

T. Heidari Dezfuli

Department of Civil
Engineering, Sirjan University
of Technology, Sirjan.

e-mail: Tobahd1371@gmail.com

A.R. Ghanizadeh*

Department of Civil
Engineering, Sirjan University
of Technology, Sirjan.

e-mail: ghanizadeh@sirjantech.ac.ir

Prediction of Compressive and Tensile Strength of Clayey Subgrade Soil Stabilized With Portland Cement and Iron Ore Mine Tailing Using Computational Intelligence Methods

One of the Practical solutions for improving subgrade soil is the utilization of additives for soil stabilization. Generally, the unconfined compressive strength (UCS) and indirect tensile strength (ITS) tests are employed for quality control of stabilized materials. These tests are time-consuming due to the time needs for curing of samples, and can also be costly if the number of samples increases. In this study, we have employed two methods including artificial neural network (ANN) and adaptive neuro-fuzzy inference system (ANFIS) to predict UCS and ITS of clayey subgrade soil stabilized with Portland cement and iron ore mine tailing (IOMT). To this end, cement content, IOMT content, optimum moisture, and curing time were considered as input parameters, and unconfined compressive strength, as well as indirect tensile strength, were considered as output parameters and in each case a dataset consisting of 100 data points were used for developing computational intelligence models. Modeling by means of these three methods confirmsthe superiority of the artificial neural network model over ANFIS model. Also, the sensitivity analysis showed that the Portland cement content and IOMT Content have the greatest and lowest effect on the predicted compressive and tensile strength, respectively.

Keywords: Unconfined Compressive Strength, Indirect Tensile Strength, clay Soil, Portland cement and iron ore mine tailings, computational intelligence.

* Corresponding author

Received 14 September 2020, Revised 02 December 2020, Accepted 06 December 2020.
DOI: 10.22091/cer.2020.5950.1213

پیش‌بینی مقاومت فشاری و کششی بستر روسی ثبیت شده با سیمان و باطله سنگ آهن با استفاده از روش‌های هوش محااسباتی

یکی از روش‌های بهسازی خاک بستر روسازی، استفاده از مواد افزودنی جهت ثبیت خاک است. برای ارزیابی کیفیت مصالح از آزمایش‌های مقاومت فشاری تکمحوری و مقاومت کششی غیرمستقیم استفاده می‌شود. بهره‌گیری از این آزمایش‌ها با توجه به زمان بر بودن عمل آوری نمونه‌ها وقت‌گیر است. همچنین در صورت افزایش تعداد نمونه‌ها می‌تواند هزینه‌بر نیز باشد. در این تحقیق، از دو روش مدل‌سازی شبکه عصبی مصنوعی (ANN) و سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) جهت پیش‌بینی مقاومت فشاری و کششی خاک رس ثبیت شده با سیمان و باطله سنگ آهن استفاده شده است. برای این منظور، پارامترهای درصد سیمان، درصد باطله، رطوبت بهینه و مدت زمان عمل آوری، به عنوان ورودی و پارامترهای مقاومت فشاری تکمحوری و مقاومت کششی غیرمستقیم، به عنوان خروجی در نظر گرفته شده است و در هر مورد پایگاهداده‌ای مشکل از ۱۰۰ داده مورد استفاده قرار گرفته است. مدل‌سازی با استفاده از این سه روش، برتری مدل شبکه عصبی مصنوعی نسبت به سیستم استنتاج عصبی-فازی تطبیقی را نشان می‌دهد. همچنین تحلیل حساسیت نشان می‌دهد که پارامترهای درصد سیمان و درصد باطله به ترتیب بیشترین و کمترین تأثیر را بر مقاومت فشاری و مقاومت کششی پیش‌بینی شده دارند.

وازگان کلیدی: مقاومت فشاری تکمحوری، مقاومت کششی غیرمستقیم، خاک رس ثبیت شده، سیمان و باطله سنگ آهن، هوش محااسباتی.

طوبی حیدری دزفولی*

دانشجوی کارشناسی ارشد،
دانشکده مهندسی عمران،
دانشگاه صنعتی سیرجان.

پست الکترونیک:
Tobahd1371@gmail.com

علیرضا غنیزاده*

دانشیار، دانشکده مهندسی
عمران، دانشگاه صنعتی سیرجان.
پست الکترونیک:
ghanizadeh@sirjantech.ac.ir

مانند سیمان، آهک، خاکستر بادی و برخی از نمک‌ها استفاده می‌شود [۱]. ترکیب این مصالح با خاک باعث بهبود در خصوصیات خاک، مقاومت خاک، نفوذپذیری و تغییرشکل خاک می‌شود. در گذشته، مطالعات فراوانی برای به کارگیری مصالح ثبیت کننده در طرح‌های مختلف در سرتاسر دنیا انجام شده است [۲]. سیمان یکی از پرکاربردترین مصالح در ثبیت شیمیایی خاک‌ها است. یکی از اولین پژوهه‌های ساخت‌وسازی که سیمان در آن به عنوان ثبیت کننده خاک در آمریکا استفاده شد، مربوط به پژوهه‌ای در نزدیکی شهر جانسون ویل در کارولینای جنوبی در سال ۱۹۳۵ بوده است [۳]. با توجه به مطالعات قبلی با افزودن سیمان به خاک رس، پتانسیل تورم، حد

۱- مقدمه

در سالیان اخیر، تقاضا برای ساخت انواع زیرساخت‌های حمل و نقل از جمله راه، فرودگاه و راه‌آهن رو به افزایش بوده است. در بسیاری از مناطق، سطح وسیعی از خاک بستر را رس تشکیل داده است که برای انجام ساخت‌وساز مناسب نیست. جهت بهسازی خاک‌ها به خصوص خاک‌های مسئله‌دار معمولاً از افزودنی‌هایی

* نویسنده مسئول

تاریخ: دریافت ۱۳۹۹/۰۶/۲۴، بازنگری ۱۳۹۹/۰۹/۱۲، پذیرش ۱۳۹۹/۰۹/۱۶.

DOI: 10.22091/cer.2020.5950.1213 شناسه دیجیتال

فشاری تک‌محوری خاک استفاده نمودند. نتایج این تحقیق، مناسب بودن این روش برای پیش‌بینی حداکثر چگالی خشک خاک و مقاومت فشاری تک‌محوری را نشان می‌داد [۱۱]. داس^۵ و همکاران (۲۰۱۱)، از روش‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای پیش‌بینی حداکثر وزن مخصوص خشک و مقاومت فشاری تک‌محوری خاک تثبیت شده با سیمان استفاده کردند. در این پژوهش، متغیرهای ورودی شامل حد مایع، حد روانی، درصد رس، درصد ماسه، درصد شن، درصد رطوبت و درصد سیمان بودند. نتایج این تحقیق براساس معیارهای مختلف آماری نشان داد که دقت روش ماشین بردار پشتیبان نسبت به روش شبکه عصبی مصنوعی بیشتر است [۱۲]. در سال ۲۰۱۲ پژوهشگران برای پیش‌بینی مقاومت فشاری تک‌محوری خاک تثبیت شده با سیمان از روش شبکه عصبی مصنوعی استفاده نمودند [۱۳]. در سال ۲۰۱۵ نیز برای پیش‌بینی مقاومت فشاری تک‌محوری مخلوط ماسه، پودر خاکستر سوخت (PFA^۶) و سیمان از روش سیستم استنتاج عصبی-فازی تطبیقی (ANFIS^۷) استفاده شد [۱۴]. در تحقیق دیگری، برای پیش‌بینی مقاومت فشاری تک‌محوری مخلوط ماسه، سیمان و صد حلزون از دو روش ماشین بردار پشتیبان و سیستم استنتاج عصبی-فازی تطبیقی استفاده گردید. نتایج تحقیق دقت بیشتر روش سیستم استنتاج عصبی-فازی تطبیقی را در مقایسه با روش ماشین بردار پشتیبان برای پیش‌بینی مقاومت فشاری تک‌محوری نشان می‌داد [۱۵]. سومان^۸ و همکاران (۲۰۱۶)، مدل‌هایی را براساس روش شبکه‌های عملکردی (FN^۹) و روش اسپلاین رگرسیون تطبیقی چندمتغیره به منظور پیش‌بینی مقاومت فشاری تک‌محوری و حداکثر چگالی خشک خاک تثبیت شده با سیمان توسعه دادند. نتایج این تحقیق

مایع و دامنه خمیری، کاهش و مقاومت برشی و حد انقباض افزایش می‌یابد [۴]. اضافه کردن سیمان به خاک رس باعث ایجاد واکنش شیمیایی مشابه با آهک می‌شود و می‌توان برای اصلاح و تثبیت این نوع خاک‌ها از آن استفاده کرد. سیمان برای تثبیت بسیاری از خاک‌ها می‌تواند مورد استفاده قرار گیرد. با این وجود، سیمان برای تثبیت بعضی خاک‌ها که دارای مواد آلی بیش از ۲٪ pH کمتر از ۵/۳ باشند، مناسب نیست [۵]. استفاده از ضایعات صنعتی از جمله ضایعات سنگ‌آهن در مصالح عمرانی به دلایل زیست‌محیطی و اقتصادی در چند سال اخیر مدنظر قرار گرفته است. در سال‌های اخیر، تحقیقات محدودی در زمینه استفاده از باطله سنگ‌آهن برای بهسازی خاک صورت گرفته است [۶-۹]. به منظور تعیین طرح اختلاط و همچنین کنترل کیفیت مصالح تثبیت شده از آزمایش‌هایی مثل مقاومت فشاری یا مقاومت کششی استفاده می‌شود.

