



Examining the impact of environmental variable scale on the accuracy of digital mapping of soil properties: A Case Study of Borujerd, Lodestone Province

Ziba Maghsudi¹ | Hamid Reza Matinfar^{1*} | Seyed Roollah Mousavi²

1. Department of Soil Science, Faculty of Agriculture, Lorestan University, Iran.
2. Department of Soil Science, Faculty of Agriculture, University of Tehran, Iran.
E-mail: matinfar.h@lu.ac.ir

Article Info

Article type:

Research Article

Article history:

Received: 07 Dec. 2024

Revised: 11 Feb. 2025

Accepted: 25 Feb. 2025

Published online: 23 Sept. 2025

Keywords:

Soil properties,
Scale,
Environmental variable,
Soil mapping.

Abstract

The scale of environmental variables is one of the most important features to consider when selecting data. Given that the complexity and details of a geographical area play a significant role in the results of soil and land assessment studies, selecting an appropriate spatial scale is crucial due to its important role in feature selection and information generalization. The aim of this study is to improve the accuracy results of digital mapping by selecting the optimal scale for predicting six soil properties, including soil organic carbon (SOC), calcium carbonate equivalent (CCE), pH, sand, silt, and clay in the Silakhor Plain region of Lorestan province. For this purpose, 100 surface soil samples (0-30 cm depth) were collected based on a random sampling pattern. Environmental variables related to topography and remote sensing were extracted from the digital elevation model (DEM) and Landsat-8 satellite. The optimal environmental variables were selected using the recursive feature elimination method in the Silakhor Plain region. Soil property modeling was conducted using machine learning models such as random forest (RF), Support Vector Regression (SVR), Cubist (CB), and hybrid modeling. The modeling results showed that the RF model performed best for predicting CCE, pH, sand, and silt with R^2 values of 0.64, 0.65, 0.59, and 0.70, respectively. Additionally, the SVR model showed the highest accuracy for predicting SOC with an R^2 of 0.62, while the CB model had the highest accuracy for predicting clay with an R^2 of 0.66. The most suitable cell sizes for CCE, pH, sand, and silt were identified as 30*30 m, for SOC as 60*60m, and for clay as 90*90m. The most important environmental variables for SOC, pH, silt, sand, and clay were valley depth, differential vegetation index, and modified vegetation index, respectively. Overall, the results indicated that in the study areas, the use of intermediate scales (cell sizes of 30 to 90 m) led to higher accuracy in predicting soil properties. This is because using larger cell sizes introduces noise that hinders accuracy. Therefore, the selection of resolution or, in other words, cell size in DSM studies can help define patterns or homogeneous management zones in soil resource management.

Cite this article: Maghsudi, Z., Matinfar, H.R., Mousavi, S.R. (2025). Examining the impact of environmental variable scale on the accuracy of digital mapping of soil properties: A case study of Borujerd, Lodestone Province. *Journal of Range & Watershed Management*, 78 (3), 299-322. DOI: <http://doi.org/10.22059/jrwm.2025.386586.1792>



بررسی اثر قدرت تفکیک مکانی متغیرهای محیطی بر دقت نقشه برداری رقومی ویژگی های خاک (مطالعه موردی: دشت سیلاخور، استان لرستان)

زیبا مقصودی^۱ | حمید رضا متین فر^{۱*} | سید روح اله موسوی^۲

۱. گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه لرستان، خرم آباد، ایران.

رایانامه: matinfar.h@lu.ac.ir

۲. گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه تهران کرج، ایران.

اطلاعات مقاله

چکیده

نوع مقاله:

مقاله پژوهشی

تاریخ دریافت: ۱۴۰۳/۰۹/۱۷

تاریخ بازنگری: ۱۴۰۳/۱۱/۲۳

تاریخ پذیرش: ۱۴۰۳/۱۲/۰۷

تاریخ انتشار: ۱۴۰۴/۰۷/۰۱

کلیدواژه‌ها:

خصوصیات خاک،

مقیاس،

متغیر محیطی،

نقشه برداری خاک.

مقیاس متغیرهای محیطی یکی از مهمترین ویژگی‌هایی است که هنگام انتخاب داده برای نقشه برداری رقومی خاک باید در نظر گرفته شود. با توجه به اینکه پیچیدگی و جزئیات یک ناحیه جغرافیایی نقش مهمی در نتایج مطالعات ارزیابی خاک و سرزمین دارد، انتخاب از مقیاس مکانی مناسب به دلیل نقش مهمی که در انتخاب ویژگی و تعمیم اطلاعات دارد، بسیار حائز اهمیت می‌باشد. هدف از این مطالعه بهبود صحت نتایج نقشه برداری رقومی از طریق انتخاب مقیاس بهینه برای پیش‌بینی شش ویژگی خاک شامل کربن آلی خاک، کربنات کلسیم معادل، pH، شن، سیلت و رس در دشت سیلاخور استان لرستان است. برای این منظور تعداد ۱۰۰ نمونه خاک سطحی (۰-۳۰ سانتی‌متری) بر اساس الگوی نمونه برداری تصادفی در محدوده ای به مساحت ۴۲۰۰۰ هکتار در سال ۱۳۹۸ برداشت گردید. متغیرهای محیطی توپوگرافی و سنجش از دور از مدل رقومی ارتفاع و ماهواره لندست ۸ استخراج شدند. سپس متغیرهای محیطی بهینه توسط روش حذف ویژگی برگشتی انتخاب گردیدند. مدل سازی ویژگی های خاک توسط مدل های یادگیری ماشین جنگل تصادفی، رگرسیون بردار پشتیبان، کوبیست و مدل سازی ترکیبی اجرا شدند. نتایج مدل سازی نشان داد، مدل جنگل تصادفی برای پیش‌بینی کربنات کلسیم معادل، pH، شن و سیلت با مقادیر R^2 به ترتیب برابر با ۰/۶۴، ۰/۶۵، ۰/۵۹ و ۰/۷۰ بهترین عملکرد را داشت. همچنین مدل رگرسیون بردار پشتیبان با $R^2 = ۰/۶۲$ برای پیش‌بینی کربن آلی خاک و مدل کوبیست با $R^2 = ۰/۶۶$ برای پیش‌بینی رس بیشترین دقت را نشان دادند. مناسب ترین اندازه سلول برای کربنات کلسیم معادل، pH، شن و سیلت ۳۰×۳۰ متر، برای کربن آلی خاک ۶۰×۶۰ متر و برای رس ۹۰×۹۰ متر شناخته شد. همچنین مهم ترین متغیرهای پیش‌بینی کننده برای ویژگی های کربن آلی خاک، pH، سیلت، شن و رس خاک به ترتیب عمق دره، شاخص تفاضلی پوشش گیاهی، شاخص پوشش گیاهی تعدیل شده بودند. به طور کلی نتایج نشان داد که در منطقه مطالعاتی استفاده از مقیاس های میانی (اندازه های مختلف سلول سلول ۳۰×۳۰ متر تا ۹۰×۹۰ متر) منجر به پیش‌بینی ویژگی های خاک با دقت بالاتر شد. بنابراین، انتخاب وضوح و یا به عبارتی اندازه سلول در مطالعات نقشه برداری رقومی خاک می تواند به تعریف الگوها یا پهنه های مدیریتی همگن در مدیریت منابع خاک کمک نماید.

استناد: مقصودی، زیبا، متین فر؛ حمیدرضا، موسوی؛ سید روح اله (۱۴۰۴). بررسی اثر قدرت تفکیک مکانی متغیرهای محیطی بر دقت نقشه برداری رقومی ویژگی های خاک (مطالعه موردی: دشت سیلاخور، استان لرستان). نشریه مرتع و آبخیزداری، ۷۸ (۳)، ۳۲۲-۲۹۹.

DOI: <http://doi.org/10.22059/jrwm.2025.386586.1792>



© نویسندگان.

ناشر: انتشارات دانشگاه تهران.

۱. مقدمه

امروزه تقاضا برای نقشه‌برداری و به‌روز رسانی اطلاعات خاک با هدف حمایت از تصمیمات و برنامه‌ریزی‌های انجام شده در سطوح مختلف مدیریت اراضی برای مقابله با چالش‌های موجود بخش کشاورزی و منابع طبیعی در مقیاس‌های جهانی و منطقه‌ای، در حال افزایش است (چن^۱ و همکاران، ۲۰۲۲). یکی از مواردی که امروزه خاکشناسان با آن روبرو هستند، رویکردهای مرسوم^۲ (یا به عبارتی سنتی) تهیه نقشه‌های خاک است که بدلیل اتکا به دانش و سطح آگاهی کارشناس خاکشناسی و همچنین فعالیتی زمان‌بر و پرهزینه بودن (لی^۳ و همکاران، ۲۰۲۱) دارای نواقص جدی در موضوع بروزرسانی است. علاوه بر این، روش‌های مرسوم نقشه‌برداری، اطلاعات قابل اندازه‌گیری از خاک که تغییرات پیوسته و واقعی خاک‌ها را توصیف می‌کند ارائه نمی‌دهد (یان^۴ و همکاران، ۲۰۲۲). همچنین برای افراد غیر خاک‌شناس، تفسیر و استفاده از این نقشه‌ها برای اتخاذ تصمیم‌گیری‌های مدیریتی فرآیندی دشوار است (چابریلات^۵ و همکاران، ۲۰۱۹). زیرا این نقشه‌ها عمدتاً مبتنی بر طبقه‌بندی می‌باشند. این درحالی است که نقشه‌های دقیق از ویژگی‌های خاک برای ارزیابی جنبه‌های متعدد مدیریت تولید محصولات در اراضی کشاورزی، از جمله پتانسیل تولید خاک^۶، برآورد نیاز آبی گیاهان، فرسایش خاک و ذخایر کربن ضروری است. چنین نقشه‌های دقیق خاک می‌تواند به اطلاع رسانی در مورد راه حل‌های سیاست حفاظت مناسب از منابع آب و خاک در سطح دولتی یا در بخش‌های خصوصی کمک کند (موسوی و همکاران، ۲۰۲۳).

مک‌برتنی^۷ و همکاران (۲۰۰۳) نخستین بار رویکرد نقشه‌برداری رقومی خاک^۸ (DSM) را برای پیش‌بینی ویژگی‌های خاک با استفاده از متغیرهای کمکی، ارائه نمودند. امروزه با افزایش دسترسی به سیستم‌های اطلاعات جغرافیایی^۹ (GIS)، سیستم‌های موقعیت‌یاب جهانی^{۱۰} (GPS)، داده‌های طیفی سنجش از دور^{۱۱} (RS)، داده‌های توپوگرافی مشتق‌شده از مدل‌های رقومی ارتفاع^{۱۲} (DEMs)، مدل‌های پیش‌بینی کننده یا استنتاجی و توسعه‌ی دانش نرم‌افزاری برای تجزیه و تحلیل داده‌ها، علم نقشه‌برداری خاک را تا حد زیادی ارتقاء یافته است (ماتیللا^{۱۳} و همکاران، ۲۰۲۲). با این حال، تمایز مهم بین DSM و نقشه‌برداری مرسوم خاک این است که در DSM از مدل‌های استنتاج کمی برای تولید پیش‌بینی کلاس‌ها یا ویژگی‌های خاک در یک پایگاه داده جغرافیایی (شبکه مبنا) استفاده می‌شود. مدل‌های مبتنی بر داده‌کاوی^{۱۴}، تجزیه و تحلیل آماری و یادگیری ماشینی^{۱۵} (ML)، مقادیر زیادی از داده‌های مکانی را در خوشه‌های معنی‌دار برای تشخیص الگوهای مکانی در سطح زمین‌نما سازمان‌دهی می‌کنند (ویلدینگ^{۱۶}، ۱۹۸۵).

