

基于鲸鱼优化算法的高效制冷机房负荷预测研究

潘亚男, 崔红社*, 刘高伟

(青岛理工大学 环境与市政工程学院, 青岛 266525)

摘要: 为了准确预测建筑冷负荷, 降低机房能耗, 提出了基于鲸鱼优化算法(WOA)的 BP 神经网络预测模型。基于青岛办公建筑的实际历史运行数据, 建立了 BP 神经网络、基于粒子群寻优的 BP 神经网络(PSO-BP)、基于遗传算法改进的 BP 神经网络(GA-BP)、基于鲸鱼优化算法的 BP 神经网络(WOA-BP) 4 种负荷预测模型, 并比较了 4 种负荷预测模型的结果。研究表明, 短期预测内, WOA-BP 神经网络预测模型的最大百分误差为 -15.76%, 最小百分误差为 -0.03%, 平均绝对值百分误差为 6.60%。与其他模型相比, WOA-BP 模型具有更高的预测精度。

关键词: 建筑节能; 鲸鱼优化算法; 负荷预测; BP 神经网络

中图分类号: TK01⁺8 **文献标志码:** A **文章编号:** 1673-4602(2024)06-0118-08

Research on the load forecast of high-efficiency refrigeration room based on whale optimization algorithm

PAN Yanan, CUI Hongshe*, LIU Gaowei

(School of Environmental and Municipal Engineering, Qingdao University of Technology, Qingdao 266525, China)

Abstract: In order to accurately forecast the cooling load of buildings and reduce the energy consumption of the refrigeration room, a BP(Back Propagation) neural network forecasting model based on the whale optimization algorithm (WOA) is proposed in this paper. Based on the actual historical operational data of office buildings in Qingdao, four load forecasting models were established, namely BP neural network, BP neural network based on particle swarm optimization (PSO-BP), BP neural network improved by genetic algorithm (GA-BP) and BP neural network based on whale optimization algorithm (WOA-BP). A comparative analysis of the results from these four load forecasting models was conducted. The research shows that in the short-term forecasting, the maximum percentage error of WOA-BP neural network forecasting model is -15.76%, the minimum percentage error is -0.03%, and the average absolute percentage error is 6.60%. Compared with the other models, WOA-BP model has higher forecasting accuracy.

Key words: building energy saving; whale optimization algorithm(WOA); load forecast; Back Propagation neural network

收稿日期: 2024-04-15

基金项目: 国家自然科学基金青年科学基金资助项目(52204039)

作者简介: 潘亚男(1998—), 女, 山东东营人。硕士, 研究方向为建筑节能。E-mail: pandyx2021@163.com。

* 通信作者: 崔红社(1971—), 男, 山东青岛人。博士, 副教授, 主要从事人工环境与建筑节能等方面的研究。
E-mail: cuihongshe@sina.com。

“双碳”目标对公共建筑的能耗提出了更高要求,在公共建筑能耗中,暖通空调系统能耗是主要组成部分,占比达 30%~40%^[1],降低空调系统的能耗是实现建筑节能的重要举措。

根据制冷机房历史运行数据,结合当地环境变量,例如温度、湿度等,进行负荷预测分析,提前设定设备启停时间及运行参数,可有效减少人工调节造成的能耗损失。随着机器学习技术的不断进步,国内外学者提出了各种预测模型。王保国等^[2]提出了 WNN 和 WSK-SV 算法,并将其应用于人机系统中。孙光伟等^[3]建立了 4 种神经网络预测模型,对用 BP 神经网络进行逐时空调负荷预报的建模方法进行了研究。孙锐^[4]将 BP 神经网络模型应用到冷负荷预测中,提出制冷机房负荷预测-参数寻优的控制策略。FAN 等^[5]采用公共建筑制冷系统的多元非线性回归(MNR)模型来准确预测短期冷负荷。陈柳^[6]提出小波时间序列方法,对未来的空调负荷逐步做出预测。

