

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

کمیل مومنی<sup>۱\*</sup>، سجاد غلامرضايی سرولات<sup>۲</sup>

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: ۱۴۰۱/۰۷/۲۰

## چکیده

عملکرد مدل‌های رگرسیونی و شبکه عصبی GMDH تعیین یافته که ساختار آن توسط الگوریتم ژنتیک و روش تجزیه مقادیر منفرد بهینه شده 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، قدرت، 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 رورویی مدل‌های رگرسیونی و شبکه عصبی GMDH و نیز مقاومت فشاری بتن بعنوان متغیر پاسخ (یا خروجی مدل‌ها) در نظر گرفته شده است. نتایج بدست آمده نشان داد که مدل‌های بکار گرفته شده از قابلیت بالایی در بیان مسئله برخوردارند، 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. اما در جایگاه مقایسه، مدل GMDH با ساختار عمومی و بهینه شده 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 نشان داشته‌اند.

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

## مشخصات سنگدانه، برای مغزه‌گیری و شرایط رطوبتی مغزه‌ها

در هنگام آزمایش به عنوان فاکتورهای موثر بر رابطه بین مقاومت مغزه و مقاومت بتن متناظر مکعبی یا استوانه‌ای توسط پژوهشگرانی چون Bungey [1, 2] و سایرین [3 - 6] به طور 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 [9 - 7]. روشن است که وجود میلگرد در مغزه عدم اطمینان

## ۱- مقدمه

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، قضابت مهندسی و ملاحظه 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،

یک برنامه آزمایشگاهی جامع است. در این راستا، آزمایش مغزه با جزئیات فراوان و با توجه ویژه به مشکلات حضور یک و یا چند میلگرد در آن و با آرایش‌های مختلف قرارگیری ارزیابی شده است. به نظر می‌رسد با توجه به پیچیده شدن موضوع و حضور پارامترهای مختلف، استفاده از روابط ساده آماری چندان رضایت بخش نباشد. در این راستا با توجه به تهیه و تدارک پایگاه جامعی از داده‌های آزمایشگاهی به دست آمده در این مطالعه، استفاده از مدل‌سازی‌های عددی شامل مدل‌های رگرسیونی و شبکه عصبی GMDH بهینه شده با الگوریتم ژنتیک برای پیش‌بینی مقاومت فشاری مغزه‌های بتونی 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 پرچاذبه آن از نظر مفهومی فرآیند ساده بکارگیری یک معادله برازش یافته است که ارتباط بین مجموعه‌ای از پارامترها را بیان می‌کند. موقیت در تحلیل رگرسیونی نیاز به درک و تیزبینی در هر دو مقوله تنوری و مسائل عملی و کاربردی دارد و زمانی بروز می‌کند که تکنیک ارزیابی و به کارگیری و درستی آزمایش به درستی انجام گرفته باشد. شبکه عصبی GMDH بهینه شده با الگوریتم ژنتیک ابزاری قدرتمند در مدل‌سازی و برازش داده‌های آزمایشگاهی شناخته می‌شود [17, 18]. به شکلی که حتی با وجود داده‌های مغوش و محدود می‌تواند عملکرد قابل قبولی داشته باشد. قابل ذکر است که مدل ساختار شبکه عصبی بکار گرفته شده در این بررسی و وزن‌های آن به طور همزمان توسط الگوریتم ژنتیک و تجزیه مقادیر منفرد<sup>۱</sup> (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

نتایج را فرایش 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 هر دلیلی، مغزه‌های استخراج شده 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 CS Report No.11 [13] و Part 120 [14] گنجانده شده است. همچنین به تازگی اصلاحی در استاندارد اخیر، توسط Khoury و همکاران [9] ارائه شده است. این در حالی است که استاندارهایی چون ACI 214 [15] و ASTM C42 [16] توصیه می‌کنند که مغزه‌های بتونی 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 نکرده‌اند [8]. در حالی که گروهی دیگر رفتارهای متناقض و مختلفی را بیان داشته اند [7, 8]. Gaynor تاثیر میلگردهای آجدار ۱۳mm و ۲۵mm در چیدمان‌های مختلف مورد مطالعه قرار داد. نتایج نشان داد که حضور میلگرد باعث کاهش مقاومت‌های فشاری اندازه‌گیری شده به میزان ۴-۱۸٪ شده است. مطالعه انجام شده 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 صرف نظر از موقعیت فولاد در مغزه بوده است. آنها همچنین بیان داشتند که وجود میلگرد در استوانه‌های بتونی 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 گفته شده 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

