

DOI: 10.12158/j.2096-3203.2026.02.013

基于气象相似日修正和 IPO-DLinear 的日前电力负荷预测

于惠钧¹, 赵文川¹, 刘颉¹, 徐银凤², 邹海², 辜海缤²

(1. 湖南工业大学交通与电气工程学院, 湖南 株洲 412007;

2. 国网湖南省电力有限公司株洲供电公司, 湖南 株洲 412000)

摘要:现有电力负荷预测方法面临诸多挑战,尤其是在考虑气象因素对负荷波动的影响时,传统方法往往忽视气象特征与负荷之间复杂的非线性关系,导致预测精度不足。对此文中提出一种基于气象相似日修正(meteorological similar day correction, MSDC)和改进鹦鹉优化(improved parrot optimizer, IPO)线性分解(decomposition-based linear, DLinear)的日前电力负荷预测模型。首先运用 Logistic 映射、自适应变异策略、螺旋波动搜索 IPO 对 DLinear 超参数进行优化,然后由 DLinear 提取数据的周期性和趋势性特征,最后通过比对气象特征欧氏距离修正负荷预测值,形成基于 IPO-DLinear-MSDC 的日前电力负荷预测模型。采用 2024 年 6 月至 10 月湖南株洲地区总电力负荷数据集进行仿真分析,IPO-DLinear-MSDC 模型的输出平均绝对百分比误差(mean absolute percentage error, MAPE)、决定系数 R^2 分别为 4.67%、0.833,相较于 IPO-DLinear 与 PO-DLinear 模型,MAPE 分别下降了 0.83 个百分点、1.43 个百分点, R^2 分别提升了 0.074、0.125。

关键词:日前电力负荷预测;气象相似日修正(MSDC);改进鹦鹉优化(IPO);线性分解(DLinear);Logistic 映射;欧氏距离

中图分类号:TM714

文献标志码:A

文章编号:2096-3203(2026)02-0121-10

0 引言

电力系统负荷预测是保障电力系统安全稳定运行、提高资源利用效率、促进可再生能源利用的重要手段^[1-2]。负荷预测为发电调度优化、电网规划扩展、电力市场经济运行提供了科学依据,有助于实现供需平衡、降低冗余浪费,同时支持需求侧管理和电价优化,推动清洁能源接入和智能电网建设。在实现碳中和目标的背景下,负荷预测对于构建高效、绿色、智能的现代电力系统具有重要意义。

当下流行多种负荷预测方法和模型,传统统计模型理论成熟、实现简便,得到了广泛应用^[3-4]。近年来,深度学习模型^[5]成为研究热点,常见的有循环神经网络、长短时记忆网络^[6-7]、门控循环单元(gated recurrent unit, GRU)^[8-9]、时间卷积网络^[10]以及卷积神经网络(convolutional neural network, CNN)^[11-12]等。集成模型通过结合多种模型的优势进一步提高预测精度^[13-17]。文献[18]提出基于双向长短时记忆(bidirectional long short-term memory, BiLSTM)神经网络的电力系统短期负荷预测模型,采用指数权移平均法处理缺失值。文献[19]提出基于完全集成经验模态分解和 BiLSTM 网络的误差预测模型以修正曲线形状。文献[20]运用迁移学习方法将 CNN-GRU 的训练迭代学习结果迁移

至目标域以提升预测性能,但对于数量庞大且相关性较低的数据存在一定局限性。文献[21]提出 CNN-双向门控循环单元(bidirectional gated recurrent unit, BiGRU)-Attention 预测模型,BiGRU 弥补了 GRU 单向时间序列的不足,但缺少对模型寻优的部分,难以在一定时间范围内得到最优解。文献[22]通过构建主从时间卷积网络实现负荷的初步预测和误差修正。新兴的线性变换模型如线性分解(decomposition-based linear, DLinear)^[23]展示出强大的预测能力,其创新之处在于结合了移动平均法来提取趋势成分,简化了复杂序列的处理过程,并采用线性建模方法分别预测趋势和季节性成分。与传统复杂模型相比,DLinear 在保持高预测精度的同时,计算效率更高、结构更简洁。

寻优算法的加入能够快速搜索大规模的解空间,找到全局最优解或接近最优解的结果,具有很强的适应性,能在不同的问题和约束条件下应用,如鹦鹉优化(parrot optimizer, PO)算法^[24]、鹭鹰优化(pied kingfisher optimizer, PKO)算法^[25]、麻雀搜索算法(sparrow search algorithm, SSA)等。文献[26]利用 SSA 对变分模态分解(variational mode decomposition, VMD)进行超参数寻优,再将数据中的噪音分解为多个周期性分量以更好地分析数据特征。文献[27]运用粒子群优化(particle swarm optimization, PSO)对 VMD 中惩罚因子和分解尺度进行寻优以消除主观调参对预测精度的影响。文献

收稿日期:2025-06-01;修回日期:2025-08-09

基金项目:国家重点研发计划资助项目(2022YFE0105200)

[28]运用 Logistic 映射对种群初始化以改进 PSO, 从而提高局部搜索能力。文献[29]通过模仿金枪鱼群螺旋觅食和抛物线觅食行为提出金枪鱼群优化(tuna swarm optimization, TSO)算法。文献[30]提出的探路者算法(pathfinder algorithm, PFA)通过模仿群体的领导层级来寻找最佳食物区域或猎物。受文献[29-30]中波动游走和螺旋觅食启发形成螺旋波动搜索策略以改进 PO 算法多路径探索, 文献[31]引入自适应变异策略处理算法迭代后期陷入局部最优解和收敛精度不高的问题。

现有的启发式算法和深度学习方法在一定程度上提高了预测精度, 但这些方法通常面临计算复杂度较高、模型过拟合等问题, 且对气象等外部因素的敏感性不足。传统组合算法难以准确捕捉各因素特征之间复杂的非线性关系, 容易陷入局部最优解, 对外部气象因素的考虑较少, 导致在气候变化较大时预测误差增大, 无法充分利用数据中的潜在信息, 进而影响预测结果的可靠性和稳定性。

为解决这一问题, 文献[32]采用最大互信息系数法对信息数据进行特征提取, 通过加权灰色关联度的历史相似日筛选方法生成历史数据集。文献[33]基于皮尔逊相关系数、灰色关联分析等构建日特征向量, 利用综合相似度寻找相似日作为深度学习网络的训练样本。文中提出一种基于历史气象数据的气象修正方法, 能够有效提高负荷预测的准确性。该方法通过计算预测日气象数据与历史气象数据之间的相似度, 选择与目标气象条件最相似的历史日, 进而修正负荷预测结果。

