

基于相似日与BiLSTM组合的短期电力负荷预测

祁宇轩¹, 范俊岩¹, 吴定会^{1†}, 汪晶²

(1. 江南大学 轻工过程先进控制教育部重点实验室, 江苏 无锡 214122; 2. 上海宝信软件有限公司, 上海 201999)

摘要: 短期电力负荷存在非线性、波动性和影响因素多等特征, 针对以上特征所导致的预测精度不足, 本文提出一种基于相似日与双向长短期记忆神经网络(BiLSTM)组合的短期电力负荷预测模型. 首先, 剖析电力负荷的动态变化机理, 基于相似日和灰色关联分析方法, 构建负荷与特征融合数据集; 其次, 采用变分模态分解(VMD)方法将高波动、非线性的原始负荷数据分解为多个相对平稳的分量, 并对各分量分别搭建BiLSTM预测模型; 最后, 采用鲸鱼优化算法(WOA)对模型的分解参数和相似日天数进行优化, 减小模型的固有误差. 以新英格兰某地区的实际数据进行仿真验证, 所提模型的平均绝对百分比误差(MAPE)、平均绝对误差(MAE)和均方根误差(RMSE)分别为0.58%, 42, 78, 均优于对照模型, 有效提升了负荷预测精度.

关键词: 短期电力负荷预测; 相似日; 深度学习; 鲸鱼优化算法; 变分模态分解

引用格式: 祁宇轩, 范俊岩, 吴定会, 等. 基于相似日与BiLSTM组合的短期电力负荷预测. 控制理论与应用, 2024, 41(12): 2304 – 2314

DOI: 10.7641/CTA.2023.20969

Short term power load forecasting based on the combination of similar days and BiLSTM

QI Yu-xuan¹, FAN Jun-yan¹, WU Ding-hui^{1†}, WANG Jing²

(1. Key Laboratory of Advanced Process Control for Light Industry, Jiangnan University, Wuxi Jiangsu 214122, China;
2. Shanghai Baosight Software Co. Ltd, Shanghai 201999, China)

Abstract: Short term power load has the characteristics of nonlinearity, volatility and many influencing factors. Aiming at the lack of forecasting accuracy caused by the above characteristics, a short-term power load forecasting model based on the combination of similar days and bi directional long short memory neural network (BiLSTM) is proposed. First, the dynamic change mechanism of power load is analyzed, and the similar day and gray correlation analysis methods are introduced to build the load and feature fusion data set; Secondly, the nonlinear and highly fluctuating original load data is decomposed into several relatively stable components by using the variational modal decomposition (VMD) method, and the BiLSTM prediction model is built for each component; Finally, the whale optimization algorithm (WOA) is used to optimize the decomposition parameters and similar days of the model to reduce the inherent error of the model. Based on the actual data of a region in New England, the simulation results show that the MAPE, MAE and RMSE of the proposed model are 0.58%, 42 and 78 respectively, which are better than the control model and effectively improve the accuracy of load forecasting.

Key words: short-term power load forecasting; similar day; deep learning; whale optimization algorithm; variational modal decomposition

Citation: QI Yuxuan, FAN Junyan, WU Dinghui, et al. Short term power load forecasting based on the combination of similar days and BiLSTM. *Control Theory & Applications*, 2024, 41(12): 2304 – 2314

1 引言

电力系统用户众多且电力负荷具有时变特征, 准确的电力负荷预测有助于维持电力系统的动态平衡, 保障其稳定高效地运行. 目前电力负荷领域预测方法

包括时间序列法、灰色预测法、机器学习、模糊理论和支持向量机等. 时间序列法^[1]适用于具有一定规律的平稳数据, 对于波动性较强的负荷数据预测效果具有局限性. 机器学习^[2]和支持向量机^[3]等处理非线性

收稿日期: 2022-11-02; 录用日期: 2023-10-11.

†通信作者. E-mail: wdh123@jiangnan.edu.cn; Tel.: +86 13961854865.

本文责任编辑: 张化光.

国家重点研发项目(2020YFB1711100, 2020YFB1711102)资助.

Supported by the National Key Scientific Research Project (2020YFB1711100, 2020YFB1711102).

数据能力较强,但模型超参数需依靠人工经验确定.对于高波动、非线性的电力负荷序列,单一预测方法难以取得理想的预测效果,将多种预测方法相结合的组合预测模型逐渐成为研究热门.文献[4]采用经验模态分解(empirical mode decomposition, EMD)与长短期记忆网络的组合模型对电力负荷进行预测,相较于单模型,预测精度获得明显提升.然而,EMD分解存在模态混叠和端点效应等问题,为改善这一问题,文献[5]引入变分模态分解(variational modal decomposition, VMD)算法,通过非递归和变分模型处理原始信号,并与权值共享门控循环单元(weighted stacked gated recurrent unit, WSGRU)构建应用于风电功率预测的VMD-WSGRU模型,取得了最佳的预测效果.

除了改进预测模型,还可以通过提升数据质量实现预测精度的提高.从模型输入数据类型来划分,目前电力负荷预测方法可分为以下两类:基于影响因素的预测方法和基于相似日的预测方法.基于影响因素的预测方法是通过灰色关联分析、皮尔逊相关系数等算法筛选出影响电力负荷变化的主要因素,构建影响因素特征集完成电力负荷预测.程志友等^[6]综合恐惧指数、天气条件和日期类型,建立以新冠肺炎疫情影响因素为主的电力负荷预测模型.元晓燕等^[7]选取历史负荷、温度、钢价等6种影响因素作为长短期记忆神经网络与支持向量机组合预测模型组合预测模型的输入.负荷影响因素能一定程度上反映电力负荷曲线的变化情况,但忽略了电力负荷数据的时序特征.基于相似日的预测方法主要通过分析各历史日与预测

日影响因素的总体相似性,筛选出最优相似日负荷序列输入模型进行预测.王开艳等^[8]针对负荷影响因素提取困难的问题,引入基于模糊C均值的相似日聚类方法,通过构建天气类型相似日挖掘负荷内部的联系与规律.该方法寻找的最优相似日负荷序列,隐含影响因素特征,且包含电力负荷数据较多的时序性特征.然而只输入负荷序列会导致模型丢失部分影响因素特征的学习,造成负荷曲线泛化性明显.

基于以上研究,本文提出一种基于相似日和变分模态分解与双向长短时记忆神经网络(VMD bi-directional long short-memory neural network, VMD-BiLSTM)组合模型的短期电力负荷预测方法.首先,通过曲线趋势度差异度联合算法和灰色关联分析法筛选出最优相似日及主要影响因素,构建负荷与特征融合数据集,避免输入数据类型单一的问题;其次,采用VMD-BiLSTM组合模型将高波动、非线性的负荷序列分解为多个较为平缓的子模态序列单独预测,并采用鲸鱼算法(whale optimization algorithm, WOA)对预测模型的分解参数和相似日天数进行优化,进一步提升模型预测精度;最后,累加所有子模态序列的预测值,完成对未来负荷的预测.以新英格兰某地区的负荷数据集为例,将所提方法与其他经典模型对比试验,仿真结果表明,本文所提方法具有更高的预测精度.

2 负荷与特征融合数据集

本文构建最优相似日负荷序列集与主要影响因素特征序列集的融合数据集,为BiLSTM信息挖掘,提供丰富数据.融合数据集构建流程如图1所示.

