

## Correlation of soil shear strength parameters and geotechnical characteristics (Case study: Kermanshah city)

Hasan Sharafi<sup>1\*</sup>, Reza Faraji<sup>2</sup>

1- Associate Professor, Department of Civil Engineering, Razi University, Kermanshah, Iran

2- Ph.D. candidate, Department of Civil Engineering, Razi University, Kermanshah, Iran

### ABSTRACT

Obtaining the soil shear strength parameters is necessary to know the site and at the same time costly and time-consuming. In this study, data from 129 geotechnical boreholes in Kermanshah was collected and classified. Utilizing the group method of data handling (GMDH) and a variety of inputs, models were constructed. The correlation between shear strength parameters (friction angle and cohesion) with SPT-N and geotechnical characteristics (such as fine particles and water content) was established. Predicted values for friction angle (RMSE=2.822) and cohesion (RMSE=4.161) were calculated with an approximation of  $\pm 20\%$  and  $\pm 6$  kilopascals, respectively. Comparisons with other researchers demonstrated the superior performance of the correlations, possibly attributed to variations in input parameters, the use of neural networks, and the focus on a specific study area. These correlations provide a valuable tool for estimating shear strength parameters in Kermanshah soil, enhancing their applicability in geotechnical designs. The study suggests that incorporating non-linear relationships with multiple input parameters reduces correlation errors, and limiting the study area improves correlation performance due to sediment variations in each region. The use of the prediction models presented in this study can be useful depending on the circumstances, especially in cases where it is difficult to prepare a sample, or in the early stages of the project for initial evaluations.

### ARTICLE INFO

**Receive Date:** 06 November 2023

**Revise Date:** 06 January 2024

**Accept Date:** 01 February 2024

### Keywords:

Standard penetration test

Friction angle

Cohesion

GMDH neural network

Kermanshah city

All rights reserved to Iranian Society of Structural Engineering.

doi: <https://doi.org/10.22065/jsce.2024.368738.2968>

\*Corresponding author: Hasan Sharafi

Email address: h\_sharafi@razi.ac.ir

## ژئوتکنیکی و مشخصات همبستگی پارامترهای مقاومت برشی خاک (مطالعه موردی: شهر کرمانشاه)

حسن شرفی<sup>۱\*</sup>، رضا فرجی<sup>۲</sup>

۱- دانشیار، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه رازی، کرمانشاه، ایران

۲- دانشجو دکتری مهندسی ژئوتکنیک، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه رازی، کرمانشاه، ایران

### چکیده

به منظور شناخت ساختگاه، به دست آوردن پارامترهای مقاومتی خاک امری ضروری و در عین حال هزینه بردار و زمان بر می‌باشد. بدین منظور با استفاده از اطلاعات ۱۲۹ گمانه حفر شده در سطح شهر کرمانشاه، اطلاعات ژئوتکنیکی مورد نیاز جمع‌آوری و دسته‌بندی و با استفاده از روش گروهی مدل‌سازی داده‌ها (GMDH) و مجموعه ورودی‌های مختلف، مدل‌ها ساخته شده‌اند. رابطه همبستگی میان پارامترهای مقاومت برشی (زاویه اصطکاک و چسبندگی) با عدد نفوذ استاندارد و مشخصات ژئوتکنیکی (ذرات ریزدانه، رطوبت و ...) به دست آورده شده است که با استفاده از شاخص‌های جذر میانگین مربعات خطا (RMSE) و میانگین قدر مطلق خطا (MAE)، بهترین مدل برای پیش‌بینی مشخصه‌ها انتخاب شده است. در روابط به دست آمده، برای زاویه اصطکاک ( $RMSE=2.822$ ) مقادیر پیش‌بینی شده با تقریب در حدود  $\pm 20\%$  و برای چسبندگی ( $RMSE=4.161$ ) با تقریب در حدود  $\pm 6$  کیلوپاسکال محاسبه می‌شوند. روابط به دست آمده در این پژوهش با سایر محققین مقایسه شده و برتری اثبات شده است، که می‌تواند به دلیل تنوع در پارامترهای ورودی، استفاده از شبکه عصبی و محدود کردن منطقه مورد مطالعه باشد. استفاده از این مدل‌ها برای برآورد پارامترهای مقاومت برشی خاک در مرحله اولیه پروژه‌ها پیشنهاد می‌شود.

کلمات کلیدی: عدد نفوذ استاندارد، زاویه اصطکاک، چسبندگی، شبکه عصبی GMDH، شهر کرمانشاه

شناسه دیجیتال:		سابقه مقاله:				
doi:	<a href="https://doi.org/10.22065/jsce.2024.368738.2968">https://doi.org/10.22065/jsce.2024.368738.2968</a>	چاپ	انتشار آنلاین	پذیرش	بازنگری	دریافت
	<a href="https://doi.org/10.22065/jsce.2024.368738.2968">10.22065/jsce.2024.368738.2968</a>	۱۴۰۳/۰۷/۳۰	۱۴۰۲/۱۱/۱۲	۱۴۰۲/۱۱/۱۲	۱۴۰۲/۱۰/۱۶	۱۴۰۲/۰۸/۱۵
حسن شرفی h_sharafi@razi.ac.ir				*نویسنده مسئول: پست الکترونیکی:		

## ۱- مقدمه

خاک ماده‌ای حیاتی در مهندسی عمران است، زیرا اغلب سازه‌ها بر روی زمین ساخته می‌شوند [۱]. برای بررسی پایداری شیب‌ها و خاکریزها، ظرفیت باربری پی و فشار وارده به سازه‌های حائل، مقدار مقاومت برشی خاک مورد نیاز است [۲]. عموماً، مقاومت برشی خاک با تعیین تنش مؤثر و پارامترهای خاک، مانند زاویه اصطکاک ( $\phi$ ) و چسبندگی ( $c$ ) محاسبه می‌شود [۳، ۱]. این پارامترهای خاک را می‌توان در آزمایشگاه با انجام آزمایش برش مستقیم و آزمایش سه محوری تعیین کرد [۴، ۵]. این آزمایشات زمان‌بر هستند و انجام آن‌ها روی نمونه‌ها مستلزم هزینه‌های زیادی است [۶].

بسیاری از محققین سعی در ارائه روش‌های جایگزین برای تعیین مقاومت برشی خاک داشته‌اند [۷-۱۱]. هاتاناکا<sup>۱</sup> و یوچیدا<sup>۲</sup> [۱۲]، رابطه بین زاویه اصطکاک ( $\phi$ ) و عدد نفوذ استاندارد ( $N$ ) آورده شده در رابطه ۱ را ارائه کردند.

$$\phi = (20 \cdot N_{1(60)})^{1/5} + 20 \quad (1)$$

که در آن  $N_{1(60)}$ ، عدد نفوذ اصلاح شده براساس تنش سربار می‌باشد. پک<sup>۳</sup> و همکاران [۱۳]، همبستگی بین  $N$  و  $\phi$  را به صورت گرافیکی نشان دادند که توسط ولف<sup>۴</sup> [۱۴]، به صورت رابطه ۲ ارائه شده است.

$$\phi = 27 / (1 + 0.3 N_{\phi}) - 0.0054 (N_{\phi})^2 \quad (2)$$

نتایج آزمایشگاهی گیبز<sup>۵</sup> و هلتز<sup>۶</sup> [۱۵] نشان داد که تنش مؤثر سربار ( $\sigma'$ ) می‌تواند بر  $N$  تاثیر بگذارد. کوله‌وی<sup>۷</sup> و مین<sup>۸</sup> [۱۶] رابطه  $N-\phi$  با در نظر گرفتن تنش مؤثر سربار، مطابق رابطه ۳ ارائه دادند.

$$\phi = \tan^{-1} [N_{\phi} / (12/2 + 20 / 3(\sigma' / p_a))]^{1/34} \quad (3)$$

که در آن  $P_a (=100 \text{ kPa})$ ، فشار اتمسفر می‌باشد.

سالاری و همکاران [۱۷]، روابطی را برای تخمین زاویه اصطکاک برای شن‌های خوب دانه‌بندی شده با ماسه و شن‌های رسی با ماسه بر اساس مقادیر عدد نفوذ استاندارد ارائه کردند. هتیارچی<sup>۹</sup> و براون<sup>۱۰</sup> [۴]، رویکرد جدیدی را برای تخمین خواص مقاومت برشی بر اساس عدد نفوذ استاندارد پیشنهاد کردند. در این تحقیق، دو معادله برای تخمین زاویه اصطکاک ماسه و دیگری برای تخمین مقاومت برشی زهکشی نشده (Cu) خاک رس استخراج گردیده است. جیانگوو<sup>۱۱</sup> [۱۸]، ارزیابی همبستگی بین عدد نفوذ استاندارد و پارامترهای مقاومت برشی خاک‌های چسبنده را انجام داد. رابطه تجربی بین مقدار عدد نفوذ استاندارد و پارامترهای مقاومتی، زاویه اصطکاک و چسبندگی، از طریق تحلیل رگرسیون به دست آورده شده است. محمود [۱۹]، همبستگی پارامترهای مقاومت برشی ( $\phi$  و  $c$ ) را برای خاک رس سیلتی سخت و خشک با ماسه با عدد نفوذ استاندارد تصحیح شده ارزیابی نمود و معادلات تجربی ارائه کرد. مجتبی و همکاران [۲۰]، به بررسی رابطه میان تراکم نسبی و زاویه اصطکاک براساس مقادیر عدد نفوذ استاندارد و با استفاده از نتایج آزمایشات صحرایی و آزمایشگاهی حاصل از ۶۰ گمانه ماسه‌ای پرداخته‌اند.

