Journal of Safe City

Online ISSN: 2676-556X

**Journal Homepage**: www.ispdrc.ir

Research Paper

# Modeling Residential Building Energy Consumption Management based on BIM Platform and Deep Learning Method

1.maleki, salman* 2.Pourrostam, Towhid 3.Jafari Nadoushan, Mohsen

1. Department of civil engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran
2. Asociated Professor of Construction Management, Department of Civil Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran.
3. Asociated Professor of Construction Management, Department of Civil Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran.

Received:26 September 2024 Received hn revised form: 24 May 2025 Accepted: 1 JULY 2025 p.p: 134 – 154

https://doi.org/10.22034/ispdrc.2025.2056162.1173

**ABSTRACT**

The management of energy consumption in residential buildings has been of great importance in the last decades, and the current debate on energy imbalance is also due to the lack of attention to this debate in previous years. Building Information Modeling (BIM), as one of the new technologies in the construction industry, provides the ability to analyze and optimize energy consumption by providing a digital building model. This article is a multi-stage research to complete the present research method. First, the Building Information Modeling (BIM) platform was completed, and then this platform was used to complete the database of applied deep learning methods. In this study, Design Builder software version 7.3 was used to simulate the thermal load, lighting energy consumption, and heating of educational buildings. Different neural networks were used in this research to implement the best deep learning method. Deep learning methods such as Support Vector Machine (SVM), Adaptive Neural Fuzzy Inference System (ANFIS), and other neural networks such as LSTM and XGBoost were used to increase the accuracy and efficiency of the model. The learning curves also indicated effective learning and high generalizability of the models. Finally, the most appropriate deep learning structure was introduced with a correlation coefficient of 0.98. This research showed that the use of BIM and its integration with advanced tools and techniques, such as energy simulation and optimization algorithms, has a significant impact on reducing energy consumption and increasing building efficiency, and emphasizes the importance of accurate data and intelligent design.

Keywords:BIM Platform, Modeling, Energy Consumption, Artificial Neural Network,

(Corresponding Author: s.maleki.eng@iauctb.ac.ir)

# Extended Abstract:

## Introduction

With the growth of urban populations and the expansion of construction activities, energy consumption in buildings has become one of the most pressing global challenges. Buildings, both residential and commercial, account for a significant portion of energy demand. Therefore, optimizing energy consumption in buildings not only helps reduce costs, but also plays a critical role in minimizing environmental impact and achieving sustainable development goals. Traditional energy management methods, such as manually adjusting heating and cooling systems or using simple sensors, often face limitations such as low accuracy and inability to adapt to changing conditions. Meanwhile, the emergence of new technologies, particularly artificial intelligence (AI) and deep learning, has opened new horizons in this field. Deep learning, with its ability to analyze large amounts of data and identify complex patterns, can contribute to more accurate energy consumption forecasting, system performance optimization, and even smart management of electrical loads. This article aims to explore the applications of deep learning in building energy management, review its benefits and challenges, and provide a broad perspective on the use of this technology in the future.

## Methodology

This research focused on optimizing the energy consumption of buildings and was carried out in several phases using different techniques and tools. In the first phase, AutoCAD drawings were transferred to DesignBuilder software to estimate the annual energy consumption of the building. In this phase, standard materials and data related to topic 19 were used. This process served as a basis for subsequent analyses and providing energy consumption optimization solutions. Subsequently, by integrating smart windows and smart shades, an attempt was made to reduce energy consumption in various sectors. The implementation of the Artificial Neural Network (ANN) method for optimizing the energy consumption of air conditioning (HVAC) systems was carried out using PYTHON software. First, the database was collected according to Table (1) for the required data. Then, coding was done using Python software and the results of the coding. Implementation of the deep learning method are presented. For training and implementation of the neural network, the following data is collected.

## Results and discussion

The results indicate a significant reduction in annual energy consumption, which can lead to improved energy efficiency and cost savings. Comparing the results with the first phase, the energy consumption for lighting has decreased from 88.08 MWh to 52.58 MWh, which is equivalent to a 40.3% annual decrease, which is a significant change. On the other hand, the heating load has increased by 9% from 74.6 to 86.44 MWh, while the cooling load has decreased by 10% from 107.43 to 95.21 MWh; this decrease is due to the reduction in heat generated by the lamps. The results in this table show that the ANFIS neural network has greater accuracy and efficiency than the SVM. It is worth noting that in terms of coding complexity and coding execution, the SVM network has more advantages. Also, the combination of two types of neural networks has had a significant impact on increasing the accuracy of deep learning modeling, bringing the correlation coefficient to 0.98.

## Conclusion

The results showed that this integration reduced the lighting energy consumption by 40.3% and the cooling load by 10%, while the heating load increased by about 9% due to the reduction in the heat generated by the lamps. The values of the equipment electricity consumption (Room Electricity) and domestic hot water (DHW) did not change, but overall these changes improved energy efficiency without major negative effects. A genetic algorithm (GA) was used to determine the best location of the cooling equipment. This algorithm identified the optimal coordinates considering the thermal comfort points (25 °C). However, some of the proposed coordinates were outside the acceptable room space, highlighting the need for position corrections. These corrections led to more accurate solutions with favorable approximations during algorithm execution. Finally, this research comprehensively demonstrated that the use of advanced techniques such as intelligent systems integration and optimization algorithms can lead to significant

reductions in energy consumption and increased energy efficiency in buildings. Also, these results emphasize the importance of accurate input data and smart design to achieve effective and sustainable results. The results obtained showed that the proposed hybrid model has high accuracy and can be well used in predicting and managing energy consumption patterns of buildings. In addition to increasing the prediction accuracy, this model showed more flexibility than traditional methods and was able to examine the impact of variables such as temperature, humidity, and lighting hours on energy consumption more accurately.

**Funding**
There is no funding support.

**Authors' Contribution**
Authors contributed equally to the conceptualization and writing of the article. All of the authors approved thecontent of the manuscript and agreed on all aspects of the work declaration of competing interest none.

**Conflict of Interest**
Authors declared no conflict of interest.

**Acknowledgments**
We are grateful to all the scientific consultants of this paper.

نشریه علمی شهر ایمن
شاپا الکترونیکی: 2676-556X
Journal Homepage: www.ispdrc.ir
مقاله پژوهشی

# مدلسازی مدیریت مصرف انرژی ساختمان مسکونی بر پایه بستر BIM و روش یادگیری عمیق

**ملکی- سلمان، پوررستم- توحید، جعفری ندوشن- محسن**

گروه مهندسی عمران، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران

دانشیار مدیریت ساخت، گروه مهندسی عمران، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران.

استادیار مدیریت ساخت، گروه مهندسی عمران، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران.

تاریخ ارسال: ۱۴۰۳/۰۷/۰۵ تاریخ بازنگری: ۱۴۰۴/۰۳/۰۳ تاریخ پذیرش: ۱۴۰۴/۰۴/۱۰ ص.ص ۱۵۴-۱۳۴

https://doi.org/10.22034/ispdrc.2025.2056162.1173

**چکیده:**

مدیریت مصرف انرژی در ساختمان مسکونی در دهه‌های اخیر از اهمیت بسیار بالایی برخوردار بوده و بحث ناترازی انرژی در حال حاضر نیز به دلیل عدم توجه به این بحث در سالیان گذشته می‌باشد. مدل‌سازی اطلاعات ساختمان (BIM) به‌عنوان یکی از فناوری‌های نوین در صنعت ساختمان، با ارائه مدل دیجیتال ساختمان، امکان تحلیل و بهینه‌سازی مصرف انرژی را فراهم می‌کند. این مقاله یک پژوهش چند مرحله‌ای جهت تکمیل روش تحقیق حاضر است. در این پژوهش ابتدا بستر مدلسازی اطلاعات ساختمان (BIM) تکمیل شده و سپس از این بستر برای تکمیل بانک اطلاعاتی روش‌های یادگیری عمیق کاربردی استفاده شده است. به این منظور، از نرم‌افزار Design Builder نسخه ۷.۳ برای شبیه‌سازی بار حرارتی، مصرف انرژی روشنایی و گرمایش ساختمان‌های مسکونی استفاده شد. شبکه‌های عصبی متنوعی در این تحقیق استفاده شده‌اند تا بهترین روش یادگیری عمیق معرفی گردد. روش‌های یادگیری عمیق مانند ماشین بردار پشتیبان (SVM)، سیستم استنتاج فازی- عصبی تطبیقی (ANFIS) و شبکه‌های عصبی دیگر مانند LSTM و XGBoost برای افزایش دقت و کارایی مدل به کار رفته‌اند. در نهایت مناسب‌ترین ساختار یادگیری عمیق با ضریب همبستگی ۰/۹۸ معرفی شده است. این تحقیق نشان داد که استفاده از BIM و ادغام آن با ابزارها و تکنیک‌های پیشرفته مانند شبیه‌سازی انرژی و الگوریتم‌های بهینه‌سازی، تأثیر چشمگیری در کاهش مصرف انرژی و افزایش بهره‌وری ساختمان دارد. یافته‌های این پژوهش بر اهمیت داده‌های دقیق و طراحی هوشمندانه تأکید دارد.

