



## A New Hybrid Intelligent-based Model for Building Electrical Consumption Forecasting

Nasser Shahsavari-Pour <sup>1\*</sup>, Mojtaba Afshar Jahanshahi <sup>2</sup>

1. Professor Department of Industrial Engineering, Vali-e-Asr University of Rafsanjan, Iran. Email: [Shahsavari\\_n@alum.sharif.edu](mailto:Shahsavari_n@alum.sharif.edu)

2. Assistant Professor of Accounting, Faculty of Administrative Sciences and Economics. Email: [afshar@vru.ac.ir](mailto:afshar@vru.ac.ir)

### ARTICLE INFO

#### Article type:

Research Paper

#### Article History:

Received 18 May 2025

Revised 7 July 2025

Accepted 13 September 2025

Published Online 23 September 2025

#### Keywords:

Building energy consumption, load forecasting, smart building, deep learning models, energy management.

### ABSTRACT

Energy information systems are crucial for the operational optimization of smart buildings. These systems can offer benefits such as high energy-saving potential, efficiency, and intelligent services. Therefore, accurate electricity consumption forecasting requires a smart estimation strategy that considers the parameters affecting electricity consumption patterns. This paper proposes an intelligent prediction model that accurately forecasts and analyzes building electricity consumption. The proposed model includes the following components: a feature selection model based on mutual information for selecting input variables, and a deep learning time series prediction model based on Long Short-Term Memory (LSTM) neural networks to forecast the target value. The model's performance was evaluated using real-world data from a two-story smart home located in Houston, Texas, USA. A comparative analysis with other benchmark models was also conducted. The comprehensive comparison demonstrated that the hybrid model is more accurate than individual models, and the proposed intelligent model outperforms other benchmark hybrid and standalone models, as indicated by the achieved prediction performance.

**Cite this article:** Shahsavari-Pour, N., Afshar Jahanshahi, M. (2025). A New Hybrid Intelligent-based Model for Building Electrical Consumption Forecasting. *Energy Systems: Technology and Management*, 1 (1), 25-34. DOI: <http://doi.org/10.48306/estm.2025.232463>



© Graduate University of Advanced Technology.  
DOI: <http://doi.org/10.48306/estm.2025.232463>

\* Corresponding author.  
Email: [Shahsavari\\_n@alum.sharif.edu](mailto:Shahsavari_n@alum.sharif.edu)



## یک مدل ترکیبی جدید مبتنی بر هوش مصنوعی برای پیش‌بینی مصرف برق ساختمان

ناصر شهسواری پور<sup>۱\*</sup>، مجتبی افشار جهانشاهی<sup>۲</sup>

۱. استاد دانشکده مهندسی صنایع، دانشگاه ولی عصر رفسنجان، رفسنجان، ایران. رایانامه: [shahsavari\\_n@alum.sharif.edu](mailto:shahsavari_n@alum.sharif.edu)  
۲. استادیار حسابداری دانشکده علوم اداری و اقتصاد، دانشگاه ولی عصر رفسنجان، رفسنجان، ایران. رایانامه: [afshar@vru.ac.ir](mailto:afshar@vru.ac.ir)

چکیده	اطلاعات مقاله
سیستم‌های اطلاعات انرژی برای بهینه‌سازی عملیاتی ساختمان‌های هوشمند بسیار حیاتی هستند. این سیستم‌ها می‌توانند مزایایی مانند پتانسیل بالای صرفه‌جویی در انرژی، کارایی و خدمات هوشمند را فراهم کنند. بنابراین، پیش‌بینی دقیق مصرف برق نیازمند یک استراتژی تخمین هوشمند است که پارامترهای مؤثر بر الگوهای مصرف برق را در نظر بگیرد. این مقاله یک مدل پیش‌بینی هوشمند را پیشنهاد می‌دهد که به طور دقیق مصرف برق ساختمان‌ها را پیش‌بینی و تحلیل می‌کند. مدل پیشنهادی شامل موارد زیر است: یک مدل انتخاب ویژگی بر اساس اطلاعات متقابل برای انتخاب ویژگی‌ها به عنوان متغیرهای ورودی؛ و یک مدل پیش‌بینی سری زمانی یادگیری عمیق بر اساس شبکه‌های عصبی حافظه بلند مدت کوتاه (LSTM) برای پیش‌بینی مقدار هدف. عملکرد مدل با استفاده از مجموعه داده‌های واقعی یک خانه هوشمند دو طبقه واقع در هیوستون، تگزاس، ایالات متحده ارزیابی شد. همچنین تحلیل مقایسه‌ای با مدل‌های معیار دیگر انجام شد. مقایسه جامع نشان داد که مدل ترکیبی دقیق‌تر از مدل‌های تکی است و مدل هوشمند پیشنهادی از سایر مدل‌های ترکیبی و تکی معیار بهتر عمل می‌کند، همانطور که عملکرد پیش‌بینی به دست آمده نشان می‌دهد.	<b>نوع مقاله:</b> پژوهشی <b>تاریخ های مقاله:</b> تاریخ دریافت: ۱۴۰۴/۰۲/۲۸ تاریخ بازنگری: ۱۴۰۴/۰۴/۱۶ تاریخ پذیرش: ۱۴۰۴/۰۶/۲۲ تاریخ انتشار: ۱۴۰۴/۰۷/۰۱ <b>کلیدواژه:</b> مصرف انرژی ساختمان، پیش‌بینی بار، ساختمان هوشمند، مدل‌های یادگیری عمیق، مدیریت انرژی.

**استناد:** شهسواری پور، ناصر، و افشار جهانشاهی، مجتبی (۱۴۰۴). یک مدل ترکیبی جدید مبتنی بر هوش مصنوعی برای پیش‌بینی مصرف برق ساختمان. سیستم‌های انرژی: فناوری و مدیریت، ۱ (۱) ۲۶-۳۴.

DOI: <http://doi.org/10.48306/estm.2025.232463>

© دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته.

DOI: <http://doi.org/10.48306/estm.2025.232463>



\* نویسنده مسئول.

