

پیش‌بینی ضریب محصورشدگی جانبی ستون‌های بتنی محصورشده با FRP به وسیله شبکه عصبی مصنوعی

احسان درویشان *

استادیار، گروه عمران، واحد رودهن، دانشگاه آزاد اسلامی، رودهن، ایران.

چکیده

محصور نمودن ستون یکی از پرکاربردترین روش‌های مقاوم‌سازی ساختمان محسوب می‌شود. محصور نمودن ستون‌های بتنی با ورقه‌های FRP به دلیل ویژگی‌هایی که دارد از جمله روش‌های نوین مقاوم‌سازی سازه‌ها محسوب می‌گردد. آزمایش‌هایی که با اعمال فشار محوری به ستون‌های دارای گردگوشگی انجام گرفته است، نشان می‌دهد که هرچه ستون به مقاطع دایره‌ای نزدیک‌تر شود، رفتار آن بهبود می‌یابد. اگرچه رفتار ستون‌های بتن آرمه محصور شده با FRP یا دارای آرماتور عرضی توسط پژوهشگران زیادی مورد مطالعه قرار گرفته است، اما تحقیق در مورد دورپیچ نمودن ستون با FRP زمانی که آرماتورهای عرضی پاسخگوی محصورشدگی مورد نیاز ستون نیستند، کمتر مورد توجه قرار گرفته است. در این مقاله مدل‌های مختلفی از ضریب محصورشدگی جانبی ارائه شده است همچنین با در نظر گرفتن نتایج ۱۱۴ آزمایش معتبر و تأثیر پارامترهای مهمی از جمله طول و عرض مقطع ستون، ضخامت ورق FRP، مقاومت فشاری بتن، مدول الاستیسیته FRP و شعاع گردشدگی گوشه‌های بتن، مدل جدیدی با استفاده از شبکه عصبی ارائه شده است که با استفاده از آن می‌توان ضریب محصورشدگی جانبی ستون‌های محصور شده را با دقت بالایی پیش‌بینی کرد. در نهایت، آنالیز حساسیت به منظور بررسی میزان تأثیر هر پارامتر ورودی روی پارامتر خروجی نیز انجام گرفته و نتایج آن ارائه شد. با توجه به دقت بالای مدل پیشنهادی توسط شبکه عصبی بدین ترتیب برای محاسبه ضریب محصورشدگی جانبی ستونی که پارامترهای آن در بازه پارامترهای تعریف شده در این مطالعه باشد دیگر نیازی به صرف هزینه و زمان برای مطالعه آزمایشگاهی آن ستون نمی‌باشد.

واژه‌های کلیدی: مقاوم سازی، ستون بتن آرمه، FRP، شبکه عصبی مصنوعی، محصورشدگی.

* نویسنده مسئول: darvishan@riau.ac.ir

۱- مقدمه

Razvi و Saatcioglu در سال‌های ۱۹۹۲ و ۱۹۹۹ [۵،۶] یک

رابطه برای پیش‌بینی رابطه تنش- کرنش بتن محصور شده پیشنهاد کردند که شامل یک منحنی برای شاخه صعودی و یک قسمت خطی برای شاخه نزولی بود. شاخه نزولی در نقطه‌ای تعریف شد که کرنش آن متناظر با کرنش نقطه‌ای می‌باشد که تنش حداکثر به میزان ۱۵ درصد افت کرده باشد. در این مطالعه پارامترهای مدل تحلیلی توسط تعداد زیادی داده آزمایشگاهی توسعه داده شد که شامل بتن‌های کم محصور شده و خوب محصور شده می‌باشد.

Chung و همکاران در سال ۲۰۰۲ [۷] یک رابطه تنش- کرنش برای بتن محصور شده حاصل از ۶۵ مطالعه تجربی پیشنهاد کردند که پارامترهای در نظر گرفته شده آن‌ها شامل مقاومت بتن، نسبت حجمی و توزیع میلگردهای طولی و عرضی می‌باشد.

در سال ۲۰۰۶، Alacali و همکاران [۸] با استفاده از الگوریتم شبکه عصبی به پیش‌بینی ضریب محصورشدگی ستون‌های بتن مسلح پرداختند. آن‌ها برای تشکیل مدل خود ۶ پارامتر به عنوان ورودی در نظر گرفتند که این مدل قادر بود تخمین‌های درستی از ضریب محصورشدگی جانبی داشته باشد.

در سال ۲۰۱۰، نادرپور و همکاران [۹] به پیش‌بینی مقاومت فشاری بتن محصور شده با FRP با استفاده از شبکه عصبی مصنوعی پرداختند. آن‌ها تعداد زیادی داده آزمایشگاهی به منظور ساختن شبکه خود استفاده کردند. آن‌ها پارامترهایی مانند مشخصات بتن و FRP را به عنوان ورودی و مقاومت فشاری بتن محصور شده با FRP را به عنوان پارامتر خروجی در نظر گرفتند. آن‌ها با مقایسه نتایج روش پیشنهادی خود با داده‌های تجربی و آزمایشگاهی دقت خوبی را برای مدل توسعه یافته خود برای پیش‌بینی مقاومت فشاری بتن، مشاهده کردند.

در سال ۲۰۱۱، Alacali و همکاران [۱۰] از شبکه عصبی مصنوعی (ANN) برای پیش‌بینی درجه محصورشدگی ستون‌های بتنی محصور شده استفاده کردند. آن‌ها به منظور بررسی اثرات محصورشدگی، سه معادله تجربی که تابعی از پارامترهای مختلف بود و همچنین یک مطالعه آزمایشگاهی را مورد بررسی قرار دادند. آن‌ها ادعا نمودند که معادلات موجود برای تعیین ضریب محصورشدگی پیچیده و وقت‌گیر است به همین دلیل آن‌ها با استفاده از الگوریتم NN یک روش دقیق و ساده برای ضریب محصورشدگی پیشنهاد کردند. مدل آن‌ها با استفاده از ۶ پارامتر

در مناطق زلزله‌خیز در سراسر دنیا سازه‌های بتن مسلح موجود دارای مقاومت لرزه‌ای ناکافی به دلیل به روزرسانی مداوم آیین‌نامه‌های لرزه‌ای هستند. زلزله‌های گذشته نشان داد که ساختمان‌های موجود، با توجه به مقاومت لرزه‌ای ضعیف عناصر سازه‌ای مانند تیرها، دال‌ها، ستون‌ها و دیوارهای برشی، به شدت آسیب می‌بینند. از این رو مقاوم بودن این اعضا نقش مهمی در مقاومت کل سازه دارد. استفاده از پیش‌تنیدگی خارجی، غلاف فولادی یا بتنی و صفحات الیاف پلیمری (FRP) برخی از روش‌های متعارف هستند. مقاوم‌سازی سازه‌های بتنی مسلح با استفاده از کامپوزیت‌های FRP، در مقایسه با سایر روش‌های ذکر شده، به دلیل دستیابی به مقاومت بالاتر در ازای زحمت کمتر و همچنین عدم تغییر در شکل و ابعاد سازه، به عنوان روش متداول در سراسر جهان پذیرفته شده است. از انواع روش‌های تقویت ستون‌ها با الیاف می‌توان به روش ترکیبی، دورپیچ کامل و نواری اشاره کرد [۱]. واضح است که محصورشدگی جانبی ستون منجر به افزایش مقاومت فشاری ستون می‌گردد. لذا به دست آوردن ضریب محصورشدگی جانبی ستون موضوعی است که دانشمندان زیادی به مطالعه آن پرداخته‌اند.

