Research Article

Agricultural Engineering., 48(2) (2025) 249 - 266 ISSN (E): 2588-526X

DOI: 10.22055/agen.2025.48977.1767 ISSN (P): 2588-5944

Estimation of available Zn content in surface soils of selected areas in northern Khuzestan province using artificial neural network

M. Torfi Mohisenpour[1], S. Hojati[2*], A. Landi[3] and H. Amerikhah[4]

1- Former M.Sc. student, Department of Soil Science, Faculty of Agriculture, Shahid Chamran University of Ahvaz, Khuzestan, Iran
2- Professor, Department of Soil Science, Faculty of Agriculture, Shahid Chamran University of Ahvaz, Khuzestan, Iran
3- Professor, Department of Soil Science, Faculty of Agriculture, Shahid Chamran University of Ahvaz, Khuzestan, Iran
4- Lecturer, Department of Soil Science, Faculty of Agriculture, Shahid Chamran University of Ahvaz, Khuzestan, Iran.

Received: 8 February 2025 Accepted: 9 April 2025 *Corresponding Author: s.hojati@scu.ac.ir

Abstract

Introduction: Previous studies indicate that many soils worldwide either lack zinc or contain it in a form that is unavailable to plants. In Iran, over 56% of agricultural soils have DTPA-extractable zinc levels below 0.75 mg/kg, while only 31% exceed 1 mg/kg. Therefore, understanding the factors influencing zinc concentration is crucial, as is prioritizing their significance in the distribution of this essential element in soil. Employing an effective model to comprehend the logical connections within the results is essential. Artificial neural networks, known for their ability to model complex and non-linear relationships between soil variables, have been widely used in numerous studies over the past few decades. Khuzestan province, located in southwest Iran, has high potential for producing a variety of agricultural and horticultural products due to its water resources and fertile soils. With an output of 17.5 million tons of agricultural and horticultural products, Khuzestan plays a vital role in ensuring the country's food security. Given the diverse topography and land uses, this study aims to estimate the available zinc content in the surface soils of a selected area in northern Khuzestan province using artificial neural networks, and to identify the key factors controlling its distribution across the study area.

Materials and Methods: Most of the study area falls within the catchment area of the Karun River, which serves as the backbone of the hydrographic network in Khuzestan province. The eastern sectors are situated in the catchment area of the Zohre-Jarhari Rivers. This region has a hot and dry climate, with average rainfall ranging from 240 mm in the center to 590 mm in the eastern parts. Various geological formations, including Asmari, Gachsaran, and Mishan, are present in this area. The soil moisture regimes include aridic, ustic, and *xeric* (in the eastern parts), while the temperature regimes are classified as *thermic* and hyperthermic. The soils in the study area are primarily classified as Aridisol, Inceptisol, and Entisol. A total number of 203 surface (0-10 cm) composite samples were randomly collected from an area of 27,452 square kilometers in northern Khuzestan province during sunny winter conditions. The soil samples were air-dried and passed

© 2025 The Author(s). Published by Shahid Chamran University of Ahvaz. This is an open-access article distributed under the terms of the Creative Commons Attribution License (http://creativecommons.org/licenses/by/4.0), which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

through a 2 mm sieve. The pH and electrical conductivity of the soil were measured in pastes and saturated extracts, respectively. Soil texture was determined using the pipette method, organic matter was assessed by the wet oxidation method with potassium dichromate, and calcium carbonate equivalent was measured through back titration.To measure the available zinc content in the soils, 10 grams of each sample were weighed, and 20 ml of a 0.005 M DTPA solution was added. The suspension was shaken for 2 hours at 120 rpm. Subsequently, the solid and solution phases were separated using Whatman 42 filter paper. The zinc content of the extracts was then measured using a GBS Variant AA atomic absorption device. Zinc concentrations of less than 3 mg/kg, between 3 and 6 mg/kg, and greater than 6 mg/kg were categorized as low, medium, and high classes of available zinc content, respectively. A Multilayer Perceptron (MLP) neural network was employed to model available zinc content alongside other soil variables in the SPSS v26 environment, with the optimal structure of the neural network determined through a trial-and-error approach. The normality of the data was assessed using the Kolmogorov-Smirnov test within SPSS v26 software.

Results and Discussion: The results indicated that the average content of available soil zinc in the study area is 2.76 mg/kg. The average calcium carbonate equivalent of the soils is 42.25%, indicating that the soils can be classified as calcareous. Furthermore, with an average pH of 7.65, the soils in the region exhibit alkaline reactions. The average soil organic carbon content is 12.6 g/kg, and the findings suggest that the studied soils primarily belong to the loam family. Among the examined soil properties, soil salinity has the highest coefficient of variation at 131.9%, while soil pH has the lowest at 4.2%. The results of the Kolmogorov-Smirnov test revealed that only the silt content exhibited a normal distribution pattern; the other variables did not pass the test of normality. When evaluating various configurations of multilayer perceptron artificial neural networks, the MLPSO7 model emerged as the most effective. This model features a stable arrangement of 3 output classes, 5 hidden layer neurons, and 7 input layers, utilizing the sigmoid function for both input and output activation. The results indicate that organic carbon, calcium carbonate equivalent, and electrical conductivity were the most influential factors in model development. Analysis of the estimation matrix for available zinc classes reveals that the MLPSO7 model accurately estimated low concentrations of available Zn more effectively than the other two classes. Additionally, the soil variables used to model available zinc contents in the study area achieved high accuracy, with 97.4% for the training dataset, 97.1% for the test dataset, and an overall accuracy of 90.8%. In contrast, the class with high concentrations of Zn (>6 mg/kg) yielded weaker estimates, likely due to the limited number of samples in this category.

Conclusion The estimates derived from the optimal neural network model show good flexibility and efficiency in explaining the available Zn content in the study area. For future large-scale studies, it is essential to pay greater attention to the significant roles of organic matter, the abundance of calcareous compounds, and soil salt content in determining available Zn levels.

Keywords: Sensitivity, receiver operating characteristic curve, calibration, validation

مهندسی زراعی (مجله علمی کشاورزی) جلد ۴۸. شماره ۲، ۱۴۰۴

مقاله پژوهشی

مدل‌سازی روی قابل دسترس در خاک سطحی بخشی از اراضی شمال استان خوزستان با استفاده از شبکه عصبی مصنوعی

محمد طرفی‌محیسن‌پور[۱]، سعید حجتی[۲*]، احمد لندی[۳] و هادی عامری‌خواه[۴]

۱- به ترتیب دانش آموخته کارشناسی ارشد گروه مهندسی علوم خاک، دانشکده کشاورزی، دانشگاه شهید چمران اهواز، خوزستان، ایران

۲- استاد گروه مهندسی علوم خاک، دانشکده کشاورزی، دانشگاه شهید چمران اهواز، خوزستان، ایران

۳- استاد گروه مهندسی علوم خاک، دانشکده کشاورزی، دانشگاه شهید چمران اهواز، خوزستان، ایران

۴- مربی گروه مهندسی علوم خاک، دانشکده کشاورزی، دانشگاه شهید چمران اهواز، خوزستان، ایران

تاریخچه مقاله

دریافت: ۱۴۰۳/۱۱/۲۰

پذیرش نهایی: ۱۴۰۴/۰۱/۲۰

کلمات کلیدی:

حساسیت،

منحنی مشخصه عامل گیرنده،

اعتبارسنجی ،

کالیبراسیون

* عهده دار مکاتبات

Email: s.hojati@scu.ac.ir

چکیده

مدل‌سازی در زمینهٔ شناخت عوامل مؤثر بر ویژگی‌های خاکی از کلیدی‌ترین روش‌های مطالعهٔ خاک است. از آن‌جایی که کمبود عنصر روی در خاک‌های آهکی رایج است و ریزمغذی‌ها در بهبود عملکرد و کیفیت محصول نقش مهمی دارند، از این رو، تعداد ۲۰۳ نمونه از عمق ۰ تا ۱۰ سانتی‌متری خاک‌ها در بخش-هایی از شمال استان خوزستان به شکل مرکب برداشت گردید. سپس ویژگی‌های خاک شامل واکنش خاک، هدایت الکتریکی، بافت، محتوای کربن آلی و کربنات کلسیم معادل به منظور مدل‌سازی پراکنش روی قابل عصاره‌گیری با DTPA در منطقهٔ مطالعاتی اندازه‌گیری شدند. از شبکهٔ عصبی مصنوعی چندلایه در محیط نرم-افزار SPSS نسخه ۲۶ برای مدل‌سازی استفاده شد. بهینه‌ترین آرایش شبکهٔ عصبی با ترکیب ۳ (تعداد لایه‌های خروجی)، ۵ (تعداد نورون‌ها) و ۷ (تعداد لایه‌های ورودی) بر مبنای تابع سیگموئیدی با یک لایهٔ پنهان و ۹۰/۸ درصد تخمین درست گزینش گردید. همچنین به منظور صحت‌سنجی عملکرد مدل از منحنی مشخصه عامل گیرنده (ROC) استفاده و مشخص شد کلاس‌های با غلظت کم و متوسط به ترتیب با مقادیر مساحت زیر سطح نمودار ۰/۹۴ و ۰/۹۱ با حساسیت عالی و کلاس با غلظت زیاد با مساحت زیر منحنی ۰/۷۵ و حساسیت نسبتاً خوب مدل‌سازی شده است. کربن آلی، کربنات کلسیم معادل و هدایت الکتریکی نیز به ترتیب مهم‌ترین پارامترها در مدل‌سازی روی قابل دسترس خاک بودند. با توجه به نتایج عملکرد شبکهٔ عصبی مصنوعی اعم از تخمین صحیح کلاس‌ها و همچنین اعتبارسنجی مدل می‌توان اذعان نمود مدل‌سازی صورت پذیرفته توانسته است عوامل مؤثر بر توزیع روی قابل دسترس را در ناحیهٔ مطالعاتی به خوبی شناسایی نماید.

