پیش‌بینی مقاومت نهایی محوری ستون‌های دایره‌ای فولادی پرشده با بتن توسط شبکه‌ی عصبی مصنوعی

محمدحسین یعقوبی[۱]، بهروز کشته‌گر[۲]، حسینعلی رهدار[۳]

۱- دانشجوی کارشناسی ارشد مهندسی عمران-سازه، دانشگاه زابل

۲- استادیار دانشکده‌ی مهندسی عمران، دانشگاه زابل

۳- استادیار دانشکده‌ی مهندسی عمران، دانشگاه زابل

Email: hossein99yaghoubi@gmail.com

چکیده

ستون‌های فولادی پرشده با بتن ویژگی‌هایی نظیر کاهش هزینه‌های ساخت، شکل‌پذیری بیشتر و مقاومت افزون بهتری نسبت به ستون‌های بتن آرمه دارد. از اینرو، کاربرد این نوع ستون‌ها در سازه‌های مهندسی از قبیل پل‌ها و ساختمان‌های بلند مورد توجه قرار گرفته است. عمدتاً، مدل‌های تجربی و آیین‌نامه‌ای از تعداد محدودی نمونه‌ی آزمایشگاهی جهت پیش‌بینی حداکثر ظرفیت این مقاطع استفاده نموده‌اند که از تجزیه وتحلیل رگرسیون حاصل شده‌اند. لذا، کاربرد مدل‌های پیش‌بینی در محدوده‌ی گسترده‌تر از دقت قابل قبولی برخوردار نمی‌باشد. در این تحقیق، براساس نتایج آزمایشگاهی یک مدل پیش‌بینی مقاومت نهایی محوری براساس شبکه‌ی عصبی مصنوعی توسعه داده شده است. نتایج حاصل از تخمین مدل شبکه‌ی عصبی بر اساس ۱۱۶۸ نمونه‌ی آزمایشگاهی، به کمک چندین آماره‌ی خطا با دو مدل تجربی و دو آیین‌نامه‌ی طراحی AISC و EC4 مقایسه گردیده است. مدل شبکه‌ی عصبی شبه نیوتن BFGS ارائه شده موجب بهبود ریشه‌ی میانگین مربعات خطا و میانگین قدر مطلق خطا به ترتیب در حدود ۹۰ درصد و ۳۰ درصد شده است و همچنین با ضریب انطباق ۰/۹۹۳ بهترین همبستگی خطی بین داده‌های پیش‌بینی و آزمایشگاهی را نسبت به سایر مدل‌های پیش‌بینی نشان داده است. بنابراین، استفاده از شبکه‌ی عصبی مصنوعی یک ابزار ساده و کارا جهت برآورد مقاومت نهایی محوری ستون‌های دایره‌ای می‌باشد که، عملکرد بالایی از حیث صحت برآورد و تطبیق بیشتر بر داده‌های آزمایشگاهی در مقایسه با مدل‌های تجربی و آیین‌نامه‌ای نشان داده است.

کلمات کلیدی: ستون دایره‌ای فولادی پرشده با بتن، مقاومت نهایی محوری، شبکه‌ی عصبی مصنوعی، پایگاه داده‌ی آزمایشگاهی، مدلسازی

Prediction of the Axial Ultimate Strength of Circular CFST Columns Using Artificial Neural Network

M. H. Yaqoubi B. Keshtegar H. A. Rahdar

Abstract

Concrete-filled steel tube (CFST) columns have features such as reduced construction costs and more dilation and carrying capacity to reinforced concrete columns. Therefore, Concrete-filled steel tube columns have been increasingly adopted in many modern structures such as bridges and high-rise buildings due to the beneficial composite action between steel tube and concrete core. Mainly, experimental and codes models of a limited number of experimental samples have been used to predict the axial ultimate strength of these sections, which are derived from regression analysis. Therefore, the use of prediction models is not widespread in the most reasonable range. In this paper, a novel predicted model of the axial ultimate strength has been developed based on Artificial Neural Network (ANN) using a large experimental data set more 1168 sample data on CFST. The predicted results of the developed ANN model were compared with tow empirical newest models and AISC and EC4 code relations using several error statistics. The proposed Broyden-Fletcher-Goldfarb-Shanno (BFGS) algorithm improves the root-mean square error and the mean absolute error is about 90% and 30%, respectively, and also with a coefficient

of correlation of 0.993, the best correlation between predicted and experimental data is shown in comparison with other prediction models.The results indicate that the successful application of the Neural Network in the estimation of the ultimate strength of these sections has been shown to be experimental and codes models.

Key Words

Concrete-filled steel tube column, Axial ultimate strength, Artificial Neural Network, Experimental database, Modeling

۱. مقدمه

در حال حاضر استفاده از بتن و فولاد به صورت گسترده در صنعت ساخت و ساز مورد استفاده قرار گرفته است. بتن مصالحی با مقاومت فشاری بالا، قیمت مناسب و مقاومت قابل توجه در برابر آتش سوزی و فولاد مصالحی با شکل‌پذیری و مقاومت زیاد و وزن کم است. با این حال، استفاده از ستون‌های فولادی در سازه‌های بلند غیر اقتصادی می‌باشد و این مقاطع معمولاً دارای تغییر شکل‌های جانبی نسبتاً زیاد بوده و در مقابل آتش سوزی مقاومت پایینی دارند. از طرفی استفاده از ستون‌های بتنی در ساختمان‌های بلند، در طبقات اولیه فضای بیشتری را اشغال نموده و دارای وزن نسبتاً بیشتری است و به علت ترد و شکننده بودن بتن، سازه‌ی حاصل دارای شکل‌پذیری کمتری بوده و در بارهای لرزه‌ای افت مقاومت در سازه بوجود خواهد آمد [۱]. از اینرو، استفاده‌ی همزمان از این دو مصالح، یک سیستم مؤثر و کاراتر نسبت به استفاده‌ی مجزا از آن‌ها را نتیجه می‌دهد. ستون فولادی پرشده با بتن (CFST)[1] که با پر کردن یک لوله‌ی فولادی توخالی توسط بتن شکل گرفته است به علت واکنش توأم و مناسب بتن و فولاد کاربرد آن در بسیاری از سازه‌های مهندسی در حال افزایش است. این مقاطع نه تنها مزایای بسیاری در ساخت دارند بلکه، باعث بهبود قابل توجهی در خواص مکانیکی اعضای سازه‌ای در مقایسه با اعضای بتن مسلح و فولادی تنها می‌گردند [۲]. وجود فولاد در بیرونی‌ترین تارهای مقطع به صورت مؤثر سبب افزایش ممان اینرسی و مقاومت خمشی مقطع می‌گردد که نهایتاً سبب افزایش سختی مقطع می‌گردد [۳]. هسته‌ی بتنی یک مقطع ایده‌آل برای باربری ثقلی است که کمانش موضعی لوله‌ی فولادی را به تأخیر می‌اندازد و در برخی حالات باعث جلوگیری از کمانش موضعی می‌گردد [۴ و ۵]. در مقایسه با ستون‌های بتنی با انبوه میلگردهای متقاطع، لوله‌ی فولادی می‌تواند از کرمو شدن بتن جلوگیری کند. به عبارت دیگر تراکم و شلوغی میلگرد خصوصاً در نواحی اتصال حذف می‌گردد که در ملاحظات لرزه‌ای بسیار سودمند خواهد بود. همچنین لوله‌ی فولادی با محصورکردن بتن باعث افزایش مقاومت فشاری و شکل‌پذیری می‌گردد [۶]. لذا، استفاده از این نوع مقاطع به عنوان ستون‌های در معرض بارهای فشاری شدید و مناطق زلزله خیز بسیار سودمند خواهد بود. علاوه بر این، لوله‌ی فولادی نقش یک قالب ماندگار را برای بتن ایفا می‌کند و این موضوع سبب کاهش هزینه‌های ساخت می‌گردد [۷ و ۸].

