

مقایسه عملکرد مدل‌های رگرسیونی و تکاملی در تخمین مقاومت فشاری مغزه‌های بتنی

کمیل مومنی^{۱*}، سجاد غلامرضایی سرولات^۲

۱- استادیار فنی - گروه مهندسی عمران - دانشگاه فنی و حرفه‌ای - تهران - ایران

۲- استادیار فنی گروه مهندسی برق - دانشگاه فنی و حرفه‌ای - تهران - ایران

kmomeni@tvu.ac.

تاریخ پذیرش: ۱۴۰۱/۰۷/۰۵

تاریخ دریافت: ۱۴۰۱/۰۲/۲۰

چکیده

عملکرد مدل‌های رگرسیونی و شبکه عصبی GMDH تعمیم‌یافته که ساختار آن توسط الگوریتم ژنتیک و روش تجزیه مقادیر منفرد بهینه‌شده در پیش‌بینی مقاومت فشاری بتن با استفاده از نتایج آزمایش مغزه‌گیری با و بدون میلگرد بررسی شده است. پارامترهایی شامل؛ نسبت طول به قطر مغزه، قطر مغزه، قطر، تعداد و برون محوری متقارن میلگردها در داخل مغزه، فاصله محور میلگرد تا انتهای نزدیک‌تر مغزه و نیز مقاومت فشاری مغزه بعنوان متغیرهای مستقل و ورودی مدل‌های رگرسیونی و شبکه عصبی GMDH و نیز مقاومت فشاری بتن به‌عنوان متغیر پاسخ (یا خروجی مدل‌ها) در نظر گرفته شده است. نتایج به‌دست‌آمده نشان داد که مدل‌های بکار گرفته‌شده از قابلیت بالایی در بیان مسئله برخوردارند، چراکه بیش از ۹۵٪ تغییرات متغیر پاسخ با مدل‌های برازش‌شده در مدل‌های رگرسیونی و حدود ۹۹٪ تغییرات مقادیر متغیر پاسخ در مدل GMDH می‌تواند بیان شود. اما در جایگاه مقایسه، مدل GMDH با ساختار عمومی و بهینه‌شده با الگوریتم ژنتیک بهترین عملکرد را از خود نشان داده است. پس از آن، مدل‌های رگرسیونی غیر خطی برتری مشخصی را نسبت به مدل‌های خطی از خود نشان‌داشته‌اند.

واژگان کلیدی: مقاومت فشاری، مغزه بتنی، میلگرد، رگرسیون، GMDH، الگوریتم ژنتیک

۱- مقدمه

مشخصات سنگدانه، برای مغزه‌گیری و شرایط رطوبتی مغزه‌ها در هنگام آزمایش به عنوان فاکتورهای موثر بر رابطه بین مقاومت مغزه و مقاومت بتن متناظر مکهبی یا استوانه‌ای توسط پژوهشگرانی چون Bungey [1, 2] و سایرین [3 - 6] به‌طور جامع و کامل گزارش شده است. دیگر فاکتور مهم و موثر بر مقاومت مغزه حضور میلگرد در آن است. تاثیر حضور میلگرد بر مقاومت مغزه توسط محققین محدودی مطالعه شده است [7 - 9]. روشن است که وجود میلگرد در مغزه عدم اطمینان

در میان روش‌های مختلف، آزمایش مغزه‌گیری به شکل گسترده ای برای ارزیابی مقاومت درجای بتن پذیرفته شده است. مرور مطالعات پیشین نشان می‌دهد که آزمایش مغزه می‌تواند نتایج قابل اعتمادی را ارائه دهد اما تفسیر نتایج آن به تجربه، قضاوت مهندسی و ملحوظ داشتن فاکتورهای موثر متعدد نیازمند است و این عوامل از قابلیت اعتماد و سطح اطمینان آن می‌کاهد. عواملی چون قطر مغزه، نسبت طول به قطر ($\frac{L}{D}$)، سن بتن،

نتایج را افزایش داده و باید تا حد امکان از آن اجتناب شود [10]. هرچند در بخش‌هایی از سازه با تراکم میلگرد بالا ممکن است این امر میسر نباشد. چنانچه به هردلیلی، مغزه‌های استخراج‌شده از میلگردهای مسلح کننده عبور کرده و مغزه حاوی میلگرد باشد، ضرایب تصحیح این الزام در استانداردهای BS EN12504-1 [11] و BS 6089 [12] و BS Part 120: 1881 [13] و CS Report No.11 [14] گنجانده شده است. همچنین به تازگی اصلاحی در استاندارد اخیر، توسط Khoury و همکاران [9] ارائه شده است. این در حالی است که استانداردهایی چون ACI 214 [15] و ASTM C42 [16] توصیه می‌کنند که مغزه‌های بتنی برای آزمایش فشاری باید بیشتر بدون میلگرد باشند. شواهد متناقض و قابل توجهی در رابطه با تاثیر حضور میلگرد بر مقاومت مغزه گزارش شده است. برخی پژوهشگران تاثیر قابل توجهی را گزارش کرده‌اند [8]. در حالی که گروهی دیگر رفتارهای متناقض و مختلفی را بیان داشته‌اند [7, 8]. Gaynor تاثیر میلگردهای آجدار ۱۳mm و ۲۵mm را در چیدمان‌های مختلف مورد مطالعه قرار داد. نتایج نشان داد که حضور میلگرد باعث کاهش مقاومت‌های فشاری اندازه‌گیری شده به میزان ۱۸٪-۴٪ شده است. مطالعه انجام‌شده توسط Loo و همکاران [8] نشان داد که کاهش مقاومت فشاری به دلیل فولاد کارگذاری شده در نمونه‌ها، که برای نسبت طول به قطر ۲ مشاهده شده بود، آشکارا با کاهش نسبت طول به قطر $(\frac{L}{D})$ کاهش می‌یابد. همچنین برای $(\frac{L}{D}) = 1$ حتی افزایش مقاومت مغزه‌ها مشاهده شد که این نتیجه صرف‌نظر از موقعیت فولاد در مغزه بوده است. آنها همچنین بیان داشتند که وجود میلگرد در استوانه‌های بتنی با نسبت طول به قطر ۱ و به میزان تا ۴٪ نسبت حجمی، تاثیر منفی قابل توجهی بر مقاومت نداشته است. در عین حال، استاندارد Concrete Society [14] کاهش مقاومت مغزه را به صورت تابعی از اندازه و موقعیت میلگرد در مغزه ارائه کرده است. پس، نتایج متناقض پیشتر گفته‌شده در خصوص مقاومت مغزه حاوی میلگرد، مطالعه دقیق‌تر و جامع‌تری را در ارزیابی قابل اعتماد مقاومت طلب می‌کند. بنابراین هدف این مطالعه، تلاش برای روشن کردن این مطلب بر پایه

