

مدل سازی مبتنی بر تجزیه و تحلیل ستون های دایره ای فولادی پر شده با بتن تحت فشار محوری توسط شبکه عصبی مصنوعی*

محمدحسین یعقوبی^(۱) بهروز کشته گر^(۲) حسینعلی رهدار^(۳)

چکیده ستون های فولادی پر شده با بتن به واسطه عملکرد مناسب بتن و فولاد موجب بهبود مقاومت نهایی محوری ستون ها می گردد. عمدتاً، مدل های تجربی و آیین نامه ای قادر به محاسبه دقیق مقاومت نهایی محوری این مقاطع برای مصالح با مقاومت های بالا نیستند. در این تحقیق، بر اساس نتایج آزمایشگاهی، یک مدل تخمین مقاومت نهایی محوری بر اساس شبکه عصبی توسعه داده شده است. نتایج حاصل از تخمین مدل شبکه عصبی بر اساس ۱۱۶۸ نمونه آزمایشگاهی، به کمک چندین آماره خطا با هشت مدل تجربی و آیین نامه EC4 مقایسه گردیده است. مدل شبکه عصبی ارائه شده در مقایسه با مدل های موجود دقیق تر است و محدوده گسترده تری از مقاومت های مصالح و نسبت قطر به ضخامت و ارتفاع به قطر را پوشش می دهد.

واژه های کلیدی ستون فولادی پر شده با بتن، مقاومت نهایی محوری، شبکه عصبی مصنوعی، مدل سازی.

Model-Based Analysis for Ultimate Axial Load of Circular CFST Columns Using Artificial Neural Network

Mohammad Hossein Yaghoubi

Behroz Keshtegar

Hossein Ali Rahdar

Abstract Concrete-filled steel tube (CFST) columns are increasingly adopted in many modern structures due to the advantage composite action between steel tube and concrete core. The almost empirical models and design code relations can not provide the accurate predictions for the axial ultimate strength of these composite steel-concrete sections, especially high (ultra-high) strength concrete. In this paper, a novel predicted model of the ultimate axial strength was introduced 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 eight empirical newest models and EC4 code relations using several error statistics. The ANN predictions are more accurate than the existing (code design) models and covers a wider range of material strengths and the ratio of diameter to thickness and height to diameter.

Key Words Concrete-filled steel tube, Axial ultimate strength, Artificial Neural Network, Modeling.

* تاریخ دریافت مقاله ۹۷/۳/۱۹ و تاریخ پذیرش آن ۹۸/۱/۲۸ می باشد.

(۱) دانشجوی کارشناسی ارشد مهندسی عمران- سازه، دانشگاه زابل.

(۲) نویسنده مسئول، استادیار دانشکده مهندسی عمران، دانشگاه زابل.

(۳) استادیار دانشکده مهندسی عمران، دانشگاه زابل.

مقدمه

ستون فولادی پرشده با بتن (CFST) که با پر کردن یک لوله 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. وجود فولاد در بیرونی‌ترین تارهای مقطع به صورت مؤثر سبب بهبود ممان اینرسی و مقاومت مقطع و نهایتاً سبب افزایش سختی مقطع می‌گردد [1, 2]. هسته بتنی یک مقطع ایده‌آل برای باربری ثقلی است که در برخی حالات باعث جلوگیری از کمانش موضعی می‌گردد [3, 4]. همچنین تیوب فولادی با محصور کردن بتن، باعث افزایش مقاومت فشاری و شکل‌پذیری می‌گردد [5]. لذا، استفاده از این نوع مقاطع به عنوان ستون‌های در معرض بارهای فشاری بالا بسیار سودمند خواهد بود. علاوه بر این، تیوب فولادی نقش یک قالب ماندگار را برای بتن ایفا می‌کند و این موضوع سبب کاهش هزینه‌های ساخت می‌گردد [6, 7].

عمدتاً، روش‌های طراحی ستون‌های فولادی پرشده با بتن همانند مقاطع فولادی و بتن آر مه در آیین‌نامه‌ها رابطه‌سازی شده‌اند و از واکنش توأم فولاد و بتن چشم‌پوشی می‌شود. از طرف دیگر، مدل‌های تجربی بر مبنای تعداد محدودی نمونه آزمایشگاهی، جهت پیش‌بینی حداکثر ظرفیت ستون‌های CFST توسعه داده شده‌اند. لذا، کاربرد مدل‌های پیشنهادی در محدوده گسترده‌تر از دقت قابل قبولی برخوردار نیست. همچنین، این مدل‌ها محدودیت‌هایی در مقاومت فولاد و بتن و همچنین نسبت قطر به ضخامت دارند. در نتیجه مدل‌های تجربی و آیین‌نامه‌ای ممکن است قادر به پیش‌بینی مناسب رفتار این نوع سازه‌ها با دقت نباشند. از طرفی، اثرات تنش جاری شدن فولاد، مقاومت فشاری بتن، نسبت قطر به ضخامت و نسبت ارتفاع به قطر بر روی رفتار ستون‌های CFST به وضوح در مطالعات قبلی

تفسیر نشده است.

در این تحقیق، از روش هوش مصنوعی بر مبنای شبکه عصبی چندلایه، جهت پیش‌بینی مقاومت نهایی محوری ستون‌های CFST استفاده گردیده است. در این روش می‌توان ارتباط غیرخطی بین مقاومت نهایی و پارامترهای ورودی ستون‌های دایره‌ای CFST ایجاد نمود. علاوه بر این، در این مطالعه یک پایگاه داده گسترده به منظور بررسی تأثیر متغیرهای مختلف بر رفتار ستون‌های CFST ایجاد گردیده است. مدل شبکه عصبی با استفاده از متغیرهای ورودی نظیر خصوصیات هندسی نمونه‌ها و خصوصیات مکانیکی فولاد و بتن آموزش داده شده که ۳۰ درصد نمونه‌های آزمایشگاهی جهت صحت‌سنجی و مقایسه با هشت مدل تجربی و آیین‌نامه [8] EC4 مورد استفاده قرار گرفته است. رفتار غیرخطی نسبت به افزایش مقاومت فشاری بتن و نیز تنش جاری شدن فولاد، در مقایسه با مدل‌های تجربی و آیین‌نامه‌ای مشاهده شده است. افزایش مقاومت نهایی بتن و نیز تنش جاری شدن برخلاف نسبت‌های ابعادی همانند نسبت ارتفاع به قطر یا قطر به ضخامت لوله فولادی موجب افزایش مقاومت ستون‌های CFST می‌گردد.

مدل‌های آیین‌نامه‌ای و تجربی مقاومت نهایی

ستون‌های CFST

جهت تخمین مقاومت نهایی محوری ستون‌های CFST، مدل‌های تجربی و آیین‌نامه‌ای که در جدول (۱) ارائه گردیده، استفاده شده است؛ که در آن σ_{cc} و f_{cc} به ترتیب تنش محوری فولاد و تنش بتن محصور شده، $\sigma_{s\theta}$ و σ_{sy} به ترتیب تنش جاری شدن و حلقه‌ای لوله فولادی، f_r تنش شعاعی بتن محصور شده، f'_c و f_{ck} به ترتیب مقاومت فشاری نمونه استوانه‌ای و مقاومت مشخصه بتن، H ارتفاع نمونه، A_c و A_s به ترتیب مساحت هسته بتنی و جدار فولادی، D قطر بیرونی ستون، t ضخامت

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_{test} مقاومت محوری حداکثر آزمایشگاه است. در نمونه‌های آزمایشی، تنش جاری شدن لوله فولاد از ۱۶۶ تا ۸۵۳ مگاپاسکال متفاوت است؛ مقاومت حداکثر بتن نمونه استوانه‌ای بین ۱۵ تا ۱۹۳ مگاپاسکال متغیر است؛ دامنه تغییرات قطر بیرونی و ضخامت لوله فولادی به ترتیب بین ۴۷ تا ۱۰۲۰ میلی‌متر و ۰/۷۰ تا ۱۳/۳۰ میلی‌متر است.

