



## Prediction of energy consumption for residential buildings based on the behavior of its residents using artificial intelligence neural network method in Tabriz city

Ali Zeynaly Azim<sup>1\*</sup> | Hamed Pooyafar<sup>2</sup> | Behnaz Amin Naieri<sup>3</sup> | Davod Paidar Khiabani<sup>4</sup> | Aida Mostafazadeh Bazargan<sup>5</sup>

1. Corresponding Author, Post-doctoral researcher in urban design, Faculty of Architecture and Urban Planning, Shahid Rajaei Tarbiat University, Tehran, Iran. Email: [al.zeynaly@gmail.com](mailto:al.zeynaly@gmail.com)
2. Department of Architecture, Aras International Branch, Islamic Azad University, Tabriz, Iran. Email: [hamedpooiafar@gmail.com](mailto:hamedpooiafar@gmail.com)
3. Department of Urban Planning, Tabriz Branch, Islamic Azad University, Tabriz, Iran. Email: [behnaz.aminnaieri2020@pardisiau.ac.ir](mailto:behnaz.aminnaieri2020@pardisiau.ac.ir)
4. PhD student in Architecture, Ahar Branch, Islamic Azad University, Ahar, Iran. Email: [davod.paidarkhiabani@yahoo.com](mailto:davod.paidarkhiabani@yahoo.com)
5. M. Arch Student, Faculty of Architecture, Rashidiyeh Non-Profit University, Tabriz, Iran. Email: [aida.mostafazadeh@gmail.com](mailto:aida.mostafazadeh@gmail.com)

### ARTICLE INFO

**Article type:**  
Research Paper

**Article History:**  
Received 05 July 2024  
Revised 05 August 2024  
Accepted 06 October 2024  
Published Online 04 January 2025

**Keywords:**  
artificial neural network,  
energy consumption prediction,  
smart houses,  
Energy storage,  
Tabriz city.

### ABSTRACT

With the advancement of computing power and data analysis techniques, it is now possible to analyze user information using big data techniques. Here, an attempt was made to integrate user information with physical characteristics of residential buildings to analyze how these elements affect energy consumption. Regression analysis was performed to accurately identify the impact of each element on energy consumption. In this study, the artificial neural network technique was used to model and predict the input energy consumed in a residential building. Regression analysis was performed to accurately identify the impact of each element on energy consumption. It was found that six elements were influential in all seasons: the number of exterior walls, the direction of the housing, the area of the housing, the number of years occupied, the number of family members and the occupation of the head of the household. Then, the elements that had influence in each period were extracted. Based on the results of the regression analysis, the input variables were selected for the training of the artificial neural network (ANN) model for each period, and residential energy consumption prediction models were implemented based on the actual consumption. The elements that are known as effective factors on energy consumption through regression analysis can be used to implement predictive models with advanced forms.

**Cite this article:** Zeynaly Azim, A.; Pooyafar, H.; Amin Naieri, B.; Paidar Khiabani, D. & Mostafazadeh Bazargan, A. (2025). Prediction of energy consumption for residential buildings based on the behavior of its residents using artificial intelligence neural network method in Tabriz city. *Journal of Sustainable Energy Systems*, 4 (1), 1-26. DOI: <http://doi.org/10.22059/ses.2024.381731.1091>



© Ali Zeynaly Azim, Hamed Pooyafar, Behnaz Amin Naieri, Davod Paidar Khiabani, Aida Mostafazadeh Bazargan  
**Publisher:** University of Tehran Press.  
DOI: <http://doi.org/10.22059/ses.2024.381731.1091>

### Introduction

Neural network models can understand any non-linear mapping between input and output, and there is no need to know the mathematical equation to describe load and effect coefficients in an advanced way. Therefore, this method is generally used to predict building energy consumption. Current applications investigate the potential of dynamic simulation of the energy demand of a building by

using a limited input set [8], as mentioned earlier, the idea that is investigated in this article is the use of It is information that is potentially available from low-cost monitoring and controlling devices, along with weather information outside the building, so that the optimal energy consumption for the current and current conditions in Tabriz city can be predicted by the neural network and any Identify abnormal conditions.

### **Methodology**

First, data from the Permanent Household Energy Survey were merged with Climate Constant annual regional temperature data. Second, a multiple regression analysis was performed using integrated data to obtain elements of energy consumption in each season. Then, the effective elements were used as input data to build an ANN model and run energy consumption prediction models. In order to accurately extract elements and build a forecast model, regression analysis and forecast model construction were performed for five periods: annual, spring, summer, autumn and winter.

### **Results**

The results of the analysis showed that Type A, which used important household information as input data in all seasons through regression analysis, showed the highest model accuracy. For variant B, which used the original data, the gradient was vanishing. Spring and summer models. Type C had higher prediction accuracy than type A, except in the annual period; But there was a significant difference between the prediction accuracy of training and testing models, which led to the problem of over-fitting. Based on the comparison and analysis results of each model, it was found that identifying the most important variables through regression analysis can improve the performance of the model, especially when variables that are difficult to quantify, such as household information, are used as input data in are considered.

### **Conclusion**

In this study, although the prediction rate was improved by using influential factors through regression analysis, the performance of the prediction model was still limited due to data limitations, as only two years of data were used. However, the dataset used in this study is updated annually, so these limitations will be overcome with the availability of more data.



## پیش‌بینی مصرف انرژی برای ساختمان‌های مسکونی بر اساس رفتار ساکنانش با استفاده از روش شبکه عصبی هوش مصنوعی در شهر تبریز

علی زینالی عظیم<sup>۱\*</sup> | حامد پویافر<sup>۲</sup> | بهناز امین نیری<sup>۳</sup> | داود پایدار خیابانی<sup>۴</sup> | آیدا مصطفی‌زاده بازرگان<sup>۵</sup>

۱. نویسنده مسؤل، پژوهشگر پسادکتری طراحی شهری، دانشکده معماری و شهرسازی، دانشگاه تربیت دبیر شهید رجایی، تهران، ایران. رایانامه: [al.zeynaly@gmail.com](mailto:al.zeynaly@gmail.com)
۲. گروه معماری، واحد بین‌المللی ارس، دانشگاه آزاد اسلامی، تبریز، ایران. رایانامه: [hamedpooiafar@gmail.com](mailto:hamedpooiafar@gmail.com)
۳. گروه شهرسازی، تبریز، دانشگاه آزاد اسلامی، تبریز، ایران. رایانامه: [behnaz.aminnayeri2020@pardisiu.ac.ir](mailto:behnaz.aminnayeri2020@pardisiu.ac.ir)
۴. دانشجوی دکتری معماری، واحد اهر دانشگاه آزاد اسلامی، اهر، ایران. رایانامه: [davod.paidarkhiabani@yahoo.com](mailto:davod.paidarkhiabani@yahoo.com)
۵. دانشجوی کارشناسی ارشد، دانشکده معماری، دانشگاه غیرانتفاعی رشیدیه، تبریز، ایران. رایانامه: [aida.mostafazadeh@gmail.com](mailto:aida.mostafazadeh@gmail.com)

### اطلاعات مقاله

### چکیده

نوع مقاله:

پژوهشی

تاریخ‌های مقاله:

تاریخ دریافت: ۱۴۰۳/۰۴/۱۵

تاریخ بازنگری: ۱۴۰۳/۰۵/۱۵

تاریخ پذیرش: ۱۴۰۳/۰۷/۱۵

تاریخ انتشار: ۱۴۰۳/۱۰/۱۵

کلیدواژه:

شبکه عصبی مصنوعی،

پیش‌بینی مصرف انرژی،

خانه‌های هوشمند،

ذخیره انرژی،

شهر تبریز.

با پیشرفت تکنولوژی و افزایش قدرت محاسباتی، امکان تحلیل جامع داده‌های کاربران با بهره‌گیری از تکنیک‌های داده‌های بزرگ فراهم شده است. این تحقیق تلاش کرده تا اطلاعات کاربران را با ویژگی‌های فیزیکی ساختمان‌های مسکونی ترکیب کرده و تأثیر این عوامل بر مصرف انرژی را بررسی کند. تحلیل رگرسیون برای شناسایی دقیق تأثیر هر عنصر بر مصرف انرژی استفاده شد و تکنیک شبکه عصبی مصنوعی (ANN) برای مدل‌سازی و پیش‌بینی مصرف انرژی ورودی در ساختمان‌های مسکونی به کار گرفته شد. نتایج نشان داد شش عامل اصلی شامل تعداد دیوارهای بیرونی، جهت ساختمان، مساحت مسکن، تعداد سال‌های اشغال شده، تعداد اعضای خانواده و شغل سرپرست خانوار، در تمام فصل‌ها تأثیر قابل توجهی بر مصرف انرژی دارند. بر اساس نتایج تحلیل رگرسیون، متغیرهای ورودی مناسب برای آموزش مدل‌های ANN انتخاب شده و مدل‌های پیش‌بینی مصرف انرژی با دقت زیاد بر اساس داده‌های واقعی پیاده‌سازی شدند. این پژوهش نشان داد ترکیب داده‌های کاربران و ویژگی‌های فیزیکی ساختمان‌ها و توجه به عوامل تأثیرگذار فصلی می‌تواند پیش‌بینی مصرف انرژی را به طور قابل توجهی بهبود بخشد. این نتایج تأکید می‌کنند که در تدوین سیاست‌های کارآمد برای مدیریت مصرف انرژی، باید به تعامل بین ویژگی‌های کاربران و ساختمان‌ها توجه ویژه‌ای شود تا امکان صرفه‌جویی انرژی و مدیریت بهینه فراهم شود.

**استناد:** زینالی عظیم، علی؛ پویافر، حامد؛ امین نیری، بهناز؛ پایدار خیابانی، داود و مصطفی‌زاده بازرگان، آیدا (۱۴۰۳). پیش‌بینی مصرف انرژی برای ساختمان‌های مسکونی بر اساس رفتار ساکنانش با استفاده از روش شبکه عصبی هوش مصنوعی در شهر تبریز. *فصلنامه سیستم‌های انرژی پایدار*، ۴ (۱) ۲۶-۱.

DOI: <http://doi.org/10.22059/ses.2024.381731.1091>

© علی زینالی عظیم، حامد پویافر، بهناز امین نیری، داود پایدار خیابانی، آیدا مصطفی‌زاده بازرگان **ناشر:** مؤسسه انتشارات دانشگاه تهران.

