



Prediction of Copper and Manganese Concentration in Citrus Leaves Using Artificial Neural Networks and Stepwise Regression (Case Study: Orchards of Southern Kerman Province)

Saber Heidari^{1*}  and Seyed Ali Ghaffari Nejad² 

1- Soil and Water Research Department, South Kerman Agricultural and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization (AREEO), Jiroft

2- Soil and Water Research Institute, Agricultural Research, Education and Extension Organization (AREEO), Karaj

* Corresponding author, Email: s.heydari@areeo.ac.ir

(Received: 3 May 2025; Revised: 26 July 2025; Accepted: 3 August 2025)

Abstract

Background and Objective: The availability of micronutrients such as copper (Cu) and manganese (Mn) in high-pH calcareous soils is a key challenge for sustainable citrus production in arid and semi-arid regions. This research was conducted to predict the concentration of these elements in citrus leaves in southern Kerman and identifying the most influential soil properties affecting their availability.

Methods: Samples were collected from 40 orchards, with a focus on both soil and leaf samples taken during the spring growth season. We used standard methods to analyze soil properties and measure Cu and Mn concentrations in the leaves.

Results: High soil pH significantly hindered nutrient absorption, as the leaf Cu and Mn showed negative correlation coefficients of -0.41 and -0.33 with pH, respectively. However, the leaf Cu was positively correlated with both clay content ($r = 0.32$) and organic carbon (OC) content ($r = 0.39$), while the leaf Mn exhibited a negative correlation with soil salinity, EC ($r = -0.29$). Stepwise regression selected the soil pH, clay, and phosphorus as predictors for the leaf Cu ($R^2 = 0.36$), and pH and EC as predictors for the leaf Mn ($R^2 = 0.28$). To overcome the limitation of linearity, a multilayer perceptron artificial neural network (ANN) was developed using the Levenberg-Marquardt algorithm with a 70/30 training/testing ratio. The best ANN model for the leaf Cu, with inputs of soil pH, OC, clay, and phosphorus and 10 hidden neurons, achieved an $R^2 = 0.78$ and RMSE = 0.88 mg kg^{-1} in the testing phase. For predicting leaf Mn, a network with inputs of soil pH, OC, clay, phosphorus, and EC and 11 hidden neurons achieved an $R^2 = 0.66$ and RMSE = 5.68 mg kg^{-1} .

Conclusion: The ANN models reduced prediction error by 42 and 38% for the leaf Cu and Mn compared to the regression model, respectively. This significant improvement demonstrates that artificial intelligence can be an effective tool for creating precise fertilization plans and ultimately enhancing the productivity of citrus orchards in these challenging environments.

Keywords: Machine learning, Soil properties, Calcareous soils, Nutrient management, Soil organic carbon.

How to Cite: Heidari, S., Ghaffari Nejad, S.A., 2025. Prediction of copper and manganese concentration in citrus leaves using artificial neural networks and stepwise regression (case study: orchards of southern Kerman province). J. Soil Plant Interact. 16(2), 61–78 (In Persian with English abstract). <https://doi.org/10.47176/jspi.16.2.21641>





پیش‌بینی غلظت مس و منگنز در برگ مرکبات با استفاده از شبکه‌های عصبی مصنوعی و رگرسیون گام‌به‌گام (مطالعه موردی: باغ‌های جنوب استان کرمان)

صابر حیدری^{۱*} و سید علی غفاری نژاد^۲

۱- بخش تحقیقات خاک و آب، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی جنوب استان کرمان، سازمان تحقیقات، آموزش و ترویج کشاورزی، جیرفت، ایران

۲- موسسه تحقیقات خاک و آب، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران

* مسئول مکاتبات، پست الکترونیکی: s.heydari@areeo.ac.ir

(تاریخ دریافت: ۱۴۰۴/۲/۱۳؛ تاریخ بازنگری: ۱۴۰۴/۵/۴؛ تاریخ پذیرش: ۱۴۰۴/۵/۱۲)

چکیده

پیشینه پژوهش و هدف: فراهمی عناصر کم‌مصرف مانند مس (Cu) و منگنز (Mn) در خاک‌های آهکی با pH زیاد، یکی از چالش‌های کلیدی در تولید پایدار مرکبات در مناطق خشک و نیمه‌خشک است. این پژوهش با هدف پیش‌بینی غلظت این عناصر در برگ مرکبات جنوب کرمان و شناسایی مؤثرترین ویژگی‌های خاک بر فراهمی آن‌ها انجام شد.

روش‌ها: بدین منظور از ۴۰ باغ مرکبات نمونه‌های مرکب خاک همراه با برگ‌های رشد بهاره برداشت شد و با روش‌های استاندارد ویژگی‌های خاک و غلظت Cu و Mn برگ اندازه‌گیری شد.

نتایج: نتایج نشان داد که pH زیاد خاک به‌طور قابل‌توجهی مانع جذب عناصر غذایی می‌شود، به‌طوری‌که Cu و Mn برگ به‌ترتیب ضرایب همبستگی ۰/۴۱- و ۰/۳۳- با pH خاک نشان دادند. همچنین ضرایب همبستگی Cu برگ با مقدار رس ۰/۳۲ و با کربن آلی (OC) ۰/۳۹ بود، در حالی‌که Mn برگ همبستگی منفی با شوری خاک (EC) با ضریب ۰/۲۹ نشان داد. رگرسیون گام‌به‌گام متغیرهای pH، رس و فسفر خاک را به‌عنوان تخمین‌گرهای Cu برگ ($R^2 = 0.36$) و pH و EC را به‌عنوان تخمین‌گرهای Mn برگ ($R^2 = 0.28$) برگزید. برای غلبه بر محدودیت خطی بودن، شبکه عصبی مصنوعی (ANN) پرسپترون چندلایه با الگوریتم لونیگ-مارکواریت و نسبت آموزش/آزمون ۳۰/۷۰ توسعه یافت. بهترین مدل ANN برای Cu برگ با ورودی‌های pH، OC، رس و فسفر خاک و ۱۰ نورون پنهان در مرحله آزمون به $R^2 = 0.78$ و $RMSE = 0.88 \text{ mg kg}^{-1}$ رسید؛ برای پیش‌بینی Mn برگ شبکه‌ای با ورودی‌های pH، OC، رس، فسفر و EC خاک و ۱۱ نورون پنهان به $R^2 = 0.66$ و $RMSE = 5.68 \text{ mg kg}^{-1}$ حاصل کرد. **نتیجه‌گیری کلی:** کاهش ۴۲ و ۳۸ درصدی خطا به‌ترتیب در پیش‌بینی غلظت Cu و Mn توسط مدل‌های ANN نسبت به مدل رگرسیون نشان داد که مدل‌های هوش مصنوعی با لحاظ تعامل‌های غیرخطی می‌توانند ابزار کارآمدی برای برنامه‌ریزی کوددهی و ارتقای بهره‌وری باغ‌های مرکبات این مناطق باشند.

واژه‌های کلیدی: یادگیری ماشین، ویژگی‌های خاک، خاک‌های آهکی، مدیریت تغذیه، کربن آلی خاک.



مقدمه


استان کرمان، به‌ویژه مناطق جیرفت و کهنوج، از مناطق مناسب برای تولید مرکبات در کشور محسوب می‌شود. این منطقه با تولید سالانه حدود ۵۰۰ هزار تن مرکبات، رتبه سوم را در ایران به خود اختصاص داده و از اقلیم و خاک مناسبی برای این منظور برخوردار است. در میان ارقام مختلف، رقم والنسیا (*Citrus sinensis* var. *Valencia*) بیشترین سطح زیر کشت را به خود اختصاص داده است. با وجود این پتانسیل بالا برای تولید، خاک‌های این منطقه اغلب به‌دلیل ماهیت آهکی و قلیایی، با چالش‌هایی در فراهمی برخی عناصر ریزمغذی ضروری برای مرکبات مواجه هستند (Sarhadi et al., 2020). در چنین شرایطی، جذب عناصر کم‌مصرف مانند مس (Cu) و منگنز (Mn) توسط ریشه محدود شده و این امر می‌تواند به یکی از موانع اصلی برای دستیابی به عملکرد مطلوب تبدیل شود (Ahmad et al., 2022). عناصر غذایی کم‌مصرف (ریزمغذی‌ها) برای رشد و عملکرد بهینه مرکبات ضروری هستند. در این میان، مس در فرآیندهای آنزیمی حیاتی مانند فتوسنتز و تنفس نقش دارد و منگنز برای فعال‌سازی آنزیم‌ها و فتوسنتز کلیدی است (Giannakoula et al., 2021). کمبود هر یک از این ریزمغذی‌ها می‌تواند تأثیر منفی بر سلامت گیاهان بگذارد و باعث کاهش رشد، عملکرد و کیفیت میوه شود. اگرچه پژوهش‌های پیشین به بررسی آثار فیزیولوژیک مس و سایر عناصر بر مرکبات پرداخته‌اند، اما اغلب آن‌ها بر توسعه مدل‌های پیش‌بینی برای جذب مواد مغذی متمرکز نبوده‌اند (Giannakoula et al., 2021). این در حالی است که فراهمی زیستی مس و منگنز در خاک به شدت تحت تأثیر ویژگی‌های فیزیکی و شیمیایی آن مانند pH، کربن آلی (OC)، بافت و شوری خاک قرار دارد (Senkondo et al., 2014; De Silva et al., 2020). بنابراین، مدل‌سازی این روابط پیچیده برای مدیریت دقیق تغذیه ضروری است.

بررسی روابط میان ویژگی‌های شیمیایی و فیزیکی محیط رشد یک گیاه و چگونگی جذب عناصر مورد نیاز آن، می‌تواند به درک و طراحی بهینه‌تری از محیط رشد برای گیاه منجر شود.

