پیش‌بینی بار گرمایشی–سرمایشی ساختمان‌های مسکونی مبتنی بر ویژگی‌های هندسی: از رگرسیون خطی تا یادگیری گروهی

محمد صالحی

کارشناسی ارشد، دانشکده مهندسی صنایع،دانشگاه صنعتی خواجه نصیرالدین طوسی،تهران،ایران

mohammad.salehi1@email.kntu.ac.ir

ناصر صفایی[1]

استادیار، ، دانشکده مهندسی صنایع، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

nsafaie@kntu.ac.ir

چکیده

بهینه‌سازی مصرف انرژی در ساختمان‌ها، به‌عنوان یکی از الزامات توسعه پایدار، مستلزم پیش‌بینی دقیق بارهای گرمایشی و سرمایشی برای طراحی و بهره‌برداری بهینه از سامانه‌های انرژی است. در این پژوهش، با هدف پیش‌بینی و مقایسه عملکرد مدل‌های مختلف در برآورد بار گرمایشی- سرمایشی ، از مجموعه‌داده‌ای شامل ۷۶۸ ساختمان استفاده شد. پس از پیش‌پردازش و تحلیل آماری داده‌ها، مدل‌های مختلف پیش‌بینی توسعه یافته و عملکرد آن‌ها بر اساس شاخص‌های ارزیابی متداول مقایسه شد. نتایج نشان داد که مدل پیشنهادی درخت‌محور XGBoost با دستیابی به ضریب تعیین ۰.۹۹۸۸ برای بار گرمایشی و ۰.۹۹۴۱ برای بار سرمایشی، بالاترین دقت پیش‌بینی را در میان مدل‌های بررسی‌شده ارائه می‌دهد. همچنین، این نتایج نشان‌دهنده توانایی بالای روش‌های یادگیری ماشین در استخراج روابط پیچیده میان ویژگی‌های ساختمان و بار انرژی و قابلیت استفاده از آن‌ها به‌عنوان ابزاری مؤثر برای پشتیبانی از تصمیم‌گیری و بهبود بهره‌وری انرژی ساختمان‌ها است.

کلمات کلیدی: پیش‌بینی بار گرمایشی، پیش‌بینی بار سرمایشی، یادگیری ماشین، XGBoost، توسعه پایدار

[1] نویسنده مسئول

Prediction of Residential Building Heating and Cooling Loads Based on Geometric Features: From Linear Regression to Ensemble Learning

Mohammad Salehi, mohammad.salehi1@email.kntu.ac.ir

Master's degree, Faculty of Industrial Engineering, Khajeh Nasiruddin Toosi University, Tehran, Iran

Nasser Safaie (corresponding author**),** nsafaie@kntu.ac.ir

Assistant Professor, Faculty of Engineering Industries, Khajeh Nasiruddin Toosi University, Tehran, Iran

Abstract

Optimizing energy consumption in buildings, as one of the requirements of sustainable development, requires accurate prediction of heating and cooling loads for the optimal design and operation of energy systems. In this study, with the aim of predicting and comprehensively comparing the performance of different modeling approaches in estimating heating and cooling loads, a dataset of 768 residential buildings with eight geometric and physical properties as input variables and heating and cooling loads as output variables was used. Prior to modeling, the dataset underwent descriptive and exploratory statistical analysis, outlier detection, correlation analysis, and feature selection to identify the most influential predictors and to address multicollinearity among input variables. Six modeling approaches spanning three distinct learning paradigms were then developed and systematically compared: multiple linear regression, decision tree, Random Forest, extreme gradient boosting (XGBoost), support vector regression (SVR), and an artificial neural network whose architecture and hyperparameters were tuned through Bayesian optimization rather than manual trial-and-error. All models were trained and evaluated under an identical train-test protocol, and their performance was assessed using six complementary metrics, including the coefficient of determination, root mean squared error, mean absolute error, mean absolute percentage error, and information criteria. The results showed that the tree-based XGBoost model achieved the highest prediction accuracy among all models studied, with a coefficient of determination of 0.9988 for heating load and 0.9941 for cooling load, followed closely by SVR and the Bayesian-optimized neural network, while linear regression, as the only parametric model, exhibited comparatively lower out-of-sample accuracy. Feature importance analysis, cross-validated across four independent algorithms, consistently identified overall height, relative compactness, and roof area as the dominant predictors of both loads. Additionally, residual analysis revealed a systematic increase in prediction error at peak-load conditions across all six models. These findings demonstrate the strong capability of machine learning methods, particularly ensemble and Bayesian-tuned approaches, to capture the complex relationships between building characteristics and energy loads, supporting their use as reliable decision-support tools for energy-efficient building design.

Keywords: Heating load prediction, cooling load prediction, machine learning, XGBoost, sustainable development

۱- مقدمه

افزایش مستمر مصرف انرژی ساختمان‌ها در سراسر جهان، همراه با تأثیرات محیطی و اقتصادی آن، توجه پژوهشگران و طراحان را به بهره‌وری انرژی ساختمان‌هاجلب کرده است. به ویژه، سیستم‌های گرمایش، تهویه و تهویه مطبوع HVAC[1] سهم عمده‌ای از مصرف انرژی ساختمان‌ها را تشکیل می‌دهند[1] و به همین دلیل، کاهش تقاضای انرژی در این بخش‌ها برای کاهش اثرات منفی زیست‌محیطی و بهینه‌سازی هزینه‌ها ضروری است. علاوه بر این، در بسیاری از کشورهای اروپایی، ساختمان‌ها موظف به رعایت حداقل الزامات بهره‌وری انرژی طبق دستورالعمل اروپایی ۹۱/۲۰۰۲ EC/هستند[2]. یکی از کلیدهای طراحی ساختمان‌های کارآمد، پیش‌بینی بارهای گرمایشی[2] و بارهای سرمایشی[3] مورد نیاز است. مطالعات نشان داده‌اند که روش‌های یادگیری ماشین و یادگیری عمیق می‌توانند برای مدل‌سازی روابط پیچیده و غیرخطی موجود در داده‌های بار مورد استفاده قرار گیرند؛ از جمله، استفاده از شبکه‌های عمیق برای پیش‌بینی اوج بار مصرفی خانگی و به‌کارگیری ترکیبی از شبکه عصبی و ماشین بردار پشتیبان برای پیش‌بینی بار کوتاه‌مدت مورد بررسی قرار گرفته است[3,4]. این پارامترها تعیین می‌کنند که سیستم‌های HVAC چه ظرفیت‌هایی نیاز دارند تا شرایط آسایش حرارتی در داخل ساختمان حفظ شود. بار حرارتی و برودتی ساختمان می‌تواند با روابط استاندارد انتقال حرارت و انرژی بیان شود. به عنوان مثال، انتقال حرارت از طریق پوسته ساختمان[5] با فرمول (۱) بیان می‌شود:

$$Q = U.A.\Delta T \qquad (1)$$

در این معادله، Q نشان‌دهنده مقدار انتقال حرارت است که می‌تواند بر حسب وات (W) یا کیلووات‌ساعت (kWh) بیان شود، U ضریب انتقال حرارت اجزای ساختمان(W/m^2K) است که نشان‌دهنده میزان هدایت حرارتی مصالح ساختمان می‌باشد، A مساحت سطح مورد نظر (m^2) و ΔT اختلاف دمای داخل و خارج ساختمان (°C) است. این رابطه پایه‌ای نقش مهمی در پیش‌بینی بارهای گرمایشی و سرمایشی ساختمان‌ها دارد و معیاری کلیدی برای طراحی سیستم‌های HVAC فراهم می‌کند. برای محاسبه بار سرمایشی ساختمان، علاوه بر انتقال حرارت از طریق دیوارها و سقف، باید اثرات گرمای تابشی خورشید که از طریق پنجره‌ها وارد می‌شود و همچنین بار داخلی ناشی از حضور افراد و تجهیزات داخل ساختمان نیز در نظر گرفته شود. این عوامل مجموعاً تعیین‌کننده مقدار انرژی سرمایشی مورد نیاز برای حفظ شرایط آسایش حرارتی در فضای داخلی هستند و پیش‌بینی دقیق آن‌ها برای طراحی بهینه سیستم‌های HVAC ضروری است. مقدار بار سرمایشی کل ساختمان (CL) [6] را می‌توان با فرمول (۲) بیان کرد:

$$CL = Q_{Conduction} + Q_{Solar} + Q_{Internal} \qquad (2)$$

که در آن $Q_{conduction}$ انتقال حرارت از طریق دیوارها و سقف، Q_{solar} بار ناشی از تابش خورشید و $Q_{internal}$ بار ناشی از حضور افراد و تجهیزات داخل ساختمان است. این رابطه نشان می‌دهد که بار سرمایشی ساختمان تنها به انتقال حرارت از طریق پوسته محدود نمی‌شود، بلکه باید تأثیر تابش خورشیدی و منابع داخلی حرارت نیز به دقت در محاسبات لحاظ شود تا سیستم‌های سرمایشی بهینه و کارآمد طراحی شوند. برای طراحی ساختمان‌های کارآمد از نظر انرژی، پیش‌بینی بار گرمایشی و بار سرمایشی مورد نیاز ضروری است. ابزارهای شبیه‌سازی انرژی ساختمان به طور گسترده برای پیش‌بینی مصرف انرژی و بررسی اثرات طراحی استفاده می‌شوند[8][7] اما استفاده از آن‌ها به دلیل پیچیدگی، نیاز به تخصص و زمان‌بر بودن محدودیت دارد. به منظور غلبه بر این محدودیت‌ها، تکنیک‌های یادگیری ماشین (ML)به طور فزاینده‌ای برای پیش‌بینی HL و CL مورد استفاده قرار گرفته‌اند. این روش‌ها امکان تحلیل سریع اثرات تغییر پارامترهای ساختمان را فراهم می‌کنند و می‌توانند روابط کمی بین متغیرهای طراحی و بارهای انرژی را استخراج کنند[2,7].

با وجود نقش حیاتی سیستم‌های HVAC در تأمین آسایش حرارتی، افزایش مصرف انرژی در ساختمان‌ها چالش‌های قابل‌توجهی را از منظر اقتصادی و زیست‌محیطی پدید آورده است. در حالی که مدل‌های شبیه‌سازی انرژی مانند EnergyPlus[4] و TRNSYS[5] برای تحلیل بارهای حرارتی و برودتی ابزارهای قدرتمندی هستند، پیچیدگی‌های محاسباتی، نیاز به داده‌های گسترده و زمان‌بر بودن فرایند شبیه‌سازی، استفاده از آن‌ها را در مراحل اولیه طراحی محدود می‌سازد. از این رو، پژوهش‌های اخیر به سمت استفاده از روش‌های داده‌محور و تکنیک‌های یادگیری ماشین (ML) حرکت کرده‌اند تا توانایی پیش‌بینی بارهای گرمایشی و سرمایشی را در زمان کمتر و با صرف هزینه کمتر فراهم کنند[8,9].

با وجود پیشرفت‌های اخیر در به‌کارگیری تکنیک‌های داده‌محور برای پیش‌بینی پارامترهای انرژی ساختمان، ادبیات پژوهش موجود همچنان با شکاف مشخصی در زمینه ارائه یک رویکرد جامع و یکپارچه برای ارزیابی و پیش‌بینی همزمان بارهای گرمایشی و سرمایشی با استفاده از طیف متنوعی از الگوریتم‌های هوشمند مواجه است. در پاسخ

[1] Heating, ventilation, and air conditioning
[2] Heating Load (HL)
[3] Cooling Load (CL)
[4] Energyplus, Version 9.5, U.S. Department of Energy, Building Technologies Office, USA
[5] Transient System Simulation program

به این چالش، هدف اصلی این مطالعه پیش‌بینی دقیق بارهای گرمایشی و سرمایشی، تحلیل رفتار الگوریتم‌ها و ارائه رویکردی پویا جهت سنجش دقیق خطای مدل‌هاست که بدین منظور، روش‌شناسی پژوهش بر پایه پیاده‌سازی ۶ مدل یادگیری ماشین (شامل رگرسیون خطی، درخت تصمیم، جنگل تصادفی، ماشین بردار پشتیبان، شبکه عصبی مصنوعی و XGBoost) به صورت مجزا برای هر دو بار انرژی استوار شده است. نوآوری‌های اصلی این مقاله در تدوین یک چارچوب مقایسه‌ای چهارگانه از سه پارادایم متفاوت مدل‌سازی بر پایه پروتکل ارزیابی کاملاً هم‌مقیاس، ارزیابی هم‌زمان هر دو بار حرارتی، ارائه شواهد کمّی مبنی بر نقش تعیین‌کننده روش نظام‌مند تنظیم ابرپارامترها (و نه صرفاً معماری شبکه) در دقت شبکه عصبی، و نیز کشف الگوی سیستماتیک رشد خطا در بارهای اوج مصرف نهفته است؛ امری که در نهایت خروجی مورد انتظاری شامل یک ابزار تصمیم‌یار هوشمند و قابلیت اتکای بالا برای ارتقای دقت طراحی سیستم‌های تهویه مطبوع و بهینه‌سازی مصرف انرژی ساختمان فراهم می‌سازد.

۱-۱ نوآوری پژوهش

نوآوری اصلی این پژوهش در ارائه یک چارچوب جامع و یکپارچه برای پیش‌بینی هم‌زمان بارهای گرمایشی و سرمایشی ساختمان نهفته است که در آن شش مدل از رویکردهای متفاوت یادگیری و مدل‌سازی آماری شامل رگرسیون خطی چندگانه، درخت تصمیم، جنگل تصادفی (Random Forest)، ماشین بردار پشتیبان (SVR)، شبکه عصبی مصنوعی (ANN) و XGBoost، تحت یک پروتکل یکسان توسعه، تنظیم و مقایسه شده‌اند. در کنار این مقایسه گسترده، شناسایی داده‌های پرت با استفاده از آزمون آماری گرابز و سطح معناداری ۰.۰۵، جایگزینی تنظیم آزمون‌وخطایی ابرپارامترها با بهینه‌سازی نظام‌مند و مبتنی بر بهینه‌سازی بیزی، و ارائه شواهد کمّی از اثر این بهبود روش‌شناختی بر دقت پیش‌بینی، از دیگر جنبه‌های متمایز پژوهش است. همچنین، برخلاف بسیاری از مطالعات پیشین، خطای پیش‌بینی نه‌تنها در سطح کلی مدل‌ها، بلکه به تفکیک فرم‌های هندسی و جهت‌گیری ساختمان تحلیل شده و تحلیل باقیمانده برای هر شش مدل به‌صورت مقایسه‌ای انجام گرفته است؛ به‌گونه‌ای که الگوی افزایش خطا در بارهای اوج به‌عنوان یک ویژگی مشترک میان مدل‌های مختلف شناسایی شده است. مجموعه این اقدامات، پژوهش حاضر را از یک مقایسه صرف میان الگوریتم‌های پیش‌بینی فراتر برده و امکان ارزیابی جامع دقت، پایداری و رفتار خطای مدل‌ها را در شرایط مختلف هندسی ساختمان فراهم می‌کند.

