

A New Estimation Approach for Fly Ash Incorporated High Strength Concrete Using Artificial Neural Network

Ali Ghorbani¹

1- Assistant Professor, Department of Civil Engineering, Faculty of Engineering, Payame Noor University, Tehran, Iran.

ABSTRACT

The fly ash obtained from the extraction of exhaust gases from coal and silt furnaces, is non-plastic and fine, which is a different combination based on natural coal fuel. Fly ash is one of the waste materials in thermal power plants. The use of waste materials such as fly ash in the concrete industry offers an alternative and valuable solution to create an environmentally friendly environment. However, experimental work is time-consuming and expensive, and the use of soft computing techniques can speed up the process of predicting concrete's resistance properties. In this study, artificial neural network (ANN) was used to predict the compressive strength of fly ash-based high-performance concrete. A number of 471 experimental data were extracted from valid sources and parameters such as cement, fly ash, water, superplasticizer, fine and coarse aggregate and age of the samples were considered as input parameters and compressive strength of samples was considered as output parameters. Among the networks with different number of neurons, a network which has the best correlation coefficient values obtained from training, evaluation and testing data and also has the lowest mean square error (MSE) value was selected as the optimal network. In this study, the network with the number of 6 neurons provided the best results. Also, the effect of each parameter in different numerical ranges on the compressive strength of concrete was investigated and presented, and it was found that the age of the samples and the amount of cement, fly ash and water have the greatest relative importance.

ARTICLE INFO

Receive Date: 10 June 2022

Revise Date: 25 August 2022

Accept Date: 19 September 2022

Keywords:

Compressive strength of concrete,
Fly ash,
Artificial neural network,
Concrete,
Matlab

All rights reserved to Iranian Society of Structural Engineering.

doi: <https://doi.org/10.22065/jsce.2022.345574.2837>

*Corresponding author: Ali Ghorbani.

Email address: ghorbani@pnu.ac.ir

تخمین مقاومت فشاری بتن‌های با عملکرد بالا بر پایه خاکستر بادی با استفاده از شبکه‌های عصبی مصنوعی

علی قربانی^{*۱}

۱- استادیار، گروه مهندسی عمران، دانشکده مهندسی، دانشگاه پیام نور، تهران، ایران

چکیده

خاکستر بادی از استخراج گازهای خروجی کوره‌های آتش با سوخت زغال و سیلت، غیر پلاستیک و ریز می‌باشد که ترکیبی متفاوت بر اساس سوخت زغال طبیعی است. خاکستر بادی جزو مصالح زائد در نیروگاه‌های حرارتی می‌باشد. استفاده از مواد زائد مانند خاکستر بادی در صنعت بتن راه حل جایگزین و ارزشمندی برای ایجاد یک محیط دوستدار محیط زیست ارائه می‌دهد. با این حال، کار آزمایشگاهی زمان‌بر و پرهزینه می‌باشد و استفاده از تکنیک‌های محاسبات نرم می‌تواند روند پیش بینی خواص مقاومتی بتن را تسریع بخشد. در این مطالعه با استفاده از شبکه عصبی مصنوعی (ANN) به پیش بینی مقاومت فشاری بتن‌های با عملکرد بالا بر پایه خاکستر بادی پرداخته شده است. تعداد ۴۷۱ داده آزمایشگاهی از منابع مطالعاتی معتبر استخراج شد و پارامترهایی مانند مقدار سیمان، مقدار خاکستر بادی، مقدار آب، میزان فوق روان کننده، مقادیر ریز دانه و درشت دانه و سن نمونه آزمایشگاهی به عنوان پارامترهای ورودی و مقاومت فشاری نمونه بتنی به عنوان پارامتر خروجی در نظر گرفته شدند. از میان شبکه‌ها با تعداد نرون‌های مختلف، شبکه‌ای به عنوان شبکه بهینه انتخاب گردید که دارای بهترین مقادیر ضریب همبستگی حاصل از داده‌های آموزش، ارزیابی و آزمایش بوده و همچنین کمترین مقدار میانگین مربعات خطاها (MSE) را داشته باشد که در این مطالعه، شبکه با تعداد ۶ عدد نرون بهترین نتایج پیش‌بینی را ارائه کرد. همچنین میزان تاثیر هر یک از پارامترها در بازه‌های عددی مختلف بر مقاومت فشاری بتن مورد بررسی قرار گرفته و ارائه گردید و مشخص شد که سن نمونه، مقدار سیمان، خاکستر بادی و آب دارای بیشترین اهمیت نسبی می‌باشند.

کلمات کلیدی: مقاومت فشاری بتن، خاکستر بادی، شبکه عصبی مصنوعی

شناسه دیجیتال:		سابقه مقاله:				
doi:	https://doi.org/10.22065/jsce.2022.345574.2837	چاپ	انتشار آنلاین	پذیرش	بازنگری	دریافت
	10.22065/jsce.2022.345574.2837	۱۴۰۲/۰۴/۳۱	۱۴۰۱/۰۶/۲۸	۱۴۰۱/۰۶/۲۸	۱۴۰۱/۰۶/۰۳	۱۴۰۱/۰۳/۲۰
				*نویسنده مسئول:		
				پست الکترونیکی:		
				علی قربانی		
				ghorbani@pnu.ac.ir		

۱- مقدمه

تعریف مقررات ملی ساختمان، مبحث نهم، از خاکستر بادی یا Fly Ash چنین می‌باشد "خاکستر بادی^۱ محصول فرعی سوخت ذغال سنگ است که شامل سیلیس، آلومین و اکسیدهای آهن و کلسیم است" [۱]. خاکستر بادی در دو نوع C و F وجود دارد. نوع C خاکستر بادی به دلیل دارا بودن بیش از ۱۰ درصد اکسید کلسیم خاصیت سیمانی شدن نیز دارد. در نیروگاه‌هایی که از ذغال سنگ به عنوان سوخت استفاده می‌کنند، ذرات شیشه ای و کروی شکل بسیار ریز به ابعاد ۱ الی ۸۰ میکرون (ابعاد دانه ای سیمان که مقاومت سیمان را تامین می‌کنند ۱۰ الی ۲۴ میکرون می‌باشند و ابعاد دانه‌های دوده سیلیسی که به شکل ذرات کروی شکل کوچک هستند دارای قطر متوسط حدود ۰/۱ می‌باشند) و در درجه ۱۶۰۰ سانتی گراد به عنوان محصول فرعی تولید می‌شوند که از بالای کوره احتراق خارج و به سرعت سرد می‌شود. این محصول که خاصیت پوزولانی دارد و خاکستر بادی نامیده می‌شود از اختلاط دو فاز شیشه‌ای یا بلوری شده که این فاز حدود ۶۰ الی ۹۰ درصد وزنی محصول را تشکیل می‌دهد و فاز بلوری نشده که ۱۰ الی ۴۰ درصد وزنی محصول را تشکیل می‌دهد، تشکیل شده است. ویژگی‌ها و کیفیت خاکستر بادی به عوامل متعددی از جمله نوع ذغال سنگ و ترکیب آن، کارایی آسیاب خرد کننده ذغال، شرایط احتراق شامل درجه حرارت و مقدار اکسیژن لازم برای سوختن و نوع کوره و به ویژه سرعت سرد شدن ذرات بستگی دارد. ذرات ریز و کروی شکل خاکستر بادی موجب می‌شوند که میزان آب اختلاط بتن برای کارایی معین کاهش یابد و یا با میزان آب ثابت، کارایی بتن تازه افزایش یابد، قابلیت پمپ شدن بتن را بهبود می‌بخشد، احتمال پدیده آب انداختن بتن کاهش می‌یابد و همچنین احتمال جدا شدن دانه‌ها در بتن کاهش می‌یابد [۲].

