

ارزیابی مدل‌های هوش مصنوعی در تخمین مقاومت فشاری بتن غلتکی

محمد عمادی^{۱*}، سید حسام مدنی^۲

۱- دانشجوی کارشناسی ارشد سازه دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته

۲- عضو هیئت علمی دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته

چکیده:

امروزه از بتن غلتکی در ساخت سدها و روسازی راه‌ها استفاده می‌شود و طی چند سال اخیر استفاده از این نوع بتن به علت مزایایی چون کوتاه شدن زمان ساخت، در دسترس بودن مصالح مورد نیاز و کاهش هزینه ساخت و ساز گسترش یافته است. حساسیت بتن غلتکی به اجزاء تشکیل دهنده آن و طرح مخلوط سبب مشکلاتی در پیش بینی مقاومت فشاری شده است. پارامترهایی نظیر عیار سیمان، نسبت آب به مواد سیمانی، مقدار مواد سیمانی جایگزین و حداکثر بعد سنگدانه بر مقاومت فشاری بتن غلتکی اثر فراوانی دارد. امروزه مدل‌سازی به کمک شبکه‌های عصبی، جایگاه ویژه‌ای در علوم فنی و مهندسی پیدا کرده است و پیش‌بینی رفتار مواد که با پیچیدگی‌های فراوانی رو به رو بوده، تا حدودی به کمک این روش میسر شده است. در این تحقیق با در نظرگیری پارامترهای طرح اختلاط بتن به عنوان ورودی، از مدل‌سازی به وسیله سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) و شبکه عصبی مصنوعی (ANN) استفاده شده است. طرح مخلوط‌های مختلفی جهت بررسی عملکرد مدل‌های مورد استفاده به کار گرفته شد و نتایج مدل‌سازی مقاومت فشاری در سن ۲۸ روز، به وسیله این مدل‌ها باهم مقایسه شده است. بررسی این مطالعه نشانگر آن است که شبکه عصبی مصنوعی و سیستم استنتاج فازی-عصبی تطبیقی توانایی بالایی در مدل‌سازی مقاومت فشاری بتن غلتکی دارند، همچنین عملکرد دو روش در مدل‌سازی بسیار به هم نزدیک و مشابه می‌باشد.

واژگان کلیدی: بتن غلتکی، مدل‌سازی، مقاومت فشاری، سیستم استنتاج فازی-عصبی تطبیقی، شبکه عصبی مصنوعی

Evaluation of artificial intelligence models to estimate the roller compacted concrete strength

M. Emadi^{1*}, H. Madani²

1- M.Sc. Structural Student, Graduate University of Advanced Technology, Iran

2- Assistant Professor, Graduate University of Advanced Technology, Iran

Abstract

Nowadays roller compacted concrete(RCC) are used to be built dams and roads, in recent years use of RCC are extend because of its advantages, such as the Shorten of construction time, availability of required materials and reduce the cost of construction. The sensitivity of RCC to its ingredients and mix design is caused problems in anticipation of compressive strength. Parameters such as cement content, water-cement ratio, the amount of replaced cementitious materials and maximum aggregates size affects the RCC compressive strength. Nowadays modeling with neural networks has found a special place in technical Sciences and engineering, and the behavior prediction of materials that faced with complexity, partly it is possible with the helping of this method. In this study mix design parameters are considered as dataset, modeling is performed with Adaptive Neuro Fuzzy Inference System(ANFIS) and Artificial Neural Network(ANN). Different RCC mixes design are used for evaluate performance of these models. The modeling results of 28 day's compressive strength are compared with each other. Evaluation of this study indicate that ANFIS and ANN have high ability to model compressive strength of RCC, and the performance of these methods are similar and very close.