۲- مروری بر پژوهش های مرتبط

پژوهش‌های پیشین در زمینه تخمین بارهای حرارتی و برودتی ساختمان، طیف متنوعی از الگوریتم‌های آماری، هوش مصنوعی و یادگیری عمیق را به کار گرفته‌اند؛ با این حال، مرور تحلیلی ادبیات موجود، محدودیت‌های ساختاری و روش‌شناختی مشخصی را نمایان می‌سازد. در حوزه مدل‌های پایه و مرورهای بالادستی،Yin و همکاران به بررسی جامع شبکه‌های عصبی مصنوعی (ANN) پرداختند؛ اما مطالعه آن‌ها صرفاً ماهیت کیفی داشته و فاقد ارزیابی کمّی متقاطع با الگوریتم‌های نوظهور نظیر روش‌های درخت‌محور است. در سوی دیگر،Sholahudin با تلفیق ANN و طرح آزمایش‌ها (DOE)، اثر متغیرهای هندسی را بر بارهای گرمایشی (HL) و سرمایشی (CL) ایزوله کردند؛ اما به دلیل اتکای منحصربه‌فرد به یک الگوریتم و عدم ارائه تحلیل باقیمانده، امکان سنجش تعمیم‌پذیری مدل‌ها را فراهم نساختند. همچنین، مطالعاتی همچون Alkhalaf و Yan با بکارگیری داده‌های عملیاتی، مدل‌های رگرسیون و شبکه عصبی را مقایسه کردند، اما عدم تفکیک بارهای گرمایشی و سرمایشی و بی‌توجهی به روش‌های یادگیری گروهی (Ensemble Learning) از نقاط ضعف آن‌ها به شمار می‌رود.[10,11,12]

در جبهه پیشرفت‌های الگوریتمی، Kumar و همکاران مدل Extreme Learning Machine (ELM) را برای پیش‌بینی بارهای حرارتی معرفی کردند که اگرچه سرعت محاسباتی بالایی داشت، اما به دلیل عدم مقایسه با الگوریتم‌های درخت‌محور و رگرسیون کلاسیک، ارزیابی جامعی از زیان‌های تفسیرپذیری ارائه نداد. Moayedi و همکاران با مقایسه شش الگوریتم (از جمله جنگل تصادفی)، ارزیابی متعددی بر پایه شاخص‌های خطا ارائه دادند، اما تمرکز انحصاری آن‌ها بر بار گرمایشی و عدم بهره‌گیری از الگوریتم‌های پیشرفته‌ای چون XGBoost، ارزیابی بار سرمایشی را مغفول گذاشت. در حوزه یادگیری عمیق، Sajjad و همکاران یک معماری چندخروجی بر پایه GRU توسعه دادند که بارهای HL و CL را هم‌زمان تخمین می‌زد؛ با این وجود، فقدان خط‌بصیرت (Baseline) مقایسه‌ای با مدل‌های ساده‌تر، اثبات کارایی این معماری پیچیده را با چالش مواجه کرده است. نهایتاً مطالعات اخیر مانند Morcillo-Jiménez و همکاران و Roshan Joshua و Shiva بر پیش‌بینی سری‌های زمانی عملیاتی تمرکز کرده‌اند که اگرچه برای فاز بهره‌برداری مفیدند، اما به دلیل ماهیت داده‌های حسگری و عدم تعمیم‌پذیری، توانایی پاسخ‌گویی به نیازهای تصمیم‌گیری در فاز «طراحی اولیه ساختمان» را ندارند.[13,14,15,16,17]

جدول ۱. مرور ادبیات

Ref	Year	Inputs	Outputs	Models	Key Strengths	Limitations and Research Gaps
[12]	2024	Shape coefficient, U-value, window-to-floor ratio, climatic parameters	HL	ANN	Systematic review and comprehensive classification of ANN applications across different building stages.	Lack of experimental validation and real-world data; no investigation of advanced tree-based algorithms (RF/XGBoost).
[13]	2016	Environmental parameters, wall/roof area, glazing ratio, orientation	HL/CL	ANN	Use of Design of Experiments (DOE) and ANOVA to assess the effects of design variables.	Single-model approach (ANN only); limited transparency in hyperparameter tuning and lack of residual analysis.
[14]	2017	Building type, window-to-wall ratio, presence of carpet, orientation	CL	Linear Regression, ANN	Use of a real-world building energy consumption database from Japan (DECC).	Limited to residential buildings; no separate analysis of HL and CL; no comparison with ensemble learning methods.
[15]	2018	Geometric and structural parameters, surface areas, glazing ratio	HL/CL	ELM	Application of the Extreme Learning Machine (ELM) algorithm with high training speed.	Focus on a single model (ELM); no comparison with classical regression or tree-based models.
[16]	2019	Area, wall length, rooftop area	HL	6 algorithms (including RF)	Comprehensive evaluation using five different error metrics across multiple models.	No investigation of cooling load (CL); absence of XGBoost; limited systematic hyperparameter evaluation and use of less diverse performance indicators.
[17]	2020	Geometric features, climatic parameters, glazing ratio	HL/CL	Deep Learning (GRU)	Implementation of a multi-output model for simultaneous prediction of HL and CL.	No comparison with baseline or ensemble algorithms; lack of interpretability analysis for variable importance.
[19]	2024	Metering and sensor data from an office building	HL	MLP, CNN, LSTM	Use of real sensor data collected under actual operational conditions.	Limited data volume; focus on operational time-series data rather than early-stage building design.
[18]	2025	Energy consumption and electrical load data from a laboratory	HL	LSTM	Analysis of load-pattern mapping in a real laboratory environment.	Highly limited application scope (electrical laboratory only); no comparable multi-model evaluation framework.
This study	—	8 geometric and early-stage building design features	HL/CL	Linear Regression, DT, RF, SVR, ANN (Bayesian), XGBoost	Simultaneous evaluation of HL and CL using six complementary models, a unified comparative framework, Bayesian hyperparameter optimization, and analysis of peak-load error patterns.	Design-stage prediction based on balanced simulated data.

با جمع‌بندی ادبیات موجود در جدول ۱، سه شکاف تحقیقاتی عمده شناسایی می‌شود: نخست، فقدان چارچوب‌های مقایسه‌ای متوازن که هم‌زمان هر دو بار گرمایشی و سرمایشی را با طیف کاملی از پارادایم‌های خطی، درخت‌محور و شبکه‌های عصبی بررسی کنند؛ دوم، عدم ارزیابی کمّی نقش «تنظیم نظام‌مند ابرپارامترها» در برابر معماری مدل‌ها؛ و سوم، مغفول ماندن تحلیل الگوی رشد خطا در بارهای اوج مصرف (Peak Loads). پژوهش حاضر با هدف پر کردن این شکاف‌ها، یک پروتکل ارزیابی یکسان ۶ مدلی را برای هر دو بار حرارتی و برودتی تدوین نموده است.

۳- روش جمع آوری داده ها

در این مطالعه، به منظور تولید مجموعه داده مورد نیاز، از یک مکعب پایه با ابعاد ۳،۵ × ۳،۵ × ۳،۵ متر به عنوان عنصر اولیه استفاده شد. بر اساس این مکعب اولیه، دوازده فرم ساختمانی مختلف ایجاد گردید که هر فرم ساختمانی از ۱۸ المان (مکعب پایه) تشکیل شده است. تمامی مدل‌های ساختمانی با استفاده از نرم‌افزار Ecotect[1]

[1] Autodesk Ecotect Analysis 2011 – version 5.60

شبیه‌سازی شدند. تمامی ساختمان‌ها دارای حجم یکسان برابر با ۷۷۱٫۷۵ مترمکعب هستند، با این تفاوت که از نظر سطح پوسته خارجی و ابعاد هندسی با یکدیگر متفاوت می‌باشند. مصالح به‌کاررفته در هر یک از ۱۸ المان ساختمانی برای تمامی فرم‌ها یکسان در نظر گرفته شد. انتخاب مصالح بر اساس جدیدترین و متداول‌ترین مواد مورد استفاده در صنعت ساختمان، و با تأکید بر کمترین مقدار ضریب انتقال حرارت (U-value) انجام شد. مشخصات حرارتی اجزای ساختمان به شرح زیر است (مقادیر U بر حسب وات بر مترمربع کلوین در پرانتز آمده‌اند: دیوارها (۱٫۷۸۰)، کف‌ها (۰٫۸۶۰)، سقف‌ها (۰٫۵۰۰) و پنجره‌ها (۲٫۲۶۰). فرض شد که ساختمان‌ها در شهر تهران، ایران واقع شده‌اند و کاربری آن‌ها مسکونی است. تعداد ساکنان هر ساختمان برابر با هفت نفر با سطح فعالیت نشسته (مصرف متابولیک ۷۰ وات) در نظر گرفته شد. شرایط طراحی داخلی به صورت زیر تنظیم گردید: پوشش لباس ۰٫۶ clo، رطوبت نسبی ۶۰ درصد، سرعت هوا ۰٫۳۰ متر بر ثانیه و سطح روشنایی ۳۰۰ لوکس.

بارهای داخلی ساختمان شامل بار محسوس برابر با ۵ وات بر مترمربع و بار نهان برابر با ۲ وات بر مترمربع در نظر گرفته شد. نرخ نفوذ هوا[1] برابر با ۰٫۵ تعویض هوا در ساعت، با حساسیت به باد برابر با ۰٫۲۵ تعویض هوا در ساعت لحاظ گردید. برای ویژگی‌های حرارتی سیستم، حالت عملکرد ترکیبی[2] با راندمان ۹۵ درصد در نظر گرفته شد. دامنه عملکرد ترموستات بین ۱۹ تا ۲۴ درجه سانتی‌گراد تنظیم گردید و ساعات بهره‌برداری سیستم به صورت ۱۵ تا ۲۰ ساعت در روزهای کاری و ۱۰ تا ۲۰ ساعت در روزهای تعطیل تعریف شد. سه نسبت مختلف سطح شیشه‌خور به مساحت کف ساختمان در این مطالعه بررسی شد که به ترتیب برابر با ۱۰ درصد، ۲۵ درصد و ۴۰ درصد می‌باشند. برای هر یک از این نسبت‌ها، پنج سناریوی مختلف توزیع سطح شیشه شبیه‌سازی گردید: توزیع یکنواخت: ۲۵ درصد شیشه در هر ضلع، تمرکز در شمال: ۵۵ درصد در ضلع شمالی و ۱۵ درصد در سایر اضلاع، تمرکز در شرق: ۵۵ درصد در ضلع شرقی و ۱۵ درصد در سایر اضلاع، تمرکز در جنوب: ۵۵ درصد در ضلع جنوبی و ۱۵ درصد در سایر اضلاع، تمرکز در غرب: ۵۵ درصد در ضلع غربی و ۱۵ درصد در سایر اضلاع.

علاوه بر این، نمونه‌هایی بدون سطح شیشه نیز مورد بررسی قرار گرفتند. تمامی فرم‌های ساختمانی همچنین نسبت به چهار جهت اصلی جغرافیایی (شمال، جنوب، شرق و غرب) چرخانده شدند. با در نظر گرفتن دوازده فرم ساختمانی، سه نسبت سطح شیشه، پنج سناریوی توزیع شیشه و چهار جهت‌گیری مختلف، در مجموع طبق رابطه (3) خواهد بود:

$$4\times5\times3\times12=720 \qquad (3)$$

نمونه ساختمانی تولید شد. علاوه بر این، دوازده فرم ساختمانی بدون شیشه برای چهار جهت‌گیری مختلف نیز شبیه‌سازی گردید که ۴۸ نمونه دیگر را شامل می‌شود. بنابراین، در مجموع ۷۶۸ ساختمان در این مطالعه مورد بررسی قرار گرفت.

برای آموزش و ارزیابی مدل‌ها، مجموعه داده‌های ۷۶۸ ساختمان شبیه‌سازی‌شده به دو زیرمجموعه آموزش و تست تقسیم شدند. به منظور حفظ تنوع و پوشش تمام ویژگی‌های مهم ساختمان‌ها، تقسیم‌بندی به صورت Stratified Split[3] انجام شد، به طوری که هر فرم ساختمان (۱۲ فرم مختلف) و هر نسبت سطح شیشه (۱۰٪، ۲۵٪ و ۴۰٪) در هر دو مجموعه آموزش و تست حضور داشت. نسبت اختصاص داده شده به مجموعه آموزش برابر با ۸۰٪ و به مجموعه تست ۲۰٪ بود. برای اطمینان از تعمیم‌پذیری مدل و کاهش خطای ناشی از انتخاب تصادفی نمونه‌ها، بر روی داده‌های آموزش کراس‌ولیدیشن[4] ۵ تایی انجام این رویکرد اطمینان می‌دهد که مدل‌ها نه تنها با داده‌های آموزش سازگار باشند، بلکه توانایی پیش‌بینی بارهای گرمایشی و سرمایشی ساختمان‌ها را در شرایط مختلف با دقت بالا داشته باشند.

هر یک از این ساختمان ها با استفاده از هشت پارامتر ساختمانی توصیف شد که در این پژوهش به عنوان متغیرهای ورودی شناخته شده و با نماد X نمایش داده می‌شوند. همچنین، برای هر ساختمان دو متغیر خروجی شامل بار گرمایشی و بار سرمایشی استخراج گردید که با نماد y نشان داده می‌شوند. جدول ۲ خلاصه‌ای از متغیرهای ورودی و خروجی، نمایش ریاضی هر متغیر و تعداد مقادیر ممکن آن‌ها و جدول ۳ نمونه ای از داده ها را ارائه می‌دهند. نتایج حاصل از شبیه‌سازی می‌توانند تصویر مناسبی از روند تغییرات و درصد تغییرات داده‌های واقعی ارائه دهند و امکان مقایسه انرژی ساختمان‌ها را فراهم سازند. از این رو، داده‌های شبیه‌سازی‌شده در این مطالعه، با احتمال بالایی نمایانگر رفتار واقعی سیستم بوده و به عنوان داده‌های مرجع[5] در نظر گرفته شده‌اند[20][2][6].

[1] Infiltration
[2] Mixed Mode
[3] تقسیم داده‌ها به آموزش و آزمون به‌گونه‌ای که توزیع مقادیر هدف در هر مجموعه حفظ شود
[4] K-Fold Cross-Validation
[5] Ground Truth

جدول ۲. نمایش ریاضی متغیرهای ورودی و خروجی

Variable	Mathematical Representation	Number of Possible Values
Relative compactness	RC	12
Surface area	SA	12
Wall area	WA	7
Roof area	RA	4
Overall height	OH	2
Orientation	ON	4
Glazing area	GA	4
Glazing area distribution	GD	6
Heating load	HL	586
Cooling load	CL	636

جدول ۳. نمونه ای از داده ها

Number	CL	HL	GD	GA	ON	OH	RA	WA	SA	RC
۱	24.91	24.03	1	0.1	3	7	147	318.5	612.5	0.82
۲	26.13	24.13	2	0.1	4	7	110.25	294	514.5	0.98
۳	14.37	12.85	4	0.1	2	3.5	220.5	367.5	808.5	0.62
۴	15.78	12.72	1	0.25	5	3.5	220.5	294	735	0.69
۵	37.41	40.19	2	0.25	3	7	147	343	637	0.79
۶	16.43	14.54	2	0.4	2	3.5	220.5	245	686	0.74

٤- روش پژوهش

چارچوب روش‌شناسی پژوهش حاضر به‌منظور تحلیل، ارزیابی مقایسه‌ای و پیش‌بینی دقیق بارهای گرمایشی و سرمایشی ساختمان در قالب یک پروتکل نظام‌مند پنج‌مرحله‌ای تدوین شده است. در گام نخست، اقدامات مرتبط با پیش‌پردازش داده‌ها، شامل مقیاس‌سازی (Normalization) متغیرهای هندسی و ساختاری، پالایش داده‌ها و پروتکل تقسیم‌بندی آن‌ها به مجموعه‌های آموزش و آزمون تشریح می‌گردد. در گام دوم، مدل‌سازی پایه بر مبنای رگرسیون خطی متعدد جهت سنجش روابط خطی حاکم بر بارهای انرژی معرفی می‌شود. گام سوم به توسعه الگوریتم‌های مبتنی بر درخت و یادگیری گروهی، شامل درخت تصمیم (DT)، جنگل تصادفی (RF) و الگوریتم افزایش گرادیان متقاطع (XGBoost) اختصاص یافته است تا توانایی این الگوریتم‌ها در مواجهه با عدم‌قطعیت‌های پیچیده سنجیده شود. در گام چهارم، مدل‌های غیرخطی شامل ماشین بردار پشتیبان (SVR) و شبکه عصبی مصنوعی با بهینه‌سازی بیزی ابرپارامتر (Bayesian Regularization ANN) جهت استخراج الگوهای عمیق و غیرخطی تبیین می‌گردند. در نهایت، در گام پنجم، الگوریتم نظام‌مند تنظیم ابرپارامترها و معیارهای ارزیابی عملکرد مدل‌ها تعریف شده و چارچوب سنجش توانایی تعمیم‌پذیری و تحلیل الگوی خطای آن‌ها در بارهای اوج مصرف ارائه می‌شود.

