



University Of Qom



## Proposing a Model for Compressive Strength Prediction of Self Compacting Concrete Using ANN

Mohammad Reza Torabi<sup>1</sup> , Mojtaba Hosseini<sup>2</sup> , Ramin Hajimohammadrezaee<sup>3</sup> 

1. Department of Civil Engineering, Faculty of Engineering, Lorestan University, Khorramabad, Iran. E-mail: [torabi.mo@fe.lu.ac.ir](mailto:torabi.mo@fe.lu.ac.ir)
2. Corresponding author, Department of Civil Engineering, Faculty of Engineering, Lorestan University, Khorramabad, Iran. E-mail: [hosseini.m@lu.ac.ir](mailto:hosseini.m@lu.ac.ir)
3. Science and Research Branch, Islamic Azad University, Tehran, Iran. E-mail: [ramin\\_hajirezaee@yahoo.com](mailto:ramin_hajirezaee@yahoo.com)

### Article Info

**Article type:**  
Research Article

**Article history:**  
Received 16 Jul 2024  
Revised 17 Oct 2024  
Accepted 19 Oct 2024  
Published 20 Oct 2024

**Keywords:**  
Self Compacting  
Concrete,  
Artificial Neural  
Network,  
Concrete Mix Design,  
Concrete Compressive  
Strength,  
Sensitivity Analysis.

### ABSTRACT

*Self-compacting concrete (SCC) is a dynamic field in construction worldwide. This type of concrete encompasses a wide range of mix designs that possess the necessary fresh and hardened concrete properties for specific applications. Although strength remains the primary criterion for the success of SCC, its fresh concrete properties are significantly broader than those of conventional vibrated concrete. These desirable properties must be maintained during placement and at the site. SCC is a preferred option in cases where reinforcement bars are densely arranged. Moreover, the absence of the need for vibrators significantly reduces environmental noise pollution. Despite its favorable features, the mix design and execution of SCC depend on various factors, such as the gradation of aggregates, the type of additives, and the fillers used. Considering each of these criteria influences the quality of hardened concrete and the workability of fresh concrete. This research has been conducted due to the need for improving accuracy and efficiency in SCC mix design and reducing the time and cost of physical testing. In this paper, the strength of SCC has been predicted using laboratory data and the application of artificial neural networks. The results indicate a high level of accuracy in the estimates made through soft computing techniques.*

**Cite this article:** Torabi MR, Hosseini M, Hajimohammadrezaee R. Proposing a Model for Compressive Strength Prediction of Self Compacting Concrete Using ANN. Civil Infrastructure Researches. 2024; 10(2): 119-131. <https://doi.org/10.22091/cer.2024.11015.1564>.



## ارائه مدلی جهت پیش‌بینی مقاومت بتن خودتراکم به کمک شبکه‌های عصبی مصنوعی

محمد رضا ترابی<sup>۱</sup>، مجتبی حسینی<sup>۲\*</sup>، رامین حاجی محمدرضائی<sup>۳</sup>

۱. گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه لرستان، خرم‌آباد، ایران. رایانامه: [torabi.mo@fe.lu.ac.ir](mailto:torabi.mo@fe.lu.ac.ir)

۲. نویسنده مسئول، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه لرستان، خرم‌آباد، ایران. رایانامه: [hosseini.m@lu.ac.ir](mailto:hosseini.m@lu.ac.ir)

۳. دانشگاه آزاد اسلامی واحد علوم و تحقیقات، تهران، ایران. رایانامه: [ramin\\_hajirezaee@yahoo.com](mailto:ramin_hajirezaee@yahoo.com)

### چکیده

بتن خودتراکم یک عرصه پویا در زمینه ساخت‌وساز در دنیا می‌باشد. این بتن، شامل بازه گسترده‌ای از طرح‌های مخلوط است که خواص بتن تازه و سخت شده لازم برای کاربری‌های خاص دارا می‌باشند. اگرچه مقاومت، همچنان معیار اصلی موفقیت این بتن می‌باشد؛ اما ویژگی‌های بتن تازه آن بسیار گسترده‌تر از بتن معمولی و متراکم شده توسط لرزاننده‌ها است. این خواص مطلوب باید در زمان، محل و بتن‌ریزی حفظ شوند. بتن خودتراکم در مواردی که شبکه‌بندی آرماتورها فشرده است، گزینه‌ای مطلوب می‌باشد. همچنین عدم نیاز به لرزاننده، آلودگی صوتی محیط را به نحو قابل‌ملاحظه‌ای کاهش می‌دهد. علی‌رغم ویژگی‌های مطلوب، طرح مخلوط و اجرای این نوع بتن به عوامل متعددی از قبیل دانه‌بندی مصالح سنگی، نوع مواد افزودنی و همچنین پرکننده‌های مورد استفاده بستگی دارد. در نظر گرفتن هریک از معیارهای فوق، کیفیت بتن سخت شده و کارپذیری بتن تازه را تحت تأثیر قرار می‌دهد. این پژوهش به دلیل نیاز به بهبود دقت و کارایی در طراحی مخلوط بتن و کاهش زمان و هزینه‌های آزمایش‌های فیزیکی انجام شده است. در این مقاله، مقاومت بتن خودتراکم به کمک داده‌های آزمایشگاهی و به‌کارگیری شبکه‌های عصبی مصنوعی پیش‌بینی گردیده است. نتایج نشان‌دهنده دقت بالای تخمین‌های انجام شده به کمک محاسبات نرم می‌باشد.

### اطلاعات مقاله

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۳/۰۴/۲۶

تاریخ بازنگری: ۱۴۰۳/۰۷/۲۶

تاریخ پذیرش: ۱۴۰۳/۰۷/۲۸

تاریخ انتشار: ۱۴۰۳/۰۷/۲۹

### کلیدواژه‌ها:

بتن خودتراکم،

شبکه عصبی مصنوعی،

مقاومت،

طرح مخلوط،

آنالیز حساسیت.

استناد: ترابی محمد رضا، حسینی مجتبی، حاجی محمدرضائی رامین. ارائه مدلی جهت پیش‌بینی مقاومت بتن خودتراکم به کمک شبکه‌های عصبی مصنوعی. پژوهش‌های زیرساخت‌های عمرانی، ۱۴۰۳، ۱۰(۲): ۱۱۹-۱۳۱.

<https://doi.org/10.22091/cer.2024.11015.1564>

## ۱- مقدمه

زمان، هزینه و کیفیت سه عامل کلیدی در اجرای پروژه‌های ساختمانی محسوب می‌شوند که نقش مهمی در صنعت ساخت‌وساز ایفا می‌کنند. هرگونه پیشرفت یا توسعه‌ای که به بهبود این عوامل کمک کند، همواره مورد توجه مهندسان عمران خواهد بود. در صورت تأثیرگذاری این پیشرفت‌ها بر صنعت ساخت‌وساز، لازم است تحقیقات جامع در خصوص مزایا و معایب آن‌ها صورت گیرد و اقدامات ضروری برای پیاده‌سازی آن‌ها در این صنعت انجام شود. بتن خودتراکم با توجه به ویژگی‌های منحصر به فرد خود، یکی از این نوآوری‌هاست که می‌تواند تأثیر چشمگیری بر صنعت ساخت‌وساز داشته باشد.

