

基于VMD-CIGWO-BP-DTA算法的空调负荷预测

白雪松, 王志毅*, 鲁浩翔, 谭永辉, 魏同正

浙江理工大学建筑工程学院, 浙江 杭州

收稿日期: 2024年1月19日; 录用日期: 2024年3月21日; 发布日期: 2024年3月28日

摘要

提出一种Circle混沌化灰狼算法(CIGWO)优化BP神经网络与变分模态分解(VMD)结合的预测模型(VMD-CIGWO-BP-DTA), 对蓄能空调负荷进行预测分析。采用CIGWO算法对BP神经网络模型寻优得到最优神经元阈值和权值, 将其与多种单一模型进行实验比较, CIGWO-BP模型预测精度最高。采用变分模态分解(VMD)对单一模型的预测残差进行分解, 利用决策树(DTA)模型对分解量预测, 将其与原模型预测值合并为最终预测结果, 预测精度均有较大提升, 其中VMD-CIGWO-BP-DTA模型的MAE、MAPE和RMSE相较于CIGWO-BP模型分别降低了20.79%、45.58%、55.12%。

关键词

计量学, 实验动物房, 空调负荷, 混沌映射序列, 灰狼算法, BP神经网络, 变分模态分解

Air Conditioning Load Forecasting Based on VMD-CIGWO-BP-DTA Algorithm

Xuesong Bai, Zhiyi Wang*, Haoxiang Lu, Yonghui Tan, Tongzheng Wei

School of Architecture and Engineering, Zhejiang Sci-Tech University, Hangzhou Zhejiang

Received: Jan. 19th, 2024; accepted: Mar. 21st, 2024; published: Mar. 28th, 2024

Abstract

A prediction model (VMD-CIGWO-BP-DTA) combining a Circle chaoticised grey wolf algorithm (CIGWO) optimised BP neural network with variational modal decomposition (VMD) is proposed for prediction analysis of storage air conditioning loads. The CIGWO algorithm is used to find the

*通讯作者。

文章引用: 白雪松, 王志毅, 鲁浩翔, 谭永辉, 魏同正. 基于 VMD-CIGWO-BP-DTA 算法的空调负荷预测[J]. 建模与仿真, 2024, 13(2): 1651-1661. DOI: 10.12677/mos.2024.132156

optimal neuron thresholds and weights for the BP neural network model, and the CIGWO-BP model has the highest prediction accuracy when compared with various single models. The prediction residuals of the single model were decomposed using variational modal decomposition (VMD), and the decomposed quantities were predicted using a decision tree (DTA) model, which were combined with the predicted values of the original model to form the final prediction results, and the prediction accuracies were all greatly improved. Compared with CIGWO-BP model, MAE, MAPE and RMSE of VMD-CIGWO-BP-DTA model were reduced by 20.79%, 45.58% and 55.12%, respectively.

Keywords

Metrology, Laboratory Animal Rooms, Air-Conditioned Loads, Chaotic Mapping, Grey Wolf Algorithm, BP Neural Networks, Variational Modal Decomposition

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

实验动物作为在医药、生物工程等研究领域不可或缺的实验载体，其饲养环境要求严格，必须通过大量的新风对室内受污染空气进行稀释，造成了实验动物房空调系统耗电量极高的问题[1]。蓄能空调通过提前蓄能的方式可以达到削峰填谷、减少运行费用的目的，但由于传统的蓄能空调通常基于典型负荷工况进行储能，无法根据实际天气情况和运行状态变化进行精准的控制，存在空调蓄能不足或过量的问题[2]。

基于数据挖掘的方法可以对建筑负荷与天气及人员活动规律等因素的关系进行挖掘，根据工况对负荷进行预测，实现对蓄能空调系统的精确控制，缓解用能紧张的状况并降低运行费用[3]。由于空调负荷受到天气和人员活动规律等复杂非线性因素影响，需要采用可以更好处理非线性关系的模型对建筑负荷进行预测，目前常见的负荷预测方法主要有支持向量机、神经网络和随机森林以及其他统计算法[4] [5] [6]。BP (Back Propagation) [7]神经网络以其强大的非线性映射、自学习、泛化、容错能力得到的广泛应用，但随着 BP 神经网络模型应用的越来越频繁，其收敛时容易陷入局部最优解问题也暴露了出来。为了解决此类问题，Chen [8]等采用多种参数优化方法的 BP 神经网络来预测能耗，对各种优化算法的特点进行了比较，通过自适应权重粒子群算法优化的神经网络被证明在预测能源消耗方面是最准确的。侯勇严[9]等用灰狼优化算法(GWO)对 BP 网络的初始权值和初始阈值进行优化，并对电网发电量进行预测，与传统 BP 和 GA-BP 算法相比，精度分别提高了 0.63%和 0.32%。

