

文章编号: 1671-6612 (2024) 03-299-06

基于神经网络的地铁站冷负荷预测对比研究

刘舸争¹ 李舒宏² 胡远洋²

李新美³ 李媛¹ 于德涌¹ 王珩¹ 刘守超³ 陈诚³

(1. 深圳地铁建设集团有限公司 深圳 518000;

2. 东南大学能源与环境学院 南京 210096;

3. 南京福加自动化科技有限公司 南京 210046)

【摘要】 冷负荷预测是建筑节能的基础,然而输入的不同会影响神经网络的预测精度,且对新建筑进行负荷预测时需要数据的积累。为得到地铁站冷负荷预测的最佳输入并评估数据库迁移预测的可行性,基于实测数据,以常用的时间变量、气象变量和历史负荷作为待选输入,比较了反向传播神经网络和卷积神经网络在不同输入下及数据库逐步更新时的预测精度。结果表明:最佳输入变量与冷负荷的皮尔逊相关系数需大于0.5;另一方面,同类型建筑在预测初期可以基于数据库逐步替换实现预测,预测精度随着数据库的更新逐渐提升,且卷积神经网络表现出更好的预测表现。

【关键词】 负荷预测; 地铁站; 神经网络; 输入组合; 数据库更新

中图分类号 TU831.2 文献标志码 A

Research on Cooling Load Prediction of Subway Stations Based on Backpropagation Neural Network and Convolutional Neural Network

Liu Gezheng¹ Li Shuhong² Hu Yuanyang²

Li Xinmei³ Li Yuan¹ Yu Deyong¹ Wang Heng¹ Liu Shouchao³ Chen Cheng³

(1. Shenzhen Metro Construction Group Co., Shenzhen, 518000;

2. School of Energy and Environment, Southeast University, Nanjing, 210096;

3. Nanjing Fuca Automation Technology Co., Nanjing, 210046)

【Abstract】 Cooling load prediction forms the foundation of building energy conservation. However, the variation in input variables significantly influences the predictive accuracy of neural networks. Furthermore, predicting loads for new buildings necessitates the accumulation of data. This study aims to determine the optimal inputs for predicting subway station cooling loads and evaluate the feasibility of database migration predictions. Leveraging empirical data and considering commonly used time variable, meteorological factors, and historical loads as potential inputs, this research compares the predictive accuracy of Backpropagation Neural Network (BPNN) and Convolutional Neural Network (CNN) under different inputs and during progressive database updates. Results indicate that the optimal input variables for cooling load prediction should exhibit Pearson correlation coefficient with the load greater than 0.5. Moreover, for similar building types, initial predictions can be made by gradually replacing the database, showcasing an enhancement in predictive accuracy with each update. Notably, the CNN demonstrate

作者简介: 刘舸争 (1969-), 男, 本科, 高级工程师, E-mail: 653448513@qq.com

通讯作者: 刘守超 (1982-), 男, 本科, 工程师, E-mail: liusc@fuca-china.com

收稿日期: 2023-11-27

superior prediction performance throughout this process.

【Keywords】 Load prediction; Subway station; Neural network; Input combination; Database update

0 引言

随着“双碳”的逐步实现和城市的快速发展，约占世界总能耗 30% 的建筑模块的节能受到广泛的关注，而在建筑模块中，中央空调的能耗占很大一部分^[1-4]。研究者们从各个方面研究了中央空调的节能，包括前馈系统调节，储能节能设计，供需匹配等方面，而实现上述节能举措的基础是准确快速的建筑冷热负荷预测^[5-7]。与此同时，地铁站的能耗在整个建筑领域不容小觑，而其空调系统占其能耗的一半以上，因此对于地铁站实现精确的冷负荷预测对公共建筑节能意义重大^[8,9]。

现有的负荷预测的方法包括白箱模型、灰箱模型和黑箱模型，白箱模型多在建筑设计初期或评估节能措施时使用，灰箱模型虽比白箱模型简易，但仍需构建物理模型且依赖运行数据，而作为仅需要运行数据进行训练且无需复杂建模过程的黑箱模型之一的神经网络则受到了研究者的关注^[10-12]。