<sup>1</sup> Hatanaka

<sup>2</sup> Uchida

<sup>3</sup> Peck

<sup>4</sup> Wolff

<sup>5</sup> Gibbs

<sup>6</sup> Holtz

<sup>7</sup> Kulhawy

<sup>8</sup> Mayne

<sup>9</sup> Hettiarachchi

<sup>10</sup> Brown

<sup>11</sup> Jianguo

با توجه به قدرت تکنیک‌های یادگیری ماشین (ML)، در سال‌های اخیر به سرعت و با موفقیت در بسیاری از زمینه‌های مهندسی عمران [۲۱-۲۴]، علوم زمین [۲۵، ۲۶]، مهندسی ژئوتکنیک [۲۷، ۲۸] و برآورد پارامترهای خاک [۲۹، ۳۰] از جمله مقاومت برشی [۳۱-۳۵] توسعه یافته است. بسالت پور و همکاران [۳۶]، در پژوهشی نشان دادند که سیستم استنتاج فازی مبتنی بر شبکه تطبیقی (ANFIS) و مدل‌های شبکه عصبی مصنوعی (ANN)، به منظور پیش‌بینی پارامترها توانایی بیشتری نسبت به روش‌های رگرسیون معمولی دارند. هم-چنین، قریشی و همکاران [۳۷] با ارزیابی همبستگی پارامترهای مقاومت برشی و عدد نفوذ استاندارد، برتری شبکه عصبی مصنوعی را نسبت به رگرسیون معمولی در پیش‌بینی پارامترها نشان داده‌اند. شوش پاشا و همکاران [۳۸] با استفاده از شبکه عصبی  $GMDH^{12}$  به ارزیابی رابطه همبستگی زاویه اصطکاک خاک‌های دانه‌ای پرداخته‌اند. نتایج نشان می‌دهند که شبکه  $GMDH$  راهی مؤثر برای تشخیص الگوهای داده‌ها و پیش‌بینی پارامترهای هدف در خاک‌های دانه‌ای می‌باشد.

کو<sup>۱۳</sup> و همکاران [۳۹] ظرفیت باربری پی سطحی مستقر بر خاک چند لایه را با استفاده از ANN مورد بررسی قرار دادند. کران<sup>۱۴</sup> و همکاران [۴۰] پارامترهای مقاومت برشی را با هفت ورودی و با استفاده از شبکه عصبی احتمالی (PNN) پیش‌بینی کردند. خانلری و همکاران [۴۱] در تحقیقی با استفاده از پنج ورودی (درصد عبوری از الک ۲۰۰، شاخص خمیری و ...)، روابطی برای تخمین زاویه اصطکاک و چسبندگی ارائه کردند. ایکه<sup>۱۵</sup> و همکاران [۴۲] با ۸۳ نمونه خاک و با استفاده از ANN به برآورد پارامترهای مقاومت برشی خاک پرداختند. محمدی و همکاران [۴۳] با استفاده از روش‌های رگرسیون‌های چندگانه و شبکه‌های عصبی، پارامترهای مقاومت برشی را براساس هفت ورودی (حدود اتربرگ، وزن مخصوص، درصد عبوری از الک ۲۰۰ و ...) پیش‌بینی کردند. نتایج نشان دادند که پرسپترون چندلایه (MLP) دقت بالاتری نسبت به تابع پایه شعاعی (RBF) و رگرسیون خطی چندگانه نشان داد.

در این پژوهش، به منظور پیش‌بینی پارامترهای مقاومت برشی در شهر کرمانشاه، روابطی با استفاده از رگرسیون ساده و شبکه عصبی  $GMDH$ ، شامل چند ورودی، ارائه شده است. از این رو، امکان برآورد سریع پارامترهای مقاومت برشی با استفاده از سایر مشخصه‌های ژئوتکنیکی گردیده.

## ۲- روش تحقیق

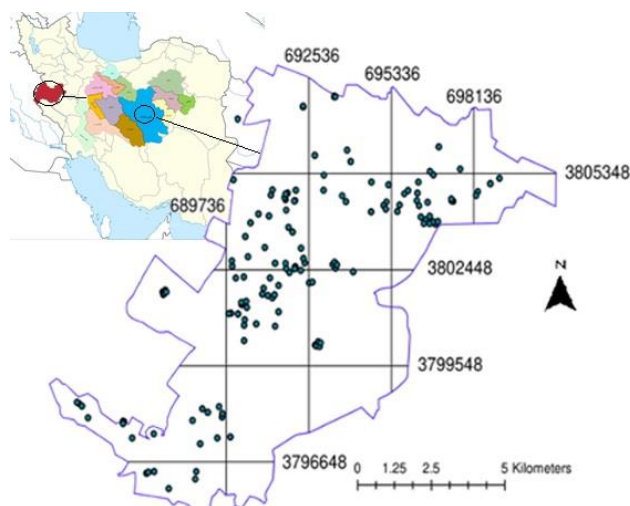
گردآوری اطلاعات ژئوتکنیکی گمانه‌های حفاری شده از طریق سازمان نظام مهندسی ساختمان استان کرمانشاه، شرکت‌های مهندسی مشاور و آزمایشگاه‌های مکانیک خاک سطح شهر انجام شده است. گزارش حاصل از گمانه‌های ژئوتکنیکی تهیه و با استفاده از مختصات و یا آدرس‌های موجود در گزارشات مکان دقیق گمانه‌ها بر روی نقشه شهر تعیین شده است، در مجموع گزارش ۱۲۹ گمانه مورد استفاده قرار گرفته است. در شکل ۱، موقعیت جغرافیایی شهر کرمانشاه (بخش مرکزی شهرستان کرمانشاه در تقسیمات کشوری) و جانمایی گمانه‌ها نشان داده شده است که اعداد نمایش داده شده براساس سامانه مختصات جهانی مرکاتور معکوس (UTM) می‌باشند. در آخر اطلاعات پارامترهای مقاومت برشی (شرایط تحکیم‌یافته-زهکشی‌شده حاصل از آزمایش برش مستقیم)، عدد SPT و مشخصات ژئوتکنیکی (شامل: درصد خاک عبوری از الک شماره ۲۰۰  $f_{200}$ ، درصد رطوبت  $(\omega)$ ، تنش مؤثر سربار  $(\sigma')$ ، حد خمیری (PL)، حد روانی (LL)) موجود برای اعماق در بازه‌های مختلف، دست‌بندی و مورد بررسی قرار گرفته‌اند که خلاصه اطلاعات در جدول ۱ ارائه شده است. براساس ارزیابی داده‌ها ۷۶٪ نمونه‌ها، CL می‌باشند (شکل ۲).

<sup>12</sup> Group Method of Data Handling

<sup>13</sup> Kuo

<sup>14</sup> Kiran

<sup>15</sup> Iyke



شکل ۱. موقعیت جغرافیایی شهر کرمانشاه و جانمایی گمانه‌های موجود

پس از آماده‌سازی داده‌ها و دسته‌بندی آن‌ها می‌بایست جهت تحلیل اطلاعات از ابزارها و نرم‌افزارهای موجود استفاده کرد. به منظور بدست آوردن ارتباط میان پارامترها از شبکه عصبی مصنوعی استفاده شده است. برنامه‌های متعددی در این زمینه موجود هستند که نرم‌افزار متلب<sup>۱۶</sup> به دلیل امکانات برنامه‌نویسی و قابلیت تغییر الگوریتم‌ها بهترین و مشهورترین آن‌ها می‌باشد، لذا در این پژوهش از نرم‌افزار مذکور استفاده شده است. شبکه‌های عصبی در ارزیابی ارتباط میان داده‌ها عملکرد بهتری نسبت به روش‌های کلاسیک دارند اما دارای محدودیت‌هایی از جمله نیاز به داده‌های ورودی زیاد جهت آموزش و عدم ارائه اطلاعات کافی برای نمایش روابط بین پارامترها می‌باشند. ضعف شبکه‌های عصبی منجر به ایجاد GMDH شد که برای آموزش آماری شبکه استفاده می‌شود [۴۴]. در این پژوهش، برای ارزیابی رابطه میان داده‌ها از شبکه عصبی GMDH استفاده شده است.