امروزه ستون‌های CFST به صورت گسترده‌ای مورد استفاده قرار گرفته‌اند. اما، همچنان به لحاظ روش‌های طراحی همانند ستون‌های فولادی و بتن آرمه به این نوع مقاطع نگریسته می‌شود و عمدتاً اثر محصورشدن هسته‌ی بتنی توسط لوله‌ی فولادی در نظر گرفته نمی‌شود. یکی از ضعف‌های مدل‌های تجربی و آیین‌نامه‌ای این است که از تعداد محدودی نمونه‌ی آزمایشگاهی جهت پیش‌بینی حداکثر ظرفیت ستون‌های CFST استفاده نموده‌اند که عمدتاً، از طریق رگرسیون حاصل شده‌اند. لذا، کاربرد مدل‌های پیشنهادی در محدوده‌ی گسترده‌تر از دقت قابل قبولی برخوردار نمی‌باشد. ظرفیت باربری ستون‌های CFST متأثر از از روابط چند متغیره ناشناخته می‌باشد و داده‌های آزمایشگاهی موجود عمدتاً دارای پراکندگی می‌باشند. از طرفی، مدل‌های تجربی و آیین‌نامه‌ای محدودیت‌هایی در مقاومت فولاد و بتن و همچنین نسبت قطر به ضخامت دارند. درنتیجه مدل‌های پیش‌بینی موجود ممکن است قادر به پیش‌بینی مناسب رفتار این نوع سازه‌ها نباشند.

در این تحقیق، یک پایگاه داده‌ی گسترده جهت پیش‌بینی مقاومت نهایی محوری ستون‌های CFST با استفاده از روش هوش مصنوعی بر مبنای شبکه‌ی عصبی چند لایه استفاده گردیده است. در این روش می‌توان ارتباط غیرخطی بین مقاومت نهایی و پارامترهای ورودی ستون‌های دایره‌ای CFST ایجاد نمود. مدل غیر خطی شبکه‌ی عصبی بر مبنای ۷۰ درصد داده‌های آزمایشگاهی متشکل از ۱۱۶۸ ستون دایره‌ای CFST با استفاده از متغیرهای ورودی نظیر خصوصیات هندسی نمونه‌ها (قطر نمونه، ارتفاع و ضخامت لوله‌ی فولادی) و خصوصیات مکانیکی فولاد و بتن (تنش تسلیم لوله‌ی فولادی و مقاومت فشاری نمونه‌ی استوانه‌ای بتن) آموزش داده شده که ۳۰ درصد نمونه‌های آزمایشگاهی جهت صحت‌سنجی و مقایسه با دو مدل مدل تجربی و آیین‌نامه‌های AISC [۹] و EC4 [۱۰] مورد استفاده قرار گرفته است. آماره‌های مقایسه‌ی خطا مانند ریشه‌ی میانگین مربعات خطا، میانگین انحراف خطا، ضریب تطبیق، و ضریب همبستگی ویلموت برای مقایسه و ارزیابی صحت تخمین مدل‌های مورد بررسی در این تحقیق استفاده شده است. نتایج، استفاده‌ی موفقیت آمیز شبکه‌ی عصبی مصنوعی و نیز عملکرد بالای این روش از حیث صحت برآورد و تطبیق بیشتر بر داده‌های آزمایشگاهی ستون‌های دایره‌ای در مقایسه با مدل‌های تجربی و آیین‌نامه‌ای نشان داده است.

1-Concrete-filled steel tube (CFST)

۲. مدل‌های آیین‌نامه‌ای و تجربی تخمین مقاومت نهایی محوری ستون‌های دایره‌ای CFST

عمدتاً، جهت تخمین مقاومت نهایی محوری ستون‌های CFST، مدل‌های تجربی و آیین‌نامه‌ای موجود در برگیرنده‌ی سهم فولاد و بتن و نیز رفتار توأم مقطع کامپوزیت می‌باشد. در جدول (۱) مدل‌های پیش‌بینی مقاومت نهایی محوری ارائه گردیده است. در آیین‌نامه‌ی AISC که به روش LRFD (ضرایب طراحی بار و مقاومت) می‌باشد هیچ اثر محصورشدگی برای هسته‌ی بتنی در نظر گرفته نشده است. در روابط طراحی آیین‌نامه‌ی EC4 واکنش توأم فولاد و بتن و همچنین اثر محصورشدگی توسط ضرایب η_a برای فولاد و η_c برای بتن در نظر گرفته شده است. با توجه به ضعف آیین‌نامه‌های طراحی در محدود بودن کاربرد مقاومت فشاری بتن و تنش جاری شدن فولاد و همچنین نسبت‌های D/t مدل‌های تجربی در صدد توسعه و بهبود مدل‌های آیین‌نامه‌ای بوده‌اند و برخی از محققان مدل‌های تخمین ظرفیت جدیدی ارائه نموده‌اند. عمدتاً، در این مدل‌ها اثر محصورکننده‌ی لوله‌ی فولادی با در نظر گرفتن ضرایب محصورشدگی بیشتر مورد توجه قرار گرفته است. مدل ارائه شده توسط دانگ و همکاران [۱۱] با تجزیه و تحلیل رگرسیون داده‌های به دست آمده از طریق مطالعه‌ی پارامتری ارائه گردیده است که در آن f_1 یک تابع از شاخص محصورشدگی ستون (ξ) تعریف شده است. در مدل وانگ و همکاران [۱۲] ضریب کاهشی η_a در سهم مقاومت فولاد برای بررسی تأثیر محصورشدن بتن و امکان کمانش موضعی لوله‌ی فولادی و ضریب افزایشی η_c برای افزایش مقاومت بتن به علت اثر محصورشدگی ارائه شده‌اند.

