

一种基于数据驱动的空调负荷预测方法

周孟然,周光耀,胡锋,朱梓伟,张奇奇,王玲,孔伟乐,吴长臻,崔恩汉

(安徽理工大学 电气与信息工程学院,安徽 淮南 232001)

摘要:空调负荷预测是空调负荷潜力分析和电网空调负荷调控的基础,为了精确地对空调负荷进行预测,文中提出了一种考虑到外界影响因素以及集成优化的空调负荷预测方法.首先,拟定好实验运行方案并采集影响因素数据.其次,使用近邻成分分析(NCA)方法进行特征选择,剔除重要度小的特征.然后使用白鲨优化算法(white shark optimizer, WSO)对支持向量回归(support vector regression, SVR)的正则化参数和核函数的宽度参数进行优化,最后,结合自适应提升算法(adaptive boosting, Adaboost)构建 Adaboost-WSO-SVR 主模型,检验其精度并与其他方法进行比较.结果表明,提出的 Adaboost-WSO-SVR 主模型相比于集成优化后的 BP, ELM 模型精度更高.可知提出的方法在负荷预测方面效果更好,为空调节能优化控制策略提供依据.

关键词:空调负荷;负荷预测;特征选择;白鲨优化算法;自适应提升算法;支持向量回归

中图分类号: TU831

文献标志码: A

文章编号: 1000-2367(2025)03-0128-07

空调耗能是我国耗能总负荷中占比相当大的一个方面,属于高耗能、高排放的一个产业^[1].我国经济发展得越来越好,空调冬夏的使用频率越来越高.特别是夏季,在某些大城市空调负荷能占到总负荷的 30%~40%,在上海等一线城市甚至可以达到 50%^[2-4].这些现象说明空调负荷能够为电力系统提供巨大的调控容量,这是电网调度需要重视的一点.准确地判断空调负荷的大小至关重要^[5].

空调负荷受多种影响因素影响,如何有效地判断哪种特征对空调负荷影响较大是比较关键的^[6].KHAN 等^[7]将随机森林(RF)和极端梯度提升(XGBoost)的方法组合起来,得到每个特征的重要度,使用递归特征消除来剔除冗余特征.XU 等^[8]使用主成分分析(PCA)的方法突出异常特征.ZHU 等^[9]使用斯皮尔曼相关系数来选择高质量的输入特征,并消除与电力消耗弱相关的变量.王永利等^[10]利用最大信息系数(MIC)分析多元负荷之间、多元负荷与天气因素之间的相关性,得到负荷的强相关性变量.易礼秋^[11]采用皮尔逊相关系数法分析影响因素对负荷的影响,借助皮尔逊相关系数分析选取了 23 个相关性较强的主要影响因素.本研究采用的近邻成分分析(NCA)方法作为一种特征降维方法,有着适应性强、灵活性高、结构简单等优点,被研究者广泛使用.

目前,大多数预测空调能耗的方法可以分为 2 类:物理模拟预测和数据驱动预测.物理模拟一般通过 TRNSYS, EnergyPlus 等软件来模拟空调能耗^[12].这些模型都需要明确建筑的物理参数以及系统内部的运行参数,但在实际情况中,这些物理参数往往很难获得,导致模型的精度比较低.除此之外,这些仿真软件往往需要花费很多时间去学习,使用成本较大.因此,数据驱动预测变得越来越受研究者的青睐.

收稿日期: 2024-06-23; **修回日期:** 2024-09-30.

基金项目:国家自然科学基金(52374177);安徽省自然科学基金能源互联网联合基金重点项目(2008085UD06);国网安徽省电力有限公司阜阳供电公司科技项目(SGAHFY00TKJS2310510).

作者简介:周孟然(1965—),男,安徽淮南人,安徽理工大学教授,博士,博士生导师,研究方向为负荷预测、电网调度等, E-mail: mrzhou8521@163.com.

通信作者:周光耀, E-mail: 499782835@qq.com.

