

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

سید شاکر هاشمی\* (استادیار)

مسعود زارعی (کارشناس ارشد)

عبدالرضا فاضلی (استادیار)

دانشکده‌ی مهندسی عمران، دانشگاه خلیج‌فارس، 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 خمی اقدام شده است. در این راستا، پس از آموزش شبکه و ارزیابی دقت روش، متأثر از تعییر 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.

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

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

## 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)<sup>۱</sup> 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 داشت 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 داشت است. سیستم مذکور از شمار زیادی عناصر پردازشی 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 تاثیر فولاد مصرفی به کارفرما داده می‌شود تا در جهت تأمین منابع مالی اقدام کند. هزینه‌ی تماشده‌ی سازه، ارتباط مستقیمی با وزن فولاد مصرف شده 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 مناسب با معماری طرح مدنظر به دست آورد. بررسی‌های انجام شده در مرحله‌ی طراحی مفهومی معماری پروژه، کمک شایانی به انتخاب سیستم مناسب با نگاه مهندسی ارزش و کم کردن وزن سازه خواهد کرد. به خصوص اینکه بازخوردهای حاصل در همان ابتدا روند طراحی، معمار و همچنین کارفرمای پروژه را در تغییرات احتمالی مشخصات طرح

\* نویسنده مسئول  
تاریخ: دریافت ۱۲/۲/۱۳۹۵، اصلاحیه ۱۲/۲/۱۳۹۶، پذیرش ۲/۲۳/۱۳۹۶.

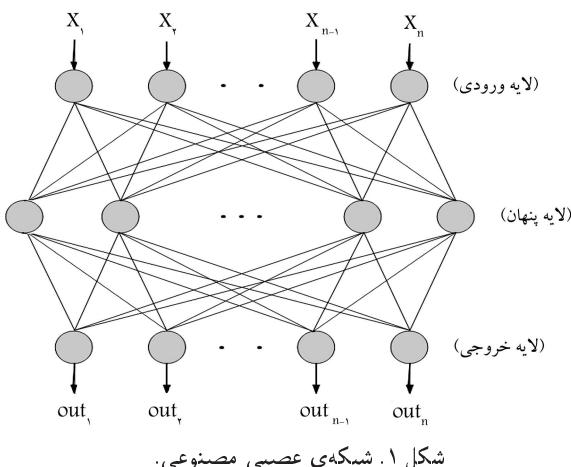
DOI:10.24200/J30.2018.2050.2078

از طراحی اسکلت ساختمان، دیدی مناسب نسبت به وزن آن ایجاد کرد. این کار به کارفرما و همچنین طراحان اجراه می‌دهد تا تخمینی مؤثر در مورد تنازع اسکلت پروژه‌ی در پیش رو داشته باشد. تنازع اسکلت نیز سهم قابل توجهی در هزینه‌ی کل پروژه دارد. در پژوهش حاضر، از سودمندی روش شبکه‌ی عصبی مصنوعی در پیش‌بینی نظام‌مند استفاده شده است تا ابتدا روش مناسب برای پیش‌بینی مقدار فولاد لازم موردنی استفاده در ساختمان‌های با قاب خشمی فولادی ارائه و از طرفی تأثیر تغییر تعدادی از پارامترهای اساسی در وزن قاب‌های خشمی فولادی برسی شود. در این راستا، ابتدا مدل‌های متنوع از ساختمان‌های با سیستم خشمی فولادی براساس تغییر در پارامترهای اساسی طراحی شده است؛ سپس با ارائه‌ی مدل‌های مذکور به شبکه‌ی عصبی مصنوعی و آموزش شبکه توسط آن، صحت شبکه با کمک خطاهای ارائه‌شده کنترل می‌شود و در ادامه، نتایج مطالعه‌ی پارامتریک پارامترهای ذکر شده در ارتباط با وزن هر مترمربع از زیربنای ارائه شده است.

