



تعیین طرح اختلاط بهینه بتن خودتراکم با استفاده از الگوریتم هیبریدی شبکه عصبی مصنوعی - بهینه سازی ازدحام ذرات ANN-PSO

نوید دیلمی معزی*^۱، حسین رزاقی^۲

۱- دانشجوی کارشناسی ارشد عمران - سازه، گروه عمران، دانشکده فنی و مهندسی، موسسه آموزش عالی

پویندگان دانش، چالوس، ایران

۲- استادیار موسسه آموزش عالی پویندگان دانش، گروه عمران، دانشکده فنی و مهندسی، چالوس، ایران

*naviddeilami@gmail.com

ارسال: فروردین ماه ۱۴۰۳ پذیرش: خرداد ماه ۱۴۰۳

چکیده

در این مقاله یک الگوریتم هیبریدی جدید بر اساس ترکیب روش شبکه عصبی مصنوعی پیشخور و روش بهینه سازی ازدحام ذرات (ANN-PSO) برای تخمین مقادیر مصالح مورد استفاده در طرح اختلاط بتن خودتراکم که یک مقدار مشخص از مقاومت فشاری ۲۸ روزه را دارا باشد، ارائه داده می شود. مصالح مورد استفاده در بتن خودتراکم شامل آب، سیمان، شن، ماسه، پودر سنگ، فوق روان کننده و میکروسیلیس است. شبکه عصبی مورد استفاده در این الگوریتم، شبکه عصبی پیشخور دو لایه است. در این الگوریتم، روش بهینه سازی ازدحام ذرات وظیفه تعریف جمعیت های اولیه (طرح های اختلاط اولیه) و تعیین بهترین جمعیت و بهینه کردن آن با تکرار بعده دارد و وظیفه شبکه عصبی مصنوعی پیش بینی مقدار مقاومت فشاری بتن با توجه به جمعیت بهینه شده در هر تکرار با روش بهینه سازی ازدحام ذرات می باشد.

در این تحقیق از ۵۶ طرح اختلاط بتن خودتراکم استفاده شده است. بعد از آموزش الگوریتم با طرح های اختلاط بتن خودتراکم و نیز مقادیر مقاومت فشاری ۲۸ روزه متناظر با آنها، مقدار مقاومت فشاری ۲۸ روزه یکی از طرح های اختلاط را بعنوان ورودی به الگوریتم معرفی شد. الگوریتم با دقت قابل قبولی مقادیر مصالح بتن خودتراکم متناظر با این مقاومت فشاری را پیش بینی نمود، بطوریکه خطای بین مقاومت فشاری پیش بینی شده برای مصالح تخمین زده شده و مقاومت فشاری اولیه ۰/۰۲ مگاپاسکال است. با توجه به نتایج بدست آمده می توان گفت که الگوریتم پیشنهادی ANN-PSO ابزاری قدرتمند برای تخمین مقادیر طرح اختلاط بتن خودتراکم برای یک مقدار مشخص از مقاومت فشاری ۲۸ روزه است.

کلمات کلیدی: الگوریتم هیبریدی، بتن خودتراکم، بهینه سازی ازدحام ذرات، شبکه عصبی مصنوعی.

۱- مقدمه

بتن مهمترین مصالح ساختمانی است که بیشترین کاربرد را در ساخت سازه های مختلف از جمله ساختمانهای مسکونی، سازه های زیربنایی مانند پل، سد، راه، ابنیه، اسکله، بند و سایر سازه ها دارد. مقاومت فشاری بتن یکی از مشخصات مهم مکانیکی بتن است که متاثر از طرح اختلاط بتن می باشد. امروزه استفاده از روش های هوشمند برای تخمین و مدلسازی مقاومت فشاری بتن از مباحثی است که مورد توجه محققین می باشد.

انواع مختلفی از مدل‌های محاسباتی تحت عنوان کلی شبکه‌های عصبی مصنوعی معرفی شده‌اند که هر یک برای دسته‌ای از کاربردها قابل استفاده هستند و در هر کدام از وجه مشخصی از قابلیت‌ها و خصوصیات مغز انسان الهام گرفته شده است. در همه این مدل‌ها، یک ساختار ریاضی در نظر گرفته شده است که البته به صورت گرافیکی هم قابل نمایش دادن است و یک سری پارامترها و پیچ‌های تنظیم دارد. شبکه‌ی عصبی یا شبکه عصبی مصنوعی به مجموعه‌ای از یاخته‌ها (سلول‌های عصبی، نورون) می‌گویند که در یک معماری ویژه‌ای برای حل مسأله‌ای خاص به هم متصل شده‌اند و هر کدام محاسبات ساده‌ای به انجام می‌رسانند.

در بسیاری پروژه‌ها، نمی‌توان مقاومت فشاری بتن را در زمان بتن ریزی تعیین نمود، چرا که این کار مستلزم نمونه برداری و نگهداری نمونه‌ها در محیط مرطوب برای مدت زمان‌های مشخص مانند ۷، ۲۸ روز یا بیشتر است. بنابراین استفاده از مدل‌ها و روش‌های محاسباتی مانند شبکه عصبی به عنوان ابزاری هوشمند می‌تواند نقش موثری در تخمین مقاومت فشاری بتن با توجه به آموزش‌های قبلی و یادگیری بدست آمده در طول آموزش بر اساس طرح‌های اختلاط مختلف ایفا نمایند.

