

Prediction of the Strength Characteristics of Limestones in the Sanandaj – Sirjan Zone Using Statistical Methods and Neural Network

Mojtaba Rahimi Shahid¹, Gholam Reza Lashkaripour^{2*}, Naser Hafezi Moghaddas³

1. Ph.D. candidate in Engineering Geology, Department of Geology, Faculty of Sciences, Ferdowsi University of Mashhad, Mashhad, Iran. E-mail: Mr619htt@gmail.com

2. Professor in Engineering Geology, Department of Geology, Faculty of Sciences, Ferdowsi University of Mashhad, Mashhad, Iran. E-mail: Lashkaripour@um.ac.ir

3. Professor in Engineering Geology, Department of Geology, Faculty of Sciences, Ferdowsi University of Mashhad, Mashhad, Iran. E-mail: Nhafezi@um.ac.ir

Article Info

Article type:

Research Article

Article history:

Received 6 July 2025

Accepted 3 September 2025

Keywords:

Multi Layer Perceptron, Engineering Geological Characteristics, Regression, Point load index, Uniaxial compressive strength.

ABSTRACT

The Sanandaj–Sirjan Structural-Sedimentary Zone is one of the most important geological regions in Iran. The limestone formations in this area play a key role in civil engineering and mining projects. Knowing the precise mechanical properties of these rocks, especially the uniaxial compressive strength (UCS dry) and dry point load index (Is_{50} -dry), is essential for safely and economically designing structures. Because direct testing methods are costly and time-consuming, this study uses indirect modeling techniques, such as regression and neural networks, to predict these properties. First, a comprehensive database was compiled by collecting the physical, mechanical, dynamic, and chemical data of limestone samples from the region. Then, univariate, bivariate, and multivariate regression analyses were conducted to extract statistical relationships among the variables. Finally, multilayer perceptron neural network models with various architectures based on the Levenberg–Marquardt learning algorithm were developed. The comparison results of the model performance indicated that neural networks, due to their ability to identify complex and nonlinear relationships between parameters, provide more accurate predictions of the limestone mechanical properties compared to statistical models. A comparison of the correlation coefficients of multivariate regression equations and neural network models showed that, overall, using neural network models improves the accuracy of UCS Dry predictions by 14.89% and the Is_{50} -Dry predictions by 4.70%. The results show that predicting UCS Dry in the presence of Is_{50} -Dry among the input parameters has a significant impact on improving the accuracy of the models. For example, the model with the inputs Is_{50} -Dry, SH, γ Dry and n showed very good performance. For predicting Is_{50} -Dry, the models that included the parameters SDI1 and BI Dry as inputs also performed very well. The application of these models can contribute to cost reduction, increased speed of rock engineering studies, and improved safety in civil projects.

Introduction

The Sanandaj-Sirjan structural-sedimentary zone is one of the most important geological regions in Iran, characterized by significant lithological and structural diversity. Limestones, one of the main sedimentary formations in this zone, play an important role in civil engineering and mining projects. Accurate knowledge of the strength properties of limestone, including its

uniaxial compressive strength and point load index, is essential for designing stable and safe design of engineering structures such as tunnels, dams, foundations and mines. However, directly testing the strength properties of rocks in a laboratory tests has always been a major challenge in rock engineering due to the cost, need for advanced equipment required and time-consuming nature of the process.

Cite this article: Rahimi Shahid, M., Lashkaripour, G. R., Hafezi Moghaddas, N. (2025). Prediction of the Strength Characteristics of Limestones in the Sanandaj – Sirjan Zone Using Statistical Methods and Neural Network. Journal of Engineering Geology, 19 (2), 290-327. <https://doi.org/10.22034/JEG.2025.19.2.1018062>

An artificial neural network is a computational model based on structure and function of the biological neural networks found in the human brain. The goal of these models aim to simulate the human learning process for analyzing, classifying or predicting data. Each neural network consists of a number of simple processing units or artificial neurons that are connected in layers. These layers include an input layer, one or more hidden layers, and an output layer. Raw data enters the network in the input layer. The neurons in the hidden layers then process and extract important patterns from this information. The output layer presents the processing results, which can be a classification, a numerical value, or another type of output. This study aims to develop models and relationships for predicting the strength properties of limestones in the Sanandaj-Sirjan zone. These properties include dry uniaxial compressive strength and dry point load index. The models are based on the physical, dynamic, and mechanical properties of samples taken from this area. To this end, a comprehensive database of the various engineering and geological properties of limestone in the Sanandaj-Sirjan region was compiled from various sources. For this purpose, a comprehensive database of various engineering geological properties of limestones in the Sanandaj - Sirjan zone was prepared by studying various sources. These properties include relative specific gravity, porosity percentage, dry and saturated specific gravity, slake durability index for the first to fifth cycles, water absorption percentage, Los Angeles abrasion percentage, aggregate impact values percentage, dry and saturated uniaxial compressive strength, dry and saturated Brazilian tensile strength, dry and saturated point load index, dry and saturated brittleness index, static Young's modulus, direct shear strength, cohesion, internal friction angle, dry and saturated pressure wave velocity, dynamic Young's modulus, dynamic Poisson's ratio, schmidt hammer number, calcimetry percentage, and dissolution rate constant at pH= 6.5-7, pH=

7-7.5, and pH= 7.5-8. The collected data were first analyzed using statistical methods and univariate and multivariate regression relationships between variables were extracted. Then, dry uniaxial compressive strength and dry point load index prediction models were created and optimized using a multilayer perceptron (MLP) neural network and the Levenberg-Marquardt learning algorithm.

Materials and Methods

The Sanandaj-Sirjan Zone is a metamorphic-igneous unit trending northwest-southeast located on the northeastern margin of the Zagros Mountains. It is a belt of metamorphic rocks of Paleozoic to Cenozoic age, mainly consisting of Cretaceous intrusive masses. Numerous tectonic events have caused the formation of a series of strike-slip faults and large thrusts in the region. Important rock units in this region include metamorphic limestone, slate, schist, and amphibolite. This study investigated the relationship between the engineering geology properties and strength properties of limestones in the Sanandaj-Sirjan structural-sedimentary zone. To do so, various engineering geology properties of these types of rocks were extracted from different sources. The extracted engineering geological properties include physical properties (relative specific gravity (Gs), porosity percentage (n), dry and saturated specific gravity (γ), slake durability index (SDI) for the first to fifth cycles, water absorption value percentage (WA), Los Angeles abrasion percentage (LA), and aggregate impact values percentage (AIV)), mechanical properties (dry and saturated uniaxial compressive strength (UCS), dry and saturated Brazilian tensile strength (BTS), point load index (Is_{50}) for dry and saturated conditions, brittleness index (BI) dry and saturated, static Young's modulus, direct shear strength, cohesion, and internal friction angle), dynamic properties (dry and saturated pressure wave velocity (V_p), dynamic Young's modulus, dynamic Poisson's ratio, and Schmidt Hammer number (SH)); and chemical properties

(calcimetry percentage and dissolution rate constant at pH= 6.5-7, pH= 7-7.5 and pH= 7.5-8). After data collection, the preprocessing stage included the removal of incomplete data, normalization of values to standardize the scale of features, and initial correlation analysis between parameters. This stage helped identify key features affecting the model response and prevented the entry of outliers and ineffective data into the models.

Next, univariate and multivariate regression were used to model the relationships between the variables. After examining various regression equations, the most valid relationships were presented, including those between dry uniaxial compressive strength (UCS_{Dry}) and dry point load index (Is_{50-Dry}) as dependent variables.

Next, an artificial neural network was used to increase the prediction accuracy and examine nonlinear relationships. Finally, the results obtained from the two regression and neural network methods were compared with each other to determine the optimal model in predicting strength properties. For this purpose, the correlation coefficient of regression equations and neural network models was compared and the measured and predicted values of regression equations and neural network

models were compared using Boxplot diagrams. In this study, ArcGIS 10.7 (geological map of the study area), STATISTICA and IBM SPSS 22 (statistical analyses and regression equations) and MATLAB R2024a (neural network models) software were used.

Results and Discussion

After removing outliers, the prediction of strength properties including UCS, BTS and Is_{50} was performed using univariate regression and based on other properties. For this purpose, the univariate regression equations for predicting UCS_{Dry} and Is_{50-Dry} are presented in Figure (1). Due to data limitations or low accuracy of some relationships, other equations for strength properties and other properties were not examined. Based on statistical analyses and examination of the presented graphs, it can be concluded that the prediction of UCS_{Dry} has higher accuracy and validity when made using the porosity percentage, first cycle durability-deflection index, water absorption percentage and dry point load index. On the other hand, the prediction of Is_{50-Dry} , when using the dry brittleness index and Schmidt hammer number, will lead to the most accurate estimate possible (Figure 1).




Fig. 1. Univariate regression equation for UCS_{Dry} with (a) n, (b) Dry Specific Weight, (c) SDI - 1, (d) Water Absorption, (e) Is_{50-Dry}, (f) Dry P Wave Velocity, (g) Schmidt Hammer and the univariate regression equation of the Is_{50-Dry} with (h) n, (i) SDI - 1, (j) Water Absorption, (k) BI - Dry, (l) Dry P Wave Velocity and (m) Schmidt Hammer

Table 1 presents bivariate linear regression equations for predicting UCS_{Dry}. Of the examined models, the one with the highest correlation coefficient ($R^2 = 0.904$) is the combination of Is_{50-Dry} and the first cycle durability-deflection index. This indicates that these two variables are key and reliable in

estimating UCS_{Dry}. The acceptable accuracy of most models ($R^2 > 0.75$) suggests that using a combination of two independent variables can provide a suitable estimate of UCS_{dry}, reducing the need for destructive testing and saving time and money on engineering projects.

Table 1. Bivariate regression equations for predicting UCS_{Dry}

Regression equation	R^2
UCS - Dry = 38.5408+2.5608* γ_d -4.4504*n	0.7695
UCS - Dry = -4515.6275+46.3942*SDI 1+0.992*n	0.7271
UCS - Dry = 112.1143+0.3968*WA-5.0763*n	0.7306
UCS - Dry = 50.5727+11.6236* Is -50 dry -2.342*n	0.846
UCS - Dry = 32.7518+10.199*Vp-2.861*n	0.8015
UCS - Dry = -15.8227+2.4705*SH-1.8038*n	0.689
UCS - Dry = -3080.4912+30.9535*SDI 1+3.746* γ_d	0.8156
UCS - Dry = 66.3492-10.051*WA+1.4972* γ_d	0.7368
UCS - Dry= -83.3759+9.1415* Is -50 dry +5.269* γ_d	0.7921
UCS - Dry= -223.7+6.0615*Vp+10.6621* γ_d	0.7576
UCS - Dry = -113.0257+2.5557*SH+3.4453* γ_d	0.7513

UCS - Dry = $-4309.0517 + 1.8475 \cdot WA + 44.3315 \cdot SDI\ 1$	0.7057
UCS - Dry = $-1391.569 + 15.0762 \cdot Is\ -50\ dry + 14.3316 \cdot SDI\ 1$	0.904
UCS - Dry = $-2606.6519 + 5.7179 \cdot Vp + 26.829 \cdot SDI\ 1$	0.7428
UCS - Dry = $-1241.239 + 2.9837 \cdot SH + 12.0997 \cdot SDI\ 1$	0.8611
UCS - Dry = $54.1062 + 11.2115 \cdot Is\ -50\ dry - 4.9587 \cdot WA$	0.8747
UCS - Dry = $46.9396 + 8.841 \cdot Vp - 5.5358 \cdot WA$	0.8225
UCS - Dry = $-26.0932 + 2.7775 \cdot SH - 3.7948 \cdot WA$	0.7889
UCS - Dry = $-14.1437 + 10.9504 \cdot Vp + 9.2701 \cdot Is\ -50\ dry$	0.7116
UCS - Dry = $-28.3647 + 1.4058 \cdot SH + 12.7173 \cdot Is\ -50\ dry$	0.7851
UCS - Dry = $-71.8693 + 1.2966 \cdot SH + 16.2343 \cdot Vp$	0.6209

The results show that bivariate regression equations can be used to predict $Is\ 50\text{-}Dry$ with acceptable accuracy, especially when two independent variables are combined (Table 2). Among these equations, those with first cycle durability-deflection index and either Schmidt hammer number or dry brittleness index as

inputs perform better, showing a higher correlation coefficient (R^2). For instance, the regression equation with first cycle durability-deflection index and Schmidt hammer number ($R^2 = 0.8445$) best fits the data, indicating high prediction accuracy.

Table 2. Bivariate regression equations for predicting $Is\ 50\text{-}Dry$

Regression equation	R^2
$Is\text{-}50\text{-}Dry = -49.8074 + 0.5499 \cdot SDI\ 1 - 0.1899 \cdot n$	0.7196
$Is\text{-}50\text{-}Dry = 5.6589 + 0.6183 \cdot WA - 0.5616 \cdot n$	0.6317
$Is\text{-}50\text{-}Dry = -11.2301 + 6.0954 \cdot BI\ dry - 0.1494 \cdot n$	0.6403
$Is\text{-}50\text{-}Dry = -3.3697 + 1.5316 \cdot Vp - 0.0162 \cdot n$	0.6411
$Is\text{-}50\text{-}Dry = -1.6533 + 0.1496 \cdot SH - 0.1038 \cdot n$	0.6862
$Is\text{-}50\text{-}Dry = -36.5192 - 0.394 \cdot WA + 0.4156 \cdot SDI\ 1$	0.681
$Is\text{-}50\text{-}Dry = -12.8405 + 10.9682 \cdot BI\ dry - 0.1293 \cdot SDI\ 1$	0.8183
$Is\text{-}50\text{-}Dry = -113.4865 + 0.4119 \cdot Vp + 1.1587 \cdot SDI\ 1$	0.617
$Is\text{-}50\text{-}Dry = -16.1767 + 0.1537 \cdot SH + 0.1338 \cdot SDI\ 1$	0.8445
$Is\text{-}50\text{-}Dry = -12.6898 + 6.5721 \cdot BI\ dry - 0.2874 \cdot WA$	0.6421
$Is\text{-}50\text{-}Dry = -2.1961 + 1.3032 \cdot Vp - 0.0676 \cdot WA$	0.6352
$Is\text{-}50\text{-}Dry = -2.3387 + 0.1595 \cdot SH - 0.1482 \cdot WA$	0.6864
$Is\text{-}50\text{-}Dry = -17.8276 + 0.7884 \cdot Vp + 6.6247 \cdot BI\ dry$	0.4572
$Is\text{-}50\text{-}Dry = -17.2769 + 0.1129 \cdot SH + 6.1874 \cdot BI\ dry$	0.5961
$Is\text{-}50\text{-}Dry = -4.8271 + 0.0192 \cdot SH + 1.5807 \cdot Vp$	0.503

In Table (3), regression equations for predicting UCS_{Dry} and $Is\ 50\text{-}Dry$ using a combination of independent variables are presented. All models have very high statistical significance values (P Value < 0.05), which indicates the validity and strength of the established relationships. For all equations, the correlation coefficient (R^2) values are often high, indicating the power of the equations to explain a significant percentage of the changes in the dependent variable. In predicting UCS_{Dry} , equations that use $Is\ 50\text{-}Dry$ and

the first cycle durability-deterioration index along with other variables have had higher accuracy; in particular, the regression that includes $Is\ 50\text{-}Dry$ and the first cycle durability-deterioration index and porosity ($R^2 = 0.9660$) has shown the best performance in predicting this parameter. Also, several equations have been proposed for predicting $Is\ 50\text{-}Dry$, in which a combination of different variables is generally seen with a high correlation coefficient ($R^2 > 0.90$), which indicates the high quality of

these equations in predicting Is_{50-Dry} . In general, the use of a combination of several effective variables has increased the accuracy of the predicted regression. Due to the high values of

the coefficient of determination and statistical significance of the equations, these relationships can be used as reliable tools in geological and rock engineering studies.

