

## تخمین بار الکتریکی ساختمان با استفاده از شبکه‌های عصبی

محمد مهدی موحدزاده<sup>۱</sup>، محمد رحمتی<sup>۲</sup>، محمد علی موحدزاده<sup>۳</sup>

<sup>۱</sup> گروه مهندسی برق و کامپیوتر، واحد زاهدشهر، دانشگاه آزاد اسلامی، زاهد شهر، ایران

<sup>۲</sup> گروه مهندسی برق و کامپیوتر، واحد زاهدشهر، دانشگاه آزاد اسلامی، زاهد شهر، ایران

<sup>۳</sup> گروه مهندسی معماری، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران

### چکیده

در دنیای مدرن امروزه، افزایش چشمگیر و روزافزون جمعیت و توسعه‌ی شهرها منجر به مصرف بی‌رویه انرژی شده است که بیشتر از هر زمان دیگر در سال‌های اخیر شاهد آن هستیم. از این رو مدیریت و بهینه‌سازی مصرف انرژی یکی از مهم‌ترین اهداف هر جامعه‌ای در سطح جهان می‌باشد؛ و با توجه به اینکه بیشترین مصرف انرژی مربوط به ساختمان‌ها می‌باشد، باید گفت کنترل انرژی در ساختمان‌ها می‌تواند یکی از مهم‌ترین اهداف هر جامعه باشد؛ که البته این موضوع در کشوری مانند ایران از اهمیت بیشتری برخوردار است. مصرف بهینه و صحیح انرژی نه تنها به حفظ منابع طبیعی کمک می‌کند، بلکه به کاهش هزینه‌های اقتصادی و همچنین کاهش انتشار گازهای گلخانه‌ای منجر می‌شود. در این راستا، بهینه‌سازی مصرف انرژی در ساختمان‌ها یکی از حوزه‌های مهم تحقیقاتی به شمار می‌رود. پیش‌بینی مصرف انرژی نیازمند در نظر گرفتن پارامترهای بسیاری است. در این پژوهش به بهینه‌سازی مصرف انرژی در ساختمان‌ها با استفاده از شبکه‌های عصبی و یادگیری عمیق می‌پردازیم.

**واژه‌های کلیدی:** شبکه‌های عصبی عمیق، یادگیری عمیق، بهینه‌سازی مصرف انرژی، مدیریت مصرف انرژی ساختمان

## ۱- مقدمه

مصرف انرژی در ساختمان‌ها یکی از بزرگ‌ترین چالش‌های جهان مدرن است که تأثیرات محیطی و اقتصادی قابل توجهی دارد. در کشورهای صنعتی و حتی در حال توسعه، ساختمان‌ها سهم قابل توجهی از کل انرژی مصرفی را به خود اختصاص می‌دهند. این مسئله در شرایطی که تقاضای انرژی به طور مداوم در حال افزایش است، بحرانی‌تر می‌شود. علاوه بر این، استفاده ناکارآمد از منابع انرژی در ساختمان‌ها منجر به انتشار مقادیر زیادی از گازهای گلخانه‌ای می‌شود که یکی از عوامل اصلی تغییرات اقلیمی به شمار می‌رود. (Biswas.MR, Robinson.MD, Fumo.N, 2016).

بر اساس آمارها، ساختمان‌ها به تنهایی بیش از ۴۰ درصد از کل انرژی مصرفی جهان را به خود اختصاص می‌دهند. این مسئله در کشورهای توسعه‌یافته و در حال توسعه، به دلیل رشد شهرنشینی و افزایش تقاضای انرژی، به مراتب بحرانی‌تر است. مصرف انرژی با افزایش هزینه‌های انرژی و نگرانی‌های زیست‌محیطی، بهینه‌سازی مصرف انرژی در ساختمان‌ها اهمیت بیشتری یافته است. از این رو، بهینه‌سازی مصرف انرژی در ساختمان‌ها به یک اولویت جهانی تبدیل شده است و استفاده از فناوری‌های نوین، به ویژه شبکه‌های عصبی مصنوعی و مدل‌های یادگیری عمیق، به عنوان یک راهکار مؤثر برای پیش‌بینی و مدیریت مصرف انرژی مطرح شده است. (Aydinalp M, Ugursal VI, Fung A, 2002).

## ۲- ادبیات تحقیق

مدل پیشنهادی تحقیق شامل بخش‌های انگیزش و نوآوری، پیشینه تحقیق، مبانی پژوهش و روش پژوهش می‌باشد که به خلاصه‌ای در مورد پیشینه و کاربردهای اصلی هریک از مطالب را بیان خواهیم کرد.

## ۲-۱- انگیزش و نوآوری

در دهه‌های اخیر، توجه به بهینه‌سازی مصرف انرژی در ساختمان‌ها به عنوان یکی از راهکارهای کلیدی برای کاهش مصرف انرژی و مقابله با تغییرات اقلیمی مورد توجه قرار گرفته است. بهینه‌سازی مصرف انرژی نه تنها به کاهش هزینه‌های انرژی کمک می‌کند، بلکه تأثیرات مثبت زیادی بر محیط زیست دارد. به همین دلیل، پژوهش‌های بسیاری در این زمینه انجام شده که از روش‌های مختلفی برای پیش‌بینی و بهینه‌سازی مصرف انرژی استفاده کرده‌اند.

یکی از رویکردهای نوین در این زمینه استفاده از فناوری‌های هوش مصنوعی و یادگیری عمیق است. مدل‌های یادگیری عمیق به دلیل توانایی بالایی خود در پردازش داده‌های بزرگ و پیچیده، ابزارهای قدرتمندی برای پیش‌بینی مصرف انرژی و بهینه‌سازی آن فراهم کرده‌اند. این مدل‌ها می‌توانند الگوهای پیچیده‌ای را که در داده‌های مصرف انرژی وجود دارد شناسایی کرده و با دقت بالایی پیش‌بینی‌های قابل اعتمادی ارائه دهند.

تکنیک‌های هوشمند مبتنی بر یادگیری عمیق، مانند شبکه‌های عصبی مصنوعی، توانسته‌اند به عنوان راهکاری نوین و کارآمد در پیش‌بینی و مدیریت مصرف انرژی مطرح شوند.