جدول ۱. توزیع آماری پارامترهای ژئوتکنیکی

پارامتر	کمینه	بیشینه	میانگین	انحراف استاندارد
$\varphi$ (degree)	۱۴	۳۷	۲۵/۵۷	۳/۹۷
c (kPa)	۱	۳۰/۴	۱۳/۱۴	۵/۸۹
$\sigma'$ (kPa)	۳۱/۴	۵۳۹/۹	۱۲۰/۸۳	۷۶/۶۷
$N_{60}$	۶	۸۸	۳۲/۹۰	۱۵/۹۸
$f_{200}$ (%)	۷	۱۰۰	۷۴/۰۴	۲۲/۶۹
$\omega$ (%)	۵	۳۵/۴	۱۸/۰۴	۵/۶۵
PL (%)	۵	۳۱	۲۰/۵۳	۳/۷۷
LL (%)	۱۸	۶۰	۳۸/۰۶	۷/۷۰


داده‌ها به دو دسته داده، دسته آموزش<sup>۱۷</sup> برای ایجاد مدل و دسته آزمون<sup>۱۸</sup> برای اعتبارسنجی مدل تقسیم می‌شوند. با توجه به مطالعات برآورد مقاومت خاک با استفاده از الگوریتم‌های ML، تحقیقات قبلی عمدتاً از نسبت‌های ۳۰/۷۰، ۲۰/۸۰ و ۱۰/۹۰ (آموزش/آزمون)

<sup>۱۶</sup> MATLAB

<sup>۱۷</sup> Training set

<sup>۱۸</sup> Testing set

برای تولید دسته‌های داده استفاده کرده‌اند [۲۲، ۳۱-۳۴، ۴۵-۴۷]. فام<sup>۱۹</sup> و همکاران [۳۱] مطالعه‌ای را بر روی تخمین مقاومت برشی خاک با تغییر اندازه دسته داده آموزش از ۳۰٪ تا ۹۰٪ انجام دادند. مطالعه نشان داد که افزایش اندازه دسته داده آموزش عملکرد آموزشی را بهبود بخشیده و مدل را پایدارتر کرده است. در مطالعه حاضر، مدل‌ها با نسبت ۷۰ به ۳۰ به ترتیب برای ایجاد و اعتبارسنجی استفاده شده‌اند. در انتها، مدل دارای کمترین خطا با روابط ارائه شده توسط سایر محققین [۱۴، ۳۷، ۴۸-۵۱] مقایسه شده است.



شکل ۲. فراوانی خاک براساس USCS<sup>۲۰</sup>

## ۲- GMDH

شبکه‌های عصبی مصنوعی به عنوان تعمیم مدل‌های ریاضی سیستم‌های عصبی بیولوژیکی توسعه یافته‌اند. اولین موج علاقه به شبکه‌های عصبی پس از معرفی نورون‌های ساده شده توسط مک‌الک<sup>۲۱</sup> و پیترس<sup>۲۲</sup> پدیدار شده است [۵۲]. یک شبکه عصبی مصنوعی از سیستم عصبی انسان تقلید می‌کند [۵۳] تا یک پردازنده هوشمند بسازد که بتواند برای مسائل رگرسیون و طبقه‌بندی با شرایط غیر خطی پیچیده استفاده شود [۵۴].

GMDH در ۱۹۶۸ توسط ریاضیدان اکرینی، الکسی ایواک‌نکو<sup>۲۳</sup> معرفی شد. این شبکه که با نام شبکه عصبی چندجمله‌ای<sup>۲۴</sup> نیز شناخته می‌شود، برای مدل کردن سیستم‌های پیچیده شامل چند ورودی  $X = (x_1, x_2, \dots, x_M)$  و یک خروجی به کار می‌رود، به طوری که مربعات خطا بین خروجی‌های اندازه‌گیری شده ( $y$ ) و پیش‌بینی شده ( $\hat{y}$ ) به حداقل برسد:

$$\sum_{i=1}^n (y_i - \hat{y}_i)^2 \rightarrow \min \quad (4)$$

رابطه میان ورودی‌ها و خروجی را می‌توان با استفاده از چندجمله‌ای ولتر-کولموگروف-گابور<sup>۲۵</sup> (رابطه ۵) بدست آورد [۵۵].

<sup>19</sup> Pham

<sup>20</sup> Unified Soil Classification System

<sup>21</sup> McCulloch

<sup>22</sup> Pitts

<sup>23</sup> Alexey Ivakhnenko

<sup>24</sup> Polynomial

$$y = a + \sum_{i=1}^M a_i x_i + \sum_{i=1}^M \sum_{j=1}^M a_{ij} x_i x_j + \dots \quad (5)$$

شکل کامل توصیف ریاضی را می توان با استفاده از چندجمله‌ای های درجه دوم که از دو متغیر تشکیل شده‌اند به صورت زیر نشان داد:

$$\hat{y} = G(x_i, x_j) = a + a_1 x_i + a_2 x_j + a_3 x_i x_j + a_4 x_i^2 + a_5 x_j^2 \quad (6)$$

ضرایب ( $a_i$ ) در رابطه ۶ با استفاده از روش‌های رگرسیون محاسبه می‌شوند، به طوری که اختلاف بین  $y$  و  $\hat{y}$  برای هر جفت  $x_i$  و  $x_j$  به عنوان متغیرهای ورودی، به حداقل برسد. گروهی از چندجمله‌ای ها با استفاده از معادله درجه دوم ارائه شده، ساخته می‌شود که ضرایب آن‌ها با روش حداقل مربعات به دست می‌آیند. به این ترتیب، ضرایب هر تابع  $G_i$  (نرون)، طوری محاسبه می‌شوند که خطا در کل مجموعه جفت داده‌های ورودی-خروجی حداقل باشد، به بیان دیگر:

$$E = \frac{\sum_{i=1}^n (y_i - G_i)^2}{n} \rightarrow \min \quad (7)$$

در الگوریتم پایه GMDH، تمام احتمالات دو متغیره (نرون) از مجموع  $M$  متغیر ورودی، برای ساخت چند جمله‌ای درجه دوم در نظر گرفته شده است. بنابراین،  $\binom{M}{2} = \frac{M(M-1)}{2}$  نرون در اولین لایه مخفی ساخته می‌شود. به عبارت دیگر، امکان ایجاد  $M$  مجموعه سه-تایی داده  $\{(y_i, x_{ip}, x_{iq}); (i=1, 2, \dots, n), p, q \in (1, 2, \dots, M)\}$ ، به صورت زیر وجود دارد.

$$\begin{bmatrix} x_{1p} & x_{1q} & y_1 \\ x_{2p} & x_{2q} & y_2 \\ \vdots & \vdots & \vdots \\ x_{np} & x_{nq} & y_n \end{bmatrix} \quad (8)$$

با استفاده از رابطه ۶ برای هر  $M$  ردیف سه عضوی، معادلات را می‌توان به صورت ماتریس نمایش داد:

$$Aa = Y \quad (9)$$

$$a = \{a_1, a_2, a_3, a_4, a_5\} \quad (10)$$

$$Y = \{y_1, y_2, y_3, y_4, y_5\}^T \quad (11)$$

که در آن،  $a$  بردار ضرایب مجهول چندجمله‌ای درجه دوم (رابطه ۶) و  $Y$  بردار پارامتر خروجی می‌باشد. با توجه به رابطه ۹ می‌توان دریافت که:

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}x_{1q} & x_{1p}^2 & x_{1q}^2 \\ 1 & x_{2p} & x_{2q} & x_{2p}x_{2q} & x_{2p}^2 & x_{2q}^2 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{np} & x_{nq} & x_{np}x_{nq} & x_{np}^2 & x_{nq}^2 \end{bmatrix} \quad (12)$$

روش حداقل مربعات از تحلیل رگرسیون چندگانه، امکان حل معادلات را به صورت زیر فراهم می‌سازد:

$$a = (A^T A)^{-1} A^T Y \quad (13)$$

این معادله بهترین بردار ضرایب رابطه ۶ را برای  $M$  مجموعه سه‌تایی ایجاد می‌کند.

## ۲-۲- ارزیابی خطا

برای ارزیابی دقت روش‌ها در تخمین پارامترهای هدف بر اساس ورودی‌ها نیازمند شاخص‌هایی برای بررسی می‌باشیم، که به قرار زیر می‌باشند:

- جذر میانگین مربعات خطا (RMSE):

$$RMSE = \left[ \frac{1}{n} \sum_{i=1}^n (e_i)^2 \right]^{1/2} \quad (14)$$

- میانگین قدر مطلق خطا (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (15)$$

که در روابط فوق  $e_i = y_i - \hat{y}_i$  می‌باشد. کم بودن مقدار پارامترهای فوق بیانگر دقت قابل قبول روش و برتری آن نسبت به روش دیگر است.

