

Estimation of rebar weight in residential buildings of concrete intermediate moment frame using Artificial Neural Network

Meysam Effati^{1*}, Hamed Ebrahimi², Mojtaba Faraji³

1- Assistant Professor, Faculty of engineering, Guilan University, Rasht, Iran

2- PHD Student in Structural Engineering, Faculty of engineering, Guilan University, Rasht, Iran

3- PHD Student in Structural Engineering, Faculty of engineering, Guilan University, Rasht, Iran

ABSTRACT

Estimating the cost of building construction, especially in the early stages of studies, is a topic of interest and importance for employers and investors. The high inflation of the country's economy in recent years and the sharp fluctuations in the price of construction materials have doubled the importance of estimating the cost of building construction, even in small urban projects. However, until the design of the building is completed and the final plans are not prepared in full detail, it is not possible to measure the project and estimate the construction costs with acceptable accuracy. On the other hand, the proposed approximate methods for initial estimates are associated with many differences from reality that are not consistent with the existential philosophy of project economic estimation. Therefore, in this study, using training capability of Artificial Intelligence and Artificial Neural Network algorithms, the weight of rebar used in concrete buildings of concrete moment frame, without complete design and preparation of executive plans is calculated and the results are compared with real values. The proposed artificial neural network model is a multilayer feeder type feeder with post-diffusion learning algorithm and is based on the parameters of number of openings in longitudinal and transverse direction, floor height, number of floors, number of columns per floor, floor area and seismic base shear. The weight of rebar used in the studied buildings has been estimated. The results indicate that the proposed neural network model can estimate the weight of rebar used in regular buildings with 95% accuracy and in irregular buildings with 80% accuracy.

All rights reserved to Iranian Society of Structural Engineering.

doi: 10.22065/JSCE.2021.279806.2425

*Corresponding author: Meysam Effati
Email address: meysameffati@guilan.ac.ir

ARTICLE INFO

Receive Date: 16 April 2021

Revise Date: 11 October 2021

Accept Date: 01 November 2021

Keywords: Soft computing
Artificial Neural Network
Structural frame weight
concrete flexural frame
structural weight Estimation

برآورد وزن میلگرد مصرفی در ساختمان‌های مسکونی قاب خمشی متوسط بتنی، با استفاده از شبکه عصبی مصنوعی

میثم عفتی^{۱*}، حامد ابراهیمی^۲، مجتبی فرجی^۳

۱-استادیار، گروه مهندسی عمران، دانشکده فنی، دانشگاه گیلان، رشت، ایران

۲-دانشجوی دکتری مهندسی سازه، گروه مهندسی عمران، دانشکده فنی دانشگاه گیلان، رشت، ایران

۳-دانشجوی دکتری مهندسی سازه، گروه مهندسی عمران، پردیس دانشگاهی دانشگاه گیلان، رشت، ایران

چکیده

برآورد هزینه‌های احداث ساختمان به‌ویژه در مراحل اولیه مطالعاتی، از موضوعات موردعلاقه و حائز اهمیت برای کارفرمایان و سرمایه‌گذاران است. تورم بالای حاکم بر اقتصاد کشور در سال‌های اخیر و نوسان شدید قیمت مصالح ساختمانی، اهمیت برآورد هزینه‌های احداث ساختمان حتی در پروژه‌های کوچک شهری را دوچندان کرده است. اما تا زمانی که طراحی ساختمان به اتمام نرسیده و نقشه‌های نهایی با تمام جزئیات تهیه نشده باشند امکان متره پروژه و برآورد هزینه‌های احداث با دقت قابل قبول میسر نیست. از طرفی روش‌های تقریبی ارائه شده جهت برآوردهای اولیه، با اختلافات زیادی نسبت به واقعیت همراه هستند که با فلسفه وجودی برآورد اقتصادی پروژه سازگاری ندارد. لذا در این پژوهش با استفاده از محاسبات مبتنی بر هوش مصنوعی و قابلیت یادگیری از داده‌های آموزشی شبکه عصبی مصنوعی، وزن میلگرد مصرفی در ساختمان‌های مسکونی قاب خمشی بتنی، بدون طراحی کامل و تهیه نقشه‌های اجرایی، محاسبه شده و نتایج با مقادیر واقعی مقایسه می‌شوند. مدل شبکه عصبی مصنوعی پیشنهادی پژوهش از نوع پرسپترون چندلایه پیش‌خور با الگوریتم یادگیری پس انتشار هست و بر اساس پارامترهای تعداد دهانه در راستای طولی و عرضی، ارتفاع ساختمان، تعداد ستون در هر طبقه، مساحت طبقه و برش پایه لرزه‌ای، وزن میلگرد مصرفی در ساختمان‌های مورد مطالعه برآورد شده است. نتایج پژوهش حاکی از این است که مدل شبکه عصبی پیشنهادی می‌تواند وزن میلگرد مصرفی را در ساختمان‌های منظم با دقت ۹۵ درصد و در ساختمان‌های نامنظم با دقت ۸۵ درصد برآورد نماید.

کلمات کلیدی: محاسبات نرم، شبکه عصبی مصنوعی، وزن اسکلت سازه، قاب خمشی بتنی، تخمین وزن سازه.

doi:	سابقه مقاله:					
	شناسه دیجیتال:	چاپ	انتشار آنلاین	پذیرش	بازنگری	دریافت
https://doi.org/10.22065/JSCE.2021.279806.2425						
10.22065/JSCE.2021.279806.2425	۱۴۰۱/۳/۳۱	۱۴۰۰/۸/۱۰	۱۴۰۰/۸/۱۰	۱۴۰۰/۷/۱۹	۱۴۰۰/۱۰/۲۷	
میثم عفتی meysameffati@guilan.ac.ir					*نویسنده مسئول: پست الکترونیکی:	

۱- مقدمه

منابع مالی در ساخت‌وساز، یکی از اساسی‌ترین موارد در طراحی و اجرای سازه است. به کمک تخمین وزن سازه در مراحل اولیه طراحی بر مبنای پارامترهای کلیدی طرح، طراح و کارفرما دید مناسبی نسبت به مقدار فولاد مصرفی کسب خواهند کرد و در این راه طراح می‌تواند با انتخاب پارامترهای مناسب و بهینه برای مشخصات هندسی سازه، هزینه اسکلت را بهینه نماید. 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. به خصوص اینکه بازخوردهای حاصل در همان ابتدای روند طراحی، معمار و همچنین کارفرمای پروژه را در تغییرات احتمالی مشخصات طرح باهدف بهینه کردن هزینه‌ی اسکلت (قاب) راهنمایی می‌کنند. انجام بررسی‌های ذکرشده قبل از شروع روند اصلی طراحی، نیازمند صرف وقت و هزینه‌ی زیاد است. یکی از روش‌های کم کردن هزینه و افزایش سرعت در پروژه، استفاده از روش‌های هوشمند مبتنی بر یادگیری است که به دلیل هزینه کم، سرعت و دقت بالا استفاده از آن در این زمینه، مفید خواهد بود.

شبکه‌های عصبی مصنوعی، الگوریتمی از محاسبات نرم هستند که دستگاه‌ها و روش‌های محاسباتی نوینی برای یادگیری ماشینی، نمایش دانش و نهایتاً تخمین و پیش‌بینی پاسخ‌های خروجی از سامانه‌های پیچیده ارائه می‌دهند. ایده اصلی این‌گونه شبکه‌ها تا حدودی الهام گرفته از شیوه‌ی کارکرد سیستم عصبی زیستی، برای پردازش داده‌ها و اطلاعات، به‌منظور یادگیری و ایجاد دانش است. سیستم مذکور از شمار زیادی عناصر پردازشی به‌هم‌پیوسته به نام نرون تشکیل شده است که برای حل یک مسئله، باهم هماهنگ عمل می‌کنند و توسط سیناپس‌ها (ارتباطات الکترومغناطیسی) اطلاعات را منتقل می‌کنند.

در شبکه‌های عصبی، اگر یک نرون آسیب ببیند، مابقی نرون‌ها می‌توانند نبود آن را جبران کنند و این قابلیت در کارکرد تحقیق حاضر به‌منظور سازگاری با نمونه‌های مختلف و متفاوت ساختمانی مؤثر است. به عبارتی یادگیری در روش پیشنهادی این پژوهش به‌صورت تطبیقی صورت می‌گیرد، یعنی با استفاده از مثال‌هایی وزن سیناپس‌ها به‌گونه‌ای تغییر می‌کند که در صورت ورود ساختمانی با مشخصات متفاوت، سیستم پاسخ مناسبی از وزن میلگرد مصرفی را در اختیار قرار می‌دهد.