输入的选择对神经网络的精度提升至关重要，Jang 等强调了时间变量的引入对负荷预测精度提升的重要性，并指出若预测水平为小时，引入时刻变量可显著提升预测精度^[13]。Lee 等指出与冷热负荷相关的变量的引入会提高预测精度^[14]。对高相关性变量的寻找通常基于相关性分析，Kapetanakis 等以 0.5 为选择变量的阈值，指出不同气候区的建筑影响冷热负荷的变量不同，且对输入按阈值进行筛选有利于减小模型复杂度^[15]。类似地，Ling 等亦基于实验强调了输入变量选取对提升预测精度的重要性^[16]。

另一方面，相关研究表明，历史负荷的引入可进一步提升负荷预测的精度，祁鑫等基于某高校宿舍的实测历史负荷数据、温湿度数据对冷负荷进行了预测并得到了良好的预测结果^[17]。Ding 等指出输入参数的丰富对模型预测精度的有益提升并强调了历史负荷的引入对冷热负荷预测精度提升的重要性^[18]。何超等选取前三个时刻的历史负荷和室外温湿度作为输入，并基于深度双 Q 神经网络实现了对空调负荷的准确预测^[19]。肖紫薇等指出基于历史负荷预测建筑负荷可减小对外部信息的依赖并保证结论的通用性^[20]。

综上所述，基于神经网络的冷热负荷预测是实现建筑节能的基础，而现有预测缺少对输入变量进行最优选择而导致预测精度偏低，与此同时，引入历史负荷不但可以提升预测精度，也可降低对其余难获取数据的依赖，但缺少将历史负荷与气象变量、时间变量同时作为输入的预测研究。另一方面，当对缺乏运行数据的建筑进行基于神经网络的负荷预测时，通常会难以预测或预测精度低。基于此，本文基于两个地铁站的实测数据，以天气参数、时间参数和历史负荷为输入基础，通过比较不同输入组合下的预测精度确定了最佳输入，再基于该结果，分析两个地铁站站间运行数据替换的预测表现确定了迁移预测的可行性，从而为后续该建筑更为精确和方便的负荷预测奠定基础。

1 方法及案例

1.1 路径简述

如图 1 所示，本研究先基于站 A 已有数据进行相关性分析，并基于不同的相关系数选择值构建不同的输入组合，然后研究不同输入下的预测精度并确定各神经网络的最佳输入组合，最后在最佳输入下以 A 站已训练好的神经网络对 B 站进行负荷预测，同时以天为单位更新 B 站数据库，最终得到 B 站在不同数据库更新时段的预测表现。

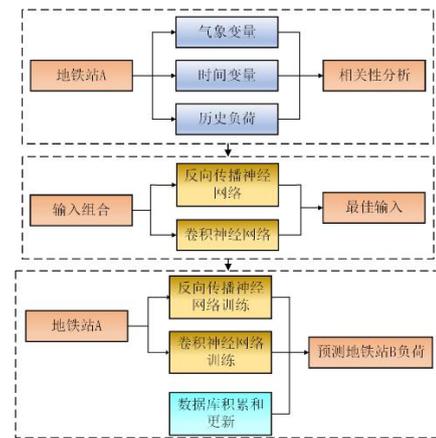


图 1 本文研究路径及方法

Fig.1 The research way and method of this paper

1.2 案例简介

一般来说，地铁站的制冷系统由冷却塔、水泵

和冷水机组组成, 冷冻水由冷水机组提供, 由冷冻水泵输送至各用冷末端换热完成冷冻水循环。本文选取两个不同的地铁站进行案例分析, 均是经典的地下岛式车站, 两个地铁站的额定冷量大小、所在地区、采样时间如表 1 所示。需要指出的是, 地铁站空调系统负荷预测全年只涉及冷负荷, 另一方面, 当进行数据库替换时, 站 A 和站 B 原则上需在同一地区以保证气候环境相似, 其地铁站建筑形式也需属于同一类别, 如均为地下二层车站, 以此保证最佳输入的相似性。