## ۳- روش اندازه‌گیری

داده‌هایی که برای ساخت مدل به عنوان پارامترهای ورودی و خروجی استفاده شده‌اند، براساس استانداردهای موجود در جدول ۲ بدست آمده‌اند.

جدول ۲. استانداردهای مورد استفاده برای تعیین پارامترها

پارامتر	استاندارد
زاویه اصطکاک و چسبندگی	ASTM D3080 [56]
عدد نفوذ استاندارد	ASTM D1586 [57]
درصد خاک عبوری از الک شماره ۲۰۰	ASTM D6913 [58]
درصد رطوبت	ASTM D2216 [59]
چگالی طبیعی	ASTM D7263 [60]
حد خمیری، حد روانی و شاخص خمیری	ASTM D4318 [61]

## ۳-۱- اصلاح عدد نفوذ استاندارد

همواره مشاهده شده، مقادیر  $N$  بدست آمده با استفاده از تجهیزات متفاوت در گمانه‌های مجاور قابل تکرار نیست [۶۲]. از این رو می‌بایست، عدد بدست آمده با استفاده از ضرایبی برای در نظر گرفتن تاثیر فاکتورهای تنش موثر سربار ( $C_N$ )، کارایی چکش ( $\eta_h$ )، طول میله ( $\eta_r$ )، نمونه‌گیر ( $\eta_s$ ) و قطر گمانه ( $\eta_b$ )، مطابق رابطه ۱۶ اصلاح شود.

$$N_{Erb} = \eta_h \cdot \eta_r \cdot \eta_s \cdot \eta_b \cdot N = \frac{E_r \cdot \eta_r \cdot \eta_s \cdot \eta_b \cdot N}{E_{rb}} \quad (16)$$

که  $E_r$  و  $E_{rb}$  به ترتیب کارایی چکش و نسبت انرژی استاندارد می‌باشند. در این پژوهش،  $E_r = 0.8$ ،  $\eta_s = 1$ ،  $\eta_b = 1$  و  $\eta_r$  براساس عمق انجام آزمایش، مطابق جدول ۳ در نظر گرفته شده است.

جدول ۳. ضریب اصلاح طول میله ( $\eta_r$ )

طول میله (متر)	$\eta_r$
۰-۴	۰/۷۵
۴-۶	۰/۸۵
۶-۱۰	۰/۹۵
>۱۰	۱/۰۰

پیشنهاداتی برای مقدار نسبت انرژی استاندارد وجود دارد، که با توجه به نظر سید<sup>۲۶</sup> و همکاران [۶۳] و اسکمپتون<sup>۲۷</sup> [۶۴]،  $E_{rb}$  برابر ۶۰ در نظر گرفته شده است.

در صورت اصلاح  $N_{Erb}$  برای تنش موثر سربار، به صورت  $N_{I(Erb)}$  نمایش داده خواهد شد.

$$N_{I(Erb)} = C_N \cdot N_{Erb} \quad (17)$$

روابط متعددی برای  $C_N$  ارائه شده است که رابطه لیاو<sup>۲۸</sup> و ویتمن<sup>۲۹</sup> [۶۵] مورد استفاده قرار گرفته است.

$$C_N = \left[ \frac{95/76}{\sigma'} \right]^{1/5} \quad (18)$$

که در آن  $\sigma'$ ، تنش موثر سربار بر حسب kPa می‌باشد.

#### ۴- تحلیل داده‌ها و تفسیر نتایج

نتایج حاصل از انجام آزمایشات بر روی گمانه‌های حفر شده در پهنه‌ی شهر کرمانشاه به منظور ارائه روش جایگزین برای برآورد پارامترهای مقاومت برشی مورد بررسی و تحلیل قرار گرفته است و با روابط سایر محققین مورد مقایسه قرار گرفته‌اند.

#### ۴-۱- تحلیل رگرسیون

تحلیل رگرسیون معمولاً برای استخراج روابط تجربی استفاده می‌شود [۱۹، ۳۷، ۵۱]. به منظور به دست آوردن روابطی برای پیش‌بینی پارامترهای مقاومت برشی در شهر کرمانشاه، از نتایج آزمون برش مستقیم و  $N_{60}$  استفاده گردیده است. ارزیابی روابط  $\phi$  و  $c$  در جدول ۴ ارائه شده است.

جدول ۴. روابط پارامترهای مقاومت برشی براساس  $N_{60}$

<sup>26</sup> seed

<sup>27</sup> Skempton

<sup>28</sup> Liao

<sup>29</sup> Whitman

c		φ	
RMSE	روش رگرسیون	RMSE	روش رگرسیون
۵/۸۰۰	خطی	۳/۶۱۲	خطی
۵/۸۷۷	نمایی	۳/۶۱۸	نمایی
۵/۸۰۴	توانی	۳/۶۹۶	توانی
۵/۵۷۹	درجه دو	۳/۵۹۶	درجه دو

معادلات خطی بدست آمده برای پیش‌بینی پارامترهای مقاومت برشی بر اساس  $N_{60}$  برای همه خاک‌ها در روابط ۱۹ و ۲۰ ارائه شده‌اند :

$$\varphi = 0.1029N_{60} + 22/18 \quad (19)$$

$$c(\text{kPa}) = 0.1047N_{60} + 9/7 \quad (20)$$

#### ۲-۴- نتایج شبکه عصبی GMDH

پارامترهای مقاومت برشی را می‌توان به صورت تابعی از سایر مشخصه‌های ژئوتکنیکی در نظر گرفت. از این رو، به منظور کمینه کردن خطا در مقادیر پیش‌بینی شده پارامترهای مقاومت برشی و پیدا کردن مجموعه ورودی با ارتباط بیشتر، چندین مدل با پارامترهای ورودی متفاوت شامل: عدد نفوذ استاندارد اصلاح شده برای شرایط محل ( $N_{60}$ )، عدد نفوذ استاندارد اصلاح شده با در نظر گرفتن سربار ( $N_{1(60)}$ )، درصد خاک عبوری از الک شماره ۲۰۰ ( $f_{200}$ )، درصد رطوبت ( $\omega$ )، تنش موثر سربار ( $\sigma'$ )، حد خمیری (PL)، حد روانی (LL) و شاخص خمیری (PI) ساخته شده و با شبکه GMDH مورد امتحان قرار گرفته شده است.

اختلاف در مقدار پیش‌بینی شده در مدل‌های مختلف بدلیل اختلاف در همبستگی میان پارامترهای ورودی با خروجی ( $\varphi$  و  $c$ ) می‌باشد. بدیهی است مدل‌هایی که دارای خطای کمتری می‌باشند، پارامترهای ورودی ارتباط بیشتری با خروجی‌ها داشته‌اند. هم‌چنین برای انتخاب بهترین مدل، باید توجه به مقدار خطا در پیش‌بینی داده‌های آزمون داشت، زیرا این داده‌ها نقشی در ایجاد مدل نداشته‌اند و کم بودن خطا در برآورد این داده‌ها نشان‌دهنده‌ی ارتباط بیشتر پارامترهای ورودی با خروجی می‌باشد. با توجه به موارد گفته شده، بهترین مدل انتخاب (جدول ۵ و ۶) و در پیوست ارائه گردیده است.

جدول ۵. نتایج مدل‌های شبکه GMDH (زاویه اصطکاک)

RMSE		پارامترهای ورودی	نام مدل
آزمون	آموزش		
۳/۰۱۲	۲/۹۲۸	$\varphi = f(N_{1(60)}, f_{200}, \omega)$	GMDH_Phi_#1
۲/۹۴۶	۲/۸۴۶	$\varphi = f(N_{60}, f_{200}, \omega)$	GMDH_Phi_#2
۳/۲۲۵	۲/۸۸۹	$\varphi = f(N_{60}, \sigma', f_{200}, \omega)$	GMDH_Phi_#3
۳/۱۲۴	۲/۸۸۴	$\varphi = f(N_{1(60)}, f_{200})$	GMDH_Phi_#4
۳/۰۵۳	۲/۸۲۵	$\varphi = f(N_{60}, f_{200})$	GMDH_Phi_#5
۲/۷۷۱	۲/۸۲۲	$\varphi = f(N_{60}, \sigma', f_{200})$	GMDH_Phi_#6*

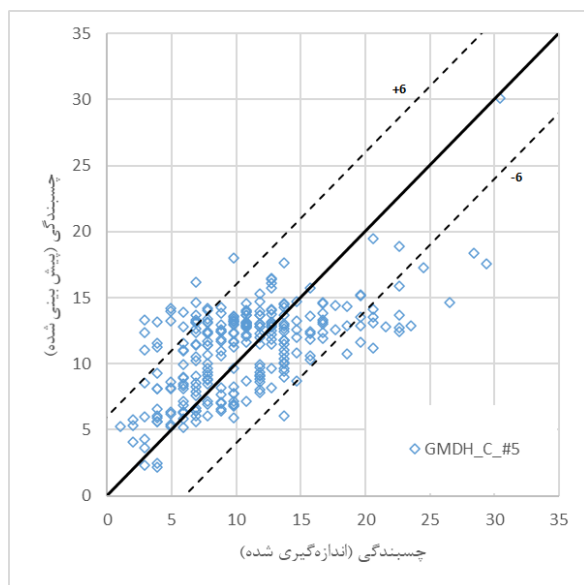
\* مدل انتخاب شده

جدول ۶. نتایج مدل های شبکه GMDH (چسبندگی)