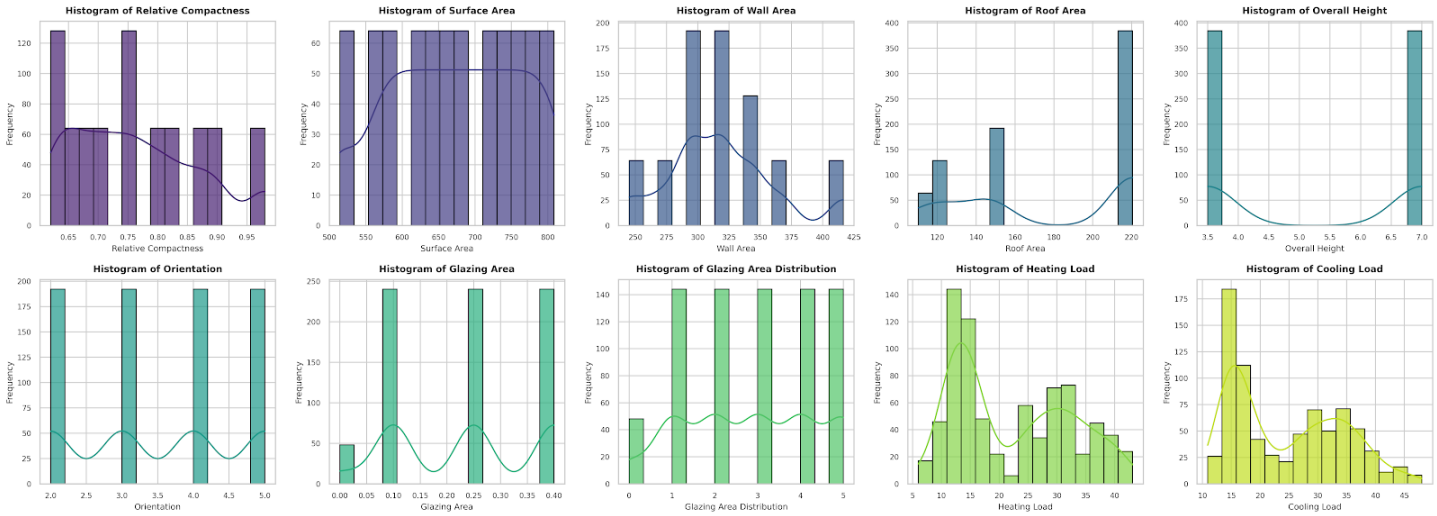
۴-۱ پیش پردازش داده ها

پیش از مدل‌سازی، تحلیل توصیفی و اکتشافی داده‌ها (EDA) با استفاده از نرم‌افزار Minitab[۱] انجام شد تا ساختار توزیعی متغیرها، وجود داده‌های پرت، و الگوی روابط میان ویژگی‌های ورودی و بارهای انرژی پیش از انتخاب رویکرد مدل‌سازی مشخص شود. شکل ۱ توزیع فراوانی هر یک از هشت متغیر ورودی و دو متغیر خروجی را نشان می‌دهد؛ نتایج حاکی از ناهمگنی ساختاری میان متغیرهاست: برخی ویژگی‌های هندسی توزیع پیوسته و نسبتاً متقارن دارند، در حالی‌که برخی دیگر به دلیل ماهیت گسسته سناریوهای شبیه‌سازی، الگوی چندقله‌ای یا محدود به سطوح مشخص نشان می‌دهند؛ متغیرهای خروجی (HL و CL) نیز چولگی و انحراف محسوسی از نرمالیتی دارند، که به‌طور اولیه بر ضرورت به‌کارگیری رویکردهای غیرخطی در کنار مدل‌های پارامتریک خطی دلالت می‌کند. شکل ۲ نمودار جعبه‌ای دامنه تغییرات و پراکندگی هر متغیر را به‌طور مقایسه‌ای نمایش می‌دهد و

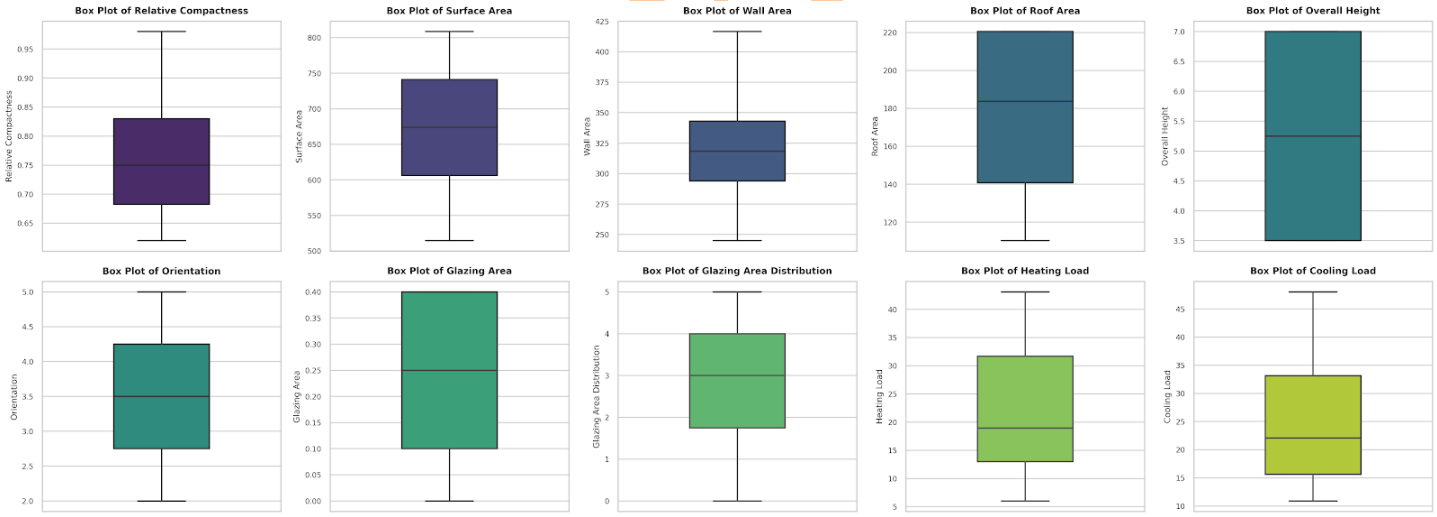
[۱] Minitab Statistical Software (نسخه ۲۲.۵.۲)

مبنای بصری برای شناسایی داده‌های پرت پیش از اجرای آزمون رسمی گرابز (بخش بعد) فراهم می‌کند.

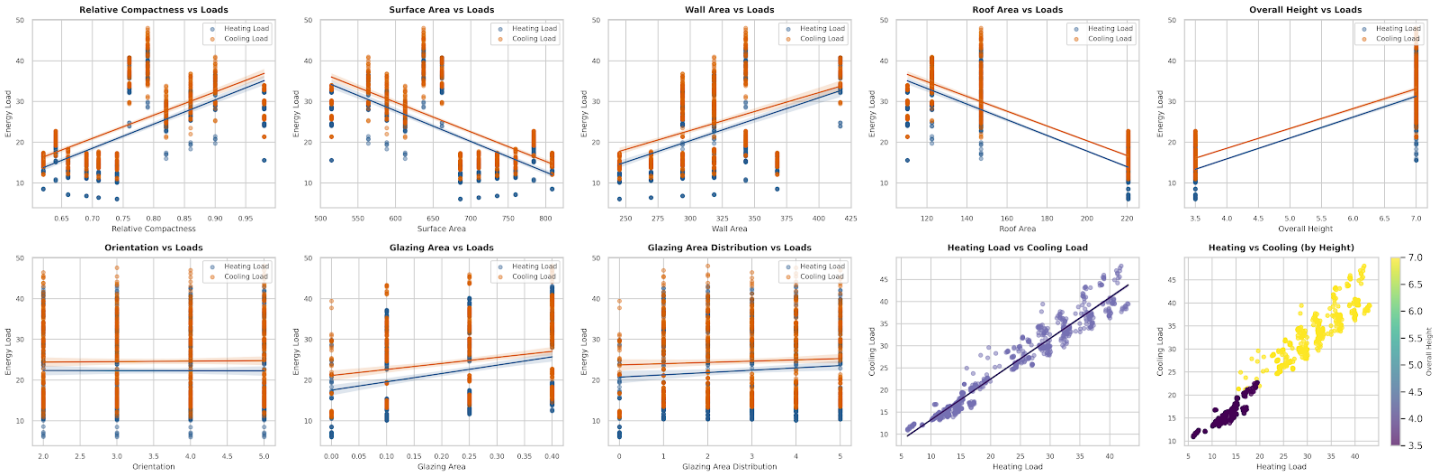
برای بررسی نوع و جهت روابط دوبه‌دو، شکل ۳ نمودارهای پراکندگی هر متغیر ورودی در برابر HL و CL را به‌همراه خط برازش رگرسیونی ارائه می‌دهد؛ این نمایش امکان تشخیص بصری خطی یا غیرخطی بودن رابطه، و نیز شناسایی الگوهای ناهمسانی واریانس (Heteroscedasticity) را در سطح هر متغیر مهیا می‌سازد. در تکمیل این تحلیل، شکل ۴ ماتریس همبستگی اسپیرمن ، که به دلیل استقلال از فرض نرمال‌بودن داده، معیار مناسب‌تری نسبت به همبستگی پیرسون برای این مجموعه‌داده است ، را میان تمامی متغیرهای ورودی و خروجی نمایش می‌دهد. نتایج این ماتریس، به‌طور هم‌زمان دو نکته کلیدی را برای مراحل بعدی پژوهش روشن می‌سازد: نخست، رتبه‌بندی نسبی شدت اثر متغیرهای ورودی بر بارهای انرژی که مبنای انتخاب ویژگی در مدل رگرسیونی قرار می‌گیرد؛ و دوم، وجود همبستگی بسیار بالا میان برخی جفت متغیرهای ورودی که ضرورت بررسی هم‌خطی چندگانه (Multicollinearity) پیش از مدل‌سازی پارامتریک را روشن می‌کند، موضوعی که در ادامه همین بخش با محاسبه ضریب تورم واریانس (VIF) پیگیری می‌شود.



شکل ۱. نمودار توزیع فراوانی (هیستوگرام)

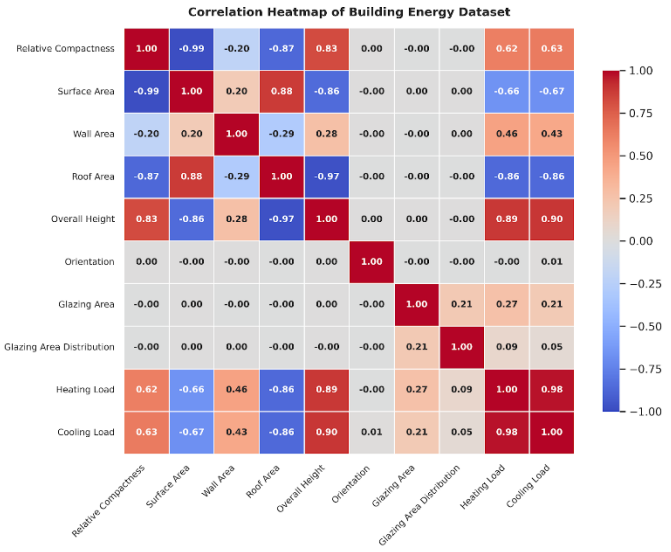


شکل ۲. نمودار جعبه ای (Box plot)



شکل ۳. نمودار پراکندگی به همراه خط رگرسیونی

داده‌های گمشده، مقادیر پرت و خطاهای احتمالی شناسایی و اصلاح شده و ویژگی‌های غیرضروری حذف می‌شوند. همچنین، مقیاس‌دهی و استانداردسازی متغیرها ـ به‌ویژه در حضور تفاوت مقیاس بین ویژگی‌ها ـ انجام می‌گیرد تا عملکرد مدل بهبود یابد. از دیگر اقدامات مهم در این بخش می‌توان به بررسی توزیع داده‌ها، اعمال تبدیل‌های مناسب در صورت نیاز به نرمال‌سازی، و شناسایی همبستگی‌های بالا بین متغیرهای ورودی به‌منظور کاهش خطر هم‌خطی (Multicollinearity) در مدل‌های رگرسیونی مطابق جدول ۳ اشاره کرد. برای شناسایی و حذف داده‌های پرت از آزمون گرابز (Grubbs' Test) استفاده شد .در این پژوهش، پس از محاسبه آماره آزمون و مقایسه آن با مقدار بحرانی در سطح معناداری مشخص، داده‌های پرت شناسایی و در صورت لزوم حذف شدند. فرمول‌های مورد استفاده در ادامه ارائه شده و نتایج حاصل از اجرای آزمون در شکل ۵ نمایش داده شده است.



شکل ۴. ماتریس همبستگی (اسپیرمن)

جدول ۳. مراحل پیش پردازش داده ها

Stage	Description	Objective
Data Collection	Importing data from Excel	Preparing the initial dataset for analysis
Missing Data Detection	Identifying missing values	Preventing bias and reducing model errors
Missing Data Handling	Managing missing values using methods such as mean imputation or other imputation techniques	Ensuring data completeness and reliability
Outlier Detection	Identifying and removing outliers	Detecting observations outside the expected range and improving model accuracy and stability
Categorical Data Encoding	Converting categorical variables into numerical representations using methods such as One-Hot Encoding or Label Encoding	Preparing the data for numerical algorithms
Data Type Checking	Verifying data types and converting them when necessary	Preventing data-processing errors

Stage	Description	Objective
Scaling and Standardization	Applying methods such as Min-Max Scaling or Z-Score Standardization	Placing features on comparable scales and improving model performance
Correlation Analysis	Calculating the correlation matrix and identifying highly correlated variables	Reducing multicollinearity
Feature Selection	Applying feature selection methods	Improving model accuracy and reducing model complexity
Train–Test Split	Dividing the dataset into training and testing sets	Providing an unbiased evaluation of model performance
Linear Relationship Analysis	Evaluating linear relationships between input features and target variables	Supporting appropriate model selection and better interpretation of relationships

۴-۲ آزمون گرابز

در ابتدای هر آزمون آماری، فرضیات صفر و یک تعریف می‌شوند. در این آزمون، فرضیه صفر (H_0)بیانگر عدم وجود داده پرت در مجموعه مشاهدات است ("داده پرت وجود ندارد"). در مقابل، فرضیه یک (H_1) بیان می‌کند که حداقل یک داده پرت در میان مشاهدات وجود دارد ("حداقل یک داده پرت وجود دارد"). هدف آزمون، جمع‌آوری شواهد آماری برای رد یا عدم رد فرضیه صفر است.

