



Development of Cyclic Seasonal Encoding to Predict the Effect of Dynamic Occupancy on Building Energy Consumption Using Neural-Network Surrogate

Sam Sarlak Goodarzi¹ | Behrang Sajadi^{2*}

1. M.Sc. Student, Department of Mechanical Engineering, College of Engineering, University of Tehran, Tehran, Tehran, Iran. Email: sam.sarlak@ut.ac.ir

2. Corresponding Author, Associate Professor, Department of Mechanical Engineering, College of Engineering, University of Tehran, Tehran, Tehran, Iran. Email: bsajadi@ut.ac.ir

ARTICLE INFO

Article type:
Research Paper

Article History:

Received: 19 February 2026

Revised: 16 March 2026

Accepted: 17 May 2026

Published Online: 23 September 2026

Keywords:

Building Energy Consumption Prediction,
Occupant-centered Energy Analysis,
Occupant Presence,
Cyclical Time Encoding,
Energy Plus.

ABSTRACT

Accurate prediction of building energy consumption for improving efficiency and reducing simulation costs requires an appropriate representation of occupant presence. In this study, occupant presence patterns at an hourly scale were encoded as continuous variables, and the months of the year were encoded cyclically (using sine and cosine functions) and used as inputs to EnergyPlus simulations and machine learning models. This approach, in contrast to discrete definitions or fixed occupancy rates, enables the analysis of the differing effects of presence across hours and seasons and improves the model's ability to generalize to new conditions. After designing an artificial neural network capable of accurately predicting the monthly average total HVAC electricity demand rate, SHAP analysis and partial dependence plots showed that midday and afternoon hours have the greatest impact on energy loads and further revealed that changing the level of occupancy at different hours of the day, across winter and summer, has distinct and markedly nonlinear effects on energy use. Finally, it was shown that shifting the start time of occupancy, without any physical changes to the building, can optimize energy consumption and provides an occupant-centric framework for intelligent building energy management. Finally, the results indicated that optimizing the timing of occupied windows throughout the year for a simple schedule can lead to reduction in the monthly average demand rate up to approximately 15%.

Cite this article: Sarlak Goodarzi, S. & Sajadi, B. (2026). Development of Cyclic Seasonal Encoding to Predict the Effect of Dynamic Occupancy on Building Energy Consumption Using Neural-Network Surrogate. *Journal of Sustainable Energy Systems*, 5 (4), 787-807. DOI: <http://doi.org/10.22059/ses.2026.414083.1239>



© Authors retain the copyright and full publishing rights.
DOI: <http://doi.org/10.22059/ses.2026.414083.1239>

Publisher: University of Tehran Press.

1. Introduction

Occupant presence affects internal heat gains, ventilation demand, and HVAC operation, yet many building models represent it using fixed densities or a few discrete schedules. This study combines continuous hourly occupancy inputs with cyclical month encoding to predict monthly average HVAC electric demand power and examine occupancy scheduling as a low-cost energy-management strategy.

2. Materials and Methods

A validated single-zone EnergyPlus model was simulated for Tehran using fixed envelope properties, HVAC settings, thermostat setpoints, and occupant density. A total of 2,880 simulations were generated, including 240 occupancy schedules per month. Each schedule contained 24 hourly

occupancy fractions between zero and one and covered standard patterns, Gaussian-jittered variations, block schedules, night shifts, and fully occupied or unoccupied cases. Month was encoded using sine and cosine functions, producing 26 inputs for a multilayer perceptron with hidden layers of 128 and 64 neurons. SHAP values and partial dependence plots were used for interpretation.

3. Results

The neural-network surrogate achieved an R^2 of 0.963 on the test data, demonstrating its ability to reproduce the nonlinear relationship among hourly occupancy, season, and monthly average HVAC demand power. Similar training and validation losses and an approximately symmetric residual distribution indicated satisfactory generalization and no clear systematic bias.

SHAP analysis identified the sine and cosine components of month as the most influential variables, confirming that seasonal heating and cooling conditions dominated annual HVAC demand. Among the hourly variables, occupancy from approximately 11:00 to 16:00 had the greatest influence. Higher occupancy during these hours generally increased demand, especially during the cooling season, whereas early-morning and late-night occupancy had smaller effects.

The influence of occupancy was strongly seasonal and nonlinear. In winter, occupant heat gains could partially offset heating demand, so increasing occupancy sometimes reduced HVAC power after a certain level. In summer, higher occupancy consistently increased demand because of additional heat gains and ventilation requirements. Partial dependence analysis showed that afternoon occupancy, particularly around 16:00, caused the largest increase in July. Thus, identical occupancy fractions produced different effects depending on the hour and season.

The model was also used to compare four-hour occupancy windows with different starting times. In January, earlier occupancy could reduce heating demand by providing useful internal heat gains. In July, shifting occupancy away from warm afternoon hours reduced cooling demand. Selecting the lowest-demand starting time for each month produced a total reduction of approximately 5,230 W relative to the sum of the monthly maximum-demand cases, equivalent to about 15% of the maximum monthly average demand rate baseline. This shows that schedule adjustment alone can reduce HVAC demand without physical modifications.

4. Discussion and Conclusion

The findings show that occupancy should not be represented only by average density or total occupied hours. Its timing and interaction with seasonal conditions are also essential. Continuous hourly inputs allowed the model to evaluate schedules beyond predefined categories, while cyclical encoding preserved continuity between consecutive months.

The numerical findings are specific to the investigated single-zone building, Tehran climate, fixed envelope, and selected HVAC system. However, the methodology can be adapted to other climates, building types, and operating conditions. Future studies may extend the framework to hourly prediction, indoor environmental-quality indicators, multiple building configurations, and active-learning methods. Overall, interpretable neural-network surrogate models can identify seasonally appropriate occupancy schedules and support low-cost occupant-centric HVAC management.



انتشارات دانشگاه تهران

فصلنامه سیستم‌های انرژی پایدار

سایت نشریه: <https://ses.ut.ac.ir>

شاپا الکترونیکی: ۸۶۹۳-۲۹۸۰

توسعه کدگذاری چرخه‌ای فصلی برای پیش‌بینی تأثیر حضور پویای ساکنان بر مصرف انرژی ساختمان با استفاده از مدل جانشین شبکه عصبی

سام سرلک گودرزی^۱ | بهرنگ سجادی^{۲*}

۱. دانشجوی کارشناس ارشد، دانشکده مهندسی مکانیک، دانشکده فنی، دانشگاه تهران، تهران، ایران. رایانامه: sam.sarlak@ut.ac.ir
۲. نویسنده مسئول، دانشیار، دانشکده مهندسی مکانیک، دانشکده فنی، دانشگاه تهران، تهران، ایران. رایانامه: bsajadi@ut.ac.ir

اطلاعات مقاله

چکیده

نوع مقاله:
پژوهشی

تاریخ‌های مقاله:

تاریخ دریافت: ۱۴۰۴/۱۱/۳۰

تاریخ بازنگری: ۱۴۰۴/۱۲/۲۵

تاریخ پذیرش: ۱۴۰۵/۰۲/۲۷

تاریخ انتشار: ۱۴۰۵/۰۷/۰۱

کلیدواژه:

پیش‌بینی مصرف انرژی ساختمان،
تحلیل ساکن محور انرژی ساختمان،
حضور ساکنان،
کدگذاری چرخه‌ای زمان،
انرژی پلاس.

پیش‌بینی دقیق مصرف انرژی ساختمان برای بهبود بهره‌وری و کاهش هزینه‌های شبیه‌سازی، نیازمند بازنمایی مناسب حضور ساکنان است. در این پژوهش، الگوهای حضور ساکنان در مقیاس ساعتی به صورت پیوسته و ماه‌های سال به صورت چرخه‌ای (با توابع سینوسی و کسینوسی) کدگذاری و به عنوان ورودی شبیه‌سازی‌های انرژی پلاس و مدل‌های یادگیری ماشین استفاده شده‌اند. این رویکرد، به خلاف تعریف‌های گسسته یا نرخ‌های ثابت، امکان تحلیل اثرات متفاوت حضور در ساعت‌ها و فصل‌های مختلف و تعمیم بهتر مدل را فراهم می‌کند. پس از طراحی شبکه عصبی مصنوعی با قابلیت پیش‌بینی میانگین ماهانه توان مصرفی ساختمان با دقت زیاد، تحلیل معیار شاپلی و نمودارهای وابستگی جزئی نشان دادند ساعت‌های ظهر و بعدازظهر بیشترین تأثیر را بر بار مصرفی دارند و همچنین، آشکار کردند که تغییر میزان حضور ساکنان در ساعت‌های مختلف روز، طی فصل‌های زمستان و تابستان، اثراتی متفاوت و به طور محسوس غیرخطی بر مصارف ساختمان به جا می‌گذارد. در نهایت، نشان داده شد جابه‌جایی زمان شروع حضور، بدون تغییرات فیزیکی در ساختمان، می‌تواند مصرف انرژی را بهینه کند و چارچوبی ساکن‌محور برای مدیریت هوشمند انرژی ارائه دهد. در نهایت، نتایج نشان داد بهینه‌سازی زمان‌بندی حضور افراد طی سال، برای یک برنامه ساده، می‌تواند نرخ تقاضای انرژی در سیستم تهویه مطبوع را نسبت به خط مبنای بیشینه ماهانه تا حدود ۱۵ درصد کاهش دهد.

