

Modeling Soil Penetration Resistance Using Regression, Artificial Neural Network and Gene Expression Programming

Sh. Asghari^{1*}, M. Hasanpour Kashani², H. Shahab Arkhazloo³

1 and 3- Professor and Associate Professor, Department of Soil Sciences and Engineering, Faculty of Agriculture and Natural Resources, University of Mohaghegh Ardabili, Ardabil, Iran, respectively.

(*- Corresponding Author Email: shasghari@uma.ac.ir)

2- Assistant Professor, Water Engineering Department, Faculty of Agriculture and Natural Resources, University of Mohaghegh Ardabili, Ardabil, Iran

Received: 12-02-2024
Revised: 05-03-2024
Accepted: 19-03-2024
Available Online: 19-03-2024

How to cite this article:

Asghari, Sh., Hasanpour Kashani, M., & Shahab Arkhazloo, H. (2024). Modeling soil penetration resistance using regression, artificial neural network and gene expression programming. *Journal of Water and Soil*, 38(2), 269-283. (In Persian with English abstract). [https://doi.org/ 10.22067/JSW.2024.86792.1385](https://doi.org/10.22067/JSW.2024.86792.1385)

Introduction

The penetration resistance (PR) of the soil shows the mechanical resistance of the soil against the penetration of a conical or flat probe; it is important in terms of seed germination, root growth and tillage operations. In general, if the PR value of a soil exceeds 2.5 MPa, the growth and expansion of roots in the soil will be significantly limited. The direct measurement of PR is also a laborious and costly task due to instrumental errors. Therefore, it is useful the use of different models such as multiple linear regression (MLR), artificial neural network (ANN) and gene expression programming (GEP) to estimate PR through easily accessible and low-cost soil characteristics. The objectives of this research were: (1) to obtain MLR, ANN and GEP models for estimating PR from the easily accessible soil variables in forest, range and cultivated lands of Fandoghloo region of Ardabil province, (2) to compare the accuracy of the aforementioned models in estimating soil PR using the coefficient of determination (R^2), root mean square error (RMSE), mean error (ME) and Nash-Sutcliffe coefficient (NS) criteria.

Materials and Methods

Disturbed and undisturbed samples ($n = 80$) were nearly systematically taken from 0-10 cm soil depth with nearly 50 m distance in forest ($n = 20$), range ($n = 23$) and cultivated ($n = 37$) lands of Fandoghloo region of Ardabil province, Iran (lat. $38^\circ 24' 10''$ to $38^\circ 24' 25''$ N, long. $48^\circ 32' 45''$ to $48^\circ 33' 5''$ E) in summer 2023. The contents of sand, silt, clay, CaCO_3 , pH, EC, bulk (BD) and particle density (PD), organic carbon (OC), gravimetric field water content (FWC), mean weight diameter (MWD) and geometric mean diameter (GMD) were measured in the laboratory. Relative bulk density (BD_{rel}) was calculated using BD and clay data. Mean geometric diameter (d_g) and geometric standard deviation (σ_g) of soil particles were computed by sand, silt and clay percentages. The penetration resistance (PR) of the soil was measured in situ using cone penetrometer (analog model) at 5 replicates. Data randomly were divided in two series as 60 data for training and 20 data for testing of models. The SPSS 22 software with stepwise method, MATLAB and Gene Xpro Tools 4.0 software were used to derive multiple linear regression (MLR), artificial neural network (ANN) and gene expression programming (GEP) models, respectively. A feed forward three-layer (2, 5 and 6 neurons in hidden layer) perceptron network and the tangent sigmoid transfer function were used for the ANN modeling. A set of optimal parameters were chosen before developing a best GEP model. The number of chromosomes and genes, head size and linking function were selected by the trial and error



©2024 The author(s). This is an open access article distributed under [Creative Commons Attribution 4.0 International License \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/), which permits use, sharing, adaptation, distribution and reproduction in any medium or format, as long as you give appropriate credit to the original author(s) and the source.

[https://doi.org/ 10.22067/JSW.2024.86792.1385](https://doi.org/10.22067/JSW.2024.86792.1385)

method, as they are 30, 3, 8, and +, respectively. The rates of genetic operators were chosen according to literature studies. The accuracy of MLR, ANN and GEP models in estimating PR were evaluated by coefficient of determination (R^2), root mean square error (RMSE), mean error (ME) and Nash-Sutcliffe coefficient (NS) statistics.

Results and Discussion

The studied soils had clay loam ($n = 11$), sandy clay loam ($n = 6$), sandy loam ($n = 12$), loam ($n = 13$), silty clay loam ($n = 14$), silty clay ($n = 1$) and silt loam ($n = 23$) textural classes. The values of sand (13.14 to 64.79 %), silt (21.11 to 74.96 %), clay (2.95 to 42.18 %), OC (1.01 to 7.17 %), FWC (11.58 to 50.47 mass percent), BD (0.84 to 1.43 g cm^{-3}) and PR (1.03 to 5.83 MPa) showed good variations in the soils of the studied region. There were found significant correlations between PR with FWC ($r = -0.45^{**}$), silt ($r = -0.36^{**}$) and σ_g ($r = 0.36^{**}$). Due to the multicollinearity of silt with σ_g ($r = -0.84^{**}$), the σ_g was not used as an input variable to estimate PR. Generally, 3 MLR, ANN and GEP models were constructed to estimate PR from measured readily available soil variables. The results of MLR, ANN and GEP models showed that the most suitable variables to estimate PR were FWC, silt and BDrel. The values of R^2 , RMSE, ME and NS criteria were obtained equal 0.44, 1.19 MPa, 0.19 MPa and 0.36, and 0.92, 0.41 MPa, -0.05 MPa and 0.92, 0.79, 0.91 MPa, 0.13 MPa, 0.63 for the best MLR, ANN and GEP models, respectively. The former researchers also reported that there is a negative and significant correlation between PR with FWC.

Conclusion

The results indicated that field water content (FWC), silt and relative bulk density (BDrel) were the most important and readily available soil variables to estimate penetration resistance (PR) in the studied area. According to the lowest values of RMSE and the highest values of NS, the accuracy of ANN models to predict soil PR was higher than MLR and GEP models in this research.

Keywords: Estimation, Fandoghloo region, Gravitational water content, Readily variables, Soil resistance

مقاله پژوهشی

جلد ۳۸، شماره ۲، خرداد-تیر ۱۴۰۳، ص. ۲۸۳-۲۶۹

مدل‌سازی مقاومت فروروی خاک با استفاده از رگرسیون، شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن

شکراله اصغری^{۱*} - مهسا حسنیور کاشانی^۲ - حسین شهاب آرخالو^۳

تاریخ دریافت: ۱۴۰۲/۱۱/۲۳

تاریخ پذیرش: ۱۴۰۲/۱۲/۲۹

چکیده

اطلاع از مقاومت فروروی (PR) خاک از نظر جوانه‌زنی بذر، رشد ریشه و عملیات خاک‌ورزی اهمیت فراوان دارد. اندازه‌گیری مستقیم PR خاک به دلیل تغییرپذیری مکانی و زمانی شدید آن، کاری پرهزینه و گران می‌باشد. هدف از این پژوهش، ارائه مدل‌های رگرسیون خطی (MLR)، شبکه عصبی مصنوعی (ANN) و برنامه‌ریزی بیان ژن (GEP) برای برآورد PR از روی ویژگی‌های زودبافت خاک بود. در مجموع ۸۰ نمونه خاک سطحی (۰ تا ۱۰ cm دست‌خورده و دست‌نخورده) با استفاده از استوانه‌های استیل به قطر و ارتفاع ۵ سانتی‌متر از اراضی جنگلی، مرتعی و زراعی منطقه فندقلوی اردبیل در تابستان ۱۴۰۲ برداشته شد سپس برخی خصوصیات فیزیکی و شیمیایی زودبافت خاک در آنها اندازه‌گیری شد. مقاومت فروروی خاک به‌طور درجا در محل با استفاده از یک فروسنج مخروطی تعیین گردید و همزمان رطوبت خاک مزرعه در استوانه‌ها اندازه‌گیری شد. داده‌ها به‌طور تصادفی به دو گروه آموزشی (۶۰ نمونه) و آزمونی (۲۰ نمونه) تقسیم گردید. مدل‌های ANN، MLR، GEP به‌ترتیب با استفاده از نرم‌افزارهای SPSS، MATLAB و Gene Xpro Tools ایجاد شدند. نتایج مدل‌سازی نشان داد که رطوبت خاک مزرعه، سیلت و جرم مخصوص ظاهری نسبی، مهم‌ترین متغیرهای ورودی در برآورد PR خاک بودند. مقادیر آماره‌های ضریب تبیین (R^2)، مجذور میانگین مربعات خطا (RMSE)، میانگین خطا (ME) و ضریب نش-ساتکلیف (NS) براساس داده‌های آزمونی برابر 0.43 ، 1.19 MPa، 0.19 MPa و 0.36 ، 0.92 ، 0.41 MPa، 0.05 MPa و 0.79 ، 0.92 ، 0.91 MPa، 0.13 MPa و 0.63 به‌ترتیب برای بهترین مدل ANN، MLR، GEP تعیین گردید. براساس نتایج آماره‌های ارزیابی مدل‌ها، می‌توان گفت که در منطقه مورد مطالعه، مدل ANN از بیشترین دقت و مدل MLR از کمترین دقت در برآورد PR خاک برخوردار بود.

واژه‌های کلیدی: تخمین، رطوبت جرمی، مقاومت خاک، منطقه فندقلو، ویژگی زودبافت

مقدمه

مقاومت فروروی^۴ (PR) خاک که مقاومت مکانیکی خاک را در برابر نفوذ یک فروسنج مخروطی یا مسطح نشان می‌دهد، از نظر جوانه زنی بذر، رشد ریشه و عملیات خاک‌ورزی حائز اهمیت است. به‌طور کلی، اگر مقدار PR یک خاک از $2/5$ مگاپاسکال فراتر رود رشد و

گسترش ریشه در خاک به‌طور معنی‌دار محدود خواهد شد (Whalley *et al.*, 2007).

