

پیش‌بینی مقاومت فشاری بتن با استفاده از شبکه‌های فازی-عصبی چند جمله‌ای

جعفر سبحانیⁱ؛ محمد حسین فاضل زرنندیⁱⁱ؛ علی اکبر رمضانیانپورⁱⁱⁱ

چکیده

در این مقاله، روشی برای تخمین مقاومت بتن بر اساس نتایج آزمایشگاهی موجود ارائه شده است. هدف از این مقاله، ارائه ساختار "شبکه‌های عصبی-فازی چند جمله‌ای" و نشان دادن چگونگی استفاده از این ساختار در پیش‌بینی مقاومت فشاری بتن است. در این مقاله، چگونگی آموزش ساختار مذکور با استفاده از الگوریتم ترکیبی پس انتشار خطا و حداقل مربعات خطا بررسی شده است. گام‌های مختلف ساخت و تولید شبکه و همچنین الگوریتم آموزشی آن در متن مقاله ارائه شده است. ویژگی دیگر این روش، استفاده از روش دسترسی گروهی داده‌ها در توسعه بخش تالی شبکه می‌باشد. ساختار فازی این روش از قواعد مخصوصی تشکیل شده است که در آن، بخش مقدم، یک شبکه فازی-عصبی و بخش تالی قواعد آن از شبکه‌های عصبی-چند جمله‌ای تشکیل می‌شود. در این مقاله، شش ساختار از این نوع برای تخمین پیش‌بینی مقاومت نمونه‌های بتنی ارائه و قابلیت هر کدام از ساختارهای طراحی شده برای این منظور با استفاده از معیارهای مرسوم آماری، آزمون انجام شده است.

کلمات کلیدی

شبکه‌های عصبی-فازی چند جمله‌ای، پس انتشار خطا، حداقل مربعات خطا، مقاومت فشاری بتن

Compressive Strength Prediction of Concrete: A Soft Computing Approach

J. Sobhani, M. H. Fazel Zarandi, A. A. Ramezaniyanpour

ABSTRACT

In this paper, an approach is introduced for prediction of the strength of the concrete mixes. The core of the proposed method is based on the fuzzy rule-based systems. The rule-base of the proposed system is a simple if-then rule, but its antecedents and consequences are of different type. The antecedent of the rule is a Fuzzy Neural Network (FNN) and its consequence is Fuzzy Polynomial Neural Network (PNN). In this method, these two parts are combined through the networks nodes (FNN, PNN) to construct the Fuzzy Polynomial Neural Network (FPNN). At the body of the paper, the method of this process and the manner of the training of the FPNN is discussed. In this paper, six models constructed, trained, and tested using available concrete mixes data. The results show that the proposed model has strong potential for predicting the compressive strength of the concrete mixes as a preliminary design tool.

KEYWORDS

fuzzy polynomial neural network, concrete strength, back propagation, least square estimating

ⁱ دانشجوی دکتری عمران سازه، دانشکده عمران و محیط زیست، دانشگاه صنعتی امیرکبیر: j_sobhani@aut.ac.ir

ⁱⁱ دانشیار دانشکده صنایع، دانشگاه صنعتی امیرکبیر: zarandi@cic.aut.ac.ir

ⁱⁱⁱ استاد دانشکده عمران و محیط زیست دانشگاه صنعتی امیرکبیر: aaramce@cic.aut.ac.ir

مهندسی باشیم. با وجود کاربرد این روش‌ها در مهندسی عمران نسبت به رشته‌های مهندسی از قبیل برق یا شیمی اندکی دیرتر آغاز شده است؛ لیکن امروزه شاهد تحقیقات بسیار فزاینده‌ای در شاخه‌های مختلف مهندسی عمران با استفاده از روش‌های هوش محاسباتی هستیم. در اینجا چندین کاربرد از هوش مصنوعی بویژه شبکه‌های عصبی مصنوعی را در زمینه پیش بینی خواص بتن ارایه می‌کنیم. در سال ۱۹۹۸، چنگ به [۶] با استفاده از نوع خاصی از شبکه عصبی با نرون‌های افزایشی مدلی ارایه کرد که قادر به پیش‌بینی مقاومت فشاری بتن معمولی باشد. در این مدل هفت پارامتر نسبت آب-به-سیمان، مقدار آب، مقدار سیمان، مقدار ریزدانه، مقدار درشت دانه، اندازه درشت دانه‌ها و سن بتن اعضای بردار ورودی به شبکه عصبی در نظر گرفته شده بود. در سال ۱۹۹۹، وُن‌اَه و همکاران [۸] روشی برای تعیین طرح اختلاط بتن معمولی ارایه کردند. در سال ۱۹۹۹، بسما و همکاران [۱۲] مدلی مبتنی بر شبکه‌های عصبی ارایه کردند که با استفاده از الگوریتم آموزش پس‌انتشار خطا قادر به پیش‌بینی درجه هیدراتاسیون سیمان بود. در سال ۲۰۰۰، کاوه و خالقی [۳] یک شبکه عصبی را که قادر به پیش‌بینی مقاومت فشاری بتن با عملکرد بالا بود، ارایه کردند. رمضانیاپور و طریقت [۱۳] نیز با کمک شبکه عصبی مدلی برای کربناتاسیون بتن ارایه داده‌اند. قابوسی و همکاران [۱۴] با ذکر توانایی‌های شبکه‌های عصبی و بررسی آن، استفاده از این مدل‌ها را در حل مسائل مربوط به مدل‌سازی رفتار مواد پیشنهاد دادند. وُن‌اَه [۸] از شبکه‌های عصبی برای تعیین طرح بتن معمولی (شامل آب، سیمان، شن، و ماسه) استفاده کرد. در کارهای جداگانه کاسپرکیویچ و همکاران [۴] و مستوفی‌نژاد و سمعی نژاد [۹] به برآورد مشخصات بتن با مقاومت بالا؛ که شامل یک افزودنی و میکروسیلیس بود، پرداختند. در تحقیق دیگری، یه [۶] به برآورد مشخصات بتن معمولی با استفاده از تغییر ساختار شبکه عصبی و بهبود عملکرد آن پرداخت. سیستم خبره‌ای را نیز برای ارایه طرح بتن و اقدامات اصلاحی، باعی و امیرخانیان [۱۱] با توجه به شرایط موردنیاز در محل سایت و هنگام اجرا نظیر ماکزیمم اندازه درشت‌دانه، درصد هوا، مقدار خاکستر بادی، دمای هوا و مدت زمان تحویل تهیه و ارایه کرده‌اند. در سال ۲۰۰۰ داور پناه و رمضانیاپور [۷] برای برآورد مشخصات بتن و همچنین بهینه سازی آن از دو نوع شبکه عصبی استفاده کردند. در این تحقیق از شبکه‌های پرسپترون چند لایه بالگوریتم آموزش پس انتشار خطا و همچنین شبکه‌های عصبی رگراسیون تعمیم یافته برای پیش‌بینی مشخصات بتن استفاده کردند.

