

پیش‌بینی داده‌محور و مدل‌سازی احتمالاتی مقاومت محوری ستون‌های فولادی پر شده با بتن (CFST) با استفاده از شبکه عصبی مصنوعی

زعید اقلیمی

دانشجوی کارشناسی ارشد، گروه مهندسی عمران، واحد فومن و شفت، دانشگاه آزاد اسلامی، فومن، ایران.

میرعلیمحمد میرگذار لنگرودی *

استادیار، گروه مهندسی عمران، واحد فومن و شفت، دانشگاه آزاد اسلامی، فومن، ایران.

حامد پوراحمدی صفت عربانی

استادیار، گروه مهندسی عمران، واحد فومن و شفت، دانشگاه آزاد اسلامی، فومن، ایران.

چکیده

هدف این پژوهش، توسعه‌ی یک مدل پیش‌بینی مبتنی بر شبکه عصبی مصنوعی (ANN) برای برآورد ظرفیت محوری ستون‌های فولادی پر شده با بتن (CFST) تحت بار محوری است. برای این منظور، پایگاه داده‌ای جامع شامل ۹۵ نمونه‌ی آزمایشگاهی از منابع معتبر گردآوری شد تا طیف گسترده‌ای از ویژگی‌های هندسی و مصالح پوشش داده شود. یک شبکه عصبی پیش‌خور چندلایه با معماری بهینه طراحی و آموزش داده شد تا روابط غیرخطی میان شاخصهای ورودی و ظرفیت محوری ستون‌های CFST را مدل‌سازی کند. مدل پیشنهادی دقت بالایی از خود نشان داد؛ به‌طوری‌که ضرایب همبستگی در داده‌های آموزش، اعتبارسنجی و آزمون به‌ترتیب برابر ۰.۹۹۶۸، ۰.۹۹۶۳ و ۰.۹۶۱۲ و در مجموعه داده‌ی مستقل برابر ۰.۹۹۹۴ به‌دست آمد. تحلیل حساسیت مبتنی بر روش Garson نشان داد نسبت قطر به ضخامت بیشترین تأثیر (۳۱.۳۹٪) و نسبت لاغری ستون کمترین تأثیر (۱۳.۹۹٪) را بر ظرفیت محوری دارد. افزون بر این، یک چارچوب محاسباتی صریح بر مبنای وزن‌ها و بایاس‌های آموزش‌یافته‌ی شبکه ارائه شد تا امکان محاسبه‌ی مستقیم ظرفیت محوری بدون نیاز به اجرای مجدد شبکه فراهم شود. در نهایت، براساس آزمون‌های برازش، توزیع مقادیر حدی تعمیم‌یافته (GEV) به‌عنوان مناسب‌ترین تابع توزیع احتمال برای مدل‌سازی ظرفیت محوری ستون‌های CFST معرفی گردید. مدل و چارچوب محاسباتی پیشنهادی، ابزاری مؤثر، دقیق و قابل تعمیم برای پیش‌بینی عملکرد محوری ستون‌های CFST در طراحی و ارزیابی سازه‌ای فراهم می‌سازد.

واژه‌های کلیدی: ستون‌های فولادی پر شده با بتن، پیش‌بینی مقاومت محوری، شبکه عصبی مصنوعی، تحلیل حساسیت، مدل‌سازی احتمالاتی.

* نویسنده مسئول: ali.mirgozar@iau.ac.ir

۱- مقدمه

داده‌ای شامل ۱۵۹۹ ستون تحت بارگذاری انفجاری و استفاده از مدل‌هایی نظیر شبکه عصبی مصنوعی، الگوریتم تقویتی مبتنی بر درخت تصمیم و رگرسیون بردار پشتیبان، توان بالای مدل‌های داده‌محور را در پیش‌بینی ظرفیت باقی‌مانده نشان دادند. Ci و همکاران [۴] نیز با انجام آزمایش‌هایی بر ستون‌های کوتاه فولادی دولایه پرشده با بتن، ناتوانی برخی آیین‌نامه‌های طراحی در پیش‌بینی دقیق مقاومت محوری را گزارش کرده و مدلی مبتنی بر شبکه عصبی مصنوعی ارائه نمودند. Wang و Chan [۵] با گردآوری ۴۰۳ نمونه آزمایشگاهی و توسعه مدل‌هایی شامل رگرسیون بردار پشتیبان، جنگل تصادفی و شبکه عصبی مصنوعی، برتری قابل توجه روش‌های یادگیری ماشین نسبت به روابط آیین‌نامه‌ای را در پیش‌بینی رفتار فشاری-خمشی خارج از مرکز نشان دادند.

از سوی دیگر، Ma و همکاران [۶] با مقایسه هشت الگوریتم یادگیری ماشین برای ستون‌های فولادی پرشده با بتن و تقویت‌شده با الیاف پلیمری، الگوریتم تقویتی مبتنی بر درخت تصمیم را با ضریب تعیین ۰/۹۸۵۰ به‌عنوان دقیق‌ترین مدل معرفی کردند. Megahed [۷] از رگرسیون نمادین برای پیش‌بینی مقاومت ستون‌های CFST تحت بارگذاری غیرمحوری استفاده نمود و دقت بالاتر آن را نسبت به آیین‌نامه‌ها گزارش کرد. Asteris و همکاران [۸] با توسعه مدل هیبریدی شبکه عصبی مصنوعی-بهینه‌سازی فراابتکاری و آموزش بیش از ۱/۵ میلیون معماری شبکه، ضمن دستیابی به مدل بهینه، یک معادله صریح برای کاربرد عملی ارائه کردند. همچنین Roy و همکاران [۹] با استفاده از ۴۲۲ داده آزمایشگاهی و تحلیل سهم ویژگی‌ها، نقش شاخصهای مؤثر بر ستون‌های فولادی ضدزنگ پرشده با بتن را بررسی نمودند. در حوزه مدل‌های تحلیلی نیز Lai و همکاران [۱۰] روابط جدیدی برای پیش‌بینی ظرفیت فشاری ارائه کرده و Qi و همکاران [۱۱] مدلی سه‌مرحله‌ای برای توصیف رفتار محوری ستون‌های CFST در کل فرایند تغییرشکل، شامل پیش‌کمانش، کمانش و تغییرشکل بزرگ، پیشنهاد کردند.