DOI: <http://doi.org/10.22059/ses.2024.381731.1091>



## ۱. مقدمه

با افزایش جهانی تقاضا برای انرژی و تغییرات آب‌وهوایی، کاهش مصرف انرژی و بهبود بهره‌وری در ساختمان‌های مسکونی به اولویتی مهم برای سیاست‌گذاران و برنامه‌ریزان تبدیل شده است. ساختمان‌های مسکونی، به دلیل وابستگی زیاد به شرایط فصلی و آب‌وهوایی، نوع مصالح و سیستم‌های انرژی، و از همه مهم‌تر رفتار مصرفی ساکنان، سهم عمده‌ای در مصرف انرژی ایفا می‌کنند [۱]. به عنوان مثال، در سال ۲۰۲۲، بخش مسکونی ایالات متحده ۱۶ درصد از کل انرژی مصرفی بخش‌های نهایی و ۵۶ درصد از مصرف انرژی ساختمان‌ها را به خود اختصاص داد. این آمار نشان می‌دهد ظرفیت زیادی برای بهینه‌سازی و صرفه‌جویی در مصرف انرژی مسکونی وجود دارد و مداخلات سیاستی در این بخش می‌توانند تأثیرات بزرگی داشته باشند. برای مدیریت بهینه انرژی و کاهش مصرف در بخش مسکونی، شناسایی دقیق عوامل مؤثر بر مصرف انرژی و طراحی مدل‌های پیش‌بینی دقیق از اهمیت زیادی برخوردار است [۲]. پیش‌بینی‌های دقیق نه تنها به مدیریت انرژی و بهبود بهره‌وری کمک می‌کنند، بلکه به سیاست‌گذاران امکان می‌دهند تا اقدامات و سیاست‌های کارآمدتری را برای صرفه‌جویی انرژی در بخش مسکونی تدوین کنند [۳]. روش‌های متداول پیش‌بینی مصرف انرژی شامل مدل‌های شبیه‌سازی و مدل‌های داده‌محور هستند؛ مدل‌های شبیه‌سازی اغلب به داده‌های دقیق فیزیکی ساختمان و اطلاعات جزئی رفتار مصرفی نیاز دارند، در حالی که مدل‌های داده‌محور می‌توانند بر اساس داده‌های واقعی مصرف انرژی و پارامترهای محیطی، پیش‌بینی‌های دقیق‌تری ارائه دهند [۴]. مصرف انرژی در ساختمان‌های مسکونی تحت تأثیر رفتار ساکنان و ویژگی‌های مصرفی آن‌ها قرار دارد. برای مثال، در خانه‌هایی که افراد بیشتر زمان خود را در آن سپری می‌کنند، مصرف انرژی معمولاً بیشتر است. همین‌طور سطح درآمد، تعداد افراد خانوار، نوع شغل و سبک زندگی ساکنان همگی می‌توانند مصرف انرژی را به شکل قابل توجهی تحت تأثیر قرار دهند [۵]. با وجود این، بسیاری از مطالعات موجود در زمینه مصرف انرژی مسکونی، تنها به بررسی ویژگی‌های فیزیکی ساختمان‌ها یا رفتار مصرفی یک یا دو عامل محدود پرداخته‌اند و کمتر به الگوهای مصرفی جامع و ترکیب این عوامل توجه کرده‌اند. از سوی دیگر، ساختمان‌های بزرگ معمولاً مجهز به سیستم‌های مدیریت انرژی ساختمان (BEMS) هستند که مصرف انرژی را مدام پایش و بهینه‌سازی می‌کنند، اما در ساختمان‌های مسکونی، به دلیل هزینه و پیچیدگی، این سیستم‌ها کمتر کاربرد دارند [۶]. با پیشرفت فناوری، توسعه دستگاه‌های کم‌هزینه نظارتی و پرتابل که قادر به کنترل و پایش پارامترهای محیطی داخلی و مصارف انرژی هستند، فرصت جدیدی برای بهینه‌سازی مصرف انرژی در ساختمان‌های مسکونی فراهم آورده است. این دستگاه‌ها می‌توانند داده‌هایی را در مورد دما، رطوبت، روشنایی، و سایر پارامترهای محیطی جمع‌آوری کنند و به ساکنان کمک کنند تا با انتخاب‌های آگاهانه‌تر، مصرف انرژی خود را کاهش دهند [۷]. از این منظر، استفاده از روش‌های محاسباتی پیشرفته، مانند شبکه‌های عصبی مصنوعی (ANN) که قابلیت پردازش داده‌های گسترده و شناسایی الگوهای پیچیده را دارند، می‌تواند رویکردی مؤثر برای پیش‌بینی دقیق مصرف انرژی باشد [۸]. شبکه‌های عصبی مصنوعی به دلیل ویژگی‌هایی مانند یادگیری، خودانطباقی، انعطاف‌پذیری و توانایی پردازش روابط غیرخطی، در زمینه پیش‌بینی مصرف انرژی بسیار کارآمد هستند. این شبکه‌ها می‌توانند الگوهای پیچیده‌ای را که به طور مستقیم قابل شناسایی نیستند، شناسایی و مدل‌سازی کنند و به کاربران امکان دهند بدون نیاز به فرمول‌های ریاضی پیچیده، روابط میان متغیرهای ورودی و مصرف انرژی را درک کنند [۹].

این مقاله تلاش دارد تا با استفاده از شبکه‌های عصبی مصنوعی و ترکیب داده‌های نظارتی کم‌هزینه و اطلاعات آب‌وهوایی، مصرف انرژی ساختمان‌های مسکونی در شهر تبریز را پیش‌بینی کند و به شناسایی شرایط غیرعادی مصرف بپردازد. این روش نه تنها به مدیریت مصرف انرژی و بهینه‌سازی مصرف کمک می‌کند، بلکه به ساکنان و سیاست‌گذاران کمک می‌کند تا الگوهای مصرف را درک کنند و به صورت مؤثرتری با چالش‌های انرژی مواجه شوند. بیشتر مطالعات درباره مصرف انرژی ساختمان‌های مسکونی عمدتاً بر ویژگی‌های فیزیکی ساختمان‌ها تمرکز دارند و رفتار کاربران را تنها با یک یا دو عنصر بررسی می‌کنند. با این حال، اطلاعات مربوط به کاربران را نمی‌توان با چنین عناصر محدودی توصیف کرد؛ بنابراین، نیاز به پژوهش‌هایی است که اطلاعات کاربران را از جنبه‌های گوناگون منعکس کنند. در این مطالعه، عناصری که مصرف انرژی الکتریکی را تحت تأثیر قرار می‌دهند، با توجه به هر دو ویژگی فیزیکی ساختمان و اطلاعات جامع‌تر کاربران مورد بررسی قرار گرفته‌اند. نوآوری این مقاله در استفاده از شبکه

عصبی مصنوعی برای پیش‌بینی مصرف انرژی ساختمان‌های مسکونی با تأکید بر رفتار ساکنان در شهر تبریز نهفته است. به خلاف بیشتر مطالعاتی که فقط به ویژگی‌های فیزیکی ساختمان‌ها توجه دارند، این پژوهش تلاش دارد تا تأثیرات رفتار مصرفی ساکنان و عوامل اجتماعی مانند شغل، زمان حضور در خانه و ساختار خانوار را در پیش‌بینی مصرف انرژی در نظر بگیرد. استفاده از داده‌های محلی و ترکیب آن‌ها با روش‌های هوش مصنوعی، رویکردی نوین و دقیق برای مدیریت و بهینه‌سازی مصرف انرژی ارائه می‌دهد که می‌تواند به سیاست‌گذاران و ساکنان کمک کند تا تصمیمات بهتری برای کاهش مصرف انرژی اتخاذ کنند.

### ۱-۱. اثرات ویژگی‌های ساختمان فیزیکی بر مصرف انرژی

اثرات ویژگی‌های فیزیکی ساختمان بر مصرف انرژی یکی از مباحث کلیدی در حوزه معماری و مهندسی ساختمان است. مصرف سالانه برق در ساختمان‌ها به عوامل متعددی همچون نوع مسکن، سال ساخت، تعداد طبقات، ساختار ساختمان و موقعیت جغرافیایی وابسته است. یکی از دغدغه‌های اصلی معماران همواره تأمین آسایش محیطی در ساختمان‌ها بوده است که این موضوع در ساختمان‌های مسکونی اهمیت بیشتری دارد. با توجه به سهم بالای ساختمان‌ها در مصرف انرژی، لزوم کنترل و مدیریت این مصرف، امری بدیهی است که از دیرباز مورد توجه قرار داشته است. شکل ساختمان تأثیر بسیاری در هماهنگی با شرایط اقلیمی و کاهش تأثیرات نامطلوب محیط بیرونی بر فضای داخلی دارد [۴]

طراحی اقلیمی، به معنای سازگارسازی ساختمان‌ها با اقلیم منطقه، نقشی مهم در بهبود آسایش حرارتی ساکنان ایفا می‌کند. این نوع طراحی می‌تواند به جای اعمال فشار بر سیستم‌های گرمایشی و سرمایشی، شرایط مطلوب محیطی را به صورت طبیعی فراهم آورد. متأسفانه امروزه در بسیاری از طراحی‌ها، اهمیت سازگاری بنا با اقلیم نادیده گرفته می‌شود که نتیجه آن، هدررفت چشمگیر منابع انرژی است [۷]. با این توضیح، روشن است که در صورت عدم کنترل مصرف انرژی، در آینده با مشکلات جدی مواجه خواهیم شد. طراحی اقلیمی در گذشته پتانسیل بالای خود را در کاهش مصرف سوخت‌های فسیلی و ایجاد شرایط آسایش نشان داده است. انتخاب صحیح تناسبات ساختمان با توجه به اقلیم و نوع کاربری، همراه با بهره‌گیری از انرژی‌های تجدیدپذیر، از نخستین گام‌ها در کاهش مصرف انرژی به شمار می‌رود. با وجود این، پیشرفت فناوری، تغییر سبک زندگی و تحولات اقلیمی مانند افزایش دما در سال‌های اخیر، نشان می‌دهد راهکارهای سنتی به‌تنهایی قادر به پاسخ‌گویی به نیازهای امروز نیستند. در این شرایط، استفاده هم‌زمان از دانش معماری و فناوری‌های نوین برای حفظ منابع تجدیدناپذیر و مدیریت بهینه مصرف انرژی ضروری به نظر می‌رسد [۸]

علاوه بر این، عوامل متعددی مانند منطقه مسکونی، روش‌های گرمایش، تعداد طبقات و جهت ساختمان تأثیر مستقیمی بر مصرف انرژی دارند. مصرف انرژی یک ساختمان همچنین به عواملی همچون سال ساخت، مساحت خانه، و نحوه گرمایش وابسته است [۹]. طراحی ساختمان‌هایی که بتوانند از طریق فرم و ویژگی‌های کالبدی خود، نیاز به سیستم‌های انرژی بر را کاهش دهند، اهمیت بسیاری در توسعه پایدار و کاهش وابستگی به سوخت‌های فسیلی دارند. این امر به‌وضوح نشان می‌دهد هماهنگی میان طراحی اقلیمی و فناوری‌های نوین، نه تنها باعث افزایش کارایی ساختمان می‌شود، بلکه می‌تواند به کاهش مصرف انرژی و حفظ منابع طبیعی کمک شایانی کند. از این رو، ایجاد یک الگوی طراحی ترکیبی که اصول سنتی و فناوری‌های مدرن را در کنار هم به کار گیرد، ضرورتی اجتناب‌ناپذیر برای معماری معاصر به شمار می‌رود [۱۰].

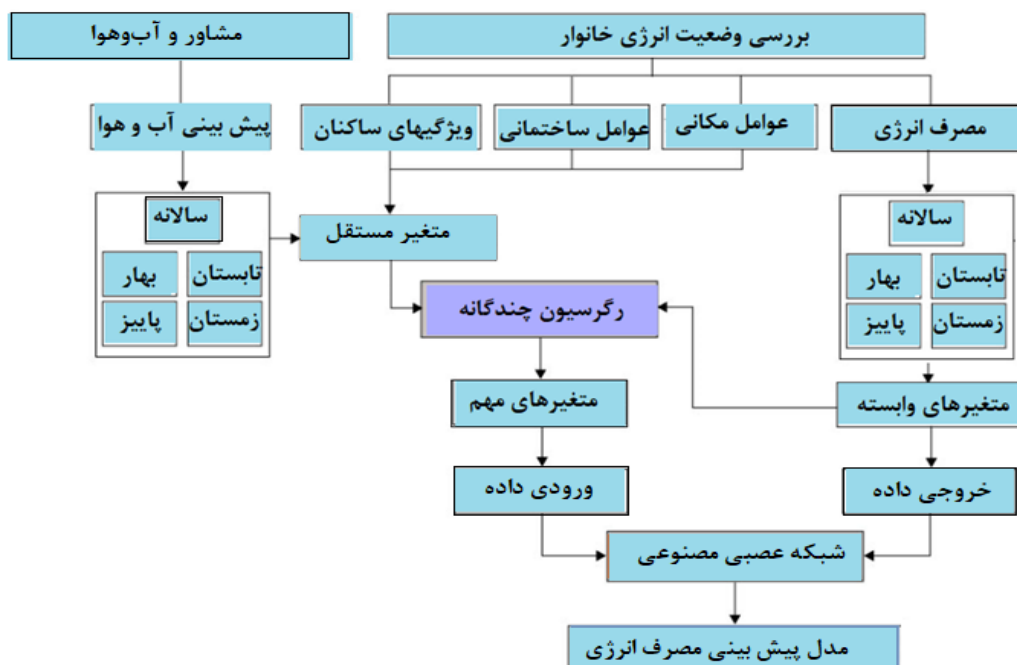
### ۱-۲. تأثیرات جامعه‌شناختی کاربران بر مصرف انرژی

رابطه میان مصرف انرژی و کاربران، همانند آینه‌ای است که تفاوت‌های جامعه‌شناختی را به‌خوبی منعکس می‌کند [۱۱]. مطالعات نشان داده‌اند درآمد افراد نقش مهمی در مصرف انرژی ایفا می‌کند. افراد با درآمدهای بالاتر معمولاً انرژی بیشتری مصرف می‌کنند، زیرا تمایل بیشتری به استفاده از فناوری‌های مدرن و امکانات پیشرفته دارند [۱۲]. در مقابل، کاربران با درآمد سطح پایین‌تر بیشتر تحت تأثیر ویژگی‌های فیزیکی ساختمان‌ها مانند عمر بنا و کیفیت زیرساخت‌ها قرار می‌گیرند که مستقیم بر میزان مصرف انرژی آن‌ها اثرگذار است [۱۳]. سبک زندگی و زمان حضور اعضای خانواده نیز تأثیر قابل توجهی بر مصرف انرژی دارد. به طور مثال، شغل افراد می‌تواند نقش مهمی در این زمینه داشته باشد [۱۴]. کارگران نسبت به افراد خوداشتغال، انرژی بیشتری مصرف می‌کنند، زیرا مدت زمان حضور بیشتری در خانه دارند. علاوه بر این، خانواده‌های پرجمعیت یا خانواده‌هایی که

زمان بیشتری را در محیط خانه سپری می‌کنند، مصرف انرژی بالاتری نسبت به خانوارهای کوچک‌تر یا افراد مجرد دارند [۱۵]. این داده‌ها نشان می‌دهد رفتارهای اجتماعی و انتخاب‌های زندگی کاربران، همانند جریانی پیوسته، مصرف انرژی را شکل می‌دهد. شناخت این رفتارها می‌تواند راهنمایی مهم برای تدوین سیاست‌های بهینه‌سازی مصرف انرژی باشد و به ما بیاموزد که مدیریت پایدار انرژی تنها از طریق درک عمیق جامعه‌شناسی کاربران امکان‌پذیر است.

