

مدلی جدید برای شاخص فشردگی خاک‌های ریزدانه با استفاده از برنامه نویسی ژنتیک چند ژنی (MGGP)

دانیال محمدزاده شادمهری^{۱*}، جعفر بلوری بزاز^۲

۱- دانشجوی کارشناسی ارشد مهندسی عمران مکانیک خاک و مهندسی پی، دانشگاه فردوسی مشهد

Dmhz1989@yahoo.com, Danail.mohammadzadehshadmehri@stu.um.ac.ir

۲- دانشیار، گروه عمران، دانشکده مهندسی، دانشگاه فردوسی مشهد

Dmhz1989@yahoo.com

خلاصه

این مقاله مدل جدیدی برای پیش بینی شاخص فشردگی خاک‌های رس با استفاده از روش برنامه نویسی ژنتیک چند ژنی (MGGP) ارائه می‌کند. برنامه نویسی ژنتیک چند ژنی یک مدل غیر خطی است که برنامه نویسی ژنتیک استاندارد را با رگرسیون کلاسیک ادغام می‌کند. مدل ارائه شده به حد روانی (LI)، حد خمیری (PL) و نسبت تخلخل (e_0) بستگی دارد. چندین نتایج آزمایشگاهی برای خاک‌های ریزدانه برای توسعه مدل استفاده شده است. معیارهای مختلفی برای بررسی اعتبار مدل در نظر گرفته شده است. در این مقاله به صورت پارامتریک، مدل مورد تجزیه و تحلیل و بحث قرار گرفته شده است. ضرایب تعیین پیش بینی برای داده‌های آموزش و تست ۰/۸۵۶ و ۰/۸۴۰ بدست آمده است. مطالعه مقایسه‌ای نشانگر برتری مدل MGGP نسبت به سایر روش‌های محاسبات نرم موجود و معادلات تجربی می‌باشد.

کلمات کلیدی: مدل جدید، شاخص فشردگی خاک، برنامه نویسی ژنتیک چند ژنی

۱. مقدمه

نظر به اهمیت نشست خاک در پایداری سازه‌ها، تعیین و پیش بینی نشست خاک حاصل از بارهای وارده از سازه به خاک، قبل از احداث سازه‌ها ضرورت می‌یابد. با توجه به این موضوع که نشست خاک در بعضی مواقع می‌تواند خسارات زیادی به یک پروژه وارد کند، پیش بینی صحیح و کاربرد آن در طراحی سازه‌ها و قراردادن معیارهای طراحی بر مبنای نشست تخمین زده شده می‌تواند نقش مهمی را در جلوگیری از این خسارات ایفا نماید. یکی از روش‌های متداول تعیین نشست، استفاده از شاخص فشردگی^۱ حاصل از آزمایش تحکیم می‌باشد. شاخص فشردگی ممکن است تابع پارامترهای مختلفی نظیر نسبت تخلخل اولیه خاک، رطوبت حد روانی، رطوبت حد خمیری، شاخص خمیری و چگالی نسبی باشد. تعیین دقیق این خواص برای آنالیز نشست خاک مهم است [۱]. این موضوع برای خاک‌های ریزدانه نسبت به خاک‌های درشت دانه از اهمیت بیشتری برخوردار است. شاخص فشردگی یکی از شاخص‌های اصلی تراکم است. این پارامتر اغلب برای اندازه گیری نشست خاک مورد استفاده قرار می‌گیرد [۲]. روابط متعدد تجربی نیز به این منظور ارائه شده است [۳ و ۹]. اکنون ثابت شده است تکنیک‌های هوش مصنوعی می‌توانند به عنوان ابزاری مناسب برای حل مسائلی تبدیل شوند که روش‌های مرسوم و قدیمی برای حل آن‌ها با شکست مواجه می‌شوند و یا ضعیف عمل می‌کنند [۱۰]. پیچیدگی تحلیل فرآیند تحکیم خاک، ضرورت استفاده از روش‌های جایگزین را برای پیش بینی شاخص فشردگی القا می‌کند. اکنون ثابت شده است تکنیک‌های هوش مصنوعی می‌توانند به عنوان ابزاری مناسب برای حل مسائلی تبدیل شوند که روش‌های مرسوم و قدیمی برای حل آن‌ها با شکست مواجه می‌شوند و یا ضعیف عمل می‌کنند. تکنیک‌های هوش مصنوعی کاربردهای بسیاری برای تخمین روابط غیرخطی دارد [۱۱ و ۱۲]. ANN یکی از شناخته شده‌ترین شاخه‌های هوش مصنوعی می‌باشد. این روش در مدلسازی رفتار بسیاری از مسائل مهندسی ژئوتکنیک از جمله پیش بینی شاخص فشردگی خاک (C_c) استفاده شده است