مقدمه

بررسی‌ها حاکی از آن است که بیش از ۱۷ درصد جمعیت جهان در خطر دریافت ناکافی روی هستند که از این مقدار قاره‌های آسیا و آفریقا به ترتیب با ۱۹ و ۲۴ درصد کمبود روی بیشتری آمار را به خود اختصاص می‌دهند (۲۳). علایم خفیف کمبود روی به صورت کم خونی، ریزش‌مو،

ناراحتی‌های پوستی، اختلالات هورمونی، اختلالات تیروئید، کوتاهی قد، بلوغ دیررس و تشدید دیابت نوع دو بروز می‌کند. همچنین باعث بروز اختلالات حسی و ناکارآمد شدن سیستم ایمنی، بروز آترواسکلروز و افزایش استرس می‌گردد (۲۶). بدیهی است گیاهانی که در شرایط کمبود روی رشد می‌کنند، محتوای روی در بافت‌های آن‌ها اندک است که سبب کاهش ارزش تغذیه‌ای آن‌ها می‌شود. روی، عنصری کم‌مصرف برای گیاهان تلقی می‌شود، زیرا در غلظت‌های اندک در بافت‌های گیاهی مورد نیاز است. متوسط غلظت روی در لیتوسفر تقریباً ۸۰ میلی‌گرم در هر کیلوگرم است و در خاک فراوانی آن از ۱۰ تا ۳۰۰ و به طور متوسط ۵۰ میلی‌گرم در هر کیلوگرم متغیر است ولی بررسی‌ها حاکی از آن است که در خاک‌های قلیایی مقدار کل روی از ۲۰ میلی‌گرم در هر کیلوگرم تجاوز نمی‌کند (۲). این در حالی است که تنها بخش بسیار کوچکی از روی کل در محلول خاک است.

مطالعات پیشین نشان داده است که بیشتر خاک‌های جهان و از جمله خاک‌های کشورمان یا کمبود روی دارند یا حاوی روی به فرم تثبیت شده می‌باشند که برای گیاه غیرقابل دسترس است. بر این اساس، بیش از ۵۶ درصد از خاک‌های زراعی ایران، مقدار روی قابل عصاره‌گیری با DTPA (که از این پس و در این متن به عنوان روی قابل دسترس نامیده می‌شود) کمتر از ۰/۷۵ میلی‌گرم بر کیلوگرم داشته و تنها ۳۱ درصد از خاک‌های کشور بیشتر از یک میلی‌گرم برکیلوگرم روی قابل دسترس دارند (۲۷). از این رو آگاهی از عوامل کنترل کنندهٔ غلظت روی و اولویت-بندی اهمیت آن‌ها در پراکنش فراوانی این عنصر در خاک به صورت یک رابطه علمی یا در قالب یک مدل می‌تواند حائز اهمیت باشد. یک مدل مناسب بایستی در هنگام استفاده به اندازه کافی ساده باشد به‌گونه‌ای که کاربر بتواند بین روابط حاصل، ارتباط منطقی شناسایی نماید و البته قابلیت اعتبار سنجی را نیز داشته باشد (۲۱). شبکهٔ عصبی مصنوعی جزء سامانه‌های پویایی است که با پردازش داده-های تجربی، قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کند. تمام فرآیندها در شبکه‌های عصبی مصنوعی از قبیل تجزیه و تحلیل، معماری شبکه و شبیه‌سازی آن از طریق یادگیری و آموزش انجام می‌شود (۱۸). شبکه‌های عصبی مصنوعی از جمله مهم‌ترین الگوریتم‌هایی هستند که در چند دههٔ اخیر به دلیل توانایی آن‌ها در مدل‌سازی روابط پیچیده و غیرخطی بین متغیرهای خاکی در مطالعات زیادی مورد استفاده قرار گرفته‌اند که در ادامه به تعدادی از آن‌ها اشاره می‌شود.

میر و همکاران[1] (۲۶) نشان دادند که شبکه عصبی شبکه عصبی پرسپترون چند لایه با آرایش ۱-۶-۴ دقت بهتری در برآورد فسفر قابل جذب نسبت به روش رگرسیون چند متغیره خطی دارد و توانسته است نزدیک به ۹۰ درصد از تغییرات فسفر قابل جذب را با استفاده از برخی ویژگی‌های خاک اعم از درصد رس، ماده آلی، کربنات کلسیم و اسیدیته پیش‌بینی نماید. این در حالی است که روش رگرسیون خطی چند متغیره تنها قادر به پیش‌بینی ۴۳ درصد از تغییرات فسفر قابل جذب است.

محمودزاده و همکاران[2] (۲۴) در پژوهشی با استفاده از شبکه عصبی مصنوعی و رگرسیون خطی چندمتغیره در استان کردستان نشان دادند که مدل‌سازی توزیع کربن آلی خاک توسط شبکهٔ عصبی مصنوعی عملکرد بهتری (R^2 =۰/۹۷) نسبت به رگرسیون خطی چندمتغییره (R^2 =۰/۹۵) داشته است.

گنگ و همکاران[3] (۱۱) در مطالعه دیگری به مقایسه برخی الگوریتم‌های یادگیری ماشین در پیش‌بینی محتوای روی در دانه برنج و محتوای روی قابل دسترس خاک در اراضی شالیزاری منطقه هیوان در استان گوانگ‌دونگ پرداخته و به کارایی مناسب الگوریتم‌های مورد مطالعه از جمله شبکه عصبی مصنوعی درپیش‌بینی محتوای روی دانه و روی قابل دسترس خاک در اراضی شالیزاری اشاره نمودند.

1- Mir *et al.*
2- Mahmoudzadeh *et al.*
3- Geng *et al.*

ایوبی و همکاران[1] (۳) نیز کارایی بهتر شبکه‌های عصبی مصنوعی را در مقایسه با روش‌های رگرسیونی برای پیش-بینی محتوای پروتئینی، و عناصر کم مصرف روی، آهن، مس و منگنز در دانه گندم برخی مزارع کشاورزی غرب ایران گزارش کرده‌اند.

در پژوهش دیگری سکولا و همکاران[2] (۳۳) به ارزیابی کارایی شبکه عصبی مصنوعی پرسپترون چندلایه در پیش‌بینی اجزای بافت ۶۹۳ نمونه خاک بر اساس قرائت داده‌های هیدرومتر پرداختند و کارایی بهتر شبکه عصبی مصنوعی را در مقایسه با روش‌های رگرسیونی مانند رگرسیون گام به گام و رگرسیون درختی گزارش نمودند.

استان خوزستان در جنوب غربی ایران به دلیل داشتن منابع آبی و خاک حاصلخیز، پتانسیل بالایی برای تولید انواع محصولات زراعی و باغی دارد. خوزستان با تولید ۱۷/۵ میلیون تن محصولات کشاورزی و باغی نقش مهمی را در کمک به تامین امنیت غذایی کشور ایفا می‌نماید. از این رو و با توجه به تنوع توپوگرافی و کاربری‌های مختلف از یک سو (۳۳ و ۳۶) و همچنین وجود مطالعاتی اندک در خصوص پراکنش روی قابل‌جذب در این رابطه، این پژوهش با هدف تخمین روی قابل‌جذب، شناسایی عوامل مؤثر بر پراکنش روی قابل دسترس و تعیین پتانسیل شبکهٔ عصبی در تخمین کلاس‌های روی قابل‌جذب انجام گرفت. بر این اساس، در این مطالعه کارایی شبکهٔ عصبی مصنوعی به‌منظور تخمین کلاس‌های روی قابل‌جذب خاک ارزیابی و متغیرهای کلیدی در مدل‌سازی پراکنش آن شناسایی و مورد تفسیر قرار گرفته-اند.

