

Digital mapping of soil texture components in the Sirjan region using machine learning models

Elham Mehrabi Gohari^{1*}  | Roghayeh Shahriaripour² | Ahmad Tajabadipoor³ | Seyed Roohollah Mousavi⁴

1. Department of Soil and Water, Agricultural and Natural Resources Research Organization, Kerman, Iran.
2. Department of Technical & Vocational University, Kerman, Iran.
3. Agricultural Resources, University of Valiasr, Rafsanjani, Iran.
4. Department of Soil Science, Faculty of Agriculture, University of Tehran, Karaj, Iran.
E-mail: elham.mehrabi.gohari@gmail.com

Article Info

Article type:
Research Article

Article history:
Received: 01 May. 2024
Revised: 24 Jun. 2024
Accepted: 30 Jun. 2024
Published online: 01 June. 2025

Keywords:
*Artificial Neural Network,
Neuro-Fuzzy,
Regression Tree,
Remote sensing.*

Abstract

This study aims to evaluate and compare the efficiency of Artificial Neural Network (ANN), Regression Tree (RT) and Neuro-Fuzzy (ANFIS) models using a digital soil mapping framework to predict soil texture in a part of Sirjan province. Sampling was carried out at 84 observation points with a regular grid of 2x2 km, and soil texture components were determined from the soil surface depth of 0 to 30 cm. Auxiliary variables included primary and secondary derivatives of the digital elevation model (DEM), a geomorphological map and remote sensing (RS) spectral indices. The appropriate variables selected using the Principal Component Analysis (PCA) feature selection method. Based on PCA, eight topographic variables and six vegetation indices and spectra from RS selected to predict soil texture components (sand, silt and clay). The efficiency of the models was evaluated using coefficient of determination (R²), mean error (ME), root mean square error (RMSE) and normalised root mean square error (nRMSE). The RMSE values in the neuro-fuzzy model compared with the regression tree model. The results of the neuro-fuzzy model were 1.43% for clay, 1.98% for sand and 2.1% for silt, which were 4.32%, 5% and 4.54% lower respectively compared to the regression tree model. The results of this study showed that the ANFIS model was more accurate in predicting clay, silt and sand compared to ANN and RT. Also, the geomorphology map, topographic wetness index, multi-resolution valley bottom flatness index and Landsat 8 bands 5 and 6 had the highest relative importance in predicting soil texture components.

Cite this article: Mehrabi Gohari, E., Shahriaripour, R., Tajabadipoor, A., Mousavi, S.R. (2025). Digital mapping of soil texture components in the Sirjan region using machine learning models. *Journal of Range & Watershed Management*, 78 (2), 265-288. DOI: <http://doi.org/10.22059/jrwm.2024.375890.1760>



© The Author(s).

Publisher: University of Tehran Press

نقشه برداری رقومی اجزا بافت خاک با استفاده از مدل های یادگیری ماشین در منطقه سیرجان

الهام مهرابی گوهری^{۱*} | رقیه شهریاری پور^۲ | احمد تاج آبادی پور^۳ | سید روح اله موسوی^۴

۱. گروه خاک و آب، سازمان تحقیقات کشاورزی و منابع طبیعی، کرمان، ایران

۲. دانشگاه فنی و حرفه ای کرمان، کرمان، ایران

۳. گروه خاکشناسی، دانشکده کشاورزی، دانشگاه ولی عصر، رفسنجان، ایران

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

رایانامه: elham.mehrabi.gohari@gmail.com

اطلاعات مقاله

چکیده

نوع مقاله:

مقاله پژوهشی

تاریخ دریافت: ۱۴۰۳/۰۲/۱۲

تاریخ بازنگری: ۱۴۰۳/۰۴/۰۴

تاریخ پذیرش: ۱۴۰۳/۰۴/۱۰

تاریخ انتشار: ۱۴۰۴/۰۳/۱۱

کلیدواژه ها:

سنجش از دور،

شبکه عصبی مصنوعی،

رگرسیون درختی،

مدل عصبی فازی.

این مطالعه با هدف مقایسه کارایی مدل های رگرسیون درختی، شبکه عصبی مصنوعی و مدل عصبی فازی به منظور نقشه برداری رقومی بافت خاک در بخشی از اراضی سیرجان انجام شد. بر این اساس در ۸۴ نقطه مشاهداتی با شبکه منظم ۲×۲ کیلومتر از عمق صفر تا ۳۰ سانتی متر، نمونه برداری خاک انجام گرفت و اجزای تشکیل دهنده بافت خاک به روش هیدرومتری تعیین شد. در این مطالعه نقشه ژئومورفولوژی، شاخص های طیفی و گیاهی سنجش از دور و مشتقات مدل رقومی ارتفاع به عنوان داده های کمکی پیش بینی کننده اجزای بافت خاک استفاده شد. سپس مهمترین داده ها توسط روش تجزیه مؤلفه های اصلی و نظر کارشناس انتخاب شدند. هشت متغیر توپوگرافی از مشتقات و شش شاخص پوشش گیاهی و طیفی به عنوان متغیر محیطی انتخاب شدند. برای بررسی عملکرد مدل های مختلف در برآورد متغیرهای وابسته (رس، شن و سیلت) از سه روش ضریب تبیین، میانگین خطا، ریشه دوم میانگین مربعات خطا و ریشه دوم میانگین مربعات خطای نرمال شده استفاده شد. نتایج نشان داد که مقدار ریشه دوم میانگین مربعات خطا در مدل انقیس برای متغیرهای رس، شن و سیلت به ترتیب ۱/۴۳، ۱/۹۸ و ۲/۱۰ درصد بود و برای متغیر رس ۴/۳۲، شن ۵ و سیلت ۴/۵۴ واحد نسبت به رگرسیون درختی کاهش داشت. نتایج اهمیت نسبی نشان داد که نقشه ژئومورفولوژی بیشترین اهمیت را در پیش بینی اجزای بافت خاک داشت و پس از آن، شاخص خیزی توپوگرافی، شاخص همواری دره با وضوح مکانی بالا، باند ۵ و ۶ ماهواره لندست ۸ در درجات بعدی قرار داشتند. بطور کلی، نقش اشکال ژئومورفولوژیک در توزیع و تغییرات بافت خاک بسیار مهم و برجسته است و توجه به این نقشه ها در مطالعات خاک شناسی می تواند به بهبود پیش بینی ها در تهیه نقشه های مدیریت پذیر خاک کمک کند.

استناد: مهرابی گوهری؛ الهام، شهریاری پور؛ رقیه، تاج آبادی پور؛ احمد، موسوی؛ سید روح اله (۱۴۰۴). نقشه برداری رقومی اجزا بافت خاک با استفاده از مدل های یادگیری ماشین در منطقه سیرجان.

نشریه مرتع و آبخیزداری، ۷۸ (۲)، ۲۶۵-۲۸۸.

DOI: <http://doi.org/10.22059/jrwm.2024.375890.1760>



© نویسندگان.

ناشر: انتشارات دانشگاه تهران.

۱. مقدمه

افت خاک یکی از مهم‌ترین ویژگی‌های خاک است که مقدار نگهداری آب و عناصر غذایی، نفوذپذیری، زهکشی، تهویه، مقدار کربن آلی، ظرفیت بافری، تخلخل و بسیاری از خصوصیات مکانیکی خاک را تحت تاثیر قرار می‌دهد (Akpa et al., 2014). داده‌های مربوط به توزیع اندازه ذرات نهایی سازنده خاک، جزء اطلاعات ورودی به اغلب مدل‌های هیدرولوژیکی، اکولوژیکی، اقلیمی و محیط زیستی هستند (Lie et al, 2012). همچنین بافت خاک در تعیین تناسب خاک برای برخی از استفاده‌های خاص و مهم مثل دفن زباله و مدیریت آب نقش اساسی دارد (Tompson et al., 2012).

در علوم خاک تهیه نقشه توزیع مکانی بافت خاک با وضوح مکانی بالا برای برنامه‌ریزی مناسب کاربری اراضی، مدیریت خاک‌ها و سایر تصمیم‌گیری‌های مرتبط با حفاظت از محیط زیست مورد نیاز است (موسوی و همکاران، ۲۰۲۳). زیرا بافت خاک یکی از مهم‌ترین ویژگی‌های خاک است که مقدار نگهداری آب و عناصر غذایی، نفوذپذیری، زهکشی، تهویه، مقدار کربن آلی، ظرفیت بافری، تخلخل و بسیاری از خواص مکانیکی خاک را تحت تاثیر قرار می‌دهد (Akpa et al., 2014). در روش‌های معمول نقشه‌برداری بافت خاک^۱ در مقیاس‌ها و کاربری‌های مختلف، نیازمند جمع‌آوری، تجزیه و تحلیل تعداد زیاد نمونه‌ها است تا تغییرپذیری مکانی بافت خاک در یک منطقه برآورد شود. از این رو در سطح جهانی، شیوه‌های نقشه‌برداری خاک تا حد زیادی به سمت استفاده از روش‌های نقشه‌برداری رقومی خاک^۲ (DSM) و استفاده از فناوری‌های نوین مرتبط با داده‌های سنجش از دور^۳ (RS) به عنوان ابزاری برای کاهش هزینه و زمان مورد نیاز برای توسعه نقشه‌های خاک تغییر یافته است (خالدیان و همکاران، ۲۰۲۰).

داده‌های RS به دلیل دسترسی ارزان، قدرت تفکیک مکانی بالا، قابلیت دسترسی در مقیاس‌های مختلف و ارائه اطلاعات دقیق از زمین‌نمای منطقه در DSM مورد توجه قرار گرفته‌اند (Wang et al., 2018). در حقیقت داده‌های RS با استفاده از فناوری نقشه‌برداری رقومی و مدل‌های پیش‌بینی کننده فرصت‌های جدیدی برای پایش مستمر ویژگی‌های خاک و بررسی توزیع مکانی آن‌ها فراهم آورده است (تقی زاده و همکاران، ۲۰۱۴). مطالعات انجام شده در سالیان اخیر نشان می‌دهد داده‌های ماهواره‌ای می‌توانند متغیرهای کمکی مفیدی برای پیش‌بینی ویژگی‌های سطحی خاک باشند (Castaldi et al., 2016; Gomez et al., 2018). به‌طور معمول، این متغیرهای کمکی علاوه بر داده‌های سنجش از دور از داده‌های ژئومورفولوژیکی، داده‌های اقلیمی و توپوگرافی به دست می‌آیند، به‌طور کلی، می‌توان گفت هدف انواع روش‌های DSM پیش‌بینی ویژگی‌های مختلف خاک از طریق مرتبط نمودن مشاهدات زمینی به پیش‌بینی کننده‌های محیطی می‌باشد (McBratney et al., 2003).