رایانامه: [shahsavari\\_n@alum.sharif.edu](mailto:shahsavari_n@alum.sharif.edu)

## ۱. مقدمه

با توسعه جمعیت انسانی، ساخت و ساز ساختمان‌ها و کاربرد فناوری، تقاضای برق به طور تصاعدی افزایش یافته است. این تقاضای رو به رشد، طراحی مدل‌های پیش‌بینی قابل اعتماد برای تقاضای انرژی، به ویژه در ساختمان‌ها که بخش قابل توجهی از مصرف انرژی جهانی را تشکیل می‌دهند، را انگیزه داده است. بنابراین، پیش‌بینی دقیق مصرف انرژی ساختمان‌ها برای تضمین کارایی انرژی و دستیابی به صرفه‌جویی و توسعه مؤثر انرژی ضروری است. با این حال، پیش‌بینی دقیق مصرف انرژی در ساختمان‌ها به دلیل عدم قطعیت‌های زیاد ناشی از سبک‌های زندگی و رفتارهای مختلف ساکنان، یک وظیفه چالش‌برانگیز است [۱] و [۲]. دو روش معمولاً برای پیش‌بینی مصرف انرژی استفاده می‌شود: روش‌های مبتنی بر داده یا مدل‌سازی فیزیکی [۳]–[۵]. روش اول بر تحلیل ویژگی‌های ساخت و ساز ساختمان و پارامترهای محیطی مانند آب و هوا، خورشید/سایه‌گذاری متکی است [۶] و [۷]. این روش نیاز به داده‌های جامع درباره ساختمان شبیه‌سازی شده ندارد، بلکه از داده‌های تاریخی برای پیش‌بینی آموزش می‌بیند [۸]. مطالعات پیشین، فاصله زمانی پیش‌بینی را به سه دسته طبقه‌بندی می‌کند: پیش‌بینی انرژی کوتاه‌مدت (۱ ساعت تا یک هفته) [۹]–[۱۱]، پیش‌بینی انرژی میان‌مدت (یک هفته تا یک ماه) [۱۲]–[۱۴] و پیش‌بینی انرژی بلندمدت (یک سال و بیشتر) [۱۵]–[۱۷]. برای حل مشکل پیش‌بینی مصرف انرژی ساختمان، روش‌های سنتی و همچنین روش‌های یادگیری عمیق (DL) و یادگیری ماشین (ML) به طور گسترده‌ای استفاده شده‌اند [۱۸] و [۱۹]. با این حال، روش‌های ML و DL به دلیل توانایی‌شان در غلبه بر مسایل غیرخطی، بیشتر مورد توجه قرار گرفته‌اند [۲۰]. درخت‌های رگرسیون (RT)، رگرسیون بردار پشتیبان (SVM) و نزدیک‌ترین همسایه‌ها (KNN) تکنیک‌های محبوب یادگیری ماشین هستند که در زمینه مصرف انرژی ساختمان استفاده می‌شوند. نویسندگان در مقاله [۲۱] یک روش پیش‌بینی بار الکتریکی مبتنی بر SVR را پیشنهاد کرده‌اند. عملکرد و دقت پیش‌بینی روش پیشنهادی با استفاده از چهار مجموعه داده تقاضای برق ارزیابی شده است. SVR همچنین در [۲۲] برای پیش‌بینی انرژی در ساختمان‌های هتل بررسی شد، با استفاده از پارامترهای آب و هوا و مشخصات عملکردی سیستم تهویه مطبوع به عنوان ورودی‌ها. نتایج شبیه‌سازی نشان داد که با نتایج پیش‌بینی شده، مصرف انرژی هتل می‌تواند به صورت بصری ارزیابی، بهبود و کاهش یابد. KNN برای مقابله با گرمایش [۲۳]، سرمایش [۲۴]، و مصرف انرژی بار در ساختمان‌ها انجام شده است. نتایج شبیه‌سازی هر دو تحقیق نشان داد که اندازه آزمون و k-همسایه‌ها که دقت خوبی ارائه دادند، برای پیش‌بینی بسیار مهم بودند. با توجه به داده‌های استرالیا، KNN همچنین در [۲۵] برای پیش‌بینی بار الکتریکی اجرا شد. برای ارزیابی اثربخشی روش، تحلیل مقایسه‌ای با مدل‌های دیگر انجام شد و نتایج توانایی آن را در بهبود کیفیت پیش‌بینی از نظر دقت و ساده‌سازی فرآیند پیش‌بینی تأیید کرد. با

استفاده از ML، نویسندگان در [۲۶] از درخت رگرسیون برای پیش‌بینی مصرف انرژی در یک دانشگاه در اسپانیا استفاده کردند. نتایج به دست آمده انعطاف‌پذیری، استحکام و دقت مدل پیشنهادی را تأیید کرد.

شبکه‌های عصبی همگشتی (CNN)، حافظه بلند مدت کوتاه (LSTM)، و شبکه‌های عصبی مصنوعی (ANN) سه زیرشاخه یادگیری عمیق هستند که اخیراً توجه محققان در پیش‌بینی مصرف برق را به خود جلب کرده‌اند. ANN در [۲۷] برای بهبود پیش‌بینی مصرف انرژی ساختمان‌های مسکونی استفاده شده است. مدل پیشنهادی بر اساس داده‌های تولید شده توسط شبیه‌سازی‌های انرژی با استفاده از پارامترهای ورودی تصادفی ایجاد شده است. نتایج توانایی آن را در پیش‌بینی مؤثر انرژی با دقت قابل قبول تأیید کرد. ANN همچنین در [۲۸] برای پیش‌بینی مصرف برق مبتنی بر کاربر در حالی که مشاغل و پروفایل‌های مصرف‌کنندگان در کره جنوبی را در نظر می‌گیرد، مورد مطالعه قرار گرفته است. این مطالعه شامل ۵۲۴۰ نفر مجرد بود و یافته‌ها وجود همبستگی بین ویژگی‌های کاربر و مصرف انرژی را تأیید کرد. علاوه بر این، ANN در [۲۹] برای پیش‌بینی بار کوتاه‌مدت مورد بررسی قرار گرفته است. نتایج نشان داد که مدل پیشنهادی می‌تواند با دقت ۹۸.۵٪ پیش‌بینی کند. مشکل پیش‌بینی انرژی خانگی توسط نویسندگان در [۳۰] با استفاده از مدل LSTM حل شد. مدل‌های LSTM دقت برتری را در مقایسه با شبکه عصبی پس‌انتشار (BPNN)، KNN، و ماشین یادگیری شدید (ELM) ارائه می‌دهند. LSTM همچنین در پیش‌بینی مصرف بار همانطور که در [۳۱] گزارش شده است، پذیرفته شده است. نتایج به دست آمده ثابت کرد که پیش‌بینی روش استفاده شده دقت پیش‌بینی بار را بهبود می‌بخشد. نویسندگان در [۳۲] کارایی مدل CNN را در پیش‌بینی انرژی مسکونی بررسی کردند. در مقایسه با LSTM، ANN، و SVM، CNN مورد مطالعه نتایج قابل مقایسه‌ای با ANN و LSTM به دست آورد اما از مدل SVR بهتر عمل کرد. CNN همچنین در [۳۳] برای پیش‌بینی بار روزانه مورد بررسی قرار گرفت. از نظر دقت، کارایی، و استحکام، نتایج مبتنی بر مدل CNN با نتایج مدل میانگین متحرک یکپارچه خودبازگشتی با ورودی خارجی (ARIMAX) مقایسه شد. هنگامی که مدل مورد بررسی با مدل ARIMAX مقایسه شد، بهترین نتایج را با دقت ۲۲.۶٪ تولید کرد.

