

DOI: 10.13715/j.issn.2096-644X.20250508.0001

引用格式: 达彪, 张涛, 王舰, 等. 基于 NRBO-LSTM 的短期电力负荷预测[J]. 湘潭大学学报(自然科学版), 2026, 48(2): 47-59.

Citation: DA Biao, ZHANG Tao, WANG Jian, et al. Short-term power load forecasting based on NRBO-LSTM[J]. Journal of Xiangtan University (Natural Science Edition), 2026, 48(2): 47-59.

基于 NRBO-LSTM 的短期电力负荷预测*

达彪^{1,2}, 张涛^{1,2}, 王舰^{1,2}, 陈毅^{1,2}

(1. 昆明理工大学 信息工程与自动化学院, 云南 昆明, 650500;
2. 云南省计算机技术应用重点实验室, 云南 昆明, 650500)

摘要: 【目的】为了实现电力资源的合理分配, 提高电力负荷预测的精度, 针对现有负荷预测算法参数设置随机性强、预测精度不足的问题, 该文提出一种基于牛顿-拉夫逊优化算法 (NRBO) 和长短期记忆网络 (LSTM) 的混合预测模型. 【方法】首先, 分析现有负荷预测算法的局限性. 然后, 利用 NRBO 算法的全局寻优能力, 自动搜索 LSTM 网络的最优超参数, 以替代传统的人工调参方式, 减少人为设置的随机性; 最后, 构建 NRBO-LSTM 模型用于电力负荷预测. 【结果】该文采用澳大利亚某地区 2009 年 1 月 1 日至 2010 年 12 月 31 日的实际电力负荷数据进行验证, 并与 Autoformer、基于蜉蝣算法优化的长短期记忆网络 (DBO-LSTM)、Transformer、基于遗传算法优化反向传播 (GA-BP) 神经网络以及标准 LSTM 模型进行对比. 实验结果表明, NRBO-LSTM 模型在各项评价指标上均表现最优: 其均方根误差 (RMSE) 分别降低了 21.51%、42.01%、47.43%、56.03%、66.44%; 平均绝对百分比误差 (MAPE) 分别降低了 31.16%、45.18%、53.19%、65.87%、72.09%; 平均绝对误差 (MAE) 分别降低了 34.97%、49.97%、58.27%、69.31%、75.85%; 决定系数 (R^2) 分别提高了 0.523%、2.728%、3.399%、8.085%、15.933%. 【结论】该文提出的 NRBO-LSTM 模型能够有效提高电力负荷预测的精度和拟合效果, 为电力系统的负荷预测提供了一种新的有效方法, 具有重要的理论和应用价值.

关键词: 牛顿-拉夫逊优化算法; 长短期记忆网络; 电力负荷预测; 电力系统

中图分类号: TM715; TP183

文献标志码: A

文章编号: 2096-644X (2026) 02-0047-13

Short-term power load forecasting based on NRBO-LSTM

DA Biao^{1,2}, ZHANG Tao^{1,2}, WANG Jian^{1,2}, CHEN Yi^{1,2}

(1. School of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China;
2. Yunnan Provincial Key Laboratory of Computer Technology Application, Kunming 650500, China)

Abstract: 【Objective】In order to realize the rational allocation of power resources and improve the accuracy of power load forecasting, aiming at the problems of strong randomness of parameter setting and insufficient prediction accuracy of existing load forecasting algorithms. A hybrid prediction model based on Newton-Raphson optimization algorithm (NRBO) and long short-term memory network (LSTM) is proposed. 【Method】Firstly, the limitations of existing load forecasting algorithms are analyzed. Then, using the global optimization ability of the NRBO algorithm, the optimal hyperparameters of the LSTM network are automatically searched to replace the traditional manual parameter adjustment method and

* 收稿日期: 2025-05-08

基金项目: 云南省自然科学基金 (202301AV070003, 202101BE070001-008); 云南省重大科技专项 (202302AG050009, 202202AD080013)

通信作者: 张涛 (1981-), 男, 云南宜良人, 助理研究员, 博士, E-mail: ztao@kust.edu.cn

reduce the randomness of artificial settings. Finally, the NRBO-LSTM model is constructed for power load forecasting. **【Result】** The actual power load data from January 1, 2009 to December 31, 2010 in a certain area of Australia were used for verification, and compared with Autoformer, long and short term memory network based on dung beetle optimization algorithm (DBO-LSTM), Transformer, back propagation neural network based on genetic algorithm (GA-BP) and standard LSTM model. The experimental results show that the NRBO-LSTM model performs best in all evaluation indicators: its root mean square error (RMSE) is reduced by 21.51%, 42.01%, 47.43%, 56.03%, and 66.44%, respectively; the mean absolute percentage error (MAPE) is reduced by 31.16%, 45.18%, 53.19%, 65.87% and 72.09%, respectively; The mean absolute error (MAE) is reduced by 34.97%, 49.97%, 58.27%, 69.31% and 75.85%, respectively; The coefficient of determination (R^2) is increased by 0.523%, 2.728%, 3.399%, 8.085% and 15.933%, respectively. **【Conclusion】** The NRBO-LSTM model proposed in this paper can effectively improve the accuracy and fitting effect of power load forecasting, and provides a new and effective method for power system load forecasting, which has important theoretical and application value.

Key words: Newton-Raphson optimization algorithm; long and short term memory network; power load forecasting; electric power system

0 引言

随着“双碳”战略的提出,以及近年来社会经济的不断发展,人们每年的耗电量也持续增长,因此对电网的稳定、可靠、高质量供电提出了更高的要求.短期电力负荷预测成为能源管理领域的核心组成部分,它在确保电力系统的稳定运行和高效调度方面起着至关重要的作用^[1-2].精确的短期电力负荷预测能够细致优化电网调度,确保电力系统安全稳定运行.这种预测的准确性不仅有助于提高电力企业的经济效益,还能够增强社会效益,同时支持社会生产活动的顺利进行^[3-4].目前研究表明,短期电力负荷预测使电力系统能够有效分配资源,减轻因新能源并网等因素带来的潜在影响^[5].短期负荷预测与人们的日常生活和工作模式紧密相关,可帮助电网公司更合理地制定电网调度、供电和交易计划,因此,这种预测具有重要的实际应用和研究价值^[6].