در نقشه‌برداری رقومی خاک برای توسعه مدل خاک-زمین نما^۴ از روش‌های مختلف یادگیری ماشین^۵، از جمله روش‌های درخت‌های تصمیم‌گیری^۶، منطق فازی^۷، شبکه‌های عصبی^۸ و غیره استفاده می‌شود (Heung et al., 2016). در این رویکرد، الگوریتم‌های یادگیری ماشین، سیستم‌های اطلاعات جغرافیایی^۹ و روش‌های مختلف آماری برای یافتن روابط بین ویژگی‌های خاک و مجموعه‌ای از متغیرهای محیطی برای پیش‌بینی آنها در مکان‌های نمونه‌برداری نشده استفاده می‌شوند. مدل‌های مختلف یادگیری ماشین توسط محققان برای پیش‌بینی بافت خاک و کلاس‌های آن به کار گرفته شده است. رایج‌ترین و موفق‌ترین کاربردهای مدل‌های یادگیری ماشین در پیش‌بینی ویژگی‌های خاک می‌توان به استفاده از مدل شبکه عصبی مصنوعی (تقی زاده و همکاران، ۲۰۲۱) در پیش‌بینی ذرات و خصوصیات خاک،

¹ Conventional Soil Texture Mapping

² Digital Soil Mapping

³ Remote Sensing

⁴ Soil Landscape model

⁵ Machin Learning

⁶ Decision Trees

⁷ Fuzzy Logic

⁸ Neural Networks

⁹ Geographic Information System

(مهرابی گوهری و همکاران، ۲۰۱۹) در پیش‌بینی ذرات تشکیل دهنده بافت خاک، رگرسیون درختی (موسوی و همکاران، ۲۰۲۲ الف) برای فسفر قابل تبادل و پتاسیم قابل جذب خاک، جنگل تصادفی (موسوی و همکاران، ۲۰۲۲ ب) برای کربن آلی خاک در لایه‌های سطحی و زیر سطحی خاک و (رحمانی و همکاران، ۲۰۲۲) برای برآورد ضخامت خاک سطحی در بخشی از اراضی دشت قزوین اشاره نمود.

یکی از روش‌های مناسب در پیش‌بینی خصوصیات خاک استفاده از سیستم‌های عصبی فازی (انفیس) است. مدل نروفازی^۱، که ترکیب شبکه عصبی با منطق فازی است، با استفاده از الگوریتم آموزش شبکه عصبی، پارامترهای سیستم فازی را تعیین می‌کند. این سیستم ترکیبی بر اساس سیستم فازی، که بیانگر عدم قطعیت است، پایه‌گذاری شده است. از این شبکه‌ها می‌توان به سیستم فازی تطبیق پذیر مبتنی بر شبکه عصبی^۲ اشاره کرد که نخستین بار توسط ژانگ (۱۹۹۷) معرفی شد. از جمله مزایای این سیستم این است که بین متغیرهای ورودی و خروجی که پارامترهای توابع عضویت بهینه‌سازی شده توسط شبکه‌های عصبی هستند ارتباط برقرار می‌کند (محمودزاده و همکاران، ۲۰۲۱). سی^۳ و همکاران (۲۰۱۵) همچنین عملکرد ANFIS و دو نوع شبکه عصبی مصنوعی را برای پیش‌بینی محتوای آب مقایسه کردند. آن‌ها به این نتیجه رسیدند که ANFIS دقیق‌ترین است. آباگون^۴ و همکاران (۲۰۲۲) در تحقیقی دو مدل ANFIS و رگرسیون خطی چند متغیره^۵ (MLR) را برای پیش‌بینی ظرفیت جذب آهن فلزی خاک به کار برد و نتایج نشان داد که مدل ANFIS با ضریب تبیین ۰/۷۶ پیش‌بینی بهتری را نشان داد. کشاورزی و همکاران (۲۰۱۷) مدل ANFIS را برای تخمین ظرفیت تبادل خاک با استفاده از داده‌های خاک و RS به کار بردند. نتایج تحقیق حاضر نشان داد که مدل ANFIS توانایی تخمین CEC خاک را با محاسبه متغیرهای به راحتی قابل اندازه‌گیری با تضمین صحت، قابلیت اطمینان و تکرارپذیری دارد. کاشی و همکاران (۲۰۱۴) برای تخمین نفوذ خاک و ظرفیت تبادل کاتیونی مدل انفیس را به کار بردند. اگرچه در طی چند سال گذشته تحقیقات مختلفی در نقاط مختلف ایران با هدف نقشه‌برداری ویژگی‌های خاک مبتنی بر رویکردهای DSM صورت گرفته است، اما همچنان در خصوص تهیه نقشه‌های بافت خاک به عنوان یکی از ویژگی‌های موثر بر روی قابلیت و تناسب اراضی نیازمند تحقیقات بیشتر و ارائه رویکردهای جدیدتر است. بنابراین پژوهش حاضر جهت پوشش برخی از نارسایی‌های موجود در این زمینه با اهداف ۱) پیش‌بینی بافت خاک سطحی با استفاده از روش‌های داده کاوی شامل مدل رگرسیون درختی، شبکه عصبی مصنوعی و انفیس، ۲) معرفی مهمترین پارامترهای توپوگرافی، داده‌های سنجش از دور، نقشه ژئومورفولوژی جهت پیش‌بینی درصد رس، شن و سیلت خاک می‌باشد و ۳) تهیه نقشه پراکنش مکانی اجزاء بافت خاک در بخشی از اراضی دشت سیرجان انجام گردید.

۲. مواد و روش‌ها

۲-۱. منطقه مورد مطالعه

منطقه مورد مطالعه، بخشی از اراضی شهرستان سیرجان واقع در غرب استان کرمان که در حدواسط طول جغرافیایی ۴۰° ۵۵' تا ۵۶° ۰۰' و عرض جغرافیایی ۲۹° ۰۰' تا ۲۹° ۳۰' واقع و دارای مساحت تقریبی ۶۳ هزار هکتار می‌باشد (شکل ۱). متوسط ارتفاع منطقه از سطح دریا ۱۷۶۶ متر و میانگین دما و بارش سالیانه آن در یک دوره آماری ۳۰ ساله به ترتیب، ۱۸ درجه سلسیوس و ۱۳۳ میلی‌متر می‌باشد. مواد مادری منطقه، غالباً آهکی می‌باشند. همچنین از نظر سامانه طبقه‌بندی آمریکایی خاک‌ها تا سطح تاکسونومیک فامیل Coarse-loamy, mixed, hyperthermic, Typic Haplosalids می‌باشد. کاربری اصلی اراضی منطقه، باغ پسته می‌باشد. رقم غالب پسته در این

^۱ Neuro-Fuzzy model


^۲ Adaptive Neuro-Fuzzy Inference System, ANFIS

^۳ Si

^۴ Agbaogun


^۵ Multi Linear Regression

منطقه، بادامی است و سن درختان، به‌طور متوسط، ۲۵ سال می‌باشد. همچنین نوع کود فوسفری مصرفی در منطقه مطالعاتی غالباً سوپر فسفات ساده با متوسط مصرف ۳۰۰ کیلوگرم در هکتار و شکل مصرف آن عمدتاً به صورت سطحی است.



شکل ۱. موقعیت منطقه مورد مطالعاتی و نحوه پراکنش مکانی داده‌های خاک

روندنمای تحقیق: مراحل انجام این تحقیق به این صورت می‌باشد: گام اول تعیین محل نقاط نمونه‌برداری به صورت یک شبکه منظم ۲ در ۲ کیلومتر برداشت و نمونه‌ها برای تهیه بانک اطلاعات خاک به آزمایشگاه خاکشناسی منتقل گردید، گام دوم تهیه داده‌های کمکی از جمله مدل رقومی ارتفاع و مشتقات آن، تصاویر ماهواره‌ای و شاخص‌های مربوط به آنها و نقشه ژئومورفولوژی منطقه تهیه گردیدند، گام سوم انتخاب بهترین متغیرهای کمکی با استفاده از روش PCA و نظر کارشناس، گام چهارم مدل‌سازی مکانی با استفاده از مدل‌های یادگیری ماشین شامل: شبکه عصبی مصنوعی، رگرسیون درختی و انفیس، گام پنجم اعتبار سنجی نتایج مدل‌سازی و گام ششم تهیه نقشه‌های رقومی ذرات خاک بر اساس مهمترین مدل پیش‌بینی کننده مکانی.



شکل ۲. روندنمای کلی تحقیق

۲-۲. مطالعات میدانی و تجزیه و تحلیل آزمایشگاهی

ابتدا نقشه توپوگرافی منطقه سیرجان (بخش گلستان) با مقیاس ۱:۲۵۰۰۰ تهیه گردید. پس از پیاده کردن محدوده مطالعاتی بر روی این نقشه و اسکن نمودن آن، با استفاده از نرم‌افزار ایلویس^۱، منطقه مزبور زمین مرجع^۲ شد. در ادامه، شبکه‌ای منظم با ابعاد ۲*۲ کیلومتر بر روی منطقه مطالعاتی اعمال گردید و بدین ترتیب، مختصات جغرافیایی ۸۴ نقطه مشاهداتی جانمایی گردید (شکل ۱). با توجه به مختصات جغرافیایی نقاط تعیین شده با استفاده از سامانه مکان‌یاب جهانی^۳، موقعیت تمامی این نقاط در صحرا تعیین گردید. سپس، نمونه‌های مورد نظر از عمق سطحی خاک (۰-۳۰ سانتی‌متر) در سال ۱۳۹۵ برداشت گردیدند. نوع واحد ژئومورفیک و نوع مواد مادری نیز یادداشت‌برداری شد. در کلیه نمونه‌های خاک پس از هوا خشک شدن و عبور از الک ۲ میلی‌متری بافت خاک به روش هیدرومتری اندازه‌گیری شد.

^۱ ILWIS

^۲ Georeference

^۳ Global Positioning System; GPS

۲-۳. متغیرهای محیطی و انتخاب آن‌ها

با توجه به اینکه متغیرهای محیطی به‌عنوان نمایندگان فاکتورهای خاکسازي در پیش‌بینی اجزاء بافت خاک مورد استفاده قرار گرفتند جهت کمی نمودن نقش این متغیرها از معادله اسکورپن که توسط (McBratney et al., 2003) ارائه گردید در این تحقیق استفاده گردید، که جزئیات بیشتر در مورد آن در رابطه ۱ ارائه شده است:

$$S_{c,s} = f(s, c, o, r, p, a, n) + e \quad \text{رابطه ۱}$$

در رابطه بالا، $S_{c,s}$: ویژگی یا کلاس مربوط به خاک، s : مربوط به اطلاعات خاک یا پایگاه داده خاک یا دانش کارشناس حاصل می‌گردد. c : اقلیم، o : جانداران منجمله جانوران و پوشش گیاهی، r : پستی و بلندی، p : مواد مادری، a : زمان و n : موقعیت مکانی و تابع f : یک طبقه‌بندی نظارت شده یا الگوریتم یادگیرنده نظارت شده را نشان می‌دهد. این معادله با هدف ایجاد ارتباط بین متغیرهای محیطی و متغیرهای وابسته (خصوصیت یا کلاس‌های خاک) بیان گردید (McBratney et al., 2003).