## ۲. روش کار

شکل ۱ فرایند تحقیق این مطالعه را نشان می‌دهد. ابتدا، داده‌های حاصل از پیمایش دائمی انرژی خانوار با داده‌های دمای منطقه‌ای سالانه کلیات کنستانت ادغام شدند. دوم، تجزیه و تحلیل رگرسیون چندگانه با استفاده از داده‌های یکپارچه برای به دست آوردن عناصر مصرف انرژی در هر فصل انجام شد. سپس، عناصر مؤثر به عنوان داده‌های ورودی برای ساخت یک مدل ANN و اجرای مدل‌های پیش‌بینی مصرف انرژی مورد استفاده قرار گرفتند. برای استخراج دقیق عناصر و ساخت مدل پیش‌بینی، تحلیل رگرسیون و ساخت مدل پیش‌بینی برای پنج دوره سالانه، بهار، تابستان، پاییز و زمستان انجام شد.



شکل ۱. فرایند انجام تحقیق

## ۲-۱. بررسی داده‌های استفاده انرژی خانوار

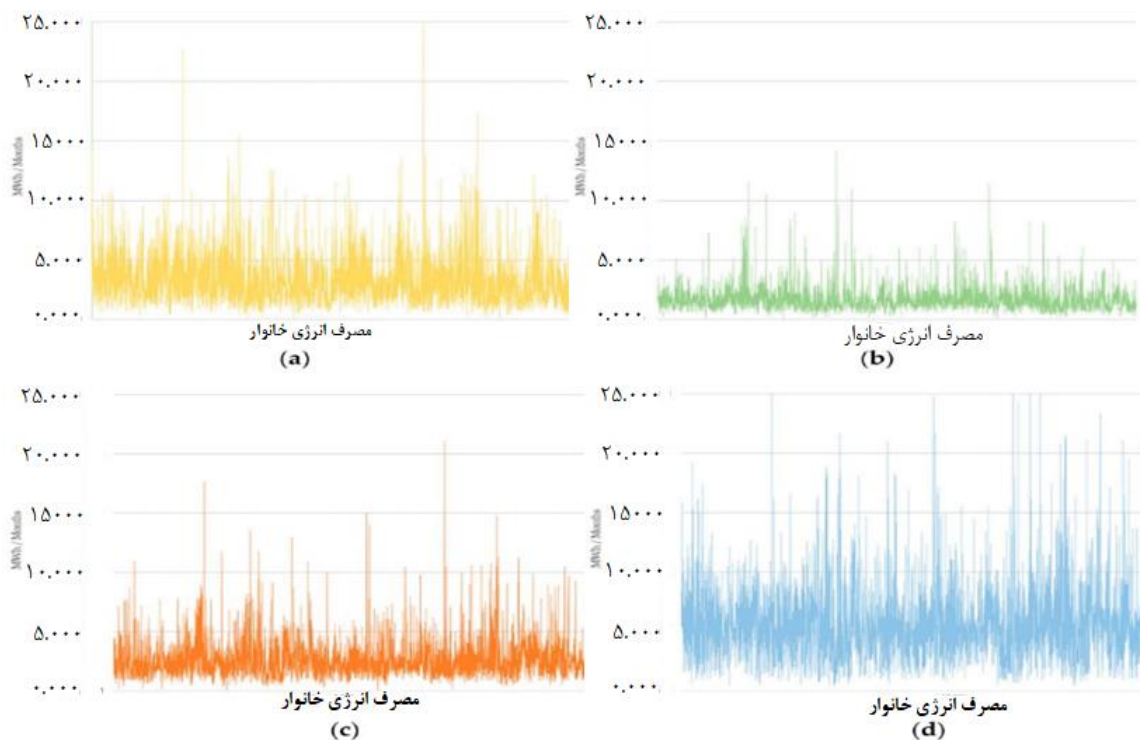
داده‌های مربوط به ساکنان برای این مطالعه از طریق بررسی وضعیت مصرف انرژی خانگی بین سال‌های ۲۰۲۲ و ۲۰۲۳ جمع‌آوری شد؛ این نظرسنجی به طور سالانه توسط مؤسسه اقتصاد انرژی ایران انجام می‌شود. در این نظرسنجی، ۲۵۲۰ خانوار از ۱۰ منطقه مختلف شهر تبریز شرکت کردند و اطلاعات مربوط به ۱۹ عنصر فیزیکی مسکن، ۱۴ عنصر گرمایش، سرمایش و پخت‌وپز، و ۱۴ عنصر خانوار ثبت شد. این تحقیق همچنین داده‌های مصرف ماهانه ۱۸ منبع انرژی مختلف از جمله برق عمومی، برق نیمه‌شب و کل برق را ارائه کرد. مشخص شد که داده‌های اولیه به دلیل محدودیت‌های موجود در نحوه ترکیب آیتم‌ها و سطح افشای کدها، برای یکپارچه‌سازی و تحلیل چندساله مناسب نبودند.

## ۲-۲. ویژگی‌های فصلی در شهر تبریز و اثرات آن بر مصرف انرژی

شهر تبریز دارای چهار فصل متمایز است؛ بنابراین، ساکنان در هر فصل از لوازم خانگی و منابع انرژی مختلفی استفاده می‌کنند.

این تغییر فصل‌ها همچنین مدت زمان حضور ساکنان داخل خانه را تحت تأثیر قرار می‌دهد. در فصل‌های بهار و پاییز، مصرف انرژی مسکونی در سطح پایینی قرار دارد، زیرا روزهای روشن و خشک بسیاری به دلیل تأثیر واچرخندهای مهاجر وجود دارد. در فصل تابستان، مصرف انرژی به دلیل استفاده از تجهیزات سرمایشی افزایش می‌یابد، در حالی که در فصل زمستان، به علت سرد و خشک بودن هوا تحت تأثیر واچرخندهای قاره‌ای، مصرف انرژی برای گرمایش به طور قابل توجهی افزایش پیدا می‌کند [۱۶].


شکل ۲ داده‌های مصرف انرژی فصلی ۴۳۹۰ خانوار، به استثنای داده‌های پرت را نشان می‌دهد. مشخص شد که مصرف انرژی در زمستان بیشترین مقدار را دارد. علاوه بر این، مصرف انرژی در بهار و زمستان بالا بود وقتی که دماهای نسبتاً کمتری در مقایسه با دیگر فصل‌ها مشاهده شد. این نشان می‌دهد مصرف انرژی مربوط به گرمایش به طور قابل توجهی مصرف انرژی کل ساختمان‌ها را تحت تأثیر قرار می‌دهد. در میان متغیرهای خروجی متفاوت که می‌توان آن‌ها را با نرم‌افزار بازگرداند، مقادیر ساعتی آن‌ها به احتمال بیشتر با استفاده از ابزارهای کم‌هزینه‌ای که برای تحلیل بعدی انتخاب شده‌اند، کنترل می‌شوند: میانگین دماهای خارج از ساختمان، میانگین دما، شعاع نور، رطوبت نسبی، تراکم دی‌اکسید کربن ( $CO_2$ )، میزان روشنایی متوسط (که در مرکز ناحیه‌ی اتاق نشیمن، تخمین زده می‌شود)، به همراه انرژی روشنایی و وسایل. با رجوع به شرایط بیرونی، شرایطی که از طرف ایستگاه‌های هواشناسی بیشتر در دسترس هستند، در نظر گرفته شدند: دمای هوای خشک، رطوبت نسبی، عمق بارش باران، و سرعت باد. شدت تابش خورشید، اگرچه نقش مهمی در تعادل انرژی ایفا می‌کند، به شکل مستقیم در نظر گرفته نشد، زیرا ایستگاه‌های نسبتاً کمی می‌توانند این مقدار را ارائه دهند، اما میزان روشنایی به عنوان متغیر جانشین خوب، در نظر گرفته شد. در پایان، مقادیر ساعتی انرژی گرمایشی کل (وضعیت موجود، پذیرفته شد و کیلووات در ساعت بیان شد) نیز به دست آورده شدند تا به عنوان متغیرهای هدف در تحلیل بعدی، استفاده شوند. با رجوع به شرایط آب‌وهوایی، ترجیح داده شد که داده‌های استفاده‌شده، از یک مجموعه‌ی اطلاعاتی بزرگ و مشابه باشند. همه‌ی تحلیل‌ها با استفاده از اطلاعات آب‌وهوایی 2024 Climate Consultan انجام شدند:



شکل ۲. توزیع مصرف انرژی خانوار بر اساس فصل، (الف) بهار؛ (ب) تابستان؛ (ج) پاییز؛ (د) زمستان

تجزیه و تحلیل برای هر یک از چهار فصل انجام شد تا تأثیر منابع انرژی و دستگاه‌های مصرف‌کننده انرژی در هر فصل را منعکس کند. مصرف انرژی سالانه برای شناسایی عناصر تأثیرگذار کلی مورد بررسی قرار گرفت. به عنوان جمع‌بندی نمودار گلباد تبریز در ماه‌های مختلف سال به صورت شکل ۳ ارائه شد.






شکل ۳. نمودار گلباد تبریز (Climate Consultant, 2024)

شکل ۳ که نمودار گلباد شهر تبریز را در تمام ماه‌ها و ساعت‌ها نشان می‌دهد حاکی از آن است که در تبریز بیشتر اوقات وزش باد وجود دارد که حداکثر سرعت آن در شرق و جنوب غربی است و در این دو جهت تغییر سرعت باد و تلاطم نیز بیشتر است. از ۵ تا ۱۳ متر بر ثانیه متغیر است. بیشترین ساعت‌های وزش باد در جهت شرق است. تمام جهات معمولاً به طور میانگین رطوبت نسبی ۳۵-۶۵ درصد و دمای ۵-۲۵ درجه را دارد. بادهای شرقی در ماه‌های گرم مناسب و محدوده آسایش را افزایش می‌دهد و در ماه‌های سرد باعث سوز باد و یا کج باران می‌شود بنابراین در جهت شرقی باید بیشترین تمهیدات انجام شود. نمودار موجود در شکل ۳ با توجه به داده‌های علوم کشاورزی به دست آمده و با ترکیب و در نظرگیری دو فاکتور دمای ماهانه و میزان بارش بیان می‌دارد که در ماه‌هایی که نمودار دما، خط مربوط به میزان بارش را قطع می‌کند و از آن فراتر می‌رود، پوشش گیاهی که موجود در سایت و فضاهای آزاد نیاز به آبیاری و تمهیدات لازم جهت حفظ و نگهداری است. همان‌گونه که مشاهده می‌شود از اواخر مه تا اوایل نوامبر خط مربوط به دما، نمودار بارش را قطع کرده است. پس در این بازه زمانی که غالب آن در تابستان قرار می‌گیرد، پوشش گیاهی در فضای آزاد و سایت نیاز به آبیاری دارد و میزان بارش موجود برای حفظ آن کافی نخواهد بود.

در شکل ۴ نمودار سایکرومتریک تبریز نشان می‌دهد به طور طبیعی حدود ۱۵ درصد (۱۲۴۶ ساعت) بدون بهره‌گیری از امکانات فعال و غیرفعال در محدوده آسایش هستیم. با بهره‌گیری از خنک‌کننده‌های دومرحله‌ای تبخیری به میزان ۱۰ درصد به محدوده آسایش اضافه می‌شود، با استفاده از رطوبت‌زنی صرف به محیط اگرچه تأثیر آن در این اقلیم کم است و فقط به ماه‌های گرم سال و در برخی از ساعت‌ها کاربرد دارد، ولی باعث افزایش محدوده آسایش می‌شود و اما مهم‌ترین فاکتور در اقلیم تبریز استفاده از گزینه ۱۰ یعنی گرم کردن همراه رطوبت‌زنی است که شامل تأثیر ۲۷ درصدی در محدوده آسایش می‌شود؛ به بیانی ۱۳۳۶ ساعت آسایش که مقدار زیادی است. با استفاده از این سه گزینه می‌توان منطقه آسایش ۱۰۰ درصد را ایجاد کرد اگرچه با استفاده از گزینه‌های افزایش حرارتی داخلی و در نظر گرفتن اثر غیرفعال خورشید در جرم حرارتی زیاد در این اقلیم نیاز به گرم کردن با استفاده از تجهیزات مکانیکی را کاهش داد، ولی نمی‌توان از استفاده با تجهیزات گرماساز چشم‌پوشی کرد. استفاده از فن‌های تهویه و وسایل خنک‌سازی با توجه به وزش خنک بادهای شرقی و شمال شرقی در این اقلیم زیاد کاربرد ندارد.