文中基于改进鹦鹉优化(improved parrot optimizer, IPO)算法对 DLinear 超参数进行寻优, 最大程度提高模型的预测能力。综合气象修正方法与优化算法, 文中提出的 IPO-DLinear 气象相似日修正(meteorological similar day correction, MSDC)模型在电力负荷预测中展现出优越的性能。

1 日前电力负荷预测气象特征筛选及相似日修正

1.1 气象特征筛选

从获取的气压、风向、风速、温度、相对湿度、水汽压、降水量中筛选出与负荷相关的气象特征, 采用皮尔逊相关系数法进行相关性分析。

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

式中: r 为皮尔逊相关系数; X_i 、 Y_i 分别为变量 X 、 Y 的第 i 个样本数据; \bar{X} 、 \bar{Y} 分别为变量 X 、 Y 的均值。

$r \in [-1, 1]$, r 值越接近 1 或 -1 表示变量之间的关系越强, 而 r 值接近 0 则表示变量之间几乎无相关关系。正相关系数表示变量之间的正向关系, 即一个变量增加时另一个也倾向增加; 负相关系数则表示反向关系, 即一个变量增加时另一个变量倾向减少。负荷与气象特征的相关系数如表 1 所示。

表 1 负荷与气象特征的相关系数

Table 1 Correlation coefficients between load and meteorological characteristics

气象特征	相关系数
气压	-0.084
风速	0.51
温度	0.87
相对湿度	-0.83
水汽压	0.21
降水量	-0.13
风向	0.022

由表 1 可知, 温度和负荷之间的相关性系数为 0.87, 表现出较强的正相关。这表明随着温度的升高, 负荷会显著增加。这通常是因为在高温天气中, 空调和制冷设备的使用频率上升, 用电需求增加。相对湿度和负荷之间的相关性系数为 -0.83, 表现出较强的负相关。这通常是因为在高温低湿的情况下, 对制冷的需求更高, 用电需求增加。因此, 当湿度降低时, 负荷会相应增加。风速和负荷之间的相关性系数为 0.51, 表现出中等强度的正相关。在风速较高时, 空气流动可能改善环境的舒适度, 从而间接影响空调等设备的使用频率, 导致负荷变化。在筛选气象特征时, 设定相关性系数的阈值为 0.5, 以确保选择的气象特征对负荷具有较强的预测能力。其他气象特征如水汽压和降水量, 虽然也与负荷存在一定关系, 但相关性较弱。基于此, 筛选得到温度、相对湿度和风速作为主要的负荷预测气象特征。

1.2 基于欧氏距离的 MSDC

基于欧氏距离的 MSDC 核心思想是利用预测日气象数据与历史气象数据之间的相似性, 结合历史负荷数据对负荷预测进行修正, 使模型在气象条件相似的前提下, 借用历史负荷的实际数据修正预测负荷, 减少预测误差。

首先, 模型读取负荷预测数据、预测日气象数据、历史负荷数据和历史气象数据, 并将这些数据转化为便于处理的 NumPy 数组。NumPy 数组是一

种多维数据结构, 具有高效的存储和计算能力。通过将数据转化为 NumPy 数组, 模型能够更方便地进行矩阵运算和数值计算。接着, 使用欧氏距离作为度量手段, 计算预测日气象数据和历史气象数据之间的相似性。欧氏距离是一种常用的度量方式, 能够有效衡量 2 个数据点之间的直线距离, 适用于多维数据的比较。具体来说, 对于每个预测日的气象数据点, 模型会计算该点与历史气象数据集中每个点的欧氏距离, 距离值越小, 表示预测日气象数据与历史气象数据的相似性越高。

通过这种方式, 模型能够找出与预测日气象数据最相似的历史气象数据点, 并提取对应的历史负荷值, 为预测提供有效的修正依据。数学描述如下:

$$S = \sqrt{\sum_{g=1}^G (F_p - H_{p,g})^2} \quad (2)$$

式中: S 为相似度; G 为历史总天数; F_p 为预测日气象数据; $H_{p,g}$ 为历史总天数中第 g 天的气象数据。

最后, 模型通过一个加权公式对预测负荷值进行修正, 结合预测负荷值和最相似历史负荷值, 利用调整系数控制修正权重, 使得模型在历史数据与预测日数据之间灵活平衡。这种方式能够适应不同数据的变化, 提高负荷预测的准确性。数学描述如下:

$$C_{\text{load}} = \alpha P_{\text{load}} + (1 - \alpha) S_{\text{load}} \quad (3)$$

式中: C_{load} 为修正后的预测负荷数据; α 为控制修正权重的参数, 文中设为 0.85; P_{load} 为模型预测的负荷; S_{load} 为最相似的历史气象点对应的负荷值。

2 基于 IPO-DLinear-MSDC 的日前电力负荷预测组合模型

2.1 PO 算法

(1) 种群初始化。设置一个大小为 N 的种群, 最大迭代数 T 设置为 100, 数学描述如下:

$$X_{i,0} = l_b + \text{rand}(0, 1) \times (u_b - l_b) \quad (4)$$

式中: $X_{i,0}$ 为第 i 个个体初始时刻位置; u_b 、 l_b 分别为搜索空间的上限和下限。

(2) 觅食行为。

$$X_{i,t+1} = (X_{i,t} - X_{\text{best}}) \text{Levy}(D) + W \quad (5)$$

$$W = \text{rand}(0, 1) \times \left(1 - \frac{t}{T}\right)^{\frac{2t}{T}} X_{\text{mean},t} \quad (6)$$

$$X_{\text{mean},t} = \frac{1}{N} \sum_{k=1}^N X_{k,t} \quad (7)$$

式中: $X_{i,t}$ 、 $X_{i,t+1}$ 分别为第 i 个个体在第 t 代、第 $t+1$ 代的位置; X_{best} 为当前搜索到的最佳位置; t 为当前迭

代次数; $\text{Levy}(D)$ 为描述鹦鹉飞行的列维分布; $X_{\text{mean},t}$ 为鹦鹉在第 t 代种群内的平均位置; $X_{k,t}$ 为种群中第 k 个个体在第 t 代的位置。

(3) 停留行为。

$$X_{i,t+1} = X_{i,t} + X_{\text{best}} \text{Levy}(D) + \text{rand}(0, 1) \times \text{ones}(1, D) \quad (8)$$

式中: $\text{ones}(1, D)$ 为维度为 D 的全 1 向量; $X_{\text{best}} \times \text{Levy}(D)$ 为鹦鹉飞向宿主的过程; $\text{rand}(0, 1) \times \text{ones}(1, D)$ 为鹦鹉随机停在宿主身体某部位的过程。