لوله فولادی، A_{sc} سطح مقطع معادل فولاد-بتن، ξ شاخص محصورشدگی، $(EI)_{eff}$ و I_{eff}^2 به ترتیب سختی مؤثر خمشی و طول مؤثر ستون، E_s و E_c به ترتیب مدول الاستیسیته فولاد و بتن، I_s و I_c به ترتیب ممان اینرسی فولاد و بتن و Ω ، f_1 ، η_c و η_a ضرایب محصورشدگی می‌باشند.

داده‌های موردبررسی

جهت ارزیابی مدل‌های پیش‌بینی مقاومت نهایی ستون‌های CFST، از داده‌های آزمایشگاهی برگرفته از مراجع استفاده شده است. در مجموع ۱۱۶۸ ستون

جدول ۱ خلاصه معادلات ارائه‌شده توسط محققان و آیین‌نامه‌های طراحی

مدل	مقاومت نهایی محوری (N_u)
Lai and Ho (2017) [7]	$N_u = \sigma_{sz} A_{st} + f_{cc} A_c; \sigma_{sz} = \frac{1}{2} [-\sigma_{s0} + \sqrt{4\sigma_{sy}^2 - 3\sigma_{s0}^2}];$ $\frac{\sigma_{s0}}{\sigma_{sy}} = 0.2 \left(\frac{D}{t}\right)^{0.35} \left(\frac{f'_c}{\sigma_{sy}}\right)^{0.45}; f_{cc} = f'_c + 3.5f_r; f_r = \frac{2t}{D-2t} \sigma_{s0}$
Dong et al. (2017) [9]	$N_u = [0.95 + f_1] f'_c A_c + \sigma_{sy} A_s; f_1 = 0.49 (\sigma_{sy} A_s / f'_c A_c)^{0.51}$
Xiong et al. (2017) [10]	$N_u = (1 + 4.1 \frac{f_r}{f'_c}) A_c f'_c + \left(\sqrt{1 - 3 \left(\frac{A_c f_r}{A_s \sigma_{sy}} \right)^2} - \frac{A_c f_r}{A_s \sigma_{sy}} \right) A_s \sigma_{sy}$ $\frac{f_r}{f'_c} = \frac{A_s \sigma_{sy}}{A_c f'_c} \frac{3.1}{\sqrt{9 + 3(3.1)^2}}$
Lai and Ho (2014) [11]	$N_u = \sigma_{sz} A_s + f_{cc}^* A_c; \xi = \frac{\sigma_{sy} A_s}{f'_c A_c};$ $\frac{\sigma_{s0}}{\sigma_{sy}} = \begin{cases} 0 & 0 \leq \xi < 0.03 \\ -0.03\xi^2 + 0.175\xi - 0.006 & 0.03 \leq \xi < 2.5 \\ 0.244 & \xi \geq 2.5 \end{cases} f_{cc}^* = f'_c + 4.1f_r$
Yu et al. (2013) [12]	$N_u = (1 + 0.5 \times \frac{\xi}{1+\xi}) (\sigma_{sy} A_s + f_{ck} A_c); \Omega = \frac{A_s}{A_c} f_{ck} = 0.67f'_c$
Lu and Zhao (2010) I [13]	$N_u = A_c f'_c + 1.47 A_s \sigma_{sy}$
Lu and Zhao (2010) II [13]	$N_u = (1.3 + 1.1\xi) f_{ck} A_{sc}; A_{sc} = A_s + A_c$
Hatzigeorgiou (2008) [14]	$N_u = 0.8f'_c A_c (1 + \xi + \sqrt{\xi})$
EC4 (2004) [8]	$N_u = (1 + \eta_c \frac{t}{D} \frac{\sigma_{sy}}{f'_c}) f'_c A_c + \eta_a \sigma_{sy} A_s; \eta_c = 4.9 - 18.5\bar{\lambda} + 17\bar{\lambda}^2 \geq 0; \eta_a =$ $0.25(3 + 2\bar{\lambda}) \leq 1 \bar{\lambda} = \sqrt{\frac{N_{pl,Rk}}{N_{cr}}}; N_{pl,Rk} = f'_c A_c + \sigma_{sy} A_s; N_{cr} =$ $\frac{\pi^2 (EI)_{eff2}}{l_{eff}^2}; (EI)_{eff2} = E_s I_s + E_c I_c E_c = 22 \left(\frac{f'_c}{10}\right)^{0.3} \text{ (GPa)}$