مدل‌های ترکیبی نیز برای پیش‌بینی مصرف انرژی ساختمان‌ها استفاده می‌شوند و نتایج امیدوارکننده‌ای داشته‌اند. LSTM با CNN در [۳۴] ترکیب شده است تا دقت مدل‌ها را برای پیش‌بینی مصرف انرژی خانوارهای فردی افزایش دهد. پیاده‌سازی با استفاده از مجموعه داده‌های واقعی یک خانوار واقع در انگلستان نشان داد که مدل در مقایسه با مدل‌های پایه دیگر با اندازه‌های مختلف گام عملکرد خوبی دارد. برای انتخاب بهترین مقادیر پارامتر LSTM و پیش‌بینی دقیق مصرف انرژی کوتاه‌مدت، میان‌مدت و بلندمدت در ساختمان‌ها،

نویسندگان در [۳۵] یک الگوریتم بهینه‌سازی سینوسی-کسینوسی پیشرفته (SCA) ایجاد کردند. عملکرد مدل مطالعه شده (ISCOA-LSTM) نسبت به مدل‌های پایه پیش‌بینی دیگر اثبات شد. برای پیش‌بینی دقیق مصرف انرژی، کار منتشر شده در [۳۶] به استفاده از بهینه‌سازی ازدحام ذرات (PSO) برای شناسایی هایپرپارامترهای مدل LSTM-CNN پرداخت. یافته‌ها نشان داد که مدل مطالعه شده منجر به پیش‌بینی دقیق و دستیابی به کمترین خطاها در مقایسه با روش‌های پایه یادگیری ماشین دیگر می‌شود. کار در [۳۷] به بررسی بهترین روش برای یافتن هایپرپارامترهای مدل LSTM برای پیش‌بینی بار مؤثر با استفاده از الگوریتم‌های ژنتیک (GAs) و PSO پرداخت. تحلیل مقایسه‌ای با مدل‌های ساده یادگیری ماشین دیگر همراه با نتایج به دست آمده دقت و عملکرد برتر روش پیشنهادی را تأیید کرد. در همان زمینه، GAs نیز در [۳۸] برای یافتن بهینه تعداد و تأخیر لایه‌ها برای مدل LSTM استفاده شد. با استفاده از اطلاعات مصرف برق متروپولیتن فرانسه، مدل پیشنهادی دقت بهتری برای پیش‌بینی میان‌مدت تا بلندمدت نسبت به مدل‌های دیگر یادگیری ماشین نشان داد. به همین ترتیب، GAs در [۳۹] برای انتخاب معماری بهبود یافته LSTM با هدف افزایش استحکام و دقت آن در پیش‌بینی مصرف انرژی ساختمان‌ها پذیرفته شد. نتایج به دست آمده نشان داد که روش مطالعه شده بهتر از مدل‌های پایه LSTM عمل می‌کند، همچنین LSTM‌هایی که هایپرپارامترهای آنها توسط PSO، بهینه‌سازی بیزی، یا جستجوی شبکه‌ای تعیین شده‌اند. نویسندگان در [۴۰] از الگوریتم بهینه‌سازی مگس میوه (FOA) برای تعیین هایپرپارامتر LSTM که دقیق‌ترین تخمین مصرف انرژی ماهانه برای ایالات متحده را ارائه می‌دهد، استفاده کردند. بر اساس مدل FAO-LSTM، یافته‌های شبیه‌سازی نشان داد که خطای مطلق درصدی متقارن می‌تواند تا ۱۱.۴۴٪ کاهش یابد. یک مدل ترکیبی جدید بر اساس ماشین تقویت گرادین (GBM)، جنگل تصادفی، LightGBM، تقویت دسته‌ای و تقویت گرادین شدید برای پیش‌بینی بار الکتریکی در [۴۱] پیشنهاد شد. در [۴۲]، نویسندگان از EnergyPlus برای طراحی یک طرح پیش‌بینی مبتنی بر سناریو برای پیش‌بینی مصرف انرژی سرمایشی ساختمان استفاده کردند. آنها همچنین یک روش پیش‌بینی مبتنی بر XGBoost را برای پیش‌بینی تغییرات آب و هوایی آینده توسعه دادند. امیری و همکاران (۲۰۲۱) یک مدل پیش‌بینی برای مصرف انرژی حمل و نقل خانوار با استفاده از نظرسنجی سفر خانوار کمیسیون برنامه‌ریزی منطقه‌ای دره دلاور، که به عنوان یک مجموعه داده منبع باز در دسترس است، توسعه دادند [۴۳]. وانگ و همکاران (۲۰۱۸) یک روش پیش‌بینی مصرف برق ساعتی مرتبط با جنگل تصادفی (RF) برای دو ساختمان آموزشی واقع در دانشگاه فلوریدا معرفی کردند [۴۲]. برای اثبات عملکرد بهبود یافته مدل RF، آنها یک مقایسه عملکرد با استفاده از درخت تصمیم (DT) و رگرسیون بردار پشتیبان (SVR) انجام دادند. بلاهسن و داگدوگی (2021) پیش‌بینی بار

کوتاه‌مدت (STLF) برای فواصل ۱۵ دقیقه، ۲ ساعت و ۲۴ ساعت جلوتر برای پنج ساختمان در مونترال، کلاندا انجام دادند [۴۳]. آنها روش STLF را با استفاده از حافظه بلند مدت کوتاه (LSTM)، پرسپترون چندلایه (MLP)، شبکه LSTM توالی به توالی، نزدیک‌ترین همسایه‌ها و RF ساختند. برای شبیه‌سازی هشت اقامتگاه مختلف در پرتغال، بلمونته و همکاران (۲۰۱۹) نتایج خود را بر اساس کیفیت هوای داخلی کالیبره کردند و به خطای ریشه میانگین مربعات بین ۵٪ تا ۱۰٪ اشاره کردند [۴۴]. آنها تأثیر سیستم تهویه مکانیکی را بر اساس مصرف CO2 ارزیابی کردند. پیرا و همکاران (2017)، ساختمان‌های مسکونی در اقلیم‌های معتدل را ارزیابی کردند و گزارش دادند که رفتار ساکنان در دستیابی به سطح کیفیت هوای داخلی (IAQ) و راحتی حرارتی بالا، که تحت تأثیر عوامل زیادی به طور همزمان قرار دارد، مؤثر است [۴۵]. علاوه بر این، پرهیزکار و همکاران (۲۰۲۱) یک مدل پیش‌بینی ترکیبی جدید با استفاده از تحلیل مؤلفه اصلی (PCA) برای پیش‌بینی مصرف انرژی در حالی که تاریخچه را در نظر می‌گیرد، توسعه دادند [۴۶]. تحلیل رگرسیون چندمتغیره مصرف انرژی را برای طراحی بهینه محیط ساختمان پیش‌بینی کرد. گو و همکاران (۲۰۱۸) چهار تکنیک یادگیری ماشین (ML) را برای پیش‌بینی نیازهای انرژی سیستم‌های گرمایشی مقایسه کردند: شبکه‌های عصبی پس‌انتشار، SVR، رگرسیون خطی چندگانه (MLR)، و تکنیک یادگیری شدید [۴۷].