^۱ دانشجوی کارشناسی ارشد عمران، خاک و پی دانشگاه فردوسی مشهد،

Dmhz1989@yahoo.com, Danail.mohammadzadehshadmehri@stu.um.ac.ir

^۲ دانشیار گروه عمران، دانشکده مهندسی دانشگاه فردوسی مشهد، bolouri@um.ac.ir

[۷ و ۱۶-۱۳]. هرچند ANN_s در پیش بینی موفق بوده‌اند ولی قادر به ایجاد معادلات کاربردی پیش بینی کننده نیستند. از این گذشته تعیین ساختار شبکه مصنوعی (به عنوان مثال تعداد ورودی‌ها، توابع انتقال، تعداد لایه‌های پنهان و غیره) بسیار دشوار می‌باشد. اصولاً، ANN_s روشی است که به عنوان بخشی از برنامه کامپیوتری استفاده می‌شود [۱۰]. Koza در سال ۱۹۹۲، بیان کرد که، GP مدل‌های کامپیوتری را بوسیله‌ی شبیه‌سازی تکامل بیولوژیکی ارگانیسم‌های زنده، تولید می‌کند [۱۷]. GP یک روش محاسباتی نرم است که، بر اساس نظریه تکامل داروین مبتنی بر برنامه‌های کامپیوتری است. برنامه‌های کامپیوتری تکامل یافته توسط GP می‌توانند به معادلات پیش بینی غیر خطی تبدیل شوند. برنامه نویسی چند ژنی (MGGP) یکی از جدیدترین شاخه‌های برنامه نویسی ژنتیک محسوب می‌شود. در حالیکه خروجی برنامه نویسی ژنتیک کلاسیک (GP) صرفاً یک برنامه واحد به عنوان راه حل بهینه است. (MGGP) شامل چندین ژن است که هر یک برنامه کامپیوتری است [۱۸]. همانند برنامه نویسی ژنتیک کلاسیک و دیگر تکنیک‌های محاسباتی نرم، کاربرد برنامه نویسی ژنتیک چند ژنی در حوزه مهندسی است. [۱۹ و ۲۰].

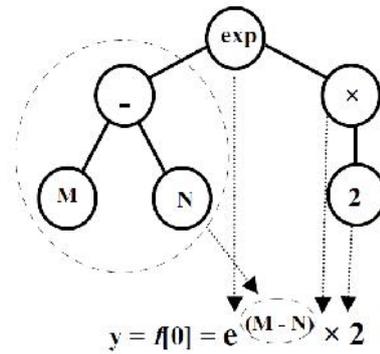
۲. برنامه نویسی ژنتیک چند ژنی

در حقیقت محاسبات نرم را می‌توان به عنوان مجموعه‌ای از تکنیک‌ها در نظر گرفت که رفتار ارگانیسم‌های زنده نظیر گیاهان، حیوانات و انسان‌ها را که رفتاری نرم، انعطاف پذیر، تطابق پذیر و هوشمند است شبیه‌سازی می‌کنند [۱۷]. ایده اصلی در GP تولید برنامه، الگوریتم و ساختارهای مشابهی نظیر این‌ها در سطحی مرتبط با الگوریتم‌های تکاملی است. GP دستیابی به این هدف را بواسطه به کار بردن الگوریتم ژنتیک امکان‌پذیر می‌نماید. در این الگوریتم، متغیرها به عنوان ساختار برنامه نویسی در نظر گرفته می‌شوند و مقدار خروجی (هزینه) نیز اینکه برنامه چه مقدار اهداف خود را تأمین نموده است را نشان می‌دهد. عملگرهای الگوریتم ژنتیک، تزویج^۱ و جهش^۲ و همچنین محاسبه هزینه به اندکی اصلاحات نیاز دارد. GP یک روش پیچیده‌تر نسبت به الگوریتم ژنتیک می‌باشد، زیرا این روش باید با متغیرهایی با طولی برابر با ساختار برنامه یا تابع کار کند. GP یک برنامه کامپیوتری می‌باشد که برنامه‌های کامپیوتری دیگر را می‌نویسد. در شکل ۱، می‌توان مشاهده کرد، که درحقیقت، برنامه نویسی ژنتیک اطلاعات ورودی و خروجی مرتبط با آن را از قبل می‌دانیم و هدف یافتن برنامه‌ای است که آن‌ها را به هم مرتبط کنیم:

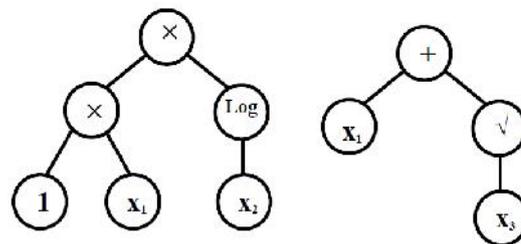


شکل ۱- مدل «ورودی-پردازش-خروجی»

شکل ۲، نشان دهنده یک برنامه درختی معمولی تکامل یافته توسط GP می‌باشد جزئیات بیشتر در مورد GP ارائه شده است [۱۹-۱۷]. برنامه نویسی ژنتیک چند ژنی (MGGP) نوع جدیدی از برنامه نویسی ژنتیک (GP) است. شکل ۳، نشان دهنده یک برنامه معمولی توسعه یافته توسط MGGP می‌باشد. ورودی‌های مدل x_1 ، x_2 و x_3 و توابع استفاده شده برای فرآیند تعمیم شامل x ، $-$ ، $+$ و Log می‌باشند. مدل در پارامترهایی شامل ضرایب C_0 و C_1 و C_2 علیرغم استفاده از عبارات غیر خطی، به صورت خطی می‌باشد [۱۸ و ۱۹]. به منظور بدست آوردن ضرایب خطی، تحلیل حداقل مربعات معمولی بر روی داده‌های آزمایشی انجام می‌شود. استفاده از روش حداقل مربعات جزئی در مورد این هدف، امکان پذیر می‌باشد [۱۸ و ۱۹]. پارامترهای مهم MGGP که نیاز به کنترل شدید دارند، تعداد ژن‌ها و عمق درخت می‌باشند. محدود کردن درخت باعث ایجاد مدل‌های فشرده‌تر خواهد شد [۱۸ و ۱۹].



شکل ۲- ارائه مدل درختی برنامه نویسی ژنتیک (GP)



$$y = c_0 + c_1(1 \times x_1 \times \text{Log}(x_2)) + c_3(x_1 + \sqrt{x_3})$$

شکل ۳- یک نمونه برنامه توسعه یافته توسط برنامه نویسی ژنتیکی چند ژنی (MGGP)

۳. مدلسازی C_c برای خاک‌های ریزدانه

به منظور تخمین دقیق شاخص فشردگی خاک اثر پارامترهای متعددی بایستی در نظر گرفته شود. با توجه به ساختار معادلات کلاسیک، شاخص فشردگی عمدتاً تابعی از پارامترهای فیزیکی خاک می‌باشد. هدف اصلی این تحقیق استخراج رابطه‌ای جدید برای تخمین شاخص فشردگی خاک‌های رسی (C_c) بر حسب خصوصیات فیزیکی خاک با استفاده از تکنیک GP است. ساختار مدل‌های موجود به وضوح نشان می‌دهد که C_c می‌تواند تابع پارامترهای مختلفی به صورت زیر باشد:

$$C_c = f(LL, PL, e_0) \quad (1-3)$$

در رابطه فوق پارامترهای به کار رفته به شرح زیر می‌باشند:

LL: حد روانی، PL: حد خمیری و e_0 : نسبت پوکی اولیه است. انتخاب متغیرهای LL، PL و e_0 بر اساس مطالعه گسترده ادبیات فنی است و اثر قابل توجه آن‌ها بر شاخص فشردگی به خوبی درک شده است. قابل ذکر است که هدف از این تحقیق ارائه رابطه‌ای ساده و کاربردی برای پیش بینی شاخص فشردگی خاک می‌باشد. لذا با وجود امکان استفاده از سایر پارامترهای فیزیکی خاک تنها به استفاده از سه پارامتر مهم LL، PL و e_0 بسنده شده است. کارآمدی استراتژی به کار گرفته شده با در نظر گرفتن دقت مدل ارائه شده بررسی و تأیید خواهد شد [۹-۳].