در این مقاله، روش نوینی برای مدل‌سازی سیستم‌ها به منظور پیش‌بینی مقاومت فشاری نمونه‌های بتنی ارایه شده است. ساختار مدل پیشنهادی، بر اساس قواعد اگر-آنگاه ماکرو است. این قواعد از دو بخش مرسوم مقدم و تالی ترکیب شده است؛ اما در این نوع قواعد، بخش مقدم یک شبکه فازی-عصبی و بخش تالی آن از یک شبکه عصبی چند جمله‌ای تشکیل شده است. دو بخش مذکور به ترتیب با استفاده از روش پس انتشار خطا و روش حداقل مربعات آموزش داده و پارامترهای آنها تنظیم می‌شود. ویژگی این سیستم خود ساماندهی و تغییر ساختار در طی مرحله آموزش است. به طور کلی، هدف اصلی در این نوع مدل‌سازی‌ها، استفاده از مقادیر قابل توجهی از اطلاعات موجود از طرح اختلاط‌های بتن برای پیش‌بینی نتایج مقاومت فشاری طرح‌های جدید است. در مدل‌های مرسوم ریاضی، به تعیین دقیق پارامترها و همچنین روابط بین آنها نیاز است که این کار از نظر عملی مشکل است و از جامعیت کافی برخوردار نیست. امروزه به جای استفاده از مدل‌های دقیق ریاضی؛ که مشکلاتی نظیر محدودیت در تعداد پارامترهای ورودی به سیستم دارد، از سیستم‌های مدل‌سازی موسوم به هیوربستیک استفاده می‌شود [۱]، [۲]. توسعه سیستم‌هایی از قبیل شبکه‌های عصبی برای تعیین مقاومت بتن [۲]-[۷]، طرح اختلاط بتن [۸]-[۱۱]، و شبیه‌سازی رفتار مصالح [۱۲]-[۱۴]، کاربرد سیستم‌های خبره [۱۱] و شبکه‌های تطبیقی ANFIS [۱۵] دارای سابقه چندین ساله دارد.

هدف از این مقاله، توسعه یک ساختار نوین بر اساس مفاهیم فازی، چند جمله‌ای‌ها و شبکه‌های عصبی برای پیش‌بینی مقاومت بتن بر حسب مصالح تشکیل دهنده بتن است. بر این اساس، ابتدا ساختار شبکه فازی-عصبی (FNN) به عنوان بخش مقدم سیستم و سپس شبکه عصبی-چندجمله‌ای (PNN) به عنوان بخش تالی سیستم معرفی و جزئیات مربوط به طراحی سیستم و نحوه آموزش آن بحث می‌شود. در انتها با استفاده از سیستم طراحی شده و داده‌های آزمایشگاهی جمع آوری شده از منابع مختلف سیستم تعلیم و آزموده شده و در جداول و نمودارهای مناسبی کیفیت و قابلیت سیستم طراحی شده نمایش داده می‌شود.

۲- مروری بر ادبیات

قابلیت‌های مختلف هوش محاسباتی سبب شده است که شاهد گسترش فزاینده این روش‌ها در رشته‌های مختلف

$$\hat{y} = \sum_{i=1}^m f_i(x_i) \quad (1)$$

که m تعداد متغیرهای ورودی است. از این دیدگاه، می‌توان تابع f_i را به عنوان قواعد نگاشت به صورت زیر در نظر گرفت:

$$\begin{aligned} R1 : & \text{ If } x_i \text{ is } A_{i1} \text{ Then } y_{i1} = w_{i1} \\ R2 : & \text{ If } x_i \text{ is } A_{i2} \text{ Then } y_{i2} = w_{i2} \\ & \dots \dots \dots \\ Rj : & \text{ If } x_i \text{ is } A_{ij} \text{ Then } y_{ij} = w_{ij} \\ & \dots \dots \dots \\ R^n : & \text{ If } x_i \text{ is } A_{in} \text{ Then } y_{in} = w_{in} \end{aligned} \quad (2)$$

به طوریکه، R^j ، j -امین قاعده، A_{ij} به معنی متغیر فازی، و A_{ij} به عنوان وزن فازی-نرون مربوطه می‌باشد. (شکل ۱). چنانچه از روش مرکز سطح برای استنتاج فازی مجموعه قواعد (۲) استفاده کنیم، خواهیم داشت:

$$f_i(x_i) = \frac{\sum_{j=1}^n \mu_{ij}(x_i) \cdot w_{ij}}{\sum_{j=1}^n \mu_{ij}(x_i)} \quad (3)$$

آموزش FNN با تنظیم وزن‌های (w_{ij}) انجام می‌گیرد. برای آموزش سیستم بر روی تابع اقلیدسی خطا (ϵ) از الگوریتم پس انتشار خطا بهره می‌گیریم.