بتن خودتراکم نخست در سال ۱۹۸۶ توسط اوکامورا<sup>۱</sup> در ژاپن پیشنهاد گردید و در سال ۱۹۸۸، این نوع بتن در کارگاه ساخته شد و نتایج قابل قبولی را از نظر خواص فیزیکی و مکانیکی بتن ارائه داد. مقالات متعددی در ارتباط با توسعه بتن خودتراکم در دنیا ارائه شد. امروزه بتن خودتراکم همزمان با کشور ژاپن در مراکز دانشگاهی و تحقیقاتی کشورهای اروپایی، کانادا و آمریکا تحت عنوان *self-consolidating concrete* موضوع بحث، بررسی و اجرای سازه‌های بتنی است [۹-۱]. در ایران نیز استفاده از بتن خودتراکم از چند سال قبل آغاز شده و از مزایای آن بهره گرفته شده است. برای مثال می‌توان از مصرف بتن خودتراکم در تونل رسالت در تهران نام برد.

در سال‌های اخیر، استفاده از روش‌های محاسبات نرم و به خصوص شبکه‌های عصبی مصنوعی در رشته مهندسی عمران، به دلیل دقت بسیار بالای این روش‌ها در پیش‌بینی نتایج، به‌طور گسترده‌ای افزایش یافته است [۱۰-۱۷]. نادرپور و فخاریان، به پیش‌بینی مقاومت پیچشی تیرهای بتنی مقاوم‌سازی شده با الیاف FRP با استفاده از شبکه عصبی مصنوعی پرداختند [۱۸].

سیدیکو<sup>۲</sup> و همکاران، مقاومت فشاری بتن خودتراکم حاوی خاکستر و توکلی و همکاران، اثرات ترکیبی الیاف و نانوسیلیس بر خواص مکانیکی بتن خودتراکم را با استفاده از شبکه‌های عصبی مصنوعی پیش‌بینی کرده‌اند [۱۹ و ۲۰]. نادرپور و همکاران، با بهره‌گیری از شبکه عصبی مصنوعی به پیش‌بینی مقاومت فشاری بتن‌های سازگار با محیط‌زیست پرداختند. وی همچنین در مقاله‌ای دیگر، با استفاده از روش‌های محاسبات نرم به پیش‌بینی مقاومت فشاری ستون‌های دایره‌ای مقاوم‌سازی شده با FRP پرداخت. آنها مدل خود را با مدل‌های موجود مقایسه کردند و دقت بسیار بالایی در مدل خود مشاهده کردند [۲۱ و ۲۲]. رضازاده و همکاران، یک فرمول جدید برای پیش‌بینی مقاومت فشاری خاک‌های رسی تثبیت شده با استفاده از ژئوپلیمرهای مبتنی بر IBP با استفاده از دو روش ANN و GMDH-NN پرداختند [۲۳]. محققان دیگری، رویکرد پیشنهادی جدیدی برای تخمین ظرفیت خمشی با استفاده از روش GMDH ارائه داده‌اند [۲۴].

لازم به ذکر است که سیال و پایدار بودن از مبانی طراحی مخلوط بتن خودتراکم می‌باشد، اما غیر از این خصوصیات، عوامل اقتصادی را نیز باید در طراحی در نظر گرفت. چالش مهم در طراحی مخلوط بتن خودتراکم، معادل بودن مشخصات مورد نیاز با مشخصات واقعی است. مواد مورد نیاز برای ساخت بتن خودتراکم شامل سیمان، سنگدانه درشت، سنگدانه ریز، مواد افزودنی معدنی، فوق‌کاهنده آب، مواد اصلاح‌کننده ویسکوزیته و فیلرها است [۲۵-۳۴]. شربتدار و همکاران پژوهشی را در زمینه بهبود خصوصیات بتن خودتراکم با استفاده از بخار سیلیکا و متاکائولین ترکیبی ارائه داده‌اند [۳۵]. بیگام<sup>۳</sup> و همکاران، تأثیر الیاف فولاد در بتن خودتراکم را مورد مطالعه قرار داده‌اند [۳۶].

<sup>۲</sup>- Siddique

<sup>۳</sup>- Begum

<sup>۱</sup>- Okamura

مثال [۳۷-۴۰]). همچنین تحقیقات متعددی با استفاده از شبکه عصبی مصنوعی برای پیش‌بینی مقاومت فشاری صورت گرفته است [۴۱-۴۹].

اگر مقدار مجموع ورودی‌ها از یک حد آستانه فراتر رود، در آن صورت پردازشگر فعال شده و از طریق آکسون علائمی را به سلول بعدی انتقال می‌دهد. سازوکار سلول‌های عصبی به صورت سری و موازی می‌باشد، بدین‌گونه که مجموعه سلول‌های عصبی موازی هم که هر یک دارای ورودی مخصوص به خود است، پس از انجام عمل پردازش، مجموعه‌ای از خروجی‌ها را تولید می‌کند. این خروجی‌ها به نوبه خود می‌تواند به عنوان ورودی‌های مجموعه دیگر از سلول‌های عصبی که به طور سری به مجموعه سلول‌های اولیه متصل می‌باشند به کار رود. بنابراین خروجی هر نرون در ضرایب وزنی ضرب و به تابع تحریک غیرخطی، به عنوان ورودی، داده می‌شود.

به طور کلی، مجموعه سلول‌های عصبی موازی، تشکیل یک لایه را می‌دهند. هر شبکه عصبی برای تولید خروجی خود می‌تواند یک یا چند لایه داشته باشد که معمولاً از این لایه‌ها تحت عنوان لایه‌های پنهان یاد می‌شود. آخرین لایه که در حقیقت خروجی شبکه را تولید می‌کند، لایه خروجی نام دارد. از انواع شبکه‌های قابل استفاده جهت پیش‌بینی، می‌توان به شبکه‌های انتشار برگشتی، پس انتشار، دلتا و غیره اشاره کرد.

از انواع شبکه‌های قابل استفاده می‌توان به شبکه‌های دلتا، انتشار برگشتی، پس انتشار و غیره اشاره کرد که در ادامه برای مدل‌سازی مقاومت بتن خودتراکم از شبکه پس‌انتشار برگشتی استفاده شده است. شبکه پس‌انتشار برگشتی آسان‌ترین و مؤثرترین مدل‌ها در میان شبکه‌های چندلایه می‌باشد. داده‌های مورد نیاز در شبکه به دو گروه داده‌های آموزشی که حدود ۷۰ درصد از کل داده‌ها را جهت آموزش و وزن‌دهی و داده‌های آزمایشی که حدود ۳۰ درصد از کل داده‌ها که در آموزش نقش نداشته و به عنوان راندمان شبکه آموزش دیده می‌باشند تقسیم می‌شود. این شبکه دارای یک لایه ورودی است که تعداد

در این مطالعه با استفاده از ۵۹ داده آزمایشگاهی معتبر به ارائه یک مدل، جهت پیش‌بینی مقاومت بتن خودتراکم به کمک شبکه‌های عصبی مصنوعی پرداخته شده است. برای مدل‌سازی با استفاده از شبکه عصبی مصنوعی، از شبکه پس انتشار برگشتی استفاده شده است. همچنین به منظور بررسی میزان تأثیر پارامترهای ورودی بر روی پارامتر خروجی آنالیز حساسیت با استفاده از معادله گارسن<sup>۴</sup> انجام شده و درصد تأثیر هر پارامتر بر روی مقاومت بتن خودتراکم تعیین گردید.