Table 3. Multivariate regression equations predicting UCS_{Dry} and Is_{50-Dry}

Regression equation	P Value	R ²
$UCS_{dry} = 69.3 - 1.58n + 1.39\gamma_{dry} - 6.65WA$	0.0000	0.7374
$UCS_{dry} = 100.95 - 3.74n - 1.22\gamma_{dry} + 7.6Is_{50-dry}$	0.0000	0.8577
$UCS_{dry} = -8.32 - 2.33n + 1.02\gamma_{dry} + 1.77SH$	0.0000	0.7643
$UCS_{dry} = -2381.18 + 2.41n + 24.03SDI\ 1 + 19.26Is_{50-dry}$	0.0000	0.9660
$UCS_{dry} = 52.87 + 0.45n - 5.7WA + 11.39Is_{50-dry}$	0.0000	0.8749
$UCS_{dry} = -34.54 + 1.64n - 6.67WA + 2.93SH$	0.0000	0.7895
$UCS_{dry} = 7.13 - 1.37n + 10.76Is_{50-dry} + 0.97SH$	0.0000	0.8464
$UCS_{dry} = 106.5 + 1.96n - 1.39\gamma_{dry} - 12.77WA + 7.3Is_{50-dry}$	0.0000	0.8692
$UCS_{dry} = 38.76 - 3.62n + 0.76\gamma_{dry} + 0.18WA + 0.97SH$	0.0000	0.7531
$UCS_{dry} = 82.73 - 2.93n - 2.24\gamma_{dry} + 76Is_{50-dry} + 0.93SH$	0.0000	0.8893
$Is_{50-dry} = -94.27 - 0.78n + 0.99SDI\ 1 + 1.32WA$	0.0000	0.7634
$Is_{50-dry} = 69.21 - 0.06n - 0.98SDI\ 1 + 12.25BI\ dry$	0.0000	0.9371
$Is_{50-dry} = -21.37 + 0.05n + 0.17SDI\ 1 + 0.18SH$	0.0000	0.904
$Is_{50-dry} = -13.95 - 0.7n + 1.16WA + 7.1BI\ dry$	0.0000	0.6943
$Is_{50-dry} = -0.34 - 0.38n + 0.52WA + 0.12SH$	0.0000	0.7
$Is_{50-dry} = -7.06 - 0.07n + 2.2BI\ dry + 0.13SH$	0.0000	0.7
$Is_{50-dry} = 44.64 - 0.23n - 0.73SDI + 0.37WA + 11.96BI\ dry$	0.0000	0.9372
$Is_{50-dry} = -46.96 - 0.15n + 0.43SDI + 0.43WA + 0.18SH$	0.0000	0.9032
$Is_{50-dry} = 49.74 - 0.018n - 0.74SDI + 9.44BI\ dry + 0.05SH$	0.0000	0.9556
$Is_{50-dry} = 29.29 - 0.13n - 0.53SDI + 0.28WA + 9.38BI\ dry + 0.05SH$	0.0000	0.957

This study evaluated various artificial neural network (MLP) models for predicting UCS_{Dry} and Is_{50-Dry} using different combinations of input parameters. Table 4 summarizes the parameters of the neural network models designed for this purpose. All models used the Tansig activation function in the hidden layers and the Purelin function in the output layer, a suitable choice for regression problems. Regarding the prediction of UCS_{Dry} , the presence of Is_{50-Dry} among the input parameters was found to significantly impact the accuracy of the models. For example, the model with inputs Is_{50-Dry} , SH , γ_{Dry} and n and the MLP

network structure 2-2-2-1 was able to show very good performance with an overall correlation coefficient $R^2=0.96$. For the prediction of Is_{50-Dry} , the models that included the $SDI1$ and BI_{Dry} parameters as inputs also performed very well. In particular, the model with BI_{Dry} , $SDI1$ and n inputs and the MLP 3-3-1 structure provided one of the best results with an overall correlation coefficient of $R^2=0.99$. This emphasizes that the petrological characteristics and indices related to the internal structure of the samples play a decisive role in the correct estimation of the strength.

Table 4. Summary of various parameters of neural network models designed to predict UCS_{Dry} and Is_{50-Dry}

Target	Input	Net name	R ²				Hidden activation	Output activation
			Training	Validation	Test	All		
UCS _{dry}	n, γ_{dry} , WA	MLP 3-3-1	0.75	0.96	0.52	0.75	Tansig	Purelin
	n, γ_{dry} , Is _{50-dry}	MLP 4-4-1	0.91	0.84	0.78	0.89	Tansig	Purelin
	n, γ_{dry} , SH	MLP 6-6-6-1	0.79	0.98	0.68	0.80	Tansig	Purelin
	n, SDI 1, Is _{50-dry}	MLP 4-4-1	1	1	1	1	Tansig	Purelin
	n, WA, Is _{50-dry}	MLP 6-6-1	0.88	0.99	0.92	0.90	Tansig	Purelin
	n, WA, SH	MLP 4-4-4-1	0.85	0.98	0.91	0.87	Tansig	Purelin
	n, SH, Is _{50-dry}	MLP 4-4-4-1	0.83	0.97	0.82	0.86	Tansig	Purelin
	n, γ_{dry} , WA, Is _{50-dry}	MLP 14-14-1	0.99	0.98	0.46	0.90	Tansig	Purelin
	n, γ_{dry} , WA, SH	MLP 4-4-4-1	0.82	0.86	0.87	0.81	Tansig	Purelin
	n, γ_{dry} , SH, Is _{50-dry}	MLP 2-2-2-1	0.98	0.98	0.82	0.96	Tansig	Purelin
Is _{50-dry}	n, SDI 1, WA	MLP 6-6-1	0.93	0.87	0.87	0.91	Tansig	Purelin
	n, SDI 1, BI dry	MLP 3-3-1	0.99	0.98	0.98	0.99	Tansig	Purelin
	n, SDI 1, SH	MLP 2-2-1	0.97	0.99	0.92	0.97	Tansig	Purelin
	n, BI dry, WA	MLP 13-13-1	0.79	0.53	0.80	0.77	Tansig	Purelin
	n, SH, WA	MLP 9-9-1	0.82	0.75	0.43	0.76	Tansig	Purelin
	n, BI dry, SH	MLP 8-8-1	0.79	0.80	0.86	0.80	Tansig	Purelin
	n, SDI 1, WA, BI dry	MLP 5-5-1	0.99	0.98	0.99	0.99	Tansig	Purelin
	n, SDI 1, WA, SH	MLP 3-3-1	0.95	0.99	0.94	0.96	Tansig	Purelin
	n, SDI 1, BI dry, SH	MLP 3-3-1	0.98	0.99	0.99	0.98	Tansig	Purelin
	n, SDI 1, WA, BI dry, SH	MLP 4-4-1	0.98	0.99	0.98	0.98	Tansig	Purelin

In order to compare the accuracy of the presented regression equations with each other and with the neural network models, the correlation coefficient values of the relationships in Figure (2) are compared. The results show that in most cases the neural network models of UCS_{Dry} prediction perform significantly better and provide higher R² values than the other models.

Multivariate regression also performs better than the simpler models (univariate and bivariate) and the univariate models have the lowest accuracy. The general trend is the same for the Is_{50-Dry} prediction models, but the accuracy of the models is slightly lower than that of the UCS_{Dry} prediction models (Figure 2).




Fig. 2. Comparison of the correlation coefficient of regression equations and neural network models for (a) UCS Dry and (b) Is 50-Dry

Conclusions

This study found that predicting UCS Dry and Is 50-Dry of limestones in the Sanandaj-Sirjan zone using only one or two variables does not provide very high accuracy. Multivariate regression models that combine physical, mechanical, dynamic, and chemical properties, however, perform better and show greater agreement with the measured values.

The best results in terms of model accuracy and stability, however, belong to neural

networks (MLP). These models can identify and model the complex, nonlinear relationships between input properties and rock strength with high accuracy and low error dispersion. A comparison of the correlation coefficients between the statistical models and the neural networks revealed that the prediction accuracy of UCS Dry increased by 14.89%, while the prediction accuracy of Is 50-Dry increased by 4.70%, when using neural networks instead of multivariate regression equations. In summary,

the neural network method is a more powerful tool than classical statistical models for predicting the strength properties of rocks, especially in situations where the relationships

between variables are complex and nonlinear. It can have many applications in rock engineering projects.



پیش‌بینی خواص مقاومتی سنگ آهک‌های زون سنندج - سیرجان با استفاده از روش‌های آماری و شبکه عصبی

مجتبی رحیمی شهید^۱، غلامرضا لشکری پور^۲، ناصر حافظی مقدس^۳

۱. دانشجوی دکتری زمین‌شناسی مهندسی، گروه زمین‌شناسی، دانشکده علوم، دانشگاه فردوسی مشهد، مشهد، ایران. رایانامه: Mr619htt@gmail.com

۲. استاد زمین‌شناسی مهندسی، گروه زمین‌شناسی، دانشکده علوم، دانشگاه فردوسی مشهد، مشهد، ایران. رایانامه: Lashkaripour@um.ac.ir

۳. استاد زمین‌شناسی مهندسی، گروه زمین‌شناسی، دانشکده علوم، دانشگاه فردوسی مشهد، مشهد، ایران. رایانامه: Nhafezi@um.ac.ir

اطلاعات مقاله چکیده

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۴/۰۴/۱۵

تاریخ پذیرش: ۱۴۰۴/۰۶/۱۲

کلیدواژه‌ها:

پرسپترون چند لایه، خواص زمین‌شناسی مهندسی، رگرسیون، شاخص بار نقطه‌ای، مقاومت فشاری تک‌محوری.

زون ساختاری - رسوبی سنندج - سیرجان یکی از مهم‌ترین مناطق زمین‌شناسی ایران است که سنگ‌آهک‌های موجود در آن نقش کلیدی در پروژه‌های عمرانی و معدنی ایفا می‌کنند. شناخت دقیق خواص مقاومتی این سنگ‌ها، به‌ویژه مقاومت فشاری تک‌محوری خشک (UCS_{Dry}) و شاخص بار نقطه‌ای خشک (Is_{50-Dry})، به‌منظور طراحی ایمن و اقتصادی سازه‌ها بسیار ضروری است. با توجه به هزینه و زمان‌بر بودن آزمایش‌های مستقیم، در این پژوهش از روش‌های غیرمستقیم مدل‌سازی شامل رگرسیون و شبکه عصبی برای پیش‌بینی این خواص استفاده شده است. ابتدا با گردآوری داده‌های فیزیکی، مکانیکی، دینامیکی و شیمیایی نمونه‌های سنگ‌آهک منطقه، بانک اطلاعات جامعی تهیه شد. سپس با استفاده از تحلیل رگرسیون تک متغیره، دومتغیره و چند متغیره، روابط آماری بین متغیرها استخراج شد. در ادامه، مدل‌های شبکه عصبی پرسپترون چندلایه با ساختارهای مختلف و بر پایه الگوریتم یادگیری Levenberg-Marquardt توسعه یافتند. نتایج حاصل از مقایسه عملکرد مدل‌ها نشان داد که شبکه‌ی عصبی به دلیل توانایی در شناسایی روابط پیچیده و غیرخطی بین پارامترها، در پیش‌بینی خواص مقاومتی سنگ‌آهک‌ها عملکرد دقیق‌تری نسبت به مدل‌های آماری ارائه می‌دهد. مقایسه‌ی ضریب هم‌بستگی معادله‌های رگرسیون چند متغیره و مدل‌های شبکه عصبی نشان می‌دهند که به‌طور کلی استفاده از مدل‌های شبکه عصبی پیش‌بینی مقاومت فشاری تک‌محوری خشک، ۱۴/۸۹ درصد و مدل‌های شبکه عصبی پیش‌بینی شاخص بار نقطه‌ای خشک، ۴/۷۰ درصد میزان دقت نتایج (ضریب هم‌بستگی) را افزایش می‌دهند. نتایج نشان می‌دهد که پیش‌بینی UCS_{Dry} در حضور Is_{50-Dry} در میان پارامترهای ورودی تأثیر بسزایی در بهبود دقت مدل‌ها دارد. به‌عنوان نمونه، مدل با ورودی‌های Is_{50-Dry} ، SH ، Is_{50-Dry} و γ عملکرد بسیار خوبی از خود نشان دهد. برای پیش‌بینی Is_{50-Dry} نیز، مدل‌هایی که شامل پارامترهای $SDI1$ و BI_{Dry} به‌عنوان ورودی بودند، عملکرد بسیار مطلوبی داشتند. استفاده از این مدل‌ها می‌تواند در کاهش هزینه‌ها، افزایش سرعت مطالعات مهندسی سنگ و بهبود ایمنی پروژه‌های عمرانی مؤثر باشد.

مقدمه

در پروژه‌های عمرانی و معدنی ایفا می‌کنند. شناخت دقیق خواص مقاومتی سنگ‌آهک‌ها، از جمله مقاومت فشاری تک‌محوری و شاخص بار نقطه‌ای، برای طراحی پایدار و ایمن سازه‌های مهندسی همچون تونل‌ها، سدها، پی‌ها و معادن

زون ساختاری - رسوبی سنندج - سیرجان یکی از مهم‌ترین مناطق زمین‌شناسی ایران است که دارای تنوع سنگ‌شناسی و ساختاری قابل توجهی است. در این زون، سنگ‌آهک‌ها به‌عنوان یکی از اصلی‌ترین سازندهای رسوبی، نقش مهمی

ضروری است. با این حال، تعیین خواص مقاومتی سنگ‌ها از طریق آزمایش‌های مستقیم آزمایشگاهی، به دلیل هزینه‌بر بودن، نیاز به تجهیزات پیشرفته و زمان‌بر بودن، همواره چالشی مهم در مهندسی سنگ بوده است.

در سال‌های اخیر، استفاده از روش‌های غیرمستقیم و مدل‌سازی پیش‌بینی خواص مقاومتی سنگ‌ها با بهره‌گیری از روش‌های آماری و هوش مصنوعی، به ویژه شبکه‌ی عصبی (Neural Network)، مورد توجه پژوهشگران قرار گرفته است. این روش‌ها به دلیل توانایی مدل‌سازی روابط پیچیده و غیرخطی بین خواص مختلف سنگ و خواص مقاومتی، امکان پیش‌بینی دقیق‌تر و سریع‌تر را فراهم می‌کنند. روش‌های آماری کلاسیک، مانند تحلیل رگرسیون و تحلیل همبستگی، ابزارهای مناسبی برای درک اولیه و ساده‌تر روابط بین خواص محسوب می‌شوند؛ اما شبکه‌ی عصبی به دلیل ساختار یادگیری و قابلیت تطبیق با داده‌های گسترده، می‌تواند دقت بالاتری در پیش‌بینی ارائه دهد. کاربرد این مدل‌های پیش‌بینی در مناطق مشابه که امکان نمونه‌برداری و انجام آزمایش‌های گسترده وجود ندارد، بسیار ارزشمند است. به این ترتیب، مهندسان و طراحان پروژه‌های عمرانی و معدنی می‌توانند با استفاده از اطلاعات حداقلی و مدل‌های توسعه یافته، تخمین‌های قابل اتکایی از رفتار مکانیکی سنگ‌آهک‌ها داشته باشند. این امر منجر به کاهش هزینه‌ها، صرفه‌جویی در زمان و افزایش ایمنی و کیفیت طراحی‌ها می‌شود. همچنین، مدل‌های ارائه شده می‌توانند به توسعه پایدار مدیریت منابع معدنی و کاهش آسیب‌های زیست‌محیطی ناشی از فعالیت‌های عمرانی کمک کنند. در نهایت، استفاده هم‌زمان از روش‌های آماری و شبکه‌ی عصبی به‌عنوان یک رویکرد ترکیبی، فرصت مناسبی برای بهره‌گیری از مزایای هر دو روش فراهم می‌آورد.

