

基于AOBP的空调能耗特征标签模型与预测方法

任禹丞¹,王雨薇²,郑 杨²,杨子跃²,刘京易²

(1. 国网江苏省电力有限公司,南京 210000;2. 国网江苏省电力有限公司 镇江供电公司,江苏 镇江 212002)

摘要:在当前全球能源和环境危机不断加剧,同时空调能耗在整个建筑能源消耗中占据很大比例背景下,精确预测空调能耗对于制定有效的节能政策、优化能源利用、减轻能源压力以及降低碳排放至关重要。提出一种基于空调使用行为概率模型的数据驱动空调能耗预测方法。首先,分析了空调能耗与空调使用者行为、环境参数、时间、建筑等因素之间的关系,构建了建筑空调能耗分析特征标签体系,涵盖了空调使用行为、环境、时间和建筑特征等多个维度。接着,引入了空调使用行为概率模型作为影响因素,以反映建筑环境、空调使用者和能源系统之间的实时交互。该模型考虑了策略、时间、事件和外部刺激的影响,较全面地估计了空调使用情况。最后,利用粒子群优化算法对长短时记忆网络进行优化,并在不同建筑物和空调类型下进行能耗预测。仿真实验结果表明,提出的数据驱动空调能耗预测方法在提高预测性能方面取得了显著进展,但计算时间也相应增加。

关键词:空调能耗预测;空调使用行为概率;数据驱动;改进长短时记忆网络

Feature labeling model and prediction method for air conditioning energy consumption based on AOBP

REN Yucheng¹, WANG Yuwei², ZHENG Yang², YANG Ziyue², LIU Jingyi²

(1. State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210000, China; 2. Zhenjiang Power Supply Company, State Grid Jiangsu Electric Power Co., Ltd., Zhenjiang 212002, China)

Abstract: Against the backdrop of the escalating global energy and environmental crisis, accurate prediction of air conditioning energy consumption is crucial for formulating effective energy-saving policies, optimizing energy utilization, reducing energy pressure, and reducing carbon emissions, as air conditioning energy consumption accounts for a large proportion of the entire building energy consumption. A data-driven air conditioning energy consumption prediction method is proposed based on a probability model of air-conditioning occupant behavior. Firstly, based on the analysis of the relationship between air conditioning energy consumption and factors such as air-conditioning occupant behavior, environmental parameters, time, and building, a feature label system for building air conditioning energy efficiency analysis is further constructed, covering multiple dimensions such as air conditioning occupant behavior, environment, time, and building characteristics. Secondly, the air-conditioning occupant behavior probability (AOBP) model is introduced as a factor to reflect the real-time interaction between the building environment, air conditioning occupants, and energy systems. This model considers the effects of strategy, time, events, and external stimuli, thus providing a more comprehensive estimation of air conditioning usage. Finally, particle swarm optimization algorithm is utilized to optimize the long short term memory network (LSTM) and to predict energy consumption across various building types and air conditioning systems. The simulation experiment results show that the proposed data-driven air conditioning energy consumption prediction method has made significant progress in improving prediction performance, but the calculation time has also correspondingly increased.

Key words: air-conditioning energy consumption prediction; air-conditioning occupant behavior probability; data driven; improving long short-term memory network

0 引言

在当今全球能源和环境危机不断加剧的背景下,对能源消耗进行有效管理变得尤为紧迫^[1]。在建筑领域,空调系统作为主要的能源消耗者之一,

在整个能源利用中扮演着至关重要的角色^[2]。据统计,全球建筑行业约占总能源消耗的40%^[3],其中空调能耗占据了相当大的比例。因此,精确预测空调能耗不仅是降低碳排放、优化能源利用的关键一步,更是制定有效的节能政策、减轻能源压力的重要基础^[4-5]。

空调系统在建筑中的能耗占比较大,准确预测

收稿日期:2025-06-05;修回日期:2025-09-08

基金项目:国网江苏省电力有限公司科技项目(J2023176)

