

文章编号: 1671-6612 (2025) 05-639-13

基于机器学习算法的制冷机房短时能耗预测模型

袁 杨^{1,2} 邹秋生¹ 王懋琪¹

(1. 四川省建筑设计研究院有限公司 成都 610000;

(2. 重庆大学土木工程学院 重庆 400044)

【摘 要】 公共建筑制冷机房的短时能耗预测对机房能耗优化和故障检测诊断至关重要, 传统方法存在输入维度高、难以捕捉机房特性、参数拟合工作量大等问题。提出了一种基于机器学习 (ML) 算法的制冷机房短期能耗预测模型, 该模型仅需八个变量作为输入。分别使用一次冷冻水变流量机房和一次冷冻水定流量机房采集的真实数据对比实验了 7 种常见的机器学习算法 (ANN、BPNN、SVM、DT、RF、XGB、MPR) 以及传统经验累加公式 (Sum) 的预测表现。实验结果表明, RF 和 XGB 模型因其预测准确性和鲁棒性取得了最优表现, 传统方法表现最差。

【关键词】 制冷机房; 短时能耗预测; 机器学习; 历史数据
中图分类号 TU831 文献标志码 A

Data-Driven Energy Consumption Prediction for Chiller Plants Using Machine Learning: A Practical Study

Yuan Yang^{1,2} Zou Qiusheng¹ Wang Maoqi¹

(1.Sichuan Provincial Architectural Design and Research Institute Co., Ltd, Chengdu, 610000;

2.Chongqing University, Chongqing, 400044)

【 Abstract 】 Chiller plants traditional energy consumption calculation methods-typically based on empirical formula summation-often suffer from issues such as high input dimensionality, laborious calibration, and limited generalizability under variable operating conditions. A machine learning (ML) approach for short-term energy consumption forecasting in the chiller plant with eight independent input variables was proposed. Seven machine learning models together with Sum were selected to predicted the energy consumption under both variable and constant primary chilled water flow conditions..The Random forest (RF) and Extreme gradient boosting trees (XGB) were determined to be the preferred model due to their better accuracy of the energy consumption forecasting than the Sum and other five machine learning models. A practical tool for engineers to evaluate energy performance and validate control strategies was provided by the novel ML-based model.

【Keywords】 Chiller plant; Energy consumption prediction; Machine learning algorithms; Historical operational data

0 引言

据统计全球建筑及其相关终端用能占全球用能的 30%, 中国 2020 年建筑建造、运行阶段的用能和碳排放占据了社会总能源消耗与碳排放的

32%^[1]。医院、商场、写字楼等大型公共建筑中中央空调系统是能耗大户, 占建筑总能耗的 50%^[2,3]。因此, 降低大型公共建筑中央空调系统运行能耗, 提高建筑能效, 是缓解全球变暖和提高环境可持续

基金项目: 既有公共建筑空调蓄冷改造技术研究 (KYYN2025026)

作者简介: 袁 杨 (1995.01-), 男, 博士, 工程师, E-mail: 187270046@qq.com

通讯作者: 王懋琪 (1985.02-), 女, 本科, 高级工程师, E-mail: 273173530@qq.com

收稿日期: 2025-06-18

性的重要手段。

已有大量学者^[4-21], 通过优化控制降低中央空调系统的制冷机房能耗, 主要包括: 混合预测控制算法^[5]、多目标优化算法^[6,14,22]、遗传 (GA) 算法^[8,11,12,16,23,24]、粒子群 (PSO) 算法^[7,10,17,19]、模型预测控制算法 (MPC) ^[4,9,15,24,25,22,21]、强化学习算法^[13]等。为了检验和实施这些优化控制算法, 就需要准确地预测制冷机房短时能耗、能效^[21]。上述研究^[6,7,15,17,25,29,30] 计算制冷机房能耗主要借助 Trnsys、EnergyPlus、DoE-2 等仿真软件通过累加水泵、冷水机组和冷却塔能耗之和得到。

这些软件中的设备能耗模型包括理论模型^[31], 经验模型^[17,23,25,32], 数据驱动类模型^[11,18,26,27,28,33,34]。理论模型基于严格的假设和大量给定的参数, 其预测的准确性受到特定条件的限制。经验模型计算设备能耗时存在受限于设备样本区间的问题, 当实际运行工况位于样本以外时会计算不准^[35]。数据驱动模型可以体现设备实际运行特性, 更贴合设备运行情况。

基于数据驱动方法建立单一设备的冷水机组模型^[11,18,26,27,28]、冷却塔模型^[11]、水泵模型^[18]等, 需要采集诸多变量的历史数据^[11,18,33,34], 因而需要安装大量传感器, 实施难度大。并且单个设备都需要对比多种数据驱动算法的准确度以选取最优算法, 导致工作繁琐。

考虑到制冷机房的能耗表现与运维人员操作偏好、机房运行条件 (例如空调水管网特性、阀门群控水平等)、建筑室内外环境等特性密切相关, 并且行业标准和规范一般以机房整体能效来评价机房的建设和运维水平, 所以能快速计算机房整体的能耗、能效尤为重要。综上, 机房运维人员和设计人员都需要一种方便、准确、反映制冷机房专属特性的能耗、能效计算工具。

故本文旨在采用系统级建模思路, 提出一种基于历史运行数据的制冷机房短时能耗预测模型以指导设计和优化运行, 该模型应具有输入变量少、参数容易采集、计算精准、适用性强的特点。

1 传统经验累加公式

前人研究^[6,7,15,17,25,29,30]均采用如式 (1) 所示的经验系数公式计算单一设备能耗后累加得到机房能耗和能效比。权威的能耗模软件例如 Trnsys、Energyplus、DoE-2 也采用这种方法计算机房的短

