

文章编号: 1671-6612 (2024) 03-320-10

# 基于改进野狗优化算法 优化极限学习机的空调负荷预测方法

代广超<sup>1</sup> 吴维敏<sup>2</sup>

(1. 浙江大学工程师学院 杭州 310015;

2. 浙江大学控制科学与工程学院 杭州 310027)

**【摘要】** 针对目前短期空调负荷预测方法预测精度低、稳定性差等问题, 提出一种基于微生物遗传算法 (Microbial genetic algorithm, MGA) 和野狗优化算法 (Dingo optimization algorithm, DOA) 优化极限学习机 (Extreme learning machine, ELM) 的空调负荷预测模型。首先利用 DOA 优化 ELM 的输入权值和隐层阈值, 建立 DOA-ELM 预测模型, 利用 MGA 改进 DOA-ELM 模型的预测稳定性和预测精度, 建立 (Microbial genetic algorithm Dingo optimization algorithm-Extreme learning machine) MDOA-ELM 预测模型。为降低预测模型的维度, 通过灰色关联分析 (GRA) 筛选影响空调负荷的输入输出因素。为验证算法有效性, 以某工厂中央空调系统为例进行实例分析。实验结果表明, 所建负荷预测模型相较于对比模型预测精度高, 稳定性好, 因此可更好地满足工程实际需求。

**【关键词】** 负荷预测; 微生物遗传算法; 野狗优化算法; 极限学习机; 灰色关联分析

中图分类号 TP391 文献标志码 A

## Optimization of Extreme Learning Machine for Air-conditioning Load Prediction Based on Improved Dingo Optimization Algorithm

Dai Guangchao<sup>1</sup> Wu Weimin<sup>2</sup>

(1. Polytechnic Institute of Zhejiang University, Hangzhou, 310015;

2. School of Control Science and Engineering, Zhejiang University, Hangzhou, 310027)

**【Abstract】** A novel air conditioning load prediction model based on Microbial genetic algorithm (MGA) and Dingo optimization algorithm (DOA) optimized Extreme learning machine (ELM) is proposed in this paper to address the issues of low prediction accuracy and poor stability in short-term air conditioning load prediction methods. A DOA-ELM prediction model is established by using DOA to optimize the input weights and hidden layer thresholds of ELM. An MDOA-ELM prediction model is established by using MGA to improve the prediction stability and accuracy of the DOA-ELM model. To reduce the dimensionality of the prediction model, Grey relational analysis (GRA) is used to screen the input and output factors that affect air conditioning load. An air conditioning load prediction example on the central air conditioning system of a factory is provided to verify the effectiveness of the proposed algorithm. Comparing with the reported model, the experimental results show that the established load prediction model has higher prediction accuracy and better stability, and therefore is able to better meet the actual needs of the project.

作者简介: 代广超 (1989.12-), 男, 硕士研究生, E-mail: 22060889@zju.edu.cn

通讯作者: 吴维敏 (1970.04-), 男, 博士, 教授, 博士生导师, E-mail: wuwm@iipca.zju.edu.cn

收稿日期: 2023-12-07

**【Keywords】** Load Prediction; Microbial Genetic Algorithm; Dingo Optimization Algorithm; Extreme Learning Machine; Grey Relational Analysis

## 0 引言

根据世界观察协会数据显示, 建筑是最大的能源消费者, 约占全球年能源消耗的 40%, 占总碳排放量的 36%, 尤其是在城市地区<sup>[1,2]</sup>, 这一现象更为突出。中央空调是公共建筑能源消耗的主体, 约占 40%<sup>[3]</sup>, 占工厂能耗的 35%。中央空调制冷系统通常基于最大负荷进行设计, 然而在实际运行中, 它们大部分往往运行在部分负荷状态下<sup>[4]</sup>。由于难以准确预测未来时段的空调负荷需求, 基于负反馈控制的空调系统通常具有较大的迟滞性, 易造成能源的浪费。

目前, 国内外学者针对空调负荷预测做了较多的研究。统计分析方面, Gahl 等<sup>[5]</sup>基于气象参数建立了自回归模型, 实验结果表明在更复杂的情况下该方法能够达到理想的效果。Nie 等<sup>[6]</sup>提出了基于 ARIMA 的日负荷预测方法, 并利用机器学习方法对预测偏差进行优化, 结果表明该方法优于传统 ARIMA 方法。周璇等<sup>[7]</sup>引入实际用能系数, 分时段考虑系统的用能特性, 建立了多元非线性回归法的负荷预测模型, 用于解决商场空调负荷预测速度慢、建模复杂、难以满足空调控制系统节能优化的问题。陈柳等<sup>[8]</sup>提出将小波分析和时间序列组合应用于空调负荷预测, 小波分析能将空调负荷序列逐层分解到不同频率通道上, 分解后的序列平稳性较原始序列更好。基于这一方法, 建立的负荷预测模型精度较高, 且优于传统时间序列模型。以上基于统计分析的预测模型, 往往需要建立在大量数据基础上且需要调试的参数较多, 不适合工程实际。