空调能耗可以帮助建筑管理者制定有效的节能管理策略,优化能源利用,降低能耗成本^[6]。文献[7]提出一种基于灰色多元线性回归的空调能耗预测模型,具有较高的能耗预测精度。文献[8]从公共建筑大数据预处理、负荷预测算法以及在空调系统节能运行应用等方面进行了相关的研究。文献[9]对建筑采暖空调能耗线性和非线性快速预测模型进行探讨,得到仅需极少次数的模拟即可得到良好的预测效果的有限点下的建筑空调能耗快速预测方法。上述传统的预测方法往往基于静态模型或统计方法,无法充分考虑到建筑环境、居民行为以及能源系统之间的复杂交互关系,因此在当前技术水平下,空调能耗的预测仍然面临着一些挑战。

此外,基于神经网络的空调能耗预测方法现在已经成为了研究的热点问题,该方法利用神经网络模型来分析建筑环境、居民行为和外部因素等多个因素对空调能耗的影响,从而实现对空调能耗的准确预测。文献[10]等提出了一种深度学习的大型建筑中央空调能耗预测系统,通过硬件和软件的功能结合,实现大型建筑中央空调的能耗预测。文献[11]利用人工神经网络具有数据处理、计算能力强、鲁棒性高的优点,提出了基于神经网络的空调能耗预测优化模型构建方法,具有更好的预测精度。文献[12]建立了基于深度信念网络的建筑空调能耗预测模型,采取实验和经验相结合的方法确定预测模型的最佳隐藏层层数和隐藏层节点数,从而得到模型最优参数。但现有方法大多没有综合考虑时间、事件和外部刺激等因素对空调使用的影响,导致预测结果精度不高,在一些复杂情况下无法满足实际需求。

空调使用行为概率模型(air-conditioning occupant behavior probability, AOBP)是一种用于描述多个空调使用者群体在某一空间(如建筑物或社区)内的行为和互动规律的模型^[13]。该模型通常基于统计学原理和行为科学研究,通过分析空调使用者群体的特征、日常行为习惯、社会互动等因素,来预测他们在特定环境下的行为概率分布。通过空调使用概率模型,可以深入分析空调使用者群体在不同时间段内的活动规律、偏好和行为选择^[14]。这些信息可以帮助建立更准确的空调能耗预测模型,从而更好地理解和控制能耗来源,因此本文将 AOBP 模型结合到空调能耗预测方法中进行改进。

针对上述问题,本文对传统的长短时记忆(long short term memory, LSTM)神经网络进行了优化,提出了一种基于空调使用行为概率模型的数据驱动空调能耗预测方法。本文旨在利用空调使用行为

概率模型和数据驱动方法,提高空调能耗预测的准确性和实用性,更加全面地估计空调的使用情况。

1 空调能耗特征因素及标签构建

空调能耗受多种因素影响,掌握这些因素有助于优化空调使用和节能。其中,影响空调能耗的特征因素主要包括空调使用者相关的参数、环境相关参数、时间相关参数、设备与建筑物相关参数。

空调使用者行为对空调能耗影响,主要包括空调使用频率、持续时间、启动/关闭时段的概率分布等。

环境参数对空调能耗影响,主要包括室内外空气温度、室内外空气相对湿度等。

时间维度对空调能耗影响,从日周期性、周周期性、节假日特性、季节变化4个方面进行分析。

设备与建筑物特征对空调能耗影响,主要包括空调系统类型、采暖空调面积、建筑类型和建筑面积等。

根据空调能耗特征因素的分析,构建能耗特征标签体系,主要包括空调使用行为标签、环境参数标签、时间特征标签、设备与建筑特征标签。通过这些标签体系,可以更精确地分析和预测空调能耗,从而实现更加高效和节能的空调管理。

(1) 空调使用行为标签

空调使用行为标签主要涵盖空调使用频率、持续时间、启动/关闭时段的概率分布标签。该标签反映空调使用者的空调使用行为特性。根据人们的使用习惯(如高频使用、低频使用),将人们分为不同群体,并量化其使用行为对能耗的影响,进而预测和分析能耗波动。

(2) 环境参数标签

环境参数标签主要涵盖室内外空气温度、室内外空气相对湿度等标签。该标签通过实时监测环境温度和湿度,评估这些因素对空调负荷的影响,帮助优化空调的使用模式,降低能耗。例如,温度和湿度较高时,空调需要更多能量来维持舒适的室内环境。

