

DOI:10.11784/tdxbz202103075

面向商业和居民混合的配电网短期负荷预测 HGWOACOA-LSTMN 方法

葛磊蛟¹, 刘航旭¹, 赵康², 李华³, 张波⁴, 李元良¹

(1. 天津大学智能电网教育部重点实验室, 天津 300072; 2. 山东科技大学电气与自动化工程学院, 青岛 266590;
3. 国网辽宁省电力有限公司经济技术研究院, 沈阳 110015; 4. 中国人民解放军 32654 部队, 济南 250024)

摘要: 针对商业和居民混合的配电网负荷预测影响因素多样和随机性强的特点, 提出了一种基于灰狼郊狼混合优化算法(HGWOACOA)和长短时记忆网络(LSTMN)相结合的配电网短期电力负荷预测方法. 为实现对电力负荷的多输入特征进行筛选和降维, 本文采用最大信息系数法(MIC)对负荷与输入特征之间的非线性相关性进行量化, 剔除无效特征, 再采用因子分析(FA)法对历史数据、气象、温度等输入特征进行信息提取, 实现对有效影响因素降维; 综合考虑灰狼优化算法(GWOA)具有全局搜索能力强、收敛速度快的特点, 郊狼优化算法(COA)具有区域探索能力强、求解精度高的特点, 为突出两种算法优点并弥补两种算法的不足, 提出 HGWOACOA 对 LSTMN 的隐藏层神经元个数和一次训练样本个数两种参数进行优化, 克服了参数选取的困难. 在保证预测精度的同时提升运行效率, 实现基于 HGWOACOA-LSTMN 的配电网短期电力负荷高精度预测. 以配电网某商业和居民混合负荷为例, 验证了文中所述预测方法具有较好的精度和鲁棒性, 同时提升了运行效率和简化模型输入特征的维数, 证明本文所提方法的精确度和适用性.

关键词: 配电网; 短期负荷预测; 因子分析; 灰狼优化算法; 郊狼优化算法; 长短时记忆网络

中图分类号: TM744 **文献标志码:** A **文章编号:** 0493-2137(2021)12-1269-11

An HGWOACOA-LSTMN Method for Short-Term Load Forecasting of Distribution Network for Commercial and Residential Users

Ge Leijiao¹, Liu Hangxu¹, Zhao Kang², Li Hua³, Zhang Bo⁴, Li Yuanliang¹

(1. Key Laboratory of Smart Grid of Ministry of Education, Tianjin University, Tianjin 300072, China;
2. School of Electrical and Automation Engineering, Shandong University of Science and Technology, Qingdao 266590, China; 3. Economic and Technological Research Institute, State Grid Liaoning Electric Power Co., Ltd., Shenyang 110015, China; 4. 32654 PLA Troops, Jinan 250024, China)

Abstract: For the commercial and residential mixed distribution network load forecasting, the influence factors are diverse and randomness is high. A short-term power load forecasting method of distribution network based on the hybrid grey wolf optimization algorithm with coyote optimization algorithm(HGWOACOA) and long short-term memory network (LSTMN) is proposed. To select and reduce multiple input characteristics of power load, in this paper, we use the maximum information coefficient(MIC) method to quantify the nonlinear correlation between the load and input characteristics, eliminate the invalid features, and then use the factor analysis(FA) method to extract the information of historical data, meteorology, temperature and other input features, so as to reduce the dimension of

收稿日期: 2021-03-31; 修回日期: 2021-06-03.

作者简介: 葛磊蛟(1984—), 男, 博士, 副教授.

通信作者: 葛磊蛟, legendgj99@tju.edu.cn.

基金项目: 国家自然科学基金资助项目(51807134); 省部共建电工装备可靠性与智能化国家重点实验室(河北工业大学)开放课题基金资助项目(EERI_KF20200014).

Supported by the National Natural Science Foundation of China(No. 51807134), the State Key Laboratory of Reliability and Intelligence of Electrical Equipment, Hebei University of Technology(No. EERI_KF20200014).

effective influencing factors. Results show that the grey wolf optimization algorithm (GWOA) has strong global search ability and fast convergence speed, and the coyote optimization algorithm (COA) has strong global search ability and fast convergence speed. To highlight the advantages of the two algorithms and make up for their corresponding shortcomings, a hybrid GWOA with COA (HGWOACOA) is proposed to solve long short-term memory networks. The number of hidden layer neurons and the number of training samples are optimized to overcome the difficulty of parameter selection. While ensuring the prediction accuracy, the operation efficiency is also improved, which realized the high-precision short-term power load forecasting of the distribution network based on HGWOACOA-LSTMN. Taking a commercial and residential mixed load in a distribution network as an example, the accuracy and robustness of the proposed forecasting method are verified. Meanwhile, the operation efficiency is improved and the dimension of the input characteristics of the model is simplified, which proves the accuracy and applicability of the proposed method.

Keywords: distribution network; short-term load forecasting; factor analysis; grey wolf optimization algorithm; coyote optimization algorithm; long short-term memory network

随着我国经济和城市快速发展,商业和居民混合场景在城市配电网中所占比例显著提升,逐渐成为城市电网的重要组成部分.为有效保证城市配电网安全可靠、经济高效运行,精准的短期负荷预测至关重要.然而,商业和居民混合负荷,不仅受营业时间及居民消费水平影响,而且易受气温、风力等诸多因素影响,具有强非线性和随机性的特征,如何实现对其精准、快速短期预测,挑战大,值得深入研究.

短期电力负荷预测是电力系统优化调度、经济运行的重要依据,国内外学者们提出了一些方法,主要可分为两种类型^[1-5].其一是时序外推法,如线性回归^[1-2]、自回归移动平均法^[3]等;其二是人工智能的预测方法,包括支持向量机(support vector machine, SVM)^[4]、人工神经网络(artificial neural network, ANN)^[5]等.然而,虽然方法不断地提出与改进,短期或者超短期负荷预测结果的精确性不断提高,但商业和居民混合负荷强随机性场景下,上述方法依然较难准确地把握其变化规律.另外,国内外对于商业和居民混合负荷的短期电力负荷预测研究涉及不多,大多集中在单一商业或单一居民负荷预测.文献[6]考虑到工作时间和气象因素的影响,提出了一种商业负荷预测模型,但预测采用线性模型,预测误差较大.文献[7]采用小波变换和支持向量机对商业负荷时间序列进行建模预测,但模型未考虑气象等影响因素,鲁棒性较差.