برای سنجش میزان "پرت بودن" داده‌ها، از آماره آزمون گرابز(G) استفاده می‌شود. این آماره با استفاده از میانگین نمونه، بزرگترین مشاهده در نمونه و انحراف معیار نمونه محاسبه می‌گردد. فرمول ارائه شده برای آماره آزمون به شرح فرمول (۴) است:

$$G = \frac{\left|\bar{X} + \max X_i\right|}{s} \qquad (4)$$

$\bar{X}$: میانگین نمونه، X_i: مشاهدات داده ای، s انحراف معیار نمونه ها را نشان میدهد،پیش از محاسبه آماره آزمون نیاز به محاسبه میانگین و انحراف معیار نمونه است.

میانگین نمونه این مقدار از طریق جمع کردن تمام مشاهدات و تقسیم آن بر تعداد کل مشاهدات از طریق فرمول (۵) به دست می‌آید.

$$\bar{X} = X_i \sum_{i=1}^{n} \frac{1}{n} \qquad (5)$$

انحراف معیار نمونه این شاخص میزان پراکندگی داده‌ها را اندازه‌گیری می‌کند و از طریق فرمول (۶) محاسبه می‌شود :

$$s = \sqrt{\frac{\sum_{i=1}^{n}\left(\bar{X} - X_i\right)}{n-1}} \qquad (6)$$

برای تصمیم‌گیری در مورد رد یا عدم رد فرضیه صفر، آماره آزمون با یک مقدار بحرانی[۱] مقایسه می‌شود. این مقدار بحرانی بر اساس سطح معناداری آزمون (α) و ویژگی‌های آماری توزیع داده‌ها تعیین می‌گردد. فرمول (۷) مقدار بحرانی است.

$$G_{\text{critical}} = \sqrt{\frac{\frac{\alpha^2}{t_{(2n),n-2}}}{n-2+\frac{\alpha^2}{t_{(2n),n-2}}}} \times \frac{n-1}{\sqrt{n}} \qquad (7)$$

α سطح معناداری آزمون است که شما آن را برابر با 0/05 در نظر گرفته‌اید. این مقدار، حداکثر احتمال پذیرفته شده برای خطای نوع اول را مشخص می‌کند. $t_{(2n),n-2}$ به مقداری از توزیع t-student اشاره دارد. درجه آزادی این توزیع $n-2$ است. بخش $t_{(2n)}$ کمی غیرمعمول به نظر می‌رسد؛ در آزمون‌های استاندارد گرابز، شاخص مربوط به معمولاً به سطح معناداری (α) و حجم نمونه n مرتبط فرمول دقیق مقدار بحرانی برای آزمون گرابز معمولاً متفاوت است.

قاعده تصمیم گیری

مرحله نهایی در آزمون گرابز، مقایسه آماره آزمون محاسبه شده با مقدار بحرانی طبق عبارت ۸ است:

$$G_{\text{critical}} < G \qquad (8)$$

آنگاه فرض صفر رد شده و داده مورد نظر به عنوان داده پرت معنادار شناسایی می‌شود.

[۱] Critical

طبق نتایج آزمون گرابز (Grubbs' Test) برای شناسایی داده‌های پرت در مجموعه داده‌ها، هیچ یک از متغیرها در سطح معنی‌داری ۵٪ ($\alpha = 0/05$) داده پرت محسوب نمی‌شوند. در این آزمون، فرضیه صفر بیان می‌کند که تمامی مقادیر از یک جمعیت نرمال واحد نشأت گرفته‌اند و فرضیه جایگزین ادعا می‌کند که کوچک‌ترین یا بزرگ‌ترین مقدار یک متغیر ممکن است داده پرت باشد. با توجه به اینکه مقدار P برای تمامی متغیرها برابر با ۱۰۰٪ (یا بسیار نزدیک به آن) است، می‌توان نتیجه گرفت که هیچ یک از داده‌ها از نظر آماری به عنوان داده پرت شناسایی نمی‌شوند. بنابراین، در سطح ۵٪، داده‌های پرت در این مجموعه داده وجود ندارند. نتایج آزمون برای هر متغیر در شکل ۵ نمایش داده شده است.

Method

Null Hypothesis	All data values come from the same normal population
Alternative Hypothesis	Smallest or largest data value is an outlier
Significance level	$\alpha = 0.05$

Grubbs' Test

Variable	N	Mean	StDev	Min	Max	G	P
Relative_Compactness	768	0.76417	0.10578	0.62000	0.98000	2.04	1.000
Surface_Area	768	671.71	88.69	514.50	808.50	1.78	1.000
Wall_Area	768	318.50	43.63	245.00	416.50	2.25	1.000
Roof_Area	768	176.60	45.17	110.25	220.50	1.47	1.000
Overall_Height	768	7.5600	1.7511	3.5000	7.0000	1.00	1.000
Orientation	768	3.5000	1.1188	2.0000	5.0000	1.34	1.000
Glazing_Area	768	0.43488	0.18372	0.00000	0.66600	1.76	1.000
Glazing_Area_Distribution	768	2.8125	1.5570	0.0000	5.0000	1.81	1.000
Heating_Load	768	22.307	10.090	6.010	43.100	2.06	1.000
Cooling_Load	768	24.558	9.513	10.900	48.030	2.46	1.000

* NOTE * No outlier at the 5% level of significance

شکل ۵. شناسایی داده های پرت

در فرآیند توسعه مدل‌های آماری، به‌ویژه رگرسیون خطی، هم‌مقیاس بودن متغیرهای ورودی از اهمیت بالایی برخوردار است؛ زیرا تفاوت زیاد در بازه عددی ویژگی‌ها می‌تواند منجر به برآورد ناپایدار ضرایب و وزن‌دهی ناعادلانه به متغیرهای با دامنه بزرگ‌تر شود[21]. با توجه به وجود متغیرهایی با مقیاس‌های متفاوت و توزیع‌های غیرنرمال در این پژوهش، روش استانداردسازی (Standardization) انتخاب شد. در این روش، هر ویژگی با استفاده از تبدیل Z-Score به‌گونه‌ای بازمقیاس می‌شود که میانگین آن صفر و انحراف معیار آن برابر یک گردد. آماره‌های توصیفی متغیرهای نرمال‌شده در جدول ۴ نشان می‌دهد که داده‌ها به‌طور متقارن حول صفر توزیع شده‌اند و پراکندگی آن‌ها در یک بازه قابل مقایسه قرار گرفته است. این موضوع بیانگر موفقیت فرآیند مقیاس‌دهی و فراهم شدن شرایط مناسب برای برازش دقیق‌تر مدل رگرسیون خطی است.

جدول ۴. بررسی آماری متغیرهای پیوسته بعد استانداردسازی

Variable	Minimum	First Quartile (Q1)	Median	Third Quartile (Q3)
RC	-1.3629	-0.9139	-0.1339	0.8115
SA	-1.7847	-0.8808	0.0232	0.9271
WA	-1.6848	-0.5616	0.0000	0.5616
RA	-1.4691	-1.0623	0.1582	0.9719
OH	-0.9993	-0.9993	0.0000	0.9993
GA	-1.7593	-1.0087	0.1173	1.2432

از استانداردسازی به روش Z-Score استفاده شد. در این روش، برای هر مقدار از یک متغیر، فاصله آن تا میانگین محاسبه شده و بر انحراف معیار آن متغیر تقسیم می‌شود. فرمول (۹) نشان دهنده این موضوع است:

$$Z = \frac{X - X^*}{\delta} \qquad (9)$$

X: مقدار واقعی، X^*: مقدار میانگین، δ: انحراف معیار در این رابطه برقرار است.

در مرحله انتخاب ویژگی‌ها، به‌منظور ارزیابی میزان ارتباط متغیرهای ورودی با بارهای گرمایشی (HL) و سرمایشی (CL)، از ضریب همبستگی رتبه‌ای اسپیرمن استفاده شد؛ زیرا داده‌ها نرمال نبودند و این شاخص توانایی سنجش روابط یکنواخت را دارد. نتایج جدول ۵ نشان می‌دهد که از نظر شدت همبستگی با متغیرهای هدف، ارتفاع کل با ضریب ۰.۸۶ در رتبه اول قرار دارد. پس از آن، مساحت سقف با ضریب حدود ۰.۸۰- در رتبه دوم، فشردگی نسبی و مساحت سطح با ضرایب حدود ۰.۶۲ تا ۰.۶۵- در رتبه‌های بعدی، و مساحت دیوار با همبستگی متوسط (حدود ۰.۴۲–۰.۴۷) در رتبه بعد قرار می‌گیرند. در مراتب پایین‌تر، مساحت شیشه با همبستگی ضعیف‌تر قرار دارد که با وجود شدت کمتر، به دلیل اهمیت مهندسی حفظ شد.

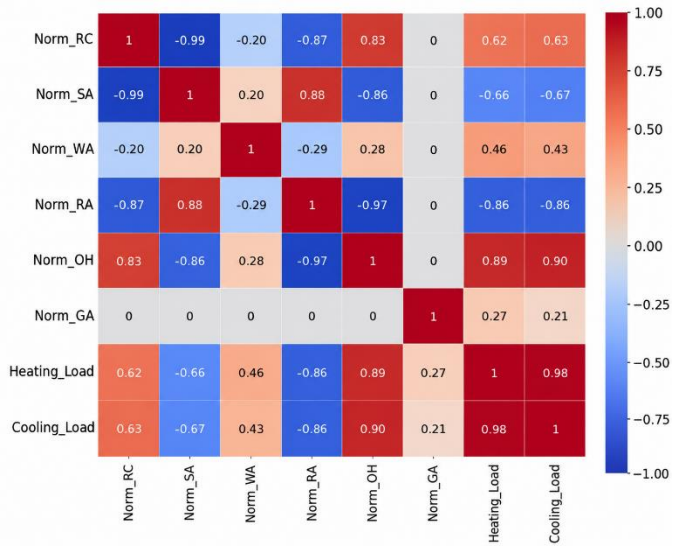
جدول ۵. بررسی همبستگی متغیر ها با HL و CL (داده های غیرنرمال)

Variable	Correlation with HL	Correlation with CL
X1	0.62	0.65
X2	−0.62	−0.65
X3	0.47	0.42
X4	−0.80	−0.80
X5	0.86	0.86
X6	≈ 0	≈ 0
X7	0.32	0.29
X8	0.07	0.05

جدول ۶. بررسی همبستگی متغیر ها با HL و CL (داده های نرمال)

Variable	Correlation with HL	Correlation with CL
X1	0.622	0.634
X2	−0.658	−0.673
X3	0.456	0.427
X4	−0.862	−0.863
X5	0.889	0.896
X6	0.270	0.208

همان‌گونه که در جدول ۶ و شکل ۶ مشاهده می‌شود، متغیر ارتفاع کل (Overall Height) بالاترین همبستگی مثبت را با هر دو متغیر خروجی دارد و به‌عنوان مهم‌ترین عامل پیش‌بینی در مدل شناخته می‌شود. همچنین مساحت سقف (Roof Area) همبستگی منفی قوی با بارهای گرمایشی (HL) و سرمایشی (CL) دارد و در مدل حفظ شد. از سوی دیگر، همان‌طور که در شکل ۶ (سطر Norm_RC، ستون Norm_SA) قابل مشاهده است، مساحت سطح و فشردگی نسبی همبستگی بسیار بالایی با یکدیگر دارند (r=−۰.۹۹۲). برخلاف بسیاری از موارد هم‌خطی در داده‌های مهندسی که پدیده‌ای صرفاً تجربی و آماری‌اند، این همبستگی در اینجا ریشه در یک هم‌ارزی هندسی دقیق دارد: فشردگی نسبی از رابطه تعریف می‌شود و چون حجم تمامی فرم‌های ساختمانی این پژوهش ثابت است (V=۷۷۱.۷۵ متر مکعب)، فشردگی نسبی عملاً تبدیلی مستقیم و تعیین‌کننده از مساحت سطح است، نه یک ویژگی فیزیکی مستقل از آن. بر همین اساس، به‌جای حذف صرفاً بر مبنای ضریب همبستگی آماری، حفظ تنها یکی از این دو متغیر، در این پژوهش فشردگی نسبی، به دلیل توزیع متقارن‌تر و فقدان داده پرت، یک ضرورت هندسی-ریاضی است که از مسئله عدم‌یکتایی (Non-identifiability) در ماتریس طراحی مدل رگرسیونی جلوگیری می‌کند. اگرچه متغیرهای جهت‌گیری (Orientation) و توزیع مساحت شیشه (Glazing Area Distribution) در تحلیل همبستگی داده‌های نرمال نقش برجسته‌ای نداشتند، اما با توجه به ماهیت گسسته آن‌ها، اثرشان از طریق آزمون‌های رگرسیونی و تحلیل واریانس مورد بررسی قرار گرفت. در صورت عدم معناداری آماری (p-value<۰.۰۵)، این متغیرها از مدل نهایی حذف خواهند شد.



شکل ۶- نمودار همبستگی نرمالایزشده

۳-۴ مدل رگرسیون خطی چندگانه

رگرسیون خطی چندگانه یکی از بنیادی‌ترین و در عین حال تفسیرپذیرترین روش‌های مدل‌سازی آماری برای پیش‌بینی یک متغیر وابسته بر اساس چندین متغیر مستقل است. [22][23] در این پژوهش، به‌منظور پیش‌بینی بار گرمایشی (HL) و بار سرمایشی (CL) ساختمان‌ها بر اساس ویژگی‌های هندسی و فیزیکی، دو مدل رگرسیون خطی چندگانه مستقل توسعه داده شد. انتخاب این رویکرد با توجه به سادگی، قابلیت تفسیر مستقیم ضرایب و امکان سنجش شدت و جهت اثر هر متغیر صورت گرفت. پس از پیش‌پردازش، نرمال‌سازی Z-score متغیرهای پیوسته، کدگذاری متغیرهای طبقه‌ای، و انتخاب ویژگی‌های مؤثر (بخش قبل)، مدل‌سازی با روش Stepwise Regression در نرم‌افزار Minitab بر روی ۶۹۶ مشاهده انجام و مدل نهایی طبق فرمول‌های (۱۰) و (۱۱) انتخاب شد. لازم به ذکر است معیارهای برازش گزارش‌شده در این بخش (R^2، S) بر مبنای برازش درون‌نمونه محاسبه شده‌اند؛ برای مقایسه کاملاً منصفانه و برون‌نمونه با سایر رویکردهای این پژوهش (شبکه عصبی، Random Forest، XGBoost، SVR، درخت تصمیم)، هر دو مدل رگرسیون علاوه بر این، با پروتکل یکسان ۸۰٪ آموزش/۲۰٪ آزمون نیز مجدداً ارزیابی شدند؛ نتایج تطبیقی هر دو رویکرد در جدول X (بخش نتایج) گزارش می‌شود.