部分学者将机器学习应用到空调负荷预测领域并进行了一定的改进, 李婷婷等<sup>[9]</sup>基于影响因素的显著性大小排序和反向传播 (Back propagation, BP) 神经网络理论建立了空调负荷预测模型。在客流变化、天气变化的情况下对模型进行验证, 最大相对误差分别为 9.825% 和 11.675%。验证结果表明, 模型预测精度较高, 具有较好的泛化能力, 能有效预测地铁车站站厅公共区域空调负荷。苏醒等<sup>[10]</sup>以客流量预测为基础, 建立了车站空调负荷预测模型, 并比较了不同时间尺度训练数据下误差反向传播神经网络算法和支持向量机算法的预测效果,

两种算法的 R2 达到了 0.95 以上, 均方根误差在 70~90kW 之间, 预测精度较高, 但支持向量机算法的运算时间是误差反向传播神经网络算法的 3~4 倍左右, 推荐数据量较大时优先选择 BP 神经网络算法。Xu 等<sup>[11]</sup>提出利用极限学习机 (ELM) 用于公共建筑空调负荷的预测, 得到了良好的效果。Ahlund 等<sup>[12]</sup>基于机器学习对负荷预测的模型进行了研究, 结果表明决策树方法在 SVM、ANN 中表现最差。以上研究大多针对于单一算法对空调负荷进行预测, 预测精度及预测稳定性已无法满足工程实际需求。本文在 ELM 算法基础上, 通过 GRA 对空调负荷影响因素进行筛选, 确定对空调负荷影响较大的因素, 并将 MGA 和 DOA 算法同 ELM 有效结合, 构建 MDOA-ELM 空调负荷预测模型, 解决了 ELM 模型输入权值和隐层阈值随机产生和预测精度不稳定的问题, 并以某工厂空调负荷数据为例, 通过对比分析验证了该模型的预测精度和预测稳定性, 为空调后期优化运行方式, 节能降耗提供依据。

## 1 负荷预测模型基本原理

### 1.1 灰色关联分析

邓聚龙教授于 1980 年提出了灰色关联分析方法。该理论和方法适用于研究未确知问题, 特别是当样本数据量较少或信息不充分时, 通过提取有价值的信息, 研究具有部分已知和未知信息的未确知系统。能够正确地描述及监控系统的操作行为<sup>[13]</sup>。灰色关联分析即灰色系统理论对系统模型的关系分析、构建、决策和预测进行研究, 用以明确数据的不完整性和不确定性。灰色系统理论应用范围广泛, 能有效地处理多输入、不确定性、数据不完整和分散数据等问题<sup>[14]</sup>。

### 1.2 极限学习机

ELM 是由 Huang 等<sup>[15]</sup>于 2004 年提出的机器学习算法。与 BPNN 相比, ELM 不需要复杂的调参, 只需要给定隐层节点数量即可, 同时避免了 BPNN 训练速度慢的缺点<sup>[16]</sup>。

ELM 结构示意图如图 1 所示。x 为神经网络预测模型的输入、t 为输出,  $\omega_i$ ,  $b_i$  分别为输入权

值及隐层阈值， $\beta_j$ 为输出权重。

对于任意  $N$  个样本  $(X_i, t_i)$ ，其中  $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$  和  $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$ 。具有  $\tilde{N}$  个隐层节点和激活函数的标准 SLFNs 数学建模为：

$$\sum_{i=1}^{\tilde{N}} \beta_i g_i(x) = \sum_{i=1}^{\tilde{N}} \beta_i g(w_i \cdot x_j + b_i) = o_j, j=1, \dots, N \quad (1)$$




图 1 ELM 结构示意图

Fig.1 ELM structural schematic diagram

### 1.3 野狗优化算法

DOA 是一种 2021 年由 Peraza-Va'zquez 等<sup>[17]</sup>提出的群智能优化算法。该算法通过模拟野狗的迫害、分组和清除行为，以及考虑野狗的生存概率来进行优化搜索。DOA 具有以下特点：操作简单、易于实现、收敛速度快。其主要思想是通过模拟野狗的社交行为，对解空间进行搜索和优化。具体来说，DOA 包含三个关键步骤：初始群体的生成、位置更新和适应度评价。其中，位置更新过程采用了不同的策略，如基于随机游走的搜索和基于优势群体的聚合等。通过这些步骤，DOA 能够在多个应用领域中实现高效的优化搜索。

