

基于改进特征模态分解的 NRBO-LSTM 短期电力负荷预测

何长江, 陈耀辉, 袁世斌, 余琳珊

(三峡大学 电气与新能源学院, 湖北 宜昌 443002)

摘要: 针对传统方法在电力负荷预测中存在的多时间尺度无法精准捕捉、深度模型超参数难以自适应优化等问题, 构建了一种基于改进特征模态分解 (FMD) 与牛顿拉夫逊算法 (NRBO) 优化长短期记忆网络 (LSTM) 的短期负荷预测模型; 该模型在特征模态分解模块中引入辅助白噪声以抑制模态混叠, 并将传统峰度模态筛选改进为基于模态能量的筛选方法, 以剔除低能量噪声模态并增强分解结果的稳定性, 基于上述改进将原始负荷序列分解为一系列具有不同中心频率的本征模态函数, 同时引入 NRBO 算法对 LSTM 的超参数进行全局寻优, 提高模型的收敛速度与泛化性能; 设置多个预测模型进行对比实验, 实验结果表明, 所提的 FMD-NRBO-LSTM 模型的 MAE、RMSE、MAPE 分别为 5.640 3 kW, 7.282 2 kW 和 1.543 3%, 效果均优于 LSTM、CNN-GRU-LSTM、CNN-GRU-LSTM-Attention 三种对比模型。验证了所提模型的预测精度与泛化性能。

关键词: 特征模态分解; 长短期记忆网络; 牛顿-拉夫逊优化算法; 多尺度特征; 短期电力负荷预测

Short-Term Power Load Forecasting Model Based on Improved Feature Mode Decomposition and NRBO-LSTM

HE Changjiang, CHEN Yaohui, YUAN Shibin, YU Linshan

(College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China)

Abstract: To address the issues of traditional methods in power load forecasting, such as inability to accurately capture multi-time-scale characteristics and difficulty to adaptively optimize hyperparameters in deep learning models, a short-term load forecasting model based on improved Feature Mode Decomposition (FMD) and a Newton-Raphson-Based Optimization (NRBO) algorithm-optimized Long Short-Term Memory (LSTM) network is proposed. In the feature mode decomposition module, the auxiliary white noise is introduced to suppress mode mixing, and the conventional kurtosis-based mode selection strategy is improved by adopting an energy-based criterion to eliminate low-energy noise modes and enhance the stability of decomposition results. Based on these, the original load sequence is decomposed into a set of intrinsic mode functions with different center frequencies. Meanwhile, the NRBO algorithm is employed to globally optimize the LSTM hyperparameters, thereby improving the convergence speed and generalization capability of the model. Comparative experiments between multiple prediction models are constructed, which shows that the proposed FMD-NRBO-LSTM model reaches the MAE, RMSE, and MAPE by 5.640 3 kW, 7.282 2 kW, and 1.543 3%, respectively, outperforming the LSTM, CNN-GRU-LSTM, and CNN-GRU-LSTM-Attention benchmark models. These results verify the superior prediction accuracy and generalization performance of the proposed model.

Keywords: FMD; LSTM network; NRBO; multi-scale features; short-term power load forecasting

0 引言

随着社会经济发展和居民生活水平提升, 电力负荷呈现出更强的波动性与复杂性。短期电力负荷预测在电

力系统运行调度、资源优化配置及安全稳定运行中具有重要作用^[1]。受经济活动等多种因素影响, 电力负荷序列具有明显的非线性、多尺度和突发波动特征, 传统统

收稿日期:2025-11-29; 修回日期:2026-01-06。

作者简介:何长江(2001-),男,硕士研究生。

引用格式:何长江,陈耀辉,袁世斌,等.基于改进特征模态分解的 NRBO-LSTM 短期电力负荷预测[J].计算机测量与控制, 2026,34(3):76-84,92.

计方法在建模此类复杂特性时预测精度和泛化能力有限, 难以满足现代电力系统对高精度预测的需求^[2]。

近年来大量智能算法与深度学习技术被应用于负荷预测中, 其中支持向量回归 (SVR, support vector regression)^[3]具有良好的泛化能力, 尤其适用于中小规模数据; 随机森林 (RF, random forest)^[4]和梯度提升树 (GBDT, gradient boosting decision tree)^[5]等集成学习方法能够处理复杂的非线性关系。随着深度学习的发展, 卷积神经网络 (CNN, convolutional neural network)^[6]、门控循环单元 (GRU, gated recurrent unit)^[7]以及长短期记忆网络 (LSTM, long short-term memory)^[8]等模型在时序预测中表现突出。文献 [9] 和 [10] 提出了一种使用卷积神经网络—长短期记忆网络 (CNN-LSTM) 的短期电力负荷预测模型。文献 [11] 和 [12] 提出了一种使用 GRU-CNN 的超短期电力负荷预测。然而, 深度学习模型普遍面临两个关键问题: 其一, 负荷数据中普遍存在多尺度特征, 若缺乏有效的多尺度处理机制, 模型对突发变化与低频趋势的学习能力有限; 其二, 深度神经网络结构对超参数高度敏感, 学习率、隐藏层规模与迭代次数等超参数若设置不当, 将导致模型收敛变慢、预测精度下降甚至陷入局部最优。

针对上述问题, 提出了一种短期负荷预测模型。该模型首先利用特征模态分解对原始负荷序列进行自适应分解, 使其在不同时间尺度上表征负荷变化特征, 并通过引入辅助白噪声增强不同频率成分之间的可分性, 从而减弱模态混叠现象; 同时, 将传统基于峰度的模态筛选方式改为基于能量的筛选准则, 以有效剔除低能量噪声分量并保留主要特征模态。在此基础上, 引入 NRBO 算法对 LSTM 的超参数进行全局优化, 以提升模型的预测精度与泛化能力。以某地区电力负荷数据为例开展实验分析, 结果表明, 所提出方法在短期负荷预测精度方面优于对比模型, 具有良好的有效性和实用价值。

