

Experimental and numerical study of concrete filled double skin steel tubes using supporting vector machines and decision tree models

Seyed Tovhid Nemati Aghamaleki¹, Morteza Naghipour^{2*}, Javad Vaseghi Amiri², Mahdi Nematzadeh³

1- Phd student, Bbol Noshirvani University of Technology, Civil Eng. Dept. Babol, Iran

2- Prof., Bbol Noshirvani University of Technology, Civil Eng. Dept. Babol, Iran

3- Associated Prof., University of Mazandaran, Babolsar, Iran

ABSTRACT

In recent decades, construction of massive structures has increased around the world. These structures which are built for different purposes, should have a useful life-time. Therefore, composite structures can increase the construction costs and useful life of such structures. Therefore, CFDST members can practically increase the efficiency of composite structures. Since the diameter and thickness of the outer tube have the greatest impact on determining the bearing capacity of CFDST columns, this study investigated four different values of D/t for the outer tube including 86, 85.8, 45.6 and 44. Two types of concrete were used to fill CFDST samples including C10 and C20. Besides, a comprehensive formula for estimating the bearing capacity of CFDST columns using artificial intelligence methods is proposed. The results showed that CFDST columns with lower D_o / t_o value have higher load capacity and with increasing D_o / t_o , it is observed that the ductility decreases. As a comparison between the filled concretes in CFDST samples of C10 and C20 grades, the stress-strain curves have shown that with increasing compressive strength, the bearing capacity for CFDST columns increased by about 6%. In the modeling section, the R^2 for artificial neural network (ANN), support vector machines (SVM) and model tree (M5-MT) in the testing stage were determined to be 0.95, 0.96 and 0.97, respectively. Accordingly, the M5-MT method in the testing stage, had a better performance than other proposed methods for estimating the bearing capacity of CFDST columns. Comparison of traditional equations and AI models in estimating the bearing capacity of CFDST columns show that the formula presented by M5-MT with an average value of 1.01 and a standard deviation of 0.19 It has performed better in modeling the bearing capacity of CFDST columns than other intelligent models and traditional relationships.

All rights reserved to Iranian Society of Structural Engineering.

ARTICLE INFO

Receive Date: 26 August 2021

Revise Date: 15 October 2021

Accept Date: 07 November 2021

Keywords: Concrete-filled, Double-skin tubes, Diameter-to-thickness ratio, AI modelling, Decision tree algorithm.

doi: 10.22065/JSCE.2021.301313.2546

*Corresponding author: Morteza Naghipour

Email address: m-naghi@nit.ac.ir

بررسی آزمایشگاهی و مدل سازی ستون های دایره ای دوجداره فولادی پر شده با بتن با استفاده از ماشین های بردار پشتیبان و مدل درخت تصمیم گیری

سید توحید نعمتی آقاملکی^۱، مرتضی نقی پور^{۲*}، جواد واثقی امیری^۲، مهدی نعمت زاده^۳

۱- دانشجوی دکتری، دانشگاه صنعتی نوشیروانی بابل، ایران

۲- استاد، دانشگاه صنعتی نوشیروانی بابل، ایران

۳- دانشیار، دانشگاه مازندران، بابلسره، ایران

چکیده

سازه های کامپوزیتی می توانند هزینه های ساخت را کاهش و عمر مفید سازه های بزرگ را افزایش دهند. از این رو، ستون های دایره ای دوجداره فولادی پر شده با بتن (CFDST) کارایی سازه های کامپوزیتی را می توانند افزایش دهند. از آنجایی که قطر و ضخامت لوله خارجی بیشترین تاثیر و نقش بسزایی در تعیین ظرفیت باربری ستون های CFDST دارد، لذا در این پژوهش ۴ مقدار مختلف از نسبت قطر به ضخامت برای لوله خارجی شامل ۸۶، ۸۵/۸، ۴۵/۶ و ۴۴ برای ساخت ۱۶ نمونه بکار گرفته شد. دو نوع بتن برای پر کردن نمونه های CFDST شامل C10 و C20 استفاده شد. سپس، رابطه ای جامع برای تخمین ظرفیت باربری ستون های CFDST با استفاده از روش های هوشمند مصنوعی ارائه شد. نتایج نشان داد که ستون های CFDST با مقدار D_o/t_o کمتر، دارای ظرفیت باربری بیشتری می باشند. همچنین، با افزایش D_o/t_o مشاهده می شود که شکل پذیری کاهش می یابد. به عنوان یک مقایسه میان بتن های پر شده در نمونه های CFDST که از رده های C10 و C20 بوده است، منحنی های تنش-کرنش نشان دادند که با افزایش مقاومت فشاری بتن، ظرفیت باربری و شکل پذیری نیز افزایش می یابد. در این تحقیق، با افزایش مقاومت فشاری ظرفیت باربری برای ستون های CFDST حدوداً ۶٪ افزایش یافت. در بخش مدل سازی، شاخص آماری ضریب تعیین برای شبکه عصبی مصنوعی (ANN)، ماشین های بردار پشتیبان (SVM) و مدل درخت تصمیم گیری (M5-MT) در مرحله آزمایش به ترتیب ۰/۹۵، ۰/۹۶ و ۰/۹۷ تعیین گردید. لذا، روش M5-MT در مرحله آزمایش نیز، از عملکرد بهتری نسبت به سایر روش های پیشنهادی تخمین ظرفیت باربری ستون های CFDST داشته است. مقایسه روابط تجربی و مدل های هوشمند پیشنهادی ANN، SVM و M5-MT در تخمین ظرفیت باربری ستون های CFDST بر اساس مقادیر نرمال شده نیروی محوری نهایی نشان می دهد که رابطه ارائه شده از M5-MT با مقدار میانگین ۱/۰۱ و انحراف معیار ۰/۱۹ عملکرد بهتری در مدل سازی ظرفیت باربری ستون های CFDST نسبت به دیگر روش های هوشمند و روابط تجربی داشته است.

کلمات کلیدی: ستون های CFDST، جداره های فولادی، ظرفیت باربری نهایی، روش های هوشمند مصنوعی، مدل M5-MT.

سابقه مقاله:		شناسه دیجیتال:			
دریافت	بازنگری	پذیرش	انتشار آنلاین	چاپ	doi:
۱۴۰۰/۱۶/۰۴	۱۴۰۰/۷/۲۳	۱۴۰۰/۸/۱۶	۱۴۰۰/۸/۱۶	۱۴۰۱/۴/۰۱	https://doi.org/10.22065/JSCE.2021.301313.2546
*نویسنده مسئول:		مرتضی نقی پور			
پست الکترونیکی:		m-naghi@nit.ac.ir			

۱- مقدمه

ستون‌های فولادی پر شده با بتن (CFST) یکی از ایده‌های رایج در احداث ساختمان‌های بلند در دنیا می‌باشند. این ستون‌ها بطور روزافزونی در قاب‌های سازه‌ای مهاربندی شده و مهاربندی نشده بعنوان ستون، و تیر- ستون مورد استفاده قرار می‌گیرند. استفاده از این ستون‌ها دارای مزایای سازه‌ای از جمله مقاومت بیشتر، شکل پذیری بالاتر و قابلیت جذب انرژی بیشتر می‌باشد. افزایش مقاومت و شکل پذیری در این سیستم در واقع به علت قرارگیری بتن تحت تنش‌های فشاری چند محوره است که از گسترش ترک‌های عرضی در بتن جلوگیری می‌کند [۱ و ۲]. با وجود تمام این مزایا، اما ستون‌های CFST دارای معایبی نیز هستند که عبارتند از: ۱) تحت فشارده سازی تک محوری، فولاد قسمت بیشتری از بار خارجی را نسبت به بتن در همان سطح مقطع تقسیم می‌کند، زیرا سختی بیشتری تحت اثر کامپوزیت دارد. ۲) تحت خمش، بتن مرکزی که نزدیک به محور خنثی است، نقش ناچیزی در مقاومت خمشی دارد. ۳) تحت پیچش، بتن مرکزی سهم ناچیزی در مقاومت پیچشی دارد. ۴) اتساع الاستیک اولیه بتن تحت فشار کم است و بنابراین فشار محدود شده توسط لوله فولادی به بتن در مرحله الاستیک نسبتاً کم است [۲]. فقط تا زمان ایجاد ترک خوردگی ریز بتن در کرنش بزرگ، می‌تواند سریع‌تر افزایش یابد. بر اساس معایب ذکر شده، بدیهی است که قسمت مرکزی بتن پر شده می‌تواند به طور موثری توسط یک لوله فولادی توخالی کوچکتر با مقاومت یکسان با لوله خارجی جایگزین شود. این شکل از ساخت ستون به عنوان ستون‌های لوله‌ای دو جداره پر شده از بتن (CFDST) شناخته می‌شود. علاوه بر این، بر اساس یافته‌های یانگ و همکاران [۳ و ۴]، زمانی که ستون‌های CFDST تحت بارگذاری چرخه‌ای و بارگذاری محوری قرار می‌گیرند، انعطاف پذیری، جذب انرژی و مقاومت بالاتری نسبت به ستون‌های CFST دارند. همچنین، ستون‌های CFDST در مقابل CFST دارای عملکرد بهتر در برابر زلزله و آتش‌سوزی دارند [۵].

هانگ و همکاران [۶] رفتار ستون‌های CFST با نسبت عرض به ضخامت (D/t) بین ۴۰ تا ۱۵۰ را مورد بررسی قرار دادند و یک روش مقاوم سازی موثر برای بهبود مشخصات مکانیکی ستون‌های فوق با مقطع مستطیلی ارائه کردند. ۱۷۰ نمونه برای بررسی اثر شکل مقطع عرضی، نسبت قطر به ضخامت و آرایش سخت کننده‌ها بر مقاومت نهایی، سختی و شکل پذیری ستون‌ها ساخته شد. با مقایسه مقاومت‌های نهایی اندازه گیری شده با مقادیر بدست آمده از برخی از آیین نامه‌ها نشان داد که آیین نامه‌های موجود با بطور قابل ملاحظه‌ای مقاومت نهایی **ستون‌ستون‌های CFST دایره‌دایره‌ای** را مخصوصاً در مورد **ستون‌ستون‌های** با D/t کوچک کمتر در نظر می‌گیرند. چن و ژانگ [۷] اشاره نمودند که چسبندگی بین فولاد و بتن یک پارامتر کلیدی و حساس در **ستون‌ستون‌های CFST** است. خطای ناشی از ساخت و جمع شدگی بتن **می‌تواند** چسبندگی در سطح مشترک که در باربری موثر است را تضعیف نماید. آنها با استفاده از یک مدل اجزا محدود که با نتایج آزمایشگاهی کالیبره شده بود یک فاصله بین فولاد و بتن ایجاد و نتایج را بررسی نمودند. مدل اجزا محدود نشان داد که از افزایش فاصله و از بین رفتن اصطکاک در سطح مشترک سبب یک افت شدید در ظرفیت باربری خواهد شد. اوشی و بریدج [۸] نتایج مربوط به ۱۸ نمونه آزمایشگاهی را که تحت فشار محوری قرار گرفته بودند را ارائه نمودند. نتایج نشان داد که چسبندگی کاهش یافته امکان کماتش موضعی لوله و **شکل‌شکل** گیری ترک‌های ریز در بتن را افزایش می‌دهد. آنها همچنین اشاره کردند که در صورتیکه چسبندگی کافی بتن لوله و بتن وجود داشته باشد کماتش موضعی اتفاق نمی‌افتد. بنابراین محصور نمودن ستون‌های CFST سبب جلوگیری از اتساع جانبی فولادی شده و به حفظ چسبندگی کمک می‌نماید.