长期以来,众多研究者对短期电力负荷预测投入了大量的研究^[7-8],并取得了显著的成果.为提升预测的精确性和可靠性,已提出多种方法和模型.陈晓华等^[9]提出一种基于经验模态分解与猎人猎物优化算法优化双向长短期记忆网络(BiLSTM)的电力负荷短期预测模型.查云龙等^[10]为避免电力负荷输出缺乏整体性,提出一种基于BasicNet-LSTM的短期负荷预测模型.简定辉等^[11]为有效提高负荷预测精度,提出一种MICResNet-LSTM-BP短期电力负荷预测模型.印江等^[12]提出一种利用改进的自适应粒子群算法优化长短期记忆网络(LSTM)的短期电力负荷预测模型.王旭^[13]提出一种利用灰狼优化算法优化LSTM的超参数对电力负荷进行预测的模型.针对电力负荷随机性强、预测精度不高的问题,高超等^[14]提出一种基于改进型黑猩猩优化算法优化LSTM的短期负荷预测模型.朱莉等^[15]提出一种基于分量感知动态图Transformer的模型,实现了负荷序列分解后各个分量的关系提取和同时预测,但仍然存在计算开销大、预测精度低的问题.对于提高电力负荷预测精度这个点,赵来奇^[16]提出一种改进的Autoformer融合模型算法.以上研究均表明,不能同时达到更高的预测精度以及更好的拟合效果.

针对以往研究的不足,本文提出一种基于牛顿-拉夫逊优化算法(NRBO)优化LSTM的

电力负荷短期预测方法. NRBO 主要利用两个规则: Newton-Raphson 搜索规则 (NRSR) 和陷阱避免算子 (TAO), 并使用几组矩阵来进一步探索最佳结果, 进一步优化 LSTM 的超参数. 最后选取澳大利亚开放数据集, 对数据集中 2009 年 1 月 1 日至 2010 年 12 月 31 日的电力负荷数据进行分析, 仿真结果表明, 其均方根误差 (RMSE) 值为 0.198 95, 平均绝对百分比误差 (MAPE) 值为 0.010 009, 平均绝对误差 (MAE) 值为 0.136 25, 决定系数 (R^2) 值为 0.990 57. 所提方法的预测精度更高, 拟合效果更好.

1 基于 NRBO-LSTM 的预测模型原理

1.1 LSTM 算法的基本原理

LSTM 是一种特殊的循环神经网络 (RNN) 结构, 它成功地克服了传统 RNN 在训练过程中遇到的梯度爆炸和梯度消失的问题. LSTM 由于其内部结构的特性, 能够学习数据中的远距离依赖关系, 这使得它在时间序列预测任务中尤为适用^[17]. LSTM 网络通过引入控制门机制到其循环单元中, 实现了对神经元状态信息的有效传递与存储^[18]. 这一基本单元的结构如图 1 所示.

LSTM 神经网络的工作原理如下:

遗忘门: 负责在 $t-1$ 时刻决定细胞内信息的保持与丢弃. 相关公式如式 (1) 所示.

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f). \quad (1)$$

输入门: 用于选择哪些新数据可以被输入记忆单元中, 以便更新细胞状态. 相关公式如式 (2) ~ 式 (4) 所示.

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i), \quad (2)$$

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c), \quad (3)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t. \quad (4)$$

输出门: 负责筛选记忆单元内的信息, 并提取出最关键的部分, 以便对未来值进行预测. 相关公式如式 (5) ~ 式 (6) 所示.

$$h_t = o_t \odot \tanh(c_t), \quad (5)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o), \quad (6)$$

$$\sigma(x) = \frac{1}{1 + e^{-x}}, \quad (7)$$

$$\tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}}, \quad (8)$$

式 (1) ~ 式 (8) 中: f_t 为遗忘门; i_t 为输入门; \tilde{c}_t 为新单元状态; c_t 为当前时刻的单元状态; h_t 为隐藏状态; o_t 为输出门; W 为输入 x_t 的权重矩阵, 其中 W_f 、 W_i 、 W_o 、 W_c 分别为遗忘门、输入门、输出门和候选记忆单元的输入权重矩阵; U 为前一刻隐藏状态 h_{t-1} 的权重矩阵, 其中 U_f 、 U_i 、 U_o 、 U_c 分别为遗忘门、输入门、输出门和候选记忆单元对应的循环权重矩阵; b 为偏置向量, 其中 b_f 、 b_i 、 b_o 、 b_c 分别为遗忘门、输入门、输出门和候选记忆单元对应的循环权

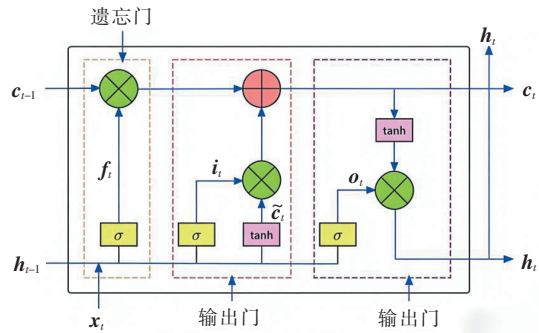


图 1 LSTM 结构示意图

Fig. 1 LSTM structure diagram

重矩阵; σ 为 sigmoid 函数; \tanh 为双曲正切函数; \odot 为逐元素乘积.

1.2 NRBO 算法的基本原理

NRBO 算法是一种基于经典牛顿-拉夫逊方法的启发式新型优化技术^[19], 其核心目标是求解函数极值, 尤其适用于寻找最小值点. 同时融合了梯度法和非梯度法的优点, 有效克服了传统算法的局限性, 为优化领域带来了新的突破. NRBO 优化算法受到 Newton-Raphson 方法的启示, 采用了 NRSR 和 TAO 两个策略来全面探索搜索空间, 并通过使用多组矩阵来深入挖掘最优解. NRBO 优化算法实现的基本流程, 如图 2 所示.