野狗的包围行为为：

$$x_i(t+1) = \beta_1 \sum_{k=1}^{na} \frac{[\varphi_k(t) - x_i(t)]}{na} - x_*(t) \quad (2)$$

野狗追捕行为为：

$$x_i(t+1) = x_*(t) + \beta_1 e^{\beta_2} (x_{r_1}(t) - x_i(t)) \quad (3)$$

食腐行为为：

$$x_i(t+1) = \frac{1}{2} [e^{\beta_2} x_{r_1}(t) - (-1)^\sigma x_i(t)] \quad (4)$$

其中， $x_i(t+1)$  为搜索野狗的新位置； $na$  为随机数； $\varphi_k(t)$  即将攻击的野狗子集； $x_i(t)$  为当前野狗； $x_*(t)$  为上一次迭代中最佳搜索代理； $\beta_1$  为  $[-2, 2]$  比例因子用于改变野狗的搜寻轨迹， $\beta_2$  为  $[-1, 1]$ ， $r_1$  从 1 到最大代理区间随机数； $x_{r_1}(t)$  选定第  $r_1$  个野狗，其中  $t \neq r_1$ 。  $\sigma \in (0, 1)$ 。

生存行为为：

$$survival(i) = \frac{fitness_{max} - fitness(i)}{fitness_{max} - fitness_{min}} \quad (5)$$

其中， $fitness_{max}$  与  $fitness_{min}$  为当代最佳/最差适应度值； $fitness(i)$  为第  $i$  个野狗的适应度值。

$$x_i(t) = x_*(t) + \frac{1}{2} [x_{r_1}(t) - (-1)^\sigma x_{r_2}(t)] \quad (6)$$

其中， $x_i(t)$  是将被更新的生存率低的野狗； $r_1, r_2$  为随机数。

### 1.4 微生物遗传算法

MGA 与遗传算法 (Genetic Algorithm, GA) 最大的区别在于其重组算子。MGA 首先使用选择方案从世代人口中选择父母，并根据他们的适应度进行评估以标记输家和赢家。与传统遗传算法不同的是，MGA 采用胜者保持完整的交叉基因方式，即将一些基因以定义的交叉概率转移到失败者，从而保留精英主义并将优秀的基因传递给下一代。在此过程中，MGA 注重保持种群的多样性，对被标记为失败者的个体进行突变，以确保种群的多样性和适应性<sup>[18]</sup>。流程图如图 2 所示。

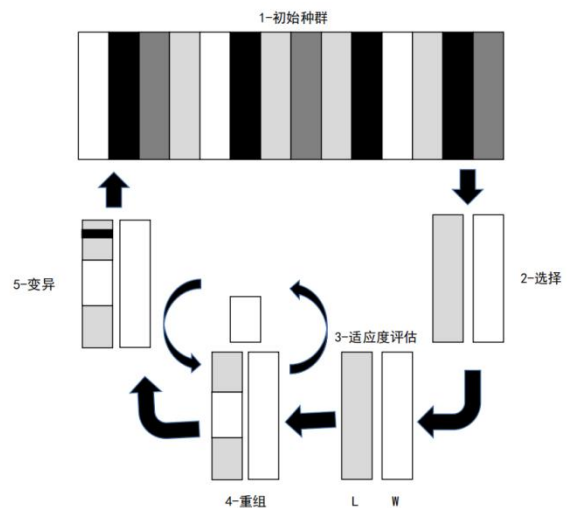


图 2 MGA 原理图

Fig.2 MGA schematic

## 2 空调负荷预测模型构建

### 2.1 MDOA-ELM 预测模型

考虑到影响空调负荷预测的因素众多,在机器学习算法训练时易导致维度灾难,通过灰色关联分析(GRA)对影响空调负荷的因素进行筛选,识别出关联度更高的因素,针对极限学习机(ELM)输入权值和隐层阈值随机产生的问题,本文利用野狗优化算法(DOA)对其进行优化,由于野狗觅食等习性,容易导致其寻优数值不稳定。利用微生物遗传算法(MGA)的优胜劣汰机制对每一代的种群进行寻优,使其预测结果更稳定,建立 MDOA-ELM 空调负荷预测模型。

改进 ELM 模型优化步骤如下:

(1) 通过 GRA 识别出关联度较高的因素,作为 ELM 空调负荷预测模型的输入输出;

(2) 建立 ELM 负荷预测模型,确定模型的隐层节点数量;

(3) 设定 DOA 的初始种群,迭代次数,利用 DOA 算法的个体迭代对 ELM 输入权值和隐层阈值进行寻优,以 MAPE 为适应度函数,寻找到 MAPE 最低时的最优解;

(4) 设定 MGA 的迭代次数及交叉、变异概率,利用 DOA-ELM 每次迭代的最优解作为 MGA 的初始种群,进行进一步迭代更新,MAPE 为适应度函数,寻找 MAPE 最低时最优解;