Keywords

Roller compacted concrete, Compressive strength, Adaptive Neuro Fuzzy Inference System, Artificial Neural Network

۱ - مقدمه

ساخت بتن غلتکی روشی در راستای توسعه و تکامل مصالحی نظیر خاک تثبیت شده با سیمان و یا اساس اصلاح شده با سیمان می باشد که مدت های مدیدی به عنوان زیر اساس و اساس در طراحی و ساخت روسازی ها کاربرد داشته است. تعریف بتن غلتکی روسازی راه عبارت است از مخلوط سفت و نسبتا خشکی از سنگدانه با اندازه حداکثر ۱۹ میلیمتر، مواد سیمانی و آب که توسط دستگاه های متداول روسازی آسفالتی پخش و پس از آن توسط غلتک و بیرهای کوبیده و متراکم می گردد و سرانجام بعد از سخت شدن در اثر واکنش هیدراتاسیون سیمان به بتن تبدیل می گردد. ابتدا مصالح تشکیل دهنده بتن غلتکی در داخل میکسر مخلوط گردیده تا یک مخلوط همگن به دست آید سپس بر روی بستر مورد نظر گسترانده می شود. از خصوصیات بارز و مشخصات ظاهری این مخلوط می توان به کارایی پایین (اسلامپ صفر) اشاره کرد. همانطور که گفته شد پس از ساخت، این مخلوطها توسط تجهیزات ساخت روسازی آسفالتی (با برخی اصلاحات) در لایه هایی که ضخامت حداکثر آنها در وضعیت متراکم شده از ۲۵ سانتی متر تجاوز نمی کند پخش و سپس این لایه ها با غلتک های فولادی متراکم می گردند. در برخی موارد به منظور دستیابی به روسازی با کیفیت بالاتر، از غلتک های چرخ لاستیکی برای تراکم نهایی لایه ها استفاده می شود. در نهایت پس از انجام فرآیند متراکم سازی، عملیات عمل آوری سطح روسازی بتن آغاز می گردد تا امکان دستیابی به روسازی با سطح سخت و بادوام فراهم آید [۱].

حساسیت بتن غلتکی به اجزاء تشکیل دهنده و طرح مخلوط سبب مشکلاتی در پیش بینی مقاومت فشاری شده است. امروزه مدل سازی به کمک شبکه های عصبی، جایگاه ویژه ای در علوم فنی و مهندسی پیدا کرده است و مدل سازی رفتار مواد که با پیچیدگی های فراوانی رو به رو بوده، تا حدودی به کمک این روش میسر شده است. محققین بسیاری توسط تکنیک های مختلف ریاضی، مدل های ارزشمندی را در زمینه تخمین رفتار بتن ارائه نموده اند که در گذشته این تکنیک ها بیشتر بر پایه رگرسیون های خطی و غیر خطی استوار بوده اند [۲]، امروزه روش های بر پایه هوش مصنوعی مانند منطق فازی و شبکه های عصبی مصنوعی در این زمینه با موفقیت مورد استفاده قرار گرفته اند [۳ و ۴، ۵، ۶، ۷].

۱-۲ - پیشینه تحقیق

آقای رضانیانپور و همکاران با استفاده از سیستم استنتاج فازی-عصبی تطبیقی، مقاومت فشاری ۲۸ روزه بتن پرمقاومت را پیش بینی کردند. آنها با شکل دادن ساختارهای مختلفی از سیستم استنتاج فازی-عصبی تطبیقی که دارای توابع عضویت گوناگون بوده است، این مهم را انجام داده اند [۸].

آقای اوزتاس و همکاران برای پیش بینی مقاومت فشاری ۲۸ روزه بتن پرمقاومت، مدلی از شبکه عصبی مصنوعی که دارای ۴ لایه بوده است را پیشنهاد کرده اند. این مدل از شبکه عصبی چندلایه، مقاومت فشاری را برای داده های آموزش و آزمایش به خوبی تخمین زده است [۹].

آقای سریدمیر مقاومت فشاری ملات حاوی متاکائولین را با استفاده از شبکه عصبی و سیستم استنتاج فازی-عصبی تطبیقی پیش بینی کرده است. آقای سریدمیر برای این کار از شبکه عصبی چندلایه پیشخور و سیستم فازی سوگنو بهره برده است. در این تحقیق شاهد توانایی بالای این مدل ها در پیش بینی مقاومت فشاری این نوع ملات هستیم [۱۰].

آقای سبحانی و همکاران برای تخمین مقاومت فشاری ۲۸ روزه بتن بدون اسلامپ از شبکه عصبی، سیستم استنتاج فازی-عصبی تطبیقی و مدل رگرسیون (خطی و غیر خطی) استفاده کرده اند. در این تحقیق مدل رگرسیون عملکرد ضعیف تری نسبت به دو روش دیگر در تخمین مقاومت فشاری بتن بدون اسلامپ از خود نشان داده است [۴].