در سازه‌های بتنی، معمولاً از انواع سیستم‌های سازه‌ای، همچون: قاب خمشی و دیوار برشی برای مقابله با بارگذاری زلزله و دیگر بارهای جانبی استفاده می‌شود. آزمایش‌های سازه‌ای نشان داده است که سیستم قاب‌های خمشی بتنی، توانایی ایجاد شکل‌پذیری و رفتار مناسب در بارگذاری‌های لرزه‌ای را دارند. هرچند که قاب‌های خمشی بتنی بسیار انعطاف‌پذیرند و محدودیت تغییر مکان، اغلب نقش مهم و کنترل‌کننده‌ای در طراحی آن‌ها ایفا می‌کند، اما از پرکاربردترین سازه‌ها هستند. بدون شک یکی از مهم‌ترین دغدغه‌های کارفرمایان و همچنین یکی از معیارهای انتخاب هندسه و مشخصات سازه‌ای در مراحل اولیه‌ی طراحی (مرحله‌ی طراحی مفهومی پروژه)، کمینه‌سازی میزان فولاد مصرفی و به‌تبع آن کاستن از هزینه‌ی ساخت اسکلت است. البته به‌نحوی که تمام ضوابط طراحی نیز پاسخگو باشد و ملاحظات مدنظر معمار پروژه نیز رعایت شود. با تخمین وزن اسکلت بر اساس پارامترهای اصلی و تأثیرگذار طراحی، می‌توان قبل از طراحی سازه ساختمان، دیدی مناسب نسبت به وزن آن ایجاد کرد. این ایده به کارفرما و همچنین طراحان اجازه می‌دهد تا تخمینی مؤثر در مورد هزینه احداث اسکلت پروژه در پیش رو داشته باشند. در پژوهش حاضر، از شبکه‌ی عصبی مصنوعی به‌منظور پیش‌بینی هوشمند، استفاده‌شده است تا رویکرد مناسبی برای برآورد مقدار میلگرد فولادی لازم قبل از احداث ساختمان‌های با قاب خمشی بتنی ارائه شود.

در بخش بعدی مقاله، تحقیقات پیشین در خصوص کاربرد شبکه‌های عصبی مصنوعی در مهندسی عمران مرور شده است. در بخش سوم، روش‌شناسی تحقیق ارائه‌شده است. در این بخش، ساختار شبکه‌های عصبی مصنوعی معرفی شده و شیوه مدل‌سازی و استخراج اطلاعات پژوهش حاضر تشریح شده است. در بخش چهارم، مدل شبکه‌ی عصبی مصنوعی پیشنهادی ارزیابی شده و نتایج آن بررسی شده است.

۲- پیشینه پژوهش

در علم مهندسی عمران، به‌طور گسترده‌ای از روش شبکه‌ی عصبی استفاده شده است. با توجه به گستره پهناور علم مهندسی عمران، این بهره‌گیری نیز متنوع و شامل مطالعات در زمینه‌های: قابلیت اطمینان، ارزیابی پتانسیل خرابی سازه‌ها، عملکرد لرزه‌ای، تخمین ظرفیت و مقاومت اجزای سازه بررسی رفتارهای موضعی المان‌ها، پیوستگی بتن و میلگرد، مکانیک خاک، مدل‌سازی رفتار مصالح، خوردگی بتن و شبکه فاضلاب و بسیاری زمینه‌های دیگر بوده است. تنوع روش‌های ذکر شده نشان می‌دهد که روش شبکه عصبی، محدود به رشته و زمینه‌ی خاصی نیست و می‌توان در حوزه‌های مختلف مهندسی عمران از آن استفاده کرد.

کاوه و همکاران [۱] با بهره‌گرفتن از دو شبکه انتشار برگشتی و تابع پایه شعاعی، کاربرد شبکه‌های عصبی مصنوعی در پیش‌بینی تغییر شکل سازه‌های گنبدی تحت اثر باد را بررسی کردند. مرتضایی و همکاران [۲] با استفاده از روش شبکه عصبی مصنوعی به تخمین طول مفصل پلاستیک ستون‌های بتن‌آرمه پرداختند. آن‌ها با استفاده از نتایج حاصل از ۱۵۰ آزمایش بر روی ستون‌های بتن مسلح، شبکه‌ای را آموزش دادند تا بتواند مشخصات مفصل پلاستیک را تخمین بزند. عفتی و همکاران [۳] با استفاده از مدل شبکه عصبی مبتنی بر نتایج حاصل از آزمایش ۴۴ نمونه بتنی، با در نظر گرفتن مؤلفه‌های اثرگذار بر طرح اختلاط بتن، به پیش‌بینی اسلامپ بتن پرداختند. هاشمی و همکاران [۴] اثر تعداد و ارتفاع طبقات اسکلت فلزی با سیستم قاب خمشی در وزن سازه را با استفاده از روش شبکه عصبی مصنوعی بررسی کردند. اکبری و همکاران [۵] با گردآوری پایگاه داده متشکل از ۳۰۴ تیر بتن مسلح با الیاف پلیمری، مقاومت برشی تیرهای مذکور را با استفاده از روش شبکه عصبی مصنوعی تخمین زده و با نتایج آزمایشگاهی و روابط آیین‌نامه‌ای مقایسه کردند. نتیجه این پژوهش نشان داد درصد میانگین نسبی مطلق خطای برآورد در مدل شبکه عصبی ۶۰ درصد کمتر از روابط آیین‌نامه‌ای است. نادر پور و همکاران [۶] پیش‌بینی مقاومت پیچشی تیرهای بتن‌آرمه تقویت‌شده با الیاف FRP به کمک شبکه عصبی مصنوعی را بررسی کردند. نتایج این پژوهش نشان داد شبکه عصبی مصنوعی بهینه با دقت مناسبی می‌تواند مقاومت پیچشی تیرهای بتن‌آرمه تقویت‌شده با الیاف FRP را تخمین بزند و از این جهت می‌تواند جایگزین مناسبی برای روش‌های زمان‌بر و پرهزینه آزمایشگاهی باشد. لیبب زاده و همکاران [۷] برای تعیین ظرفیت باربری محوری ستون‌های بتنی مسلح شده با آرماتورهای طولی مارپیچ، نتایج حاصل از روش اجزای محدود و نمونه‌های آزمایشگاهی را با مقادیر برآورد شده توسط مدل شبکه عصبی مصنوعی مقایسه کردند. نتایج نشان داد مدل شبکه عصبی مصنوعی می‌تواند ظرفیت باربری این تپ از ستون‌ها را با دقت قابل قبولی تخمین بزند و در آینده به ارائه روابط کاربردی جهت طراحی و استفاده در صنعت ساختمان منجر شود. Mangalathu و همکاران [۸] به معرفی یک روش تولید منحنی شکنندگی لرزه‌ای پل‌ها مبتنی بر الگوریتم شبکه عصبی مصنوعی پرداختند. نتایج مطالعات آن‌ها بر روی یک نمونه پل بتنی با عرشه جعبه‌ای نشان داد، شدت لرزه‌خیزی منطقه، طول دهانه پل و نسبت میلگردهای طولی پایه پل، بیشترین تأثیر را بر شکنندگی لرزه‌ای پل‌ها دارند. شاه‌منصوری و همکاران [۹] با استفاده از یک مدل شبکه عصبی مصنوعی، مقاومت فشاری نمونه‌های بتن پوزولانی سازگار با محیط‌زیست را بررسی کردند. نتایج مطالعات ایشان نشان داد که خروجی‌های مدل شبکه عصبی مصنوعی، انطباق قابل قبولی با نتایج حاصل از مطالعات آزمایشگاهی دارد. مرادی و همکاران [۱۰] با ارائه یک مدل مبتنی بر شبکه‌های عصبی مصنوعی پیش‌بینی مقاومت، سختی و تغییر مکان جانبی دیوارهای برشی فولادی و بتنی را بررسی کردند. نتایج تحقیقات ایشان نشان داد، مدل پیشنهادی می‌تواند جایگزین مناسبی برای روش‌های ارزیابی مبتنی بر تحلیل غیرخطی و مطالعات آزمایشگاهی باشد. Feng و همکاران [۱۱] با استفاده از نتایج حاصل از ۱۳۳ آزمایش بر روی ستون‌های بتن مسلح، به ارائه یک مدل شبکه عصبی مصنوعی جهت تخمین طول مفصل پلاستیک ستون‌های بتنی پرداختند. نتایج تحقیقات ایشان نشان داد، خروجی مدل مذکور انطباق قابل قبولی با نتایج مطالعات آزمایشگاهی دارد و می‌تواند جایگزین مناسبی برای روابط تجربی ارائه‌شده توسط محققین پیشین باشد. برنجیان و همکاران [۱۲] عملکرد شبکه‌های عصبی مصنوعی در پیش‌بینی مقاومت فشاری بتن خودتراکم را ارزیابی کردند. نتایج نشان داد شبکه‌های عصبی به عنوان ابزار قابل اعتمادی، با صرفه‌جویی در زمان و هزینه دارای قدرت بالایی در پیش‌بینی مقاومت فشاری ۷ روزه و ۲۸ روزه نمونه‌های بتنی می‌باشد.