具体改进流程图如图 3 所示。

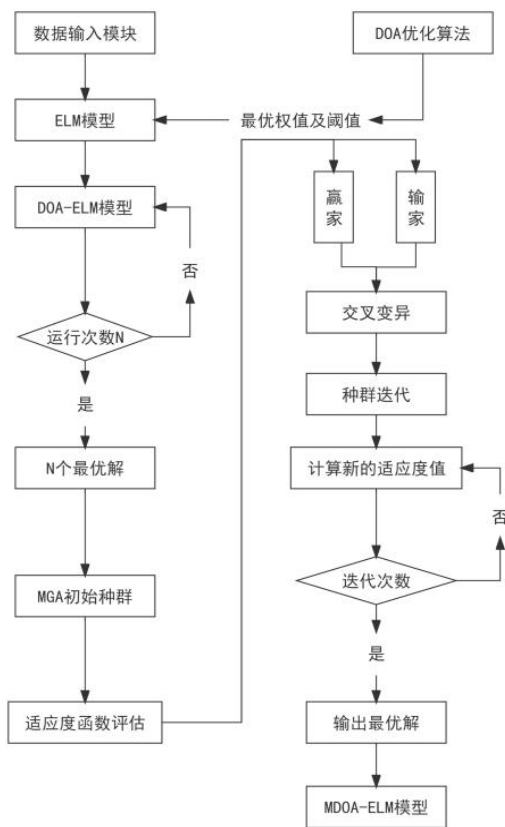


图 3 空调负荷预测模型流程图

Fig.3 Flow chart of air-conditioning load prediction model

### 2.2 MDOA-ELM 运行原理说明

DOA-ELM 模型在 24 小时预测模式下连续迭代 N 次,生成的 N 个优化结果作为 MGA 初代种群,分别表示为 D1、D2...Dn。其中 D1 等由 ELM 的 IW 和 B 构成,参与交叉及变异。对初代种群进行评估筛选出优秀的个体,如图 4 所示,其中 D2 代表本次评估出最优个体。在迭代过程中,D2 不参与交叉及变异,

其组成基因 IW 和 B 完成保留至下一代,其余个体如 D1...Dn 参与交叉变异,例如 D3 和 D4 的 IW41 和 IW31, IW42 和 IW32 完成了交叉, D5 个体中 B52 基因完成了变异,第二代重新进行适应度评估,此时的最优个体从 D2 变成了 D3。则下一代迭代过程中 D3 不参与交叉及变异,基因完整保留至下一代,由 D1、D2、...Dn 等参与交叉及变异。达到终止条件后,

输出最优的个体  $D_n$ ，其携带的基因  $I_{Wn1}$ 、 $I_{Wn2}$ 、 $I_{Wnn}$ 、 $B_{n1}$ 、 $B_{n2}$ 、 $B_{nn}$  为最优解，形成 MDOA-ELM 负荷预测模型。