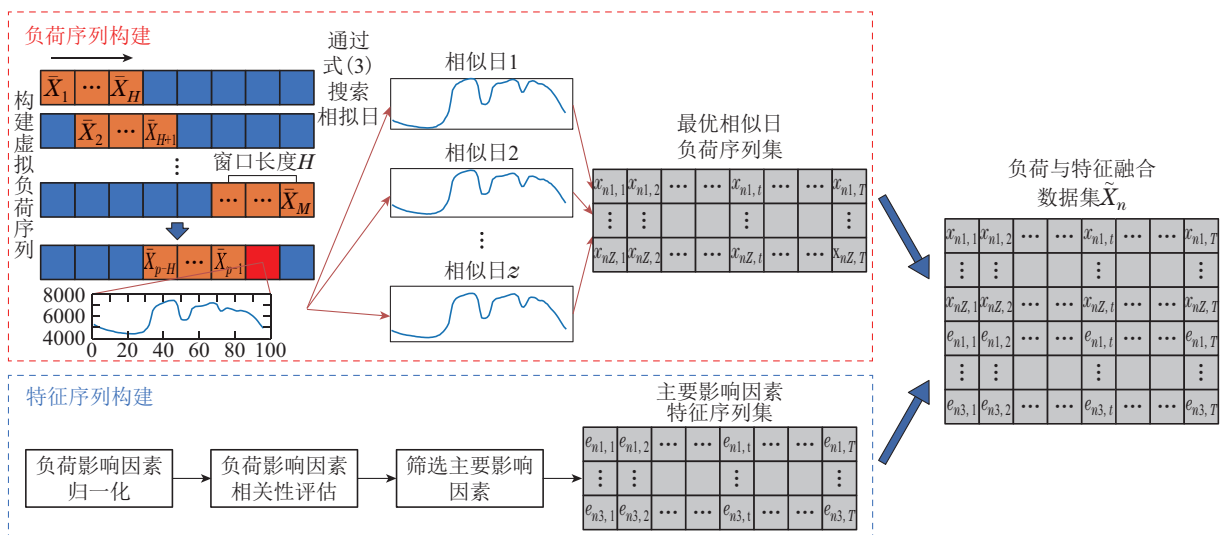


图 1 融合数据集构建流程图

Fig. 1 Flow chart of fusion dataset construction

2.1 最优相似日负荷序列集选取

短期负荷预测系统大多应用组合模型完成预测以提高预测准确度和适应性.在这种预测机制中,相似

日选取的质量好坏对于预测精度有直接影响^[9].本文采用曲线趋势度和差异度联合算法,通过比较历史日与预测日负荷曲线的相似性,筛选出最优相似日负荷

序列集.

2.1.1 曲线趋势度和差异度联合算法

传统的相似日预测方法,其预测精度很大程度上取决于选取的影响因素,而影响因素大多依靠人工经验自行确定,具有主观性.电力系统的日负荷曲线隐含了该系统的大量信息,通过寻找与预测日负荷曲线相似的历史日,能充分挖掘预测日的隐含特征信息,实现预测精度的提高,同时也避免了人工选择影响因素带来的误差.基于此,本文提出一种联合曲线趋势度和差异度的相似日筛选算法.

电力负荷预测领域所描述的曲线趋势度是指两条曲线的“垂直平移相似性”(即在只允许垂直方向平移的情况下,两条曲线的最大重合度).通过该方法可以量化任意两日电力负荷曲线的趋势相似度,其计算公式如下:

$$R_{mn}(m) = \frac{2[E(X_m X_n) - E(X_m)E(X_n)]}{D(X_m) + D(X_n)}, \quad (1)$$

式中: X_m, X_n 分别代表历史日 m 和预测日 n 的当日电力负荷序列, 可以看成由等概率分布的随机向量 X_m, X_n 的 T 个采样点集合 $(x_{m,1}, \dots, x_{m,t}, \dots, x_{m,T})$ 和 $(x_{n,1}, \dots, x_{n,t}, \dots, x_{n,T})$ 分别表示; T 为序列长度; $x_{m,t}, x_{n,t}$ 分别为历史日电力负荷序列 X_m 与预测日电力负荷序列 X_n 在各自序列第 t 点的数值大小; $E(\cdot)$ 表示数学期望, $D(\cdot)$ 为方差. 趋势相似度越大, 代表两相似日负荷曲线形状越相似.

曲线趋势度模型可以很好地描述任意两日负荷曲线的相似性, 但当电力负荷曲线整体上升或下降时, 尽管两日的趋势相似度很大, 实际数值却相差甚远. 为弥补这一缺陷, 提高相似日选取的准确性, 在趋势相似度最大的基础上, 继续引入曲线差异度最小的概念. 曲线差异度是指任意两条曲线数值大小的差别而表现出的差异程度^[10], 曲线差异度越小, 代表两日曲线误差越小, 其计算公式如下:

$$O_{mn}(m) = \sqrt{\sum_{t=1}^T |x_{m,t} - x_{n,t}|^2}. \quad (2)$$

先将差异度进行归一化操作, 与趋势度实现统一量纲, 再将曲线趋势度减去曲线差异度后, 可以得到历史日 m 与预测日 n 的最终相似度系数 V_{mn} , 计算公式如式(3)所示, 相似度系数越大, 表示两日越相似.

$$V_{mn}(m) = R_{mn}(m) - \frac{O_{mn}(m)}{\sum_{t=1}^T x_{n,t}}. \quad (3)$$

通过这种将趋势相似度最大和曲线差异度最小结合的相似日筛选法, 可以充分提取电力负荷曲线中的时序信息和隐藏的特征信息, 完成最优相似日序列集的筛选.

2.1.2 预测日虚拟负荷序列构建

实际应用中预测日的电力负荷序列是未知的, 因此在筛选之前, 需要构建合适的预测日虚拟负荷序列.

定义 $\bar{X}_{p-h} = \sum_{t=1}^T x_{p-h,t}/T$ 为历史日 p 前第 h 日的日平均负荷数值, $\bar{X}_{n-h} = \sum_{t=1}^T x_{n-h,t}/T$ 为预测日 n 前第 h 日的日平均负荷数值. 历史日 p 与预测日 n 附近 H 日的日平均负荷序列可表示为 $\bar{X}_{pH} = (\bar{X}_{p-H}, \dots, \bar{X}_{p-h}, \dots, \bar{X}_{p-1})$ 和 $\bar{X}_{nH} = (\bar{X}_{n-H}, \dots, \bar{X}_{n-h}, \dots, \bar{X}_{n-1})$. 序列 \bar{X}_{pH} 与 \bar{X}_{nH} 的相似度系数 V_{pn} 可以反映这两日附近 H 日的日平均负荷变化规律的相似程度. 附近 H 日日平均负荷相似度接近的两日, 其当日平均负荷也相似^[11], 即这两日所在的周期互为相似周期(周期长度为 $H+1$ 日). 普通电网负荷等一般以星期为单位划分相似周期, 工业负荷主要以一个生产周期为单位划分相似周期. 依据电力负荷具有规律性的特点, 在相似周期中处于相同位置的两日, 其当日负荷曲线趋势相似度也相近. 因此, 在历史日日平均负荷已知的情况下, 可以通过滑动时间窗寻找历史数据中令 V_{pn} 最大的历史日 p , 将该日的负荷序列 $X_p = (x_{p,1}, x_{p,2}, \dots, x_{p,T})$ 作为预测日的虚拟负荷序列.

最优相似日负荷序列集选取流程如下:

1) 构建预测日虚拟负荷序列. 设置滑动时间窗窗口长度为 H , 按式(3)滑动搜索令 V_{pn} 最大的历史日 p , 选取历史日 p 的负荷曲线 X_p 作为预测日 n 的虚拟负荷曲线.