(4) 沟通行为。沟通行为分为飞向鸟群和飞离鸟群, 假设 2 种行为发生概率相等, 同时将 $X_{\text{mean},t}$ 记为群体中心。该过程表达式如下:

$$\begin{cases} 0.2R \left(1 - \frac{t}{T}\right) (X_{i,t} - X_{\text{mean},t}) & 0 \leq R \leq 0.5 \\ 0.2R \exp\left(-\frac{t}{\text{rand}(0, 1) \times T}\right) & 0.5 < R \leq 1 \end{cases} \quad (9)$$

式中: R 为 0~1 内的随机数; $0.2R \left(1 - \frac{t}{T}\right) (X_{i,t} - X_{\text{mean},t})$ 为个体加入群体交流的过程; $0.2R \times \exp\left(-\frac{t}{\text{rand}(0, 1) \times T}\right)$ 为个体交流完飞离的过程。

(5) 害怕陌生人行为。

$$X_{i,t+1} = X_{i,t} + R (X_{\text{best}} - X_{i,t}) \cos\left(0.5\pi \times \frac{t}{T}\right) - (X_{i,t} - X_{\text{best}}) \left(\frac{t}{T}\right)^{\frac{2}{T}} \cos(R\pi) \quad (10)$$

式中: $R (X_{\text{best}} - X_{i,t}) \cos\left(0.5\pi \times \frac{t}{T}\right)$ 为鹦鹉向宿主飞去的过程; $(X_{i,t} - X_{\text{best}}) \left(\frac{t}{T}\right)^{\frac{2}{T}} \cos(R\pi)$ 为鹦鹉远离陌生人的过程。

PO 算法流程如图 1 所示。

2.2 IPO 算法

(1) Logistic 映射初始化种群位置。在 PO 算法中, 初始种群的多样性对于全局搜索能力非常重要。为避免初始种群过于集中或趋于单一导致算法无法在搜索空间中有效探索, 采用 Logistic 映射初始化种群位置, 利用混沌映射增加初始种群的多样性, 确保搜索过程不受局部区域的限制, 从而提升全局搜索能力。数学描述如下:

$$C_{t+1} = \mu C_t (1 - C_t) \quad (11)$$

式中: μ 为控制映射状态的可调参数, 取值范围为 0~4, 文中取 3.9; C_t 为当前混沌序列的值; C_{t+1} 为更新后混沌序列的值。

(2) 螺旋波动搜索更新鹦鹉位置。种群个体的位置更新通常是线性的, 这会导致个体在搜索空间中沿着较为规则的路径进行搜索, 容易陷入局部最

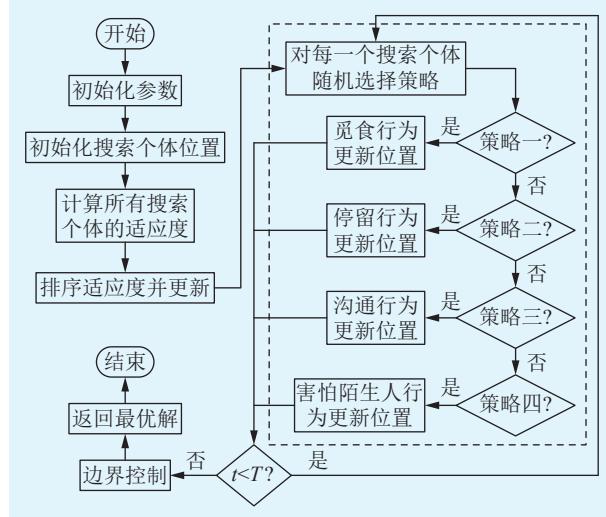


图 1 PO 算法流程

Fig.1 PO algorithm flowchart

优解。引入螺旋波动搜索策略后,个体能够在搜索空间中采用更加灵活、动态的路径进行搜索,从而增强算法跳出局部最优解的能力。数学描述如下:

$$Y_{i,t+1} = Y_{i,t} + r \exp(\theta i) (Y_{i,t} - Y_{\text{best},t}) \quad (12)$$

式中: $Y_{i,t}$ 为第 i 个个体在第 t 代的位置; $Y_{i,t+1}$ 为第 i 个个体经过螺旋搜索更新后的位置; r 、 θ 为螺旋搜索参数; $Y_{\text{best},t}$ 为第 t 代的最佳位置。

(3) 自适应变异策略。在 PO 算法的后期,当种群个体趋于收敛时,算法容易陷入局部最优解,搜索过程会变得缓慢且效果不佳。为提高后期搜索的效率,避免过早收敛,引入自适应变异策略。该策略能够在算法的后期通过调整变异强度增加种群的多样性,从而使个体继续进行有效的局部搜索,进一步提高收敛精度。自适应变异策略根据迭代次数动态调整变异强度,避免在早期阶段变异过强而破坏已获得的优良解。数学描述如下:

$$Y'_{\text{best}} = Y_{\text{best}} + \text{trnd}(t)(Y_{\text{best}} - Y_{\text{mean}}) \quad (13)$$

式中: Y_{best} 为当前最优解; Y'_{best} 为变异后的最优解; $\text{trnd}(t)$ 为分布变异函数; Y_{mean} 为种群平均位置。

利用 Rastrigin 函数测试 PO 算法在改进前后的寻优效果。Rastrigin 函数是一个典型的多峰优化问题,常用于测试优化算法的性能。其数学表达式包含大量局部极小值,并且由于 $\cos(2\pi x_i)$ 项的高频振荡,函数具有复杂的波动结构,导致算法容易陷入局部最优解, x_i 为第 i 个决策变量的值。全局最优解位于 $x_i = 0$ 时,函数值为 0,且随着维度的增大,局部最优解数量激增,优化难度也随之增加。数学表达式如下:

$$f(x_i) = 10d + \sum_{i=1}^d (x_i^2 - 10 \cos(2\pi x_i)) \quad (14)$$

式中: d 为决策变量的维度。

PO 算法改进前后迭代收敛情况如图 2 所示。

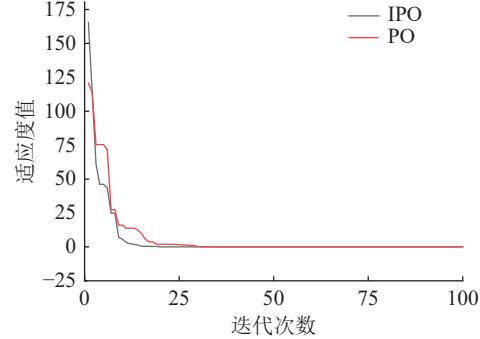


图 2 迭代收敛

Fig.2 Iterative convergence

2.3 DLLinear 模型

DLLinear 是一种专为时间序列预测设计且简洁高效的线性模型。其核心思想在于将输入的多变量时间序列数据分解为趋势成分和季节性成分,并对这两部分分别进行建模,最后将预测结果进行组合以获得最终的预测值。其分解与独立建模的方法能够提高预测的准确性。DLLinear 结构如图 3 所示,其中 W_t 、 W_s 为线性层的权重。