مقاومت فروروی (PR) خاک با تغییر سایر ویژگی‌های خاک مانند کربن آلی، جرم مخصوص ظاهری و رطوبت خاک مزرعه، با زمان و مکان تغییر پیدا می‌کند. به‌طور مثال، اصغری و همکاران (Asghari *et al.*, 2017) گزارش کردند ضریب تغییرات (CV) مقاومت فروروی

۱ و ۳- به‌ترتیب استاد و دانشیار، گروه علوم و مهندسی خاک، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل، ایران
* نویسنده مسئول: (Email: shasghari@uma.ac.ir)

۲- استادیار، گروه مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل، ایران

برآورد هدایت هیدرولیکی نزدیک اشباع خاک در دشت مغان استان اردبیل برخوردار بود. نتایج پژوهش احمدزاده کلیبر و فولادپناه (Ahmadzadeh Kaleibar & Fuladipناه, 2023) در دشت ارسباران واقع در شمال غرب ایران نیز نشان داد که مدل GEP در مقایسه با مدل‌های رگرسیون خطی و غیرخطی از دقت بالاتری در برآورد رطوبت‌های ظرفیت مزرعه و نقطه پژمردگی دائم برخوردار بود. زانگ و زانگ (Zhang & Zhang, 2024) گزارش کردند که مدل GEP توانست ضریب نفوذپذیری خاک را از روی برخی ویژگی‌های خاک مانند نسبت پوکی، اندازه مؤثر و میانگین اندازه ذره با دقت بالاتری (R^2 برابر با ۰/۹۴ و RMSE برابر با ۰/۰۰۴۸) نسبت به سایر مدل‌های هوشمند و روابط ریاضی تخمین بزند.

اگرچه مدل‌های رگرسیونی و شبکه عصبی مصنوعی (ANN) مختلفی برای برآورد PR خاک در نقاط مختلف دنیا ارائه گردیده است ولی کاربرد عملی این مدل‌ها در خاک‌های سایر مناطق جهان با شرایط اقلیمی متنوع، همواره توسط محققان با شک و تردید همراه بوده است. از سوی دیگر، تحقیقات انجام گرفته در زمینه استفاده از مدل برنامه ریزی بیان ژن (GEP) برای برآورد PR خاک انگشت‌شمار است. بررسی منابع نشان داد که تاکنون تحقیقی در زمینه برآورد PR توسط مدل‌های هوشمند مانند ANN و GEP و مقایسه آن با مدل‌های رگرسیونی در جنگل‌های فندقلوی اردبیل اجرا نگردیده است لذا موضوع پژوهش حاضر از این نظر دارای نوآوری است. با توجه به اینکه منطقه فندقلوی استان اردبیل از مناطق گردشگری مهم و پرتردد کشور به‌ویژه در فصل تابستان محسوب می‌شود و تغییر کاربری اراضی جنگلی و مرتعی به زراعی نیز در آن با شدت زیاد در حال وقوع است لذا ارائه مدل‌های هوشمند برای اطلاع از وضعیت فیزیکی و مکانیکی خاک‌های منطقه مذکور حائز اهمیت فراوان است. بنابراین اهداف پژوهش حاضر عبارت بودند از (۱) ارائه مدل‌های ANN، MLR و GEP برای برآورد PR از روی متغیرهای زودیافت در خاک‌های جنگلی، مرتعی و زراعی منطقه فندقلوی استان اردبیل (۲) مقایسه دقت مدل‌های مذکور در برآورد PR خاک با استفاده از معیارهای R^2 ، RMSE، میانگین خطا $(ME)^2$ و ضریب نش-ساتکلِف $(NS)^3$ بود.

مواد و روش‌ها

خاک‌های مورد مطالعه، در اراضی منطقه گردشگری فندقلو واقع در شرق استان اردبیل (مختصات جغرافیایی $38^{\circ} 33' 45''$ تا $38^{\circ} 5' 33''$ و $48^{\circ} 24' 10''$ تا $48^{\circ} 24' 25''$ عرض شمالی) قرار

در ۱۰۵ نمونه خاک برداشته شده (با فواصل ۳۰۰ متر) از اراضی زراعی دشت اردبیل (24×42 km) حدود ۵۰ درصد تعیین گردید و دامنه تغییرات کربن آلی از ۰/۳ تا ۲/۴ درصد، جرم مخصوص ظاهری از ۱/۰۲ تا ۱/۶۳ گرم بر سانتی‌متر مکعب و PR از ۱/۱ تا ۶/۶ مگاپاسکال به دست آمد. همچنین اصغری و شهابی (Asghari & Shahabi, 2019) مقادیر CV را برای مقاومت فروروی خاک در اراضی زراعی و بایر بخش شندآباد منطقه شبستر (400×2000 m) حدود ۴۶ درصد گزارش نمودند. از سوی دیگر، اندازه‌گیری مستقیم PR نیز به دلیل خطاهای ابزاری، کاری طاقت‌فرسا و پرهزینه است؛ بنابراین استفاده از مدل‌های مختلف مانند رگرسیون خطی چندگانه^۱ (MLR)، شبکه عصبی مصنوعی^۲ (ANN) و برنامه‌ریزی بیان ژن^۳ (GEP) برای برآورد PR از طریق ویژگی‌های سهل‌الوصول و کم‌هزینه خاک می‌تواند در این زمینه راهگشا باشد.

نتایج پژوهش بیات و همکاران (Bayat et al., 2008) نشان داد که در برآورد PR از روی تخلخل کل، درجه اشباع نسبی و رطوبت خاک مزرعه، مدل ANN در مقایسه با مدل‌های رگرسیون خطی و غیرخطی از دقت بالاتری برخوردار بود. واز و همکاران (Vaz et al., 2011) گزارش کردند که رطوبت خاک، مهمترین ویژگی تأثیرگذار بر مقاومت فروروی خاک می‌باشد. سانتوس و همکاران (Santos et al., 2011) از جرم مخصوص ظاهری و رطوبت خاک مزرعه برای برآورد PR خاک در مدل‌های رگرسیونی و ANN استفاده کردند. آنها بیان کردند که PR با جرم مخصوص ظاهری رابطه مستقیم و با رطوبت خاک مزرعه رابطه معکوس دارد. شیخ‌زاده و همکاران (Sheykhzadeh et al., 2016) گزارش کردند که در برآورد PR خاک، مقادیر ضریب تبیین $(R^2)^4$ و مجذور میانگین مربعات خطا^۵ (RMSE) به ترتیب در مدل ANN برابر با ۰/۹۱ و ۰/۳۷ MPa و در مدل MLR برابر با ۰/۵۵ و ۰/۸۹ MPa به دست آمد بنابراین مدل ANN نسبت به مدل MLR دارای دقت بالاتری بود؛ همچنین رطوبت خاک مزرعه، جرم مخصوص ظاهری و توزیع اندازه ذرات خاک، مهمترین متغیرهای ورودی در برآورد PR خاک تشخیص داده شد. اخیراً از سایر روش‌های هوشمند مانند الگوریتم ژنتیک و مدل GEP در برآورد ویژگی‌های دیریافت خاک استفاده گردیده است؛ احمدی و همکاران (Ahmadi et al., 2016) گزارش کردند که در برآورد هدایت هیدرولیکی اشباع خاک در دشت تبریز، مدل GEP نسبت به مدل رگرسیون راجع به‌علت داشتن R^2 بالا و RMSE پایین دارای دقت بالاتری بود. آزاد مرد و همکاران (Azadmard et al., 2019) بیان کردند مدل ترکیبی ANN با الگوریتم ژنتیک در مقایسه با مدل MLR از دقت به مراتب بالاتری در

5- Root mean square error

6- Mean error

7- Nash-Sutcliffe coefficient

1- Multiple linear regression

2- Artificial neural network

3- Gene expression programming

4- Determination coefficient

گام به گام در نرم‌افزار SPSS 22 انجام شد.

مدل‌های شبکه عصبی مصنوعی (ANN) با استفاده از نرم‌افزار MATLAB ایجاد گردید. در این پژوهش شبکه پرسپترون سه لایه شامل یک لایه ورودی، یک لایه پنهان و یک لایه خروجی با الگوریتم پس انتشار خطا و ۱۰۰۰ تکرار برای رسیدن به حداقل خطا و حداکثر پایداری شبکه به کار گرفته شد و تعداد نرون‌های مناسب به روش سعی و خطا در لایه پنهان برای سه مدل شبکه عصبی به ترتیب برابر ۶، ۵ و ۲ انتخاب گردید. نرون‌های پنهان داخل شبکه پرسپترون چند لایه، در هر لایه به نرون‌های لایه بعد متصل هستند. به منظور تجزیه و تحلیل ویژگی‌ها در داده‌های ورودی، توابع فعال‌سازی تانژانت سیگموئید و خطی به ترتیب در لایه‌های پنهان و خروجی هر سه مدل به کار برده شد (Ghorbani et al., 2019). به منظور آموزش شبکه با دقت بالا از الگوریتم آموزشی مارکوارت-لونبرگ استفاده گردید.

