



Modeling the relationship between iron concentration in citrus leaves and some soil properties using artificial neural network (case study of southern Kerman province)

Saber Heidari^{1✉} | Seyed Ali Ghaffari Nejad² | Javad Sarhadi³ | Mehri Sharif³

1. Corresponding Author, Soil and Water Research Department, South Kerman Agricultural and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization (AREEO), Jiroft, Iran. E-mail: s.heydari@areeo.ac.ir
2. Soil and Water Research Institute, Agricultural Research, Education and Extension Organization (AREEO), Karaj, Iran. E-mail: ma_ghaffari51@yahoo.com
3. Soil and Water Research Department, South Kerman Agricultural and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization (AREEO), Jiroft, Iran. E-mail: javad.sarhadi2009@gmail.com
4. Soil and Water Research Department, South Kerman Agricultural and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization (AREEO), Jiroft, Iran. E-mail: saber.he@gmail.com

Article Info

ABSTRACT

Article type: Research Article

Article history:

Received: Dec. 12, 2023

Revised: Jan. 6, 2024

Accepted: Jan. 24, 2024

Published online: April. 2024

Keywords:

Citrus,
Multilayer Perceptron,
Soil Organic Matter,
Stepwise Regression.

This study was conducted to evaluate the relationship between leaf iron and some easily-available soil properties in citrus orchards in the southern region of Kerman province by artificial neural network modeling and stepwise regression. For this purpose, 40 orchards were selected from the study area and the physical and chemical properties of soil and iron in the plant leaves were measured. Using artificial neural network in different models with different data from soil properties as input and leaf iron as output, the ability of these models to predict leaf iron concentration was evaluated. The results showed artificial neural network with variables of organic carbon, pH, clay, phosphorus, TNV and electrical conductivity with explanation coefficient of 0.86 and 0.81 and root mean square error (RMSE) of 14.60 and 20.13 mg.kg⁻¹ for data Training and testing were the best models in estimating leaf iron. Comparison of regression and neural network models in the test data showed that the neural network had a higher accuracy with an explanation coefficient of 0.81 than stepwise regression with an explanation coefficient of 0.2. The amount of RMSE in the neural network also improved and increased from 27.72 mg.kg⁻¹ in the stepwise regression model to 20.13 mg.kg⁻¹ in the neural network. Artificial neural networks have been able to predict the iron in plant leaves based on the easily-available properties of the soil, so that by choosing organic carbon as the input of the first model to the best model by selecting organic carbon, pH, clay, phosphorus, TNV and electrical conductivity, model accuracy increased.

Cite this article: Heidari, S., Ghaffari Nejad, S.A., Sarhadi, J., & Sharif, M. (2024) Experimental investigation of the effect of implementing steps over chute on local scour variations downstream of a flip bucket, *Iranian Journal of Soil and Water Research*, 55 (2), 285-296. <https://doi.org/10.22059/ijswr.2024.369507.669619>

© The Author(s).

Publisher: The University of Tehran Press.

DOI: <https://doi.org/10.22059/ijswr.2024.369507.669619>



مدل سازی رابطه غلظت آهن در برگ مرکبات با برخی خصوصیات خاک با استفاده از شبکه عصبی مصنوعی (مطالعه موردی جنوب استان کرمان)

صابر حیدری^۱ | سید علی غفاری نژاد^۲ | جواد سرحدی^۳ | مهروی شریف^۴

۱. نویسنده مسئول، بخش تحقیقات خاک و آب، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی جنوب استان کرمان، سازمان تحقیقات، آموزش و ترویج کشاورزی، جیرفت، ایران. رایانامه: s.heydari@areeo.ac.ir

۲. موسسه تحقیقات خاک و آب، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران. رایانامه: ma_ghaffari51@yahoo.com

۳. بخش تحقیقات خاک و آب، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی جنوب استان کرمان، سازمان تحقیقات، آموزش و ترویج کشاورزی، جیرفت، ایران. رایانامه: javad.sarhadi2009@gmail.com

۴. بخش تحقیقات خاک و آب، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی جنوب استان کرمان، سازمان تحقیقات، آموزش و ترویج کشاورزی، جیرفت، ایران. رایانامه: saber.he@gmail.com

اطلاعات مقاله

چکیده

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۲/۹/۲۱

تاریخ بازنگری: ۱۴۰۲/۱۰/۱۶

تاریخ پذیرش: ۱۴۰۲/۱۱/۴

تاریخ انتشار: اردیبهشت ۱۴۰۳

واژه‌های کلیدی:

پرسپترون چند لایه،

رگرسیون گام به گام،

ماده آلی خاک،

مرکبات.

هدف از این پژوهش ارزیابی رابطه بین آهن موجود در برگ با برخی ویژگی‌های زود یافت خاک در باغات مرکبات منطقه جنوب استان کرمان به وسیله روش‌های مدل سازی شبکه عصبی مصنوعی و رگرسیون گام به گام بود. به همین منظور ۴۰ باغ بارده از کل منطقه انتخاب شده و خصوصیات فیزیکی و شیمیایی خاک و آهن موجود در برگ گیاه اندازه گیری شد. با استفاده از شبکه عصبی مصنوعی و مدل‌های مختلف با داده‌های متفاوت از ویژگی‌های خاک به عنوان ورودی و آهن برگ به عنوان خروجی، توانایی این مدل‌ها در پیش‌بینی غلظت آهن برگ مورد ارزیابی قرار گرفت. نتایج مدل سازی نشان داد شبکه عصبی مصنوعی با متغیرهای کربن آلی، پ‌هاس، رس، فسفر، درصد مواد خنثی شونده و هدایت الکتریکی با ضرایب تبیین ۰/۸۶ و ۰/۸۱ و ریشه میانگین مربعات خطا (RMSE) 60/14 و ۲۰/۱۳ میلی گرم بر کیلوگرم برای داده‌های آموزش و آزمون بهترین در برآورد آهن برگ بود. مقایسه مدل‌های رگرسیون و شبکه عصبی در داده‌های آزمون نشان داد که شبکه عصبی دقت بالاتری با ضریب تبیین ۰/۸۱ نسبت به رگرسیون گام به گام با ضریب تبیین ۰/۲ داشت. همچنین مقدار RMSE شبکه عصبی نیز بهبود بیشتری داشته و از ۲۷/۷۲ میلی گرم بر کیلوگرم در مدل رگرسیون گام به گام به ۲۰/۱۳ میلی گرم بر کیلوگرم در شبکه عصبی رسید. شبکه عصبی مصنوعی بر اساس ویژگی‌های زود یافت خاک قادر به پیش‌بینی آهن موجود در برگ گیاه بوده‌اند به گونه‌ای که با انتخاب کربن آلی به عنوان ورودی اولین مدل تا در بهترین مدل با انتخاب کربن آلی، پ‌هاس، رس، فسفر، درصد مواد خنثی شونده و هدایت الکتریکی، دقت مدل افزایش یافت.

استناد: حیدری، صابر؛ غفاری نژاد، سیدعلی؛ سرحدی، جواد؛ و شریف، مهروی، (۱۴۰۳) مدل سازی رابطه غلظت آهن در برگ مرکبات با برخی خصوصیات خاک با استفاده از شبکه عصبی مصنوعی (مطالعه موردی جنوب استان کرمان)، مجله تحقیقات آب و خاک ایران، ۵۵ (۲)، ۲۸۵-۲۹۶.