یک برنامه آزمایشگاهی جامع است. در این راستا، آزمایش مغزه با جزئیات فراوان و با توجه ویژه به مشکلات حضور یک و با چند میلگرد در آن و با آرایش‌های مختلف قرارگیری ارزیابی شده است. به نظر می‌رسد با توجه به پیچیده‌شدن موضوع و حضور پارامترهای مختلف، استفاده از روابط ساده آماری چندان رضایت بخش نباشد. در این راستا با توجه به تهیه و تدارک پایگاه جمعی از داده‌های آزمایشگاهی به دست آمده در این مطالعه، استفاده از مدل‌سازی‌های عددی شامل مدل‌های رگرسیونی و شبکه عصبی GMDH بهینه‌شده با الگوریتم ژنتیک برای پیش‌بینی مقاومت فشاری مغزه‌های بتنی حاوی میلگرد مد نظر است. تحلیل رگرسیونی یکی از روش‌های آماری برای تحلیل داده‌های چندعاملی است که حوزه کاربرد آن بیشترین وسعت را دارد. نتایج پرجاذبه آن از نظر مفهومی فرآیند ساده بکارگیری یک معادله برازش یافته است که ارتباط بین مجموعه‌ای از پارامترها را بیان می‌کند. موفقیت در تحلیل رگرسیونی نیاز به درک و تیزبینی در هر دو مقوله تئوری و مسائل عملی و کاربردی دارد و زمانی بروز می‌کند که تکنیک ارزیابی و به کارگیری و درستی‌آزمایی به درستی انجام گرفته باشد. شبکه عصبی GMDH بهینه‌شده با الگوریتم ژنتیک ابزاری قدرتمند در مدل‌سازی و برازش داده‌های آزمایشگاهی شناخته می‌شود [17, 18]. به شکلی که حتی با وجود داده‌های مغشوش و محدود می‌تواند عملکرد قابل قبولی داشته باشد. قابل ذکر است که مدل ساختار شبکه عصبی بکار گرفته‌شده در این بررسی و وزن‌های آن به طور همزمان توسط الگوریتم ژنتیک و تجزیه مقادیر منفرد^۱ (SVD) بهینه می‌شود. همچنین این شبکه با ساختار عمومی بکار برده شده است. به این معنی که برای ساخت نرون در لایه جدید از نرون‌ها در تمامی لایه‌های قبل استفاده می‌کنند و در آن قید استفاده الزامی از نرون‌های لایه قبل در ساخت لایه بعد که در ساختار قدیمی این شبکه وجود داشت برداشته شده است. بطور خلاصه در این مطالعه تاثیر ویژگیهای آزمایش مغزه‌گیری برای مغزه‌های با و بدون میلگرد شامل مشخصات مغزه و میلگرد و نیز چگونگی آرایش میلگردهای داخل مغزه به صورت (۱) نسبت طول به قطر مغزه

اشباع آتش از آزمایش در نظر گرفته شد. کمترین 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) خلاصه شده است.

جدول ۱. جزئیات مغزه های آزمایش

Core diameter (D), mm	L/D ratio	Rebar size (d _{rebar}) mm	Number of reinforcing bars (N _{rebar})	Cover steel bar (H), mm
75	2	16,10	2,1	75,50,30
100	2,1	16,10	3-1	75,50,30

Table 1: Details of test cores

۳- مروری بر روش های مدلسازی

به دلیل نبود یک رابطه تئوری خیلی دقیق از ارتباط بین نتایج آزمایش مغزه های حاوی میلگرد و مقاومت فشاری بتن ناشی از عوامل متعدد و تاثیرگذار بر نتایج، اینگونه به نظر می رسد که تنها راه ممکن که بتوان به آن اشاره کرد بهره گیری از تکنیک های مختلف در برقراری روابط تجربی و نیز برازش داده های ورودی و خروجی مدل ها به طرق هرچه دقیق تر و کامل تر باشد.

۳-۱- تحلیل رگرسیون

۳-۱-۱- مدل های خطی

در بعضی از مسائل ممکن است که تئوری خاصی برای مشاهده کردن چگونگی تغییر پاسخ با متغیرها موجود باشد اما در بسیاری موارد، هیچگونه رابطه تئوری خاصی وجود نداشته و در این صورت برای مشاهده رفتار و روند تغییر پاسخ می توان از رگرسیون بهره برد. در حالت کلی متغیر پاسخ y ممکن است به k متغیر مستقل بستگی داشته باشد. رابطه ۵-۲ یک مدل رگرسیون چند متغیره خطی با k متغیر رگرسیونی است.

$$y = \beta_0 + \sum_{i=1}^k \beta_i x_i + \varepsilon \quad (1)$$

(L/D)، (۲) قطر مغزه (D_{core})، (۳) قطر (d_{rebar})، (۴) تعداد (N_{rebar}) و (۵) برون محوری متقارن میلگرد داخل مغزه (SD)، (۶) پوشش میلگرد (H) و نیز (۷) مقاومت فشاری مغزه (f_{core}) در نظر گرفته شده است. به عبارت دیگر، نمونه های شامل این اطلاعات به عنوان متغیرهای مستقل (که می توانند ورودی مدل های رگرسیونی و شبکه عصبی GMDH را شکل دهند) و مقاومت فشاری بتن (f_{cube}) به عنوان متغیر پاسخ (یا خروجی مدل ها) مد نظر است.

