https://doi.org/10.1007/s10661-023-11980-6>
21. Lee, S., Baek, W.K., Jung, H.S., & Lee, S. (2020). Susceptibility mapping on urban landslides using deep learning approaches in Mt. Umyeon. *Applied Sciences*, 10(22), 8189. <https://doi.org/10.3390/app10228189>
22. Loiseau, T., Chen, S., Mulder, V.L., Dobarco, M.R., Richer-de-Forges, A.C., Lehmann, S., ... & Arrouays, D. (2019). Satellite data integration for soil clay content modelling at a national scale. *International Journal of Applied Earth Observation and Geoinformation*, 82, 101905. <https://doi.org/10.1016/j.jag.2019.101905>
23. Lucas, M., Schlüter, S., Vogel, H.J., & Vetterlein, D. (2019). Soil structure formation along an agricultural chronosequence. *Geoderma*, 350, 61-72. <https://doi.org/10.1016/j.geoderma.2019.04.041>
24. Ma, Y., Minasny, B., Malone, B.P., & Mcbratney, A.B. (2019). Pedology and digital soil mapping (DSM). *European Journal of Soil Science*, 70(2), 216-235. <https://doi.org/10.1111/ejss.12790>.
25. Mahler, P.J. (1970). Manual of Multipurpose Land Classification. Report no. 212. *Soil and Water Research Institute*, Tehran. Iran. (In Persian)
26. 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>

27. Maleki, S., Karimi, A., Mousavi, A., Kerry, R., & Taghizadeh-Mehrjardi, R. (2023). Delineation of soil management zone maps at the regional scale using machine learning. *Agronomy*, 13(2), 445. <https://doi.org/10.3390/agronomy13020445>
28. Malone, B., & Searle, R. (2021). Updating the Australian digital soil texture mapping (Part 1\*): re-calibration of field soil texture class centroids and description of a field soil texture conversion algorithm. *Soil Research*, 59(5), 419-434. <https://doi.org/10.1071/SR20283>
29. McBratney, A.B., Santos, M.M., & Minasny, B. (2003). On digital soil mapping. *Geoderma*, 117(1-2), 3-52. [https://doi.org/10.1016/S0016-7061\(03\)00223-4](https://doi.org/10.1016/S0016-7061(03)00223-4)
30. Minasny, B., & McBratney, A.B. (2006). A conditioned Latin hypercube method for sampling in the presence of ancillary information. *Computers & geosciences*, 32(9), 1378-1388. <https://doi.org/10.1016/j.cageo.2005.12.009>
31. Mosleh, Z., Salehi, M. H., Jafari, A., Borujeni, I.E., & Mehnatkesh, A. (2016). The effectiveness of digital soil mapping to predict soil properties over low-relief areas. *Environmental Monitoring and Assessment*, 188, 1-13. <https://doi.org/10.1007/s10661-016-5204-8>
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. <https://doi.org/10.22059/ijswr.2021.323030.668957>
33. Mousavi, S.R., Sarmadian, F., Angelini, M.E., Bogaert, P., & Omid, M. (2023). Cause-effect relationships using structural equation modeling for soil properties in arid and semi-arid regions. *Catena*, 232, 107392. <https://doi.org/10.1016/j.catena.2023.107392>
34. Mousavi, S.R., Parsayi, F., Rahmani, A., Sedri, M.H., & Kohsar Bostani, M. (2020). Spatial prediction some of the surface soil properties using interpolation and machine learning models. *Journal of Soil Management and Sustainable Production*, 10(3), 27-49. (In Persian with English abstract). <https://doi.org/10.22069/EJSMS.2021.17251.1916>
35. Mousavi, S.R., Sarmadian, F., Rahmani, A., & Khamoshi, S.E. (2019). Digital soil mapping with regression tree classification approaches by RS and geomorphometry covariate in the Qazvin Plain, Iran. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 773-777.
36. Ließ, M., Glaser, B., & Huwe, B. (2012). Uncertainty in the spatial prediction of soil texture: comparison of regression tree and Random Forest models. *Geoderma*, 170, 70-79. <https://doi.org/10.1016/j.geoderma.2011.10.010>
37. Organization of Geology and Mineral Explorations of Ira, (1995). Geology map (1:100000) scale. Marvdasht, Fars, Iran.
38. Ostovari, Y., Moosavi, A.A., Mozaffari, H., & Pourghasemi, H.R. (2021). RUSLE model coupled with RS-GIS for soil erosion evaluation compared with T value in Southwest Iran. *Arabian Journal of Geosciences*, 14, 1-15. <https://doi.org/10.1007/s12517-020-06405-4>
39. Olaya, V. I. C. T. O. R. . A gentle introduction to SAGA GIS. The SAGA User Group eV, Gottingen, Germany, 208.
40. Padarian, J., Minasny, B., & McBratney, A.B. (2019). Machine learning and soil sciences: A review aided by machine learning tools. *SOIL*, 6, 35-52. <https://doi.org/10.5194/soil-6-35-2020>.
41. Pahlavan-Rad, M.R., & Akbarimoghaddam, A. (2018). Spatial variability of soil texture fractions and pH in a flood plain (case study from eastern Iran). *Catena*, 160, 275-281. <https://doi.org/10.1016/j.catena.2017.10.002>
42. Paramasivam, C.R. (2019). Merits and demerits of GIS and geostatistical techniques. *GIS and Geostatistical Techniques for Groundwater Science*, 17-21.