<https://doi.org/10.22059/ijswr.2024.369507.669619>

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijswr.2024.369507.669619>

مقدمه

جنوب استان کرمان (منطقه جیرفت و کهنوج) یکی از مناطق مستعد تولید مرکبات بوده و در حال حاضر با تولیدی در حدود ۵۰۰ هزار تن در سال رتبه سوم در کشور را دارا می‌باشد. یکی از مزیت‌های منطقه در تولید انواع مرکبات علاوه بر داشتن اقلیم نسبتاً خوب، داشتن خاک ایده‌آل از نظر خواص فیزیکی برای مرکبات است. اگرچه ارقام مختلفی از مرکبات در منطقه پرورش می‌یابد اما رقم والنسیا (*Citrus Sinensis var. Valencia*) از اهمیت ویژه‌ای برخوردار بوده و تولید آن نسبت به سایر ارقام بیشتر است (سرحدی و همکاران، ۱۳۹۸). عوامل متعددی از جمله وضعیت آب و هوایی، نوع پایه، شرایط گیاه، نوع آبیاری و شرایط خاک بر وضعیت تغذیه‌ای گیاه و جذب عناصر غذایی و در نتیجه کیفیت و کمیت میوه مرکبات اثرگذار است. مرکبات مقدار قابل توجهی از عناصر غذایی را از خاک جذب کرده و در زیست توده و اندام هوایی خود ذخیره می‌کند که بخشی از آن به اندام‌های در حال رشد مانند میوه‌ها، جوانه‌های در حال رشد توزیع می‌شود (Li et al., 2015).

تاکنون پژوهش‌های چندانی در مورد وضعیت عناصر ریزمغذی مانند آهن در مرکبات و شناسایی عوامل خاکی موثر بر آن با روش شبکه عصبی مصنوعی و مقایسه آن با روش رگرسیون گام به گام انجام نشده است. بنابراین هدف از این پژوهش ارزیابی رابطه بین آهن موجود در برگ مرکبات با برخی ویژگی‌های زودپافت خاک در باغات مرکبات منطقه جنوب استان کرمان به وسیله روش‌های مدل‌سازی شبکه عصبی مصنوعی و رگرسیون گام به گام بود.

پیشینه پژوهش

پژوهش‌های برخی از محققان نشان می‌دهد که در برخی موارد می‌تواند رابطه معنی‌داری بین محتوای عناصر موجود در برگ گیاه و خصوصیات یا محتوای عناصر موجود در خاک وجود داشته باشد. مهمترین عوامل موثر در عملکرد و کیفیت میوه و تجمع عناصر در اندام‌های هوایی می‌تواند هدایت الکتریکی، pH، درصد شن، سیلت و رس، میزان ماده آلی و غلظت برخی عناصر مانند پتاسیم و فسفر باشد (Cheng et al., 2016). پتاسیم کافی در خاک می‌تواند سبب افزایش عملکرد، اندازه میوه و غلظت عناصر در برگ مرکبات گردد (مرادی و عبادی، ۱۳۹۱). تاثیر pH نیز می‌تواند پاسخ متفاوتی در گیاه ایجاد کند به عنوان مثال افزودن مقدار بالای مس در خاک می‌تواند سبب کاهش غلظت عناصر پتاسیم، فسفر، کلسیم و منیزیم در برگ گیاه شود. در حالی که در خاک‌های دارای pH قلیایی کاهش اتفاق نمی‌افتد (Alva & Syvertsen, 1991). اثر بافت خاک نیز می‌تواند بر کیفیت میوه موثر باشد. گزارش شده است با افزایش مقدار رس خاک، عملکرد میوه مرکبات نیز افزایش یافت (Srivastava & Singh, 2004). برهمکنش منفی بین میزان فسفر خاک و جذب عناصر غذایی کم مصرف مانند آهن در پژوهش‌های مختلفی گزارش شده است (Sarhadi-Sardoui et al., 2003).

مطالعه روابط بین ویژگی‌های شیمیایی و فیزیکی محیط رشد یک گیاه و جذب عناصر مورد نیاز توسط گیاه می‌تواند منجر به شناخت و طراحی محیط رشد بهتری در آن گیاه شود. بنابراین می‌توان از ابزارهای آماری و ریاضی مانند رگرسیون خطی، رگرسیون لجستیک و مدل‌های ترکیبی آنها، در این جهت استفاده کرد (Dayhoff & DeLeo, 2001). در سال‌های اخیر استفاده از شبکه عصبی مصنوعی^۱ (ANN) در پیش‌بینی و مدل‌سازی روابط غیرخطی پدیده‌های مختلف که پیچیدگی زیادی داشته و مدل‌های خطی و آنالیزهای آماری معمول قادر به توضیح روابط بین این پدیده‌ها نیستند، گسترش یافته است (حسینی فرد و همکاران، ۱۳۹۸). در حقیقت شبکه عصبی مصنوعی بر اساس شبیه‌سازی سیستم عصبی مغز الهام گرفته شده است و با ارائه اطلاعات چند متغییره به صورت ورودی در آن و انتخاب وزن‌ها و توابع فعال‌ساز مناسب، می‌توان روابط عمدتاً غیرخطی را استخراج و شبیه‌سازی کرد (آجیلی لاهیجی و همکاران، ۱۳۹۸). مهمترین ویژگی شبکه عصبی مصنوعی که روش محاسباتی را مشخص می‌کند، فرآیند آموزش آن است. آموزش شبکه با تغییرات وزن‌های اختصاص داده شده در سیناپس‌ها یا اتصالات نرون‌ها با استفاده از الگوریتم‌های خاص انجام می‌گیرد. شناخته شده‌ترین الگوریتم یادگیری، روش پس انتشار^۲ است که در آن، خطای ایجاد شده ناشی از اختلاف بین خروجی سیستم و خروجی واقعی مجدداً به وزن‌های سیناپسی برگشت داده می‌شود (Prasad & Gupta, 2008). استفاده از شبکه عصبی مصنوعی توسط محققین مختلف در پیش‌بینی عملکرد سوبا (Wang et al., 2006)، کارائی مصرف آب (شیردلی و توسلی، ۱۳۹۴)، عملکرد تولید روغن‌های گیاهی (Gonzalez-Fernandez et al., 2019) مورد توجه و بررسی قرار گرفته است.

1 - Artificial Neural Network

2 - Back-propagation

روش‌شناسی پژوهش

موقعیت جغرافیایی منطقه مورد مطالعه

جنوب کرمان جزئی از ناحیه جنوب شرقی ایران محسوب شده و بر روی طول جغرافیایی ۵۶ درجه و ۱۷ دقیقه و عرض جغرافیایی ۲۶ درجه و ۴۳ دقیقه واقع شده است و از شمال به کرمان، از جنوب به باتلاق جازموریان و استان هرمزگان، از شرق به استان سیستان بلوچستان و بم، از غرب به شهرستان بافت و قسمتی از استان هرمزگان محدود شده است. منطقه مورد مطالعه شامل هفت شهرستان جیرفت، کهنوج، عنبرآباد، منوجان، رودبار جنوب، قلعه گنج و فاریاب است (سرحدی و همکاران، ۱۳۹۸).

