

کاربرد شبکه‌های عصبی مصنوعی در تخمین مصرف انرژی فضاهای آموزشی

دکتر مهسا فلاح‌نیا*

تاریخ دریافت مقاله: ۱۳۹۵/۱۱/۰۷ تاریخ پذیرش نهایی: ۱۳۹۶/۱۱/۱۶

چکیده

تاکنون توصیه‌های دقیقی برای مهندسان معمار جهت تعیین ابعاد مناسب پنجره با رویکرد کاهش مصرف انرژی برای فضاهای آموزشی ارائه نشده است. برای آنکه طراحان فضاهای آموزشی به‌دوراز محاسبات هزینه‌بر و وقت‌گیر شبیه‌سازی انرژی قادر به تعیین سطح مناسب پنجره و یا حداقل اولویت‌بندی گزینه‌های ممکن نورگیری باشند، در تحقیق حاضر بر پایه هوش مصنوعی ساختاری جدید ارائه شده است که می‌تواند هزینه انرژی را در مدت بهره‌برداری از یک کلاس درس استاندارد، به‌عنوان مهم‌ترین بخش فضای آموزشی، پیش‌بینی نماید. بدین منظور، ۲۸۸ سناریوی نورگیری شبیه‌سازی شده و نتایج حاصله برای آموزش شبکه عصبی مصنوعی استفاده شده است. آزمون‌های شبکه آموزش نشان می‌دهد که ساختار پیشنهادی به‌خوبی می‌تواند جایگزین مدل شبیه‌ساز مصرف انرژی گردد و طراح تنها با مشخص نمودن جهت نورگیری و نسبت سطح پنجره به سطح دیوار کلاس می‌تواند هزینه مصرف گاز و الکتریسیته را در مدت بهره‌برداری با دقت بسیار خوبی پیش‌بینی نماید.

واژه‌های کلیدی

پنجره کلاس درس، مصرف انرژی، DOE-2، هوش مصنوعی، شبکه عصبی مصنوعی

* استادیار گروه معماری، دانشکده معماری و شهرسازی، دانشگاه هنر، تهران، ایران. (مسئول مکاتبات)

Email: fallahnia@art.ac.ir

مقدمه

مصرف انرژی از عوامل مهمی است که در نظر گرفتن آن در مرحله طراحی ساختمان توسط مهندس معمار تأثیر

بسیاری در کاهش هزینه بهره‌برداری از ساختمان و حفظ منابع تأمین انرژی دارد. متأسفانه سهولت عرضه و قیمت نازل انرژی باعث شده است که با مصرف و اتلاف بی‌رویه، وضعیت مصرف انرژی در کشور ما با اصول مربوط به ارتقاء بهره‌وری و بازدهی انرژی در جهان مغایرت داشته باشد. از طرفی در شرایطی که در کشور ما حدود بیست درصد جمعیت شامل بیش از ۱۴ میلیون دانش‌آموز و حدود یک‌میلیون فرهنگی (عصر/ایران، ۱۳۸۹) در ساختمان‌هایی تحت عنوان مدرسه بیش از سه‌چهارم ایام سال به فعالیت آموزشی مشغول‌اند، کوچک‌ترین فعالیتی در جهت بهبود شرایط محیطی و افزایش بهره‌وری از قابلیت‌های طبیعی برای تأمین انرژی این فضاها، بزرگ‌ترین اثرات مثبت را در ارتقاء کیفیت محیط‌های آموزشی و صرفه‌جویی در مصرف انرژی‌های فسیلی، به‌صورت توأم، در پی خواهد داشت. از جمله قابلیت‌های طبیعی که تاکنون کمتر موردتوجه طراحان قرار گرفته است، نور روز است. اهمیت نور روز در ارتقاء کیفی فضاهای آموزشی بر کسی پوشیده نیست اما به دلیل عدم آگاهی از قابلیت‌های این انرژی تجدیدپذیر و نبود کنترل‌های کالبدی صحیح بر میزان ورود نور به درون این‌گونه ساختمان‌ها، غالب مدارس به شیوه صحیح از این امکان بهره‌مند نمی‌گردند و نقش نور روز در تأمین انرژی کلاس‌های درس و در پی آن کیفیت‌بخشی به فضاهای آموزشی بسیار کم‌رنگ است. از طرفی پنجره‌ها عمده‌ترین عامل اتلاف انرژی نیز هستند. حدود ۴۰ درصد انرژی موردنیاز بشر، در ساختمان‌ها مصرف می‌شود (زارع و حیدری، ۱۳۹۴). حدود یک‌چهارم کل انرژی لازم برای گرمایش و سرمایش فضاهای مسکونی و تجاری آمریکا در سال ۱۹۹۴ برای جبران گرمای ازدست‌رفته از طریق پنجره‌ها مصرف شده است (Singh and Michaelowa, 2004). راهکارهای کاهش مصرف انرژی، از طریق کنترل مشخصات پنجره‌ها، در ایران نیز موردتوجه محققان محدودی قرار گرفته است. به‌عنوان نمونه (کریم پور و همکاران، ۱۳۹۶) در تحقیقی نشان داده‌اند که می‌توان با استفاده از یک سیستم سایه‌انداز بهینه داخلی بر روی پنجره‌ها، مصرف انرژی در بخش مسکن شهر تهران را تا ۱۴ درصد کاهش داد (کریم پور و همکاران، ۱۳۹۶). بنابراین، برای بهره‌وری بهینه در درازمدت، انتخاب پنجره با ابعاد و جهت‌گیری مناسب، در مرحله طراحی مدارس، از جمله معیارهای تأثیرگذار و حائز اهمیت بسیار است. گرچه امروزه در خصوص ارائه راهکارهای طراحی فضاهای آموزشی با توجه به الزامات مصرف بهینه انرژی تلاش‌هایی در سراسر دنیا صورت گرفته است اما در کشور ما آئین‌نامه‌های موجود استانداردسازی مدارس فاقد معیارهای دقیقی در باب استفاده بهینه از نور روز برای کاهش مصرف انرژی هستند. در بخش بهینه‌سازی مصرف انرژی نیز انتخاب نحوه مناسب نورگیری با معیار سطح مناسب پنجره در جهت‌های مختلف نورگیری، مستلزم مدل‌سازی‌های

متعدد نرم‌افزاری برای سناریوهای مختلف نورگیری جهت پیش‌بینی دقیق مصرف انرژی است که معمولاً انجام آن توسط مهندسان معمار که تعیین‌کننده ابعاد پنجره‌ها در مرحله طراحی هستند، فعالیتی زمان‌بر و نیازمند جمع‌آوری متغیرهای بسیار و همچنین تخصص ویژه در استفاده از نرم‌افزارهای شبیه‌ساز مصرف انرژی محسوب می‌شود. از طرفی، بسیاری از سیستم‌های مرتبط با مدل‌سازی مصرف انرژی طبیعت پیچیده غیرخطی دارند که حل معادلات دیفرانسیلی حاکم بر آنها دشوار است و از طرفی عدم آگاهی از این معادلات مهارت استفاده از نرم‌افزارهای مدل‌سازی انرژی را کاهش می‌دهد. حال آنکه رفتار پیچیده چنین سیستم‌هایی را می‌توان به راحتی با مدل‌های جعبه سیاه مبتنی بر هوش مصنوعی مدل‌سازی کرد و مصرف انرژی را پیش‌بینی نمود. از آنجاکه در مدل‌های جعبه سیاه لزومی بر اطلاع کاربر از معادلات حاکم بر مسئله و چگونگی حل آنها و نحوه عملکرد نرم‌افزارهای مرتبط وجود ندارد و ساختار مبتنی بر هوش مصنوعی تنها بر اساس مجموعه‌ای از داده‌ها، آموزش می‌بیند و ارتباط لازم بین ورودی‌ها و خروجی سیستم را بدون نیاز به حل معادلات پیچیده حاکم بر مسئله به وجود می‌آورد، مدل‌های آموزش‌دیده مبتنی بر هوش مصنوعی را، در صورتی که از دقت خوبی برخوردار باشند، می‌توان در مسائل مرتبط با مدل‌سازی مصرف انرژی به کار گرفت. یکی از پرکاربردترین روش‌های مبتنی بر هوش مصنوعی، شبکه‌های عصبی مصنوعی هستند که کاربردهای وسیعی در علوم مختلف از کنترل هواپیمای بدون خلبان تا تشخیص چهره داشته‌اند. مکانیزم آموزش مغز بر تجربه استوار است و شبکه‌های عصبی مصنوعی که ارتباط سیناپسی و ساختار نرونی مغز را مدل می‌کنند، مدلی از ساختار عصبی مغز انسان هستند. به دلیل دارا بودن قابلیت آموزش و تعمیم، با پردازش داده‌ها، دانش پیش‌بینی داده‌های جدید در شبکه‌های عصبی مصنوعی به ساختار شبکه منتقل می‌گردد. در حقیقت، شبکه عصبی مصنوعی بدون دانش قبلی از روابط بین پارامترهای مورد مطالعه، قادر به پیدا کردن رابطه بین مجموعه ورودی‌ها و خروجی‌ها برای پیش‌بینی هر خروجی متناظر با ورودی دلخواه است. از این‌رو، شبکه‌های عصبی مصنوعی، با قابلیت یادگیری که دارند، ابزاری نوین برای مسائل پیچیده‌ای محسوب می‌شوند که مدل‌سازی آنها دشوار است. در همین راستا، کسپرکیویکس^۱ در سال ۱۹۹۵ از شبکه‌های