با وجود پیشرفت‌های چشمگیر، بررسی ادبیات پژوهش نشان می‌دهد که بخش قابل توجهی از مدل‌های مبتنی بر شبکه عصبی

ستون‌های فولادی پرشده با بتن^۱ (به‌اختصار CFST) به دلیل برخورداری هم‌زمان از مزایای فولاد و بتن، از جمله مقاومت محوری بالا، سختی مناسب، شکل‌پذیری مطلوب و ظرفیت جذب انرژی قابل توجه، به‌عنوان یکی از کارآمدترین اعضا در سازه‌های مدرن شناخته می‌شوند. محصورشدگی بتن توسط لوله فولادی موجب افزایش مقاومت و شکل‌پذیری هسته بتنی شده و از سوی دیگر، حضور بتن از کمانش موضعی جداره فولادی جلوگیری می‌کند. این اندرکنش دو مصالح، رفتار سازه‌ای مطلوبی را فراهم می‌سازد که سبب کاربرد گسترده ستون‌های CFST در ساختمان‌های بلندمرتبه، پل‌های دهانه‌بلند، سازه‌های صنعتی و زیرساخت‌های حیاتی شده است [۱]. با گسترش استفاده از این سیستم سازه‌ای، پیش‌بینی دقیق مقاومت محوری آن به‌عنوان یکی از شاخصهای کلیدی طراحی، اهمیت دوچندان یافته است.

رویکردهای کلاسیک مبتنی بر آیین‌نامه‌های طراحی، عموماً بر پایه روابط نیمه‌تجربی و ضرایب اصلاحی توسعه یافته‌اند و در بسیاری موارد قادر به انعکاس کامل اثرات هم‌زمان شاخصهای هندسی و مکانیکی نیستند. مطالعات آزمایشگاهی و عددی نشان داده‌اند که نسبت قطر به ضخامت، نسبت لاغری، مقاومت فشاری بتن و مقاومت تسلیم فولاد تأثیرات غیرخطی و متقابل بر ظرفیت محوری ستون‌های CFST دارند [۱]. موضوعی که مدل‌سازی آن با روابط بسته تحلیلی با محدودیت همراه است.

در سال‌های اخیر، تکنیک‌های محاسبات نرم و هوش مصنوعی، به‌ویژه شبکه‌های عصبی مصنوعی (ANN) و سیستم‌های استنتاج عصبی-فازی تطبیقی (ANFIS)، توانایی فوق‌العاده‌ای در مدل‌سازی رفتارهای مکانیکی پیچیده و غیرخطی انواع بتن و اعضای سازه‌ای نشان داده‌اند. به‌عنوان نمونه، کارایی بالای این رویکردهای داده‌محور پیش از این در پیش‌بینی و مدل‌سازی دقیق مقاومت خمشی بتن‌های سبک به اثبات رسیده است [۲]. موفقیت این روش‌ها در تسخیر الگوهای غیرخطی مصالح، سبب شده تا بهره‌گیری از آن‌ها برای پیش‌بینی رفتار اعضای پیچیده‌تری همچون ستون‌های فولادی پرشده با بتن (CFST) نیز مورد توجه گسترده قرار گیرد. در همین راستا، Li و همکاران [۳] با توسعه پایگاه

^۱ Concrete-Filled Steel Tubular

مطالعات پیشین استخراج شده‌اند. به‌منظور یکپارچه‌سازی و سهولت ارجاع، تمامی نمونه‌ها با کدگذاری L-001 تا L-095 نام‌گذاری شده‌اند.

نمونه‌های L-001 تا L-007 برگرفته از نتایج آزمایشگاهی Abramski [۱۲] می‌باشند که تحت بارگذاری محوری هم‌مرکز و با شرایط تکیه‌گاهی مفصلی مورد آزمایش قرار گرفته‌اند. نمونه‌های L-008 تا L-015 از نتایج گزارش شده توسط Xu و همکاران [۱۳] استخراج شده‌اند که با هدف بررسی رفتار فشاری محوری ستون‌های فولادی پر شده با بتن خودمتراکم و با مقاومت بالا انجام شده است. نمونه‌های L-016 تا L-027 مربوط به آزمایش‌های Ekmekyapar و Al-Eliwi [۱۴] هستند که در آن‌ها ستون‌هایی با مشخصات متنوع هندسی و مکانیکی، در دامنه‌ای گسترده از شاخصها، تحت بارگذاری محوری بررسی شده‌اند. نمونه‌های L-028 تا L-051 از نتایج آزمایش‌های Dundu [۱۵] استخراج شده‌اند که در آن‌ها ستون‌ها پس از بتن‌ریزی لایه‌ای و عمل‌آوری استاندارد، تحت بارگذاری محوری کنترل‌شده تا مرحله پس‌اوج مورد آزمایش قرار گرفته‌اند. نمونه‌های L-052 تا L-063 برگرفته از آزمایش‌های De Oliveira و همکاران [۱۶] هستند که در آن‌ها نسبت لاغری ستون و مقاومت بتن به‌عنوان شاخصهای متغیر اصلی بررسی شده است. نمونه‌های L-064 تا L-066 از نتایج Han و Yao [۱۷] استخراج شده‌اند که بر بررسی رفتار فشاری ستون‌های جدار نازک پر شده با بتن خودمتراکم تمرکز داشته‌اند. در نهایت، نمونه‌های L-067 تا L-072 از آزمایش‌های Tan و Pu [۱۸] و نمونه‌های L-073 تا L-095 از آزمایش‌های Cai و همکاران [۱۹] استخراج شده‌اند که اطلاعات آن‌ها از طریق مطالعه Yang و همکاران [۲۰] گردآوری شده است.

در هر یک از برنامه‌های آزمایشگاهی مورد استفاده، مشخصات هندسی ستون، خواص مکانیکی مصالح و نتایج مقاومتی استخراج و در پایگاه داده ثبت شده است. شاخصهای گردآوری‌شده شامل قطر خارجی ستون فولادی D ، نسبت قطر خارجی به ضخامت جداره D/t ، نسبت طول ستون به قطر خارجی L/D ، تنش تسلیم فولاد f_{sy} ، مقاومت فشاری بتن پرکننده f_c و مقاومت محوری نهایی حاصل از آزمایش $N_{u,exp}$ می‌باشند. لازم به ذکر است که مقاومت فشاری بتن در مطالعات مختلف به اشکال متفاوتی (نمونه‌های

مصنوعی به‌صورت «جعبه سیاه» عمل می‌کنند و اگرچه از دقت پیش‌بینی بالایی برخوردارند، اما فاقد روابط صریح و شفاف مهندسی برای استفاده مستقیم در فرایند طراحی هستند. علاوه بر این، اغلب پژوهش‌ها مقاومت محوری ستون‌های CFST را به‌صورت مقداری قطعی مدل‌سازی کرده و عدم قطعیت‌های آماری آن کمتر مورد توجه قرار گرفته است؛ در حالی که رویکردهای نوین طراحی سازه‌ای مبتنی بر قابلیت اطمینان، مستلزم شناسایی تابع توزیع احتمال مناسب برای ظرفیت باربری اعضا هستند.