محققین متعددی در گذشته از روش‌های هوش محاسباتی برای پیش‌بینی مقاومت فشاری تک‌محوری خاک‌های تثبیت شده استفاده نموده‌اند که در ادامه به تعدادی از آن‌ها اشاره خواهد شد. گونایدین^۱ (۲۰۱۰)، با استفاده از تجزیه و تحلیل آماری^۲ (مدل‌های آماری سنتی) و شبکه عصبی مصنوعی (ANN^۳) به پیش‌بینی مقاومت فشاری خاک مصنوعی پرداختند. در این تحقیق، حد مایع، حد انقباض، شاخص خمیری، وزن مخصوص، حد خمیری، اندازه دانه‌ها، درصد رس، درصد لای و میزان نفوذپذیری به عنوان ورودی و مقاومت فشاری به عنوان خروجی در نظر گرفته شده است. نتایج این تحقیق نشان‌دهنده دقت بالای روش شبکه عصبی مصنوعی بود [۱۰]. علوی^۴ و همکاران (۲۰۱۱)، از شبکه عصبی مصنوعی برای پیش‌بینی حداکثر چگالی خشک و مقاومت

^۵- Das^۶- Pulverized Fuel Ash^۷- Adaptive Neuro-Fuzzy Inference System^۸- Suman^۹- Functional Networks^۱- Gunaydin²- statistical analyses³- Artificial neural network⁴- Alavi

خاک لای تثبیت شده با پودر خاکستر^{۱۲}، الیاف جوت^{۱۳}، فیبر فولاد^{۱۴}، تحت سیکل های ذوب- یخندان استفاده کردند. پارامترهای ورودی به صورت درصد پودر خاکستر، درصد الیاف جوت، درصد الیاف فولاد و تعداد سیکل های ذوب- یخندان و پارامتر خروجی به صورت مقاومت فشاری تک محوری در نظر گرفته شد. نتایج این تحقیق نشان داد که شبکه عصبی پایه شعاعی در مقایسه با سایر روش ها دارای دقت بالاتری بود [۲۱]. در سال ۲۰۱۷ در پژوهشی به پیش بینی مقاومت فشاری و کششی بزرگی^{۱۵} خاک تثبیت شده با سیمان، الیاف پلی پروپلین و خاکستر بادی^{۱۶} با استفاده از رگرسیون خطی چند گانه (MLR)^{۱۷} و شبکه عصبی مصنوعی پرداختند. پارامترهای ورودی شامل درصد سیمان، درصد الیاف، وزن مخصوص خشک و درصد رطوبت بهینه بود و پارامترهای خروجی به صورت مقاومت فشاری و مقاومت کششی غیر مستقیم در نظر گرفته شدند. نتایج این تحقیق برتری دقت شبکه عصبی مصنوعی هم برای پیش بینی مقاومت فشاری و مقاومت اسپیلاین رگرسیونی تطبیقی چند متغیره، مدل درختی (GMDH)^{۱۹} و M5P^{۱۸} روش گروهی بررسی داده ها (GMDH)^{۱۹} به پیش بینی مقاومت فشاری خاک رس تثبیت شده با سیمان و پودر سرباره کوره انفجار (GGBS^{۲۰}) و خاکستر بادی در برابر سیکل های ذوب- یخندان پرداختند. نتایج دقت بیشتر روش مدل اسپیلاین رگرسیونی تطبیقی چند متغیره را در مقایسه با سایر روش ها نشان می داد [۲۳]. غنیزاده و همکاران (۱۳۹۸) به توسعه مدل پیش بینی مقاومت فشاری تک محوری بستر رسی تثبیت شده با

مناسب بودن این دو روش را برای پیش بینی مقاومت فشاری تک محوری و حداکثر چگالی خشک خاک نشان می داد [۱۶]. موزومدر و اسلام لشکر^{۱۰} (۲۰۱۵)، از روش شبکه عصبی مصنوعی و تحلیل رگرسیون چند متغیره برای تخمین مقاومت فشاری تک محوری خاک رس تثبیت شده با ژئوپلیمر استفاده کردند. نتایج این تحقیق نشان دهنده مناسب بودن روش شبکه عصبی برای پیش بینی مقاومت فشاری تک محوری خاک رس تثبیت شده با ژئوپلیمر بود [۱۷]. همچنین در تحقیقی دیگر کاربرد روش رگرسیون ماشین بردار پشتیبان برای تخمین مقاومت فشاری تک محوری خاک رس تثبیت شده با ژئوپلیمر ارزیابی شد. نتایج نشان دهنده مناسب بودن روش رگرسیون ماشین بردار پشتیبان برای پیش بینی مقاومت فشاری تک محوری خاک رس تثبیت شده با ژئوپلیمر بود [۱۸]. جوادیان (۲۰۱۷)، به منظور مدل سازی مقاومت فشاری خاک های ریزدانه تثبیت شده با ژئوپلیمر و خاکستر بادی حاصل از سرباره کوره انفجار از روش سیستم استنتاج عصبی- فازی تطبیقی استفاده نمود. نتایج دقت بالای این روش را نشان می داد [۱۹]. در سال ۲۰۱۷ محققان برای پیش بینی مقاومت فشاری تک محوری خاک رس تثبیت شده با زباله صنعتی از روش شبکه عصبی مصنوعی و تحلیل رگرسیون استفاده کردند. طبق نتایج بدست آمده، هر دو روش توانایی پیش بینی مقاومت فشاری تک محوری را با توجه به خواص خاک با دقت بالا دارند، اما روش شبکه عصبی مصنوعی نسبت به تحلیل رگرسیون، پیش بینی دقیق تری را ارائه می دهد [۲۰]. پژوهشگران همچنین از شبکه های عصبی پایه شعاعی^{۱۱}، سیستم چند لایه پروسپترون، شبکه عصبی رگرسیون عمومی و سیستم استنتاج عصبی- فازی تطبیقی به منظور پیش بینی مقاومت فشاری تک محوری

¹²- Powder Ash

¹³- Jute Fibers

¹⁴- Steel fiber

¹⁵- Brazilian tensile strength: (BTS)

¹⁶- fly ash

¹⁷- Multiple Linear Regression

¹⁸- M5 Prime

¹⁹- Group method of data Handling

²⁰- Ground granulated blast furnace slag

¹⁰- Mozumder and Islam Laskar

¹¹- Radial base neural networks

۱۲ و ۱۵ درصد) و چهار زمان عمل‌آوری (۷، ۱۴، ۲۸ و ۵۶ روز) برای انجام آزمایش‌های مقاومت فشاری تکمحوری و مقاومت کششی غیرمستقیم آماده‌سازی شدند. پس از انجام آزمایش‌ها بر روی نمونه‌ها (دو تکرار برای هر نمونه) و ایجاد پایگاه داده از روش‌های شبکه عصبی مصنوعی و سیستم استنتاج عصبی-فازی تطبیقی به منظور مدل‌سازی مقاومت فشاری و مقاومت کششی استفاده شد. در انتها نتایج حاصل از این دو روش مدل‌سازی مقایسه و بر روی مدل منتخب از دیدگاه دقت، تحلیل حساسیت و تحلیل پارامتریک انجام شد.

۲- مطالعات آزمایشگاهی

۱-۲- مصالح

خاک مصرفی در این تحقیق از فاصله ۶۰ کیلومتری شمال شرقی شهرستان سیرجان و باطله سنگ‌آهن از شرکت معدنی و صنعتی گل‌گهر سیرجان تهیه شده بود. همچنین سیمان مورد استفاده، سیمان پرتلند تیپ II کارخانه سیمان ممتازان در ۴۰ کیلومتری شمال غرب شهر کرمان بود. مشخصات خاک رس و باطله سنگ‌آهن در جدول ۱ آورده شده است. نمودار دانه‌بندی خاک رس و باطله سنگ‌آهن مصرفی نیز در شکل ۱ نشان داده شده است.

۲-۲- آزمایش تراکم

آزمایش تراکم به روش پروکتور اصلاح شده طبق استاندارد ASTM D1557 با هدف تعیین درصد رطوبت بهینه و حدکثر چگالی خشک نمونه‌ها به ازای درصدهای مختلف سیمان و باطله انجام شد [۲۶]. نتایج آزمایش تراکم نشان‌دهنده این است که با افزایش درصد باطله، درصد رطوبت بهینه کاهش و چگالی خشک حدکثر افزایش می‌یابد. همچنین درصد رطوبت بهینه برای نمونه‌ها بین ۱۰/۱ تا ۱۴/۷ درصد و چگالی خشک حدکثر بین ۱/۹۳۵ تا ۲/۱۲۰ گرم بر سانتی‌مترمکعب متغیر است.

سیمان و آهک با استفاده از روش گروهی بررسی داده‌ها پرداختند. جهت دستیابی به این هدف، درصد سیمان، درصد آهک، درصد رطوبت بهینه و زمان عمل‌آوری به عنوان ورودی و مقاومت فشاری تکمحوری به عنوان خروجی در نظر گرفته شد. نتایج، نشان‌دهنده دقت بالای روش GMDH برای پیش‌بینی مقاومت فشاری و مقاومت کششی خاک رس تثبیت شده با سیمان و آهک بود [۲۴]. محققان با استفاده از چهار مدل شبکه عصبی مصنوعی، روش جنگل تصادفی (RF^{21})، فرآیند گاووسی (GP^{22}) و مدل درختی به پیش‌بینی مقاومت فشاری خاک تثبیت‌شده با سیمان کلینکر و خاکستر بادی پرداختند. در این تحقیق ورودی‌ها شامل درصد خاک، درصد سیمان کلینکر، درصد خاکستر بادی و زمان عمل‌آوری بودند. نتایج نشان داد که دقت شبکه عصبی مصنوعی، فرآیند گاووسی (GP) و مدل درختی ($M5P$) برای پیش‌بینی مقاومت فشاری تقریباً برابر است. این مدل‌سازی با روش جنگل تصادفی (RF) دارای دقت بیشتری بود [۲۵].