آزمون‌های دقت پیش‌بینی نشان داد که روش پیشنهادی ممکن است از نظر کارایی از مدل‌های جایگزین بهتر عمل کند. مشارکت اصلی مقاله به شرح زیر است:

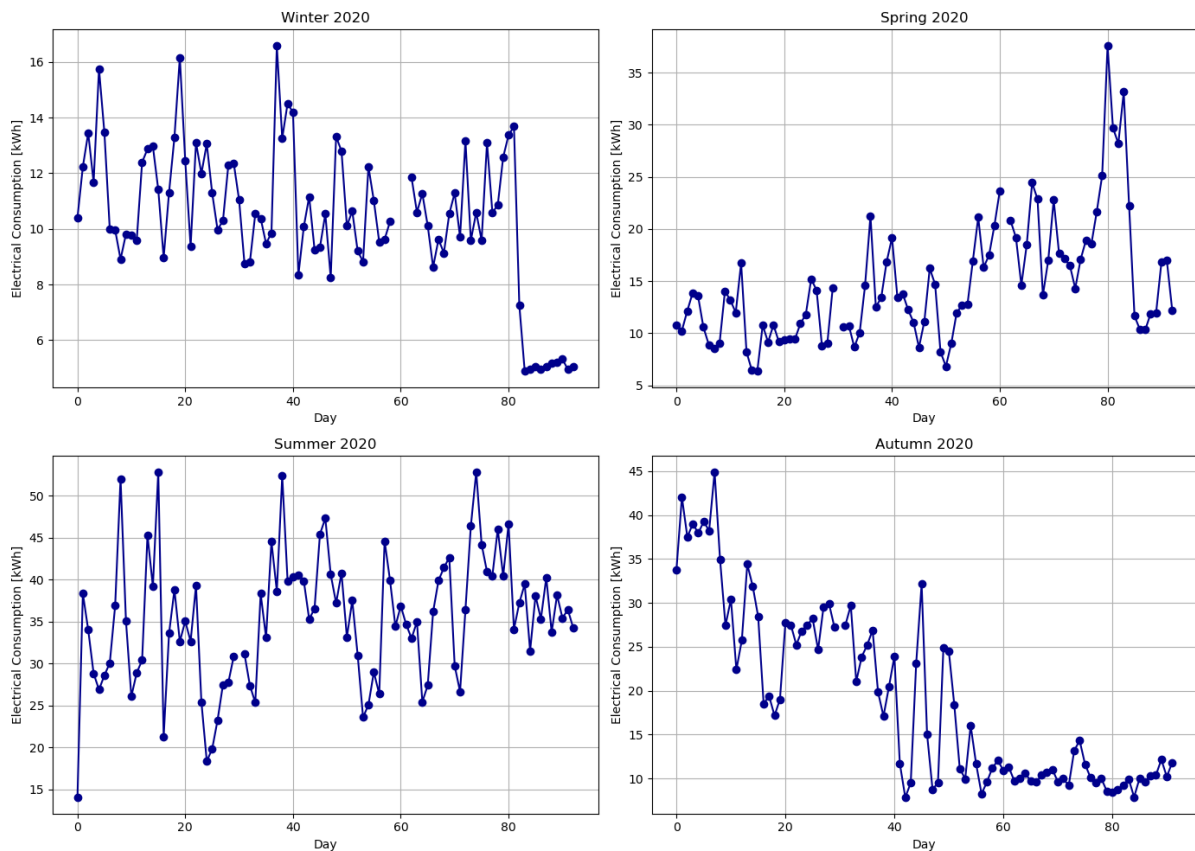
- یک رویکرد ترکیبی جدید برای پیش‌بینی مصرف برق که مدل LSTM را با مدل تجزیه حالت متغیر و مدل انتخاب ویژگی مبتنی بر اطلاعات متقابل ترکیب می‌کند.
- پیاده‌سازی موفقیت‌آمیز در یک خانه هوشمند دو طبقه واقعی واقع در هیوستون، تگزاس، ایالات متحده، و تحلیل مقایسه‌ای با مدل‌های معیار و تکی دیگر با استفاده از معیارهای خطا.

## ۲. مواد و روش‌ها

### ۲-۱- مطالعه موردی

مجموعه داده‌ای که در این مقاله مورد استفاده قرار گرفته، از یک خانه دوطبقه واقع در هیوستون، تگزاس، ایالات متحده جمع‌آوری شده است. داده‌های ثبت‌شده توسط کنتورهای هوشمند شامل مصرف ساعتی انرژی بر حسب کیلووات‌ساعت در بازه زمانی بین سال‌های ۲۰۱۹ تا ۲۰۲۰ می‌باشد. بارهای الکتریکی موجود در این خانه شامل یک دستگاه DVR امنیتی، دوربین‌های POI، دو یخچال، و دو آبگرم‌کن ۵۰ گالن (معادل ۳۷۸ لیتر) هستند که در طول روز فعال هستند. در طول شب، انواع لامپ‌ها، تلویزیون‌ها، ماشین لباسشویی، خشک‌کن و سیستم تهویه مطبوع (AC) از ساعت ۶ عصر تا ۸ صبح فعال می‌باشند. نمایه

مصرف ساعتی برق یک خانه هوشمند دوطبقه در مدت یک سال (چهار فصل) در شکل ۱ نشان داده شده است.



شکل ۱: مصرف برق ساعتی برای یک خانه هوشمند دو طبقه (کیلووات)

که در آن  $x$  و  $y$  به ترتیب ورودی‌ها و هدف را نشان می‌دهند. ویژگی‌های غیرمرتبط از MI بزرگ، مشابه یا صفر بین ورودی و هدف نتیجه می‌گیرند. همانطور که در معادله (۱) نشان داده شده است، هدف  $y$  و ورودی  $x$  با  $n$  و  $m$  متغیر به ترتیب، برای رتبه‌بندی ویژگی‌های ورودی استفاده می‌شوند. علاوه بر این، با استفاده از ورودی‌های کاندید و مقدار MI، آستانه می‌تواند به طور مرتبط‌تری تعریف شود.