هدف این مقاله بررسی کارایی این مدل‌ها و ترکیب آن‌ها در پیش‌بینی و بهینه‌سازی مصرف انرژی در ساختمان‌ها است. در این مقاله، ما به بررسی استفاده از دومدل یادگیری عمیق، یعنی شبکه‌های عصبی کانولوشنی (CNN)<sup>۱</sup> و شبکه‌های عصبی حافظه طولانی-کوتاه مدت (LSTM)<sup>۲</sup> برای پیش‌بینی و بهینه‌سازی مصرف انرژی در ساختمان‌ها می‌پردازیم. این مطالعه به دنبال ارائه یک راهکار کارآمد برای کاهش مصرف انرژی و بهینه‌سازی عملکرد انرژی ساختمان‌هاست. هدف اصلی این مقاله بررسی کارایی شبکه‌های عصبی مصنوعی در پیش‌بینی مصرف انرژی و ارائه مدلی برای بهینه‌سازی مصرف در ساختمان‌ها است.

<sup>۱</sup> Convolutional neural network

<sup>۲</sup> Long Short Term Memory

## ۲-۲- پیشینه تحقیق

پیش‌بینی انرژی مصرف شده در ساختمان‌ها دارای اهمیت زیادی است و مصرف انرژی یکی از حوزه‌های تحقیقاتی پررونق در دهه‌های اخیر بوده است. محققان بسیاری به پیش‌بینی مصرف انرژی ساختمان با روش‌های مختلف پرداخته‌اند. این روش‌ها شامل روش‌های مهندسی، روش‌های آماری، روش‌های هوش مصنوعی و روش‌های ترکیبی است. روش‌های مهندسی از اصول فیزیکی برای محاسبات دینامیک حرارت و رفتار انرژی در ساختمان استفاده می‌کنند. این روش‌ها طی پنجاه سال گذشته به طور کامل توسعه پیدا کرده‌اند. (آبادی، ۱۳۹۶)

روش‌های مهندسی در دو دسته روش‌های دقیق جامع و روش‌های ساده شده طبقه‌بندی می‌شوند. روش‌های جامع شامل محاسبات دقیق و گام به گام دینامیک حرارت است. در زمینه ارزیابی انرژی ساختمان، انرژی‌های تجدیدپذیر و پایداری انرژی نرم افزارهایی مانند R-ESP-2, DOE, Plus Energy و BLAST توسعه پیدا کرده‌اند. اگرچه این ابزارهای شبیه‌سازی دقیق و موثر هستند اما دارای مشکلاتی نیز می‌باشند. این ابزارها برای شبیه‌سازی دقیق نیاز به دستیابی به جزئیات پارامترهای ساختمان و محیط زیست به عنوان داده ورودی دارند. دستیابی به این پارامترها برای بسیاری از سازمان‌ها امکان‌پذیر نیست برای مثال دست‌یابی به اطلاعات هر اتاق در یک ساختمان بزرگ بسیار دشوار است. نیاز به اطلاعات دقیق به عنوان ورودی به روند بسیار کند در این روش منجر می‌شود. از سوی دیگر استفاده از این نرم‌افزارها نیاز به کار فراوان یک فرد متخصص دارد. (Zhao.HX, 2012)

به همین علت محققان مدل‌های ساده‌تری را پیشنهاد کردند، اما بین این مدل‌های ساده و پیچیده مرز مشخصی وجود ندارد. اگرچه روش‌های ساده شده می‌تواند کافی باشد اما برای شبیه‌سازی‌های دقیق روش‌های جامع موثرتر خواهند بود. در ابتدا، روش‌های سنتی آماری مانند رگرسیون خطی برای پیش‌بینی مصرف انرژی استفاده می‌شدند. این روش‌ها به دلیل سادگی و قابلیت تفسیر، همچنان در بسیاری از کاربردها مورد استفاده قرار می‌گیرند؛ اما با افزایش پیچیدگی داده‌های مصرف انرژی و ورود فناوری‌های جدید، نیاز به روش‌های پیشرفته‌تر احساس شد. (تشنه لب، جعفری، ۱۳۹۴)

یکی از مشکلات اصلی روش‌های سنتی این است که این مدل‌ها قادر به شناسایی الگوهای پیچیده و غیرخطی در داده‌های مصرف انرژی نیستند. این موضوع منجر به پیش‌بینی‌های نادرست و ناکارآمد می‌شود، به خصوص زمانی که داده‌ها دارای وابستگی‌های زمانی و مکانی باشند. (ناصر کرد، فرشید کی‌نیا، ۱۳۹۹)

در مقابل، مدل‌های هوش مصنوعی به دلیل توانایی بالای خود در مدل‌سازی روابط پیچیده و غیرخطی، به عنوان جایگزین‌های مناسبی برای روش‌های سنتی مطرح شده‌اند. شبکه‌های عصبی مصنوعی (ANNs) و ماشین‌های بردار پشتیبان (SVMs) از جمله اولین روش‌های هوش مصنوعی بودند که در پیش‌بینی مصرف انرژی مورد استفاده قرار گرفتند. (حسینی، ۱۳۸۸) این مدل‌ها با استفاده از ویژگی‌های خاص داده‌ها، توانستند دقت پیش‌بینی‌ها را افزایش دهند.

## ۲-۳- مبانی پژوهش

در این بخش به مفاهیمی از جمله شبکه‌های عصبی پیچشی، شبکه‌های عصبی مکرر و شبکه‌های عصبی حافظه طولانی کوتاه-مدت پرداخته می‌شود که در نهایت، به چالش‌ها و فرصت‌های پیش‌رو که در بهینه‌سازی مصرف انرژی با استفاده از این تکنیک‌ها می‌تواند به ما کمک کند، پرداخته خواهد شد.