اگرچه تحقیقات گسترده‌ای در زمینه تثبیت خاک با سیمان انجام شده است، اما تاکنون مدلی به منظور پیش‌بینی مقاومت فشاری و کششی خاک رس خمیری کم تثبیت‌شده با سیمان و باطله سنگ‌آهن با استفاده از روش‌های هوش محاسباتی ارائه نشده است. هدف از تحقیق حاضر، ارائه مدلی به منظور پیش‌بینی مقاومت فشاری و کششی خاک رس خمیری کم تثبیت‌شده با سیمان و باطله سنگ‌آهن با استفاده از روش‌های شبکه عصبی مصنوعی و سیستم استنتاج عصبی-فازی تطبیقی است.

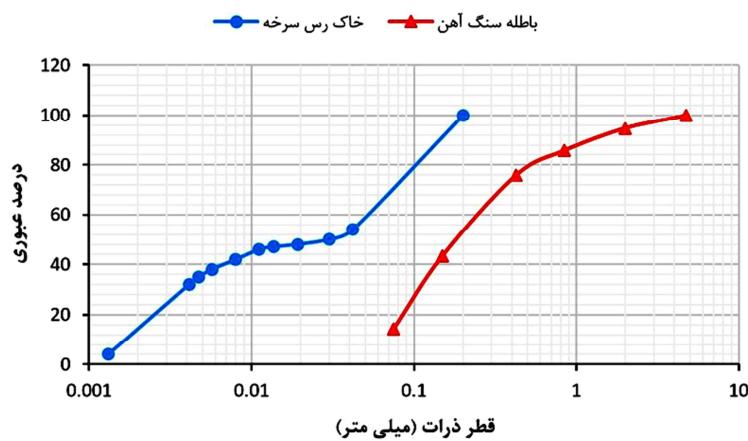
برای این منظور، ابتدا نمونه‌های تثبیت شده خاک رس با پنج درصد مختلف باطله سنگ‌آهن (صفر، ۱۰، ۲۰، ۳۰ و ۴۰ درصد) و پنج درصد مختلف سیمان (صفر، ۶، ۹

²¹- Techniques random forest

²²- Gaussian process

جدول ۱- مشخصات خاک مورد آزمایش

مشخصات	استاندارد	خاک رس	باطله سنگ آهن
طبقه‌بندی آشتو	ASTM D3282 [27]	A-6	A-2-4
طبقه‌بندی یونیفايد	ASTM D2487 [28]	CL	SM
چگالی دانه‌ها (G_s)	ASTM D854 [29]	۲/۴۵	۲/۹۵
حد روانی	ASTM D4318 [30]	۳۶/۵۸	NP
حد خمیری	ASTM D4318 [30]	۲۲/۲۴	NP
شاخص خمیری	ASTM D4318 [30]	۱۴/۳۴	NP
حد انقباض	ASTM D427 [31]	۱۷/۷۶	۳۰/۴۳
pH	ASTM D4972 [32]	۷/۷۰	۸/۸۱
NP: Non Plastic			



شکل ۱- نمودار دانه‌بندی خاک رس و باطله سنگ‌آهن

آهستگی مقدار آب محاسبه شده (درصد رطوبت بهینه) اضافه گردید. مصالح بلا فاصله پس از عمل اختلاط، در قالب و تحت اثر انرژی تراکم پروکتور اصلاح شده متراکم شدند، به گونه‌ای که حداقل چگالی از آزمایش تراکم به دست آید. سپس نمونه‌های استوانه‌ای از قالب فولادی خارج و بلا فاصله در کیسه‌های نایلونی در دمای اتاق (قریباً 24°C) عمل آوری شدند.

نمونه‌های آزمایش مقاومت کششی غیرمستقیم دارای ارتفاع ۵۰ میلی‌متر و قطر ۵۰ میلی‌متر بودند. نمونه‌ها در درصد رطوبت بهینه و تحت اثر انرژی تراکم پروکتور اصلاح شده متراکم شدند، به گونه‌ای که چگالی آن‌ها به حداقل چگالی تعیین شده در آزمایش تراکم پروکتور اصلاح شده برسد. سپس در کیسه‌های نایلونی قرار داده شده و عمل آوری شدند.

۳-۲- ساخت و عمل آوری نمونه‌های مقاومت فشاری و مقاومت کششی

به منظور توسعه پایگاه داده جهت انجام مدل‌سازی، ۲۰۰ نمونه مقاومت فشاری (۱۰۰ نمونه با ۲ تکرار) و ۲۰۰ نمونه مقاومت کششی (۱۰۰ نمونه با ۲ تکرار) ساخته شد. نمونه‌های ساخته شده دارای پنج درصد مختلف باطله سنگ‌آهن (صفر، ۱۰، ۲۰، ۳۰ و ۴۰ درصد) و پنج درصد مختلف سیمان (صفر، ۶، ۹، ۱۲ و ۱۵ درصد) و چهار زمان عمل آوری (۷، ۱۴، ۲۸ و ۵۶ روز) بودند.

نمونه‌های ساخته شده برای آزمایش مقاومت فشاری محدود نشده دارای ارتفاع ۱۰۰ میلی‌متر و قطر ۵۰ میلی‌متر بودند. برای ساخت نمونه‌ها، ابتدا مصالح در همزن به مدت ۲ دقیقه مخلوط شدند و سپس به

در تحقیق حاضر، از مجموعه داده به دست آمده از مطالعات آزمایشگاهی به منظور توسعه مدل‌های هوش محاسباتی جهت پیش‌بینی مقاومت فشاری و مقاومت کششی خاک رسی تثبیت شده با سیمان و باطله سنگ‌آهن استفاده شده است. در این مجموعه داده‌ها، پارامترهای درصد سیمان، درصد باطله، درصد رطوبت بهینه و زمان عمل‌آوری به عنوان متغیرهای مستقل و تأثیرگذار بر مقاومت فشاری تک‌محوری و مقاومت کششی غیرمستقیم در نظر گرفته شدند. در این تحقیق از ۱۰۰ داده برای ساختن مدل‌های پیش‌بینی مقاومت فشاری تک‌محوری و از ۱۰۰ داده برای ساخت مدل‌های پیش‌بینی مقاومت کششی غیرمستقیم استفاده شده است. به منظور مدل‌سازی ۷۰ درصد از داده‌ها به عنوان مجموعه همچنین توزیع فراوانی و درصد فراوانی تجمعی هریک از متغیرها در شکل ۲ نشان داده شده است. براساس این نتایج، دیده می‌شود که درصد فراوانی تجمعی متغیرها اغلب به صورت یکنواخت نبوده و همین امر به ساخت مدل‌هایی با قابلیت اطمینان بیشتر کمک خواهد نمود.

۴-۲- آزمایش مقاومت فشاری تک‌محوری (USC)

این آزمایش مطابق استاندارد ASTM D2166 انجام شد. پس از عمل‌آوری، نمونه‌ها از نایلون خارج و جهت بارگذاری، به صورت قائم بین دو صفحه مسطح دستگاه تک‌محوری قرار داده شدند [۳۳]. بارگذاری با سرعت یک میلی‌متر بر دقیقه انجام شد تا نمونه‌ها گسیخته شوند. در نهایت، مقاومت فشاری به عنوان حداکثر بار در واحد سطح به دست آمد.

۵- آزمایش مقاومت کششی غیرمستقیم (ITS)

برای انجام آزمایش مقاومت کششی غیرمستقیم، نمونه‌ها پس از عمل‌آوری از نایلون خارج و به صورت افقی بین دو صفحه مسطح دستگاه تک‌محوری قرار داده شدند. بارگذاری با سرعت یک میلی‌متر بر دقیقه تا لحظه گسیختگی نمونه‌ها انجام شد.

مقاومت کششی غیرمستقیم، مطابق با استاندارد ASTM C496 و براساس رابطه (۱) به دست آمد [۳۴]:

$$T = \frac{2P}{\pi d l} \quad (1)$$

در این رابطه، T مقاومت کششی غیرمستقیم بر حسب مگاپاسکال، P حداکثر نیروی اعمال شده به نمونه بر حسب نیوتون، d قطر نمونه بر حسب میلی‌متر و L نیز طول نمونه بر حسب میلی‌متر می‌باشد.