## ۲. تئوری پژوهش

ساختر 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)<sup>۳</sup>، نرون‌ها به صورت لایه‌ی سازمان‌دهی می‌شوند. شبکه‌ی مذکور یک لایه‌ی ورودی، یک یا چند لایه‌ی پنهانی و یک لایه‌ی خروجی دارد. تعداد نرون‌های لایه‌ی ورودی و خروجی، نشان‌دهنده‌ی تعداد پارامترهای ورودی و خروجی شبکه است. تعداد نرون‌های لایه‌ی میانی، ابتدا به صورت تجریبی انتخاب و سپس به منظور حصول بهترین شبکه، بهینه‌یابی می‌شوند (شکل ۱). هر نرون به همه‌ی نرون‌های لایه‌ی بعد متصل است، ولی اتصالی بین نرون‌های یک لایه وجود ندارد. در نرون، یکتابع فعال‌ساز وجود دارد، که معمولاً به صورت تابع سیگموئید لگاریتمی، تابع سیگموئید تائزانت هیپربولیک و یا تابع خطی است. سیگنال خروجی تابع فعال‌ساز از طریق اتصال‌ها به نرون‌های لایه‌ی بعدی منتقل می‌شود. یک وزن لایه‌ی ورودی می‌شود و بنا بر این تعدادی سیگنال وزن دار وارد نرون لایه‌ی جدید می‌شود و در آنجا پس از جمع شدن، مجدد 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 وزن‌های است، به گونه‌یی که خطای ناشی از اختلاف خروجی‌های شبکه با مقادیر خروجی اندازه‌گیری شده در الگوهای مختلف



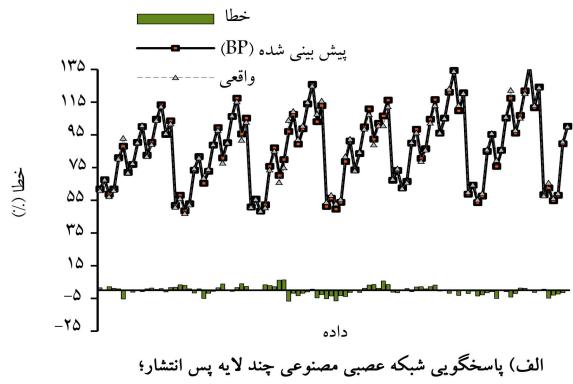
مذکور، اگر یک نرون آسیب ببیند، بقیه‌ی نرون‌ها می‌توانند نبود آن را جبران کنند و نیز در بازسازی آن سهیم باشند و آن‌ها مانند سلول‌های زیستی، قادر به یادگیری‌اند. مثلاً با اعمال سوزش به سلول‌های عصبی لامسه یاد می‌گیرند که به طرف جسم داغ نیزند و با این الگوریتم سیستم می‌آموزد که خطای خود را اصلاح کنند. یادگیری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

در سال ۱۹۴۳، برای اولین بار یک مدل فرموله شده از شبکه‌ی عصبی مصنوعی به صورت برنامه‌نویسی شده معرفی شد<sup>[۱]</sup> و شبکه‌ی شکل داده شده‌ی مذکور تقریباً برای تمامی مدل‌های بعد، مدل پایه‌یی بودند. در سال ۱۹۶۲، نیز یک مدل فرموله شده از نرون بیولوژیکی بر پایه‌ی نرون‌های پژوهش اخیر به نام پرسپترون<sup>۲</sup> (Perceptron) توسعه داده شد<sup>[۲]</sup> که از واحدهای حساسی تشکیل می‌شدند که به تکلاهای نرون در پژوهش اخیر، ارتباط داده می‌شدند.<sup>[۳]</sup> همچنین ایشان به الگوریتم یادگیری برای شبکه‌های پرسپترون با واحدهای پنهان دست یافتدند که آن‌ها را پس انتشار (BP)<sup>۳</sup> می‌خوانند که حالا یکی از پرکاربردترین الگوریتم‌های آموزش است.<sup>[۴]</sup> 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 انتطاق استفاده می‌شوند. اما بیشتر شبکه‌های عصبی مصنوعی به طور کلی در شناسایی و دسته‌بندی الگوها مناسب‌اند. یادگیری در شبکه‌های عصبی مصنوعی، دونوع نظرارت شده و نظرارت نشده است. در یادگیری نظرارت شده، شبکه با استفاده از خروجی‌ها آموزش می‌بیند. شبکه‌های پس انتشار نظرارت شده، در حقیقت از محبوب‌ترین شبکه‌های عصبی مصنوعی برای برنامه‌های مهندسی عمران است.<sup>[۵-۶]</sup> بعضی دیگر از شبکه‌های شناخته شده از نوع شبکه‌های هایفید،<sup>[۷]</sup> و بعضی دیگر از نوع شبکه‌ی کوهن هستند.<sup>[۸]</sup>