لازم به تأکید است که با توجه به اثبات قاطع برتری مدل‌های یادگیری ماشین بر روابط کلاسیک آیین‌نامه‌های طراحی در مطالعات متعدد پیشین، تمرکز اصلی پژوهش حاضر بر اثبات مجدد این تفاوت دقت نیست. بلکه این مطالعه تلاش می‌کند تا با ارائه هم‌زمان یک فرمول صریح ریاضی و یک چارچوب احتمالاتی، شکاف موجود بین مدل‌های پیچیده هوش مصنوعی (که معمولاً به عنوان جعبه سیاه شناخته می‌شوند) و نیازهای عملی مهندسان طراح را پر کند.

بر این اساس، پژوهش حاضر با اتخاذ یک رویکرد داده‌محور، به توسعه یک شبکه عصبی پیش‌خور چندلایه برای پیش‌بینی دقیق مقاومت محوری ستون‌های فولادی پر شده با بتن تحت بارگذاری هم‌مرکز می‌پردازد. بدین منظور، پایگاه داده‌ای جامع از نتایج آزمایشگاهی گردآوری و پس از پیش‌پردازش نظام‌مند، برای آموزش و ارزیابی مدل استفاده شده است. افزون بر ارزیابی آماری عملکرد شبکه و تحلیل حساسیت شاخصهای ورودی، یک چارچوب محاسباتی صریح مبتنی بر وزن‌ها و بایاس‌های شبکه استخراج شده است تا امکان محاسبه مستقیم مقاومت محوری بدون نیاز به اجرای مجدد مدل فراهم گردد. در نهایت، با بهره‌گیری از رویکرد احتمالاتی و آزمون‌های نیکویی برازش، تابع توزیع احتمال مناسب برای توصیف رفتار آماری مقاومت محوری ستون‌های CFST شناسایی شده است.

۲- روش تحقیق

۲-۱- جمع‌آوری داده‌ها

پایگاه داده مورد استفاده در این پژوهش شامل ۹۵ نمونه آزمایشگاهی ستون فولادی پر شده با بتن تحت بارگذاری محوری هم‌مرکز است که از نتایج آزمایش‌های معتبر منتشرشده در

لازم به ذکر است که به جز نمونه‌های تکراری مذکور که میانگین مقاومت آن‌ها لحاظ گردید، هیچ‌یک از داده‌های آزمایشگاهی مستخرج از منابع، به‌عنوان داده پرت (Outlier) حذف نشدند تا مدل بتواند تنوع واقعی رفتاری را در شرایط مختلف پوشش دهد. با این حال، محدود نمونه‌هایی که دارای اطلاعات ناقص در متغیرهای هندسی یا مشخصات مکانیکی مصالح بودند، پیش از ورود به فرایند پیش‌پردازش از پایگاه داده کنار گذاشته شدند تا یکپارچگی و دقت آموزش شبکه تضمین گردد.

در گام بعدی، برای ایجاد یک مبنای یکنواخت برای تحلیل، مقاومت فشاری تمامی نمونه‌ها استانداردسازی شد و به مقاومت نمونه مکعبی $150 \times 150 \times 150$ میلی‌متر تبدیل گردیدند. همچنین برای اطمینان از اثرگذاری متوازن تمامی متغیرها و جلوگیری از تأثیر غالب شاخصهای با دامنه بزرگ، تمامی داده‌ها با استفاده از روش Z-Score نرمال‌سازی شدند.

۲-۳- ساختار و معماری شبکه عصبی مورد استفاده

در این پژوهش، ورودی‌های شبکه عصبی به گونه‌ای انتخاب شدند که تمامی عوامل مؤثر بر مقاومت محوری ستون‌ها را پوشش دهند و روابط غیرخطی بین شاخصها برای شبکه قابل درک باشد. شاخصهای ورودی شامل D/t ، L/D ، f_{sy} و f_c هستند که هر یک نقش کلیدی در کنترل رفتار ستون‌ها و ظرفیت محوری آن‌ها دارند. خروجی شبکه مقاومت محوری نهایی ستون تعریف شد (شکل ۱). لازم به ذکر است که قطر ستون به‌طور مستقیم به ورودی‌ها اضافه نشد، زیرا اثر آن پس از لحاظ کردن نسبت‌های D/t و L/D قابل استخراج است و این تصمیم باعث کاهش پیچیدگی شبکه و بهبود فرایند یادگیری شد. در واقع، در ستون‌های فولادی پرشده با بتن، رفتار سازه‌ای تابع مستقیم تداخل اندرکنش سه‌محوره هسته بتنی و لوله فولادی است. شاخصهای بی‌بعد انتخاب شده، یعنی نسبت قطر به ضخامت D/t و نسبت لاغری L/D به خوبی اثرات مربوط به کماتش موضعی جداره فولادی و رفتار کلی ستون را پوشش می‌دهند. بنابراین، اضافه کردن قطر مطلق (D) نه تنها منجر به افزایش پیچیدگی غیرضروری شبکه و خطر بیش‌برازش می‌شد، بلکه به دلیل همبستگی آماری بالا با سایر شاخصهای ورودی، اطلاعات جدیدی برای بهبود دقت مدل به همراه نداشت.

استفاده از شاخصهای بی‌بعد هندسی نظیر نسبت‌های D/t و L/D


استوانه‌ای با ابعاد $200 \times 100 \times 150$ و 300×150 میلی‌متر و نمونه مکعبی با ابعاد $150 \times 150 \times 150$ میلی‌متر) گزارش شده است.

این مجموعه نمونه‌ها دامنه وسیعی از شاخصهای هندسی و مصالح را شامل می‌شوند؛ نسبت D/t بین $19/4$ تا $104/5$ ، نسبت L/D بین 5 تا $51/5$ ، تنش تسلیم فولاد بین 235 تا $488/2$ مگا پاسکال و مقاومت فشاری بتن بین $25/6$ تا $107/2$ مگا پاسکال قرار دارند. این تنوع گسترده، پوشش طیف وسیعی از شرایط طراحی و اجرای ستون‌های مرکب فولادی-بتنی را فراهم کرده و پایگاه داده را برای توسعه مدل‌های پیش‌بینی دقیق و قابل اعتماد کاملاً مناسب می‌سازد. لازم به ذکر است که اگرچه در برخی مطالعات از پایگاه داده‌های بسیار حجیم استفاده شده است، اما این پژوهش با هدف دستیابی به بیشترین دقت پیش‌بینی، رویکردی کیفیت‌محور را اتخاذ نموده است. محدودیت حجم پایگاه داده در این تحقیق، ناشی از غربال‌گری سخت‌گیرانه برای حذف نمونه‌های دارای اطلاعات ناقص، ناسازگار یا گزارش‌های آزمایشگاهی غیرقابل استناد بوده است. این فرایند پالایش داده‌ها، هرچند تعداد نمونه‌ها را محدود کرده، اما با جلوگیری از ورود نویزهای محاسباتی و داده‌های پرت (Outliers) به فرایند یادگیری، پایداری مدل را تضمین کرده و منجر به دستیابی به ضریب همبستگی بسیار بالا (بیش از ۰.۹۹) در ارزیابی نهایی شده است.