استناد: سرلک گودرزی، سام و سجادی، بهرنگ (۱۴۰۵). توسعه کدگذاری چرخه‌ای فصلی برای پیش‌بینی تأثیر حضور پویای ساکنان بر مصرف انرژی ساختمان با استفاده از مدل جانشین شبکه عصبی. فصلنامه سیستم‌های انرژی پایدار، ۵ (۴) ۷۸۷-۸۰۷.

DOI: <http://doi.org/10.22059/ses.2026.414083.1239>

ناشر: مؤسسه انتشارات دانشگاه تهران.

© نویسندگان.

DOI: <http://doi.org/10.22059/ses.2026.414083.1239>



۱. مقدمه

رابطه میان تولید انرژی و پیامدهای زیست‌محیطی، به مسئله‌ای محوری در توسعه پایدار تبدیل شده است. با وجود سیاست‌هایی مانند توافق پاریس، هنوز بیش از ۸۴ درصد انرژی جهان از سوخت‌های فسیلی تأمین می‌شود و روند افزایشی دمای سطح زمین و اقیانوس‌ها رکوردهای تازه‌ای از گرمایش جهانی ایجاد کرده است [۱]. در این میان، بخش ساختمان با سهمی نزدیک به ۴۰ درصد از مصرف نهایی انرژی، یکی از عوامل کلیدی در معادلات انرژی و اقلیم است که حدود ۲۱ درصد آن به ساختمان‌های مسکونی مربوط می‌شود [۱].

برآوردها نشان می‌دهد مصرف جهانی انرژی بین ۲۰۱۰ تا ۲۰۴۰ حدود ۵۶ درصد افزایش خواهد یافت و رشد جمعیت، شهرنشینی و گسترش زیربنای ساختمانی محرک اصلی افزایش تقاضای انرژی در ساختمان‌ها هستند [۲]. رفتار کاربران و کارایی پایین تجهیزات نیز می‌تواند به‌تنهایی ۲ تا ۲۲ درصد اتلاف انرژی ایجاد کند و پیش‌بینی‌ها بیانگر آن است که بار سرمایش سریع‌ترین رشد را در میان مصارف مختلف ساختمان خواهد داشت [۱]. بنابراین، بهبود بهره‌وری انرژی، بهینه‌سازی سامانه‌های سرمایشی و به‌کارگیری سامانه‌های مدیریت انرژی ساختمان و ابزارهای پیش‌بینی، به عنوان راهبردی مهم برای کاهش تقاضا و انتشار مطرح شده است [۳]. با این حال، کارایی واقعی این راه‌حل‌ها زمانی محقق می‌شود که حضور، فعالیت و رفتار ساکنان در مدل‌ها بازنمایی شود. مطالعات نشان می‌دهد شکاف بین مصرف شبیه‌سازی‌شده و واقعی در برخی پروژه‌ها می‌تواند تا چند برابر باشد و در نمونه‌ای از یک دفتر اداری، مصرف واقعی تقریباً سه برابر مقدار پیش‌بینی‌شده گزارش شده است [۴]. شواهد کمی نیز نشان می‌دهند تغییر سناریوهای رفتاری و سبک زندگی می‌تواند شدت مصرف انرژی و بارهای گرمایش/سرمایش را ده‌ها درصد جابه‌جا کند، به طوری که در برخی موارد اثر رفتار ساکنان به مراتب از مداخلات فیزیکی مانند تغییر نوع پنجره‌ها بزرگ‌تر است [۵ و ۶].

پوسته ساختمان، شامل عناصری مانند نسبت سطح پنجره به نما، جنس پنجره‌ها، عایق‌کاری، ضریب انتقال حرارت و جرم حرارتی، از اصلی‌ترین عوامل تعیین‌کننده عملکرد انرژی و بار سامانه‌های تهویه مطبوع است. در راستای بررسی اثرات پوسته ساختمان، احمد و همکاران [۷] تأثیر نوع دیوار، طراحی بام و نسبت پنجره به نما را در ساختمان‌های مسکونی واقع در اقلیم مختلط هند بررسی کردند. یک ترکیب شامل دیوار عایق، بام بهینه، جهت‌گیری شمالی و نسبت پنجره به نما پایین، بهترین عملکرد را داشت و به‌ترتیب ۲۶ درصد کاهش بار سرمایش و ۲۸ درصد کاهش بار گرمایش نسبت به بدترین حالت ایجاد کرد. در ادامه، گوپتا و دب [۸] مروری جامع بر تأثیر متغیرهای پوشش ساختمان در اقلیم‌های گرمسیری ارائه کردند. نتایج تحقیق یادشده نشان داد عایق، نوع شیشه و نسبت پنجره به نما مؤثرترین عوامل اند و به‌تنهایی عایق مناسب می‌تواند تا ۲۶ درصد صرفه‌جویی سالانه ایجاد کند. ترکیب بهینه متغیرها می‌تواند صرفه‌جویی را تا ۶۰ درصد افزایش دهد.

در کنار ویژگی‌های فیزیکی پوسته، نحوه استفاده واقعی از ساختمان و الگوهای حضور و فعالیت ساکنان نیز نقش مهمی در الگوی مصرف انرژی ایفا می‌کند. ژیهونگ پانگ و همکاران [۹] در کالج استیشن^۱ تگزاس یک مطالعه میدانی روی آپارتمان‌های مسکونی انجام دادند تا اثر ترموستات‌های هوشمند مبتنی بر حضور را بر مصرف تهویه مطبوع بسنجند. مطابق نتایج، در فصل سرمایش حدود ۱۵ درصد صرفه‌جویی رخ داد و شبیه‌سازی‌ها صرفه‌جویی ۱۹ تا ۲۴ درصد فصلی را برآورد کردند، هرچند در برخی ساعت‌های اوج، پدیده بازگشت دما و افزایش بار اوج مشاهده شد. کُنگ و همکاران [۱۰] یک مطالعه تجربی در آزمایشگاه دانشگاه سیراکیوز^۲ اجرا کردند که در آن دو اتاق اداری مشابه، یکی با برنامه زمان‌بندی ثابت و دیگری با کنترل مبتنی بر حضور تجهیز شد. نتایج نشان داد کنترل مبتنی بر حضور ۱۷ درصد تا ۲۴ درصد صرفه‌جویی هفتگی در انرژی تهویه مطبوع ایجاد کرد. نوروزی‌اصل و همکاران [۱۱] چارچوبی مبتنی بر عامل برای تولید برنامه‌های حضور واقع‌بینانه در ساختمان‌های اداری ارائه کردند. در مدل پیشنهادی سه جنبه حضور، موقعیت و تعامل با سیستم‌ها شبیه‌سازی شد. نصب حسگر حضور برای روشنایی،

1. College Station
2. Syracuse University

مصرف را ۲۴ تا ۳۳ درصد کاهش داد. این مطالعه نشان داد مدل‌سازی مبتنی بر عامل می‌تواند برنامه‌های حضور احتمالی و مقیاس‌پذیر برای ادغام در ابزارهای شبیه‌سازی عملکرد ساختمان را فراهم کند.

پیچیدگی هم‌زمان اثر پوسته، سامانه‌های فنی و رفتار ساکنان، نیاز به ابزارهای پیش‌بینی انعطاف‌پذیر و داده‌محور را برجسته می‌کند. در این چارچوب، مدل‌های یادگیری ماشین و سایر رویکردهای جعبه‌سیاه و ترکیبی، به عنوان ابزاری قدرتمند برای تقریب رفتار انرژی، بهره‌برداری و سیاست‌گذاری وارد ادبیات شده‌اند. آلواریز سانز و همکاران [۱۲] به بررسی نقش پارامترهای طراحی در تقاضای گرمایشی مسکونی پرداخته و هدف اصلی آن‌ها توسعه مدل‌های پیش‌بینی دقیق بود. تحلیل پس‌پردازشی با استفاده از روش شاپلی^۱ چهار متغیر کلیدی ضریب شکل ساختمان، نرخ نفوذ هوا، سطح معادل جنوبی و بارهای داخلی را به عنوان اثرگذارترین عوامل شناسایی کرد. همچنین نتایج، اهمیت متغیر سطح معادل جنوبی را در این ساختمان نشان داد و آن را به عنوان شاخصی مهم برای استراتژی‌های بازسازی انرژی معرفی کرد. کیم و سو [۱۳] نوعی مدل پیش‌بینی انرژی برای ساختمان‌های مسکونی بلندمرتبه در کره جنوبی توسعه دادند که بر پارامترهای پوسته ساختمان تمرکز داشت. نفوذ هوا مهم‌ترین عامل گرمایش و ضریب بهره‌برداری از گرمای خورشیدی و نسبت پنجره به نما مهم‌ترین عوامل سرمایش بودند. افزایش ضریب انتقال حرارت پنجره گرمایش را تا ۲۹ درصد افزایش و سرمایش را تا ۲۶ درصد کاهش داد.