جدول ۱- خلاصه‌ی معادلات ارائه شده جهت پیش‌بینی مقاومت نهایی محوری ستون‌های دایره‌ای CFST توسط محققان و آیین‌نامه‌های طراحی

شماره‌ی مدل	مدل	مقاومت نهایی محوری (N_u)
۱	AISC (2010)	$N_u = \begin{cases} P_{no.AISC}\left[0.658^{(\frac{P_{no.AISC}}{P_{e.AISC}})}\right] & \frac{P_{no.AISC}}{P_{e.AISC}} \le 2.25;\ p_{no,AISC} = 0.95 f_c' A_c + \sigma_{sy} A_s \\ 0.877 P_{e,AISC} & \frac{P_{no.AISC}}{P_{e.AISC}} > 2.25;\ P_{e,AISC} = \frac{\pi^2 (EI)_{eff}}{l_{eff}^2} \end{cases}$ $(EI)_{eff} = E_s I_s + C_3 E_c I_c;\ C_3 = 0.6 + 2(\frac{A_s}{A_s + A_c}) \le 0.9;\ E_c = 4700\sqrt{f_c'}\,(MPa)$
۲	EC4 (2004)	$N_u = (1 + \eta_c \frac{t}{D}\frac{\sigma_{sy}}{f_c'}) f_c' A_c + \eta_a \sigma_{sy} A_s;\ \eta_c = 4.9 - 18.5\bar{\lambda} + 17\bar{\lambda}^2 \ge 0;\ \eta_a = 0.25(3 + 2\bar{\lambda}) \le 1$ $\bar{\lambda} = \sqrt{\frac{N_{pl,Rk}}{N_{cr}}};\ N_{pl,Rk} = f_c' A_c + \sigma_{sy} A_s;\ N_{cr} = \frac{\pi^2 (EI)_{eff2}}{l_{eff}^2};\ (EI)_{eff2} = E_s I_s + E_c I_c$ $E_c = 22(\frac{f_c'}{10})^{0.3}(GPa)$
۳	Dong *et al.* (2017)	$N_u = [0.95 + f_1] f_c' A_c + \sigma_{sy} A_s;\ f_1 = 0.49\xi^{0.51};\ \xi = \frac{\sigma_{sy} A_s}{f_c' A_c}$
۴	Wang *et al.* (2017)	$N_u = \eta_a \sigma_{sy} A_s + \eta_c f_c' A_c;\ \ \eta_a = 0.95 - 12.6\sigma_{sy}^{-0.85} \ln(0.14 D/t)$ $\eta_c = 0.99 + \left[5.04 - 2.37(\frac{D}{t})^{0.04}(f_c')^{0.1}\right](\frac{t\sigma_{sy}}{D f_c'})^{0.51}$

در جدول (۱) N_u مقاومت نهایی محوری، σ_{sy} تنش جاری شدن لوله‌ی فولادی، f_c' مقاومت فشاری نمونه‌ی استوانه‌ای بتن، H ارتفاع نمونه، A_c و A_s به ترتیب مساحت هسته‌ی بتنی و جدار فولادی، D قطر بیرونی ستون، t ضخامت لوله‌ی فولادی، ξ شاخص محصورشدگی، $(EI)_{eff}$ و l_{eff} به ترتیب سختی مؤثر خمشی و طول مؤثر ستون، E_s و E_c به ترتیب مدول الاستیسیته‌ی فولاد و بتن، I_s و I_c به ترتیب ممان اینرسی فولاد و بتن و f_1 ، η_c و η_a ضرایب محصورشدگی می‌باشند.

۳. داده‌های مورد بررسی

جهت ارزیابی مدل‌های پیش‌بینی مقاومت نهایی ستون‌های دایره‌ای CFST، از داده‌های آزمایشگاهی برگرفته از مراجع بر اساس آزمایش فشار محوری استفاده شده است. در مجموع ۱۱۶۸ ستون دایره‌ای CFST در ساختار مدلسازی استفاده شده است که خصوصیات هندسی و خصوصیات مکانیکی فولاد و بتن در جدول (۲) ارائه گردیده است که در آن $N_{\exp}$ مقاومت محوری حداکثر آزمایشگاه می‌باشد. در نمونه‌های آزمایشی، تنش جاری شدن لوله‌ی فولاد از ۱۶۶ تا ۸۵۳ مگاپاسکال متفاوت می‌باشد؛ مقاومت حداکثر بتن نمونه‌ی استوانه‌ای بین ۱۵ تا ۱۹۳ مگاپاسکال متغیر است؛ دامنه‌ی تغییرات قطر بیرونی و ضخامت لوله‌ی فولادی به ترتیب بین ۴۷ تا ۱۰۲۰ میلی‌متر و ۰/۷۰ تا ۱۳/۳۰ میلی‌متر است.

جدول ۲- جزئیات داده‌های آزمایشگاهی برگرفته از منابع موجود

مرجع	$N_{\exp}(kN)$	$f'_c(MPa)$	$\sigma_{sy}(MPa)$	$t(mm)$	$D(mm)$	$H(mm)$	تعداد
[۱۳]	۲۳۱۴-۹۱۸۷	۵۲-۱۹۳	۳۰۰-۴۲۸	۳/۶-۱۰	۱۱۴-۲۱۹	۲۱۰-۶۰۰	۱۸
[۱۴]	۳۱۲-۱۳۷۷۶	۳۰-۱۳۰	۲۳۲-۸۵۳	۱-۱۱/۸۸	۶۰-۴۵۰	۱۵۲-۱۳۵۰	۲۲۵
[۱۵]	۳۱۲-۴۶۰۰۰	۱۵-۱۲۵	۱۶۵-۸۵۳	۰/۸۶-۱۳/۲۵	۶۰-۱۰۲۰	۱۸۰-۳۰۶۰	۲۷۲
[۱۶]	۶۱۰-۳۴۰۰	۲۴-۹۲	۲۶۶-۵۳۷	۱/۶-۶/۷	۸۹-۲۱۹	۱۰۴-۶۵۰	۴۰
[۱۷]	۱۸۲۳-۲۰۴۶۲	۷۳/۲	۲۹۰-۳۴۵	۱/۵-۱۱/۳	۱۵۳-۴۷۷	۳۰۶-۹۵۴	۳۶
[۱۸]	۴۰۳۰-۲۹۴۶۳	۴۹/۶۴	۲۵۹-۵۹۰	۲/۶-۱۱/۲	۲۱۵-۶۳۲	۶۵۷-۱۸۹۰	۱۲
[۱۹]	۱۸۸۰-۴۹۷۶	۲۹-۴۵	۳۱۱	۳/۶۸-۳/۸۷	۳۰۰	۹۰۰	۱۲
[۲۰]	۵۶۶-۱۹۹۹	۲۶-۳۲	۳۴۵-۴۸۸	۳-۳/۵	۱۱۴-۱۹۳	۱۰۰۰-۲۵۰۰	۲۴
[۲۱]	۹۴۱-۱۳۷۷۶	۲۵-۸۹	۲۶۵-۸۵۳	۲/۹-۶/۵	۱۰۸-۳۶۱	۳۰۰-۵۲۰	۳۸
[۲۲]	۶۹۹-۱۶۷۴	۳۱-۶۵	۲۶۶-۴۱۲	۲-۶	۱۰۴-۱۱۴	۳۳۰	۶
[۲۳]	۱۰۹۱-۲۰۰۰	۴۱-۱۰۶	۲۷۰-۲۸۳	۵	۱۵۹-۱۶۰	۲۰۰۰-۴۰۰۰	۱۴
[۲۴]	۹۹۸-۷۲۶۰	۲۵-۸۸	۳۴۳-۵۲۵	۳/۷۵-۵	۱۱۴-۳۶۱	۳۰۰-۱۰۸۳	۱۲
[۲۵]	۱۵۶۰-۳۶۰۰	۳۴-۶۴	۳۵۰	۲/۷۲-۴/۷۸	۱۶۵-۲۱۹	۵۰۰-۶۵۰	۱۷
[۲۶]	۶۱۰-۹۲۹۷	۲۳-۱۶۸	۱۸۵/۷-۴۵۲	۰/۸۶-۱۰/۴	۱۰۱-۳۱۸	۲۰۰-۹۵۶	۶۶
[۲۷]	۸۷۷-۱۹۹۰	۵۶-۱۰۷	۲۳۵-۳۵۵	۲/۷-۵/۹	۱۱۴/۳	۳۰۰-۹۰۰	۱۸
[۲۸]	۵۷۸-۱۶۶۲	۱۷-۳۹	۲۹۵-۳۱۵	۲/۴-۳/۹۵	۱۰۶-۱۷۰	۳۴۲-۴۹۵	۱۷
[۲۹]	۱۰۲۴-۱۱۹۸	۲۶-۳۲	۲۸۸	۲/۵۲-۲/۷۴	۱۴۰-۱۳۷	۸۰۰	۱۴
[۳۰]	۵۰۴-۶۷۹	۲۱-۲۹	۳۴۲-۳۵۷	۱/۶۵-۲/۶۷	۸۸-۱۱۳	۲۸۳-۳۶۴	۲۲
[۳۱]	۳۵۵-۴۶۰۰۰	۱۵-۱۱۴	۱۸۶-۶۳۳	۰/۷-۱۳/۳	۷۶-۱۰۲۰	۱۵۲-۳۰۶۰	۴۱
[۳۲]	۱۰۶۸-۱۷۷۴	۴۴-۶۳	۳۰۶	۳-۵	۱۲۹-۱۳۳	۳۸۷-۳۹۹	۳۶
[۳۳]	۳۵۲-۲۷۳۳	۵۰	۲۷۷-۲۸۸	۱/۹	۱۰۱-۲۵۶	۳۰۰-۱۴۰۰	۱۱
[۳۴]	۲۹۴-۱۱۶۴	۲۴-۱۰۰	۳۲۴	۱/۳۳-۴	۱۰۰	۳۰۰-۱۲۰۰	۴۰
[۳۵]	۱۱۴۷-۱۷۰۷	۳۸-۴۲	۳۳۹-۳۸۸	۲/۷۹-۲/۸۶	۱۳۸-۱۷۰	۴۲۰-۵۱۰	۸
[۳۶]	۵۰۹-۲۱۴۷	۲۳-۵۳	۳۰۰-۳۵۷	۱/۶۵-۴/۶۶	۸۸-۲۱۹	۲۸۵-۶۵۷	۱۰۵
[۳۷]	۱۳۵۰-۳۲۶۰	۴۱-۱۰۸	۱۸۵-۳۶۳	۰/۸۶-۲/۸۲	۱۶۵-۱۹۰	۵۷۷-۶۶۴	۱۶
[۳۸]	۴۹۴-۷۵۴	۲۲-۴۰	۳۶۰	۲/۷۴-۲/۸۹	۸۹-۱۱۲	۳۴۰	۴۸

