

بررسی اثر تعداد و ارتفاع طبقات اسکلت فلزی با سیستم قاب خمشی در وزن سازه به روش شبکه‌ی عصبی مصنوعی

Research Note

سید شاکر هاشمی* (استادیار)

مسعود زارعی (کارشناس ارشد)

عبدالرضا فاضلی (استادیار)

دانشکده‌ی مهندسی عمران، دانشگاه خلیج فارس، بوشهر

با توجه بیشتر به برآورد میزان فولاد مصرفی، قبل از شروع طراحی و براساس مشخصات کلیدی طرح، طراح و کارفرما می‌توانند دید مناسبی نسبت به مقدار فولادی مصرفی کسب کنند. در پژوهش حاضر، با استفاده از روش شبکه‌ی عصبی مصنوعی نسبت به برآورد میزان وزن سازه‌های فولادی با سیستم قاب خمشی اقدام شده است. در این راستا، پس از آموزش شبکه و ارزیابی دقت روش، متاثر از تغییر پارامترهای ارتفاع طبقه، نسبت طول به دهانه، نوع مقطع ستون و تعداد طبقات، وزن سازه برآورد و اطلاعات مذکور در قالب روابط و منحنی‌های کاربردی بیان شده است. نتایج نشان می‌دهند که استفاده از مقاطع BOX به جای مقاطع H شکل، باعث صرفه جویی ۱۰ درصدی در وزن سازه خواهد شد. همچنین افزایش نسبت طول دهانه به ارتفاع طبقه از ۱ به ۱٫۵، باعث افزایش ۵ درصدی و افزایش این نسبت از ۱ به ۲، باعث افزایش ۲۰ درصدی میزان فولاد مصرفی خواهد شد.

واژگان کلیدی: وزن اسکلت سازه، قاب خمشی فولادی، شبکه‌ی عصبی مصنوعی، تخمین وزن سازه.

sh.hashemi@pgu.ac.ir
zareii.masoud@gmail.com
fazeli@pgu.ac.ir

۱. مقدمه

با هدف بهینه‌تر کردن هزینه‌ی اسکلت (قاب) راهنمایی می‌کنند. انجام بررسی‌های ذکر شده قبل از شروع روند اصلی طراحی، نیازمند صرف وقت و هزینه‌ی زیاد است. به دست آوردن وزن اسکلت به نوعی هم وقت‌گیر و هم هزینه‌بر است. وقت‌گیر از این نظر که باید حتماً سازه تحلیل و طراحی شود، تا مقدار دقیق وزن مشخص شده باشد؛ هزینه‌بر از این نظر که تحلیل و طراحی سازه، مختص افراد با صلاحیت علمی است، که این نیز از هزینه‌های جانبی طرح خواهد بود. یکی از روش‌های کم کردن هزینه و افزایش سرعت در پروژه، استفاده از روش‌های شبکه‌ی عصبی مصنوعی (ANN)^۱ است که به دلیل هزینه‌ی کم، سرعت و دقت بالا استفاده از آن در این زمینه، مفید فایده خواهد بود.

شبکه‌های عصبی مصنوعی یا به زبان ساده‌تر شبکه‌های عصبی، سیستم‌ها و روش‌های محاسباتی نوینی برای یادگیری ماشینی، نمایش دانش و در انتها اعمال دانش به دست آمده در جهت پیش‌بینی پاسخ‌های خروجی از سامانه‌های پیچیده هستند. ایده‌ی اصلی این‌گونه شبکه‌ها (تا حدودی) الهام‌گرفته از شیوه‌ی کارکرد سیستم عصبی زیستی، برای پردازش داده‌ها و اطلاعات به منظور یادگیری و ایجاد دانش است. سیستم مذکور از شمار زیادی عناصر پردازشی به هم پیوسته به نام نرون تشکیل شده است که برای حل یک مسئله با هم هماهنگ عمل می‌کنند و توسط سیناپس‌ها (ارتباطات الکترومغناطیسی) اطلاعات را منتقل می‌کنند. در شبکه‌های

منابع مالی در ساخت و ساز، یکی از اساسی‌ترین موارد در طراحی و اجرای سازه است. به کمک تخمین وزن سازه در مراحل اولیه‌ی طراحی بر مبنای پارامترهای کلیدی طرح، طراح و کارفرما دید مناسبی نسبت به مقدار فولادی مصرفی کسب خواهند کرد و در این راه طراح می‌تواند با انتخاب پارامترهای مناسب و بهینه برای مشخصات هندسه‌ی سازه، سعی در بهینه‌سازی وزن اسکلت داشته باشد. از طرف دیگر، ضمن حفظ منافع مالی کارفرما، از همان ابتدا درک مناسب در مورد تناژ فولاد مصرفی به کارفرما داده می‌شود تا در جهت تأمین منابع مالی اقدام کند. هزینه‌ی تمام‌شده‌ی سازه، ارتباط مستقیمی با وزن فولاد مصرف‌شده در اسکلت سازه خواهد داشت. انتخاب سیستم با مشخصات مناسب و برآورد وزن اسکلت (قاب) پروژه‌ی ساختمانی را می‌توان با پیشنهاد، تحلیل، و طراحی سازه‌های متنوع متناسب با معماری طرح مدنظر به دست آورد. بررسی‌های انجام‌شده در مرحله‌ی طراحی مفهومی معماری پروژه، کمک شایانی به انتخاب سیستم مناسب با نگاه مهندسی ارزش و کم کردن وزن سازه خواهد کرد. به‌خصوص اینکه بازخوردهای حاصل در همان ابتدای روند طراحی، معمار و همچنین کارفرمای پروژه را در تغییرات احتمالی مشخصات طرح

* نویسنده مسئول

تاریخ: دریافت ۱۳۹۵/۱۲/۲، اصلاحیه ۱۳۹۶/۲/۱۲، پذیرش ۱۳۹۶/۲/۲۳

DOI:10.24200/J30.2018.2050.2078


مذکور، اگر یک نرون آسیب ببیند، بقیه‌ی نرون‌ها می‌توانند نبود آن را جبران کنند و نیز در بازسازی آن سهیم باشند و آن‌ها مانند سلول‌های زیستی، قادر به یادگیری‌اند. مثلاً با اعمال سوزش به سلول‌های عصبی لامسه یاد می‌گیرند که به طرف جسم داغ نروند و با این الگوریتم سیستم می‌آموزد که خطای خود را اصلاح کند. یادگیری در سیستم‌های ذکرشده به صورت تطبیقی صورت می‌گیرد، یعنی با استفاده از مثال‌ها، وزن سیناپس‌ها به گونه‌ی تغییر می‌کند که در صورت دادن ورودی‌های جدید، سیستم پاسخ درستی تولید کند.