بررسی‌های ژائو [۹] نشان داد **ستون‌ستون‌های CFDST** مزایای زیادی نسبت به ستون‌های CFST مانند سبکی، مقاومت و قابلیت جذب انرژی بیشتر را دارا **می‌باشند**. تحقیقات یانگ و همکاران [۱۰] نیز مشابه ژائو [۹] مزایای ستون‌های CFDST را نسبت به **ستون‌ستون‌های CFST** در مورد شکل پذیری، مقاومت و جذب انرژی به اثبات رساند. نتایج مشابهی نیز توسط ناکانیشی [۱۱] بدست آمد. لی و همکاران [۵] همچنین نشان دادند که **ستون‌ستون‌های CFDST** رفتار بهتری نسبت به **ستون‌ستون‌های CFST** در هنگام **آتش‌آتش**-سوزی دارند. وی و همکاران [۱۲] و [۱۳] ۲۶ نمونه ستون کوتاه CFDST با قطر لوله خارجی ۷۴/۷ mm تا ۱۱۴/۳ mm و قطر لوله داخلی ۶۱/۲ mm تا ۸۸/۹ mm را مورد آزمایش قرار دادند نسبت D/t لوله‌های خارجی بین ۴۳ تا ۱۶۹، بتن مصرفی از نوع پلیمری با مقاومت مکعبی ۷۵ مگاپاسکال، تنش تسلیم لوله‌های داخلی و خارجی به ترتیب ۲۱۶ تا ۵۱۲ و ۲۵۵ تا ۵۲۴ مگاپاسکال و طول تمام نمونه‌ها

¹ Concrete Filled Steel Tubular

² Concrete Filled Double Skin Steel Tubes

۲۲۹mm در نظر گرفته شد. شکست نمونه‌ها بصورت کمانش موضعی لوله‌های خارجی و داخلی در واسط ارتفاع نمونه به همراه شکست برشی بتن در ناحیه کمانش مشاهده گردید. همچنین مقاومت نمونه‌ها در حدود ۱۵٪ بیشتر از مجموع مقاومت تک تک اجزای مقطع به دست آمد که نشانگر تاثیر مثبت محصور شدگی می‌باشد.

ژائو و همکاران [۱۴] تحقیقاتی را بر روی ۶ نمونه ستون کوتاه CFDST به طول ۴۰۰mm انجام دادند. مقاومت نمونه مکعبی بتن مصرفی ۷۸/۴ مگاپاسکال، مقاومت تسلیم لوله‌های داخلی و خارجی ۳۹۵ تا ۴۵۴ مگاپاسکال، قطر لوله‌های خارجی ۱۱۴mm و ۱۶۵mm، قطر لوله‌های داخلی ۴۸mm و ۱۰۲mm، نسبت D/t لوله‌های خارجی و داخلی به ترتیب ۱۹ تا ۵۷ و ۱۷ تا ۳۳ در نظر گرفته شد. مشابه تحقیق وی و تائو، در این نمونه‌ها نیز لوله خارجی براساس کمانش به خارج و لوله داخلی براساس کمانش به داخل دچار شکست گردیدند. مقاومت نمونه‌ها در حدود ۴٪ بیشتر از مجموع مقاومت تک تک اجزای مقطع بدست آمد که نشانگر تاثیر ناچیز محصور شدگی در این تحقیق بوده است. یوناکا و همکاران [۱۵] ۱۲ نمونه ستون کوتاه شامل ۹ نمونه CFDST و ۳ نمونه CFST را مورد آزمایش قرار دادند. مقاومت مکعبی بتن ۲۳ مگا پاسکال، قطر لوله‌های خارجی ۱۵۸mm و قطر لوله‌های داخلی ۳۹/۷۷mm و ۱۱۴mm، مقاومت تسلیم لوله‌های خارجی و داخلی ۲۲۱ تا ۳۰۸ مگاپاسکال و طول نمونه‌ها ۴۵۰mm در نظر گرفته شد. مشابه تحقیقات قبلی لوله‌های داخلی و خارجی به ترتیب دچار کمانش موضعی داخلی و خارجی و بتن دچار شکست برسی گردید. نتایج نشان داد در برخی نمونه‌های CFDST مقاومت نمونه‌ها ۰٪ تا ۴۱٪ بیشتر از مقادیر پیش‌بینی شده بود که بیانگر تاثیر محصور شدگی در برخی نمونه‌های CFDST می‌باشد که با افزایش قطر لوله‌های داخلی، اثر محصور شدگی کاهش می‌یافت. اکمکیپار و حسن [۱۶] تاثیر لوله‌های فولادی داخلی تحت اثر بارگذاری را در ستون‌های CFDST مورد بررسی قرار دادند. آنها در مطالعه خود ۱۶ نمونه را با دو نسبت متفاوت D/t به همراه دو نوع مختلف بتن معمولی و بتن با مقاومت بالا ساخته و مورد آزمایش قرار دادند. برای اینکه بتوان تاثیر پارامترها را تجزیه و تحلیل کرد، حالت‌های خرابی، بارگذاری محوری در برابر منحنی تنش-کرنش و نسبت‌های سهم بتن و فولاد بررسی شد. نتایج نشان داد که در صورت استفاده از پیکربندی مناسب لوله داخلی فولادی، ستون‌های CFDST می‌توانند عملکرد بیشتری نسبت به ستون‌های CFST داشته باشند. علاوه بر این، لوله داخلی به طور مداوم با بتن پر شده کار می‌کند و نقش مهمی در کاهش حالت خرابی CFDST حتی با بتن با مقاومت بالا دارد. گوین و همکاران [۱۷] با استفاده از شبکه عصبی مصنوعی به مدلسازی و پیش‌بینی مقاومت فشاری ستون‌های CFST تحت بارگذاری محوری پرداختند. در مطالعه آنها، ۲۴۱ نمونه آزمایشگاهی از تحقیقات پیشین برای ساختن شبکه مدل جمع‌آوری شد. آنها برای بهینه کردن شبکه مدل پیشنهادی خود از الگوریتم بهینه‌سازی ازدحام ذرات استفاده کردند و مدل ترکیبی خود را با دیگر روش‌های هوشمند مقایسه کردند. نتایج نشان داد که روش ترکیبی پیشنهادی نسبت به دیگر مدل‌ها دارای دقت بیشتری در پیش‌بینی مقاومت فشاری ستون‌های CFST داشته است. وو و همکاران [۱۸] مشخصه مقاومتی ستون‌های CFST تحت بارگذاری محوری را با استفاده از مدل گرادیان درختی تقویت شده مدل‌سازی کردند. داده های جمع‌آوری شده در پژوهش آنها ۱۰۰۰ تست از ستون‌های CFST بوده که برای آموزش و آزمایش مدل پیشنهادی در نظر گرفته شد. بر اساس نتایج، مدل گرادیان درختی تقویت شده نسبت به مدل‌های درخت تصمیم‌گیری و ماشین‌های بردار پشتیبان دارای دقت بهتری در مدل‌سازی بوده است.

آنچه این تحقیق را از دیگر مطالعات متمایز می‌سازد، ساخت ۱۶ نمونه از ستون‌های CFDST با ۴ نسبت مختلف D/t برای لوله خارجی و ۲ نسبت مختلف برای لوله داخلی و همچنین استفاده از رده‌های C10 و C20 از بتن‌های معمولی جهت ارزیابی رفتار مکانیکی ستون‌های CFDST می‌باشد. همچنین، شبیه‌سازی مقاومت محوری نهایی ستون‌های CFDST با استفاده از روش‌های هوشمند مصنوعی نظیر شبکه عصبی مصنوعی (ANN) و ماشین‌های بردار پشتیبان (SVM) و مدل درخت تصمیم‌گیری (M5-MT) در کنار ارزیابی آزمایشگاهی رفتار این نوع از ستون‌ها می‌باشد که هر یک از این روش‌های هوشمند رابطه‌ای در جهت پیش‌بینی مقاومت محوری نهایی ستون‌های CFDST با قطرها و ضخامت‌های مختلف و همچنین مقاومت‌های مختلف بتن‌ها ارائه می‌دهد.