ساخت بتن نیاز به مطالعه عمیق اجزای مورد استفاده دارد و اغلب به کار آزمایشی برای دستیابی به مقاومت فشاری هدف نیاز دارد. این امر باعث ایجاد عدم قطعیت در ساخت بتن می‌شود زیرا مخلوطی از سنگدانه ریز، سنگدانه درشت، سیمان، مواد افزودنی و مصالح افزودنی خام^۲ است. بنابراین این اجزاء به طور تصادفی در ماتریس بتن توزیع می‌شوند. این عدم قطعیت در ساخت بتن با عملکرد بالا^۳ می‌تواند منجر به مقاومت‌های مختلف شود و برای دستیابی به مقاومت دقیق زمان زیادی را صرف کند. بتن با عملکرد بالا به عوامل زیادی مانند اندازه ذرات، نسبت آب به سیمان و نسبت سنگدانه‌ها بستگی دارد [۳]. به طور کلی، اقدامات فیزیکی برای به دست آوردن مقاومت فشاری انجام می‌شود. این امر با آزمایش مکعب‌ها و استوانه‌های مختلف با نسبت‌های طرح اختلاط در آزمایشگاه به دست می‌آید. با این حال، فرآیند کار آزمایشگاهی برای اطمینان از مقاومت کاملاً غیراقتصادی و زمان‌بر است. بنابراین، تلاش‌هایی برای پیش‌بینی متغیرها با استفاده از مدل‌های رگرسیون و یادگیری ماشین انجام شده است. این نه تنها می‌تواند عدم قطعیت در پیش‌بینی را کاهش دهد، بلکه می‌تواند مقادیر مورد نیاز در طرح اختلاط را برای ایجاد استحکام تضمین کند. این الگوریتم‌های یادگیری ماشین، روابط قوی را شناسایی کرده و بهترین مدل را با استفاده از مجموعه‌ای از متغیرهای ورودی پیش‌بینی می‌کنند. امروزه استفاده از شبکه‌های عصبی مصنوعی به دلیل ویژگی‌های خوبی که دارد در همه زمینه‌های علمی با سرعت زیادی در حال گسترش می‌باشد. در مهندسی عمران به دلیل دقت بالای شبکه‌های عصبی در پیش‌بینی نتایج و همچنین هزینه بالای انجام مطالعات آزمایشگاهی استفاده از آن محبوبیت بالایی در بین محققین پیدا کرده است [۴-۹]. الگوریتم‌های متعددی در گذشته برای پیش‌بینی مقاومت بتن مورد استفاده قرار گرفته‌اند [۱۰، ۱۱]. شاهمنصوری و همکاران [۱۲] از برنامه ریزی بیان ژن (GEP) با استفاده از مواد زائد، سرباره کوره آهن دانه بندی شده (GGBS)، با ۳۵۱ داده آزمایشگاهی در پیش‌بینی خواص بتن ژئوپلیمری (GPC) استفاده کردند. در این مطالعه از هیدروکسید سدیم (NaOH)، ژئولیت طبیعی (NZ)، دوده سیلیس (SF)، و سرباره کوره آهن دانه بندی شده (GBFS) به عنوان متغیرهای ورودی و از مقاومت فشاری به عنوان متغیر خروجی استفاده شده است. نتایج این مطالعه نشان داد که با استفاده از یک مدل GEP، داده‌های آموزشی و داده‌های اعتبارسنجی همبستگی قوی به ترتیب $R^2 = 0.918, 0.94$ را نشان دادند. آوویرا و همکاران [۱۳] از الگوریتم‌های یادگیری ماشین شامل الگوریتم ژنتیک (GEP) و شبکه عصبی مصنوعی (ANN) در پیش‌بینی مقاومت بتن ژئوپلیمری (GPC) با استفاده از خاکستر بادی (FA)، GGBS، SF،

¹ Fly ash

² SRMs

³ HPC

جریان اسلامپ و چندین پارامتر ورودی دیگر برای پیش‌بینی نتایج مقاومت فشاری، کششی و خمشی استفاده کردند. نتایج نشان داد که مدل GEP در مقایسه با ANN، به دلیل توصیف روابط تجربی موثرتر، برتری دارد. دانتاس^۴ و همکاران [۱۴] و دوان^۵ و همکاران [۱۵] با استفاده از شبکه عصبی مصنوعی بر روی ۱۱۷۸ داده به پیش‌بینی خواص بتن ساخته شده با استفاده از سنگدانه‌های بازیافتی و مواد زائد حاصل از ساخت و ساز پرداختند. نگوین^۶ و همکاران [۱۶] از یک الگوریتم ترکیبی با استفاده از حداقل مربعات ماشین بردار پشتیبان (LSSVM) و بهینه‌سازی ازدحام ذرات (PSO) برای پیش‌بینی خواص بتن تازه با ۱۴۲ داده آزمایشگاهی استفاده کردند. ژانگ^۷ و همکاران [۱۷] از چنین مدل‌هایی برای پیش‌بینی مشخصات بتن شنی استفاده کردند. صدیق^۸ و همکاران [۱۸] از خاکستر کف (BA) در بتن خود متراکم (SCC) استفاده کردند و مشخصات آن را با استفاده از روش ANN با ۸۰ داده از مطالعات پیشین و ۳۱ داده حاصل از کار آزمایشگاهی پیش‌بینی کردند. تران^۹ و همکاران [۱۹] از مدل ANN برای پیش‌بینی مقاومت لوله فولادی پر شده با بتن (CSFT) با بتن با مقاومت بسیار بالا (۷۶۸ مجموعه داده) استفاده کرده و یک همبستگی قوی را گزارش کردند. اقبال^{۱۰} و همکاران [۲۰] از تکنیک GEP برای پیش‌بینی خواص بتن سبز ساخته شده با استفاده از ماسه ریخته‌گری ضایعاتی به‌عنوان یک مؤلفه با پایگاه داده ۲۳۴ مجموعه‌ای برای مقاومت فشاری و ۱۶۳ داده برای آزمایش دونیم شدن (splitting) استفاده کردند. کنگرو^{۱۱} و همکاران [۲۱] از الگوریتم ANN برای پیش‌بینی مقاومت خمشی بتن الیافی (FRC) با استفاده از ۴۰۰ داده آزمایشگاهی استخراج شده از مطالعات پیشین استفاده کردند. کومار^{۱۲} و همکاران [۲۲] با استفاده از مدل‌های مختلف یادگیری ماشین به پیش‌بینی مقاومت فشاری بتن‌های سبک پرداختند. بهترین مدل در مطالعه آن‌ها که اقتصادی و موثر بود دارای $R=0.9803$ بود. شمس‌آبادی و همکاران [۲۳] با استفاده از دو روش ANN و روش بهبود حداکثر گرادیان (XGB) به پیش‌بینی مقاومت فشاری بتن حاوی پودر سنگ مرمر که یک پرکننده بسیار ریز می‌باشد و به پیشرفت هیدراسیون بتن در سنین اولیه کمک می‌کند، پرداختند. آن‌ها هر دو روش را با دقت بالا معرفی کرده ($R^2 > 0.97$) با این حال روش ANN را با حساسیت بیشتری در پیش‌بینی بتن‌های حاوی پودر سنگ مرمر دانستند. راجا^{۱۳} و همکاران [۲۴] به بررسی استفاده از ANN در شناسایی ویژگی‌های بتن خود متراکم هنگامی که قسمتی از سیمان پرتلند پوزولانی با پسماندهایی مانند خاکستر نیشکر و خاکستر پوسته برنج جایگزین می‌شود، پرداختند. از ANN برای پیش‌بینی درجه غلظت استاندارد، زمان گیرش و مقاومت فشاری استفاده شد. آن‌ها از ۷۰ درصد داده‌ها برای آموزش و از ۳۰ درصد داده‌ها برای صحت پیش‌بینی‌ها استفاده کردند. ضریب همبستگی (R) و جذر میانگین مربعات (RMSE) برای ANN به ترتیب برابر با ۹۷ و ۹۹ درصد به دست آمدند.

یادگیری ماشین ابزار مفیدی در مهندسی عمران و بسیاری از حوزه‌های دیگر در پیش‌بینی خواص است. با توجه به مطالعات انجام شده می‌توان گفت که شبکه عصبی مصنوعی (ANN) یکی از پرکاربردترین، رایج‌ترین و دقیق‌ترین تکنیک‌ها در زمینه یادگیری ماشین می‌باشد. لذا در این مطالعه با استفاده از این ابزار قدرتمند به پیش‌بینی مقاومت فشاری بتن‌های با عملکرد بالا ساخته شده بر پایه خاکستر بادی پرداخته می‌شود. استفاده از داده‌های زیاد و همچنین نوع بتن که بتن با عملکرد بالا بر پایه خاکستر بادی می‌باشد، برای پیش‌بینی می‌تواند از نکات قابل توجه در این مطالعه باشد که به ندرت در پیش‌بینی با استفاده از شبکه‌های عصبی مصنوعی به کار گرفته شده است. به منظور دقیق بودن و جامع بودن مدل ارائه شده، از ۴۷۱ داده آزمایشگاهی برگرفته از منابع معتبر [۲۵] استفاده شده است. ابتدا داده‌ها از منابع معتبر گردآوری شد و با استفاده از شبکه عصبی مصنوعی و تعداد نورون‌های مختلف به پیش‌بینی مقاومت فشاری بر اساس دقیق

⁴ Dantas

⁵ Duan

⁶ Nguyen

⁷ Zhang

⁸ Siddique

⁹ Tran

¹⁰ Iqbal

¹¹ Congro

¹² Kumar

¹³ Raja

ترین نتایج پرداخته شد. پارامترهای ورودی شبکه شامل مقادیر سیمان، خاکستر بادی، آب، فوق روان کننده، درشت دانه و ریز دانه و همچنین سن بتن بودند.