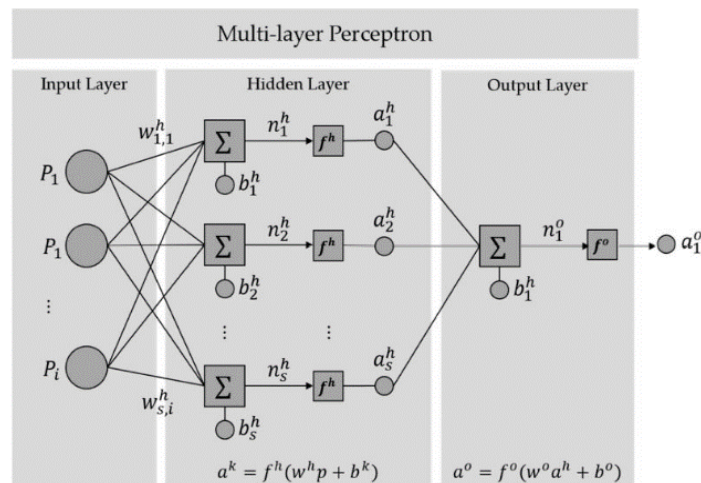


شکل ۴. نمودار سایکرومتریک (Climate Consultant, 2022)


## ۲-۳. شبکه عصبی مصنوعی (ANN)

در این پژوهش، شبکه عصبی مصنوعی (ANN) با استفاده از جعبه‌ابزار شبکه عصبی در برنامه‌ی مطلب پیاده‌سازی شد و تنظیم پارامترها از طریق الگوریتم انتشار معکوس لونبرگ - مارکوارت انجام گرفت. یک شبکه پیش‌خور دولایه‌ای با نورون‌های حلقوی مخفی و نورون‌های خروجی خطی به کار گرفته شد و تعداد نورون‌ها با روش آزمایش و خطا تعیین شد. مقادیر ساعتی انرژی گرمایشی به‌عنوان داده‌های هدف و ده متغیر قبلی به عنوان ورودی استفاده شدند؛ همچنین داده‌هایی مانند ساعت روز، روز هفته و میانگین دماهای داخلی و خارجی اضافه شدند. به منظور ارزیابی دقت مدل، از معیارهایی مانند MSE و ضریب همبستگی (R) استفاده شد. مدل با داده‌های ۲۰ ساختمان آپارتمانی در تبریز، در بازه‌ای که شامل ۱۴۲۶۰ ساعت داده مصرف انرژی بود، پیاده‌سازی شد. به‌علاوه، شش متغیر شخصی شامل جنسیت، سن، شغل، درآمد، سطح تحصیلات و مدت اقامت بررسی و مدلی با دقت ۷۱ درصد ارائه شد که اهمیت این متغیرها در مصرف انرژی را نشان می‌دهد. با توجه به شبیه‌سازی داده‌های انرژی، مقایسه با داده‌های واقعی برای اعتبارسنجی مدل و تحقیقات بیشتر برای تحلیل مصرف فصلی و بررسی ساختمان‌های مختلف توصیه می‌شود.

$$n_k^h = \sum_{j=1}^R w_{kj}^h p_j + b_k^h, k = 1 \text{ to } s. \quad (1)$$



شکل ۵. ساختار مدل شبکه عصبی مصنوعی (ANN).



شکل ۶. ساختار یک مدل پیش‌بینی مصرف انرژی فصلی

### ۳. نتایج و بحث

#### ۳-۱. استخراج عناصر تأثیرگذار

این بخش به طور کلی به شناسایی و استخراج عواملی می‌پردازد که می‌توانند بر متغیرهای مورد بررسی تأثیرگذار باشند. در این مطالعه، عناصر تأثیرگذار شامل جنبه‌های مختلفی از داده‌های خانوار، ویژگی‌های ساختمان‌ها و اطلاعات کاربران هستند که با دقت مورد تجزیه و تحلیل قرار گرفته‌اند.

#### ۳-۱-۱. فرایند تجزیه و تحلیل (چندخطی بودن، خارج از دسترس، و متغیرهای مستقل و وابسته)

فرایند تجزیه و تحلیل برای اطمینان از دقت نتایج و شناسایی روابط بین متغیرها به کار گرفته شده است. این فرایند شامل حذف داده‌های پرت، بررسی متغیرهای مستقل و وابسته، و ارزیابی چندخطی بودن متغیرها است.

#### ۱. حذف داده‌های پرت

در مرحله پیش‌پردازش، داده‌های پرت شناسایی و حذف شدند تا از تأثیر آن‌ها بر دقت نتایج جلوگیری شود. این داده‌ها شامل خانوارهایی بودند که اطلاعات نادرست یا غیرقابل شناسایی داشتند. نمونه آماری این پژوهش شامل ۲۴۰۰ خانوار در هر یک از سال‌های ۲۰۲۲ و ۲۰۲۳ است. داده‌های پرت شامل ۹۸ خانوار با اطلاعات غیرقابل تشخیص، ۴ خانوار در صدک‌های بالا و ۸ خانوار با تعداد زیادی افراد مسن بودند که حذف شدند.

#### ۲. عناصر ساختمان و اطلاعات کاربر

مطابق جدول ۱، داده‌ها شامل ۱۲ عنصر ساختمان فیزیکی و ۱۲ عنصر اطلاعات کاربر از تمامی ۱۰ منطقه بودند. این عناصر شامل اطلاعاتی در مورد مشخصات فیزیکی ساختمان و ویژگی‌های دموگرافیک کاربران، مانند جنسیت، سن، سطح تحصیلات و شغل سرپرست خانوار است. این اطلاعات به منظور تحلیل جامع ویژگی‌های خانوار و تأثیر آن‌ها بر متغیرهای کیفیت زندگی مورد بررسی قرار گرفت.

#### ۳. ویژگی‌های جغرافیایی، جو اجتماعی، اقتصادی و آب‌وهوایی

متغیرهای مکانی مانند ویژگی‌های جغرافیایی، جو اجتماعی، مشخصات اقتصادی و شرایط آب‌وهوایی سالانه به عنوان مؤلفه‌های اساسی برای تحلیل جامع شرایط مناطق مختلف لحاظ شدند. اطلاعات آب‌وهوایی از نرم‌افزار مشاور آب‌وهوا به دست آمد که تغییرات دمایی قابل توجه در سال‌های ۲۰۲۰ و ۲۰۲۳ را نشان داد. برای مثال، ساختمان‌های رو به شمال در تبریز که بهره‌وری انرژی کمتری دارند، به طور خاص کدگذاری و تحلیل شدند.

#### ۴. متغیرهای اسمی و تجزیه و تحلیل رگرسیون

در تحلیل رگرسیون، متغیرهای اسمی مانند جنسیت و شغل با استفاده از کدگذاری ساختگی تحلیل شدند. متغیرهای مرجع به صورت دقیق برای هر متغیر اسمی مشخص شدند تا بتوان ارتباطات بین متغیرهای مختلف را به صورت معنادار بررسی کرد. این مرحله به مقایسه اثرات متغیرهای مختلف و ارزیابی تأثیر آن‌ها کمک کرد.

#### ۵. ارزیابی چندخطی بودن متغیرها

صحت چندخطی بودن متغیرها پیش از تحلیل بررسی شد. چندخطی بودن، به معنای همبستگی زیاد میان متغیرهای مستقل است که می‌تواند باعث انحراف در نتایج تحلیل شود. در این مطالعه، با بررسی عامل تورم واریانس (VIF) که برای تمام آیت‌ها کمتر از ۱۰ بود، مشخص شد که هیچ چندخطی قابل توجهی بین متغیرها وجود ندارد. این بررسی، تضمینی برای صحت و دقت بیشتر نتایج نهایی تحلیل فراهم می‌آورد.

جدول ۱. نتایج تجزیه و تحلیل ساخت داده‌ها، آمارهای توصیفی و عوامل تورم واریانس (VIF)

کد	متغیر	دسته	میانگین	انحراف استاندارد	N	قدر نسبت	VIF
		منطقه ۱	۰.۶۴۷/۰۰	۲۴۶.۰۹/۰	۴۶۹۰	۰.۷۰۳	۱/۴۲۳
		منطقه ۲	۰.۴۷۵/۰۰	۲۱۲۸۲/۰	۴۶۹۰	۰.۷۷۸	۱/۲۸۵
		منطقه ۳	۰.۴۷۷/۰۰	۲۱۳۲۵/۰	۴۶۹۰	۰.۷۷۴	۱/۲۹۲
		منطقه ۴	۰.۴۷۳/۰۰	۲۱۲۳۹/۰	۴۶۹۰	۰.۷۵۶	۱/۳۲۲
		منطقه ۵	۰.۴۷۱/۰۰	۲۱۱۹۵/۰	۴۶۹۰	۰.۷۹۱	۱/۲۶۴
شهر	مناطق تبریز	منطقه ۶	۰.۳۲۴/۰۰	۱۷۷۰۰/۰	۴۶۹۰	۰/۸۱۸	۱/۲۲۲
		منطقه ۷	۱۱۰۷/۰	۳۱۳۷۴/۰	۴۶۹۰	۰/۶۲۸	۱/۵۹۳
		منطقه ۸	۰.۴۷۵/۰۰	۲۱۲۸۲/۰	۴۶۹۰	۰/۷۳۳	۱/۳۶۴
		منطقه ۹	۰.۴۲۳/۰۰	۲۰۸۰۲/۰	۴۶۹۰	۰/۷۴۴	۱/۳۴۵
		منطقه ۱۰	۰.۶۳۷/۰۰	۲۴۴۲۹/۰	۴۶۹۰	۰/۶۶۷	۱/۵۰۰
		خانه مستقل یا ویلایی	۳۸۶۲/۰	۴۸۶۹۳/۰	۴۶۹۰	۰/۴۰۰	۲/۵۰۰
B_a1	نوع خانه‌سازی	آپارتمان	۴۵۷۴/۰	۴۹۸۲۳/۰	۴۶۹۰	۰/۲۲۶	۴/۴۳۳
		دیگر موارد*	-	-	-	-	-
B_a2	تعداد طبقات	عددی	۲۲/۸	۸۰۵/۷	۴۶۹۰	۰/۱۸۲	۵/۴۸۵
B_a3	شماره طبقه	عددی	۳۴/۴	۹۴۳/۴	۴۶۹۰	۰/۴۴۳	۲/۲۵۸
B_a4	تعداد دیوارهای بیرونی	عددی	۴/۳۳	۱/۲۷۸	۴۶۹۰	۰/۵۸۲	۱/۷۱۸
		شرق	۰/۱۱۹۴	۴۶۹۰	۴۶۹۰	۰/۳۰۳	۳/۳۰۵
		غرب	۰۰/۰۶۴۱	۴۶۹۰	۴۶۹۰	۰/۴۲۶	۲/۳۴۶
		جنوب	۰/۴۲۰۰	۴۶۹۰	۴۶۹۰	۰/۱۶۲	۶/۱۸۹
		شمال*	-	-	-	-	--
B_a4	جهت خانه‌سازی	جنوب شرقی	۰/۱۹۹۳	۰/۳۹۹۴۹	۴۶۹۰	۰/۲۲۴	۴/۴۷۳
		جنوب غربی	۰/۱۰۳۴	۰/۳۰۴۴۸	۴۶۹۰	۰/۳۲۷	۳۰/۰۵۵
		شمال شرقی	۰.۲۹۹/۰۰	۱۷۰.۴۴/۰	۴۶۹۰	۰/۶۱۰	۱/۶۴۰
		شمال غربی	۰.۱۹۰/۰۰	۱۳۶۶۰/۰	۴۶۹۰	۰/۶۹۴	۱/۴۴۰
B_a6	سال ساخت و ساز	عددی	۸۲/۳	۲۹۸/۱	۴۶۹۰	۴۶۹۰	۱/۶۷۴
B_a7	مساحت خانه‌سازی	عددی	۱۷/۳	۸۶۷/۰	۴۶۹۰	۴۶۹۰	۲/۳۷۸
B_a8	تعداد اتاق خواب‌ها (اتاق‌ها)	عددی	۷۲/۲	۷۲۸/۰	۴۶۹۰	۴۶۹۰	۱۹/۰۵۰
B_a9	تعداد پنجره‌های دیوار بیرونی	عددی	۱۱/۸	۹۶۱/۳	۴۶۹۰	۰/۷۳۷	۱/۳۵۷