در سال ۱۹۴۳، برای اولین بار یک مدل فرموله‌شده از شبکه‌ی عصبی مصنوعی به صورت برنامه‌نویسی شده معرفی شد،^[۱] و شبکه‌ی شکل داده‌شده‌ی مذکور تقریباً برای تمامی مدل‌های بعد، مدل پایه‌ی بودند. در سال ۱۹۶۲، نیز یک مدل فرموله‌شده‌ی ساده از نرون بیولوژیکی بر پایه‌ی نرون‌های پژوهش اخیر به نام پرسپترون^۲ (۱۹۶۰) توسعه داده شد،^[۲] که از واحدهای حساسی تشکیل می‌شدند که به تک‌لایه‌های نرون در پژوهش اخیر، ارتباط داده می‌شدند.^[۱] همچنین ایشان به الگوریتم یادگیری برای شبکه‌های پرسپترون با واحدهای پنهان دست یافتند که آن‌ها را پس‌انتشار (BP)^۳ می‌خوانند که حالا یکی از پرکاربردترین الگوریتم‌های آموزش است.^[۳] شبکه‌های عصبی مصنوعی، تنوع وسیعی در ساختار دارند. هر نوع از شبکه‌های عصبی مصنوعی در پژوهش‌های متنوع، مزیت خاص خود را دارند و در یادگیری و انطباق استفاده می‌شوند. اما بیشتر شبکه‌های عصبی مصنوعی به طور کلی در شناسایی و دسته‌بندی الگوها مناسب‌اند. یادگیری در شبکه‌های عصبی مصنوعی، دو نوع نظارت‌شده و نظارت‌نشده است. در یادگیری نظارت‌شده، شبکه با استفاده از خروجی‌ها آموزش می‌بیند. شبکه‌های پس‌انتشار نظارت‌شده، در حقیقت از محبوب‌ترین شبکه‌های عصبی مصنوعی برای برنامه‌های مهندسی عمران است.^[۴-۸] بعضی دیگر از شبکه‌های شناخته‌شده از نوع شبکه‌های هاپفیلد،^[۹] و بعضی دیگر از نوع شبکه‌ی کوهن هستند.^[۱۰]

۲. تئوری پژوهش

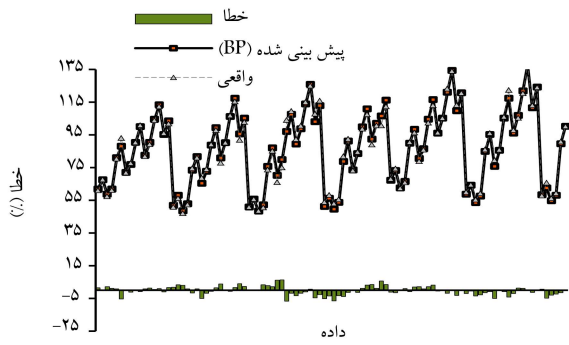
ساختار شبکه‌های عصبی از تعدادی واحد پردازشگر به نام نرون یا سلول عصبی که از طریق اتصال‌ها یا عصب‌ها به هم متصل هستند، تشکیل می‌شود. در یک شبکه با ساختار چندلایه‌ی (MLP)^۴، نرون‌ها به صورت لایه‌ی سازمان‌دهی می‌شوند. شبکه‌ی مذکور یک لایه‌ی ورودی، یک یا چند لایه‌ی پنهانی و یک لایه‌ی خروجی دارد. تعداد نرون‌های لایه‌های ورودی و خروجی، نشان‌دهنده‌ی تعداد پارامترهای ورودی و خروجی شبکه است. تعداد نرون‌های لایه‌ی میانی، ابتدا به صورت تجربی انتخاب و سپس به منظور حصول بهترین شبکه، بهینه‌یابی می‌شوند (شکل ۱). هر نرون به همه‌ی نرون‌های لایه‌ی بعد متصل است، ولی اتصالاتی بین نرون‌های یک لایه وجود ندارد. در هر نرون، یک تابع فعال‌ساز وجود دارد، که معمولاً به صورت تابع سیگموئید لگاریتمی، تابع سیگموئید تانژانت هیپربولیکی و یا تابع خطی است. سیگنال خروجی تابع فعال‌ساز از طریق اتصال‌ها به نرون‌های لایه‌ی بعدی منتقل می‌شود. یک وزن به هر اتصال نسبت داده می‌شود و بنابراین تعدادی سیگنال وزن‌دار وارد نرون لایه‌ی جدید می‌شود و در آنجا پس از جمع شدن، مجدداً تحت اثر تابع فعال‌ساز قرار می‌گیرند (شکل ۲).

اولین گام در تولید و به‌کارگیری شبکه‌ی عصبی مصنوعی، آموزش آن است. در واقع، منظور از آموزش شبکه، تنظیم مقدار وزن‌هاست، به گونه‌ی که خطای ناشی از اختلاف خروجی‌های شبکه با مقادیر خروجی اندازه‌گیری‌شده در الگوهای مختلف

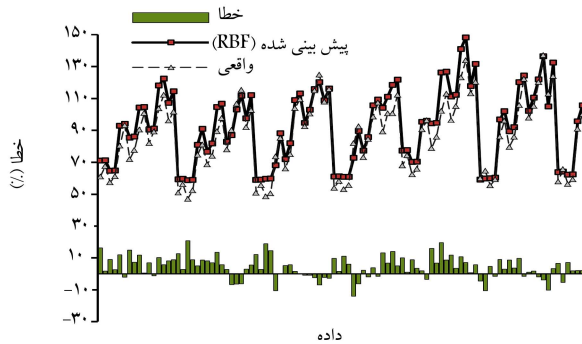


شکل ۱. شبکه‌ی عصبی مصنوعی.

