



پیش بینی مقاومت فشاری بتن با مقاومت بالا با استفاده از شبکه های عصبی تابع بنیادی شعاعی (RBF) و پس انتشار خطا (BP)

محمد رضا قاسمی^۱، محمدرضا سهرابی^۲، غلامرضا آهنی^۳ ابو حمزه صائب^۳

۱- دانشیار گروه مهندسی عمران دانشگاه سیستان و بلوچستان

۲- استادیار گروه مهندسی عمران دانشگاه سیستان و بلوچستان

۳- دانشجوی کارشناسی ارشد گروه مهندسی عمران دانشگاه سیستان و بلوچستان

rezacivil82@yahoo.com

خلاصه

پیش نیاز اولیه جهت انجام مطالعات تمامی پروژه های مقاوم سازی تعیین مشخصات مصالح است. در پروژه هایی که سازه آنها از بتن تشکیل شده است مهمترین مشخصه مورد نیاز، مقاومت فشاری بتن می باشد که تعیین آن در روند انجام مطالعات از اهمیت بسزایی برخوردار است. در این مقاله از شبکه های عصبی تابع بنیادی شعاعی RBF و BP برای پیش بینی مقاومت فشاری ۲۸ روزه بتن با مقاومت بالا استفاده شده است. مدل شبکه عصبی ارائه شده پس از آموزش کافی بوسیله داده های واقعی مربوط به آزمایش های صورت گرفته روی بتن، قادر به پیش بینی مقاومت بتن خواهد بود.

کلمات کلیدی: پیش بینی ، مقاومت فشاری بتن، شبکه های عصبی تابع بنیادی شعاعی (RBF)، شبکه های پس انتشار خطا (BP).

۱. مقدمه

بتن معمولی به عنوان یکی از رایج ترین مصالح ساختمانی از موادی چون سیمان، آب، درشت دانه و ریز دانه تشکیل شده است. با این وجود، پیش بینی خواص بتن با استفاده از روش های تحلیلی و دقیق قابل بررسی نمی باشد. بیشتر روش های استفاده شده در پیش بینی خواص بتن، بر این اساس بدست آمده اند که بر مبنای آزمایش های انجام گرفته، فرمول های تجربی، نمودار ها، نمودار ها، و جداولی بدست آمده و ترسیم می شوند سپس این جداول و نمودارها در موارد جدید تعمیم داده شده و نتیجه گیری های لازم در مورد آن ها انجام می گیرد. [۱]

اما نکته قابل توجه در این گونه طراحی ها این است که هر یک از مواد تشکیل دهنده بتن بصورت یک پارامتر در نظر گرفته می شود. حال آنکه هر یک از این مواد دارای ابعاد گوناگونی می باشند بطور مثال، سیمان ها دارای مقاومت، نرمی و ترکیبات شیمیایی متفاوتی هستند. ریزدانه ها اندازه های مختلف و جنس های متفاوتی دارند. درشت دانه های مصرفی در بتن ممکن است از معادن متفاوتی به دست آمده باشند همچنین ممکن است شکسته یا طبیعی باشند.

در سال های اخیر، مواد جدید و فن آوری های ساخت نوینی در بتن به وجود آمده که تعداد پارامترهای موثر در طرح اختلاط بتن را تا دو برابر افزایش می دهد. مثلاً در ترکیب بتن ها با مقاومت بالا افزودنی های شیمیایی مانند روان کننده ها، سرباره کوره های آهن گدازی، خاکستر بادی، میکروسیلیس و الیاف مختلف وجود دارد که هر کدام به صورت یک یا چند پارامتر در طرح اختلاط بتن وارد می شوند. جدا از مواد تشکیل دهنده بتن، خواص بتن به نسبت مخلوط کردن اجزاء بتن و روش اختلاط بتن نیز بستگی خواهد داشت. نتیجتاً مساله تعیین طرح بهینه اختلاط بتن، به یک مسئله جستجو در یک فضای ۱۰ الی ۲۰ بعدی تبدیل خواهد شد. [۱]