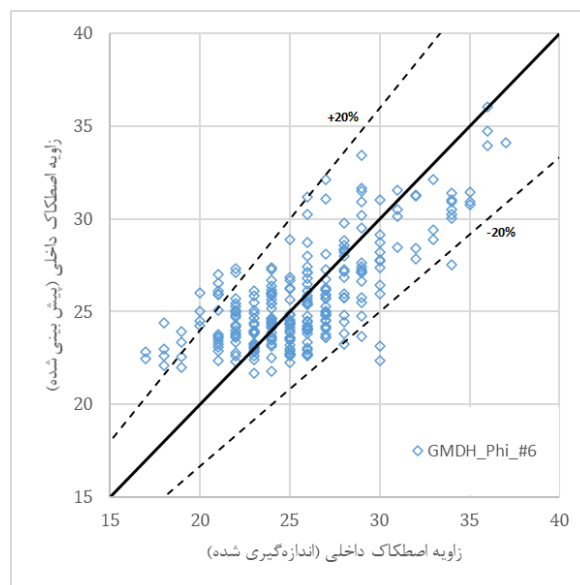
RMSE		پارامترهای ورودی	نام مدل
آزمون	آموزش		
۴/۵۲۶	۴/۱۹۸	$c = f(N_{1(60)}, f_{200}, \omega, PI)$	GMDH_C_#1
۴/۶۱۴	۴/۲۳۴	$c = f(N_{1(60)}, f_{200}, \omega, LL, PL)$	GMDH_C_#2
۴/۴۱۲	۴/۱۷۰	$c = f(N_{60}, \sigma', f_{200}, \omega, PI)$	GMDH_C_#3
۴/۵۵۱	۴/۱۹۴	$c = f(N_{60}, \sigma', f_{200}, \omega, LL, PL)$	GMDH_C_#4
۴/۲۸۹	۴/۱۶۱	$c = f(\sigma', f_{200}, \omega, PI)$	GMDH_C_#5*
۴/۳۷۵	۴/۲۲۲	$c = f(\sigma', f_{200}, \omega, LL, PL)$	GMDH_C_#6

\* مدل انتخاب شده

با توجه به ماهیت پیچیده خاک های رسی، پیش بینی چسبندگی نسبت به زاویه اصطکاک دشوارتر بوده که در نتایج ارائه شده در جداول مشهود می باشد. زاویه اصطکاک و چسبندگی پیش بینی شده بر حسب مقادیر اندازه گیری شده در شکل ۳ ارائه شده است. مطابق نتایج، برای زاویه اصطکاک داده های پیش بینی شده با تقریب در حدود  $\pm 20\%$  و برای چسبندگی در حدود  $\pm 6$  کیلوپاسکال قابل محاسبه می باشند.



ب



الف

شکل ۳. نمودار مقادیر پیش بینی شده بر حسب اندازه گیری شده الف) زاویه اصطکاک (درجه) ب) چسبندگی (کیلوپاسکال)

## ۳-۴ - مقایسه و صحت‌سنجی نتایج

پیش‌بینی پارامترهای مقاومت برشی خاک با روش‌های رگرسیون (جدول ۴) و GMDH (جدول ۵ و ۶) ارائه شده است. به طور کلی مدل‌های GMDH نسبت به مدل‌های رگرسیونی عملکرد بهتری در پیش‌بینی مقاومت برشی خاک داشته‌اند که می‌تواند ناشی از تنوع نوع خاک و در نتیجه افزایش تعداد پارامترهای مؤثر در تعیین مقاومت برشی باشد که در مدل‌های رگرسیونی در نظر گرفته نشده است.

به منظور مقایسه نتایج از روابط دیگر محققین که در جدول ۷ آورده شده، استفاده گردیده است. مقدار خطا در پیش‌بینی مقادیر برای روابط موجود در این تحقیق و روابط جدول ۷، برای زاویه اصطکاک داخلی و چسبندگی به ترتیب در جدول‌های ۸ و ۹ آورده شده است. همچنین، نمودار مقادیر پیش‌بینی شده برحسب اندازه‌گیری شده برای زاویه اصطکاک و چسبندگی در شکل ۴ آمده است. همانطور که در شکل ۴-الف مشاهده می‌شود، روابط ۲۱ الی ۲۳ مقدار زاویه اصطکاک را دست بالا پیش‌بینی می‌کند و در میان روابط موجود در جدول ۷، عباسی [۵۰]، کمترین مقدار خطا را دارد. با توجه به شکل ۴-ب، به طور کلی، قریشی و همکاران [۳۷] و کومار و همکاران [۵۱]، مقدار c را بیشتر برآورد می‌کنند. همچنین، براساس روابط ۲۵ و ۲۶ که برای دو نوع رس با خصوصیات متفاوت ارائه شده‌اند، می‌توان دریافت که در پیش‌بینی پارامترهای مقاومت برشی، شرایط زمین‌شناسی و چگونگی تشکیل رسوبات موجب ایجاد عدم قطعیت می‌شوند و خطا را افزایش می‌دهند، که می‌بایست برای هر منطقه روابط براساس اطلاعات گمانه‌های حفر شده محلی استخراج گردد و یا قبل از استفاده از روابط موجود با داده‌های منطقه مورد نظر، صحت‌سنجی گردند.

مطابق نتایج، کمترین خطا در پیش‌بینی زاویه اصطکاک داخلی و چسبندگی، مربوط به روابط استخراج شده در این پژوهش (شبکه GMDH) می‌باشد، که با توجه به استفاده از تعداد پارامترهای مرتبط ورودی بیشتر نسبت به دیگر روابط، قدرت شبکه‌های عصبی در ارزیابی ارتباط میان پارامترها و محدود کردن منطقه مورد مطالعه، چنین نتیجه‌ای بدست آمده است.

جدول ۷. روابط مورد استفاده در مقایسه مدل‌ها (زاویه اصطکاک و چسبندگی)

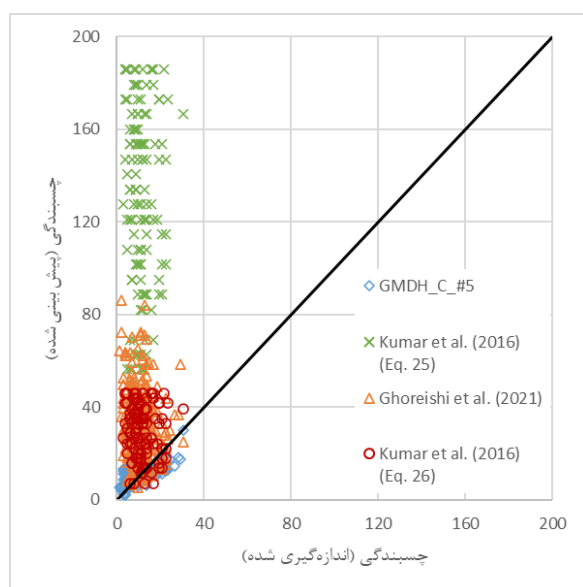
رابطه ارائه شده	محقق/محققین
$\varphi = 27/1 + 0/3N_{\phi} - 0/00054(N_{\phi})^2$	Wolff (1989) [14] (۲۱)
$\varphi = (15N_{\phi})^{1/5} + 15 \leq 45$	Japan Road Association (1990) [49] (۲۲)
$\varphi = (18N_{\phi}')^{1/5} + 15$	Shioi and Fukui (1982) [48] (۲۳)
$\varphi = 0/298N_{\phi} + 19/2$	عباسی (۱۳۹۱) [۵۰] (۲۴)
$C(kpa) = -2/2049 + 6/484N$ $2 < N < 30$ (Cohesive soils)	Kumar et al. (2016) [51] (۲۵)
$C(kpa) = -16/5 + 2/15N$ $10 < N < 30$ (Intermediate soils)	Kumar et al. (2016) [51] (۲۶)
$C(kpa) = 0/981N_{\phi} + 0/3924$	Ghoreishi et al. (2021) [37] (۲۷)

جدول ۸. نتایج مقایسه روابط (زاویه اصطکاک)

