

基于 HDBO-LSTM 的短期电力负荷预测方法

蔡春雷, 刘 微, 任腾腾

(沈阳理工大学 信息科学与工程学院, 沈阳 110159)

摘要: 为提高电力系统短期电力负荷预测的准确性, 提出一种基于混合蜣螂优化 (hybrid dung beetle optimization, HDBO) 算法优化长短期记忆 (long short-term memory, LSTM) 网络的预测模型 (HDBO-LSTM)。首先, 为克服原始蜣螂优化 (dung beetle optimization, DBO) 算法全局搜索能力较弱且易陷入局部最优的问题, 在原始 DBO 算法的基础上引入随机对立学习策略、 Harris 鹰优化算法、逐维高斯变异策略和动态处理机制, 以此形成 HDBO 算法, 增强算法的搜索能力和收敛速度, 并通过 10 个基准函数的对比实验验证 HDBO 算法的搜索性能; 其次, 采用 HDBO 算法优化 LSTM 网络的超参数, 以减小随机超参数对负荷预测精度的影响。使用电工数学建模竞赛的电力负荷数据集对模型进行评估, 结果显示, 在数据集内随机选取的七天预测任务中, HDBO-LSTM 模型的均方根误差 (RMSE)、平均绝对百分比误差 (MAPE)、平均绝对误差 (MAE) 和变异系数 (COV) 较原始 LSTM 模型分别降低了 22.38%、16.33%、19.16% 和 22.52%, 该模型能够有效提升短期电力负荷预测的准确性。

关键词: 电力负荷预测; 蜣螂优化算法; 长短期记忆网络

中图分类号: TM715

文献标志码: A DOI: 10.3969/j.issn.1003-1251.2025.05.004

Short-term Power Load Forecasting Method Based on HDBO-LSTM

CAI Chunlei, LIU Wei, REN Tengting

(Shenyang Ligong University, Shenyang 110159, China)

Abstract: To improve the accuracy of short-term power load forecasting in the power system, a prediction model (HDBO-LSTM) based on hybrid dung beetle optimization (HDBO) algorithm to optimize long short-term memory (LSTM) network is proposed. Firstly, to solve the problem of weak global search ability and susceptibility to local optima in the original dung beetle optimization (DBO) algorithm, the HDBO algorithm is formed by introducing random opposition learning strategy, Harris hawks optimization algorithm, dimension-by-dimension Gaussian variation strategy, and dynamic boundary handling mechanism based on the original DBO algorithm. This enhances the search ability and convergence speed of the algorithm, and the search performance of the HDBO algorithm is verified through comparative experiments with 10 benchmark functions. Secondly, the HDBO algorithm is used to optimize the hyperparameters of the LSTM network, in order to reduce the impact of random hyperparameter selection on the accuracy of load forecasting. Finally, the model is evaluated by using the power load dataset from the electrical mathematics modeling competition. The results show that compared to the original LSTM model, the HDBO-LSTM model reduces root mean square error (RMSE), mean absolute percentage error (MAPE), mean absolute

error (MAE), and coefficient of variation (COV) by 22.38%, 16.33%, 19.16%, and 22.52%, respectively, in the randomly selected seven day prediction task within the dataset. This model can effectively improve the accuracy of short-term power load forecasting.

Key words: power load forecasting; dung beetle optimization algorithm; long short-term memory network

电力负荷预测是电力能源管理系统的重要组成部分,可为电网调度、控制与运行提供必要的指导。例如,依据负荷预测数据,调度人员可提前灵活调控发电机出力、合理投用无功补偿设备,维持系统电压与频率稳定,并优先启用低成本机组,有效降低发电成本。目前,元启发式算法在负荷预测领域应用最为广泛,包括经典的粒子群优化(particle swarm optimization, PSO)算法^[1]、鲸鱼优化算法(whale optimization algorithm, WOA)^[2]和麻雀搜索算法(sparrow search algorithm, SSA)^[3]等。这些基于群体的优化算法通过模拟自然界中的生物行为来搜索问题的最优解,但普遍存在局部最优、收敛速度慢、对参数敏感等局限性,尤其在处理高维和多模态问题时更难以实现全局优化并易陷入局部最优解。