1 FMD-NRBO-LSTM 模型

1.1 特征模态分解及改进

1.1.1 特征模态分解

负荷序列通常表现为噪声成分、周期性波动及趋势变化等多尺度特征并存, 传统方法难以充分分离。FMD^[13]通过特征驱动的分解策略, 能够根据信号在频域与时域的特征自适应提取不同模态, 使高频扰动、日周期成分与低频趋势自然分离, 从而抑制模态混叠问题, 保持各模态之间的独立性。

FMD 通过构建自适应的有限冲激响应滤波器组, 并基于数据的瞬时特性优化滤波器系数, 实现数据中不同模态的分离^[14]。该方法利用相关峰度等指标同时考量数据的冲动性与周期性, 在分解过程中自适应地锁定

目标数据对应的模态。其核心优势在于滤波器形状、带宽及中心频率的完全自适应确定。其具体原理如下:

将时域长度为 N 的原始观测序列 $x(n)$ 作为输入, 可将其分解过程转化为带约束条件的问题求解:

$$\begin{cases} \arg \max_{\{f_k(l)\}} \{CK_M(u_k) = \frac{\sum_{n=1}^N (\prod_{m=0}^M u_k(n-mT_s))}{(\sum_{n=1}^N u_k(n)^2)^{M+1}}\} \\ \text{s. t. } u_k(n) = \sum_{l=1}^L f_k(l)x(n-1+l)n \end{cases} \quad (1)$$

式中, $u_k(n)$ 表示第 k 个模态, f_k 表达第 k 个模态及其对应的 FIR 滤波器, L 表示滤波器长度, T_s 表示输入数据的周期, M 表示位移控制参数。

基于特征值迭代分解策略, 求解式 (1) 中的约束问题, 分解模态表示为:

$$u_k = X \cdot f_k \quad (2)$$

其中: X 表示原始数据构建的卷积矩阵。

分解模态量的相关峭度 CK 可表示为:

$$CK_M(u_k) = \frac{u_k^H \mathbf{W}_M u_k}{u_k^H u_k} \quad (3)$$

式中, H 表示共轭转置, u_k^H 表示共轭转置矩阵, \mathbf{W}_M 表示加权相关矩阵。将式 (2) 代入式 (3) 可得:

$$CK_M(u_k) = \frac{f_k^H \mathbf{X}^H \mathbf{W}_M \mathbf{X} f_k}{f_k^H \mathbf{X}^H \mathbf{X} f_k} = \frac{f_k^H \mathbf{R}_{XWX} f_k}{f_k^H \mathbf{R}_{XX} f_k} \quad (4)$$

$$\mathbf{R}_{XWX} f_k = \mathbf{R}_{XX} f_k \lambda$$

上述式子中 \mathbf{R}_{XWX} 表示加权相关矩阵, \mathbf{R}_{XX} 表示相关矩阵。

采用自相关分析来精确估计周期。具体方法是定位自相关频谱的过零点, 并选择该点之后出现的首个局部最大值作为信号的估计周期。输入数据的自相关函数表示如下:

$$R_x(t) = \int_{n-1}^N x(n)x(n+t)dn \quad (5)$$

其中: t 表示滞后时间。为了消除模式混合或冗余模式, 计算两个相邻模态之间的相关系数, 计算方法如下:

$$CC_{pq} = \frac{\sum_{n=1}^N [u_p(n) - \bar{u}_p][u_q(n) - \bar{u}_q]}{\sqrt{\sum_{n=1}^N [u_p(n) - \bar{u}_p]^2} \sqrt{\sum_{n=1}^N [u_q(n) - \bar{u}_q]^2}} \quad (6)$$

式中, \bar{u}_p , \bar{u}_q 分别为相邻模态 u_p , u_q 的均值。

特征模态分解的具体操作步骤总结如下。

步骤 1: 加载原始数据并输入参数, 包括目标模式数 K 和滤波器长度 L 。

步骤 2: 通过汉宁窗初始化 M 个滤波器的 FIR 滤波器组, 并设置迭代计数器 $i=1$ 。

步骤 3: 通过当前滤波器组获得分解模态。

步骤 4: 基于原始数据 $x(n)$ 的自相关谱估计模态周期, 该周期定义为自相关谱过零点后出现的首个局部最大值点, 并据此更新滤波器系数, 完成一次迭代后设置 $i=i+1$ 。

步骤 5: 若迭代次数未达到预设值, 则返回上一步继续迭代优化, 否则进入模态筛选阶段。

步骤 6: 计算所有模态两两之间的相关系数以构建一个 $M \times M$ 的矩阵 CC , 锁定其中相关系数最大的两个模态 CC_{max} , 并计算它们的相关峭度 CK 值, 随后舍弃 CK 较小的模态, 并令 $M = M - 1$ 。

步骤 7: 判断当前模式数 M 是否已达到目标模态数 K , 若未达到, 则返回步骤 3 继续优化与筛选; 若已达到, 则将最终保留的模态作分解结果。

1.1.2 特征模态分解改进

在传统 FMD 方法中, 滤波器组初始化后直接对原始负荷序列分解, 存在以下不足: 1) 容易出现模态混叠, 高频细节丢失, 导致短时负荷突变和尖峰特征提取不充分; 2) 模态筛选依赖峰度来舍弃低峰度模态, 峰度对低幅高频波动不敏感, 且受异常值影响大, 长时间序列计算稳定性差, 噪声模态有时可能被误保留, 降低负荷预测精度。

针对上述问题, 本文对 FMD 处理电力负荷问题分解流程进行了两方面改进:

在步骤 1 中向原始负荷序列中加入零均值、独立同分布的白噪声 $\alpha(n)$:

$$x_i(n) = x(n) + \alpha(n) \quad (7)$$

其中: $x(n)$ 表示原始数据, $x_i(n)$ 表示加入白噪声后的负荷序列。

在步骤 6 中, 将模态能量作为模态筛选指标, 舍弃相关系数最大的模态组中能量较小的模态, 模态能量公式如下:

$$E_k = \sum_{n=1}^N |IMF_k(n)|^2 \quad (8)$$

其中: k 表示模态序号, N 表示信号长度。

传统 FMD 对原始负荷序列进行分解, 滤波器自适应过程易受低频高能量成分主导, 导致不同频段模态混叠, 高频细节被平滑, 短时负荷突变和尖峰特征难以充分提取; 同时, 基于峰度的模态筛选对低幅高频波动不敏感, 且易受异常值干扰, 稳定性不足。针对上述不足, 改进 FMD 分解阶段引入零均值白噪声, 使信号在全频段内获得均匀激励, 从而增强滤波器组对不同频率成分的探索能力, 减弱低频高能量成分对滤波过程的主导作用, 使高频细节能够被更充分地分离出来。通过该方式, 分解得到的各模态在频谱分布上更加清晰, 不同时间尺度之间的边界更加明确, 缓解分解后的模态分量间混叠问题; 在模态筛选阶段, 本文采用模态能量替代

传统峰度作为判别指标, 通过量化各分量对原始负荷信号的整体贡献程度, 稳定保留能量占比较高、具有实际物理意义的高频和中频模态, 同时有效剔除能量较低、主要反映随机扰动的噪声分量。

流程如图 1 所示。

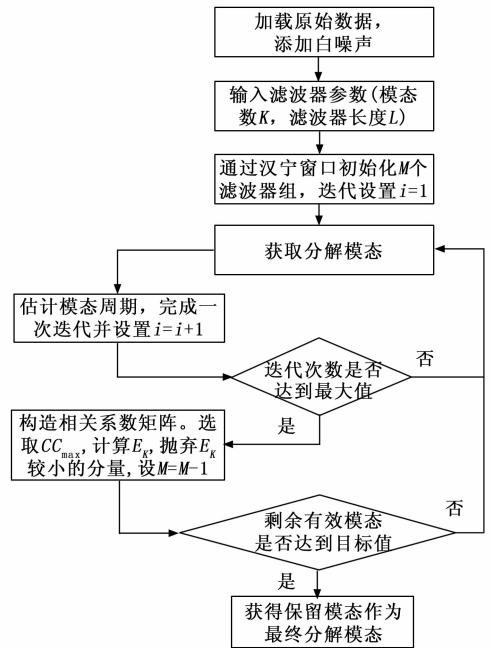


图 1 改进特征模态分解步骤流程图

1.1.3 FMD 分解参数选取

1) 白噪声比例:

为评估不同白噪声幅值下的模态的混叠抑制效果, 可通过模态正交性检验分析各模态之间的相关程度, 从而判断模态混叠的抑制效果。观察白噪声标准差与负荷序列的标准差倍数与模态间正交性指数的关系如图 2 所示。




图 2 白噪声幅值选取

图中显示随着噪声幅值的增加噪声幅值较低时正交性数值偏高, 混叠情况严重, 在 0.1 至 0.3 倍标准差范围内正交性数值较低, 混叠情况被抑制, 噪声倍数大于 0.4 时, 混叠情况严重。综合以上分析, 该分解噪声倍数比例取信号标准差的 0.1 倍。

2) 模态能量阈值:

为评估不同能量水平模态对原始负荷信号的表征能力, 模态能量阈值对应的模态分量与时域原始信号之间

的平均相关系数作为评价指标, 刻画各能量层级模态对原始信号信息的贡献程度, 确定能量阈值。




图 3 模态能量阈值选取

由图 3 中的结果可以看出, 当阈值超过图中第二个标记点后, 相关系数显著提高并保持在较高水平, 表明此时所保留的模态分量与原始信号具有较强相关性。设定此标点为能量阈值 $\epsilon = 18.772$ 。

1.2 长短期记忆网络

LSTM 是一种特殊的循环神经网络, 传统 RNN 在处理长时间序列时, 较早的信息会逐渐丢失。为了解决这一问题, LSTM 引入了门控机制和记忆单元, 一种特别设计来解决标准循环神经网络 RNN 处理长序列数据时遇到的梯度消失或梯度爆炸问题, 使模型能够有效地学习和处理时间序列数据中的长期依赖特征。通过对信息进行有选择的保留或遗忘, 该网络能够更好地捕捉长时间间隔下的关联特征。

LSTM 通过记忆单元中的 3 个门控制结构的来控制信息的流动, 分别是遗忘门、输入门和输出门。内容如下。

遗忘门: 用于决定从记忆单元中去弃哪些信息, 它通过一个 sigmoid 激活函数来实现, 其输出值介于 0 和 1 之间。公式如下:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (9)$$

其中: f_t 表示遗忘门在时间步 t 的输出, σ 表示 sigmoid 激活函数, W_f 表示输入到遗忘门和隐藏层到遗忘门的权重矩阵, b_f 表示遗忘门的偏置向量。该门读取 h_{t-1} 和 x_t 输出 x_t , 当 f_t 接近 0 时, 表示要丢弃相应的信息, 当 f_t 接近 1 时, 表示保留信息。

输入门: 负责决定将哪些新信息添加到记忆单元中。它由两部分组成, 一部分表示通过 sigmoid 函数计算得到的输入门值 i_t , 另一部分表示通过 tanh 函数计算得到的候选值 \tilde{C}_t 。计算公式如下:

$$\begin{aligned} i_t &= \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t &= \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \end{aligned} \quad (10)$$