以上优化算法在很大程度上避免了 BP 神经网络陷入局部最优化，但由于其优化算法中粒子位置随机的生成，它们在预测准确度方面仍然不尽人意[10]。VMD [11]算法是一种对复杂信号进行分解并提取局部特征的信号处理方法，其对非线性负荷信号的分解能力强。于军琪[12]等利用 VMD 算法分解负荷序列，分别采用 LSSVM、XGBoost 模型建立负荷的非线性、线性子序列模型，重构叠加各子序列预测结果得到预测结果，仿真实验结果表明了该模型的预测精度有所提升。

本文采用 Circle 混沌序列[13]对灰狼算法[14]的灰狼个体位置更新方式进行优化，并对 BP 神经网络模型神经元阈值和权值进行寻优，增加 BP 神经网络更新自身权值与阈值过程中跳出局部最优化的概率，使用 VMD 算法将 CIGWO-BP 模型残差分解为多个相对平稳的子序列，并通过 DTA 模型对子序列进行预测后重构，与 CIGWO-BP 模型预测结果构成最终预测值，进一步提升模型的泛化能力和鲁棒性，为实

验动物房蓄冷空调系统提供更加精确的运行依据。

2. 研究思路及模型建立

2.1. 模型建立

2.1.1. BP 神经网络模型

BP 神经网络(如图 1)是一种采用前向传播和基于梯度降低的反向传播结合的方式对输出结果和误差进行传播的神经网络,其含有输入层、隐含层、输出层三层结构[15]。输入层神经元与输入参数个数相同,隐含层神经元数量通过公式(1)计算。输出层神经元个数与输出参数数量相同,本文设置为 1,层与层之间通过权值连接,神经元内部设置阈值,权值的数量根据公式(2)和公式(3)计算。

$$m = 2e + 1 \quad (1)$$

$$l = m \times e \quad (2)$$

$$k = m \times r \quad (3)$$

其中, m 为隐含层神经元个数; e 为输入层神经元个数; r 为输出层神经元个数; l 为输入层到隐含层权值个数; k 为隐含层到输出层权值个数。

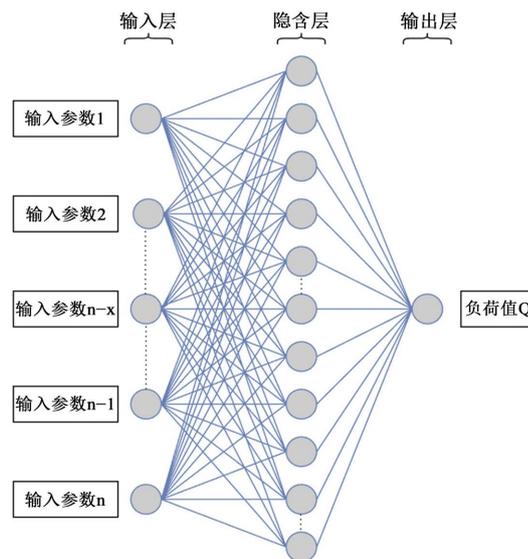


Figure 1. BP neural network topology drawing

图 1. BP 神经网络拓扑结构图

为了加快训练速度,对数据集进行归一化处理,统一量纲(如式(4))。

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

其中, x 为初始数据集每一列的数据值; x' 为初始数据归一化后的数据值; x_{\max} 和 x_{\min} 为每一列的最大值与最小值。

2.1.2. CIGWO-BP 模型

通过引入 Circle 混沌序列对灰狼优化算法灰狼个体位置更新方式进行优化,再通过优化后的改进灰狼优化算法对 BP 神经网络模型的初始权值和神经元阈值进行迭代和优化,寻找到最优的权值和神经元

