

## پیش‌بینی مشخصات سخت شده بتن خودتراکم الیافی به کمک شبکه‌های عصبی مصنوعی

جواد برنجیان<sup>۱</sup>، نویدرضا فروهر<sup>۲\*</sup> و محسن قاسمی<sup>۳</sup>

<sup>۱</sup> استادیار، گروه آموزشی مهندسی عمران، مؤسسه آموزش عالی غیر انتفاعی طبری، بابل، ایران

<sup>۲</sup> دانشجوی کارشناسی ارشد، گروه آموزشی مهندسی عمران، مؤسسه آموزش عالی غیر انتفاعی طبری، بابل، ایران

<sup>۳</sup> دانشجوی کارشناسی ارشد، گروه آموزشی مهندسی عمران، مؤسسه آموزش عالی غیر انتفاعی طبری، بابل، ایران

frouharnavid@gmail.com

**چکیده:** امروزه روش‌های هوشمند و الهام گرفته از طبیعت در حل مسائل پیچیده طرفداران زیادی دارد یکی از پرطرفدارترین و کاراترین این ساختارها، شبکه‌های عصبی مصنوعی هستند که قادرند یک رابطه کلی بین اطلاعات حجیم و پیچیده ناشی از آزمایش‌ها و مثال‌های تجربی به دست آورند. از طرف دیگر، ترکیب بتن الیافی با بتن خودتراکم، یک نوع بتن جدید با سیالیت بالا و چسبندگی خوب تولید می‌کند. این نوع بتن به علت حضور الیاف دارای مزایای فراوانی همچون، مقاومت بالا در برابر ضربه، خستگی، فرسایش و همچنین افزایش مقاومت کششی و خمشی و کاهش جدا شدگی می‌باشد. در این تحقیق با در نظر گرفتن اجزای طرح اختلاط بتن به عنوان ورودی شبکه‌ها و مدل سازی دو نوع شبکه عصبی، یکی تابع بنیادی شعاعی و دیگری شبکه عصبی بازگشتی نارکس برای پیش‌بینی مشخصات سخت شده بتن استفاده شد. برای آموزش هر چه بهتر شبکه‌ها، ۴۰ طرح اختلاط بتن خودتراکم الیافی، توسط سه نوع الیاف فولادی، شیشه و پلی پروپیلن ساخته شد. مقایسه نتایج آزمایشات و خروجی شبکه، بیانگر آن است که هر دو شبکه از دقت کافی در تخمین مشخصات سخت شده بتن خودتراکم برخوردار می‌باشند و شبکه عصبی بازگشتی نارکس دارای خطای کمتری نسبت به شبکه عصبی تابع بنیادی شعاعی می‌باشد.

**کلمات کلیدی:** پیش‌بینی، شبکه عصبی مصنوعی، بتن خودتراکم الیافی، مشخصات سخت شده.

## Prediction the Hardened Properties of Fiber-Reinforced Self-Compacting Concrete Using Artificial Neural Networks

J. Berenjjan, N.R. Frouhar and M. Ghasemi

**Abstract:** Nowadays, intelligent methods inspired from nature are implemented to resolve complex problems, there are very popular too. The most common one is artificial neural network; they are capable to collect huge amount of complex information through experiments and tests. On the other hand, combination of fiber concrete with self-consolidating concrete produces a new product with high fluidity and good adhesion. Due to the presence of fibers, this type of concrete presents high-quality advantages such as high resistance to impact, high fatigue performance, low rate of erosion, enhances the tensile and flexural strengths and reduces the segregation. In this study by considering the components of the concrete mix design as networks input and two kinds of neural network modelling, a Radial Basis function and a recurrent neural network (NARX) for predicting the properties of hardened concrete, were used. To improve networks training, 40 concrete mix fibers reinforced self-consolidating concrete and three fiber types including steel fibers, glass and polypropylene, were prepared. Comparison of experimental results and network outputs indicate that both networks have the sufficient accuracy in estimating the hardened properties of self-consolidating concrete and recurrent neural network (NARX) error is less than Radial Basis Function Neural Network.

**Keywords:** Prediction, Artificial Neural Network, Fiber-Reinforced Self-Compacting Concrete, Hardened Properties .

## ۱- مقدمه

شبکه‌های عصبی مصنوعی شامل یک سری عملگرهای محاسباتی هستند که نحوه کار آنها مشابه سیستم‌های عصبی بیولوژیکی است. هر شبکه عصبی از یک سری ورودی، تعدادی لایه پنهان و یک لایه خروجی تشکیل شده است. ورودی‌های شبکه پس از ورود به لایه پنهان در آنجا مورد پردازش قرار گرفته و پس از خروج از لایه خروجی، به پاسخ شبکه تبدیل می‌شود [۵]. شبکه عصبی به وسیله الگوریتمی که با استفاده از تنظیم و تغییر مقدار وزن در اتصالات نرون‌ها عمل می‌کند، روابط بین داده‌ها را کشف می‌کند و تغییر وزن را تا جایی که مقدار خطا بین مقادیر واقعی و خروجی شبکه به مقدار مطلوب برسد، تکرار می‌کند [۶].

### ۱-۲- شبکه ایستا<sup>۱</sup>

شبکه عصبی مصنوعی را می‌توان به دو دسته ایستا (استاتیکی) و پویا (دینامیکی)<sup>۱</sup> تقسیم‌بندی نمود. شبکه‌های ایستا فاقد اجزای پسخوردی<sup>۱۱</sup> و تأخیری<sup>۱۲</sup> می‌باشند و خروجی آن‌ها مستقیماً از طریق اتصالات شبکه تعیین می‌شود [۷].