长短期记忆网络(long short-term memory networks, LSTMN)适用于影响因素多且复杂随机性强的预测,正好贴合商业和居民混合负荷特色.然而,长短期记忆网络方法应用于负荷预测的主要问题有:一方面,现有的研究大多把重点放在输入数据的选择,并未充分考虑输入数据对负荷预测结果精准与稳

定的干扰;另一方面,负荷预测模型超参数选择是预测精准的关键之一,如何选择最适合输入特征的模型超参数,现在缺乏较多的依据.

针对上述问题,本文提出了一种基于灰狼郊狼混合优化算法(hybrid grey wolf optimization algorithm with coyote optimization algorithm, HGWOACOA)和 LSTMN 相结合的配电网商业及居民混合短时负荷预测模型.针对商业和居民混合负荷的强非线性和随机性特点,首先采用最大信息系数(maximal information coefficient, MIC)法筛选输入特征,确定具有强相关性的影响因素,并利用因子分析(factor analysis, FA)法对多输入特征进行筛选和降维,作为负荷模型的输入.然后,提出一种灰狼郊狼混合优化算法,并通过该算法对长短期记忆网络模型的隐藏层神经元个数和一次训练样本个数两种参数进行优化,构建基于 HGWOACOA 的短期负荷预测模型.最后,以某区域商业居民混合的实际配电网负荷数据进行仿真计算,验证本文所述预测方法具有极高精确性和鲁棒性.

1 负荷预测输入特征分析

1.1 负荷预测影响因素分析

配电网商业和居民混合负荷预测的影响因素众多^[8],主要为历史负荷、日期类型和多种气象因素等.其中,历史负荷具有日周期性的特点,不同时刻的负荷显著不同;日期类型会影响商业场所的人流量和居民用电行为,导致休息日与工作日的负荷水平不一致;气象因素的变化会引起负荷的剧烈波动.综合考虑以上的影响因素,对负荷预测的原始输入进行梳理,如表 1 所示,其中假设预测时刻为 t ,日期类型为工作日与休息日.

表1 负荷预测输入特征

Tab.1 Input feature of load forecasting

影响因素	描述
历史负荷	预测日前 2 个同日期类型日 $t, t-1, t+1$ 时刻历史负荷值
温度	预测日 t 时刻预测温度, 预测日平均预测温度
积温效应	预测日前 3 天 t 时刻温度
气压	预测日 t 时刻预测气压
风速	预测日 t 时刻预测风速
相对湿度	预测日 t 时刻预测相对湿度
降水量	预测日 t 时刻预测降水量
日照时长	预测日日照时长
时刻	t 时刻

1.2 负荷预测输入特征的筛选与降维

商业和居民混合负荷受到众多复杂因素的影响. 如果选取负荷预测输入特征过多, 会导致预测模型出现过拟合现象, 增加计算的复杂程度、降低模型性能. 同时, 商业和居民混合负荷具有较多气象输入特征, 不同气象输入特征之间具有强相关性. 为此, 本文采用 MIC 法和 FA 法对气象输入特征进行降维, 以降低负荷预测复杂程度.

1.2.1 最大信息系数法

针对商业和居民混合负荷预测和输入特征的强非线性特点, 本文采用 MIC 法量化短期负荷与输入特征之间的关系, 该方法能够公平覆盖所有类型函数, 能较好克服原始数据中的噪声和异常点^[9], 下面进行详细阐述.

对于一个二元数据集 $O \in \mathbf{R}^2$, 将 O 划分为 x 列 y 行的网格. 对于划分的网格 G , 计算 G 中的每个单元的概率, 得到二元数据集在网格 G 上的概率分布 $O|_G$. 求得其最大互信息 $\max I(O|_G)$, 将其保存为 $I^*[O(x, y)]$, 即

$$I^*[O(x, y)] = \max I(O|_G) \quad (1)$$

进一步, 将其得到的互信息标准化, 并求出最大互信息系数

$$M(O)_{x,y} = \frac{I^*[O(x, y)]}{\lg \min\{x, y\}} \quad \text{s.t. } xy < B(n) \quad (2)$$

式中: n 为采样样本大小; $B(n)$ 是关于采样样本大小的函数, 表示网格 G 划分方格总数 xy 的约束, 需小于 $B(n)$, 一般 $B(n) = n^{0.6}$.

$$L(O)_{\text{MIC}} = \max_{xy < B(n)} \{M(O)_{x,y}\} \quad (3)$$

两个变量之间的 MIC 值越大, 其相关性越强; MIC 值越小, 相关性越弱.

1.2.2 因子分析法

因子分析法是一种通过降维技术化简多维向量的多元统计方法, 属于主成分分析 (principal component analysis, PCA) 的推广, 常被用于电力系统中具有复杂相关性的多维向量降维化简^[10].

设标准化后的气象输入特征为 $\mathbf{P} = [P_1, P_2, \dots, P_{\text{dim}}]^T$, dim 为气象输入特征维数, 因子分析的一般模型为

$$\mathbf{P} = \mathbf{A}\mathbf{F} + \boldsymbol{\varepsilon} \quad (4)$$

式中: $\mathbf{F} = [f_1, f_2, \dots, f_r]^T$ 为公共因子变量; $\mathbf{A} = (a_{ij})_{\text{dim} \times r}$ 为因子荷载矩阵, 其解释了变量 P_i 之间的相关关系, a_{ij} 为变量 P_i 在公共因子 f_j 上的荷载, 它反映了公共因子 f_j 对变量 P_i 的重要程度. $\mathbf{A}\mathbf{F}$ 为公共分量, 包含了气象输入特征的共性信息. $\boldsymbol{\varepsilon} = [\varepsilon_1, \varepsilon_2, \dots, \varepsilon_{\text{dim}}]^T$ 为特殊因子向量, 代表负荷预测输入特征中不能被公共因子解释的部分.