در اکثر این پروژه‌ها به منظور جلوگیری از نیاز به زمان طولانی و همچنین کاهش هزینه‌های انجام مطالعات ژئوتکنیک اغلب تعداد آزمایش‌ها کاهش داده می‌شود و در نتیجه اطلاعات پیوسته و جامع از خاک‌ها به خصوص در مواردی که تنوع لایه بندی زیاد است، به دست نمی‌آید. این امر سبب می‌شود طراحان کم تجربه و بدون داشتن اطلاعات کافی، اقدام به ساده‌سازی پارامترهای طراحی نمایند که معمولاً به صورت دست بالا است و از جهت دیگر سبب افزایش هزینه‌های اجرا می‌شود. بنا براین لازم است معیارهایی مشخص گردند تا بتوان از طریق آن‌ها به دانشی جامع و با خطای قابل قبول پارامترهای تحکیم را تخمین زد. این کار علاوه بر این که سبب کاهش حجم آزمایش‌ها و صرفه جویی در زمان و هزینه می‌شود از طرف دیگر می‌تواند اطلاعات پیوسته‌های از ساختگاه مورد نظر را فراهم سازد و دانش طراحان را به میزان قابل توجهی بهبود بخشد. در صورت تحقق این مهم، صرفه‌جویی‌های قابل توجهی در طراحی‌های مهندسی ژئوتکنیک صورت خواهد گرفت [۲۰].

به منظور توسعه مدل بر اساس MGGP، یک پایگاه داده جامع که شامل خصوصیات فیزیکی خاک (LL، PL، e_0) مورد استفاده قرار گرفته شده است. تقسیم بندی داده به سه دسته آموزش، اعتبار سنجی و آزمایش بر اساس بررسی‌ها و پیشنهاد پژوهشگران بسیاری در جهت بدست آمدن مدل‌هایی با قدرت پیش بینی بالا صورت گرفته است. در جدول ۳، الگوریتم MGGP، بر روی داده‌های یادگیری قرار گرفت و بررسی در دو زیر مجموعه مورد بررسی قرار گرفت. مدل مطلوب با توجه به سادگی و همچنین عملکرد آن بر روی داده‌های یادگیری و اعتبار سنجی انتخاب شد. ضریب همبستگی (R^2)، مجذور میانگین مربعات خطا (RMSE) و میانگین کلی خطا (MAE) برای ارزیابی عملکرد مدل استفاده قرار گرفت.

الف. تست‌های آزمایشگاهی

داده‌های آزمایشگاهی بر روی نمونه‌های بدست آمده از نقاط مختلف استان خراسان رضوی (مشهد)، ایران به دست آمده است. نمونه‌های خاک از چاله آزمون در عمق (۱۰-۵) بر داشت شده است. شاخصه‌های فیزیکی و پلاستیک خاک از طریق آزمون‌های آزمایشگاهی تعیین شده است. به منظور تعیین (C_c) از آزمون متعارف ادنومتری استفاده شده است، روش آزمون ارائه شده است [۲۰].

جدول ۱، پارامترهای (LL، PL، e_0 و C_c) مورد استفاده در این مطالعه را نشان می‌دهد. داده‌های آزمایشگاهی از مجموع ۱۰۱ تست آزمایشگاهی در نمونه خاک‌های ریزدانه بدست آمده است. علاوه بر این، تعداد ۷ نتیجه آزمایشگاهی نیز توسط ملیح از ادبیات فنی استخراج و به داده‌های موجود اضافه شده است [۲۱]. انواع مختلف خاک مورد استفاده در این مطالعه رس سیلتی با شن و ماسه (CL-M)، خاک رس با شن (CL) و سیلت، شن و ماسه رسی (SC-SM) بوده است.