لیو و همکاران [۱۴] نوعی روش پیش‌بینی بار الکتریکی ساختمان با استفاده از داده‌های حضور افراد مبتنی بر حسگری بی‌سیم را توسعه دادند. داده‌های پژوهش یادشده از یک ساختمان تجاری واقعی به دست آمد و اشغال فضاها از طریق تغییرات سیگنال سنسورهایی در چندین اتاق، نه از طریق شبیه‌سازی یا برنامه‌های زمان‌بندی فرضی، استخراج شد. مدل با ترکیب داده‌های بار، آب‌وهوا، تقویم و الگوی حضور افراد، تغییرات زمانی بار را در پیش‌بینی‌های کوتاه‌مدت در نظر گرفت و افزودن اطلاعات حضور افراد باعث بهبود ریشه میانگین مربعات خطا^۲ و میانگین درصد خطای مطلق^۳ به ترتیب به میزان ۱۳/۲۱ درصد و ۱۴/۹۷ درصد شد.

لیان و همکاران [۱۵] نوعی مدل پیش‌بینی مصرف انرژی ساعتی را برای یک ساختمان اداری در شانگهای توسعه دادند که داده‌های واقعی مصرف انرژی، آب‌وهوا و اشغال را ترکیب می‌کرد. اطلاعات حضور افراد در این تحقیق از رکوردهای ورود و خروج افراد با کارت‌زنی و داده‌های آب‌وهوایی از ایستگاه هواشناسی جمع‌آوری شد، بنابراین داده‌ها شبیه‌سازی شده نبودند. مدل حافظه طولانی کوتاه‌مدت^۴ اثر تغییرات زمانی را در مقیاس ساعتی و نوع روز بررسی کرد، اما به دلیل محدود بودن داده‌ها به فصل تابستان، اثر ماه‌های مختلف به صورت گسترده تحلیل نشد. با اضافه کردن داده حضور افراد، میانگین درصد خطای مطلق پیش‌بینی ساعتی از ۱۱ درصد به ۹ درصد کاهش یافت.

بررسی پژوهش‌های پیشین نشان می‌دهد بدون بازنمایی مناسب حضور و رفتار کاربران، حتی پیشرفته‌ترین ابزارهای شبیه‌سازی و مدیریت انرژی نیز تصویر دقیقی از تقاضا ارائه نمی‌دهند. در امتداد این شکاف، نوآوری‌های اصلی این پژوهش را می‌توان به صورت زیر خلاصه کرد:


۱. بازنمایی پیوسته و ساعتی حضور ساکنان به جای استفاده از چند الگوی ثابت و گسسته، به گونه‌ای که شدت و زمان وقوع حضور طی شبانه‌روز در مدل قابل بررسی باشد؛
۲. لحاظ کردن اثر زمان در دو مقیاس ساعت‌های شبانه‌روز و ماه‌های سال، به منظور بررسی هم‌زمان اثر زمان وقوع حضور و تغییرات فصلی بر نرخ تقاضای انرژی سیستم تهویه مطبوع؛
۳. به کارگیری تحلیل وابستگی جزئی برای تفسیر اثر متغیرهای حضور و زمان بر خروجی مدل و شناسایی بازه‌های زمانی مؤثرتر بر افزایش یا کاهش توان مصرفی.

1. Shapley Additive exPlanations (SHAP)
 2. Root Mean Squared Error (RMSE)
 3. Mean Absolute Percentage Error (MAPE)
 4. Long Short-Term Memory

به این ترتیب، گامی به سوی مدل‌سازی ساکن‌محور پیوسته در مقیاس ماهانه و استفاده از پنجره‌های حضور به عنوان اهرم کم‌هزینه مدیریت انرژی برداشته می‌شود.

۲. مدل‌سازی و نرم‌افزارها

در روند این تحقیق برای کاهش هزینه و زمان اجرای شبیه‌سازی‌های گسترده، ابتدا مدل ساختمان ساخته شد و ورودی‌های اصلی آن شامل مصالح، پنجره‌ها، نفوذ هوا، روشنایی، سیستم تهویه مطبوع و الگوهای حضور ساکنان در نرم‌افزار تکمیل شد. پس از اعتبارسنجی مدل با یک پژوهش مرجع، سناریوهای متنوع حضور تولید و میانگین ماهانه توان مصرفی برای هر سناریو استخراج شد. سپس، داده‌های حاصل از شبیه‌سازی برای آموزش یک شبکه عصبی پرسپترون چندلایه به عنوان مدل جایگزین استفاده شدند و نتایج به کمک روش‌های تحلیلی تفسیر شدند. روند کلی مراحل انجام کار در فلوچارت شکل ۱ نشان داده شده است.



شکل ۱. فلوچارت از روند کلی انجام تحقیق از مراحل اعتبارسنجی تا خروجی‌های مدل شبکه عصبی

۲-۱. نرم‌افزارهای مدل‌سازی

در این پژوهش، زنجیره مدل‌سازی و شبیه‌سازی مصارف ساختمان بر پایه سه رکن اصلی نرم‌افزار شبیه‌سازی انرژی ساختمان انرژی پلاس^۱ به عنوان هسته فیزیکی، محیط اسکچ‌آپ^۲ و اوپن‌استودیو^۳ برای تولید و مدیریت هندسه و فایل‌های ورودی و در نهایت کتابخانه‌های پایتونی برای خودکارسازی شبیه‌سازی‌ها و آماده‌سازی داده‌ها برای استفاده در مدل‌های یادگیری ماشین بنا شده است. در ادامه، نقش هر یک به صورت خلاصه معرفی می‌شود.

انرژی پلاس نرم‌افزار اصلی شبیه‌سازی این پژوهش است که توسط وزارت انرژی آمریکا توسعه یافته و امروزه یکی از مراجع استاندارد شبیه‌سازی انرژی ساختمان به شمار می‌رود. این نرم‌افزار با ادغام قوت‌ها BLAST و DOE-2، بار حرارتی/برودتی، سامانه‌های تهویه مطبوع و موتورخانه را به صورت یکپارچه و در گام‌های زمانی زیرساعتی حل می‌کند. امکان مدل‌سازی دقیق پوسته، بارهای داخلی و سیستم‌ها و همچنین خروجی‌گیری در قالب فایل‌های جدولی و SQL، آن را برای اتصال به ابزارهای داده‌محور و یادگیری ماشین مناسب می‌سازد.

1. EnergyPlus
2. SketchUp
3. OpenStudio


برای ایجاد و ویرایش مدل هندسی ساختمان، از چارچوب متن‌باز اوپن‌استودیو و افزونه آن در نرم‌افزار اسکچ‌آپ استفاده شده است. اسکچ‌آپ امکان ترسیم سه‌بعدی حجم و تعریف فضاها و نواحی حرارتی را فراهم می‌کند و اوپن‌استودیو این هندسه را به مدل انرژی‌پلاس تبدیل کرده و فایل‌های IDF/OSM را تولید می‌کند. در این پژوهش، ناحیه حرارتی مرجع و نسبت‌های مختلف سطح پنجره به نما ابتدا در اسکچ‌آپ و اوپن‌استودیو تعریف شده و سپس به عنوان الگوی پایه برای شبیه‌سازی‌ها به کار رفته‌اند [۱۶].

برای خودکارسازی فرایند شبیه‌سازی و آماده‌سازی داده‌ها، از زبان پایتون و کتابخانه Eppy استفاده شده است. Eppy امکان خواندن، ویرایش و تولید فایل‌های IDF و اجرای انرژی‌پلاس را به صورت برنامه‌نویسی شده فراهم می‌کند. در این کار، سناریوهای مختلف حضور ساکنان به طور خودکار در IDF اعمال، شبیه‌سازی‌ها به صورت دسته‌ای اجرا و خروجی‌های مورد نیاز استخراج و در قالب مناسب برای مدل‌های یادگیری ماشین ذخیره شده‌اند. این پیوند انرژی‌پلاس و پایتون، ستون فقرات چارچوب داده‌محور این پژوهش را شکل می‌دهد.