空调负荷具有非线性、非平稳性和随机性的特点,且易受天气因素影响,使用传统的预测方法进行负荷预测误差较大,需要对负荷预测方法进行优化。马倩倩等^[7]提出 LM-BP 神经网络,结合粒子群优化算法,建立基于建筑历史数据的空调系统冷负荷神经网络预测模型。李宗霖等^[8]将 PSO-Elman 预测模型与 Elman 预测模型的预测结果进行对比分析,研究表明,PSO-Elman 预测模型能够更精确有效地预测商业建筑空调的冷负荷。杨熊等^[9]基于 PSO-BP 神经网络预测模型,预测大型公共建筑冷负荷,模型预测精度和收敛速度均得到优化。YU 等^[10]结合了 JMP 数据分析、PSO-BP 神经网络和马尔科夫链,对商场冷负荷进行预测,预测精度更高。张军等^[11]针对小型楼宇电、冷、热多元负荷预测,建立了基于鲸鱼优化算法(WOA)的时序卷积神经网络预测模型,有效降低了多元负荷预测误差。

综合上述研究成果可见,针对公共建筑空调系统的能耗优化,采用先进的预测模型和智能控制算法是必不可少的。本文提出了一种新的负荷预测模型,即 WOA-BP 神经网络模型。通过结合鲸鱼优化算法(WOA)和 BP 神经网络的优点,提高空调冷负荷预测的准确性和效率,为公共建筑的能源节约提供参考。

1 神经网络负荷预测模型

1.1 BP 神经网络

BP 神经网络(Back Propagation Neural Network, BP)是一种常用的人工神经网络模型。它包括输入层、隐含层和输出层,神经元通过带有不同权重的连接相互联系,将信号传递至下一层。BP 神经网络的训练过程包括前向传播和反向传播 2 个阶段,前向传播计算网络输出,而反向传播根据损失函数的梯度调整连接权重。图 1 为 3 层 BP 神经网络的结构。

BP 神经网络具有较强的非线性拟合能力和泛化能力,常用于解决分类和回归等问题。然而,BP 神经网络在处理大规模数据和复杂问题时容易出现局部极小化、收敛速度慢、过拟合等问题^[12]。

1.2 WOA-BP 神经网络预测模型

鲸鱼优化算法(Whale Optimization Algorithm, WOA)是一种新兴的智能优化算法。该算法受到座头鲸的气泡网捕猎策略启发而来,包括搜索觅食、收缩包围和螺旋更新位置 3 个阶段,在许多数值优化和工程问题的求解中表现出较好的寻优性能,具有较好的全局搜索性能^[13]。为了改善 BP 神经网络存在的问题,本文结合鲸鱼优化算法(WOA),引入了 WOA-BP 神经网络预测模型,以优化神经网络的训练过程,提高模型的综合性能。算法流程如图 2 所示。




图 1 3 层 BP 网络结构

2 模型搭建

2.1 确定输入输出数据

建筑能耗预测通常将室内气候条件视为室外气候条件的直接代表,即室内气候条件与室外气候条件存在直接的正比例关系^[14]。因此,在传统建筑中,空调系统的控制方式通常采用反馈控制。这种控制方

式通过设定好的运行调节公式,实时监控室内温度,使其接近设定温度并保持稳定^[15]。然而,这种过程存在时间上的滞后,且建筑本身具有热惰性,导致给定时间的室外条件与同一时间的室内条件并不完全匹配。因此,在进行负荷预测时,需要考虑到时滞性对建筑负荷的影响,输入量应当包括预测时刻之前的室外气候条件数据。