其中: i_t 表示输入门在时间步 t 的输出, \tilde{C}_t 表示候选值, W_i , W_C 分别表示相应的权重矩阵, b_i 和 b_C 表示偏置向量。

记忆单元更新: 根据遗忘门和输入门的输出, 对记忆单元进行更新。公式为:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (11)$$

其中: 符号 * 表示逐元素相乘, C_{t-1} 表示上一时刻的记忆单元, \tilde{C}_t 表示当前时刻更新后的记忆单元。

输出门: 输出门用于决定记忆单元中的哪些信息将被输出。它首先通过 sigmoid 函数计算输出门值 o_t , 然后根据记忆单元 C_t 和输出门值 o_t 计算最终的输出 h_t 。公式如下:

$$\begin{aligned} o_t &= \sigma(W_o [h_{t-1}, x_t] + b_o) \\ h_t &= o_t * \tanh(C_t) \end{aligned} \quad (12)$$

其中: o_t 表示输出门在时间步 t 的输出, h_t 表示当前时刻的隐藏层输出, W_o 表示权重矩阵, b_o 表示偏置向量。

1.3 牛顿拉夫逊优化算法

1.3.1 NRBO 算法

通过模拟自然界中资源的分配和利用来优化问题^[15], 牛顿-拉夫逊优化算法结合牛顿-拉夫逊搜索机制 (NRSR, newton-raphson search rules) 与陷阱规避算子 (TAO, trap-avoids operators), 并借助多个向量集合对全局搜索空间进行充分探索。通过牛顿-拉夫逊方法 (NRM, ewton-Raphson method) 对潜在优良区域进行识别, 从而确定更具优势的搜索方向, 并据此生成一条更优的参数更新路径。NRBO 算法被用于优化 FMD-LSTM 模型的关键超参数, 包括 LSTM 隐藏层单元数、学习率以及迭代轮数等。通过 NRBO 的全局搜索和牛顿-拉夫逊局部精调机制, 能够自适应选择最优的超参数组合, 使 LSTM 充分地捕捉负荷序列中的多尺度特征, 同时提升预测精度和模型稳定性。预测均方根误差作为评价指标, 被用来指导 NRBO 对候选参数的优劣进行打分, 从而实现迭代优化直至收敛。NRBO 优化过程如下。

1) 种群初始化: NRBO 通过在候选解的边界内生成初始随机种群来启动对最优解的搜索。鉴于存在 N 个种群, 每个种群都涵盖模糊的决策变量或向量。这些变量或向量组成搜索空间的初始集合。以下公式生成随机种群:

$$\begin{aligned} x_j^n &= lb + rand \times (ub - lb), \\ n &= 1, 2, \dots, N, j = 1, 2, \dots, dim \end{aligned} \quad (13)$$

其中: x_j^n 表示 n 个总体的第 j 个维度的位置; ub 表示 x_j 上界; lb 表示 x_j 下界; $rand$ 表示 0-1 的随机数; n 表示第 n 个种群; N 表示总体的种群数量; dim 表示维度。

下式表示所有维度的种群矩阵 X_n :

$$X_n = \begin{bmatrix} x_1^1 & x_2^1 & \dots & x_{dim}^1 \\ x_1^2 & x_2^2 & \dots & x_{dim}^2 \\ \vdots & \vdots & \ddots & \vdots \\ x_1^N & x_2^N & \dots & x_{dim}^N \end{bmatrix}_{N \times dim} \quad (14)$$

其中： x_{dim}^N 表示第 N 个种群的第 dim 个维度的位置。

2) NRSR 搜索：利用 NRSR 搜索规则促进勘探趋势并且能够加收敛，NRSR 是基于 NRM 的概念，NRM 从一个假定的初始解开始，并沿着一个确定的方向前进到下一个位置。相邻的位置 X 分别用 $x_n + \Delta x$ 和 $x_n - \Delta x$ 表示。在这种情况下，NRBO 将位置 X_b 替换为位置 $x_n - \Delta x$ ，因为 X_b 在其邻域中具有比位置 x_n 更优的位置，同时将位置 $x_n + \Delta x$ 替换为位置 X_w ，因为 X_w 在其邻域内具有比位置 x_n 更差的位置。这种方法使用位置。NRSR 的公式表示如下：

$$NRSR = \frac{randn \times (X_w - X_b) \times \Delta x}{2 \times (X_w + X_b - 2 \times x_n)} \quad (15)$$

其中： $randn$ 表示均值为 0 方差为 1 的正态分布随机数， Δx 表示相对位置变量。 x_n 表示种群 n 的位置。 X_w 表示最差位置， X_b 表示最优位置。 Δx 的表达式如下：

$$\Delta x = rand(1, dim) \times |X_b - X_n^T| \quad (16)$$

其中： X_n^T 表示 X_n 经过 T 次迭代等得到的矩阵。 X_b 表示最优解， $rand(1, dim)$ 是有 dim 维度的决策变量的随机数。用一个自适应系数来增强算法。此自适应系数的公式如下：

$$\delta = \left(1 - \left(\frac{2 \times T}{MaxT}\right)^5\right) \quad (17)$$

其中： T 表示当前的迭代次数，而 $MaxT$ 表示最大的迭代次数。此系数会在迭代过程中自动进行调整，这样能够保证探索阶段和开发阶段保持平衡。此系数的值的范围是 $(-1, 1)$ 。通过 NRSR 获得跟新之后的位置，更新位置表示如下：

$$x_{n+1} = x_n - NRSR \quad (18)$$

为了进一步改进提出的 NRBO 方法，引入参数 ρ ，它的作用是引导种群朝着正确的方向前进。参数 ρ 的表达式如下所示：

$$\rho = a \times (X_b - X_n^T) + b \times (X_{r_1}^T - X_{r_2}^T) \quad (19)$$

其中： a 和 b 表示 $0 \sim 1$ 之间的随机数。 r_1 和 r_2 表示总体中随机选择的不同整数。 $X_{r_1}^T$ 表示 X_{r_1} 经过 T 次迭代等得到的矩阵。 $X_{r_2}^T$ 表示 X_{r_2} 经过 T 次迭代等得到的矩阵。

y_w 和 y_b 分别表示 Z_{n+1} 和 x_n 得到两个向量的位置，公式表达如下：

$$\begin{aligned} y_w &= r_1 \times (Mean(x_{n+1} + x_n) + r_1 \times \Delta x) \\ y_b &= r_1 \times (Mean(x_{n+1} + x_n) - r_1 \times \Delta x) \end{aligned} \quad (20)$$