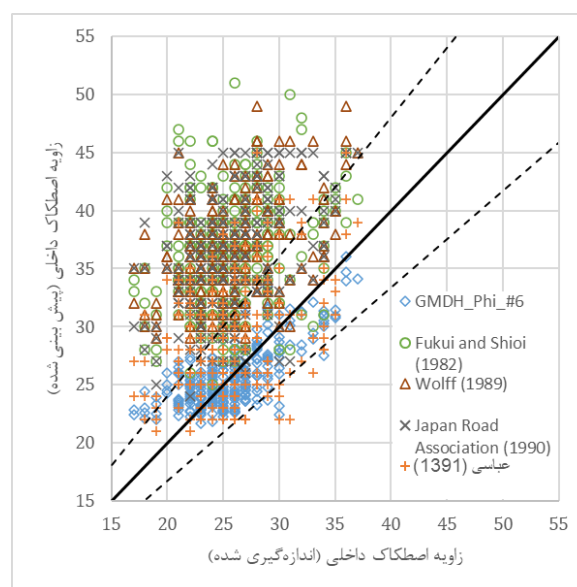
MAE	RMSE	نام مدل/محقق
۲/۲	۲/۸	GMDH_Phi_#6
۱۰/۷	۱۱/۶	Wolff (1989)
۱۰/۹	۱۲/۰	Japan Road Association (1990)
۱۰/۷	۱۱/۹	Shioi and Fukui (1982)
۴/۸	۵/۹	عباسی (۱۳۹۱)

جدول ۹. نتایج مقایسه روابط (چسبندگی)

MAE	RMSE	نام مدل/محقق
۳/۴	۴/۲	GMDH_C_#5
۱۱۴/۲	۱۲۱/۴	Kumar et al. (2016) (Eq. 25)
۱۸/۴	۳۱/۳	Kumar et al. (2016) (Eq. 26)
۲۱/۸	۳۵/۵	Ghoreishi et al. (2021)



ب



الف

شکل ۴. نمودار مقادیر پیش‌بینی شده برحسب اندازه‌گیری شده (مقایسه روابط) الف) زاویه اصطکاک (درجه) ب) چسبندگی (کیلوپاسکال)

## ۴- تحلیل حساسیت

مدل‌های چند جمله‌ای توسعه‌یافته با استفاده از شبکه GMDH، به شکل معادلات چند ورودی می‌باشد و بنابراین تأثیر پارامترهای ورودی بر خروجی مدل آشکار نیست. بنابراین، تحلیل حساسیت مدل توسعه‌یافته برای ارزیابی تأثیر پارامترهای ورودی بر مدل انجام می‌شود. با توجه به هدف مورد نظر، روش‌های تحلیل حساسیت را می‌توان به چند گروه تقسیم کرد [۶۶]:

- تحلیل حساسیت محلی<sup>۳۰</sup> و جامع<sup>۳۱</sup>

در تحلیل حساسیت محلی، تغییرات خروجی در برابر تغییرات یک فاکتور ورودی حول مقداری خاص در نظر گرفته می‌شود، در حالی که در تحلیل حساسیت جامع تغییرات در کل فضای عوامل ورودی مورد بررسی قرار می‌گیرد.

- تحلیل حساسیت کمی<sup>۳۲</sup> و کیفی<sup>۳۳</sup>

تحلیل حساسیت کمی برای روش‌هایی استفاده می‌شود که هر ورودی با ارزیابی کمی و قابل تکرار از تأثیر نسبی خود، معمولاً از طریق مجموعه‌ای از شاخص‌های حساسیت، مرتبط گردد. اما در تحلیل حساسیت کیفی، حساسیت با بررسی بصری پیش‌بینی‌های مدل یا ابزارهای بصری‌سازی خاص مانند نمودارهای گردبادی، نمودارهای اسکاتر ارزیابی می‌شود.

- یک در زمان<sup>۳۴</sup> (OAT) و همه در یک زمان<sup>۳۵</sup> (AAT)

تمایز بین روش‌های OAT و AAT بر اساس رویکرد اتخاذ شده برای انتخاب نمونه‌های ورودی است:

در روش‌های OAT، تغییرات خروجی با تغییر یک عامل ورودی بررسی می‌شوند، در حالی که بقیه ثابت نگه داشته می‌شوند.

در روش‌های AAT، تغییرات خروجی با تغییر همه عوامل ورودی به طور همزمان بررسی می‌شوند. بنابراین حساسیت به هر فاکتور، به تأثیر مستقیم آن و همچنین تأثیر مشترک ناشی از اندرکنش سایر فاکتورها بستگی دارد.

برای انجام تحلیل، از روش دامنه کسینوس [۶۷، ۶۸] استفاده شده است. این روش در معادله زیر نمایش داده می‌شود:

$$R_{ij} = \frac{\sum_{k=1}^n (x_{ik} \times x_{jk})}{\left[ \sum_{k=1}^n x_{ik}^2 \sum_{k=1}^n x_{jk}^2 \right]^{1/2}} \quad (28)$$

$x_i$  و  $x_j$  به ترتیب پارامترهای ورودی و خروجی و  $n$  تعداد داده‌ها می‌باشد.  $R_{ij}$  که بین ۰ و ۱ قرار دارد، قدرت همبستگی بین هر پارامتر ورودی و هدف را نشان می‌دهد. به عبارت دیگر، اگر متغیر خروجی هیچ ارتباطی با ورودی نداشته باشد، مقدار  $R_{ij}$  صفر است، در حالی که مقدار  $R_{ij}$  نزدیک به ۱ تأثیر بیشتر پارامتر ورودی بر خروجی را نشان می‌دهد. قدرت همبستگی به دست آمده در شکل (۵) آورده شده است. همانطور که در این شکل نشان داده شده است،  $N_{60}$  و  $f_{200}$  به ترتیب تأثیرگذارترین پارامترها بر روی خروجی‌های  $\varphi$  و  $c$  هستند.

<sup>30</sup> Local


<sup>31</sup> Global

<sup>32</sup> Quantitative

<sup>33</sup> Qualitative

<sup>34</sup> One-At-a-Time (OAT)

<sup>35</sup> All-At-a-Time (AAT)



شکل ۵. تأثیر هر پارامتر ورودی بر مدل‌های الف) زاویه اصطکاک ب) چسبندگی

## ۵- بحث و نتیجه‌گیری

در این تحقیق به منظور پیش‌بینی پارامترهای مقاومت برشی ( $c$  و  $\phi$ ) خاک، شبکه عصبی GMDH و رگرسیون ساده بررسی شده است. برای ارزیابی عملکرد روش‌ها از شاخص‌های RMSE و MAE استفاده شده است. شبکه عصبی با استفاده از ورودی‌های متنوع آموزش داده شد. در بین شش مدل GMDH برای تخمین  $\phi$ ، مدلی که ورودی‌های آن N60،  $\sigma'$  و f200 می‌باشد، با  $RMSE=2/822$  بهترین مدل است. GMDH\_C\_#5 بهترین مدل برای تخمین چسبندگی با  $RMSE=4/161$  می‌باشد. ورودی‌های این مدل  $\sigma'$ ، f200،  $\omega$  و PI بودند. براساس تحلیل حساسیت به روش دامنه کسینوس، تأثیرگذارترین پارامترهای ورودی بر  $c$  و  $\phi$  به ترتیب، f200 و N60 می‌باشند. رگرسیون ساده تک متغیره (N60) در پنج مدل برای  $c$  و  $\phi$  انجام شده است. مقایسه عملکرد مدل‌های GMDH و رگرسیون ساده برای تخمین پارامترهای مقاومت برشی نشان دادند که رابطه غیرخطی در پیش‌بینی پارامترهای مقاومت برشی، منجر به ارائه روابط همبستگی دقیق‌تری می‌شود و همچنین پارامترهای مقاومت برشی خاک تابعی از عوامل مختلف می‌باشند که با وارد نمودن این پارامترها در رابطه، پیش‌بینی بهتری صورت می‌گیرد. برتری مدل‌های شبکه عصبی بر روابط پیشین نیز اثبات شده است که علاوه بر موارد مذکور می‌تواند به دلیل محدود کردن منطقه مورد مطالعه نیز باشد. در عمل، به دلیل سادگی برآورد پارامترهای ورودی، استفاده از این مدل‌ها برای برآورد پارامترهای مقاومت برشی خاک در مرحله اولیه پروژه‌ها پیشنهاد می‌شود.

## مراجع

- [۱] Das, B. M., & Sobhan, K. (2013). *Principles of geotechnical engineering*. Cengage learning .
- [۲] Vanapalli, S., Fredlund, D., Pufahl, D., & Clifton, A. (1996). Model for the prediction of shear strength with respect to soil suction. *Canadian geotechnical journal*, 33(3), 379-392 .
- [۳] Kaya, A. (2009). Residual and fully softened strength evaluation of soils using artificial neural networks. *Geotechnical and Geological Engineering*, 27, 281-288 .
- [۴] Hettiarachchi, H., & Brown, T. (2009). Use of SPT blow counts to estimate shear strength properties of soils: energy balance approach. *Journal of Geotechnical and Geoenvironmental engineering*, 135(6), 830-834 .