## ۲- پیش‌بینی مقاومت بتن خودتراکم به کمک

### شبکه‌های عصبی مصنوعی

جهت پیش‌بینی مقاومت بتن خودتراکم به کمک شبکه‌های عصبی می‌بایست میزان سیمان، میزان خاکستر بادی، میزان آب، میزان ریزدانه، میزان درشت‌دانه و فوق روان‌کننده به عنوان ورودی و مقاومت فشاری بتن خودتراکم به عنوان خروجی در نظر گرفته می‌شود.

شبکه عصبی نوعی ساختار ریاضی است که براساس مدل بیولوژیکی مغز انسان به وجود آمده است. هر شبکه عصبی مشتمل بر مجموعه‌ای از اجزای کوچک پردازنده به نام نورون<sup>۵</sup> می‌باشد که هر نورون به نورون‌های دیگر از طریق یک رابطه جهت‌دار که دارای وزن مختص به خود است، مرتبط می‌گردد. وزن‌ها نمایش‌دهنده اطلاعات مورد نیاز شبکه برای حل یک مسئله هستند. یک نورون بیولوژیکی دارای سه جزء دندریت<sup>۶</sup>، سوما<sup>۷</sup> و آکسون<sup>۸</sup> است. تعداد زیادی دندریت علائم دریافتی از سایر نورون‌ها را اصلاح می‌کنند و سوما (بدنه واحد پردازشگر)، علائم ورودی را جمع می‌نماید [۱۱ و ۱۴]. در مطالعات زیادی محققان در زمینه پیش‌بینی مقاومت فشاری بتن از شبکه‌های عصبی مصنوعی استفاده کرده‌اند (به عنوان

<sup>۴</sup>- Garson

<sup>۵</sup>- Neuron

<sup>۶</sup>- Dendrite

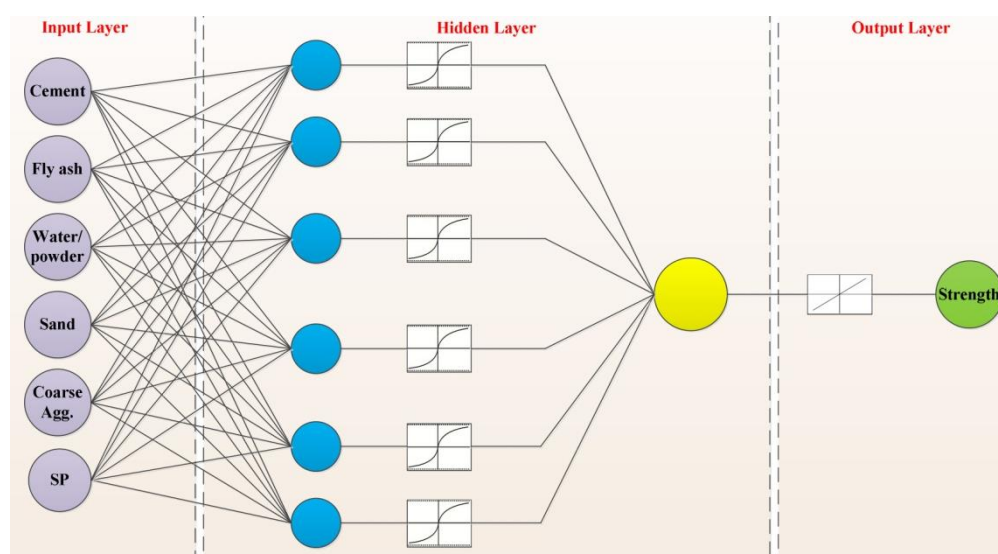
<sup>۷</sup>- Soma

<sup>۸</sup>- Axon

سیگموئید است. شکل ۱، نمونه شماتیک از لایه ورودی و پنهان را مشخص کرده است.

از نتایج آزمایشگاهی ۵۹ نمونه استاندارد بتنی ساخته شده از بتن خودتراکم جهت آموزش شبکه عصبی مصنوعی استفاده شده است [۵۰-۷۲]. دیتای مورد استفاده جهت آموزش، صحت‌سنجی و تست شبکه در جدول ۱ آورده شده است. در شکل ۲، ماتریس همبستگی بین پارامترهای تحقیق ارائه شده است.

ورودی‌های شبکه، بیانگر تعداد پارامترهای موجود در بخش ورودی شبکه بوده و دارای یک یا چند لایه پنهان است که هرکدام دارای تعدادی نورون هستند که تعداد این نورون‌ها و نوع تابع رفتاری در رفتار شبکه مورد نظر تأثیرگذار می‌باشد. در این مقاله تعداد لایه پنهان، یک در نظر گرفته شده است و تابع انتقال به‌کار رفته در لایه خروجی از نوع خطی ساده و در لایه پنهان از نوع تانژانت



شکل ۱- نمونه شماتیک شبکه عصبی ۶-۶-۱

جدول ۱- دیتای مورد استفاده جهت آموزش، صحت‌سنجی و تست شبکه

No.	Inputs						Target	Ref.
	Cement (kg/m <sup>3</sup> )	Fly ash (kg/m <sup>3</sup> )	Water/powder	Sand (kg/m <sup>3</sup> )	Coarse Agg. (kg/m <sup>3</sup> )	SP (%)	Strength (MPa)	
1	465	85	0.41	910	590	0.97	35.19	[50]
2	247	165	0.45	845	846	0.12	34.6	[51]
3	163	245	0.4	851	851	0.2	26.2	
4	161	241	0.35	866	864	0.3	35.8	[52]
5	83	468	0.41	624	794	1	14.64	
6	165	385	0.34	656	834	1	34.9	
7	225	525	0.33	487	620	1.36	34.83	
8	275	275	0.34	691	880	1.25	57.9	
9	325	325	0.34	611	777	1.18	50.07	
10	385	165	0.31	732	931	1.25	77.08	
11	350	150	0.36	707	901	0.795	71.62	
12	495	55	0.29	756	962	1.5	86.41	[53]
13	215	215	0.38	925	905	0.15	20.4	
14	350	150	0.35	900	600	1	37.18	
15	300	300	0.28	787	720	0.33	52.7	[55]


