

基于聚类及优化集成神经网络的地铁车站空调 负荷预测

孟 华¹, 孙 浩¹, 裴 迪¹, 王 海¹, 李元阳², 徐 敏³

(1. 同济大学 机械与能源工程学院, 上海 201804; 2. 广东美的暖通设备有限公司 美的全球创新中心, 广东 佛山 528311;

3. 上海克来沃美的暖通设备有限公司, 上海 200335)

摘要: 分别从优化算法集成神经网络及将数据聚类后按类建模两方面建立 3 种模型对地铁车站空调负荷进行逐时预测, 结果表明: 同一物理量对地铁车站空调负荷所产生的影响程度随时间呈现某种动态变化特征, 根据历史数据定量分析这些特征, 对精准筛选模型输入参数、提高模型预测精度大有裨益。在 3 种模型中, 粒子群优化算法-神经网络(PSO-BPNN)和果蝇优化算法-神经网络(FOA-BPNN)预测的平均相对误差(MAPE)较单纯神经网络(BPNN)分别降低 25.87% 和 40.08%, 聚类-神经网络(Kmeans-BPNN)预测的 MAPE 比 PSO-BPNN 及 FOA-BPNN 分别降低 61.12% 和 51.90%。说明在同等情况下, 优化算法集成模型比单纯 BPNN 预测精度更高, 而当区分实际负荷变化特点后, 采用聚类后建模比优化集成建模效果更佳。

关键词: 地铁车站; 负荷预测; 优化算法; 聚类; 神经网络

中图分类号: TU119

文献标志码: A

Air-Conditioning Load Prediction of Subway Station Based on Clustering and Optimization Algorithm Ensemble Neural Network

MENG Hua¹, SUN Hao¹, PEI Di¹, WANG Hai¹,
LI Yuanyang², XU Min³

(1. School of Mechanical Engineering, Tongji University, Shanghai 201804, China; 2. Midea Global Innovation Center, Guangdong Media HVAC Equipment Co., Ltd., Foshan 528311, China; 3. Shanghai Kravomeid HVAC Equipment Co., Ltd., Shanghai 200335, China)

Abstract: Three models were developed to predict the air-conditioning hourly cooling load of a subway station from the aspects of optimization algorithm ensemble back

propagation neural network (BPNN) and BPNN with data clustering pre-processing. The results show that the influence of the same physical parameters on the air-conditioning load of the subway station reflects a certain dynamic change characteristic over time. Quantitative analysis of these features based on historical data is of great benefit to precisely selecting the model input parameters and improving model prediction accuracy. In the three given models, the predicted mean absolute percentage error (MAPE) of particle swarm optimization (PSO)-BPNN and the fruit fly optimization algorithm (FOA)-BPNN decreases by 25.87% and 40.08% respectively compared with that of BPNN, while the MAPE of Kmeans-BPNN is reduced by 61.12% and 51.90% respectively compared with that of PSO-BPNN and FOA-BPNN, which means that the performance of optimization algorithm ensemble models is better than that of pure BPNN on even ground. Moreover, BPNN with data clustering is better than optimization algorithm ensemble BPNNs after distinguishing the characteristics of real load changes.

Key words: subway station; load prediction; optimization algorithm; clustering; neural network

2019 年我国轨道交通总耗电量约 152.6 亿千瓦时, 占全国年总耗电量的 2.4%^[1]; 我国南方地区地铁站空调环控能耗约占总能耗的 50% 以上^[2]。地铁站空调系统能耗大的主要原因是系统运行调控供需不平衡, 而要想缓解不平衡、实现节能运行, 首先必须对地铁站空调负荷进行准确预测。学者们已在地上建筑空调负荷预测方面做过大量研究, 既

收稿日期: 2021-01-30

基金项目: 国家重点研发计划(2017YFC0702907)

第一作者: 孟 华(1968—), 女, 副教授, 工学博士, 主要研究方向为建筑节能技术及区域供热。

E-mail: mengh@tongji.edu.cn

通信作者: 王 海(1976—), 男, 副教授, 工学博士, 主要研究方向为区域供热、建筑节能、能源互联网。

E-mail: wanghai@tongji.edu.cn



论文
拓展
介绍

有传统的参数回归法(简单回归模型、多变量回归模型、高斯过程回归^[3]等);时间序列法(自回归模型、线性与非线性方程模型^[4-5])、滑动平移模型^[6]、混沌法^[7]、小波分析法等^[8];也有基于黑箱的误差反向传播神经网络^[9-10](back-propagation neural network, BPNN)及基于数据聚类^[11-12]和优化算法^[13-16]的负荷预测。