آماده‌سازی نمونه‌ها

به منظور انجام این پژوهش، ۴۰ باغ بارده مرکبات از کل منطقه انتخاب شده و از هر باغ ۱۰ نمونه خاک از عمق صفر تا ۳۰ و ۳۱ تا ۶۰ سانتی‌متری از یک سوم انتهایی سایه انداز درختان سالم برداشت گردید. خاک‌ها پس از هوا خشک شدن از الک دو میلی‌متری عبور داده شدند و پس از مخلوط کردن پنج نمونه خاک، یک کیلوگرم نمونه مرکب از هر باغ و از هر عمق آماده گردید. درصد شن، سیلت، رس، درصد مواد خنثی شونده (TNV) (Rowell, 2014)، درصد کربن آلی (Nelson & Sommers, 1983)، pH خاک در خمیر اشباع و هدایت الکتریکی (EC) در عصاره اشباع (Allison & Richards, 1954) و فسفر به روش اولسن و همکاران (Olsen, 1954) اندازه‌گیری شد. همچنین نمونه‌های برگ بالغ (از قسمت میانی درخت) به تعداد ۲۰ عدد از هر درخت برداشت گردید. برگ‌ها در آزمایشگاه شسته و با آون در دمای ۷۰ درجه سانتیگراد خشک و با روش خشک سوزانی، هضم شدند و میزان آهن موجود در آن با روش جذب اتمی اندازه‌گیری گردید (Kalra, 1997).

روش رگرسیون گام به گام

در این پژوهش به منظور مدل‌سازی رابطه غلظت آهن در برگ با برخی از ویژگی‌های خاک، از روش‌های رگرسیون گام به گام و شبکه عصبی مصنوعی استفاده شد. برای رگرسیون گام به گام از نرم افزار SAS استفاده گردید. در روش رگرسیون گام به گام از رابطه زیر استفاده شد.

$$y = a + bx_1 + cx_2 + \dots \quad (\text{رابطه ۱})$$

که در این رابطه، y متغییر وابسته (خروجی مدل)، x_1, x_2 متغییر مستقل (متغیرهای ورودی به مدل) و a, b, c ثابت‌های مدل می‌باشند (Berk, 2004).

شبکه عصبی مصنوعی

به منظور مدل‌سازی شبکه عصبی مصنوعی، از نرم افزار MATLAB و شبکه عصبی پرسپترون چند لایه^۲ و الگوریتم یادگیری پس انتشار^۳ استفاده شد. نمای کلی از این شبکه در شکل ۱ نشان داده شده است. در این الگوریتم به منظور نزدیک کردن خروجی شبکه با خروجی واقعی داده‌ها و کاهش خطا، از روش گرادیان نزولی استفاده می‌شود که در آن داده‌ها از لایه ورودی به لایه پنهان و لایه خروجی عبور داده شده و پس از مقایسه خروجی شبکه و خروجی واقعی، میزان خطا محاسبه می‌شود. در ادامه این خطا به سمت لایه ورودی برگشت داده شده و از طریق تنظیم وزن‌های ارتباط داده شده بین لایه‌های شبکه مقدار خطا بهینه یا کاهش می‌یابد. این فرآیند تا ایجاد کمترین خطا و نزدیک‌ترین مقدار خروجی شبکه با خروجی واقعی ادامه می‌یابد. در این شبکه از الگوریتم لوببرگ-مارکوات به منظور آموزش شبکه استفاده شد (Minasny & McBratney, 2002).

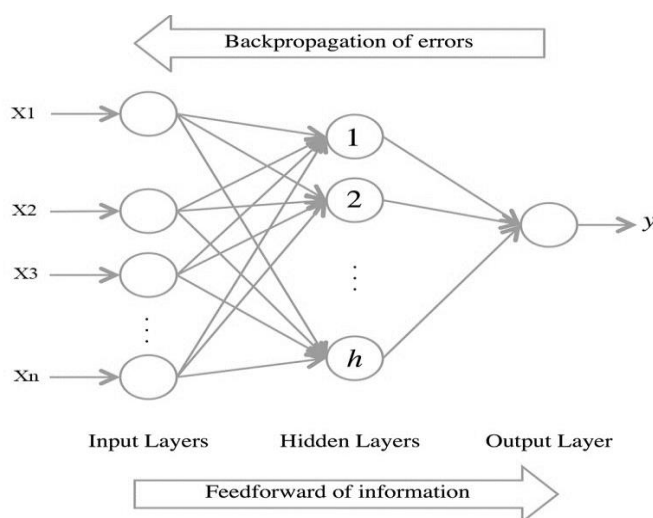
به منظور انتخاب بهترین شبکه عصبی مصنوعی، مدل‌های مختلفی با تعداد پارامترها ورودی متغییر (از ۱ تا ۷ ورودی در سناریوهای مختلف) (جدول ۴)، یک پارامتر خروجی مورد استفاده قرار گرفت. مدل‌ها حاوی یک لایه پنهان بود اما تعداد نرون‌های لایه پنهان برای بدست آوردن عملکرد بهتر در شبیه‌سازی بین ۲ تا ۱۵ نرون انتخاب شد. از بین ۴۰ داده، ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد برای آزمون به صورت تصادفی استفاده شد. در نهایت برای ارزیابی دقت و کارایی مدل‌های مختلف از شاخص‌های ضریب تبیین (R^2) (رابطه ۲) و ریشه میانگین مربعات خطا^۴ (RMSE) (رابطه ۳) استفاده شد.

1 - Total Neutralizing Value
2 - Multilayer perceptron
3 - Back Propagation
4 - Root Mean Square Error

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad \text{رابطه ۲}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad \text{رابطه ۳}$$

که y_i ، \hat{y}_i و \bar{y}_i به ترتیب مقادیر غلظت آهن اندازه گیری شده، برآورده شده توسط مدل و میانگین اندازه گیری شده می باشند. بهترین مدل، مدلی خواهد بود که مقدار R^2 و RMSE به ترتیب نزدیکترین مقادیر به یک و صفر را داشته باشند.



شکل ۱- نمای شماتیک از شبکه عصبی مصنوعی پرسپترون چند لایه با الگوریتم پس انتشار

یافته های پژوهش

در این پژوهش به منظور مدل سازی رابطه آهن برگ با ویژگی های فیزیکی و شیمیایی خاک از میانگین دو عمق صفر تا ۳۰ و ۳۰ تا ۶۰ سانتی متری خاک استفاده گردید. توصیف آماری برخی خصوصیات فیزیکی و شیمیایی خاک و آهن موجود در برگ در جدول ۱ ارائه گردید. در خاک های مطالعه شده، صفاتی مانند هدایت الکتریکی (EC)، درصد سیلت، درصد رس، درصد کربنات های خاک (TNV) دارای ضرایب تغییرات بالایی بودند که می تواند بیانگر دامنه گسترده تر این صفات باشد. از نظر قابلیت هدایت الکتریکی، تعداد ۹ خاک دارای EC بالای ۴ و بقیه خاک های EC کمتر از ۴ بودند. همچنین کلاس بافتی خاک ها بین شنی تا رسی بود. با توجه به راهنمای تفسیر نتایج آزمون برگ در مرکبات (Basirat et al., 2018)، از نظر آهن برگ بین کم تا زیاد در نوسان بود.