³ Artificial Neural Network

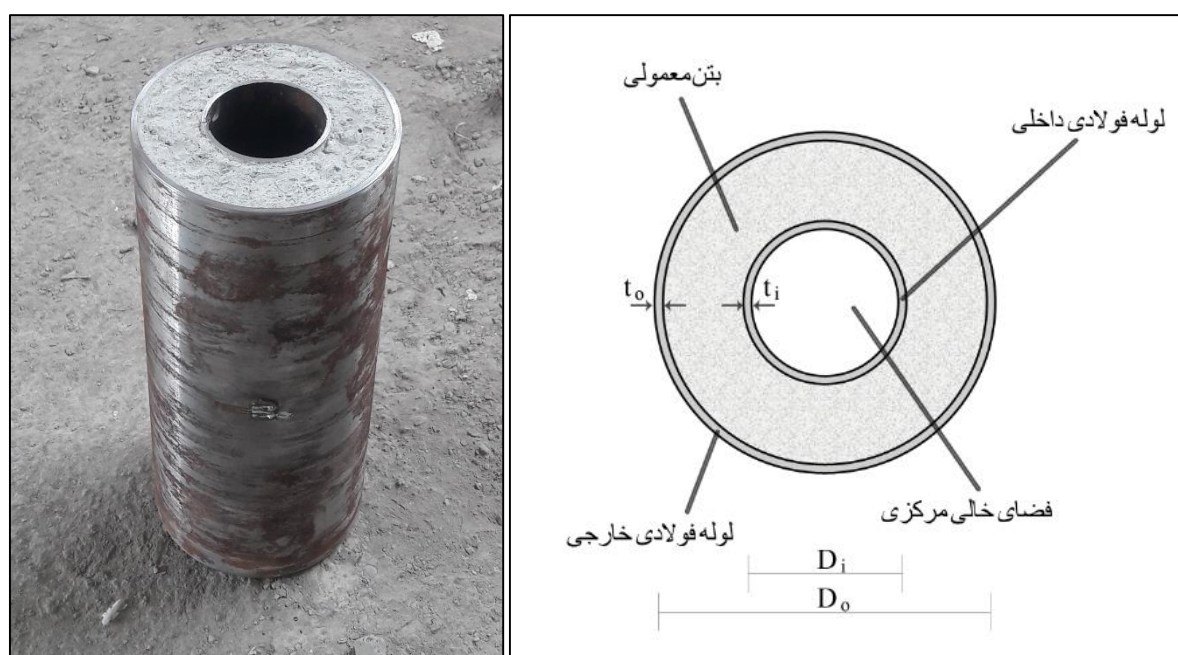
⁴ Support Vector Machine

⁵ M5 Model Tree

۲- برنامه آزمایشگاهی

۲-۱- مراحل ساخت نمونه

در این مطالعه از ۱۶ نمونه CFDST با مقادیر مختلف D_o/t_o ، D_i/t_i و f_c مورد بررسی آزمایشگاهی قرار گرفت و تست شد. ۸ نمونه از ستون‌های CFDST از بتن رده C10 و ۸ نمونه هم از بتن رده C20 پر شد. برای لوله‌های داخلی دو مقدار مختلف قطر ۳۹ و ۴۱ میلیمتر و برای لوله خارجی چهار مقدار مختلف از قطر شامل ۸۶mm، ۸۸mm، ۱۱۱/۶mm و ۱۱۴mm در نظر گرفته شد. ارتفاع تمامی نمونه‌های ساخته برابر با ۲۵۰ میلی‌متر بوده است و از هر مشخصه برای ساخت ستون‌های CFDST، دو نمونه ساخته شد. همچنین، برای دستیابی به ضخامت‌های مختلف از لوله‌های فولادی، از یک دستگاه برش برای تراش سطح فولاد استفاده شد. طرح شماتیک ستون CFDST پر شده از بتن معمولی در شکل ۱ ارائه شده است. جدول ۱ نیز مشخصات نمونه‌های ساخته شده در این مطالعه را نشان می‌دهد.



شکل ۱: طرح شماتیک ستون‌های دو جداره فولادی پر شده از بتن


جدول ۱: مشخصات نمونه‌های ساخته شده آزمایشگاهی

Tag	D_o (mm)	t_o (mm)	D_i (mm)	t_i (mm)	L/D_o	D_o/t_o	D_i/t_i	f'_c (MPa)
SN86-39(20)	86	1	39	1	2.71	86	39	19.51
SN86-39(10)	86	1	39	1	2.70	86	39	10.35
SN86-39(20)	86	1	41	2	2.72	86	20.5	20.92
SN86-39(10)	86	1	41	2	2.72	86	20.5	9.84
SN44-39(20)	88	2	39	1	2.65	44	39	20.18
SN44-39(10)	88	2	39	1	2.65	44	39	9.84
SN44-20.5(20)	88	2	41	2	2.65	44	20.5	21.85
SN44-20.5(10)	88	2	41	2	2.66	44	20.5	11.01

SN85.8-39(20)	111.6	1.3	39	1	2.10	85.84	39	19.51
SN85.8-39(10)	111.6	1.3	39	1	2.08	85.84	39	10.35
SN85.8-20.5(20)	111.6	1.3	41	2	2.10	85.84	20.5	20.92
SN85.8-20.5(10)	111.6	1.3	41	2	2.11	85.84	20.5	9.84
SN45.6-39(20)	114	2.5	39	1	2.09	45.6	39	20.18
SN45.6-39(10)	114	2.5	39	1	2.01	45.6	39	9.84
SN45.6-20.5(20)	114	2.5	41	2	2.07	45.6	20.5	21.85
SN45.6-20.5(10)	114	2.5	41	2	2.06	45.6	20.5	11.62

۲-۲- آماده سازی ستون ها برای انجام آزمون

پس از ساخت نمونه ها در این تحقیق، مقادیر نیرو-جابجایی برای ستون های CFDST ساخته شده آزمایشگاهی توسط تکنیک کرنش سنج تصویری (DIC) ثبت شدند. DIC یک روش نوین بوده که می تواند برای اندازه گیری دقیق کرنش بکار گرفته شود. به واسطه قابلیت این روش برای دریافت سریع داده ها، این تکنیک برای تعیین ویژگی های مواد در هردو محدوده الاستیک و پلاستیک بسیار مناسب است. این روش همچنین مزایایی همانند full-field غیر تماسی و با دقت بالا در اندازه گیری جابجایی و کرنش دارد. در روش DIC موقعیت نقاط فیزیکی موجود در تصویر مرجع با تصاویر تغییر شکل یافته تعقیب و آنالیز می گردد. برای دستیابی به این هدف، مربع کوچکی از یک پیکسل بر روی الگوی نقاط اطراف نقطه مورد نظر در تصویر مرجع در نظر گرفته شده و با موقعیت آن در تصاویر بعدی تغییر شکل یافته مقایسه می گردد. بر اساس این تکنیک، دو نقطه در بالا و پایین نمونه ها مطابق شکل ۲ برای بدست آوردن جابجایی به ازای نیرو در هر ثانیه علامت گذاری می شود.



شکل ۲: الف) سیستم ثبت DIC، ب) نحوه علامت گذاری دو نقطه برای ثبت جابجایی به ازای نیرو

آزمایش نمونه ها پس از عمل آوری ۲۸ روزه و با استفاده از دستگاه تست ELE با ظرفیت ۲۰۰۰ کیلو نیوتون انجام شد. میزان افزایش بار تا جایی ادامه یافت تا نمونه ها به مرحله شکست برسند. میانگین نرخ افزایش بار ۴۲ کیلونیوتون در دقیقه برابر با ۰/۲۹ مگاپاسکال بر ثانیه بوده که بر اساس آیین نامه ASTM C39M انجام پذیرفت [۱۹].

⁶ Digital Image Correlation

۳- معرفی مدل‌های هوشمند مصنوعی

۳-۱- شبکه‌های عصبی مصنوعی (ANN)

المان پردازشگر پایه شبکه‌های عصبی، نرون‌های مصنوعی یا گره نامیده می‌شوند. در مدل ریاضی ساده‌شده عصب، تأثیرات سیناپس‌ها با وزن‌های اتصال که اثر سیگنال‌های ورودی را بیان می‌کنند ارائه می‌شوند. همچنین خاصیت غیرخطی یا خطی عصب‌ها به‌وسیله تابع انتقال (فعال‌سازی یا تحریک) نمایندگی می‌شود [۲۰]. عصب با دریافت سیگنال از لایه قبل خود تحریک شده و جمع وزن‌های سیگنال‌های ورودی را محاسبه کرده و توسط تابع تحریک به لایه بعدی منتقل می‌کند. قابلیت آموزش شبکه عصبی با تنظیم وزن‌ها با توجه به الگوریتم آموزش به دست می‌آید. ورودی یک عصب از ضرب خروجی عصب‌های متصل به آن در وزن‌ها حاصل می‌شود [۲۱]. حاصل جمع وزن‌های ورودی با معادله ۱ محاسبه می‌شود.

$$(net)_j = \sum_{i=1}^n w_i o_i + b \quad (1)$$

که $(net)_j$ حاصل جمع وزن عصب i ام برای ورودی‌های لایه قبل که دارای n عصب است، است. w_i وزن بین عصب i ام در لایه قبل و عصب j و O_i خروجی عصب i ام در لایه قبل است. کمیت b بایاس نام دارد و ثابتی برای تنظیمات داخلی عصب j ام می‌باشد [۲۰]. تابع محرک، خروجی یک‌لایه از شبکه را محاسبه می‌کند و انواع متفاوتی دارد و می‌تواند حالتی خطی یا غیرخطی داشته باشد. توابع محرکی که بیش‌ترین استفاده را در مطالعات گوناگون دارند شامل تانژانت سیگموید^۷ و لوگاریتمیک سیگموید^۸ برای حالات غیرخطی و تابع تحریک پیورلین^۹ برای حالت خطی است که به ترتیب با معادلات ۲ تا ۴ تعیین می‌گردند [۲۲].

$$a = \text{tansig}(n) = \frac{2}{(1 + \exp(-2*n)) - 1} \quad (2)$$

$$a = \text{logsig}(n) = \frac{1}{(1 + \exp(-n))} \quad (3)$$

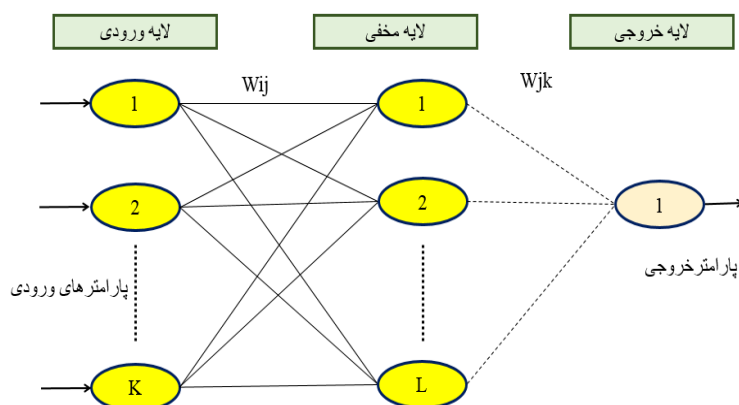
$$a = \text{purelin}(n) = n \quad (4)$$

شبکه‌های عصبی پیش‌خور مشهورترین و پرکاربردترین شبکه عصبی مصنوعی است که با نام‌های متفاوتی از جمله شبکه عصبی چندلایه پرسپترون شناخته شده‌اند. شبکه عصبی پرسپترون توسط فرانک روزنالت در سال ۱۹۵۸ میلادی ابداع شد [۲۱]. این شبکه‌ها دارای سه لایه ورودی، پنهان و خروجی می‌شوند (شکل ۳). در شبکه‌های عصبی پیش‌خور سیگنال‌های ورودی از واحدهای ورودی به سمت واحدهای خروجی در جریان هستند [۲۳].