در مراجع موجود، اطلاعات بسیار زیادی راجع به نمونه های متعدد آزمایش شده وجود دارد، اما در هیچ کدام روش تحلیلی و دقیقی برای پیش بینی خواص بتن ارائه نشده است. همچنین هیچ روش و راه حلی برای تعیین خواص بتن ارائه نگردیده، که تمام جزئیات مهم اجزای آن را شامل باشد. بدین ترتیب با توجه به مطالب گفته شده در بالا، تعیین مقاومت بتن به عنوان یکی از خواص مهم آن، با استفاده از روش های تحلیلی، عملاً ناممکن و غیر قابل اعتماد به نظر می رسد.

در سال های اخیر شاهد حرکتی مستمر از تحقیقات صرفاً نظری به تحقیقات کاربردی به ویژه در پردازش اطلاعات برای مسائلی که با برای آنها راه حلی موجود نیست و یا به راحتی قابل حل نیستند، بوده ایم. بر این اساس مدل های مبتنی بر شبکه های عصبی مصنوعی ساخته شده از داده های



آزمایشگاهی، مورد توجه و علاقه محققین شاخه های گوناگون قرار گرفته است. دلیل عمده این توجه آن است که برخلاف روش های کلاسیک موجود در تئوری های آماری، شبکه های عصبی به هیچ مدل یا تابع مشخص به همراه فرضیات محدود کننده برای خطی کردن مسئله، نیاز ندارند. شبکه های عصبی ابزار قدرتمند و منحصر بفردی برای تحلیل های غیر متعارف، مشکل و یا غیر ممکن می باشند. یکی از این موارد تشخیص سیستم های غیر خطی است [۱].

۲. شبکه های عصبی مصنوعی

هر چند زمان زیادی از ابداع شبکه های عصبی مصنوعی سپری نشده، لیکن به دلیل آنکه شیوه پردازشی آن به عملکرد مغز انسان شبیه بوده و می تواند تا اندازه ای عملکردی مشابه با شبکه های زیستی در یادگیری داشته باشد و این یادگیری را تعمیم دهد، دامنه تحقیقات در این زمینه روز به روز گسترده تر می شود. ایده اصلی شبکه های عصبی مصنوعی بر مبنای شبیه سازی شبکه عصبی انسان است. مهمترین عنصر پردازش در سیستم های زیستی نرون است. در مغز انسان بیش از ۱۰ میلیارد نرون وجود دارد که هر یک با حدود ۱۰ هزار نرون دیگر مرتبط بوده و یک ساختار مترامک را ایجاد کرده است. هر نرون شامل شاخه های ورودی به نام دندریت، هسته اصلی و یک شاخه های خروجی به نام آکسون است. آکسون نرون در محل سیناپس به دندریت های نرون های دیگر متصل می شود. هنگامی که نرون فعال شود سیگنالی الکتروشیمیایی درون آکسون هایش ایجاد کرده، این سیگنال از طریق سیناپس ها به نرون های دیگر رسیده و آن ها را تحریک می کند. هر نرون زمانی فعال می شود که مجموع سیگنال های رسیده به بدنه آن از حد آستانه مشخصی بیشتر شود. قدرت سیگنال های رسیده به هر نرون به اثر سیناپس ها بستگی دارد. هر نرون تعدادی ورودی را از داده های اصلی (سیگنال های حسی) یا از خروجی نرون های دیگر دریافت می کند. هر اتصال دارای قدرت (وزن) خاصی میان دو نرون است. این وزن ها شبیه اثر سیناپس ها در سیستم های زیستی هستند. عملکرد هر نرون چنین است که هر سلول، مجموع وزن دار سیگنال های ورودی را یافته و سپس آن را با حد آستانه تابع تحریک مقایسه می کند و بدین ترتیب خروجی هر نرون محاسبه می شود. براساس ترکیب های مختلف نرون ها و قوانین مختلف یادگیری، شبکه های مختلفی تشکیل می شود که یکی از کاربردی ترین آن ها در علوم مهندسی برای نگاشت غیر خطی، شبکه های پس انتشار خطا (BP) و شبکه های تابع بنیادی شعاعی (RBF) هستند. [۲]