طی سال‌های اخیر تکنیک‌های ML برای بررسی تغییرات مکانی ویژگی‌های خاک (چن و همکاران، ۲۰۲۲؛ ژئو^{۱۷} و همکاران، ۲۰۱۹؛ دی سولا^{۱۸} و همکاران، ۲۰۲۰؛ امیریان چکان و همکاران، ۲۰۱۷) به شدت مورد توجه قرار گرفته است. خالدیان^{۱۹} و میلر (۲۰۲۰) به بررسی نقاط ضعف و قوت مدل‌های ML پرداختند. نتایج ایشان نشان داد که مدل شبکه عصبی مصنوعی^{۲۰} (ANN) به تعداد نقاط مشاهداتی حساس است. اما این مدل نتایج خوبی برای پیش‌بینی الگوهای غیر خطی ارائه می‌دهد. مدل جنگل تصادفی^{۲۱} (RF) و کوویست^{۲۲} (CB) هر دو نتایج بهتری نسبت به مدل ANN دارند. ولی مدل RF سریعتر است و مدل CB به اطلاعات مستقیم^{۲۳} برای پیش‌بینی نیاز دارد. RF پرکاربردترین

¹ Chen

² Conventional methods

³ Li

⁴ Yuan

⁵ Chabrilat

⁶ Soil potential productivity

⁷ McBratney

⁸ Digital Soil Mapping

⁹ Geographical information system

¹⁰ Global positioning systems

¹¹ Remote Sensing

¹² Digital elevation models

¹³ Mattila

¹⁴ Data Mining

¹⁵ Machine Learning

¹⁶ Wilding

¹⁷ Guo

¹⁸ de Sousa

¹⁹ Khaledian

²⁰ Artificial Neural Network

²¹ Random Forest

²² Cubist

²³ Direct Information

مدل در پیش‌بینی ویژگی‌های خاک است. زیرا قادر به مدل‌سازی روابط غیر خطی در داده‌های با ابعاد بالا^۱ است. همچنین امکان اولویت‌بندی متغیرهای کمکی را نیز ارائه می‌نماید (پهلوان راد و اکبری مقدم، ۲۰۱۸)، (پائول^۲ و همکاران، ۲۰۲۰)، (سو^۳ و همکاران، ۲۰۲۴). مطالعات مختلفی قابلیت‌های مدل RF را نسبت به سایر مدل‌ها برای پیش‌بینی ویژگی‌های خاک بیان کرده است. پارسایی و همکاران (۲۰۲۱) نشان دادند که مدل RF نسبت به دو مدل درخت تصمیم^۴ (DT) و CB منجر به ریشه میانگین مربعات خطا^۵ کمتر به ترتیب برابر با ۰/۰۳۲، ۰/۰۳۵ و ۰/۰۴۳ (درصد) برای پیش‌بینی نیتروژن خاک شد. موسوی و همکاران (۲۰۲۲) از مدل RF و پنج مدل دیگر ML در دشت قزوین برای پیش‌بینی کربن آلی خاک^۶ (SOC) با کاربری‌های زراعت آبی، دیم، مراتع شور و غیر شور استفاده کردند. نتایج ایشان حاکی از کارایی بالاتر مدل RF برای پیش‌بینی SOC خاک در کاربری‌های مختلف پیش‌بینی کرد. در مطالعه محمودزاده و همکاران (۲۰۲۰) نیز مدل RF نسبت به مدل‌های نزدیک‌ترین همسایه^۷ (k-NN) و افزایش گرادیان^۸ (EGB) و ماشین بردار پشتیبانی^۹ (SVM) با $R^2=0.6$ و $RMSE=35\%$ برای پیش‌بینی SOC در کاربری‌های جنگل، چمنزار، زراعی و مرتع بهتر عمل کرد. اساس DSM بر پایه‌ی مقیاس می‌باشد. با این وجود به دلیل پیچیدگی‌های زیادی که تاکنون در جنبه‌های مختلف فرآیند نقشه‌برداری وجود داشته است، چندان مورد توجه قرار نگرفته است و در شرایط فعلی نیاز است تا بصورت عمیق‌تر مورد توجه قرار گیرند (مالون^{۱۰} و همکاران، ۲۰۱۷).

عمده مطالعات نقشه‌برداری رقومی تاکنون در پیش‌بینی ویژگی‌ها یا کلاس‌های خاک متمرکز بر روی کیفیت پیش‌بینی یا تعیین فاکتورهای مؤثر بر این تغییرپذیری بوده و در کمتر مطالعه‌ای به بررسی مقیاس متغیرهای کمکی در پیش‌بینی ویژگی‌های خاک پرداخته شده است (اسماعیل‌پور، ۲۰۲۴؛ موسوی و همکاران، ۲۰۲۲؛ کاسا^{۱۱} و همکاران، ۲۰۲۰). بنابراین از دیدگاه مدیریتی و کاربردی این مورد ضروری است تا به این جنبه از علم پدومتری با جزئیات بیشتر پرداخته شود (ماچاریا^{۱۲} و همکاران، ۲۰۲۲). موفقیت DSM به طور قابل توجهی به کیفیت متغیرهای کمکی ورودی بستگی دارد (زراعت پیشه و همکاران، ۲۰۲۲) و در مواقعی اغلب بر انتخاب الگوریتم مدل‌سازی اولویت دارد (کسکین و گرانوالد^{۱۳}، ۲۰۱۸). یک شاخص مهم برای کیفیت این متغیرهای محیطی ورودی، مقیاس آنها است. در DSM، متغیرهای کمکی به صورت شبکه‌ای نشان داده می‌شوند و وضوح آنها اغلب بر اساس اندازه‌ی سلول‌های DEM تعیین می‌شود. به عبارت دیگر، مقیاس، اندازه سلول یک نقشه رستری را توصیف می‌کند که سلول‌های بزرگ و کوچک به ترتیب به عنوان وضوح درشت-کم و وضوح خوب-بالا شناخته می‌شوند (فارینا^{۱۴}، ۲۰۲۲). با افزایش در دسترس بودن DEM‌ها در مقیاس‌های مختلف، تأثیر وضوح DEM بر مدل‌سازی محیطی به طور گسترده‌ای مورد بحث قرار گرفته است (دورنیک^{۱۵} و همکاران، ۲۰۲۲). بسیاری از مطالعات اهمیت تحلیل چند مقیاسی متغیرهای زمین‌نما در DSM را برجسته کرده‌اند (بهرنس^{۱۶} و همکاران، ۲۰۱۸)، (کاوازی^{۱۷} و همکاران، ۲۰۱۳). بهرنس و همکاران (۲۰۱۰)، مطالعه‌ای تحت عنوان تجزیه و تحلیل مقیاس‌های چندگانه زمین و انتخاب ویژگی برای DSM انجام دادند. رویکرد تحلیل رقومی در مقیاس‌های چندگانه بر اساس اندازه پنجره‌های با اندازه ۳×۳ تا ۳۱×۳۱ بود. ایشان از یک DEM با وضوح مکانی ۲۰×۲۰ متر نیز برای مطالعه استفاده نمودند. نتایج پیش‌بینی بر اساس یک درخت طبقه بندی رقومی نشان داد، الگوی پراکنش مکانی کلاس‌های خاک در مقیاس‌های مشخص با توجه به ویژگی‌های خاص زمین‌نما متفاوت است. همچنین نتایج نشان داد که برخی از کلاس‌های خاک در یک مقیاس نسبت به مقیاس‌های دیگر قابلیت شناسایی بیشتری دارند و به برخی ویژگی‌های زمین‌نما نسبت به سایر مقیاس‌ها مرتبط‌تر می‌باشند. در نهایت این گونه نتیجه‌گیری شد که رویکردهای مقیاس چندگانه و همچنین انتخاب ویژگی‌های مورد

¹ High dimensional data

² Paul

³ Su

⁴ Decision Tree

⁵ Root mean square error

⁶ Soil organi carbon

⁷ K- Nearest neighbor

⁸ Extreme Gradient Boosting

⁹ Support vector machine

¹⁰ Malone

¹¹ Casa

¹² Macharia

¹³ Keskin & Grunwald

¹⁴ Farina

¹⁵ Dornik

¹⁶ Behrens

¹⁷ Cavazzi

استفاده، نیازمند تحقیقات بیشتری هستند تا تکنیک‌های نقشه برداری رقومی خاک در زمینه‌های مورد نیاز اعمال شود و دقت پیش‌بینی بهتری حاصل گردد. کاوازی و همکاران (۲۰۱۳)، در پژوهش خود در خصوص ارزیابی وضوح مکانی مناسب در نقشه برداری رقومی خاک گزارش نمودند که در مناطق با تنوع توپوگرافی، عمدتاً متغیرهای محیطی با اندازه‌های سلولی بسیار ریز (30×30 متر)، در مناطق هموار و همگن اندازه‌های سلولی خیلی درشت (بیش از 140×140 متر) و در مناطق با فیزیوگرافی مختلط (ترکیب مناطق مسطح و ناهموار) مقادیر حد واسطه (40×40 تا 120×120 متر) مقیاس در DSM مناسب می‌باشد. تقی‌زاده مهرجردی و نبی‌الهی در (۲۰۱۶)، مطالعه‌ای از اندازه‌های پنجره 3×3 ، 5×5 ، 7×7 ، 9×9 ، 11×11 ، 13×13 ، 15×15 ، 17×17 ، 19×19 و 21×21 اندازه سلول مختلف 10×10 ، 20×20 ، 30×30 ، 40×40 ، 50×50 ، 70×70 ، 90×90 ، 100×100 ، 150×150 ، 200×200 ، 250×250 متر برای پیش‌بینی رس خاک با استفاده از مدل رگرسیون درختی در دو منطقه میبد و یاسوکند استفاده کردند. نتایج حاکی از آن بود که منطقه میبد دارای حداقل RMSE و حداکثر R^2 (به ترتیب ۹ و ۰/۴۷) برای اندازه سلولی 150×150 متر و ابعاد پنجره 7×7 بود. در حالیکه در منطقه یاسوکند با تغییرات توپوگرافی بیشتر کمترین RMSE و بیشترین R^2 (به ترتیب $5/65$ و $0/7$) برای اندازه سلولی ۱۰ متر و اندازه پنجره 21×21 به دست آمد. همچنین خسروانی و همکاران (۲۰۲۴) از سناریوهای مختلف مقیاس متغیرهای محیطی در اندازه‌های سلولی 30×30 ، 60×60 ، 90×90 تا 2100×2100 متر برای پیش‌بینی چهارویژگی ماده آلی خاک، جرم مخصوص ظاهری، مقاومت برشی و میانگین وزنی قطر خاکدانه در استان فارس استفاده نمودند، و نتایج ایشان نشان داد که به‌ترتیب بهینه‌ترین اندازه مقیاس برای این ویژگی‌ها 1200×1200 ، 180×180 ، 1200×1200 و 2100×2100 متر بود. تعیین وضوح مکانی بهینه برای متغیرهای کمکی برای دستیابی به نقشه برداری دقیق خاک بسیار مهم است. علاوه بر این، منبع داده‌های DEM نقش مهمی در تعیین کیفیت و خطاهای بالقوه در مورد اثرگذاری ویژگی‌های زمین نما بازی می‌کند که مستقیماً بر دقت مدل‌های ML تأثیر می‌گذارد (ماچاریا و همکاران، ۲۰۲۲).

مقیاس مفهوم پیچیده‌ای است که با معانی مختلف و اغلب متفاوت قابل درک است و به شدت به زمینه مطالعه بستگی دارد (آدنیی^۱ و همکاران، ۲۰۲۴). در این تحقیق مقیاس به عنوان بعد فیزیکی یک پدیده یا فرآیند در مکان در نظر گرفته می‌شود که بر حسب واحدهای مکانی اندازه سلولی بیان می‌شود، که در نقشه برداری رقومی خاک تعیین بهینه اندازه سلول در انتخاب فاکتورهای محیطی برای استفاده در نقشه برداری یا پیش‌بینی مکانی ویژگی‌های خاک همچنان نیازمند بررسی بیشتر می‌باشد. بنابراین مطالعه حاضر با اهداف (۱) ارزیابی نقش مقیاس متغیرهای محیطی (30×30 ، 60×60 ، 90×90 ، 150×150 ، 250×250 متر) در دقت پیش‌بینی نقشه‌های ویژگی‌های خاک (مورد نظر، ۲) تعیین مهمترین متغیرهای محیطی در پیش‌بینی شش ویژگی کلیدی خاک (SOC, CCE, pH, Sand, Silt, Clay) و (۳) ارزیابی کارایی سه مدل یادگیری ماشین (RF, CB, SVR) در تهیه نقشه‌ی ویژگی‌های خاک در سناریوهای مختلف مقیاس در بخشی اراضی منطقه بروجرد استان لرستان می‌باشد. به طور کلی از نتایج این تحقیق و خروجی به دست آمده، انتظار می‌رود که با استفاده از انتخاب مناسب متغیرهای محیطی و تعیین مقیاس بهینه آنها، یک مدل منطقه‌ای برای استفاده محققین و کارشناسان فعال در بخش مطالعات تهیه نقشه‌های مدیریت پذیر خاک در عرصه‌های کشاورزی و منابع طبیعی منجر گردد.


۲. مواد و روش‌ها

۲-۱. منطقه مورد مطالعه

منطقه مورد مطالعه در غرب ایران در استان لرستان (شکل ۱) حد فاصل طول جغرافیایی $46^{\circ}12'$ و $57^{\circ}43'$ و عرض جغرافیایی $32^{\circ}31'$ و $32^{\circ}38'$ متر و منطقه 39 شمالی در دشت سیلاخور (شکل ۱) واقع شده است. متوسط تغییرات ارتفاع 1453 تا 2188 متر از سطح دریا می‌باشد. از نظر فیزیوگرافی خاک‌های منطقه مورد مطالعه بر روی تیپ‌های اراضی دشت‌های دامنه‌ای، تپه‌ها و تراس‌های

¹ Adeniyi

فوقانی پراکنش یافته‌اند. رژیم رطوبتی و حرارتی خاک‌های منطقه به ترتیب زیریک^۱ و ترمیک^۲ است. رده‌بندی خاک‌ها براساس سامانه رده‌بندی آمریکایی (هیأت خاک‌شناسی ایالت متحده^۳، ۲۰۲۲) در دو رده اینسپتی سولز^۴ و انتی‌سولز^۵ قرار دارند. کاربری غالب اراضی منطقه شامل زراعت آبی و دیم محصولات زراعی یکساله گندم، جو و کلزا می‌باشد.



شکل ۱. موقعیت استان لرستان بر روی نقشه ایران، موقعیت منطقه مورد مطالعه بر روی نقشه استان لرستان، موقعیت نقاط نمونه‌برداری

۲-۲. نمونه‌برداری و تهیه متغیرهای محیطی

عملیات میدانی و نمونه‌برداری از خاک‌ها شامل انتخاب ۱۰۰ موقعیت نمونه خاک سطحی (۰-۳۰ سانتی‌متر) با میانگین فاصله ۱۰۰۰ متر در بخشی از اراضی زراعی دشت سیلاخور با مساحت ۴۲۰۰۰ هکتار و براساس الگوی نمونه‌برداری تصادفی و نظر کارشناس انجام گرفت. نمونه‌ها پس از برداشت ابتدا هوا خشک شده و سپس از الک دو میلی‌متری عبور داده شدند. در این مطالعه به ترتیب درصد اجزاء بافت خاک (Silt، Sand، Clay) به روش هیدرومتری (گی^۶ و همکاران، ۱۹۸۶)، کربنات کلسیم معادل (CCE) به روش تیتراسیون برگشتی (نلسون و لی^۷، ۱۹۸۶)، واکنش خاک (pH) در عصاره گل اشباع (مک لین^۸، ۱۹۸۲) و مقدار کربن آلی خاک (SOC) به روش اکسیداسیون تر (جکسون^۹، ۱۹۶۹) اندازه‌گیری شدند.