آقای صدرممتازی و همکاران به پیش بینی مقاومت فشاری بتن سبک ساخته شده با دانه های منبسط شده پلی استایرن به وسیله مدل رگرسیون، شبکه عصبی مصنوعی و سیستم استنتاج فازی-عصبی تطبیقی پرداخته است. نتایج نشانگر این است که شبکه عصبی چندلایه که دارای ۲ لایه پنهان و ۳ نرون در هر لایه می باشد عملکرد بهتری نسبت به مدل رگرسیون و سیستم استنتاج فازی-عصبی تطبیقی دارد [۷].

۲- روش‌شناسی^۱

در این تحقیق از دو روش برای مدل‌سازی مقاومت فشاری ۲۸ روزه بتن غلتکی استفاده شده است که در ادامه هر روش شرح داده می‌شود.

۲-۱- شبکه عصبی مصنوعی

در شکل‌گیری علم شبکه‌های عصبی مصنوعی، از شبکه‌های عصبی بیولوژیکی الهام گرفته شده است. بدین معنی که یک شبکه عصبی از چندین عنصر به نام نرون تشکیل شده که هر یک از این نرون‌ها با نرون‌های دیگر ارتباط دارند. هدف شبکه عصبی مصنوعی، تقلید از نرون‌های سیستم عصبی انسان است که این کار با اتصال تعداد زیادی از پردازشگرها موسوم به نرون‌های مصنوعی انجام می‌شود. نرون‌ها اجزای اصلی شبکه‌های عصبی می‌باشند که اساساً از سه بخش وزن، بایاس و تابع انتقال تشکیل می‌شود. معمولاً مدل‌های شبکه عصبی از سه بخش اصلی لایه ورودی، لایه پنهان و لایه خروجی تشکیل شده است. هر نرون در لایه ورودی به نرون‌های لایه پنهان متصل می‌باشد و باید به این نکته توجه داشت که بین نرون‌ها در یک لایه هیچگونه اتصالی وجود ندارد. تعداد نرون‌ها در هر لایه به عوامل متعددی بستگی دارد. به عنوان مثال، تعداد نرون‌های ورودی و خروجی به پارامترهای ورودی و خروجی مورد نظر در مدل‌سازی بستگی داشته و معمولاً تعداد نرون‌ها در لایه پنهان به کمک روش‌های مختلف بر اساس پیچیدگی مسئله مورد نظر تعیین می‌شود [۵]. به طور کلی شبکه‌های عصبی با معرفی، محاسبه و تفکیک داده‌ها در یک فضای چند متغیره، آنها را به فضاهای مطلوب تبدیل می‌کند. برای آموزش شبکه داده‌های آموزشی به عنوان ورودی به شبکه داده می‌شود و خروجی شبکه محاسبه می‌گردد. با محاسبه اختلاف بین خروجی شبکه و خروجی مد نظر، وزن‌های و بایاس‌های شبکه تنظیم می‌شود تا خطا به حداقل مقدار برسد [۳]. با استفاده از دانش برنامه نویسی می‌توان ساختار داده‌ای طراحی کرد که همانند یک نرون عمل نماید. سپس با ایجاد شبکه‌ای از این نرون‌های مصنوعی به هم پیوسته و ایجاد یک الگوریتم آموزشی برای شبکه و اعمال این الگوریتم به شبکه، آن را آموزش داد. عموماً تعداد زیادی از زوج‌های ورودی و خروجی به کار گرفته می‌شوند تا در این روند که از آن تحت عنوان آموزش نظارت شده یاد می‌شود، شبکه آموزش داده شود.

در این تحقیق از شبکه عصبی مصنوعی چند لایه پرسپترون^۲ استفاده شده است. برای این شبکه عصبی ۳ لایه تعریف شده که یک لایه پنهان می‌باشد. لایه پنهان دارای ۵ نرون می‌باشد و تابع محرک به کار گرفته شده در این لایه از نوع تانسینگ است. همچنین از تابع لونیبرگ-مارکوارد برای بهینه‌سازی وزن‌ها و بایاس‌ها استفاده شده است. جدول ۱ نشان دهنده متغیرهای به کار رفته در شبکه عصبی می‌باشد. مدل‌سازی با شبکه عصبی مصنوعی به کمک نرم افزار متلب صورت گرفته است.


