

doi:10.11835/j.issn.1000.582X.2024.04.011

参数优化变分模态分解与 LSTM 的电力物资需求预测

向洪伟¹, 曹馨雨², 张丽娟¹, 周楚婷², 张迪¹, 邓晨凤¹, 谢鸿鹏¹, 王楷²

(1. 国网重庆招标有限公司, 重庆 401121; 2. 重庆大学自动化学院, 重庆 400044)

摘要: 国家电网物资采购管理水平不断提高, 线上采购流程逐步完善, 但仍存在由于采购计划预估不准导致招投标过程中, 供应商利用招投标总标包机制进行价格博弈而造成电网公司采购成本增加, 因此, 建立准确有效的电力物资需求预测模型具有重要意义。针对电力物资序列的非稳定性、波动性和间歇性特点, 提出一种基于参数优化变分模态分解 (variational mode decomposition, VMD) 与长短时记忆神经网络 (long short-term memory, LSTM) 的电力物资需求预测方法, 选取国网电商专区平台的典型电力物资, 采用鲸鱼优化算法 (whale optimization algorithm, WOA) 参数优化的 VMD 对原始序列进行模态分解, 将分解获得的各模态分量分别构建 LSTM 模型, 最后将各模态的预测值叠加重构为电力物资的预测值。实验结果表明: 所提电力物资需求预测方法较 LSTM、EMD-LSTM、VMD-LSTM、PSO-VMD-LSTM、SSA-VMD-LSTM 有更高的准确率, 对电网物资采购预测具有一定实际意义。

关键词: 电力物资; 长短期记忆神经网络; 变分模态分解; 鲸鱼优化算法; 时间序列

中图分类号: TP39

文献标志码: A

文章编号: 1000-582X(2024)04-127-12

A power material demand forecasting method based on parameter optimization variational mode decomposition and LSTM

XIANG Hongwei¹, CAO Xinyu², ZHANG Lijuan¹, ZHOU Chuting², ZHANG Di¹,
DENG Chenfeng¹, XIE Hongpeng¹, WANG Kai²

(1. State Grid Chongqing Tendering Co., Ltd., Chongqing 401121, P. R. China; 2. College of Automation, Chongqing University, Chongqing 400044, P. R. China)

Abstract: The State Grid has continuously improved its material procurement management level and refined its online procurement processes. However, inaccurate estimation of procurement plans, has led suppliers to engage in price games using the general bidding and tendering mechanism during the bidding process. This has resulted in

收稿日期: 2023-11-05

基金项目: 国家电网有限公司科技资助项目 (SGCQWZ00ZBJS2313256)。

Supported by State Grid Corporation of China Science and Technology Project (SGCQWZ00ZBJS2313256).

作者简介: 向洪伟 (1994—), 男, 工程师, 主要从事电网物资计划管理、电网物资需求预测等方向研究, (E-mail) 373217391@qq.com。

通信作者: 王楷 (1981—), 男, 博士, 副教授, (E-mail) kaiwang@cqu.edu.cn。

increased procurement costs of the power grid company. Therefore, it is of great significance to establish an accurate and effective electricity material demand forecasting model. In response to the instability, volatility and intermittency of power material sequences, this paper proposes a forecasting method for power material demand based on parameter-optimized variational mode decomposition (VMD) and long short-term memory neural network (LSTM). Typical power materials from the State Grid e-commerce zone platform were selected. VMD, optimized by using the whale optimization algorithm(WOA) parameters, was adopted to perform modal decomposition on the original sequence. LSTM models were then constructed for each modal component obtained from the decomposition. Finally, the predicted values of each mode were superimposed and reconstructed into the predicted value of power materials. Experimental results show that the proposed method achieves higher prediction accuracy compared to LSTM, EMD-LSTM, VMD-LSTM, PSO-VMD-LSTM and SSA-VMD-LSTM. This approach holds practical significance for the forecast of power grid material purchase.