Kent و Park در سال ۱۹۷۱ [۲] یک منحنی تنش- کرنش برای بتن‌های محصورشده با خاموت‌های فولادی مربعی پیشنهاد کردند. این منحنی تا نقطه ماکزیمم به وسیله یک منحنی درجه دوم و یک شاخه نزولی خطی و یک قسمت خطی افقی با تنش ثابت در نقطه 0.7 تنش ماکزیمم، رسم می‌گردد. Park و همکاران این مدل پیشنهاد شده را در سال ۱۹۸۲ اصلاح کردند. در سال ۱۹۸۰، Sheikh و Uzumeri [۳] تعداد ۲۴ ستون کوتاه را تحت بارگذاری فشاری مونوتونیک قرار دادند تا تأثیر پارامترهای مختلف را در رفتار ستون‌های محصور شده با خاموت بررسی کنند. پارامترهای اصلی شامل توزیع میلگردهای طولی، محیط ستون، شکل خاموت‌ها و مقدار میلگردهای طولی و عرضی بودند. آن‌ها همچنین در سال ۱۹۸۲ [۴] یک منحنی تنش- کرنش کامل برای بتن محصور شده بر اساس نتایج آزمایشگاهی ارائه کردند. آن‌ها نشان دادند که توزیع میلگردهای طولی و فاصله کمتر خاموت‌ها منجر به مقاومت و شکل‌پذیری بیشتری در بتن خواهد شد که منظور آن‌ها از شکل‌پذیری توانایی مواد به تغییر شکل تحت تنش‌های کششی می‌باشد.

فشاری بتن، عرض و فاصله و زاویه نوارهای FRP، نسبت دهانه برشی به عمق، مدول الاستیسیته FRP و ضخامت FRP پیش‌بینی کردند و نتایج حاصل از آن را با آیین‌نامه‌های معتبری نظیر fib-CSA-S806(12) و ACI 440.2R-08، CIDAR، TG9.3 مقایسه کردند و نتیجه گرفتند که مدل پیشنهادی یک وسیله قابل اعتماد و صحیح در مقایسه با فرمول‌های آیین‌نامه‌ای می‌باشد. در این مطالعه با استفاده از شبکه عصبی مصنوعی و نتایج معتبر آزمایشگاهی، ضریب محصورشدگی جانبی ستون پیش‌بینی می‌شود و با استفاده از آنالیز حساسیت تأثیر هر یک از پارامترهای ورودی در نظر گرفته شده روی ضریب محصورشدگی مشخص می‌گردد.

محاسبات نرم حاصل تلاش‌های جدید علمی می‌باشد که مدل‌سازی، تحلیل، و در نهایت کنترل سیستم‌های پیچیده را با سهولت و موفقیت زیادتری امکان‌پذیر می‌سازد. به‌عنوان مهم‌ترین شاخه‌های این محاسبات، باید منطق فازی، شبکه‌های عصبی مصنوعی، و الگوریتم ژنتیک را نام برد که می‌توان برای پیش‌بینی نتایج از آن‌ها استفاده کرد [۱۴-۱۶]. مدل‌سازی سیستم‌ها با ابزارهای ریاضی معمول مانند معادلات دیفرانسیل برای سیستم‌های پیچیده و دارای عدم قطعیت مناسب و کارا نیست و مدل‌های حاصل از تحلیل‌های رگرسیونی قادر به ارائه پیش‌بینی خوبی از نتایج نمی‌باشند اما شبکه‌های عصبی مصنوعی به‌طور خودکار روابط بین متغیرها را مدیریت می‌کنند و بر اساس داده‌های مورد استفاده برای آموزش آن‌ها سازگار می‌شوند. لذا با توجه به دقت و سرعت بالای شبکه عصبی در آموزش و یادگیری و پیش‌بینی در این مطالعه از این روش توانمند استفاده شده است. در این مقاله، با در نظر گرفتن تعداد ۱۱۴ نمونه آزمایشگاهی معتبر و تعداد ۶ پارامتر ورودی از جمله طول و عرض مقطع ستون، ضخامت ورق FRP، مقاومت فشاری بتن، مدول الاستیسیته FRP و شعاع گردشگی گوشه‌های بتن به پیش‌بینی ضریب محصورشدگی جانبی ستون‌های محصور شده پرداخته شده است. لذا با توجه به این مطالعه دیگر نیازی به صرف هزینه و زمان جهت مطالعه آزمایشگاهی به منظور به دست آوردن ضریب محصورشدگی جانبی ستون‌های محصور شده که پارامترهای آن در بازه پارامترهای این مطالعه هستند، نمی‌باشد.

ورودی شکل گرفت و نتایج آن در مقایسه با معادله‌های تجربی اعتبار این الگوریتم را نشان داد.

نایب و همکاران در سال ۲۰۱۳ [۱۱] به مطالعه‌ای در مورد پیش‌بینی ضریب محصورشدگی جانبی در ستون‌های بتن مسلح با استفاده از روش یادگیری ماشین پرداختند و چندین فرمول آزمایشگاهی را برای پیش‌بینی آن توسعه دادند. در این مطالعه از روش‌های محاسبات نرم جدیدی نسبت به روش‌های رایج مثل مدل درختی به منظور پیش‌بینی ضریب محصورشدگی استفاده شد. مزایای مهم مدل درختی این است که برخلاف دیگر ابزارهای آموزش داده‌ها، راحت‌تر استفاده می‌شوند و مهم‌تر از همه قواعد ریاضی قابل فهم را نشان می‌دهند. در این مطالعه برای پیش‌بینی ضریب محصورشدگی، یک فرمول جدید که شامل پارامترهای ساختاری استخراج شده از پارامترهای بی بعد می‌باشد، به دست آمده است. در این مطالعه با استفاده از مقایسه نتایج حاصل از فرمول جدید با فرمول‌های داده شده توسط دیگر محققان دقت خوبی حاصل شد. در سال ۲۰۱۵، Doran و همکاران [۱۲] از روش منطق فازی برای پیش‌بینی ضریب محصورشدگی جانبی برای ستون‌های دورپیچ شده با CFRP استفاده کردند. در این مطالعه مدل‌های محصورشدگی موجود در مطالعات گذشته مورد بررسی قرار گرفته و بر اساس دیتاهای موجود در آن مطالعات یک الگوریتم جدید بر اساس هوش مصنوعی برای مدل‌سازی افزایش مقاومت ستون‌های بتن مسلح محصور شده با CFRP و با استفاده از منطق فازی پیاده‌سازی شده است. نتایج حاصل از منطق فازی با خروجی‌های حاصل از رگرسیون غیرخطی مشتق شده از مدل‌های نمایشی، مقایسه گردید. بهترین عملکرد در مدل‌ها با توجه به شاخص‌های آماری مختلف مورد ارزیابی قرار گرفت. مقایسه روش‌های پیشنهادی با داده‌های تجربی و آزمایشگاهی موجود، دقت بسیار بالای مدل بر پایه هوش مصنوعی را در پیش‌بینی ضریب محصورشدگی جانبی در ستون‌های بتن مسلح دورپیچ شده با CFRP نشان می‌دهد.