求解式(1)需要对估计因子荷载阵 \mathbf{A} 和特殊方差阵 $\boldsymbol{\Theta}$ 进行估计, 采用主成分估计法:

$$\hat{\mathbf{A}} = \left[\sqrt{\hat{\lambda}_1} \hat{e}_1, \sqrt{\hat{\lambda}_2} \hat{e}_2, \dots, \sqrt{\hat{\lambda}_r} \hat{e}_r \right] = (a_{ij})_{\text{dim} \times r} \quad (5)$$

$$\hat{\boldsymbol{\Theta}} = \text{diag}(\hat{v}_1^2, \hat{v}_2^2, \dots, \hat{v}_{\text{dim}}^2) \quad (6)$$

$$\hat{v}_i^2 = s_{ii} - \sum_{j=1}^r \hat{a}_{ij}^2 \quad i=1, 2, \dots, \text{dim} \quad (7)$$

式中: $\hat{\lambda}_1 \geq \hat{\lambda}_2 \geq \dots \geq \hat{\lambda}_r \geq 0$ 为样本协方差矩阵 $S_{\text{dim} \times \text{dim}}$ 前 r 个最大特征值; $\hat{e}_1, \hat{e}_2, \dots, \hat{e}_r$ 为相应的正交单位特征向量; \hat{v}_i^2 为 i 时刻特殊因子方差估计值; s_{ii} 为样本协方差矩阵 \mathbf{S} 中第 i 个对角线元素; \hat{a}_{ij} 为第 i 行 j 列的荷载矩阵元素估计值.

基于历史观测样本, 由式(5)~(7)得到因子荷载 \mathbf{A} 和特殊方差阵 $\boldsymbol{\Theta}$ 估计值后, 可计算得到样本对应的公共因子估计向量 $\hat{\mathbf{F}}$ 为

$$\hat{\mathbf{F}} = \hat{\mathbf{A}}' \mathbf{S}^{-1} \mathbf{P} \quad (8)$$

公共因子的维数 r 通常由公共因子的总方差贡献率得到, 当排名靠前的 r 个主成分累计贡献率达到 85% 以上时^[10], 可认为前 r 个公共因子已基本包含气象输入特征的全部信息.

2 短期电力负荷预测方法

LSTMN 预测方法是近年来一种典型的配电网负荷预测方法, 其隐藏层神经元的个数选择步骤繁琐, 同时针对不同的场景, 达到最优预测效果所需要的神经元个数也不相同, 寻优范围大, 耗费时间长. 本文

利用灰狼优化算法 (grey wolf optimization algorithm, GWOA) 全局搜索能力强、收敛速度快的特点, 进行隐藏层神经元的个数优化选取, 可以在保证寻优速度的前提下, 找到一个较好的 LSTMN 模型隐藏层神经元的个数, 提高预测精度.

GWOA 与郊狼优化算法 (coyote optimization algorithm, COA) 同属狼群算法, 但是结构上较 COA 简洁, 实现简易, 效果明朗, 同时较 COA 在算法的收敛速度、运算效率方面更为出色. 郊狼算法独特的搜索方式与结构, 较好地平衡了算法的探索与开发能力. 通过分组更新候选解的方式, 显著提高了获得最优解的概率, 但 COA 由于提出的时间较短, 各方面仍需要完善, 如在处理某些复杂优化问题时存在处理时间长、收敛速度慢的问题. 另外, 在郊狼的成长阶段, 采用贪心算法判断是否保留新解的方式虽然在一定程度上加快了算法收敛速度, 但是也进一步提高了陷入局部最优的概率.

LSTMN 预测模型一次训练所选取的样本数在不同的场景下可以有一定的预估范围, 这样有效回避了 COA 容易陷入局部最优、处理时间长、收敛速度慢的缺点, 突出 COA 强大的局部搜索能力, 因此, 通过将两者的优点结合, 提出了一种 HGWOACO, 进行 LSTMN 预测模型优化, 利用 COA 对 LSTMN 预测模型一次训练的样本数进行优化选取, 以均方根误差 (RMSE) 作为郊狼的适应度, 通过迭代最终选取最优解, 在预估范围内实现全局优化. 在降低复杂程度的同时, 提高运算效率, 提升优化性能.

2.1 长短时记忆网络

LSTMN 是基于循环神经网络 (recurrent neural network, RNN) 的一种改进算法^[11-13]. 它解决了传统 RNN 循环神经网络梯度反转过程中由于逐步缩减而产生的梯度消失的问题, 同时又能够很好地解释预测对象和多个影响因素之间的复杂非线性关系, 适用于对影响因素众多且具有复杂随机性的商业和居民混合负荷进行预测.

LSTMN 由输入门、输出门、遗忘门和记忆细胞组成, 对应网络的输入为 $[X_1, X_2, \dots, X_t]$ 表示为 LSTMN 的以时刻 t 为索引的输入序列. LSTMN 的内部结构如图 1 所示.

LSTMN 结构中存在记忆细胞状态更新, 通过存储单元状态 S_{t-1} 、中间输出 h_{t-1} 和随后的输入 X_t 共同确定需要舍弃旧的信息和内部新状态的更新, 除了 LSTMN 内部状态的更新, LSTMN 结构还定义了输入门 i_t 、输出门 o_t 和遗忘门 f_t . 其中所有节点的公




图 1 LSTMN 的内部结构
Fig.1 Internal structure of LSTMN

式^[16]为

$$f_t = \sigma(W_{f_x} x_t + W_{f_h} h_{t-1} + b_f) \tag{9}$$

$$i_t = \sigma(W_{i_x} x_t + W_{i_h} h_{t-1} + b_i) \tag{10}$$

$$g_t = \tanh(W_{g_x} x_t + W_{g_h} h_{t-1} + b_g) \tag{11}$$

$$o_t = \sigma(W_{o_x} x_t + W_{o_h} h_{t-1} + b_o) \tag{12}$$

$$h_t = \tanh(s_t) \odot o_t \tag{13}$$

$$S_t = g_t \odot i_t + S_{t-1} \odot f_t \tag{14}$$

式中: W_{g_x} 、 W_{g_h} 、 W_{i_x} 、 W_{i_h} 、 W_{f_x} 、 W_{f_h} 、 W_{o_x} 和 W_{o_h} 是网络激活功能相应输入的权重矩阵; \odot 代表逐元素乘法; σ 表示 S 型激活函数.

LSTMN 的训练过程分为前向传播和反向传播两个阶段. 前向传播通过式 (9) ~ 式 (14) 计算出神经元的输出值; 反向传播采用的是基于时间的反向传播 (back propagation through time, BPTT) 算法, 通过反向计算每个神经元的误差, 进而根据误差去优化神经元的权重. 相较于其他模型优化算法, Adam 梯度下降算法具有计算高效平稳、占用内存较少且较好处理稀疏梯度的特点, 因此, 本文用其来优化参数的自适应学习率.