برای مدل‌سازی نقشه ویژگی‌های خاک منطقه از متغیرهای توپوگرافی و داده‌های RS مستخرج از مدل رقومی ارتفاع و همچنین تصاویر ماهواره لندست ۸ با وضوح مکانی ۳۰×۳۰ متر استفاده گردید. همچنین پیش از تهیه شاخص‌های توپوگرافی، برای شناسایی اثرات مصنوعی در DEM از توابع پرکردن-فرورفتگی^{۱۰} موجود در نرم افزار SAGA GIS نسخه ۴/۷ برای تصحیح خطاهای موجود در مدل رقومی ارتفاع

¹ Xeric

² Thermic

³ Soil Survey Staff

⁴ Inceptisols

⁵ Entisols

⁶ Gee

⁷ Nelson & Lee

⁸ McLean

⁹ Jackson

¹⁰ Fill- Sink

شامل پرکردن فرورفتگی‌ها و حفظ شیب نزولی در طول مسیر جریان استفاده شد (وانگ و هانگزینگ^۱، ۲۰۰۶). همچنین شاخص‌های RS حاصل از نسبت‌گیری باندی پس از اعمال تصحیحات رادیومتری لازم در محیط نرم افزار ERDAS IMAGINE 2014 تهیه شدند. برخی از متغیرهای توپوگرافی که توصیف‌کننده خصوصیات توپوگرافی و هیدرولوژی منطقه می‌باشند در جدول ۱ ارائه شده است.

جدول ۱. متغیرهای ژئومورفومتری استخراج شده از مدل رقومی ارتفاع

نام متغیر	اسم کامل و نماد	نام متغیر	اسم کامل و نماد
تحلیل سایه روشن تپه‌ای	Analytical hillshading (AH)	شاخص همواری کف دره با درجه تفکیک بالا	Multi-Resolution Valley Bottom Flatness (MrVBF)
جهت شیب	Aspect	ارتفاع نرمال شده	Normalized Height (NH)
شیب حوزه آبریز	Catchment Slop (CS)	موقعیت شیب نسبی	Relative Slope Position (RSP)
سطح پایه شبکه کانال	Channel Network Base Level (CNBL)	ارتفاع شیب	Slope Height (SH)
شاخص همگرایی	Convergence Index (CI)	شیب	Slope
تحدب	Convexity	ارتفاع استاندارد شده	Standard Height (SH)
تابش پخشیده	Diffuse Insolation (DI)	شاخص زبری سطح	Topographic Ruggedness Index (TRI)
تابش مستقیم	Direct Radiation (DR)	شاخص موقعیت توپوگرافی	Topographic Position Index (TPI)
جریان تجمعی	Flow Accumulation (FA)	شاخص خبسی توپوگرافی	Topographic Wetness Index (TWI)
فاکتور طول در درجه شیب	Slope Length and Steepness factor (LS-Factor)	فاصله افقی تا شبکه آبراهه	VDCN
موقعیت میانی شیب	Midslope position (MSP)	عمق دره	Valley Depth (VD)
حوزه آبریز اصلاح شده	Modified Catchment area (MCA)	شاخص اثر باد	Wind Effect (WEF)
شاخص هموری قله با درجه تفکیک بالا	Multi-resolution Ridge Top Flatness (MrRTF)	جهت باد	Wind Exposure (WEP)

شاخص‌های تسلدکپ و شاخص‌های پوشش گیاهی نیز از جمله شاخص‌های RS استخراج شده از تصاویر ماهواره‌ای، دیگر متغیرهای کمکی RS بودند. این تصاویر از طریق سامانه USGS و با درصد پوشش ابری کمتر از ۱۰ درصد از ماهواره لندست ۸ دانلود گردید. در جدول ۲ شاخص‌های RS تهیه شده ارائه گردیده است.

۲-۳. روند نمای کلی پژوهش

مراحل انجام تحقیق حاضر در هفت گام مطابق با شکل ۲ انجام شده است. هشت گام اجرا شده به شرح زیر می‌باشد ۱. نمونه‌برداری از مناطق مورد مطالعه و اندازه‌گیری ویژگی‌های خاک مورد نظر. ۲. تهیه متغیرهای محیطی توپوگرافی و RS ۳. تهیه متغیرهای محیطی در اندازه‌های سلول ۳۰×۳۰، ۶۰×۶۰، ۹۰×۹۰، ۱۵۰×۱۵۰ و ۲۵۰×۲۵۰ متر. ۴. انتخاب متغیرهای محیطی بهینه ۵. مدل‌سازی ویژگی‌های خاک ۶. تهیه نقشه پیش‌بینی ویژگی‌های خاک مورد نظر و ۷. تعیین اهمیت نسبی متغیرهای محیطی کمکی.


۲-۴. مدل سازی مکانی

برای پیش‌بینی مکانی ویژگی‌های خاک شامل Sand، Silt، Clay، pH، CCE و SOC از سه مدل یادگیری ماشین جنگل تصادفی (RF)، کوپست (CB)، رگرسیون بردار پشتیبان (SVR) و رویکرد مدلسازی ترکیبی (رگرسیون - کریجینگ) استفاده شد. به طور کلی مجموعه داده‌ها به صورت تصادفی ۸۰ درصد برای آموزش و ۲۰ درصد برای اعتبار سنجی استفاده شد. برای این منظور از بسته تخصصی "Caret" و "randomForest" و "svmRadial" در محیط نرم افزار R نسخه 4.2.1 استفاده شد.

¹ Wang & Hongxing

جدول ۲. متغیرهای RS استخراج شده از ماهواره لندست

علامت اختصاری	نام شاخص	فرمول ریاضی
Brightness	روشنایی	$0.3037(\text{Band}1)+0.2792(\text{Band}2)+0.4743(\text{Band}3)+0.5585(\text{Band}4)+0.5082(\text{Band}5)+0.1863(\text{Band}7)-0.2848(\text{Band}1-0.2435(\text{Band}2-0.5436(\text{Band}3)+0.7243(\text{Band}4-0.0840(\text{Band}5-0.1800(\text{Band}7)+0.1509(\text{Band}1)+0.1973(\text{Band}2)+0.3279(\text{Band}3)+0.3406(\text{Band}4)+0.7112(\text{Band}5)+0.4572(\text{Band}7)$
Greenness	سبزیگی	
Wetness	خیسی	
DVI	شاخص تفاضلی پوشش گیاهی	$\frac{\text{NIR}-\text{RED}}{\text{NIR}+\text{RED}}$
EVI	شاخص پوشش گیاهی توسعه یافته	$\frac{2.5 \times (\text{NIR} - \text{RED})}{(\text{NIR} + 6\text{RED} - 7.5 * B + 1)}$
NDVI	شاخص تفاضلی پوشش گیاهی نرمال شده	$\frac{\text{NIR} - \text{RED}}{\text{NIR} + \text{RED}}$
NRVI	شاخص نسبتی پوشش گیاهی نرمال شده	$\frac{\text{RVI}-1}{\text{RVI}+1}$
PVI	شاخص عمودی پوشش گیاهی	$\frac{(\text{NIR}-a \cdot b)}{\sqrt{a^2+1}}$
CTVI	شاخص پوشش گیاهی تبدیل شده اصلاح شده	$\frac{\text{NDVI} + 0.5}{\text{NDVI} + 0.5} \sqrt{[(\text{NDVI}) + 0.5]}$
RVI	شاخص پوشش گیاهی نسبی	$\frac{\text{NIR}}{\text{RED}}$
SAVI	شاخص پوشش گیاهی تعدیل کننده اثر خاک	$\frac{(\text{NIR} - \text{RED})}{(\text{NIR} + \text{RED} + L) * (1 + L)}$
TTVI	شاخص پوشش گیاهی تغییر شکل یافته تیام	$\sqrt{\frac{\text{abs}(\text{NIR} - \text{RED})}{(\text{NIR} + \text{RED}) + 0.5}}$
TVI	شاخص پوشش گیاهی تبدیل شده	$\sqrt{\frac{\text{NIR}-R}{\text{NIR}+R}} + 0.5$
TSAVI	شاخص پوشش گیاهی تبدیل یافته و تعدیل کننده اثر خاک	$(s(\text{NIR}-s*\text{Red}-a))/(a*\text{NIR}+\text{Red}-a*s+X*(1+s2))$



شکل ۳. روند نمای تحقیق

۲-۴-۱. جنگل تصادفی

مدل جنگل تصادفی (RF) یک تکنیک یادگیرنده فعال است که توسط بریمن (بریمن^۱، ۲۰۰۱) ارائه شده است. مدل RF توسعه یافته از مدل طبقه‌بندی و رگرسیون درختی است که داده‌ها را به‌طور تکراری برای به‌دست آوردن ارتباط بین متغیر پاسخ و متغیرهای مستقل و انجام تخمین جداسازی می‌کند. این الگوریتم یادگیری گروهی به‌طور تصادفی گروهی از مشاهدات را از مجموعه داده آموزشی (بوت استرپینگ) انتخاب کرده و یک درخت تصمیم مرتبط با مشاهدات انتخاب شده ایجاد می‌کند (چوتیا^۲ و همکاران، ۲۰۱۷). این فرآیند برای ساخت چندین درخت تصمیم تکرار می‌شود. RF درخت‌های تصمیم را برای تولید پیش‌بینی خطا با استفاده از استراتژی خارج از کیسه (OOB) فراهم می‌کند. OOB هر درخت را با استفاده از مجموعه‌های نمونه راه انداز مختلف می‌سازد که در آن دو سوم مشاهدات برای آموزش استفاده می‌شود. بقیه مشاهدات برای آزمایش خطای مدل کنار گذاشته می‌شوند. RF ترتیب چیدمان با جایگشت متغیرهای کمکی را به‌طور تصادفی تغییر می‌دهد و همه احتمالات را برای انتخاب متغیرهای کمکی در نمونه‌های OOB در نظر می‌گیرد. پیش‌بینی‌ها بر اساس میانگین نتایج حاصل از هزاران درخت تصمیم‌گیری انجام می‌شود. مهمترین پارامترهای تنظیمی برای این الگوریتم تعداد درختانی (ntree) است که باید رشد کنند، تعداد متغیرهای کمکی به‌طور تصادفی در هر گره انتخاب شده و حداقل تعداد برگ‌های (mtry) نمونه برای ثبت نویز در داده‌های آموزشی (خالدیان و برادلی^۴، ۲۰۲۰).

۲-۴-۲. رگرسیون بردار پشتیبان

رگرسیون بردار پشتیبان (SVR) یک تکنیک یادگیری نظارت شده است که توسط دراکر (دراکر^۵ و همکاران، ۱۹۹۶) از الگوریتم ماشین بردار پشتیبان (SVM) که برای مسائل طبقه‌بندی استفاده می‌شد، برای موارد رگرسیون گسترش یافت. از آنجایی که فضای اصلی را به یک فضای ویژگی با ابعاد بالا ترسیم می‌کند، به عنوان ماشین یادگیری دو لایه (لایه ورودی و لایه فضای ویژگی با ابعاد بالا) در نظر گرفته می‌شود.

۲-۴-۳. کوپست

کوپست (CB) یک روش درخت تصمیم است که از مدل درختی M5 ایجاد شده است. CB به عنوان یک الگوریتم ML برای پیش‌بینی متغیر هدف مورد استفاده قرار می‌گیرد و از نظر روش اجرا و عملکرد شبیه به درختان رگرسیون است (بریمن، ۲۰۰۱). با این حال، برخلاف مدل‌های درخت تصمیم رگرسیونی یا طبقه‌بندی، اغلب از مدل‌های خطی برای برازش داده‌های در سیستم درختی بهره می‌گیرد. علاوه بر این، مدل درختی کوپست و رگرسیون درختی تفاوت آشکاری با یکدیگر دارند. به‌طور کلی، مدل CB معادلات رگرسیونی چند متغیرهای را می‌سازد که در فرآیند تخمین بر اساس قوانین "اگر" یا "آنگاه" عمل می‌کنند (خالدیان و میلر^۶، ۲۰۲۰).

۲-۵. مدل ترکیبی

هدف مدل‌های ترکیبی، بهینه‌سازی پیش‌بینی ویژگی‌های خاک در مناطقی است که نمونه‌گیری انجام نشده است. فرض اصلی این مدل‌ها این است که متغیر هدف مورد نظر با مدل رگرسیون محاسبه می‌شود. سپس تغییرات مکانی باقی مانده‌های مدل، با مولفه‌های وابسته نشان داده می‌شوند. رگرسیون کریجینگ نیز حاصل یک مدل زمین آماری و رگرسیونی است که ابتدا از رگرسیون متغیرهای کمکی توسط مدل‌های ML و سپس از روش‌های زمین آمار (مانند کریجینگ ساده و معمولی) برای درون‌یابی باقیمانده رگرسیون

¹ Beriman

² Chutia

³ Out-of-bag

⁴ Khaledian & Bradley

⁵ Drucker

⁶ Khaledian and Mill

استفاده می‌کند. در کریجینگ معمولی (OK) یک مدل نیمه متغیر^۱ برای تعریف وزن تابع و یک نیمه تغییرنا برای تعریف همبستگی خودکار، به عنوان ابزار اصلی برای ارزیابی ساختار توزیع مکانی ویژگی‌های خاک استفاده می‌شود (کینگزلی^۲ و همکاران، ۲۰۱۹) مطابق با رابطه زیر (رابطه ۱) نیم تغییرنمای تجربی تغییرات مکانی داده‌ها و تغییرات تصادفی آنها را توصیف می‌کند:

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^n \sum [Z(X_i) - Z(X_i + h)]^2 \quad (\text{رابطه ۱})$$

در اینجا: $\gamma(h)$ نیمه تغییرنا، h فاصله تاخیر^۳، Z پارامتر ویژگی خاک، $N(h)$ تعداد جفت مکان‌هایی که توسط فاصله تاخیر جدا شده‌اند، $Z(x_i)$ و $Z(x_i + h)$ مقادیر Z در موقعیت‌های x_i و $x_i + h$ می‌باشند (لیانگهنگ^۴ و همکاران، ۲۰۱۸).