همبستگی بین خصوصیات خاک با غلظت آهن در برگ

در پژوهش حاضر، از ضرایب همبستگی پیرسون بین خصوصیات فیزیکی و شیمیایی خاک با غلظت آهن برگ استفاده شد (جدول ۲). نتایج نشان داد که مقدار ماده آلی خاک و مقدار آهن موجود در برگ همبستگی مثبت و معنی داری در سطح احتمال یک درصد دارد (جدول ۲).

رگرسیون گام به گام

همان طوری که در جدول ۳ نشان داده شده است، بر اساس نتایج تجزیه واریانس رابطه بین مقدار آهن موجود در برگ با ویژگی های خاک در سطح احتمال یک درصد معنی دار بود. در رگرسیون گام به گام، مقدار آهن برگ به عنوان متغیر وابسته و بقیه صفات خاک به عنوان متغیر مستقل در مدل وارد شد. معادله زیر (رابطه ۴)، مدل رگرسیونی رابطه آهن برگ با ویژگی های خاک را نشان می دهد:

$$\text{Fe-Leaf} = 91.31789 + 116.79214 \text{OC} \quad \text{رابطه ۴}$$

بنابر مدل به دست آمده، کربن آلی خاک با ضریب ۱۱۶/۷۹۲۱۴ تنها عامل موثر بر تخمین آهن برگ بوده است و بقیه متغیرهای مستقل وارد شده در مدل (هدایت الکتریکی، pH، سیلت، رس، درصد مواد خنثی شونده و فسفر خاک) بر برآورد مقدار آهن برگ تاثیر نداشتند.

جدول ۱- خلاصه آماری برخی ویژگی‌های خاک و آهن موجود در برگ

انحراف معیار Std Dev	میانگین Mean	کمینه Minimum	بیشینه Maximum	
۲/۴۹	۳/۰۴	۰/۵۵	۱۳/۳۵	EC (ds/m)
۰/۲۸	۷/۷۵	۷/۲۵	۸/۳۰	pH
۱۳/۲۱	۲۴/۶۷	۴/۲۰	۴۶/۴۵	Silt (%)
۵/۶۷	۸/۹۸	۳	۲۶/۵۰	Clay (%)
۳/۴۷	۶/۳۶	۰	۱۵/۳۷	TNV (%)
۰/۱۱	۰/۳۱	۰/۰۹	۰/۵۱	OC (%)
۳/۰۶	۶/۵۶	۰/۹۷	۱۲/۱۳	P (mg.kg ⁻¹)
۳۰/۳۳	۱۲۷/۷۹	۷۴/۵۰	۲۱۵/۵۰	Fe-Leaf (mg.kg ⁻¹)

جدول ۲- ماتریس ضرایب همبستگی بین صفات مورد مطالعه

FeLeaf (mg/kg)	P (mg/kg)	OC (%)	TNV (%)	Clay (%)	Silt (%)	pH	EC (ds/m)
							۱
						۱	-۰/۲۳
					۱	**۰/۳۶	**۰/۴۱
			۱	**۰/۷۱	*-۰/۳۸	-۰/۱۲	Clay (%)
			۱	**۰/۵۳	**۰/۴۶	-۰/۲۱	-۰/۲۰
		۱	-۰/۱۱	-۰/۲۸	-۰/۱۸	۰/۱۵	-۰/۰۷
	۱	*-۰/۳۵	۰/۲۲	۰/۱۷	۰/۱۶	-۰/۰۵	-۰/۱۱
۱	-۰/۱۶	**۰/۴۱	۰/۱۱	-۰/۰۳	۰/۰۸	-۰/۱۹	-۰/۱۷

* و ** به ترتیب معنی‌داری در سطح احتمال ۵ و ۱ درصد

جدول ۳- تجزیه واریانس رگرسیون Fe برگ با برخی ویژگی‌های خاک

F Value	میانگین مربعات Mean Square	مجموع مربعات Sum of Squares	درجه آزادی df	متغیر Variable
۸/۶۶**	۶۶۵۱/۵۷	۶۶۵۷/۵۱	۱	رگرسیون Regression
	۷۶۸/۸۵	۲۹۲۱۶	۳۸	خطا Error
		۳۵۸۷۴	۳۹	کل Total

** معنی‌داری در سطح احتمال یک درصد

شبکه عصبی مصنوعی

شبکه عصبی پرسپترون سه لایه با تعداد ۱ نرون در لایه خروجی و ۲ تا ۱۵ نرون در لایه میانی با الگوریتم پس انتشار خطا مورد استفاده قرار گرفت. با توجه به نتایج ضرایب همبستگی پیرسون (جدول ۲) و رگرسیون گام به گام (جدول ۳)، کربن آلی رابطه معنی‌دار در سطح احتمال یک درصد را به غلظت آهن برگ داشت. در نتیجه همانطور که در جدول ۴ نشان داده شده است در ابتدا کربن آلی به عنوان مدل تک متغیره در شبکه وارد شد و در ادامه دیگر مدل‌ها با افزودن سایر ویژگی‌های خاک ایجاد گردید. از تعداد ۴۰ نمونه، ۷۰ درصد از نمونه‌ها (۲۸ نمونه) برای آموزش و ۳۰ درصد (۱۲ نمونه) برای آزمون استفاده شد. در این پژوهش، آموزش شبکه با استفاده از توابع سیگموئیدی با تعداد نرون‌های مختلف در لایه میانی (از کم به زیاد) انجام گرفت و بهترین تعداد نرونی که بیشترین تاثیر را در بهبود خطا داشت، انتخاب گردید (جدول ۴).

همان‌طوری که در جدول ۴ نشان داده شده است، در مدل ANN 1 با انتخاب کربن آلی به عنوان تنها ورودی مدل و تعداد ۱۰ نرون در لایه میانی، مقدار ضرایب تبیین ۰/۳۳ و ۰/۳۲ برای داده‌های آموزش و آزمون به دست آمد که نسبت به ضریب تبیین همین مدل در رگرسیون گام به گام ($R^2=0/2$) عملکرد بهتری داشته است. نتایج سنجش خطا برای این مدل (ANN 1) در معیار RMSE در دوره

آموزش و آزمون به ترتیب ۲۷/۳۰ و ۵۲/۱۸ میلی‌گرم بر کیلوگرم بدست آمد. در مدل ANN 2 با افزودن متغیر pH به عنوان ورودی دقت پیش‌بینی (ضریب تبیین) تا حدودی افزایش یافته و به ۰/۵۰ و ۰/۴۷ برای داده‌های آموزش و آزمون رسید. همچنین سنجش خطا با توجه به ضریب RMSE به ۲۶/۸۴ و ۳۳/۹۴ میلی‌گرم بر کیلوگرم برای داده‌های آموزش و آزمون کاهش یافت. در ادامه با افزودن تعداد متغیرهای ورودی در مدل‌های ANN 3، ANN 4 و ANN 5 شاهد بهبود نسبی ضرایب تبیین و معیار سنجش خطا در داده‌های آموزش و آزمون بودیم. بهترین نتیجه در برآورد آهن برگ در مدل ANN 6 با متغیرهای کربن آلی، pH، رس، فسفر، TNV و هدایت الکتریکی با ضرایب تبیین ۰/۸۱ و ۰/۸۱ و RMSE ۱۴/۶۰ و ۲۰/۱۳ میلی‌گرم بر کیلوگرم برای داده‌های آموزش و آزمون بدست آمد.