شبکه عصبی مصنوعی، مدلی محاسباتی است که از ساختار و کارکرد شبکه‌های عصبی زیستی در مغز انسان الهام گرفته

شده است. هدف این مدل‌ها شبیه‌سازی فرایند یادگیری انسان برای تحلیل، طبقه‌بندی یا پیش‌بینی داده‌هاست. هر شبکه عصبی از تعدادی واحد پردازشی ساده به نام نورون مصنوعی تشکیل می‌شود که به‌صورت لایه‌ای به هم متصل شده‌اند. این لایه‌ها شامل لایه ورودی، تعدادی لایه پنهان و یک لایه خروجی هستند. در لایه ورودی، داده‌های خام وارد شبکه می‌شوند. این داده‌ها به‌صورت سیگنال‌هایی به نورون‌های لایه‌های پنهان ارسال می‌شوند که وظیفه پردازش و استخراج الگوهای مهم از اطلاعات را بر عهده دارند. در نهایت، نتایج پردازش در لایه خروجی ارائه می‌شود که می‌تواند به‌صورت یک دسته‌بندی، یک مقدار عددی یا هر نوع خروجی دیگری باشد. یادگیری در شبکه‌های عصبی از طریق تنظیم وزن‌های اتصالات بین نورون‌ها انجام می‌شود. ابتدا در مرحله انتشار رو به جلو، داده‌های ورودی با وزن‌های اولیه ترکیب می‌شوند و خروجی اولیه تولید می‌شود. سپس میزان خطا یا تفاوت میان خروجی پیش‌بینی‌شده و خروجی واقعی محاسبه می‌شود. برای کاهش این خطا، شبکه وارد مرحله بازپخش خطا یا پس انتشار می‌شود که طی آن وزن‌ها اصلاح می‌شوند تا شبکه به مرور زمان پیش‌بینی دقیق‌تری انجام دهد. این فرایند بارها تکرار می‌شود تا شبکه به سطح مناسبی از دقت برسد (Aggarwal, 2018).

مرادی و همکاران (Moradi et al., 2022)، عبدالعزیز و همکاران (Abdulaziz et al., 2024)، فدهیل و همکاران (Fadhil et al., 2024) از روش‌های رگرسیون خطی و غیر خطی جهت تعیین مقاومت فشاری تک‌محوری با استفاده از خواص مختلف استفاده کرده‌اند. تقوی و همکاران (Taghavi et al., 2023)، خواجه‌وند (Khajevand, 2023)، خاتی و گروور (Khatti and Grover, 2023)، ابراهیم و همکاران (Ibrahim et al., 2024)، خاتی و گروور (Khatti and Grover, 2024)، شریفی و همکاران (Sharifi et al., 2024)، امیری و همکاران (Amiri et al.,)

از (Pandey, 2023) و پاندی (Koohmishi, 2023) روش‌های رگرسیون خطی و غیر خطی جهت تعیین شاخص بار نقطه‌ای با استفاده از خواص مختلف استفاده کرده‌اند. در جدول‌های (۱) و (۲) نتایج برخی از این مطالعات ارائه شده است.

(2024) و ستایشی‌راد و همکاران (Setayeshirad et al.,) (2025) از روش‌های رگرسیون خطی و غیر خطی و شبکه عصبی جهت تعیین مقاومت فشاری تک‌محوری با استفاده از خواص مختلف استفاده کرده‌اند. رحیمی شهید و همکاران (Rahimi Shahid et al., 2022)، کوه‌میشی

جدول ۱. برخی مطالعات پیشین صورت گرفته جهت پیش‌بینی مقاومت فشاری تک‌محوری و شاخص بار نقطه‌ای با استفاده از روش‌های آماری

Table 1. Some previous studies have been conducted to predict uniaxial compressive strength and point load index using statistical methods

Regression equation	R ²	Reference	Rock type
$UCS_{dry} = -78.94 + 4.61 SH$	0.70	Moradi et al. (2022)	Tuff
$UCS_{dry} = -1021 + 447.4 \gamma_d$	0.41		
$UCS_{dry} = -686 + 4.41 SH + 243 \gamma_d$	0.84		
$UCS_{dry} = -77.85 + 3.79 SH$	0.86		
$UCS_{dry} = -266.7 + 147.7 \gamma_d$	0.86		Sandstone
$UCS_{dry} = -175 + 2.05 SH + 72.6 \gamma_d$	0.89		
$UCS_{dry} = 3.41 + 1.32 SH$	0.68		Marl
$UCS_{dry} = -76.49 + 52.01 \gamma_d$	0.63		
$UCS_{dry} = -37.5 + 0.866 SH + 23.6 \gamma_d$	0.73	Sharifi et al. (2024)	Limestone
$UCS_{dry} = 16.44 Gs + 19.46 \gamma_{dry} - 11.72 \log W.A - 0.99 \log n - 525.37$	0.41		
$UCS_{sat} = 82.02 Gs + 210465.7 \gamma_{sat} - 1.80 \log W.A - 6.03 \log n - 210665.2$	0.48		
$UCS = 14.86 - 0.198 n$	0.74	Abdulaziz et al. (2024)	Carbonate
$UCS = 4.315 + 1.58 SH$	0.91	Fadhil et al. (2024)	Limestone
$UCS = 1.49 SH - 1.95$	0.91		Claystone
$UCS = 1.23 SH + 4.89$	0.92		Sandstone
$I_{s-50-dry} = 7.8 - 0.48 n$	0.84	Rahimi Shahid et al. (2022)	Limestone
$UCS = 0.0048 R + 11.89$	0.93	Taghavi et al. (2023)	Breccia
$UCS = -0.59 VBP + 63.82$	0.63		
$UCS = 0.023 + 0.006 R + 0.168 VBP$	0.89		
$UCS = -71.18 + 18.23 \gamma_{dry} + 2.52 n + 9.67 V_p$	0.53	Khajevand (2023)	Different sedimentary rocks
$UCS = -24.36 + 5.18 \gamma_{dry} + 0.99 n + 4.44 I_{s-50}$	0.63		
$UCS = -87.18 + 29.61 \gamma_{dry} + 2.25 n + 5.34 BTS$	0.80		
$UCS = 1.72 - 4.80 \gamma_{dry} - 0.28 n + 6.36 BPS$	0.77		
$UCS = 21.53 + 22.51 \gamma - 2.03 n - 3.38 WA + 8.68 V_p$	0.92	Setayeshirad et al. (2025)	Carbonate Rocks
$UCS = 18.93 + 14.25 I_{s-50} + 2.86 BTS$	0.91		

R: Specific Resistivity, VBP: Volumetric Block Proportion, BPS: Block Punch Strength

جدول ۲. برخی مطالعات پیشین صورت گرفته جهت پیش‌بینی مقاومت فشاری تک‌محوری با استفاده از روش شبکه عصبی
 Table 2. Some previous studies have been conducted to predict uniaxial compressive strength using neural network methods

Target	Input	Net name	R ²				MSE	Reference
			Training	Validation	Test	All		
UCS dry	GS, n, γ_{dry} , WA	MLP 4-7-1	0.68	0.96	0.51	0.64	-	Sharifi et al. (2024)
UCS sat	GS, n, γ_{sat} , WA	MLP 6-6-1	0.71	0.96	0.99	0.78	-	
UCS dry	BTS dry, $I_{s-50-dry}$, WA, V_p dry, ρ dry	DNN (PCA) 8-6-4-1	-	-	-	-	0.0067	Amiri et al. (2024)
UCS	R, VBP	ANN 2-5-1	0.96	0.99	0.99	0.97	3.59	Taghavi et al. (2023)
UCS	R, VBP	ANFIS	-	-	-	0.99	2.51	
UCS	n, γ_{dry} , V_p	ANN	0.99	0.96	0.95	0.98	2.42	Khajevand (2023)
UCS	n, γ_{dry} , I_{s-50}	ANN	0.95	0.83	0.97	0.94	4.90	
UCS	n, γ_{dry} , BTS	ANN	0.96	0.95	0.77	0.95	4.01	
UCS	n, γ_{dry} , BPS	ANN	0.98	0.92	0.91	0.95	3.61	
UCS	n, γ_{dry} , V_p	ANFIS	-	-	-	0.98	0.36	
UCS	n, γ_{dry} , I_{s-50}	ANFIS	-	-	-	0.98	0.40	
UCS	n, γ_{dry} , BTS	ANFIS	-	-	-	0.98	0.64	
UCS	n, γ_{dry} , BPS	ANFIS	-	-	-	0.98	0.61	
UCS	γ , I_{s-50} , E, V_p , BTS, n	ANN 6-1	-	-	-	0.91	0.26	Setayeshirad et al. (2025)

ρ dry: Dry density, MLP: Multilayer Perceptron, DNN: Deep Neural Network, PCA: Principal Component Analysis, MSE: Mean Squared Error, ANN: Actual Neural Network, ANFIS: Adaptive Neuro Fuzzy Inference System, E: Modulus of Elasticity

شاخص بار نقطه‌ای خشک و اشباع، شاخص شکنندگی خشک و اشباع، مدول یانگ استاتیکی، مقاومت برشی مستقیم، چسبندگی، زاویه‌ی اصطکاک داخلی، سرعت موج فشاری خشک و اشباع، مدول یانگ دینامیک، نسبت پواسون دینامیک، عدد چکش اشمیت، درصد کلسیمتری و ثابت سرعت انحلال در pH= 6.5-7، pH= 7-7.5، و pH= 7.5-8 اشاره کرد. داده‌های گردآوری شده ابتدا با استفاده از روش‌های آماری تحلیل شده و روابط رگرسیونی تک و چند متغیره بین متغیرها استخراج شد. سپس با به‌کارگیری شبکه عصبی چندلایه پرسپترون (MLP) و الگوریتم یادگیری Levenberg-Marquardt، مدل‌های پیش‌بینی مقاومت فشاری تک‌محوری خشک و شاخص بار نقطه‌ای خشک ایجاد و بهینه‌سازی شدند.


پژوهش حاضر با هدف توسعه روابط و مدل‌های پیش‌بینی خواص مقاومتی (مقاومت فشاری تک‌محوری خشک و شاخص بار نقطه‌ای خشک) سنگ‌آهک‌های زون سنندج - سیرجان، بر اساس خواص فیزیکی، دینامیکی و مکانیکی نمونه‌های برداشت شده از این منطقه انجام شده است. بدین منظور با مطالعه‌ی منابع مختلف، یک بانک اطلاعات منسجم از خصوصیات زمین‌شناسی مهندسی مختلف سنگ‌آهک‌های زون سنندج - سیرجان، تهیه شد. از جمله این خصوصیات می‌توان به وزن مخصوص نسبی، درصد تخلخل، وزن مخصوص خشک و اشباع، شاخص دوام - وارفتگی چرخه‌ی اول تا پنجم، درصد جذب آب، درصد سایش لس‌آنجلس، درصد ارزش ضربه‌ای مصالح، مقاومت فشاری تک‌محوری خشک و اشباع، مقاومت کششی برزیلین خشک و اشباع،

مواد و روش‌ها

منطقه مورد مطالعه

زون سنندج - سیرجان به عنوان یک واحد دگرگونی - آذرین با روند شمال غربی - جنوب شرقی، در حاشیه‌ی شمال شرقی زاگرس قرار گرفته است (شکل ۱). این زون نمایانگر کمربندی از سنگ‌های دگرگونی با سن پالئوزوئیک تا سنوزوئیک و توده‌های نفوذی عمدتاً کرتاسه است. رخدادهای زمین‌ساختی متعدد باعث تشکیل مجموعه‌ای از گسل‌های راستالغز و راندگی‌های بزرگ در این زون شده‌اند. سنگ‌های آهکی دگرگون شده، اسلیت، شپست و آمفیبولیت از جمله واحدهای سنگی مهم این منطقه هستند (Stöcklin, 1968). شکل (۱) سازندهای حاوی سنگ‌آهک در زون سنندج - سیرجان را نشان می‌دهد. در این شکل هر واحد سازندی دارای یک نماد است که مربوط به یک سازند یا لایه می‌باشد. این واحدها شامل Com سازند میلا، Cb سازند باروت، Cm سازند مبارک، Cs سازند سردر، Dsh سازند شیشتو، E1l سنگ‌آهک نومولیتی، E1f سنگ‌آهک ماسه‌ای، E1s سنگ‌آهک ماسه‌ای، E2l سنگ‌آهک نومولیتی، E2s و Ef حاوی سنگ‌آهک، Eja سازند جهرم، Jkav میان لایه‌هایی از سنگ‌آهک، Jkbl سنگ‌آهک خاکستری ضخیم لایه اوولیتی، Jkkgp گروه خامی شامل سنگ‌آهک‌های نازک لایه توده‌ای است که سازندهای سورمه، انیدریت هیث، گدوان، فلهیان و داریان را در برمی‌گیرد، Jk1 سنگ‌آهک تبلور یافته، Jbd سازند بادامو، Jf سنگ‌آهک، JI سازند لار، Jq سازند قلعه دختر، Js حاوی سنگ‌آهک، Jsm سازند

سورمه، K1l سنگ‌آهک اوربیتولین‌دار توده‌ای تا ضخیم لایه، K1m سنگ‌آهک رسی، K2l1 سنگ‌آهک هیپریت‌دار، Kpef حاوی سنگ‌آهک، Kbgp گروه بنگستان شامل سازندهای کژدمی، سروک، سورگاه و ایلام، Kda-fa سازند فلهیان و داریان، Kdzsh سازند زنجیر دره، Klsol سنگ‌آهک ماسه‌ای، Klsol سنگ‌آهک اوربیتولین‌دار توده‌ای تا ضخیم لایه، Ksm.1 میان لایه‌هایی از سنگ‌آهک، Ktb سازند تاربور، Ktl سازند تفت، Ktzi سازند تیزکوه، Kupl سنگ‌آهک حاوی گلوبوترنکا، Kurl سنگ‌آهک پلاژیک، Mplfgp گروه فارس شامل سازندهای گچساران، میشان، آقاجاری، Mmn سازند میشان، Omas سازند آسماری، Omq سازند قم، Omql سنگ‌آهک ریفی توده‌ای تا ضخیم لایه، Omr سازند رازک، Omqm میان لایه‌هایی از سنگ‌آهک، Pd سازند درود، Pda سازند دالان، PeEsa سازند ساچون، PeEz سازند زیارت، Pel سنگ‌آهک لایه‌ای، Pj سازند جمال، Pml سنگ‌آهک فوزولین‌دار، Pr سازند روته، Pzkb سنگ‌آهک تبلور مجدد یافته، TRjvm سنگ‌آهک، TRkurl میان لایه‌های سنگ‌آهک نرتیک و پلاژیک، سنگ‌آهک سیاه‌رنگ (عضو حوض خان)، TRdl سنگ‌آهک تبلور یافته، TRe سازند الیکا، TRel سنگ‌آهک آرژلیک، TRkknz سنگ‌آهک رسی نازک لایه (سازند خامه کت و نیریز)، TRml حاوی سنگ‌آهک، TRn سازند نایبند، TRn5 سنگ‌آهک ماسه‌ای، TRuJm سنگ‌آهک کریستالی، Om2 و Om3 سنگ‌آهک پلاژیک، pC-Ch سنگ‌آهک لایه‌ای، PC-Cs سازند سلطانیه، PCr حاوی سنگ‌آهک (سری ریزو) و tm سنگ‌آهک پلاژیک، هستند.