长短期记忆(long short-term memory, LSTM)网络用于电力负荷预测的效果良好,但其超参数的选择对预测精度的影响较大^[4]。因此,许多学者选择将元启发式优化算法与 LSTM 结合,通过不同算法迭代优化 LSTM 网络的超参数,以改善人为经验选择参数导致预测结果不佳的问题。文献[5]采用 SSA 优化 LSTM 网络超参数,提出了基于 SSA-LSTM 的短期电力负荷预测模型,验证实验结果表明, LSTM 模型在性能上优于传统的反向传播(back propagation, BP)模型, SSA-LSTM 模型优于未经优化的 LSTM 模型及采用 PSO 算法优化 LSTM 的对比模型;文献[6]采用布谷鸟搜索(cuckoo search, CS)算法优化 LSTM 网络超参数,构建了 CS-LSTM 负荷预测模型,该模型在均方根误差(RMSE)、平均绝对百分比误差(MAPE)和平均绝对误差(MAE)等测试指标上均优于 PSO 算法优化 LSTM 模型(PSO-LSTM)及遗传算法(GA)优化 LSTM 模型(GA-LSTM);文献[7]将蜣螂优化(dung beetle optimization, DBO)算法与 LSTM 网络结合,用于短期电力负荷预测,通过优化超参数,改进后模型的 RMSE 和 MAPE 相较于原 LSTM 模型分别降低了 12.74% 和 15.95%,验证了 DBO 算法在优化 LSTM 超参数中的优越性。

原始 DBO 算法存在全局探索与局部开发能

力失衡以及容易陷入局部最优的问题^[8],本文通过引入随机对立学习策略、融合哈里斯鹰优化(Harris hawks optimizer, HHO)算法、采用逐维高斯变异策略和动态处理机制,对 DBO 算法进行改进,形成混合蜣螂优化(hybrid dung beetle optimization, HDBO)算法,并通过基准测试函数与其他多种优化算法对比,验证本文改进算法的有效性。为减小 LSTM 网络超参数的选择对预测结果的影响,使用 HDBO 算法优化 LSTM 网络的超参数,构建一种基于 HDBO 算法优化 LSTM 的短期电力负荷预测模型(HDBO-LSTM)。采用电工数学建模竞赛数据集进行实验,验证本文提出模型的性能。

1 基本算法

1.1 LSTM 网络

LSTM 网络的提出解决了循环神经网络(recurrent neural network, RNN)中存在的梯度爆炸问题,其作为 RNN 的改进版,能够高效捕捉并处理序列数据中的长期依赖关系^[9],在处理时间序列数据时具有独特的优势,尤其适用于电力负荷预测一类的时序预测任务。

LSTM 的核心部分包括记忆单元、输入门、遗忘门和输出门,分别控制信息的存储、输入、管理和输出,从而增强系统的长期记忆能力。LSTM 的内部结构如图 1 所示。图中: C_{t-1} 和 C_t 分别表示上一时间步($t-1$)和当前时间步(t)的细胞状态; h_{t-1} 和 h_t 分别表示上一时间步和当前时间步的隐藏状态; X_t 是当前时间步的输入; f_t 表示遗忘门在当前时间步的值; W_f 和 b_f 分别是遗忘门的权重矩阵和偏置项; σ 表示 Sigmoid 激活函数; i_t 表示输入门在当前时间步的值; W_i 和 b_i 分别是输入门的权重矩阵和偏置项; W_c 和 b_c 分别是记忆单元的权重矩阵和偏置项; o_t 为输出门在当前时间步的值; W_o 和 b_o 分别是输出门的权重矩阵和偏置项; \tanh 为双曲正切激活函数。

1.2 DBO 算法

DBO 算法是一种新型的群智能优化方法,灵感源于自然界中蜣螂的复杂社会行为模式^[10]。该算法将蜣螂种群划分为滚球蜣螂、繁殖蜣螂、小

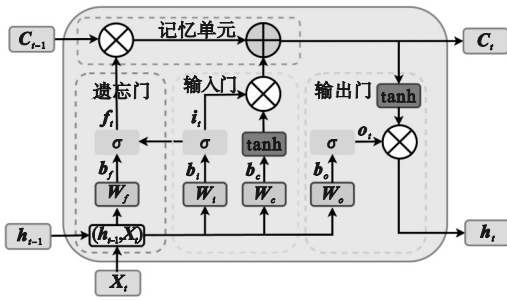


图 1 LSTM 的内部结构

Fig.1 Internal structure of LSTM

蛭螂和偷窃蛭螂四类代理,蛭螂种群代表潜在的解决方案,各种群蛭螂协同工作,随着迭代过程的不断推进,逐步收敛至问题的最优解区域,从而实现对复杂问题的优化求解。

2 DBO 算法的改进及性能测试

本文对 DBO 算法进行改进,引入随机对立学习策略,融合 HHO 算法,采用逐维高斯变异策略和动态处理机制,提出 HDBO 算法,并在 10 个基准测试函数上与其他四种算法进行性能比较。