Keywords: power materials; long short-term memory neural network; variational mode decomposition; whale optimization algorithm; time series

随着国家电网采购交易管理水平的提高和现代化智慧供应链体系的完善,公司采购全面数字化,物资采购活动在国网电子商务平台全流程在线实施。当前物资公司的采购模式是在年初制定下一年度电力物资清单进行公开招标、按照总标包中标与供应商签订年度采购合同,但是在实际执行合同过程中,物资公司将中标的物资作为单个商品放进电商专区平台按照物资中标单价执行。在这种总标包模式下,供应商往往会在一些预期需求量较小的电力物资上报高价,同时在其他电力物资上报低价,以最终总价偏低的方式击败竞争对手。但是在执行过程中采购的电力物资比例又与计划需求存在差异,较高单价的电力物资实际需求量较大,导致公司采购成本增加,因此准确预测下一年度电力物资数量对于物资公司统筹计划意义重大。电力物资电商专区的物资种类繁多且消耗特点各异,这导致电力物资需求的预测方法要灵活适应各物资的实际消耗特点。

针对电力物资需求预测,国内外学者使用不同方法进行研究。传统的预测模型如回归分析^[1]、指数平滑^[2]较为简单,在面对非线性、非平稳的复杂数据时效果欠佳。时间序列预测方法如差分整合移动平均自回归(autoregressive integrated moving average model, ARIMA)^[3]、季节性差分整合移动平均自回归(seasonal autoregressive integrated moving average model, SARIMA)^[4]等在预测时充分考虑了时间序列的周期性、季节性、随机性等特点,有较好预测效果,但此类方法对于数据要求较高,需要满足数据平稳、残差正态分布的假设,同时针对不同数据需要选择合适的阶数以满足精度需求。近年来,机器学习在电力物资需求预测的应用中广泛展开。杨迪等^[5]构建了融合多部门数据的电力工程物资数据空间,建立基于树模型的物资预测模型准确预测电力工程的物资需求;牛凯等^[6]基于先知(Prophet)算法对各种时间序列特征进行分析,处理具有异常值和趋势变化的周期性数据,准确预测短期内的电力物资需求;Dai等^[7]针对单一预测模型无法准确预测所有类型物资需求的问题,采用基于特征融合和多模型堆叠方式,充分发挥多个模型的优势提高整体电力物资预测精度;陶加贵等^[8]根据电力物资数据集的分布和特征,提出蒙特卡洛模拟扩充数据集,建立基于引导聚集算法的长短期记忆(long short-term memory, LSTM)电力物资需求预测模型,提高小样本情况下物资预测精度和泛化能力。当前在电力物资需求领域展开的研究,有效验证机器学习在处理复杂预测任务上的优势,但也存在过度依赖数据或者小样本环境下效果有限问题,因此研究兼顾预测精度与鲁棒性的预测模型很有必要。

针对电力物资序列具有非平稳性、间歇性等特点,直接使用原始序列作为输入会忽略掉序列真正的随机扰动规律,常用的序列分解方法有经验模态分解(empirical mode decomposition, EMD)^[9]、集合经验模态分解(ensemble empirical mode decomposition, EEMD)^[10]等,但EMD存在模态混杂和断点效应,EEMD运行效率低,可能会对模态分解造成影响从而降低预测精度。而变分模态分解(variational mode decomposition, VMD)通过带通滤波确定每个模态分量的中心频率,有效避免模态频率偏移,同时VMD算法时间复杂度较低,计算