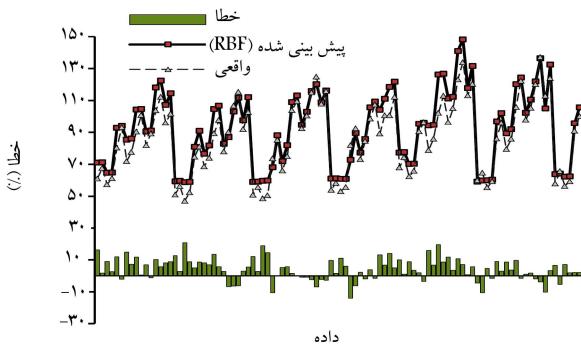
در علم مهندسی عمران، به طور گسترده‌ی از روش شبکه‌ی عصبی استفاده شده است. با توجه به گستره‌ی پهناور علم مهندسی عمران، این بهره‌گیری نیز متنوع و شامل مطالعات در زمینه‌های: قابلیت اطمینان،<sup>[۹]</sup> ارزیابی پتانسیل خرابی سازه‌ها،<sup>[۱۰]</sup> عملکرد لرزه‌یی،<sup>[۱۱]</sup> تخمین ظرفیت و مقاومت اجزاء سازه،<sup>[۱۲]</sup> بررسی رفتارهای موضعی المان‌ها،<sup>[۱۳]</sup> پیوستگی بتن و میلگرد،<sup>[۱۴]</sup> مکانیک خاک،<sup>[۱۵]</sup> مدل‌سازی رفتار صالح،<sup>[۱۶]</sup> خوردگی بتن و شبکه‌ی فاضلاب،<sup>[۱۷]</sup> و بسیاری زمینه‌های دیگر بوده است. تنوع روش‌های ذکر شده نشان می‌دهد که روش شبکه‌ی عصبی، محدود به زمینه‌ی خاصی نیست و به کمک روش‌های روش شبکه‌ی عصبی می‌توان در حوزه‌های مختلف مهندسی عمران از آن استفاده کرد.

در سازه‌های فلزی، معمولاً از انواع سیستم‌های سازه‌یی، همچون: قاب خشمی فولادی، قاب‌های مهاربندی هم‌مرکز و خارج از مرکز برای مقابله با بارگذاری زلزله و دیگر بارهای جانبی استفاده می‌شود. آزمایش‌های سازه‌یی نشان داده است که سیستم قاب‌های خشمی فولادی، توانایی ایجاد شکل پذیری و رفتار مناسب در بارگذاری‌های لرزه‌یی را دارند. هر چند که قاب‌های خشمی فولادی بسیار انعطاف‌پذیرند و محدودیت تغییر مکان، اغلب نقش مهم و کشنده‌یی در طراحی آن‌ها ایفا می‌کند، اما از پر کاربردترین سازه‌ها هستند. بدون شک یکی از مهم‌ترین 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 مدنظر 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؛

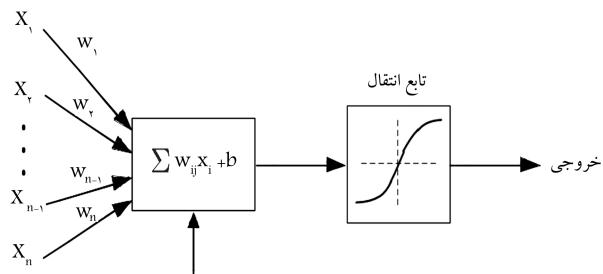


ب) پاسخگویی شبکه عصبی مصنوعی پایه شعاعی.

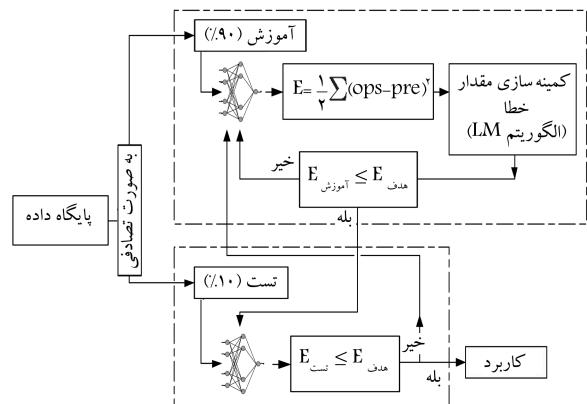
شکل ۴. ارزیابی پاسخگویی شبکه عصبی مصنوعی.