时能耗和能效。

$$P_{\text{chp}}(t) = \sum_{i=1}^{N_{\text{ch}}} P_{\text{ch},i}(t) + \sum_{j=1}^{N_{\text{ct}}} P_{\text{ct},j}(t) + \sum_{k=1}^{N_{\text{chwp}}} P_{\text{chwp},k}(t) + \sum_{l=1}^{N_{\text{cwp}}} P_{\text{cwp},l}(t) \quad (1)$$

$$EER_{\text{chp}} = \frac{Q_{\text{chp}}}{P_{\text{chp}}} \quad (2)$$

式中: N_{chwp} 为冷冻水泵数量, 台; N_{ch} 为冷水机组数, 台; N_{ct} 为冷却塔台数, 台; N_{cwp} 为冷冻水泵数量, 台; $P_{\text{ch},i}$ 为第 i 台冷水机组能耗, kW; $P_{\text{chwp},k}$ 为第 k 台冷冻水泵能耗, kW; $P_{\text{ct},j}$ 为第 j 台冷却塔能耗, kW; $P_{\text{cwp},l}$ 为第 l 台冷却水泵能耗, kW。

在机房节能优化控制和机房诊断评估实践中, 式 (1) 无法体现因空调水管网特性、阀门群控水平、运维人员操作偏好、设备组合运行效果等原因产生的机房异质性和特征, 而上述因素的确对机房能耗表现产生影响。同时, 求解单一设备的能耗经验公式中的拟合系数, 还需要进行大量繁琐的参数收集和系数拟合校准工作。综上, 传统方法被证明是不准确和低效的。

2 方法与材料

针对传统方法的局限, 本文将冷水机组、冷冻水泵、冷却水泵、冷却塔视作一个整体, 借助数据驱动方法基于机房的历史运行数据训练可以准确反映机房运行特征的能耗预测模型。为了实现这一目标就需要确定模型的输入变量, 并确定与模型兼容且准确的数据驱动算法。

预测模型研究应满足如下要求: (1) 考虑模型的通用性, 输入变量应保证适用于不同类型的制冷机房; (2) 考虑可行性, 要求输入变量简洁且便于采集; (3) 考虑模型先进性, 对比选用成熟、准确的数据驱动算法。

2.1 模型输入变量筛选

数据驱动模型一般通过敏感性分析方法选取输入变量, 但该方法选出的变量可能难于采集且存在交叉重叠。考虑采集便利性且保证模型通用性和简洁, 本文采用基于专家经验法和作用机理分析的方法筛选输入变量。

本文选取了 4 种经典的冷水机组经验能耗模型以罗列冷水机组能耗影响因素, 包括: GN (Gordon-Ng) 模型^[36], 如式 (3) 所示; Comstock

模型^[37],如式(4)所示;Chang模型^[38],如式(5)所示;Braun模型^[31],如式(6)所示。

$$P_{ch} = \frac{Q_e(t_{cwr} - t_{chws}) + \alpha_1 t_{cwr} t_{chws} + \alpha_2 (t_{cwr} - t_{chws}) + \alpha_3 Q_e^2}{t_{chws} - \alpha_3 Q_e} \quad (3)$$

$$P_{ch} = \alpha_1 + \alpha_2 t_{chws} + \alpha_3 t_{cwr} + \alpha_4 Q_{ch} + \alpha_5 t_{chws} Q_{ch} + \alpha_6 t_{cwr} Q_{ch} + \alpha_7 Q_{ch}^2 \quad (4)$$

$$P_{ch} = \alpha_1 + \alpha_2 PLR + \alpha_3 PLR^2 + \alpha_4 (t_{cwr} - t_{chws}) + \alpha_5 (t_{cwr} - t_{chws})^2 + \alpha_6 PLR(t_{cwr} - t_{chws}) \quad (5)$$

$$P_{ch} = P_o(\alpha_0 + \alpha_1 PLR + \alpha_2 PLR^2 + \alpha_3 y + \alpha_4 y^2 + \alpha_5 y PLR) \quad (6)$$

式中: $Q_e = C_p \cdot m_w \cdot (t_{chws} - t_{chwr})$ 为机组制冷量, kW; t_{chws} 为机组蒸发器出口温度, °C; t_{cwr} 为机组冷凝器进口温度, °C; $\alpha_1 \sim \alpha_7$ 为使用制造商测试数据拟合的回归系数。

式(6)中: $y = (t_{cwo} - t_{chws}) / (t_{cwo} - t_{chws})_{design}$, $(t_{cwo} - t_{chws})_{design}$ 为机组冷凝器出水温度与蒸发器供水温度的固定设计温差; PLR 计算公式为 $PLR = Q_e / Q_{e0}$, Q_{e0} 为冷水机组的额定制冷量, kW。

可以看出式(3)~(6)中共有的输入变量包括机组的冷冻供水温度 t_{chws} ; 冷冻回水温度 t_{chwr} ; 冷却回水温度 t_{cwr} ; 冷冻水流量 m_w 。其中式(6)还包含了机组冷却出水温度 t_{cwo} 。

冷却和冷冻水泵能耗计算采用业内常用的拟合多项式的形式^[29],如式(7)~(8)所示。

$$P_{chwp} = \beta_0 + \beta_1 m_{chwp} + \beta_2 m_{chwp}^2 + \beta_3 m_{chwp}^3 \quad (7)$$

$$P_{cwp} = \beta_0 + \beta_1 m_{cw} + \beta_2 m_{cw}^2 + \beta_3 m_{cw}^3 \quad (8)$$

式中: m_{chwp} 为冷冻水泵流量, kg/s; m_{cwp} 为冷却水泵流量, kg/s。 $\beta_0 \sim \beta_3$ 为水泵能耗与流量关系的拟合系数。

