

Combining Neural Network Models to Prediction the Bond Strength of Glass FRP to Concrete

Farshad Peyman¹, Ahmad Fathi^{2*}

1- Ph.D. Student, Department of Civil Engineering – Construction Management and Engineering , Science and Research Branch, Islamic Azad University, Tehran, Iran.

2 -Assistant Professor, Department of Hydraulic Structures, Water Science Engineering Faculty, Shahid Chamran University, Ahvaz, Iran.

ABSTRACT

The use of FRP and other composite materials as bar or sheets is one of the most technically and economically viable options in the construction, refurbishment, and reinforcement of structures such as concrete structures. One of the most important issues to consider when using such materials is their bond strength to structural concrete. In this paper, the effect of combining ensemble prediction models with single estimation models on improving the results of single models is estimated to estimate the bond strength of GFRP bars to concrete. To this end, neural networks with predictive results inputs are first used to estimate the bond strength of GFRP to improve the best model result from the two previous models-Be. Then, by considering the prediction outputs of the first neural network model and the best single model above mentioned as input, the neural networks are again used to present a better model than the first ANN model. The final results show the reduction of the prediction error of the ANN model combined with single and ensemble methods compared to the single models previously presented, the weighted average output model of the two single models above and the ANN model. The combination of the two models usefulness a single.

ARTICLE INFO

Receive Date: 16 January 2020
Revise Date: 15 March 2020
Accept Date: 02 April 2020

Keywords:

*Bond strength of GFRP bar
Structural concrete
Artificial neural networks
Combination of ensemble and single models
MATLAB software*

All rights reserved to Iranian Society of Structural Engineering.

doi: <https://dx.doi.org/10.22065/jsce.2020.216063.2051>

*Corresponding author: Ahmad Fathi
Email address: a.fathi@scu.ac.ir

ترکیب مدل‌های شبکه عصبی برای پیش‌بینی مقاومت چسبندگی میلگردهای پلیمری با الیاف شیشه به بتن

فرشاد پیمان^۱، احمد فتحی^{۲*}

۱- دانشجوی دکتری، گروه عمران- مدیریت ساخت، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

۲- استادیار، دانشگاه شهید چمران، دانشکده مهندسی علوم آب، گروه سازه‌های آبی، اهواز، ایران.

چکیده

استفاده از مصالح FRP و سایر مصالح کامپوزیتی به عنوان میلگرد یا ورق، یکی از گزینه‌های مناسب فنی و اقتصادی در ساخت، بهسازی و مقاوم‌سازی سازه‌هایی نظیر سازه‌های بتنی است. یکی از مهمترین مسائلی که باید در مورد استفاده از چنین مصالحی مدنظر قرار گیرد، مقاومت چسبندگی آنها به بتن سازه‌ای است. در این مقاله، تأثیر ترکیب مدل‌های پیش‌بینی گروهی با مدل‌های تخمین منفرد بر روی بهتر شدن نتایج مدل‌های منفرد برآورد مقاومت چسبندگی میلگردهای FRP با الیاف شیشه به بتن مورد بررسی قرار می‌گیرد. برای رسیدن به این هدف ابتدا از شبکه‌های عصبی با ورودی‌های نتایج پیش‌بینی دو مدل منفرد قبلاً ارائه شده برای برآورد مقاومت چسبندگی GFRP به منظور بهبود نتیجه بهترین مدل از میان دو مدل مذکور استفاده می‌شود. سپس با در نظرگیری خروجی‌های پیش‌بینی مدل شبکه عصبی اول و بهترین مدل منفرد از بین دو مدل فوق‌الذکر به عنوان ورودی، دوباره از شبکه‌های عصبی برای ارائه یک مدل بهتر از مدل ANN اول استفاده می‌شود. نتایج انتهایی نشان از کاهش خطای پیش‌بینی مدل ANN ترکیب شده از روش‌های منفرد و گروهی نسبت به مدل‌های منفرد قبلاً ارائه شده، مدل میانگین وزن‌دار نتایج خروجی پیش‌بینی شده دو مدل منفرد مذکور و مدل ANN ترکیبی آن دو مدل منفرد می‌دهند.

کلمات کلیدی: مقاومت چسبندگی میلگردهای GFRP، بتن سازه‌ای، شبکه‌های عصبی مصنوعی، تلفیق مدل‌های پیش‌بینی گروهی و منفرد، نرم‌افزار MATLAB.

شناسه دیجیتال:		سابقه مقاله:				
doi:	https://dx.doi.org/10.22065/jsce.2020.216063.2051	چاپ	انتشار آنلاین	پذیرش	بازنگری	دریافت
	10.22065/jsce.2020.216063.2051	۱۴۰۰/۰۳/۳۰	۱۳۹۹/۰۱/۱۴	۱۳۹۹/۰۱/۱۴	۱۳۹۸/۱۲/۲۵	۱۳۹۸/۱۰/۲۶
			احمد فتحی a.fathi@scu.ac.ir		*نویسنده مسئول: پست الکترونیکی:	

۱- مقدمه

میلگردهای پلیمری مسلح شده با الیاف^۱ (FRP) دارای مزایایی همچون مقاومت کششی بالاتر از فولاد، وزن حدود یک چهارم میلگردهای فولادی، عدم تأثیر در میدان‌های مغناطیسی و فرکانس‌های رادیویی (مثل دستگاه‌های بیمارستانی)، ضریب ارتجاعی مناسب (تقریباً در حدود فولاد)، مقاومت شیمیایی و مقاومت در برابر خوردگی (کلراسیون و کربناسیون) بالاتر نسبت به فولاد و عدم هدایت الکتریکی و حرارتی هستند. یکی از انواع الیافی که در این مصالح کامپوزیت بکار می‌رود، الیاف شیشه^۲ (G) است. این نوع الیاف دارای مزایایی همچون مقاومت شیمیایی بالا، استحکام کششی بالا و خواص عایقی و الکتریکی بالا است. خصوصیت چسبندگی برای هر ماده‌ای که به عنوان مسلح‌کننده بتن بکار می‌رود، بسیار مهم تلقی می‌شود. در مورد میلگردهای کامپوزیتی FRP، اگرچه در بررسی اولیه، مقاومت چسبندگی^۳ ضعیفی برای کامپوزیت‌هایی از جنس الیاف شیشه گزارش شده است، اما تحقیقات اخیر نشان می‌دهد که مقاومت چسبندگی خوب و قابل قبولی دارند. با این حال با توجه به گزارش‌های اولیه، اهمیت مقاومت چسبندگی این نوع میلگردها به بتن زیاد است [1]. معادلات (۱) و (۲)، روابط پیش‌بینی‌کننده مقاومت چسبندگی میلگردهای FRP به بتن مطابق با آیین‌نامه‌های موسسه بتن آمریکا^۴ (ACI) و استاندارد انجمن کانادا^۵ (CSA) را نشان می‌دهند:

$$\tau_b = \left(0.33 + 0.025 \frac{C}{d_b} + 8.3 \frac{d_b}{l} \right) \sqrt{f_c} \quad (1)$$

$$\tau_b = \frac{d_{sc} \sqrt{f_c}}{1.15(k_1 k_2 k_3 k_4 k_5) \pi d_b} \quad (2)$$

که در این روابط، C حداقل پوشش بتن بر حسب میلی‌متر، d_b قطر میلگرد بر حسب میلی‌متر، l طول مهاری میلگرد^۶ بر حسب میلی‌متر، f_c مقاومت فشاری بتن^۷ بر حسب نیوتن بر میلی‌متر مربع (MPa)، d_{sc} (کوچکتر یا مساوی ۲/۵ برابر قطر میلگرد) کمترین فاصله از نزدیک سطح بتن به مرکز میلگرد مهاری یا دو سوم فاصله میلگردهای مهاری، k_1 ضریب محل میلگرد (۱/۳ برای تقویت افقی با بتن‌ریزی بیش از ۳۰۰ میلی‌متر با بتن تازه در زیر میلگرد و ۱ برای سایر موارد)، k_2 ضریب تراکم بتن (۱/۳ برای بتن سازه‌ای با تراکم پایین، ۱/۲ برای بتن سازه‌ای با تراکم نیمه کم و ۱ برای بتن با تراکم معمولی)، k_3 ضریب اندازه میلگرد (۰/۸ برای میلگردهای با سطح مقطع کوچکتر یا مساوی ۳۰۰ میلی‌متر مربع و ۱ برای سایر مساحت‌ها)، k_4 ضریب الیاف میلگرد (۱ برای FRP با الیاف‌های کربن و شیشه و ۱/۲۵ برای FRP با الیاف آرامید) و k_5 نوع سطح میلگرد (۱/۰۵ برای سطوح مارپیچی یا آجدار، ۱/۸ برای سطوح دندانه‌دار و ۱ برای سطوح زبر یا پوشیده شده با ماسه) است [2]. شایان ذکر است که نتایج مقاله گل‌افشانی و همکاران [2] نشان می‌دهد که دقت روابط آیین‌نامه‌های مذکور از مدل‌های هوش مصنوعی، خیلی کمتر است.

همواره کوشش برای افزایش دقت عملکرد مدل‌های پیش‌بینی و مقایسه آنها با یکدیگر در موضوعات گوناگون ادامه دارد. طرق مورد استفاده در مدل‌سازی‌های پیش‌بینی را به دو شیوه می‌توان تلفیق کرد. اول، در آغاز مراحل مدل‌سازی. مثلاً بکارگیری شبکه‌های عصبی مصنوعی^۸ (ANN) برای ارائه مدل پیش‌بینی و بکارگیری الگوریتم‌های جدید بهینه‌سازی برای تعیین پارامترهای تنظیم بهینه شبکه‌های عصبی. دوم، پس از اتمام مراحل ارائه دو یا چند مدل برآورد. مثلاً بکارگیری روش‌های میانگین ساده^۹ یا وزن‌دار^{۱۰} و یا بکارگیری یک روش متداول ساخت مدل‌های برآورد (اعم از نرم‌افزارهای آماده و جعبه‌ابزارها^{۱۱} و همچنین مدل‌های برنامه‌نویسی‌شده) برای پیدا کردن

¹ Fibr Reinforcement Polymer

² Glass

³ Bond Strength

⁴ American Concrete Institute

⁵ Canadian Standards Association

⁶ Bar Development Length

⁷ Compressive Strength Concrete

⁸ Artificial Neural Network

⁹ Simple Average

¹⁰ Weighted Average

¹¹ Toolbox

رابطه بین نتایج تخمین دو یا چند مدل ارائه شده با خروجی واقعی. همان گونه که بسیار دیده شده است، برای مشخص کردن مدل بهینه در روش های مبتنی بر هوش مصنوعی باید آموزش مدل به تعدد انجام شود تا بهترین نتایج حاصل گردد. بهترین نتایج مطابق با مقادیر خطای میانگین و ضریب همبستگی (R) ^{۱۲} تمام الگوها ^{۱۳} (نمونه ها ^{۱۴}) حاصل می گردد و این بدان معنی نمی باشد که مدل بهینه برای هر یک از الگوها دارای کمترین میزان خطا در پیش بینی است. دسته ای دیگر از روش های برآورد گروهی ^{۱۵} هستند؛ که در تعداد زیاد انجام آموزش مدل ها الگوها را مطابق با خروجی های پیش بینی شده به چند گروه تقسیم بندی کرده و برای هر گروه، مدل بهینه را تعیین می کنند. با این روش، دقت نتایج برآورد افزایش خواهد یافت. حال این سوال مطرح می شود که تلفیق مدل های پیش بینی گروهی و منفرد منتج به چه نتایجی می شود؟