## ادامه جدول ۱.

کد	متغیر	دسته	میانگین	انحراف استاندارد	N	قدر نسبت	VIF	کد
B_a10	روش گرمایش اصلی	۱	مجزا	۹۰۹۲/۰	۴۶۹۰	۴۶۹۰	۰/۷۸۵	۱/۲۷۴
		۲	گرمایش مرکزی*	—	—	—	—	—
B_a11	روش سرمایه‌گذاری	۱	تهویه مطبوع	۳۰۴۵/۰	۴۶۰۲۳/۰	۴۶۹۰	۰/۱۸۰	۵/۵۵۸
		۲	بدون تهویه مطبوع*	—	—	—	—	—
B_a11	دستگاه تهویه مطبوع، دما را تنظیم می‌کند		عددی	۱۳/۳	۰۴۹/۲۰	۴۶۹۰	۰/۱۶۰	۶/۳۳۹
H_a1	تعداد سال‌هایی که ساکن بوده‌اند.		عددی	۹۱/۱۰	۷۲۲/۸	۴۶۹۰	۰/۱۵۴	۶/۵۱۳
H_a2	مالک خانه	۱	مالک	۷۵۸۹/۰	۴۲۷۸۲/۰	۴۶۹۰	۰/۸۲۷	۱/۲۰۹
		۲	مالک نیست	—	—	—	—	—
H_a3	تعداد اعضای خانوار		عددی	۹۷/۲	۲۴۲/۱	۴۶۹۰	۰/۴۸۷	۲۰/۰۵۴
H_a4	تعداد اعضای خانوار که از نظر اقتصادی فعال هستند (کار می‌کنند)		عددی	۴۵/۱	۷۶۷/۰	۴۶۹۰	۰/۶۲۲	۱/۶۰۸
H_a5	تعداد اعضای خانوار که بالای ۶۵ سال و یا بیشتر از ۶۵ سن دارند		عددی	۴۷/۰	۰۷۴۳/	۴۶۹۰	۰/۵۵۷	۱/۷۹۵
H_a6	ترکیب اعضای خانوار	۱	کودکان	۰۵۰۰/۰۰	۴۶۹۰	۴۶۹۰	۰/۷۵۶	۱/۳۲۲
		۲	بدون کودکان*	—	—	—	—	—
H_a7	جنس سرپرست خانوار	۱	مرد	۷۴۹۹/۰	۴۳۳۰۹/۰	۴۶۹۰	۰/۷۴۲	۱/۳۴۸
		۲	زن*	—	—	—	—	—
H_a8	سن سرپرست خانوار		عددی	۷۴/۳	۰۵۲/۱۰	۴۶۹۰	۰/۴۸۶	۲۰/۰۵۶
H_a9	سطح تحصیلات سرپرست خانوار	۱	دیپلم یا زیر دیپلم	۵۸۵۵/۰	۴۶۹۰	۴۶۹۰	۰/۶۲۴	۱/۶۰۲
		۲	لیسانس یا بالاتر از لیسانس	—	—	—	—	—
H_a10	شغل سرپرست خانوار	۱	کارمند دائمی	۴۹۶۵/۰	۵۰۰۰۴/۰	۴۶۹۰	۰/۳۶۰	۲/۷۷۵
		۲	کارمند موقتی	۰۵۵۸/۰۰	۲۲۹۶۳/۰	۴۶۹۰	۰/۷۷۰	۱/۲۹۸
		۳	مالک‌گرداننده	۲۳۲۰/۰	۴۲۲۱۸/۰	۴۶۹۰	۰/۴۵۹	۲/۱۷۹
		۴	موارد دیگر	—	—	—	—	—
H_a11	ویژگی‌های غیرعادی خانوار	۱	ویژگی‌های غیرعادی	۰۹۸۱/۰۰	۲۹۷۵۰/۰	۴۶۹۰	۰/۶۳۳	۱/۵۷۹
		۲	عادی*	—	—	—	—	—
H_a12	درآمد ناخالص سالیانه		عددی	۳/۶۷	۱/۸۶۲	۴۶۹۰	۰/۴۲۶	۲/۳۴۷

جدول ۲ نشان می‌دهد مدل‌های تحلیل رگرسیون برای مصرف انرژی مسکونی در دوره‌های مختلف سالانه، بهار، تابستان، پاییز و زمستان به خوبی مناسب بوده‌اند. نتایج آزمون دوربین - واتسون بین ۱/۵۳۸ و ۱/۶۹۸ متغیر بود، که نشان‌دهنده نبود خودهمبستگی است؛ چرا که این مقادیر به عدد ۲ نزدیک هستند. توان توضیحی مدل برای مصرف انرژی مسکونی، به عنوان متغیر وابسته در ارتباط با متغیرهای مستقل، به ترتیب ۱۶ درصد در دوره سالانه، ۱۶/۵ درصد در بهار، ۱۸/۲ درصد در تابستان، ۱۷ درصد در پاییز و ۱۶/۳ درصد در زمستان ارزیابی شد. این مقادیر در مقایسه با مطالعات پیشین درباره مصرف انرژی در

ساختمان‌ها نسبتاً پایین است. به نظر می‌رسد دلیل این موضوع، گنجاندن ویژگی‌های کاربران از جمله عوامل جامعه‌شناختی و انسانی در تحلیل است که این متغیرها پیچیدگی بیشتری را به مدل افزوده‌اند.

جدول ۲. نتایج تحلیل تناسب و توان توضیحی مدل

دوره زمانی	ضریب غیر استاندارد	$R^2$	$R^2$ تعدیل شده	برورد خطای استاندارد	دورین-واتسون	F	سطح معناداری
سال	۰/۳۳۵	۰/۱۱۸	۰/۱۰۹	۵۱۶۷/۳۱۲	۱/۵۴۱	۱۲۸/۰۶۵	۰/۰۰۱
بهار	۰/۳۴۲	۰/۱۲۳	۰/۱۱۴	۱۴۳۲/۳۶۰	۱/۵۹۸	۱۳۷/۰۸۵	۰/۰۰۱
تابستان	۰/۳۶۳	۰/۱۳۹	۰/۱۳۱	۶۹۴۸/۰۸۳	۱/۶۷۳	۱۸/۹۵۳	۰/۰۰۱
پاییز	۰/۳۱۶	۰/۱۰۷	۰/۰۹۸	۱۰۵۳/۱۸۶	۱/۵۸۴	۱۲۴/۰۰۱	۰/۰۰۱
زمستان	۰/۳۳۲	۰/۱۲۱	۰/۱۰۱	۱۹۸۵۳/۰۳۲	۱/۵۶۹	۱۵/۶۹۳	۰/۰۰۱


### ۳-۲. عناصر مؤثر بر مصرف انرژی

جدول ۳ عناصر فیزیکی و ویژگی‌های کاربران را که از طریق تجزیه و تحلیل رگرسیون به عنوان عوامل مؤثر بر مصرف انرژی مسکونی سالانه و در دوره‌های فصلی بهار، تابستان، پاییز و زمستان شناسایی شده‌اند، نشان می‌دهد. متغیرهای کدگذاری شده ساختگی نیز با مقایسه با گروه مرجع تحلیل شده‌اند تا اثرات هر متغیر را بر مصرف انرژی به طور دقیق‌تری مشخص کنند.


جدول ۳. عناصر فیزیکی و ویژگی‌های کاربر

بخش	کد متغیرها	متغیر	بهار	تابستان	پاییز	زمستان	سالانه
دما		دما	0		0		
عوامل ساختمانی ۱۲ عامل	۱B-a	نوع مسکن		0	0	0	0
	۲B-a	تعداد طبقات				0	
	۳B-a	شماره طبقه					
	۴B-a	تعداد دیوارهای بیرونی	0	0	0	0	0
	۵B-a	جهت مسکن	0	0	0	0	0
	۶B-a	سال ساخت	0	0	0	0	
	۷B-a	منطقه مسکن	0	0	0	0	0
	۸B-a	تعداد اتاق خواب (اتاق)		0			
	۹B-a	تعداد پنجره‌های دیوار بیرونی				0	0
	۱۰B-a	روش گرمایش اصلی	0	0	0		
	۱۱B-a	روش خنک‌کننده		0	0		0
	۱۲B-a	تنظیم دمای کولر گازی			0	0	
ویژگی ساکنان ۱۲ عامل	۱H_a	تعداد سال‌های اشتغال شده	0	0	0	0	0
	۲H_a	مالکیت مسکن					
	۳H_a	تعداد اعضای خانوار	0	0	0	0	0
	۴H_a	تعداد اعضای فعال اقتصادی خانوار					
	۵H_a	تعداد اعضای خانواده ۶۵ سال یا بیشتر		0			
	۶H_a	ترکیب اعضای خانواده			0		
	۷H-a	جنسیت			0	0	0
	۸H_a	سن سرپرست خانوار				0	
	۹H-a	سطح تحصیلات سرپرست خانوار				0	
	۱۰H_a	شغل سرپرست خانوار	0	0	0	0	0
	۱۱H_a	ویژگی‌های غیر معمول خانه		0		0	
	۱۲H_a	درآمد ناخالص سالانه	0	0		0	0


علاوه بر متغیرهای مناطق، مشخص شد که در میان عناصر فیزیکی ساختمان، تعداد دیوارهای خارجی، جهت مسکن و منطقه مسکونی در تمام فصل‌ها تأثیرگذار بوده‌اند. در میان ویژگی‌های کاربر، تعداد سال‌های اشغال‌شده، تعداد اعضای خانواده و اشغال سرپرست خانواده در تمام فصل‌ها تأثیرگذار بودند. شکل‌های ۷ - ۱۲ نمودارهای توزیع مصرف انرژی سالانه و فصلی را برای این شش عنصر نشان می‌دهند.




(a)




(b)



(c)








(d)




(e)

شکل ۷. مصرف انرژی فصلی با توجه به دیوارهای خارجی: (الف) سالانه؛ (ب) بهار؛ (ج) تابستان؛ (د) پاییز؛ (ه) زمستان




شکل ۸. مصرف انرژی فصلی بر اساس جهت ساختمان: (الف) سالانه؛ (ب) بهار؛ (ج) تابستان؛ (د) پاییز؛ (ه) زمستان







مساحت ساختمان  
(a)




مساحت ساختمان  
(b)



مساحت ساختمان  
(c)




مساحت ساختمان  
(d)




مساحت ساختمان  
(e)

شکل ۹. مصرف انرژی فصلی بر اساس مساحت ساختمان: (الف) سالانه؛ (ب) بهار؛ (ج) تابستان؛ (د) پاییز؛ (ه) زمستان




میزان سالهای مورد استفاده

(a)




میزان سالهای مورد استفاده

(b)




میزان سالهای مورد استفاده

(c)



میزان سالهای مورد استفاده


(d)




میزان سالهای مورد استفاده

(e)


شکل ۱۰. مصرف انرژی فصلی با توجه به سال‌های مورد استفاده: (الف) سالانه؛ (ب) بهار؛ (ج) تابستان؛ (د) پاییز؛ (ه) زمستان




(a)




(b)



(c)