۴. آماره‌های قیاس مدل‌های تخمین مقاومت نهایی ستون‌های CFST

دقت و صحت‌سنجی مدل‌های ارائه شده در جدول (۱) و نیز روش هوش مصنوعی بر مبنای شبکه‌ی عصبی بر اساس آماره‌های زیر مقایسه شده‌اند [۳۹].

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(O_i - P_i)^2} \quad (۱)$$

$$MAE = \frac{1}{N}\sum_{i=1}^{N}\left|O_i - P_i\right| \quad (۲)$$

$$NSE = 1 - \frac{\sum_{i=1}^{N}\left[O_i - P_i\right]^2}{\sum_{i=1}^{N}\left[O_i - O_m\right]^2} \qquad -\infty \le NSE \le 1 \quad (۳)$$

$$d = 1 - \frac{\sum_{i=1}^{N}(P_i - O_i)^2}{\sum_{i=1}^{N}(|P_i - O_m| + |O_i - O_m|)^2} \qquad 0 \le d \le 1 \quad (۴)$$

که در آن $RMSE$ ریشه‌ی میانگین مربعات خطا، MAE میانگین قدر مطلق خطا، NSE آماره‌ی Nash–Sutcliffe و d شاخص صحت‌سنجی ویلموت می‌باشد که بر اساس مقادیر واقعی آزمایشگاهی (O_i)، میانگین مقادیر واقعی (O_m)، و مقدار پیش‌بینی مدل‌ها (P_i) قابل محاسبه هستند. N تعداد داده مورد ارزیابی است که در بخش آموزش برابر با ۸۱۸ داده و در بخش تست برابر با ۳۵۰ داده می‌باشد. مقادیر نزدیک به صفر MAE و $RMSE$ نشان‌دهنده‌ی عملکرد بهتر مدل به لحاظ حداقل خطا می‌باشد. محدوده d بین صفر (بدون همبستگی) و یک (تناسب کامل) متفاوت است و یک معیار توصیفی برای اندازه‌گیری همبستگی می‌باشد. NSE بین داده‌های آزمایشگاهی و پیش‌بینی توسط واریانس داده‌های آزمایشگاهی نرمال شده است. NSE نشان‌دهنده‌ی رویکرد مدلسازی است و مقدار برابر با یک نشان‌دهنده‌ی تطبیق کامل پیش‌بینی بر داده‌های مدلسازی است [۳۹].

۵. شبکه‌ی عصبی مصنوعی چند لایه‌ی پرسپترون

در شبکه‌های عصبی مصنوعی از رفتار نانو رشته‌های بیولوژیکی (نورون) مغز انسان، جهت مدلسازی الهام گرفته شده است. مفاهیم ابتدایی شبکه‌ی عصبی به صورت یک مدل توسط McCulloch و Pitts ارائه گردیده است [۴۰]. سادگی، هزینه‌ی کم محاسبات و عملکرد بالا جهت تخمین، این ابزار محاسباتی را به طور قابل توجهی محبوب ساخته است. در بین شبکه‌های عصبی، شبکه‌ی عصبی پیش‌خوربه طور گسترده‌ای مورد استفاده قرار گرفته که اطلاعات را به عنوان ورودی‌ها در یک طرف دریافت و از طرف دیگر خروجی‌ها را با استفاده از اتصال یک طرفه بین نورون‌ها در لایه‌های مختلف فراهم می‌کند [۴۱]. در شبکه‌ی عصبی پیش‌خور پروسپترون چند لایه می‌توان یک ارتباط غیرخطی بین ورودی‌ها و خروجی ایجاد کرد. به صورت کلی، شبکه‌های چند لایه به عنوان طبقه‌بندی الگو، پیش‌بینی داده‌ها و تقریب عملکرد تابع می‌توانند مورد استفاده قرار گیرند [۴۲].

مدلسازی بر مبنای محاسبات نرم برای رفع مشکلات مهندسی در سالیان اخیر بسیار محبوب گردیده است. برای مثال، احمدی و همکاران در سال ۲۰۱۴ [۴۳] امکان استفاده از شبکه‌ی عصبی مصنوعی برای مدلسازی ظرفیت بار محوری ستون‌های کوتاه CFST را مورد بررسی قرار داده‌اند. از ۲۷۲ نمونه‌ی آزمایشگاهی برای توسعه‌ی مدل شبکه‌ی عصبی استفاده گردیده است. علاوه بر این، نادرپور و همکاران در سال ۲۰۱۸ [۴۴] از شبکه‌ی عصبی مصنوعی برای پیش‌بینی مقاومت فشاری بتن سازگار با محیط زیست استفاده نموده‌اند. نتایج نشان داده است که شبکه‌ی عصبی یک مدل کارآمد برای پیش‌بینی مقاومت فشاری بتن با سنگدانه‌ی بازیافتی می‌باشد.