$$E_p = (y_p - \hat{y}_p)^2 \quad (4)$$


که E_p تابع خطای اقلیدسی داده p -ام، و y_p و \hat{y}_p به ترتیب p -امین تابع هدف خروجی واقعی و خروجی مدل می‌باشد. علاوه بر این در این مطالعه، برای N دسته داده ورودی و خروجی اندیس خطای زیر تعریف می‌شود:

$$E_p = \frac{1}{N} \sum_{p=1}^N (y_p - \hat{y}_p)^2 \quad (5)$$

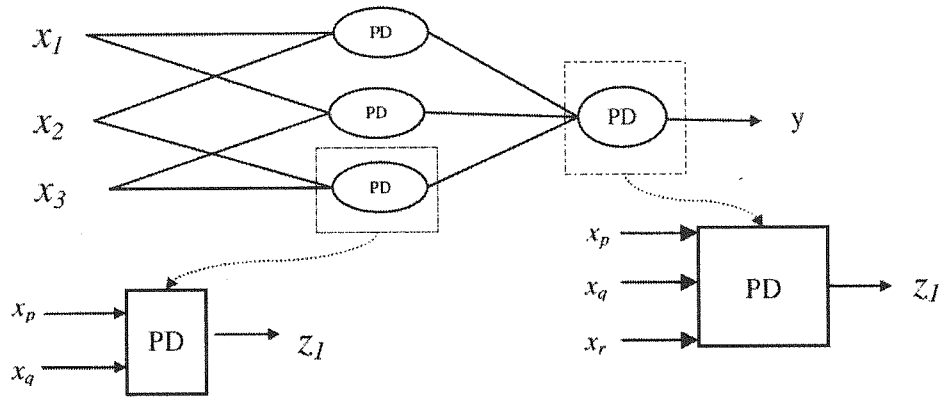
در این مقاله، ساختاری مرکب از سیستم‌های فازی، شبکه‌های عصبی، و چند جمله‌ای‌هایی با درجات مختلف و به نام شبکه‌های فازی-عصبی چند جمله‌ای (FPNN) ارائه شده است. در این مطالعه، ساختار ترکیبی مذکور برای پیش‌بینی مقاومت بتن پیشنهاد شده است. اساساً FPNN از دو قسمت اصلی تشکیل شده است: شبکه فازی-عصبی (FNN) و شبکه عصبی چندجمله‌ای (PNN). این سیستم دارای ساختار قاعده مبنا است که در آن FNN به عنوان مقدم و PNN به عنوان تالی قواعد عمل می‌کند. بخش مقدم این ساختار از یک سیستم استنتاج فازی و روش پس انتشار خطا استفاده می‌کند. بخش مقدم دو نقطه اتصال به بخش تالی سیستم دارد. بخش تالی سیستم بر اساس روش دسترسی گروهی داده‌ها (GMDH) ساخته می‌شود. سیستم FPNN ساختار انعطاف‌پذیر دارد که در طی فرآیند آموزش توپولوژی آن بر حسب معیارهای کیفی آموزشی قابل اصلاح است.

۳-۱- شبکه‌های عصبی-فازی (FNN)

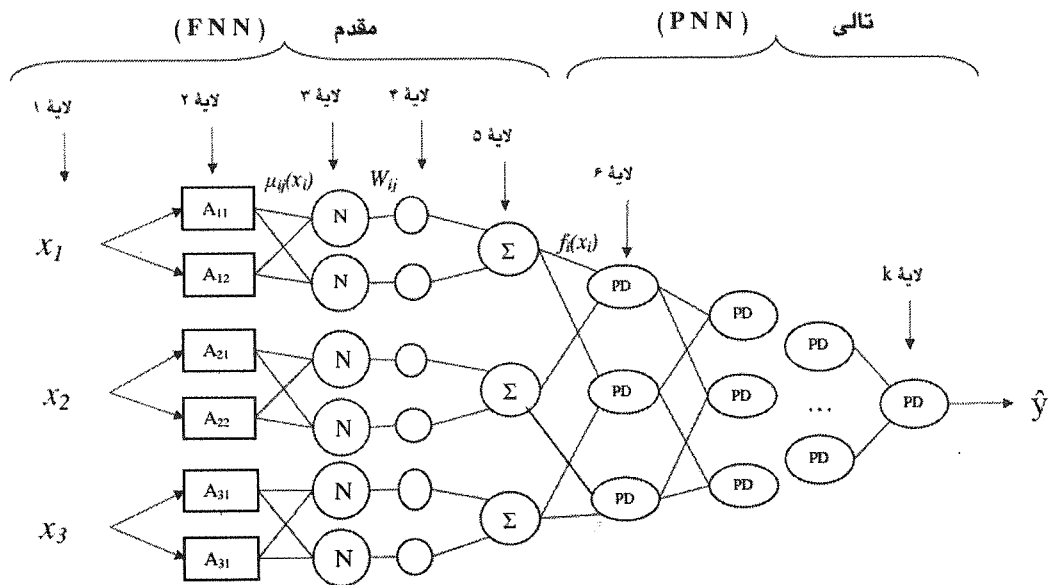
قبلاً گفته شد، بخش مقدم سیستم مورد نظر، یک شبکه فازی-عصبی (FNN) است. در شکل (۱)، ساختار کلی شبکه فازی-عصبی نشان داده شده است. این ساختار یک پارتیشن‌بندی فازی روی مجموعه ورودی‌های مسأله انجام می‌دهد. در این شکل، علامت N داخل دایره کار نرمال‌سازی را بر روی مقادیر عضویت $\mu_{ij}(x_i)$ متغیر x_i را انجام می‌دهد. خروجی $f_i(x_i)$ مربوط به نرون " Σ " توسط چندین تابع غیر خطی f_i بدست می‌آید. در نهایت، \hat{y} به عنوان خروجی FNN با استفاده از معادله زیر محاسبه می‌شود:



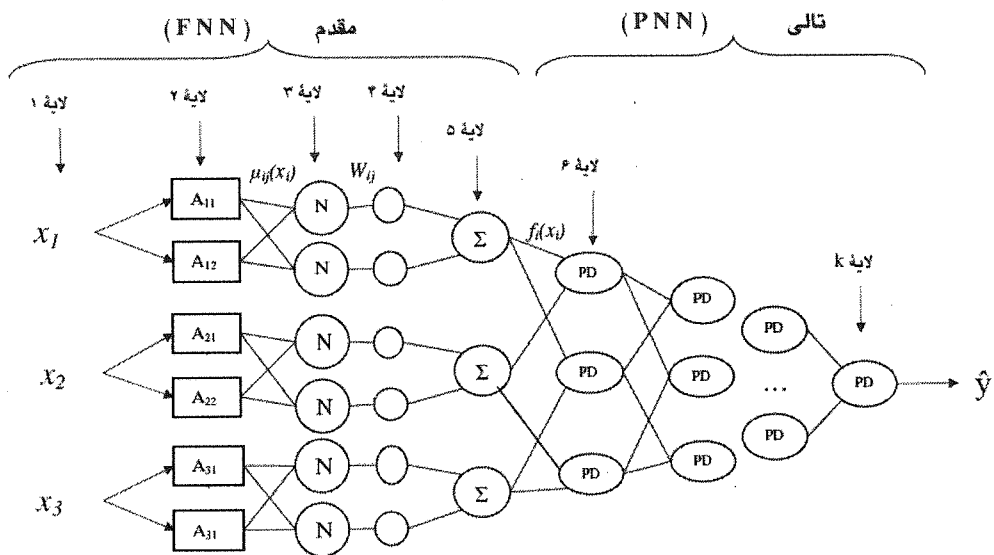
شکل (۱): ساختار فازی-عصبی بخش مقدم سیستم (FNN) به همراه دو نقطه اتصال محتمل



شکل (۲): نمونه ای از ساختار شبکه عصبی-چند جمله ای (PNN) به عنوان بخش تالی سیستم



شکل (۳): ترکیب بخش مقدم و تالی سیستم از موقعیت ۱ (FPNN-Type1)



شکل (۴): ترکیب بخش مقدم و تالی سیستم از موقعیت ۲ (FPNN-Tpe2)

لم- فرمول تنظیم وزن اتصالات نرون‌های FNN عبارت است از [۲]:

$$\Delta w_{ij} = 2\eta \cdot (y_p - \hat{y}_p) \cdot \mu_{ij}(x_i) + \alpha(w_{ij}(t) - w_{ij}(t-1)) \quad (6)$$

به طوری که α و η به ترتیب ضریب مومنتوم و نرخ آموزش شبکه هستند که اعدادی مثبت و کمتر از یک می باشند.

۳-۲- شبکه عصبی-چندجمله ای (PNN)

همان طوری که قبلاً ذکر شد، PNN به عنوان بخش تالی ساختار قاعده مبنای سیستم عمل می‌کند. اساس کار PNN بر روش دسترسی گروهی داده‌ها (GMDH) بنا نهاده شده است که در این روش کلاسی، از چندجمله‌ای‌ها استفاده می‌شود که اصطلاحاً آن را جزئی-تعریف شده (PDS) می‌نامند [۲]. مثالی از این چند جمله‌ای‌های جزئی-تعریف شده در جدول (۱) نشان داده شده است. با انتخاب نمونه‌های خاصی از این چندجمله‌ای‌ها با مراتب مشخص شده در جدول و انتخاب دو گره در هر لایه می‌توان بهترین نوع PD-ها را برای مسأله خاص به دست آورد. رابطه بین ورودی و خروجی؛ که به وسیله الگوریتم PNN حاصل می‌شود با رابطه زیر محاسبه می‌شود:

$$y = f(x_1, x_2, \dots, x_n) \quad (7)$$

مقدار خروجی تخمینی \hat{y} از داده واقعی (آزمایشگاهی) y عبارت است از:

$$\hat{y} = \hat{f}(x_1, x_2, \dots, x_n) = c_0 + \sum_{k1} c_{k1} x_{k1} + \sum_{k1k2} c_{k1k2} x_{k1k2} + \sum_{k1k2k3} c_{k1k2k3} x_{k1k2k3} + \dots \quad (8)$$

به طوری که C_{ks} ضرایب مدل هستند که قرار است با سیستم طراحی شده بهینه شود. شکل (۲) مثالی از ساختار PNN را نشان می‌دهد. در جدول (۱) تعدادی از چندجمله‌ای‌های قابل استفاده در سیستم نشان داده شده است. در این جدول منظور از Type I مرتبه اول (چند جمله ای خطی)؛ Type II مرتبه ۲ (کوادراتیک) و Type III به معنی چندجمله‌ای اصلاح شده می‌باشد. در مورد اخیر، برای ساده‌سازی استفاده و کاهش زمان محاسبات از بعضی از جملات صرفه نظر شده است.

۳-۳- شبکه فازی-عصبی چندجمله ای (FPNN)

گام بعدی ترکیب دو ساختار قبلی برای ساخت شبکه فازی-عصبی چندجمله‌ای است. برای این منظور، دو موقعیت ممکن برای ترکیب FNN و PNN وجود دارد که در شکل (۱) نشان داده شده است. برای ساخت یک FPNN، می‌توان از هر

دو موقعیت ممکن استفاده کرد. شکل‌های (۳) و (۴)، به ترتیب ساختارهای نهایی FPNN را با توجه به اتصال FNN و PNN از موقعیت‌های اتصال ۱ و ۲ را نشان می‌دهد. تفاوت این دو ساختار در ورودی‌های آن به PDها می‌باشد؛ که در این مورد، به ترتیب w_i و f_i ورودی PDهای لایه‌های بعدی را تشکیل می‌دهند. فرآیند طراحی برای هر لایه (نشان داده شده در شکل‌های (۴) و (۵))، در بخش مقدم و تالی FPNN عبارت است از:

بخش مقدم FPNN:

لایه ۱- در این لایه، سیگنال‌های ورودی مستقیماً به سمت گره‌های لایه بعدی انتشار می‌یابد.

لایه ۲- در این لایه، هر گره به یک متغیر فازی در لایه ۱ ارتباط داده می‌شود. در این لایه، مقدار تحریک ورودی بر حسب متغیر فازی مربوطه تعیین می‌شود.