الگوریتم PSO یکی از الگوریتم‌های تکامل یافته هوش مصنوعی، مبتنی بر هوش جمعی است که بر اساس روند تکاملی ذرات موجود در یک دسته به منظور رسیدن به هدف بهینه طراحی شده است. روش PSO در سال ۱۹۹۵ توسط کندی و ابرهات ارائه داده شد [۱]. در این مقاله ما الگوریتم هیبریدی معرفی می‌نماییم که از PSO برای تعیین مقادیر مصالح طرح اختلاط و از شبکه عصبی برای تعیین مقاومت فشاری متناظر با مقادیر طرح اختلاط بدست آمده از PSO استفاده می‌شود. با این الگوریتم جدید می‌توان برای هر مقدار از مقاومت فشاری که مدنظر است، طرح اختلاط آن را تعیین نماییم.

تحقیقات در زمینه بتن و استفاده از روش‌های هوش مصنوعی از جمله استفاده از شبکه‌های عصبی مصنوعی و نیز بهینه‌سازی ازدحام ذرات به دلیل اهمیت زیادی که دارند، در منابع مختلف بوفور یافت می‌شود. از جمله این تحقیقات می‌توانیم به مواردی که در ادامه ذکر شده است، اشاره نمود. دنگ و همکاران (۲۰۱۸) از شبکه عصبی پیشخور عمیق برای پیش‌بینی مقاومت فشاری بتن استفاده کرده‌اند [۲]. الشیری و همکاران (۲۰۰۹) با استفاده از شبکه عصبی و انجام آزمایشات روی نمونه‌های ۳، ۷، ۱۴ و ۲۸ روزه و با استفاده از ورودی‌های نسبت آب به سیمان، لیکا، سوپر پلاستیسیر، درشت دانه سبک و ریز دانه سبک توانستند تخمین مناسبی از مقاومت بتن سبک ارائه دهند. نتایج آزمایش‌های آنها نشان داد که شبکه عصبی دارای قدرت بالایی در تخمین مقاومت فشاری بتن سبک سازه‌ای می‌باشد [۳]. چوپرا و همکاران (۲۰۱۶) پس از ساخت نمونه‌های مقاومت فشاری ۲۸، ۵۶ و ۹۱ روزه، از شبکه‌های عصبی و برنامه نویسی ژنتیکی برای ساخت مدل‌های پیش‌بینی خود استفاده نمودند [۴] و آگمر و همکاران (۲۰۲۱) از شبکه عصبی مصنوعی برای پیش‌بینی مقاومت فشاری و کششی بتن حاوی زئولیت استفاده نمودند [۵]. غنی زاده و همکاران (۱۳۹۵) از شبکه عصبی مصنوعی بهینه شده با الگوریتم ازدحام ذرات برای پیش‌بینی مدول الاستیسیته بتن استفاده نمودند [۶]. دهقانی و همکاران (۱۳۹۷) از الگوریتم بهینه‌سازی ازدحام ذرات PSO برای پیش‌بینی مقاومت فشاری بتن استفاده نمودند [۷]. املشی و همکاران (۲۰۲۰) یک الگوریتم یادگیری ماشین سه هیبریدی (سه ترکیب متفاوت) برای پیش‌بینی خواص مکانیکی نمونه‌های بتن پلاستیک با شکل هندسی مختلف توسعه دادند. الگوریتم استفاده شده شامل شبکه عصبی مصنوعی ANN، ماشین بردار پشتیبان SVM و سیستم استنتاج فازی عصبی تطبیقی ANFIS که با استفاده از بهینه‌سازی ازدحام ذرات PSO بهینه شده است که از آنها برای تخمین مقاومت فشاری و کششی شکاف خوردگی بتن پلاستیک استفاده شده است [۸].

۲- بتن خودتراکم

بتن خودتراکم به بتنی اطلاق می‌شود که بخاطر روانی و سیالیت زیاد، بدون نیاز به متراکم کردن یا ویبراسیون، به راحتی شکل هر قالبی را بدون میله گرد و یا هر میزان میله گرد و آرماتور، بطور کامل بخود گرفته و قالب را کاملاً پر کرده و بتنی با تراکم تقریباً ۱۰۰ درصد ایجاد نماید. بنابراین می‌توان گفت که بتن خودتراکم یا خودمتراکم مخلوطی (ملائی) با روانی و قابلیت شکل‌پذیری بسیار بالا است که بدون ایجاد جدایش بین دانه‌های تشکیل دهنده آن، می‌تواند بتن سخت یک دست و کاملاً فشرده و متراکم با سطوحی کاملاً صاف ارائه نماید. در این تحقیق از ۵۶ طرح اختلاط‌های بتن خودتراکم با نسبت‌های آب به سیمان ۰/۲۵، ۰/۳، ۰/۳۵،

۰/۴، ۰/۴۵، ۰/۵ و ۰/۵۵ مطابق جدول ۱ استفاده شده است. مقاومت فشاری ۲۸ روزه متناظر با تمامی طرح اختلاطها در جدول ۲ آورده شده است. در این طرح‌های اختلاط، میکروسیلیس جایگزین سیمان و فوق روان کننده جایگزین آب در طرح اختلاط می‌شود.