⁷ Tangent Sigmoid

⁸ Log Sigmoid

⁹ Purelin



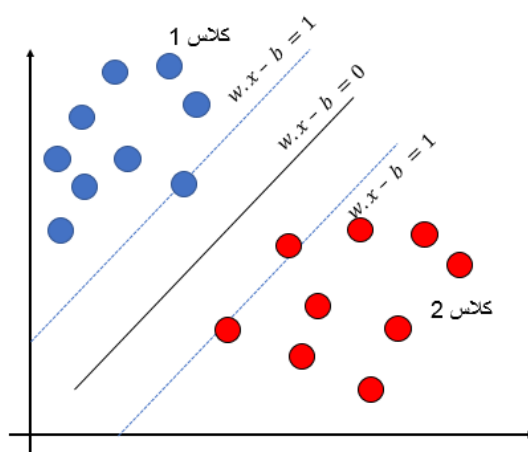
شکل ۳: معماری شبکه عصبی مصنوعی

۲-۲- ماشین بردار پشتیبان (SVM)

روش SVM، یکی از روش‌های یادگیری با نظارت است که برای طبقه‌بندی و رگرسیون استفاده می‌شود و بر این اساس عمل می‌کند که هیچ گونه اطلاعاتی از چگونگی توزیع داده‌ها وجود نداشته باشد. ویژگی اصلی این روش توانایی بالا در استفاده از نمونه‌های تعلیمی کمتر و رسیدن به دقت بالاتر در مقایسه با سایر روش‌های طبقه‌بندی پیشین است [۲۴]. روش طبقه‌بندی ماشین بردار پشتیبان که یکی از روش‌های طبقه‌بندی خطی است، بهترین ابرسطحی را پیدا می‌کند که با حداکثر فاصله ممکن، داده‌های مربوط به دو طبقه را از هم تفکیک کند. در نحوه ساخت ابرسطح جداکننده توسط ماشین بردار پشتیبان، ابتدا یک پوسته در اطراف نقاط هر کدام از کلاس‌ها در نظر بگیرید. ایده اصلی این است که یک جداکننده مناسب انتخاب شود. منظور، جداکننده‌ای است که بیشترین فاصله را با نقاط همسایه از هر دو طبقه دارد. این جواب در واقع بیشترین مرز را با نقاط مربوط به دو طبقه مختلف دارد و می‌تواند با دو ابرسطح موازی که حداقل از یکی از نقاط دو طبقه عبور می‌کنند، کران‌دار شود. این بردارها، بردارهای پشتیبان نام دارند. فرمول ریاضی این دو ابرسطح موازی که مرز جداکننده را تشکیل می‌دهند در عبارات ۵ و ۶ نشان داده شده است (شکل ۴) [۲۵]:

$$w \cdot x - b = 1 \quad (۵)$$

$$w \cdot x - b = -1 \quad (۶)$$



شکل ۴: نحوه طبقه‌بندی در مدل ماشین‌های بردار پشتیبان

نکته قابل توجه این است که اگر داده‌های تعلیمی به صورت خطی تفکیک‌پذیر باشند، می‌توان دو ابرسطح مرزی را به گونه‌ای انتخاب کرد که هیچ داده‌ای بین آنها نباشد و سپس فاصله بین این دو ابرسطح موازی را به حداکثر رساند. با به کارگیری قضایای هندسی، فاصله این دو ابرسطح عبارت است از $2/|w|$ ، پس باید $|w|$ را به حداقل رساند. همچنین باید از قرار گرفتن نقاط داده در ناحیه درون مرز جلوگیری کرد، برای این کار یک محدودیت ریاضی به تعریف فرمال اضافه می‌شود [۲۶]. برای هر i ، با اعمال محدودیت‌های زیر اطمینان حاصل می‌شود که هیچ نقطه‌ای در مرز قرار نمی‌گیرد:

برای داده‌های مربوط به طبقه اول :

$$w \cdot x_i - b \geq 1 \quad (7)$$

برای داده‌های مربوط به طبقه دوم :

$$w \cdot x_i - b \leq -1 \quad (8)$$

می‌توان این محدودیت را به صورت رابطه زیر نشان داد:

$$c_i(w \cdot x_i - b) \geq 1, \quad 1 \leq i \leq n \quad (9)$$

با در نظر گرفتن محدودیت زیر و به حداقل رساندن w ، مسئله بهینه‌سازی بدین شکل تعریف می‌شود:

$$c_i(w \cdot x_i - b) \geq 1, \quad 1 \leq i \leq n \quad (10)$$

۳-۳- مدل درخت تصمیم‌گیری (M5-MT)

درخت تصمیم یکی از ابزارهای قوی و متداول برای دسته‌بندی است که دارای یک ساختار درختی، شبیه به فلوجارت می‌باشد. درخت‌های تصمیم روشی برای نمایش یک سری از قوانین هستند که منتهی به یک رده یا مقدار می‌شوند. درخت‌های تصمیم به کمک جداسازی متوالی داده‌ها به یک سری گروه مجزا تشکیل شده و سعی می‌شود در فرآیند جداسازی، فاصله بین گروه‌ها افزایش یابد. ساختار یک مدل درختی شامل ریشه، گره‌های داخلی و برگ می‌باشد. از مدل‌های درخت تصمیم در حل بسیاری از مسائل طبقه‌بندی و رگرسیونی استفاده شده است (شکل ۵) [۲۷].

الگوریتم M5 رایج‌ترین طبقه‌بندی استفاده شده در خانواده مدل تصمیم‌گیری درختی است که توسط کوینلان در سال ۱۹۹۲ برای پیش‌بینی داده‌های پیوسته ارائه شد. مدل درختی M5 یک الگوریتم پیش‌بینی عددی است و گره‌های درخت با خواص بیشینه خطاهای مورد انتظاری که به عنوان تابعی از انحراف استاندارد پارامترهای خروجی می‌باشد، انتخاب می‌شوند. مدل M5 یک مدل درختی برای پیش‌بینی صفات عددی پیوسته است که در آن، توابع رگرسیونی خطی در برگ‌های این درخت ظاهر می‌گردند [۲۸]. این مدل، بر خلاف مدل‌های درخت تصمیم معمول که کلاس یا رده‌های گسسته را به عنوان خروجی ارائه می‌نمایند، یک مدل خطی چندمتغیره را برای داده‌ها در هر گره از مدل درختی می‌سازد. تشکیل ساختار مدل‌های درخت تصمیم‌گیری شامل مراحل ایجاد درخت و هرس کردن آن است [۲۹ و ۳۰] که در مرحله تشکیل درخت، از یک الگوریتم استنتاجی یا معیار تقسیم (انشعاب) برای تولید یک درخت تصمیم استفاده می‌شود. معیار تقسیم برای الگوریتم مدل M5، انحراف معیار مقادیر هر کلاسی است که به عنوان کمیتی از خطا به یک گره می‌رسد و کاهش مورد انتظار در این خطا را به عنوان نتیجه آزمون هر صفت در آن گره محاسبه می‌نماید. کاهش معیار (SDR) از رابطه زیر به دست می‌آید [۳۱ و ۳۲]:

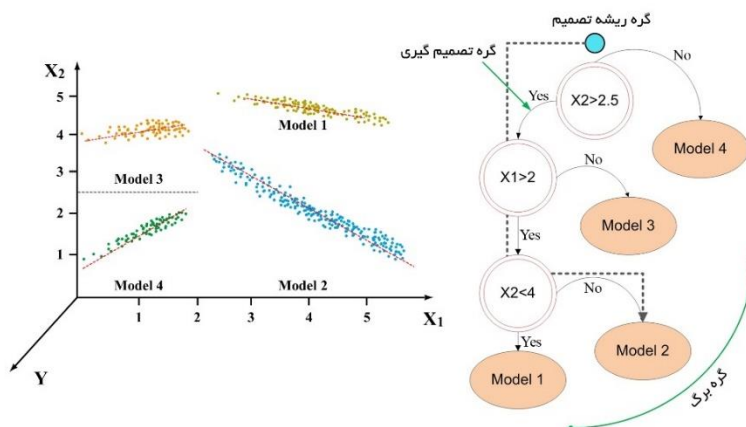
$$SDR = sd(T) - \sum_i \frac{T_i}{|T|} \times sd(T_i) \quad (11)$$

$$Sd(E) = \sqrt{\frac{1}{N} \left(\sum_{i=1}^N y_i^2 - \frac{1}{N} \left(\sum_{i=1}^N y_i \right)^2 \right)} \quad (12)$$

که در آن E بیانگر مجموعه‌ای از نمونه‌هاست که به گره می‌رسند، Sd بیانگر انحراف معیار، y_i مقدار عددی ویژگی هدف نمونه i ، N شماره داده‌ها و E_i بیانگر زیرمجموعه‌ای از نمونه‌هاست که A امین نتیجه تست پتانسیلی را دارند، می‌باشد. به دلیل فرآیند انشعاب، داده‌های قرار گرفته در گره‌های فرزند، انحراف معیار کمتری نسبت به گره مادر داشته و بنابراین خالص‌تر هستند. پس از حداکثرسازی تمامی انشعاب-

¹ Standard Deviation Reduction

های ممکن، M5 صفتی را انتخاب می کند که کاهش مورد انتظار را بیشینه نماید. این تقسیم بیشتر ساختار شبه درختی بزرگی را تشکیل می دهد که باعث بیش برآزش می گردد. برای غلبه بر مساله بیش برآزش، درخت تشکیل شده باید هرس شود. این کار با جایگزینی یک درخت فرعی با یک برگ انجام می شود. بنابراین، مرحله دوم در طراحی مدل درختی شامل هرس نمودن درخت رشد یافته و جایگزینی درختان فرعی با توابع رگرسیونی خطی است [۲۹].



شکل ۵: ساختار تشکیل درخت در مدل تصمیم گیری

۴- ارزیابی عملکرد مدل های هوشمند مصنوعی

برای مقایسه عملکرد مدل های ارائه شده و روابط تجربی در مراحل آموزش و تست، شاخص های آماری شامل ضریب همبستگی (R)، ریشه میانگین مربعات خطا (RMSE)، درصد میانگین مطلق خطا^۱ (MAPE)، میانگین خطای مطلق (MAE) و ریشه مطلق خطا^۱ (RAE) در معادلات ۱۷-۱۳ نشان داده شده است.

$$R = \frac{\sum_{i=1}^M (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^M (O_i - \bar{O}) \sum_{i=1}^M (P_i - \bar{P})}} \quad (13)$$

$$RMSE = \frac{\sum_{i=1}^M (P_i - O_i)}{M} \quad (14)$$

$$MAE = \frac{\sum_{i=1}^M |P_i - O_i|}{M} \quad (15)$$

$$RAE = \frac{\sum_{i=1}^M |P_i - O_i|}{\sum_{i=1}^M (O_i - \bar{O})} \quad (16)$$

$$MAPE = \frac{\sum_{i=1}^M \left| \frac{P_i - O_i}{O_i} \right|}{M} \times 100 \quad (17)$$

که O_i مقادیر مشاهده ای، P_i مقادیر پیش بینی، \bar{O} میانگین داده های مشاهده ای، \bar{P} میانگین داده های پیش بینی و M تعداد داده ها می باشد.

¹ Root Mean Square Error 1

¹ Mean Absolute Percentage of Error 2



¹ Mean Absolute Error 3

¹ Root Absolute Error 4

۵- نتایج و بحث

۵-۱- حالت شکست نمونه‌های CFDST

حالت شکست بخش فولادی نمونه‌های CFDST تحت بارگذاری محوری به علت نسبت‌های مختلف D_i/t_i و D_o/t_o ، L/D_i ، L/D_o اندکی با هم متفاوت هستند. اما چیزی که در این نمونه‌ها در حالت شکست با هم یکسان بود، محل کمانش این نمونه‌ها بوده است که در ابتدا در بالای نمونه‌ها و سپس به وسط نمونه‌ها کمانش کرده است. روند شکست نمونه SN45.6-20.5(20) در شکل ۶ نشان داده شده است. بر اساس شکل ۶، نقاط (a) و (b) قبل از رسیدن به نقطه اوج هیچ تغییر ظاهری و یا کمانشی بر روی لوله فولادی خارجی دیده نشده است. اگرچه، با افزایش میزان بارگذاری، در نقطه (c) تغییر شکلی می‌توان در بخش بالایی نمونه مشاهده نمود. در آخر نیز کمانش خارجی در نقطه (d) که در بخش میانی نمونه صورت پذیرفته، قابل مشاهده است.