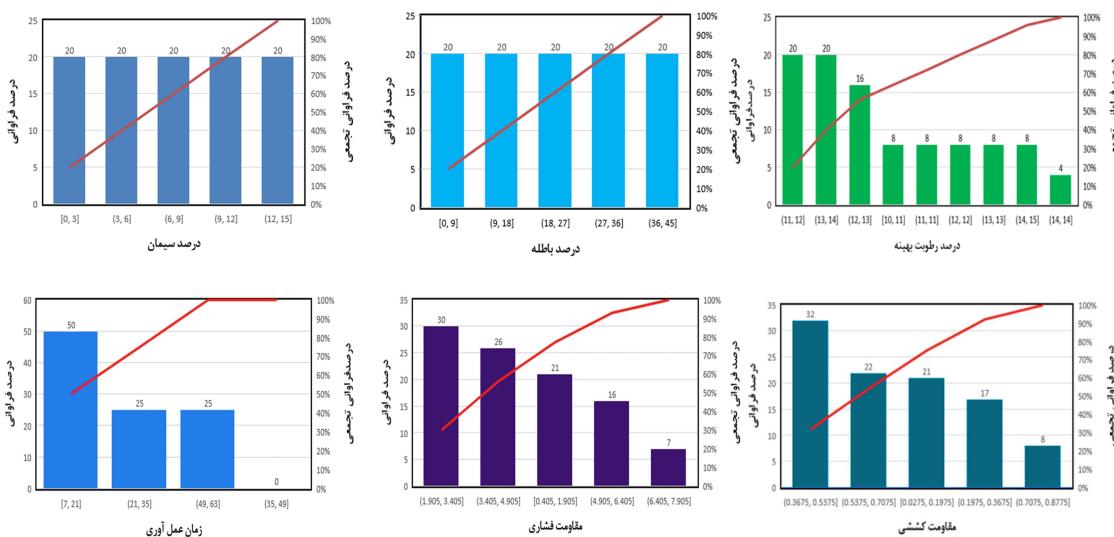
۳- مجموعه داده

جدول ۲- حدود آماری مجموعه آموزش (۷۰ داده) رس تثبیت شده با سیمان و باطله سنگ‌آهن

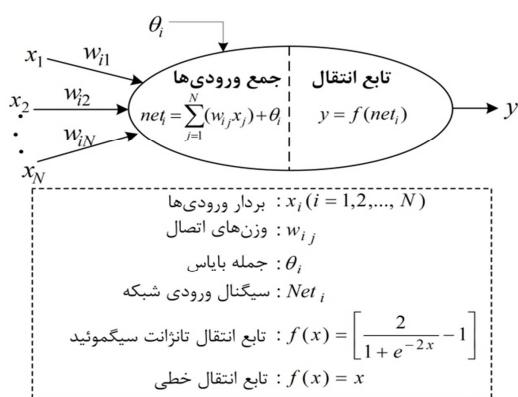
متغیر	درصد سیمان (%)	درصد باطله (%)	درصد رطوبت بهینه (%)	زمان عمل‌آوری (روز)	مقاومت فشاری تک‌محوری (MPa)	مقاومت کششی غیرمستقیم (MPa)
درصد سیمان (%)	۹	۲۰	۱۲/۶	۲۸	۳/۲۹	۰/۴۱
درصد باطله (%)	۱۵	۴۰	۱۴/۷	۵۶	۷/۲۴	۰/۸۷
درصد رطوبت بهینه (%)	(%)	(%)	(%)	(%)	(MPa)	(MPa)

جدول ۳- حدود آماری مجموعه آزمون (۳۰ داده) رس

میانه	انحراف معیار	میانگین	حداقل	حداکثر	متغیر
۹	۴/۴۰	۸/۴	صفر	۱۵	درصد سیمان (%)
۲۵	۱۴/۹۹	۲۱/۳۳	صفر	۴۰	درصد باطله (%)
۱۲/۰۵	۱/۳۲	۱۲/۳۱	۱۰/۲	۱۴/۷	درصد رطوبت بهینه (%)
۱۴	۱۸/۷۵	۲۴/۹۶	۷	۵۶	زمان عمل آوری (روز)
۳/۰۵	۱/۵۷	۳/۲۳	۰/۴۵	۶/۵۱	مقاومت فشاری تکمحوری (MPa)
۰/۴۱	۰/۱۷	۰/۳۹	۰/۰۴	۰/۷۰	مقاومت کششی غیرمستقیم (MPa)



شکل ۲- نمودارهای فراوانی تجمعی متغیرهای مجموعه داده خاک رس تثبیت شده با سیمان و باطله سنگ آهن



شکل ۳- ساختار یک نرون از شبکه عصبی مصنوعی

مجموعه‌ای از نرون‌های موازی، یک لایه را تشکیل می‌دهند. هر شبکه عصبی مصنوعی می‌تواند برای تولید خروجی‌ها خود از چندین لایه تشکیل شود که شامل

۴- مدل‌سازی

۱-۴- روش شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی (ANN) با الهام از ساختار مغز انسان و به عنوان یک ساختار ریاضی، بین مجموعه‌ای از اعداد ورودی و خروجی نگاشت برقرار می‌کنند [۳۵]. سلول‌های عصبی (نرون) که از اجزای تشکیل‌دهنده شبکه‌های عصبی مصنوعی می‌باشند، از مجموعه‌ای از ورودی و خروجی‌ها و تعداد زیادی گره یا واحد پردازشگر موسوم به تابع انتقال می‌باشند. شکل ۳، ساختار یک نرون و تابع انتقال را به صورت شماتیک نشان می‌دهد.

- در فاز دوم که فاز برگشتی یا رو به عقب نامیده می‌شود، پارامترهای شبکه، تغییر پیدا کرده و تنظیم خواهد شد. این تنظیم، براساس قانون اصلاح خطای صورت می‌گیرد و سیگنال خطای در لایه خروجی شبکه تشکیل می‌شود.

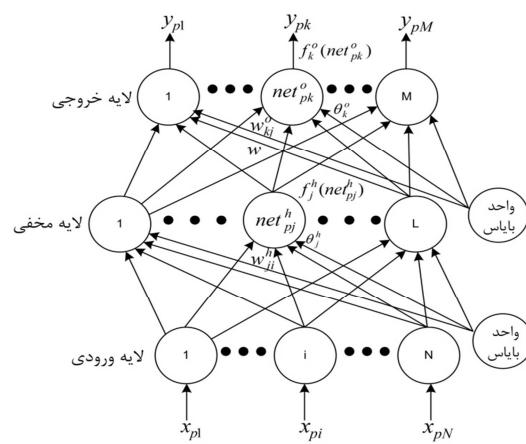
شبکه‌ها با همگرایی پاسخ‌های آن‌ها با مقادیر متناظر واقعی، حالت آموزش‌دیده پیدا خواهند کرد و انتظار می‌رود تا در صورت ورود داده‌های دارای تنوع و تعداد مطلوب، پاسخ‌های پیش‌بینی شده توسط شبکه با مقادیر واقعی متناظر خود کمترین میزان اختلاف ممکن را داشته باشند.

۴-۲- روش سیستم استنتاج عصبی- فازی تطبیقی

این روش برای اولین بار در سال ۱۹۹۳ توسط جانگ^{۳۹} مطرح شد [۳۹]. سیستم استنتاج فازی عصبی- تطبیقی نوعی شبکه عصبی مصنوعی براساس سیستم فازی تاکاگی- سوگنو است. این سیستم فازی با استفاده از مجموعه‌ای از قوانین فازی اگر- آنگاه قابلیت یادگیری برای تقریب زدن توابع غیرخطی را دارد. به طوری که با استفاده از این قواعد می‌توان ارتباط بین تعدادی متغیر ورودی و خروجی را به دست آورد. به این ترتیب از سیستم استنتاج فازی می‌توان برای مدل‌سازی داده‌های ورودی- خروجی که دارای عدم قطعیت بالایی هستند، استفاده کرد؛ زیرا در چنین شرایطی روش‌های متداول پیش‌بینی مانند رگرسیون نمی‌توانند عدم قطعیت‌های موجود در داده‌ها را به خوبی در نظر بگیرند. سیستم‌های فازی به طور مستقل، قابلیت یادگیری ندارند؛ ولی در ترکیب با شبکه‌های عصبی، قابلیت یادگیری نیز برای آن‌ها ایجاد می‌شود. ساختار ANFIS شامل پنج لایه است که به ترتیب گره‌های ورودی، گره‌های قاعده، گره‌های میانی، گره‌های نتیجه و گره‌های خروجی می‌باشند و به طور مستقیم با هم ارتباط دارند. هر گره دارای تابعی با

لایه‌های پنهان و لایه خروجی خواهد شد و این لایه‌ها به صورت سری به یکدیگر متصل می‌شوند.

هر ورودی در شبکه عصبی دارای وزن متناظر با خود بوده که با تأثیرپذیری از آن و با هدف اعمال پردازش و تولید ورودی‌های لایه‌های بعدی واردتابع انتقال خواهد شد. تاکنون با توجه به نوع توابع انتقال، لایه‌های تشکیل‌دهنده شبکه و نحوه تأثیرگذاری وزن‌ها بر ورودی‌ها، انواع مختلف شبکه‌های عصبی مصنوعی معرفی شده است. یکی از انواع مختلف شبکه‌های عصبی مصنوعی در رابطه با حل مسائلی که نیاز به شناسایی الگوها و ایجاد توابع نگاشت پیچیده دارند، شبکه‌های عصبی پس‌خور با انتشار برگشتی است که در شکل ۴ نمایش داده شده است [۳۶].



شکل ۴- معماری شبکه عصبی مصنوعی پس‌خور با انتشار برگشتی دارای یک لایه پنهان

آموزش شبکه‌های عصبی پس‌خور با استفاده از الگوریتم انتشار برگشتی دارای دو مرحله اصلی است [۳۷] و [۳۸]:

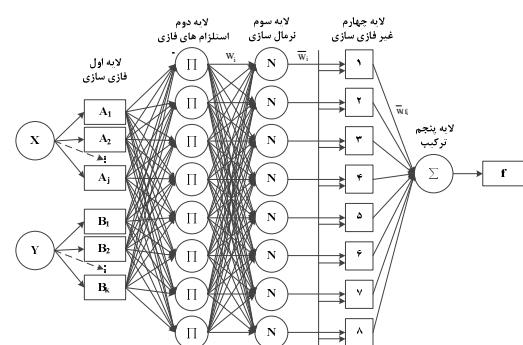
- در فاز اول که فاز رو به جلو نامیده می‌شود، بردار ورودی به شبکه اعمال شده و تأثیرات آن از طریق لایه پنهان به لایه خروجی منتشر می‌شود و بردار خروجی ارائه شده در لایه خروجی پاسخ واقعی شبکه را تشکیل می‌دهد. در این مسیر پارامترهای شبکه، ثابت و بدون تغییر در نظر گرفته می‌شود.