### ۲-۳- شبکه عصبی LSTM

Hochreiter و Schmidhuber اولین بار معماری LSTM را در [۵۳] معرفی کردند. سپس توسط دیگران بهبود یافت تا عملکرد مطلوب‌تری در [۵۴] و [۵۵] به دست آید. شبکه LSTM نوعی شبکه عصبی بازگشتی است که با یادگیری وابستگی‌ها برای مدت طولانی مشخص می‌شود. برخلاف RNN ساده، شبکه LSTM دارای مکانیزم‌های داخلی است که به وسیله آن می‌تواند اطلاعات را در طول زمان حفظ یا رها کند.

$$g_f = \sigma(W_{fx} \cdot X_t + W_{fh} \cdot h_{t-1} + b_f) \quad (2)$$

$$g_i = \sigma(W_{ix} \cdot X_t + W_{ih} \cdot h_{t-1} + b_i) \quad (3)$$

$$g_o = \sigma(W_{ox} \cdot X_t + W_{oh} \cdot h_{t-1} + b_o) \quad (4)$$

### ۲-۲- رویکرد انتخاب ویژگی

به طور گسترده‌ای در یادگیری ماشین اعمال می‌شود، جایی که ما یک زیرمجموعه از ویژگی‌های موجود داده‌ها را برای استفاده در الگوریتم یادگیری انتخاب می‌کنیم [۴۸]. مطلوب‌ترین زیرمجموعه دارای کمترین تعداد ویژگی‌های کلیدی است که در دقت دخیل هستند؛ در حالی که ویژگی‌های باقی‌مانده که مهم نیستند حذف می‌شوند. اطلاعات متقابل (MI) یک رویکرد انتخاب ویژگی است که اخیراً بر اساس مفهوم آنروپی معرفی شده و به شدت برای انتخاب ویژگی در مسائل طبقه‌بندی اعمال می‌شود [۴۹]–[۵۱]. ارتباط: با در نظر گرفتن MI برای ورودی و خروجی، شباهت بین هدف و ورودی به عنوان یک ضرورت اصلی به دست می‌آید. MI در طول فیلتر کردن ورودی با استفاده از تعریف زیر محاسبه می‌شود [۵۲]:

$$MI(x, y) = \sum_{i=1}^n \sum_{j=1}^m P(x_i, y_j) \log_2 \left( \frac{P(x_i, y_j)}{P(x_i)P(y_j)} \right) \quad (1)$$

مرحله ۳: با در نظر گرفتن رویکرد انتخاب ویژگی مبتنی بر MI، بهترین کاندیدها به عنوان ورودی‌ها انتخاب می‌شوند.

مرحله ۴: ارزیابی مدل با استفاده از شاخص‌های مختلف خطا مانند RMSE، MAE و R انجام می‌شود.

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (x_{real_i} - x_{predicted_i})^2} \quad (8)$$

$$MAE = \frac{1}{m} \sum_{i=1}^m |x_{real_i} - x_{predicted_i}| \quad (9)$$

که در آن  $m$  تعداد نمونه‌ها،  $x_{real_i}$  و  $x_{predicted_i}$  به ترتیب مقادیر واقعی و پیش‌بینی شده هستند. این معیارها ارزیابی جامعی از دقت و قابلیت اطمینان مدل ارائه می‌دهند. RMSE و MAE میزان خطاهای پیش‌بینی را اندازه‌گیری می‌کنند، در حالی که  $R$  قدرت رابطه بین مقادیر پیش‌بینی شده و واقعی را ارزیابی می‌کند. این شاخص‌ها به درک اثربخشی مدل پیش‌بینی ترکیبی در پیش‌بینی مصرف برق ساختمان کمک می‌کنند.

مرحله ۵: پس از آزمایش همه ترکیبات پارامترهای قبل تنظیم، یا بهترین پارامتر بر اساس تابع خطا انتخاب شدند و یا پارامتر بر اساس روش انتخاب ویژگی تغییر داده شده، سپس به مرحله ۲ باز میگردد.

#### ۴. نتایج

همانطور که در بخش‌های قبلی بحث شد، هدف این مطالعه ارائه یک مدل ترکیبی برای پیش‌بینی مصرف برق ساختمان است. برای پیش‌بینی هدف، داده‌های ورودی متعدد (مقادیر تأخیری مختلف) استفاده می‌شوند. برای پیش‌بینی مصرف برق ساختمان در این مطالعه موردی، سه مدل شامل GRNN، ANFIS و MI-LSTM پیشنهاد شده‌اند. علاوه بر این، چهار شکل مختلف داده (روزهای هفته، آخر هفته، و تعطیلات) در این مقاله استفاده شده‌اند. نتایج پیش‌بینی مدل‌های مختلف برای تعطیلات (۲۰ دسامبر ۲۰۱۹ تا ۱ ژانویه ۲۰۲۰)، روزهای هفته (۲-۳ آوریل ۲۰۲۰)، و آخر هفته (۵ آوریل ۲۰۲۰) در جدول ۱ ارائه شده است. همانطور که نتایج جدول ۱ نشان می‌دهد، مدل پیشنهادی در پیش‌بینی مصرف برق از تکنیک‌های موجود دیگر بهتر عمل می‌کند.

جدول ۱: مقایسه عملکرد روش‌های پیش‌بینی در مرحله آزمایش، در تعطیلات، روزهای هفته، و روزهای آخر هفته

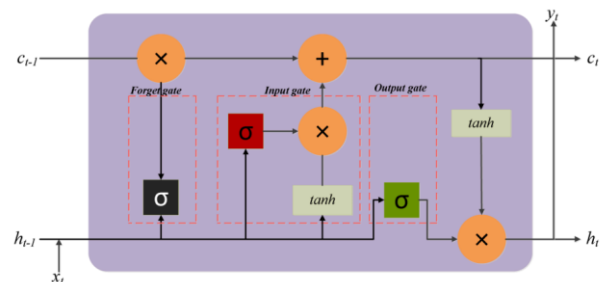
Time	Methods	RMSE	MBE	MAPE	MAE	R
Vacation	GRNN	0.124	0.024	50.497	0.103	0.668
	ANFIS	0.138	0.044	58.898	0.117	0.701
	Proposed model	0.070	-0.075	29.248	0.062	0.894
Weekday	GRNN	0.287	0.022	26.730	0.145	0.444

$$C_t = g_f \cdot C_{t-1} + g_i \cdot \tanh(W_{cx} \cdot X_t + W_{ch} \cdot h_{t-1} + b_c) \quad (5)$$