شکل ۱. (a) نقشه زون‌های ساختاری - رسوبی ایران (Stöcklin, 1968) و (b) نقشه واحدهای حاوی سنگ‌آهک در زون ساختاری سنندج - سیرجان

Fig. 1. (a) Map of the structural - sedimentary zones of Iran (Stöcklin, 1968) and (b) Map of stone units containing limestone in the Sanandaj - Sirjan structural zone.

سلیمی (Salimi, 2009)؛ خانلری و عبدی‌لر (Khanlari et al., 2011)

and Abdilor, 2011)؛ خانلری و همکاران (Khanlari et al., 2015)

al., 2015)؛ ناصری (Naseri, 2013)؛ قبادی و امیری

(Ghabadi, 2018)؛ احمدی (Ahmadi, 2006)؛ خانلری و

همکاران (Khanlari et al., 2013)؛ قبادی و ناصری

(Ghobadi and Naseri, 2016)؛ تقی‌زاده (Taghizadeh, 2013)

استخراج شد. خصوصیات زمین‌شناسی مهندسی

روش پژوهش

در این پژوهش، به‌منظور بررسی روابط میان خصوصیات زمین‌شناسی مهندسی با خواص مقاومتی سنگ‌آهک‌های زون ساختاری - رسوبی سنندج - سیرجان، ابتدا خصوصیات زمین‌شناسی مهندسی مختلف این نوع سنگ‌ها با استناد به منابع مختلف شامل: شاهسوار (Shahsavari, 2012)؛ دوستی (Dousti, 2009)؛ کاپله (Kapelehe, 2008)؛

خشک (UCS Dry) و شاخص بار نقطه‌ای خشک (Is 50-Dry) به‌عنوان متغیرهای وابسته ارائه شده است. سایر روابط میان ویژگی‌های مقاومتی و دیگر خواص، به دلیل محدودیت داده‌ها یا دقت پایین نتایج، در این مطالعه مورد بررسی قرار نگرفتند. در ادامه، جهت افزایش دقت پیش‌بینی و بررسی روابط غیرخطی، از شبکه‌ی عصبی مصنوعی استفاده شد. در این مرحله مدل‌های شبکه‌ی عصبی چند لایه پرسپترون (MLP: Multi Layer Perceptron) طراحی و پیاده‌سازی شدند که شامل یک لایه ورودی با ویژگی‌های زمین‌شناسی مهندسی، دو یا سه لایه پنهان با تابع فعال‌سازی Tan sigmoid و یک لایه خروجی با تابع خطی بودند. برای هر مدل داده‌ها به سه بخش آموزش (۷۰ درصد)، اعتبارسنجی (۱۵ درصد) و آزمون (۱۵ درصد) تقسیم شدند و شبکه‌ها با الگوریتم پس انتشار خطا (Backpropagation) و الگوریتم یادگیری Levenberg-Marquardt، آموزش دیدند. عملکرد این مدل‌ها با استفاده از معیارهایی چون خطای جذر میانگین مربعات و مقایسه‌ی مقادیر اندازه‌گیری شده و پیش‌بینی شده ارزیابی شدند. داده‌های ورودی جهت پیش‌بینی مقاومت فشاری تک‌محوری خشک شامل درصد تخلخل، وزن مخصوص خشک، شاخص دوام - وارفنگی چرخه‌ی اول، درصد جذب آب، شاخص بار نقطه‌ای خشک، سرعت موج فشاری خشک، عدد چکش اشمیت هستند. همچنین داده‌های ورودی جهت پیش‌بینی شاخص بار نقطه‌ای خشک شامل درصد تخلخل، شاخص دوام - وارفنگی چرخه‌ی اول، درصد جذب آب، شاخص شکنندگی خشک، سرعت موج فشاری خشک، عدد چکش اشمیت هستند. در پایان، نتایج حاصل از دو روش رگرسیون و شبکه‌ی عصبی یکدیگر مقایسه شدند تا مدل بهینه در پیش‌بینی خواص مقاومتی تعیین شود. بدین منظور مقایسه‌ی ضریب هم‌بستگی معادله‌های رگرسیون و مدل‌های شبکه‌ی عصبی و مقایسه‌ی مقادیر اندازه‌گیری شده و پیش‌بینی شده‌ی

استخراج شده شامل خواص فیزیکی (وزن مخصوص نسبی (Gs)، درصد تخلخل (n)، وزن مخصوص (γ) خشک و اشباع، شاخص دوام - وارفنگی (SDI) چرخه‌ی اول تا پنجم، درصد جذب آب (WA)، درصد سایش لس‌آنجلس (LA)، درصد ارزش ضربه‌ای مصالح (AIV)، خواص مکانیکی (مقاومت فشاری تک‌محوری (UCS) خشک و اشباع، مقاومت کششی برزیلین (BTS) خشک و اشباع، شاخص بار نقطه‌ای (Is 50) خشک و اشباع، شاخص شکنندگی (BI) خشک و اشباع، مدول یانگ استاتیکی، مقاومت برشی مستقیم، چسبندگی، زاویه‌ی اصطکاک داخلی)، خواص دینامیکی (سرعت موج فشاری (Vp) خشک و اشباع، مدول یانگ دینامیک، نسبت پواسون دینامیک، عدد چکش اشمیت (SH)) و خواص شیمیایی (درصد کلسیمتری و ثابت سرعت انحلال در $pH=6.5-7$ ، $pH=7-7.5$ و $pH=7.5-8$) است. پس از جمع‌آوری داده‌ها، مرحله پیش‌پردازش شامل حذف داده‌های ناقص، نرمال‌سازی مقادیر برای یکنواخت‌سازی مقیاس ویژگی‌ها و تحلیل اولیه همبستگی میان پارامترها صورت گرفت. این مرحله به شناسایی ویژگی‌های کلیدی مؤثر بر پاسخ مدل کمک کرده و از ورود داده‌های پرت و ناکارآمد به مدل‌ها جلوگیری کرد. در گام بعد، برای مدل‌سازی روابط میان متغیرها، ابتدا از رگرسیون تک و چند متغیره استفاده شد. در این راستا، معادله‌های رگرسیون خطی و غیرخطی به‌کمک روش حداقل مربعات (OLS) برازش داده شد و روابط میان متغیرهای مستقل (خصوصیات مکانیکی، فیزیکی، دینامیکی و شیمیایی) و متغیر وابسته (خصوصیات مکانیکی) تحلیل گردید. جهت ارزیابی دقت معادله‌ها، از معیارهایی همچون ضریب هم‌بستگی (R^2)، تحلیل باقی‌مانده‌ها، مقایسه‌ی منحنی توزیع نرمال مقادیر اندازه‌گیری شده و پیش‌بینی شده و P Value استفاده شد. پس از بررسی معادلات مختلف رگرسیون، معتبرترین روابط بین خصوصیات مختلف شامل مقاومت فشاری تک‌محوری

جز سنگ‌های با تخلخل پایین و خیلی پایین قرار می‌گیرد و تنها ۲۰ درصد نمونه‌ها تخلخل متوسط و بالا دارند. بر اساس طبقه‌بندی آنون (Anon, 1979) وزن مخصوص خشک (KN/m^3) نمونه‌ها در رده‌ی بالا و خیلی بالا قرار می‌گیرند. میانگین وزن مخصوص اشباع (KN/m^3) نیز ۲۴/۸۸ است. بر اساس تقسیم‌بندی فرانکلین و کاندرا (Franklin and Chandra, 1972) و گامبل (Gamble, 1971) برای تمامی نمونه‌ها چرخه‌ی اول شاخص دوام - وارفتگی در رده‌ی شدیداً مقاوم قرار می‌گیرد. همچنین بیش از ۹۰ درصد نمونه‌ها بر اساس شاخص دوام - وارفتگی چرخه‌ی دوم، در رده‌ی خیلی مقاوم ($\text{SDI-2} > 98\%$) قرار می‌گیرند. میانگین شاخص دوام - وارفتگی چرخه‌ی سوم، ۹۹/۰۲ درصد، چرخه‌ی چهارم، ۹۸/۸۳ درصد و چرخه‌ی پنجم، ۹۷/۳۶ درصد هستند. مقادیر درصد جذب آب ($\text{WA}\%$) نمونه‌ها بر اساس رده‌بندی آنال و آلتونک (Ünal and Altunok, 2019)، در رده‌ی کم قرار می‌گیرند. میانگین سایش لسانجلس ($\text{LA}\%$) بین ۱۹ تا ۳۰ درصد است و جزء سنگ‌های سخت قرار می‌گیرند (Roberts et al., 1996; Wu et al., 1998). ارزش ضربه‌ای مصالح عمدتاً کم‌تر از ۲۰ درصد هستند که بر اساس طبقه‌بندی اف (Of, 2005) در رده‌ی مقاوم و خیلی مقاوم قرار می‌گیرند؛ بنابراین نتایج نشان می‌دهند که سنگ‌آهک‌های مورد مطالعه بر اساس خصوصیات فیزیکی، شرایط نسبتاً مطلوبی دارند

معادله‌های رگرسیون و مدل‌های شبکه‌ی عصبی با استفاده از نمودارهای Boxplot انجام شد. در این پژوهش از نرم‌افزارهای ArcGIS 10.7 (نقشه زمین‌شناسی منطقه مورد مطالعه)، STATISTICA و IBM SPSS 22 (تحلیل‌های آماری و معادله‌های رگرسیون) و MATLAB R2024a (مدل‌های شبکه‌ی عصبی) استفاده شده است.

خصوصیات زمین‌شناسی مهندسی سنگ‌آهک‌های مورد مطالعه

پس از تشکیل بانک اطلاعات خصوصیات زمین‌شناسی مهندسی سنگ‌آهک‌های زون ساختاری - رسوبی سنندج - سیرجان، تحلیل‌های آماری بر روی این خواص انجام شد. در جدول (۳) خلاصه‌ای از شاخص‌های آماری این خصوصیات نمایش داده شده است. در شکل‌های (۲) و (۳) هیستوگرام فراوانی و منحنی توزیع نرمال خصوصیات مختلف زمین‌شناسی مهندسی سنگ‌های مورد مطالعه نمایش داده شده است. در ادامه به توصیف آماری خصوصیات زمین‌شناسی مهندسی سنگ‌آهک‌های بانک اطلاعات ساخته شده، پرداخته می‌شود. شکل‌های (۲) و (۳) نشان می‌دهند که تقریباً برای اکثر خواص، توزیع از نوع نرمال است. بیش از ۷۰ درصد نمونه‌ها وزن مخصوص نسبی (Gs) بیش از ۲/۵ دارند. بر اساس تقسیم‌بندی ریدر (Rider, 2002) سنگ‌های مورد مطالعه با میانگین درصد تخلخل ($\text{n}\%$) ۴/۷۴ درصد

جدول ۳. شاخص‌های آماری خصوصیات زمین‌شناسی مهندسی

Table 3. Statistical indicators of engineering geological characteristics

Variable	Descriptive Statistics				
	Valid N	Mean	Min.	Max.	Std.Dev.
Gs	53	2.57	2.40	2.85	0.09
n (%)	134	4.74	0.24	26.63	6.26
Dry Specific Weight (KN/m^3)	164	25.39	20.40	27.17	1.61
Saturation Specific Weight (KN/m^3)	80	24.88	20.11	27.17	1.57
SDI - 1 (%)	123	99.27	96.63	99.91	0.61
SDI - 2 (%)	83	98.78	94.52	99.82	1.04
SDI - 3 (%)	10	99.02	98.61	99.25	0.23


SDI - 4 (%)	10	98.83	98.30	99.17	0.31
SDI - 5 (%)	16	97.36	89.85	99.61	3.28
Water Absorption (%)	121	1.99	0.08	14.38	3.11
Los Angeles (%)	39	28.17	20.77	46.05	6.83
Aggregate Impact Value (%)	81	10.85	5.97	35.79	6.07
UCS - Dry (MPa)	172	79.83	8.90	142.08	33.17
UCS - Sat (MPa)	68	69.78	12.06	134.05	34.19
BTS - Dry (MPa)	86	11.39	2.35	24.59	5.03
BTS - Sat (MPa)	28	10.36	3.87	12.38	2.52
Is-50 - Dry (MPa)	158	4.26	0.82	9.42	1.85
Is-50 - Sat (MPa)	68	3.12	0.95	5.67	1.35
BI - Dry	172	2.65	2.22	2.85	0.15
BI - Sat	68	2.62	2.26	2.83	0.14
Static Yang Modulus (GPa)	13	12.06	3.47	17.80	4.90
Direct shear strength (MPa)	40	14.04	5.41	18.39	3.40
Cohesion (MPa)	18	1.10	0.09	1.67	0.59
Friction angle (Degree)	18	33.08	26.50	37.50	3.68
P Wave Velocity - Dry (km/s)	114	5.28	2.89	7.93	1.14
P Wave Velocity - Sat (km/s)	28	5.81	3.54	6.84	1.05
Dynamic Yang Modulus (GPa)	28	30.93	9.00	50.11	11.64
Dynamic Poisson Ratio	28	0.49	0.29	0.50	0.04
Schmidt Hammer (SH)	118	45.27	24.00	58.00	7.32
Calcimetry (%)	85	78.96	58.83	95.00	10.59
Solubility - K (m/s), pH= 6.5-7	59	1.87E-05	1.07E-06	6.39E-05	2E-05
Solubility - K (m/s), pH= 7-7.5	59	1.36E-05	1.28E-06	5.11E-05	1.5E-05
Solubility - K (m/s), pH= 7.5-8	59	8.29E-06	8.01E-07	3.23E-05	9.63E-06

نتایج نشان می‌دهد که تقریباً اکثر خصوصیات مکانیکی توزیع تقریباً نرمالی دارند (شکل ۲). بر اساس تقسیم‌بندی (ISRM, 2007) حدود ۵۶ درصد نمونه‌ها از لحاظ مقاومت فشاری تک‌محوری خشک در رده‌ی متوسط قرار می‌گیرند و حدود ۲۴ درصد نمونه‌ها مقاومت بالا دارند. همچنین بر اساس مقاومت فشاری تک‌محوری اشباع، ۶۲ درصد نمونه‌ها در رده‌ی متوسط قرار می‌گیرند. نتایج نشان می‌دهد که اشباع شدن نمونه‌ها باعث می‌شود که مقاومت فشاری تک‌محوری ۱۲ درصد افت پیدا کند (جدول ۳). ۶۶ درصد نمونه‌ها مقاومت کششی برزیلین خشک و ۸۲ درصد نمونه‌ها مقاومت کششی برزیلین اشباع بیش‌تر از ۱۰ مگاپاسکال دارند؛ بنابراین بر اساس مقاومت کششی برزیلین خشک و

اشباع سنگ‌آهک‌های مورد مطالعه بسیار مقاوم هستند. مقایسه‌ی نتایج نشان می‌دهد که با اشباع شدن نمونه‌ها، مقاومت کششی برزیلین ۹ درصد افت داشته است. بر اساس تقسیم‌بندی بنیائوسکی (Bieniawski, 1973)، شاخص بار نقطه‌ای خشک ۳۵ درصد نمونه‌ها در رده‌ی متوسط قرار می‌گیرند و ۵۱ درصد نمونه‌ها در رده‌ی بالا و خیلی بالا قرار می‌گیرند؛ اما برای شاخص بار نقطه‌ای اشباع، ۶۶ درصد نمونه‌ها در رده‌ی متوسط و ۱۹ درصد نمونه‌ها در رده‌ی کم قرار می‌گیرند. مقایسه‌ی مقادیر میانگین شاخص بار نقطه‌ای در دو حالت خشک و اشباع نشان می‌دهد که با اشباع شدن نمونه‌ها، شاخص بار نقطه‌ای ۲۶/۷۶ درصد کاهش می‌یابد (جدول ۳). بر اساس رده‌بندی هوک (Hoek, 1983)، برای

می‌شود، تمامی نمونه‌ها، مدول یانگ استاتیکی کمتر از ۱۸ گیگا پاسکال دارند و میانگین آن نیز ۱۲/۰۶ گیگا پاسکال است. مقاومت برش مستقیم نمونه‌ها بین ۱۰ تا ۱۶ مگاپاسکال متغیر است و ۶۶ درصد نمونه‌ها مقاومت بین ۱۴ تا ۱۸ مگاپاسکال دارند. میانگین چسبندگی نمونه‌ها ۱/۱۰ مگاپاسکال است و زاویه‌ی اصطکاک داخلی ۶۷ درصد از نمونه‌ها بین ۳۰ تا ۴۵ درجه متغیر است.