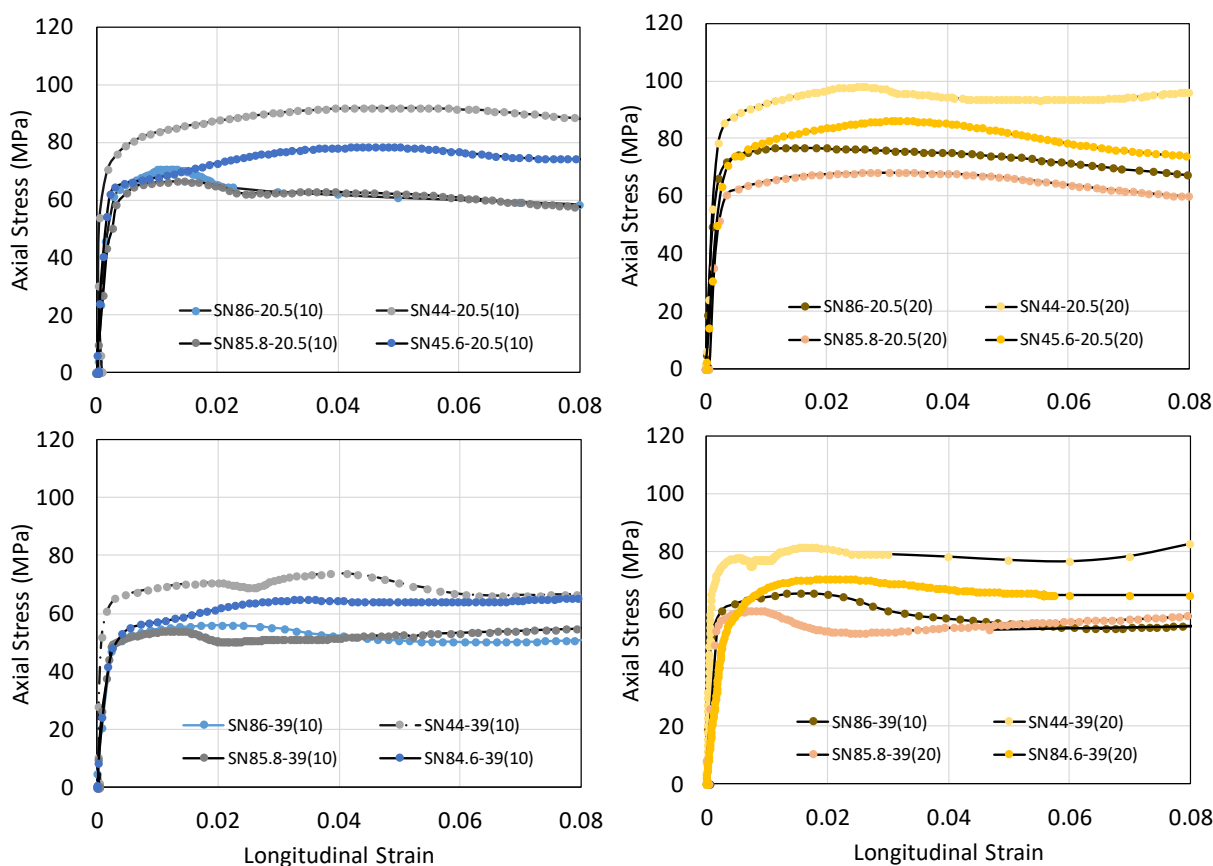
شکل ۶: روند پیش رونده حالت شکست در نمونه SN45.6-20.5(20)

۵-۲- ارزیابی عملکرد جداره‌های داخلی و خارجی و رده مقاومتی بتن بر ظرفیت باربری نمونه‌ها

شکل پذیری هر یک از نمونه‌های CFDST و همچنین ظرفیت باربری این نمونه‌ها در منحنی تنش- کرنش رسم شده برای دو رده مقاومتی بتن C10 و C20 در شکل ۷ نشان داده است. بر اساس نتایج بدست آمده از منحنی‌های تنش-کرنش، اینگونه برداشت می‌شود که ستون‌های CFDST با مقدار D_o/t_o کمتر، دارای ظرفیت باربری بیشتری می‌باشند. همچنین، با افزایش D_o/t_o مشاهده می‌شود که شکل-پذیری کاهش می‌یابد. به عنوان مثال برای نمونه SN86-20.5(10) میزان شکل پذیری به میزان ۳۳ درصد نسبت به نمونه SN45.6-20.5(10) کاهش یافته است. برای نمونه SN44-20.5(10) با $D_o/t_o=44$ نشان داده شده است که ظرفیت باربری محوری حدود ۵۵ درصد نسبت به نمونه SN85.8-20.5(10) با $D_o/t_o=85.8$ افزایش یافته است که عمده دلیل این پدیده، افزایش نسبت قطر به ضخامت لایه خارجی ستون‌های CFDST می‌باشد.

اما در خصوص نسبت قطر به ضخامت لوله داخلی (D_i/t_i) نتایج نشان داد که با افزایش این نسبت از ۲۰/۵ به ۳۹ برای ستون‌های CFDST، ظرفیت باربری کاهش می‌یابد. برای یک نسبت برابر D_o/t_o ، زمانی که D_i/t_i از ۲۰/۵ به ۳۹ افزایش یافت، شکل‌پذیری نیز کاهش یافته است که دلیل آن کاهش ضخامت لوله داخلی می‌باشد. برای نمونه SN44-20.5(10)، ظرفیت باربری و شکل‌پذیری زمانی که D_i/t_i برابر ۳۹ شد، به ترتیب به میزان ۲۴ درصد و ۳۱ درصد کاهش یافت. برای نمونه SN85.8-20.5(10) نیز میزان ظرفیت باربری ۲۵ درصد نسبت به نمونه SN85.8-39(10) کاهش یافته است.

به عنوان یک مقایسه میان بتن‌های پر شده در نمونه‌های CFDST که از رده‌های C10 و C20 می‌باشد، منحنی‌ها نشان داده‌اند که با افزایش مقاومت فشاری بتن، ظرفیت باربری و شکل‌پذیری نیز افزایش می‌یابد. در این تحقیق، با افزایش مقاومت فشاری ظرفیت باربری برای ستون‌های CFDST حدوداً ۶٪ افزایش یافته است. اما نکته قابل توجه این است که میزان افزایش مقاومت فشاری یعنی استفاده از بتن C20 در ازای C10 تاثیری در شکل‌پذیری نمونه‌های ساخته شده ندارد. در خصوص ظرفیت باربری نمونه SN44-39(20) نسبت به SN44-39(10) نتایج نشان داد که نیروی محوری از ۷۶ مگاپاسکال به ۸۱ مگاپاسکال رسیده است. اما در خصوص شکل‌پذیری نمونه‌های ساخته شده، می‌توان مشاهده کرد که تقریباً تغییری در میزان کرنش ایجاد شده به ازای نیروی وارده شده ایجاد نشده است.



شکل ۷: منحنی تنش-کرنش برای نمونه‌های CFST پر شده از بتن‌های رده C20 و C10

۵-۳- نتایج پیش‌بینی ظرفیت باربری ستون‌های CFST با استفاده از روش‌های هوشمند مصنوعی

مرحله مشخصات طراحی با هدف ارائه روش‌های استاندارد که فرمول‌های پیش‌بینی ظرفیت باربری را بر اساس نظریه‌های مختلف در بر گرفته است، ارائه می‌دهند. آیین‌نامه ACI به همراه بعضی از روابط تجربی که توسط یوناکا و همکاران [۱۵] و حسنین و همکاران [۳۳] که روش‌های شناخته شده در زمینه طراحی سازه‌های استفاده می‌شوند، برای این تحقیق در نظر گرفته شدند. به منظور دستیابی به این هدف، این مطالعه فرمول جدیدی را برای ستون‌های دایره‌ای دو جداره فولادی برای ارزیابی قابلیت‌های پیش‌بینی ظرفیت باربری محوری ستون‌های CFST ارائه داده است. قبل از مقایسه نتایج، درک اصول روش‌ها و نظریه‌های اساسی لازم است.

آیین‌نامه ACI: این آیین‌نامه یک رابطه برای تعیین ظرفیت باربری نهایی ستون‌های دو جداره فولادی ارائه داده است:

$$(N_u)_{ACI} = f_{yo}A_o + 0.85f_cA_c + f_{yi}A_i \quad (18)$$

که در این رابطه N_u ظرفیت باربری محوری، f_{yo} تنش تسلیم لوله خارجی، A_o سطح مقطع لوله خارجی، f_c مقاومت فشاری بتن، A_c سطح مقطع بتن، f_{yi} تنش تسلیم لوله داخلی و A_i سطح مقطع لوله داخلی می‌باشد.

علاوه بر رابطه ارائه شده بر اساس آیین‌نامه ACI، محققین مختلفی نیز روابط تجربی جهت تخمین ظرفیت باربری نهایی ستون‌های CFST ارائه دادند. یوناکا و همکاران [۱۵] جزو آن دسته از محققینی بوده‌اند که رابطه زیر را برای تعیین ظرفیت باربری نهایی ستون‌های دوجداره فولادی ارائه دادند:

$$(N_u)_{Uenaka et al.} = (2.86 - 2.59(\frac{D_i}{D_o}))f_{y0}A_o + 0.85f_cA_c + f_{yi}A_i \quad (19)$$

حسین و همکاران [۳۳] رابطه‌ای که ایشان برای تعیین ظرفیت باربری ستون‌های تک‌جداره فولادی ارائه داده بودند را اطلاق و برای تعیین ظرفیت باربری ستون‌های CFDST رابطه جدیدی ارائه دادند:

$$(N_u)_{Hassanein et al.} = \gamma_o f_{y0} A_o + (\gamma_c f_c + 4.1 f'_{rp,o}) A_c + \gamma_i f_{yi} A_i \quad (20)$$

که در این رابطه، γ_o ، γ_c و γ_i به ترتیب ضرایبی هستند که توصیف‌کننده تاثیر سخت‌شوندگی لوله خارجی، بتن و لوله داخلی می‌باشد.

$$\gamma_o = 1.458(\frac{D_o}{t_o})^{-0.1}, \quad 0.9 < \gamma_o < 1.1 \quad (21)$$

$$\gamma_c = 1.85 D_c^{-0.135}, \quad 0.85 < \gamma_c < 1.0 \quad (22)$$

$$D_c = D_o - 2t_o \quad (23)$$

$$f'_{rp,o} = (0.006241 - 0.0000357 \frac{D_o}{t_o}) f_{y0} \quad (24)$$

$$\gamma_i = 1.458(\frac{D_i}{t_i})^{-0.1}, \quad 0.9 < \gamma_i < 1.1 \quad (25)$$

جهت توسعه مدل‌های هوشمند مصنوعی و اراده رابطه با استفاده از مدل درخت تصمیم‌گیری، این تحقیق نیازمند مجموعه‌ای از داده‌های آزمایشگاهی می‌باشد تا با داده‌های بدست آمده از این تحقیق تجمیع شده تا رابطه‌ای جامع و دقیق‌تر برای تعیین ظرفیت باربری ستون‌های CFDST باشد. بدین منظور ۱۰۶ داده آزمایشگاهی از مقالات مختلف [۳۴-۳۸ و ۱۶ و ۱۵] معتبر به همراه ۱۶ داده آزمایشگاهی تحقیق حاضر با هم جمع شده و در مجموع، ۱۲۲ داده برای توسعه و مدل‌سازی فراهم گردید. از کل داده‌ها به ترتیب ۷۵٪ و ۲۵٪ برای اجرای مراحل آموزش و آزمایش شبکه‌ها در روش‌های هوشمند مصنوعی در نظر گرفته شده است. جدول‌های ۲ و ۳ به ترتیب نشانگر وزن‌ها و بایاس بدست آمده از مدل ANN و همچنین مدل‌های SVM و M5-MT می‌باشد.

