

استفاده از شبکه عصبی GMDH تعمیم یافته برای پیش بینی مقاومت فشاری بتن به کمک روش مغزه گیری

رحمت مدن دوست^{۱*}، ملک محمد رنجبر^۲، کمیل مومنی^۳

۱ و ۲- دانشیار ۳- دانشجوی دکتری، دانشگاه گیلان

(دریافت: ۹۶/۰۳/۲۹، پذیرش: ۹۶/۱۰/۰۱)

چکیده

در این مطالعه، شبکه عصبی GMDH با ساختار عمومی (تعمیم یافته) با موفقیت برای مدل سازی روش مغزه گیری حاوی میل گرد و بر پایه نتایج گسترده آزمایشگاهی بکار گرفته شده است. الگوریتم ژنتیک و روش تجزیه مقادیر منفرد برای تعیین ساختار بهینه مدل گسترش یافته اند. مجموعه داده های ورودی و خروجی برای آموزش و آزمایش مدل های استخراج شده شامل متغیرهای قطر مغزه بتنی، نسبت ابعاد مغزه، تعداد میل گرد های داخل مغزه، فاصله محور میل گرد تا انتهای نزدیک تر مغزه و نیز مقاومت مغزه (با و بدون میل گرد) به عنوان پارامترهای ورودی و مقاومت مکعبی استاندارد بتن به عنوان متغیر خروجی مدل در نظر گرفته شده اند. مقایسه بین نتایج آزمایشگاهی به دست آمده در این مطالعه و مقادیر متناظر پیش بینی شده توسط مدل GMDH نشان داد که این مدل توانایی بالایی در پیش بینی مقاومت فشاری بتن بر پایه نتایج آزمایش مغزه گیری دارد. در انتها، آنالیز حساسیت به منظور بررسی تأثیر پارامترهای ورودی بر خروجی مدل GMDH انجام گرفت. این آنالیز نشان داد که مقادیر متغیر خروجی (مقاومت مکعبی استاندارد بتن) به طور قابل توجهی متأثر از مقادیر پارامترهای مقاومت مغزه و تعداد میل گرد ها در مقایسه با سایر متغیرهاست.

کلیدواژه ها: مقاومت فشاری، آزمایش مغزه، GMDH، الگوریتم ژنتیک، میل گرد

Generalized GMDH-Type Neural Network for Prediction of Concrete Compressive Strength via Core Testing

R. Madandoust*, M. M. Ranjbar, K. Momeni

Gilan University

(Received: 19/06/2017; Accepted: 22/12/2017)

Abstract

In this paper, generalized Group Method of Data Handling (GMDH)-type neural network has been successfully used for modeling concrete core testing including reinforcing bars based on various data obtained experimentally. Genetic Algorithm (GA) and Singular Value Decomposition (SVD) techniques are deployed for optimal design of such model. A set of input-output data for the training and testing the evolved models are employed in which core diameter, length-to-diameter ratio, number of reinforcing bars, distance of bar axis from nearer end of core as well as strength of cores, with or without reinforcing bars, are considered as inputs and standard cube strength of concrete is regarded as the output variables. The comparison of results obtained experimentally in this work with the proposed GMDH model depicted that this model has a great ability for prediction of the concrete compressive strength on the basis of core testing. Finally, sensitivity analysis was performed on the models obtained by GMDH-type neural network to study the influence of input parameters on model output. The sensitivity analysis reveals that the output variable (standard cube strength) is significantly changed by core strength and number of rebars in comparison with other input variables.

Keywords: Compressive Strength, Core Test, GMDH, Genetic Algorithm, Reinforcing Bars

۱. مقدمه

در مرحله اول، مقاومت مغزه غیراستاندارد می‌بایست به مقاومت معادل مغزه استاندارد تبدیل شده و سپس مقاومت مغزه استاندارد به مقاومت معادل بتن در محل به کمک ضرایب تصحیح مورد نیاز تبدیل شود و سپس مقاومت مغزه استاندارد به مقاومت معادل بتن در محل به کمک ضرایب تصحیح مورد نیاز تبدیل شود. حتی زمانی که این ضریب تصحیح مناسب باشد می‌بایست این مورد را مد نظر داشت که این مقدار به صورت یک مقدار میانگین با کمی پراکندگی و خطا حول و حوش آن است. لذا، این امکان وجود دارد که در یک شرایط خاص، استفاده از یک یا چند ضریب تصحیح ضرورت داشته باشد که در این حالت، به کارگیری این ضرایب تصحیح یکی پس از دیگری، می‌تواند عدم قطعیت‌هایی را در خصوص تخمین مقاومت بتن مطرح نماید.

نگارنده معتقد است که ضرایب تصحیح مقاومت منتشرشده، به ویژه ضریب تصحیح میل‌گرد، لزوماً دقیق نیستند و ممکن است به‌طور عمومی کاربردی نباشند. چرا که آن‌ها منتج از اطلاعات و آزمایش‌های خاص خود بودند. همان‌طور که در بالا توضیح داده شد، در نظر گرفتن همه این عوامل مستلزم به کارگیری مدل‌های بسیار پیچیده و دقیق برای پیش‌بینی درست مقاومت بتن است. در این بین، استفاده از روش‌های مدل‌سازی قدیمی در پیش‌بینی رفتار بتن، به ویژه مقاومت فشاری بتن، کاری دشوار، زمان‌بر و نامطمئن است [۱۶ و ۱۷].

شناسایی سامانه‌ها و مدل‌سازی فرآیندهای پیچیده با استفاده از داده‌های ورودی - خروجی همواره مورد توجه محققین زیادی بوده است. در واقع روش‌های شناسایی سامانه در شاخه‌های علمی متعددی به منظور پیش‌بینی رفتار سامانه‌های ناشناخته و پیچیده بر پایه داده‌های ورودی - خروجی در دسترس به کار گرفته می‌شود [۱۸]. از نظر تئوریک، برای مدل کردن یک سامانه، شناخت دقیق روابط صریح ریاضی بین متغیرهای ورودی و خروجی ضرورت دارد. مؤلفه‌های اصلی محاسبات نرم، مانند منطق فازی، شبکه عصبی و الگوریتم ژنتیک، توانایی بالایی را در حل مسائل پیچیده و غیرخطی کنترل و شناسایی سامانه‌ها از خود نشان داده‌اند.