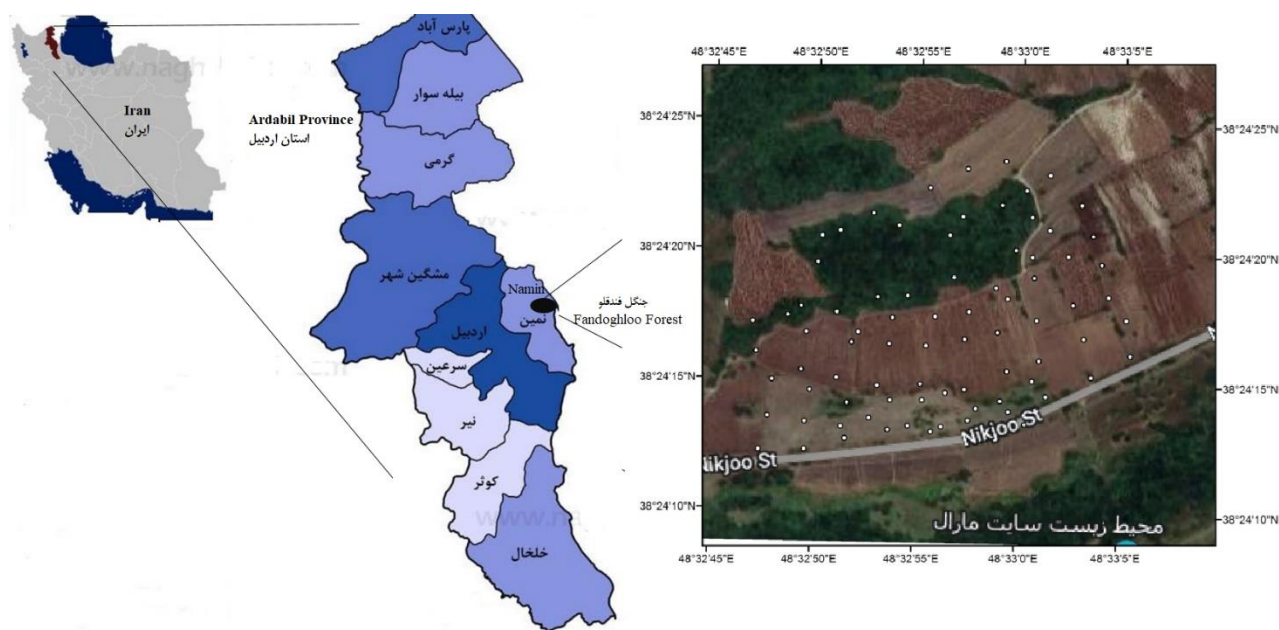
برنامه‌ریزی بیان ژن (GEP) توسط فریرا (Ferreira, 2001) پیشنهاد شد. این روش یک الگوریتم توسعه‌یافته براساس برنامه‌ریزی ژنتیک و الگوریتم ژنتیک می‌باشد و مبنای تمامی آنها براساس نظریه تکامل داروین استوار است که در آن کروموزوم‌های خطی و ساده با طول ثابت مشابه آنچه در الگوریتم ژنتیک استفاده می‌شود و ساختارهای شاخه‌ای با اندازه‌ها و اشکال متفاوت مشابه با برنامه‌ریزی ژنتیک ترکیب می‌شوند. برای مطالعه بیشتر در زمینه جزئیات مدل GEP می‌توان به مقاله زانگ و زانگ (Zhang & Zhang, 2024) مراجعه نمود. در این تحقیق برای مدل‌سازی مقاومت فروری (PR) خاک براساس برنامه‌ریزی بیان ژن (GEP) از نرم‌افزار Gene Xpro Tools 4.0 استفاده شد. برای این منظور از مجموعه عملگرهای ریاضی شامل چهار عمل اصلی (+، -، × و /)، جذر، اکسپونشیال، لگاریتم طبیعی، توان ۲ و ۳ و ریشه سوم استفاده شد. همچنین پارامترهای لازم برای مدل‌سازی GEP در جدول ۱ آورده شده است.

در همه مدل‌های به کار رفته در تحقیق حاضر از مجموع ۸۰ داده برای هر متغیر، بعد از تصادفی کردن کل داده‌ها در نرم‌افزار اکسل، ۶۰ داده برای آموزش مدل و ۲۰ داده برای آزمون مدل در نظر گرفته شد. برای ارزیابی دقت و کارایی مدل‌های ANN، MLR، و GEP در برآورد PR، از محک‌های آماری ضریب تبیین (R^2)، مجذور میانگین مربعات خطا (RMSE)، میانگین خطا (ME) و ضریب نش-ساتکلیف (NS) (Ghorbani et al., 2019) استفاده شد. مقادیر بالای R^2 (نزدیک به ۱) بیانگر دقت بالای برآورد می‌باشد.

دارد که فاصله آن از مرکز استان اردبیل در حدود ۳۰ کیلومتر می‌باشد. تعداد ۸۰ نمونه خاک دست‌خورده (با حداقل دست‌خوردگی) و دست‌نخورده (با استفاده از استوانه‌های استیل به قطر و ارتفاع ۵ سانتی‌متر) از محدوده عمق ۰ تا ۱۰ سانتی‌متر اراضی شیبدار و تپه‌ای با کاربری جنگلی (۲۰ نمونه)، مرتعی (۲۳ نمونه) و زراعی (۳۷ نمونه) به هم چسپیده به فواصل حدود ۵۰ متر و به طور تصادفی-منظم در تابستان ۱۴۰۲ برداشته شد. موقعیت هر یک از نقاط نمونه‌برداری شده با استفاده از دستگاه موقعیت‌یاب جهانی (GPS) ثبت گردید (شکل ۱).

پس از هواخشک کردن نمونه‌های خاک، بخشی از آن‌ها برای تعیین پایداری خاکدانه‌ها جدا گردیده و بخش دیگر برای تعیین سایر ویژگی‌های فیزیکی و شیمیایی از الک ۲ mm گذرانده شد. توزیع اندازه ذرات شن، سیلت و رس و کلاس بافت خاک به روش هیدرومتری ۴ قرآته (Gee & Or, 2002) تعیین و پارامترهای میانگین هندسی قطر (d_g) و انحراف استاندارد هندسی (σ_g) ذرات خاک از روی درصد‌های شن، سیلت و رس محاسبه گردید (Campbell, 1985). کربن آلی به روش اکسیداسیون تر (Nelson & Sommers, 1982)، اسیدیته (pH) و هدایت الکتریکی (EC) در عصاره ۱ به ۲/۵ خاک به آب و آهک به روش تیتراسیون با اسید و سود (Page, 1985) تعیین شد. جرم مخصوص ظاهری (BD) در استوانه‌های استیل (Blake & Hartge, 1986a) و جرم مخصوص حقیقی (PD) به روش پیکنومتر (Blake & Hartge, 1986b) اندازه‌گیری شد. جرم مخصوص ظاهری نسبی (BDrel) از روی داده‌های جرم مخصوص ظاهری و درصد رس محاسبه گردید (Kelishadi et al., 2014). میانگین وزنی قطر MWD^2 و میانگین هندسی قطر GMD^3 خاکدانه‌ها به روش الک خشک در ۵۰ گرم خاک هواخشک گذرانده شده از الک ۴/۷۵ میلی‌متر با استفاده از دستگاه شیکر الک با به‌کارگیری الک‌های با قطر سوراخ به ترتیب از بالا به پایین ۲، ۱، ۰/۵، ۰/۲۵ و ۰/۱۰۶ میلی‌متر اندازه‌گیری و محاسبه گردید (Yoder, 1936). مقاومت فروری (PR) خاک به طور مستقیم در مزرعه با استفاده از دستگاه فروسنج مخروطی مدل عقربه‌ای ساخت شرکت اکل کمپ کشور هلند در ۵ تکرار اندازه‌گیری شد (Lowery & Morrison, 2002) و همزمان رطوبت خاک مزرعه در حین اندازه‌گیری PR، با استفاده از استوانه‌های خاک برداشته شده برای اندازه‌گیری BD پس از آون خشک کردن در دمای $105^\circ C$ به روش وزنی تعیین گردید (Gardner, 1986).

نرمال بودن توزیع داده‌ها با آزمون کولموگروف-اسمیرنوف بررسی گردید سپس محاسبات مربوط به آمار توصیفی و ضریب همبستگی پیرسون بین متغیرها و نیز اشتقاق مدل‌های رگرسیونی خطی چندگانه (MLR) بین متغیرهای زودیاقت خاک با متغیر دیریاقت (PR) به روش



شکل ۱- موقعیت جغرافیایی و نقشه توزیع نقاط نمونه برداری در تصویر ماهواره‌ای منطقه مورد مطالعه
 Figure 1- Geographic position and distribution map of sampled points in satellite image of the studied area

جدول ۱- مقادیر پارامترهای مدل برنامه‌ریزی بیان ژن (GEP)

Table 1- The values of GEP model parameters

مقادیر Values	عوامل ژنتیک Genetic factors	مقادیر Values	تنظیمات عمومی General adjustment
0.044	Mutation rate نرخ جهش	30	تعداد کروموزومها Number of chromosome
0.1	Inversion rate نرخ وارون سازی	8	اندازه سر Head size
0.3	One point recombination rate نرخ ترکیب تک نقطه‌ای	3	تعداد ژن‌ها Number of genes
0.3	Two point recombination rate نرخ ترکیب دو نقطه‌ای	جمع (+)	تابع پیوند Linking function
0.1	Gene recombination rate نرخ ترکیب ژن	RMSE	معیار خطای تابع Fitness function error type

$$ME = \frac{\sum_{i=1}^n Y_{i(p)} - Y_{i(m)}}{n} \quad (2)$$

$$NS = 1 - \frac{\sum_{i=1}^n (Y_{i(p)} - Y_{i(m)})^2}{\sum_{i=1}^n (Y_{i(m)} - \bar{Y}_m)^2} \quad (3)$$

در معادله‌های ۱، ۲ و ۳، $Y_{i(p)}$ ، $Y_{i(m)}$ و \bar{Y}_m به ترتیب مقادیر اندازه گیری، برآورد شده و میانگین مقادیر اندازه‌گیری شده PR توسط مدل و n تعداد داده‌ها برای PR در هر مدل می‌باشد. از میان مدل‌های ایجاد شده برای برآورد PR، مناسب‌ترین مدل ANN، MLR و GEP با ترکیب متغیرهای ورودی در داده‌های آزمون براساس محک‌های آماری مذکور تعیین گردید. آزمون مدل‌ها در تشخیص دقت مدل به ازای داده‌هایی که در آموزش مدل استفاده نشده‌اند به کار می‌رود.