阈值并代入到 BP 神经网络模型中，进而使用原始数据集进行负荷预测训练。CIGWO-BP 模型实现过程如下：

确定对灰狼算法种群规模为 N ，最大迭代次数为 t_{max} ，寻优的空间维度 D ；

$$D = m \times e + m + m \times r + r \tag{5}$$

随机产生 N 个灰狼个体，并分别计算每个灰狼的适应度 $f(x_i)(i=1,2,3,4,\dots,N)$ ，根据最小适应度选择对应的灰狼个体位置 $x_\alpha, x_\beta, x_\theta$ 。适应度计算方法如下：

$$U = \{V, G\} = \{v_{1,1}, v_{1,2}, \dots, v_{n,n}, g_1, g_2, \dots, g_n\} \tag{6}$$

$$MAE = \frac{1}{n_{test}} \sum_{i=1}^{n_{test}} |y_i - y_{ti}| \tag{7}$$

$$\min F(U) = \overline{MAE} \tag{8}$$

其中， $v_{i,j}$ 为节点之间的权值； g_j 为隐藏节点神经元的阈值的二进制编码形式； y_{ti} 为训练样本实际负荷值； y_i 为预测值；

隐藏节点阈值及节点之间权值对应的灰狼个体位置更新计算方法如下：

$$x(t+1) = \text{mod} \left(x(t) + b - \left(\frac{a}{2\pi} \right) \sin(2\pi x(t)), 1 \right) \tag{9}$$

$$c = 2e^{-t_{max}} \tag{10}$$

其中， mod 为取余函数， $b = 0.2$ ， $a = 0.5$ ， c 为惯性权重；

更新灰狼个体位置；

评估灰狼个体适应度值并更新历史最优适应度值；

更新灰狼种群全局最优适应度值及对应的灰狼个体位置；

当 $t < t_{max}$ 且未满足收敛条件时进行下一轮迭代，在达到收敛条件时或 $t = t_{max}$ 且时迭代停止，输出最优权值和隐藏节点神经元的阈值；

将得到的最优的权值 $v_{i,j,best}$ 和阈值 $g_{j,best}$ 代入 BP 神经网络模型，完成 CIGWO-BP 模型的构造。

图 2 为 CIGWO-BP 模型预测实现流程图。

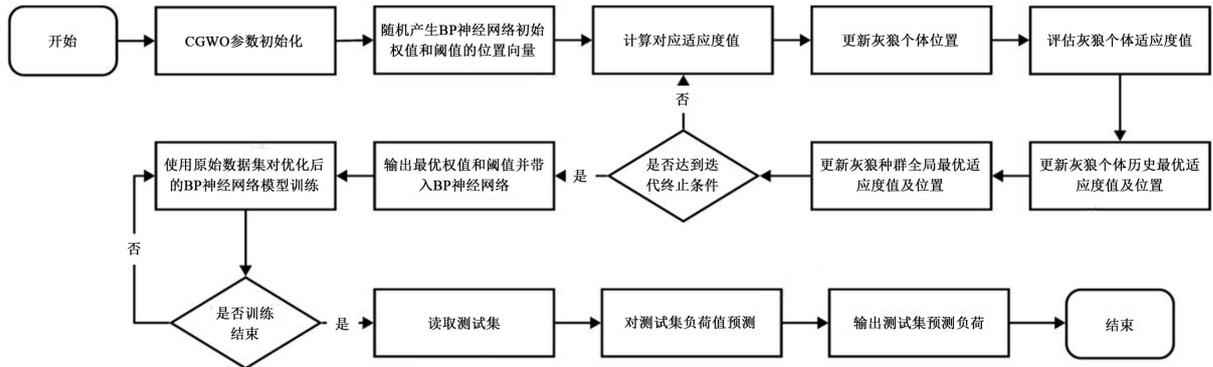


Figure 2. CIGWO-BP model prediction flow drawing

图 2. CIGWO-BP 模型预测流程图

2.1.3. VMD 分解模型

由于空调负荷受到天气、建筑材料及人员活动等多因素影响，其具有明显的非线性。VMD 采用非递

归及变分模态求解模式处理原始信号，可以自适应的将 CIGWO-BP 模型预测负荷残差分解为具有特定稀疏性的模态信号，交替迭代的更新，寻找最优解，其分别代表预测负荷残差的不同特性。其算法如下：

将 CIGWO-BP 模型预测负荷残差 $q(t)$ 分解为不同带宽的分量 $q_k(t)$ ，中心频率为 $\omega_k(t)$ ；

使用希尔伯特变换对分量 $q_k(t)$ 进行计算得到其频谱函数：

$$\left[\delta(t) + \frac{j}{\pi t} \right] * q_k(t) \quad (11)$$

其中， $\delta(t)$ 代表狄拉克函数；* 代表卷积运算；

将 CIGWO-BP 模型预测负荷残差分量的频谱通过与指数协调的方式将 $q_k(t)$ 的中心频率转移到基带：

$$\left\{ \left[\delta(t) + \frac{j}{\pi t} \right] * q_k(t) \right\} e^{-j\omega_k t} \quad (12)$$