جدول ۱- ادامه

No.	Inputs						Target	Ref.
	Cement (kg/m3)	Fly ash (kg/m3)	Water/powder	Sand (kg/m3)	Coarse Agg. (kg/m3)	SP (%)	Strength (MPa)	
16	480	96	0.38	819	699	0.94	53	[56]
17	350	162	0.406	768	840	0.18	51.7	[57]
18	349	162	0.389	779	852	0.29	59.9	
19	350	133	0.38	815	883	0.338	55.3	
20	350	111	0.39	831	900	0.32	61	
21	250	257	0.38	787	853	0.226	51.5	
22	427	115	0.359	779	844	0.257	59.4	
23	348	224	0.305	783	848	0.9	58.6	
24	350	90	0.388	852	923	0.3	46.5	
25	327	173	0.35	902	803	0.41	61.6	
26	380	145	0.35	788	854	0.205	73.5	
27	350	186	0.33	786	851	0.22	70.4	
28	380	145	0.35	988	659	0.277	65.5	
29	380	192	0.349	931	621	0.21	67.8	
30	275	250	0.35	775	840	0.199	54.5	
31	399	100	0.35	814	882	0.146	55	[58]
32	344	147	0.35	814	881	0.116	48.75	
33	437	80	0.34	743	924	0.43	69.7	[59]
34	375	125	0.35	938	673	0.7	60.8	[60]
35	300	200	0.35	923	663	0.7	54.69	
36	225	275	0.35	908	652	0.7	41.42	
37	290	290	0.38	975	650	0.45	37.97	[61]
38	250	275	0.34	842	772	0.23	39.62	[62]
39	333	215	0.33	835	766	0.24	50.24	
40	417	153	0.32	828	759	0.306	61.82	
41	500	101	0.32	820	753	0.377	70.93	
42	583	50	0.31	813	745	0.455	81.25	
43	420	80	0.33	785	860	0.299	56	[63]
44	477	53	0.45	768	668	0.087	32.19	[64]
45	350	150	0.38	830	876	0.827	21.6	[65]
46	300	200	0.4	845	860	0.818	26.5	
47	250	250	0.42	856	856	0.781	31.25	
48	270	180	0.44	801	842	0.27	60.3	[66]
49	180	270	0.44	788	829	0.28	42.5	
50	440	110	0.32	714	917	0.69	69.8	[67]
51	330	220	0.32	700	899	0.69	60.9	
52	220	330	0.32	686	881	0.62	47.5	
53	165	385	0.58	735	865	0.836	37.92	[68]
54	275	275	0.37	796	937	0.74	63.32	
55	385	165	0.29	821	966	0.84	89.1	
56	220	180	0.39	916	900	0.115	49	[69]

جدول ۱- ادامه

No.	Inputs						Target	Ref.
	Cement (kg/m <sup>3</sup> )	Fly ash (kg/m <sup>3</sup> )	Water/powder	Sand (kg/m <sup>3</sup> )	Coarse Agg. (kg/m <sup>3</sup> )	SP (%)	Strength (MPa)	
57	321.75	173.25	0.36	862.45	729.18	0.545	32.26	[70]
58	360	240	0.28	853	698	0.3	63.5	[71]
59	380	20	0.38	1180	578	0.398	40.4	[72]

$$R = \frac{\sum_{i=1}^n (\tilde{y}_i - \bar{\tilde{y}})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (\tilde{y}_i - \bar{\tilde{y}})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (۶)$$



شکل ۲- ماتریس همبستگی بین پارامترهای تحقیق

شکل ۳، نمودار میزان دقت نتایج ناشی از مدل‌سازی شبکه عصبی در مقایسه با نتایج واقعی آزمایشگاهی را نشان می‌دهد که هرچه تمرکز این نقاط بر روی نیمساز ربع اول بیشتر باشد، نشانگر دقت بالاتر آن می‌باشد. در شکل ۴، مقدار رگرسیون شبکه انتخابی در مراحل مختلف مدل‌سازی پس از هشت اپوک مورد بررسی قرار گرفته است و افت حداقل مربعات خطا را نشان می‌دهد. شکل ۵، روند تغییرات شبکه طی اپوک‌های مختلف را نشان می‌دهد. در شکل ۶، مقایسه نتایج آزمایشگاهی با پیش‌بینی شبکه عصبی آورده شده است.

در شکل ۷، نتایج حاصل از شبکه عصبی مصنوعی در برابر داده‌های آزمایشگاهی با در نظر گرفتن میزان انحراف به کمک خطوط نیمه پر، نمایش داده شده است.

### ۳- سنجش پارامترهای خطا

در این تحقیق ارزیابی دقت و قابلیت مدل با استفاده از نمایه‌های ضریب همبستگی ( $R^2$ )، ریشه میانگین مربعات خطا میانگین خطای مطلق ( $RMSE^{10}$ )، خطای میانگین مربعات ( $MSE^{11}$ )، میانگین خطای مطلق ( $MAE^{12}$ )، میانگین  $MAPE^{13}$  و  $NMAE^{14}$  طبق روابط زیر صورت می‌گیرد [۲۳]:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\tilde{y}_i - y_i)^2 \quad (۱)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\tilde{y}_i - y_i)^2} \quad (۲)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\tilde{y}_i - y_i| \quad (۳)$$

$$MAPE = \frac{1}{n} \left[ \frac{\sum_{i=1}^n |\tilde{y}_i - y_i|}{\sum_{i=1}^n y_i} \right] \times 100 \quad (۴)$$

$$NMAE = \left[ \frac{\frac{1}{n} \sum_{i=1}^n |\tilde{y}_i - y_i|}{\text{Max}(y_i) - \text{Min}(y_i)} \right] \times 100 \quad (۵)$$

<sup>9</sup>- Linear Correlation Coefficient

<sup>10</sup>- Root-Mean-Squared Error

<sup>11</sup>- Mean-Squared Error

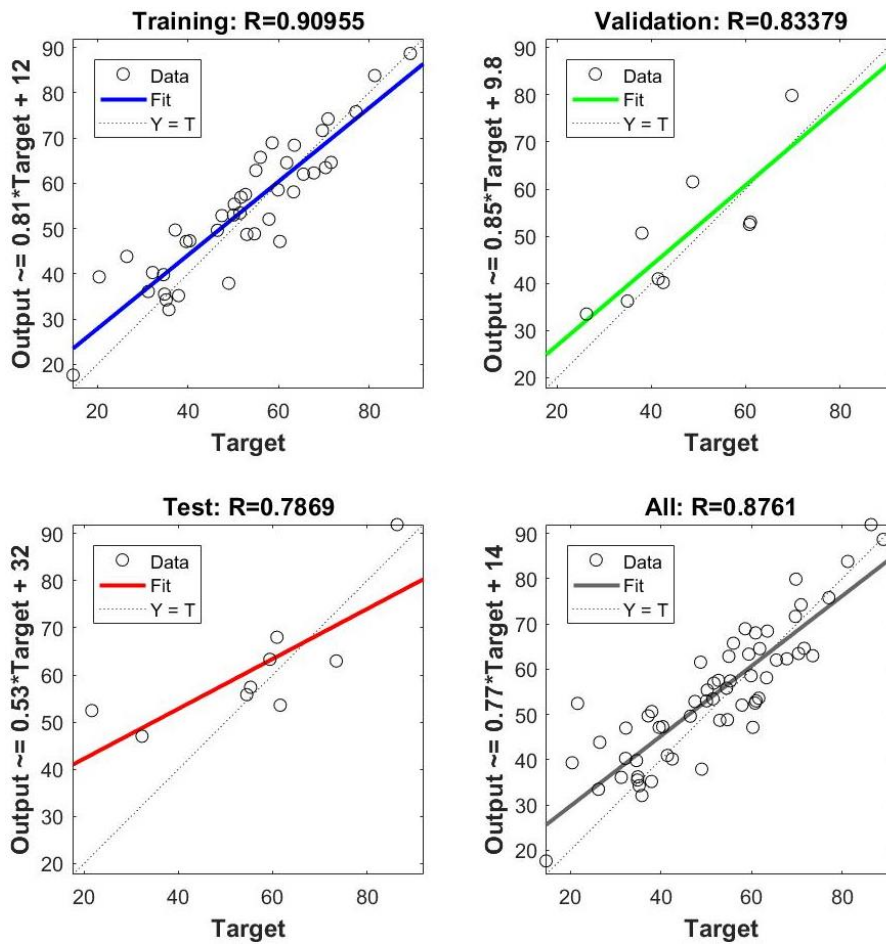
<sup>12</sup>- Mean Absolute Error

<sup>13</sup>- Mean Absolute Percentage Error


<sup>14</sup>- Normalized Mean Absolute Error

مناسبتی توانسته داده‌های آزمایشگاهی را تخمین بزند.