在 LSTMN 模型中, 隐藏层神经元个数选择以及一次训练所选取的样本数是其两个重要参数, 对模型的预测性能有较大的影响.

在隐藏层神经元个数选择方面, 如果隐藏层神经元的数目过少, 模型的训练效果就会很差, 模型的泛化能力弱, 甚至完全没有实用价值; 如果隐藏层神经元的数目过多, 则会在训练过程中出现过拟合的现象, 对实验结果的精确性造成影响.

在一次训练所选取的样本数方面, 样本数 (bath size) 的大小直接影响模型的优化性能, 如果选取了

适当的样本数,梯度下降的方向会更加准确.本文通过采用灰狼郊狼混合优化算法对 LSTMN 进行参数寻优,以提高 LSTMN 预测模型的精度.

2.2 灰狼优化算法

GWOA 是在 2014 年由 Mirgalili 等^[14]提出的一种种群智能优化搜索算法.该算法模拟灰狼群体中的社会等级支配关系以及搜寻、包围、攻击猎物等一系列机制来完成对参数的优化工作.一般而言,GWOA 在全局寻优方面的效果要优于遗传算法(genetic algorithm, GA)、粒子群算法(particle swarm optimization, PSO)等智能优化算法.同时,该算法具有较强的收敛性能,参数简单且易于实现.GWOA 中的灰狼群等级制度如图 2 所示.

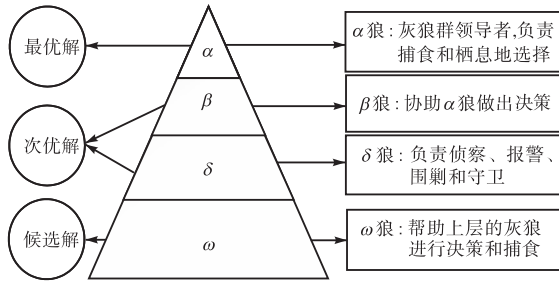


图 2 灰狼群等级制度

Fig.2 Grey wolf group hierarchy

在优化算法的过程中,将 α 狼定义为狼群团队的最优解, β 狼和 δ 狼定义为次优解, ω 狼定义为候选解,捕到的猎物定义为全局最优解.在狼群狩猎过程中, ω 狼将在 α 狼、 β 狼、 δ 狼的带领下不断跟踪并包围猎物,最终捕获猎物.GWOA 的数学模型如下.

(1) 狩猎距离.狼群进行狩猎前,首先要对猎物进行包围,确定灰狼群与猎物之间的距离

$$D = |CX_p(k) - X(k)| \quad (15)$$

式中, k 代表迭代次数; $X_p(k)$ 为猎物的位置向量; $X(k)$ 表示灰狼的位置向量; C 为系数矢量,其表达式为

$$C = 2r_1 \quad (16)$$

式中 r_1 为 $[0, 1]$ 内的随机向量.

(2) 狼群位置的更新.在对猎物进行包围,确定狼群与猎物之间的距离后,需要对灰狼自身的位置进行更新,其更新公式为

$$X(k+1) = X_p(k) - AD \quad (17)$$

式中 A 为收敛因子,表达式为

$$A = 2a r_2 - aI \quad (18)$$

其中, a 随着不断迭代从 2 逐渐减小到 0; r_2 也是 $[0, 1]$ 内的随机向量; I 为单位向量.

(3) 猎物位置的更新.为了从数学模型上模拟狩猎行为,假设 α 狼、 β 狼和 δ 狼为狼群中最靠近猎物的头狼,即为目前得到的 3 个优解,并通过三者的位置迫使剩余狼群 ω 更新位置,即

$$D_\alpha = |C_1 X_\alpha(k) - X(k)| \quad (19)$$

$$D_\beta = |C_2 X_\beta(k) - X(k)| \quad (20)$$

$$D_\delta = |C_3 X_\delta(k) - X(k)| \quad (21)$$

$$X_1 = X_\alpha - A_1 D_\alpha \quad (22)$$

$$X_2 = X_\beta - A_2 D_\beta \quad (23)$$

$$X_3 = X_\delta - A_3 D_\delta \quad (24)$$

$$X_p(t+1) = (X_1 + X_2 + X_3)/3 \quad (25)$$

式中, D_α 、 D_β 、 D_δ 分别表示 α 狼、 β 狼、 δ 狼与猎物之间的距离; C_1 、 C_2 、 C_3 与 A_1 、 A_2 、 A_3 是关于 α 、 β 、 δ 的随机向量; $X_p(k+1)$ 是当前解的位置.

2.3 郊狼优化算法

COA 是由 Pierezan 等^[15]在 2018 年提出的一种新型智能算法.COA 模拟郊狼的成长、生老病死、被驱逐和被接纳等一系列社会活动.在结构上采用多组搜索框架,具有极强的全局探索能力,同时组内采用的引导新生郊狼的成长方式对局部探索能力有了一定的加强,能够更好地解决复杂优化问题.COA 包括初始化狼群和随机分组、组内郊狼成长、郊狼生与死、被组群驱逐接纳等主要步骤.

(1) 初始化狼群并随机分组.首先初始化狼群组数,设置郊狼群的规模、郊狼组数 N_p 、组内郊狼个数 N_c 以及最大迭代次数 MaxDT,其中初始化公式为

$$\text{soc}_{c,j} = \text{lb}_j + r(\text{ub}_j - \text{lb}_j) \quad (26)$$

式中: $\text{soc}_{c,j}$ 为第 p 组第 c 个郊狼的 j 维社会状态因子; lb_j 、 ub_j 分别表示第 j 维社会状态因子的下限和上限.

然后,再对郊狼的社会适应度 fit_c 进行计算,即

$$\text{fit}_c = f(\text{soc}_c) \quad (27)$$

式中 $f(\cdot)$ 为适应度函数.