۲- انتخاب داده‌ها

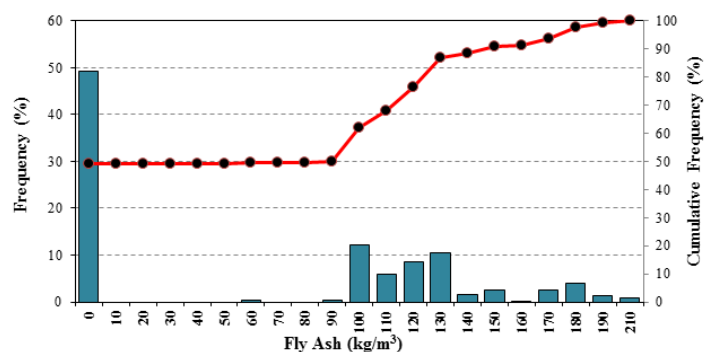
انتخاب داده‌های معتبر و همگن آزمایشگاهی از مهم‌ترین مراحل برای ایجاد یک شبکه عصبی دقیق و کارآمد می‌باشد. همچنین هرچه تعداد داده‌ها و بازه تغییر متغیرها بیشتر باشد شبکه ایجاد شده دقیق‌تر و جامع‌تر خواهد بود. در این مطالعه، داده‌های مورد نیاز (۴۷۱ داده) برای پیش‌بینی مقاومت فشاری بتن‌های با عملکرد بالا حاوی خاکستر بادی از مطالعات معتبر گذشته [۲۵] انتخاب گردید. هفت ویژگی برای پیش‌بینی مقاومت فشاری بتن نهایی مورد استفاده قرار گرفت، از جمله سن نمونه، سیمان، سنگدانه‌های ریز، آب، فوق روان کننده، سنگدانه‌های درشت، و همچنین خاکستر بادی. مقادیر میانگین، انحراف استاندارد، دامنه (اختلاف حداکثر و حداقل داده)، حداقل و حداکثر هر پارامتر ورودی در جدول ۱ آورده شده است. سعی شده است تا تمام موارد تاثیر گذار در مقاومت فشاری بتن (خروجی) به عنوان پارامترهای ورودی در نظر گرفته شوند تا اثر همه پارامترهای موثر در تشکیل شبکه دیده شده باشد.

جدول ۱- مشخصات آماری داده‌های مورد نظر برای تشکیل شبکه

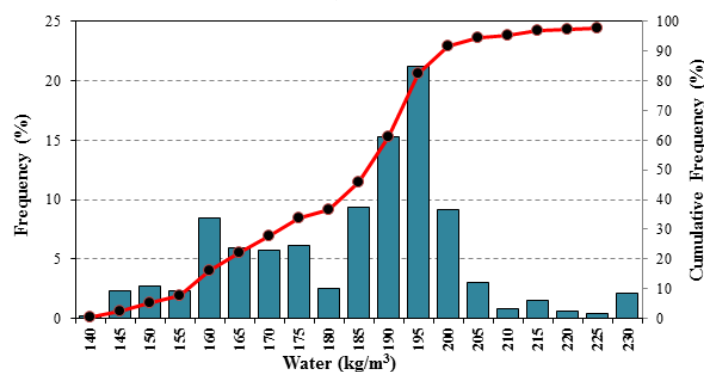
پارامتر	سن (روز)	ریز دانه (kg/m ³)	درشت دانه (kg/m ³)	فوق روان کننده (kg/m ³)	آب (kg/m ³)	خاکستر بادی (kg/m ³)	سیمان (kg/m ³)	مقاومت فشاری (MPa)
میانگین	۴۷/۸۴	۷۹۳/۱۷	۱۰۰۴/۰۴	۵/۰۲	۱۸۱/۸۸	۶۲/۵۹	۲۹۸/۰۸	۳۱/۶
انحراف استاندارد	۶۵/۵۳	۷۳/۸۶	۷۴/۱۷	۵/۴۹	۱۸/۰۱	۶۴/۸۸	۱۰۰/۶۹	۱۴/۷۴
بازه	۳۶۴	۳۵۱	۳۲۴	۲۸/۲	۸۸	۲۰۰/۱	۴۰۵/۳	۷۳/۷۲
مینیمم	۱	۵۹۴	۸۰۱	۰	۱۴۰	۰	۱۳۴/۷	۶/۲۷
ماکزیمم	۳۶۵	۹۴۵	۱۱۲۵	۲۸/۲	۲۲۸	۲۰۰/۱	۵۴۰	۷۹/۹۹

متغیرهای ورودی اثر چشمگیری بر خروجی مدل داشتند. پارامترهای مورد استفاده برای اجرای مدل‌های پیش‌بینی مقاومت فشاری بتن با عملکرد بالا نیز نقش مثبتی در پیش‌بینی داشتند. در شکل ۱ میزان تکرار هر یک از پارامترهای ورودی در محدوده مشخص بر حسب درصد آورده شده است. در این نمودارها، خط قرمز نشانگر میزان تکرار تجمعی پارامترها در محدوده‌های نشان داده شده می‌باشد. به طور مثال در میان همه داده‌ها حدود ۳۶ درصد داده‌ها دارای مقدار سیمان ۳۰۰ کیلوگرم در هر متر مکعب بتن می‌باشند و مقدار تجمعی آن برابر ۷۳ درصد می‌باشد.

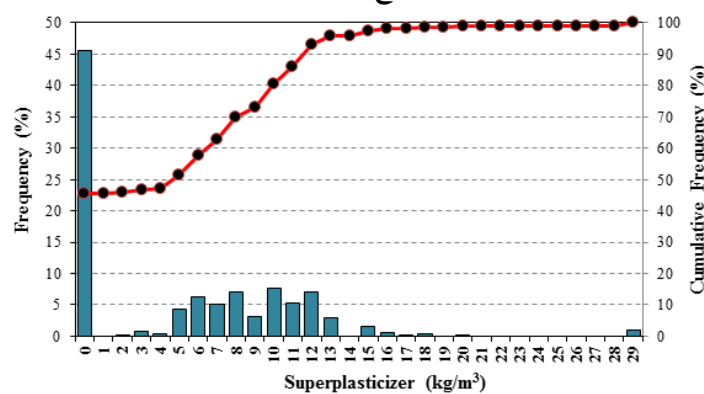




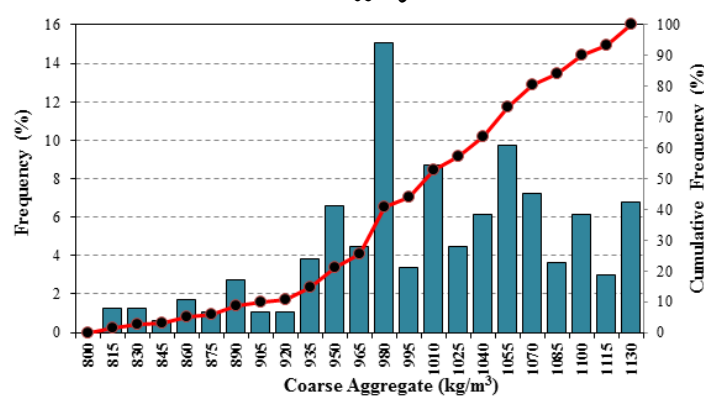
(ب) خاکستر بادی




(ج) آب



(د) فوق روان کننده



(ه) درشت دانه



شکل ۱- میزان فراوانی هر یک از پارامترها و مقدار تجمعی آن‌ها بر حسب درصد

۳- شبکه عصبی مصنوعی (ANN)

شبکه‌های عصبی مصنوعی بر اساس مدل بیولوژیکی مغز جانوران بوجود آمده‌اند و در واقع یک سیستم داده‌پردازی اطلاعات است و دارای خصوصیات اجرایی همانند شبکه‌های عصبی جانوری می‌باشد. شبکه‌های عصبی مصنوعی ممکن است از چند نورون تا چند هزار نورون تشکیل شده باشند و اندازه شبکه بستگی به پیچیدگی مساله دارد. شبکه‌های عصبی را می‌توان در موارد گوناگون از جمله ذخیره کردن و بازبینی داده‌ها، گروه‌بندی‌ها، شکل‌ها، انجام یک نگاشت کلی از یک مجموعه ورودی به یک مجموعه خروجی، گروه‌بندی اشکالی که مشابه هم هستند و بهینه‌سازی و تعیین جواب با وجود قیود متعدد بکار گرفت [۴]. یک پردازشگر عصبی مصنوعی با الگو گرفتن از یک نورون بیولوژیکی علائم متعددی را دریافت می‌کند. علائم دریافتی با اعمال وزن معین می‌گردند. ورودی‌هایی که بر آن‌ها وزن اعمال شده است در واحد پردازشگر جمع می‌شوند. اگر ورودی‌ها به اندازه کافی بزرگ باشند، واحد پردازشگر فعال شده و علائم را به خارج منتقل می‌کند. گاهی خروجی یک پردازشگر به تعداد زیادی پردازشگر دیگر انتقال می‌یابد [۵، ۲۶، ۲۷]. یکی از مشخصات بارزی که استفاده از شبکه‌های عصبی را از روش‌های متداول محاسباتی متمایز می‌کند، آموزش این شبکه‌ها برای یادگیری است. یک شبکه آموزش می‌بیند تا یک سری نتایج مورد انتظار با توجه به اطلاعات ورودی ایجاد نماید. هرگاه شبکه‌ای آموزش ببیند، می‌توان از آن به طور نامحدود و با استفاده از داده‌های ورودی، اطلاعاتی را بدست آورد که شبکه قبلاً با آن‌ها مواجه نبوده است. به عبارت دیگر، شبکه بر اساس تجربه آموزش می‌بیند و برخلاف آنچه در محاسبات متداول روی می‌دهد، با وجود یک اشتباه در اطلاعات ورودی تمامی محاسبات دچار اشکال نمی‌گردد [۵، ۲۶].