1. Singular Value Decomposition

اشیاع<sup>۲</sup> پیش از آزمایش در نظر گرفته شد. کمترین ۴۸۰ مغزه بتنه 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. جزییات مغزه‌های آزمایش

Core diameter (D), mm	L/D ratio	Rebar size (d <sub>rebar</sub> ) mm	Number of reinforcing bars(N <sub>rebar</sub> )	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 روش‌های مدلسازی

به دلیل نبود یک رابطه تئوری خیلی دقیق از ارتباط بین نتایج آزمایش مغزه‌های حاوی میلگرد و مقاومت فشاری بتن ناشی از عوامل متعدد و تاثیرگذار بر نتایج، اینگونه به نظر می‌رسد که تنها راه ممکن که بتوان به آن اشاره کرد بهره‌گیری از تکنیک‌های مختلف در برقراری روابط تجربی و نیز برآش داده‌های رودی و خروجی مدل‌ها به طرق هرچه دقیق‌تر و کامل‌تر باشد.

#### ۳-۱-۱-۳- تحلیل رگرسیون ۳-۱-۱-۳- مدل‌های 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 می‌توان از رگرسیون بهره برد. در حالت کلی متغیر پاسخ  $y$  ممکن است به  $k$  متغیر مستقل بستگی داشته باشد. رابطه ۲-۵ یک مدل رگرسیون چند متغیره خطی با  $k$  متغیر رگرسیونی است.

$$y = \beta_0 + \sum_1^k \beta_i x_i + \varepsilon \quad (1)$$

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

### ۲- برنامه آزمایشگاهی

طرح اختلاط‌هایی برای دست‌یابی مقاومت مکعبی ۵۶ روزه ۲۱/۳ Mpa و ۴۸/۱ Mpa با نسبت‌های آب به سیمان ۵۵/۰ و ۴/۰ در نظر گرفته شد. مقادیر سیمان به ترتیب  $\frac{kg}{m^3} 250$  و  $\frac{kg}{m^3} 380$  انتخاب شد. همچنین مقادیر مصالح ریزدانه خوب دانه‌بندی شده و مصالح درشت دانه با بیشترین اندازه اسمی ۱۹ mm ترتیب در محدوده‌های  $\frac{kg}{m^3} 953-1020$  و  $\frac{kg}{m^3} 985-1005$  تعیین شد. در تمام اختلاط‌ها از سیمان پرتلند تیپ II، ماسه رودخانه‌ای شسته شده و مصالح درشت دانه شکسته استفاده شد. تأثیر میلگرد فولادی بر مقاومت مغزه‌های بتنه 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 بتنه مسلح و غیرمسلح به ابعاد  $300 \times 300 \times 100$  mm ساخته شده و در شرایط آزمایشگاه با رطوبت نسبی ۷۰٪ و دمای ۲۵°C به همراه نمونه‌های مکعبی کترل ۱۰۰ mm نگهداری شدند. میلگردهای فولادی مصرف شده از نوع آجردار با قطرهای ۱۶ mm و ۱۰ mm بودند. مغزه‌هایی با قطرهای ۷۵ و ۱۰۰ mm با نسبت ابعاد ۱ و ۲ از تیرهای ساخته شده در جهت عمود بر جهت بتن ریزی گرفته شد. مغزه‌ها توسط ملات گوگرد کلاهک‌گذاری 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

کمیل مومنی و سجاد غلامرضاei سرولات  
 $X = (x_1, x_2, x_3, \dots, x_n)$  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:

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

حال امکان آموزش یک شبکه عصبی از نوع GMDH برای پیش‌بینی مقادیر خروجی  $\hat{y}_i$  برای هر بردار ورودی مشخص شده معمولاً از روش حداقل مربعات استفاده می‌شود.