2) 搜索最佳相似日序列集. 通过式(3)遍历历史负荷数据中的所有历史日, 将每个历史日的相似度系数从大到小进行排序, 选取前 Z 日构建预测日 n 对应的最优相似日负荷序列集 $[X_{n1}; X_{n2}; \dots; X_{nZ}]$.

2.2 主要影响因素特征序列选取

电力负荷曲线包含了当日的特征信息, 但大多隐含在曲线变动中, 预测模型难以直观有效地提取. 将主要影响因素特征序列输入预测模型, 能帮助模型更直接地学习特征变动带来的负荷差异.

电网电力负荷一般受到电力价格、温度、湿度、降雨量、风速等因素影响, 使得电力负荷曲线呈现非线性和强规律性^[12]. 本文采用灰色关联分析法(grey relational analysis, GRA)对所有影响因素进行关联度计算和排序^[13], 筛选出影响电力负荷的主要因素. GRA 算法具体步骤如下.

首先对所有数据进行归一化处理, 然后利用式(4)可计算出影响因素序列 E_m^d 与当日负荷序列 X_m 的灰色关联系数(X_m 为历史日 m 的电力负荷序列, E_m^d 为

历史日 m 第 d 个影响因素序列), 即

$$\xi_m^d = \sum_{t=1}^T \frac{\min_d \min_t |\Delta_m^d(t)| + \rho \max_d \max_t |\Delta_m^d(t)|}{|\Delta_m^d(t)| + \rho \max_d \max_t |\Delta_m^d(t)|}, \quad (4)$$

式中: $\Delta_m^d(t) = X_m(t) - E_m^d(t)$; $\min_d \min_t |\Delta_m^d(t)|$ 代表二级最小差; $\max_d \max_t |\Delta_m^d(t)|$ 代表二级最大差; ρ 为分辨系数, T 表示 E_m^d 的序列长度。

最后对所有历史日的 ξ_m^d 取均值, 可以得到第 d 个影响因素的灰色关联度 $\mu_d (\mu_d \in [0, 1])$ 。

采用新英格兰某地区的负荷数据集进行相关性分析, 使用的影响因素有温度、湿度、风速、降雨量和电力价格。通过GRA对每个影响因素进行评价, 结果如表1所示。需要注意的是, 由于本文收集到的气象数据分辨率为1 h, 而负荷数据分辨率为15 min, 为使气象数据与负荷数据相匹配, 对气象数据进行线性插值, 得到分辨率为15 min的气象数据。

表 1 负荷影响因素相关性评估

Table 1 Correlation assessment of load influencing factors

影响因素	湿度/ %	电力价格/ (元·kW ⁻¹)	风速/ (m·s ⁻¹)	降雨量/ (mm·h ⁻¹)	温度/ °C
相关系数	0.669	0.761	0.335	0.439	0.907

由表1可以看出, 上述影响因素中, 温度与电力负荷存在极强相关性 ($\mu \in (0.8, 1.0]$); 电力价格和湿度与电力负荷存在强相关性 ($\mu \in (0.6, 0.8]$); 电力负荷和降雨量存在中相关性 ($\mu \in (0.4, 0.6]$), 和风速存在弱相关性 ($\mu \in (0, 0.4]$)。经综上分析, 选取湿度、温度和电力价格作为负荷的主要影响因素。采集预测日当天的特征数据, 构建主要影响因素特征序列集 $[E_{n1}; E_{n2}; E_{n3}]$, 将其与第2.1.2节中最优相似日负荷序列集 $[X_{n1}; X_{n2}; \dots; X_{nZ}]$ 合并, 即完成预测日 n 负荷与特征融合数据集 \tilde{X}_n 的构建, 如式(5)所示:

$$\tilde{X}_n = \begin{bmatrix} X_{n1} \\ X_{n2} \\ \vdots \\ X_{nZ} \\ E_{n1} \\ \vdots \\ E_{n3} \end{bmatrix} = \begin{bmatrix} x_{n1,1} & \cdots & x_{n1,t} & \cdots & x_{n1,T} \\ x_{n2,1} & \cdots & x_{n2,t} & \cdots & x_{n2,T} \\ \vdots & & \vdots & & \vdots \\ x_{nZ,1} & \cdots & x_{nZ,t} & \cdots & x_{nZ,T} \\ e_{n1,1} & \cdots & e_{n1,t} & \cdots & e_{n1,T} \\ \vdots & & \vdots & & \vdots \\ e_{n3,1} & \cdots & e_{n3,t} & \cdots & e_{n3,T} \end{bmatrix}, \quad (5)$$

式中: $x_{n1,t}$ 表示预测日 n 第1个相似日的负荷序列在其第 t 点的数值大小; $e_{n1,t}$ 表示预测日 n 第1个主要影响因素的特征序列在其第 t 点的数值大小。

3 WOA优化VMD-BiLSTM的预测模型

针对电力负荷为非线性时序数据的特点, 本文首

先利用VMD对原始数据进行平稳化和滤噪处理, 其次利用BiLSTM神经网络学习数据的双向时序信息, 提高预测精度。但该模型存在VMD子模态个数和惩罚因子需人工确定, 模型相似日天数依靠经验选取等缺点。针对这些问题, 本文引入WOA算法自动优化VMD分解参数 K , α 和相似日天数 Z , 避免了人工经验确定参数带来的预测误差。

3.1 变分模态分解算法

3.1.1 变分模态分解原理

针对电力负荷高波动、非线性的特点, VMD通过非递归、变分的方式, 将原本复杂的时序信号分解成多个简单的固有模态分量^[4], 具体步骤如下:

步骤 1 构建变分问题。将待处理的原始序列 $f(i)$ 分解成 K 个具有不同中心频率带宽的变分模态分量 u_k , 且保证各模态的估计带宽之和为最小, 具体的变分约束表达式可定义为

$$\begin{cases} \min_{\{u_k\}, \{w_k\}} \left\{ \sum_{k=1}^K \|\partial_t [B_k(i)] e^{-jw_k i}\|_2^2 \right\}, \\ \text{s.t.} \quad \sum_{k=1}^K u_k(i) = f(i), \end{cases} \quad (6)$$

式中: 原始序列 $f(i)$ 为最优相似日负荷序列集 $[X_{n1}; X_{n2}; \dots; X_{nZ}]$; $\{u_k\}, \{w_k\}$ 分别表示所有子模态和其对应中心频率的集合; $B_k(i) = (\delta(i) + \frac{j}{\pi i}) \cdot u_k(i)$, 表示第 k 个子模态经Hilbert解调后的解析信号; $\delta(i)$ 为单位脉冲信号; $u_k(i)$ 表示第 k 个子模态的模态函数。

步骤 2 拉格朗日变换。引入拉格朗日乘子 λ 和惩罚因子 α 解决变分约束的最优解问题, 将式(6)约束问题转换为式(7)的无约束变分问题。其中, α 保证高噪声环境下信号重构的准确性, λ 保证约束条件的严格性。

$$\begin{aligned} L(\{u_k\}, \{w_k\}, \lambda) = & \alpha \sum_k \|\partial_t [B_k(i)] e^{-jw_k i}\|_2^2 + \|f(i) - \sum_k u_k(i)\|_2^2 + \\ & \langle \lambda(i), f(i) - \sum_k u_k(i) \rangle. \end{aligned} \quad (7)$$