$$h_t = g_o \cdot \tanh(C_t) \quad (6)$$

$$y_t = \sigma(W_y \cdot h_t + b_y) \quad (7)$$

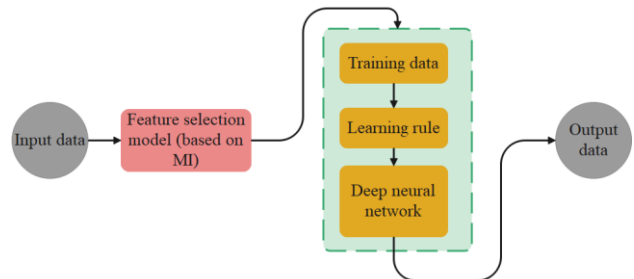
که در آن  $g_f, g_i, g_o, g_f$  به ترتیب مقادیر مربوط به حالت دروازه فراموشی، حالت دروازه خروجی، حالت دروازه ورودی، سلول حافظه و حالت پنهان در زمان  $t$  را نشان می‌دهند.  $\tanh$  و  $\sigma$  تابع تانژانت هایپربولیک و همچنین تابع سیگموئید هستند،  $W$  و  $b$  نشان‌دهنده بردار بایاس و ماتریس وزن هستند. معماری شبکه LSTM در شکل ۲ نشان داده شده است.



شکل ۲: معماری شبکه LSTM

#### ۳. روش پیش‌بینی هوشمند ترکیبی پیشنهادی

نمودار بلوکی مدل پیش‌بینی ترکیبی پیشنهادی برای پیش‌بینی مصرف برق ساختمان در شکل ۳ نشان داده شده است.



شکل ۳: نمودار بلوکی مدل پیش‌بینی هوشمند ترکیبی پیشنهادی

رویکرد پیشنهادی شامل مراحل زیر است:

مرحله ۱: پردازش داده‌های جمع‌آوری شده.

مرحله ۲: پیش‌بینی مصرف برق با مقادیر تأخیری مختلف سیگنال

اصلی نیاز به ساخت مجموعه ورودی کاندیدها به عنوان متغیرها دارد.

Weekend	ANFIS	0.331	0.027	35.013	0.191	0.378
	Proposed model	0.121	0.011	21.995	0.101	0.882
	GRNN	0.257	0.015	22.332	0.159	0.857
	ANFIS	0.527	0.017	40.067	0.304	0.683
	Proposed model	0.181	0.010	31.045	0.138	0.927

جدول ۳: مقایسه عملکرد روش‌های پیش‌بینی در مرحله آزمایش در ماه آوریل



Time	Methods	RMSE	MBE	MAPE	MAE	R
March	GRNN	0.479	0.039	40.726	0.257	0.529
	ANFIS	0.313	0.024	30.672	0.165	0.735
	Proposed model	0.161	-0.075	24.517	0.116	0.884

با توجه به نتایج جدول ۱، مدل پیشنهادی می‌تواند الگوهای مصرف برق ساختمان را در شرایط مختلف با دقت بالا و قابل اعتمادتر نسبت به مدل‌های پیش‌بینی معتبر دیگر در دوره‌های زمانی مختلف (تعطیلات، روزهای هفته و آخر هفته) پیش‌بینی کند. همچنین، مقادیر پیش‌بینی شده و واقعی مصرف برق و ضریب همبستگی مدل‌های پیش‌بینی در ماه‌های مارس و آوریل ۲۰۲۰ در به ترتیب در شکل‌های ۵ و ۶ ارائه شده است.


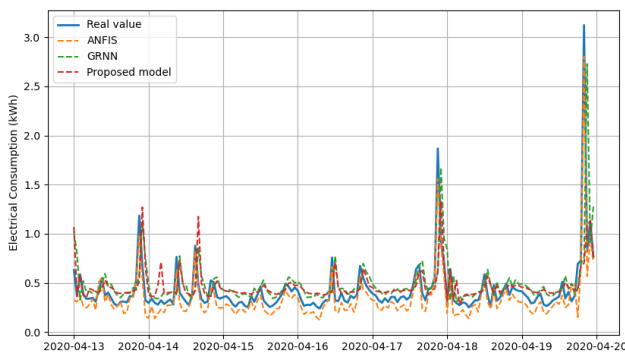
اگرچه مصرف برق در تعطیلات، روزهای هفته و آخر هفته نوسانات مختلفی دارد، مدل پیشنهادی (MI-LSTM) می‌تواند چنین داده‌هایی را به دقت پیش‌بینی کند. مقادیر کمتر RMSE و MAE و مقدار بالای R نسبت به روش‌های دیگر این ادعا را تأیید می‌کند. در این مطالعه، الگوی مصرف برق ساختمان توسط مدل پیشنهادی تحلیل و پیش‌بینی شده است. بر اساس زمان‌های ثبت شده قرنطینه، دو دوره زمانی مختلف (۱۹-۳۱ مارس ۲۰۲۰ و ۳۰-۱۳ آوریل ۲۰۲۰) در ارزیابی مدل پیشنهادی در نظر گرفته شدند. نتایج در جدول ۲ نشان داده شده است.

جدول ۲: مقایسه عملکرد روش‌های پیش‌بینی در مرحله آزمایش در ماه مارچ

Time	Methods	RMSE	MBE	MAPE	MAE	R
April	GRNN	0.305	0.006	25.958	0.139	0.736
	ANFIS	0.447	0.038	37.817	0.236	0.531
	Proposed model	0.143	-0.103	23.434	0.113	0.933