عصبی برای پیش‌بینی مقاومت بتن استفاده نمود (Kasperkiewicz, 1995). آرگیرو^۲ و همکاران یک کنترل‌کننده گرمای مبتنی بر شبکه عصبی مصنوعی ارائه نمودند که قادر است مقدار انرژی لازم برای تأمین دمای مناسب ساختمان را بر اساس وضعیت آب و هوایی تعیین نماید (Argiriou et al., 2000). بالال^۳ و شر^۴ نشان دادند که به کمک شبکه عصبی مصنوعی می‌توان سیستم سازه‌ای قابل‌اجرای یک ساختمان را به‌خوبی تعیین کرد (Ballal & Sher, 2003). مون^۵ و همکاران با استفاده از بسته‌های نرم‌افزاری موجود در MATLAB، شبکه عصبی مصنوعی را برای تولید

شبیه‌سازی کلاس استاندارد جمع‌آوری و مؤلفه‌های مؤثر بر میزان مصرف انرژی تعیین شوند. در ساختار پیشنهادی مدل‌سازی دقیق مصرف انرژی به کمک یک مدل عددی مبتنی بر دینامیک سیالات محاسباتی برای تولید داده‌های لازم برای آموزش شبکه عصبی مصنوعی ضروری است. از این‌روی، گام دوم به توسعه مدلی عددی برای پیش‌بینی مقدار مصرف انرژی اختصاص داده شده است که با مدل‌سازی یک کلاس درس واقعی تنظیم و صحت عملکرد آن ارزیابی می‌گردد. در گام سوم با تغییر عوامل مؤثر، نظیر ابعاد پنجره کلاس و جهت نورگیری، سناریوهای مختلف نورگیری تولید شده و برای بررسی این سناریوها در بهره‌برداری از نور روز، هریک از آنها به کمک همان مدل عددی از نظر مصرف انرژی شبیه‌سازی می‌شوند. از جمع‌آوری نتایج این شبیه‌سازی‌های عددی پایگاه داده‌ای حاصل می‌گردد که در گام چهارم با جزئیاتی که در شکل ۱ ارائه شده است، برای آموزش و آزمون یک ساختار هوشمند مبتنی بر شبکه‌های عصبی مصنوعی به کار گرفته می‌شود و در نهایت عملکرد ساختار هوشمند حاصل با استفاده از شاخص‌های آماری مورد ارزیابی قرار می‌گیرد.

در ادامه بخش‌های اصلی مدل پیشنهادی تشریح می‌گردد.

مشخصات کلاس مورد مطالعه

گام اول ساختار پیشنهادی شامل انتخاب کلاس استاندارد و تعیین برگ خریدهای مؤثر بر میزان مصرف انرژی است. ضوابط و معیارهای طراحی فضاهای آموزشی توسط گروه معماری دفتر فنی معاونت فنی و نظارت سازمان نوسازی، توسعه و تجهیز مدارس کشور ارائه گردیده است. بر اساس این معیار، کلاس استاندارد کلاسی به ابعاد ۷/۴ × ۷/۴ متر است که ظرفیت ۳۶ دانش‌آموز را دارد و ارتفاع این کلاس ۳ متر در نظر گرفته شده است (سازمان نوسازی، توسعه و تجهیز مدارس کشور، ۱۳۸۶).

در گام بعدی، جمع‌آوری اطلاعات لازم برای شبیه‌سازی مصرف انرژی کلاس درس مطرح است. از مهم‌ترین عوامل لازم برای شبیه‌سازی مصرف انرژی اطلاعات هواشناسی منطقه مورد مطالعه است. فرض بر این است که کلاس استاندارد در شهر شیراز واقع شده است. میانگین بلندمدت پارامترهای هواشناسی ایستگاه‌های هواشناسی این شهر نشان می‌دهد که شیراز دارای متوسط دمای ۱۸ درجه سانتی‌گراد است که متوسط دمای حداقل و حداکثر آن به ترتیب ۱۰/۲ و ۲۵/۸ درجه سانتی‌گراد هست. متوسط رطوبت نسبی ماهانه شیراز ۴۱ درصد است که به‌طور متوسط در سال ۴۱ روز یخبندان را تجربه می‌کند. به‌طور متوسط تعداد ساعات آفتابی این شهر ۹/۲ ساعت است. در جدول ۱ مقادیر میانگین عوامل مختلف هواشناسی در دوره آماری ۱۳۵۰ تا ۱۳۹۰ در ایستگاه سینوپتیک شیراز ارائه شده است.

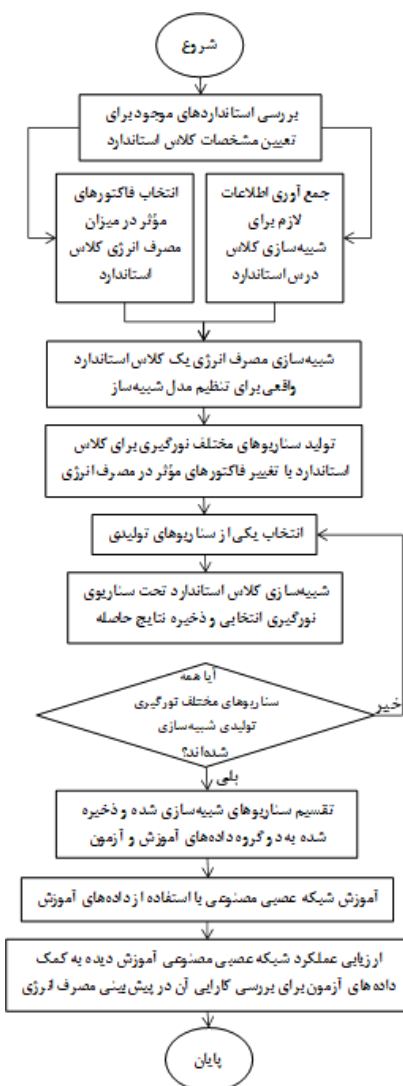
ساختاری پیشرفته برای تأمین آسایش حرارتی در ساختمان‌های مسکونی به کار بردند (Moon et al., 2009). همچنین، عملکرد بسیار خوب شبکه عصبی مصنوعی در پیش‌بینی نیاز انرژی برای گرمایش یک‌خانه در ترکیه توسط دامبایسی^۶ گزارش شده

است (Dombayci, 2010). کومار^۷ و همکاران هم در سال ۲۰۱۳ از شبکه عصبی مصنوعی برای پیش‌بینی مصرف انرژی یک ساختمان استفاده کردند (Kumar et al., 2013). در سال ۲۰۱۵، سه نوع مختلف از شبکه‌های عصبی برای پیش‌بینی مصرف انرژی یک فضای دانشگاهی توسط جوانویک^۸ و همکاران به کار گرفته شد. نتایج این تحقیق نشان می‌دهد که هر سه شبکه عصبی به کار گرفته شده با دقت بسیار خوبی قادر به پیش‌بینی مصرف انرژی لازم برای گرمایش هستند (Jovanovic et al., 2015). نتایج تحقیق دب^۹ و همکاران نشان می‌دهد که شبکه عصبی مصنوعی با دقت بسیار خوبی قادر است مصرف انرژی روزانه بار سرمایش ساختمان‌ها را تعیین کند (Deb et al., 2016). بررسی این تحقیقات، و نمونه‌های بسیار دیگر در این زمینه، نشان می‌دهد که با وجود عملکرد موفق شبکه عصبی مصنوعی در مدل‌سازی سیستم‌های پیچیده در علوم مختلف، تاکنون امکان بهره‌گیری از این ابزار نوین در ارتباط با نور روز در فضاهای آموزشی در تحقیقات ملی و بین‌المللی مورد بررسی قرار نگرفته است.

با توجه به سهم قابل توجه فضاهای آموزشی در مصرف انرژی در کشور ما و همچنین کمبود معیارهای طراحی دقیق برای استفاده بهینه از انرژی در این فضاها، برای آنکه طراحان فضاهای آموزشی از محاسبات هزینه‌بر و وقت‌گیر شبیه‌سازی مصرف انرژی به دور بوده و تنها با دادن مشخصات هندسی و مکانی مدّنظر به یک سامانه هوشمند، امکان انتخاب بهترین گزینه طراحی از نظر مصرف انرژی برای آنها میسر گردد، در این مقاله ساختاری مبتنی بر هوش مصنوعی پیشنهاد شده است که این قابلیت را دارد که میزان مصرف انرژی کلاس درس استاندارد را در شرایط مختلف نورگیری و بدون نیاز به شبیه‌سازی عددی با استفاده از نرم‌افزار پیش‌بینی نماید. به کمک این ساختار پیشنهادی، معمار به‌سادگی می‌تواند مصرف انرژی گزینه‌های مختلف نورگیری را تخمین زده و در خصوص انتخاب گزینه بهینه طراحی پنجره، از منظر مصرف انرژی، تصمیم‌گیری نماید.