²³- Jang

بهترین معماری را با توجه به شرط کمینه‌سازی میزان جذر میانگین مربعات خطای (RMSE^{۲۴}) کل داده‌ها پیدا می‌کند.تابع انتقال در لایه پنهان به صورت تائزانت سیگموئید^{۲۵} و تابع انتقال در لایه خروجی به صورت خطی^{۲۶} در نظر گرفته شد. به منظور آموزش، اعتبارستنی و آزمون شبکه برای پیش‌بینی مقاومت فشاری و کششی به ترتیب از ۳۰ و ۱۰ درصد کل مجموع داده‌ها استفاده شد. در جدول ۴ تعداد نرون‌های بهینه به همراه پارامترهای عملکردی شبکه عصبی بهینه به منظور پیش‌بینی مقاومت فشاری تک محوری و مقاومت کششی نشان داده شده است. همانگونه که ملاحظه می‌شود، معماری بهینه شبکه عصبی مصنوعی برای پیش‌بینی مقاومت فشاری به صورت ۴-۱۷-۱ (۴-ورودی، ۱۷ نرون در لایه مخفی و ۱ خروجی) است و معماری بهینه شبکه عصبی مصنوعی برای پیش‌بینی مقاومت کششی به صورت ۱-۹-۴ (۴-ورودی، ۹ نرون در لایه مخفی و ۱ خروجی) است.

عملکرد مدل شبکه عصبی مصنوعی برای پیش‌بینی مقاومت فشاری تکمحوری و مقاومت کششی غیرمستقیم خاک رس ثبیت شده با سیمان و باطله سنگ‌آهن با توجه به داده‌های آموزش و آزمون به ترتیب در شکل‌های ۶ و ۷ نشان داده شده است. با توجه به شکل ۶ می‌توان دریافت که مدل شبکه عصبی برای پیش‌بینی مقاومت فشاری تکمحوری دارای مقادیر R^2 برابر با ۰/۹۹ و در شکل ۷ برای پیش‌بینی مقاومت کششی غیرمستقیم دارای مقادیر R^2 برابر با ۰/۹۷ و ۰/۹۷ به ترتیب برای داده‌های آموزش و آزمون است. این اعداد نشان‌دهنده دقیق بالای روش شبکه عصبی مصنوعی در پیش‌بینی مقاومت فشاری و مقاومت کششی است. به علاوه نزدیک بودن پارامتر R^2 برای داده‌های آموزش و آزمون

پارامترهای قابل تنظیم یا ثابت است [۴۰]. شکل ۵ ساختار مناسب ANFIS متناسب با داده‌های ورودی، درجه عضویت، قوانین و توابع عضویت ورودی و خروجی انتخاب می‌گردد [۳۹].



شکل ۵- ساختار مدل فازی- عصبی نوع سه [۳۹]

در مرحله آموزش با اصلاح پارامترهای درجه عضویت براساس میزان خطای قابل قبول، مقادیر ورودی به مقادیر واقعی نزدیک‌تر می‌شود. اکثر سیستم‌های استنتاج فازی شامل سه نوع، سیستم ممداňی، سیستم سوگنو و سیستم سوکاموتون می‌باشند که در بیشتر موارد از سیستم ممداňی استفاده می‌شود، اما سیستم سوگنو در محاسبات عملکرد بهتری دارد و از خروجی قطعی برخوردار می‌باشد [۴۰].

در این پژوهش از سیستم مدل‌سازی به روش سوگنو و تابع عضویت گوسی و برای تعیین درجه عضویت بهینه از روش سعی و خطای استفاده شده است. همچنین از الگوریتم یادگیری پیوندی که ترکیبی از الگوریتم پس انتشار خطای و روش حداقل مربعات می‌باشد، برای آموزش و تطبیق در سیستم استنتاج فازی استفاده شده است.

۴-۳-۴- مدل‌سازی با روش شبکه عصبی مصنوعی

در این تحقیق از روش سعی و خطای به منظور تعیین معماری بهینه شبکه عصبی (تعداد نرون‌ها در لایه مخفی) استفاده شد. برای این منظور، برنامه‌ای در محیط متلب نوشته شد که فرآیند سعی و خطای را به صورت خودکار و با هدف تعیین بهترین معماری شبکه انجام می‌دهد. برنامه فوق با ارزیابی تعداد مختلف نرون‌ها،

²⁴- Root-Mean-Square Error

²⁵- Tansig

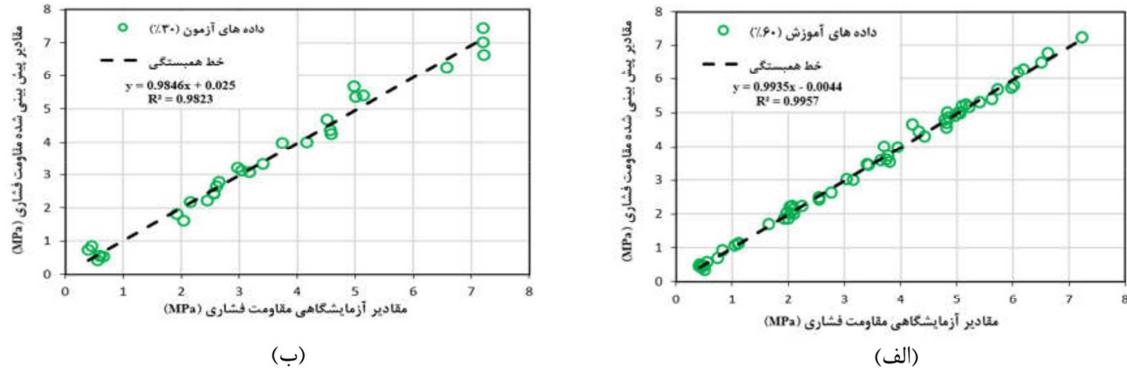
²⁶- Purelin

توسعه داده شده است.

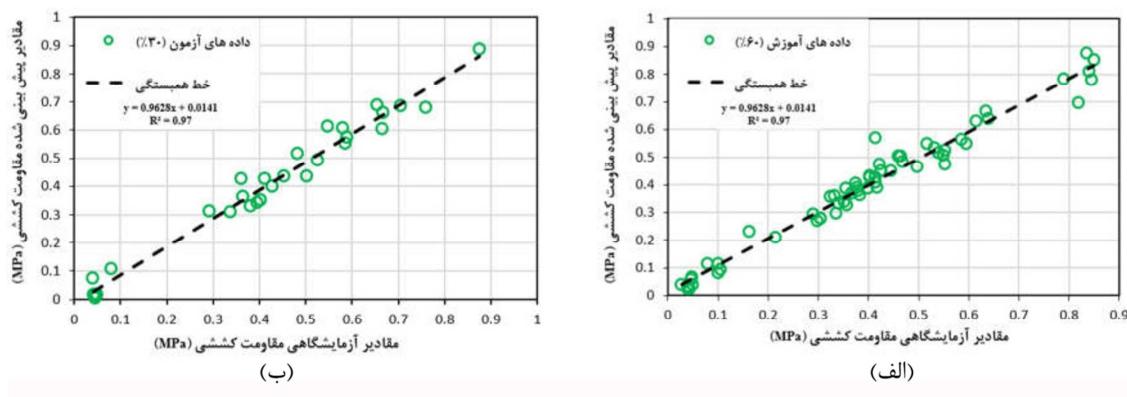
نشان‌دهنده تعمیم‌پذیری بسیار بالای شبکه‌های عصبی

جدول ۴- تأثیر تعداد نمونه‌ها بر روی عملکرد ANN مربوط به پیش‌بینی مقاومت فشاری و کششی

MSE کل داده‌ها	MSE اعتبارسنجی	MSE مجموعه آزمون	MSE مجموعه آموزش	R ² کل داده‌ها	R ² اعتبارسنجی	R ² مجموعه آزمون	R ² مجموعه آموزش	تعداد نمونه‌ای محفی اول	مدل
۰/۰۵۳۲	۰/۲۰۸۱	۰/۰۷۴۱	۰/۰۱۶۹	۰/۹۸۵۸	۰/۹۱۸۰	۰/۹۸۲۲	۰/۹۹۵۸	۱۷	فشاری
۰/۰۰۱۵	۰/۰۰۱۱	۰/۰۰۱۶	۰/۰۰۱۵	۰/۹۷۲۱	۰/۹۸۹۹	۰/۹۷۵۳	۰/۹۷۰۰	۹	کششی



شکل ۶- عملکرد مدل ANN برای پیش‌بینی مقاومت فشاری، (الف) آموزش و (ب) آزمون



شکل ۷- عملکرد مدل ANN برای پیش‌بینی مقاومت کششی، (الف) آموزش و (ب) آزمون

داده شده دارای سیستم فازی تاکاگی- سوگنو با توابع عضویت گوسین بود. برای یافتن تعداد بهینه توابع عضویت سیستم استنتاج عصبی- فازی تطبیقی از روش سعی و خطا استفاده شد. برای این منظور، تعداد توابع عضویت در دامنه ۳ الی ۱۵ تغییر داده شد و برای تک تک اعداد این دامنه، ۱۰ شبکه متفاوت آموزش و بهترین شبکه مربوط به هر معماری ذخیره‌سازی شد. تعداد بهینه توابع عضویت برای مدل پیش‌بینی مقاومت فشاری و مقاومت کششی به همراه پارامترهای مدل ANFIS برای پیش‌بینی مقاومت فشاری و مقاومت کششی در جدول ۵ داده شده است. همانگونه که ملاحظه می‌شود تعداد بهینه توابع عضویت