## ۲-۳-۱- شبکه‌های عصبی

معماری شبکه عصبی شامل تعداد لایه‌ها، تعداد نرون موجود در هر لایه و نوع تابع فعال‌ساز هر لایه می‌باشد. معماری شبکه عصبی تاثیر مهمی بر عملکرد آن دارد. تاکنون هیچ روش کلی برای طراحی ساختار بهینه‌ی شبکه عصبی ارائه نشده است. یافتن ساختار بهینه شبکه عصبی را می‌توان یکی از مشکلات استفاده از آن عنوان کرد. معمولاً در شبکه‌های عصبی جهت تخمین زدن از تابع انتقال خطی برای تابع فعال‌ساز لایه خروجی و از توابع سیگموئید و یا تانژانت سیگموئید برای توابع فعال‌ساز

لایه های پنهان استفاده می شود. به طور کل در روشهای سنتی انتخاب توابع فعالساز، تعیین تعداد لایه ها و تعداد نرون در هر لایه با روش سعی و خطا تعیین می شود. (حدادمهریزی، ابزرگ زاده، ۱۳۸۷)

## ۲-۳-۲- الگوی شبکه های عصبی مصنوعی

شبکه های عصبی مصنوعی، چارچوب محاسباتی انعطاف پذیر برای مدل سازی دامنه وسیعی از مسائل غیرخطی هستند (Khashei, Mehdi and Bijari, Mehdi, 2011) از بین انواع شبکه های عصبی، شبکه عصبی پیشخور<sup>۳</sup> با یک لایه مخفی، یکی از رایج ترین مدل ها برای مدل سازی و پیش بینی سری های زمانی محسوب می شود. این شبکه عصبی از سه لایه شامل یک لایه ورودی جهت اعمال ورودی های مساله، چند لایه مخفی یا پنهان<sup>۴</sup> (حداقل یک لایه) و یک لایه خروجی که نهایتاً پاسخ مسئله را ارائه می نمایند، تشکیل شده است. (Wang, Xiping and Meng, Ming, 2012)

## ۲-۳-۳- یادگیری عمیق

یادگیری عمیق<sup>۵</sup> (DL) شاخه ی جدیدی از علم یادگیری ماشین و شبکه های عصبی مصنوعی است که دارای مفهوم درک و فهم چند لایه ای و ساختار یادگیری سلسه مراتبی است (Wang, J. Zhang, 2015) این نوع یادگیری مبتنی بر آموزش سطوح مختلف نمایش یک عارضه است و یک راه حل کارا تر و موثرتر از روش های قدیمی ارائه می دهد. در حال حاضر، یادگیری عمیق در کاربردهای مختلفی نظیر شناسایی عوارض، طبقه بندی تصاویر، برچسب گذاری معنایی، تشخیص صدا و پردازش زبان طبیعی<sup>۶</sup> مورد استفاده قرار میگیرد. (Bengio, 2009)

## ۲-۳-۴- معماری شبکه CNN

شبکه عصبی کانولوشنی (CNN) به عنوان یک ابزار قدرتمند در تحلیل داده های تصویری و سری های زمانی شناخته شده است. معماری CNN مورد استفاده در این تحقیق شامل چندین لایه کانولوشنی و نمونه برداری<sup>۷</sup> است که به استخراج ویژگی های پیچیده از داده ها کمک می کند. (Dong.B, Cao.C, Lee.SE, 2005) لایه های کانولوشنی: این لایه ها به شناسایی الگوهای محلی در داده ها می پردازند و ویژگی های مختلفی از جمله لبه ها، گوشه ها و بافت های مختلف را استخراج می کنند. (Zhao.HX, 2012) لایه های نمونه برداری: این لایه ها برای کاهش ابعاد داده ها و افزایش کارایی مدل استفاده می شوند. آن ها به مدل اجازه می دهند تا ویژگی های مهم را بدون از دست دادن اطلاعات حیاتی حفظ کند. لایه های تمام متصل: پس از لایه های کانولوشنی و نمونه برداری، لایه های تمام متصل برای ترکیب ویژگی های استخراج شده و پیش بینی نهایی مصرف انرژی استفاده می شوند. (Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, 1998)


<sup>3</sup> Feedforward Neural Network

<sup>4</sup> Hidden

<sup>5</sup> Deep Learning

<sup>6</sup> Natural Language Processing

<sup>7</sup> Pooling




شکل ۱: معماری شبکه عصبی کانولوشنی (CNN)

این شبکه شامل لایه‌های مختلفی است که هر یک وظیفه استخراج و فشرده‌سازی ویژگی‌های مختلف از داده‌ها را بر عهده دارند. لایه‌های کانولوشنی با استفاده از فیلترهای مختلف، ویژگی‌های محلی داده‌ها را شناسایی کرده و سپس این ویژگی‌ها را به لایه‌های بعدی منتقل می‌کنند. لایه‌های پلی وظیفه کاهش ابعاد داده‌ها و افزایش کارایی مدل را دارند. (W. Dong, 2009)

### ۲-۳-۵- معماری شبکه LSTM

شبکه LSTM به دلیل قابلیت نگهداری اطلاعات بلندمدت و شناسایی وابستگی‌های زمانی، به عنوان یکی از بهترین ابزارها برای پیش‌بینی سری‌های زمانی شناخته می‌شود (Yokoyama.R, Wakui.T, Satake.R, 2009). واحدهای LSTM: این واحدها با استفاده از حافظه داخلی خود، اطلاعات مربوط به مقادیر قبلی را برای مدت طولانی نگهداری می‌کنند و از آن‌ها برای پیش‌بینی مقادیر آینده استفاده می‌کنند و این ویژگی به مدل اجازه می‌دهد تا روندهای بلندمدت مصرف انرژی را با دقت بیشتری پیش‌بینی کند. (Aydinalp-Koksal.M, Ugursal.VI, 2008). لایه‌های مخفی: لایه‌های مخفی در LSTM به مدل کمک می‌کنند تا وابستگی‌های پیچیده‌تری را شناسایی و مدل‌سازی کند. (Azadeh, A., Ghaderi, S.F., Sohrabkhani, S, 2007). لایه خروجی: این لایه برای ارائه پیش‌بینی نهایی مصرف انرژی بر اساس اطلاعات پردازش شده در لایه‌های قبلی استفاده می‌شود.

در این پژوهش، از یک مدل LSTM با چند لایه مخفی برای پیش‌بینی مصرف انرژی استفاده شده است (S. L. Phung, [ ] and A. Bouzerdoum, 2009).