۳- روش‌شناسی پژوهش

هدف پژوهش حاضر برآورد وزن میلگرد مصرفی در سازه بر اساس مشخصات معماری و مبتنی بر اطلاعات شماری از سازه‌های مورد مطالعه که ساخت آن‌ها به اتمام رسیده است. از آنجایی که هدف، از نوع تخمین و پیش‌بینی است و نیز با توجه به این‌که مؤلفه‌های مؤثر بر خروجی مورد نظر در سازه از گستردگی بالایی برخوردار است و وزن تأثیر هر مؤلفه ورودی در تولید خروجی، از سازه‌ای به سازه دیگر متفاوت است و نمی‌توان از طریق توزیع‌های آماری و برازش‌های ریاضی به یک رابطه عمومی دست پیدا کرد، لذا رویکرد این تحقیق ارائه یک مدل شبکه عصبی توسعه داده شده به منظور برآورد وزن میلگرد مصرفی در ساختمان‌های مسکونی قاب خمشی بتنی متوسط هست. از مزایای مدل پیشنهادی می‌توان: کاهش هزینه، کاهش مدت زمان، دقت قابل قبول در برآورد و استفاده از مشخصات ساختمان‌های واقعی جهت ساخت شبکه را برشمرد. همچنین گستردگی متغیرهای مؤثر در طراحی سازه‌ای و محدودیت در دسترسی به اطلاعات ساختمان‌های واقعی و توسعه مدل پیشنهادی مبتنی بر اطلاعات یک نوع سیستم سازه‌ای (قاب خمشی متوسط بتنی) از محدودیت‌های مدل شبکه عصبی پیشنهادی می‌باشد.

- شبکه عصبی مصنوعی

مهم‌ترین کاربرد شبکه‌های عصبی مصنوعی در مهندسی عمران تخمین توابع غیرخطی با دقتی مناسب است. معمولاً با استفاده از داده‌های واقعی، خروجی شبکه عصبی مصنوعی به خروجی هدف تعیین شده سوق می‌یابد و شبکه عصبی مصنوعی آموزش می‌بیند. شبکه بر مبنای مقایسه بین خروجی شبکه و خروجی هدف، تعدیل می‌شود، تا هنگامی که خروجی باهدف مطابقت کند. مدل‌های شبکه عصبی از سه بخش اصلی لایه ورودی، لایه پنهان و لایه خروجی تشکیل شده است که هر لایه وظیفه دریافت داده‌ها، پردازش و تولید کمیت خروجی را بر عهده دارد. هر نرون در لایه ورودی به نرون‌های لایه پنهان متصل است و باید توجه شود که هیچ اتصالی بین نرون‌ها در یک لایه وجود ندارد. تعداد نرون‌ها در هر لایه به عوامل متعددی بستگی دارد که تعداد نرون‌های لایه ورودی و خروجی به پارامترهای ورودی و خروجی مورد نظر در مدل‌سازی بستگی داشته و معمولاً تعداد نرون‌ها در لایه پنهان به کمک روش‌های مختلف بر اساس پیچیدگی مسئله مورد نظر تعیین می‌شود. تمام لایه‌های شبکه با اتصالاتی با وزن‌های متفاوت به هم متصل می‌باشند [۱۳]. متداول‌ترین نوع شبکه‌های عصبی، شبکه‌های چندلایه پرسپترون پیش‌خور است که از یک لایه ورودی، یک و یا چند لایه پنهان و یک لایه خروجی تشکیل شده‌اند. متناسب با هر اتصال، یک وزن در نظر گرفته می‌شود. لایه ورودی، داده‌های ورودی را دریافت می‌کند و به نرون‌های لایه پنهان انتقال می‌دهد. سپس داده‌ها پس از پردازش، به لایه خروجی وارد می‌شوند. نتیجه نرون‌های لایه متناسب با داده‌های ورودی است [۱۴]. روش مشخص و جامعی برای به دست آوردن تعداد نرون‌ها و لایه‌های مورد نیاز هر مسئله وجود ندارد و برای آن باید بر اساس تجربه و آزمون و خطا عمل کرد [۱۵].

اولین گام در تولید و به‌کارگیری شبکه عصبی مصنوعی، آموزش آن است. در واقع، منظور از آموزش شبکه، تنظیم مقدار وزن‌هاست، به‌گونه‌ای که خطای ناشی از اختلاف خروجی‌های شبکه با مقادیر خروجی اندازه‌گیری شده در الگوهای مختلف به مقدار کمینه‌ی ممکن کاهش یابد. الگوریتم پس‌انتشار خطا یکی از پرکاربردترین الگوریتم‌ها برای آموزش شبکه‌های عصبی مصنوعی چندلایه پیش‌خور می‌باشد. در این روش از تکنیک کاهش شیب تابع خطا استفاده می‌شود که طی آن خطاها از لایه خروجی به سمت لایه ورودی پخش شده و وزن‌ها به گونه‌ای اصلاح می‌شوند که خطا کمینه شود. بنابراین، فرآیند آموزش شامل اصلاح تدریجی وزن‌ها در جهت کمینه کردن خطا می‌باشد. این عمل تازمانی که یکی از معیارهای توقف ارضا شود ادامه می‌یابد چون الگوریتم پس‌انتشار به همگرایی خطی، سرعت کمی دارد؛ در پژوهش حاضر، از الگوریتم توسعه‌یافته‌تری به نام الگوریتم لونبرگ - مارکوارت (LM) برای آموزش شبکه استفاده شده است، که به‌نوعی یک روش بهینه‌سازی است و برای یافتن کمیت‌های توابع چند متغیره‌ی غیرخطی از نوع مجموع مربعات، مشابه تابع خطای شبکه‌های عصبی، کاربرد دارد. الگوریتم لونبرگ - مارکوارت (LM) بدون محاسبه دقیق ماتریس هسین و با استفاده از بردار گرادیان و ماتریس ژاکوبین کار می‌کند و به دلیل استفاده از روش تقریب مشتق مرتبه دوم، سرعت همگرایی بالاتری دارد [۱۶]. به‌موازات فرآیند آموزش، شبکه آزمایش می‌شود. بدین منظور درصدی از الگوهای موجود جدا و در هر گام از آموزش شبکه، خطای الگوهای مذکور در کنار خطای الگوهای آموزش محاسبه می‌شود. همچنین درصدی از الگوها به منظور صحت سنجی شبکه جدا می‌شوند و هیچ نقشی در آزمایش با آموزش شبکه ندارند.

وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. از این رو داده‌های ورودی به شبکه بایستی نرمال شوند. به طوری که همه داده‌ها مقادیری بین صفر و یک داشته باشند. نرمال کردن داده‌ها برای به حداقل رساندن تأثیر اختلاف مقیاس پارامترهای مختلف و اطمینان از یکسان بودن پارامترها می‌باشد. [۱۷] در واقع در صورتی که ورودی‌های بزرگی به شبکه ارائه داده شود، حتی با وجود نرون‌های کوچک در شبکه، جمع ورودی‌های وزن‌دار به نرون لایه بعد بزرگ خواهد بود و مشکل عدم انجام آموزش رخ خواهد داد. [۱۲] لذا برای انجام این پژوهش، نرمال‌سازی داده‌ها در بازه (۰-۱) از رابطه (۱) استفاده شده است. که در این رابطه، x_n داده نرمال شده، x_i داده خام، x_{min} کمینه مقادیر داده و x_{max} بیشینه مقادیر داده می‌باشد.