جدول ۲: مقادیر وزن‌ها و بایاس در هر لایه از شبکه عصبی مصنوعی

وزن‌های لایه ورودی به لایه مخفی			وزن‌های لایه مخفی به لایه خروجی		بایاس‌ها
$W_{0,10} = 1.44$	$W_{0,11} = -1.54$	$W_{0,12} = 0.67$	$W_{10,13} = -0.81$		$b_{10} = -1.24$
$W_{1,10} = 0.03$	$W_{1,11} = 0.57$	$W_{1,12} = 1.97$	$W_{11,13} = 2.49$		$b_{11} = 2.25$
$W_{2,10} = -0.11$	$W_{2,11} = -0.54$	$W_{2,12} = 0.78$	$W_{12,13} = -0.36$		$b_{12} = -0.34$
$W_{3,10} = -6.60$	$W_{3,11} = -2.41$	$W_{3,12} = -0.35$	---		$b_{13} = 0.67$
$W_{4,10} = -2.41$	$W_{4,11} = 0.14$	$W_{4,12} = -1.05$	---		---
$W_{5,10} = -0.44$	$W_{5,11} = -2.15$	$W_{5,12} = -0.85$			
$W_{6,10} = 1.89$	$W_{6,11} = 1.01$	$W_{6,12} = -1.45$			
$W_{7,10} = -0.58$	$W_{7,11} = -0.05$	$W_{7,12} = 1.85$			

$W_{8,10}$ = -1.57	$W_{8,11} = -1.21$	$W_{8,12} = 0.02$
$W_{9,10} = 2.19$	$W_{9,11} = 0.85$	$W_{9,12} = -1.68$

جدول ۳: پارامترهای درونی هر یک از مدل‌های ماشین‌های بردار پشتیبان و درخت تصمیم‌گیری

مدل	ماشین‌های بردار پشتیبان			مدل درخت تصمیم‌گیری		
	پارامتر	γ	σ	Batch size	Unpruned	DP
مقدار		2.68	3.19	100	خیر	4

بعد از تفکیک داده‌ها به دو بخش آموزش و آزمون، مدل درختی M5 بر روی داده‌های آموزش برازش داده شد. در این مرحله داده‌ها به گروه‌هایی دسته‌بندی شدند و برای هر دسته یک مدل رگرسیون چند متغیره خطی^۱ (LM) ارائه شد. معادلات رگرسیونی و قوانین حاکم بر آن برای تخمین ظرفیت باربری ستون‌های CFDST در جدول ۴ آورده شده است.

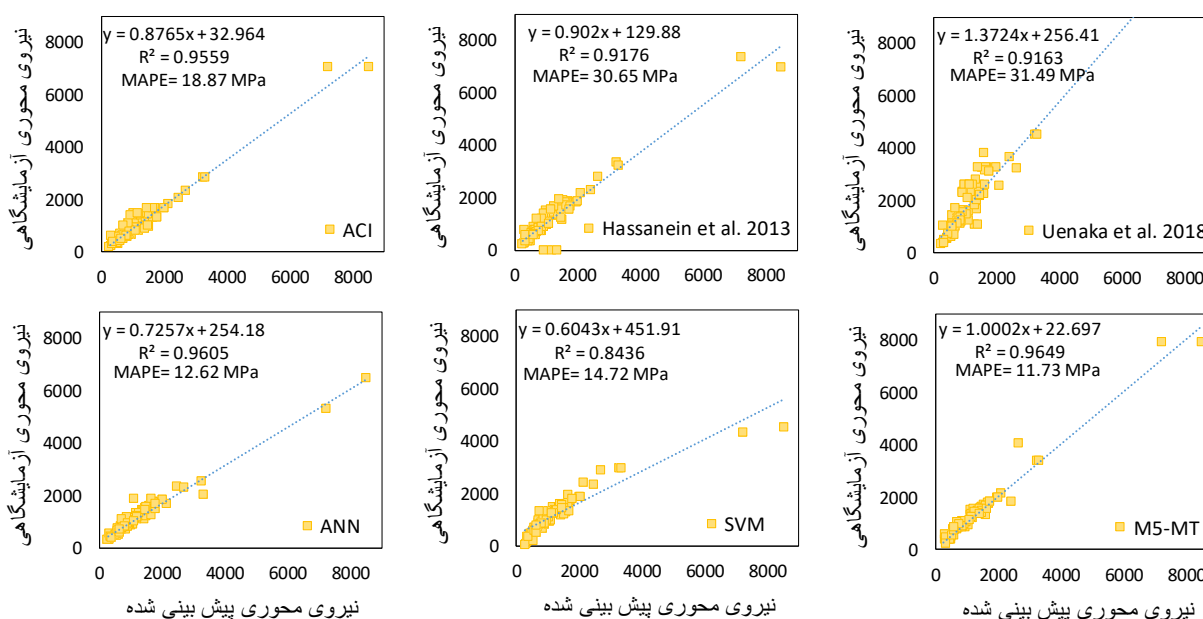
جدول ۴: معادلات رگرسیونی و قوانین حاکم در روش مدل درخت تصمیم

شماره قانون	اگر	آنگاه
۱	$D0 \leq 174.2$ $To \leq 2.975$ $L > 321.5$ $Di/ti > 23.486$	$Nu = -0.387L + 10.03Do + 152.9to - 1.52Di + 51.4286L/Do - 0.839Do/to - 4.63Di/ti + 2.18fc - 626.088$
۲	$L > 321$ $Do \leq 166.45$ $Fy > 334.5$	$Nu = -0.383L + 12.68Do + 46.85ti - 2.68Di - 5.59Do/to + 1.69fc - 556.759$
۳	$159 < Do \leq 186.85$	$Nu = 0.844L + 7.972Do + 403.79to - 3.391Di + 1.075Do/to - 1.417fc - 1160.92$
۴	$Do \leq 175.85$ $L \leq 321$	$Nu = 0.387L + 15.109Do - 10.428Do/to - 508.89$
۵	$Do \leq 175.85$	$Nu = -0.183L + 12.051Do - 12.453Do/to + 121.55$
۶	$Do \leq 221.35$	$Nu = -0.409L + 18.544Do - 22.764Do/to + 32.953$
۷	$Do \leq 328$	$Nu = 34.614Do - 25.447Do/to - 4463.86$
۸	-	7879

بر اساس شکل ۸، پیش‌بینی‌های صورت گرفته از ظرفیت باربری ستون‌های CFDST با استفاده از روش‌های هوشمند پیشنهادی، در مرحله آموزش، روش‌های شبکه عصبی مصنوعی و مدل درخت تصمیم دارای عملکرد نسبتاً بهتری در مقایسه با روش ماشین‌های بردار پشتیبان در پیش‌بینی مقادیر ظرفیت باربری ستون‌های CFDST از خود نشان داده اند. در خصوص عملکرد روابط تجربی ارائه شده، آیین-

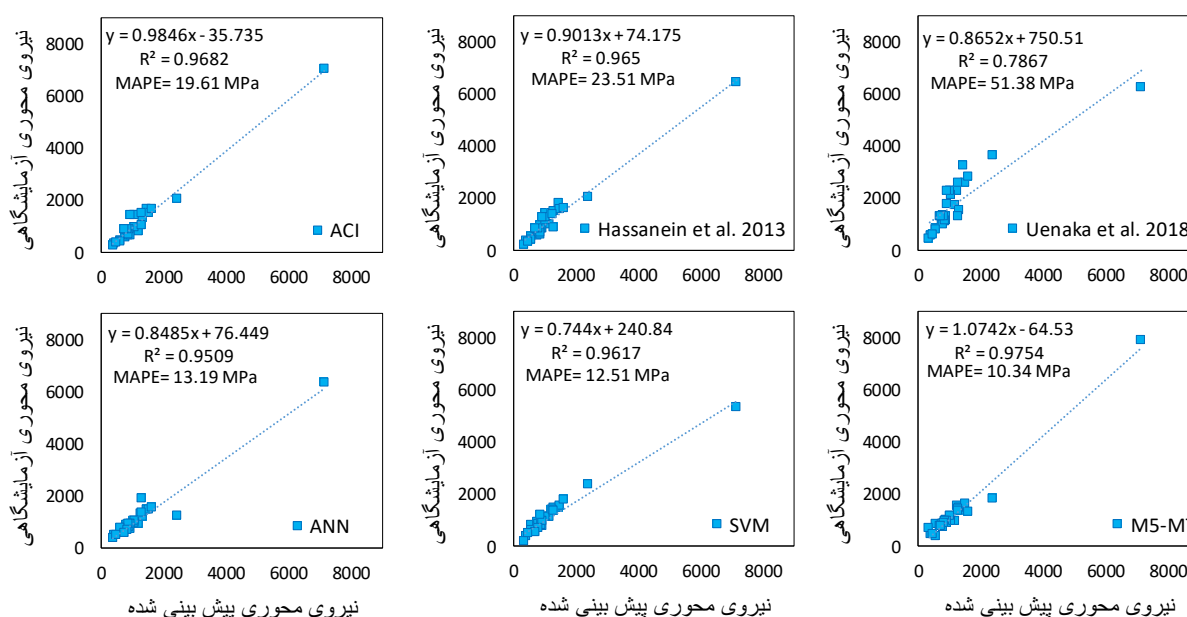
¹ Linear Model

نامه ACI ($R^2=0.95$) در این مرحله پیش‌بینی دقیق‌تری نسبت به روابط ارائه شده توسط یوناکا و همکاران [۱۵] و حسنین و همکاران [۳۳] داشته است. در بین روابط تجربی، رابطه یوناکا و همکاران [۱۵] عملکردی به اصطلاح *under-estimate* را در پیش‌بینی ظرفیت باربری داشته است و نقاط بدست آمده از نمودار پراکندگی، زیر خط نیمساز بوده است. همچنین، در پیش‌بینی مقدار بیشتر از ۶۰۰۰ کیلونیوتون از ظرفیت باربری، روش SVM دارای خطای نسبتاً زیادی (بیش از ۵۰ درصد) و برازش ضعیف‌تر در مقایسه با روش MT می‌باشد. در نگاه کلی تر در شکل ۸، در مرحله آموزش تقریباً دو روش M5-MT و ANN پیشنهادی عملکرد قابل قبولی ارائه داده اما دقت در SVM در پیش‌بینی‌ها ضعیف‌تر (دورتر از خط نیمساز) می‌باشد.