(3) 时间特征标签

时间特征标签主要涵盖日周期性、周周期性、节假日特性、季节变化等标签。该标签关注不同时间段(如白天、夜晚、高峰期、低谷期等)的空调使用规律,为能耗管理提供依据。节假日和季节变化带来的负荷波动也是重要的能耗特征,需要考虑在标签中。

(4) 设备与建筑物特征标签

设备与建筑物特征标签主要涵盖空调系统类型、采暖空调面积、建筑类型和建筑面积等标签。该标签关注空调系统类型(如中央空调、分体空

调)、建筑类型(如住宅、办公、商业)、建筑面积和采暖空调面积等因素。通过评估空调设备的能效和建筑特性,识别导致高能耗的设备或建筑,有助于制定节能策略。

2 空调使用者行为概率模型

2.1 空调使用行为概率模型定义

经过长期研究和实践验证,发现尤其在能效评估和建筑设计中,温度被认为是影响空调能耗的最关键因素。其中,室内外空气温度往往被认为是最主要和决定性的影响因素。由于室内空气温度比室外空气温度更直接地与人体舒适度相关,本节将室内空气温度作为AOBP模型主要的环境因素。AOBP模型定义见式(1),该概率模型可通过室内空气温度和空调控制策略作为模型输入,从而构建空调使用者行为作为模型输出。

对于空调能耗预测,本文对AOBP模型建模定义如下

$$P_{(t_i-t_{i+1})}=f(x,t,\pi) \quad (1)$$

式中: x 为平均室内空气温度; t 为时间; π 为从时间 t_i 到 t_{i+1} 的空调控制策略。此外, P 定义为空调使用行为概率,通常包括空调使用频率、持续时间、启动/关闭时段的概率分布; i 为迭代时间索引值,如果 i 为8,则 t_{i-1} 、 t_i 、 t_{i+1} 分别为 $t_{07:00}$ 、 $t_{08:00}$ 和 $t_{09:00}$;本文中开始和结束时刻为整数小时。

2.2 空调使用行为概率模型建模

为了更加适合在线应用,本文使用了统计模型来估计群体行为的概率。

为了评估整体空调使用行为,本文使用的环境数据表示建筑物内记录的平均数据。测量点分布在所有空调区域,并通过在每个走廊和房间安装温度传感器来实现。室内空气温度定义为所有测量点的平均值。此外,额外激励(室内空气温度)的时间范围设置为 t_{i-1} 到 t_i , P 的时间范围设置为 t_i 到 t_{i+1} ,以确保通过使用前一时间的环境参数来实现预测。

首先在不考虑完全不规则的随机行为情况下,模型的主要类别如下所示:

(1) 主要影响因素是时间或事件,如式(2)所示

$$P_{(T_1-T_2)} = \begin{cases} 1 & \text{特定事件或时间} \\ 0 & \text{其他} \end{cases} \quad (2)$$

(2) 主要影响因素是额外激励,如式(3)到式(5)所示

$$S = k \times \Delta I^n \quad (3)$$

$$P \propto \Delta S \quad (4)$$

$$P_{(t_i-t_{i+1})} = f(I_{(t_{i-1}-t_i)}) = [ax + b], \left[\frac{a + b(X - X_0)^n}{1 + (X - X_0)^n} \right], \dots \quad (5)$$

式中: S 为心理学的数学度量(代表使用者的不适感强度); I 为物理参数(额外激励); ΔI 为室内温度偏离舒适温度的幅度,并且指数 k 和 n 对于不同人的感官具有不同的值; a 和 b 为固定的系数值,由不同的激励与场景确定。式(3)基于热舒适理论,量化室内温度偏离舒适温度时引发的不适感强度,不适感随偏离幅度的增大而增强; P 为行为的数学度量(基于不适感采取调节空调行为的概率); X 为特定激励(在本文中该激励是室内空气温度); X_0 为感到舒适的激励值。式(4)、式(5)表示了行为和心理之间的关系。

3 数据驱动空调能耗预测方法

空调能耗具有强烈的时间依赖性(当前能耗受过去数小时甚至数天的状态影响)、周期性(日、周、季节)以及动态性(行为、环境实时变化)。为了提高精度,加快收敛速度,避免过拟合,本文使用反馈神经网络代替传统的前馈神经网络和使用群智能算法进行优化。