در این راستا تلاش‌های زیادی در استفاده از روش‌های تکاملی به‌عنوان ابزاری کارآمد در شناسایی سامانه گسترش یافته است [۱۹-۲۱]. در میان این روش‌ها، الگوریتم دسته‌بندی گروهی داده‌های عددی (GMDH) یک روش خودسازمان ده است که به تدریج بر روی مدل‌های پیچیده بر اساس تکامل عملکردشان بر روی یک مجموعه داده‌های چند ورودی - یک خروجی (X_i, y_i) $(i=1,2,\dots,M)$ شکل می‌گیرد. روش GMDH اولین بار توسط ایواخنکو [۲۲] به صورت یک روش آنالیز چند متغیره برای

روش مغزه‌گیری متداول‌ترین روش ارزیابی مقاومت فشاری بتن در محل به شمار می‌رود که عمدتاً در پاسخ به نقص بتن به کار رفته و یا سوء ظن مطرح‌شده برای یک سازه مشکوک مطرح می‌شود. گرچه این روش کاملاً ساده به نظر می‌رسد اما نتایج به‌دست‌آمده از آن به دلیل فاکتورهای متعددی که درگیر آن هستند ممکن است به خطاهای قابل توجهی همراه باشد. عواملی شامل قطر مغزه، نسبت طول به قطر مغزه، سن مغزه، خصوصیات سنگدانه، جهت مغزه‌گیری و شرایط رطوبت در هنگام آزمایش به‌عنوان متغیرهایی که می‌توانند رابطه بین مقاومت مغزه و مقاومت نمونه مکعبی یا استوانه‌ای استاندارد را متأثر سازند شناخته شده‌اند [۶-۱]. هرچند که تأثیر حضور میل‌گردهای فولادی به‌عنوان یک عامل بالقوه بر مقاومت مغزه تنها توسط عده کمی از محققین مورد بررسی قرار گرفته است [۹-۷].

اگر به هر دلیلی مغزه بریده شده حاوی میل‌گرد باشد، این الزام در آیین‌نامه‌های BS EN 12504-1 [۱۰] و British Standard BS 6089 [۱۱] و BS 1881: part 120 [۱۲] و همچنین گزارش شماره ۱۱ انجمن بتن [۱۳] به صورت ضرایب تصحیح حضور یک یا چند میل‌گرد گنجانده شده است. اخیراً، اصلاحاتی ارائه شده است [۸]. این در حالی است که برخی استانداردها مانند ACI 214 [۱۴]، ASTM C42 [۱۵] توصیه می‌کنند که مغزه‌های بتنی برای آزمایش فشاری ترجیحاً می‌بایست حاوی میل‌گرد نباشند. گزارش‌های متناقض قابل توجهی در خصوص تأثیر میل‌گرد وجود دارد. برخی محققین تأثیر چندانی نیافتند [۸] در حالی که برخی دیگر رفتارهای متناقض و متفاوتی را بیان کردند [۷-۹].

تأثیر میل‌گردهای آجدار 13^{mm} ، 25^{mm} در چیدمان‌های مختلف نیز ارزیابی شده است و نتایج نشان داده که حضور میل‌گرد در مغزه باعث کاهش مقاومت‌های فشاری اندازه‌گیری شده به میزان ۱۸-۴ درصد می‌شود [۷]. تحقیق دیگری نشان داده که میزان کاهش مقاومت فشاری استوانه‌ای در نتیجه میل‌گردهای تعبیه‌شده، برای نسبت طول به قطر ۲، آشکارا با کاهش نسبت $\frac{l}{d}$ کاهش می‌یابد [۸]. همچنین در عوض برای $\frac{l}{d} = 1$ ، افزایش مقاومت مغزه‌ها صرف‌نظر از موقعیت میل‌گرد در مغزه مشاهده شد. آن‌ها همچنین گزارش کردند که حضور میل‌گرد تا ۴٪ حجمی نمونه‌های استوانه‌ای بتنی با نسبت طول به قطر ۱، تأثیر منفی قابل توجهی بر مقاومت نشان نداده است. انجمن بتن [۱۳] این کاهش مقاومت را به صورت تابعی از اندازه و موقعیت میل‌گردهای فولادی در مغزه گزارش می‌کند.

۲. روش تحقیق

طرح اختلاطهایی برای دستیابی مقاومت مکعبی ۵۶ روزه $۲۱/۳ \text{ Mpa}$ و $۴۸/۱ \text{ Mpa}$ با نسبت‌های آب به سیمان $۰/۴$ و $۰/۵۵$ در نظر گرفته شد. مقادیر سیمان به ترتیب $۳۸۰ \frac{\text{kg}}{\text{m}^3}$ ، $۲۵۰ \frac{\text{kg}}{\text{m}^3}$ انتخاب شد. همچنین مقادیر مصالح ریزدانه خوب دانه بندی شده و مصالح درشت دانه با حداکثر اندازه اسمی 19^{mm} به ترتیب در محدوده‌های $۹۰۵-۹۸۵ \frac{\text{kg}}{\text{m}^3}$ ، $۹۵۳-۱۰۲۰ \frac{\text{kg}}{\text{m}^3}$ تعیین گردید. در تمام اختلاطها از سیمان پرتلند تیپ ۲، ماسه رودخانه‌ای شسته شده و مصالح درشت دانه شکسته استفاده شد. تأثیر میل گرد فولادی بر مقاومت مغزه‌های بتنی توسط پارامترهای مختلف شامل؛ قطر مغزه، نسبت طول به قطر مغزه، شرایط رطوبتی مغزه، سطح مقاومت بتن و همچنین قطر و تعداد میل گرد و موقعیت آن در مغزه ارزیابی شده است.

برای هر طرح تیرهای بتنی مسلح و غیرمسلح به ابعاد $۳۰۰ \times ۳۰۰ \times ۱۰۰۰ \text{ mm}$ ساخته شده و در شرایط آزمایشگاه با رطوبت نسبی ۷۰% و دمای ۲۵°C به همراه نمونه‌های مکعبی کنترل ۱۰۰ mm نگهداری شدند. میل‌گردهای فولادی مصرف شده از نوع آجدار با قطرهای ۱۰ mm ، ۱۶ mm بودند. مغزه‌هایی با قطرهای ۷۵ mm و ۱۰۰ mm با نسبت ابعاد ۱ و ۲ از تیرهایی ساخته شده در جهت عمود بر جهت بتن ریزی گرفته شد. مغزه‌ها توسط ملات گوگرد کلاک گذاری شده (capped) و به منظور ارزیابی اهمیت شرایط رطوبت مغزه در هنگام آزمایش، در شرایط عمل‌آوری مختلف شامل نگهداری در هوای آزاد به مدت ۷ روز و نیز دو روز اشباع پیش از آزمایش در نظر گرفته شد (soaked for 2 days). حداقل ۴۸۰ مغزه بتنی برای مقاومت فشاری ۵۶ روزه آزمایش شدند و هر نتیجه استخراج شده به صورت میانگین نتایج حداقل ۳ نمونه بوده است.