تمامی نمونه‌ها شاخص شکنندگی خشک و اشباع کمتر از ۱۰ است و بنابراین سنگ‌های مورد مطالعه در رده‌ی کمی شکننده قرار می‌گیرند. بر اساس میانگین شاخص شکنندگی در دو حالت خشک و اشباع، با اشباع شدن نمونه‌ها، شاخص شکنندگی ۱/۱۳ درصد کاهش پیدا می‌کند. شاخص شکنندگی اکثر نمونه‌ها در دو حالت خشک و اشباع بین ۲/۲ تا ۲/۸ متغیر است. همان‌طور که در شکل (۲) مشاهده



شکل ۲. هیستوگرام فراوانی و منحنی توزیع نرمال (a) وزن مخصوص نسبی، (b) درصد تخلخل، (c) وزن مخصوص خشک و اشباع (KN/m³)، (d) شاخص دوام - وارفنگی چرخه‌ی اول و دوم، (e) شاخص دوام - وارفنگی چرخه‌ی سوم تا پنجم، (f) درصد جذب آب، (g) درصد سایش لس‌آنجلس، (h) درصد ارزش ضربه‌ای مصالح، (i) مقاومت فشاری تک‌محوری خشک و اشباع (MPa)، (j) مقاومت کششی برزیلین خشک و اشباع (MPa)، (k) شاخص بار نقطه‌ای خشک و اشباع (MPa)، (l) شاخص شکنندگی خشک و اشباع، (m) مدول یانگ استاتیکی (GPa)، (n) مقاومت برشی مستقیم (MPa)، (o) چسبندگی (MPa) و (p) زاویه‌ی اصطکاک داخلی

Fig. 2. Frequency histogram and normal distribution curve (a) Gs, (b) n, (c) Dry and saturation Specific Weight (KN/m³), (d) SDI - 1 and 2 (%), (e) SDI - 3 to 5 (%), (f) Water Absorption (%), (g) Los Angeles (%), (h) Aggregate Impact Value (%), (i) UCS - Dry and Sat (MPa), (j) BTS - Dry and Sat (MPa), (k) Is-50 - Dry and Sat (MPa), (l) BI - Dry and Sat, (m) Static Yang Modulus (GPa), (n) Direct shear strength (MPa), (o) Cohesion (MPa) and (p) Friction angle (Degree)

و میلر (Deere and Miller, 1966) در رده‌ی سنگ‌های با مقاومت بالا قرار می‌گیرند. سنگ‌آهک‌های مورد مطالعه با میانگین کلسیمتری ۷۸/۹۶ درصد، جز مواد فوق‌العاده آهکی (Extremely Calcareous) محسوب می‌شوند و به شدت قلیایی هستند. سنگ‌آهک‌های مورد مطالعه بر اساس ثابت سرعت انحلال، جز سنگ‌های با انحلال‌پذیری متوسط هستند. البته نتایج نشان می‌دهد که افزایش pH باعث کاهش ۵۵/۶۶ درصدی ثابت سرعت انحلال شده است (شکل ۳).



شکل ۳. هیستوگرام فراوانی و منحنی توزیع نرمال (a) سرعت موج فشاری خشک و اشباع (km/s)، (b) مدول یانگ دینامیک (GPa)، (c) نسبت پواسون دینامیک، (d) عدد چکش اشمیت، (e) درصد کلسیمتری و (f) ثابت سرعت انحلال (k) در pH= 6.5-7، pH= 7-7.5 و pH= 7.5-8

Fig. 3. Frequency histogram and normal distribution curve (a) P Wave Velocity - Dry and saturation (km/s), (b) Dynamic Yang Modulus (GPa), (c) Dynamic Poisson Ratio, (d) Schmidt Hammer (SH), (e) Calcimetry (%) and (f) Solubility - K (m/s) in pH= 6.5-7, pH= 7-7.5 and pH= 7.5-8

در ادامه و در شکل (۴) معادلات رگرسیون تک متغیره

پیش‌بینی UCS_{Dry} و IS_{50-Dry} ارائه شده است. به علت محدودیت داده‌ها یا دقت پایین برخی روابط، سایر معادلات خصوصیات مقاومتی و دیگر خواص بررسی نشدند. به‌منظور پیش‌بینی UCS_{Dry} از درصد تخلخل، وزن مخصوص خشک، شاخص دوام - وارفتگی چرخه‌ی اول، درصد جذب آب، IS_{50-Dry} سرعت موج فشاری خشک و عدد چکش اشمیت

بر اساس تقسیم‌بندی آنون (Anon, 1979)، میانگین سرعت موج فشاری در هر دو حالت خشک و اشباع در رده‌ی خیلی بالا قرار می‌گیرند. عمده‌ی نمونه‌ها دارای مدول یانگ دینامیکی بین ۲۵ تا ۵۰ گیگا پاسکال هستند و میانگین مدول یانگ دینامیکی نمونه‌ها نیز ۳۰/۹۳ گیگا پاسکال است. بررسی نسبت پواسون دینامیکی نمونه‌ها نشان می‌دهد که عمده نمونه‌ها، نسبت پواسون دینامیکی ۰/۵ دارند. بر اساس مطالعات صورت گرفته عمده تغییرات عدد چکش اشمیت برای نمونه‌ها بین ۴۰ تا ۵۵ است و بر اساس تقسیم‌بندی دیر


نتایج و بحث

پیش‌بینی UCS_{Dry} و IS_{50-Dry} با استفاده از رگرسیون تک متغیره

پس از حذف داده‌های پرت، پیش‌بینی خصوصیات مقاومتی شامل UCS ، BTS و IS_{50} با بهره‌گیری از رگرسیون تک متغیره و بر اساس سایر خصوصیات انجام شد. بدین منظور

نمودارهای ارائه شده، می‌توان نتیجه گرفت که پیش‌بینی UCS_{Dry} هنگامی که با بهره‌گیری از درصد تخلخل، شاخص دوام - وارفنگی چرخه‌ی اول، درصد جذب آب و شاخص بار نقطه‌ای خشک صورت گیرد، از دقت و اعتبار بالاتری برخوردار است. در سوی دیگر، پیش‌بینی Is_{50-Dry} در صورت استفاده از شاخص شکنندگی خشک و عدد چکش اشمیت، به دقیق‌ترین برآورد ممکن منتهی خواهد شد (شکل ۴).

استفاده شده و جهت پیش‌بینی Is_{50-Dry} از درصد تخلخل، شاخص دوام - وارفنگی چرخه‌ی اول، درصد جذب آب، شاخص شکنندگی خشک، سرعت موج فشاری خشک و عدد چکش اشمیت استفاده شده است. معادلات رگرسیون تک متغیره به‌صورت خطی، نمایی یا لگاریتمی ارائه شده‌اند که امکان پیش‌بینی دقیق‌تر مقاومت سنگ را از طریق خواص ساده‌تر فراهم می‌کند. بر پایه‌ی تحلیل‌های آماری و بررسی



شکل ۴. معادله‌ی رگرسیون تک متغیره UCS_{Dry} با (a) درصد تخلخل، (b) وزن مخصوص خشک، (c) شاخص دوام - وارفنگی چرخه‌ی اول، (d) درصد جذب آب، (e) Is_{50-Dry} ، (f) سرعت موج فشاری خشک، (g) عدد چکش اشمیت و معادله‌ی رگرسیون تک متغیره Is_{50-Dry} با (h) درصد تخلخل، (i) شاخص دوام - وارفنگی چرخه‌ی اول، (j) درصد جذب آب، (k) شاخص شکنندگی خشک، (l) سرعت موج فشاری خشک و (m) عدد چکش اشمیت


Fig. 4. Univariate regression equation for UCS_{Dry} with (a) n , (b) Dry Specific Weight, (c) SDI - 1, (d) Water Absorption, (e) Is_{50-Dry} , (f) Dry P Wave Velocity, (g) Schmidt Hammer and the univariate regression equation of the Is_{50-Dry} with (h) n , (i) SDI - 1, (j) Water Absorption, (k) BI - Dry, (l) Dry P Wave Velocity and (m) Schmidt Hammer

شده، در ادامه تحلیل باقیمانده‌های استاندارد شده و

به منظور ارزیابی بهتر معادله‌های رگرسیون تک متغیره ارائه

خطاهاست. توزیع باقیمانده‌ها بیشتر به صورت زنگوله‌ای (تقریباً نرمال) است. این امر نشان‌دهنده ثبات و کیفیت نسبی مدل‌سازی است. تعداد نمونه‌های هر مدل بین ۸۵ تا ۱۴۱ است که به لحاظ آماری حجم مناسبی برای آزمون نرمال بودن باقیمانده‌ها به شمار می‌رود و نتیجه‌گیری‌ها از نظر آماری قابل قبول هستند. با توجه به برآورده شدن مفروضه نرمال بودن باقیمانده‌ها، می‌توان با اطمینان بیشتری از این مدل‌های رگرسیونی برای تحلیل‌های بعدی مثلاً برای آزمون‌های فرض، پیش‌بینی و برآورد بازه‌های اطمینان استفاده کرد.

مقایسه‌ی منحنی توزیع نرمال مقادیر اندازه‌گیری شده و پیش‌بینی شده‌ی آن‌ها نمایش داده شده است (شکل‌های ۵ و ۶). تمامی نمودارهای هیستوگرام باقیمانده‌های استاندارد شده به صورت کلی توزیع تقریباً نرمال و متقارن دارند که با منحنی چگالی نرمال همپوشانی نسبی دارند (شکل ۵). این امر نشان می‌دهد مدل‌های رگرسیونی تا حدودی فرض نرمال بودن خطاها را برآورده می‌کنند. میانگین باقیمانده‌ها در تمام مدل‌ها نزدیک به صفر است و انحراف معیار در همه موارد حدود ۰/۹۹ تا یک است. این مقادیر هم نشان‌دهنده‌ی عدم وجود سوگیری سیستماتیک در مدل‌ها و مقیاس درست




شکل ۵. هیستوگرام فراوانی و منحنی توزیع نرمال باقیمانده‌های معادله‌های رگرسیون تک متغیره UCS Dry با (a) درصد تخلخل، (b) وزن مخصوص خشک، (c) شاخص دوام - وارفتگی چرخه‌ی اول، (d) درصد جذب آب، (e) Is 50-Dry، (f) سرعت موج فشاری خشک، (g) عدد چکش اشمیت و معادله‌های رگرسیون تک متغیره Is 50-Dry با (h) درصد تخلخل، (i) شاخص دوام - وارفتگی چرخه‌ی اول، (j) درصد جذب آب، (k) شاخص شکنندگی خشک، (l) سرعت موج فشاری خشک و (m) عدد چکش اشمیت

Fig. 5. Frequency histogram and normal distribution curve of residuals of univariate regression equations of UCS Dry with (a) n, (b) Dry Specific Weight, (c) SDI - 1, (d) Water Absorption, (e) Is 50-Dry, (f) Dry P Wave Velocity, (g) Schmidt Hammer and the univariate regression equations of the Is 50-Dry with (h) n, (i) SDI - 1, (j) Water Absorption, (k) BI - Dry, (l) Dry P Wave Velocity and (m) Schmidt Hammer

در شکل (۶) مقایسه‌ی منحنی توزیع نرمال مقادیر اندازه‌گیری شده و پیش‌بینی شده‌ی معادله‌های رگرسیون تک متغیره نمایش داده شده است. در اکثر موارد، منحنی‌های مقادیر اندازه‌گیری شده و پیش‌بینی شده تقریباً

همپوشانی خوبی دارند. تفاوت میان میانگین‌ها و انحراف معیارها در مقادیر اندازه‌گیری شده و پیش‌بینی شده نسبتاً کم است.




شکل ۶. مقایسه‌ی منحنی توزیع نرمال مقادیر اندازه‌گیری شده و پیش‌بینی شده‌ی معادله‌های رگرسیون تک متغیره UCS Dry با (a) درصد تخلخل، (b) وزن مخصوص خشک، (c) شاخص دوام - وارفتگی چرخه‌ی اول، (d) درصد جذب آب، (e) Is 50-Dry، (f) سرعت موج فشاری خشک، (g) عدد چکش اشمیت و معادله‌های رگرسیون تک متغیره Is 50-Dry با (h) درصد تخلخل، (i) شاخص دوام - وارفتگی چرخه‌ی اول، (j) درصد جذب آب، (k) شاخص شکنندگی خشک، و (l) سرعت موج فشاری خشک و (m) عدد چکش اشمیت

Fig. 6. Comparison of the normal distribution curve of measured and predicted values of univariate regression equations of dry uniaxial compressive strength with (a) n, (b) Dry Specific Weight, (c) SDI - 1, (d) Water Absorption, (e) Is 50-Dry, (f) Dry P Wave Velocity, (g) Schmidt Hammer and the univariate regression equations of the Is 50-Dry with (h) n, (i) SDI - 1, (j) Water Absorption, (k) BI - Dry, (l) Dry P Wave Velocity and (m) Schmidt Hammer

سنگ آهک‌های مورد مطالعه را فراهم می‌کنند. در هر نمودار، سطوح رنگی از سبز (مقادیر پایین) تا قرمز (مقادیر بالا) گسترش یافته‌اند که نشان‌دهنده‌ی شدت یا ضعف شاخص مورد نظر در نقاط مختلف از دامنه تغییرات متغیرها هستند. این گرادین رنگی درک بهتری از توزیع مقاومت در سطوح مختلف ورودی‌ها را فراهم می‌کند.