جدول ۲ جزئیات داده‌های آزمایشگاهی برگرفته از منابع موجود

تعداد	H(mm)	D(mm)	t(mm)	σ_{sy} (Mpa)	f'_c (Mpa)	N_{test} (kN)	مرجع
۱۸	۲۱۰-۶۰۰	۱۱۴-۲۱۹	۳/۶-۱۰	۳۰۰-۴۲۸	۵۱/۶-۱۹۳	۲۳۱۴-۹۱۸۷	[10]
۲۲۵	۱۵۲-۱۳۵۰	۶۰-۴۵۰	۱-۱۱/۸۸	۲۳۲-۸۵۳	۳۰-۱۳۰	۳۱۲-۱۳۷۷۶	[13]
۲۷۲	۱۸۰-۳۰۶۰	۶۰-۱۰۲۰	۰/۸۶-۱۳/۲۵	۱۶۵-۸۵۳	۱۵-۱۲۵/۳	۳۱۲-۴۶۰۰	[19]
۴۰	۱۰۴-۶۵۰	۸۹-۲۱۹	۱/۶-۶/۷	۲۶۶-۵۳۷	۲۳/۸-۹۱/۹	۶۱۰-۳۴۰۰	[20]
۳۶	۳۰۶-۹۵۴	۱۵۳-۴۷۷	۱/۵-۱۱/۳	۲۹۰-۳۴۵	۷۳/۲	۱۸۲۳-۲۰۴۶۲	[21]
۱۲	۶۵۷-۱۸۹۰	۲۱۵-۶۳۲	۲/۶-۱۱/۲	۲۵۹-۵۹۰	۴۹/۶۴	۴۰۳۰-۲۹۴۶۳	[22]
۱۲	۹۰۰	۳۰۰	۳/۶۸-۳/۸۷	۳۱۱	۲۸/۶-۴۴/۷	۱۸۸۰-۴۹۷۶	[23]
۲۴	۱۰۰۰-۲۵۰۰	۱۱۴-۱۹۳	۳-۳/۵	۳۴۵-۴۸۸	۲۵/۶-۳۲/۱	۵۶۶-۱۹۹۹	[24]
۳۸	۳۰۰-۵۲۰	۱۰۸-۳۶۱	۲/۹-۶/۵	۲۶۵-۸۵۳	۲۵-۸۹	۹۴۱-۱۳۷۷۶	[25]
۶	۳۳۰	۱۰۴-۱۱۴	۲-۶	۲۶۶-۴۱۲	۳۱-۶۵	۶۹۹-۱۶۷۴	[26]
۱۴	۲۰۰۰-۴۰۰۰	۱۵۹/۶-۱۶۰/۳	۵	۲۷۰-۲۸۳	۴۱-۱۰۶	۱۰۹۱-۲۰۰۰	[27]
۱۲	۳۰۰-۱۰۸۳	۱۱۴-۳۶۱	۳/۷۵-۵	۳۴۳-۵۲۵	۲۵/۴-۸۷/۷	۹۹۸-۷۲۶۰	[28]
۱۷	۵۰۰-۶۵۰	۱۶۵-۲۱۹	۲/۷۲-۴/۷۸	۳۵۰	۳۴-۶۴	۱۵۶۰-۳۶۰۰	[29]
۶۶	۲۰۰-۹۵۵/۵	۱۰۱-۳۱۸	۰/۸۶-۱۰/۴	۱۸۵/۷-۴۵۲	۲۳-۱۶۷/۹	۶۱۰-۹۲۹۷	[30]
۱۸	۳۰۰-۹۰۰	۱۱۴/۳	۲/۷-۵/۹	۲۳۵-۳۵۵	۵۶-۱۰۷	۸۷۷-۱۹۹۰	[31]
۱۷	۳۴۲-۴۹۵	۱۰۵/۹-۱۶۰/۸	۲/۴-۳/۹۵	۲۹۵-۳۱۵	۱۶/۷-۳۹/۳	۵۷۸-۱۶۶۲	[32]
۱۴	۸۰۰	۱۳۷/۸-۱۳۹/۸	۲/۵۲-۲/۷۴	۲۸۸	۲۵/۹-۳۲/۴	۱۰۲۴-۱۱۹۸	[33]
۲۲	۲۸۳-۳۶۴	۸۸-۱۱۳	۱/۶۵-۲/۶۷	۳۴۲-۳۵۷	۲۱/۴-۲۹/۲	۵۰۴-۶۷۹	[34]
۴۱	۱۵۲-۳۰۶۰	۷۶-۱۰۲۰	۰/۷-۱۳/۳	۱۸۶-۶۳۳	۱۵-۱۱۴	۳۵۵-۴۶۰۰	[35]
۳۶	۳۸۷-۳۹۹	۱۲۹-۱۳۳	۳-۵	۳۰۶	۴۴-۶۳	۱۰۶۸-۱۷۷۴	[36]
۱۱	۳۰۰-۱۴۰۰	۱۰۱-۲۵۶	۱/۹	۲۷۷-۲۸۸	۵۰	۳۵۲-۲۷۳۳	[37]
۴۰	۳۰۰-۱۲۰۰	۱۰۰	۱/۳۳-۴	۳۲۴	۲۴-۱۰۰	۲۹۴-۱۱۶۴	[38]
۸	۴۲۰-۵۱۰	۱۳۸-۱۷۰	۲/۷۹-۲/۸۶	۳۳۹-۳۸۸	۳۷/۸-۴۱/۷	۱۱۴۷-۱۷۰۷	[39]
۱۰۵	۲۸۵-۶۵۷	۸۸-۲۱۹	۱/۶۵-۴/۶۶	۳۰۰-۳۵۷	۲۲/۶-۵۲/۹	۵۰۹-۲۱۴۷	[40]
۱۶	۵۷۷-۶۶۴	۱۶۵-۱۹۰	۰/۸۶-۲/۸۲	۱۸۵-۳۶۳	۴۱-۱۰۸	۱۳۵۰-۳۲۶۰	[41]
۴۸	۳۴۰	۸۹-۱۱۲	۲/۷۴-۲/۸۹	۳۶۰	۲۲-۴۰	۴۹۴-۷۵۴	[42]

طبقه‌بندی داده، پیش‌بینی و تقریب عملکرد یک رابطه می‌توانند مورد استفاده قرار گیرند [43]. در شبکه‌های عصبی پرسپترون چندلایه می‌توان یک ارتباط غیرخطی بین ورودی‌ها و خروجی ایجاد نمود.

شبکه عصبی مصنوعی چندلایه پرسپترون (MLPNN)

شبکه‌های عصبی مصنوعی (ANN) یک ابزار محاسباتی ساده با هزینه محاسبات کم و عملکرد بالا جهت تخمین است. به صورت کلی، شبکه‌های چندلایه به عنوان

در این تحقیق، از الگوریتم شبه نیوتن BFGS برای دستیابی به یک ساختار شبکه مناسب با ۵ نورون ورودی، ۱۱ نورون در لایه پنهان و یک نورون خروجی با ۳۰۰۰ تکرار استفاده گردیده است.

آماره‌های قیاس مدل‌های تخمین مقاومت نهایی ستون‌های CFST

دقت و صحت سنجی مدل‌های ارائه شده در جدول (۱) و نیز روش هوش مصنوعی بر مبنای شبکه عصبی بر اساس آماره‌های زیر مقایسه شده‌اند [44].

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (O_i - P_i)^2} \quad (۴)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |O_i - P_i| \quad (۵)$$

$$NSE = 1 - \frac{\sum_{i=1}^N [O_i - P_i]^2}{\sum_{i=1}^N [O_i - O_m]^2} \quad -\infty \leq NSE \leq 1 \quad (۶)$$

$$d = 1 - \frac{\sum_{i=1}^N (P_i - O_i)^2}{\sum_{i=1}^N (|P_i - O_m| + |O_i - O_m|)^2} \quad 0 \leq d \leq 1 \quad (۷)$$

که در آن RMSE ریشه میانگین مربعات خطا، MAE میانگین قدر مطلق خطا، NSE آماره Nash-Sutcliffe و d شاخص صحت سنجی ویلموت است 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 است. مقادیر نزدیک به صفر MAE و RMSE نشان‌دهنده عملکرد بهتر مدل به لحاظ حداقل خطا است. محدوده d بین صفر (بدون همبستگی) و یک (تناسب کامل) متفاوت است. مقدار NSE برابر با یک نشان‌دهنده تطبیق کامل پیش‌بینی بر داده‌های مدل‌سازی است [46].

شکل (۱) یک شبکه سه لایه نشان داده شده است. هر نورون پنهان بر اساس متغیرهای ورودی (X_i) می‌تواند به صورت زیر بیان گردد [43]:


$$s_j = \sum_{i=1}^n (W_{ij}X_i) + B_j, j = 1, 2, \dots, h \quad (۱)$$

که در آن n تعداد نورون‌های ورودی است؛ W_{ij} نمایانگر وزن اتصال نورون i_{th} در لایه ورودی به نورون j_{th} در لایه پنهان است، B_j بایاس نورون پنهان j_{th} است و X_i نورون از لایه ورودی $H, D, t, f_{sy}, f'_c, d, S, f_{sr}$ را نشان می‌دهد.

از تابع انتقال سیگموئیدی برای خروجی هر نورون پنهان به صورت زیر استفاده شده است:

$$S_j = \frac{1}{(1 + \exp(-s_j))} \quad j = 1, 2, \dots, h \quad (۲)$$

نورون خروجی را با استفاده از مقدار انتقال یافته رابطه (۲) به لایه پنهان به صورت زیر می‌توان متصل نمود.



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

$$N_{NN} = \sum_{j=1}^h (W_{jk}S_j) + B_0 \quad (۳)$$

که در آن W_{jk} وزن اتصال از نورون پنهان j_{th} به نورون خروجی N_{NN} 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.