#### ۱-۱-۲- شبکه‌های عصبی تابع بنیادی شعاعی<sup>۱۳</sup>

یکی از شبکه‌های عصبی ایستا، شبکه مصنوعی عصبی تابع بنیادی می‌باشد. این نوع توابع اولین بار توسط پاول<sup>۱۴</sup> به عنوان راه‌حلی برای مسائل درون‌یابی چندمتغیری معرفی شدند. بروم هد<sup>۱۵</sup> و لوو<sup>۱۶</sup> در سال ۱۹۸۸ و همچنین مودی<sup>۱۷</sup> و دار کن<sup>۱۸</sup> در سال ۱۹۸۹ اولین کسانی بودند که از تابع پایه شعاعی در طراحی شبکه‌های عصبی استفاده کردند. شبکه‌های عصبی تابع بنیادی شعاعی تقریب سازهای بسیار قدرتمندی هستند؛ به طوری که با داشتن تعداد نرون کافی در لایه میانی، قادر به تقریب سازی هر تابع پیوسته‌ای با هر درجه از دقت می‌باشند. این شبکه‌ها تنها با داشتن یک لایه مخفی دارای چنین خاصیتی هستند؛ در حالی که در سایر انواع شبکه‌ها با تعبیه چندین لایه مخفی به سختی می‌توان چنین خاصیتی را ایجاد نمود. هر گره لایه مخفی شامل یک تابع پایه شعاعی، به عنوان تابع انتقال<sup>۱۹</sup> می‌باشد [۸].

در هر گره لایه مخفی ابتدا فاصله اقلیدسی بین مراکز هر تابع و بردارهای ورودی باید محاسبه شود. منظور از فاصله اقلیدسی همان فاصله مستقیم بین دو نقطه در فضا می‌باشد. یکی از توابع شعاعی که کاربرد زیادی در شبکه عصبی RBF دارد، تابع گوسین است. نمودار و فرم ریاضی این تابع در

به دلیل پیچیدگی رفتار بتن و تغییر در مشخصات آن که ناشی از تغییر در کیفیت و کمیت مصالح و شرایط حاکم بر مسأله می‌باشد، ارائه طرح اختلاط مناسب با توجه به شرایط اجرا و نیازهای طرح بسیار پیچیده است. برآورد خواص بتن به عنوان ماده‌ای مرکب، به وسیله مدل‌های ریاضی و فیزیکی و همچنین بررسی تأثیر هر یک از اجزای طرح اختلاط در چگونگی تغییرات خواص آن همواره مورد توجه دانشمندان حوزه عمران بوده است. تکثر پارامترهای تأثیرگذار در خواص بتن و ارتباط عمدتاً غیرخطی پارامترهای تأثیرگذار با خواص بتن و نیز زمان طولانی برای تعیین برخی از خواص بتن از عمده دلایل این امر است؛ لذا روشی که بتواند عملکرد خواص میکانیکی و عوامل مربوط به دوام را به صورت همزمان بیان کند، می‌تواند دارای ارزش بالایی باشد [۱].

بوگا و همکاران به مقایسه عملکرد دو ابزار قدرتمند هوش مصنوعی<sup>۱</sup>، شبکه عصبی مصنوعی<sup>۲</sup> و سیستم تطبیقی نرو فازی<sup>۳</sup> جهت پیش‌بینی مشخصات میکانیکی و دوام (که عبارت‌اند از مقاومت فشاری، مقاومت کششی و نفوذ یون کلر در بتن حاوی روباره‌های ریز<sup>۴</sup>) پرداختند. نتایج حاکی از آن است که شبکه عصبی مصنوعی مقاومت فشاری، کششی و نفوذ یون کلر را به ترتیب با دقت ۹۷/۱، ۹۷/۰ و ۷۳/۳ درصد و سیستم تطبیقی نرو فازی به ترتیب ۶۷، ۶۷ و ۹۲/۲ درصد نسبت به مقادیر آزمایشگاهی مشاهده شده پیش‌بینی کردند [۲].

دانتاس و همکاران نیز در تحقیقی مجزا به پیش‌بینی مقاومت فشاری بتن حاوی نخاله‌های ساختمانی<sup>۵</sup>، در سنین ۳، ۷، ۲۸ و ۹۰ روز با استفاده از شبکه عصبی مصنوعی پرداخت. ۷۷/۷۶ درصد از کل داده‌ها جهت آموزش و مابقی برای آزمایش شبکه استفاده شد. شاخص آماری ضریب همبستگی<sup>۶</sup> برای دو مجموعه آموزش و آزمایش نسبت به نتایج مشاهده شده به ترتیب برابر ۰/۹۲۸ و ۰/۹۷۱ می‌باشد [۳].


در این تحقیق به منظور بررسی عملکرد دو نوع شبکه عصبی مصنوعی جهت پیش‌بینی ۶ ویژگی بتن خودتراکم ایافی<sup>۷</sup> (مقاومت فشاری در سنین ۷، ۲۸ و ۹۰ روزه، مقاومت کششی ۲۸ روزه، درصد جذب آب ۷۲ ساعته و وزن مخصوص سخت شده ۲۸ روزه) با استفاده از جعبه ابزار متلب<sup>۸</sup> پرداخته شد [۴].

## ۲- شبکه‌های عصبی مصنوعی

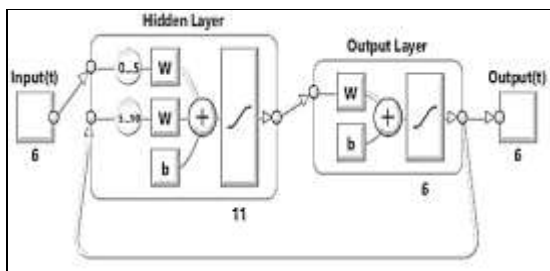
دسته‌ای از شبکه‌های عصبی بازگشتی به نام مدل‌های خود برگشتی غیرخطی با ورودی‌های برونزاد (نارکس)، ابداع شده است که علاوه بر توانایی در ذخیره اطلاعات، برای مشکل میرا شدن گرادیان نیز راه حلی دارد. در شبکه نارکس از نرون خروجی به ورودی شبکه پس‌خورده وجود دارد، و واحدهای تأخیر موجود در مسیر این پس‌خورده سبب تأخیر در میرا شدن گرادیان می‌شود. مشخص شده است که توانایی یادگیری نارکس و عملکرد تعمیم آن، نسبت به سایر شبکه‌های بازگشتی، بالاتر است. مدل نارکس علاوه بر ورودی‌های درونزاد، دارای ورودی‌های برونزاد است و با رابطه ۲ توصیف می‌شود:

$$\hat{y}(t+1) = f(y(t), \dots, y(t-D_y), u(t), \dots, u(t-D_u)) + \varepsilon_t \quad (2)$$