2.1 基于随机对立学习的策略

为进一步提高 DBO 算法的全局搜索能力,并平衡局部开发与全局探索的能力,本文在 DBO 算法中引入随机对立学习策略^[11]更新种群。该策略的基本思想是通过对比学习来加速算法的收敛,同时避免陷入局部最优,其数学描述为

$$\mathbf{X}_{\text{rand}} = \mathbf{L}_B + \mathbf{U}_B - r_0 \times \mathbf{X} \quad (1)$$

式中: \mathbf{X} 为当前解; \mathbf{X}_{rand} 为随机对立解; r_0 为 $[0, 1]$ 之间的随机数; \mathbf{L}_B 和 \mathbf{U}_B 分别为上、下边界。

在每次迭代中选择随机对立学习策略更新种群位置,以反映个体优劣程度的种群适应度作为评估种群个体与优化目标契合程度的指标。完成更新后,与初始种群的适应度值进行比较,使用贪婪算法选择适应度更高的前 N 个个体构建新种群。

2.2 融合哈里斯鹰优化算法

在提升 DBO 全局搜索能力的基础上,选择 HHO 算法中的探索阶段更新公式,并集成 Levy 飞行策略更新滚球蛭螂的位置。在 HHO 的探索阶段,鹰群成员通过模拟寻找猎物的策略进行大范围搜索,这种策略特别适合用来引导滚球蛭螂算法在多峰、高维问题中进行全局优化,从而避免算法陷入局部最优解。Levy 飞行策略通过引入较大步长的随机搜索,模拟随机游走行为。结合

Levy 飞行策略后,HHO 的更新策略不仅提升了算法的全局搜索能力,还能有效引导 Levy 飞行的跳跃性。Levy 飞行的步长和方向由 HHO 的更新策略控制,使滚球蛭螂算法能够在全局范围内进行跳跃性探索,并保持较好的搜索效率和多样性。滚动更新公式为

$$\mathbf{X}(t+1) = \begin{cases} \text{Levy} \oplus \mathbf{X}_{\text{rand}}(t) - \\ r_{11} |\mathbf{X}_{\text{rand}}(t) - 2r_{22} \mathbf{X}(t)|, q_1 \geq 0.5 \\ \mathbf{X}_b - \mathbf{X}_m(t) - \\ r_{33} [\mathbf{L}_B + r_{44} (\mathbf{U}_B - \mathbf{L}_B)], q_1 < 0.5 \end{cases} \quad (2)$$

式中: $\mathbf{X}(t)$ 与 $\mathbf{X}(t+1)$ 分别表示蛭螂在第 t 次和 $t+1$ 次迭代时的位置; r_{11} 、 r_{22} 、 r_{33} 、 r_{44} 、 q_1 为随机数因子,取值在 $(0, 1)$ 之间; $\mathbf{X}_{\text{rand}}(t)$ 为种群中随机选择的蛭螂位置; $\mathbf{X}_m(t)$ 表示种群在当前迭代中的平均位置; \oplus 表示逐点成对相乘; \mathbf{X}_b 表示当前群体中选取的最优位置;Levy 表示 Levy 飞行策略。Levy 分布公式为

$$\mathbf{X}(t+1) = \mathbf{X}(t) + \alpha \oplus \text{Levy} \quad (3)$$

式中 α 为步进因子,通常取为 0.01。Levy 飞行步长的计算公式为

$$\begin{cases} s_k = \frac{\mu}{|v|^{\frac{1}{\beta}}}, k = 1, 2, \dots, n \\ \mu \sim N(0, \sigma^2), v \sim N(0, 1) \\ \sigma = \left[\frac{\Gamma(1+\beta) \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left(\frac{1+\beta}{2}\right) \times \beta \times 2^{\frac{\beta-1}{2}}} \right]^{\frac{1}{\beta}} \end{cases} \quad (4)$$

式中: s_k 为步长; k 是索引变量; β 是步长分布的形状参数; $\Gamma(\cdot)$ 表示标准 Gamma 函数。

2.3 逐维高斯变异策略

为解决在迭代后期蛭螂种群无法达到全局最优的问题,通常使用变异扰动技术在解空间中进行进一步探索^[12],对当前迭代中的最优蛭螂个体进行变异操作,增加蛭螂种群的多样性,使算法更容易退出局部最优区域。此外,通过引入惯性权重提高算法的收敛速度。变异公式为

$$\mathbf{X}_{\text{bestnew}} = w \times \mathbf{X}_{\text{best}} + r \times \mathbf{X}_{\text{best}} \quad (5)$$