روش پژوهش

ساختار روش پیشنهادی در این تحقیق برای نیل به یک مدل مبتنی بر هوش مصنوعی برای تخمین مصرف انرژی را می‌توان به چهار گام اصلی تقسیم‌بندی نمود که در شکل ۱ خلاصه شده‌اند. همان‌گونه که در این شکل ملاحظه می‌گردد، گام نخست شامل انتخاب کلاس استاندارد بر اساس استانداردهای موجود است. در این گام لازم است اطلاعات لازم برای



شکل ۱. ساختار کلی مدل پیشنهادی برای پیش‌بینی مصرف انرژی کلاس استاندارد به کمک شبکه عصبی مصنوعی

جدول ۱. میانگین فاکتورهای مختلف هواشناسی در ایستگاه سینوپتیک شیراز (مأخذ: اداره کل هواشناسی استان فارس، ۱۳۹۶)

ماه	میانگین درجه حرارت (سانتیگراد)			مقدار بارندگی (میلیمتر)	متوسط رطوبت نسبی (درصد)	ساعات آفتابی (جمع ماهانه)
	حداکثر دما	متوسط دما	حداقل دما			
فروردین	۲۲.۲	۱۵.۲	۸.۱	۳۸.۲	۳۸	۲۶۰.۵
اردیبهشت	۲۸.۹	۲۰.۹	۱۲.۹	۱۲.۲	۳۷	۳۰۲.۲
خرداد	۳۵.۲	۲۶.۲	۱۷.۲	۰.۲	۳۵	۳۶۲.۲
تیر	۳۸.۲	۲۹.۲	۲۰.۲	۰.۲	۳۲	۳۲۶.۲
مرداد	۳۷.۲	۲۹.۲	۲۰.۲	۱.۲	۳۶	۳۳۹.۱
شهریور	۳۵.۲	۲۶.۱	۱۶.۹	۰.۱	۳۸	۳۳۸.۹
مهر	۲۹.۸	۲۰.۸	۱۱.۷	۱.۶	۳۲	۳۲۶.۹
آبان	۲۲.۷	۱۳.۶	۶.۲	۱۹.۱	۳۲	۲۵۰.۸
آذر	۱۶.۲	۹.۲	۲.۲	۶۲.۱	۵۲	۲۱۳.۵
دی	۱۳.۶	۶.۶	۰.۶	۷۸.۱	۶۱	۲۰۹.۲
بهمن	۱۳.۵	۷.۲	۱.۱	۵۹.۸	۵۷	۲۲۲.۷
اسفند	۱۷.۸	۱۱.۱	۳.۲	۳۹.۶	۵۱	۲۲۲.۱

مدل شبیه‌ساز مصرف انرژی

(Calise, 2010). در سال ۲۰۱۶، هانگ^{۲۵} و همکاران با شبیه‌سازی مصرف انرژی مدارس و همچنین میزان تولید و جذب دی‌اکسید کربن، تأثیر اقتصادی و محیطی عملکرد مدارس ابتدایی و همچنین صرفه‌جویی در مصرف انرژی را ارزیابی نموده‌اند (Hong et al., 2012). مدل‌سازی‌های متعددی که در سال ۲۰۱۳ توسط لی^{۲۶} و همکاران به کمک DOE-2 انجام گرفت نشان داد که جذب حرارت تابشی از سمت غرب در ایالت هاینان چین بیشتر از جهات دیگر است و استفاده از سایبان می‌تواند تأثیر قابل توجهی در کاهش انرژی مصرفی داشته باشد (Li et al., 2013). متحدی و همکاران نیز در سال ۲۰۱۵، برای بررسی تأثیر شکل ساختمان بر کل انرژی مصرفی از قابلیت‌های مدل DOE-2 برای مدل‌سازی ساختمان‌های مختلف در دو منطقه آب و هوایی متفاوت در مونتانا و کالیفرنیا آمریکا بهره گرفته‌اند (Mottahedi et al., 2015). در سال ۲۰۱۶، حسینی و اخباری از DOE-2 برای شبیه‌سازی مصرف انرژی برای ساختمان‌های اداری واقع در شهرهای سرد شمال آمریکا نظیر تورنتو و مونترئال استفاده کردند و تأثیر وجود یک‌لایه برف روی بام را بر میزان مصرف انرژی ارزیابی نمودند (Hosseini & Akhbari., 2016). از آنجاکه در تمام تحقیقات فوق مدل DOE-2 به خوبی توانسته است مصرف انرژی ساختمان‌ها را شبیه‌سازی کند، در این تحقیق نیز در بخش شبیه‌سازی سناریوهای مختلف نورگیری از مدل توانمند DOE-2.2 استفاده شده است که نسخه توسعه‌یافته‌ای از DOE-2 است.

شبکه عصبی مصنوعی

شبکه عصبی مصنوعی از طرز کار شبکه عصبی واقعی اقتباس شده است. عصب که نقش انتقال اطلاعات و پیام‌ها را در بدن ایفا می‌کند اجتماعی از نرون‌ها است. ترون^{۲۷} یکی از سلول‌های عصبی است که مهم‌ترین جزء سازنده مغز به شمار می‌آید اصلی‌ترین و ساده‌ترین واحد ساختاری سیستم‌های عصبی است که می‌تواند به هزار تا ده‌هزار نرون دیگر اتصال یابد و با اتصال به یکدیگر شبکه‌ای عظیم ایجاد نمایند. شبکه عصبی مصنوعی نیز مبتنی بر نرون مصنوعی است. در شبکه عصبی مصنوعی نرون‌ها به فرم نشان داده‌شده در شکل ۲ نمایش داده می‌شوند. در این شکل، p سیگنالی ورودی است که با ضرب در پارامتر وزن، w تقویت و یا تضعیف شده و وارد نرون می‌شود. در هسته سلول سیگنال ضریب دار با سیگنال دیگری به اندازه b که بایاس^{۲۸} نامیده می‌شود، جمع می‌شود. در واقع سیگنال b سیگنال واحدی است که با ضرب در b تقویت یا تضعیف شده و انعطاف‌پذیری شبکه را افزایش می‌دهد. مجموع این دو سیگنال، $pw+b$ ، ورودی تابعی به نام f است که به تابع انتقال^{۲۹} مشهور است که خروجی آن $a=f(pw+b)$ است. مجموعه‌ای از این نرون‌ها تشکیل یک شبکه عصبی را می‌دهند که طی فرآیند یادگیری b و w های شبکه مقادری می‌شوند.

در تحقیق حاضر برای شبیه‌سازی مصرف انرژی کلاس استاندارد در بخش شبیه‌سازی از ساختار پیشنهادی، از مدل شبیه‌ساز DOE-2^{۱۰} استفاده شده است. این مدل که توسط آزمایشگاه لارنس برکلی^{۱۱} در سال ۱۹۸۳ با حمایت مالی دپارتمان انرژی آمریکا تولید شده است تاکنون توسط محققین متعدد نظیر بودارت^{۱۲} و دهرد^{۱۳} (Bodart & De Herde 2002)، لم^{۱۴} و همکاران (Loutzenhiser & Lam et al., 2006)، لوتزنهیزر^{۱۵} و ماکسول^{۱۶} (Maxwell, 2006) و ایم^{۱۷} و همکاران (Ihm et al., 2009) با موفقیت به کار گرفته شده است به گونه‌ای که به یکی از پرکاربردترین مدل‌های شبیه‌سازی مصرف انرژی تبدیل شده است. الربیعی^{۱۸} و همکاران با شبیه‌سازی ساختمان توسط نرم‌افزار DOE-2 در شرایط مختلف، میزان انرژی الکتریکی مصرفی برای سرمایه‌گذاری ساختمان‌ها را در اقلیم بسیار گرم و مرطوب (جده عربستان) اندازه‌گیری کردند و تأثیر مدل‌های مختلف طراحی را بر مصرف انرژی الکتریکی ارزیابی نمودند (Al-Rabghi et al., 1999). ژو^{۱۹} از مدل‌سازی عددی برای ارزیابی گزینه‌های مختلف بهره‌وری (صرفه‌جویی) مصرف انرژی در مورد یک نمونه موردی در ناحیه جنوب شرقی ایالات متحده استفاده نمود تا بتواند بهترین راهکار را به کاربران فضاهایی با عملکردهای مختلف و تعداد استفاده‌کنندگان مختلف و در شرایط مختلف ارائه نماید. در تحقیق وی از eQuest که مبتنی بر مدل DOE-2 است به عنوان نرم‌افزار شبیه‌ساز برای شبیه‌سازی مصرف گاز و برق یک محیط واقعی بهره گرفته شده است (Zhu, 2006). با بررسی ۱۲۰ مدرسه موجود در ایتالیا، کرنگاتی^{۲۰} و همکاران روشی را برای تخمین مصرف انرژی گرمایی در ساختمان‌های موجودی که ساخت آنها به اتمام رسیده است مطرح نمودند (Corgnati et al., 2008). در سال ۲۰۰۸ نقش استفاده از سیستم‌های الکتریکی کنترلی در استفاده از نور روز برای صرفه‌جویی در مصرف انرژی ساختمان‌ها توسط دولس^{۲۱} و همکاران بررسی گردید (Doulos et al. 2008). پرز^{۲۲} و کاپلوتو^{۲۳} هم در سال ۲۰۰۹ مقاله‌ای تحت عنوان بررسی معیارهای طراحی مدارس در اقلیم گرم و مرطوب برای کاهش مصرف انرژی ارائه نمودند که هدف آنها تدوین پیشنهادهایی برای طراحی مدارس در اقلیم گرم و مرطوب و بررسی تغییر مؤلفه‌های مختلف بر مصرف انرژی است (Perez & Capeluto, 2009). در آن تحقیق، تأثیر عواملی نظیر سایبان پنجره و نوع پوشش پنجره بر مصرف انرژی الکتریکی کلاس مینا در اقلیم گرم و مرطوب مورد بررسی قرار گرفته و نتیجه‌گیری شده است که می‌توان از طریق یک طراحی مناسب مصرف انرژی الکتریکی را تا پنجاه درصد کاهش داد. از نرم‌افزار DOE-2 برای مدل‌سازی مصرف انرژی خانه‌ها توسط ژو^{۱۹} و همکاران نیز با موفقیت استفاده شده است (Zhu et al., 2009). کالیس^{۲۴} نیز، در سال ۲۰۱۰، تأثیر سامانه‌های کمکی گرمایش و سرمایش خورشیدی را بر مصرف انرژی و هزینه‌های بهره‌برداری برای انواع مختلف مدارس ایتالیا بررسی نموده است