其中， $e^{-j\omega_k t}$ 代表估计的中心频率；

通过高斯平滑原理，对 $q_k(t)$ 进行带宽解调：

$$\min_{\{q_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * q_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\}, \text{ s.t. } \sum_k q_k = f(t) \quad (13)$$

其中， $\{q_k\} = \{q_1, \dots, q_k\}$ 为模态函数集合； $\{\omega_k\} = \{\omega_1, \dots, \omega_k\}$ 为模态的中心频率数据集；

将二次乘法因子 α 和拉格朗日算子 $\lambda(t)$ 引入公式(13)，将其从约束问题转化为无约束问题，公式为：

$$\begin{aligned} & L(\{q_k\}, \{\omega_k\}, \lambda(t)) \\ &= \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * q_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \\ &+ \left\| f(t) - \sum_k q_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k q_k(t) \rangle \end{aligned} \quad (14)$$

利用乘法算子交替方向法对式(14)解算，得到各分量 q_k 和相应的中心频率 ω_k ：

$$\hat{q}_k^{(n+1)}(\omega) = \frac{\hat{q}(\omega) - \sum_{i \neq k} \hat{q}_i^n(\omega) + \frac{\hat{\lambda}^{(n)}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^{(n)})^2} \quad (15)$$

$$\hat{\omega}_k^{n+1} = \frac{\int_0^\infty \omega |\hat{q}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{q}_k^{n+1}(\omega)|^2 d\omega} \quad (16)$$

其中， n 为迭代次数； $\hat{q}(\omega)$ 、 $\hat{q}_k^n(\omega)$ 、 $\hat{\lambda}(\omega)$ 代表 $q(t)$ 、 $q_k(t)$ 、 $\lambda(t)$ 的傅里叶变换结果。

3. 仿真实验与结果分析

本文以苏州某实验动物房为例，获取 2022 年全年空调逐时负荷进行分析。此实验动物房净化空调区域面积 281.6 m²，层高 2.5 m。空调系统全天运行，制冷和制热工况下的室内温度分别设定为 26℃ 和 21℃，相对湿度分别设定 60% 和 50%，净化空调换气次数设定为 25 次/h，空调区域外墙导热系数为 0.6 W/(m²·k)。当室外环境温度处于 22℃~24℃ 时不对新风进行制冷和制热处理。通过温湿度自计仪、太阳辐射观测仪和冷热量表对室内外温湿度、风、太阳辐射情况和空调负荷进行监测，采样间隔 1 h，通过现 PLC 对数据进行数据存储(如图 3)。

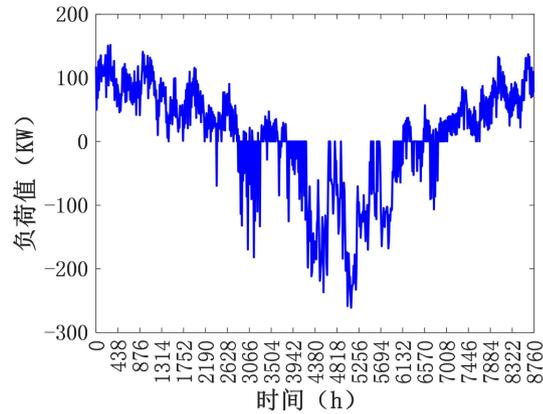


Figure 3. Laboratory animal room hour-by-hour load
图 3. 实验动物房逐时负荷

3.1. 原始数据集构建

太阳辐射、风、大气压力、太阳高度、人员个数、室外温湿度、室内温湿度等对空调负荷值具有影响，并且由于空调负荷具有周期性[16]的特点，因此认为前一天同一时刻负荷值 Q_{t-24} 对当前空调负荷具有参考意义。由于空调负荷不符合正态分布，本文使用 SPSS 分别对输入参数与当前空调负荷值进行斯皮尔曼秩相关性分析[17]。分析结果如表 1 所示，相关性系数绝对值超过 0.2 认为其相关性较强，其中人员数量的显著性水平超过了 0.05，认为人员数量与实验动物房空调负荷没有显著性关系，由于 24 小时以后的太阳辐射强度获取难度较大，对室内相对湿度难以精确测量，因此将前一天相同时间的负荷值 Q_{t-24} 、太阳高度、室外干球温度、室外相对湿度、室内干球温度作为负荷模型最终输入参数。

Table 1. Correlation coefficient of input parameters and loads
表 1. 输入参数与负荷秩相关系数

变量名称	秩相关系数	显著性水平
负荷值 Q_{t-24}	0.789	0
太阳辐射强度	-0.251	0
风速	-0.09	0
风向	0.047	0
大气压力	-0.046	0
太阳高度	-0.336	0
太阳方位角	-0.113	0
人员个数	-0.021	0.054
室外干球温度	-0.849	0
室外相对湿度	0.208	0
室内干球温度	-0.916	0
室内相对湿度	-0.625	0