ولی تعداد لایه‌های پنهان موردنیاز برای شبکه عصبی مصنوعی زیاد نیست. آموزش در شبکه‌های پس انتشار در دو فاز فیدفوروارد و پس انتشار انجام می‌شود. در فاز فیدفوروارد، نزون‌های لایه‌ی ورودی مقادیر فردی ورودی را در لایه‌ی پنهان قرار می‌دهند. هر یک از نزون‌های لایه‌ی پنهان مجموع وزن دارشده‌ی آن ورودی را محاسبه می‌کند و از میان تابع فعال‌ساز برای لایه‌ی خروجی عبور می‌دهند. با وزن دارشدن مجموع هر نزون 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)<sup>۸</sup> برای اولین بار در سال ۱۹۸۸<sup>[۲۴]</sup> جهت طراحی شبکه‌های عصبی استفاده شده‌اند. تقاضت اساسی شبکه‌های RBF با شبکه‌های چندلایه، در بردار ورودی و تابع تحریک است.<sup>[۱۵]</sup> شبکه‌ی RBF معمولاً<sup>۳</sup> لایه دارد: یک لایه‌ی ورودی، یک لایه با تعداد کافی گره و یک لایه‌ی خروجی. از تابع پایه‌ی شعاعی متقاضی 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 طورکلی بدون نظر نظرت در نظر گرفته می‌شود. آموزش پارامترهای شبکه (وزن و بایاس) بین لایه‌های پنهان و خروجی با کمک نظارت بر پایه‌ی هدف اصلی رح 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 براساس مدل سازی‌های انجام شده، که جزئیات آن در بخش بعدی ذکر شده است، با رجوع به شکل ۴، مقادیر خطای ایجادشده در خصوص بهکارگیری دو نوع شبکه عصبی RBF و BP قابل ارزیابی است. نتایج نشان می‌دهد که خطای شبکه عصبی RBF نسبت به شبکه عصبی BP به مراتب بیشتر است. همین دلیل در ادامه‌ی روند پژوهش از شبکه عصبی BP استفاده شده است.



شکل ۲. فرایند محاسبات شبکه عصبی مصنوعی.



شکل ۳. یادگیری و آزمون شبکه عصبی مصنوعی.<sup>[۲۳]</sup>

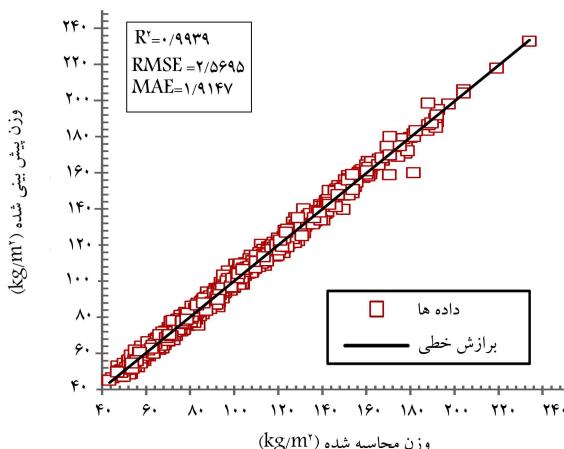
به مقدار کمینه‌ی ممکن کاهش یابد. شبکه برای آموزش به تعدادی الگو یا مجموعه‌ی داده و همچنین الگوریتم‌هایی همچون پس انتشار نیاز دارد. در روش پس انتشار وزن‌ها به نسبت خطای ایجادشده اصلاح می‌شوند. چون الگوریتم پس انتشار به دلیل هم‌گرایی خطی، سرعت کمی دارد؛ در پژوهش حاضر، از الگوریتم توسعه یافته‌تری به نام الگوریتم لونبرگ - مارکوارت (LM)<sup>۵</sup> 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 - مارکوارت بدون محاسبه‌ی دقیق ماتریس هسین<sup>۶</sup> و با استفاده از بردار گرادیان و ماتریس زاکوبین<sup>۷</sup> کار می‌کند و به عملت استفاده از روش تقریب مشتق مرتبه‌ی دوم، سرعت هم‌گرایی بالاتری دارد.<sup>[۲۴]</sup> به موازات فرایند آموزش، شبکه آزمایش می‌شود. بدین منظور درصدی از الگوهای موجود (معمولًا ۱۰٪) جدا و در هر گام از آموزش شبکه، خطای الگوهای مذکور در کنار خطای شبکه نشان می‌شود. شکل ۳، روند آموزش و آزمایش شبکه را نشان می‌دهد. همچنین درصدی از الگوها به منظور صحبت‌سنگی 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 براساس درصد خطای در خروجی شبکه عصبی است. مطابق شکل ۱، واحدهای پردازش در یک شبکه عصبی مصنوعی پس انتشار همواره شامل دستکم 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، لایه میانی است؛

جدول ۱. خصوصیات مدل‌های مورد بررسی در پژوهش حاضر.