واژگان کلیدی:بستر BIM، مدلسازی، مصرف انرژی، شبکه عصبی مصنوعی

نویسنده مسئول:s.maleki.eng@iauctb.ac.ir

## ۱- مقدمه

با افزایش مصرف انرژی و بحران‌های زیست‌محیطی، بهینه‌سازی مصرف انرژی در ساختمان‌ها به یک ضرورت تبدیل شده است. در این راستا، فناوری‌های نوین مانند مدلسازی اطلاعات ساختمان (*BIM*) به عنوان ابزاری کارآمد برای طراحی و مدیریت ساختمان‌های کم‌مصرف و پایدار مورد توجه قرار گرفته‌اند. این فناوری امکان شبیه‌سازی انرژی ساختمان، تحلیل رفتار حرارتی، و مقایسه سناریوهای مختلف برای کاهش مصرف انرژی را فراهم می‌آورد [۱]. مطالعات متعددی در زمینه مدلسازی اطلاعات ساختمان (*BIM*) و مدیریت مصرف انرژی ساختمان انجام شده است. این تحقیقات به بررسی تأثیر *BIM* در بهینه‌سازی مصرف انرژی، کاهش هزینه‌های عملیاتی و افزایش بهره‌وری سیستم‌های ساختمانی پرداخته‌اند [۲]. در ادامه، برخی از مهم‌ترین پژوهش‌های انجام‌شده در این حوزه ارائه می‌شود. *Volk et al.* (۲۰۱۴) نشان دادند که نیاز به مدل‌سازی دقیق اطلاعات ساختمان و هماهنگی بین ذینفعان پروژه از مهم‌ترین چالش‌های استفاده از *BIM* در مدیریت انرژی هستند [۳]. *Kim et al.* (۲۰۱۵) با استفاده از *BIM* و نرم‌افزارهای تحلیل انرژی (مانند *Revit* و *Energy Plus*)، نشان دادند که امکان پیش‌بینی و بهینه‌سازی عملکرد انرژی ساختمان از طریق شبیه‌سازی‌های دیجیتال وجود دارد [۴]. *Ham et al.* (۲۰۱۸) به بررسی ادغام *BIM* با سیستم‌های مدیریت هوشمند انرژی پرداختند و نشان دادند که ترکیب این فناوری‌ها می‌تواند کاهش قابل‌توجهی در مصرف انرژی و انتشار گازهای گلخانه‌ای ایجاد کند [۵]. حسن‌زاده (۱۴۰۱) در پژوهشی به بررسی کاربرد *BIM* در بهینه‌سازی مصرف انرژی ساختمان‌های اداری در تهران پرداختند [۶]. نتایج نشان داد که استفاده از *BIM* می‌تواند مصرف انرژی را بین ۲۰ تا ۴۰ درصد کاهش دهد. دیواندری و همکاران (۱۴۰۲) به بررسی راهکارهای بهبود پیاده‌سازی *BIM* در ایران پرداختند و پیشنهاد کردند که آموزش نیروی متخصص و تدوین قوانین و استانداردهای بومی می‌تواند به افزایش استفاده از *BIM* کمک کند [۷]. حویزه و رستم‌پور (۱۴۰۲) در مطالعه‌ای به مدل سازی اطلاعات ساختمان (*BIM*) و تاثیر آن برفرآیند طراحی معماری پرداختند [۸]. نتایج نشان داد که استفاده از *BIM* در طراحی اولیه، تأثیر بسزایی در کاهش هزینه‌های گرمایشی و سرمایشی دارد. اطهری و گلابچی (۱۴۰۲) در تحقیق خود نشان دادند که نبود استانداردهای ملی، محدودیت‌های نرم‌افزاری و کمبود نیروی متخصص از موانع اصلی گسترش *BIM* در ایران است [۹]. مرور تحقیقات نشان می‌دهد که *BIM* یک ابزار قدرتمند برای مدیریت مصرف انرژی ساختمان است و می‌تواند نقش مهمی در کاهش مصرف انرژی، بهینه‌سازی طراحی، و افزایش بهره‌وری ساختمان‌ها ایفا کند. با این حال، چالش‌هایی مانند نیاز به آموزش، هزینه‌های اولیه بالا و کمبود استانداردهای اجرایی در مسیر پیاده‌سازی آن وجود دارد. پژوهش‌های داخلی نیز تأکید دارند که گسترش *BIM* در ایران مستلزم توسعه زیرساخت‌های نرم‌افزاری، آموزش تخصصی و حمایت‌های قانونی است.

از سوی دیگر، الگوریتم‌های فراابتکاری مانند *ANFIS* و *SVM*، به دلیل توانایی‌های بالای خود در بهینه‌سازی و تحلیل داده‌ها، به عنوان راهکارهایی مناسب برای مدیریت مصرف انرژی مطرح شده‌اند [۱۰]. این الگوریتم‌ها می‌توانند به شناسایی الگوهای مصرف انرژی و ارائه راهکارهای بهینه‌سازی کمک کنند. این پژوهش به دنبال بررسی کاربرد *BIM* در مدیریت مصرف انرژی ساختمان‌های مسکونی با استفاده از الگوریتم‌های *ANFIS* و *SVM* است [۱۱]. هدف از این تحقیق، شناسایی و تحلیل مؤلفه‌های کلیدی مصرف انرژی و توسعه راهکارهایی برای بهینه‌سازی مصرف انرژی در ساختمان‌های مسکونی است. در پنج سال گذشته، جریان مداومی از شرکت‌های نوآور و جدید که در کاربرد انواع فناوری‌های اطلاعات و خودکارسازی که در صنایع دیگر توسعه یافته‌اند، تخصص دارند، به صنعت ساخت‌وساز وارد شده‌اند. این شرکت‌های نوپا توسط سرمایه‌گذاران خطرپذیر، تحقیقات دانشگاهی و برنامه‌های انکوباتور عمومی و خصوصی حمایت می‌شوند و با همکاری این عوامل، یک اکوسیستم که عموماً به عنوان 'تکنولوژی ساخت‌وساز' شناخته می‌شود (که شبیه به نام 'تکنولوژی پیشرفته' است که برای صنعت فناوری اطلاعات و خودکارسازی استفاده می‌شود) شکل می‌دهند. در ایالات متحده، گزارش شده است که میزان سرمایه‌گذاری خطرپذیر در تکنولوژی ساخت‌وساز سالانه از حدود ۲۵۰ میلیون دلار در سال ۲۰۱۳ به بیش از ۱۰۰۰ میلیون دلار در سال ۲۰۱۸ افزایش یافته است [۱۲]. شیرمنش و همکاران نیز در سال ۱۴۰۲ به بررسی طراحی ساختمان با بهره وری انرژی بر اساس *BIM* و فناوری هوش مصنوعی پرداختند [۱۳]. پیشرفت فناوری و نیاز صنعت به استفاده از آن، مدل‌سازی اطلاعات ساختمان (*BIM*) را به یکی از فناوری‌های نوین در صنعت ساخت‌وساز تبدیل کرده است. پژوهشگران در ایران نیز همسو با این روند، تحقیقات خود را در این زمینه انجام داده‌اند. بررسی تحقیقات گذشته نشان می‌دهد که

در ایران خلأ جدی در پروژه‌های عملی و مطالعات موردی وجود دارد. بخشی از این مشکل ناشی از مقاومت صنعت ساخت‌وساز و بخشی دیگر مرتبط با نیازهای قانونی برای اجرای پروژه‌های مبتنی بر فناوری *BIM* است. همچنین، این مقاله به بررسی کاربرد *BIM* و هوش مصنوعی در ساختمان‌های با بهره‌وری انرژی پرداخته و چارچوبی برای طراحی ساختمان‌های کارآمد از نظر انرژی بر اساس این فناوری‌ها ارائه می‌دهد. شبکه‌های عصبی عمیق برای آموزش مؤثر به حجم زیادی از داده‌های دقیق و متنوع نیاز دارند [۱۴]. در ساختمان‌هایی که داده‌کاوی کافی انجام نشده، این موضوع می‌تواند محدودیت ایجاد کند. *SVM* و *ANFIS* نیز به داده‌های مناسب برای تنظیم پارامترها وابسته هستند [۱۵].

کاظمی و همکاران در سال ۲۰۲۵ بهینه‌سازی مصرف انرژی در ساختمان‌های هوشمند با استفاده از شبکه‌های عصبی فیزیکی-آگاه (*PINN*) و چارچوب دوقلوی دیجیتال (*Digital Twin*) انجام دادند. این مطالعه یک مدل ترکیبی مبتنی بر یادگیری عمیق ارائه می‌دهد که از شبکه‌های عصبی فیزیکی-آگاه (*PINN*)، دوقلوی دیجیتال (*Digital Twin*) و فناوری بلاک‌چین برای بهینه‌سازی مصرف انرژی در ساختمان‌های هوشمند استفاده می‌کند. مدل پیشنهادی با استفاده از داده‌های واقعی شامل مصرف انرژی، تولید انرژی تجدیدپذیر، قیمت‌گذاری پویا و ترجیحات کاربران آموزش دیده و اعتبارسنجی شده است. نتایج نشان می‌دهد که این مدل توانسته است با دقت بالا ($R^2 = 0.978$) مصرف انرژی را پیش‌بینی کرده و هزینه‌های انرژی را تا ۳۵٪ کاهش دهد، در حالی که شاخص راحتی کاربران را در سطح ۹۶٪ حفظ کرده است. لی و همکاران در سال ۲۰۲۵ در تحقیق خود، پنجره‌های هوشمند ترموکرومیک سه‌حالته توسعه یافته‌اند که قادر به تنظیم انتقال حرارت و نور بر اساس شرایط محیطی هستند را بررسی کردند. با مقایسه بارهای گرمایشی و سرمایشی در ساختمان‌هایی با این پنجره‌ها و ساختمان‌های با شیشه‌های معمولی، مشخص شد که استفاده از این پنجره‌ها می‌تواند به طور قابل توجهی مصرف انرژی را کاهش دهد.

هدف اصلی تحقیق حاضر مدلسازی مصرف انرژی در ساختمان به کمک روش یادگیری عمیق است. مجموعه اطلاعات این تحقیق در پروژه‌های ساختمانی اجرا شده در شهر تهران جمع‌آوری شده است. بخش اول مقاله حاضر به مقدمه و مروری بر ادبیات فنی تحقیق پرداخته است. در بخش دوم این مقاله، به معرفی و تعریف مبانی نظری تحقیق این مقاله پرداخته شده است. در بخش سوم روش تحقیق بیان شده است. سپس در بخش چهارم نتایج مدلسازی تحقیق بررسی شده است و در نهایت در بخش پنج نیز به جمع‌بندی و نتیجه‌گیری پرداخته است.

