



Evaluation of Regression and Intelligent Models for Estimating Mean Weight Diameter of Wet Aggregates

Sh. Asghari^{1*}, K. Heidari², M. Hasanpour Kashani³, H. Shahab Arkhazloo⁴

1, 2 and 4- Professor, Ph.D. Student 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)

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

Received: 03-12-2024

Revised: 31-12-2024

Accepted: 12-01-2025

Available Online: 12-01-2025

How to cite this article:

Asghari, Sh., Heidari, K., Hasanpour Kashani, M., & Shahab Arkhazloo, H. (2025). Evaluation of regression and intelligent models for estimating mean weight diameter of wet aggregates. *Journal of Water and Soil*, 38(6), 749-764. (In Persian with English abstract). <https://doi.org/10.22067/JSW.2025.91071.1454>

Introduction

The study of soil mean weight diameter (MWD) of wet aggregates that is important for sustainable soil management, has recently received much attention. As the prediction of MWD is challenging, laborious, and time-consuming, there is a crucial need to develop a predictive estimation method to generate helpful information required for the soil health assessment to save time and cost involved in soil analysis. Therefore, it is useful to use different models such as multiple linear regression (MLR) and intelligent models including artificial neural network (ANN) and gene expression programming (GEP) to estimate MWD of wet aggregates through easily accessible and low-cost soil properties. The objectives of this study were (1) to creating MLR, ANN and GEP models for predicting MWD from the easily measurable soil variables in forest, range and cultivated lands of the Fandoghloo region of Ardabil province, (2) to compare the precision of the mentioned models in the prediction of MWD of wet aggregates 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 soil samples ($n= 80$) were nearly systematically taken from 0-10 cm depth with nearly 50 m distance in forest ($n= 20$), range ($n= 23$) and cultivated ($n= 37$) lands of the 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 (PD) density, organic carbon (OC), geometric mean diameter (GMD) of dry aggregates were determined in the laboratory using standard methods. Total porosity (n) was calculated using BD and PD data ($n= 1\text{-}BD/PD$). The mean geometric diameter (d_g) and geometric standard deviation (σ_g) of soil particles were computed by sand, silt and clay percentages. The mean weight diameter (MWD) of wet aggregates was measured in the aggregates smaller than 4.75 mm by wet sieving equipment using sieves with 2, 1, 0.5, 0.25 and 0.106 mm pore diameter. All data were randomly divided into two series as 60 data for training and 20 data for testing of models. The SPSS 22 software with the 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 (9, 8, 6 and 6 neurons in the 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 the best GEP model. The number of chromosomes and genes, head size and linking function were selected by the trial and error method, and they are 30, 3, 8, and +, respectively. The rates of genetic operators were chosen according to literature studies. The



©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/).

<https://doi.org/10.22067/JSW.2025.91071.1454>

precision of MLR, ANN and GEP models in predicting MWD of wet aggregates were evaluated by the coefficient of determination (R^2), root mean square error (RMSE), mean error (ME) and Nash-Sutcliffe coefficient (NS) statistics.

Results and Discussion

The values of sand (13.14 to 64.79 %), silt (21.11 to 74.96 %), clay (3 to 42.18 %), OC (1.01 to 7.17 %), PD (2.00 to 2.67 g cm⁻³), n (0.39 to 0.87 cm³ cm⁻³), GMD of dry aggregates (0.8 to 1.33 mm) and MWD of wet aggregates (0.35 to 2.65 mm) showed good variations in the soils of the studied region. 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. There were found significant correlations between MWD with OC ($r= 0.67^{**}$), sand ($r= 0.70^{**}$), GMD ($r= 0.30^{**}$) and PD ($r= -0.46^{**}$). Also, significant and positive correlation was found between OC and sand ($r= 0.59^{**}$). Due to the multicollinearity of sand with d_g ($r= 0.87^{**}$), we did not use the d_g as an input variable to estimate MWD of wet aggregates. Generally, four MLR, ANN and GEP models were constructed to predict MWD of wet aggregates from measured readily available soil variables. The results of MLR, ANN and GEP models indicated that the most suitable variables to estimate MWD of wet aggregates were sand, OC and GMD of dry aggregates. The values of R^2 , RMSE, ME and NS criteria were obtained equal 0.52, 0.48 mm, 0.13 mm and 0.48, and 0.85, 0.30 mm, 0.03 mm and 0.78, 0.79, 0.35 mm, -0.10 mm, 0.95 for the best MLR, ANN and GEP models in the testing data set, respectively. Many researchers also reported that there is a positive and significant correlation between MWD of wet aggregates and OC.

Conclusion

The results showed that sand, OC and GMD of dry aggregates were the most important and readily available soil variables to predict the mean weight diameter (MWD) of wet aggregates in the Fandoghloo region of Ardabil province. According to the lowest values of RMSE and the highest values of R^2 and NS, the precision of ANN models to predict MWD of wet aggregates was more than MLR and GEP models in this study. Because ANN is more flexible and effectively captures non-linear relationships, it performed better than the other models in predicting MWD.

Keywords: Aggregate stability, Artificial neural network, Gene expression programming, Sloped lands, Soil pedotransfer functions

مقالات پژوهشی

چلد ۳۸، شماره ۶، بهمن-اسفند ۱۴۰۳، ص. ۷۶۴-۷۴۹

ارزیابی مدل‌های رگرسیونی و هوشمند پرای پرآورد میانگین وزنی قطر خاکدانه‌های تر

شکر الله اصغری^{۱*}- کیمیا حیدری^۲- مهسا حسینپور کاشانی^{۳ID}- حسین شهاب آرخازلو^{۴ID}

تاریخ دریافت: ۱۴۰۳/۰۹/۱۳

تاریخ پذیرش: ۱۴۰۳/۱۰/۲۳

جگہ

اندازه‌گیری مستقیم میانگین وزنی قطر (MWD) خاکدانه‌های تر به عنوان یکی از ساخته‌های مهم برای ارزیابی پایداری ساختمان خاک، کاری وقت‌گیر و پرهزینه است. هدف پژوهش حاضر مقایسه دقت مدل رگرسیون خطی چندگانه (MLR) و دو مدل هوشمند شامل شبکه عصبی مصنوعی (ANN) و برنامه‌ریزی بیان ژن (GEP) در برآورد MWD از روی متغیرهای زودیافت و سهله‌الوصول خاک بود. برای این منظور، ۸۰ نمونه خاک سطحی دست‌خورده و دست‌نخورده از عمق صفر تا ۱۰ cm اراضی جنگلی، مرتعی و زراعی منطقه فندقلوی استان اردبیل جمع آوری شد. سپس برخی ویژگی‌های فیزیکی و شیمیایی زودیافت آن‌ها و میانگین وزنی قطر (MWD) خاکدانه‌های تر مطابق روش‌های معمول و استاندارد تعیین گردید. داده‌ها به طور تصادفی به دو مجموعه آموزشی (۶۰ داده) و آزمونی (۲۰ داده) تقسیم گردید. مدل‌های MLR و ANN و GEP به ترتیب با به کارگیری نرم‌افزارهای SPSS و MATLAB و Xpro Tools Gene ایجاد شدند. نتایج نشان‌دهنده همبستگی مثبت و معنی‌دار ($P < 0.05$) بین شن و کربن آلی خاک بود. شن، کربن آلی و میانگین هندسی قطر (GMD) خاکدانه‌های خشک از مهمترین متغیرهای ورودی مدل‌ها در برآورد MWD خاکدانه‌های تر بودند. براساس داده‌های آزمونی، مقادیر ضریب تبیین (R^2)، رشته میانگین مربعات خطای (RMSE)، میانگین خطای (ME) و ضریب نش - ساتکلیف (NS) برابر 0.52 mm، 0.48 mm، 0.44 mm، 0.40 mm، 0.38 mm، 0.35 mm، 0.30 mm، 0.28 mm، 0.26 mm، 0.24 mm و 0.20 mm بودند. GEP به دست آمد. بنابراین مدل MLR در مقایسه با مدل‌های هوشمند از دقت کمتری و خطای بیشتری در برآورد MWD برخوردار بود؛ مدل ANN به علت داشتن R^2 و NS بالا و RMSE پایین توانست در مقایسه با دو مدل دیگر، MWD خاکدانه‌های تر را دقت زیاد و خطای کم در منطقه مورد مطالعه تخمین بزند.

واژه‌های کلیدی: ارضی شیبدار، توابع انتقالی خاک، برنامه‌ریزی بیان زن، پایداری خاکدانه، شبکه عصبی مصنوعی

١٦٣

اطلاع از وضعیت پایداری خاکدانه‌ها و ساختمان خاک از نظر مدیریت آب و خاک به ویژه در اراضی شیبدار که در معرض فرسایش قرار دارند حائز اهمیت است. یکی از شاخص‌های مهم و با ارزش برای

^{۱، ۲ و ۳}- به ترتیب استاد، دانشجوی دکتری و دانشیار گروه علوم و مهندسی خاک، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل، ایران
^۴- نویسنده مسئول (Email: shashehri@uma.ac.ir)

^۳- دانشیار، گروه مهندسی، آب، دانشکده کشاورزی، و منابع طبیعی، دانشگاه محقق اردبیل، اردبیل، ایران.