جدول ۱- طرح‌های اختلاط بتن خود تراکم

شماره طرح مخلوط	نسبت آب به سیمان w/c	مقدار ماسه kg	مقدار شن kg	مقدار پودر سنگ kg	مقدار فوق روان کننده (درصد وزن سیمان)	مقدار فوق روان کننده kg	مقدار میکروسیلیس (درصد وزن سیمان)	مقدار سیمان kg	مقدار آب kg
1	0.25	614	901	160	0.4	2.4	0	600	150
2	0.25	614	901	160	0.4	2.16	10	540	150
3	0.25	614	901	160	0.8	4.8	0	600	150
4	0.25	614	901	160	0.8	4.32	10	540	150
5	0.25	614	901	160	1.2	7.2	0	600	150
6	0.25	614	901	160	1.2	6.48	10	540	150
7	0.25	614	901	160	1.6	9.6	0	600	150
8	0.25	614	901	160	1.6	8.64	10	540	150
9	0.3	641	884	157.5	0.4	2.2	0	550	165
10	0.3	641	884	157.5	0.4	1.98	10	495	165
11	0.3	641	884	157.5	0.8	4.4	0	550	165
12	0.3	641	884	157.5	0.8	3.96	10	495	165
13	0.3	641	884	157.5	1.2	6.6	0	550	165
14	0.3	641	884	157.5	1.2	5.94	10	495	165
15	0.3	641	884	157.5	1.6	8.8	0	550	165
16	0.3	641	884	157.5	1.6	7.92	10	495	165
17	0.35	668	867	155	0.4	2	0	500	175
18	0.35	668	867	155	0.4	1.8	10	450	175
19	0.35	668	867	155	0.8	4	0	500	175
20	0.35	668	867	155	0.8	3.6	10	450	175
21	0.35	668	867	155	1.2	6	0	500	175
22	0.35	668	867	155	1.2	5.4	10	450	175
23	0.35	668	867	155	1.6	8	0	500	175
24	0.35	668	867	155	1.6	7.2	10	450	175
25	0.4	695	850	152.5	0.4	1.8	0	450	180
26	0.4	695	850	152.5	0.4	1.62	10	405	180
27	0.4	695	850	152.5	0.8	3.6	0	450	180
28	0.4	695	850	152.5	0.8	3.24	10	405	180
29	0.4	695	850	152.5	1.2	5.4	0	450	180
30	0.4	695	850	152.5	1.2	4.86	10	405	180
31	0.4	695	850	152.5	1.6	7.2	0	450	180
32	0.4	695	850	152.5	1.6	6.48	10	405	180
33	0.45	722	833	150	0.4	1.6	0	400	180
34	0.45	722	833	150	0.4	1.44	10	360	180
35	0.45	722	833	150	0.8	3.2	0	400	180
36	0.45	722	833	150	0.8	2.88	10	360	180
37	0.45	722	833	150	1.2	4.8	0	400	180
38	0.45	722	833	150	1.2	4.32	10	360	180
39	0.45	722	833	150	1.6	6.4	0	400	180
40	0.45	722	833	150	1.6	5.76	10	360	180
41	0.5	749	816	147.5	0.4	1.4	0	350	175
42	0.5	749	816	147.5	0.4	1.256	10	314	175
43	0.5	749	816	147.5	0.8	2.8	0	350	175
44	0.5	749	816	147.5	0.8	2.512	10	314	175
45	0.5	749	816	147.5	1.2	4.2	0	350	175
46	0.5	749	816	147.5	1.2	3.768	10	314	175
47	0.5	749	816	147.5	1.6	5.6	0	350	175
48	0.5	749	816	147.5	1.6	5.024	10	314	175
49	0.55	776	799	145	0.4	1.2	0	300	165
50	0.55	776	799	145	0.4	1.08	10	270	165
51	0.55	776	799	145	0.8	2.4	0	300	165

52	0.55	776	799	145	0.8	2.16	10	270	165
53	0.55	776	799	145	1.2	3.6	0	300	165
54	0.55	776	799	145	1.2	3.24	10	270	165
55	0.55	776	799	145	1.6	4.8	0	300	165
56	0.55	776	799	145	1.6	4.32	10	270	165

جدول ۲- مقادیر مقاومت فشاری ۲۸ روزه بدست آمده در آزمایشگاه برای نمونه های بتن خودتراکم

شماره طرح مخلوط	مقاومت فشاری ۲۸ روزه Mpa	شماره طرح مخلوط	مقاومت فشاری ۲۸ روزه Mpa
1	57.43	29	52.63
2	55.28	30	61.27
3	50.74	31	54.85
4	48.61	32	56.31
5	53.18	33	55.8
6	56.58	34	63.85
7	54.39	35	56.99
8	53.72	36	55.22
9	68.73	37	48.31
10	67.32	38	54.14
11	61.25	39	52.71
12	62.17	40	58.15
13	60.38	41	53.17
14	69.86	42	59.54
15	63.21	43	54.48
16	61.47	44	54.29
17	67.34	45	49.36
18	64.82	46	53.72
19	57.27	47	52.64
20	58.07	48	56.29
21	57.92	49	49.14
22	70.75	50	52.32
23	63.13	51	50.85
24	61.28	52	48.45
25	63.36	53	44.81
26	61.24	54	47.63
27	56.78	55	45.96
28	57.2	56	48.57