نتایج نشان می‌دهد که شبکه عصبی مصنوعی با دقت




شکل ۳- نمودار رگرسیون شبکه پس از آموزش

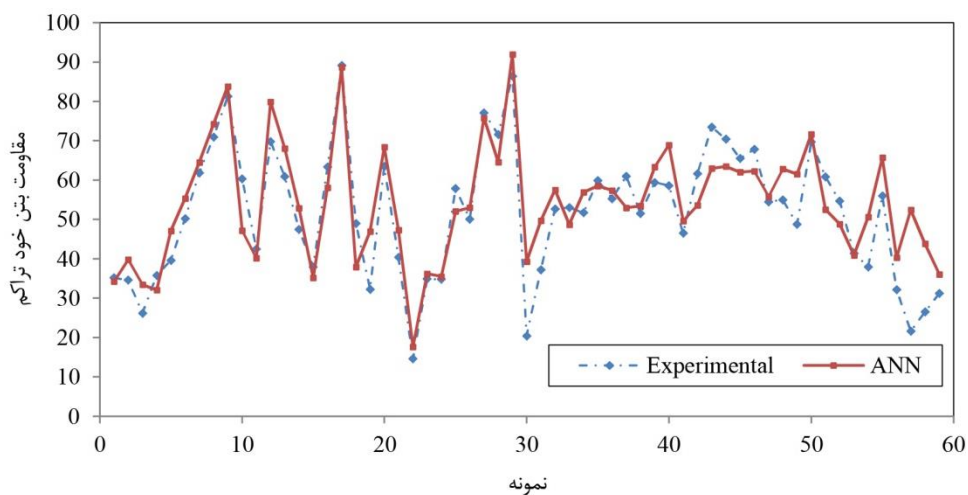


شکل ۴- روند تغییرات شبکه در مراحل آموزش شبکه






شکل ۵- نمودار میانگین مربعات خطا در فرآیند آموزش شبکه




شکل ۶- مقایسه نتایج آزمایشگاهی و شبکه عصبی



شکل ۷- مقایسه نتایج حاصل از شبکه عصبی مصنوعی با نتایج آزمایشگاهی و تراز خطاها

#### ۴- تحلیل حساسیت

نتایج تحلیل حساسیت (شکل ۸) نشان می‌دهد میزان سیمان در طرح مخلوط بیشترین تأثیر را بر روی مقاومت بتن خودتراکم می‌گذارد و به عنوان مهم‌ترین پارامتر تأثیرگذار شناخته می‌شوند.



شکل ۸- درصد تأثیر پارامترهای ورودی

#### ۵- نتیجه‌گیری

در این مقاله، از نتایج آزمایشگاهی ۵۹ نمونه استاندارد بتنی ساخته شده از بتن خودتراکم به منظور استفاده در مدل‌سازی شبکه عصبی مصنوعی بهره گرفته شده است. این نمونه‌ها به صورت دقیق و با رعایت تمامی استانداردهای لازم تهیه شده‌اند تا داده‌های به‌دست آمده از آن‌ها برای شبکه عصبی از بالاترین کیفیت و اعتبار برخوردار باشند. نتایج حاصل از مدل‌سازی شبکه عصبی نشان می‌دهد که به‌کارگیری این شبکه‌ها جهت پیش‌بینی مقاومت بتن‌های خودتراکم از دقت بالایی برخوردار است و به خوبی می‌تواند در فرایندهای طراحی و ارزیابی کیفیت بتن‌های خودتراکم مورد استفاده قرار گیرد. در فرایند مدل‌سازی، شبکه‌ای بهینه تلقی می‌شود که علاوه بر دستیابی به بالاترین ضریب رگرسیون، کمترین مقدار میانگین مربعات خطا را نیز داشته باشد. این معیارها نشان می‌دهد که شبکه باید توانایی تعمیم خوبی داشته باشد و همزمان دقت بالایی در پیش‌بینی‌ها ارائه دهد.

آنالیز براساس مقادیر وزن، منحصر بر مبنای مقادیر ذخیره شده در ماتریس استاتیک وزن‌ها برای تعیین تأثیر نسبی هر یک از داده‌های ورودی بر داده‌های خروجی شبکه می‌باشد. معادلات مختلفی مبتنی بر مقادیر وزن‌ها ارائه شده است که تمامی آنها با محاسبه حاصل ضرب وزن‌ها  $w_{ij}$  (وزن اتصال بین نورون ورودی  $i$  و نورون مخفی  $j$ ) و  $v_{jk}$  (وزن اتصال بین نورون مخفی  $j$  و نورون خروجی  $k$ ) برای هر یک از نورون‌های مخفی شبکه به‌صورت مجموع حاصل‌ضرب‌های محاسبه شده به‌دست می‌آید. یکی از کاربردی‌ترین معادلات، معادله Garson می‌باشد که در رابطه (۷) ذکر شده است.

$$Q_{ik} = \frac{\sum_{j=1}^L \left( \frac{w_{ij}}{\sum_{r=1}^N w_{rj}} v_{jk} \right)}{\sum_{i=1}^N \left( \sum_{j=1}^L \left( \frac{w_{ij}}{\sum_{r=1}^N w_{rj}} v_{jk} \right) \right)} \quad (7)$$

در رابطه (۷)،  $\sum_{r=1}^N w_{rj}$  مجموع وزن‌های اتصال بین نورون‌های ورودی  $N$  و نورون‌های مخفی  $L$ ،  $Q_{ik}$  درصد تأثیر متغیر ورودی  $x_i$  بر متغیر خروجی  $y_k$  می‌باشد. این روش زمانی که وزن‌های مثبت و منفی با هم وجود دارند، نسبت درستی ارائه نمی‌دهد. به همین سبب میلن روش گارسون را اصلاح کرد. میلن برای اصلاح روش گارسون از قدرمطلق وزن‌ها استفاده کرد که با این روش، نسبت‌های صحیحی برای هر دو وزن مثبت و منفی به‌دست می‌آید. رابطه (۸) روش میلن را نشان می‌دهد [۷۳]:

$$\frac{\sum_{j=1}^{n_{hidden}} \frac{w_{ji}}{\sum_{l=1}^{n_{inputs}} |w_{jl}|} \cdot w_{oj}}{\sum_{k=1}^{n_{inputs}} \left( \sum_{j=1}^{n_{hidden}} \frac{w_{jk}}{\sum_{l=1}^{n_{inputs}} |w_{jl}|} \cdot w_{oj} \right)} \quad (8)$$

عصبی در مسائل پیش‌بینی است. به منظور بررسی دقیق‌تر میزان تأثیر هر یک از پارامترهای ورودی بر مقاومت بتن، آنالیز حساسیت نیز به عنوان بخشی از این پژوهش انجام شده است. در این آنالیز از روش میلن با استفاده از وزن‌های تنظیم شده و به‌دست آمده از شبکه عصبی ایده‌آل استفاده شد. نتایج این آنالیز نشان داد که از میان تمامی پارامترهای ورودی، سیمان بیشترین تأثیر را بر مقاومت نهایی نمونه‌های بتنی خودتراکم دارد. این یافته اهمیت توجه به نوع و مقدار سیمان را در طراحی مخلوط‌های بتنی خودتراکم برجسته می‌کند و نشان می‌دهد که تغییرات کوچک در این پارامتر می‌تواند به طور قابل توجهی بر خواص مکانیکی بتن تأثیر بگذارد.