但是,目前针对地铁车站空调负荷预测的研究还较少。地铁车站属于地下建筑,仅通过出入口通道及地面风亭与外界相连,站内客流、设备、屏蔽门、列车运行产热、活塞风及周围土壤传热等因素,都使得地铁车站空调负荷特点不同于地上建筑,其系统控制变量多、高度非线性、惯性大滞后强,若采用传统空调负荷预测方法难度较大,而日益完善的地铁车站空调自控系统使得基于大数据的黑箱负荷预测模型成为有效方法。文献[17]采用BPNN模型预测地铁站厅空调负荷,但其数据集是采用仿真模拟结果。文献[18-19]利用遗传算法优化BPNN模型以预测地铁车站冰蓄冷空调负荷,但模型输入参数是定性选取的。文献[20]利用基因遗传及粒子群算法优化BPNN模型以预测地铁车站空调负荷,但文中数据集情况不详。

目前在地铁车站空调负荷预测研究中,关于定量表征各因素对负荷影响程度随时间的动态变化特征以及采用不同优化算法模型对负荷预测精度及预测效果进行比较等研究目前还很有限。本文分别从优化算法集成神经网络(PSO-BPNN与FOA-BPNN)及将数据聚类(Kmeans-BPNN)后按类分别建模两方面建立地铁车站空调负荷预测模型。根据实际运行数据,定量分析各物理量对负荷影响程度随时间变化的动态特征,获取相关系数曲线,并以此甄选模型输入参数。基于所提出的3种模型对地铁车站空调负荷进行逐时预测,利用4种指标对预测结果进行评价,从优化算法集成建模及对数据集进行前处理后再建模2个维度,总结精度更高和效果更好的地铁车站空调负荷预测方法。

1 预测模型

1.1 Kmeans聚类-BPNN模型

单纯BPNN^[21]模型直接利用数据集进行训练及预测,不考虑数据集的特征。作为无监督学习的一种算法,聚类将数据集中所有待预测样本划分为若干个互不相交的子集,即“簇”^[22]。K均值(Kmeans)

聚类通过针对样本集 $D=\{x_1, x_2, \dots, x_m\}$ 划分所得簇 $C=\{C_1, C_2, \dots, C_k\}$,使其平方误差 E 最小,即

$$E = \sum_{i=1}^k \sum_{x \in C_i} \|x - \mu_i\|_2^2 \quad (1)$$

式中: x 为单个样本; C_k 为单个簇; μ_k 为簇 C_k 的均值向量,其公式为

$$\mu_i = \frac{1}{|C_i|} \sum_{x \in C_i} x \quad (2)$$

利用Kmeans聚类后再根据各类分别构建BPNN模型。

1.2 粒子群优化算法集成BPNN模型(PSO-BPNN)

粒子群优化算法(Particle Swarm Optimization, PSO)^[23]将觅食的鸟类作为 N 维空间搜索个体,其速度与位置的更新方法为

$$V_{id} = \omega V_{id} + C_1 r(P_{id} - X_{id}) + C_2 r(P_{gd} - X_{id}) \quad (3)$$

$$X_{id} = X_{id} + V_{id} \quad (4)$$

式中: ω 为惯性因子; C_1 和 C_2 分别为每个粒子的个体与社会学习因子; r 为在区间 $[0, 1]$ 上的随机数; X_{id} 和 V_{id} 分别为 d 时刻第 i 个粒子的位置和速度; V_{id} 为 d 时刻第 i 个粒子的个体最优解; P_{gd} 为 d 时刻所有粒子 g 的全局最优解。

模型集成原理为:每次PSO算法将迭代得出的全局最优解粒子速度与位置赋值给BPNN模型的权值及阈值,将模型训练得出的预测值与实际目标误差作为适应度函数,直至满足适应度函数,则PSO优化算法迭代停止,其粒子的速度与位置即为BPNN的最优权值与阈值。

1.3 果蝇优化算法集成BPNN模型(FOA-BPNN)

果蝇优化算法(Fruit Fly Optimization Algorithm, FOA)^[24]是以模拟果蝇觅食寻求全局优化的算法。果蝇的位置更新表达式与味道浓度判定函数为

$$X_i = X_{axis} + r_{randomValue} \quad (5)$$

$$S_{Smell} = f_{Function}(S_i) \quad (6)$$

式中: X_{axis} 为果蝇在轴线 X 初始位置; $r_{randomValue}$ 为果蝇活动范围内的随机值; S_i 表示果蝇 i 闻到食物的味道浓度值; S_{Smell} 为判定函数。