۳- شبکه عصبی پیشخور

شبکه های عصبی پیشخور به علت سهولت کاربرد و توانایی زیاد به طور گسترده در حل مسائل مختلف از قبیل تشخیص الگو کاربرد دارند. این شبکه از یک سری نرون یا اجزای پردازشگر تشکیل شده، که هر نرون شامل برداری از وزن های قابل تنظیم است. وظیفه هر نرون، نگاشت بردار ورودی بر روی بردار خروجی است [۹]. جریان داده ها از لایه اول یا لایه ورودی شروع شده و وزن ها عمدتاً با حداقل سازی اختلاف بین خروجی های شبکه و خروجی های مطلوب، محاسبه می شوند. در شبکه عصبی به فرآیند یافتن وزن های بهینه، آموزش شبکه و مجموعه داده های ورودی -خروجی، داده های آموزش گفته می شود. هدف از آموزش شبکه، ایجاد تناظر یک به یک بین الگوی ورودی و خروجی معلوم، در مساله مورد نظر است.


در این مقاله، از الگوریتم پس انتشار (Back Propagation) خطا برای آموزش شبکه استفاده شده است. رایج ترین تکنیک آموزش نظارتی، الگوریتم پس انتشار خطا است. اگر بردارهای x با N عضو، ورودی شبکه و بردارهای y با M عضو، خروجی مطلوب شبکه باشد، می خواهیم با Q داده آموزشی، یک شبکه دولایه ای را آموزش دهیم. وقتی x^q (q امین بردار ورودی) به یکی از نرونهای لایه مخفی می رسد، پاسخ نرون به صورت زیر خواهد بود [۹]:

$$a_j^q = f^h \left(\sum_{i=1}^N W_{ji}^h x_i^q + b_j \right) \quad (1)$$

در این رابطه a_j^q پاسخ ژامین نرون در لایه مخفی به q امین بردار ورودی (بالانویس h معرف لایه مخفی)، W_{ji}^h وزن نرون j ام، b_j بایاس و f^h تابع تحریک است. از توابع تحریک متعددی می توان استفاده نمود که در اینجا از تابع حلقوی تانژانت هایپربولیک (sigmoid) با رابطه زیر در لایه مخفی استفاده شده است:

$$f(x) = \left(\frac{2}{1 + e^{-2x}} \right) - 1 \quad (2)$$

این تابع از نظر ریاضیات بسیار نزدیک به $\tanh(x)$ می باشد. در این رابطه در $x=0$ مقدار تابع صفر می باشد (شکل ۱).



شکل ۱- تابع تحریک حلقوی (سیگموئید تانژانت)

برای یادگیری وزن های یک شبکه چند لایه از روش Back Propagation استفاده می شود. در این روش با استفاده از gradient descent سعی می شود تا مربع خطای بین خروجی های شبکه و تابع هدف مینیمم شود. خطا بصورت زیر تعریف می شود:

$$E(\vec{W}) = \frac{1}{2} \sum_{d \in D} \sum_{k \in outputs} (t_{kd} - o_{kd})^2 \quad (3)$$

مراد از outputs خروجی های مجموعه واحد های لایه خروجی و t_{kd} و o_{kd} مقدار هدف و خروجی متناظر با k امین واحد خروجی و مثال آموزشی d است.

۴- بهینه سازی ازدحام ذرات

الگوریتم بهینه ساز ازدحام ذرات PSO یک روش بهینه سازی آماری مبتنی بر جمعیت است که رفتار اجتماعی گروهی از پرندگان، زنبورها و اجتماع ماهی ها را شبیه سازی می کند، راه حل های انتخابی را به عنوان مقادیر اولیه و به صورت تصادفی به الگوریتم می دهد و این الگوریتم با موفقیت به سمت بهینه کلی هدایت می شود. این مسئله با یک روش تکرار هوشمند در یک سیستم تکاملی حاصل می شود. در الگوریتم PSO استاندارد، هر ذره i (پارامتر مورد بررسی) دارای دو قسمت اصلی شامل موقعیت فعلی ذره (x_i) (مقدار پارامتر) و سرعت فعلی ذره (v_i) (سرعت تغییر مقدار پارامتر) است. موقعیت بعدی هر ذره در فضای جستجو با موقعیت فعلی و سرعت بعدی آن تعیین می شود. سرعت بعدی هر ذره با استفاده از چهار عامل اصلی یعنی موقعیت فعلی ذره، سرعت فعلی ذره، بهترین موقعیت ذره که تاکنون تجربه شده است و در حافظه آن ذخیره شده ($pbest$) و بهترین موقعیت در میان ذرات گروه که در حکم تجربه گروهی یاد می شود ($gbest$)، تعیین می شود. با توجه به تعاریف ذکر شده، سرعت بعدی هر ذره (پارامتر مدل) i با رابطه زیر بیان می شود [۱۰]:

$$v_i(t+1) = \omega v_i(t) + c_1 rand(pbest(t) - x_i(t)) + c_2 rand(gbest(t) - x_i(t)) \quad (4)$$