یکی از نکات کلیدی در فرایند مدل‌سازی شبکه‌های عصبی مصنوعی، انتخاب شبکه‌ای است که با داشتن تعداد نوروهای کمتر بتواند دقت بالاتری ارائه دهد، چرا که شبکه‌های پیچیده با تعداد نوروهای بیشتر، گاهی ممکن است منجر به بیش‌برازش (Overfitting) شوند و کارایی شبکه را کاهش دهند. در این مقاله، شبکه عصبی پیشنهادی بهینه از نوع انتشار برگشتی با ساختار ۱-۶-۶ است. این ساختار شامل یک لایه ورودی، دو لایه پنهان و یک لایه خروجی می‌باشد. تابع انتقال در لایه پنهان از نوع تانژانت سیگموئید و در لایه خروجی از نوع خطی ساده انتخاب شده است. همچنین تابع عملکرد خطی میانگین مجموع مربعات خطا در نظر گرفته شده که یکی از روش‌های پرکاربرد برای ارزیابی عملکرد شبکه‌های

## References

- [1] Wu X, Ghaboussi J, Garrett Jr JH. Use of neural networks in detection of structural damage. *Computers & structures*. 1992 Feb 17; 42(4): 649-659. doi: 10.1016/0045-7949(92)90132-J
- [2] Pal C, Hagiwara I, Kayaba N, Morishita S. Dynamic system identification by neural network: a new, fast learning method based on error back propagation. *Journal of intelligent material systems and structures*. 1994 Jan; 5(1): 127-135. doi: 10.1177/1045389X9400500116
- [3] Ghaboussi J, Garrett Jr JH, Wu X. Knowledge-based modeling of material behavior with neural networks. *Journal of engineering mechanics*. 1991 Jan; 117(1): 132-153. doi: 10.1061/(ASCE)0733-9399(1991)117:1(132)
- [4] Ranjithan S, Eheart JW, Garrett Jr JH. Neural network-based screening for groundwater reclamation under uncertainty. *Water Resources Research*. 1993 Mar; 29(3): 563-574. doi: 10.1029/92WR02129
- [5] Adeli H, Park HS. A neural dynamics model for structural optimization-theory. *Computers & structures*. 1995 Nov 3; 57(3): 383-390. doi: 10.1016/0045-7949(95)00048-L
- [6] El-Chabib H, Nehdi M, Sonebi M. Artificial intelligence model for flowable concrete mixtures used in underwater construction and repair. *Materials Journal*. 2003 Mar 1; 100(2): 165-173.
- [7] Diab AM, Elyamany HE, Abd Elmoaty M, Shalan AH. Prediction of concrete compressive strength due to long term sulfate attack using neural network. *Alexandria Engineering Journal*. 2014 Sep 1; 53(3): 627-642. doi: 10.1016/j.aej.2014.04.002
- [8] Ozawa K, Maekawa K, Okamura H. Development of the high performance concrete, *Proc. Jpn. Concr. Inst*. 1989; 11: 699-704.
- [9] Fernandez-Gomez J, Landsberger GA. Evaluation of shrinkage prediction models for self-consolidating concrete. *ACI Materials Journal*. 2007 Sep 1; 104(5): 464-473.
- [10] Fakharian P, Nouri Y, Ghanizadeh AR, Jahanshahi FS, Naderpour H, Kheyroddin A. Bond strength prediction of externally bonded reinforcement on groove method (EBROG) using MARS-POA. *Composite Structures*. 2024 Dec 1; 349: 118532. doi: 10.1016/j.compstruct.2024.118532
- [11] Shahmansouri AA, Akbarzadeh Bengar H, Jafari A. Modeling the lateral behavior of concrete rocking walls using multi-objective neural network. *Journal of Concrete Structures and Materials*. 2020 Nov 21; 5(2): 110-128. doi: 10.30478/jcsm.2021.272480.1192
- [12] Shahmansouri AA, Bengar HA, AzariJafari H. Life cycle assessment of eco-friendly concrete mixtures incorporating natural zeolite in sulfate-aggressive environment. *Construction and Building Materials*. 2021 Jan 25; 268: 121136. doi: 10.1016/j.conbuildmat.2020.121136
- [13] Shahmansouri AA, Akbarzadeh Bengar H, Ghanbari S. Experimental investigation and predictive modeling of compressive strength of pozzolanic geopolymer concrete using gene expression programming. *J Concr Struct Mater* 2020; 5: 92-117. doi: 10.30478/jcsm.2020.214158.1141