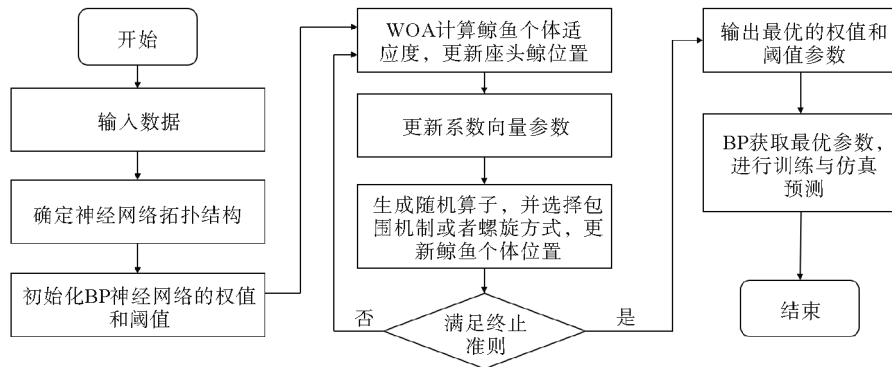


图2 WAO-BP神经网络训练流程

由于机组反应存在一定的时间延迟,使用当天实时负荷数据进行预测可能会导致控制滞后,因此,选择利用前一天的历史数据进行预测。同时,气象数据可通过天气预报等方式获取。综合考虑这些因素,选取了预测日当天的温度和露点温度,以及前一天预测时刻的冷负荷作为模型的负荷影响因素。

对得到的预测指标与 T 时刻冷负荷进行皮尔逊相关性分析:

$$r = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2} \sqrt{\sum (Y_i - \bar{Y})^2}} \quad (1)$$

式中: r 为选取的变量与 T 时刻冷负荷之间的皮尔逊相关系数; X_i 、 Y_i 分别为该变量与 T 时刻冷负荷的观测值; \bar{X} 、 \bar{Y} 分别为该变量与 T 时刻冷负荷的均值。

当 $|r| > 0.3$ 时,认为变量之间存在较强的相关性,可以将其作为最终的有效影响因素。

2.2 数据预处理

在训练神经网络时,需要特别关注训练集的规模和质量,因为它们直接影响模型的预测效果。由于制冷运行数据的采集受到人为因素、设备故障和采样精度等影响,可能会出现缺失值或异常值^[16]。为了提高预测的准确性,需要对输入输出数据进行清洗,消除缺失值和异常值。采用马氏距离法识别离群值,并将其视为缺失值处理;随后,通过插值方法填充缺失值,并直接删除异常值;最后,对处理后的数据进行归一化处理,以确保神经网络模型的稳定训练。

2.2.1 离散值辨别

马氏距离(Mahalanobis Distance)表示两点的空间距离,可以计算 2 个未知样本集的相似度,常用于检测涉及多个变量的统计分析中的异常值。具体定义为

$$D_{MAH} = \sqrt{(x - \mu)^T \Sigma^{-1} (x - \mu)} \quad (2)$$

式中: D_{MAH} 为计算得到的马氏距离; Σ 为样本数据集 X 方差协方差矩阵; μ 为 X 的质心; x 为样本数据集 X 内的数据, μ 、 x 均为空间向量。

由于马氏距离服从卡方分布,因此将 p 值低于 0.001 的数据认为是离散值。 p 值计算方式为

$$p = 1 - D_{CDF, CHISQ}(D_{MAH}, D_{df}) \quad (3)$$

式中: $D_{CDF, CHISQ}$ 为元素的卡方累积分布函数; D_{df} 为自由度,即变量个数。

2.2.2 数据归一化

数据归一化是一种通过无量纲的处理手段,将数据按比例缩放,使其落入特定的范围。主要目的是补

偿数据不匹配现象、消除数据属性值间的差别、平滑数据样本值的波函数^[17]。对于每个特征,使用公式(4)进行缩放:

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (4)$$

式中: x_{norm} 为归一化的数据值; x_{\max} 、 x_{\min} 分别为数据集中每个特征的最大值和最小值。

2.3 预测模型搭建

将处理完的数据划分为训练集和测试集。训练集用于训练模型,测试集用于评估模型的性能。建立 WOA-BP 负荷预测模型,模型预测主要包括以下过程:

1) 节点数目确定:输入层的节点数应等于选取的负荷影响指标的数量,而输出层通常只有 1 个节点,因为负荷预测是一个回归问题,需要预测一个连续的数值。至于隐含层的节点数,则是一个关键参数,它决定了模型的复杂度和表达能力。本文参照经验公式对隐含层节点数进行确定:

$$N_h = \text{sqrt}(N_i + N_o) + \alpha \quad (5)$$

式中: N_h 是隐含层节点数; N_i 是输入层神经元个数; N_o 是输出层神经元个数; α 是可以自取的任意变量,通常范围可取 1~10。

2) 模型训练过程:使用 WOA 算法对 BP 神经网络进行训练。通过反向传播算法来更新权重和偏置,以最小化损失函数。采用批量梯度下降(Batch Gradient Descent)的优化算法来调整模型参数,以提高模型的收敛速度和准确性(图 3)。

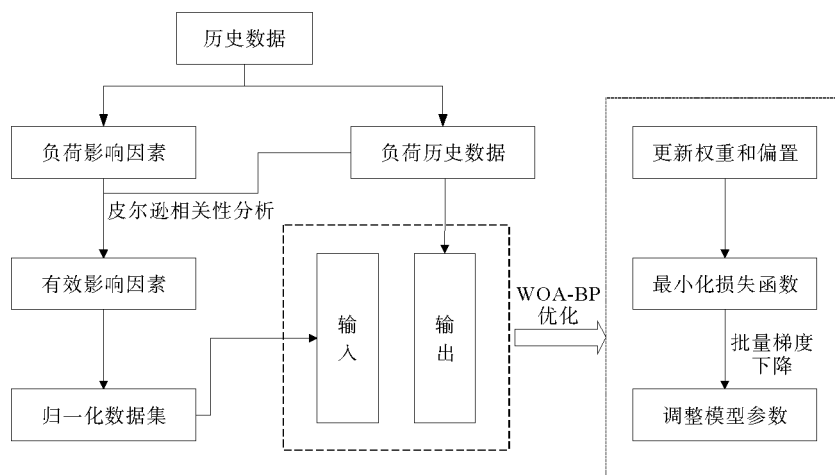


图 3 模型预测过程

2.4 预测模型评价指标

为对负荷预测模型做出更为精准的评价,本文采用百分误差(D_{PE})、平均绝对值百分误差(D_{MAPE})作为预测模型的评价指标。二者表达式如下:

$$D_{PE} = \frac{x_i - \hat{x}_i}{x_i} \quad (6)$$

$$D_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - \hat{x}_i}{x_i} \right| \quad (7)$$

式中: \hat{x}_i 为预测值; x_i 为真实值; n 为数据样本数量。

3 算例分析

3.1 算例概况

为验证本文所提方法的预测效果,以青岛市某办公建筑为实际研究案例。该建筑于 2020 年开始使

用,空调系统运行时间为工作日的8:00—16:00,夜间、周末及节假日停机。采集该项目近3年的制冷季运行数据,包括环境温度和建筑冷负荷。采样设备为温度自计仪、冷热量,采样间隔为1 h。由于无法测量建筑物实际负荷,当供需平衡时,实际负荷供应量等于需求量^[18],故本文采集的冷负荷数据为冷负荷供应量。露点温度数据来源于美国国家气候数据中心(National Climatic Data Center, NCDC),时间精度为1 h。

本文将2020年7—9月、2021年7—9月和2022年7—8月的冷负荷数据和天气数据作为训练集,共1002组数据;将2022年9月1—9日的冷负荷数据和天气数据作为测试集,共60组数据。