引用本文:周孟然,周光耀,胡锋,等.一种基于数据驱动的空调负荷预测方法[J].河南师范大学学报(自然科学版),2025, 53(3): 128-134.(Zhou Mengran, Zhou Guangyao, Hu Feng, et al. A data-driven method for air conditioning load forecasting[J]. Journal of Henan Normal University(Natural Science Edition), 2025, 53(3): 128-134. DOI: 10.16366/j.cnki.1000-2367.2024.06.23.0001.)

数据驱动预测一般使用机器学习算法并依赖历史数据来对未来的负荷进行预测.张晨晨^[13]使用长短期记忆神经网络(LSTM)来对空调负荷进行预测.WANG 等^[14]使用人工神经网络 ANN 结合部分物理规则对建筑物冷负荷进行了动态预测,提高了负荷预测精度.张磊等^[15]使用 XGBoost 算法构建了电力系统惯量短期预测模型.以上观点虽然预测效果良好,但预测形式比较单一.本研究采用的集成学习方法通过集成多个弱学习器的方法,不断调整下一个弱学习器的权重,最后组成一个强学习器,能达到较好的预测精度.

优化算法通过不断迭代找寻最优解的方式能为预测模型找寻到最适合的参数,以此提高模型的精确度.HU 等^[16]采用改进的果蝇算法(IFOA)对 SVR 进行优化,并结合了案例确定优化后的 SVR 具有更高的预测性能.白宇等^[17]使用金豺优化算法(GJO)优化了 CNN-BiLSTM 的参数,解决了因 CNN-BiLSTM 网络的超参数选取不当而影响热负荷预测结果的问题.王强等^[18]使用鹌鹑优化算法(POA)对深度极限学习机(DELM)进行优化,极大提升了模型精度.白鲨优化算法(WSO)作为一种新颖的元启发式算法,通过模拟大白鲨觅食和追踪的行为找寻最优解,具有高效的全局搜索能力^[19].

基于以上观点,本研究针对传统空调负荷预测,提出以下创新点:1)本研究首先制定了一个采集空调负荷功率以及相关影响因素的实验方案,并准备实验设备去采集相关数据,故本研究所用样本数据均为独立测得.2)采用了 NCA 作为本研究的特征筛选方法,能够有效地分析数据的相关性,并剔除相关性较小的特征.3)使用集成学习以及优化算法的方法来构建本研究的预测主模型,通过集成多个弱学习器,最后合成一个强学习器,并与其他模型进行对比实验,来验证本文模型的优越性.

1 理论介绍

1.1 近邻成分分析

近邻成分分析是一种基于最邻近(KNN)算法的特征选择方法^[20],此方法通过最小化训练数据上的留一法分类误差来学习特征权重向量,通过二次马氏距离度量,使用对称半正定矩阵表示,输入的特征根据线性变换能够最大程度提升分类准确率或预测的精度,并提供属性的重要度和特征排序^[21].

1.2 Adaboost 模型

Adaboost 集成算法,也叫自适应推进算法,是一种机器学习中集成学习领域的算法^[22],可运用于回归与分类问题.Adaboost 算法是通过集成多个弱学习器,将其组合成一个强学习器,这个强学习器的学习能力会优于弱学习器,它的本质是通过调整弱学习器的样本权重大小来进行强学习器组合的,对于正确学习的数据,它们的权重会变低,对于错误学习的数据,权重会变高,使得后续的弱学习器集中训练这些数据.

1.3 白鲨优化算法

白鲨优化算法是由 BRAIK 等^[23]2022 年提出的一种元启发式算法.具有搜索方式连续稳定、能快速高效的达到全局最优解的优点.在海洋中,白鲨需要进行广泛的搜索才能确定猎物的位置.其中主要分为 3 步.1)快速向猎物运动.白鲨利用听觉和嗅觉基于猎物运动产生波动的情况来搜寻猎物.2)向最优猎物移动.白鲨在海洋深处随机搜寻猎物,向猎物位置移动并靠近最优猎物.3)向最优白鲨个体运动.白鲨利用鱼群行为,向最接近最优猎物的最优白鲨运动.具体步骤见文献^[24].