مبانی نظری تحقیق

مدلسازی اطلاعات ساختمان (*Building Information Modeling - BIM*) یک فناوری و رویکرد نوین در صنعت ساختمان است که امکان ایجاد، مدیریت و تحلیل اطلاعات ساختمان را در یک مدل دیجیتال فراهم می‌کند. این مدل شامل داده‌های فیزیکی، عملکردی و زیست‌محیطی ساختمان در تمام مراحل چرخه حیات آن (از طراحی تا بهره‌برداری و نگهداری) است. بر اساس تعریف انجمن ملی *BIM* آمریکا (*NBIMS-US, 2015*)، این فناوری یک رویکرد مبتنی بر مدل‌های دیجیتال هوشمند است که امکان همکاری، تصمیم‌گیری آگاهانه، کاهش خطاها و بهینه‌سازی عملکرد ساختمان را فراهم می‌کند [۱۶].

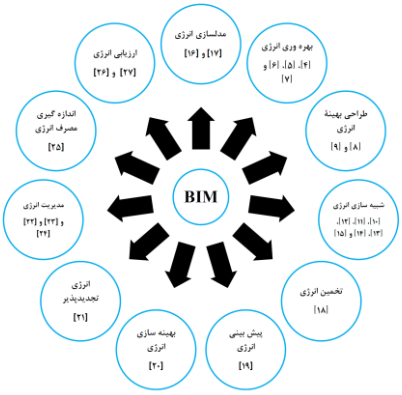


**شکل ۱- کاربردهای بستر BIM در حوزه های مختلف انرژی**

مدیریت مصرف انرژی در ساختمان به مجموعه اقداماتی اطلاق می‌شود که به بهینه‌سازی مصرف انرژی، کاهش هزینه‌ها و افزایش بهره‌وری سیستم‌های تأسیساتی و گرمایشی-سرمایشی منجر می‌شود. بر اساس گزارش آژانس بین‌المللی انرژی (*IEA, 2021*)، ساختمان‌ها حدود ۴۰٪ از مصرف کل انرژی جهانی را به خود اختصاص می‌دهند، بنابراین استفاده از فناوری‌های نوین برای کاهش مصرف انرژی در این بخش از اهمیت بالایی برخوردار است. مدیریت مصرف انرژی شامل موارد زیر است: تحلیل رفتار حرارتی ساختمان برای کاهش اتلاف انرژی. بهینه‌سازی سیستم‌های سرمایش، گرمایش و تهویه (*HVAC*). به‌کارگیری فناوری‌های هوشمند و سیستم‌های مدیریت انرژی ساختمان (*BEMS*). انتخاب مصالح و طراحی پایدار [۱۷].

بستر *BIM* می‌تواند نقش کلیدی در بهینه‌سازی مصرف انرژی ساختمان داشته باشد، زیرا این فناوری امکان شبیه‌سازی انرژی، تحلیل عملکرد سیستم‌های تأسیساتی و مدیریت بهره‌برداری ساختمان را فراهم می‌کند. برخی از مهم‌ترین کاربردهای *BIM* در این زمینه عبارت‌اند از: ۱- شبیه‌سازی انرژی ساختمان: *BIM* از طریق ابزارهایی مانند *Energy Plus*، *Green Building Studio*، *IES-VE* و *Design Builder* امکان تحلیل عملکرد انرژی ساختمان را در مراحل اولیه طراحی فراهم می‌کند. این شبیه‌سازی‌ها شامل موارد زیر هستند: بررسی اتلاف حرارتی ساختمان در شرایط مختلف آب‌وهوایی. تحلیل میزان نور طبیعی و تأثیر آن بر مصرف انرژی. مقایسه مصالح مختلف از نظر کارایی انرژی. ۲- بهینه‌سازی طراحی معماری و جهت‌گیری ساختمان: یکی از مهم‌ترین عوامل تأثیرگذار بر مصرف انرژی، جهت‌گیری ساختمان نسبت به نور خورشید و شرایط اقلیمی است. *BIM* امکان مدل‌سازی دقیق تأثیر نور خورشید، سایه‌اندازی و تهویه طبیعی را فراهم می‌کند و به طراحان اجازه می‌دهد بهترین جهت‌گیری را برای کاهش مصرف انرژی انتخاب کنند. ۳- انتخاب سیستم‌های تأسیساتی و بهره‌برداری هوشمند: *BIM* در انتخاب و تنظیم عملکرد سیستم‌های تأسیساتی (مانند *HVAC* و روشنایی) نقش مهمی دارد. مدیریت هوشمند انرژی ساختمان (*BEMS*) با ادغام *BIM*، می‌تواند داده‌های حسگرهای هوشمند را تحلیل کند و استراتژی‌های صرفه‌جویی در مصرف انرژی را اعمال کند. ۴- کاهش هزینه‌های عملیاتی و نگهداری: طبق گزارش *Autodesk* (۲۰۱۹)، استفاده از *BIM* می‌تواند هزینه‌های عملیاتی ساختمان را تا ۲۰ درصد کاهش دهد. این فناوری با ارائه اطلاعات دقیق از تجهیزات و تأسیسات، به مدیران ساختمان کمک می‌کند بهینه‌ترین راهکارهای نگهداری و تعمیرات را اجرا کنند [۱۸].

در مطالعه ژانگ و همکاران، ضرایب رگرسیون استاندارد برای بررسی تأثیر پارامترهای ساختمانی بر مصرف سالانه‌ی انرژی در سه ناحیه‌ی اقلیمی مختلف و در هر دو طرح ساختمان تجاری یعنی $H$ و مستطیلی، استفاده شدند. نتایج مدل‌ها نشان‌دهنده‌ی درصد خطای قابل قبول کمتر از ۵٪ بود. برنامه‌ریزی اشغال در هر دو طرح $H$ و مستطیلی در هر سه ناحیه‌ی اقلیمی بیشترین تأثیر را بر مصرف انرژی ساختمان داشت، زیرا مصرف انرژی ساختمان در محیط‌های شهری به شدت به شرایط آب‌وهوایی پیرامون وابسته است [۲۰].

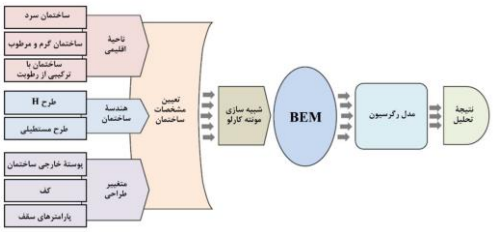


**شکل ۲-کاربردهای بستر BIM در حوزه های مختلف انرژی**

در سال ۲۰۲۲، ژانگ و همکاران ]۲۰[ دریافتند که شرطی‌ساز ی حرارتی هوای داخلی ارتباط نزدیکی با انتقال حرارت بین ساختمان های داخلی و خارجی دارد که بر آسای ش حرارتی ساکنین و مصرف انرژ ی برای شرطی ساز ی فضا تأثیر می گذارد. یکی از پارامترهای مهم در تحلیل حرارتی، ضریب انتقال حرارت پوسته های خارجی ساختمان است. آن ها به ارزیابی اثر کاهش خلأ بی ن

اطلاعات طراحی شده‌ی *BIM* و شرایط واقعی ساختمان پرداختند. آنها بیان داشتند که علیرغم توانایی نقشه‌های ساختمانی سه‌بعدی در توصیف شرایط، هنوز به نرم‌افزار شبیه‌سازی انرژی *DOE* برای محاسبه‌ی مصرف انرژی و بهبود دقت مدلسازی نیاز است.
در سال ۲۰۲۰، آندریک و همکاران [۲۱] دریافتند که شبیه‌سازی انرژی برای کدگذاری و پایدارسازی سیستم‌های پروژه‌های ساختمانی رایج شده است، اما به دلیل مدل‌سازی مکرر و هزینه‌بر بودن، به ندرت در روند طراحی استفاده می‌شود. آن‌ها مشاهده کردند که اگر مدل انرژی از مدل *BIM* تولید شود، شبیه‌سازی انرژی مؤثرتر خواهد بود. در این مطالعه، مدل ساده‌ای با استفاده از *Autodesk REVIT* ایجاد و ذخیره شد. سپس فایل‌ها به *GBS* تبدیل شدند و شبیه‌سازی‌ها در *EnergyPlus* و *eQuest* انجام شد. در همین سال، بهزادپور و همکاران [۲۲] بیان کردند که صرفه‌جویی بیشتر در انرژی با طراحی بهینه ممکن است، اما به دلیل کمبود ابزارهای مؤثر، ارزیابی عملکرد انرژی پس از طراحی انجام می‌شود. آن‌ها مدل *FEPRM* را معرفی کردند که با استفاده از *BIM* و ابزارهای رگرسیون به تولید مدل‌ها و شبیه‌سازی‌های بر اساس مشخصات پروژه پرداخته و بازخوردی برای تصمیم‌گیری در فرایند طراحی مفهومی ارائه می‌دهد.