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

اکنون مسئله تعیین یک شبکه عصبی GMDH به گونه‌ای است که مربع اختلافات بین مقدار واقعی خروجی و مقدار پیش‌بینی شده متضاظر به کمترین بررسی 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 گستته 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 جمله‌ای 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 (7) به کمک تکنیک‌های رگرسیونی محاسبه می‌شوند [18, 19, 21, 19, 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:

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

پارامترهای  $k=0,1,\dots,j$  و  $\beta_i$  ضرایب رگرسیون نامیده می‌شوند. در واقع این مدل یک ابرصفحه در فضای  $k$  بعدی از متغیرهای رگرسیونی  $x_i$  است. پارامتر  $\beta_i$  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 تغییر 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  $\varepsilon_i$  یک خطای تصادفی با  $E(\varepsilon_i) = 0$  و  $V(\varepsilon_i) = \sigma^2$  است و معمولاً فرض می‌شود که  $\varepsilon_i$  ها دارای توزیع نرمال هستند. تابع  $f$  تابع امید،  $x_i$  یک بردار از متغیرهای رگرسیونی و  $\theta$  یک بردار نامعلوم از پارامترهای مدل است.

### ۳-۲- شبکه عصبی

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 بسانند. 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

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 توبولوژی شبکه تکرار می‌شود [21, 22].

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

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

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

در این روش هدف انتخاب بهینه بردار  $A$  است، که این مسئله به یافتن معکوس اصلاح شده 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 ضرائب بهینه شده  $A$  مطابق رایطه زیر محاسبه می‌شوند.

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

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 شبکه‌های عصی GMDH

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

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،  $\frac{n(n-1)}{2}$  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:

$$A \cdot a = Y \quad (9)$$

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

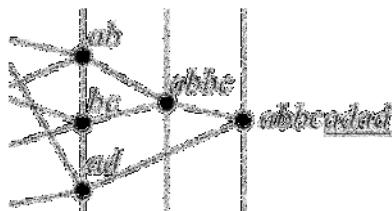


Fig. 2. Chromosome related to structure of generalized CS-GMDH type

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  $abbcc\_{dad}$  (شبکه نوع GS) را به  $abbcc\_{dad}$  (شبکه CS) تبدیل می‌کند.

شکل ۳. تبدیل ژنوم abbcadad از نوع GS، به ژنوم abbc از نوع CS



Fig. 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

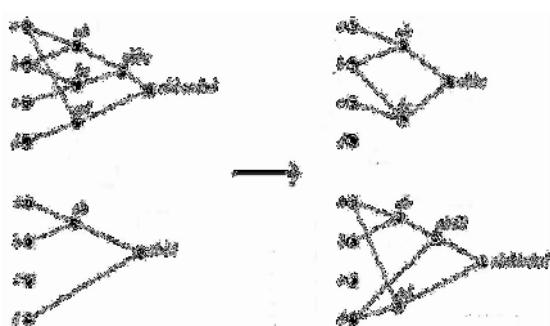


Fig. 4. How to apply the graft operator on structure of generalized CS-GMDH type

#### ۴- نتایج و بحث

مستعار داده‌های  $X_1, X_2, X_3, \dots$  می‌باشند، معرفی کرد. برای مثال در صورتیکه تعداد ۴ داده ورودی وجودداشته 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<sup>۳</sup> گویند. برای نمونه کروموزمی مانند CS-GMDH شبکه  $abccadbd$  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 وجوددارد که طول رشته در این مورد به ویژه برابر با  $2^{2+1} = 8$  است.

شکل ۱. ساختار شبکه عصبی از نوع CS-GMDH

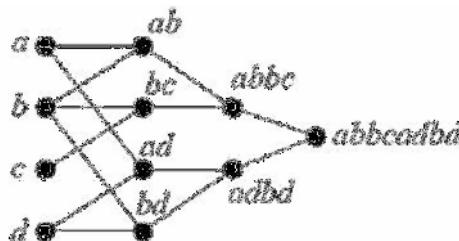


Fig. 1. Evolved structure of generalized CS-GMDH type  
از مفاهیم بیان شده در کدگذاری شبکه‌های CS-GMDH استفاده می‌شود تا کدگذاری شبکه‌های GS-GMDH به شکل مطلوبی انجام گیرد. هر نرون به طول  $2^n$  متعلق به لایه  $n$  است. برای شبکه  $abccadad$  کلیه نرون‌ها با طول دو ( $2^1$ ) متعلق به لایه اول  $ad|bc|ab|bc$  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 از نوع GS-GMDH تشکیل شود. در شبکه عصبی از نوع GS-GMDH نرون‌ها با طول های 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- نتایج مدل سازی رگرسیون

##### ۴-۱- 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 کار گیری پارامترهای ورودی شامل؛ (۱) نسبت طول به قطر مغزه، (۲) قطر مغزه، (۳) قطر، (۴) تعداد و (۵) برون محوری متقاضی 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 گستردۀ 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 شدن 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 دو دستگی 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 موردنظر این مطالعه از مدل های ریاضی و مدل های تکاملی به صورت مجزا برآرش 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			t	Sig.		
	Unstandardized Coefficients		Standardized Coefficients	T	Sig.	Unstandardized Coefficients	Standardized Coefficients			
	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 درنظر گرفتن آنها در مدل نهایی نیست.