در سازه‌های فلزی، معمولاً از انواع سیستم‌های سازه‌ی، همچون: قاب خمشی فولادی، قاب‌های مهاربندی هم‌مرکز و خارج از مرکز برای مقابله با بارگذاری زلزله و دیگر بارهای جانبی استفاده می‌شود. آزمایش‌های سازه‌ی نشان داده است که سیستم قاب‌های خمشی فولادی، توانایی ایجاد شکل‌پذیری و رفتار مناسب در بارگذاری‌های لرزه‌ی را دارند. هرچند که قاب‌های خمشی فولادی بسیار انعطاف‌پذیرند و محدودیت تغییرمکان، اغلب نقش مهم و کنترل‌کننده‌ی در طراحی آن‌ها ایفا می‌کند، اما از پر کاربردترین سازه‌ها هستند. بدون شک یکی از مهم‌ترین دغدغه‌های کارفرمایان و همچنین یکی از معیارهای انتخاب هئندسه و مشخصات سازه‌ی در مراحل اولیه‌ی طراحی (در مرحله‌ی طراحی مفهومی پروژه)، کمیته‌سازی میزان فولاد مصرفی و به تبع آن کاستن از هزینه‌ی ساخت اسکلت است. البته به نحوی که تمام ضوابط طراحی نیز پاسخ‌گو باشد و ملاحظات مد نظر معمار پروژه نیز رعایت شود. با تخمین وزن اسکلت براساس پارامترهای اصلی و تأثیرگذار طراحی، می‌توان قبل



الف) پاسخگویی شبکه عصبی مصنوعی چند لایه پس انتشار؛

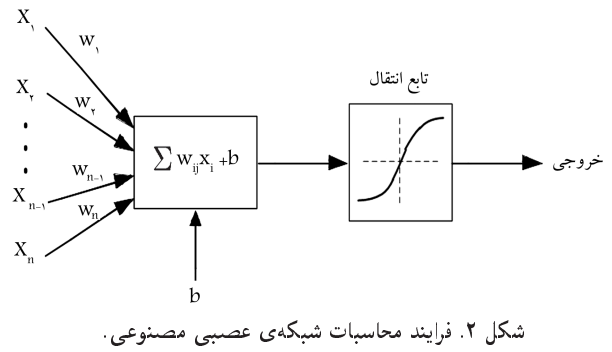


ب) پاسخگویی شبکه عصبی مصنوعی پایه شعاعی.

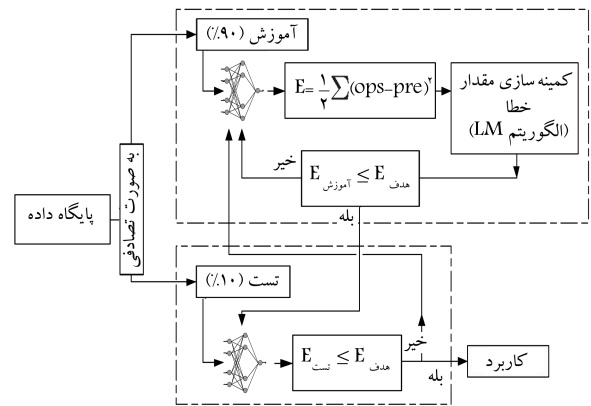
شکل ۴. ارزیابی پاسخگویی شبکه عصبی مصنوعی.

ولی تعداد لایه‌های پنهان مورد نیاز برای شبکه‌ی عصبی مصنوعی زیاد نیست. آموزش در شبکه‌های پس انتشار در دو فاز فید فوروارد و پس انتشار انجام می‌شود. در فاز فید فوروارد، نرون‌های لایه‌ی ورودی، مقادیر فردی ورودی را در لایه‌ی پنهان قرار می‌دهند. هر یک از نرون‌های لایه‌ی پنهان مجموع وزن‌دار شده‌ی آن ورودی را محاسبه می‌کنند و از میان تابع فعال‌ساز برای لایه‌ی خروجی عبور می‌دهند. با وزن‌دار شدن مجموع هر نرون در لایه‌ی خروجی محاسبات دنبال می‌شود، مجموع از میان تابع فعال‌ساز عبور می‌کند و یک مقدار خروجی برای شبکه را نتیجه می‌دهد. توابع پایه‌ی شعاعی (RBF)^۸ برای اولین بار در سال ۱۹۸۸^[۲۴] جهت طراحی شبکه‌های عصبی استفاده شده‌اند. تفاوت اساسی شبکه‌های RBF با شبکه‌های چند لایه، در بردار ورودی و تابع تحریک است.^[۲۵] شبکه‌ی RBF معمولاً ۳ لایه دارد: یک لایه‌ی ورودی، یک لایه با تعداد کافی گره و یک لایه‌ی خروجی. از تابع پایه‌ی شعاعی متقارن برای تابع انتقال یا فعال‌ساز آن در لایه‌ی پنهان آن استفاده می‌شود. انتقال از گره‌های ورودی به گره‌های خروجی به صورت غیرخطی و آموزش این بخش از شبکه به طور کلی بدون نظارت در نظر گرفته می‌شود. آموزش پارامترهای شبکه (وزن و بایاس) بین لایه‌های پنهان و خروجی با کمک نظارت بر پایه‌ی هدف اصلی رخ می‌دهد. در شبکه‌های RBF، ابتدا فاصله‌ی برداری میان بردار وزن و بردار ورودی محاسبه می‌شود؛ سپس بردار حاصل در بردار بایاس ضرب و حاصل ضرب آن به عنوان بردار ورودی به تابع انتقال شبکه در نظر گرفته می‌شود.

در پژوهش حاضر و بر اساس مدل‌سازی‌های انجام شده، که جزئیات آن در بخش بعدی ذکر شده است، با رجوع به شکل ۴، مقادیر خطای ایجاد شده در خصوص به‌کارگیری دو نوع شبکه‌ی عصبی RBF و BP قابل ارزیابی است. نتایج نشان می‌دهد که خطای شبکه‌ی RBF نسبت به شبکه‌ی BP به مراتب بیشتر است. به همین دلیل در ادامه‌ی روند پژوهش از شبکه‌ی BP استفاده شده است.



شکل ۲. فرایند محاسبات شبکه‌ی عصبی مصنوعی.



شکل ۳. یادگیری و آزمون شبکه‌ی عصبی مصنوعی.^[۲۳]