表 1 案例车站基本介绍

Table 1 The basic introduction of case station

编号	名称	所在地区	额定冷量	采样时间
1	A 站	广东省	3570kW	2021.7.25-2021.10.24
2	B 站	广东省	1785kW	2022.9.1-2022.10.24

1.3 选择方法

本文采用皮尔逊相关系数来衡量各变量与冷负荷间的相关性, 其计算公式如式 (1) 所示, 其计算数值在-1 到 1 之间, 数值正负分别代表正相关和负相关, 数值大小代表相关性的强弱, 0 则是完全不相关, 一般来说, 高于 0.2 的变量才认为是有相关性而被选取为输入^[13]。例如, 在气象变量中, 假设室外温度为 x , 冷负荷为 y , 当代入式 (1) 的计算结果大于 0.2 时, 则室外温度被保留为输入变量, 反之则输入中舍弃该变量, 其余变量以此类推。

$$\rho_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

式中: ρ_{xy} 代表变量 x 和变量 y 的皮尔逊相关系数; x_i 和 y_i 分别代表变量 x 和 y 的第 i 点数据; \bar{x} 和 \bar{y} 分别代表变量 x 和 y 的平均值。

1.4 数据库更新方法

B 站训练数据库更新方法如下: 假设 A 站有运行 30 天的成对数据, 各对数据的输入和输出将在 2.1.1 部分介绍, 而 B 站刚开始运行, 没有数据供模型进行训练并预测冷负荷。那么先以 A 站的数据在 B 站进行训练并实现预测, 往后每过 1 天, B 站则多了 1 天运行数据, 则第二天 B 站的负荷预测采用的训练数据库由 B 站第 1 天的运行数据和 A 站后 29 天的数据库组成, 依次类推, 直到 B 站运行了 30 天而有了足够的运行数据为止。

2 模型及评价指标

2.1 神经网络

2.1.1 反向传播神经网络

反向传播神经网络 (BPNN) 是应用最广泛的神经网络之一, 由输入层、隐含层和输出层组成, 各层的神经元基于权值和阈值连接计算, 权值和阈值的确定基于反向传播的梯度下降法^[21]。本文采用三层 BP 神经网络, 其输入层用于接受所选的输入数据, 具体数据为表 2 所示的变量结合式 (1) 筛选后的结果, 输出层为冷负荷数值。

表 2 输入变量及类别汇总

Table 2 Input variables and category summary

变量类别	变量
气象变量	室外温度 (T_{air}) 室外湿度 (RH)
时间变量	所在时刻 (t)
历史负荷	前 24h 冷负荷 ($h(t-i)$, $i=1, 2, \dots, 24$)

2.1.2 卷积神经网络

作为神经网络的一种, 卷积神经网络 (CNN) 也有输入层和输出层, 不同于 BPNN 之处在于 CNN 的输入层到输出层的传递基于卷积层和全连接层实现, 更多关于卷积神经网络的信息可见文献^[22]。其中, 该神经网络的输入和输出同 2.1.1 节中 BP 神经网络, 在此不再赘述。

2.2 数据归一化

由于不同输入间的数值范围存在较大差异, 如室外温度的波动范围在 18°C - 37°C , 时刻的范围为 0-23, 而历史负荷的波动范围为 13-1028kW, 当上述变量同时作为输入预测冷负荷时, 波动范围大的历史负荷会削弱波动范围较小的时间变量和室外温度的预测效果。因此需要在训练黑箱模型前对上述变量进行归一化处理, 此外, 由于进行了归一化处理, 因此预测的冷负荷的数值也在-1 到 1 之间, 为得到真实的预测冷负荷值, 需在预测后进行反归一化, 归一化和反归一化公式如式 (2)、式 (3) 所示。

$$x_j = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (2)$$

$$x_{\text{predict}} = x_{\text{model}} \cdot (x_{\max} - x_{\min}) + x_{\min} \quad (3)$$

式中: x_i 和 x_j 分别代表归一化前后的数据; x_{\min} 和 x_{\max} 分别代表变量 x 中的最小值和最大值; x_{predict} 代表反归一化后的数值; x_{model} 代表反归一化前的模型预测值。