۲- برنامه آزمایشگاهی

طرح اختلاط هایی برای دستیابی مقاومت مکعبی ۵۶ روزه ۲۱/۳ Mpa و ۴۸/۱ Mpa با نسبت های آب به سیمان ۰/۵۵ و ۰/۴ در نظر گرفته شد. مقادیر سیمان به ترتیب $250 \frac{kg}{m^3}$ و $380 \frac{kg}{m^3}$ انتخاب شد. همچنین مقادیر مصالح ریزدانه خوب دانه بندی شده و مصالح درشت دانه با بیشترین اندازه اسمی ۱۹ mm به ترتیب در محدوده های $9.05 - 9.85 \frac{kg}{m^3}$ و $953 - 1020 \frac{kg}{m^3}$ تعیین شد. در تمام اختلاط ها از سیمان پرتلند تیپ II، ماسه رودخانه ای شسته شده و مصالح درشت دانه شکسته استفاده شد. تأثیر میلگرد فولادی بر مقاومت مغزه های بتنی توسط پارامترهای مختلف شامل؛ قطر مغزه، نسبت طول به قطر مغزه، شرایط رطوبتی مغزه، سطح مقاومت بتن و همچنین قطر و تعداد میلگرد و موقعیت آن در مغزه ارزیابی شده است. برای هر طرح تیرهای بتنی مسلح و غیرمسلح به ابعاد $300 \times 300 \times 1000$ mm ساخته شده و در شرایط آزمایشگاه با رطوبت نسبی ۷۰٪ و دمای $25^\circ C$ به همراه نمونه های مکعبی کنترل 100 mm نگهداری شدند. میلگردهای فولادی مصرف شده از نوع آجدار با قطرهای 16 mm و 10 mm بودند. مغزه هایی با قطرهای 75 و 100 mm با نسبت ابعاد ۱ و ۲ از تیرهایی ساخته شده در جهت عمود بر جهت بتن ریزی گرفته شد. مغزه ها توسط ملات گوگرد کلاهی گذاری شده و به منظور ارزیابی اهمیت شرایط رطوبت مغزه در هنگام آزمایش، در شرایط عمل آوری مختلف شامل نگهداری در هوای آزاد به مدت ۷ روز و نیز دو روز

پارامترهای β_j و $j=0,1,\dots,k$ ضرایب رگرسیون نامیده می‌شوند. در واقع این مدل یک ابرصفحه در فضای k بعدی از متغیرهای رگرسیونی x_i است. پارامتر β_i نشان دهنده تغییرات موردنظر پاسخ y به ازای یک واحد متغیر در x_i است، وقتی که همه متغیرهای رگرسیونی باقیمانده دیگر ثابت نگه داشته می‌شوند. برای برآورد ضرایب رگرسیون در معادله فوق معمولاً از روش حداقل مربعات استفاده می‌شود.

۳-۱-۲- مدل‌های غیرخطی

مدل‌های رگرسیونی خطی چهارچوب وسیع و غنی را در بر می‌گیرد و نیاز به تحلیل‌های زیادی را نیز برآورده می‌سازد و پاسخ می‌دهد. هرچند این مدل‌های خطی برای همه مسائل نمی‌تواند مناسب باشد، زیرا گاهی اوقات متغیر پاسخ و متغیرهای رگرسیونی با توابع غیرخطی بهم مربوط می‌شوند.

یک مدل رگرسیون غیرخطی را می‌توان به صورت زیر در نظر گرفت:

$$y_i = f(x_i, \theta) + \varepsilon_i \quad (2)$$

که در آن $i = 0, 1, \dots, n$ و ε_i یک خطای تصادفی با $E(\varepsilon_i) = 0$ و $V(\varepsilon_i) = \sigma^2$ است و معمولاً فرض می‌شود که ε_i ها دارای توزیع نرمال هستند. تابع f تابع امید، x_i یک بردار از متغیرهای رگرسیونی و θ یک بردار نامعلوم از پارامترهای مدل است.

۳-۲- شبکه عصبی GMDH

مطابق الگوریتم GMDH یک مدل می‌تواند به صورت مجموعه ای از نرون‌ها بطوری که زوج‌های مختلف آنها در هر لایه از طریق یک معادله چند جمله‌ای 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

$$y_i = f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) \quad (i = 1, 2, \dots, M) \quad (3)$$

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

$$\hat{y}_i = \hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) \quad (i = 1, 2, \dots, M) \quad (4)$$

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

$$\sum_{i=1}^M [\hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) - y_i]^2 \rightarrow \min \quad (5)$$

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:

$$y = a_0 + \sum_1^n a_i x_i + \sum_1^n \sum_1^n a_{ij} x_i x_j + \sum_1^n \sum_1^n \sum_1^n a_{ijk} x_i x_j x_k + \dots \quad (6)$$

که به چند جمله‌ای Kolmogorov-Gabor شناخته می‌شوند [19-24]. این فرم کامل از بیان ریاضی را می‌توان به صورت یک سیستم از چند جمله‌های مرتبه دو جزئی بیان نمود به طوری که شامل تنها دو متغیر (نرون) در فرم زیر باشند:

$$\hat{y} = G(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i x_j + a_4 x_i^2 + a_5 x_j^2 \quad (7)$$

که ضریب a_i در معادله (۷) به کمک تکنیک‌های رگرسیونی محاسبه می‌شوند [18, 19, 21, 22]. 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 معادله مرتبه دو G_i برای برازش بهینه خروجی در کل مجموعه زوج داده‌های ورودی - خروجی به دست می‌آید. به عبارت دیگر:

$$E = \frac{\sum_{i=1}^M (y_i - G_i)^2}{M} \rightarrow \min \quad (8)$$

این معادله بردار بهترین ضرایب معادله (۷) برای کل مجموعه M داده سه گانه تعیین می‌کند. شایان ذکر است که این روش برای هر نرون از لایه پنهان بعدی مطابق با توپولوژی شبکه تکرار می‌شود [22, 21].