۲-۶. انتخاب متغیرهای محیطی

انتخاب ویژگی، یک رویکرد ارزشمند برای شناسایی عوامل محیطی مهم موثر بر ویژگی‌های خاک است. حذف ویژگی بازگشتی^۵ (RFE) به عنوان یک روش انتخاب ویژگی نظارت شده، برای شناسایی مهم‌ترین ویژگی‌ها در یک مجموعه داده استفاده می‌شود. RFE از یک مدل RF استفاده می‌کند که در ابتدا بر روی مجموعه کاملی از ویژگی‌ها آموزش دیده است (کوهن و جانسون^۶، ۲۰۱۳). متعاقباً، به صورت بازگشتی ویژگی‌های با اهمیت حداقل را حذف می‌کند تا زمانی که به تعداد مطلوبی از ویژگی‌ها برسد. اهمیت ویژگی با ارزیابی کاهش عملکرد مدل هنگام حذف یک ویژگی تعیین می‌شود. این روند تا رسیدن به تعداد مورد نظر از ویژگی‌ها یا تا زمانی که عملکرد مدل با حذف بیشتر بهبود پیدا نکند ادامه می‌یابد. RFE می‌تواند ابزار قدرتمندی برای کاهش ابعاد مجموعه داده‌های با ابعاد بالا، افزایش قابلیت تفسیر و بهبود عملکرد تعمیم مدل‌های یادگیری ماشینی باشد (موسوی و همکاران، ۲۰۲۲).

۲-۷. بررسی اثر اندازه سلولی (قدرت تفکیک مکانی)

در این مطالعه پس از انتخاب متغیرهای محیطی که نسبت به مجموعه اصلی بیشترین اهمیت را داشتند، کلیه متغیرهای توپوگرافی و RS استخراج شده با وضوح مکانی پایه ۳۰×۳۰ متر با استفاده از تابع باز نمونه‌گیری^۷ و روش درون‌یابی خطی در محیط نرم‌افزار ArcGIS به اندازه‌های سلولی ۶۰×۶۰ متر، ۹۰×۹۰ متر، ۱۵۰×۱۵۰ متر و ۲۵۰×۲۵۰ متر تبدیل شده و سپس پیش‌بینی مکانی ویژگی‌های خاک توسط مدل‌های یادگیری ماشینی با هدف یافتن مناسبترین اندازه سلولی انجام گردید.

۲-۸. ارزیابی کارایی مدل‌های یادگیری ماشین

فرایند اعتبارسنجی مدل‌های تولید شده با استفاده از ۲۰ درصد 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^۸ (R^2)، میانگین ریشه خطای مربع^۹ (RMSE) و میانگین خطای مطلق^{۱۰} (MAE) و ضریب همبستگی تطابق^{۱۱} (CCC) برآورد شد. رتبه‌بندی مقادیر ضریب تبیین «رابطه ۲» 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 ($R^2 < 0.4$)، (راسل و همکاران^{۱۲}، ۲۰۰۹). RMSE یک معیار پرکاربرد برای تخمین تفاوت بین مقادیر پیش‌بینی شده توسط یک

¹ Semi variogram

² Kingsley

³ Lag distance

⁴ Lianheng

⁵ Recursive feature elimination

⁶ Kuhn & Johnson

⁷ Resampling

⁸ Coefficient Determination

⁹ Root Mean Square Error

¹⁰ Mean Absolute Error

¹¹ Concordance correlation coefficient

¹² Rossel

مدل و مقادیر اندازه‌گیری شده است. همچنین RMSE مقیاسی از اندازه خطا را برآورد می‌کند که به مقادیر پرت حساس است و توسط رابطه ۳ محاسبه می‌شود.

$$R2 = \frac{\sum_{i=1}^n (X_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad \text{رابطه ۲}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2} \quad \text{رابطه ۳}$$

«رابطه ۴» نحوه محاسبه MAE را نشان می‌دهد.

$$MAE = \frac{\sum_{i=1}^n |X_i - Y_i|}{n} \quad \text{رابطه ۴}$$

محاسبه CCC نیز مطابق با «رابطه ۵» می‌باشد:

$$CCC = \frac{2r\sigma_X\sigma_Y}{\sigma_X^2 + \sigma_Y^2 + (\bar{X} - \bar{Y})^2} \quad \text{رابطه ۵}$$

در روابط بالا X_i داده‌های اندازه‌گیری شده و Y داده‌های پیش‌بینی شده، $\bar{X}$ میانگین داده‌های پیش‌بینی شده و $\bar{Y}$ میانگین داده‌های پیش‌بینی شده، r ضریب همبستگی، σ_X انحراف معیار داده‌های اندازه‌گیری شده و σ_Y انحراف معیار داده‌های پیش‌بینی شده و n تعداد داده‌ها است.

۳. یافته‌های پژوهش

۳-۱. خلاصه آماری ویژگی‌های خاک

نتایج خلاصه آماری ویژگی‌های اندازه‌گیری شده خاک در (جدول ۳) ارائه شده است. میانگین اجزاء بافت خاک شامل Silt، Clay و Sand به ترتیب برابر با ۱۸/۵۴، ۲۹/۷۸ و ۱۵/۷۷ است، بطوریکه کلاس بافت غالب خاک منطقه لومی می‌باشد. کمترین و بیشترین مقدار CCE به ترتیب ۷/۵ تا ۳۸ درصد اندازه‌گیری شد. همچنین مقادیر pH از ۷/۶۲ تا ۸/۳۳ (قلیایی خفیف تا نسبتاً قلیایی) متغیر بود. مقدار میانگین pH (۷/۹۷) نشان می‌دهد که خاک منطقه بروجرد نسبتاً قلیایی است. با توجه به میانگین مقدار SOC (۱/۴۵) در خاک‌های دشت سیلاخور در کلاس محتوای متوسط قرار دارد (چارمن و روپر^۱، ۲۰۰۷). کمترین و بیشترین مقدار SOC به ترتیب ۰/۲۷ و ۲/۱۸ درصد اندازه‌گیری شد. با توجه به مقادیر درصد ضریب تغییرات (CV%)، به ترتیب برای Silt، Clay، Sand، CCE و SOC به ترتیب برابر با ۲۲/۶۱، ۲۳/۶۶،

¹ Charman & Roper

۲۱/۸۴، ۲۸/۰۵ و ۲۲/۱۵ است. بنابراین ویژگی‌ها خاک به جز pH در دشت سیلاخور دارای تغییرپذیری متوسط می‌باشند و pH با CV برابر با ۱/۷ دارای تغییرپذیری کم است (ویلدینگ، ۱۹۸۵).

جدول ۳. خلاصه آماری ویژگی‌های اندازه‌گیری شده خاک دشت سیلاخور

ویژگی‌ها	واحد	کمترین	بیشترین	میانگین	SD	CV%
رس (Clay)	%	۳/۰۴	۵۱/۳۶	۱۸/۵۴	۱۱/۳۵	۲۲/۶۱
سیلت (Silt)	%	۱۱/۲۲	۵۱/۶۴	۲۹/۷۸	۷/۰۵	۲۳/۶۶
شن (Sand)	%	۱۵/۷۸	۷۴/۱۴	۱۵/۷۷	۱۱/۳۱	۲۱/۸۴
کربنات کلسیم معادل (CCE)	%	۷/۵	۳۸	۱۲/۱۲	۵/۹۲	۲۸/۰۵
کربن آلی خاک (SOC)	%	۰/۲۷	۲/۱۸	۱/۴۵	۰/۳۲	۲۲/۱۵
اسیدیته (PH)	-	۷/۶۲	۸/۳۳	۷/۹۷	۰/۱۴	۱/۷۰

۲-۳. انتخاب متغیرهای محیطی کمکی

انتخاب متغیرهای محیطی در این منطقه با استفاده از دور ویکرد ترکیبی حذف ویژگی برگشتی (RFE) و نظرکارشناس صورت گرفت. نتایج انتخاب متغیرهای محیطی نشان داد، ۱۲ متغیر از مجموع ۴۴ متغیر اولیه (توپوگرافی و RS) استخراج و برای پیش‌بینی ویژگی‌های خاک انتخاب شدند. متغیرهای انتخاب شده شامل متغیرهای توپوگرافی از جمله سطح پایه شبکه آبراهه، تحدب شیب، شدت تابش پخشیده، شاخص همواری کف دره با درجه تفکیک بالا، موقعیت نسبی شیب، شاخص خیزی توپوگرافی، بافت، عمق دره و شاخص اثر باد و متغیرهای RS شاخص عمودی پوشش گیاهی (PVI) ^۱ و شاخص پوشش گیاهی تعدیل شده خاک (SAVI) ^۲ و شاخص پوشش گیاهی تعدیل شده خاک تغییر یافته (TSAVI) ^۳ است (جدول ۴). همچنین پراکنش مکانی متغیرهای محیطی مورد استفاده برای پیش‌بینی توزیع مکانی ویژگی‌های خاک مورد نظر در دشت سیلاخور در شکل ۴ نشان داده شده است.


جدول ۴. متغیرهای محیطی منتخب برای مدل‌سازی ویژگی‌های خاک در دشت سیلاخور

متغیرهای محیطی	نام متغیر	ماهیت متغیر	نماد
Channel Network Base Level	سطح پایه شبکه کانال	توپوگرافی	CNBL
Convexity	تحدب	توپوگرافی	Convexity
Diffuse Insolation	تابش پخشیده	توپوگرافی	DI
Multi-Resolution Valley Bottom Flatness	شاخص همواری کف دره با درجه تفکیک بالا	توپوگرافی	MrVBF
Perpendicular Vegetation Index	شاخص عمودی پوشش گیاهی	سنجش از دور	PVI
	موقعیت شیب نسبی	توپوگرافی	RSP
Soil Adjusted Vegetation Index	شاخص پوشش گیاهی تعدیل شده خاک	سنجش از دور	SAVI
SAGA Wetness Index	شاخص خیزی ساگا	توپوگرافی	SWI
Terrain SurfaceTexture	بافت	توپوگرافی	Texture
Transformed Soil Adjusted Vegetation Index	شاخص پوشش گیاهی تعدیل شده خاک تغییر یافته		TSAVI
Valley Depth	عمق دره	توپوگرافی	VD
Wind Effect	شاخص اثر باد	توپوگرافی	WEF

^۱ Perpendicular Vegetation Index

^۲ Soil Adjusted Vegetation Index

^۳ Transformed Soil Adjusted Vegetation Index



شکل ۴. پراکنش مکانی متغیرهای کمکی الف: سطح پایه شبکه آبراهه، ب: تحدب شیب، پ: شدت تابش پخشیده، ت: شاخص همواری دره با درجه تفکیک بالا، ث: شاخص عمودی پوشش گیاهی، ج: موقعیت نسبی شیب، چ: شاخص پوشش گیاهی تعدیل شده خاک، ح: شاخص خیزی ساگا، خ: بافت سطح زمین، د: شاخص پوشش گیاهی تعدیل شده خاک تغییر یافته، ذ: عمق دره، ر: شاخص اثر باد

۳-۳. ارزیابی مدل‌سازی ویژگی‌های خاک در اندازه‌های سلولی مختلف

نتایج ارزیابی صحت مدل RF برای پیش‌بینی ویژگی‌های SOC، CCE، pH، Sand، Silt و Clay در پنج اندازه سلول ۳۰×۳۰، ۶۰×۶۰، ۹۰×۹۰، ۱۵۰×۱۵۰ و ۲۵۰×۲۵۰ متر در جدول ۵ نشان داده شده است. براساس داده‌های اعتبار سنجی مدل RF، تغییرات صحت پیش‌بینی ویژگی‌های خاک برای اندازه‌های سلولی مختلف از یک روند ثابت پیروی نمی‌کند. به طوریکه بیشترین صحت پیش‌بینی SOC در اندازه سلول ۶۰×۶۰ متر (R^2 و RMSE به ترتیب ۰/۵۷ و ۰/۲۹) و کمترین صحت پیش‌بینی در اندازه سلول ۹۰×۹۰ متر (R^2 و RMSE به ترتیب ۰/۴۹ و ۰/۲۹) محاسبه شد. اندازه سلول ۳۰×۳۰ متر بهینه‌ترین مقدار برای پیش‌بینی CCE توسط مدل RF شناخته شد به طوریکه R^2 و RMSE به ترتیب برابر با ۰/۶۴ و ۴/۸۸ به دست آمد. R^2 محاسبه شده برای پیش‌بینی CCE در سایر اندازه‌های سلولی بین ۰/۵۳ تا ۰/۶۲ متغیر است. همچنین متغیرهای کمکی با اندازه سلول ۳۰×۳۰ متر منجر به تهیه نقشه pH، Sand و Silt خاک دشت سیلاخور با بالاترین صحت نیز شد. R^2 محاسبه شده برای pH، Sand و Silt در اندازه سلول ۳۰×۳۰ متر به ترتیب ۰/۶۵، ۰/۵۹ و ۰/۷ محاسبه شد. پیش‌بینی Clay توسط مدل RF در دشت سیلاخور در اندازه سلول ۲۵۰×۲۵۰ متر منجر به تهیه نقشه با بیشترین R^2 برابر با ۰/۶۱ شد. با توجه به مطالعات راسل و همکاران (۲۰۰۹) صحت پیش‌بینی CCE، pH و Silt در اندازه سلول ۳۰×۳۰ متر توسط مدل RF خوب (۰/۶۱ تا ۰/۸۱) و برای Sand متوسط (۰/۴۱ تا ۰/۶۱) است.