پژوهش های انجام شده در مورد ارائه مدل های گروهی (تلفیق داده ^{۱۶}) پیش بینی خواص بتن جستجو گردیدند؛ که در ادامه به بعضی از موارد پیدا شده اشاره می شود. با توجه به تحقیقات بررسی شده در این زمینه، توسط نویسندگان مقاله دیده نشد که تاکنون مدل هایی ساخته شده باشد که پس از تمام شدن مراحل ساخت و آزمایش مدل های تخمین گروهی، نتایج آنها دوباره توسط روش های منفرد بهبود بیابد. در این مقاله سعی بر ارائه مدلی است که بتواند نتایج مدل های گروهی را بهبود ببخشد. برای رسیدن به این هدف از جعبه ابزار شبکه عصبی پس انتشار ^{۱۷} با معماری جלו سو ^{۱۸} (nftool) در نرم افزار MATLAB-R2014a استفاده می شود. در بخش بعد ابتدا به بعضی از مطالعات معتبر مربوط به ارائه مدل های تخمین خواص بتن با میلگردهای FRP مانند: مقاومت چسبندگی میلگردهای FRP به بتن و سپس به تحقیقات جدید مربوط به مدل های گروهی و سایر روش های محاسبات نرم مورد استفاده برای برآورد خواص بتن اشاره می شود.

۲- مروری بر ادبیات موضوع

۲-۱- مروری بر تحقیقات ارائه مدل های برآورد خواص بتن با میلگردهای FRP

گل افشانی ^{۱۹} و همکاران [2] از جعبه ابزار شبکه های عصبی مصنوعی در نرم افزار MATLAB (nftool) و برنامه ریزی ژنتیک چندژن ^{۲۰} (MGP) برای ارائه یک مدل تخمین مقاومت چسبندگی میلگردهای GFRP به بتن (نیوتن بر میلی متر مربع) استفاده کرده اند. تعداد نمونه های مورد استفاده در مجموعه های آموزشی، ارزیابی و آزمایشی به ترتیب برابر با ۱۱۱، ۲۴ و ۲۴ الگو است (با تقسیم بندی تصادفی) (نمونه های مجموعه ها در همه مدل ها یکسان است). ۷ ورودی در نظر گرفته شده نیز عبارتند از: قطر میلگرد (میلی متر)، مقاومت فشاری بتن (نیوتن بر میلی متر مربع)، نسبت حداقل پوشش بتن (میلی متر) به قطر میلگرد (میلی متر)، موقعیت میلگرد (بالا یا پایین)، سطح میلگرد (ماسه اندود یا حلزونی یا مارپیچی)، نسبت طول مهاری میلگرد (میلی متر) به قطر میلگرد (میلی متر) و نسبت مساحت تقویت شده عرضی (میلی متر مربع) به حاصلضرب فاصله تقویت شده عرضی ^{۲۱} (میلی متر) در قطر میلگرد (میلی متر) در تعداد میلگردهای مهاری. سایر روش های مدل سازی بکار گرفته شده نیز عبارتند از: روابط ریاضی آیین نامه های انجمن بتن آمریکا ^{۲۲} (ACI) و انجمن استاندارد کانادا ^{۲۳} (CSA) و روش رگرسیون خطی چندمتغیره ^{۲۴} (MLR). نتایج نهایی مقایسه مدل ها نشان از برتری مدل برنامه ریزی ژنتیک داده اند. شایان ذکر است که در انتهای مقاله از تحلیل حساسیت ^{۲۵} (SA) برای تعیین میزان تأثیر ورودی ها بر خروجی در دو مدل هوش مصنوعی و روابط دو آیین نامه استفاده شده است.

¹² Correlation Coefficient

¹³ Pattern

¹⁴ Sample

¹⁵ Ensemble Prediction

¹⁶ Multi Data Fusion

¹⁷ Back-Propagation Network

¹⁸ Feed Forward

¹⁹ Golafshani

²⁰ Multi-Gene Genetic Programming

²¹ Transverse Reinforcement

²² American Concrete Institute

²³ Canadian Standards Association

²⁴ Multi-Linear Regression

²⁵ Sensitivity Analysis

کوئیلهو^{۲۶} و همکاران [3] از الگوریتم‌های داده کاوی^{۲۷} (DM) به منظور برآورد مقاومت چسبندگی میلگردهای FRP به بتن به روش نصب نزدیک سطح^{۲۸} (NSM) استفاده کرده‌اند. روش‌های مدل‌سازی بکار گرفته شده عبارتند از: شبکه‌های عصبی مصنوعی، ماشین-های بردار پشتیبان^{۲۹} (SVM)، ابزار مبتنی بر وب Rminer Library Tool شامل روش‌های رگرسیونی (R) و طبقه‌بندی^{۳۰} (C). مجموعاً از ۴۳۱ نمونه در آموزش (دو سوم نمونه‌ها) و آزمایش (یک سوم نمونه‌ها) مدل‌ها استفاده گردیده است. ۴ مجموعه ورودی در نظر گرفته شده نیز عبارتند از: پارامترهای تأثیرگذار بر مقاومت چسبندگی ۱- در آیین‌نامه ACI (۴ ورودی)، ۲- در آیین‌نامه استاندارد استرالیا^{۳۱} (SA) (۷ ورودی)، ۳- مطابق با نظر متخصصان (۶ ورودی) و ۴- انتخاب به طور تصادفی و توسط نرم‌افزار (۷ ورودی). نتایج انتهایی مقایسه مدل‌ها نشان از برتری مدل‌های داده کاوی نسبت روابط آیین‌نامه‌ها داده‌اند.

نادرپور و همکاران [4] از رگرسیون غیرخطی در SVM برای پیش‌بینی ظرفیت برش پانچ دال‌های بتن مسلح با FRP و مقایسه مدل ارائه شده با روابط آیین‌نامه‌های بین‌المللی و روابط ارائه شده توسط برخی محققین استفاده کرده‌اند. در مقاله مذکور، از ۷۴ نمونه در ساخت و آزمایش مدل استفاده گردیده است (۵۹ نمونه معادل ۸۰٪ در آموزش و ۱۵ نمونه معادل ۲۰٪ در آزمایش و صحت‌سنجی). ۶ ورودی نیز برای مدل در نظر گرفته شده است؛ که تمامی ورودی‌ها در بازه ۰/۱ تا ۰/۹ نرمال شده‌اند. در انتها این نتیجه بدست آمده است که مدل ارائه شده، کارایی بیشتری نسبت به روابط تجربی دارد.

بازلی^{۳۲} و همکاران [5]، روابطی ریاضی را به صورت‌های احتمالاتی و آزمایشگاهی برای تخمین مقاومت چسبندگی میلگردهای GFRP به انواع مختلف بتن (معمولی یا NC^{۳۳}، با مقاومت بالا یا HPC^{۳۴}، سبک یا LWC^{۳۵} و خودمترکم یا SCC^{۳۶}) در انواع مختلف شرایط محیطی (آب دریا، محیط قلیایی و محیط اسیدی) ارائه داده‌اند. تعداد کل نمونه‌های مورد استفاده در مدل‌سازی برابر با ۱۳۲ نمونه بوده است. نتایج نهایی مدل‌ها نشان از برتری روابط احتمالاتی پیش‌بینی‌کننده مقاومت چسبندگی در محیط قلیایی داده‌اند.

کبوتری و همکاران [6] از سیستم استنتاج عصبی-فازی تطبیقی^{۳۷} (ANFIS) برای ارائه یک مدل تخمین نیروی چسبندگی بتن به ورق‌های FRP (کیلونیوتن) با ورودی‌های مقاومت فشاری بتن (نیوتن بر میلی‌متر مربع)، عرض ورق FRP (میلی‌متر)، طول تأثیرگذار چسب (میلی‌متر)، نسبت عرض ورق FRP (میلی‌متر) به عرض بتن (میلی‌متر) و سختی محوری ورق FRP (گیگاپاسکال یا GPA بر میلی‌متر) استفاده کرده‌اند. تعداد داده‌های مورد استفاده در آموزش (۷۰ درصد نمونه‌ها) و آزمایش (۳۰ درصد نمونه‌ها) مدل برابر با ۱۵۰ الگو است. نتایج انتهایی نشان از عملکرد قوی و دقت بالای مدل ارائه شده داده‌اند. لازم به ذکر است که تحلیل حساسیتی انجام شده است و مشخص گردیده است که ورودی‌های با بیشترین تأثیر بر خروجی به ترتیب عبارتند از: سختی محوری FRP و عرض ورق FRP.

یان^{۳۸} و همکاران [7] از شبکه عصبی با تنظیمات بهینه شده توسط الگوریتم ژنتیک^{۳۹} (GA) برای ارائه یک مدل برآورد مقاومت چسبندگی میلگردهای GFRP به بتن با ورودی‌های قطر میلگرد، نسبت پوشش بتن به قطر میلگرد، جذر مقاومت فشاری بتن، نسبت آرماتور تقویت عرضی و نسبت طول جابجینی^{۴۰} به قطر میلگرد استفاده کرده‌اند. تعداد داده‌های مورد استفاده در آموزش (۶۰ درصد الگوها) و آزمایش (۴۰ درصد الگوها) مدل برابر است با ۱۵۷ تیر بتنی. نتایج مقایسه مدل ارائه شده با ۴ آیین‌نامه معتبر بین‌المللی و مدل رگرسیون غیرخطی چندمتغیره^{۴۱} (MNR) نشان از برتری مطلق و محسوس مدل ANN-GA داده‌اند.