ساختار برای شبکه عصبی مصنوعی، از معیارهای ضریب همبستگی (CC)، میانگین مربعات خطا (MSE) و ریشه میانگین مربعات خطا (RMSE) استفاده می‌شود.

ریشه میانگین مربعات خطا (RMSE) معیاری برای مقایسه ابعاد خطا است که عبارت است از:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2}$$

رابطه ۱. فرمول محاسبه ریشه میانگین مربعات خطا

دیگر معیار مورد استفاده در ارزیابی پیش‌بینی‌ها معیار میانگین مربعات خطا (MSE) است که عبارت است از:

$$MSE = \frac{\sum_{i=1}^N (Y_i - \hat{Y}_i)^2}{N}$$

رابطه ۲. فرمول محاسبه میانگین مربعات خطا

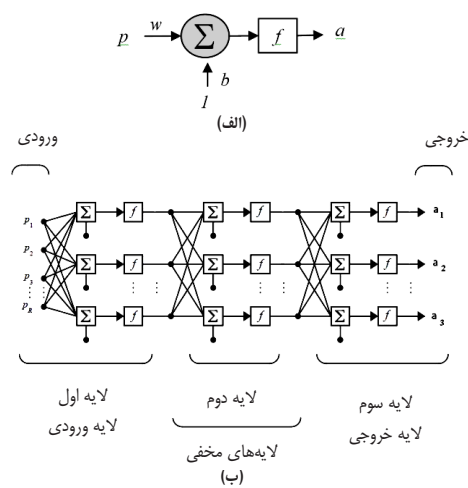
میانگین مربعات خطای نرمال شده (NMSE) از تقسیم MSE بر واریانس داده‌های واقعی حاصل می‌شود. ضریب همبستگی (CC) میزان انطباق داده‌های پیش‌بینی شده با داده‌های مشاهده شده را نشان می‌دهد که به فرم زیر تعریف می‌گردد. هرچه ضریب همبستگی به یک نزدیک‌تر باشد، همبستگی داده‌ها بیشتر و در نتیجه دقت مدل در پیش‌بینی‌ها بیشتر است.

$$CC = \frac{\sum_{i=1}^N (Y_i - \bar{Y})(\hat{Y}_i - \bar{\hat{Y}})}{\sqrt{\sum_{i=1}^N (Y_i - \bar{Y})^2 \sum_{i=1}^N (\hat{Y}_i - \bar{\hat{Y}})^2}}$$

رابطه ۳. فرمول محاسبه ضریب همبستگی

در روابط بالا $\bar{Y}_i, \bar{\hat{Y}}_i, \bar{Y}, \bar{\hat{Y}}$ به ترتیب خروجی مطلوب، خروجی تخمینی توسط مدل‌های مبتنی بر هوش مصنوعی، میانگین خروجی‌های مطلوب و میانگین خروجی تخمینی توسط شبکه می‌باشند. همچنین N تعداد مشاهدات آزمون است.

از معروف‌ترین و پرکاربردترین شبکه‌های عصبی، شبکه پرسپترون چندلایه^{۳۳} است که به MLP مشهور است. در این نوع از شبکه‌های عصبی مصنوعی هر نرون در لایه به تمامی نرون‌های لایه قبل متصل است.



شکل ۲. الف) ساختار یک تک نرون مصنوعی (ب) نمای از شبکه عصبی و لایه‌های تشکیل‌دهنده آن (Source: Demuth & Beale 2002)

اجتماع نرون‌ها در چند لایه امکان‌پذیر است و معمولاً به بازدهی بهتر سیستم می‌انجامد. در این حالت خروجی هر لایه بردار ورودی لایه بعدی را تشکیل می‌دهد. لایه‌ای که حاوی داده‌های ورودی شبکه است را لایه ورودی و لایه‌های حاوی داده‌های هدف را لایه خروجی می‌نامند. لایه‌های باقیمانده میانی به لایه‌های مخفی^{۳۴} مشهورند. با تغییر در تعداد لایه‌های مخفی می‌توان قابلیت‌های شبکه را ارتقا داد. انتخاب معماری مناسب شبکه عصبی مصنوعی در محاسبات مربوط به شبکه عصبی با روش سعی و خطا انجام می‌گیرد. برای انتخاب معماری مناسب شبکه عصبی مصنوعی لازم است ارقام مختلف لایه‌های پنهان و نرون‌های مربوط را آزمون تا بهترین شبکه حاصل گردد. لازم به ذکر است که، هر چه تعداد لایه‌ها و نرون‌ها افزایش یابد، عملکرد شبکه برای دوره آموزش بهتر می‌شود اما نتایج آزمون شبکه نشان از بهبود کارایی شبکه آموزش دیده ندارد و شبکه نمی‌تواند ارتباط خوبی بین ورودی‌ها و خروجی‌ها برقرار سازد در این حالت گفته می‌شود شبکه اصطلاحاً زیاد آموزش دیده^{۳۵} است. این مشکل بدین سبب بروز می‌کند که شبکه با داشتن تعداد زیادی لایه پنهان و نرون‌های مربوط، بیش از اندازه بر اساس داده‌های دوره آموزش واسنجی می‌گردد و قدرت انعطاف را برای دیگر الگوها از دست می‌دهد (Tsai and Lee, 1999).

از دیگر عوامل مؤثر در ارتقا، قابلیت‌های شبکه، تابع انتقال است. توابع انتقال خطی و غیرخطی متعددی توسط محققان مختلف ارائه شده است. ویژگی‌های خروجی مطلوب شبکه در انتخاب تابع انتقال مؤثر است. تابع انتقالی که عملکرد بهتری نسبت به سایر توابع نشان می‌دهد به‌عنوان بهترین تابع انتقال انتخاب می‌گردد. برای بررسی عملکرد مدل‌ها و نهایتاً انتخاب مناسب‌ترین

روملهارت^{۳۳} و همکاران در سال ۱۹۸۶ الگوریتم پس انتشار خطا^{۳۴} را برای آموزش این شبکه‌ها مطرح نمودند که انقلابی در شبکه‌های عصبی محسوب می‌شود (Rummelhart, 1986). در تحقیق حاضر، یک شبکه عصبی چندلایه با الگوریتم پس انتشار خطا به‌عنوان ابزاری به کار گرفته شده است که قادر است یک نگاشت غیرخطی بین ورودی‌ها و خروجی که میزان مصرف انرژی است برقرار سازد.

یافته‌های پژوهش

نتایج حاصل قابل تفکیک به دو بخش نتایج کاربرد مدل شبیه‌ساز مصرف انرژی کلاس استاندارد و کاربرد و بررسی عملکرد شبکه عصبی مصنوعی توسعه داده شده است که در ادامه به آنها پرداخته شده است.