ارزیابی صحت پیش‌بینی مدل‌ها

۷۰ درصد کل داده‌های موردبررسی (۸۱۸ داده)، به‌عنوان آموزش شبکه عصبی پرو سپترون سه لایه استفاده شده است. نتایج ارزیابی آماره‌های مقایسه خطا برای مدل‌های برگرفته از جدول (۱) و روش شبکه عصبی در دو فاز آموزش و صحت‌سنجی (تست) (۳۵۰ داده) در جدول (۳) درج شده است. با توجه به نتایج جدول (۳) کمترین مقدار ریشه میانگین مربعات خطا در بخش آموزش در مدل‌های تجربی (Lai and Ho (2017) و Hatzigeorgiou و در بخش تست در مدل‌های Dong et al و Hatzigeorgiou حاصل گردیده است. از طرفی مدل‌های Xiong et al و مدل دوم Lu and Zhao دارای بیشترین مقدار ریشه میانگین مربعات خطا و میانگین قدر مطلق خطا در بخش آموزش و تست می‌باشند. از این‌رو، مدل‌های تجربی ارائه‌شده توسط (Lai and Ho (2017) و Lu and Hatzigeorgiou و Dong et al و مدل اول Lu and Zhao به همراه آیین‌نامه EC4 دارای بهترین همبستگی در هر دو بخش آموزش و تست می‌باشند که اختلاف خطای آن‌ها ناچیز است. در حالی که مدل شبکه عصبی مورد استفاده در این پژوهش، کمترین مقدار ریشه میانگین مربعات خطا و میانگین قدر مطلق خطا و بیشترین میزان همبستگی را در بخش آموزش و تست

ارائه نموده است که نشان‌دهنده بهترین عملکرد در میان مدل‌های آیین‌نامه‌ای و تجربی است.

همچنین در شکل (۲) جهت ارزیابی مدل‌های موردبررسی از حیث صحت و تطبیق بر داده‌های آزمایشگاهی از نسبت شاخص صحت‌سنجی ویلموت به میانگین قدر مطلق خطا استفاده شده که مقدار حداکثر این آماره نشان‌دهنده تطبیق صحیح‌تر مدل‌سازی است. بر اساس نتایج ارائه شده در شکل (۲) می‌توان مشاهده نمود که مدل شبکه عصبی بهترین عملکرد پیش‌بینی را داراست.

با مقایسه مدل‌های تجربی ارائه شده در جدول (۱) می‌توان بیان نمود که روابط Hatzigeorgiou، مدل اول Lu and Zhao و مدل Dong et al. با یک رابطه ریاضی غیرخطی بسیار ساده قادر به پیش‌بینی مقاومت نهایی ستون‌های CFST می‌باشند.


نمودار پراکنندگی داده‌های پیش‌بینی شده نسبت به داده‌های آزمایشگاهی در بخش تست برای مدل‌های مورد ارزیابی در شکل (۳) نشان داده شده است که در آن (R^2) همبستگی خطی بین داده‌های پیش‌بینی و آزمایشگاهی است. مقدار $R^2 = 1$ نشان‌دهنده یک انطباق کامل از داده‌های پیش‌بینی بر داده‌های آزمایشگاهی مقاومت حداکثر محوری ستون‌های CFST است.

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

مدل	آموزش				تست			
	RMSE	MAE	NSE	D	RMSE	MAE	NSE	d
Lai and Ho (2017)	۶۶۱/۳۵۸	۲۴۹/۹۲۰	۰/۹۶۸	۰/۹۹۲	۶۴۷/۹۷۰	۲۴۹/۲۹۶	۰/۹۷۶	۰/۹۹۳
Dong et al. (2017)	۷۳۱/۶۴۷	۲۴۳/۰۷۲	۰/۹۶۱	۰/۹۹۱	۵۵۷/۸۱۰	۲۱۶/۱۹۰	۰/۹۸۲	۰/۹۹۵
Xiong et al. (2017)	۱۳۱۶/۵۳۰	۶۰۳/۱۸۵	۰/۸۷۴	۰/۹۷۴	۱۰۳۰/۶۴۴	۵۴۶/۴۳۷	۰/۹۳۹	۰/۹۸۶
Lai and Ho (2014)	۷۱۵/۶۴۹	۳۲۵/۵۱۹	۰/۹۶۳	۰/۹۹۰	۸۵۹/۹۶۱	۳۳۵/۹۳۳	۰/۹۵۸	۰/۹۸۸
Yu et al. (2013)	۷۷۸/۹۷۸	۳۵۰/۴۸۰	۰/۹۵۶	۰/۹۸۸	۹۱۰/۵۰۵	۳۶۸/۱۸۶	۰/۹۵۳	۰/۹۸۶
Lu and Zhao (2010) I	۷۱۷/۴۵۷	۲۶۰/۴۴۸	۰/۹۶۳	۰/۹۹۱	۶۳۰/۰۲۴	۲۴۶/۵۶۵	۰/۹۷۷	۰/۹۹۴
Lu and Zhao (2010) II	۱۰۱۶/۰۳۱	۵۶۲/۳۲۳	۰/۹۲۵	۰/۹۷۸	۱۲۷۷/۵۵۰	۵۷۱/۷۹۳	۰/۹۰۶	۰/۹۷۰
Hatzigeorgiou (2008)	۶۹۸/۵۵۸	۲۳۷/۴۷۱	۰/۹۶۵	۰/۹۹۱	۵۷۸/۱۳۷	۲۲۶/۵۳۴	۰/۹۸۱	۰/۹۹۵
EC4 (2004)	۷۰۵/۴۵۷	۲۵۴/۳۶۷	۰/۹۶۴	۰/۹۹۱	۶۱۷/۵۸۳	۲۳۰/۶۴۶	۰/۹۷۸	۰/۹۹۴
ANN	۳۲۹/۹۹۳	۱۷۵/۷۲۳	۰/۹۹۲	۰/۹۹۸	۳۹۷/۷۲۵	۱۸۴/۷۲۳	۰/۹۹۱	۰/۹۹۸

آموزش و در حدود ۴۵ و ۲۵ درصد در فاز تست بهبود بخشیده شده است. همچنین می‌توان بیان نمود که ضریب همبستگی ویلموت از دامنه ۰/۹۷۰ تا ۰/۹۹۵ به مقدار ۰/۹۹۸ بهبود یافته است که نشان‌دهنده یک مدل توانمند هوش مصنوعی نسبت به مدل‌های تجربی است. این روش پیش‌بینی قادر به محاسبه صحیح ظرفیت باربری ستون‌های CFST بوده و می‌تواند جهت ارزیابی ظرفی باربری و یا طراحی آتی این مقاطع به نحو توانمند مورد استفاده قرار گیرند.