نقشه‌برداری رقومی دارای سه جز داده‌های خاک، داده‌های کمکی و مدلی است که بتواند این دو را به هم ارتباط دهد. در معادله اسکورپن ویژگی‌ها یا کلاس خاک با یکسری متغیرهای محیطی (متغیرهای کمکی) ارتباط داده می‌شوند. به این صورت که در هر موقعیت مشاهده‌ی خاک، یک سری متغیرهای کمکی وجود دارد که همبستگی بالایی با خصوصیات یا کلاس‌های خاک دارند که یافتن این ارتباط و پیش‌بینی خصوصیات یا کلاس‌های خاک در تمام منطقه مورد مطالعه می‌گردد. بنابراین جزء اصلی معادله اسکورپن برنامه یادگیری (مدل پیش‌بینی کننده) می‌باشد. برای پیش‌بینی خصوصیات خاک می‌توان از مدل‌های مختلفی استفاده کرد که در این تحقیق از شبکه عصبی مصنوعی، رگرسیون درختی و انفیس استفاده شد. در این مطالعه از شاخص‌های سنجش از دور، مدل رقومی ارتفاع (DEM) و نقشه واحدهای ژئومورفولوژی منطقه به عنوان داده‌های کمکی پیش‌بینی کننده اجزای بافت خاک استفاده شد. بعد از برداشتن نمونه‌های زمینی در مرداد ماه ۱۳۹۵، تصاویر ماهواره لندست ۸ از ماهواره‌ی لندست-۸ با شماره‌ی ردیف و مسیر به ترتیب ۴۰ و ۱۶۱ از پایگاه داده مکانی Explorer Earth USGS بارگیری شد و پس از اعمال تصحیحات رادیومتریک روی آنها اعمال گردید. در مجموع، ۳۵ متغیر محیطی شامل ۲۰ شاخص از مشتقات اولیه و ثانویه مدل رقومی ارتفاع در محیط نرم افزار ساگا جی ای اس (نسخه ۴/۷) و ۱۵ شاخص سنجش از دور در محیط نرم افزار ENVI (نسخه ۵/۳) تهیه شدند. تمامی متغیرهای محیطی مورد استفاده به وضوح مکانی ۳۰ متر باز نمونه‌گیری گردیدند. برای انتخاب مناسب‌ترین متغیرهای محیطی از روش تجزیه مؤلفه‌های اصلی (PCA) استفاده شد. روش PCA برای متراکم‌سازی داده‌ها و بهبود تفسیر داده‌های ماهواره‌ای استفاده می‌شود. با استفاده از این رویکرد ۱۴ متغیر محیطی به منظور ورودی مدل‌های پیش‌بینی انتخاب شدند که شامل ۸ متغیر توپوگرافی از DEM و ۶ شاخص پوشش گیاهی و طیفی بودند (جدول ۱). این مراحل در محیط نرم افزار JMP11(SW) انجام گردید.

۲-۴. متغیرهای کمکی

بر اساس مدل اسکورپن در نقشه‌برداری رقومی خاک، علاوه بر داده‌های خاک نیاز به داده‌های کمکی می‌باشد. در مطالعه حاضر، از دو سری داده کمی و کیفی به عنوان داده‌های کمکی استفاده گردید.

۲-۴-۱. متغیر کمکی کمی

از مدل رقومی ارتفاع سازمان زمین‌شناسی آمریکا (قدرت تفکیک ۳۰ متر) استفاده گردید. از آماده کردن مدل رقومی ارتفاع، از آن برای استخراج کردن اطلاعات کمکی یا تصاویر تخمین‌زننده متغیرهای خاک استفاده گردید. پارامترهای زمین‌نما از قبیل جهت شیب، ارتفاع نسبت به سطح دریای آزاد (متر)، مساحت حوزه‌های اصلاح‌شده، میانگین گرادیان بالای مسیر جریان، شاخص خیزی، شاخص همواری

دره^۱ شاخص بالایی پشته (MrRTF) و الگوریتم جریان در محیط سامانه جغرافیایی ساگا^۲ محاسبه و استخراج گردید.

جدول ۱. داده‌های کمکی مورد استفاده به عنوان پیش‌بینی کننده در مدل‌سازی مکانی اجزاء بافت خاک

منبع	تعریف	معادل فارسی	پارامترها
National Cartographic Center (2010)	ارتفاع نسبت به سطح دریای آزاد (متر)	ارتفاع	Elevation
Conrad et al., 2015	جهت شیب	جهت شیب	Aspect
Gallant and Dowling (2003)	فرایند مجزا کردن موقعیت‌های مختلف زمین نما واقع بر بستر در (مناطق پست زمین نما)	دره با وضوح مکانی بالا همواری شاخص	Multi-resolution Valley Bottom Flatness Index (MrVBF)
Gallant and Dowling (2003)	فرایند مجزا کردن موقعیت‌های مختلف زمین نما واقع بر رأس یال‌ها	شاخص خط الراس با وضوح مکانی بالا	Multi-resolution Ridge-top Flatness Index (MrRTF)
Olaya, V. I. C. T. O. R. (2004).	شیب متوسط پیکسل‌ها در یک حوزه آبخیز مشخص بر (%)	شیب متوسط	Catchment slope (CS)
Moor et al, 1991	بیانگر یک معیار عددی برای نشان دادن پتانسیل اشباع خاک و رواناب در یک مکان خاص در یک حوضه آبریز است. $(W=A/S)$ ، W =عرض منطقه اشباع، A : مساحت حوضت آبریز بالادست، (S) : تانژانت شیب.	شاخص خیس توپوگرافیک	Topographic wetness index
Wilson (2018)	نسبت حجم کل دبی مستقیم حوزه بر بارندگی موثر	مساحت حوزه‌های اصلاح شده	Catchment area
Boehner, J., Selige, T. (2006)	محاسبه فاکتور طول شیب نسبت به درجه شیب در حوزه آبخیز مشابه معادل جهانی فرسایش (ULSE)	فاکتور طول شیب	LS_Factor (Slope Length and Steepness factor)
Boettinger et al. (2008)	$(B5-B3)/(B5+B3)$	شاخص تفاضلی نرمال شده سبزیگی پوشش گیاهی	Green Normalized Difference Vegetation Index GNDVI
Boettinger et al. (2008)	$(B5-B3)/B5+B3+0.5*1.5$	شاخص بهینه شده سبزیگی خاک و پوشش گیاهی	Green Soil Adjusted Vegetation Index GSAVI
Boettinger et al. (2008)	$(B3-B5)/(B3+B5)$	شاخص تفاضل نرمال شده آب	Normalized difference water index NDWI
Boettinger et al. (2008)	$(2*B5+1-\sqrt{(2*b5+1)^2-8*(b5-b4)})/2$	شاخص اصلاح شده خاک و پوشش گیاهی	Modified Soil-adjusted Vegetation Index MSAVI
Landsat satellite	Reflectance value of Landsat (NIR) satellite band	باند ۵- مادون قرمز نزدیک	Band5
Landsat satellite	(SWIR1): Reflectance value of Landsat satellite band	باند ۶- مادون قرمز کوتاه	Band6
Toomanian et al. (2006)	نقشه واحدهای ژئومورفولوژی تفکیک شده در منطقه	نقشه ژئومورفولوژی	Geomorphology map

۲-۴-۲. متغیر کمکی کیفی


به دلیل اهمیت واحدهای ژئومورفولوژی، در منطقه مورد مطالعه نقشه ژئومورفیک نیز از سازمان تحقیقات با فرمت شیب فایل تهیه شد (شکل ۳) و راهنمای نقشه در جدول ۲ نمایش داده شد.

تمامی اطلاعات (داده‌های خاک و متغیرهای محیطی) به فرمت نهایی txt تبدیل شده و برای انجام فرایند مدل‌سازی در نرم‌افزارهای

¹ Multi-resolution Valley Bottom Flatness Index (MrVBF)

² SAGA

مربوطه (JMP, GIS, SAGA, MATLAB) آماده شدند.



شکل ۳. نقشه ژئومورفولوژی منطقه مورد مطالعه (موسسه آب و خاک کرمان).

جدول ۲. راهنمای نقشه ژئومورفولوژی منطقه مورد مطالعه

کد مربوط به نقشه ژئومورفولوژی	سطح زمین ریخت
QT2	سطح پایین مخروط افکنه و رسوبات تراس دره
DM	تناوب سنگ مرمر، میکاشیست، آمفیبولیت و کوارتزیت
OML	سنگ آهک مرجانی عظیم تا ضخیم
QSL	دریاچه نمک
QSF	دشت نمک
QT1	رسوبات تراس و فن پدیمت سطح بالا
QAL	کانال جریان، کانال پر شده و رسوبات دشت سیلابی
OMSM	سنگ آهک، مارن، مارن گچی، ماسه و ماسه سنگ
LMET	سنگ‌های دگرگونی منطقه ای متوسط درجه (رخساره آمفیبولیت)

۲-۵. مدل‌سازی مکانی

به منظور نمایش تغییرپذیری و مدل‌سازی توزیع مکانی ذرات نسبی خاک در محدوده‌ی مطالعاتی و ارائه نقشه پهنه‌بندی آن از سه

الگوریتم یادگیری ماشین شامل رگرسیون درختی (RT)، شبکه عصبی مصنوعی (ANN) و مدل انفیس (ANFIS) استفاده شد. در انتها مدلی که دارای بیشترین دقت در برآورد اجزا بافت خاک بود، برای تهیه نقشه توزیع مکانی ذرات خاک مورد استفاده قرار گرفت.

۲-۵-۱. رگرسیون درختی

فرآیند مدل سازی درختی شامل تقسیم بندی کردن داده ها به زیرمجموعه های بسیار یکنواختی است که به آن ها گره های نهایی می گویند. در تحقیق حاضر از نرم افزار جمپ (JMP) برای ساختن رگرسیون درختی و در نهایت پیش بینی اجزای بافت خاک (رس، شن و سیلت) استفاده شد (Rezaei et al., 2023).

۲-۵-۲. شبکه عصبی مصنوعی

یکی از متداول ترین شبکه های عصبی مورد استفاده، شبکه عصبی پروپسترون چند لایه می باشد. ساختار پرسپترون چند لایه یک ترکیب استاندارد از ورودی ها، واحدهای عصبی خطی و غیر خطی و خروجی ها می باشد. خروجی تمام واحدهای پردازش از هر لایه به تمام واحدهای پردازش لایه بعدی انتقال داده می شود. واحدهای پردازش لایه ورودی همگی خطی هستند ولی در لایه مخفی از نرون ها با توابع سیگموئید (لوگ سیگ، تانژانت هیپربولیک) یا هر تابع غیر خطی و پیوسته مشتق پذیر دیگری می توان استفاده کرد. معمولاً برای مدل سازی و رگرسیون و افزایش سرعت آموزش، نرون های لایه خروجی خطی انتخاب می گردد. در مسائل طبقه بندی بهتر است نرون های لایه خروجی همانند نرون های لایه مخفی انتخاب شود.

در این تحقیق شبکه عصبی مصنوعی پرسپترون چند لایه با یک لایه مخفی که دارای تابع فعال سازی سیگموئید در لایه مخفی و تابع فعال سازی خطی در لایه خروجی بوده و تعداد نرون های آن از دو تا ۱۰ نرون متغیر بوده و بهترین تعداد نرون به صورت سعی و خطا تعیین شد، مورد بررسی قرار گرفت. همچنین به علت کارایی، سادگی و سرعت بالا در این تحقیق الگوریتم آموزشی لونبرگ مارکوارت استفاده شد. در تحقیق حاضر از نرم افزار جمپ برای ساختن شبکه عصبی مصنوعی و پیش بینی اجزای بافت خاک (رس، شن و سیلت) استفاده شد.