از لحاظ آماری کمترین مقدار RMSE، صفر می‌باشد که در آن وضعیت، مقادیر اندازه‌گیری و برآورد شده PR باهم برابر هستند؛ هرچه مقدار RMSE کوچکتر باشد برآوردهای انجام شده توسط مدل برآورد کننده دقیق‌تر است. مقادیر مثبت ME بیش برآوردی و مقادیر منفی آن کم برآوردی مدل را نشان می‌دهد. اگر ضریب NS برابر یک باشد بیانگر آن است که مدل‌سازی با دقت بالایی انجام گرفته و مقادیر اندازه‌گیری و برآورد شده PR در تطابق کامل هستند. مقدار برابر با صفر NS نشان‌دهنده آن است که برآوردهای مدل، دقتی برابر با دقت میانگین داده‌های اندازه‌گیری شده دارند.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_{i(p)} - Y_{i(m)})^2}{n}} \quad (1)$$

نتایج و بحث

آماره‌های توصیفی ویژگی‌های خاک

توصیف آماری ویژگی‌های خاک منطقه فندقلوی اردبیل در جدول ۲ نشان می‌دهد که داده‌های آموزشی و آزمونی به کار رفته در توسعه و ارزیابی مدل‌های رگرسیون خطی چندگانه (MLR)، شبکه عصبی مصنوعی (ANN) و برنامه‌ریزی بیان ژن (GEP) دارای توزیع نسبتاً مناسبی هستند و این موضوع از نظر توسعه و ارزیابی مدل‌ها حائز اهمیت است؛ به‌طور مثال، دامنه تغییرات بالا به‌ترتیب در داده‌های آموزشی و آزمونی برای مقاومت فروری خاک (PR) از ۱/۲ تا ۴/۸ مگاپاسکال و از ۱/۰۳ تا ۵/۸۳ مگاپاسکال و برای رطوبت خاک مزرعه (FWC) از ۱۱/۴۸ تا ۵۰/۴۴ درصد وزنی و ۱۲/۹۰ تا ۵۰/۴۷ درصد وزنی و کربن آلی خاک از ۱/۰۱ تا ۷/۱۷ و ۶/۳۱ تا ۶/۳۱ درصد مؤید این موضوع است. همچنین مقادیر میانگین داده‌ها در سری آموزش و آزمون به هم نزدیک بوده و به‌ترتیب برای PR ۲/۱۵ و ۲/۲۲ مگاپاسکال، برای FWC ۲۴/۴۶ و ۲۵/۷۳ درصد وزنی و برای کربن آلی، ۲/۸۵ و ۲/۹۰ درصد می‌باشد. لازم به توضیح است که مقادیر بالای کربن آلی به کاربری جنگلی و مقادیر پایین کربن آلی به کاربری زراعی مربوط می‌باشد. همچنین مقادیر بالای به‌دست آمده برای

رطوبت خاک مزرعه (در لحظه اندازه‌گیری PR) به‌علت وقوع بارندگی در اواخر تیر ۱۴۰۲ در منطقه مورد مطالعه می‌باشد. مقادیر متوسط میانگین وزنی (MWD) و هندسی (GMD) قطر خاکدانه‌ها به‌ترتیب در داده‌های سری آموزش برابر با ۱/۵۵ و ۱/۰۳ mm و در داده‌های سری آزمون برابر با ۱/۶۱ و ۱/۴ mm به‌دست آمد (جدول ۲)؛ مقادیر بالای شاخص‌های پایداری خاکدانه‌ها (MWD و GMD) در تحقیق حاضر در مقایسه با سایر خاک‌های استان اردبیل را می‌توان به کربن آلی زیاد خاک در منطقه مورد مطالعه نسبت داد. شیخ‌زاده و همکاران (Sheykhzadeh et al., 2016) میانگین کربن آلی و PR خاک را به‌ترتیب ۱/۱۱ درصد و ۲/۷۸ مگاپاسکال در ۱۰۵ نمونه خاک زراعی برداشته‌شده از دشت اردبیل گزارش کردند. امیرعابدی و همکاران (Amirabedi et al., 2016) نیز میانگین کربن آلی و MWD را به ترتیب ۰/۷۷ درصد و ۰/۵۰ mm در ۱۰۰ نمونه خاک زراعی برداشته شده از دشت اردبیل گزارش کردند.

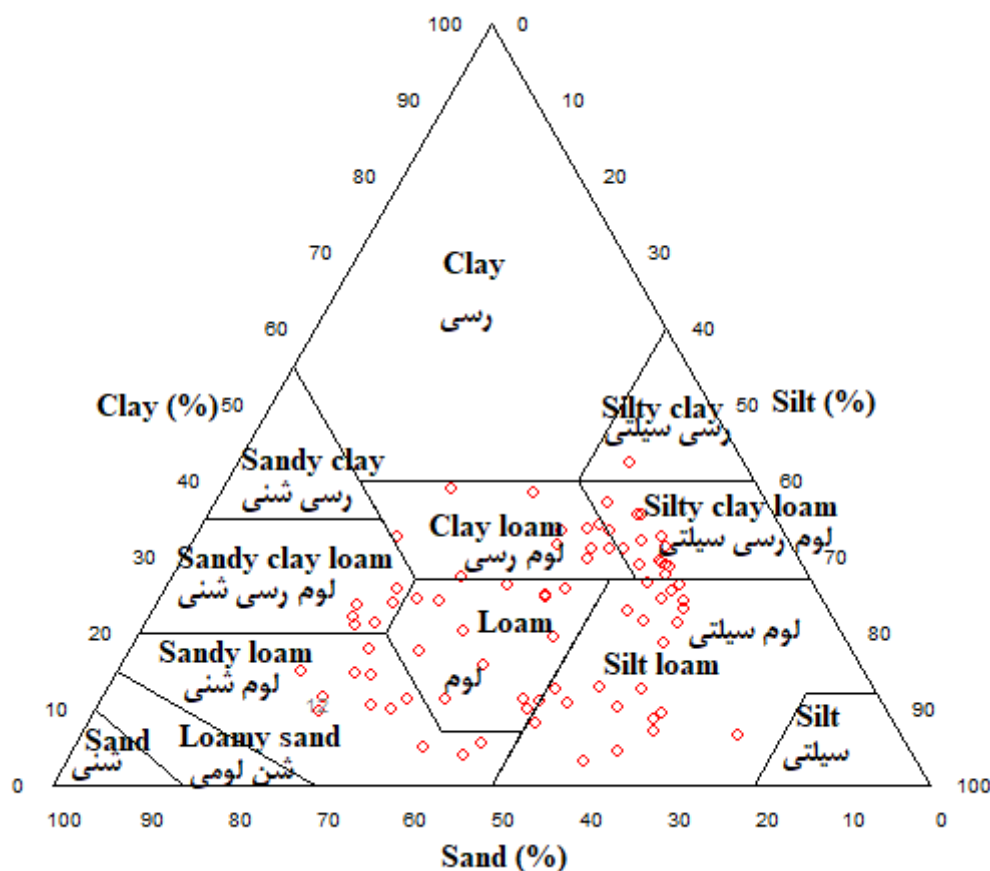
با توجه به شکل ۲ مشاهده می‌شود که کلاس بافت خاک‌های مورد مطالعه براساس مثلث بافت آمریکایی لوم، لوم رسی سیلتی، لوم شنی، لوم رسی، لوم سیلتی و رسی سیلتی بود که بیانگر توزیع گسترده بافتی در منطقه مورد مطالعه است.

جدول ۲- آماره‌های توصیفی متغیرهای خاک در منطقه مورد مطالعه

Table 2- Descriptive statistics of soil variables in the studied area

متغیر Variable	آموزش Training				آزمون Testing			
	Min.	Max.	Mean	Sd.	Min.	Max.	Mean	Sd.
FWC (% g g ⁻¹)	11.48	50.44	24.46	10.24	12.90	50.47	25.73	12.15
BDrel	0.44	0.75	0.63	0.07	0.43	0.79	0.63	0.10
PD (g cm ⁻³)	2.01	2.67	2.44	0.15	2.02	2.68	2.41	0.17
Clay (%)	2.95	42.18	21.78	9.53	3.94	38.40	20.28	11.27
Silt (%)	21.11	65.19	44.62	12.90	25.53	74.96	47.45	12.35
Sand (%)	13.14	64.10	33.59	15.52	15.31	64.80	32.27	14.89
d _g (mm)	0.01	0.18	0.06	0.05	0.02	0.21	0.06	0.05
σ _g (-)	6.94	20.43	11.75	3.29	6.94	20.43	11.75	3.29
MWDd (mm)	0.98	2.31	1.55	0.28	1.19	1.98	1.61	0.25
GMD (mm)	0.8	1.33	1.03	0.11	0.8	1.2	1.04	0.1
OC (%)	1.01	7.17	2.85	1.75	1.15	6.31	2.90	1.71
CaCO ₃ (%)	3.12	10.32	7.18	1.76	2.1	15.6	6.74	2.67
pH _{1:2.5}	5.45	7.2	6.29	0.38	5.68	7.34	6.33	0.43
EC _{1:2.5} (dS m ⁻¹)	0.02	1.08	0.15	0.19	0.04	0.33	0.11	0.07
PR (MPa)	1.2	4.8	2.15	0.85	1.03	5.83	2.22	1.52

FWC: رطوبت خاک مزرعه (field water content), BDrel: جرم مخصوص ظاهری نسبی (relative bulk density), D_p: جرم مخصوص حقیقی (particle density), Clay: رس، silt: سیلت، sand: شن، d_g: میانگین هندسی قطر ذرات (geometric mean diameter), σ_g: انحراف استاندارد هندسی ذرات (geometric standard deviation), MWDd: میانگین وزنی قطر خاکدانه‌ها به روش الک خشک (mean weight diameter), GMD: میانگین هندسی قطر خاکدانه‌ها (geometric mean diameter), OC: کربن آلی (organic carbon), CaCO₃: کربنات کلسیم معادل، PR: مقاومت فروری (penetration resistance), Sd: انحراف استاندارد، Mean: میانگین، Max: حداکثر، Min: حداقل.