式中: \mathbf{X}_{best} 为当前个体最优位置; $\mathbf{X}_{\text{bestnew}}$ 为新的候选位置; w 为惯性权重因子; r 为从标准正态分布中生成的一个随机数。

引入贪婪规则,以确定是否更新位置。贪婪规则表示为

$$\mathbf{X}_{\text{best}} = \begin{cases} \mathbf{X}_{\text{bestnew}}, & f(\mathbf{X}_{\text{bestnew}}) < f(\mathbf{X}_{\text{best}}) \\ \mathbf{X}_{\text{best}}, & \text{其他} \end{cases} \quad (6)$$

式中 $f(\cdot)$ 表示计算个体适应度值的函数。

2.4 动态边界处理机制

在群智能算法中,超出有效范围的个体会被重新映射回解空间。本文采用动态边界处理机制,将个体返回到解空间的最优个体附近,确保算法向更优方向前进。具体公式为

$$X = \begin{cases} X_{\text{best}} + r \times [(T_{\text{max}} - t)/T_{\text{max}}] \times (U_B - X_{\text{best}}), X > U_B \\ X_{\text{best}} - r \times [(T_{\text{max}} - t)/T_{\text{max}}] \times (X_{\text{best}} - L_B), X < L_B \end{cases} \quad (7)$$

式中 T_{max} 为最大迭代次数。

2.5 HDBO 算法性能测试

在 10 个基准函数上对 HDBO 算法性能进行测试,并将其与 HHO^[13]、SSA^[14]、WOA^[15] 和 DBO^[10] 算法进行比较,所有算法的参数设置均与原始文献一致,测试结果如表 1 所示。表中 F_1, F_2, F_3, F_4, F_5 为单峰测试函数, F_6, F_7, F_8 为多峰测试函数, F_9 和 F_{10} 为固定维度的多峰测试函数。

表 1 各算法在不同基准函数上的测试结果

Table 1 Test results of each algorithm based on different benchmark functions

函数	统计量	HHO	SSA	WOA	DBO	HDBO
F_1	平均值	2.20×10^{-94}	7.00×10^{-52}	4.60×10^{-73}	1.48×10^{-115}	0
	标准差	1.21×10^{-93}	3.83×10^{-51}	1.31×10^{-72}	8.12×10^{-115}	0
F_2	平均值	1.24×10^{-47}	5.39×10^{-27}	9.40×10^{-51}	2.49×10^{-57}	0
	标准差	6.81×10^{-47}	2.95×10^{-26}	3.71×10^{-50}	1.36×10^{-56}	0
F_3	平均值	4.82×10^{-72}	4.61×10^{-27}	4.32×10^4	5.61×10^{-52}	0
	标准差	2.05×10^{-71}	2.05×10^{-26}	1.33×10^4	3.06×10^{-51}	0
F_4	平均值	7.51×10^{-50}	4.96×10^{-32}	5.43×10^1	4.83×10^{-51}	0
	标准差	2.75×10^{-49}	1.89×10^{-31}	3.09×10^1	1.33×10^{-51}	0
F_5	平均值	3.40×10^{-4}	3.61×10^{-4}	8.51×10^4	7.87×10^{-4}	3.13×10^{-4}
	标准差	2.95×10^{-4}	1.78×10^{-4}	2.44×10^4	3.84×10^{-4}	2.34×10^{-5}
F_6	平均值	0	0	0	1.50×10^{-1}	0
	标准差	0	0	0	8.30×10^{-1}	0
F_7	平均值	8.88×10^{-16}	8.88×10^{-16}	3.85×10^{-14}	8.88×10^{-16}	8.88×10^{-16}
	标准差	0	0	2.10×10^{-14}	0	0
F_8	平均值	0	0	0	0	0
	标准差	0	0	0	0	0
F_9	平均值	-1.25×10^4	-8.50×10^3	-1.05×10^4	-8.02×10^3	-1.26×10^4
	标准差	3.97×10^2	5.75×10^2	1.90×10^3	1.40×10^3	5.20×10^{-1}
F_{10}	平均值	-5.23	-9.16	-8.58	-8.38	-1.01×10^1
	标准差	9.70×10^{-1}	2.29	2.83	2.73	1.35