ω ضریب وزن اینرسی است که اثر سرعت در مرحله (تکرار) قبل را کنترل می کند. c_1, c_2 ضرایب شتاب یا ضرایب یادگیری فردی و گروهی ذره می باشند. دستور $rand$ عددی تصادفی در بازه صفر و یک تولید می کند. $v_i(t)$ سرعت ذره (پارامتر) i ام در تکرار t و $x_i(t)$ مقدار ذره (پارامتر) i ام در تکرار t است. با تعیین سرعت بعدی هر ذره، موقعیت بعدی (مقدار پارامتر) آن از رابطه زیر بدست می آید:

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (5)$$

۴-۱- بهبود ضرایب شتاب (آموزش)

در الگوریتم بهینه‌ساز ازدحام ذرات PSO، مقادیر فاکتورهای شتاب (آموزش) قدرت تغییر اطلاعات بین ذرات را منعکس می‌کند. این ضرایب (c_1 , c_2) مسیر حرکت ذرات و نتایج همگرایی الگوریتم را تعیین می‌کند. مشخص است که مقادیر بزرگتر یا کوچکتر فاکتورهای آموزش برای بهینه‌سازی ذرات سودمند نمی‌باشند. می‌توانم این ضرایب را بصورت یک رابطه تعدیل کننده خطی پویا در نظر گرفت.

$$c_1 = 2.4 - \frac{1.4t_{iter}}{T_{max}} \quad (6)$$

$$c_2 = 0.9 + \frac{1.6t_{iter}}{T_{max}} \quad (7)$$

همانطور که از روابط بالا مشخص است، با افزایش تعداد تکرار، c_1 کاهش می‌یابد. c_1 ضریب pbest یا بهترین موقعیتی که ذره تاکنون تجربه کرده است. پس جستجو بصورت محلی است و با کاهش c_1 ، جستجوی محلی (local) هم کاهش می‌یابد. از طرفی با افزایش تعداد تکرار، c_2 افزایش می‌یابد. c_2 ضریب gbest یا بهترین موقعیت کل ذرات است. پس جستجو بصورت سراسری (global) انجام می‌شود. در نهایت با افزایش تعداد تکرار، توانایی جستجو بصورت سراسری افزایش می‌یابد و به یافتن بهینگی سراسری کمک خواهد کرد.

۴-۲- بهبود ضریب وزن اینرسی

در الگوریتم PSO برای ضریب وزن اینرسی w یک محدوده کمینه (w_{min}) و بیشینه (w_{max}) تعریف می‌شود تا تغییرات وزن اینرسی در هر تکرار همواره در این محدوده واقع شود. تغییرات کاهشی ضریب وزن اینرسی ذرات در هر تکرار با استفاده از رابطه خطی زیر در هر تکرار صورت می‌پذیرد [۱۱]:

$$w = w_{max} - (w_{max} - w_{min}) \times \frac{t_{it}}{T_{max}} \quad (8)$$

که در آن t_{it} شماره تکرار فعلی و T_{max} تعداد تکرار تعریف شده می‌باشد.

۵- الگوریتم هیبرید ANN-PSO

در این تحقیق یک الگوریتم هیبریدی (دو جزئی) از ترکیب شبکه عصبی مصنوعی و روش بهینه‌سازی ازدحام ذرات برای تخمین طرح اختلاط بهینه هر گونه بتن برای یک مقدار مشخص از مقاومت فشاری معرفی می‌شود. شبکه عصبی مورد استفاده، شبکه عصبی پیشخور دو لایه می‌باشد. برنامه نویسی برای این الگوریتم در نرم افزار متلب صورت گرفته است. قابل ذکر است که از این الگوریتم می‌توان برای مشخصه‌های مختلف بتن استفاده نمود. لازمه این کار این است تا شبکه عصبی برای آن ویژگی خاص بتن آموزش داده شود. برای استفاده از این الگوریتم نیاز است تا طرح‌های اختلاط بعلاوه مقاومت فشاری متناظر با هر طرح بعنوان داده‌های ورودی، به شبکه عصبی معرفی شده و شبکه عصبی مورد آموزش قرار گیرد. در این تحقیق از تابع آموزش الگوریتم پس انتشار لونبرگ-مارکوآردت^۱ و تابع یادگیری بایاس و وزن گرادیان کاهشی^۲ استفاده می‌شود. روش بازگشت به عقب^۳ گرادیان تابع هزینه را برای تمام وزن‌های شبکه عصبی محاسبه می‌کند و بعد از روش‌های گرادیان کاهشی برای پیدا کردن مجموعه وزن‌های بهینه استفاده می‌نماید. تابع عملگر (تعیین مقدار خطا در هر تکرار) تابع خطای کمترین مربعات^۴ MSE می‌باشد.

بطور مرسوم تقریباً از ۷۰ درصد داده‌ها برای آموزش شبکه عصبی، ۱۵ درصد داده‌ها برای اعتبار سنجی و از ۱۵ درصد باقی مانده داده‌ها برای آزمایش استفاده می‌شود. در این الگوریتم، جمعیت‌های اولیه که در واقع طرح‌های اختلاط مختلف می‌باشند تولید