۲-۲. اعتبارسنجی مدل شبیه‌سازی

برای اطمینان از قابلیت اتکا، پیش از استفاده گسترده از انرژی‌پلاس به عنوان نرم‌افزار مولد داده، عملکرد مدل در برابر داده‌های مستقل تجربی اعتبارسنجی شد. برای این منظور، یک مطالعه موردی مروگانانتام^۱ در دانشگاه ایالتی آریزونا^۲ انتخاب شد [۱۷]. وی در پژوهش خود از اتاقک‌های آزمایشی یکسان برای جمع‌آوری داده استفاده کرد.

هندسه اتاقک، جنس و ضخامت دیوارها، سقف، کف، نوع پنجره و در و همچنین، مشخصات سیستم تهویه مطبوع بر اساس مستندات مرجع در اسکچ‌آپ و اوپن‌استودیو مدل‌سازی و به انرژی‌پلاس منتقل شد. آزمایش‌های این تحقیق در سوله‌ای آزمایشگاهی با ابعاد ۴/۸۸ متر طول، ۳/۶۶ متر عرض و ۲/۴۴ متر ارتفاع و با بام شیب‌دار با شیب ۱۸/۴ درجه انجام شدند. دیوارها از استادهای چوبی ۴×۲ اینچ با فاصله ۱۶ اینچ از یکدیگر، عایق فایبرگلاس R-13، نمای T-111 و پوشش داخلی گچ‌برگ ۰/۵ اینچ ساخته شده بودند. همچنین، فضای زیرشیروانی محصور بوده و در سقف از عایق فایبرگلاس R-19 استفاده شده بود. پوشش بام نیز شامل تخته OSB با ضخامت ۰/۵ اینچ، لایه نمدی ۱۵ پوندی و فایبرگلاس استاندارد بود. همچنین، سیستم تهویه مطبوع واقعی از نوع پمپ حرارتی یک‌تکه نصب‌شده روی پنجره بود که در مدل با مؤلفه Packaged Terminal Heat Pump و پارامترهای معادل تعریف شد. تنظیمات ترموستات، برنامه‌های زمانی گرمایش و سرمایش و سناریوهای حضور ساکنان نیز طبق مرجع اعمال شدند. نفوذ هوا با استفاده از مدل Effective Leakage Area و بر اساس داده‌های سازه‌ای اتاقک مدل‌سازی شد. داده‌های تجربی شامل دمای نقاط مختلف و مصرف انرژی سیستم تهویه مطبوع، همراه با شرایط آب‌وهوایی دقیق سال ۲۰۰۸ بوده است. این داده‌ها با گام زمانی ۱ دقیقه‌ای تا ۱۰ دقیقه‌ای ثبت شده و از طریق فایل آب‌وهوایی متناظر در شبیه‌سازی اعمال شد. پس از اجرای شبیه‌سازی سالانه، مصرف الکتریکی ماهانه از خروجی انرژی‌پلاس استخراج و روی نمودار با مقادیر گزارش‌شده در مرجع مقایسه شد. برای سنجش عملکرد، منحنی‌های مصرف ماهانه حاصل از شبیه‌سازی با مقادیر گزارش‌شده در مرجع تجربی در نمودار شکل ۲ قرار داده شد تا هم‌پوشانی روندها و میزان انحراف به صورت بصری قابل بررسی باشد. نتایج نشان داد روند تغییرات ماه‌به‌ماه و مقادیر مصرف شبیه‌سازی‌شده و تجربی هم‌خوانی مناسبی دارند. برای مقایسه، در استانداردهایی مانند ASHRAE Guideline 14 حدود ۱۵ درصد برای خطای ماهانه به عنوان معیار رایج اعتبارسنجی مدل‌های انرژی ساختمان مطرح شده است. بنابراین، خطای نسبی حدود ۱۷ درصد به‌دست‌آمده در این مطالعه، با توجه به خطاهای احتمالی اندازه‌گیری سنسورها، عدم قطعیت داده‌های واقعی و ساده‌سازی‌های مدل شبیه‌سازی، در محدوده‌ای نزدیک به معیارهای رایج اعتبارسنجی ماهانه قرار دارد که قابل قبول است [۱۸].



شکل ۲. نمودار میزان مصرف انرژی سوله در سه حالت مختلف (نتایج مربوط به شبیه‌سازی انرژی پلاس، نتایج شبیه‌سازی مروگانانام با انرژی پلاس و نتایج مربوط به آزمایش میدانی) [۱۷]

۲-۳. مدل‌سازی هندسه، پوسته و سامانه‌های ساختمان

مدل پایه به صورت یک حجم تک‌زون مستطیلی با ابعاد تقریبی ۱۵/۲۴ در ۱۵/۲۴ متر و ارتفاع ۴/۵۷ متر در نظر گرفته شد. نسبت سطح پنجره به نما ۰/۴ در نظر گرفته شد. تمام سناریوها با یک پیکربندی عمومی ثابت شبیه‌سازی شدند. محل شبیه‌سازی تهران، گام زمانی ۱۰ دقیقه (۶ گام در ساعت) و مدل هدایت جدارها بر اساس CTF انتخاب شد. مدل‌های همرفت Simple و Simple Combined برای داخل و خارج، و الگوریتم‌های Sizing در سطح زون/سیستم فعال و در سطح Plant غیرفعال شدند. پوسته دیوار خارجی از دو لایه عایق پشم‌شیشه و بتن، با ضریب انتقال حرارت ۲/۱ وات بر مترمربع کلین، ضخامت لایه بتن ۲۰ سانتی‌متر، پشم شیشه ۱۰ سانتی‌متر و ضریب بهره‌برداری از گرمای خورشیدی برای پنجره‌ها ۰/۴۵ تشکیل شد. تعداد ساکنان با مؤلفه افراد و بر اساس چگالی ثابت ۰/۲۵ نفر بر مترمربع تعریف شد که با کاربری‌های آموزشی/اداری متعارف و مقادیر پیش‌فرض استانداردهای تهویه [۱۹] سازگار است. پارامترهای آسایش شامل بازده کاری صفر، سرعت هوا ۲ متر بر ثانیه، سطح عایق لباس ۰/۵ کلو برای تابستان و ۱ کلو برای زمستان و توان متابولیک مبنا (حدود ۱۲۰ وات برای هر نفر، متناظر با ۱/۱ تا ۱/۳ متر) مطابق محدوده‌های استاندارد انتخاب شده‌اند [۲۰].

نفوذ هوا به صورت دبی بر واحد مساحت سطح خارجی مدل شد و مقدار مرجع ۰/۵، متر بر ثانیه که طبق استاندارد ASHRAE نزدیک به میانگین کاربری‌های آموزشی/اداری است، انتخاب شد تا مقایسه سناریوها بر پایه کیفیت پوسته شفاف‌تر باشد [۲۱]. سامانه تهویه مطبوع با خانواده HVACTemplate مدل شد. ترموستات ناحیه‌ای، ترمینال VAV:HeatAndCool با بازگرمایش و سیستم مرکزی حجم هوا متغیر با کویل سرمایش انبساط مستقیم دومرحله‌ای و گرمایش الکتریکی انتخاب شدند. نقاط تنظیم ترموستات برای کل سناریوها ثابت و برابر ۲۴ درجه سلسیوس در سرمایش و ۲۱ درجه سلسیوس در گرمایش در نظر گرفته شد تا بدون پیچیده‌سازی کنترل، مقایسه اثر برنامه‌های حضور و ماه‌های مختلف امکان‌پذیر باشد.

برنامه‌های زمانی حضور، روشنایی، تجهیزات و ست‌پوینت‌ها با ساختار Schedule:Compact تعریف شدند. برنامه حضور افراد بر اساس منابع استاندارد (مبحث ۱۹ مقررات ملی ساختمان [۲۲] و الگوهای مرجع DOE/NREL [۲۱] مبتنی بر ASHRAE 90.1 [۲۰]) تنظیم و سپس در ادامه کار به نمایش عددی مناسب برای استفاده در مدل یادگیری ماشین نگاشت شده است. برنامه‌های روشنایی و تجهیزات و نیز غیرفعال‌سازی سرمایش/گرمایش خارج ساعت‌های کاری تابع حضور تعریف شدند تا از مصرف غیرضروری جلوگیری شود.

در نهایت، تنها خروجی اصلی فراخوانی شده از انرژی پلاس، میانگین ماهانه توان مصرفی سیستم تهویه مطبوع است. این متغیر مجموع نرخ تقاضای الکتریکی تمام اجزای سامانه تهویه مطبوع، شامل فن‌ها، کویل‌های الکتریکی، پمپ‌ها، چیلرها، برج‌های خنک‌کننده و سایر تجهیزات مرتبط را در هر گام زمانی (۱۰ دقیقه) محاسبه کرده و در گزارش ماهانه به صورت میانگین نرخ تقاضای همان ماه، یا به بیانی میانگین ماهانه توان مصرفی (وات) ارائه می‌کند تا پایه تحلیل حساسیت و آموزش مدل جانشین را تشکیل دهد.