۳-۲-۱- کاربرد روش تجزیه مقادیر منفرد (SVD) در ساختار GMDH

در حالتی که تعداد معادلات بیشتر از مجهولات باشد SVD با روش کمترین مربعات خطا به حل چنین دستگاه‌هایی می‌پردازد.

$$A=U.W.V^T \quad (14)$$

در این روش هدف انتخاب بهینه بردار A است، که این مسئله به یافتن معکوس اصلاح‌شده ماتریس قطری W محدود می‌شود. در تعیین معکوس ماتریس قطری W، معکوس عناصر صفر یا نزدیک به صفر ($\frac{1}{w_j} = \infty$) برابر با صفر قرار داده می‌شوند. سپس بردار ضرایب بهینه‌شده A مطابق رابطه زیر محاسبه می‌شوند.

$$a = V \cdot \left[\text{diag} \left(\frac{1}{w_j} \right) \right] \cdot U^T \cdot Y \quad (15)$$

بکاربردن روش SVD در ساختار الگوریتم GMDH ابتکار نوینی بوده و نیز عاملی برای بهینه‌سازی این الگوریتم به شمار می‌آید.

۳-۲-۲- کاربرد ژنتیک و ژنوم معرف شبکه های عصبی GMDH

ژنوم یا نمایش کروموزم که جزئیات ساختاری شبکه-CS GMDH را نشان می‌دهد از رشته‌هایی که اجزای آن حروف الفبا هستند ساخته شده است. در این روش کدگذاری داده‌های مختلف ورودی با حروف الفبا نامگذاری شده‌اند و هر کروموزم رشته‌ای است که از به هم پیوستن داده‌های ورودی نامگذاری شده ایجاد شده است. بنابراین داده‌های ورودی $X = \{x_1, x_2, x_3, \dots, x_n\}$ را می‌توان به صورت رشته‌ای به هم پیوسته از نشانه‌های $\alpha \in \{a, b, c, d, \dots\}$ و جمعیت‌ها را به صورت $chromosome = (\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_n)$ که $a, b, c, \dots$ نام

در فرم اصلی الگوریتم GMDH، همه حالت‌های ممکن دو متغیر مستقل از مجموع n متغیر ورودی به منظور تشکیل چند جمله‌ای‌های رگرسیون به فرم معادله (۷) در نظر گرفته می‌شوند به طوری که بهترین برازش‌های مشاهدات وابسته $(y_i, i = 1, 2, \dots, M)$ در جهت ارضای کمترین مربعات به دست آید. 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 سه گانه $\{(y_i, x_{ip}, x_{iq}) (i = 1, 2, \dots, M)\}$ 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 زیر مجموعه مرتبه دو به فرم معادله (۷) برای هر ردیف از M داده سه گانه، معادلات ماتریسی به آسانی به صورت زیر به دست می‌آید:

$$Aa = Y \quad (9)$$

که a بردار ضرایب ناشناخته از چند جمله‌ای‌های مرتبه دو معادله (۷) است.

$$a = \{a_0, a_1, a_2, a_3, a_4, a_5\} \quad (10)$$

$$Y = \{y_1, y_2, y_3, \dots, y_M\}^T \quad (11)$$

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

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}x_{1q} & x_{1p}^2 & x_{1q}^2 \\ 1 & x_{2p} & x_{2q} & x_{2p}x_{2q} & x_{2p}^2 & x_{2q}^2 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 1 & x_{Mp} & x_{Mq} & x_{Mp}x_{Mq} & x_{Mp}^2 & x_{Mq}^2 \end{bmatrix} \quad (12)$$

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

$$a = (A^T A)^{-1} A^T Y \quad (13)$$

شکل ۲. کروموزوم مربوط به شبکه عصبی نوع GS-GMDH




Fig. 2. Chromosome related to structure of generalized CS-GMDH type

با توجه به شکل‌های (۳ و ۴) عملگر پیوند می‌تواند دو نوع شبکه GS و CS را به همدیگر تبدیل کند. این عملگر قابلیت ترکیب کروموزوم‌هایی با طول‌های متفاوت را دارد. همچنین عملگر جهش با تغییر یک یا چند بایت اطلاعاتی از یک کروموزوم، کروموزومی با خواص جدید تولید می‌کند. برای نمونه $abbcadad$ (شبکه نوع GS) را به $abbcadad$ (شبکه نوع CS) تبدیل می‌کند.

شکل ۳. تبدیل ژنوم $abbcadad$ از نوع GS، به ژنوم $abbc$ از نوع CSFig. 3. Converting genome $abbcadad$ GS type to genome $abbc$ CS type

شکل ۴. چگونگی اعمال عملگر پیوند بر روی شبکه عصبی از نوع GS-GMDH




Fig. 4. How to apply the graft operator on structure of generalized CS-GMDH type

۴- نتایج و بحث

مستعار داده‌های $X_1, X_2, X_3, \dots$ می‌باشند، معرفی کرد. برای مثال در صورتیکه تعداد ۴ داده ورودی وجود داشته باشد ۴ حرف الفبا مثل a, b, c, d را می‌توان به صورت رشته‌های تک حرفی که از به هم پیوستن آنها کروموزوم تشکیل خواهد شد، برای معرفی شبکه‌های مختلف و نیز کروموزوم‌های متفاوت استفاده کرد. بنابراین طول هر کروموزوم $k \in \{1, 2, 3, \dots, (n_1 + 1)\}$ است که n_1 تعداد لایه‌های مخفی می‌باشد و می‌توان به راحتی آن را در شبکه CS-GMDH ترجمه کرد، با این توجه که در چنین شبکه‌ای هر نرون تنها بر مبنای دو نرون لایه قبلی بنا نهاده شده است. این شبکه‌ها را شبکه‌های پیشخور^۳ گویند. برای نمونه کروموزومی مانند $abbcadbd$ شبکه CS-GMDH منحصر به فردی را ایجاد می‌کند که شامل ۴ داده ورودی و یک داده خروجی است که در شکل (۱) نمایش داده شده است. باید در نظر داشت که در این جا دو لایه مخفی وجود دارد که طول رشته در این مورد به ویژه برابر با $2^{2+1} = 8$ است.