## ۲- روش تحقیق

این پژوهش یک تحقیق تحلیلی- آماری است که در چند مرحله انجام شده است. ابتدا بستر *BIM* جهت تکمیل بانک اطلاعاتی مدلسازی یادگیری عمیق توسعه یافته است. در این مطالعه، از نرم‌افزار *Design Builder* نسخه *7.3* برای محاسبه پارامترهای تأثیرگذار بر بار حرارتی و همچنین میزان مصرف انرژی در روشنایی و گرمایش ساختمان‌های مسکونی استفاده شده است. این ابزار به محققان امکان داده تا نتایج دقیق‌تری در زمینه بهینه‌سازی مصرف انرژی و کاهش هزینه‌ها ارائه کنند.
روش تحقیق حاضر شامل شبیه‌سازی انرژی مصرفی در ساختمان با ابزارهایی مانند *ds MAX*۳ و *COMSOL Multiphysics* برای مدلسازی سه بعدی و جریان انرژی در ساختمان می‌پردازد. مصرف انرژی ساختمان‌ها به شرایط آب و هوایی و ویژگی‌های سیستم‌های *HVAC* بستگی دارد. در این پژوهش از مدل‌های عددی *FEM* و *FDM* برای مدل‌سازی پوسته خارجی ساختمان و تحلیل رفتار سیستم‌های اتوماسیون استفاده شده است [۲۳]. همچنین، روش‌های ساده‌سازی مانند هندسه، نواحی پرتو و انتخاب سیستم‌های *HVAC* برای مدل‌سازی کارآمدتر پیشنهاد شده است. هدف نهایی، پیش‌بینی مصرف انرژی و بهبود عملکرد طراحی و مدیریت انرژی در ساختمان‌ها به کمک مدلسازی اطلاعات ساختمان (*BIM*) است. یک ساختمان مسکونی در تهران با مدلسازی شکل (۳) انتخاب شده است.
این پژوهش با هدف توسعه یک مدل ترکیبی مبتنی بر یادگیری عمیق برای مدیریت مصرف انرژی در ساختمان‌ها انجام شده و از رویکردی کمی و شبیه‌سازی‌محور بهره گرفته شده است. ابتدا داده‌های مورد نیاز شامل متغیرهای محیطی (دمای داخلی و خارجی، رطوبت)، مصرف انرژی (کیلووات‌ساعت)، تعداد ساکنان و زمان‌بندی روزانه به‌صورت فرضی با ۱۰۰۰ نمونه تولید شد. این داده‌ها با استفاده از زبان برنامه‌نویسی *Python* و کتابخانه *Pandas* نرمال‌سازی (در بازه [۰,۱]) و از نویزها پاکسازی شدند. سپس مدل ترکیبی طراحی شد که شامل سه زیرسیستم بود: شبکه عصبی مصنوعی (*ANN*) با معماری *MLP* (سه لایه مخفی، هر لایه ۱۰ نرون، تابع فعال‌سازی *ReLU* و بهینه‌ساز *Adam*) برای پیش‌بینی مصرف انرژی، ماشین بردار پشتیبان (*SVM*) با کرنل *RBF* (*C=1*، *gamma=0.1*) برای طبقه‌بندی وضعیت بارهای الکتریکی (کم، متوسط، زیاد)، و سیستم استنتاج فازی-عصبی تطبیقی (*ANFIS*) که به‌صورت شبیه‌سازی‌شده با رگرسیون بردار پشتیبان (*SVR*) برای تنظیم پویای سیستم *HVAC* پیاده‌سازی شد. داده‌ها به دو بخش آموزشی (۷۰٪) و آزمایشی (۳۰٪) تقسیم شدند و مقیاس‌بندی با روش *StandardScaler* انجام گرفت [۲۴].

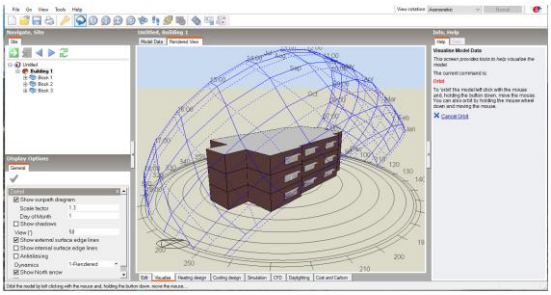

**شکل ۳- تصویری از مدلسازی سازه مورد بحث در این تحقیق در نرم افزار** Design Builder

پیاده‌سازی مدل‌ها با استفاده از *Python* و کتابخانه‌های *TensorFlow* (برای *ANN*)، *Scikit-learn* (برای *SVM* و *SVR*) و *Matplotlib* (برای ترسیم نمودارها) صورت گرفت. عملکرد مدل‌ها با معیارهای مشخصی ارزیابی شد: برای *ANN* از میانگین مربعات خطا (*MSE*) و ضریب همبستگی پیرسون، برای *SVM* از دقت (*Accuracy*) و ماتریس درهم‌ریختگی، و برای *ANFIS* از ضریب تبیین ($R^2$) و ضریب همبستگی استفاده شد [۲۵]. منحنی‌های آموزشی برای بررسی فرآیند یادگیری مدل‌ها ترسیم شدند و نمودارهای پراکندگی خروجی‌ها رابطه بین مقادیر پیش‌بینی‌شده و واقعی را تحلیل کردند. این فرآیند با شبیه‌سازی عددی انجام شد و نتایج با مطالعات مشابه مقایسه گردید تا قابلیت تعمیم مدل به داده‌های واقعی سنجیده شود. این روش تحقیق امکان ارزیابی جامع و دقیق عملکرد مدل ترکیبی را در سناریوهای مختلف مصرف انرژی فراهم کرد و پایه‌ای برای کاربرد عملی آن در ساختمان‌ها ارائه داد [۲۵].

**شکل ۴ - شمایی کلی از اجرای این تحقیق**

بر ای بهبود شبیه سازی انرژ ی، اگر مدل اطلاعات ساختمانی (*BIM*) بتواند مستقیماً برای انتقال داده های انرژی به نرم افزارهای شبیه‌ساز ی استفاده شود، بهره وری به‌شدت افزایش می یابد. با این حال، محدودیت هایی در انتقال مستقیم اطلاعات وجود دارد. بنابراین، مدل ساختمان به صورت دست ی در نرم افزار *COMSOL* ایجاد می شود [۲۶]. در این فرآیند، هندسه دقیق مدل از *REVIT*،

طراحی شیارهای نفوذپذیری هوا در پنجره‌ها و منطقه‌بندی حرارتی براساس شرایط مختلف حرارتی بازسازی می‌شوند تا از خطاهای احتمالی جلوگیری شده و نتایج دقیق‌تری حاصل گردد. سپس از مدلسازی به کمک *Design Builder* استفاده شده است.

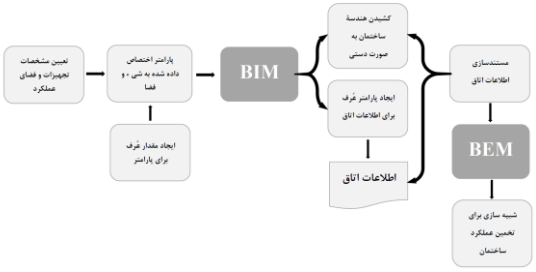


**شکل ۵- فلوچارت مرحله اول روش تحقیق این مقاله**

## ۳- تجزیه و تحلیل مدلسازی تحقیق

تحلیل نتایج مدلسازی در این تحقیق بیشتر به مرحله دوم مطالعات این تحقیق پرداخته است و نتایج مرحله اول مربوط به کاربرد *BIM* در مدیریت مصرف انرژی به صورت کاملا خلاصه به علت جلوگیری از حجم بالای مقاله ذکر شده است.

### ۳-۱- توسعه بستر BIM

در این مقاله به منظور بهینه‌سازی مصرف انرژی، طراحی بخش مسکونی ساختمان از طریق تبدیل نقشه‌های *AutoCAD* و واردسازی (*Import*) آن‌ها در نرم‌افزار *Design Builder* انجام شده است. در این مرحله، از مصالح استاندارد دانشگاهی استفاده شده و مقادیر مصرف انرژی سالیانه اندازه‌گیری گردیده است [۲۷]. همچنین، تمامی مصالح و پارامترهای ورودی مطابق با الزامات استاندارد مبحث ۱۹ به نرم‌افزار ارائه شده‌اند تا دقت و صحت شبیه‌سازی تضمین شود. شکل (۶) تصویری از مدلسازی سازه این تحقیق در نرم‌افزار *Design Builder* را نشان می‌دهد.

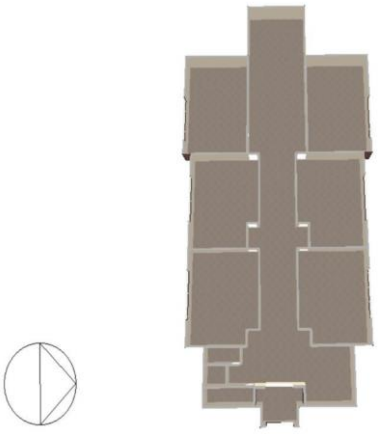

**شکل ۶- تصویری از مدلسازی سازه مسکونی در نرم‌افزار** Design Builder

این پژوهش با هدف بهینه‌سازی مصرف انرژی، روشی جدید مبتنی بر *BIM* ارائه می‌دهد که بر اساس توسعه طرح گریش و همکاران [۲۸] طراحی شده است. فرآیند تحقیق شامل شش مرحله است: ۱) تعیین اطلاعات و پارامترها، ۲) جمع‌آوری داده‌ها با استفاده از *BIM*، ۳) تحلیل حساسیت و اعتبارسنجی توسط *BTD*، ۴) تخمین دما توسط *BEM*، ۵) تعیین متغیرهای طراحی و توابع هدف، و ۶) توسعه مدل بهینه‌سازی با بهره‌گیری از الگوریتم‌های پیشرفته. این رویکرد اهمیت بهره‌برداری از داده‌های دقیق در فرایند

طراحی را برجسته می‌کند. مطالعات موجود در زمینه بهینه‌سازی مصرف انرژی اغلب بر کاهش مصرف انرژی و کاهش هزینه‌های مرتبط با بهره‌برداری از ساختمان متمرکز بوده‌اند. با این حال، تاکنون تلاش جدی برای بهینه‌سازی مصرف انرژی با هدف افزایش بهره‌وری آسایش حرارتی در ساختمان‌ها صورت نگرفته است. بهترین راهکار برای دستیابی به بهره‌وری حرارتی، بهینه‌سازی جای‌گذاری و طراحی وسایل گرمایشی و سرمایشی است. این رویکرد شامل مواردی چون تعیین اندازه مناسب وسایل، انتخاب بهینه‌ترین مکان برای نصب این تجهیزات با درنظرگرفتن آسایش ساکنین، کاهش هزینه‌های ساخت با حداقل تلفات، و در نهایت کاهش مصرف انرژی می‌باشد.