1.4 支持向量回归

支持向量回归(SVR)具体是使用构造分类超平面的方式将非线性回归映射为高维线性回归问题^[25],能在高维空间实现数据训练样本的线性回归,可将所有训练样本至平面误差降至最小.SVR 不但能解决线性回归问题,也能很好地解决非线性回归问题,相对于大规模数据来说,更适用于中小规模数据.SVR 算法模型的计算表达式如下:

$$y(x) = \sum_{j=1}^N [(\alpha_j^* - \alpha_j)K(x_j, x)] + d,$$

式中, x 为输入向量, y 为对应输出值, α_j^* 和 α_j 均为拉格朗日乘子, $K(x_j, x)$ 为核函数, d 为偏置量, N 为样本集总数.

1.5 评价指标

本研究使用相关系数 R^2 和平均绝对比例误差 $MAPE(M)$ 作为本研究模型的评价指标,

$$R^2 = 1 - (\sum_{i=1}^n (\hat{y}_i - y_i)^2 / \sum_{i=1}^n (\hat{y}_i - \bar{y})^2), M = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i) / y_i|,$$

式中, y_i 表示的是真实值, $\hat{y}_i$ 表示的是模型预测值, $\bar{y}$ 表示的是平均真实值, n 表示的是样本数量.

2 算例分析

2.1 实验环境

本研究采集数据的实验地点为某高校某学院的 2 间工作室.硬件使用联想拯救者笔记本 2022 版,CPU 为英特尔第 12 代酷睿 i5-12500H,使用 MATLAB2023b 仿真软件进行仿真实验.

2.2 实验准备

2.2.1 实验影响因素

影响空调负荷的参数主要分为:建筑物理参数、室内环境参数、室外气象参数以及建筑物内人员运行参数.建筑物理参数包括建筑使用面积、建筑高度、围护结构传热系数等.这些参数对空调负荷影响很大,但在负荷预测模型中很少考虑这些参数的影响.因为这些物理参数在空调运行周期内一般不会改变,可以将它们视作负荷预测的常数.室内环境参数主要是指建筑物的室内温度和室内湿度.这些参数受空调系统终端设备的影响,对人体舒适度影响较大.室外气象参数包括天气、风速、室外湿度、室外温度等.这些参数不受建筑物内部活动的影响,且相对容易采集,因此在空调负荷预测建模中更多考虑.空调负荷具有一定的周期性、规律性和滞后性.因此,历史时刻的空调负荷功率受到多种影响因素的影响,并且包含了各影响因素的变化趋势,因此常被用作预测模型的输出结果.

2.2.2 实验设备

本研究主要探究的是空调功率和各影响因素之间的关系,需要通过以下设备来测量实验数据.图 1 为测量数据的设备连接方案图.

温湿度记录仪:室内温湿度使用 COS-03USB 款温湿度内置探头传感器测量,室外温湿度使用 COS-03USB 款温湿度外延探头测量,温度精度均为 $\pm 0.1\text{ }^{\circ}\text{C}$,湿度精度均为 $\pm 1.5\%\text{ RH}$,为了提高实验的精确性,本研究采用的记录时间间隔为仪器可设定最小的 5 s 区间,为了防止数据过多,设定每天导出 1 次.供电电源:对三相电力采集模块和串口数据记录仪进行供电,将其设置为 24 V 电压.电流互感器:将此装置套在火线上,可放大测得的空调电流,本研究选择的型号为 JLCT45KX,精度为 0.2 级,变比为 150/5 A.三相电力采集模块:可测得空调的电流以及电压,型号为 E1-3DLCJ-V2,电压检测精度 $< 1.5\%$,电流检测精度 $< 1\%$.串口数据记录仪:将测得的空调电流和电压储存到 U 盘当中,本研究使用 DTSE9G3 系列 64 GB 的 U 盘,为了提高实验的精确性,记录间隔设置为 1 s,同样也每天导出 1 次.