۲-۴. مدل جانشین یادگیری ماشین و فرایند آموزش

زنجیره تولید داده به صورت برنامه‌وار با پایتون و کتابخانه Eppy پیاده‌سازی شد. فایل IDF پایه و EPW خوانده می‌شوند، مقادیر متغیرهای کلیدی (پارامترهای پوسته، پنجره، ماه، و برنامه‌های حضور) در IDF به‌روزرسانی شده، شبیه‌سازی‌های دسته‌ای انرژی پلاس اجرا و خروجی‌ها به صورت DataFrame ذخیره می‌شوند. هدف این طراحی، ایجاد یک مجموعه داده منظم و قابل‌بازتولید برای آموزش مدل جانشین است، به طوری که در کل فضای ویژگی‌ها پوشش اولیه‌ای بدون سوگیری شدید فراهم شود. سپس، بانک اصلی برنامه‌ها از الگوهای استاندارد مبحث ۱۹ مقررات ملی ساختمان [۲۲]، DOE [۲۱] و ASHRAE [۲۰] گرفته شد. در این الگوها، تغییرات زمانی حضور ساکنان با ضربی به نام کسر حضور تعریف می‌شود. این مقدار عددی بین صفر و یک است که سهم حضور واقعی افراد را نسبت به حالت پیشینه نشان می‌دهد. در این مطالعه، چگالی ۰/۲۵ نفر بر مترمربع به عنوان مقدار پیشینه حضور در فضا در نظر گرفته شد. بنابراین، کسر حضور برابر با ۱ به معنای حضور کامل بر اساس این چگالی، کسر حضور برابر با صفر به معنای نبود ساکنان و مقادیر میانی نشان‌دهنده حضور نسبی افراد در هر ساعت هستند. برای اینکه مجموعه داده فقط به چند الگوی تکراری و بیش‌ازحد یکنواخت محدود نشود، با روش جیتر گاوسی^۱ متنوع شد. در این فرایند به هر مقدار حضور ساعتی یک نویز نرمال با میانگین صفر و انحراف معیار ۰/۰۶ افزوده شد تا مدل به تغییرات کوچک کسر حضور افراد حساس شود و از هر برنامه پایه چند نسخه هم‌خانواده اما متفاوت تولید شد. علاوه بر این، الگوهای مرزی مانند حالت همیشه خالی و یا همیشه پر از ساکنان، بلوک‌های یک‌تکه یا دوبخشی حضور، پالس‌های کوتاه، شیفت شب و حضور روزانه با افت حضور برای ساعت‌های استراحت همچون ناهار نیز اضافه شدند تا شرایط افراطی و مرزی هم پوشش داده شوند. به این ترتیب، هر نمونه شامل ۲۴ مقدار خام حضور و مشخصه ماه است. اقلیم و محل شبیه‌سازی در تمام موارد روی تهران (EPW ثابت) نگه داشته شده تا اثر تغییرات، عمدتاً ناشی از حضور و ماه باشد. برای هر ماه ۲۴۰ برنامه حضور تولید و فقط همان ماه شبیه‌سازی شده است (در مجموع ۲۸۸۰ شبیه‌سازی). در نهایت، توان لحظه‌ای الکتریکی سیستم تهویه مطبوع از خروجی انرژی پلاس خوانده و به میانگین ماهانه توان مصرفی تبدیل شده و به عنوان متغیر هدف ثبت شده است.


۲-۵. مدل جانشین یادگیری ماشین و فرایند آموزش

برای متغیر ماه که ذاتاً رفتاری چرخه‌ای دارد، استفاده از نمایش عددی ساده ۱ تا ۱۲ می‌تواند مدل را گمراه کند؛ زیرا برای مثال ماه‌های دسامبر (ماه دوازدهم سال میلادی) و ژانویه (ماه اول سال میلادی) در واقعیت همسایه‌اند؛ اما در این مقیاس عددی از هم دور می‌افتند. برای رفع این مشکل، در مرحله پیش‌پردازش، شاخص ماه m طبق معادله ۱ به دو مؤلفه سینوسی و کسینوسی نگاشت شده است [۲۳].

$$\text{ماه } (m \in \{0, 1, 2, \dots, 12\})$$

$$\begin{aligned} s_m &= \sin\left(\frac{2\pi(m-1)}{12}\right), \\ c_m &= \cos\left(\frac{2\pi(m-1)}{12}\right) \end{aligned} \quad (1)$$

در این نگاشت، مانند شکل ۳، هر ماه مانند یک بردار واحد روی دایره واحد در نظر گرفته می‌شود که زاویه آن فاز فصلی را نشان می‌دهد.



شکل ۳. نمایش چرخه‌ای ماه‌ها روی دایره واحد با استفاده از کدگذاری سینوسی - کسینوسی

مؤلفه کسینوس موقعیت روی محور زمستان - تابستان و مؤلفه سینوس موقعیت روی محور بهار - پاییز را بازتاب می‌دهد. به این ترتیب، هم همسایگی واقعی ماه‌ها و هم گذار پیوسته فصل‌ها در فضای ویژگی‌ها حفظ می‌شود و مدل می‌تواند الگوهای فصلی حضور توان مصرفی را به صورت پیوسته و واقع‌گرایانه‌تری بیاموزد. این ترفند که در مهندسی ویژگی رایج است، همسایگی چرخه‌ای را در فضای دوبعدی واحد حفظ می‌کند و برای مدل‌های حساس به فواصل اقلیدسی مناسب‌تر است.

برای پیش‌بینی میانگین ماهانه توان مصرفی بر اساس ویژگی‌های زمانی و رفتاری، از یک مدل یادگیری نظارت‌شده^۱ بر پایه شبکه عصبی پرسپترون چندلایه^۲ استفاده شد. ورودی مدل شامل ۲۴ مقدار حضور ساعتی و دو مؤلفه کدگذاری چرخه‌ای ماه بود. متغیر هدف، میانگین ماهانه توان مصرفی سیستم تهویه مطبوع است که از شبیه‌سازی‌ها استخراج شده است. پیش از آموزش، تمام ویژگی‌ها با استانداردسازی (میانگین صفر و واریانس یک) نرمال شدند تا از غلبه متغیرهای با مقیاس بزرگ جلوگیری شود. سپس، داده‌ها به سه بخش آموزش، اعتبارسنجی و آزمون تقسیم شدند تا تنظیم ابرپارامترها^۳ و ارزیابی نهایی روی زیرمجموعه‌های مستقل انجام شود و از بیش‌برازش^۴ جلوگیری شود. شبکه عصبی شامل یک لایه ورودی، چند لایه پنهان با تابع فعال‌ساز ReLU و یک لایه خروجی تک‌نودی برای رگرسیون است. آموزش با الگوریتم‌های گرادیان‌محور، تابع هزینه میانگین مربعات خطا (MSE) و تنظیم مناسب نرخ یادگیری و تعداد دوره‌ها انجام می‌شود. عملکرد مدل با شاخص‌هایی شامل RMSE، MAE و R^2 ارزیابی شده تا هم دقت و هم توان توضیح‌دهی آن سنجیده شود. برای تفسیر مدل و استخراج بینش از نقش ویژگی‌ها، از مقادیر شپ برای اندازه‌گیری اهمیت و جهت اثر هر ویژگی و از نمودارهای وابستگی جزئی^۵ برای نمایش پاسخ متوسط مدل نسبت به تغییرات یک یا دو ویژگی استفاده شد. این ابزارها کمک می‌کنند نشان داده شود که کدام ساعت‌های روز

1. Supervised Learning
2. Multi-Layered Perceptron
3. Hyperparameters
4. Overfitting
5. Partial Dependence Plots

و کدام ماه‌ها (از طریق کدگذاری سینوسی/اکسینوسی) بیشترین نقش را در تغییر توان مصرفی دارند و این اثرات تا چه حد غیرخطی و وابسته به فصل هستند.

شبیه‌سازی‌ها و آموزش مدل‌ها روی یک لپ‌تاپ با پردازنده Intel Core i7، حافظه RAM برابر با ۱۲ گیگابایت و کارت گرافیک NVIDIA GeForce 940MX انجام شد. با توجه به تک‌زون بودن مدل ساختمانی، اجرای شبیه‌سازی‌های سالانه انرژی‌پلاس از نظر محاسباتی سبک بود و زمان هر اجرا در حد چند ثانیه تا کمتر از یک دقیقه قرار داشت. در مقابل، بخش عمده زمان محاسباتی مربوط به آموزش مدل شبکه عصبی مصنوعی بود که به تعداد نمونه‌های آموزشی، تعداد ویژگی‌های ورودی، معماری شبکه و تعداد دوره‌های آموزش وابسته است.