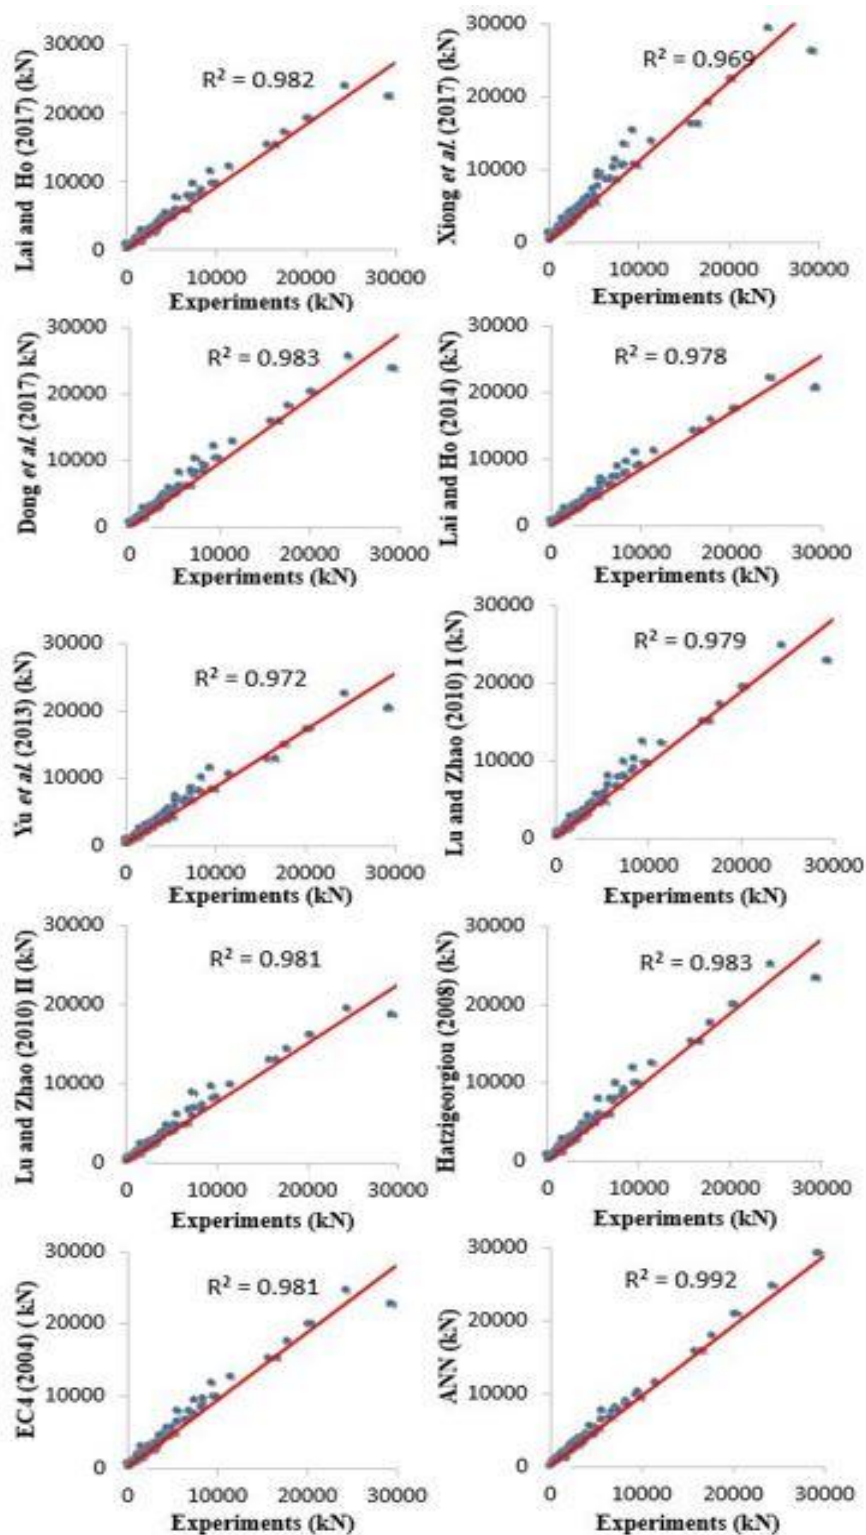
در شکل (۴) نمودار پراکنش نسبت مقاومت حداکثر آزمایشگاه به مقاومت حداکثر پیش‌بینی شده مدل‌های مختلف به تنش فشاری بتن در دو فاز آموزش و تست رسم شده است. مشخص است که کمترین ضریب تغییرات مدل‌سازی (نسبت انحراف معیار عدم قطعیت در مدل‌سازی به میانگین (STD/Mean)) در مدل‌های Dong et al., EC4, مدل اول Lu and Zhao و مدل Hatzigeorgiou با نسبت ۰/۱۳۷ حاصل شده است. لذا می‌توان بیان نمود که بر اساس روابط ساده سه مدل تجربی فوق در مقابل مدل پیچیده آیین نامه EC4 می‌توان تخمین حداکثر صحیح‌تری با عدم قطعیت کمتر برآورد نمود. از طرفی، روش ارائه شده هوش مصنوعی با نسبت ۰/۱۱۱ نه تنها صحت مدل‌سازی را افزایش داده بلکه، منجر به کاهش عدم قطعیت مدل‌سازی نسبت به سایر مدل‌های پیش‌بینی گردیده است. با توجه به شکل (۴) بیشترین خطای مدل‌سازی به دلیل تعداد داده‌های بالا برای بتن با مقاومت معمولی در دامنه ۲۰ تا ۴۰ مگاپاسکال بر اساس مدل‌های تجربی حاصل شده اما روش شبکه عصبی به‌طور چشمگیری صحت مدل‌سازی در این محدوده را بهبود بخشیده است.



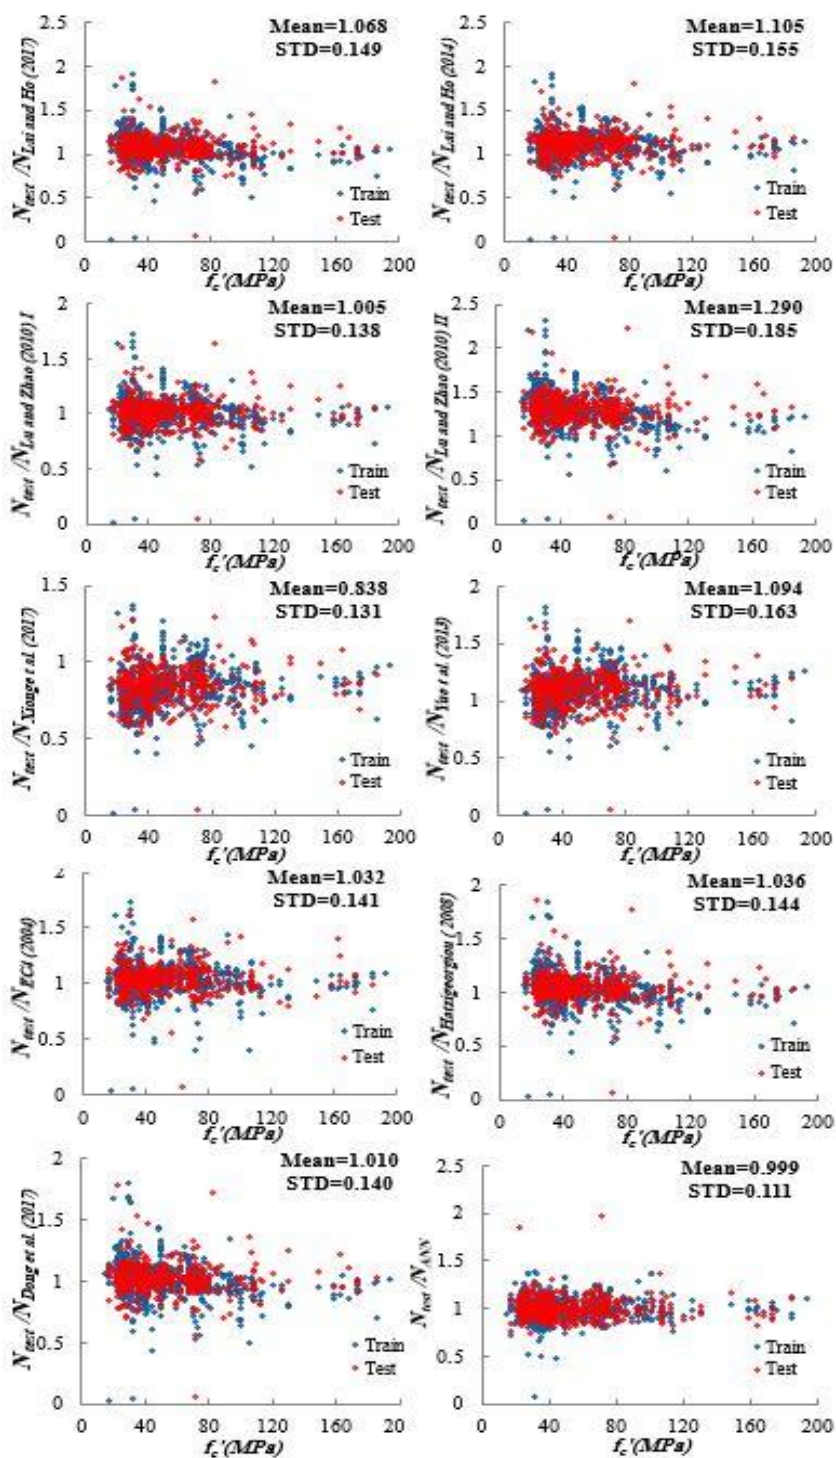
شکل ۲ نسبت d/MAE مدل‌های پیش‌بینی و شبکه عصبی