فرضیات کلاسیک رگرسیون برای هر دو متغیر هدف بررسی شد. برای بار گرمایشی شکل ۷، باقی‌مانده‌ها به‌صورت تصادفی و متقارن حول صفر پراکنده‌اند و الگوی غیرخطی مشاهده نمی‌شود؛ فرض خطی‌بودن رابطه بین متغیرهای مستقل (Norm_WA، Norm_GA، Norm_RA، Glazing_Area_Distribution) و متغیر وابسته تأیید می‌شود. برای بار سرمایشی شکل ۸، انحنای بسیار ملایمی در

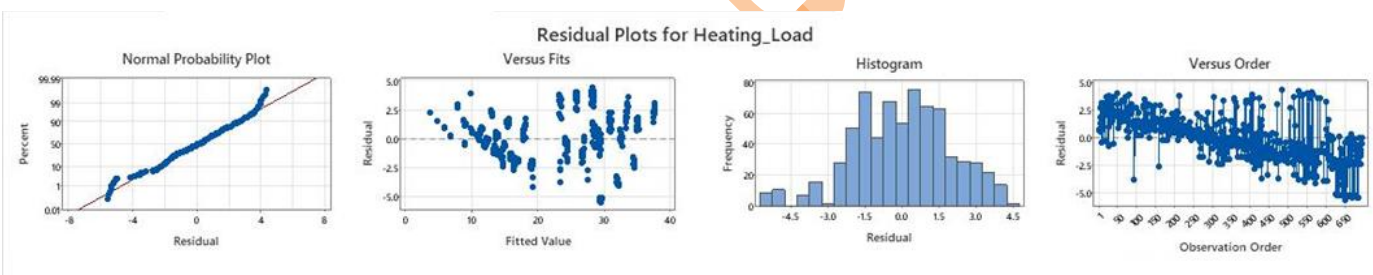
باقی‌مانده‌ها دیده می‌شود که با توجه به ضریب تعیین بالای مدل، قابل‌اغماض و ناقض فرض خطی‌بودن به‌طور کلی نیست.

بررسی شاخص VIF برای هر دو مدل، مقادیر پایین (حداکثر ۴.۱۷ برای HL؛ حداکثر ۱.۰۸ برای CL، هر دو به‌مراتب کمتر از آستانه بحرانی ۱۰) را تأیید کرد[23]. گفتنی است متغیر پرخطرتر از منظر هم‌خطی (مساحت سطح) پیش‌تر، بر مبنای همارزی هندسی توضیح‌داده‌شده در بخش قبل (نه صرفاً معیار آماری)، از مدل حذف شده بود؛ بنابراین این مقادیر پایین VIF، تأییدی بر اثربخشی آن تصمیم‌اند، نه یافته‌ای مستقل. نرمال‌بودن باقی‌مانده‌ها (نمودار احتمال نرمال و هیستوگرام) برای هر دو مدل تقریباً برقرار است؛ انحراف جزئی در دم‌ها با توجه به حجم نمونه نسبتاً بزرگ (n=۶۹۶) قابل‌قبول است (چولگی خفیف به راست برای CL). همگنی واریانس نیز در هر دو مدل با پراکندگی یکنواخت باقی‌مانده‌ها در برابر مقادیر برازش‌شده تأیید شد (S=۲.۰۱۹ برای HL؛ S=۲.۴۷۹ برای CL). روند نزولی خفیفی در نمودار Residuals vs Observation Order در هر دو مدل مشاهده شد که با توجه به ماهیت شبیه‌سازی‌شده و غیرزمانی داده، نشانه نقض جدی استقلال خطاها نیست. بررسی نقاط پرت نشان داد در هر دو مدل، تعداد محدودی باقی‌مانده استانداردشده بزرگ‌تر از ۲± وجود دارد که هیچ‌کدام از ۳± فراتر نرفته و کمتر از ۵٪ داده‌ها را شامل می‌شوند؛ بنابراین نقطه پرت بحرانی در هیچ‌یک از دو مدل مشاهده نشد[20,22,23,24].

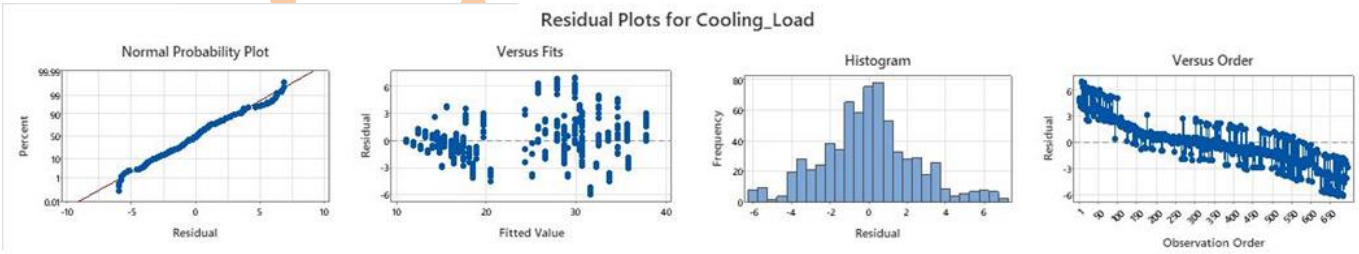
با توجه به تحلیل ضرایب، شاخص‌های برازش، آزمون‌های معنی‌داری و بررسی کامل فروض کلاسیک برای هر دو متغیر هدف، جمع‌بندی مقایسه‌ای عملکرد مدل‌ها، شامل R^2، S، وضعیت VIF، نرمال‌بودن باقی‌مانده‌ها، همگنی واریانس و نقاط پرت، در قالب جدول ۷ ارائه شده است

$$Heating\ Load = 18/17 + 1/8237\,Norm_{WA} + 2/2096\,Norm_{GA} - 7/6080\,Norm_{RA} \quad (10)$$

$$Cooling\ Load = 23/6855 + 1/4088\,Norm_{WA} + 1/8465\,Norm_{GA} - 7/2234\,Norm_{RA} \quad (11)$$



شکل ۷- نمودارهای تحلیل خطا و باقیمانده مدل پیش‌بینی بار گرمایشی



شکل ۸- نمودارهای تحلیل خطا و باقیمانده مدل پیش‌بینی بار سرمایشی

جدول ۷. نتایج نهایی مدل‌های رگرسیون خطی

Feature / Metric	Heating Load (HL)	Cooling Load (CL)
Coefficient of Determination (R^2)	95.17%	91.48%
Adjusted R^2	95.11%	91.45%
Predicted R^2	95.03%	91.38%
MSE	4.023	6.111
RMSE	2.006	2.472
Residual Standard Deviation (S)	2.019	2.479

MAE	1.609	1.88
MAPE	8.31%	8.34%
AIC	986.92	1267.85
BIC	1027.83	1286.03
Model Significance (p-value)	0	0
Significance of All Parameters ($p < 0.05$)	Yes	Yes
Variance Inflation Factor (VIF)	Maximum = 4.17 (Acceptable)	Maximum = 1.08 (Excellent)
Residual Normality	Approximately satisfied	Approximately satisfied
Homoscedasticity	Acceptable	Acceptable
Error Independence	Reasonable and acceptable	Reasonable and acceptable

انحراف معیار باقی‌مانده‌ها (S) توسط Minitab با مخرج درجه آزادی (n−k) محاسبه می‌شود، در حالی‌که RMSE با مخرج n محاسبه شده است؛ اختلاف جزئی این دو مقدار (۲.۰۱۹ در برابر ۲.۰۰۶ برای HL) ناشی از همین تفاوت تعریف است، نه خطای محاسباتی. AIC/BIC با تعداد پارامتر واقعی مدل (k=۹ برای HL شامل جمله دسته‌ای توزیع شیشه؛ k=۴ برای CL) و بر مبنای n=۶۹۶ محاسبه شده‌اند.

۴-۴ الگوریتم‌های مبتنی بر درخت و یادگیری گروهی[۱]

به‌منظور ارزیابی رویکردهای غیرپارامتریک مبتنی بر ساختار درختی برای پیش‌بینی HL و CL، سه الگوریتم به‌صورت تدریجی از ساده به پیچیده بررسی شدند: درخت تصمیم منفرد (به‌عنوان خط مبنا)، Random Forest (یادگیری گروهی مبتنی بر Bagging)، و XGBoost (یادگیری گروهی مبتنی بر Boosting). برخلاف مدل رگرسیون خطی، این الگوریتم‌ها نیازی به پیش‌فرض خطی‌بودن رابطه یا نرمال‌سازی ویژگی‌ها ندارند و توانایی ذاتی برای شناسایی برهم‌کنش‌های غیرخطی پیچیده بین متغیرها دارند؛ به همین دلیل، تمام هشت ویژگی ورودی (بدون حذف بر مبنای همبستگی خطی) به این مدل‌ها داده شد. برای اطمینان از سازگاری روش‌شناختی با سایر مدل‌های این پژوهش، هر سه الگوریتم با همان پروتکل تقسیم داده به‌کاررفته در شبکه عصبی (۸۰٪ آموزش / ۲۰٪ آزمون، random_state=۴۲) آموزش و ارزیابی شدند، و تنظیم ابرپارامتر هر سه مدل، به‌جای آزمون‌وخطا با روش نظام‌مند RandomizedSearchCV همراه با اعتبارسنجی متقاطع ۵-تایی روی مجموعه آموزش انجام شد.

۴-۴-۱ درخت تصمیم[۲]

درخت تصمیم به‌عنوان مدل پایه (Baseline) برای سنجش میزان بهبود حاصل از یادگیری گروهی به کار رفت. فضای جست‌وجوی ابرپارامتر شامل عمق درخت (مقادیر ۳، ۴، ۵، ۶، ۸، ۱۰ و بدون محدودیت :max_depth)، حداقل نمونه لازم برای شکافت یک گره (۲ تا ۸:min_samples_split)، و حداقل نمونه در هر برگ (۱ تا ۵:min_samples_leaf) بود، با ۲۵ آزمایش تصادفی. مدل بهینه برای هر دو هدف با عمق (max_depth=۸) به‌دست آمد؛ برای بار گرمایشی min_samples_split=۳ و min_samples_leaf=۲، و برای بار سرمایشی min_samples_split=۳ و min_samples_leaf=۳.

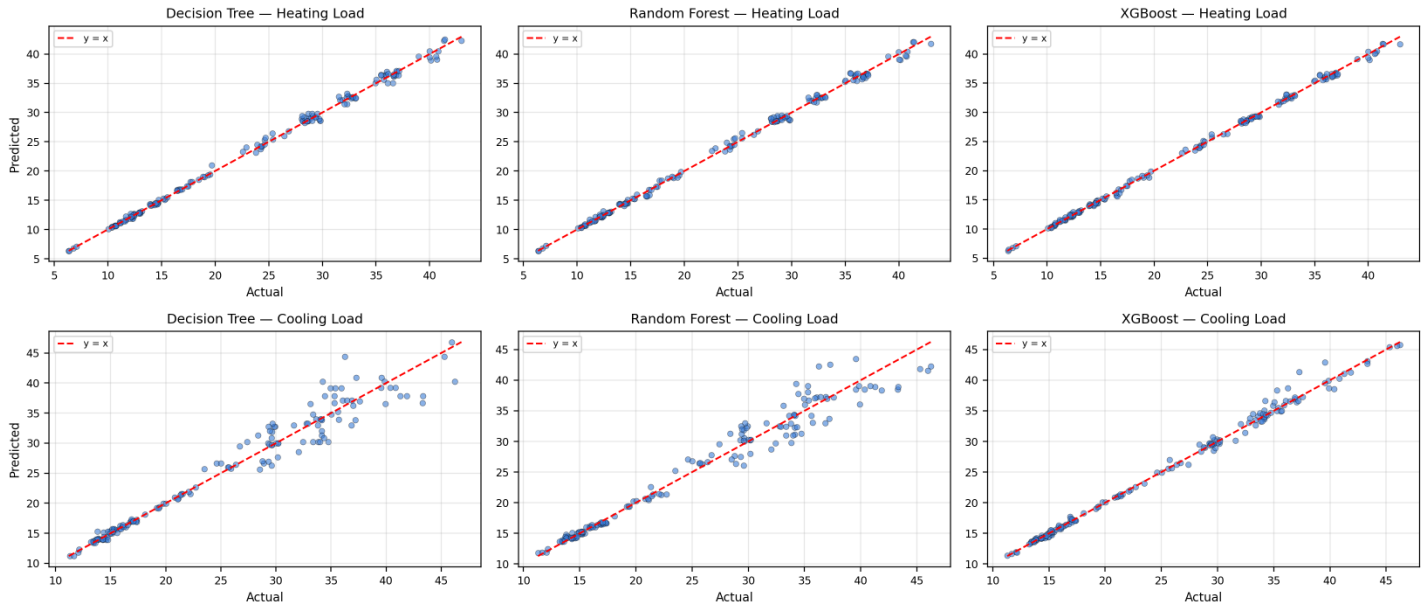
۴-۴-۲ جنگل تصادفی[۳]

Random Forest با میانگین‌گیری از N درخت تصمیم مستقل، هرکدام آموزش‌دیده روی یک زیرنمونه Bootstrap از داده و زیرمجموعه تصادفی از ویژگی‌ها در هر شکافت، واریانس پیش‌بینی را کاهش می‌دهد. فضای جست‌وجو شامل تعداد درخت (۱۵۰ تا ۴۵۰:n_estimators)، عمق (بدون محدودیت تا ۲۰:max_depth)، min_samples_split (۲ تا ۸)، min_samples_leaf (۱ تا ۵)، و نسبت ویژگی‌های نمونه‌برداری‌شده در هر شکافت (max_features: sqrt۲، یا کسری از ۰.۶ تا ۱.۰log) بود، با ۳۰ آزمایش تصادفی. معماری بهینه برای هر دو هدف: n_estimators=۳۵۰،max_depth=۸ با تفاوت در max_features (۰.۸ برای گرمایش، log۲ برای سرمایش) و min_samples_split (۲ برای گرمایش، ۸ برای سرمایش). بهترین RMSE اعتبارسنجی متقاطع: ۰.۵۵ (گرمایش) و ۱.۷۸ (سرمایش).