۳. شبکه عصبی پس انتشار خطا (BP^۱)

این شبکه شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. برای آموزش این شبکه، معمولاً از الگوریتم پس انتشار (BP) استفاده می شود. در طی آموزش شبکه پس انتشار خطا به کمک الگوریتم یادگیری BP، ابتدا محاسبات از ورودی شبکه به سوی خروجی شبکه انجام می شود و سپس مقادیر خطای محاسبه شده به لایه های قبل انتشار می یابد. در ابتدا، محاسبه خروجی به صورت لایه به لایه انجام می شود و خروجی هر لایه، ورودی لایه بعدی خواهد بود. در حالت پس انتشار، ابتدا لایه های خروجی تعدیل می شود، زیرا برای هر یک از نرون های لایه خروجی، مقدار مطلوبی وجود دارد و می توان به کمک آنها و قاعده های بهنگام سازی، وزن ها را تعدیل نمود. با وجود اینکه الگوریتم پس انتشار خطا نتایج بسیار خوبی در حل مسائل ارائه داده است، در حل برخی از مسائل ضعیف عمل می کند که می تواند به دلیل طولانی بودن یا مشخص نبودن زمان یادگیری، انتخاب نامناسب ضریب یادگیری و یا توزیع تصادفی وزنه های اولیه باشد. در برخی موارد نیز به دلیل وجود کمینه موضعی، فرایند یادگیری مختل می شود که به دلیل قرار گرفتن جواب در قسمت های هموار توابع آستانه دچار وقفه می شود. مراحل آموزش به کمک این الگوریتم عبارتند از الف) - اختصاص ماتریس وزن تصادفی به هر یک از اتصالات (ب) - انتخاب بردار ورودی و خروجی متناسب با آن (پ) - محاسبه خروجی نرون در هر لایه و در نتیجه محاسبه خروجی نرون ها در لایه خروجی (ت) - بهنگام سازی وزن ها به روش انتشار خطای شبکه به لایه های قبل که خطای یاد شده ناشی از اختلاف بین خروجی واقعی و خروجی محاسبه شده است. (ث) - ارزیابی عملکرد شبکه آموزش دیده به کمک برخی شاخص های تعریف شده مانند میانگین مربعات خطا (MSE) و سرانجام برگشت به قسمت پ یا پایان آموزش. [۳]

¹ Back propagation

۴. شبکه عصبی تابع بنیادی شعاعی (RBF)

توابع بنیادی شعاعی برای اولین بار توسط بروم هد^۱ و لوو^۲ [4] به عنوان تابع تحریک نرون در طراحی شبکه های عصبی به کار برده شدند. محققین بعدی اثبات کردند که شبکه های RBF تقریب سازهای بسیار قدرتمندی هستند به طوری که با داشتن تعداد نرون های کافی در لایه مخفی، قادر به تقریب سازی هر تابع پیوسته ای با هر درجه ای از دقت می باشند. نکته قابل توجه این است که، شبکه های RBF تنها با داشتن یک لایه مخفی و یک لایه خروجی، دارای چنین خاصیتی هستند در حالی که در سایر شبکه های پیشخور با تعبیه چندین لایه مخفی به سختی می توان چنین خاصیتی را ایجاد نمود. در شکل ۱ ساختار کلی یک شبکه RBF نشان داده شده است.



شکل ۱- ساختار کلی یک شبکه RBF

در شکل ۱، هر کدام از I ها نشان دهنده یک مولفه از بردار ورودی هستند. σ_i نشان دهنده محدوده ای است که نرون I_m در آن پاسخ قابل قبول و معنی دار ارائه می دهد و u_i برداری است که مولفه های آن وزن های ارتباط دهنده هر یک از ورودی ها با نرون I_m است. f نیز تابع تحریک نرون های لایه پنهان است که از نوع نمائی گوس می باشد. این تابع تحریک با معادله ۱ نشان داده شده است. O ها نیز خروجی های شبکه هستند که در اثر اعمال یک تابع تحریک خطی به سیگنال های ارسال شده از لایه مخفی به لایه خروجی، تولید می شوند.