##### ۴-۲- رگرسیون غیرخطی

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 (p) Sig بیانگر نشانه ای از اهمیت متغیر پیشگویی کننده است، به طوری که مقادیر بزرگ قدر مطلق t-value و مقادیر کوچک P-value (کوچکتر از ۰/۰۵) که پیشتر 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 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، مناسب‌ترین روابط غیرخطی پیش‌بینی مقاومت مکعبی بتن برای هر دو حالت شرایط عمل آوری محیطی و ۲ روز مرطوب به صورت زیر به دست آمده است:

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

مناسب و تنظیم کردن ضرایب آنها یعنی  $\alpha_i$ ‌ها است. ضرایب به دست آمده با روش Levenberg–Marquardt در جدول (۳) برای شرایط عمل آوری محیطی و مرطوب ارائه شده است.

ترکیب متغیر یا متغیرهای مستقل به صورت تکی یا گروهی با متغیر پاسخ سودمند باشد، روابط از طریق فرایندهای تکراری سعی و خطابی تا رسیدن به مناسب‌ترین ترکیب متغیرها ادامه می‌یابد. انتخاب نهایی مدل‌ها بر اساس ارزیابی عملکرد آنها

واحدهای متغیرهای به کاررفته در این معادله بر حسب میلی‌متر و نیوتن بر میلی‌متر مربع است. همچنین  $\alpha_i$  ضرایب رگرسیونی هستند. مهمترین قسمت کار پیداکردنتابع غیرخطی

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

عملکرد قابل قبول مدل‌های رگرسیونی در پیش‌بینی مقاومت شکل توانایی کم و بیش بالاتر مدل‌های غیرخطی 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 غیرخطی (الف) نمونه‌های خشک (ب) نمونه‌های اشباع

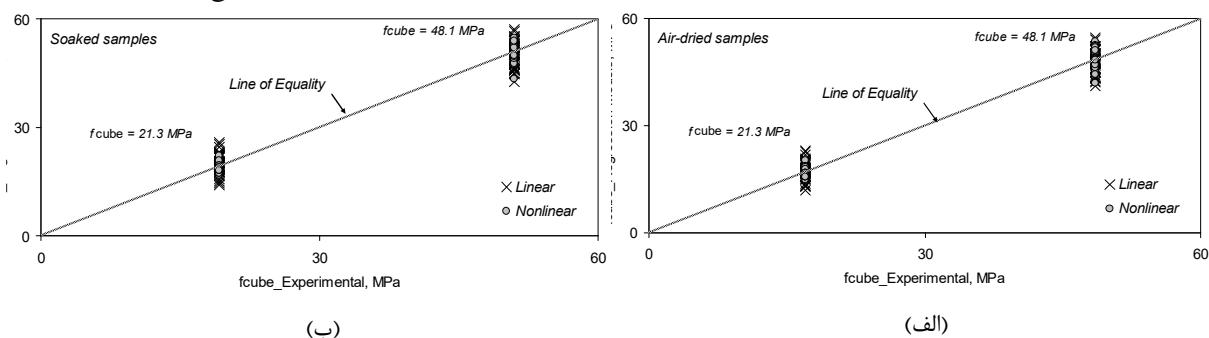


Fig. 5. Comparison of the performance of linear and nonlinear regression models (a) Air-dried samples (b) Soaked samples