۴-۴-۳ تقویت گرادیان شدید[۴]

[۱] Tree-based algorithms and ensemble learning
[۲] Decision Tree
[۳] Random Forest
[۴] XGBoost

XGBoost با ساخت متوالی و اصلاحی درخت‌ها (هر درخت جدید خطای باقی‌مانده درخت‌های قبلی را اصلاح می‌کند) و جریمه تنظیم صریح، بایاس مدل را به‌طور نظام‌مند کاهش می‌دهد. فضای جست‌وجو شامل عمق (۳ تا ۸:max_depth)، نرخ یادگیری (learning_rate: ۰.۰۱ تا ۰.۱)، نسبت نمونه‌برداری سطری و ستونی (subsample، colsample_bytree: ۰.۶ تا ۱)، حداقل وزن فرزند (۱ تا ۷:min_child_weight)، و ضرایب تنظیم (reg_alpha ۲/L۱L، reg_lambda)، با ۴۰ آزمایش تصادفی. برای تعیین تعداد بهینه دورهای Boosting به‌صورت داده‌محور (نه به‌صورت ثابت و از پیش‌تعیین‌شده)، از مکانیزم Early Stopping بر مبنای همان ۱۵٪ از داده آموزش که برای اعتبارسنجی داخلی شبکه عصبی نیز استفاده شد (هماهنگی مستقیم با پروتکل بخش ۴.۴) بهره گرفته شد. معماری بهینه: برای بار گرمایشی max_depth=۶، learning_rate=۰.۰۵، subsample=۰.۹، olsample_bytree=۰.۷c، با توقف در دور ۴۵۵ام؛ برای بار سرمایشی max_depth=۵، learning_rate=۰.۱، subsample=۰.۹، colsample_bytree=۱، با توقف در دور ۱۰۶۱ام. بهترین RMSE اعتبارسنجی متقاطع: ۰.۴۱ (گرمایش) و ۱.۰۱ (سرمایش)، پایین‌تر از Random Forest در هر دو هدف، که همسو با نتایج نهایی مجموعه آزمون است. شکل ۹ پراکندگی مقادیر پیش‌بینی‌شده در برابر مقادیر واقعی را برای هر سه مدل درخت تصمیم، جنگل تصادفی و XGBoost نشان می‌دهد؛ نزدیکی نقاط به خط مرجع y=x در هر سه مدل، به‌ویژه برایXGBoost ، برازش دقیق مدل‌ها را به‌صورت بصری تأیید می‌کند. شکل ۱۰ نیز اهمیت نسبی هشت ویژگی ورودی را در هر سه مدل نمایش می‌دهد؛ همان‌طور که مشاهده می‌شود، فشردگی نسبی و ارتفاع کل در اکثر مدل‌ها به‌عنوان مهم‌ترین پیش‌بین‌ها شناسایی شده‌اند.



شکل ۹- نمودارهای پراکندگی مقادیر پیش‌بینی‌شده در برابر واقعی(مدل های درخت تصمیم، جنگل تصادفی، XGBoost)

در ادامه رویکردهای درخت‌محور، دو الگوریتم دیگر با سازوکار یادگیری غیرخطی اساساً متفاوت بررسی شدند: ماشین بردار پشتیبان (SVR) که روابط غیرخطی را از طریق نگاشت ضمنی داده به فضایی با بعد بالاتر (Kernel Trick) مدل می‌کند، و شبکه عصبی مصنوعی که این روابط را از طریق ترکیب لایه‌ای توابع فعال‌سازی غیرخطی یاد می‌گیرد. هر دو مدل، مشابه بخش قبل، با همان پروتکل تقسیم داده) ۸۰٪ آموزش/۲۰٪ آزمون، random_state=۴۲ و با روش نظام‌مند تنظیم ابرپارامتر (به‌جای آزمون‌وخطا) آموزش داده شدند

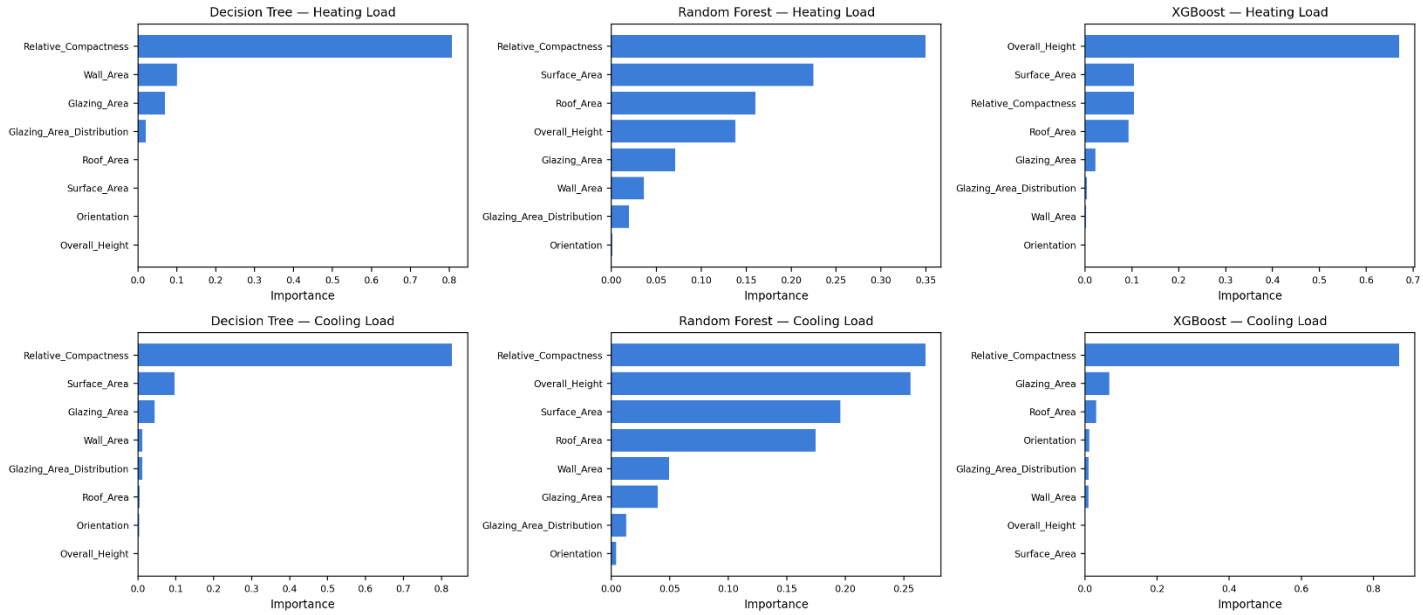
۴-۵ مدل‌های غیرخطی(ماشین بردار پشتیبان[۱] و شبکه عصبی مصنوعی[۲])

۴-۵-۱ ماشین بردار پشتیبان

[۱] Support Vector Regression (SVR)

[۲] Artificial Neural Network (ANN)

از SVR با هسته شعاعی (RBF Kernel) استفاده شد که امکان مدل‌سازی روابط غیرخطی پیچیده بدون فرض شکل تابعی از.



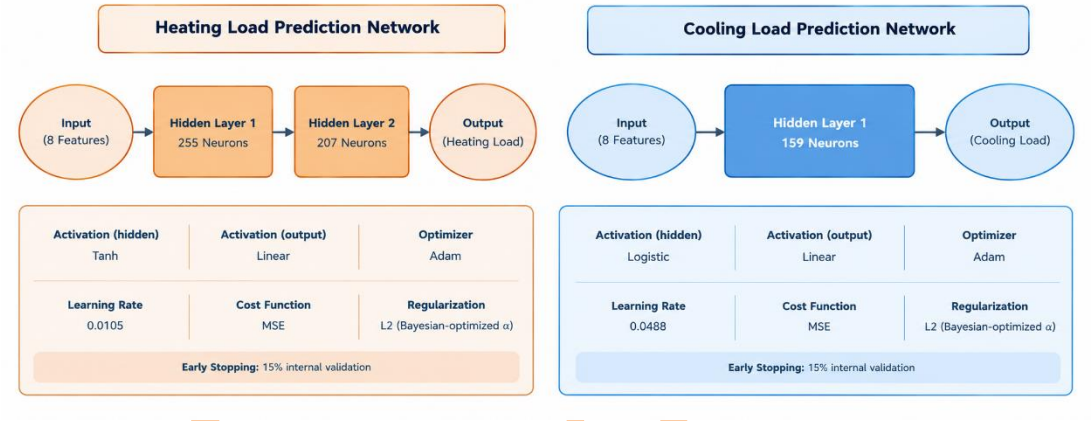
شکل ۱۰- نمودارهای میله‌ای اهمیت ویژگی‌ها(مدل های درخت تصمیم، جنگل تصادفی، XGBoost)

پیش‌تعیین‌شده را فراهم می‌کند. پیش از آموزش، تمامی ویژگی‌های ورودی با StandardScaler (برازش‌شده صرفاً روی داده آموزش) استانداردسازی شدند، چون برخلاف مدل‌های درخت‌محور، SVR به مقیاس ویژگی‌ها حساس است. تنظیم ابرپارامتر با RandomizedSearchCV و اعتبارسنجی متقاطع ۵-تایی روی سه پارامتر کلیدی انجام شد: ضریب جریمه C (۱ تا ۱۰۰۰، مقیاس لگاریتمی)، پهنای حاشیه بی‌تفاوتی epsilon (۰.۰۱ تا ۰.۵)، و ضریب هسته gamma (شامل مقادیر خودکار scale و auto، به‌همراه مقادیر ثابت ۰.۰۱ تا ۰.۱)، با ۳۰ آزمایش تصادفی. معماری بهینه برای بار گرمایشی: C=۵۰۰، epsilon=۰.۰۵، gamma=auto؛ برای بار سرمایشی: C=۵۰۰، epsilon=۰.۰۵، gamma=scale.

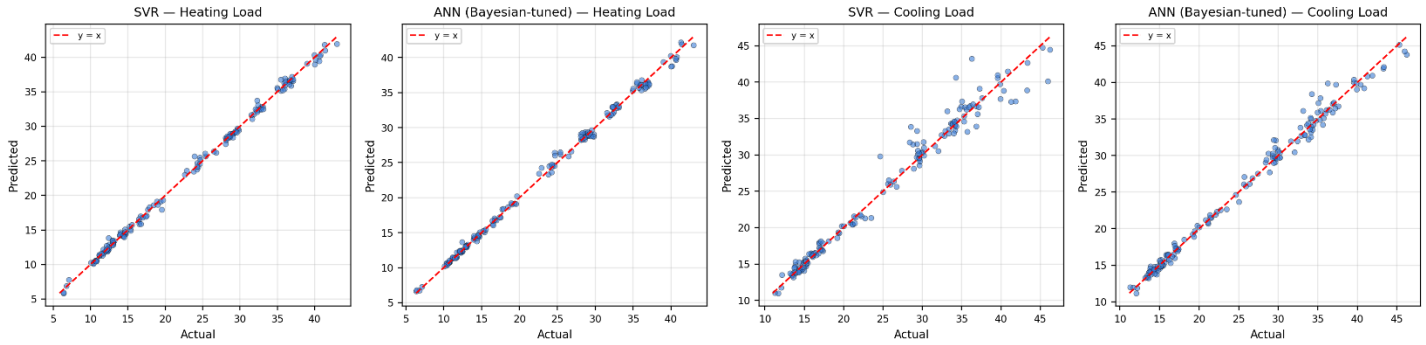
۲-۵-۴ شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی به‌عنوان یکی از روش‌های مؤثر یادگیری ماشین، قابلیت مناسبی برای مدل‌سازی روابط پیچیده و غیرخطی میان متغیرهای ورودی و خروجی دارند. این ویژگی به‌ویژه در مسائل مرتبط با عملکرد انرژی ساختمان اهمیت دارد، زیرا اثر متقابل ویژگی‌های هندسی ساختمان بر بارهای گرمایشی و سرمایشی لزوماً از یک رابطه خطی ساده پیروی نمی‌کند. بر این اساس، در این پژوهش از یک پرسپترون چندلایه (MLP) برای پیش‌بینی بارهای گرمایشی و سرمایشی مطابق شکل ۱۱ استفاده شد. تنظیم ابرپارامترهای شبکه شامل تعداد لایه‌های پنهان، تعداد نورون هر لایه، تابع فعال‌سازی، نرخ یادگیری و ضریب تنظیم L۲ با استفاده از بهینه‌سازی بیزی مبتنی بر الگوریتم TPE انجام گرفت. در این روش، با ایجاد و به‌روزرسانی یک مدل احتمالاتی از رابطه میان ترکیب ابرپارامترها و خطای مدل، آزمایش‌های بعدی به‌صورت هدفمند به سمت نواحی امیدبخش‌تر فضای جست‌وجو هدایت می‌شوند. برای هر هدف، پنج ابرپارامتر به‌طور هم‌زمان شامل تعداد لایه‌های پنهان (۱ تا ۳)، تعداد نورون هر لایه (۱۶ تا ۲۵۶)، تابع فعال‌سازی (ReLU، Tanh یا Logistic)، نرخ یادگیری اولیه ($۱۰^{-۴}$ تا ۵×۱۰^{-۲}) و ضریب تنظیم L۲ در ۵۰ آزمایش و با اعتبارسنجی متقاطع ۳-تایی روی مجموعه آموزش بررسی شدند. همچنین، برای کنترل بیش‌برازش، ۱۵٪ از داده‌های آموزش به‌عنوان مجموعه اعتبارسنجی داخلی اختصاص یافت و مکانیزم توقف زودهنگام (Early Stopping) به کار گرفته شد تا تعداد دوره‌های آموزش بر اساس روند یادگیری مدل و به‌صورت داده‌محور تعیین شود.

بر اساس فرآیند بهینه‌سازی، معماری نهایی مدل بار گرمایشی شامل دو لایه پنهان با ۲۵۵ و ۲۰۷ نورون، تابع فعال‌سازی Tanh و نرخ یادگیری ۰/۰۱۰۵، و معماری مدل بار سرمایشی شامل یک لایه پنهان با ۱۵۹ نورون، تابع فعال‌سازی Logistic و نرخ یادگیری ۰/۰۴۸۸ به دست آمد. این دو مدل در مجموعه آزمون به‌ترتیب به ضریب تعیین ۰/۹۹۷۳ و ۰/۹۹۰۴ دست یافتند. به‌منظور بررسی پایداری عملکرد مدل نسبت به تغییر ابرپارامترها، تحلیل حساسیت مستقلی برای سه عامل کلیدی شامل تابع فعال‌سازی، نرخ یادگیری و تعداد دوره آموزش انجام شد (شکل ۱۱). نتایج این تحلیل نشان داد که در پیش‌بینی بار گرمایشی، توابع ReLU و Tanh عملکردی نزدیک به یکدیگر و بهتر از Logistic دارند، در حالی‌که برای بار سرمایشی عملکرد Logistic برتری نشان می‌دهد. همچنین، نرخ یادگیری در بازه ۰/۰۱ تا ۰/۰۵ کمترین خطا را ایجاد کرده و مقادیر بسیار کوچک آن موجب کاهش محسوس دقت مدل می‌شوند. بررسی منحنی‌های همگرایی، شامل نمودار Loss و امتیاز اعتبارسنجی در طول آموزش، نیز نشان داد که مدل طی حدود ۱۵۰ تا ۲۰۰ دوره به همگرایی می‌رسد و ادامه آموزش پس از این محدوده بهبود محسوسی در دقت پیش‌بینی ایجاد نمی‌کند. شکل ۱۲ پراکندگی مقادیر پیش‌بینی‌شده در برابر مقادیر واقعی را برای هر دو مدل SVR و ANN (تنظیم‌شده با بهینه‌سازی بیزی)، در هر دو هدف، نمایش می‌دهد؛ نزدیکی گسترده نقاط به خط مرجع y=x در هر دو مدل، دقت بالای هر دو رویکرد غیرخطی را تأیید می‌کند، با اندکی پراکندگی بیشتر در بار سرمایشی نسبت به بار گرمایشی.