其中： $Mean(x_{n+1} + x_n)$ 表示求取 $Z_{n+1} + x_n$ 的均值。 r_1 表示 $0 \sim 1$ 的随机数。

位置更新，矢量当前的位置 x_n^T 可由下式表示：

$$\begin{aligned} X1_n^T &= x_n^T - \left(\frac{randn \times (y_w - y_b) \times \Delta x}{2 \times (y_w + y_b - 2 \times x_n)}\right) + \\ &(a \times (X_b - X_n^T)) + b \times (X_{r_1}^T - X_{r_2}^T) \end{aligned} \quad (21)$$

其中： $X1_n^T$ 表示通过更新 X_n^T 而得到的新矢量。

通过上式中得到的结果代替 X_b 构造最新的新矢量 $X2_n^T$ ：

$$\begin{aligned} X2_n^T &= x_n^T - \left(\frac{randn \times (y_w - y_b) \times \Delta x}{2 \times (y_w + y_b - 2 \times x_n)}\right) + \\ &[a \times (X1_n^T - X_n^T)] + b \times (X_{r_1}^T - X_{r_2}^T) \end{aligned} \quad (22)$$

对于局部搜索有局限性，NRBO 同时使用上述公式来改善多样化和强化阶段。下一次迭代期间的新位置矢量用下列公式表示：

$$\begin{aligned} x_n^{T+1} &= r_2 \times (r_2 \times X1_n^T + (1 - r_2) \times X2_n^T) + (1 - r_2) \times X3_n^T \\ X3_n^T &= X_n^T - \delta \times (X2_n^T - X1_n^T) \end{aligned} \quad (23)$$

其中： x_n^{T+1} 表示新位置矢量。 $X1_n^T$ 表示通过更新 X_n^T 而得到的新矢量。 $X2_n^T$ 表示通过更新 $X1_n^T$ 而得到的新矢量。 $X3_n^T$ 表示通过更新 $X1_n^T$ 和 $X2_n^T$ 而得到的新矢量。 δ 表示增强算法的自适应系数。 X_n^T 表示第 n 个种群迭代 T 次的矩阵。

3) 陷阱规避操作：

TAO 操作能够提高 NRBO 处理实际问题的有效性，避免局部最优。通过组合最佳位置 X_b 和当前矢量位置的 $X1_n^T$ 来得到增强 X_{TAO}^T 的方法。如果 $rand$ 的值小于决策因子 DF，使用以下公式产生 X_{TAO}^T ，DF 取 0.5。

$$\begin{cases} X_{TAO}^T = X_n^{T+1} + \theta_1 \times (\mu_1 \times x_b - \mu_2 \times X_n^T) + \\ \quad \theta_2 \times \delta \times (\mu_1 \times Mean(X^T) - \mu_2 \times X_n^T), \\ \text{if} & \mu_1 < 0.5 \\ X_{TAO}^T = x_b + \theta_1 \times (\mu_1 \times x_b - \mu_2 \times X_n^T) + \\ \quad \theta_2 \times \delta \times (\mu_1 \times Mean(X^T) - \mu_2 \times X_n^T), \\ \text{Otherwise} \\ X_n^{T+1} = X_{TAO}^T \end{cases} \quad (24)$$

其中： X_n^{T+1} 表示新位置矢量。 X_n^T 表示第 n 个种群迭代 T 次的矩阵， x_b 表示种群最佳位置。 $Mean(X_n^T)$ 表示取 X_n^T 的均值。 X_{TAO}^T 表示增强后的矢量位置。 θ_1 和 θ_2 分别表示 $(-1, 1)$ 和 $(-0.5, 0.5)$ 之间的随机数。 μ_1 和 μ_2 表示随机数，由以下公式生成：

$$\begin{aligned} \mu_1 &= \beta \times 3 \times rand + (1 - \beta) \\ \mu_2 &= \beta \times rand + (1 - \beta) \end{aligned} \quad (25)$$

其中： β 表示二进制变量。引入这些随机数有助于增强种群多样性，使算法能脱离局部最优，提高搜索的全局性。

1.3.2 优化算法对比

为观测 NRBO 对 LSTM 参数的优化效果，设置 NRBO、PSO^[16]、GWO^[17] 和 WOA^[18] 4 种优化算法进行对比实验，评估不同算法在预测精度与计算效率上的表现，实验数据集包含 2 400 条负荷样本，训练集与测试集比例设置为 9 : 1，预测结果 RMSE 作为目标函数。实验结果如图 4 所示，NRBO 最终获得了最低的预测误差。从收敛过程可以看出，PSO、GWO 和 WOA 在迭代初期下降速度较快，但容易过早陷入局部最优，其

RMSE 在较早阶段即趋于稳定, 后续难以进一步改善; NRBO 虽然前期收敛速度相对较慢, 但在迭代过程中能够持续降低目标函数值, 表现出更强的全局搜索能力和跳出局部最优的能力, 从而在后期获得更优的超参数组合, 使 LSTM 具有更高的预测精度和更稳定的泛化性能。