شکل ۲- توزیع کلاس بافت در خاک‌های مورد مطالعه
Figure 2- Distribution of textural class in the studied soils

نتایج مدل‌های رگرسیون خطی چندگانه (MLR) برای برآورد مقاومت فروری (PR) خاک

به‌طور کلی براساس روش گام به گام در رگرسیون خطی، ۳ نوع مدل MLR برای برآورد PR با استفاده از متغیرهای رطوبت خاک مزرعه (FWC)، سیلت و جرم مخصوص ظاهری نسبی (BDrel) از بین متغیرهای زودیافت در منطقه مورد مطالعه تشخیص داده شد (جدول ۴). نتایج ضریب همبستگی پیرسون بین PR با متغیرهای زودیافت خاک در جدول ۳ نشان می‌دهد که بیش‌ترین همبستگی منفی و معنی‌دار بین PR با FWC ($r = -0.45^{**}$) یافت شد. همچنین همبستگی منفی و معنی‌دار بین PR با سیلت ($r = -0.36^{**}$) و همبستگی مثبت و معنی‌دار بین PR با انحراف استاندارد هندسی ذرات (σ_g) ($r = 0.36^{**}$) به‌دست آمد؛ البته به‌دلیل همراستایی سیلت و σ_g از σ_g به‌عنوان ورودی در تخمین PR استفاده نشد و سایر متغیرهای

ضرایب همبستگی پیرسون (r) بین متغیرهای خاک در جدول ۳ نشان می‌دهد که همبستگی خطی قوی ($r > 0.60$) بین شن با سیلت و میانگین هندسی قطر ذرات (d_g)، سیلت با انحراف استاندارد هندسی ذرات (σ_g)، رس با d_g ، کربن آلی با رطوبت خاک مزرعه و MWDD با وجود دارد بنابراین برای اجتناب از همراستایی چندگانه^۱ از این متغیرها به‌عنوان ورودی مدل به‌طور همزمان برای ایجاد مدل‌های MLR در برآورد PR استفاده نشد. عامل تورم واریانس^۲ (VIF) از جمله روش‌های تشخیص همراستایی چندگانه بوده که نشان می‌دهد واریانس ضرایب برآوردی تا چه حد نسبت به‌حالتی که متغیرهای برآوردی همبستگی خطی ندارند افزایش یافته است (Yazdani et al., 2014). نتایج آنالیز هم‌خطی حداکثر تورم واریانس (VIF) مدل‌های MLR مربوطه (جدول ۴) مقادیر کمتر از ۵ را نشان دادند که مقدار حداکثر آن در این پژوهش ۱/۴ به‌دست آمد. به‌طور کلی، اگر آماره VIF برای یک متغیر کمتر از ۵ باشد آن متغیر در مدل وارد می‌گردد در غیر این صورت باید از مدل حذف شود.

2- Variance inflation factor (VIF)

1- Multicollinearity

می‌رود با افزایش درصد سیلت در خاک به علت ایجاد حالت سست و نرم، مقاومت فروری خاک کاهش یابد. در مدل MLR شماره ۳، علاوه بر FWC و سیلت، جرم مخصوص ظاهری نسبی (BDrel) نیز با علامت منفی وارد مدل گردید. به نظر می‌رسد با افزایش سهم رس در توزیع اندازه ذرات خاک، جرم مخصوص ظاهری مرجع در مخرج کسر محاسبه BDrel کاهش و در نتیجه BDrel افزایش و منجر به کاهش PR می‌گردد. کلیشادی و همکاران (Kelishadi et al., 2014) توضیح نسبتاً کاملی درخصوص کاستی‌های جرم مخصوص ظاهری و مزیت‌های استفاده از BDrel به جای آن ارائه کرده‌اند. همان‌طوری‌که از **جدول ۳ و ۴** نمایان است برخلاف انتظار، در این پژوهش بین کربن آلی و PR همبستگی معنی‌دار یافت نشد بنابراین کربن آلی نتوانست به‌عنوان یک متغیر ورودی مدل‌های رگرسیونی تخمین‌زننده PR ظاهر گردد که دلیل این مسأله را شاید بتوان به ضریب تغییرات بالای آن (CV= 60%) در سه کاربری مجاور هم جنگلی، مرتعی و زارعی منطقه فندقلوی اردبیل نسبت داد. این در حالی است که در تحقیق شیخ‌زاده و همکاران (Sheykhzadeh et al., 2016) در خاک‌های دشت اردبیل، بین کربن آلی و PR همبستگی منفی و معنی‌دار ($r = -0.47^{**}$) پیدا شد و کربن آلی در برخی مدل‌های MLR برای برآورد PR، به‌عنوان ورودی مدل انتخاب گردید.

ورودی (به استثنای BDrel) نیز براساس تشخیص روش گام به گام و احتمالاً به علت نداشتن همبستگی معنی‌دار با PR، در مدل‌های MLR ظاهر نشدند.

مشاهده می‌شود FWC در هر سه مدل MLR به‌عنوان متغیر ورودی و با علامت منفی ظاهر گردیده است (**جدول ۴**) بنابراین در پژوهش حاضر رطوبت خاک مزرعه (FWC) مهمترین عامل اثرگذار در برآورد مقاومت فروری خاک بوده است. در مدل‌های رگرسیونی ارائه شده توسط بیات و همکاران (Bayat et al., 2008)، واز و همکاران (Vaz et al., 2011) و شیخ‌زاده و همکاران (Sheykhzadeh et al., 2016) نیز رطوبت خاک مزرعه یکی متغیرهای ورودی مهم در برآورد PR گزارش گردیده است. علامت منفی FWC در هر سه مدل MLR نیز بیانگر آن است که با افزایش رطوبت خاک محل و نرم شدن خاک، مقاومت مکانیکی خاک در برابر نفوذ فروسنج مخروطی کاهش یافته است که با یافته‌های سانتوس و همکاران (Santos et al., 2011) و اصغری و شهابی (Asghari & Shahabi, 2019) در یک راستا می‌باشد. همچنین مشاهده می‌شود در مدل MLR شماره ۲ و ۳، سیلت با علامت منفی به‌عنوان متغیر ورودی وارد مدل گردیده است (**جدول ۴**)؛ ذرات سیلت در مقایسه با زبری ذرات شن و چسپندگی ذرات رس از خاصیت نرمی برخوردار هستند (Campbell, 1985) بنابراین انتظار

جدول ۳- ضریب همبستگی پیرسون (r) بین متغیرهای مورد مطالعه (n=80)

Table 3- Pearson correlation coefficient (r) between studied variables (n=80)

Variable	OC	Sand	Silt	Clay	dg	σ_g	FWC	BDrel	PD	MWDd	GMD	CaCO ₃
PR	-0.06	0.21	-0.36**	0.14	0.10	0.36**	-0.45**	0.17	0.19	0.08	-0.01	-0.03
OC	1	0.59**	-0.24*	-0.59**	0.55**	0.03	0.78**	-0.50**	-0.57**	0.23*	0.14	0.40**
Sand		1	-0.76**	-0.56**	0.88**	0.42**	0.44**	-0.19	-0.32*	0.18	0.11	0.42**
Silt			1	-0.11	-0.50**	-0.84**	-0.07	-0.17	0.07	-0.24*	-0.27*	-0.28*
Clay				1	-0.71**	0.43**	-0.59**	0.50**	0.15	0.04	0.18	-0.29*
dg					1	0.01	0.47**	-0.34**	-0.36**	0.02	-0.03	0.45**
σ_g						1	-0.12	0.33**	0.08	0.34**	0.36**	0.05
FWC							1	-0.57**	-0.63**	0.25*	0.17	0.37**
BDrel								1	0.52**	-0.03	-0.01	-0.19
PD									1	-0.14	-0.08	-0.28*
MWDd										1	0.87**	-0.07
GMD											1	0.02
CaCO ₃												1

* و **: به ترتیب معنی‌دار در سطح احتمال ۱ و ۵ درصد. توصیف علائم متغیرها در زیر **جدول ۲** آورده شده است.

Variable symbols description is available under Table 2. *, **: Significant at $P < 0.05$ and $P < 0.01$, respectively.

جدول ۴- مدل‌های رگرسیون خطی چندگانه (MLR) مقاومت فروری (PR) خاک

Table 4- MLR models of soil PR

شماره Number	مدل Model	حداکثر VIF Max VIF
1	PR= 3.007 - 0.035 FWC	1.00
2	PR= 4.22 - 0.041 FWC - 0.024 silt	1.03
3	0.059 FWC - 0.030 silt - 5.098 BDrel PR= 8.161-	1.40

توصیف متغیرها در زیر **جدول ۲** آورده شده است.

Variables description is available under Table 2.

جدول ۵- معیارهای ارزیابی مدل‌های رگرسیونی خطی چندگانه (MLR) مقاومت فروروی (PR) خاک

Table 5- Evaluation criteria for MLR models of PR

شماره Number	متغیرهای ورودی Input variables	آزمون Testing set			آموزش Training				
		R ²	RMSE (MPa)	ME (MPa)	NS	R ²	RMSE (MPa)	ME (MPa)	NS
1	FWC	0.27	1.32	0.12	0.20	0.18	0.77	-0.001	0.18
2	FWC, silt	0.44	1.19	0.19	0.36	0.31	0.70	0.003	0.31
3	FWC, silt, BDrel	0.34	1.25	0.19	0.29	0.45	0.63	0	0.45

NS: ضریب نش-ساتکلیف، RMSE: مجذور میانگین مربعات خطا، ME: میانگین خطا، R²: ضریب تبیین. توصیف متغیرها در زیر جدول ۲ آورده شده است.
R²: coefficient of determination; RMSE: root mean square error; ME: mean error; NS: Nash-Sutcliffe coefficient. Variables description is available under Table 2.