模型集成原理为采用FOA算法不断优化BPNN模型的拓扑结构,将迭代寻优的果蝇最佳位置赋值给BPNN权值与阈值,以提高模型的预测性能及泛化能力。

本文提出的Kmeans-BPNN、PSO-BPNN、FOA-BPNN预测模型流程如图1。

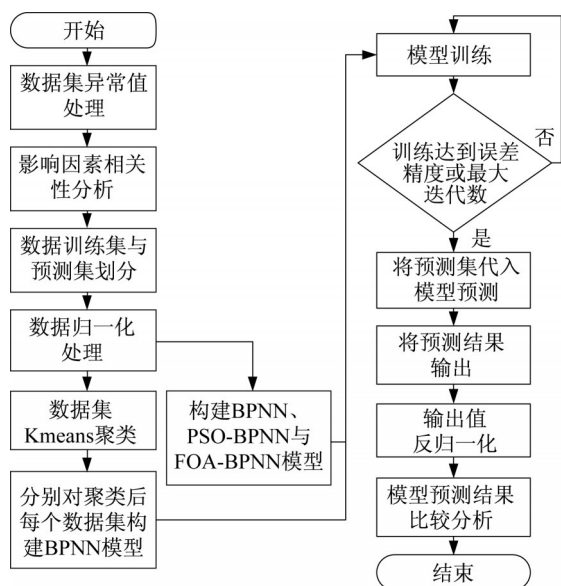


图1 预测模型流程

Fig.1 Flowchart of prediction models

1.4 预测模型的评价指标

采用4项指标对各预测模型进行评价:相关系数 R 、平均绝对误差(mean absolute error, E_{MAE})、均方根误差(root mean square error, E_{RMSE})与平均绝对百分比误差(mean absolute percentage error, E_{MAPE}),计算公式为(7)-(10)。

$$R = \frac{\text{Cov}(\hat{y}, y)}{\sqrt{\text{Var}[\hat{y}] \text{Var}[y]}} \quad (7)$$

$$E_{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (8)$$

$$E_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (9)$$

$$E_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (10)$$

式中: $\text{Cov}(\hat{y}, y)$ 为预测值 \hat{y} 与实际值 y 的协方差; $\text{Var}[\hat{y}]$ 、 $\text{Var}[y]$ 分别为预测值 \hat{y} 与实际值 y 的方差; n 表示预测时长; \hat{y}_i 及 y_i 分别为第 i 时刻的预测值和实际值。

2 地铁站空调负荷预测实例分析

2.1 数据来源及处理

以广州某地铁车站空调系统实际运行数据作为样本集,该站共设2台冷水机组。原始数据包括2台冷机的冷水供、回水温度,冷却水供回、水温度,2台冷机的瞬时冷量,站台层A、B端及站厅层A、B端各4个采集点的空气温度及相对湿度,以及地铁站台入

口处的室外空气温度和相对湿度;采集时间段为2020年5月1日0时至8月31日23时,数据采集间隔2min,共计88 560组数据。对样本集进行了训练集及测试集的划分。

数据采集期间广州地铁车站夜间也有冷机运行。通过对原始样本的分析发现,空调负荷存在在白天地铁正常运营时很小甚至为零而夜间机组部分关闭时却很大等不合理现象,这可能是由于2台冷机切换运行或数据传输系统瞬时不稳定所致。为避免模型训练难以收敛、预测误差较大等后果,需对原始数据异常值进行处理。本文利用平均值或样条插值对负荷值为零、过大、过小或缺失等处进行替换或补充。原始数据集处理后的空调负荷如图2。后面所有预测模型都以处理后的负荷值作为原始样本。其他采集参数无异常。

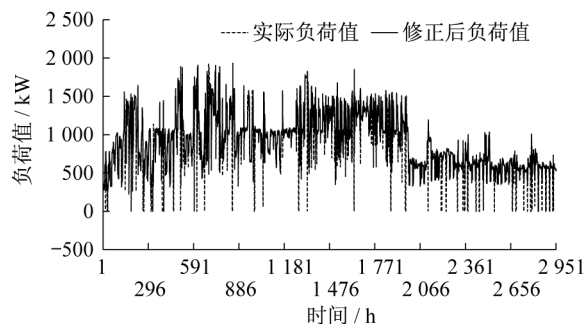


图2 空调负荷异常值的处理

Fig. 2 Treatment of abnormal data of cooling load

2.2 预测模型输入参数的确定

本文采用黑箱方法建立地铁车站空调负荷的预测模型,包括BPNN模型在内的所有黑箱模型都是通过对历史数据自学习来映射出待预测物理量与对该量产生影响的其他各物理量之间的关系,而这些物理量对负荷的影响程度具有随时间变化的动态特征,定量分析这些动态特征将对准确选择模型输入参数及确保模型预测精度至关重要。由于地铁车站位于地下,土壤具有很大的蓄热性及传热惰性,因此太阳辐射及风速等参数对地铁车站空调负荷影响很小。根据文献[17-18,20]调研,初选地铁车站室内、外空气温度、相对湿度及历史负荷作为影响因素。考虑这些物理量在不同历史时刻对负荷的影响程度不同,现采用SPSS Statistics 21软件对上述5个量在过去24h(记为 $t \sim t-24$)内对地铁车站空调负荷的动态影响程度进行定量分析,利用Person相关系数 r 作为衡量影响负荷程度强弱的指标。

$$r=\frac{N\sum x_iy_i-\sum x_i\sum y_i}{\sqrt{N\sum x_i^2-(\sum x_i)^2}\sqrt{N\sum y_i^2-(\sum y_i)^2}}$$

(11)

式中: N 为特征样本数量; x_i 和 y_i 分别表示第 i 个影响因素与历史负荷。通过定量计算,各物理量在过去24h内对地铁车站空调负荷相关系数的动态变化如图3。