图 4 优化算法对比

2 预测流程和评价指标

2.1 预测模型流程

步骤 1: 数据清洗, 该阶段主要针对缺失值、离群点及相关性较弱的样本进行处理。为保证序列的连续性与整体特征的一致性, 对异常样本进行剔除和修正, 采用线性差值方法补全缺失数据, 从而在保留原始数据统计特性的基础上提升数据质量与模型输入的完整性。

步骤 2: 特征模态分解, 通过自适应算法特性将原始负荷序列分解为 K 组 IMF 分量, 这些分量具有更高的平稳性与更明确的时间尺度特征, 为后续建模提供更具判别性的输入特征。目标模态设置为 $K=5$, 滤波器初始长度设置为 $L=24$ 。

步骤 3: 归一化数据, 对原始全年小时负荷数据进行归一化处理, 这一处理能够显著加快模型的收敛速度, 提升训练过程的数值稳定性, 并帮助模型更有效地捕捉数据中潜在的规律模式。对原始负荷序列采用 Min-Max 归一化^[19-20]方法进行预处理, 通过将原始数据按比例映射到固定区间 $[0, 1]$, 保持数据的原始分布形态并统一量纲。从而避免不同量级数据对模型训练造成的影响, 提升模型的收敛速度与稳定性。其公式如下:

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

其中: x 表示原数据, x_{\max} 表示数据最大值, x_{\min} 表示数据最小值, x' 表示归一化后的数据。模型预测结果通过反归一化公式还原至真实量纲。

步骤 4: 负荷预测: 在模型训练阶段, 从数据集中选取前 90% 数据样本构建训练集, 后 10% 为测试集。将训练集输入至 NRBO-LSTM 模型进行参数学习。模型训练完成后, 将测试集输入模型并对其输出结果进行反归一化处理, 获得最终的电力负荷预测结果。

预测流程如图 5 所示, 其中数据清洗环节确保了原

始数据的完整性与可靠性, 为后续模型训练提供了数据基础; 特征模态分解将原始负荷序列转化为更加平稳且具有明确时间尺度特征的 IMF 分量, 采用 Min-Max 归一化进一步保证了各输入特征在同一量级下参与模型训练, 提高了训练过程的收敛速度与稳定性。在此基础上, 引入 NRBO 算法对 LSTM 神经网络的超参数进行自适应搜索, 构建 NRBO-LSTM 预测模型。该模型能够充分挖掘各 IMF 分量的时序依赖关系, 对每个分量进行精准预测。将各 IMF 子序列的预测结果进行叠加, 并通过反归一化处理还原至原始数据尺度, 最终得到完整的负荷预测结果。该流程充分发挥了信号分解、优化算法与深度学习模型的协同优势。

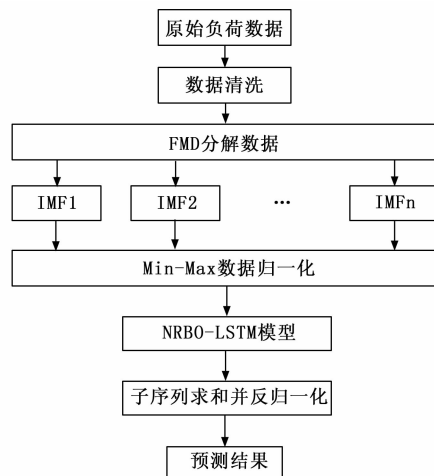


图 5 电力负荷预测流程图

2.2 评价指标

为全面评估模型的预测性能, 选取平均绝对误差 (MAE)、均方根误差 (RMSE) 和平均绝对百分比误差 (MAPE) 三类指标, 从不同角度衡量预测结果的准确性与稳定性。三种指标数学表达如下:

$$\begin{aligned} MAE &= \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \\ RMSE &= \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \\ MAPE &= \frac{100\%}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \end{aligned} \quad (27)$$

其中: y_i 表示真实值, \hat{y}_i 表示预测值, N 表示样本数量。

平均绝对误差用于衡量模型整体预测偏差的平均水平。对于 NRBO 优化的 FMD-LSTM 模型而言, MAE 能直观反映模型对负荷序列主趋势的拟合能力, 误差越小, 说明模型在大多数时间点上能够较准确地给出负荷预测结果, 具有较好的整体预测精度。

均方根误差对较大偏差更加敏感, 主要用于评价模型在面对负荷突变时的稳定性。对于本文构建的 NR-

BO-FMD-LSTM 模型而言, *RMSE* 能揭示模型在异常波动、峰值负荷及高变化速率区间的误差情况, *RMSE* 越小, 说明模型对剧烈波动具有更强的鲁棒性和稳定性。

平均绝对百分比误差反映模型在不同负荷水平下的相对预测误差。采用 *MAPE* 评估模型在不同负荷时的泛化表现, 反映其在不同时间段和负荷水平下的预测性能。较低的 *MAPE* 表明模型在不同运行状态下均能保持较高的精度。

3 实验与分析

为验证基于 NRBO-FMD-LSTM 负荷预测模型的可行性, 采用某地智能电表采集系统 (AMI, advanced metering infrastructure)^[21-23] 获取的负荷数据, 共 2 400 个负荷数据样本, 时间分辨率为 1 h。用于验证所提模型的预测性能。由于数据仅来自单一地区且负荷类型有限, 结果主要用于方法有效性的验证。未来工作中, 将考虑引入多地区、多类型负荷数据, 以评估模型的泛化能力。