速度较快。Wang等^[11]以火电行业的煤炭需求作为研究对象,提出基于数据驱动与分解集成的煤炭需求预测模型,结合各行业的煤炭实际消耗特点,采用VMD分解煤炭消耗数据,结合最小二乘支持向量机(least squares support vector machine, LSSVM)对各行业的煤炭需求进行预测,在实验中表现出较好预测精度。VMD分解时间序列数据的时候需要按照序列特点和经验设定参数,人为参数设定的偶然性和不稳定性会影响模型的预测精度,因此有必要对VMD参数进行寻优。参数优化算法例如粒子群算法(particle swarm optimization, PSO)^[12]、遗传算法(genetic algorithm, GA)^[13]、鲸鱼优化算法(whale optimization algorithm, WOA)^[14]和麻雀算法(sparrow search algorithm, SSA)^[15]等在VMD参数优化中有较多应用。相比之下,PSO简单易实现却收敛慢、易陷入局部最优解,GA计算量大且需要针对不同问题创建合适的表示形式,SSA和WOA收敛快且不易陷入局部解,笔者结合电力物资数据低维度特点且存在连续或间歇序列的情况,采用通过WOA进行参数寻优的VMD对电力物资进行参数寻优的方法对电力物资原始序列进行模态分解,获得最优模态分量序列,再将各序列分别输入LSTM模型获得各模态分量的预测值,将预测结果重构后得到最终电力物资预测结果。

1 基于参数优化的VMD-LSTM的电力物资需求预测模型架构设计

基于参数优化的VMD-LSTM模型建立电力物资需求预测模型,其预测过程如图1所示。采用WOA-VMD分解原始数据,减少电力物资序列的随机性,接着将分解后的各模态分量构建不同的LSTM预测模型,不同模态分量得出预测结果后重构得到总体预测结果,将结果与LSTM、EMD-LSTM、VMD-LSTM、PSO-VMD-LSTM、SSA-VMD-LSTM获得的结果进行对比,确保所提模型的准确性、可行性。研究思路如下:

- 1) 收集4种电商专区典型电力物资历史数据,进行异常点处理、缺失值处理、数据按月重采样以及数据归一化操作;
- 2) 由于电力物资消耗原始序列具有非稳定性、波动性和间歇性,使用WOA-VMD对原始序列进行模态分解;
- 3) 将分解后的各个模态分量分别构建LSTM预测模型,分别获得各模态分量的预测值;
- 4) 将各模态分量的预测值进行叠加,得到电力物资预测值,并计算各误差评价指标;
- 5) 分别构建LSTM、EMD-LSTM、VMD-LSTM、PSO-VMD-LSTM、SSA-VMD-LSTM 5种预测模型作对比,将4组不同电力物资作为输入,评估分析模型的有效性和准确性。