43. Poppiel, R.R., Lacerda, M.P., Demattê, J.A., Oliveira Jr, M.P., Gallo, B.C., & Safanelli, J.L. (2019). Pedology and soil class mapping from proximal and remote sensed data. *Geoderma*, 348, 189-206. <https://doi.org/10.1016/j.geoderma.2019.04.028>
44. Parent, E.J., Parent, S.É., & Parent, L.E. (2021). Determining soil particle-size distribution from infrared spectra using machine learning predictions: Methodology and modeling. *Plos One*, 16(7), e0233242. <https://doi.org/10.1371/journal.pone.0233242>
45. Radočaj, D., Jurišić, M., AntoniĆ, O., Šiljeg, A., Cukrov, N., Rapčan, I., Plaščak, I., & Gašparović, M. (2022). A multiscale cost-benefit analysis of digital soil mapping methods for sustainable land management. *Sustainability*, 14(19), 12170. <https://doi.org/10.3390/su141912170>
46. Riza, S., Sekine, M., Kanno, A., Yamamoto, K., Imai, T., & Higuchi, T. (2021). Modeling soil landscapes and soil textures using hyperscale terrain attributes. *Geoderma*, 402, 115177.
47. 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. [https://doi.org/10.1007/978-1-4020-8592-5\\_13](https://doi.org/10.1007/978-1-4020-8592-5_13).
48. Sahraei, N., Landi, A., & Hojati, S. (2022). Digital mapping of soil texture components in part of Khuzestan plain lands using machine learning models. *Iranian Journal of Soil and Water Research*, 53(10), 2261-2276. <https://doi.org/10.22059/ijswr.2022.348442.669360>

49. Shahriari, M., Delbari, M., Afrasiab, P., & Pahlavan-Rad, M.R. (2019). Predicting regional spatial distribution of soil texture in floodplains using remote sensing data: A case of southeastern Iran. *Catena*, 182, 104149. <https://doi.org/10.1016/j.catena.2019.104149>
50. Sahraei, N., Landi, A., & Hojati, S. (2022). Digital mapping of soil texture components in part of Khuzestan plain lands using machine learning models. *Iranian Journal of Soil and Water Research*, 53(10), 2261-2276. (In Persian with English abstract). <https://doi.org/10.22059/ijswr.2022.348442.669360>
51. Sørensen, H. (2004). RPD revisited – a mean to distinguish between poor and good predictions. *Journal of Near Infrared Spectroscopy*, 12(6), 321-327.
52. Swain, S.R., Chakraborty, P., Panigrahi, N., Vasava, H.B., Reddy, N.N., Roy, S., Majeed, I., & Das, B.S. (2021). Estimation of soil texture using Sentinel-2 multispectral imaging data: An ensemble modeling approach. *Soil and Tillage Research*, 213, 105134. <https://doi.org/10.1016/j.still.2021.105134>
53. Taghizadeh-Mehrjardi, R., Toomanian, N., Khavaninzadeh, A. R., Jafari, A., & Triantafyllis, J. (2016). Predicting and mapping of soil particle-size fractions with adaptive neuro-fuzzy inference and ant colony optimization in central Iran. *European Journal of Soil Science*, 67(6), 707-725. <https://doi.org/10.1111/ejss.12382>
54. Tashayo, B., Honarbakhsh, A., Akbari, M. & Eftekhari, M. (2020). Land suitability assessment for maize farming using a GIS-AHP method for a semi-arid region, Iran. *Journal of the Saudi Society of Agricultural Sciences*, 19(5), 332-338. <https://doi.org/10.1016/j.jssas.2020.03.003>
55. Tümsavaş, Z., Tekin, Y., Ulusoy, Y., & Mouazen, A.M. (2019). Prediction and mapping of soil clay and sand contents using visible and near-infrared spectroscopy. *Biosystems Engineering*, 177, 90-100. <https://doi.org/10.1016/j.biosystemseng.2018.06.008>
56. Wadoux, A.M.C., Minasny, B., & McBratney, A.B. (2020). Machine learning for digital soil mapping: Applications, challenges and suggested solutions. *Earth-Science Reviews*, 210, 103359. <https://doi.org/10.1016/j.earscirev.2020.103359>
57. Wallach, D., Makowski, D., Jones, J.W., & Brun, F. (2006). *Working with dynamic crop models: evaluation, analysis, parameterization, and applications*. Elsevier.
58. Wang, Z., Shi, W., Zhou, W., Li, X., & Yue, T. (2020). Comparison of additive and isometric log-ratio transformations combined with machine learning and regression kriging models for mapping soil particle size fractions. *Geoderma*, 365, 114214. <https://doi.org/10.1016/j.geoderma.2020.114214>
59. Wilding, L.P. (1985). *Spatial variability: its documentation, accommodation and implication to soil surveys*. In: *Soil Spatial Variability*, Las Vegas NV, pp. 166–194.
60. Zeraatpisheh, M., Ayoubi, S., Jafari, A., Tajik, S., & Finke, P. (2019). Digital mapping of soil properties using multiple machine learning in a semi-arid region, central Iran. *Geoderma*, 338, 445-452. <https://doi.org/10.1016/j.geoderma.2018.09.006>
61. Ziadat, F.M., 2005. Analyzing digital terrain attributes to predict soil attributes for a relatively large area. *Soil Science Society of America Journal*, 69, 1590–1599. <https://doi.org/10.2136/sssaj2003.0264>
62. Zinck, J.A., Metternicht, G., Bocco, G., & Del Valle, H.F. (2015). *Geopedology: An integration of geomorphology and pedology for soil and landscape studies*. Springer.
63. Zhang, Y.Y., Wu, W., & Liu, H. (2019). Factors affecting variations of soil pH in different horizons in hilly regions. *Plos One*, 14(6), e0218563. <https://doi.org/10.1371/journal.pone.0218563>
64. Zhang, X., Zhang, W.C., Wu, W., & Liu, H.B. (2023). Horizontal and vertical variation of soil clay content and its controlling factors in China. *Science of The Total Environment*, 864, 161141.