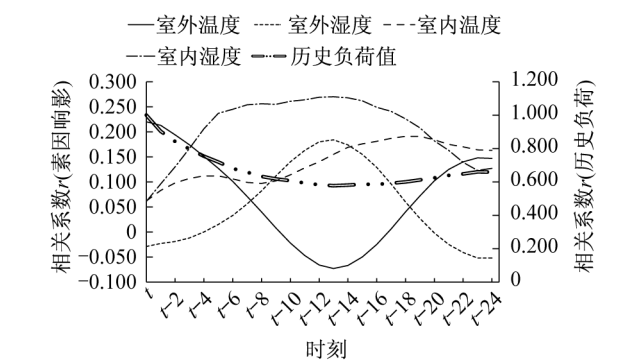


图3 不同物理量对负荷影响相关系数的动态变化

Fig. 3 Dynamic variation of correlation coefficient of different parameters on load

由此可见前述5个物理量在过去24h内对地铁车站空调负荷的影响程度随时间呈现某种动态变化特征。首先根据定性分析,空调负荷与室内外温度呈正相关,而图3中室外温度与历史负荷在 $t-9$ 到 $t-17$ 时刻为负值,违反定性分析,故需要剔除此时间段室外温度。随后根据定量分析,室外温度线上的 t 时刻和室内温度线上的 $t-18$ 时刻所对应的 r 值最高,说明这2个参数在这2个时刻比其他时刻对负荷的影响程度更大。同理根据定性分析,空调负荷与室内外相对湿度呈负相关,图3中室外相对湿度与历史

负荷在 $t-4$ 到 $t-20$ 时刻为正值,室内相对湿度与历史负荷在 t 到 $t-24$ 时刻均为正值,违反定性分析,故需要剔除这2个时间段室内外相对湿度。定量分析可得室外相对湿度在 $t-24$ 时刻比其他时刻对负荷的影响更大。而历史负荷在 $t-1$ 、 $t-2$ 及 $t-24$ 时刻比其他时刻对当前负荷的影响更大。通过各物理量对负荷相关系数的动态变化分析,最终确定地铁车站空调负荷的6个重要影响参数,并将其作为预测模型的输入参数。根据Kolmogorov定理,经仿真试验确定隐含层节点数为13,预测模型的结构为6-13-1,模型参数见表1。

表1 预测模型的结构参数

Tab. 1 Construction parameters of prediction models	
类别	表示符号
输入参数	$T_{t, O}, T_{t-18, I}, H_{t-24, O}, L_{t-1}, L_{t-2}, L_{t-24}$
输出参数	L_t
隐含层节点数	13

注: $T_{t, O}$ 代表 t 时刻室外空气温度, $T_{t-18, I}$ 代表 $t-18$ 时刻室内空气温度, $H_{t-24, O}$ 代表 $t-24$ 时刻室外相对湿度, $L_t, L_{t-1}, L_{t-2}, L_{t-24}$ 分别代表 $t, t-1, t-2, t-24$ 时刻空调负荷。

确定数据集后,还需要对数据进行归一化处理,最终模型输出参数经反归一化处理即可得到负荷预测值。

通过分析发现原始样本中空调负荷呈现一定特点,因此本文利用Kmeans聚类对数据集进行预处理,并针对聚类后的各类数据分别建立BPNN模型;此外,还利用PSO与FOA优化算法集成BPNN模型。将这些模型结果与单纯BPNN模型加以比较,以考察其对地铁车站空调负荷预测精度的影响。

经仿真试验确定各模型中的超参数见表2。

表2 模型训练中的超参数

Tab. 2 Hyper parameters for each model								
模型	最大迭代次数	训练速率	训练目标误差	C_1	C_2	种群规模	进化次数	聚类数
BPNN	1 000	0.01	0.001					
PSO-BPNN	1 000	0.01	0.001	1.494 4	1.494 4	20	80	
FOA-BPNN	1 000	0.01	0.001			60	100	
Kmeans-BPNN	1 000	0.01	0.001					2

2.3 聚类神经网络预测模型结果及分析

2.3.1 Kmeans聚类结果及分析

本文利用Python中sklearn库调用Kmeans聚类算法,每个类别之间的距离选择Euclidean(欧氏)距离。利用Calinski Harabasz(CH)评价指标确定最佳聚类数,CH越大代表类之间样本距离越小,联系越紧密,聚类效果越好。部分聚类数及对应的CH评

价指标计算结果见表3。而当聚类数大于7后,CH值显著下降,聚类效果较差。根据表4的结果把数据集聚为2类,聚类结果如表4。

表3 不同聚类数的CH值

Tab. 3 CH for different clustering numbers						
聚类数	2	3	4	5	6	7
CH	165.65	125.77	97.65	82.68	73.42	64.21

表 4 Kmeans 聚类结果
Tab. 4 Clustering results of Kmeans

月份	日期																															
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	
5	A	A	A	A	A	A	B	B	B	B	A	A	A	A	B	B	B	A	A	B	B	B	A	A	B	B	A	A	B	B	B	B
6	B	A	B	B	B	A	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	—
7	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	B	A	A	A	A	A	B	A	A	A	A
8	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A