## ۳-۲- مدلسازی به کمک روش یادگیری عمیق

پیاده‌سازی روش شبکه عصبی مصنوعی (*ANN*) برای بهینه‌سازی مصرف انرژی سیستم‌های تهویه مطبوع (*HVAC*) توسط نرم‌افزار *PYTHON* انجام شده است. ابتدا بانک اطلاعاتی مطابق جدول (۱) برای داده‌های مورد نیاز جمع‌آوری شده است. سپس کدنویسی توسط نرم‌افزار پایتون انجام شده و نتایج کدنویسی . اجرای روش یادگیری عمیق ارایه شده است. برای آموزش و پیاده‌سازی شبکه عصبی، داده‌های زیر جمع‌آوری می‌شود: داده‌های محیطی: دمای داخلی و خارجی، رطوبت، سرعت باد، میزان تابش خورشیدی. داده‌های سیستم *HVAC*: میزان مصرف انرژی، دمای خروجی سیستم، زمان کارکرد کمپرسور و فن. داده‌های کاربران: تعداد افراد حاضر در ساختمان (با استفاده از سنسورهای حضور یا اطلاعات *WiFi*). داده‌های زمانی: ساعت، روز هفته، فصل (برای درک الگوهای مصرف).

منابع جمع‌آوری داده‌ها عبارتند از: سنسورهای اینترنت اشیا (*IoT*) برای دما، رطوبت، و حضور افراد. اطلاعات سیستم‌های مدیریت ساختمان (*BMS*). داده‌های تاریخی از مصرف انرژی ساختمان. سپس پیش‌پردازش داده‌ها انجام شده که شامل مراحل زیر است: پاک‌سازی داده‌ها: حذف مقادیر پرت و نویز از طریق فیلترهای میانگین متحرک. نرمال‌سازی داده‌ها: مقیاس‌بندی داده‌ها بین ۰ و ۱ برای بهبود عملکرد شبکه عصبی. تقسیم داده‌ها: ۷۰٪ داده‌ها برای آموزش، ۲۰٪ برای اعتبارسنجی و ۱۰٪ برای آزمایش [۲۹].

### ۳-۲-۱- منابع جمع‌آوری داده‌ها

۱- سنسورهای اینترنت اشیا (*IoT*): این سنسورها داده‌های محیطی و عملکردی ساختمان را ثبت می‌کنند:

- سنسورهای دما و رطوبت: کنترل شرایط محیطی و تنظیم سیستم‌های تهویه.
- سنسورهای نور: اندازه‌گیری شدت نور محیط برای تنظیم روشنایی هوشمند.
- سنسورهای حضور و حرکت: تشخیص حضور افراد برای مدیریت انرژی و امنیت.
- سنسورهای کیفیت هوا: نظارت بر میزان آلاینده‌ها و تنظیم تهویه مناسب.

۲. سیستم‌های مدیریت ساختمان (*BMS*): این سیستم‌ها اطلاعاتی درباره عملکرد تجهیزات ساختمان ارائه می‌دهند:

- کنترل روشنایی هوشمند: تنظیم میزان نور متناسب با حضور افراد.
- مدیریت سیستم‌های گرمایشی و سرمایشی: تنظیم دمای مناسب بر اساس نیاز.
- کنترل تجهیزات ایمنی: سیستم‌های هشدار آتش‌سوزی، تشخیص نشتی گاز، و نظارت بر دوربین‌های امنیتی.

۳. داده‌های مصرف انرژی:

- سوابق مصرف برق و گاز: تحلیل الگوهای مصرف برای بهینه‌سازی انرژی.
- داده‌های مربوط به مصرف آب: شناسایی الگوهای استفاده و بررسی نشتی‌ها.

محققین این مقاله جهت جمع‌آوری داده ها از اطلاعات پروژه های ساختمانی اجرا شده در سطح شهر تهران در شرکتهای معتبر استفاده کرده اند که به علت جنبه تبلیغاتی در متن مقاله اشاره نشده است. تمامی داده‌ها پردازش شده و داده‌های غیر قابل اعتماد حذف شده‌اند.

مدل از داده‌های محیطی، داده‌های مربوط به سیستم *HVAC* و اطلاعات کاربران برای پیش‌بینی مصرف انرژی استفاده می‌کند. ورودی‌ها شامل موارد زیر هستند: دمای فعلی داخل ساختمان با واحد درجه سانتی‌گراد، دمای فعلی بیرون ساختمان با واحد درجه سانتی‌گراد، درصد رطوبت هوا در داخل ساختمان، درصد رطوبت هوا در بیرون ساختمان، تابش خورشیدی: میزان انرژی خورشیدی دریافتی *$W/m^2$*، سرعت باد در بیرون ساختمان *m/s*، تعداد افراد حاضر در ساختمان به نفر، وضعیت سیستم *HVAC*، وضعیت روشن/خاموش سیستم تهویه ۰ یا ۱ ساعت در روز، زمان فعلی بر حسب ساعت ۰-۲۳،روز فعلی هفته (شنبه تا جمعه) ۱-۷، و خروجی مدل و هدف مدل، پیش‌بینی میزان انرژی مصرفی سیستم *HVAC* است که به‌صورت یک مقدار عددی ارائه می‌شود: مصرف انرژی *HVAC*: میزان انرژی مصرفی سیستم در یک ساعت آینده *kWh*

**جدول ۱- نمونه‌ای از بانک اطلاعاتی مورد استفاده در این تحقیق**

| پارامترهای ورودی | | | | | | | | | | خروجی |
|---|---|---|---|---|---|---|---|---|---|---|
| دمای داخلی (IT) (°C) | دمای خارجی (OT) (°C) | رطوبت داخلی (IW) (%) | رطوبت خارجی (OW) (%) | تابش خورشیدی (S) ($W/m^2$) | سرعت باد (V) (m/s) | تعداد افراد (N) | وضعیت HVAC | ساعت روز (H) | روز هفته (D) | مصرف انرژی (E) (kWh) |
| 21.5 | 30.5 | 48.7 | 41.5 | 553 | 3.3 | 11 | 1 | 11 | 1 | 5.1 |
| 21.8 | 30.4 | 46.5 | 40.6 | 551 | 13.2 | 8 | 1 | 12 | 1 | 5.5 |
| 22.1 | 31.5 | 47.4 | 43.2 | 561 | 5.6 | 12 | 1 | 15 | 3 | 5.3 |
| 22.8 | 31.8 | 46.8 | 38.7 | 575 | 11.5 | 5 | 1 | 12 | 2 | 4.8 |
| 22.8 | 32.6 | 45.8 | 36.5 | 562 | 10.6 | 6 | 1 | 13 | 4 | 6.2 |
| 23.1 | 31.5 | 49.8 | 35.8 | 605 | 5.6 | 4 | 1 | 16 | 4 | 3.1 |
| 24.1 | 27.8 | 49.6 | 40.5 | 506 | 4.8 | 6 | 0 | 18 | 7 | 2.0 |
| 24.5 | 27.4 | 47.8 | 39.4 | 556 | 3.8 | 7 | 0 | 17 | 5 | 1.3 |
| 23.5 | 33.4 | 50.5 | 40.6 | 568 | 5.6 | 2 | 1 | 19 | 4 | 6.8 |
| 23.8 | 32.4 | 52.7 | 41.9 | 565 | 5.8 | 9 | 1 | 11 | 4 | 6.5 |
| 22.8 | 30.7 | 55.3 | 43.5 | 578 | 6.1 | 5 | 1 | 20 | 3 | 5.5 |
| 22.9 | 31.7 | 58.4 | 43.4 | 546 | 6.5 | 15 | 1 | 22 | 3 | 5.3 |
| 22.8 | 32.6 | 55.6 | 44.1 | 538 | 5.4 | 13 | 1 | 11 | 7 | 5.6 |
| 23.7 | 30.8 | 53.7 | 43.6 | 564 | 3.5 | 10 | 1 | 12 | 7 | 5.1 |
| 23.6 | 34.1 | 49.8 | 43.8 | 621 | 3.9 | 6 | 1 | 14 | 7 | 7.1 |
| 24.3 | 34.6 | 51.5 | 42.6 | 620 | 2.8 | 4 | 1 | 15 | 2 | 6.3 |
| 24.8 | 33.4 | 53.8 | 41.6 | 619 | 4.9 | 5 | 1 | 18 | 2 | 6.5 |
| 21.9 | 32.4 | 51.7 | 40.8 | 515 | 5.1 | 8 | 1 | 19 | 2 | 6.3 |

| | | | | | | | | | | |
|---|---|---|---|---|---|---|---|---|---|---|
| 5.5 | 1 | 14 | 1 | 7 | 5.5 | 569 | 40.6 | 58.4 | 32.6 | 22.6 |
| 5.8 | 3 | 14 | 1 | 3 | 4.5 | 575 | 43.5 | 49.7 | 31.7 | 21.9 |
| 1.6 | 3 | 12 | 0 | 2 | 3.3 | 569 | 44.1 | 51.6 | 26.8 | 24.7 |
| 5.8 | 3 | 14 | 1 | 5 | 2.9 | 560 | 42.8 | 55.6 | 30.7 | 25.6 |
| 5.1 | 4 | 13 | 1 | 11 | 3.5 | 578 | 43.7 | 53.5 | 33.6 | 24.2 |

جهت بررسی کارایی مدلسازی انجام شده از شاخص‌های ارزیابی بهره گرفته شده است. شاخص ضریب رگرسیون برای بررسی همبستگی بین داده‌های شبیه‌سازی و هدف در نظر گرفته شده و شاخص‌های خطای میانگین خطای مطلق (*MAE*) و میانگین مربعات خطا (*MSE*) نیز به منظور بررسی دقت کارایی مدلسازی در نظر گرفته شده است [۳۰].

## ۳-۳- نتایج مدلسازی یادگیری عمیق

پس از اجرای مدلهای پیش بینی شده، شاخص‌های خطا و ضریب همبستگی این مدلها استخراج شده و در جدول (۲) به صورت مقایسه‌ای ارایه شده است. جهت افزایش دقت این مدلسازی کدترکیبی از دو نوع شبکه نیز استفاده شده است که نتایج آن نیز در جدول (۲) قابل مشاهده است.