۲-۲- کنترل، یکپارچه‌سازی و آماده‌سازی داده‌ها

در بررسی پایگاه داده آزمایشگاهی، مشخص شد که برخی نمونه‌ها مانند L-069 و L-070 با شاخصهای هندسی و مکانیکی یکسان، چندین بار مورد آزمایش قرار گرفته‌اند و هر بار مقاومت محوری نهایی متفاوتی گزارش شده است (به‌عنوان مثال ۱۱۹۴ و ۱۲۳۲ کیلو نیوتن). این تفاوت‌ها نشان‌دهنده نوسانات حدود $3/18$ درصدی نسبت به حداقل مقدار مقاومت است که ماهیت تجربی آزمایش‌ها را منعکس می‌کند و می‌تواند ناشی از عوامل متنوعی مانند کیفیت بتن‌ریزی، شرایط عمل‌آوری، تأثیرات محیطی و حساسیت ابزارهای اندازه‌گیری باشد. برای حفظ انسجام داده‌ها و کاهش اثر نوسانات جزئی، در این پژوهش میانگین مقاومت محوری نهایی نمونه‌های تکراری به‌عنوان مقدار نماینده آن گروه لحاظ شد و بدین ترتیب ورود داده‌های پراکنده و غیرمؤثر به فرایند مدل‌سازی کنترل گردید.

تعمیم‌پذیری مدل به داده‌های ناشناخته به کار رفتند. داده‌های بخش اول (۹۰٪) نیز مطابق رویه‌های متداول یادگیری ماشین به سه زیرمجموعه شامل آموزش (۷۰٪)، اعتبارسنجی (۱۵٪) و آزمون حین آموزش (۱۵٪) تقسیم شدند. لازم به تأکید است که این آزمون حین آموزش، با آزمون نهایی مستقل متفاوت بوده و صرفاً در فرایند تنظیم مدل نقش دارد.



شکل ۱- معماری شبکه عصبی مورد استفاده در این پژوهش

با توجه به حجم پایگاه داده مورد استفاده در مقایسه با شاخصهای تنظیم‌پذیر شبکه (وزن‌ها و بایاس‌ها)، مدیریت خطر بیش‌برازش (Overfitting) یکی از ملاحظات اصلی در فرایند آموزش بود. بدین منظور، علاوه بر تقسیم‌بندی تصادفی داده‌ها، از استراتژی توقف زودهنگام (Early Stopping) از طریق نظارت مستمر بر خطای مجموعه اعتبارسنجی (Validation Set) استفاده شد تا فرایند آموزش پیش از حفظ کردن نویزهای محلی متوقف گردد. علاوه بر این، عملکرد بسیار مطلوب مدل بر روی مجموعه آزمون مستقل (Independent Test Set) که در هیچ مرحله‌ای از آموزش دخالت نداشت، اثبات می‌کند که شبکه به جای حفظ کردن داده‌ها، الگوهای فیزیکی حاکم بر ستون‌های CFST را به درستی فرا گرفته و از قابلیت تعمیم‌پذیری (Generalization) بالایی برخوردار است.

در نهایت، تعیین تعداد نوروں‌های لایه پنهان از طریق فرایند سعی و خطا انجام شد. تعداد نوروں‌ها از ۵ افزایش داده شد تا زمانی که به بهترین عملکرد آماری دست یافتیم. نتایج نشان داد استفاده از ۷ نوروں در لایه پنهان منجر به بهینه‌ترین همگرایی و کمترین خطای پیش‌بینی می‌شود.

به جای ابعاد فیزیکی مطلق، ضمن جلوگیری از سوگیری (Bias) شبکه به سمت مقیاس خاصی از نمونه‌ها، به پایداری عددی مدل کمک شایانی می‌کند. اگرچه در اعضای بتنی متعارف، پدیده اثر مقیاس (Size Effect) می‌تواند موجب کاهش مقاومت با افزایش ابعاد شود، اما در ستون‌های CFST به دلیل محصورشدگی شدید و سه‌محوره هسته بتنی توسط غلاف فولادی، حساسیت به اثر مقیاس به میزان قابل توجهی تعدیل می‌گردد. بر این اساس، فرض بر این است که در محدوده ابعادی پایگاه داده حاضر، نقش اثر مقیاس در مقایسه با اثرات غالب نسبت‌های لاغری و فشردگی مقطع در درجه دوم اهمیت قرار دارد.

شبکه مورد استفاده از نوع پیش‌خور چندلایه بوده و شامل لایه ورودی با چهار نوروں، یک لایه پنهان با تعداد نوروں قابل تعیین با روش سعی و خطا و یک لایه خروجی با یک نوروں است. الگوریتم آموزش شبکه Levenberg-Marquardt انتخاب شد که به دلیل سرعت همگرایی بالا و پایداری عددی، برای مدل‌سازی روابط غیرخطی بین شاخصهای هندسی، خواص مصالح و مقاومت محوری مناسب است. در لایه پنهان، از تابع انتقال تانژانت سیگموئیدی و در لایه خروجی از تابع خطی استفاده شد. عملکرد شبکه در طول آموزش با استفاده از میانگین مربعات خطا ارزیابی شد که اختلاف بین مقادیر پیش‌بینی‌شده و مقادیر واقعی حاصل از آزمایش‌های ستون‌ها را نشان می‌دهد و معیار مناسبی برای کنترل دقت و همگرایی مدل فراهم می‌آورد.