نادرپور و علوی، در سال ۲۰۱۷ [۱۳] از مدل پایه فازی برای پیش‌بینی سهم برش FRP در تیرهای بتن مسلح دورپیچ شده با صفحات FRP استفاده کردند. آن‌ها با در نظر گرفتن ۸۹ داده آزمایشگاهی مقاومت برشی FRP را با استفاده از ۷ پارامتر ورودی مثل کرنش نهایی FRP، عمق موثر FRP، مقاومت

$$K_s = 1 + \frac{22.9b_c^2}{P_{occ}} \left[\left(1 - \frac{mc_1^2}{5.5b_c^2} \right) \left(1 - \frac{s}{2b_c} \right)^2 \right] \sqrt{\rho_s f_{yh}} \quad (4)$$

$$P_{occ} = 0.85(A_{ck} - A_{st}) \quad (5)$$

که در این معادلات A_{ck} مساحت هسته محصور شده بتن، A_{st} مساحت نهایی میلگردهای طولی، m تعداد میلگردهای طولی و c_1 فاصله خالص بین میلگردهای طولی محدود شده توسط محیط مقطع می‌باشد.

Shah و Fafitis در سال ۱۹۸۵ [۱۸] یک رابطه تنش-کرنش برای بتن محصور شده و محصور نشده پیشنهاد کردند. آن‌ها یک مطالعه پارامتری به منظور بررسی تأثیر مقاومت بتن، میزان بار محوری، درجه محصورشدگی و شکل مقطع روی ظرفیت ستون‌های تحت جابه‌جایی‌های بزرگ انجام دادند. طبق مطالعه آن‌ها یک مطابقت نسبتاً خوب بین نتایج تئوری و آزمایشگاهی به دست آمد. معادله تجربی به صورت زیر ارائه شد.

$$K_s = 1 + \left(1.15 + \frac{214.27}{f'_c} \right) \frac{f_r}{f'_c} \quad (6)$$

که f_r از معادله زیر محاسبه می‌گردد.

$$f_r = \frac{A_{sh} f_{yh}}{sD} \quad (7)$$

که D عرض مقطع ستون می‌باشد. Razvi و Saatcioglu در سال ۱۹۹۹ [۶] در مطالعه خود نشان دادند که فشار جانبی غیرفعال تولید شده به وسیله بتن منبسط شده و میلگردهای عرضی در ستون‌های مربعی و مستطیلی همیشه یکنواخت نمی‌باشد. بنابراین مدل محصورکننده پیشنهاد شده که بر اساس محاسبه فشار یکنواخت معادل داده شده که اثراتی مشابه با فشار محصورکننده غیر یکنواخت که برای ستون با آرایش مختلف آرماتورها توسعه داده شده در شکل ۱ نشان داده شده است. معادل ارائه شده مطابق زیر می‌باشد.

$$K_s = 1 + \frac{6.7}{f'_c} (f_{1e})^{-0.17} f_{1e} \quad (8)$$

در معادله ۸ فشار یکنواخت معادل، f_{1e} می‌تواند از رابطه زیر محاسبه شود.

$$f_{1e} = k_2 f_1 = k_2 \frac{\sum A_{sh} f_{yh} \sin \alpha}{sb_c} \quad (9)$$

۲- روابط موجود برای ضریب محصورشدگی جانبی

یک رابطه شناخته شده از Richart و همکاران [۱۷] می‌تواند برای بیان مقاومت فشاری بتن محصور شده مورد استفاده قرار گیرد.

$$f'_{cc} = f'_{co} + k_1 f'_l \quad \text{or} \quad K_s = \frac{f'_{cc}}{f'_{co}} = 1 + \frac{k_1 f'_l}{f'_{co}} \quad (1)$$

که f'_l تنش محصورشدگی جانبی مؤثر (مطابق شکل ۱)، f'_{cc} و f'_{co} به ترتیب مقاومت فشاری بتن محصور شده و محصور نشده می‌باشند و K_s ضریب محصورشدگی جانبی می‌باشد. چندین مدل پیش‌بینی کننده مهم و دقیق بر اساس این رویکرد برای بتن محصور شده با ژاکت‌های کامپوزیتی FRP وجود دارند که مهمترین آن‌ها به شرح زیر می‌باشند.

Park و Kent در سال ۱۹۷۱ [۲] یک رابطه تنش-کرنش اصلاح شده برای بتن محصور شده و یک رابطه برای محصورشدگی غیرفعال کنترل شده به وسیله K_s پیشنهاد کردند. در این رابطه‌ها محل میلگردهای طولی و چیدمان میلگردهای عرضی در نظر گرفته نشد. مطالعه تجربی ارائه شده توسط آن‌ها در ادامه آمده است.

$$K_s = 1 + \frac{\rho_s f_{yh}}{f'_c} \quad (2)$$

در این مطالعه، ρ_s (نسبت حجمی خاموت‌ها) می‌تواند از رابطه زیر محاسبه شوند.

$$\rho_s = \frac{A_{sh} l_s}{sb_c d_c} \quad (3)$$

که b_c و d_c به ترتیب عرض و عمق هسته محصور شده می‌باشند که از لبه بیرونی خاموت‌ها اندازه‌گیری می‌شوند و S مرکز به مرکز فاصله خاموت‌ها می‌باشد. l_s طول نهایی میلگردهای عرضی، A_{sh} مساحت میلگرد عرضی، f_{yh} مقاومت جاری شدگی میلگردهای عرضی و f'_c مقاومت فشاری سیلندر بتنی می‌باشند.

Sheikh و Uzumeri در سال ۱۹۸۲ [۴] یک مطالعه آزمایشگاهی در مورد رابطه تنش-کرنش و محصورشدگی انجام دادند. در مطالعه آن‌ها پارامتر K_s به وسیله افزایش در مقاومت فشاری در اثر محصورشدگی حاصل از میلگردهای عرضی اثر داده شد. علاوه بر این، آن‌ها اثر میلگردهای عرضی را به صورت نسبت حجمی در نظر گرفتند. از یک تجزیه و تحلیل رگرسیون، K_s به صورت زیر ارایه شد.


بدون لزوم ایجاد یک مدل یک از سیستم بیولوژیکی واقعی استفاده شوند.

یک نورون بیولوژیکی دارای بخش‌های عمده‌ای است که برای درک یک نورون مصنوعی مورد توجه خاص هستند و عبارتند از: دندریت‌ها، بدنه سلولی، آکسون و سیناپس. یک نورون محاسباتی دارای ورودی، وزن متغیر، سلول‌های عصبی و خروجی است. دندریت‌ها با خطوط ورودی نشان داده می‌شوند. هر نورون مصنوعی دارای یک خط خروجی است که نشان دهنده آکسون متعلق به نورون است. ارتباط بین شبکه عصبی بیولوژیکی با شبکه عصبی محاسباتی در جدول ۱ آورده شده است. در نورون‌های محاسباتی، تابع خالص تعیین می‌کند که چگونه ورودی‌های شبکه $\{y_j; 1 \leq j \leq N\}$ درون نورون ترکیب می‌شوند. در شکل ۲، یک ترکیب خطی وزن دار آورده شده است [۲۱]:

$$u = \sum_{j=1}^n w_j y_j + \theta \quad (11)$$

جدول ۱- ارتباط بین مولفه‌های شبکه عصبی مصنوعی و بیولوژیکی

شبکه عصبی مصنوعی	شبکه عصبی بیولوژیکی
Neuron	Soma
Input	Dendrite
Output	Axon
Weight	Synapse




شکل ۲- شماتیکی از نورون محاسباتی

که در آن $\{w_j; 1 \leq j \leq N\}$ پارامترهایی هستند که به عنوان وزن‌های سیناپسی شناخته می‌شوند. مقدار θ به عنوان bias نامیده می‌شود و برای مدل‌سازی آستانه استفاده می‌شود.