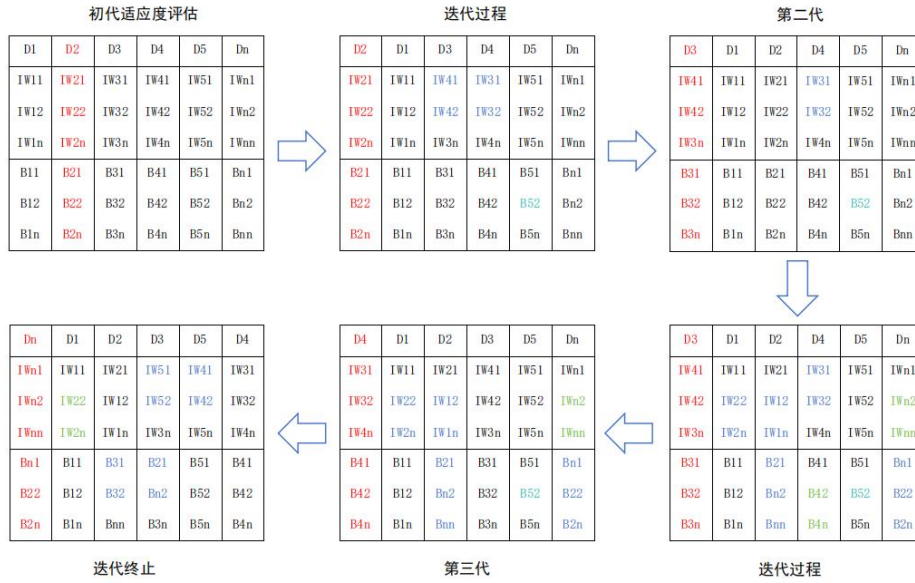


图 4 MDOA-ELM 迭代原理

Fig.4 MDOA-ELM Iteration principle

### 3 模型评价指标

评估一个模型的好坏需要考虑其预测精度和泛化能力，并采用多个评价标准进行综合评估，以确保预测模型能够获得全面的评估和测试。目前用于评价误差的标准主要包括：均方根误差（Root mean square error, RMSE）、平均绝对误差（Mean absolute error, MAE）、平均绝对百分比误差（Mean absolute percentage error, MAPE）等。分别对以上几种评价指标进行介绍，在进行原理介绍之前，设定参数如： $y_i$  为真实值， $y_i^*$  为预测值。 $N$  为样本数量。 $\bar{y}$  为空调冷负荷真实值的平均值。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y_i^*)^2} \quad (7)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - y_i^*| \quad (8)$$

$$MAPE = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{y_i - y_i^*}{y_i} \right| \quad (9)$$

本文采用 MAPE 为主要评价指标，其他指标例如 MAE、RMSE 等作为辅助参考指标。

### 4 实例验证分析

本节以某工厂中央空调制冷系统为研究对象，从预测精度及稳定性两个方面来验证本文所建模型的预测效果。该工厂总投资 5 亿元，占地面积 140 亩，总建筑面积三万平方米，建筑高度为 19 米，共分为两层，其中生产车间一万八千平米。中央空调制冷系统位于该建筑屋面，制冷系统由 3 台相同规格的制冷站组成群控，为车间提供冷源，3 台制冷站最大额定制冷总负荷为 2856KW。设备明细表如表 1 所示。

表1 制冷站群控系统设备明细表

Table 1 Equipment list of refrigeration station group control system

序号	名称	品牌及型号	设备输入功率	台数
1	螺杆机组	KCWF1270BTV1	158.4kW	3
2	冷冻水泵	格兰富，变频	37kW	3
3	冷却水泵	格兰富，定频	11kW	3
4	方形横流冷却塔	国祥	9kW	3



### 4.1 数据处理

#### 4.1.1 负荷预测的数据来源

依据前人研究成果及工程实际, 空调负荷预测数据来源主要包含两个方面, 一是来源于负荷模拟软件, 例如 DesignBuilder、DeST 等通过建模分析得到所需的逐时负荷数据, 此方法适用于空调设计及选型阶段。二是来源于气象站和空调历史负荷数据。本文采用方法二。气象信息来自于专业气象信息网站, (<https://www.msn.cn/zh-cn/weather/forecast>)。监测并搜集了 2022 年 6 月 22 日至 2022 年 8 月 31 日期间的气象和空调运行数据, 数据采样周期为 1h, 用于空调负荷预测模型的训练及验证。特征数据选取温度、风速、云量、能见度、湿度、露点、产量、空调负荷等因素。

#### 4.1.2 数据筛选

对采集到的 1704 小时数据集利用灰色关联分析方法进行分析。通过对比空调负荷影响因素: 温度、风速、云量、能见度、湿度、露点、产量与空调冷负荷之间的关联度。选择关联度较大的数据作为负荷预测模型的输入输出因素。

表2 影响负荷各因素与负荷关联度

Table 2 Factors affecting load and their correlation with load

因素	关联度
温度	0.8235
风速	0.5404
云量	0.6134
能见度	0.6189
湿度	0.6989
露点	0.6314
产量	0.7159

由表2关联结果, 选取关联度值在0.65以上的因素作为负荷预测模型的输入数据, 包括温度、湿度和产量。空调负荷作为输出数据。具体关联效果如图5所示。




图 5 负荷预测因素灰色关联分析结果

Fig.5 Grey relational analysis results of load forecasting factors

### 4.2 模型实验对比

#### 4.2.1 ELM 参数确定及模型评估

ELM 的输入权值和隐层阈值随机给定, 只需确定 ELM 的隐层节点, 即可实现模型的预测功能。通过试凑随机给定隐层节点数值, 发现模型的预测精度变化较大。隐层节点数量根据经验公式  $\tilde{N} = \sqrt{I + P} + MAX$ , 其中  $I$  为输入节点数量,  $P$  为输出节点数量,  $MAX$  为 1-20 间随机数。由于空调负荷预测的短期时效性, 随机选择前一周数据作为训练集共 168 小时, 测试集 24 小时,  $MAX=20$ , 利用 MATLAB 对 ELM 模型进行仿真。结果显示, ELM 隐层节点为 6 时 MAPE 最佳。随机选择前二周数据作为训练集共 336 小时, 测试集 24 小时,  $MAX=20$ , 利用 MATLAB 对 ELM 模型进行仿真, 结果显示, ELM 隐层节点为 6 时 MAPE 最佳, 如图 6 所示。