$$f_i = e^{\left[\frac{-D_i^2}{(2\sigma^2)} \right]} \quad (1)$$

در رابطه فوق $D_i^2 = (I - u_i)^T (I - u_i)$ نماد T نشان دهنده ترانپوز بردار، I بردار ستونی ورودی می باشد. هر کدام از ارتباط های نشان داده شده در شکل ۱ به واسطه یک ضریب که وزن نامیده می شوند برقرار می شوند. این وزن ها در روند آموزش بر طبق قانون آموزش مناسب، تعدیل می شوند. تعداد نرون های لایه مخفی برابر با تعداد جفت های آموزشی موجود در مجموعه آموزشی هستند. همچنین تعداد نرون های موجود در لایه خروجی برابر با تعداد مولفه های بردار هدف می باشند. لازم به توضیح است که آموزش نظارت شده با استفاده از جفت های آموزشی که عبارتند از بردار ورودی و بردار خروجی مطلوب متناظر به صورتی انجام می گیرد که اختلاف بین خروجی های واقعی شبکه با خروجی های مطلوب یا هدف به حداقل ممکن برسد. در شبکه RBF وزن های لایه ورودی نیاز به آموزش ندارند و ترانپوز ماتریس ورودی به عنوان ماتریس وزن لایه اول اختصاص می یابد. وزن های لایه دوم شبکه RBF با استفاده از قانون آموزش نظارت شده زیر تعدیل می شوند:

۱- بردار ورودی I از مجموعه آموزشی، به شبکه ارائه می شود.

۲- خروجی های نرون های لایه مخفی محاسبه شده و بردار f را تشکیل می دهند.

۳- بردار خروجی شبکه (O) محاسبه و با بردار هدف (t) مقایسه می شود. ماتریس وزن لایه دوم (W) در جهت کاهش اختلاف بردارهای O و t تعدیل می شود. اغلب جهت این کار از رابطه زیر استفاده می شود:

$$w_{ij}(n+1) = w_{ij}(n) + \eta(t_j - O_j)I_i \quad (2)$$

در رابطه فوق η ضریب نرخ آموزش نام دارد و معمولاً خیلی کمتر از ۱ می باشد.

۴- گام های ۱ تا ۳ جهت هر بردار مجموعه آموزشی تکرار می شوند.

۵- گام های ۱ تا ۴ تا زمانی که خطا به حد قابل قبولی برسد ادامه می یابند و در این نقطه، آموزش پایان می یابد. بعد از آموزش شبکه با ارائه بردار های ورودی به آن می توان بردارهای خروجی شبیه سازی شده توسط شبکه را دریافت نمود [۵].

¹ Broomhead

² Lowe



برای توقف محاسبات در یک شبکه عصبی دو معیار را در نظر می گیریم: ۱- تعداد دوره های انجام گرفته از یک حد مورد نظر بیشتر شود. ۲- میزان خطای محاسبه شده در خروجی شبکه، از مقدار حدی آن کمتر گردد. خطای خروجی شبکه را با چندین روش می توتن محاسبه کرد: ۱- روش میانگین مربعات خطا (MSE) ۲- روش مجموع مربعات خطا (SSE) ۳- میانگین مطلق خطا (MAE). روش دوم نسبت به روش اول عدد بزرگتری را به دست می دهد و هر چه تعداد زوج های آموزشی بیشتر باشد، خطای محاسبه شده به روش دوم نیز بیشتر شده و همگرایی شبکه سخت تر خواهد شد. لذا توصیه می شود در صورتی که تعداد زوج های آموزشی زیاد باشد از روش اول برای محاسبه خطای شبکه استفاده شود.