شکل ۸: نمودار پراکندگی برای پیش‌بینی ظرفیت باربری ستون‌های CFDST در مرحله آموزش

در مرحله آزمایش، بجز رابطه تجربی یوناکا و همکاران [۱۵]، دیگر روش‌های هوشمند مصنوعی به همراه رابطه تجربی حسنین و همکاران [۳۳] و آیین‌نامه ACI عملکرد مطلوبی در تخمین ظرفیت باربری ستون‌های CFDST داشته‌اند (شکل ۹). در این تحقیق شاخص آماری ضریب تعیین برای ANN، SVM و M5-MT در مرحله آزمایش به ترتیب ۰/۹۵، ۰/۹۶ و ۰/۹۷ تعیین گردید. به این ترتیب، روش M5-MT در مرحله آزمایش نیز، از عملکرد بهتری نسبت به سایر روش‌های پیشنهادی تخمین ظرفیت باربری ستون‌های CFDST داشته است. در یک مقایسه‌ی کیفی، بیش‌تر مقادیر ظرفیت باربری در روش M5-MT در شکل ۶ بر روی خط نیمساز متمرکز هستند و فقط تعداد اندکی از این نقاط خارج از منطقه تمرکز می‌باشند اما در دو روش دیگر پراکندگی داده‌ها از خط نیمساز مشخص‌تر می‌باشد. علت این دقت در روش مدل درخت تصمیم یک ساختار دسته‌بندی این روش در پیش‌بینی می‌باشد. بر اساس شاخص خطای MAPE، عملکرد رابطه ACI در مرحله آموزش (MAPE=18.87 MPa) نسبت به دو رابطه دیگر خطای کمتری در پیش‌بینی‌ها دیده می‌شود، اما این خطا در مرحله آزمایش برای رابطه حسنین و همکاران [۳۳] کمترین خطا را دارا بوده است. میان مدل‌های هوشمند نیز مدل M5-MT به ترتیب ۱۱/۷۳ و ۱۰/۳۴ کمترین مقدار خطا را نسبت به مدل‌های SVM و ANN در مراحل آموزش و آزمایش داشته است.



شکل ۹: نمودار پراکندگی برای پیش بینی ظرفیت باربری ستون‌های CFDST در مرحله آزمایش

جدول ۵ نیز مقادیر شاخص‌های آماری خطا را برای بررسی نحوه عملکرد و دقت هر یک از روش‌های پیشنهادی برای تخمین ظرفیت باربری ستون‌های CFDST ارائه می‌دهد. در مرحله آموزش، رابطه ارائه شده توسط آیین‌نامه ACI بهترین عملکرد را در میان روابط تجربی داشته و دقت این رابطه در شاخص R برابر ۰/۹۷ بوده؛ درحالی‌که این شاخص برای روابط یوناکا و همکاران [۱۵] و حسنین و همکاران [۳۳] به ترتیب برابر ۰/۹۵ و ۰/۹۴ بوده است. در میان روش‌های هوشمند مصنوعی نیز، روش SVM در مرحله آموزش ضعیف‌ترین پیش‌بینی را با توجه به شاخص ریشه میانگین کمترین مربعات خطا ($RMSE=545.01$) و ($MAE=193.24$) در مقایسه با دیگر روش‌های پیشنهادی برای پیش‌بینی ظرفیت باربری ستون‌های CFDST داشته است. دلیل این ضعف می‌تواند در این مسئله باشد که هر مدل دارای پارامترهای درونی هستند که تأثیر بسیار زیادی بر عملکرد مدل‌ها دارند و روش ANN نیز از این قاعده مستثنی نیست و باید پارامترهای این مدل را با سعی و خطا بدست آورد. لذا این مورد می‌تواند عدم قطعیت بالایی به نتایج بدست آمده از روش ANN برای پیش‌بینی مقادیر ظرفیت باربری ستون‌های CFDST به همراه داشته باشد. در مرحله آزمایش، روش M5-MT بهترین دقت ($R=0.99$) را در پیش‌بینی مقادیر ظرفیت باربری ستون‌های CFDST داشته است در حالی‌که رابطه یوناکا و همکاران [۱۵] ضعیف‌ترین دقت ($R=0.88$) را داشته است.

جدول ۵: نتایج عملکرد روابط تجربی و مدل‌های هوشمند در مرحله آموزش و آزمایش

مدل‌ها	R	RMSE	MAE	RAE	MAPE
مرحله آموزش					
ACI	0.97	287.85	212.43	82.04	18.86
Hassanein et al. [۳۱]	0.94	368.34	203.46	141.07	30.65
Uenaka et al. [۱۵]	0.95	980.61	760.89	1353.5	31.49
ANN	0.981	371.04	158.95	167.67	12.62
SVM	0.92	545.01	193.24	402.24	14.72

M5-MT	0.985	218.9	125.33	50.91	11.72
مرحله آزمایش					
ACI	0.98	217.95	181.49	91.64	19.61
Hassanein et al. [۳۱]	0.98	237.48	181.77	201.06	23.51
Uenaka et al. [۱۵]	0.88	807.59	647.83	7899.7	51.38
ANN	0.97	307.81	165.56	254.74	13.19
SVM	0.98	355.05	175.68	384.7	12.51
M5-MT	0.99	220.47	147.89	196.18	10.34

جدول ۶ مقایسه روابط تجربی و مدل‌های هوشمند پیشنهادی ANN، SVM و M5-MT در تخمین ظرفیت باربری ستون‌های CFDST بر اساس مقادیر نرمال شده نیروی محوری نهایی را نشان می‌دهد. این نکته قابل توجه است که بر اساس داده‌های جمع‌آوری شده و محدوده وسیع پارامترهای ورودی و خروجی، روابط تجربی مشخصاً قابلیت تعیین و تخمین دقیق ظرفیت باربری را نخواهند داشت و این در جدول ۳ کاملاً مشخص است. بر اساس جدول ۶، از میان روابط تجربی ارائه شده، آیین‌نامه ACI با مقدار میانگین ۱/۱ و انحراف معیار ۰/۲۵ عملکرد بهتری در مدل‌سازی ظرفیت باربری ستون‌های CFDST نسبت به دیگر روابط تجربی داشته است. اگرچه، از میان روش‌های هوشمند مصنوعی، رابطه ارائه شده از M5-MT با مقدار میانگین ۱/۰۱ و انحراف معیار ۰/۱۹ دقیق‌ترین مدل شناخته شده است.

جدول ۶: نسبت‌های مقادیر ظرفیت باربری آزمایشگاهی به مقادیر پیش‌بینی شده برای ستون‌های CFDST

Nu	N(exp)/ N(ACI)	Nu(exp)/ Nu(Uenaka et al.)	Nu(exp)/ Nu(Hassanein et al.)	Nu(exp)/Nu(ANN)	Nu(exp)/Nu(SVM)	Nu(exp)/Nu(M5-MT)
898.00	1.30	0.80	0.97	1.07	1.02	0.94
1041.60	0.75	0.46	0.74	1.02	0.96	0.91
7159.00	1.02	1.14	1.11	1.14	1.35	0.91
1188.70	1.53	0.69	1.22	1.34	1.08	1.26
1254.90	0.90	0.55	0.88	0.99	0.92	0.82
1055.00	1.12	0.50	0.94	1.14	0.97	1.14
590.97	1.43	0.70	1.13	0.92	0.77	0.71
1451.40	0.88	0.45	0.80	1.01	1.00	1.08
418.78	1.38	0.77	1.17	0.92	1.16	0.93
1319.00	1.02	0.86	0.89	1.14	0.92	0.90
804.00	1.14	0.60	0.96	0.94	1.00	0.97
1510.60	1.03	0.58	0.97	1.06	1.00	0.94
773.97	1.45	0.72	1.42	1.04	0.86	0.93
872.00	1.43	0.79	1.49	1.10	1.01	0.92
361.07	1.45	0.85	1.70	1.09	2.13	0.56
1047.30	0.75	0.46	0.83	1.02	0.96	0.91
1625.00	1.00	0.58	1.01	1.07	0.93	1.24
825.00	1.02	0.83	1.09	1.10	1.01	1.17
1286.40	0.87	0.50	0.92	0.99	0.94	0.91
2421.00	1.19	0.67	1.18	1.99	1.03	1.34

932.00	1.45	0.52	1.12	1.33	1.27	1.07
729.00	0.86	0.56	0.90	1.33	1.40	0.95
901.60	1.06	0.69	1.11	1.14	1.14	0.95
1301.00	1.28	1.00	1.49	0.70	0.98	0.98
941.40	0.68	0.41	0.74	1.05	0.99	0.98
879.10	1.29	0.76	1.31	0.98	0.76	0.92
591.13	1.56	0.77	1.56	0.82	0.99	1.59
831.70	0.98	0.64	1.02	1.23	1.27	0.97
732.10	0.86	0.56	0.90	1.34	1.41	0.96
478.00	1.39	0.81	1.52	0.99	1.02	1.06
Avg	1.10	0.87	1.14	1.10	1.08	1.01
Std	0.25	0.27	0.26	0.22	0.25	0.19