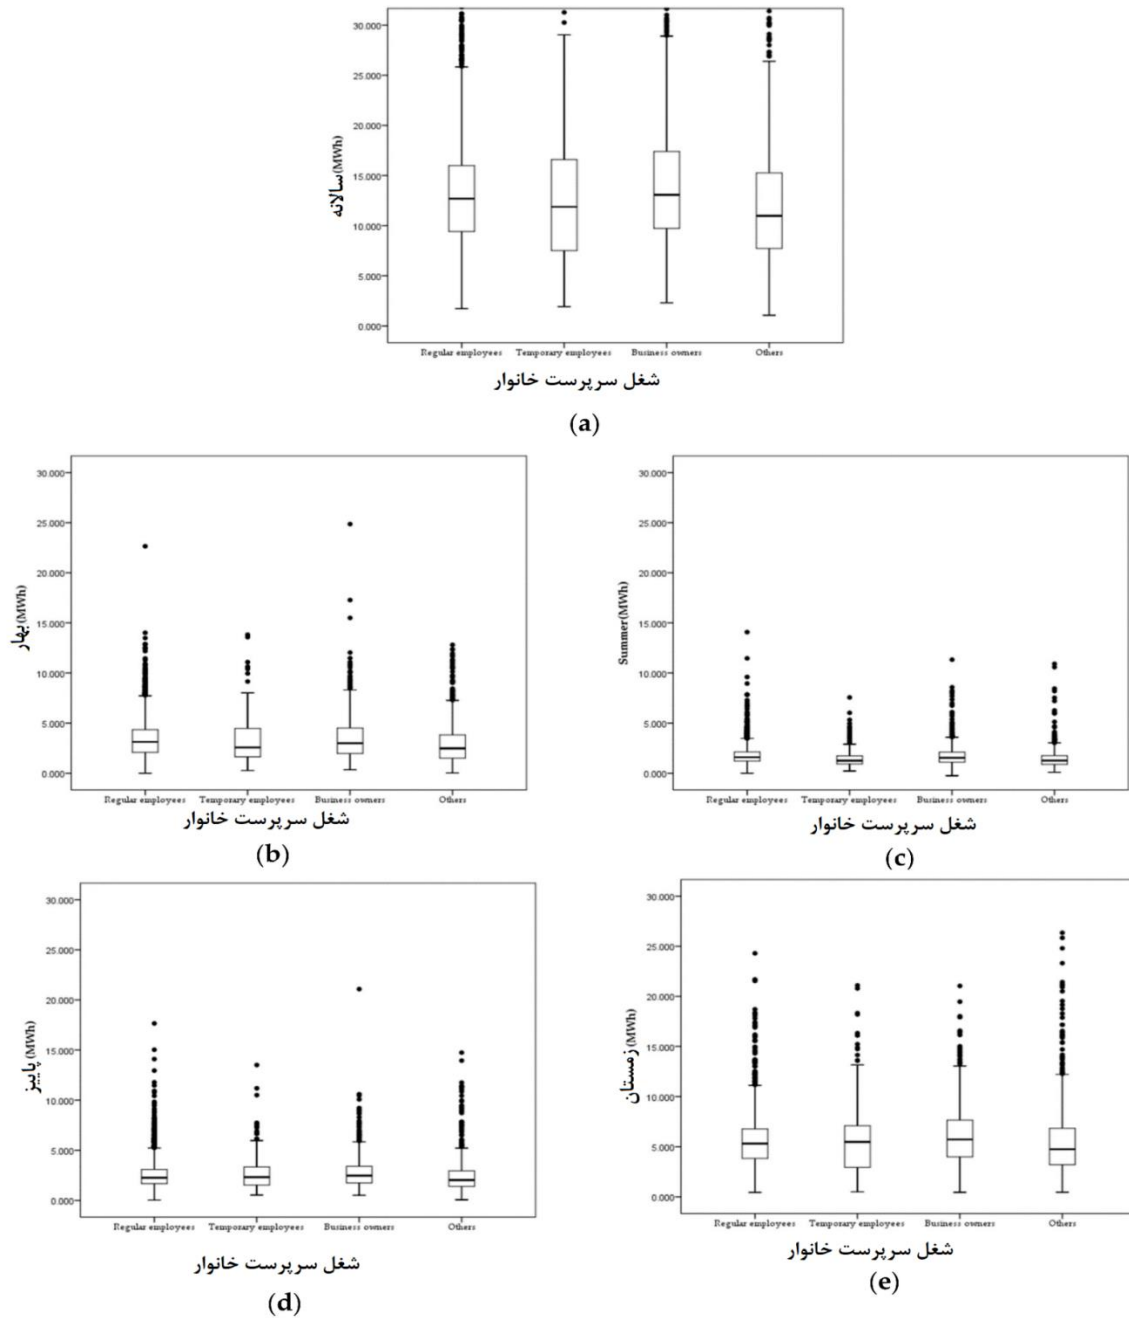


(d)



(e)

شکل ۱۱. مصرف فصلی انرژی با توجه به تعداد اعضای خانوار: (الف) سالانه؛ (ب) بهار؛ (ج) تابستان؛ (د) پاییز؛ (ه) زمستان



شکل ۱۲. مصرف فصلی انرژی با توجه به شغل سرپرست خانوار: (الف) سالانه؛ (ب) بهار؛ (ج) تابستان؛ (د) پاییز؛ (ه) زمستان

### ۳-۳. مدل پیش‌بینی مصرف انرژی

مدل پیش‌بینی مصرف انرژی به منظور تخمین میزان انرژی مصرفی در بخش مسکونی طراحی شده است و از عوامل مختلف مانند فصلی بودن و ویژگی‌های کاربر برای بهبود دقت پیش‌بینی‌ها بهره می‌برد. این مدل با استفاده از شبکه‌های عصبی مصنوعی (ANN) و تحلیل رگرسیون، روندهای مصرف انرژی را براساس متغیرهای ورودی انتخاب‌شده برای هر فصل بررسی و تحلیل می‌کند.

### ۳-۳-۱. داده‌های ورودی/خروجی

مدل شبکه عصبی مصنوعی (ANN) برای پنج بازه زمانی سالانه، بهار، تابستان، پاییز و زمستان ایجاد شد. متغیرهایی که در هر فصل تأثیرگذار بودند، به عنوان ورودی مدل برای تحلیل انتخاب شدند. برای متغیرهای اسمی، مدل ANN با در نظر گرفتن

گروه مرجع و پس از اجرای کدگذاری ساختگی توسعه یافت. با توجه به متغیرهای ورودی مرتبط در هر مدل، تعداد متغیرهای ورودی برای مدل سالانه ۴۰، مدل بهار ۳۶، مدل تابستان ۴۴، مدل پاییز ۴۵ و مدل زمستان ۴۶ بوده است. همان‌طور که در جدول ۴ آمده است، برای این تحلیل از ۴۹۳۰ داده استفاده شد که داده‌های پرت از آن‌ها حذف شده بودند. از این داده‌ها، ۳۳۹۹ داده برای مرحله آموزش، ۷۲۱ داده برای اعتبارسنجی و ۷۲۱ داده برای آزمایش به کار گرفته شدند.

جدول ۴. اطلاعات در مورد استفاده از داده‌ها

آزمون	اعتبارسنجی	داده‌های آموزشی	تعداد نمونه‌ها
%۱۸	%۱۸	۶۴%	۴۶۹۰
۷۲۱	۷۲۱	۳۳۹۹	

### ۳-۴. لایه و گره پنهان

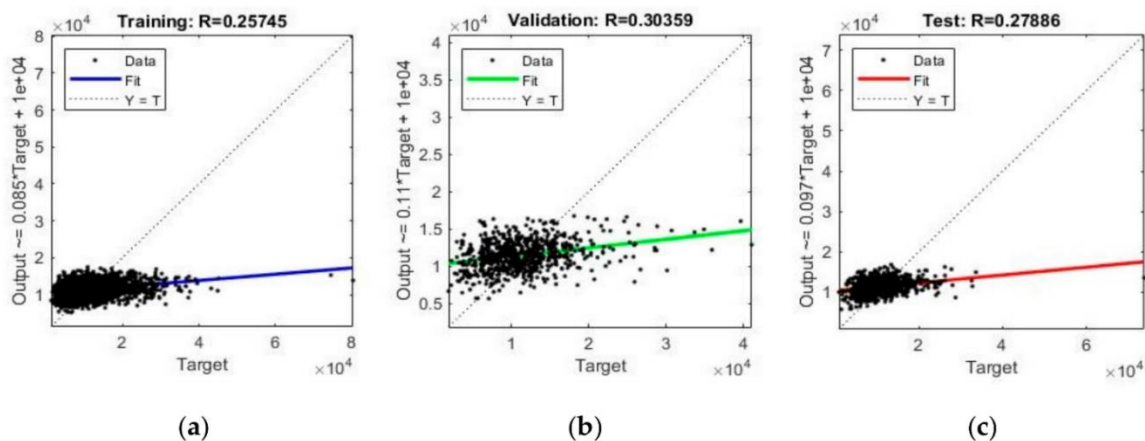
جدول ۵ شش مورد از مدل‌های پیش‌بینی فصلی را که بالاترین عملکرد را دارند، بر اساس تعداد لایه‌ها نشان می‌دهد. در این جدول، به مسئله ناپدید شدن گرادیان اشاره شده است؛ این مسئله زمانی رخ می‌دهد که تعداد لایه‌های مدل بیشتر از مقادیر ارائه‌شده در جدول باشد، که در این حالت مدل پیش‌بینی قادر به بهینه‌سازی و ارائه عملکرد مطلوب نخواهد بود.

جدول ۵. عملکرد مدل‌های پیش‌بینی مصرف انرژی فصلی با توجه به لایه‌های پنهان


دوره پایانی	میانگین مجذور اختلاف بین مقادیر پیش‌بینی شده	ارزش آزمون R	ارزش اعتبارسنجی R	ارزش R در داده‌های آموزشی	نورون	لایه	حداکثر	حداقل	دوره زمانی	یافت
th۱۲	$2/4761 \times 10^{-7}$	-۰/۲۷۲	-۰/۲۹۹	-۰/۲۵۱	۵۶	۱	۸۹	۴۰	سال	th۱۲
th۵	$2/7545 \times 10^{-6}$	۳۰۶/۰	-۰/۲۷۹	-۰/۳۴۹	۳۵	۲				th۵
th۵	$3/4174 \times 10^{-6}$	۳۱۲/۰	-۰/۲۹۹	-۰/۴۱۴	۲۱	۳				th۵
th۴	$2/5974 \times 10^{-6}$	۲۶۲/۰	-۰/۲۸۸	-۰/۳۵۹	۱۱	۴				th۴
th۷	$2/7884 \times 10^{-6}$	۲۷۲/۰	-۰/۲۷	-۰/۴۰۹	۱۳	۵				th۷
th۱۲	$3/1274 \times 10^{-6}$	۲۵۶/۰	-۰/۳۴۸	-۰/۴۹۹	۱۴	۶				th۱۲
th۱۴	$2/5755 \times 10^{-5}$	۲۳۵/۰	-۰/۲۹۶	-۰/۳۲۱	۴۷	۱	۷۵	۳۶	بهار	th۱۴
th۵	$2/5001 \times 10^{-5}$	۲۷۹/۰	-۰/۲۸۴	-۰/۳۸۹	۲۴	۲				th۵
th۷	$2/6785 \times 10^{-5}$	۲۴۶/۰	-۰/۳۱۲	-۰/۴۵۹	۸	۵				th۷
th۴	$2/7128 \times 10^{-5}$	۳۳۱/۰	-۰/۲۵۶	-۰/۴۴۴	۱۲	۶				th۴
th۸	$2/6633 \times 10^{-5}$	۳۳۴/۰	-۰/۲۸۳	-۰/۳۶۲	۶	۷				th۸
th۹	$2/5584 \times 10^{-5}$	۳۱۷/۰	-۰/۲۷۸	-۰/۳۹۸	۷	۸				th۹
th۱۲	$5/2999 \times 10^{-4}$	۲۸۳/۰	-۰/۳۱۵	-۰/۳۰۹	۵۸	۱	۹۳	۴۴	تابستان	th۱۲
th۵	$7/9174 \times 10^{-4}$	۲۴۳/۰	-۰/۲۶۴	-۰/۵۲۶	۲۳	۲				th۵
th۷	$5/1043 \times 10^{-4}$	۲۷/۰	-۰/۳۱۸	-۰/۳۸۲	۱۶	۳				th۷
nd۲	$6/1391 \times 10^{-4}$	۲۱۳/۰	-۰/۲۴۷	-۰/۳۸۲	۱۷	۴				nd۲
th۸	$5/2385 \times 10^{-4}$	۳۵۳/۰	-۰/۳۸۹	-۰/۴۵	۱۰	۵				th۸
th۶	$5/9482 \times 10^{-4}$	۳۷۲/۰	-۰/۳۴۲	-۰/۴۴۲	۸	۶				th۶
th۲۷	$1/3888 \times 10^{-3}$	۲۱۷/۰	-۰/۲۷۸	-۰/۳۳۶	۴۷	۱	۹۷	۴۵	پاییز	th۲۷
th۱۹	$1/6054 \times 10^{-3}$	۱۳۱/۰	-۰/۱۵۸	-۰/۱۵۲	۳۰	۲				th۱۹
rd۳	$1/6571 \times 10^{-3}$	۲۰۱/۰	-۰/۲۷۳	-۰/۳۹۹	۱۶	۳				rd۳
rd۳	$1/8019 \times 10^{-3}$	۱۶۷/۰	-۰/۲۰۸	-۰/۲۸۸	۱۷	۴				rd۳
th۴	$1/6133 \times 10^{-3}$	-۰/۲۹۳	-۰/۲۴۸	-۰/۴۲۳	۱۰	۵				th۴
th۷	$1/8063 \times 10^{-3}$	-۰/۳۱۶	-۰/۲۴۴	-۰/۵۶۵	۱۵	۶				th۷
th۱۵	$6/1731 \times 10^{-3}$	-۰/۲۶۱	-۰/۲۸۷	-۰/۳۳۶	۸۴	۱	۹۷	۴۶	زمستان	th۱۵
th۸	$5/7602 \times 10^{-3}$	-۰/۲۱۲	-۰/۲۳۴	-۰/۲۸۷	۲۴	۲				th۸
nd۲	$5/9531 \times 10^{-3}$	-۰/۳۳۶	-۰/۳۵۹	-۰/۷۳۲	۲۴	۳				nd۲
th۱۱	$5/9060 \times 10^{-3}$	-۰/۲۵۶	-۰/۲۹۳	-۰/۴۲۵	۱۸	۴				th۱۱
rd۳	$7/2293 \times 10^{-3}$	-۰/۲۴۱	-۰/۱۸۲	-۰/۴۰۲	۱۶	۶				rd۳
th۴	$6/3134 \times 10^{-3}$	-۰/۲۹۳	-۰/۲۵۲	-۰/۴۸۵	۱۳	۷				th۴

### ۳-۵. نتیجه شبیه‌سازی ANN

شکل ۱۳ مقادیر R داده‌های آموزشی، اعتبارسنجی و تست بالاترین اجرای مدل پیش‌بینی مصرف انرژی سالانه را نشان می‌دهد. مقدار R برای داده‌های آموزشی  $0.23839$ ، برای داده‌های اعتبارسنجی  $0.32569$  و برای داده‌های تست  $0.28941$  بود. مقدار MSE برابر با  $10^6 \times 2/4761$  بود. این مدل دارای یک لایه و ۷۰ گره بود. مشخص شد که مدل شبکه عصبی (NN) بالاترین عملکرد را نشان می‌دهد. شکل ۱۴ مقادیر R داده‌های آموزشی، اعتبارسنجی و آزمایشی را نشان می‌دهد بیشترین عملکرد را در مدل پیش‌بینی مصرف انرژی بهار دارند. مقدار R برای داده‌های آموزشی  $0.38538$ ، برای داده‌های اعتبارسنجی  $0.26946$  برای داده‌های تست  $0.29573$  بود. مقدار MSE برابر با  $10^5 \times 2/5755$  بود و مدل دو لایه و ۲۴ گره داشت. مشخص شد که مدل DNN با دو لایه بالاترین عملکرد را نشان می‌دهد.