$$x_n = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (1)$$

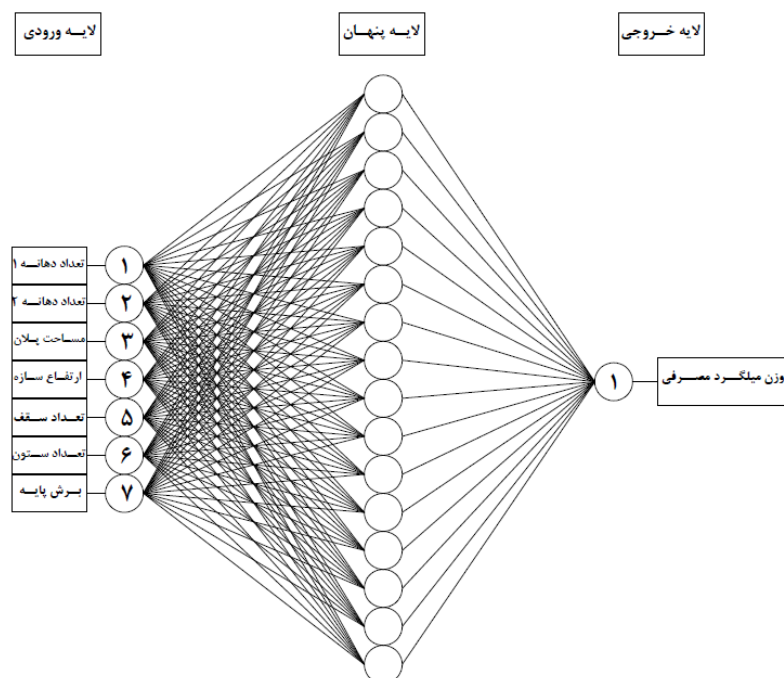
تابع خطای مناسب و قابل‌استفاده در این پژوهش، تابع میانگین مربعات خطا MSE می‌باشد که معمول‌ترین تابع در بررسی کارایی شبکه‌های عصبی می‌باشد که در رابطه‌ی (۲) آورده شده است. همچنین از ضریب همبستگی R جهت نشان دادن میزان ارتباط بین خروجی شبکه و مقادیر آزمایشگاهی استفاده شد که طبق رابطه‌ی (۳) به دست می‌آید. در هر دو رابطه، t مقدار واقعی، o_i پیش‌بینی شده و n تعداد داده‌ها می‌باشد. [۱۸]

$$MSE = \frac{1}{n} \sum_{i=1}^n (t_i - o_i)^2 \quad (2)$$

$$R = \frac{(n \sum t_i o_i - \sum t_i \sum o_i)}{\sqrt{[n \sum t_i^2 - (\sum t_i)^2][n \sum o_i^2 - (\sum o_i)^2]}} \quad (3)$$

زمانی که $|R| \geq 0.8$ باشد ارتباط قوی بین دو مجموعه از متغیرها وجود دارد. اگر $0.2 < |R| < 0.8$ باشد، ارتباط نسبی بین دو مجموعه از متغیرها وجود دارد. وقتی که $|R| \leq 0.2$ باشد ارتباط ضعیف بین دو مجموعه از متغیرها وجود دارد [۱۹].

در شکل ۱، ساختار مدل شبکه عصبی مصنوعی ارائه شده در این پژوهش نشان داده شده است. هم‌چنین در جدول ۱، مشخصات شبکه عصبی پیشنهادی و در جدول ۲، متغیرهای ورودی و خروجی مسئله و دامنه تغییرات آن‌ها ارائه شده است. متغیرهای مذکور در بخش‌های بعدی تشریح شده است.



شکل ۱: ساختار شبکه عصبی مصنوعی پیشنهادی

جدول ۱: مشخصات مدل شبکه عصبی پیشنهادی

۶	تعداد نرون‌های لایه ورودی
۱	تعداد لایه میانی
۱۰	تعداد نرون‌های لایه میانی
۱	تعداد نرون‌های لایه خروجی
پرسپترون چندلایه MLP	ساختار شبکه عصبی
Feed Forward	نوع شبکه عصبی
Back Propagation	الگوریتم خطایابی
Levenberg-Marquardt	الگوریتم آموزش
Sigmoid	تابع فعال‌ساز لایه پنهان
Pureline	تابع فعال‌ساز لایه خروجی

جدول ۲: دامنه متغیرهای ورودی و خروجی

ردیف	متغیرهای مسئله	کمترین	بیشترین	میانگین	انحراف
۱	تعداد دهانه ۱	۲	۷	۲,۷۳	۰,۸۰
۲	تعداد دهانه ۲	۲	۳	۲,۰۷	۰,۲۵
۳	مساحت پلان (مترمربع)	۵۵	۲۹۵	۱۲۰,۷۲	۴۳,۷۶
۴	ارتفاع سازه (متر)	۹,۲	۲۱,۴	۱۳,۳۸	۲,۳۳
۵	تعداد ستون در هر طبقه	۹	۲۴	۱۱,۴۷	۲,۶۹
۶	برش پایه (تن)	۲۴,۳	۳۱۰,۵۷	۱۱۲,۱۷	۵۲,۷۱
۸	وزن میلگرد مصرفی در سازه (تن)	۶,۳۴	۵۵,۲۷	۱۹,۵۲	۱۰,۱۰

۴- مدل سازی و استخراج اطلاعات

در پژوهش پیش رو، از مدل سازه‌ای ۹۰ ساختمان مسکونی احداثی که به جهت انطباق با مقررات ملی ساختمان [۲۰]، [۲۱] و استاندارد ۲۸۰۰ ایران [۲۲]، توسط واحد کنترل نقشه سازمان نظام مهندسی ساختمان تأیید شده‌اند بهره گرفته شده است. ساختمان‌های مذکور از جهت پراکندگی دیدگاه حاکم بر طراحی، توسط طیف متنوعی از گروه‌های طراحی، طراحی شده‌اند و در عین حال به جهت انطباق با مقررات ملی ساختمان و آیین‌نامه‌های طراحی لرزه‌ای در سطح استاندارد می‌باشند. در جدول ۳، مشخصات ورودی و خروجی‌های مسئله برای ۲۰ مورد از ساختمان‌های مورد مطالعه به‌عنوان نمونه ارائه شده است. شایان ذکر است ساختمان‌های مورد مطالعه صرفاً مدل‌های پژوهشی نبوده بلکه ساختمان‌های موجود یا در مرحله اتمام در منطقه مورد مطالعه می‌باشند. برای تمامی مدل‌های مورد مطالعه نقشه‌های اجرایی سازه با تمامی جزئیات ترسیم شده و در نهایت جدول لیستوفر مصالح مصرفی تهیه شده است. بارگذاری ساختمان‌ها 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. بارگذاری لرزه‌ای مدل‌ها بر مبنای ویرایش چهارم استاندارد ۲۸۰۰ ایران، انجام شده است. هم‌چنین سیستم سقف ساختمان‌های مورد مطالعه از نوع تیرچه و بلوک است. از آنجایی که تعداد پارامترهای مؤثر در رفتار ساختمان به‌خصوص وزن ساختمان و وزن میلگردهای مصرفی در سازه بتنی بسیار متنوع است، در پژوهش حاضر روی مهم‌ترین آن‌ها تمرکز شده و تعداد محدودی از تأثیرگذارترین آن‌ها در رفتار سازه و به تبع آن در وزن نهایی سازه طراحی شده، بررسی شده‌اند. یادآور می‌شود در پژوهش حاضر پارامترهایی به‌عنوان ورودی‌های مسئله انتخاب شده است که از معماری ساختمان قابل استخراج باشند و در نهایت با بهره‌گیری از روش پیشنهادی تحقیق بدون طراحی سازه، بتوان خروجی‌های سازه‌ای را برآورد نمود. ورودی‌های مدل توسعه داد شده پیشنهادی عبارت‌اند از: تعداد دهانه‌های قاب خمشی در راستای طولی و عرضی، ارتفاع ساختمان، مساحت پلان، تعداد ستون‌ها در هر طبقه و برش پایه لرزه‌ای. تعداد دهانه‌های قاب خمشی در دو راستای طولی و عرضی نماینده پیکربندی