یک شبکه‌ی پرسپترون سه لایه، شامل لایه‌های ورودی، پنهان و خروجی در شکل (۱) نشان داده شده که ورودی هر نورون پنهان مجموع وزن متغیرهای ورودی (W_{ij}) با یک بایاس (B_j) است که می‌تواند به صورت زیر بیان گردد [۴۲]:

$$s_j = \sum_{i=1}^{n}(W_{ij}X_i) + B_j \,,\; j = 1,2,\ldots,h \quad (۵)$$

که در آن n تعداد نورون‌های ورودی است؛ W_{ij} نمایانگر وزن اتصال نورون از گره‌ی نورون i_{th} در لایه‌ی ورودی به گره‌ی نورون j_{th} در لایه‌ی پنهان می‌باشد؛ B_j بایاس (آستانه) گره‌ی نورون پنهان j_{th} است و X_i گره های نورون های ورودی i_{th} از لایه‌ی ورودی $H, D, t, \sigma_{sy}, f'_c$ را نشان می‌دهد. عمدتاً، تابع انتقال سیگموئیدی برای خروجی هر نورون پنهان به صورت زیر استفاده می‌گردد:

$$S_j = \frac{1}{(1+\exp(-s_j))} \,,\; j = 1,2,\ldots,h \quad (۶)$$

با انتقال داده‌های لایه‌ی پنهان براساس تابع رابطه‌ی (۵) می‌توان نورون خروجی را با استفاده از مقدار انتقال یافته رابطه‌ی (۶) به لایه‌ی پنهان به صورت رابطه‌ی (۷) متصل نمود:

$$N_{NN} = \sum_{j=1}^{h} (W_j S_j) + B_0 \qquad (۷)$$

که در آن W_j وزن اتصال از گره‌ی نورون پنهان j_{th} به نورون خروجی N_{NN}، که مقاومت نهایی محوری پیش‌بینی شده توسط شبکه‌ی عصبی می‌باشد، است و B_0 بایاس نورون خروجی است. همان‌گونه که در معادلات فوق دیده می‌شود، اوزان و بایاس‌ها موجب پیش‌بینی مقاومت نهایی محوری ستون‌های CFST می‌گردند.

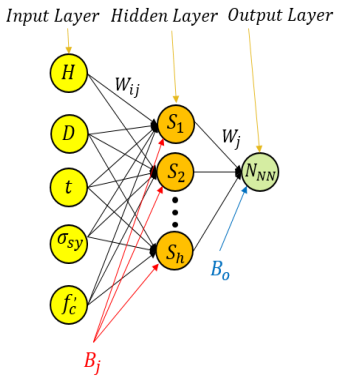

شکل ۱- ساختار شبکه‌ی عصبی پرسپترون سه لایه با پنج متغیر ورودی $(H, D, t, \sigma_{sy}, f'_c)$، h نورون در لایه پنهان و یک نورون خروجی (N_{NN})

آموزش پروسپترون سه لایه، شامل پیدا کردن مقادیر مناسب برای اوزان و بایاس‌ها به منظور دستیابی به اتصال غیرخطی لایه ورودی با لایه خروجی است. در پروسپترون چند لایه، اکثر برنامه‌های کاربردی، از الگوریتم‌های استاندارد یا انتشار بازگشت یافته به عنوان روش‌های یادگیری شبکه‌ی عصبی برای تخمین اتصالات بین نورون‌ها استفاده می‌شود [۴۵]. هدف نهایی فرآیند یادگیری، پیدا کردن بهترین ترکیب از اوزان و بایاس‌ها در شبکه‌ی عصبی برای دستیابی به حداقل خطا است.

جهت دستیابی به مقادیر بهینه‌ی وزن و بایاس اتصال بین نورون‌ها، تعداد نورون‌های پنهان برابر با ۲ تا ۲۰ نورون در نظر گرفته شده است که در شکل (۲) میانگین ۵ پاسخ ریشه‌ی میانگین مربعات خطا برای تعداد نورون‌های پنهان نشان داده شده است.

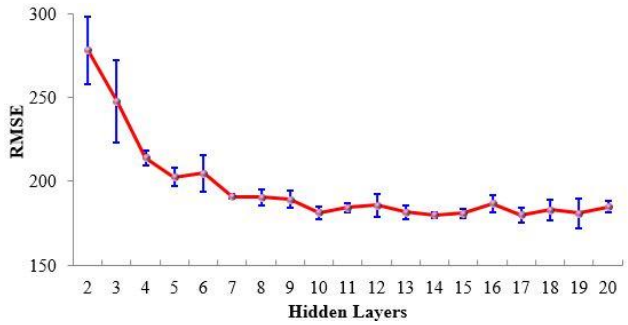

شکل ۲- میانگین پنج پاسخ خطای *RMSE* تعداد نورون‌های نورون‌های پنهان

با توجه به شکل (۲) خطای *RMSE* زیادی به ازای تعداد نورون‌های پنهان بین ۲ تا ۶ نورون حاصل شده است که انحراف خطا در این محدوده بالا به نظر می‌رسد. با افزایش تعداد نورون‌ها بین ۷ تا ۱۵ نورون، خطا نوسان زیادی ندارد که می‌تواند این تعداد لایه پاسخ پایداری نیز ارائه دهد. با افزایش تعداد نورون‌ها از ۱۶ تا ۲۰ نورون انحراف خطا بیشتر شده است. بنابراین تعداد نورون‌های پنهان عددی بین ۱۰ تا ۱۵ نورون در نظر گرفته می‌شود. برای کاهش محاسبات و همچنین انحراف خطای کمتر، تعداد نورون‌های پنهان برابر با ۱۱ نورون در نظر گرفته شده است. از اینرو، برای پیش‌بینی مقاومت نهایی محوری ستون‌های CFST از یک شبکه‌ی عصبی سه لایه با ۵ نورون ورودی در لایه‌ی اول، ۱۱ نورون در لایه‌ی پنهان و یک نورون خروجی در لایه‌ی سوم با استفاده از الگوریتم

شبه نیوتن (BFGS)[2] با ۳۰۰۰ تکرار جهت همگرایی مقادیر بهینه‌ی وزن و بایاس اتصال بین نورون‌ها برای دستیابی به یک ساختار شبکه‌ی بهینه و مناسب استفاده گردیده است.

۶. ارزیابی صحت پیش‌بینی مدل‌ها

جهت صحت‌سنجی نتایج پیش‌بینی حداکثر مقاومت محوری ستون‌های CFST با در نظر گرفتن از آماره‌های مقایسه‌ی روابط ۱ تا ۴ استفاده شده است. ۷۰ درصد کل داده‌های مورد بررسی(۸۱۸ داده)، به عنوان آموزش شبکه‌ی عصبی پروسپترون سه لایه با روش آموزش شبه نیوتن BFGS استفاده شده است. نتایج ارزیابی آماره‌های مقایسه‌ی خطا برای مدل‌های موجود در جدول (۱) و روش شبکه‌ی عصبی در دو فاز آموزش و صحت‌سنجی (تست) (۳۵۰ داده) در جدول (۳) درج شده است.