جدول ۱ - متغیرهای شبکه عصبی

نام متغیر	تنظیمات
تعداد لایه‌ها	۳
تعداد لایه پنهان	۱
تعداد نرون در لایه پنهان	۵
نوع تابع محرک لایه پنهان	سیگموئید (tansig)
نوع تابع محرک لایه خروجی	خطی (purelin)
نوع تابع آموزش	Levenberg-Marquardt

¹ Methodology

² Multilayer Perceptron (MLP)

شکل ۱ ساختار شبکه عصبی مصنوعی به کار گرفته شده را نشان می‌دهد.



شکل ۱ - ساختار شبکه عصبی مصنوعی

۲ - سیستم استنتاج فازی - عصبی تطبیقی

مهمترین ویژگی منطق فازی در مقایسه با منطق کلاسیک این است که دانش و تجربه بشر را می‌تواند در قالب روابط ریاضی بیان نماید. این امر سبب گردیده است که مسائل موجود در دنیای واقعی را بتوان با استفاده از آن مدل‌سازی نمود. سیستم استنتاج فازی بر اساس قواعد اگر - آنگاه بنا نهاده شده است، به طوری که با استفاده از قواعد ذکر شده ارتباط بین تعدادی متغیر ورودی و خروجی را به دست آورد. بنابراین از سیستم استنتاج فازی می‌توان به عنوان یک مدل پیش‌بینی برای شرایطی که داده‌های ورودی و خروجی دارای عدم قطعیت بالایی باشند استفاده نمود. به دلیل اینکه در چنین شرایطی روش‌های کلاسیک پیش‌بینی مانند رگرسیون نمی‌توانند به خوبی عدم قطعیت موجود در داده‌ها را در نظر بگیرند. برای توسعه سیستم استنتاج فازی از عملگرهای استلزام فازی و ترکیب روابط فازی استفاده می‌گردد. استفاده از سیستم استنتاج فازی در پژوهش‌های مربوط به بتن و پیش‌بینی نتایج حاصل آزمایش‌ها در موارد متعددی با موفقیت انجام پذیرفته است [۳ و ۴]. سیستم استنتاج فازی-عصبی تطبیقی، سیستم استنتاج فازی است که تنظیم پارامترهای آن همانند شبکه عصبی مبتنی بر یک فرآیند یادگیری است به نحوی که مقادیر بهینه پارامترهای موجود به نحوی تعیین می‌شوند که بیشترین تطبیق را با داده‌های موجود از آن فرآیند داشته باشند.

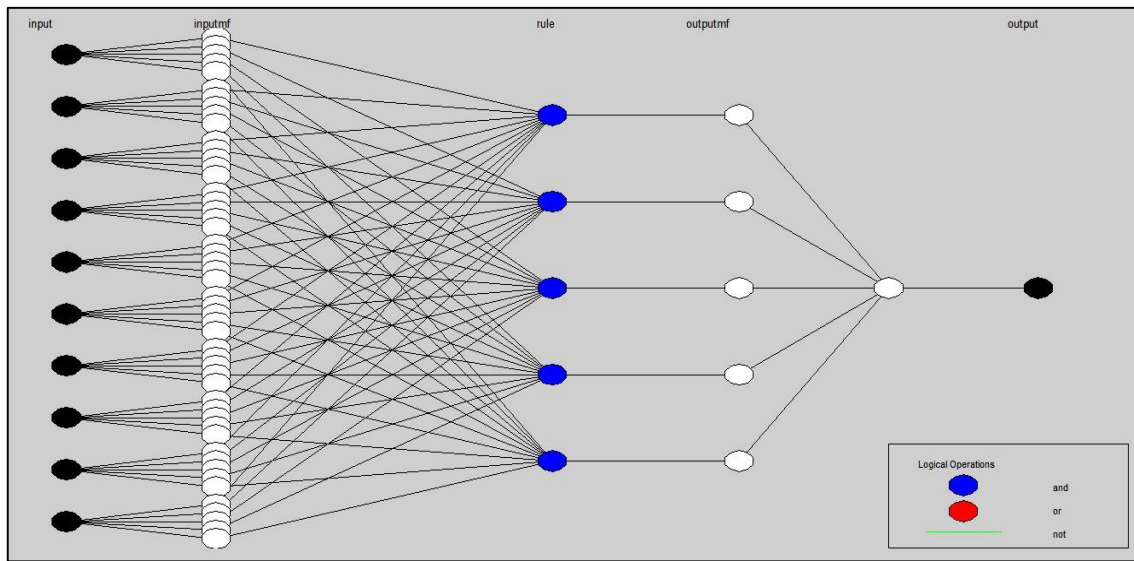
آنچه در آموزش یک شبکه مهم می‌باشد آن است که شبکه قادر باشد به ازای بردار ورودی که با آن آموزش ندیده است، خروجی مرتبط با آن را ارائه نماید. به طور کلی هدف از آموزش، قابلیت درون‌یابی سیستم برای کلیه سری‌های آموزشی است. در این تحقیق از الگوریتم یادگیری هیبرید که ترکیبی از روش کاهش شیب گرادیان و روش حداقل مربعات است، به منظور اصلاح پارامترهای شبکه استفاده شده است. روش شیب گرادیان به منظور تنظیم پارامترهای غیرخطی مقدماتی به کار گرفته می‌شود، در حالی که روش حداقل مربعات به منظور معین کردن پارامترهای بخش تالی به کار می‌رود.