- [14] Nematzadeh M, Shahmansouri AA, Zabihi R. Innovative models for predicting post-fire bond behavior of steel rebar embedded in steel fiber reinforced rubberized concrete using soft computing methods. *InStructures* 2021 Jun 1; 31: 1141-1162. doi: **10.1016/j.istruc.2021.02.015**
- [15] Naderpour H, Noormohammadi E, Fakharian P. Prediction of punching shear capacity of RC slabs using support vector machine. *Concrete Research*. 2017 Jul 23; 10(2): 95-107. doi: **10.22124/JCR.2017.2417**
- [16] Hosseini P, Kaveh A, Naghian A. Development and optimization of self-compacting concrete mixes: Insights from artificial neural networks and computational approaches. *Int. J. Optim. Civil Eng*. 2023 Oct 10; 13(4): 457-476. doi: **10.22068/ijoce.2023.13.4.566**
- [17] Hosseini P, Kaveh A, Naghian A. The use of artificial neural networks and metaheuristic algorithms to optimize the compressive strength of concrete. *Int. J. Optim. Civil Eng*. 2023 Jul 10; 13(3): 327-338. doi: **10.22068/ijoce.2023.13.3.558**
- [18] Naderpour H, Fakharian P. Predicting the Torsional Strength of Reinforced Concrete Beams Strengthened with FRP Sheets in terms of Artificial Neural Networks. *J Struct Constr Eng* 2018; 5(1): 20-35. doi: **10.22065/jsce.2017.70668.1023** [In Persian]
- [19] Siddique R, Aggarwal P, Aggarwal Y. Prediction of compressive strength of self-compacting concrete containing bottom ash using artificial neural networks. *Advances in engineering software*. 2011 Oct 1; 42(10): 780-786. doi: **10.1016/j.advengsoft.2011.05.016**
- [20] Tavakoli HR, Omran OL, Shiade MF, Kutanaei SS. Prediction of combined effects of fibers and nanosilica on the mechanical properties of self-compacting concrete using artificial neural network. *Latin American Journal of Solids and Structures*. 2014; 11: 1906-1923. doi: **10.1590/S1679-78252014001100002**
- [21] Naderpour H, Rafiean AH, Fakharian P. Compressive strength prediction of environmentally friendly concrete using artificial neural networks. *Journal of building engineering*. 2018 Mar 1; 16: 213-219. doi: **10.1016/j.jobee.2018.01.007**
- [22] Naderpour H, Nagai K, Fakharian P, Haji M. Innovative models for prediction of compressive strength of FRP-confined circular reinforced concrete columns using soft computing methods. *Composite Structures*. 2019 May 1; 215: 69-84. doi: **10.1016/j.compstruct.2019.02.048**
- [23] Rezazadeh Eidgahee D, Rafiean AH, Haddad A. A novel formulation for the compressive strength of IBP-based geopolymer stabilized clayey soils using ANN and GMDH-NN approaches. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*. 2020 Mar; 44(1): 219-229. doi: **10.1007/s40996-019-00263-1**
- [24] Naderpour H, Eidgahee DR, Fakharian P, Rafiean AH, Kalantari SM. A new proposed approach for moment capacity estimation of ferrocement members using Group Method of Data Handling. *Engineering Science and Technology, an International Journal*. 2020 Apr 1; 23(2): 382-391. doi: **10.1016/j.jestch.2019.05.013**
- [25] Zhu W, Gibbs JC. Use of different limestone and chalk powders in self-compacting concrete. *Cement and Concrete Research*. 2005 Aug 1; 35(8): 1457-1462. doi: **10.1016/j.cemconres.2004.07.001**
- [26] Heirman G, Vandewalle L, Van Gemert D, Boel V, Audenaert K, De Schutter G, Desmet B, Vantomme J. Time-dependent deformations of limestone powder type self-compacting concrete. *Engineering Structures*. 2008 Oct 1; 30(10): 2945-2956. doi: **10.1016/j.engstruct.2008.04.009**
- [27] F Felekoglu B. Utilisation of high volumes of limestone quarry wastes in concrete industry (self-compacting concrete case). *Resources, Conservation and Recycling*. 2007 Oct 1; 51(4): 770-791. doi: **10.1016/j.resconrec.2006.12.004**
- [28] Bosiljkov VB. SCC mixes with poorly graded aggregate and high volume of limestone filler. *Cement and Concrete Research*. 2003 Sep 1; 33(9): 1279-1286. doi: **10.1016/S0008-8846(03)00013-9**
- [29] Sonebi M. Medium strength self-compacting concrete containing fly ash: Modelling using factorial experimental plans. *Cement and Concrete research*. 2004 Jul 1; 34(7): 1199-1208. doi: **10.1016/j.cemconres.2003.12.022**
- [30] Takada K, Tangtermsirikul S. *Self-Compacting Concrete-State-of-the-Art Report of RILEM TC 174-SCC*. Edited by Å. Skarendahland, Ö. Petersson, RILEM Pub. SARL. 2000:25-39.
- [31] Haykin S, Network N. A comprehensive foundation. *Neural networks*. 2004 Feb;2(2004):41.
- [32] Yeh IC. Modeling of strength of high-performance concrete using artificial neural networks. *Cement and Concrete research*. 1998 Dec 1; 28(12): 1797-1808. doi: **10.1016/S0008-8846(98)00165-3**
- [33] Lai S, Serra M. Concrete strength prediction by means of neural network. *Construction and Building Materials*. 1997 Mar 1; 11(2): 93-98. doi: **10.1016/S0950-0618(97)00007-X**
- [34] Nehdi M, El Chabib H, El Naggar MH. Predicting performance of self-compacting concrete mixtures using artificial neural networks. *Materials Journal*. 2001 Sep 1; 98(5): 394-401. doi: **10.14359/10729**
- [35] Sharbatdar MK, Abbasi M, Fakharian P. Improving the properties of self-compacted concrete with using combined silica fume and metakaolin. *Periodica Polytechnica Civil Engineering*. 2020 Apr 14; 64(2): 535-544. doi: **10.3311/PPci.11463**

- [36] Begum SJ, Anjaneyulu PJ, Ratnam MK. A study on effect of steel fiber in fly ash based self compacting concrete. *International Journal for Innovative Research in Science & Technology*. 2018; 5(1): 95-99.
- [37] Ghazy MF, Elaty MA, Zalhaf NM. Prediction of temperature distribution and fire resistance of RC slab using artificial neural networks. *International Journal of Structural Engineering*. 2021; 11(1): 1-8. **doi: 10.1504/IJSTRUCTE.2021.112084**
- [38] Tavares DS, Ribeiro DA, Junior TY, Lacerda WS, Tiradentes ET, Teixeira RG, Garcia HV. Use of artificial neural networks to predict concrete compression strength. *Brazilian Journal of Development*. 2020 Jul 2; 6(7): 42815-42826. **doi: 10.34117/bjdv6n7-050**
- [39] Dias MP, Inácio MJ, de Carvalho Júnior ÁB. Aplicação de redes neurais artificiais para previsão da incidência solar na cidade de Belo Horizonte. *Brazilian Journal of Development*. 2020 Jul 29; 6(7): 52603-52615. **doi: 10.34117/bjdv6n7-780**
- [40] Keshavarz Z, Torkian H. Application of ANN and ANFIS models in determining compressive strength of concrete. *Journal of Soft Computing in Civil Engineering*. 2018 Jan 1; 2(1): 62-70. **doi: 10.22115/scce.2018.51114**
- [41] Uysal M, Tanyildizi H. Predicting the core compressive strength of self-compacting concrete (SCC) mixtures with mineral additives using artificial neural network. *Construction and Building Materials*. 2011 Nov 1; 25(11): 4105-4111. **doi: 10.1016/j.conbuildmat.2010.11.108**
- [42] Mashhadban H, Kutanaei SS, Sayarnejad MA. Prediction and modeling of mechanical properties in fiber reinforced self-compacting concrete using particle swarm optimization algorithm and artificial neural network. *Construction and Building Materials*. 2016 Aug 30; 119: 277-287. **doi: 10.1016/j.conbuildmat.2016.05.034**
- [43] Uysal M, Tanyildizi H. Estimation of compressive strength of self compacting concrete containing polypropylene fiber and mineral additives exposed to high temperature using artificial neural network. *Construction and Building Materials*. 2012 Feb 1; 27(1): 404-414. **doi: 10.1016/j.conbuildmat.2011.07.028**
- [44] Asteris PG, Kolovos KG, Douvika MG, Roinos K. Prediction of self-compacting concrete strength using artificial neural networks. *European Journal of Environmental and Civil Engineering*. 2016 Nov 15; 20(sup1): s102-s122. **doi: 10.1080/19648189.2016.1246693**
- [45] Alavi SA, Naderpour H, Fakharian P. An approach for estimating the rotation capacity of wide flange beams using bayesian regularized artificial neural networks (BRANN). *Modares Civil Engineering journal*. 2018 Nov 10; 18(4): 157-169. [In Persian]
- [46] Mohammed A, Rafiq S, Sihag P, Kurda R, Mahmood W, Ghafor K, Sarwar W. ANN, M5P-tree and nonlinear regression approaches with statistical evaluations to predict the compressive strength of cement-based mortar modified with fly ash. *Journal of Materials Research and Technology*. 2020 Nov 1; 9(6): 12416-12427. **doi: 10.1016/j.jmrt.2020.08.083**
- [47] Singh SK, Pranathi BM, Kirthika SK. Prediction of particle packing density of alternative fine aggregates by artificial neural network applications. *Journal of The Institution of Engineers (India): Series A*. 2020 Mar; 101: 127-140. **doi: 10.1007/s40030-019-00412-9**
- [48] Mohammed A, Rafiq S, Mahmood W, Al-Darkazalir H, Noaman R, Qadir W, Ghafor K. Artificial Neural Network and NLR techniques to predict the rheological properties and compression strength of cement past modified with nanoclay. *Ain Shams Engineering Journal*. 2021 Jun 1; 12(2): 1313-1328. **doi: 10.1016/j.asej.2020.07.033**
- [49] Ramkumar KB, Kannan Rajkumar PR, Noor Ahmmad S, Jegan M. A review on performance of self-compacting concrete-use of mineral admixtures and steel fibres with artificial neural network application. *Constr Build Mater* 2020; 261: 120215. **doi: 10.1016/j.conbuildmat.2020.120215**
- [50] Siddique R. Properties of self-compacting concrete containing class F fly ash. *Materials & Design*. 2011 Mar 1; 32(3): 1501-1507. **doi: 10.1016/j.matdes.2010.08.043**
- [51] Bouzoubaâ N, Lachemi M. Self-compacting concrete incorporating high volumes of class F fly ash: Preliminary results. *Cement and concrete research*. 2001 Mar 1; 31(3): 413-420. **doi: 10.1016/S0008-8846(00)00504-4**
- [52] Dinakar P, Babu KG, Santhanam M. Mechanical properties of high-volume fly ash self-compacting concrete mixtures. *Structural concrete*. 2008 Jun; 9(2): 109-116. **doi: 10.1680/stco.2008.9.2.109**
- [53] Nehdi M, Pardhan M, Koshowski S. Durability of self-consolidating concrete incorporating high-volume replacement composite cements. *Cement and Concrete Research*. 2004 Nov 1; 34(11): 2103-2112. **doi: 10.1016/j.cemconres.2004.03.018**
- [54] Uysal M, Sumer M. Performance of self-compacting concrete containing different mineral admixtures. *Construction and Building materials*. 2011 Nov 1; 25(11): 4112-4120. **doi: 10.1016/j.conbuildmat.2011.04.032**
- [55] Venkatakrishnaiah R, Sakthivel G. Bulk utilization of flyash in self compacting concrete. *KSCE Journal of Civil Engineering*. 2015 Nov; 19: 2116-2120. **doi: 10.1007/s12205-015-0706-4**
- [56] Hemalatha T, Ramaswamy A, Chandra Kishen JM. Micromechanical analysis of self compacting concrete.