۵- نتیجه‌گیری

در این تحقیق، ۱۶ نمونه آزمایشگاهی از ستون‌های CFDST با نسبت‌های مختلف از D/t لوله‌های داخلی و خارجی ساخته شد. هشت نمونه از این نمونه‌ها با بتن C10 و هشت نمونه نیز با بتن C20 پر شده است و حالت شکست نمونه‌ها مورد بررسی قرار گرفت. با جمع‌آوری ۱۰۶ داده آزمایشگاهی به همراه ۱۶ نمونه ساخته شده، رابطه‌ای با استفاده از روش هوشمند مدل درخت تصمیم ارائه شد و نتایج آن با دیگر روش‌های هوشمند مصنوعی نظیر ماشین‌های بردار پشتیبان و شبکه عصبی مصنوعی مقایسه گردید. همچنین، رابطه استخراج شده از روش M5-MT با آیین‌نامه ACI و دو رابطه تجربی پرکاربرد مقایسه شد. نتایج نشان داد که ستون‌های CFDST با مقدار D/t_0 کم-تر، دارای ظرفیت باربری بیش‌تری می‌باشند. همچنین، با افزایش D/t_0 مشاهده می‌شود که شکل‌پذیری کاهش می‌یابد. به عنوان یک مقایسه میان بتن‌های پر شده در نمونه‌های CFDST که از رده‌های C10 و C20 بوده است، منحنی‌های تنش-کرنش نشان دادند که با افزایش مقاومت فشاری بتن، ظرفیت باربری و شکل‌پذیری نیز افزایش می‌یابد. در این تحقیق، با افزایش مقاومت فشاری ظرفیت باربری برای ستون‌های CFDST حدوداً ۶٪ افزایش یافت. اما نکته قابل توجه این بوده است که میزان افزایش مقاومت فشاری یعنی استفاده از بتن C20 در ازای C10 تأثیری در شکل‌پذیری نمونه‌های ساخته شده نداشته است. در خصوص ظرفیت باربری نمونه SN44-39(20) نسبت به SN44-39(10) نتایج نشان داده است که نیروی محوری از ۷۶ مگاپاسکال به ۸۱ مگاپاسکال رسیده است. اما در خصوص شکل‌پذیری نمونه‌های ساخته شده، می‌توان مشاهده کرد که تقریباً تغییری در میزان کرنش ایجاد شده به ازای نیروی وارده شده ایجاد نشده است. در خصوص مدل‌سازی ظرفیت باربری با روش‌های هوشمند مصنوعی، در مرحله آزمایش، بجز رابطه تجربی که توسط یوناکا و همکاران ارائه شد، دیگر روش‌های هوشمند مصنوعی به همراه رابطه تجربی ارائه شده توسط حسنین و همکاران و آیین‌نامه ACI عملکرد مطلوبی در تخمین ظرفیت باربری ستون‌های CFDST داشته‌اند. در این تحقیق شاخص آماری ضریب تعیین برای ANN، SVM و M5-MT در مرحله آزمایش به ترتیب ۰/۹۵، ۰/۹۶ و ۰/۹۷ تعیین گردید. به این ترتیب، روش M5-MT در مرحله آزمایش نیز، از عملکرد بهتری نسبت به سایر روش‌های پیشنهادی تخمین ظرفیت باربری ستون‌های CFDST داشته است. مقایسه روابط تجربی و مدل‌های هوشمند پیشنهادی ANN، SVM و M5-MT در تخمین ظرفیت باربری ستون‌های CFDST بر اساس مقادیر نرمال‌شده نیروی محوری نهایی نشان می‌دهد که از میان روابط تجربی ارائه شده، آیین‌نامه ACI با مقدار میانگین ۱/۱ و انحراف معیار ۰/۲۵ عملکرد بهتری در مدل‌سازی ظرفیت باربری ستون‌های CFDST نسبت به دیگر روابط تجربی داشته است. اگرچه، از میان روش‌های هوشمند مصنوعی، رابطه ارائه شده از M5-MT با مقدار میانگین ۱/۰۱ و انحراف معیار ۰/۱۹ دقیق‌ترین مدل شناخته شده است.

مراجع

- [1] Hu, H. T., & Su, F. C. (2011). Nonlinear analysis of short concrete-filled double skin tube columns subjected to axial compressive forces. *Marine Structures*, 24(4), 319-337.
- [2] Romero, M. L., Ibañez, C., Espinós, A., Portolés, J. M., & Hospitaler, A. (2017). Influence of ultra-high strength concrete on circular concrete-filled dual steel columns. *Structures*, 9, 13-20.
- [3] Farahi, M., Heidarpour, A., Zhao, X. L., & Al-Mahaidi, R. (2016). Compressive behaviour of concrete-filled double-skin sections consisting of corrugated plates. *Engineering Structures*, 111, 467-477.
- [4] Yan, X. F., & Zhao, Y. G. (2020). Compressive strength of axially loaded circular concrete-filled double-skin steel tubular short columns. *Journal of Constructional Steel Research*, 170, 106114.
- [5] Li, W., Wang, T., & Han, L. H. (2019). Seismic performance of concrete-filled double-skin steel tubes after exposure to fire: Experiments. *Journal of Constructional Steel Research*, 154, 209-223.
- [6] Huang, C. S., Yeh, Y. K., Liu, G. Y., Hu, H. T., Tsai, K. C., Weng, Y. T., ... & Wu, M. H. (2002). Axial load behavior of stiffened concrete-filled steel columns. *Journal of Structural Engineering*, 128(9), 1222-1230.
- [7] Chen, S., & Zhang, H. (2012). Numerical analysis of the axially loaded concrete filled steel tube columns with debonding separation at the steel-concrete interface. *Steel and Composite Structures*, 13(3), 277-293.
- [8] O'Shea, M. D., & Bridge, R. Q. (2000). Design of circular thin-walled concrete filled steel tubes. *Journal of Structural Engineering*, 126(11), 1295-1303.
- [9] Zhao, X. L., & Grzebieta, R. (2002). Strength and ductility of concrete filled double skin (SHS inner and SHS outer) tubes. *Thin-walled structures*, 40(2), 199-213.
- [10] Yagishita, F., Kitoh, H., Sugimoto, M., Tanihira, T., & Sonoda, K. (2000). Double skin composite tubular columns subjected to cyclic horizontal force and constant axial force. In *Proc., 6th ASCCS Int. Conf. on Steel-Concrete Composite Structures* (pp. 497-503). Los Angeles: Univ. of Southern California.
- [11] Nakanishi, K., Kitada, T., & Nakai, H. (1999). Experimental study on ultimate strength and ductility of concrete filled steel columns under strong earthquake. *Journal of Constructional Steel Research*, 51(3), 297-319.
- [12] Wei, S., Mau, S. T., Vipulanandan, C., & Mantrala, S. K. (1995). Performance of new sandwich tube under axial loading: experiment. *Journal of structural engineering*, 121(12), 1806-1814.
- [13] Wei, S., Mau, S. T., Vipulanandan, C., & Mantrala, S. K. (1995). Performance of new sandwich tube under axial loading: analysis. *Journal of Structural Engineering*, 121(12), 1815-1821.
- [14] Zhao, X. L., Grzebieta, R., & Elchalakani, M. (2002). Tests of concrete-filled double skin CHS composite stub columns. *Steel and Composite Structures*, 2(2), 129-146.
- [15] Uenaka, K., Kitoh, H., & Sonoda, K. (2010). Concrete filled double skin circular stub columns under compression. *Thin-walled structures*, 48(1), 19-24.
- [16] Ekmekyapar, T., & Hasan, H. G. (2019). The influence of the inner steel tube on the compression behaviour of the concrete filled double skin steel tube (CFDST) columns. *Marine Structures*, 66, 197-212.
- [17] Nguyen, M. S. T., Trinh, M. C., & Kim, S. E. (2021). Uncertainty quantification of ultimate compressive strength of CCFST columns using hybrid machine learning model. *Engineering with Computers*, 1-20.
- [18] Vu, Q. V., Truong, V. H., & Thai, H. T. (2021). Machine learning-based prediction of CFST columns using gradient tree boosting algorithm. *Composite Structures*, 259, 113505.
- [19] ASTM C39 / C39M-14, Standard Test Method for Compressive Strength of Cylindrical Concrete Specimens, ASTM International, West Conshohocken, PA, 2014, www.astm.org
- [20] Tealab, A. (2018). Time series forecasting using artificial neural networks methodologies: A systematic review. *Future Computing and Informatics Journal*, 3(2), 334-340.
- [21] Hopfield, J. J. (1988). Artificial neural networks. *IEEE Circuits and Devices Magazine*, 4(5), 3-10.
- [22] Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44.
- [23] Shenfield, A., Day, D., & Ayes, A. (2018). Intelligent intrusion detection systems using artificial neural networks. *ICT Express*, 4(2), 95-99.
- [24] Huang, S., Cai, N., Pacheco, P. P., Narrandes, S., Wang, Y., & Xu, W. (2018). Applications of support vector machine (SVM) learning in cancer genomics. *Cancer genomics & proteomics*, 15(1), 41-51.
- [25] Muthukrishnan, S., Krishnaswamy, H., Thanikodi, S., Sundaresan, D., & Venkatraman, V. (2020). Support vector machine for modelling and simulation of Heat exchangers. *Thermal Science*, 24(1 Part B), 499-503.
- [26] Cui, S., Wang, D., Wang, Y., Yu, P. W., & Jin, Y. (2018). An improved support vector machine-based diabetic readmission prediction. *Computer methods and programs in biomedicine*, 166, 123-135.

- [27] Wang, M., Rezaie-balf, M., Naganna, S. R., & Yaseen, Z. M. (2021). Sourcing CHIRPS precipitation data for streamflow forecasting using Intrinsic Time-scale Decomposition based Machine Learning models. *Hydrological Sciences Journal*, (just-accepted).
- [28] Hester, T., Quinlan, M., & Stone, P. (2010, May). Generalized model learning for reinforcement learning on a humanoid robot. In *2010 IEEE International Conference on Robotics and Automation* (pp. 2369-2374). IEEE.
- [29] Rezaie-balf, M., Naganna, S. R., Ghaemi, A., & Deka, P. C. (2017). Wavelet coupled MARS and M5 Model Tree approaches for groundwater level forecasting. *Journal of hydrology*, 553, 356-373.
- [30] Chen, W., Xie, X., Wang, J., Pradhan, B., Hong, H., Bui, D. T., ... & Ma, J. (2017). A comparative study of logistic model tree, random forest, and classification and regression tree models for spatial prediction of landslide susceptibility. *Catena*, 151, 147-160.
- [31] Bui, D. T., Tuan, T. A., Klempe, H., Pradhan, B., & Revhaug, I. (2016). Spatial prediction models for shallow landslide hazards: a comparative assessment of the efficacy of support vector machines, artificial neural networks, kernel logistic regression, and logistic model tree. *Landslides*, 13(2), 361-378.
- [32] Sattari, M. T., Pal, M., Apaydin, H., & Ozturk, F. (2013). M5 model tree application in daily river flow forecasting in Sohu Stream, Turkey. *Water Resources*, 40(3), 233-242.
- [33] Hassanein, M. F., Kharoob, O. F., & Liang, Q. Q. (2013). Circular concrete-filled double skin tubular short columns with external stainless steel tubes under axial compression. *Thin-Walled Structures*, 73, 252-263.
- [34] Essopjee, Y., & Dundu, M. (2015). Performance of concrete-filled double-skin circular tubes in compression. *Composite Structures*, 133, 1276-1283.
- [35] Li, Y. L., Zhao, X. L., Singh, R. R., & Al-Saadi, S. (2016). Experimental study on seawater and sea sand concrete filled GFRP and stainless steel tubular stub columns. *Thin-Walled Structures*, 106, 390-406.
- [36] Li, Y. L., Zhao, X. L., Raman, R. S., & Yu, X. (2018). Axial compression tests on seawater and sea sand concrete-filled double-skin stainless steel circular tubes. *Engineering Structures*, 176, 426-438.
- [37] Tao, Z., Han, L. H., & Zhao, X. L. (2004). Behaviour of concrete-filled double skin (CHS inner and CHS outer) steel tubular stub columns and beam-columns. *Journal of Constructional steel research*, 60(8), 1129-1158.
- [38] Li, W., & Cai, Y. X. (2019). Performance of CFDST stub columns using high-strength steel subjected to axial compression. *Thin-Walled Structures*, 141, 411-422.