反馈神经网络不同于前馈神经网络,它具有很强的联想记忆能力和优化计算能力。常用的模型结构包括Prophet、自回归移动平均(autoregressive integrated moving average, ARIMA)模型、长短时记忆(long short-term memory, LSTM)神经网络。然而Prophet工具包适用于预测长趋势分解,对长序列复杂动态模式捕捉能力有限,ARIMA难以处理强非线性、多变量输入,预测趋势不准确,同样也不适用于长序列问题。因此,在本文中选择了反馈算法的经典代表LSTM神经网络。

LSTM通过其门控机制(输入门、遗忘门、输出门)和细胞状态,能够有效学习长期依赖关系,记忆和遗忘相关信息,处理变长输入序列,捕捉复杂的非线性动态模式。这些特性使其非常适合对具有显著时间动态性、受历史状态影响大的空调能耗序列预测问题进行建模。此外,本文构建的特征标签体系(AOBP, Env, Time, Bld)本身是按时间序列组织的多变量输入,LSTM天然适合处理这类时空数据,其能够学习这些特征在时间维度上的演变规律及其与未来能耗的复杂映射关系。在此基础上,本文对LSTM进行了优化,选取粒子群优化算法(particle swarm optimization, PSO)来优化LSTM神经网络的参

数。使用PSO进行优化的优点是可以更快找到神经网络权值和阈值等超参数的最优解,进一步提高预测精度。具体步骤如下:首先,将LSTM神经网络的权值和阈值表示为算法中的粒子的位置,作为优化问题的解;然后,利用算法模拟群体的协作与竞争机制,通过更新粒子的位置和速度,迭代搜索最优解,目标是 minimized 网络的损失函数或提高其性能;最终,经过多次迭代,找到一组最优权值和阈值,提升神经网络的准确度。此外,它还可以提高神经网络的收敛速度和输出精度。除了理论上的优势外,本文在下一节还给出了算例来进行验证。

在讨论算法的优缺点时,需要保证其他条件的一致性,重点是输入和输出的一致性。输出是空调能耗,而输入在本文中可以分为两种类型的输入系统,包括通用输入和新型输入。通用输入包括时间特征标签(日周期性、周周期性、节假日特性、季节变化等)、环境参数标签(室内空气温度、室外空气温度等);新型输入包括空调使用行为标签(空调使用频率、持续时间、启动/关闭时段的概率分布等)和其他通用输入包括设备及建筑特征标签(空调系统类型、采暖空调面积、建筑类型和建筑面积等)。在本文中,训练集与测试集的比例为7:3。此外,对输入和输出要进行归一化处理。如果输入的数量为 m ,则隐藏层的数量为 $(2m+1)$ 。此外,神经网络最大迭代次数设置为1 000,学习率设置为0.01,动量因子设置为0.01,最小性能梯度为 10^{-6} 。PSO的初始种群大小取为10,最大迭代次数取为30。

由于LSTM和PSO算法已经得到了广泛而充分的研究,因此本文中并没有扩展其具体实现过程。然而,对于初始PSO,使用随机生成的数据作为初始种群信息,这将难以保留种群的多样性,导致算法易陷入局部最优以及收敛慢问题。因此,本文引入混沌映射进行改进。常见的混沌映射包括Logistic映射、Singer映射等,本文选择一种数值分布均匀的映射,即Circle映射作为优化方法,对初始PSO进行优化,从而均匀初始化种群、增强全局搜索能力、以及避免早熟收敛。具体步骤如下:首先,使用Circle映射调整每个粒子的当前位置和速度,以增强其搜索的多样性和全局探索能力;然后,通过更新位置和速度,帮助算法更好地跳出局部最优解,寻找全局最优解;最终,经过多次迭代,优化算法的性能并提高了收敛速度和准确性。此外,为了优化神经网络的权值和阈值,本文使用了自适应权值过程,如下所示

$$w = w_{\min} + (w_{\max} - w_{\min}) \times mm \times \exp\left(\frac{-t}{G_{\max}}\right) \quad (6)$$

式中: w 为权重; $w_{\max}$ 为1; $w_{\min}$ 为0; mm 为调整系数;

t 为迭代次数; $G_{\max}$ 为种群最大进化代数。

在搜索早期(w 较大)侧重全局探索,后期(w 较小)侧重局部开发,平衡搜索能力。改进的算法分别命名为混沌映射与自适应权重优化的粒子群算法(CISA-PSO-LSTM)。