3.2. CIGWO-BP 模型参数设置

原始数据集共 8736 组数据，数据集采用 5:1 的比例对训练集及测试集进行划分。灰狼种群数量设置

为 50, 阈值的上限 u_b 和下限 l_b 设置为 1 和 -1, 最大迭代次数设置为 100。BP 模型训练次数设置为 1000, 学习速率设置为 0.01, 训练目标误差设置为 1×10^{-6} , 最小性能梯度设置为 1×10^{-6} 。

3.3. 单一模型预测结果分析

通过原始数据集分别对 BP 神经网络模型、PSO-BP 模型、GWO-BP 模型、LIBSVM 和 CIGWO-BP 模型进行训练及预测, 并根据误差评定方法对其进行对比分析。由图 4(a)可知, 五种模型的预测结果均可以贴合实际负荷变化趋势, 但其预测精度相差较大(见图 4(b)), 其预测精度 CIGWO-BP 模型最高, 由高到底为 CIGWO-BP 模型、GWO-BP 模型、PSO-BP 模型、LIBSVM 模型、BP 模型, 特别在波峰和波谷部分, 对照组模型的误差相较于其他负荷值部分要更大, 存在过估计的现象, 总体预测负荷高于实际负荷, 容易过度蓄能, 造成能源浪费。通过 BP 模型、PSO-BP 模型、GWO-BP 模型与 CIGWO-BP 模型的预测精度的对比可以得出混沌映射对灰狼算法的位置更新优化具有良好效果, 可以使模型更好地跳出局部最优, 预测精度较高。

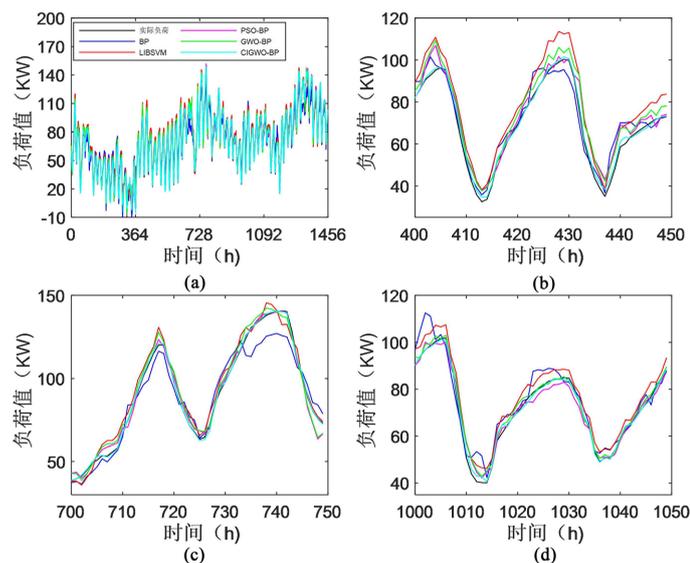


Figure 4. Graph of single model prediction results

图 4. 单一模型预测结果图

3.4. VMD 残差分解

空调预测负荷残差受到较多因素影响, 具有较强的非线性、随机性和波动性, 通过 VMD 可以分为将其分解为多个不同中心频率的相对平稳分量。在模态分量数量设置中, VMD 模态分量分解数量过少会引起信息丢失, 数量过多会引起模态混叠, 造成信息的失真, 影响预测精度。采用中心频率观察法确定分解的模态数量。不同模态分量个数 K

对应的中心频率分布如表 2。当分解变量个数为 2 时, IMF2 的中心频率较低, 表示欠分解, 当分解变量个数为 4 和 5 时, IMF1 和 IMF2 的中心频率较近, 表示过度分解, 模态之间出现混叠。

图 5 为 K 值为 3 时负荷残差模态信号的频谱图, 从图中可以清楚的看出分解后的模态分量相互之间重叠较少, 模态分量之间未出现模态混叠, 可以将分解后的模态分量作为输出参数。

模态分量为 3 时, 分解时域图如图 6 所示, 图 6(b)为截取的前 2000 个负荷残差的分解图, 从图中可以清晰的看出三个模态分量代表不同信息, 且与原始信号相比相对平稳。