نتایج مدل‌های شبکه عصبی مصنوعی (ANN) برای برآورد مقاومت (PR) خاک

برای ایجاد مدل‌های شبکه عصبی مصنوعی (ANN) برآورد کننده PR، از ۳ مدل با همان متغیرهای ورودی مدل‌های MLR (جدول ۵) استفاده شد؛ جدول ۶ معیارهای ارزیابی ۳ مدل ANN ارائه شده برای برآورد PR را نشان می‌دهد. رتبه‌بندی مدل‌های ANN نیز همانند مدل‌های MLR (جدول ۵)، بر مبنای پایین بودن RMSE و بالا بودن NS انجام شد. براساس معیارهای فوق در داده‌های آزمونی (جدول ۶)، بهترین مدل ANN برای برآورد PR، مدل ANN شماره ۳ با متغیرهای ورودی رطوبت خاک مزرعه، سیلت و جرم مخصوص ظاهری نسبی در مقایسه با سایر مدل‌های ANN بود. مقادیر R²، RMSE، ME و NS این مدل برای داده‌های آموزشی به ترتیب برابر ۰/۷۹، ۰/۳۹ MPa، ۰/۰۵ MPa و ۰/۷۸ و برای داده‌های آزمونی برابر ۰/۹۲، ۰/۴۱ MPa، ۰/۰۵ MPa - و ۰/۹۲ تعیین گردید (جدول ۶). مقادیر مثبت و منفی ME برای داده‌های آموزشی و آزمونی به ترتیب بیان گر برآورد جزئی بیشتر و کمتر از مقدار واقعی PR خاک توسط مدل شماره ۳ می‌باشد. در رتبه‌های بعدی، به ترتیب مدل ANN شماره ۲ و شماره ۱ دارای دقت بیشتری در برآورد PR می‌باشد؛ مدل ANN شماره ۲ نشان می‌دهد اضافه شدن متغیر سیلت به مدل ANN شماره ۱ موجب کاهش خطای مدل و افزایش دقت آن گردید به طوری که براساس داده‌های آزمونی، RMSE مدل ANN شماره ۲ نسبت به مدل ANN شماره ۱ به میزان ۴۵ درصد کاهش و ضریب NS مدل ANN شماره ۲ نسبت به مدل ANN شماره ۱ به میزان ۹۳ درصد افزایش یافت. بیات و همکاران (Bayat et al., 2008) گزارش کردند افزودن متغیر درجه اشباع نسبی به مدل ANN برای برآورد PR، موجب بهبود تخمین مقاومت فروروی خاک از طریق افزایش R² از ۰/۷۵ به ۰/۸۰ و کاهش RMSE به میزان ۸/۶۵ درصد گردید. سانتوس و همکاران (Santos et al., 2011) بیان کردند که مقاومت فروروی خاک با دقت بالایی (R²= ۰/۹۸ و RMSE= ۰/۰۸۴) توسط شبکه عصبی مصنوعی از روی متغیرهای ورودی جرم مخصوص ظاهری و رطوبت خاک مزرعه مورد

در جدول ۵ مقادیر معیارهای ضریب تبیین (R²)، مجذور میانگین مربعات خطا (RMSE)، میانگین خطا (ME) و ضریب نش-ساتکلیف (NS) برای ارزیابی مدل‌های MLR از نظر دقت برآورد PR آورده شده است. استفاده از R² به تنهایی برای سنجش اعتبار مدل‌ها ممکن است فریبنده باشد و الزاماً R² نزدیک به ۱ دلیل بر تطابق کامل مقادیر اندازه‌گیری با مقادیر برآوردی PR نیست یعنی بالا بودن R² دلیلی بر کم بودن خطا نیست (Kozak et al., 1996) بنابراین در پژوهش حاضر رتبه‌بندی مدل‌های MLR، ANN و GEP در برآورد PR، بر مبنای پایین بودن RMSE و بالا بودن NS انجام شد. براساس پایین بودن میزان RMSE و بالا بودن میزان NS در داده‌های آزمونی، مشاهده می‌شود مدل MLR شماره ۲ (جدول ۵) با متغیرهای ورودی رطوبت خاک مزرعه و سیلت از نظر برآورد PR دارای دقت بالاتری در مقایسه با سایر مدل‌های MLR بود. مقادیر R²، RMSE، ME و NS این مدل برای داده‌های آموزشی به ترتیب برابر ۰/۳۱، ۰/۷۰ MPa، ۰/۰۳ MPa و ۰/۳۱ و برای داده‌های آزمونی برابر ۰/۴۴، ۱/۱۹ MPa، ۱/۱۹ MPa و ۰/۳۶ تعیین گردید (جدول ۵). مقادیر مثبت ME برای داده‌های آموزشی و آزمونی بیان گر برآورد بیشتر از مقدار واقعی PR خاک توسط مدل شماره ۲ می‌باشد. همچنین معادله رگرسیونی این مدل (جدول ۴) نشان می‌دهد که تأثیر منفی متغیر رطوبت خاک مزرعه به علت داشتن ضریب رگرسیونی بالاتر در برآورد PR به مراتب بیشتر از متغیر سیلت می‌باشد. در رتبه‌های بعدی، مدل شماره ۳ با متغیرهای ورودی رطوبت خاک مزرعه، سیلت و جرم مخصوص ظاهری نسبی و مدل ۱ با متغیر ورودی رطوبت خاک مزرعه قرار دارد (جدول ۵)؛ پس در مجموع براساس آماره‌های ارزیابی سه مدل رگرسیونی فوق‌الذکر، مدل شماره ۲ برای برآورد PR ارجح‌تر است. در پژوهش شیخ‌زاده و همکاران (Sheykhzadeh et al., 2016) نیز بهترین مدل MLR با متغیرهای ورودی رطوبت خاک مزرعه و تخلخل کل با مقادیر R²، RMSE و ME به ترتیب برابر با ۰/۴۱، ۱/۱۶ MPa، ۰/۱۷ MPa (داده‌های آزمونی) برای برآورد PR در خاک‌های زراعی دشت اردبیل تعیین گردید.

مخصوص ظاهری نسبی در مقایسه با سایر مدل های GEP می باشد. مقادیر R^2 ، RMSE، ME و NS برای این مدل براساس داده های آموزشی به ترتیب برابر 0.75 ، 0.43 MPa، 0.4 MPa و 0.74 و داده های آزمون برای برابر 0.79 ، 0.91 MPa، 0.13 MPa و 0.63 به دست آمد (جدول ۷). مقادیر مثبت ME در داده های آموزشی و آزمون نشان دهنده اندکی بیش برآوردی در تخمین PR خاک توسط مدل GEP شماره ۳ می باشد. در رتبه های بعدی، به ترتیب مدل GEP شماره ۲ و شماره ۱ دارای بیشترین دقت در برآورد PR می باشد؛ با توجه به جدول ۷ مشاهده می شود افزودن متغیر سیلت به مدل GEP شماره ۱ باعث کاهش RMSE از $1/26$ به $0/93$ مگاپاسکال و افزایش ضریب NS از $0/28$ به $0/61$ در داده های آزمون گردید. دیناروند و همکاران (Dinarvand et al., 2018) نیز بیان کردند مدل GEP با متغیرهای ورودی رطوبت خاک مزرعه، جرم مخصوص ظاهری، رس و میانگین هندسی قطر (d_g) ذرات خاک توانست PR خاک در اراضی زراعی دشت اردبیل با دقت بالایی تخمین بزند به طوری که مقادیر R^2 ، RMSE و ME مدل مذکور به ترتیب برابر با $0/51$ ، 1 MPa و $-0/43$ MPa در داده های آزمون به دست آمد.

تخمین قرار گرفت. شیخزاده و همکاران (Sheykhzadeh et al., 2016) نیز در خاک های زراعی دشت اردبیل، مدل با متغیرهای ورودی رطوبت خاک مزرعه، سیلت، جرم مخصوص ظاهری و انحراف استاندارد هندسی (σ_g) ذرات خاک را به عنوان بهترین مدل (R^2 ، RMSE و ME به ترتیب برابر با $0/41$ ، $1/4$ MPa، $0/206$ MPa - در داده های آزمون) برای برآورد PR خاک معرفی کردند.

نتایج مدل های برنامه ریزی بیان ژن (ANN) برای برآورد مقاومت فروروی (PR) خاک

در برآورد PR با استفاده برنامه ریزی بیان ژن (GEP) نیز ۳ نوع مدل با همان متغیرهای ورودی مدل های MLR و ANN (جدول ۵ و ۶) ایجاد گردید؛ جدول ۷ معیارهای ارزیابی ۳ مدل GEP ارائه شده برای برآورد PR را نشان می دهد. رتبه بندی مدل های GEP نیز همانند مدل های MLR (جدول ۵) و ANN (جدول ۶)، براساس پایین بودن RMSE و بالا بودن NS انجام گردید. بر مبنای آماره های مذکور در داده های آزمون (جدول ۷)، دقیق ترین مدل GEP برای برآورد PR، مدل شماره ۳ با متغیرهای ورودی رطوبت خاک مزرعه، سیلت و جرم

جدول ۶- معیارهای ارزیابی مدل های شبکه عصبی مصنوعی مقاومت فروروی (PR) خاک

Table 6 - Evaluation criteria for ANN models of PR

شماره Number	متغیرهای ورودی Input variables	آزمون Testing set				آموزش Training			
		R^2	RMSE (MPa)	ME (MPa)	NS	R^2	RMSE (MPa)	ME (MPa)	NS
1	FWC	0.56	1.12	0.17	0.43	0.14	0.79	0.07	0.13
2	FWC, silt	0.89	0.61	-0.29	0.83	0.70	0.46	-0.03	0.70
3	FWC, silt, BDrel	0.92	0.41	-0.05	0.92	0.79	0.39	0.05	0.78

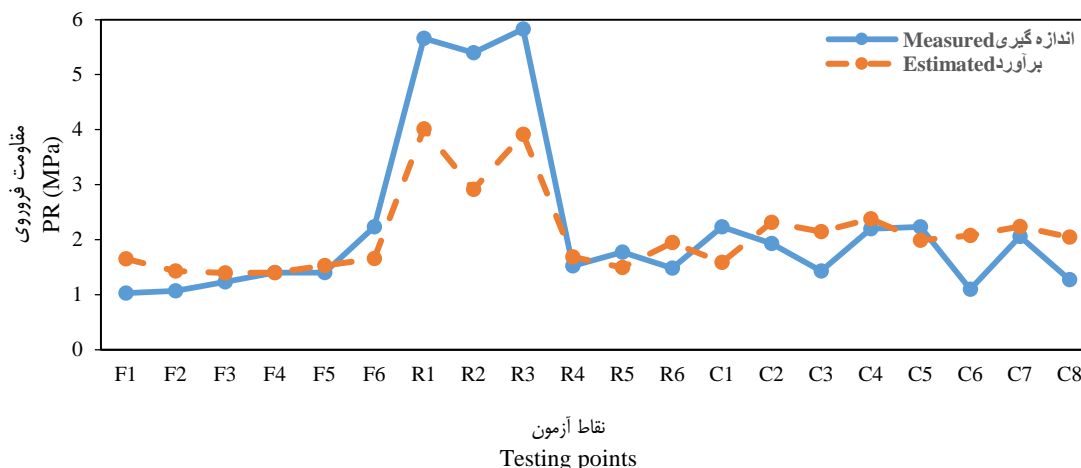
NS: ضریب نش-ساتکلیف، RMSE: مجذور میانگین مربعات خطا، ME: میانگین خطا، R^2 : ضریب تبیین. توصیف متغیرها در زیر جدول ۲ آورده شده است.
 R^2 : coefficient of determination; RMSE: root mean square error; ME: mean error; NS: Nash-Sutcliffe coefficient. Variables description is available under Table 2.