۲-۵-۳. مدل فازی - عصبی تطبیقی (ANFIS)

این مدل توسط یانگ در سال ۱۹۹۷ بسط یافت، اجازه می دهد که سامانه های فازی در مباحث آموزش جزءها، از روش آموزش پس انتشار تطبیقی استفاده نماید. منطق فازی ابزاری توانمند جهت حل مسائل مربوط به سیستم های دینامیک و پیچیده ای که درک آن ها مشکل بوده و یا دارای مسائل وابسته به استدلال و تصمیم گیری می باشند، به شمار می آید. در سال های اخیر از ترکیب منطق فازی با شبکه های عصبی مصنوعی، سیستم های فازی عصبی به وجود آمده اند. سیستم های فازی عصبی به سه دسته تقسیم می شوند:

۱. مدل فازی که با استفاده از تکنیک یادگیری شبکه عصبی نظارت شده ایجاد می شود.

۲. مدل فازی که با استفاده از تکنیک یادگیری مبنی بر تقویت ایجاد می شود.

۳. مدل فازی که با استفاده از تکنیک شبکه عصبی به منظور تقسیم فازی فضای ویژگی ایجاد می شود.

شبکه تطبیقی، ساختار پیشرو چند لایه ای است که رفتار کلی خروجی آن به وسیله مقدار یک مجموعه از پارامترهای قابل اصلاح تعیین می گردد. به عبارت دیگر ساختار شبکه تطبیقی شامل مجموعه ای از گره های متصل به یکدیگر است که به طور مستقیم به هم مرتبط شدند و در آن هر گره یک واحد پردازش محسوب می شود

در طراحی مدل شبکه های عصبی فازی این تحقیق، از شبکه عصبی چند لایه پیش خور، الگوریتم یادگیری پس انتشار خطا و سیستم

استنتاج فازی ساگنو^۱ و تابع خروجی خطی و برای غیرفازی کردن، از تابع میانگین وزنی استفاده شد. برای طراحی سیستم بهینه شبکه‌های عصبی فازی، از طریق تغییر مداوم تعداد لایه‌ها و تعداد نرون‌های لایه پنهان، توپولوژی مناسب شبکه عصبی بررسی و از طریق تغییر مداوم توابع عضویت مختلف و تعداد توابع عضویت، سیستم مناسب پایگاه استنتاج فازی طراحی شد. مدل نروفازی در محیط انفیس ادیت در نرم افزار مطلب اجرا شد.

ارزیابی مدل‌ها: برای ارزیابی عملکرد رگرسیون درختی، شبکه عصبی مصنوعی و مدل‌های فازی عصبی، ده برابر مقیاس اعتبار سنجی مورد استفاده قرار گرفت (هر کدام از مدل‌ها ۱۰ بار اجرا شد، سپس میانگین‌گیری شد و مقادیر انحراف معیار تعیین شد). برای بررسی عملکرد مدل‌های مختلف در برآورد متغیرهای وابسته (رس، شن و سیلت) از چهار روش خطای مختلف استفاده شد: ضریب تبیین (R^2)، میانگین خطا (ME)، متوسط مربعات خطا (RMSE) و میانگین خطای مربعات نرمال شده (nRMSE). چنانچه مقدار RMSE به میانگین متغیر وابسته تقسیم گردد، آن را RMSE نرمال شده (nRMSE) می‌نامند. این معیار برای مقایسه مدل‌های مختلف مناسب خواهد بود. مقادیر nRMSE (معادله ۳) کمتر از ۰/۱ نشان‌دهنده پیش‌بینی عالی، بین ۰/۱ و ۰/۲ خوب، بین ۰/۲ تا ۰/۳ متوسط و بیشتر از ۰/۳ ضعیف خواهد بود (Wallach et al., 2006).

$$R^2 = \left[\frac{\sum_{i=1}^n (X_e - \bar{X}_e) \times (X_o - \bar{X}_o)}{\sqrt{((X_e - \bar{X}_e)^2 \times (X_o - \bar{X}_o))^2}} \right]^2 \quad \text{رابطه ۲}$$

$$ME = \frac{1}{n} \sum_{i=1}^n (X_o - X_e) \quad \text{رابطه ۳}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_o - X_e)^2} \quad \text{رابطه ۴}$$

$$nRMSE = \frac{RMSE}{\bar{X}} \quad \text{رابطه ۵}$$

در روابط بالا:

X_o : متغیرهای کمی مشاهده شده، X_e : متغیرهای کمی تخمین زده، $\bar{X}_o$: میانگین متغیرهای مشاهده شده $\bar{X}_e$: میانگین متغیرهای کمی برآورد شده

۳. نتایج و بحث

در جدول ۳ خلاصه آماری رس، سیلت و شن آمده است. همان‌طور که مشاهده می‌شود، درصد رس از میزان ۴ درصد تا ۲۰ درصد متفاوت بود، میزان سیلت نیز بین ۹ درصد تا ۳۵ درصد در منطقه متغیر بود. فراوانی شن از ۵۰ درصد تا ۸۲ درصد با میانگین و انحراف

¹ Sugeno

معیار ۶۴/۴۵٪ و ۶/۴۵٪ متغیر بود. میزان بالاتر درصد رس در خاک مربوط به قسمت‌های جنوبی و غربی منطقه مورد مطالعه می‌باشد که از نظر زمین‌شناسی در سطح بالایی دامنه‌هایی واقع شده است که دارای تراس‌های عمیق رسوب‌گذاری شده می‌باشند. درصد سیلت در نقاط مختلف منطقه در حد متوسط بود. از نظر ژئومورفولوژی اکثر خاک‌های منطقه خصوصاً قسمت‌های شرقی و شمال شرق در رسوبات آهکی دارای شیب کم و فاصله آبراهه‌های زیاد واقع شده است که میزان بالای درصد شن در آنها دیده می‌شود و به دلیل زهکشی مناسب این اراضی تحت کشت پسته قرار داشتند.

جدول ۳. پارامترهای آماری مربوط به خصوصیات شن، رس و سیلت

پارامتر	حداقل	حداکثر	میانگین	انحراف معیار	ضریب تغییرات
رس	۴	۲۰	۱۲/۸۵	۳/۲۸	۲۵
شن	۵۰	۸۲	۶۴/۴۵	۶/۴۵	۱۰
سیلت	۹	۳۵	۲۲/۴۳	۶/۰۱	۲۷

۳-۱. متغیرهای محیطی


به منظور انتخاب مناسب‌ترین متغیرهای ورودی به مدل‌های رگرسیون درختی و شبکه عصبی مصنوعی و فازی عصبی از روش تجزیه‌ی مؤلفه‌های اصلی (PCA) استفاده شد. با روش تجزیه‌ی مؤلفه‌های اصلی اطلاعات طیفی به دست آمده را خلاصه نموده، تا بتوان جهات با حداکثر واریانس داده‌های طیفی را جستجو نمود. روش تحلیل مؤلفه اصلی روشی است که متغیرهای موجود در یک فضای چندبعدی همبسته را به یک مجموعه از مؤلفه‌های غیرهمبسته خلاصه می‌کند که هر یک از آن‌ها ترکیب خطی از متغیرهای اصلی می‌باشند. مؤلفه‌های غیرهمبسته به دست آمده مؤلفه‌های اصلی نامیده می‌شوند که از بردارهای ویژه ماتریس کوواریانس یا ماتریس همبستگی متغیرهای اصلی به دست می‌آیند. اولین مؤلفه بیشترین اطلاعات را با خود به همراه دارد و از نقطه نظر آماری بیشترین واریانس را دارد. مؤلفه دوم بیشترین اطلاعات باقیمانده که توسط مؤلفه اول توضیح داده نشده است را بیان می‌کند. با انتخاب چند مؤلفه اصلی اول، سایر مؤلفه‌ها از محاسبات بعدی حذف می‌شوند. بر همین اساس، ۷ مؤلفه اصلی با ارزش ویژه بزرگتر از یک و با توجیه بیش از ۸۰ درصد واریانس جمعی را تحت پوشش قرار می‌دادند، استخراج شد (جدول ۴؛ شکل ۴).

درون هر مؤلفه اصلی متغیرهای کمکی که دارای بیشترین مقدار ضرایب وزنی بودند شناسایی شدند و پس از انطباق با ضریب همبستگی بین آن‌ها، در صورت همبستگی بالا، متغیر با بالاترین مقدار نگه داشته شد و مابقی حذف گردیدند. بر این اساس از بین ۳۵ متغیر ورودی ۱۴ متغیر کمکی انتخاب شدند که از جمله برای مؤلفه اول باند ۶ ماهواره لندست و شاخص گیاهی تعدیل‌کننده اثر خاک، مؤلفه دوم ارتفاع از سطح دریا و شیب موثر و فاکتور طول شیب، مؤلفه سوم شاخص تفاضلی نرمال شده سبزینگی پوشش گیاهی و شاخص بهینه شده خاک و پوشش گیاهی، مؤلفه چهارم شاخص خط الراس با وضوح مکانی بالا، مؤلفه پنجم شاخص همواری دره با وضوح مکانی بالا، مؤلفه ششم باند ۵ ماهواره لندست و مؤلفه هفتم شاخص خیسی به عنوان متغیرهای محیطی منتخب جهت پیش‌بینی اجزای بافت خاک مورد استفاده قرار گرفتند. سایر محققین نیز از این روش برای انتخاب متغیرهای محیطی استفاده کردند و بر کارایی روش انتخاب متغیر محیطی تجزیه مؤلفه‌های اصلی در مطالعات نقشه‌برداری خاک تأکید نموده‌اند. به عنوان مثال در مطالعه موسوی و همکاران (۲۰۲۱) از رویکرد تجزیه مؤلفه‌های اصلی با هدف نقشه‌برداری رقومی کربنات کلسیم معادل خاک در اعماق سطحی و زیرسطحی خاک در دشت قزوین استفاده نمودند و بطور مشابه با تحقیق حاضر از الگوریتم‌های غیرخطی یادگیری ماشین شامل جنگل تصادفی، کیوبیست و رگرسیون بردار پشتیبان استفاده نمودند و در پایان بر کارایی این رویکرد انتخاب متغیر در مطالعه انجام شده تأکید نمودند. همچنین در دیگر مطالعات نیز در همین راستا توسط رحمانی و همکاران (۲۰۲۰) نتایج مشابهی را در استفاده از این رویکرد به

همراه استفاده از الگوریتم‌های یادگیری ماشین گزارش نموده اند.