2.3 评价指标

为量化评价各输入组合下各黑箱模型的预测效果, 选取平均绝对误差 (MAE) 和均方根误差变异系数 (CV-RMSE) 作为评价指标, 如式 (4)、式 (5) 所示。

$$MAE = \frac{\sum_{i=1}^n |y_i - y_{i,pre}|}{n} \quad (4)$$

$$CV-RMSE = \frac{n}{\sum_{i=1}^n y_i} \sqrt{\frac{\sum_{i=1}^n (y_i - y_{i,pre})^2}{n}} \quad (5)$$

式中: n 表示样本数; y_i 表示样本 i 的真实值; $y_{i,pre}$ 表示样本 i 的预测值。

3 结果分析

3.1 输入相关性分析

基于文献综述, 气象参数、历史负荷以及时间对于任何地铁站均可获得且在建筑负荷预测中被广泛使用, 因此为提升结论通用性, 本文基于这三

类变量, 通过皮尔逊相关系数对地铁站 A 的历史负荷、天气参数以及时间参数共计 27 个变量进行皮尔逊相关系数分析, 以进行输入组合和筛选, 皮尔逊相关系数计算结果如图 2 所示。

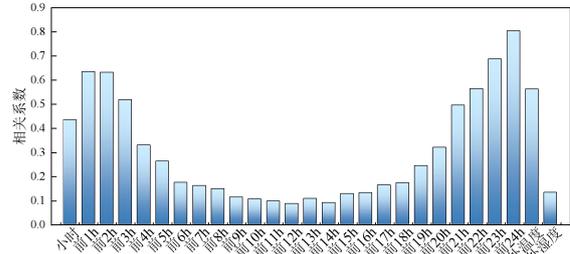


图 2 地铁站 A 各输入变量相关系数

Fig.2 Correlation coefficient of each input variable of subway station A

从图 2 可以看出, 地铁站 A 各时刻的历史负荷的相关性先降低再增高, 同时, 小时和室外温度与冷负荷相关性较高, 而室外湿度与负荷相关性较低, 基于此, 将相关系数高于某个值的变量进行组合, 最终得到表 3 的 6 种组合。

表 3 最终输入组合

Table 3 The final input combination

组合	选择阈值	输入变量	输入数目
1	0.2	t 、 $h(t-1)\sim h(t-5)$ 、 $h(t-19)\sim h(t-24)$ 、 T_{air}	13
2	0.3	t 、 $h(t-1)\sim h(t-4)$ 、 $h(t-20)\sim h(t-24)$ 、 T_{air}	11
3	0.4	t 、 $h(t-1)\sim h(t-3)$ 、 $h(t-21)\sim h(t-24)$ 、 T_{air}	9
4	0.5	$h(t-1)\sim h(t-3)$ 、 $h(t-22)\sim h(t-24)$ 、 T_{air}	7
5	0.6	$h(t-1)\sim h(t-2)$ 、 $h(t-23)\sim h(t-24)$	4
6	0.7	$h(t-24)$	1

3.2 输入组合研究

一般黑箱模型的训练会随机选择 70% 或 80% 的数据, 并将剩余的数据作为预测集评估模型预测效果。但此举会带来随机性, 采用 5 重交叉检验的方法可避免随机性, 该方法将数据集按照 4:1 的比例分成 5 段, 分别以每一段作为测试集, 其余的作为训练集, 重复 5 次, 最终量化结果以各次的平均值得到。

对于站 A 分别以表 3 所示的 6 种输入组合在 BPNN 和 CNN 中进行了预测效果分析, 其量化结果如图 3 和图 4 所示。不难看出, 对于该案例车站, 不同的神经网络有着相同的最佳输入组合, 对于 BPNN 和 CNN, 其预测精度最高的输入均是组合 4,

且 CNN 的预测表现始终优于 BPNN, 最佳预测 CV_RMSE 为 18.18%。文献[8]同样采取 CV_RMSE 来衡量不同黑箱模型基于历史数据预测冷负荷的精度, 他们的研究中, 表现最好的黑箱模型的 CV_RMSE 为 20.1%, 文献[23]在基于特征选择前的冷负荷预测 CV_RMSE 为 21.71%, 均差于本文筛选输入后的最佳预测表现。组合 4 对应的最佳的 7 个输入变量如表 4 所示, 需要指出的是, 本文的研究是基于地下两层地铁站为例, 且采取的输入变量均为常规变量, 因此该最佳输入组合结论适用于任何类似形式的地铁站。当建筑结构或形式发生改变时, 可基于实际运行数据库, 按照本文方法, 进行类似的最优变量分析以寻求最佳输入。