در این تحقیق از سیستم استنتاج فازی-عصبی سوگنو استفاده شده است. به ازاء هر ورودی ۵ تابع عضویت گوسی تعریف شده که در نهایت منجر به ایجاد ۵ قاعده^۳ شد. برای ایجاد سیستم استنتاج فازی از تابع `genfis3` استفاده شد. ساختار سیستم استنتاج فازی-عصبی به کار گرفته شده در این تحقیق در شکل ۲ نمایش داده شده است. مدل‌سازی به‌وسیله این روش در نرم‌افزار متلب انجام شده است.

¹ Fuzzy Inference System (FIS)

² Hybrid algorithm

³ Rule



شکل ۲ - ساختار سیستم استنتاج فازی - عصبی

۲ - ۳ - معیارهای ارزیابی

منظور از ارزیابی، به دست آوردن میزان خطای مدل با توجه به داده‌های ورودی داده شده به مدل جهت آموزش و بر اساس معیارهای مختلف محاسبه خطا می‌باشد. ضرایب ارزیابی مورد استفاده به شرح زیر است:

۲ - ۳ - ۱ - ضریب همبستگی^۱

این ضریب میزان نزدیکی مقاومت‌های شبیه‌سازی شده و مشاهده شده را نشان می‌دهد. مقدار ضریب همبستگی از صفر تا یک متغیر است که هرچه پاسخ به یک نزدیک‌تر باشد، نشان دهنده برازش بهتر مدل می‌باشد.

۲ - ۳ - ۲ - ریشه میانگین مربعات خطا^۲

این معیار نشان دهنده ریشه دوم مربعات اختلاف میان مقاومت مشاهده شده و شبیه‌سازی شده است. مقدار آن از صفر تا $+\infty$ متغیر است که هرچه این مقدار به صفر نزدیک‌تر باشد نشان دهنده برازش بهتر مدل است.

۲ - ۳ - ۳ - میانگین خطای مطلق^۳

این معیار نشان دهنده میانگین اختلاف مطلق میان مقاومت‌های مشاهده شده و شبیه‌سازی شده است. مقدار آن از صفر تا $+\infty$ متغیر است که هرچه این مقدار به صفر نزدیک‌تر باشد نشان دهنده برازش بهتر مدل است.

۳ - مجموعه داده‌های مدل‌سازی

در این تحقیق مدل‌سازی مقاومت فشاری ۲۸ روزه بتن غلتکی با استفاده از شبکه عصبی مصنوعی و سیستم استنتاج فازی-عصبی تطبیقی انجام گرفته است. در مجموع ۱۰۱ طرح مخلوط برگرفته از مطالعات مختلف گذشته [۱۰ و ۱۱ ، ۱۲ ، ۱۳] به عنوان دیتا

¹ correlation coefficient (R)

² Root Mean Square Error (RMSE)

³ Mean Absolute Error (MAE)

در نظر گرفته شده است. پارامترهای تاثیر گذار بر مقاومت فشاری که در جدول ۲ ذکر شده‌اند، به عنوان ورودی به مدل‌ها داده شده است.