MWD، مدل هوشمند نروفازی ($R^2 = 0.97$) نسبت به مدل MWD ($R^2 = 0.90$) از ضریب تبیین بالاتر و در نتیجه دقت بیشتری برخوردار بود. اصغری و همکاران (Asghari et al., 2021) از مدل‌های ANN و نروفازی برای برآورد MWD خاکدانه‌های تر در اراضی متاثر از نمک اطراف دریاچه ارومیه استفاده کردند. نتایج نشان داد کربن آلی، شن و نسبت جذبی سدیم مهم‌ترین متغیرهای زودیافت در برآورد MWD بودند همچنین مدل ANN به دلیل داشتن خطای کم در مقایسه با توابع رگرسیونی و نروفازی از دقت بیشتری در برآورد MWD تر برخوردار بود. سرکار و همکاران (Sarkar et al., 2023) از مدل‌های رگرسیونی (MLR) و هوشمند شامل ANN، ماشین بردار پشتیبان (SVM)، درخت تصمیم‌گیری (RT) و جنگل تصادفی (RF) برای برآورد MWD خاکدانه‌های تر از روی شن، سیلت، رس، گرم مخصوص ظاهری، بعد فراکتالی، کربن آلی و گلومالین در ۱۲۱ نمونه خاک منتخب از کشور هندوستان استفاده کردند؛ نتایج نشان داد که مدل MLR از دقت کمتری در برآورد MWD در مقایسه با سایر مدل‌های هوشمند برخوردار بود در حالی که مدل SVM دارای بیشترین دقت در تخمین MWD در بین مدل‌های مورد مطالعه بود. اخیراً از مدل GEP نیز به عنوان یک روش هوشمند در برآورد برخی ویژگی‌های دیریافت خاک استفاده شده است؛ به عنوان مثال، Ahmedzadeh Kaleibar & Fuladipanah (2023) گزارش کردند که مدل GEP در مقایسه با مدل‌های رگرسیون خطی و غیرخطی توانست رطوبت‌های ظرفیت مزمعه و نقطه پژمردگی را با دقت بالایی تخمین بزند. نتایج پژوهش زانگ و زانگ (Zhang & Zhang, 2024) نیز نشان داد که مدل GEP در مقایسه با سایر مدل‌های هوشمند و روابط ریاضی توانست ضریب نفوذپذیری خاک را با دقت بیشتر و خطای کمتر ($R^2 = 0.94$ و RMSE برابر با 0.48 m) برآورد نماید.

بررسی منابع نشان داد مدل‌های MLR و ANN متعددی برای برآورد شاخص‌های پایداری خاکدانه در ایران و جهان ارائه شده است ولی واقعیت آن است که به دلیل تغییرپذیری بالای مکانی و زمانی شاخص‌های پایداری ساختمان خاک، مدل‌های مذکور اغلب برای اراضی مناطق مورد مطالعه کارایی لازم را دارند و کاربرد آن‌ها برای خاک‌های سایر مناطق اقلیمی نیاز به راستی آزمایی دارد؛ از سوی دیگر، براساس اطلاعات موجود و در دسترس، تاکنون از مدل GEP برای برآورد MWD خاکدانه‌های تر به ویژه در اراضی شیبدار منطقه فندقلوی اردبیل استفاده نگردیده است لذا پژوهش حاضر از این نظر دارای نوآوری می‌باشد. اراضی جنگلی، مرتعی و زراعی منطقه فندقلو

Karbini آلی و آهک در مناطق مختلف اقلیمی ایران (Alijanpour et al., 2011; Amirabedi et al., 2016; Asghari et al., 2021; Marashi et al., 2019) و جهان (Bhattacharya et al., 2021; Sarkar et al., 2023) ارائه گردیده است.

توابع انتقالی متعددی بر مبنای مدل‌های رگرسیون خطی چندگانه^۱ (MLR)، شبکه عصبی مصنوعی^۲ (ANN) و برنامه‌ریزی بیان ژن^۳ (GEP) برای برآورد متغیرهای دیریافت و پرهزینه خاک از روی متغیرهای زودیافت و کم‌هزینه خاک ارائه گردیده است؛ اکثر محققان گزارش کرده‌اند که در بین مدل‌های تخمین‌گر، توابع MLR به علت در نظر نگرفتن روابط غیرخطی بین متغیرهای ورودی (زودیافت) و خروجی (دیریافت) از عملکرد ضعیفی برخوردار هستند (Bhattacharya et al., 2021; Sarkar et al., 2023). با توجه به این که داده‌های واقعی در مقیاس جهانی، عمدتاً غیرخطی هستند لذا مدل‌های هوشمند همانند ANN و GEP بر مبنای روش‌های ماشین پژمردگی و تشخیص الگو عمل نموده و قادر به شناسایی بهتر روابط غیرخطی بین متغیرهای زودیافت و دیریافت خاک هستند.

علی‌جانپور شلمانی و همکاران (Alijanpour Shalmani et al., 2011) از مدل‌های MLR و ANN برای برآورد میانگین هندسی قطر^۴ (GMD) خاکدانه‌های خشک در اراضی جنگلی استان گیلان استفاده کردند. نتایج بیانگر آن بود که مدل ANN به علت داشتن ضریب تبیین بالا و خطای پایین در مقایسه با مدل MLR از دقت بالاتری برخوردار بود و pH، گرم مخصوص حقیقی، سیلت و مقاومت مکانیکی خاک به عنوان مناسب‌ترین متغیرهای ورودی تعیین گردیدند. نتایج پژوهش امیرعبادی و همکاران (Amirabedi et al., 2016) در دشت اردبیل نشان داد که مدل ANN نسبت به مدل MLR توانست MWD خاکدانه‌های تر را با دقت بالاتری برآورد نماید و رس، کربن آلی و گرم مخصوص ظاهری به عنوان بهترین متغیرهای ورودی در منطقه مورد مطالعه شناسایی شدند. اصغری و همکاران (Asghari et al., 2017) گزارش نمودند استفاده از بعد فراکتالی خاکدانه^۵ در ورودی MWD مدل‌های MLR و ANN موجب افزایش دقت تخمین خاکدانه‌های تر (مرحله آموزش) در اراضی جنگلی، مرتعی و زراعی منتخب از استان اردبیل گردید همچنین مدل ANN ($R^2 = 0.95$) در مقایسه با مدل MLR ($R^2 = 0.85$) دارای ضریب تبیین بالاتری بود. مرعشی و همکاران (Marashi et al., 2019) از رس، pH، کربن آلی، ظرفیت تبادل کاتیونی و بعد فراکتالی خاکدانه‌ها به عنوان متغیرهای ورودی برای تخمین MWD خاکدانه‌های تر در استان آذربایجان شرقی استفاده کردند. نتایج بیانگر آن بود که در برآورد

5- Fractal dimension

6- Support vector machine

7- Regression tree

8- Random forest

1- Multiple linear regression

2- Artificial neural network

3- Gene expression programming

4- Geometric mean diameter

استوانه‌های استیل (Blake & Hartge, 1986a) و جرم مخصوص حقیقی (PD) به روش پیکنومتر (Blake & Hartge, 1986b) اندازه‌گیری شد. میانگین هندسی قطر (GMD) خاکدانه‌ها به روش الک خشک در ۵۰ گرم خاک هواخشک گذرانده شده از الک ۴/۷۵ میلی‌متر با استفاده از دستگاه شیکر الک خشک و با به کارگیری الک‌های با قطر سو راخ به ترتیب از بالا به پایین ۲، ۱، ۰/۵، ۰/۲۵، ۰/۱۰۶ میلی‌متر اندازه‌گیری و محاسبه گردید (Kemper & Rosenau, 1986).

میانگین وزنی قطر (MWD) خاکدانه‌های تر در ۵۰ گرم خاک هواخشک گذرانده شده از الک ۴/۷۵ میلی‌متر با استفاده از دستگاه شیکر الکتر با شدت ۳۰ نوسان در دقیقه و مدت ۵ دقیقه در داخل سطل‌های بزرگ آب تعیین گردید. به این ترتیب که، MWD خاکدانه‌های تر با به کارگیری الک‌های با قطر سو راخ به ترتیب از بالا به پایین ۲، ۱، ۰/۵ و ۰/۱۰۶ میلی‌متر پس از تصحیح به وزن شن بر حسب میلی‌متر از رابطه زیر محاسبه گردید (Yoder, 1936).

$$MWD = \sum_{i=1}^{i=5} \left(\frac{R-S}{m_{a-S}} \right) i \times d_i \quad (1)$$

در این رابطه، R وزن آون خشک خاکدانه‌ها و شن‌های مانده بر روی الک نام (گرم)، S وزن آون خشک شن‌های مانده بر روی الک نام (گرم)، S وزن مجموع شن‌ها (گرم)، m_a وزن خاک آون خشک (گرم) و d_i میانگین قطر سو راخ دو الک متولی است. لازم به توضیح است که MWD روش الک تر، پایداری خاکدانه‌ها در آب را نشان می‌دهد که برای تعیین آن حدود سه روز زمان لازم است در حالی که برای تعیین GMD روش الک خشک در حدود یک ساعت زمان لازم است.

قبل از اجرای فرآیند مدل‌سازی داده‌ها به روش‌های رگرسیونی و هوشمند، آزمون نرمال بودن توزیع داده‌ها به روش کولموگروف-اسمیرنوف^۴ و نیز محاسبات مربوط به آمار توصیفی و ضریب همبستگی پیرسون بین متغیرها در نرم‌افزار 22 SPSS انجام گرفت؛ آزمون نرمال بودن نشان داد همه داده‌ها از توزیع نرمال برخوردار هستند. اشتاقاق مدل‌های رگرسیونی خطی چندگانه (MLR) بین متغیرهای زودیافت خاک با متغیر دیریافت (MWD خاکدانه‌های تر) به روش گام^۵ در نرم‌افزار 22 SPSS انجام شد. در مجموع، بر اساس روش گام به گام چهار نوع مدل MLR بین متغیرهای ورودی (زودیافت) و خروجی (دیریافت) تشخیص داده شد.