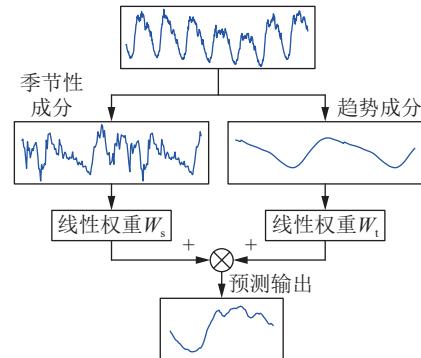


图 3 DLLinear 结构

Fig.3 DLLinear structure

在 DLLinear 模型中,序列分解通过移动平均实现。具体而言,给定一个时间序列 X_t ,首先通过移动平均法计算提取趋势成分 X_{trend} :

$$X_{\text{trend}} = \frac{1}{E} \sum_{i=0}^{E-1} x_{t-i} \quad (15)$$

式中: E 为移动窗口的大小。通过这种平滑操作,消除序列中的短期波动,突出长期趋势。随后,通过原始序列减去趋势成分得到季节性成分 X_{season} :

$$X_{\text{season}} = X_t - X_{\text{trend}} \quad (16)$$

分解后的趋势成分和季节性成分分别通过线性层进行建模和预测。对于每个成分,模型定义相应的线性变换:

$$\hat{X}_{\text{trend}} = W_t X_{\text{trend}} + b_t \quad (17)$$

$$\hat{X}_{\text{season}} = W_s X_{\text{season}} + b_s \quad (18)$$

式中: \hat{X}_{trend} 、 \hat{X}_{season} 分别为线性变换后的趋势成分和季节性成分; b_t 、 b_s 为对应的偏置项。

最终, DLinear 模型将趋势成分和季节性成分的预测结果进行组合, 得到最终的预测值 \hat{X} :

$$\hat{X} = \hat{X}_{\text{trend}} + \hat{X}_{\text{season}} \quad (19)$$

为了更好地优化 DLinear 模型的训练过程, 选择合适的超参数至关重要。不同的超参数配置会显著影响模型的收敛速度与预测精度。以下是一些关键的超参数设置, 其在模型的训练过程中起着决定性作用:

(1) 批次大小(batch size, BS), 控制每次更新中用于计算梯度的样本数量。

(2) 时间步长(time step, TS), 指每次输入到模型中的时间序列长度。较长的 TS 可以捕捉到更长时间范围内的依赖关系, 而较短的 TS 更适用于短期预测。

(3) 学习率(learning rate, LR), 控制每次权重更新的步长, 直接影响模型的收敛速度。过大的 LR 可能导致训练不稳定, 过小的 LR 则可能导致训练速度过慢。

(4) 学习率调度器耐心参数(learning patience, LP), 用于动态调整学习率, 以便在训练过程中根据验证集的表现逐步减小 LR, 从而提高模型的收敛

效果。

2.4 IPO-DLinear-MSDC 组合预测模型

基于 IPO-DLinear-MSDC 模型的日前电力负荷预测步骤如下。

阶段一: 将超参数 BS、TS、LR、LP 赋值为宿主位置, Logistic 映射初始化鹦鹉种群位置, 同时采用螺旋波动搜索更新位置, 通过自适应变异策略提高最优位置收敛精度, 输出超参数的最优值。

阶段二: 将经过标准化归一化的数据输入更新超参数后的 DLinear 中, DLinear 提取出季节性成分和趋势成分, 经线性层输出初步预测值。

阶段三: 将预测日气象数据与历史气象数据经欧氏距离比对后得出最佳相似日, 找到该日的历史负荷, 与预测负荷加权修正后输出最终预测结果。

图 4 为 IPO-DLinear-MSDC 模型, 其中采样间隔为 15 min。

3 实例验证分析

3.1 数据处理及评估指标

采用 2024 年 6 月至 10 月湖南株洲地区电网真实总电力负荷数据集、2024 年 10 月 31 日气象数据、2022 年总负荷数据集及 2022 年气象数据进行模型验证分析。其中 2024 年 6 月 1 日至 10 月 30 日为历史日, 10 月 31 日为待测日。2024 年