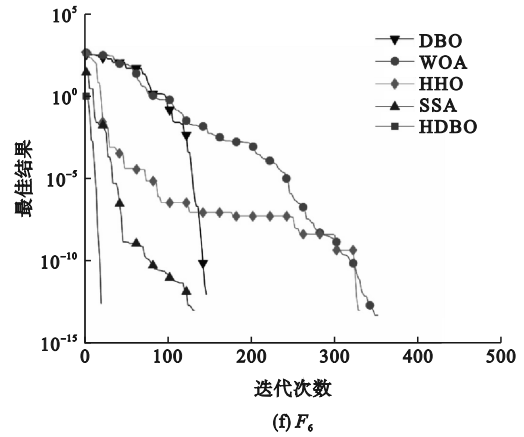
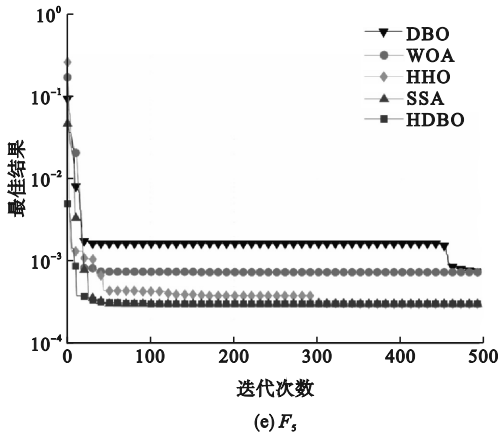




由表 1 可以看出:HDBO 算法在函数 F_1, F_2, F_3, F_4, F_5 上均取得了理论上的最优值,优于其他对比算法;HDBO 在多峰测试函数 F_6, F_7, F_8 上均获得了理论最优值,表现出较强的全局探索能力;尽管 HDBO 在固定维度的多峰测试函数 F_9 和 F_{10} 上无法每次都获得理论最优值,但其性能仍优于其他对比算法。图 2 所示为各算法在不同基准函数上的收敛曲线。由图 2(a)~2(d)可以看出, HDBO 在收敛速度上具有绝对优势,且收敛精度较高;由图 2(e)~2(h)可以看出,虽然其他算法

也可能找到理论上的最优值,但 HDBO 的收敛时间明显快于其他算法;由图 2(i)~2(j)可以看出,在复杂的固定维度的多峰测试函数中,HDBO 算法的收敛性能较其他算法更好。

进一步采用 Wilcoxon 符号秩检验来评估 HDBO 算法与其他优化算法之间的性能是否存在显著差异。计算 p 值以确定差异的统计显著性,当 p 值小于 0.05 时,表示两种算法之间存在显著差异,若 p 值为 NaN,则表明算法性能过于接近。HDBO 算法与其他对比算法经 Wilcoxon 符号秩

检验得到的 p 值如表 2 所示,可见 HDBO 算法与 HHO 算法、SSA 算法在函数 F_9 和 F_{10} 上性能接

近,其余情况下 HDBO 算法与其他对比算法间均存在显著差异,HDBO 算法的性能更为优异。



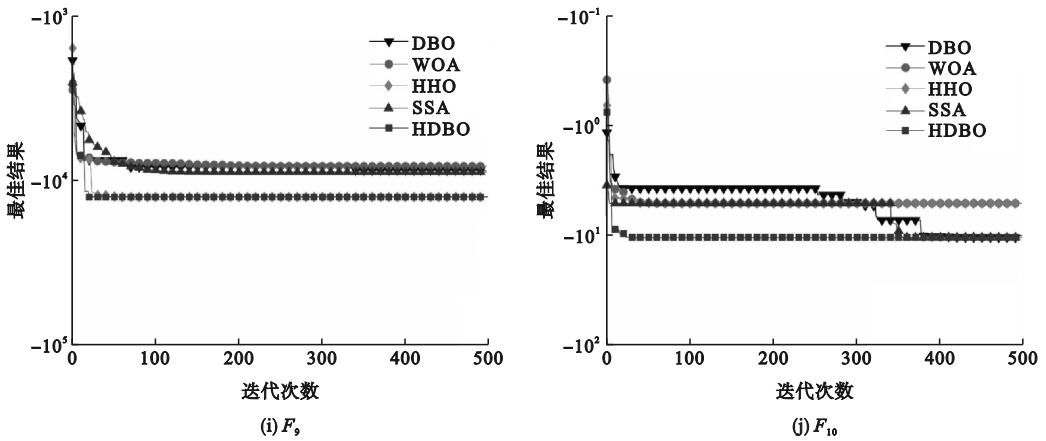


图2 各算法在不同基准函数上的收敛曲线

Fig.2 Convergence curves of each algorithm based on different benchmark functions