步骤 3 交替更新。初始化 $\{u_k^1\}, \{w_k^1\}, \lambda^1$, 采用交替方向乘子法求解式(7), 可得各主变量更新公式, 如式(8)所示, 依据式(7)对 u_k^1, w_k^1, λ^1 进行迭代更新。

$$\begin{cases} \hat{f}(\omega) - \sum_{v \neq k} \hat{u}_v^s(\omega) + \frac{\hat{\lambda}^s(\omega)}{2} \\ \hat{u}_k^{s+1}(\omega) = \frac{1 + 2\alpha(\omega - w_k)^2}{1 + 2\alpha(\omega - w_k)^2}, \\ w_k^{s+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega}, \\ \hat{\lambda}^{s+1}(\omega) = \hat{\lambda}^s(\omega) + \tau(\hat{f}(\omega) - \sum_k \hat{u}_k^{s+1}(\omega)), \end{cases} \quad (8)$$

式中: s 为迭代次数, ω 代表频率, τ 为噪声容限, \hat{u}_k^{s+1} , w_k^{s+1} 分别表示第 k 个子模态在 $s+1$ 次迭代时的模态函数和中心频率; $\hat{\lambda}^{s+1}(\omega)$ 为VMD算法在 $s+1$ 次迭代时的拉格朗日乘子数值; $\hat{f}(\omega)$, $\hat{u}_k^{s+1}(\omega)$, $\hat{u}_e^s(\omega)$ 和 $\hat{\lambda}^s(\omega)$ 分别表示 $f(i)$, $u_k^{s+1}(i)$, $u_e^s(i)$ 和 $\lambda^s(i)$ 傅里叶变换后的形式。

步骤4 输出子模态信号. 依据式(9)判断是否满足终止条件, 若不满足, 则返回步骤3, 否则, 对最后一次更新的 $\{\hat{u}_k(\omega)\}$ 进行傅里叶逆变换, 得到其在时域范围内的集合 $\{u_k(i)\}$. 最终输出 K 个子模态信号, 其子模态函数为 $u_k(i)$, 对应中心频率为 w_k .

$$\sum_k^K \frac{\|\hat{u}_k^{s+1} - \hat{u}_k^s\|_2^2}{\|\hat{u}_k^s\|_2^2} < \varepsilon, \quad (9)$$

式中 ε 为判断精度($\varepsilon > 0$).

3.1.2 变分模态分解评价指标

定义重构序列 $f'(i) = \sum_{k=1}^K u_k(i)$, 表示VMD分解后 K 个子模态信号相加之和. 在理想情况下, 重构序列 $f'(i)$ 与原始序列 $f(i)$ 相同, 但在实际分解过程中会出现一定的分解损失. 过多的分解损失会导致预测精度的下降, 因此需要定义一个评价指标来量化VMD的分解精度. 基于此, 本文提出一种适用于电力负荷预测的评价指标VMDLoss, 其实质为VMD分解后各子模态信号稀疏性的均值^[15], 即包络熵平均值. 具体计算公式如下:

$$\begin{cases} \text{VMDLoss} = - \sum_{k=1}^K \sum_{i=1}^C \varepsilon_k(i) \lg \varepsilon_k(i), \\ \varepsilon_k(i) = \frac{b_k(i)}{\sum_{i=1}^C b_k(i)}, \end{cases} \quad (10)$$

式中: $b_k(i)$ 表示第 k 个子模态解析信号 $B_k(i)$ 的实部; $\varepsilon_k(i)$ 表示将 $b_k(i)$ 进行归一化操作得到的概率分布序列; C 为子模态信号采样数量. VMDLoss越小, 表明分解损失越小, 模态所包含信息就越多, 模型也就越准确.

3.2 鲸鱼算法(WOA)优化

VMD的分解效果取决于分解参数的选择. 分解参数选取不当会导致信号模态混叠, 降低信息重构精度. 同样, 过多或过少的相似日天数会造成预测模型信息堆叠或学习不充分, 降低模型的预测精度. 因此, 本文采用鲸鱼算法对VMD分解参数 K , α 和相似日天数 Z 自动优化, 以减少模型的固有误差.

鲸鱼算法具有原理简单、参数设置少、寻优能力强等特点^[16]. 该算法主要通过收缩包围、螺旋运动、随机搜索这三种方式更新参数位置. WOA优化VMD分解参数 K , α 的步骤如下:

步骤1 初始化参数: 输入VMD分解后 K 个子模态信号, 设置最大迭代次数、种群个体数等算法参数, 设置寻优参数种类为2, 分别为子模态个数 K 和惩罚因子 α ;

步骤2 获取全局最优个体和适应度: 随机生成符合均匀分布的初始种群, 并依据式(10)的VMDLoss构建WOA算法适应度函数, 记为包络熵平均最小值, 具体公式如式(11)所示. 通过计算适应度保留当前种群下的全局最优个体和最优适应度;

$$\begin{cases} \text{fit}(K, \alpha) = \min_{K, \alpha} \left(- \sum_{k=1}^K \sum_{i=1}^C \varepsilon_k(i) \lg \varepsilon_k(i) \right), \\ \text{s.t.} \begin{cases} K \in \{2, 3, \dots, 20\}, \\ \alpha \in [10^2, 10^4]; \end{cases} \end{cases} \quad (11)$$

步骤3 个体位置更新: 生成一个随机数 ρ ($\rho \in [0, 1]$), 若 ρ 小于0.5, 则通过螺旋运动更新位置, 否则通过收缩包围更新位置, 如式(12)所示. 执行收缩包围操作时, 需判断 $|A|$ 是否小于1, 若小于1则继续执行收缩包围操作, 否则表示鲸群位置已经越过猎物位置, 需要放弃当前移动方向, 执行随机搜索更新位置, 以免陷入局部极值, 如式(13)所示:

$$G(r+1) = \begin{cases} G_\theta(r) - 2 \text{rand}_1 \cdot A \cdot D, & \rho < 0.5, \\ D \cdot e^{\sigma l} \cos(2\pi l) + G_\theta(r), & \rho \geq 0.5, \end{cases} \quad (12)$$

$$G(r+1) = G_\tau(r) - |2 \text{rand}_1 \cdot G_\tau(r) - G(r)|, \quad (13)$$

式中: r 代表当前迭代次数; $G(r)$ 和 $G(r+1)$ 分别为个体当前时刻位置和下一时刻位置; $G_\theta(r)$ 为目前最优鲸鱼位置向量; $G_\tau(r)$ 表示随机选取的鲸鱼位置向量; $D = |G_\theta(r) - G(r)|$, 表示鲸鱼与最优位置的距离; l 为 $[-1, 1]$ 之间的随机数; σ 为用于限定螺旋形状的常数; A 定义为

$$A = 2a \cdot \text{rand}_2 - a, \quad a = 2 - \frac{2r}{r_{\max}}; \quad (14)$$

rand_1 和 rand_2 为 $[0, 1]$ 之内的随机数; a 为算法收敛因子; r_{\max} 代表最大迭代次数;

步骤4 个体近似处理: 由于子模态个数 K 必须为正整数, 故对 K 的更新方式进行四舍五入处理, 将其近似整数作为新位置. 连续变量 α 则直接替换;

步骤5 更新全局最优个体和适应度: 位置更新结束, 重新计算每个个体的适应度, 并更新全局最优个体和适应度;

步骤6 迭代或输出结果: 判断是否达到最大迭代次数, 若不满足, 重复步骤3-5; 否则输出全局最优个体和适应度. 此时全局最优个体为VMD子模态个数 K 和惩罚因子 α 的最佳组合, 最优适应度为最小分解损失.