از انواع شبکه‌های قابل استفاده جهت پیش‌بینی، می‌توان به شبکه‌های انتشار برگشتی، پس‌انتشار، دلتا و ... اشاره کرد که در ادامه برای مدل‌سازی از شبکه پس‌انتشار برگشتی استفاده شده

که f_1 میانگین فشار جانبی، α ، زاویه بین میلگرد عرضی و b_c و ضریب k_2 برای کاهش فشار میانگین تعریف شده است از رابطه زیر به دست می‌آید.

$$k_2 = 0.26 \sqrt{\left(\frac{b_c}{s}\right) \left(\frac{b_c}{c_i}\right) \left(\frac{1}{f_1}\right)} \leq 1 \quad (10)$$



شکل ۱- مکانیزم محصورشدگی برای بتن محصورشده با FRP و فولاد عرضی [۱۰]

نادرپور و همکاران در سال ۲۰۱۹ [۱۹] با استفاده از روش‌های محاسبات نرم به پیش‌بینی مقاومت فشاری ستون‌های دایره‌ای تقویت شده با الیاف FRP پرداختند. ویژگی مطالعه آن‌ها این بود که تأثیر همزمان FRP، میلگردهای طولی همچنین خاموت‌ها بر مقاومت فشاری دیده شده بود.

۳- شبکه‌های عصبی مصنوعی

Pitts و McCulloch در دهه ۱۹۴۳ [۲۰] نورون‌های ساده شده را معرفی کردند و پس از آن استفاده از شبکه‌های عصبی روند افزایشی را نشان داد. این نورون‌ها به عنوان مدلی از نورون‌های بیولوژیکی و به عنوان مؤلفه‌های مفهومی برای مدارهایی است که می‌توانند وظایف محاسباتی را انجام دهند، ارائه شدند. یک شبکه عصبی شامل یک گروه به هم پیوسته از نورون‌های مصنوعی و پردازش اطلاعات با استفاده از یک رویکرد مرتبط به محاسبات است. شبکه‌های عصبی مصنوعی ممکن است برای درک شبکه‌های عصبی بیولوژیکی یا برای حل مشکلات هوش مصنوعی

است. شبکه‌های پس انتشار برگشتی یکی از معروف‌ترین، مؤثرترین و آسان‌ترین مدل‌ها برای پیش‌بینی و پیش‌گویی چندین هدف در میان شبکه‌های پیچیده و چند لایه هستند [۲۲، ۹-۲۴].

۴- مدل‌سازی

برای آموزش شبکه عصبی از مشخصات نمونه‌های آزمایش شده و گزارش شده در مقالات معتبر در مورد رفتار ستون‌های بتن آرمه محصور شده با FRP استفاده شده است. این شبکه طبق مطالعات انجام گرفته، در سال ۲۰۰۳، Lam و Teng با ۱۲ نمونه [۲۵]، Harajli و همکاران در سال ۲۰۰۶ با ۱۸ نمونه [۲۶]، Shehata و همکاران در سال ۲۰۰۲ با ۸ نمونه [۲۷]، Turgay در سال ۲۰۰۷ با ۱۳ نمونه [۲۸]، Chaallal و همکاران در سال ۲۰۰۳ با ۲۴ نمونه [۲۹]، Demers و Neale در سال ۱۹۹۴ با ۳ نمونه [۳۰]، Hosotani و همکاران در سال ۲۰۰۱ با ۴ نمونه [۳۱]، Feng و همکاران در سال ۱۹۹۷ با ۳ نمونه [۳۲]، Wang و Parvin و همکاران در سال ۲۰۰۱ با ۲۴ نمونه [۳۳]،

$$b_{scaled} = \left[(0.9 - 0.1) \times \frac{(b - b_{min})}{(b_{max} - b_{min})} \right] + 0.1 \quad (12)$$

که b برابر با مقدار طول مقطع ستون آزمایش شده، b_{max} و b_{min} نیز به ترتیب برابر با حداقل و حداکثر عرض مقطع ستون و مطابق با جدول ۳ می‌باشند.

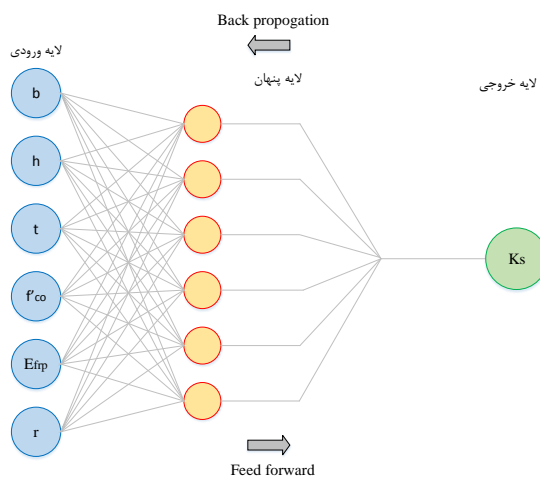
جدول ۲- پارامترهای موثر در رفتار ستون‌های بتن آرمه محصور شده با FRP

پارامتر	توضیح
$b (mm)$	عرض مقطع ستون
$h (mm)$	طول مقطع ستون
$t (mm)$	ضخامت دورپیچ FRP
$f'_{co} (MPa)$	مقاومت فشاری بتن
$E_{FRP} (MPa)$	مدول الاستیسیته FRP
$r (mm)$	شعاع گردش‌دهی گوشه‌های مقطع ستون

جدول ۳- مشخصات آماری داده‌های ورودی و خروجی

گره ورودی	b (mm)	h (mm)	t (mm)	f'_{co} (MPa)	E_{FRP} (MPa)	r (mm)	K_s
مینیمم	۲۰	۱۰۸	۰	۱۰/۸	۱۰۵۰۰	۵	۱
ماکزیمم	۴۵۷	۴۵۷	۳	۵۵	۴۳۹۰۰۰	۵۰	۴/۶
میانگین	۱۵۷	۱۸۰	۱	۲۹	۱۹۴۵۸۸	۲۳	۱/۷۱
انحراف استاندارد	۶۹/۵۹	۴۹/۴۷	۰/۴۵	۱۱/۶	۷۹۷۸۲/۳۸	۱۰/۱	۰/۶۸
ضریب تغییرات	۰/۴۴	۰/۲۷	۰/۸۵	۰/۴	۰/۴۱	۰/۴۴	۰/۴

نتایج آزمایشگاهی است. مقادیر پایین به معنای عملکرد بهتر شبکه است (صفر یعنی بدون خطا). مقادیر رگرسیون (مقادیر R) ارتباط بین مقادیر پیش‌بینی شده توسط شبکه و نتایج آزمایشگاهی را اندازه‌گیری می‌کنند. مقدار $R=1$ به معنای یک رابطه نزدیک و در مقابل $R=0$ به معنی یک رابطه تصادفی است. این دو معیار (مقادیر R و MSE) به عنوان پایه‌ای برای انتخاب شبکه ایده‌آل در نظر گرفته شدند. به منظور دستیابی به یک شبکه مناسب، شبکه‌هایی با تعداد نوروں‌های مخفی بین ۴ تا ۲۰ عدد شکل گرفت.