جدول ۴- مدل شبکه عصبی برتر در رابطه بین Fe برگ با برخی ویژگی‌های خاک

داده های آزمون Test data		داده های آموزش Training data		تعداد نرون Number of neurons	ترکیب پارامترهای ورودی Composition of input parameters	مدل Model
RMSE	R ²	RMSE	R ²			
۵۲/۱۸	۰/۳۲	۲۷/۳۰	۰/۳۳	۱۰	OC	ANN 1
۳۳/۹۴	۰/۴۷	۲۶/۸۴	۰/۵۰	۷	OC, pH	ANN 2
۳۵/۰۵	۰/۴۵	۲۷/۶۹	۰/۴۸	۷	OC, pH, Clay	ANN 3
۴۴/۷۴	۰/۶۹	۱۸/۶۷	۰/۷۶	۵	OC, pH, Clay, P	ANN 4
۲۸/۶۸	۰/۶۵	۱۹/۱۲	۰/۷۴	۳	OC, pH, Clay, P, TNV	ANN 5
۲۰/۱۳	۰/۸۱	۱۴/۶۰	۰/۸۶	۴	OC, pH, Clay, P, TNV, EC	ANN 6
۳۸/۲۲	۰/۷۵	۱۵/۴۲	۰/۸۶	۸	OC, pH, Clay, P, TNV, EC, Silt	ANN 7

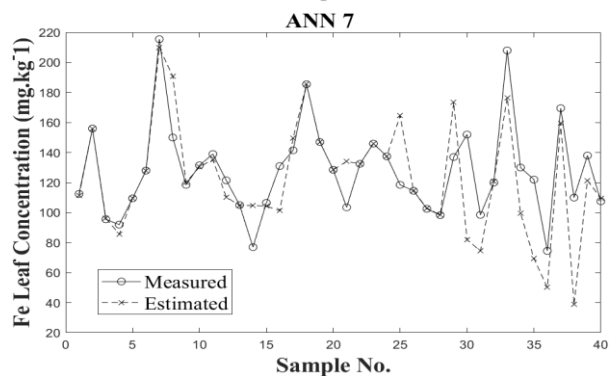
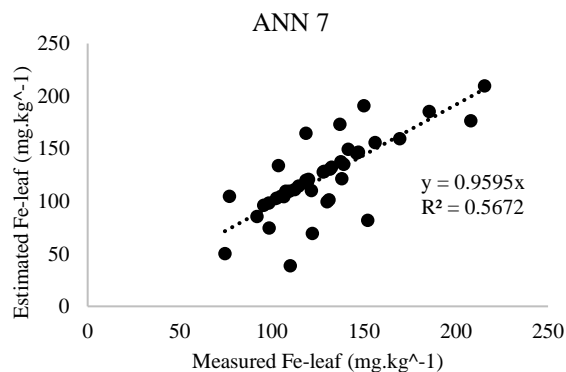



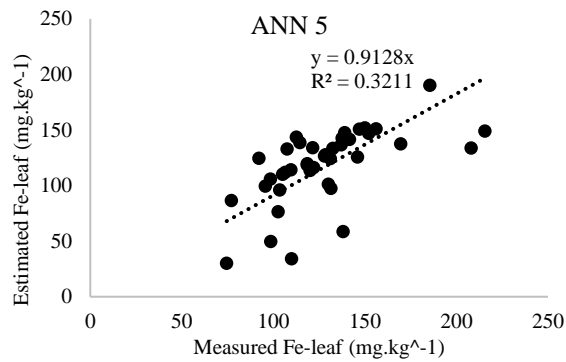
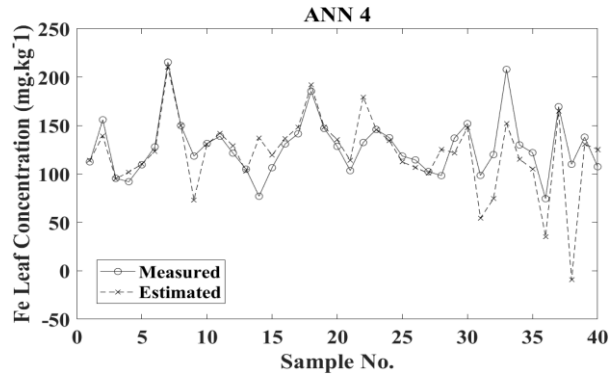

در شکل ۲ مقایسه مقادیر اندازه‌گیری شده و برآورد شده آهن برگ در مدل‌های شبکه عصبی ۴ تا ۷ که بهترین ضرایب تبیین و RMSE را داشتند، آورده شده است. همان‌طوری که در شکل ۲ مشاهده می‌شود، در مدل ANN 6 مقدار اندازه‌گیری شده و برآورد شده دارای بیشترین تطابق در داده‌ها بوده و کمترین انحراف را نسبت به خط ۱:۱ دارند. بر اساس نتایج جدول ۴ و شکل ۲ می‌توان دریافت که مهمترین ویژگی‌های خاکی موثر بر جذب و غلظت آهن در برگ گیاه، کربن آلی و پس از آن pH بود به صورتی که از ترکیب متغیرهای کربن آلی و pH در مدل ANN 2 ضرایب تبیین ۰/۵۰ و ۰/۴۸ در داده‌های آموزش و آزمون بدست آمد. پس از این دو متغیر، مهمترین ویژگی‌ها به ترتیب اهمیت شامل فسفر، هدایت الکتریکی بوده است.

مقایسه رگرسیون گام به گام و شبکه عصبی مصنوعی

در جدول ۵ مقایسه مدل‌های رگرسیون و شبکه عصبی در داده‌های آزمون نشان داده شده است. همان‌طور که در این جدول مشخص است، شبکه عصبی دقت بالاتری با ضریب تبیین ۰/۸۱ نسبت به رگرسیون گام به گام با ضریب تبیین ۰/۲ داشت. همچنین مقدار RMSE شبکه عصبی نیز بهبود بهتری داشته و از ۲۷/۷۲ میلی‌گرم بر کیلوگرم در مدل رگرسیون گام به گام به ۲۰/۱۳ میلی‌گرم بر کیلوگرم در شبکه عصبی رسید. با توجه به نتایج ضرایب تبیین و RMSE در پژوهش حاضر، شبکه عصبی مصنوعی عملکرد بهتری با خطای کمتر نسبت به رگرسیون گام به گام داشت.