به علت شیبدار بودن، تردد کنترل نشده گردشگر در فصول معتدل و گرم سال، چرای بی‌رویه دام‌های سنگین (گاو و گاویش) و شخم موازی شب توسط کشاورزان محلی در معرض فرسایش و تخریب شدید قرار دارند لذا ایجاد مدل‌های رگرسیونی و هوشمند برای برآورد پایداری خاکدانه در آب و نیز ارزیابی دقت مدل‌های مذکور به منظور اعمال روش‌های مدیریتی صحیح آب و خاک در منطقه مذکور ضروری به نظر می‌رسد. اهداف پژوهش حاضر عبارت بودند از (۱) ارائه مدل‌های ANN و GEP برای برآورد MWD خاکدانه‌های تر از روی متغیرهای زودیافت خاک در اراضی جنگلی، مرتعی و زراعی مجاور هم منطقه فندقلوی استان اردبیل (۲) مقایسه و ارزیابی دقت مدل‌های مذکور در برآورد MWD خاکدانه‌های تر با استفاده از آماره‌های ضریب تبیین (R²، ریشه میانگین مربعات خطأ)، (RMSE) میانگین خطأ (ME) و ضریب نش-ساتکلیف^۶ (NS).

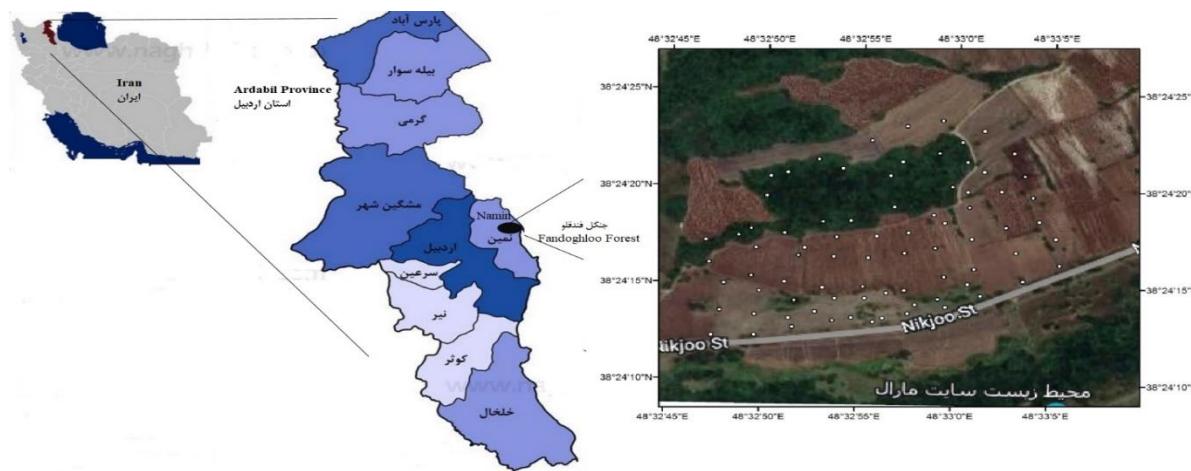
مواد و روش‌ها

تعداد ۸۰ نمونه خاک از عمق ۰ تا ۱۰ سانتی‌متری اراضی شیبدار و مجاور هم شامل: کاربری‌های جنگلی (۲۰ نمونه)، مرتعی (۲۳ نمونه) و زراعی (۳۷ نمونه) منطقه فندقلوی اردبیل با ثبت مختصات جغرافیایی نقاط در فواصل حدود ۵۰ متری و به طور تقریباً منظم در تابستان ۱۴۰۲ برداشت شد (شکل ۱). نمونه‌برداری خاک در هر نقطه به دو صورت دستخورده (با احتیاط کامل و کمترین تخریب خاکدانه‌ها) با استفاده از بیلچه و دستنخورده (استوانه‌های استیل به قطر و ارتفاع ۵ سانتی‌متر) با استفاده از نمونه‌بردار دستی انجام گرفت. نمونه‌های خاک در آزمایشگاه هواخشک شدن سپس مقداری از آن‌ها برای تعیین میانگین وزنی قطر (MWD) خاکدانه‌های تر و نیز میانگین هندسی قطر (GMD) خاکدانه‌های خشک جدا گردید و با قیامنده خاک پس از خرد شدن به منظور اندازه‌گیری سایر متغیرهای خاک از الک ۲ mm عبور داده شد. درصد ذرات شن، سیلت و رس (کلاس بافت خاک) به روش هیدرومتری چهار قرائته (Gee & Or, 2002) اندازه‌گیری شد سپس متغیرهای میانگین هندسی قطر (d_g) و انحراف استاندارد هندسی (σ_g) ذرات خاک از روی درصدهای ذرات خاک و با استفاده از روابط ارائه شده توسط شیرازی و بورسما (Shirazi & Boersma, 1984) محاسبه گردید. اسیدینه (pH) و هدایت الکتریکی (EC) در عصاره ۱/۲ خاک به آب و آهک به روش تیتراسیون با اسید و سود اندازه‌گیری شد (Page, 1985) کریں آلی به روش اکسیداسیون تر (Nelson & Sommers, 1982) تعیین گردید. جرم مخصوص ظاهری (BD) به روش نمونه دستنخورده در

1- Root mean square error

2- Mean error

3- Nash-Sutcliffe coefficient



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

برنامه‌ریزی ژنتیک ترکیب می‌شوند (Ferreira, 2001). جزئیات بیشتر در مورد فرایند اجرای مدل GEP در تحقیق زانگ و زانگ (Zhang & Zhang, 2024) بیان شده است. در تحقیق حاضر برای مدل‌سازی MWD خاکدانه‌های تر به روش برنامه‌ریزی بیان ژن (GEP) از نرم‌افزار 4.0 Gene Xpro Tools (GEP) استفاده گردید. در این نوع مدل‌سازی یک سری عملگرهای ریاضی از قبیل جمع، تفریق، ضرب، تقسیم، ریشه دوم، ریشه سوم، لگاریتم طبیعی، لگاریتم نپری، توان دوم و توان سوم به کار گرفته شد. **جدول ۱**، مقادیر انتخابی پارامترهای لازم برای اجرای مدل GEP را نشان می‌دهد.

در هر سه روش مدل‌سازی ANN، MLR و GEP از کل 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 کارآیی مدل‌های ANN، MLR و GEP در برآورد MWD خاکدانه‌های تر از آمارهای ضریب تبیین (R^2)، ریشه میانگین مربعات خطأ (RMSE)، میانگین خطأ (ME) و ضریب نش-ساتکلیف (NS) (Ghorbani et al., 2019) استفاده گردید.

برای ایجاد مدل‌های شبکه عصبی مصنوعی (ANN) با استفاده از نرم‌افزار MATLAB، از همان متغیرهای ورودی در چهار مدل MLR استفاده گردید. برای این منظور، شبکه پرسپترون سه لایه (وروودی، پنهان و خروجی) با الگوریتم پس انتشار خطأ و ۱۰۰۰ تکرار برای رسیدن به حداقل خطأ و حداقل پایداری شبکه به کار گرفته شد و تعداد نرون‌های مناسب به روش سعی و خطأ در لایه پنهان برای چهار مدل شبکه عصبی به ترتیب برابر ۸، ۹، ۶ و ۶ 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 تائزانت سیگموئید و خطی به ترتیب در لایه‌های پنهان و خروجی هر چهار 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) یک الگوریتم توسعه یافته براساس برنامه‌ریزی ژنتیک و الگوریتم ژنتیک می‌باشد و مبنای تمامی آنها بر اساس 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

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	30	تعداد کروموزوم‌ها
0.1	Inversion rate	8	اندازه سر
0.3	one point recombination rate	3	تعداد ژن‌ها
0.3	two point recombination rate	جمع (+)	لینکینگ فکشن
0.1	Gene recombination rate	RMSE	معیار خطای تابع

تخلخل کل خاک از ۳۹ تا ۶۲ و ۴۳ تا ۸۷ درصد بیانگر این موضوع می‌باشد. علاوه بر آن، از **جدول ۲** مشهود است که مقادیر متوسط متغیرها در مراحل آموزش و آزمون مدل‌ها تقریباً نزدیک هم بوده و بهترتیب برای MWD خاکدانه‌های تر $1/3$ و $1/35$ میلی‌متر، برای GMD خاکدانه‌های خشک $1/0.3$ و $1/0.4$ میلی‌متر، برای شن $34/0.8$ و $30/0.81$ درصد، برای کربن آلی $2/78$ و $2/80$ درصد و برای تخلخل MWD کل خاک 53 و 54 درصد می‌باشد. مقادیر زیاد کربن آلی، GMD خاکدانه‌های تر و GMD خاکدانه‌های خشک در کاربری جنگلی به دلیل تجمع هر ساله لاشبرگ‌های درختان (عمدتاً فندق) و مقادیر کم متغیرهای مذکور در کاربری زراعی به علت اتفاف ماده آلی خاک در اثر فرسایش خاک ناشی از شخم اراضی شیبدار در منطقه مورد مطالعه به دست آمد. این نتایج با یافته‌های اصغری و همکاران ([Asghari et al., 2016](#)) در یک راستا می‌باشد؛ این محققان مقادیر متوسط کربن آلی خاک را 6 و $2/24$ درصد و MWD خاکدانه‌های تر را $1/28$ و $0/35$ میلی‌متر بهترتیب در کاربری‌های جنگلی و زراعی منطقه فندقلوی اردبیل گزارش کردند. کلاس بافت خاک‌های مورد مطالعه در پژوهش حاضر براساس درصد‌های شن، سیلت و رس و طبق مثلت بافت آمریکایی، لوم رسی سیلتی ($n=23$)، لوم رسی سیلتی ($n=14$)، لوم ($n=13$)، لوم شنی ($n=12$)، لوم رسی ($n=11$)، لوم رسی شنی ($n=6$) و رسی سیلتی ($n=1$) به دست آمد که مؤید توزیع نسبتاً خوب بافت خاک در داده‌های مورد مطالعه می‌باشد. مقایسه مقادیر متوسط شاخص‌های پایداری خاکدانه (MWD و GMD) و تخلخل کل خاک در پژوهش حاضر با یافته‌های محققان در سایر اراضی واقع در استان اردبیل بیانگر پایداری بیشتر ساختمان خاک و نیز تخلخل بالای خاک به علت برخورداری از پوشش گیاهی جنگلی و مرتعد در منطقه مورد مطالعه می‌باشد. به طور مثال، امیرعبدی و همکاران ([Amirabedi et al., 2016](#)) مقدار متوسط MWD خاکدانه‌های تر و تخلخل کل خاک را بهترتیب $0/50$ میلی‌متر و 47 درصد در اراضی دشت اردبیل (با فاصله حدود 30 کیلومتر از محل پژوهش حاضر) گزارش نمودند.