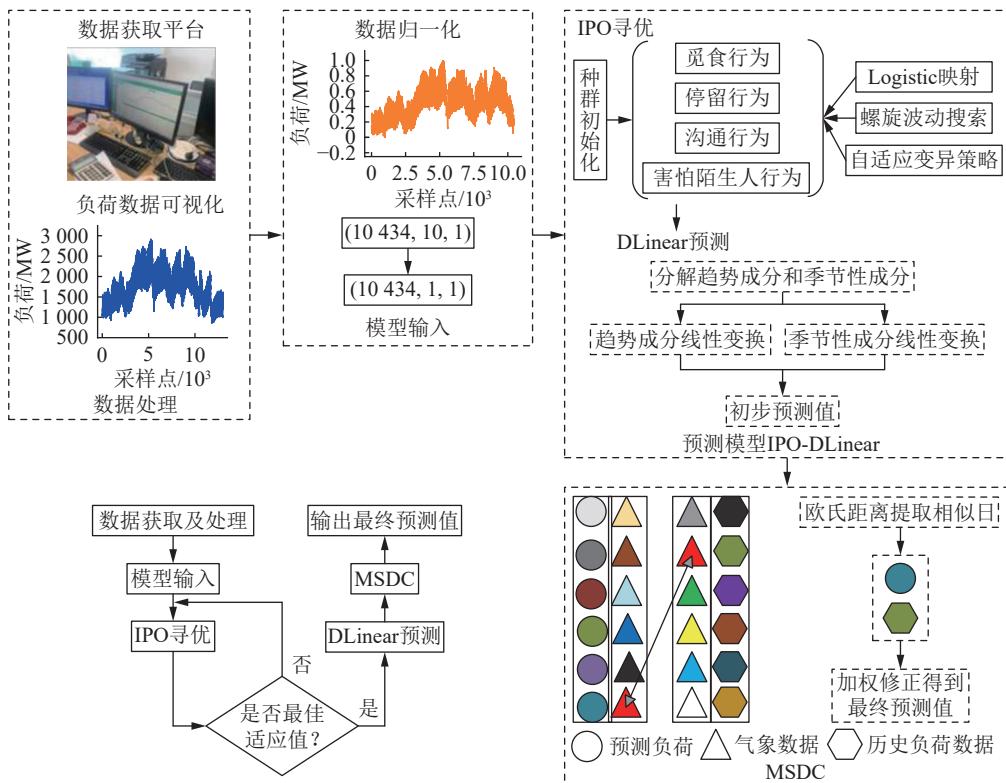


图 4 IPO-DLinear-MSDC 模型

Fig.4 IPO-DLinear-MSDC model

10月31日气象数据及2022年气象数据将用于气象相似日比对,比对筛选后从2022年总负荷数据集中得到最相似日的负荷数据,再与2024年10月31日负荷预测值进行修正处理。数据采样间隔为15 min,每天采样96组数据。

模型输出结果采用均方根误差(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)、决定系数 R^2 作为评估指标。其中RMSE对较大误差敏感,强调模型在极端值上的表现。MAE是预测值与实际值之间绝对差异的平均值,可直观反映预测值与实际值的误差大小。MAPE提供误差的相对比例,用于理解和比较不同模型的性能。 R^2 衡量模型对数据变异的解释能力,用于衡量模型拟合度。

3.2 DLinear 超参数寻优

采用IPO、PO、PKO、SSA对DLinear网络寻优,种群维度均设为15。DLinear网络超参数寻优范围如表2所示,寻优结果如表3所示。

表2 超参数寻优范围

Table 2 Optimization range of super parameters

超参数	寻优范围
BS	[16, 256]
TS	[24, 168]
LR	[0.0001, 0.01]
LP	[2, 10]

表3 超参数寻优结果

Table 3 Optimization results of super parameters

寻优算法	BS	TS	LR	LP
IPO	40	120	0.01000	6
PO	38	121	0.00996	10
PKO	96	110	0.00301	5
SSA	27	162	0.00973	8

3.3 模型预测结果

寻优后DLinear将以更新后的超参数进行负荷预测。图5、图6分别为IPO-DLinear模型对2024年10月31日预测负荷数据分解得到的季节性成分与趋势成分。

DLinear从数据中提取出季节性成分和趋势成分后,经线性权重输出初步预测值,随后通过2024年10月31日气象数据与2022年全年气象数据比对得到最佳相似日进行修正。表4为2024年10月31日与2022年历史日相似度前20排名。

将文中模型与IPO-DLinear模型、PO-DLinear

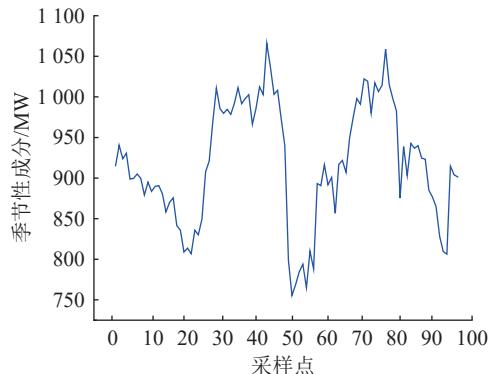


图5 电力负荷季节性成分

Fig.5 Seasonal component of power load

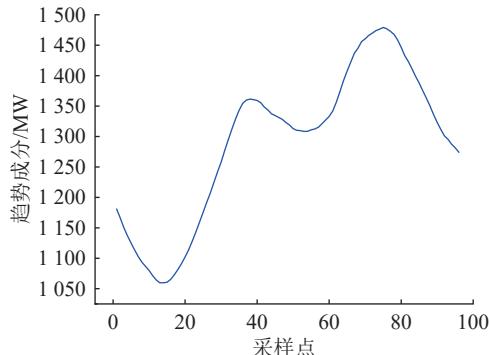


图6 电力负荷趋势成分

Fig.6 Trend component of power load

表4 10月31日与历史日相似度排名

Table 4 Ranking of similarity between October 31th and historical day

日期	欧氏距离	排名
2022年10月19日	358.219	1
2022年12月18日	359.674	2
2022年10月18日	368.299	3
2022年12月23日	398.751	4
2022年12月17日	402.228	5
2022年9月5日	405.257	6
2022年10月10日	407.489	7
2022年12月22日	413.405	8
2022年4月8日	415.085	9
2022年10月9日	418.839	10
2022年12月19日	426.641	11
2022年12月24日	434.166	12
2022年9月6日	434.623	13
2022年10月24日	435.039	14
2022年10月22日	439.978	15
2022年4月7日	440.778	16
2022年9月8日	447.588	17
2022年4月9日	447.902	18
2022年10月20日	447.971	19
2022年12月16日	448.445	20

模型、PKO-DLinear 模型、SSA-DLinear 模型、DLinear 模型、CNN-BiGRU-Attention 及 CNN-BiLSTM 传统组合预测模型进行对比, 训练迭代数均设置为 100。预测结果如图 7 所示, 图 8 为 11:15—15:00 预测结果放大图, 图 9 为误差散点图, 图 10 为 15:00—18:45 预测误差放大图, 表 5 为预测值与实际值的评估指标对比。

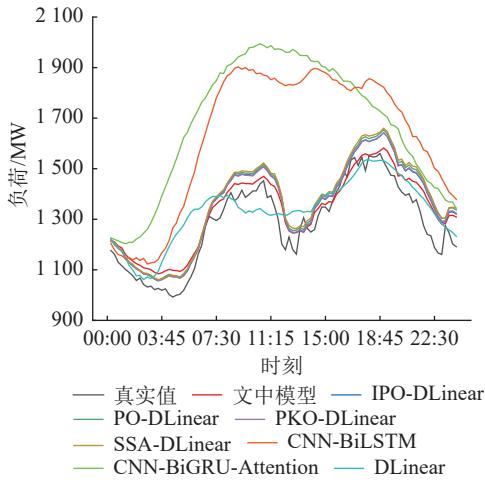


图 7 预测结果对比

Fig.7 Comparison of prediction results

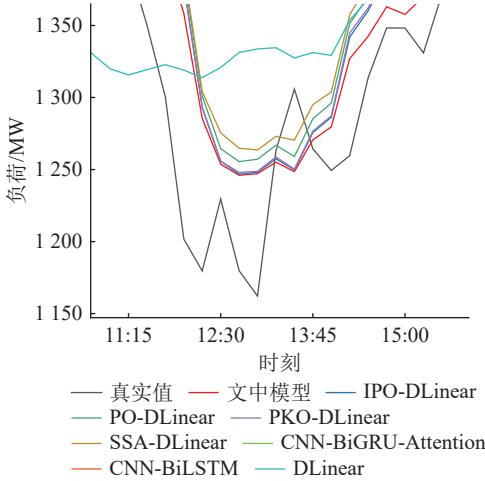


图 8 11:15—15:00 预测结果放大对比

Fig.8 Enlarged comparison of prediction results from 11:15 to 15:00

由图 7—图 10 可知, 文中模型相较于其他模型精度明显提升。结合气象修正的模型在多个时间段内表现出较小的预测误差, 尤其在负荷变化较大的时段, 负荷预测值的精度显著高于其他模型。