以上验证结果表明, 隐层节点数量对于 ELM 模型预测的精度有显著影响。例如在训练集 168 小时模式下, 当隐层节点为 4 时, MAPE 为 12, 当隐层节点为 3 时, MAPE 为 14。此外, 不同测试集, ELM 的整体预测精度也不同, 例如在训练集为 168 时, 其 MAPE 稳定在 4.2 左右, 当训练集为 336 时, 其 MAPE 稳定在 3.2 左右。因此, 选取适当的隐层节点数量对于 ELM 模型的预测准确性至关重要。

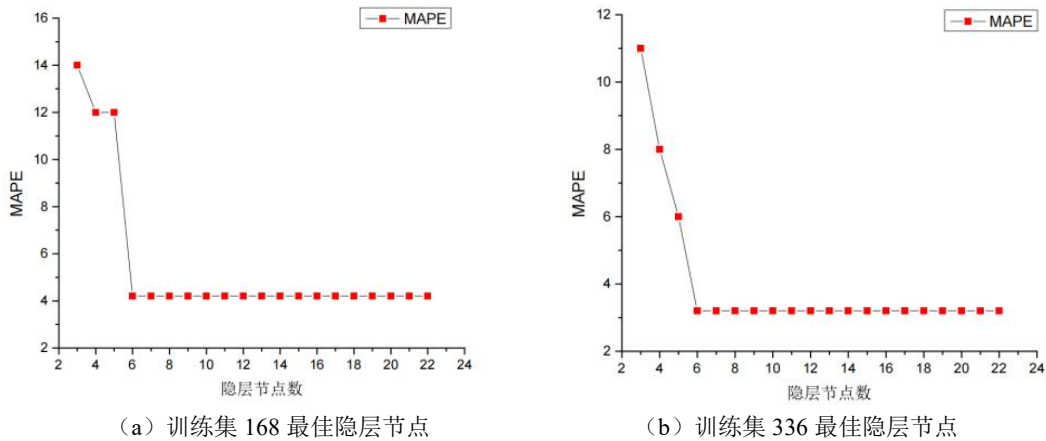


图 6 不同训练集模式 ELM 最佳隐层节点图

Fig.6 Optimal hidden layer node graph for ELM with different training set patterns

在确定隐层节点为 6 的基础上，需进一步验证其随机性。分别对 ELM 进行三次实验，结果表明，ELM 模型的输入权值和隐层阈值在不同的 MAPE 结果下均获得了不同的随机值，如图 7 所示。随机产生的输入权值和隐层阈值易导致 ELM 模型预测结果不稳定，且无法判断是否为全局最优。




图 7 ELM 的输入权值及隐层阈值随机运行粒子变化曲线图

Fig.7 The input weight and hidden layer threshold of ELM randomly run particle variation curve graph

#### 4.2.2 MDOA-ELM 预测精度改进验证

通过对本文所建立的 MDOA-ELM 预测模型与 GWO 改进极限学习机模型和 ELM 模型预测精度进行对比。GWO 是一种群智能优化算法，由 Mirjalili 等人<sup>[19]</sup>于 2014 年提出。该算法的灵感来源于灰狼捕食猎物的活动，相较于其他算法，GWO 具有以下优点：收敛性能强、参数少、易于实现等。实验随机选取两种方案分别为 168 小时和 336 小时数据作为训练集，24 小时数据作为测试集。几种模型参数分别设置如下：

ELM 的最佳隐层节点为 6，输入权值  $\omega$  及隐层阈值  $b$  随机产生；BPNN 参数设置为：激活函数 Sigmoid，训练次数 100，学习速率 0.01，训练目标最小误差 0.000001；GWO-ELM：ELM 隐层节点同上。GWO 种群数量 50，迭代次数 100；DOA-ELM：ELM 预测模块隐层节点同上。DOA 种群数量 50，迭代次数 100，狩猎或食腐选择概率  $P=0.5$ ，攻击或迫害选择概率  $Q=0.7$ 。

表 3 几种模型不同训练集预测模式下评价指标对比

Table 3 Comparison of evaluation indicators under different training set prediction models of several models

方案	训练集	测试集	误差类别	BPNN	ELM	GWO-ELM	DOA-ELM	MDOA-ELM
一	168	24	MAE	0.03	0.01	0.01	0.01	0.01
			RMSE	0.04	0.02	0.01	0.01	0.01
			MAPE (%)	10.58	4.13	3.54	2.78	1.98
二	336	24	MAE	0.01	0.01	0.01	0.01	0.01
			RMSE	0.02	0.01	0.01	0.01	0.01
			MAPE (%)	6.00	3.84	3.48	2.84	2.15