شکل ۲: معماری شبکه عصبی حافظه طولانی-کوتاه مدت (LSTM)

شبکه LSTM با استفاده از واحدهای حافظه‌ای خود، قادر به نگهداری اطلاعات مربوط به داده‌های گذشته و استفاده از آن‌ها برای پیش‌بینی‌های دقیق‌تر است. این ویژگی به ویژه در پیش‌بینی‌هایی که نیاز به تحلیل وابستگی‌های زمانی دارند، بسیار مفید است. (علی آبادی ۱۳۹۶)

## ۲-۳-۶- مبانی نظری یادگیری عمیق و CNN

به طور کلی روش‌های یادگیری عمیق به چهار دسته تقسیم می‌شوند

۱- روش‌هایی بر پایه CNN

۲- روش‌هایی بر پایه ماشین بولتزمن محدود<sup>۸</sup>

۳- روش‌هایی بر پایه اتوانکدر

۴- روش‌های برپایه بازنمایی تنک<sup>۹</sup>

در میان چهار دسته فوق، روش‌های مبتنی بر CNN در کاربردهای بینایی ماشین<sup>۱۰</sup> محبوبیت گسترده‌ای پیدا کرده است. از مزایای روش CNN می‌توان به کاهش تعداد پارامترهای وزن به کمک مفهوم به اشتراک گذاری وزنها<sup>۱۱</sup> اشاره کرد. همچنین در تولید ویژگی‌ها در این روش، همسایگی‌های یک پیکسال در نظر گرفته می‌شود که با فرض یکسان بودن خواص آماری پیکسل‌های یک بخش در تصاویر سازگار است. (Y. Guo, Y. Liu, A. Oerlemans, S. Lao, S. Wu, and M. S. Lew, (2016) در شبکه‌های عصبی چند لایه‌ای پرسپترون<sup>۱۲</sup> نورون‌ها به صورت کامل به یکدیگر متصل هستند و با افزایش ابعاد تصاویر، تعداد اتصالات و پارامترهای آزاد بسیار زیاد شده و در نتیجه داده‌های آموزشی بسیار حجیمی لازم خواهد بود. (Bengio, 1998)

## ۲-۳-۷- شبکه‌های عصبی حافظه طولانی کوتاه-مدت

حضور شبکه‌های عصبی حافظه طولانی کوتاه-مدت (LSTM) در سال‌های اخیر بسیار پررنگ شده است. (Sherstinsky, 2020) در حقیقت هدف از طراحی شبکه LSTM حل مشکل وابستگی بلند مدت بود. به یادسپاری اطلاعات برای بازه‌های زمانی بلند مدت، رفتار پیش فرض و عادی شبکه‌های LSTM است و ساختار آنها به صورتی است که اطلاعات بسیار دور (از لحاظ زمانی) را به خوبی می‌آموزند. تمام شبکه‌های عصبی مکرر توالی‌های تکرار شونده از ماجولهای (واحدهای) شبکه‌های عصبی هستند. در شبکه‌های عصبی مکرر ساده، این ماجولهای تکرار شونده دارای ساختار ساده‌ای هستند. شبکه‌های LS نیز دارای چنین ساختار دنباله یا زنجیره مانند هستند اما ماجول تکرار شونده دارای ساختار پیچیده‌تری است. عنصر اصلی LST وضعیت سلل<sup>۱۳</sup> است که LSTM را قادر به حذف یا اضافه کردن اطلاعات جدید به وضعیت سلول می‌کند. این عمل توسط ساختارهای دقیقی با نام دروازه<sup>۱۴</sup> صورت می‌گیرد که مسیری برای ورود اختیاری اطلاعات هستند. (جنتی، ۱۳۹۰)

<sup>8</sup> Restricted Boltzman Machine Methods

<sup>9</sup> Sparse Coding Based Methods

<sup>10</sup> Machine vision

<sup>11</sup> Weight Sharing

<sup>12</sup> Multi-layer Perceptron

<sup>13</sup> Cell State


<sup>14</sup> Gateway

## ۲-۳-۸- روشهای پیش بینی سری های زمانی

روشهای زیادی برای بررسی آینده های مختلف و پیش بینی های دقیق و محتمل تر متغیرها وجود دارد که گردن<sup>۱۵</sup> در یک دسته بندی کلی، این روش ها را به کیفی و کمی تفکیک کرده است. به طوریکه روشهای کمی خود دربردارنده روشهای سری زمانی و مبتنی بر مدل هستند. (قصایی و روانمهر ۱۳۹۹)

در الگوهای سری زمانی که اغلب برای پیش بینیهای کوتاه مدت مورد استفاده قرار میگیرند، سعی میشود، رفتار یک متغیر براساس مقادیر گذشته آن متغیر و احتمالا مقادیر گذشته سایر متغیرهایی که پیش بینی آنها مد نظر است توضیح داده شود. این الگوها حتی در مواردی که الگوی اقتصادی زیرساختی مشخصی وجود ندارد، نیز قادر به ارائه پیش بینی هایی دقیق از متغیرهای مورد نظر است. (نوفرستی، ۱۳۷۸)

الگوهای سری زمانی را می توان به دو گروه الگوهای خطی و غیر خطی تقسیم نمود. (عباس عرب مازار و همکاران، ۱۳۸۷)



شکل ۳: انواع الگوهای سری زمانی

دو الگوی خودتوضیح میانگین متحرک انباشته ARIMA<sup>۱۶</sup> و فضای حالت<sup>۱۷</sup> جزء الگوهای خطی محسوب میشوند. در مقابل، الگوهای سری زمانی غیرخطی از گستردگی بیشتری برخوردار می باشند، به طوری که الگوهای شبکه عصبی مصنوعی<sup>۱۸</sup> در گروه الگوهای سری زمانی غیرخطی عمومی با ناظر<sup>۱۹</sup> قرار دارند. (خادمی زارع، ۲۰۰۹)

<sup>15</sup> Gordon

<sup>16</sup> Autoregressive Integrated Moving Average Processes

<sup>17</sup> State Space

<sup>18</sup> Artificial Neural Networks

<sup>19</sup> Supervised General Nonlinearity

### ۲-۳-۹- الگوی خودتوضیح میانگین متحرک انباشته ARIMA

مدل های ARIMA که به مدل های باکس- جنکینز<sup>۲۰</sup> نیز معروف اند، از روش های معروف مدل سازی در سری های زمانی است که عمدتاً برای پیش بینی سری های زمانی مورد استفاده قرار میگیرد. متدلوژی این روش مبتنی است بر تجزیه و تحلیل تصادفی سریه ای زمانی. (گجراتی، ۱۳۷۸)

### ۳- مدل و فرضیه های تحقیق

در این پژوهش به معرفی یک شبکه عصبی عمیق ترکیبی برای پیش بینی بار الکتریکی در سیستم های توزیع برق می پردازیم. تحقیقات انجام شده نشان می دهد که استفاده ترکیبی از دو مدل CNN و LSTM می تواند دقت پیش بینی ها را به طور قابل توجهی افزایش دهد. این رویکرد به خصوص در مواردی که داده ها دارای الگوهای پیچیده و وابستگی های زمانی هستند، بسیار موثر است. این مدل ها به دلیل قابلیت های خود در پردازش داده های پیچیده و سری های زمانی، موفق به ارائه نتایج دقیق تری نسبت به مدل های سنتی شده اند.