شکل ۱. ساختار شبکه عصبی از نوع CS-GMDH




Fig. 1. Evolved structure of generalized CS-GMDH type
از مفاهیم بیان شده در کدگذاری شبکه‌های CS-GMDH استفاده می‌شود تا کدگذاری شبکه‌های GS-GMDH به شکل مطلوبی انجام گیرد. هر نرون به طول 2^n متعلق به لایه n ام است. برای شبکه $abbcadad$ کلیه نرون‌ها با طول دو (2^1) متعلق به لایه اول $ad|bc|ab|bc$ و کلیه نرون‌ها با طول چهار (2^2)، متعلق به لایه دو $abbc|acbc$ هستند. از این خاصیت استفاده می‌شود تا ژنومی را برای شبکه عصبی نوع GS-GMDH تشکیل شود. در شبکه عصبی نوع GS-GMDH نرون‌ها با طول‌های مختلف با یکدیگر ترکیب می‌شوند. در حقیقت نرون با طول کوچکتر باید از چند لایه مخفی جهش کند و با نرون با طول بزرگتر ترکیب شود (شکل ۲ نرون ad).

۴-۱- نتایج مدل سازی رگرسیون

۴-۱-۱- رگرسیون خطی

بر مبنای توضیحات ارائه شده، فرم و توانایی مدل های رگرسیون خطی چند متغیره و اهمیت ضرایب رگرسیونی بر اساس داده های آزمایشگاهی بدست آمده برای نمونه های قرار گرفته در دو شرایط عمل آوری مختلف، به منظور پیش بینی مقاومت فشاری مکعبی بتن و با به کارگیری پارامترهای ورودی شامل؛ (۱) نسبت طول به قطر مغزه، (۲) قطر مغزه، (۳) قطر، (۴) تعداد و (۵) برون محوری متقارن میلگرد داخل مغزه، (۶) پوشش میلگرد و نیز (۷) مقاومت فشاری مغزه در جدول (۲) قابل ارزیابی است. در این جدول مقادیر ضرایب رگرسیونی استاندارد شده، t-value (در سطح اطمینان ۹۵٪) و همچنین Sig (p)-Value نشان داده شده است.

در این مطالعه، برپایه اطلاعات گسترده آزمایشگاهی شامل ویژگی های مختلف مغزه های با و بدون میلگرد مدل های رگرسیون خطی و غیرخطی، شبکه عصبی GMDH بهینه شده با الگوریتم ژنتیک در تبیین رفتار سیستم آزمایشگاهی بکار برده شدند و قابلیت این مدل ها در برآورد مقاومت فشاری مقایسه و بحث شده است. باید عنوان نمود که بررسی نتایج همبستگی مقاومت فشاری مغزه ها و مقاومت فشاری نمونه های مکعبی بتن پراکندگی زیاد و دودستگی مشخصی را بر اساس پارامتر شرایط عمل آوری نشان داد. بنابراین این تصمیم گرفته شد که مدل های استخراج شده از هر نوع با توجه به شرایط عمل آوری و مجزا باشند. به عبارت دیگر، تمام مدل های مورد نظر این مطالعه از مدل های ریاضی و مدل های تکاملی به صورت مجزا برازش شده و از اثر فاکتور شرایط عمل آوری مغزه ها بعنوان پارامتر ورودی در مدل ها صرف نظر شد.

جدول ۲. اهمیت ضرایب رگرسیونی مدل های خطی

Model	air-dried				soaked for 2 days					
	Unstandardized Coefficients		Standardized Coefficients	T	Sig.	Unstandardized Coefficients		Standardized Coefficients	t	Sig.
	B	Std. Error	Beta			B	Std. Error	Beta		
(Constant)	-19.768	4.279		-4.620	0.000	-25.436	5.291		-4.807	0.000
L/D	4.738	0.709	0.145	6.682	0.000	5.348	0.763	0.163	7.011	0.000
D_core	0.064	0.037	0.040	1.925	0.058	0.078	0.041	0.048	1.885	0.063
d_rebar	-0.030	0.088	-0.007	-0.337	0.737	0.048	0.115	0.009	0.416	0.679
N_rebar	3.900	0.562	0.168	6.941	0.000	4.611	0.616	0.171	7.482	0.000
SD	0.026	0.036	0.015	0.731	0.467	0.030	0.037	0.017	0.801	0.426
H	0.029	0.021	0.034	1.419	0.159	0.033	0.025	0.030	1.293	0.200
f_core	1.665	0.033	1.016	50.629	0.000	1.742	0.037	1.012	47.639	0.000

a. Dependent Variable: f_{cube}

Table 2. Importance of regression coefficients of linear models

مراجعه به جدول (۲) می توان دید که متغیرهای قطر میلگرد و برون محوری آن و ضخامت پوشش بتن روی میلگرد در تبیین رفتار متغیر پاسخ ضعیف بوده و می توان گفت که نیازی به در نظر گرفتن آنها در مدل نهایی نیست.

۴-۱-۲- رگرسیون غیر خطی

مدل های ریاضی غیرخطی به صورت آزمایشی و تجربی به دست می آیند. از سویی، مدل غیرخطی را می توان بر مبنای توابع چند جمله ای، کسری، نمایی، توانی و یا ترکیبی از آنها در نظر گرفت. همچنین بیشتر ممکن است که پیش آگاهی از بهترین

مقادیر t و Sig (p) بیانگر نشانه ای از اهمیت متغیر پیشگویی کننده است، به طوری که مقادیر بزرگ قدرمطلق t-value و مقادیر کوچک P-value (کوچکتر از ۰/۰۵ که بیشتر انتخاب شده بود) بیان می کند که متغیر مستقل پیشگویی کننده تاثیر زیادی بر متغیر معیار یا پاسخ دارد. باید توجه داشت که اگر مقدار P-value بزرگتر از ۰/۰۵ نتیجه شود، این متغیر مستقل مورد بررسی از مدل خارج شده و تحلیل رگرسیون بر مبنای متغیرهای مستقل باقیمانده انجام می گیرد. به عبارت دیگر، متغیرهای مستقل با مقدار P-value کوچکتر از ۰/۰۵ در سطح اطمینان ۹۵٪ برای ایجاد مدل حائز اهمیت تلقی می شود. با

خواهد بود. در این مطالعه بر مبنای روند گفته شده، مناسب-ترین روابط غیرخطی پیش‌بینی مقاومت مکعبی بتن برای هر دو حالت شرایط عمل‌آوری محیطی و ۲ روز مرطوب به صورت زیر به دست آمده است:

$$f_{cube} = \left\{ \alpha_1 \times \left(\frac{1}{1.5 + \frac{\alpha_2}{L/D}} \right) \times (1 + D_{core}^{\alpha_3} \times H^{0.1}) \times (1 + \alpha_4 \times d_{rebar} + \alpha_5 \times N_{rebar} + \alpha_6 \times SD) \right\} \times f_{core} \quad (16)$$

مناسب و تنظیم کردن ضرایب آنها یعنی a_i ها است. ضرایب به دست آمده با روش Levenberg-Marquardt در جدول (۳) برای شرایط عمل‌آوری محیطی و مرطوب ارائه شده است.