جدول ۴. نتایج تجزیه مولفه‌های اصلی متغیرهای محیطی تهیه شده در پیش بینی اجزاء بافت خاک برای منطقه مورد مطالعه

متغیرهای محیطی							مولفه‌های اصلی
PC7	PC6	PC5	PC4	PC3	PC2	PC1	
۱/۱۲	۱/۲۵	۲/۴۳	۳/۵۲	۳/۶۰	۶/۱۴	۱۲/۶۲	ارزش ویژه
۴/۵۷	۵/۰۶	۷/۱۶	۱۱/۱۲	۱۱/۲۴	۱۶/۶۳	۲۴/۴۵	% واریانس
۸۰/۲۳	۷۵/۶۶	۷۰/۶۰	۶۳/۴۴	۵۴/۳۲	۴۱/۰۸	۲۴/۴۵	درصد تجمعی
-۰/۰۹	۰/۰۲	-۰/۵۷	۰/۶۳	-۰/۵۵	-۰/۳۲	۰/۹۲۹	B6
-۰/۳۳	-۰/۴۰	-۰/۴۵	۰/۰۹	-۰/۱۶	-۰/۳۳	-۰/۸۵۰	MSAVI
-۰/۰۲۸	۰/۰۳۶	-۰/۵۰	۰/۰۹۸	-۰/۱۷۸	-۰/۳۲	۰/۶۴	B2
-۰/۰۱۷	-۰/۰۱۳	۰/۰۲۷	۰/۰۱۲	-۰/۰۹۲	-۰/۰۹۴	۰/۶۳	B7
-۰/۰۰۷	۰/۰۳۱	-۰/۰۵۸	۰/۰۷۸	-۰/۱۵۷	-۰/۰۴۳	۰/۶۱	B1
-۰/۰۳۲	-۰/۰۰۲	۰/۰۴۶	۰/۰۰۴	۰/۱۸۷	۰/۰۱۹	۰/۶۱۰	B4
-۰/۲۲	۰/۷۱۴	-۰/۱۰۴	۰/۰۵۸	۰/۴۰۵	-۰/۰۷۲	۰/۶۰۰	B5
-۰/۰۲۲	-۰/۰۱۵	-۰/۱۰۴	۰/۰۵۸	۰/۵۸۱	-۰/۰۷۲	۰/۵۸۷	B3
۰/۱۰۳	-۰/۰۰۸	-۰/۰۸۱	-۰/۰۶۰	۰/۳۹۲	-۰/۱۲۳	۰/۵۵۰	NDVI
-۰/۰۷۰	۰/۱۰۶	۰/۰۳۸	-۰/۰۱۹	۰/۰۴۴	۰/۳۳۸	۰/۱۰۷	Slope
-۰/۰۶۴	-۰/۰۲۹	۰/۲۳۸	-۰/۱۰۴	-۰/۰۵۸	۰/۸۲۰	۰/۰۰۸	Catchment slope
-۰/۰۳۷	۰/۰۲۱	۰/۰۸۹	-۰/۰۶۶	۰/۱۱۶	۰/۸۰۶	۰/۱۸۵	LS
۰/۰۰	۰/۱۰۲	-۰/۱۲۴	-۰/۰۴۶	-۰/۱۱۲	۰/۶۲۰	-۰/۱۱۴	VDCN
۰/۰۱۰	-۰/۰۲۲	-۰/۰۳۷	-۰/۰۸۷	-۰/۳۱۰	۰/۷۸۲	-۰/۳۱۳	Elevation
۰/۰۱۲	-۰/۰۴۶	-۰/۰۱۹	-۰/۰۹۲	-۰/۳۳۹	۰/۵۳۰	-۰/۳۴۳	CHNBL
-۰/۰۴۳	۰/۱۹۲	۰/۱۷۳	۰/۰۱۴	-۰/۱۸۳	۰/۶۰۷	-۰/۱۷۹	RSP
۰/۰۹۰	-۰/۱۴۴	-۰/۸۲	-۰/۰۰۹	۰/۳۱۹	-۰/۶۰۱	۰/۳۲۴	MRVBF
۰/۲۳۷	۰/۲۱۵	-۰/۲۶۲	۰/۱۷۷	۰/۲۲۵	۰/۵۰۸	۰/۳۰۱	Analytical Hillshading
۰/۰۱۳	-۰/۰۱۴	-۰/۰۹۲	-۰/۰۲۲	۰/۸۸	-۰/۱۲۷	-۰/۰۳۳	GSAVI
۰/۰۱۳	-۰/۰۱۴	-۰/۰۹۲	-۰/۰۲۲	۰/۸۰	-۰/۱۲۷	-۰/۰۳۳	GNDVI
-۰/۰۱۳	-۰/۸۱۰	۰/۰۹۲	۰/۰۲۲	-۰/۲۴۰	۰/۱۲۷	۰/۰۳۳	NDWI
۰/۰۹۴	-۰/۱۴۰	-۰/۰۰۹	-۰/۸۳۱	-۰/۰۰۷	۰/۱۳۵	-۰/۰۱۶	Cell Balance
-۰/۰۳۷	۰/۲۴۱	-۰/۰۲۵	۰/۸۱۳	-۰/۰۸۳	-۰/۲۴۰	۰/۰۷۰	Curvature Classification
۰/۲۲۴	۰/۰۱۷	-۰/۰۹۵	۰/۷۳۸	-۰/۰۱۸	۰/۰۴۰	۰/۱۲۴	Cross Sectional Curvature
-۰/۲۲۸	-۰/۰۴۹	۰/۱۰۹	۰/۶۶۹	۰/۰۱۰	۰/۰۵۲	۰/۰۵۰	Convergence Index
-۰/۴۳۹	-۰/۰۵۲	-۰/۲۳۲	۰/۷۵۰	۰/۲۵۴	-۰/۳۴۷	۰/۰۸۳	MRRTF
۰/۰۱۴	-۰/۰۲۲	۰/۹۱۲	-۰/۰۷۷	-۰/۱۵۱	۰/۱۶۹	-۰/۱۱۰	Flow Path Length
۰/۰۴۲	-۰/۰۰۲	۰/۸۹۵	-۰/۱۲۱	-۰/۱۰۶	۰/۰۸۰	-۰/۰۹۷	Catchment area
-۰/۰۵۷	۰/۰۵۶	-۰/۰۰۹	۰/۰۷۳	-۰/۰۴۱	۰/۱۲۲	۰/۰۰۶	Longitudinal Curvature
۰/۰۲۲	۰/۲۸۸	۰/۰۱۲	۰/۵۲۰	-۰/۴۶	۰/۱۲۲	۰/۱۲۵	TPI
۰/۱۶۵	-۰/۴۷۳	۰/۷۶۰	۰/۰۱۴	-۰/۷۸	-۰/۱۱۳	۰/۱۴۵	Aspect
۰/۰۶۴	-۰/۰۵۵	-۰/۰۲۸	۰/۰۳۹	۰/۰۲۸	-۰/۰۴۰	-۰/۰۲۲	Flow Accumulation
۰/۶۹۰	-۰/۰۸۳	۰/۲۵۷	-۰/۵۰۷	۰/۰۴۹	-۰/۲۵۸	-۰/۰۳۸	TWI
۰/۱۲۴	-۰/۱۸۶	-۰/۱۰۷	-۰/۰۲۶	-۰/۱۴۷	۰/۳۵۴	۰/۰۷۷	VD
-۰/۰۰۵	۰/۲۰۵	۰/۱۰۵	۰/۷۰۵	۰/۰۹۳	-۰/۲۰۶	۰/۰۳۰	MCA



شکل ۴. نمودار اسکری (بازویی) برای تعیین تعداد مولفه‌های مناسب

۳-۲. نتایج مدل سازی مکانی به روش رگرسیون درختی

در روش رگرسیون درختی، مجموعه‌ای از شرط‌های منطقی به صورت یک الگوریتم با ساختار درختی برای پیش‌بینی ذرات خاک به کار می‌رود. جدول ۵ پارامترهای مختلف ارزیابی مدل را با مقادیر مربوطه برای ارزیابی عملکرد پیش‌بینی مدل رگرسیون درختی خلاصه می‌کند. نتایج نشان داد که ضریب تبیین R^2 برای رس برابر با ۰/۶۱، برای شن ۰/۷۰ و برای سیلت ۰/۶۳ بود که با نتایج برخی از محققان سازگار است. مقدار nRMSE برای پارامترهای رس و شن و سیلت به ترتیب ۰/۲۷، ۰/۲۱ و ۰/۲۵ به دست آمد که بر اساس دامنه‌بندی میانگین خطای مربعات نرمال شده در محدوده ۲۰ تا ۳۰ می‌باشد و دقت متوسط مدل را نشان می‌دهد. خیر^۱ و همکاران (۲۰۱۰) از یک مدل رگرسیون درختی برای نقشه‌برداری خاک استفاده کرد و همچنین تقی زاده و همکاران (۲۰۱۳) یک نقشه سه‌بعدی شوری خاک با استفاده از یک مدل رگرسیون درختی ایجاد کرد. همچنین مونجان^۲ و همکاران (۲۰۱۰) تکنیک شبکه‌های عصبی مصنوعی و درخت تصمیم‌گیری را برای پیش‌بینی واحدهای خاک مقایسه کرد و نشان داد که بین دو روش برای پیش‌بینی تفاوت معنی‌داری وجود ندارد. موسوی و همکاران (۲۰۲۱) رگرسیون درختی را با جنگل تصادفی به منظور بررسی تغییرات عمقی کربنات کلسیم خاک به کار بردند و نتایج نشان داد که رگرسیون درختی نتایج قابل قبولی ارائه نکرد.

جدول ۵. پارامترهای مختلف ارزیابی عملکرد پیش‌بینی مدل رگرسیون درختی مربوط به خصوصیات شن، رس و سیلت

اجزاء یافت خاک	R^2	RMSE	ME	nRMSE
رس	۰/۶۱	۵/۷۵	۰/۰۴	۰/۲۷
شن	۰/۷۰	۶/۹۸	۰/۰۹	۰/۲۱
سیلت	۰/۶۳	۶/۶۴	۰/۲۱	۰/۲۵

^۱ Kheir

^۲ Moonjun

۳-۳. نتایج مدل‌سازی مکانی به کمک تکنیک شبکه عصبی مصنوعی

تعداد نرون‌ها در لایه‌های ورودی و خروجی ثابت بوده و بسته به تعداد ورودی (متغیرهای کمکی) و خروجی (رس، شن و سیلت) مدل به کار گرفته شده دارد. لایه ورودی شبکه شامل ۱۴ ورودی برای رس، شن و سیلت می‌باشد. لایه خروجی شامل یک نرون می‌باشد. در این تحقیق یک لایه مخفی برای ایجاد شبکه پرسپترون مورد استفاده قرار گرفت. تعداد نرون‌های لایه مخفی و همچنین تعداد اپوک در فرآیند آموزش و به صورت سعی و خطا به دست آمدند. در این پژوهش، تعداد نرون ۲ تا ۱۰ مورد آزمایش قرار گرفت. برای تعیین بهترین ترکیب از شاخص ریشه مربعات خطا، ضریب تبیین، و میانگین خطا استفاده شد. جدول ۶ پارامترهای مختلف ارزیابی مدل را با مقادیر مربوطه برای ارزیابی عملکرد پیش‌بینی مدل شبکه عصبی مصنوعی خلاصه می‌کند. نتایج نشان داد که تعداد نرون ۸، ۹ و ۱۰ دارای بهترین ترکیب برای پیش‌بینی رس، شن و سیلت خاک می‌باشند. نتایج ریشه مربعات خطا برای جزء رس، شن و سیلت خاک سطحی ۲/۰۲ درصد، ۴/۴۰ درصد و ۲/۷۵ درصد بود، همچنین نتایج ضریب تبیین R^2 به ترتیب ۰/۸۹، ۰/۹۲ و ۰/۹۱ به دست آمد. میانگین خطای مربعات نرمال شده این مدل برای رس و سیلت در محدوده ۲۰-۳۰ بود که نشان دهنده دقت متوسط مدل می‌باشد و برای شن در محدوده ۱۰-۲۰ که مناسب بودن مدل را برای تخمین درصد شن نشان می‌دهد.