جدول ۷- معیارهای ارزیابی مدل های برنامه ریزی بیان ژن مقاومت فروروی (PR) خاک

Table 7- Evaluation criteria for GEP models of PR

شماره Number	متغیرهای ورودی Input variables	آزمون Testing set				آموزش Training			
		R^2	RMSE (MPa)	ME (MPa)	NS	R^2	RMSE (MPa)	ME (MPa)	NS
1	FWC	0.30	1.26	0.08	0.28	0.55	0.59	-0.02	0.50
2	FWC, silt	0.74	0.93	0.13	0.61	0.61	0.53	-0.03	0.61
3	FWC, silt, BDrel	0.79	0.91	0.13	0.63	0.75	0.43	0.04	0.74

NS: ضریب نش-ساتکلیف، RMSE: مجذور میانگین مربعات خطا، ME: میانگین خطا، R^2 : ضریب تبیین. توصیف متغیرها در زیر جدول ۲ آورده شده است.
 R^2 : coefficient of determination; RMSE: root mean square error; ME: mean error; NS: Nash-Sutcliffe coefficient. Variables description is available under Table 2.



شکل ۳- بررسی عملکرد بهترین مدل برنامه‌ریزی بیان ژن (GEP) در برآورد مقاومت فروروی (PR) خاک در نقاط آزمونی (n=20): F: کاربری جنگلی، R: کاربری مرتعی و C: کاربری زراعی

Figure 3- Investigation the performance of GEP model in estimating soil penetration resistance (PR) at the testing points (n=20); F: forest land use, R: range land use and C: cultivated land use

در مقایسه با مدل‌های رگرسیون خطی چندگانه (R^2 از ۰/۲۷ تا ۰/۳۴، NS از ۰/۲۰ تا ۰/۳۶ و RMSE از ۱/۲۵ تا ۱/۳۲ مگاپاسکال) و مدل‌های برنامه‌ریزی بیان ژن (R^2 از ۰/۳۰ تا ۰/۷۹، NS از ۰/۲۸ تا ۰/۶۳ و RMSE از ۰/۹۱ تا ۱/۲۶ مگاپاسکال) دارای دقت بالاتری و خطای کمتری در برآورد PR بودند. شکل ۴ نیز نمودار ۱:۱ مقادیر اندازه‌گیری و برآورد شده PR خاک را با استفاده از بهترین مدل MLR (مدل شماره ۲ در جدول ۵)، بهترین مدل ANN (مدل شماره ۳ در جدول ۶) و بهترین مدل GEP (مدل شماره ۳ در جدول ۷) برای داده‌های آزمونی نشان می‌دهد. با توجه به این شکل مشاهده می‌شود که پراکندگی داده‌ها حول محور ۱:۱ در بهترین مدل ANN کمتر از مدل‌های MLR و GEP برای برآورد PR در خاک‌های منطقه مورد مطالعه می‌باشد همچنین می‌توان گفت مدل‌های شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن در تخمین PR به دلیل استفاده از روابط غیر خطی به مراتب دقیق‌تر از مدل‌های رگرسیونی خطی چندگانه عمل نموده‌اند. علت برآورد دقیق‌تر شبکه‌های عصبی مصنوعی نسبت به مدل‌های رگرسیونی را می‌توان در نحوه عمل شبکه پرسپترون سه لایه دانست. عملکرد این شبکه به این صورت است که ابتدا الگویی به شبکه عصبی عرضه می‌شود و خروجی آن محاسبه می‌شود سپس شبکه این خروجی را با مقادیر اندازه‌گیری شده متغیر یا متغیرهای خروجی مقایسه می‌کند و ضرایب وزنی شبکه را به نوعی تغییر می‌دهد که کمترین اختلاف بین مقادیر پیش‌بینی شده و اندازه‌گیری شده باشد. بیات و همکاران (Bayat et al., 2008) و شیخ‌زاده و همکاران (Sheykhzadeh et al., 2016) نیز گزارش نمودند که شبکه‌های عصبی مصنوعی نسبت به مدل‌های رگرسیونی خطی چندگانه در برآورد PR دقیق‌تر عمل نمودند. سانتوس و همکاران (Santos et al., 2011) نشان دادند تابع شبکه عصبی

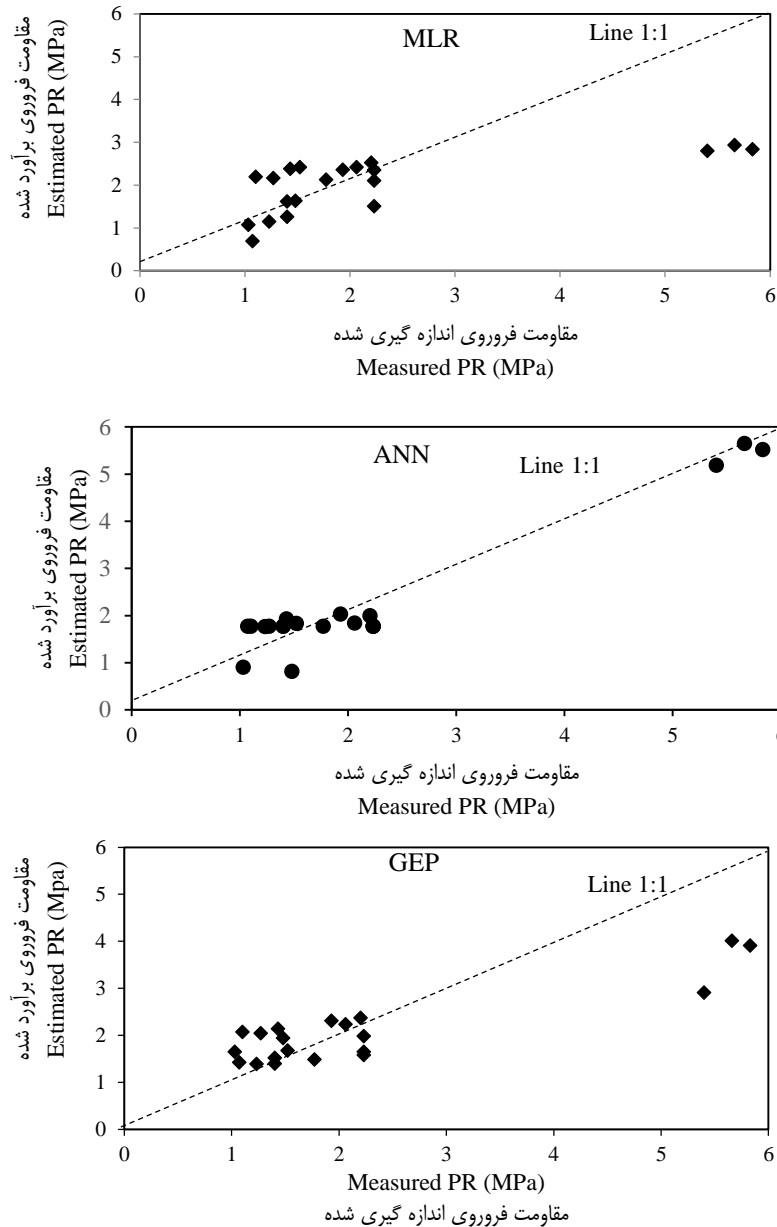
بررسی عملکرد بهترین مدل در برآورد مقاومت فروروی (PR) خاک در نقاط آزمونی (۲۰ داده تصادفی) به‌عنوان نمونه در شکل ۳ برای مدل برنامه‌ریزی بیان ژن (GEP) نشان داده شده است؛ با توجه به این شکل مشاهده می‌شود خطای مدل (اختلاف بین مقادیر اندازه‌گیری شده با مقادیر برآورد شده) در پیش‌بینی متغیر وابسته (PR) از روی متغیرهای مستقل (رطوبت خاک مزرعه، سیلت و جرم مخصوص ظاهری نسبی) در نمونه‌های خاک برداشته شده از کاربری مرتعی (R) به مراتب بیشتر از کاربری‌های جنگلی (F) و زراعی (C) می‌باشد؛ علت این مسأله را شاید بتوان به ضریب تغییرات (CV) بالای مقاومت فروروی خاک در کاربری مرتعی (۵۸ درصد) در مقایسه با کاربری‌های جنگلی (۲۲ درصد) و زراعی (۲۳ درصد) نسبت داد همچنین از بین متغیرهای مستقل نیز رطوبت خاک مزرعه دارای بیشترین ضریب تغییرات در کاربری مرتعی (۳۷ درصد) در مقایسه با کاربری‌های جنگلی (۱۶ درصد) و زراعی (۱۶ درصد) بود. نتایج تحقیقات قبلی نیز بیانگر تأثیرپذیری بیشتر مقاومت فروروی از رطوبت خاک مزرعه در مقایسه با سایر ویژگی‌های زودیافت خاک می‌باشد (Bayat et al., 2008; Vaz et al., 2011; Santos et al., 2011; Sheykhzadeh et al., 2016; Asghari & Shahabi, 2019).

مقایسه دقت مدل‌های MLR، ANN و GEP در برآورد PR

مقادیر R^2 ، RMSE و NS برای مدل‌های MLR (جدول ۵)، ANN (جدول ۶) و GEP (جدول ۷) ارائه شده برای برآورد PR در داده‌های آزمونی بیانگر آن است که مدل‌های شبکه‌های عصبی مصنوعی (ANN) به علت داشتن R^2 بالا (از ۰/۵۶ تا ۰/۹۲) و NS بیشتر (از ۰/۴۳ تا ۰/۹۳) و RMSE پایین (از ۰/۴۱ تا ۱/۱۲ مگاپاسکال)

های رگرسیون خطی و غیرخطی در برآورد ویژگی‌های دیربافت خاک از روی ویژگی‌های زودبافت خاک توسط احمدزاده کلیبر و فولادپناه (Ahmadzadeh Kaleibar & Fuladipناه, 2023) و زانگ و زانگ (Zhang & Zhang, 2024) گزارش گردیده است.