²⁶ Coelho

²⁷ Data Mining

²⁸ Near-Surface Mounted

²⁹ Support Vector Machines

³⁰ Classification

³¹ Standards Australia

³² Bazli

³³ Normal Concrete

³⁴ High Strength Concrete

³⁵ Light Weight Concrete

³⁶ Self-Compacting Concrete

³⁷ Adaptive Neuro-Fuzzy Inference System

³⁸ Yan

³⁹ Genetic Algorithm

⁴⁰ Embedment Length

⁴¹ Multi-Nonlinear Regression

نادرپور و فخاریان [8] از شبکه‌های عصبی مصنوعی برای پیش‌بینی مقاومت پیچشی تیرهای بتن آرمه تقویت شده با FRP استفاده کرده‌اند. تعداد ورودی‌های مدل برابر با ۹ عامل تأثیرگذار بر لنگر پیچشی قابل تحمل توسط تیر در نظر گرفته شده است. تمامی داده‌ها برای معرفی به شبکه در بازه ۰/۱ تا ۰/۹ نرمال شده‌اند. از ۵۶ نمونه نیز برای ساخت و آزمایش مدل (۷۰٪ داده‌ها در آموزش و ۱۵٪ داده‌ها در هر یک از مجموعه‌های ارزیابی و آزمایشی) استفاده شده است. نتایج تحلیل حساسیت با استفاده از وزن‌های شبکه عصبی به روش میلن^{۴۲} نشان داده‌اند که نسبت عرض موثر نوار تقویتی در راستای طول تیر به فاصله مرکز تا مرکز رکابی FRP، بیشترین تأثیر و ارتفاع تیر، کمترین تأثیر را بر خروجی دارد. در انتها این نتیجه بدست آمده است که دقت مدل، مناسب است و می‌تواند جایگزین مناسبی برای روش‌های پرهزینه و زمان‌بر آزمایشگاهی باشد.

بلانندی^{۴۳} و همکاران [9] از برنامه‌ریزی ژنتیک چندژن (MGP) برای ارائه یک مدل تخمین مقاومت چسبندگی میلگردهای FRP به بتن با ۶ ورودی نسبت طول جایگزینی میلگرد (میلیمتر) به قطر میلگرد (میلیمتر)، موقعیت میلگرد (بالا یا پایین)، سطح میلگرد (ماسه-اندود یا حلزونی یا مارپیچی)، نسبت پوشش بتن (میلیمتر) به قطر میلگرد (میلیمتر)، مقاومت فشاری بتن (نیوتن بر میلی‌متر مربع) و قطر میلگرد (میلیمتر) استفاده نموده‌اند. تعداد الگوهای مورد استفاده (مجموعاً ۲۲۳ نمونه) در مجموعه‌های آموزشی، ارزیابی و آزمایشی به ترتیب عبارت است از: ۱۵۷، ۳۳ و ۳۳. نتایج انتهایی نشان از برتری مدل MGP نسبت به آیین‌نامه ACI داده‌اند.

نادرپور^{۴۴} و همکاران [10] از روش گروهی پردازش داده‌ها^{۴۵} (GMDH) برای پیش‌بینی مقاومت فشاری ستون‌های بتن مسلح با مقطع دایره‌ای و محصور شده با FRP استفاده کرده‌اند. روش‌های دیگر بکار گرفته شده برای مدل‌سازی عبارتند از: ANN و برنامه‌ریزی تشریح ژن^{۴۶} (GEP). تعداد متغیرهای ورودی برابر با ۷ عامل موثر بر تنش فشاری نهایی در ستون در نظر گرفته شده است. از ۹۵ داده نرمال شده در محدوده ۰/۱ تا ۰/۹ نیز در آموزش و آزمایش مدل‌ها استفاده گردیده است (برای مدل ANN، ۷۰٪ آموزش و ۳۰٪ ارزیابی و آزمایشی). تحلیل حساسیت برای هر سه مدل ارائه شده صورت گرفته است؛ که نتایج روش میلن برای مدل ANN نشان داده است که حداکثر فشار محصورشدگی ایجاد شده توسط FRP، بیشترین تأثیر و فشار محصور شدگی ایجاد شده توسط فولاد جانبی، کمترین تأثیر را بر خروجی دارد. در انتها این نتیجه بدست آمده که ANN با ۱۱ نورون^{۴۷} در لایه پنهان^{۴۸}، بهترین عملکرد را نسبت به دو مدل دیگر، رابطه تجربی ACI و سه مدل موجود در سایر مقالات داشته است.

نادرپور و میررشید^{۴۹} [11] از مدل سیستم استنتاجی عصبی-فازی تطبیقی^{۵۰} (ANFIS) با ۵ ورودی و ۸۲ نمونه (۶۴ نمونه برای آموزش و ۱۸ نمونه برای آزمایش مدل) به منظور پیش‌بینی برش پانچ اتصالات دال-ستون تقویت شده با FRP (بر حسب کیلونیوتن) استفاده کرده‌اند. داده‌های مورد استفاده در مدل‌سازی بین ۰/۱ تا ۰/۹ نرمال شده‌اند. در انتها نتیجه‌گیری شده است که دقت مدل ارائه شده، مناسب است و به راحتی می‌تواند در تحقیقات دیگر کاربرد داشته باشد.

۲-۲- مروری بر پژوهش‌های ارائه مدل‌های پیش‌بینی گروهی خواص بتن و سایر روش‌های محاسبات نرم

چوئو و فام^{۵۱} [12] از روش‌های تخمین منفرد SVM، ANN، درخت تصمیم کاشف تعاملات خودکار کای دو^{۵۲} (CHAID)، درخت رگرسیون و طبقه‌بندی^{۵۳} (CART)، رگرسیون خطی^{۵۴} (LR) و خطی تعمیم‌یافته^{۵۵} (GENLIN) و از روش برآورد اعتبارسنجی متقابل^{۵۶} ضربدری K قسمت^{۵۷} هر یک از مدل‌های تخمین منفرد فوق‌الذکر برای پیش‌بینی مقاومت فشاری بتن HPC استفاده نموده‌اند. از ۵

⁴² Milne

⁴³ Bolandi

⁴⁴ Naderpour

⁴⁵ Group Method of Data Handling

⁴⁶ Gene Expression Programming

⁴⁷ Neuron

⁴⁸ Hidden Layer

⁴⁹ Mirrashid

⁵⁰ Adaptive Neuro-Fuzzy Inference System

⁵¹ Chou and Pham

⁵² Chi-Squared Automatic Interaction Detection

⁵³ Classification and Regression Tree

⁵⁴ Linear Regression

⁵⁵ Generalized Linear

⁵⁶ Cross Validation

⁵⁷ K-Fold

مجموعه داده از کشورهای کره جنوبی، تایوان، کشورهای عربی، شیلی و ترکیه در ساخت و آزمایش مدل‌ها استفاده شده است (مجموعاً ۱۶۵۵ الگو). نتایج انتهایی نشان از برتری روش برآورد گروهی بهینه برای هر مجموعه داده نسبت به روش تخمین منفرد بهینه داده‌اند. چوئو و همکاران [13] از روش‌های برآورد منفرد SVM، LR، شبکه پرسپترون چندلایه^{۵۸} (MLP)، CART و روش‌های پیش‌بینی گروهی رأی‌گیری^{۵۹}، بسته‌سازی^{۶۰} (که در آن، یک مدل برآورد منفرد با خودش، یک مدل تخمین گروهی می‌سازد) و روش انباشتن^{۶۱} برای پیش‌بینی مقاومت فشاری بتن HPC استفاده نموده‌اند. از ۵ مجموعه داده از کشورهای مختلف در مدل‌سازی استفاده شده است (مجموعاً ۱۶۷۵ الگو). نتایج نهایی نشان داده‌اند که تنها برای ۱ مجموعه داده، مدل تخمین منفرد MLP از مدل‌های گروهی دقیق‌تر بوده است.

آیدوگموس^{۶۲} و همکاران [14] از روش‌های منفرد SVM، MLP، RBF، CART و روش برآورد گروهی بسته‌سازی هر یک از مدل‌های پیش‌بینی منفرد برای برآورد اسلامپ^{۶۳} بتن HPC (سانتیمتر) استفاده نموده‌اند. آنها در مدل‌سازی از ۱۰۳ داده اطلاعاتی (نمونه بتن) استفاده کرده‌اند. در نهایت، نتایج نشان از بهتر بودن مدل Bagging داده‌اند.

نادرپور و همکاران [15] از ANN با ۱۸ نورون در لایه پنهان و با ۶ ورودی و ۱۳۹ داده جمع‌آوری شده از ۱۴ اثر انتشار یافته (۷۰٪) برای آموزش و ۱۵٪ برای انجام هر یک از عملیات ارزیابی و آزمایش مدل (به منظور پیش‌بینی مقاومت فشاری یک نوع بتن دوست‌دار محیط زیست یعنی بتن با سنگدانه بازیافتی^{۶۴} (RAC) استفاده کرده‌اند. داده‌های مورد استفاده در مدل‌سازی در محدوده ۰/۱ تا ۰/۹ نرمال شده‌اند و تحلیل حساسیت ورودی‌ها با روش میلن انجام گرفته است. نتایج SA نشان داده‌اند که نسبت آب به کل مصالح و درصد جذب آب، بیشترین تأثیر و نسبت آب به سیمان، کمترین تأثیر را بر خروجی دارند. نتیجه بدست آمده در آخر عبارت است از: از ANN به عنوان یک مدل کارآمد می‌توان برای تخمین CS بتن با انواع مختلف سنگدانه بازیافتی استفاده کرد.

لینگ^{۶۵} و همکاران [16]، یک مدل تلفیقی با استفاده از SVM و روش پیش‌بینی گروهی K-Fold برای تخمین مقاومت فشاری بتن در محیط‌های دریایی ارائه داده‌اند. روش‌های برآورد منفرد استفاده شده در مقاله مذکور عبارتند از: SVM، ANN و درخت تصمیم-گیری^{۶۶} (DT). مدل K-Fold نیز برای هر یک از مدل‌های منفرد فوق‌الذکر ارائه شده است. شایان ذکر است که از ۸۰ نمونه بتن در آموزش مدل و از ۳۶ نمونه بتن در آزمایش آن استفاده گردیده است. در نهایت، نتایج نشان از بهتر بودن مدل SVM K-Fold داده‌اند.

ژانگ^{۶۷} و همکاران [17] از روش‌های مدل‌سازی داده کاوی به منظور ارائه مدل‌های تخمین مدول الاستیسیته^{۶۸}، مقاومت فشاری، کرنش کششی^{۶۹}، مقاومت کششی^{۷۰} و انقباض خشک^{۷۱} بتن هیدرولیکی استفاده کرده‌اند. روش‌های تخمین گروهی در مقاله مورد بررسی عبارتند از: K-Fold مدل‌های برآورد منفرد DT، رگرسیون گرادیان تقویتی^{۷۲} (GB)، LR و فرآیند گوسی^{۷۳} (GP). ورودی‌های همه مدل‌ها نیز عبارتند از: سن بتن، نسبت آب به سیمان، مقادیر خاکستر بادی، آب، ماسه، هوای وارد شده غیر عمدی، میزان هوای وارد شده عمدی به منظور افزایش دوام بتن و سنگدانه‌های درشت. در ضمن مجموعاً از ۵۳۷ نمونه بتن در مدل‌های برآورد ۵ خاصیت بتن استفاده گردیده است. نتایج نشان از بهتر بودن مدل GB K-Fold برای کرنش کششی، مدول الاستیسیته، مقاومت فشاری و میانگین ۵ خاصیت بتن داده‌اند.