由表 5 可知, 文中模型与其他模型相比, MAE 分别下降 13.3、21.134、13.695、25.243、19.649、341.53、290.608 MW; RMSE 分别下降 13.492、21.629、14.068、25.842、32.277、382.463、319.434 MW; MAPE 分别下降 0.83、1.43、0.86、1.73、1.75、26.98、22.19 个百分点; R^2 分别上升 0.074、0.125、

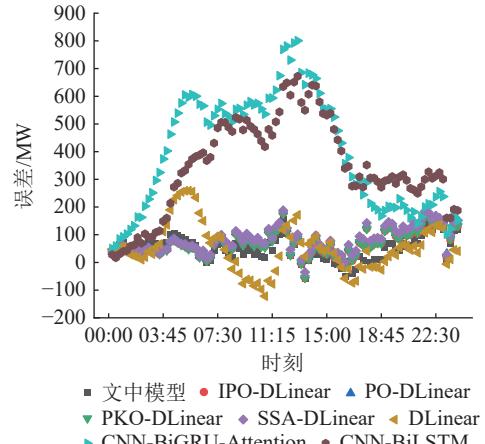


图 9 预测误差对比

Fig.9 Comparison of prediction errors

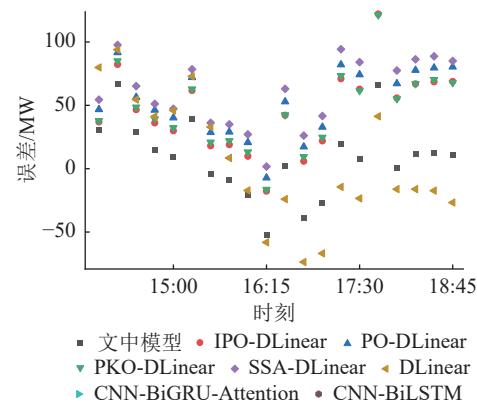


图 10 15:00—18:45 预测误差放大对比

Fig.10 Enlarged comparison of prediction errors from 15:00 to 18:45

表 5 评估指标对比

Table 5 Comparison of evaluation indices

模型	MAE/MW	RMSE/MW	MAPE/%	R^2
文中模型	56.639	66.957	4.67	0.833
IPO-DLinear	69.939	80.449	5.50	0.759
PO-DLinear	77.773	88.586	6.10	0.708
PKO-DLinear	70.334	81.025	5.53	0.755
SSA-DLinear	81.882	92.799	6.40	0.679
DLinear	76.288	99.234	6.42	0.633
CNN-BiGRU-Attention	398.169	449.420	31.65	-6.524
CNN-BiLSTM	347.247	386.391	26.86	-4.562

0.078、0.154、0.2、7.357、5.395。

4 结论

文中提出基于 IPO 的寻优算法, 结合自适应变异策略和螺旋波动搜索策略, 以解决传统算法在全局搜索能力和收敛度上的不足。首先, 运用 Logistic 映射初始化种群位置, 提升初始化位置的多样性, 增强算法的全局搜索能力。其次, 在螺旋波动搜索

策略下, IPO 算法能够根据多条路径灵活调整位置, 从而有效找到全局最优解。最后, 引入自适应变异策略, 解决算法在后期收敛度不高和易陷入局部最优解的问题。IPO 算法相比 PO 算法在求解精度和收敛速度上均有所提升, 特别是在处理高维复杂问题时表现出更为稳定和准确的预测能力。同时, 文中针对电力系统负荷的季节性和天气依赖性, 提出基于历史气象数据的气象修正方法。通过欧氏距离计算预测日气象数据与历史数据之间的相似度, 模型能够识别出与当前气象条件最相似的历史天数, 并利用相应的历史负荷数据进行修正, 从而有效提升负荷预测的准确性。

文中研究表明将 IPO-DLinear 模型与气象修正方法相结合能够显著提高常规情况下的预测精度。结合气象数据的多种输入变量, 模型不仅能增强对气象变化的适应能力, 还能有效改善预测结果的鲁棒性。此外, 考虑到数据处理和预测操作的便捷性, 后续将搭建人机交互平台, 进一步优化实际应用中的预测工作。

致谢

本文得到国网湖南省电力有限公司株洲供电公司科技项目(SGHNZZ00DKWT2400646)资助, 谨此致谢!

参考文献:

- [1] 申洪涛, 李飞, 史轮, 等. 基于气象数据降维与混合深度学习的短期电力负荷预测[J]. 电力建设, 2024, 45(1): 13-21.
SHEN Hongtao, LI Fei, SHI Lun, et al. Short-term power load forecasting based on reduction of meteorological data dimensionality and hybrid deep learning[J]. Electric Power Construction, 2024, 45(1): 13-21.
- [2] 韩宝慧, 陆玲霞, 包哲静, 等. 基于多头概率稀疏自注意力模型的综合能源系统多元负荷短期预测[J]. 电力建设, 2024, 45(2): 127-136.
HAN Baohui, LU Lingxia, BAO Zhejing, et al. Short-term forecasting of multienergy loads of integrated energy system based on multihead probabilistic sparse self-attention model[J]. Electric Power Construction, 2024, 45(2): 127-136.
- [3] 卜飞飞, 白宏坤, 王圆圆, 等. 基于人体舒适度指数的居民用电分析及用电负荷预测研究[J]. 中国测试, 2023, 49(4): 85-91.
BU Feifei, BAI Hongkun, WANG Yuanyuan, et al. Research on resident electricity consumption based on human comfort index and power load forecasting[J]. China Measurement & Test, 2023, 49(4): 85-91.
- [4] 吴迪, 马文莉, 杨利君. 二次指数平滑多目标组合模型电力负荷预测[J]. 计算机工程与设计, 2023, 44(8): 2541-2547.
WU Di, MA Wenli, YANG Lijun. Power load forecasting with quadratic exponential smoothing multi-objective combination model[J]. Computer Engineering and Design, 2023, 44(8): 2541-2547.
- [5] XU H S, FAN G L, KUANG G F, et al. Construction and application of short-term and mid-term power system load forecasting model based on hybrid deep learning[J]. IEEE Access, 2023, 11: 37494-37507.
- [6] 汤义勤, 邹宏亮, 蒋旭, 等. 基于 VMD 和贝叶斯优化 LSTM 的母线负荷预测方法[J]. 电网与清洁能源, 2023, 39(2): 46-52, 59.
TANG Yiqin, ZOU Hongliang, JIANG Xu, et al. A bus load forecasting method based on VMD and Bayesian optimization LSTM[J]. Power System and Clean Energy, 2023, 39(2): 46-52, 59.
- [7] 王延峰, 曹育晗, 孙军伟. 基于多策略改进金豺算法优化 LSTM 的短期电力负荷预测[J]. 电力系统保护与控制, 2024, 52(14): 95-102.
WANG Yanfeng, CAO Yuhuan, SUN Junwei. Short-term power load forecasting based on multi-strategy improved golden jackal algorithm-optimized LSTM[J]. Power System Protection and Control, 2024, 52(14): 95-102.
- [8] 侯健敏, 孟莹, 李志, 等. 基于综合相关性指标与 SA-BiGRU 的综合能源系统多元负荷预测[J]. 电力建设, 2024, 45(5): 118-130.
HOU Jianmin, MENG Ying, LI Zhi, et al. Multi-energy load forecasting in integrated energy systems based on comprehensive correlation index and SA-BiGRU network[J]. Electric Power Construction, 2024, 45(5): 118-130.
- [9] 肖威, 方娜, 邓心. 基于 VMD-LSTM-IPSO-GRU 的电力负荷预测[J]. 科学技术与工程, 2024, 24(16): 6734-6741.
XIAO Wei, FANG Na, DENG Xin. Short-term load forecasting based on VMD-LSTM-IPSO-GRU[J]. Science Technology and Engineering, 2024, 24(16): 6734-6741.
- [10] 许青, 张龄之, 梁琛, 等. 基于联合时序场景和改进 TCN 的高比例新能源电网负荷预测[J]. 广东电力, 2024, 37(1): 1-7.
XU Qing, ZHANG Lingzhi, LIANG Chen, et al. Short-term load forecasting for power system with high proportion new energy based on joint sequential scenario and improved TCN[J]. Guangdong Electric Power, 2024, 37(1): 1-7.
- [11] 陈晓红, 王辉, 李喜华. 基于 KPCA-CNN-DBiGRU 模型的短期负荷预测方法[J]. 管理工程学报, 2024, 38(2): 221-231.
CHEN Xiaohong, WANG Hui, LI Xihua. A short-term load forecasting method based on KPCA-CNN-DBiGRU model[J]. Journal of Industrial Engineering and Engineering Management, 2024, 38(2): 221-231.
- [12] 葛众, 隆交凤, 李健, 等. 结合 CNN 与软共享机制的综合能源系统多元负荷预测[J]. 电力建设, 2024, 45(12): 162-173.
GE Zhong, LONG Jiaofeng, LI Jian, et al. Multivariate load forecasting of integrated energy systems based on convolutional neural network and soft sharing mechanism[J]. Electric Power Construction, 2024, 45(12): 162-173.
- [13] 李甲祎, 赵兵, 刘宣, 等. 基于 DWT-Informer 的台区短期负