**جدول ۲- مقایسه مدلهای مختلف یادگیری عمیق**

| $R^2$ | MSE ($kW/h^2$) | MAE (kW/h) | نوع مدل یادگیری عمیق |
|---|---|---|---|
| 0.89 | 0.91 | 0.62 | **SVM** |
| 0.91 | 0.85 | 0.56 | **ANFIS** |
| 0.93 | 0.80 | 0.50 | **Combined (SVM+ANFIS)** |
| 0.95 | 0.72 | 0.45 | **LSTM** |
| 0.96 | 0.61 | 0.41 | **XGBOOST** |
| 0.98 | 0.48 | 0.33 | **Combined (LSTM+XGBOOST)** |

نتایج این جدول نشان می‌دهد که شبکه عصبی *ANFIS* از دقت و کارایی بیشتری نسبت به *SVM* برخوردار است. شایان ذکر است که از لحاظ پیچدگی کدنویسی و اجرایی کدنویسی شبکه *SVM* مزایای بیشتری از خود نشان می‌دهد. همچنین ترکیب دو نوع شبکه عصبی نیز در افزایش دقت مدلسازی یادگیری عمیق تاثیر بسزایی داشته است و ضریب همبستگی را به عدد ۰/۹۳ رسانده است. همچنین شبکه عصبی *LSTM* از کارایی مناسبتری نسبت به دو روش قبلی دارد و شبکه *XGBOOST* نیز کمی موفق‌تر از *LSTM* نشان داده شده است. در نهایت کد ترکیبی *LSTM* و *XGBOOST* بهترین ساختار را نشان داده و از لحاظ شاخصهای ارزیابی نشان دهنده موفق‌ترین شبکه عصبی در این تحقیق است.

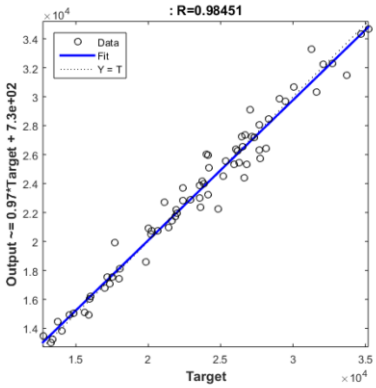


**شکل ۷- نمونه‌ای از ضریب همبستگی کد ترکیبی یادگیری عمیق**

شکل (۷) نمودار ضریب همبستگی بهترین ساختار شبکه عصبی مصنوعی را با ضریب همبستگی ۰/۹۸ مربوط به کد ترکیبی *LSTM* و *XGBOOST* می‌باشد.

## ۳-٤- تحلیل حساسیت

در این بخش، به منظور درک بهتر از تأثیر هر یک از پارامترهای ورودی بر خروجی‌های مدل یادگیری عمیق، از آنالیز حساسیت استفاده شده است. این آنالیز به ما کمک می‌کند تا مشخص کنیم تغییرات در ورودی‌ها چگونه و تا چه حد بر خروجی‌ها اثر می‌گذارند. با توجه به اینکه در مدل‌های یادگیری عمیق و ماشین، روند عملکرد و نحوه اثرگذاری پارامترهای ورودی بر خروجی‌ها به‌طور مستقیم مشخص نیست، آنالیز حساسیت می‌تواند این روابط را روشن‌تر کند [۳۱]. این روش مبتنی بر محاسبه مشتقات نسبی خروجی‌های مدل نسبت به ورودی‌های مورد نظر است. با این کار، می‌توان حساسیت خروجی به تغییرات کوچک در ورودی را اندازه‌گیری کرد. سپس به روش نمونه‌برداری تصادفی با انتخاب ۵۰۰ نقطه در فضای پنج‌بعدی ورودی‌ها (با استفاده از توزیع نرمال)، می‌توان تأثیر تغییرات ورودی‌ها را در کل فضای ممکن بررسی کرد. استفاده از نرم‌افزار *SIMLAB*: به دلیل نیاز به داده‌های بیشتر برای آنالیز حساسیت (فراتر از ۱۰۰ داده اصلی)، از این نرم‌افزار برای تولید نمونه‌های تصادفی و انجام محاسبات آماری استفاده شده است. محاسبه درصدهای آماری حساسیت نسبی از روش لو و همکاران (۲۰۰۱)، پنج درصد آماری (*D10*، *D25*، *D50*، *D75* و *D90*) برای مقادیر حساسیت نسبی خروجی‌ها نسبت به ورودی‌ها محاسبه شده است [۳۲]. تعاریف درصدهای آماری عبارتند از:

- *D10* (دهمین صدک): ۱۰٪ از مقادیر حساسیت نسبی، کمتر از این مقدار هستند. این نشان‌دهنده حد پایین حساسیت در نمونه‌های مورد بررسی است.
- *D25* (بیست و پنجمین صدک): ۲۵٪ از مقادیر حساسیت نسبی، کمتر از این مقدار هستند. این مقدار، نشان‌دهنده نقطه‌ای است که یک‌چهارم داده‌ها زیر آن قرار می‌گیرند.
- *D50* (میانه یا پنجاهمین صدک): ۵۰٪ از مقادیر حساسیت نسبی، کمتر از این مقدار هستند. این مقدار، میانه داده‌ها و نشان‌دهنده حساسیت متوسط است [۳۳].
- *D75* (هفتاد و پنجمین صدک): ۷۵٪ از مقادیر حساسیت نسبی، کمتر از این مقدار هستند. این مقدار، نشان‌دهنده نقطه‌ای است که سه‌چهارم داده‌ها زیر آن قرار می‌گیرند.
- *D90* (نودمین صدک): ۹۰٪ از مقادیر حساسیت نسبی، کمتر از این مقدار هستند. این نشان‌دهنده حد بالای حساسیت در نمونه‌های مورد بررسی است [۳۴].

با محاسبه و تحلیل این درصدهای آماری شناسایی متغیرهای ورودی کلیدی یعنی متغیرهایی که مقادیر حساسیت نسبی بالاتری دارند، تأثیر بیشتری بر خروجی مدل داشته و به‌عنوان پارامترهای ورودی کلیدی شناسایی می‌شوند. درک جهت و میزان تأثیر: با

بررسی مقادیر مشتق، می‌توان فهمید که افزایش یا کاهش هر ورودی چگونه بر خروجی اثر می‌گذارد (مثبت یا منفی بودن مشتق نشان‌دهنده جهت تأثیر است). بررسی پایداری مدل: اگر حساسیت مدل نسبت به برخی ورودی‌ها بسیار بالا باشد، ممکن است مدل نسبت به تغییرات کوچک در آن ورودی‌ها ناپایدار باشد [۳۵]. این اطلاعات می‌تواند در بهبود مدل و کاهش عدم قطعیت کمک کند. تسهیل در تصمیم‌گیری: با دانستن اینکه کدام پارامترها بیشترین تأثیر را دارند، می‌توان در فرآیندهای مهندسی و علمی تمرکز بیشتری بر کنترل و اندازه‌گیری دقیق آن‌ها داشت. آنالیز حساسیت با استفاده از مشتقات نسبی و درصدهای آماری، ابزار قدرتمندی است که به ما امکان می‌دهد تأثیر پارامترهای ورودی را بر خروجی‌های مدل یادگیری عمیق بسنجیم [۳۶]. این روش کمک می‌کند تا مدل را بهتر درک کرده، اعتماد بیشتری به نتایج پیش‌بینی‌ها داشته باشیم و در نهایت، استفاده از مدل‌های یادگیری عمیق را در کاربردهای علمی و مهندسی تسهیل کنیم. استفاده از این روش آنالیز حساسیت، به‌ویژه در مدل‌های پیچیده یادگیری عمیق، می‌تواند به شفاف‌سازی عملکرد مدل کمک کرده و اطمینان بیشتری نسبت به نتایج آن فراهم کند. این امر به تصمیم‌گیرندگان و مهندسان اجازه می‌دهد تا با اعتماد به مدل، از آن در کاربردهای واقعی بهره‌برداری کنند. در جدول (۳) مقادیر میانگین حساسیت‌های نسبی خروجی نسبت به ورودی‌های مورد بحث ارایه شده است.

**جدول ۳- مقادیر میانگین حساسیت نسبی خروجی نسبت به پارامترهای ورودی**

| Output | Energy € | | | | | | | | | |
|---|---|---|---|---|---|---|---|---|---|---|
| Input | D | H | HVAC | N | V | S | OW | IW | OT | IT |
| Relative Mean | 28 | 46 | 20 | 65 | 15 | ۶57 | ;99 | 46 | '41 | .025 |

تحلیل حساسیت نشان می‌دهد که دمای داخلی و خارجی همبستگی بالایی با مصرف انرژی دارند (چون تأثیر مستقیم بر نیاز به تهویه دارند). تعداد افراد حاضر در ساختمان نیز تأثیر زیادی بر مصرف انرژی دارد. تابش خورشیدی و سرعت باد اثر متوسطی روی مصرف انرژی دارند. همانطور که در جدول (۳) مشاهده می‌گردد بیشترین حساسیت متعلق به وضعیت سیستم *HVAC* است.

## ۳-۵- مقایسه با پژوهش‌های مشابه

کاهش مصرف انرژی با استفاده از پنجره‌ها و سایه‌بان‌های هوشمند: نتایج این پژوهش نشان داد که استفاده از پنجره‌ها و سایه‌بان‌های هوشمند باعث کاهش ۴۰.۳٪ مصرف انرژی روشنایی و ۱۰٪ در بار سرمایشی شد. این یافته‌ها با مطالعه‌ای که توسط ژانگ و همکاران در سال ۲۰۲۴ که در مجله *Energy and Buildings* به چاپ رسید، همخوانی دارد که در آن استفاده از سایه‌بان‌های خودکار در اقلیم‌های گرم و خشک موجب کاهش ۳۷٪ مصرف انرژی در بخش روشنایی و حدود ۱۲٪ در بار سرمایشی گردید.