۳. نتایج و بحث

با هدف بررسی اثر زمان و یا تعداد ساعت‌های حضور افراد در ناحیه مورد بررسی و همچنین اثرات کسر حضور افراد، سناریوهای زیر شبیه‌سازی شدند:


۱- حضور تنها در ۱۲ ساعت اول روز.

۲- حضور افراد در ۱۲ ساعت دوم روز.

۳- حضور ۲۴ ساعته افراد.

۴- حضور تنها در ۱۲ ساعت اول روز در حالتی که کسر حضور افراد تنها برابر ۲۰ درصد ظرفیت ناحیه بوده.

مقایسه مورد ۱ تا ۳ (شکل ۴) نشان‌دهنده اثرات زمان و یا تعداد ساعت‌های حضور افراد در ناحیه مورد بررسی است و مقایسه مورد ۱ و ۴ (شکل ۵) نشان‌دهنده اثرات کسر حضور افراد در تعداد ساعت‌ها برابر حضور است. این نتایج اهمیت درصد کسر حضور ناحیه و تعداد ساعت‌ها و بازه زمانی حضور ساکنان در یک ناحیه را نشان می‌دهند که دلیل انتخاب چهار ویژگی انتخاب‌شده در این تحقیق را توجیح می‌کنند.




شکل ۴. مقایسه میانگین ماهانه توان مصرفی برای سه حالت: حضور افراد تنها در ۱۲ ساعت اول روز، حضور افراد تنها در ۱۲ ساعت دوم روز و حضور ۲۴ ساعته افراد در ناحیه مورد بررسی




شکل ۵. مقایسه میانگین ماهانه توان مصرفی برای دو حالت: حضور افراد تنها در ۱۲ ساعت اول روز با کسر حضور برابر ۱ و حضور افراد تنها در ۱۲ ساعت اول روز با کسر حضور برابر ۰/۲

در این بخش نتایج مدل‌سازی داده‌محور ارائه می‌شود؛ هدف، ارزیابی عملکرد شبکه عصبی مصنوعی، تفسیر نقش حضور ساعتی ساکنان و عوامل فصلی، و نشان دادن توانایی مدل در کشف الگوهای حضور کم‌مصرف است. مدل شبکه عصبی مورد استفاده شامل دو لایه پنهان با ۱۲۸ و ۶۴ نورون بود که از تابع فعال‌سازی ReLU استفاده می‌کردند. بهینه‌ساز Adam با نرخ یادگیری ۰/۰۰۱ برای ۱۰۰۰ دوره یادگیری به کار گرفته شد. ورودی شامل ۲۶ ویژگی (۲۴ مقدار حضور ساکنان ساعتی به همراه ماه، که به صورت دو فاکتور سینوس و کسینوس تعریف شده است) بود و خروجی، پیش‌بینی میانگین ماهانه توان مصرفی بود. ساختار کلی شبکه در شکل ۶ نمایش داده شده است که جریان اطلاعات را از ورودی‌ها به لایه‌های پنهان و سپس خروجی نشان می‌دهد. دیاگرام شمایک معماری مدل شبکه عصبی شامل لایه ورودی با ۲۶ ویژگی، دو لایه پنهان (۱۲۸ و ۶۴ نورون) و یک خروجی برای پیش‌بینی میانگین ماهانه توان مصرفی.




شکل ۶. دیاگرام نشان‌دهنده ساختار کلی شبکه عصبی استفاده‌شده شامل لایه ورودی با ۲۶ متغیر، لایه‌های پنهان با ۱۲۸ و ۶۴ نورون و تابع فعال‌ساز ReLU و در نهایت میانگین ماهانه توان مصرفی

مدل شبکه عصبی به دقت بالایی دست یافت و در داده‌های آزمون مقدار دقت R^2 برابر 0.963 به دست آمد که نشان‌دهنده توانایی در شناسایی روابط غیرخطی بین حضور ساکنان، ماه‌های سال و توان مصرفی است. نمودارهای میانگین مربعات خطا آموزش و اعتبارسنجی (شکل ۷) روند نزولی یکنواختی را نشان می‌دهند که در پایان به مقادیر مشابهی همگرا می‌شوند. این موضوع بیانگر تعمیم‌پذیری مدل و اجتناب از بیش‌برازش است. منحنی کاهش loss طی آموزش (شکل ۸) نیز کاهش تدریجی و بدون نوسان شدید را نشان می‌دهد.




شکل ۷. منحنی میانگین مربعات خطا آموزش و اعتبارسنجی شبکه عصبی مصنوعی طی ۱۰۰۰ دوره آموزشی، همگرایی مشابه و پایداری تعمیم‌پذیری را نشان می‌دهد




شکل ۸. منحنی loss طی آموزش، کاهش یکنواخت و بدون نوسان را نمایش می‌دهد

نمودارهای توازن در شکل ۹ دقت مدل را بیشتر تأیید می‌کنند. مقادیر پیش‌بینی‌شده در سه بخش آموزش، اعتبارسنجی و آزمون به‌خوبی با خط ۴۵ درجه منطبق هستند. در نهایت، توزیع باقی‌مانده‌ها در نمودار هیستوگرام شکل ۱۰ به صورت متقارن حول صفر قرار دارد و بیانگر آن است که خطاها فاقد سوگیری سیستماتیک بوده و بیشتر به صورت تصادفی رخ داده‌اند.



شکل ۹. نمودارهای توازن برای سه بخش الف) آموزش، ب) اعتبارسنجی و ج) آزمون، هم‌خوانی پیش‌بینی‌ها با مقادیر واقعی را تأیید می‌کند




شکل ۱۰. نمودار هیستوگرام باقی‌مانده‌های آزمون که توزیع متقارن حول صفر را نشان می‌دهد

۳-۱. تحلیل مقادیر تبیین‌های افزایشی شاپلی (شپ)^۱

شکل ۱۱ نمودار ازدحامی شپ^۲ را نشان می‌دهد که با کمی‌سازی سهم هر ویژگی ورودی در پیش‌بینی میانگین ماهانه توان مصرفی، تبیینی سراسری از شبکه عصبی ارائه می‌کند. در این نمودار، محور افقی مقادیر شپ^۳ را نمایش می‌دهد که اثر هر

1. SHapley Additive exPlanations (SHAP)
 2. SHAP beeswarm
 3. SHAP values

ویژگی را نسبت به حالت پایه، یعنی میانگین پیش‌بینی مدل روی نمونه‌های آموزش، نشان می‌دهد. مقادیر مثبت شپ موجب افزایش و مقادیر منفی موجب کاهش میانگین ماهانه توان مصرفی پیش‌بینی‌شده نسبت به حالت پایه می‌شوند. هر نقطه یک نمونه را نشان می‌دهد و رنگ آن بیانگر مقدار واقعی ویژگی است؛ برای ویژگی‌های کسر حضور، رنگ آبی به قرمز از حضور کم تا زیاد را نشان می‌دهد و برای کدگذاری‌های زمانی، مقدار مؤلفه سینوسی یا کسینوسی مربوط به موقعیت چرخه‌ای ماه در سال را مشخص می‌کند.




شکل ۱۱. نمودار ازدحامی شپ که سهم ویژگی‌های زمانی و حضور ساعتی را در پیش‌بینی میانگین ماهانه توان مصرفی نشان می‌دهد

این نمودار نشان می‌دهد اثرگذارترین ویژگی‌ها متغیرها دو مؤلفه ماه، یعنی مؤلفه کسینوسی و سینوسی ماه هستند؛ امری که تأیید می‌کند اقلیم و تغییرات فصلی محرک‌های اصلی مصرف سالانه سیستم است؛ جایی که بارهای گرمایش و سرمایش بین زمستان و تابستان به طور قابل توجهی جابه‌جا می‌شوند، که با فیزیک ساختمان سازگار است. پس از آن، چند ساعت از روز، به‌ویژه بین ساعت‌های ۱۱ تا ۱۶، بیشترین مقادیر مطلق شپ را دارند. حضور بالا در این ساعت‌ها (نقاط قرمز) اغلب با مقادیر مثبت شپ همراه است، یعنی افزایش توان مصرفی پیش‌بینی‌شده؛ که با الگوهای مورد انتظار بار تهویه مطبوع در زمانی که نرخ متابلیک و تقاضای تهویه بیشینه‌اند همخوانی دارد. در مقابل، حضور در ساعت‌های بامداد یا اواخر شب (مثل ۲۱، ۲۲ و ۱) پراکندگی‌های کوچک‌تر و متقارن‌تری پیرامون صفر نشان می‌دهد که دلالت بر اثر حاشیه‌ای محدودتر آن‌ها بر توان مصرفی کل دارد. با بررسی نمودار می‌توان متوجه شد که در برخی ماه‌های سرد، همان حضور بالا می‌تواند با تأمین بار حرارتی داخلی، مصرف گرمایش را کاهش دهد و به مقادیر منفی شپ منجر شود. این دواگانگی نشان‌دهنده برهم‌کنش قوی بین حضور و شرایط فصلی است. این نتایج نشان می‌دهد مدل نه‌تنها سطح حضور، بلکه زمان حضور را نیز به طور حساس در نظر می‌گیرد و کدگذاری پیوسته حضور ساعتی، نسبت به رویکردهای رسته‌ای، تصویر غنی‌تری از نقش ساعت‌های مختلف روز در میانگین ماهانه توان مصرفی فراهم کرده است.