بر اساس نتایج حاصل از شکل (۳) می‌توان نتیجه گرفت که مدل‌های Lai and Ho (2017) و Lu and Zhao, Dong et al. دوم و Hatzigeorgiou آیین‌نامه EC4 عملکردی بهتر و برابر در پیش‌بینی مقاومت محوری حداکثر نشان داده‌اند و مدل ارائه شده توسط Xiong et al. (2017) بدترین پیش‌بینی را نسبت به سایر مدل‌ها با ضریب همبستگی برابر با ۰/۹۶۹ نشان داده است.

بر مبنای نتایج حاصل از جدول (۳) و شکل (۳) مدل شبکه عصبی بهترین پیش‌بینی مقاومت محوری حداکثر ستون‌های CFST را در میان مدل‌های آیین‌نامه‌ای و تجربی دارا است؛ بنابراین، می‌توان بیان نمود که استفاده از شبکه عصبی مصنوعی یک ابزار ساده و کارا جهت برآورد مقاومت حداکثر محوری ستون‌های دایره‌ای CFST است 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. به‌نحوی که با ارزیابی بهترین نتایج مقایسه از مدل‌های تجربی و آیین‌نامه‌ای می‌توان نتیجه گرفت که مدل غیرخطی شبکه عصبی مصنوعی ریشه میانگین مربعات خطا و میانگین قدر مطلق خطا به ترتیب در حدود ۱۰۰ و ۴۵ درصد در فاز



شکل ۳ نمودار پراکندگی داده‌های پیش‌بینی و آزمایشگاهی مقاومت حداکثر ستون‌های فولادی پرشده با بتن



شکل ۴ نسبت مقاومت حداکثر آزمایشگاه به مقاومت حداکثر پیش‌بینی‌شده مدل‌های مختلف به تنش فشاری بتن در بخش آموزش (نقاط آبی) و تست (نقاط قرمز)

مدل‌های موجود این است که بر اساس مصالح با مقاومت بالا و فوق بالا ارائه گردیده است.

بر اساس نتایج شکل (۵)، شاهد یک رابطه غیرخطی بین افزایش مقاومت بتن و تنش تسلیم فولاد بر اساس مدل شبکه عصبی هستیم. درحالی‌که مدل‌های تجربی و آیین‌نامه‌ای قادر به بیان چنین ارتباطی نیستند. برای بتن‌های با مقاومت فشاری کمتر از ۸۰ مگاپاسکال و فولاد با تنش تسلیم کمتر از ۳۵۰ مگاپاسکال، انطباق بالایی بین مدل شبکه عصبی با سایر مدل‌های پیش‌بینی مشاهده می‌گردد. لذا، این مدل‌ها برای نمونه‌های با مقاومت فشاری کمتر از ۸۰ مگاپاسکال، می‌تواند عملکرد مناسبی داشته باشند و رفتار ترکیبی بتن و فولاد را به نحوی مناسب پیش‌بینی نمایند؛ اما افزایش مقاومت بتن از ۱۰۰ مگاپاسکال و نیز فولاد با مقاومت تسلیم بالا منجر به توزیع غیرخطی تنش فولاد و بتن می‌گردد که روابط ساده تجربی و آیین‌نامه‌ای قادر به در نظر گرفتن این ارتباط نیستند.

اثر نسبت ارتفاع به قطر ستون (H/D)



مقاومت حداکثر پیش‌بینی شده چهار رده مقاومت فشاری بتن (۳۰، ۵۰، ۸۰ و ۱۲۰ مگاپاسکال) در $\sigma_{sy} = 360\text{MPa}$ برای H/D مختلف در شکل (۶) نشان داده شده است. همان‌گونه که مشاهده می‌گردد با کاهش نسبت H/D مقاومت حداکثر افزایش یافته است. این امر نشان‌دهنده آن است که با افزایش نسبت H/D اثر محصورکننده لوله فولادی کاهش یافته که موجب کاهش مقاومت حداکثر می‌گردد. قابل توجه است که در میان مدل‌های ارائه شده در جدول (۱) تنها آیین‌نامه EC4 اثر ارتفاع ستون را در نظر می‌گیرد. درحالی‌که سایر مدل‌های توسعه داده شده جدید، قادر به در نظر گرفتن اثر ابعادی ستون CFST (نسبت ارتفاع به قطر) نمی‌باشند. لذا، مدل شبکه عصبی به‌عنوان یک رابطه طراحی مناسب همانند مدل EC4 قادر به در نظر گرفتن نسبت ابعادی ستون است. مشخص است این ارتباط با شیب ملایم به‌صورت خطی تابعی از نسبت ارتفاع به قطر است.

مدل‌های شبکه عصبی و مدل تجربی (Dong et al. (2017) برای پیش‌بینی مقاومت نهایی ستون‌های با مقاومت فشاری فوق بالا (تنش فشاری بیشتر از ۱۲۰ مگاپاسکال) می‌تواند برآورد با عدم قطعیت کمتری نسبت به سایر مدل‌ها ارائه دهند اما مدل (Dong et al. (2017) برای بتن‌های با مقاومت معمولی عدم قطعیت بالاتری را نشان داده است. از آنجایی‌که در ساختار آموزش مدل هوش مصنوعی بر مبنای شبکه عصبی چندلایه، از انواع داده آزمایشگاهی با بتن مقاومت معمولی و بالا استفاده شده است. لذا، این مدل توانمندی قابل توجهی در پیش‌بینی مقاومت نهایی ستون‌ها با بتن مقاومت بالا، نسبت به مدل‌های تجربی نشان داده است.


اثرات تنش جاری شدن فولاد و مقاومت فشاری بتن بر رفتار ستون‌های CFST

در شکل (۵) تأثیر افزایش مقاومت فشاری بتن و تنش جاری شدن فولاد بر مقاومت حداکثر یک ستون CFST با قطر ۱۰۰ میلی‌متر، ارتفاع ۳۰۰ میلی‌متر و ضخامت لوله ۲ میلی‌متر نشان داده شده است. نتایج پیش‌بینی مدل‌های مختلف و شبکه عصبی نشان می‌دهد که با افزایش مقاومت فشاری بتن از محدوده ۱۰۰ تا ۱۹۰ مگاپاسکال اختلاف قابل توجهی در پیش‌بینی مقاومت حداکثر (N_{pre}) بین مدل‌های پیش‌بینی موجود و مدل شبکه عصبی است. این بدان معنا است که این مدل‌ها قادر به پیش‌بینی صحیح به ازای بتن‌های با مقاومت بالا و فوق بالا نمی‌باشند. درحالی‌که شبکه عصبی قادر به بیان یک ارتباط غیرخطی بین مقاومت نهایی و مقاومت فشاری بتن است. افزایش مقاومت فشاری بتن موجب انتقال مناسب تنش محصورشدگی بین بتن و فولاد می‌گردد که باعث افزایش مقاومت نهایی ستون می‌گردد.