冷却塔风机能耗拟合系数公式如式(9)所示。

$$P_{ct} = c_0 + c_1 m_a + c_2 m_a^2 + c_3 m_a^3 \quad (9)$$

式中: $c_0 \sim c_3$ 为模型拟合系数; P_{ct} 为冷却塔风机能耗, kW; m_a 为冷却塔风量, m³/h。

综合公式(3)~(9),可以得到影响机房能耗的变量包括: m_w ; m_a ; m_{chwp} ; m_{cwp} ; t_{chws} ; t_{chwr} ; t_{cwo} ; t_{cwr} ; T_{owb} ; N_{ch} 。

在多台并联冷水机组类型制冷机房中,机组冷冻水的进出口水温 t_{chws} 和 t_{chwr} 与机房冷冻主管供回水温度 T_{chws} 和 T_{chwr} 相关,类似的机组冷却水进出口温度 t_{cwo} 、 t_{cwr} 与机房冷却主管的供回水温度 T_{cws} 和 T_{cwr} 相关。冷冻泵流量 m_{chwp} 、冷水机组流量 m_w 、冷冻主管流量 m_{chwt} 三者存在关联性。冷冻主管流量等于多台冷冻水泵流量累加值,考虑变量独立性和输入变量简洁性考虑,统一使用机房冷冻水主管

流量 m_{chwt} 代替,冷却侧同理。

考虑到单台冷却塔风量不便于采集,而冷却塔运行风量 m_a 的调节逻辑主要与室外湿球温度 T_{owb} 和机房冷却回水温度 T_{cwr} 有关,因此 m_a 与 T_{owb} 和 T_{cwr} 存在关联性,考虑输入变量独立性及便于采集,使用 T_{owb} 和 T_{cwr} 代替 m_a 。

综上,机房能耗模型的输入参数可简化为8个独立变量,即机房冷冻主管水流量 m_{chwt} ; 冷冻主管供水温度 T_{chws} ; 冷冻主管回水温度 T_{chwr} ; 冷却主管供水温度 T_{cws} ; 冷却主管回水温度 T_{cwr} ; 冷却主管水流量 m_{cwt} ; 室外湿球温度 T_{owb} ; 冷水机组运行台数 N_{ch} 。所以修正后通用机房短时能耗模型,如式(10)所示。

$$P_{chp} = f(m_{chwt}, m_{cwt}, T_{chws}, T_{chwr}, T_{cws}, T_{cwr}, T_{owb}, N_{ch}) \quad (10)$$

机房制冷量可通过计算公式(11)计算得到,由于式(11)的输入变量均包括在式(10)中,根据机房 $EER = Q_{chp} / P_{chp}$,可得 EER 计算,如式(12)所示。

$$Q_{chp} = C_p \cdot m_{chwt} \cdot (T_{chws} - T_{chwr}) \quad (11)$$

$$EER_{chp} = f(m_{chwt}, m_{cwt}, T_{chws}, T_{chwr}, T_{cws}, T_{cwr}, T_{owb}, N_{ch}) \quad (12)$$

2.2 预测技术

数据驱动算法主要包括机器学习类算法、深度学习类算法和强化学习类算法。与其他两类算法相比,机器学习类算法具有结构简单,计算量低,训练速度快,样本依赖性较低等优势。适用于样本规模适中,特征数有限,本地化部署的制冷机房能耗预测任务。本文选取7种建筑能耗预测领域常见的机器学习算法用于对比研究,包括:人工神经网络(ANN)、决策树(DT)、支持向量机(SVM)、多元多项式(MPR)、反向传播神经网络(BPNN)、随机森林(RF)、极端梯度提升(XGB)算法^[39]。

ANN^[23,34,39,40]和BPNN^[15,41]是传统和经典的机

器学习算法，适合作为能耗预测模型的基准和参考。ANN 是受生物神经元结构和功能启发的计算模型。通常由输入层、一个或多个隐藏层和输出层组成，每层由多个相互连接的节点（神经元）组成，其通过调整连接权重和偏差来学习数据中的复杂关系，从而建立输入和输出之间的映射。BPNN 在结构上与 ANN 一致，是一种基于误差反向传播算法训练的多层前馈网络，其训练过程^[41]包含正向传播、反向传播和权值记忆三个阶段。




图 1 神经网络模型结构图

Fig.1 Structure of a typical feed-forward ANN

SVM^[42-45]是一种基于统计学理论的机器学习算法，适用于处理小样本、非线性问题，与 ANN 相比具有较强的泛化能力。有学者^[24,46]指出 SVM 是预测热负荷的最佳模型并使用 SVM 预测建筑负荷。

DT 是一种灵活的预测技术，已经被广泛应用于能耗预测研究，其预测准确性与 ANN 和 SVM 相当。DT 的显著优势是易于理解，但实现和操作相对复杂^[39]，已经有学者将 DT 模型应用于电能消耗预测^[47]。

RF^[40,48,50-52]和 XGB^[53,54,55]都是基于 DT 改进的集成模型，预测精度优于 DT 和 ANN，除具备 DT 的优势还具有抗过拟合能力。两种算法都已经用于建筑能耗预测和空调负荷预测任务。

MPR 能够捕捉不同变量间的非线性关系，具有开发简单、可解释性强、使用方便等特点。MPR 已经被学者用于建立建筑短时冷负荷预测模型^[56]和地源热泵系统 COP 预测模型^[57]。

3 案例研究

为了量化和对比本文所涉及机器学习模型的性能表现。研究人员选用常见的一次侧冷冻变流量系统和一次侧冷冻水定流量系统进行案例研究。实验工作在一台个人电脑（Intel Core i5 2.50 GHz with 16 GB of RAM）上使用 Matlab 软件执行。