جدول ۳ نشان می‌دهد براساس ضرایب همبستگی پیرسون (r)، همبستگی خطی قوی ($r > 0.60$) بین شن با سیلت و میانگین هندسی قطر ذرات (d_g)، سیلت با انحراف استاندارد هندسی ذرات (s_g) و رس با d_g وجود دارد لذا برای پرهیز از همراستایی چندگانه، این متغیرها به طور همزمان به عنوان ورودی مدل برای ایجاد مدل‌های MLR در برآورد MWD خاکدانه‌های تر به کار گرفته نشدند.

مقادیر بالای R^2 (نرדיک به ۱) بیانگر دقت بالای تخمین می‌باشد. از لحاظ آماری کمترین مقدار RMSE، صفر می‌باشد که در آن شرایط، مقادیر اندازه‌گیری و تخمینی MWD باهم برابرند؛ هرچه مقدار RMSE کوچکتر باشد تخمین انجام شده توسعه مدل برآورد کننده دقیق‌تر است. مقادیر مثبت ME بیش‌برآورده و مقادیر منفی آن کم‌برآورده مدل را نشان می‌دهد. اگر ضریب NS برابر یک باشد بیانگر آن است که مدل سازی با دقت بالایی انجام گرفته و مقادیر اندازه‌گیری و تخمینی MWD برهمنطبق هستند؛ مقدار صفر NS نشان دهنده آن است که مقادیر تخمینی مدل با میانگین داده‌های اندازه‌گیری شده دارای دقت یکسان می‌باشند.

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

$$ME = \frac{\sum_{i=1}^n Y_{i(p)} - Y_{i(m)}}{n} \quad (3)$$

$$NS = 1 - \frac{\sum_{i=1}^n (Y_{i(p)} - Y_{i(m)})^2}{\sum_{i=1}^n (Y_{i(m)} - \bar{Y}_m)^2} \quad (4)$$

در معادلات ۲، ۳ و ۴، $Y_i(p)$ و $Y_i(m)$ بهترتیب مقادیر اندازه‌گیری، برآورده و میانگین مقادیر اندازه‌گیری شده MWD در هر مدل می‌باشد. از تعداد داده‌ها برای MWD، بهترین مدل MLR و GEP با ترکیب متغیرهای ورودی در داده‌های آزمونی، براساس آماره‌های مذکور تعیین شد. آزمون مدل‌ها در شناسایی دقت مدل به ازای داده‌هایی که در آموزش مدل به کار نرفته‌اند استفاده می‌شود.

نتایج و بحث

توصیف آماری متغیرهای خاک

با توجه به **جدول ۲** مشاهده می‌شود که داده‌های به کار رفته در مراحل آموزش و آزمون مدل‌های رگرسیون خطی چندگانه (MLR)، شبکه عصبی مصنوعی (ANN) و برنامه‌ریزی بیان ژن (GEP) از توزیع نسبتاً مناسبی برخوردار هستند؛ این نکته از نظر ایجاد و ارزیابی مدل‌ها مهم تلقی می‌شود به عنوان مثال پراکنش نسبتاً وسیع داده‌ها بهترتیب در مراحل آموزش و آزمون برای MWD خاکدانه‌های تر از $0/35$ تا $2/65$ میلی‌متر و از $0/60$ تا $2/50$ میلی‌متر، برای GMD خاکدانه‌های خشک از $1/33$ تا $1/33/0.80$ تا $1/20$ میلی‌متر و از $0/89$ تا $1/13/14$ تا $1/13/0.80$ تا $1/15/31$ تا $1/15/35$ میلی‌متر، برای شن از $6/55$ تا $7/17$ درصد و $1/15$ تا $1/10$ درصد و برای

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.
n ($\text{cm}^3 \text{ cm}^{-3}$)	0.39	0.62	0.53	0.05	0.43	0.87	0.54	0.09
PD (g cm^{-3})	2.01	2.67	2.43	0.15	2.03	2.68	2.41	0.16
Clay (%)	3.00	42.18	20.59	9.73	3.94	38.40	23.86	10.41
Silt (%)	21.12	65.20	45.33	13.10	23.38	74.97	45.32	11.91
Sand (%)	13.14	64.80	34.07	15.82	15.31	56.35	30.81	13.63
d _g (mm)	0.01	0.21	0.06	0.05	0.02	0.15	0.05	0.04
σ_g (-)	6.94	20.43	11.39	3.21	5.61	17.05	11.92	3.07
MWD (mm)	0.35	2.65	1.30	0.61	0.60	2.50	1.35	0.69
GMD (mm)	0.8	1.33	1.03	0.11	0.89	1.20	1.04	0.09
OC (%)	1.01	7.17	2.78	1.71	1.15	6.55	2.80	1.85
CaCO ₃ (%)	3.12	15.60	7.16	2.00	2.10	10.24	6.82	2.12
pH _{1:2.5}	5.45	7.34	6.28	0.39	5.68	7.09	6.38	0.41
EC _{1:2.5} (dS m ⁻¹)	0.02	1.08	0.15	0.17	0.04	0.80	0.13	0.16

PD: جرم مخصوص حقیقی (geometric mean density)، d_g: میانگین هندسی قطر ذرات (geometric mean diameter)، sand: رس، silt: سیلت، clay: میانگین هندسی قطر ذرات (geometric mean diameter)، σ_g: انحراف استاندارد هندسی ذرات (geometric standard deviation)، MWD: میانگین وزنی قطر خاکدانه‌های تر (mean weight diameter)، GMD: میانگین هندسی قطر خاکدانه‌های خشک (geometric mean diameter)، OC: کربن آلی (organic carbon)، CaCO₃: کربنات کلسیم معادل، Mean: میانگین، pH: انحراف استاندارد، Sd: کربنات کلسیم معادل، Min: حداقل، Max: حداکثر.

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

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

Variable	MWD	GMD	Clay	Sand	Silt	OC	pH	EC	CaCO ₃	σ _g	dg	PD
GMD	0.30**	1.00										
Clay	-0.48**	0.18 ^{ns}	1.00									
Sand	0.70**	0.11 ^{ns}	-0.55**	1.00								
Silt	-0.46**	-0.27*	-0.10 ^{ns}	-0.76**	1.00							
OC	0.67**	0.14 ^{ns}	-0.59**	0.59**	-0.24*	1.00						
pH	0.52**	0.06 ^{ns}	-0.24*	0.59**	-0.52**	0.33**	1.00					
EC	0.06 ^{ns}	-0.07 ^{ns}	-0.05 ^{ns}	0.15 ^{ns}	-0.14 ^{ns}	0.08 ^{ns}	0.40**	1.00				
CaCO ₃	0.37**	0.02 ^{ns}	-0.28*	0.41**	-0.27*	0.39**	0.45**	0.14 ^{ns}	1.00			
σ _g	0.33**	0.36**	0.42**	0.41**	-0.83**	0.02 ^{ns}	0.37**	0.02 ^{ns}	0.04 ^{ns}	1.00		
dg	0.57**	-0.30 ^{ns}	-0.71**	0.87**	-0.49**	0.55**	0.47**	0.18 ^{ns}	0.44**	0.01 ^{ns}	1.00	
PD	-0.46**	-0.08 ^{ns}	0.41**	-0.32**	0.06 ^{ns}	-0.58**	-0.22*	-0.11 ^{ns}	-0.28*	0.08 ^{ns}	-0.36**	1.00
n	-0.23*	-0.02 ^{ns}	0.08 ^{ns}	-0.22*	0.20 ^{ns}	-0.06 ^{ns}	-0.30**	0.005 ^{ns}	-0.09 ^{ns}	-0.16 ^{ns}	-0.13 ^{ns}	0.19 ^{ns}

* و **: به ترتیب معنی دار 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. * and **: Significant at P < 0.05 and P < 0.01, respectively.

صورت باید از مدل حذف شود.

نتایج مدل‌های رگرسیون خطی چندگانه (MLR) برای میانگین وزنی قطر (MWD) خاکدانه‌های تر

چهار نوع مدل MLR برای برآورد MWD خاکدانه‌های تر از روی متغیرهای زودیافت خاک شامل شن، کربن آلی، GMD خاکدانه‌های خشک و جرم مخصوص حقیقی (PD) مطابق روش گام

عامل تورم واریانس (VIF) از جمله روش‌های تشخیص هم‌استایی چندگانه می‌باشد که بیانگر آن است واریانس ضرایب برآورده تا چه حد نسبت به حالته که متغیرهای برآورده همبستگی خطی ندارند افزایش یافته است (Yazdani et al., 2014). تحلیل هم‌خطی حدکثتر تورم واریانس (VIF) چهار مدل در [جدول ۴](#) نشان می‌دهد که مقادیر VIF کمتر از ۵ هستند و بیشترین مقدار آن در پژوهش حاضر ۲/۰۶ می‌باشد. بهطور کلی، اگر آماره VIF یک متغیر کمتر از ۵ باشد آن متغیر در مدل وارد می‌گردد در غیر این

1- Variance inflation factor (VIF)

MLR شماره ۴ نیز بیانگر آن است که با افزایش جرم مخصوص حقیقی خاک MWD خاکدانه‌های تر کاهش یافته است که علت آن را می‌توان به رابطه همبستگی منفی و معنی‌دار بین کربن آلی با PD ($r = -0.58^{**}$) نسبت داد؛ این نتیجه با یافته‌های علی‌جانپور شلمانی و همکاران (Alijanpour Shalmani *et al.*, 2011) در یک راستا می‌باشد که گزارش کردند متغیر PD با علامت منفی در مدل‌های MLR برای برآورد GMD خاکدانه‌های خشک وارد گردید.