WOA优化预测模型中相似日天数 Z 具体步骤如下: ①初始化参数, 设置算法寻优参数种类为1, 为相似日天数 Z ; ②获取全局最优个体和适应度, 适应度函数选取为模型预测结果中训练集与测试集整体的均方误差平均值, 具体计算公式如下:

$$\begin{cases} \text{fit}(Z) = \min_Z \frac{\text{MSE}_{\text{train}} + \text{MSE}_{\text{test}}}{2}, \\ \text{s.t. } Z \in [2, 30], \end{cases} \quad (15)$$

式中: Z 为相似日天数; $\text{MSE}_{\text{train}}$ 和 MSE_{test} 分别为训练集和测试集的均方误差; ③个体位置更新; ④个体

近似处理; ⑤更新全局最优个体和适应度; ⑥迭代或输出结果。

3.3 双向长短时记忆神经网络

双向长短时记忆(BiLSTM)神经网络在长短时记忆(LSTM)神经网络的基础上, 通过融合双向递归神经网络(bidirectional recurrent neural network, BiRNN)神经网络, 构建出由正向LSTM通道和反向LSTM通道组合而成的双向神经网络结构^[17], 使得每一个输入序列正向和反向都经过一次循环神经网络, 展开的BiLSTM神经网络具体结构如图2所示。

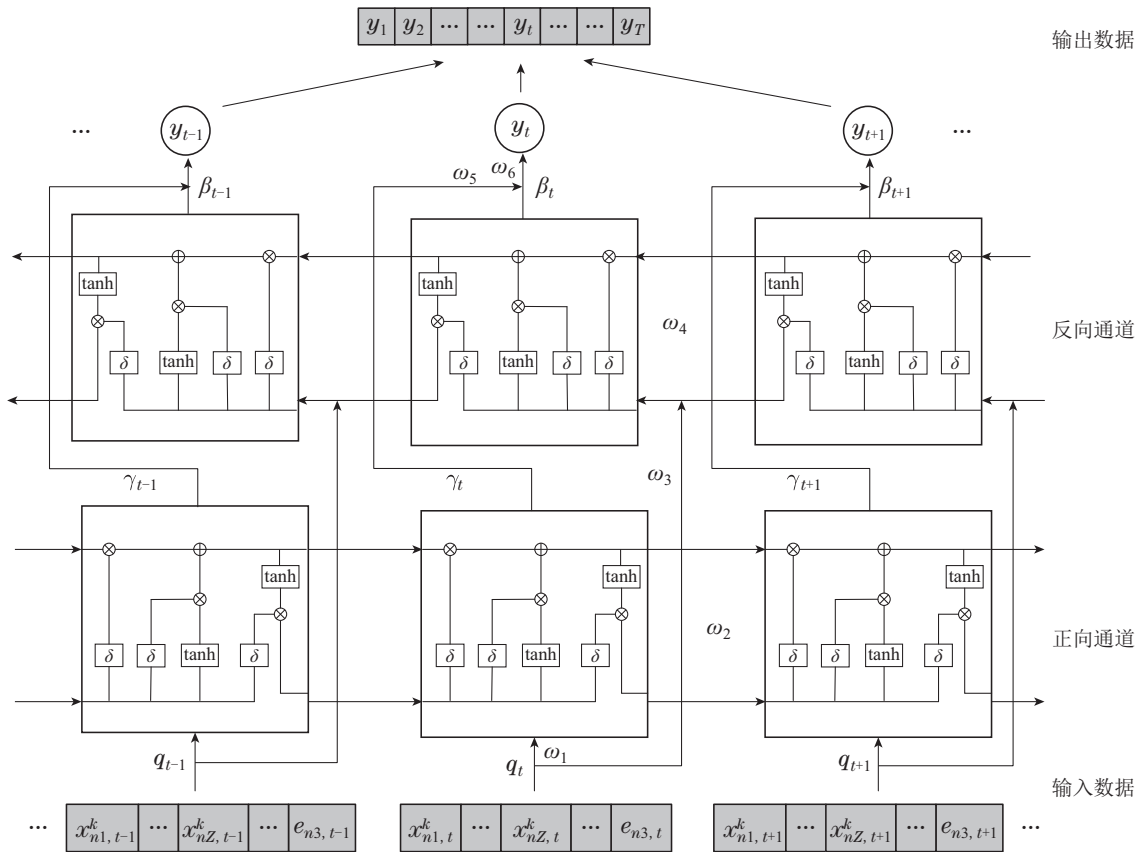


图 2 BiLSTM神经网络结构图

Fig. 2 Structure of BiLSTM neural network

输入序列 $q_t(t \in [1, T])$ 为输入矩阵 \tilde{X}_n^k 第 t 列的列向量(\tilde{X}_n^k 表示将融合数据集 \tilde{X}_n 中原本负荷序列 $[X_{n1}; X_{n2}; \dots; X_{nZ}]$ 替换为经VMD分解后其第 k 个子模态序列 $[X_{n1}^k; X_{n2}^k; \dots; X_{nZ}^k]$ 的融合数据矩阵), y_t 为相应时刻的最终输出, ω 是权重, γ_t, β_t 分别表示正向通道和反向通道隐藏层在第 t 点的输出, o, c, g 为不同隐藏层中使用的激活函数。

输入序列 q_t 分别以正向和反向输入至两个LSTM神经网络进行特征提取, 其各自隐藏层输出 γ_t, β_t 可由计下式计算得出:

$$\gamma_t = o(\omega_1 q_t + \omega_2 \gamma_{t-1}), \quad (16)$$

$$\beta_t = c(\omega_3 q_t + \omega_4 \beta_{t+1}). \quad (17)$$

将两个输出数据按一定权重进行拼接后, 可以得到BiLSTM神经网络的最终输出 y_t , 即

$$y_t = g(\omega_5 \gamma_t + \omega_6 \beta_t). \quad (18)$$

由图2可见, 输出 y_t 受到正向通道和反向通道输出的综合作用, 这样的结构赋予每个输出节点完整的双向时序信息, 使得模型具有更强的非线性学习能力和鲁棒性。

3.4 模型预测流程

WOA优化VMD-BiLSTM的预测模型如图3所示。具体预测流程如下:

步骤 1 输入融合数据集, 并设置相似日天数、VMD分解参数、WOA迭代次数和种群规模等初始参

数;

步骤 2 选取式(11)作为WOA算法的适应度函数,对VMD的分解参数 K 和 α 进行优化;

步骤 3 将步骤2寻得的最优分解参数赋值给VMD,通过VMD对融合数据集中的最优相似日负荷序列集进行变分模态分解,得到 K 个子模态信号;

步骤 4 将每个子模态信号与融合数据集中的主要影响因素特征序列集组合,构建各子模态负荷与

特征融合数据集,利用BiLSTM神经网络对每个子模态单独建模预测,并将各模态预测结果相加得到总预测结果;

步骤 5 选取式(15)作为WOA算法的适应度函数,对预测模型中相似日天数 Z 进行优化;

步骤 6 依据步骤5得到的 Z ,重构负荷与特征融合数据集,将重构数据集输入预测模型,重复步骤3-4,得到最终预测结果.