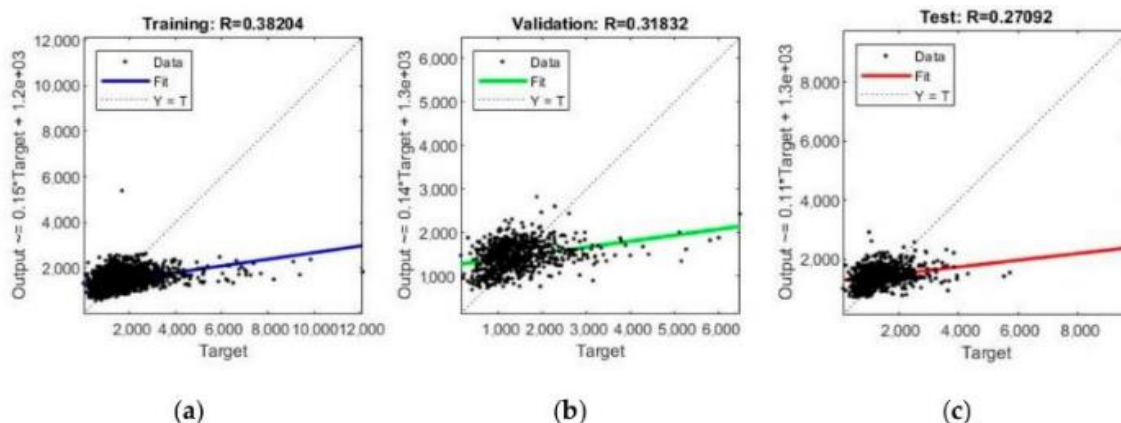


شکل ۱۳. مدل پیش‌بینی مصرف انرژی سالانه (لایه: ۱، گره: ۷۰): (a) نتیجه رگرسیون داده‌های آموزشی؛ (b) نتیجه رگرسیون داده‌های اعتبارسنجی؛ (c) نتیجه رگرسیون داده‌های آزمایشی



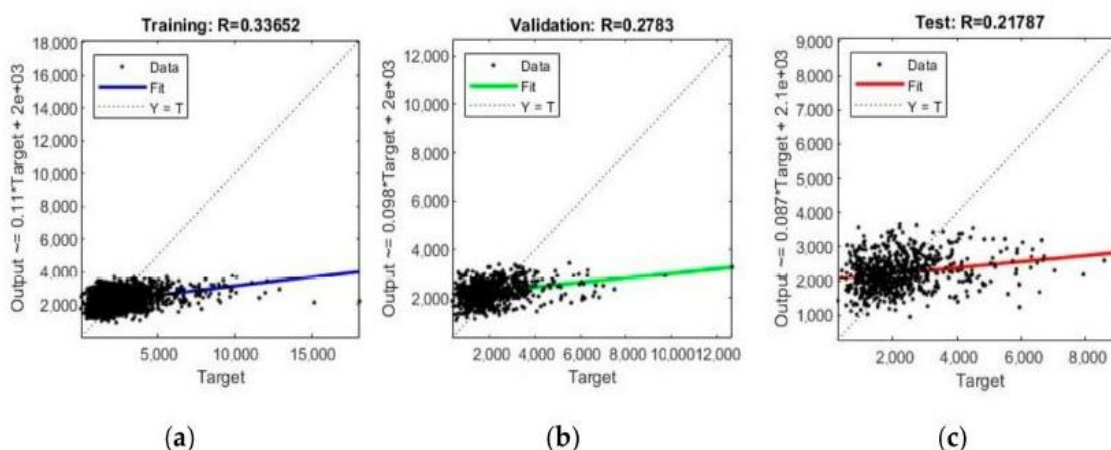
شکل ۱۴. مدل پیش‌بینی مصرف انرژی بهار (لایه: ۲، گره: ۲۴): (a) نتیجه رگرسیون داده‌های آموزشی؛ (b) نتیجه رگرسیون داده‌های اعتبارسنجی؛ (c) نتیجه رگرسیون داده‌های آزمایشی

شکل ۱۵ مقادیر R مربوط به داده‌های آموزشی، اعتبارسنجی و تست برای بهترین اجرای مدل پیش‌بینی مصرف انرژی تابستان را نشان می‌دهد. مقدار R برای داده‌های آموزشی  $0.37606$ ، برای داده‌های اعتبارسنجی  $0.32951$  و برای داده‌های تست  $0.28527$  بود. مقدار MSE این مدل برابر با  $10^4 \times 5/1268$  بود. این مدل دارای سه لایه و ۱۶ گره است و نشان داد مدل DNN با سه لایه، عملکرد بالاتری نسبت به مدل‌های دیگر ارائه می‌دهد.



شکل ۱۵. مدل پیش‌بینی مصرف انرژی تابستانی (لایه: ۳، گره: ۱۶); (a) نتیجه رگرسیون داده‌های آموزشی. (b) نتیجه رگرسیون داده‌های اعتبارسنجی. (c) نتایج رگرسیون داده‌های آزمایشی

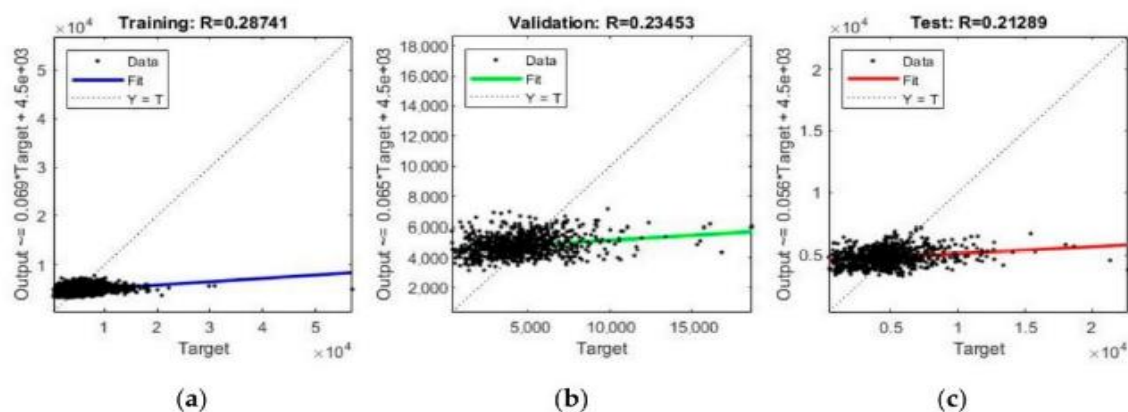
شکل ۱۶ مقادیر R مربوط به داده‌های آموزشی، اعتبارسنجی و آزمایشی برای بهترین اجرای مدل پیش‌بینی مصرف انرژی در فصل پاییز را نشان می‌دهد. مقدار R برای داده‌های آموزشی  $0.35111$ ، برای داده‌های اعتبارسنجی  $0.28941$  و برای داده‌های تست  $0.22003$  بود. مقدار MSE برابر با  $10^5 \times 0.44851$  بود. این مدل شامل یک لایه با ۴۷ گره است و نشان داد مدل شبکه عصبی (NN) با یک لایه، بهترین عملکرد را برای پیش‌بینی مصرف انرژی در پاییز ارائه می‌دهد.



شکل ۱۶. مدل پیش‌بینی مصرف انرژی سقوط (لایه: ۱، گره: ۴۷); (a) نتیجه رگرسیون داده‌های آموزشی؛ (b) نتیجه رگرسیون داده‌های اعتبارسنجی؛ (c) نتیجه رگرسیون داده‌های آزمایشی

شکل ۱۷ مقادیر R مربوط به داده‌های آموزشی، اعتبارسنجی و تست مربوط به بالاترین اجرای مدل پیش‌بینی مصرف انرژی در زمستان را نشان می‌دهد. مقدار R برای داده‌های آموزشی  $0.27842$ ، برای داده‌های اعتبارسنجی  $0.22976$  و برای داده‌های تست  $0.22255$  بود. مقدار MSE برابر با  $10^5 \times 0.8110$  بود. این مدل شامل دو لایه و ۲۴ گره است و نشان داد مدل DNN با دو لایه عملکرد بهتری نسبت به مدل‌های دیگر دارد. برای دوره‌های سالانه و پاییز، مدل‌های شبکه عصبی (NN) با یک لایه عملکرد مناسبی داشتند؛ اما مدل‌های DNN با دو یا چند لایه مقدار MSE مشابهی نشان دادند. این نتایج بیانگر آن است که در صورت استفاده از داده‌های کافی از وضعیت انرژی خانوارها، می‌توان به بهبود عملکرد مدل دست یافت و از مدل‌های DNN با اطمینان بیشتری استفاده کرد.





شکل ۱۷. مدل پیش‌بینی مصرف انرژی زمستانی (لایه: ۲، گره: ۲۴): (a) نتیجه رگرسیون داده‌های آموزشی؛ (b) نتیجه رگرسیون داده‌های اعتبارسنجی؛ (c) نتیجه رگرسیون داده‌های آزمایشی

جدول ۶. عملکرد مدل‌های پیش‌بینی مصرف انرژی فصلی با توجه به نوع داده‌های ورودی

دورهٔ پایان یافت	میانگین مجذور اختلاف بین مقادیر پیش‌بینی شده	ارزش آزمون R	ارزش اعتبارسنجی R	ارزش R در داده‌های آموزشی	نورون	لایه	نوع ورودی	دورهٔ زمانی
th12	$2/4761 \times 10^6$	-/272	-/299	-/251	56	1	A	سال
th15	$3/1472 \times 10^6$	-/258	-/233	-/323	56	1	B	سال
th22	$3/409 \times 10^5$	-/268	-/211	-/318	56	1	C	سال
th3	$2/4162 \times 10^5$	-/275	-/278	-/389	21	2	A	بهار
-	-	-	-	-	21	2	B	بهار
th6	$3/1876 \times 10^5$	-/294	-/357	-/719	21	2	C	بهار
th5	$5/0999 \times 10^4$	-/267	-/310	-/376	13	3	A	تابستان
-	-	-	-	-	13	3	B	تابستان
th3	$7/5302 \times 10^4$	-/331	-/268	-/617	13	3	C	تابستان
th34	$1/3996 \times 10^5$	-/209	-/275	-/328	39	1	A	پاییز
th14	$1/4942 \times 10^5$	-/288	-/163	-/255	39	1	B	پاییز
th14	$1/5955 \times 10^5$	-/236	-/318	-/368	39	1	C	پاییز
th7	$5/6879 \times 10^5$	-/208	-/231	-/281	21	2	A	زمستان
th2	$6/3858 \times 10^5$	-/215	-/266	-/579	21	2	B	زمستان
th5	$6/3520 \times 10^5$	-/308	-/282	-/471	21	2	C	زمستان

جدول ۶ به مقایسهٔ مدل‌های پیش‌بینی مصرف انرژی با سه نوع داده ورودی مختلف می‌پردازد. مدل‌های نوع A با استفاده از تجزیه و تحلیل رگرسیون و بر اساس عناصر اطلاعاتی خانوار و عوامل مؤثر فصلی ساخته شدند. مدل‌های نوع B از تمام ۱۲ مجموعه دادهٔ خانگی برای تمام فصل‌ها به عنوان ورودی استفاده کردند. مدل‌های نوع C نیز بر اساس عناصر رایجی که در مطالعات قبلی تأثیرگذار شناخته شده‌اند، مانند درآمد، تعداد اعضای خانواده و شغل، طراحی شدند. برای اطمینان از مقایسهٔ استاندارد، عناصر تأثیرگذار برای هر فصل به صورت یکسان در مدل‌های A، B و C اعمال شدند، و همچنین تعداد لایه‌ها و نورون‌ها در این مدل‌ها ثابت در نظر گرفته شد تا تأثیر عوامل غیر از داده‌های ورودی کنترل شود. نتایج تحلیل نشان داد مدل نوع A، با استفاده از عناصر مهم خانگی از طریق تجزیه و تحلیل رگرسیون، بیشترین دقت را داشت. در مدل نوع B، که به تمام داده‌های اصلی تکیه داشت، پدیدهٔ ناپدید شدن گرادیان به‌ویژه در مدل‌های بهار و تابستان مشاهده شد. مدل نوع C دقت بیشتری نسبت به نوع A نشان داد، به‌جز در دورهٔ سالانه؛ اما در آن تفاوت معناداری بین دقت پیش‌بینی داده‌های آموزشی و آزمایشی وجود داشت که به بیش‌برازش منجر شد. بر اساس نتایج، مشخص شد که شناسایی مهم‌ترین متغیرها از طریق تحلیل رگرسیون می‌تواند عملکرد مدل را به‌ویژه در مواردی که داده‌های خانگی با پیچیدگی بالا به عنوان ورودی استفاده می‌شود، بهبود بخشد.