جزئیات برنامه آزمایشگاهی در جدول (۱) و نمایی کلی از برنامه گسترده آزمایشگاهی انجام شده در این مطالعه در شکل (۱) خلاصه شده است.

جدول ۱. جزئیات مغزه‌های آزمایش

پوشش میل گرد (میلی متر)	تعداد میل گرد	قطر میل گرد (میلی متر)	نسبت طول به قطر (L/D)	قطر مغزه D (میلی متر)
۳۰، ۵۰ و ۷۵	۱ و ۲	۱۰ و ۱۶	۲	۷۵
۳۰، ۵۰ و ۷۵	۱ و ۲	۱۰ و ۱۶	۲ و ۱	۱۰۰

مدل سازی و شناسایی سامانه‌های پیچیده توسعه پیدا کرد. هدف اصلی GMDH بنا نهادن یک تابع تحلیلی بر اساس یک شبکه پیشخور (feed-forward) است که هر المان آن یک تابع درجه دوم شکل می‌دهد که ضرایب آن به کمک روش‌های رگرسیونی به دست می‌آیند [۲۳]. مرور بسیار جامعی از استفاده الگوریتم‌های تکاملی در طراحی شبکه‌های عصبی مصنوعی انجام شده است [۲۴]. پیش‌تر از الگوریتم‌های ژنتیک در شبکه عصبی مصنوعی از نوع GMDH به منظور جستجوی مجموعه بهینه از ارتباطات هر نرون با لایه‌های قبلی استفاده شده است. [۱۶، ۱۷، ۲۵ و ۲۶]

این مطالعات بیان‌کننده یک استفاده ترکیبی از الگوریتم ژنتیک برای یک شبکه عصبی GMDH با ساختار ساده شده است، به طوری که ارتباطات نرون‌ها فقط به لایه‌های مجاور محدود نبوده و پیکربندی ارتباطات نرون‌ها فقط منحصر به لایه‌های مجاور نیست این مسئله توسط نریمان زاده و همکاران [۲۶] پیش‌تر عنوان شده است. این تعمیم یافتگی توپولوژی شبکه می‌تواند عملکرد شبکه عصبی GMDH را به طور چشمگیری بهبود بخشد. از این گذشته، ترکیب الگوریتم ژنتیک و تجزیه مقادیر منفرد (SVD) برای طراحی همزمان ساختار شبکه و ضرایب آن، روش‌های طراحی پیشین [۲۷] برای فرآیند مشابه تعیین تعداد لایه‌های پنهان و تعداد نرون‌های آن را به طور قابل ملاحظه‌ای ارتقا داده است. در این حالت شبکه‌های به مراتب ساده‌تر و با ساختار بهینه طراحی می‌شوند.

هدف از مطالعه حاضر پیش‌بینی مقاومت مکعبی استاندارد بتن (f_{cu}) به وسیله نتایج آزمایش مغزه‌گیری با توجه ویژه به عوامل کاربردی حضور یک یا چند میل گرد در مغزه بتنی در وضعیت‌های مختلف است. نشان داده شده است که شبکه عصبی GMDH می‌تواند به طور موثر و کارآمد مقاومت فشاری بتن (f_{cube}) را به صورت تابعی از متغیرهای مهم ورودی شامل؛ نسبت طول به قطر مغزه (L/D)، قطر مغزه (D_{core})، تعداد میل‌گردهای فولادی (N_{rebar})، فاصله محور میل‌گرد (ها) از انتهای نزدیک‌تر مغزه (H) و مقاومت فشاری مغزه (f_{core}) در دو شرایط عمل‌آوری مختلف، مدل‌سازی و پیش‌بینی نماید. در این راستا، الگوریتم ژنتیک در یک روش جدید برای طراحی کل ساختار شبکه عصبی GMDH بسط یافته است. تعداد نرون‌ها در هر لایه پنهان و پیکربندی ارتباطات آن‌ها با یکدیگر به منظور دستیابی به مجموعه‌ای مطلوب از ضرایب مناسب معادلات درجه دو بهینه‌سازی شده است. همچنین قابلیت پیش‌بینی مدل‌های شبکه عصبی GMDH با مدل‌های رگرسیون خطی مقایسه شده است.



شکل ۱. مراحل انجام ساخت تیرها، عمل آوری، مغزه گیری از تیرها و آزمایش مغزه ها در ابعاد مختلف با چیدمان مختلف میل گرد ها

۳. مروری بر شبکه عصبی GMDH

معادله مرتبه دو G_i برای برازش بهینه خروجی در کل مجموعه زوج داده‌های ورودی - خروجی به دست می‌آید. به عبارت دیگر:

$$E = \frac{\sum_{i=1}^M (y_i - G_i)^2}{M} \rightarrow \min \quad (6)$$

در فرم اصلی الگوریتم GMDH، همه حالت‌های ممکن دو متغیر مستقل از مجموع n متغیر ورودی به منظور تشکیل چندجمله‌ای‌های رگرسیون به فرم معادله (۵) در نظر گرفته می‌شوند به طوری که بهترین برازش‌های مشاهدات وابسته $(y_i, i = 1, 2, \dots, M)$ در جهت ارضای کمترین مربعات حاصل گردد. در نتیجه، $\binom{n}{2} = \frac{n(n-1)}{2}$ نرون در اولین لایه از شبکه پیشخور (feed-forward) از مشاهدات $\{(y_i, x_{ip}, x_{iq}) (i = 1, 2, \dots, M)\}$ برای مقادیر مختلف $p, q \in \{1, 2, \dots, n\}$ گسترش می‌یابند. به عبارت دیگر در این حالت امکان تشکیل M داده سه‌گانه $\{(y_i, x_{ip}, x_{iq}) (i = 1, 2, \dots, M)\}$ از مشاهدات به کمک چنین فرمی $p, q \in \{1, 2, \dots, n\}$ وجود دارد:

$$\begin{bmatrix} x_{1p} & x_{1q} & \vdots & y_1 \\ x_{2p} & x_{2q} & \vdots & y_2 \\ \dots & \dots & \vdots & \dots \\ x_{Mp} & x_{Mq} & \vdots & y_M \end{bmatrix}$$

به کمک زیرمجموعه مرتبه دو به فرم معادله (۵) برای هر ردیف از M داده سه‌گانه، معادلات ماتریسی به آسانی به صورت زیر به دست می‌آید:

$$A \mathbf{a} = Y \quad (7)$$

که در آن، \mathbf{a} بردار ضرایب ناشناخته از چندجمله‌ای‌های مرتبه دو معادله (۵) است.