دو نمونه از شبکه‌های عصبی مصنوعی در رشته‌های مهندسی بیشتر از شبکه‌های دیگر در تقریب توابع بکار گرفته می‌شوند که این شبکه‌ها شامل شبکه عصبی انتشار برگشتی و شبکه عصبی انتشار متقابل می‌باشند. شبکه‌های عصبی انتشار برگشتی در مقایسه با

شبکه‌های عصبی انتشار متقابل دقت بیشتری دارند و آن را می‌توان در مواردی که نیاز به آموزش شبکه عصبی برای یک بار و استفاده دائم از آن باشد، بکار گرفت. شبکه عصبی بازگشتی که به آن شبکه عصبی مکرر نیز گفته می‌شود، نوعی از شبکه عصبی مصنوعی است که در تشخیص گفتار، پردازش زبان طبیعی (NLP) و همچنین در پردازش داده‌های ترتیبی (Sequential data) استفاده می‌شود. بسیاری از شبکه‌های عمیق مانند CNN شبکه‌های پیش‌خور (Feed Forward) هستند یعنی سیگنال در این شبکه‌ها فقط در یک جهت از لایه ورودی، به لایه‌های مخفی و سپس به لایه خروجی حرکت می‌کند و داده‌های قبلی به حافظه سپرده نمی‌شوند. اما شبکه‌های عصبی بازگشتی (RNN) یک لایه بازخورد دارند که در آن خروجی شبکه به همراه ورودی بعدی، به شبکه بازگردانده می‌شود. RNN می‌تواند به علت داشتن حافظه داخلی، ورودی قبلی خود را به خاطر بسپارد و از این حافظه برای پردازش دنباله‌ای از ورودی‌ها استفاده کند. به بیان ساده، شبکه‌های عصبی بازگشتی شامل یک حلقه بازگشتی هستند که موجب می‌شود اطلاعاتی را که از لحظات قبلی بدست آورده ایم از بین نروند و در شبکه باقی بمانند [۲۸].

۴- مدل‌سازی شبکه

برای مدل‌سازی شبکه از نرم افزار MATLAB [۲۹] استفاده شده است. روش جامع و دقیقی برای به دست آوردن تعداد نورون‌ها و لایه‌های مورد نیاز برای تشکیل بهترین شبکه وجود ندارد و به منظور رسیدن به بهینه‌ترین و دقیق‌ترین شبکه باید بر اساس آزمون و خطا عمل کرد [۳۰]. برای تشکیل شبکه تعداد ۴۰۰ داده در نظر گرفته شده که از این ۴۰۰ داده ۷۰ درصد داده‌ها برای آموزش شبکه، ۱۵ درصد برای آزمایش و ۱۵ درصد نیز برای صحت‌سنجی در نظر گرفته شده است. بعد از تشکیل شبکه با تعداد نورون‌های مختلف و انتخاب شبکه بهینه و به منظور بررسی و آزمایش بهتر شبکه، مابقی داده‌هایی که در تشکیل شبکه در نظر گرفته شده نبودند (۷۱ داده)، برای بررسی و آزمایش شبکه در نظر گرفته شدند که عملکرد داده‌های اصلی (۴۰۰ داده) و داده‌های ثانویه (۷۱ داده) در جدول ۲ آورده شده است. انتخاب داده‌های اصلی و ثانویه به صورت کاملاً تصادفی می‌باشد. در این مطالعه از شبکه عصبی Back Propagation Feed Forward (BPFF) با دو لایه پنهان استفاده شده است. برای بررسی شبکه، تعداد نورون‌ها از ۳ تا ۲۰ عدد مورد بررسی قرار گرفت و مقادیر ضریب همبستگی (R) برای داده‌های آموزش، صحت‌سنجی و آزمایش به دست آمد و در جدول ۲ ارائه شده است. همچنین در این جدول مقادیر میانگین درصد مطلق خطا (MAPE) برای داده‌های آموزش و آزمایش و میانگین مربعات خطا (MSE) برای داده‌های آموزش و آزمایش محاسبه و آورده شده است.

منظور از ضریب همبستگی بین دو متغیر، قابلیت پیش‌بینی مقدار یکی بر حسب دیگری است. ضریب همبستگی خطی گاهی به نام تکمیل‌کننده آن کارل پیرسون معرفی شده و از رابطه زیر به دست می‌آید.

$$R = \frac{n \sum xy - (\sum x)(\sum y)}{\sqrt{n(\sum x^2) - (\sum x)^2} \sqrt{n(\sum y^2) - (\sum y)^2}} \quad (1)$$

در رابطه بالا n برابر با تعداد داده‌ها، x برابر با مقادیر آزمایشگاهی و y برابر با مقادیر پیش‌بینی شده می‌باشد. همچنین نحوه محاسبه مقادیر MAPE و MSE در معادله‌های ۲ و ۳ آورده شده است.

$$MAPE = \frac{1}{N} \left[\frac{\sum_{i=1}^N |f_{c(model)} - f_{c(actual)}|}{\sum_{i=1}^N f_{c(actual)}} \times 100 \right] \quad (2)$$

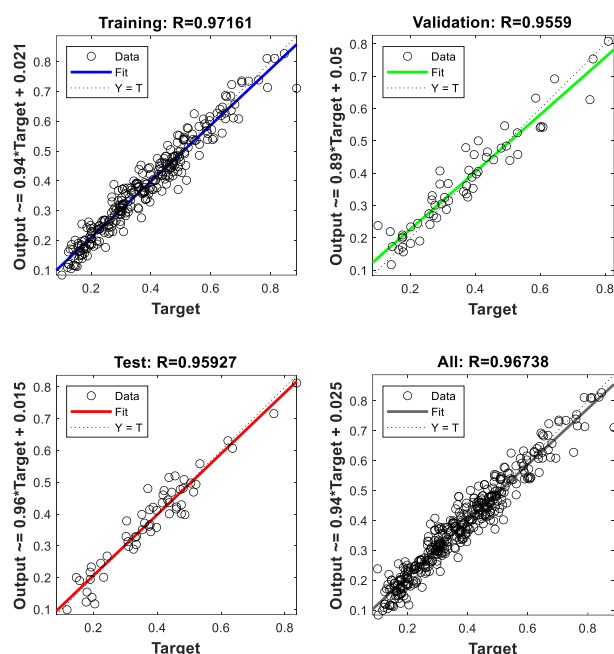
$$MSE = \frac{1}{N} \sum_{i=1}^N (f_{c(model)} - f_{c(actual)})^2 \quad (3)$$

در روابط بالا N برابر با تعداد داده‌ها، $f_c(\text{model})$ برابر با مقادیر پیش‌بینی شده توسط شبکه و $f_c(\text{actual})$ برابر با نتایج آزمایشگاهی می‌باشند.


جدول ۲- مقادیر R ، MSE و $MAPE$ برای شبکه با تعداد نوروهای مختلف.