که در اینجا جملات  $u(t), \dots, u(t-D_u)$  ورودی‌های برونزاد هستند که توسط یک تأخیر زمانی با مرتبه  $D_u$  تولید می‌شوند. به‌طور مشابه  $y(t), \dots, y(t-D_y)$  ورودی‌های درونزاد را تشکیل می‌دهند و با تأخیری با مرتبه  $D_y$  از خروجی شبکه نارکس تولید می‌شوند.  $f$  یک تابع غیر خطی است که مقدار بعدی  $y(t)$  یعنی  $\hat{y}(t+1)$  را تخمین می‌زند.  $\varepsilon_t$  نویز (ثابت) جمع شونده تخمین است. ساختار غیر خطی پرسپترون چند لایه یک شبکه عصبی بازگشتی نارکس در شکل ۳ نشان داده شده است. مزیت شبکه نارکس بر دیگر شبکه‌های بازگشتی آن است که پس‌خورده‌ها به طور مستقیم، خروجی را به ورودی ارتباط می‌دهند [۱۰]. شکل شماتیک شبکه نارکس در جعبه ابزار متلب به صورت شکل ۴ می‌باشد.



شکل ۲: شکل شماتیک شبکه RBF در نرم افزار متلب



شکل ۴: شکل شماتیک شبکه نارکس در نرم افزار متلب


شکل ۱ و رابطه ۱ نشان داده شده است. در این رابطه  $r$  شعاع و  $\sigma$  پهنای تابع می‌باشد که هر دوی آن‌ها مقادیر بزرگ‌تر از صفر دارند. در شبکه RBF شعاع همان فاصله اقلیدسی بین مرکز تابع و بردارهای ورودی می‌باشد که به صورت  $\|x_i - c_i\|$  نشان داده می‌شود [۹]. شکل شماتیک شبکه RBF در جعبه ابزار متلب به صورت شکل ۲ می‌باشد.

$$\varphi(r) = \exp\left(-\frac{\|x_i - c_i\|^2}{2\sigma^2}\right) \quad (1)$$


## ۲-۲- شبکه عصبی دینامیکی

در شبکه‌های پویا خروجی شبکه علاوه بر ورودی فعلی آن، به ورودی‌ها و خروجی‌های قبل نیز بستگی دارد. شبکه‌های پویا به دو دسته کلی تقسیم می‌شوند: شبکه‌هایی که فقط دارای اتصالات رو به جلو هستند و شبکه‌هایی که دارای اتصالات پس‌خورده می‌باشند. از نوع دوم عموماً تحت عنوان شبکه‌های بازگشتی یاد می‌شود [۷]. در حالت کلی، برای آنکه یک رفتار پویا برای یک سامانه پارامتری قابل یادگیری باشد، باید سه شرط برآورده شود، سامانه توان ذخیره اطلاعات را برای هر مدت دلخواه دارا باشد، سامانه در مقابل نویز پایدار باشد؛ منظور از نویز، هر نوسان ورودی است که دارای مقادیر تصادفی باشد یا به خروجی مطلوب نامربوط باشد و بتوان پارامترهای سامانه را در زمان محدود آموزش داد [۱۰].

### ۲-۲-۱- شبکه عصبی بازگشتی نارکس



شکل ۱: نمودار تابع گوسین



شکل ۳: یک مدل خودبازگشتی غیرخطی با ورودی برونزاد (نارکس)

### ۳-۲- آماده‌سازی داده‌ها

#### ۳-۱- برنامه آزمایشگاهی

برای جلوگیری از تغییر دانه‌بندی و رطوبت حین انجام کار، کلیه مصالح مورد نیاز طرح در ابتدا تهیه و به صورت یکجا دیو شدند. ریزدانه (ماسه) مصرفی در این تحقیق از نوع رودخانه‌ای بابل با چگالی ۲۵۵۰ کیلوگرم بر متر مکعب، جذب آب ۲ درصد و ارزش ماسه‌ای ۸۵/۶۵ می‌باشد. مصالح درشت دانه (شن) از نوع شکسته دولومیتی آمل با جذب آب ۱/۴ درصد با بزرگترین اندازه سنگدانه ۱۹/۵ میلی‌متر و چگالی ۲۶۰۰ کیلوگرم بر متر مکعب می‌باشد. منحنی دانه بندی شن و ماسه با رعایت استاندارد ASTM C33 به ترتیب در شکل‌های ۵ و ۶ نشان داده شده است. سیمان مورد استفاده سیمان تیپ II نکا می‌باشد که دارای دانسیته برابر با ۳/۱۵ کیلوگرم بر متر مکعب است. در این تحقیق از پودر سنگ آهک به منظور کاهش تخلخل و افزایش درجه توپیری بتن با دانسیته ۲/۷ به عنوان عنصر فیلر (پرکننده) استفاده به عمل آمد. مشخصات شیمیایی میکروسلیس، به عنوان جایگزین درصدی از سیمان و پودر سنگ و سیمان در جدول ۱ و مشخصات فیزیکی و میکانیکی الیاف در جدول ۲ مشخص شده است. آب مصرفی از آب آشامیدنی شهر بابل استفاده شده است، همچنین برای دستیابی به روانی مورد نیاز برای بتن خودتراکم، از فوق روان کننده با پایه کربوکسیلاتی با قابلیت حفظ اسلامپ بالا، محصول شرکت طراحان بتن پایدار با نام تجاری WBK-50 استفاده شد.