- 荷预测[J]. 电测与仪表, 2024, 61(3): 160-166, 191.
- LI Jiayi, ZHAO Bing, LIU Xuan, et al. Short-term substation load forecasting based on DWT-Informer model[J]. Electrical Measurement & Instrumentation, 2024, 61(3): 160-166, 191.
- [14] 朱继忠, 苗雨旺, 董朝阳, 等. 基于 Attention-LSTM 与多模型集成的短期负荷预测方法[J]. 电力工程技术, 2023, 42(5): 138-147.
- ZHU Jizhong, MIAO Yuwang, DONG Zhaoyang, et al. Short-term load forecasting method based on Attention-LSTM and multi-model integration[J]. Electric Power Engineering Technology, 2023, 42(5): 138-147.
- [15] 王永利, 刘泽强, 董焕然, 等. 基于 CEEMDAN-CSO-LSTM-MTL 的综合能源系统多元负荷预测[J]. 电力建设, 2025, 46(1): 72-85.
- WANG Yongli, LIU Zeqiang, DONG Huanran, et al. Multivariate load forecasting of integrated energy system based on CEEMDAN-CSO-LSTM-MTL[J]. Electric Power Construction, 2025, 46(1): 72-85.
- [16] 李楠, 姜涛, 隋想, 等. 一种时频尺度下的多元短期电力负荷组合预测方法[J]. 电力系统保护与控制, 2024, 52(13): 47-58.
- LI Nan, JIANG Tao, SUI Xiang, et al. A multi-component short-term power load combination forecasting method on a time-frequency scale[J]. Power System Protection and Control, 2024, 52(13): 47-58.
- [17] 刘杰, 从兰美, 夏远洋, 等. 基于 DBO-VMD 和 IWOA-BiLSTM 神经网络组合模型的短期电力负荷预测[J]. 电力系统保护与控制, 2024, 52(8): 123-133.
- LIU Jie, CONG Lanmei, XIA Yuanyang, et al. Short-term power load prediction based on DBO-VMD and an IWOA-BiLSTM neural network combination model[J]. Power System Protection and Control, 2024, 52(8): 123-133.
- [18] 张淑清, 李君, 姜安琦, 等. 基于 FPA-VMD 和 BiLSTM 神经网络的新型两阶段短期电力负荷预测[J]. 电网技术, 2022, 46(8): 3269-3279.
- ZHANG Shuqing, LI Jun, JIANG Anqi, et al. A novel two-stage model based on FPA-VMD and BiLSTM neural network for short-term power load forecasting[J]. Power System Technology, 2022, 46(8): 3269-3279.
- [19] 张家安, 李凤贤, 王铁成, 等. 一种采用记忆神经网络和曲线形状修正的负荷预测方法[J]. 电力工程技术, 2024, 43(1): 117-126.
- ZHANG Jiaan, LI Fengxian, WANG Tiecheng, et al. A load prediction method using memory neural network and curve shape correction[J]. Electric Power Engineering Technology, 2024, 43(1): 117-126.
- [20] 程明, 翟金星, 马骏, 等. 基于迁移学习的 CNN-GRU 短期电力负荷预测方法[J]. 武汉大学学报(工学版), 2024, 57(6): 812-820.
- CHENG Ming, ZHAI Jinxing, MA Jun, et al. Transfer learning based CNN-GRU short-term power load forecasting method [J]. Engineering Journal of Wuhan University, 2024, 57(6): 812-820.
- [21] 任爽, 杨凯, 商继财, 等. 基于 CNN-BiGRU-Attention 的短期电力负荷预测[J]. 电气工程学报, 2024, 19(1): 344-350.
- REN Shuang, YANG Kai, SHANG Jicai, et al. Short-term power load forecasting based on CNN-BiGRU-attention[J]. Journal of Electrical Engineering, 2024, 19(1): 344-350.
- [22] 李文武, 张鹏宇, 石强, 等. 基于聚合混合模态分解和时序卷积神经网络的综合能源系统负荷修正预测[J]. 电网技术, 2022, 46(9): 3345-3357.
- LI Wenwu, ZHANG Pengyu, SHI Qiang, et al. Correction prediction of integrated energy system load based on aggregated mixed mode decomposition and TCN[J]. Power System Technology, 2022, 46(9): 3345-3357.
- [23] ZENG A L, CHEN M X, ZHANG L, et al. Are transformers effective for time series forecasting?[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2023, 37(9): 11121-11128.
- [24] LIAN J B, HUI G H, MA L, et al. Parrot optimizer: algorithm and applications to medical problems[J]. Computers in Biology and Medicine, 2024, 172: 108064.
- [25] BOUAOUEDA A, HASHIM F A, SAYOUTI Y, et al. Pied kingfisher optimizer: a new bio-inspired algorithm for solving numerical optimization and industrial engineering problems[J]. Neural Computing and Applications, 2024, 36(25): 15455-15513.
- [26] 林彦旭, 高辉. 基于 SSA-VMD-BiLSTM 模型的充电站负荷预测方法[J]. 广东电力, 2024, 37(6): 53-61.
- LIN Yanxu, GAO Hui. Load prediction method of charging station based on SSA-VMD-BiLSTM model[J]. Guangdong Electric Power, 2024, 37(6): 53-61.
- [27] 徐岩, 向益锋, 马天祥. 基于粒子群算法优化参数的 VMD-GRU 短期电力负荷预测模型[J]. 华北电力大学学报(自然科学版), 2023, 50(1): 38-47.
- XU Yan, XIANG Yifeng, MA Tianxiang. VMD-GRU short-term power load forecasting model based on optimized parameters of particle swarm algorithm[J]. Journal of North China Electric Power University (Natural Science Edition), 2023, 50(1): 38-47.
- [28] 雷何, 方仍存, 杨东俊, 等. 基于改进二阶粒子群算法的微电网群优化调度[J]. 武汉大学学报(工学版), 2022, 55(9): 894-900.
- LEI He, FANG Rengcun, YANG Dongjun, et al. Multi-microgrid optimization scheduling based on improved secondorder particle swarm optimization algorithm[J]. Engineering Journal of Wuhan University, 2022, 55(9): 894-900.
- [29] XIE L, HAN T, ZHOU H, et al. Tuna swarm optimization: a novel swarm-based metaheuristic algorithm for global optimization[J]. Computational Intelligence and Neuroscience, 2021, 2021: 9210050.
- [30] YAPICI H, CETINKAYA N. A new meta-heuristic optimizer:

- pathfinder algorithm[J]. *Applied Soft Computing*, 2019, 78: 545-568.
- [31] 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]. 中国测试, 2025, 51(4): 82-90.
- BAI Yu, XUE Guijun, XIE Wenju, et al. Improved GJO optimized CNN-BiLSTM heat load prediction model[J]. China Measurement & Test, 2025, 51(4): 82-90.
- [32] WEI S C, HE C, ZHANG J L, et al. Short-term load forecast based on similar daily retrieval and deep learning[C]//2023 IEEE/IAS Industrial and Commercial Power System Asia (I&CPS Asia). Chongqing, China. IEEE, 2023: 1136-1142.
- [33] 艾雨, 贾燕冰, 韩肖清. 基于相似日筛选与组合深度学习模型的日前电价预测方法[J]. 电网技术, 2025, 49(1): 242-251.

AI Yu, JIA Yanbing, HAN Xiaoqing. Day-ahead electricity price prediction method based on similar day screening and combined deep learning modeling[J]. *Power System Technology*, 2025, 49(1): 242-251..

作者简介：



于惠钧

于惠钧(1975),男,博士,教授,研究方向为电气分析与仿真、系统保护与自动化技术(E-mail: arejonyu@foxmail.com);

赵文川(2001),男,硕士在读,研究方向为电力系统负荷预测;

刘颉(1989),男,博士,讲师,研究方向为电能质量在线检测、检测技术与自动化技术。

Day-ahead power load forecasting based on meteorological similar day correction and IPO-DLinear

YU Huijun¹, ZHAO Wenchuan¹, LIU Jie¹, XU Yinfeng², ZOU Hai², GU Haibin²

(1. School of Transportation and Electrical Engineering, Hunan University of Technology, Zhuzhou 412007, China;

2. Zhuzhou Power Supply Company, State Grid Hunan Electric Power Co., Ltd., Zhuzhou 412000, China)

Abstract: The existing power load forecasting methods encounter significant challenges, particularly when accounting for the influence of meteorological factors on load fluctuations. Traditional methods often overlook the complex nonlinear relationship between meteorological characteristics and load, leading to reduced forecasting accuracy. A day-ahead power load forecasting model based on meteorological similar day correction (MSDC)-improved parrot optimizer (IPO)-decomposition-based linear (DLinear) is proposed. The proposed method enhances the parrot optimizer (PO) by incorporating a logistic map, adaptive mutation strategy, and spiral fluctuation search to optimize the DLinear superparameters. Periodicity and trend characteristics are extracted from the DLinear model. The load forecast value is corrected by comparing the Euclidean distance of meteorological characteristics. The resulting day-ahead power load forecasting model, IPO-DLinear-MSDC, is validated using a simulation analysis of total load data from the Zhuzhou area in Hunan from June to October 2024. The model's performance is evaluated with an average absolute percentage error (MAPE) of 4.67% and R^2 of 0.833, demonstrating improvements of 15.09% and 23.44%, and increases of 0.074 1 and 0.125 3, respectively, comparing to IPO-DLinear model and PO-DLinear model.

Keywords: day-ahead power load forecasting; meteorological similar day correction (MSDC); improved parrot optimizer (IPO); decomposition-based linear (DLinear); Logistic map; Euclidean distance

(编辑 方晶)