جدول ۲ - پارامترهای ورودی مدل‌ها و نماد آنها

نماد متغیر	متغیر ورودی
X1	مقدار درشت‌دانه $[kg/m^3]$
X2	مقدار ریزدانه $[kg/m^3]$
X3	مقدار سیمان $[kg/m^3]$
X4	نسبت آب به مواد سیمانی
X5	مقدار خاکستر بادی $[kg/m^3]$
X6	مقدار آب $[kg/m^3]$
X7	درصد مواد سیمانی ^۱
X8	مقدار افزودنی کاهنده آب $[kg/m^3]$
X9	نسبت درشت‌دانه به ریزدانه
X10	بیشینه سایز سنگ‌دانه مصرفی $[mm]$

۴ - تقسیم‌بندی داده‌ها

در مدل‌سازی رفتار پدیده‌ها بوسیله هوش مصنوعی، نیاز به معرفی ۳ سری داده وجود دارد. داده‌های آموزشی،^۲ صحت‌سنجی^۳ و آزمون^۴ که با در نظر گرفتن درصدهای متفاوتی از کل داده‌ها پدید می‌آیند. نسبت هر سری از داده‌های ذکر شده به کل داده‌ها در شبکه عصبی مصنوعی و سیستم استنتاج فازی-عصبی تطبیقی در جدول ۳ آورده شده است.

جدول ۳ - درصد داده‌های آموزش، اعتبارسنجی و آزمایش

	شبکه عصبی مصنوعی	سیستم استنتاج فازی - عصبی تطبیقی
داده آموزشی	٪ ۷۰	٪ ۷۵
داده اعتبارسنجی	٪ ۱۵	-
داده آزمایشی	٪ ۱۵	٪ ۲۵

¹ $\frac{flyash}{cement + flyash}$


² Train Data

³ Validation Data


⁴ Test Data

۵- ارائه نتایج مدل سازی


نتایج مربوط به مدل سازی مقاومت فشاری ۲۸ روزه بتن غلتکی به وسیله شبکه عصبی مصنوعی و سیستم استنتاج فازی-عصبی تطبیقی در ادامه به تفکیک روش مدل سازی در قالب اشکال و جداول ارائه شده است.



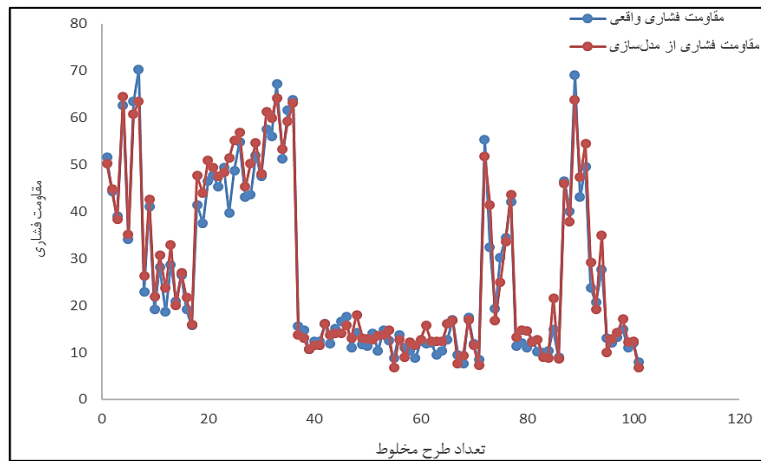
شکل ۳ - مقایسه مقاومت فشاری واقعی و مقاومت فشاری پیش بینی شده، مجموعه داده های آموزش ANN



شکل ۴ - مقایسه مقاومت فشاری واقعی و مقاومت فشاری پیش بینی شده، مجموعه داده های اعتبارسنجی ANN




شکل ۵ - مقایسه مقاومت فشاری واقعی و مقاومت فشاری پیش بینی شده، مجموعه داده های آزمایش ANN