由表 4 可见,通过 Kmeans 聚类后的数据被分为 A、B 2 类,A 类数据主要集中在 5、7 月几天及 8 月整月,这些天气负荷相对低些;而 B 类数据集中在 6、7 月,这段时期负荷相对较高。

2.3.2 Kmeans-BPNN 预测结果及分析

利用聚类后的 A、B 2 类数据分别建立 BPNN 模型进行地铁车站的空调负荷预测,同时对未聚类数据也建立 BPNN 模型。2 种模型的训练集及预测集相同,测试集 8 月 31 日的数据聚类于 A 类。2 种模型的负荷预测值见图 4,它们对实际负荷的相对误差见图 5。

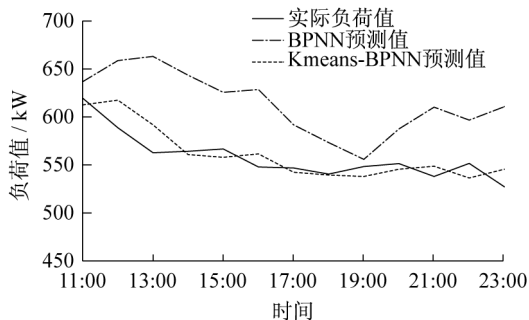


图 4 Kmeans-BPNN 及 BPNN 模型的负荷预测
Fig. 4 Comparison of load prediction for Kmeans-BPNN model and BPNN model

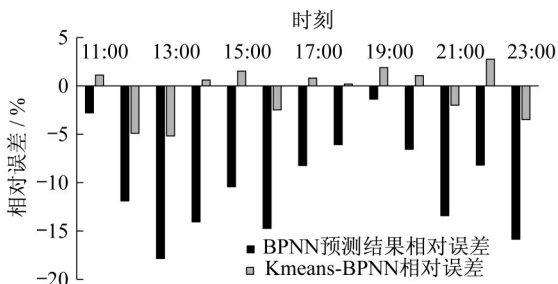


图 5 Kmeans-BPNN 及 BPNN 模型负荷预测的相对误差
Fig. 5 Relative errors of cooling load prediction for Kmeans-BPNN model and BPNN model

由图 5 可见,无论是 Kmeans-BPNN 模型还是 BPNN 模型的负荷预测值都与实际值相差不大,预测相对误差基本在 15% 以内,经计算其相关系数 R 最低为 0.912,说明采用本文前述的以各物理量对负

荷相关系数的动态变化特征定量甄选模型输入参数的方法能够产生较好的预测效果。同时由图 4 可见,通过聚类后的 Kmeans-BPNN 模型比单纯 BPNN 能够更好地追踪实际负荷的变化特点,尤其在中午 11:00-13:00 期间,当地铁车站空调负荷逐渐降低时,Kmeans-BPNN 的预测值在经过一小段时滞后也能显示出相似的变化趋势;尽管 8 月 31 日是周一工作日,但实际负荷在 17:00 时后变化平稳直至夜里 23:00 时后降低,Kmeans-BPNN 模型的预测值也基本能反应实际特点。从图 5 也可见 Kmeans-BPNN 模型预测的相对误差最大值在 5% 之内,较单纯 BPNN 总体误差更低,预测精度更高。这说明在地铁车站空调系统实际运行中,若历史负荷变化呈现一些特点,则采用数据聚类神经网络模型比单纯 BPNN 模型具有更高的预测精度。

2.4 优化算法集成神经网络预测模型结果及分析

从优化算法集成神经网络的角度分别建立 PSO-BPNN 与 FOA-BPNN 模型。与传统 BPNN 训练过程不同,优化算法集成模型先根据所设定的训练超参数对初始种群进行迭代寻优,用每次寻优结果更新 BPNN 中的权值和阈值,直至满足适应度函数,最终用最优种群迭代结果确定神经网络的结构参数。PSO-BPNN、FOA-BPNN 及 BPNN 模型对地铁车站空调负荷预测值的对比如图 6。它们对实际负荷的相对误差见图 7。

由图可见,采用 3 种模型预测地铁车站空调负

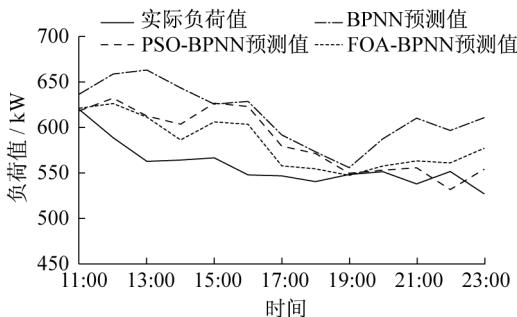


图 6 PSO-BPNN、FOA-BPNN 及 BPNN 模型的负荷预测
Fig. 6 Comparison of load prediction for PSO-BPNN, FOA-BPNN, and BPNN model