داده‌های شبکه عصبی از ۴۰ طرح اختلاط شامل ۳ سری به ترتیب ۵، ۱۰، ۱۵ درصد وزنی جایگزین سیمان میکروسلیس، که در هر سری شامل ۳ نوع الیاف به صورت ساده ( فلزی : ۰/۲۵ و ۰/۵ درصد حجمی و پلی پروپیلن : ۰/۰۷۵ و ۰/۱۵ درصد حجمی و شیشه : ۰/۰۷۵ و ۰/۱۵ درصد حجمی ) و ترکیبی ۲۲ است، ساخته شد.

#### ۳-۲- انتخاب و تقسیم مناسب داده‌ها

در این تحقیق شش پارامتر ورودی شبکه عصبی مصنوعی از طرح اختلاط بتن کار برداشت که عبارتند از : ۱- مقدار سیمان<sup>۲۳</sup> ۲- مقدار میکروسلیس<sup>۲۴</sup> ۳- مقدار فوق روان کننده<sup>۲۵</sup> ۴- مقدار وزنی الیاف فولادی<sup>۲۶</sup> ۵- مقدار وزنی الیاف پلی پروپیلن<sup>۲۷</sup> ۶- مقدار وزنی الیاف شیشه<sup>۲۸</sup> در یک متر مکعب بتن.

شش پارامتر خروجی شامل مشخصات بتن سخت شده می‌باشد که عبارتند از: ۱- مقاومت فشاری ۷ روزه<sup>۲۹</sup> ۲- مقاومت فشاری ۲۸ روزه<sup>۳۰</sup> ۳- مقاومت فشاری ۹۰ روزه<sup>۳۱</sup> ۴- مقاومت کششی ۲۸ روزه<sup>۳۲</sup> ۵- درصد جذب آب ۷۲ ساعته<sup>۳۳</sup> ۶- وزن مخصوص سخت شده ۲۸ روزه<sup>۳۴</sup>.

از بین ۴۰ مجموعه زوج داده آزمایشگاهی، ۹۰ درصد زوج داده‌ها (۳۶ زوج) برای آموزش شبکه، و ۱۰ درصد زوج داده‌ها (۴ زوج) که شبکه با آن آموزش داده نشده باشد، برای آزمایش انتخاب می‌شود. این داده‌ها باید به گونه ای تقسیم‌بندی شده باشند که خصوصیات آماری تقریباً یکسانی داشته باشند [۱۱]. به این منظور، پنج دفعه نمونه‌های چهارتایی از مجموعه چهل-تایی به طور تصادفی انتخاب شد. شکل ۷ اختلاف میانگین مجموعه آموزش و آزمایش را، که به عنوان یکی از معیارهای انتخاب سری آزمایش می‌باشد، نشان می‌دهد. سری چهارم به علت دارا بودن کمترین اختلاف نسبت به مجموعه آموزش، انتخاب می‌شود. خصوصیات آماری سری چهارم که شامل میانگین، انحراف از معیار<sup>۳۵</sup>، ماکزیمم، مینیمم و دامنه است در جدول ۳ نشان داده شده است.

#### ۳-۳- پیش پردازش داده‌ها<sup>۳۶</sup>

در این قسمت قبل از آموزش مدل، داده‌ها نرمالیزه<sup>۳۷</sup> می‌شوند. نرمالیزه کردن داده‌ها برای به حداقل رساندن تأثیر اختلاف مقیاس پارامترهای مختلف و اطمینان از یکسان بودن بازه پارامترها می‌باشد [۱۲].

دلیل دیگر نرمالیزه کردن این است که شیب تابع محرک تنها به ازای مقادیر واقع در بازه [۰،۱] از دامنه قابل توجه بوده و در خارج از این بازه از تغییرات ناچیزی برخوردار است. به همین سبب جهت جلوگیری از اشباع شبکه، کلیه داد های مورد استفاده اعم از ورودی و خروجی به بازه {۰،۱} انتقال داده شده‌اند [۱۳]. برای نرمالیزه کردن داده‌ها از تابع خطی ۳ استفاده شده است که داده‌ها را به مقیاس بین ۰-۱ می‌برد :

$$S_x = \frac{(z-z_{min})}{(z_{max}-z_{min})} \quad (3)$$

که در آن  $S_x$  مقدار نرمال شده متغیر  $z$ ،  $Z_{max}$  و  $Z_{min}$  به ترتیب مقادیر ماکزیمم و مینیمم این متغیر هستند [۱۴].

#### ۴- بررسی ساختار مدل و تحلیل نتایج

تعداد لایه و تعداد گره‌ها در هر لایه، معماری مدل را تشکیل می‌دهد؛ به عبارت دیگر معماری مدل، تعیین تعداد

پیش‌بینی مشخصات سخت شده بتن ...

که در آن  $\overline{obs}$  میانگین  $obs$  (مقادیر مشاهده شده) و  $\overline{calc}$  میانگین  $calc$  (مقادیر محاسبه شده توسط شبکه) و  $n$  برابر تعداد داده‌ها در هر مرحله آزمون‌های آزمایش و آموزش می‌باشد [۱۶].

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$

که  $y_i$  مقادیر پیش‌بینی شده،  $\hat{y}_i$  مقادیر مشاهداتی و  $n$  تعداد داده‌ها می‌باشد. هر چه مقدار  $MSE$  مقادیر کمتری داشته باشد و مقدار  $R$  ۱ باشد، نشان دهنده آن است که مدل نزدیک‌تر به خطای کمتری نسبت به پیش‌بینی مقادیر آزمایشگاهی اقدام می‌نماید [۱۷]. اسمیت<sup>۳۹</sup> در سال ۱۹۸۶ این پیشنهاد را که  $R$  باید بین اعداد ۰ تا ۱ باشد مطرح کرد:

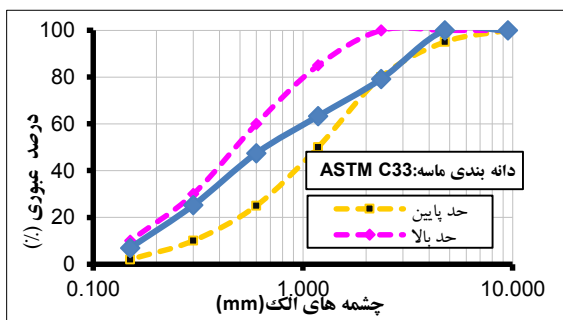
- زمانی که  $|R| \geq 0/8$ : ارتباط قوی بین دو مجموعه از متغیرها وجود دارد.
- زمانی که  $0/2 < |R| < 0/8$ : ارتباط بین دو مجموعه از متغیرها وجود دارد.
- زمانی که  $|R| \leq 0/2$ : ارتباط ضعیف بین دو مجموعه از متغیرها وجود دارد [۱۸].