$$\mathbf{a} = \{a_0, a_1, a_2, a_3, a_4, a_5\} \quad (8)$$

$$Y = \{y_1, y_2, y_3, \dots, y_M\}^T \quad (9)$$

بردار مقادیر خروجی مشاهدات است. می‌توان به آسانی دریافت که:

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}x_{1q} & x_{1p}^2 & x_{1q}^2 \\ 1 & x_{2p} & x_{2q} & x_{2p}x_{2q} & x_{2p}^2 & x_{2q}^2 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 1 & x_{Mp} & x_{Mq} & x_{Mp}x_{Mq} & x_{Mp}^2 & x_{Mq}^2 \end{bmatrix} \quad (10)$$

روش حداقل مربعات از آنالیز رگرسیون چند متغیر منجر به حل معادلات ضرایب به فرم زیر می‌شود:

$$\mathbf{a} = (A^T A)^{-1} A^T Y \quad (11)$$

مطابق الگوریتم GMDH یک مدل می‌تواند به صورت مجموعه‌ای از نرون‌ها به طوری که زوج‌های مختلف آن‌ها در هر لایه از طریق یک معادله چندجمله‌ای مرتبه دوم به هم مرتبط شده‌اند بیان شود و نرون‌های جدید در لایه‌های بعدی را بسازند. این چنین نمایشی می‌تواند در مدل‌سازی مسیر ورودی‌ها به خروجی به کار گرفته شود. تعریف مشخص و قراردادی شناسایی یک مسئله، یافتن تابع \hat{f} است به طوری که می‌تواند تقریباً به جای مقدار واقعی f به منظور پیش‌بینی خروجی \hat{y} به ازای یک بردار ورودی مشخص $X = (x_1, x_2, x_3, \dots, x_n)$ در نزدیک‌ترین حالت ممکن به مقدار واقعی خروجی y به کار رود. بنابراین، M مشاهده مشخص از زوج داده‌های چند ورودی - یک خروجی به طوری که:

$$y_i = f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) (i = 1, 2, \dots, M) \quad (1)$$

حال امکان آموزش یک شبکه عصبی از نوع GMDH برای پیش‌بینی مقادیر خروجی \hat{y}_i برای هر بردار ورودی مشخص $X = (x_{i1}, x_{i2}, x_{i3}, \dots, x_{in})$ به عبارتی:

$$\hat{y}_i = \hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) (i = 1, 2, \dots, M) \quad (2)$$

اکنون مسئله تعیین یک شبکه عصبی GMDH به گونه‌ای است که مربع اختلافات بین مقدار واقعی خروجی و مقدار پیش‌بینی شده متناظر به حداقل برسد و به عبارتی:

$$\sum_{i=1}^M [\hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) - y_i]^2 \rightarrow \min \quad (3)$$

ارتباطات کلی بین ورودی‌ها و متغیرهای خروجی را می‌توان با استفاده از یک فرم پیچیده گسسته از سری توابع ولترا (Voterra) به فرم زیر بیان نمود:

$$y = a_0 + \sum_1^n a_i x_i + \sum_1^n \sum_1^n a_{ij} x_i x_j + \sum_1^n \sum_1^n \sum_1^n a_{ijk} x_i x_j x_k + \dots \quad (4)$$

که به چندجمله‌ای Kolmogorov - Gabor شناخته می‌شوند [۲۳-۲۸]. این فرم کامل از بیان ریاضی را می‌توان به صورت یک سامانه از چند جمله‌های مرتبه دو جزئی بیان نمود به طوری که شامل تنها دو متغیر (نرون) در فرم زیر باشند:


$$\hat{y} = G(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i x_j + a_4 x_i^2 + a_5 x_j^2 \quad (5)$$

که ضریب a_i در معادله (۵) به کمک روش‌های رگرسیونی محاسبه می‌شوند. [۲۶ و ۲۵ و ۲۳ و ۲۲] به طوری که اختلاف بین مقدار واقعی (y) و مقدار برآورده شده (\hat{y}) برای هر زوج از متغیرهای ورودی X_i, X_j حداقل شود. در این راستا، ضرایب هر


[۱۷- ۱۶]. قابل ذکر است که بررسی رابطه بین مقاومت مغزه و مقاومت مکعبی استاندارد متناظر آن‌ها نشان داد که پراکندگی مشخصی برای دو شرایط نگهداری مختلف وجود دارد. لذا، دو مدل مجزا برای دو شرایط نگهداری خشک و دو روز مرطوب در نظر گرفته شد. به منظور اثبات قابلیت و توانایی پیش‌بینی مدل شبکه عصبی GMDH، داده‌ها در دو گروه مختلف آموزش و آزمایش تقسیم‌بندی شدند. داده‌های آموزش که شامل ۷۴ داده از مجموعه ۱۰۲ زوج داده ورودی- خروجی برای شرایط نگهداری خشک و ۷۴ داده از مجموع ۹۶ زوج داده ورودی- خروجی برای شرایط نگهداری دو روز مرطوب بودند، تنها برای آموزش شبکه مطابق روش‌های تکاملی این مطالعه به کار برده شدند. داده‌های آزمایش که شامل به ترتیب ۲۸ و ۲۱ نمونه ورودی- خروجی برای دو شرایط نگهداری خشک و مرطوب بودند، تنها برای آزمایش مدل‌های استخراج‌شده به کار برده شدند تا قابلیت و توانایی مدل‌های GMDH پایه‌ریزی شده را نشان دهند. لذا این داده‌های آزمایش هیچ مشارکتی در بخش آموزش شبکه نداشتند.

۴-۲. نتایج مدل‌سازی

ساختار مدل شبکه عصبی GMDH دارای ۳ لایه پنهان در شکل‌های (۲-۳) نشان داده شده است.



شکل ۲. ساختار تکامل مدل شبکه عصبی GMDH متعارف برای نمونه‌های خشک‌شده در هوا



شکل ۳. ساختار تکامل مدل شبکه عصبی GMDH متعارف برای نمونه‌های مرطوب در هوا

همان‌طور که از شکل‌ها بر می‌آید پیکربندی ارتباط نرون‌ها فقط محدود به لایه‌های مجاور نیست. عملکردهای شبکه‌های GMDH تعمیم‌یافته در شکل‌های (۴-۵) ارائه شده است.