شکل ۳- نمونه شماتیک شبکه عصبی

مقادیر رگرسیون شبکه‌ها با تعداد مختلف نوروں‌های مخفی در شکل ۴ ارائه شده است.

در مدل‌سازی شبکه ANN از شبکه پس انتشار برگشتی با یک لایه پنهان استفاده شده است در حالی که تابع انتقال \tan -sigmoid می‌باشد. این نوع از شبکه‌های عصبی در ارتباط با کاربردهای تخمین توابع از کارایی مناسبی برخوردار هستند. قبل از آموزش نرمال‌سازی همه داده‌ها با استفاده از رابطه ۱۲ انجام گرفت. به منظور مقیاس داده‌ها از ۰/۱ تا ۰/۹ مینیمم و ماکزیمم مقادیر برای استفاده رابطه خطی بین داده‌ها در نظر گرفته شد. الگوریتم Levenberg-Marquardt به طور تصادفی بردارهای ورودی و بردارهای هدف را به سه مجموعه شامل آموزش، اعتبار سنجی و آزمایش تقسیم می‌کند.

در این مطالعه، به عنوان یک مرحله مقدماتی، برخی از مجموعه داده‌ها با درصد نسبی متفاوت مورد بررسی قرار گرفتند که در آن داده‌های آموزش از ۵۰٪ تا ۹۰٪ متفاوت است و به ترتیب مقادیر ۶۰٪، ۲۰٪ و ۲۰٪ برای آموزش، اعتبار سنجی و آزمایش برای به دست آوردن کارآمدترین توزیع مجموعه داده‌ها انتخاب شد. معماری شبکه مورد استفاده در این مطالعه $6-n-1$ نامیده شده است که در آن رقم اول تعداد گره‌های ورودی، n تعداد گره‌های پنهان و رقم سوم تعداد گره‌های خروجی است که در شکل ۳ نشان داده شده است.


معیار توقف آموزش شبکه‌ها، میانگین مربعات خطا (MSE) است که میانگین مربعات خطا بین مقادیر پیش‌بینی شده توسط شبکه و




شکل ۴- مقادیر رگرسیون در تعداد نوروں‌های مخفی مختلف

در شکل ۶، میانگین مربع خطاها (MSE) در اپوک‌های مختلف یادگیری آورده شده است که با توجه به معیار همگرایی در نظر گرفته شده، مشاهده می‌شود یادگیری در اپوک ۱۲ به خوبی انجام شده است. شکل ۷، روند تغییرات شبکه طی اپوک‌های مختلف را نشان می‌دهد. در شکل ۸، مقادیر R به ازای چهار حالت آموزش، صحت سنجی، آزمایش و کل داده‌ها به دست آمده است. هر چه تمرکز این نقاط بر روی نیمساز ربع اول بیشتر باشد، نشانگر دقت بالاتر آن می‌باشد.


مقادیر MSE برای نوروں‌های پنهان مختلف نیز در شکل ۵ آمده است. برای انتخاب شبکه بهینه هرچه مقدار میانگین مربعات خطا (MSE) کمتر باشد و مقادیر رگرسیون به عدد یک نزدیکتر باشد آن شبکه عملکرد بهتری در پیش بینی نتایج دارد. به این ترتیب طبق شکل های ۴ و ۵ تعداد نوروں های مخفی برابر با ۱۹ دارای کمترین مقدار میانگین مربعات خطا و مقادیر رگرسیون نزدیک به یک می‌باشند، در نتیجه این شبکه به عنوان شبکه بهینه انتخاب می‌شود.



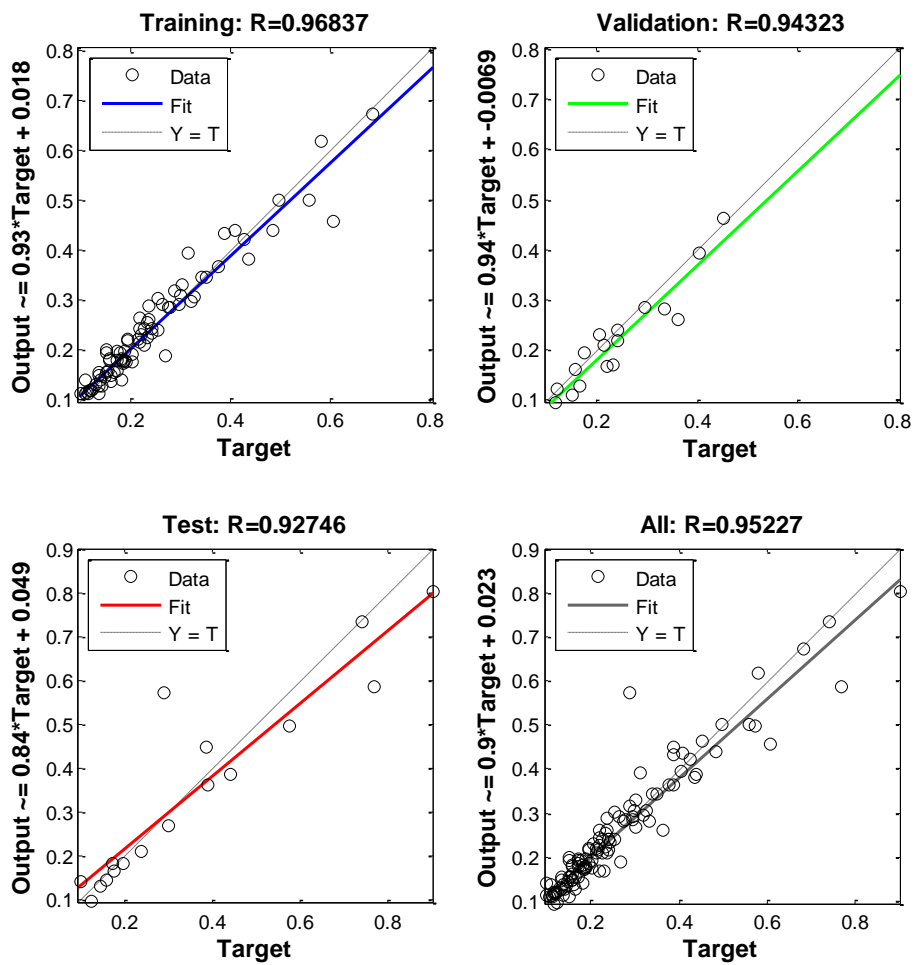
شکل ۵- مقدار میانگین مربعات خطا در تعداد نوروں های مخفی مختلف