۳-۲. نتایج نمودارهای وابستگی جزئی

برای تبیین روندهای متوسط، نمودارهای وابستگی جزئی تک‌متغیره برای سه ماه شاخص ژانویه (غلبه بار گرمایش)، ژوئیه (غلبه بار سرمایش) و اوت (شرایط معتدل) در شکل‌های ۱۲ تا ۱۴ ارائه شده است. در هر ماه، شش ساعت منتخب از شبانه‌روز (۶، ۹، ۱۲، ۱۶، ۲۰ و ۲۴) به صورت جداگانه بررسی شده‌اند. این نمودارها نشان می‌دهند چگونه تغییر نرخ حضور در هر ساعت می‌تواند میانگین ماهانه توان مصرفی ساختمان را افزایش یا کاهش دهد و به این ترتیب امکان مقایسه رفتار سیستم در فصل‌های مختلف سال را فراهم می‌سازند.


شکل ۱۲ مربوط به ژانویه (غلبه بار گرمایشی) است. در ساعت‌های ابتدایی مانند ۶ زمانی که بار حرارتی خورشید حداقل مقدار خود است و دمای محیط پایین‌تر است، افزایش ساکنان حاضر ابتدا میانگین ماهانه توان مصرفی را بیشتر می‌کند (به دلیل نیاز بیشتر به گرمایش)، اما در نرخ‌های بالاتر حضور، مصرف کاهش می‌یابد، زیرا بار حرارتی داخلی بار گرمایشی را جبران می‌کند. در مقابل، در ساعت ۱۶ که تابش خورشید وجود دارد، مصرف پایه پایین‌تر است و افزایش حضور کاهش بار گرمایشی را سریع‌تر می‌کند.




شکل ۱۲. نمودارهای وابستگی جزئی اثرات حضور ساکنان برای ساعت‌های ۶، ۹، ۱۲، ۱۶، ۲۰ و ۲۴ و کسرهای حضور بین ۰ تا ۱ در ماه ژانویه بر میانگین ماهانه توان مصرفی (وات)

مقایسه مشابه برای ماه ژوئیه، که بیشترین بار مصرفی مربوط به سرمایش است، در شکل ۱۳ ارائه شده است. حضور در تمام ساعت‌ها موجب افزایش میانگین ماهانه توان مصرفی می‌شود، زیرا حرارت داخلی و نیاز به تهویه بار سرمایشی را بیشتر می‌کنند. بیشترین افزایش در ساعت ۱۶ مشاهده می‌شود که اوج بار سرمایش است. در نهایت، در ماه اوت متحنی‌ها ملایم‌ترند و بسته به ساعت، رفتار بین الگوی زمستانی و تابستانی مطابق شکل ۱۴ در نوسان است.

برآیند این نتایج نشان می‌دهد حضور ساکنان در زمستان می‌تواند نقش کاهش‌دهنده گرمایش و در تابستان نقش تقویت‌کننده سرمایش داشته باشد و ساعت ۱۶ در اکثر ماه‌ها یکی از ساعت‌های حساس از نظر اثر حضور بر مصرف است، که یافته‌ای که با رتبه‌بندی نمودار ازدحامی شپ هم‌راست است.



شکل ۱۳. نمودارهای وابستگی جزئی اثرات حضور ساکنان برای ساعت‌های ۶، ۹، ۱۲، ۱۶، ۲۰ و ۲۴ و کسرهای حضور بین ۰ تا ۱ در ماه ژوئیه بر میانگین ماهانه توان مصرفی (وات)




شکل ۱۴. نمودارهای وابستگی جزئی اثرات حضور ساکنان برای ساعت‌های ۶، ۹، ۱۲، ۱۶، ۲۰ و ۲۴ و کسرهای حضور بین ۰ تا ۱ در ماه اوت بر میانگین ماهانه توان مصرفی (وات)


۲-۳. بهینه‌سازی الگوهای حضور

برای نمایش کاربرد عملی مدل شبکه عصبی مصنوعی، تابعی توسعه یافت که سه ورودی شامل تعداد ساعت‌های حضور، ساعت شروع بازه و نرخ حضور را دریافت می‌کند. این تابع بر اساس ورودی‌ها برنامه حضور را ایجاد کرده و سپس میانگین ماهانه توان مصرفی متناظر را با استفاده از مدل پیش‌بینی می‌کند. نتایج حاصل در شکل‌های ۱۵ و ۱۶ برای دو ماه شاخص، ژانویه و ژوئیه و طول بازه حضور چهار ساعت ارائه شده است. محور افقی در این نمودارها ساعت شروع بازه حضور را نشان می‌دهد و محور

عمودی میانگین ماهانه توان مصرفی پیش‌بینی شده را نمایش می‌دهد. هر نقطه حاصل یک پیش‌بینی مدل شبکه عصبی است. نتایج نشان می‌دهند در ژانویه بیشترین مصرف توان الکتریکی زمانی رخ می‌دهد که حضور از اواخر صبح آغاز شود. این نتیجه با منطق فیزیکی ساختمان سازگار است، زیرا در ساعات‌های ابتدایی روز نیاز گرمایشی بالاتر است و حضور در این زمان می‌تواند بار سیستم گرمایش را افزایش دهد، در حالی که شروع زودتر بازه حضور، مثلاً حوالی شش یا هفت صبح، میانگین ماهانه توان مصرفی را کاهش می‌دهد، چرا که بار حرارتی داخلی ناشی از حضور بخشی از گرمایش لازم را جبران می‌کند.



شکل ۱۵. رابطه بین میانگین ماهانه توان مصرفی پیش‌بینی شده و ساعت شروع بازه ۴ ساعته در ماه ژانویه (کسر حضور = ۱)
* نقاط روی نمودار، که ساعات‌های شروع بازه حضور هستند، داده‌های پیش‌بینی مدل شبکه عصبی را نشان می‌دهند.



شکل ۱۶. رابطه بین میانگین ماهانه توان مصرفی پیش‌بینی شده و ساعت شروع بازه ۴ ساعته در ماه ژوئیه (کسر حضور = ۱)
* نقاط روی نمودار، که ساعات‌های شروع بازه حضور هستند، داده‌های پیش‌بینی مدل شبکه عصبی را نشان می‌دهند. توان مصرفی در ساعات‌های بعدازظهر به طور قابل توجهی افزایش یافته و الگوی رشد مصرف در ساعات‌های گرم‌تر روز را نمایش می‌دهد.

همچنین نتایج ارائه شده نشان می‌دهد زمان‌بندی حضور افراد طی شبانه‌روز نقش مهمی در الگوی توان مصرفی سیستم تهویه مطبوع ایفا می‌کند. به طوری که با بهینه‌سازی زمان وقوع چهار ساعت حضور در مقیاس ماهانه، مقدار شاخص نرخ تقاضا در حالت بهینه نسبت به خط مبنای بیشینه ماهانه کاهش قابل توجهی نشان داد. در این مطالعه، مجموع اختلاف‌های ماهانه بین بیشترین مقدار مشاهده شده در هر ماه و مقدار متناظر در حالت بهینه برابر با ۵۲۳۰ وات به دست آمد که معادل حدود ۱۵ درصد از مجموع مقادیر خط مبنای بیشینه میانگین ماهانه توان مصرفی است.

۴. نتیجه‌گیری

این پژوهش با هدف پیش‌بینی ساکن‌محور میانگین ماهانه توان مصرفی و در عین حال کاهش نیاز به داده‌های شبیه‌سازی گسترده انجام شد. با تولید تنها ۲۸۸۰ سناریوی شبیه‌سازی‌شده، که در آن الگوهای حضور ساعتی ساکنان و ماه‌های سال به صورت پیوسته و کدگذاری‌شده وارد مدل شدند، یک شبکه عصبی مصنوعی توانست رابطه بین حضور، زمان و میانگین ماهانه توان مصرفی را با دقت بالا بیاموزد.