- [۵] Motaghedi, H., & Eslami, A. (2014). Analytical approach for determination of soil shear strength parameters from CPT and CPTu data. *Arabian Journal for Science and Engineering*, 39(6), 4363-4376 .
- [۶] Nguyen, Q. H., Ly, H.-B., Ho, L. S., Al-Ansari, N., Le, H. V., Tran, V. Q., Prakash, I., & Pham, B. T. (2021). Influence of data splitting on performance of machine learning models in prediction of shear strength of soil. *Mathematical Problems in Engineering*, 2021, 1-15 .
- [۷] Cha, M., & Cho, G.-C. (2007). Shear strength estimation of sandy soils using shear wave velocity. *Geotechnical Testing Journal*. ۴۹۵-۴۸۴ ,(۶)۳۰ .
- [۸] Garven, E., & Vanapalli, S. (2006). Evaluation of empirical procedures for predicting the shear strength of unsaturated soils. In *Unsaturated soils 2006* (pp. 2570-2592) .
- [۹] Ohu, J. O., Raghavan, G., McKyes, E., & Mehuys, G. (۱۹۸۶). Shear strength prediction of compacted soils with varying added organic matter contents. *Transactions of the ASAE*, 29(2), 351-355 .
- [۱۰] Tiwari, B., & Marui, H. (2005). A new method for the correlation of residual shear strength of the soil with mineralogical composition. *Journal of Geotechnical and Geoenvironmental engineering*, 131(9), 1139-1150 .
- [۱۱] Hossain, M. M., Sultana, N., & Malo, R. C. (2020). Correlations between CPT, SPT and Soil Parameters for Khulna, Bangladesh. *India: MAT Journals Pvt. Ltd* .
- [۱۲] Hatanaka, M., & Uchida, A. (1996). Empirical correlation between penetration resistance and internal friction angle of sandy soils. *Soils and foundations*, 36(4), 1-9 .
- [۱۳] Peck, R. B., Hanson, W. E., & Thornburn, T. H. (1991). *Foundation engineering*. John Wiley & Sons .
- [۱۴] Wolff, T. F. (1989). Pile capacity prediction using parameter functions. Predicted and observed axial behavior of piles: results of a pile prediction symposium ,
- [۱۵] Gibbs, H. J. (1956). Research on determining the density of sands by spoon penetration testing .
- [۱۶] Kulhawy, F. H., & Mayne, P. W. (1990). *Manual on estimating soil properties for foundation design* .
- [۱۷] Salari, P., Lashkaripour, G., & Ghafoori, M. (2015). Presentation of empirical equations for estimating internal friction angle of SP and SC soils in Mashhad, Iran using standard penetration and direct shear tests and comparison with previous equations. *International Journal of Geography and Geology*, 4(5), 89 .
- [۱۸] Jianguo, C. (2012). Correlation Analysis of SPT $\sqrt{N}$  Values and Cohesion $\square$  and International Angle of a Clay. *Soil Engineering and Foundation*, 26(4), 91 .
- [۱۹] Mahmoud, M. A. A. N. (2013). Reliability of using standard penetration test (SPT) in predicting properties of silty clay with sand soil. *International Journal of Civil and Structural Engineering*, 3(3), 545 .
- [۲۰] Mujtaba, H., Farooq, K., Sivakugan, N., & Das, B. M. (2018). Evaluation of relative density and friction angle based on SPT-N values. *KSCE Journal of Civil Engineering*, 22, 572-581 .
- [۲۱] Ly, H.-B., Le, T.-T., Vu, H.-L. T., Tran, V. Q., Le, L. M., & Pham, B. T. (2020). Computational hybrid machine learning based prediction of shear capacity for steel fiber reinforced concrete beams. *Sustainability*, 12(7), 2709 .
- [۲۲] Dao, D. V., Adeli, H., Ly, H.-B., Le, L. M., Le, V. M., Le, T.-T., & Pham, B. T. (2020). A sensitivity and robustness analysis of GPR and ANN for high-performance concrete compressive strength prediction using a Monte Carlo simulation. *Sustainability*, 12(3), 830 .
- [۲۳] Dao, D. V., Ly, H.-B., Vu, H.-L. T., Le, T.-T., & Pham, B. T. (2020). Investigation and optimization of the C-ANN structure in predicting the compressive strength of foamed concrete. *Materials*, 13(5), 1072 .
- [۲۴] Ly, H.-B., Pham, B. T., Dao, D. V., Le, V. M., Le, L. M., & Le, T.-T. (2019). Improvement of ANFIS model for prediction of compressive strength of manufactured sand concrete. *Applied Sciences*, 9(18), 3841 .

- [۲۵] Chen, W., Li, Y., Xue, W., Shahabi, H., Li, S., Hong, H., Wang, X., Bian, H., Zhang, S & Pradhan, B. (2020). Modeling flood susceptibility using data-driven approaches of naïve bayes tree, alternating decision tree, and random forest methods. *Science of The Total Environment*, 701, 134979 .
- [۲۶] Nhu, V.-H., Mohammadi, A., Shahabi, H., Ahmad ,B. B., Al-Ansari, N., Shirzadi, A., Clague, J. J., Jaafari, A., Chen, W., & Nguyen, H. (2020). Landslide susceptibility mapping using machine learning algorithms and remote sensing data in a tropical environment. *International journal of environmental research and public health*, 17(14), 4933 .
- [۲۷] Abedini, M., Ghasemian, B., Shirzadi, A., Shahabi, H., Chapi, K., Pham, B. T., Bin Ahmad, B., & Tien Bui, D. (2019). A novel hybrid approach of bayesian logistic regression and its ensembles for landslide susceptibility assessment. *Geocarto International*, 34(13), 1427-1457 .
- [۲۸] Pham, B. T., Prakash, I., Khosravi, K., Chapi, K., Trinh, P. T., Ngo, T. Q., Hosseini, S. V., & Bui, D. T. (2019). A comparison of Support Vector Machines and Bayesian algorithms for landslide susceptibility modelling. *Geocarto International*, 34(13), 1385-1407 .
- [۲۹] Nguyen, M. D., Pham, B. T., Tuyen, T. T., Hai Yen, H. P., Prakash, I., Vu, T. T., Chapi, K., Shirzadi, A., Shahabi, H., & Dou, J. (2019). Development of an artificial intelligence approach for prediction of consolidation coefficient of soft soil: a sensitivity analysis. *The Open Construction & Building Technology Journal*, 13 .(۱)
- [۳۰] Pham, B. T., Nguyen, M. D., Van Dao, D., Prakash, I., Ly, H.-B., Le, T.-T., Ho, L. S ,Nguyen, K. T., Ngo, T. Q., & Hoang, V. (2019). Development of artificial intelligence models for the prediction of Compression Coefficient of soil: An application of Monte Carlo sensitivity analysis. *Science of The Total Environment*, 679, 172-184 .
- [۳۱] Pham, B. T., Qi, C., Ho, L. S., Nguyen-Thoi, T., Al-Ansari, N., Nguyen, M. D., Nguyen, H. D., Ly, H.-B., Le, H. V., & Prakash, I. (2020). A novel hybrid soft computing model using random forest and particle swarm optimization for estimation of undrained shear strength of soil. *Sustainability*, 12(6), 2218 .
- [۳۲] Moayedi, H., Gör, M., Khari, M., Foong, L. K., Bahiraei, M., & Bui, D. T. (2020). Hybridizing four wise neural-metaheuristic paradigms in predicting soil shear strength. *Measurement*, 156, 107576 .
- [۳۳] Nhu, V.-H., Hoang, N.-D., Duong, V.-B., Vu, H.-D., & Tien Bui, D. (2020). A hybrid computational intelligence approach for predicting soil shear strength for urban housing construction: a case study at Vinhomes Imperia project, Hai Phong city (Vietnam ).*Engineering with Computers*, 36(2), 603-616 .
- [۳۴] Moayedi, H., Tien Bui, D., Anastasios, D., & Kalantar, B. (2019). Spotted hyena optimizer and ant lion optimization in predicting the shear strength of soil. *Applied Sciences*, 9(22), 4738 .
- [۳۵] Moayedi ,H., Tien Bui, D., Dounis, A., Kok Foong, L., & Kalantar, B. (2019). Novel nature-inspired hybrids of neural computing for estimating soil shear strength. *Applied Sciences*, 9(21), 4643 .
- [۳۶] Besalatpour, A., Hajabbasi, M., Ayoubi, S., Afyuni, M., Jalalian, A., & Schulin, R. (2012). Soil shear strength prediction using intelligent systems: artificial neural networks and an adaptive neuro-fuzzy inference system. *Soil science and plant nutrition*, 58(2), 149-160 .
- [۳۷] Ghoreishi, B., Khaleghi Esfahani, M ,Alizadeh Lushabi, N., Amini, O., Aghamolaie, I., Hashim, N. A. A. N., & Alizadeh, S. M. S. (2021). Assessment of geotechnical properties and determination of shear strength parameters. *Geotechnical and Geological Engineering*, 39, 461-478 .
- [۳۸] Shooshpasha, I., Amiri, I., & MolaAbasi, H. (2015). AN INVESTIGATION OF FRICTION ANGLE CORRELATION WITH GEOTECHNICAL PROPERTIES FOR GRANULAR SOILS USING GMDH TYPE NEURAL NETWORKS (RESEARCH NOTE) .
- [۳۹] Kuo, Y., Jaksa, M., Lyamin, A., & Kaggwa, W. (2009). ANN-based model for predicting the bearing capacity of strip footing on multi-layered cohesive soil. *Computers and Geotechnics*, 36(3), 503-516 .
- [۴۰] Kiran, S., Lal, B., & Tripathy, S. (2016). Shear strength prediction of soil based on probabilistic neural network *Indian J. Sci. Technol*, 9(41), 1-6 .