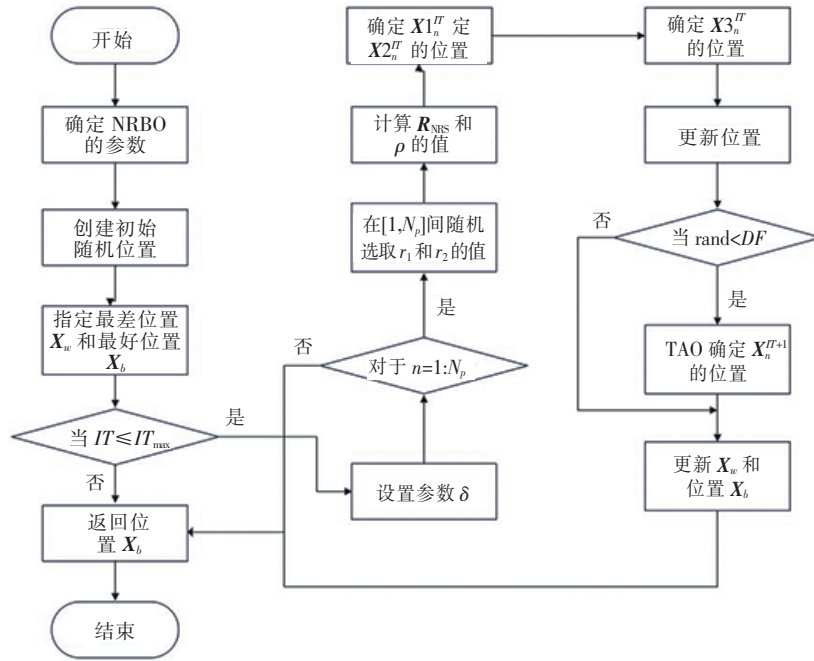


图 2 NRBO 算法流程图

Fig. 2 Flowchart of NRBO algorithm

1.2.1 种群初始化

NRBO 的种群初始化是通过在候选解的边界内产生初始随机种群来启动对最优解的搜索. 基于存在 N_p 个种群的事实, 且每个种群由模糊决策变量组成. 因此, 种群初始化公式可表示如下:

$$x_j^n = lb + \text{rand}(ub - lb), \quad (9)$$

式中: $n=1, 2, \dots, N_p$; $j=1, 2, \dots, dim$; x_j^n 为第 n 个总体的第 j 维位置; dim 为问题维数; lb 为下界; ub 为上界; rand 为 $(0, 1)$ 之间的随机数.

式 (10) 给出了可以描述所有维度的种群矩阵:

$$\mathbf{X}_n = \begin{bmatrix} x_1^1 & x_2^1 & \cdots & x_{dim}^1 \\ x_1^2 & x_2^2 & \cdots & x_{dim}^2 \\ \vdots & \vdots & \ddots & \vdots \\ x_1^{N_p} & x_2^{N_p} & \cdots & x_{dim}^{N_p} \end{bmatrix}_{N_p \times dim}. \quad (10)$$

1.2.2 搜索规则 (\mathbf{R}_{NRS})

\mathbf{R}_{NRS} 控制向量允许更准确地探索可行区域并获得更好的位置. 它使用泰勒级数展开来近似函数, 并利用一阶和二阶导数信息更新解的位置, 二阶导数表述为:

$$f(x + \Delta x) = f(x) + f'(x_0) \Delta x + \frac{1}{2!} f''(x_0) \Delta x^2 + \frac{1}{3!} f'''(x_0) \Delta x^3 + \dots, \quad (11)$$

$$f(x - \Delta x) = f(x) - f'(x_0) \Delta x + \frac{1}{2!} f''(x_0) \Delta x^2 - \frac{1}{3!} f'''(x_0) \Delta x^3 + \dots. \quad (12)$$

更新后的根的位置如下^[18]:

$$\mathbf{x}_{n+1} = \mathbf{x}_n - \frac{(f(\mathbf{x}_n + \Delta x) - f(\mathbf{x}_n - \Delta x)) \Delta x}{2(f(\mathbf{x}_n + \Delta x) + f(\mathbf{x}_n - \Delta x) - 2f(\mathbf{x}_n))}, \quad (13)$$

$$\mathbf{R}_{\text{NRS}} = \text{randn} \times \frac{(\mathbf{X}_w - \mathbf{X}_b) \Delta x}{2(\mathbf{X}_w + \mathbf{X}_b - 2\mathbf{x}_n)}, \quad (14)$$

$$\Delta x = \text{rand}(1, \text{dim}) \cdot |\mathbf{X}_b - \mathbf{X}_n^{IT}|, \quad (15)$$

式中: randn 为均值是 0、方差是 1 的正态分布随机数; \mathbf{X}_w 为最差位置; \mathbf{X}_b 为最佳位置. 为了提升算法的性能, 引入自适应参数 δ . 该参数 δ 的表达式如式 (16) 所示.

$$\delta = \left(1 - \left(\frac{2IT}{IT_{\text{Max}}}\right)^5\right), \quad (16)$$

式中: IT 为当前的迭代步骤; IT_{Max} 为允许的最大迭代次数. 为了在探索与利用阶段维持均衡, 参数 δ 将在迭代过程中自适应地进行调整, 且 δ 的值在 -1 到 1 之间变化.

接着通过增加一个名为 $\boldsymbol{\rho}$ 的新参数, 该参数有助于引导种群朝正确的搜索方向前进.

$$\boldsymbol{\rho} = a(\mathbf{X}_b - \mathbf{X}_n^{IT}) + b(\mathbf{X}_{r_1}^{IT} - \mathbf{X}_{r_2}^{IT}), \quad (17)$$

式中: a 和 b 为 (0, 1) 之间均匀分布的随机数; r_1 和 r_2 为从总体中随机选择的整数, 且 r_1 和 r_2 的值不相等; \mathbf{X}_b 为最佳位置; \mathbf{X}_n^{IT} 为 \mathbf{X}_n 经过 IT 次迭代后得到的矩阵; $\mathbf{X}_{r_1}^{IT}$ 为 \mathbf{X}_{r_1} 经过 IT 次迭代后得到的矩阵; $\mathbf{X}_{r_2}^{IT}$ 为 \mathbf{X}_{r_2} 经过 IT 次迭代后得到的矩阵.