شکل ۶ - اختلاف بین مقاومت فشاری واقعی و مقاومت فشاری پیش‌بینی شده با شبکه عصبی

جدول ۴ - خطاهای داده‌های شبکه عصبی مصنوعی

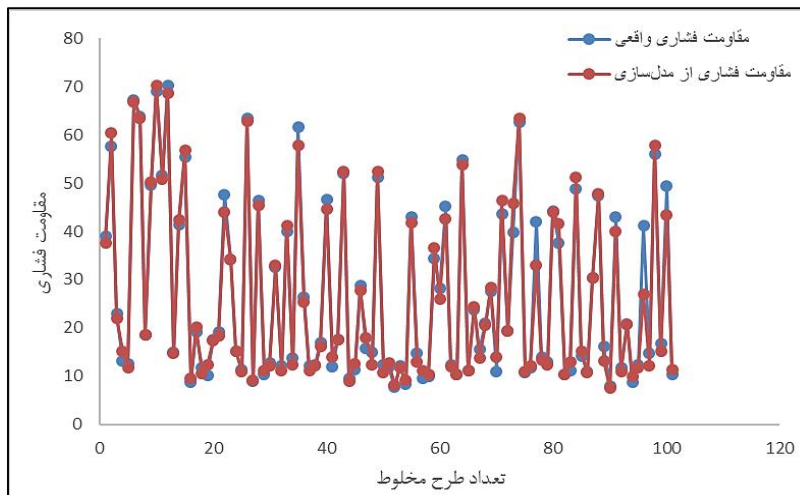
معیار ارزیابی	<i>R</i>	<i>RMSE</i>	<i>MAE</i>
آموزش	۰,۹۸۹۱	۳,۰۵۰۴	۲,۳۳۴۵
اعتبارسنجی	۰,۹۶۵۱	۳,۷۵	۲,۸۹۶۸
تست	۰,۹۸۲۳	۳,۴۶۲	۲,۷۳۹۹



شکل ۷ - مقایسه مقاومت فشاری واقعی و مقاومت فشاری پیش‌بینی شده، مجموعه داده های آموزش ANFIS



شکل ۸ - مقایسه مقاومت فشاری واقعی و مقاومت فشاری پیش بینی شده، مجموعه داده های آزمایش ANFIS



شکل ۹ - اختلاف بین مقاومت فشاری واقعی و مقاومت فشاری پیش بینی شده با سیستم استنتاج فازی - عصبی تطبیقی

جدول ۵ - خطاهای داده های سیستم استنتاج فازی - عصبی تطبیقی

معیار ارزیابی	<i>R</i>	<i>RMSE</i>	<i>MAE</i>
آموزش	۰٫۹۹۶۶	۱٫۵۴۹۱	۱٫۱۵۷۹
تست	۰٫۹۷۲۴	۳٫۹۲۵۴	۲٫۲۸۴۵

نتایج مدل سازی با هر دو روش قابل قبول بوده که نشان دهنده توانایی بالای شبکه عصبی مصنوعی و سیستم استنتاج فازی - عصبی تطبیقی در مدل سازی مقاومت فشاری ۲۸ روزه بتن غلتکی می باشد. همانگونه که مشاهده می شود نتایج دو روش بسیار بهم نزدیک می باشد. علی رغم نزدیکی نتایج با بررسی معیارهای ارزیابی، بهبود جزئی عملکرد شبکه عصبی مصنوعی در مدل سازی مقاومت

فشاری نسبت به سیستم استنتاج فازی-عصبی مشاهده می‌شود. با بررسی ضریب همبستگی درمی‌یابیم که شبکه عصبی مصنوعی قابلیت آموزش کمتری نسبت به سیستم استنتاج فازی از خود نشان داده‌است، ولی مدل‌سازی داده‌ها به وسیله شبکه عصبی در مرحله آزمایش عملکرد بهتری داشته‌است. می‌توان این مساله را به وجود مرحله اعتبارسنجی که سبب می‌شود خطای مدل‌سازی در شبکه عصبی کاهش یابد، دانست.

۶ - نتیجه‌گیری

- با استفاده از هوش مصنوعی می‌توان در طرح اختلاط بتن‌هایی مانند بتن غلتکی که تکیه به ساخت نمونه‌های آزمایشی اولیه در تعیین طرح مخلوط نهایی دارند، تحول ایجاد کرد که نتیجه آن صرفه‌جویی در زمان و هزینه می‌باشد.
- این تحقیق توانایی بالای شبکه عصبی مصنوعی و سیستم استنتاج فازی-عصبی تطبیقی در مدل‌سازی مقاومت فشاری ۲۸ روزه بتن غلتکی را نشان می‌دهد.
- نتایج مدل‌سازی شبکه عصبی مصنوعی اندکی بهتر از سیستم استنتاج فازی-عصبی تطبیقی است و می‌توان گفت عملکرد دو روش بسیار به هم نزدیک و مشابه می‌باشد.
- شبکه‌های عصبی مصنوعی قابلیت آموزش دیدن را از روی نمونه‌های موجود و تعمیم دادن رفتار را به خوبی دارا می‌باشند. این مسئله، شبکه‌های عصبی را به یک ابزار قوی جهت مدل کردن مکانیزم‌های پیچیده علوم مهندسی تبدیل می‌کند.