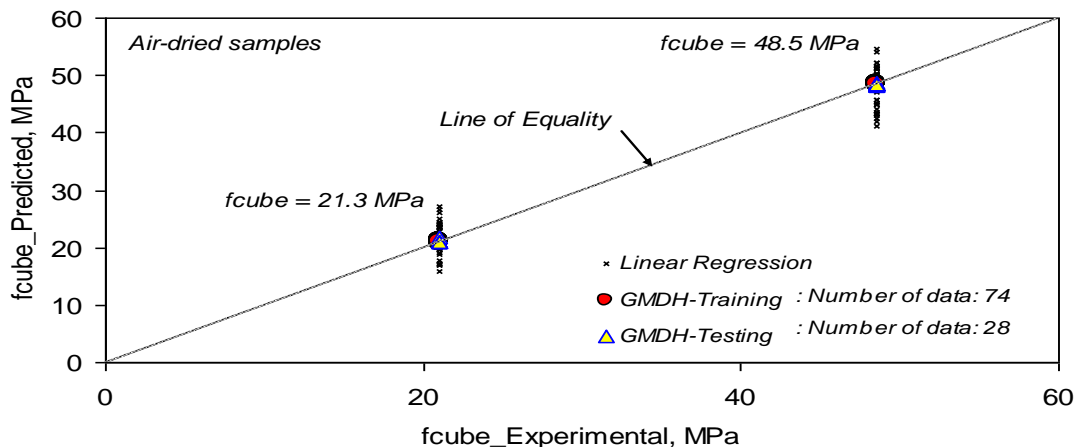
این معادله بردار بهترین ضرایب معادله (۵) برای کل مجموعه M داده سه‌گانه تعیین می‌کند. شایان ذکر است که این روش برای هر نرون از لایه پنهان بعدی مطابق با توپولوژی شبکه تکرار می‌شود [۲۶-۲۵].

در این مطالعه، طراحی همزمان ساختار و ضرایب معادلات حاکم بر آن به ترتیب به کمک الگوریتم ژنتیک (GA) و تجزیه مقادیر منفرد (SVD) انجام گرفته است. این کاربرد ترکیبی به وسیله استفاده از الگوریتم ژنتیک برای انتخاب بهینه ساختار شبکه و به‌طور همزمان ضرایب وابسته هر کاندید حل در جمعیت گسترش‌یافته به کمک روش SVD در یک حالت بهینه انجام شده است. این به‌کارگیری، اندازه فضای جستجو برای طراحی تکاملی شبکه عصبی GMDH را شدیداً کاهش می‌دهد به‌گونه‌ای که هر یک از شش ضریب متعلق به هر یک از ارتباطات دو نرون متصل به‌طور بهینه توسط روش SVD محاسبه می‌شود. علاوه بر آن، به دلیل کاربرد الگوریتم ژنتیک، تعداد نرون‌ها در هر لایه پنهان و ساختار ارتباطی آن‌ها به‌منظور دستیابی به بهترین مجموعه از ضرایب چندجمله‌ای‌های درجه دو بهینه‌سازی شده است. همچنین پیکربندی ارتباطات نرون‌ها به لایه‌های مجاور محدود نبوده است که این موضوع پیش‌تر توسط نریمان‌زاده و همکاران [۲۶] مطرح شده است. این روش‌ها برای شبکه عصبی GMDH به‌دست‌آمده به همراه کلیه اطلاعات تعمیم‌سازی و بهینه‌سازی ساختار شبکه عصبی GMDH توسط نریمان‌زاده و همکاران [۲۶-۲۵] گزارش شده است.


۴. مدل‌سازی f_{cube}

۴-۱. مدل‌سازی شبکه عصبی GMDH

هدف اصلی این مطالعه ایجاد توسعه یک تابع چندجمله‌ای بر پایه پارامترهای ورودی شامل؛ نسبت طول به قطر مغزه، قطر مغزه، تعداد میل‌گردهای فولادی داخلی مغزه، فاصله محور میل‌گرد از انتهای نزدیک‌تر مغزه و مقاومت مغزه برای تخمین مقاومت مکعبی استاندارد بتن به‌عنوان متغیر خروجی است. به منظور طراحی ژنتیکی مدل شبکه عصبی GMDH که در بالا و در بخش قبل تشریح شد، از جمعیت اولیه ۵۰ با احتمال پیوند ۹۵٪ و احتمال جهش ۱٪ در ۲۰۰ نسل استفاده شد به‌طوری که بهبود بیشتری برای این اندازه جمعیت انتخابی حاصل نشد. برای این مدل حداکثر تعداد لایه‌های پنهان سه لایه انتخاب شد. با این انتخاب، بهترین ساختار به‌طور خودکار برای ۳ لایه پنهان و کمتر برگزیده می‌شود. انتخاب تعداد لایه‌های پنهان بیشتر به شدت پیچیدگی ساختار مدل می‌افزاید درحالی‌که تغییر چندانی در نتایج به‌دست نمی‌آید. از این گذشته، عملکرد بالای مدل شبکه عصبی با ۳ لایه پنهان بیشتر در تحقیقات به اثبات رسیده بود



شکل ۴. مقادیر آزمایشی مقاومت مکعب استاندارد بتن در مقابل نتایج پیش‌بینی شده GMDH برای شرایط عمل‌آوری خشک



شکل ۵. مقادیر آزمایشی مقاومت مکعب استاندارد بتن در مقابل نتایج پیش‌بینی شده GMDH برای شرایط عمل‌آوری مرطوب.

به هر پارامتر از طریق آزمایش تغییرات مقاومت مکعبی استاندارد به‌عنوان متغیر خروجی نسبت به پارامتر ورودی مشخص درحالی‌که سایر متغیرها ثابت نگه داشته شده‌اند ارزیابی می‌شود. شایان‌ذکر است که تغییرات هر پارامتر در محدوده قابل‌قبول متناظر با محدوده تغییرات واقعی و مجاز آن نگه داشته می‌شود تا خطا و انحراف نتایج به حداقل برسد. نتایج آنالیز حساسیت مدل‌های شبکه عصبی GMDH به‌دست‌آمده برای نمونه‌های خشک و مرطوب در شکل‌های (۶-۷) نشان داده شده است. می‌توان دریافت که متغیر خروجی f_{cube} به‌طور قابل‌توجهی با تغییرات N_{rebar} , f_{core} در مقایسه با سایر پارامترهای ورودی تغییر می‌کند. همچنین دیگر پارامترهای ورودی تأثیر ناچیزی بر روند تغییرات مقاومت مکعبی استاندارد بروز دادند. هرچند می‌بایست تأکید نمود که بررسی اعتبار این موضوع برای انواع مختلف بتن و خارج از محدوده داده‌های منظور شده در این مطالعه نیازمند مطالعات بیشتری است و چه بسا الگوی متفاوت دیگری از تغییرات دنبال شود.