آماره‌های ارزیابی مدل‌های MLR برای برآورد MWD خاکدانه‌های تر در **جدول ۵** آورده شده است. این آماره‌ها شامل ضریب تبیین (R^2)، ریشه میانگین مربعات خطأ (RMSE)، میانگین خطأ (ME) و ضریب نش-ساتکلیف (NS) بودند. بر پایه نتایج مطالعات قبلی، فقط به کارگیری R^2 برای ارزیابی مدل‌ها شاید گول زننده باشد لذا R^2 بالا دلیل بر مطابقت کامل مقادیر اندازه‌گیری با مقادیر برآوردهی MWD و کم بودن خطأ نمی‌باشد (Kozak *et al.*, 1996) (لذا در این پژوهش ارزش‌گذاری مدل‌های MLR، ANN و GEP در برآورد MWD، بر اساس پایین بودن RMSE و بالا بودن NS در داده‌های آزمونی صورت گرفت. با توجه به **جدول ۵** مشاهده می‌شود که مدل MLR شماره ۲ با متغیرهای ورودی شن و کربن آلی نسبت به سایر مدل‌های RMSE از MLR پایین و NS بالا در نتیجه دقت زیاد در برآورد MWD در مرحله آزمون داده‌ها برخوردار بود. مقادیر R^2 ، ME، RMSE و NS این مدل برای داده‌های آموزشی به ترتیب برابر ۰/۶۳، ۰/۳۷ mm و ۰/۰۲ mm هستند. برای داده‌های آزمونی برابر ۰/۴۸ mm و ۰/۱۳ mm نیز R^2 ، ME و NS مقدار واقعی MWD توسط مدل شماره ۲ می‌باشد. در رتبه بعدی، مدل MLR شماره ۳ با متغیرهای ورودی شن، کربن آلی و GMD قرار دارد (**جدول ۵**).

به گام در رگرسیون خطی چندگانه تعیین گردید (**جدول ۴**). نتایج ضریب همبستگی پیرسون بین MWD خاکدانه‌های تر با متغیرهای زودیافت خاک در **جدول ۳** نشان می‌دهد که برخلاف انتظار، بالاترین مقدار همبستگی مثبت و معنی‌دار بین MWD با شن ($r = 0.70^{**}$) پیدا شد؛ شن از عوامل مخرب خاکدانه‌سازی محسوب می‌شود دلیل این یافته متناقض در پژوهش حاضر را شاید بتوان به همبستگی مثبت و معنی‌دار بین کربن آلی و شن ($r = 0.59^{**}$) نسبت داد (**جدول ۴**)؛ به عبارت دیگر، در منطقه مورد مطالعه با افزایش شن، کربن آلی خاک نیز افزایش یافته و موجب افزایش خاکدانه‌سازی (MWD) گردیده است. همچنین همبستگی‌های منفی و معنی‌دار بین MWD خاکدانه‌های تر با سیلت ($r = -0.46^{**}$) و رس ($r = -0.48^{**}$) و همبستگی مثبت و معنی‌دار بین MWD با میانگین هندسی قطر ذرات (d_g) ($r = 0.57^{**}$) تعیین گردید؛ البته به دلیل همراستایی رس، سیلت با شن از این متغیرها به عنوان ورودی در کنار شن برای برآورد MWD خاکدانه‌های تر استفاده نگردید و سایر متغیرهای ورودی نیز براساس تشخیص روش گام به گام و احتمالاً به علت همبستگی ضعیف با MWD، در مدل‌های MLR به عنوان متغیر ورودی و با شن و کربن آلی در مدل‌های MLR ظاهر نشدند. مشاهده می‌شود علامت مثبت ظاهر گردیدند البته ضریب کربن آلی از ضریب شن بزرگتر است (**جدول ۴**). در پژوهش حاضر با توجه به این که شن در هر چهار مدل به کار گرفته شده است بنابراین مهمترین عامل اثرگذار در برآورد MWD خاکدانه‌های تر بوده است و کربن آلی، GMD و PD در درجه بعدی اهمیت قرار دارند. در مدل‌های رگرسیونی ارائه شده توسط اصغری و همکاران (Asghari *et al.*, 2021) و امیرعبدی و همکاران (Amirabedi *et al.*, 2016) نیز شن و کربن MWD آلی به عنوان متغیرهای ورودی حائز اهمیت در برآورد خاکدانه‌های تر گزارش گردیده است. علامت منفی PD در مدل

جدول ۴- مدل‌های رگرسیون خطی چندگانه (MLR) میانگین وزنی قطر خاکدانه‌های تر (MWD)

Table 4- MLR models of mean weight diameter of wet aggregates (MWD)

شماره Number	مدل Model	حداکثر Max VIF
1	MWD = 0.028 Sand + 0.346	1.00
2	MWD = 0.018 Sand + 0.148 OC + 0.244	1.55
3	MWD = 0.017 Sand + 0.137 OC + 1.444 GMD – 1.148	1.58
4	MWD = 0.016 Sand + 0.099 OC + 1.519 GMD – 0.746 PD + 0.721	2.06

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

Variables description is available under Table 2.

جدول ۵- معیارهای ارزیابی مدل‌های رگرسیونی خطی چندگانه (MLR) میانگین وزنی قطر خاکدانه‌های تر (MWD)

Table 5- Evaluation criteria for MLR models of mean weight diameter of wet aggregates (MWD)

شماره Number	متغیرهای ورودی Input variables	آزمون Testing				آموزش Training			
		R ²	RMSE (mm)	ME (mm)	NS	R ²	RMSE (mm)	ME (mm)	NS
1	Sand	0.47	0.51	0.14	0.41	0.52	0.42	-0.001	0.52
2	Sand, OC	0.52	0.48	0.13	0.48	0.63	0.37	0.02	0.63
3	Sand, OC, GMD	0.48	0.49	0.08	0.45	0.69	0.34	-0.02	0.69
4	Sand, OC, GMD, PD	0.43	0.51	0.07	0.41	0.71	0.32	-0.004	0.71

NS: ضریب نش-ساتکلیف، RMSE: مجدد میانگین مربعات خطای میانگین خطای، ME: میانگین خطای، 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-Sutcliff coefficient. Variables description is available under Table 2.

داده‌های آموزشی و آزمونی نشان‌دهنده تخمین جزئی بیشتر از مقدار واقعی MWD توسط مدل ANN شماره ۳ در این پژوهش می‌باشد. در درجات بعدی، بهترین مدل ANN شماره ۲ و شماره ۴ دارای دقت بالاتری در تخمین MWD می‌باشد؛ مدل ANN شماره ۲ نشان می‌دهد اضافه شدن متغیر کربن آلی به مدل ANN شماره ۱ موجب کاهش خطای مدل و افزایش دقت آن گردید به طوری که بر اساس داده‌های آزمونی، RMSE مدل ANN شماره ۲ نسبت به مدل ANN شماره ۱ به میزان حدود ۲۱ درصد کاهش و ضریب NS مدل ANN شماره ۲ نسبت به مدل ANN شماره ۱ به میزان حدود ۳۲ درصد افزایش یافت. اصغری و همکاران ([Asghari et al., 2021](#)) نیز در خاک‌های متاثر از نمک اطراف دریاچه ارومیه گزارش نمودند که MWD خاکدانه‌های تر با دقت بالا و خطای پایین (R²= ۰/۸۴) توسعه شبکه عصبی مصنوعی از روی متغیرهای ورودی شن، کربن آلی و نسبت جذبی سدیم برآورد گردید.

نتایج مدل‌های شبکه عصبی مصنوعی (ANN) برای بروآورد میانگین وزنی قطر (MWD) خاکدانه‌های تر

از چهار مدل شبکه عصبی مصنوعی (ANN) با همان متغیرهای ورودی مدل‌های MLR ([جدول ۵](#)) برای بروآورد MWD خاکدانه‌های تر استفاده گردید. در [جدول ۶](#) آماره‌های ارزیابی مدل‌های ANN برای بروآورد MWD ارائه شده است. ارجحیت مدل‌های ANN در بروآورد MWD نیز همانند مدل‌های MLR ([جدول ۵](#)، بر اساس پایین بودن میزان RMSE و بالا بودن میزان NS در داده‌های آزمونی تعیین گردید. بر این اساس، بهترین مدل ANN برای بروآورد MWD مدل ANN شماره ۳ با متغیرهای ورودی شن، کربن آلی و GMD در بین سایر مدل‌های ANN بود؛ مقادیر R²، RMSE، ME و NS این مدل برای داده‌های آموزشی بهترین مقدار دارند. مدل ANN شماره ۱ با متغیرهای ورودی شن، کربن آلی و GMD در بین مدل‌های ANN دارای نتایج نسبتاً خوبی است. مقدار ME برای داده‌های آزمونی برابر ۰/۰۳ و ۰/۰۰۳ و برای داده‌های آزمونی برابر ۰/۰۷۸ و ۰/۰۷۸ به دست آمد ([جدول ۶](#)). مقادیر اندک مثبت ME برای

جدول ۶- معیارهای ارزیابی مدل‌های شبکه عصبی مصنوعی میانگین وزنی قطر خاکدانه‌های تر (MWD)

شماره Number	Input variables	متغیرهای ورودی Input variables	R ²	آزمون Testing				آموزش Training			
				RMSE (mm)	ME (mm)	NS	R ²	RMSE (mm)	ME (mm)	NS	
1		Sand	0.59	0.43	-0.049	0.56	0.61	0.38	0.03	0.61	
2		Sand, OC	0.74	0.34	-0.002	0.74	0.75	0.30	-0.03	0.75	
3		Sand, OC, GMD	0.85	0.31	0.030	0.78	0.82	0.26	0.03	0.81	
4		Sand, OC, GMD, PD	0.72	0.38	-0.127	0.68	0.78	0.29	0.02	0.77	

NS: ضریب نش-ساتکلیف، RMSE: مجدد میانگین مربعات خطای میانگین خطای، 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-Sutcliff coefficient. Variables description is available under Table 2.