لایه ۳- در این لایه، حاصل مقادیر فعال شده در لایه قبل با استفاده از فرمول زیر نرمال‌سازی می‌شود:

$$\bar{\mu}_{ij} = \mu_{ij} / \sum_{j=1}^n \mu_{ij} \quad (9)$$

لایه ۴- مقادیر نرمال محاسبه شده در لایه ۳ در وزن اتصالات ضرب می‌شود:

$$a_{ij} = \bar{\mu}_{ij}(x_i) \times w_{ij} \quad (10)$$

در صورت اتصال از موقعیت اتصال ۱ برای ایجاد ساختار FPNN (شکل ۳)، a_{ij} به عنوان متغیر ورودی به PNN است؛ ولی در صورت اتصال از موقعیت اتصال ۲، a_{ij} مربوط به سیگنال ورودی لایه خروجی FNN به عنوان متغیر ورودی PNN خواهد بود (شکل ۴).

لایه ۵- در این لایه، روش استنتاج فازی مرکز سطح به خروجی قواعد اعمال می‌شود:

$$f_i(x_i) = \sum_{j=1}^n a_{ij} / \sum_{j=1}^n \mu_{ij}(x_i) = \sum_{j=1}^n \mu_{ij}(x_i) \cdot w_{ij} / \sum_{j=1}^n \mu_{ij}(x_i) \quad (11)$$

در صورت انتخاب موقعیت اتصال ۲ (شکل ۴)، f_i متغیر ورودی PNN به عنوان تالی ساختار FPNN خواهد بود.

لایه خروجی FNN- خروجی FNN در این لایه به وسیله فرمول زیر محاسبه می‌شود:

$$y = f_1(x_1) + f_2(x_2) + \dots + f_n(x_n) = \sum_{i=1}^m f_i(x_i) \quad (12)$$

ورودی		
مواد طرح اختلاط	دامنه (در واحد وزن)	
	حداقل	حداکثر
شن (CA)	۰/۱۸۷۶۱۸	۰/۵۸۷۴۶۹
ماسه (FA)	۰/۰۱۱۲۵۴	۰/۵۶۴۷۱
ماده فوق روان کننده (SP)	۰	۰/۰۱۷۰۴۵
میکروسیلیس (SF)	۰	۰/۱۵۲۱۰۵
آب (W)	۰/۰۰۶۸۹۲	۰/۲۱۸۴۷۸
سیمان (C)	۰/۰۴۱۲۰۲	۰/۵۲۸۹۶۴
خروجی		
خصوصیات مکانیکی	دامنه (مگا پاسکال)	
	حداقل	حداکثر
مقاومت ۲۸ روزه	۲/۸	۱۳۵

تعداد ورودی ها	نوع	چند جمله ای
2	I	$C_0 + C_1x_1 + C_2x_2$
	II	$C_0 + C_1x_1 + C_2x_2 + C_3x_1^2 + C_4x_2^2 + C_5x_1x_2$
	III	$C_0 + C_1x_1 + C_2x_2 + C_3x_1x_2$
3	I	$C_0 + C_1x_1 + C_2x_2 + C_3x_3$
	II	$C_0 + C_1x_1 + C_2x_2 + C_3x_3 + C_4x_1^2 + C_5x_2^2 + C_6x_3^2 + C_7x_1x_2 + C_8x_1x_3 + C_9x_2x_3$
	III	$C_0 + C_1x_1 + C_2x_2 + C_3x_3 + C_4x_1x_2 + C_5x_1x_3 + C_6x_2x_3$
4	I	$C_0 + C_1x_1 + C_2x_2 + C_3x_3 + C_4x_4$
	II	$C_0 + C_1x_1 + C_2x_2 + C_3x_3 + C_4x_4 + C_5x_1^2 + C_6x_2^2 + C_7x_3^2 + C_8x_4^2 + C_9x_1x_2 + C_{10}x_1x_3 + C_{11}x_1x_4 + C_{12}x_2x_3 + C_{13}x_2x_4 + C_{14}x_3x_4$
	III	$C_0 + C_1x_1 + C_2x_2 + C_3x_3 + C_4x_4 + C_5x_1x_2 + C_6x_1x_3 + C_7x_1x_4 + C_8x_2x_3 + C_9x_2x_4 + C_{10}x_3x_4$

$$Y = [y_1 \ y_2 \ \dots \ y_{n_r}]^T \quad (18)$$

$$X_i = [X_{i1} \ X_{i2} \ \dots \ X_{ki} \ \dots \ X_{n_i}]^T$$

در رابطه فوق؛

$$X_{ki}^T = [x_{ki1} \ x_{ki2} \ \dots \ x_{kin} \ \dots \ x_{ki1}^m \ x_{ki2}^m \ \dots \ x_{kin}^m]^T \quad (19)$$

و

$$C_i = [C_{0i} \ C_{1i} \ C_{2i} \ C_{3i} \ \dots \ C_{n_i}]^T \quad (20)$$

بطوریکه، i شماره گره، n_r تعداد زیر مجموعه داده های آموزشی، n تعداد مقادیر منتخب ورودی، m ماکزیم مرتبه و n' تعداد ضرایب تعیین شده به جز ضریب ثابت چندجمله ای است.

فاز ۴- سرانجام در این فاز، PDهایی با بهترین قابلیت پیش بینی انتخاب می شوند. در نهایت بر اساس اندیس ارایه شده در رابطه (۵)، سعی می شود بهترین PD انتخاب گردد.