(2) 组内郊狼成长.在 COA 中,本文确定最优狼 alpha、中值郊狼 cult 和组内其余两只郊狼 c_1 和 c_2 . δ_1 、 δ_2 为最优狼 alpha 与组内其余两只狼的差异,组内的郊狼在差异的影响下成长.成长方式如下所示:

$$\text{cult}_j = \begin{cases} O_{(N_c+1)/2,j} & N_c \text{ 是奇数} \\ (O_{N_c/2,j} + O_{N_c/2+1,j})/2 & N_c \text{ 是偶数} \end{cases} \quad (28)$$

$$\delta_1 = \text{alpha} - \text{soc}_{c_1} \quad (29)$$

$$\delta_2 = \text{cult} - \text{soc}_{c_2} \quad (30)$$

$$\text{new_soc}_c = \text{soc}_c + r_3\delta_1 + r_4\delta_2 \quad (31)$$

$$\text{new_fit}_c = f(\text{new_soc}_c) \quad (32)$$

式中: r_3 、 r_4 为 $[0, 1]$ 内的随机数; new_fit_c 为对第 c 头郊狼进行评估得到的新社会适应度值。

最后通过迭代贪心算法迭代, 选取最优狼

$$\text{soc} = \begin{cases} \text{new_soc}_c & \text{new_fit}_c < \text{fit}_c \\ \text{soc}_c & \text{其他} \end{cases} \quad (33)$$

(3) 郊狼生与死. 在 COA 中, 郊狼的重要社会活动是郊狼的出生与死亡. 新郊狼的出生来自于父母郊狼的遗传和环境的变异, 新郊狼出生后对其社会适应度进行评估. 若组内只有一只郊狼比年幼郊狼的社会适应度低, 则淘汰社会适应能力差的郊狼, 幼狼得以存活; 若组内存在多个社会适应度低于幼狼的郊狼, 则从中选取年龄最大的那只淘汰, 如果存在多个年龄最大的郊狼, 则其中最差的郊狼淘汰, 幼狼存活; 若幼狼的社会适应度低于全组郊狼, 则幼狼淘汰. 一系列社会活动的模型为

$$\text{pup}_j = \begin{cases} \text{soc}_{\alpha, j} & r_j < P_s \text{ 或 } j = j_1 \\ \text{soc}_{\alpha, j} & r_j \geq P_s + P_a \text{ 或 } j = j_2 \\ R_j & \text{其他} \end{cases} \quad (34)$$

$$P_s = 1/D \quad (35)$$

$$P_a = (1 - P_s)/2 \quad (36)$$

式中: pup_j 为幼狼; P_s 为分散概率; P_a 为关联概率; R_j 为 j 维范围中随机产生的变异值。

(4) 被组群驱逐或接纳. 为了使 COA 各组郊狼之间能够进行一定的信息交流, 以确保狼群的多样

性, 采用概率 P_c 来模拟郊狼被驱逐和被接纳的过程, 其公式为

$$P_c = 0.005N_c^2 \quad (37)$$

2.4 预测模型的建立与算法流程

本文针对商业和居民的混合配电网短期负荷预测制约因素多、强随机性的特点, 提出的基于 HGWOACOALSTMN 的配电网短期电力负荷预测模型主要步骤如下。

(1) 数据的分析与预处理。

(2) 采用 MIC 和 FA 算法对气象输入特征中的主要信息进行提取, 实现输入特征的筛选与降维。

(3) 选取相似日构成模型训练样本; 相似日日平均温度与预测日相差 $\pm 3^\circ\text{C}$ 以内且日期类型(休息日、工作日)与预测日一致的样本组合成相似日集。

(4) 训练样本集. 将训练样本集选取预测日的负荷数据作为测试集, 其余部分按照对应数据集的比例作为训练集, 以 LSTMN 模型的均方根误差作为 HGWOACOALSTMN 的适应度函数, 对 LSTMN 的参数进行寻优, 首先郊狼优化算法先对 LSTMN 模型一次训练所选取的样本数进行优化选取, 然后灰狼优化算法对 LSTMN 模型的隐藏层神经元的个数进行优化选取, 实现 LSTMN 模型两类参数的优化。

(5) 输入训练样本集对最优参数 LSTMN 短期负荷预测模型进行离线训练, 得到基于 HGWOACOALSTMN 的短期电力负荷预测模型. 最后将预测日的输入特征数据输入预测模型中, 得到预测日各个时刻的负荷预测值. 算法流程如图 3 所示。

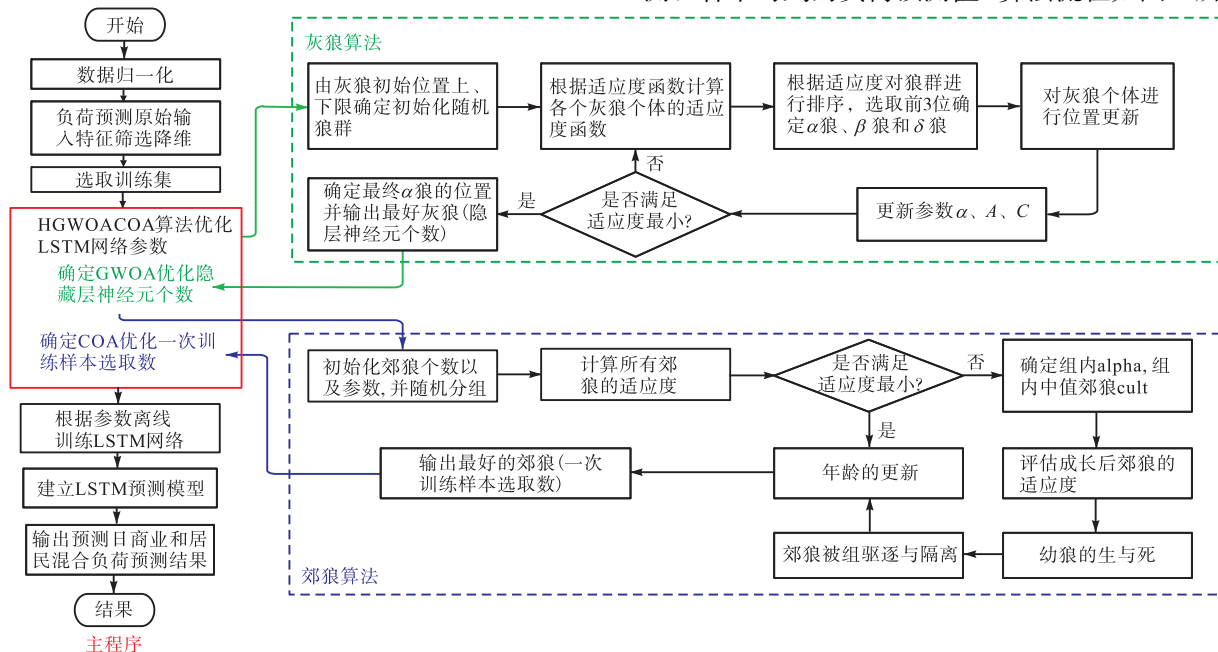


图 3 基于 HGWOACOALSTMN 的短期电力负荷预测流程

Fig.3 Flow chart of short-term power load forecast based on HGWOACOALSTMN

3 短期负荷预测实例及结果分析

本文以配电网某区域(包含一座商业综合体和两个居民小区)2016 年 12 月 1 日至 2017 年 11 月 30 日的负荷数据为例验证本文方法的有效性,其中负荷数据采集的时间间隔为 1 h.