矢量通过更新位置后得到新的位置如下:

$$\mathbf{X}1_n^{IT} = \mathbf{x}_n^{IT} - \left(\text{randn} \times \frac{(\mathbf{y}_w - \mathbf{y}_b) \Delta x}{2(\mathbf{y}_w + \mathbf{y}_b - 2\mathbf{x}_n)}\right) + (a(\mathbf{X}_b - \mathbf{X}_n^{IT}) + b(\mathbf{X}_{r_1}^{IT} - \mathbf{X}_{r_2}^{IT})), \quad (18)$$

式中: $\mathbf{X}1_n^{IT}$ 为通过更新 \mathbf{X}_n^{IT} 而得到的新矢量; \mathbf{x}_n^{IT} 为当前的位置矢量; \mathbf{y}_w 和 \mathbf{y}_b 为两个对称的动态参考点.

通过用当前矢量 \mathbf{x}_n^{IT} 的位置代替最佳矢量 \mathbf{X}_b 的位置来构造新矢 $\mathbf{X}2_n^{IT}$ 如下:

$$\mathbf{X}2_n^{IT} = \mathbf{X}_b - \left(\text{randn} \times \frac{(\mathbf{y}_w - \mathbf{y}_b) \Delta x}{2(\mathbf{y}_w + \mathbf{y}_b - 2\mathbf{x}_n)}\right) + (a(\mathbf{X}_b - \mathbf{X}_n^{IT}) + b(\mathbf{X}_{r_1}^{IT} - \mathbf{X}_{r_2}^{IT})), \quad (19)$$

式中: $\mathbf{X}2_n^{IT}$ 为通过更新 $\mathbf{X}1_n^{IT}$ 而得到的新矢量; \mathbf{X}_b 为当前的最佳位置矢量; \mathbf{y}_w 和 \mathbf{y}_b 为两个对称的动态参考点.

接着, NRBO 算法通过式 (18) 和式 (19) 来优化探索阶段的多样性和开发阶段的强化效果. 在下一轮迭代中, 新的位置向量由式 (20) 和式 (21) 来确定.

$$\mathbf{x}_n^{IT+1} = r_2(r_2\mathbf{X}1_n^{IT} + (1-r_2)\mathbf{X}2_n^{IT}) + (1-r_2)\mathbf{X}3_n^{IT}, \quad (20)$$

$$\mathbf{X}3_n^{IT} = \mathbf{X}_n^{IT} - \delta(\mathbf{X}2_n^{IT} - \mathbf{X}1_n^{IT}), \quad (21)$$

式 (20) ~ 式 (21) 中: \mathbf{x}_n^{IT+1} 为新位置矢量; $\mathbf{X}1_n^{IT}$ 为通过更新 \mathbf{X}_n^{IT} 而得到的新矢量; $\mathbf{X}2_n^{IT}$ 为通过更新 $\mathbf{X}1_n^{IT}$ 而得到的新矢量; $\mathbf{X}3_n^{IT}$ 为通过更新 $\mathbf{X}1_n^{IT}$ 和 $\mathbf{X}2_n^{IT}$ 而得到的新矢量; δ 为自适应参数; \mathbf{X}_n^{IT} 为第 n 个种群迭代 IT 次的矩阵.

1.2.3 TAO 算子

引入 TAO 算子旨在增强所提出的 NRBO 算法在解决现实世界问题时的实用性帮助 NRBO 避开局部最优解. 采用 TAO 能够显著地调整 \mathbf{X}_n^{IT+1} 的位置. 它通过将最佳位置 \mathbf{X}_b 与当前矢量位置 \mathbf{X}_n^{IT} 相结合, 生成一个质量提升的解决方案 \mathbf{X}_{TAO}^{IT} . 如果随机数 rand 小于 DF, 那么解 \mathbf{X}_{TAO}^{IT} 将按照以下公式生成^[18]:

$$\begin{cases} \mathbf{X}_{TAO}^{IT} = \mathbf{X}_n^{IT+1} + \theta_1 (\mu_1 \mathbf{x}_b - \mu_2 \mathbf{X}_n^{IT}) + \theta_2 \delta (\mu_1 \text{Mean}(\mathbf{X}^{IT}) - \mu_2 \mathbf{X}_n^{IT}), & \mu_1 < 0.5, \\ \mathbf{X}_n^{IT+1} = \mathbf{X}_{TAO}^{IT}, \\ \mathbf{X}_{TAO}^{IT} = \mathbf{X}_b + \theta_1 (\mu_1 \mathbf{x}_b - \mu_2 \mathbf{X}_n^{IT}) + \theta_2 \delta (\mu_1 \text{Mean}(\mathbf{X}^{IT}) - \mu_2 \mathbf{X}_n^{IT}), & \text{否则}, \end{cases} \quad (22)$$

式中: \mathbf{X}_{TAO}^{IT} 为增强后的矢量位置; \mathbf{X}_n^{IT+1} 为新位置矢量; \mathbf{X}_b 为种群最佳位置; $\text{Mean}(\mathbf{X}^{IT})$ 为取 \mathbf{X}^{IT} 的均值; θ_1 和 θ_2 分别为 $(-1, 1)$ 和 $(-0.5, 0.5)$ 之间的一致随机数; μ_1 和 μ_2 为随机数, 分别由式 (23) 和式 (24) 生成:

$$\mu_1 = 3\beta \times \text{rand} + (1 - \beta), \quad (23)$$

$$\mu_2 = \beta \times \text{rand} + (1 - \beta), \quad (24)$$

式中: β 为二进制变量, 取值为 1 或 0; rand 为 $(0, 1)$ 之间的随机数; 如果随机数的值不小于 0.5, 那么 β 将被设定为 0; 反之, 则设定为 1. 由于参数 μ_1 和 μ_2 是随机选取的, 这使得种群更加多样化, 并有助于摆脱局部最优解, 从而提升了种群的多样性.

2 基于 NRBO-LSTM 的预测模型的建立

由于在算法训练的过程中, 发现了 LSTM 神经网络应用于电力负荷预测时, 其预测精度与超参数之间存在极为紧密且复杂的关联. 超参数的细微变动, 比如学习率的大小差异、隐含层神经元数量的增减, 以及最大迭代次数的设定不同, 都会显著影响模型对电力负荷数据特征的学习与捕捉能力, 从而影响最终预测结果的准确性. 因此, 本文关键在于突破传统 LSTM 模型在电力负荷预测中的性能瓶颈, 创新性地提出一种改进的混合模型 NRBO-LSTM. 该模型的核心在于增强电力负荷预测的精准度与稳定性, 以满足电力系统复杂多变的实际需求.