شکل ۶- نمودار میانگین مربعات خطا در فرآیند آموزش شبکه

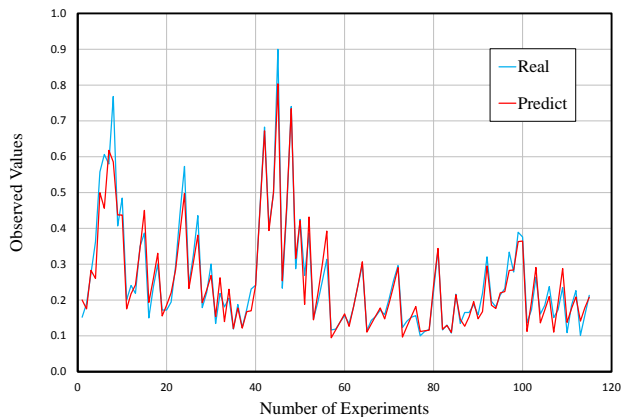


شکل ۷- روند تغییرات شبکه در مراحل آموزش شبکه

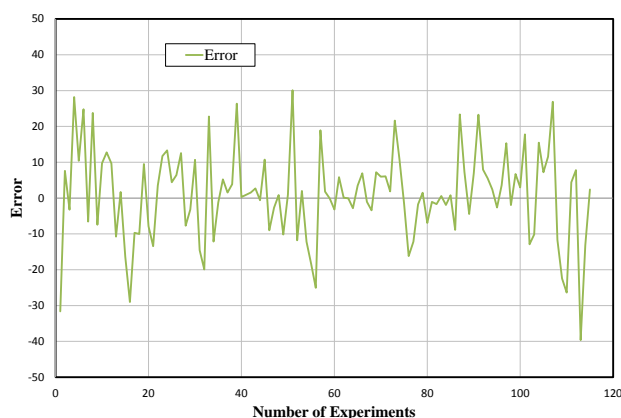


شکل ۸- نمودار رگرسیون شبکه پس از آموزش

با مشاهده مقادیر حداکثر و حداقل K_s در نمونه‌های آزمایشگاهی که در جدول ۳ آمده است و مقایسه آن‌ها با پیش‌بینی‌های شبکه عددی می‌توان نتیجه گرفت که مقادیر حداکثر و حداقل K_s در نمونه‌های آزمایشگاهی در پیش‌بینی‌های شبکه عددی پیشنهادی حداکثر و حداقل نمی‌باشند.



شکل ۹- مقایسه نتایج آزمایشگاهی و شبکه عصبی



شکل ۱۰- درصد خطای حاصل از پیش‌بینی شبکه عصبی در هر یک از نمونه‌های آزمایشگاهی

به‌منظور درک بهتر از عملکرد شبکه بهینه انتخاب شده در پیش‌بینی نتایج، مقدار واقعی نتیجه آزمایشگاهی در هر نمونه با مقدار پیش‌بینی شده حاصل از شبکه در شکل ۹ ترسیم شده است و میزان خطای هر نمونه نیز بر حسب درصد در شکل ۱۰ نشان داده شده است. همچنین به‌منظور بررسی عملکرد این مدل و صحت آن در پیش‌بینی نتایج آزمایشگاهی از معیارهای عملکرد مختلفی مانند میانگین درصد خطای مطلق (MAPE)، کسر مطلق واریانس (R^2) و میانگین خطای مطلق نرمال‌شده (NMAE) استفاده شد که مقادیر آن در جدول ۴ و فرمول‌های مربوطه در روابط (۱۳) تا (۱۵) آمده است. همان‌گونه که در جدول ۴ مشاهده می‌شود مقدار حداکثر خطا در این شبکه ۳۹/۶۳ درصد و میانگین درصد خطای مطلق، ۹/۶۹ درصد می‌باشد همچنین مقدار R^2 نیز برابر با ۰/۹۸ می‌باشد که هر چه به یک نزدیکتر باشد نشان از دقت بالای مدل دارد در مورد میانگین خطای مطلق نرمال‌شده نیز هر چه عدد کوچکتر و نزدیک به صفر باشد نشان از دقت بالای مدل دارد در نتیجه این اعداد نشان از عملکرد خوب این شبکه در پیش‌بینی نتایج را نشان می‌دهند.

$$R^2 = 1 - \frac{\sum_{i=1}^N (M_{u(actual)} - M_{u(model)})^2}{\sum_{i=1}^N (M_{u(actual)} - \overline{M_{u(actual)}})^2} \quad (13)$$

$$MAPE = \frac{1}{M} \left[\frac{\sum_{i=1}^M |M_{u(model)} - M_{u(actual)}|}{\sum_{i=1}^M M_{u(actual)}} \times 100 \right] \quad (14)$$

$$NMAE = \frac{\frac{1}{n} \sum_{i=1}^n |M_{u(model)} - M_{u(actual)}|}{M_{u(model)} - M_{u(actual)}} \quad (15)$$

جدول ۴- مشخصات آماری داده‌های ورودی و خروجی

مدل	حداقل خطا	حداکثر خطا	انحراف استاندارد خطاها	ضریب تغییرات خطاها	R^2	MAPE	NMAE
ANN	۰/۰۵۸	۳۹/۶۳	۸/۴۹	۰/۸۷	۰/۹۸	۹/۶۹	۸/۵ e-۴


شده در ماتریس استاتیک وزن‌ها برای تعیین تأثیر نسبی هر یک از داده‌های ورودی بر داده‌های خروجی شبکه می‌باشد. معادلات مختلفی مبتنی بر مقادیر وزن‌ها ارائه شده است. یکی از کاربردی‌ترین معادلات، معادله Milne [۳۷] می‌باشد. این رابطه با

۵- آنالیز حساسیت پارامترهای ورودی

در طول سال‌های گذشته روش‌های مختلفی برای تحلیل اثر متغیرهای ورودی بر خروجی شبکه عصبی پیش‌خورنده پیشنهاد شده‌اند. آنالیز بر اساس مقادیر وزن، منحصر بر مبنای مقادیر ذخیره

می‌آید. $iw\{1,1\}$ وزن پارامترهای ورودی و $iw\{2,1\}$ وزن خروجی می‌باشد. همان‌طور که از شکل ۱۱ مشاهده می‌شود، نتایج آنالیز حساسیت بیانگر این است که مقاومت فشاری بتن و طول مقطع ستون به ترتیب با درصد تأثیر ۲۰/۰۵ و ۱۷/۶۴ بیشترین تأثیر را روی ضریب محصورکنندگی جانبی داشته‌اند در صورتی که طول مقطع ستون و مدول الاستیسیته FRP کمترین تأثیر را روی خروجی داشته‌اند.

پارامترهای مربوط به نمونه‌های دارای بیشترین و کمترین مقدار خطا در جدول ۵ آورده شده است. با توجه به آنالیز حساسیت که پارامترهای f'_{co} ، h و t دارای بیشترین تأثیر روی پارامتر خروجی هستند و همچنین با توجه به جدول ۵ می‌توان نتیجه گرفت که افزایش یا کاهش همزمان این سه پارامتر بیشترین تأثیر را بر روی دقت پیش‌بینی شبکه عصبی خواهد داشت.