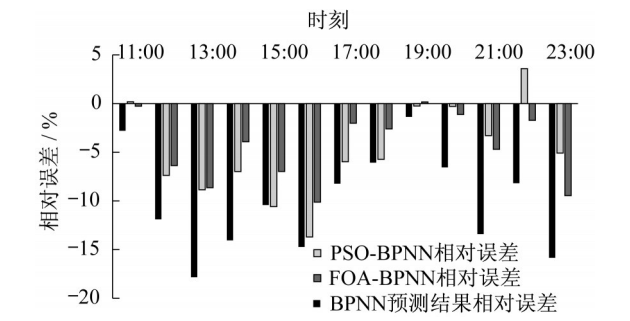


图7 PSO-BPNN、FOA-BPNN 及 BPNN 模型预测的相对误差

Fig. 7 Relative errors of cooling load prediction for PSO-BPNN, FOA-BPNN, and BPNN model

荷的最大相对误差低于17%,采用2种算法集成模型的预测值较单纯BPNN精度更好,更能反应实际负荷的变化特点,例如当负荷在中午11:00时到16:00时呈现先逐渐降低、后变化平稳然后再降低时,2种优化集成模型都能基本表现出类似的变化趋势。这主要由于无论是 PSO 算法还是 FOA 算法都具有较好的全局搜索力,而 BPNN 模型具有快速局部搜索力,二者结合可避免后者易陷入局部极小等缺陷,有利于提升模型预测精度。

2 种优化集成模型相比,FOA-BPNN 在大部分时间似乎比 PSO-BPNN 预测表现更佳,只是在晚上 19:00 时之后预测性能略差。由图 7 也可看出,2 种优化集成模型的预测相对误差都比 BPNN 降低,预测精度更高;而 FOA-BPNN 总体比 PSO-BPNN 模型的预测误差更低,精度更高。

利用数据聚类预处理的 Kmeans-BPNN 预测负荷的均方根误差仅为 14.769kW,平均相对误差仅为 2.15%,不仅显著低于 BPNN 模型,也比优化算法集成的 PSO-BPNN 及 FOA-BPNN 预测平均相对误差分别低 61.12% 和 51.90%。

由此可见,在相同的样本集下,通过对模型输入参数的定量分析,在考察实际负荷变化特点的基础上,采用对数据集进行聚类后 BPNN 模型的预测效果比采用优化算法不断优化更新 BPNN 模型结构的预测精度更好,效果更佳。

2.5 各类模型的预测结果比较及分析

为了更准确地评价各类模型的预测性能,选取 4 项指标对其进行评价比较,见表 5、表 6。由表可见,4 种模型预测的最小相关系数为 0.912,最大相对误差为 7.46%,这说明本文利用不同物理量对负荷相关系数随时间的动态变化特征来定量选择模型输入参数的方法效果较好。

表 5 各类模型负荷预测评价指标

Tab. 5 Evaluation indicators of load prediction for each model

模型	R	E_{MAE}/kW	E_{RMSE}/kW	$E_{MAPE}/\%$
BPNN	0.912	41.484	43.164	7.46
PSO-BPNN	0.935	30.756	37.838	5.53
FOA-BPNN	0.938	24.751	30.981	4.47
Kmeans-BPNN	0.920	12.025	14.769	2.15

利用优化算法集成 BPNN 模型比单纯利用 BPNN 模型可使预测误差有不同程度的降低,PSO-BPNN 预测负荷均方根误差为 37.838kW,比单纯 BPNN 的 43.164kW 降低 12.34%,预测平均相对误差较 BPNN 的 7.46% 降低到 5.53%,降低了 25.87%;而 FOA-BPNN 预测负荷均方根误差为 30.981kW,比单纯 BPNN 降低 28.22%,预测平均相对误差为 4.47%,较 BPNN 降低了 40.08%。

这说明采用 2 种优化集成模型都比单纯采用 BPNN 模型的预测精度有提高。2 种集成模型相比,利用 FOA 算法优化 BPNN 的性能表现更好,预测平均相对误差较低。

表 6 各类负荷预测模型评价指标对比

Tab. 6 Comparison of evaluation indicators of different load prediction models

基准模型	比较模型	$\Delta R/\%$	$\Delta E_{MAE}/\%$	$\Delta E_{RMSE}/\%$	$\Delta E_{MAPE}/\%$
BPNN	PSO-BPNN	2.52	-25.86	-12.34	-25.87
BPNN	FOA-BPNN	2.85	-40.34	-28.22	-40.08
BPNN	Kmeans-BPNN	0.88	-71.01	-65.78	-71.18
PSO-BPNN	Kmeans-BPNN	-1.60	-60.90	-60.97	-61.12
FOA-BPNN	Kmeans-BPNN	-1.92	-51.42	-52.33	-51.90

3 结论

为更准确地预测地铁车站空调负荷以降低系统运行能耗,建立了 PSO-BPNN 和 FOA-BPNN 2 种优化算法集成神经网络模型及 Kmeans 聚类神经网络模型,利用广州某地铁车站空调系统实际运行数据对模型进行训练和预测,并将结果与单纯 BPNN 模型进行比较分析,主要结论如下:

(1)通过定量分析发现,同一物理量对负荷所产生的影响程度随时间呈现某种动态变化特征。比如

前1h、前2h以及前一天当前时刻的历史负荷就比其他时刻对当前负荷的影响程度更大;而前一天当前时刻的室外相对湿度也比前1小时或前几小时对负荷的影响程度更大。因此若能根据历史数据定量分析主要物理量对负荷影响程度随时间的动态变化特征,则对精准筛选模型输入参数、提高模型预测精度大有裨益。

(2)采用2种优化算法集成BPNN模型进行负荷预测,PSO-BPNN和FOA-BPNN模型的预测平均相对误差较单纯BPNN分别降低25.87%和40.08%;而2种优化集成模型相比,FOA-BPNN的模型预测平均相对误差较低,性能表现更好。这说明在地铁车站空调负荷预测时,在同等情况下(比如模型输入参数、训练集和测试集等相同)如果利用优化算法集成BPNN往往能够获得精度更高的预测效果,至于具体采用何种优化算法集成模型效果更好则需要通过仿真试验决定。

(3)采用对数据集聚类后按类分别建立BPNN模型进行负荷预测,Kmeans-BPNN模型的预测平均相对误差仅为2.15%,不仅显著低于BPNN模型,也比PSO-BPNN及FOA-BPNN模型的预测平均相对误差分别降低61.12%和51.90%。这说明在同等情况下,在区分实际负荷变化特点基础上,采用对数据集进行聚类后BPNN模型的预测效果可以比采用优化算法不断优化更新BPNN模型结构的预测精度更好,效果更佳。

作者贡献声明:

孟 华:参与研究的构思、设计,对主要学术性内容做文稿修订。

孙 浩:进行研究的构思、设计、数据运算、起草论文。

裴 迪:参与研究的构思、设计。

王 海:对重要学术性内容提出建议、做出修订。

李元阳:参与试验数据的测试及收集。

徐 敏:参与试验数据的测试及收集。

参考文献:

- [1] 中国城市轨道交通协会. 2019年中国城市轨道交通牵引能耗[EB/OL]. [2020-12-03]. <http://www.rotonix.com.cn/cn/news/1/18.html>.
China Association of Metros. The traction energy consumption of China's urban rail transit in 2019 [EB/OL]. [2020-12-03]. <http://www.rotonix.com.cn/cn/news/1/18.html>.
- [2] 菱泰能源. 江亿: 轨道交通车站能耗与节能[EB/OL]. [2017-12-25]. <http://www.szltny.com/articles/hvacjiangyi.html>.
Lingtai Energy . JIANG Yi: Energy consumption and energy

saving of rail transit station. [EB/OL]. [2017-12-25]. <http://www.szltny.com/articles/hvacjiangyi.html>.

- [3] San JIBAN Sekhar Roy, Pijush Samui , ISHAN Nagtode, *et al.* Forecasting heating and cooling loads of buildings: A comparative performance analysis [J]. Journal of ambient intelligence and humanized computing, 2020, 11(3):1253.
- [4] ALAM S M Mahfuz, ALI Mohd Hasan. Equation based new methods for residential load forecasting [J]. Energies, 2020, 13:1.
- [5] LI Wenqiang, GONG Guangcai, FAN Houhua, *et al.* A clustering-based approach for "cross-scale" load prediction on building level in HVAC systems [J]. Applied Energy, 2021, 282 (15):116.
- [6] ZHAO Yang, ZHANG Chaobo, ZHANG Yiwen, *et al.* A review of data mining technologies in building energy systems: Load prediction, pattern identification, fault detection and diagnosis [J]. Energy and Built Environment, 2020, 1 (2):149.
- [7] ZHANG Chaobo, ZHAO Yang, FAN Cheng, *et al.* A generic prediction interval estimation method for quantifying the uncertainties in ultra-short-term building cooling load prediction [J]. Applied Thermal Engineering, 2020, 173:1.
- [8] 孙育英, 王丹, 王伟, 等. 空调运行负荷预测方法的研究综述[J]. 建筑科学, 2016, 32(6):142.
SUN Yuying, WANG Dan, WANG Wei, *et al.* Research summary of air conditioning operation load forecasting methods [J]. Building Science, 2016, 32(6):142.
- [9] 陈锐彬, 李泽奇, 黄永益. 基于BP神经网络模型的大型公共建筑冷负荷预测[J]. 建设科技, 2019, 375:38.
CHEN Ruibin, LI Zeqi, HUANG Yongyi. Cooling load prediction of the large public building using BP neural network model [J]. Construction Science and Technology, 2019, 375: 38.
- [10] 张峰, 李苏泷. 基于BP神经网络的建筑空调负荷预测[J]. 智能建筑与智慧城市, 2019, 11:34.
ZHANG Feng, LI Sulong. Air-conditioning load forecasting based on BP neural network [J]. Intelligent Building & Smart City, 2019, 11: 34.
- [11] 张梦成, 刘兆辉, 谭洪卫. 基于FCM优化神经网络的办公楼空调负荷预测[J]. 建筑科学, 2018, 34(6):23.
ZHANG Mengcheng, LIU Zhaohui, TAN Hongwei. Cooling load prediction for office buildings based on FCM-BP prediction model [J]. Building Science, 2018, 34 (6): 23.
- [12] 刘倩颖, 阮应君, 时翔, 等. 基于Kmeans聚类与BP神经网络算法的办公建筑逐时电负荷预测[J]. 热能动力工程, 2018, 33 (3):138.
LIU Qianying, RUAN Yingjun, SHI Xiang, *et al.* Hourly power load forecasting of office building based on Kmeans clustering and BP neural network algorithm [J]. Journal of Engineering for Thermal Energy and Power, 2018, 33 (3): 138.
- [13] 墨蒙, 赵龙章, 龚媛雯, 等. 基于粒子群神经网络的空调冷负荷