جدول ۳- نتایج ارزیابی آماری مدل‌های آیین‌نامه‌ای و تجربی با شبکه‌ی عصبی در حالت آموزش و تست

مدل	آموزش				تست			
	RMSE (*kN*)	*MAE* (*kN*)	*NSE*	*d*	*RMSE* (*kN*)	*MAE* (*kN*)	*NSE*	*d*
AISC	۹۳۳/۰۱۴	۴۸۲/۴۵۵	۰/۹۴۶	۰/۹۸۴	۱۰۰۰/۳۱۷	۵۰۳/۰۱۷	۰/۹۱۹	۰/۹۷۵
EC4	۷۵۱/۴۵۷	۲۷۳/۳۶۷	۰/۹۶۸	۰/۹۹۱	۶۴۷/۵۸۳	۲۷۳/۶۴۶	۰/۹۷۸	۰/۹۹۴
Dong *et al.*	۷۳۱/۶۴۷	۲۴۳/۰۷۲	۰/۹۷۱	۰/۹۹۱	۵۵۷/۸۱۰	۲۱۶/۱۹۰	۰/۹۸۲	۰/۹۹۵
Wang *et al.*	۶۶۳/۴۴۰	۲۵۲/۹۱۴	۰/۹۷۳	۰/۹۹۳	۶۳۲/۳۴۶	۲۵۲/۰۱۹	۰/۹۸۰	۰/۹۹۳
BFGS	۱۸۷/۶۹۲	۱۲۴/۱۰۷	۰/۹۹۸	۰/۹۹۹	۲۹۶/۵۴۵	۱۶۶/۴۰۳	۰/۹۹۳	۰/۹۹۸

با توجه به نتایج جدول (۳) کمترین مقدار ریشه‌ی میانگین مربعات خطا و میانگین خطای مطلق در فاز آموزش به ترتیب در مدل‌های تجربی وانگ و دانگ و در فاز تست در مدل دانگ حاصل گردیده است. همچنین مدل‌های وانگ و دانگ به همراه آیین‌نامه‌ی EC4 دارای شاخص ویلموت و خطای *NSE* تقریباً برابری در دو فاز آموزش و تست می‌باشند. از طرفی آیین‌نامه‌ی AISC دارای بیشترین مقدار ریشه‌ی میانگین مربعات خطا و میانگین قدر مطلق خطا و کمترین مقدار شاخص ویلموت و خطای *NSE* در دو فاز آموزش و تست نسبت به سایر مدل‌ها می‌باشد. علت این امر ناشی از عدم در نظر گرفتن اثر محصورکننده‌ی لوله‌ی فولادی می‌باشد. در حالی‌که، مدل شبکه‌ی عصبی BFGS مورد استفاده در این پژوهش، کمترین مقدار ریشه‌ی میانگین مربعات خطا و میانگین قدر مطلق خطا و بیشترین مقدار آماره‌های d و *NSE* را در هر دو فاز آموزش و تست ارائه نموده است که نشان دهنده‌ی بهترین عملکرد در میان مدل‌های آیین‌نامه‌ای و تجربی می‌باشد. با مقایسه‌ی مدل‌های تجربی ارائه شده در جدول (۱) می‌توان بیان نمود که روابط ساده‌ی وانگ و دانگ با یک رابطه‌ی ریاضی غیر خطی بسیار ساده نسبت به روابط نسبتاً پیچیده‌ی آیین‌نامه‌های AISC و EC4 قادر به پیش‌بینی مناسب مقاومت نهایی ستون‌های CFST می‌باشند.

نمودار پراکندگی داده‌های پیش‌بینی شده نسبت به داده‌های آزمایشگاهی در بخش تست برای مدل‌های مورد ارزیابی در شکل (۲) نشان داده شده است که در آن R^2 همبستگی خطی بین داده‌های پیش‌بینی و آزمایشگاهی می‌باشد. مقدار $R^2 = 1$ نشان‌دهنده‌ی یک انطباق کامل از داده‌های پیش‌بینی بر داده‌های آزمایشگاهی مقاومت حداکثر محوری ستون‌های CFST می‌باشد.

بر اساس نتایج حاصل از شکل (۲) می‌توان نتیجه گرفت که، مدل‌های وانگ و دانگ به همراه آیین‌نامه‌ی EC4 عملکردی برابر در پیش‌بینی مقاومت محوری حداکثر نشان داده‌اند و آیین‌نامه‌ی AISC بدترین پیش‌بینی را نسبت به سایر مدل‌ها با ضریب همبستگی برابر با ۰/۹۷۵ نشان داده است. در حالی‌که، الگوریتم شبه نیوتن BFGS با ضریب انطباق ۰/۹۹۳ بهترین همبستگی خطی بین داده‌های پیش‌بینی و آزمایشگاهی را نسبت به سایر مدل‌های پیش‌بینی نشان داده است.

بر مبنای نتایج حاصل از جدول (۳) و شکل (۲) مدل شبکه‌ی عصبی BFGS بهترین عملکرد را در پیش‌بینی مقاومت نهایی محوری ستون‌های CFST را در میان مدل‌های آیین‌نامه‌ای و تجربی دارا می‌باشد. بنابراین، می‌توان بیان نمود که استفاده از شبکه‌ی عصبی مصنوعی یک ابزار ساده و کارا جهت برآورد مقاومت حداکثر محوری ستون‌های دایره‌ای CFST می‌باشد که، عملکرد بالایی از حیث صحت برآورد و تطبیق بیشتر بر داده‌های آزمایشگاهی ستون‌های دایره‌ای در مقایسه با مدل‌های تجربی و آیین‌نامه‌ای را نشان داده است. به نحوی که با ارزیابی بهترین نتایج مقایسه بین مدل‌های پیش‌بینی می‌توان نتیجه گرفت که مدل غیر خطی شبکه‌ی عصبی مصنوعی ریشه‌ی میانگین مربعات خطا و میانگین قدر مطلق خطا به ترتیب در حدود ۲۵۰ و ۹۵ درصد در فاز آموزش و در حدود ۹۰ و ۳۰ درصد در فاز تست بهبود بخشیده شده است. همچنین در فاز تست ضریب همبستگی ویلموت از مقدار ۰/۹۹۵ به مقدار ۰/۹۹۸ و آماره‌ی *NSE* از مقدار

2- Broyden-Fletcher-Goldfarb-Shanno (BFGS)

۰/۹۸۲ به مقدار ۰/۹۹۳ بهبود یافته است که نشان‌دهنده‌ی مدل توانمند هوش مصنوعی نسبت به مدل‌های تجربی می‌باشد. این روش پیش‌بینی قادر به محاسبه‌ی صحیح ظرفیت باربری ستون‌های CFST بوده و می‌تواند جهت ارزیابی ظرفیت باربری و یا طراحی آتی این مقاطع به نحوی توانمند مورد استفاده قرار گیرد.