نتایج کاربرد مدل شبیه‌ساز مصرف انرژی کلاس درس استاندارد

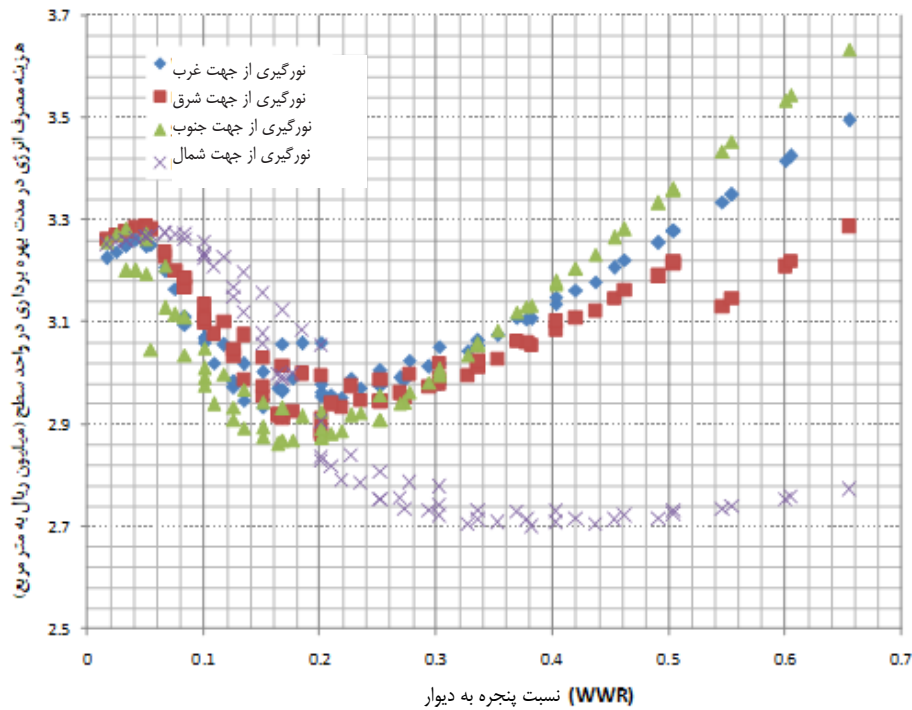
در شبیه‌سازی کلاس درس، پوشش داخلی و خارجی یکسانی برای کلاس در جبهه‌های غیر نورگیر، با توجه به مصالح مرسوم در ساخت، در نظر گرفته شده است که شامل اندود گچ و خاک به ضخامت ۲/۵ سانتیمتر روی آجرکاری با بلوک سفالی است که با گچ، سفیدکاری و پرداخت می‌شود. پوشش خارجی کلاس درس در وجهی که نورگیری انجام می‌شود متفاوت از سایر وجه‌ها و منطبق بر مصالح مرسوم مورد استفاده در نمای خارجی و با ضخامت معمول دیوار خارجی منظور شده است که علاوه بر آجرکاری با بلوک سفالی و ملات ماسه سیمان، اندود گچ و خاک و سفیدکاری پرداخت با گچ برای وجه داخلی، شامل نما چینی با آجر پلاک (دوغابی) با ملات ماسه سیمان است. در شرایط واقعی تقریباً همه کلاس‌ها در مجموعه مدرسه به‌گونه‌ای قرار می‌گیرند که درب آنها با هوای خارج در ارتباط نیست و این موضوع در شبیه‌سازی کلاس استاندارد در نظر گرفته شده است. پنجره‌ها فاقد سایبان و عناصر سایه‌انداز می‌باشند. سیستم کنترل نور کلاس کلید روشن و خاموش است که در صورت کمتر شدن میزان نور از مقدار پیشنهادی، (۵۰۰ لوکس) برای کلاس درس مدارس (دفتر تدوین مقررات ملی ساختمان، ۱۳۹۵)، روشن می‌گردد. در مدل‌سازی‌ها فرض به این است که این کلاس شش روز در هفته از ۸ صبح تا ۶ بعدازظهر فعال است. دمای تنظیم سرمایش کلاس ۲۷،۳ و دمای تنظیم گرمایش ۲۲/۲ درجه سانتی‌گراد تنظیم شده

است (ASHRAE 55, 2010). تعداد دفعات تعویض هوا در این کلاس ۳ بار در ساعت (ACH3) در نظر گرفته شده است (زمردیان و تحصیل دوست، ۱۳۹۴). همان‌گونه که اشاره شد، برای مدل‌سازی مصرف انرژی کلاس استاندارد مدل DOE-2.2 به کار گرفته شده است. این مدل برای مدل‌سازی یک کلاس استاندارد موجود در شهر شیراز توسط محقق قبلاً به کار گرفته شده است و صحت مدل‌سازی‌های آن در تخمین میزان مصرف انرژی الکتریکی و گازها خطایی در حدود ۷ درصد به اثبات رسیده است (Fallahnia et al., 2012).

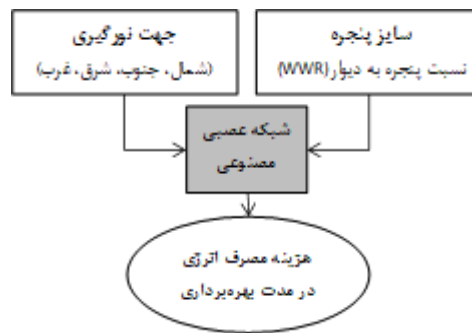
طی یک بررسی اولیه مشخص گردید که مؤلفه جهت نورگیری و ابعاد پنجره انتخابی برای کلاس استاندارد تأثیر قابل توجهی در میزان مصرف انرژی الکتریکی و گاز دارند. برای بررسی اثر اندازه پنجره کلاس، فاکتور بدون بعد نسبت پنجره، WWR، که معرف نسبت سطح پنجره کلاس به سطح دیوار است تعریف گردید. از طریق تغییر نسبت پنجره در بازه ۱/۷ تا ۶۵/۵ درصد، ۷۲ حالت نورگیری در هر جهت تولید و تک تک ۲۸۸ حالت نورگیری تولید شده توسط نرم‌افزار شبیه‌ساز مصرف انرژی مدل‌سازی شدند. مدل‌سازی‌های انجام گرفته برای یک دوره ۵۰ ساله (عمر مفید یک کلاس درس) انجام شد. در محاسبه هزینه گاز و برق از تعرفه‌های مصرف انرژی برق و گاز وزارت نیرو و نفت برای مدارس استفاده شده است. هزینه مصرف انرژی در مدت بهره‌برداری از مجموع هزینه مصرف گاز و انرژی الکتریکی در مدت بهره‌برداری حاصل گردید که در شکل ۳ نشان داده شده است.

ساختار شبکه عصبی مصنوعی توسعه داده شده و بررسی عملکرد آن

همان‌گونه که اشاره شد، برای کلاس استاندارد مورد بررسی (کلاسی به ابعاد ۷/۴ در ۷/۴) با تغییر جهت نورگیری و نسبت سطح پنجره به دیوار ۲۸۸ حالت مدل‌سازی تولید شد و در هر حالت میزان مصرف برق و گاز برای واحد سطح کلاس محاسبه و تحت عنوان هزینه مصرف انرژی تعیین گردید. نظر به اینکه اجرای مدل شبیه‌سازی مصرف انرژی برای مهندسان معماری طراح کلاس‌های درس زمان‌بر بوده و به آموزش‌های متعددی نیازمند است در جهت تسهیل در پیش‌بینی هزینه مصرف انرژی در مدت بهره‌برداری از کلاس از ابزار هوش مصنوعی استفاده شده است تا بدون نیاز به شبیه‌سازی مصرف انرژی، مهندس معمار بتواند با انتخاب ابعاد پنجره و جهت نورگیری، هزینه ساخت و بهره‌برداری متناظر با سناریوی انتخابی را پیش‌بینی نماید. از آنجاکه بر اساس حساسیت سنجی انجام گرفته در بخش مدل‌سازی عددی مشخص گردید که هزینه مصرف انرژی در مدت بهره‌برداری از کلاس به درصد پنجره و جهت نورگیری وابسته است، ساختار هوش مصنوعی توسعه داده شده منطبق بر ساختار نشان داده شده در شکل ۴ است. از نتایج ۲۸۸ حالت شبیه‌سازی انجام گرفته حدود ۲۱ درصد داده‌ها (۶۰ عدد) به‌طور تصادفی از مجموعه حالات شبیه‌سازی شده، حذف گردید و برای آزمون شبکه استفاده شده است. در انتخاب داده‌های آزمون، به‌گونه‌ای عمل شد که در هر جهت نورگیری به‌طور تصادفی ۱۵ عدد حذف شود. برای آموزش شبکه‌های مبتنی بر هوش مصنوعی از باقیمانده داده‌ها استفاده شد. عملکرد مدل‌های مختلف بر داده‌های آزمون با استفاده از معیارهای ضریب همبستگی، میانگین مربعات خطا، میانگین مربعات خطای نرمال شده و ریشه میانگین مربعات خطا، ارزیابی شده و نهایتاً بهترین مدل هوشمند توصیه شده است.



شکل ۳. هزینه مصرف انرژی در مدت بهره‌برداری از کلاس استاندارد واقع در شیراز



شکل ۴. ورودی‌ها و خروجی ساختار شبکه‌عصبی مصنوعی توسعه داده‌شده در این پژوهش

دسترس قرار گرفته است که بسته نرم‌افزاری شبکه عصبی موجود در زبان برنامه‌نویسی MATLAB معروف‌ترین و پرکاربردترین آنها است. بسته نرم‌افزاری موجود در MATLAB توسط محققان مختلف توسعه داده‌شده و برای آموزش شبکه عصبی از روش‌های متعددی بهره می‌گیرد. در جدول ۲

در پژوهش حاضر از نوعی از شبکه‌های عصبی مصنوعی مشهور به شبکه‌های چندلایه پرسپترون، استفاده شده است. در این نوع از شبکه‌های عصبی مصنوعی هر نرون در لایه به‌تمامی نرون‌های لایه قبل متصل است. با توجه به استفاده روزافزون از شبکه‌های عصبی مصنوعی نرم‌افزارهای متعددی در

فهرست توابع بکار رفته برای آموزش شبکه و در جدول ۳ فهرست توابع است. آموزش مورد استفاده برای تعیین مقادیر وزن و بایاس خلاصه شده‌اند.