یکی از مدل های مهم در این زمینه، شبکه های عصبی کانولوشنی (CNN) است که برای تحلیل داده های تصویری و سری های زمانی استفاده می شود. مدل های CNN قادر به شناسایی و استخراج ویژگی های مهم از داده ها هستند که در نهایت به بهبود دقت پیش بینی ها منجر می شود.

از سوی دیگر، شبکه های عصبی حافظه طولانی-کوتاه مدت (LSTM) به دلیل ساختار خاص خود برای مدل سازی وابستگی های زمانی در سری های زمانی مانند مصرف انرژی بسیار کارآمد هستند. این مدل ها با استفاده از واحدهای حافظه ای قادر به نگهداری و استفاده از اطلاعات تاریخی برای پیش بینی های آینده هستند.

در دهه های اخیر، مطالعات گسترده ای بر روی پیش بینی مصرف انرژی با استفاده از روش های مختلف انجام شده است. مدل های آماری سنتی مانند رگرسیون خطی، با وجود سادگی، در مواردی که داده ها دارای الگوهای پیچیده هستند، عملکرد مناسبی نداشته اند. به همین دلیل، استفاده از روش های هوش مصنوعی مانند شبکه های عصبی مصنوعی و ماشین های بردار پشتیبان (SVM)<sup>۲۱</sup> در سال های اخیر افزایش یافته است.

شبکه های عصبی مصنوعی به دلیل توانایی بالا در مدل سازی روابط غیرخطی و پیچیده میان متغیرها، به ویژه در پیش بینی سری های زمانی مانند مصرف انرژی، بسیار مورد توجه قرار گرفته اند. مدل های یادگیری عمیق مانند CNN و LSTM نیز به دلیل توانایی در پردازش داده های پیچیده و سری های زمانی، کارایی بالایی در پیش بینی مصرف انرژی نشان داده اند. انواع مختلفی از شبکه های عصبی با توجه به اهداف تحقیق می توانند مورد استفاده قرار گیرند که یکی از معروف ترین آنها، شبکه عصبی پیش خور (MFNN) می باشد. شبکه عصبی چند لایه پیش خور با استفاده از یک ناظر خود را آموزش می دهد. بر طبق مطالعات اخیر بیش از پنجاه درصد مطالعات گزارش شده از شبکه عصبی، بصورت چند لایه و با قوانین یادگیری پس انتشار می باشند. این نوع شبکه عصبی دارای کاربردهای گسترده در مسایل مدیریت از قبیل پیش بینی، طبقه بندی و مدلسازی بوده و دارای قابلیت یادگیری مناسب است.

تمامی مدل های ذکر شده دارای معایب و مزایایی هستند با این وجود با استفاده از روش ترکیبی می توان با دانستن معایب و استفاده روش جایگزین در آن قسمت به نتیجه مطلوب تر رسید و توقع عملکرد بهتر در پیش بینی مصرف انرژی ساختمان را داشته باشیم.

<sup>20</sup> Box-Jenkins models

<sup>21</sup> Support Vector Machine

## ۴- روش تحقیق

## ۴-۱- جمع‌آوری و پیش‌پردازش داده‌ها

این پژوهش شامل چند مرحله از جمله جمع‌آوری داده‌ها، پیش‌پردازش و طراحی و آموزش مدل‌های CNN و LSTM است. داده‌های مربوط به مصرف انرژی از منابع مختلف جمع‌آوری و برای مدل‌سازی به دو بخش آموزش و آزمون تقسیم شده‌اند. این داده‌ها شامل اطلاعات مربوط به مصرف انرژی در بازه‌های زمانی مختلف، شرایط جوی و سایر متغیرهای تاثیرگذار می‌باشد. این داده‌ها پس از پیش‌پردازش و نرمال‌سازی به دو مدل CNN و LSTM وارد شدند. داده‌های مصرف انرژی از چندین منبع مختلف شامل سیستم‌های مدیریت انرژی ساختمان‌ها، پایگاه‌های داده عمومی، مقالات، پایان نامه‌ها جمع‌آوری شده است. این داده‌ها شامل پارامترهای مختلفی مانند مصرف برق، دما، رطوبت، تابش خورشید و سایر عوامل محیطی است که تأثیر مستقیم بر مصرف انرژی دارند. در جدول ۱، نمونه‌ای از داده‌های استفاده شده در این مطالعه ارائه شده است.

جدول ۱: نمونه‌ای از داده‌های مصرف انرژی

| زمان  | مصرف برق (کیلووات ساعت) | دما ( $^{\circ}\text{C}$ ) | رطوبت (%) | تابش خورشید ( $\text{W/m}^2$ ) |
|-------|-------------------------|----------------------------|-----------|--------------------------------|
| ۰۸:۰۰ | ۱۵۰۰                    | 22                         | 60        | 500                            |
| ۰۹:۰۰ | 1600                    | 23                         | 58        | 550                            |
| ۱۰:۰۰ | 1700                    | 24                         | 55        | 600                            |

## ۴-۲- انتخاب داده‌ها و پیش‌پردازش

داده‌های مصرف انرژی مورد استفاده در این تحقیق که شامل اطلاعاتی مانند مصرف برق، دما، رطوبت، میزان تابش خورشید و سایر متغیرهای جوی هستند که تأثیر مستقیم بر مصرف انرژی ساختمان‌ها دارند پس از جمع‌آوری داده‌ها، مرحله پیش‌پردازش آغاز می‌شود که شامل چندین گام اصلی است:

- ۱- پاکسازی داده‌ها: در این مرحله داده‌های ناقص و دارای نویز حذف یا تصحیح می‌شوند. این کار به منظور افزایش دقت مدل‌های پیش‌بینی انجام می‌شود.
- ۲- نرمال‌سازی داده‌ها: داده‌ها نرمال‌سازی می‌شوند تا مقیاس‌های مختلف داده‌ها همسان‌سازی شده و از تأثیر نادرست مقیاس‌ها بر مدل‌ها جلوگیری شود.
- ۳- تقسیم داده‌ها: داده‌ها به دو مجموعه آموزش و آزمون تقسیم می‌شوند. مجموعه آموزش برای یادگیری مدل‌ها استفاده می‌شود و مجموعه آزمون برای ارزیابی عملکرد آن‌ها مورد استفاده قرار می‌گیرد.