جدول ۵. نتایج اعتبار سنجی پیش‌بینی ویژگی‌های خاک در اندازه‌های سلولی مختلف توسط مدل RF

pH				CCE				SOC				اندازه سلول
MAE	CCC	RMSE	R ²	MAE	CCC	RMSE	R ²	MAE	CCC	RMSE	R ²	
۰/۱	۰/۷۲	۰/۱۲	۰/۶۵	۴/۲	۰/۶۶	۴/۸۸	۰/۶۴	۰/۲۴	۰/۵۸	۰/۲۹	۰/۵۳	۳۰×۳۰
۰/۱	۰/۶۶	۰/۱۲	۰/۶	۳/۹۹	۰/۶۷	۴/۵۹	۰/۶۲	۰/۲۴	۰/۶۵	۰/۲۹	۰/۵۷	۶۰×۶۰
۰/۱	۰/۶۷	۰/۱۲	۰/۶۱	۳/۹۷	۰/۵۸	۴/۷۵	۰/۵۳	۰/۲۴	۰/۵۸	۰/۲۹	۰/۴۹	۹۰×۹۰
۰/۱	۰/۷	۰/۱۲	۰/۶۴	۴/۲۳	۰/۵۹	۵/۱۱	۰/۵۵	۰/۲۵	۰/۵۵	۰/۳	۰/۵۲	۱۵۰×۱۵۰
۰/۱	۰/۵۴	۰/۱۲	۰/۴۸	۳/۸۷	۰/۶۳	۴/۷۳	۰/۵۶	۰/۲۶	۰/۶۵	۰/۳۲	۰/۴۶	۲۵۰×۲۵۰
Clay				Silt				Sand				اندازه سلول
MAE	CCC	RMSE	R ²	MAE	CCC	RMSE	R ²	MAE	CCC	RMSE	R ²	
۸/۳	۰/۶۲	۹/۴۶	۰/۵۸	۵/۷۹	۰/۷۳	۷/۱	۰/۷۰	۸/۳۳	۰/۶۷	۹/۹	۰/۵۹	۳۰×۳۰
۸/۳۳	۰/۶۲	۹/۴۵	۰/۵۸	۵/۶۱	۰/۵۹	۶/۹۱	۰/۵۴	۸/۹	۰/۶۳	۱۰/۰۷	۰/۵۷	۶۰×۶۰
۷/۸۷	۰/۶۶	۹/۱۷	۰/۵۹	۵/۱۳	۰/۶۳	۶/۱۷	۰/۵۸	۸/۶	۰/۵۵	۹/۷۸	۰/۴۷	۹۰×۹۰
۸/۹۵	۰/۶۳	۱۰/۱۷	۰/۵۶	۵/۲۴	۰/۶۱	۶/۳۴	۰/۵۶	۹/۰۶	۰/۵۸	۱۰/۲۵	۰/۵۳	۱۵۰×۱۵۰
۷/۹۳	۰/۶۵	۹/۰۸	۰/۶۱	۵/۲۹	۰/۶۶	۶/۳	۰/۶	۸/۳۷	۰/۵۷	۹/۳۴	۰/۵۵	۲۵۰×۲۵۰

نتایج ارزیابی صحت مدل‌سازی ویژگی‌های خاک توسط مدل SVR در جدول ۶ ارائه شده است. پیش‌بینی مکانی SOC و pH توسط مدل SVR در اندازه سلولی ۶۰×۶۰ متر بیشترین صحت را دارا می‌باشند. R² محاسبه شده برای SOC برابر با ۰/۶۲ و RMSE برابر با ۰/۲۸ است. بنابراین عملکرد مدل SVR برای پیش‌بینی SOC خوب (راسل و همکاران، ۲۰۰۹) و همچنین بیشتر از مدل RF است. همچنین عملکرد مدل SVR در اندازه سلول ۳۰×۳۰ متر برای پیش‌بینی CCE، ۹۰×۹۰ متر برای پیش‌بینی Sand و Clay و ۱۵۰×۱۵۰ متر برای پیش‌بینی Silt نسبت به سایر اندازه‌های سلول مورد استفاده بیشتر است.

جدول ۶. نتایج اعتبار سنجی پیش‌بینی ویژگی‌های خاک در اندازه‌های سلولی مختلف توسط مدل SVR

PH				CCE				SOC				اندازه سلول
MAE	CCC	RMSE	R ²	MAE	CCC	RMSE	R ²	MAE	CCC	RMSE	R ²	
۰/۱	۰/۵۹	۰/۱۲	۰/۵۵	۴/۴۱	۰/۶۶	۵/۲۱	۰/۶۱	۰/۲۵	۰/۵۵	۰/۲۹	۰/۴۸	۳۰×۳۰
۰/۱	۰/۶	۰/۱۲	۰/۵۶	۳/۷۸	۰/۶	۴/۴۲	۰/۵۵	۰/۲۴	۰/۶۷	۰/۲۸	۰/۶۲	۶۰×۶۰
۰/۱	۰/۵۶	۰/۱۲	۰/۵	۳/۸۱	۰/۶۲	۴/۵۷	۰/۵۶	۰/۲۵	۰/۵۴	۰/۲۹	۰/۴۹	۹۰×۹۰
۰/۰۹	۰/۵۸	۰/۱۲	۰/۵۲	۴/۱۵	۰/۶۵	۴/۹۷	۰/۵۸	۰/۲۵	۰/۵۷	۰/۲۹	۰/۵۲	۱۵۰×۱۵۰
۰/۱	۰/۵۴	۰/۱۲	۰/۴۷	۴/۱۵	۰/۴۹	۴/۹۵	۰/۴۴	۰/۲۴	۰/۲۴	۰/۲۹	۰/۴۶	۲۵۰×۲۵۰
Clay				Silt				Sand				اندازه سلول
MAE	CCC	RMSE	R ²	MAE	CCC	RMSE	R ²	MAE	CCC	RMSE	R ²	
۹/۳۲	۰/۵۷	۱۰/۹۵	۰/۵۳	۵/۱۴	۰/۴۵	۶/۲۳	۰/۴	۸/۹۸	۰/۵۸	۱۰/۶۶	۰/۵۴	۳۰×۳۰
۸/۲۴	۰/۶۱	۹/۷۷	۰/۵۶	۵/۴۷	۰/۴۶	۶/۶۶	۰/۴۱	۸/۲۷	۰/۶	۱۰/۲۲	۰/۵۵	۶۰×۶۰
۷/۷۵	۰/۶۸	۹/۳۷	۰/۶۲	۵/۲۳	۰/۵۴	۶/۳۱	۰/۵۱	۸/۶۵	۰/۶۴	۹/۴۶	۰/۵۸	۹۰×۹۰
۹/۰۱	۰/۵۹	۱۰/۶	۰/۵۴	۵/۳	۰/۶۱	۶/۲۹	۰/۵۶	۹/۰۵	۰/۴۹	۱۰/۵۴	۰/۴۵	۱۵۰×۱۵۰
۸/۵۱	۰/۶۱	۱۰	۰/۵۶	۵/۲۷	۰/۴۹	۶/۲۲	۰/۴۴	۸/۵۶	۰/۶	۹/۹۷	۰/۵۵	۲۵۰×۲۵۰

نتایج اعتبار سنجی پیش‌بینی ویژگی‌های خاک توسط مدل CB در جدول ۷ نشان داده شده است. پیش‌بینی‌های انجام شده توسط مدل CB در منطقه بروجرد برای تمام ویژگی‌ها به جز Clay و در تمام اندازه‌های سلولی متوسط (۰/۴۱ تا ۰/۶۱) است. با اینحال بهترین پیش‌بینی برای Clay در دشت سیلاخور توسط مدل CB و در اندازه سلول ۹۰×۹۰ متر با R² برابر با ۰/۶۶ و RMSE برابر با ۹/۷۱ انجام شد.

جدول ۷. نتایج اعتبار سنجی پیش‌بینی ویژگی‌های خاک در اندازه‌های سلولی مختلف توسط مدل CB

pH				CCE				SOC				اندازه سلول
MAE	CCC	RMSE	R2	MAE	CCC	RMSE	R2	MAE	CCC	RMSE	R2	
۰/۱۱	۰/۵۷	۰/۱۳	۰/۵۴	۳/۷۹	۰/۶۷	۴/۴۲	۰/۶۳	۰/۲۵	۰/۵۷	۰/۳	۰/۵۳	۳۰×۳۰
۰/۱۱	۰/۵۷	۰/۱۳	۰/۵۳	۳/۶۸	۰/۶۵	۴/۴۵	۰/۶۲	۰/۲۶	۰/۶۴	۰/۳۲	۰/۶	۶۰×۶۰
۰/۱	۰/۴۹	۰/۱۲	۰/۴۴	۳/۷۹	۰/۶۴	۴/۴۹	۰/۵۸	۰/۲۴	۰/۵۳	۰/۲۹	۰/۴۸	۹۰×۹۰
۰/۱۱	۰/۶۲	۰/۱۳	۰/۵۹	۴/۶۳	۰/۵۴	۵/۵۷	۰/۵۱	۰/۲۶	۰/۵۲	۰/۳۱	۰/۴۶	۱۵۰×۱۵۰
۰/۱۱	۰/۵۲	۰/۱۳	۰/۴۶	۳/۹۶	۰/۵۹	۴/۸۲	۰/۵۴	۰/۲۵	۰/۴۸	۰/۳	۰/۴۵	۲۵۰×۲۵۰
Clay				Silt				Sand				اندازه سلول
MAE	CCC	RMSE	R2	MAE	CCC	RMSE	R2	MAE	CCC	RMSE	R2	
۸/۴۹	۰/۵۹	۹/۶۶	۰/۵۶	۵/۱۹	۰/۵۲	۰/۷۲	۰/۴۸	۹/۳۳	۰/۵۵	۱۱/۱۱	۰/۵۲	۳۰×۳۰
۸/۷۸	۰/۶۵	۱۰/۳۲	۰/۶۰	۷/۳۷	۰/۵۲	۷/۱۵	۰/۴۷	۸/۸	۰/۶	۱۰/۱۲	۰/۵۵	۶۰×۶۰
۷/۸۸	۰/۷۳	۹/۷۱	۰/۶۶	۵/۲۸	۰/۵	۶/۳	۰/۴۵	۸/۹۶	۰/۵۷	۱۰/۴۵	۰/۵	۹۰×۹۰
۹/۳۷	۰/۵۷	۱۱/۰۷	۰/۵۱	۵/۶۶	۰/۵۲	۶/۶۴	۰/۴۷	۹/۲	۰/۵۶	۱۰/۵۹	۰/۵۱	۱۵۰×۱۵۰
۸/۱۶	۰/۶۱	۹/۷	۰/۵۶	۵/۹۳	۰/۶۱	۷/۰۶	۰/۵۶	۸/۹۲	۰/۵۴	۱۰/۰۹	۰/۵	۲۵۰×۲۵۰

۳-۴. ارزیابی مدل‌سازی ویژگی‌های خاک با مدل‌های ترکیبی

نتایج اعتبار سنجی مدل‌های ترکیبی در جدول ۸ نشان داده شده است. استفاده از مدل ترکیبی RF-OK منجر به تهیه نقشه‌های با R^2 برابر با ۰/۷۳، ۰/۶۹، ۰/۶۹ و ۰/۷ به ترتیب برای pH، CCE، Sand و Silt با اندازه سلولی ۳۰×۳۰ متر شد. همچنین مدل SVR-OK منجر به تهیه نقشه SOC با R^2 برابر با ۰/۶۶ با اندازه سلولی ۶۰×۶۰ متر شد. از طرفی برای Clay نیز با اندازه سلولی ۹۰×۹۰ متر با استفاده از مدل CB-OK با صحت ۰/۷۲ پیش‌بینی شد. به طور کلی استفاده از مدل‌سازی ترکیبی با انتخاب بهترین اندازه سلولی منجر به افزایش ۴، ۱۶، ۹، ۱۰ و ۷ درصدی در صحت پیش‌بینی SOC، CCE، pH، Sand، Clay و Silt شد.