مواد و روش‌ها

منطقه مطالعاتی

بخش اعظم منطقهٔ مورد مطالعه در حوزه‌ی آبریز رودخانه کارون و متأثر از رسوبات این حوزه است و در واقع این حوزه استخوان بندی شبکه هیدروگرافی استان خوزستان را تشکیل می‌دهد (۳۵). بخش دیگر منطقهٔ مطالعاتی (قسمت‌های شرقی) نیز در حوزهٔ آبریز رودخانه-های زهره – جراحی قرار دارند. مواد مادری خاک‌ها در منطقه مطالعاتی عمدتا متاثر از رسوبات دوره کواترنر است. البته سازندهای زمین‌شناسی مختلفی اعم از آسماری، گچساران و میشان نیز در این منطقه وجود دارند (۱). به طور کلی، اقلیم منطقه گرم و خشک است و میانگین بارش از ۲۴۰ میلی‌متر در مرکز تا ۵۹۰ میلی‌متر در شرق استان متغیر است. میانگین ارتفاعی منطقهٔ مورد مطالعه ۵۲۸ متر و حداکثر ارتفاع آن ۳۷۴۰ متر می‌باشد. کاربری‌های اراضی عمده در منطقه شامل کشاورزی آبی و دیم، جنگل، مراتع استپی و کوهستانی و اراضی بایر عمدتاً با پوشش گیاهی ویزه دشت‌های شور می‌باشند (۳۵). رژیم رطوبتی منطقهٔ مورد مطالعه اریدیک، یوستیک و زریک (بخش‌های شرقی) و رژیم‌های حرارتی آن ترمیک و هایپرترمیک است و خاک‌های منطقه به‌طور عمده در رده‌های اریدی‌سول، اینسپتی‌سول و انتی‌سول طبقه‌بندی می‌شوند (۴).

نمونه‌برداری

به‌منظور تخمین کلاس‌های روی قابل دسترس تعداد ۲۰۳ نمونه از منطقه‌ای به مساحت ۲۷۴۵۲ کیلومترمربع در نیمه شمالی استان خوزستان شامل شهرهای ایذه، هفتکل، باغ‌ملک، رامهرمز، مسجد سلیمان، لالی، اندیکا، گتوند، شوشتر، باوی، اهوز و رامشیر به شکل تصادفی ساده نمونه-برداری شد (شکل ۱). برداشت نمونه از عمق ۰ تا ۱۰ سانتی‌متری و به شکل مرکب انجام شد. به‌گونه‌ای که در هر نقطه یک مربع به ابعاد ۱ متر × ۱ متر به مرکزیت نقطه مورد نظر انتخاب و از گوشه‌های هر مربع نمونه‌برداری گردید. سپس نمونه‌ها با یکدیگر مخلوط و برای آماده-سازی به آزمایشگاه منتقل گردیدند. نمونه‌برداری در شرایط آفتابی و در فصل زمستان صورت پذیرفت.

اندازه‌گیری‌های آزمایشگاهی

نمونه‌های خاک پس از انتقال به آزمایشگاه ابتدا هواخشک شده و سپس از الک ۲ میلی‌متری عبور داده

1- Ayoubi *et al.*
2- Sekula *et al.*

شدند. سپس در نمونه‌های تهیه شده مقادیر واکنش خاک و هدایت الکتریکی به‌ترتیب در گل و عصارهٔ اشباع خاک‌ها اندازه‌گیری شدند (۳۱). بافت خاک به روش پیپت (۱۰)، مادهٔ آلی به روش اکسایش تر در مجاورت دی‌کرومات پتاسیم (۲۸) و کربنات کلسیم معادل به روش تیتراسیون برگشتی (۲۲) اندازه‌گیری شد.

به‌منظور اندازه‌گیری روی قابل دسترس خاک‌ها، ابتدا ۱۰ گرم از هر نمونهٔ خاک توزین، و سپس ۲۰ میلی‌لیتر محلول DTPA با غلظت ۰/۰۰۵ مولار به هر نمونه اضافه شد. آن‌گاه، تعلیق به‌دست آمده به مدت ۲ ساعت و با شدت ۱۲۰ دور در دقیقه تکان داده شد. سپس بخش جامد از محلول در تعلیق‌های موجود با استفاده از کاغذ واتمن ۴۲ از یکدیگر جداسازی شدند. در پایان، در عصاره‌های تهیه شده، محتوای روی نمونه‌ها با دستگاه جذب اتمی GBS مدل Variant AA اندازه‌گیری شد (۲۰).

اقدامات قبل از مدل‌سازی

با توجه به شرط توزیع نرمال در فرآیندهای داده‌کاوی، پس از تعیین متغیرهای خاکی، بررسی نرمال بودن توزیع آماری داده‌ها (آزمون کولموگروف – اسمیرنوف) (۵) و شناسایی داده‌های پرت در محیط نرم‌افزار SPSS نسخه ۲۶ انجام شد.

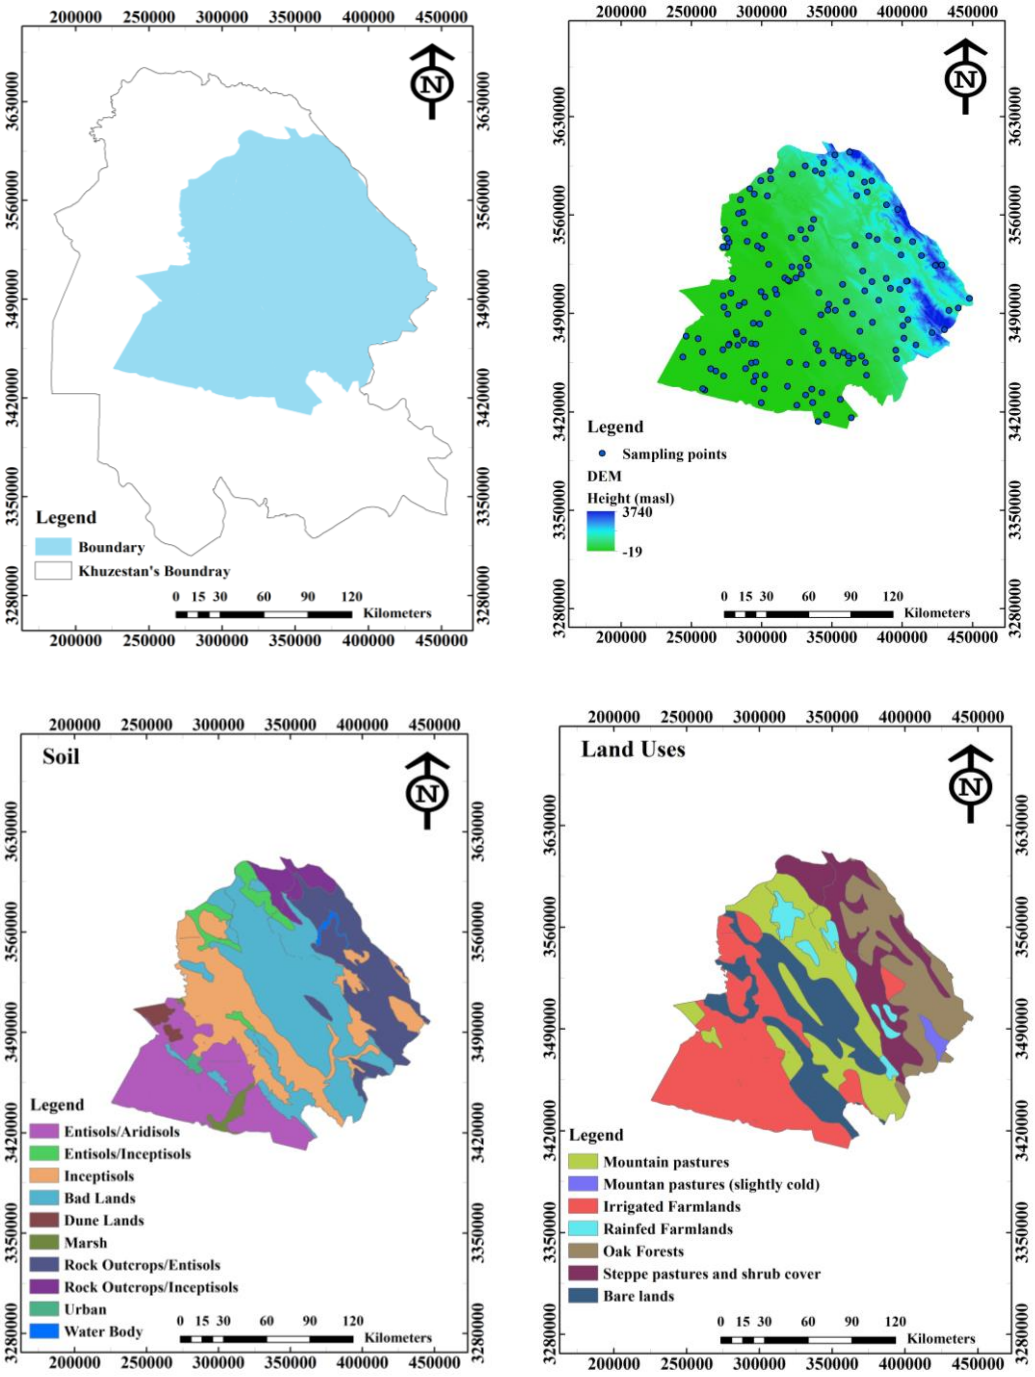
پیش‌پردازش پارامترهای مدل‌سازی

پیش‌پردازش پارامترهای ورودی به‌منظور انتخاب یک ترکیب بهینه از فرآیندهای پیچیده و ضروری در مدل‌سازی سیستم‌های غیرخطی است. بدین منظور، از شبکهٔ عصبی مصنوعی پرسپترون چندلایه با یک و دو لایه پنهان استفاده گردید. همچنین توابع فعال‌ساز سیگموئیدی و تانژانت هایپربولیک به‌عنوان لایه پنهان و توابع سیگموئیدی، تانژانت هایپربولیک و سافت‌مکس به عنوان توابع فعال‌کنندهٔ لایه‌های خروجی مورد استفاده قرار گرفتند و در نهایت بهینه‌ترین ترکیب با بیشترین مقدار درصد تخمین صحیح داده‌های آزمون گزینش گردید. بررسی‌ها نشان داده‌اند که استفاده از توابع مزبور باعث بهبود مدل‌سازی در داده‌های پیچیده و غیرخطی خواهند شد (۴ و ۳۱).