表2 经 Wilcoxon 符号秩检验得到的 p 值

Table 2 p-values obtained by Wilcoxon signed-rank test

函数	DBO	HHO	WOA	SSA
F_1	1.21×10^{-12}	1.21×10^{-12}	1.21×10^{-12}	4.57×10^{-12}
F_2	1.21×10^{-12}	1.21×10^{-12}	1.21×10^{-12}	1.21×10^{-12}
F_3	1.21×10^{-12}	1.21×10^{-12}	1.21×10^{-12}	4.57×10^{-12}
F_4	1.21×10^{-12}	1.21×10^{-12}	1.21×10^{-12}	4.57×10^{-12}
F_5	3.02×10^{-11}	1.24×10^{-4}	3.02×10^{-11}	4.98×10^{-11}
F_6	3.02×10^{-11}	9.06×10^{-8}	3.02×10^{-11}	3.02×10^{-11}
F_7	6.12×10^{-10}	7.73×10^{-1}	2.37×10^{-10}	1.70×10^{-8}
F_8	3.34×10^{-11}	7.94×10^{-3}	3.01×10^{-7}	3.02×10^{-11}
F_9	3.34×10^{-1}	NaN	1.61×10^{-1}	NaN
F_{10}	3.34×10^{-1}	NaN	1.23×10^{-9}	NaN

3 HDBO-LSTM 模型的建立及实验分析

3.1 HDBO-LSTM 负荷预测模型

为避免人为经验选择 LSTM 超参数时的随机性,本文提出 HDBO 算法,用于优化 LSTM 网络中的超参数,构建 HDBO-LSTM 负荷预测模型。图3所示为采用 HDBO-LSTM 模型进行负荷预测的流程图。

3.2 数据预处理与模型评估指标

考虑到电力负荷数据具有时间序列的连续性,本文采用均值填充的方法对缺失和异常数据进行处理^[16]。

对数据进行归一化处理可更容易找到最佳解,从而更有效地分析未来负荷数据趋势,并加速算法收敛。数据归一化公式为

$$x_r = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (8)$$

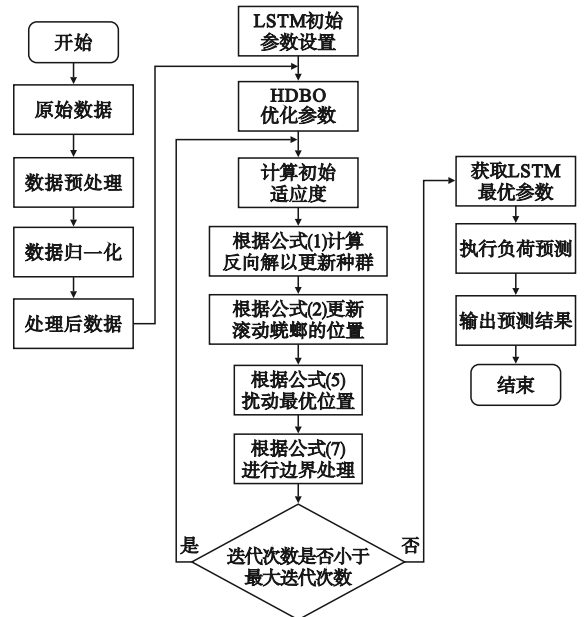


图3 负荷预测流程图

Fig.3 Flow chart of load forecasting

式中: x_r 表示归一化值; x 表示原始负荷数据值; x_{\max} 和 x_{\min} 分别表示当天的最大负荷值和最小负荷值。

本文选择 MAPE、RMSE、MAE 以及变异系数 (COV) 作为模型的评估指标^[17]。

3.3 数据集简介及模型参数选择

实验数据来自电工数学建模竞赛,包括2014年1月1日至2015年1月9日期间的历史负荷数据及负荷相关影响变量。历史负荷数据每天包含96个采样点,采样间隔为15min。数据集中的负荷数据按照9:1的比例划分为训练集和测试集。

模型优化的超参数包括学习率、隐藏层数量(包括第一隐藏层数量 L_1 和第二隐藏层数量 L_2)及训练次数。适应度函数定义为实际值与模型预

测值之间的均方误差(MSE)^[18],通过 HDBO 的优化搜索,可以确定一组使训练模型均方误差最小化的超参数。超参数迭代曲线如图 4 所示,优化后的超参数取值如表 3 所示。




图 4 超参数迭代曲线

Fig. 4 Hyperparameter iteration curves

表 3 优化后的超参数取值

Table 3 Optimized hyperparameter values

超参数	数值
学习率	0.006 3
第一隐藏层数量 L_1	252
第二隐藏层数量 L_2	327
训练次数	270

3.4 实验结果及分析

为验证本文提出模型的有效性,将原始 LSTM 模型、DBO 优化的 LSTM 模型 (DBO-LSTM) 与本文提出的 HDBO-LSTM 模型进行比较。在测试集中随机选取 7 天的数据进行测试,并绘制各模型的预测曲线,结果如图 5 所示。可见:LSTM 模型的预测曲线拟合效果相对较差;相较于 LSTM 模型,DBO-LSTM 模型在拟合度上有了明显提升;相较于 DBO-LSTM 模型,HDBO-LSTM 模型的预测曲线更平滑,拟合效果更好。各模型的评估指标如表 4 所示。