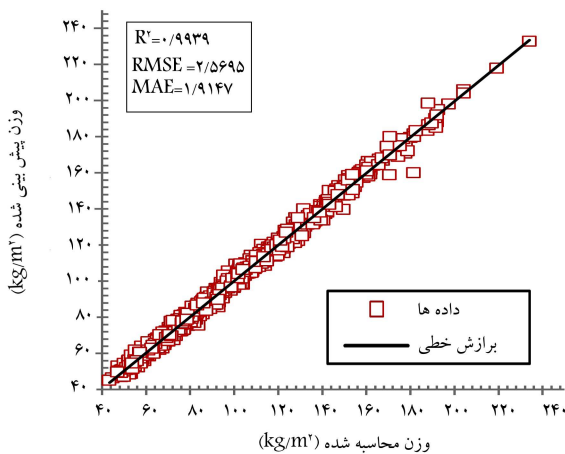
به مقدار کمی می‌توان کاهش یابد. شبکه برای آموزش به تعدادی الگو یا مجموعه‌ی داده و همچنین الگوریتم‌هایی همچون پس انتشار نیاز دارد. در روش پس انتشار وزن‌ها به نسبت خطای ایجاد شده اصلاح می‌شوند. چون الگوریتم پس انتشار به دلیل هم‌گرایی خطی، سرعت کمی دارد؛ در پژوهش حاضر، از الگوریتم توسعه یافته‌تری به نام الگوریتم لونبرگ - مارکواریت (LM)^۵ برای آموزش شبکه استفاده شده است، که به نوعی یک روش بهینه‌سازی است و برای یافتن کمینه‌ی توابع چندمتغیره‌ی غیرخطی از نوع مجموع مربعات، مشابه تابع خطای شبکه‌های عصبی، کاربرد دارد. الگوریتم لونبرگ - مارکواریت بدون محاسبه‌ی دقیق ماتریس هسین^۶ و با استفاده از بردار گرادینان و ماتریس ژاکوبین^۷ کار می‌کند و به علت استفاده از روش تقریب مشتق مرتبه‌ی دوم، سرعت هم‌گرایی بالاتری دارد.^[۲۴] به موازات فرایند آموزش، شبکه آزمایش می‌شود. بدین منظور درصدی از الگوهای موجود (معمولاً ۱۰٪) جدا و در هر گام از آموزش شبکه، خطای الگوهای مذکور در کنار خطای الگوهای آموزش محاسبه می‌شود. شکل ۳، روند آموزش و آزمایش شبکه را نشان می‌دهد. همچنین درصدی از الگوها به منظور صحت‌سنجی شبکه جدا می‌شوند و هیچ نقشی در آزمایش یا آموزش شبکه ندارند.

۱.۲. شبکه‌ی پس انتشار یا شبکه‌ی پایه‌ی شعاعی

شبکه‌ی عصبی پس انتشار (BP)، قانون یادگیری خاصی دارد. قانون یادگیری شبکه‌ی پس انتشار با به روزرسانی وزن‌های هر لایه بر اساس درصد خطای خروجی شبکه‌ی عصبی است. مطابق شکل ۱، واحدهای پردازش در یک شبکه‌ی عصبی مصنوعی پس انتشار همواره شامل دست کم ۳ لایه می‌شود. به جز لایه‌ی ورودی، تمامی لایه‌های دیگر در کار پردازش شرکت می‌کنند و در نهایت خروجی به دست می‌آید. این تذکر لازم است که اصلی‌ترین لایه در کار پردازش، لایه‌ی میانی است؛

جدول ۱. خصوصیات مدل‌های مورد بررسی در پژوهش حاضر.

مدل	تعداد نرون‌های لایه‌ی		الگوریتم آموزش	تابع فعال‌ساز دو لایه‌ی اول	درصد خطا (MSE)	
	اول	دوم			آموزش	آزمایش
۱	۷۰	۴۰	LM	tansig-tansig	۱۴٫۲	۳۲٫۱
۲	۴۰	۳۶	LM	tansig-tansig	۲٫۶	۳۰٫۶
۳	۴۰	۱۲	LM	logsig-logsig	۳٫۶	۱۱٫۴
۴	۲۵	۱۲	LM	logsig-logsig	۶٫۲	۱۴٫۴
۵	۲۵	۳	LM	tansig-tansig	۵٫۹	۱۲٫۷
۶	۲۵	-	LM	Logsig	۴٫۱	۷٫۲
۷	۷	۳	LM	logsig-logsig	۶٫۸	۸٫۵
۸	۷	-	LM	tansig	۹٫۱	۹٫۸



شکل ۵. مقایسه‌ی داده‌های واقعی و پیش‌بینی شده.

۲.۲. آموزش شبکه در پژوهش حاضر

بر مبنای روش چندلایه‌ی BP، برای تعیین شبکه‌ی با بهترین عملکرد، مدل‌های مختلفی مطابق جدول ۱ بررسی شدند که در آن‌ها تعداد لایه‌های میانی، تعداد نرون‌های هر لایه، الگوریتم آموزش و توابع فعال‌ساز تغییر یافتند تا شبکه با خطای بهینه حاصل شود. نهایتاً یک مدل با ۷ نرون در لایه‌ی ورودی، ۲۵ نرون در لایه‌ی پنهان و یک نرون در لایه‌ی خروجی به عنوان مدل بهینه انتخاب شد. در مدل مذکور از الگوریتم لونیگ - مارکواریت (LM) برای آموزش استفاده شده است. تابع انتقال لایه‌ی پنهان Logsig و لایه‌ی آخر Liner است. از ۱۱۰۱ الگوی ایجاد شده، ۱۰٪ برای آزمایش، ۱۰٪ برای ارزیابی شبکه و ۸۰٪ باقیمانده برای آموزش شبکه استفاده شده است. در رابطه‌ی ۱، تابع انتقال Logsig ارائه شده است:

$$Activation Function = 1 / (1 + e^{-\sum w_{ji} o_i - b}) \quad (1)$$

که در آن، w_{ji} وزن مرتبط با نرون i در لایه‌ی پایین‌تر به نرون j در لایه‌ی بالاتر و o_i خروجی نرون i و b یک بایاس هستند.

روند آموزش که با استفاده از شبکه‌ی عصبی مصنوعی در محیط نرم‌افزار متلب^۹،^{۲۶} توسعه پیدا کرده‌اند، به صورت خلاصه شامل این مراحل بوده است:

- خواندن و دسته‌بندی داده‌های آموزش و تعیین متغیرهای ورودی و خروجی شبکه‌ی عصبی مصنوعی؛
- نرمالایز کردن داده‌های آموزش به روش min-max در بازه‌ی ۰ تا ۱؛
- مشخص کردن ساختار شبکه که با تعیین تعداد لایه‌های پنهان و تعداد نرون‌های لایه‌های ورودی، پنهان و خروجی صورت می‌گیرد؛
- تعیین تابع انتقال مورد استفاده برای لایه‌ی پنهان و لایه‌ی خروجی که موارد استفاده معمولاً سیگموئید و خطی هستند؛
- تعیین قاعده‌ی مورد استفاده در یادگیری که الگوریتم لونیگ - مارکواریت (LM) استفاده شده است؛
- تعیین پارامترهای آموزش مورد نیاز برای بهینه‌شدن میانگین مجذور خطاها MSE^{۱۰} و حدود بیشینه‌ی تعداد تکرار؛
- آموزش شبکه‌ی عصبی طبق تعاریف در گام‌های اخیر؛
- محاسبه‌ی متغیرهای هدف نرمالایز شده و تبدیل آن‌ها به همان واحدهای هدف اصلی؛

- ارزیابی بازده آموزش شبکه‌ی عصبی مصنوعی به وسیله‌ی مقایسه‌ی خروجی‌های شبکه‌ی عصبی با مقادیر اصلی هدف.