3.2 有效影响因素

图4为该建筑一典型日的室外气候条件与冷负荷变化曲线。如图4所示,1 d内的太阳辐射值先升高后降低;环境温度随太阳辐射值变化也呈先升高后降低的趋势;建筑冷负荷虽然整体呈下降趋势,但其变化也受到太阳辐射和环境温度的影响。具体来说,太阳辐射峰值和室外环境温度峰值分别出现在11:00和12:00,而冷负荷在下午13:00再次出现峰值。理论上,室外环境温度的变化应当与冷负荷的变化同步进行,但实际情况是它们之间存在一定的延时现象。




图4 青岛某建筑一典型日室外气候条件与冷负荷变化曲线

—◆— 环境温度; —■— 太阳辐射; —●— 冷负荷

因此,选取预测时刻和之前时刻的温度和露点温度,以及前一天的历史数据作为负荷影响因素,并对它们与 T 时刻的冷负荷进行皮尔逊相关性分析。在皮尔逊相关性分析中,相关系数 r 的取值范围为 $[-1, 1]$,且 $|r|$ 越大,表示相关性越强;显著性小于0.001时,认为存在显著相关性。本研究将 $|r| > 0.3$ 作为显著相关性的阈值,可用于负荷预测模型影响因素的选择。相关性分析结果如表1所示。

通过筛选,得到最终的负荷影响因素,分别为 T 、 T_1 、 T_2 、 T_{24} 时刻的环境温度和露点温度、 T_{24} 时刻的冷负荷。将这9个数据作为输入值,输出值为 T 时刻的冷负荷。

3.3 算例数据预处理

对输入输出数据进行清洗,消除缺失值和异常值。通过计算马氏距离进行数据离散值分析,得到

表1 负荷影响因素相关性分析

负荷影响因素	相关系数	显著性
T 时刻环境温度	0.581	<0.001
T_1 时刻环境温度	0.554	<0.001
T_2 时刻环境温度	0.552	<0.001
T_3 时刻环境温度	0.052	0.670
T_{24} 时刻环境温度	0.530	<0.001
T 时刻露点温度	0.541	<0.001
T_1 时刻露点温度	0.523	<0.001
T_2 时刻露点温度	0.529	<0.001
T_3 时刻露点温度	0.087	0.020
T_{24} 时刻露点温度	0.605	<0.001
T_{24} 时刻冷负荷	0.829	0.000

D_{MAH} 值,根据式(3)计算得到 p 值。若 $p < 0.001$ 则为离群值,将其标记为缺失值;反之,则为正常值进行保留。图 5 为 p 值分布散点图,共有 52 组数据 $p < 0.001$,将其标记为图中所示的菱形绿色方块,横坐标为离群值数据对应的 D_{MAH} 值。随后,通过插值方法填充缺失值,并直接删除异常值。

考虑到本文数据的取值范围差异较大,例如负荷数据在 [110, 2200],室外环境温度在 [20, 33],露点温度在 [8, 29],这可能导致神经元输出的饱和现象,从而影响网络的学习效果。为了解决这个问题,需要对样本进行归一化处理,将不同特征的取值范围映射到相同的区间内。这样做有助于加速神经网络的训练过程,提高模型的性能。图 6 为数据归一化处理前后的 3D 散点图。