¹ Levenberg-Marquardt

² Gradient descent weight and bias

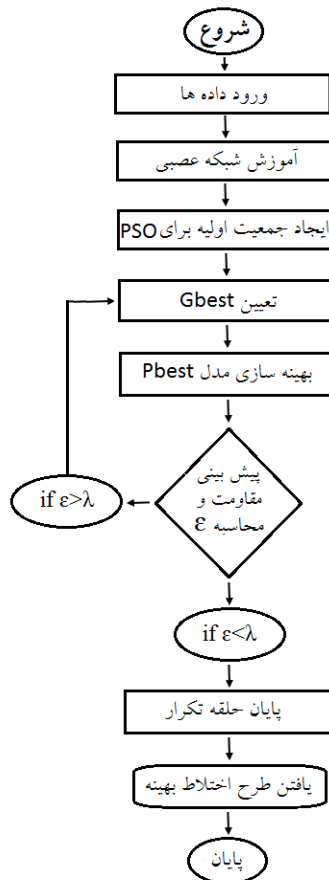
³ Back propagation

⁴ Mean squared error


شده و با استفاده از الگوریتم بهینه ساز ازدحام ذرات، بهترین طرح اختلاط در هر تکرار انتخاب و بهبود می یابد. این طرح اختلاط در هر تکرار به شبکه عصبی پیشخور آموزش داده شده اعمال شده و شبکه عصبی مقاومت فشاری متناظر با آن طرح اختلاط را پیش بینی می نماید. خطای بین مقاومت فشاری پیش بینی شده و مقاومت فشاری مورد انتظار λ محاسبه و با مقدار خطای مجاز تعریف شده ϵ مقایسه می شود. اگر این خطا بیشتر از خطای تعریف شده باشد روند بهبود طرح اختلاط توسط PSO ادامه پیدا کرده و دوباره طرح اختلاط بهبود پیدا کرده به شبکه عصبی معرفی می گردد. این روند تا جایی ادامه پیدا می کند تا خطای بین مقاومت فشاری پیش بینی شده و مقاومت فشاری مورد انتظار کمتر از خطای تعریف شده اولیه گردد و یا تعداد تکرار به پایان برسد. شکل ۲ فلوچارت الگوریتم هیبرید ANN-PSO را نشان می دهد.

۶- آماده سازی الگوریتم هیبریدی

گام نخست برای استفاده از الگوریتم هیبریدی ANN-PSO تعریف ساختار شبکه عصبی می باشد. شکل ۳ ساختار شبکه عصبی پیشخور را نشان می دهد. از آنجا که طرح اختلاط بتن خودتراکم شامل ۷ مصالح آب، سیمان، ماسه، شن، پودر سنگ، روان کننده و میکروسیلیس است (جدول ۱)، بنابراین ورودی شبکه عصبی شامل ۷ نرون و از آنجا که خروجی شبکه عصبی مقاومت فشاری ۲۸ روزه است، بنابراین لایه خروجی شبکه عصبی دارای یک نرون می باشد (شکل ۳). تعداد نرون لایه پنهان برابر با مجموع تعداد نرون لایه ورودی و لایه خروجی یعنی ۸ عدد در نظر گرفته شده است. تابع فعال سازی (تابع انتقال) لایه میانی، تابع فعال سازی سیگموئید و تابع فعال سازی لایه خروجی، تابع فعال سازی خطی است. شکل ۴ تغییرات مربوط به خطای کمترین مربعات (MSE) بین داده های مقاومت فشاری بتن خودتراکم در نظر گرفته شده بعنوان داده آموزشی، اعتبارسنجی و آزمایشی که توسط شبکه عصبی پیشخور تعریف شده در شکل ۳ محاسبه شده است و مقدار مقاومت فشاری ۲۸ روزه اولیه با افزایش تکرار را نشان می دهد.



شکل ۲- فلوچارت الگوریتم هیبرید ANN-PSO



شکل ۳- ساختار شبکه عصبی پیشخور مورد استفاده در الگوریتم هیبریدی ANN-PSO برای تخمین طرح اختلاط بیهینه بتن خودتراکم


با توجه به شکل ۴ بهترین عملکرد شبکه عصبی در طی آموزش بوسیله داده‌های طرح اختلاط بتن خودتراکم و مقاومت فشاری ۲۸ روزه نظیر، مربوط به تکرار هفتم می‌باشد که خطای کمترین مربعات مربوط به داده‌های اعتبارسنجی آن ۲۸/۲ مگاپاسکال می‌باشد. چرا که بعد از تکرار هفتم تا شش تکرار بعدی، یعنی تکرار سیزدهم مقدار خطای کمترین مربعات داده‌های اعتبارسنجی افزایش یافته است و در تکرار ۱۱۳م روند آموزش شبکه عصبی متوقف می‌گردد. بر روی محورهای عمودی شکل‌های ۵الف، ب، ج و د، معادله بهترین خط برازش داده شده بر روی مقاومت فشاری پیش بینی شده برترتیب برای مجموع داده‌های آموزشی (رابطه ۹)، اعتبارسنجی (رابطه ۱۰)، آزمایشی (رابطه ۱۱) و کل (رابطه ۱۲) را نشان می‌دهند:

$$\text{Output} = 0.88 \times \text{Target} + 7.4 \quad (9)$$

$$\text{Output} = 0.78 \times \text{Target} + 13 \quad (10)$$

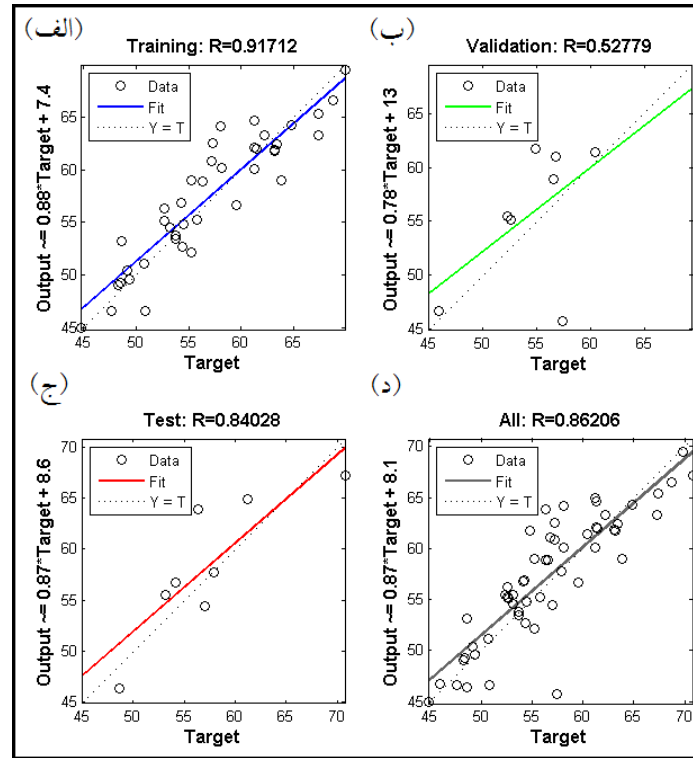
$$\text{Output} = 0.87 \times \text{Target} + 8.5 \quad (11)$$

$$\text{Output} = 0.87 \times \text{Target} + 8.1 \quad (12)$$



شکل ۴- تغییرات خطای کمترین مربعات بین داده‌های آموزشی، اعتبارسنجی و آزمایشی با هر تکرار در شبکه عصبی

که در آنها Target داده‌های مقاومت فشاری ۲۸ روزه بتن خودتراکم و Output مقاومت فشاری پیش بینی شده بر اساس رابطه رگرسیون خطی می‌باشد. با توجه به شکل ۵ می‌توانیم مقادیر مقاومت فشاری ۲۸ روزه برای بتن خود تراکم توسط شبکه عصبی پیشخور آموزش داده شده را بر اساس معادله‌های رگرسیون خط برازش داده شده برای داده‌های آموزشی (شکل ۵الف)، داده‌های اعتبارسنجی (شکل ۵ب)، داده‌های آزمایشی (شکل ۵ج) و کل داده‌ها (شکل ۵د) پیش بینی نمود. مقادیر همبستگی بدست آمده بین مقادیر مقاومت فشاری ۲۸ روزه اندازه گیری شده در آزمایشگاه با مقادیر پیش بینی شده توسط شبکه عصبی برای داده‌های آموزشی، اعتبارسنجی، آزمایشی و کل نمونه‌ها برترتیب ۰/۹۱۷، ۰/۵۲۸، ۰/۸۴ و ۰/۸۶ می‌باشد.



شکل ۵- محاسبه مقادیر ضریب همبستگی بین مقادیر مقاومت فشاری ۲۸ روزه اولیه بتن خودتراکم و پیش بینی شده با شبکه عصبی و روابط رگرسیونی خطی برازش داده شده بر روی داده‌های آموزشی، اعتبارسنجی، آزمایشی و کل بدست آمده از شبکه عصبی پیشخور

۷- تحلیل داده ها و نتیجه گیری

برای تخمین طرح اختلاط بهینه با استفاده از الگوریتم پیشنهادی ANN-PSO و اینکه بتوانیم دقت نتایج را مورد ارزیابی قرار دهیم، یکی از طرح اختلاط‌های مربوط به بتن خود تراکم را انتخاب نمودیم (طرح اختلاط شماره ۴۲ در جدول ۱ و ۲). این طرح اختلاط دارای 749 kg/m^3 ماسه، 1256 kg/m^3 روان کننده، 175 kg/m^3 آب، 314 kg/m^3 سیمان، 36 kg/m^3 میکروسیلیس، $147/5$ پودر سنگ و 816 kg/m^3 شن می‌باشد و مقاومت فشاری ۲۸ روزه آن $59/54$ مگاپاسکال است. تعداد جمعیت اولیه و تکرار در نظر گرفته شده برای الگوریتم هیبریدی به ترتیب ۵۰ جمعیت و ۴۰ تکرار و مقادیر کمینه و بیشینه ضریب وزن اینرسی ۱۷ به ترتیب ۰/۲ و ۰/۹ می‌باشد. همچنین مقدار خطای مجاز در نظر گرفته شده، ۰/۰۱ مگاپاسکال تعیین شده است. الگوریتم هیبریدی ANN-PSO مقادیر طرح اختلاط بهینه برای مقاومت فشاری ۲۸ روزه $59/54$ مگاپاسکال را بصورت $747/3 \text{ kg/m}^3$ برای ماسه، 131 kg/m^3 روان کننده، 180 kg/m^3 آب، $325/31 \text{ kg/m}^3$ سیمان، 40 kg/m^3 میکروسیلیس، 157 kg/m^3 پودر سنگ و $80/42$ شن تخمین و مقاومت فشاری متناظر با این مصالح تعیین شده با استفاده از الگوریتم هیبریدی $59/52$ مگاپاسکال پیش بینی شده است (جدول ۳). با توجه به جدول ۳ مقدار خطا و درصد خطای پیش بینی مصالح طرح اختلاط و مقاومت فشاری به ترتیب برای ماسه $1/7 \text{ kg/m}^3$ و ۰/۲۳٪، برای روان کننده $0/054 \text{ kg/m}^3$ و ۰/۴۳٪، برای آب 5 kg/m^3 و ۲/۸۶٪، برای سیمان $11/31 \text{ kg/m}^3$ و ۳/۶٪، برای میکروسیلیس 4 kg/m^3 و ۱۱/۱۱٪، برای پودر سنگ $9/5 \text{ kg/m}^3$ و ۶/۴٪، برای شن $15/58 \text{ kg/m}^3$ و ۱/۹٪ و برای مقاومت فشاری $0/02 \text{ Mpa}$ و ۰/۳۴٪ می‌باشد. خطای بین مقاومت فشاری پیش بینی شده و مقاومت فشاری اولیه ۰/۰۲ مگاپاسکال است. از آنجایی که در هیچ تکراری مقدار خطای بین مقاومت فشاری پیش بینی شده متناظر با هر طرح اختلاط (جمعیت) و مقاومت فشاری مد نظر کمتر از مقدار خطای اولیه تعریف شده، نشده است تعداد تکرارها به اتمام رسیده و سپس الگوریتم جمعیتی که کوچکترین مقدار خطا را داشته است را بعنوان بهترین جمعیت (طرح اختلاط بهینه) در نظر گرفته است. زمان اجرای کد $31/34$ ثانیه است.