۳.۲. عملکرد شبکه

با مقایسه‌ی نتایج مدل شبکه‌ی عصبی مصنوعی در شکل ۵ با مقادیر پیش‌بینی شده می‌توان به تخمین با دقت بالای برنامه در به دست آوردن وزن واحد سطح سازه‌ی ساختمان دست یافت. مقایسه‌ی مدل شبکه‌ی عصبی مصنوعی با داده‌های واقعی به کمک محاسبه‌ی مقادیر خطاهایی مانند میانگین قدرمطلق خطا (MAE)^{۱۱} و جذر میانگین مربع خطاها (RMSE)^{۱۲} و همچنین ضریب R^2 از رگرسیون خطی بین مقادیر پیش‌بینی شده و داده‌های واقعی صورت گرفته است. شاخص‌های مذکور در روابط ۲ الی ۴ معرفی شده‌اند.

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - O_i| \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (4)$$

-- نوع مقطع ستون‌ها: مقطع ستون‌ها در مدل‌های مورد بررسی از دو نوع جعبه‌یی (BOX) و H (IPB) بوده و ابعاد آن‌ها به نحوی در نظر گرفته شده‌است که ضوابط فشردگی لرزه‌یی را تأمین کرده باشند. اگرچه مقاطع IPB در بازار کمتر یافت می‌شوند، ولی در پژوهش حاضر از این نوع مقاطع به دلیل H شکل بودن و داشتن ضوابط فشردگی لرزه‌یی استفاده شده است و به نوعی نماینده‌ی دیگر مقاطع ساخته‌شده از ورق به‌صورت H خواهند بود که طراحی اسکلت، امری نسبتاً رایج است.

پایگاه داده‌ی پژوهش حاضر شامل بیش از ۱۱۰۰ مدل از ساختمان‌های با سیستم قاب خمشی بوده است. در پژوهش حاضر، طراحی‌های لازم برای آماده‌سازی زوج بردارهای ورودی و خروجی با تغییر در پارامترهای نامبرده انجام شده است. طراحی‌های مذکور، مدل‌هایی با طول دهانه‌های ۳، ۴، ۴٫۵، ۵، ۵٫۵ و ۶ متر و تعداد طبقات ۳، ۴، ۹، ۱۲ و ۱۴ را شامل می‌شوند. ارتفاع طبقات نیز برای طراحی به‌صورت متنوع ۳، ۴ و ۴٫۴ متر استفاده و جنس خاک ساخت‌گاه در دو نوع ۲ و ۳ بررسی شده است. مدل‌ها پس از بارگذاری، براساس آیین‌نامه‌ی AISC ۳۶۰-۱۰ به روش LFRD طراحی شده‌اند.^[۲۹] برای تحلیل و طراحی مدل‌ها از نرم‌افزار SAP۲۰۰۰ استفاده شده است.^[۳۰] مقاطع مورد استفاده در روند طراحی تیرها در همه‌ی مدل‌ها از خانواده‌ی IPE بوده است. برای تخمین وزن اسکلت پس از پایان مدل‌سازی‌ها و تکمیل طراحی‌های انجام‌شده، مقادیر وزن هر کدام از سازه‌ها از نرم‌افزار گرفته شده است. این مقدار به‌صورت خلاصه از مجموع وزن ستون‌ها و تیرهای به‌کاررفته در مدل حاصل شده است. از طرفی وزن کل اسکلت (قاب) شامل اتصال‌هایی همچون اتصال‌های تیرها، ستون‌ها، صفحه‌ستون‌ها و غیره نیز است. برای لحاظ کردن وزن اتصال‌ها و دیگر قطعه‌های الحاقی، شامل ورق‌های پیوستگی و وصله ستون‌ها، و غیره نیز درصدی از وزن کل را (که مقداری بین ۵ تا ۱۰ درصد در نظر گرفته شده است)، به وزن مجموع تیرها و ستون‌ها اضافه شده است. مقادیر حاصل از مدل‌سازی‌های برای ادامه‌ی پیشبرد روش، به شبکه‌ی عصبی مصنوعی واگذار شده است. با توجه به اهمیت صحت انجام شبکه، ۱۰٪ داده‌های طراحی شده به ارزیابی تخصیص داده شده است، تا برنامه مشکلی از نظر جواب‌گویی نهایی نداشته باشد. بعد از تقسیم‌بندی پایگاه داده به آموزش شبکه پرداخته شده است.

۴. بحث و تفسیر نتایج

با معرفی مشخصاتی شامل شتاب مبنای طراحی (A) و ضریب رفتار نهایی سازه (R_u)، در ادامه نتایج به‌دست آمده از شبکه‌ی عصبی و مطالعه‌ی پارامتریک ارائه شده است:

۱.۴. تأثیر تعداد طبقات در وزن اسکلت

در شکل ۷، به ازاء ثابت فرض کردن پارامترهای $R_u = 5$ ، $L = 4 m$ (برای سیستم قاب خمشی متوسط)، $A = 0.3$ (منطقه با وضعیت لرزه‌خیزی زیاد) و خاک نوع ۳ تأثیر تعداد طبقات به همراه تغییر نوع مقطع ستون بررسی شده است. افزایش وزن واحد سطح سازه با اضافه شدن تعداد طبقات بدیهی است، ولی منحنی‌های تولیدشده می‌توانند نرخ رشد آن را بهتر نشان بدهند. این افزایش با شیب افزایش‌دهی ملایمی به سمت بالا در حرکت است. نکته‌ی مهم‌تری که در نمودارها مشاهده می‌شود، تفاوت وزنی قابل توجه مدل‌های با ستون با مقطع BOX و H شکل (IPB) است. این تفاوت با کم‌تر بودن وزن تمامی مدل‌هایی که از مقطع BOX در ستون آن‌ها استفاده

که در آن‌ها، O_i مقادیر مشاهده‌یی، P_i مقادیر پیش‌بینی‌شده، \bar{O} میانگین مقادیر مشاهده‌یی و n تعداد کل داده‌ها در هر مرحله از آزمون‌های آموزش، آزمایش و ارزیابی است. هر چه مقدار $RMSE$ و MAE به صفر و مقدار R^2 به ۱ نزدیک‌تر باشد، نشان‌دهنده‌ی نزدیک‌تر بودن مقادیر مشاهده شده و پیش‌بینی شده به یکدیگر و دقیق‌تر بودن جواب‌ها در هر مرحله است. شاخص‌های عملکرد، نشانگر کارایی مناسب شبکه‌ی عصبی مصنوعی برای پیش‌بینی وزن اسکلت هستند.