3.1 误差指标

本文采用平均绝对百分比误差(MAPE)、均方根误差(RMSE)来衡量预测模型的准确性与鲁棒性,计算方法分别如式(38)、式(39)所示. MAPE 表示预测结果较实际结果的数据偏移程度,计算 MAPE 可以评价模型预测误差的波动程度;RMSE 对误差结果中极大或极小的值反应敏感,计算 RMSE 可以检验模型的拟合水平和稳定性.

$$E_M = \frac{1}{n} \sum_{t=1}^n \frac{|\hat{y}_t - \hat{y}_{sr}|}{\hat{y}_{sr}} \times 100\% \quad (38)$$

$$E_R = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{y}_t - \hat{y}_{sr})^2} \quad (39)$$

式中: E_M 和 E_R 分别代表误差评价指标 MAPE 和 RMSE; n 为预测时刻的个数; \hat{y}_t 为 t 时刻的预测负荷值; \hat{y}_{sr} 为 t 时刻的实际负荷值.

3.2 数据归一化

为了提升模型的收敛速度,保证模型的精度,对历史负荷和输入特征数据进行归一化处理,按式(40)将输入特征数据映射到[1, -1]区间上.

$$Z^* = \frac{z - \frac{z_{\max} + z_{\min}}{2}}{\frac{z_{\max} - z_{\min}}{2}} \quad (40)$$

式中 z_{\max} 、 z_{\min} 分别为变量的极大值与极小值.

3.3 原始输入特征的筛选与降维

本文首先采用最大信息系数(MIC)法对气象输入特征进行筛选. 文献[10]认为在显著性水平为 0.001 时, $MIC = 0.28$, 即当 $MIC > 0.28$ 时, 可认为外部影响因素与负荷具有显著性关系. 通过 MIC 对表 1 列出的 9 项 20 种原始输入特征与商业和居民混合负荷的相关性进行分析, 可得相对湿度、风速与降水量的 MIC 相关性值分别为 0.13、0.11 和 0.09, 均小于 MIC 规定的阈值 0.28, 因此, 可将相对湿度、风速与降水量这 3 项输入特征剔除.

根据因子得分分数可构成公因子的线性函数方程. 可以得出: 从气象输入特征中提取出公因子, 公因子的方差贡献率为 94.079% (> 85%), 说明该公因子已基本包含 10 项气象输入特征的全部有效信息,

见表 2.

表 2 气象输入特征的因子分析结果
Tab.2 Factor analysis results of meteorological input characteristics

指标	公因子得分
预测日 t 时刻预测温度	0.107
预测日 $t-1$ 时刻预测温度	0.107
预测日 $t-2$ 时刻预测温度	0.107
预测日 $t-3$ 时刻预测温度	0.106
前 1 天 t 时刻温度	0.105
前 2 天 t 时刻温度	0.104
前 3 天 t 时刻温度	0.103
预测日平均预测温度	0.105
预测日 t 时刻预测气压	0.098
预测日日照时长	0.099

3.4 预测结果分析

为验证本文提出的面向商业与居民混合的配电网电力负荷预测模型的精确性, 首先按照图 3 所示流程选取春季训练集, 并对传统 LSTMN 模型与 HGWOACOA-LSTMN 模型的预测流程及结果进行对比分析. 优化算法的参数设置为: 在 COA 中郊狼组数 $N_p = 5$, 组内郊狼个数 $N_e = 3$, 最大迭代次数 $MaxDT = 3$. 在灰狼优化算法中: 灰狼数 $N = 5$, 迭代次数 $T_{\max} = 5$.

优化前 LSTMN 模型的参数与优化后 LSTMN 模型的参数如表 3 所示, 模型训练过程 loss 曲线如图 4、图 5 所示, 通过 loss 曲线可以较为直观地反映出该模型训练的情况, 侧面反映参数优化前后模型的性能优劣, 负荷实际与预测值如表 4 所示, 两模型预测结果中实际值与预测值误差对比如图 6 所示.

表 3 传统 LSTMN 与 HGWOACOA-LSTMN 模型参数选择

Tab.3 Parameter selection of traditional LSTMN model and HGWOACOA-LSTMN model

模型	隐层神经元的个数	一次训练样本数	训练次数
传统 LSTMN	150	2	250
HGWOACOA-LSTMN	6	10	250




图 4 传统 LSTMN 模型训练过程 loss 曲线

Fig.4 Training process loss curves of traditional LSTMN model




图 5 HGWOACOA-LSTMN 模型训练过程 loss 曲线

Fig.5 Training process loss curves of HGWOACOA-LSTMN model

表 4 传统 LSTMN 与 HGWOACOA-LSTMN 模型预测负荷比较

Tab.4 Comparison of traditional LSTMN model and HGWOACOA-LSTMN model for load forecasting

时刻	实际负荷值/ kW	预测负荷值/kW	
		传统 LSTMN	HGWOACOA-LSTMN
00:00	511.438	495.823	501.935
01:00	463.748	459.678	457.773
02:00	428.264	458.306	443.968
03:00	428.156	468.876	454.180
04:00	418.404	451.403	433.535
05:00	400.628	454.363	439.374
06:00	406.380	448.457	432.097
07:00	524.500	511.001	513.871
08:00	550.452	566.834	577.538
09:00	919.532	925.863	953.381
10:00	1 875.022	1 815.685	1 859.137
11:00	1 927.020	1 944.326	1 949.972
12:00	2 010.368	1 969.387	1 988.031
13:00	1 902.156	1 993.252	2 016.181
14:00	1 862.474	1 983.944	2 004.578
15:00	1 892.336	1 958.642	1 971.914
16:00	1 881.878	1 959.675	1 973.171
17:00	1 922.140	1 920.554	1 923.440
18:00	2 020.932	1 964.631	1 981.044
19:00	2 249.104	2 083.328	2 141.271
20:00	2 216.118	2 084.402	2 144.465
21:00	2 131.290	2 120.173	2 143.261
22:00	809.200	934.867	883.553
23:00	532.284	531.595	534.174

通过分析上述图表,可以得出以下结论.