#### ۴. نتیجه‌گیری

مطالعات زیادی در زمینه مصرف انرژی ساختمان‌های مسکونی انجام شده است، اما این تحقیق از سه جنبه با مطالعات پیشین تفاوت دارد. اول، این تحقیق براساس داده‌های واقعی مصرف انرژی در شهر تبریز انجام شده است. دوم، ترکیبی از اطلاعات فیزیکی ساختمان و اطلاعات مربوط به کاربران با در نظر گرفتن تأثیرات متقابل آن‌ها مورد استفاده قرار گرفته است. در نهایت، مدل‌های پیش‌بینی مصرف انرژی با تقسیم فصلی و شناسایی عوامل مؤثر در هر فصل طراحی و اجرا شدند. نتایج نشان داد اطلاعات مربوط به کاربران، همانند ویژگی‌های فیزیکی ساختمان، نقش مهمی در مصرف انرژی ایفا می‌کنند.

در ادامه، سه عامل اصلی مؤثر در هر فصل به شرح زیر مشخص شدند:

– **بهار:** جهت ساختمان بیشترین تأثیر را داشت و پس از آن روش اشغال و سیستم سرمایشی قرار داشتند. ساختمان‌های رو به شمال و شمال غربی با تابش خورشیدی کمتر، مصرف انرژی بیشتری نشان دادند. همچنین، ساختمان‌هایی که توسط صاحبان مشاغل اشغال شده‌اند و از کولر برای سرمایش استفاده می‌کنند، مصرف انرژی بیشتری دارند.

– **تابستان:** سیستم سرمایشی تأثیرگذارترین عامل بود. در این فصل، به دلیل گرمای زیاد، برای خنک کردن فضای مسکونی انرژی بیشتری مصرف می‌شود و خانوارهایی که از کولر استفاده می‌کنند، بیشترین مصرف انرژی را دارند.

– **پاییز:** منطقه مسکونی مهم‌ترین عامل تأثیرگذار بود و پس از آن نوع مسکن و میزان اشغال قرار داشتند. ساختمان‌های با مساحت بزرگ‌تر و خانه‌های جدا از دیگر واحدها، مصرف انرژی بیشتری داشتند. همچنین، خانه‌های اشغال‌شده توسط صاحبان مشاغل بیشترین مصرف انرژی را نشان دادند.

– **زمستان:** جهت ساختمان بیشترین تأثیر را داشت، و پس از آن مساحت و میزان اشغال قرار گرفتند. ساختمان‌های رو به شمال و شمال غربی با تابش خورشیدی کمتر، و ساختمان‌های بزرگ‌تر مصرف انرژی بیشتری داشتند.

مطالعه حاضر به بررسی تأثیر عوامل مختلف بر مصرف انرژی در فصل‌های مختلف پرداخته و نشان می‌دهد این عوامل در هر فصل تأثیرات متفاوتی بر مصرف انرژی دارند. این موضوع باید در طراحی سیستم‌های مدیریت انرژی و اقدامات آینده برای صرفه‌جویی سیستماتیک انرژی مد نظر قرار گیرد.

برای برنامه‌ریزی بهتر، ارائه اطلاعات دقیق درباره مصرف فصلی انرژی زمانی امکان‌پذیر است که ساکنان منطقه‌های مسکونی، ویژگی‌های خاص مصرف انرژی را داشته باشند. با به دست آوردن اطلاعات کافی از تطبیق کاربران با ساختمان‌های مسکونی، سیاست‌های پیچیده‌تری قابل اجرا خواهند بود، و سطح آگاهی فردی در زمینه مصرف انرژی افزایش می‌یابد. چنین رویکردی می‌تواند با افزودن عوامل تأثیرگذار و گسترش دامنه تجزیه و تحلیل به کاهش مستمر مصرف انرژی کمک کند.

در این مطالعه، مدل‌های پیش‌بینی مصرف انرژی برای سه نوع مختلف از داده‌ها مقایسه شدند:

• **نوع A:** یک مدل پیش‌بینی که از متغیرهای فصلی تأثیرگذار به عنوان داده‌های ورودی استفاده کرده است، این داده‌ها از طریق تجزیه و تحلیل رگرسیون به دست آمده‌اند.

• **نوع B:** یک مدل پیش‌بینی بر اساس اطلاعات چهار عنصر کلیدی کاربر که در مطالعات قبلی تعیین شده‌اند؛ شامل درآمد، شغل، ترکیب اعضای خانواده و تعداد اعضای خانواده.

• **نوع C:** یک مدل پیش‌بینی که از تمام اطلاعات خانوار موجود در داده‌های اصلی بهره می‌برد.

نتایج مقایسه نشان داد مدل نوع A بالاترین دقت را داشته است. این یافته نشان می‌دهد مدل‌های پیش‌بینی با عملکرد بهتر می‌توانند با تأیید تأثیر عناصر مختلف از طریق تجزیه و تحلیل رگرسیون به دست آیند و برای مدل‌سازی‌های آتی، به‌ویژه در پیش‌بینی داده‌های غیر معمول همچون اطلاعات اعضای خانواده، مورد استفاده قرار گیرند.

مدل‌های نوع B قادر به شناسایی عوامل مؤثر هستند و می‌توانند اطلاعات ارزشمندی برای تدوین طرح‌های کاهش مستمر مصرف انرژی ارائه دهند. با توجه به این عوامل، اقدامات متقابل در راستای صرفه‌جویی انرژی پایدار هنگام طراحی سیاست‌های مرتبط، قابل اجرا خواهند بود.

در صورت استفاده از مدل پیشنهادی این مطالعه برای پیش‌بینی تأثیر مصرف انرژی ساختمان و کاربران، می‌توان نوعی ارزیابی جامع تأثیر انرژی را انجام داد که مصرف انرژی غیرضروری پس از سکونت را کاهش می‌دهد و به ایجاد محیط‌های مسکونی با صرفه‌جویی انرژی کمک می‌کند؛ محیط‌هایی که توسط دولت یا کاربران به صورت پایدار طراحی شده‌اند. در این مطالعه، اگرچه نرخ پیش‌بینی با استفاده از عوامل تأثیرگذار از طریق تجزیه و تحلیل رگرسیون بهبود یافت، اما عملکرد مدل پیش‌بینی به دلیل محدودیت داده‌ها همچنان محدود بود؛ زیرا تنها از داده‌های دوساله استفاده شد. با این حال، مجموعه داده‌های مورد استفاده در این مطالعه به صورت سالانه به‌روزرسانی می‌شود، از این‌رو این محدودیت‌ها با دسترسی به داده‌های بیشتر برطرف خواهند شد.

## منابع

- [1] El-Gohary, M.; El-Abed, R.; Omar, O. (2023), Prediction of an Efficient Energy-Consumption Model for Existing Residential Buildings in Lebanon Using an Artificial Neural Network as a Digital Twin in the Era of Climate Change. *Buildings*, 13, 3074. <https://doi.org/10.3390/buildings13123074>.
- [2] Hong, G.; Seong, N.(2023), Optimization of the ANN Model for Energy Consumption Prediction of Direct-Fired Absorption Chillers for a Short-Term. *Buildings*, 13, 2526. <https://doi.org/10.3390/buildings13102526>.
- [3] Monah, P.I.; Rahul, S.G.; Kavitha, P.; Dhiviyasri, G. (2017), Prediction of Electricity Load Using Artificial Neural Network for Technology, Tower Block of VIT University. *Int. J. Appl. Eng. Res.*, 12, 7717–7723.
- [4] Olanrewaju, O.A.; Mbohwa, C. (2017), Prediction of Residential Sector Energy Consumption: Artificial Neural Network Application. In *Proceedings of the International Conference on Industrial Engineering and Operations Management (IEOM)*, Bristol, UK. 24–25 July 2017.
- [5] Hong, G.; Seong, N. (2023), Optimization of the ANN Model for Energy Consumption Prediction of Direct-Fired Absorption Chillers for a Short-Term. *Buildings* 13, 2526.
- [6] Moon J, Park S, Rho S, Hwang E. A comparative analysis of artificial neural network architectures for building energy consumption forecasting. *International Journal of Distributed Sensor Networks*. 2019;15(9). <https://doi.org/10.1177/1550147719877616>.
- [7] Khodadadi, M., Riazi, L., & Yazdani, S. (2024). A Novel Ensemble Deep Learning Model for Building Energy Consumption Forecast. *International Journal of Engineering*, 37(6), 1067-1075. doi: 10.5829/ije.2024.37.06c.03
- [8] R. R. A. Issa, I. Flood, and M. Asmus. (2001). Development of a neural network to predict residential energy consumption. In *Proceedings of the sixth international conference on Application of artificial intelligence to civil & structural engineering (ICAAICSE '01)*. Civil-Comp Press, 65-66.
- [9] Vanting, N.B., Ma, Z. & Jørgensen, B.N.(2022), Evaluation of neural networks for residential load forecasting and the impact of systematic feature identification. *Energy Inform* 5 (Suppl 4), 63. <https://doi.org/10.1186/s42162-022-00224-5>.
- [10] Xu B, Sun Y, Wang H, Yi S (2019), Short-term electricity consumption forecasting method for residential users based on cluster classification and backpropagation neural network. In: 11th international conference on intelligent human-machine systems and cybernetics, IHMSC 2019. Institute of Electrical and Electronics Engineers Inc., pp 55–59
- [11] Sauter P, Karg P, Pfeifer M, Kluwe M, Zimmerlin M, Leibfried T et al (2017), Neural network-based load forecasting in distribution grids for predictive energy management systems. In: *International ETG congress 2017*. pp 1–6.
- [12] Samuel IA, Ekundayo S, Awelewa A, Somefun TE, Adewale A (2020), Artificial neural network base short-term electricity load forecasting: a case study of a 132/33 kv transmission sub-station. *Int J Energy Econ Policy* 10(2):2 00-205. <https://doi.org/10.32479/ijeep.8629>
- [13] Sadaei HJ, de Lima e Silva PC, Guimarães FG, Lee MH (2019) Short-term load forecasting by using a combined method of convolutional neural networks and fuzzy time series. *Energy*, 175 :365-377. <https://doi.org/10.1016/j.energy.2019.03.081>
- [14] Gören G, Dindar B, Gül Ö (2022) Artificial neural network based cost estimation of power losses in electricity distribution system. In: 2022 4th global power, energy and communication conference (GPECOM). 455-460
- [15] Ardabili S, Abdolalizadeh L, Mako C, Torok B and Mosavi A (2022) Systematic Review of Deep Learning and Machine Learning for Building Energy. *Front. Energy Res*, 10 (3) :786027. <https://doi.org/10.3389/fenrg.2022.786027>.
- [16] Gao M. (2022), An Artificial Neural Network-Based Approach to Optimizing Energy Efficiency in Residential Buildings in Hot Summer and Cold Winter Regions. *Comput Intell Neurosci*. 25(3): 2611695. <https://doi.org/10.1155/2022/2611695>.