分析表 4 可知:通过 DBO 算法优化获得 LSTM 超参数的方法明显优于人工经验选择超参数的方法,在随机七天的负荷预测中,RMSE 和 MAPE 分别降低了 7.98% 和 6.53%;与 DBO-LSTM 模型相比,在七天的预测周期内,HDBO-LSTM 预测模型的 RMSE 和 MAPE 分别降低了 22.38% 和 16.33%;与原始的 LSTM 模型相比,

HDBO-LSTM 模型的性能有较大提升。本文改进的 HDBO 算法具有更强的优化搜索能力。

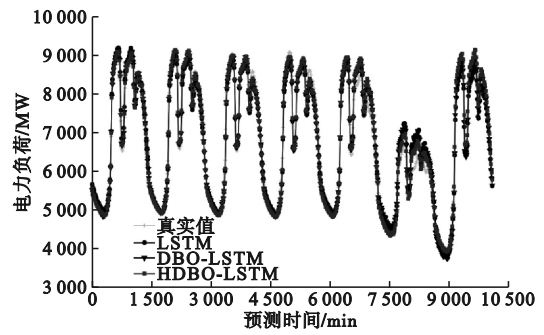


图 5 随机七天的负荷预测曲线

Fig. 5 Load forecasting curves for randomized seven-day

表 4 随机七天的负荷预测评估指标

Table 4 Load forecasting evaluation indicators for randomized seven-day

模型	MAPE	RMSE	MAE	COV
LSTM	0.024 5	227.037 7	169.300 4	0.033 3
DBO-LSTM	0.022 9	208.915 3	152.916 7	0.030 6
HDBO-LSTM	0.020 5	176.224 6	136.861 0	0.025 8

每秒浮点运算次数 (floating point operations per second, FLOPs) 是评估计算性能的关键指标,本文采用 FLOPs 作为模型复杂度的衡量标准,用 F 表示,其计算式为

$$F = 8 \times T \times \sum_{i=1}^L [m_i \times (m_i + d_i)] \quad (9)$$

式中: T 为时间步长; L 为 LSTM 的层数; m_i 为第 i 层的隐藏单元数; d_i 为第 i 层输入特征的维度。模型复杂度计算结果如表 5 所示,可以看出,HDBO-LSTM 的计算复杂度略低于 DBO-LSTM,即 HDBO-LSTM 在实际应用中具有更高的计算效率。

表 5 模型复杂度比较

Table 5 Comparison of model complexity

模型	L_1	L_2	FLOPs/ 10^6
HDBO-LSTM	252	327	2.23
DBO-LSTM	428	196	2.79

为进一步验证本文模型的预测性能,选择 SSA、PSO、灰狼优化 (grey wolf optimizer, GWO) 和 DBO 等 4 种元启发式算法分别用于 LSTM 网络参数优化,构建 4 种负荷预测模型。选择数据集中最后两天的数据进行预测,结果如表 6 所示。由表 6 可见:本文模型的各项指标均优于其他对比模型;DBO-LSTM 模型的性能仅次于本文模型;SSA-LSTM 模型的性能优于 GWO-LSTM 和

PSO-LSTM 模型;GWO-LSTM 模型的 RMSE 和 COV 指标优于 PSO-LSTM 模型,而在 MAPE 和 MAE 指标上略差。

表 6 不同模型的负荷预测评估指标

Table 6 Load forecasting evaluation indicators of different models

模型	MAPE	RMSE	MAE	COV
HDBO-LSTM	0.014 4	133.775 8	105.214 8	0.019 0
DBO-LSTM	0.015 6	150.053 0	114.843 5	0.021 3
SSA-LSTM	0.017 1	151.567 9	122.596 1	0.021 5
GWO-LSTM	0.018 2	156.737 6	129.771 4	0.022 2
PSO-LSTM	0.017 3	157.272 5	124.366 6	0.022 3

4 结论与展望

提出了一种用于短期电力负荷预测的 HD-BO-LSTM 模型。通过多种优化策略改进 DBO 算法,提出了 HDBO 算法,该算法在基准函数测试上的表现优于原始 DBO 算法;针对 LSTM 网络中超参数选择问题,采用 HDBO 算法进行超参数优化,有效避免了因人为经验选择参数导致预测精度下降的问题。实验结果验证了本文算法的有效性。