۳. مدل‌سازی سازه‌ها و تهیه‌ی داده‌های آموزش

مطالعات حاضر بر روی مدل‌های با پلان منظم و سه بعدی انجام شده است. سیستم سازه‌یی از نوع قاب خمشی با شکل‌پذیری متوسط بوده و در شکل ۶، یک نمونه از تیپ پلان‌ها ارائه شده است. تنش تسلیم فولاد مصرفی 240 مگاپاسکال و تنش نهایی آن 370 مگاپاسکال در نظر گرفته شده است. بارگذاری ساختمان بر مبنای کاربری مسکونی بوده و مقادیری معمول از بارهای مرده و زنده در مدل‌سازی‌ها برای سطوح و دیوارهای پیرامونی و داخلی لحاظ شده است. به این ترتیب که بار مرده در سطوح طبقات با احتساب سربار معادل تیغه‌های داخلی (kg/m^2) 670 و بار زنده‌ی طبقات (kg/m^2) 200 در نظر گرفته شده است. همچنین بار مرده و زنده‌ی پشت‌بام به ترتیب 575 و 150 (kg/m^2) در نظر گرفته شده است. با انتخاب محلی فرضی برای راه پله (حد فاصل محورهای ۱ و ۲ و C و D) بار مرده و زنده‌ی این ناحیه به ترتیب 650 و 500 (kg/m^2) در نظر گرفته شده است. بار دیوارهای خارجی ساختمان در دو قسمت با و بدون نما نیز در محل خود اعمال شده است. بارگذاری مدل‌ها بر مبنای آیین‌نامه‌ی لرزه‌یی ایران،^[۲۷، ۲۸] انجام شده است. با توجه به کاربری مفروض برای ساختمان، که از نوع مسکونی است، ضریب اهمیت سازه ۱ در نظر گرفته شده است. ضوابط محدودکننده‌ی تغییرمکان جانبی سازه مطابق با مقررات آیین‌نامه‌یی در طراحی مدل‌ها لحاظ شده است. از آنجا که تعداد پارامترهای مؤثر در رفتار ساختمان به خصوص وزن ساختمان بسیار زیاد است، در پژوهش حاضر روی مهم‌ترین آن‌ها تمرکز کرده و تعداد محدودی از تأثیرگذارترین آن‌ها در رفتار سازه و به تبع آن در وزن نهایی سازه‌ی طراحی‌شده، بررسی شده‌اند. پارامترهای مذکور عبارت‌اند از:




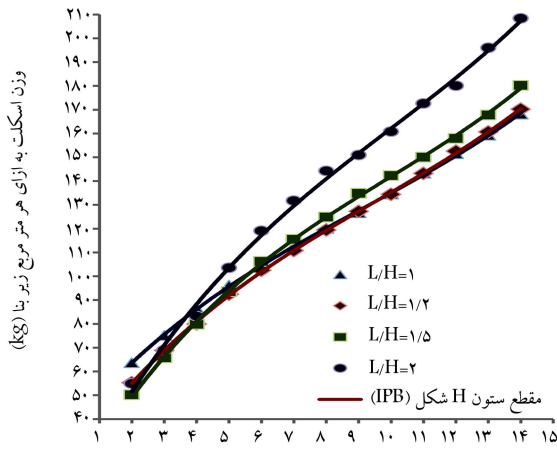
-- طول دهانه‌های قاب (L);

-- ارتفاع طبقات (H);

-- تعداد طبقات ساختمان (N);



شکل ۶. نمونه‌ی پلان از مدل‌های مورد بررسی در پژوهش حاضر.



شکل ۸. نمودار تغییر وزن با افزایش تعداد طبقات و نسبت طول به ارتفاع طبقه.

شکل ۷. نمودار تغییر وزن با افزایش تعداد طبقات و تغییر نوع مقطع ستون.

برای سازه با ستون BOX:

$$\left\{ \begin{array}{l} L/H = 1 \Rightarrow W = 0,0056 N^2 - 0,269 N^1 + 10,52 N + 38,77 \\ L/H = 1/2 \Rightarrow W = 0,0126 N^2 - 0,555 N^1 + 14,50 N + 22,77 \\ L/H = 1/5 \Rightarrow W = 0,0171 N^2 - 0,733 N^1 + 16,97 N + 17,22 \\ L/H = 2 \Rightarrow W = 0,0283 N^2 - 0,942 N^1 + 19,77 N + 16,16 \end{array} \right. \quad (5)$$

برای سازه با ستون H شکل (IPB):

$$\left\{ \begin{array}{l} L/H = 1 \Rightarrow W = 0,0347 N^2 - 0,947 N^1 + 15,99 N + 35,16 \\ L/H = 1/2 \Rightarrow W = 0,0391 N^2 - 1,203 N^1 + 18,63 N + 21,19 \\ L/H = 1/5 \Rightarrow W = 0,05211 N^2 - 1,547 N^1 + 23,68 N + 7,713 \\ L/H = 2 \Rightarrow W = 0,0546 N^2 - 1,630 N^1 + 26,61 N + 4,467 \end{array} \right. \quad (6)$$

شده است، نمایان می‌شود. به بیان دیگر، استفاده از مقاطع BOX نسبت به H شکل در سازه‌های فولادی خمشی باعث کاهش مصرف فولاد می‌شود و مقرون به صرفه‌تر خواهد بود. به طور متوسط مقدار صرفه‌جویی را که استفاده‌ی مقطع BOX نسبت به H شکل در هزینه دارد، حدود ۱۰٪ است که قابل توجه است. لذا استفاده از مقاطع BOX نسبت به H شکل در ستون سازه‌های فولادی خمشی باعث کاهش مصرف فولاد می‌شود و مقرون به صرفه‌تر خواهد بود.

۲.۴. تأثیر نسبت طول دهانه به ارتفاع طبقه در وزن اسکلت

در شکل ۸، به اِزاء ثابت فرض کردن پارامترهای $H = 3,2 m$ ، $Ru = 5$ (برای سیستم قاب خمشی متوسط)، $A = 0,3$ (منطقه با وضعیت لرزه‌خیزی زیاد) و خاک نوع ۳ تأثیر تعداد طبقات به همراه تغییر نوع مقطع ستون به اِزاء نسبت‌های مختلف L/H بررسی شده است. نتایج نشان می‌دهند که افزایش نسبت طول دهانه به ارتفاع طبقات (L/H) در تمامی مدل‌ها باعث افزایش وزن می‌شود. افزایش L/H در ساختمان از ۱ به ۱,۵ باعث افزایش تقریباً ۰,۵٪ وزن اسکلت می‌شود و همچنین افزایش این نسبت از ۱ به ۲ می‌تواند اضافه وزنی حدود ۰,۲٪ را به وزن کل اسکلت ساختمان تحمیل کند. در روابط ۴ و ۵، معادلات برآورد شده به نتایج حاصل از شکل ۸ ارائه شده است که براساس آن‌ها امکان تخمین سریع مقدار وزن فولاد مصرفی به اِزاء واحد سطح زیربنای ساختمان میسر خواهد بود.