考虑到采集案例建筑冷却塔附近的室外湿球温度 T_{owb} 的难度，并且湿球温度主要影响机房冷冻回水温度 T_{chwr} 、冷却回水温度 T_{cwr} 和冷却塔能耗 P_{ct} ，所以此处提出代替输入变量 T_{owb} 的公式（13）。

$$P_{chp}(t) = f(m_{chw}, m_{cw}, T_{chws}, T_{chwr}, T_{cws}, T_{cwr}, N_{ch}, P_{ct})(t) \tag{13}$$

3.1 案例一：冷冻水一次变流量系统

3.1.1 案例背景

案例一为位于成都市的 2 栋办公建筑共用制冷机房，总空调面积为 92954m²，夏季设计空调负荷 143526kW。制冷机房设计为一次变流量系统，采用多台机组并联架构，冷水机组品牌为 McQuay 牌。冷冻水泵采用 4 台 605m³/h 和 2 台 302m³/h 离心式水泵。冷却水泵采用 4 台 710m³/h 和 2 台 356m³/h 离心式水泵。采用定流量逆流式冷却塔台数 4 大 1 小，风机定速运行。

表 1 案例机房设备参数表

Table 1 Chiller plant parameter

设备名称	数量	额定参数
离心式冷水机组	4	制冷量 3516KW，功率 575.3kW，COP: 6.11，冷冻供回水温 7/12℃，冷却供回水温 32/37℃
离心式冷水机组	1	制冷量 1758KW，功率 322kW，COP: 5.46，冷冻供回水温 7/12℃，冷却供回水温 32/37℃
冷冻水泵	4	流量 605m ³ /h，扬程 41m，功率 90kW，电压/频率 380V/50HZ，转速 1480r/min
冷冻水泵	2	流量 302m ³ /h，扬程 41m，功率 45kW，电压/频率 380V/50HZ，转速 1450r/min
冷却水泵	4	流量 710m ³ /h，扬程 41m，功率 90kW，电压/频率 380V/50HZ，转速 1450r/min
冷却水泵	2	流量 356m ³ /h，扬程 41m，功率 55kW，电压/频率 380V/50HZ，转速 1450r/min
冷却塔	4	水流量 800m ³ /h，功率 45kW，进出水温 32/37℃，工作室外湿球温度 27℃
冷却塔	1	水流量 400m ³ /h，进出水温: 32/37℃，工作室外湿球温度 27℃，功率 15kW

3.1.2 数据采集

本案例配备了 BMS 智慧楼宇平台系统, 研究人员通过 BMS 系统导出了 2024 年 6 月 1 日 10:30

到 6 月 27 日 16:50 中的 1891 个时刻的有效数据, 时间步长为 10min。采集式 (13) 所需变量的数据情况如表 2 所示。

表 2 采集数据精度

Table 2 Data accuracy

参数名称	最小值	最大值	均值	中位值	标准差	95%置信区间
机房能耗/kW	0.00	1051.40	449.12	417.75	261.37	[437.29,460.96]
冷冻总管流量/(m³/h)	0.00	1310.30	896.65	1190.60	393.28	[878.85,914.44]
冷却总管流量/(m³/h)	0.00	1396.02	934.38	1213.75	407.75	[915.93,52.84]
冷冻主管供水温度/°C	9.70	19.73	11.80	11.83	1.41	[11.74,11.87]
冷冻主管回水温度/°C	11.10	20.40	12.96	12.73	1.23	[12.90,13.01]
冷却主管出水温度/°C	19.40	33.27	24.79	24.73	2.62	[24.67,24.91]
冷却主管回水温度/°C	18.60	31.57	23.42	23.40	2.27	[23.32,23.52]
冷水机组运行台数/台	0.00	2.00	1.34	1.00	0.61	[1.31,1.37]
冷却塔能耗/kW	0.00	30.00	28.29	30.00	6.06	[28.02,28.56]

3.1.3 参数识别

使用传统经验累加公式需要确定式 (3)~(9) 中的公式系数, 其中冷水机组能耗拟合公式采用 ASHRAE 推荐的式 (5), 水泵能耗计算公式采用式 (7) 和式 (8)。研究人员使用采集到的冷水机

组的部分负荷率 PLR 、蒸发器流量 m_w 、蒸发器回水温度 t_{chwr} 、蒸发器供水温度 t_{chws} 、冷凝器回水温度 t_{cwr} 、机组能耗 P_{ch} , 使用最小二乘法计算式 (5) 的拟合系数。使用水泵运行流量, 能耗数据拟合得到式 (7)~(8) 的拟合系数。

表 3 机组、水泵能耗经验公式拟合系数

Table 3 Coefficient values of empirical formulas

式 (7) 拟合系数		式 (8) 拟合系数		式 (5) 拟合系数	
β_0	1.2090	γ_0	-8.2933×10^{-13}	α_0	213.5303
β_1	-0.0248	γ_1	4.5675×10^{-15}	α_1	913.3908
β_2	1.399×10^{-4}	γ_2	-7.9358×10^{-18}	α_2	-399.7720
β_3	-9.2356×10^{-8}	γ_3	6.7737×10^{-8}	α_3	-39.3770
				α_4	2.3406
				α_5	-29.1821

3.2 案例二: 冷冻水一次定流量系统

3.2.1 案例背景

案例二为成都市某住院楼制冷机房, 设计夏季最大冷负荷 7200kW, 机房由 4 台并联相同容量的冷水机组及其附属的冷冻水泵、冷却水泵和冷却塔

组成。采用 4 台同型号特灵牌离心式冷水机组, 额定制冷量 1758kW, 输入功率 290kW, 冷冻供回水温 7/12℃。冷却塔采用运行台数控制, 当冷却塔出口水温高于 32℃, 增加开启一台冷却塔。