۳- ارائه و تفسیر نتایج


۳-۱- آموزش و ارزیابی شبکه عصبی

به منظور توسعه و ارزیابی مدل پیشنهادی، از پایگاه داده‌ای شامل ۹۵ نمونه آزمایشگاهی استفاده شد که دامنه گسترده‌ای از شاخصهای هندسی و مشخصات مصالح را پوشش می‌دهد. در گام نخست، کل داده‌ها به صورت تصادفی اما با حفظ توزیع یکنواخت شاخصهای ورودی، به دو بخش اصلی شامل مجموعه آموزش (۹۰٪) و مجموعه آزمون نهایی مستقل (۱۰٪) تقسیم شدند. نمونه‌های L-011، L-022، L-032، L-038، L-047، L-056، L-077 و L-081 به عنوان مجموعه آزمون نهایی انتخاب شدند. این نمونه‌ها در هیچ یک از مراحل آموزش یا تنظیم شبکه مورد استفاده قرار نگرفتند و صرفاً برای ارزیابی قابلیت

بیانگر عملکرد بسیار مناسب مدل در بازتولید رفتار کلی پایگاه داده است.

در نهایت، ارزیابی مستقل مدل بر روی مجموعه آزمون نهایی انجام شد که نتایج آن در شکل ۳ ارائه شده است. ضریب همبستگی بین مقادیر پیش‌بینی شده و نتایج آزمایشگاهی نشان‌دهنده انطباق تقریباً کامل نتایج مدل با داده‌های واقعی است. مقدار ریشه میانگین مربعات خطای نرمال شده برابر با $1/3807$ درصد به دست آمد که نشان‌دهنده دقت بسیار بالای مدل در پیش‌بینی مقاومت محوری است.

نمودارهای رگرسیون ارائه شده در شکل ۲ بیانگر همبستگی بسیار بالای بین مقادیر پیش‌بینی شده و نتایج آزمایشگاهی هستند. ضریب همبستگی مرحله آموزش برابر با $0/99684$ به دست آمد که نشان‌دهنده یادگیری دقیق روابط غیرخطی بین متغیرهای ورودی و مقاومت محوری ستون‌ها است. مقادیر ضریب همبستگی برای مراحل اعتبارسنجی و آزمون حین آموزش به ترتیب $0/96631$ و $0/96122$ محاسبه شد که نزدیکی آن‌ها به مقدار مرحله آموزش ضریب همبستگی عدم بروز بیش‌برازش و پایداری فرایند یادگیری است. ضریب همبستگی کل داده‌ها نیز برابر با $0/98898$ محاسبه شد که



شکل ۲- نمودارهای رگرسیون شبکه عصبی آموزش دیده برای مراحل آموزش، اعتبارسنجی، آزمون حین آموزش و کل داده‌ها

ورودی در تعیین مقاومت محوری، تحلیل حساسیت با استفاده از روش Garson و بر اساس وزن‌های آموزش دیده شبکه انجام شد.

۳-۲- تحلیل حساسیت

پس از تأیید دقت مدل، به منظور بررسی سهم نسبی شاخصهای

۳-۳- ارائه چارچوب محاسباتی مبتنی بر شبکه عصبی برای پیش‌بینی مقاومت محوری

به‌منظور فراهم‌سازی امکان استفاده عملی از مدل توسعه‌یافته در طراحی مهندسی، شبکه عصبی آموزش‌دیده به یک رابطه محاسباتی صریح تبدیل شد. این اقدام موجب می‌شود بدون نیاز به اجرای مجدد فرایند آموزش یا استفاده از محیط‌های نرم‌افزاری هوش مصنوعی، مقاومت محوری ستون تنها از طریق جایگذاری شاخصهای ورودی در روابط ارائه‌شده قابل محاسبه باشد. بدین ترتیب، مدل پیشنهادی از یک ابزار یادگیری عددی به یک فرمول محاسباتی کاربردی تبدیل گردید.

بردار ورودی مدل مطابق رابطه ۱ شامل چهار شاخص D/t (معادل با J_1)، L/D (معادل با J_2)، f_{sy} (معادل با J_3) و f_c (معادل با J_4) تعریف می‌شود. مقاومت محوری ستون بر حسب کیلو نیوتن از طریق رابطه ۲ محاسبه می‌گردد:


$$J = \left[\frac{J_1 - 42.28}{17.54}, \frac{J_2 - 10.95}{7.81}, \frac{J_3 - 341.04}{58.45}, \frac{J_4 - 52.18}{27.13} \right] \quad (1)$$

$$N_u = 498.27 \left[W_1 \times \tanh(W_0 J^T + B_0) + B_1 \right] + 1251.95 \quad (2)$$

که در آن، J بردار ورودی، W_0 ماتریس وزن‌های بین لایه ورودی و پنهان، W_1 بردار وزن‌های بین لایه پنهان و خروجی، B_0 و B_1 به ترتیب بایاس‌های لایه پنهان و خروجی هستند.

ضرایب عددی وزن‌ها و بایاس‌ها از شبکه عصبی آموزش‌دیده در بخش (۳-۱) استخراج شده و در روابط ۳ تا ۶ ارائه شده‌اند. این ضرایب بیانگر الگوی غیرخطی آموخته‌شده از ۹۵ داده آزمایشگاهی بوده و تمامی اثرات اندرکنشی بین شاخصهای هندسی و مشخصات مصالح را در خود منعکس می‌کنند.


به‌منظور اعتبارسنجی چارچوب پیشنهادی، نتایج حاصل از رابطه ۲ با داده‌های آزمایشگاهی مستقل مقایسه شد (شکل ۵). اختلاف پیش‌بینی‌ها در بازه ۲ تا ۸ درصد قرار دارد و هیچ نمونه‌ای دارای خطای بیش از ۱۰ درصد نیست که نشان‌دهنده دقت بالا و قابلیت اعتماد رابطه صریح استخراج‌شده برای کاربردهای مهندسی است. شایان ذکر است که رابطه صریح ارائه‌شده، منطبق بر محدوده آموزش شبکه عصبی توسعه یافته است. بنابراین، استفاده از این چارچوب محاسباتی برای ستون‌های CFST با مشخصات خارج



شکل ۳- مقایسه نتایج پیش‌بینی شبکه عصبی با داده‌های

آزمایشگاهی در آزمون نهایی مستقل

الگوریتم گارسون با استفاده از ماتریس وزن‌های اتصالی بین لایه‌های ورودی، پنهان و خروجی شبکه، سهم نسبی هر شاخص ورودی را در پیش‌بینی خروجی نهایی ارزیابی می‌کند. مزیت اصلی این روش آن است که بدون نیاز به حذف متغیرها و اجرای مجدد مدل، تأثیرات غیرخطی هر شاخص را به‌صورت درصدی از کل تأثیرات محاسبه کرده و دیدگاهی کمی از فیزیک حاکم بر مسأله ارائه می‌دهد. نتایج ارائه‌شده در شکل ۴ نشان می‌دهد که نسبت D/t با سهم ۳۹/۳۱٪ بیشترین تأثیر را بر ظرفیت محوری ستون‌ها دارد که بیانگر نقش تعیین‌کننده ضخامت جداره فولادی و میزان محصورشدگی بتن است. پس از آن، مقاومت تسلیم فولاد با سهم ۲۵/۴۴٪ و مقاومت فشاری بتن با سهم ۲۱/۲۶٪ در رتبه‌های بعدی قرار می‌گیرند که اهمیت خواص مکانیکی مصالح را در رفتار فشاری عضو نشان می‌دهد. در مقابل، نسبت لاغری L/D با سهم ۱۳/۹۹٪ کمترین تأثیر نسبی را در میان شاخصهای بررسی‌شده داشته است؛ هرچند این شاخص همچنان در پایداری کلی ستون نقش مؤثر ایفا می‌کند.