۵. پیش بینی مقاومت فشاری بتن با مقاومت بالا

به منظور پیش بینی مقاومت فشاری بتن با مقاومت بالا با استفاده از شبکه تابع بنیادی شعاعی، ابتدا اطلاعات مربوط به ۱۹۰ نمونه آزمایشی با استفاده از منابع مختلف، شامل مقالات ارائه شده در کنفرانس ها و مقالات متعدد چاپ شده در مجلات جمع آوری شده است. این اطلاعات شامل وزن یا درصد وزنی هر یک از اجزاء تشکیل دهنده بتن شامل (سیمان، آب، میکروسیلیس، فوق روان کننده، ریزدانه و درشت دانه) به عنوان ورودی شبکه عصبی و مقاومت فشاری ۲۸ روزه بتن به عنوان خروجی شبکه عصبی می باشد.

از آنجا که دقت یک شبکه عصبی به مقدار زیادی به ماهیت پراکندگی اطلاعات ورودی جهت آموزش شبکه بستگی دارد لذا طبقه بندی اطلاعات ورودی برای آموزش شبکه از اهمیت ویژه ای برخوردار است. یک شبکه عصبی در مناطقی که داده های بیشتری برای آموزش وجود دارد بهتر عمل می کند و جواب بهتری می دهد. در نتیجه محدوده هایی که در آن تعداد نمونه بیشتری وجود دارد به صورت جدول ۱ می باشد. بنابراین اگر مقدار اجزاء تشکیل دهنده بتن را در نواحی فوق انتخاب نماییم شبکه عصبی آموزش داده شده قادر خواهد بود با دقت مناسبی مقاومت فشاری ۲۸ روزه بتن را پیش بینی نماید.

جدول ۱- محدوده اجزاء طرح اختلاط بتن که در این محدوده تعداد داده بیشتری وجود دارد

	درشت دانه (کیلوگرم بر متر مکعب)	ریزدانه (کیلوگرم بر متر مکعب)	فوق روان کننده (کیلوگرم بر متر مکعب)	میکروسیلیس (کیلوگرم بر متر مکعب)	آب (کیلوگرم بر متر مکعب)	سیمان (کیلوگرم بر متر مکعب)
min	800	600	0	0	106	300
max	1300	1100	20	60	200	550

۶. نرمال سازی بردارهای آموزشی

از آنجایی که مقادیر ورودی های شبکه عصبی ممکن است دارای پراکندگی زیاد باشند، که این پراکندگی باعث می شود شبکه نتواند جواب مطلوبی ارائه دهد. برای جلوگیری از این پراکندگی باید مقادیر ورودی ها را به رنج خاصی محدود نماییم که به این کار نرمال سازی می گویند. نرمال سازی بردارهای ورودی بسیار مفید و مطلوب خواهد بود. زیرا این کار سبب می شود که تغییرات بردارها در همه ابعاد فضای بردارهای ورودی، یکسان باشد. روش نرمال سازی که در این مقاله از آن استفاده شده است به صورت زیر می باشد:

۱- محاسبه انحراف استاندارد مولفه های متناظر همه بردارهای ورودی مجموعه آموزشی

۲- تقسیم همه آن مولفه ها بر انحراف استاندارد محاسبه شده


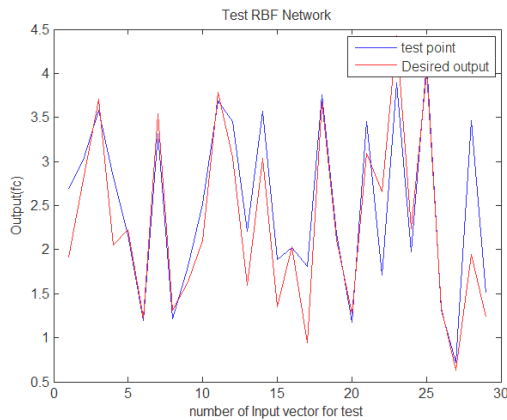
۷. نتایج حاصل از پیش بینی مقاومت فشاری بتن با مقاومت بالا با استفاده از شبکه عصبی RBF

همان گونه که در بالا گفته شد برای پیش بینی مقاومت فشاری بتن با مقاومت بالا با استفاده از شبکه عصبی RBF از ۱۹۰ داده استفاده شده است که ۸۵ درصد این داده ها جهت آموزش و ۱۵ درصد داده ها برای تست شبکه به کار گرفته شده اند. همان گونه که در جدول ۲ ملاحظه می شود پس از سعی و خطای بسیار و اجرای برنامه به دفعات زیاد نهایتاً مقدار spread بهینه بین ۱ تا ۳ به دست آمد که از این مقادیر spread همانگونه که در جدول ۲ مشخص می باشد بهترین جواب با توجه به کمترین خطاها و بیشترین مقدار پارامتر R برای آموزش و تست شبکه، در $spread=2.5$ به دست آمد.