روند مدل‌سازی

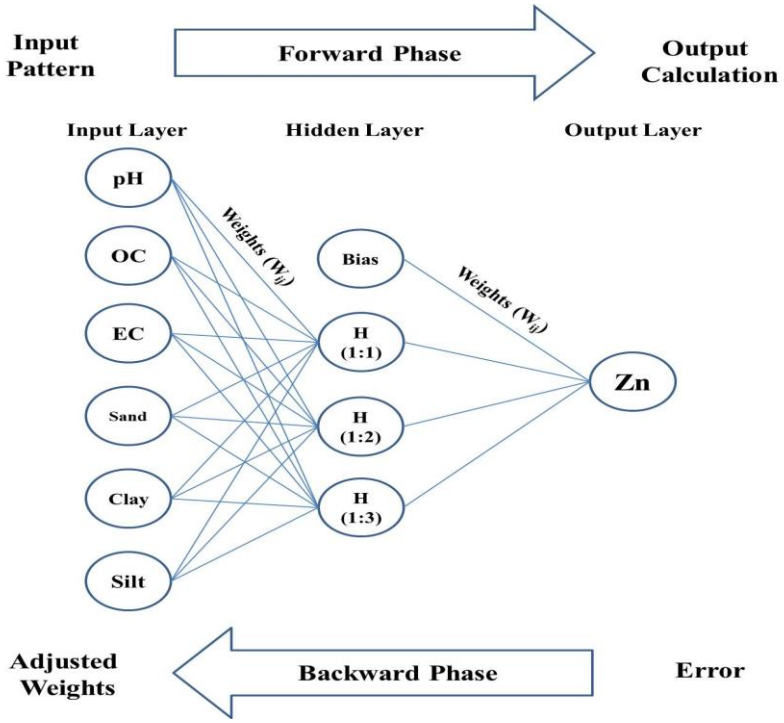
به‌منظور تخمین کلاس‌های روی قابل دسترس در منطقهٔ مطالعاتی، غلظت‌های کمتر از ۳، ۳ تا ۶ و بیش از ۶ میلی‌گرم بر کیلوگرم به‌ترتیب به عنوان کلاس‌هاس کم، متوسط و زیاد روی قابل دسترس تعیین شدند (۳۹). در این پژوهش اجرای شبکهٔ عصبی (شبکهٔ عصبی پرسپترون چندلایه[1] (MLP)) در محیط نرم‌افزار SPSS نسخهٔ ۲۶ انجام شد و آرایش بهینهٔ شبکهٔ عصبی بر مبنای سعی و خطا تعیین گردید. شبکه‌های عصبی MLP بر مبنای الگوریتم پس‌انتشار خطا آموزش می‌بینند. بدین ترتیب که خروجی‌های واقعی با خروجی‌های دلخواه مقایسه می‌شوند و وزن‌ها به‌وسیلهٔ الگوریتم پس‌انتشار، به صورت تحت نظارت تنظیم می‌گردد تا الگوی مناسبی ایجاد شود. شبکهٔ MLP شامل لایه(ها)ی ورودی (اجزای بافت خاک، کربن آلی، هدایت الکتریکی، pH و محتوای کربنات کلسیم معادل)، خروجی (کلاس‌های روی قابل دسترس) و حداقل یک لایهٔ مخفی می‌باشد. هرکدام از این لایه‌ها دارای تعدادی نورون و واحد(ها)ی پردازشی می‌باشد. لازم به ذکر است که هر واحد به طور کامل با اتصال وزن‌دار (Wij) به واحدهای لایهٔ بعدی متصل می‌گردد. شکل ۲، طرح شبکه عصبی مصنوعی مورد استفاده در این پژوهش را با تعداد سه نورون در یک لایه پنهان برای تخمین روی قابل دسترس خاک نمایش می‌دهد.

1- Multilayer perceptron neural networks, MLP



شکل (۱) موقعیت منطقه مطالعاتی در استان خوزستان، مدل رقومی ارتفاع و نقشه‌های خاک و کاربری اراضی منطقهٔ (۱۵)

Figure (1) Location of the study area in Khuzestan Province, along with the Digital Elevation Model (DEM), soil and land use maps of the area (15)



شکل(۲) طرح شبکهٔ عصبی مصنوعی پرسپترون چندلایه مورد استفاده در این مطالعه

Figure (2) A schematic of the multilayer perceptron artificial neural network used in this study

خروجی Y با انتقال خروجی‌های قبلی و انگاشت توسط یک تابع فعال‌سازی به‌دست می‌آید (۳۳). در این رابطه لارم به توضح است که از حدوداً ۷۰ درصد داده-های آزمایشی برای آموزش شبکه‌های عصبی و مابقی داده‌ها (حدوداً ۳۰ درصد) برای ارزیابی عملکرد آن‌ها استفاده شد.

ارزیابی و آنالیز حساست مدل

به‌منظور ارزیابی عملکرد شبکهٔ عصبی به‌کار گرفته‌شده در تخمین کلاس‌های مختلف روی قابل دسترس در منطقهٔ مطالعاتی، از منحنی مشخصهٔ عامل‌گیرنده[1] که از این پس به اختصار ROC خوانده می‌شود، استفاده گردید. نمودار ROC یک نمودار یا طرح گرافیکی است که با استفاده از میزان مثبت واقعی (حساسیت) بر روی محور x و میزان کاذب (بعد- ۱) بر روی محور y در آستانه‌های مختلف ایجاد می‌شود (۱۲). همچنین از این منحنی مقادیر مساحت زیر منحنی[2] (AUC) متناظر با هر کلاس استخراج و برای ارزیابی حساسیت مدل‌سازی‌ها استفاده گردید (جدول ۱).

مقادیر مساحت زیر نمودار به منزلهٔ معیاری برای قدرت تفکیک مدل در تشخیص کلاس‌ها هستند. نزدیکتر شدن منحنی به قطر، دقت کم مدل را نشان می‌دهد. قطر بیانگر حالت تصادفی است یعنی در هر آستانه‌ای شانس تخمین یک مثبت واقعی معادل یک مثبت کاذب است. مساحت زیر منحنی برابر با ۰/۵ نشان می‌دهد که مدل فاقد صحت است و مقدار برابر ۱ حاکی از صحت کامل مدل می‌باشد (۱۲).

کمی سازی اهمیت متغیرها

در این مطالعه از روش ارتباط وزنی بین لایه‌های ورودی (فراوانی رس، سیلت و شن، هدایت الکتریکی، واکنش خاک، محتوای کربن آلی و کربنات کلسیم معادل) و لایه(ها)ی پنهان و همچنین وزن بین لایه(ها)ی پنهان و لایه خروجی (روی قابل دسترس) برای کمی سازی اهمیت متغیرهای ورودی استفاده شده است (۱۲ و ۲۶). روش ارتباط وزنی بر پایه جمع حاصل‌ضرب‌های ارتباط بین وزن‌های هر نرون ورودی و خروجی در ارتباط با همه متغیرهای ورودی است (۲۹). کمی‌سازی اهمیت متغیرهای ورودی در محیط نرم‌افزار SPSS نسخه شماره ۲۶ انجام گردید.

1- Receiver Operating Characteristic, ROC
2- Area Under Curve

نتایج و بحث

توصیف آماری ویژگی‌های مورد بررسی

جدول ۲ توصیف آماری ویژگی‌های مورد بررسی در خاک‌های منطقه مطالعاتی را نشان می‌دهد. بر این اساس، میانگین مقادیر روی قابل دسترس ۲/۷۶ میلی‌گرم بر کیلوگرم به‌دست آمد. میانگین کربنات کلسیم معادل خاک‌ها ۴۲/۲۵٪ است. کمترین و بیش‌ترین اعداد ثبت شده برای کربنات کلسیم معادل خاک‌ها به ترتیب ۱۹/۵ و ۴۸/۸ درصد است و بر این اساس، خاک‌های محدوده مطالعاتی در گروه خاک‌های آهکی قرار دارند. همچنین، حداقل و حداکثر مقادیر pH اندازه‌گیری شده در نمونه‌های مورد بررسی، ۷/۱۸ و ۸/۹۳ می‌باشد. از این رو می‌توان گفت که خاک‌های منطقه با میانگین pH معادل ۷/۶۶ در گروه خاک‌های با واکنش بازی قرار می‌گیرند. میانگین کربن آلی در حدود ۱/۲۶٪ می‌باشد کم‌ترین و بیش‌ترین مقادیری که برای کربن آلی ثبت شده است، به ترتیب ۰/۰۹ و ۳/۶۷ درصد می‌باشد که با نتایج میرزاشاهی (۲۷) همخوانی دارد.