نادرپور و همکاران [18] از GMDH با ۵ ورودی برای پیش‌بینی ظرفیت لنگر اعضای بتن مسلح در سیستم ملات با توری سیمی^{۷۴} (نیوتن-متر) استفاده کرده‌اند. به منظور انجام مدل‌سازی، ۷۵ نمونه از ۹ اثر علمی منتشر شده جمع‌آوری شده است (۸۰٪ یعنی ۶۰ نمونه

⁵⁸ Multilayer Perceptron

⁵⁹ Voting

⁶⁰ Bagging

⁶¹ Stacking

⁶² Ayoogmus

⁶³ Slump

⁶⁴ Recycled Aggregate Concrete

⁶⁵ Ling

⁶⁶ Decision Tree

⁶⁷ Zhang

⁶⁸ Elastic Modulus

⁶⁹ Tensile Strain

⁷⁰ Tensile Strength

⁷¹ Dry Shrinkage Rate

⁷² Gradient Boosting

⁷³ Gaussian Processes

⁷⁴ Ferrocement

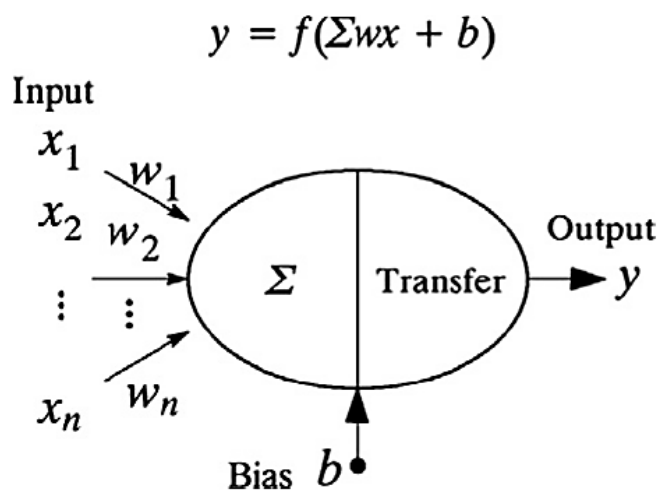
برای آموزش مدل) و قبل از استفاده در مدل، بین ۰/۱ تا ۰/۹ نرمال شده‌اند. نتایج SA با روش اثر بر جذر خطای میانگین مربعات^{۷۵} (RMSE) نشان داده است که به ترتیب، کسر حجمی مش سیمی^{۷۶} و مقاومت فشاری سیستم Ferrocement، بیشترین و کمترین تأثیر را بر ظرفیت لنگر دارند. نتایج انتهایی نشان داده‌اند که مدل GMDH به طور قابل توجهی بهتر از برخی مدل‌ها و روش‌های قبلی است.

شاه‌منصوری^{۷۷} و همکاران [19] از GEP با ۸ ورودی برای پیش‌بینی مقاومت فشاری و مقاومت الکتریکی^{۷۸} (ER) (بر حسب اهم-متر) بتن سازگار با محیط زیست حاوی زئولیت طبیعی (به عنوان یک ماده سیمانی مکمل) استفاده کرده‌اند. به منظور انجام مدل‌سازی، ۵۴ طرح اختلاط، ۳۲۴ نمونه برای CS و ۱۶۲ نمونه برای ER با سه نسبت آب به مواد چسباننده (سیمان و زئولیت)، سه مقدار مختلف از مواد چسباننده و شش سطح متفاوت از مقدار (درصد) جایگزینی زئولیت ساخته شده است. ۸۰٪ نمونه‌ها برای آموزش مدل‌ها در نظر گرفته شده است. نتایج آزمایش‌ها نشان داده است که استفاده از ۷/۵٪ تا ۱۰٪ جایگزینی زئولیت با سیمان باعث افزایش مقاومت فشاری بتن در دراز مدت و استفاده از ۲۰٪ جایگزینی باعث افزایش قابل ملاحظه مقاومت الکتریکی بتن به ویژه در سنین بالاتر می‌گردد. نتایج مدل‌سازی نیز نشان داده است که مدل‌های GEP ارائه شده برای هر دو خاصیت این نوع بتن، پتانسیل بالایی در تخمین دارند.

۳- شبکه‌های عصبی مصنوعی

۳-۱- کوچکترین جز سلول‌های شبکه عصبی

نورون‌ها اجزای حیاتی شبکه‌های عصبی می‌باشند؛ که از سه جز بایاس^{۷۹}، وزن^{۸۰} و تابع انتقال^{۸۱} تشکیل شده‌اند. در شبکه BPN با معماری جلوسو از تابع‌های لگاریتم سیگموئید^{۸۲} (logsig)، خطی^{۸۳} (purelin) و تانژانت سیگموئید^{۸۴} (tansig) به عنوان تابع‌های انتقال استفاده می‌شود. تابع purelin همان میزان ورودی (n) را به خروجی (a) انتقال می‌دهد ($a=n$). تابع logsig، مقادیر n را می‌گیرد و میزان خروجی (a) را بین ۰ و ۱ مطابق با معادله $a = 1/(1 + e^{-n})$ تولید می‌کند. تابع tansig نیز مقادیر n را می‌گیرد و میزان خروجی (a) را بین -۱ و ۱ مطابق با معادله $a = [2/(1 + e^{-2n})] - 1$ تولید می‌کند [20]. نمای شماتیک از یک نورون محاسباتی و اجزای آن در شکل ۱ نشان داده شده است [8]. در جعبه‌ابزار شبکه عصبی به ترتیب از tansig و purelin تحت عنوان تابع‌های انتقال لایه پنهان و لایه خروجی استفاده می‌گردد.



شکل ۱: نمای شماتیک از یک نورون محاسباتی [8].

⁷⁵ Root Mean Squared Error

⁷⁶ Volume Fraction of Wire Mesh

⁷⁷ Shahmansouri

⁷⁸ Electrical Resistivity

⁷⁹ Bias

⁸⁰ Weight

⁸¹ Transfer Function

⁸² Log-Sigmoid

⁸³ Linear

⁸⁴ Tan-Sigmoid

۳-۲- نوع شبکه عصبی مورد استفاده در این مقاله

در تحقیقات انجام شده توسط نادرپور و فخاریان [8] و نادرپور و همکاران [10]، از شبکه عصبی پس‌انتشار با معماری جلوسو برای تخمین خواص بتن آرمه تقویت شده با FRP استفاده شده است. پس در این مقاله نیز به منظور ساخت مدل‌های پیش‌بینی گروهی مقاومت چسبندگی میلگردهای GFRP به بتن از این نوع شبکه عصبی استفاده می‌گردد.

شبکه پس‌انتشار با رایج‌ترین معماریش یعنی جلوسو از ۳ لایه یا بیشتر متشکل است؛ لایه ورودی، یک یا بیشتر از یک لایه پنهان و لایه خروجی. تعداد نورون‌های ورودی مساوی با تعداد ورودی‌ها و تعداد نورون‌های خروجی مساوی با تعداد خروجی‌ها است [20]. تعداد بهینه نورون‌های لایه پنهان در مقالات فوق‌الذکر از روش سعی و خطا تعیین شده است. بنابراین در این مقاله نیز از روش سعی و خطا استفاده می‌شود.

۳-۳- الگوریتم آموزش^{۸۵} شبکه جلوسو

در کتاب کیا [20] از سه مسأله گوناگون برای مقایسه سرعت و دقت بودن ۹ الگوریتم آموزش شبکه در پیش‌بینی توابع استفاده گردیده است. بدین صورت که سه شبکه جلوسو با الگوریتم‌های گوناگون آموزش داده شده‌اند و نتایج حاصل گردیده است. ۲ تا از نتایج بدست آمده، این است که عموماً در مسائل شامل تعداد کمی ورودی و شبکه با اندازه کوچک و متوسط، الگوریتمی که دارای سرعت، کارآمدی و عملکرد بالا در آموزش شبکه است، لونبرگ-مارکواردت^{۸۶} (trainlm) است. ولی معمولاً در مسائل شامل تعداد زیادی ورودی و شبکه با اندازه بزرگ، شیب مزدوج مقیاس‌بندی شده^{۸۷} (trainscg) مناسب است. در این مقاله، بهترین الگوریتم با سعی و خطا تعیین می‌شود.

۳-۴- معیارهای ارزیابی کارآمدی مدل

معیارهای بکار رفته در جعبه‌ابزار nftool، ضریب همبستگی^{۸۸} (R)، عددی بین -۱ و +۱ که هر چه به +۱ نزدیک‌تر باشد، یعنی عملکرد مدل بهتر است) و خطای میانگین مربعات^{۸۹} (MSE) (معیارهای خطا هر به صفر نزدیک‌تر باشند، یعنی خطای پیش‌بینی مدل کمتر است) هستند. در مقاله گل‌افشانی و همکاران [2] نیز از معیارهای R، جذر خطای میانگین مربعات (RMSE) (همان جذر MSE) و قدرمطلق خطای میانگین^{۹۰} (MAE) استفاده شده است. در مقاله‌های جدیدتر مثل مقاله گل‌افشانی و عاشور^{۹۱} [21] از تابع هدف^{۹۲} (OBJ) نیز به عنوان معیار سنجشی مدل بر اساس مجموعه‌های آموزشی و آزمایشی استفاده شده است؛ که معیارهای R، MAE و RMSE در مقدار آن تأثیرگذارند. شایان ذکر است که در این مقاله، چون در nftool از معیار MAE استفاده نمی‌شود و ضمناً داده‌هایی به مجموعه ارزیابی تعلق می‌گیرد، تابع هدف برای مدل‌ها فقط بر اساس دو معیار سنجشی دیگر و برای یک مجموعه آموزشی و دو مجموعه آزمایشی به صورت معادله (۳) محاسبه می‌شود. R، RMSE و MAE نیز از معادلات (۴) تا (۶) بدست می‌آیند. در انتها این نکته باید ذکر شود که چون معیار MAE در مقاله مورد مقایسه استفاده شده است، در این مقاله نیز میزان این خطا برای مجموعه کل داده‌ها محاسبه شده و با مقدار مدل ارائه شده در مقاله گل‌افشانی و همکاران [2] مقایسه می‌گردد. برای تعیین مدل بهینه شبکه جلوسو نیز از معیارهای R و MSE استفاده می‌شود.