Table 2. Center frequency corresponding to different K
表 2. 不同 K 值对应的中心频率

K	2	3	4	5
IMF1	392	378	362	351
IMF2	1762	1664	762	673
IMF3	-	3255	1831	1673
IMF4	-	-	3453	2532
IMF5	-	-	-	3521

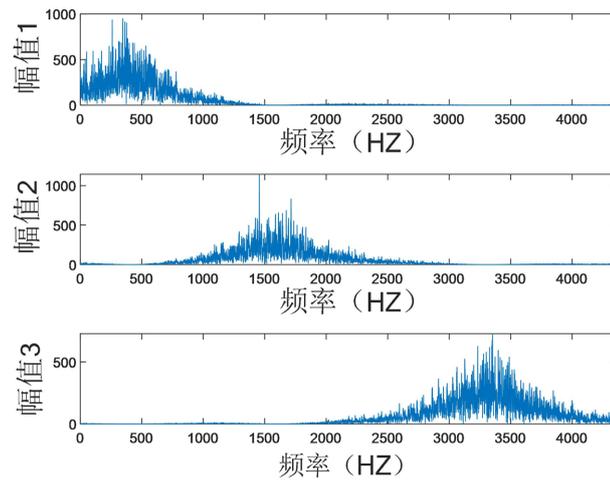


Figure 5. Graph of VMD frequency spectrum
图 5. VMD 频谱图

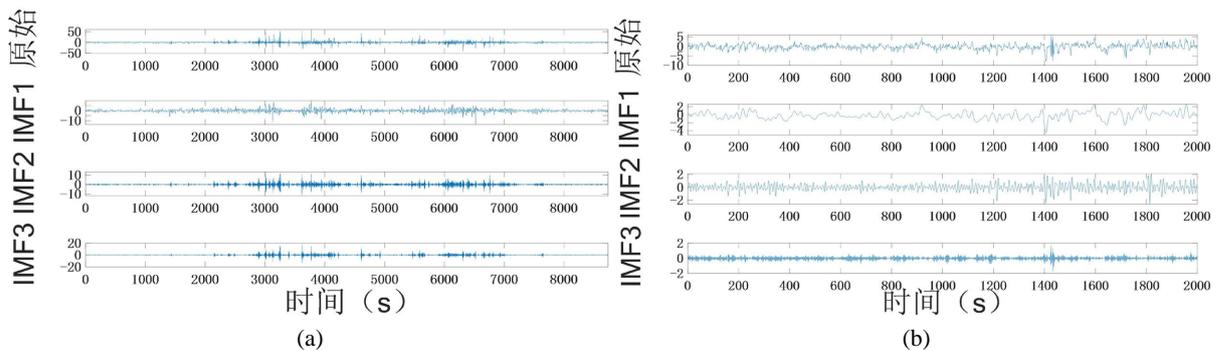


Figure 6. VMD decomposition results
图 6. VMD 分解结果

3.5. CIGWO-BP 残差分解优化模型建立

通过 BP、决策树和 LIBSVM 模型分别对 CIGWO-BP 残差分解后的模态分量进行预测，将其预测结果与 CIGWO-BP 模型预测结果相加后而得到最终预测结果，并分别计算各个模型预测结果的 MAE、MAPE 和 RMSE (如表 3)。VMD-CIGWO-BP-DTA 的 MAE、MAPE 和 RMSE 均为最小，因此后续使用决策树模型对单一模型残差的模态分量进行预测。

Table 3. Comparison of the residual decomposition optimization model performance
表 3. 残差分解优化模型性能对比

预测模型	MAE (KW)	MAPE (%)	RMSE (KW)
VMD-CIGWO-BP	1.01	3.56	1.47
VMD-CIGWO-BP-BP	0.98	3.36	1.42
VMD-CIGWO-BP-LIBSVM	0.94	3.17	1.41
VMD-CIGWO-BP-DTA	0.8	2.54	1.14

如图 7 所示, VMD-CIGWO-BP-DTA 模型的预测值与实际值的相对误差的绝对值在 12% 以下, 其中相对误差较大的部分集中在实际负荷值接近 0 的时间段, 此时相同的绝对误差比实际负荷值不接近 0 的时间段引起的相对误差会更大。另外, 根据统计结果可知, 相对误差在 0%~2% 的样本数量占全部数量的 75.55%, 相对误差在 2%~6% 的样本数量占全部数量的 19.10%, 相对误差在 6%~10% 的样本数量占全部数量的 4.55%, 相对误差在 10% 以上的样本数量只占全部数量的 0.81%。通过上述模拟实验结果可以得出结论: VMD-CIGWO-BP-DTA 模型对实验动物房空调负荷的预测中相对误差的波动随着实际负荷的变化波动较小, 稳定性较强, 可以较好的应对环境变化对预测效果的影响。