پیش‌بینی UCS Dry و Is 50-Dry با استفاده از رگرسیون چند متغیره

در شکل (۷) نمودارهای سه‌بعدی تغییرات UCS Dry در برابر دو متغیر مستقل (رگرسیون‌های دو متغیره خطی) ارائه شده است. این نمودارها بررسی اثر هم‌زمان دو متغیر مستقل بر UCS Dry به منظور مدل‌سازی و پیش‌بینی رفتار مقاومتی



شکل ۷. نمودارهای سه‌بعدی تغییرات UCS Dry در برابر تغییرات خصوصیات مختلف (رگرسیون‌های دو متغیره)

Fig. 7. Three-dimensional diagram of changes in the UCS Dry against changes in various characteristics (bivariate regressions)

($R^2=0.904$) مربوط به ترکیب Is 50-Dry و شاخص دوام - وارفتگی چرخه‌ی اول است که نشان می‌دهد این دو متغیر در تخمین UCS Dry نقش کلیدی و قابل‌اتکایی دارند. دقت قابل قبول اغلب مدل‌ها ($R^2>0.75$) نشان می‌دهد که استفاده از ترکیب دو متغیر مستقل می‌تواند تخمین مناسبی از UCS Dry فراهم آورد که این امر به کاهش نیاز به آزمون‌های مخرب، کاهش هزینه‌ها و صرفه‌جویی در زمان پروژه‌های مهندسی منجر می‌شود.

در جدول (۴)، معادلات رگرسیون خطی دو متغیره جهت پیش‌بینی UCS Dry ارائه شده‌اند. به‌منظور ارزیابی دقت این معادلات، از ضریب هم‌بستگی (R^2) به‌عنوان شاخص هم‌بستگی و کیفیت برازش استفاده شده است. بر اساس تحلیل معادله‌های رگرسیون دو متغیره ارائه‌شده برای پیش‌بینی UCS Dry، مشخص شد که ارتباط معناداری میان خصوصیات مختلف و مقدار UCS Dry وجود دارد. در میان مدل‌های بررسی‌شده، بالاترین ضریب هم‌بستگی


جدول ۴. معادله‌های رگرسیون دو متغیره پیش‌بینی UCS Dry

Table 4. Bivariate regression equations for predicting UCS Dry

Regression equation	R^2
UCS - Dry = $38.5408+2.5608*\gamma_d-4.4504*n$	0.7695
UCS - Dry = $-4515.6275+46.3942*SDI\ 1+0.992*n$	0.7271
UCS - Dry = $112.1143+0.3968*WA-5.0763*n$	0.7306
UCS - Dry = $50.5727+11.6236*Is\ -50\ dry-2.342*n$	0.846
UCS - Dry = $32.7518+10.199*Vp-2.861*n$	0.8015
UCS - Dry = $-15.8227+2.4705*SH-1.8038*n$	0.689
UCS - Dry = $-3080.4912+30.9535*SDI\ 1+3.746*\gamma_d$	0.8156
UCS - Dry = $66.3492-10.051*WA+1.4972*\gamma_d$	0.7368
UCS - Dry = $-83.3759+9.1415*Is\ -50\ dry+5.269*\gamma_d$	0.7921
UCS - Dry = $-223.7+6.0615*Vp+10.6621*\gamma_d$	0.7576
UCS - Dry = $-113.0257+2.5557*SH+3.4453*\gamma_d$	0.7513
UCS - Dry = $-4309.0517+1.8475*WA+44.3315*SDI\ 1$	0.7057
UCS - Dry = $-1391.569+15.0762*Is\ -50\ dry+14.3316*SDI\ 1$	0.904
UCS - Dry = $-2606.6519+5.7179*Vp+26.829*SDI\ 1$	0.7428
UCS - Dry = $-1241.239+2.9837*SH+12.0997*SDI\ 1$	0.8611
UCS - Dry = $54.1062+11.2115*Is\ -50\ dry-4.9587*WA$	0.8747
UCS - Dry = $46.9396+8.841*Vp-5.5358*WA$	0.8225
UCS - Dry = $-26.0932+2.7775*SH-3.7948*WA$	0.7889
UCS - Dry = $-14.1437+10.9504*Vp+9.2701*Is\ -50\ dry$	0.7116
UCS - Dry = $-28.3647+1.4058*SH+12.7173*Is\ -50\ dry$	0.7851
UCS - Dry = $-71.8693+1.2966*SH+16.2343*Vp$	0.6209

تأثیر متقابل دو عامل بر مقدار Is 50-Dry است. در هر نمودار، سطوح رنگی از سبز (مقادیر پایین) تا قرمز (مقادیر بالا) گسترش یافته‌اند که نشان‌دهنده شدت یا ضعف شاخص مورد نظر در نقاط مختلف از دامنه تغییرات متغیرها هستند.

شکل (۸) شامل مجموعه‌ای از نمودارهای سه‌بعدی است که تغییرات Is 50-Dry را در برابر تغییرات هم‌زمان دو متغیر مستقل نشان می‌دهد. این نمودارها با استفاده از رگرسیون‌های دو متغیره ترسیم شده‌اند و هدف آن‌ها تحلیل



شکل ۸. نمودارهای سه‌بعدی تغییرات Is 50-Dry در برابر تغییرات خصوصیات مختلف (رگرسیون‌های دو متغیره)

Fig. 8. Three-dimensional diagram of changes in the Is 50-Dry against changes in various characteristics (bivariate regressions)

اول و شاخص شکنندگی خشک را به عنوان ورودی دارند، عملکرد بهتری داشته و ضریب هم‌بستگی (R^2) بالاتری را نشان می‌دهند؛ به‌طور مثال، رگرسیون شامل متغیرهای شاخص دوام - وارفنگی چرخه‌ی اول و عدد چکش اشمیت ($R^2=0.8445$) بهترین تناسب را با داده‌ها دارد و نشان‌دهنده‌ی دقت بالای پیش‌بینی است.

نتایج نشان می‌دهد که استفاده از معادلات رگرسیون دو متغیره برای پیش‌بینی Is_{50-Dry} می‌تواند نتایج قابل قبولی ارائه دهد، به‌ویژه زمانی که ترکیبی از دو متغیر مستقل به کار گرفته شود (جدول ۵). در میان معادله‌های رگرسیون، معادله‌هایی که متغیرهای شاخص دوام - وارفنگی چرخه‌ی اول و عدد چکش اشمیت یا شاخص دوام - وارفنگی چرخه‌ی

جدول ۵. معادله‌های رگرسیون دومتغیره پیش‌بینی Is_{50-Dry} Table 5. Bivariate regression equations for predicting Is_{50-Dry}

Regression equation	R^2
$Is_{50-Dry} = -49.8074 + 0.5499 * SDI - 0.1899 * n$	0.7196
$Is_{50-Dry} = 5.6589 + 0.6183 * WA - 0.5616 * n$	0.6317
$Is_{50-Dry} = -11.2301 + 6.0954 * BI_{dry} - 0.1494 * n$	0.6403
$Is_{50-Dry} = -3.3697 + 1.5316 * Vp - 0.0162 * n$	0.6411
$Is_{50-Dry} = -1.6533 + 0.1496 * SH - 0.1038 * n$	0.6862
$Is_{50-Dry} = -36.5192 - 0.394 * WA + 0.4156 * SDI - 1$	0.681
$Is_{50-Dry} = -12.8405 + 10.9682 * BI_{dry} - 0.1293 * SDI - 1$	0.8183
$Is_{50-Dry} = -113.4865 + 0.4119 * Vp + 1.1587 * SDI - 1$	0.617
$Is_{50-Dry} = -16.1767 + 0.1537 * SH + 0.1338 * SDI - 1$	0.8445
$Is_{50-Dry} = -12.6898 + 6.5721 * BI_{dry} - 0.2874 * WA$	0.6421
$Is_{50-Dry} = -2.1961 + 1.3032 * Vp - 0.0676 * WA$	0.6352
$Is_{50-Dry} = -2.3387 + 0.1595 * SH - 0.1482 * WA$	0.6864
$Is_{50-Dry} = -17.8276 + 0.7884 * Vp + 6.6247 * BI_{dry}$	0.4572
$Is_{50-Dry} = -17.2769 + 0.1129 * SH + 6.1874 * BI_{dry}$	0.5961
$Is_{50-Dry} = -4.8271 + 0.0192 * SH + 1.5807 * Vp$	0.503

تخلخل است ($R^2=0.9660$)، بهترین عملکرد را در پیش‌بینی این پارامتر نشان داده است. همچنین، معادله‌های متعددی برای پیش‌بینی Is_{50-Dry} ارائه شده‌اند که در آن‌ها ترکیبی از متغیرهایی مختلف و با ضریب هم‌بستگی عموماً بالا دیده می‌شود ($R^2 > 0.90$) که این امر کیفیت بالای این معادله‌ها را در پیش‌بینی Is_{50-Dry} نشان می‌دهد. به‌طور کلی، استفاده از ترکیب چند متغیر مؤثر موجب افزایش دقت رگرسیون پیش‌بینی شده است. به دلیل مقادیر بالای ضریب تعیین و معناداری آماری معادله‌ها، این روابط می‌توانند به عنوان ابزارهای قابل اعتماد در مطالعات زمین‌شناسی و مهندسی سنگ مورد استفاده قرار گیرند.

در جدول (۶)، معادله‌های رگرسیون برای پیش‌بینی UCS Dry و Is_{50-Dry} با بهره‌گیری از ترکیبی از متغیرهای مستقل ارائه شده است. تمامی مدل‌ها دارای مقادیر معناداری آماری بسیار بالایی ($P \text{ Value} < 0.05$) بوده که بیانگر اعتبار و قوت روابط برقرار شده، است. برای تمامی معادله‌ها مقادیر ضریب هم‌بستگی (R^2) اغلب بالا بوده و نشان‌دهنده‌ی توان معادله‌ها در تبیین درصد قابل توجهی از تغییرات متغیر وابسته است. در پیش‌بینی UCS_{Dry} ، معادله‌هایی که Is_{50-Dry} و شاخص دوام - وارفنگی چرخه‌ی اول را در کنار سایر متغیرها به کار گرفته‌اند، از دقت بالاتری برخوردار بوده‌اند؛ به‌ویژه رگرسیونی که شامل Is_{50-Dry} و شاخص دوام - وارفنگی چرخه‌ی اول و

جدول ۶. معادله‌های رگرسیون چند متغیره پیش‌بینی UCS Dry و Is 50-Dry

Table 6. Multivariate regression equations predicting UCS Dry and Is 50-Dry

Regression equation	P Value	R ²
$UCS_{dry} = 69.3 - 1.58n + 1.39\gamma_{dry} - 6.65WA$	0.0000	0.7374
$UCS_{dry} = 100.95 - 3.74n - 1.22\gamma_{dry} + 7.6Is_{50-dry}$	0.0000	0.8577
$UCS_{dry} = -8.32 - 2.33n + 1.02\gamma_{dry} + 1.77SH$	0.0000	0.7643
$UCS_{dry} = -2381.18 + 2.41n + 24.03SDI\ 1 + 19.26Is_{50-dry}$	0.0000	0.9660
$UCS_{dry} = 52.87 + 0.45n - 5.7WA + 11.39Is_{50-dry}$	0.0000	0.8749
$UCS_{dry} = -34.54 + 1.64n - 6.67WA + 2.93SH$	0.0000	0.7895
$UCS_{dry} = 7.13 - 1.37n + 10.76Is_{50-dry} + 0.97SH$	0.0000	0.8464
$UCS_{dry} = 106.5 + 1.96n - 1.39\gamma_{dry} - 12.77WA + 7.3Is_{50-dry}$	0.0000	0.8692
$UCS_{dry} = 38.76 - 3.62n + 0.76\gamma_{dry} + 0.18WA + 0.97SH$	0.0000	0.7531
$UCS_{dry} = 82.73 - 2.93n - 2.24\gamma_{dry} + 76Is_{50-dry} + 0.93SH$	0.0000	0.8893
$Is_{50-dry} = -94.27 - 0.78n + 0.99SDI\ 1 + 1.32WA$	0.0000	0.7634
$Is_{50-dry} = 69.21 - 0.06n - 0.98SDI\ 1 + 12.25BI\ dry$	0.0000	0.9371
$Is_{50-dry} = -21.37 + 0.05n + 0.17SDI\ 1 + 0.18SH$	0.0000	0.904
$Is_{50-dry} = -13.95 - 0.7n + 1.16WA + 7.1BI\ dry$	0.0000	0.6943
$Is_{50-dry} = -0.34 - 0.38n + 0.52WA + 0.12SH$	0.0000	0.7
$Is_{50-dry} = -7.06 - 0.07n + 2.2BI\ dry + 0.13SH$	0.0000	0.7
$Is_{50-dry} = 44.64 - 0.23n - 0.73SDI + 0.37WA + 11.96BI\ dry$	0.0000	0.9372
$Is_{50-dry} = -46.96 - 0.15n + 0.43SDI + 0.43WA + 0.18SH$	0.0000	0.9032
$Is_{50-dry} = 49.74 - 0.018n - 0.74SDI + 9.44BI\ dry + 0.05SH$	0.0000	0.9556
$Is_{50-dry} = 29.29 - 0.13n - 0.53SDI + 0.28WA + 9.38BI\ dry + 0.05SH$	0.0000	0.957

(Mean Squared Error) برای مجموعه داده‌های آموزش

(Train)، تست (Test) و اعتبارسنجی (Validation) در


طول آموزش است. همچنین بهترین عملکرد مدل بر اساس کمترین مقدار خطای اعتبارسنجی مشخص شده و به صورت عددی همراه با شماره دوره‌ای که در آن به دست آمده، نمایش داده شده است.

مقادیر بهترین عملکرد اعتبارسنجی از حدود صفر (مدل پیش‌بینی UCS Dry با درصد تخلخل، شاخص دوام - وارفتگی چرخه‌ای اول، Is 50-Dry) تا حدود ۴۸/۴۰ (مدل پیش‌بینی UCS Dry با درصد تخلخل، عدد چکش اشمیت، Is 50-Dry) متغیر است.

پیش‌بینی UCS Dry و Is 50-Dry با استفاده از شبکه‌ی

عصبی

در این مطالعه، مدل‌های مختلف شبکه عصبی مصنوعی (MLP) جهت پیش‌بینی UCS Dry و Is 50-Dry با استفاده از ترکیب‌های متنوعی از پارامترهای ورودی مورد ارزیابی قرار گرفتند. در شکل (۹) مجموعه‌ای از نمودارهای عملکرد یادگیری مدل‌های مختلف شبکه‌های عصبی نمایش داده شده است که به وضوح مراحل آموزش و اعتبارسنجی آن‌ها را در طول تعدادی از دوره‌های آموزش (Epochs) مقایسه می‌کند. هر نمودار نمایانگر سیر خطای جذر میانگین مربعات



شکل ۹. منحنی تغییرات میانگین مربعات خطا در برابر تعداد تکرارهای انجام شده در حالت‌های آموزش، اعتبارسنجی و آزمون
Fig. 9. Curve of changes in mean square error versus number of iterations performed in training, validation, and testing modes

برای $R^2=0.96$ عملکرد بسیار خوبی از خود نشان دهد. برای پیش‌بینی Is_{50-Dry} نیز، مدل‌هایی که شامل پارامترهای BI_{Dry} و $SDI1$ به‌عنوان ورودی بودند، عملکرد بسیار مطلوبی داشتند. به‌طور خاص، مدل با ورودی‌های BI_{Dry} ، $SDI1$ و n و ساختار MLP 3-3-1 با ضریب هم‌بستگی کلی $R^2=0.99$ یکی از بهترین نتایج را ارائه کرد. این امر تأکید می‌کند که ویژگی‌های سنگ‌شناسی و شاخص‌های مرتبط با ساختار داخلی نمونه‌ها نقش تعیین‌کننده‌ای در برآورد صحیح مقاومت دارند.