شکل ۵: مقایسه مدل‌های پیش‌بینی ارائه شده برای ماه مارچ ۲۰۲۰



شکل ۶: مقایسه مدل‌های پیش‌بینی ارائه شده برای ماه آوریل ۲۰۲۰

- [11] M. Ishaq and S. Kwon, "Short-term energy forecasting framework using an ensemble deep learning approach," *IEEE Access*, vol. 9, pp. 94262–94271, 2021.
- [12] P. Matrenin, M. Safaraliev, and S. Dmitriev, "Medium-term load forecasting in isolated power systems based on ensemble machine learning models," *Energy Reports*, vol. 8, pp. 612–618, 2022.
- [13] T. Ahmad and H. Zhang, "Novel deep supervised ML models with feature selection approach for large-scale utilities and buildings short and medium-term load requirement forecasts," *Energy*, vol. 209, p. 118477, 2020.
- [14] J. Gu, J. Wang, C. Qi, C. Min, and B. Sundén, "Medium-term heat load prediction for an existing residential building based on a wireless on-off control system," *Energy*, vol. 152, pp. 709–718, 2018.
- [15] I. Ghalekhondabi, E. Ardjmand, G. R. Weckman, and W. A. Young, "An overview of energy demand forecasting methods published in 2005–2015," *Energy Syst.*, vol. 8, no. 2, pp. 411–447, 2017.
- [16] S. Yang and L. Shi, "Prediction of long-term energy consumption trends under the New National Urbanization Plan in China," *J. Clean. Prod.*, vol. 166, pp. 1144–1153, 2017.
- [17] S. J. Oh, K. C. Ng, K. Thu, W. Chun, and K. J. E. Chua, "Forecasting long-term electricity demand for cooling of Singapore's buildings incorporating an innovative air-conditioning technology," *Energy Build.*, vol. 127, pp. 183–193, 2016.
- [18] N. Wei, C. Li, X. Peng, F. Zeng, and X. Lu, "Conventional models and artificial intelligence-based models for energy consumption forecasting: A review," *J. Pet. Sci. Eng.*, vol. 181, p. 106187, 2019.
- [19] J. Devaraj, R. Madurai Elavarasan, G. M. Shafiullah, T. Jamal, and I. Khan, "A holistic review on energy forecasting using big data and deep learning models," *Int. J. Energy Res.*, vol. 45, no. 9, pp. 13489–13530, 2021.
- [20] H. Wang, Z. Lei, X. Zhang, B. Zhou, and J. Peng, "A review of deep learning for renewable energy forecasting," *Energy Convers. Manag.*, vol. 198, p. 111799, 2019.
- [21] S. Maldonado, A. Gonzalez, and S. Crone, "Automatic time series analysis for electric load forecasting via support vector regression," *Appl. Soft Comput.*, vol. 83, p. 105616, 2019.
- [22] M. Shao, X. Wang, Z. Bu, X. Chen, and Y. Wang, "Prediction of energy consumption in hotel buildings via support vector machines," *Sustain. Cities Soc.*, vol. 57, p. 102128, 2020.
- [23] A. Boudjella and M. Y. Boudjella, "Heating Load Energy Performance of Residential Building: Machine Learning-Cluster K-Nearest Neighbor CKNN (Part I)," in *International Conference in Artificial Intelligence in Renewable Energetic Systems*, 2020, pp. 425–435.
- [24] A. Boudjella and M. Y. Boudjella, "Cooling Load Energy Performance of Residential Building: Machine Learning-Cluster K-Nearest Neighbor CKNN (Part I)," in *International Conference in Artificial Intelligence in Renewable Energetic Systems*, 2020, pp. 436–446.
- [25] Y. Dong, X. Ma, and T. Fu, "Electrical load forecasting: A deep learning approach based on K-nearest neighbors," *Appl. Soft Comput.*, vol. 99, p. 106900, 2021.
- [26] M. D. C. Ruiz-Abellón, A. Gabaldón, and A. Guillamón, "Load forecasting for a campus university using ensemble methods based on regression trees," *Energies*, vol. 11, no. 8, p. 2038, 2018.
- [27] E. Elbeltagi and H. Wefki, "Predicting energy consumption for residential buildings using ANN through parametric modeling," *Energy Reports*, vol. 7, pp. 2534–2545, 2021.
- [28] S. Lee, S. Jung, and J. Lee, "Prediction model based on an artificial neural network for user-based building energy consumption in South Korea," *Energies*, vol. 12, no. 4, p. 608, 2019.
- [29] A. Ahmad, N. Javaid, M. Guizani, N. Alrajeh, and Z. A. Khan, "An accurate and fast converging short-term load forecasting model for industrial applications in a smart grid," *IEEE Trans. Ind. Informatics*, vol. 13, no. 5, pp. 2587–2596, 2016.
- [30] W. Kong *et al.*, "Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network," *IEEE Trans. Smart Grid*, vol. 10, no. 1, pp. 841–851, 2019, doi: 10.1109/TSG.2017.2753802.

بر اساس نتایج شکل‌های ۵ و ۶، مدل پیشنهادی قادر است الگوهای مصرف برق ساختمان را در شرایط مختلف با دقت بالا و قابل اعتمادتر نسبت به مدل‌های پیش‌بینی معتبر دیگر پیش‌بینی کند.

## ۵. نتیجه‌گیری

این مطالعه یک روش پیش‌بینی ترکیبی را پیشنهاد داد که هدف آن پیش‌بینی الگوهای مصرف برق ساختمان است. روش پیشنهادی شامل یک تحلیل مبتنی بر اطلاعات متقابل به عنوان تکنیک انتخاب ویژگی و استفاده از شبکه‌های عصبی حافظه بلند مدت کوتاه (LSTM) به عنوان پیش‌بینی‌کننده است. ارزیابی این مدل شامل استفاده از مجموعه داده‌های واقعی از یک ساختمان هوشمند که شامل مصرف برق است، می‌شود. علاوه بر این، چهار نوع داده برای ارزیابی کارایی و عملکرد پیش‌بینی مدل پیشنهادی استفاده شده‌اند: الف) روزهای هفته، ب) آخر هفته، و ج) تعطیلات. تحقیقات مقایسه‌ای نشان داد که در مقایسه با روش‌های دیگر، روش پیشنهادی خطاهای کمتری داشت و قابل اعتمادتر بود. سه شاخص خطا-MAE، RMSE، و R برای ارزیابی بیشتر اعتبار مدل پیشنهادی در نظر گرفته شدند. نتایج به دست آمده نشان داد که در زمان قرنطینه، مقادیر RMSE برای ANFIS، GRNN، و مدل پیشنهادی به ترتیب ۰.۲۲۳، ۰.۳۳۲، و ۰.۱۲۴ بودند. نتایج به دست آمده نشان داد که مدل پیشنهادی از نظر قابلیت اطمینان، دقت و توانایی پیش‌بینی از GRNN و ANFIS پایه بهتر عمل می‌کند.

## مراجع

- [1] K. W. Mui, M. K. Satheesan, and L. T. Wong, "Building cooling energy consumption prediction with a hybrid simulation Approach: Generalization beyond the training range," *Energy Build.*, vol. 276, p. 112502, 2022.
- [2] Z. A. Khan *et al.*, "Efficient short-term electricity load forecasting for effective energy management," *Sustain. Energy Technol. Assessments*, vol. 53, p. 102337, 2022.
- [3] Y. Chen, M. Guo, Z. Chen, Z. Chen, and Y. Ji, "Physical energy and data-driven models in building energy prediction: A review," *Energy Reports*, vol. 8, pp. 2656–2671, 2022.
- [4] Y. Zhang, B. K. Teoh, M. Wu, J. Chen, and L. Zhang, "Data-driven estimation of building energy consumption and GHG emissions using explainable artificial intelligence," *Energy*, vol. 262, p. 125468, 2023.
- [5] S. Kapp, J. K. Choi, and T. Hong, "Predicting industrial building energy consumption with statistical and machine-learning models informed by physical system parameters," *Renew. Sustain. Energy Rev.*, vol. 172, p. 113045, 2023.
- [6] K. Amasyali and N. M. El-Gohary, "A review of data-driven building energy consumption prediction studies," *Renew. Sustain. Energy Rev.*, vol. 81, pp. 1192–1205, 2018.
- [7] Y. Wei *et al.*, "A review of data-driven approaches for prediction and classification of building energy consumption," *Renew. Sustain. Energy Rev.*, vol. 82, pp. 1027–1047, 2018.
- [8] H. Esen, M. Esen, and O. Ozsolak, "Modelling and experimental performance analysis of solar-assisted ground source heat pump system," *J. Exp. Theor. Artif. Intell.*, vol. 29, no. 1, pp. 1–17, 2017.
- [9] L. Zhang and J. Wen, "A systematic feature selection procedure for short-term data-driven building energy forecasting model development," *Energy Build.*, vol. 183, pp. 428–442, 2019.
- [10] C. Ghenai, O. A. A. Al-Mufti, O. A. M. Al-Isawi, L. H. L. Amirah, and A. Merabet, "Short-term building electrical load forecasting using adaptive neuro-fuzzy inference system (ANFIS)," *J. Build. Eng.*, vol. 52, p. 104323, 2022.