جدول ۱: مشخصات شیمیایی


L.O.I	CaCO <sub>3</sub>	K <sub>2</sub> O	Fe <sub>2</sub> O <sub>3</sub>	Al <sub>2</sub> O <sub>3</sub>	SiO <sub>2</sub>	Na <sub>2</sub> O	SO <sub>3</sub>	MgO	CaO	ترکیبات مصالح
۱/۰۵	-	۰/۶۳	۳/۱۹	۴/۹۵	۲۱/۲۵	۰/۳۸	۲/۰۴	۱/۲۰	۶۴/۰۷	سیمان
۲/۱	-	-	۲	۱/۵۵	۹۱/۱۰	-	۰/۴۵	۰/۶۵	۲/۲۴	میکروسلیس
-	۹۹/۳	-	۰/۰۲	۰/۱	۰/۳	-	-	۰/۰۲	-	پودرسنگ آهک

جدول ۲: مشخصات فیزیکی و مکانیکی الیاف

جنس الیاف	شکل ظاهری	وزن مخصوص $gr/cm^3$	مدول یانگ $kg/cm^2 \times 10^5$	مقاومت کششی $kg/cm^2$	طول (mm)	قطر (mm)	نسبت منظر
شیشه	صاف	۲/۵	۷/۲	۱۴۰۰۰	۱۲	۰/۰۲	۶۰۰
فولادی	دوطرف قلابدار	۷/۸	۱۶	۲۱۰۰۰	۳۶	۰/۷	۵۰
پلی پروپیلن	صاف	۰/۹۱	۰/۵	۴۵۰۰	۶	۰/۱	۶۰



شکل ۶: دانه بندی ماسه



شکل ۵: دانه بندی شن

لایه بهینه و تعداد گره‌ها در هر لایه است. برای تعیین معماری بهینه شبکه عصبی، تئوری مشخصی وجود ندارد و عموماً معماری مدل با ثابت کردن تعداد لایه‌ها و انتخاب تعداد گره‌ها در هر لایه قابل دسترسی است [۱۱].

#### ۴-۱- معیار مقایسه مدل‌ها

پس از اتمام فرآیند آموزش مدل‌ها، عملکرد آن‌ها توسط داده‌هایی که در فرآیند آموزش استفاده نشده‌اند (داده آزمایش) مورد آزمون قرار می‌گیرند. آزمایش مدل‌ها به منظور اطمینان از توانایی مدل در کلیت بخشی در محدوده داده‌های موجود صورت می‌گیرد [۱۵]. نتایج ارزیابی پیش‌بینی مدل‌ها به کمک دو شاخص آماری، ضریب همبستگی در رابطه ۴ و میانگین مربعات خطا<sup>۳۸</sup> در رابطه ۵ ارائه شده است.

$$R = \frac{\sum_{i=1}^n (\overline{obs} - \overline{obs})(\overline{calc} - \overline{calc})}{\sqrt{\sum_{i=1}^n (\overline{obs} - \overline{obs})^2 \sum_{i=1}^n (\overline{calc} - \overline{calc})^2}} \quad (4)$$

جدول ۳: خصوصیات آماری سری چهارم


پارامترها	انحراف معیار	میانگین	دامنه	ماکزیمم	مینیمم
ورودی ها					
سیمان (عیار)(کیلوگرم در متر مکعب)					
آموزشی	14/68	365/57	52/2	400	347/8
آزمایشی	15/80	360/04	33/15	380/95	347/8
میکروسیلیس(کیلوگرم در متر مکعب)					
آموزشی	14/66	34/41	52/17	52/17	0
آزمایشی	15/79	39/93	33/12	52/17	19/05
مقدار فوق روان کننده(کیلوگرم در متر مکعب)					
آموزشی	0/57	4/28	2/34	5/45	3/11
آزمایشی	0/67	4/51475	1/5	5/5	4
الیاف فولادی (کیلوگرم در متر مکعب)					
آموزشی	10/02	8/77	39	39	0
آزمایشی	16/96	14/62	39	39	0
الیاف پلی پروپیلن (کیلوگرم در متر مکعب)					
آموزشی	0/395	0/24	1/365	1/365	0
آزمایشی	0/68	0/56	1/365	1/365	0
الیاف شیشه (کیلوگرم در متر مکعب)					
آموزشی	1/22	0/79	3/75	3/75	0
آزمایشی	0/62	0/31	1/25	1/25	0
مقاومت فشاری ۷ روزه (کیلوگرم بر سانتی متر مربع)					
آموزشی	52/60	404/41	200/5	500	299/5
آزمایشی	37/42	400/875	81	437/5	356/5
مقاومت فشاری ۲۸ روزه (کیلوگرم بر سانتی متر مربع)					
آموزشی	62/36	583/19	225	684	459
آزمایشی	40/32	569/5	91/5	603	511/5
مقاومت فشاری ۹۰ روزه (کیلوگرم بر سانتی متر مربع)					
آموزشی	68/22	606/44	243	718	475
آزمایشی	44/063	589/62	100/5	626	525/5
مقاومت کششی ۲۸ روزه (کیلوگرم بر سانتی متر مربع)					
آموزشی	7/45	51/36	31/5	66	34/5
آزمایشی	6/37	54	14	63	49
جذب آب ۷۲ ساعته (درصد)					
آموزشی	0/171	1/59	0/643	1/914	1/271
آزمایشی	0/167	1/54	0/33	1/723	1/393
وزن مخصوص سخت شده ۲۸ روزه (گرم بر سانتی متر مکعب)					
آموزشی	0/0581	2/294	0/2941	2/3967	2/1026
آزمایشی	0/1177	2/297	0/2878	2/4436	2/1558

پیش‌بینی مشخصات سخت شده بتن ...