جدول ۷- معیارهای ارزیابی مدل‌های برنامه‌ریزی بیان ژن میانگین وزنی قطر خاکدانه‌های تر (MWD)
Table 7- Evaluation criteria for GEP models of mean weight diameter of wet aggregates (MWD)

شماره Number	متغیرهای ورودی Input variables	R^2	RMSE (mm)	ME (mm)	آزمون Testing		آموزش Training		
					NS	R^2	RMSE (mm)	ME (mm)	NS
1	Sand	0.49	0.50	-0.14	0.89	0.60	0.38	0.00	0.60
2	Sand, OC	0.69	0.37	-0.04	0.94	0.75	0.30	-0.03	0.75
3	Sand, OC, GMD	0.79	0.35	-0.10	0.95	0.80	0.27	0.00	0.80
4	Sand, OC, GMD, PD	0.71	0.40	-0.10	0.93	0.80	0.27	0.01	0.80

NS: ضریب نش-ساتکلیف، RMSE: میانگین مربعات خطأ، ME: میانگین خطأ، R^2 : ضریب تبیین. توصیف متغیرها در زیر جدول ۲ آورده شده است.

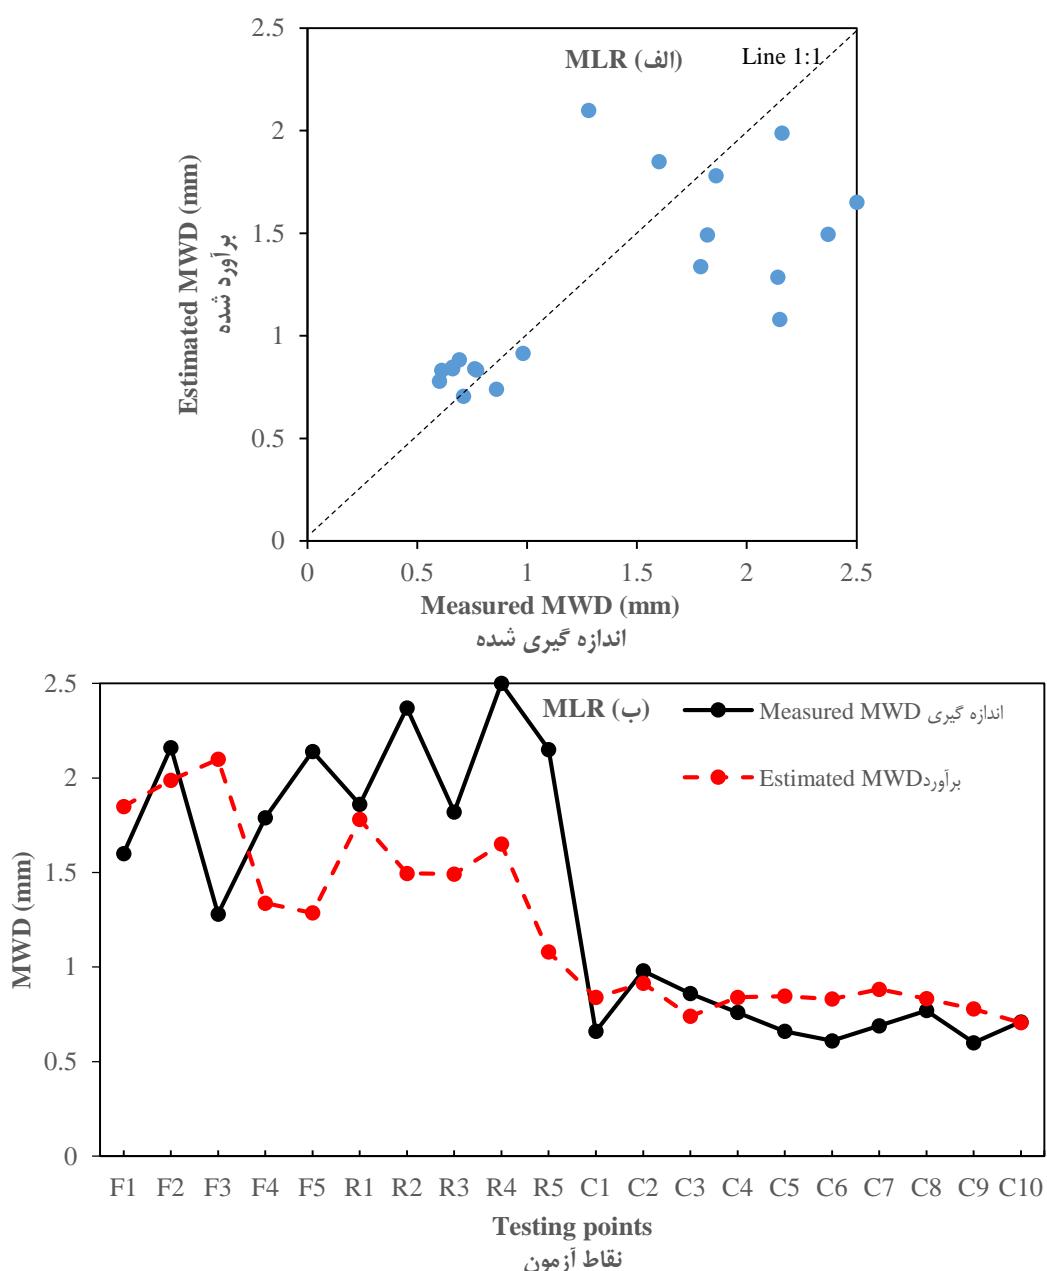
R^2 : coefficient of determination; RMSE: root mean square error; ME: mean error; NS: Nash-Sutcliff coefficient. Variables description is available under Table 2.

و GEP بهترین در شکل‌های ۳، ۲ و ۴ (الف) نشان داده شده است؛ با توجه به این اشکال مشاهده می‌شود بیشترین مقادیر اندازه‌گیری شده MWD خاکدانه‌های تر مربوط به کاربری‌های جنگلی (F) و مرتعی (C) و کمترین مقادیر آن مربوط به کاربری زراعی (C) می‌باشد که علت آن را می‌توان به مقادیر کم کربن آلی خاک (عامل اصلی سیمانی کننده ذرات خاک و خاکدانه‌سازی) در کاربری زراعی نسبت داد. همچنین مشاهده می‌شود خطای هر سه مدل ANN، MLR و GEP (اختلاف بین مقادیر اندازه‌گیری شده با مقادیر برآورد شده) در برآورد MWD خاکدانه‌های تر در نمونه‌های خاک برداشته شده از کاربری زراعی (C) به مرتب کمتر از کاربری‌های مرتعی (R) و جنگلی (F) می‌باشد؛ علت این مسئله را می‌توان به سهم بیشتر داده‌های کاربری زراعی در مقایسه با کاربری‌های جنگلی و زراعی در مرحله آموزش هر سه مدل مذکور نسبت داد.

مقادیر R^2 ، RMSE و NS برای مدل‌های MLR (جدول ۵)، MWD ANN (جدول ۶) و GEP (جدول ۷) ارائه شده برای برآورد خاکدانه‌های تر در داده‌های آزمونی بیانگر آن است که مدل‌های شبکه‌های عصبی مصنوعی (ANN) به علت داشتن R^2 بالا (از ۰/۵۹ تا ۰/۸۵) و NS بیشتر (از ۰/۵۶ تا ۰/۰۷۸) و RMSE پایین (از ۰/۳۱ تا ۰/۰۵۲ تا ۰/۰۴۳ میلی‌متر) در مقایسه با مدل‌های رگرسیون خطی چندگانه (R^2 از ۰/۰۵۲ تا ۰/۰۴۱، NS از ۰/۰۴۸ تا ۰/۰۴۸، RMSE از ۰/۰۴۸ تا ۰/۰۴۹ میلی‌متر) و مدل‌های برنامه‌ریزی بیان ژن (R^2 از ۰/۰۷۹ تا ۰/۰۸۹، NS از ۰/۰۹۵ تا ۰/۰۳۵ میلی‌متر) از دقت زیاد و خطای کم در برآورد MWD برخوردار بودند. شکل‌های ۲، ۳ و ۴ (ب) نیز نمودار ۱:۱ مقادیر اندازه‌گیری و برآورد شده MWD را با استفاده از ANN (مدل شماره ۲ در جدول ۵)، بهترین مدل MWD (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 در مقایسه با بهترین مدل‌های MLR و GEP کمتر است.