表 4 最佳输入变量

Table 4 The optimal input variables

编号	1	2	3	4	5	6	7
变量	H (t-1)	H (t-2)	H (t-3)	H (t-22)	H (t-23)	H (t-24)	T _{air}

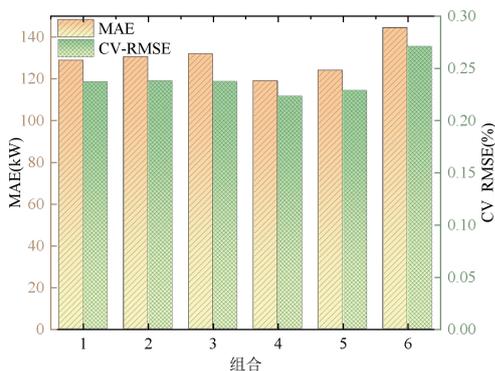


图 3 BPNN 预测地铁站冷负荷的表现

Fig.3 Performance of subway station cooling load

prediction based on BPNN

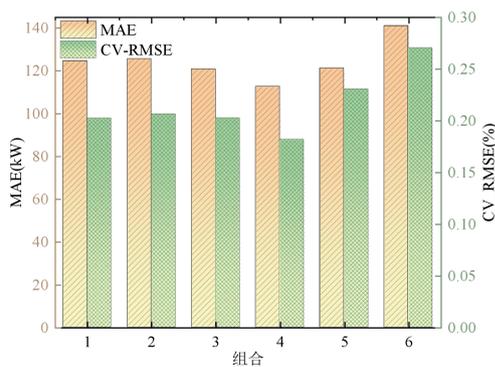


图 4 CNN 预测地铁站冷负荷测的表现

Fig.4 Performance of subway station cooling load

prediction based on CNN

3.3 B 站训练数据库更新研究

基于上述研究,可以得到案例车站基于两种神经网络的最佳输入,基于已有 21 年地铁站 A 的运行数据对两种神经网络进行训练后,将其直接应用于 22 年地铁站 B 的负荷预测,以 MAE 为评价指标,用于预测站 B 的训练数据库基于天为单位进行更新,更新方法如 1.4 部分所述,观察数据库替换与预测效果的关系,如图 5 和图 6 所示。此外,将两种神经网络在数据库替换时的逐日预测相对误差进行分析比较如图 7 所示。