به همین دلیل، ابزارهای آماری و ریاضی همچون رگرسیون خطی، رگرسیون لجستیک و مدل‌های ترکیبی این دو، می‌توانند در این زمینه به کار گرفته شوند (Dayhoff and DeLeo, 2001). روش‌های آماری سنتی مانند رگرسیون گام‌به‌گام می‌توانند برای شناسایی مهم‌ترین متغیرهای خاک مؤثر بر جذب عناصر غذایی به کار روند. برای نمونه، (Senkondo et al., 2014) از این روش برای شناسایی عوامل مؤثر بر غلظت مس در برگ موز استفاده کردند. با این حال، این مدل‌های خطی در توصیف کامل برهم‌کنش‌های پیچیده و غیرخطی میان ویژگی‌های خاک و جذب عناصر، که در سیستم‌های بیولوژیک رایج است، با محدودیت مواجه هستند.

برای غلبه بر این محدودیت‌ها، امروزه از ابزارهای یادگیری ماشین مانند شبکه‌های عصبی مصنوعی (ANN) استفاده می‌شود. شبکه‌های عصبی قادرند روابط پیچیده و غیرخطی بین مجموعه‌ای از متغیرهای ورودی (مانند ویژگی‌های خاک) و خروجی (غلظت عنصر در برگ) را با دقت زیادی مدل‌سازی کنند. معماری چندلایه‌ای و توابع فعال‌سازی غیرخطی در ANN به این مدل اجازه می‌دهد تا الگوهای پیچیده‌ای را که رگرسیون خطی قادر به شناسایی آن‌ها نیست، کشف و مدل‌سازی کند (Hosseini-fard et al., 2019). همچنین مدل‌های ANN توانایی زیادی در ادغام و پردازش هم‌زمان چندین متغیر ورودی داشته و می‌توانند آثار برهم‌کنش و چندبعدی آن‌ها را در نظر بگیرند. پژوهش‌های اخیر نیز پتانسیل زیاد ANN را در تحلیل داده‌های پیچیده کشاورزی، از جمله طبقه‌بندی برگ مرکبات بر اساس عناصر تشکیل‌دهنده (Maione et al., 2017) و پیش‌بینی غلظت آهن در برگ مرکبات (Heidari et al., 2024a) نشان داده‌اند. از این رو، مدل‌سازی با ANN رویکردی امیدوارکننده برای بهینه‌سازی مدیریت مواد مغذی ارائه می‌دهد.

در مقابل، رگرسیون گام‌به‌گام به‌دلیل اتکا به روابط خطی، ناگزیر به ساده‌سازی این روابط است و متغیرهایی را که آثار غیرخطی یا برهم‌کنشی دارند، نادیده می‌گیرد. با این حال، باید اذعان داشت که این دقت زیاد در ANN به قیمت کاهش قابلیت



شکل ۱. موقعیت نقاط نمونه برداری در منطقه مورد بررسی

Fig. 1. The location of the sampling points in the studied region

مواد و روش ها

مشخصات منطقه مورد بررسی

منطقه مورد بررسی با مختصات جغرافیایی طول $۵۶^{\circ} ۱۷'$ و عرض $۲۶^{\circ} ۴۳'$ ، در ناحیه جنوب شرقی ایران واقع شده است. این محدوده از شمال به کرمان، از جنوب به تالاب جازموریان و استان هرمزگان و از شرق به استان سیستان و بلوچستان و بم محدود می شود. منطقه مورد بررسی هفت شهر جیرفت، کهنوج، عنبرآباد، منوجان، رودبار جنوب، قلعه گنج و فاریاب را در بر می گیرد. موقعیت نقاط نمونه برداری در شکل ۱ نشان داده شده است.

نمونه برداری از خاک و گیاه

در این پژوهش، ۴۰ باغ مرکبات مختلف از رقم والنسیا (*Citrus sinensis* var *Valencia*) و با سن درختان بیش از ۱۰ سال در منطقه انتخاب شدند. از هر باغ با استفاده از اوگر، ۱۰ نمونه خاک در دو لایه مختلف (۰ تا ۳۰ و ۳۱ تا ۶۰ سانتی متر) از سایه انداز (یک سوم انتهایی) درختان جمع آوری شد. پس از ترکیب ۱۰

تفسیر مدل تمام می شود. در حالی که معادله رگرسیون یک بینش مستقیم و قابل فهم از رابطه متغیرها ارائه می دهد، ANN به صورت یک مدل جعبه سیاه^۱ عمل می کند که تفسیر سازوکارهای درونی آن دشوار است (Patel et al., 2022). بنابراین، انتخاب ANN در این پژوهش، یک موازنه آگاهانه بین سادگی تفسیر و قدرت پیش بینی بود که با توجه به پیچیدگی سیستم مورد بررسی و دقت زیاد ANN، این مدل برای کاربردهای عملی در مدیریت تغذیه باغ ها برتری یافت.

با توجه به چالش های ذکر شده، این پژوهش با هدف توسعه و اعتبارسنجی یک مدل هوشمند و دقیق برای پیش بینی غلظت مس و منگنز در برگ مرکبات بر پایه ویژگی های قابل اندازه گیری خاک است. اهداف مشخص این پژوهش عبارتند از: ۱- شناسایی و رتبه بندی تأثیرگذارترین ویژگی های فیزیکی و شیمیایی خاک بر فراهمی عناصر مس و منگنز، و ۲- مقایسه کارایی و دقت یک مدل پیشرفته غیرخطی (ANN) در برابر یک مدل آماری رایج (رگرسیون گام به گام) به منظور نمایش برتری روش های هوشمند در تحلیل روابط پیچیده خاک-گیاه.

1- Black box model

آماري آنها پس از هر مرحله، ارزیابی می‌گردد. در این روش، ترکیب بهینه‌ای از متغیرهای مستقل که بهترین هم‌خوانی را با متغیر وابسته دارند، شناسایی می‌شود (Hosseinpour et al., 2018). فرمول رگرسیون گام‌به‌گام به صورت زیر است:

$$y = a + bx_1 + cx_2 + \dots \quad (1)$$

که در این رابطه، y خروجی مدل، x_1 ، x_2 و ... متغیرهای ورودی مدل و a ، b ، c و ... ثابت‌های مدل هستند.

شبکه عصبی مصنوعی (ANN)

مدل شبکه عصبی مصنوعی (ANN) در دو مرحله اصلی عمل می‌کند (i): یادگیری از محیط و (ii) استفاده از ارتباطات بین نوروها برای پردازش دانش به‌دست‌آمده (Patel et al., 2022). این فرآیند شامل پنج مرحله اساسی است: انتخاب داده‌های ورودی، انتخاب معماری مناسب، طراحی شبکه عصبی، فرآیند آموزش و آزمون، و ارزیابی نهایی مدل (Sahoo and Jha, 2013). به طور معمول، یک شبکه عصبی مصنوعی از سه لایه تشکیل می‌شود: لایه ورودی، لایه خروجی و لایه‌های پنهان که به‌عنوان یک پل بین ورودی و خروجی عمل می‌کنند (Feng et al., 2019). شبکه‌های عصبی مصنوعی از راه یک فرآیند آموزشی به‌طور خودکار توانایی پردازش داده‌ها را کسب می‌کنند که در آن وزن‌های اتصالات لایه‌های شبکه به‌طور تصادفی اصلاح می‌شوند تا خروجی شبکه به پاسخ‌های واقعی نزدیک‌تر گردد (Sihag et al., 2020). در این پژوهش، از یک شبکه عصبی پیش‌خور با روش آموزش پس‌انتشار خطا استفاده شد. ساختار کلی مدل ANN در شکل ۲ نمایش داده شده است.

برای انتخاب بهترین مدل ANN، مدل‌های مختلفی با تعداد متفاوتی از ورودی‌ها (بین ۱ تا ۷ ورودی) و یک متغیر خروجی در سناریوهای مختلف طراحی شدند. سازوکار انتخاب متغیرهای ورودی برای مدل‌سازی بر دو اصل کلیدی استوار بود. نخست، تمرکز بر ویژگی‌های زودبافت و کم‌هزینه خاک (مانند pH، مقدار ماده آلی و بافت)، تا مدل نهایی کاربرد عملی در کشاورزی دقیق داشته باشد. دوم، با توجه به توانایی شبکه عصبی در کشف


نمونه خاک، یک نمونه مرکب یک کیلوگرمی از هر باغ و هر لایه تهیه شد. برای اندازه‌گیری ویژگی‌های فیزیکی و شیمیایی، نمونه‌های خاک پس از خشک‌شدن در هوا، خردشدن و عبور از الک ۲ میلی‌متری، با روش‌های استاندارد مورد آزمایش قرار گرفتند. بافت خاک (درصد شن، سیلت و رس) به روش هیدرومتری تعیین شد (Gee and Bauder, 1986). pH و رسانایی الکتریکی (EC) در عصاره اشباع خاک اندازه‌گیری شد (Allison and Richards, 1954). درصد کربن آلی (OC) خاک با روش اکسیداسیون تر والکلی-بلک (Nelson and Sommers, 1983) و درصد کربنات کلسیم معادل (CCE) با روش تیتراسیون برگشتی اسید-باز (Rowell, 2014) تعیین شد. همچنین، فسفر فراهم خاک با روش اولسن استخراج شده و مقدار آن توسط دستگاه اسپکتروفتومتر در طول موج ۸۸۰ نانومتر خوانده شد (Olsen, 1954).

برای نمونه‌برداری از برگ، در هر باغ ۲۰ درخت به صورت تصادفی انتخاب شد. در اواخر تابستان (شهریور ماه) سال ۱۴۰۱، از هر درخت تعداد ۵ برگ از شاخه‌های غیرثمر با رشد بهاره که ۴ تا ۶ ماه سن داشتند، جمع‌آوری شد. این نمونه‌ها از چهار جهت جغرافیایی درخت و از ارتفاع ۱/۵ تا ۲ متری از سطح زمین انتخاب شدند. سپس برگ‌های جمع‌آوری‌شده از هر ۲۰ درخت با یکدیگر ترکیب شده و یک نمونه‌ی مرکب برای هر باغ تهیه شد (Asadi Kangarshahi et al., 2019). نمونه‌های برگ پس از انتقال به آزمایشگاه، ابتدا با آب مقطر شستشو داده شد و سپس برای خشک‌شدن به مدت ۷۲ ساعت در آون با دمای ۷۰ درجه سلسیوس قرار گرفتند.