جدول ۱- شرح آماری نتایج و متغیرهای مورد استفاده در مدل‌سازی

Parameter	e_0	LL (%)	PL (%)	C_c
Mean	0.75	36.16	22.61	0.17
Standard Deviation	0.12	12.79	5.64	0.05
Range	0.52	52.60	29.20	0.18
Minimum	0.51	19.40	14.80	0.08
Maximum	1.03	72.00	44.00	0.25

داده‌های موجود برای بسط مدل‌هایی که بتوانند شاخص فشرده‌گی را به خصوصیات خاک ارتباط دهند، به کار رفته‌اند. برای تحلیل اطلاعات موجود به دو دسته آموزش^۱ (یادگیری و اعتبار سنجی^۲) و آزمایش^۳ تقسیم شده‌اند. برای دستیابی به تقسیم بندی مناسب داده‌ها، ترکیب‌های مختلف دسته‌های آموزش (یادگیری و صحت سنجی) و آزمایش مورد بررسی قرار گرفته‌اند. انتخاب به گونه‌ای بوده است که حداکثر، حداقل و انحراف معیار پارامترها در مجموعه‌های آموزش، اعتبار سنجی و آزمایش با هم مطابقت داشته باشد. مدل با بالاترین مقدار R^2 (ضریب همبستگی) و کمترین مقدار مجذور میانگین مربعات خطا (RMSE) و میانگین کلی خطا (MAE) در یادگیری و اعتبارسنجی‌ها به عنوان مدل مطلوب انتخاب شد. از آنجا که هر دو مجموعه یادگیری و اعتبارسنجی در مدل انتخاب شدند. آن‌ها با هم به عنوان داده‌های آموزشی مورد بررسی قرار گرفتند. آزمون، اعتبارسنجی و آزمون داده‌ها معمولاً به عنوان ۷۰٪-۵۰٪، ۲۵٪-۱۵٪ و ۲۵٪-۱۵٪ از تمام اطلاعات به ترتیب گرفته شده است. در اینجا حدود ۶۵٪ (۷۱ داده برای یادگیری)، ۱۵٪ (۱۶ داده برای صحت سنجی) و ۲۰٪ (۲۱ داده برای آزمایش نهایی مدل) به کار رفته‌اند.

ب. فرمولاسیون بر اساس برنامه نویسی ژنتیک چند ژنی برای C_c

جدول ۲، نشان دهنده پارامترهای در نظر گرفته شده برای اجراهای مختلف می‌باشد. به منظور یافتن بهترین مدل، مقادیر بزرگ برای جمعیت و تولید مثل در نظر گرفته شده‌اند.

1. Training
2. Learning
3. Validation
4. Testing

جدول ۲- تنظیم پارامترها در الگوریتم برنامه نویسی ژنتیک چند ژنی (MGGP)

Parameter	Settings
Population size	200, 400, 800, 1200, 1500, 2000, 3000
Generations	200, 400, 800, 1000
Maximum number of genes	4, 6, 10, 12
Maximum tree depth	4, 6, 10, 12
Tournament size	25
Crossover events	0.85
Mutation events	0.1
Function set	+, -, ×, /, ^2, ^3, tanh, sin, cos, exp

مطابق جدول ۲، $7 \times 4 \times 4 \times 4 = 448$ آرایش پارامتری وجود دارد. تمامی این ترکیبات (آرایش‌ها) همراه با ۲ تکرار برای هر کدام مورد آزمایش قرار گرفته‌اند. بنابراین تقریباً $448 \times 2 = 896$ اجرای منحصر به فرد بهینه انجام شده است. جعبه ابزار GPTIPS کدگذاری شده در متلب، را به منظور اجرای الگوریتم، مورد استفاده قرار داده شد. تابع RMSE به منظور به حداقل رساندن خطا در حین اجرا، تطبیق یافته است.

به منظور تسهیل در استفاده از مدل ارائه شده، به یک مدل تابعی تبدیل و سپس به صورت زیر ساده‌سازی شده است:

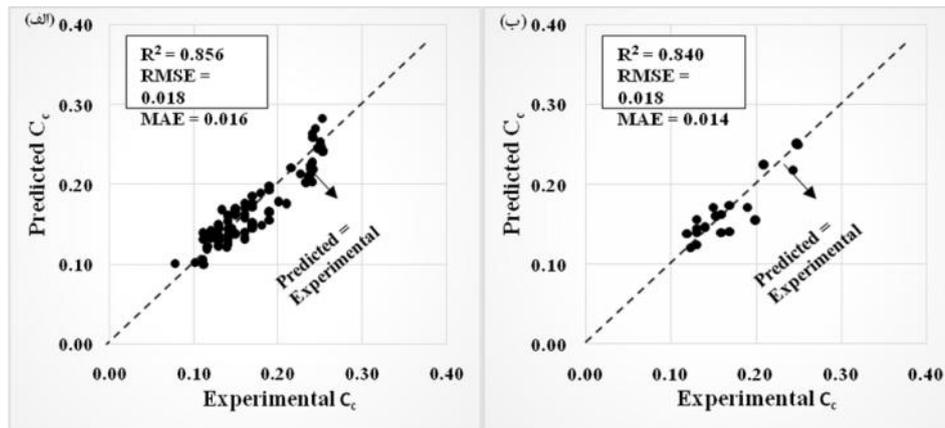
$$C_c = 0.87e_0 - 0.0059LL - 0.0186PL + 7.33 \times 10^{-4} \sin(LL) - 0.162 \tanh(PL) + 7.33 \times 10^{-4} \tanh(LL) + 0.00468e_0LL - \frac{(1.38 \times 10^{15}LL)}{(7.21 \times 10^{16}e_0 + 7.21 \times 10^{16}PL + 7.21 \times 10^{16} \tanh(\tanh(\exp(LL - \exp(e_0))))))} - \frac{(4.22 \times 10^{14}LL + 4.22 \times 10^{14}PL + 4.22 \times 10^{14} \tanh(e_0))}{(1.15 \times 10^{18}e_0 + 1.15 \times 10^{18}PL + 5.76 \times 10^{17} \exp(\tanh(e_0PL)))} + \frac{(0.016PL)}{e_0} - \frac{0.148PL}{LL}$$

تعداد جمعیت، تولید مثل، ژن‌ها و عمق درخت‌ها برای مدل به ترتیب معادل با ۱۵۰۰، ۸۰۰، ۱۰ و ۱۰ می‌باشد. عملکرد مدل در هر دو داده‌های آزمایشی و آموزشی مناسب می‌باشد.

۴. تأیید اعتبار سنجی

در این مطالعه، C_c خاک‌های رسی به عنوان پارامتر مستقلی در نظر گرفته شده است که خود تابع پیچیده‌ای از متغیرهای تأثیرگذار LL ، PL و e_0 است. بر اساس یک فرضیه منطقی، Smith در سال ۱۹۸۶ معیارهای زیر را برای بررسی عملکرد مدل‌ها ارائه کرده است [۲۲]: اگر ضریب همبستگی (R) برای مدلی بزرگتر از ۰/۸، $(R > 0.8)$ باشد، همبستگی بین مقادیر واقعی و پیش‌بینی شده قوی می‌باشد. علاوه بر این ارزیابی خطا باید در همه موارد حداقل باشد. شکل ۴، مدل برنامه نویسی ژنتیک چند ژنی (MGGP) را با RMSE و MAE کم را نشان می‌دهد. علاوه بر این، اعتبار مدل ارائه شده برای داده‌های آزمایشی توسط معیارهای جدیدی که Golbraikh و Trophsa در سال ۲۰۰۲ پیشنهاد کرده‌اند بررسی شده است [۲۳]. بر این اساس، حداقل یکی از شیب‌های خطوط رگرسیون (k و k') بایستی نزدیک به ۱ باشد. به تازگی، Roy و Roy در سال ۲۰۰۸، شاخص تعیین R_m را برای ارزیابی قابلیت پیش‌بینی مدل‌ها معرفی کرده‌اند. به ازای $R_m > 0.5$ ارضا می‌شود. همچنین، مربع ضریب همبستگی بین مقادیر پیش‌بینی شده به مقادیر واقعی (Ro^2) و مربع ضریب همبستگی بین مقادیر واقعی به مقادیر پیش‌بینی شده (Ro'^2) بایستی نزدیک ۱ باشد. معیارهای اعتبارسنجی ذکر شده و نتایج به دست آمده توسط مدل‌ها در جدول ۳، نشان داده شده است. همانطور که ملاحظه می‌شود، مدل GP کلیه شرایط را ارضا می‌کند. مدل تنها شرط R_m را بصورت بسیار مرزی ارضا نمی‌کند. نتایج به دست آمده نشانگر اعتبار بسیار بالای مدل ارائه شده می‌باشد. معیارهای فوق برای مدل توسعه یافته بررسی می‌شود (داده‌ها در جدول ۳، موجود است).