جدول ۳. ضرایب مدل‌های رگرسیونی غیرخطی

Parameter	air-dried for 7 days				soaked for 2 days			
	Estimate	Std. Error	95% Confidence Interval		Estimate	Std. Error	95% Confidence Interval	
			Lower Bound	Upper Bound			Lower Bound	Upper Bound
a1	2.719	0.08	2.561	2.877	0.498	0.106	0.287	0.709
a2	0.664	0.063	0.539	0.788	0.681	0.063	0.556	0.807
a3	-6.1	0.067	-6.252	-5.948	0.237	0.058	0.121	0.353
a4	-0.004	0.002	-0.008	-0.001	0.001	0.002	-0.004	0.006
a5	0.19	0.013	0.164	0.217	0.19	0.018	0.154	0.225
a6	0.001	0.001	-0.001	0.002	0.001	0.001	-0.001	0.002

Table 3. Importance of regression coefficients of nonlinear models

شکل توانایی کم و بیش بالاتر مدل‌های غیر خطی در پیش‌بینی مقاومت واقعی بتن بر مدل‌های خطی آشکار است.

عملکرد قابل قبول مدل‌های رگرسیونی در پیش‌بینی مقاومت مکعبی بتن در شکل (۵) نشان داده شده است. بر اساس این

شکل ۵. مقایسه عملکرد مدل‌های رگرسیونی خطی و غیر خطی (الف) نمونه‌های خشک (ب) نمونه‌های اشباع




Fig. 5. Comparison of the performance of linear and nonlinear regression models (a) Air-dried samples (b) Soaked samples

گذراندن آموزش رابطه بین ورودی‌ها و خروجی را به صورت یک چند جمله‌ای برآورد کند که دقت این چند جمله‌ای به داده‌ها و ساختار شبکه بستگی دارد. تابع هدف به صورت تابعی از متغیرهای در نظر گرفته شده، که پیشتر کاملاً تشریح شدند،

به دست آوردن یک تابع چند جمله‌ای که با دریافت متغیرهای در نظر گرفته شده تاثیرگذار بتواند پارامتر خروجی را برگرداند هدف این بخش است. شبکه عصبی GMDH می‌تواند پس از

۲-۴- مدل سازی شبکه عصبی GMDH

شکل ۶. ساختار مدل شبکه عصبی GMDH برای نمونه های خشک




Fig. 6. Evolved structure of generalized GMDH-type for air-dried samples

شکل ۷. ساختار مدل شبکه عصبی GMDH برای نمونه های مرطوب




Fig. 7. Evolved structure of generalized GMDH-type for soaked samples

همان گونه که از شکل ها بر می آید پیکربندی ارتباط نرون ها فقط محدود به لایه های مجاور نیست. همچنین عملکردهای شبکه های GMDH تعمیم یافته در شکل های (۸ و ۹) ارائه شده است. این اشکال نشان می دهند که مقادیر واقعی پیش بینی شده و مقاومت مکعبی استاندارد به خوبی به هم مرتبط (با نسبت ۱) بوده بنابراین توانایی پیش بینی و تخمین بالای مدل شبکه عصبی GMDH در مقایسه با مدل های رگرسیون نتیجه می شود.

شکل ۸. تغییرات نسبت خروجی مدل ها به مقدار واقعی برای شرایط عمل آوری خشک




Fig. 8. Variation of models output ratio to real value for air-dried samples

برای پیش بینی مقاومت فشاری بتن بکار می رود. بر اساس تحلیل رگرسیون و همبستگی همه نتایج بر این نکته که متغیرهای قطر میلگرد و برون محوری متقارن میلگرد تاثیر بسیار ناچیزی در تبیین متغیر وابسته داشتند، پس در این بخش از شرکت دادن این مولفه های بردارهای ورودی در آموزش و آزمایش شبکه های عصبی صرف نظر شده است. در جدول (۴) مؤلفه های مهم الگوریتم ژنتیک ارائه شده است.

جدول ۴. مؤلفه های مهم الگوریتم ژنتیک

Population size=50	Generation=200
Mutation Probability = 0.01	Crossover Probability = 0.95

Table 4. Components of the Genetic Algorithm

برای این مدل بیشترین تعداد لایه های پنهان سه لایه انتخاب شد. با این انتخاب، بهترین ساختار بطور خودکار برای ۳ لایه پنهان و کمتر برگزیده می شود. انتخاب تعداد لایه های پنهان بیشتر به شدت بر پیچیدگی ساختار مدل می افزاید در حالی که تغییر چندانی در بهبود نتایج به دست نمی آید. از این گذشته، عملکرد بالای مدل شبکه عصبی با ۳ لایه پنهان بیشتر در پژوهش ها به اثبات رسیده است [17, 18]. به منظور اثبات قابلیت و توانایی پیش بینی مدل شبکه عصبی GMDH، داده ها در دو گروه مختلف آموزش و آزمایش تقسیم بندی شدند. داده های 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 روش های تکاملی این مطالعه بکار برده شدند. داده های آزمایش که شامل به ترتیب ۲۸ و ۲۱ نمونه ورودی - خروجی برای دو شرایط نگهداری خشک و مرطوب بودند، تنها برای آزمایش مدل های استخراج شده بکار برده شدند تا قابلیت و توانایی مدل های GMDH پایه ریزی شده را نشان دهند. پس این داده های آزمایش هیچ مشارکتی در بخش آموزش شبکه نداشتند. ساختار مدل شبکه عصبی GMDH دارای ۳ لایه پنهان در شکل (۶ و ۷) نشان داده شده است.