غلظت کل مس و منگنز برگ‌ها با هضم در اسید سولفوریک در دمای ۳۸۰ درجه سلسیوس و به‌روش جذب اتمی اندازه‌گیری شدند (Kalra, 1997).

رگرسیون گام‌به‌گام

رگرسیون گام‌به‌گام یک ساختار از مدل رگرسیون است که در آن متغیرهای مستقل به تدریج انتخاب یا حذف می‌شوند و معناداری



شکل ۲. نمودار شماییک شبکه عصبی مصنوعی پرسپترون چند لایه همراه با الگوریتم پس انتشار خطا (Yuan et al., 2024)

Fig. 2. Schematic diagram of a multilayer perceptron artificial neural network with backpropagation algorithm (Yuan et al., 2024)

جدول ۱. متغیرهای ورودی با ترکیبات مختلف در مدل شبکه عصبی مصنوعی

Table 1. Input variables with different combinations in the artificial neural network model

Composition of input variables	Model
ترکیب متغیرهای ورودی	مدل
pH	ANN 1
pH, OC	ANN 2
pH, OC, Clay	ANN 3
pH, OC, Clay, P	ANN 4
pH, OC, Clay, P, EC	ANN 5
pH, OC, Clay, P, EC, Silt	ANN 6
pH, OC, Clay, P, EC, Silt, CCE	ANN 7

EC: Electrical conductivity, CCE: Calcium carbonate equivalent, OC: Organic carbon content

EC: رسانایی الکتریکی، CCE: کربنات کلسیم معادل، OC: مقدار کربن آلی

انتخاب شد (Heidari et al., 2024b). فرآیند آموزش شبکه با الگوریتم لونبرگ-مارکوارت برای جلوگیری از بیش‌برازش^۳ تحت معیارهای توقف استاندارد کنترل می‌شد. آموزش زمانی خاتمه می‌یافت که یکی از شرایط زیر محقق می‌شد: (۱) رسیدن به بیشینه تعداد تکرار^۴ تعریف شده (۱۰۰۰ تکرار)، (۲) کوچک شدن گرادیان خطا به کمتر از حد آستانه ($1e^{-7}$)، یا (۳)

روابط غیرخطی، متغیرهایی با همبستگی خطی ضعیف نیز در مدل‌ها آورده شد تا برهمکنش پیچیده بین متغیرها نیز آزموده شود (جدول ۱). این مدل‌ها شامل یک لایه پنهان بودند. یک لایه پنهان برای پیش‌بینی جذب مس و منگنز بر اساس پژوهش‌های مشابه پیشین کافی تشخیص داده شد. برای هر مدل، ساختار بهینه شبکه از راه یک فرآیند نظام‌مند آزمون و خطا تعیین شد. برای دستیابی به بهینه‌ترین مدل شبکه عصبی مصنوعی، یک فرآیند بهینه‌سازی چندمرحله‌ای شامل انتخاب متغیر، تنظیم فرامترها و پیش‌پردازش داده‌ها به کار گرفته شد. در گام اول، با هدف انتخاب بهینه متغیرها، سناریوهای مختلفی با ترکیبات ورودی متفاوت آزموده شد تا مجموعه‌ای از متغیرها که بیشترین اطلاعات مرتبط را فراهم می‌کنند، شناسایی شوند. در گام بعد، تنظیم فرامترهای کلیدی^۲ شبکه، شامل تعداد نوروها در لایه پنهان (در بازه ۲ تا ۲۰)، تعداد لایه‌های پنهان و نرخ یادگیری، با استفاده از روش آزمون و خطا و با هدف کمینه‌سازی خطای مدل روی داده‌های آزمون انجام گرفت. این پیش‌پردازش، پایداری فرآیند آموزش را افزایش داده و به همگرایی سریع‌تر مدل کمک می‌کند. معماری نهایی که بهترین عملکرد را بر اساس معیارهای آماری (R^2 و RMSE) در فاز آزمون نشان داد، به عنوان مدل بهینه

4- Epoch

2- Hyperparameter tuning

3- Overfitting

نتایج و بحث

در این پژوهش، برای مدل‌سازی ارتباط مس و منگنز برگ با ویژگی‌های فیزیکی و شیمیایی خاک از میانگین دو لایه (۳۰-۶۰ و ۶۰-۳۰ سانتی‌متر) بهره گرفته شد. در جدول ۲، آماره‌های برخی ویژگی‌های خاک و مقادیر غلظت کل مس و منگنز در برگ‌ها ارائه شده است. خاک‌های مورد بررسی از نظر ویژگی‌های درصد سیلت، درصد رس، رسانایی الکتریکی (EC)، درصد کربنات کلسیم معادل (CCE) و غلظت منیزیم و پتاسیم تفاوت‌های چشم‌گیری داشتند. این ویژگی‌ها که ضرایب تغییرات بزرگی داشتند، نشان‌دهنده تنوع زیاد در خاک‌های مختلف است. بافت خاک‌ها از شنی تا لوم رسی متغیر بود. از نظر pH، ۱۰ خاک دارای pH کمتر از ۷/۵ و در ارتباط با EC، ۹ نمونه خاک دارای EC برابر یا بیشتر از ۴ dS/m بودند. بر اساس معیارهای تفسیر نتایج آزمون خاک در مرکبات (Asadi Kangarshahi et al., 2019)، مقادیر فسفر خاک‌ها بین خیلی کم تا مطلوب (حدود کمبود تا مطلوب فسفر خاک > ۵ تا ۲۵ میلی گرم در کیلوگرم) گروه‌بندی شدند. همچنین، در مورد غلظت کل مس و منگنز برگ، بر اساس معیارهای تفسیر نتایج آزمون برگ در مرکبات (Asadi Kangarshahi et al., 2019)، مقدار آنها در برگ‌ها بین مقادیر کمبود تا مناسب متغیر بود (حدود کمبود تا مناسب مس در برگ از < ۳ تا > ۵ میلی گرم در کیلوگرم و منگنز در برگ از < ۱۵ تا > ۲۵ میلی گرم در کیلوگرم است).

همبستگی بین ویژگی‌های خاک با غلظت مس و منگنز در برگ
ماتریس ضرایب همبستگی بین غلظت مس و منگنز گیاه با ویژگی‌های خاک در جدول ۳ نشان داده شده است. نتایج تحلیل همبستگی نشان داد که ویژگی‌های خاک تأثیر قابل‌وجهی بر غلظت‌های مس (Cu) و منگنز (Mn) در برگ‌های گیاه دارند، به‌طوری‌که pH، OC، مقدار رس و EC خاک نقش‌های کلیدی ایفا می‌کنند. کربن آلی خاک همبستگی مثبتی با غلظت مس در

عدم بهبود خطای اعتبارسنجی^۵ برای ۶ تکرار متوالی. استفاده از این معیار توقف زودهنگام که بر مبنای عملکرد مدل روی بخشی از داده‌های آموزشی (داده‌های اعتبارسنجی) استوار است، به بهبود توانایی تعمیم مدل^۶ و جلوگیری از حفظ کردن داده‌های آموزشی کمک شایانی می‌کند (Ebrahimi et al., 2022). برای ایجاد مدل مبتنی بر هوش مصنوعی در این پژوهش، از نرم‌افزار MATLAB® (Mathworks, 2014) استفاده شد.

برای ارزیابی دقت و کارایی مدل‌های شبکه عصبی مصنوعی (ANN) از ضریب تبیین (R^2)، ریشه میانگین مربعات خطا ($RMSE^7$)، میانگین خطای مطلق (MAE^8) و ضریب ناش-ساتکلیف (NSE^۹) (روابط ۲، ۳، ۴ و ۵) استفاده شد. مقدار R^2 که در معادله ۲ تعریف شده است، درجه همبستگی بین داده‌های مشاهده‌شده و شبیه‌سازی‌شده را نشان می‌دهد و مقادیر R^2 نزدیک به ۱ بیانگر مدل با همبستگی بیشتر است. مقادیر $RMSE$ (معادله ۳) و MAE (معادله ۴) بیانگر خطای برآورد بوده و هرچه این مقادیر به صفر نزدیک‌تر باشند، شبیه‌سازی دقیق‌تر است. همچنین، مقدار NSE (معادله ۵) هرچه به ۱ نزدیک‌تر باشد، شبیه‌سازی دقیق‌تر خواهد بود (Mehdizadeh et al., 2017):

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (3)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

که در این روابط، y_i ، $\hat{y}_i$ و $\bar{y}$ به ترتیب مقادیر غلظت مس و منگنز اندازه‌گیری‌شده، تخمین زده‌شده توسط مدل، و میانگین مقادیر اندازه‌گیری‌شده هستند.