نتایج این بررسی نشان داد که در مورد مطالعه شده، شبکه عصبی مصنوعی نسبت به معادلات رگرسیونی کارایی بهتری داشته است. زیرا احتمالاً کارایی توابع انتقالی به دست آمده در مناطق مختلف با هم متفاوت است (مهرابی و همکاران، ۲۰۱۹) و همچنین می‌توان گفت در طراحی شبکه‌های عصبی نوع خاصی معادلات لازم نیست و با ایجاد ارتباط مناسب بین داده‌های ورودی و خروجی می‌توان به نتایج مناسب دست پیدا کرد و به علت وجود روابط غیرخطی میان متغیرهای وابسته و پیش‌بینی شونده شبکه عصبی عملکرد بهتری نسبت به رگرسیون درختی داشته است. نتایج به دست آمده از این تحقیق با آنچه که ژائو^۱ و همکاران (۲۰۰۹) در کشور چین بدست آورد هم خوانی دارد. ایشان توانستند با استفاده از شبکه عصبی مصنوعی، نقشه رقومی کلاس‌های بافت خاک را با دقت کلی ۸۸٪ و کارایی بالا به دست بیاورند. نبی‌الهی و همکاران (۲۰۱۴) از شبکه‌های عصبی مصنوعی برای مدل‌سازی بافت لایه سطحی خاک‌های منطقه بیجار استفاده کردند و مقادیر ضریب تبیین برای پیش‌بینی درصدهای رس، سیلت و شن را به ترتیب برابر با ۱۰، ۴۰ و ۱۳ به دست آوردند. پاچسکی^۲ و همکاران (۱۹۹۶) با استفاده از آمارهای ضریب همبستگی و ریشه میانگین مربعات خطا به بررسی شبکه عصبی مصنوعی و رگرسیون درختی پرداختند. آن‌ها به این نتیجه رسیدند که شبکه عصبی برآورد بهتر و خطای کمتری بر اساس داده‌های زود یافت خاک دارد. تقی زاده و همکاران (۲۰۲۱) توزیع فضایی ذرات تشکیل دهنده بافت خاک را با روش شبکه عصبی مصنوعی و چند هیبرید زیستی ترکیب شده با ANN در استان مازندران انجام دادند. نتایج نشان داد که شبکه عصبی مصنوعی هیبریدی زیستی با خطای کمتر توانست درصد ذرات بافت خاک را تخمین بزند. نوری و همکاران (۲۰۲۱) در تحقیقی جزء فرسایش پذیری بادی خاک را به کمک مدل‌های شبکه عصبی مصنوعی و تلفیق شبکه عصبی مصنوعی با الگوریتم ژنتیک در بخشی از اراضی جنوب شرقی قزوین برآورد کردند، نتایج نشان داد که جزء فرسایش پذیر خاک با پنج خصوصیت خاک شامل pH، هدایت الکتریکی، SAR، رس و ماده آلی، در سطح یک درصد همبستگی معنی دار داشت اما مدل‌های مورد استفاده از صحت مناسبی در هر دو مرحله آموزش و آزمون برخوردار نبودند، طوری که بیشترین ضریب تبیین در مدل شبکه عصبی مصنوعی ۰/۴۹ با داده‌های سری آزمون به دست آمد. محمودزاده و همکاران (۲۰۲۱) بیان داشتند که اگرچه مدل شبکه عصبی مصنوعی قابلیت‌های زیادی دارد، اما نقاط ضعف عمده‌ای مانند هزینه توسعه دارد و اجرای آن می‌تواند زمان‌بر باشد.

¹ Zhao

² Pachepsky

جدول ۶. پارامترهای مختلف ارزیابی عملکرد پیش‌بینی مدل ANN مربوط به خصوصیات شن، رس و سیلت

اجزاء بافت خاک	R ²	RMSE	ME	nRMSE
رس	۰/۸۹	۲/۰۲	۰/۰۲	۰/۲۱
شن	۰/۹۱	۴/۴۰	۰/۰۶	۰/۱۶
سیلت	۰/۹۲	۲/۷۵	۰/۱	۰/۲۶

۳-۴. نتایج مدل‌سازی مکانی به کمک تکنیک انفیس

جدول ۷ خلاصه پارامترهای مدل ارزیابی با مقادیر مربوطه آن‌ها برای ارزیابی عملکرد پیش‌بینی مدل انفیس استفاده می‌شود. نتایج پیش‌بینی نشان داد که مقدار خطای مربعات ریشه به ترتیب برای رس، شن و سیلت $1/43$ (g kg⁻¹), $1/98$ (g kg⁻¹) و $2/10$ (g kg⁻¹) می‌باشد. همچنین نتایج ضریب تبیین به ترتیب برای رس، شن و سیلت $0/9$ ، $0/91$ و $0/92$ بود. میانگین خطای مربعات نرمال برای درصد ذرات رس، شن و سیلت به ترتیب $0/09$ ، $0/06$ و $0/10$ تعیین شد که نشان‌دهنده دقت بالای مدل انفیس در تخمین درصد ذرات می‌باشد. از جمله مطالعات قبلی کاربرد مدل ANFIS برای پیش‌بینی ضریب فشار خاک (Pham et al., 2019)، کانی‌های رسی خاک (Najafi-Ghiri et al., 2019) و برش پیچشی خاک (Srokosz & Bagińska, 2020) با موفقیت به کار گرفته شده است. سی^۱ و همکاران (۲۰۱۵) عملکرد ANFIS و دو نوع ANN را برای پیش‌بینی محتوای آب مورد مطالعه قرار دادند و نتیجه گرفتند که مدل ANFIS دقیق‌تر است. اگرچه نشان داده شده است که مدل ANFIS در مقایسه با ANN برای پیش‌بینی نرخ نفوذ کل عملکرد خوبی دارد (کشاورزی و همکاران، ۲۰۱۱)، عملکرد برتر مدل‌های رگرسیون خطی چندگانه و مدل‌های ANN در پیش‌بینی ظرفیت تبادل کاتیونی و نفوذ خاک (کاشی و همکاران، ۲۰۱۴) و مدل‌های رگرسیونی برای پیش‌بینی تراکم خاک اراضی کشاورزی نیز در مطالعات قبلی نشان داده شده است (عباسپور-گیلانده، ۲۰۱۹). اما در رابطه با تخمین بافت خاک و اندازه ذرات تشکیل دهنده خاک، تقی زاده و همکاران (۲۰۱۶) بافت خاک در مناطق مرکزی ایران با مدل انفیس و رگرسیون خطی چندگانه تخمین زدند و نتایج آن‌ها نشان داد که مدل انفیس با $RMSE=4/51$ و $R^2=0/74$ دقیق‌تر از مدل رگرسیون خطی چندگانه بود. مهرابی گوهری و همکاران (۲۰۱۹) نیز در مطالعه‌ای به تخمین بافت خاک در پنج عمق استاندارد پرداختند و نتایج آن‌ها عملکرد بهتر مدل انفیس نسبت به شبکه عصبی مصنوعی و رگرسیون درختی را نشان داد. در شکل ۵ مقادیر اندازه‌گیری شده شن، سیلت و رس در مقابل مقادیر پیش‌بینی شده به ترتیب الف، ب و ج با استفاده از مدل ANFIS نمایش داده شده است.


۳-۵. اهمیت متغیرهای محیطی در پیش‌بینی مکانی بافت خاک

نتیجه اهمیت نسبی متغیرهای محیطی پیش‌بینی کننده با استفاده از مدل شبکه عصبی مصنوعی در شکل ۶ و نقشه‌های تعدادی از آن‌ها در شکل ۷ ارائه شده است. بر این اساس نقشه واحدهای ژئومورفولوژی به طور مشخص مهم‌ترین فاکتور پیش‌بینی کننده اجزا بافت خاک بود که پس از آن فاکتورهای از قبیل باند ۵ و باند ۶ MrVBF، شاخص خیزی و MrRTF به ترتیب برای رس، سیلت و شن در درجات اهمیت بعدی قرار داشتند. ژئومورفولوژی دارای بیشترین اهمیت در بین متغیرهای کمکی می‌باشد که تاثیر این متغیر در تشکیل و تکامل خاک‌های منطقه را نشان می‌دهد. به عبارتی، نقش فرایندهای ژئومورفولوژی در توسعه خاک را تأیید می‌کند. نقش مؤثر فرایندهای ژئومورفولوژی و همبستگی نزدیک ژئومورفولوژی و خاک در بسیاری از مطالعات خاک ژئومورفولوژی نشان داده شده است (زراعت پیشه و همکاران، ۲۰۲۰).

^۱ Si

جدول ۷. پارامترهای مختلف ارزیابی عملکرد پیش‌بینی مدل انفیس مربوط به خصوصیات شن، رس و سیلت


اجزاء بافت خاک	R ²	RMSE	ME	nrmse
رس	۰/۹۰	۱/۴۳	۰/۰۲	۰/۰۹
شن	۰/۹۱	۱/۹۸	۰/۰۶	۰/۰۶
سیلت	۰/۹۲	۲/۱۰	۰/۰۹	۰/۱۰




شکل ۵. در شکل فوق به ترتیب الف: مقادیر اندازه‌گیری شده در مقابل مقادیر پیش‌بینی شده شن، ب: سیلت، ج: رس با استفاده از مدل ANFIS

در حقیقت، حضور ویژگی‌های پستی و بلندی به همراه فرآیندهای ژئومورفیک در پیش‌بینی کلاس‌های خاک نشان داد که این فاکتورها برآیند و نتیجه نیروهای مؤثر خاکسازي در منطقه مورد مطالعه هستند. به طور کلی در مناطق خشک و نیمه‌خشک کلاس‌ها و ویژگی‌های خاک غالباً به وسیله مواد مادری و پستی و بلندی کنترل و تعیین می‌شوند (مارکوس و مرکلی، ۲۰۰۷) که این دو عامل در تهیه نقشه ژئومورفولوژی نیز بکار برده شده است. نقشه ژئومورفولوژی با دارا بودن حداکثر اطلاعات به عنوان متغیر کمکی استفاده شده است، بنابراین شامل تعداد زیادی واحد می‌باشد که می‌توانند بخش زیادی از تغییرپذیری خاک‌ها در منطقه مورد مطالعه را توضیح دهند. ادھیکاری^۱ و همکاران (۲۰۱۳) مطالعه‌ی خاک‌های منطقه‌ای مسطح (اختلاف ارتفاع ۳۲ متر) در دانمارک، گزارش نمودند که میزان رس خاک سطحی، ارتفاع و نقشه‌ی زمین شناسی، مهمترین پارامترهای محیطی برای بیان تغییرات خاک با استفاده از سامانه‌ی رده‌بندی جهانی می‌باشند. جعفری و همکاران (۲۰۱۳) در منطقه زرد استان کرمان نتیجه گرفت که سطوح ژئومورفیک و اجزای سرزمین (شاخص همواری دره با درجه تفکیک بالا و شاخص خیزی) به عنوان یک پیش‌بینی کننده مؤثر در پیش‌بینی همه گروه‌های بزرگ خاک عمل می‌کند که این اثر منجر به افزایش دقت پیش‌بینی می‌شود. باند ۶ تصاویر ماهواره‌ای نیز یکی از مهمترین متغیرهای محیطی در منطقه بود. برون و همکاران (۲۰۰۶) از مقادیر رقمی باندهای ۶ و ۷ به عنوان متغیر محیطی برای تخمین بافت خاک منطقه استفاده کردند، نتایج آن‌ها نشان داد که بین این دو باند و اجزای بافت خاک همبستگی خوبی وجود دارد. آنها دلیل اصلی آن را حساسیت بالای طول موج قرمز کوتاه به مقدار رطوبت قابل دسترس خاک و وابسته بودن این مقدار آب به بافت خاک دانستند. همچنین بیان داشتند در مناطق خشک و نیمه خشک به دلیل رطوبت پایین خاک و تاج پوشش کم گیاهی، طول موج قرمز کوتاه به خوبی ویژگی‌های خاک را منعکس می‌کند.