为了进一步评估能耗预测性能,本文使用4个评价指标,包括决定系数 R 、平均绝对百分比误差 M_{APE} 、均方根误差 R_{MSE} 、均方根误差的变异系数 C_{V-RMSE} ,分别如下所示

$$R(E_a, E_b) = 1 - \frac{\sum_{c=1}^{c=n} (E_{a,c} - E_{b,c})^2}{\sum_{c=1}^{c=n} (\bar{E}_b - E_{a,c})^2} \quad (7)$$

$$M_{APE}(E_a, E_b) = \frac{\sum_{c=1}^{c=n} \left| \frac{E_{a,c} - E_{b,c}}{E_{b,c}} \times 100\% \right|}{n} \quad (8)$$

$$R_{MSE}(E_a, E_b) = \sqrt{\frac{\sum_{c=1}^{c=n} (E_{a,c} - E_{b,c})^2}{n}} \quad (9)$$

$$C_{V-RMSE}(E_a, E_b) = \frac{R_{MSE}(E_a, E_b)}{\bar{E}_b} \quad (10)$$

式中: c 为采样点; n 为所有采样点的数量; E_a 和 E_b 分别为预测和实际能耗数据; $\bar{E}_b$ 为平均实际能耗。

4 算例分析

为了验证该预测系统在不同建筑物和空调类型下的性能,本文首先选取了3个典型建筑物(住宅楼、商场楼及办公楼)作为研究对象,具体信息见表1。这些数据提供了不同建筑物和空调使用策略对能耗的影响,为进一步的能耗预测和优化提供了基础。同时,为了获取建筑物内空调能耗数据标签,部署智能插座、605A型号空调控制器(时间间隔1 min)和建筑能源管理系统(BEMS)监控空调设备的实时开关状态、运行功率/电流、设定温度。通过时间戳记录开关机事件,计算使用频率(单位时间开关次数)、持续时间(单次开机时长、日累计运行时长)、启动/关闭时段分布(统计不同时段开关机的概率)。通过在建筑物中安装型号为DS18B20的数字温度传感器(精度 $\pm 0.5^\circ\text{C}$)来获得室内环境数据,使用能耗监测系统记录能耗数据。室外环境数据从气象科学数据中心获得,该中心是中国气象局的共享门户,提供基础公共气象数据。此外,从系统时间戳直接提取或构造小时、星期、是否节假日、季节。从建筑图纸、设备手册或管理记录中获取空调类型、面积、建筑类型等。

表1 3个典型建筑的空调运行数据
Table 1 Air conditioning operation data of three typical buildings

建筑	运行时间	空调使用策略	空调使用行为概率
A (住宅楼)	冬季07:00—23:00	空调可以打开或关闭,并在冬季的任何时候进行调节。所有空调使用者都可以根据空气温度(热感觉)使用和控制空调。	$P=f(x)$ f 在不同时段会有不同的形式
	夏季	不使用	$P=0$
	春秋季	不使用	$P=0$
B (商场楼)	冬季08:00—22:00	所有空调将被打开,不再关闭(由管理员控制)	$P=1.0$
	冬季23:00—次日07:00	所有空调将关闭,不再打开(由管理员控制)	$P=0$
	冬季07:00—08:00和22:00—23:00	开放和关闭时间为07:30和22:30(由管理员控制)	$P=0.5$
	夏季	不使用	$P=0$
	春秋季	不使用	$P=0$
C (办公楼)	冬季08:00—22:00	所有空调将被打开,不再关闭(由管理员控制)	$P=1.0$
	冬季23:00—次日07:00	所有空调将关闭,不再打开(由管理员控制)	$P=0$
	冬季07:00—08:00和22:00—23:00	开放和关闭时间为07:30和22:30(由管理员控制)	$P=0.5$
	夏季08:00—22:00	所有空调将被打开,不再关闭(由管理员控制)	$P=1.0$
	夏季23:00—次日07:00	所有空调将关闭,不再打开(由管理员控制)	$P=0$
	夏季07:00—08:00和22:00—23:00	开放和关闭时间为07:30和22:30(由管理员控制)	$P=0.5$
	春秋季	不使用	$P=0$