۳-۴- ارزیابی عملکرد مدل‌های در نظر گرفته شده

برای مقایسه عملکرد پیش‌بینی مدل‌های استخراج شده، از شاخص‌های ضریب تعیین تعدیل یافته^۱ (R_{adj}^2)، جذر میانگین مربعات خطی^۲ (RMSE) و مقدار اعتبار^۳ (VAF) و متوسط قدر مطلق خطاهای نسب^۴ (MAPE) استفاده شده است که در روابط روابط ۱۷ تا ۲۰ دیده می‌شود.

شکل ۹. تغییرات نسبت خروجی مدل‌ها به مقدار واقعی برای شرایط عمل آوری مرطوب



Fig. 9. Variation of models output ratio to real value for soaked samples

را از خود نشان داده است که این برتری با در نظر داشتن این موضوع که حدود ۷۵ درصد از داده‌ها در آموزش مدل عصبی نقش داشته‌اند برجسته‌تر می‌شود. پس از آن، مدل‌های رگرسیونی غیرخطی برتری مشخصی را نسبت به مدل‌های خطی از خود نشان داده‌اند. شایان ذکر است که اعتبار مدل‌های ارائه‌شده در این مطالعه برای انواع دیگر بتن و نیز خارج از محدوده‌های بررسی شده نیازمند مطالعات بیشتری است.

شکل ۱۰. مقایسه شاخص آماری R_{adj}^2 مدل‌های رگرسیونی و شبکه عصبی برای شرایط عمل آوری مختلف




Fig. 10. Comparison of statistical parameters R_{adj}^2 of regression and neural network models for different curing conditions

$$(۱۷)$$

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

$$(۱۸)$$

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

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

$$(۱۹)$$

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

$$(۲۰)$$

در این روابط y, y', p, n به ترتیب بیانگر مقدار مشاهده شده، مقدار پیش‌بینی، تعداد پارامترهای مدل و تعداد نمونه‌ها است. پارامترهای برآورد خطا شامل $R_{adj}^2, RMSE, MAPE, VAF$ بر اساس عملکرد مدل‌های در نظر گرفته شده در اشکال (۱۰) تا (۱۳) نمایش داده شده است. بر اساس این اشکال، دقت مدل‌های ارائه شده به وضوح تایید می‌شود، چراکه بیش از ۹۵٪ تغییرات متغیر پاسخ با مدل‌های برازش شده در مدل‌های رگرسیونی و حدود ۹۹٪ تغییرات مقادیر متغیر پاسخ در مدل GMDH می‌تواند بیان شود. همان‌گونه که از نتایج بر می‌آید مدل‌های بکار گرفته شده از قابلیت بالایی در بیان مسئله برخوردارند. اما در جایگاه مقایسه، مدل GMDH با ساختار عمومی و بهینه شده با الگوریتم ژنتیک و SVD بهترین عملکرد

۵. نتیجه گیری

برای پیش‌بینی مقاومت فشاری بتن از مدل‌سازی نتایج مغزه-گیری برای مغزه‌های با و بدون میلگرد از مدل‌های رگرسیونی و شبکه عصبی GMDH تعمیم یافته که ساختار و ضرایب آن با الگوریتم ژنتیک و روش SVD بهینه شده‌اند استفاده شده است. مقایسه بین نتایج آزمایشگاهی به دست‌آمده در این مطالعه و مقادیر متناظر پیش‌بینی شده توسط مدل‌ها نشان داد که این مدل‌ها توانایی بالایی در پیش‌بینی مقاومت فشاری بتن بر پایه نتایج آزمایش مغزه‌گیری داشته و نتایج به دست‌آمده بیانگر همبستگی عالی با نتایج آزمایشگاهی برای هر دو شرایط مختلف عمل‌آوری نمونه‌ها بوده است. لذا می‌توان بیان داشت که تخمین مقاومت مکعبی استاندارد بر اساس نتایج مقاومت مغزه‌های حاوی میلگرد با دقت بالا انجام پذیر است. همچنین بر اساس نتایج حاصل، شبکه عصبی GMDH در مقایسه با مدل‌های رگرسیونی خطی و غیر خطی عملکرد بسیار بالاتری داشته است. به طوریکه حدود ۹۹٪ تغییرات متغیر پاسخ در مدل GMDH و بیش از ۹۵٪ تغییرات مقادیر متغیر پاسخ در مدل‌های رگرسیونی می‌تواند بیان شود. قابل ذکر است که این برتری با در نظر داشتن این موضوع که ۷۵٪ از داده‌ها در تشکیل مدل عصبی نقش داشته‌اند برجسته‌تر می‌شود.

۶. مراجع

1. Bungey, J.H., Millard, S.G., & Grantham, M.G., (2006). "Testing of concrete in structures", fourth ed. Taylor & Francis, London and New York, 352p.
2. Bungey, J.H. (1979). "Determining concrete strength by using small-diameter cores", Magazine of Concrete Research, 31(107), 91-98.
3. Neville, A.M. (1996). "Properties of concrete", fourth ed., John Wiley and Sons, Inc., New York, 844p.
4. Meininger, R.C. Wagner, F.T. & Hall, K.W. (1977). "Concrete core strength-the effect of Length to Diameter ratio", Journal of Testing and Evaluation, 5(3), 147-153.
5. Yip, W.K. & Tam, C.T. (1988). Concrete strength evaluation through the use of small diameter cores", Magazine of Concrete Research, 40(143) 99-105.
6. Munday, J.G.L. & Dhir, R.K. (1984).

شکل ۱۱. مقایسه شاخص آماری RMSE مدل‌های رگرسیونی و عصبی برای شرایط عمل‌آوری مختلف




Fig. 11. Comparison of statistical parameters RMSE of regression and neural network models for different curing conditions

شکل ۱۲. مقایسه شاخص آماری MAPE مدل‌های رگرسیونی و عصبی برای شرایط عمل‌آوری مختلف




Fig. 12. Comparison of statistical parameters MAPE of regression and neural network models for different curing conditions

شکل ۱۳. مقایسه شاخص آماری VAF مدل‌های رگرسیونی و عصبی برای شرایط عمل‌آوری مختلف.