شکل ۴- مقایسه میزان تأثیرگذاری شاخصهای ورودی بر

مقاومت محوری ستون‌ها بر اساس روش Garson

۳- ۴- توسعه مدل پیش‌بینی عددی به چارچوب احتمالاتی

اگرچه در بخش ۳-۳ یک رابطه صریح برای پیش‌بینی مقاومت محوری ستون‌های پر شده با بتن ارائه شد، خروجی آن ماهیتی قطعی دارد؛ در حالی که در تحلیل‌های قابلیت اطمینان، مقاومت سازه‌ای باید به‌عنوان یک متغیر تصادفی مدل‌سازی شود. در تحلیل‌های نوین مهندسی سازه، تکیه بر مقادیر قطعی ممکن است منجر به نادیده گرفتن عدم قطعیت‌های ناشی از کیفیت اجرای پروژه، نوسانات خواص مصالح و خطاهای مدل‌سازی گردد. رویکرد احتمالاتی اتخاذ شده در این مطالعه، با شناسایی تابع توزیع مناسب برای ظرفیت باربری، امکان ارزیابی «ریسک شکست» را فراهم می‌آورد. به‌ویژه، انتخاب توزیع Generalized

Extreme Value (GEV) به این دلیل است که برخلاف توزیع‌های متقارن (مانند نرمال)، این تابع انعطاف‌پذیری بالایی در مدل‌سازی مقادیر حدی دارد. این ویژگی برای مهندسان طراح حیاتی است، زیرا در ارزیابی قابلیت اطمینان سازه‌ای، دقت در نواحی کم‌احتمال اما پرخطر به مراتب مهم‌تر از میانگین توزیع است. بر این اساس، چارچوب عددی توسعه یافته برای پوشش کامل عدم قطعیت‌های ناشی از نوسانات خواص مصالح، هندسه و خطاهای مدل‌سازی، به یک چارچوب احتمالاتی تعمیم داده شد. در این راستا، مقادیر مقاومت محوری حاصل از مدل پیشنهادی به‌عنوان داده‌های پایه برای برازش توابع توزیع احتمال در نظر گرفته شدند. هدف اصلی در این گام، ارائه یک توصیف آماری کلان از طیف مقاومت‌های محوری موجود و شبیه‌سازی رفتار تجمعی آن‌هاست. در حالی که در توسعه مستقیم ضرایب آیین‌نامه‌ای، تمرکز بر توزیع خطای مدل (نسبت مقاومت واقعی به پیش‌بینی شده) می‌باشد، استخراج تابع توزیع احتمال برای خود ظرفیت باربری در این پژوهش، گامی کاربردی برای استفاده مستقیم در شبیه‌سازی‌های مبتنی بر قابلیت اطمینان، مانند روش مونت کارلو، جهت ارزیابی آسیب‌پذیری لرزه‌ای یا انفجاری مجموعه‌ای از ستون‌ها با مشخصات تصادفی در سطح شبکه به شمار می‌رود. به‌منظور انتخاب مناسب‌ترین مدل آماری، مجموعه‌ای از توابع توزیع احتمال پر کاربرد و انعطاف‌پذیر به‌عنوان توابع کاندید مورد بررسی قرار گرفتند. برازش این توزیع‌ها بر داده‌های مقاومت محوری در شکل ۶ ارائه شده است. برای ارزیابی


از دامنه شاخص‌های تعریف شده در پایگاه داده این پژوهش (به‌ویژه مقادیر خارج از محدوده برای نسبت‌های D/t و L/D یا مقاومت‌های بسیار بالای بتن و فولاد)، مستلزم احتیاط مهندسی و انجام ارزیابی‌های تکمیلی است. چرا که مدل‌های داده‌محور درون‌یابی‌های (Interpolators) بسیار قدرتمندی هستند، اما قابلیت برون‌یابی (Extrapolation) آن‌ها محدود است.

$$W_0 = \begin{bmatrix} -0.2924 & -1.3239 & 4.2871 & 1.7560 \\ -0.6156 & 0.7554 & 3.7709 & 1.2094 \\ -0.6985 & 0.2748 & -0.9122 & 1.7391 \\ -2.8573 & -0.2760 & -0.1130 & 0.5071 \\ -3.3588 & 0.3037 & 0.0038 & -1.5730 \\ -1.1104 & 0.6641 & -0.6632 & 0.2658 \\ -2.8354 & 2.6175 & 0.2213 & 1.5876 \end{bmatrix} \quad (3)$$

$$W_1^T = \begin{bmatrix} 0.6236 \\ -0.6265 \\ 0.9018 \\ 2.1568 \\ -0.3759 \\ -1.3639 \\ 0.2774 \end{bmatrix} \quad (4)$$

$$B_0 = \begin{bmatrix} -1.5217 \\ -2.9504 \\ 0.8136 \\ -5.1224 \\ 0.5317 \\ 0.0075 \\ -0.5878 \end{bmatrix} \quad (5)$$

$$B_1 = 1.8944 \quad (6)$$



شکل ۵- مقایسه مقاومت محوری پیش‌بینی شده و نتایج آزمایشگاهی

میزان انطباق هر توزیع با داده‌ها، از آزمون‌های نیکویی برازش Anderson-Kolmogorov-Smirnov (KS)، Darling (AD) و Chi-Squared (CS) استفاده شد تا رفتار تجمعی، نواحی دنباله و توزیع فراوانی به‌طور همزمان بررسی گردد. نتایج مقایسه سه توزیع برتر هر آزمون در جدول ۱ نشان می‌دهد که توزیع GEV (Generalized Extreme Value) در آزمون‌های KS و CS رتبه نخست را کسب کرده و در آزمون AD نیز در رتبه دوم قرار دارد. اختلاف آماره AD این توزیع با بهترین گزینه آن آزمون (Weibull) تنها ۳/۰۸ درصد است که از نظر آماری ناچیز محسوب می‌شود.