جدول ۵- مقایسه مدل‌های رگرسیون و شبکه عصبی با معیارهای سنجش خطا

Fe	سنجش خطا	مدل Model
۰/۲۰	R ²	Regression
۲۷/۷۲	RMSE	
۰/۸۱	R ²	ANN 6
۲۰/۱۳	RMSE	



شکل ۲- مقایسه مقادیر اندازه‌گیری شده و برآورد شده آهن برگ در مدل‌های شبکه عصبی ۴ تا ۷ در مجموع داده‌های آموزش و آزمون

بحث

همبستگی مثبت بین غلظت عناصر کم مصرف در برگ و ماده آلی خاک در پژوهش‌های مختلفی گزارش شده است که بیان داشتند مواد آلی علاوه بر تامین عناصر مورد نیاز گیاه، در افزایش فعالیت‌های بیولوژیکی موثر در انحلال این عناصر و افزایش جذب آن توسط گیاه نقش دارد (Ahmad et al., 2022). همچنین رابطه منفی و غیرمعنی‌داری بین مقادیر pH خاک و آهن برگ وجود داشت. ضریب همبستگی بین اجزای معدنی خاک شامل درصد سیلت و رس با آهن برگ بسیار ضعیف و کمتر از یک درصد بود. ضریب همبستگی EC با آهن برگ نیز ۰/۱۷- بدست آمد که نشان‌دهنده همبستگی منفی و ضعیف آن می‌باشد. pH بالای خاک معمولاً منجر به رسوب عناصر مورد نیاز گیاه

می‌شود. از سوی دیگر، افزایش هدایت الکتریکی خاک به دلیل نمک‌های محلول در آب، پتانسیل اسمزی محلول خاک را تغییر می‌دهد که این تغییر منجر به کاهش سطح عناصر غذایی در گیاه می‌شود (Ahmad et al., 2022).

بیشتر خاک‌های باغات مرکبات منطقه دارای ماده آلی پایینی بودند (جدول ۱). دلیل اصلی کم بودن مواد آلی در باغات این منطقه ممکن است به دلیل دمای بالا و بارندگی کم باشد. با توجه به وجود عناصر مختلف خصوصا عناصر کم مصرف در ماده آلی، این مواد نقش مهمی را در تامین این عناصر برای گیاه از خاک ایفا می‌کنند. تجزیه میکربی ماده آلی سبب آزاد شدن عناصر موجود در آن و جذب توسط ریشه گیاه شده و سبب افزایش غلظت این عناصر در اندام‌های هوایی و در نهایت افزایش عملکرد گیاه می‌شود (میرسلیمانی و همکاران، ۱۳۹۸).

پتانسیل ردکس و pH دو عامل مهم در رفتار آهن در خاک هستند. شرایط اسیدی (کاهش pH) و احیا، به افزایش حلالیت آهن در خاک منجر می‌شوند (Wiseman & Püttmann, 2005). از دیگر فعالیت‌های موثر در افزایش حلالیت آهن در خاک فعالیت‌های باکتریایی در شرایط بی‌هوازی است. فعالیت این باکتری‌ها نیز تحت تاثیر ترشحات ریشه گیاه و مقادیر مواد آلی موجود در خاک است. تجزیه ماده آلی خاک یک فرآیند حیاتی مرتبط با چرخه آهن در خاک است که هم می‌تواند آهن موجود در این مواد را در دسترس گیاه قرار داده و هم در طول فرآیند تجزیه این مواد و تولید هیومیک اسید، قابلیت دسترسی آهن در خاک را افزایش دهد (Dhaliwal et al., 2019). pH بالای خاک‌های منطقه یکی از دلایل مهم کاهش قابلیت دسترسی عناصر کم مصرف و خصوصا آهن است. در دسترس بودن عناصر غذایی مورد نیاز گیاه با افزایش pH خاک، کاهش می‌یابد. یافته‌های مشابهی توسط خلید و همکاران (Khalid et al., 2012) انجام شد نشان داد که افزایش pH نقش مهمی در کاهش قابلیت جذب عناصر کم مصرف توسط مرکبات داشت. سرحدی و همکاران (۱۳۹۸) نیز یافته مشابهی در مورد افزایش هدایت الکتریکی خاک در کاهش و عدم تعادل عناصر کم مصرف در برگ مرکبات گزارش دادند و اثر افزایش هدایت الکتریکی بر کاهش رشد مرکبات را به عواملی مانند استرس اسمزی ناشی از عدم دسترسی به آب، اثرات سمی برخی از یون‌ها در فرآیندهای متابولیک سلولی و عدم تعادل در جذب عناصر غذایی ناشی از سمیت یون‌ها مربوط دانستند.

سرویواتساوا و سیک (Srivastava & Singh, 2005) بیان داشتند که وجود فسفر در خاک به صورت معنی‌داری سبب کاهش غلظت آهن در برگ درختان مرکبات شده است که احتمالا به دلیل کاهش انتقال آهن از ریشه به اندام‌های هوایی گیاه است. انتقال آهن در گیاه توسط سیترات انجام می‌گیرد و فسفر به دلیل رقابت با سیترات مانع از انتقال آهن می‌شود (Mathan & Amberger, 1977) محققان دیگری نیز نتایج مشابهی در پژوهش‌های مختلف بدست آوردند و گزارش دادند که شبکه عصبی مصنوعی نسبت به رگرسیون برآورد بهتری بر اساس داده‌های زودیافت خاک داشتند (Abrougui et al., 2019; Torkashvand et al., 2020). روستایی و همکاران (Roustaei et al., 2018) در مطالعه‌ای به منظور ارزیابی کارایی شبکه عصبی مصنوعی و رگرسیون چند متغیره در پیش‌بینی تغییرپذیری مکانی شوری خاک، گزارش دادند که شبکه عصبی مصنوعی کارایی بهتری با ضریب تبیین ۰/۷۹ و RMSE ۰/۱۱ داشت. جمشیدی و همکاران (Jamshidi et al., 2016) از مدل‌های شبکه عصبی مصنوعی و رگرسیون گام به گام در پیش‌بینی عملکرد گلایی بر اساس غلظت عناصر غذایی استفاده کردند. نتایج آنان نشان داد که شبکه عصبی عملکرد بهتری نشان داده و از بین ویژگی‌های مورد اندازه‌گیری شده، آمونیوم، نیترات، پتاسیم بالاترین ارزش در برآورد بهینه عملکرد داشتند.

نتیجه‌گیری

نتایج مدل‌سازی به دو روش رگرسیون و شبکه عصبی مصنوعی نشان داد که آهن موجود در برگ گیاه بیشترین ارتباط را با مقدار ماده آلی و pH خاک داشت. این پژوهش نشان داد که مدل‌های ساخته شده با شبکه عصبی مصنوعی بر اساس ویژگی‌های زودیافت خاک قادر به پیش‌بینی آهن موجود در برگ گیاه بوده‌اند به گونه‌ای که با انتخاب کربن آلی به عنوان ورودی اولین مدل تا در بهترین مدل با انتخاب کربن آلی، pH، رس، فسفر، TNV و هدایت الکتریکی، دقت مدل از ۰/۳۲ به ۰/۸۱ افزایش یافت.

"هیچ‌گونه تعارض منافع بین نویسندگان وجود ندارد"

منابع

آجیلی لاهیجی، علی؛ محمدی ترکاشوند، علی؛ محنت کش، عبدالمحمد؛ نویدی، میرناصر. (۱۳۹۸). تعیین مهمترین عوامل موثر بر عملکرد باغات



زیتون شمال ایران. علوم باغبانی، ۳۳(۴)، ۷۴۳-۷۵۵.