⁸⁵ Training Algorithm

⁸⁶ Levenberg-Marquardt

⁸⁷ Scaled Conjugate Gradient

⁸⁸ Coefficient of Correlation

⁸⁹ Mean Squared Error

⁹⁰ Mean Absolute Error

⁹¹ Golafshani and Ashour

⁹² Objective Function

$$OBJ = \left(\frac{NO_{tr} - NO_{te+va}}{NO_{tr} + NO_{te+va}} \right) \left(\frac{RMSE_{tr}}{R_{tr} + 1} \right) + \left(\frac{2NO_{va}}{NO_{tr} + NO_{te+va}} \right) \left(\frac{RMSE_{va}}{R_{va} + 1} \right) + \left(\frac{2NO_{te}}{NO_{tr} + NO_{te+va}} \right) \left(\frac{RMSE_{te}}{R_{te} + 1} \right) \quad (3)$$

$$R = \frac{\sum_{i=1}^n [(Y_{Ai} - Y_{Aim})(Y_{Pi} - Y_{Pim})]}{\sqrt{[\sum_{i=1}^n (Y_{Ai} - Y_{Aim})^2][\sum_{i=1}^n (Y_{Pi} - Y_{Pim})^2]}} \quad (4)$$

$$RMSE = \sqrt{MSE} = \sqrt{\frac{\sum_{i=1}^n (Y_{Ai} - Y_{Pi})^2}{n}} \quad (5)$$

$$MAE = \frac{\sum_{i=1}^n |Y_{Ai} - Y_{Pi}|}{n} \quad (6)$$

که در این معادلات، Y_{Ai} میزان واقعی خروجی داده نام $[Target(i)]$ ، Y_{Pi} مقدار برآورد مدل برای خروجی داده نام $[Output(i)]$ ، Y_{Aim} میانگین مقادیر Y_{Ai} ، Y_{Pim} میانگین مقادیر Y_{Pi} و n تعداد داده‌های یک مجموعه (مثلاً آموزشی) است. شایان ذکر است که tr نشانه مجموعه آموزشی، te نشانه مجموعه آزمایشی، va نشانه مجموعه ارزیابی و NO نشانه تعداد الگوهای مجموعه یا مجموعه‌های اندیش است.

۴- جمع‌آوری داده‌های اطلاعاتی

در این مقاله، برای ساخت و آزمون مدل‌های تخمین گروهی و ترکیبی منفرد و گروهی پیش‌بینی مقاومت چسبندگی میلگردهای GFRP از همان تعداد الگوهای موجود در مقاله گل‌افشانی و همکاران [2] و نتایج مدل‌های تخمین منفرد ANN و MGP (مدل بهینه) حاصل شده در مقاله مورد بررسی استفاده می‌گردد. پس مجموعاً از ۱۵۹ داده استفاده می‌شود؛ که نمونه‌ها همانند مقاله فوق‌الذکر به طور تصادفی در مجموعه‌های آموزشی (۷۰٪ داده‌ها برابر با ۱۱۱)، ارزیابی و آزمایشی (هر کدام ۱۵٪ داده‌ها برابر با ۲۴) تقسیم می‌شوند.

۵- ساخت و آزمایش مدل اول شبکه عصبی

در مدل اول، نتایج مدل‌های برآورد منفرد ANN و MGP (دو مدل دارای بهترین عملکرد در مقاله [2]) بر حسب نیوتن بر میلیمتر مربع، دو ورودی و مقاومت چسبندگی میلگردهای GFRP به بتن (نیوتن بر میلیمتر مربع) نیز خروجی است. مشخصات آماری (میانگین، حداکثر، حداقل، انحراف استاندارد و دامنه تغییرات) داده‌های ورودی و هدف در جدول ۱ نشان داده شده است.

جدول ۱: مشخصات آماری ورودی‌ها و هدف مدل اول شبکه عصبی

نام مشخصه آماری	میانگین	حداکثر	حداقل	انحراف	دامنه
نام ورودی و هدف	تغییرات استاندارد				
خروجی پیش‌بینی شده MGP	۷/۷۴	۲۰	۱/۱۸	۴/۷۹	۱۸/۸۲
خروجی پیش‌بینی شده ANN	۷/۸۶	۲۰/۲۸	۱/۱۳	۴/۸۰	۱۹/۱۵
خروجی واقعی (هدف)	۷/۸۳	۲۲/۳۴	۱/۶۴	۵/۰۳	۲۰/۷۰

بر اساس کتاب کیا [20]، بیش‌برازش^{۹۳}، پدیده‌ای است که زمانی اتفاق می‌افتد که شبکه صرفاً بر روی الگوهای آموزشی متمرکز شده و پیش‌بینی خوبی برای مجموعه آزمایشی انجام نمی‌دهد (بر خلاف مجموعه آموزشی)؛ که نشانه این مشکل، وجود نوسان بین نقاط منحنی برازش مجموعه آموزشی است. بعد از انجام تنظیمات نرم‌افزار، روند آموزش مدل با حداکثر ۱۰۰۰ تکرار شروع می‌شود. بهترین الگوریتم آموزش مدل و بهترین تعداد نورون‌های لایه پنهان از راه سعی و خطا و مطابق با معیارهای ارزیابی R و MSE به ترتیب، الگوریتم LM و ۹ نورون بدست آمده‌اند. بر اساس کتاب کیا [20]، یک شرط اتمام آموزش مدل، افزایش خطای ارزیابی در شش تکرار سری است؛ به این صورت از بیش‌برازش مدل بر روی مجموعه داده‌های آموزشی جلوگیری می‌شود. آموزش مدل بعد از ۲۵ تکرار و به علت فوق‌الذکر به اتمام رسیده است؛ که MSE کمینه برای مجموعه داده‌های ارزیابی برابر با ۰/۰۱۵ بدست آمده است (در تکرار ۱۹). اوزان مدل بهینه در معادلات (۷) تا (۱۰) نشان داده شده است. معادله (۱۱) [8]، رابطه نرمال‌سازی ورودی‌ها و خروجی در محدوده ۰/۱ تا ۰/۹ است. علت انتخاب این معادله برای نرمال‌سازی، اختصاص مقدار غیرصفر (۰/۱) به داده حداقل است؛ تا بی‌تأثیر در مدل نباشد.

$$lw\{2,1\} = [-0.5633 \quad -2.7594 \quad -3.0505 \quad -0.1472 \quad 0.1776 \quad 3.7629 \quad -0.2183 \quad 1.6342 \quad -0.7945] \quad (7)$$

$$iw\{1,1\} = \begin{bmatrix} -0.8531 & -2.9230 \\ 0.5341 & 11.3922 \\ -0.9517 & -8.9077 \\ -1.7104 & -7.1113 \\ 1.3926 & 11.4760 \\ -8.6040 & 8.5781 \\ -0.2689 & -5.9044 \\ 5.2206 & -5.3033 \\ -2.7036 & 3.2187 \end{bmatrix} \quad (8)$$

$$b\{1\} = \begin{bmatrix} -4.6930 \\ -6.7160 \\ 5.6127 \\ 2.3665 \\ 1.3331 \\ -3.2643 \\ -3.5367 \\ 1.9043 \\ -4.1800 \end{bmatrix} \quad (9)$$







$$b\{2\} = [0.8030] \quad (10)$$

$$X_{norm} = \left[(0.9 - 0.1) \frac{X - X_{min}}{X_{max} - X_{min}} \right] + 0.1 \quad (11)$$


که در معادله (۱۱)، X_{norm} میزان نرمال شده داده، X میزان واقعی داده، X_{min} میزان حداقل داده‌ها و X_{max} میزان حداکثر داده‌ها است. در معادلات (۷) تا (۱۰) نیز $iw\{1,1\}$ وزن‌های لایه اول (یعنی لایه پنهان) است؛ که ورودی‌های نرمال شده بر اساس معادله (۱۱) در آنها ضرب شده و با مقدارهای بایاس لایه اول یا همان $b\{1\}$ جمع شده و به عنوان ورودی‌های تابع انتقال لایه پنهان در نظر گرفته خواهند شد. $lw\{2,1\}$ نیز وزن‌های لایه دوم (یعنی لایه خروجی) است؛ که خروجی‌های تابع انتقال لایه اول در آنها ضرب شده و با مقدارهای بایاس لایه خروجی یعنی $b\{2\}$ جمع شده و به عنوان ورودی‌های تابع انتقال لایه خروجی در نظر گرفته خواهند شد. به دلیل خطی بودن تابع انتقال لایه خروجی، ورودی‌ها به این تابع همان خروجی‌های نرمال شده نرم‌افزار هستند. شایان ذکر است که به منظور مقایسه مدل‌های ارائه شده در این مقاله با مدل بهینه ارائه شده در مقاله [2]، مقادیر خطا و همبستگی برای نتایج خروجی نرمال شده مدل MGP در بازه

⁹³ Over Fitting

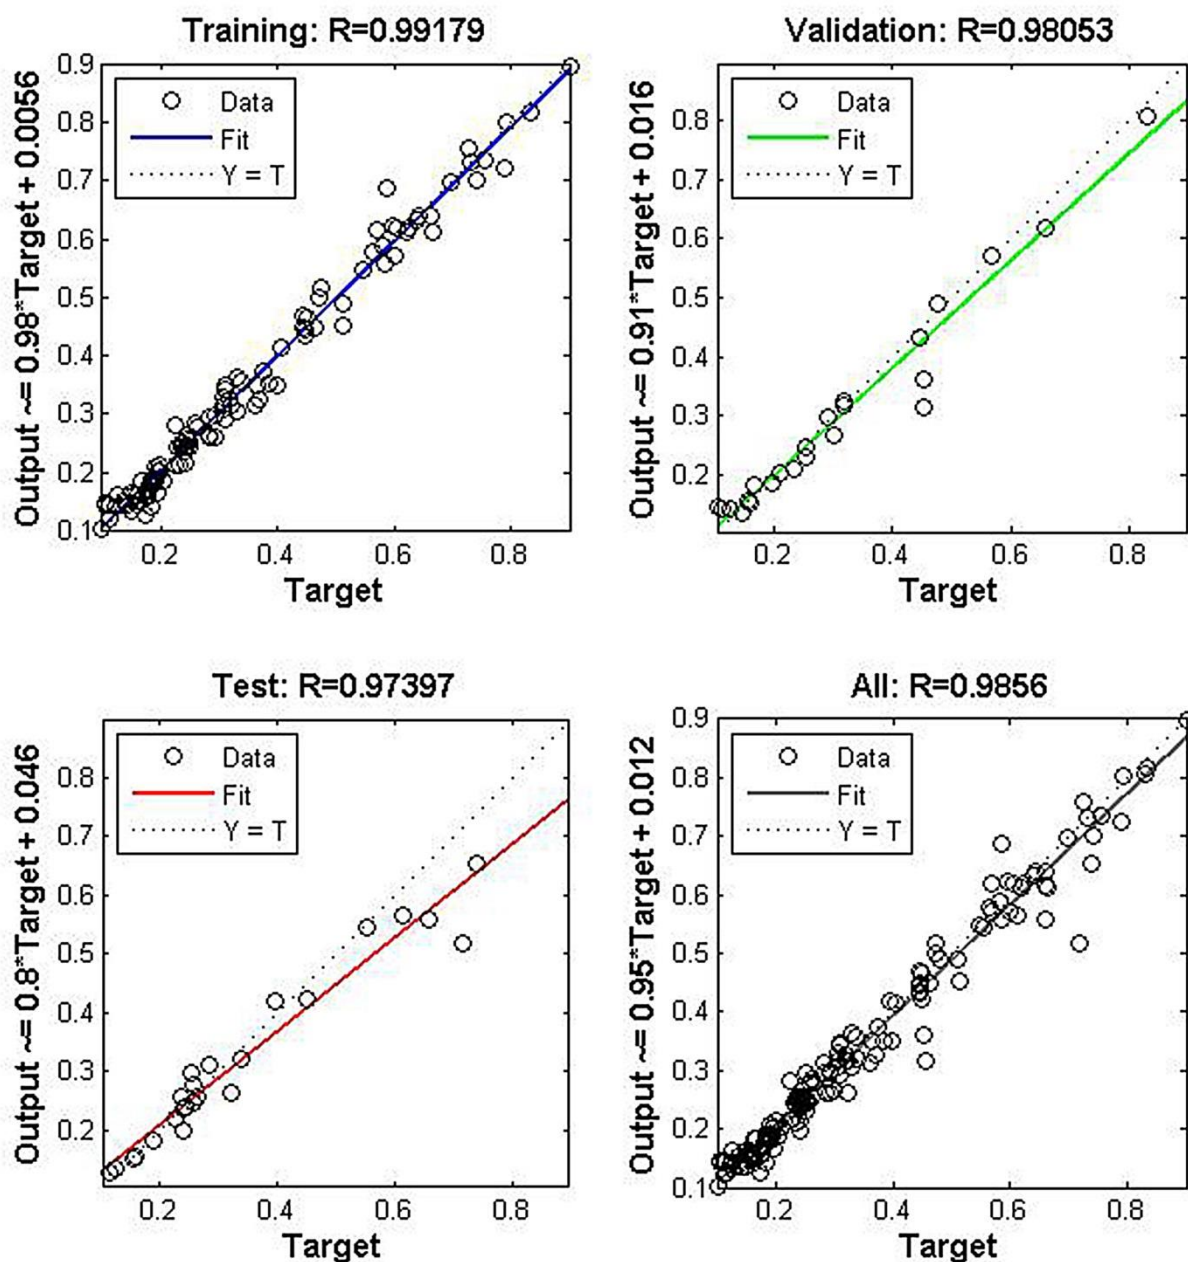
۰/۱ تا ۰/۹ محاسبه شده‌اند. تصویر پنجره نتایج ساخت مدل اول بهینه، نمودار عملکرد آموزش و نمودارهای همبستگی آن، به ترتیب در شکل ۲، شکل ۳ و شکل ۴ نشان داده شده‌اند (نمودارها خروجی‌های گرافیکی نرم‌افزار MATLAB هستند).