(۷)

$$f(x) = \begin{cases} \frac{1}{\sigma} \exp(-(1+kz)^{-1/k}) (1+kz)^{-1-1/k} & k \neq 0 \\ \frac{1}{\sigma} \exp(-z - \exp(-z)) & k = 0 \end{cases}$$

$$F(x) = \begin{cases} \exp(-(1+kz)^{-1/k}) & k \neq 0 \\ \exp(-\exp(-z)) & k = 0 \end{cases} \quad (۸)$$

(۹)


$$f(x) = \frac{\exp(-(1-0.16903z)^{5.9161})(1-0.16903z)^{4.9161}}{476.73}$$

$$F(x) = \exp(-(1-0.16903z)^{5.9161}) \quad (۱۰)$$


$$z = \frac{x-1015}{476.73} \quad (۱۱)$$

بررسی همزمان شاخص‌ها در جدول ۱ نشان می‌دهد که توزیع GEV نسبت به سایر توزیع‌ها عملکردی پایدارتر و متوازن‌تر در تمامی معیارها ارائه می‌دهد. در حالی که برخی توزیع‌ها در یک آزمون خاص عملکرد بهتری داشته‌اند، اما در سایر شاخص‌ها افت محسوسی نشان داده‌اند. بر این اساس، توزیع GEV به‌عنوان تابع توزیع احتمال بهینه برای مدل‌سازی مقاومت محوری ستون‌ها انتخاب شد.

تابع چگالی احتمال (PDF) و تابع توزیع تجمعی (CDF) این توزیع به‌ترتیب در روابط ۷ و ۸ ارائه شده‌اند. توزیع GEV دارای سه شاخص مکان (μ)، مقیاس (σ) و شکل (k) است که به‌ترتیب



شکل ۶- برازش توابع کاندید به داده‌ها



شکل ۷- مقایسه اختلاف احتمال بین مدل احتمالاتی پیشنهادی و داده‌های آزمایشگاهی مقاومت محوری ستون‌ها

جدول ۱- مقایسه سه توزیع برتر بر اساس آزمون‌های نیکویی برازش KS، AD و CS

#	Kolmogorov Smirnov		Anderson Darling		Chi-Squared	
	Distribution	Statistic	Distribution	Statistic	Distribution	Statistic
Best-fitted distributions	GEV	0.06234	Weibull	0.37919	GEV	2.6721
	Burr	0.06247	GEV	0.39125	Burr	3.1757
	Gamma	0.06336	Burr	0.3934	Log-Logistic	3.5663
Proposed distribution	Gen. Extreme Value		Gen. Extreme Value		Gen. Extreme Value	
Difference (%)	0		3.08		0	

۴- نتیجه‌گیری

بر مقاومت محوری داشته، در حالی که تنش تسلیم فولاد و مقاومت فشاری بتن در رتبه‌های بعدی قرار گرفتند و نسبت لاغری ستون تأثیر نسبی کمتری داشت. این نتایج با رفتار مکانیکی شناخته‌شده ستون‌های CFST هم‌خوانی دارد و نقش حیاتی مهارشدگی بتن توسط جداره فولادی را تأیید می‌کند.

یکی از دستاوردهای مهم این پژوهش، توسعه یک چارچوب محاسباتی صریح مبتنی بر وزن‌ها و بایاس‌های شبکه عصبی آموزش‌دیده بود که امکان محاسبه مستقیم مقاومت محوری ستون‌ها بدون نیاز به اجرای مجدد شبکه عصبی را فراهم می‌کند. مقایسه نتایج این چارچوب با داده‌های آزمایشگاهی نشان داد که اختلاف پیش‌بینی‌ها کمتر از ۱۰ درصد بوده و در اغلب نمونه‌ها در بازه ۲ تا ۸ درصد قرار دارد، که نشان‌دهنده دقت عملی و قابلیت استفاده مهندسی بالای مدل است.

این پژوهش با هدف توسعه یک مدل دقیق و قابل‌اعتماد برای پیش‌بینی مقاومت محوری ستون‌های فولادی پرشده با بتن (CFST) انجام شد. نتایج نشان داد که شبکه عصبی مصنوعی آموزش‌دیده توانسته است روابط غیرخطی و پیچیده بین شاخصهای هندسی و مکانیکی ستون‌ها و مقاومت محوری نهایی را به‌طور مؤثر شناسایی کند. دقت بالای مدل در مراحل آموزش، اعتبارسنجی و آزمون مستقل، با ضریب همبستگی نزدیک به یک و خطای پیش‌بینی بسیار کم ($NRMSE \approx 1.38\%$) تأیید شده است، که نشان‌دهنده قابلیت تعمیم‌پذیری و پایداری شبکه عصبی در تحلیل ستون‌های CFST است.

تحلیل حساسیت انجام‌شده اهمیت نسبی شاخصهای ورودی را مشخص نمود؛ نسبت قطر به ضخامت جداره ستون بیشترین تأثیر را

of Axial Compressive Capacity of CFRP-Confined Concrete-Filled Steel Tubular Short Columns Based on XGBoost Algorithm. *Engineering Structures*, 260 (2022), 114239.

[7] Megahed, K. Symbolic Regression for Strength Prediction of Eccentrically Loaded Concrete-Filled Steel Tubular Columns. *Scientific Reports*, 15(1) (2025), 3085.

[8] Asteris, P. G., Sivenas, T., Gkantou, M., Formisano, A., Le, T. T. Estimation of Axial Load-Carrying Capacity of Elliptical Concrete Filled Steel Tubular Columns Using Computational Intelligence. *Journal of Building Engineering*, 113738 (2025).

[9] Roy, D., Das, D., Islam, K., Billah, A. M. Machine Learning Assisted Axial Strength Prediction Models for Concrete Filled Stainless Steel Tubular Columns. *Structures*, 73 (2025), 108329.

[10] Lai, B. L., Zheng, X. F., Fan, S. G., Chang, Z. Q. Behavior and Design of Concrete Filled Stainless Steel Tubular Columns under Concentric and Eccentric Compressive Loading. *Journal of Constructional Steel Research*, 213 (2024), 108319.

[11] Qi, H. H., Li, G. Q., Lou, G. B. Behavior of Concrete-Filled Steel Tubular Column at Large Axial Deformation. *Structures*, 70 (2024), 107603.

[12] Abramski, M. Load-Carrying Capacity of Axially Loaded Concrete-Filled Steel Tubular Columns Made of Thin Tubes. *Archives of Civil and Mechanical Engineering*, 18(3) (2018), 902–913.