مدل	آزمایش	آزمایش	آزمایش	آزمایش	آزمایش	آزمایش	آزمایش	تعداد نرون‌های لایه‌ی	تعداد نرون‌های لایه‌ی
								اول	دوم
۲۴/۹	۳۲/۱	۱۴/۲	tansig-tansig	LM	۴۰	۷۰	۱		
۳۰/۶	۳۱/۶	۲/۶	tansig-tansig	LM	۳۶	۴۰	۲		
۱۸/۱	۱۱/۴	۳/۶	logsig-logsig	LM	۱۲	۴۰	۳		
۱۴/۴	۱۸/۲	۶/۲	logsig-logsig	LM	۱۲	۲۵	۴		
۸/۵	۱۲/۷	۵/۹	tansig-tansig	LM	۳	۲۵	۵		
۴/۴	۷/۲	۴/۱	Logsig	LM	-	۲۵	۶		
۱۱/۹	۸/۵	۶/۸	logsig-logsig	LM	۳	۷	۷		
۱۲/۸	۹/۸	۹/۱	tansig	LM	-	۷	۸		



شکل ۵. مقایسه‌ی داده‌های واقعی و پیش‌بینی شده.

- از زیابی 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 تخمين با دقت بالاي برنامه در به دست آوردن وزن واحد سطح سازه‌ی ساختمان دست یافت. مقایسه‌ی مدل شبکه‌ی عصبی مصنوعی با داده‌های واقعی به کمک محاسبه‌ی مقادیر خطاهای مانند میانگین قدرمطلق خطأ ( $MAE$ )<sup>۱۱</sup> و جذر میانگین مربع خطاهای ( $RMSE$ )<sup>۱۲</sup> و همچنین ضربی  $R^*$  از رگرسیون خطی بین مقادیر پیش‌بینی شده و داده‌های واقعی صورت گرفته است. ساخته‌های مذکور در روابط ۲ الی ۴ معرفی شده‌اند.

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

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

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

### 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 تابع فعال‌ساز تعییر یافتد 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 لوینگ - مارکوارت (LM) برای آموزش استفاده شده است. تابع انتقال لایه‌ی پنهان Logsig و لایه‌ی آخر Liner است. از ۱۰۱ 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 از ارائه شده است:

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

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

روند آموزش که با استفاده از شبکه‌ی عصبی مصنوعی در محیط نرم‌افزار متلب<sup>۱۳</sup> 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 عموماً سیگموئید و خطی هستند؛
- تعیین قاعده‌ی مورد استفاده در یادگیری که الگوریتم لوینگ - مارکوارت (LM) استفاده شده است؛
- تعیین پارامترهای آموزش مورد نیاز برای بهینه‌شدن میانگین مجدد خطاهای MSE<sup>۱۰</sup> و حدود پیشنهادی تعداد تکرار؛
- آموزش شبکه‌ی عصبی طبق تعاریف در گام‌های اخیر؛
- محاسبه‌ی متغیرهای هدف نرمالایز شده و تبدیل آن‌ها به همان واحدهای هدف اصلی؛

که در آن ها،  $O_i$  مقادیر مشاهده بی،  $P_i$  مقادیر پیش بینی شده،  $\bar{O}_i$  میانگین مقادیر مشاهده بی و  $n$  تعداد کل داده ها در هر مرحله از آزمون های آموزش، آزمایش و ارزیابی است. هر چه مقدار  $MAE$  و  $RMSE$  به صفر و مقدار  $R^2$  به ۱ نزدیک تر باشد، نشان دهنده ای نزدیک تر بودن مقادیر مشاهده شده و پیش بینی شده به یکدیگر و دقیق تر بودن جواب ها در هر مرحله است. شاخص های عملکرد، نشانگر کارایی مناسب شبکه ای عصبی مصنوعی برای پیش بینی وزن اسکلت هستند.