در جدول (۷) خلاصه‌ای از پارامترهای مختلف مدل‌های شبکه‌ی عصبی طراحی شده جهت پیش‌بینی UCS_{Dry} و Is_{50-Dry} آورده شده است. در تمامی مدل‌ها از تابع فعال‌سازی Tansig در لایه‌های پنهان و Purelin در لایه خروجی استفاده شده است که برای مسائل رگرسیونی انتخاب مناسبی است. در خصوص پیش‌بینی UCS_{Dry} ، مشخص شد که حضور Is_{50-Dry} در میان پارامترهای ورودی تأثیر بسزایی در بهبود دقت مدل‌ها دارد. به‌عنوان نمونه، مدل با ورودی‌های Is_{50-Dry} ، SH ، $γ_{Dry}$ و n و ساختار شبکه‌ی MLP 2-2-2-1 توانست با ضریب هم‌بستگی کلی

جدول ۷. خلاصه‌ای از پارامترهای مختلف مدل‌های شبکه‌ی عصبی طراحی شده جهت پیش‌بینی Is_{50-Dry} و UCS_{Dry}

Table 7. Summary of various parameters of neural network models designed to predict UCS_{Dry} and Is_{50-Dry}


Target	Input	Net name	R^2				Hidden activation	Output activation
			Training	Validation	Test	All		
UCS_{dry}	n, γ_{dry} , WA	MLP 3-3-1	0.75	0.96	0.52	0.75	Tansig	Purelin
	n, γ_{dry} , Is_{50-dry}	MLP 4-4-1	0.91	0.84	0.78	0.89	Tansig	Purelin
	n, γ_{dry} , SH	MLP 6-6-6-1	0.79	0.98	0.68	0.80	Tansig	Purelin
	n, SDI 1, Is_{50-dry}	MLP 4-4-1	1	1	1	1	Tansig	Purelin
	n, WA, Is_{50-dry}	MLP 6-6-1	0.88	0.99	0.92	0.90	Tansig	Purelin
	n, WA, SH	MLP 4-4-4-1	0.85	0.98	0.91	0.87	Tansig	Purelin
	n, SH, Is_{50-dry}	MLP 4-4-4-1	0.83	0.97	0.82	0.86	Tansig	Purelin
	n, γ_{dry} , WA, Is_{50-dry}	MLP 14-14-1	0.99	0.98	0.46	0.90	Tansig	Purelin
	n, γ_{dry} , WA, SH	MLP 4-4-4-1	0.82	0.86	0.87	0.81	Tansig	Purelin
Is_{50-dry}	n, γ_{dry} , SH, Is_{50-dry}	MLP 2-2-2-1	0.98	0.98	0.82	0.96	Tansig	Purelin
	n, SDI 1, WA	MLP 6-6-1	0.93	0.87	0.87	0.91	Tansig	Purelin
	n, SDI 1, BI dry	MLP 3-3-1	0.99	0.98	0.98	0.99	Tansig	Purelin
	n, SDI 1, SH	MLP 2-2-1	0.97	0.99	0.92	0.97	Tansig	Purelin
	n, BI dry, WA	MLP 13-13-1	0.79	0.53	0.80	0.77	Tansig	Purelin
	n, SH, WA	MLP 9-9-1	0.82	0.75	0.43	0.76	Tansig	Purelin
	n, BI dry, SH	MLP 8-8-1	0.79	0.80	0.86	0.80	Tansig	Purelin
	n, SDI 1, WA, BI dry	MLP 5-5-1	0.99	0.98	0.99	0.99	Tansig	Purelin
	n, SDI 1, WA, SH	MLP 3-3-1	0.95	0.99	0.94	0.96	Tansig	Purelin
Is_{50-dry}	n, SDI 1, BI dry, SH	MLP 3-3-1	0.98	0.99	0.99	0.98	Tansig	Purelin
	n, SDI 1, WA, BI dry, SH	MLP 4-4-1	0.98	0.99	0.98	0.98	Tansig	Purelin

بهتری دارند و مقادیر R^2 بالاتری را نسبت به سایر مدل‌ها ارائه می‌دهند. رگرسیون چند متغیره نیز نسبت به مدل‌های ساده‌تر (تک متغیره و دومتغیره) عملکرد بهتری دارد و مدل‌های تک متغیره دارای کمترین دقت هستند. در خصوص مدل‌های پیش‌بینی Is_{50-Dry} نیز روند کلی به همین صورت است اما دقت مدل‌ها کمی کمتر از مدل‌های پیش‌بینی UCS_{Dry} است (شکل ۱۰).

مقایسه نتایج

جهت مقایسه‌ی میزان دقت معادله‌های رگرسیون ارائه شده با هم و با مدل‌های شبکه‌ی عصبی، مقادیر ضریب هم‌بستگی روابط در شکل (۱۰) و مقادیر اندازه‌گیری شده و پیش‌بینی شده‌ی UCS_{Dry} و Is_{50-Dry} در شکل‌های (۱۱) و (۱۲) با هم مقایسه شده‌اند.

نتایج نشان می‌دهند که در اکثر موارد مدل‌های شبکه‌ی عصبی پیش‌بینی UCS_{Dry} به‌طور قابل توجهی عملکرد



شکل ۱۰. مقایسه‌ی ضریب هم‌بستگی معادله‌های رگرسیون و مدل‌های شبکه‌ی عصبی (a) UCS Dry و (b) Is 50-Dry

Fig. 10. Comparison of the correlation coefficient of regression equations and neural network models for (a) UCS Dry and (b) Is 50-Dry


50-Dry با استفاده از نمودارهای Boxplot در شکل‌های (۱۱)

و (۱۲) با هم مقایسه شده‌اند. مقایسه‌ی نتایج رگرسیون تک متغیره نشان می‌دهد که دقت کم‌تری جهت پیش‌بینی

جهت مقایسه‌ی میانگین و انحراف معیار معادله‌های رگرسیون ارائه شده با هم و با مدل‌های شبکه‌ی عصبی، مقادیر اندازه‌گیری شده و پیش‌بینی شده‌ی UCS Dry و Is

UCS_{Dry} دارند؛ زیرا اختلاف نسبتاً قابل توجهی بین مقادیر پیش‌بینی شده و مقادیر اندازه‌گیری شده وجود دارد. این موضوع بیانگر آن است که UCS_{Dry} تحت تأثیر هم‌زمان چندین خصوصیت فیزیکی، مکانیکی و غیره قرار دارد و مدل‌های ساده نمی‌توانند این روابط پیچیده را به‌درستی درک کنند. در خصوص استفاده از رگرسیون دو متغیره هرچند نتایج نسبت به مدل تک متغیره بهبود یافته‌اند و برخی ترکیبات عملکرد بهتری دارند، اما همچنان پراکندگی در مقادیر پیش‌بینی شده زیاد است و انطباق کامل با مقادیر اندازه‌گیری شده مشاهده نمی‌شود. این امر نشان می‌دهد که حتی ترکیب دو خصوصیت برای مدل‌سازی رفتار پیچیده سنگ دقت حداکثری را ارائه نمی‌کند. در روش رگرسیون

چند متغیره، مقادیر پیش‌بینی شده تطابق بسیار بیشتری با مقادیر اندازه‌گیری شده داشته و دامنه تغییرات کاهش یافته است. این نتیجه نشان‌دهنده اهمیت لحاظ کردن هم‌زمان چندین خصوصیت برای درک رفتار مقاومتی سنگ است. در نهایت، روش شبکه‌ی عصبی (MLP) به‌عنوان یک مدل یادگیری ماشین غیرخطی، بهترین عملکرد را از نظر دقت و ثبات ارائه داده است. مقادیر پیش‌بینی شده در این روش بیش‌ترین هم‌پوشانی را با مقادیر اندازه‌گیری شده دارند و پراکندگی نقاط حداقل است. این موضوع نشان می‌دهد که شبکه‌های عصبی قادرند روابط غیرخطی و پیچیده بین ویژگی‌های ورودی و UCS_{Dry} را بهتر از روش‌های آماری سنتی مدل‌سازی کنند (شکل ۱۱).



شکل ۱۱. مقایسه‌ی نتایج مقادیر اندازه‌گیری شده و پیش‌بینی شده‌ی معادله‌های رگرسیون و مدل‌های شبکه‌ی عصبی UCS Dry با استفاده

از نمودارهای Boxplot (a) تک متغیره، (b) دو متغیره، (c) چند متغیره و (d) شبکه‌ی عصبی


Fig. 11. Comparison of measured and predicted values of regression equations and neural network models of UCS Dry using boxplot diagrams (a) univariate, (b) bivariate, (c) multivariate and (d) neural network

مقادیر اندازه‌گیری شده هم‌پوشانی کمی داشتند و پراکندگی داده‌ها زیاد است. این موضوع نشان می‌دهد که روابط بین متغیرها و Is 50-Dry پیچیده‌تر از آن است که تنها با یک متغیر بتوان آن را مدل کرد. با افزودن یک متغیر دیگر و استفاده از رگرسیون دومتغیره، دقت مدل بهبود یافته است. هم‌پوشانی داده‌های پیش‌بینی‌شده با مقادیر اندازه‌گیری شده بیش‌تر

مقایسه مقادیر پیش‌بینی‌شده با مقادیر اندازه‌گیری شده رگرسیون تک متغیره Is 50-Dry نشان می‌دهد که استفاده از تنها یک خصوصیت در مدل‌سازی باعث شده که مقادیر پیش‌بینی‌شده انحراف نسبتاً زیادی با مقادیر اندازه‌گیری شده داشته باشند. در اغلب موارد، مقادیر پیش‌بینی‌شده و

به‌مراتب بهتری از سایر روش‌ها نشان داده است. مقادیر پیش‌بینی‌شده در این روش بسیار نزدیک به مقادیر اندازه‌گیری شده هستند و هم‌پوشانی جعبه‌ها در نمودار Boxplot بیانگر دقت بالای این مدل است. همچنین، میزان پراکندگی خطاها بسیار کمتر شده است که نشان می‌دهد این مدل توانسته الگوهای پیچیده‌تر موجود در داده‌ها را به خوبی فرا بگیرد (شکل ۱۲).

شده و پراکندگی کاهش یافته، هرچند هنوز اختلاف‌هایی مشاهده می‌شود که نشان از کافی نبودن این روش برای درک کامل الگوی داده‌ها دارد. در رگرسیون چند متغیره که در آن ترکیبی از چندین خصوصیت به کار گرفته شده است، مدل توانسته روابط میان متغیرها و Is_{50-Dry} را بهتر تشخیص دهد. نتایج این بخش نشان‌دهنده کاهش قابل توجه خطا و افزایش هم‌خوانی بین مقادیر اندازه‌گیری شده و پیش‌بینی‌شده است. مقایسه نتایج شبکه عصبی عملکرد



شکل ۱۲. مقایسه‌ی نتایج مقادیر اندازه‌گیری شده و پیش‌بینی شده‌ی معادله‌های رگرسیون و مدل‌های شبکه‌ی عصبی Is_{50-Dry} با استفاده از نمودارهای Boxplot (a) تک متغیره، (b) دومتغیره، (c) چند متغیره و (d) شبکه‌ی عصبی

Fig. 12. Comparison of the results of measured and predicted values of regression equations and neural network models of Is_{50-Dry} using boxplot diagrams (a) univariate, (b) bivariate, (c) multivariate and (d) neural network

توانایی مدل‌سازی دقیق پدیده‌های مهندسی پیچیده را ندارند. در مقابل، مدل‌های پیشرفته‌تر مانند رگرسیون چند متغیره و به‌ویژه شبکه‌های عصبی، توانایی بالاتری در

دقت پیش‌بینی خواص مقاومتی با افزایش پیچیدگی مدل‌ها و تعداد متغیرهای ورودی به طور چشم‌گیری بهبود می‌یابد. در اکثر موارد مدل‌های ساده‌تر مانند رگرسیون تک متغیره

شناسایی و مدل‌سازی الگوهای پیچیده و غیرخطی بین ویژگی‌های سنگ و خواص مقاومتی دارند. مقایسه‌ی ضریب هم‌بستگی معادله‌های رگرسیون چند متغیره و مدل‌های شبکه عصبی نشان می‌دهند که به‌طور کلی استفاده از مدل‌های شبکه عصبی پیش‌بینی UCS_{Dry} ، $14/89$ درصد و مدل‌های شبکه عصبی پیش‌بینی IS_{50-Dry} ، $4/70$ درصد میزان دقت نتایج (ضریب هم‌بستگی) را افزایش می‌دهند. نتایج نشان می‌دهد که دقت پیش‌بینی خواص مقاومتی سنگ‌ها به شدت تحت تأثیر انتخاب نوع مدل و تعداد متغیرهای ورودی قرار دارد. در رگرسیون تک متغیره، اگرچه برخی روابط به ویژه بین تخلخل، شاخص دوام - وارفتگی چرخه‌ی اول، درصد جذب آب و UCS_{Dry} هم‌بستگی قابل قبولی نشان دادند، اما به دلیل پیچیدگی رفتار مکانیکی سنگ‌ها، این روش‌ها به‌تنهایی قادر به توصیف کامل تغییرات مقاومت نیستند و پراکندگی بالای مقادیر پیش‌بینی‌شده و فاصله نسبتاً زیاد میان نتایج واقعی و پیش‌بینی شده، نشان‌دهنده‌ی محدودیت ذاتی مدل‌های ساده در تحلیل این پدیده‌های پیچیده است. در رگرسیون دومتغیره، اگرچه ترکیب دو ویژگی (مانند IS_{50-Dry} و شاخص دوام - وارفتگی) توانست دقت مدل‌ها را به‌طور محسوسی افزایش دهد (تا $R^2 \approx 0.90$)، اما همچنان محدودیت‌هایی در بازتاب کامل تأثیر متغیرهای متعدد وجود دارد. این موضوع بیانگر آن است که رفتار مقاومتی سنگ‌ها نتیجه‌ی اثر هم‌زمان چندین پارامتر است و حذف هر کدام از این عوامل می‌تواند منجر به کاهش دقت مدل گردد. مدل‌های چند متغیره گام مهمی در افزایش دقت برداشتند و با استفاده از ترکیب چندین ویژگی ورودی توانستند R^2 هایی در حدود $0/95$ تا $0/96$ به دست آورند که نشان‌دهنده توانایی بالای رگرسیون چند متغیره در درک روابط پیچیده‌تر میان پارامترهای سنگ‌شناسی و مقاومت مکانیکی است. از نظر کاربردی، این دقت بالا می‌تواند به کاهش نیاز به آزمون‌های مخرب و صرفه‌جویی در