جدول ۸. نتایج اعتبار سنجی پیش‌بینی ویژگی‌های خاک دشت سیلاخور توسط مدل ترکیبی در بهترین اندازه‌های سلولی

MAE	CCC	RMSE	R ²	ویژگی	اندازه سلولی	مدل
۰/۰۲	۰/۶۵	۰/۲	۰/۶	SOC	۶۰×۶۰	SVR-OK
۲/۵	۰/۷۸	۳/۰۹	۰/۷۳	CCE	۳۰×۳۰	RF-Ok
۲/۴۵	۰/۷۵	۴/۵۷	۰/۶۹	pH	۳۰×۳۰	RF-Ok
۵/۹۱	۰/۷۵	۷/۳۹	۰/۶۹	Sand	۳۰×۳۰	RF-Ok
۲/۴۲	۰/۷۸	۴/۴۹	۰/۷	Silt	۳۰×۳۰	RF-Ok
۵/۹۹	۰/۵۷	۷/۴۸	۰/۷۲	Clay	۹۰×۹۰	CB-OK


نسبت واریانس قطعه‌ای به آستانه برای توصیف درجه همبستگی مکانی بقایای مدل‌سازی مکانی ویژگی‌های خاک استفاده شد (جدول ۹). نسبت واریانس قطعه‌ای به آستانه نشان داد که بقایای مدل RF برای پیش‌بینی CCE دارای همبستگی مکانی زیاد (کمتر از ۰/۲۵) و برای pH، Sand و Silt دارای همبستگی مکانی متوسط می‌باشد. همچنین بقایای مدل SVR برای پیش‌بینی SOC دارای همبستگی مکانی متوسط بوده و بقایای مدل CB برای پیش‌بینی مکانی Caly دارای همبستگی مکانی قوی است. قوی بودن کلاس همبستگی مکانی برای ویژگی‌های CCE و Clay بیانگر این است که مقدار قلیل توجهی از واریانس تغییرات این ویژگی‌ها توسط مدل‌های یادگیری ماشین توجیه نشده بوده است که خوشبختانه مدل کریجینگ معمولی تا حد زیادی آنها را برازش داده است (متین فر و همکاران، ۲۰۲۱).

جدول ۹. پارامتر برازش داده شده برای مدل واریوگرام نمائی برآورد شده از پیش‌بینی مدل کریجینگ


مدل ترکیبی	ویژگی	دامنه تاثیر (متر)	واریانس قطعه‌ای	آستانه	واریانس قطعه‌ای / آستانه	همبستگی مکانی
SVR-OK	SOC	۱۹۰	۰/۰۸۵۵	۰/۱۴۴۷	۰/۵۹	متوسط
RF-OK	CCE	۳۶۹۶/۶	۱/۵۲۲۳	۱۱/۲۴۶	۰/۱۳	قوی
RF-OK	pH	۱۴۹۱/۱	۰/۰۰۵۶	۰/۰۱۲۱	۰/۴۶	متوسط
RF-OK	شن	۶۷۵۰/۲	۱۵/۳۹۵	۳۶/۲۱۴	۰/۴۲	متوسط
RF-OK	سیلت	۱۸۲	۸/۵۲۲	۲۳/۵۰۸	۰/۳۶	متوسط
CB-OK	رس	۵۴۹۷/۳	۷/۳۴۲	۵۶/۸۴۴	۰/۱۲	قوی

۳-۵. اهمیت متغیرهای محیطی

اهمیت نسبی متغیرهای محیطی در پیش‌بینی ویژگی‌های خاک در دشت سیلاخور در شکل ۵ نشان داده شده است. متغیرهای توپوگرافی VD، MrVBF و RSP به ترتیب با ۲۴/۳۸، ۱۷/۵۷ و ۱۶/۵، سپس متغیر وابسته به RS از قبیل SAVI با اهمیت نسبی ۱۰ درصد مهمترین متغیرهای پیش‌بینی کننده SOC می‌باشند. اگرچه متغیر DI با ۱۷/۹۷ درصد مهمترین پیش‌بینی کننده CCE است، اما متغیرهای RS شامل SAVI، PVI و TSAVI با مجموع ۴۰ درصد نقش مهمی در پیش‌بینی CCE در دشت سیلاخور دارند. همچنین PVI و TSAVI مهمترین متغیرها برای پیش‌بینی pH و اندازه ذرات خاک (Clay و Silt، Sand) نیز شناخته شدند. PVI به ترتیب با ۳۰/۱۴ و ۳۲/۶ درصد به عنوان مهمترین پیش‌بینی کننده pH و Silt و همچنین TSAVI به ترتیب با ۱۶/۲ و ۱۴/۴۵ درصد مهمترین پیش‌بینی کننده Sand و Clay شناخته شدند. VD و SAVI با ۱۷/۸ و ۱۶/۲۳ درصد اهمیت از دیگر متغیرهای موثر بر پیش‌بینی pH می‌باشند. WEF و PVI نیز با مجموع ۲۸/۶ درصد، بر پیش‌بینی Sand موثر می‌باشند بنابراین در مجموع نتایج بیانگر اهمیت بیشتر متغیرهای RS در پیش‌بینی ویژگی‌های خاک بود.



شکل ۵. اهمیت نسبی متغیرهای محیطی برای پیش‌بینی الف: SOC، ب: CCE، ج: pH، د: Sand، ه: Silt، ی: Clay در دشت سیلاخور



ادامه شکل ۵.


۳-۶. پهنه بندی مکانی ویژگی‌های خاک منطقه مورد مطالعه

پهنه‌بندی مکانی ویژگی‌های خاک پیش‌بینی شده توسط مدل‌های ML منفرد و ترکیبی در شکل ۶ ارائه شده است. با توجه به (شکل ۶ الف) SOC پیش‌بینی شده توسط مدل ترکیبی SVR-OK از ۰/۹۸ تا ۲/۰۳ متغیر است. مدل SVR این مقدار را بین ۱/۳۳ تا ۱/۶۸ پیش‌بینی کرده است. بیشترین مقادیر SOC در بخش‌های شرقی منطقه مشاهده گردید، درحالی‌که کمترین مقدار آن در نواحی غربی می‌باشد. کمترین و بیشترین مقدار CCE برابر با ۸/۸ تا ۳۶/۹۷ درصد توسط مدل RF-OK پیش‌بینی شد. همچنین بیشترین مقادیر CCE در بخش غربی منطقه تجمع یافته است و نوار شرقی با توجه به SOC بیشتر و CCE کمتر (شکل ۶ ب) از حاصلخیزی بیشتری برخوردار است. این در حالی است که در بخش‌های مرکزی منطقه مورد مطالعه خاک‌ها دارای مقادیر pH بالاتری می‌باشند. به‌طوریکه بیشترین مقدار pH با مقادیر برابر با ۸/۱۵ در نواحی مرکزی و جنوب غربی منطقه تا و کمترین مقدار آن برابر ۷/۷۱ در بخش‌های جنوب شرقی منطقه متغیر است (شکل ۶ ج).

بیشترین مقادیر تجمع Sand در منطقه مورد مطالعه در قسمت شمال غربی و جنوب می‌باشد، در حالی‌که کمترین میزان آن در مرکز و شرق است. بیشترین مقدار شن برابر با ۷۴/۲۸ و کمترین میزان آن ۲۶/۲۷ درصد محاسبه شد (شکل ۶ د). همچنین تغییرات سیلت در منطقه مورد نظر یکنواخت‌تر بوده و تنها در بخش‌هایی شرق منطقه میزان آن به حداکثر (۴۵/۵ درصد) می‌رسد (شکل ۶ ه). برخلاف تغییرات Sand، Clay در قسمت‌های شمال غربی و جنوب از میزان کمتری برخوردار است (۰/۳۶ درصد) و مقادیر آن در مرکز و شرق منطقه مورد مطالعه بیشتر (۴۹/۶۵ درصد) است (شکل ۶ ی).


۴. بحث و نتیجه‌گیری

بخش‌های غالب منطقه مطالعاتی بویژه در مناطق مرکزی بطور عمده تحت کاربری زراعت آبی قرار دارند. بر اساس نتایج مدلسازی مقادیر اندازه سلولی کوچکتر (۳۰×۳۰ و ۶۰×۶۰) در مناطق با تنوع توپوگرافی کم منجر به پیش‌بینی ویژگی‌های خاک با صحت بیشتر شده است. مطالعات مختلفی در مورد تاثیر اندازه سلول بر عملکرد مدل‌های یادگیری ماشین انجام شده است که نشان می‌دهد استفاده از مقیاس‌های میانی دقت پیش‌بینی را بهبود می‌بخشد. به عنوان مثال، بهرنس و همکاران (۲۰۱۸) به این نتیجه رسیدند که مقیاس‌های میانی (۲۰×۲۰ - ۹۰×۹۰ متر) ممکن است با مقیاس‌های فرآیندهای پدوژنتیکی مهم انطباق بیشتری داشته باشند و دقت پیش‌بینی را بهبود بخشند.



شکل ۶. پهنه‌بندی مکانی ویژگی‌های خاک

شامل الف: SOC، ب: CCE، ج: pH، د: شن، ه: سیلت، ی: رس در دشت سیلاخور توسط مدل منفرد و ترکیبی



ادامه شکل ۶.

در همین راستا، بهرنس و همکاران (۲۰۱۸) به این نتیجه رسیدند که مقیاس‌های میانی ممکن است با مقیاس‌های فرآیندهای پدوژنتیکی مهم انطباق بیشتری داشته باشند و دقت پیش‌بینی را بهبود بخشند. ساهو^۱ و همکاران (۲۰۲۱)، روش‌های مختلف زمین آماری (معکوس فاصله وزنی، کریجینگ کروی و نمایی و کریجینگ بیزی تجربی) و یادگیری ماشین (جنگل تصادفی و ماشین بردار پشتیبان) را برای پیش‌بینی توزیع کربن آلی خاک در یک زمین به مساحت ۶۰ هکتار در چهار اندازه سلولی مختلف (۲۰×۲۰-۴۰×۴۰-۶۰×۶۰-۸۰×۸۰ متر) استفاده نمودند. نتایج نشان داد بهینه‌ترین مقیاس برای پیش‌بینی کربن آلی خاک اندازه سلولی ۲۰×۲۰ متر می‌باشد. تنوع توپوگرافی منطقه و فقدان متغیرهای کمکی منجر به عملکرد ضعیف روش‌های یادگیری ماشین در مقایسه با روش‌های کریجینگ شده است که می‌توان عملکرد مدل‌ها را با استفاده از متغیرهای کمکی که همبستگی بالایی با ویژگی‌های خاک همراه با نمونه‌برداری بالا بهبود بخشید. اسماعیل پور و همکاران (۲۰۲۴)، مطالعه‌ای با هدف بررسی دقت پیش‌بینی شوری خاک با استفاده از مدل شبکه عصبی مصنوعی در اندازه سلول‌های مختلف (۳۰×۳۰، ۵۰×۵۰، ۲۰۰×۹۰، ۲۰۰×۹۰ و ۵۰۰×۵۰۰ متر) در دو منطقه مجزا با توپوگرافی شیب‌دار و مسطح انجام دادند. نتایج نشان داد اندازه سلول ۳۰×۳۰ تا ۵۰×۵۰ متر دقیق‌ترین پیش‌بینی‌ها را به همراه داشت. اسکندری و همکاران (۲۰۱۷)، به بررسی بزرگ مقیاس‌سازی مکانی در نقشه‌برداری رقومی SOC با استفاده از متغیرهای کمکی در منطقه بانه پرداخت. در این مطالعه در ابتدا نقشه SOC با قدرت تفکیک مکانی ۳۰×۳۰ متر با استفاده از داده‌های نمونه‌برداری شده و متغیرهای محیطی کمکی و مدل درختی به دست آمد. سپس با استفاده از روش میانگین‌گیری بلوکی نقشه SOC با قدرت تفکیک مکانی ۱۵۰×۱۵۰ متر به دست آمد. سپس با استفاده از روش بزرگ مقیاس‌سازی شبکه عصبی مصنوعی و رگرسیون تعمیم، نقشه SOC از ۱۵۰×۱۵۰ متر به ۳۰×۳۰ متر تغییر یافت. نتایج نشان داد مدل درختی برای پیش‌بینی SOC با وضوح ۳۰×۳۰ متر عملکرد خوبی دارد.