- [50] S. Sharmin, M. Shoyaib, A. A. Ali, M. A. H. Khan, and O. Chae, "Simultaneous feature selection and discretization based on mutual information," *Pattern Recognit.*, vol. 91, pp. 162–174, 2019.
- [51] Z. Sun *et al.*, "Mutual information based multi-label feature selection via constrained convex optimization," *Neurocomputing*, vol. 329, pp. 447–456, 2019.
- [52] G. Memarzadeh and F. Keynia, "A new short-term wind speed forecasting method based on fine-tuned LSTM neural network and optimal input sets," *Energy Convers. Manag.*, vol. 213, p. 112824, 2020.
- [53] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [54] A. Graves and J. Schmidhuber, "Framewise phoneme classification with bidirectional LSTM and other neural network architectures," *Neural Networks*, vol. 18, no. (5-6), pp. 602–610, 2005.
- [55] M. F. Ahammed, A. A. Molla, R. Kadir, and M. I. Kadir, "Deep bidirectional LSTM for the signal detection of universal filtered multicarrier systems," *Mach. Learn. with Appl.*, vol. 10, p. 100425, 2022.
- [31] C. Cui, M. He, F. Di, Y. Lu, Y. Dai, and F. Lv, "Research on power load forecasting method based on LSTM model," in *2020 IEEE 5th Information Technology and Mechatronics Engineering Conference (ITOEC)*, 2020, pp. 1657–1660.
- [32] K. Amarasinghe, D. L. Marino, and M. Manic, "Deep neural networks for energy load forecasting," in *26th International Symposium on Industrial Electronics (ISIE)*, 2017, pp. 1483–1488.
- [33] M. Cai, M. Pipattanasomporn, and S. Rahman, "Day-ahead building-level load forecasts using deep learning vs. traditional time-series techniques," *Appl. Energy*, vol. 236, pp. 1078–1088, 2019.
- [34] K. Yan, W. Li, Z. Ji, M. Qi, and Y. Du, "A hybrid LSTM neural network for energy consumption forecasting of individual households," *IEEE Access*, vol. 7, pp. 157633–157642, 2019.
- [35] N. Somu, G. R. MR, and K. Ramaritham, "A hybrid model for building energy consumption forecasting using long short term memory networks," *Appl. Energy*, vol. 261, p. 114131, 2020.
- [36] T. Y. Kim and S. B. Cho, "Particle swarm optimization-based CNN-LSTM networks for forecasting energy consumption," in *2019 IEEE congress on evolutionary computation*, 2019, pp. 1510–1516.
- [37] S. Bouktif, A. Fiaz, A. Ouni, and M. A. Serhani, "Multi-sequence LSTM-RNN deep learning and metaheuristics for electric load forecasting," *Energies*, vol. 13, no. 2, p. 391, 2020.
- [38] S. Bouktif, A. Fiaz, A. Ouni, and M. A. Serhani, "Optimal deep learning lstm model for electric load forecasting using feature selection and genetic algorithm: Comparison with machine learning approaches," *Energies*, vol. 11, no. 7, p. 1636, 2018.
- [39] X. J. Luo and L. O. Oyedele, "Forecasting building energy consumption: Adaptive long-short term memory neural networks driven by genetic algorithm," *Adv. Eng. Informatics*, vol. 50, p. 101357, 2021.
- [40] L. Peng, Q. Zhu, S. X. Lv, and L. Wang, "Effective long short-term memory with fruit fly optimization algorithm for time series forecasting," *Soft Comput.*, vol. 24, no. 19, pp. 15059–15079, 2020.
- [41] J. Moon, S. Rho, and S. W. Baik, "Toward explainable electrical load forecasting of buildings: A comparative study of tree-based ensemble methods with Shapley values," *Sustain. Energy Technol. Assessments*, vol. 54, p. 102888, 2022.
- [42] D. Chakraborty, A. Alam, S. Chaudhuri, H. Başağaoğlu, T. Sulbaran, and S. Langar, "Scenario-based prediction of climate change impacts on building cooling energy consumption with explainable artificial intelligence," *Appl. Energy*, vol. 291, p. 116807, 2021.
- [43] S. S. Amiri, S. Mottahedi, E. R. Lee, and S. Hoque, "Peeking inside the black-box: Explainable machine learning applied to household transportation energy consumption," *Comput. Environ. Urban Syst.*, vol. 88, p. 101647, 2021.
- [44] J. F. Belmonte, R. Barbosa, and M. G. Almeida, "CO2 concentrations in a multifamily building in Porto, Portugal: Occupants' exposure and differential performance of mechanical ventilation control strategies," *J. Build. Eng.*, vol. 23, pp. 114–126, 2019.
- [45] P. F. Pereira, N. M. Ramos, R. M. Almeida, M. L. Simões, and E. Barreira, "Occupant influence on residential ventilation patterns in mild climate conditions," *Energy Procedia*, vol. 132, pp. 837–842, 2017.
- [46] T. Parhizkar, E. Rafieipour, and A. Parhizkar, "Evaluation and improvement of energy consumption prediction models using principal component analysis based feature reduction," *J. Clean. Prod.*, vol. 279, p. 123866, 2021.
- [47] Y. Guo *et al.*, "Machine learning-based thermal response time ahead energy demand prediction for building heating systems," *Appl. Energy*, vol. 221, pp. 16–27, 2018.
- [48] N. Amjady and F. Keynia, "Day-ahead price forecasting of electricity markets by mutual information technique and cascaded neuro-evolutionary algorithm," *IEEE Trans. Power Syst.*, vol. 24, no. 1, pp. 306–318, 2008.
- [49] N. Kwak and C. H. Choi, "Input feature selection for classification problems," *IEEE Trans. Neural Networks*, vol. 13, no. 1, pp. 143–159, 2002.