بررسی نتایج بافت خاک‌های منطقه مطالعاتی نیز نشان می‌دهد که خاک‌های منطقه به‌طور عمده در خانواده لوم قرار دارند. زیاد بودن میانگین مقادیر سیلت نسبت به باقی اجزاء بافت خاک و ضریب تغییرات بالای تمام پارامترهای بافت خاک را می‌توان به آبرفتی بودن خاک‌های منطقه، تنوع توپوگرافی و احتمالاً متفاوت بودن سازندهای زمین‌شناسی منطقه مطالعاتی نسبت داد (۴۰). از آن‌جایی که جزء سیلت نسبت به سایر اجزای بافت خاک حساسیت بیشتری به فرسایش آبی دارد، و با توجه به حضور رودهای کارون و زهره و جراجی در منطقه مطالعاتی و تاثیر وقوع سیلاب‌های این رودخانه‌ها بر جابجایی ذرات خاک، تغییرپذیری و محتوای بیشتر این جزء اندازه‌ای نسبت به بخش شن و رس خاک محتمل می‌باشد. وانگ و همکاران[1] (۳۷) نیز در مطالعه‌ای افزایش محتوای ذرات سیلت و رس خاک را پس از وقوع سیلاب‌های فصلی در منطقه‌ای در استان هوبی در کشور چین گزارش نمودند.

در میان ویژگی‌های مورد بررسی بیشترین ضریب تغییرات مربوط به شوری خاک (۱۳۱/۸۶) و کمترین آن مربوط به واکنش خاک (۴/۱۸) می‌باشد. تغییرات زیاد شوری خاک را نیز می‌توان به تنوع توپوگرافی، کیفیت متفاوت آب آبیاری، تفاوت در نحوهٔ مدیریت زراعی و البته وضعیت زهکشی راضی نسبت داد (۳۲). از سوی دیگر تغییرپذیری اندک واکنش خاک را می‌توان علیرغم شرایط اقلیمی نسبتاً متفاوت در بخش‌های شمالی، شرقی و شمال شرقی با دیگر بخش‌های واقع در منطقه مطالعاتی، با توجه به آهکی بودن ماهیت خاک‌های منطقه منبعث از وجود خاصیت بافری در این خاک‌ها دانست.

به‌منظور ارزیابی توزیع آماری متغیرهای مورد استفاده در این مطالعه از آزمون کولموگروف – اسمیرنوف استفاده شد (جدول ۳). در جدول ۳ مقادیر معنی‌داری بزرگتر از ۰/۰۵ نشان دهندهٔ این است که داده‌های آزمایشی از لحاظ آماری دارای توزیع نرمال می‌باشند (۵ و ۱۴). بر این اساس، در میان ویژگی‌های مورد بررسی تنها پارامتر سیلت از توزیع نرمال پیروی نموده و در رابطه با سایر متغیرها نیاز به نرمال‌سازی وجود داشت که با استفاده از توابع مناسب نرمال‌سازی شدند. هیستوگرام و نمودار Q-Q Plot داده‌های خام و نرمال‌شده مقادیر روی قابل دسترس از طریق روش IDF.Normal به عنوان نمونه در شکل ۳ آورده شده است.

بهینه‌ترین آرایش شبکهٔ عصبی

نتایج به‌کارگیری آرایش‌های مختلف شبکه‌های عصبی مصنوعی پرسپترون چندلایه در جدول ۴ نشان می‌دهد که مدل MLPSO7 با به‌کارگیری متغیرهای خاکی مورد استفاده در این پژوهش توانایی تفکیک کلاس‌های روی قابل دسترس با ۹۰/۸ درصد تخمین صحیح داده‌های آزمون و آرایش پایدار ۳ (تعداد کلاس‌های خروجی)– ۵ (تعداد نورون‌های لایه پنهان)– ۷

1- Wang *et al.*

(تعداد لایه‌های ورودی) و به‌کارگیری تابع سیگموئیدی برای توابع فعال‌ساز ورودی و خروجی بهترین عملکرد را در پیش‌بینی مقادیر روی قابل دسترس در نمونه خاک‌های مطالعه شده، دارد. وانگ و همکاران (۳۸) نیز به توانایی قابل قبول شبکه عصبی مصنوعی (R^2 = ۰/۹۳) برای پیش‌بینی فاکتور تجمع زیستی روی در اراضی شالیزاری مناطقی در مرکز و شرق استان گوانگژی در کشور چین با استفاده از ویژگی‌هایی مانند pH، محتوای کربن آلی، منگنز و روی کل خاک به عنوان متغیرهای پیش‌بینی کننده اشاره نمودند.

جدول (۱) معیار ارزیابی مقادیر AUC (۱۲)

Table (1) Evaluation criteria of AUC values (12)

کلاس (Class)	مساحت زیر منحنی (AUC) Area Under the Curve (AUC)
عالی (Excellent)	0.9-1.0
خوب (Good)	0.8-0.9
نسبتاً خوب (Moderately Good)	0.7-0.8
ضعیف (Poor)	0.6-0.7
بی فایده (Useless)	0.5-0.6

جدول(۲) توصیف آماری مقادیر اندازه‌گیری شدهٔ متغیرهای خاکی در محدودهٔ مطالعاتی

Table (2) Statistical description of the measured values of soil variables in the study area

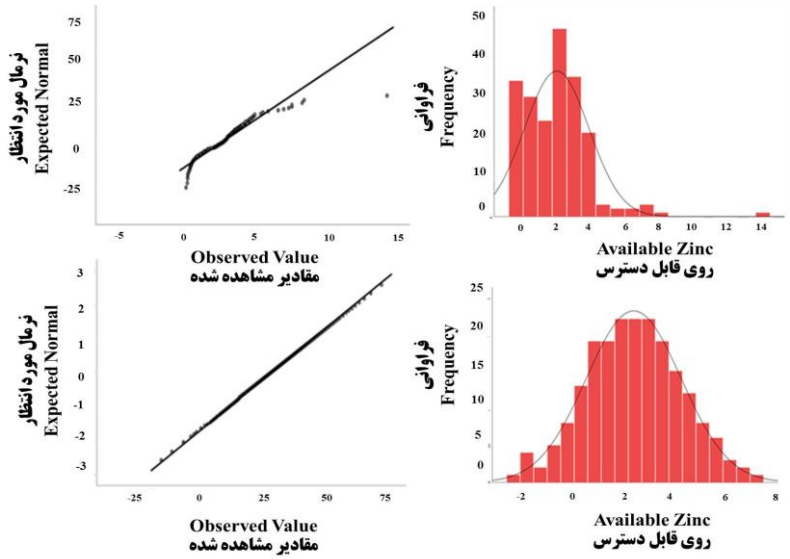
EC_e	pH	OC	Sand	Silt	Clay	CCE	Available Zn	شاخص‌های آماری (Statistics)
dS/m		(%)					mg/kg	
0.08	7.18	0.09	1.00	2.00	1.00	19.50	0.19	حداقل (Minimum)
35.20	8.93	3.67	88.00	80.00	74.00	49.88	14.23	حداکثر (Maximum)
4.55	7.66	1.26	26.72	42.37	30.87	42.25	2.76	میانگین (Mean)
2.50	7.62	1.14	24.00	43.00	32.00	42.88	2.83	میانه (Median)
6.00	0.32	0.71	16.16	15.07	12.03	5.52	1.85	انحراف معیار (Standard Deviation)
131.86	4.18	56.34	60.47	35.56	38.96	13.06	67.02	ضریب تغییرات (٪) Coefficient of Variation (%)
36.01	0.10	0.51	261.15	227.04	144.79	30.52	3.43	واریانس (Variance)
2.44	0.63	1.12	1.44	-0.12	0.14	-0.76	1.63	چولگی (Skewness)
6.72	1.16	1.49	2.57	0.28	0.77	1.14	6.94	کشیدگی (Kurtosis)
35.12	1.95	3.58	87.00	80.00	73.00	30.38	14.04	دامنه (Range)

EC: Electrical conductivity; OC: Organic carbon; CCE: Calcium carbonates equivalent

جدول (۳) نتایج آزمون Kolmogrov-Smirnov برای بررسی وضعیت توزیع نرمال داده‌های آزمایشی

Table (3) Results of the Kolmogrov-Smirnov test for normal distribution of experimental data

متغیر	مقدار معنی‌داری (Significance value)	
	داده‌های خام (Raw Data)	داده‌های نرمال شده (Normalized Data)
ECe	0.000	0.20
pH	0.001	0.08
OC	0.000	0.11
Sand	0.000	0.11
Silt	0.051	0.05
Clay	0.020	0.13
CCE	0.002	0.17
Avaible Zinc	0.001	0.20



شکل(۳) وضعیت توزیع نرمال مقادیر روی قابل دسترس در منطقه مطالعاتی. ردیف‌های بالا و پائین به‌ترتیب داده‌ها را قبل و پس از نرمال‌سازی نشان می‌دهد. همچنین، نمودارهای ارائه شده در سمت راست و چپ شکل به ترتیب هیستوگرام و نمودارهای احتمال نرمال را نشان می‌دهد.

Figure (3) Normal distribution of Zn availability in soils of the study area. The top and bottom rows display the data before and after normalization, respectively. The diagrams in right and left sides of the figure represent the histogram and normal probability plots, respectively.