۴- جمع آوری داده های طرح اختلاط بتن

در اصل هدف از این تحقیق، توسعه سیستمی به نام FPNN برای پیش بینی مقاومت فشاری نمونه های بتن بر حسب مواد موجود در طرح اختلاط آن است. بدین منظور، لازم است بانک اطلاعاتی مناسبی برای ایجاد مجموعه داده های آموزشی و آزمایشی به مانند سایر روش های مدل سازی؛ مانند شبکه های عصبی و رگرسیون جمع آوری شود. در این تحقیق، داده های مختلفی از منابع گوناگون جمع آوری شده است. این منابع شامل نتایج آزمایشگاهی از کشورهای ایران و لهستان می باشد. در مجموع، از ۴۹۲ رکورد آزمایشگاهی، ۳۲۸ مورد برای مجموعه آموزشی و ۱۵۴ نمونه برای آزمایش سیستم اختصاص داده شده است. البته، انتخاب هر کدام دسته از داده ها به صورت

گام های محاسباتی بخش تالی FPNN عبارتند از:

فاز ۱- در این فاز، متغیرهای ورودی بخش تالی سیستم مشخص می شود. اگر موقعیت ۱ انتخاب شود، a_{ij} به عنوان متغیر ورودی بخش تالی سیستم خواهد بود؛ بنابراین:

$$x_1 = a_{11}, x_2 = a_{12}, \dots, x_n = a_{1j} \quad (n = i \times j) \quad (12)$$

همچنین در صورتی که موقعیت اتصال ۲ انتخاب شود، f_i به عنوان متغیر ورودی به بخش تالی سیستم خواهد بود:

$$x_1 = f_1, x_2 = f_2, \dots, x_n = f_m \quad (n = m) \quad (14)$$

فاز ۲- در این فاز، ساختار PNN، یعنی متغیرهای ورودی و مرتبه PDها شکل داده می شود؛ برای مثال، یک PD با سه ورودی و چندجمله های مرتبه ۲ را ممکن است به شکل زیر استفاده کنیم:

$$z_k = c_0 + c_1x_1 + c_2x_2 + c_3x_3 + c_4x_4 + c_5x_1^2 + c_6x_2^2 + c_7x_3^2 + c_8x_4^2 + c_9x_1x_2 + c_{10}x_1x_3 + c_{11}x_1x_4 + c_{12}x_2x_3 + c_{13}x_2x_4 + c_{14}x_3x_4 \quad (15)$$

در این رابطه C_1, C_2, \dots, C_{14} ضرایبی هستند که با استفاده از روش تخمین حداقل مربعات (LSE) [۲] محاسبه می شود.

فاز ۳- در این فاز، ضرایب PD برآورد می شود. با استفاده از زیر مجموعه داده ها، n_r مجموعه معادلات خروجی را می توان در هر لایه به صورت زیر نمایش داد:

$$Y = X_i C_i \quad (16)$$

حال، چنانچه از روش حداقل مربعات استفاده شود، ضرایب PDها با استفاده از رابطه زیر محاسبه می شود:

$$C_i = (X_i^T X_i)^{-1} X_i^T Y \quad (17)$$

به طوری که:

تصادفی انجام گرفته است تا از آموزش گمراه کننده و تأثیر سوء آن بر پروسه آموزش سیستم جلوگیری شود. پارامترهای ورودی سیستم به صورت مقادیر وزنی در واحد وزن بتن است و شامل (۱) شن (CA)، (۲) ماسه (FA) (۳) ماده فوق روان کننده (SP)، (۴) ماده میکروسیلیس (SF)، (۵) آب، (۶) سیمان

جدول (۳): ساختار مدل‌های مختلف FPNN

Cases	نرخ آموزش		نوع سیستم	خصوصیات PDها		بخش تالی					
	η	α		نوع	تعداد ورودی‌ها	تعداد PDهای فعال در لایه					
						z_1	z_2	z_3	z_4	z_5	z_6
Model 1	0.09	0.0001	FPNN-Type1	I	2	6	4	3	2	1	-
Model 2	0.125	0.001	FPNN-Type1	I	2	8	6	3	2	1	-
Model 3	0.125	0.001	FPNN-Type2	I	2	5	4	4	4	2	1
Model 4	0.115	0.002	FPNN-Type1	II	2	7	3	2	2	1	-
Model 5	0.115	0.002	FPNN-Type2	II	2	7	3	2	2	1	-
Model 6	0.119	0.023	FPNN-Type1	III	3	6	4	1	-	-	-

جدول (۴): مقایسه عملکرد و قابلیت پیش‌بینی مدل‌های مختلف

Cases	R.M.S.			ضریب همبستگی		
	کنترلی	آموزشی	آزمایشی	کنترلی	آموزشی	آزمایشی
Model 1	14.654	16.00	12.067	0.807	0.769	0.693
Model 2	14.665	16.01	11.682	0.807	0.769	0.716
Model 3	22.062	19.21	15.636	0.460	0.754	0.356
Model 4	12.491	14.69	10.659	0.864	0.810	0.771
Model 5	14.419	7.103	10.121	0.814	0.974	0.796
Model 6	11.688	14.44	9.5555	0.882	0.819	0.821

۶- داده‌های آموزشی، آزمایشی و کنترلی


مجموعه داده‌ها به صورت اتفاقی به دو دسته تقسیم شده است: ۳۲۸ داده آموزشی و ۱۵۴ داده آزمایشی. البته، در این تحقیق دسته داده دیگری را به صورت اتفاقی از بین هر دو دسته آموزشی و آزمایشی انتخاب و با نام نقاط کنترلی (CD) برای نظارت بر پیشرفت درست آموزش شبکه در داخل سیستم FPNN جای داده شده است. در این مقاله این دسته داده برای مانیتورینگ فرآیند آموزش بکار گرفته شده است (۹۸ داده). این کار تعادلی بین توانایی شبکه در تخمین و تعمیم‌دهی ایجاد می‌کند.

۷- فازی‌سازی فضای متغیرهای ورودی

در این مقاله، از سه متغیر کلامی (Small, Zero, and Big) برای تجزیه دامنه هر ورودی استفاده شده است. شکل (۶) توابع عضویت مربوط به ورودی‌ها را نشان می‌دهد. مقادیر a


۵- پیش‌بینی مقاومت فشاری بتن

سیستم FPNN ای که در این مقاله تشریح شد، به وسیله زبان برنامه نویسی مطلب پیاده‌سازی شده است. شکل (۷) ساختار شماتیک سیستم مورد نظر را نشان می‌دهد. موتور استنتاجی که در این شکل نشان داده شده، یک ساختار FPNN است که با استفاده از مجموعه داده‌های جمع آوری شده آموزش داده شده است.



شکل (۵): ساختار شماتیک سیستم پیش‌بینی کننده

b و c مربوط به توابع در جدول (۵) ارایه شده است.