Training R	Testing R	MSE_Tr	MSE_Ts	Training MAPE (%)	Testing MAPE (%)	R_train	R_test	R_valid	تعداد لایه (NN)
۰/۹۵۱	۰/۹۳۴	۰/۰۰۲	۰/۰۰۴	۱۰/۵۳۸	۱۱/۲۰۴	۰/۹۴۸	۰/۹۶۴	۰/۹۴۷	۳
۰/۹۴۱	۰/۹۳۲	۰/۰۰۳	۰/۰۰۴	۱۱/۱۹۵	۱۱/۱۸۳	۰/۹۶۲	۰/۹۰۱	۰/۸۹۷	۴
۰/۹۵۷	۰/۹۳۸	۰/۰۰۲	۰/۰۰۳	۱۱/۳۹۳	۱۱/۰۰۱	۰/۹۶۴	۰/۹۳۴	۰/۹۵۰	۵
۰/۹۶۷	۰/۹۶۱	۰/۰۰۲	۰/۰۰۲	۹/۸۰۲	۹/۹۳۱	۰/۹۷۲	۰/۹۵۹	۰/۹۵۶	۶
۰/۹۵۷	۰/۹۱۸	۰/۰۰۲	۰/۰۰۵	۱۰/۰۵۹	۱۲/۶۳۹	۰/۹۶۵	۰/۹۴۳	۰/۹۴۲	۷
۰/۹۵۲	۰/۹۴۳	۰/۰۰۲	۰/۰۰۳	۱۰/۹۶۲	۱۱/۷۲۸	۰/۹۶۰	۰/۹۳۶	۰/۹۴۴	۸
۰/۹۴۹	۰/۹۲۲	۰/۰۰۳	۰/۰۰۵	۱۱/۱۸۱	۱۲/۳۰۹	۰/۹۶۲	۰/۹۳۹	۰/۹۰۱	۹
۰/۹۶۹	۰/۹۴۲	۰/۰۰۲	۰/۰۰۳	۸/۰۶۹	۱۱/۳۱۸	۰/۹۸۸	۰/۸۸۳	۰/۹۵۷	۱۰
۰/۹۵۲	۰/۹۰۴	۰/۰۰۲	۰/۰۰۵	۱۰/۳۹۷	۱۳/۳۰۲	۰/۹۶۶	۰/۹۰۱	۰/۹۴۸	۱۱
۰/۹۵۶	۰/۸۹۹	۰/۰۰۲	۰/۰۰۶	۹/۹۰۷	۱۳/۵۲۷	۰/۹۶۳	۰/۹۲۵	۰/۹۶۱	۱۲
۰/۹۵۶	۰/۸۴۱	۰/۰۰۲	۰/۰۱۰	۱۰/۱۰۰	۱۶/۷۷۴	۰/۹۷۴	۰/۹۰۷	۰/۹۱۷	۱۳
۰/۹۷۳	۰/۹۲۷	۰/۰۰۱	۰/۰۰۴	۸/۵۰۶	۱۱/۸۱۰	۰/۹۸۲	۰/۹۵۰	۰/۹۴۶	۱۴
۰/۹۵۶	۰/۹۲۸	۰/۰۰۲	۰/۰۰۴	۱۰/۳۸۳	۱۲/۰۷۳	۰/۹۷۲	۰/۸۹۶	۰/۹۳۷	۱۵
۰/۹۵۹	۰/۹۳۶	۰/۰۰۲	۰/۰۰۳	۱۰/۶۷۱	۱۱/۶۲۳	۰/۹۶۳	۰/۹۵۲	۰/۹۴۲	۱۶
۰/۹۷۰	۰/۹۱۵	۰/۰۰۱	۰/۰۰۵	۷/۵۶۲	۱۱/۵۴۴	۰/۹۸۴	۰/۹۰۳	۰/۹۶۸	۱۷
۰/۹۶۳	۰/۸۹۸	۰/۰۰۲	۰/۰۰۶	۹/۸۱۴	۱۳/۴۳۴	۰/۹۶۷	۰/۹۳۹	۰/۹۶۰	۱۸
۰/۹۶۰	۰/۹۴۴	۰/۰۰۲	۰/۰۰۳	۷/۸۹۸	۱۰/۰۷۲	۰/۹۸۴	۰/۸۸۴	۰/۹۴۸	۱۹
۰/۹۳۸	۰/۸۸۸	۰/۰۰۳	۰/۰۰۶	۱۳/۹۶۱	۱۷/۰۷۷	۰/۹۵۵	۰/۸۹۶	۰/۹۰۶	۲۰

از میان شبکه‌های مورد بررسی با تعداد نوروهای متفاوت، شبکه‌ای که در آن مقادیر R در داده‌های آموزش، ارزیابی، آزمایش و همه داده‌ها، هر چه به یک نزدیک‌تر بوده و همچنین هر چه مقدار میانگین مربعات خطا در آن کمتر باشد، به عنوان بهترین شبکه انتخاب شده و مدل‌سازی بر اساس آن به عنوان معیار قرار می‌گیرد. همان‌گونه که در جدول ۲ مشاهده می‌شود شبکه با تعداد نورو ۶ به عنوان بهترین شبکه انتخاب شده و مقادیر R و همچنین MSE برای این شبکه در شکل ۲ آورده شده است. مقدار MSE برای شبکه برگزیده برابر با $۰/۰۰۲۴۸۰۷$ می‌باشد. همچنین هر چه قدر مقدار $MAPE$ کمتر باشد نیز نشان از دقیق‌تر بودن شبکه در پیش‌بینی نتایج دارد. R های مختلف گزارش شده در جدول ۲ و شکل ۲ مربوط به داده‌های آموزش، ارزیابی و آزمایش داده‌ها می‌باشد. همان‌طور که در شکل ۲-الف نشان داده شده است تعداد ۴۰۰ داده برای تشکیل شبکه در نظر گرفته شده است که از این ۴۰۰ داده ۷۰ درصد برای آموزش، ۱۵ درصد برای ارزیابی و ۱۵ درصد نیز برای آزمایش در نظر گرفته شده‌اند که R های نشان داده‌شده در این شکل و R های موجود در سه ستون جدول ۲ (R -valid, R -train, R -test) مربوط به این موارد هستند. بعد از تشکیل شبکه و آزمایش بهتر شبکه شکل گرفته، تعداد ۷۱ داده که در آموزش شبکه دخالتی نداشتند برای پیش‌بینی به شبکه داده شدند و نتایج حاصل از آن‌ها به صورت R در دو ستون آخر جدول ۲ (R -train, R -test) ارائه گردیده است.



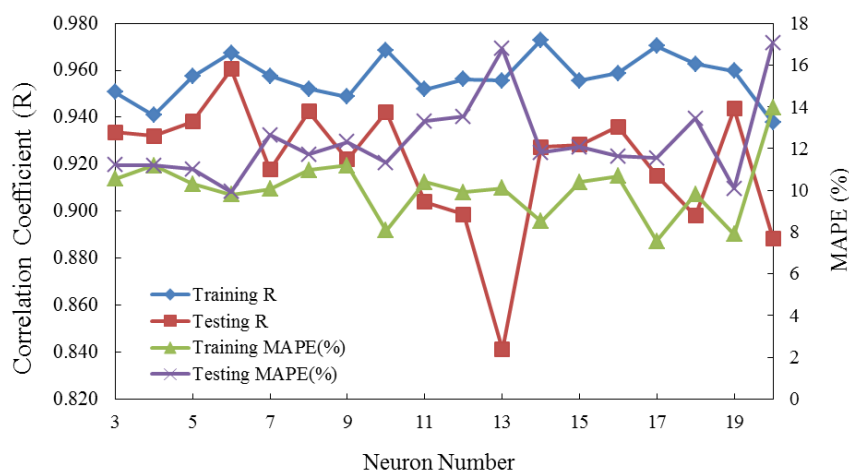
الف) مقادیر R برای داده‌های آموزش، صحت سنجی، آزمایش و کل



ب) مقدار میانگین مربعات خطا


شکل ۲- مقادیر R و MSE برای بهترین شبکه انتخاب شده.

در شکل ۳ مقدار ضریب همبستگی (محور قائم در سمت چپ) و میانگین درصد مطلق خطا (محور قائم در سمت راست) برای داده‌های آموزش و آزمایش به ازای تعداد نوروں‌های مختلف به صورت نمودار آورده شده است. همان‌گونه که مشاهده می‌شود مقدار R برای داده‌های آزمایش به ازای تعداد ۱۳ نوروں دارای کمترین مقدار (کمترین دقت پیش‌بینی) می‌باشد در حالی که مقدار MAPE برای داده‌های آزمایش برای این تعداد نوروں نیز دارای مقدار بالایی می‌باشد. همچنین در این نمودار شبکه با تعداد ۶ نوروں، بهینه‌ترین حالت را از نظر نزدیکی R به عدد یک و کمترین مقدار MAPE را در داده‌های آموزش و آزمایش دارا می‌باشد.




شکل ۳- مقادیر R و MAPE به ازای نورون‌های مختلف.


در شکل ۴ ارتباط بین تغییرات هر یک از پارامترهای ورودی بر روی پارامتر خروجی نشان داده شده است. این ارتباط با فرض برابری بقیه پارامترها با مقدار میانگین‌شان به دست آمده است. همان‌گونه که از این شکل مشاهده می‌شود با افزایش مقدار سیمان، خاکستر بادی و سن نمونه مقدار مقاومت فشاری افزایش پیدا می‌کند در مورد مقدار آب این ارتباط به صورت عکس می‌باشد. در مورد فوق روان کننده، درشت دانه و ریز دانه، مقدار این پارامترها در یک محدوده باعث کاهش و در محدوده ای دیگر باعث افزایش مقاومت فشاری می‌گردد.