نتایج حاصل از آموزش شبکه‌های عصبی RBF و نارکس، در دو دسته آموزش و آزمایش در جدول‌های ۴ و ۵ نشان داده شده است. برای مقایسه این شبکه‌ها در شرایط مختلف (شعاع و نرون متفاوت)، از معیارهای ارزیابی میانگین مربعات خطا (MSE)، ضریب همبستگی (R) و شیب نمودار (m) بین خروجی شبکه مربوطه و نتایج آزمایشگاهی، استفاده شد.

مشخصات شبکه بهینه RBF و نارکس در جدول ۶ نشان داده شده است. البته به شبکه‌ای بهینه گفته می‌شود که دارای کمترین مقدار MSE و نزدیکترین مقدار R و m به ۱، در حالت آزمایش باشد.

نمودار همبستگی نتایج آزمایشگاهی نسبت به خروجی-های شبکه بهینه عصبی نارکس و تابع بنیادی شعاعی در شکل‌های ۸ و ۹ در حالات آموزش و آزمایش برای همه پارامترها نشان داده شده است. جدول ۷ مقدار عددی خروجی هر دو شبکه بهینه را با نتایج آزمایشگاهی نشان می‌دهد.



شکل ۷: اختلاف میانگین مجموعه آموزش و آزمایش پنج سری تصادفی


## ۴-۲- تحلیل نتایج

جدول ۴: معیارهای ارزیابی شبکه RBF در حالت‌های آموزش و آزمایش

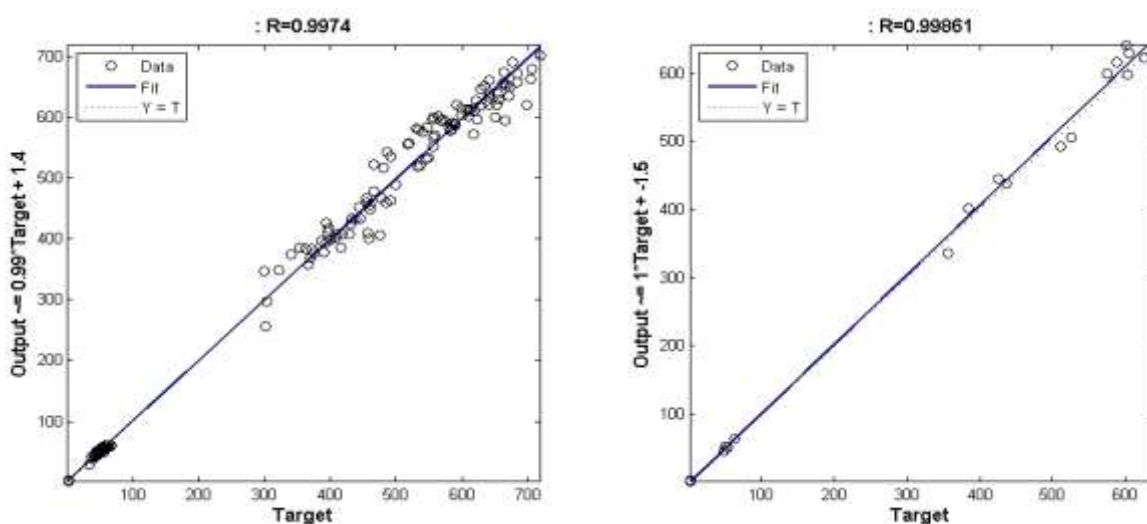
Net Name	Spreads	MSE(train)	R(train)	m(train)	MSE(test)	R(test)	m(test)
RBF01	0/1	1/65E-27	1	1	780/83	0/99483	0/97
RBF1	1	3/15E-22	1	1	834/21	0/99387	1
RBF10	10	1/07E-09	1	1	18979	0/87892	0/76
RBF100	100	29/86	0/9998	1	283/36	0/99837	1
RBF1000	1000	131/28	0/99909	1	483/65	0/99745	1
RBF <sub>e4</sub>	e4	374/28	0/9974	0/99	223/0121	0/99861	1
RBF <sub>e5</sub>	e5	374/28	0/9974	0/99	223/0155	0/99861	1
RBF <sub>e6</sub>	e6	374/42	0/9974	0/99	223/2467	0/99861	1
RBF <sub>e7</sub>	e7	430/63	0/99701	0/99	235/81	0/99866	1
RBF <sub>e8</sub>	e8	1841/8	0/98712	0/97	707/74	0/99527	1

جدول ۵: معیارهای ارزیابی شبکه نارکس در حالت‌های آموزش و آزمایش

Net Name	Neuron Number	MSE(train)	R(train)	m(train)	MSE(test)	R(test)	m(test)
nx1	1	647.6038	0/99553	0/98	287.7590	0/99824	1
nx2	2	200.4624	0/99861	1	294.6889	0/99843	1
nx3	3	215.7257	0/9985	1	495.3024	0/99652	1
nx4	4	231.9081	0/99839	1	1.8452e+03	0/99233	1/1
nx5	5	180.9186	0/99879	0/99	607.2945	0/99583	1
nx6	6	158.1051	0/9989	1	571.7991	0/99769	1
nx7	7	112.1900	0/99923	1	702.0475	0/99483	1
nx8	8	123.3826	0/99922	1	557.7850	0/99612	0/98
nx9	9	159.1935	0/9989	0/99	204.3558	0/99891	1
nx10	10	82.4899	0/99943	1	1.1590e+03	0/99155	1
nx11	11	92.4050	0/99936	1	126.5522	0/99935	1
nx12	12	148.0309	0/99897	1	513.0134	0/99704	1