### ۳. مدل سازی سازه ها و تهیه ای داده های آموزش

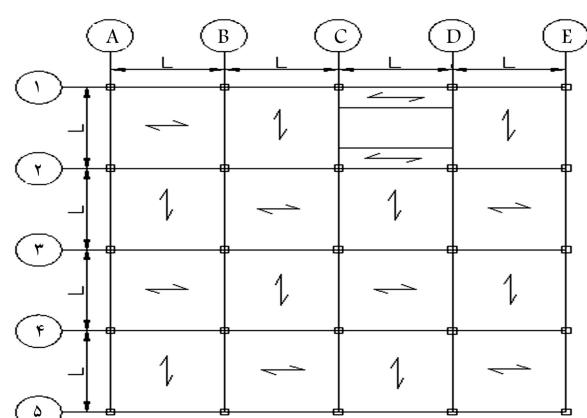
مطالعات حاضر بر روی مدل های با پلان منظم و سه بعدی انجام شده است. سیستم سازه بی از نوع قاب خمشی بوده است. در پژوهش حاضر، طراحی های لازم برای آماده سازی زوج بردارهای رورودی و خروجی با تغییر در پارامترهای نامبرده انجام شده است. طراحی های مذکور، مدل هایی با طول دهانه های ۳، ۵، ۴، ۵، ۵، ۶، ۴، ۵، ۵ و ۶ متر و تعداد طبقات ۳، ۶، ۹، ۱۲، ۱۴ و ۱۶ را شامل می شوند. ارتفاع طبقات نیز برای طراحی به صورت متنوع ۳، ۴، ۳ و ۴ متر استفاده و جنس خاک ساختگاه در دو نوع ۲ و ۳ بررسی شده است. مدل ها پس از بارگذاری، براساس آین نامه  $AISC 360-10$  به روش LRFD طراحی شده اند.<sup>[۲۹]</sup> برای تحلیل و طراحی مدل ها از نرم افزار SAP ۲۰۰۰ استفاده شده است.<sup>[۳۰]</sup> مقاطع مورد استفاده در روند طراحی تیرها در همه مدل ها از خانواده IPE بوده است. برای تخمین وزن اسکلت پس از پیمان مدل سازی ها و تکمیل طراحی های انجام شده، مقادیر وزن هر کدام از سازه ها از نرم افزار گرفته شده است. این مقدار به صورت خالص از مجموع وزن ستون ها و تیرهای بکار رفته در مدل حاصل شده است. از طرفی وزن کل اسکلت (قاب) شامل اتصال هایی همچون اتصال های تیرها، ستون ها، صفحه ستون ها و غیره نیز است. برای لحاظ کردن وزن اتصال ها و دیگر قطعه های الحاقی، شامل ورق های پیوستگی و وصله ستون ها، 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 ستون ها اضافه شده است. مقادیر حاصل از مدل سازی های برای ادامه پیش برد روش، به شبکه ای عصبی مصنوعی واگذار شده است. با توجه به اهمیت صحبت انجام شبکه، ۱۰٪ داده های طراحی شده به ارزیابی تخصیص داده شده است، تا برنامه مشکل ای از نظر جواب گویی نهایی نداشته باشد. بعد از تقسیم بندی پایگاه داده به آموزش شبکه پرداخته شده است.

### ۴. بحث و تفسیر نتایج

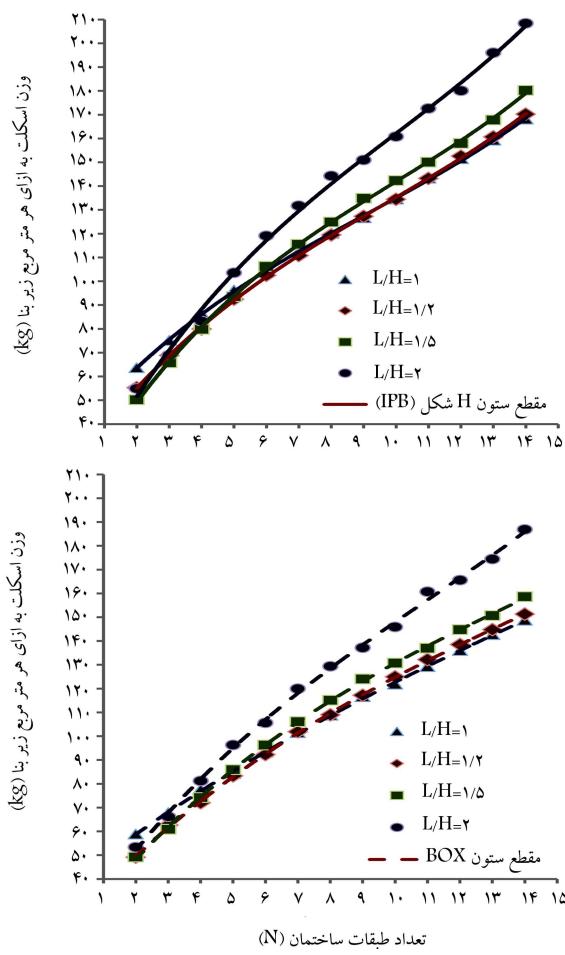
با معرفی مشخصاتی شامل شتاب مبنای طراحی ( $A$ ) و ضریب رفتار نهایی سازه ( $R_u$ ، در ادامه نتایج به دست آمده از شبکه ای عصبی و مطالعه ای پارامتریک ارائه شده است:

#### ۴.۱. تأثیر تعداد طبقات در وزن اسکلت

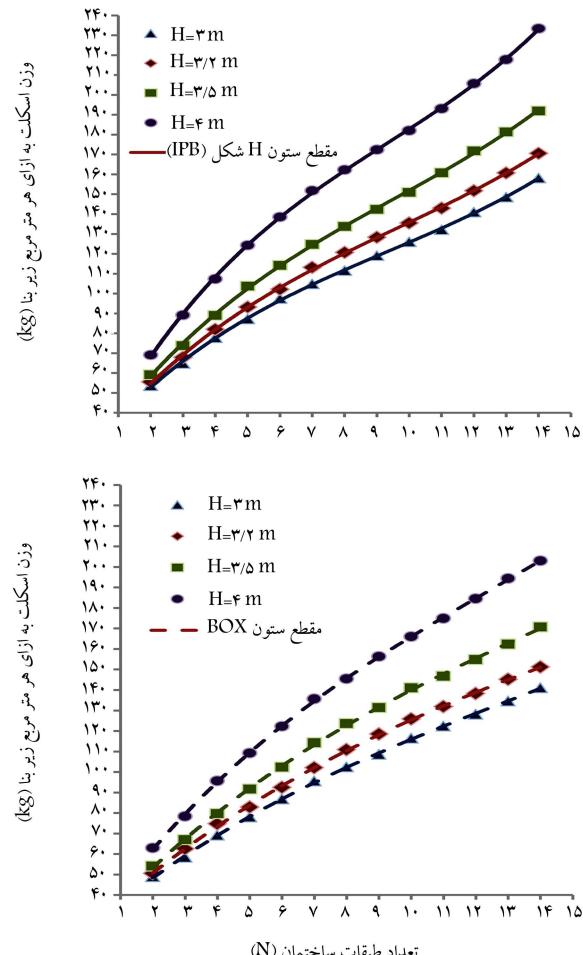
در شکل ۷، به ازاء ثابت فرض کردن پارامترهای  $R_u = 5$ ،  $L = 4 m$  (برای سیستم قاب خمشی متوسط)،  $A = 0.5 m^2$  (منطقه با وضعیت لزه خیزی زیاد) و خاک نوع ۳ تأثیر تعداد طبقات به همراه تغییر نوع مقاطع ستون بررسی شده است. افزایش وزن واحد سطح سازه با اضافه شدن تعداد طبقات بدیهی است، ولی منحنی های تولید شده می توانند نزدیک شدن را بهتر نشان بدهند. این افزایش با شبکه ای ملایمی به سمت بالا در حرکت است. نکته ای مهم تری که در نمودارها مشاهده می شود، تفاوت وزنی قابل توجه مدل های با ستون با مقاطع BOX و H شکل (IPB) است. این تفاوت با کمتر بودن وزن تمامی مدل هایی که از مقاطع BOX در ستون آن ها استفاده



شکل ۶. نمونه ای پلان از مدل های 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 مقاطع ستون.

شده است، نمایان می‌شود. به بیان دیگر، استفاده از مقاطع BOX نسبت به H شکل در سازه‌های فولادی خمی باعث کاهش مصرف فولاد می‌شود و مقرنون به صرفه‌تر خواهد بود. به طور متوسط مقدار صرفه‌جویی را که استفاده ای مقاطع 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 ساختن سازه‌های فولادی خمی باعث کاهش مصرف فولاد می‌شود و مقرنون به صرفه‌تر خواهد بود.

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

در شکل ۸، به ازاء ثابت فرض کردن پارامترهای  $Ru = 5$ ,  $H = 3,2\text{ m}$  (برای سیستم قاب خمی متوسط)،  $A = 0,3\text{ m}^2$  (منطقه با وضعیت لرزه‌خیزی زیاد) و خاک نوع ۳ تأثیر تعداد طبقات به همراه تغییر نوع مقاطع ستون به ازاء نسبت های 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 به ۱,۵ نسبت افزایش تقریباً ۵٪ وزن اسکلت می‌شود و همچنین افزایش این نسبت از ۱ به ۲ می‌تواند اضافه وزنی حدود ۲۰٪ را به وزن کل اسکلت ساختمان تحمیل کند. در روابط ۴ و ۵، معادلات برازش شده به نتایج حاصل از شکل ۸ ارائه شده است که براساس آن‌ها امکان تخمین سریع مقدار وزن فولاد مصرفی به ازاء واحد سطح زیربنای ساختمان میسر خواهد بود.