NRBO-LSTM 模型的改进重点在于通过 NRBO 优化算法对 LSTM 神经网络进行深度优化. 相较于传统的 LSTM 模型, NRBO-LSTM 模型并非简单对参数调整, 而是进行了系统性的调整与增强. 巧妙融合了 NRBO 算法, 该算法能够凭借独特的迭代策略, 精准定位 LSTM 模型超参数的最优解空间.

在实际优化过程中, NRBO 算法对 LSTM 模型的超参数进行逐一校准, 包括对学习率的动态优化, 以平衡模型的收敛速度与训练稳定性; 对隐含层神经元数量的科学调整, 使其既能充分提取电力负荷数据中的复杂特征, 又能避免因神经元过多导致过拟合问题; 还有对最大迭代次数的合理设定, 确保模型在训练过程中既能充分学习数据特征, 又不会陷入无效的重复计算, 从而实现模型预测性能的显著提升.

通过这种优化策略, NRBO-LSTM 模型在电力负荷预测的任务上取得了非常明显的成效. NRBO-LSTM 电力负荷预测模型的构建流程如图 3 所示.

适应度值可以定义为:

$$\text{Fitness} = \frac{1}{\text{RMSE} + 1}, \quad (25)$$

式中, RMSE 为均方根误差, 表明预测误差的大小.

这种适应度值定义方式确保了适应度值随着误差的增加而减小, 从而使得具有较小误差的模型获得更高的适应度值.

其基本步骤概括如下:

1) 样本数据处理: 对实验所用的电力负荷数据集进行预处理和特征提取, 剔除异常数据, 同时进行归一化处理, 确保所有特征都在相同的尺度上, 有助于加快模型的学习速度, 提高模型的泛化能力, 使得模型的预测更加稳定. 并按照 7 : 2 : 1 的比例将 LSTM 模型的输入划分为训练集、测试集、验证集.

2) LSTM 的模型构建: 构建一个 LSTM 神经网络模型, 通常包括输入层、LSTM 层、ReLU 激活层、全连接层以及输出回归层. 输入层的作用是将原始数据传递给神经网络, 进行特征提取和格式化, 为后续层提供学习数据的基础. LSTM 层的作用是学习序列数据的长期依赖关系, 处理时间序列数据, 并通过门控机制控制信息的流动. ReLU 激活层的作用是引入非线性, 加快模型训练速度, 避免神经元死亡. 全连接层的作用就是把一堆原始信息拼在一起, 形成新的组合信息, 这样可以让模型更好地理解数据的深层含义. 输出回归层的作用是输出预测结果.

3) NRBO 算法优化: 先对 NRBO 算法的种群规模、最大迭代次数等关键参数进行初始化. 随后, 在解空间内随机生成初始种群, 并通过适应度函数计算筛选出当前最差解与最优解. 同时, 结合电力负荷数据特征, 设定 LSTM 网络的训练次数、学习率及隐藏神经元数等超参数. 算法运行阶段, NRBO 利用 NRSR 搜索新解, 通过构建目标函数的二阶导数信息, 快速逼近潜在最优解. 为规避局部最优陷阱, 引入 TAO 算子, 动态调整搜索方向, 确保算法在全局范围内持续探索. 在每次迭代中, 依据新解的适应度表现, 更新种群位置, 经过多轮迭代优化, 最终获取 LSTM 网络超参数的最优组合.

4) 模型训练: 达到最大迭代次数后, 获得最优解 X_b , 将最优解输入 LSTM 神经网络中进行进一步训练, 再通过网络预测直到达到最优的输出.

5) 进行预测: 使用训练好的模型对未来的电力负荷进行预测, 并输出结果.

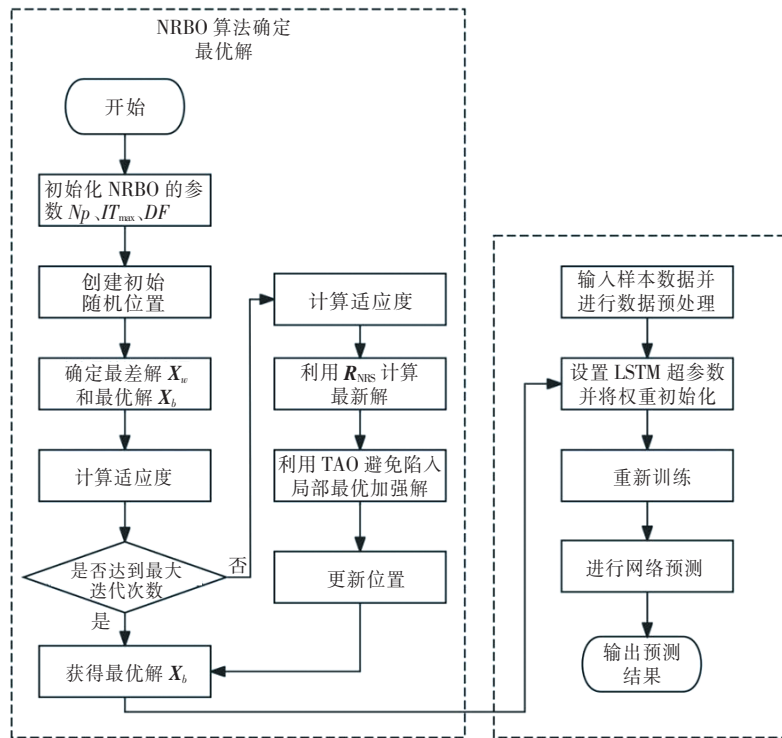


图 3 NRBO-LSTM 模型流程图
Fig. 3 Flowchart of NRBO-LSTM model

3 预测结果与对比分析

3.1 数据集描述与处理

本文所采用的是澳大利亚开放数据集, 选取数据集中 2009 年 1 月 1 日至 2010 年 12 月 31 日的电力负荷数据集作为实验数据. 采样间隔为 0.5 h, 将采样后所得的数据作为输入部分, 对数据进行预处理和归一化. 归一化处理如下式:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (26)$$

式中: x' 为归一化后的结果; x 为原始数据集; x_{\min} 为数据中的最小值; x_{\max} 为数据中的最大值. 接着将处理完毕的数据按照 7:2:1 的比例划分为训练集、测试集、验证集.