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،

#### ۲-۴- مدل‌سازی شبکه عصبی GMDH

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

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

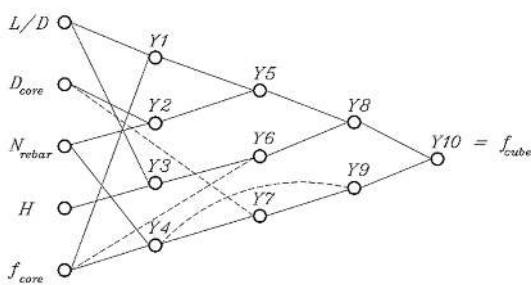


Fig. 6. Evolved structure of generalized GMDH-type for air-dried samples

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

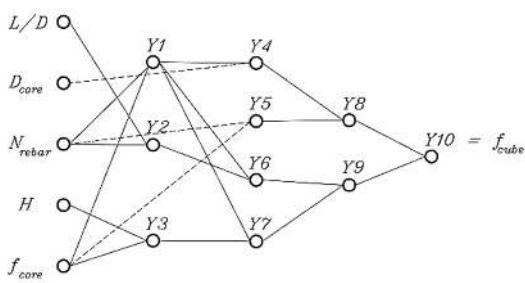


Fig. 7. Evolved structure of generalized GMDH-type for soaked samples

همان‌گونه که از شکل‌ها بر می‌آید پیکربندی ارتباط نرون‌ها فقط محدود به لایه‌های مجاور نیست. همچنین عملکردهای شبکه‌های GMDH تعمیم یافته در شکل‌های (۸) و (۹) ارائه شده است. این اشکال نشان می‌دهند که مقادیر واقعی پیش‌بینی شده و مقاومت مکعبی استاندارد به خوبی به هم مرتبط (با نسبت ۱) بوده بنابراین توانایی پیش‌بینی و تخمین بالای مدل شبکه عصبی GMDH در مقایسه با مدل‌های رگرسیونی نتیجه می‌شود.

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



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

برای پیش‌بینی مقاومت فشاری بتن بکار می‌رود. بر اساس تحلیل رگرسیون و همبستگی همه نتایج بر این نکته که متغیرهای قطر میلگرد و برون محوری متقاضی میلگرد تاثیر بسیار ناچیزی در تبیین متغیر وابسته داشتند، پس در این بخش از شرکت دادن این مولفه‌های بردارهای ورودی در آموزش و آزمایش شبکه‌های عصبی صرف نظر شده است. در جدول (۴) مولفه‌های مهم الگوریتم رئیسیک ارائه شده است.

جدول ۴. مؤلفه‌های مهم الگوریتم رئیسیک

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 لایه‌های پنهان سه لایه انتخاب شد. با این انتخاب، بهترین ساختار بطور خودکار برای ۳ لایه پنهان و کمتر برگزیده می‌شود. انتخاب تعداد لایه‌های پنهان بیشتر به شدت بر پیچیدگی ساختار مدل می‌افزاید در حالی که تغییر چندانی در بهبود نتایج به دست نمی‌آید. از این گذشته، عملکرد بالای مدل شبکه عصبی با ۳ لایه پنهان بیشتر در پژوهش‌ها به اثبات رسیده است [۱۷, ۱۸]. به منظور اثبات قابلیت و توانایی پیش‌بینی مدل شبکه عصبی GMDH، داده‌ها در دو گروه مختلف آموزش و آزمایش تقسیم بندی 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 بکار 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 استخراج شده بکار برده شدند تا قابلیت و توانایی مدل‌های GMDH پایه‌ریزی شده را نشان دهند. پس این داده‌های 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.

**۴-۳- ارزیابی عملکرد مدل‌های در نظر گرفته شده**

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

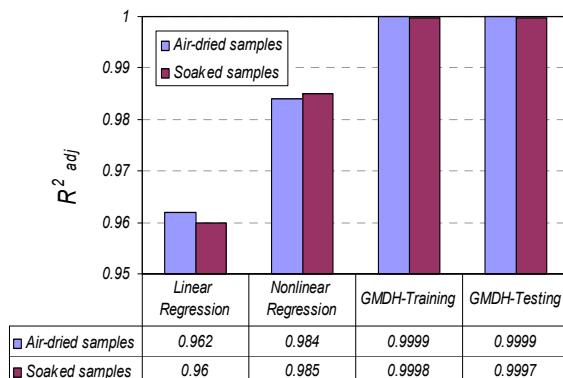
شکل ۹. تغییرات نسبت خروجی مدل‌ها به مقدار واقعی برای شرایط عمل آوری مرتبط



**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 داشته‌اند. شایان ذکر است که اعتبار مدل‌های ارائه شده در این مطالعه برای انواع دیگر بنن 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)

$$R_{adj}^2 = 1 - \frac{n-1}{n-p} (1 - R^2) \quad (18)$$

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

$$VAF = \left[ 1 - \frac{\text{var}(y - y')}{\text{var}(y)} \right] \times 100 \quad (19)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y - y'}{y} \right| \times 100 \quad (20)$$