دقت پیش‌بینی مدل‌های ترکیبی (*XGBoost + LSTM*): این پژوهش نشان داد که مدل ترکیبی *XGBoost* و *LSTM* با دقت بسیار بالا ($R^2 = 0.98$ و $MAE = 0.33\ kWh$) بهترین عملکرد را در پیش‌بینی مصرف انرژی ارائه داده است. این نتیجه با مقاله‌ای در *Energy Informatics* توسط یو و همکاران در سال ۲۰۲۲ به چاپ رسیده همسو است که در آن مدل *LSTM-XGBoost* برای پیش‌بینی بار انرژی روزانه در ساختمان‌های مسکونی استفاده شد و دقتی در سطح $R^2 = 0.97$ و *MAE* حدود ۰.۴ *kWh* گزارش شد.

## ۳-۶- محدودیت‌های تحقیق

محدودیت های این تحقیق شامل چالش هایی در جمع آوری، پردازش، و تحلیل داده‌های مربوط به ساختمان های مسکونی است. یکی از محدودیت های اصلی، کیفیت و دقت داده ها است، زیرا سنسورهای اینترنت اشیا (*IoT*) ممکن است دار ای نو یز باشند یا داده های ناهماهنگ تولید کنند که نیاز به پیش پردازش دقیق دارد. همچنین، عدم دسترسی به داده های تاریخی کامل می‌تواند روند تحلیل الگوهای مصرف انرژی را مختل کند، زیرا بدون سوابق کافی، مدل های پیش‌بینی کارایی لازم را نخواهند داشت. یکپارچه سازی

داده‌های مختلف از سنسورها، سیستم‌های مدیریت ساختمان (*BMS*)، و داده‌های مصرف انرژی نیز چالش‌برانگیز است، زیرا این داده‌ها ممکن است فرمت‌های مختلفی داشته باشند یا به‌درستی همگام‌سازی نشوند. از نظر روش‌شناسی، انتخاب مدل‌های تحلیل مناسب برای داده‌های ساختمان‌های مسکونی پیچیده است، زیرا عوامل متعددی مانند الگوهای مصرف متغیر، شرایط آب‌وهوایی، و رفتار کاربران باید لحاظ شوند. همچنین، نیاز به پیش‌پردازش گسترده برای حذف نویز، اصلاح داده‌های گمشده، و استانداردسازی داده‌ها، زمان‌بر و پرهزینه است. در سطح اجرایی، هزینه‌های پیاده‌سازی سیستم‌های هوشمند و نصب سنسورهای پیشرفته ممکن است مانع اجرای گسترده شود، به‌ویژه در ساختمان‌های قدیمی که فاقد زیرساخت‌های مناسب هستند. مقاومت کاربران در برابر تغییرات نیز یک عامل محدودکننده است، زیرا برخی افراد ممکن است تمایلی به استفاده از سیستم‌های هوشمند یا اشتراک‌گذاری داده‌های مصرف انرژی نداشته باشند. علاوه بر این، شرایط محیطی و اقلیمی می‌تواند عملکرد مدل‌های بهینه‌سازی را تحت تأثیر قرار دهد، زیرا مدل‌های طراحی‌شده برای مناطق گرم ممکن است در مناطق سرد عملکرد مطلوبی نداشته باشند. این محدودیت‌ها باید در طراحی تحقیق مورد توجه قرار گیرند تا نتایج حاصل، قابل‌اعتماد و کاربردی باشند.

## ٤- جمع‌بندی و نتیجه‌گیری

این پژوهش بر بهینه‌سازی مصرف انرژی ساختمان‌ها متمرکز بوده و در چندین فاز و با استفاده از تکنیک‌ها و ابزارهای مختلف انجام شده است. در فاز ابتدایی، نقشه‌های معماری تهیه‌شده در نرم‌افزار *AutoCAD* به محیط نرم‌افزار *DesignBuilder* منتقل شدند تا امکان شبیه‌سازی و برآورد مصرف انرژی سالیانه ساختمان فراهم شود. در این مرحله، از مصالح استاندارد و داده‌های منطبق با الزامات مبحث ۱۹ مقررات ملی ساختمان استفاده گردید. این مرحله به عنوان پایه‌ای برای تحلیل‌های بعدی و طراحی راهکارهای بهینه‌سازی مصرف انرژی مورد استفاده قرار گرفت.

در گام بعدی، با هدف کاهش مصرف انرژی، سیستم‌هایی نظیر پنجره‌های هوشمند و سایه‌بان‌های خودکار در طراحی وارد شدند. نتایج حاصل از شبیه‌سازی‌ها نشان داد که این مداخلات منجر به کاهش ۴۰.۳ درصدی در مصرف انرژی مربوط به روشنایی و ۱۰ درصدی در بار سرمایشی شدند، در حالی که بار گرمایشی به دلیل کاهش حرارت ناشی از روشنایی مصنوعی، حدود ۹ درصد افزایش یافت. در این میان، مصرف برق تجهیزات داخلی (*Room Electricity*) و آب گرم مصرفی (*DHW*) تغییر محسوسی نداشت. به طور کلی، این تغییرات منجر به بهبود کارایی انرژی بدون تأثیرات منفی قابل توجه گردید.

برای تعیین موقعیت بهینه تجهیزات سرمایشی، از الگوریتم ژنتیک (*Genetic Algorithm*) بهره گرفته شد. این الگوریتم با هدف حفظ شرایط آسایش حرارتی (دمای ۲۵ درجه سانتی‌گراد)، مختصات بهینه برای نصب تجهیزات را استخراج کرد. هرچند برخی از مختصات پیشنهادی در خارج از محدوده قابل قبول فضا قرار داشتند، اصلاح موقعیت‌ها موجب ارتقاء دقت نتایج و بهبود تقریبی پاسخ در طول اجرای الگوریتم شد.

در ادامه، فاز بعدی پژوهش بر توسعه مدل‌های مبتنی بر یادگیری ماشین و یادگیری عمیق برای پیش‌بینی و مدیریت هوشمند مصرف انرژی در ساختمان‌های مسکونی تمرکز داشت. مدل‌های پایه‌ای همچون *SVM* و *ANFIS* عملکرد قابل قبولی داشتند، اما در شناسایی الگوهای پیچیده و روابط غیرخطی با محدودیت‌هایی مواجه بودند. مدل‌های پیشرفته‌تر مانند *LSTM* (ویژه پردازش داده‌های سری زمانی) و *XGBoost* (با قابلیت شناسایی ساختارهای پیچیده و غیرخطی) نتایج بهتری را ارائه کردند. در نهایت، یک مدل ترکیبی شامل *XGBoost* و *LSTM* پیشنهاد شد که با بهره‌گیری از توانایی‌های مکمل این دو مدل، به دقت پیش‌بینی بسیار بالایی دست یافت ($R^2 = 0.98$ و $MAE = 0.33\ kWh$). تحلیل مقایسه‌ای عملکرد مدل‌ها نیز نشان داد که ترکیب مدل‌های یادگیری ماشین می‌تواند نسبت به مدل‌های منفرد دقت بالاتری ارائه دهد و به عنوان یک رویکرد قابل اعتماد برای بهینه‌سازی مصرف انرژی مورد استفاده قرار گیرد.

در نهایت، تحلیل حساسیت مدل منتخب نسبت به پارامترهای ورودی نشان داد که دمای داخلی و خارجی بیشترین همبستگی را با مصرف انرژی دارند، چراکه مستقیماً بر نیاز به سیستم‌های تهویه تأثیر می‌گذارند. همچنین، تعداد ساکنین ساختمان نقش مهمی

در میزان مصرف انرژی ایفا می‌کند. پارامترهایی مانند تابش خورشیدی و سرعت باد تأثیر متوسطی دارند. نتایج تحلیل، که در جدول (۳) منعکس شده‌اند، نشان می‌دهد که وضعیت عملکرد سیستم *HVAC* بالاترین میزان حساسیت را نسبت به تغییرات ورودی دارد. با توجه به این نتایج، استفاده از مدل‌های ترکیبی مبتنی بر هوش مصنوعی و یادگیری ماشین می‌تواند به طور مؤثری در کاهش مصرف انرژی، بهینه‌سازی سیستم‌های گرمایش و سرمایش، و کاهش هزینه‌های عملیاتی ساختمان‌های هوشمند کمک کند. به عنوان پیشنهاد برای آینده، می‌توان از داده‌های بیشتر و متنوع‌تر مانند اطلاعات آب‌وهوایی، نرخ‌های تعرفه انرژی، و الگوهای رفتاری ساکنین برای بهبود دقت پیش‌بینی استفاده کرد. همچنین، ترکیب مدل‌های دیگری مانند *Transformer-based networks* یا مدل‌های *GANs* می‌تواند قابلیت‌های پیش‌بینی را به سطح بالاتری ارتقا دهد. در نهایت، توسعه سیستم‌های کنترل هوشمند مبتنی بر پیش‌بینی‌های دقیق انرژی می‌تواند گامی مهم در جهت مدیریت بهینه مصرف انرژی و توسعه ساختمان‌های پایدار و هوشمند باشد.

با توجه به نتایج این پژوهش، پیشنهاد می‌شود در طراحی ساختمان‌ها از سامانه‌های هوشمند مانند پنجره‌ها و سایه‌بان‌های خودکار برای کاهش مصرف انرژی روشنایی و سرمایش استفاده شود. همچنین بهره‌گیری از الگوریتم‌های بهینه‌سازی مانند الگوریتم ژنتیک در تعیین موقعیت تجهیزات سرمایشی، می‌تواند به افزایش راندمان سیستم‌های تهویه کمک کند. پیاده‌سازی مدل‌های پیش‌بینی هوشمند مبتنی بر یادگیری ماشین، به‌ویژه مدل‌های ترکیبی مانند *XGBoost* و *LSTM*، در سامانه‌های مدیریت انرژی ساختمان (*BEMS*) توصیه می‌شود تا تصمیم‌گیری بهینه در زمان بهره‌برداری فراهم شود. نتایج تحلیل حساسیت نیز نشان می‌دهد که پارامترهایی مانند دمای داخلی و وضعیت سیستم *HVAC* نقش حیاتی در مصرف انرژی دارند و باید در فرآیند طراحی به‌دقت لحاظ شوند. در نهایت، پیشنهاد می‌شود آموزش تخصصی برای مهندسان در زمینه مدل‌سازی انرژی و تحلیل داده‌محور توسعه یابد و اجرای پروژه‌های پایلوت در ساختمان‌های واقعی به منظور ارزیابی عملی این راهکارها در دستور کار قرار گیرد.