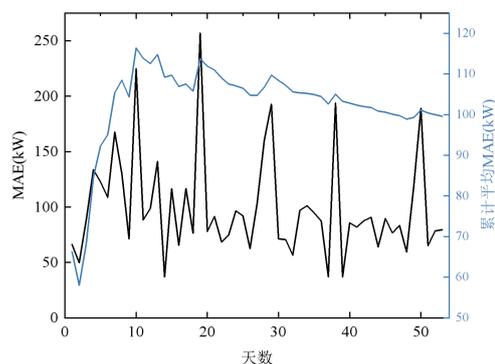


图 5 BPNN 逐日更新数据库的预测表现

Fig.5 The prediction performance of BPNN with daily database updates

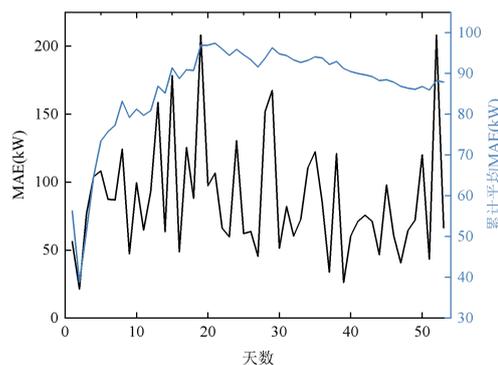


图 6 CNN 逐日更新数据库的预测表现

Fig.6 The prediction performance of CNN with daily database updates

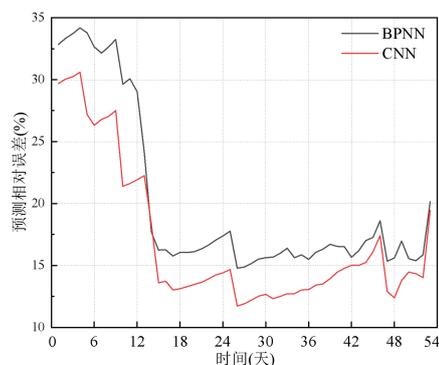


图 7 两种神经网络逐日更新训练数据库的预测表现

Fig7 The prediction performance of two neural networks with daily database updates

基于图 5 和图 6 可以看出当基于 A 站训练的

神经网络直接用于 B 站的负荷预测时,由于建筑特性的改变会使得预测精度有一定的波动,但总体上两种神经网络预测的累计平均 MAE 最后均呈降低的趋势。另一方面,基于 CNN 的逐日 MAE 和累计平均 MAE 均显著低于 BPNN,这表明 CNN 在数据库发生改变时比 BPNN 具有更强的适应性。这一点从图 7 也可看出,在实际工程中,当需要对新地铁站进行负荷预测而缺少运行数据时,可以采用逐日更新数据库的方法进行负荷预测,当数据替换在 15 天左右时,预测的绝对误差和相对误差均趋于稳定,预测的绝对误差在 90kW 左右,预测的相对误差约在 15%左右。同时,不同神经网络在变换数据库时的适应性不同,本案例中更推荐使用 CNN。值得一提的是,如 1.2 部分所述,此处数据库替换的定量结论对同地区形式相似的建筑具有参考性,若建筑形式发生变化时,可基于本文研究方法,以实际数据库对文中所述数据库进行替换以解决实际问题。

4 结论

(1) 当基于神经网络预测地铁站负荷时,各输入变量与冷负荷之间的皮尔逊相关系数应大于 0.5,对于 BPNN 和 CNN,其预测最佳 CV_RMSE 分别是 22.33%和 18.18%;

(2) 当某站运行数据不足而又需要预测负荷时,可考虑训练数据库逐步替换的迁移预测方法,本研究表明,随着训练数据库的替换,冷负荷平均预测误差会呈降低的趋势,本案例中的预测相对误差最终会稳定在 15%左右;

(3) 基于同样的数据库和输入预测冷负荷时,CNN 比 BPNN 的预测 MAE 和 CV_RMSE 分别低 6.73%和 17.59%,在训练数据库替换分析中,CNN 也优于 BPNN,因此,CNN 更适用于建筑冷负荷预测。

参考文献:

- [1] 李宗霖,雷蕾,郭雪松.基于粗糙集和 PSO-Elman 的商业建筑空调冷负荷预测[J].流体机械,2023,51(6):53-59.
- [2] 徐伟,倪江波,孙德宇,等.我国建筑碳达峰与碳中和目标分解与路径辨析[J].建筑科学,2021,37(10):1-8,23.
- [3] Cao X, Dai X, Liu J. Building energy-consumption status worldwide and the state-of-the-art technologies for zero-energy buildings during the past decade [J]. Energy and Buildings, 2016,128(1):198-213.
- [4] M Mehregan, A Naminezhad, S Vakili, et al. Building energy model validation and estimation using heating and cooling degree days (HDD-CDD) based on accurate base temperature [J]. Energy Science and Engineering, 2022,10(9):3638-3649.
- [5] 魏文罡,魏庆芑,张辉,等.基于负荷预测的机场航站楼冷源系统运行调控策略研究与应用[J].建筑节能(中英文),2022,50(1):50-56.
- [6] 王潇,康旭源,燕达,等.基于冷量预测的商业综合体冰蓄冷系统控制方法研究[J].建筑科学,2022,38(12):7-16,66.
- [7] 龙惟定.碳中和城市建筑能源系统(1):能源篇[J].暖通空调,2022,52(3):2-17.
- [8] 王遇川,刘东.屏蔽门地铁站公共区空调系统节能分析[J].暖通空调,2010,40(12):28-32.
- [9] 马翰.地铁站空调系统冷负荷预测算法研究[J].暖通空调,2022,52(S2):85-88.
- [10] D Zhu, T Hong, D Yan, et al. A detailed loads comparison of three building energy modeling programs: EnergyPlus, DeST and DOE-2.1E[J]. Building Simulation, 2013,6(3):323-335.
- [11] Braun JE, Chaturvedi N. An Inverse Gray-Box Model for Transient Building Load Prediction[J]. HVAC&R research, 2002,8(1):73-99.
- [12] A Fouquier, S Robert, F Suard, et al. State of the art in building modelling and energy performances prediction: A review[J]. Renewable and Sustainable Energy Reviews, 2013,23(1):272-288.
- [13] J Jang, J Lee, E Son, et al. Development of an Improved Model to Predict Building Thermal Energy Consumption by Utilizing Feature Selection[J]. Energies, 2019,21(12):418701-418720.
- [14] C Lee, DE Jung, D Lee, et al. Prediction Performance Analysis of Artificial Neural Network Model by Input Variable Combination for Residential Heating Loads[J]. Energies, 2021,14(3):75602-75619.
- [15] Kapetanakis D, Mangina E, Finn DP. Input variable selection for thermal load predictive models of commercial buildings[J]. Energy and Buildings, 2017, 137(1):13-26.

(下转第 350 页)

- [12] 高凤,冯璐,刘宾灿,等.国内外低能耗建筑研究标准体系发展综述[J].建筑节能(中英文),2023,51(12):123-128.
- [13] 张喜明,王俊廷,陶进.近零能耗建筑中新型相变供暖方式研究[J].吉林建筑大学学报,2022,39(5):45-50.
- [14] 何福群,聂金哲.近零能耗建筑外墙保温材料及适宜厚度研究[J].煤气与热力,2022,42(7):15-20.
- [15] 王艳,曾长女,李皖皖,等.基于定形相变材料的相变砂浆热力学性能[J].地球科学,2023,48(12):4680-4688.
- [16] 孙艳刚,王敬维,李冠杰,等.相变储能保温砂浆的制备与性能研究[J].化工新型材料,2023,51(S2):520-524.
- [17] 蒋骞,潘大伟,艾天,等.铁尾矿与采剥废石基多孔陶瓷复合相变储能材料的制备与表征[J].化工矿物与加工,2023,52(5):24-31.
- [18] 康美华,邓琴琴,聂金哲,等.近零能耗居住建筑典型结构性热桥对围护结构传热系数影响模拟分析[J].新型建筑材料,2021,48(5):109-115.

(上接第 304 页)

- [16] J Ling, N Dai, J Xing, et al. An improved input variable selection method of the data-driven model for building heating load prediction[J]. Journal of Building Engineering, 2021,44(1):10325501-10325511.
- [17] 祁鑫,王福忠,张丽,等.基于 SVD-LSTM 的高校学生宿舍空调负荷预测[J].电子科技,2020,33(11):59-66.
- [18] Y Ding, Q Zhang, T Yuan, et al. Effect of input variables on cooling load prediction accuracy of an office building[J]. Applied Thermal Engineering, 2018,128(1): 225-234.
- [19] 何超.基于深度强化学习的建筑节能方法研究[D].苏州:苏州科技大学,2019:26-33.
- [20] 肖紫薇,刚文杰,袁嘉琦,等.基于长短期记忆网络的短期空调冷负荷预测[J].暖通空调,2022,52(4):132-137.
- [21] 王新雨,郭振伟,于丹,等.基于 PCA-PSO-BP 神经网络的住宅供热逐时负荷预测[J].暖通空调,2023,53(3):138-142,160.
- [22] 梁煜,张金铭,张为.一种改进的卷积神经网络的室内深度估计方法[J].天津大学学报(自然科学与工程技术版),2020,53(8):840-846.
- [23] 牛纪德,林欣怡,张恒,等.基于模型校准的建筑冷负荷短期预测模型人工内扰特征变量获取方法[J].暖通空调,2023,53(3):54-60.