2.2.3 实验样本数据点

实验地点分为 2 个场所:实验 A 配备了一台空调,实验 B 配备了 2 台空调,地点 A、B 空间大小、布局均是相同的,每台空调的型号也是相同的.以每 60 min 采样一次,选择空调运作时的时间段,将测得的空调功率以及室内外温湿度取均值.实验 B 选择 2 台空调同时运行的时间段取功率和温湿度的均值.

空调设定温度根据试验方案设定,空调台数通过实验地点确定,空调功率通过三相功率模块测得.室内外温湿度根据上述温湿度记录仪得到,人员散热量根据记录的人员流通情况确定,主要包括每个人使用的设备散热量(电脑)以及人体散热量(以 1 名成年的男士计算).天气和风速均通过实时天气预报测得,每 30 min 记录 1 次.天气情况使用数字来替代,1 代表晴天,2 代表多云,3 代表雨天,4 代表雾霾.




图1 实验设备连接方案图

Fig.1 Experimental equipment connection plan

2.3 实验方案

本研究采集实验数据的季节为冬季,故探究的是空调热负荷功率特性.实验时间为每天 8:00—22:00,空调设定温度从 20 ℃调至 30 ℃,设置空调每 60 min 升高 1 ℃,当调至最高温度后,每 60 min 降低 1 ℃.每隔 30 min 记录 1 次人员流通情况、天气情况、风速情况.

2.4 实验结果及对比

2.4.1 相关性分析

将采集的 474 组样本数据输入到 NCA 模型后,得到图 2.权重越大代表特征与空调功率的相关性越高,其中特征 1~9 分别对应空调设定温度、空调台数、室外温度、室湿度、室内温度、室内湿度、人员散热量、天气、风速.从图 2 中可以明显地看出特征 7,8(人员散热量以及天气情况)所占权重较低,由此可见特征 7,8 与空调功率的相关性较低.NCA 模型的阈值设定为 0.9,最终筛选出了 7 个特征,剔除了相关性较低的特征 7,8.将筛选后的 474 组样本数据整合成本研究所使用的数据集,并按 3 : 1 的比例划分为训练集和测试集.

2.4.2 基学习器选择

使用 SVR,BP,ELM 这 3 种简单的回归模型来对采集的样本数据集进行评估.3 种模型的参数设定值均为系统默认值.使用评价指标来判断模型的优劣,为了防止实验的偶然性,本研究采用 5 次实验的平均值作为结果,使实验结果更稳定(图 3).SVR 模型的效果是最好的,比 BP,ELM 模型的高;MAPE 比 BP,ELM 模型的低.




图2 特征相关性图

Fig.2 Feature importance diagram






图3 初始模型结果

Fig.3 Initial model results


使用 WSO 算法对 SVR,BP,ELM 模型进行参数寻优,需要确定 WSO 优化 3 种模型的参数类型,参数范围以及变量类型.WSO 优化 SVR 模型的参数为正 regularization 参数 c 和核函数的宽度参数 g ,参数范围为 $[0.1, 100]$,变量类型为浮点型,优化 BP 模型和 ELM 模型的参数均为初始权值和初始阈值 b ,参数范围为 $[-1, 1]$,变量类型为实数型.WSO 算法的种群数目设置为 30,迭代次数设置为 100,其他参数使用原始算法的默认参数,使用 MSE 作为算法的适应度函数.得到的各模型迭代曲线图如图 4 所示,随着迭代次数的增加,fitness 均不断减小,并趋于稳定.这意味着模型能找到更合适的参数值.



(a) WSO-SVR 迭代曲线



(b) WSO-BP 迭代曲线



(c) WSO-ELM 迭代曲线

图4 WSO算法优化3种模型的迭代曲线

Fig.4 Iteration curves of three models optimized by WSO algorithm

实验结果同样也取 5 次实验的平均值,用 3 种模型优化后得到的结果与优化前的结果作对比,如表 1 所示,可以看出,经过 WSO 算法优化后的 3 种模型效果均优于原始模型.且 WSO-SVR 模型的效果是最好的,评价指标 R^2 达到了 0.971 2,MAPE 达到了 3.55%,所以选择 WSO-SVR 模型作为本研究的基学习器.