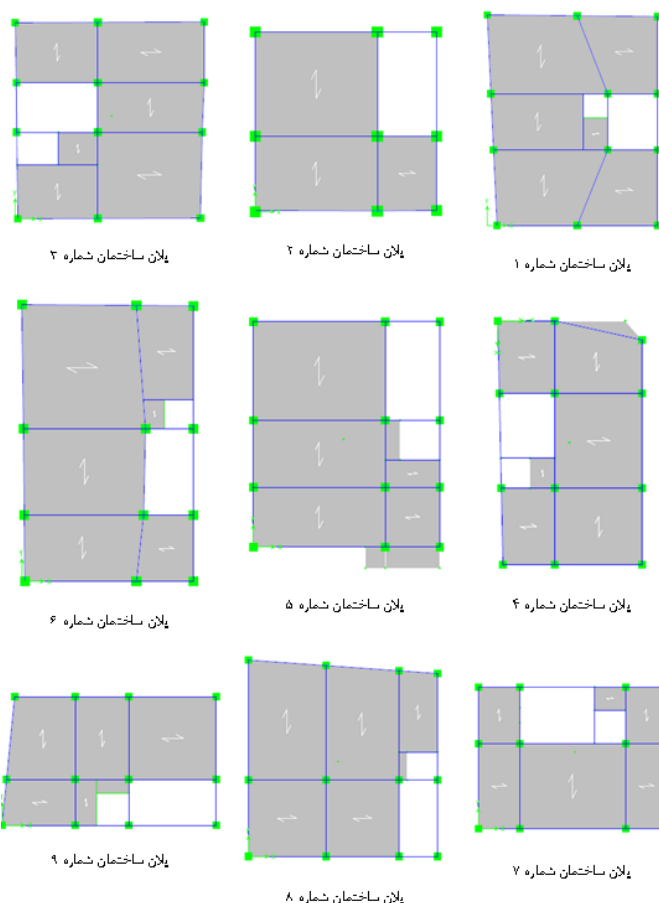
سازه‌ای و پلان تیرریزی و تعداد تیرهای ساختمان است که ارتباط مستقیم با میلگرد مصرفی در سازه دارد. مساحت پلان نماینده وسعت ساختمان از نظر معماری است و افزایش مساحت پلان به افزایش وزن سازه و افزایش وزن میلگرد مصرفی منجر می‌شود. با افزایش ارتفاع سازه و تعداد طبقات، افزایش وزن سازه شتاب بیشتری می‌گیرد. زیرا علاوه بر طراحی سازه برای تحمل نیروها، بایستی ابعاد مقاطع و میزان میلگرد گذاری جهت کنترل تغییر مکان جانبی سازه افزایش یابد. ستون‌ها وظیفه تحمل بارهای وارد بر سازه و انتقال آن‌ها به فونداسیون را بر عهده‌دارند. تعداد ستون‌ها در هر طبقه نماینده کفایت المان‌های باربر لرزه‌ای و نامعینی سازه است. شاید به نظر برسد که برش پایه لرزه‌ای یک مؤلفه سازه‌ای است که محاسبه آن مستلزم مدل‌سازی دقیق و طراحی کامل سازه است. در این خصوص یادآور می‌شود که با توجه به ضریب لرزه‌خیزی شهری که سازه در آن واقع شده است و با معلوم بودن زیربنای ساختمان، کاربری ساختمان، جزئیات اجرایی سفت‌کاری و نازک‌کاری و ابعاد متداول مقاطع سازه‌ای که جملگی از نقشه‌های معماری قابل‌برداشت هست می‌توان برش پایه لرزه‌ای را با دقت بسیار بالا محاسبه کرد. از دیگر سو برش پایه لرزه‌ای مؤلفه‌ای است که منعکس‌کننده بارگذاری‌های اصلی ساختمان یعنی بار مرده و بار زنده و بار لرزه‌ای است. خروجی مسئله شامل وزن کل میلگردهای مصرفی در ساختمان است که از جمع میلگردهای برشی و خمشی تیرها و ستون‌ها به دست می‌آید. برای تحلیل و طراحی مدل‌ها از نرم‌افزار ETABS [۲۳] استفاده شده است. برای تخمین وزن میلگرد مصرفی در سازه پس از پایان مدل‌سازی‌ها و تکمیل طراحی‌های انجام‌شده، برای تمامی مدل‌های مورد مطالعه نقشه‌های اجرایی سازه با تمامی جزئیات ترسیم‌شده و در نهایت جدول لیستوفر مصالح مصرفی تهیه شد. در شکل ۲، نمونه پلان‌های سازه‌ای ساختمان‌های مورد مطالعه نشان داده شده است.

بر مبنای مدل چندلایه بازگشتی شبکه عصبی توسعه داده شده تحقیق، برای تعیین شبکه‌ی با بهترین عملکرد، مدل‌های مختلفی 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 ۶ نرون در لایه ورودی و یک نرون در لایه خروجی به‌عنوان مدل بهینه انتخاب شد. تعداد نرون‌ها در لایه پنهان شبکه در عملکرد آن شبکه مؤثر است. استفاده از نرون‌های خیلی کم منجر به عدم انطباق و استفاده از گره‌های بسیار زیاد حفظ الگوهای داده‌های ورودی را در پی دارد [۲۴]. آموزش شبکه بر اساس ۶ نرون در لایه پنهان آغاز و تا ۱۵ نرون در لایه پنهان ادامه یافت. با توجه به کمترین مربعات متوسط خطاها، ۱۰ نرون برای لایه پنهان در نظر گرفته شد. در مدل مذکور از الگوریتم لونیگ - مارکوارت (LM) برای آموزش استفاده شده است. از ۹۰ ساختمان مورد مطالعه، ۱۵ درصد (نمونه ۱۴) برای آزمایش، ۱۵ درصد (نمونه ۱۴) برای ارزیابی شبکه و ۷۰ درصد باقیمانده (نمونه ۶۲) به صورت تصادفی برای آموزش شبکه در نظر گرفته شده است. در پژوهش حاضر جهت ساخت و آموزش شبکه‌های عصبی از جعبه ابزار نرم‌افزار MATLAB استفاده شده است [۲۵].

جدول ۳: مشخصات فنی ۲۰ نمونه از ساختمان‌های مورد مطالعه

سازه	تعداد دهانه ۱	تعداد دهانه ۲	مساحت پلان (m ²)	ارتفاع سازه (m)	تعداد ستون در هر طبقه	برش پایه (ton)	کل میلگرد مصرفی (ton)
۱	۳	۲	۱۵۱	۱۲٫۷	۱۲	۱۳۶٫۳۷	۲۱٫۶۹
۲	۲	۲	۶۳	۹٫۵	۹	۴۸٫۵۳	۹٫۵۶
۳	۳	۲	۱۲۱	۱۲٫۷	۱۲	۱۰۵٫۳۱	۱۴٫۴۹
۴	۳	۲	۱۴۸	۱۶	۱۲	۱۴۸٫۶۶	۲۳
۵	۳	۲	۱۱۲	۱۲٫۷	۱۲	۹۱٫۷۵	۱۳٫۶۶
۶	۳	۲	۱۴۵	۱۶	۱۲	۱۷۱٫۳	۳۲٫۸۵
۷	۳	۲	۹۸	۱۶	۱۲	۱۱۶٫۱۴	۲۰٫۳۴
۸	۳	۲	۱۵۵	۱۶٫۲	۱۲	۱۴۳٫۰۴	۲۰٫۹
۹	۲	۲	۱۰۲	۱۲٫۷	۹	۸۲	۱۳٫۵۴
۱۰	۲	۲	۱۰۸	۱۶	۹	۱۳۲٫۹۲	۲۶٫۳۹
۱۱	۳	۲	۹۶	۱۲٫۸	۱۲	۷۱٫۰۸	۱۸٫۴۴
۱۲	۲	۲	۱۰۲	۱۲٫۷	۹	۹۴٫۱۲	۱۶٫۷۴
۱۳	۲	۲	۸۵	۱۲٫۷	۹	۸۶٫۱۶	۱۵٫۳۶

۱۸,۵۸	۹۶,۶۵	۹	۱۲,۷	۱۱۰	۲	۲	۱۴
۱۳,۸۵	۹۴,۶۶	۹	۱۲,۷	۱۰۱	۲	۲	۱۵
۱۴,۰۷	۱۰۲,۴	۹	۱۲,۷	۱۱۳	۲	۲	۱۶
۱۵,۲۹	۹۶,۸۱	۱۲	۱۲,۷	۱۰۲	۲	۳	۱۷
۱۵,۱۵	۹۶,۰۸	۱۲	۱۲,۷	۱۱۲	۲	۳	۱۸
۲۴,۰۲	۱۴۰,۶۸	۱۲	۱۶	۱۲۲	۲	۳	۱۹
۲۲,۷۸	۱۳۷,۵۲	۱۲	۱۲,۷	۱۶۶	۳	۳	۲۰




شکل ۲: نمونه پلان‌های سازه‌ای ساختمان‌های مورد مطالعه

۵- بحث و تفسیر نتایج

همان‌طور که در بخش‌های قبل عنوان شد اطلاعات ۹۰ مدل شامل ۷ مؤلفه ورودی و یک مؤلفه خروجی به الگوریتم شبکه عصبی معرفی شد. شبکه با استفاده از روش مارک-لونبرگ و با نسبت داده‌های ۱۵-۷۵-۱۵ درصد آموزش داده شد. عملکرد مدل مذکور از طریق مقایسه مقادیر پیش‌بینی‌شده و مقادیر اصلی با شاخص‌هایی همچون ضریب همبستگی، میانگین مربعات خطا و توزیع پراکندگی خطاها ارزیابی شده است. همان‌طور که در جدول ۴ و شکل ۳ نشان داده شده است ضریب خطی همبستگی بین داده‌های مدل‌سازی و مقادیر پیش‌بینی‌شده توسط مدل شبکه عصبی مصنوعی بالا است. ضریب همبستگی برای گروه آموزش برابر با ۰/۹۸ و برای صحت سنجی برابر با ۰/۹۷ و برای آزمایش برابر با ۰/۹۷ است. این مقادیر نشان می‌دهد که آموزش و عملکرد مدل شبکه عصبی پیشنهادی خوب است. هم‌چنین در جدول ۵، مقادیر برآورد شده توسط مدل شبکه عصبی مصنوعی با مقادیر واقعی مقایسه شده است.