هزینه و زمان پروژه‌های مهندسی منجر شود. با این حال، مقایسه‌ی نهایی نتایج نشان می‌دهد که شبکه‌ی عصبی (MLP) برتری قابل توجهی نسبت به روش‌های آماری دارند. شبکه‌های عصبی توانستند با در نظر گرفتن روابط غیرخطی و پیچیده میان متغیرها، بیش‌ترین همپوشانی را با داده‌های واقعی ارائه دهند و پراکندگی نتایج را به حداقل برسانند. به‌ویژه مدل‌هایی که شامل متغیرهای کلیدی مانند IS_{50-Dry} ، $SDI1$ و BI_{Dry} بودند، عملکرد بسیار بالایی نشان دادند (تا $R^2 \approx 0.99$) و این امر تأکید می‌کند که استفاده از الگوریتم‌های یادگیری ماشین، به‌ویژه در حوزه مهندسی سنگ، ابزار قدرتمندی برای پیش‌بینی دقیق خواص مکانیکی محسوب می‌شود. در مطالعات تقوی و همکاران (Taghavi et al., 2023) و خواجه‌وند (Khajevand, 2023) مدل‌های عصبی - فازی می‌تواند مقاومت فشاری تک‌محوری را با دقت بیشتری نسبت به روش‌های شبکه عصبی مصنوعی و رگرسیون چند متغیره پیش‌بینی کند. بر اساس مطالعات شریفی و همکاران (Sharifi et al., 2024) استفاده از روش شبکه عصبی جهت پیش‌بینی مقاومت فشاری تک‌محوری نسبت به روش رگرسیون، ضریب هم‌بستگی روابط را بین 56 تا 62 درصد بهبود می‌بخشد. در جمع‌بندی می‌توان گفت مدل‌های ساده (تک متغیره) تنها در شرایطی که داده‌های محدودی در دسترس باشند برای برآورد اولیه مقاومت مفید هستند، در حالی که مدل‌های دومتغیره و چند متغیره توانسته‌اند بخشی از پیچیدگی رفتار سنگ‌ها را پوشش دهند و در بسیاری از موارد دقت قابل قبولی ارائه کنند. در نهایت، مدل‌های شبکه عصبی به دلیل قابلیت یادگیری روابط غیرخطی، بهترین گزینه برای پیش‌بینی دقیق خصوصیات مقاومتی بوده و می‌توانند جایگزین مناسبی برای آزمون‌های پرهزینه و زمان‌بر باشند. همچنین پیشنهاد می‌شود در پژوهش‌های آینده از ترکیب روش‌های آماری و الگوریتم‌های یادگیری ماشین به‌صورت هیبریدی استفاده شود تا ضمن

بالا و پراکندگی خطای کم، رفتار پیچیده و غیرخطی بین ویژگی‌های ورودی و مقاومت سنگ‌ها را شناسایی و مدل‌سازی کنند. مقایسه ضریب همبستگی بین مدل‌های آماری و شبکه عصبی نشان داد که دقت پیش‌بینی UCS Dry با استفاده از شبکه عصبی تا ۱۴/۸۹ درصد و دقت پیش‌بینی Is 50-Dry تا ۴/۷۰ درصد نسبت به معادله‌های رگرسیون چند متغیره افزایش یافته است.

در مجموع، می‌توان نتیجه گرفت که روش شبکه عصبی، به‌ویژه در شرایطی که روابط بین متغیرها پیچیده و غیرخطی باشد، ابزار قدرتمندتری نسبت به مدل‌های آماری کلاسیک برای پیش‌بینی خواص مقاومتی سنگ‌ها است و می‌تواند در پروژه‌های مهندسی سنگ کاربردهای فراوانی داشته باشد.

قدردانی

نگارندگان لازم می‌دانند تا از گروه زمین‌شناسی دانشگاه فردوسی مشهد به سبب فراهم نمودن امکانات لازم برای انجام طرح پژوهشی شماره ۳/۵۶۹۴۳ قدردانی نمایند. همچنین از جناب آقای مهندس حمید حافظی مقدس مسئول آزمایشگاه زمین‌شناسی مهندسی دانشگاه فردوسی مشهد، تشکر می‌شود.

بهره‌مندی از سادگی و قابلیت تفسیر رگرسیون، از دقت بالای مدل‌های هوش مصنوعی نیز بهره‌مند گردند.

نتیجه‌گیری

نتایج نشان می‌دهد که پیش‌بینی UCS Dry در حضور Is 50-Dry در میان پارامترهای ورودی تأثیر بسزایی در بهبود دقت مدل‌ها دارد. به‌عنوان نمونه، مدل با ورودی‌های Is 50-Dry، SH، Dry γ و n عملکرد بسیار خوبی از خود نشان دهد. برای پیش‌بینی Is 50-Dry نیز، مدل‌هایی که شامل پارامترهای SDI1 و BI Dry به‌عنوان ورودی بودند، عملکرد بسیار مطلوبی داشتند.

نتایج این پژوهش نشان داد که استفاده از تنها یک یا دو متغیر برای پیش‌بینی UCS Dry و Is 50-Dry سنگ‌آهک‌های زون سنندج - سیرجان، دقت خیلی بالایی را فراهم نمی‌کنند. در مقابل، مدل‌های رگرسیون چند متغیره که ترکیب چندین ویژگی فیزیکی، مکانیکی، دینامیکی و شیمیایی را لحاظ می‌کنند، عملکرد بهتری دارند و تطابق بیش‌تری با مقادیر اندازه‌گیری شده نشان می‌دهند.

با این حال، بهترین نتایج از نظر دقت و ثبات مدل، متعلق به شبکه‌های عصبی (MLP) است. این مدل‌ها توانستند با دقت

References

- Abdulaziz, Q. A. A., Awadh, S. M., & Al-Mimar, H. S. (2024). Estimation of Rock Mechanical Properties of the Hartha Formation and their Relationship to Porosity Using Well-Log Data. *The Iraqi Geological Journal*, 34-44.
- Aggarwal, C. C. (2018). *Neural networks and deep learning* (2 ed., Vol. 10). Springer, 529p. <https://doi.org/10.1007/978-3-031-29642-0>
- Ahmadi, L. (2006). The study of engineering geology and effect of carbonate rocks texture on the rate of corrosion (Hamedan Province). M.Sc. Thesis, Faculty of Science, Bu-Ali Sina University, 224p.
- Amiri, M., Amiri, M., Karrari, S. S., & Moradi, S. (2024). Predicting uniaxial compressive strength of different rocks using principal component analysis and deep neural network. *Journal of Geomine*, 2(2), 78-89. <https://doi.org/10.22077/jgm.2025.8451.1041>
- Anon, O. (1979). Classification of rocks and soils for engineering geological mapping part I: Rock and soil materials. *Bulletin of the International Association of Engineering Geology*, 19(1), 364-371. <https://doi.org/10.1007/bf02600503>
- Bieniawski, Z. T. (1973). Engineering classification of jointed rock masses. *Transactions of the South African Institution of Civil Engineers*, 15(12), 335-344.
- Deere, D. U., & Miller, R. P. (1966). Engineering classification and index properties for intact rock

- (Tech. Rep. AFWL-TR-65-116). Air Force Weapons Laboratory.
- Dousti, M. (2009). Engineering Geology Study of Limestone Rocks in North and Northwest of Hamedan. M.Sc. Thesis, Faculty of Science, Bu-Ali Sina University, 184p.
- Fadhil, A. I., Al-Adly, A. I. F., & Fattah, M. Y. (2024). Estimation of uniaxial compressive and indirect tensile strengths of intact rock from Schmidt hammer rebound number. *Journal of the Mechanical Behavior of Materials*, 32(1), 20220255.
- Franklin, J. A. & Chandra, R. (1972). The slake-durability test. *International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts*, 9(3), 325-328. [https://doi.org/10.1016/0148-9062\(72\)90001-0](https://doi.org/10.1016/0148-9062(72)90001-0)
- Gamble, J. C. (1971). Durability-plasticity Classification of Shales and Other Argillaceous Rocks. University of Illinois at Urbana-Champaign. https://books.google.de/books?id=YMUxnQEA_CAAJ
- Ghabadi, M. H., & Amiri, M. (2018). Assessment of Karst development based on lithological, morphological and structural characteristics in the Hasan Abad Galebozi region, East of Mobarakeh, East of Isfahan province. *Proceedings of the 21st Conference of the Geological Society of Iran & the 11th National Conference on Geology of Payame Noor University, Qom, Iran*.
- Ghobadi, M. H., & Naseri, F. (2016). Rock brittleness prediction using geomechanical properties of Hamekasi limestone: regression and artificial neural networks analysis. *Journal of Rock Mechanics and Geotechnical Engineering*, 8(4), 123-134.
- Hoek, E. (1983). Strength of jointed rock masses. *Geotechnique*, 33(3), 187-223.
- Ibrahim, A. F., Hiba, M., Elkatatny, S., & Ali, A. (2024). Estimation of tensile and uniaxial compressive strength of carbonate rocks from well-logging data: artificial intelligence approach. *Journal of Petroleum Exploration and Production Technology*, 14(1), 317-329. <https://doi.org/10.1007/s13202-023-01707-1>
- ISRM. (2007). The Complete ISRM Suggested Methods for Rock Characterization, Testing and Monitoring: 1974-2006. Suggested Methods Prepared by the Commission on Testing Methods, International Society for Rock Mechanics. Compilation Arranged by the ISRM Turkish National Group Ankara.
- Kapelehe, M. (2008). The study of engineering geology of Qom formation in east and northeast of Hamedan. M.Sc. Thesis, Faculty of Science, Bu-Ali Sina University, 157p.
- Khajevand, R. (2023). Prediction of the Uniaxial Compressive Strength of Rocks by Soft Computing Approaches. *Geotechnical and Geological Engineering*, 41(6), 3549-3574. <https://doi.org/10.1007/s10706-023-02473-x>
- Khanlari, G., & Abdilor, Y. (2011). Estimation of strength parameters of limestone using artificial neural networks and regression analysis. *Australian Journal of Basic and Applied Sciences*, 5(11), 1049-1053.
- Khanlari, G., Naseri, F., & Osman Pour, A. (2015). Introducing a new aggregates index (AI) using petrographical and geomechanical properties (Case study: Hamedan province limestones). *Scientific Quarterly Journal of Iranian Association of Engineering Geology*, 8(1 & 2), 51-66.
- Khanlari, G., Rafiei, B., & Osmanpour, H. (2013). Investigating the characteristics of limestones as aggregates (Case study: north and northeast of Hamadan). in *Proceedings of the 8th Conference of the Iranian Society of Engineering Geology and the Environment, Ferdowsi University of Mashhad, Mashhad, Iran*.
- Khatti, J., & Grover, K. S. (2023). Estimation of Intact Rock Uniaxial Compressive Strength Using Advanced Machine Learning. *Transportation Infrastructure Geotechnology*, 11(4), 1989-2022. <https://doi.org/10.1007/s40515-023-00357-4>
- Khatti, J., & Grover, K. S. (2024). Assessment of the uniaxial compressive strength of intact rocks: an extended comparison between machine and advanced machine learning models. *Multiscale and Multidisciplinary Modeling, Experiments and Design*, 7(4), 3301-3325. <https://doi.org/10.1007/s41939-024-00408-4>
- Koohmishi, M. (2023). Assessing the Strength of Individual Railway Ballast Aggregate by Setting up Bilateral Point Loading Condition. *Arabian*

- Journal for Science and Engineering, 48(4), 4393-4402. <https://doi.org/10.1007/s13369-022-06989-x>
- Moradi, S., Amiri, M., Rahimi Shahid, M., & Karrari, S. (2022). The presentation of simple and multiple regression relationships to the evaluation of uniaxial compressive strength sedimentary and pyroclastic rocks with usage experimental of the Schmidt hammer. *New Findings in Applied Geology*, 16(32), 92-108. <https://doi.org/10.22084/nfag.2021.24761.1480>
- Naseri, F. (2013). The Study of Geomechanical Properties of Carbonaceous Rocks From South and Southeast of Hamedan as Aggregates. M.Sc. Thesis, Faculty of Science, Bu-Ali Sina University, 188p.
- Of, M. (2005). Aggregates Impact Value of Soft Aggregates, 1970 (Reaffirmed 2003).
- Pandey, S. (2023). The Correlation Between Point Load Index and Uniaxial Compressive Strength of Various Rock Types in Rimna-Bhalma Area of Jajarkot District, Karnali Province, Nepal. *GEO WORLD*, 11(158).
- Rahimi Shahid, M., Amiri, M., Lashkaripour, G. R., & Moradi, S. (2022). The estimation of Hamedan limestone brittleness index using point load index and porosity test. *Geopersia*, 12(2), 331-352. <https://doi.org/10.22059/GEOPE.2022.341721.648656>
- Rider, M. H. (2002). The Geological Interpretation of Well Logs. Rider-French Consulting. <https://books.google.com/books?id=nN2UAAAACAAJ>
- Roberts, F. L., Kandhal, P. S., Brown, E. R., Lee, D.-Y., & Kennedy, T. W. (1996). Hot mix asphalt materials, mixture design and construction, National Asphalt Pavement Association.
- Salimi, S. (2009). Engineering Geology Study of Limestone Rocks in South and Southeast of Hamedan. M.Sc. Thesis, Faculty of Science, Bu-Ali Sina University, 176p.
- Setayeshirad, M. R., Uromeie, A., & Nikudel, M. R. (2025). Modeling of the Uniaxial Compressive Strength of Carbonate Rocks Using Statistical Analysis and Artificial Neural Network. *Rock Mechanics and Rock Engineering*, 58(6), 6025-6042. <https://doi.org/10.1007/s00603-025-04441-8>
- Shahsavari, M. (2012). The engineering geology study of Gheshlagh Olia reservoir dam site with emphasis on anisotropy of schists and solubility of limestones (Northwest of Sahneh city, Kermanshah Province). M.Sc. Thesis, Faculty of Science, Bu-Ali Sina University, 172p.
- Sharifi, Z., Lashkaripour, G., Khanehbad, M., & Rahimi Shahid, M. (2024). Estimating the uniaxial compressive strength of Esfandiar limestone strata based on their physical characteristics (Case study: North of Tabas City, Iran). *Geopersia*, 14(1), 45-62. <https://doi.org/10.22059/geope.2023.360469.648718>
- Stöcklin, J. (1968). Structural history and tectonics of Iran: a review. *AAPG bulletin*, 52(7), 1229-1258.
- Taghavi, B., Hajizadeh, F., & Moomivand, H. (2023). Comparison of artificial intelligence and multivariate regression methods in predicting the uniaxial compressive strength of rock during the specific resistivity monitoring. *Bulletin of Engineering Geology and the Environment*, 82(11), 409. <https://doi.org/10.1007/s10064-023-03415-w>
- Taghizade, D. (2013). Assessment of powder factor based on the in-situ rock mass properties in active benches of limestone mine of Urmia Cement Company. M.Sc. Thesis, Faculty of Engineering, Urmia University.
- Ünal, M., & Altunok, E. (2019). Determination of Water Absorption Properties of Natural Building Stones and Their Relation to Porosity. *E-journal of New World Sciences Academy*, 14(1), 39-45. <https://doi.org/10.12739/nwsa.2019.14.1.1a0429>
- Wu, Y., Parker, F., & Kandhal, P. S. (1998). Aggregate toughness/abrasion resistance and durability/soundness tests related to asphalt concrete performance in pavements. *Transportation Research Record*, 1638(1), 85-93.