جدول ۲- نتایج حاصل از شبکه عصبی RBF

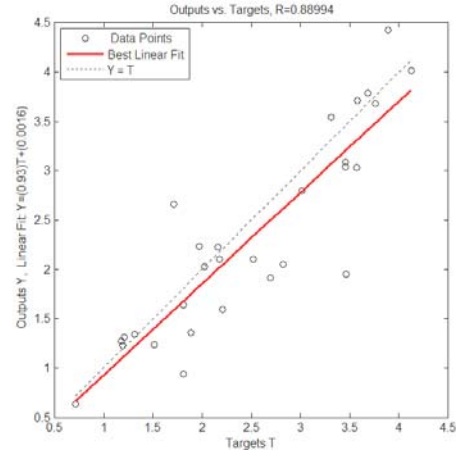
spread	neuron	train				test			
		MSEtrain	MAEtrain	SSEtrain	Rtrain	MSEtest	MAEtest	SSEtn	Rtest
1	91	0.039	0.135	6.202	0.981	0.843	0.602	24.451	0.703
1.1	96	0.039	0.130	6.241	0.980	0.727	0.546	21.086	0.726
1.2	79	0.038	0.130	6.076	0.981	0.622	0.543	18.032	0.762
1.3	94	0.039	0.142	6.298	0.980	0.934	0.626	27.082	0.727
1.4	96	0.040	0.141	6.416	0.980	0.473	0.510	13.721	0.802
1.5	96	0.038	0.135	6.193	0.981	0.416	0.443	12.076	0.833
1.6	58	0.039	0.141	6.350	0.980	0.269	0.380	7.798	0.871
1.7	92	0.039	0.136	6.298	0.980	0.437	0.458	12.668	0.826
1.8	66	0.040	0.140	6.418	0.980	0.307	0.406	8.911	0.863
1.9	83	0.040	0.138	6.408	0.980	0.331	0.394	9.605	0.857
2	78	0.039	0.140	6.228	0.981	0.410	0.445	11.900	0.825
2.1	65	0.040	0.141	6.427	0.980	0.318	0.420	9.232	0.860
2.2	68	0.039	0.142	6.274	0.980	0.362	0.407	10.496	0.850
2.3	91	0.038	0.143	6.178	0.981	0.331	0.417	9.611	0.848
2.4	83	0.039	0.138	6.330	0.980	0.737	0.569	21.364	0.775
2.5	93	0.040	0.141	6.410	0.980	0.249	0.357	7.226	0.890
2.6	82	0.039	0.137	6.282	0.980	0.575	0.483	16.685	0.790
2.7	75	0.040	0.140	6.420	0.980	0.444	0.450	12.880	0.819
2.8	60	0.039	0.141	6.345	0.980	0.418	0.467	12.128	0.831
2.9	73	0.038	0.139	6.139	0.981	0.381	0.446	11.045	0.834
3	90	0.040	0.145	6.413	0.980	0.540	0.504	15.666	0.821



شکل ۲- نمودار مقادیر مطلوب و مقادیر حاصل از شبکه RBF در مد آموزش
شکل ۳- نمودار مقادیر مطلوب و مقادیر حاصل از شبکه RBF در مد آزمایش