3.2 评价标准

为了评估 NRBO-LSTM 在电力负荷预测中的性能, 选取各模型预测精度评价指标中的 $RMSE$ 、 MAE 、 $MAPE$ 和 R^2 来进行评估, $RMSE$ 和 MAE 可以表明预测误差的大小, $MAPE$ 可以了解预测误差相对于真实负荷的大小, R^2 则可以显示出模型对负荷变化的解释程度. 综合使用这些指标可以全面评估电力负荷预测模型的性能. 所有模型选择 $RMSE$ 作为适应度函数, 选择其中适应度函数最优的参数作为寻优结果. 各项误差指标计算表达式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (27)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|, \quad (28)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (29)$$

$$R^2 = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}, \quad (30)$$

式 (27) ~ 式 (30) 中: \hat{y}_i 为预测值; y_i 为真实值; \bar{y}_i 为所有真实值的平均值; $RMSE$ 为衡量预测结果与实际观测值之间差异的指标; MAE 为对预测误差绝对值的平均值进行衡量的指标; $MAPE$ 为预测误差相对于实际值的百分比平均值. 以上 3 个数越小表示模型的拟合效果越好、预测准确性越高、相对误差越小. R^2 为介于 0 和 1 之间的值, 用于评估模型拟合程度的指标, 其数值越接近 1 表示模型对数据的拟合效果越好.

3.3 NRBO-LSTM 模型测试分析

为了评估 NRBO-LSTM 模型的效能, 本文通过电力负荷的数据进行不断的训练和预测, 同时对比优化前后的 LSTM 模型性能. 通过利用 NRBO 对标准 LSTM 模型的正则化系数、初始学习率以及隐藏层节点数量进行优化调整. 优化前后的参数变化如表 1 所示. 根据表格数据, 可以观察到, 经过 NRBO 优化, LSTM 模型的正则化系数和隐藏层节点数量有所减少, 而初始学习率有所提高. 这一变化说明, 引入 NRBO 的 LSTM 模型在拟合能力上有所增强, 并且有效减少了网络结构的复杂性. 这样的优化显著缓解了 LSTM 模型的过拟合现象.

表 1 优化前后参数对比

Tab. 1 Comparison of parameters before and after optimization

参数名称	优化前	优化后
正则化系数	0.005 6	0.002 1
初始学习率	0.000 1	0.010 0
隐藏层节点数	64	14

图 4 展示了包含 20 个区间的误差直方图. 从该图中可以明显看出, 在优化之前, LSTM 模型的误差范围和误差值均较为显著. 而在采用 NRBO 进行优化之后, LSTM 模型的误差范围和误差值均有显著降低. 这一结果充分说明 NRBO 显著提升了 LSTM 模型的预测准确性.

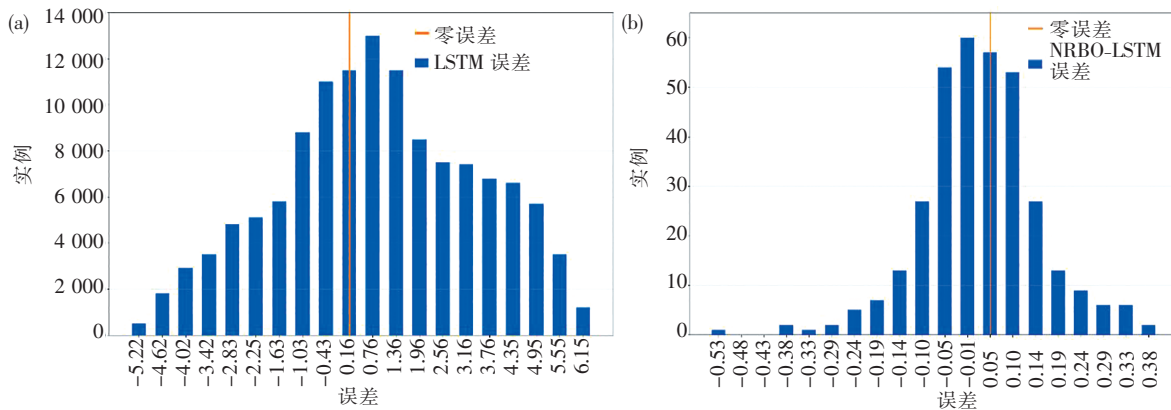


图 4 (a) LSTM 误差直方图; (b) NRBO-LSTM 误差直方图

Fig. 4 (a) Histogram of LSTM error ; (b) Histogram of NRBO-LSTM error

3.4 各模型对比分析

为了进一步验证所提出的基于 NRBO-LSTM 模型对电力负荷的预测效能, 选取 5 种预测方法与 NRBO-LSTM 进行比较, 这 5 种方法分别是 LSTM、Transformer、Autoformer、遗传算法优化反向传播 (GA-BP) 神经网络以及蜣螂算法优化的长短时记忆网络 (DBO-LSTM) 进行了实验对比. 为了确保实验结果的公平性, 消除数据处理对结果的影响, 所有模型的输入数据均经过相同的预处理. 在模型参数设置方面, 所有模型的学习率均设置为 0.000 1, Dropout 值设置为 0.1, 批次大小都设置为 32, 训练轮数为 100, 并使用早停机制.

此外将 GA-BP 模型的种群大小设置为 50, 最大迭代次数设置为 100, 交叉概率为 0.8, 变异概率为 0.1; LSTM 模型的隐藏层维度设置为 128、num.layers 为 2 层; DBO-LSTM 模型的种群大小设置为 50, 最大迭代次数设置为 100, 损失函数设置为 MSELoss, 扰度系数设置为 0.1; NRBO-LSTM 模型的种群大小设置为 50, 最大迭代次数设置为 100, DF 控制因子设置为 0.4; 将 Transformer 模型和 Autoformer 模型的隐藏层维度设置为 128、注意力头数设置为 8、编码器层数设置为 2, 解码器中的层数设置为 1. 在此基础上, 分别进行实验来保证实验的公平性. 所有实验均在搭载 GeForce RTX 4090 (89 501 MB 显存) 的超星 PC 移动工作站上, 使用 Matlab R2023b 软件完成.