این شکل‌ها نشان می‌دهند که مقادیر واقعی پیش‌بینی‌شده مقاومت مکعبی استاندارد به خوبی به هم مرتبط بوده و لذا توانایی پیش‌بینی و تخمین بالای مدل شبکه عصبی GMDH در مقایسه با مدل‌های رگرسیون خطی نتیجه می‌شود. پارامترهای برآورد خطا شامل $MAPE$, $RMSE$, R^2_{adj} بر اساس عملکرد مدل‌های GMDH در جدول (۲) خلاصه شده است.

ارزیابی‌های آماری ثابت می‌کنند که نتایج مدل‌های پیشنهادی دقت بسیار بالایی دارند به‌طوری‌که حدود ۹۹٪ تغییرات مقادیر متغیر پاسخ توسط مدل‌های استخراج‌شده می‌تواند تبیین شود. همچنین، معادلات چندجمله‌ای متناظر با دو شرایط نگهداری مختلف در جدول‌های (۳-۴) ارائه شده است.

۵. آنالیز حساسیت

آنالیز حساسیت مدل‌های به‌دست‌آمده به‌منظور ارزیابی تأثیر پارامترهای ورودی بر خروجی مدل انجام گرفته است. معادلات چندجمله‌ای به‌دست‌آمده با شبکه عصبی GMDH به فرم معادلات پیچیده‌ای است و تأثیر هر پارامتر ورودی را نمی‌توان به سادگی بر عملکرد مدل بررسی نمود. به جای آن حساسیت مدل

جدول ۲. ارزیابی آماری مدل های شبکه عصبی نوع GMDH

GMDH-type neural network	تعداد نمونه ها	R_{adj}^2	RMSE	MAPE	VAF (%)
نمونه های خشک شده در هوا					
Training	۷۴	۰/۹۹۹۹	۰/۰۹۲۸	۰/۳۰۷۷	۹۹/۹۹
Testing	۲۸	۰/۹۹۹۹	۰/۱۹۵۳	۰/۳۵۳۳	۹۹/۹۹
نمونه های مرطوب					
Training	۷۴	۰/۹۹۹۸	۰/۲۰۶۳	۰/۴۸۰۰	۹۹/۹۸
Testing	۲۲	۰/۹۹۹۷	۰/۲۷۵۸	۰/۷۳۹۳	۹۹/۹۷

$$R_{adj}^2 = 1 - \frac{n-1}{n-p} (1 - R^2)$$

$$MAPE = \frac{1}{n} \sum_1^n \left| \frac{y - y'}{y} \right| \times 100$$

$$RMSE = \sqrt{\frac{1}{n} \sum_1^n (y - y')^2}$$

$$VAF = \left[1 - \frac{\text{var}(y - y')}{\text{var}(y)} \right] \times 100$$

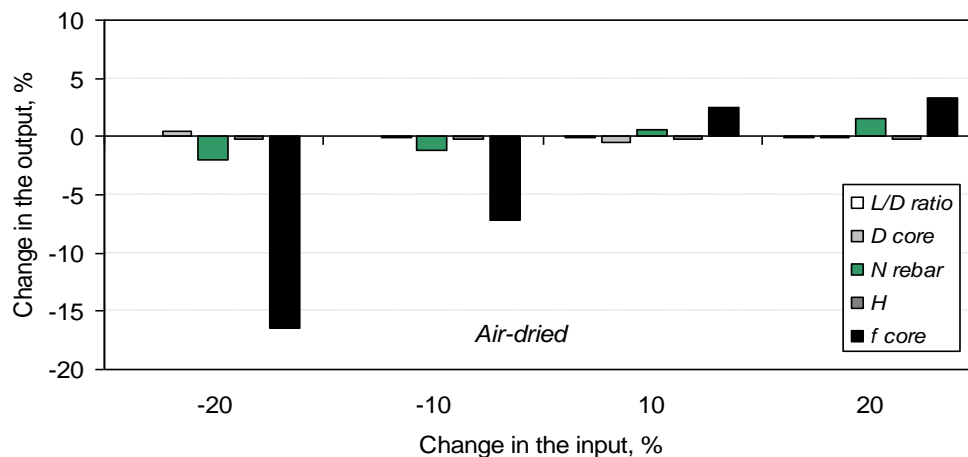
که در آن y, y', p, n به ترتیب بیانگر مقدار مشاهده شده، مقدار پیش بینی، تعداد پارامترهای مدل و تعداد حالات هستند

جدول ۳. مدل چندجمله ای تولید شده توسط شبکه عصبی GMDH تکامل یافته برای نمونه های خشک شده هوا