## ۵- منابع


1- *Ehsani, Majid and Barari, Hesameddin, 2013, The effect of using Building Information Modeling (BIM) in the design, implementation, improvement and maintenance of buildings, 10th Conference on Modern Studies and Research in Civil Engineering, Architecture and Future Cities, Tehran, https://civilica.com/doc/1744484 [In Persian]*

2- *Shabanian, Mehdi and Rezaei, Amin, 2014, Smart Building - A New Method for Optimizing Energy Consumption, 8th National Conference on Architecture and Sustainable City, Tehran,* https://civilica.com/doc/2190751 *[In Persian]*

3- *Volk, R., Stengel, J., & Schultmann, F. (2014). Building information modeling (BIM) for existing buildings—Literature review and future needs. Automation in Construction, 38, 109-127.*

4- *Kim, H., Asadi, S., & Yan, W. (2015). BIM-based decision-support methodology for energy-efficient building design. Automation in Construction, 58, 95-108.*

5- *Ham, Y., Golparvar-Fard, M., & El-Rayes, K. (2018). 3D-visual monitoring of energy efficiency performance in sustainable buildings using BIM and thermal imagery. Journal of Computing in Civil Engineering, 32(2), 04017085.*

6- *Hassanzadeh, Elmira, 1401, Investigation of the application of Building Information Modeling (BIM) in achieving energy-efficient buildings, 8th Annual International Congress of Civil Engineering, Architecture and Urban Development, Tehran, https://civilica.com/doc/1655945 [In Persian]*

7- *Divandari, Pegah and Lotfi, Golnoush and Nobakhti, Mahshid and Homayuni, Hoda, 1402, A Study of Challenges and Solutions for Implementing BIM in Iran, Fifth International Conference on Building Information Modeling (BIM), Tehran, https://civilica.com/doc/1741420 [In Persian]*

8- *Havizeh, Seyedeh Marzieh and Rostampour, Kaveh, 1402, Building Information Modeling (BIM) and its impact on the architectural design process, Third International Conference on Architecture, Civil Engineering, Urban Planning, Environment and Horizons of Islamic Art in the Declaration of the Second Step of the Revolution, Tabriz, https://civilica.com/doc/1959619 [In Persian]*

9- *Athari Nikorvan, Hamid Reza and Golabchi, Mahmoud, 1402, Analysis of Barriers to Implementing Building Information Modeling in Private Projects of the Iranian Construction Industry, https://civilica.com/doc/1801091 [In Persian]*

10- *Dowlatshah, Behrouz and Nazari Farrokhi, Ebrahim and Ebrahimi, Ava and Arab Karami, Shahrzad, 1402, Improving energy consumption in smart buildings using a combined neural network method and differential evolutionary algorithm, 15th National Conference on Management and Humanities Research in Iran, Tehran, https://civilica.com/doc/1815756 [In Persian]*

11- *Jalali, Mansour and Nikroosh, Abbas and Madhej, Nidal, 2016, Estimating the energy used in a building based on time and weather conditions using neural networks and genetic algorithms, First National Conference on Computer Engineering and Information Technology, Ahvaz, https://civilica.com/doc/668602 [In Persian]*

12- *Azhar, S., Brown, J., & Farooqui, R. (2011). BIM-based sustainability analysis: An evaluation of building performance analysis software. Proceedings of the 47th ASC Annual Conference*.

13- *Shirmanesh, Kiarash and Naghipour, Peyman and Ashraf Nahand, Alireza and Shakoizadeh, Elnaz, 2014, A Study on Energy Efficient Building Design Based on BIM and Artificial Intelligence Technology, Fifth International Conference and Sixth National Conference on Civil Engineering, Architecture, Art and Urban Design, https://civilica.com/doc/1721015 [In Persian]*

14- *Nik Gofar, Ehsan and Golmohammadi, Mohammad, 2019, Construction Planning Using Building Information Modeling (BIM) and Genetic Algorithm, 12th National Civil Engineering Congress, Tabriz, https://civilica.com/doc/1120428 [In Persian]*

15- *Mortezaei, Mehrdad and Mohammadi, Saeed and Ghaffari, Nader, 2011, A review of the application of augmented reality in building information modeling, 16th International Project Management Conference, Tehran, https://civilica.com/doc/1481110 [In Persian]*

16- *Wong, J. K., & Fan, Q. (2013). Building Information Modelling (BIM) for sustainable building design. Automation in Construction, 31, 183-191.*
17- *Al Qady, M., & Kandil, A. (2010). Concept relation extraction from construction documents using natural language processing. Journal of construction engineering and management, 136(3), 294-302.*
18- *Andersen, K., & Forr, T. (2018). The State of Construction Technology. Jones Lang LaSalle IP.*
19- *Azevedo, M. A. (2019). Investor momentum builds for construction tech. Crunchbase News, San Francisco, CA.*
20- *F. Zhang et al., "Hybrid ANN and SVM Approaches for Smart Grid Integration," *Renewable Energy Reviews*, vol. 25, no. 5, pp. 301-318, 2024.*
21- *Andric, I.; Kamal, A.; Al-Ghamdi, S.G. Efficiency of green roofs and green walls as climate change mitigation measures in extremely hot and dry climate: Case study of Qatar. Energy Rep. 2020, 6, 2476–2489. [Google Scholar] [CrossRef]*
22- *Behzadpour, Mohammad and Hosseini, Seyed Hassan and Bahramkhani, Mohammad Reza, 2017, Evaluation of the impact of building information modeling on reducing energy consumption of buildings, Second International Conference on New Technologies in Architectural Engineering and Urban Planning of Iran, Tehran,* https://civilica.com/doc/1237776 *[In Persian]*
23- *B. Johnson et al., "Support Vector Machines in Energy Load Classification," *Energy Systems*, vol. 8, no. 2, pp. 123-135, 2022.*
24- *Emami, M. Modelling and Prediction of Coarse Grained Alluvium Behavior by Pressuremeter Test Results and Laboratory Chamber. Doctoral Dissertation, Tarbiat Modares University, Tehran, Iran, 2014.*
25- *Bekkelien, A., Deriaz, M., & Marchand-Maillet, S. (2012). Bluetooth indoor positioning. Master's thesis, University of Geneva.*
26- *A. Smith, "Deep Learning for Energy Consumption Forecasting in Smart Buildings," *Journal of Building Energy Management*, vol. 12, no. 3, pp. 45-60, 2023.*
27- *C. Lee, "ANFIS-Based Modeling for HVAC Optimization," *International Journal of Fuzzy Systems*, vol. 15, no. 4, pp. 210-225, 2021 .*
28- *Alsaqabi, Y., Almhafdy, A., Haider, H., Ghaffarianhoseini, A., Ghaffarianhoseini, A., & Ali, A. A. M. (2023). Techno-Environmental Assessment of Insulation Materials in Saudi Arabia: Integrating Thermal Performance and LCA. Buildings, 13(2), 331.*
29- *Emami, M.; Yasrobi, S.S. Modeling and interpretation of pressuremeter test results with artificial neural networks. Geotech. Geol. Eng. 2014, 32, 375–389.*
30- *Andersen, K., & Forr, T. (2018). The State of Construction Technology. Jones Lang LaSalle IP.*
31- *Emami Korendeh, M.; Nourbakhsh, S.N. Optimization of Steel Structure Weight Using Artificial Neural Network Method. New Approaches Civ. Eng. 2020, 4, 63–77.*
32- *Azevedo, M. A. (2019). Investor momentum builds for construction tech. Crunchbase News, San Francisco, CA.*
33- *Emami, M.; Yasrobi, S.S. Modelling of pressuremeter tests with artifitial neural networks. Sharif J. Civ. Eng. 2012, 2, 25–36.*
34- *Belsky, M., Sacks, R., & Brilakis, I. (2016). Semantic enrichment for building information modeling. Computer-Aided Civil and Infrastructure Engineering, 31(4), 261-274.*
35- *Yasrebi, S.S.; Emami, M. Application of Artificial Neural Networks (ANNs) in prediction and interpretation of pressuremeter test results. In Proceedings of the 12th International Conference of International Association for Computer Methods and Advances in Geomechanics (IACMAG), Goa, India, 1–6 October 2008; pp. 1634–1638.*
36- *Blanco, J. L., Mullin, A., Pandya, K., & Sridhar, M. (2017). The new age of engineering and construction technology. McKinsey & Company-Capital Projects & Infrastructure.*
37- *Chi, D., Zhang, Y., Wang, X., & Li, X. (2024). Performance analysis of automated shading systems*

*in office buildings under different control strategies. Energy and Buildings, 297, 113129. https://doi.org/10.1016/j.enbuild.2024.113129.*

38- *Alahakoon, S., Yu, H., & Yu, Y. (2022). A hybrid deep learning model for short-term electricity load forecasting: Combining LSTM and XGBoost. Energy Informatics, 5(1), 10. https://doi.org/10.1186/s42162-022-00212-9.*

39- *Kazemi Naeini, H., et al. (2025). PINN-DT: Optimizing Energy Consumption in Smart Building Using Hybrid Physics-Informed Neural Networks and Digital Twin Framework with Blockchain Security. arXiv preprint arXiv:2503.00331.*

40- *Li, Y., et al. (2025). Three-State Thermochromic Smart Window for Building Energy Efficiency. Advanced Science, 12(5), 24016688. https://doi.org/10.1002/advs.202416688 .*