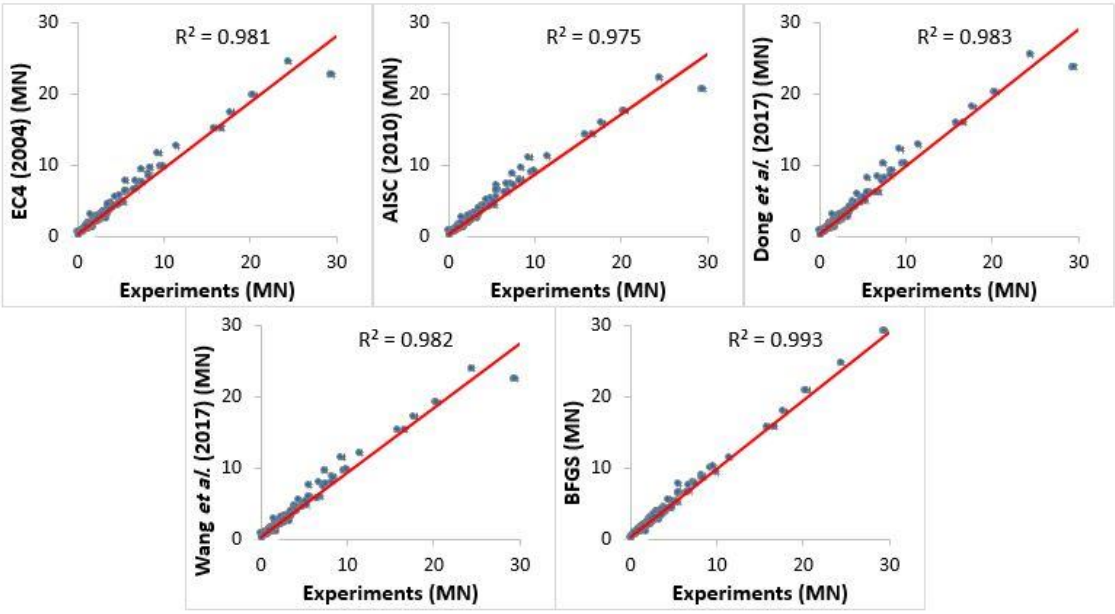

شکل ۲- نمودار پراکندگی داده‌های پیش‌بینی و آزمایشگاهی مقاومت حداکثر ستون‌های فولادی پرشده با بتن

۷. نتیجه‌گیری

در این تحقیق، یک مدل پیش‌بینی مقاومت نهایی محوری ستون‌های دایره‌ای CFST توسط شبکه‌ی عصبی مصنوعی ارائه گردیده است. صحت مدل شبکه‌ی عصبی ارائه شده با دو مدل تجربی و دو آیین‌نامه‌ی AISC و EC4 توسط آماره‌های خطا مورد ارزیابی قرار گرفته است. مدل‌های تجربی ارائه شده توسط وانگ و دانگ خطای پیش‌بینی کمتری نسبت به دو آیین نامه‌ی طراحی نشان داده است. آیین‌نامه‌ی AISC به علت عدم در نظر گرفتن اثر محصورشدگی لوله‌ی فولادی بر هسته‌ی بتنی بیشترین خطای مدلسازی و کمترین ضریب انطباق را نسبت به سایر مدل‌های پیش‌بینی نشان داده است. با مقایسه‌ی نتایج حاصل شده می‌توان بیان نمود که مدل‌های تجربی ساده‌ی وانگ و دانگ با یک رابطه‌ی ریاضی غیرخطی بسیار ساده نسبت به روابط نسبتاً پیچیده‌ی آیین‌نامه‌های AISC و EC4 قادر به پیش‌بینی مناسب مقاومت نهایی ستون‌های CFST می‌باشند.

نتایج حاکی از ارائه‌ی یک مدل شبکه‌ی عصبی توانمند و کارا جهت پیش‌بینی مقاومت نهایی ستون‌های فولادی پر شده با بتن برای مقاطع دایره‌ای دارد که موجب افزایش تطبیق و کاهش خطای پیش‌بینی نسبت به مدل‌های تجربی و آیین‌نامه‌ای گردیده است. مدل شبکه‌ی عصبی شبه نیوتن BFGS ارائه شده موجب بهبود ریشه‌ی میانگین مربعات خطا و میانگین قدر مطلق خطا به ترتیب در حدود ۹۰ درصد و ۳۰ درصد شده است و با ضریب انطباق ۰/۹۹۳ بهترین همبستگی خطی بین داده‌های پیش‌بینی و آزمایشگاهی را نسبت به سایر مدل‌های پیش‌بینی نشان داده است.

مراجع

[1] Zhang, S., Liu, J. (2007). “Seismic behavior and strength of square tube confined reinforced-concrete (STRC) columns”. *Journal of Constructional SteelResearch*, Vol. 63, pp 1194-1207.

[2] Uy, B. (2001). “Strength of short concrete filled high strength steel box columns”. *J. Constr .Steel Res*, Vol. 57 (2), pp 113-134.

[3] Han, L. H. (2004). “Flexural behaviour of concrete-filled steel tubes”. *Journal of Constructional SteelResearch*, Vol. 60 (2), pp 313-337.

[4] Bradford, M. A., Loh, H. Y. & Uy, B. (2002). “Slenderness limits for filled circular steel tubes”. *Journal of Constructional Steel Research*, Vol. 58 (2), pp 243-252.