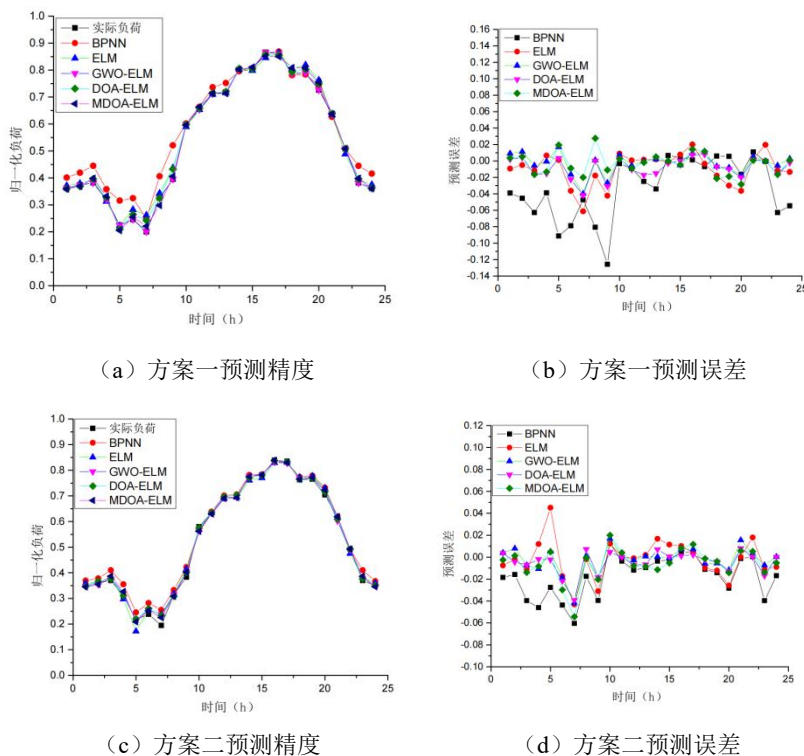


图 8 几种模型不同训练集负荷预测精度及误差对比

Fig.8 Comparison of load forecasting accuracy and error of several models with different training sets

通过以上实验结果表明, 本文所建 MDOA-ELM 模型预测精度在不同预测周期模式下准确性较其他几种算法更高。在测试方案一训练集为 168, 测试集为 24 模式下, MAPE1.98%, 远低于 BPNN 的 10.58%和 ELM 改进前的 4.13%, 其他两种误差评价指标 MAE 和 RMSE 均明显降低。在测试方案二训练集为 336, 测试集为 24 模式下 MAPE2.15%。同样远低于 BPNN 的 6%和 ELM 改进前的 3.84%。但在 ELM 后期优化阶段, 特别是

组合式算法应用后, MAE 及 RMSE 指标趋于相同。后期需验证 MAPE 改进效果。

#### 4.2.3 MDOA-ELM 预测稳定性改进验证

对 MDOA-ELM 的预测稳定性进行测试, 在方案一训练集 168 和方案二训练集 336 小时, 测试集均为 24 小时模式下运行 24 次, 最佳 ELM 隐层节点数量为 6。具体参数设置同上节。实验结果表明, MDOA-ELM 模型运行稳定性及预测精度均最高。

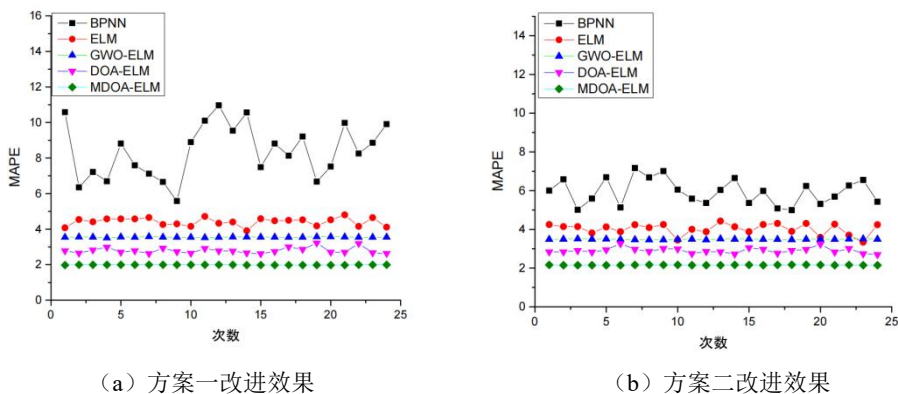


图 9 预测模型稳定性对比


Fig.9 Comparison of stability of prediction models




#### 4.2.4 实例验证

为验证本文所建空调负荷预测模型的实际预测效果,选取 2023 年最大制冷季 7 月和温差最大季 9 月中的某一天进行实例验证,测试模型的准确性。根据 7 月和 9 月气象条件相近的两天进行实际测试,其中 7 月选择 7 月 23 日运行数据作为参考