8- Mean absolute error

9- Nah-Sutcliffe efficiency

5- Validation error

6- Generalization

7- Root mean square error

جدول ۲. خلاصه آماری برخی ویژگی‌های خاک و غلظت کل مس و منگنز در برگ در ۴۰ نمونه

Table 2. Statistical summary of some soil properties and total concentration of copper and manganese in leaves in 40 samples

Property ویژگی	Maximum بیشینه	Minimum کمینه	Mean میانگین	Standard deviation انحراف معیار
EC (dS/m)	13.35	0.55	3.03	2.49
pH	8.30	7.20	7.75	0.28
Silt (%)	46.65	4.20	24.22	13.21
Clay (%)	26.50	3	8.98	5.67
CCE (%)	15.37	0	6.37	3.47
OC (%)	0.51	0.09	0.31	0.11
P (mg/kg)	22.13	0.97	6.54	3.06
Mn-Leaf (mg/kg)	36.50	9.50	20.21	5.70
Cu-Leaf (mg/kg)	6.51	1.50	3.50	1.08

EC: Electrical conductivity, CCE: Calcium carbonate equivalent, OC: Organic carbon content

EC: رسانایی الکتریکی، CCE: کربنات کلسیم معادل، OC: مقدار کربن آلی

جدول ۳. ماتریس ضرایب همبستگی بین صفات مورد بررسی

Table 3. Matrix of correlation coefficients between the studied traits

Mn-Leaf	Cu-Leaf	P	OC	CCE	Clay	Silt	pH	EC
								1
							1	0.11
						1	-0.01	0.19
					1	0.41*	0.003	-0.38
				1	0.39*	0.28	0.57**	-0.24
			1	-0.21	0.17	0.12	-0.38*	-0.18
		1	0.16	-0.01	-0.07	-0.23	-0.007	0.28
	1	-0.31*	0.39*	-0.18	0.32*	0.22	-0.41*	-0.22
1	0.2	0.002	0.28*	0.007	0.12	0.13	-0.33*	-0.29*

EC: Electrical conductivity, CCE: Calcium carbonate equivalent, OC: Organic carbon content

EC: رسانایی الکتریکی، CCE: کربنات کلسیم معادل، OC: مقدار کربن آلی

* و ** به ترتیب نشان‌دهنده معنی‌داری در سطوح احتمال ۵ و ۱ درصد است.

* and ** indicate significant at the 5 and 1 percent probability levels, respectively.

تشکیل کمپلکس‌های آلی-فلزی محلول، از رسوب مس به شکل هیدروکسیدها و کربنات‌های نامحلول جلوگیری کرده و آن را در فاز محلول خاک برای جذب توسط ریشه حفظ می‌کنند (Lejon et al., 2008). همبستگی مثبت بین مقدار رس خاک و غلظت مس در برگ (۰/۳۲) نیز این ایده را تایید می‌کند که مقدار رس و CEC بیشتر به‌ویژه در خاک‌های درشت‌بافت، توانایی بیشتری در نگهداری ریزمغذی‌های ضروری مانند مس داشته و آن‌ها را

برگ داشت (۰/۳۹) که نشان‌دهنده نقش مواد آلی در بهبود نگهداری ریزمغذی‌ها و افزایش فراهمی فلزات از راه افزایش گنجایش تبادل کاتیونی (CEC) است. مواد آلی با بهبود ساختمان خاک و فعالیت‌های میکروبی، فراهمی بیولوژیک به مس را افزایش می‌دهند. در خاک‌های معدنی، به‌ویژه در شرایط قلیایی و آهکی این منطقه که میانگین کربن آلی خاک کم است (۰/۳۱٪)، ماده آلی نقش تسهیل‌کننده دارد. اسیدهای هیومیک و فولویک با

جدول ۴. تجزیه واریانس رگرسیون غلظت مس در برگ با برخی ویژگی‌های خاک

Table 4. Regression variance analysis of copper concentration in leaf with some soil properties

F	Mean squares میانگین مربعات	Sum of squares مجموع مربعات	Degree of freedom درجه آزادی	Source of variation منبع تغییر
6.94**	5.38	16.16	3	Regression
	0.77	27.94	36	Error
		44.10	39	Total

** معنی‌داری در سطح احتمال ۱ درصد

** Significant at the 1 percent probability level

جدول ۵. تجزیه واریانس رگرسیون غلظت منگنز در برگ با برخی ویژگی‌های خاک

Table 5. Regression variance analysis of manganese concentration in leaf with some soil properties

F	Mean squares میانگین مربعات	Sum of squares مجموع مربعات	Degree of freedom درجه آزادی	Source of variation منبع تغییر
4.10*	91.95	183.91	3	Regression
	22.43	830.00	36	Error
		1013.91	39	Total

* معنی‌داری در سطح احتمال ۵ درصد

* Significant at the 5 percent probability level

و فرآیند هم‌رسوبی (Moreno-Lora and Delgado, 2020). این برهم‌کنش بازدارنده میان pH و آهک با فراهمی ریزمغذی‌ها، یک چالش اساسی در مدیریت تغذیه باغ‌های مناطق خشک و نیمه‌خشک محسوب می‌شود (Ahmad et al., 2022). همچنین، همبستگی منفی بین فسفر و غلظت مس در برگ، نشان‌دهنده یک اثر آنتاگونیستی دیگر است؛ غلظت زیاد فسفر می‌تواند با تشکیل رسوبات نامحلول مس-فسفات یا از راه رقابت برای جذب بر روی سطوح کانی‌ها، فراهمی مس را برای گیاه محدود سازد (Feil et al., 2020). در مجموع، این برهم‌کنش‌ها به وضوح توضیح می‌دهند که چرا در خاک‌های این منطقه، فراهمی عناصر مس و منگنز برای مرکبات با محدودیت جدی مواجه است.

رگرسیون گام‌به‌گام

همانطور که در جداول ۴ و ۵ نشان داده شده است، براساس نتایج تجزیه واریانس رابطه بین غلظت مس و منگنز در برگ با ویژگی‌های خاک در سطح ۱٪ معنی‌دار بود. در رگرسیون

برای گیاهان فراهم می‌سازند (Feil et al., 2020). همبستگی منفی بین EC خاک و غلظت منگنز در برگ (۰/۲۹) نشان می‌دهد که شوری خاک عامل مهم دیگری است که بر فراهمی ریزمغذی‌ها تأثیر می‌گذارد.

همبستگی‌های مشاهده‌شده، به‌ویژه رابطه منفی قوی بین pH و غلظت برگی مس و منگنز، ریشه در فرآیندهای ژئوشیمیایی حاکم بر خاک‌های آهکی و قلیایی دارد. pH خاک به عنوان یک متغیر کلیدی، حلالیت و فراهمی زیستی ریزمغذی‌ها را کنترل می‌کند. در مقادیر زیاد pH خاک، یون‌های مس و منگنز تمایل زیادی به تشکیل هیدروکسیدهای نامحلول دارند که این امر باعث خروج آن‌ها از محلول خاک و کاهش شدید فراهمی آن‌ها برای گیاه می‌شود (Moreno-Lora and Delgado, 2020).

علاوه بر این، مقادیر زیاد کربنات کلسیم، که در این پژوهش با شاخص CCE ارزیابی شد، این اثر محدودکننده را از دو راه تشدید می‌کند: نخست با حفظ pH در محدوده قلیایی و دوم با جذب سطحی مستقیم این کاتیون‌ها بر روی سطوح کانی کلسیت

جدول ۶. معیارهای آماری مدل رگرسیون گام به گام در رابطه بین غلظت مس (Cu) و منگنز (Mn) برگ با ویژگی های خاک

Table 6. Statistical criteria for stepwise regression models in relation to leaf copper (Cu) and manganese (Mn) concentrations with soil characteristics

NSE	MAE	RMSE	R ²	Model
0.16	1.16	1.30	0.36	Cu
0.02	4.52	5.31	0.28	Mn

R²: ضریب تبیین، RMSE: ریشه میانگین مربعات خطا، MAE: میانگین خطای مطلق، NSE: ضریب ناش-ساتکلیف

R²: Coefficient of determination, RMSE: Root mean square error, MAE: Mean absolute error, NSE: Nah-Sutcliffe efficiency

EC و pH، روابطی منفی با غلظت منگنز برگ داشتند. ضریب منفی و معنی دار به دست آمده برای pH (۰/۰۵-)، بر رابطه معکوس این متغیر با غلظت منگنز برگ تأکید دارد؛ به طوری که خاک های اسیدی تر (pH کم تر) با مقادیر بیشتر منگنز در برگ ها مرتبط بودند. به همین ترتیب، شوری خاک که با EC اندازه گیری می شود، نیز یک همبستگی منفی (با ضریب ۰/۶۶-) با میزان منگنز برگ نشان داد. این یافته پیشنهاد می کند که افزایش شوری خاک، جذب منگنز توسط گیاهان مرکبات را محدود می سازد.

رابطه معکوس بین pH خاک و غلظت های مس و منگنز با منابع علمی به خوبی همخوانی دارد. شرایط اسیدی انحلال پذیری این ریز مغذی ها را افزایش داده و در نتیجه فراهمی زیستی آنها را برای گیاهان بهبود می بخشد (Mhalla et al., 2021). به همین ترتیب، نقش مثبت رس خاک در فراهمی مس توسط CEC زیاد رس توجیه می شود که به حفظ و آزادسازی تدریجی ریز مغذی ها کمک می کند (Fageria et al., 2011). همبستگی منفی بین غلظت فسفر در خاک و غلظت مس در برگ، یافته های پیشین در مورد تضاد عناصر غذایی را بیشتر تأیید می کند، جایی که فسفر اضافی با تشکیل کمپلکس های نامحلول مس-فسفات، جذب مس را کاهش می دهد (Feil et al., 2020). با این حال، ضریب تبیین نسبتاً کم رگرسیون گام به گام، به ویژه برای منگنز، محدودیت مدل سازی خطی در بیان پیچیدگی برهمکنش های خاک و عناصر غذایی را نشان می دهد که اغلب غیرخطی و وابسته به شرایط هستند (Hosseinifard et al., 2019). علاوه بر این، روش های گام به گام، اگرچه از نظر آماری معتبر هستند، به دلیل اتکا به آثار تجمعی خطی، این خطر را دارند که متغیرهای با برهمکنش های پیچیده و غیرخطی را حذف کنند (Sahoo and Jha, 2013).