所有数据采集自2023年1月1日至2023年12月31日,覆盖完整年度以包含季节变化。此外,本文对短时间(<3 h)缺失的温度数据,采用线性插值填补;对空调状态数据缺失,视为关闭状态或根据前后状态推断,长时间缺失段数据被剔除。为了避

免方法过拟合现象,本文采用了 K 折交叉验证进行数据仿真试验。

基于式(1)到式(3),以及建筑物的打开与关闭时间、空调的实际使用策略,可以计算出相应的AOBP,计算得到的结果见表2到表4。

表2 建筑A(住宅楼)的AOBP模型

时间	概率模型
冬季08:00—22:00	$P=0.5$
冬季20:00—07:00	$P=0$
冬季07:00—09:00和18:00—20:00	$P=1.0$
夏季和春秋季	$P=0$

表3 建筑B(商场楼)的AOBP模型

时间	概率模型
冬季08:00—22:00	$P=1.0$
冬季23:00—07:00	$P=0$
冬季07:00—08:00和22:00—23:00	$P=0.5$
夏季	$P=0$
春秋季	$P=0$

表4 建筑C(办公楼)的AOBP模型

时间	概率模型
冬夏季08:00—22:00	$P=1.0$
冬夏季23:00—次日07:00	$P=0$
冬夏季07:00—08:00和22:00—23:00	$P=0.5$
春秋季	$P=0$

根据空调使用行为与能耗之间的关系,可将AOPB模型主要分为线性函数模型和逻辑函数模型。线性函数模型适用于描述连续的能耗变化,而逻辑函数模型则更适合处理离散的、受限的行为模式(如开/关空调的概率)。这两种模型能够根据空调使用者的使用习惯和行为特征预测空调能耗。对于建筑物A,概率模型与外部温度有关。这种策略反映的数学模型为 S 形或 S 形的一部分(S 表示逻辑函数)。以供暖为例,这意味着当温度较低时,空调使用概率稳定且较高;而当温度较高时,空调使用概率稳定但较低。当温度居中时,空调使用概率的变化是剧烈的和不稳定的。对于建筑物B,在空调使用者可以自由控制和使用空调的时间内,概率模型同样显示为 S 形或部分 S 形。在其他时间,管理员将以统一的方式操作空调。对于建筑物C,概率模型是线性函数模型。本文通过不同建筑物的空调打开与关闭时间、空调实际使用策略搭建实验场景。根据所收集的数据来进行AOBP模型的拟

合,并且对未来的行为与能耗进行预测。

为进一步分析在增加了新的输入后改进算法的效果,设计了一个算例仿真实验进行比较。实验分为2组,每组包括3个样本建筑,即共6组实验。其中,含AOBP模型和不含AOBP模型的实验结果如表5、表6所示。根据表5中结果,所有的 R 值都在0.872 4至0.917 5之间,这意味着实验选取的方法均有较良好的拟合性能。但是对于本文所提出的改进后的方法,与传统的LSTM相比,明显拥有更加优良的预测性能,包括预测精度和运行时间。此外,由表6可知考虑AOBP模型的性能效果越好。

表5 6组对比试验的设置与结果(含AOBP模型)

Table 5 Results of the 6-group comparison test with AOBP model

实验编号	算法	R	R_{MSE}	M_{APE}	C_{V-RMSE}	时间/s
A-a	CISA-PSO-LSTM	0.912 0	2.126 9	13.90	0.153 5	28.63
A-b	LSTM	0.917 5	2.878 9	14.24	0.207 8	58.32
B-a	CISA-PSO-LSTM	0.910 2	3.186 6	14.68	0.229 9	20.25
B-b	LSTM	0.915 2	2.797 9	14.70	0.201 9	46.32
C-a	CISA-PSO-LSTM	0.889 9	18.912	15.53	0.400 3	13.89
C-b	LSTM	0.872 4	17.564	22.15	0.371 7	35.69

表6 6组对比试验的设置与结果(无AOBP模型)