3.1 数据预处理

数据清洗阶段, 检查负荷数据序列, 其中样本中的空缺值采用线性差值法补齐序列。填补数据后采用 Min-Max 归一化方法, 对数据进行归一化处理, 使归一化后的信号幅值限制在 [0, 1] 区间以消除量纲差异并提升模态分解的稳定性。随后将处理后的负荷序列输入 FMD 算法完成模态分解, 获得由高频到低频逐级变化的 IMF 的模态分量。分解的模态分量如图 6 所示。




图 6 IMF 模态分量

各分量的频谱图如图 7, 图中显示原始负荷序列中的多时间尺度特征: IMF1 包含最高频率成分 0.167 Hz, 对应着 6 小时的周期, 反映了日内特定时段的负荷波

动; IMF2 在 0.125 Hz 反映以 8 小时为周期的负荷变化; IMF3 在 0.083 Hz 处的单一强峰反映数据中负荷 12 小时的周期变化; IMF4 显示出 0.042 Hz 频率特性, 分别反映了以周为周期等多时间尺度的低频变化; IMF5 频谱平缓且无显著峰值, 反映电力负荷的长期趋势成分。预测模型依据上述 IMF 分量所对应的不同时间尺度训练。




图 7 各 IMF 分量频谱图

3.2 NRBO 优化

将 LSTM 预测的 *RMSE* 作为目标函数, 选取超参数组合表示种群个体, 设置种群个体的上界为 [200, 0.05, 0.005], 下界为 [10, 0.005, 1×10^{-6}] 来寻找隐藏层单元数, 学习率, 以及 L2 正则化系数 3 种超参数。种群数量为 5, 迭代次数为 50。各 IMF 分量的收敛如图 8, 适应度值采用 *RMSE* 的对数坐标。各 IMF 分量的适应度值随迭代次数的增加均呈现快速下降后趋于稳定的趋势, 表明超参数优化过程高效且收敛良好。该结果验证了该优化算法能为不同特性的子序列找到最优的超参数组合。




图 8 各 IMF 分量适应度值变化

3.3 负荷预测分析

为了验证 FMD-NRBO-LSTM 模型的电力负荷预测的准确性, 将 2 400 个小时的数据样本按照 9 : 1 比例划分训练集和测试集。引入 LSTM 神经网络^[24]、CNN-GRU-LSTM 预测模型、CNN-GRU-LSTM-Attention 预测模型、和所提出的 FMD-NRBO-LSTM 预测模型进行对比, 分别训练预测模型并对未来 100 小时的电力负荷预测测试。图 9 展示了各 IMF 分量测试集的预测值以及求和后反归一化与真实值对比, 其中图 (a) 展示各个分量的预测值, 图 (b) 表示 (a) 图中各分量根据式 (26) 反推理进行反归一化并求和的结果。可以看到预测结果紧密贴合真实值。验证所提的预测模型在短期负荷预测中的准确性。




图 9 各分量预测

图 10 展示了不同模型的预测效果。各模型均能大致跟踪实际负荷的变化趋势, 呈现出相似的波动性, 图中可以看出整体所提模型 FMD-NRBO-LSTM 的预测轨迹与真实值更为接近。图 11 展示了不同模型的误差的分布。从误差分布可以看出 FMD-NRBO-LSTM 预测模型的误差曲线最接近 0 基准线, 且其波动幅度和范围明显小于其他模型。




图 10 各个预测模型预测结果对比

表 1 比较了各模型的预测结果。所提的 FMD-NRBO-LSTM 模型预测结果的 MAE 比 LSTM 模型减少了 7.969 2 kW, 比 CNN-GRU-LSTM 模型减少 8.004 8 kW, 比 CNN-GRU-LSTM-Att 模型减少 7.135 4 kW。在 RMSE 方面, FMD-NRBO-LSTM 模型比 LSTM 模型减少了




图 11 各个预测模型预测误差对比

11.655 5 kW, 比 CNN-GRU-LSTM 模型减少了 9.393 kW, 比 CNN-GRU-LSTM-Att 模型减少了 7.639 1 kW。在 MAPE 方面 FMD-NRBO-LSTM 比 LSTM 模型减少了 1.473 9%, 比 CNN-GRU-LSTM 模型减少了 1.419 0%, 比 CNN-GRU-LSTM-Att 模型减少了 1.443 8%。上述结果表明 NRBOFMD-LSTM 模型在预测精度上优于其他所提到的模型, 验证了其具有较高的预测精度。

表 1 预测模型评价表

预测模型	MAE/kW	RMSE/kW	MAPE/%
LSTM	13.607 5	18.937 7	3.017 2
CNN-GRU-LSTM	13.645 1	16.675 2	2.962 3
CNN-GRU-LSTM-Att	12.774 8	14.921 3	2.987 1
FMD-NRBO-LSTM	5.640 3	7.282 2	1.543 3

表 2 比较了所提模型及对比模型在训练时间、预测时间和内存占用方面的情况。其中, 训练时间指模型在训练数据集上完成训练所需的时间, 预测时间指对测试集进行预测所需的时间, 内存占比为预测过程占用总预测内存的百分比。

表 2 预测模型资源占用

预测模型	训练时间/s	预测时间/s	内存占比/%
LSTM	19.849 9	0.100 4	8.8
CNN-GRU-LSTM	64.919 4	0.148 2	20.6
CNN-GRU-LSTM-Att	78.715 6	0.151 7	29.4
FMD-NRBO-LSTM	84.641 9	0.053 2	41.2

可以看出, 随着模型复杂度的增加, 训练时间和内存占用也相应提升, 而预测时间在各模型间差异较小。本文实验结果显示, 尽管 FMD-NRBO-LSTM 在训练时间和内存占用上高于传统 LSTM, 预测时间上仍具有明显优势。

4 结束语

本文提出了一种结合 FMD 分解和 NRBO 优化 LSTM 的电力负荷预测模型。使用 FMD 自适应分解负荷数据集, 针对传统 FMD 在模态混叠与噪声抑制方面的不足, 本文在分解过程中引入辅助白噪声以增强不同频率成分的可分离性, 并将传统峰值筛选替换为基于模