¹ Sahu

تغییرات در دقت پیش‌بینی مدل‌های ML در هر شکل به تفاوت در کیفیت DEM که منبع مشتقات توپوگرافی بودند نسبت داده شد. این تفاوت‌ها در منابع داده و وضوح مکانی (مقیاس) به احتمال زیاد به اختلاف در دقت منجر شده است. علاوه بر این، لاکوست^۱ و همکاران (۲۰۱۴) ارتباط وضوح DEM در پیش‌بینی SOC را بررسی کرد. آنها دریافتند کردند که داده‌های اولیه DEM در وضوح ۲×۲ متر دارای نویز می‌باشند. برای رسیدگی به این مشکل، آنها DEM را مجدداً بازنمونه‌گیری^۲ کرده و وضوح‌های مختلف، از جمله ۵×۵ متر، ۱۰×۱۰ متر، و ۲۰×۲۰ متر را مورد بررسی قرار دادند و در نهایت DEM با اندازه سلول ۵×۵ متر را به عنوان مناسبترین اندازه سلولی تشخیص دادند. این نتایج بر اهمیت انتخاب یک تفکیک مکانی مناسب برای طبقه‌بندی کلاس‌های خاک تأکید می‌کند. وضوح مکانی بیش از حد بالا ممکن است لزوماً دقت را افزایش ندهد، به ویژه اگر مجموعه داده‌ها و روش‌های اساسی نتوانند تغییرات در مقیاس محلی را ثبت کنند (کاوازی و همکاران، ۲۰۱۳). اندازه‌های سلول بالا می‌توانند نویزهایی را ایجاد کنند که از دقت جلوگیری می‌کند (پادارین^۳ و همکاران، ۲۰۱۹)، و اجرای آنها نیازمند افزایش زمان و هزینه پردازش است (کوستا^۴ و همکاران، ۲۰۱۸). استفاده از متغیرهای کمکی مقیاس‌بندی شده سبب شد تا پیش‌بینی ویژگی‌های خاک در منطقه بروجرد، استفاده از اندازه‌های سلولی ۳۰×۳۰ تا ۶۰×۶۰ متر بیشترین صحت را برای پیش‌بینی ویژگی‌های خاک نسبت به اندازه‌های سلولی ۹۰×۹۰، ۱۵۰×۱۵۰ و ۲۵۰×۲۵۰ متر ارائه کرد. نتایج این تحقیق اطلاعات ارزشمندی در مورد تأثیر وضوح مکانی متغیرهای کمکی بر عملکرد مدل‌های ML در پیش‌بینی ویژگی‌های خاک ارائه می‌دهد. عملکرد مدل‌های ML، بسته به وضوح مکانی متفاوت است. این مطالعه نشان می‌دهد که بهینه‌ترین یا پایدارترین وضوح مکانی بسته به اینکه مدل در حال ارتقاء (انتقال به وضوح درشت‌تر) یا کاهش مقیاس (انتقال به وضوح بهتر) باشد، دارای عملکرد متفاوتی است. کاهش عملکرد از اندازه سلولی ۳۰×۳۰ متر به ۲۵۰×۲۵۰ متر احتمالاً به دلیل از دست دادن اطلاعات و الگوهای مکانی ریز هنگام انتقال به وضوح‌های درشت‌تر است، که می‌تواند بر توانایی مدل برای پیش‌بینی دقیق روی مجموعه داده جدید تأثیر منفی بگذارد (سورت^۵ و همکاران، ۲۰۲۲). همانطور که بهرنس و همکاران (۲۰۱۸) نشان داد که هر پیش‌بینی‌کننده، بالاترین قدرت پیش‌بینی خود را در مقیاس‌های مختلف برای کلاس‌های مختلف خاک دارد؛ نتایج این مطالعه نیز نشان داد که این نتیجه برای پیش‌بینی ویژگی‌های خاک نیز صادق است. بنابراین این نتایج نشان می‌دهد که ویژگی‌های زمین‌نما که به فرآیندهای مختلف تشکیل خاک مربوط می‌شوند، به مقیاس این فرآیندها بستگی دارند، بنابراین مقیاس‌های مختلف برای متغیرهای محیطی بهینه، برای پیش‌بینی یک ویژگی خاص خاک شناسایی می‌شوند (کاوازی و همکاران، ۲۰۱۳)، (بهرنس و همکاران، ۲۰۱۸). نتایج پژوهش حاضر نشان داد که که زیرمجموعه‌ای از متغیرهای کمکی با دقت انتخاب‌شده و مقیاس‌بندی شده برای نقشه‌برداری ویژگی‌های خاک منجر به عملکرد بهتر مدل پیش‌بینی کننده خواهد شد. در این مطالعه مدل RF در اندازه‌های سلولی مختلف نسبت به دو مدل دیگر عملکرد بالاتری داشت. نتایج (زراعت پیشه و همکاران، ۲۰۱۹) نیز تأیید کرد که مدل RF در حال حاضر از نظر بالاترین دقت پیش‌بینی، یکی از موفق‌ترین روش‌ها در خصوص پیش‌بینی مکانی درصد رس و ماده آلی است. مطالعات جان^۶ و همکاران (۲۰۲۱)، مسعودی و همکاران (۲۰۲۳) و متین فر و همکاران (۲۰۲۱) نیز نشان دادند که مدل RF دقیق‌ترین مدل در پیش‌بینی SOC در مقایسه با سایر مدل‌های یادگیری ماشین بود. در این مطالعه، استفاده از مدل رگرسیون کریجینگ سبب افزایش صحت پیش‌بینی مدل‌های یادگیری ماشین شده است. به طور کلی، مدل‌های یادگیری ماشین دارای ظرفیت بالایی برای پیش‌بینی ویژگی‌های خاک در ترکیب با روش‌های زمین‌آماري مانند وزن‌دهی عکس فاصله (IDW)^۷ و کریجینگ هستند (لوی^۸، ۲۰۰۶). مطابق با نتایج به دست آمده در این مطالعه، متین فر و همکاران (۲۰۲۱) بیان کردند که مدل ترکیبی RF-OK دقت پیش‌بینی کربن آلی خاک را در مقایسه با مدل منفرد ۹ و ۱۴ درصد افزایش داد. وانگ و شی (۲۰۱۷) از روش ترکیبی برای تخمین ذرات شن و سیلت و رس استفاده کردند. RMSE محاسبه شده برای هر سه به ترتیب ۹/۲۷، ۷/۶۷ و ۴/۱۷ محاسبه شد. شهریار

¹ Lacoste² Resample³ Padarian⁴ Costa⁵ Saurette⁶ John⁷ Inverse Distance Weighted⁸ Levin

و همکاران (۲۰۱۹) از روش‌های ترکیبی برای پیش‌بینی ذرات خاک با داده‌های محدود استفاده کردند. RMSE محاسبه شده برای پیش‌بینی ذرات شن و رس خاک با استفاده از مدل جنگل تصادفی به ترتیب برابر مقادیر ۱۷/۸۹، ۸/۸۹ به‌دست آمد در حالی که استفاده از مدل‌های ترکیبی RMSE برای ذرات شن و رس خاک را به ترتیب به ۱۵/۰۴ و ۸/۷۷ کاهش داد.

نتایج اهمیت متغیرهای کمکی مقیاس‌بندی شده در پیش‌بینی ویژگی‌های خاک در دشت سیلاخور بیان‌گر تاثیر بیشتر متغیرهای RS نسبت به متغیرهای توپوگرافی در دشت سیلاخور است. همسو با نتایج مطالعه حاضر داروماراجان^۱ و همکاران (۲۰۱۷) متغیرهای TPI، EVI، NDVI و MrRTF را متغیرهای مهم در پیش‌بینی ماده آلی معرفی کردند. در مطالعه خسروانی و همکاران (۲۰۲۴) ارزیابی اهمیت نسبی^۲ (RI) متغیرهای محیطی کمکی نشان داد که هر دو دسته ویژگی‌های توپوگرافی و RS نقش عمده‌ای در پیش‌بینی ویژگی‌های خاک دارند. نتایج مطالعه ممداف^۳ و همکاران (۲۰۲۱) نشان داد که یکی از متغیرهای مهم در پیش‌بینی CCE خاک متغیر شاخص خیزی توپوگرافی (TWI) است که نشان‌دهنده تمایل آب و سایر مواد به انباشته شدن در نواحی پایین‌تر زمین‌نما، ناشی از اثرات ترکیبی حوضه و شیب آن است. مهرابی و همکاران (۲۰۱۹) متغیرهای TWI و شاخص همواری کف دره با درجه تفکیک بالا را به‌عنوان متغیرهای دارای بیشترین سهم در پیش‌بینی رس، سیلت و شن معرفی کردند. همچنین وانگ و همکاران (۲۰۱۷) تاثیر متغیرهای توپوگرافی در پیش‌بینی رس و نیتروژن خاک را نشان دادند. داروماراجان و همکاران (۲۰۱۷) متغیرهای EVI و NDVI را به‌عنوان مهمترین متغیرهای موثر بر پیش‌بینی ویژگی‌های فیزیکی و شیمیایی خاک معرفی کردند. همسو با نتایج قبلی، سو^۴ و همکاران (۲۰۲۴)، تاج پوشش گیاهی^۵ را مهمترین متغیر برای پیش‌بینی SOC معرفی کردند. خسروانی و همکاران (۲۰۲۴) نیز در مطالعه خود بیان داشتند که متغیرهای محیطی انتخاب شده برای پیش‌بینی ویژگی‌های خاک شامل میانگین وزنی قطر خاکدانه، ماده آلی خاک و وزن مخصوص ظاهری متاثر از هر دو دسته ویژگی‌های توپوگرافی مشتق شده از مدل رقومی ارتفاع و RS می‌باشند.

مطالعه حاضر با هدف شناسایی مقیاس بهینه جهت بهینه‌سازی دقت نقشه‌برداری رقومی خاک در عمق (۰-۳۰ سانتی‌متر) برای ویژگی‌های pH، CCE، SOC، سیلت و رس خاک در دشت سیلاخور انجام شد. برای این منظور متغیرهای محیطی توپوگرافی و RS در پنج اندازه سلول ۳۰×۳۰، ۶۰×۶۰، ۹۰×۹۰، ۱۵۰×۱۵۰ و ۲۵۰×۲۵۰ متر تهیه گردیدند. همچنین مدل‌سازی تغییرات مکانی ویژگی‌های خاک توسط سه مدل یادگیری ماشین RF، SVR و CB انجام شد. پس از مشخص شدن بهترین مدل ML، از مدل ترکیبی برای افزایش دقت نقشه‌های تهیه گردیده استفاده شد. متغیرهای محیطی بهینه توسط روش RFE انتخاب شدند.

به طور کلی نتایج بررسی اثر مقیاس متغیرهای محیطی نشان داد که در دشت سیلاخور اندازه سلول ۳۰×۳۰، ۶۰×۶۰ و ۹۰×۹۰ متر بهینه‌ترین اندازه سلول برای هر شش ویژگی خاک می‌باشند. مدل RF در پیش‌بینی ویژگی‌های pH، CCE، Sand و Silt بیشترین صحت را داشت مدل SVR برای پیش‌بینی SOC و مدل CB برای پیش‌بینی Clay نیز منجر به بالاترین دقت پیش‌بینی شدند. همچنین مدل ترکیبی دقت پیش‌بینی تمام ویژگی‌های خاک را در منطقه افزایش داد منجر به پیش‌بینی با دقت خوب شد.

این مطالعه بر نیاز به یک رویکرد مناسب برای انتخاب متغیر بر اساس وضوح مکانی DEM‌ها تأکید می‌کند. نتایج نشان می‌دهد که مدل‌های توسعه‌یافته در وضوح‌های مکانی دقیق‌تر، هنگام انتقال به وضوح‌های درشت‌تر، با چالش‌هایی مواجه می‌شوند که کاهش عملکرد را تجربه می‌کنند. نتایج این مطالعه به اهمیت توجه دقیق به تفکیک مکانی هنگام توسعه و انتقال مدل‌های پیش‌بینی کننده ویژگی‌های خاک تأکید دارد. از محققان و متخصصان خواسته می‌شود که انتخاب متغیرهای محیطی با وضوح‌های مکانی مختلف را با مقیاس و اهداف مطالعات خود هماهنگ کنند، زیرا نتایج این مطالعه نشان داد که متغیرهای محیطی با اندازه سلولی کوچکتر (ریز) جزئیات بسیار دقیقی را برای مطالعاتی که در مقیاس محلی انجام می‌شد ارائه می‌دهد، در حالی که وضوح‌های درشت‌تر ممکن است برای کاربرد در مقیاس منطقه‌ای

¹ Dharumarajan² Relative Importance³ Mammadov⁴ Su⁵ Canopy

مناسب‌تر باشند. به طور کلی، بینش‌های به‌دست‌آمده از این مطالعه به بهینه‌سازی مدل‌های پیش‌بینی کننده مکانی، تقویت کاربرد آن‌ها در زمین‌نماها و مقیاس‌های مکانی متنوع، و در نهایت ارتقای درک ما از تغییرات مکانی ویژگی‌های خاک در تهیه نقشه‌های خاک در دشت‌های استارتژیک کشور که تحت کشاورزی هستند کمک می‌کند. همچنین توصیه می‌گردد رویکرد مورد استفاده در این تحقیق برای سایر زمین‌نماهای مشابه در کشور و به‌عنوان یک راهنمای کاربردی در تهیه نقشه‌های مدیریت پذیر خاک‌ها مورد ارزیابی و بررسی قرار گیرد.