شکل ۸: نمودار همبستگی داده‌های آزمایشگاهی با نتایج شبکه بهینه نارکس در حالت:  
الف: آموزش      ب: آزمایش



شکل ۹: نمودار همبستگی داده‌های آزمایشگاهی با نتایج شبکه بهینه تابع بنیادی شعاعی در حالت:  
الف: آموزش      ب: آزمایش

جدول ۶: مشخصات شبکه بهینه RBF و نارکس

نوع شبکه	نام شبکه بهینه	تابع انتقال لایه پنهان	تابع انتقال لایه خروجی	تعداد نرون در لایه ورودی	تعداد نرون در لایه پنهان	تعداد نرون در لایه خروجی	شعاع	الگوریتم آموزش	زمان تأخیر	بیشترین تکرار شکست متوالی
RBF	RBFE4	RBF	PURLINE	6	36	6	10000	-	-	-
NARX	NX11	TANSIG	TANSIG	6	11	6	-	LM	[0 5]- [5 10]	100



جدول ۷: خروجی‌های شبکه بهینه RBF و نارکس

مشخصه پیش‌بینی شده	شماره نمونه	1	2	3	4
FC7	آزمایشگاهی	384	356/5	425/5	437/5
	NARX	379/028494	349/108872	440/211877	458/523167
	RBF	401/081884	335/234612	444/916516	437/831534
FC28	آزمایشگاهی	575	511/5	588/5	603
	NARX	564/997086	514/833252	600/726127	625/705971
	RBF	599/750174	492/219725	615/661909	597/719431
FC90	آزمایشگاهی	605	525/5	602	626
	NARX	593/061747	529/509027	629/424999	649/028848
	RBF	628/100996	504/959078	640/363723	621/656343
SS28	آزمایشگاهی	54	49	63	50
	NARX	55/351348	41/596119	62/1219474	54/9794532
	RBF	50/321016	45/1216215	63/6353034	52/4461116
WAb72	آزمایشگاهی	1/651	1/393	1/723	1/41
	NARX	1/71887407	1/45908326	1/72938763	1/49704762
	RBF	1/67448922	1/40637403	1/80261985	1/54646891
ρ	آزمایشگاهی	2/3025	2/1558	2/4436	2/2864
	NARX	2/31073417	2/2127448	2/38229298	2/26230622
	RBF	2/30573701	2/16334145	2/4229599	2/26511256

#### ۵- نتیجه‌گیری

- میانگین خطای کل شبکه نارکس و RBF نسبت به داده‌های مشاهداتی آزمایشگاهی به ترتیب برابر با ۳/۴۰۷ و ۳/۴۵۸ درصد می‌باشد و این نکته قابل توجه است که شبکه‌های عصبی مصنوعی دینامیکی نسبت به استاتیکی از دقت بیشتری برخوردارند و مدل دینامیکی پیش‌بینی دقیق‌تری ارائه می‌دهد.
- به طور کلی مقایسه روش‌های گردایانی آموزش مدل نارکس نشان می‌دهد که روش لونیگ-مارکوارت نسبت به روش‌های دیگر نتایج بهتری دارد.
- مقایسه نتایج مدل‌های عصبی نشان می‌دهد که مدل نارکس با مقدار کل MSE (۱۲۶) نسبت به مدل RBF با مقدار کل MSE (۲۲۳) در پیش‌بینی مشخصات بتن دقت بالاتری دارد.
- مدل نارکس در پیش‌بینی همه مشخصات بتن خودتراکم الیافی به جز مقاومت کششی ۲۸ روزه و وزن مخصوص سخت شده نسبت به RBF بهتر عمل کرده است.
- همان‌طور که مشاهده می‌شود آموزش شبکه نارکس دارای پیچیدگی‌های بیشتری نسبت به RBF در قسمت طراحی می‌باشد. به علت وجود تأخیرها و پس‌خوردها آموزش آن نیز طولانی می‌باشد و همچنین مقدار زمانی را که برای تعیین شبکه بهینه برای نارکس صرف می‌شود بسیار بیشتر از RBF است؛ لذا پیشنهاد می‌شود برای تخمین سریع جواب، از مدل سازی استاتیکی RBF استفاده شود. اما از لحاظ دقت و عملکرد مناسب، شبکه‌های دینامیکی نارکس در اولویت قرار دارند.
- یکی از محدودیت‌های شبکه عصبی نیاز همیشگی این شبکه‌ها در کارهای عملی به آموزش مجدد (به روز کردن) است تا تغییرات جدید را در بر گیرند و مجدداً پیش‌بینی با دقت بالا صورت گیرد. همچنین این روش‌ها در صورت استفاده از برون‌یابی دارای خطای بیشتری هستند به دلیل اینکه داده‌ها در محدوده‌ای خارج از محدوده داده‌های آموزش یافته قرار می‌گیرد. بدیهی است هرچقدر که پایگاه داده‌های آموزشی در