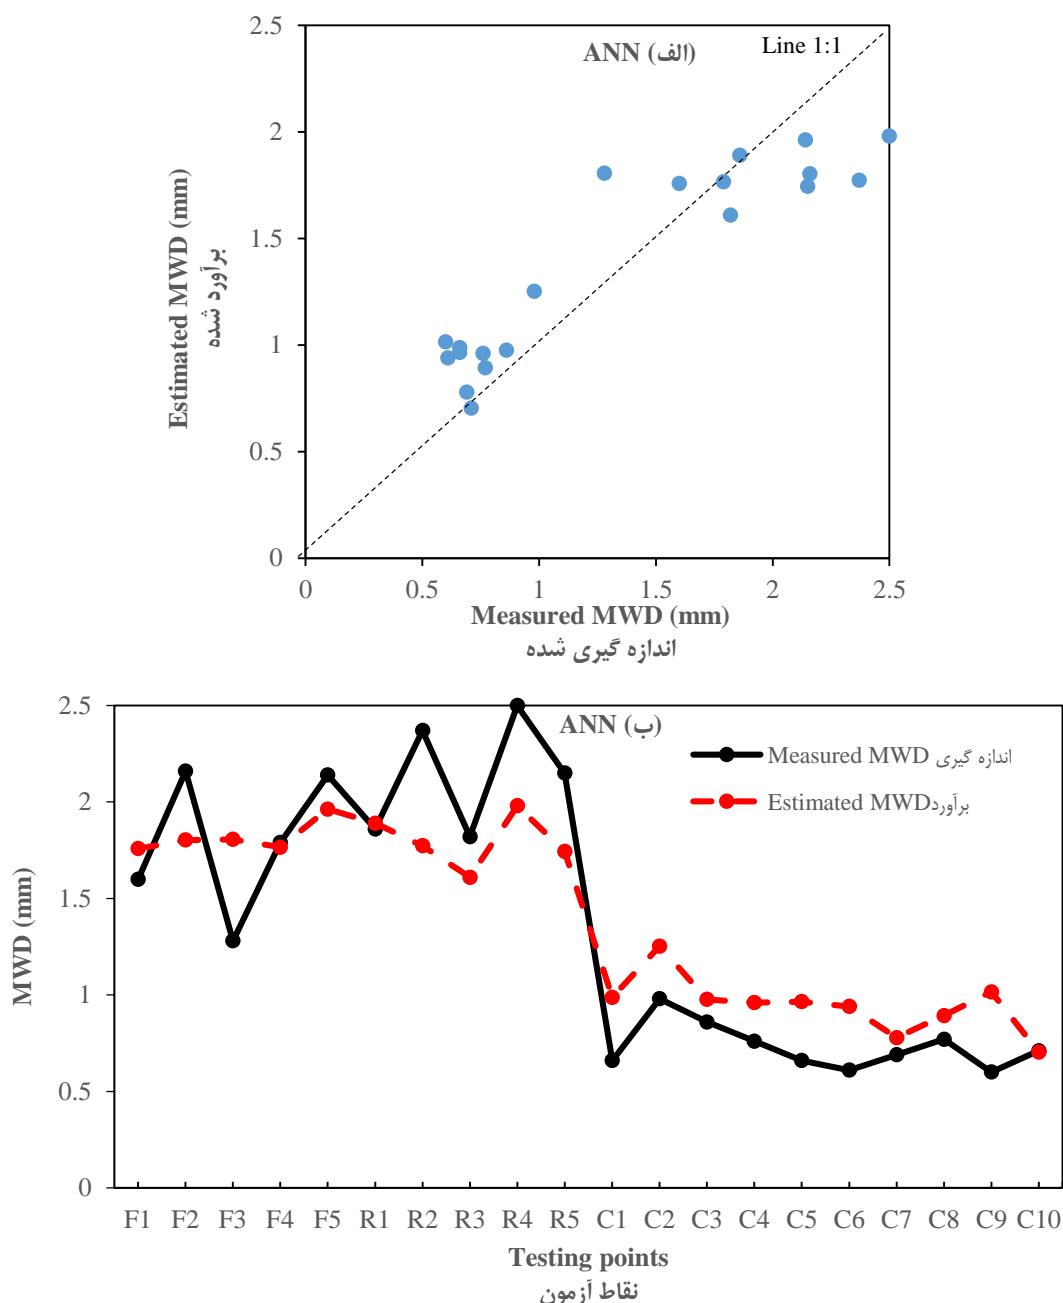
نتایج مدل‌های برنامه‌ریزی بیان ژن (GEP) برای برآورد میانگین وزنی قطر (MWD) خاکدانه‌های تر از چهار مدل برنامه‌ریزی بیان ژن (GEP) با همان متغیرهای ورودی مدل‌های MLR و ANN (جدول ۵ و ۶) برای برآورد MWD آماره‌های ارزیابی مدل‌های خاکدانه‌های تر استفاده شد؛ در جدول ۷ آماره‌های ارزیابی مدل‌های مذکور آورده شده است. اهمیت نسبی مدل‌های GEP در برآورد MWD نیز همانند مدل‌های MLR (جدول ۵) و ANN (جدول ۶) بر اساس پایین بودن میزان RMSE و بالا بودن میزان NS در داده‌های آزمونی تعیین گردید. بر این اساس، مدل شماره ۳ با متغیرهای ورودی شن، کربن آلی و GMD نسبت به سایر مدل‌های GEP توانست MWD را با خطای کم و دقت بالا تخمین بزند؛ مقادیر R^2 ، RMSE و ME برای این مدل بر اساس داده‌های آموزشی به ترتیب برابر ۰/۰۷۹ mm، ۰/۳۵ mm و ۰/۰۹۵ mm هستند. آزمونی برای ۰/۰۸۰ mm، ۰/۰۲۷ mm و ۰/۰۰۰ mm تعیین گردید (جدول ۷). مقدار منفی ME در داده‌های آموزشی بیانگر کم برآورده و MWD و مقدار صفر آن در داده‌های آزمونی بیانگر تخمین دقیق خاکدانه‌های تر توسط مدل GEP شماره ۳ در این پژوهش می‌باشد. در درجات بعدی اهمیت، به ترتیب مدل GEP شماره ۲ و شماره ۴ قرار دارد؛ با توجه به جدول ۷ مشاهده می‌شود افزودن متغیر کربن آلی به مدل GEP شماره ۱ باعث کاهش RMSE از ۰/۰۵۰ mm و افزایش ضریب NS از ۰/۰۸۹ به ۰/۰۹۴ در داده‌های آزمونی گردید. به علت نبود مطالعه در زمینه مدل‌سازی MWD خاکدانه‌های تر با استفاده از روش برنامه‌ریزی بیان ژن (GEP)، امکان مقایسه دقیق نتایج این قسمت با یافته‌های سایر محققان میسر نشد.

مقایسه دقت مدل‌های ANN، MLR و GEP در برآورد میانگین وزنی قطر (MWD) خاکدانه‌های تر مقایسه عملکرد بهترین مدل در برآورد MWD خاکدانه‌های تر بر ANN ن نقاط آزمونی (۲۰ داده تصادفی) برای مدل‌های MLR، GEP



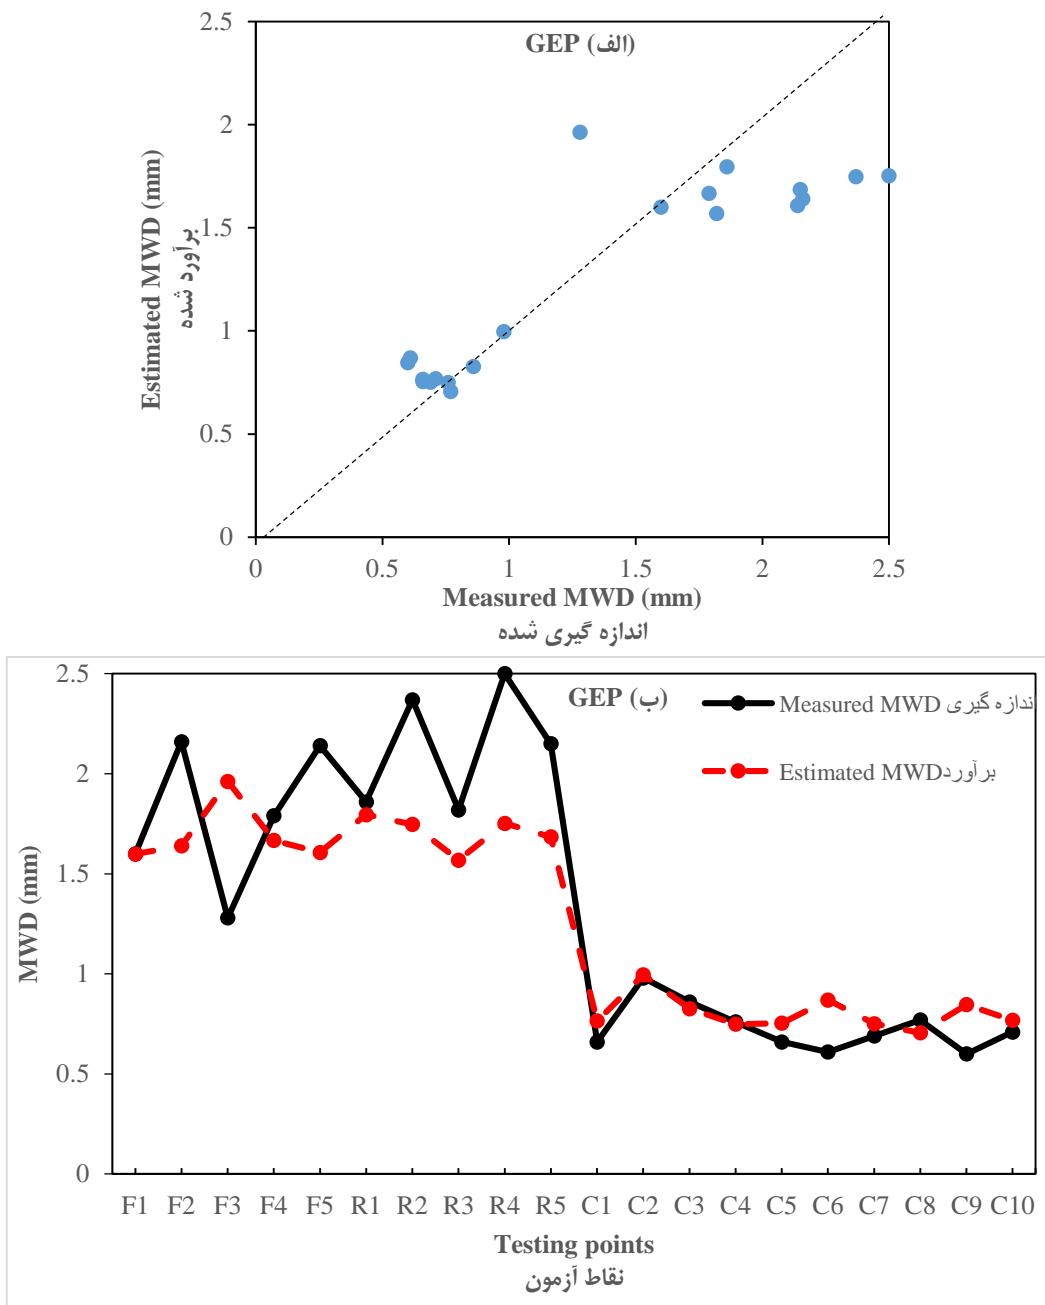
شکل ۲- مقایسه مقادیر اندازه‌گیری و برآورده شده میانگین وزنی قطر خاکدانه‌های تر (MWD) با استفاده از بهترین مدل رگرسیون خطی چندگانه (MLR) بر اساس داده‌های آزمونی (n=20): F: کاربری جنگلی، R: کاربری مرتعی و C: کاربری زراعی
اطلاعات مربوط به مدل و متغیرهای ورودی در [جدول ۵](#) آورده شده است.