گام به گام، مقدار مس و منگنز برگ به عنوان متغیر وابسته و بقیه ویژگی های خاک به عنوان متغیر مستقل در مدل وارد شد. روابط زیر مدل های رگرسیونی بین غلظت مس و منگنز برگ با ویژگی های خاک را نشان می دهند:

$$\text{Cu-Leaf} = 16.76661 - 1.73436\text{pH} + 0.06558\text{Clay} - 0.05867\text{P} \quad (۶)$$

$$\text{Mn-Leaf} = 68.63872 - 0.66426\text{EC} - 6.05257\text{pH} \quad (۷)$$

برای ارزیابی کارایی و خطای مدل های رگرسیون گام به گام، معیارهای آماری در جدول ۶ خلاصه شده است که نشان دهنده قدرت تبیین محدود این مدل ها، به ویژه برای منگنز، است.

یافته های تحلیل رگرسیون نشان داد که سه عامل خاک شامل pH، درصد رس و میزان فسفر، در مجموع توانستند ۳۶ درصد از کل پراکندگی (تغییرات) غلظت مس در برگ مرکبات را تبیین کنند (جدول ۶). ضریب منفی به دست آمده برای pH خاک (۱/۷۳-) حاکی از وجود یک رابطه عکس است؛ به این مفهوم که با افزایش pH، غلظت مس در برگ کاهش می یابد. در نقطه مقابل، درصد رس خاک همبستگی مثبتی با غلظت مس برگ نشان داد. ضریب مثبت (۰/۰۶۵) برای این متغیر بیانگر آن است که مقادیر بیشتر رس در خاک با جذب بیشتر مس توسط برگ های مرکبات هم راستا است. در نهایت، میزان فسفر خاک یک ارتباط منفی ضعیف (با ضریب ۰/۰۵۸-) با غلظت مس برگ نشان داد.

در خصوص غلظت منگنز در برگ های مرکبات، مدل رگرسیون گام به گام دو متغیر اصلی پیش بینی کننده شامل EC و pH خاک (معادله ۷) را شناسایی کرد. این مدل توانست ۲۸ درصد از کل تغییرات مشاهده شده در غلظت منگنز برگ را توضیح دهد (جدول ۶). نکته قابل توجه این بود که هر دو متغیر

جدول ۷. مدل‌های شبکه عصبی در رابطه بین غلظت مس برگ با ویژگی‌های خاک

Table 7. Neural network models in relation to leaf copper concentration with soil characteristics

Test data داده‌های آزمون				Training data داده‌های آموزش				Number of neurons	Model
NSE	MAE	RMSE	R ²	NSE	MAE	RMSE	R ²	تعداد نورون	مدل
-2.01	0.12	1.34	0.31	-0.51	0.9	1.13	0.38	4	ANN 1
0.18	0.84	1.09	0.42	0.39	0.65	0.76	0.62	1	ANN 2
0.30	0.84	1.01	0.56	0.33	0.65	0.80	0.67	19	ANN 3
0.57	0.72	0.88	0.78	0.66	0.42	0.52	0.81	10	ANN 4
-1.14	1.20	1.47	0.46	0.27	0.55	0.80	0.73	20	ANN 5
-0.26	0.87	1.06	0.31	0.23	0.73	0.92	0.56	1	ANN 6
-1.79	1.29	1.59	0.32	0.25	0.86	1.15	0.56	17	ANN 7

R²: ضریب تبیین، RMSE: ریشه میانگین مربعات خطا، MAE: میانگین خطای مطلق، NSE: ضریب ناش-ساتکلایفR²: Coefficient of determination, RMSE: Root mean square error, MAE: Mean absolute error, NSE: Nah-Sutcliffe efficiency

ANN1: pH, ANN2: pH, OC, ANN3: pH, OC, Clay, ANN4: pH, OC, Clay, P, ANN5: pH, OC, Clay, P, EC, ANN6: pH, OC, Clay, P, EC, Silt, ANN7: pH, OC, Clay, P, EC, Silt, CCE

جدول ۸. مدل‌های شبکه عصبی در رابطه بین غلظت منگنز برگ با ویژگی‌های خاک

Table 8. Neural network models in relation to leaf manganese concentration with soil characteristics

Test data داده‌های آزمون				Training data داده‌های آموزش				Number of neurons	Model
NSE	MAE	RMSE	R ²	NSE	MAE	RMSE	R ²	تعداد نورون	مدل
-0.42	3.45	4.27	0.37	0.18	4.25	4.98	0.44	2	ANN 1
-0.17	3.51	4.18	0.50	0.21	4.07	4.81	0.48	6	ANN 2
0.03	3.82	4.89	0.47	0.03	4.10	4.89	0.45	3	ANN 3
-0.82	4.77	5.58	0.46	0.39	2.93	3.90	0.63	2	ANN 4
0.10	5.10	5.68	0.66	0.50	1.42	3.23	0.76	11	ANN 5
0.01	4.44	5.35	0.57	-0.29	4.78	5.51	0.63	13	ANN 6
0.24	4.05	4.64	0.52	0.31	2.97	4.01	0.58	1	ANN 7


R²: ضریب تبیین، RMSE: ریشه میانگین مربعات خطا، MAE: میانگین خطای مطلق، NSE: ضریب ناش-ساتکلایفR²: Coefficient of determination, RMSE: Root mean square error, MAE: Mean absolute error, NSE: Nah-Sutcliffe efficiency

ANN1: pH, ANN2: pH, OC, ANN3: pH, OC, Clay, ANN4: pH, OC, Clay, P, ANN5: pH, OC, Clay, P, EC, ANN6: pH, OC, Clay, P, EC, Silt, ANN7: pH, OC, Clay, P, EC, Silt, CCE

شبکه عصبی مصنوعی

در این پژوهش، قابلیت مدل‌های شبکه عصبی مصنوعی (ANN) در تخمین غلظت عناصر مس (Cu) و منگنز (Mn) در برگ گیاه مورد سنجش قرار گرفت. نتایج مربوط به پیش‌بینی غلظت مس و منگنز در برگ به ترتیب در جداول ۷ و ۸ گردآوری شده است. برای یافتن ساختار بهینه شبکه، تعداد متفاوتی نورون در لایه

به‌طورکلی، رگرسیون گام‌به‌گام بینش‌های مفید و قابل تفسیری را به‌ویژه در مورد رابطه pH و فسفر ارائه داد. با این وجود، ناتوانی آن در مدل‌سازی کامل وابستگی‌های برهمکنش پیچیده بین ویژگی‌های خاک و پویایی عناصر غذایی گیاه، نشان می‌دهد که یک رویکرد مکمل یا جایگزین ممکن است سودمندی پیش‌بینی‌کننده بهتری به همراه داشته باشد.



شکل ۳. مقایسه مقادیر اندازه‌گیری‌شده و برآوردشده غلظت مس برگ در مدل شبکه عصبی ۴ (ANN4) در مجموع داده‌های آموزش و آزمون

Fig. 3. Comparison of measured and estimated values of leaf copper concentration in neural network model 4 (ANN4) in total training and test datasets


دادند. افزایش تدریجی متغیرهای ورودی در مدل‌های بعدی ANN3، ANN4 و ANN5 منجر به ارتقاء نسبی عملکرد با توجه به تمامی شاخص‌های R^2 ، RMSE، MAE و NSE هم برای مجموعه داده‌های آموزشی و هم آزمایشی گردید. مطلوب‌ترین عملکرد در تخمین غلظت Cu با مدل ANN4 حاصل شد که در آن از pH، OC، رس و فسفر خاک به عنوان متغیرهای ورودی استفاده شده بود. برای این مدل، مقادیر R^2 برابر با ۰/۸۱ (آموزش) و ۰/۷۸ (آزمون)، مقادیر RMSE برابر با ۰/۵۲ (آموزش) و ۰/۸۸ (آزمون)، مقادیر MAE برابر با ۰/۴۲ (آموزش) و ۰/۷۲ (آزمون)، و مقادیر NSE برابر با ۰/۶۶ (آموزش) و ۰/۵۷ (آزمون) مشاهده شد.

شکل ۳ نمودار مقایسه مقادیر اندازه‌گیری‌شده و مقادیر پیش‌بینی‌شده غلظت Cu توسط مدل بهینه ANN4 را نمایش می‌دهد. همانطور که مشهود است، همخوانی زیادی بین داده‌های مشاهده‌ای و برآوردهای مدل در هر دو فاز آموزش و آزمون وجود دارد که این امر، اعتبار و قابلیت اطمینان مدل توسعه‌یافته را تأیید می‌کند.

جدول ۸ به ارائه شاخص‌های آماری عملکرد مدل‌های ANN در فرآیند برآورد غلظت منگنز برگ اختصاص دارد. بر اساس نتایج این جدول، مقادیر R^2 در فاز آموزش مدل‌ها بین ۰/۴۴ تا

پنهان شبکه آزموده شد و بهترین پیکربندی‌ها بر مبنای معیارهای ارزیابی R^2 ، RMSE، MAE و NSE انتخاب شد. جدول ۱ جزئیات مربوط به ترکیبات مختلف متغیرهای ورودی استفاده‌شده در مدل‌های ANN را ارائه می‌دهد.