表 4 制冷机房设备参数

Table 4 Chiller plant parameter

设备名称	数量	额定参数
离心式冷水机组	4	制冷量 1758kW, 功率 290kW, COP= 6.06, 冷冻供回水温 7/12℃, 冷却供回水温 32/37℃
冷冻水泵	4	流量 320m³/h, 扬程 43m, 功率 55kW
冷却水泵	4	流量 375m³/h, 扬程 22m, 功率 37kW
冷却塔	4	风量 105000m³/h, 功率 11kW, 进出口水温 37/32℃, 室外湿球温度 27℃

3.2.2 数据采集

研究人员采集到了 2020 年 3 月 26 日 08:00 至 11 月 20 日 22:00 的总计 1424 行有效数据,数据来

源为案例机房的值班运行记录。表 5 中总结了公式 (13) 输入变量数据。由于冷却塔均采用定频运行其能耗按照额定功率估算。

表 5 采集数据精度

Table 5 Data accuracy

参数名称	最小值	最大值	均值	中位值	标准差	95%置信区间
机房能耗 P_{chp}/kW	0.00	276.50	188.01	191.63	29.43	[186.81,189.22]
冷冻主管流量 $m_{\text{chwt}}/(\text{m}^3/\text{h})$	0.00	252.50	138.32	168.33	51.99	[135.62,142.03]
冷却主管流量 $m_{\text{cwt}}/(\text{m}^3/\text{h})$	0.00	266.67	146.09	177.78	54.90	[143.23,148.94]
冷冻主管供水温度 $T_{\text{chws}}/^\circ\text{C}$	6.60	14.40,	12.03	12.50	1.45	[11.95,12.10]
冷冻主管回水温度 $T_{\text{chwr}}/^\circ\text{C}$	8.70	19.10	15.63	16.10	1.75	[15.54,15.72]
冷却主管供水温度 $T_{\text{cws}}/^\circ\text{C}$	22.30	39.00	34.14	34.40	1.82	[34.04,34.23]
冷却主管回水温度 $T_{\text{cwr}}/^\circ\text{C}$	23.70	35.70	30.53	30.80	1.83	[30.43,30.62]
冷水机组运行台数 $N_{\text{ch}}/\text{units}$	0.00	3.00,	1.64	2.00	0.62	[1.61,1.68]
冷却塔能耗 P_{ct}/kW	7.50	7.50	7.50	7.50	—	—

3.2.3 参数识别

因冷冻水泵、冷却水泵定频运行,其运行能耗按照水泵额定能耗估算。冷水机组能耗采用式 (5) 计算,式 (5) 的拟合系数汇总于表 6。

表 6 机组经验公式拟合系数

Table 6 Coefficient values of empirical formulas

式 (5) 拟合系数	数值
α_0	-206.10
α_1	444.30
α_2	-56.62
α_3	21.46
α_4	-0.23
α_5	-15.95

3.3 数据预处理

为了提升模型性能避免极端异常值,保持数据一致性,训练前对采集数据进行预处理,方法如下:

(1) 剔除因能耗计量错误和人为记录错误的异常数据,剔除因为传感器故障数据丢失导致的空白值和假零值,剔除机组加载和卸载阶段的能耗脏数据。

(2) 采用四分位距法 (IQR) 识别异常数据并采用中位值替换。

(3) 模型输入数据采取归一化处理。

(4) 采集数据按照 80%和 20%的比例划分为训练集和测试集,兼顾 MPR 技术的使用限制,要求测试集数值居于训练集的上下限内。

4 实验结果

为了比较传统经验累加公式和 7 种机器学习算法建立预测模型的有效性和先进性,本文使用局部评价指标和全局评价指标评估上述模型的表现。为了排除训练随机性的影响,模型预测值采用重复训练 10 次的平均值。为了便于表述将传统经验累加公式 (1) 统一简称为 Sum。

4.1 评估指标

鉴于相对误差在真实值较小时敏感性较高可能导致误判,故选用对数相对误差 (LRE) 作为局部评价指标。全局评价指标采用四种常用的能耗预测模型评价指标^[39]: 平均绝对误差 (MAE)、均方根误差 (RMSE)、决定系数 (R^2) 和平均绝对百分比误差 (MAPE)。

4.2 案例一

案例一中 ANN、BPNN、SVM、DT、RF、XGB、MPR 和 Sum 的预测能耗与实际能耗的对比如图 2 所示。




图 2 模型预测值与实际值

Fig.2 Comparison curves between predicted values and real values of each prediction model

表 7 展示了 8 种能耗预测模型的全局性能指标。根据 R^2 、MAE、RMSE 指标，机器学习类模型的准确性均优于 Sum。RF 和 XGB 实现了最优的表现，两者 R^2 为 0.97 和 0.97，MAE 值为 24.44 和 26.38，RMSE 值为 47.70 和 47.80。剩余模型的准确性排序为 DT，MPR，ANN，BPNN，SVM。

表 7 案例一全局指标表现

Table 7 Summary of the global performance metrics of eight models				
预测模型	R^2	MAE	RMSE	MAPE/%
ANN	0.95	31.25	61.65	47.13
BPNN	0.95	33.54	58.24	41.23
SVM	0.95	33.73	58.16	39.31
DT	0.93	28.03	70.31	11.90
RF	0.97	24.44	47.70	18.25
XGB	0.97	26.38	47.80	29.02
MPR	0.95	29.64	60.17	68.61
Sum	0.82	70.27	116.72	56.29