همان گونه که در جداول ۲ و ۳ نشان داده شده است، الگوریتم‌های موجود برای آموزش تنوع زیادی دارند و بر اساس تحقیقات گذشته هیچ یک برای همه شرایط مناسب نیست. در این تحقیق از همه توابع مذکور که در جعبه ابزار برنامه MATLAB موجود است (۱۶۸=۱۲×۱۴ حالت آموزش) بهره گرفته شده است تا نتایج مربوط به الگوریتم آموزشی که کمترین خطا را در داده‌های آموزش در پی داشته برای تعداد لایه‌ها و نرون‌های مختلف مشخص گردد. برای تابع انتقال لایه‌های مخفی از تابع $tansig$ و برای لایه خروجی از تابع $Purelin$ استفاده شده است. که مشخصات آنها در شکل ۵ خلاصه شده است.

با ثابت نگه داشتن تعداد لایه‌ها و تغییر فاکتورهای تنظیم برنامه MLP برای هر تعداد لایه، ۱۰۰۸ حالت آموزش شبکه انجام گرفت و از بین این حالات، حالت متناظر با کمترین RMS که متناظر با بیشترین ضریب همبستگی نیز بود انتخاب گردید.

خصوصیات بهترین شبکه‌های آموزش دیده در تعداد لایه‌های مختلف، در جدول ۴ خلاصه شده است. همان گونه که در این جدول ملاحظه می‌گردد شبکه عصبی دو لایه با شش نرون که متناظر با کمترین خطا است، را می‌توان به عنوان بهترین جواب در نظر گرفت. نتایج مقادیر پیش‌بینی شده و واقعی (مبتنی بر مدل شبیه‌ساز انرژی) برای بهترین تعداد نرون در هر یک از حالات یک، دو و سه لایه نیز در نمودار شکل ۶ ارائه شده است.

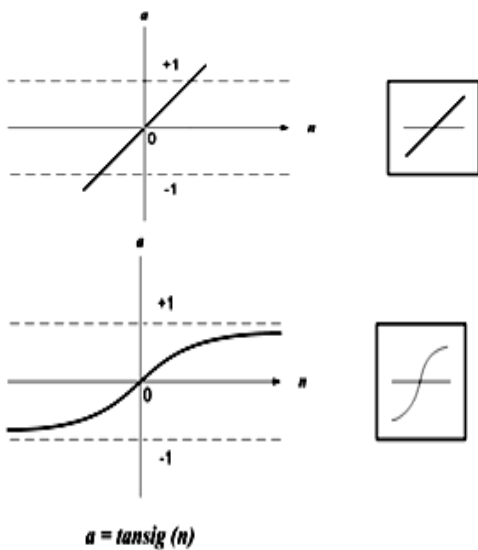
جدول ۲. توابع مورد استفاده در آموزش شبکه

نام تابع	هدف
trainda	Gradient descent with adaptive learning rate backpropagation
traindx	Gradient descent with momentum and adaptive learning rate backpropagation
trainlm	Levenberg-Marquardt backpropagation
traincg	Conjugate gradient backpropagation with Polak-Ribière updates
traincgf	Conjugate gradient backpropagation with Fletcher-Reeves updates
traincgb	Conjugate gradient backpropagation with Powell-Beale restarts
traincsg	Scaled conjugate gradient backpropagation
trainoss	One-step secant backpropagation
trainbfg	BFGS quasi-Newton backpropagation
trainrp	Resilient backpropagation
traincgp	Conjugate gradient backpropagation with Polak-Ribière updates
trainbr	Bayesian regulation backpropagation

در این روند، افزایش تعداد لایه‌ها به بیش از ۳ لایه منجر به بهبود نتایج نگردید از این رو بهترین شبکه آموزش متناظر است با دو لایه و شش نرون

جدول ۳. توابع مورد استفاده برای تعیین مقادیر وزن و بایاس

نام تابع	هدف
learnp	Perceptron weight and bias learning function
learnos	Outstar weight learning function
learnk	Kohonen weight learning function
learnis	Instar weight learning function
learnhd	Hebb with decay weight learning rule
learnh	Hebb weight learning rule
learnwh	Widrow-Hoff weight/bias learning function
learnpn	Normalized perceptron weight and bias learning function
learnh1	LVQ1 weight learning function
learnh2	LVQ2.1 weight learning function
learncon	Conscience bias learning function
learnsom	Self-organizing map weight learning function
learngd	Gradient descent weight and bias learning function
learnadm	Gradient descent with momentum weight and bias learning function



شکل ۵: مشخصات توابع انتقال مورد استفاده

نقاط آزمون شماره ۱ تا ۱۶ در شکل ۶ مربوط به پیش‌بینی شده با جهت نورگیری شمال، نقاط ۱۷ تا ۳۱ مربوط به جهت نورگیری جنوب، نقاط ۳۲ تا ۴۶ مربوط به جهت نورگیری شرق و مابقی (نقاط ۴۷ تا ۶۰) مربوط به جهت نورگیری از غرب است. همان گونه

تعدادی شبیه‌سازی است تا از نتایج شبیه‌سازی برای آموزش شبکه عصبی مصنوعی استفاده شود از آن پس شبکه آموزش دیده، جایگزین مدل شبیه‌ساز شده و بدون نیاز به اجرای

مدل شبیه‌ساز، مصرف انرژی قابل پیش‌بینی است.

به‌منظور ارزیابی عملکرد ساختار پیشنهادی، یک کلاس درس استاندارد برای ۲۸۸ سناریوی مختلف نورگیری برای تعیین میزان مصرف انرژی به کمک ۲۰۰۰-۲ مدل‌سازی گردید تا پایگاه داده لازم برای آموزش شبکه عصبی مصنوعی حاصل گردد. سپس عملکرد شبکه آموزش دیده مبتنی بر این مدل‌سازی‌ها توسط شاخص‌های آماری ارزیابی گردید. نتایج ارزیابی‌ها نشان می‌دهد که دامنه تغییرات میانگین مربعات خطا بسیار محدود بوده و تعداد نرون‌ها و لایه‌های مختلف در محدوده ۰/۰۰۶ تا ۰/۰۲۱ تغییر است.

دیگر شاخص آماری مورد توجه قرار گرفته، ریشه میانگین مربعات خطا است که دامنه محدود تغییرات آن (از ۰/۰۸۱۱ تا ۰/۱۴۵۵) نشان از دقت بالای شبکه عصبی مصنوعی در پیش‌بینی میزان مصرف انرژی دارد. این موضوع در خصوص شاخص ضریب همبستگی نتایج پیش‌بینی شده برای میزان مصرف انرژی در واحد سطح در مدت بهره‌برداری نیز صادق است که در تمامی حالت‌های مورد بررسی از تعداد نرون‌ها و لایه‌های مختلف، بیش از ۰/۸۹۷ حاصل گردیده است. در این میان، شبکه عصبی دولا به با شش نرون با میانگین مربعات خطا ۰/۰۶۶ و ریشه میانگین مربعات خطا ۰/۰۸۱۱ و ضریب همبستگی ۰/۹۶۷۲، بهترین نتایج را در این تحقیق در برداشته است که نشان می‌دهد با مشخص نمودن جهت نورگیری و نسبت سطح پنجره به سطح دیوار کلاس می‌توان به کمک ساختار آموزش دیده هزینه مصرف گاز و الکتریسیته را بدون نیاز به شبیه‌سازی مصرف انرژی در مدت بهره‌برداری، با دقت بسیار خوبی پیش‌بینی کرد.

سادگی روش پیشنهادی در این است که مهندس معمار قادر است تنها با مشخص نمودن نسبت سطح پنجره به سطح دیوار کلاس استاندارد و جهت نورگیری، هزینه مصرف انرژی گاز و الکتریسیته در یک بازه پنجاه‌ساله را با دقت بسیار خوبی پیش‌بینی نماید. ابزار جدید پیشنهادی این امکان را برای مهندس معمار مهیا می‌سازد که بتواند گزینه‌های مختلفی را که برای نورگیری یک کلاس مدنظر دارد، از نظر مصرف انرژی به‌سرعت مقایسه و بهترین گزینه را که متناظر است با کمترین هزینه مصرف انرژی انتخاب نماید. از آنجاکه نتایج تحقیق حاضر محدود به ابعاد کلاس استاندارد در اقلیم مشخصی است، مطالعات آتی می‌تواند به بررسی تأثیر اقلیم، ابعاد کلاس و دیگر مؤلفه‌های تعریف‌کننده فضای معماری بر میزان مصرف انرژی متمرکز گردد.

که ملاحظه می‌شود دقت پیش‌بینی‌ها در جهت غرب نسبت به سایر جهت‌ها کمتر است. و دقیق‌ترین پیش‌بینی‌ها متناظر است با نورگیری از جنوب.