Results			
	 Samples	 MSE	 R
 Training:	111	6.44379e-4	9.91794e-1
 Validation:	24	1.50606e-3	9.80528e-1
 Testing:	24	2.94326e-3	9.73974e-1

شکل ۲: تصویر پنجره نتایج مدل اول شبکه عصبی در nftool.



شکل ۳: نمودار عملکرد آموزش مدل اول شبکه عصبی (خروجی MATLAB).



شکل ۴: نمودارهای R بدست آمده از آموزش مدل اول شبکه عصبی (خروجی MATLAB).

با توجه به نمودار عملکرد آموزش، نتیجه‌های بدست آمده از آموزش مدل در صورت محقق شدن ۳ شرط کوچک بودن میزان نهایی MSE ، شبیه بودن رفتار و خصوصیت‌های روند خطاهای مجموعه‌های آزمایشی و ارزیابی و روی ندادن بیش‌برازش تا تکراری که MSE کمینه برای مجموعه ارزیابی حاصل می‌گردد، مطلوب است [20]. با توجه به شکل ۳، نوسان در نقاط نمودار مجموعه آموزشی وجود ندارد و روند خطاهای مجموعه‌های آزمایشی و ارزیابی، مشابه و کاهشی است. ضمناً مطابق با شکل ۴، مقادارهای ضریب همبستگی مجموعه‌ها نزدیک بهم است. بنابراین آموزش مدل به درستی انجام شده است. اکنون زمان مقایسه MAE و OBJ (کل داده‌ها) مدل برآورد گروهی nftool1 با مدل‌های منفرد MGP (مدل بهینه مقاله [2]) و گروهی میانگین وزن‌دار نتایج خروجی نرمال شده مدل‌های ANN و MGP ارائه شده در مقاله [2] (مدل بهتر از مدل میانگین ساده) است. لازم به ذکر است که اوزان بهینه خروجی‌های مدل‌های فوق‌الذکر در معادله

میانگین وزن دار به ترتیب مساوی با ۰/۴۵ و ۰/۵۵ محاسبه شده است. مقادیرهای OBJ مدل‌های MGP، میانگین وزن دار و $nftool1$ برای کل مجموعه‌های آزمایشی، ارزیابی و آموزشی به ترتیب برابر با ۰/۰۲۸۴، ۰/۰۲۷۹ و ۰/۰۱۹۲ محاسبه شده است. مقادیر MAE (کل الگوها) مدل‌های MGP، میانگین وزن دار و $nftool1$ نیز به ترتیب برابر با ۰/۰۴۶۶، ۰/۰۴۶۰ و ۰/۰۲۲۰ محاسبه شده است. بنابراین مدل $nftool1$ دقت پیش‌بینی بیشتری دارد. در نمودارهای رگرسیونی هر چه نقاط بر روی نیمساز ربع اول متمرکزتر باشد، نشانگر عملکرد بهتر مدل است [8]. بر این اساس با توجه به شکل ۴، خط برازش داده شده از میان نقاط، فاصله زیادی با نیمساز ربع اول در مجموعه‌های ارزیابی و آزمایشی ندارد. لذا می‌توان گفت که عملکرد آزمایشی و صحت‌سنجی مدل $nftool1$ خوب است. ضمناً می‌توان گفت که هر چه مقدار هدف افزایش یابد، قابلیت تعمیم مدل به میزان نسبتاً زیادی کمتر می‌شود.

۶- ساخت و آزمایش مدل دوم شبکه عصبی و تحلیل حساسیت بر اساس وزن‌های شبکه به روش میلن

در مدل دوم، نتایج مدل‌های برآورد منفرد MGP و گروهی $nftool1$ ، دو ورودی هستند؛ که میانگین، حداکثر، حداقل، انحراف استاندارد و دامنه تغییرات ورودی $nftool1$ به ترتیب عبارت است از: ۰/۷۰، ۰/۲۲/۲۷، ۰/۱۷۳، ۴/۸۵ و ۲۰/۵۴. بهترین الگوریتم آموزش مدل و بهترین تعداد نورون‌های لایه پنهان از راه سعی و خطا به ترتیب، الگوریتم LM و ۹ نورون بدست آمده‌اند. آموزش مدل بعد از ۲۸ تکرار و به علت بهتر نشدن میزان خطای ارزیابی در حداکثر ۶ تکرار سری توقف کرده است؛ که MSE کمینه برای مجموعه داده‌های ارزیابی برابر با ۰/۰۰۸۵۶ بدست آمده است (در تکرار ۲۲). اوزان مدل بهینه در معادلات (۱۲) تا (۱۵) نشان داده شده است. رابطه (۱۶) [10] نیز معادله تحلیل حساسیت بر اساس وزن‌های شبکه عصبی به روش میلن را نشان می‌دهد.

$$lw\{2,1\} = [-0.4339 \quad 0.1797 \quad 0.5193 \quad -0.8096 \quad 0.2036 \quad -0.8144 \quad 0.4779 \quad 1.1038 \quad 0.3328] \quad (12)$$







$$iw\{1,1\} = \begin{bmatrix} -3.3638 & 0.7687 \\ -3.0152 & 2.9702 \\ -1.3202 & 4.2535 \\ -1.8494 & 3.8660 \\ 2.7825 & 2.8098 \\ -1.6333 & -1.9396 \\ -4.0775 & 0.1167 \\ -3.3145 & 3.1022 \\ 4.1709 & 1.1496 \end{bmatrix} \quad (13)$$

$$b\{1\} = \begin{bmatrix} 1.6711 \\ 3.0038 \\ 2.2470 \\ 1.1293 \\ -0.9471 \\ -1.5509 \\ -2.5813 \\ -2.5465 \\ 3.9537 \end{bmatrix} \quad (14)$$


$$b\{2\} = [0.9633] \quad (15)$$

$$Q_{ik} = \frac{\sum_{j=1}^{n_{hidden}} \left(\frac{W_{ji}}{\sum_{l=1}^{n_{inputs}} |W_{jl}|} \cdot W_{oj} \right)}{\sum_{k=1}^{n_{inputs}} \left[\sum_{j=1}^{n_{hidden}} \left| \frac{W_{jk}}{\sum_{l=1}^{n_{inputs}} |W_{jl}|} \cdot W_{oj} \right| \right]} \quad (16)$$