表 1 基础预测模型与优化后的模型评价指标对比

Tab. 1 Comparison of evaluation indicators between the basic prediction model and the optimized model

预测模型	评价指标	结果	预测模型	评价指标	结果	预测模型	评价指标	结果
SVR	R^2	0.961 8	ELM	R^2	0.955 2	WSO-BP	R^2	0.962 3
	MAPE	4.16%		MAPE	5.32%		MAPE	4.54%
BP	R^2	0.942 8	WSO-SVR	R^2	0.971 2	WSO-ELM	R^2	0.961 2
	MAPE	5.99%		MAPE	3.55%		MAPE	4.76%

2.4.3 Adaboost-WSO-SVR 模型

本研究构建的主模型如图 5 所示,首先使用 WSO 算法优化 SVR 模型的 c, g 参数,构建出一个基础学习器,然后使用 Adaboost 算法集成一定数量的弱学习器,达到增强稳定预测的结果.

将已经筛选过特征的样本数据集训练集带入主模型中训练,训练好后带入测试集检验预测的情况.得到的测试集预测结果图如图 6 所示.可以看出,测试集预测结果集合能很好地拟合测试集的输出结果.

2.4.4 实验对比

为了验证 NCA 模型筛选特征的合理性,现将剔除了天气和人员散热量后的样本数据集与筛选前的样本数据集分别带入 Adaboost-WSO-SVR 模型中,使用评价指标 R^2 和 MAPE 来检验结果,评价指标在测试集的结果如图 7 所示,筛选后的样本数据集带入模型的效果要好于筛选之前的样本数据集,评价指标 R^2 值提高了 0.348 1,MAPE 值降低了 24.25%.




图5 Adaboost-WSO-SVR主模型
Fig. 5 Adaboost WSO-SVR main model




图6 测试集预测结果
Fig. 6 Test set prediction results




图7 特征筛选前后对比
Fig. 7 Comparison before and after feature screening

在 Adaboost-WSO-SVR 主模型与其他对比模型 Adaboost-WSO-BP,Adaboost-WSO-ELM 模型对比之前,为了防止实验的偶然性,使用 5 次实验的平均值作为结果,使实验结果更稳定,具有可靠性.得到的结果如表 2 所示.可以看出,Adaboost-WSO-SVR 模型的 MAPE 值是最低的,达到了 3.20%, R^2 值是最高的,达到了 0.972 9,效果比其他对比模型都好,说明了使用 Adaboost 模型集成 WSO-SVR 弱学习器是可行的.使用此方法能够提高负荷预测的精确度.

表 2 不同预测模型各评价指标对比

Tab. 2 Comparison of evaluation indicators of different prediction models

预测模型	评价指标	结果	预测模型	评价指标	结果	预测模型	评价指标	结果
Adaboost-WSO-ELM	R^2	0.966 2	Adaboost-WSO-BP	R^2	0.962 9	Adaboost-WSO-SVR	R^2	0.972 9
	MAPE	4.13%		MAPE	3.95%		MAPE	3.20%

3 结论与展望

本研究针对空调负荷预测问题进行了展开研究.得到了 474 组数据并将其以 3 : 1 的比例划分为训练集和测试集.使用 NCA 方法筛选出相关性较大的特征,剔除相关性较小的天气和人员散热量特征.然后进行基学习器的选择.本研究在 SVR,BP,ELM3 种简单的回归模型以及使用 WSO 算法优化后的 3 种模型中进行选择,结果表明选用 WSO-SVR 模型作为基学习器是最优的.由此构建了本研究的主模型——Adaboost-WSO-SVR 模型.为了验证特征筛选的效果,将筛选后的样本数据和筛选前的样本数据分别带入本研究的模型中,筛选后样本数据得到的 R^2 比筛选前提高了 0.348 1,MAPE 值降低了 24.25%,效果明显提高.最后将筛选后的样本数据带入 3 种集成优化后的预测模型当中,结果表明,本研究所采用的 Adaboost-WSO-SVR 模型精度是最高的, R^2 达到了 0.972 9,MAPE 值达到了 3.20%,预测效果比其他模型更好.为后续空调潜力分析和空调负荷电网调度提供了基础.未来的研究工作可以着重于改进白鲨优化算法,以便让本研究的模型取得更优秀的预测效果.