尽管 HDBO-LSTM 模型在短期电力负荷预测中表现出色,但在处理更加复杂和多变的电力负荷数据时,其适应性和可扩展性仍需进一步研究。由于 HDBO-LSTM 模型能够更好地捕捉能源生产中的波动特性,可将其应用于风力、太阳能等可再生能源的发电量预测,本文模型的优化策略还可应用于环境监测、气候变化预测等,未来将重点研究本文模型在应对这些领域中复杂数据时的预测性能。

参考文献 (References):

[1] 李文武,石强,李丹,等.基于 VMD 和 PSO-SVR 的短期电力负荷多阶段优化预测[J].中国电力,2022,55(8):171-177.
LI W W,SHI Q,LI D,et al. Multi-stage optimization forecast of short-term power load based on VMD and PSO-SVR[J]. Electric Power,2022,55(8):171-177. (in Chinese)

[2] DU P, YE Y X, WU H, et al. Study on deterministic and interval forecasting of electricity load based on multi-objective whale optimization algorithm and transformer model[J]. Expert Systems with Applications,2025,268:126361.

[3] 赵艺然,王宇驰,原令泽.基于 SSA-CNN-LSTM 的短期电力负荷预测[J].现代工业经济和信息化,2024,14(8):169-170.
ZHAO Y R,WANG Y C,YUAN L Z. Short-term power load

forecasting based on SSA-CNN-LSTM[J]. Modern Industrial Economy and Informationization,2024,14(8):169-170. (in Chinese)

[4] RUMA J F, ADNAN M S G, DEWAN A, et al. Particle swarm optimization based LSTM networks for water level forecasting;a case study on Bangladesh river network[J]. Results in Engineering,2023,17:100951.

[5] 赵婧宇,池越,周亚同.基于 SSA-LSTM 模型的短期电力负荷预测[J].电工电能新技术,2022,41(6):71-79.
ZHAO J Y,CHI Y,ZHOU Y T. Short-term load forecasting based on SSA-LSTM model[J]. Advanced Technology of Electrical Engineering and Energy,2022,41(6):71-79. (in Chinese)

[6] HAN L J, WANG X H, YU Y, et al. Power load forecast based on CS-LSTM neural network[J]. Mathematics,2024,12(9):1402.

[7] TANG T Y,LI B,MA X T,et al. DBO-LSTM-based demand-side resource load forecasting method[C]//2024 International Conference on Smart Grid and Energy (ICSGE). Singapore, Singapore:IEEE,2024:53-57.

[8] WANG X,WEI Y X,GUO Z H,et al. A sinh-cosh-enhanced DBO algorithm applied to global optimization problems[J]. Biomimetics(Basel),2024,9(5):271.

[9] 孙先亮,谭小波.基于 LSTM 的动态网络异常行为检测方法[J].沈阳理工大学学报,2021,40(6):22-26.
SUN X L,TAN X B. Detection method of abnormal behavior of dynamic network based on LSTM[J]. Journal of Shenyang Ligong University,2021,40(6):22-26. (in Chinese)

[10] XUE J K,SHEN B. Dung beetle optimizer;a new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing,2023,79(7):7305-7336.

[11] LONG W, JIAO J J, LIANG X M, et al. A random opposition-based learning grey wolf optimizer[J]. IEEE Access,2019,7:113810-113825.

[12] DU H R, WANG J X, QIAN W J, et al. An improved sparrow search algorithm for the optimization of variational modal decomposition parameters[J]. Applied Sciences,2024,14(5):2174.

[13] HEIDARI A A, MIRJALILI S, FARIS H, et al. Harris hawks optimization;algorithm and applications[J]. Future Generation Computer Systems,2019,97:849-872.

[14] XUE J K,SHEN B. A novel swarm intelligence optimization approach;sparrow search algorithm[J]. Systems Science & Control Engineering,2020,8(1):22-34.

[15] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software,2016,95:51-67.

[16] PARK K, JEONG J, KIM D, et al. Missing-insensitive short-term load forecasting leveraging autoencoder and LSTM[J]. IEEE Access,2020,8:206039-206048.

[17] ZHA W T, JI Y Q, LIANG C. Short-term load forecasting method based on secondary decomposition and improved hierarchical clustering[J]. Results in Engineering,2024,22:101993.

[18] WANG M H, XIA Y S, ZHANG X S. Research on renewable energy power demand forecasting method based on IWOA-SA-BILSTM modeling[J]. Frontiers in Energy Research,2024,11:1331076.

(责任编辑:宋颖韬)