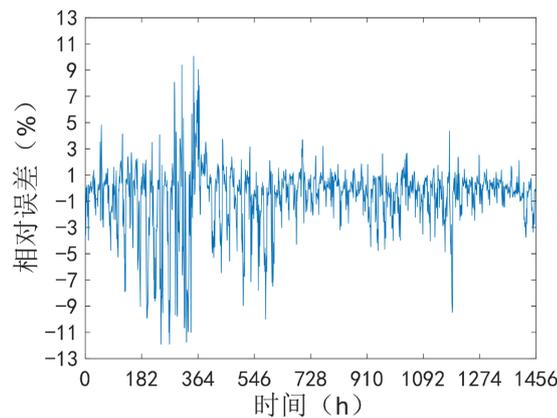


Figure 7. Relative error of VMD-CIGWO-BP-DTA model

图 7. VMD-CIGWO-BP-DTA 模型相对误差

3.6. VMD 残差分解对单一模型性能提升

为进一步验证 VMD 残差分解对单一模型预测性能提升的有效性, 采用 VMD 分别对 BP 模型、PSO-BP 模型、GWO-BP 模型、LIBSVM 模型和 CIGWO-BP 模型的预测残差进行分解, 并使用 DTA 模型对模态分量进行预测, 与各单一模型预测值相加获得各自的最终预测结果。使用 VMD 残差分解后, 以上 5 种模型预测结果的 MAE 降低幅度在 20.79% 到 52.05%; MAPE 降低幅度在 27.72% 到 52.71%; RMSE 降低幅度在 22.45% 到 45.05% (图 8)。由上述数据得出结论: 对单一模型预测残差进行 VMD 分解并预测重构对模型预测性能会有较大提升。

4. 结论

为了实现对实验动物房蓄能空调负荷的精准预测, 本文提出了一种基于残差分解的空调负荷预测模型, 并进行了模拟实验分析。主要结论如下:

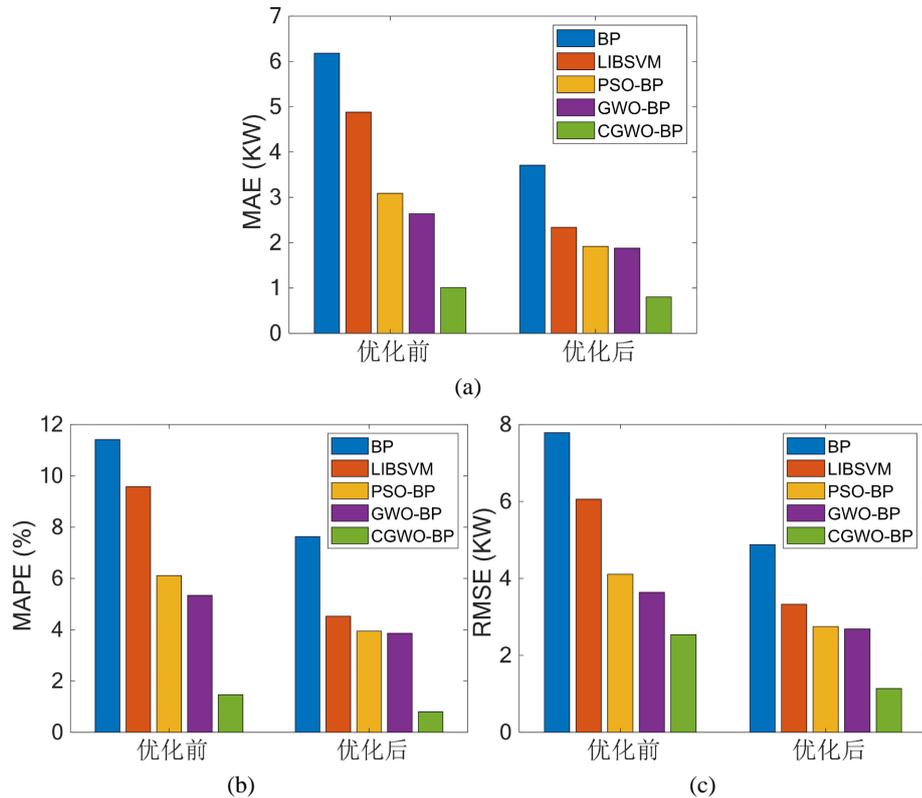


Figure 8. Comparison of model prediction performance
图 8. 模型预测性能对比图

1) 通过 Circle 混沌序列优化的灰狼算法可以对 BP 神经网络预测模型的权值和阈值进行优化, 相较于 BP 模型、PSO-BP 模型、GWO-BP 模型和 CIGWO-BP 模型有更好的预测精度, 证明其可以更好地跳出局部最优。