¹ Adhikari



شکل ۶. اهمیت نسبی متغیرهای محیطی در پیش بینی ذرات رس، سیلت و شن با استفاده از مدل شبکه عصبی (توضیح هر یک از داده‌های کمکی در جدول ۱ آمده است)



شکل ۷. نقشه‌های مهمترین متغیرهای کمکی پیش‌بینی کننده ذرات شن و رس و سیلت در منطقه مورد مطالعه

پرویز (۲۰۱۷) نیز در مطالعه‌ای با هدف ارزیابی تأثیر پیش پردازش پارامترهای ورودی حاصل از تصاویر ماهواره‌ای به شبکه عصبی مصنوعی در تعیین بافت خاک بیان کرد حالت تکی باندهای ماهواره‌ای همبستگی بالایی با اجزا بافت خاک دارند. لیا^۱ و همکاران (۲۰۱۳) در نتایجی مشابه بیان داشتند که باندهای ۱ تا ۵ و باند ۷ ماهواره‌ی لندست ۵ بیشترین تأثیر را در پیش‌بینی ذرات تشکیل‌دهنده بافت سطحی دارد. همچنین صحرایی و همکاران (۲۰۲۲) یکی از پارامترهای محیطی مهم در تخمین بافت خاک را باند ۶ لندست ۸ بیان کردند. فاکتور موثر دیگر، شاخص خیزی یا رطوبتی است که برای تعیین توزیع مکانی نفوذ و جریان آب سطحی بکار می‌رود. در واقع تأثیر توپوگرافی بر مکان و میزان تجمع رطوبت در خاک و یا آب در سطح ما را نشان می‌دهد (Moor et al., 1991). این پارامتر با متغیرهای وابسته‌ای که با رطوبت ارتباط دارند و تحت تأثیر رطوبت قرار دارند، همبستگی بیشتری نشان می‌دهد (جعفری و همکاران، ۲۰۱۳). در مطالعه حاضر، شاخص خیزی به عنوان یک متغیر پیش‌بینی کننده معنی‌دار در مدل ذرات خاک وارد شده است. شاخص خیزی مناطق مستعد برای دریافت رسوبات را نشان می‌دهد (Moor et al., 1991). با توجه به اینکه حساس‌ترین جزء خاک به فرسایش سیلت

¹ Liao

می‌باشد، بنابراین انتظار می‌رود که رسوبات عمدتاً حاوی سیلت باشند که در نتیجه همبستگی بالایی بین شاخص خیسی و سیلت وجود دارد (جعفری و همکاران، ۲۰۱۳). احتمالاً با توجه به رسوبی بودن و شیب کم منطقه می‌توان بیان داشت ویژگی‌های توپوگرافیکی و شاخص‌های مربوط به آن از درجه اهمیت کمتری در تخمین میزان رس نسبت به شاخص‌های سنجش از دور برخوردار باشند. شاخص گیاهی تعدیل کننده اثر خاک مهمترین شاخص در تخمین میزان رس بود و در مقابل، شاخص خیسی مهمترین متغیر محیطی به منظور پیش‌بینی شن بود. به‌طورمشابه رحمانی و همکاران (۲۰۲۲) اهمیت شاخص خیسی را در نقشه‌برداری رقومی خاک در منطقه خود تایید کرده‌اند. جعفری و همکاران (۲۰۱۳) نیز در منطقه خشک اقدام به پیش‌بینی رقومی خاک کرده‌اند و شاخص خیسی را به عنوان پارامتر مهم برای مدل خود معرفی کردند. در این مطالعه نیز شاخص همواری دره و شاخص بالای پشته متغیرهای دارای اهمیت بالا بودند. تقی زاده و همکاران (۲۰۱۶) در تحقیقی در مناطق مرکزی ایران این دو شاخص را به همراه شاخص پوشش گیاهی تفاضلی نرمال شده، شاخص گیاهی تعدیل کننده اثر خاک از جمله متغیرهای محیطی مهم نام بردند.


۳-۶. مقایسه کارایی مدل‌ها

همان‌طور که می‌دانیم تمامی مدل‌ها بر پایه دقیق بودن متغیرهای مورد مطالعه و مشاهدات مربوط به آن‌ها استوار است و روابط بین متغیرها نیز دقیق فرض می‌گردد. در صورتی که در سیستم‌های طبیعی مانند خاک، عموماً با مشاهدات یا روابط ناشناخته بین متغیرها رو به رو هستیم. در چنین شرایطی باید از مدل‌هایی بهره گرفت که قادر به ارائه الگوهای مناسب‌تر باشند، به گونه‌ای که بتوانند انطباق بیشتری با دنیای واقعی داشته باشند. به این ترتیب با توجه به ماهیت ابهامی پدیده‌های مرتبط با خاک یا تقریبی بودن مقادیر اندازه‌گیری شده ذرات خاک، به نظر می‌رسد کارایی بالاتر مدل مبتنی بر مجموعه‌های فازی در پردازش توابع انتقالی خاک به همین علت باشد. در تحقیق حاضر نتایج نشان داد که شبکه عصبی مصنوعی در مقایسه با انفیس کارایی کمتری در برآورد پارامترهای خاک داشت. مقدار RMSE و همچنین nRMSE محاسبه شده مدل انفیس در مورد هر سه پارامتر رس، شن و سیلت کمتر از شبکه عصبی مصنوعی و رگرسیون می‌باشد که نشان‌دهنده دقت بالاتر این مدل در مقایسه با سایر مدل‌ها می‌باشد. البته نتایج نشان داد که در سطح ۵٪ تفاوت معنی‌داری بین نتایج شبکه عصبی مصنوعی و انفیس وجود ندارد البته مدل شبکه عصبی بسیار پیچیده تر و وقت گیرتر می‌باشد. اما در مقایسه مدل انفیس نسبت به مدل رگرسیون درختی مقدار RMSE برای متغیر رس ۴/۳۲، برای شن ۵ و برای سیلت ۴/۵۴ واحد کاهش داشته که نشان‌دهنده کارایی بهتر مدل انفیس می‌باشد. در نهایت نقشه‌های رقومی ذرات رس، شن و سیلت (شکل ۸) با استفاده از مدل انفیس تهیه شد.

۴. نتیجه‌گیری

به‌طور کلی، تحقیق حاضر با هدف تهیه نقشه اجزای بافت خاک با استفاده از روش‌های یادگیری ماشین و متغیرهای محیطی در بخشی از اراضی دشت سیرجان انجام شد. نتایج مقایسه مدل‌های انفیس، شبکه عصبی مصنوعی و رگرسیون درختی برای پیش‌بینی درصد ذرات رس، شن و سیلت نشان داد که مدل انفیس دارای کارایی بالاتری در پیش‌بینی این ذرات بود و پس از آن مدل شبکه عصبی مصنوعی نسبت به رگرسیون درختی عملکرد بهتری داشت. بنابراین، مدل یادگیری ماشین انفیس می‌تواند فرآیند نقشه‌برداری خاک‌ها را در مناطق با گستره‌های مختلف و متشکل از انواع عوارض طبیعی با دقت بالایی انجام داده و سرعت و کارآمدی نقشه‌برداری رقومی خاک را در انتقال داده‌ها و اطلاعات افزایش دهند. همچنین اهمیت نسبی متغیرهای کمکی، نشان داد که نقشه واحدهای ژئومورفولوژی و پس از آن مشتقات توپوگرافی و باندهای منفرد تصاویر ماهواره‌ای (باند ۵ و ۶ لندست ۸ و شاخص‌های پوشش گیاهی) نقش موثری در پیش‌بینی اجزای بافت خاک در منطقه مطالعاتی داشتند. در این میان، نقشه واحدهای ژئومورفولوژی به عنوان نماینده تغییرات زمین‌نما در منطقه مطالعاتی بیشترین تأثیر را در پیش‌بینی تغییرات مکانی اجزای بافت خاک نشان داد که این بیانگر اهمیت و نقش اشکال سرزمین در

پراکنش و تغییرات مکانی بافت خاک در منطقه است. بنابراین، به نظر می‌رسد که هر واحد ژئومورفولوژی دارای نوع خاصی از مواد مادری، وضعیت هیدرولوژیک و توپوگرافی خاص خود باشد. به‌طوری‌که بیشترین مقدار شن در بخش‌های شرقی و شمالی منطقه که دارای منشا رسوبات جوان و بیشتر رودخانه‌ای و بر روی دامنه‌ها واقع شده‌اند، مشاهده شد. بیشترین مقدار سیلت در بخش مرکزی متمایل به جنوب و بیشترین مقدار رس در بخش جنوبی منطقه مشاهده گردید که دقیقاً همراستا با تغییرات ارتفاع و ژئومورفولوژی منطقه به ترتیب بر روی اشکال فیزوگرافی دشت سیلابی و اراضی پست قرار دارند. این مناطق به دلیل قرارگیری در پایین‌ترین موقعیت ارتفاعی، کلیه رسوبات تحت تأثیر جریان‌های هیدرولوژیک به این مناطق منتهی می‌شوند که کاملاً با تئوری و رویکردهای تشکیل خاک همخوانی دارد. بنابراین، نقش اشکال ژئومورفولوژیک در توزیع و تغییرات بافت خاک بسیار مهم و برجسته است و توجه به این نقشه‌ها در مطالعات خاک‌شناسی می‌تواند به بهبود پیش‌بینی‌ها در تهیه نقشه‌های مدیریت‌پذیر خاک کمک کند.