نتایج مربوط به برآورد غلظت مس در برگ (Cu) در جدول ۷ نشان می‌دهد که شاخص‌های آماری عملکرد مدل‌های ANN بسته به نوع ورودی‌های مورد استفاده، متغیر بوده‌اند. به طور مشخص، مقادیر R^2 در فاز آموزش مدل‌ها در بازه ۰/۳۸ تا ۰/۸۱ و در فاز آزمون بین ۰/۳۱ تا ۰/۷۸ قرار داشت. همچنین، مقادیر RMSE برای داده‌های آموزشی از ۰/۵۲ تا ۱/۱۵ و برای داده‌های آزمایشی از ۰/۸۸ تا ۱/۵۹ متغیر بود. به عنوان نمونه، در مدل ANN1 که تنها از pH به عنوان ورودی و با ۴ نورون در لایه پنهان استفاده می‌کرد، مقادیر R^2 برای مراحل آموزش و آزمون به ترتیب ۰/۳۸ و ۰/۳۱ به دست آمد. مقادیر RMSE و MAE برای این مدل نیز به ترتیب ۱/۱۳ و ۰/۹ (برای آموزش) و ۱/۳۴ و ۱/۱۲ (برای آزمون) محاسبه شد. با افزودن OC به عنوان ورودی دوم در مدل ANN2، دقت پیش‌بینی بهبود یافت و شاخص R^2 به ۰/۶۲ (آموزش) و ۰/۴۲ (آزمون) افزایش پیدا کرد. به موازات آن، RMSE به ۰/۷۶ (آموزش) و ۱/۰۹ (آزمون) کاهش یافت و معیارهای MAE و NSE نیز روند بهبودی را نشان



شکل ۴. مقایسه مقادیر اندازه‌گیری‌شده و برآوردشده غلظت منگنز برگ در مدل شبکه عصبی ۵ (ANN5) در مجموع داده‌های آموزش و آزمون

Fig. 4. Comparison of measured and estimated values of leaf manganese concentration in neural network model 5 (ANN5) in total training and test datasets

مدل ANN5 بود. این مدل با استفاده از pH، OC، رس، فسفر و EC خاک به عنوان ورودی، توانست به R^2 برابر با ۰/۷۶ (آموزش) و ۰/۶۶ (آزمون) و RMSE برابر با ۳/۲۳ (آموزش) و ۵/۶۸ (آزمون) دست یابد. شکل ۴ نمودار همخوانی مقادیر منگنز اندازه‌گیری‌شده در برگ و مقادیر تخمین‌زده‌شده آن توسط مدل بهینه ANN5 را به تصویر می‌کشد. این نمودار به ارزیابی بصری عملکرد مدل منتخب کمک می‌کند.

یکی از اهداف اصلی این پژوهش، توسعه مدلی برای پیش‌بینی عناصر کم‌مصرف بر اساس ویژگی‌های خاک بود که اندازه‌گیری آن‌ها ساده، سریع و کم‌هزینه باشد تا بتوان از آن به عنوان ابزاری کاربردی در کشاورزی دقیق بهره برد. به همین دلیل، تمرکز بر متغیرهای رایج در آزمون‌های خاک‌شناسی قرار گرفت. ارزیابی عملکرد مدل‌های مختلف شبکه عصبی در جداول ۷ و ۸ نشان‌دهنده توانایی این مدل‌ها در پیش‌بینی غلظت مس و منگنز در برگ است. ضریب تبیین (R^2)، که بیانگر درصدی از واریانس متغیر وابسته است که توسط متغیرهای مستقل تبیین می‌شود، در مدل‌های بهینه برای هر دو عنصر مقادیر زیادی را نشان داد. همچنین، نتایج نشان داد که تعداد نوروهای لایه پنهان نقش تعیین‌کننده‌ای در عملکرد مدل دارد. کاهش قابل توجه عملکرد در مدل‌هایی با تعداد نوروهای کمتر (مانند ANN1) به

۰/۷۶ و در فاز آزمون بین ۰/۳۷ تا ۰/۶۶ نوسان داشت. همچنین، دامنه تغییرات RMSE برای داده‌های آموزشی از ۳/۲۳ تا ۵/۵۱ و برای داده‌های آزمایشی از ۴/۱۸ تا ۵/۶۸ متغیر بود. مدل پایه ANN1، که تنها از pH خاک به عنوان ورودی و با ۲ نرون در لایه پنهان استفاده می‌کرد، به مقادیر R^2 برابر با ۰/۴۴ (آموزش) و ۰/۳۷ (آزمون) دست یافت. برای همین مدل، مقادیر RMSE برابر ۴/۹۸ (آموزش) و ۴/۲۷ (آزمون)، و مقادیر MAE برابر با ۴/۲۵ (آموزش) و ۳/۴۵ (آزمون) محاسبه شد. شاخص NSE برای مدل ANN1 در مراحل آموزش و آزمون به ترتیب برابر ۰/۱۸ و -۰/۴۲ به دست آمد که مقدار منفی در مرحله آزمون نشان‌دهنده عملکرد ضعیف‌تر مدل نسبت به میانگین داده‌های مشاهده‌ای است. با افزودن متغیر OC در مدل ANN2، بهبود اندکی در ضریب تبیین مشاهده شد، به‌طوری‌که مقادیر R^2 برای آموزش و آزمون به ترتیب به ۰/۴۸ و ۰/۵۰ رسیدند. مقادیر RMSE مربوطه نیز ۴/۸۱ (آموزش) و ۴/۱۸ (آزمون) گزارش شد. برخلاف روند بهبود نسبتاً پیوسته در پیش‌بینی مس، افزودن متغیرهای ورودی بیشتر در مدل‌های ANN3، ANN4، ANN5، ANN6 و ANN7 برای تخمین غلظت منگنز در برگ، نتایج یکنواختی به همراه نداشت و خروجی‌های متفاوتی را رقم زد. با این حال، بهترین عملکرد کلی در برآورد غلظت Mn مربوط به

پیچیده شامل فعالیت میکروبی و بافت خاک، توسط رویکردهای خطی به خوبی به تصویر کشیده نمی‌شوند (Dayhoff and DeLeo, 2001). به عنوان مثال، نقش کربن آلی در افزایش جذب مس از راه تشکیل کمپلکس و فعالیت‌های میکروبی، ذاتاً غیرخطی و وابسته به شرایط است و از معماری یادگیری تطبیقی ANN بهره می‌برد (Lejon et al., 2008).

علاوه بر این، توانایی ANN در آزمودن ترکیبات (پیکربندی‌های) مختلف از متغیرهای ورودی، همان طور که با مقایسه هفت سناریوی مدل مشهود است، ابزار قدرتمندی برای کاوش داده‌های چندبعدی ارائه می‌دهد. انتخاب متغیرهای ورودی مانند pH، EC و OC با عوامل شناخته‌شده‌ای که بر تحرک و جذب ریزمغذی‌ها تأثیر می‌گذارند، همخوانی دارد (Chatzistathis et al., 2017). هر مدل ANN با ترکیب ورودی متفاوت، در حال حل یک مسئله بهینه‌سازی متفاوت است. عملکرد نهایی به این بستگی دارد که آیا ترکیب ورودی‌ها توانسته است به بهترین شکل ممکن، پویایی پیچیده، غیرخطی و برهمکنشی حاکم بر سیستم خاک-گیاه را نمایندگی کند یا خیر. عملکرد متفاوت مدل‌های ANN با ترکیبات ورودی گوناگون، ناشی از برهمکنش‌های پیچیده و منحصر به فرد هر متغیر با عناصر مس و منگنز است. بهترین مدل، ترکیبی از ورودی‌هاست که مهم‌ترین عوامل مؤثر بر فراهمی عنصر مورد نظر را در بر گیرد و شامل متغیرهای غیرمرتبطی که باعث کاهش دقت و قابلیت تعمیم‌پذیری مدل می‌شوند، نباشد. به طور کلی، pH به عنوان یک متغیر اصلی، حلالیت شیمیایی هر دو عنصر را کنترل می‌کند و در خاک‌های قلیایی منطقه، فراهمی آن‌ها را کاهش می‌دهد (Koukoulakis et al., 2013) در مقابل، کربن آلی با تشکیل کمپلکس‌های پایدار، از رسوب این عناصر جلوگیری کرده و به صورت یک عامل هم‌افزا^۱، فراهمی آن‌ها را افزایش می‌دهد (Heidari et al., 2024a).

تفاوت اصلی در مدل‌سازی مس و منگنز به نقش ویژه فسفر و رسانایی الکتریکی خاک باز می‌گردد. فسفر به عنوان یک عامل

پدیده کم‌پرازشی نسبت داده می‌شود. یک شبکه با توان محاسباتی ناکافی، قادر به یادگیری و مدل‌سازی روابط پیچیده و غیرخطی حاکم بر سیستم خاک-گیاه نیست. به عبارت دیگر، تعداد کم نورون‌ها به مدل اجازه نمی‌دهد تا برهمکنش‌های پیچیده بین متغیرهای متعدد ورودی را به درستی تقریب بزند و در نتیجه، پیش‌بینی ضعیف‌تری ارائه می‌دهد (Heidari et al., 2024b). افزایش تعداد نورون‌ها تا یک سطح بهینه (مانند ۱۰ نورون در مدل ANN4 برای مس)، این توان را فراهم کرده و به مدل امکان می‌دهد تا الگوهای پیچیده داده‌ها را با دقت بیشتری بیاموزد.

از نظر روش‌شناختی، برتری ANNs بر رگرسیون گام‌به‌گام با کارهای پیشین در زمینه‌ی پیش‌بینی آهن در مرکبات (Heidari et al., 2024a)، مدل‌سازی آب‌های زیرزمینی (Sahoo and Jha, 2013) و برآورد دامنه رطوبتی با حداقل محدودیت خاک (Soleimani et al., 2021) هم‌راستا است. این امر، ارزش رویکردهای یادگیری ماشین را برای استخراج روابط پیچیده و غیرخطی خاک-گیاه تقویت می‌کند. با این حال، مدل‌های ANN در این پژوهش به قدرت پیش‌بینی بیشتری برای غلظت مس در برگ نسبت به منگنز دست یافتند. این تفاوت احتمالاً ریشه در پویایی ژئوشیمیایی پیچیده‌تر منگنز در خاک‌های آهکی دارد. فراهمی منگنز نه تنها به pH، بلکه به شدت به پتانسیل اکسیداسیون و احیا (Eh) خاک نیز وابسته است. این واکنش‌های اکسیداسیون و احیا به شدت تحت تأثیر فعالیت میکروبی و نوسانات موضعی رطوبت و اکسیژن خاک قرار دارند (Koukoulakis et al., 2013)؛ عواملی که در مدل فعلی به عنوان ورودی لحاظ نشده‌اند. در مقابل، شیمی مس در خاک بیشتر تحت کنترل pH و میزان ماده آلی خاک است که متغیرهای پایدارتری بوده و در مدل پژوهش حاضر نیز گنجانده شده‌اند.