## مراجع

- [1] سبحانی، ب. طریقت، ا. "مدلسازی شبکه عصبی مصنوعی برای طرح اختلاط بتن‌های توانمند،" هفتمین کنگره ملی مهندسی عمران، دانشکده مهندسی شهید نیکبخت، زاهدان، ایران، ۱۷ و ۱۸ اردیبهشت ماه، ۱۳۹۲.
- [2] Boga, A.R et al., "Using ANN and ANFIS to predict the mechanical and chloride permeability properties of concrete containing GGBFS and CNI "Composites: Part B 45, pp.688-696, 2013.
- [3] Dantas, A.T.A et al., "Prediction of compressive strength of concrete containing construction and demolition waste using artificial neural networks "Construction and Building Materials, No. 38, pp. 717-722, 2013.
- [4] Matlab. Neural networks toolbox user guide; 2013.
- [5] Hashash, Y., Hook, J. J., Schmidt, B., Yao J. I. C., "Seismic design and analysis of underground Structures," Tunneling Underground Space Technology, No. 16, pp. 247-293, 2001.
- [6] R. Toufouti, S. Meziane, H. Benalla., " Direct Torque Control for Induction Motor using Intelligent Techniques", JATIT, pp. 35-44, 2007.
- [7] سید مصطفی کیا، " شبکه‌های عصبی در MATLAB"، چاپ چهارم نشر کیان رایانه سبز، ۱۳۹۰.
- [8] موسی امجد س، "پیش‌بینی سطح عملکرد قاب‌های فولادی با اتصال نیمه صلب در برابر نیروهای لرزه‌ای با استفاده از شبکه‌های عصبی مصنوعی"، پایان‌نامه کارشناسی ارشد سازه، دانشگاه سیستان و بلوچستان، ایران، ۱۳۹۰.
- [9] منہاج، م ب، "مبانی شبکه‌های عصبی"، انتشارات دانشگاه امیرکبیر، چاپ پنجم، ۱۳۸۷.
- [10] بهارلو، ر، "پیش‌بینی سری زمانی با وابستگی‌های دراز مدت با استفاده از شبکه عصبی بازگشتی نارس،" دوازدهمین کنفرانس دانشجویی مهندسی برق، پژوهشگاه بین‌المللی زلزله شناسی و مهندسی زلزله، ۱۳۸۸.
- [11] عربی، م، و همکاران، " پیش‌بینی رفتار شمع‌ها در برابر نشست بر مبنای مقاومت برشی زهکشی نشده خاک با استفاده از هوش مصنوعی،" هفتمین کنگره ملی مهندسی عمران، دانشکده مهندسی شهید نیکبخت، زاهدان، ایران، ۱۷ و ۱۸ اردیبهشت ماه، ۱۳۹۲.
- [12] Masters, T., "Practical neural network recipes in C++", Academic Press, San Diego, California, 1993.

طی زمان افزایش یابد، نتایج پیش‌بینی واقعی تر و پاسخ شبکه عصبی بهتر خواهد بود.

- مقایسه نتایج آزمایشات و خروجی شبکه، بیانگر آن است که با استفاده از این شبکه‌ها، با صرف هزینه‌ای اندک، بدون آزمایشات وقت‌گیر و طی مدت زمان کم، می‌توان مشخصات سخت شده بتن خودتراکم الیافی را با دقت خوبی پیش‌بینی نمود.

## پی‌نوشت

- <sup>1</sup> Artificial Intelligence ( AI
- <sup>2</sup> Artificial Neural Network ( ANN )
- <sup>3</sup> Adaptive Neuro-Fuzzy Inference System ( ANFIS )
- <sup>4</sup> Ground-Granulated Blast Furnace Slag ( GGBFS )
- <sup>5</sup> Construction and Demolition Waste ( CDW )
- <sup>6</sup> Coefficient of Correlation ( R )
- <sup>7</sup> Fiber-Reinforced Self Consolidating Concrete (FRSCC)
- <sup>8</sup> MATLAB Toolbox
- <sup>9</sup> Static Network
- <sup>10</sup> Dynamic Network
- <sup>11</sup> Feedback
- <sup>12</sup> Delay
- <sup>13</sup> Radial Basis Function (RBF)
- <sup>14</sup> Powell
- <sup>15</sup> Broomhead
- <sup>16</sup> Lowe
- <sup>17</sup> Moody
- <sup>18</sup> Darken
- <sup>19</sup> Transfer Function
- <sup>20</sup> Recurrent
- <sup>21</sup> Nonlinear Autoregressive Network with Exogenous Inputs
- <sup>22</sup> Hybrid
- <sup>23</sup> Cement ( C )
- <sup>24</sup> Silica Fume ( SF )
- <sup>25</sup> Super Plasticizer ( SP )
- <sup>26</sup> Steel Fiber ( ST )
- <sup>27</sup> Polypropylene Fiber ( PP )
- <sup>28</sup> Glass Fiber ( GL )
- <sup>29</sup> Compressive Strength ( FC7 )
- <sup>30</sup> ( FC28 )
- <sup>31</sup> ( FC 90 )
- <sup>32</sup> Tensile Strength ( SS28 )
- <sup>33</sup> Water Absorption ( WAb72 )
- <sup>34</sup> ( ρ )
- <sup>35</sup> Standard Deviation (SD)
- <sup>36</sup> Data Preprocessing
- <sup>37</sup> Normalization
- <sup>38</sup> Mean Square Error ( MSE )
- <sup>39</sup> Smith

پیش‌بینی مشخصات سخت شده بتن ...

[۱۶] درواری، ز. سلیمانی، ک. "شبیه‌سازی جریان رودخانه با استفاده از شبکه عصبی مصنوعی (ANN) (مطالعه موردی حوضه معرف کسلیان) "نهمین سمینار سراسری آبیاری و کاهش تبخیر، کرمان، بهمن، ۱۳۸۶.

[۱۷] حسین پور، م. و همکاران، "رأورد ظرفیت برشی تیرهای بتن آرمه تقویت شده توسط پلیمرهای مسلح شده به فیبر به روش شبکه‌های عصبی مصنوعی" اولین کنفرانس ملی مهندسی صنایع و سیستم‌ها، دانشگاه آزاد واحد نجف آباد، ۲۹ و ۳۰ آذر، ۱۳۹۱.

[18] Smith, M., "Neural networks for statistical modelling." Van NostrandReinhold, New York, N. 1993.

[۱۳] رمضانی، ف.، "پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی،" پایان‌نامه کارشناسی ارشد مهندسی عمران گرایش آب، دانشکده عمران، دانشگاه امیرکبیر، ۱۳۸۵.

[14] Arsalan, MH., " Prediction of torsional strength of RC beams by using different artificial neural network algorithms and building codes", Advances in Engineering Software, Vol.41 pp. 946-55, 2010.

[15] Pooya Nejad F, Mark B. Jaks, Kakhi M, McCabe Bryan A., "Prediction of pile settlement using artificial neural networks based on standard penetration test data," Computers and Geotechnics, Vol. 36, pp.1125-1133, 2009.