态能量的筛选机制,从而有效剔除低能量噪声模态、保留关键特征模态,提高分解结果的稳定性。将复杂时间尺度负荷序列分解为多个相对简单、规律性更强的子序列预测问题。同时引入 NRBO 优化算法利用 NRSR 规则和 TAO 算子,自动寻找最优的 LSTM 超参数组合。最后设计对比实验验证所提模型的有效性,预测结果表明,所提 FMD-NRBO-LSTM 模型在预测的平均绝对误差,均方根误差,平均绝对百分比误差等指标均优于对比模型。该模型有效弥补了单一模型对复杂时间尺度特征学习能力的不足,并通过 NRBO 算法,实现了对 LSTM 超参数的自动全局优化,从而同步提升了模型的预测精度与稳定性。该模型融合了数据分解与智能优化的混合框架,在预测准确性与鲁棒性上均展现出一定潜力,有助于提升电力系统调度与决策的可靠性。

参考文献:

- [1] CHEN Z, DU C, ZHANG B. A cybersecure distribution-free learning model for interval forecasting of power load under cyberattacks [J]. *Industrial Informatics, IEEE Transactions on*, 2025, 21 (3): 2540 - 2549.
- [2] PENG Z, YANG X. Short-and medium-term power load forecasting model based on a hybrid attention mechanism in the time and frequency domains [J]. *Expert Systems with Application*, 2025: 278.
- [3] LIU B, TANG Z, LI G, et al. Research on soft measurement method combining grid search optimization clustering and improved SVR algorithm [C] //2024 5th International Conference on Computer, Big Data and Artificial Intelligence (ICCBD + AI), Jingdezhen, China, 2024: 187 - 192.
- [4] BIONDI M, BORTOLI E, MARINI L. Classification of computed tomography scans: a novel approach implementing an enforced random forest algorithm [J]. *Physica Medica*, 2025, 137 (000): 11.
- [5] MARTINS W, BAGESTEIRO L B, WEBER T O. FP-GA-based implementation of random forest classifier for sEMG signal classification [J]. 2024 46th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2024: 1 - 4.
- [6] ZAMANIDOOST Y, OULD-BACHIR T, MARTEL S. OMS-CNN: optimized multi-scale CNN for lung nodule detection based on faster R-CNN [J]. *Biomedical and Health Informatics, IEEE Journal of*, 2025, 29 (3): 2148 - 2160.
- [7] TANG Z, WANG Y, MAO S, et al. TCN-xLSTM: a hybrid temporal model integrating TCN and xLSTM for lower limb joint moment estimation from IMU signals, in *IEEE Robotics and Automation Letters*, 2026, 11 (1): 153 - 160.
- [8] JIAN W, et al. SA-Bi-LSTM: self attention with Bi-Directional LSTM-Based intelligent model for accurate fake news detection to ensured information integrity on social media platforms, in *IEEE Access*, 2024, 12: 48436 - 48452.
- [9] ABDEL-BASSET M, HAWASH H, SALLAM K, et al. STLF-Net: two-stream deep network for short-term load forecasting in residential buildings [J]. *Journal of King Saud University-Computer and Information Sciences*, 2022, 34 (7): 4296 - 4311.
- [10] 杨迪, 张璐, 杨力人, 等. 基于 CNN 与 LSTM 的农村电力负荷预测研究 [J]. *电器工业*, 2022 (9): 26 - 29.
- [11] 吴永洪, 张智斌. 基于贝叶斯优化的 CNN-GRU 短期电力负荷预测 [J]. *现代电子技术*, 2023, 46 (20): 125 - 129.
- [12] 陈雷, 刘林虎, 闫川川, 等. 基于孤立森林和 GRU-CNN-Attention 的超短期电力负荷预测 [J]. *电子设计工程*, 2023, 31 (20): 140 - 144.
- [13] 张子恒, 张玉言, 马晨波, 等. 全参数自适应特征模态分解及其在滚动轴承早期故障诊断中的应用 [J]. *振动工程学报*, 2025, 38: 1 - 13.
- [14] 丁力, 伍星, 刘岩. 高斯误差联合优化 FMD 的轴承故障特征提取研究 [J]. *噪声与振动控制*, 2025, 45 (6): 139 - 146.
- [15] 张天军, 曹新爽, 宋爽. 基于 NRBO-XGBoost 的煤体破坏声发射特征及裂纹扩展状态智能识别 [J]. *Coal Geology & Exploration*, 2025, 53 (4): 141 - 152.
- [16] AGUIAR A L S, SOUSA F B C, MELO Y V L D. Optical distribution network design using PSO [J]. *IEEE Communications Letters*, 2023, 27: 239 - 242.
- [17] ZHOU K, TAN C, WU Y. Research on solving flexible job shop scheduling problem based on improved GWO algorithm SS-GWO [J]. *Neural Processing Letters*, 2024, 56 (1): 1 - 26.
- [18] NIU Z, LV C, YU Y. Cigarette quality problem prediction based on WOA-BiLSTM-SPA [J]. *Electronics Letters*, 2025, 61 (1): e70292.
- [19] CAO M, HUA Y, ZHANG J, et al. Denoising method for ultrasonic echo signal of mining well logging instrument based on NRBO-ICEEMDAN wavelet thresholding [J]. *Sensors Journal, IEEE*, 2025, 25 (15): 29700 - 29710.
- [20] ZOU Z, LI M, WANG H, et al. Identification of mixing ratios of new and used hot pot oil using multi-source and NRBO-optimized deep learning [J]. *Journal of Food Composition & Analysis*, 2025, 146: 8.

(下转第 92 页)