عملکرد برتر ANN را می‌توان به توان آن در مدل‌سازی برهمکنش‌های غیرخطی بین متغیرها نسبت داد که در پویایی عناصر غذایی خاک-گیاه مهم هستند. چنین برهمکنش‌هایی، از جمله آثار هم‌افزایی و آنتاگونیستی عناصر غذایی و بازخوردهای

مقایسه رگرسیون گام‌به‌گام و شبکه عصبی مصنوعی

نتایج ارزیابی‌ها در پژوهش حاضر، برتری عملکردی شبکه عصبی مصنوعی را نسبت به رگرسیون گام‌به‌گام آشکار ساخت. این برتری هم در میزان دقت مدل (ضریب تبیین $0/78$ برای شبکه عصبی در برابر $0/36$ برای رگرسیون گام‌به‌گام در مس و ضریب تبیین $0/66$ برای شبکه عصبی در برابر $0/28$ برای رگرسیون گام‌به‌گام در منگنز) و هم در کاهش خطا قابل مشاهده بود. به طور مشخص، مقدار RMSE برای پیش‌بینی Cu در مدل رگرسیون گام‌به‌گام برابر $1/30$ میلی‌گرم بر کیلوگرم بود، ولی در مدل شبکه عصبی به $0/88$ میلی‌گرم بر کیلوگرم کاهش یافت. بنابراین، با استناد به مقادیر مطلوب‌تر ضریب تبیین و RMSE، می‌توان نتیجه گرفت که شبکه عصبی مصنوعی کارایی بهتر و خطای کمتری در مقایسه با رگرسیون گام‌به‌گام داشته است.

این یافته‌ها با منابع علمی زیادی هماهنگ است که نشان می‌دهد در حالی که روش‌های رگرسیون قابلیت تفسیر و دقت آماری را ارائه می‌دهند، اغلب در به تصویر کشیدن ماهیت پیچیده برهمکنش‌های بیولوژیک و محیطی توانایی کمی دارند (Sahoo and Jha, 2013; Hosseinifard et al., 2019). در مقابل، مدل‌های ANN در شرایطی که داده‌ها چندبعدی بوده و روابط بین متغیرها پیچیده است، برتری دارند، این شرایط در سامانه‌های با برهمکنش‌های پیچیده خاک-گیاه مشاهده می‌شود که تحت تأثیر همزمان عواملی چون pH، شوری، بافت و ماده آلی خاک قرار دارند.

علاوه بر این، پژوهش‌های پیشین عمدتاً روابط بین ویژگی‌های خاک و جذب ریزمغذی‌ها را به صورت جداگانه بررسی کرده‌اند، در حالی که رویکرد شبکه عصبی در این پژوهش امکان مدل‌سازی همزمان چندین ویژگی خاک و برهم‌کنش‌های پیچیده آن‌ها را فراهم ساخته است. بدین ترتیب، هرچند اصول کلی یافته‌های پژوهش حاضر در چارچوب دانش موجود تایید می‌شود، بهره‌گیری از مدل ANN دید جامع‌تری از برهمکنش عوامل ارائه کرده که در پژوهش‌های پیشین کمتر مشهود است.

متضاد^{۱۱} شناخته می‌شود که با تشکیل رسوبات نامحلول مس-فسفات، فراهمی مس را محدود می‌کند (Moreno-Lora and Delgado, 2020). به همین دلیل، حضور فسفر در مدل ANN4، دقت پیش‌بینی مس را به شکل چشم‌گیری بهبود بخشیده است. از سوی دیگر، رسانایی الکتریکی به عنوان یک عامل تنش‌زای یونی، عمدتاً بر جذب منگنز تأثیر منفی دارد. این موضوع توضیح می‌دهد که چرا افزودن متغیر رسانایی الکتریکی به مدل (ANN5)، منجر به بهترین عملکرد برای پیش‌بینی منگنز شد، در حالی که همین کار دقت مدل مس را کاهش داد. بنابراین، مدل بهینه برای هر عنصر، نشان‌دهنده ترکیب منحصربه‌فردی از عوامل کنترلی، هم‌افزا و متضاد است که شبکه عصبی توانسته آن را به درستی مدل‌سازی کند.

علت اصلی عملکرد برتر مدل شبکه عصبی مصنوعی در این است که این روابط در آن به صورت مجزا و خطی عمل نمی‌کنند. این متغیرها دارای برهمکنش‌های غیرخطی و پیچیده‌ای هستند؛ برای نمونه، تأثیر منفی pH زیاد توسط غلظت ماده آلی تعدیل می‌شود. مدل‌های خطی مانند رگرسیون، قادر به درک و مدل‌سازی این روابط پیچیده نیستند و به همین دلیل تنها بخش کوچکی از تغییرات را تبیین می‌کنند. در مقابل، ANN با ساختار شبکه‌ای و توابع فعال‌سازی غیرخطی خود، این قابلیت را دارد که الگوی حاصل از این برهمکنش‌های پیچیده را مستقیماً از داده‌ها بیاموزد و یک شبیه‌سازی بسیار دقیق‌تر و واقع‌گرایانه‌تر از سیستم خاک-گیاه ارائه دهد (Heidari et al., 2024b).

با این حال، باید توجه داشت که مدل‌های ANN، در حالی که قدرتمند هستند، به عنوان جعبه‌های سیاه با قابلیت تفسیر محدود در مقایسه با رگرسیون عمل می‌کنند، که یک نقطه ضعف شناخته‌شده در کاربردهای زراعی است که اغلب به بینش‌های کاربردی نیاز است (Patel et al., 2022). با این وجود، توازن بین پیچیدگی مدل، دقت پیش‌بینی و سازگاری تجربی، سودمندی ANN را در کشاورزی دقیق، به‌ویژه برای مدیریت عناصر غذایی تحت شرایط متغیر، تأیید می‌کند.

در نتیجه، در حالی که رگرسیون گام به گام درک پایه‌ای از پیش‌بینی‌کننده‌های کلیدی را فراهم کرد، ANN یک چارچوب مدل‌سازی دقیق‌تر و از نظر کمی برتر ارائه داد. پیامدهای این امر برای مدیریت تغذیه مرکبات قابل توجه است و از ادغام یادگیری ماشین در تشخیص حاصلخیزی خاک و برنامه‌ریزی مدیریت عناصر غذایی حمایت می‌کند.

نتیجه‌گیری

این پژوهش نشان داد که مدل‌های شبکه عصبی مصنوعی ابزاری قدرتمند و دقیق برای پیش‌بینی غلظت عناصر کم مصرف مس و منگنز در برگ مرکبات، بر اساس ویژگی‌های زودیافت خاک هستند. نتایج تأیید کرد که فراهمی این عناصر بیش از آنکه تحت تأثیر یک عامل واحد باشد، توسط شبکه‌ای از برهمکنش‌های پیچیده میان pH، ماده آلی، رس، فسفر و شوری خاک کنترل می‌شود. اگرچه رگرسیون گام به گام توانست متغیرهای کلیدی خطی را شناسایی کند، اما شبکه عصبی مصنوعی با توانایی مدل‌سازی برهمکنش‌های غیرخطی میان این متغیرها، برآوردهای دقیق‌تری ارائه داد. نکته قابل توجه این بود که مدل بهینه ANN در پیش‌بینی غلظت مس ($R^2=0.78$) عملکرد بهتری نسبت به منگنز ($R^2=0.66$) از خود نشان داد. این تفاوت که در نتایج نیز مشهود است، می‌تواند به پویایی پیچیده‌تر و چندعاملی‌تر منگنز در خاک‌های آهکی منطقه مرتبط باشد که مدل‌سازی آن را دشوارتر می‌سازد.

با این وجود، برتری مدل شبکه عصبی در پیش‌بینی غلظت هر دو عنصر، کاربردهای عملی مهمی برای مدیریت تغذیه باغ‌های مرکبات دارد. این مدل می‌تواند به عنوان یک ابزار پشتیبان تصمیم‌گیری برای تشخیص سریع کمبودهای تغذیه‌ای پیش از

ظهور علائم بالینی به کار رود. باغداران و کارشناسان می‌توانند با اندازه‌گیری چند ویژگی کلیدی خاک (pH، ماده آلی، شوری و رس) و استفاده از مدل آموزش‌دیده، غلظت احتمالی مس و منگنز را در برگ‌ها پیش‌بینی کرده و اقدامات اصلاحی مانند کوددهی را به موقع و به صورت هدفمند انجام دهند.

با این حال، لازم است به محدودیت‌های این رویکرد نیز توجه شود. مدل‌های شبکه عصبی، با وجود توان پیش‌بینی زیاد، اغلب به صورت جعبه سیاه عمل می‌کنند. به این مفهوم که تفسیر روابط دقیق بین متغیرهای ورودی و خروجی در آن‌ها دشوار است، که این موضوع یک نقطه ضعف شناخته‌شده در کاربردهای زراعی است. در نهایت، توازن میان دقت زیاد پیش‌بینی و قابلیت تفسیر محدود، نشان می‌دهد که مدل ANN ابزاری کارآمد برای گذار به سمت کشاورزی دقیق و مدیریت بهینه تغذیه در باغ‌های مرکبات است و می‌تواند به بهبود عملکرد، افزایش بهره‌وری اقتصادی و حفظ محیط زیست منجر شود.

تشکر و سپاسگزاری

بدینوسیله از همکاری بی‌دریغ همکاران محترم موسسه خاک و آب به خاطر تأمین اعتبار، همکاران گرانقدر مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی جنوب استان کرمان که در اجرای این پروژه نهایت همکاری را داشته‌اند، تشکر و قدردانی می‌گردد.