شکل ۱۱- درصد تأثیر پارامترهای ورودی بر روی پارامتر خروجی

جدول ۵- پارامترهای مربوط به نمونه‌های دارای بیشترین و کمترین خطا

	b (mm)	h (mm)	r (mm)	t (mm)	E frp (MPa)	f'co (MPa)	Ks	درصد خطا
نمونه دارای حداکثر خطا	۲۰۰	۲۰۰	۳۰	۰/۴۱۴	۶۵۰۰۰	۴۰	۱/۰۱۰	۳۹/۶۳
نمونه دارای حداقل خطا	۱۰۸	۱۶۵	۲۵	۰/۳۶۰	۲۳۰۰۰۰	۲۵/۱	۱/۶۴۰	۰/۰۵۸

تعداد ۱۱۴ داده آزمایشگاهی معتبر در نظر گرفته شد. تعداد ۶ پارامتر شامل عرض مقطع ستون، طول مقطع ستون، ضخامت دورپیچ FRP، مقاومت فشاری بتن، مدول الاستیسیته FRP و

محاسبه حاصل ضرب وزن‌ها w_{ji} (وزن اتصال بین نورون ورودی i و نورون مخفی j) و w_{oj} (وزن اتصال بین نورون مخفی j و نورون خروجی o) برای هر یک از نورون‌های مخفی شبکه به صورت مجموع حاصلضرب‌های محاسبه شده بدست می‌آید.

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

در رابطه (۱۶)، $\sum_{l=1}^{n_{inputs}} |w_{jl}|$ مجموع وزن‌های اتصال بین نورون‌های ورودی N و نورون‌های مخفی L درصد تأثیر متغیر ورودی x_i بر متغیر خروجی y_k می‌باشد. با استفاده از این روش نسبت‌های صحیحی برای هر دو وزن مثبت و منفی بدست

۶- نتیجه‌گیری

در این مطالعه به منظور پیش‌بینی ضریب محصورشدگی جانبی ستون‌های تقویت شده با FRP به وسیله شبکه عصبی مصنوعی

- index. Compos Struct 2019;209:112–28. doi:10.1016/j.compstruct.2018.10.088.
- [2] Kent DC, Park R. Flexural members with confined concrete. J Struct Div 1971.
- [3] Sheikh SA, Uzumeri SM. Strength and ductility of tied concrete columns. J Struct Div 1980;106.
- [4] Sheikh SA, Uzumeri SM. Analytical model for concrete confinement in tied columns. J Struct Div 1982;108:2703–22.
- [5] Saatcioglu M, Razvi SR. Strength and Ductility of Confined Concrete. J Struct Eng 1992;118:1590–607. doi:10.1061/(ASCE)0733-9445(1992)118:6(1590).
- [6] Razvi S, Saatcioglu M. Confinement Model for High-Strength Concrete. J Struct Eng 1999;125:281–9. doi:10.1061/(ASCE)0733-9445(1999)125:3(281).
- [7] Chung H-S, Yang K-H, Lee Y-H, Eun H-C. Stress-strain curve of laterally confined concrete. Eng Struct 2002;24:1153–63. doi:10.1016/S0141-0296(02)00049-4.
- [8] Alacalı SN, Doran B, Akbas B. Predicting Lateral Confinement Coefficient for R/C Rectangular Columns By a Neural Network Model. EAEE, First Eur Conf Earthq Eng Seismol, 2006.
- [9] Naderpour H, Kheyroddin A, Amiri GG. Prediction of FRP-confined compressive strength of concrete using artificial neural networks. Compos Struct 2010;92:2817–29. doi:10.1016/j.compstruct.2010.04.008.
- [10] Alacalı SN, Akbaş B, Doran B. Prediction of lateral confinement coefficient in reinforced concrete columns using neural network simulation. Appl Soft Comput 2011;11:2645–55. doi:10.1016/j.asoc.2010.10.013.
- [11] Naeef M, Bali M, Naeef MR, Amiri JV. Prediction of lateral confinement coefficient in reinforced concrete columns using M5' machine learning method. KSCE J Civ Eng 2013;17:1714–9. doi:10.1007/s12205-013-0214-3.
- [12] Doran B, Yetilmezsoy K, Murtazaoglu S. Application of fuzzy logic approach in predicting the lateral confinement coefficient for RC columns wrapped with CFRP. Eng Struct 2015;88:74–91. doi:10.1016/j.engstruct.2015.01.039.
- [13] Naderpour H, Alavi SA. A proposed model to estimate shear contribution of FRP in strengthened RC beams in terms of Adaptive Neuro-Fuzzy Inference System. Compos Struct 2017;170:215–27. doi:10.1016/j.compstruct.2017.03.028.
- [14] Fakharian P, Naderpour H, Haddad A, Rafiean AH, Eidgahee DR. A proposed model for compressive strength prediction of FRP-confined rectangular column in terms of Genetic expression Programming (GEP). Concr Res 2018;11:5–18.

شعاع گردشگری گوشه های مقطع ستون به عنوان پارامترهای ورودی در نظر گرفته شدند و ضریب محصورشدگی جانبی ستون نیز به عنوان پارامتر خروجی در نظر گرفته شد. شبکه عصبی پیشنهادی در این مقاله از نوع انتشار برگشتی (BPNN) می باشد که تابع انتقال آن در لایه پنهان از نوع تانژانت سیگموئید و در لایه خروجی از نوع خطی ساده است. در فرایند مدل سازی، شبکه های بهینه محسوب می شود که هم زمان با داشتن بالاترین رگرسیون، کمترین میانگین مربعات خطا را نیز داشته باشد. بنابراین مهم ترین نکته در فرایند مدل سازی شبکه های عصبی مصنوعی، انتخاب شبکه با تعداد نورون کمتر و رگرسیون بیشتر است. پیش بینی های به دست آمده از شبکه با میانگین درصد خطای مطلق برابر با ۹/۶۹ و کسر مطلق واریانس (R^2) برابر با ۰/۹۸ دقت بالایی را در پیش بینی نتایج از خود نشان داد. همچنین آنالیز حساسیت با استفاده از روش میلن با وزن های تنظیم شده و حاصل از شبکه عصبی ایده آل انجام شد و نشان داد که پارامترهای مقاومت فشاری بتن f'_{co} و طول مقطع ستون h به ترتیب با درصد تأثیر ۲۰/۰۵ و ۱۷/۶۴ بیشترین تأثیر را روی خروجی حاصل از شبکه پیشنهادی داشته اند. شبکه عصبی بر اساس پارامترهای ورودی و خروجی این ۱۱۴ نمونه، یک ارتباط بین آن ها شکل داده (آموزش و یادگیری شبکه عصبی) و بر اساس همین ارتباط، مقادیر خروجی جدیدی را با دقت بسیار بالا برای نمونه ها پیش بینی می کند. به عبارتی شبکه عصبی دانش ارتباط بین چند مجموعه داده را از طریق آموزش فراگرفته و برای استفاده در موارد مشابه ذخیره می کند. حال اگر بخواهیم مقدار K_s را برای یک نمونه که جزو این ۱۱۴ نمونه نبوده ولی مقادیر پارامترهای ورودی آن در بازه مینیمم و ماکزیمم موجود در این مطالعه باشد، دیگر نیازی به صرف هزینه و زمان زیاد برای ساخت نمونه آزمایشگاهی نمی باشد و شبکه عصبی قادر است با استفاده از مدل بهینه خود مقدار K_s برای نمونه جدید را با دقت بسیار بالایی پیش بینی نماید. لذا با استفاده از این ابزار توانمند صرفه جویی قابل توجهی در هزینه و زمان خواهد شد.