[5] Tang, Y. Q., Zhou, Z. H. & Chan, S. L. (2013). “An accurate curved beam element based on trigonometrical mixed polynomial function”, *InternationalJournal of Structural Stability & Dynamics*, Vol. 13 (4), pp 1-19.
[6] Lai, M. H., Ho, J. C. M. (2014). “Confinement effect of ring-confined concrete-filled-steel-tube columns under uni-axial load”. *Engineering Structures,* Vol. 67, pp123-141.
[7] Uy, B., Das, S. (1997). “Wet concrete loading of thin-walled steel box columns during the construction of a tall building”. *Journal of Constructional Steel Research,* Vol. 42 (2), pp 95-119.
[8] Lai, M. H., Ho, J. C. M. (2017). “An analysis-based model for axially loaded circular CFST columns”. *Thin-Walled Structures,* Vol. 119, pp 770-781.
[9] ANSI/AISC 360-10. (2010). “specification for structural steel buildings”. Chicago, USA: American institute of steel construction (AISC).
[10] EC4. (2004). “Design of composite steel & oncretestructures”. Part 1-1: General rules & rules for buildings, En-1994-1-1, European committee for t&ardization: British St&ards Institution.
[11] Dong, C. X., Kwan, A. K. H. & Ho, J. C. M. (2017). “Effects of external confinement on structural performance of concrete-filled steel tubes”. *Journal of Constructional Steel Research,* Vol.132, pp 72-82.
[12] Wang, Z. B., Tao, Z., H, L. H., Uy, B,. L, D,. & K, W, H. (2017). “Strength, stiffness and ductility of concrete-filled steel columns under axial compression”. *Engineering Structures,* Vol. 135, pp 209-221.
[13] Xiong, M. X., Xiong, D. X. & Liew, J. Y. R. (2017). “Axial performance of short concrete filled steel tubes with high- and ultra-high- strength materials”. *Engineering Structures,* Vol.136, pp 494-510.
[14] Lu, Z. H., Zaho, Y. G. (2010). “Suggested empirical models for the axial capacity of circular CFT stub columns”. *Journal of Constructional Steel Research,* Vol. 66, pp 850-862.
[15] Lai, M. H., Ho, J. C. M. (2016). “A theoretical axial stress-strain model for circular concrete-filled-steel-tube columns”. *Engineering Structures,* Vol. 125, pp 124-125.
[16] Kwan, A. K. H., Dong, C. X. & Ho, J. C. M. (2016). “Axial & lateral stress–strain model for concrete-filled steel tubes”. *Journal of Constructional Steel Research,* Vol.122, pp 421-433.
[17] Wang, Y., Chen, P. & Zhang, Y. (2017). “Size effect of circular concrete-filled steel tubular short columns subjected to axial compression”. *Thin-Walled Structures,* Vol. 120, pp 397-407.
[18] Wang, W., Ma, H., Li, Z. & Tang, Z. (2017). “Size effect in circular concrete-filled steel tubes with different diameter-to-thickness ratios under axial compression”. *Engineering Structures,* Vol. 151, pp 554-567.
[19] Ding, F. X., Liu, J., Liu, X. M., Yu, Z. W. & Li, D. W. Zhang, Y. (2015). “Mechanical behavior of circular & square concrete filled steel tube stub columns under local compression”. *Thin-Walled Structures,* Vol. 94, pp 155-166.
[20] Dundu, M. (2012). “Compressive strength of circular concrete filled steel tube columns”. *Thin-Walled Structures,* Vol. 56, pp 62-70.
[21] Liang, Q. Q., Fargomeni, S. (2009). “Nonlinear analysis of circular concrete-filled steel tubular short columns under axial loading”. *Journal of Constructional Steel Research,* Vol. 65, pp 2186-2196.
[22] Lam, D., Gardner, L. (2008). “Structural design of stainless steel concrete filled columns”. *Journal of Constructional Steel Research,* Vol. 64, pp 1275-1282.
[23] Zeghiche, J., Chaoui, K. (2005). “An experimental behaviour of concrete-filled steel tubular columns”. *Journal of Constructional Steel Research,* Vol. 61, pp 53-66.
[24] Ellobody, E., Young, B. & Lam, D. (2006). “Behaviour of normal & high strength concrete-filled compact steel tube circular stub columns”, *Journal of Constructional Steel Research,* Vol. 62, pp. 706-715.
[25] Yu, Z. W., Ding, F. X. & Cai, C. S. (2007). “Experimental behavior of circular concrete-filled steel tube stub columns”, *Journal of Constructional Steel Research,* Vol. 63, pp 165-174.
[26] Hoang, A. L., Fehling, E. (2017). “Numerical study of circular steel tube confined concrete (STCC) stub columns”. *Journal of Constructional Steel Research,* Vol. 136, pp 238-255.
[27] Ekmekyapar, T., Al-Eliwi, B. J. M. (2016). “Experimental behaviour of circular concrete filled steel tube columns & design specifications”. *Thin-Walled Structures,* Vol. 105, pp 220-230.
[28] Zhongqiu, F., Bohai, J. & Yang. M. (2011). “The Mechanical Properties of Lightweight Aggregate Concrete Confined by Steel Tube”. *Design, Construction, Rehabilitation, & Maintenance of Bridges,* Vol. 219, pp 33-39.
[29] Geng, Y., Wang, Y. & Chen. J. (2015). “Time-Dependent Behavior of Recycled Aggregate Concrete–Filled Steel Tubular Columns”. *J. Struct. Eng.,* Vol. 141, pp 1-12.
[30] Chen, Z., Xu, J., Xue, J. & Su, Y. (2014). “Performance & Calculations of Recycled Aggregate Concrete-filled Steel Tubular (RACFST) Short Columns under Axial Compression”. *International Journal of Steel Structures,* Vol. 14, pp 31-42.
[31] Guneyisi, E. M., Gultekin, A. & Mermerdas, K. (2016). “Ultimate Capacity Prediction of Axially Loaded CFST Short Columns”. *International Journal of Steel Structures,* Vol. 16 (1), pp 99-114.
[32] Lu, Y. Y., Li, N., Li, S. & Liang, H. J. (2015). “Experimental investigation of axially loaded steel fiber reinforced high strength concrete-filled steel tube columns”. *J. Cent. South Univ.,* Vol. 22, pp 2287-2296.

[33] Aslani, F., Uy, B., Hur, J. & Carino, P. (2017). “Behaviour & design of hollow & concrete-filled spiral welded steel tube columns subjected to axial compression”. *International Journal of Steel Structures,* Vol. 128, pp 261-288.
[34] Ellobody, E. (2013). “Numerical modelling of fibre reinforced concrete-filled stainless steel tubular columns”. *Thin-Walled Structures,* Vol. 63, pp 1-12.
[35] Tam, V. W. Y., Wang, Z. B. & Tao, Z. (2013). “Behaviour of recycled aggregate concrete filled stainless steel stub columns”. *Materials & Structures,* DOI 10.1617/s11527-013-0061-1.
[36] Wang, Y., Chen, J. & Geng, Y. (2015). “Testing & analysis of axially loaded normal-strength recycled aggregate concrete filled steel tubular stub columns”. *Engineering Structures,* Vol. 86, pp 192-212.
[37] O'Shea, M. D., Bridge, R. Q. (2000). “Design of circular thin-walled concrete filled steel tubes”. *Journal of Structural Engineering*, Vol. 126, pp 1295-1303.
[38] Gupta, P. K., Sarda, S. M. & Kumar, M. S. (2007). “Experimental& computational study of concrete filled steel tubular columns under axial loads”. *Journal of Constructional Steel Research,* Vol. 63, pp 182-193.
[39] Keshtegar, B., Heddam, S. (2017). “Modeling daily dissolved oxygen concentration using modified response surface method & artificial neural network: a comparative study”. *Neural Computing & Applications*, DOI 1007/10/s00521-017-2917-8.
[40] Mangasarian, O. L. (1990). Wolberg, W.H., “Cancer Diagnosis via Linear Programming”. University of Wisconsin-Madison, Computer Sciences Department.
[41] Fine, T. L. (1999). “Feedforward Neural Network Methodology”. *Springer Verlag*,
[42] Mirjalili, S., Mirjalili, S. M. & Lewis, A. (2014). “Let a biogeography-based optimizer train your Multi-Layer Perceptron”. *Information Sciences,* Vol. 269, pp188-209.
[43] Ahmadi, M., Naderpour, H. & Kheyroddin, A. (2014). “Utilization of artificial neural networks to prediction of the capacity of CCFT short columns subject to short term axial load”. *Archives of Civil and Mechanical Engineering,* Vol. 14, pp 510-517.
[44] Naderpour, H., Rafiean, A. H. & Fakharian, P. (2018). “Compressive strength prediction of environmentally friendly concrete using artificial neural networks”. *Journal of Building Engineering*, Vol. 16, pp 213–219.
[45] Adeli, H., Hung, S. (1994). “An adaptive conjugate gradient learning algorithm for efficient training of neural networks”. *Applied Mathematics & Computation*, Vol. 62, pp 81–102.