جدول ۴: مقادیر ضریب همبستگی و میانگین مربعات خطا برای داده‌های آموزشی، صحت سنجی و آزمایشی

نوع داده‌ها	تعداد داده‌ها	میانگین مربعات خطا (MSE)	ضریب همبستگی (R)
آموزشی	۶۲	۰,۰۰۱۳۵	۰,۹۸۳۸۵
صحت سنجی	۱۴	۰,۰۰۱۷۱	۰,۹۶۷۴۷
آزمایشی	۱۴	۰,۰۰۱۸۷	۰,۹۷۲۴۷




شکل ۳: نمودار ضریب همبستگی برای داده‌های آموزشی، صحت سنجی، آزمایشی و کل داده‌ها

جدول ۵: مقادیر اصلی و پیش‌بینی شده مربوط به داده‌های آزمایشی در شبکه عصبی مصنوعی

ردیف	مقادیر اصلی نرمال	مقادیر پیش‌بینی شده نرمال	مقادیر اصلی	مقادیر پیش‌بینی شده	درصد خطای نسبی
۱	۱	۰٫۹۴	۵۵٫۲۷	۵۲٫۳۳	۵٫۳٪
۲	۰٫۴۱	۰٫۳۸	۲۶٫۴	۲۴٫۹۳	۵٫۶٪
۳	۰٫۳۶	۰٫۳۹	۲۳٫۹۵	۲۵٫۴۲	۶٫۱٪
۴	۰٫۳	۰٫۳۳	۲۱٫۰۲	۲۲٫۴۹	۷٪
۵	۰٫۲۹	۰٫۳۳	۲۰٫۵۳	۲۲٫۴۹	۹٫۵٪
۶	۰٫۲۱۷	۰٫۲۱۹	۱۶٫۹۶	۱۷٫۰۶	۰٫۶٪
۷	۰٫۱۶	۰٫۱۷	۱۴٫۱۷	۱۴٫۶۶	۳٫۵٪
۸	۰٫۱۵	۰٫۱۸	۱۳٫۶۸	۱۵٫۱۵	۱۰٫۷٪
۹	۰٫۱۲	۰٫۱۵	۱۲٫۲۱	۱۳٫۶۸	۱۲٪
۱۰	۰٫۱۵	۰٫۱۴	۱۳٫۶۸	۱۳٫۱۹	۳٫۶٪
۱۱	۰٫۱۴	۰٫۱۴	۱۳٫۱۹	۱۳٫۱۹	۰٫۰٪
۱۲	۰٫۰۱۴	۰٫۱۴	۷٫۰۳	۷٫۰۳	۰٫۰٪
۱۳	۰٫۲۵	۰٫۱۴	۱۸٫۵۷	۱۳٫۱۹	۲۹٪
۱۴	۰٫۰۵	۰٫۱۱	۸٫۷۹	۱۱٫۷۲	۳۳٫۴٪

در شکل ۴، مقایسه نتایج حاصل از پیش‌بینی وزن میلگرد مصرفی در سازه توسط مدل شبکه عصبی مصنوعی و مقادیر واقعی نشان داده شده است. همان‌طور که در نمودار مشاهده می‌شود مقادیر پیش‌بینی شده انطباق قابل قبولی با مقادیر واقعی دارد که نشان دهنده مناسب بودن روش شبکه عصبی مصنوعی در موضوع پژوهش از طرفی و انتخاب مناسب متغیرهای ورودی موثر در برآورد وزن میلگرد مصرفی در سازه از سوی دیگر می‌باشد.



شکل ۴: مقایسه مقادیر پیش‌بینی شده و مقادیر واقعی

وزن میلگرد مصرفی در سازه، متأثر از عوامل متعددی هست که لزوماً رابطه خطی باهم ندارند. با افزایش تعداد مؤلفه‌های موردبررسی و به عبارتی با افزایش تعداد نرون‌های لایه ورودی، شاید بتوان دقت مدل شبکه عصبی را بهبود بخشید لیکن مسئله از حالت ارائه برآورد قابل قبول در مطالعات اولیه خارج شده و به سمت طراحی نهایی سازه با جزئیات کامل درخواهد آمد.

۶- نتیجه‌گیری

در این پژوهش از قابلیت‌های یادگیری و تخمین و پیش‌بینی شبکه عصبی مصنوعی، برای برآورد وزن میلگردهای مصرفی در ساختمان‌های مسکونی قاب خمشی بتنی بهره گرفته شد. بدین منظور ۹۰ مدل سازه‌ای که از جهت انطباق با مقررات ملی ساختمان و استاندارد ۲۸۰۰ ایران توسط سازمان نظام‌مهندسی ساختمان بررسی و کنترل شده‌اند مورد استفاده قرار گرفت. با معرفی شش پارامتر ورودی شامل، تعداد دهانه‌های قاب خمشی در راستای طولی و عرضی، ارتفاع سازه، مساحت طبقه، تعداد ستون در هر طبقه و برش پایه لرزه‌ای، وزن میلگردهای مصرفی در سازه تخمین زده شد. نتایج حاصل نشان داد برآوردهای شبکه عصبی مصنوعی انطباق قابل قبولی با نتایج واقعی دارد و با استفاده از این روش می‌توان بدون طراحی سازه و فقط با گروهی از اطلاعاتی که از نقشه‌های معماری قابل استخراج است وزن میلگردهای مصرفی در سازه بتنی را برآورد کرد. میلگرد مصرفی در سازه تابع متغیرهای فراوانی می‌باشد و حساسیت متغیرها از سازه‌ای به سازه دیگر متفاوت می‌باشد. از آنجایی که نمونه‌های مورد مطالعه، ساختمان‌های واقعی اجرا شده با تنوع مشخصات بالا می‌باشد، دقت بالای نتایج مدل شبکه عصبی مصنوعی، نشان‌دهنده انتخاب مناسب متغیرهای ورودی مساله می‌باشد. از ۱۴ نمونه بررسی شده برای آزمایش شبکه، ۹ نمونه با خطای کمتر از ۷ درصد میلگرد مصرفی در سازه را تخمین زدند. این دستاورد کمک شایانی به سرمایه‌گذاران و کارفرمایان جهت محاسبه هزینه‌ها و برنامه‌ریزی تأمین مالی پروژه محسوب می‌شود. با افزایش تعداد ساختمان‌های مورد مطالعه می‌توان دقت مدل شبکه عصبی پیشنهادی را افزایش داد و در مطالعات آتی برای مشخص شدن میزان تاثیر هر یک از پارامترهای ورودی بر میلگرد مصرفی در سازه می‌توان آنالیز حساسیت انجام داد و روابط کاربردی جهت برآورد وزن میلگرد مصرفی سازه ارائه نمود.