ب) خاکستر بادی



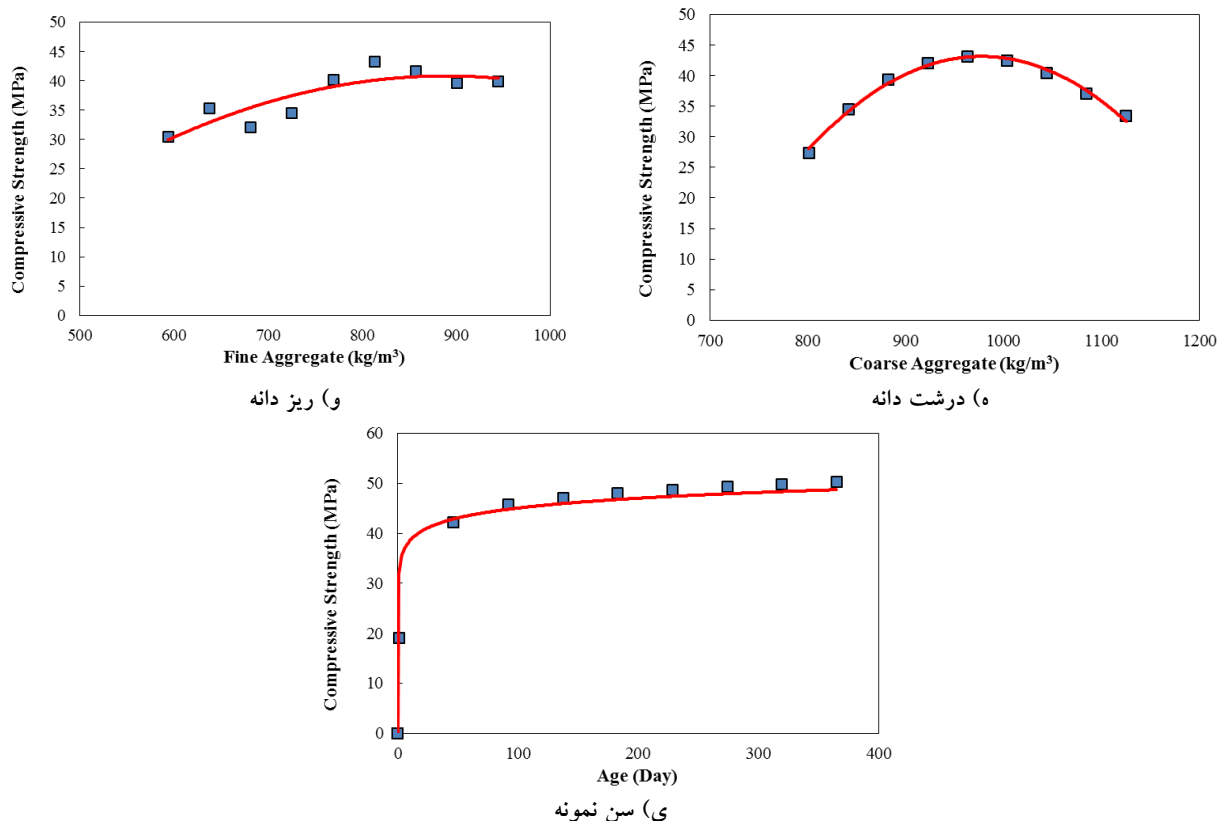
الف) سیمان



د) فوق روان‌کننده



ج) آب



شکل ۴- تاثیر پارمترهای ورودی مختلف بر روی مقاومت فشاری بتن.

۵- مطالعه مقایسه‌ای

در مورد پیش بینی مقاومت فشاری بتن‌های با عملکرد بالا از روش‌های دیگری نیز استفاده شده است. لذا در این قسمت نتایج حاصل از شبکه عصبی مصنوعی (ANN) شکل گرفته در این مطالعه با روش‌های دیگر در مطالعات دیگر، مقایسه و بررسی می‌گردد. در جدول زیر مقدار ضریب همبستگی حاصل از روش‌های به کاررفته در مطالعات پیشین در پیش‌بینی مقاومت فشاری بتن‌های با عملکرد بالا ارائه شده است.

جدول ۳ مقایسه مقادیر R در پیش‌بینی مقاومت فشاری بتن‌های با عملکرد بالا با استفاده از روش‌های مختلف

نویسندگان	مرجع	روش مورد استفاده	R	نسبت به مطالعه کنونی R قدر مطلق درصد اختلاف
Yeh	[۳۱]	Liner regression (LR)	۰/۷۵۷	۲۷/۷۴
Gupta et al.	[۳۲]	Neural-expert system (NEX)	۰/۷۵۹	۲۷/۴
Chou et al.	[۳۳]	Multiple regression (MR)	۰/۷۸۲	۲۳/۶۶
Fazel Zarandi et al.	[۳۴]	Fuzzy polynomial neural networks (FPN)	۰/۹۰۶	۶/۷۳
Deepa et al.	[۳۵]	M5P model tree (M5P)	۰/۸۸۷	۹
مطالعه کنونی	---	Artificial neural network (ANN)	۰/۹۶۷	----

با توجه به جدول بالا مشاهده می‌شود که مقدار ضریب همبستگی در این مطالعه که با روش شبکه عصبی مصنوعی انجام شده است در مقایسه با روش‌های دیگر بهبود قابل توجهی داشته است. بیشترین درصد افزایش R در اثر استفاده از شبکه عصبی برابر با ۲۷/۷۴ درصد و در مقایسه با روش برازش خطی (LR) می‌باشد. کمترین افزایش نیز مربوط به روش M5P بوده و درصد افزایش آن ۹ درصد

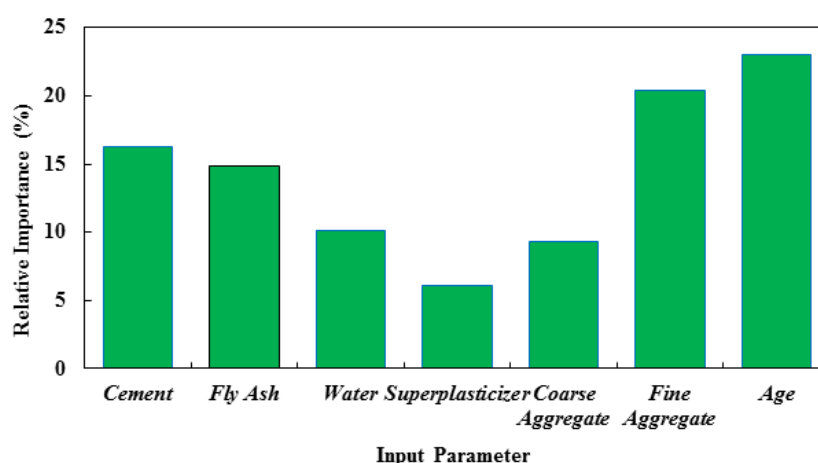
می‌باشد. گرچه داده‌های تشکیل دهنده شبکه در مطالعات ذکر شده در جدول ۳ یکسان نبوده اما به طور کلی و تقریبی می‌توان نتیجه گرفت که استفاده از شبکه عصبی مصنوعی نسبت به روش‌های ارائه شده در جدول ۳ برتری قابل توجهی دارد.

۶- آنالیز حساسیت

آنالیز حساسیت میزان تأثیر هر پارامتر ورودی را بر پارامتر خروجی تعیین می‌کند. روش‌های گوناگون برای تحلیل حساسیت ارائه شده است. در این مطالعه آنالیز حساسیت با استفاده از مقادیر وزنی به دست آمده است. در این روش از یک ماتریس وزن ایستا برای تعیین تأثیر هر ورودی بر خروجی شبکه استفاده می‌شود. فرمول‌های مختلفی برای آنالیز حساسیت با استفاده از مقادیر وزنی پیشنهاد شده است که در این مطالعه به دلیل کاربردی بودن و رایج تر بودن، از معادله Milne [۳۶] (معادله (۳)) استفاده شده است.

$$Q_{ik} = \frac{\sum_{j=1}^{n_{hidden}} \frac{W_{ji}}{\sum_{l=1}^{n_{inputs}} |W_{jl}|} \cdot W_{oj}}{\sum_{k=1}^{n_{inputs}} \left(\sum_{j=1}^{n_{hidden}} \frac{W_{jk}}{\sum_{l=1}^{n_{inputs}} |W_{jl}|} \cdot W_{oj} \right)} \quad (3)$$

در این معادله $\sum_{l=1}^{n_{inputs}} |W_{jl}|$ برابر با مجموع وزن‌های اتصال بین نورون ورودی N و نورون مخفی J می‌باشد. Q_{ik} برابر با درصد تأثیر متغیر ورودی x_i بر متغیر خروجی y_k می‌باشد. $\{1,1\}$ برابر با وزن پارامترهای ورودی و $\{2,1\}$ برابر با وزن پارامتر خروجی می‌باشد. W_{ji} برابر با وزن اتصال بین نورون‌های ورودی i و نورون‌های مخفی j و W_{oj} برابر با وزن اتصال بین نورون‌های مخفی j و نورون خروجی o می‌باشد. این معادله به وسیله ضرب وزن‌های W_{ji} و W_{oj} برای هر یک از نورون‌های مخفی در شبکه به صورت مجموع مقادیر محاسبه شده ضرب به دست می‌آید. مقادیر وزن‌ها برای پارامترهای ورودی و همچنین پارامتر خروجی در جدول ۴ آورده شده است. در شکل ۵ اهمیت نسبی بر حسب درصد برای هر یک از پارامترهای ورودی بر روی پارامتر خروجی بر اساس وزن‌های به دست آمده از شبکه نشان داده شده است.