شکل ۱۱- معماری و تنظیمات بهینه شبکه‌های عصبی مصنوعی برای پیش‌بینی بار گرمایشی و سرمایشی



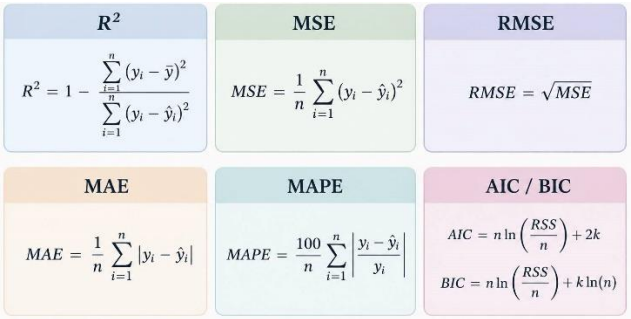
شکل ۱۲- پراکندگی مقادیر پیش‌بینی‌شده در برابر واقعی (ماشین بردار پشتیبان و شبکه عصبی مصنوعی)

۴-۶ چارچوب یکپارچه تنظیم ابرپارامتر، ارزیابی عملکرد

برای تمامی شش مدل این پژوهش، تنظیم ابرپارامتر با یک اصل مشترک صورت گرفت: جایگزینی جست‌وجوی دستی با روش‌های نظام‌مند مبتنی بر اعتبارسنجی متقاطع. برای مدل‌های Random Forest، XGBoost، SVR و درخت تصمیم، از RandomizedSearchCV با اعتبارسنجی متقاطع ۵-تایی روی مجموعه آموزش استفاده شد؛ برای شبکه عصبی، به دلیل فضای پارامتری پیوسته و پرهزینه‌تر بودن هر آزمایش، از بهینه‌سازی بیزی (Optuna/TPE) با اعتبارسنجی متقاطع ۳-تایی بهره گرفته شد. برای مدل‌های با فرآیند آموزش تکرارشونده (XGBoost و شبکه عصبی)، از مکانیزم توقف زودهنگام بر مبنای

۱۵٪ داده آموزش کنارگذاشته‌شده برای اعتبارسنجی داخلی استفاده شد تا تعداد بهینه تکرار آموزش به‌صورت داده‌محور و نه ثابت تعیین شود. تمامی شش مدل با پروتکل تقسیم داده کاملاً یکسان (۸۰٪ آموزش / ۲۰٪ آزمون، با بذر تصادفی ثابت) آموزش و ارزیابی شدند تا مقایسه عملکرد آن‌ها کاملاً منصفانه و قابل‌اتکا باشد.

۱-۶-۴ ارزیابی عملکرد



شکل ۱۳- معیارهای ارزیابی عملکرد

در روابط شکل ۱۳، n حجم مجموعه آزمون، RSS مجموع مربعات باقی‌مانده، و k تعداد پارامترهای مؤثر مدل است. برای رگرسیون خطی و شبکه عصبی، k برابر با تعداد واقعی پارامترهای برازش‌شده مدل در نظر گرفته شد؛ برای مدل‌های درخت‌محور و SVR که تعداد پارامتر رسمی و مشخصی ندارند، k=9 (برابر با تعداد ویژگی‌های ورودی به‌علاوه یک) به‌عنوان قرارداد یکسان برای مقایسه نسبی در نظر گرفته شد. نتایج در جدول ۸ قابل مشاهده است.

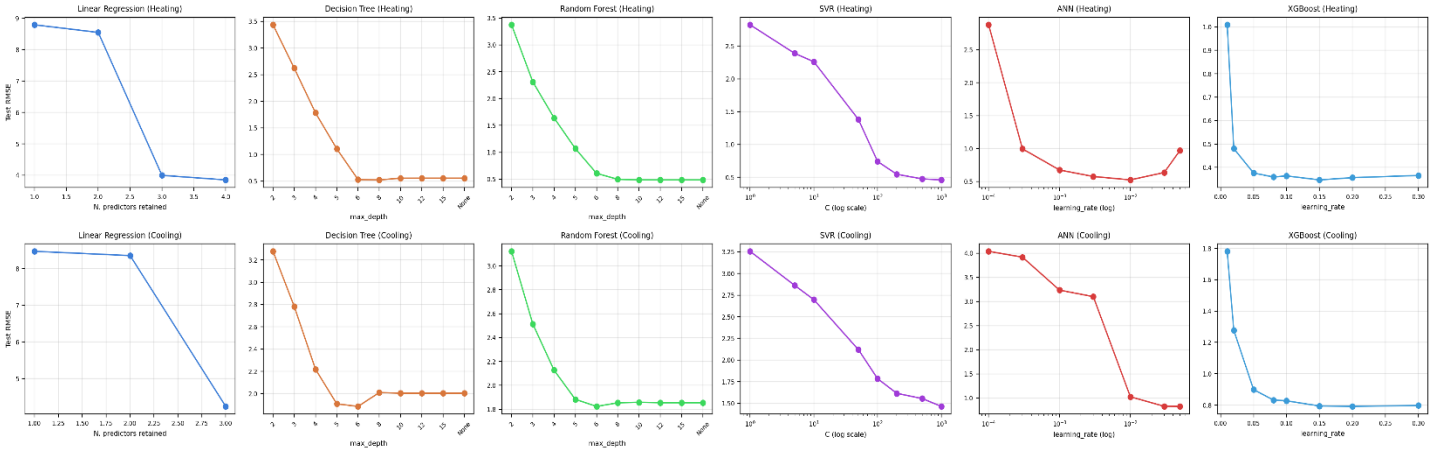
جدول ۸-مقایسه نهایی شش مدل برای هر دوبار گرمایشی و سرمایشی

Target	Model	R^2	MSE	RMSE	MAE	MAPE (%)	AIC	BIC
Heating Load	Linear Regression	0.858	14.84	3.85	2.65	11.69	433.4	460.7
Heating Load	Decision Tree	0.9974	0.27	0.52	0.36	1.41	−182.0	−154.7
Heating Load	Random Forest	0.9976	0.25	0.5	0.37	1.54	−197.3	−170.0
Heating Load	SVR	0.9978	0.23	0.48	0.35	1.8	−211.3	−184.0
Heating Load	Artificial Neural Network	0.9973	0.28	0.53	0.39	1.68	−188.9	−161.6
Heating Load	XGBoost	0.9988	0.13	0.36	0.26	1.17	−298.1	−270.8
Cooling Load	Linear Regression	0.806	18.01	4.24	2.91	10.95	453.2	465.3
Cooling Load	Decision Tree	0.9564	4.04	2.01	1.25	4.14	233	260.4
Cooling Load	Random Forest	0.9629	3.44	1.85	1.25	4.2	208.2	235.6
Cooling Load	SVR	0.9739	2.42	1.56	0.91	3.39	154.1	181.4
Cooling Load	Artificial Neural Network	0.9904	0.89	0.94	0.64	2.49	−11.5	15.9
Cooling Load	XGBoost	0.9941	0.55	0.74	0.42	1.55	−75.0	−47.7

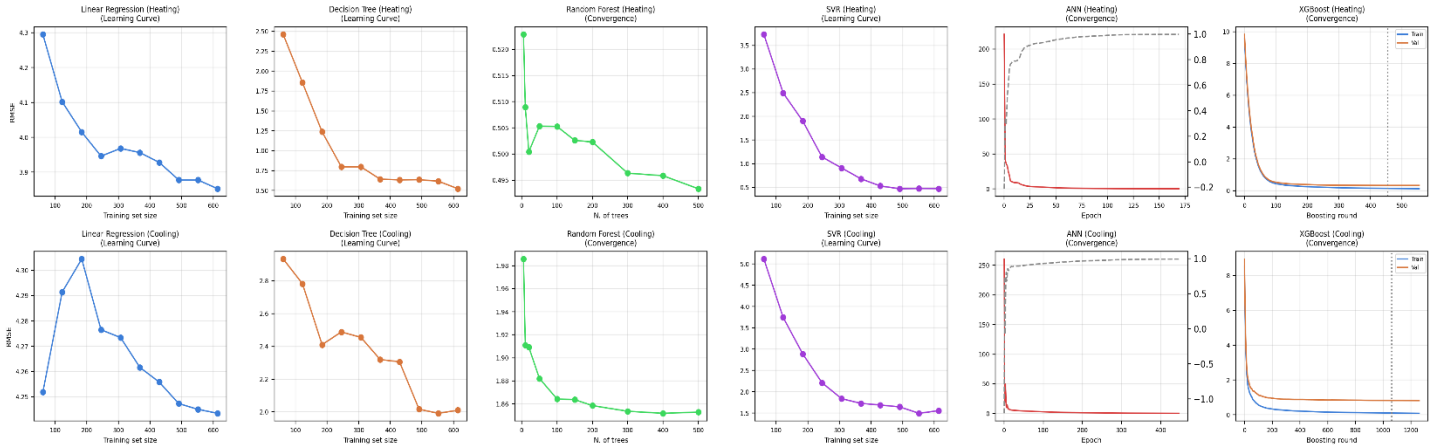
برای اطمینان از پایداری هر شش مدل نسبت به تغییر مهم‌ترین ابرپارامتر، شکل ۱۴ تحلیل حساسیت تطبیقی همه مدل‌ها را ارائه می‌دهد. از آنجا که رگرسیون خطی و درخت تصمیم فاقد ابرپارامتر پیوسته قابل‌تنظیم به سبک سایر مدل‌ها هستند، برای رگرسیون خطی حساسیت به تعداد متغیرهای مستقل نگه‌داشته‌شده در فرآیند Stepwise و برای درخت تصمیم و Random Forest حساسیت به عمق درخت بررسی شد؛ در مقابل، برای SVR، شبکه عصبی و XGBoost به‌ترتیب حساسیت نسبت به C، نرخ یادگیری و نرخ یادگیری ارزیابی گردید. نتایج نشان می‌دهد که در هر شش مدل، یک ناحیه بهینه مشخص وجود دارد و رابطه عملکرد با ابرپارامترها یکنواخت نیست؛ به‌گونه‌ای که انتخاب مقادیر پایین‌تر یا بالاتر از این ناحیه به افزایش خطا منجر می‌شود. این یافته، ضرورت تنظیم نظام‌مند ابرپارامترها و پرهیز از انتخاب اختیاری مقادیر را تأیید می‌کند. همچنین، شکل ۱۵ روند بهبود دقت مدل‌ها را متناسب با ماهیت فرآیند آموزش آن‌ها نشان می‌دهد. برای مدل‌های فاقد فرآیند آموزش تکرارشونده، شامل رگرسیون خطی،

درخت تصمیم و SVR، منحنی یادگیری برحسب خطای آزمون و حجم داده آموزش ترسیم شده است که همگرایی تدریجی خطا با افزایش داده را نشان می‌دهد. برای Random Forest، منحنی همگرایی بر مبنای تعداد درختان (n_estimators) رسم شده و پس از حدود ۱۰۰ درخت به فلات می‌رسد؛ در شبکه عصبی و XGBoost نیز منحنی‌های همگرایی واقعی، شامل خطای آموزش و اعتبارسنجی در برابر Epoch یا دور Boosting، ارائه شده‌اند که فاصله کوچک و پایدار میان دو منحنی پس از نقطه انتخاب‌شده، بیانگر کنترل مناسب بیش‌برازش است.

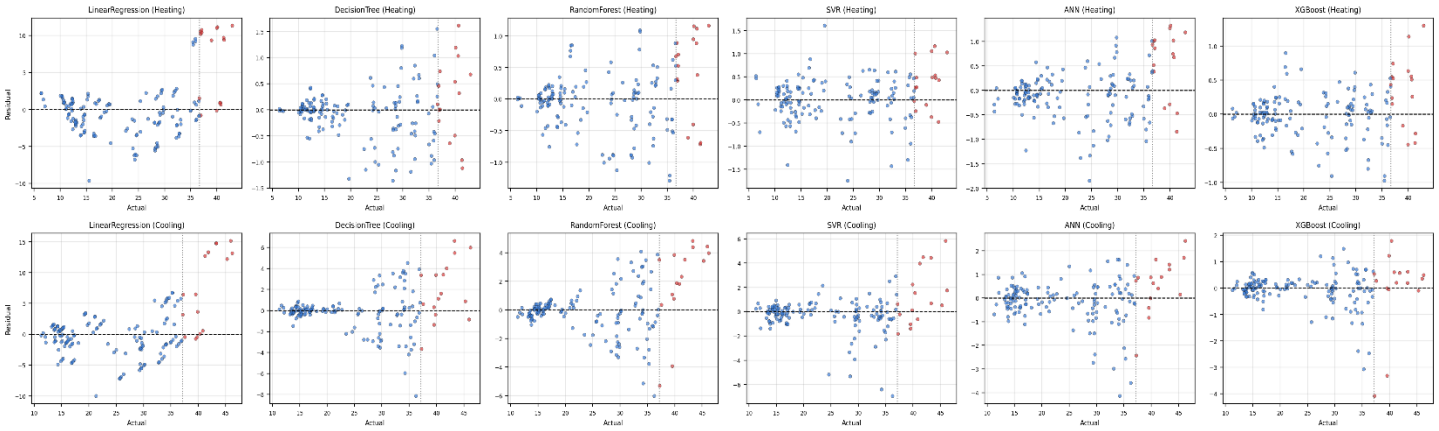
در ادامه، شکل ۱۶ چارچوب تحلیل باقیمانده را برای هر شش مدل و هر دو هدف پیش‌بینی، از طریق نمایش پراکندگی باقیمانده در برابر مقدار واقعی و با علامت‌گذاری صریح دهک بالای بار به‌عنوان ناحیه بار اوج ارائه می‌کند. نتایج نشان می‌دهد که الگوی افزایش خطا در ناحیه بار اوج، با شدت‌های متفاوت، در تمام شش مدل بدون استثنا مشاهده می‌شود. در این میان، رگرسیون خطی شدیدترین الگوی رشد خطا را نشان می‌دهد؛ به‌طوری‌که مقدار باقیمانده در بار اوج سرمایشی تا حدود ۱۵ واحد افزایش می‌یابد، در حالی‌که XGBoost و درخت تصمیم کنترل‌شده‌ترین رفتار را در این ناحیه دارند. بنابراین، اگرچه شدت خطا میان مدل‌ها متفاوت است، وجود این الگوی مشترک در نواحی حدی نشان می‌دهد که حتی مدل‌های با عملکرد کلی بهتر نیز در پیش‌بینی بارهای اوج کاملاً بدون خطا نیستند. از این رو، استفاده مستقیم از خروجی هر یک از مدل‌ها برای تصمیمات طراحی ظرفیت در نواحی حدی بار باید با احتیاط انجام شود؛ زیرا رفتار مدل در بخش‌های معمول دامنه داده لزوماً تضمین‌کننده دقت مشابه در شرایط اوج نیست.