۷- منابع

- [1] J. R. Berry, R. L. Duncan, R. J. Fluhr, R. L. Harvey, R. a McComb, B. F. McCullough, A. Nanni, T. L. Neff, J. E. Oliverson, T. W. Sherman, J. L. Rice, and R. J. Risser, "Report on Roller-Compacted Concrete Pavements," vol. 95, no. Reapproved, pp. 1-32, 2001.
- [2] M. F. M. Zain and S. M. Abd, "Multiple regression model for compressive strength prediction of high performance concrete," *J. Appl. Sci.*, vol. 9, no. 1, pp. 155-160, 2009.
- [3] M. I. Khan, "Predicting properties of High Performance Concrete containing composite cementitious materials using Artificial Neural Networks," *Autom. Constr.*, vol. 22, pp. 516-524, 2012.
- [4] J. Sobhani, M. Najimi, A. R. Pourkhorshidi, and T. Parhizkar, "Prediction of the compressive strength of no-slump concrete: A comparative study of regression, neural network and ANFIS models," *Constr. Build. Mater.*, vol. 24, no. 5, pp. 709-718, 2010.
- [5] T. Mehmnavaz, V. Khalilikhorram, S. M. Sajjadi, and M. Samadi, "Presenting an Appropriate Neural Network for Optimal Mix Design of Roller Compacted Concrete Dams," *Res. J. Appl. Sci. Eng. Technol.*, vol. 7, no. 9, pp. 1872-1877, 2014.
- [6] M. M. Alshihri, A. M. Azmy, and M. S. El-Bisy, "Neural networks for predicting compressive strength of structural light weight concrete," *Constr. Build. Mater.*, vol. 23, no. 6, pp. 2214-2219, 2009.
- [7] A. Sadrumontazi, J. Sobhani, and M. A. Mirgozar, "Modeling compressive strength of EPS lightweight concrete using regression, neural network and ANFIS," *Constr. Build. Mater.*, vol. 42, pp. 205-216, 2013.
- [8] A. A. Ramezani pour, M. SOBHANI, and J. Sobhani, "Application of network-based neuro-fuzzy system for prediction of the strength of high strength concrete," 2004.
- [9] A. Öztaş, M. Pala, E. Özbay, E. Kanca, N. Çağlar, and M. A. Bhatti, "Predicting the compressive strength and slump of high strength concrete using neural network," *Constr. Build. Mater.*, vol. 20, no. 9, pp. 769-775, 2006.
- [10] M. Sarıdemir, "Predicting the compressive strength of mortars containing metakaolin by artificial neural networks and fuzzy logic," *Adv. Eng. Softw.*, vol. 40, no. 9, pp. 920-927, 2009.

- [11] M. C. Nataraja, M. A. Jayaram, and C. N. Ravikumar, "Prediction of early strength of concrete: a fuzzy inference system model," *Int. J. Phys. Sci.*, vol. 1, no. 2, pp. 47–56, 2006.
- [12] S. Akkurt, G. Tayfur, and S. Can, "Fuzzy logic model for the prediction of cement compressive strength," *Cem. Concr. Res.*, vol. 34, no. 8, pp. 1429–1433, 2004.
- [13] S. Tangtermsirikul, T. Kaewkhluab, and P. Jitvutikrai, "A compressive strength model for roller-compacted concrete with fly ash," *Mag. Concr. Res.*, vol. 56, no. 1, pp. 35–44, 2004.
- [14] C. Cao, W. Sun, and H. Qin, "Analysis on strength and fly ash effect of roller-compacted concrete with high volume fly ash," *Cem. Concr. Res.*, vol. 30, no. 1, pp. 71–75, 2000.
- [15] C. D. Atiş, "Strength properties of high-volume fly ash roller compacted and workable concrete, and influence of curing condition," *Cem. Concr. Res.*, vol. 35, no. 6, pp. 1112–1121, 2005.
- [16] M. I. Abu-Khashaba, I. Adam, and A. El-Ashaal, "Investigating the possibility of constructing low cost roller compacted concrete dam," *Alexandria Eng. J.*, vol. 53, no. 1, pp. 131–142, 2014.