- 短期预测[J]. 建筑热能通风空调, 2018, 37(5):6.
- MO Meng, ZHAO Longzhang, GONG Aiwen, *et al.* Short-term prediction of air-conditioning cooling load based on particle swarm neural network [J]. Building Energy & Environment, 2018, 37(5): 6.
- [14] 杨熊,于军琪,郭晨露,等. 基于改进 PSO-BP 神经网络的冰蓄冷空调冷负荷动态预测模型[J]. 土木与环境工程学报, 2019, 41(1):168.
- YANG Xiong, YU Junqi, GUO Chenlu, *et al.* Dynamic load forecasting model of ice storage air conditioning based on improved PSO-BP neural network [J]. Journal of Civil and Environmental Engineering, 2019, 41(1): 168.
- [15] 于军琪,井文强,赵安军,等. 基于改进 PSO-BP 算法的冷负荷预测模型[J]. 系统仿真学报, 2021, 33(1):1. <https://doi.org/10.16182/j.issn1004731x.joss.19-0223>.
- YU Junqi, JING Wenqiang, ZHAO Anjun, *et al.* Cold load prediction model based on improved pso-bp algorithm [J]. Journal of System Simulation, 2021, 33(1):1.<https://doi.org/10.16182/j.issn1004731x.joss.19-0223>.
- [16] 王蕾,张九根,李腾,等. 基于改进 BP 神经网络的中央空调冷负荷预测研究[J]. 计算机测量与控制, 2014, 22(6):1690.
- WANG Lei, ZHANG Jiugen, LI Teng, *et al.* Prediction of cooling load of HVAC system based on improved BP model [J]. Computer Measurement & Control, 2014, 22(6): 1690.
- [17] 李婷婷,毕海权,王宏林,等. 基于 BP 神经网络的地铁站厅空调负荷预测[J]. 计算机科学, 2019, 46(11A):590.
- LI Tingting, BI Haiquan, WANG Honglin, *et al.* Prediction of air-conditioning load in metro station hall based on BP neural network[J]. Computer Science, 2019, 46(11A): 590.
- [18] 陈哲,张九根,陈浩. 地铁冰蓄冷空调系统负荷预测研究[J]. 现代电子技术, 2018, 41(23):169.
- CHEN Zhe, ZHANG Jiugen, CHEN Hao. Study on load prediction of ice storage air conditioning system in metro [J]. Modern Electronics Technique, 2018, 41(23): 169.
- [19] 李妤姝,卢军,李永财,等. 基于负荷预测的冰蓄冷空调系统运行策略研究[J]. 暖通空调, 2019, 49(3):129.
- LI Yushu, LU Jun, LI Yongcai, *et al.* Research on operation strategy of ice cool storage air conditioning system based on load forecasting [J]. Heating Ventilating & Air Conditioning, 2019, 49(3): 129.
- [20] 付亮. 地铁站中央空调系统负荷预测与节能优化[D]. 西安: 西安建筑科技大学, 2019.
- FU Liang. Load forecast and energy saving optimization of central air-conditioning system in metro station [D]. Xi'an: Xi'an University of Architecture and Technology, 2019.
- [21] 丛爽. 面向 Matlab 工具箱的神经网络理论与应用[M]. 合肥: 中国科学技术大学出版社, 2013.
- CONG Shuang. Neural network theory and applications with Matlab toolboxes [M]. Hefei: China University of Science and Technology Press, 2013.
- [22] 周志华. 机器学习[M]. 北京:清华大学出版社, 2016.
- ZHOU Zhihua. Machine learning [M]. Beijing: Tsinghua University Press, 2016.
- [23] KENNEDY J, EBERHART R C, SHI Y. Swarm intelligence [M]. San Francisco: Morgan Kaufman Publishers, 2001.
- [24] 潘文超. 果蝇最佳化演算法——最新演化式计算技术[M]. [S.l.]: 澹海书局, 2011.
- PAN Wenchao. Fluit fly optimization algorithm: The latest evolutionary computing technology [M]. [S.l.]: Danhai Book Company, 2011.