References

- Amirian Chekan, A., Taghizadeh-Mehrjardi, R., Sarmadian, F., & Heydari, A. (2017). Three-dimensional mapping of soil texture using spline depth functions and artificial neural networks. *Iranian Journal of Soil and Water Research*, 48(1), 113-123. 10.22059/IJSWR.2017.61346. (In Persian).
- Adeniyi, O. D., & Maerker, M. (2024). Explorative analysis of varying spatial resolutions on a soil type classification model and it's transferability in an agricultural lowland area of Lombardy, Italy. *Geoderma Regional*, 37, e00785. <https://doi.org/10.1016/j.geodrs.2024.e00785>.
- Breiman, L. (2001). *Random forests*. Machine Learning, 45(1), 5-32. <http://dx.doi.org/10.1023/A:1010933404324>.
- Behrens, T., Schmidt, K., Zhu, A. X., & Scholten, T. (2010). The ConMap approach for terrain-based digital soil mapping. *European Journal of Soil Science*, 61(1), 133-143. <https://doi.org/10.1111/j.1365-2389.2009.01205.x>.
- Behrens, T., Schmidt, K., MacMillan, R. A., & Viscarra Rossel, R. A. (2018). Multi-scale digital soil mapping with deep learning. *Scientific reports*, 8(1), 15244. <https://doi.org/10.1038/s41598-018-33516-6>.
- Cavazzi, S., Corstanje, R., Mayr, T., Hannam, J., & Fealy, R. (2013). Are fine resolution digital elevation models always the best choice in digital soil mapping? *Geoderma*, 195, 111-121. <https://doi.org/10.1016/j.geoderma.2012.11.020>.
- Chutia, D., Bhattacharyya, D. K., Sarma, J., & Raju, P. N. L. (2017). An effective ensemble classification framework using random forests and a correlation-based feature selection technique. *Transactions in GIS*, 21(6), 1165-1178. <https://doi.org/10.1111/tgis.12268>.
- Costa, E. M., Samuel-Rosa, A., & Anjos, L. H. C. D. (2018). Digital elevation model quality on digital soil mapping prediction accuracy. *Ciência e Agrotecnologia*, 42(6), 608-622. <https://doi.org/10.1590/1413-70542018426027418>.
- Chabrillat, S., Ben-Dor, E., Cierniewski, J., Gomez, C., Schmid, T., & van Wesemael, B. (2019). Imaging spectroscopy for soil mapping and monitoring. *Surveys in Geophysics*, 40, 361-399. <https://doi.org/10.1007/s10712-019-09524-0>.
- Chen, S., Lin, B., Li, Y., & Zhou, S. (2020). Spatial and temporal changes of soil properties and soil fertility evaluation in a large grain-production area of subtropical plain, China. *Geoderma*, 357, 113937. <https://doi.org/10.1016/j.geoderma.2019.113937>.
- Casa, R., Pignatti, S., Pascucci, S., Huang, W., & Pepe, M. (2020, September). Effect of spatial resolution on soil properties retrieval from imaging spectroscopy: an assessment of the hyperspectral CHIME mission potential. In *IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium* (pp. 4906-4909). <https://doi.org/10.1109/IGARSS39084.2020.9323268>.
- Chen, S., Arrouays, D., Mulder, V. L., Poggio, L., Minasny, B., Roudier, P., ... & Walter, C. (2022). Digital mapping of GlobalSoilMap soil properties at a broad scale: A review. *Geoderma*, 409, 115567. <https://doi.org/10.1016/j.geoderma.2021.115567>.
- Charman, P.E.V., & Roper, M.M. (2007). Soil Organic Matter. In: Charman, P.E.V. and Murphy, B.W., Eds., *Soils—Their Properties and Management*, 3rd Edition, Oxford University Press, Melbourne, 276-285.
- Burges, C. J., & Schölkopf, B. (1996). Improving the accuracy and speed of support vector machines. *Advances in neural information processing systems*, 9. (NIPS 1996).
- Dharumarajan, S., Hegde, R., & Singh, S. K. (2017). Spatial prediction of major soil properties using Random Forest techniques-A case study in semi-arid tropics of South India. *Geoderma Regional*, 10, 154-162. <https://doi.org/10.1016/j.geodrs.2017.07.005>.
- Dornik, A., Chețan, M. A., Drăguț, L., Dicu, D. D., & Iliuță, A. (2022). Optimal scaling of predictors for digital mapping of soil properties. *Geoderma*, 405, 115453. <https://doi.org/10.1016/j.geoderma.2021.115453>.
- Eskandari, S., nabiollahi, K. and Taghizade-Mehrjardi, R. (2018). Digital Mapping of Soil Organic Carbon (Case Study: Marivan, Kurdistan Province). *Water and Soil*, 32(4), 737-750. doi: 10.22067/jsw.v32i4.68318. (In Persian).
- Esmailpour, S., Mahmoudabadi, E., Ganjehie, M. G., & Karimi, A. (2024). Different pixel sizes of topographic data for prediction of soil salinity. *PLoS one*, 19(12), e0315807. <https://doi.org/10.1371/journal.pone.0315807>.
- Farina, Almo. (2022). "Human-Dependent Landscapes Around the World—An Ecological Perspective." In *Principles and Methods in Landscape Ecology: An Agenda for the Second Millennium*, pp. 339-399. Cham: Springer International Publishing, 2022.

- Gee, G. W., & Bauder, J. W. (1986). *Particle-size analysis 1. Methods of soil analysis: part 1—physical and mineralogical methods, (methodsofsoilanal1)*.
- Guo, L., Shi, T., Linderman, M., Chen, Y., Zhang, H., & Fu, P. (2019). Exploring the influence of spatial resolution on the digital mapping of soil organic carbon by airborne hyperspectral VNIR imaging. *Remote Sensing*, 11(9), 1032. <https://doi.org/10.3390/rs11091032>.
- Jackson, M. L. (1969). Soil chemical analysis-advanced course. *Prentice Hall Inc.* Osmania University. 521 pages.
- John, K., Afu, S. M., Isong, I. A., Aki, E. E., Kebonye, N. M., Ayito, E. O., ... & Penížek, V. (2021). Mapping soil properties with soil-environmental covariates using geostatistics and multivariate statistics. *International Journal of Environmental Science and Technology*, 1-16. <https://doi.org/10.1007/s13762-020-03089-x>.
- Kuhn, M., & Johnson, K. (2013). Applied Predictive Modeling, 4614-6849. *Springer New York, NY*. <https://doi.org/10.1007/978-1-4614-6849-3>.
- Keskin, H., & Grunwald, S. (2018). Regression kriging as a workhorse in the digital soil mapper's toolbox. *Geoderma*, 326, 22-41. <https://doi.org/10.1016/j.geoderma.2018.04.004>.
- Kingsley, J., Lawani, S. O., Esther, A. O., Ndiye, K. M., Sunday, O. J., & Penížek, V. (2019). Predictive mapping of soil properties for precision agriculture using geographic information system (GIS) based geostatistics models. *Modern Applied Science*, 13(10), 60-77. <https://doi.org/10.5539/mas.v13n10p60>
- Khaledian, Y., & Miller, B. A. (2020). Selecting appropriate machine learning methods for digital soil mapping. *Applied Mathematical Modelling*, 81, 401-418. <https://doi.org/10.1016/j.apm.2019.12.016>.
- Khosravani, P., Baghernejad, M., Taghizadeh-Mehrjardi, R., Mousavi, S. R., Moosavi, A. A., Fallah Shamsi, S. R., ... & Scholten, T. (2024). Assessing the role of environmental covariates and pixel size in soil property prediction: a comparative study of various areas in Southwest Iran. *Land*, 13(8), 1309. <https://doi.org/10.3390/land13081309>
- Lacoste, M., Minasny, B., McBratney, A., Michot, D., Viaud, V., & Walter, C. (2014). High resolution 3D mapping of soil organic carbon in a heterogeneous agricultural landscape. *Geoderma*, 213, 296-311. <https://doi.org/10.1016/j.geoderma.2013.07.002>.
- Levin, G. (2006). Computer vision for artists and designers: pedagogic tools and techniques for novice programmers. *AI & SOCIETY*, 20, 462-482. <https://doi.org/10.1007/s00146-006-0049-2>.
- Lagacherie, P., McBratney, A., & Voltz, M. (2006). Digital soil mapping: an introductory perspective. *Elsevier publisher*.
- Lianheng, Z., Shuaihao, Z., Dongliang, H., Shi, Z., & Dejian, L. (2018). Quantitative characterization of joint roughness based on semivariogram parameters. *International Journal of Rock Mechanics and Mining Sciences*, 109, 1-8. <https://doi.org/10.1016/j.ijrmms.2018.06.008>
- Li, S., Xu, L., Jing, Y., Yin, H., Li, X., & Guan, X. (2021). High-quality vegetation index product generation: A review of NDVI time series reconstruction techniques. *International Journal of Applied Earth Observation and Geoinformation*, 105, 102640. <https://doi.org/10.1016/j.jag.2021.102640>.
- Masoudi, R., Mousavi, S. R., Rahimabadi, P. D., Panahi, M., & Rahmani, A. (2023). Assessing data mining algorithms to predict the quality of groundwater resources for determining irrigation hazard. *Environmental monitoring and assessment*, 195(2), 319. <https://doi.org/10.1007/s10661-022-10909-9>.
- McLean, E. O. (1982). *Soil pH and lime requirement." Methods of soil analysis: Part 2 Chemical and microbiological properties*.
- Malone, B. P., Styc, Q., Minasny, B., & McBratney, A. B. (2017). Digital soil mapping of soil carbon at the farm scale: A spatial downscaling approach in consideration of measured and uncertain data. *Geoderma*, 290, 91-99. <https://doi.org/10.1016/j.geoderma.2016.12.008>.
- Mehrabi Gouhori, E., Matinfar, H. R., Taghizadeh-Mehrjardi, R., & Jafari, A. (2019). Investigating the effect of wetness index and spectral data in estimating the percentage of soil particles using neurophasic models, artificial neural network and tree regression. *Scientific Research Journal of Irrigation and Water Engineering of Iran*. 10(2), 126-105. (In Persian).
- 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>
- Mammadov, E., Nowosad, J., & Glaesser, C. (2021). Estimation and mapping of surface soil properties in the Caucasus Mountains, Azerbaijan using high-resolution remote sensing data. *Geoderma Regional*, 26, e00411. <https://doi.org/10.1016/j.geodrs.2021.e00411>.
- Matinfar, H. R., Maghsodi, Z., Mousavi, S. R., & Rahmani, A. (2021). Evaluation and Prediction of Topsoil organic carbon using Machine learning and hybrid models at a Field-scale. *Catena*, 202, 105258. <https://doi.org/10.1016/j.catena.2021.105258>.
- 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. <https://doi.org/10.1016/j.measurement.2022.111706>

- Macharia, P. M., Ray, N., Gitonga, C. W., Snow, R. W., & Giorgi, E. (2022). Combining school-catchment area models with geostatistical models for analysing school survey data from low-resource settings: Inferential benefits and limitations. *Spatial statistics*, 51, 100679. <https://doi.org/10.1016/j.spasta.2022.100679>.
- Mattila, T. J., Hagelberg, E., Söderlund, S., & Joona, J. (2022). How farmers approach soil carbon sequestration? Lessons learned from 105 carbon-farming plans. *Soil and Tillage Research*, 215, 105204. <https://doi.org/10.1016/j.still.2021.105204>.
- Nelson, D. W., & Sommers, L. E. (1980). Total nitrogen analysis of soil and plant tissues. *Journal of the Association of Official Analytical Chemists*, 63(4), 770-778.
- 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>.
- Padarian, J., Minasny, B., & McBratney, A. B. (2019). Using deep learning for digital soil mapping. *Soil*, 5(1), 79-89. <https://doi.org/10.5194/soil-5-79-2019>.
- Paul, G. C., Saha, S., & Ghosh, K. G. (2020). Assessing the soil quality of Bansloi river basin, eastern India using soil-quality indices (SQIs) and Random Forest machine learning technique. *Ecological Indicators*, 118, 106804. <https://doi.org/10.1016/j.ecolind.2020.106804>.
- Parsaie, F., Farrokhan Firouzi, A., Mousavi, S. R., Rahmani, A., Sedri, M. H., & Homae, M. (2021). Large-scale digital mapping of topsoil total nitrogen using machine learning models and associated uncertainty map. *Environmental Monitoring and Assessment*, 193, 1-15. <https://doi.org/10.1007/s10661-021-08947-w>.
- Rossel, R. V., & McBratney, A. B. (2008). Diffuse reflectance spectroscopy as a tool for digital soil mapping. In Digital soil mapping with limited data, *Springer, Dordrecht*. 165-172. Netherlands. https://doi.org/10.1007/978-1-4020-8592-5_13.
- 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>.
- Sahu, B., & Ghosh, A. K. (2021). Deterministic and geostatistical models for predicting soil organic carbon in a 60-ha farm on Inceptisol in Varanasi, India. *Geoderma Regional*, 26, e00413. <https://doi.org/10.1016/j.geodrs.2021.e00413>.
- Saurette, D. D., Berg, A. A., Laamrani, A., Heck, R. J., Gillespie, A. W., Voroney, P., & Biswas, A. (2022). Effects of sample size and covariate resolution on field-scale predictive digital mapping of soil carbon. *Geoderma*, 425, 116054. <https://doi.org/10.1016/j.geoderma.2022.116054>.
- Su, L., Heydari, M., Jaafarzadeh, M. S., Mousavi, S. R., Rezaei, M., Fathizad, H., & Heung, B. (2024). Incorporating forest canopy openness and environmental covariates in predicting soil organic carbon in oak forest. *Soil and Tillage Research*, 244, 106220. <https://doi.org/10.1016/j.still.2024.106220>.
- de Sousa, L. M., Poggio, L., Batjes, N. H., Heuvelink, G. B., Kempen, B., Riberio, E., & Rossiter, D. (2020). SoilGrids 2.0: producing quality-assessed soil information for the globe. *Soil discussions*, 2020, 1-37. <https://doi.org/10.5194/soil-7-217-2021>.
- Taghizadeh-Mehrjardi, R., & Nabiollahi, K. (2016). Determining the most suitable pixel resolution and window size of the height digital model to determine the spatial distribution of soil clay percentage. *Soil research (soil and water sciences)*.30 (1),95-104. <https://doi.org/10.1001.1.22287124.1395.30.1.9.4>. (In Persian).
- Wilding, L. P. (1985). Spatial variability: its documentation, accommodation and implication to soil surveys. *Conference paper: Soil spatial variability*, 1985, 166-189 ref. 15.
- Wang, L., & Liu, H. (2006). An efficient method for identifying and filling surface depressions in digital elevation models for hydrologic analysis and modelling. *International Journal of Geographical Information Science*, 20(2), 193-213. <https://doi.org/10.1080/13658810500433453>.
- Wang, Z., & Shi, W. (2017). Mapping soil particle-size fractions: A comparison of compositional kriging and log-ratio kriging. *Journal of Hydrology*, 546, 526-541. <https://doi.org/10.1016/j.jhydrol.2017.01.029>.
- Yuan, Y., Miao, Y., Yuan, F., Ata-UI-Karim, S. T., Liu, X., Tian, Y., ... & Cao, Q. (2022). Delineating soil nutrient management zones based on optimal sampling interval in medium-and small-scale intensive farming systems. *Precision Agriculture*, 1-21. <https://doi.org/10.1007/s11119-021-09848-1>.
- 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>.
- Zeraatpisheh, M., Jafari, A., Bodaghabadi, M. B., Ayoubi, S., Taghizadeh-Mehrjardi, R., Toomanian, N., ... & Xu, M. (2020). Conventional and digital soil mapping in Iran: Past, present, and future. *Catena*, 188, 104424. <https://doi.org/10.1016/j.catena.2019.104424>.