شکل (۶): فازی سازی فضای متغیرهای ورودی اول (شن)

جدول (۵): پارامترهای توابع شکل

ورودی	a	b	c
شن	.1876	.3875	.5875
ماسه	.0114	.2880	.5647
فوق روان کننده	0	.0085	.0170
میکروسیلیس	0	.0761	.1521
آب	.0069	.1127	.2185
سیمان	.0412	.2851	.5290

$$RMS = \sqrt{\frac{\sum_{i=1}^P (f_{c_i} - \hat{f}_{c_i})^2}{P}} \quad (21)$$

در این معادله، P مجموع کل تعداد نمونه‌های بتنی، f_c مقاومت ۲۸ روزه نمونه‌های بتنی (آزمایشگاهی)، و \hat{f}_c مقاومت فشاری بتن پیش‌بینی شده با مدل پیشنهادی می‌باشد.

$$Corl.(f_c, \hat{f}_c) = \frac{cov(F_c, \hat{F}_c)}{\sqrt{cov(\hat{F}_c, \hat{F}_c) \cdot cov(F_c, F_c)}} \quad (22)$$



که،

$$F_c = (f_{c1}, f_{c2}, \dots, f_{cp}), \quad \hat{F}_c = (\hat{f}_{c1}, \hat{f}_{c2}, \dots, \hat{f}_{cp}) \quad (23)$$

و

$$cov(F_c, \hat{F}_c) = E[(F_c - \mu_c) \cdot (\hat{F}_c - \hat{\mu}_c)] \quad (24)$$


بطوریکه، $\mu_c = E(F_c)$ ، $\hat{\mu}_c = E(\hat{F}_c)$ ، E امید ریاضی است. جدول (۴)، خلاصه نتایج به دست آمده از مدل‌سازی‌ها را نشان می‌دهد. این جدول نشان می‌دهد که با استفاده از PDهایی با مراتب بالاتر به همراه تعداد ورودی بیشتر می‌توان نتایج بهتری به دست آورد. همچنین که در اشکال بعدی مشاهده می‌شود، عملکرد مدل‌ها مناسب است.



شکل (۸): مقایسه بین پیش‌بینی مدل ۶ با مقادیر واقعی

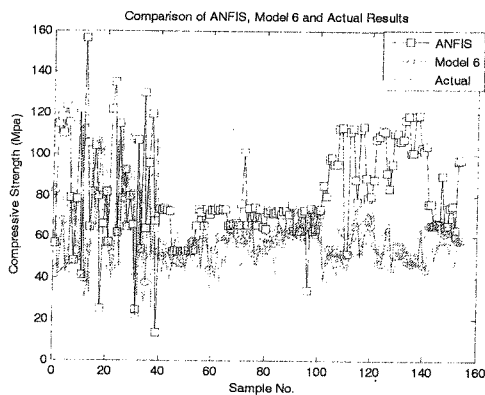
۸- آموزش و آزمایش مدل پیشنهادی

در این مرحله، روش پیشنهادی برای تخمین مقاومت فشاری بتن استفاده می‌شود. وزن‌های اولیه اتصالات شبکه بصورت اعداد تصادفی بین صفر و یک و همچنین برای نرخ‌های آموزش (η و γ) نیز اعدادی بین صفر و ۱ در نظر گرفته می‌شود. ساختار و جزئیات مدل پیش‌بینی کننده در جدول (۳) نشان داده شده است.



شکل (۷): مقایسه خروجی مدل ۶ نتایج واقعی آزمایشگاهی

نتایج مدل‌سازی در هر مورد جدول (۳) در جدول (۴) خلاصه شده است. در این جدول با استفاده از دو نرم RMS (معادله ۲۴) و همبستگی (معادله ۲۵) مقایسه‌ای بین قابلیت مدل‌ها انجام شده است.



شکل (۱۰): مقایسه بین پیش‌بینی مدل ۶ با نتایج مدل ANFIS و مقادیر واقعی


۹- خلاصه و نتیجه گیری

هدف اصلی از این تحقیق، استفاده از شبکه‌های فازی-عصبی چند جمله‌ای (FPNN) برای تخمین مقاومت فشاری نمونه‌های بتنی است. در این مطالعه، دو ساختار مختلف FPNN معرفی و طریقه آموزش آنها آرایه و سپس شش ساختار مختلف FPNN با داده‌های جمع آوری شده از آزمایشگاه‌های مختلفی از ایران و لهستان تعلیم داده شد و با استفاده از داده‌های آزمایشی آزموده شد. شش ورودی این مدل‌ها شامل شن، ماسه، فوق روان کننده، میکروسیلیس، آب و سیمان می‌باشد. خروجی مدل‌ها مقاومت فشاری ۲۸ روزه بتن است که بر اساس طرح اختلاطی شامل مصالح مذکور تهیه شده است. نتایج تحقیق حاکی از مناسب بودن این روش برای پیش‌بینی مقاومت بتن است. بر اساس مطالعات آماری و نمودارهای آرایه شده، مدل‌های ۱، ۲، ۴ و ۶ جزء مدل‌های مناسب و مدل‌های ۳ و ۵ مدل‌های نامناسبی برای پیش‌بینی مقاومت بتن تشخیص داده شد. ویژگی بارز این تحقیق استفاده از یک الگوریتم جدید با نام شبکه‌های عصبی-فازی چند جمله‌ای (FPNN) در حوزه پیش‌بینی مقاومت بتن می‌باشد. از دیدگاه کاربردی، این روش با ترکیبی از روش مرسوم پس انتشار خطا (BP) و تخمین حداقل مربعات (LES) سیستم قابل قبولی در زمینه پیش‌بینی مقاومت فشاری بتن می‌باشد. این روش را می‌توان برای پیش‌بینی خواص سایر مصالح ساختمانی نیز به کار برد.