بر این اساس این جدول می‌توان گفت مدل بدست آمده مورد تأیید می‌باشد. علاوه بر این مدل برنامه نویسی ژنتیک چند ژنی (MGGP) با دو روش قدرتمند دیگر برنامه نویسی ژنتیک چندرسانه‌ای (MEP) و (ANN) که توسط پژوهشگران دیگر مورد بررسی قرار گرفته است مورد مقایسه قرار گرفت [۳-۹].



شکل ۴- نتایج پیش بینی C_c به وسیله بهترین مدل GP عملکرد مدل (MGGP) (الف) داده‌های آموزش و (ب) داده‌های آزمایش

جدول ۳- پارامترهای مربوط به اعتبارسنجی مدل‌های ارائه شده (MGGP)

Formula	Condition	MGGP
$k = \frac{\sum_{i=1}^n (h_i \times t_i)}{h_i^2}$	$0.85 < k < 1.15$	1.001
$k' = \frac{\sum_{i=1}^n (h_i \times t_i)}{t_i^2}$	$0.85 < k' < 1.15$	0.989
$R_m = R^2 \times (1 - \sqrt{ R^2 - Ro^2 })$	$0.5 < R_m$	0.503
$Ro^2 = 1 - \frac{\sum_{i=1}^n (t_i - \bar{t}_i)^2}{\sum_{i=1}^n (t_i - \bar{t}_i)^2}$	Should be close to 1	1.000
$h_i^o = k \times t_i$		
$Ro'^2 = 1 - \frac{\sum_{i=1}^n (h_i - \bar{h}_i)^2}{\sum_{i=1}^n (h_i - \bar{h}_i)^2}$	Should be close to 1	0.998
$t_i^o = k' \times h_i$		

۵. نتیجه گیری

در این مقاله مدل MGGP برای پیش بینی C_c در خاک‌های ریزدانه ارائه شده است. فرمول C_c از خواص اساسی خاک نظیر (e_0, LL, PL) بدست آمده است. مدل بر اساس یک بانک جامع داده‌های تجربی به دست آمده است. همچنین شبیه‌سازی گسترده به منظور یافتن مدل بهینه انجام شده است، به منظور تأیید اعتبار مدل، معیارهای مختلفی تدوین شده‌اند. در این مقاله به صورت پارامتریک و آنالیز حساسیت مدل مورد تجزیه و تحلیل و مورد بحث قرار گرفته است. ضرایب تعیین پیش بینی برای داده‌های آموزش و تست ۰/۸۵۶ و ۰/۸۴۰ بدست آمده است. نتایج به دست آمده نشانگر اعتبار بسیار بالای مدل MGGP نسبت به سایر روش‌های محاسبات نرم موجود و معادلات تجربی می‌باشد. نتایج حاصل نشان می‌دهد که C_c با افزایش LL و PL به ترتیب ۳۲٪ و ۲۲٪ افزایش می‌یابد. به دلیل رفتار به شدت غیرخطی C_c ، مدل غیرخطی MGGP نتایج بسیار بهتری را در مقایسه با روش‌های دیگر تولید کرده است. در محدوده در نظر گرفته شده، می‌توان مدل پیشنهادی را به عنوان جایگزینی مؤثر نسبت به روش‌های دشوار آزمایش جهت تعیین C_c در نظر گرفت. به طور کلی، این روش‌ها می‌توانند به آسانی بسیاری از مسائل پیچیده را حل نموده و مشکلات ناشی از انجام آزمایش‌های پیشرفته و پرهزینه را برطرف سازند.