(1) 从图4、图5 可知,当训练次数设置为 250 次

时,两模型训练集和测试集损失值曲线不断下降直至趋于平稳,表明两模型的训练过程良好,但 HGWOACOA-LSTMN 模型较传统 LSTMN 模型在训练集 loss 与测试集 loss 之间的偏差更小,同时曲线变化更为平稳,拟合程度更好,说明把 GWOA 以及 COA 寻优得到的参数输入模型后,模型训练效果得到了改善.

(2) 由图 6 可以看出,HGWOACOA-LSTMN 模型的预测误差比传统 LSTMN 模型有了明显的降低,而且 HGWOACOA-LSTMN 模型能够把大部分的预测误差控制在 6% 以内.




图 6 传统 LSTMN 与 HGWOACOA-LSTMN 模型预测误差

Fig.6 Prediction errors of traditional LSTMN model and HGWOACOA-LSTMN model

(3) 由图 6 和表 4 可以看到,在部分时刻,传统 LSTMN 模型的实际负荷与预测负荷偏差较大,预测精度难以保证. 相比于传统 LSTMN 模型,本文提出的模型鲁棒性更好,更加符合短时电力负荷预测精准与稳定的要求.

为了验证本文提出的面向商业与居民混合的配电网电力负荷预测模型的精确性,分别选取春、夏、秋、冬 4 个季节进行预测,与基于 RBFNN 算法、传统 LSTMN 算法的预测模型进行实验对比,其中,RBFNN 算法的优化参数光滑因子采用网格搜索法获得,预测结果如表 5 所示. 同时为了进一步验证模型的泛化性,保证模型在处理多段复杂时间序列负荷数据时的准确性,依次选取冬季训练集中的某几个典型日作为预测数据,结果如图 7 所示.

表 5 不同季节 3 种预测模型精度比较


Tab.5 Comparison of the accuracy of three prediction models in different seasons

模型	春季		夏季		秋季		冬季		四季平均值	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
传统 LSTMN	5.35	68.95	6.39	125.11	4.29	78.00	4.06	87.01	5.02	89.77
HGWOACOA-LSTMN	3.86	60.42	5.78	92.77	3.32	66.98	2.44	56.51	4.03	69.17
RBFNN	8.39	103.61	9.91	96.01	6.44	71.64	5.13	71.64	7.47	85.73


由实验结果可以得到如下结论.

(1) 总体来看,由表 5 可知,HGWOACOA-


LSTMN 的 MAPE 和 RMSE 四季平均值均小于对比模型. 在夏冬两季相较于 LSTMN 和 RBFNN 来说同



(a) 1 个典型日下模型相对误差



(b) 2 个典型日下模型相对误差



(c) 3 个典型日下模型相对误差

图 7 不同个数典型日下预测误差

Fig.7 Typical daytime prediction errors with different numbers

样误差较小,在春秋两季,传统 LSTMN 模型与 HGWOACOA-LSTMN 模型的 RMSE 无明显差异,但 MAPE 高了很多,说明传统 LSTMN 模型的鲁棒性相对较弱.同时,HGWOACOA-LSTMN 模型的

MAPE 均值较其余两种模型分别降低了 0.99% 和 3.44%;RMSE 的均值为 69.17,较传统的 LSTMN 模型和 RBFNN 分别降低了 20.60 和 16.56,表明本文提出的短时电力负荷 HGWOACOA-LSTMN 预测模型在预测过程中具有较强的精确度与鲁棒性,该模型能更好地拟合商业和居民混合负荷与输入特征之间的复杂非线性关系,具有较强的抗干扰能力.

(2) 由图 7 可以看到,在连续日的预测中,HGWOACOA-LSTMN 模型能够把绝大部分误差控制在 10% 以内,且负荷预测误差较为稳定,表明 HGWOACOA-LSTMN 短时负荷预测模型在处理复杂时间序列预测问题时具有极强的泛化性.

3.5 优化方法对比分析

为了进一步验证 HGWOACOA-LSTMN 模型的优化效果,本文选取了春、冬两季商业和居民混合负荷历史数据,分别将 GWOA、COA、HGWOACOA 共 3 种模型对 LSTMN 进行参数优化,比较其优化后 LSTMN 模型的精度与速度,参数选择如表 6 所示,其中 COA-LSTMN 代表 LSTMN 模型只进行郊狼优化算法对一次训练选取样本数参数优化,GWOA-LSTMN 代表 LSTMN 模型代表只进行灰狼优化算法对隐层神经元个数参数优化,运算结果如表 7 所示.

表 6 不同模型的优化参数选择

Tab.6 Optimization parameter selection of different models

季节	模型	参数	
		隐层神经元个数	一次训练选取样本数
春季 Epoch = 250	LSTMN	150	2
	GWOA-LSTMN	6	2
	COA-LSTMN	150	10
	HGWOACOA	6	10
冬季 Epoch = 150	LSTMN	150	8
	GWOA-LSTMN	20	8
	COA-LSTMN	150	4
	HGWOACOA	20	4

表 7 不同模型的优化效果对比

Tab.7 Optimization effect comparison of different models

模型	春季			冬季		
	RMSE	MAPE	模型运行时间/s	RMSE	MAPE	模型运行时间/s
GWOA-LSTMN	60.71	3.86	44.52	80.33	3.73	23.08
COA-LSTMN	52.62	3.55	24.30	57.42	2.74	143.25
HGWOACOA	55.62	3.62	11.49	57.73	2.78	42.52
LSTMN	67.34	4.75	79.17	87.01	4.06	135.62

由表 7 中春季和冬季的实验结果可知,只通过 GWO 对隐层神经元个数优化,评估指标 RMSE、MAPE 变化范围很小,但在运行时间上较传统

LSTMN 负荷预测模型分别减少了 34.65 s 和 112.54 s. 只通过 COA 对 LSTMN 一次训练选取样本数进行参数优化,优化后的预测模型较传统 LSTMN

负荷预测模型的 RMSE、MAPE 显著下降,但在运行时间上较传统 LSTMN 分别减少了 54.87 s 与 7.63 s,这表明只通过 COA 进行一次训练选取样本数参数优化模型的运行速度虽然有所提高,但具有一定的不确定性,稳定性较差。