شکل ۵ - نمودار عملکرد داده های آموزش شبکه RBF



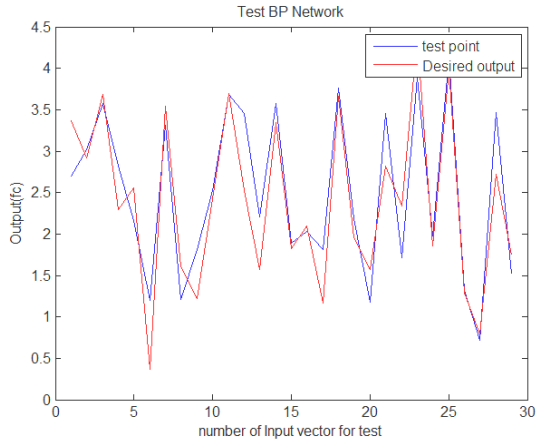
شکل ۴ - نمودار عملکرد داده های تست شبکه RBF

۸. نتایج حاصل از پیش بینی مقاومت فشاری بتن با مقاومت بالا با استفاده از شبکه عصبی BP

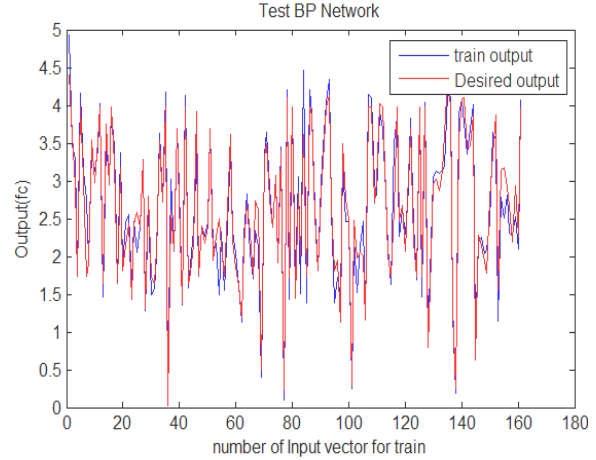
برای آموزش شبکه عصبی BP هم مانند شبکه عصبی RBF از ۸۵ درصد داده ها برای آموزش و ۱۵ درصد داده ها برای تست شبکه استفاده شد. در شبکه BP ابتدا با سعی و خطا بهترین توپولوژی شبکه که شامل دو لایه پنهان است به دست آمد. تعداد نرون های لایه پنهان اول با سعی و خطا در بهترین حالت همان طور که در جدول ۳ مشخص شده است ۸ می باشد و تعداد نرون لایه پنهان دوم در تمام حالات ۱ تعیین شد. قابل ذکر می باشد برای تعیین تعداد نرون لایه پنهان اول پس اجرای برنامه با محدوده نرون های مختلف بهترین محدوده همانگونه که در جدول ۳ مشخص می باشد بین ۶ تا ۱۵ به دست آمد.

جدول ۳- نتایج حاصل از شبکه عصبی BP


تعداد نرون لایه پنهان اول	تعداد نرون لایه پنهان دوم	iteration	train				test			
			MSEtrain	MAEtrain	SSEtrain	Rtrain	MSEtest	MAEtest	SSEtest	Rtest
6	1	34	0.065	0.179	10.453	0.967	0.235	0.337	6.807	0.870
7	1	4221	0.078	0.186	12.570	0.960	0.267	0.408	7.736	0.861
8	1	13	0.064	0.181	10.318	0.968	0.167	0.324	4.848	0.921
9	1	42	0.068	0.189	10.880	0.966	0.246	0.357	7.140	0.872
10	1	27	0.068	0.186	10.912	0.966	0.274	0.400	7.938	0.851
11	1	855	0.068	0.169	10.946	0.965	0.259	0.357	7.499	0.855
12	1	17	0.068	0.188	10.899	0.966	0.264	0.368	7.651	0.850
13	1	46	0.067	0.180	10.856	0.966	1.563	0.622	45.317	0.673
14	1	10	0.059	0.167	9.465	0.971	0.262	0.359	7.598	0.872
15	1	10	0.066	0.189	10.654	0.972	0.346	0.448	10.048	0.860