در این روابط  $y$ ,  $y'$ ,  $n$ ,  $p$  و به ترتیب بیانگر مقدار مشاهده شده، مقدار پیش‌بینی، تعداد پارامترهای مدل و تعداد نمونه‌ها است. پارامترهای برآورد خطأ شامل  $R^2_{adj}$ , VAF, MAPE, RMSE،  $R^2$ ، 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 برآش 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 مستعلمه برخوردارند. اما در جایگاه مقایسه، مدل GMDH با ساختار عمومی و بهینه شده با الگوریتم ثنتیک و SVD بهترین عملکرد

3 - Values Account For

4 - Mean Absolute Percentage Error

1 - Adjusted

2 - Root Mean Square Error

## ۵. نتیجه‌گیری

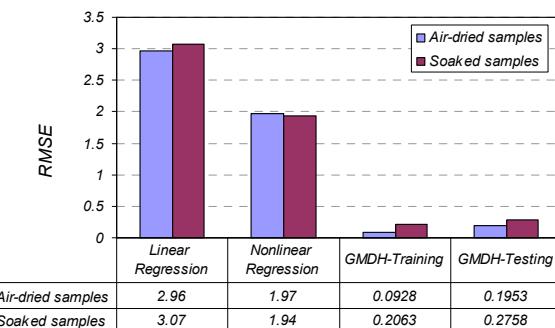
برای پیش‌بینی مقاومت فشاری بتن از مدل‌سازی نتایج مغزه‌گیری برای مغزه‌های با و بدون میلگرد از مدل‌های رگرسیونی و شبکه عصبی GMDH تعمیم یافته که ساختار و ضرایب آن با الگوریتم ژنتیک و روش SVD بهینه شده‌اند استفاده شده است. مقایسه بین نتایج آزمایشگاهی به دست‌آمده در این مطالعه و مقادیر متناظر پیش‌بینی شده 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 عمل آوری 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 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 بر جسته‌تر می‌شود.

## ۶. مراجع

- Bungey, J.H., Millard, S.G., & Grantham, M.G., (2006). "Testing of concrete in structures", fourth ed. Taylor & Francis, London and New York, 352p.
- Bungey, J.H. (1979). "Determining concrete strength by using small-diameter cores", Magazine of Concrete Research, 31(107), 91-98.
- Neville, A.M. (1996). "Properties of concrete", fourth ed., John Wiley and Sons, Inc., New York, 844p.
- 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.
- 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.
- Munday, J.G.L. & Dhir, R.K. (1984).

شکل ۱۱. مقایسه شاخص آماری RMSE مدل‌های رگرسیونی و عصبی

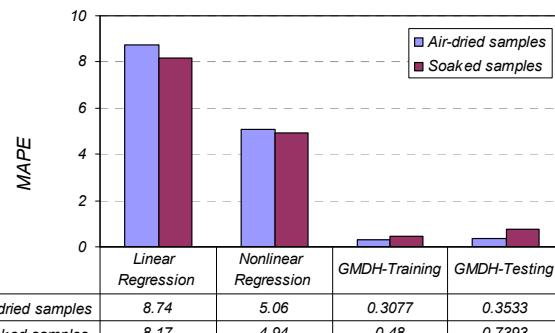
برای شرایط عمل آوری مختلف



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

شکل ۱۲. مقایسه شاخص آماری MAPE مدل‌های رگرسیونی و عصبی

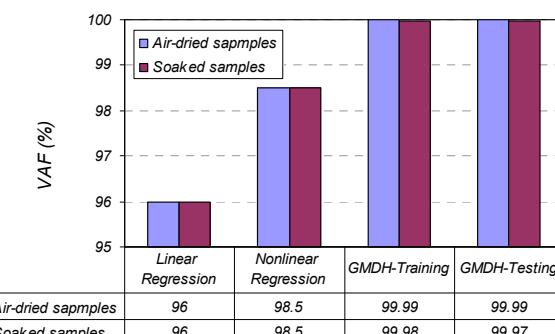
برای شرایط عمل آوری مختلف



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

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

شرایط عمل آوری مختلف.



**Fig. 13.** Comparison of statistical parameters VAF of regression and neural network models for different quering 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. Narimanzade, 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", inProceedings 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. Momeni<sup>1</sup>, S. Gholamrezaei<sup>2</sup>

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 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.