۴-۴- مدل‌سازی با روش سیستم استنتاج عصبی- فازی (ANFIS)

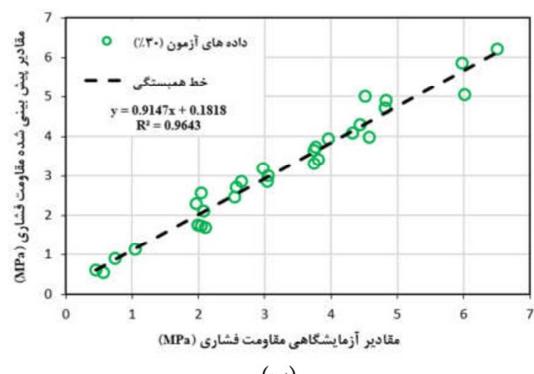
مدل سیستم استنتاج عصبی- فازی تطبیقی نیز با استفاده از جعبه ابزار برنامه متلب توسعه داده شد. با توجه به اینکه در مرحله آموزش، مدل سیستم استنتاج عصبی- فازی تطبیقی نیاز به اعتبارسنجی نبود؛ به منظور مقایسه نتایج با شبکه عصبی مصنوعی، مجموع ۷۰ درصد داده‌ها (داده‌های آموزش و اعتبارسنجی مطابق روش شبکه عصبی مصنوعی) برای آموزش و ۳۰ درصد مجموع داده‌ها به عنوان مجموعه آزمون در نظر گرفته شد. مدل توسعه

R^2 برابر با 0.98 و 0.96 است. همچنین مطابق شکل ۹ سیستم استنتاج عصبی- فازی تطبیقی بهینه برای پیش‌بینی مقاومت کششی دارای مقادیر R^2 برابر با 0.98 و 0.91 به ترتیب برای داده‌های آموزش و آزمون می‌باشند. اختلاف نسبتاً زیاد مقادیر R^2 برای مجموعه داده‌های آموزش و آزمون مدل ANFIS در پیش‌بینی مقاومت کششی نشان‌دهنده قابلیت تعمیم‌پذیری نسبتاً پایین آن است.

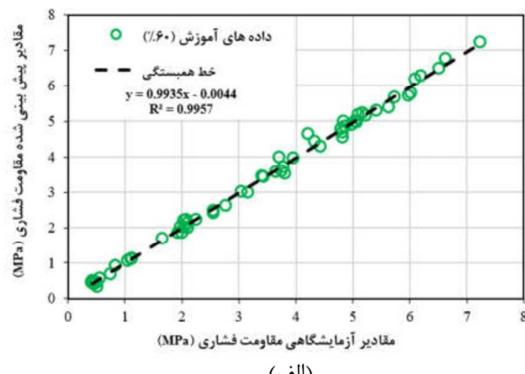
برای پیش‌بینی مقاومت فشاری و مقاومت کششی به ترتیب برابر با 14 و 10 می‌باشند. عملکرد مدل سیستم استنتاج عصبی- فازی تطبیقی برای پیش‌بینی مقاومت فشاری تکمحوری و مقاومت کششی غیرمستقیم خاک رس ثابت شده با سیمان و باطله سنگ‌آهن با توجه به داده‌های آموزش و آزمون به ترتیب در شکل‌های ۸ و ۹ نشان داده شده است. با توجه به شکل ۸ می‌توان پی برد که مدل سیستم استنتاج عصبی- فازی تطبیقی بهینه برای پیش‌بینی مقاومت فشاری تکمحوری دارای مقادیر

جدول ۵- تأثیر تعداد توابع عضویت بر روی عملکرد ANFIS مربوط به پیش‌بینی مقاومت فشاری و کششی

MSE کل داده‌ها	MSE مجموعه آزمون	MSE مجموعه آموزش	R^2 کل داده‌ها	R^2 مجموعه آزمون	R^2 مجموعه آموزش	تعداد توابع عضویت	مقاومت
0.0697	0.1039	0.0551	0.9812	0.9643	0.9868	۱۴	فشاری
0.0013	0.0027	0.00062	0.9759	0.9103	0.9898	۱۰	کششی

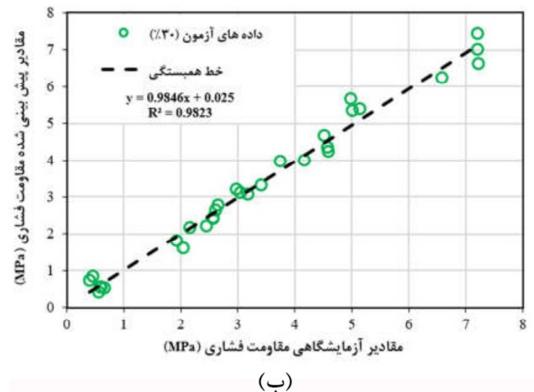


(ب)

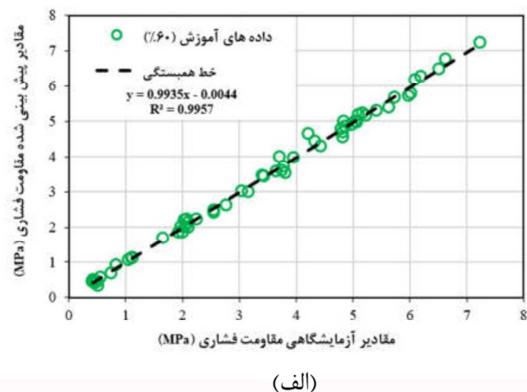


(الف)

شکل ۸- عملکرد مدل ANFIS برای پیش‌بینی مقاومت فشاری (الف): آموزش و (ب): آزمون



(ب)



(الف)

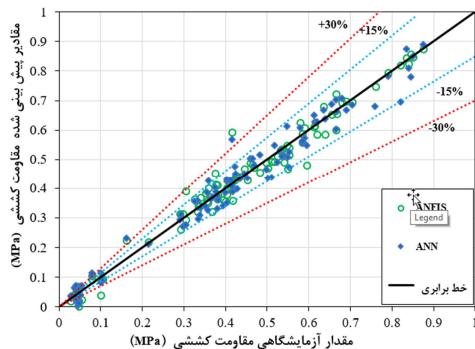
شکل ۹- عملکرد مدل ANFIS برای پیش‌بینی مقاومت کششی، (الف) آموزش و (ب) آزمون

در شکل ۱۰، عملکرد دو مدل ANN و ANFIS برای پیش‌بینی مقاومت فشاری و کششی برای کل

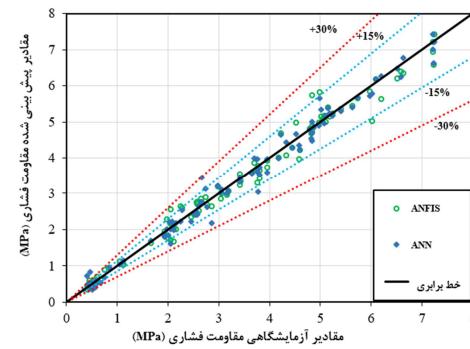
۵- مقایسه عملکرد روش‌های ANFIS و ANN

همچنین می‌توان دید که از بین دو روش ارزیابی شده در این تحقیق روش ANFIS در مقایسه با روش ANFIS امکان پیش‌بینی دقیق‌تر مقاومت فشاری و کششی را فراهم ساخته است.

مجموعه داده‌ها مقایسه شده است. در این شکل علاوه بر خط برابر محدوده خطای ۱۵ و ۳۰ درصد نیز ترسیم شده است. همانگونه که ملاحظه می‌شود مدل‌های ANFIS و ANFIS در اکثر موارد مقدار مقاومت فشاری و کششی را با خطای کمتر از ۱۵ درصد پیش‌بینی می‌کنند.



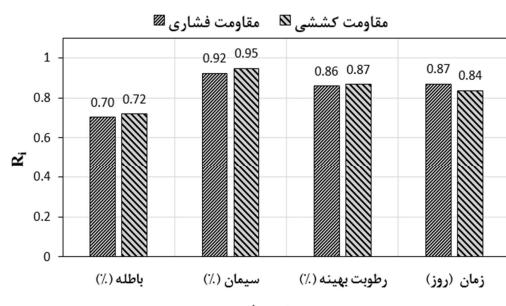
(ب)



(الف)

شکل ۱۰- مقایسه عملکرد مدل‌های مختلف در پیش‌بینی مقاومت فشاری و کششی، (الف) مقاومت فشاری و (ب) مقاومت کششی

ارتباط بیشتر یک پارامتر ورودی خاص با خروجی مدل می‌باشد. با توجه به شکل ۱۱ می‌توان دریافت که در طیف وسیعی از داده‌های ارزیابی شده در این تحقیق، پارامتر درصد سیمان دارای بیشترین درجه اهمیت و پارامتر درصد باطله دارای کمترین درجه اهمیت برای پیش‌بینی مقاومت فشاری تکمحوری است. همچنین پارامتر درصد سیمان دارای بیشترین درجه اهمیت و پارامتر درصد باطله دارای کمترین درجه اهمیت برای پیش‌بینی مقاومت کششی غیرمستقیم است.