## ۵- یافته‌های تحقیق

در این بخش نتایج به دست آمده از اجرای مدل‌های CNN و LSTM بر روی داده‌های مصرف انرژی بررسی و تحلیل می‌شوند؛ و یک ارزیابی از عملکرد این مدل‌ها در پیش‌بینی مصرف انرژی را ارائه می‌دهد. نتایج به دست آمده از اجرای مدل‌های CNN و LSTM نشان‌دهنده دقت بالای این مدل‌ها در پیش‌بینی مصرف انرژی است. برای ارزیابی عملکرد این مدل‌ها، از معیارهایی مانند میانگین مربع خطا (MSE)، میانگین قدر مطلق خطا (MAE) و ضریب تعیین ( $R^2$ ) استفاده شده است. نتایج حاصل از اجرای مدل TM بر روی مجموعه داده‌های مصرف انرژی ارائه می‌شود. به منظور ارزیابی عملکرد این مدل‌ها، معیارهایی نظیر میانگین مربع خطا (MSE)، میانگین قدر مطلق خطا (MAE) و ضریب تعیین ( $R^2$ ) مورد استفاده قرار گرفته است.

جدول ۲: نتایج ارزیابی مدل ها

| مدل    | MSE   | MAE   | $R^2$ |
|--------|-------|-------|-------|
| CNN    | ۰,۰۱۲ | ۰,۰۴۵ | ۰,۹۸  |
| LSTM   | ۰,۰۱۰ | ۰,۰۴۲ | ۰,۹۹  |
| ترکیبی | ۰,۰۰۸ | ۰,۰۳۹ | ۰,۹۹  |

## ۱-۵- نتایج مدل CNN

نتایج نشان‌دهنده دقت بالای مدل CNN در پیش‌بینی مصرف انرژی به ویژه در بازه‌های زمانی کوتاه‌مدت است. این مدل توانسته است با شناسایی الگوهای محلی و ویژگی‌های خاص داده‌ها، پیش‌بینی‌های دقیقی ارائه دهد. دقت مدل CNN در بازه‌های زمانی کوتاه‌تر به دلیل توانایی این مدل در استخراج ویژگی‌های محلی از داده‌ها بیشتر است، زیرا این ویژگی‌ها اغلب در داده‌های مصرف انرژی کوتاه‌مدت بسیار تأثیرگذار هستند. این مدل به ویژه در پیش‌بینی‌های کوتاه‌مدت، به دلیل توانایی در شناسایی الگوهای پیچیده و استخراج ویژگی‌های خاص از داده‌ها، عملکرد بهتری نسبت به مدل‌های دیگر داشته است. نتایج نشان می‌دهد که این مدل می‌تواند به عنوان ابزاری موثر در بهینه‌سازی مصرف انرژی در ساختمان‌ها مورد استفاده قرار گیرد.

مدل CNN با دقت بالایی توانسته است الگوهای پیچیده موجود در داده‌های مصرف انرژی را شناسایی و پیش‌بینی‌های دقیقی ارائه دهد. نتایج نشان داد که این مدل به ویژه در پیش‌بینی مصرف انرژی در کوتاه‌مدت بسیار مؤثر است.

مدل CNN برای پیش‌بینی مصرف انرژی در بازه‌های زمانی کوتاه‌مدت استفاده شد و نتایج بسیار دقیقی ارائه داد.

## ۲-۵- نتایج مدل LSTM

مدل LSTM به دلیل ساختار حافظه‌ای خود و توانایی در شناسایی وابستگی‌های طولانی‌مدت زمانی، در پیش‌بینی‌های بلندمدت مصرف انرژی عملکرد بسیار خوبی داشته است. این مدل توانسته است روندهای کلی مصرف انرژی را به درستی پیش‌بینی کند و میزان خطای پیش‌بینی‌های آن نسبت به مدل‌های سنتی به طور قابل‌توجهی کاهش یافته است. در نتیجه، LSTM برای کاربردهایی که نیاز به پیش‌بینی‌های بلندمدت دارند، مناسب‌تر است.

مدل LSTM نیز در پیش‌بینی مصرف انرژی، به ویژه در بلندمدت، عملکرد خوبی داشته است. این مدل با توجه به توانایی در نگهداری اطلاعات مربوط به مقادیر گذشته، در پیش‌بینی روندهای بلندمدت دقت بیشتری نشان داده است.

مدل LSTM نیز در پیش‌بینی‌های بلندمدت مصرف اقبال قبولی داشته است. به دلیل توانایی این مدل در نگهداری اطلاعات بلندمدت و شناسایی وابستگی‌های زمانی، دقت پیش‌بینی‌های بلندمدت افزایش یافته و نتایج بهتری نسبت به مدل‌های سنتی ارائه شده است. این امر نشان‌دهنده قابلیت بالای مدل LSTM در مدیریت و بهینه‌سازی مصرف انرژی در بازه‌های زمانی مختلف است.

مدل LSTM برای پیش‌بینی مصرف انرژی در بازه‌های زمانی بلندمدت استفاده شد و نتایج حاصل نشان‌دهنده دقت بالا و کاهش خطای پیش‌بینی بود.

## ۶- بحث و نتیجه‌گیری

تحلیل نتایج به دست آمده از اجرای مدل‌های CNN و LSTM نشان می‌دهد که این مدل‌ها می‌توانند به طور موثری برای پیش‌بینی و بهینه‌سازی مصرف انرژی در ساختمان‌ها مورد استفاده قرار گیرند. مدل CNN به دلیل توانایی بالای خود در

شناسایی الگوهای محلی و ویژگی‌های خاص داده‌ها، در پیش‌بینی‌های کوتاه‌مدت عملکرد بسیار خوبی داشته است. از سوی دیگر، مدل LSTM با توجه به ساختار حافظه‌ای خود و توانایی در نگهداری اطلاعات طولانی‌مدت، در پیش‌بینی‌های بلندمدت بسیار موفق عمل کرده است.