图 5 p 值分布散点图

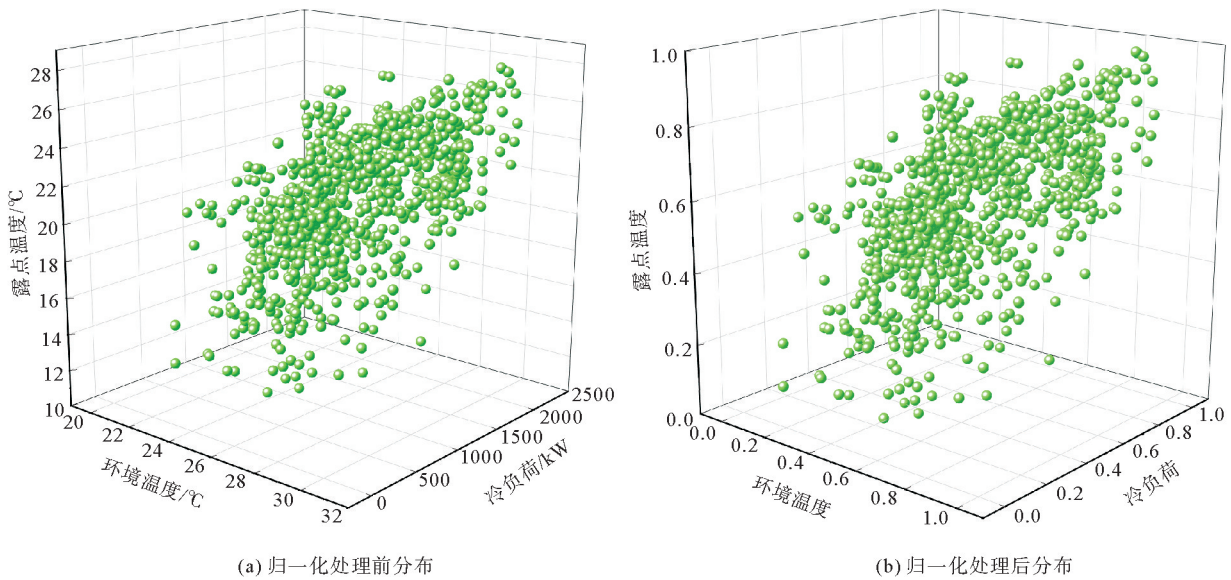


图 6 归一化处理前后数据分布对比

训练样本数据归一化后,将其输入到网络中,并结合鲸鱼优化算法对 BP 神经网络进行优化。在此过程中,设置网络的输入层和隐含层激活函数为 tansig 函数,输出层的激活函数为 logsig 函数。使用 trainlm 函数进行反向传播训练。根据式(5),并经过多次实验,将隐含层神经元数设定为 9,建立 BP 神经网络,网络结构为 9-9-1。最后,采用批量梯度下降(Batch Gradient Descent)的优化算法调整模型参数,以提高模型的收敛速度和准确性。

3.4 算例结果

为了验证 WOA-BP 神经网络的寻优性能,本文在同一个数据集下分别采用 BP 神经网络、基于粒子群寻优的 BP 神经网络(PSO-BP)、基于遗传算法改进的 BP 神经网络(GA-BP)和基于鲸鱼算法优化的 BP 神经网络(WOA-BP)进行机房的负荷预测。

图 7 为测试集中负荷预测方案的预测结果,可以观察到,4 种预测方法得到的预测结果与真实值总体波动趋势一致。在短期预测中,PSO-BP、GA-BP 和 WOA-BP 这 3 种预测方法更接近真实值,表现更为出色。

图 8 展示了 4 种预测方法的百分误差棒。图中圆球代表着真实值与预测值的数据均值,误差棒则反映了预测误差的范围,误差棒越长表示误差越大,反之则误差越小。尽管在个别时刻,本文提出的预测方

法存在较大误差,但总体来看,在其他时刻的误差均小于其他预测方法,这表明了本文提出的基于 WOA-BP 神经网络的预测方法在短期预测中表现出色。





表2为4种负荷预测方式的最大、最小百分误差和平均绝对值百分误差。从表2可以看出,4种模型的拟合效果都较为良好。其中,BP神经网络的最大百分误差最大,为 -20.83% ; PSO-BP和GA-BP的最大、最小百分误差相近,但PSO-BP神经网络预测模型的平均绝对值百分误差较大,为 10.74% ,存在较多误差较大的预测结果,这在误差棒图中也有所体现,表明该模型的预测准确性较差。而WOA-BP的最大、最小百分误差及平均绝对值百分误差均小于以上3种模型,说明在负荷预测方面,本文提出的鲸鱼算法优化的BP神经网络预测结果更加准确。