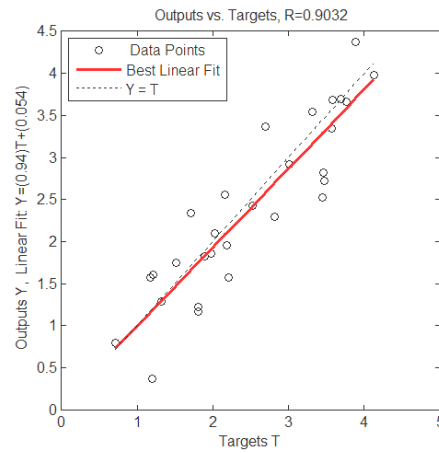
شکل ۷- نمودار مقادیر مطلوب و مقادیر حاصل از شبکه BP درمد آزمایش



شکل ۶- نمودار مقادیر مطلوب و مقادیر حاصل از شبکه BP درمد آموزش



شکل ۹- نمودار عملکرد داده های آموزش شبکه BP



شکل ۸- نمودار عملکرد داده های تست شبکه BP

جدول ۴- مقایسه نتایج حاصل از شبکه عصبی RBF و BP

نوع شبکه	train				test			
	MSEtrain	MAEtrain	SSEtrain	Rtrain	MSEtest	MAEtest	SSEtest	Rtest
شبکه RBF	0.04	0.141	6.41	0.98	0.249	0.357	7.22	0.89
شبکه BP	0.064	0.181	10.31	0.968	0.167	0.324	4.84	0.92



۹. مقایسه نتایج حاصل از شبکه های عصبی RBF و BP

در شکل های ۲، ۳، ۴ و ۷ برای دو مد آموزش و تست مقادیر خروجی مطلوب و خروجی حاصل از هر دو نوع شبکه برای هر ورودی ترسیم شده است همان طور که از شکل مشخص می باشد منحنی های خروجی مطلوب و خروجی شبکه مطابقت خوبی با هم دارند. در شکل های ۴، ۵، ۸ و ۹ برای هر دو مد آموزش و تست مقدار واقعی در مقابل خروجی شبکه ترسیم شده است که خطوط رسم شده در این اشکال نشان دهنده نتایج مطلوب شبکه می باشد. با توجه به اشکال و جداول ترسیم شده در بالا که به طور خلاصه در جدول ۴ آمده است ملاحظه می شود خطای آموزش و تست شبکه RBF کمی نسبت به شبکه BP کمتر می باشد بنابراین نتیجه می شود در این مقاله شبکه عصبی RBF نسبت به شبکه BP عملکرد بهتری داشته است.

۱۰. نتیجه گیری

در این تحقیق با استفاده از شبکه های عصبی RBF و BP مدلی ارائه گردید که قادر می باشد مقاومت فشاری ۲۸ روزه بتن با مقاومت بالا را با دقت مناسبی پیش بینی نماید. مدل هایی که تاکنون برای پیش بینی مقاومت فشاری بتن با مقاومت بالا ارائه شده اند موضعی بوده و فقط بر روی نمونه های شخص آزمایش کننده خطای کمی را به دست می دهد و اگر همین مدل ها را به صورت کلی برای پیش بینی مقاومت بتن در نظر بگیریم احتمالاً با خطای قابل ملاحظه ای همراه خواهد بود.

۱۱. مراجع

1. Kasperkiewicz, J., Racz, J., and dubrawski, A., (1995), "HPC Strength Prediction Using Artificial Neural Network", Journal of Computing in Civil Engineering, Vol. 9, No. 4, pp. 279-284.
۲. کاوه، ع، ایرانمنش، ع، "شبکه های عصبی مصنوعی در بهینه سازی سازه ها"، مرکز تحقیقات ساختمان و مسکن ۱۳۷۸
۳. منهاج، م، "مبانی شبکه های عصبی"، مرکز نشر پروفیسور حسابی ۱۳۷۸
4. Broomhead, D.S. and Lowe, D., (1998), "Multivariable Functional Interpolation and Adaptive Networks", Complex Systems, Vol. 2, pp 321-355.
5. Wasserman, P. D. (1993) "Advanced Methods in Neural Computing", USA: Prentic Hall Company, Van Nostrand Reinhold, New York.