- Materials and Structures. 2015 Nov; 48: 3719-3734. doi: **10.1617/s11527-014-0435-z**
- [57] Bui VK, Akkaya Y, Shah SP. Rheological model for self-consolidating concrete. Materials Journal. 2002 Nov 1; 99(6): 549-559.
- [58] Douglas RP, Bui VK, Akkaya Y, Shah SP. Properties of Self-consolidating concrete containing class f fly ash: With a Verification of the minimum paste volume method. Special Publication. 2006 Mar 9; 233: 45-64.
- [59] Liu M. Self-compacting concrete with different levels of pulverized fuel ash. Construction and Building Materials. 2010 Jul 1; 24(7): 1245-1252. doi: **10.1016/j.conbuildmat.2009.12.012**
- [60] Bingöl AF, Tohumcu İ. Effects of different curing regimes on the compressive strength properties of self compacting concrete incorporating fly ash and silica fume. Materials & Design. 2013 Oct 1; 51: 12-18. doi: **10.1016/j.matdes.2013.03.106**
- [61] Barbhuiya S. Effects of fly ash and dolomite powder on the properties of self-compacting concrete. Construction and Building Materials. 2011 Aug 1; 25(8): 3301-3305. doi: **10.1016/j.conbuildmat.2011.03.018**
- [62] Sukumar B, Nagamani K, Raghavan RS. Evaluation of strength at early ages of self-compacting concrete with high volume fly ash. Construction and Building Materials. 2008 Jul 1; 22(7): 1394-1401. doi: **10.1016/j.conbuildmat.2007.04.005**
- [63] Sun ZJ, Duan WW, Tian ML, Fang YF. Experimental research on self-compacting concrete with different mixture ratio of fly ash. Advanced materials research. 2011 Jul 6; 236: 490-495. doi: **10.4028/www.scientific.net/AMR.236-238.490**
- [64] Dhiyaneshwaran S, Ramanathan P, Baskar I, Venkatasubramani R. Study on durability characteristics of self-compacting concrete with fly ash. Jordan journal of civil engineering. 2013 May; 7(3): 342-353.
- [65] Pathak N, Siddique R. Properties of self-compacting-concrete containing fly ash subjected to elevated temperatures. Construction and building materials. 2012 May 1; 30: 274-280. doi: **10.1016/j.conbuildmat.2011.11.010**
- [66] Gesoğlu M, Güneyisi E, Özbay E. Properties of self-compacting concretes made with binary, ternary, and quaternary cementitious blends of fly ash, blast furnace slag, and silica fume. Construction and building materials. 2009 May 1; 23(5): 1847-1854. doi: **10.1016/j.conbuildmat.2008.09.015**
- [67] Güneyisi E, Gesoğlu M, Özbay E. Strength and drying shrinkage properties of self-compacting concretes incorporating multi-system blended mineral admixtures. Construction and Building Materials. 2010 Oct 1; 24(10): 1878-1887. doi: **10.1016/j.conbuildmat.2010.04.015**
- [68] Dinakar P. Design of self-compacting concrete with fly ash. Magazine of Concrete Research. 2012 May; 64(5): 401-409. doi: **10.1680/macr.10.00167**
- [69] Patel R, Hossain KM, Shehata M, Bouzoubaa N, Lachemi M. Development of statistical models for mixture design of high-volume fly ash self-consolidating concrete. Materials Journal. 2004 Jul 1; 101(4): 294-302.
- [70] Jawahar JG, Sashidhar C, Reddy IR, Peter JA. Micro and macrolevel properties of fly ash blended self compacting concrete. Materials & Design (1980-2015). 2013 Apr 1; 46: 696-705. doi: **10.1016/j.matdes.2012.11.027**
- [71] Boel V, Audenaert K, De Schutter G, Heirman G, Vandewalle L, Desmet B, Vantomme J. Transport properties of self compacting concrete with limestone filler or fly ash. Materials and structures. 2007 Jun; 40: 507-516. doi: **10.1617/s11527-006-9159-z**
- [72] Jalal M, Mansouri E. Effects of fly ash and cement content on rheological, mechanical, and transport properties of high-performance self-compacting concrete. Science and Engineering of Composite Materials. 2012 Dec 1; 19(4): 393-405. doi: **10.1515/secm-2012-0052**
- [73] Milne L. Feature Selection Using Neural Networks with Contribution Measures. Aust Conf Artif Intell 1995: 1-8.