表2 误差对比

预测方法	最大 D_{PE}	最小 D_{PE}	D_{MAPE} %
BP	-20.83	0.15	9.76
PSO-BP	18.70	-0.74	10.74
GA-BP	18.77	-0.80	9.18
WOA-BP	-15.76	-0.03	6.60

4 结论

本文采用了基于鲸鱼优化算法的BP神经网络预测模型的方法,并基于实际项目历史运行数据进行算例分析,以实现建筑冷负荷的精准预测:

1) 鲸鱼优化算法是一种新兴的智能优化算法,通过模拟鲸鱼觅食的过程来搜索最优解。本文将其应用于BP神经网络中,以优化网络的权重和偏置,提高模型的性能和泛化能力。

2) 基于实际历史运行数据,将优化后的模型与传统的BP神经网络、PSO-BP神经网络和GA-BP神经网络预测模型进行比较。通过比较各模型的最大、最小百分误差和平均绝对值百分误差,评估其预测性能。结果表明,基于鲸鱼算法优化的BP神经网络预测模型在短期冷负荷预测方面表现出色,最大百分误差为 -15.76% ,最小百分误差为 -0.03% ,平均绝对值百分误差为 6.60% 。

3) 通过采用鲸鱼优化算法优化BP神经网络,本文实现了较高精度的冷负荷预测。这种方法能够有效利用历史数据和实时气象信息,准确预测建筑冷负荷,为提高机房能耗管理和控制水平提供参考。

参考文献(References):

- [1] 孙洪鹏,陈晨,张广智. 国内大型公共建筑空调系统运行管理现状调查研究[J]. 建筑节能,2020,48(10):8-13.
SUN Hongpeng, CHEN Chen, ZHANG Guangzhi. Investigation on the operation and management of air-conditioning system for large public buildings in China[J]. Building Energy Efficiency, 2020, 48(10): 8-13.