شکل ۱۴- تحلیل حساسیت مقایسه‌ای ابرپارامترها



شکل ۱۵- منحنی‌های همگرایی و یادگیری



شکل ۱۶- پراکندگی باقیمانده در برابر مقدار واقعی

۵- بحث و نتیجه گیری

نتایج این پژوهش نشان داد که در میان شش رویکرد بررسی‌شده، XGBoost در هر دو متغیر هدف بالاترین دقت را کسب کرد (R^2=۰.۹۹۸۸ برای بار گرمایشی و ۰.۹۹۴۱ برای بار سرمایشی)، در حالی‌که SVR و شبکه عصبی مصنوعی (با بهینه‌سازی بیزی ابرپارامتر) در رتبه‌های بعدی و با فاصله بسیار اندک قرار گرفتند و رگرسیون خطی، به‌عنوان تنها مدل پارامتریک این مقایسه، به‌طور قابل‌انتظار پایین‌ترین دقت برون‌نمونه را نشان داد (۰.۸۵۸ و R^2=۰.۸۰۶)، یافته‌ای که برتری روش‌های غیرخطی و یادگیری گروهی را در مواجهه با روابط پیچیده میان ویژگی‌های هندسی ساختمان و بارهای انرژی تأیید می‌کند. این سطح از دقت با پیشرفته‌ترین نتایج گزارش‌شده در ادبیات این حوزه هم‌راستا و در برخی موارد برتر است: Moayedi و همکاران [16]، در مقایسه شش الگوریتم یادگیری ماشین برای بار گرمایشی، Random Forest را با R^2=۰.۹۹۸۹، RMSE=۰.۴۶۴۹ و MAE=۰.۳۳۸۵ روی مجموعه آزمون به‌عنوان برترین مدل معرفی کردند؛ Lu و همکاران [1]، با یک چارچوب یادگیری ماشین خودکار، به R^2=۰.۹۹۶۵ و RMSE=۰.۶۰۲ برای بار گرمایشی و R^2=۰.۹۸۹۹ و RMSE=۰.۹۷۳ برای بار سرمایشی رسیدند؛ و Kumar و همکاران [15] با روش ماشین یادگیری فرین (Extreme Learning Machine) و نسخه برخط آن (OSELM)، عملکرد این روش‌ها را در مقایسه با ANN، SVM و Gradient Boosting برای ترکیب‌های مختلفی از ویژگی‌های ورودی ارزیابی کردند. مدل XGBoost این پژوهش (RMSE=۰.۳۵۸ برای گرمایش و ۰.۷۳۹ برای سرمایش) از هر دو معیار عددی گزارش‌شده توسط Moayedi و Lu برای بار گرمایشی برتر عمل کرده و برای بار سرمایشی در محدوده بهترین نتایج گزارش‌شده در ادبیات قرار دارد. تحلیل اهمیت ویژگی از طریق چهار الگوریتم مستقل با سازوکار یادگیری اساساً متفاوت (ضرایب استانداردشده رگرسیون، اهمیت متغیر شبکه عصبی، و اهمیت ویژگی Random Forest و XGBoost) به‌طور هم‌زمان ارتفاع کل، فشردگی نسبی، و مساحت سقف را به‌عنوان مؤثرترین پیش‌بین‌های بار انرژی شناسایی کرد؛ این یافته با نتایج Sholahudin و همکاران [13] (ارتفاع کل و فشردگی نسبی)، و Atıcı و Tuna [22] (ارتفاع، مساحت سقف/کف) هم‌راستاست، و همگرایی آن میان چهار الگوریتم مستقل، اطمینان بسیار بالاتری نسبت به گزارش تک‌الگوریتمی رایج در ادبیات فراهم می‌کند. یافته روش‌شناختی مهم دیگر این پژوهش آن است که جایگزینی روش آزمون‌وخطا با بهینه‌سازی بیزی، به‌تنهایی و بدون تغییر داده یا معماری بنیادین، دقت شبکه عصبی را به‌طور چشمگیری افزایش داد (R^2 بار گرمایشی از ۰.۹۴۷۶ به ۰.۹۹۷۳ و بار سرمایشی از ۰.۹۸۰۷ به ۰.۹۹۰۴ رسید)، که پیشنهاد می‌کند بخش قابل‌توجهی از تفاوت دقت گزارش‌شده میان مطالعات مشابه در این حوزه می‌تواند ناشی از تفاوت در دقت فرآیند تنظیم ابرپارامتر باشد، نه صرفاً تفاوت ذاتی توان مدل‌سازی الگوریتم‌ها.

از منظر کاربردی، تحلیل خطا نشان داد الگوی رشد خطا در بار اوج مصرف (دهک بالای بار) در تمام شش مدل بدون استثنا دیده می‌شود، یافته‌ای با اهمیت مستقیم برای طراحی ظرفیت سیستم‌های HVAC، چون این ظرفیت معمولاً بر مبنای بار اوج، نه میانگین، تعیین می‌شود؛ همچنین تحلیل خطا بر مبنای فرم هندسی نشان داد دقت مدل برای برخی فرم‌های خاص (فشردگی نسبی در بازه ۰.۷۹ تا ۰.۸۲) به‌طور محسوسی کمتر است. این دو یافته با هم پیشنهاد می‌کنند که در کاربرد عملی این مدل‌ها برای تصمیمات طراحی، افزودن یک ضریب اطمینان در نواحی بار اوج و برای فرم‌های هندسی با خطای تاریخی بالاتر محتاطانه خواهد بود.

ویرایشی نشده

این پژوهش با محدودیت‌هایی نیز همراه است که باید در تفسیر و کاربرد نتایج مورد توجه قرار گیرند. نخست، داده‌های این پژوهش از طریق نرم‌افزار شبیه‌سازی تولید شده‌اند و عواملی نظیر رفتار واقعی ساکنان، کیفیت اجرای مصالح نسبت به مقادیر طراحی، و پل‌های حرارتی پیش‌بینی‌نشده در این شبیه‌سازی به‌صورت ساده‌شده لحاظ می‌شوند (برای نمونه، تعداد و الگوی فعالیت ساکنان ثابت فرض شده است)؛ بنابراین نتایج در محدوده فضای پارامترهای شبیه‌سازی‌شده معتبرند و تعمیم مستقیم به عملکرد عملیاتی واقعی ساختمان‌ها نیازمند اعتبارسنجی با داده میدانی است. دوم، داده‌ها مبتنی بر شرایط اقلیمی تهران تولید شده‌اند و تعمیم مستقیم یافته‌ها، به‌ویژه برتری نسبی هر مدل در بار سرمایشی در برابر بار گرمایشی، به اقلیم‌های دیگر، به‌ویژه مناطق بسیار مرطوب یا بسیار سرد که سازوکار غالب انتقال حرارت متفاوت است، بدون بازآموزی مدل با داده اقلیمی متناظر توصیه نمی‌شود. سوم، همان‌طور که ذکر شد، تمام شش مدل در برآورد بارهای حدی قابلیت اطمینان کمتری نسبت به میانگین کلی نشان می‌دهند، که باید در تصمیمات حساس طراحی ظرفیت مورد توجه قرار گیرد. چهارم، یافته‌ها مبتنی بر ساختمان‌های مسکونی با فرم‌های هندسی مشخص است و بدون بازآموزی مدل به ساختمان‌های تجاری، اداری یا صنعتی با الگوی مصرف انرژی متفاوت قابل‌تعمیم نیست.

بر مبنای این یافته‌ها و محدودیت‌ها، پژوهش‌های آتی می‌توانند در چند مسیر ادامه یابند: اعتبارسنجی مدل‌های توسعه‌یافته با داده میدانی از ساختمان‌های واقعاً ساخته‌شده، به‌ویژه در تهران، برای سنجش دقت تعمیم‌پذیری فراتر از داده شبیه‌سازی‌شده؛ بازآموزی و ارزیابی مدل‌ها با داده اقلیمی سایر مناطق جغرافیایی ایران و کشورهای با شرایط اقلیمی متفاوت؛ ترکیب مدل‌های این پژوهش در چارچوب‌های یادگیری گروهی چندسطحی برای کاهش بیشتر خطا در نواحی بار اوج؛ گنجاندن داده‌های رفتار واقعی ساکنان و پارامترهای اقلیمی پویا به‌جای فرض‌های ثابت برای افزایش واقع‌گرایی مدل؛ و توسعه و آزمون این چارچوب مقایسه‌ای شش‌گانه برای انواع دیگر ساختمان به‌منظور سنجش تعمیم‌پذیری فراتر از بخش مسکونی. در جمع‌بندی نهایی، این پژوهش با توسعه و مقایسه نظام‌مند شش رویکرد یادگیری آماری و ماشین، از رگرسیون خطی کلاسیک تا الگوریتم‌های پیشرفته یادگیری گروهی، چارچوبی جامع برای پیش‌بینی بار گرمایشی و سرمایشی ساختمان‌های مسکونی ارائه داد؛ یافته‌ها نشان داد مدل‌های غیرخطی و به‌ویژه یادگیری گروهی مبتنی بر Boosting، با دقتی در سطح یا برتر از پیشرفته‌ترین مطالعات مشابه ، جایگزین قابل‌اتکایی برای رویکردهای پارامتریک سنتی‌اند، در حالی‌که شناسایی الگوی مشترک رشد خطا در بار اوج و در فرم‌های هندسی خاص، اهمیت به‌کارگیری محتاطانه این مدل‌ها را در تصمیمات حساس طراحی یادآوری می‌کند؛ نتایج این پژوهش می‌تواند مبنایی برای توسعه ابزارهای تصمیم‌یار داده‌محور در فرآیند طراحی انرژی‌کارآمد ساختمان‌های مسکونی، به‌ویژه در بستر اقلیمی ایران، فراهم آورد.

۶- مراجع (References)

1. Lu, C., Li, S. and Lu, Z. (2022) ‘Building energy prediction using artificial neural networks: a literature survey’, *Energy and Buildings*, *262*, 111718. https://doi.org/10.1016/j.enbuild.2021.111718
2. Yin, Q., Han, C., Li, A., Liu, X. and Liu, Y. (2024) ‘A review of research on building energy consumption prediction models based on artificial neural networks’, *Sustainability*, *16*(17), 7805. https://doi.org/10.3390/su16177805
3. Neshat, N., Sardari Zarchi, M. and Malhooji, H. (2020) ‘Application of deep learning models in forecasting socio-economic time series: a case study of household peak load time series’, *Sharif Journal of Industrial Engineering (SJIE)*, *36*(1.2), pp. 103–111. https://doi.org/10.24200/j65.2019.54014.2029
4. Ebrahimi, F., Afshar, A., Rezaei Nour, J. and Ghanbari Sarkhi, A. (2017) ‘An effective intelligent method for short-term electrical load forecasting’, *Sharif Journal of Industrial Engineering (SJIE)*, *33*(1.2), pp. 43–54. https://doi.org/10.24200/j65.2017.5590
5. Gao, Z., Yang, S., Yu, J. and Zhao, A. (2024) ‘Hybrid forecasting model of building cooling load based on combined neural network’, *Energy*, *297*, 131317. https://doi.org/10.1016/j.energy.2024.131317
6. Chaganti, R., Rustam, F., Daghriri, T., de la Torre Díez, I., Vidal Mazón, J.L., Rodríguez, C.L. and Ashraf, I. (2022) ‘Building heating and cooling load prediction using ensemble machine learning model’, *Sensors*, *22*(19), 7692. https://doi.org/10.3390/s22197692
7. Zhang, L., Wen, J., Li, Y., Chen, J., Ye, Y., Fu, Y. and Livingood, W. (2021) ‘A review of machine learning in building load prediction’, *Applied Energy*, *285*, 116452. https://doi.org/10.1016/j.apenergy.2021.116452
8. D’Amico, A. and Ciulla, G. (2022) ‘An intelligent way to predict the building thermal

needs: ANNs and optimization', *Expert Systems with Applications*, *191*, 116293. https://doi.org/10.1016/j.eswa.2021.116293
9. Xu, Y., Li, F. and Asgari, A. (2022) 'Prediction and optimization of heating and cooling loads in a residential building based on multi-layer perceptron neural network and different optimization algorithms', *Energy*, *240*, 122692. https://doi.org/10.1016/j.energy.2021.122692
10. Mazzeo, D. and Matera, N. (2020) 'EnergyPlus, IDA ICE and TRNSYS predictive simulation accuracy for building thermal behaviour evaluation by using an experimental campaign in solar test boxes with and without a PCM module', *Energy and Buildings*, *212*, 109812. https://doi.org/10.1016/j.enbuild.2020.109812
11. Magni, M. and Ochs, F. (2021) 'Detailed cross comparison of building energy simulation tools results using a reference office building as a case study', *Energy and Buildings*, *250*, 111260. https://doi.org/10.1016/j.enbuild.2021.111260
12. Yin, Q., Han, C., Li, A., Liu, X. and Liu, Y. (2024) 'A review of research on building energy consumption prediction models based on artificial neural networks', *Sustainability*, *16*(17), 7805. https://doi.org/10.3390/su16177805
13. Sholahudin, S., Alam, A.G., Baek, C.I. and Han, H. (2016) 'Prediction and analysis of building energy efficiency using artificial neural network and design of experiments', *Applied Mechanics and Materials*, *819*, pp. 541–545. https://doi.org/10.4028/www.scientific.net/AMM.819.541
14. Alkhalaf, H. and Yan, W. (2017) 'Comparison of regression model and artificial neural network model for energy benchmarking of accommodation buildings in Kanto, Japan', *Energy and Sustainability*, pp. 71–82. https://doi.org/10.2495/ESUS170071
15. Panda, S., Samanta, I.S., Sahoo, B. and Rout, P.K. (2025) 'Comprehensive framework for smart residential demand side management with electric vehicle integration and advanced optimization techniques', *Scientific Reports*, *15*(1), 9948. https://doi.org/10.1038/s41598-025-93817-5
16. Moayedi, H., Bui, D.T., Dounis, A., Lyu, Z. and Foong, L.K. (2019) 'Predicting heating load in energy-efficient buildings through machine learning techniques', *Applied Sciences*, *9*(20), 4338. https://doi.org/10.3390/app9204338
17. Sajjad, M., Khan, S.U., Khan, N., Haq, I.U., Ullah, A., Lee, M.Y. and Baik, S.W. (2020) 'Towards efficient building designing: heating and cooling load prediction via multi-output model', *Sensors*, *20*(22), 6419. https://doi.org/10.3390/s20226419
18. Roshan Joshua, J. and Shiva, S.G. (2025) 'Building LSTM based forecast model with pattern exploration of load profiles for enhancing energy efficiency in electrical laboratories', *Electrical Engineering*, *107*(9), 12481. https://doi.org/10.1007/s00202-025-03162-z
19. Morcillo-Jimenez, R., Mesa, J., Amparo, J.G.M., Maria, V. and Gómez-Romero, J. (2024) 'Deep learning for prediction of energy consumption: an applied use case in an office building', *Applied Intelligence*, pp. 5813–5825. https://doi.org/10.1007/s10489-024-05451-9
20. Qin, H., Yu, Z., Li, Z., Li, H. and Zhang, Y. (2024) 'Nearly zero-energy building load forecasts through the competition of four machine learning techniques', *Buildings*, *14*(1), 147. https://doi.org/10.3390/buildings14010147
21. Jain, R.B. (2010) 'A recursive version of Grubbs' test for detecting multiple outliers in environmental and chemical data', *Clinical Biochemistry*, *43*(12), pp. 1030–1033. https://doi.org/10.1016/j.clinbiochem.2010.04.071
22. Atıcı, S. and Tuna, G. (2025) 'Comparative evaluation of regression models for building energy efficiency assessment based on heating and cooling load requirements', *Kırklareli University Journal of Engineering and Science*, *11*(2), pp. 283–303. https://doi.org/10.34186/klujes.1804525
23. Mehdizadeh Khorrami, B., Soleimani, A., Pinnarelli, A., Brusco, G. and Vizza, P. (2024) 'Forecasting heating and cooling loads in residential buildings using machine learning: a comparative study of techniques and influential indicators', *Asian Journal of Civil Engineering*, *25*(2), pp. 1163–1177. https://doi.org/10.1007/s42107-023-00834-8
24. Grubbs, F.E. (1969) 'Procedures for detecting outlying observations in samples', *Technometrics*, *11*(1), pp. 1–21. https://doi.org/10.1080/00401706.1969.10490657
25. O'Brien, R.M. (2007) 'A caution regarding rules of thumb for variance inflation factors', *Quality*

and Quantity, *41*(5), pp. 673–690. https://doi.org/10.1007/s11135-006-9018-6

26. Xie, Z., Wang, X., Zheng, L., Chang, H. and Wang, F. (2022) 'A period-based neural network algorithm for predicting building energy consumption of district heating', *Energies*, *15*(17), 6338. https://doi.org/10.3390/en15176338

1.

ویراستاری نشده