شکل ۵- اهمیت نسبی پارامترها بر خروجی شبکه

بر اساس معادله (۳) میزان اهمیت نسبی هر پارامتر ورودی بر پارامتر خروجی (مقاومت فشاری بتن) بر حسب درصد به دست آمد و در شکل ۵ نشان داده شده است. همان‌گونه که از شکل مشاهده می‌گردد پارامترهای سن نمونه و مقدار ریز دانه به ترتیب با اهمیت نسبی ۲۳ و ۲۰ درصد دارای بیشترین درصد اهمیت نسبی و همچنین مقادیر فوق روان‌کننده و درشت دانه با اهمیت نسبی ۹ و ۶ درصد کمترین درصد اهمیت نسبی را بر روی مقاومت فشاری بتن دارند. نتایج حاصل از آنالیز حساسیت بر اساس معادله Milne [۳۶] به دست

آمده است و به نظر می‌رسد که در تعیین درصد پارامترهای نسبی به طور دقیقی عمل نکرده است زیرا به طور کلی در بتن‌های معمولی باید مقدار سیمان و آب بیشترین تاثیر را در مقاومت فشاری بتن داشته باشند با این حال نتایج به دست آمده بر اساس وزن‌ها و داده‌های موجود به دست آمده و می‌تواند مورد پذیرش قرار گیرد.

جدول ۴- وزن‌های مربوط به مقادیر ورودی و خروجی برای شبکه بهینه.

a1 و w							b1 و
-۱/۱۱۲۶۷	-۰/۶۰۰۹۴	-۰/۳۰۸۷	۰/۱۸۲۸۷	-۰/۴۲۳۹۶	-۰/۸۰۰۹۱	۵/۵۸۵۶۷۸	۶/۱۲۱۹۶
۳/۲۴۹۶۳	۲/۴۴۸۹۴۸	-۰/۰۵۶۲۵	-۰/۲۰۱۹۷	۱/۰۴۲۸۰۹	۱/۷۲۲۰۲۵	-۲/۱۶۴۳۹	-۴/۱۴۷۵۳
-۰/۵۳۳۵۳	-۴/۲۰۱۸۱	۲/۴۵۵۷۰۲	۴/۱۴۰۶۴۹	۱/۳۵۰۷۱۲	-۵/۳۷۴۷۹	۰/۴۹۷۷۷۵	-۲/۰۶۴۰۴
۲/۷۲۲۵۸۱	۲/۰۶۵۴۸۳	-۱/۲۲۱۵۶	-۰/۴۲۰۲۴	-۰/۱۲۶۹۷	۱/۶۵۲۷۹۵	۰/۱۲۳۹۴۸	۱/۰۶۷۷۰۵
-۰/۹۸۷۵۷	-۰/۰۱۶۳۶	-۱/۰۶۱۲۴	-۰/۰۵۸۷۸	-۱/۱۷۳۱۷	-۱/۱۳۱۱۵	-۳/۳۱۰۲۲	-۴/۱۳۲۴
-۰/۶۰۷۱۹	۱/۰۵۶۱۲۵	۱/۳۱۰۷۷۱	-۰/۳۷۷۸۸	۱/۵۴۲۰۹۸	۲/۹۴۴۴۰۹	-۰/۷۹۹۴۹	-۲/۱۶۳۷۷

a2 و w						b2 و
۳/۰۰۱۷۰۸	۲/۵۰۹۹۰۱	۰/۲۲۸۰۳۷	۰/۴۰۳۵۴۹	-۰/۹۳۸۱۶	-۰/۲۵۳۴۹	-۱/۳۹۲۱۵

در جدول بالا $w(1,1)$ برابر با وزن پارامترهای ورودی، $w(2,1)$ برابر با وزن پارامترهای خروجی، $b(1,1)$ برابر با بایاس پارامترهای ورودی و $b(2,1)$ برابر با بایاس پارامتر خروجی می‌باشند.

۷- نتایج

در این مطالعه با استفاده از شبکه عصبی مصنوعی به پیش‌بینی مقاومت فشاری بتن‌های با عملکرد بالا بر پایه خاکستر بادی پرداخته شده است. پارامترهای ورودی برای شبکه شامل مقادیر سیمان، خاکستر بادی، آب، فوق‌روان‌کننده، درشت دانه، ریز دانه و سن نمونه بتنی بودند و مقاومت فشاری نمونه بتنی به عنوان پارامتر خروجی در نظر گرفته شد.

- از میان ۴۷۱ داده، بررسی میزان تکرار و فراوانی پارامترهای مختلف نشان داد که در داده‌های آزمایشگاهی بیشترین مقدار سیمان استفاده شده بین ۲۳۰ تا ۳۵۰ کیلوگرم در هر متر مکعب بتن می‌باشد. در مورد خاکستر بادی این میزان بین ۱۰۰ تا ۱۳۰ کیلوگرم مشاهده گردید.
- در این مطالعه با استفاده از شبکه انتشار برگشتی با دو لایه پنهان و تعداد نورون‌های مختلف از ۳ تا ۲۰ عدد آموزش داده شد و تعداد ۶ نورون در هر لایه پنهان به عنوان بهترین شبکه شناسایی شد. مقادیر ضریب همبستگی و میانگین مربعات خطا برای این شبکه بهینه به ترتیب برابر با ۰/۹۷ و ۰/۰۰۲۴۸۰۷ به دست آمد.
- با توجه به داده‌های مورد بررسی، بیشترین میزان تاثیر هر پارامتر ورودی بر روی مقاومت فشاری بتن را، با توجه به ثابت بودن مابقی پارامترها به اندازه مقدار میانگینشان (آنالیز پارامتریک)، مقدار سیمان و آب دارند. کمترین میزان تاثیر برای مقادیر فوق‌روان‌کننده و ریزدانه مشاهده شد.
- آنالیز حساسیت با استفاده از مقادیر وزنی انجام شد و مشخص شد که مقادیر سن نمونه، ریز دانه و سیمان به ترتیب بیشترین تاثیر و مقادیر فوق‌روان‌کننده، درشت دانه و آب به ترتیب کمترین اثر را بر روی پارامتر خروجی (مقاومت فشاری) داشتند.
- با توجه به مقادیر ضریب همبستگی به دست آمده توسط شبکه (بالای ۹۵ درصد) می‌توان نتیجه گرفت که شبکه مدل شده قابلیت بسیار خوبی در پیش‌بینی مقاومت فشاری بتن‌های با عملکرد بالا بر پایه خاکستر بادی در محدوده ۶ تا ۸۰

مگا پاسگال دارد. همچنین مقادیر ضریب همبستگی در شبکه عصبی مصنوعی دقت بالاتری را در مقایسه با روش‌های دیگر از مطالعات دیگر، از خود نشان داد.

۸- پیشنهاد برای مطالعات آتی

موضوعات زیر به عنوان پیشنهاد برای مطالعات آتی در نظر گرفته می‌شوند:

تخمین مقاومت فشاری بتن‌های با عملکرد بالا بر پایه خاکستر بادی با استفاده از روش‌های ابتکاری و فراابتکاری

تعیین طرح اختلاط بهینه در بتن‌های با عملکرد بالا بر پایه خاکستر بادی با استفاده از روش‌های بهینه سازی مختلف

تخمین مقاومت فشاری بتن‌های با عملکرد بالا بر پایه خاکستر بادی با استفاده از روش‌های GEP و GMDH