۱۰- مراجع

- [۱] Jang, J. R. , "ANFIS: Adaptive-Neuro-Based Fuzzy Inference System", IEEE Tran. on Sys. Man. and Cyber. , Vol. 23 No. 3, pp 665-685 1993
- [۲] Park, H. S. , "A Study on Multi-Layer Fuzzy Polynomial Inference System base on an Extended GMDH algorithm," IEEE Int. Fuzzy System Conf. Proc., pp 2212 , Seoul, Korea, August, 1999

در شکل (۷)، قابلیت پیش‌بینی مدل ۶ به عنوان نمونه برای مجموعه داده‌های کنترلی (CP) نشان داده شده است. در این شکل، نتایج خروجی مدل با نتایج واقعی (آزمایشگاهی) نشان داده شده است. محور افقی نشانگر شماره نمونه بتنی (شماره طرح اختلاط) و محور قائم مقاومت فشاری نمونه‌ها را بر حسب مگاپاسکال نشان می‌دهد. همان گونه که در این شکل ملاحظه می‌شود، این مدل تطابق خوبی با نتایج آزمایشگاهی نشان می‌دهد. همچنین جا دارد قابلیت مدل‌ها را در دسته‌های آموزشی و آزمایشی را مطالعه و مقایسه شود. شکل (۸) مقایسه‌ای بین پیش‌بینی مدل ۶ (به عنوان نمونه) و مقادیر واقعی برای هر دو مجموعه داده‌های آموزشی و آزمایشی را نشان می‌دهد. در این نمودارها، محور افقی نشان دهنده نتایج حاصله از پیش‌بینی مدل پیشنهادی و محور قائم نماینده نتایج آزمایشگاهی می‌باشد. پراکندگی نقاط از خط قطری نشانگر نزدیکی و دوری نتایج حاصله از مدل به مقادیر واقعی است. مدل ۶ (Model 6) با ضریب همبستگی ۰/۸۱۹۴ و ۰/۸۲۰۹ به ترتیب برای مجموعه داده‌های آموزشی و آزمایشی دارای بهترین تطابق با مقادیر واقعی است.



شکل (۹): مقایسه بین پیش‌بینی مدل ۳ و ۵ با مقادیر واقعی

با توجه به جدول (۴) مشاهده می‌شود مدل شماره ۲ و ۵ خاصیت تخمین و تعمیم خوبی ندارد. همان طوری که در شکل (۹) تأکید شده است، این مدل‌ها به دلیل آرایه نتایج نامعقول (خروجی منفی برای مقادیر مقاومت فشاری بتن) مردود شناخته می‌شود). بنابراین به جز مدل‌های ۳ و ۵، سایر مدل‌ها را می‌توان به عنوان مدل‌های خوب پیش‌بینی کننده برای مقاومت فشاری بتن به حساب آورد. برای مقایسه، پیش‌بینی مقاومت نمونه‌ها از مدل ANFIS استفاده و با خروجی مدل ۶ مقایسه شده است. در شکل (۱۰) نتایج پیش‌بینی مقاومت نمونه‌ها با مدل ANFIS با نتایج مدل ۶ مقایسه شده است. همان طوری که مشاهده می‌شود، مدل پیشنهادی نتایج قابل قبول‌تری به دست می‌دهد.

- [۳] Kaveh, A., and Khaleghi, H. A., "Prediction of Strength for Concrete Specimen Using Artificial Neural Network", *Asian Journal of Civil Engineering*, Vol. 2, No. 2, pp 1-13, 2000
- [۴] Kasperkiewicz, J., Racz J. and Dubrawski A.; "HPC Strength Prediction Using Artificial Neural Network"; *Jour. of Comp. in Civil Eng.*, Vol. 9, No. 4, 1995
- [۵] مستوفی نژاد، د. و سماعی نژاد، ع؛ "پیش‌بینی مقاومت بتن با عملکرد بالا با استفاده از شبکه‌های عصبی؛ کنفرانس بین‌المللی بتن و توسعه، تهران، ایران، ۱۳۸۰.
- [۶] Yeh, I. C.; "Modeling Concrete Strength with Augment-Neuron Networks"; *Journal of Materials in Civil Engineering*", Vol. 10 No. 4, 1998.
- [۷] داورد پناه، آر.ش.، "برآورد مشخصات بتن و بهینه سازی طرح اختلاط آن مبتنی بر استفاده از شبکه های عصبی" پایان‌نامه کارشناسی ارشد، به راهنمایی علی‌اکبر رمضانیاپور، دانشکده عمران، دانشگاه صنعتی امیر
- [۸] Oh, J. W., Lee, I. W., Kin, J. T., and Lee, G. W., "Application of Neural Networks for Proportioning of Concrete Mixes", *ACI Material Journal*, Vol. 96, No. 1, pp 6467 1999
- [۹] Oh, J. , Lee I., Kim, T. and Lee G. ; "Applications of Neural Networks for Proportioning of Concrete Mixes"; *ACI Mat. Jour.*, Vol. 96, No. 1, 1999.
- [۱۰] Yeh, I. C.; "Design of High-Performance Concrete Mixture Using Neural Networks and Nonlinear Programming"; *Jour. of Comp. in Civil Eng.*, Vol. 13, No. 1, 1999
- [۱۱] Bai, Y. and Amirkhani, S.N., "Knowledge-Based Expert System for Concrete Mix Design"; *Jour. of Const. Eng. and Manag.*, Vol. 120, No. 2, 1994.
- [۱۲] Basma, A. A., Barakat, S., and Al-Orimi, S., "Prediction of Cement Degree of Hydration Using Artificial Neural Networks"; *ACI Mat. Jour.*, Vol. 96, No. 2, pp 4248 1999
- [۱۳] Ramezaniapour, A. A. & Tarighat; A., "Neural Network Modeling of Concrete Carbonation"; *ACI SP*, pp. 199-52, 2000
- [۱۴] Ghaboussi, J., J. Garrett H. and Wu, X. ; "Knowledge-Based Modeling of Material Behavior with Neural Networks"; *Jour. of Eng. Mech.*, Vol. 117, No. 1, 1991
- [۱۵] Ramezaniapour, A. A. Sobhani, M., Sobhani, J. "Application of network based neuro-fuzzy system for prediction of the strength of high strength concrete", *Amirkabir Jour. of Scien. and Tech.*, Vol.15 No.59C, Summer 2004 [in Farsi].