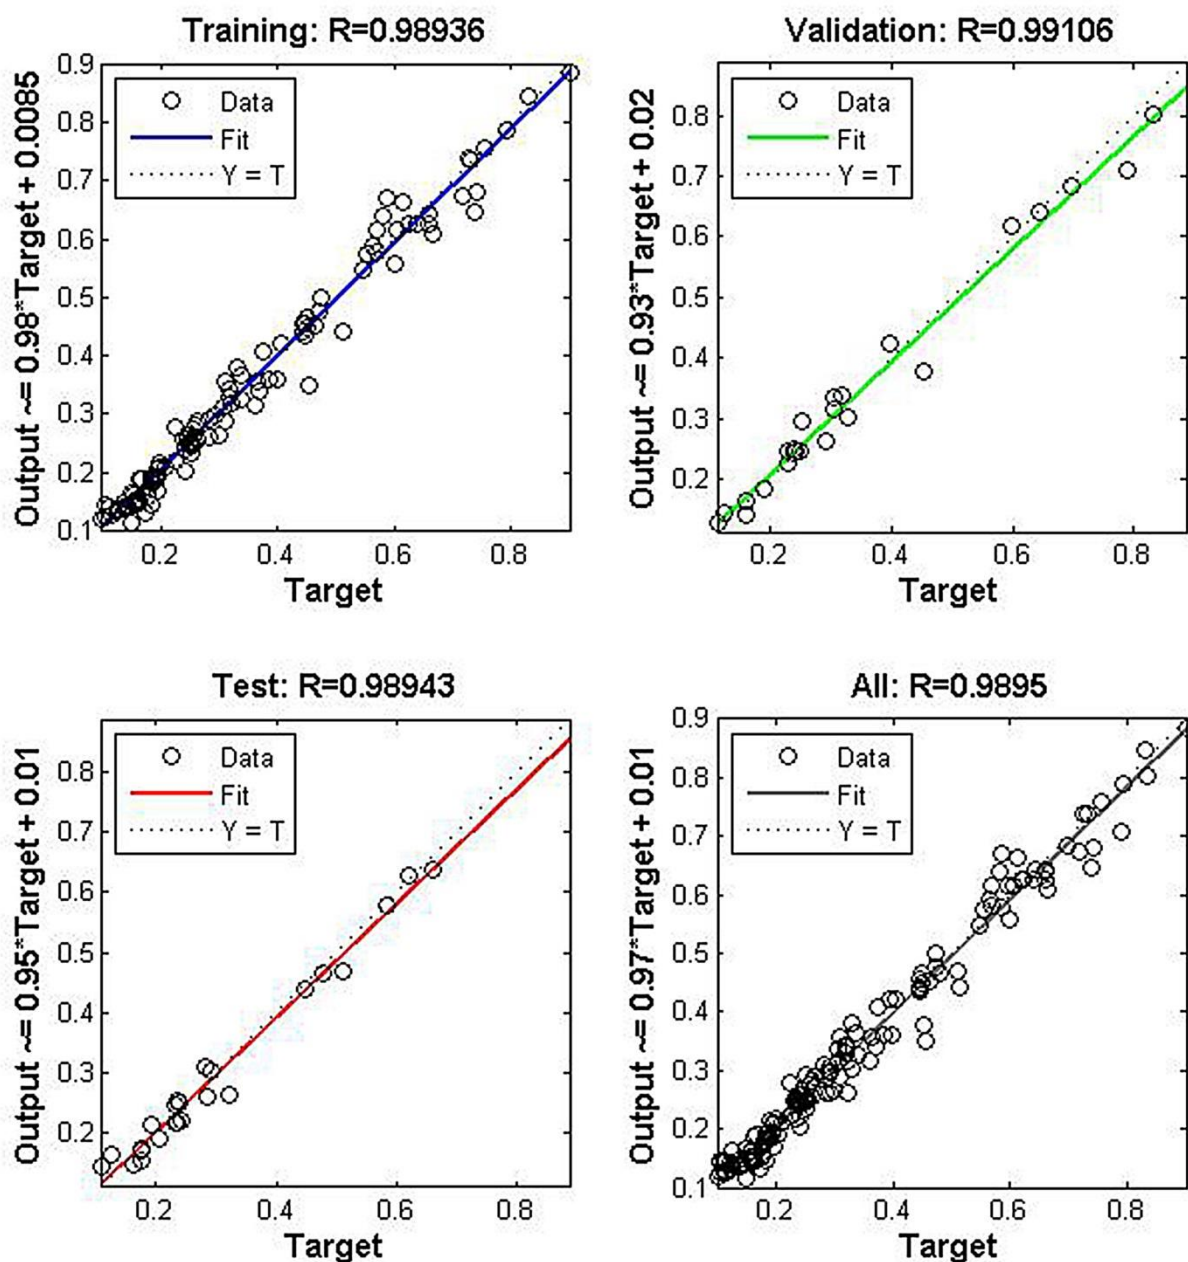
که در معادله (۱۶)، درصد تأثیر متغیر ورودی x_i بر متغیر خروجی y_k ، n_{hidden} تعداد نورون‌های لایه پنهان، n_{inputs} تعداد ورودی‌ها، قدرمطلق $\sum_{l=1}^{n_{inputs}} W_{jl}$ مجموع وزن‌های اتصال بین نورون‌های ورودی n و z نورون پنهان، W_{ji} وزن اتصال بین i نورون ورودی و z نورون پنهان و W_{oj} وزن اتصال بین z نورون پنهان و o نورون (یک) خروجی است [10]. تصویر پنجره نتایج ساخت مدل دوم بهینه، نمودار عملکرد آموزش و نمودارهای همبستگی آن، به ترتیب در شکل ۵، شکل ۶ و شکل ۷ نشان داده شده‌اند.

Results			
	 Samples	 MSE	 R
 Training:	111	8.32494e-4	9.89361e-1
 Validation:	24	8.55662e-4	9.91061e-1
 Testing:	24	5.52279e-4	9.89427e-1

شکل ۵: تصویر پنجره نتایج مدل دوم شبکه عصبی در nftool.



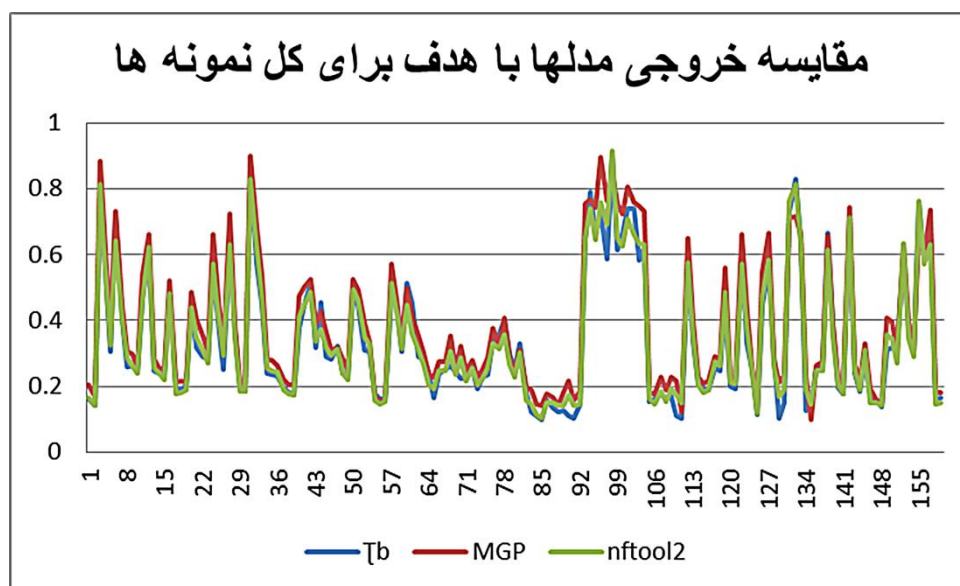
شکل ۶: نمودار عملکرد آموزش مدل دوم شبکه عصبی (خروجی MATLAB).



شکل ۷: نمودارهای R بدست آمده از آموزش مدل دوم شبکه عصبی (خروجی MATLAB).

بر اساس شکل ۶، نوسان در نقاط نمودار مجموعه آموزشی اصلاً وجود ندارد و روند خط‌های مجموعه‌های آزمایشی و ارزیابی، بسیار مشابه و کاهشی است. ضمناً بر اساس شکل ۷، مقدارهای ضریب همبستگی مجموعه‌ها بسیار نزدیک بهم است. بنابراین آموزش مدل به طور کامل و به درستی انجام شده است. حال زمان مقایسه *OBJ* و *MAE* (کل داده‌های نرمال شده) مدل ترکیبی روش‌های منفرد و گروهی *nftool2* با مدل تخمین گروهی *nftool1* است. مقدارهای *OBJ* مدل‌های *nftool1* و *nftool2* برای کل مجموعه‌های ارزیابی، آموزشی و آزمایشی به ترتیب برابر با ۰/۰۱۹۲ و ۰/۰۱۳۸ محاسبه شده است. مقدارهای *MAE* (کل داده‌های نرمال شده) *nftool1* و *nftool2* نیز به ترتیب برابر با ۰/۰۲۲۰ و ۰/۰۲۱۷ محاسبه شده است. پس مدل *nftool2* قوی‌ترین عملکرد را در بین تمامی مدل‌های مورد بررسی دارد.

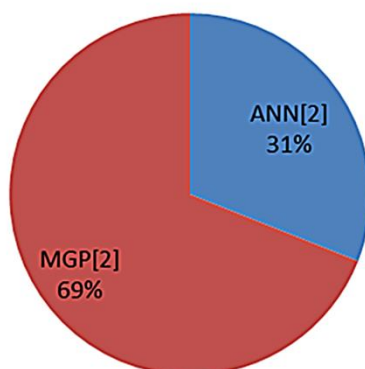
شایان ذکر است که فاصله خط برازش داده شده با نیمساز ربع اول در نمودارهای رگرسیونی مجموعه‌های آزمایشی و ارزیابی در شکل ۷، بسیار کم است. لذا می‌توان گفت که قابلیت تعمیم و دقت صحت‌سنجی مدل nftool2 زیاد است. ضمناً می‌توان گفت که هر چه مقدار هدف کمتر باشد، قابلیت تعمیم مدل نیز بیشتر است. در انتهای این قسمت، شکل ۸ قرار داده شده است؛ که مقادیر واقعی خروجی (τ_b) و مقادیر خروجی پیش‌بینی شده مدل‌های MGP [2] و nftool2 برای کل داده‌ها را نشان می‌دهد. نقاط خروجی واقعی در شکل ۸ غالباً زیر و یا بر روی نقاط خروجی پیش‌بینی شده مدل‌ها قرار گرفته‌اند. نقاط خروجی مدل MGP نیز غالباً بالاتر از نقاط خروجی مدل nftool2 قرار گرفته‌اند. لذا می‌توان نتیجه گرفت که هر دو مدل غالباً تخمینی بیشتر از مقدار واقعی دارند؛ که تخمین مدل MGP بیشتر از مدل nftool2 (با فاصله‌ای بیشتر، از مقادیر واقعی) است.



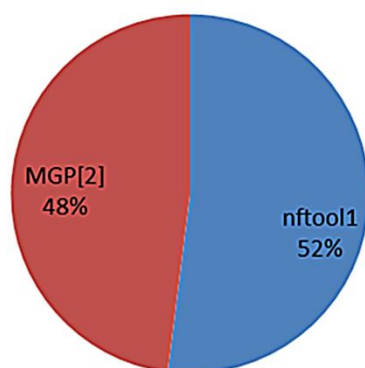
شکل ۸: مقادیر خروجی واقعی و مقادیر خروجی پیش‌بینی شده مدل‌های MGP و nftool2 برای کل نمونه‌ها.

نتایج تحلیل‌های حساسیت انجام شده به روش میلن به صورت نمودارهای دایره‌ای درصدی تأثیر ورودی‌های مدل شبکه عصبی اول (نتایج [2] ANN و نتایج [2] MGP) و ورودی‌های مدل شبکه عصبی دوم (نتایج nftool1 و نتایج [2] MGP) بر هدف در شکل ۹ مشخص شده است. همان‌طور که در شکل ۹ قابل مشاهده است، مدل شبکه عصبی ارائه شده در تحقیق گل‌افشانی و همکاران [2] به علت عملکرد ضعیفتر در پیش‌بینی نسبت به مدل MGP ارائه شده در آن مقاله، درصد تأثیرگذاری خیلی کمتری بر هدف دارد. اما مدل شبکه عصبی ارائه شده در این مقاله به دلیل دقت بالاتر نسبت به MGP، درصد تأثیرگذاری بیشتری بر هدف دارد. مقایسه‌ای نیز بین نتایج مدل نهایی در حالتی که ورودی‌ها و خروجی در بازه ۰ و ۱ نرمال شده‌اند و نتایج مدل نهایی در حالتی که ورودی‌ها و خروجی در محدوده ۰/۱ تا ۰/۹ نرمال شده‌اند، صورت گرفته است؛ که R ، $RMSE$ و MAE بدست آمده برای کل ۱۵۹ داده بازگردانده شده به حالت غیرنرمال در دو حالت در جدول ۲ نشان داده شده است. مطابق با جدول ۲، دقت و عملکرد مدل با داده‌های نرمال شده بین ۰/۱ و ۰/۹ نسبت به مدل با داده‌های نرمال شده بین ۰ و ۱، بهتر است. در انتها به منظور جمع‌بندی و خلاصه کردن نتایج، مقادیرهای MAE و OBJ (هر دو برای کل داده‌های نرمال شده) و مقادیرهای R و خطای $RMSE$ برای هر یک از مجموعه‌های مدل‌های MGP، میانگین وزن‌دار، nftool1 و nftool2 در جدول ۳ نشان داده شده‌اند. مطابق با جدول ۳، در نظرگیری نتایج تخمین یک مدل برآورد گروهی به عنوان ورودی یک مدل دیگر در کنار نتایج تخمین یک مدل منفرد با عملکرد خوب باعث افزایش قابلیت تعمیم (آزمایش و ارزیابی) آن مدل‌های گروهی و منفرد می‌گردد.