由表 7 中还可以看到,通过将 GWOA、COA 算法结合对 LSTMN 进行参数优化,较传统 LSTMN 负荷预测模型 RMSE、MAPE、模型的运行时间都有着显著提升。因此,相对于 GWOA、COA 算法单方面的参数优化,HGWOACO 优化算法在考虑模型的预测精度的同时,保证了模型的运行速度,显著提高了负荷预测效率和准确性。

4 结 论

(1) 考虑负荷历史数据、气象因素和日期类型 3 方面构建负荷预测输入特征,分别采用 MIC 和 FA 方法对气象输入特征进行筛选与降维,提取出含有原始信息 90% 以上的较少变量,在保证精度的前提下,简化了模型输入特征的维数。

(2) HGWOACO-LSTMN 模型能较好地拟合商业和居民混合的配电网负荷与输入特征之间的复杂非线性关系,在处理时间序列问题时较其他模型更加具优势。利用 GWOA、COA 各自的优势分别对隐层神经元个数与一次训练选取样本数进行优化,弥补参数选择时的困难,保证预测精度的同时进一步提升运行效率与其拟合回归的能力。

(3) 本文模型充分挖掘历史负荷与气象因素中的有效信息,具有较好的鲁棒性及较高的预测精度,可为今后包含商业和居民混合的配电网短期电力负荷预测研究提供借鉴。

参考文献:

- [1] 史佳琪, 张建华. 基于多模型融合 Stacking 集成学习方式的负荷预测方法[J]. 中国电机工程学报, 2019, 39(14): 4032-4041.
Shi Jiaqi, Zhang Jianhua. Load forecasting based on multi-model by Stacking ensemble learning[J]. Proceedings of the CSEE, 2019, 39(14): 4032-4041 (in Chinese).
- [2] 杨 阳, 练 冲, 马 超. 晴天光伏发电功率的日内变化规律及预测方法研究[J]. 天津大学学报: 自然科学与工程技术版, 2020, 53(6): 565-572.
Yang Yang, Lian Chong, Ma Chao. Daily variation laws and prediction methods in photovoltaic power generation on sunny days[J]. Journal of Tianjin University: Science and Technology, 2020, 53(6): 565-572 (in Chinese).
- [3] 陆继翔, 张琪培, 杨志宏, 等. 基于 CNN-LSTM 混合神经网络模型的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(8): 131-137.
Lu Jixiang, Zhang Qipei, Yang Zhihong, et al. Short-term load forecasting method based on CNN-LSTM hybrid neural network model[J]. Automation of Electric Power Systems, 2019, 43(8): 131-137 (in Chinese).
- [4] 彭 文, 王金睿, 尹山青. 电力市场中基于 Attention-LSTM 的短期负荷预测模型[J]. 电网技术, 2019, 43(5): 1745-1751.
Peng Wen, Wang Jinrui, Yin Shanqing. Short-term load forecasting model based on Attention-LSTM in electricity market[J]. Power System Technology, 2019, 43(5): 1745-1751 (in Chinese).
- [5] 张素香, 赵丙镇, 王风雨, 等. 海量数据下的电力负荷短期预测[J]. 中国电机工程学报, 2015, 35(1): 2805-2813.
Zhang Suxiang, Zhao Bingzhen, Wang Fengyu, et al. Short-term power load forecasting based on big data [J]. Proceedings of the CSEE, 2015, 35(1): 2805-2813 (in Chinese).
- [6] Chau Tat Kei, Yu Samson Shenglong, Fernando Tyrone, et al. A load-forecasting-based adaptive parameter optimization strategy of STATCOM using ANNs for enhancement of LFOD in power systems[J]. IEEE Transactions on Industrial Informatics, 2018, 14(6): 2463-2472.
- [7] 杨屹洲, 方瑞明, 黄文权, 等. 应用小波变换和支持向量机的商业电力负荷预测[J]. 华侨大学学报: 自然科学版, 2015, 36(2): 142-146.
Yang Yizhou, Fang Ruiming, Huang Wenquan, et al. Commercial power load forecasting using wavelet transform and SVM[J]. Journal of Huaqiao University: Natural Science, 2015, 36(2): 142-146 (in Chinese).
- [8] 李冬辉, 尹海燕, 郑博文. 基于 MFOA-GRNN 模型的年电力负荷预测[J]. 电网技术, 2018, 42(2): 585-590.
Li Donghui, Yin Haiyan, Zheng Bowen. An annual

- load forecasting model based on generalized regression neural network with multi-swarm fruit fly optimization algorithm[J]. *Power System Technology*, 2018, 42(2): 585-590 (in Chinese).
- [9] 蒋杭进. 最大信息系数及其在脑网络分析中的应用[D]. 武汉, 中国科学院研究生院(武汉物理与数学研究所), 2013.
- Jiang Hangjin. Maximal Information Coefficient and Its Application to Brain Network Analysis[D]. Wuhan: Graduate School of Chinese Academy of Sciences (Wuhan Institute of Physics and Mathematics), 2013 (in Chinese).
- [10] 张冠英, 姜一鸣, 葛磊蛟, 等. 经济新常态下基于 Verhulst-SVM 的中长期负荷预测模型[J]. *电测与仪表*, 2019, 56(1): 102-107.
- Zhang Guanying, Xian Yiming, Ge Leijiao, et al. Medium and long-term load forecasting model based on Verhulst-SVM under new normal economy[J]. *Electrical Measurement & Instrumentation*, 2019, 56(1): 102-107 (in Chinese).
- [11] Hochreiter S, Schmidhuber J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [12] Zhang Y Z, Xiong R, He H W, et al. Long short-term memory recurrent neural network for remaining useful life prediction of lithium-ion batteries[J]. *IEEE Transactions on Vehicular Technology*, 2018, 67(7): 5695-5705.
- [13] Peng T M, Hubele N F, Karady G G. Advancement in the application of neural networks for short-term load forecasting[J]. *IEEE Transactions on Power Systems*, 1992, 7(1): 250-257.
- [14] Mirjalili S, Mirjalili S.M, Lewis A. Grey wolf optimizer[J]. *Advances in Engineering Software*, 2014, 69: 46-61.
- [15] Pierezan J, Coelho L S. Coyote optimization algorithm: A new metaheuristic for global optimization problems[C]// 2018 IEEE Congress on Evolutionary Computation (CEC). Rio de Janeiro, Brazil, 2018: 2633-2640.

(责任编辑: 樊素英)