参 考 文 献

[1] 于军琪,边策,赵安军,等.考虑频域分解后数据特征的空调负荷预测模型[J].控制理论与应用,2022,39(6):1149-1157.

[2] 李丙辉.基于负荷预测的空调冷冻水系统节能优化研究[D].西安:西安建筑科技大学,2021.

[3] 贺宁,闫琦,李若夏,等.基于 CEEMDAN 和 TCN-GRU-MLR 模型的空调电负荷短期预测[J/OL].控制工程.[2024-04-10].<https://doi.org/10.14107/j.cnki.kzgc.20230938>.

[4] 杨永标,颜庆国,徐石明,等.公共楼宇空调负荷参与电网虚拟调峰的思考[J].电力系统自动化,2015,39(17):103-107.

YANG Y B,YAN Q G,XU S M,et al.Thinking of public building air-conditioning load participating in grid with virtual peak clipping[J].Automation of Electric Power Systems,2015,39(17):103-107.

[5] 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):142-150.

SUN Y Y,WANG D,WANG W,et al.Review of research on air-conditioning operating load prediction methods[J].Building Science,2016,32(6):142-150.

[6] 苏醒,王磊,田少宸,等.基于动态客流量模型的地铁车站空调负荷预测[J].同济大学学报(自然科学版),2022,50(1):114-120.

[7] KHAN S,HAYDER I,HABIB M,et al.Enhanced machine-learning techniques for medium-term and short-term electric-load forecasting in smart grids[J].Energies,2022,16(1):276.

[8] XU X,WEN H,LIN H J,et al.Online detection method for variable load conditions and anomalous sound of hydro turbines using correlation analysis and PCA-adaptive-K-means[J].Measurement,2024,224:113846.

[9] ZHU Z W,ZHOU M R,HU F,et al.A day-ahead industrial load forecasting model using load change rate features and combining FA-ELM and the AdaBoost algorithm[J].Energy Reports,2023,9:971-981.

[10] 王永利,刘泽强,董焕然,等.基于 VMD-CSO-RF 的综合能源系统短期负荷预测[J/OL].华北电力大学学报(自然科学版).[2024-04-11].<http://kns.cnki.net/kcms/detail/13.1212.TM.20240314.1850.002.html>.

[11] 易礼秋.基于长短期记忆神经网络变权综合的短期电力负荷预测[D].乌鲁木齐:新疆财经大学,2021.

[12] EGUÍA P,GRANADA E,ALONSO J M,et al.Weather datasets generated using Kriging techniques to calibrate building thermal simulations with TRNSYS[J].Journal of Building Engineering,2016,7:78-91.

[13] 张晨晨.混合优化的长短期记忆神经网络短期空调冷负荷预测及其应用研究[D].青岛:青岛大学,2022.

[14] WANG L,LEE E W M,YUEN R K K.Novel dynamic forecasting model for building cooling loads combining an artificial neural network and an ensemble approach[J].Applied Energy,2018,228:1740-1753.

[15] 张磊,李海涛,熊致知,等.基于可解释性 XGBoost 的电力系统惯量短期预测方法[J].电力建设,2023,44(8):22-30.
ZHANG L,LI H T,XIONG Z Z,et al.Short-term prediction method based on interpretable XGBoost for power system inertia[J].Electric Power Construction,2023,44(8):22-30.

[16] HU G,XU Z Q,WANG G R,et al.Forecasting energy consumption of long-distance oil products pipeline based on improved fruit fly optimization algorithm and support vector regression[J].Energy,2021,224:120153.