شکل ۱۱- درجه اهمیت پارامترهای ورودی بر مقاومت فشاری و کششی

۷- تحلیل پارامتریک

۶- تحلیل حساسیت

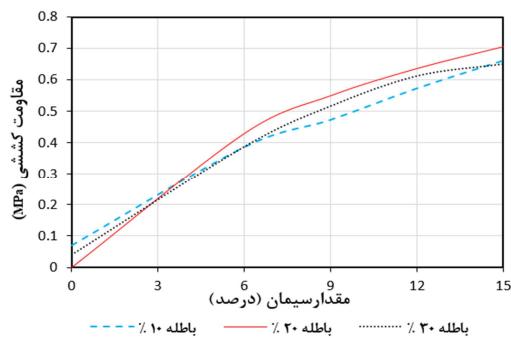
برای انجام تحلیل حساسیت یا تعیین درجه اهمیت روش‌های متفاوتی وجود دارد. در این تحقیق از روش دامنه کسینوس (CAM^{۲۷}) با هدف ارزیابی درجه اهمیت هریک از پارامترهای ورودی بر روی پیش‌بینی مقاومت فشاری و مقاومت کششی استفاده شده است. در این روش، درجه اهمیت پارامتر ورودی با توجه به درجه همبستگی میان داده ورودی و خروجی از رابطه (۲) به دست می‌آید:

$$R_i = \frac{\sum_{k=1}^m x_{ik} y_k}{\sqrt{\sum_{k=1}^m x_{ik}^2 \times \sum_{k=1}^m y_k^2}} \quad (2)$$

که در این رابطه x_{ik} متغیر مستقل داده k م و y_k متغیر وابسته متناظر با داده k م و m تعداد کل داده‌ها می‌باشد. براساس این رابطه، هرچه R_i بالاتر باشد، نشان‌دهنده

²⁷- Cosine Amplitude Method

با توجه به شکل ۱۳ مشاهده می‌شود که با افزایش درصد سیمان، مقاومت کششی افزایش پیدا می‌کند. همچنین همانند مقاومت فشاری، نرخ افزایش مقاومت کششی در مقابل افزایش درصد سیمان تا درصد سیمان ۶ درصد بیشتر است و با افزایش درصد سیمان به بیش از ۶ درصد این نرخ کاهش می‌یابد. همچنین ملاحظه می‌شود که همانند مقاومت فشاری، افزایش درصد باطله تأثیر مشخصی بر روی مقاومت کششی ندارد. به طور مثال در شکل ۱۳ مقاومت کششی مربوط به نمونه‌های حاوی ۱۰ درصد باطله تا زمانی که درصد سیمان کمتر از حدود ۶ درصد باشد بیشتر از نمونه‌های حاوی ۳۰ درصد باطله است و با افزایش درصد سیمان به بیش از ۶ درصد، مقاومت کششی نمونه‌های حاوی ۱۰ درصد باطله کمتر از نمونه‌های حاوی ۳۰ درصد باطله می‌شود.



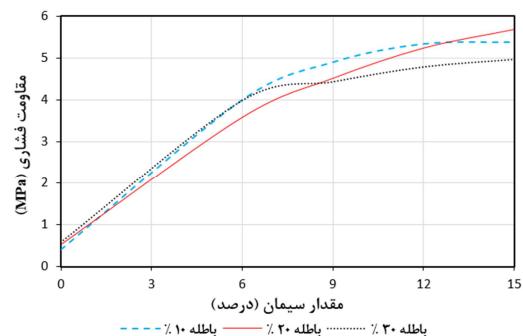
شکل ۱۳- تأثیر مقدار سیمان بر مقاومت کششی

۲-۷- تحلیل پارامتریک تأثیر زمان عملآوری بر مقاومت فشاری و کششی

یکی دیگر از پارامترهای مؤثر بر مقاومت فشاری و کششی، زمان عملآوری است. برای انجام تحلیل پارامتریک مربوط به زمان عملآوری، درصد باطله برابر با ۲۰ درصد و سه درصد مختلف سیمان ۹، ۶ و ۱۵ درصد و رطوبت بهینه متناظر با آنها فرض گردید و با تغییر زمان عملآوری در بازه‌های ۷، ۱۴، ۲۸ و ۵۶ روز، مقاومت فشاری و کششی با استفاده از مدل شبکه عصبی مصنوعی تعیین گردید. با توجه به شکل ۱۴ مشاهده می‌شود که با افزایش زمان عملآوری، مقاومت فشاری و مقاومت

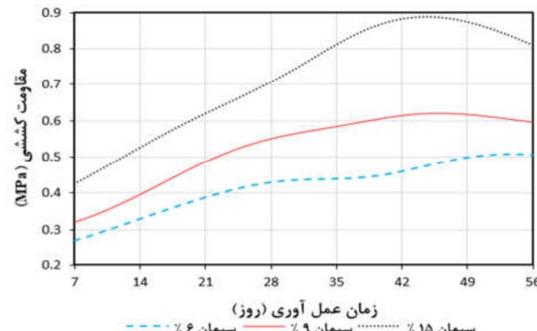
۱-۷- تأثیر درصد سیمان بر مقاومت فشاری و کششی

یکی از پارامترهای مؤثر بر مقاومت فشاری و کششی، درصد سیمان است. برای انجام تحلیل پارامتریک، درصد باطله برابر با ۲۰ درصد و زمان عملآوری برابر با ۲۸ روزه و درصد رطوبت بهینه به دلیل واستگی به درصد سیمان، متناظر با درصد سیمان (صفرا، ۶، ۹ و ۱۵ درصد) به صورت متغیر در نظر گرفته شد. تحلیل پارامتریک، به جز مقدار میانگین درصد باطله، به ازای ۱۰ درصد باطله بیشتر و ۱۰ درصد باطله کمتر نیز انجام شد. شکل ۱۲، تأثیر درصد سیمان بر مقاومت فشاری را با استفاده از مدل شبکه عصبی نشان می‌دهد. مشاهده می‌شود که با افزایش درصد سیمان، مقاومت فشاری افزایش پیدا می‌کند. این بررسی نشان می‌دهد که با افزایش یافتن درصد سیمان، مقاومت فشاری در بازه صفر تا ۶ درصد با شبیب بیشتری افزایش می‌یابد و با افزایش درصد سیمان به بیش از ۶ درصد، این شبیب کاهش می‌یابد. همان‌گونه که مشخص است، بین درصد باطله و مقاومت فشاری ارتباط مستقیمی وجود ندارد. به طور مثال در شکل ۱۲ مقاومت فشاری مربوط به نمونه‌های حاوی ۳۰ درصد باطله تا زمانی که درصد سیمان کمتر از حدود ۹ درصد باشد بیشتر از نمونه‌های حاوی ۲۰ درصد باطله است و با افزایش درصد باطله به بیش از ۶ درصد، مقاومت فشاری نمونه‌های حاوی ۳۰ درصد باطله کمتر از نمونه‌های حاوی ۲۰ درصد باطله می‌شود.



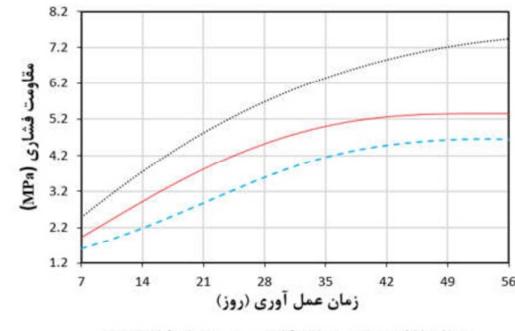
شکل ۱۲- تأثیر مقدار سیمان بر مقاومت فشاری

به عبارتی، در روزهای اولیه عمل‌آوری، نرخ کسب مقاومت بیشتر است و با افزایش زمان عمل‌آوری، نرخ کسب مقاومت کاهش می‌یابد.



(ب)

کششی افزایش می‌یابد. همچنین ملاحظه می‌شود که با افزایش زمان عمل‌آوری، نرخ افزایش مقاومت فشاری و کششی نسبت به افزایش زمان عمل‌آوری کاهش می‌یابد.



(الف)

شکل ۱۴- تأثیر زمان عمل‌آوری بر (الف) مقاومت فشاری و (ب) مقاومت کششی

مقاومت فشاری و مقاومت کششی پیش‌بینی شده

- توسط مدل شبکه عصبی مصنوعی دارند.
- ۵- تحلیل پارامتریک نشان داد که با افزایش درصد سیمان و زمان عمل‌آوری، مقاومت فشاری و مقاومت کششی خاک رس تثبیت‌شده با سیمان و باطله سنگ‌آهن افزایش می‌یابد.
- ۶- پیشنهاد می‌شود تا از سایر روش‌های تعیین درجه اهمیت به منظور انجام تحلیل حساسیت استفاده شود.

- ۷- نتایج این تحقیق با دقت مناسب در خصوص خاک‌های رس مشابه با این تحقیق از دیدگاه طبقه‌بندی خاک و حدود اتریبرگ قابل تعمیم است. با این وجود از نتایج این تحقیق نمی‌توان در مورد خاک‌هایی که اختلاف زیادی با خاک رس مورد استفاده در این تحقیق دارند، استفاده نمود. همچنین مدل‌های توسعه یافته در این تحقیق در صورتی که مقادیر ورودی‌ها در محدوده داده شده در جدول ۲ باشند، قابل استفاده می‌باشند.

۸- نتیجه‌گیری

۱- از بین مدل‌های ارزیابی شده جهت پیش‌بینی مقاومت فشاری خاک رس تثبیت‌شده با سیمان و باطله سنگ‌آهن در این تحقیق، مدل ANN با ضریب رگرسیون 0.985 ± 0.001 دارای دقت بیشتر و مدل ANFIS با ضریب رگرسیون 0.981 ± 0.001 دارای دقت کمتر است.

۲- از بین مدل‌های ارزیابی شده جهت پیش‌بینی مقاومت کششی خاک رس تثبیت‌شده با سیمان و باطله سنگ‌آهن در این تحقیق، مدل ANN با ضریب رگرسیون 0.972 ± 0.001 دارای دقت بیشتر و مدل ANFIS با ضریب رگرسیون 0.9759 ± 0.001 دارای دقت کمتر است.