这些方法与 NRBO-LSTM 的预测效果进行对比, 结果如图 5 所示, 可见 NRBO-LSTM 的预测效果更加优异.

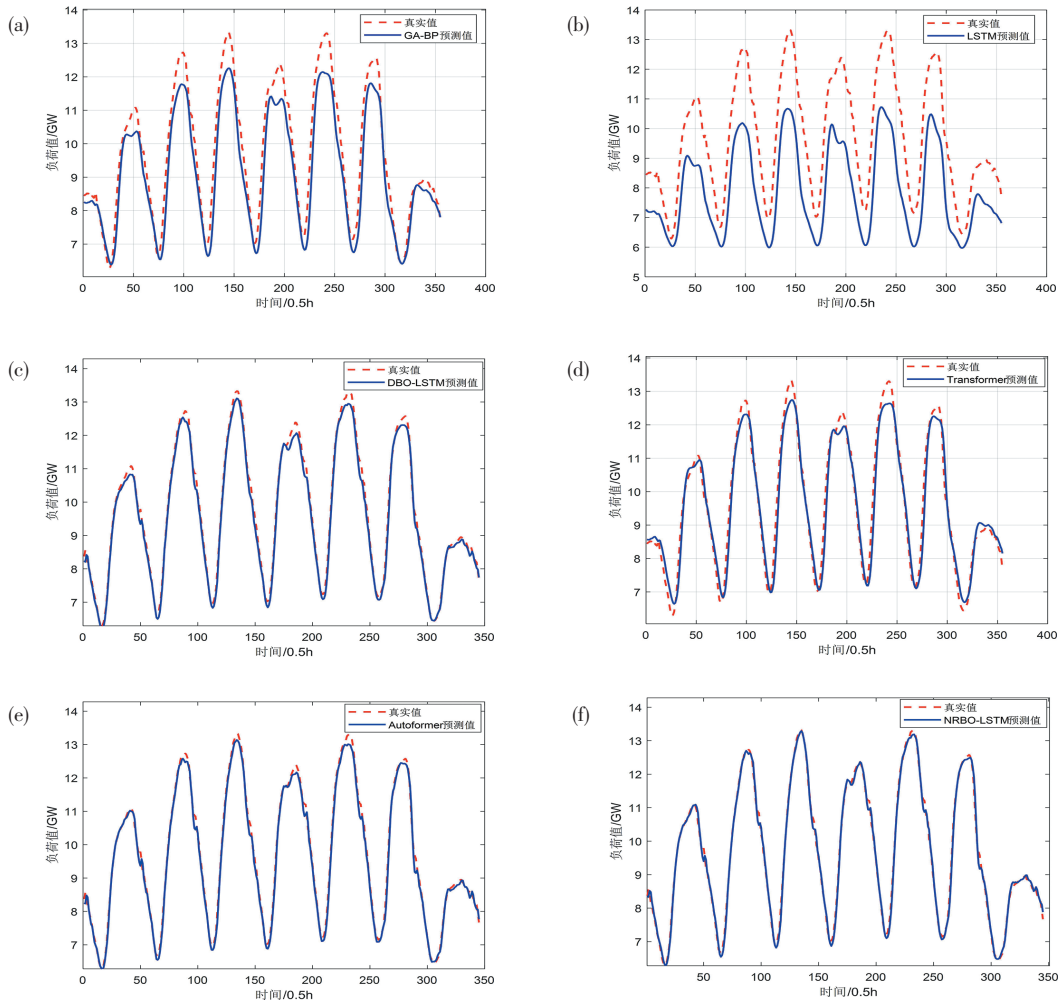


图5 (a) LSTM 预测效果图; (b) GA-BP 预测效果图; (c) Transformer 预测效果图;

(d) DBO-LSTM 预测效果图; (e) Autoformer 预测效果图; (f) NRBO-LSTM 预测效果图

Fig. 5 (a) LSTM prediction effect diagram; (b) GA-BP prediction effect diagram; (c) Transformer prediction effect diagram; (d) DBO-LSTM prediction effect diagram; (e) Autoformer prediction effect diagram; (f) NRBO-LSTM prediction effect diagram

表 2 展示了不同模型在电力负荷预测任务中的性能评价指标. NRBO-LSTM 模型凭借其 R^2 值为 0.990 57, 在所有模型中表现出最高的预测精度. 其 $RMSE$ 、 $MAPE$ 和 MAE 分别为 0.198 95、0.010 009 和 0.136 25, 这些指标表明了其误差小、线性相关性强和拟合度高的特点. 具体来看, 与 Autoformer、DBO-LSTM、Transformer、GA-BP 和 LSTM 模型相比, NRBO-LSTM 在 $RMSE$ 上分别下降了 21.51%、42.01%、47.43%、56.03%、66.44%; $MAPE$ 分别下降了 31.16%、45.18%、53.19%、65.87%、72.09%; MAE 分别下降 34.97%、49.97%、58.27%、69.31%、75.85%; 同时 R^2 提高了 0.523%、2.728%、3.399%、8.085%、15.933%. 这些改进进一步凸显了 NRBO-LSTM 在预测性能上的优势.

表 2 6 种模型性能指标

Tab. 2 Performance indexes of the six models

算法名称	RMSE/%	MAPE/%	MAE/%	R^2
NRBO-LSTM	0.198 95	0.010 009	0.136 25	0.990 57
Autoformer	0.253 46	0.014 582	0.209 53	0.985 34
DBO-LSTM	0.343 57	0.018 259	0.272 36	0.963 29
Transformer	0.378 44	0.021 382	0.326 48	0.956 58
GA-BP	0.452 43	0.029 326	0.443 92	0.909 72
LSTM	0.592 88	0.035 863	0.564 12	0.831 24

从图 6 中可以看出, NRBO-LSTM 模型相比于其他 5 种模型来说, 它的拟合效果达到了最好, R^2 值高达 0.990 57. 总体来讲, NRBO-LSTM 模型各方面都优于其他 5 种模型, 从而更高效地进行负荷预测.