[17] 白宇,薛贵军,谢文举,等.改进 GJO 优化 CNN-BiLSTM 的热负荷预测模型[J/OL].中国测试.[2024-04-11].<http://kns.cnki.net/kcms/detail/51.1714.TB.20240328.1617.002.html>.

[18] 王强,刘宏伟,聂子凡.基于 VMDT-POA-DELM-GPR 的两阶段短期负荷预测[J].国外电子测量技术,2024,43(1):101-109.
WANG Q,LIU H W,NIE Z F.Two-stage short-term load forecasting based on VMDT-POA-DELM-GPR[J].Foreign Electronic Measurement Technology,2024,43(1):101-109.

[19] 李浩博,崔双喜,樊伟杰.基于改进白鲨算法的综合能源系统低碳经济调度[J/OL].电测与仪表.[2024-04-15].<http://kns.cnki.net/kcms/detail/23.1202.TH.20230215.1432.018.html>.

[20] GOLDBERGER J,ROWEIS S,HINTON G,et al.Neighbourhood components analysis[M].Cambridge,Mass:MIT Press,2005:17.

[21] 卞凯.基于体征参数的数据归约矿工健康状况辨识方法研究[D].淮南:安徽理工大学,2022.

[22] 方博扬,赵国彦,马举,等.Adaboost 集成学习优化的巷道围岩松动圈预测研究[J].黄金科学技术,2023,31(3):497-506.
FANG B Y,ZHAO G Y,MA J,et al.Prediction study on loosening ring of surrounding rock around roadways using the optimized ensemble learning algorithms based on adaboost[J].Gold Science and Technology,2023,31(3):497-506.

[23] BRAIK M,HAMMOURI A,ATWAN J,et al.White Shark Optimizer;a novel bio-inspired meta-heuristic algorithm for global optimization problems[J].Knowledge-Based Systems,2022,243:108457.

[24] 孙世政,庞珂,于竞童,等.基于白鲨优化极限学习机的三维力传感器非线性解耦[J].光学精密工程,2023,31(18):2664-2674.
SUN S Z,PANG K,YU J T,et al.Nonlinear decoupling of 3d force sensors based on WSO-ELM[J].Optics and Precision Engineering,2023,31(18):2664-2674.

[25] 满轲,曹子祥,刘晓丽,等.利用 HHO-LSTM-SVR 模型预测 TBM 掘进参数[J/OL].铁道标准设计.[2024-04-13].<https://doi.org/10.13238/j.issn.1004-2954.202309130004>.

A data-driven method for air conditioning load forecasting

Zhou Mengran, Zhou Guangyao, Hu Feng, Zhu Ziwei, Zhang Qiqi, Wang Ling, Kong Weile, Wu Changzhen, Cui Enhan
(College of Electrical and Information Engineering, Anhui University of Science and Technology, Huainan 232001, China)

Abstract: Air conditioning load forecasting is the basis for analyzing the potential of air conditioning load and regulating the air conditioning load of the power grid. In order to accurately predict the air conditioning load, this paper proposes an air conditioning load forecasting method taking into account of external influencing factors and integrates optimization. Firstly, develop an experimental operation plan and collect data on influencing factors. Secondly, the nearest neighbor component analysis (NCA) method is used for feature selection to remove features with low importance. Then the white shark optimizer(WSO) algorithm for support vector regression(SVR) are used. The regularization parameter of SVR and the width parameter of the kernel function are optimized, and finally, the adaptive boosting algorithm is combined. Construct the Adaboost WSO-SVR main model, test its accuracy, and compare it with other methods. The results indicate that the accuracy of the Adaboost WSO-SVR main model proposed in this article is higher than the integrated optimized BP, ELM models. It is known that the proposed method has better performance in load forecasting, providing a basis for optimizing control strategies for air conditioning energy conservation.

Keywords: air conditioning load; load forecasting; feature selection; white shark optimization algorithm; adaptive boosting algorithm; support vector regression

[责任编辑 杨浦 刘洋]