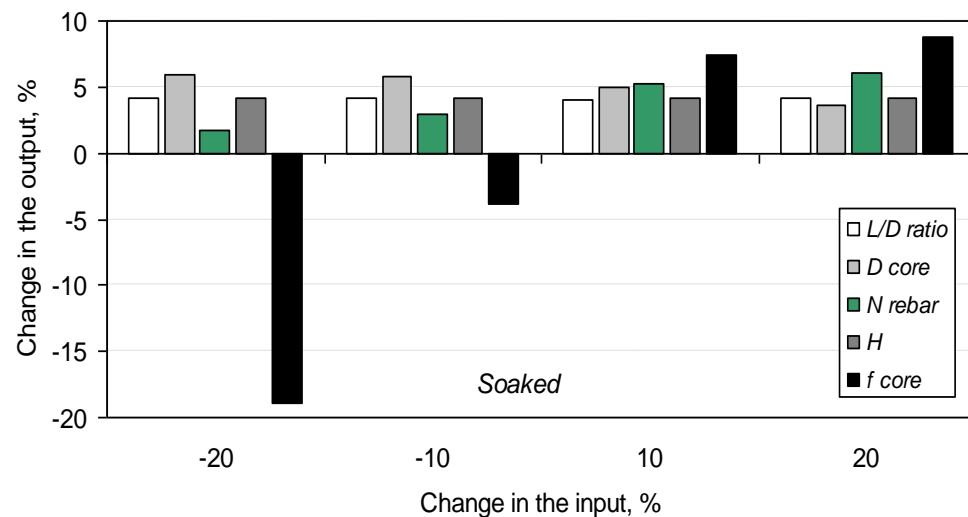
Y_i	Parameters	$Y = a(1) + a(2)*X(1) + a(3)*X(2) + a(4)*X(1)^2 + a(5)*X(2)^2 + a(6)*X(1)*X(2)$					
		a1	a2	a3	a4	a5	a6
Y1	L/D, f_{core}	-۱۴/۱۲۸۳	-۸/۴۳۲۷۴	۴/۳۷۷۹۳۱	۲/۹۵۸۴۰۲	-۰/۰۷۰۶۳	۰/۰۱۸۵۶۹
Y2	D_{core}, N_{rebar}	۰/۰۰۸۴۲۵	۰/۳۶۱۰۸	۱۳/۵۶۷۷۹	-۰/۰۰۰۰۶	-۳/۳۵۱۸۵	-۰/۰۵۱۴۶
Y3	L/D, H	۵/۲۳۸۰۶۴	۳/۸۴۷۹۳۶	۱/۰۶۹۰۱۹	۱/۰۶۷۶۷۹	-۰/۰۰۷۳۸	-۰/۱۶۹۵۱
Y4	N_{rebar}, f_{core}	-۳/۳۴۱۶	۲/۷۹۵۰۴۷	۵/۳۱۲۰۱۸	۰/۹۰۳۵۵۳	-۰/۰۸۵۷۲	-۰/۱۸۱۹۱
Y5	Y1, Y2	۶۸/۷۰۸۳۳	۰/۱۶۹۵۰۸	-۳/۷۸۲۶۶	۰/۰۱۹۷۶۹	۰/۰۶۵۹۴۴	-۰/۰۱۳۷۷
Y6	$f_{core}, Y3$	-۲۸/۶۰۷۱	۴/۹۶۴۱۶۴	-۰/۱۳۷۰۳۱	-۰/۰۷۵۴۷	۰/۰۰۳۶۸۸	-۰/۰۱۱۸۲
Y7	Y4, D_{core}	۰/۰۰۶۴۶۷	۰/۰۱۲۰۶۹	۰/۲۷۷۱۲۸	۰/۰۱۵۴۸۶	-۰/۰۰۱۴۸	-۰/۰۰۰۲۷
Y8	Y5, Y6	-۲/۱۵۹۶۹	۲/۱۹۵۱۷۲	-۱/۰۰۸۸۳	-۰/۱۱۷۴۸	-۰/۰۶۸۸۳	۰/۱۸۳۵۶۸
Y9	Y4, Y7	۲۴/۰۴۵۸۷	-۳/۴۹۰۰۷	۲/۵۷۶۴۸۳	-۰/۲۰۴۸۵	-۰/۰۳۲۳۷۴	۰/۶۰۷۹۷۴
Y10	Y8, Y9	-۱۸/۱۹۳۵	-۰/۰۵۰۵۵	۲/۴۹۴۷۶۱	۰/۰۰۸۰۳۴	-۰/۰۱۵۷۱	-۰/۰۱۴۳۷

جدول ۴. مدل چندجمله ای تولید شده توسط شبکه عصبی GMDH تکامل یافته برای نمونه های مرطوب

Y_i	Parameters	$Y = a(1) + a(2)*X(1) + a(3)*X(2) + a(4)*X(1)^2 + a(5)*X(2)^2 + a(6)*X(1)*X(2)$					
		a1	a2	a3	a4	a5	a6
Y1	N_{rebar}, f_{core}	-۳۷/۹۳۸۳	۱/۹۹۶۷۰۷	۵/۸۲۶۰۶۲	۱/۶۴۸۹۹۸	-۰/۰۹۱۱۶	-۰/۲۲۲۹۱
Y2	L/D, N_{rebar}	۴۴/۸۳۹۱۷	۲۶/۴۸۸۳۳	-۳۴/۷۳۷۱	-۱۰/۲۱۳۳	۸/۹۴۳۷۵	۲/۹۵۹۱۶۷
Y3	H, f_{core}	-۳۰/۳۲۲	-۰/۰۲۳۷۶	۵/۵۷۹۳۴۴	-۲/۰۸E-۰۵	-۰/۰۹۵۱۸	۰/۰۰۱۶۳۱
Y4	Y1, D_{core}	۰/۰۰۰۴۴	۰/۷۹۵۲۲۳۳	۰/۰۱۸۸۷۱	۰/۰۰۵۰۳۹	۰/۰۰۰۳۶۱	-۰/۰۰۱۵۹
Y5	f_{core}, N_{rebar}	-۳۷/۹۳۸۳	۵/۸۲۶۰۶۰	۱/۹۹۶۷۰۷	-۰/۰۹۱۱۶	۱/۶۴۸۹۹۸	-۰/۲۲۲۹۱
Y6	Y1, Y2	-۱۶/۵۳۴۷	۰/۴۲۰۶۱۸	۱/۱۸۲۹۱۱	۰/۰۰۸۰۳۱	-۰/۰۱۳۹۴	۰/۱۱۱۴۱
Y7	Y3, Y1	۸/۵۲۶۶۳۴	۰/۰۹۸۱۶	۰/۲۸۲۴۴۲	-۰/۰۱۰۸۳	۰/۰۰۱۵۳۳	۰/۰۱۷۹۵۵
Y8	Y4, Y5	۳۶/۲۷۵۵	۶/۸۱۴۲۱۱	-۸/۳۸۶۱۶	-۱/۵۳۴۳۷	-۱/۰۰۹۶۵	۲/۶۶۷۵۴۳
Y9	Y6, Y7	-۸/۵۴۳	۱/۰۰۹۹۰۹	۰/۵۲۴۱۸	-۴/۷۶۷۳۹	-۴/۷۵۲۹	۹/۵۱۱۳۵۸
Y10	Y8, Y9	-۲۲/۴۶۲۸	۲/۶۳۵۹۳	-۰/۰۲۰۶۶	-۰/۰۶۸۵۷	-۰/۰۴۵۹۶	۰/۰۹۱۵۰۳



شکل ۶. تغییرات متغیر خروجی در اثر تغییرات متغیرهای ورودی برای نمونه‌های خشک



شکل ۷. تغییرات متغیر خروجی در اثر تغییرات متغیرهای ورودی برای نمونه‌های مرطوب.

پارامتر خروجی (مقاومت مکعبی استاندارد) با توجه به تغییرات پارامترهای ورودی انجام شد. بر اساس این آنالیز مشخص گردید که تأثیر f_{core} ، N_{rebar} به ترتیب در مقایسه با سایر متغیرها چشمگیرتر است.