和参数选取的依据,7 月 24 日用于模型预测验证。9 月 4 日运行数据作为参考和参数选取的依据,9 月 5 日用于模型预测验证。7 月 24 日预测 MAPE 为 1.99%,9 月 5 日预测 MAPE 为 1.98%,达到预期效果。测试结果如图 10 所示。



(a) 7 月 24 日验证结果



(b) 9 月 5 日验证结果

图 10 MDOA-ELM 模型实例验证效果

Fig.10 MDOA-ELM model instance validation effect

## 5 结论

针对目前单一算法在短期空调负荷预测领域预测精度和预测稳定性不佳的问题,本文提出了基于 MDOA-ELM 短期空调负荷预测方法,并得出如下结论:

(1) 利用 GRA 对影响空调负荷的相关因素进行识别,筛选出关联度高的因素,降低数据维度的同时提高负荷预测的精度。

(2) 本文以 ELM 算法为基础,为避免其输入权值和隐层阈值随机产生的问题,并改善其预测精度,通过 MGA 和 DOA 算法对其输入权值和隐层阈值进行优化,建立 MDOA-ELM 空调负荷预测模型。

(3) 为验证所建预测模型的预测精度,选取 2023 年最大制冷季气象条件相近的 7 月 23 日和 7 月 24 日;温差最大季 9 月 4 日和 9 月 5 日进行实际预测效果验证,结果表明:MDOA-ELM 预测模型预测精度 MAPE 分别为 1.99%和 1.98,优于改进前的 4.13%,预测精度提高了约 2.1%。

#### 参考文献:

[1] Bui D K, Nguyen T N, Ngo T D, et al. An artificial neural network (ANN) expert system enhanced with the

electromagnetism-based firefly algorithm (EFA) for predicting the energy consumption in buildings[J]. Energy, 2020,190.

[2] Wang W, Hong T, Xu X, et al. Forecasting district-scale energy dynamics through integrating building network and long short-term memory learning algorithm[J]. Applied Energy, 2019,248:217-30.

[3] Verhelst J, Van H G, Saelens D, et al. Model selection for continuous commissioning of HVAC-systems in office buildings: A review[J]. Renewable and Sustainable Energy Reviews, 2017,76:673-686.

[4] Liu G, Liu Z, Yan J, et al. Study on Operation Features Analysis and Energy Saving Optimization Methods for Chilled Water System of Centralized Air Conditioning[J]. Building Science, 2018.

[5] Dahl M, Brun A, Andresen G B. Using ensemble weather predictions in district heating operation and load forecasting[J]. Applied Energy, 2017,193(MAY1):455-465.

[6] Nie H, Liu G, Liu X, et al. Hybrid of ARIMA and SVMs for Short-Term Load Forecasting[J]. Energy Procedia, 2012,16(part-PC):1455-1460.

- [7] 周璇,凡祖兵,刘国强,等.基于多元非线性回归法的商场空调负荷预测[J].暖通空调,2018,48(3):7.
- [8] 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):4.
- [9] 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(S2):590-594.
- [10] 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.
- [11] Xu Y, Gao J, Lei Z, et al. A Forecasting Method of Air Conditioning Energy Consumption Based on Extreme Learning Machine Algorithm[C]. 2017 IEEE 6th Data Driven Control and Learning System Conference (DDCLS). IEEE, 2017.
- [12] Ahlund, Christer, Schelen, et al. Applied machine learning: Forecasting heat load in district heating system[J]. Energy and Buildings, 2016,133(Dec.): 478-488.
- [13] Singh D, Singh B. Investigating the impact of data normalization on classification performance- ScienceDirect[J]. Applied Soft Computing, 2019,97.
- [14] Wang Y, Wang H. A new model based on GRA and LSSVM to predict silicon content in hot metal[C]. Artificial Intelligence and Computational Intelligence (AICI), 2010 International Conference on. IEEE, 2010.
- [15] Huang G B. Extreme learning machine: a new learning scheme for feedforward neural networks[J]. Proc. Intl Joint Conf. on Neural Networks, 2004.
- [16] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006,70(1-3),489-501.
- [17] Hernán Peraza-Vázquez, Adrián F Peña-Delgado, Gustavo Echavarría-Castillo, et al. A Bio-Inspired Method for Engineering Design Optimization Inspired by Dingoes Hunting Strategies[J]. Mathematical Problems in Engineering, 2021:1-19.
- [18] Umer S. Investigation into Mutation Operators for Microbial Genetic Algorithm[C]. 7th International Conference on Evolutionary Computation Theory and Applications (ECTA 2015). IEEE, 2015.
- [19] S Mirjalili, S M Mirjalili, A. Lewis. Grey Wolf Optimizer[J]. Advances in Engineering Software, 2014,69:46-61.