شکل ۸. نقشه پیش‌بینی ذرات رس، شن و سیلت با استفاده از مدل انفیس

References

- Abbaspour-Gilandeh, M., & Abbaspour-Gilandeh, Y. (2019). Modelling soil compaction of agricultural soils using fuzzy logic approach and adaptive neuro-fuzzy inference system (ANFIS) approaches. *Modeling Earth Systems and Environment*, 5(1): 13-20.
- Adhikari, K., Kheir, R. B., Greve, M. B., Bocher, P. K., Malone, B. P., Minasny, B., McBratney, A. B. & Greve, M. H. (2013). High-resolution 3-D mapping of soil texture in Denmark. *Soil Science Society of America Journal*, 77: 860-876.
- Agbaogun, B.K., Olu-Owolabi, B.I., Buddenbaum, H & Fischer, K. (2023). Adaptive neuro-fuzzy inference system (ANFIS) and multiple linear regression (MLR) modelling of Cu, Cd, and Pb adsorption onto tropical soils. *Environmental Science and Pollution Research*. 30: 31085–31101.
- Akpa, S. I. C., Odeh, I. O. A & Bishop, T.F. A. (2014). Digital mapping of soil particle-size fractions for Nigeria. *Soil Science Society of America Journal*, 78(6), 1953-1966.
- Castaldi, F., Palombo, A., Santini, F., Pascucci, S., Pignatti, S. & Casa, R. (2016). Evaluation of the potential of the current and forthcoming multispectral and hyperspectral imagers to estimate soil texture and organic carbon. *Remote Sensing. Environment*, 179, 54–65.
- Gomez, C., Adeline, K., Bacha, S., Driessen, B., Gorretta, N., Lagacherie, P., Roger, J.M., & Briottet, X. (2018). Sensitivity of clay content prediction to spectral configuration of VNIR/SWIR imaging data, from multispectral to hyperspectral scenarios. *Remote Sensing. Environment*, 204, 18–30.
- Heung, B., Ho, H. C., Zhang, J., Knudby, A., Bulmer, C. E., & Schmidt, M. G. (2016). An overview and comparison of machine-learning techniques for classification purposes in digital soil mapping, *Geoderma*, 265, 62-77.
- Jafari, A., Ayoubi, S., Khademi, H., Finke, P.A., & Toomanian, N. (2013). Selection of a taxonomic level for soil mapping using diversity and map purity indices: A case study from an Iranian arid region. *Geomorphology*, 201, 86-97.
- Jang, J., Sun, C., & Mizutani, E. (1997). *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Prentice Hall, Upper Saddle River, New Jersey, USA.
- Kashi, H., Emamgholizadeh, S., & Ghorbani, H. (2014). Estimation of Soil Infiltration & Cation Exchange Capacity Based on Multiple Regression, ANN (RBF, MLP), and ANFIS Models. *Communications in Soil Science and Plant Analysis*, 45, 1195–1213.
- Keshavarzi, A., Sarmadian, F., Labbafi, R., & Vandechali, M.R. (2011). Modeling of soil cation exchange capacity based on fuzzy table look-up scheme and artificial neural network approach. *Modern Applied Science*, 5(1): 153.
- Keshavarzi, A., Sarmadian, F., Shiri, J., Munawar, L., Tirado-Corbalá, R., & Omran, E.-S.E. (2017). Application of ANFIS-based subtractive clustering algorithm in soil Cation Exchange Capacity estimation using soil and remotely sensed data. *Measurement*. 95: 173-180.
- Khaledian, Y., & Miller, B.A. (2020). Selecting appropriate machine learning methods for digital soil mapping. *Applied Mathematical Modelling*. 81, 401–418.
- Kheir, B., Greve, M.H., Bocher, P.K., Greve, M.B., Larsen, R., & McCloy, K. (2010). Predictive mapping of soil organic carbon in wet cultivated lands using classification-tree based models: The case study of Denmark. *Journal of Environmental Management*, 91, 1150-1160.
- Liao, K., Xu, S., Wu, J., & Zhu, Q. (2013). Spatial estimation of surface soil texture using remote sensing data. *Soil Science Plant Nutrient*, 59(4), 488–500.
- Lie, 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.
- Mahmoudzadeh, H., Matinfar, H.R., Kerry, R., Eskandari, S., Ebrahimi-Khusfi, Z., & Taghizadeh-Mehrjardi, R. (2021). New hybrid evolutionary models for spatial prediction of soil properties in Kurdistan. *Soil use and management*. 38, 191-211.
- McBratney, A.B., Santos, M.L.M & Minasny, B. (2003). On digital soil mapping. *Geoderma*. 117, 3-52.
- Mehrabi-Gohari, E., Matinfar, H. R., Jafari, A., Taghizadeh-Mehrjardi, R., & Triantafyllis, J. (2019). The spatial prediction of soil texture fractions in arid regions of Iran. *Soil Systems*, 3(4): 65.
- Moonjun, R., Farshad, A., Shrestha, D.P., & Vaiphasa, C. (2010). Artificial Neural Network and Decision Tree in Predictive Soil Mapping of hoi NumRin Sub-Watershed, Thailand. *Digital Soil Mapping Soil Science*, 2, 151-164. https://doi.org/10.1007/978-90-481-8863-5_13.

- Moore, I.D., Grayson, R.B., & Ladson, A.R. (1991). Digital terrain modeling: review of hydrological, geomorphological and biological applications. *Hydrology. Proc.* 5, 3-30.
- 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. (In Persian)
- Mousavi, S. R., Sarmadian, F., Omid, M., & Bogaert, P. (2021). Modeling the Vertical Soil Calcium Carbonate Equivalent Variation by Machine Learning Algorithms in Qazvin Plain. *Journal of Water and Soil Science*. 35(5), 719-734. (In Persian)
- 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)
- Nabiollahi, K., Haidari, A. & Taghizadeh Mehrjerdi, R. (2014). Digital mapping of soil texture using regression tree and artificial neural network in Bijar, Kurdistan. *Journal of Water and Soil*, 28:1025-1036. (In Persian)
- Najafi-Ghiri, M., Mokarram, M., & Owliaie, H.R. (2019). Prediction of soil clay minerals from some soil properties with use of feature selection algorithm and ANFIS methods. *Soil Research*, 57(7): 788-796.
- Noori, A., Eftekhari, K., Esfandiari, M., Mohamadi Torkashvand, A., & Ahmadi, A. (2021). Estimation of soil erodible fraction using artificial neural network models and integration of artificial neural network with genetic algorithm in the part of Qazvin province. *Quarterly journal of Environmental Erosion Research*. 45(12): 145-159. (In Persian)
- Olaya, V. I. C. T. O. R. (2004). A gentle introduction to SAGA GIS. The SAGA User Group eV, Gottingen, Germany, 208.
- Pachepsky, Y. A., Timilin, D., & Varallyay, G. (1996). Artificial neural networks to estimate soil water retention from easily measurable data. *Journal Soil Science Society of America*. 60: 727-733.
- Parviz, L. (2017). Evaluation the Preprocessing Effect of Satellite Images Input Parameters in to Artificial Neural Network for Soil Texture Determination. *Iranian Journal of Applied Soil Research*, 5(2): 66-80 (In Persian)
- Pham, B. T., Nguyen, M. D., Dao, D. V., Prakash, I., Ly, H.-B., Le, T.-T., Ho, L. S., Nguyen, K. T., Ngo, T. Q., Hoang, V. U., Son, L. H., Ngo, H. T. T., Tran, H. T., Do, N. M., Van Le, H., Ho, H. L., & Tien Bui, D. (2019). Development of artificial intelligence models for the prediction of Compression Coefficient of soil: An application of Monte Carlo sensitivity analysis. *Science of the Total Environment*, 679: 172-184.
- Rahmani A., Sarmadian F., Mousavi S.R., & Khamoshi S.E.(2020). Application of Geomorphometric attributes in digital soil mapping by using of machine learning and fuzzy logic approaches. *Journal of Range and Watershed Managment* .73(1): 105-124. (In Persian)
- Rahmani, A., Sarmadian, F., & Arefi, H. (2022). Digital Mapping of Top-soil Thickness and Associated Uncertainty Using Machine Learning Approach in Some Part of Arid and Semi-arid Lands of Qazvin Plain. *Iranian Journal of Soil and Water Research*, 53(3): 585-602. (In Persian)
- Rezaei, M., Mousavi, S. R., Rahmani, A., Zeraatpisheh, M., Rahmati, M., Pakparvar, M., ... & Cornelis, W. (2023). Incorporating machine learning models and remote sensing to assess the spatial distribution of saturated hydraulic conductivity in a light-textured soil. *Computers and Electronics in Agriculture*, 209: 107821.
- Sahraee, 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)
- Si, Jianhua., Feng, Qi., Wen, Xiaohu., Xi, Haiyang., Yu, Tengfei., Li, Wei., & Zhao, Chunyan. (2015). Modeling soil water content in extreme arid area using an adaptive neuro-fuzzy inference system. *Journal of Hydrology*. 527: 679-687.
- Srokosz, P. E., & Bagińska, M. (2020). Application of adaptive neurofuzzy inference system for numerical interpretation of soil torsional shear test results. *Advances in Engineering Software*, 143: 102793.
- Taghizadeh Mehrjardi, R., Minasny, B., Sarmadian, F & Malone, P.B. (2014). Digital mapping of soil salinity in Ardakan region, central Iran. *Geoderma*. 213: 15-28.
- Taghizadeh-Mehrjardi, R., Emadi, M., Cherati, A., Heung, B., Mosavi, A & Scholten, T. (2021). Bio-Inspired Hybridization of Artificial Neural Networks: An Application for Mapping the Spatial Distribution of Soil Texture Fractions. *Remote Sensing*. 13, 1025-1048.
- Taghizadeh-Mehrjardi, R., Minasny, B., Sarmadian, F., & Malone, P.B. (2013). Digital mapping of soil salinity in Ardakan region, central Iran. *Geoderma*, 213: 15-28.

- Taghizadeh-Mehrjardi, R., Toomanian, N., Khavaninzadeh, A. R., Jafari, A., & Triantafilis, 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: 707–725.
- Thompson, J. A., Roecker, S., Grunwald, S & Owens, P. R. (2012). Digital soil mapping: Interactions with and applications for hydopedology. *H. Lin, ed. Hydopedology*. 665-709. Amsterdam: Academic Press. <https://doi.org/10.1016/B978-0-12-386941-8.00021-6>.
- Wallach, D., Makowski, D., Jones, J. W., & Brun, F. (2006). Working with dynamic crop models: evaluation, analysis, parameterization, and applications. *Elsevier*
- Wang, B., Waters, C., Origill, S., Gray, J., Cowie, A., Clark, A., & Liu, D.L. (2018). High resolution mapping of soil organic carbon stocks using remote sensing variables in the semi-arid rangelands of eastern Australia. *Science of the Total Environment*. 630,367–378.
- Zeraatpisheh, M., Jafari, A., Bagheri Boadaghabadi, M., Ayoubi, S., Taghizadeh Mehrjardi, R., Toomanian, N., Kerry, R., Xu, M. (2020). Conventional and digital soil mapping in Iran: Past, present, and future. *CATENA*, 188: 104424.
- Zhao, Z., T.L., Chow, H.W., Rees, Q., Yang, Z. Xing., & Meng, F. (2009). Predict soil texture distributions using an artificial neural network model. *Computers and Electronics in Agriculture*. 65, 36-48.