- [2] 王保国,黄伟光,徐燕骥,等.两种智能高效预测方法及其在人机系统中的应用[J].青岛理工大学学报,2012,33(5):82-85.
WANG Baoguo,HUANG Weiguang,XU Yanji,et al. Two efficient and intelligent forecasting methods and application in human-machine system[J]. Journal of Qingdao Technological University,2012,33(5):82-85.
- [3] 孙光伟,索胜军,陶永纯,等.基于BP网络的空调负荷预报建模方法的研究[J].哈尔滨建筑大学学报,1999(3):79-82.
SUN Guangwei,SUO Shengjun,TAO Yongchun,et al. The research on load prediction model of air-conditioning system based on BP neural network[J]. Journal of Harbin University of Civil Engineering and Architecture,1999(3):79-82.
- [4] 孙锐.基于粒子群优化的高效制冷机房负荷预测及控制策略研究[D].青岛:青岛理工大学,2022.
SUN Rui. Research on load forecast and control strategy of high-efficiency refrigeration station based on particle swarm optimization[D]. Qingdao:Qingdao University of Technology,2022.
- [5] FAN C,DING Y. Cooling load prediction and optimal operation of HVAC systems using a multiple nonlinear regression model[J]. Energy and Buildings,2019,197:7-17. DOI:10.1016/j.enbuild.2019.05.043.
- [6] 陈柳.小波时间序列在空调负荷预测中的应用[J].流体机械,2008,36(2):83-86.
CHEN Liu. Application of wavelet analysis and time series in air conditioning load forecasting[J]. Fluid Machinery,2008,36(2):83-86.
- [7] 马倩倩,崔红社,孙锐,等.基于PSO-LM-BP算法的空调系统节能预测控制研究[J].低温与超导,2022,50(4):65-70. DOI:10.16711/j.1001-7100.2022.04.011.
MA Qianqian,CUI Hongshe,SUN Rui,et al. Energy saving predictive control of air conditioning system based on PSO-LM-BP algorithm[J]. Cryogenics & Superconductivity,2022,50(4):65-70. DOI:10.16711/j.1001-7100.2022.04.011.
- [8] 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.
LI Zonglin,LEI Lei,GUO Xuesong. Air-conditioning cooling load prediction in commercial buildings based on rough set and PSO-Elman[J]. Fluid Machinery,2023,51(6):53-59.
- [9] 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(中英文),2019,41(1):168-174.
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):168-174.
- [10] YU J Q,JING W Q,ZHAO A J,et al. Application of improved PSO-BP neural network in cold load forecasting of mall air-conditioning[J]. Journal of Control Science and Engineering,2019(12):1-9. DOI:10.1155/2019/2428176.
- [11] 张军,张河宜,肖嵘,等.考虑气象因素的WOA-TCN楼宇IES多元负荷预测[J].电气时代,2023(10):65-68.
ZHANG Jun,ZHANG Heyi,XIAO Rong,et al. Multivariate load forecasting of WOA-TCN building IES considering meteorological factors[J]. Electric Age,2023(10):65-68.
- [12] 李威武,白永利,罗世刚,等.结合改进聚类算法与PSO-GA-BP神经网络算法的日最大负荷预测方法[J].中南民族大学学报(自然科学版),2023,42(6):819-827. DOI:10.20056/j.cnki.ZNMDZK.20230613.
LI Weiwu,BAI Yongli,LUO Shigang,et al. A combination of improved clustering algorithm and PSO-GA-BP neural network algorithm for daily maximum load prediction[J]. Journal of South-Central Minzu University(Natural Science Edition),2023,42(6):819-827. DOI:10.20056/j.cnki.ZNMDZK.20230613.
- [13] MAHMOOD S,BAWANY N Z,TANWEER M R. A comprehensive survey of whale optimization algorithm:Modifications and classification[J]. Indonesian Journal of Electrical Engineering and Computer Science,2023,29(2):899.
- [14] YUN G Y,LEE J H,STEEMERS K. Extending the applicability of the adaptive comfort model to the control of air-conditioning systems[J]. Building and Environment,2016,105:13-23.
- [15] 黄巍,于震,李怀,等.近零能耗建筑空调负荷预测研究[J].建筑节能(中英文),2021,49(6):72-78.
HUANG Wei,YU Zhen,LI Huai,et al. Load prediction of HVAC system in nearly zero energy building[J]. Building Energy Efficiency,2021,49(6):72-78.
- [16] 吴劲松,张少峰,徐向民,等.计及PUE的数据中心短期电力负荷预测方法[J].哈尔滨理工大学学报,2021,26(6):1-9. DOI:10.15938/j.jhust.2021.06.001.
WU Jinsong,ZHANG Shaofeng,XU Xiangmin,et al. Short-term power load forecasting method of data center considering PUE[J]. Journal of Harbin University of Science and Technology,2021,26(6):1-9. DOI:10.15938/j.jhust.2021.06.001.
- [17] 汤荣志,段会川,孙海涛.SVM训练数据归一化研究[J].山东师范大学学报(自然科学版),2016,31(4):60-65.
TANG Rongzhi,DUAN Huichuan,SUN Haitao. Research on data normalization for SVM training[J]. Journal of Shandong Normal University(Natural Science),2016,31(4):60-65.
- [18] 闫军威,卢泽东,周璇.基于NSGA-II的冷源机房设备运行参数多目标优化[J].科学技术与工程,2021,21(7):2896-2903.
YAN Junwei,LU Zedong,ZHOU Xuan. Multi-objective optimization of operating parameters of central air conditioning cold source equipmentroom based on NSGA-II[J]. Science Technology and Engineering,2021,21(7):2896-2903.