مهمترین متغیرهای مدل‌سازی

شکل ۴ مهمترین متغیرهای خاکی به کاربرده شده در مدل سازی روی قابل دسترس را با استفاده از شبکهٔ عصبی مصنوعی نشان می‌دهد. بر این اساس، کربن آلی مهم‌ترین نقش را در ساخت مدل ایفا کرده است که این نقش پررنگ مدیون ارتباط تنگاتنگ مادهٔ آلی و روی قابل دسترس در فاز محلول خاک است. توجیه اهمیت زیاد این متغیر را می‌توان به نقش کربن آلی بر فراهمی ریزمغذی‌ها مربوط دانست. در واقع هوموس خاک که بخش اصلی مادهٔ آلی است منبعی از عناصر ریزمغذی در خاک است که سبب فراهمی روی می‌شود (۹ و ۱۳). از سوی دیگر، مادهٔ آلی با کاهش پتانسیل ریداکس سبب دسترسی بیشتر به ریزمغذی‌ها از جمله روی در فاز محلول خاک می‌شود (۷). دومین متغیر خاکی

مهم در این گروه، کربنات کلسیم معادل (CCE) می‌باشد. به‌طور کلی، با افزایش ترکیبات آهکی، مقدار روی قابل دسترس در فاز محلول خاک رو به کاستی می‌رود که دلیل عمدهٔ آن با توجه محتوای زیاد کربنات کلسیم معادل را می‌توان به جذب شیمیایی روی توسط کربنات‌کلسیم و رسوب آن با اکسیدهای آهن نسبت داد (۹ و ۱۴). سومین متغیر تاثیرگذار بر فراوانی روی قابل دسترس در خاک‌های منطقه مطالعاتی هدایت الکتریکی تشخیص داده شد. در مطالعه‌ای که حجتی و همکاران[1] (۱۶) نیز در رابطه با مدل‌سازی فسفر قابل جذب خاک‌های شمال استان خوزستان با استفاده از متغیرهای خاکی و بهره‌گیری از الگوریتم جنگل تصادفی انجام دادند، شوری خاک را به عنوان یکی از متغیرهای کلیدی و تاثیرگذار گزارش نمودند. کشاورز و همکاران[2] (۱۷) نشان دادند که با افزایش شوری مقدار روی قابل دسترس (عصاره‌گیری شده با DTPA) به طور معنی داری ($P>$ ۰/۰۵) افزایش می‌یابد. راویکوویچ و همکاران[3] (۳۰) نیز نشان دادند که فراهمی روی قابل دسنرس در خاک با افزایش مقدار شوری و به دلیل جایگزینی روی تبادلی با سدیم افزایش می‌یابد.

تحلیل ماتریس تخمین کلاس‌ها

جدول ۵ کلاس‌های روی قابل دسترس تخمین زده شده بر اساس آرایش بهینهٔ شبکه عصبی به کارگرفته شده در فرآیند مدل‌سازی (MLPSO7) را نشان می‌دهد. بر این اساس (جدول ۵) می‌توان بیان داشت که شبکهٔ عصبی به کاربرده شده توانسته است کلاس با غلظت کم روی قابل دسترس را نسبت به دیگر کلاس‌های روی قابل دسترس با صحت بیشتری تخمین بزند. همچنین متغیرهای خاکی توانسته‌اند با بیشترین صحت (۹۷/۴ برای داده‌های آموزش و ۹۷/۱ برای داده‌های آزمون) و دقت کلی ۹۰/۸ مقدار روی قابل دسترس خاک را در منطقهٔ مطالعاتی تخمین بزنند. از سویی دیگر کلاس با غلظت زیاد با ضعیف‌ترین تخمین‌ها روبرو شده است که به‌نظر می‌رسد از دلایل اصلی آن می‌توان به تعداد کم نمونه‌های مورد بررسی در این کلاس اشاره نمود. در واقع به دلیل تعداد کم این مشاهدات، مدل به خوبی قادر به شناسایی دقیق الگوهای این مشاهدات نبوده است. به‌طور مشابه، در مطالعاتی که ایوبی و همکاران[4] (۳) و وانگ و همکاران (۳۸) به ترتیب برای پیش‌بینی محتوای روی در دانه گندم برخی مزارع کشاورزی ایران و فاکتور تجمع زیستی روی در برخی اراضی شالیزاری کشور چین انجام دادند، کارایی شبکهٔ عصبی مصنوعی با به‌کارگیری متغیرهای خاکی به عنوان ورودی مورد تأیید قرار گرفت.

ارزیابی حساسیت تخمین‌ها با منحنی مشخصهٔ عامل گیرنده (ROC)

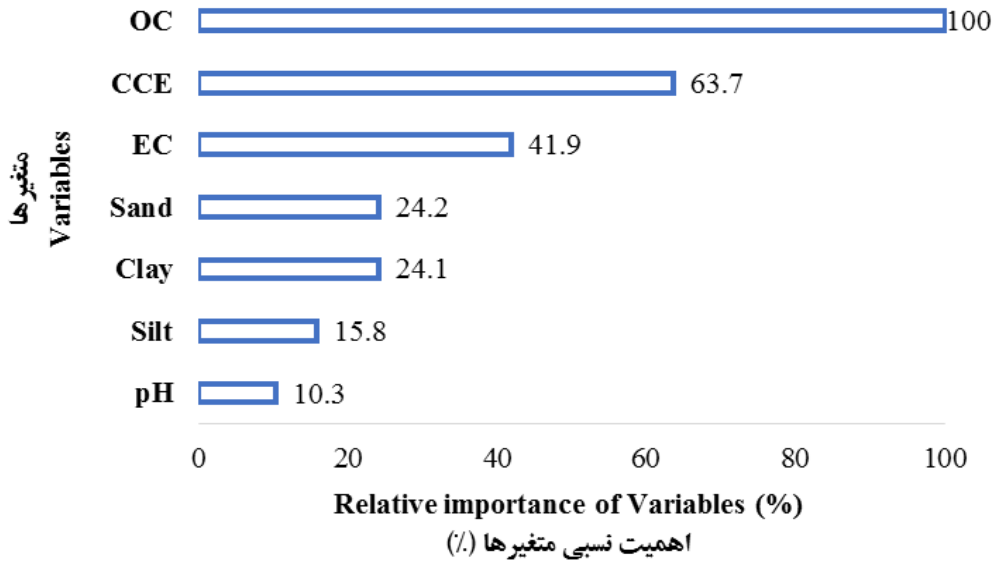
شکل ۵ منحنی مشخصه عامل گیرنده برای کلاس‌های مختلف روی قابل دسترس اعم از کم، متوسط و زیاد را در منطقه مطالعاتی نشان می‌دهد. بر این اساس، همان‌گونه که مشاهده می‌گردد در میان کلاس‌های روی قابل دسترس، منحنی‌های مشخصه عامل گیرنده در رابطه با کلاس‌های کم و متوسط نسبت به کلاس زیاد فاصله بیشتری را با قطر نشان می‌دهند که دلالت بر بهتر بودن مدل‌سازی کلاس‌های کم و متوسط روی قابل دسترس نسبت به کلاس زیاد با استفاده از الگوریتم شیکه عصبی مصنوعی به کاربرده شده در این پژوهش را نشان می‌دهد. همچنین، مقایسه مساحت زیر منحنی مشخصه عامل گیرنده (AUC) برای کلاس‌های کم (۹۴٪)، متوسط (۹۱٪) و زیاد (۷۵٪) روی قابل دسترس نیز نشان می‌دهد که مدل‌سازی کلاس‌های با غلظت کم و متوسط روی قابل دسترس نسبت به کلاس با غلظت زیاد روی قابل دسترس در منطقه مطالعاتی با حساسیت بیشتری صورت گرفته است. لین و همکاران[5] (۱۹) نیز به منظور ارزیابی کارایی مدل کریجینگ شاخص در مدل‌سازی پراکنش فلزات سرب، کروم، روی و نیکل مقادیر مساحت زیر منحنی مشخصه عامل گیرنده را در محدودهٔ ۰/۷۹ تا ۰/۸۳ گزارش نمودند. فاتحی و همکاران[6] (۸) نیز در مطالعه‌ای با هدف پهنه‌بندی احتمال کمبود و سمیت فسفر قابل جذب و کربن آلی، با استناد به مقادیر مساحت زیر منجنی مشخصه عامل گیرنده که در محدوده ۰/۷ تا ۰/۸ گزارش شد، به کارایی مناسب روش کریجینگ شاخص در برآورد مقادیر فسفر قابل جذب و کربن آلی اشاره نمودند.