مراجع:

- [1] Kaveh, A. (2007) Application of artificial neural networks for predicting the displacements of domes under wind loading. International journal of industrial engineering and production management (IJIE) Volume 18, Number 2; Page(s) 45 To 53.
- [2] Mortezaei, A. (2012). Modeling and estimation of plastic hinge length of RC columns using artificial neural networks. Journal of modeling in engineering, Volume 10, Issue 29, Pages 1-17.
- [3] Effati, M. (2017). Prediction of the Concrete Slump with Artificial Neural Network Model and the Multivariable Linear Regression Method. Concrete Research Quarterly Journal, Volume 10, Issue 19, Pages 125-136
- [4] Hashemi, S. Sh. (2019). Investigation of the effects of number and height of the floors on the weight of the structures with moment-resisting steel frames using artificial neural. Sharif journal of civil engineering, Volume 35-2, Issue 1, Pages 81-89.
- [5] Akbari, M. (2018). Shear strength estimation of the concrete beams reinforced with FRP; comparison of artificial neural network and equations of regulations. Journal of Structural and Construction Engineering, Volume 4, Issue 4, Pages 79-9.
- [6] Naderpour, H. (2018). Predicting the Torsional Strength of Reinforced Concrete Beams Strengthened with FRP Sheets in terms of Artificial Neural Networks, Volume 5, Issue 1, Pages 20-35.
- [7] Labibzadeh, M. (2019). Determining of Load Bearing Capacity of Rectangular Concrete Columns Reinforced with Longitudinal Spirals Using FEM and ANN Methods. Volume 6, Issue 2, Pages 157-176.
- [8] Sujith Mangalathu. (2018). Artificial neural network based multi-dimensional fragility development of skewed concrete bridge classes. Engineering Structures volume 162, Pages 166-176.
- [9] Shahmansouri, AA. (2021). Data-Driven Models for Predicting the Shear Strength of Rectangular and Circular Reinforced Concrete Columns. Journal of Structural Engineering, Volume 147(1).
- [10] Moradi, MJ. (2019). Developing a Library of Shear Walls Database and the Neural Network Based Predictive Meta-Model. Applied Sciences ; doi:10.3390/app9122562.
- [11] De-Cheng Feng. (2021). Data-Driven Approach to Predict the Plastic Hinge Length of Reinforced Concrete Columns and Its Application. Journal of Structural Engineering, Volume 147.2: 04020332.

- [12] Berenjian, J. (2019). Predicting the compressive strength of self-compacting concrete using Elman artificial neural network with two different sets of input parameters. *Journal of Structural and Construction Engineering*, Volume 5, Issue 4, Pages 162-178.
- [13] Hubick, K. T. (1992). *Artificial neural networks in Australia*. Canberra: Department of Industry, Technology and Commerce, 1-132.
- [14] Suzuki, K. (2011). *Artificial Neural Networks: Methodological Advances and Biomedical Applications*. Rijeka: InTech, 1-362.
- [15] Masters, T. (1993). *Practical neural network recipes in C++*. San Diego, California: Academic Press publication, 1-493.
- [16] Marquardt, C. (2009). Lifetime calculation under variable amplitude loading with the application of artificial neural networks. *International Journal of Fatigue*, Volume 27(8), Pages 920-927
- [17] Masters, T. (1993). *Practical neural network recipes in C++*. San Diego, California: Academic Press publication, 1-493.
- [18] Saridemir, M. (2009). Prediction of long-term effects of GGBFS on compressive strength of concrete by artificial neural networks and fuzzy logic. *Construction and Building Materials*, Volume 23, Pages 1279–1286.
- [19] Smith, M. (1993). *Neural networks for statistical modelling*. New York: Van Nostrand Reinhold, 1-235.
- [20] Iranian National Building Code, Part 6. (2013). *Loading on structures*. Tehran: Ministry of Road and Urban Development.
- [21] Iranian National Building Code, Part 9. (2013). *Design and Construction of RC Buildings*. Tehran: Ministry of Road and Urban Development.
- [22] Road, Housing and Urban Development Research Center. (2013). *Iranian code of practice for seismic-resistant design of buildings*. Iranian Building Code, Standard No. 2800, 4th Edn.
- [23] CSI, "ETABS 9.7.4 Extended 3D Analysis of Building Systems," Computers and Structures Inc., Berkeley, California.
- [24] Beer, M. Spanos, P.D. (2009). "A neural network approach for simulating stationary stochastic processes". *Structural Engineering and Mechanics*, Vol. 32, No. 1, pp. 71-94.
- [25] MathWorks, MATLAB. (2018). *The language of technical computing*. Version 7.11.0. (R2018b).

ضمائم:

جدول ۶: جدول اطلاعات کامل ساختمان های مورد مطالعه

سازه	تعداد دهانه ۱	تعداد دهانه ۲	مساحت پلان (مترمربع)	ارتفاع سازه (متر)	تعداد ستون در هر طبقه	برش پایه (کیلوگرم)	کل میلگرد مصرفی (کیلوگرم)
۱	۴	۲	۹۵	۱۲.۷	۱۵	۱۰۰۷۵۳	۱۷۷۸۸
۲	۳	۲	۱۰۲	۱۲.۷	۱۲	۱۰۰۰۵۹	۱۸۸۴۲
۳	۳	۲	۱۱۶	۱۲.۷	۱۲	۹۸۰۶۲	۱۶۹۶۷
۴	۳	۲	۱۲۸	۱۶.۲	۱۲	۱۴۵۷۳۵	۲۳۷۹۲
۵	۳	۲	۱۱۶	۱۲.۷	۱۲	۹۸۸۵۵	۱۸۰۲۱
۶	۳	۲	۱۱۷	۱۲.۸	۱۲	۸۱۶۰۸	۱۸۵۱۳
۷	۲	۲	۶۱	۱۲.۷	۹	۶۱۵۵۷	۱۴۳۲۱
۸	۳	۲	۱۲۷	۱۲.۷	۱۲	۱۱۳۴۷۰	۲۰۷۳۳
۹	۲	۲	۱۰۲	۱۲.۷	۹	۸۱۹۹۸	۱۳۵۴۴
۱۰	۲	۲	۱۰۸	۱۶	۹	۱۳۲۹۲۰	۲۶۳۹۳
۱۱	۳	۲	۹۶	۱۲.۸	۱۲	۷۱۰۷۷	۱۸۴۴۱
۱۲	۲	۲	۱۰۲	۱۲.۷	۹	۹۴۱۲۱	۱۶۷۳۹
۱۳	۲	۲	۸۵	۱۲.۷	۹	۸۶۱۶۱	۱۵۳۶۵
۱۴	۲	۲	۱۱۰	۱۲.۷	۹	۹۶۶۴۵	۱۸۵۸۴
۱۵	۲	۲	۱۰۱	۱۲.۷	۹	۹۴۶۵۶	۱۳۸۵۵
۱۶	۲	۲	۱۱۳	۱۲.۷	۹	۱۰۲۴۰۲	۱۴۰۷۵
۱۷	۳	۲	۱۰۲	۱۲.۷	۱۱	۹۶۸۰۷	۱۵۲۸۷
۱۸	۳	۲	۱۱۲	۱۲.۷	۱۱	۹۶۰۸۴	۱۵۱۵۰
۱۹	۳	۲	۱۲۲	۱۶	۱۱	۱۴۰۶۷۱	۲۴۰۲۲