از منظر تفسیرپذیری، تحلیل‌های شپ و نمودارهای وابستگی جزئی نشان دادند کدگذاری فصلی ماه‌ها (یعنی مؤلفه کسینوسی و سینوسی ماه) و حضور ساعتی ساکنان هر دو در شکل‌گیری توان مصرفی سیستم نقش کلیدی دارند. به‌ویژه ساعت‌های ظهر و بعدازظهر، حساس‌ترین بازه‌ها برای افزایش یا کاهش توان مصرفی شناسایی شدند و مدل به طور ضمنی ماهیت چرخه‌ای زمان (گروه‌بندی ساعت‌های بعدازظهر و شب) را فراگرفت. تحلیل بازه‌های حضور نیز نشان داد فقط با تغییر ساعت شروع و طول بازه حضور می‌توان در زمستان بخشی از بار گرمایش را با حرارت داخلی جبران کرد و در تابستان از اوج‌گیری غیرضروری بار سرمایش جلوگیری کرد؛ بدون کوچک‌ترین تغییر فیزیکی در ساختمان.

در این پژوهش، هدف اصلی ارائه یک مقدار ثابت و قابل تعمیم مستقیم برای همه ساختمان‌ها و اقلیم‌ها نبوده، بلکه هدف، بررسی اثر زمان وقوع حضور ساکنان در مقیاس ساعت‌های شبانه‌روز و ماه‌های سال بر میانگین ماهانه توان مصرفی بوده است. طبیعی است که مقادیر عددی به‌دست‌آمده تحت تأثیر اقلیم، دمای محیط، جهت‌گیری ساختمان، توزیع تابش خورشیدی، مشخصات پوسته، نوع کاربری، تراکم و الگوی حضور ساکنان و نوع سیستم تهویه مطبوع قرار دارند. بنابراین، نتایج عددی این مطالعه به طور مستقیم به همه ساختمان‌ها قابل تعمیم نیستند. با این حال، چارچوب روش‌شناسی پژوهش می‌تواند برای سایر اقلیم‌ها، کاربری‌ها و سامانه‌های ساختمانی نیز به کار گرفته شود تا اثر زمان‌بندی حضور بر مصرف یا تقاضای انرژی در شرایط خاص همان ساختمان ارزیابی شود. نوآوری مهم این کار در این است که به‌جای تعریف صدها یا هزاران برنامه گسسته حضور برای ترکیب‌های مختلف ساعت، ماه و سطح حضور، حضور ساکنان به صورت بردارهای پیوسته (۲۴ مقدار در روز) و ماه‌ها به صورت کدگذاری سینوسی/کسینوسی مدل شدند. به این ترتیب، مدل جانشین یاد گرفت چگونه به طیف وسیعی از برنامه‌های جدید نیز تعمیم دهد، در حالی که حجم شبیه‌سازی‌ها نسبت به رویکردهای کلاسیک به طور چشمگیری کاهش یافت. بنابراین، این پژوهش نشان داد می‌توان با مهندسی ویژگی مناسب و یک مدل جانشین داده‌محور، نیاز به شبیه‌سازی‌های حجیم انرژی‌پلاس را کاهش داد و همچنان روابط پیچیده بین حضور، فصل و میانگین ماهانه توان مصرفی را با دقت بالا استخراج کرد. برای پژوهش‌های آینده، می‌توان چارچوب پیشنهادی را در چند جهت توسعه داد. نخست، پیش‌بینی مصارف سیستم تهویه مطبوع می‌تواند از مقیاس ماهانه به مقیاس‌های زمانی دقیق‌تر، مانند روزانه یا ساعتی، گسترش یابد تا اثر تغییرات کوتاه‌مدت حضور ساکنان با دقت بیشتری بررسی شود. افزون بر شاخص‌های انرژی، می‌توان معیارهای آسایش بصری را نیز با استفاده از نرم‌افزارهای تخصصی شبیه‌سازی روشنایی وارد فرایند ارزیابی کرد. همچنین، بررسی کنترل ساکن‌محور به عنوان یک راهکار عملیاتی کم‌هزینه در مقایسه با بازطراحی فیزیکی ساختمان می‌تواند مسیر کاربردی مهمی برای کاهش مصرف انرژی باشد. در نهایت، استفاده از یادگیری فعال برای ساخت مجموعه داده‌های عمومی‌تر، از جمله با لحاظ کردن اقلیم‌های مختلف به صورت داده‌های رسته‌ای، می‌تواند قابلیت تعمیم مدل را در مطالعات بعدی افزایش دهد.

منابع

- [1] Akram MW, Mohd Zublie MF, Hasanuzzaman M, Rahim NA. Global prospects, advance technologies and policies of energy-saving and sustainable building systems: A review. *Sustainability*. 2022; 14(3):1316.
- [2] De la Cruz-Lovera C, Perea-Moreno AJ, De la Cruz-Fernández JL, Alvarez-Bermejo J, Manzano-Agugliaro F. Worldwide research on energy efficiency and sustainability in public buildings. *Sustainability*. 2017; 9(8):1294.
- [3] Beucker S, Bergesen JD, Gibon T. Building energy management systems: global potentials and environmental implications of deployment. *J Ind Ecol*. 2016; 20(2):223-233.
- [4] Torabi M, Mahdavinnejad M. Past and future trends on the effects of occupant behaviour on building energy consumption. *J Sustain Archit Civ*. 2021; 29(2):83-101.
- [5] He Y, Chen Y, Chen Z, Deng Z, Yuan Y. Impacts of occupant behavior on building energy consumption and energy savings analysis of upgrading ASHRAE 90.1 energy efficiency standards. *Buildings*. 2022; 12(8):1108.
- [6] Yousefi F, Gholipour Y, Yan W. A study of the impact of occupant behaviors on energy performance of building envelopes using occupants' data. *Energy Build*. 2017; 148:182-198.
- [7] Ahmad A, Prakash O, Brar LS, et al. Effect of wall, roof, and window-to-wall ratio on the cooling and heating load of a building in India. *Energy Sci Eng*. 2025; 13(3):1255-1279.
- [8] Gupta V, Deb C. Envelope design for low-energy buildings in the tropics: A review. *Renew Sustain Energy Rev*. 2023; 186:113650.
- [9] Pang Z, Guo M, Smith-Cortez B, et al. Quantification of HVAC energy savings through occupancy presence sensors in an apartment setting: Field testing and inverse modeling approach. *Energy Build*. 2024; 302:113752.
- [10] Kong M, Dong B, Zhang R, O'Neill Z. HVAC energy savings, thermal comfort and air quality for occupant-centric control through a side-by-side experimental study. *Appl Energy*. 2022; 306:117987.
- [11] Norouziasl S, Jafari A, Wang C. An agent-based simulation of occupancy schedule in office buildings. *Build Environ*. 2020; 186:107352.
- [12] Álvarez-Sanz M, Satriya FA, Terés-Zubiaga J, Campos-Celador Á, Bermejo U. Ranking building design and operation parameters for residential heating demand forecasting with machine learning. *J Build Eng*. 2024; 86:108817.
- [13] Kim DD, Suh HS. Heating and cooling energy consumption prediction model for high-rise apartment buildings considering design parameters. *Energy Sustain Dev*. 2021; 61:1-14.
- [14] Liu C, Xu Z, Yuan M, Xie J, Yuan Y, Ma K. Building electrical load forecasting with occupancy data based on wireless sensing. *Appl Energy*. 2025; 380:124960.
- [15] Lian H, Wei H, Wang X, Chen F, Ji Y, Xie J. Research on real-time energy consumption prediction method and characteristics of office buildings integrating occupancy and meteorological data. *Buildings*. 2025; 15(3):404.
- [16] U.S. Department of Energy. EnergyPlus 9.6.0 documentation: Engineering reference. 2021. Accessed August 29, 2025. https://energyplus.net/assets/nrel_custom/pdfs/pdfs_v23.2.0/EngineeringReference.pdf.
- [17] Muruganantham K, Phelan P, Lee T, Reddy A. Application of Phase Change Material in Buildings: Field Data vs. EnergyPlus Simulation. Tempe: Arizona State University; 2010.
- [18] Magni M, Ochs F, de Vries S, Maccarini A, Sigg F. Detailed cross comparison of building energy simulation tools results using a reference office building as a case study. *Energy Build*. 2021; 250:111260.
- [19] American Society of Heating Refrigeration and Air-conditioning. ASHRAE 55: Thermal environmental conditions for human occupancy. Atlanta: ASHRAE; 2023.
- [20] American Society of Heating Refrigeration and Air-conditioning. ASHRAE 90.1: Energy standard for sites and buildings except low-rise residential buildings. Atlanta: ASHRAE; 2025.
- [21] American Society of Heating Refrigeration and Air-conditioning. ANSI/ASHRAE 62.1: Ventilation for acceptable indoor air quality. Atlanta: ASHRAE; 2025.

- [22] Ministry of Roads and Urban Development. Iranian national building code, part 19: Energy conservation [in Persian]. 4th ed. National Building Regulations Office: Tehran: 2020.
- [23] Andrich van Wyk. Encoding cyclical features for deep learning. Accessed August 29, 2025. <https://www.kaggle.com/code/avanwyk/encoding-cyclical-features-for-deep-learning>