جدول ۳- مقادیر مصالح طرح اختلاط در نظر گرفته شده و مقادیر تخمین زده شده با الگوریتم ANN-PSO

مقاومت فشاری Mpa	ماسه Kg/m ³	شن Kg/m ³	پودر سنگ Kg/m ³	روان کننده Kg/m ³	میکروسیلیس Kg/m ³	سیمان Kg/m ³	آب kg/m ³	مصالح
59.54	749	816	147.5	1.256	36	314	175	مقادیر اولیه
59.52	747.3	800.42	157	1.31	40	325.31	180	تخمین زده شده
0.02	1.7	15.58	9.5	0.054	4	11.31	5	خطا
0.034	0.23	1.9	6.4	4.3	11.11	3.6	2.86	درصد خطا

با توجه به نتایج بدست آمده می توان گفت که الگوریتم پیشنهادی ANN-PSO ابزاری قدرتمند برای تخمین مقادیر طرح اختلاط بتن برای یک مقدار مشخص از مقاومت فشاری است.

۸- مراجع

- Kennedy, J., and Eberhart, R., 1995, Particle swarm optimization: IEEE International Conference on Neural Networks, 4, 1942-1948.
- Deng F., He Y., Zhou S., Yu Y., Cheng H., Wu X., 2018. Compressive strength prediction of recycled concrete based on deep Learning. Construction and Building Materials 175 (2018) 562-569.
- Alshihri, M. M., Azmy, A. M. and El-Bisy, M. S. 2009. "Neural networks for predicting compressive strength of structural light weight concrete". Constr. Build. Mater., 23(6): 2214-2219.
- Chopra, P. Sharma, R. K. and Kumar, M. 2016. Prediction of Compressive Strength of Concrete Using Artificial Neural Network and Genetic Programming. Advances in Materials Science and Engineering.
- Waghmare, S., A. D. Katdare, N. K. Patil. 2021. Prediction of compressive and tensile strengths of zeolite blended concrete in rigid pavement using artificial neural network. RT&A, 1 (60).
- غنی زاده، ع.، عباسلو، ح.، توانا املشی، الف.، ۱۳۹۵، پیش بینی مدول الاستیسیته بتن پلاستیک با استفاده از شبکه عصبی مصنوعی بهینه شده با الگوریتم ازدحام ذرات، دومین کنفرانس محاسبات تکاملی و هوش جمعی، ۱۷-۱۹ اسفندماه، دانشگاه شهید باهنر کرمان.
- دهقانی، ح.، جهان آرا، الف.ع.، هاشمزی، ع. یافتن مقاومت فشاری حداکثر بتن سبک با استفاده از ترکیب شبکه عصبی و PSO. ۱۳۹۷. چهارمین کنفرانس ملی مهندسی عمران و معماری با تاکید بر فن آوری های بومی ایران.
- Tavana Amlashi, A., Ghanizadeh, A.R., Abbaslou, H., Alidoust, P., 2020. Developing three hybrid machine learning algorithms for predicting the mechanical properties of plastic concrete samples with different geometries. AUT J. Civil Eng., 4(1), 37-54. DOI: 10.22060/ajce.2019.15026.5517.
- Macias, C., Sen M. K. & Stoffa P. L. (2000). Artificial neural networks for parameter estimation in geophysics. Geophys. Prospecting, 48, 21-47.
- Sweilam N.H., El-Metwally K., Abdelazeem M., (2007) Self potential signal inversion to simple polarized bodies using the particle swarm optimization method: A visibility study. Journal of Applied Geophysics, 6, 195-208.
- Shi Y. and Eberhart R., (1998). A modified particle swarm optimizer. In IEEE international conference on evolutionary computation. IEEE Press, Piscataway, NJ, pp. 69-73.