با توجه به این نتایج، می‌توان پیشنهاد کرد که برای بهینه‌سازی مصرف انرژی در ساختمان‌ها از یک ترکیب مناسب از این دو مدل استفاده شود. به عنوان مثال، می‌توان از مدل CNN برای پیش‌بینی‌های کوتاه‌مدت و از مدل LSTM برای پیش‌بینی‌های بلندمدت استفاده کرد. همچنین استفاده از روش‌های ترکیبی که از هر دو مدل CNN و LSTM بهره می‌برند، می‌تواند به نتایج دقیق‌تری منجر شود.

این مطالعه نشان می‌دهد که یادگیری عمیق می‌تواند به عنوان یک ابزار موثر در مدیریت هوشمند انرژی در ساختمان‌ها مورد استفاده قرار گیرد. در تحقیقات آینده، می‌توان از مدل‌های پیشرفته‌تر و داده‌های بیشتر برای بهبود دقت پیش‌بینی‌ها و ارائه راهکارهای بهینه‌سازی دقیق‌تر استفاده کرد.

استفاده از مدل‌های یادگیری عمیق در پیش‌بینی مصرف انرژی ساختمان‌ها نشان داده است که این مدل‌ها قادرند به‌طور قابل‌توجهی دقت پیش‌بینی‌ها را افزایش دهند. مدل CNN به دلیل قابلیت بالای استخراج ویژگی‌های پیچیده از داده‌ها، در پیش‌بینی‌های کوتاه‌مدت عملکرد بهتری دارد. از سوی دیگر، مدل LSTM با توجه به ساختار حافظه‌ای خود، در پیش‌بینی‌های بلندمدت دقیق‌تر عمل می‌کند.

این نتایج نشان می‌دهد که استفاده ترکیبی از این دو مدل می‌تواند به بهبود مدیریت مصرف انرژی در ساختمان‌ها کمک کند. به عنوان یک پیشنهاد، استفاده از مدل‌های ترکیبی (Hybrid Models) که از ویژگی‌های هر دو مدل CNN و LSTM بهره‌مند هستند، می‌تواند در بهینه‌سازی مصرف انرژی در مقیاس وسیع‌تر مؤثر باشد.

با توجه به نتایج به‌دست‌آمده، می‌توان نتیجه گرفت که استیج یادگیری عمیق مانند CNN و LSTM در پیش‌بینی مصرف انرژی ساختمان‌ها می‌تواند به بهبود دقت پیش‌بینی‌ها و بهینه‌سازی مصرف انرژی کمک کند. مدل CNN به دلیل قابلیت بالای خود در استخراج ویژگی‌های پیچیده از داده‌ها، برای پیش‌بینی‌های کوتاه‌مدت مناسب‌تر است. از سوی دیگر، مدل LSTM به دلیل ساختار حافظه‌ای خود، در پیش‌بینی‌های بلندمدت عملکرد بهتری دارد.

این نتایج نشان می‌دهد که استفاده از این دو مدل به صورت ترکیبی می‌تواند راهکاری موثر برای مدیریت هوشمند انرژی در ساختمان‌ها باشد. پیشنهاد می‌شود که در تحقیقات آینده، استفاده از مدل‌های ترکیبی CNN-LSTM مورد بررسی قرار گیرد تا بتوان به نتایج بهتری در بهینه‌سازی مصرف انرژی دست یافت.

## منابع

- [1] م. ل. پ. جعفری، "شبکه‌های عصبی و کنترل کننده های عصبی پیشر ته با رویکرد"، *دانشگاه صنعتی خواجه نصیرالدین طوسی*، 1394.
- [2] ن. کرد and ف. ک. نیا، "ارائه مدل جدید تخمین مصرف انرژی برق براساس مبدل‌های موجک موازی"، *هوش محاسباتی در مهندسی برق*، 1399،
- [3] م. شاه حسینی، "طراحی مدل سیاستگذاری انرژی در افق چشم انداز با رویکرد سیستمهای پویا"، *پایان نامه دکتری تخصصی؛ دانشگاه تهران دانشکده مدیریت*، 1388،
- [4] حسن خادمی زارع، اخوان آخرین، "ارائه یک مدل تلفیقی به منظور پیش بینی پیک بار و برقراری تعادل عرضه و تقاضای انرژی الکتریکی با اهداف چند گانه"، *بیست و چهارمین کنفرانس بین المللی برق، ایران، تهران*، 2009،
- [5] ن. فرشاد، "بهره وری انرژی در بخش ساختمان و مسکن in"، *کنفرانس بهینه سازی مصرف انرژی، موسسه همایش صنعت*، تهران، ۱۳۸۹.
- [6] ا. طلوعیان، "مدیریت مصرف انرژی و رابطه آن با توسعه پایدار و آلودگی محیط زیست in"، *پنجمین همایش بهینه سازی مصرف سوخت در ساختمان*، 1385،
- [7] س. م. ع. آبادی، "پیش‌بینی مصرف انرژی ساختمان مسکونی با استفاده از شبکه عصبی"، *پایان نامه کارشناسی ارشد مهندسی کنترل، دانشکده مهندسی برق و رباتیک، دانشگاه صنعتی شاهرود*، 1396،
- [8] م. ز. م. ا. حداد، "بهینه یابی تعداد الیه ها و نرون های شبکه عصبی مصنوعی به روش الگوریتم ژنتیک در پیش‌بینی جریان"، ۱۳۸۷.
- [9] ز. م. خ. ز. ح. ف. م. باقر، "بهینه یابی سبد مصرف انرژی و خوشه بندی ساختمان‌های مسکونی با بهبود شبکه عصبی فازی با اوزان و معماری"، *AHP، پژوهشهای مدیریت عمومی*، vol. 6, no. 19, pp. 129-152, 1392،
- [10] ق. س. ر. رضا، "پیش‌بینی کوتاه مدت مصرف بار الکتریکی با استفاده از شبکه‌های عصبی عمیق"، *نشریه علمی-پژوهشی کیفیت و بهره وری صنعت برق ایران سال دهم*، vol. 10, 1399،
- [11] ب. جنتی، "پیش‌بینی و تحلیل مصرف فرآورده‌های نفتی طی سالهای ۱۳۹۱ الی ۱۳۹۴ با استفاده از مدل in"، *ARIM/اولین کنفرانس بین المللی نفت، گاز، پتروشیمی و نیروگاهی، مرکز همایش های بین المللی هتل المپیک تهران، تهران*، ۱۳۹۰.
- [12] ن. محمد، "ریشه واحد و همجمعی در اقتصادسنجی in"، *موسسه خدمات فرهنگی رسا*، 1378،
- [13] ع. م. ع. و. همکاران، "الگوهای پیش‌بینی درآمدهای مالیاتی in"، *طرح پژوهشی سازمان امور مالیاتی کشور*، 1387،
- [14] گ. دامودار، *مبانی اقتصاد سنجی*، تهران: ترجمه حمید ابریشمی انتشارات دانشگاه تهران، ۱۳۷۸.
- [15] B. L. R. Y. Yulan Yang, "A method of identifying and weighting indicators of energy efficiency assessment in Chinese residential buildings," *Energy Policy*, vol. 12, no. 7687-7697, p. 38, 2010.
- [16] L. U. V. I. Swan, "Modeling of end- use energy consumption in the residential sector," *A review of modeling techniques, Renewable and sustainable energy reviews*, vol. 1819-1835, p. 13, 2009.
- [17] A. G. S. S. S. Azadeh, "Forecasting electrical consumption by integration of NN," *time series and ANOVA Applied mathematics and computation*, Vols. 1753-1761, p. 186, 2007.
- [18] J. L. H. W. S. Wong, "Intelligent building research: a review, Automation in Construction," vol. 1, no. 143-159, p. 14, 2005.
- [19] J. J. H. B. J. Lee, "Well-Being index of super tall residential buildings in Korea," *Building and Environment*, Vols. 1184-1194, p. 46, 2011.