۷- مراجع

- [1] Haji M, Naderpour H, Kheyroddin A. Experimental study on influence of proposed FRP-strengthening techniques on RC circular short columns considering different types of damage

- Struct J 2006;103:672–82.
- [27] Shehata IAEM, Carneiro LA V., Shehata LCD. Strength of short concrete columns confined with CFRP sheets. *Mater Struct* 2002;35:50–8. doi:10.1007/BF02482090.
- [28] Turgay T. Behaviour of RC columns confined with FRP. Yildiz Technical University, 2007.
- [29] Chaallal O, Hassan M, Shahawy M. Confinement model for axially loaded short rectangular columns strengthened with fiber-reinforced polymer wrapping. *Struct J* 2003;100:215–21.
- [30] Demers M, Neale KW. Strengthening of concrete columns with unidirectional composite sheets. *Proc Fourth Int Conf Short Medium Span Bridg, Canadian Society for Civil Engineering Montreal, Canada; 1994, p. 895–905.*
- [31] Pessiki S, Harries KA, Kestner JT, Sause R, Ricles JM. Axial Behavior of Reinforced Concrete Columns Confined with FRP Jackets. *J Compos Constr* 2001;5:237–45. doi:10.1061/(ASCE)1090-0268(2001)5:4(237).
- [32] Hosotani M, Kawashima K, Hoshikuma J. A study on confinement effect of concrete cylinders by carbon fiber sheets. *Non-Metallic Reinf Concr Struct* 1997;1:209–16.
- [33] Feng P, Lu XZ, Ye LP. Experimental research and finite element analysis of square concrete columns confined by FRP sheets under uniaxial compression. *Proc 17th Australas Conf Mech Struct Mater Gold Coast, Aust, 2002, p. 71–6.*
- [34] Parvin A, Wang W. Behavior of FRP Jacketed Concrete Columns under Eccentric Loading. *J Compos Constr* 2001;5:146–52. doi:10.1061/(ASCE)1090-0268(2001)5:3(146).
- [35] Al-Salloum YA. Influence of edge sharpness on the strength of square concrete columns confined with FRP composite laminates. *Compos Part B Eng* 2007;38:640–50. doi:10.1016/j.compositesb.2006.06.019.
- [36] Rousakis TC, Karabinis AI, Kiousis PD. FRP-confined concrete members: Axial compression experiments and plasticity modelling. *Eng Struct* 2007;29:1343–53. doi:10.1016/j.engstruct.2006.08.006.
- [37] Milne L. Feature selection using neural networks with contribution measures. *Aust Conf Artif Intell AI'95, Citeseer; 1995, p. 1–8.*
- doi:10.22124/JCR.2018.7162.1191.
- [15] Rezazadeh Eidgahee D, Rafiean AH, Haddad A. A Novel Formulation for the Compressive Strength of IBP-Based Geopolymer Stabilized Clayey Soils Using ANN and GMDH-NN Approaches. *Iran J Sci Technol Trans Civ Eng* 2019. doi:10.1007/s40996-019-00263-1.
- [16] Naderpour H, Rezazadeh Eidgahee D, Fakharian P, Rafiean AH, Kalantari SM. A new proposed approach for moment capacity estimation of ferrocement members using Group Method of Data Handling. *Eng Sci Technol an Int J* 2019. doi:10.1016/j.jestch.2019.05.013.
- [17] Richart F, Brandtzaeg A, Brown RL. A Study of the Failure of Concrete under Combined Compressive Stresses. *Univ Illinois Bull* 1928;26, *Bullet*:1–104.
- [18] Fafitis A, Shah SP. Predictions of ultimate behavior of confined columns subjected to large deformations. *J Am Concr Inst* 1985;82:423–33.
- [19] Naderpour H, Nagai K, Fakharian P, Haji M. Innovative models for prediction of compressive strength of FRP-confined circular reinforced concrete columns using soft computing methods. *Compos Struct* 2019;215:69–84. doi:10.1016/j.compstruct.2019.02.048.
- [20] McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. *Bull Math Biophys* 1943;5:115–33. doi:10.1007/BF02478259.
- [21] Ahmadi M, Naderpour H, Kheyroddin A. Utilization of artificial neural networks to prediction of the capacity of CCFT short columns subject to short term axial load. *Arch Civ Mech Eng* 2014;14:510–7. doi:10.1016/j.acme.2014.01.006.
- [22] Rezazadeh Eidgahee D, Fasihi F, Naderpour H. Optimized Artificial Neural Network for Analyzing Soil-Waste Rubber Shred Mixtures. *Sharif J Civ Eng* 2015;31.2:105–11.
- [23] Naderpour H, Fakharian P, Mostakhdemin Hosseini F. Prediction of Behavior of FRP-Confined Circular Reinforced Concrete Columns using Artificial Neural Network. *8th Natl Conf Concr, DOI: 10.13140/RG.2.2.11714.58568; 2016.*
- [24] Naderpour H, Fakharian P. Predicting the Torsional Strength of Reinforced Concrete Beams Strengthened with FRP Sheets in terms of Artificial Neural Networks. *J Struct Constr Eng* 2017;5:20–35. doi:10.22065/jsce.2017.70668.1023.
- [25] LAM L, TENG JG. Design-Oriented Stress-Strain Model for FRP-Confined Concrete in Rectangular Columns. *J Reinf Plast Compos* 2003;22:1149–86. doi:10.1177/0731684403035429.
- [26] MH H, E H, K. S. Stress-strain model for fiber-reinforced polymer jacketed concrete columns. *ACI*

Prediction of the Lateral Confinement Coefficient of The concrete Columns Confined by FRP using the Artificial Neural Network

Ehsan Darvishan *

Assistant Professor, Department of Civil Engineering, College of Engineering, Roudehen Branch, Islamic Azad University, Roudehen, Iran.

Abstract

Confining columns is one of the most commonly used methods of retrofitting structures. The confinement of concrete columns by FRP sheets is considered as one of the modern methods of retrofitting structures due to their properties. Tests conducted on a rounded-corner column by applying axial compression indicate that its behavior improves as well as the cross-section of column approaches the circular section. However, the behavior of columns confined with FRP or having transverse reinforcement has been studied by many researchers, yet study on wrapping columns by FRP when the transverse reinforcement does not satisfy the required confinement for the column has not been investigated by researchers. In this study, different models of the lateral confinement coefficient are presented. Also, by considering valid test results and the influence of different parameters such as length and width of column section, thickness of FRP sheet, the compressive strength of concrete, elasticity modulus of FRP and, radius of rounded-corner concrete a new model is presented using the Neural network in which the lateral confinement coefficient of confined columns can be predicted with high accuracy. Finally, the sensitivity analysis is carried out to evaluate the effect of each input parameter on the output parameter, and the results are presented.

Keywords: Retrofitting, Reinforced Concrete Column, FRP, Artificial Neural Network, Confinement.

* Corresponding Author: darvishan@riau.ac.ir