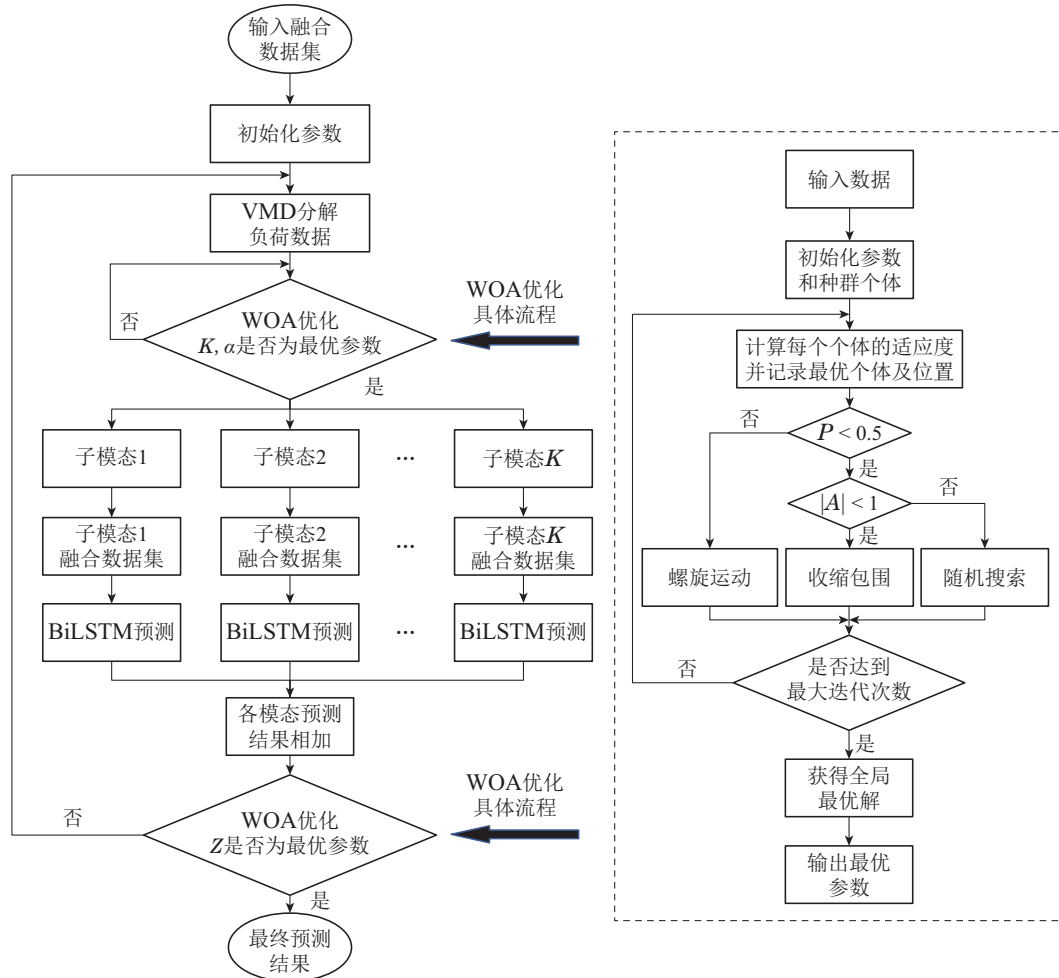


图3 WOA优化VMD-BiLSTM的预测模型

Fig. 3 Prediction model of WOA optimized VMD-BiLSTM

4 算例分析及仿真实验对比

4.1 数据来源及评价指标

本文采用新英格兰某地区的负荷数据集,内容包括负荷、温度、湿度、降雨量、风速和电力价格共6维.时间选取2013年1月1日至2014年4月15日,采样周期为15 min,共270720条负荷数.

为消除不同因素之间的量纲影响,将预测模型的输入数据归一化至[0, 1]区间.训练集和测试集的比例选取为6:1,训练集选取2014年4月9日至4月14日及每日对应的相似日共5760个数据,测试集选取2014年4月15日及其对应的相似日共960个数据.评价标准选

择平均绝对误差(mean absolute error, MAE)、均方根误差(root mean squared error, RMSE)和平均绝对百分比误差(mean absolute percentage error, MAPE).

4.2 负荷与特征融合数据集选取

设置窗口长度为5,利用滑动时间窗遍历历史日,依据式(3)计算每日的平均相似度,最终选择2014年2月16日的负荷序列作为预测日的虚拟负荷序列.在此基础上,继续利用曲线趋势度和差异度联合算法,筛选出6个最优相似日序列作为预测模型的负荷数据,具体如表2所示.

通过天气预报等手段采集4月15日当天湿度、温

度和电力价格数据,与表2的负荷数据组成负荷与特征融合数据集,输入预测模型。

表 2 最优相似日选取

Table 2 Selection of optimal similar day

相似日	日期	相似度系数
1	2014-04-08	0.991
2	2013-05-08	0.987
3	2014-03-26	0.982
4	2014-03-19	0.979
5	2014-03-21	0.977
6	2014-04-03	0.972

4.3 WOA优化实验及分析

4.3.1 WOA优化VMD分解参数

本文采用WOA优化VMD的分解参数 K 和 α 。为体现WOA的优越性,分别采用人工经验选取、粒子群优化算法(particle swarm optimization, PSO)寻优值以及鲸鱼算法(WOA)寻优值作为VMD的分解参数,将负荷序列分解为相应的模态分量。PSO与WOA均设置最大迭代次数为20,种群个数为10,PSO的个体学习因子和社会学习因子的加速度常数设置为1.45。根据式(11)计算包络熵平均最小值的迭代过程如图4所示,各算法寻优所得的最优分解参数及包络熵平均最小值如表3所示。

由图4和表3可知,采用人工经验选取时,VMD的分解效果最差,包络熵平均最小值稳定在3.0007;采用PSO寻优值时,包络熵平均最小值较人工经验选取

有显著下降,由于PSO优化能力有限,最终稳定在2.9939;采用WOA优化时,其包络熵平均最小值为2.9926,相较前两者更低,从优化结果来看,WOA比PSO拥有更佳的寻优效果。将WOA寻得的最优分解参数输入VMD,分解得到6组不同频率尺度的子模态信号,如图5所示。

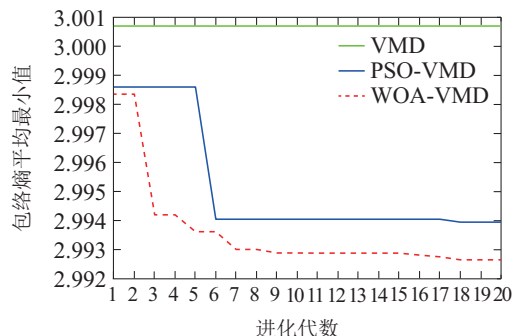


图 4 不同算法包络熵平均最小值的寻优过程图

Fig. 4 Optimization process of envelope entropy average minimum value of different algorithms

表 3 VMD最佳分解参数及实验结果

Table 3 VMD optimal decomposition parameters and experimental results

优化方法	K	α	包络熵平均最小值
人工经验选取	5	2000	3.0007
PSO-VMD	6	923.23	2.9939
WOA-VMD	6	933.65	2.9926