2) 通过 VMD 对单一模型预测残差进行分解, 可以得到相对平稳的模态分量, 通过预测模型对分解的模态分量预测并将预测结果与单一模型预测结果相加可以较好地提升其预测精度。

3) 相较于 BP 和 LIBSVM 模型, 决策树模型对 VMD 分解后的预测负荷残差分量进行预测并与 CIGWO-BP 预测结果相加得到的最终预测结果与实际值更加接近, 建立的 VMD-CIGWO-BP-DTA 模型在对实验动物房空调负荷的预测中预测精度最高且效果稳定, 具有较高的泛化能力和鲁棒性, 可以为实验动物房空调系统提供更加精确的运行依据。

参考文献

- [1] 王文涛, 郑功杭, 李先庭, 等. 利用室内空气循环净化降低实验动物房新风量的节能效果[J]. 制冷学报, 2021, 42(6): 1-7.
- [2] 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): 129-134+43.
- [3] 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.
- [4] 马诗洋, 王宇, 王鹏飞, 等. 基于支持向量机的相位敏感光时域反射仪研究[J]. 计量学报, 2022, 43(5): 609-616.
- [5] 迟玉伦, 吴耀宇, 江欢, 等. 基于模糊神经网络与主成分分析的磨削表面粗糙度在线预测[J]. 计量学报, 2022, 43(11): 1389-1397.

-
- [6] 李梦娜, 吕承泽, 王蕾, 等. 基于机器学习算法的超声流量计使用中检验[J]. 计量学报, 2022, 43(12): 1627-1633.
- [7] Li, K., Su, H. and Chu, J. (2011) Forecasting Building Energy Consumption Using Neural Networks and Hybrid Neuro-Fuzzy System: A Comparative Study. *Energy and Buildings*, **43**, 2893-2899. <https://doi.org/10.1016/j.enbuild.2011.07.010>
- [8] Chen, S., Ren, T.T. and Wu, Z.C. (2018) Research on Neural Network Optimization Algorithm for Building Energy Consumption Prediction. *Journal of Computational Methods in Sciences and Engineering*, **18**, 695-707. <https://doi.org/10.3233/JCM-180820>
- [9] 侯勇严, 杨澳, 郭文强, 等. 基于灰狼算法优化的神经网络短期发电量预测[J]. 陕西科技大学学报, 2022, 40(4): 171-177.
- [10] Zhang, J.R., Zhang, J., Lok, T.M., *et al.* (2007) A Hybrid Particle Swarm Optimization-Back-Propagation Algorithm for Feedforward Neural Network Training. *Applied Mathematics and Computation*, **185**, 1026-1037. <https://doi.org/10.1016/j.amc.2006.07.025>
- [11] Dragomiretskiy, K. and Zosso, D. (2013) Variational Mode Decomposition. *IEEE Transactions on Signal Processing*, **62**, 531-544. <https://doi.org/10.1109/TSP.2013.2288675>
- [12] 于军琪, 边策, 赵安军, 解云飞, 惠蕾蕾. 考虑频域分解后数据特征的空调负荷模型[J]. 控制理论与应用, 2022, 39(6): 1149-1157.
- [13] 赵霞, 张君毅, 龙倩倩. 基于 Circle 混沌映射的 ISSA-ELM 神经网络室内可见光定位方法[J]. 光学学报, 2023, 43(2): 33-42.
- [14] 陈红岩, 刘嘉豪, 盛伟铭, 黄瀚, 赵永佳. 基于 GWO 的 SVM 在红外甲烷传感器测量误差分析中的应用[J]. 计量学报, 2021, 42(9): 1244-1249.
- [15] Tan, X., Zhu, Z., Sun, G., *et al.* (2022) Room Thermal Load Prediction Based on Analytic Hierarchy Process and Back-Propagation Neural Networks. *Building Simulation*, **15**, 1989-2002. <https://doi.org/10.1007/s12273-022-0905-0>
- [16] 甘中学, 喻想想, 许裕栗, 李德伟. 基于周期性 ARMA-SVR 模型的空调冷热负荷预测[J]. 控制工程, 2020, 27(2): 380-385.
- [17] Wu, Y., Liu, H., Li, B., *et al.* (2021) Individual Thermal Comfort Prediction Using Classification Tree Model Based on Physiological Parameters and Thermal History in Winter. *Building Simulation*, **14**, 1-15.