۷. مراجعها

- [1] Neville, A. M. "Properties of Concrete"; Fourth Ed., John Wiley and Sons, Inc., New York, 1996, 844p.
- [2] Munday, J. G. L.; Dhir, R. K. "Assessment of in Situ Concrete Quality by Core Testing, In Situ/Nondestructive Testing of Concrete, SP-82"; American Concrete Institute, Detroit, 1984, 393-410.
- [3] Yip, W. K.; Tam, C. T. "Concrete Strength Evaluation Through the Use of Small Diameter Cores"; Mag. Concrete Res. 1988, 40, 99-105.
- [4] Meiningner, R. C.; Wagner, F. T.; Hall, K. W. "Concrete Core Strength- The Effect of Length to Diameter Ratio"; J. Testing and Eval. 1977, 5, 147-153.
- [5] Bungey, J. H.; Millard S. G.; Grantham, M. G. "Testing of Concrete in Structures"; 4th Ed., Taylor & Francis, London and New York, 2006.

۶. نتیجه‌گیری

در این مطالعه سعی شده است که یک روش قدرتمند شناسایی سامانه به منظور پیش‌بینی مقاومت فشاری بتن بر اساس نتایج آزمایش مغزه‌گیری شامل میل‌گردهای فولادی گسترش یابد. یک مدل شبکه عصبی GMDH بهینه‌شده با الگوریتم ژنتیک و روش تجزیه مقادیر منفرد برای ایجاد یک مدل ریاضی بر مبنای پارامترهای ورودی نسبت طول به قطر مغزه، قطر مغزه، تعداد میل‌گردهای فولادی داخل مغزه، فاصله محور میل‌گرد از انتهای نزدیک‌تر مغزه و مقاومت فشاری مغزه برای تخمین مقاومت مکعبی استاندارد بتن به‌عنوان خروجی مدل پایه‌ریزی شد. نتایج به‌دست‌آمده از مدل شبکه عصبی GMDH بیانگر همبستگی عالی با نتایج آزمایشگاهی برای هر دو شرایط مختلف عمل‌آوری نمونه‌ها بودند و نشان داده‌شده که تخمین مقاومت مکعبی استاندارد بر اساس نتایج مقاومت مغزه‌های حاوی میل‌گرد با دقت بالا انجام‌پذیر است. همچنین آنالیز حساسیت روابط چندجمله‌ای استخراج‌شده از شبکه عصبی GMDH از طریق ارزیابی تغییرات

- [18] Astrom, K. J.; Eykhoff, P. "System Identification a Survey"; *Automatica* 1971, 7, 123-62.
- [19] Koza. J. "Genetic Programming on the Programming of Computers by Means of Natural Selection"; Cambridge (MA), MIT Press, 1992.
- [20] Kristinson, K.; Dumont, G. "System Identification and Control Using Genetic Algorithms"; *IEEE Trans. Syst. Man Cybernet* 1992, 22, 1033-1046.
- [21] Iba, H.; Kurita, T.; De Garis, H.; Sato T. "System Identification Using Structured Genetic Algorithms"; *Proc. 5th Int. Conf. on Genetic Algorithms* 1993, 279-286.
- [22] Ivakhnenko, A. G. "Polynomial Theory of Complex Systems"; *IEEE Trans. Syst. Man Cybernet* 1971, SMC-1 364-378.
- [23] Farlow, S. J. "Self-organizing Method in Modeling: GMDH Type Algorithms"; Marcel-Dekker Inc., New York, 1984.
- [24] Yao, X. "Evolving Artificial Neural Networks"; *Proceedings of the IEEE* 1999, 87, 1423-1447.
- [25] Narimanzadeh, N.; Darvizeh, A.; Darvizeh, M.; Gharababaei, H. "Modeling of Explosive Cutting Process of Plates Using GMDH-type Neural Network and Singular Value Decomposition"; *J. Mater. Process. Tech.* 2002, 128, 80-87.
- [26] Narimanzade, N.; Darvizeh, A.; Ahmadzadeh, G. R. "Hybrid Genetic Design of GMDH-type Neural Networks Using Singular Value Decomposition for Modeling and Prediction of the Explosive Cutting Process"; *J. Eng. Manuf.* 2003 217, 779-790.
- [27] Darvizeh, A.; Nariman-Zadeh, N.; Gharababei, H. "GMDH-type Neural Network Modeling of Explosive Cutting Process of Plates Using Singular Value Decomposition"; *Proc. Int. 15th Multiconf. European Simulation, Prague*, 2001.
- [28] Lemke, F.; Mueller, J. A. "Self-organizing Data Mining: an Intelligent Approach to Extract Knowledge from Data"; Libri Press, BoD Hamburg, 2000.
- [6] Bungey, J. H. "Determining Concrete Strength by Using Small Diameter Cores"; *Mag. Concrete Res.* 1979, 107, 91-98.
- [7] Khoury, S.; Aliabdo, A.; Ghazy, A. "Reliability of Core Test-Critical Assessment and Proposed New Approach"; *Alexandria Eng. J.* 2014, 53, 169-184.
- [8] Loo, Y. H.; Tan, C. W.; Tam, C. T. "Effects of Embedded Reinforcement on Measured Strength of Concrete Cylinders"; *Mag. Concrete Res.* 1989, 41, 11-18.
- [9] Gaynor, R. D. "Effect of horizontal Reinforcing Steel on the strength of Molded Cylinders"; *Amer. Conc. I.* 1965, 62, 837-840.
- [10] BS EN 12504-1 "Testing Concrete in Structures. Cored Specimens. Taking, Examining and Testing in Compression"; BSI British Standards, 2009.
- [11] BS 6089 "Guide to Assessment of Concrete Strength in Existing Structures"; British Standards Institution, 1981.
- [12] BS 1881: Part 120 "Method for Determination of the Compressive Strength of Concrete Cores"; British Standards, 1983.
- [13] "Concrete Society, Concrete Core Testing for Strength"; Concrete Society Technical Report 11, 1976.
- [14] ASTM C 42-90 "Test for Obtaining and Testing Drilled Cores and Sawed Beams of Concrete"; *Annual Book of ASTM Standards*, (2008).
- [15] ACI Committee 214.4-03 "Guide for Obtaining Cores and Interpreting Compressive Strength Results"; American Concrete Institute, 2003.
- [16] Madandoust, R.; Ghavidel, R.; Nariman-Zadeh, N. "Evolutionary Design of Generalized GMDH-Type Neural Network for Prediction of Concrete Compressive Strength Using UPV"; *Comp. Mater. Sci.* 2010, 49, 556-567.
- [17] Madandoust, R.; Bungey, J. H.; Ghavidel, R. "Prediction of the Concrete Compressive Strength by Means of Core Testing Using GMDH-type Neural Network and ANFIS Models"; *Comp. Mater. Sci.* 2012, 51, 261-272.