- [20] H. G. W. Z. W. Ren, "Nakagami, K. Multi-criteria evaluation for the optimal adoption of distributed residential energy systems in Japan," *Energy Policy*, vol. 12, no. 5484-5493, p. 37, 2009.
- [21] "www.eia.gov," [Online].
- [22] R. F. Biswas.MR, ""Prediction of residential building energy consumption," in *A neural network approach. Energy*, 2016.
- [23] Z. Y. L. S. Deb.C, "A review on time series forecasting techniques for building energy consumption," vol. Renewable and Sustainable Energy , 2017.
- [24] S. Wang.Z, "A review of artificial intelligence based building energy," vol. Renewable and Sustainable Energy Reviews, 2017.
- [25] M. Zhao.HX, "A review on the prediction of building energy consumption," *Renewable and Sustainable Energy Reviews*, 2012.
- [26] Dong.B, Cao.C, Lee.SE, "Applying support vector machines to predict building energy consumption in tropical region," *Energy and Buildings*, 2005.
- [27] N. S. Kalogirou.SA, "Building heating load estimation using artificial neural networks," in *InProceedings of the 17th international conference on Parallel architectures and compilation techniques*, 1997.
- [28] Yokoyama.R, Wakui.T, Satake.R, "Prediction of energy demands using neural network with model identification by global optimization," *Energy Conversion and Management*, 2009.
- [29] U. Aydinalp-Koksal.M, "Comparison of neural network conditional demand analysis, and engineering approaches for modeling end-use energy consumption in the residential sector," *Applied Energy*, 2008.
- [30] M. a. B. M. Khashei, "A Novel Hybridization of Artificial Neural Networks and ARIMA Models for Time Series Forecasting," *Applied* , vol. 11: 2664, 2011.
- [31] X. a. M. M. Wang, "A Hybrid Neural Network and ARIMA Model for Energy Consumption Forecasting," *Journal of Computers*, Vols. 7, No.5, 2012.
- [32] S. F. Y. Z. P. W. J. Z. T. Liu, "—Implementation of training convolutional neural networks," *Computer Vision and Pattern Recognition*, 2015.
- [33] W. D. R. S. L.-J. L. K. L. L. F.-F. —. J. Deng, "A large-scale hierarchical image database," *In Proc.CVPR*, 2009.
- [34] Y. Bengio, "—Learning Deep Architectures for AI," *Foundations and Trends in Machine Learning*, vol. 2, no. 1, pp. 1-127, 2009.
- [35] a. L. A. A. JS. Filipe, "From the human visual system to the computational models of visual attention: A survey Artificial Intelligence Review," *IEEE Transactions On Geoscience And Remote Sensing*, vol. 52, no. 11, pp. 1-47, 2014.
- [36] a. A. B. JS. L. Phung, "MATLAB Library for Convolutional Neural Networks, Technical Report," in *Visual and Audio Signal Processing Lab* , University of Wollongong, 2009.
- [37] Y. L. A. O. S. L. S. W. a. M. S. L. Y. Guo, "Deep learning for visual understanding: A review," *Neurocomputing*, vol. 187, pp. 27-48, 2016.
- [38] L. B. Y. B. a. P. H. Y. Lecun, "Gradient learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, 1998.

## Estimating building electrical load based on deep neural networks

Mohammad Mahdi Movahedzadeh<sup>1</sup>, Mohammad Rahmati<sup>2</sup>, Mohammad Ali Movahedzadeh<sup>3</sup>

<sup>1</sup>Department of Electrical and Computer Engineering, Zahedshahr Branch, Islamic Azad University, Zahedshahr, Iran

<sup>2</sup>Department of Electrical and Computer Engineering, Zahedshahr Branch, Islamic Azad University, Zahedshahr, Iran

<sup>3</sup>Department of Architecture Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran

---

### Abstract

In today's modern world, the staggering and increasing population growth and urban development have led to excessive energy consumption, which we have witnessed more than ever in recent years. Therefore, managing and optimizing energy consumption is one of the most important goals of every society worldwide. And considering that the highest energy consumption is related to buildings, it must be said that energy control in buildings can be one of the most important goals of every society. Of course, this issue is more important in a country like Iran. Optimal and correct energy consumption not only helps to preserve natural resources, but also leads to reduced economic costs and reduced greenhouse gas emissions. In this regard, optimizing energy consumption in buildings is one of the important research areas. Predicting energy consumption requires considering many parameters. In this research, we will optimize energy consumption in buildings using neural networks and deep learning.

**Keywords:** Deep neural networks, deep learning, energy consumption optimization, building energy, Consumption Management.

---