تضاد منافع

نویسندگان مقاله اذعان دارند هیچگونه تضاد منفعی با شخص، شرکت یا سازمانی برای این پژوهش ندارند.

References

- Ahmad, N., Hussain, S., Ali, M.A., Minhas, A., Waheed, W., Danish, S., Fahad, S., Ghafoor, U., Baig, K.S., Sultan, H., Hussain, M.I., Ansari, M.J., Marfo, T.D., Datta, R., 2022. Correlation of soil characteristics and citrus leaf nutrients contents in current scenario of Layyah district. Horticulturae 8(1), 61. <https://doi.org/10.3390/horticulturae8010061>.
- Allison, L., Richards, L., 1954. Diagnosis and Improvement of Saline and Alkali Soils. Soil and Water Conservation Research Branch, Agricultural Research Service, Washington, D.C..

منابع مورد استفاده

3. Asadi Kangarshahi, A., Fallah Nosrat Abad, A., Akhlaghi Amiri, N., 2019. Guide to sampling and interpreting soil and leaf analysis results for citrus trees. Soil and Water Research Institute, 561, 55. (In Persian)
4. Chatzistathis, T., Papaioannou, A., Gasparatos, D., Molassiotis, A., 2017. From which soil metal fractions Fe, Mn, Zn and Cu are taken up by olive trees (*Olea europaea* L., cv. 'chondrolia chalkidikis') in organic groves? J. Environ. Manage. 203, 489–499. <https://doi.org/10.1016/j.jenvman.2017.07.079>.
5. Dayhoff, J.E., DeLeo, J.M., 2001. Artificial neural networks: opening the black box. Cancer 91(S8), 1615–1635. [https://doi.org/10.1002/1097-0142\(20010415\)91:8+%3C1615::AID-CNCR1175%3E3.0.CO;2-L](https://doi.org/10.1002/1097-0142(20010415)91:8+%3C1615::AID-CNCR1175%3E3.0.CO;2-L).
6. De Silva, S., Huynh, T., Ball, A.S., Indrapala, D.V., Reichman, S.M., 2020. Measuring soil metal bioavailability in roadside soils of different ages. Environments 7(10), 91. <https://doi.org/10.3390/environments7100091>.
7. Ebrahimi, M., Sarikhani, M.R., Shiri, J., 2022. Application of artificial neural network and gene expression programming to estimate soil microbial metabolic quotient. Appl. Soil Ecol. 175, 104465. <https://doi.org/10.1016/j.apsoil.2022.104465>.
8. Fageria, N.K., Gheyi, H.R., Moreira, A., 2011. Nutrient bioavailability in salt affected soils. J. Plant Nutr. 34(7), 945–962. <https://doi.org/10.1080/01904167.2011.555578>.
9. Feil, S.B., Pii, Y., Valentinuzzi, F., Tiziani, R., Mimmo, T., Cesco, S., 2020. Copper toxicity affects phosphorus uptake mechanisms at molecular and physiological levels in *Cucumis sativus* plants. Plant Physiol. Biochem. 157, 138–147. <https://doi.org/10.1016/j.plaphy.2020.10.023>.
10. Feng, Y., Cui, N., Hao, W., Lili, G., Gong, D., 2019. Estimation of soil temperature from meteorological data using different machine learning models. Geoderma 338, 77–67. <https://doi.org/10.1016/j.geoderma.2018.11.044>.
11. Gee, G.W., Bauder, J.W., 1986. Particle-size analysis. In: Klute, A. (Ed.), Methods of Soil Analysis, Part 1. Physical and Mineralogical Methods, 2nd ed, Agronomy Monograph 9. ASA/SSSA, Madison, WI, pp. 383–411.
12. Giannakoula, A., Therios, I., Chatzissavvidis, C., 2021. Effect of lead and copper on photosynthetic apparatus in citrus (*Citrus aurantium* L.) plants. The role of antioxidants in oxidative damage as a response to heavy metal stress. Plants 10(1), 155. <https://doi.org/10.3390/plants10010155>.
13. Heidari, s., Ghaffari Nejad, S.A., Sarhadi, J., Sharif, M., 2024a. Modeling the relationship between iron concentration in citrus leaves and some soil properties using artificial neural network (case study of southern Kerman province). Iran. J. Soil Water Res. 55(2), 285–296. <https://doi.org/10.22059/ijswr.2024.369507.669619>. (In Persian with English abstract)
14. Heidari, S., Vadiati, M., Nejad, S.A.G., Sarhadi, J., Kisi, O., 2024b. Modeling Zn availability and uptake by citrus plants using easily measured soil characteristics. Environ. Model. Assess. 29(5), 883–900. <https://doi.org/10.1007/s10666-024-09962-0>.
15. Hosseinfard, S.J., Shirani, H., Hashemipour, H., 2019. Modeling the relationship between cadmium and some soil physical and chemical properties in pistachio orchards using regression and artificial neural network. Environ. Sci. 17(3), 177–188. <https://doi.org/10.29252/envs.17.3.177>. (In Persian with English abstract)
16. Hosseinpour, M., Sharifi, H., Sharifi, Y., 2018. Stepwise regression modeling for compressive strength assessment of mortar containing metakaolin. J. Mater. Sci. 38(4), 207–215. <https://doi.org/10.1080/02286203.2017.1422096>.
17. Kalra, Y., 1997. Handbook of Reference Methods for Plant Analysis. CRC Press, Boca Raton.
18. Koukoulakis, P., Chatzissavvidis, C., Papadopoulos, A., Pontikis, D., 2013. Interactions between leaf macro, micronutrients and soil properties in pistachio (*Pistacia vera* L.) orchards. Acta Bot. Croat. 72(2). <https://doi.org/10.2478/V10184-012-0021-9>.
19. Lejon, D.P.H., Martins, J.M.F., Lévêque, J., Spadini, L., Pascault, N., Landry, D., Ranjard, L., 2008. Copper dynamics and impact on microbial communities in soils of variable organic status. Environ. Sci. Technol. 42(8), 2819–2825. <https://doi.org/10.1021/ES071652R>.
20. Maione, C., Turra, C., Fernandes, E.A.D.N., Bacchi, M.A., Barbosa Jr, F., Barbosa, R.M., 2017. Finding the most significant elements for the classification of organic orange leaves: A data mining approach. Anal. Lett. 50(14), 2292–2307. <https://doi.org/10.1080/00032719.2017.1286667>.
21. Mehdizadeh, S., Behmanesh, J., Khalili, K., 2017. Application of gene expression programming to predict daily dew point temperature. Appl. Therm. Eng. 112, 1097–1107. <https://doi.org/10.1016/j.applthermaleng.2016.10.181>.
22. Mhalla, B., Ahmed, N., Datta, S.P., Golui, D., Singh, M., Shrivastava, M., 2021. Solubility relationship of metals in acid soils of Kumaon Himalaya region of India. Commun. Soil Sci. Plant Anal. 2(19), 2373–2387. <https://doi.org/10.1080/00103624.2021.1928170>.
23. Moreno-Lora, A., Delgado, A., 2020. Factors determining Zn availability and uptake by plants in soils developed under Mediterranean climate. Geoderma 376, 114509. <https://doi.org/10.1016/j.geoderma.2020.114509>.
24. Nelson, D.A., Sommers, L.E., 1983. Total carbon, organic carbon, and organic matter. In: Page, A.L. (Ed.), Methods of Soil Analysis: Part 2 Chemical and Microbiological Properties. ASA/SSSA, Madison, WI, pp. 539–579.
25. Olsen, S.R., 1954. Estimation of available phosphorus in soils by extraction with sodium bicarbonate. US Department of Agriculture, Washington, D.C.
26. Patel, M.B., Patel, J.N., Bhilota, U.M., 2022. Comprehensive modelling of ANN. In: Research Anthology on

- Artificial Neural Network Applications. IGI Global, Hershey, PA, pp. 31–40.
27. Rowell, D.L., 2014. Soil Science: Methods & Applications, 1st ed., Routledge, University of Reading, London.
 28. Sahoo, S., Jha, M.K., 2013. Groundwater-level prediction using multiple linear regression and artificial neural network techniques: A comparative assessment. *Hydrogeol. J.* 21(8), 1865–1887. <https://doi.org/10.1007/s10040-013-1029-5>.
 29. Sarhadi, J., Heidari, S., Sharif, M., 2020. The effect of organic, chemical fertilizer and superabsorbant on nutritional status of sure orange rootstock (*Citrus aurantium*). *Hortic. Plants Nutr.* 2(2), 198–212. <https://doi.org/10.22070/hpn.2020.4840.1047>. (In Persian with English abstract)
 30. Senkondo, Y.H., Tack, F.M.G., Semu, E., 2014. Copper accumulations in soils, coffee, banana, and bean plants following copper-based fungicides in coffee farms in Arusha and Kilimanjaro regions, Tanzania. *Commun. Soil Sci. Plant Anal.* 45(15), 2032–2045. <https://doi.org/10.1080/00103624.2014.919312>.
 31. Sihag, P., Esmailbeiki, F., Singh, B., Pandhiani, S.M., 2020. Model-based soil temperature estimation using climatic parameters: The case of Azerbaijan Province, Iran. *Geol. Ecol. Landsc.* 4(3), 203–215. <https://doi.org/10.1080/24749508.2019.1610841>.
 32. Soleimani, R., Chavoshi, E., Shirani, H., Boroujeni, I.E., 2021. Estimating least limiting water range (LLWR) of soil using artificial neural networks and genetic algorithms. *J. Soil Plant Interact.* 12(3), 101–114. <http://dx.doi.org/10.47176/jspi.12.3.08881>. (In Persian with English abstract)
 33. Yuan, T., Li, N., Sun, H., Tan, S., 2024. A joint estimation method of SOC and SOH for lithium-ion battery considering cyber-attacks based on GA-BP. *Comput. Mater. Continua.* 80(3), 4497–4512. <https://doi.org/10.32604/cmc.2024.056061>.