从对数相对误差箱型图（见图 3）中可以看出，DT 模型的对数相对误差最小，四分位间距（IQR）为 0.01~0.06，平均值为 0.35，之后是 RF 和 XGB 模型，RF 的 IQR 为 0.01~0.08，平均值为 0.38；XGB 的 IQR 为 0.01~0.08，平均值为 0.43，都具有较好的稳定性和准确性。ANN、BPNN 和 SVM 的对数相对误差稍小，IQR 分别为 0.02~0.12、0.02~0.10 和 0.02~0.10，均值分别为 0.46、0.44 和 0.47。MPR 和 Sum 模型的对数相对误差最大，IQR 分别为 0.01~0.09 和 0.04~0.20，均值分别为 0.50 和 0.56。综上，在冷冻水变流量案例中，DT、RF 和 XGB 在对数相对误差指标中表现出稳健的性能。




图3 对数相对误差箱型图

Fig.3 Boxplot of logarithmic relative errors for prediction models

图4给出了8个模型的对数平均误差的区间分布。DT模型取得了最低的对数相对误差分布，对数相对误差在0~0.1以内的占比为80.4%，RF和XGB模型紧随其后，分别为78.0%和77.2%。ANN、

BPNN、SVM、MPR和Sum模型的对数平均误差表现不如前者，对数平均误差在0~0.1以内占比为50.5%~76.2%。




图4 案例一对数相对误差区间分布

Fig.4 Distribution of logarithmic relative errors for prediction models

综合全局和局部指标的表现, 可以确定 RF 和 XGB 模型具有更好的准确性, 是制冷机房能耗预测的首选模型。DT、SVM、ANN 和 BPNN 模型在特定条件下可以作为互补选择, 因为它们在全局指标和局部指标中表现出竞争力。Sum 模型表现出高

误差分布, 泛化能力有限, 不适合在变流量运行工况下用作机房能耗建模。

4.3 案例二

图 5 展示了 7 种机器学习模型的能耗与 Sum 的预测结果。




图 5 预测能耗与实际能耗对比

Fig.5 Comparisons of the predicted energy consumption with the actual

表 8 预测模型模全局指标

Table 8 Summary of the global performance metrics of eight models				
预测模型	R ²	MAE	RMSE	MAPE/%
ANN	0.78	49.14	79.48	11.70
BPNN	0.86	43.84	67.02	10.38
SVM	0.85	44.00	69.83	10.17
DT	0.83	47.02	73.04	11.22
RF	0.88	37.24	60.87	8.85
XGB	0.89	38.56	59.52	9.29
MPR	-29196.51	1857.14	30650.46	326.22
Sum	0.82	47.77	77.05	10.82

表 8 展示了 8 种能耗预测模型的全局性能指标。根据 R²、MAE、RMSE 指标, XGB 模型表现最佳, R² 为 0.89, MAE 为 38.56, RMSE 为 59.52;

RF 模型紧随其后, R² 为 0.88, MAE 为 37.24, RMSE 为 60.87。其余模型的预测准确度排序为: BPNN、SVM、DT、ANN、Sum 和 MPR。

由于 MPR 模型优于出现极端异常值导致 R² 为-29196.51, MAE 为 1857.14, RMSE 为 30650.46, MAPE 为 326.22%表明模型预测失败, 下文也不再对其进行分析和讨论。

图 6 展示了除 MPR 外 7 个模型的对数相对误差的箱形图分布。RF 模型的对数相对误差最小, IQR 为 0.02~0.10, 平均值为 0.09; 之后是 XGB 模型和 SVR 模型, IQR 为 0.02~0.11 和 0.02~0.12, 平均值同为 0.09。BPNN、ANN 和 Sum 的对数相对误差稍小, IQR 分别为 0.03~0.13、0.02~0.12 和 0.03~0.12, 平均值同为 0.10。DT 模型的对数相对误差最大, IQR 为 0.02~0.15, 平均值为 0.11。综上, 在冷冻水定流量案例中 RF 和 XGB 在最小化

对数相对误差方面表现出稳健的性能。




图 6 对数相对误差箱型图

Fig.6 Boxplot of Logarithmic Relative Errors for Forecasting Models in Case2

图 7 给出了 7 个模型的对数相对误差的区间分布。RF 模型的对数相对误差分布最小，在 0~0.1 以内占比为 74.6%；其次是 XGB 模型，对数相对误差在 0~0.1 以内占比为 70.8%；ANN、BPNN、SVM、DT 和 Sum 模型有 63.0%~70.4% 的对数相对误差在 0~0.1 以内。相比之下 DT 和 Sum 模型表现

出最大的对数相对误差分布，在 0.5~1.0 以内的对数相对误差占比高达 2.1%和 2.5%。

上述结果表明，RF 和 XGB 在定流量工况制冷机房能耗预测任务中也取得了最优的准确性和稳定性，BPNN、SVM、DT、ANN 取得了次等的表现。




图 7 案例一对数相对误差区间分布

Fig.7 Interval-wise distribution of logarithmic relative errors

5 结论

针对制冷机房短时能耗计算传统方法的局限,本文提出一种基于机器学习算法的制冷机房能耗预测模型,由制冷机房的历史运行数据训练得到。该模型只需8个输入变量即可预测机房短时能耗,为工程师评估制冷机房能耗和能效,验证群控策略节能效果提供了一种实用工具。主要研究结论如下:

(1) 综合全局与局部指标结果,RF和XGB模型在冷冻水变流量与定流量两种工况下的制冷机房能耗预测中均取得最优精度,优于其他五种机器学习模型(BPNN、SVM、DT、ANN和MPR)且显著优于传统经验累加公式,建议作为优选方法。

(2) MPR模型在案例一中RMSE、MAPE和LRE指标偏高,在案例二因极端异常值导致预测失败,说明该方法容易出现过拟合现象,不建议作为制冷机房短时能耗预测方法。

(3) DT模型相比于其他机器学习模型在案例一种表现出最低的LRE分布,但在案例二中表现出最高的LRE分布,表明其预测误差的不稳定,建议作为辅助参考方法。

参考文献:

- [1] 清华大学建筑节能研究中心.中国建筑节能年度发展研究报告 2023(公共建筑专题)[M].北京:中国建筑工业出版社,2023.
- [2] L Pérez-Lombard, J Ortiz, C Pout. A review on buildings energy consumption information[J]. *Energy and Buildings*, 2008,(40):394-398.
- [3] M González-Torres, L Pérez-Lombard, JF Coronel, et al. A review on buildings energy information: trends, end-uses, fuels and drivers[J]. *Energy Reports*, 2022,(8):626-637.
- [4] JA Borja-Conde, JM Nadales, JG Ordonez, et al. Efficient management of HVAC systems through coordinated operation of parallel chiller units: An economic predictive control approach[J]. *Energy and Buildings*, 2024,(304):113879.
- [5] Yundan Liao, Gongsheng Huang. A hybrid predictive sequencing control for multi-chiller plant with considerations of indoor environment control, energy conservation and economical operation cost[J]. *Sustainable Cities and Society*, 2019,(49):101616.
- [6] Shanshuo Xing, Jili Zhang. Chiller-pump system optimisation method for minimum energy operation based on multi-objective evolutionary algorithm[J]. *Applied Thermal Engineering*, 2022,(208):118150.
- [7] Shanshuo Xing, Jili Zhang, Shian Li, et al. Delivering holistic energy-saving operation for heterogeneous all-parallel chiller plant systems through two-stage optimization assisted by input convex neural networks[J]. *Applied Energy*, 2024,(376):124208.
- [8] Lu Lu, W Cai, YC Soh, et al. Global optimization for overall HVAC systems—Part II problem solution and simulations[J]. *Energy Convers Manag*, 2005,46(7-8): 1015-1028.
- [9] Chengliang Fan, Xiaoqing Zhou. Model-based predictive control optimization of chiller plants with water-side economizer system[J]. *Energy and Buildings*, 2023, (278):112633.
- [10] Li Y, Pan Q, Wang, Z. Huang. A non-cooperative game-based distributed optimization method for chiller plant control[J]. *Building Simulation*, 2022,(15):1015-1034.
- [11] L Wang, E W M Lee, R K K Yuen, et al. Cooling load forecasting-based predictive optimisation for chiller plants[J]. *Energy and Buildings*, 2019,(198):261-274.
- [12] Z Chiam, A Easwaran, D Mouquet, et al. A hierarchical framework for holistic optimization of the operations of district cooling systems[J]. *Appl Energy*, 2019,(239):23-40.
- [13] Kun He, Qiming Fu, You Lu, et al. Predictive control optimization of chiller plants based on deep reinforcement learning [J]. *Journal of Building Engineering*, 2023,(76):107158.
- [14] L Yao, J-H Huang. Multi-objective optimization of energy saving control for air conditioning system in data center[J]. *Energies*, 2019,12(8):1474.
- [15] Jing Zhao, Dehan Liu, Xiulian Yuan, et al. Model predictive control for the ice-storage air-conditioning system coupled with multi-objective optimization[J]. *Applied Thermal Engineering*, 2024,(243):122595.
- [16] Z Ma, S Wang. Supervisory and optimal control of

- central chiller plants using simplified adaptive models and genetic algorithm[J]. *Applied Energy*, 2011,88(1): 198-211.
- [17] M Karami, L Wang. Particle Swarm optimization for control operation of an all-variable speed water-cooled chiller plant[J]. *Appl Therm Eng*, 2018,(130):962-978.
- [18] A Kusiak, M Li, F Tang. Modeling and optimization of HVAC energy consumption[J]. *Applied Energy*, 2010,87(10):3092-3102.
- [19] A Beghi, L Cecchinato, G Cusi, et al. A PSO-based algorithm for optimal multiple chiller systems operation[J]. *Appl. Therm. Eng*, 2012,(32):31-40.
- [20] Yiqun Zhu, Quan Zhang, Liping Zeng, et al. An advanced control strategy for optimizing the operation state of chillers with cold storage technology in data center [J]. *Energy and Buildings*, 2023,(301):113684.
- [21] Y Liao, G Huang. A hybrid predictive sequencing control for multi-chiller plant with considerations of indoor environment control, energy conservation and economical operation cost[J]. *Sustainable Cities and Society*, 2019,(49):101616.
- [22] Y Yao, DK Shekhar. State of the art review on model predictive control (MPC) in Heating Ventilation and Air-conditioning (HVAC) field[J]. *Build. Environ*, 2021,(200):107952.
- [23] J Zhao, L Shi, J Li, et al. A model predictive control regulation model for radiant air conditioning system based on delay time[J]. *Build. Eng*, 2022,(62):105343.
- [24] J Zhao, J Li, Y Shan, Research on a forecasted load-and time delay-based model predictive control (MPC) district energy system model[J]. *Energy Build*, 2021,(231):110631.
- [25] Yiqun Zhu, Quan Zhang, Liping Zeng, et al. An advanced control strategy for optimizing the operation state of chillers with cold storage technology in data center[J]. *Energy and Buildings*, 2023,(301):113684.
- [26] Y Wang, X Jin, X Fang. Rapid evaluation of operation performance of multi-chiller system based on history data analysis[J]. *Energy Build*, 2017,(134):162-170.
- [27] Yijun Wang, Xinqiao Jin, Zhimin Du, et al. Evaluation of operation performance of a multi-chiller system using a data-based chiller model[J]. *Energy and Buildings*, 2018,(172):1-9.
- [28] Behzad Salimian Rizi, Afshin Faramarzi, Amanda Pertzborn, et al. Forecasting operation of a chiller plant facility using data-driven models[J]. *International Journal of Refrigeration*, 2024,(167):70-89.
- [29] Sundar Raj Thangavelu, Aung Myat, Ashwin Khambadkone. Energy optimization methodology of multi-chiller plant in commercial buildings[J]. *Energy*, 2017,(123):64-76.
- [30] Lu Lu, W Cai, Y S Chai, et al. Global optimization for overall HVAC systems — Part I problem formulation and analysis[J]. *Energy Convers. Manage*, 2005,46(7-8): 999-1014.
- [31] J E Braun. Methodologies for the Design and Control of Central Cooling Plants[D]. Madison: University of Wisconsin-Madison, 1988.
- [32] Yijun Wang, Xinqiao Jin, Zhimin Du, et al. Evaluation of operation performance of a multi-chiller system using a data-based chiller model[J]. *Energy and Buildings*, 2018,(172):1-9.
- [33] Mohd Herwan Sulaiman, Zuriani Mustaffa. Chiller energy prediction in commercial building: A metaheuristic-Enhanced deep learning approach[J]. *Energy*, 2024,(297):131159.
- [34] Yung-Chung Chang. Sequencing of chillers by estimating chiller power consumption using artificial neural networks[J]. *Building and Environment*, 2007,42(1):180-188.
- [35] Zhaohui Liu, Hongwei Tan, Duo Luo, et al. Optimal chiller sequencing control in an office building considering the variation of chiller maximum cooling capacity[J]. *Energy and Buildings*, 2017,(140):430-442.
- [36] J M Gordon, K C Ng, H T Chua. Centrifugal chillers: thermodynamic modelling and a diagnostic case study [J]. *Int. J. Refrig*, 1995,18(4):253-257.
- [37] COMSTOCK M C, BRAUN J E. Development of analysis tools for the evaluation of fault detection and diagnostics in chillers, ASHRAE Research Project RP-1043[R]. Atlanta: American Society of Heating, Refrigerating and Air-Conditioning Engineers, Inc, 1999.
- [38] Y C Chang, C Y Chen, J T Lu, et al. Verification of