[13] Xu, L. H., Xu, F. Z., Zhou, P. H., Gu, Y. S., Wu, M. Experimental Research on Axial Compression Performance of Medium-and-Long Steel Tubular Columns Filled with High Strength Self-Stressing Self-Compacting Concrete. *China Civil Engineering Journal*, 49(11) (2016), 26–34, 44.

[14] Ekmekyapar, T., Al-Eliwi, B. J. Experimental Behaviour of Circular Concrete Filled Steel Tube Columns and Design Specifications. *Thin-Walled Structures*, 105 (2016), 220–230.

[15] Dundu, M. Compressive Strength of Circular Concrete Filled Steel Tube Columns. *Thin-Walled Structures*, 56 (2012), 62–70.

[16] De Oliveira, W. L. A., De Nardin, S., de Cresce El, A. L. H., El Debs, M. K. Influence of Concrete Strength and Length/Diameter on the Axial Capacity of CFT Columns. *Journal of Constructional Steel Research*, 65(12) (2009), 2103–2110.

[17] Han, L. H., Yao, G. H. Experimental Behaviour of Thin-Walled Hollow Structural Steel (HSS) Columns Filled with Self-Consolidating Concrete

با تعمیم چارچوب عددی به مدل احتمالاتی، عدم قطعیت موجود در مقاومت محوری ستون‌ها به‌طور دقیق مدل‌سازی شد و توزیع Generalized Extreme Value به‌عنوان تابع توزیع احتمال بهینه شناسایی گردید. بررسی تطابق مدل احتمالاتی با داده‌های آزمایشگاهی نشان داد که اختلاف پیش‌بینی کمتر از ۷ درصد است، که بیانگر قابلیت بالای مدل در توصیف رفتار آماری مقاومت محوری ستون‌های CFST و کاربرد آن در تحلیل‌های قابلیت اطمینان و طراحی مبتنی بر احتمال می‌باشد.

در مجموع، پژوهش حاضر نشان داد که استفاده از شبکه عصبی مصنوعی همراه با چارچوب احتمالاتی، رویکردی جامع، دقیق و کاربردی برای پیش‌بینی مقاومت محوری ستون‌های CFST ارائه می‌دهد. این مدل امکان تحلیل سریع، با دقت بالا و با در نظر گرفتن عدم قطعیت‌ها را فراهم کرده و می‌تواند به‌عنوان ابزاری عملی برای تحلیل، طراحی و ارزیابی قابلیت اطمینان سازه‌های فولادی-بتنی مورد استفاده مهندسین قرار گیرد.

۵- مراجع

[1] Yang, C., Gao, P., Wu, X., Chen, Y. F., Li, Q., Li, Z. Practical Formula for Predicting Axial Strength of Circular-CFST Columns Considering Size Effect. *Journal of Constructional Steel Research*, 168 (2020), 105979.

[2] Sobhani, J., Ejtemaei, M., Sadrmomtazi, A., Mirgozar, M. A. Modeling Flexural Strength of EPS Lightweight Concrete Using Regression, Neural Network and ANFIS. *International Journal of Optimization in Civil Engineering*, 9(2) (2019), 313–329.

[3] Li, J., Pang, Y., Mu, Q., Zhang, X., Shi, Y., Wang, H. Post-Blast Capacity Evaluation of Concrete-Filled Steel Tubular (CFST) Column Based on Machine Learning Technique. *Advances in Structural Engineering*, 26(11) (2023), 1953–1972.

[4] Ci, J., Ahmed, M., Tran, V. L., Jia, H., Chen, S. Axial Compressive Behavior of Circular Concrete-Filled Double Steel Tubular Short Columns. *Advances in Structural Engineering*, 25(2) (2022), 259–276.

[5] Wang, C., Chan, T. M. Machine Learning (ML) Based Models for Predicting the Ultimate Strength of Rectangular Concrete-Filled Steel Tube (CFST) Columns under Eccentric Loading. *Engineering Structures*, 276 (2023), 115392.

[6] Ma, L., Zhou, C., Lee, D., Zhang, J. Prediction

(SCC). Thin-Walled Structures, 42(9) (2004), 1357–1377.

[18] Tan, K. F., Pu, X. C. Study on Behavior and Load Bearing Capacities of Slender Steel Tubular Columns and Eccentrically Loaded Steel Tubular Columns Filled with Extra Strength Concrete. Journal of Building Structures, 21(2) (2000), 12–19.

[19] Cai, S. H., Gu, W. L. Behaviour and Ultimate Strength of Long Concrete-Filled Steel Tubular Columns. Journal of Building Structures, 3 (1985), 32–40.

Data-Driven Prediction and Probabilistic Modeling of the Axial Capacity of Concrete-Filled Steel Tubular (CFST) Columns Using Artificial Neural Networks

Zaeed Eqlimi

M.Sc. Student, Department of Civil Engineering, FSh. C., Islamic Azad University, Fouman, Iran.

Mir Alimohammad Mirgozar Langaroudi *

Assistant Professor, Department of Civil Engineering, FSh. C., Islamic Azad University, Fouman, Iran.

Hamed Pourahmadi Sefat Arabani

Assistant Professor, Department of Civil Engineering, FSh. C., Islamic Azad University, Fouman, Iran.

Abstract

This study aims to develop an Artificial Neural Network (ANN) model to predict the axial capacity of Concrete-Filled Steel Tubular (CFST) columns under axial loading. A comprehensive database comprising 95 experimental specimens from reliable sources was compiled to capture a wide range of geometric and material characteristics. A multilayer feedforward ANN with optimized architecture was designed and trained to model the nonlinear relationships between input parameters and the axial capacity of CFST columns. The model demonstrated high accuracy, with correlation coefficients of 0.9968, 0.9663, and 0.9612 for the training, validation, and test datasets, respectively. Evaluation using an independent dataset further confirmed the model's reliability, yielding a correlation coefficient of 0.9994. Sensitivity analysis based on Garson's method indicated that the diameter-to-thickness ratio had the greatest influence (31.39%), while the column slenderness ratio had the least (13.99%). Additionally, a practical computational framework was developed based on the trained ANN weights and biases, allowing direct calculation of axial capacity without rerunning the network. Finally, goodness-of-fit tests suggested that the Generalized Extreme Value distribution provides the best match to the experimental data, serving as an optimal probability distribution function for the axial capacity of CFST columns. The proposed ANN model and computational framework provide an efficient, accurate, and generalizable tool for predicting the axial performance of CFST columns in structural design and assessment.

Keywords: Concrete-Filled Steel Tubular (CFST) Columns, Axial Capacity Prediction, Artificial Neural Network (ANN), Sensitivity Analysis, Probabilistic Modeling.

* Corresponding Author: ali.mirgozar@iau.ac.ir