- [۴۱] Khanlari, G., Heidari, M., Momeni, A., & Abdilor, Y. (2012). Prediction of shear strength parameters of soils using artificial neural networks and multivariate regression methods. *Engineering Geology*, 131, 11-18 .
- [۴۲] Iyeke, S., Eze, E., Ehiorobo, J., & Osuji, S. (2016). Estimation of shear strength parameters of lateritic soils using artificial neural network. *Nigerian Journal of Technology*, 35(2), 260-269 .
- [۴۳] Mohammadi, M., Fatemi Aghda, S. M., Talkhablou, M., & Cheshomi, A. (2022). Prediction of the shear strength parameters from easily-available soil properties by means of multivariate regression and artificial neural network methods. *Geomechanics and Geoengineering*, 17(2), 442-454 .
- [۴۴] ABRISHAMI, H., JABALAMELI, F., ABOLHASANI, M., & JAVAN, A. (2015). PERFORMANCE OF ARIMA AND NEURAL NETWORK GMDH APPROACHES IN PREDICTION OF NATURAL GAS DEMAND IN VARIOUS SECTORS (IRAN-1380-1389) .
- [۴۵] Tien Bui, D., Hoang, N.-D., & Nhu, V.-H. (2019). A swarm intelligence-based machine learning approach for predicting soil shear strength for road construction: a case study at Trung Luong National Expressway Project (Vietnam). *Engineering with Computers*, 35(3), 955-965 .
- [۴۶] Pham, B. T., Hoang, T.-A., Nguyen, D.-M., & Bui, D. T. (2018). Prediction of shear strength of soft soil using machine learning methods. *Catena*, 166, 181-191 .
- [۴۷] Das, S., Samui, P., Khan, S., & Sivakugan, N. (2011). Machine learning techniques applied to prediction of residual strength of clay. *Open Geosciences*, 3(4), 449-461 .
- [۴۸] Shioi, Y., & Fukui, J. (2021). Application of N-value to design of foundations in Japan. In *Penetration Testing, volume 1* (pp. 159-164). Routledge .
- [۴۹] Association, J. R. (1990). Design specifications of highway bridges. Part IV: substructures. *Tokyo: Japan Road Association (in Japanese)* .
- [۵۰] Abasi, M. (2012). *Estimation of the internal friction angle ( $\phi$ ) of coarse-grained sediments of Mashhad train line two route based on the results of the Standard Penetration Test (NSPT)* 9th international congress on civil engineering (ICCE), Isfahan, Iran .
- [۵۱] Kumar, R., Bhargava, K., & Choudhury, D. (2016). Estimation of engineering properties of soils from field SPT using random number generation. *INAE Letters*, 1, 77-84 .
- [۵۲] Abraham, A. (2005). Artificial neural networks. *Handbook of measuring system design* .
- [۵۳] McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5, 115-133 .
- [۵۴] Hydrology, A. T. C. o. A. o. A. N. N. i. (2000). Artificial neural networks in hydrology. II: Hydrologic applications. *Journal of Hydrologic Engineering*, 5(2), 124-137 .
- [۵۵] Onwubolu, G. C. (2014). *Gmdh-methodology And Implementation In C (With Cd-rom)*. World Scientific .
- [۵۶] ASTM D3080. (2004). Standard Test Method for Direct Shear Test of Soils Under Consolidated Drained Conditions. In: West Conshohocken, PA: ASTM.
- [۵۷] ASTM D1586. (2011). Standard Test Method for Standard Penetration Test (SPT) and Split-Barrel Sampling of Soils. In: West Conshohocken, PA: ASTM.
- [۵۸] ASTM D6913. (2004). Standard Test Methods for Particle-Size Distribution (Gradation) of Soils Using Sieve Analysis. In: West Conshohocken, PA: ASTM.
- [۵۹] ASTM D2216. (2010). Standard Test Methods for Laboratory Determination of Water (Moisture) Content of Soil and Rock by Mass. In: West Conshohocken, PA: ASTM.
- [۶۰] ASTM D7263. (2009). Standard Test Methods for Laboratory Determination of Density (Unit Weight) of Soil Specimens. In: West Conshohocken, PA: ASTM.

- [۶۱] ASTM D4318. (2010). Standard Test Methods for Liquid Limit, Plastic Limit, and Plasticity Index of Soils. In: West Conshohocken, PA: ASTM.
- [۶۲] Bowles, J. (1996). Foundation Analysis & Design 5th Edition McGraw-Hill Companies. In: Inc.
- [۶۳] Seed, H. B., Tokimatsu, K., Harder, L., & Chung, R. M. (1985). Influence of SPT procedures in soil liquefaction resistance evaluations. *Journal of geotechnical engineering*, 111(12), 1425-1445 .
- [۶۴] Skempton, A. (1986). Standard penetration test procedures and the effects in sands of overburden pressure, relative density, particle size, ageing and overconsolidation. *Geotechnique*, 36(3), 425-447 .
- [۶۵] Liao, S. S., & Whitman, R. V. (1986). Overburden correction factors for SPT in sand. *Journal of geotechnical engineering*, 112(3), 373-377 .
- [۶۶] Pianosi, F., Beven, K., Freer, J., Hall, J. W., Rougier, J., Stephenson, D. B., & Wagener, T. (2016). Sensitivity analysis of environmental models: A systematic review with practical workflow. *Environmental Modelling & Software*, 79, 214-232 .
- [۶۷] Kayabasi, A., Gokceoglu, C., & Ercanoglu, M. (2003). Estimating the deformation modulus of rock masses: a comparative study. *International Journal of Rock Mechanics and Mining Sciences*, 40(1), 55-63 .
- [۶۸] Momeni, E., Nazir, R., Armaghani, D. J., & Maizir, H. (2014). Prediction of pile bearing capacity using a hybrid genetic algorithm-based ANN. *Measurement*, 57, 122-131 .

### پیوست

$$\varphi = -7/391 + 0/393y_{11} + 1/165y_{12} - 0/1734y_{11}^2 - 0/2213y_{12}^2 + 0/3846y_{11}y_{12}$$

$$y_{11} = 34/7107 - 0/0113N_{\phi} - 0/159f_{r..} + 0/013N_{\phi}^2 + 3/2887 \times 10^{-4} f_{r..}^2 + 6/915 \times 10^{-4} N_{\phi} f_{r..}$$

$$y_{12} = 34/3032 + 0/0084\sigma' - 0/1728f_{r..} - 2/9225 \times 10^{-4} (\sigma')^2 + 4/7358 \times 10^{-4} f_{r..}^2 + 1/0108 \times 10^{-4} \sigma' f_{r..}$$

$$c(\text{kPa}) = 0/205666 + 2/926486y_{21} - 1/967035y_{22} - 0/265422y_{22}^2 - 0/050482y_{22}^2 + 0/318793y_{21}y_{22}$$

$$y_{21} = 0/017317 + 0/574578y_{11} + 0/312721y_{12} + 0/03637y_{11}^2 + 0/008028y_{12}^2 - 0/036403y_{11}y_{12}$$

$$y_{22} = -3/398465 + 1/344319y_{12} + 0/215354y_{12} - 0/073996y_{12}^2 + 0/003185y_{12}^2 + 0/049432y_{12}y_{13}$$

$$y_{11} = 5/107062 - 0/071063f_{r..} + 0/205062(\text{PI}) + 0/001027f_{r..}^2 - 0/013556(\text{PI})^2 + 0/004715f_{r..}(\text{PI})$$

$$y_{12} = 1/829197 + 0/304571\omega + 0/314969(\text{PI}) - 0/016911\omega^2 - 0/021125(\text{PI})^2 + 0/035414\omega(\text{PI})$$

$$y_{13} = 7/876016 - 0/031638\sigma' - 0/046331f_{r..} + 4/15751 \times 10^{(-5)} (\sigma')^2 + 0/00109f_{r..}^2 + 3/739643 \times 10^{(-4)} \sigma' f_{r..}$$