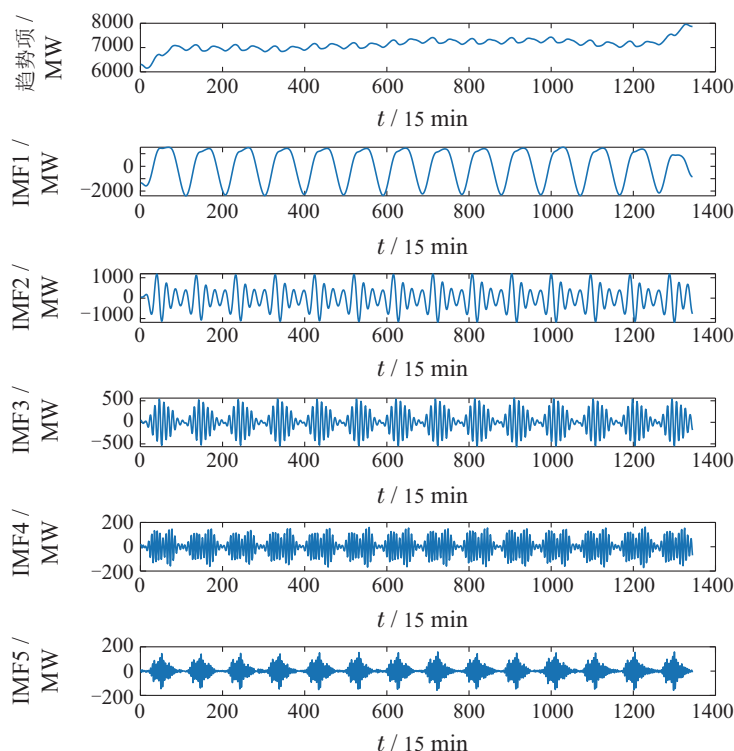


图 5 WOA优化后VMD分解的子模态信号

Fig. 5 VMD decomposed submodal signals after WOA optimization

4.3.2 WOA优化相似日天数

本文采用WOA优化预测模型的相似日天数 Z , 为体现WOA优化的优越性, 分别采用人工经验选取、粒子群算法(PSO)寻优值以及鲸鱼算法(WOA)寻优值作为预测模型的相似日天数. PSO与WOA的算法参数设置与第4.3.1节中相同. 根据式(15)计算均方误差平均值的迭代过程如图6所示, 各算法寻优所得的最佳相似日天数及均方误差平均值如表4所示.

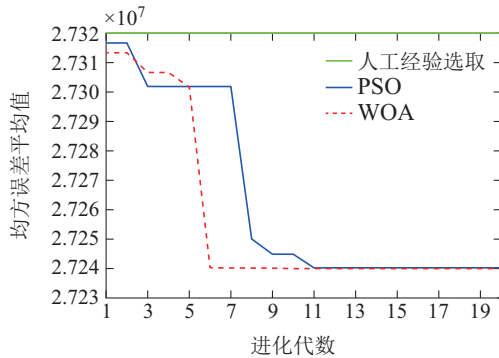


图6 不同算法均方误差平均值的寻优过程

Fig. 6 Optimization process of the mean square error of different algorithms

表4 预测模型相似日天数及实验结果

Table 4 Optimization process of mean square error of different algorithms

优化方法	相似日天数	均方误差平均值($\times 10^7$)
人工经验选取	5	2.7322
PSO	7	2.7241
WOA	6	2.7239

由图6和表4可知, 人工经验选取的均方误差平均值远高于PSO和WOA. PSO和WOA在均方误差平均值基本一致的情况下, WOA在第6代收敛获得最佳参数, PSO在第11代收敛获得最佳参数, 从优化速度来看, WOA比PSO拥有更佳的寻优速度.

综上所述, WOA能自动确定最佳分解参数和相似日天数, 避免了人工经验确定带来的随机性, 提升了VMD和预测模型的精度. 同时, WOA相较于PSO等算法, 在优化速度和优化性能上有显著优势.

4.4 实例分析

4.4.1 不同类型数据集的实例对比分析

为了验证负荷与特征融合数据集的优越性, 本文选用3种类型数据集对比实验. I型数据集采用预测日前6天的历史负荷序列作为输入数据; II型数据集采用传统相似日方法筛选的负荷序列作为输入数据, 即通过灰色关联分析法计算每个历史日与预测日的总体特征相似度^[18], 选择前6个相似日的负荷序列组成数据集; III型数据集采用第4.2节中构建的负荷与特征融

合数据集作为输入数据. 为了保证实验的合理性, 预测模型均采用WOA-VMD-BiLSTM模型. 最终的结果如图7和表5所示.

由图7及表5可知, I型数据集各项误差指标均为最高. 相较于II型数据集, III型数据集MAPE下降了56%, RMSE和MAE分别下降至78和42, 拥有更好的预测精度, 验证了本文所提负荷与特征融合数据集的优越性.




图7 各类型数据集的预测结果曲线

Fig. 7 Prediction result curves of each type of data set

表5 各数据集的预测准确率对比

Table 5 Comparison of prediction accuracy of each data set

数据集	RMSE	MAPE/%	MAE
I型数据集	249	1.92	124
II型数据集	193	1.34	100
III型数据集	78	0.58	42

4.4.2 不同模型的实例对比分析

为了验证WOA-VMD-BiLSTM预测模型的优越性, 本文在保证输入数据皆为负荷与特征融合数据集的条件下, 选择5种预测模型进行对比试验, 分别为BiLSTM, VMD-Elman, VMD-BiLSTM, PSO-VMD-BiLSTM和WOA-VMD-BiLSTM. 同时, 为了保证实验的合理性, BiLSTM和Elman神经网络的隐含层参数设置相同, 隐含层节点设置为16, 最大迭代次数为100, 初始学习率为0.01, 激活函数均选取tanh函数. 5种预测模型的结果如图8和表6所示.

由图8及表6可知, 相较于后4种组合模型, BiLSTM单模型的预测精度有限, 加入VMD后, 将非线性序列转换为多个简单模态分量, 数据复杂性的降低使得预测模型的精度得到提升, 验证了VMD算法的有效性; 在经过VMD分解后, BiLSTM相较于传统的Elman神经网络, MAPE下降了28%, RMSE下降了45%, MAE下降了44%, 说明BiLSTM相较于传统的神经网络, 有更强的学习能力和预测精度; 经PSO和WOA优化分解参数和相似日天数后, 模型的预测能

力进一步提升,相较于 PSO-VMD-BiLSTM, WOA-VMD-BiLSTM 的 RMSE 和 MAE 分别下降至 78 和 42, MAPE 下降了 33%, 说明 WOA 优化的必要性和优越性. 综上所述, 本文提出的基于相似日和 BiLSTM 组合模型具有更快的预测速度和更高的预测精度.

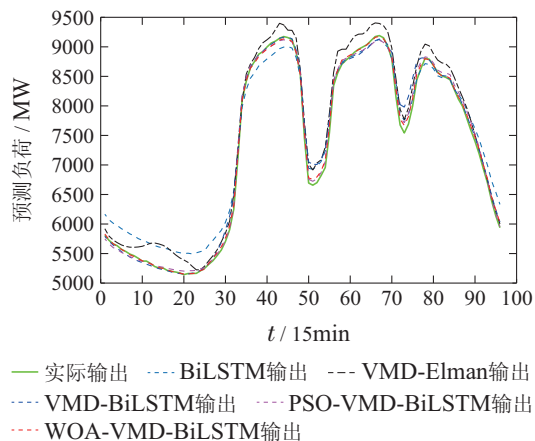


图 8 各预测模型的预测结果曲线

Fig. 8 Prediction results curves of each prediction mode

表 6 各预测模型的预测结果对比

Table 6 Comparison of prediction result of each prediction model

优化方法	RMSE	MAPE/%	MAE
BILSTM	343	3.34	206
VMD-Elman	282	2.44	174
VMD-BiLSTM	204	1.33	97
PSO-VMD-BiLSTM	114	0.87	62
WOA-VMD-BiLSTM	78	0.58	42

5 结论

本文基于相似日和 BiLSTM 组合模型开展短期电力负荷预测, 结合实例计算和误差分析得到以下结论:

1) 针对电力负荷规律性强的特点, 本文从曲线相似性入手, 通过曲线趋势度和差异度联合算法对相似日选取方法进行改进, 提升了相似日质量.

2) 本文构建负荷与特征融合数据集输入预测模型, 实现电力数据时序性信息和特征信息的融合, 避免了输入数据类型单一的问题.

3) 针对电力负荷为非线性时序数据的特点, 构建 VMD-BiLSTM 组合预测模型, 将复杂的序列分解为多个简单的子模态序列单独预测, 降低了预测难度. 在此基础上, 引入 WOA 算法对预测模型的分解参数和相似日天数进行优化, 减少了模型的固有误差, 进一步提升了预测精度.