با نگاهی به نمودارهای شکل ۹ می‌توان فرورفتگی‌هایی را با افزایش نسبت طول دهانه به ارتفاع طبقه (L/H) در تمامی مدل‌ها مشاهده کرد. از طرفی نمودارها نشان می‌دهند که با افزایش L/H در ساختمان‌هایی که تعداد طبقات کمتری دارند، وزن ابتدا سیر نزولی دارد و سپس صعودی می‌شود؛ در صورتی که ساختمان‌های با تعداد طبقات زیاد، بلافاصله سیر صعودی را برای وزن تجربه خواهند کرد. همچنین می‌توان به این مسئله پی برد که وزن اسکلت در نسبت خاصی از طول دهانه به ارتفاع طبقه (L/H) ، کمترین مقدار را به خود می‌گیرد. به این صورت که هر چه تعداد طبقات ساختمان کاهش می‌یابد، این نسبت بیشتر می‌شود. یعنی هر چه ساختمان‌ها کوتاه‌تر می‌شوند، افزایش این نسبت به بهینه‌سازی وزن سازه بیشتر کمک می‌کند. اگر لازم باشد مقادیر بهینه در مدل‌های مذکور شامل تعداد طبقات متفاوت به دست آورده شود، باید کمینه‌ی تمامی معادلات محاسبه شود. این مقادیر از مشتق‌گیری از تمامی معادلات برازش شده بر نمودارهای شکل ۹ به دست می‌آید. با محاسبه‌ی تمامی مقادیر مذکور، جدول ۲ نتیجه می‌شود. می‌توان به این نتیجه رسید که برای بهینه‌شدن وزن اسکلت با افزایش طبقات، مقادیر L/H را می‌توان مطابق با جدول ۲ کاهش داد. این کاهش تا جایی ادامه دارد که این نسبت به مقداری حدود ۱ به بهینه‌ترین مقدار خود می‌رسد. در معنای دیگر، در ساختمان‌های با طبقات بالا، هر چه این نسبت به ۱ نزدیک‌تر باشد، وزن بهینه‌تر خواهد شد.


۵. نتیجه‌گیری

در پژوهش حاضر، روش شبکه‌ی عصبی برای تخمین وزن سازه‌های با سیستم قاب خمشی فولادی با کاربری مسکونی استفاده و بیش از 110° مدل تحلیل و طراحی شده است. سپس با استفاده از شبکه‌ی عصبی مصنوعی به تحلیل داده‌های حاصل پرداخته و اثر پارامترهای مختلفی، شامل: ارتفاع طبقه، طول دهانه، تعداد طبقات و نوع مقطع ستون بررسی شده است. خلاصه‌ی نتایج به دست آمده از پژوهش حاضر عبارت‌اند از:

- روش پیشنهادی و همچنین منحنی‌های تخمین وزن واحد سطح زیربنای حاصل بر مبنای روش شبکه‌ی عصبی می‌تواند راهنمای طراحان برای برآورد و تخمین وزن اسکلت ساختمان قبل از شروع طراحی و در مرحله‌ی طراحی ابتدایی سازه باشد تا به نوعی بتوانند در انتخاب مشخصات هندسه‌ی بهینه و پیش‌بینی میزان فولاد مصرفی و تخمین هزینه‌ی اجرا، تصمیم‌گیری مناسب‌تری داشته باشند.
- مقادیر ناچیز $RMSE$ و MAE و همچنین ضریب رگرسیونی با مقدار 0.99 و نزدیک به ۱، نمایانگر عملکرد مناسب شبکه‌ی عصبی مصنوعی در حوزه‌ی کاربرد برآورد وزن سازه است.
- ساختار شبکه‌ی عصبی پیشنهادی به صورت $(1-25-7)$ شامل ۷ نرون در لایه‌ی اول، ۲۵ نرون در لایه‌ی دوم و یک نرون پایانی است. بررسی‌های پارامتریک انجام شده، خلاصه‌ی این نتایج را در بر داشته است:
- با افزایش نسبت طول دهانه به ارتفاع طبقه (L/H) ، مقدار افزایش وزن در سازه‌های با سیستم قاب خمشی فولادی با تعداد طبقات مختلف یکسان نیست. با افزایش L/H در ساختمان‌هایی که تعداد طبقات کمتری دارند، مقدار وزن سازه ابتدا سیر نزولی دارد و سپس صعودی می‌شود. در صورتی که وزن سازه‌های با

۳.۴. تأثیر تعداد طبقات با افزایش نسبت طول دهانه به ارتفاع طبقه در وزن ساختمان

در ادامه، به گونه‌ی متفاوت به بحث تأثیرگذاری نسبت طول دانه به ارتفاع طبقه و تعداد طبقات ساختمانی بر وزن نگاه شده است. افزایش پارامتر مذکور بر روی مدل‌های ساختمانی با تعداد طبقات متفاوت بررسی شده‌اند، تا مقدار بهینه‌ی آن برای مدل‌های ذکر شده نیز بیان شود. در شکل ۹، به ازاء ثابت فرض کردن پارامترهای $A = 0.3$ ، $Ru = 5$ ، $H = 3.4$ m، نوع مقطع ستون BOX، تأثیر نسبت L/H در وزن سازه به ازاء تغییر تعداد طبقات از ۳ تا ۱۴ بررسی شده است.



شکل ۹. نمودار تغییر وزن با افزایش نسبت طول دهانه و تعداد طبقات.

جدول ۲. بهینه‌ی مقدار نسبت طول دهانه به ارتفاع طبقه در ساختمان‌های با تعداد طبقات مختلف ($H = 3.4$).

L	L/H	N
(طول دهانه به متر)	(نسبت ارتفاع به طول دهانه)	(تعداد طبقات)
۴٫۵۵	۱٫۳۴	۳
۴٫۳	۱٫۲۷	۴
۴٫۱	۱٫۱۲	۵
۴٫۰	۱٫۱۷۵	۶
۳٫۷۵	۱٫۱۰۸	۷
۳٫۶۵	۱٫۰۷	۸
۳٫۵	۱٫۰۳	۹
۳٫۴۵	۱٫۰۱	۱۰
۳٫۴	۱٫۰۰	۱۱
۳٫۴	۱٫۰۰	۱۲
۳٫۳۵	۰٫۹۸۸	۱۳
۳٫۲۵	۰٫۹۵۹	۱۴

فولاد مصرفی خواهد شد. همچنین افزایش این نسبت از ۱ به ۲ باعث افزایش ۲۰ درصدی میزان فولاد مصرفی خواهد شد.