- حسینی فرد، سیدجواد؛ شیرانی، حسین؛ صدر، سمیه؛ هاشمی پور، حکیمه. (۱۳۹۸). مدل سازی ارتباط کادمیم با برخی از ویژگی های فیزیکی و شیمیایی خاک در باغ های پسته با استفاده از رگرسیون و شبکه عصبی مصنوعی. فصلنامه علوم محیطی، ۱۷(۳)، ۱۷۷-۱۸۸.
- سرحدی، جواد؛ حیدری، صابر؛ شریف، مهری. (۱۳۹۸). تاثیر کود آلی، شیمیایی و سوپرچاذب بر وضعیت تغذیه ای نهال پایه نارنج (Citrus aurantium). نشریه تغذیه گیاهان باغی، ۲(۲)، ۱۹۸-۲۱۲.
- شیردلی، عظیم؛ توسلی، ابوالفضل. (۱۳۹۴). پیش بینی عملکرد و کارایی مصرف آب زعفران با استفاده از مدل های شبکه عصبی مصنوعی بر مبنای فاکتورهای اقلیمی و آب. زراعت و فناوری زعفران، ۳(۲)، ۱۲۱-۱۳۱.
- میرسلیمانی، عباس؛ امین، حسین؛ نجفی قیری، مهدی. (۱۳۹۸). بررسی روابط ویژگی های خاک و غلظت عناصر برگ با ویژگی های کیفی میوه پرتقال واشنگتن ناول در منطقه داراب، استان فارس. نشریه تولید و فرآوری محصولات زراعی و باغی، ۹(۲)، ۱۵۷-۱۷۱.
- مرادی، بیژن؛ عبادی، هرمز. (۱۳۹۱). بررسی خصوصیات کمی و کیفی پرتقال تامسون ناول روی پایه سیتروملو با استفاده از کود پتاسیم و آبیاری تکمیلی. پژوهش های تولید گیاهی، ۱۸(۳)، ۴۷-۶۲.

REFERENCES

- Abrougui, K., Gabsi, K., Mercatoris, B., Khemis, C., Amami, R., & Chehaibi, S. (2019). Prediction of organic potato yield using tillage systems and soil properties by artificial neural network (ANN) and multiple linear regressions (MLR). *Soil and Tillage Research*, 190, 202-208. <https://doi.org/https://doi.org/10.1016/j.still.2019.01.011>
- 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/https://doi.org/10.3390/horticulturae8010061>
- Ajili Lahiji, A., Mohammadi Torkashvand, A., Mehnatkesh, A., & Navidi, M. (2020). Determination of the Most Important Factors Affecting Yield of Olive (*Olea europaea* L.) Orchards in the North of Iran. *Journal Of Horticulture Science (Agricultural Sciences And Technology)*, 33(4), 743-755. <https://doi.org/https://doi.org/10.1080/01904169109364237> (In Persian)
- Allison, L., & Richards, L. (1954). *Diagnosis and improvement of saline and alkali soils*. Soil and Water Conservative Research Branch, Agricultural Research Service.
- Alva, A., & Syvertsen, J. (1991). Irrigation water salinity affects soil nutrient distribution, root density, and leaf nutrient levels of citrus under drip fertigation. *Journal of plant nutrition*, 14(7), 715-727.
- Basirat, M., Haghghatnia, H., & Mousavi, S. M. (2018). Evaluation and Determination the Nutritional Status of Valencia Orange Orchards in South of Fars Province. *Water and Soil*, 32(1), 143-154. <https://doi.org/10.22067/jsw.v32i1.67597>
- Cheng, J., Ding, C., Li, X., Zhang, T., & Wang, X. (2016). Soil quality evaluation for navel orange production systems in central subtropical China. *Soil and Tillage Research*, 155, 225-232. <https://doi.org/https://doi.org/10.1016/j.still.2015.08.015>
- Dayhoff, J. E., & DeLeo, J. M. (2001). Artificial neural networks: opening the black box. *Cancer: Interdisciplinary International Journal of the American Cancer Society*, 91(S8), 1615-1635. [https://doi.org/https://doi.org/10.1002/1097-0142\(20010415\)91:8+%3C1615::AID-CNCR1175%3E3.0.CO;2-L](https://doi.org/https://doi.org/10.1002/1097-0142(20010415)91:8+%3C1615::AID-CNCR1175%3E3.0.CO;2-L)
- Dhaliwal, S. S., Naresh, R. K., Mandal, A., Singh, R., & 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*, 1-2, 100007. <https://doi.org/https://doi.org/10.1016/j.indic.2019.100007>
- Gonzalez-Fernandez, I., Iglesias-Otero, M., Esteki, M., Moldes, O., Mejuto, J., & Simal-Gandara, J. (2019). A critical review on the use of artificial neural networks in olive oil production, characterization and authentication. *Critical reviews in food science and nutrition*, 59(12), 1913-1926. <https://doi.org/https://doi.org/10.1080/10408398.2018.1433628>
- 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 [(In Persian)]. *Environmental Sciences*, 17(3), 177-188. <https://doi.org/https://doi.org/10.29252/envs.17.3.177> (In Persian)
- Jamshidi, S., Yadollahi, A., Ahmadi, H., Arab, M. M., & Eftekhari, M. (2016). Predicting In vitro Culture Medium Macro-Nutrients Composition for Pear Rootstocks Using Regression Analysis and Neural Network Models [Methods]. *Frontiers in Plant Science*, 7. <https://doi.org/10.3389/fpls.2016.00274>