$$\left. \begin{array}{l} L/H = 1 \Rightarrow W = 0,0056 N^3 - 0,269 N^2 + 10,52 N \\ \quad + 38,77 \\ L/H = 1,2 \Rightarrow W = 0,0126 N^3 - 0,555 N^2 + 14,50 N \\ \quad + 22,77 \\ L/H = 1,5 \Rightarrow W = 0,0171 N^3 - 0,733 N^2 + 16,97 N \\ \quad + 17,22 \\ L/H = 2 \Rightarrow W = 0,0283 N^3 - 0,942 N^2 + 19,77 N \\ \quad + 18,16 \end{array} \right\} \text{برای سازه با ستون H شکل (IPB)}$$

$$\left. \begin{array}{l} L/H = 1 \Rightarrow W = 0,0347 N^3 + 15,99 N \\ \quad + 35,16 \\ L/H = 1,2 \Rightarrow W = 0,0391 N^3 - 1,203 N^2 + 18,63 N \\ \quad + 21,19 \\ L/H = 1,5 \Rightarrow W = 0,05211 N^3 - 1,547 N^2 + 22,68 N \\ \quad + 27,713 \\ L/H = 2 \Rightarrow W = 0,0546 N^3 - 1,630 N^2 + 26,61 N \\ \quad + 4,467 \end{array} \right\} \text{برای سازه با ستون H شکل (BOX)}$$

با نگاهی به نمودارهای شکل ۹ می‌توان فرورفتگی‌های 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، بلافتسله 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 مقادیر 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 بازیابی 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 مقادیر خود می‌رسد. در معنای دیگر در ساختمان‌های با طبقات بالا، هر چه این نسبت به ۱ نزدیک‌تر باشد، وزن بهینه‌تر خواهد شد.

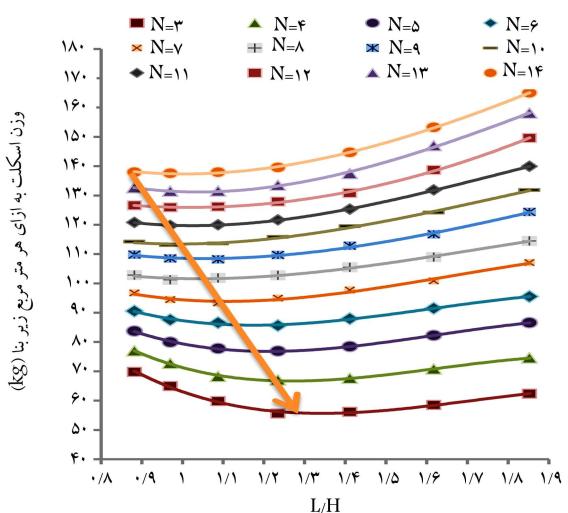
## ۵. نتیجه‌گیری

در پژوهش حاضر، روش شبکه‌ی عصبی برای تخمین وزن سازه‌های با سیستم قاب خمی فولادی با کاربری مسکونی استفاده و بیش از ۱۱۰۰ 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 سنتون بررسی شده است. خلاصه‌ی نتایج به دست آمده از پژوهش حاضر عبارت‌اند از:

- روش پیشنهادی و همچنین منحني‌های 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 بتواند در انتخاب مشخصات هندسه‌ی بهینه و پیش‌بینی میزان فولاد مصرفی و تخمین هزینه‌ی اجر، تصمیم‌گیری مناسب‌تری داشته باشند.
- مقادیر ناچیز  $MAE$  و  $RMSE$  و همچنین ضریب رگرسیونی با مقدار ۰,۹۹ و نزدیک به ۱، نمایانگر عملکرد مناسب شبکه‌ی عصبی مصنوعی در حوزه‌ی کاربرد برآورد وزن سازه است.
- ساختار شبکه‌ی عصبی پیشنهادی به صورت (۱-۲۵-۷) 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 خمی 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 دهانه 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  $A = ۰,۲$ ،  $Ru = ۵$ ،  $H = ۲,۴ m$  و خاک نوع ۲ و نوع مقطع سنتون 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 ( $H = ۳, ۴$  m).

(تعداد طبقات)	(نسبت ارتفاع به طول دهانه)	(طول دهانه به متر)	$N$
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 ساخته شده با ستون‌های با مقاطع BOX نسبت سازه‌های با ستون با مقاطع 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 کمینه‌ساختن 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 cachrydolia* 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).