مراجع

1. *Design and construction of reinforced concrete buildings, fourth edition.* (2013).
2. Ahmaruzzaman, M. (2010). A review on the utilization of fly ash. *Progress in Energy and Combustion Science*, 36(3), 327–363. <https://doi.org/10.1016/j.pecs.2009.11.003>
3. Neville, A., & Aitcin, P.-C. (1998). High performance concrete—An overview. *Materials and Structures*, 31(2), 111–117. <https://doi.org/10.1007/BF02486473>
4. Prasad, B. K. R., Eskandari, H., & Reddy, B. V. V. (2009). Prediction of compressive strength of SCC and HPC with high volume fly ash using ANN. *Construction and Building Materials*, 23(1), 117–128. <https://doi.org/10.1016/j.conbuildmat.2008.01.014>
5. Asl, S. H., Ahmadi, M., Ghiasvand, M., Tardast, A., & Katal, R. (2013). Artificial neural network (ANN) approach for modeling of Cr(VI) adsorption from aqueous solution by zeolite prepared from raw fly ash (ZFA). *Journal of Industrial and Engineering Chemistry*, 19(3), 1044–1055. <https://doi.org/10.1016/j.jiec.2012.12.001>
6. Topçu, İ. B., & Sarıdemir, M. (2008). Prediction of compressive strength of concrete containing fly ash using artificial neural networks and fuzzy logic. *Computational Materials Science*, 41(3), 305–311. <https://doi.org/10.1016/j.commatsci.2007.04.009>
7. Rezazadeh Eidgahee, D., Jahangir, H., Solatifar, N., Fakharian, P., & Rezaeemanesh, M. (2022). Data-driven estimation models of asphalt mixtures dynamic modulus using ANN, GP and combinatorial GMDH approaches. *Neural Computing and Applications*. <https://doi.org/10.1007/s00521-022-07382-3>
8. Naderpour, H., Sharei, M., Fakharian, P., & Heravi, M. A. (2022). Shear Strength Prediction of Reinforced Concrete Shear Wall Using ANN, GMDH-NN and GEP. *Journal of Soft Computing in Civil Engineering*, 6(1), 66–87. <https://doi.org/10.22115/scce.2022.283486.1308>
9. Naderpour, H., Rezazadeh Eidgahee, D., Fakharian, P., Rafiean, A. H., & Kalantari, S. M. (2020). A new proposed approach for moment capacity estimation of ferrocement members using Group Method of Data Handling. *Engineering Science and Technology, an International Journal*, 23(2), 382–391. <https://doi.org/10.1016/j.jestch.2019.05.013>
10. Naderpour, H., Rafiean, A. H., & Fakharian, P. (2018). Compressive strength prediction of environmentally friendly concrete using artificial neural networks. *Journal of Building Engineering*, 16, 213–219. <https://doi.org/10.1016/j.jobe.2018.01.007>
11. Naderpour, H., Nagai, K., Fakharian, P., & Haji, M. (2019). Innovative models for prediction of compressive strength of FRP-confined circular reinforced concrete columns using soft computing methods. *Composite Structures*, 215, 69–84. <https://doi.org/10.1016/j.compstruct.2019.02.048>
12. Shahmansouri, A. A., Akbarzadeh Bengar, H., & Ghanbari, S. (2020). Compressive strength prediction of eco-efficient GGBS-based geopolymer concrete using GEP method. *Journal of Building Engineering*, 31, 101326. <https://doi.org/https://doi.org/10.1016/j.jobe.2020.101326>
13. Awoyera, P. O., Kirgiz, M. S., Viloria, A., & Ovallos-Gazabon, D. (2020). Estimating strength properties of geopolymer self-compacting concrete using machine learning techniques. *Journal of Materials Research and*

- Technology*, 9(4), 9016–9028. <https://doi.org/10.1016/j.jmrt.2020.06.008>
14. Dantas, A. T. A., Batista Leite, M., & De Jesus Nagahama, K. (2013). Prediction of compressive strength of concrete containing construction and demolition waste using artificial neural networks. *Construction and Building Materials*, 38, 717–722. <https://doi.org/10.1016/J.CONBUILDMAT.2012.09.026>
 15. Duan, Z. H., Kou, S. C., & Poon, C. S. (2013). Prediction of compressive strength of recycled aggregate concrete using artificial neural networks. *Construction and Building Materials*, 40, 1200–1206. <https://doi.org/10.1016/j.conbuildmat.2012.04.063>
 16. Nguyen, T.-D., Tran, T.-H., & Hoang, N.-D. (2020). Prediction of interface yield stress and plastic viscosity of fresh concrete using a hybrid machine learning approach. *Advanced Engineering Informatics*, 44, 101057. <https://doi.org/10.1016/j.aei.2020.101057>
 17. Zhang, J., Li, D., & Wang, Y. (2020). Toward intelligent construction: Prediction of mechanical properties of manufactured-sand concrete using tree-based models. *Journal of Cleaner Production*, 258, 120665. <https://doi.org/10.1016/j.jclepro.2020.120665>
 18. Siddique, R., Aggarwal, P., & Aggarwal, Y. (2011). Prediction of compressive strength of self-compacting concrete containing bottom ash using artificial neural networks. *Advances in Engineering Software*, 42(10), 780–786. <https://doi.org/10.1016/j.advengsoft.2011.05.016>
 19. Tran, V.-L., Thai, D.-K., & Nguyen, D.-D. (2020). Practical artificial neural network tool for predicting the axial compression capacity of circular concrete-filled steel tube columns with ultra-high-strength concrete. *Thin-Walled Structures*, 151, 106720. <https://doi.org/10.1016/j.tws.2020.106720>
 20. Iqbal, M. F., Liu, Q., Azim, I., Zhu, X., Yang, J., Javed, M. F., & Rauf, M. (2020). Prediction of mechanical properties of green concrete incorporating waste foundry sand based on gene expression programming. *Journal of Hazardous Materials*, 384, 121322. <https://doi.org/10.1016/j.jhazmat.2019.121322>
 21. Congro, M., Monteiro, V. M. de A., Brandão, A. L. T., Santos, B. F. dos, Roehl, D., & Silva, F. de A. (2021). Prediction of the residual flexural strength of fiber reinforced concrete using artificial neural networks. *Construction and Building Materials*, 303, 124502. <https://doi.org/10.1016/j.conbuildmat.2021.124502>
 22. Kumar, A., Arora, H. C., Kapoor, N. R., Mohammed, M. A., Kumar, K., Majumdar, A., & Thinnukool, O. (2022). Compressive Strength Prediction of Lightweight Concrete: Machine Learning Models. *Sustainability*, 14(4), 2404. <https://doi.org/10.3390/su14042404>
 23. Asadi Shamsabadi, E., Roshan, N., Hadigheh, S. A., Nehdi, M. L., Khodabakhshian, A., & Ghalehnovi, M. (2022). Machine learning-based compressive strength modelling of concrete incorporating waste marble powder. *Construction and Building Materials*, 324, 126592. <https://doi.org/10.1016/j.conbuildmat.2022.126592>
 24. Thirumalai Raja, K., Jayanthi, N., Leta Tesfaye, J., Nagaprasad, N., Krishnaraj, R., & Kaushik, V. S. (2022). Using an Artificial Neural Network to Validate and Predict the Physical Properties of Self-Compacting Concrete. *Advances in Materials Science and Engineering*, 2022, 1–10. <https://doi.org/10.1155/2022/1206512>
 25. Frank, A. ., & Asuncion, A. {UCI}. (2010). Machine Learning Repository. Available online: <https://archive.ics.uci.edu/ml/index.php> (accessed on 2 January 2021).
 26. Naderpour, H., Nagai, K., Fakharian, P., & Haji, M. (2019). Innovative models for prediction of compressive strength of FRP-confined circular reinforced concrete columns using soft computing methods. *Composite Structures*, 215, 69–84. <https://doi.org/10.1016/j.compstruct.2019.02.048>
 27. Naderpour, H., Haji, M., & Mirrashid, M. (2020). Shear capacity estimation of FRP-reinforced concrete beams using computational intelligence. *Structures*, 28, 321–328. <https://doi.org/10.1016/j.istruc.2020.08.076>
 28. Ghasemzadeh mosavinejad, S. H., ganjeh khosravi, benyamin, & razzaghi, javad. (2019). Evaluation of neural network model for compressive strength of the steel fiber reinforced concrete using break-off method. *Journal of Structural and Construction Engineering*, 5(4), 41–56. <https://doi.org/10.22065/jsce.2017.86365.1194>
 29. Toolbox, S. M. (1993). Matlab. *Mathworks Inc.*
 30. Mukherjee, A., & Nag Biswas, S. (1997). Artificial neural networks in prediction of mechanical behavior of concrete at high temperature. *Nuclear Engineering and Design*, 178(1), 1–11. <https://doi.org/10.1016/S0029->

5493(97)00152-0

31. Yeh, I.-C. (1998). Modeling Concrete Strength with Augment-Neuron Networks. *Journal of Materials in Civil Engineering*, 10(4), 263–268. [https://doi.org/10.1061/\(ASCE\)0899-1561\(1998\)10:4\(263\)](https://doi.org/10.1061/(ASCE)0899-1561(1998)10:4(263))
32. Gupta, R., Kewalramani, M. A., & Goel, A. (2006). Prediction of Concrete Strength Using Neural-Expert System. *Journal of Materials in Civil Engineering*, 18(3), 462–466. [https://doi.org/10.1061/\(ASCE\)0899-1561\(2006\)18:3\(462\)](https://doi.org/10.1061/(ASCE)0899-1561(2006)18:3(462))
33. Chou, J.-S., Chiu, C.-K., Farfoura, M., & Al-Taharwa, I. (2011). Optimizing the Prediction Accuracy of Concrete Compressive Strength Based on a Comparison of Data-Mining Techniques. *Journal of Computing in Civil Engineering*, 25(3), 242–253. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000088](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000088)
34. Fazel Zarandi, M. H., Türksen, I. B., Sobhani, J., & Ramezani pour, A. A. (2008). Fuzzy polynomial neural networks for approximation of the compressive strength of concrete. *Applied Soft Computing*, 8(1), 488–498. <https://doi.org/10.1016/j.asoc.2007.02.010>
35. Deepa, C., Sathiyakumari, K., & Sudha, V. P. (2010). Prediction of the Compressive Strength of High Performance Concrete Mix using Tree Based Modeling. *International Journal of Computer Applications*, 6(5), 18–24. <https://doi.org/10.5120/1076-1406>
36. Milne, L. (1995). Feature selection using neural networks with contribution measures. In *Australian Conference on Artificial Intelligence AI'95* (pp. 1–8). Citeseer.