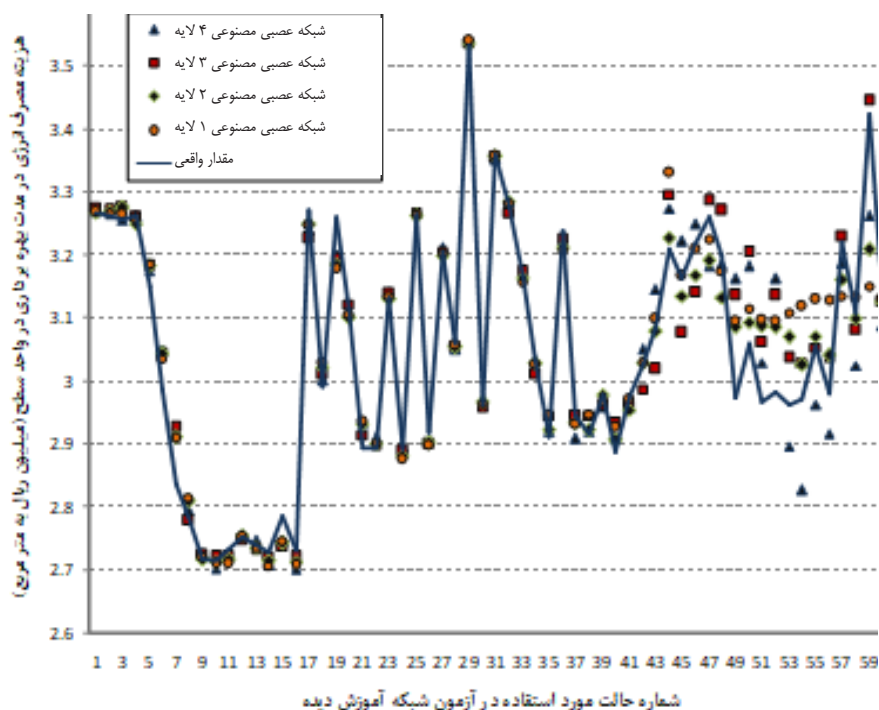
جدول ۴. خصوصیات بهترین شبکه آموزش دیده مبتنی بر شبکه عصبی مصنوعی در لایه‌های مختلف

تعداد لایه	تعداد نرون	مشخصات بهترین ساختار		CC	MSE	RMSE
		بهترین تابع تلفیق آموزش شبکه	بهترین تابع نکل رفته برای تعیین مقادیر وزن و بایاس			
۱	۲	trainlm	learncon	-۰.۹۰۹۷۵	-۰.۱۸۱۰	-۰.۱۳۲۵۲
	۵	trainbr	learnpn	-۰.۹۲۳۷۰	-۰.۱۳۵۰۶	-۰.۱۳۲۳۲
	۶	trainlm	learnqd	-۰.۹۲۵۲۶	-۰.۱۳۵	-۰.۱۳۶۰۸
۲	۲	trainbr	learnis	-۰.۹۶۶۹۸	-۰.۲۱۱۷	-۰.۱۳۵۲۹
	۵	trainlm	learnp	-۰.۹۱۶۲۲	-۰.۱۶۲۶۶	-۰.۱۳۷۹۱
	۶	trainlm	learnp	-۰.۹۲۷۱۶	-۰.۱۰۶۵۸	-۰.۱۸۱۱۰
۳	۲	trainbr	learnhd	-۰.۹۱۳۰۹	-۰.۱۸۸۰	-۰.۱۳۷۱۱
	۵	trainlm	learnhd	-۰.۹۲۷۲۲	-۰.۱۰۷۱۳	-۰.۱۸۲۷۷
	۶	trainlm	learnqdm	-۰.۹۲۲۲۹	-۰.۱۱۲۲۹	-۰.۱۱۱۲۲
۴	۲	traincgp	learnpn	-۰.۹۳۲۵۰	-۰.۱۱۲۵	-۰.۱۳۷۳۶
	۵	traincgp	learnh	-۰.۹۲۷۲۸	-۰.۱۳۱۵	-۰.۱۳۲۶۷
	۶	trainlm	learnp	-۰.۹۵۲۰۱	-۰.۱۰۹۳۹	-۰.۱۶۶۰۰

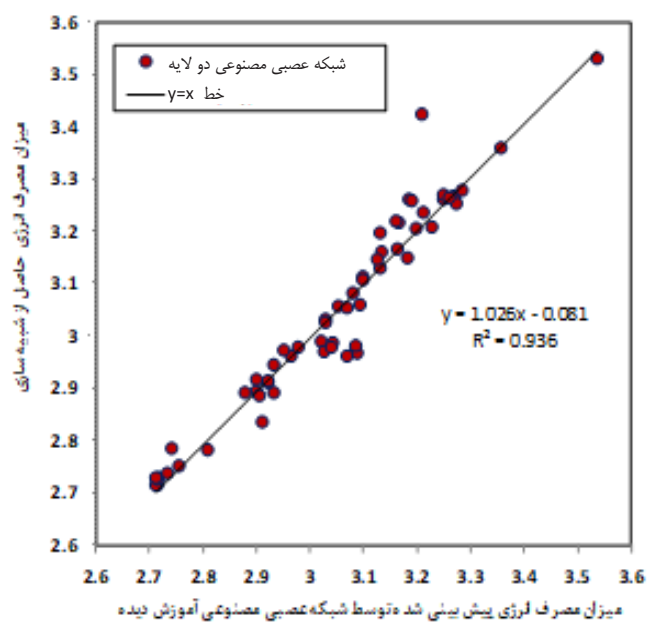
به‌منظور ارزیابی عملکرد بهترین شبکه عصبی آموزش دیده، در شکل ۷ نمودار پراکندگی مقادیر هزینه مصرف انرژی در مدت بهره‌برداری در واحد سطح که از کاربرد شبکه عصبی مصنوعی آموزش دیده حاصل گردیده است در مقابل مقادیر مشاهده‌ای مبتنی بر مدل شبیه‌سازی مصرف انرژی برای داده‌های آزمون ترسیم شده است. نمودار نشان داده‌شده در شکل ۷ نشان می‌دهد که شبکه عصبی آموزش دیده کارکرد خوبی داشته و در حقیقت شبکه توانسته است پیش‌بینی صحیحی انجام دهد.

نتیجه‌گیری

در تحقیق حاضر روشی جدید بر پایه شبکه عصبی مصنوعی برای پیش‌بینی مصرف انرژی کلاس استاندارد معرفی گردیده است. در این روش به کمک داده‌های ورودی و خروجی حاصل از شبیه‌سازی مصرف انرژی کلاس استاندارد، قانون نهفته در فیزیک مسئله و ارتباط بین ورودی‌ها و خروجی‌ها تشخیص داده می‌شود. از مزایای این روش می‌توان به‌سرعت بالا و دقت مناسب بدون نیاز به شبیه‌سازی اشاره کرد. در گام نخست، این روش نیازمند



شکل ۶. نمودار مقایسه‌ای نتیجه صحت‌سنجی بهترین شبکه‌های عصبی حاصله برای تعداد لایه‌های مختلف



شکل ۷. نمودار مقایسه‌ای نتیجه صحت‌سنجی بهترین شبکه عصبی مصنوعی آموزش‌دیده در پیش‌بینی هزینه مصرف انرژی در مدت بهره‌برداری در واحد سطح (میلیون ریال به مترمربع)

پی‌نوشت‌ها

فهرست مراجع

۱. سازمان نوسازی، توسعه و تجهیز مدارس کشور. (۱۳۸۶). ضوابط و معیارهای طراحی فضاهاى آموزشی. (ویرایش ۳). تهران: دفتر فنى سازمان نوسازی، توسعه و تجهیز مدارس کشور.
۲. عصر ایران. (۱۳۸۹). دقیق‌ترین آمار دانش‌آموزی و نیروی انسانی تاریخ آموزش و پرورش. کد خبر: ۱۵۶۳۹۱. بازیابی ۲۵ بهمن ۱۳۸۹، از www.asriran.com/fa/news/156391
۳. اداره کل هواشناسی استان فارس. (۱۳۹۶). میانگین‌های اقلیمی ایستگاه هواشناسی سینوپتیک شیراز، دوره آماری (۹۰-۱۳۵۰). www.farsmet.ir/amar/syngraph/shiraz.pdf
۴. دفتر تدوین مقررات ملی ساختمان. (۱۳۹۵). طرح و اجرای تأسیسات برقی ساختمان‌ها-مبحث سیزدهم مقررات ملی ساختمان ایران. تهران: مرکز تحقیقات راه، مسکن و شهرسازی.
۵. کریم پور، علیرضا؛ دیبا، دارب؛ و اعتمام، ایرج. (۱۳۹۶). تحلیل تأثیر آفتاب‌گیرهای داخلی بر مصرف انرژی با استفاده از مدل‌های شبیه‌سازی (مطالعه موردی: واحد مسکونی در تهران). هویت شهر، ۱۱ (۳۰)، ۱۷-۳۰.
۶. زارع، فائزه؛ و حیدری، شاهین. (۱۳۹۴). طراحی معماری با بهره‌گیری از روشنایی طبیعی رویکردی در طراحی کتابخانه برای شهر تهران. هویت شهر، ۹ (۲۴)، ۵۵-۶۴.
۷. زمردیان، زهرا سادات؛ تحصیل دوست، محمد. (۱۳۹۴). اعتبارسنجی نرم‌افزارهای شبیه‌سازی انرژی در ساختمان: با رویکرد تجربی و مقایسه‌ای. نشریه انرژی ایران، ۱۸ (۴)، ۱۱۵-۱۳۲.
8. Al-Rabghi, O. M., Al-Beiruty, M.H., &Fathalah, K. A. (1999). Estimation and measurement of electric energy consumption due to air conditioning cooling load. *Energy Conversion & Management*, 40, 1527-1542.
9. Argiriou, A.A., Bellas-Velidis, I.,&Balaras, C.A. (2000). *Development of a neural network heating controller for solar buildings*. *Neural Networks*, 13, 811-820.
10. ASHRAE 55 (2010). *ANSI/ASHRAE Standard 55-2010, ASHRAE Environmental Conditions for Human Occupancy*, Atlanta, Ga, USA: American Society of Heating, Refrigeration and Air Conditioning Engineers, Inc.
11. Bodart, M., De Herde, A. (2002). Global energy savings in offices buildings by use of daylighting. *Energy Build*, 34, 421-429.
1. Kasperkiewicz
2. Argiriou
3. Ballal
4. Sher
5. Moon
6. Dombayci
7. Kumar
8. Jovanovic
9. Deb
10. DOE2 – Department of Energy Version 2
11. Lawrence Berkeley Laboratory
12. Bodart
13. De Herde
14. Lam
15. Loutzenhiser
16. Maxwell
17. Ihm
18. Al-Rabghi
19. Zhu
20. Corgnati
21. Doulos
22. Perez
23. Capeluto
24. Calise
25. Hong
26. Li
27. Neuron
28. Bias
29. Transfer function
30. Hidden Layers
31. Over Learning
32. Multi Layer Perceptron
33. Rummelhart
34. Back Propagation Error