- Kalra, Y. (1997). Handbook of reference methods for plant analysis. CRC press.
- Khalid, R., Mahmood, T., Bibi, R., Siddique, M. T., Alvi, S., & Naz, S. Y. (2012). Distribution and indexation of plant available nutrients of rainfed calcareous soils of Pakistan. *Soil and Environment*, 31(2), 146-151.
- Li, Y., Han, M.-Q., Lin, F., Ten, Y., Lin, J., Zhu, D.-H., Guo, P., Weng, Y., & Chen, L.-S. (2015). Soil chemical properties, 'Guanximiyou' pummelo leaf mineral nutrient status and fruit quality in the southern region of Fujian province, China. *Journal of soil science and plant nutrition*, 15(3), 615-628. <https://doi.org/http://dx.doi.org/10.4067/S0718-95162015005000029>
- Mathan, K., & Amberger, A. (1977). Influence of iron on the uptake of phosphorus by maize. *Plant and Soil*, 46(2), 413-422. <https://doi.org/https://doi.org/10.1007/BF00010097>
- Minasny, B., & McBratney, A. B. (2002). The neuro-m method for fitting neural network parametric pedotransfer functions. *Soil Science Society of America Journal*, 66(2), 352-361. <https://doi.org/https://doi.org/10.2136/sssaj2002.3520>
- Mirsoleimani, A., Amin, H., & Najafi Ghiri, M. (2019). Investigating the Relationship of Soil Properties and Leaf Element Concentration with Qualitative Characteristics of the Washington Navel Orange Fruit in Darab Region, Fars province [(In Persian)] [Research]. *Journal of Crop Production and Processing*, 9(2), 157-171. <https://doi.org/10.29252/jcpp.9.2.157> (In Persian)
- Moradi, B., & Ebadi, H. (2011). Investigation of quantitative and qualitative characteristics of Thomson Navel orange on Citrumelo rootstock as affected by potassium and supplementary irrigation [(In Persian)]. *Journal of Plant Production (Journal of Agricultural Sciences and Natural Resources)*, 18(3), 47-62. <https://doi.org/https://dorl.net/dor/20.1001.1.23222050.1390.18.3.4.7> (In Persian)
- Nelson, D. a., & Sommers, L. E. (1983). Total carbon, organic carbon, and organic matter. In *Methods of soil analysis: Part 2 chemical and microbiological properties* (Vol. 9, pp. 539-579).
- Olsen, S. R. (1954). Estimation of available phosphorus in soils by extraction with sodium bicarbonate. US Department of Agriculture.
- Prasad, V., & Gupta, S. D. (2008). Applications and potentials of artificial neural networks in plant tissue culture. In *Plant tissue culture engineering* (pp. 47-67). Springer.
- Roustaei, F., Ayoubi, S., & Norouzi Masir, M. (2018). Comparison of artificial neural network and multiple linear regressions efficiency for predicting soil salinity in Yazd -Ardakan plain, central Iran. *Desert Ecosystem Engineering Journal*, 1(1), 11-20. <https://doi.org/10.22052/jdee.2017.62315>
- Rowell, D. L. (2014). *Soil Science: Methods & Applications (1st ed.)*. Routledge, University of Reading, London. <https://doi.org/https://doi.org/10.4324/9781315844855>
- Sarhadi-Sardoui, J., Ronaghi, A., Maftoun, M., & Karimian, N. (2003). Growth and chemical composition of corn in three calcareous sandy soils of Iran as affected by applied phosphorus and manure. *Journal of Agricultural Science* 5, 77-84.
- Sarhadi, J., heidari, s., & Sharif, M. (2020). The effect of organic, chemical fertilizer and superabsorbant on nutritional status of sure orange rootstock (*Citrus aurantium*) [(In Persian)]. *Horticultural Plants Nutrition*, 2(2), 198-212. <https://doi.org/10.22070/hpn.2020.4840.1047> (In Persian)
- Shirdeli, A., & Tavassoli, A. (2015). Predicting yield and water use efficiency in saffron using models of artificial neural network based on climate factors and water [(In Persian)]. *Saffron agronomy and technology*, 3(2), 121-131. <https://doi.org/https://doi.org/10.22048/jsat.2015.10381> (In Persian)
- Srivastava, A., & Singh, S. (2004). Leaf and soil nutrient guide in citrus—A review. *Agricultural Reviews*, 25(4), 235-251.
- Srivastava, A., & Singh, S. (2005). Soil and plant nutritional constraints contributing to citrus decline in Marathwada region, India. *Communications in soil science and plant analysis*, 35(18), 2537-2550. <https://doi.org/https://doi.org/10.1081/LCSS-200030359>
- Torkashvand, A. M., Ahmadipour, A., & Mousavi Khaneghah, A. (2020). Estimation of kiwifruit yield by leaf nutrients concentration and artificial neural network. *The Journal of Agricultural Science*, 158(3), 185-193. <https://doi.org/10.1017/S002185962000043X>
- Wang, L., Qi, G., Fu, Q., & Liu, Y. (2006). Soybean Yield Forecast Application Based on HOPFIELD ANN Model. *The Journal of American Science*, 2(3), 85-89.
- Wiseman, C., & Püttmann, W. (2005). Soil organic carbon and its sorptive preservation in central Germany. *European Journal of Soil Science*, 56(1), 65-76. <https://doi.org/https://doi.org/10.1111/j.1351-0754.2004.00655.x>



Modeling the Relationship between Iron Concentration in Citrus Leaves and Some Soil Properties Using Artificial Neural Network (Case Study of Southern Kerman Province)

EXTENDED ABSTRACT

Introduction

Studying the relationships between the chemical and physical characteristics of a plant's growing environment and the uptake of required elements by the plant can lead to better knowledge and design of the growing environment in that plant. Therefore, statistical and mathematical tools such as linear regression, logistic regression, and their combined models can be used in this direction. In recent years, the use of the artificial neural network (ANN) in predicting and modeling the nonlinear relationships of various phenomena that have great complexity, and the usual linear models and statistical analyzes that are unable to explain the relationships has expanded. The purpose of this study was conducted to evaluate the relationship between leaf iron and some easily-available soil properties in citrus orchards in the southern region of Kerman province by artificial neural network modeling and stepwise regression.

Materials and methods

The studied area is the south of Kerman province and includes seven cities: Jiroft, Kohnouj, Anbarabad, Manojan, Rudbar Janub, Ghaleganj and Faryab. To conduct this research, 40 orchards were selected from the study area and the physical and chemical properties of soil and iron in the plant leaves were measured. To model the relationship between iron concentration in leaves and some soil characteristics, stepwise regression and artificial neural network methods were used. To model the artificial neural network, MATLAB software, multilayer perceptron neural network, and backpropagation learning algorithm were used. using artificial neural networks in different models with different data from soil properties as input and leaf iron as output, the ability of these models to predict leaf iron concentration was evaluated and compared with the stepwise regression model.

Results and Discussion

The results of the regression model showed that soil organic carbon with a coefficient of 116.79 was the most and the only effective factor in the estimation of leaf iron, and the rest of the independent variables in the model did not affect the estimation of leaf iron. Most of the soils of citrus orchards in the region had low organic matter. The modeling results showed that in the ANN 1 model, with the selection of organic carbon as the only model input and the number of 10 neurons in the middle layer, the value of the regression coefficients was 0.33 and 0.32 for the training and test data, which had a better performance than the same model in stepwise regression. In the ANN 2 model, by adding the pH variable as an input, the prediction accuracy (regression coefficient) increased and reached 0.50 and 0.47 for the training and test data. Further, by adding the number of input variables in the ANN 3, ANN 4, and ANN 5 models, the relative improvement of the regression coefficients and error in the training and test data was achieved. The best result in the estimation of leaf iron was obtained in the ANN 6 model. The artificial neural network with variables of organic carbon, pH, clay, phosphorus, TNV, and electrical conductivity with regression coefficients of 0.86 and 0.81 and root mean square error (RMSE) of 14.60 and 20.13 mg/kg for data Training and testing were the best models in estimating leaf iron. The results of the neural network showed that the most important soil characteristic affecting iron absorption and concentration in plant leaves was organic carbon, followed by pH, and after these two variables, the most important characteristics in order of importance were phosphorus, and electrical conductivity. Comparison of regression and neural network models in the test data showed that the neural network had a higher accuracy with a regression coefficient of 0.81 than stepwise regression with a regression coefficient of 0.2. The amount of RMSE in the neural network also improved and increased from 27.72 mg.kg⁻¹ in the stepwise regression model to 20.13 mg.kg⁻¹ in the neural network.

Conclusion

The results of modeling using two methods of regression and an artificial neural network showed that the iron in plant leaves was most closely related to the amount of organic matter and soil pH. Artificial neural networks have been able to predict the iron in plant leaves based on the easily-available properties of the soil so by choosing organic carbon as the input of the first model to the best model by selecting organic carbon, pH, clay, phosphorus, TNV, and electrical conductivity, model accuracy increased.

Keywords: Citrus, Multilayer Perceptron, Soil Organic Matter, Stepwise Regression.