- chiller performance promotion and energy saving [J]. Engineering, 2013,(5):141-145.
- [39] Mathieu Bourdeau, Xiao qiang Zhai, Elyes Nefzaoui, et al. Patrice Chatellier, Modeling and forecasting building energy consumption: A review of data-driven techniques[J]. Sustainable Cities and Society, 2019,(48):101533.
- [40] Muhammad Waseem Ahmad, Monjur Mourshed, Yacine Rezgui. Trees vs Neurons: Comparison between random forest and ANN for high-resolution prediction of building energy consumption[J]. Energy and Buildings, 2017,(147):77-89.
- [41] Chengliang Fan, Yunfei Ding, Yundan Liao. Analysis of hourly cooling load prediction accuracy with data-mining approaches on different training time scales[J]. Sustainable Cities and Society, 2019,(51): 101717.
- [42] B Schölkopf, A J Smola. Learning with kernels: support vector machines, regularization, optimization, and beyond[M]. Cambridge, Massachusetts: The MIT Press, 2001.
- [43] T Hastie, R Tibshirani, J H Friedman. The elements of statistical learning[M]. New York: Springer-Verlag, 2003.
- [44] I Steinwart, A Christmann. Support vector machines[M]. New York: Springer, 2008.
- [45] N Cristianini, J Shawe-Taylor. An introduction to support vector machines and other kernel-based learning methods[M]. New York: Cambridge University Press, 2000.
- [46] J-S Chou, D-K Bui. Modeling heating and cooling loads by artificial intelligence for energy-efficient building design[J]. Energy Build, 2014,(82):437-446.
- [47] Maxim Shcherbakov, Valeriy Kamaev, Nataliya Shcherbakova. Automated Electric Energy Consumption Forecasting System Based On Decision Tree Approach[J]. IFAC Proceedings, 2013,(46)9:1027-1032.
- [48] L Breiman. "Random forests"[J]. Mach Learn, 2001, 45(1):5-32.
- [49] M Khalil, A S McGough, Z Pourmirza, et al. Machine learning, deep learning and statistical analysis for forecasting building energy consumption - A systematic review[J]. Eng. Appl. Artif. Intel, 2022,(115):105287.
- [50] B Jiang, Z Cheng, Q Hao, et al. A building energy consumption prediction method based on random forest and ARMA[C]. Chinese Automation Congress (CAC), 2018:3550-3555.
- [51] Z Wang, Y Wang, R Zeng, et al. Random forest based hourly building energy prediction[J]. Energ. Buildings, 2018,(171):11-25.
- [52] F Smarra, A Jain, T De Rubeis, et al. Data-driven model predictive control using random forests for building energy optimization and climate control[J]. Applied Energy, 2018,(226):1252-1272.
- [53] T Chen, C Guestrin. XGBoost: a scalable tree boosting system[C]. Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining, ACM, 2016:785-794.
- [54] M Al-Rakhami, A Gumaei, A Alsanad, et al. An ensemble learning approach for accurate energy load prediction in residential buildings[J]. IEEE Access, 2019,(7):48328-48338.
- [55] L T Le, H Nguyen, J Zhou, et al. Estimating the heating load of buildings for smart city planning using a novel artificial intelligence technique PSO - XGBoost[J]. Appl. Sci., 2019,(9):2714.
- [56] Chengliang Fan, Yunfei Ding. Cooling load prediction and optimal operation of HVAC systems using a multiple nonlinear regression model[J]. Energy and Buildings, 2019,(197):7-17.
- [57] Ting Lan, Rong Hu, Qi Tang, et al. A multivariate nonlinear regression prediction model for the performance of cooling tower assisted ground source heat pump system[J]. Energy Conversion and Management, 2025,(325):119333.