درصد تأثیر ورودیهای مدل اول بر هدف



درصد تأثیر ورودیهای مدل دوم بر هدف



شکل ۹: نمودارهای دایره‌ای نتایج تحلیل حساسیت به روش میلن برای مدل‌های اول و دوم شبکه عصبی.

جدول ۲: نتایج مقایسه بین مدل با داده‌های نرمال شده بین ۰ تا ۱ و مدل با داده‌های نرمال شده بین ۰/۱ تا ۰/۹

نام مدل	RMSE (کل داده‌ها)	R (کل داده‌ها)	MAE (داده‌ها)
nftool2 (با داده‌های نرمال شده بین ۰ و ۱)	۰/۷۴۱	۰/۹۸۹	۰/۵۵۳
nftool2 (با داده‌های نرمال شده بین ۰/۱ و ۰/۹)	۰/۷۳۱	۰/۹۹۰	۰/۵۳۸

جدول ۳: خلاصه نتایج بدست آمده از مدل‌های تخمین مقاومت چسبندگی

MAE	OBJ	R	RMSE	نام معیار	نام مدل
(کل داده‌ها)	(کل داده‌ها)			نام مجموعه	
		۰/۹۸۱	۰/۰۶۰۰	آموزشی	MGP
۰/۰۴۶۶	۰/۰۲۸۴	۰/۹۸۵	۰/۰۳۹۸	آزمایشی	MGP
		۰/۹۶۵	۰/۰۶۷۵	ارزیابی	MGP
		۰/۹۸۳	۰/۰۵۶۷	آموزشی	میانگین وزن دار (0.45ANN+0.55MGP)
۰/۰۴۶۰	۰/۰۲۷۹	۰/۹۸۴	۰/۰۴۵۱	آزمایشی	میانگین وزن دار (0.45ANN+0.55MGP)
		۰/۹۸۰	۰/۰۶۳۵	ارزیابی	میانگین وزن دار (0.45ANN+0.55MGP)
		۰/۹۹۲	۰/۰۲۵۰	آموزشی	nftool1 (ورودی‌ها: ANN و MGP)
۰/۰۲۲۰	۰/۰۱۹۲	۰/۹۷۴	۰/۰۵۴۰	آزمایشی	nftool1
		۰/۹۸۱	۰/۰۳۹۰	ارزیابی	nftool1
		۰/۹۸۹	۰/۰۲۹۰	آموزشی	nftool2 (ورودی‌ها: MGP و nftool1)
۰/۰۲۱۷	۰/۰۱۳۸	۰/۹۹۱	۰/۰۲۴۰	آزمایشی	nftool2
		۰/۹۸۹	۰/۰۲۹۰	ارزیابی	nftool2

۷- نتیجه گیری

در این مقاله با بکارگیری جعبه‌ابزار nftool در MATLAB، یک مدل پیش‌بینی گروهی و یک مدل مرکب از مدل‌های برآورد گروهی و منفرد برای پیش‌بینی مقاومت چسبندگی میلگردهای GFRP به بتن ارائه شد. خلاصه کار انجام شده و نتایج عبارت است از: ۱- برای ساخت و آزمایش هر دو مدل شبکه عصبی از اطلاعات ۱۵۹ نمونه بتن (۱۱۱ نمونه در مجموعه آموزشی و ۲۴ نمونه در هر یک از مجموعه‌های ارزیابی و آزمایشی) استفاده شد. ۲- با توجه به اینکه هدف مهم مقاله، بهبود عملکرد مدل‌های تلفیق داده توسط ترکیب آنها با مدل‌های منفرد بود؛ ورودی‌های مدل اول شبکه عصبی، نتایج برآورد دو مدل منفرد قبلاً ارائه شده و ورودی‌های مدل دوم شبکه عصبی، نتایج تخمین مدل بهینه ارائه شده از میان آن دو مدل و خروجی‌های مدل ANN اول ارائه شده در این مقاله در نظر گرفته شدند. ۳- تحلیل حساسیتی بر اساس وزن‌های شبکه به روش میلن انجام گرفت؛ که این نتیجه بدست آمد که هر چه مدلی که خروجی پیش‌بینی شده‌اش به عنوان ورودی مدلی دیگر در نظر گرفته می‌شود، خطای تخمین کمتری داشته باشد، درصد تأثیرگذاری بیشتری بر هدف آن مدل دیگر دارد. ۴- نرمال‌سازی ورودی‌ها و خروجی در بازه ۰/۱ تا ۰/۹ باعث افزایش دقت برآورد مدل نسبت به نرمال‌سازی در محدوده ۰ و ۱ می‌شود. ۵- می‌توان با تلفیق انواع مدل‌های تخمین گروهی با منفرد، هم خطای مدل‌های منفرد و هم گروهی را کم کرد. شایان ذکر

است که برای مطالعات آینده توصیه می‌گردد از مدل‌های کننویسی برای انجام مدل‌سازی به شیوه این مقاله استفاده شود و با نتیجه‌های کسب شده در این مقاله مقایسه گردد.

مراجع

- [1] Zandi, Y. (2009). *Advanced Concrete Technology*. 2nd Edition. Tabriz: Forouzes Publisher, 577-596 (In Persian).
- [2] Golafshani, E.M., Rahai, A. and Sebt, M.H. (2015). Artificial neural network and genetic programming for predicting the bond strength of GFRP bars in concrete. *Materials and Structures*, 48, pp 1581-1602.
- [3] Coelho, M.R.F., Sena-Cruz, J.M., Neves, L.A.C., Pereira, M., Cortez, P. and Miranda, T. (2016). Using data mining algorithms to predict the bond strength of NSM FRP systems in concrete. *Construction and Building Materials*, 126, 484-495.
- [4] Naderpour, H., Nourmohammadi, E. and Fakharian, P. (2017). Prediction of punching shear capacity of RC slabs using support vector machine. *Concrete Research*, 10 (2), 95-107 (In Persian).
- [5] Bazli, M., Ashrafi, H. and Oskouei, A.V. (2017). Experiments and probabilistic models of bond strength between GFRP bar and different types of concrete under aggressive environments. *Construction and Building Materials*, 148, 429-443.
- [6] Kaboutari, M., Ghiami, A., Sadrsadat, E. and Ghorbani, B. (2017). Prediction of Bond Strength Between Concrete and FRP Using Data Laboratory. *5th International Congress on Civil Engineering, Architecture and Urban Development*. Tehran: Shahid Beheshti University, 1-9 (In Persian).
- [7] Yan, F., Lin, Z., Wang, X., Azarmi, F. and Sobolev, K. (2017). Evaluation and prediction of bond strength of GFRP-bar reinforced concrete using artificial neural network optimized with genetic algorithm. *Composite Structures*, 161, 441-452.
- [8] Naderpour, H. and Fakharian, P. (2018). Predicting the torsional strength of reinforced concrete beams strengthened with FRP sheets in terms of artificial neural networks. *Journal of Structural and Construction Engineering*, 5 (1), 20-35 (In Persian).
- [9] Bolandi, H., Banzhaf, W., Lajnef, N., Barri, K. and Alavi, A.H. (2019). An intelligent model for the prediction of bond strength of FRP bars in concrete: A soft computing approach. *Technologies*, 7 (2), 42;1-16.
- [10] Naderpour, H., Nagai, K., Fakharian, P. and Haji, M. (2019). Innovative models for prediction of compressive strength of FRP-confined circular reinforced concrete columns using soft computing methods. *Composite Structures*, 215, 69-84.
- [11] Naderpour, H. and Mirrashid, M. (2019). A neuro-fuzzy model for punching shear prediction of slab-column connections reinforced with FRP. *Journal of Soft Computing in Civil Engineering*, 3 (1), 16-26.
- [12] Chou, J.S. and Pham, A.D. (2013). Enhanced artificial intelligence for ensemble approach to predicting high performance concrete compressive strength. *Construction and Building Materials*, 49, 554-563.
- [13] Chou, J.S., Tsai, C.F., Pham, A.D. and Lu, Y.H. (2014). Machine learning in concrete strength simulations: Multi-nation data analytics. *Construction and Building Materials*, 73, 771-780.
- [14] Aydogmus, H.Y., Erdal, H.I., Karakurt, O., Namli, E., Turkan, Y.S. and Erdal, H. (2015). A comparative assessment of bagging ensemble models for modeling concrete slump flow. *Computers and Concrete*, 16 (5), 741-757.
- [15] Naderpour, H., Rafiean, A.H. and Fakharian, P. (2018). Compressive strength prediction of environmentally friendly concrete using artificial neural networks. *Journal of Building Engineering*, 16, 213-219.
- [16] Ling, H., Qian, C., Kang, W., Liang, C. and Chen, H. (2019). Combination of Support Vector Machine and K-Fold cross validation to predict compressive strength of concrete in marine environment. *Construction and Building Materials*, 206, 355-363.
- [17] Zhang, M., Li, M., Shen, Y., Ren, Q. and Zhang, J. (2019). Multiple mechanical properties prediction of hydraulic concrete in the form of combined damming by experimental data mining. *Construction and Building Materials*, 207, 661-671.
- [18] Naderpour, H., Rezazadeh Eidgahee, D., Fakharian, P., Rafiean, A.H. and Kalantari, S.M. (2019). A new proposed approach for moment capacity estimation of ferrocement members using Group Method of Data Handling. *Engineering Science and Technology, an International Journal*, In press, doi.org/10.1016/j.jestch.2019.05.013.
- [19] Shahmansouri, A.A., Akbarzadeh Bengar, H. and Jahani, E. (2019). Predicting compressive strength and electrical resistivity of eco-friendly concrete containing natural zeolite via GEP algorithm. *Construction and Building Materials*, 229, Number Article: 116883.
- [20] Kia, S.M. (2012). *Neural Networks in the MATLAB*. 2nd Edition. Tehran: Kian Rayaneh Sabz Publisher, 81-239 (In Persian).
- [21] Golafshani, E.M. and Ashour, A. (2016). A feasibility study of BBP for predicting shear capacity of FRP reinforced concrete beams without stirrups. *Advances in Engineering Software*, 97, 29-39.