- سازه‌های ساخته‌شده با ستون‌های با مقاطع BOX نسبت سازه‌های با ستون با مقطع H شکل (IPB) حدود ۱۰٪ سبک وزن‌تر خواهند بود.

تعداد طبقات زیاد با افزایش L/H سیر صعودی دارد. در مجموع، با تغییر تعداد طبقات ساختمانی از ۳ تا ۱۴، بهترین نسبت طول به دهانه برای کمیته‌ساختن مقدار وزن اسکلت، از ۱/۳۴ تا ۰/۹۶ متغیر خواهد بود.

- افزایش نسبت L/H در ساختمان از ۱ به ۱/۵ باعث افزایش ۵ درصدی میزان

پانوشتها

1. artificial neural network
2. Perceptron
3. back propagation
4. multi-layer perceptron
5. levenberg-marquadt (LM)
6. hessian matrix
7. Jacobian
8. radial basis function (RBF)
9. Matlab
10. mean square error
11. mean absolute error
12. root mean square error

منابع (References)

1. McCulloch, W.S. and Pitts W. "A logical calculus of the ideas immanent in nervous activity", *The Bulletin of Mathematical Biophysics*, **5**(4), pp. 115-133 (1943).
2. Rosenblatt, F., *Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms*, Washington, D.C., Spartan Books (1962).
3. Rumelhart, D.E., Hinton, G.E. and Williams, R.J. "Learning internal representations by error propagation", In: *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, 1, pp. 318-362, Cambridge, MIT Press (1986).
4. Vanluchene, R.D. and Roufai, S. "Neural networks in structural engineering", *Computer-Aided Civil and Infrastructure Engineering*, **5**(3), pp. 207-215 (1990).
5. Arslan, A. and Ince, R. "Neural network-based design of edge-supported reinforced concrete slabs", *Structural Engineering Review*, **8**(4), pp. 329-335 (1996).
6. Arslan, A. and Ince, R. "The neural network approximation to the size effect in fracture of cementitious materials", *Engineering Fracture Mechanics*, **54**(2), pp. 249-261 (1996).
7. Adeli, H. and Park, H.S. "A neural dynamic model for structural optimization theory", *Computers & Structures*, **57**(3), pp. 383-390 (1995).
8. Oh, J.W., Lee, I.W., Kim, J.T. and et al. "Application of neural networks for proportioning of concrete mixes", *ACI Material Journal*, **96**(1), pp. 61-67 (1999).
9. Hopfield, J.J. "Neural networks and physical systems with emergent collective computational abilities", *Proceedings of the National Academy of Sciences of the United States of America*, **79**(8), pp. 2554-2558 (1982).

10. Kohonen, T. "Self-organization and associative memory", *Springer Series in Information Sciences*, **8**, pp. (1989).
11. Chojaczyk, A.A., Teixeira, A.P., Neves, L.C. and et al. "Review and application of Artificial Neural Networks models in reliability analysis of steel structures", *Structural Safety*, **52**(A), pp. 78-89 (2015).
12. Hakim, S.J.S., Abdul Razak, H. and Ravanfar, S.A. "Fault diagnosis on beam-like structures from modal parameters using artificial neural networks", *Measurement*, **76**, pp. 45-61 (2015).
13. Arslan, M.H. "An evaluation of effective design parameters on earthquake performance of RC buildings using neural networks", *Engineering Structures*, **32**(7), pp. 1888-1898 (2010).
14. Jorgensen, C., Grastveit, R. and Roca, J.G. "Bearing capacity of steel-caged RC columns under combined bending and axial loads: Estimation based on artificial neural networks", *Engineering Structures*, **56**, pp. 1262-1270 (2013).
15. Pu, Y. and Mesbahi, E. "Application of artificial neural networks to evaluation of ultimate strength of steel panels", *Engineering Structures*, **28**(8), pp. 1190-1196 (2006).
16. Lee, S. and Lee, C. "Prediction of shear strength of FRP-reinforced concrete flexural members without stirrups using artificial neural networks", *Engineering Structures*, **61**, pp. 99-112 (2014).
17. Tohidi, S. and Sharifi, Y. "Neural networks for inelastic distortional buckling capacity assessment of steel I-beams", *Thin-Walled Structures*, **94**, pp. 359-371 (2015).
18. Dahou, Z., Sbartai, Z.M., Castelc, A. and et al. "Artificial neural network model for steel-concrete bond prediction", *Engineering Structures*, **31**(8), pp. 1724-1733 (2009).
19. Shouling, H. and Jiang, L. "Modeling nonlinear elastic behavior of reinforced soil using artificial neural networks", *Computers & Structures*, **9**(3), pp. 954-961 (2009).
20. Cabalar, A.F. and Cevik A. "Modelling damping ratio and shear modulus of sand-mica mixtures using neural networks", *Engineering Geology*, **104**(1), pp. 31-40 (2009).

21. Jiang, G., Keller, J., Bond, Ph.L. and et al. "Predicting concrete corrosion of sewers using artificial neural network", *Water Research*, **92**, pp. 52-60 (2016).
22. Khajeh, M., Moghaddam, M.Gh. and Shakeri, M. "Application of artificial neural network in predicting the extraction yield of essential oils of *Diplotaenia cachrydi-folia* by supercritical fluid extraction", *Supercritical Fluids*, **69**, pp. 91-96 (2012).
23. Marquardt, C. and Zenner, H. "Lifetime calculation under variable amplitude loading with the application of artificial neural networks", *International Journal of Fatigue*, **27**(8), pp. 920-927 (2005).
24. Broomhead, D.S. and Lowe, D. "Multi-variable functional interpolation and adaptive networks", *Complex Systems*, **2**, pp. 321-355 (1988).
25. Wasserman, P.D. "Advanced methods in neural computing", Prentic Hall Company, VanNostrand Reinhold (1993).
26. MathWorks, MATLAB "The language of technical computing", Version 7.11.0. (R2014a). (2014).
27. Iranian National Building Code, Part 6: Loading on Structures, Ministry of Road and Urban Development, Tehran, Iran, (In Persian) (2013).
28. Road, Housing and Urban Development Research Center, "Iranian code of practice for seismic resistant design of buildings", Standard No. 2800, 4th edition, (In Persian) (2013).
29. AISC360-10: Specification for Structural Steel Buildings, An American National Standard, 5th Printing (2010).
30. Computers and Structures: Inc. SAP2000 advanced 14.2.0, Berkeley, California, USA, (2010).