همچنین با افزایش تنش جاری شدن فولاد از محدوده ۳۵۰ تا ۸۵۰ مگاپاسکال نیز اختلاف چشمگیری بین مدل‌های موجود و مدل‌های (Xiong et al. (2017) و شبکه عصبی است که نشان‌دهنده ضعف مدل‌های موجود در استفاده از فولاد با مقاومت بالا و فوق بالا است. علت پیش‌بینی بهتر مدل (Xiong et al. (2017) نسبت به سایر



شکل ۵ مقایسه افزایش نسبت مقاومت به واسطه محصورشدگی خارجی برای مدل‌های مختلف پیش‌بینی




شکل ۶ اثر نسبت ابعادی H/D بر مقاومت حداکثر


D/t در شکل (۷) نشان داده شده است. مشخص است که مقاومت حداکثر با کاهش نسبت D/t افزایش یافته است.

اثر نسبت قطر به ضخامت ستون (D/t)

مقاومت حداکثر یک ستون با چهار نوع f'_c (۳۰، ۵۰، ۸۰ و ۱۲۰ مگاپاسکال) و $\sigma_{sy} = 360\text{MPa}$ در برابر نسبت



شکل ۸ اثر نسبت مقاومتی σ_{sy}/E_s بر مقاومت حداکثر



شکل ۷ اثر نسبت ابعادی D/t بر مقاومت حداکثر

نسبت افزایش ظرفیت محوری به ازای σ_{sy}/E_s کمتر از ۲۰۰۰ ارتباط غیرخطی را نشان داده است اما با افزایش σ_{sy}/E_s بیشتر از ۲۰۰۰ شاهد یک رابطه با شیب ثابت هستیم. این بدان معنا است که اثر محصورشدگی لوله فولادی برای هسته بتنی برای مقاومت‌های پایین فولاد چندان مشهود نبوده و یک رفتار غیرخطی از این نوع مقاطع مرکب را نشان می‌دهد. درحالی‌که با افزایش مقاومت فولاد، نه تنها عملکرد توأم بتن و فولاد بهبود یافته بلکه، متناظراً مقاومت نهایی ستون CFST نیز افزایش می‌یابد.

نتیجه‌گیری

در این پژوهش، یک مدل برای پیش‌بینی مقاومت نهایی ستون‌های دایره‌ای فولادی پرشده با بتن (CFST) توسط شبکه عصبی مصنوعی معرفی گردیده است. صحت مدل شبکه عصبی ارائه‌شده با هشت مدل تجربی و آیین‌نامه EC4 مورد ارزیابی قرار گرفته است. بر اساس نتایج حاصل از مدل‌سازی می‌توان مطالب زیر را استخراج نمود.

۱. الگوریتم شبکه عصبی با ضریب $0/992$ بهترین انطباق بین داده‌های پیش‌بینی و آزمایشگاهی را نسبت به سایر مدل‌های نشان داده است.

این امر نشان می‌دهد که در نسبت‌های کمتر D/t ، اثر محصورکننده لوله فولادی بیشتر است که منجر به افزایش بیشتر مقاومت می‌گردد. همچنین می‌توان مشاهده کرد که یک ارتباط غیرخطی بین کاهش مقاومت و نسبت ابعادی قطر ستون به ضخامت لوله فولاد هستیم که نرخ کاهش مقاومت به ازای نسبت ابعادی D/t کمتر از ۶۰ اختلاف شدیدتری را نسبت به D/t بزرگ‌تر از ۸۰ نشان داده شده است.

اثر نسبت تنش تسلیم به مدول الاستیسیته

(σ_{sy}/E_s) فولاد

مقاومت حداکثر پیش‌بینی‌شده توسط شبکه عصبی با چهار نوع f'_c برابر با ۳۰، ۵۰، ۸۰ و ۱۲۰ مگاپاسکال نسبت به تنش تسلیم به مدول ارتجاعی فولاد (σ_{sy}/E_s) در شکل (۸) نشان داده شده است. مشخص است که با افزایش نسبت مقاومتی فولاد σ_{sy}/E_s ، اثر محصورکننده فولاد افزایش یافته که منجر به افزایش مقاومت محوری گردیده است. در مدل‌های معمول آیین‌نامه‌ای و همچنین روابط تجربی که در جدول (۱) ارائه شده، اثرات تنش تسلیم به مدول ارتجاعی فولاد را نمی‌توان ارزیابی نمود. درحالی‌که در مدل توسعه داده شده شبکه عصبی این نسبت مقاومتی در برآورد مقاومت نهایی ستون‌های کامپوزیتی لحاظ شده است.

۲. در صورت استفاده از مصالح با مقاومت بالا و فوق بالا، مدل‌های تجربی و آیین‌نامه‌ای قادر به پیش‌بینی دقیق مقاومت نیستند. درحالی‌که مدل شبکه عصبی برآورد دقیق‌تر در محدوده گسترده تری از مقاومت‌های بتن پیش‌بینی می‌کند.
۳. برای بتن‌های با مقاومت فوق بالا (تنش فشاری بزرگ‌تر از ۱۰۰ مگاپاسکال)، ارتباط غیرخطی بین مقاومت بتن و مقاومت نهایی محوری مشاهده شده است؛ اما مدل‌های تجربی قادر به بیان این ارتباط غیرخطی نیستند.
۴. افزایش نسبت ابعادی ارتفاع به قطر ستون، موجب کاهش ظرفیت باربری ستون می‌گردد.
۵. نسبت ابعادی قطر ستون به ضخامت لوله فولادی بر خلاف نسبت ابعادی قطر به ارتفاع ستون رفتار غیرخطی برای ستون‌های CFST نشان داده است. به نحوی که با افزایش نسبت قطر به ضخامت لوله فولادی از مقاومت نهایی ستون کاسته شده است.
۶. با افزایش نسبت تنش تسلیم به مدول ارتجاعی فولاد، اثر محصورکننده فولاد افزایش یافته لذا، عملکرد توأم بتن و فولاد بهبود می‌یابد.

مراجع

1. Uy, B., "Strength of short concrete filled high strength steel box columns", *J. Constr. Steel Res.*, Vol. 57(2), pp. 113-134, (2001).
2. Han, L.H., "Flexural behaviour of concrete-filled steel tubes", *Journal of Constructional Steel Research*, Vol. 60(2), pp. 313-337, (2004).
3. Bradford, M.A., Loh, H.Y. and Uy, B., "Slenderness limits for filled circular steel tubes", *Journal of Constructional Steel Research*, Vol. 58(2), pp. 243-252, (2002).
4. Tang, Y.Q., Zhou, Z.H. and Chan, S.L., "An accurate curved beam element based on trigonometrical mixed polynomial function", *International Journal of Structural Stability and Dynamics*, Vol. 13(4), pp. 1-19, (2013).
5. Lai, M.H. and Ho, J.C.M., "Confinement effect of ring-confined concrete-filled-steel-tube columns under uni-axial load", *Engineering Structures*, Vol. 67, pp.123-141, (2014).
6. Uy, B. and Das, S., "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, (1997).
7. Lai, M.H. and Ho, J.C.M., "An analysis-based model for axially loaded circular CFST columns", *Thin-Walled Structures*, Vol. 119, pp. 770-781, (2017).
8. EC4., "Design of composite steel and concrete structures", Part 1-1: General rules and rules for buildings., En-1994-1-1., European committee for standardization: British Standards Institution, (2004).
9. Dong, C.X., Kwan, A.K.H. and Ho, J.C.M., "Effects of external confinement on structural performance of concrete-filled steel tubes", *Journal of Constructional Steel Research*, Vol.132, pp. 72-82, (2017).
10. Xiong, M.X., Xiong, D.X. and Liew, J.Y.R., "Axial performance of short concrete filled steel tubes with high- and ultra-high- strength materials", *Engineering Structures*, Vol.136, pp. 494-510, (2017).