۶. مراجع

1. B. T. Tiwari and B. Ajmera ,(2012),“New Correlation Equations for Compression Index of Remoulded Clays,” J. Geotech. Geoenviron. Eng. vol. 138(6), pp. 757-762.
2. M. Carter and S. P. Bentley ,(1991), “Correlations of Soil Properties”. Pentech Press, London,.
3. A. S. Azzouz, R. J. Krizek and R. B. Corotis ,(1976), “Regression analysis of soil compressibility,” Soils Found., vol. 16, pp. 19-29,.
4. V. M. Cozzolino, ,(1961), “Statistical forecasting of compression index”. In: Proceedings of the fifth international conference on soil mechanics and foundation engineering, Paris, vol. 1, pp. 51-53
5. P. W. Mayne, (1980),“Cam-clay predictions of undrained strength,” J. Geotech. Eng. Div. ASCE, vol. 106, pp. 1219-1242.
6. Y. Nishida, (1956), “A Brief Note on Compression Index of Soils,” J. Soil Mech. Found. ASCE, vol. 82, SM3, pp. 1027-1-1027-14.
7. H. Park and S. R. Lee, (2011),“Evaluation of the compression index of soils using an artificial neural network. Comput Geotech, vol. 38, pp. 472-481.
8. A. W. Skempton (1944),“Notes on the Compressibility of Clays,” Quarterly J. Geol. Soc. London, vol. 100, pp. 119-135.
9. K. Terzaghi and R. B. Peck , (1967),“Soil Mechanics in Engineering Practice”, John Wiley & Sons Inc. New York.
10. A. H. Alavi and A. H. Gandomi, (2011),“A robust data mining approach for formulation of geotechnical engineering systems,” Eng. Computations vol. 28(3), pp. 242-274.
11. S. K. Das and P. K. Basudhar, (2008),“Prediction of Residual Friction Angle of Clays Using Artificial Neural Network” Eng. Geol., vol. 100, pp. (3-4): 142-145.
12. S. K. Das, P. K. Basudha, N. Sivakugan and B. Das, (2011), “Classification of slopes and prediction of factor of safety using differential evolution neural networks,” Environ. Earth. Sci. vol. 64(1), pp. 201-210.
13. M. Daryae, M. Kashefipour, J. Ahadiyan and R. Ghobadiyan, (2010),“Modeling the Compression Index of Fine Soils Using Artificial Neural Network and Comparison with the other Empirical Equations” J Water Soil 24(4), 659-667.
14. C. K. Desai and A. Shaikh, (2012),“Prediction of depth of cut for single-pass laser micro-milling process using semi-analytical, ANN and GP approaches” J. Adv. Manufact. Tech., vol. 60, pp. 865 – 882.

۱۵. سعید فرخنده و جعفر بلوری بزاز، (۱۳۸۹)، “برآورد نشست تحکیمی خاک‌های رسی با استفاده از شبکه‌های عصبی مصنوعی،” پنجمین کنگره ملی مهندسی عمران، دانشگاه فردوسی، مشهد، ایران، ۱۶-۱۴ اردیبهشت.

16. V. P. Kumar and C. H. S. Rani, (2011),“Prediction of compression index of soils using artificial neural networks (ANNs),” International Journal of Engineering Research and Applications (IJERA), vol. 1(4), pp. 1554-1558.
17. J. Koza, (1992), “Genetic programming, on the programming of computers by means of natural selection”. Cambridge (MA), MIT Press.
18. D. P. Searson, , D. E. Leahy and M. J. Willis, (2010),“GPTIPS: An Open Source Genetic Programming Toolbox For Multigene Symbolic Regression”. Proc Int Multi Conf Eng Comput Scie Hong Kong.
19. A. H. Gandomi and A. H. Alavi, (2012),“New Multi-Gene Genetic Programming Approach to Nonlinear System Modeling. Part I: Materials and Structural Engineering Problems,” Neural Comput. Appl., vol. 21, pp. 171-187.
20. D. Mohammadzadeh S., J. Bolouri Bazaz and A. H. Alavi, (2014) ,“An Evolutionary Computational Approach for Formulation of Compression Index of Fine-Grained Soils,” Eng. Appl. Artif. Intel., vol. 33, pp. 58-68.

۲۱. خوش گفتار ملیح، س.، (۱۳۸۵)، "ارائه‌ی مدل فازی در تعیین پارامترهای آزمایش تحکیم در خاک‌های رسی"، پایان‌نامه کارشناسی

ارشد، دانشگاه گیلان، گیلان.

22. G. N. Smith, (1986), "Probability and statistics in civil engineering". Collins, London.
23. A. Golbraikh and A. Tropsha, (2002), "Beware of q^2 " J. Mol. Graph. Model. vol. 20, pp. 269–276.
24. P. P. Roy and K. Roy, (2008), "On some aspects of variable selection for partial least squares regression models," QSAR Comb Sci vol. 27, pp. 302–132.