۲۲۷۸۰	۱۳۷۵۲۰	۱۴	۱۲.۷	۱۶۶	۳	۳	۲۰
۵۰۸۰۳	۳۰۳۱۵۰	۱۷	۱۹.۲	۲۱۸	۲	۵	۲۱
۵۵۲۷۳	۳۱۰۵۷۴	۱۸	۱۶	۲۹۵	۲	۵	۲۲
۶۳۴۰	۴۳۴۰۰	۹	۹.۵	۶۵	۲	۲	۲۳
۲۴۲۴۸	۱۱۱۹۵۰	۱۲	۱۲.۷	۱۲۲	۲	۳	۲۴
۱۵۳۱۳	۹۵۹۳۸	۱۲	۱۲.۷	۱۰۴	۲	۳	۲۵
۹۵۶۳	۴۸۵۲۷	۹	۹.۵	۶۳	۲	۲	۲۶
۱۱۹۵۴	۷۰۰۱۴	۹	۹.۵	۹۹	۲	۲	۲۷
۲۱۶۸۵	۱۳۶۳۶۹	۱۲	۱۲.۷	۱۵۱	۲	۳	۲۸
۱۵۴۲۶	۹۶۸۰۸	۱۱	۱۲.۷	۱۰۲	۲	۳	۲۹
۲۲۸۱۶	۱۴۶۷۲۴	۱۲	۱۶	۱۳۴	۲	۳	۳۰
۲۴۸۶۵	۱۵۰۵۳۸	۱۱	۱۶	۱۳۳	۲	۳	۳۱
۹۵۱۴	۶۰۲۰۷	۹	۹.۵	۱۰۳	۲	۲	۳۲
۱۳۸۵۱	۹۴۶۵۶	۹	۱۲.۷	۱۰۱	۲	۲	۳۳
۲۸۷۰۵	۱۵۳۶۱۱	۱۴	۱۲.۷	۱۶۷	۳	۳	۳۴
۵۰۲۷۰	۲۱۰۸۷۱	۱۱	۲۱.۴	۱۳۰	۲	۳	۳۵
۲۲۷۶۳	۱۲۸۵۷۳	۱۲	۱۶	۱۰۴	۲	۳	۳۶
۳۲۸۵۳	۱۷۱۴۳۳	۱۲	۱۶	۱۴۵	۲	۳	۳۷
۱۵۱۸۶	۹۱۷۵۱	۹	۱۲.۸	۱۰۱	۲	۲	۳۸
۲۴۱۴۹	۱۳۸۵۰۰	۱۲	۱۵.۸	۱۲۵	۲	۳	۳۹
۱۸۴۲۱	۶۹۱۰۰	۱۲	۱۲.۵	۱۴۰	۲	۳	۴۰
کل میلگرد مصرفی (کیلوگرم)	برش پایه (کیلوگرم)	تعداد ستون در هر طبقه	ارتفاع سازه (متر)	مساحت پلان (مترمربع)	تعداد دهانه ۲	تعداد دهانه ۱	سازه
۶۲۷۶	۲۴۳۰۰	۸	۹.۲	۵۵	۲	۲	۴۱
۱۴۵۳۵	۴۹۰۰۰	۹	۱۲.۵	۸۳	۲	۲	۴۲
۹۱۱۶	۶۰۱۱۰	۱۲	۹.۳	۱۰۴	۲	۳	۴۳
۲۶۵۹۴	۱۵۴۰۰۰	۱۵	۱۲.۵	۲۰۴	۳	۳	۴۴
۳۰۰۷۶	۱۷۷۰۰۰	۱۲	۱۷.۲	۱۷۰	۲	۳	۴۵
۱۵۷۲۲	۹۳۵۲۰	۹	۱۲.۶	۱۰۶	۲	۲	۴۶
۲۹۰۴۲	۱۸۵۷۸۰	۱۲	۱۵.۸	۱۷۵	۲	۳	۴۷
۴۳۱۸۵	۲۴۶۰۵۰	۲۱	۱۵.۸	۲۵۰	۲	۷	۴۸
۳۰۵۰۹	۱۸۰۷۳۰	۱۲	۱۵.۸	۱۹۸	۲	۳	۴۹
۱۶۴۸۸	۱۰۳۵۰۰	۱۰	۱۲.۴	۱۲۵	۲	۳	۵۰
۷۰۹۵	۵۳۷۷۷	۹	۹.۶	۸۵	۲	۲	۵۱
۱۴۴۹۰	۱۰۵۳۰۶	۱۲	۱۲.۸	۱۲۱	۲	۳	۵۲
۶۸۸۹	۴۱۱۶۵	۹	۹.۳	۶۶	۲	۲	۵۳
۲۰۸۹۸	۱۴۳۰۳۹	۱۲	۱۶.۲	۱۵۵	۲	۳	۵۴
۱۲۴۴۵	۸۴۱۲۰	۹	۱۲.۷	۹۲	۲	۲	۵۵
۸۱۹۵	۵۹۵۶۰	۱۲	۹.۶	۹۵	۲	۳	۵۶
۲۰۸۴۷	۱۲۶۴۹۸	۱۲	۱۶	۱۰۷	۲	۳	۵۷
۲۰۵۴۲	۱۳۰۶۳۳	۱۲	۱۶	۱۲۵	۲	۳	۵۸
۱۳۶۵۹	۹۱۷۴۸	۱۲	۱۲.۸	۱۱۲	۲	۳	۵۹
۲۲۹۹۶	۱۴۸۶۵۸	۱۲	۱۶	۱۴۸	۲	۳	۶۰
۶۳۴۳	۴۲۵۴۳	۹	۹.۶	۶۲	۲	۲	۶۱
۷۱۷۸	۵۵۰۷۴	۹	۹.۷	۸۸	۲	۲	۶۲
۸۶۶۵	۶۱۴۴۴	۹	۱۲.۷	۶۳	۲	۲	۶۳
۹۷۷۸	۶۸۹۵۲	۹	۱۲.۷	۷۴	۲	۲	۶۴
۹۳۹۵	۶۳۳۸۵	۹	۱۲.۸	۶۵	۲	۲	۶۵
۱۱۵۶۱	۷۴۶۴۰	۹	۱۳	۸۵	۲	۲	۶۶

۲۰۳۴۲	۱۱۶۱۴۱	۱۲	۱۶	۹۸	۲	۳	۶۷
۹۴۷۶	۶۳۸۷۴	۹	۱۲.۸	۶۹	۲	۲	۶۸
۸۷۰۰	۵۵۵۳۳	۹	۱۳	۶۰	۲	۲	۶۹
۱۰۹۰۷	۷۱۷۰۴	۱۲	۱۳	۸۲	۲	۳	۷۰
۲۸۴۳۳	۱۶۶۳۸۲	۱۲	۱۵.۵	۱۶۵	۲	۳	۷۱
۳۴۵۵۲	۲۳۶۴۵۰	۱۸	۱۵.۹	۲۳۴	۲	۵	۷۲
۲۱۶۱۶	۱۱۹۵۲۰	۱۲	۱۳.۱	۱۴۴	۲	۳	۷۳
۲۰۱۳۵	۱۰۶۹۱۰	۱۲	۱۲.۶	۱۱۷	۲	۳	۷۴
۱۷۳۷۸	۱۰۶۶۴۵	۱۲	۱۲.۷	۱۳۵	۲	۳	۷۵
۱۴۹۹۵	۹۶۲۴۰	۹	۱۲.۶	۱۱۶	۲	۲	۷۶
۱۴۲۳۳	۸۶۵۸۰	۱۲	۱۲.۶	۹۴	۲	۳	۷۷
۲۴۱۱۱	۱۵۵۵۴۵	۱۴	۱۲.۶	۲۰۳	۳	۳	۷۸
۸۶۱۲۰	۱۳۱۷۸۰	۹	۱۵.۸	۱۲۱	۲	۲	۷۹
۱۴۷۷۲	۱۰۷۶۳۰	۱۲	۱۲.۷	۱۲۹	۲	۳	۸۰
۷۰۳۱	۴۵۱۴۰	۹	۹.۳	۶۹	۲	۲	۸۱
۲۱۳۶۲	۱۲۶۱۰۰	۹	۱۵.۸	۱۱۵	۲	۲	۸۲
۱۳۱۶۵	۸۱۰۴۵	۹	۱۲.۴	۹۶	۲	۲	۸۳
کل میلگرد مصرفی (کیلوگرم)	برش پایه (کیلوگرم)	تعداد ستون در هر طبقه	ارتفاع سازه (متر)	مساحت پلان (مترمربع)	تعداد دهانه ۲	تعداد دهانه ۱	سازه
۱۵۲۱۳	۹۸۵۳۸	۹	۱۲.۴	۱۲۵	۲	۲	۸۴
۲۵۰۳۰	۱۴۸۷۷۷	۱۲	۱۵.۹	۱۳۹	۲	۳	۸۵
۱۶۸۵۴	۹۷۱۵۵	۹	۱۲.۷	۱۱۷	۲	۲	۸۶
۳۰۹۰۸	۱۷۲۱۲۸	۱۶	۱۵.۹	۱۸۳	۳	۳	۸۷
۳۱۷۵۴	۱۶۸۲۵۹	۱۴	۱۶.۱	۱۷۱	۳	۳	۸۸
۲۳۸۱۸	۱۳۴۴۰۰	۱۲	۱۵.۶	۱۲۹	۲	۳	۸۹
۱۹۵۲۸	۱۱۴۶۰۰	۱۲	۱۲.۶	۱۵۸	۲	۳	۹۰

جدول ۷: وزن‌ها و بایاس گره‌ها

B1									
1.351325	1.369115	1.370086	0.509743	0.540733	-0.603960	-0.271391	-0.988993	-1.565173	2.293728
W1									
-0.059620	-1.441974	-0.189423	-1.075052	-1.345536	-0.946284	-0.573764	-0.787861	-1.026826	0.548409
-0.531187	0.295023	-0.859454	-0.014364	0.124216	-0.379560	-0.921900	-0.211178	0.841000	0.772598
-0.607559	-0.990275	-0.089022	0.547243	-0.572565	-0.776221	1.099585	-1.112056	-0.842702	-0.839480
-1.006612	0.286389	0.317544	1.646530	1.09359	1.259338	0.377548	-1.152643	0.928380	1.043395
1.574059	0.994695	1.488445	0.011007	-1.115822	-0.432159	-0.487664	-1.159322	1.010453	-0.420689
-1.024767	-0.909797	0.210466	0.097338	-1.088452	0.977938	0.476915	0.956942	-0.180245	0.213868
B2									
0.0172577									
W2									
-0.824771	-0.878792	0.755555	-0.326986	0.382782	-0.298163	0.472502	0.613133	0.126155	1.068541