1- Hojati *et al.*
2- Keshavarz *et al.*
3- Ravikovitch *et al.*
4- Ayoubi *et al.*
5- Lin *et al.*
6- Fatehi *et al.*

جدول (٤) آرایش بهینهٔ شبکهٔ عصبی مصنوعی پرسپترون چندلایه (MLP) استفاده شده برای پیش‌بینی کلاس‌های روی قابل دسترس

Table (4) The optimal arrangement of the MLP neural network model for predicting available zinc content in soils

نام مدل Model Name	درصد داده‌های آموزشی Calibration data (%)	درصد داده-های آزمون Validation data (%)	تعداد لایه‌های پنهان Number of hidden layers	تعداد نورون در لایه پنهان ۱ Number of neurons in the first hidden layer	تعداد نورون در لایه پنهان ۲ Number of neurons in the second hidden layer	تابع فعال ساز Input activation function	نوع تابع فعال ساز Output activation function	تخمین صحیح داده های آزمون (٪) Validation data correctly predicted (%)
MLPSO1	69.0	31.0	1	5	-	Tangant-Hyperbolic	Sigmoid	81.0
MLPSO2	61.6	38.4	2	5	4	Tangant-Hyperbolic	Sigmoid	88.5
MLPSO3	70.9	29.1	1	5	-	Tangant-Hyperbolic	Softmax	84.7
MLPSO4	67.0	33.0	2	5	4	Tangant-Hyperbolic	Softmax	89.6
MLPSO5	69.5	30.5	1	5	-	Tangant-Hyperbolic	Tangant-Hyperbolic	83.9
MLPSO6	63.1	36.9	2	5	4	Tangant-Hyperbolic	Tangant-Hyperbolic	77.3
MLPSO7	68.0	32.0	1	5	-	Sigmoid	Sigmoid	90.8
MLPSO8	70.0	30.0	2	5	4	Sigmoid	Sigmoid	85.2
MLPSO9	69.0	31.0	1	5	-	Sigmoid	Softmax	76.2
MLPSO10	97.2	27.1	2	5	4	Sigmoid	Softmax	78.2
MLPSO11	69.5	30.5	1	5	-	Sigmoid	Tangant-Hyperbolic	83.9
MLPSO12	71.4	28.6	2	5	4	Sigmoid	Tangant-Hyperbolic	82.8



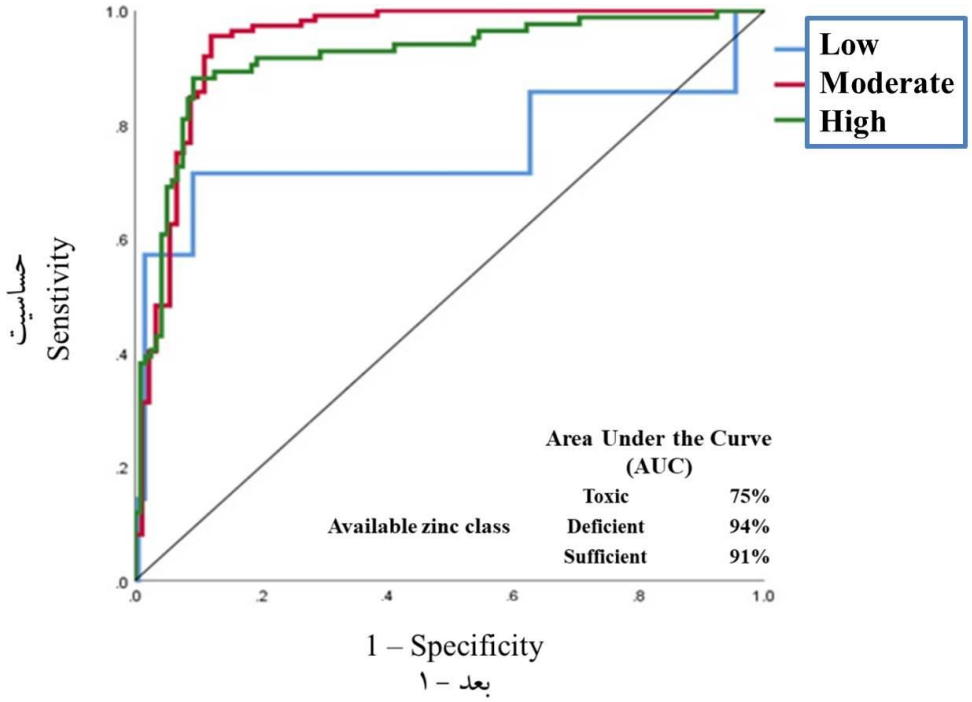
شکل(٤) مهم‌ترین متغیرهای خاکی به کاربرده شده در فرآیند مدل‌سازی روی قابل دسترس با شبکه عصبی مصنوعی

Figure (4) Important soil variables used for modeling available contents of Zn utilizing artificial neural network algorithm

جدول (٥) ماتریس تخمین کلاس‌های روی قابل دسترس توسط متغیرهای خاکی بر اساس آرایش بهینهٔ شبکهٔ عصبی استفاده شده

Table (5) The confusion matrix for estimating available zinc classes using soil variables based on the optimal architecture of the applied neural network

داده (Data)	مشاهده شده (Measured)	تخمین زده شده (Estimated)			
		زیاد (High)	کم (Low)	متوسط (Moderate)	صحیح تخمین‌شده (Correctly estimated)
آموزش (Calibration)	زیاد (High)	0	0	4	0
	کم (Low)	0	76	2	97.4
	متوسط (Moderate)	0	13	42	76.4
	درصد از کل (Percent of Total)	0	65.2	34.8	85.5
آزمون (Validation)	زیاد (High)	0	0	2	0
	کم (Low)	0	33	1	97.1
	متوسط (Moderate)	0	3	26	89.7
	درصد از کل (Percent of Total)	0	55.4	44.6	90.8



شکل (۵) منحنی مشخصه عامل گیرنده به‌دست آمده از مدل‌سازی روی قابل دسترس خاک در منطقهٔ مطالعاتی
Figure (5) Receiver Operating Characteristic curve for modeling DTPA extractable Zn in the study area

نتیجه‌گیری

در این مطالعه توانایی شبکه‌های عصبی مصنوعی در مدل‌سازی مقدار روی قابل دسترس با استفاده از متغیرهای خاکی که در مطالعات خاکشناسی به طور معمول اندازه-گیری می‌شوند، مورد بررسی قرار گرفت. بدین منظور ابتدا آرایش بهینه شبکه عصبی مصنوعی تعیین گردید و سپس با استفاده از الگوریتم بهینه (تعداد ۸ متغیر ورودی، یک لایه پنهان حاوی ۵ نورون و تابع فعال سازی سیگموئیدی در هر دو لایه ورودی و خروجی) مدل‌سازی روی قابل دسترس خاک انجام شد. نظر به تنوع توپوگرافیکی و وسعت منطقهٔ مطالعاتی می‌توان گفت که تخمین‌های انجام شده با استفاده از شبکه عصبی منتخب، انعطاف و کارایی خوبی برای توجیه مقادیر روی قابل دسترس در منطقهٔ مطالعاتی را داشته است. در میان متغیرهای خاکی مورد استفاده در مدل سازی توجه به نقش عمدهٔ مادهٔ آلی و فراوانی ترکیبات آهکی و املاح خاک بسیار حائز اهمیت است. از نکات مهم و جالب این مطالعه اهمیت بیشتر هدایت الکتریکی نسبت به جزء رس خاک در فرآیند مدل‌سازی است که اهمیت مسئلهٔ شوری خاک را برای تامین روی قابل دسترس برای مطالعات آتی در مقیاس‌های بزرگ را برجسته می‌کند.

سپاس گزاری

هزینه اجرای این پژوهش توسط معاونت پژوهشی، فناوری و ارتباط با جامعه دانشگاه شهید چمران اهواز (پژوهانه شماره SCU.AS1399.365) پرداخت شده است.

References

1. Abyat, A., Azhdari, A., Joudaki, M., and Darvishi Khatoni, J. 2017. Study and separation of Quaternary sedimentary environments in Khuzestan plain. Advanced Applied Geology, *7*(3), 49-64. https://doi.org/10.22055/AAG.2017.21931.1702

2. Alloway, B.J. 2008. Zinc in soils and crop nutrition. Second edition, published by IZA and IFA, Brussels, Belgium and Paris, France.

3. Ayoubi S., Mehnatkesh A., Jalalian A., Sahrawat K.L., and Gheysari M. 2014. Relationships between grain protein, Zn, Cu, Fe and Mn contents in wheat and soil and topographic attributes. Archives of Agronomy and Soil Science, 60 (5), 625-638. https://doi.org/10.1080/03650340.2013.825899

4. Banaei, M.H. 1998. Maps of soils moisture and temperature regimes in Iran. Soils and Water Research Institute, Tehran, Iran.

5. Berger, V.W., and Zhou, Y. 2014. Kolmogorov–Smirnov test: Overview. *Wiley Statsref: Statistics reference online*. https://doi.org/10.1002/9781118445112.stat06558

6. Bouasria, A., Ibno Namr, K., Rahimi, A., Ettachfini, E. M., and Rerhou, B. 2022. Evaluation of Landsat 8 image pansharpening in estimating soil organic matter using multiple linear regression and artificial neural networks. Geo-spatial Information Science, 25, 353-364. https://doi.org/10.1080/10095020.2022.2026743

7. Dhaliwal, S. S., Naresh, R. K., Mandal, A., Singh, R., and Dhaliwal, M. K. 2019. Dynamics and transformations of micronutrients in agricultural soils as influenced by organic matter build-up: A review. Environmental and Sustainability Indicators, 1, 100007. https://doi.org/10.1016/j.indic.2019.100007

8. Fatehi, Sh., Kafashi, A.K., and Ahmadi, Gh.H. 2017. Probability mapping of deficiency or excess of soil available phosphorus and organic carbon by indicator kriging. Applied Soil Research 5(1), 67-78.