Table 6 Results of the 6-group comparison test without AOBP model

实验编号	算法	R	R_{MSE}	M_{APE}	C_{V-RMSE}	时间/s
A-a	CISA-PSO-LSTM	0.910 2	2.246 5	14.10	0.1653	28.75
A-b	LSTM	0.909 8	2.995 0	14.78	0.2158	58.55
B-a	CISA-PSO-LSTM	0.909 5	3.328 8	14.95	0.2352	20.36
B-b	LSTM	0.901 2	2.985 0	15.20	0.2135	46.35
C-a	CISA-PSO-LSTM	0.868 5	19.250	16.21	0.4102	13.95
C-b	LSTM	0.856 2	18.125	22.85	0.3885	35.85

图1和图2展示了不同建筑物能耗数据的分布,将其数据进行归一化,并显示了数据集的中位数(实线)和平均值(虚线)。通过对图1的分析,可以判断出不同建筑物在空调能耗上的差异性,与建筑类型、外部气候条件等因素有关。其中C建筑物的能耗数据较大幅偏离中位数或平均值,则可能该建筑物的空调系统可能存在特殊情况(如使用不当或故障等)。通过图2结果,可以得出建筑物B和建筑物C在空调能耗预测中表现较好, $MAPE$ 和 $CV-RMSE$ 值越高,意味着该建筑物的空调能耗优化效果越好。总之,该结果较全面地评估建筑物的空调能耗指标,并为未来的空调能耗优化和预测模型改进提供依据。




图1 不同建筑物的空调能耗数据分布

Fig. 1 Distribution of air conditioning energy consumption data for different buildings




图2 不同建筑物的空调能耗数据 M_{APE} 与 C_{V-RMSE} 比较

Fig. 2 Comparison of air-conditioning energy consumption data M_{APE} and C_{V-RMSE} for different Buildings

5 结束语

本文提出了一种基于空调使用行为概率模型的数据驱动空调能耗预测方法。首先,本文分析了影响空调能耗特征因素之间的关系,构建了空调能耗特征标签体系,全面分析建筑空调能耗与空调使用者行为、环境参数、时间因素及设备与建筑属性之间的耦合关系。接着,引入了AOBP模型,以动态反映建筑环境、空调使用者和能源系统之间的实时交互。通过考虑策略、时间、事件和额外输入等因素,AOBP模型能够更准确地刻画空调使用情况,提高了预测精度。此外,本文还利用改进的PSO算法对LSTM进行了优化,并在不同建筑物和空调类型下进行了能耗预测。通过建立融合AOBP的特征标签体系,并结合PSO算法和LSTM网络,本文提出的数据驱动空调能耗预测方法。该方法将AOBP作为关键输入引入数据驱动的能耗预测模型中,能够更好地捕捉时间序列数据的规律性,提高了预测的准确性和稳定性。最后,本文通过算法实例验证了所提出方法的有效性和性能优势。结果表明,与传统

方法相比,本文方法在空调能耗预测性能方面取得了显著进展,能够更准确地预测空调能耗,为节能减排提供了重要支持。

在空调能耗预测的基础上,有必要开展AOBP模型动态运行策略优化、能效故障诊断及用户行为引导的研究,构建“预测-决策”闭环框架支撑节能实践。

参考文献:

- [1] 齐崇霞. 基于人工智能的智能建筑能源管理系统优化研究[J]. 家电维修, 2024(4): 67-69.
QI Congxia. Optimization research on intelligent building energy management system based on artificial intelligence[J]. Appliance Repair, 2024(4): 67-69.
- [2] 葛罗, 冯焯, 胡凯, 等. 新型电力系统下空调负荷聚合建模及可控调潜力评估[J]. 浙江电力, 2023, 42(4): 45-53.
GE Luo, FENG Xuan, HU Kai, et al. Air conditioning load aggregation modeling and the schedulable potential evaluation in the context of new-type power system[J]. Zhejiang Electric Power, 2023, 42(4): 45-53.
- [3] 蔡伟光, 刘奇琪, 李睿, 等. 碳排放“双控”背景下的建筑能耗总量省际分配——基于公平与效率耦合的视角[J]. 干旱区资源与环境, 2023, 37(11): 100-109.
CAI Weiguang, LIU Qiqi, LI Rui, et al. Provincial allocation of total building energy consumption in the context of “double control” of carbon emissions: a perspective from coupling of equity and efficiency[J]. Journal of Arid Land Resources and Environment, 2023, 37(11): 100-109.
- [4] 段冠囡, 王岳人. 超高层建筑暖通空调能耗精准预测仿真[J]. 计算机仿真, 2018, 35(12): 317-320, 379.
DUAN Guannan, WANG Yueren. Simulation of HVAC energy consumption prediction for super high-rise building[J]. Computer Simulation, 2018, 35(12): 317-379.
- [5] 曹虎. 地铁通风空调系统的能耗预测和节能措施研究[J]. 企业科技与发展, 2022(11): 128-130.
CAO Hu. Research on energy consumption prediction and energy-saving measures of subway ventilation and air conditioning system[J]. Enterprise Science and Technology & Development, 2022(11): 128-130.
- [6] 白燕, 武璐璐, 贺引娥, 等. 基于动态温度调控的空调系统能耗预测[J]. 系统仿真学报, 2022, 34(2): 366-375.
BAI Yan, WU Lulu, HE Yine, et al. Energy consumption prediction of air conditioning system based on dynamic temperature regulation [J]. Journal of System Simulation, 2022, 34(2): 366-375.
- [7] 豆晨昊, 徐峰. 基于灰色多元线性回归的上海某办公建筑空调能耗预测模型[J]. 制冷与空调 (四川), 2021, 35(3): 352-359, 450.
DOU Chenhao, XU Feng. Air conditioning systems energy consumption prediction model of office buildings based on grey-multiple linear regression theory [J]. Refrigeration & Air Conditioning (Sichuan), 2021, 35(3): 352-359, 450.
- [8] 彭献永, 王波波, 张骞. 基于大数据的我国公共建筑空调负荷预测的研究进展[J]. 安徽建筑, 2019, 26(4): 11-14.
PENG Xianyong, WANG Bobo, ZHANG Qian. Research progress on air conditioning load prediction of public buildings in China based on big data [J]. Anhui Architecture, 2019, 26(4): 11-14.
- [9] 罗智星, 王逸群, 路逸晴, 等. 基于室内设计温度更新的建筑空调能耗快速预测方法研究[J]. 建筑节能 (中英文), 2021, 49(11): 28-35.
LUO Zhixing, WANG Yiqun, LU Yiqing, et al. Rapid prediction method of building air-conditioning energy consumption based on indoor design temperature update [J]. Building Energy Efficiency, 2021, 49(11): 28-35.
- [10] 冉均均, 袁磊. 基于深度学习的大型建筑中央空调能耗预测系统[J]. 自动化技术与应用, 2022, 41(12): 1-4.
RAN Junjun, YUAN Lei. Central air conditioning energy consumption prediction system for large buildings based on deep learning [J]. Techniques of Automation and Applications, 2022, 41(12): 1-4.
- [11] 于文涛, 栗越妍, 刘猷, 等. 基于神经网络的工厂能耗预测模型研究[J]. 仪器仪表标准化与计量, 2022(3): 22-24.
YU Wentao, LI Yueyan, LIU Xian, et al. Research on neural network-based energy consumption prediction model of HVAC system [J]. Instrument Standardization & Metrology, 2022, (3): 22-24.
- [12] 侯博文, 吴俊峰, 陈焕新, 等. 深度信念网络在建筑能耗预测领域的应用研究[J]. 制冷技术, 2021, 41(5): 72-77, 99.
HOU Bowen, WU Junfeng, CHEN Huanxin, et al. Research on application of deep belief network in building energy consumption prediction [J]. Chinese Journal of Refrigeration Technology, 2021, 41(5): 72-77, 99.
- [13] SHABRINA A, FAHRIANTO F, ANGGRAINI N. Estimation system of occupant behavior against the use of electricity using Bayes method and decision tree algorithm [C]. 2017 Second International Conference on Informatics and Computing (ICIC), 2017: 1-6.
- [14] MUN, SUN-HYE, KWAK, et al. A case study on the air-conditioner use of occupant behavior in apartment [J]. Journal of Korean Institute of Architectural Sustainable Environment and Building Systems, 2018: 12.

作者简介:

任禹丞(1990), 男, 江苏连云港人, 硕士, 高级工程师, 研究方向为综合能源, 电力需求侧响应;

王雨薇(1993), 女, 江苏镇江人, 硕士, 工程师, 研究方向为综合能源技术;

郑杨(1982), 男, 硕士, 江苏盐城人, 高级经济师, 研究方向为电力需求侧管理。

(责任编辑 水 鸥)