Figure 2- Comparison of estimated and measured values of mean weight diameter of wet aggregates (MWD) using the best MLR model based on testing data (n=20); F: forest land use, R: range land use and C: cultivated land use
Table 5 provides detailed information about model and input variables.



شکل ۳- مقایسه مقادیر اندازه گیری و برآورده شده میانگین وزنی قطر خاکدانه‌های تر (MWD) با استفاده از بهترین مدل شبکه عصبی مصنوعی (ANN) بر اساس داده‌های آزمونی ($n=20$)؛ F: کاربری جنگلی، R: کاربری مرتعی و C: کاربری زراعی
اطلاعات مربوط به مدل و متغیرهای ورودی در جدول ۶ آورده شده است.

Figure 3- Comparison of estimated and measured values of mean weight diameter of wet aggregates (MWD) using the best ANN model based on testing data ($n=20$); F: forest land use, R: range land use and C: cultivated land use
Table 6 provides detailed information about each model and input variables.



شکل ۴- مقایسه مقادیر اندازه‌گیری و برآورد شده میانگین وزنی قطر خاکدانه‌های تر (MWD) با استفاده از بهترین مدل برنامه‌ریزی بیان ژن (GEP) بر اساس داده‌های آزمونی (n=20); F: کاربری جنگلی، R: کاربری مراتعی و C: کاربری زراعی
اطلاعات مربوط به مدل و متغیرهای ورودی در [جدول ۷](#) آورده شده است.

Figure 4- Comparison of estimated and measured values of mean weight diameter of wet aggregates (MWD) using the best GEP model based on testing data (n=20); F: forest land use, R: range land use and C: cultivated land use
Table 7 provides detailed information about each model and input variables.

موفق‌تر عمل نموده‌اند. علت پیش‌بینی‌های با دقت بالای شبکه‌های عصبی مصنوعی در مقایسه با مدل‌های رگرسیونی را شاید بتوان به شیوه عملکرد شبکه پرسپترون سه لایه ربط داد. عملکرد این شبکه به این صورت است که ابتدا الگویی به شبکه عصبی عرضه می‌شود و

بنابراین می‌توان چنین استنباط نمود که در این پژوهش، مدل‌های شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن در برآورد MWD از روی متغیرهای زودیافت خاک به علت استفاده از روابط غیر خطی پیچیده در مقایسه با مدل‌های رگرسیونی خطی چندگانه به مراتب

نتیجه‌گیری

دقت مدل رگرسیونی خطی چندگانه (MLR) و دو مدل هوشمند شامل شبکه عصبی مصنوعی (ANN) و برنامه‌ریزی بیان ژن (GEP) از نظر تخمین میانگین وزنی قطر (MWD) خاکدانه‌های تر از روی متغیرهای زودیافت و سهل‌الوصول خاک در اراضی منطقه فندقلوی اردبیل تحت سه کاربری بهم چسپیده جنگلی، مرتعی و زراعی مورد ارزیابی و مقایسه قرار گرفت. رابطه همبستگی مثبت و معنی‌دار بین MWD خاکدانه‌های تر با کربن آلی و شن یافت شد. مشخص گردید در هر سه روش مدل‌سازی، شن، کربن آلی و میانگین هندسی قطر (GMD) خاکدانه‌های خشک از مهم‌ترین و اثربارترین متغیرهای ورودی در برآورد MWD خاکدانه‌های تر در منطقه مورد مطالعه هستند. ارزیابی و مقایسه نتایج مدل‌ها نشان داد ANN به دلیل داشتن ضرایب تبیین (R^2) و نش-ساتکلیف (NS) بالا و ریشه میانگین مربعات خطای (RMSE) پایین‌تر، دارای دقت زیاد و خطای کم در برآورد MWD نسبت به مدل‌های MLR بودند. توصیه می‌گردد در پژوهش‌های آتی از بعد فراکتالی خاکدانه نیز به عنوان متغیر ورودی در مدل‌سازی MWD خاکدانه‌های تر استفاده شود همچنین نتایج مدل‌های رگرسیون غیرخطی و سایر مدل‌های هوشمند مانند نروفازی، ماشین بردار پشتیبان و جنگل تصادفی نیز در برآورد MWD خاکدانه‌های تر مقایسه و بررسی گردد.

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 برآورده شده و اندازه‌گیری شده باشد. اصغری و همکاران (Asghari et al., 2021) و امیرعبدی و همکاران (Amirabedi et al., 2016) نیز گزارش نمودند که شبکه‌های عصبی مصنوعی در مقایسه با مدل‌های رگرسیون خطی چندگانه در برآورد MWD خاکدانه‌های تر بهتر عمل نمودند. باتاچاریا و همکاران (Bhattacharya et al., 2021) نیز نمودند که مدل شبکه عصبی مصنوعی ($R^2 = 0.74$) در مقایسه با مدل رگرسیون خطی چندگانه ($R^2 = 0.65$) از دقت بیش‌تری در برآورد MWD از روی شن، سیلت، رس، جرم مخصوص ظاهری و کربن آلی برخوردار بود. اگرچه تحقیقی برای مقایسه مدل GEP در برآورد MWD یافت نشد ولی محققان قبلی مانند احمدزاده Ahmadzadeh Kaleibar & Fuladipanah, (2023) و زانگ و زانگ (Zhang & Zhang, 2024) به دقت بالای GEP در مقایسه با مدل‌های رگرسیون خطی و غیرخطی در برآورد ویژگی‌های دیریافت خاک مانند رطوبت‌های ظرفیت مزروعه و نقطه پژمردگی و نفوذپذیری از روی ویژگی‌های زودیافت خاک پی برده‌اند.

References

- Alijanpour Shalmani, A., Shabani, M., Asadi, H., & Bagheri, F. (2011). Estimation of soil aggregate stability in forest's soils of Guilan province by artificial neural networks and regression pedotransfer functions. *Water and Soil Science*, 21(3), 153-162. (In Persian with English abstract)
- 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)
- Ahmazadeh Kaleibar, F., & Fuladipanah, 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>
- Asghari, Sh., Dizajghoorbani Aghdam, S., & Esmali, A. (2016). Investigation the spatial variability of some soil physical quality indices in Fandoghlu region of Ardabil using geostatistics. *Water and Soil*, 28(6), 1271-1283. <https://doi.org/10.22067/jsw.v0i0.33460>
- Asghari, Sh., Alimohammadi, M., Ahmadi, A., & Davatgar, N. (2017). Derivation of pedotransfer functions for estimating wet aggregate stability using fractal dimensions of particles and aggregates. *Water and Soil Science*, 27(1), 107-119.
- Asghari, Sh., Hatamvand, M., & Hasanzadeh Kashani, M. (2021). Estimating wet aggregates stability from easily available soil properties in north west of Urmia Lake. *Applied Soil Research*, 9(2), 102-115. (In Persian with English abstract)
- Bhattacharya, P., Maity, P.P., Ray, M., & Mridha, N. (2021). Prediction of mean weight diameter of soil using machine learning approaches. *Agronomy Journal*, 113(2), 1303–1316. <https://doi.org/10.1002/agj2.20469>
- 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.

10. Ferreira, C. (2001). Gene expression programming: a new adaptive algorithm for solving problems. *Complex Systematic*, 13, 87–129. <https://doi.org/10.48550/arXiv.cs/0102027>
11. 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>
12. 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.
13. Kemper, W.D., & Rosenau, K. (1986). *Size distribution of aggregates*. p. 425–442. In: Klute A. (ed). Methods of Soil Analysis Part 1, Physical and Mineralogical Methods. 2nd ed. ASA and SSSA, Madison, WI.
14. 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.
15. Marashi, M., Mohammadi Torkashvand, A., Ahmadi, A., & Esfandyari, M. (2019). Adaptive neurofuzzy inference system: estimation of soil aggregates stability. *Acta Ecologica Sinica*, 39, 95–101. <https://doi.org/10.1016/j.chnaes.2018.05.002>
16. 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.
17. Page, A.L. (ed.). (1985). *Methods of Soil Analysis. Part 2. Chemical and Microbiological Methods*. Agronomy No. 9. American Society of Agronomy, Madison, WI.
18. Sarkar, A., Maity, P.P., Ray, M., Chakraborty, D., Das, B., & Bhatia, A. (2023). Inclusion of fractal dimension in four machine learning algorithms improves the prediction accuracy of mean weight diameter of soil. *Ecological Informatics*. 74, 1–15. <https://doi.org/10.1016/j.ecoinf.2022.101959>
19. Shirazi, M.A., & Boersma, L. (1984). A unifying quantitative analysis of soil texture. *Soil Science Society American Journal*, 48(1), 142–147.
20. 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)
21. 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.
22. 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>