مصنوعی ($R^2= ۰/۹۸$ و $RMSE= ۰/۰۸۴$) نسبت به تابع رگرسیونی دقت بیشتری در برآورد مقاومت فروروی از روی جرم مخصوص ظاهری و رطوبت خاک مزرعه داشت. نتایج مشابهی در خصوص دقت بالای مدل GEP در مقایسه با مدل



شکل ۴- مقایسه مقادیر اندازه‌گیری و برآورد شده مقاومت فروروی (PR) خاک با استفاده از بهترین مدل رگرسیون خطی چندگانه (MLR)، شبکه عصبی مصنوعی (ANN) و برنامه‌ریزی بیان ژن (GEP) بر اساس داده‌های آزمونی (n=20). اطلاعات مربوط به مدل‌ها و متغیرهای ورودی در جداول ۵، ۶ و ۷ آورده شده است. خط‌چین بیانگر نمودار ۱:۱ است.

Figure 4- Comparisons of estimated and measured values of penetration resistance (PR) for the testing data set based on the best MLR, ANN and GEP models. Tables 4, 5 and 6 provide detailed information about each model and input variables. The dashed lines indicate the 1:1 diagonals.

نتیجه گیری

کمتری در برآورد PR خاک نسبت به مدل های MLR بودند. پیشنهاد می شود در تحقیقات بعدی از روش رگرسیون غیر خطی و نیز سایر مدل های هوشمند مانند نروفازی، ماشین بردار پشتیبان و جنگل تصادفی برای برآورد مقاومت فروروی خاک استفاده گردیده و نتایج آن با مدل های رگرسیونی مقایسه گردد.

سپاسگزاری

این مقاله مستخرج از طرح پژوهشی مصوب دانشگاه محقق اردبیلی می باشد به این وسیله از حمایت های معاونت محترم پژوهشی و فن آوری دانشگاه تشکر و قدردانی می شود.

در این تحقیق از مدل های رگرسیونی خطی چندگانه (MLR)، شبکه عصبی مصنوعی (ANN) و برنامه ریزی بیان ژن (GEP) برای برآورد مقاومت فروروی (PR) خاک از روی ویژگی های زود یافت خاک در اراضی جنگلی، مرتعی و زراعی فندقلوی اردبیل استفاده گردید. نتایج نشان داد در منطقه مورد مطالعه، متغیرهای رطوبت خاک مزرعه، سیلت و جرم مخصوص ظاهری نسبی در برآورد PR در مقایسه با سایر ویژگی های زود یافت خاک از اهمیت بیشتری برخوردار بوده و در ورودی مدل ها به کار گرفته شدند. مقایسه نتایج مدل ها نشان داد ANN به علت داشتن ضرایب تبیین (R^2) و نش-ساتکلیف (NS) بالاتر و مجذور میانگین مربعات خطای (RMSE) پایین تر، دارای دقت بالاتر و خطای

Referensec

- Asghari, Sh., & Shahabi M. (2019). Spatial variability of soil saturated hydraulic conductivity and penetration resistance in salt-affected lands around Lake Urmia. *Water and Soil*, 33(1), 103-116. (In Persian with English abstract). <https://doi.org/10.22067/JSW.V33I1.74411>
- Asghari, Sh., Sheykhzadeh, G.R., & Shahabi, M. (2017). Geostatistical analysis of soil mechanical properties in Ardabil plain of Iran. *Archives of Agronomy and Soil Science*, 63(12), 1631-1643. <https://doi.org/10.1080/03650340.2017.1296136>
- Azadmard, B., Mosaddeghi, M.R., Ayoubi, S., Chavoshi, E., & Raoof, M. (2019). Estimation of near-saturated soil hydraulic properties using hybrid genetic algorithm-artificial neural network. *Ecohydrology & Hydrobiology*, 20(3), 437-449. <https://doi.org/10.1016/j.ecohyd.2019.09.001>
- Ahmadzadeh Kaleibar, F., & Fuladipannah, M. (2023). Assessment of regression, support vector machine, and gene expression programming transfer functions to predict soil humidity parameters in Arasbaran plain. *Journal of Water and Soil Science*, 27(2), 135-149. <https://doi.org/10.47176/jwss.27.2.42532>
- Ahmadi, A., Palizvan zand, P., & Palivan zand, H. (2018). Estimation of saturated hydraulic conductivity by using gene expression programming and ridge regression (A case study in East Azerbaijan province). *Iranian Journal of Soil and Water Research*, 48(5), 1087-1095. (In Persian with English abstract). <https://doi.org/10.22059/ijswr.2018.218413.667555>
- Amirabedi, H., Asghari, Sh., Mesri, T., & Balandeh, N. (2016). Prediction of mean weight diameter of aggregates using artificial neural network and regression models. *Applied Soil Research*, 4(1), 39-53. (In Persian with English abstract)
- Bayat, H., Neyshabouri, M.R., & Hajabbasi, M. (2008). Comparing neural networks, linear and nonlinear regression techniques to model penetration resistance. *Turkish Journal of Agriculture and Forestry*, 32, 425-433.
- Blake, G.R., & Hartge, K.H. (1986a). *Bulk density*. p. 363-375. In: Klute A. (ed). *Methods of Soil Analysis Part 1, Physical and Mineralogical Methods*. 2nd ed. American Society of Agronomy, Madison, WI.
- Blake, G.R., & Hartge, K.H. (1986b). *Particle density*. p. 377-381. In: Klute A. (ed). *Methods of Soil Analysis Part 1, Physical and Mineralogical Methods*. 2nd ed. ASA and SSSA, Madison, WI.
- Campbell. G.S. (1985). *Soil Physics with Basic: Transport Models for Soil-Plant System*. Elsevier. New York. 150 p.
- Dinarvand, H., Asghari, Sh., & Shahabi, M. (2018). Estimating soil penetration resistance using neurofuzzy, support vector machine and gene expression programming methods. Available at <https://civilica.com/doc/808626> (In Persian with English abstract)
- Ferreira, C. (2001). Gene expression programming: a new adaptive algorithm for solving problems. *Complex Syst* 13, 87-129.
- Ghorbani, M.A., Deo, R.C., Kashani, M.H., Shahabi M., & Ghorbani, S. (2019). Artificial intelligence-based fast and efficient hybrid approach for spatial modeling of soil electrical conductivity. *Soil and Tillage Research*, 186, 152-164. <https://doi.org/10.1016/j.still.2018.09.012>
- Gardner, W.H. (1986). *Water content*. p. 493-544. In: Klute A. (ed). *Methods of Soil Analysis. Part 1*. 2nd ed. Agronomy. Monograph. 9. ASA, Madison, WI.
- Gee, G.W., & Or, D. (2002). *Particle-size analysis*. p. 255-293. In: Dane J. H., & Topp G. C. (eds.). *Methods of Soil*

- Analysis. Part 4. SSSA Book Series No. 5. Soil Science Society of America, Madison, WI.
- 16- Kelishadi, H., Mossaddeghi, M.R., Hajabbasi, M.A., & Ayoubi, S. (2014). Near-saturated soil hydraulic properties as influenced by land use management systems in Koohrang region of central Zagros, Iran. *Geoderma*, 213, 426-434. <https://doi.org/10.1016/j.geoderma.2013.08.008>
- 17- Kozak, E., Pachepsky, Y.A., Sokolowski, S., Sokolowska, Z., & Stepniewski, W. (1996). A modified number-based method for estimating fragmentation fractal dimensions of soils. *Soil Science Society of America Journal*, 60, 1291-1297.
- 18- Lowery, B., & Morrison, J.E. (2002). *Soil penetrometer and penetrability*. In: Dane J.H., & Topp GC (eds.). *Methods of soil analysis, part 4. Physical methods*. Madison (WI): Soil Science Society of America; pp. 363-388.
- 19- Nelson, D.W., & Sommers, L.E. (1982). *Total carbon, organic carbon, and organic matter*. p. 539-579. In A.L. Page et al. (ed.) *Methods of Soil Analysis. Part 2*. 2nd ed. Agron. Monogr. 9. ASA and SSSA, Madison, WI.
- 20- Page, A.L. (ed.). (1985). *Methods of Soil Analysis. Part 2. Chemical and Microbiological Methods*. Agronomy No. 9. American Society of Agronomy, Madison, WI.
- 21- Santos, F.L., De Jesus, V.A.M., & Valente, D.S.M. (2012). Modeling of soil penetration resistance using statistical analyses and artificial neural networks. *Acta Scientiarum. Agronomy*, 34, 219-224.
- 22- Sheykhzadeh, G.R., Asghari, Sh., & Mesri Gundoshmian, T. (2016). Estimating penetration resistance in agricultural soils of Ardabil plain using artificial neural network and regression methods. *Water and Soil*, 30(3), 941-954. (In Persian with English abstract). <https://doi.org/10.22067/JSW.V30I3.42235>
- 23- Vaz, C.M.P., Manieri, J.M., de Maria, I.C., & Tuller, M. (2011). Modeling and correction of soil penetration resistance for varying soil water content. *Geoderma*, 166, 92-101. <https://doi.org/10.1016/j.geoderma.2011.07.016>
- 24- Whalley, W., To, J., Kay, B.D., & Whitmore, A.P. (2007). Prediction of the penetrometer resistance of soils with models with few parameters. *Geoderma*, 137, 370-377. <https://doi.org/10.1016/j.geoderma.2006.08.029> [Get rights and content](#)
- 25- Yazdani, A., Mosaddeghi, M.R., Khademi, H., Ayoubi, S., & Khayamim, F. (2014). Relationship between surface aggregate stability and some soil and climate properties in Isfahan province. *Soil Management*, 3(2), 23-31. (In Persian with English abstract)
- 26- Yoder, R.E. (1936). A direct method of aggregate analysis of soils and a study of the physical nature of erosion losses. *Journal of American Society Agronomy*, 28, 337-35.
- 27- Zhang, R., & Zhang, S. (2024). Coefficient of permeability prediction of soils using gene expression programming. *Engineering Applications of Artificial Intelligence*, 128(107504). <https://doi.org/10.1016/j.engappai.2023.107504>