9. Foth, H., and Ellis, B. 1997. Soil Fertility. United Kingdom, CRC Press, 290p. https://doi.org/10.1201/9780203739341

10. Gee, G.W., and Bauder, J. W. 1982. Particle-Size Analysis. In Klute, A. (Ed.), pp. 383-411. Methods of Soil Analysis. Part 1: Physical and Mineralogical Properties, 2nd edition. Agron. Monogr.9. ASA and SSSA, Madison, WI, USA.

11. Geng, W., Li, T., Zhu, X., Dou, L., Liu, Z., Qian, K., Ye, G., Lin, K., Li, B., Ma, X., Hou, Q., Yu, T., and Yang, Z. 2025. Predicting the zinc content in rice from farmland using machine learning models: Insights from universal geochemical parameters. Applied Sciences 15, 1273. https://doi.org/10.3390/app15031273

12. Hanley, J. A. 1989. Receiver operating characteristic (ROC) methodology: the state of the art. Critical Review in Diagnostic Imaging, 29(3), 307-335. https://doi.org/10.1002/9781118445112.stat05255

13. Havlin, J. L. 2020. Landscape and Land Capacity. In: Wang, Y. (Ed.), Soil: Fertility and nutrient management. In *Landscape and Land Capacity*. 2nd Edition, CRC Press, Boca Raton, pp. 251-265. https://doi.org/10.1201/9780429445552

14. Hazelton, P., and Murphy, B. 2016. *Interpreting soil test results: What do all the numbers mean?* CSIRO publishing. https://doi.org/10.1071/9781486303977

15. Hojati, S. 2018. Spatial variability of selected heavy metals in surface soils of northern Khuzestan Province. Project No. 93021034, Iran National Science Foundation, Tehran, Iran, 133 pages.

16. Hojati, S., Norouzi Masir, M., and Biswas, A. 2022. Modeling distribution of available phosphorous contents in surface soils of northern Khuzestan Province using linear and random forest models. Iranian Journal of Soil and Water Research 53 (6), 1331-1344. http//doi.org/10.22059/ijswr.2022.342792.669262

17. Keshavarz, P., Malakouti, M.J., Karimian, N., and Fotovat, A. 2006. The effects of salinity on extractability and chemical fractions of Zn in selected calcareous soils of Iran. Journal of Agricultural Science and Technology, 8, 181-190. http//doi.org/20.1001.1.16807073.2006.8.2.2.2

18. Kohli, S., Miglani, S., and Rapariya, R. 2014. Basics of artificial neural network. International Journal of Computer Science and Mobile Computing, *3*(9), 745-751.

19. Lin Y.P., Cheng B.Y., Shyu G.S., and Chang T.K. 2010. Combining a finite mixture distribution model with indicator kriging to delineate and map the spatial patterns of soil heavy metal pollution in Chunghua County, central Taiwan. Environmental Pollution, 158: 235–244. https://doi.org/10.1016/j.envpol.2009.07.015

20. Lindsay, W.L., and Norvel, W.A. 1979. Development of a DTPA as a soil response investigation of Mn+ 2 complexation in natural and synthetic organics. Soil Science Society of America Journal, 46, 1137-1143. https:// doi.org/ 10. 2136/sssaj1978. 03615995004200030009x

21. Ljung, L., and Glad, T. 1994. Modeling of dynamic systems. Prentice-Hall, Inc., 361p. https://doi.org/ 10.1016/0967-0661(95)90022-5

22. Loeppert, R.H., and Suarez, D.L. 1996. Carbonate and Gypsum. In: Sparks, D.L., Page, A.L., Helmke, P.A., Loeppert, R.H., Soltanpour, P.N., Tabatabai, M.A., Johnston, C.T., and Sumner, M.E. (Eds.), pp. 437-474. Methods of Soil Analysis. Part 3. Chemical Methods, ASA and SSSA, Madison, WI, USA.

23. Lowe, N.M., Hall, A.G., Broadley, M.R., Foley, J., Boy, E., and Bhutta, Z.A. 2024. Preventing and controlling zinc deficiency across the life course: A call to action. Advances in Nutrition, 15, 100181. https://doi.org/10.1016/j.advnut.2024.100181

24. Mahmoudzadeh, H., Matinfar, H.R., and Taghizadeh-Mehrjerdi, R. 2021. Digitization of soil organic carbon with artificial neural network and multivariate linear regression in Kurdistan province. Journal of Soil Management and Sustainable Production 10(4), 77-98. https://doi.org/10.22069/EJSMS.2021.18090.1958

25. Masoudnia, Sh., and Soleimani, A. 2013. The role of zinc in health and disease. Feyz Medical Science Journal 16(7), 771-772.

26. Mir, H., Gholamalizadeh Ahangar, A., and Shabani, A. 2016. Determination of the most important soil parameters affecting the availability of phosphorous in Sistan Plain, using connection weight method in neural networks. Journal of Water and Soil, 29 (6), 1674-1687. https://doi.org/10.22067/jsw.v29i6.39564

27. Mirzashahi, K. 2017. Periodic study of soil organic carbon in plains of Khuzestan and providing extensions. Land Management 5(1), 1-12. https://doi.org/10.22092/LMJ.2017.113290

28. Nelson, D.W., and Sommers, L. 1982. Total carbon, organic carbon, and organic matter. In: Page, A.L., (Ed.), Methods of soil analysis. Part 2: Chemical and microbiological properties, pp. 539-579. American Society of Agronomy and Soil Science Society of America, Madison, WI, USA.

29. Olden, J.D., Joy, M.K., and Death, R.G. 2004. An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data. Ecological Modeling, 178, 389-397. https://doi.org/10.1016/S0304-3800(04)00156-5

30. Ravikovitch, S., Margolin, M., and Navrot, J. 1968. Zinc Availability in Calcareous Soils: I. Comparison of Chemical Extraction Methods for Estimation of Plant Availability Zinc. Soil Science, 105, 57-61.

31. Rhoades, J.D., 1986. Soluble salts. In: Page, A.L., Miller, R.H., and Keeny, D.R. (Eds.), pp. 167–180. Methods of Soil Analysis, Part 2. Chemical and Microbiological Properties, second ed. ASA and SSSA, Madison, WI, USA.

32. Savari, Z.., Hojati, S., and Taghizadeh Mehrjerdi, R. 2021. Digital mapping of surface soil salinity in Khuzestan Province, using regression kriging. Journal of Water and Soil Science 25(3), 159-175. https://doi.org/10.47176/jwss.25.3.24654

33. Sekula, K., Karlowska-Pik, J., and Kmiecik, E. 2023. The use of artificial neural networks in the determination of soil grain composition. Stochastic Environmental Research and Risk Assessment, 37, 3797-3805. https://doi.org/10.1007/s00477-023-02480-7

34. Shahbazi, K., and Besharati, H. 2013. Overview of agricultural soil fertility status in Iran. Land Management, 1(1), 1-15. https://doi.org/10.22092/LMJ.2013.100072

35. Sharifi, M. 2014. Land use planning studies of Khuzestan province. Urban Planning and Architecture Studies and Research Center, Tehran, Iran, 461p.

36. Soleimani, R., Chavoshi, E., Shirani, H., and Esfandiar Pour, I. 2020. Comparison of stepwise multilinear regressions, artificial neural network, and genetic algorithm-based neural network for prediction the plant available water of unsaturated soils in a semi-arid region of Iran (case study: Chaharmahal Bakhtiari province). Communications in Soil Science and Plant Analysis 51(17), 2297-2309. https://doi.org/10.1080/ 00103624.2020.1822385

37. Wang, Y., Chen, F., Zhang, M., Chen, S., Tan, X., Liu, M., and Hu, Z. 2018. The effects of the reverse seasonal flooding on soil texture within the hydro-fluctuation belt in Three Gorges reservoir, China. Journal of Soils and Sediments 18, 109-115. https://doi.org/10.1007/s11368-017-1725-1

38. Wang, Y., Yu, T., Yang, Z., Bo, H., Lin, Y., Yang, Q., Liu, X., Zhang, Q., Zhuo, X., and Wu, T. 2021. Zinc concentration prediction in rice grain using back-propagation neural network based on soil properties and safe utilization of paddy soil: A large-scale field study in Guangxi, China. Science of the Total Environment 798, 149270. https://doi.org/10.1016/j.scitotenv.2021.149270

39. Yazdaninejhad, F., Torabi, H., and Davatgar, N. 2014. Mapping of available Fe, Zn, Cu and Mn in soils of southern Tehran lands by geostatistical and GIS techniques. Iranian Journal of Soil and Water Research 44(4), 383-395. https://doi.org/10.22059/IJSWR.2013.50411

40. Yin, G., Chen, X., Zhu, H., Chen, Z., Su, C., He, Z., Qiu, J., and Wang, T. 2022. A novel interpolation method to predict soil heavy metals based on a genetic algorithm and neural network model. Science of the Total Environment 825, 153948. https://doi.org/10.1016/j.scitotenv.2022.153948