12. Calise, F. (2010). Thermo economic analysis and optimization of high efficiency solar heating and cooling systems for different Italian school buildings and climates. *Energy and Buildings*, 42 (7), 992-1003.
13. Corgnati, S. P., Corrado, V., &Filippi, M. (2008). A method for heating consumption assessment in existing buildings: A field survey concerning 120 Italian schools. *Energy and Buildings*, 40, 801–809.
14. Deb, C., Eang, L. S., Yang, J., &Santamouris, M. (2016). Forecasting diurnal cooling energy load for institutional buildings using Artificial Neural Networks. *Energy and Buildings*, 121, 284-297.
15. Demuth, H., & Beale, M. (2002). *Neural Network Toolbox User's Guide*. Math Works Inc., Natick, MA, U.S.A.
16. Dombaycı, Ö. A. (2010). The prediction of heating energy consumption in a model house by using artificial neural networks in Denizli–Turkey. *Advances in Engineering Software*, 41(2), 141-147.
17. Doulos, L., Tsangrassoulis, A., &Topalis, F. (2008). Quantifying energy savings in daylight responsive systems: The role of dimming electronic ballasts. *Energy and Buildings*, 40, 36–50.
18. Fallahnia, M., Kerachian, R., Etessam, I., &Majedi, H. (2012). The impact of window characteristics on gas and electric costs in educational buildings: Application of Support Vector Machines. *Iranian Journal of Science and Technology. Transactions of Mechanical Engineering*, 36 (M2), 193-205.
19. Hong, T., Kim, J.M., &Koo, C.W. (2012). LCC and LCCO2 analysis of green roofs in elementary schools with energy saving measures. *Energy and Buildings*, 45, 229–239.
20. Hosseini, M., &Akbari, H. (2016). Effect of cool roofs on commercial buildings energy use in cold climates. *Energy and Buildings*, 114, 143-155.
21. Ihm, P., Nemri, A., &Krarti, M. (2009). Estimation of lighting energy savings from daylighting. *Building and Environment*, 44, 509– 514.
22. Jovanović, R., Aleksandra, Ž., Sretenović, A., &Živković, B. D. (2015). Ensemble of various neural networks for prediction of heating energy consumption. *Energy and Buildings*, 94, 189-199.
23. Kasperkiewics, J., Racz J., &Dubrawski A. (1995). HPC strength prediction using ANN. *ASCE. Journal of Comp. Civil Eng*, 4, 279–284
24. Kumar, R., Aggarwal, R. K., &Sharma, J. D. (2013). Energy analysis of a building using artificial neural network: A review. *Energy and Buildings*, 65, 352-358.
25. Lam, J. C., Tsang, C. L., &Yang, L. (2006). Impacts of lighting density on heating and cooling loads in different climates in China. *Energy Conversion and Management*, 47, 1942–1953.
26. Li, X. P., Yin, B., Yang, C. X., &Zhou, H. Z. (2013). Application Potential of Solar-Shading in Tropical Island Cities. *Applied Mechanics and Materials*, 361, 312-317.
27. Loutzenhiser, P.G., &Maxwell, G.M. (2006). A comparison of DOE-2-2.1E daylighting and HVAC system interactions to actual building performance. *ASHRAE Transactions*, 112(2), 409-417.
28. Moon, J., W., Jung, S.K., Kim, & J.J. (2009). Application of ANN (Artificial Neural Network) in residential thermal control. *IBPSA. Proceeding of Eleventh International IBPSA Conference*. July 27-30, (pp.64-71). Glasgow, Scotland.
29. Mottahedi, M., Mohammadpour, A., Amiri, S. S., Riley, D., &Asadi, S. (2015). Multi-linear regression models to predict the annual energy consumption of an office building with different shapes. *Procedia Engineering*, 118, 622-629.
30. Perez, Y., V., &Capeluto, I., G. (2009). Climatic considerations in school building design in the hot–humid climate for reducing energy consumption. *Applied Energy*, 86, 340–348.
31. Rumelhart, D.E., Hinton, G.E. and Williams, R.J., 1986. Learning representations by back-propagating errors. *nature*, 323(6088), p.533.

32. Rumelhart, David E., Hinton, Geoffrey E., Williams, Ronald J. (1986). *Learning representations by back-propagating errors*. *Nature*, 323(6088), 533–536.
33. Singh, I., & Michaelowa, A. (2004). *HWVA Discussion Paper 289*, Hamburg Institute of International Economics, Hamburg, Germany.
34. Ballal, T.M., & Sher, W.D. (2003). Artificial neural network for the selection of buildable structural systems. *Engineering, Construction and Architectural Management*, 10 (4), 263-271.
35. Tsai, C.P., & Lee, T.L. (1999). Back-Propagation neural network in tidal level forecasting, *ASCE, Journal of Waterway, Port, Coastal and Ocean Engineering*, 125, 195-202.
36. Zhu, Y. (2006). Applying computer-based simulation to energy auditing: A case study. *Energy and Buildings*, 38, 421–428.
37. Zhu, L., Hurt, R., Correa, D., & Boehm, R. (2009). Comprehensive energy and economic analyses on a zero energy house versus a conventional house, *Energy*, 34, 1043–1053.

Estimating Energy Consumption of Educational Spaces Using Artificial Neural Networks (ANNs)

*Mahsa Fallahnia**, Ph.D., Assistant Professor, Faculty of Architecture and Urbanism, University of Art, Tehran, Iran.

Abstract

Size of classroom's windows has significant effects on both comfort level of users and electricity consumption for lighting. Moreover, windows are the main source of energy loss in classrooms in both cooling and heating sectors. Considering the large number of educational buildings and long life cycle of such them, choosing proper window size is crucial for energy saving in sustainable architectural design. Despite the role that windows have in energy consumption, the literatures are surprisingly limited in providing detailed recommendations for architects in determining the appropriate window size in different climates. Therefore, energy based window design has always been complicated for architects due to the number of involved different components and variables. In order to help the architectural designers, in this paper a new methodology is developed using a well-known artificial intelligence technique. In the proposed methodology, a predictive model for energy consumption cost in terms of window to wall ratio (WWR) and the window facing was created using Artificial Neural Network (ANN). The methodology consisted of a limited sets of direct numerical energy simulations for any specific climatic zone to generate the data required for training the ANN. The DOE-2 is suggested in the proposed methodology for direct numerical energy simulations of the daylighting scenarios required for training the ANN. The DOE-2 is a popular and powerful computational model developed with financial support of U.S. department of energy. The trained ANN-based model provides a fast and convenient way of comparing the different daylighting scenarios in designing stage. Indeed, further calculations for direct energy simulations are not necessary and an architect can readily utilize the trained ANN-based model as a powerful tool for forecasting the total energy consumption cost. In order to show the applicability and performance of the proposed approach, 288 daylighting scenarios for a standard classroom in a warm and dry climate, Shiraz-Iran, were simulated to determine the corresponding electric and gas consumption. A square classroom of side 7.4 m is the standard classroom defined by Iranian Organization for Renovating, Developing and Equipping Schools. The DOE-2 is utilized for simulating the defined standard classroom in the study area for estimating the annual gas and electric consumption of the generated scenarios over a 50 years period. Included daylighting scenarios were randomly split into train and test sets. In this study, around 80 percent of data were used for training, and the rest were used to evaluate the performance of the trained ANN. The best training and learning functions for different number of layers and neurons was determined in a trial-error process. Correlation Coefficient (CC), Mean square error (MSE) and Root mean square error (RMSE) are the statistical indices used for training procedure. The best results were obtained with 2 hidden layers and 6 neurons per layer. The 'Levenverg-Marquardt back propagation (trainlm)' and 'perceptron weight and bias learning function (learnp)' were the best training functions found for this research. The results show that the trained ANN can accurately predict the total energy consumption cost (RMSE=0.0811, MSE=0.0066, and CC=0.9672).

Keywords: Classroom Window, Energy Consumption, DOE-2, Artificial Intelligence, Artificial Neural Network.

* Corresponding Author: Email: fallahnia@art.ac.ir