Fig. 13. Comparison of statistical parameters VAF of regression and neural network models for different curing conditions

- using GMDH-type neural network and ANFIS models", Computational Materials Science, 51(1), 261-272.
18. Madandoust, R., Ghavidel, R. & Nariman-zadeh, N., (2010). "Evolutionary design of generalized GMDH-type neural network for prediction of concrete compressive strength using UPV", Computational Materials Science, 49(3), 556-567.
 19. Farlow S. J. 1984 (Ed.), "Self-organizing Method in Modelling: GMDH Type Algorithms, Marcel-Dekker Inc.", New York, pp. 1-24.
 20. Yao, X. (1999) "Evolving artificial neural networks", Proceedings of the IEEE, 87(9), 1423-1447.
 21. Narimanzadeh, N., Darvizeh, A., Darvizeh, M., & Gharababaei, H., (2002). "Modeling of Explosive cutting process of plates using GMDH-type neural network and singular value decomposition", Journal of Materials Processing Technology, 128, 80-87.
 22. Narimanzadeh, N., Darvizeh, A. & Ahmadzadeh, G.R., (2003), "Hybrid Genetic Design of GMDH-type Neural Networks Using Singular Value Decomposition for Modeling and Prediction of the Explosive Cutting process", Journal of Engineering Manufacture Proceeding of the I MECH E Part B, 217, 779-790.
 23. Darvizeh, A. Nariman-Zadeh, N. & Gharababaei, H. (2001). "GMDH-type neural network modelling of explosive cutting process of plates using singular value decomposition", in Proceedings of the ESM'2001, Prague.
 24. Mueller. Lemke, J.-A., F. (2000). "Self-organizing Data Mining: An Intelligent Approach to Extract Knowledge from Data", Libri, Hamburg, 225p.
 7. Gaynor, R.D. (1965). "Effect of horizontal reinforcing steel on the strength of molded cylinders", J. Am. Concr. Inst., 62(7), 837-840.
 8. Loo, Y.H., Tan, C.W. & Tam, C.T. (1989). "Effects of embedded reinforcement on measured strength of concrete cylinders", Magazine of Concrete Research, 41(146), 11-18.
 9. Khoury, S. Aliabdo, A.A. & Ghazy, (2014). "A. Reliability of core test – Critical assessment and proposed new approach", Alexandria Engineering Journal, 53, 169-184.
 10. Neville, A. (2001). "Core tests – Easy to perform, not easy to interpret", Concrete International, 23(11), 59-68.
 11. BS EN 12504-1, (2000). "Testing concrete in structures – Cored specimens – Taking, examining and testing in compression", British Standards Institution, London, 8 pp.
 12. BS 6089, (1981). "Guide to Assessment of Concrete Strength in Existing Structures", British Standards Institution, 11 pp.
 13. BS 1881: Part 120: 1983, (1983). "Method for determination of the compressive strength of concrete cores", British Standards.
 14. Concrete Society, (1976). "Concrete Core Testing for Strength", Concrete Society Technical Report No. 11, 44 pp.; Addendum, 1987, pp. 45-59.
 15. ACI Committee 214.4-03, (2003). "Guide for Obtaining Cores and Interpreting Compressive Strength Results American Concrete Institute", Farmington Hills, Mich., 16pp.
 16. ASTM C42, (2008). "Standard method of obtaining and testing drilled cores and sawn beams of concrete", American Society for Testing and Materials, Philadelphia.
 17. Madandoust, R., Bungey, J.H. & Ghavidel, R., (2012). "Prediction of the concrete compressive strength by means of core testing

Comparative study of regression and evolutionary models for prediction of concrete compressive strength by means of concrete cores

K. Momeni¹, S. Gholamrezaei²

1. PHD of Civil Engineering, Department of Civil Engineering, Technical and Vocational University (TVU), Tehran, Iran

2. Department of Electrical Engineering, Technical and Vocational University (TVU), Tehran, Iran

Abstract:

Core testing is the most direct method to assess the in-situ concrete compressive strength in an existing structure, generally related to suspected construction malpractice or deficiency of concrete supply, to carry out the condition assessment of buildings before taking up repair and upgrading work. Although this test is quite simple to conduct, the results obtained may sometimes contain considerable errors because of the great variety of parameters involved. The general problems of core testing are well known. The factors including core diameter, length-to-diameter ratio (L/D), concrete age, aggregate characteristics, direction of coring and the moisture condition at the time of testing are known which affect the relationship between core strength and the corresponding standard cube or cylinder strength are fully reported by researchers. Another potential factor influencing the testing of cores is the presence of reinforcing bars within the core. The effects of the presence of steel bars on the strength of cores have been investigated by only a few researchers. Reinforcement bars passing through a core will increase the uncertainty of results and should be avoided wherever possible. Regression analysis and generalized GMDH network, whose structure is investigated using genetic algorithm and single-particle number optimization method for predicting the compressive strength of concrete using the results of coring tests with and without fittings. The form and ability of the multivariate linear regression models and the importance of regression coefficients based on the experimental data obtained for samples in two different processing conditions, in order to predict the cubic compressive strength of the concrete and using the input parameters including (1) the length to diameter ratio Core, (2) core diameter, (3) diameter, (4) number and (5) axial axial axis of the rebar in the core, (6) reinforcement of the rebar, and (7) core compressive strength as independent and input variables, as well as resistance Concrete pressure is evaluated as the response variable (or output of the models). This method is used for the GMDH neural network. The objective of the GMDH neural network method is to obtain a polynomial function that can be used to retrieve the output parameter by the input of the considered variables. The GMDH neural network can, after training, estimate the relationship between inputs and outputs in a polynomial, which depends on the accuracy of this polynomial on the data and structure of the network. The single-particle decomposition (SVD) method in the GMDH structure for the case where the number of equations is greater than that of unknowns, uses the least squares error method to solve such devices. The results showed that the models used have high ability to express the problem, since more than 95% of variations of response variables with fitted models in regression models and about 99% of changes in the response variable values in the GMDH model can be expressed. But in a comparative position, GMDH model with a general structure optimized with Genetic Algorithm and SVD has shown the best performance, with this superiority becoming noticeable, considering that about 75% of the data is involved in training the neural model. Subsequently, nonlinear regression models show a certain advantage over linear models.

Keywords: Compressive strength, Concrete core, Rebar, Regression , GMDH , Genetic algorithm.