图 6 (a) LSTM 拟合图; (b) GA-BP 拟合图; (c) Transformer 拟合图; (d) DBO-LSTM 拟合图; (e) Autoformer 拟合图; (f) NRBO-LSTM 拟合图

Fig. 6 (a) LSTM fitting plot; (b) GA-BP fitting plot; (c) Transformer fitting plot; (d) DBO-LSTM fitting plot; (e) Autoformer fitting plot; (f) NRBO-LSTM fitting plot

4 结论与展望

1) 该文介绍了一种新的电力负荷时序预测模型,该模型基于 NRBO 算法对 LSTM 进行优化,并用于预测电力负荷,取得了显著的成果,其 RMSE 值为 0.198 95, MAPE 值为 0.010 009, MAE 值为 0.136 25, R^2 值为 0.990 57. 这些指标表明,结合了 NRBO 算法的 LSTM 模型在时序预测任务中具有较高的准确性和可靠性.

2) 采用 LSTM 模型对电力系统负荷进行预测,其中超参数的设置,如学习率、迭代次数和隐藏层神经元数量,对预测结果的精度有显著影响.为了提高预测模型的精度,本文提出了一种基于 NRBO-LSTM 的电力负荷预测方法.结果显示,该方法通过迭代优化,以模型预测值与真实值的均方差作为适应度函数,寻找到最佳的超参数组合.通过这一优化过程,建立了一个更精确的预测模型,从而提升了预测的精度.

3) 在电力负荷时序预测任务中, NRBO-LSTM 模型与 LSTM、GA-BP、Transformer、DBO-LSTM 和 Autoformer 模型进行了对比.实验结果显示, NRBO-LSTM 模型在所有评估指标上都显著优于其他模型,展现了卓越的拟合能力和预测准确性.这表明 NRBO-LSTM 模型能够更有效地预测电力负荷,为实际应用提供了可靠的技术支持.

以上结论表明,本文提出的模型将 LSTM 与 NRBO 优化算法进行了融合,由于 LSTM 对长序列的性能始终不太稳定,通过 NRBO 优化算法寻找最佳的超参数组合,从而提升了混合后整体算法的预测精度和良好的鲁棒性.然而目前该模型在数据量偏大时,仍然有计算复杂度高、耗时长的问题.下一步将考虑引用 Transformer 来实现序列间的建模从而降低计算开销,提高预测模型的效率以及准确性.并考虑引入更多类型的数据,如节假日特征,以提升预测的全面性和准确性.

参 考 文 献

- [1] 唐贤伦,陈洪旭,熊德意,等.基于极端梯度提升和时间卷积网络的短期电力负荷预测[J].高电压技术,2022,48(8):3059-3067.
- [2] 祝少卿,张钧皓,于禄霖,等.基于 QPSO-LSTM 的短期电力负荷预测[J].信息记录材料,2024,25(2):240-242.
- [3] 多立,段炼,陈菁,等.基于 WEKPCA 与深度学习的短期电力负荷预测[J].电力信息与通信技术,2020,18(10):34-41.
- [4] 孙超,吕奇,朱思瞳,等.基于双层 XGBoost 算法考虑多特征影响的超短期电力负荷预测[J].高电压技术,2021,47(8):2885-2898.
- [5] 邱雪.一种基于 LSTM 算法的城市短期电力负荷预测方法[C]//中国电机工程学会电力通信专业委员会.中国电机工程学会电力通信专业委员会第十四届学术会议论文集,2024:190-192.
- [6] 罗凤章,张旭,杨欣,等.基于深度学习的综合能源配电系统负荷分析预测[J].高电压技术,2021,47(1):23-32.
- [7] MAMUN A A, SOHEL M, MOHAMMAD N, et al. A comprehensive review of the load forecasting techniques using single and hybrid predictive models[J]. IEEE Access, 2020, 8: 134911-134939.
- [8] AHMAD T, ZHANG H C, YAN B. A review on renewable energy and electricity requirement forecasting models for smart grid and buildings[J]. Sustainable Cities and Society, 2020, 55: 102052.
- [9] 陈晓华,吴杰康,蔡锦健,等.基于猎人猎物优化算法优化 BiLSTM 的电力负荷短期预测[J].山东电力技术,2024,51(4):64-71.
- [10] 查云龙,茅玉龙,卜宇,等.基于 BasicNet-LSTM 的短期电力负荷预测模型构建[J].中国设备工程,2024

- (11):139-141.
- [11] 简定辉,李萍,黄宇航,等. 基于 MIC-ResNet-LSTM-BP 的短期电力负荷预测[J]. 计算机仿真,2024,41(4):75-79,499.
- [12] 印江,戴春萍,袁华保峰,等. 基于 APSO-LSTM 模型的短期电力负荷预测[J]. 科技与创新,2023(2):47-51.
- [13] 王旭. 基于 GWO-LSTM 的短期电力负荷预测[J]. 兰州文理学院学报(自然科学版),2023,37(1):66-69.
- [14] 高超,孙谊嫒,赵洪峰,等. 改进的黑猩猩算法优化 LSTM 的短期电力负荷预测[J]. 现代电子技术,2022,45(21):122-126.
- [15] 朱莉,高靖凯,朱春强,等. 基于分量感知动态图 Transformer 的短期电力负荷预测[J]. 计算机应用研究,2025,42(2):381-390.
- [16] 赵来奇. 基于改进 Autoformer 融合模型的电力负荷预测[J]. 信息与电脑,2025,37(6):96-99.
- [17] 李盖,林余杰,吴成坚,等. 基于 LSTM 组合模型的短期电力负荷预测[J]. 电力与能源,2023,44(5):429-436,440.
- [18] WANG X T, DUAN Z H, LIU L Q, et al. Multi-Timescale Load Forecast of Large Power Customers Based on Online Data Recovery and Time Series Neural Networks[J]. Journal of Circuits, Systems and Computers, 2022, 31(5):22500888.
- [19] SOWMYA R, PREMKUMAR M, JANGIR P. Newton-Raphson-based optimizer: A new population-based metaheuristic algorithm for continuous optimization problems[J]. Engineering Applications of Artificial Intelligence, 2024, 128: 107532.

(责任编辑:夏金玉、朱碧云)