۳- روش ANN در اکثر موارد، امکان پیش‌بینی پارامترهای مقاومت فشاری و کششی را با درصد خطای کمتر از 15% فراهم می‌کند.

۴- تحلیل حساسیت نشان داد که درصد سیمان و زمان عمل‌آوری، بیشترین تأثیر را بر میزان

مراجع

- [1] Mu, T. (2013). *Soil Stabilization with Fly Ash and Fibers*. Thesis of Master of Science, Southern Illinois University Carbondale.
- [2] Bergado, D. T., Anderson, L. R., Miura, N., & Balasubramaniam, A. S. (1996). *Soft ground improvement in lowland and other environments*. ASCE, 978-0-7844-0151-4 (ISBN-13)|0-7844-0151-9 (ISBN-10).
- [3] Braja, M. D. (1990). *Principle of foundation engineering*. PWS-KENT, Boston, 978-0495668107 (ISBN-13)|0495668109 (ISBN-10).
- [4] Nelson, J., & Miller, D. J. (1997). *Expansive soils: problems and practice in foundation and pavement engineering*. John Wiley & Sons.
- [5] Barclay, R. T., Casias, T. J. E. A., David A. C., De Graffenreid, R. L., Hess, J. R., Roof, H. C., & Dennis, W. S. (1990). "State-of-the-art report on soil cement", *ACI Materials Journal*, 87(4), 395-417.
- [6] Ghasemi, M., & Nezamabadi, B. (2016). "Evaluating the effect of iron mine wastes on the compressive strength of lime concrete", *3rd International Congress on New Research Achievements in Civil Engineering, Architecture & Urban Management*, Tehran, Iran.
- [7] Ghasemi, M., & Nezamabadi, B. (2016). "Evaluating the effect of iron mine wastes on the strength of cement sand mortars", *3rd International Congress on New Research Achievements in Civil Engineering, Architecture & Urban Management*, Tehran, Iran.
- [8] Ghasemi, M., & Normandi, A. (2016). "Evaluating the effect of iron mine wastes on lime stabilized soil", *1st International Comprehensive Competition Conference on Engineering Science in Iran*, Anzali, Iran.
- [9] Yarmahmoudi, A. (2018). *Stabilization of cohesive red clay soil using Portland cement and iron ore mine tailing*. M.Sc Thesis, Department of Civil Engineering, Sirjan University of Technology, Iran.
- [10] Gunaydin, O., Gokoglu, A., & Fener, M. (2010). "Prediction of artificial soil's unconfined compression strength test using statistical analyses and artificial neural networks", *Advances in Engineering Software*, 41(9), 1115-1123.
- [11] Alavi, A. H., & Gandomi, A. H. (2011). "A robust data mining approach for formulation of geotechnical engineering systems", *Engineering Computations*, 28(3), 242-274.
- [12] Das, S. K., Samui, P., & Sabat, A. K. (2011). "Application of Artificial Intelligence to Maximum Dry Density and Unconfined Compressive Strength of Cement Stabilized Soil", *Geotechnical and Geological Engineering*, 29(3), 329-342.
- [13] Shrestha, R., & Al-Tabbaa, A. (2012). "Development of predictive models for cement stabilized soils", *In Grouting and Deep Mixing*, 2012, 221-230.
- [14] Motamed, S., Shamshirband, S., Hashim, R., Petković, D., & Roy, C. (2015). "RETRACTED: Estimating unconfined compressive strength of cockle shell–cement–sand mixtures using soft computing methodologies", *Engineering Structures*, 98, 49-58.
- [15] Motamed, S., Shamshirband, S., Petković, D., & Hashim, R. (2015). "Application of adaptive neuro-fuzzy technique to predict the unconfined compressive strength of PFA-sand-cement mixture", *Powder Technology*, 278, 278-285.
- [16] Suman, S., Mahamaya, M., & Das, S. K. (2016). "Prediction of Maximum Dry Density and Unconfined Compressive Strength of Cement Stabilised Soil Using Artificial Intelligence Techniques", *International Journal of Geosynthetics and Ground Engineering*, 2(2), 1-11.
- [17] Mozumder, R. A., & Laskar, A. I. (2015). "Prediction of unconfined compressive strength of geopolymers stabilized clayey soil using Artificial Neural Network", *Computers and Geotechnics*, 69, 291-300.
- [18] Mozumder, R. A., Laskar, A. I., & Hussain, M. (2017). "Empirical approach for strength prediction of geopolymers stabilized clayey soil using support vector machines", *Construction and Building Materials*, 132, 412-424.
- [19] Javdanian, H. (2017). "The Effect of Geopolymerization on the Unconfined Compressive Strength of Stabilized Fine-grained Soils", *International Journal of Engineering*, 30(11), 1673-1680.
- [20] Sathyapriya, S., Arumairaj, P. D., & Ranjini, D. (2017). "Prediction of unconfined compressive strength of a stabilised expansive clay soil using ANN and regression analysis (SPSS)", *Asian Journal of Research in Social Sciences and Humanities*, 7(2), 109-123.
- [21] Güllü, H., & Fedakar, H. I. (2017). "On the prediction of unconfined compressive strength of silty soil stabilized with bottom ash, jute and steel fibers via artificial intelligence", *Geomech Eng*, 12(3), 441-464.
- [22] Chore, H. S., & Magar, R. B. (2017). "Prediction of unconfined compressive and Brazilian tensile strength of fiber reinforced cement stabilized fly ash mixes using multiple linear regression and artificial neural network", *Advances in Computational Design*, 2, 225-240.
- [23] Sihag, P., Suthar, M., & Mohanty, S. (2019). "Estimation of UCS-FT of Dispersive Soil Stabilized with Fly Ash, Cement Clinker and GGBS by Artificial Intelligence", *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 1-12.

- [24] Ghanizadeh, A., Bayat, M., Tavana Amlashi, A., & Rahrovan, M. (2019). "Prediction of unconfined compressive strength of clay subgrade soil stabilized with Portland cement and lime using Group Method of Data Handling (GMDH)", *Journal of Transportation Infrastructure Engineering*, 5(1), 77-96.
- [25] Mohanty, S., Roy, N., Singh, S. P., & Sihag, P. (2019). "Estimating the Strength of Stabilized Dispersive Soil with Cement Clinker and Fly Ash", *Geotechnical and Geological Engineering*, 37(4), 2915-2926.
- [26] ASTM International. (2015). *ASTM D 1557: standard Test Methods for Laboratory Compaction Characteristics of Soil Using Modified Effort* (56,000 ft-lbf/ft³ (2,700 kN-m/m³)). In Annual book of ASTM standards 2015 (pp. 19428-2959). West Conshohocken, PA: American Society for Testing & Materials.
- [27] ASTM International. (2015). *ASTM D 3282: Standard Test Method Practice for Classification of Soils & Soil-Aggregate Mixtures for Highway Construction Purposes*. In Annual book of ASTM standards 2015 (pp. 19428-2959). West Conshohocken, PA: American Society for Testing & Materials.
- [28] ASTM International. (2015). *ASTM D 2487: Standard Test Method Practice for Classification of Soils for Engineering Purposes* (Unified Soil Classification System). In Annual book of ASTM standards 2015 (pp. 19428-2959). West Conshohocken, PA: American Society for Testing & Materials.
- [29] ASTM International. (2014). *ASTM D 854: standard test methods for Specific Gravity of Soil Solids by Water Pycnometer on Soil*. In Annual book of ASTM standards 2014 (pp. 19428-2959). West Conshohocken, PA: American Society for Testing & Materials.
- [30] ASTM International. (2014). *ASTM D 4318: Standard Test Methods for Liquid Limit, Plastic Limit, & Plasticity Index of Soils*. In Annual book of ASTM standards 2014 (pp. 19428-2959). West Conshohocken, PA: American Society for Testing & Materials.
- [31] ASTM International. (2008). *ASTM D 427: standard Test Method for Shrinkage Factors of Soils by The Mercury Method*. In Annual book of ASTM standards 2008 (pp. 19428-2959). West Conshohocken, PA: American Society for Testing & Materials.
- [32] ASTM International. (2013). *ASTM D 4972: Standard Test Method Method for PH of Soils*. In Annual book of ASTM standards 2013 (pp. 19428-2959). West Conshohocken, PA: American Society for Testing & Materials.
- [33] ASTM International. (2015). *ASTM D 2166: standard Test Method for Unconfined Compressive Strength of Cohesive Soil*. In Annual book of ASTM standards 2015 (pp. 19428-2959). West Conshohocken, PA: American Society for Testing & Materials.
- [34] ASTM International. (2014). *ASTM D 496: Standard Test Method Method for Splitting Tensile Strength of Cylindrical Concrete Specimens*. In Annual book of ASTM standards 2014 (pp. 19428-2959). West Conshohocken, PA: American Society for Testing & Materials.
- [35] Haykin, S. (2001). *Neural networks: principles and practice*. Bookman, 11, 900.
- [36] Freeman, J. A., & Skapura, D. M. (1992). "Backpropagation", *Neural Networks Algorithm Applications and Programming Techniques*, 40, 89-125.
- [37] Werbos, P. (1974). *Beyond regression: new tools for prediction and analysis in the behavioral sciences*. Ph. D. dissertation, Harvard University.
- [38] Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). "Learning representations by back-propagating errors", *Nature*, 323(6088), 533-536.
- [39] Jang, J. R. (1993). "ANFIS: adaptive-network-based fuzzy inference system", *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), 665-685.
- [40] Kisi, O., Haktanir, T., Ardiclioglu, M., Ozturk, O., Yalcin, E., & Uludag, S. (2009). "Adaptive neuro-fuzzy computing technique for suspended sediment estimation", *Advances in Engineering Software*, 40(6), 438-444.