4) 以新英格兰某地区的负荷数据集为例, 基于相似日和 BiLSTM 组合模型的预测方法相比于对照模型, 表现出更高的预测精度, 验证了该方法的有效性.

参考文献:

- [1] LINA A, QUSAY N. Short-term load forecasting for jordan power system based on narx-elman neural network and arma model. *IEEE Canadian Journal of Electrical and Computer Engineering*, 2021, 44(3): 356 – 363.
- [2] GUO Y, LI Y, QIAO X B, et al. BiLSTM multi-task learning based combined load forecasting considering the loads coupling relationship for multi-energy system. *IEEE Transactions on Smart Grid*, 2022, 13(5): 3481 – 3492.
- [3] GE Q B, GUO C, JIANG H Y, et al. Industrial power load forecasting method based on reinforcement learning and PSO-LSSVM. *IEEE Transactions on Cybernetics*, 2022, 52(2): 1112 – 1124.
- [4] XU Yan, XIANG Yifeng, MA Tianxiang. Short term power load forecasting based on EMD-CNN-LSTM hybrid model. *Journal of North China Electric Power University (Natural Science Edition)*, 2022, 49(2): 81 – 89.
(徐岩, 向益锋, 马天祥. 基于 EMD-CNN-LSTM 混合模型的短期电力负荷预测. 华北电力大学学报(自然科学版), 2022, 49(2): 81 – 89.)
- [5] SHENG Siqing, JIN Hang, LIU Changrong. Medium short term and short-term prediction of wind farm power generation based on VMD-WSGRU. *Power System Technology*, 2022, 46(3): 897 – 904.
(盛四清, 金航, 刘长荣. 基于 VMD-WSGRU 的风电场发电功率中短期及短期预测. 电网技术, 2022, 46(3): 897 – 904.)
- [6] CHENG Zhiyou, ZHANG Yangfan. Short term power load forecasting method under the influence of epidemic based on fear index. *Transactions of Beijing Institute of Technology*, 2021, 41(9): 961 – 969.
(程志友, 章杨凡. 基于恐惧指数的疫情影响下短期电力负荷预测方法. 北京理工大学学报, 2021, 41(9): 961 – 969.)
- [7] QI Xiaoyan, LIU Hengjie, HOU Qiuhua, et al. Short term power load forecasting of iron and steel enterprises integrating LSTM and SVM. *Journal of Shandong University (Engineering Science)*, 2021, 51(4): 91 – 98.
(亓晓燕, 刘恒杰, 侯秋华, 等. 融合 LSTM 和 SVM 的钢铁企业电力负荷短期预测. 山东大学学报(工学版), 2021, 51(4): 91 – 98.)
- [8] WANG Kaiyan, DU Haodong, JIA Rong, et al. Short range probability prediction of photovoltaic power based on similar day clustering and QR-CNN-BiLSTM model. *High Voltage Technology*, 2022, 48(11): 4372 – 4388.
(王开艳, 杜浩东, 贾嵘, 等. 基于相似日聚类 and QR-CNN-BiLSTM 模型的光伏功率短期区间概率预测. 高电压技术, 2022, 48(11): 4372 – 4388.)
- [9] WU Yun, LEI Jianwen, BAO Lishan, et al. Short term load forecasting based on improved grey relational analysis and bat optimized neural network. *Automation of Electric Power Systems*, 2018, 42(20): 67 – 72.
(吴云, 雷建文, 鲍丽山, 等. 基于改进灰色关联分析与蝙蝠优化神经网络的短期负荷预测. 电力系统自动化, 2018, 42(20): 67 – 72.)
- [10] WANG Jianfeng, XIANG Tiejuan, XU Fuxiang, et al. Short term load forecasting based on segmented multi-objective similar day selection method. *Engineering Journal of Wuhan University*, 2016, 49(3): 435 – 440.
(王剑锋, 向铁元, 徐富祥, 等. 基于分段多目标相似日选取法的短期负荷预测. 武汉大学学报(工学版), 2016, 49(3): 435 – 440.)
- [11] MO Weiren, ZHANG Boming, SUN Hongbin, et al. Discussion on selecting similar days in short-term load forecasting. *Journal of Tsinghua University (Science and Technology)*, 2004, 44(1): 106 – 109.
(莫维仁, 张伯明, 孙宏斌, 等. 短期负荷预测中选择相似日的探讨. 清华大学学报(自然科学版), 2004, 44(1): 106 – 109.)

- [12] SHANG Liqun, LI Hongbo, HOU Yadong, et al. Short term power load forecasting based on feature selection and optimized limit learning machine. *Journal of Xi'an Jiaotong University*, 2022, 56(4): 165 – 175.
(商立群, 李洪波, 侯亚东, 等. 基于特征选择和优化极限学习机的短期电力负荷预测. 西安交通大学学报, 2022, 56(4): 165 – 175.)
- [13] YE Jiahao, WEI Xia, HUANG Qide, et al. Short term prediction of BSO ELM AdaBoost wind power based on grey correlation analysis. *Acta Energiæ Solaris Sinica*, 2022, 43(3): 426 – 432.
(叶家豪, 魏霞, 黄启德, 等. 基于灰色关联分析的BSO-ELM-AdaBoost风电功率短期预测. 太阳能学报, 2022, 43(3): 426 – 432.)
- [14] YIN Xunlong, MOU Zonglei, WANG Youqing. Fault diagnosis of rotating machinery based on DVMD noise reduction. *Control Theory & Applications*, 2022, 39(7): 1324 – 1334.
(尹逊龙, 牟宗磊, 王友清. 基于DVMD降噪的旋转机械故障诊断. 控制理论与应用, 2022, 39(7): 1324 – 1334.)
- [15] TANG Guiji, WANG Xiaolong. Application of optimized variational mode decomposition method in early fault diagnosis of rolling bearings. *Journal of Xi'an Jiaotong University*, 2015, 49(5): 73 – 81.
(唐贵基, 王晓龙. 优化变分模态分解方法在滚动轴承早期故障诊断中的应用. 西安交通大学学报, 2015, 49(5): 73 – 81.)
- [16] FENG Wentao, DENG Bing. Global convergence analysis and parameter selection of whale optimization algorithm. *Control Theory & Applications*, 2021, 38(5): 641 – 651.
(冯文涛, 邓兵. 鲸鱼优化算法的全局收敛性分析及参数选择. 控制理论与应用, 2021, 38(5): 641 – 651.)
- [17] Motepe S, HASAN A N, TWALA B, et al. Effective load forecasting for large power consuming industrial customers using long short-term memory recurrent neural networks. *Journal of Intelligent & Fuzzy Systems*, 2019, 37(6): 8219 – 8235.
- [18] LI Bin, LU Mingzhen. Short term load forecasting model of regional power grid considering real-time meteorological coupling. *Automation of Electric Power Systems*, 2020, 44(17): 60 – 68.
(李滨, 陆明珍. 考虑实时气象耦合作用的地区电网短期负荷预测模型. 电力系统自动化, 2020, 44(17): 60 – 68.)

作者简介:

祁宇轩 硕士研究生, 目前研究方向为短期电力负荷预测与深度学习, E-mail: nldqyx@163.com;

范俊岩 博士研究生, 目前研究方向为钢铁生产特征表征分析、副产煤气预测与调度, E-mail: fjiy201807@163.com;

吴定会 教授, 目前研究方向为多能源介质预测、优化调度, E-mail: wdh123@jiangnan.edu.cn;

汪晶 高级工程师, 目前研究方向为多能源介质预测、优化调度, E-mail: wangjing@baosight.com.