11. Lai, M.H. and Ho, J.C.M., "Confinement effect of ring-confined concrete-filled-steel-tube columns under uni-axial load", *Engineering Structures*, Vol. 67, pp. 123-141, (2014).
12. Yu, M., Zha, X. and Li, Y., "A unified formulation for circle and polygon concrete-filled steel tube columns under axial compression", *Engineering Structures*, Vol. 49, pp. 1-10, (2013).
13. Lu, Z.H. and Zaho, Y.G., "Suggested empirical models for the axial capacity of circular CFT stub columns", *Journal of Constructional Steel Research*, Vol. 66, pp. 850-862, (2010).
14. Hatzigeorgiou, G.D., "Numerical model for the behavior and capacity of circular CFT columns", Part II: Verification and extension, *Engineering Structures*, Vol. 30, pp. 1579-1589, (2008).
15. Chinese Code CECS., "Technical specification for concrete-filled steel tubular structures", In CECS 28: 2012, Beijing, China: China Planning Press, (2012).
16. ACI. "Building code requirements for structural concrete (ACI318-99)", Detroit (MI): American concrete institute (ACI), (1999).
17. Chinese Code DLT., "Chinese design code for steel-concrete composite structures", In: DLT 5085-1999, Beijing, China: Chinese Electricity Press, (1999).
18. Mander, J.B., Priestley, M.J.N. and Park, R., "THEORETICAL STRESS-STRAIN MODEL FOR CONFINED CONCRETE", *J. Struct. Eng.*, Vol. 114, pp. 1804-1826, (1988).
19. Lai, M.H. and Ho, J.C.M., "A theoretical axial stress-strain model for circular concrete-filled-steel-tube columns", *Engineering Structures*, Vol. 125, pp. 124-125, (2016).
20. Kwan, A.K.H., Dong, C.X. and Ho, J.C.M., "Axial and lateral stress-strain model for concrete-filled steel tubes", *Journal of Constructional Steel Research*, Vol. 122, pp. 421-433, (2016).
21. Wang, Y., Chen, P. and Zhang, Y., "Size effect of circular concrete-filled steel tubular short columns subjected to axial compression", *Thin-Walled Structures*, Vol. 120, pp. 397-407, (2017).
22. Wang, W., Ma, H., Li, Z. and Tang, Z., "Size effect in circular concrete-filled steel tubes with different diameter-to-thickness ratios under axial compression", *Engineering Structures*, Vol. 151, pp. 554-567, (2017).
23. Ding, F.X., Liu, J., Liu, X.M., Yu, Z. W. and Li, D.W., Zhang, Y., "Mechanical behavior of circular and square concrete filled steel tube stub columns under local compression", *Thin-Walled Structures*, Vol. 94, pp. 155-166, (2015).
24. Dundu, M., "Compressive strength of circular concrete filled steel tube columns", *Thin-Walled Structures*, Vol. 56, pp. 62-70, (2012).
25. Liang, Q.Q. and Fargomeni, S., "Nonlinear analysis of circular concrete-filled steel tubular short columns under axial loading", *Journal of Constructional Steel Research*, Vol. 65, pp. 2186-2196, (2009).
26. Lam, D. and Gardner, L., "Structural design of stainless steel concrete filled columns", *Journal of*

- Constructional Steel Research*, Vol. 64, pp. 1275-1282, (2008).
27. Zeghiche, J. and Chaoui, K., "An experimental behaviour of concrete-filled steel tubular columns", *Journal of Constructional Steel Research*, Vol. 61, pp. 53-66, (2005).
28. Ellobody, E., Young, B. and Lam, D., "Behaviour of normal and high strength concrete-filled compact steel tube circular stub columns", *Journal of Constructional Steel Research*, Vol. 62, pp. 706-715, (2006).
29. Yu, Z.W., Ding, F.X. and Cai, C.S., "Experimental behavior of circular concrete-filled steel tube stub columns", *Journal of Constructional Steel Research*, Vol. 63, pp. 165-174, (2007).
30. Hoang, A.L. and Fehling, E., "Numerical study of circular steel tube confined concrete (STCC) stub columns", *Journal of Constructional Steel Research*, Vol. 136, pp. 238-255, (2017).
31. Ekmekyapar, T. and Al-Eliwi, B.J.M., "Experimental behaviour of circular concrete filled steel tube columns and design specifications", *Thin-Walled Structures*, Vol. 105, pp. 220-230, (2016).
32. Zhongqiu, F., Bohai, J. and Yang, M., "The Mechanical Properties of Lightweight Aggregate Concrete Confined by Steel Tube", *Design, Construction, Rehabilitation, and Maintenance of Bridges*, Vol. 219, pp. 33-39, (2011).
33. Geng, Y., Wang, Y. and Chen, J., "Time-Dependent Behavior of Recycled Aggregate Concrete-Filled Steel Tubular Columns", *J. Struct. Eng.*, Vol. 141, pp. 1-12, (2015).
34. Chen, Z., Xu, J., Xue, J. and Su, Y., "Performance and Calculations of Recycled Aggregate Concrete-filled Steel Tubular (RACFST) Short Columns under Axial Compression", *International Journal of Steel Structures*, Vol. 14, pp. 31-42, (2014).
35. Guneyisi, E.M., Gultekin, A. and Mermerdas, K., "Ultimate Capacity Prediction of Axially Loaded CFST Short Columns", *International Journal of Steel Structures*, Vol. 16(1), pp. 99-114, (2016).
36. Lu, Y.Y., Li, N., Li, S. and Liang, H.J., "Experimental investigation of axially loaded steel fiber reinforced high strength concrete-filled steel tube columns", *J. Cent. South Univ.*, Vol. 22, pp. 2287-2296, (2015).
37. Aslani, F., Uy, B., Hur, J. and Carino, P., "Behaviour and design of hollow and concrete-filled spiral welded steel tube columns subjected to axial compression", *International Journal of Steel Structures*, Vol. 128, pp. 261-288, (2017).
38. Ellobody, E., "Numerical modelling of fibre reinforced concrete-filled stainless steel tubular columns", *Thin-Walled Structures*, Vol. 63, pp. 1-12, (2013).
39. Tam, V.W.Y., Wang, Z.B. and Tao, Z., "Behaviour of recycled aggregate concrete filled stainless steel stub columns", *Materials and Structures*, DOI 10.1617/s11527-013-0061-1, (2013).
40. Wang, Y., Chen, J. and Geng, Y., "Testing and analysis of axially loaded normal-strength recycled

- aggregate concrete filled steel tubular stub columns", *Engineering Structures*, Vol. 86, pp. 192-212, (2015).
41. O'Shea, M.D. and Bridge, R.Q., "Design of circular thin-walled concrete filled steel tubes", *Journal of Structural Engineering*, Vol. 126, pp. 1295-1303, (2000).
42. Gupta, P.K., Sarda, S.M. and Kumar, M.S., "Experimental and computational study of concrete filled steel tubular columns under axial loads", *Journal of Constructional Steel Research*, Vol. 63, pp. 182-193, (2007).
43. Mirjalili, S., Mirjalili, S.M. and Lewis, A., "Let a biogeography-based optimizer train your Multi-Layer Perceptron", *Information Sciences*, Vol. 269, pp.188-209, (2014).
44. Keshtegar, B. and Heddham, S., "Modeling daily dissolved oxygen concentration using modified response surface method and artificial neural network: a comparative study", *Neural Computing and Applications*, DOI 1007/10/s00521-017-2917-8, (2017)