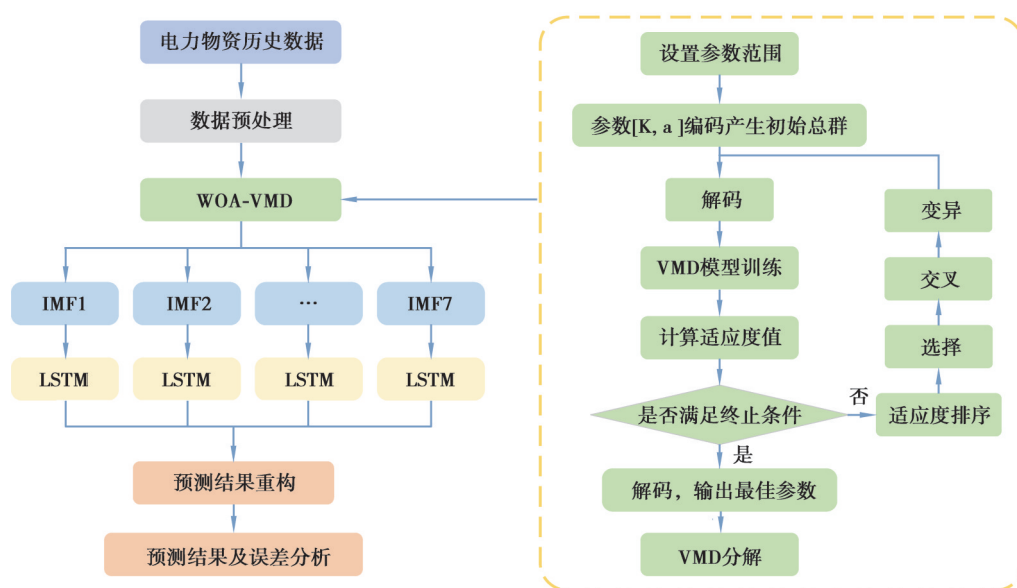


图1 基于WOA-VMD-LSTM的电力物资需求预测模型结构

Fig. 1 The structure of power material demand forecasting model based on WOA-VMD-LSTM

2 研究方法

2.1 基于WOA-VMD的电力物资序列模态分解

由于电力物资原始序列消耗曲线存在较强的波动性,为了有效建模,研究采用VMD对序列进行分解。VMD算法^[16]需要预先设置模态分解的个数 K 和惩罚因子 α 。但在处理不同原始序列时,为取得最佳分解效果, K 和 α 的值需要针对每个序列进行单独设定。为了实现参数的自适应优化,笔者使用WOA来搜索不同序列对应的 K 和 α 最优值,有效提升VMD对每个特定序列的分解性能,更准确地挖掘序列内在的模式结构。

2.1.1 VMD算法

VMD是一种依赖于变分模型的自适应非递归信号处理方法。该方法的主要思想是生成并求解变分问题,通过确定变分模型的最优解来实现自适应信号分解^[17-18]。假设电力物资原始序列被分解为 K 个模态,每个模态的有限频带有一个中心频率,使得各分解模态的估计带宽之和最小,约束变分表达式

$$\begin{cases} \min_{\{\nu_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left(\partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * \mu_k(t) \right] e^{-j\omega_k t} \right)_2^2 \right\}, \\ \text{s.t.} \sum_{k=1}^K \mu_k = f, \end{cases} \quad (1)$$

其中: K 表示分解的IMF的数量; $\{\mu_k\}$ 表示分解的模态信号集合; $\{\omega_k\}$ 表示中心频率的集合; $\delta(t)$ 表示狄拉克函数;*表示卷积算子; f 表示原始信号。该方程可以使用增广拉格朗日乘法算子来求解,将约束问题转变为非约束问题,其表达式如式(2)所示

$$\begin{aligned} L(\{\mu_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_{k=1}^K \left(\partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * \mu_k(t) \right] e^{-j\omega_k t} \right)_2^2 + \\ & \left(f(t) - \sum_{k=1}^K \mu_k(t) \right)_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K \mu_k(t) \right\rangle, \end{aligned} \quad (2)$$

其中: α 表示减少高斯噪声干扰的惩罚因子; λ 表示拉格朗日乘子。增广拉格朗日求解无约束的变分问题将最小化的问题变为寻找鞍点。

采用交替方向乘子法(ADMM)不断迭代计算 $\{\mu_k\}$ 、 $\{\omega_k\}$ 、 λ 3个参数的值,直至满足式(3)的条件,即达到最终结果。

$$\frac{\sum_{k=1}^K \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{(\hat{u}_k^n)_2^2} < \varepsilon_0. \quad (3)$$

此时VMD根据先验设定的 K 和 α 分解出对应的IMF序列分量。

2.1.2 WOA优化VMD参数

由VMD算法的原理可知,需要在实验开始前设定 K 和 α 参数的值,人为设置VMD参数有很强的主观性,对于VMD分解的结果有很大偶然性,且在进行多组数据实验时,每次单独设置不同的 K 和 α 值会导致模型泛化性低,因此采用WOA优化算法对VMD的参数进全局寻优^[19-21]。WOA是一种模拟座头鲸特殊捕食行为的群智能优化算法。采用随机或最佳搜索代理来模拟捕猎行为,并使用螺旋来模拟座头鲸的气泡网攻击机制,具有搜索能力强、能够跳出局部最优且收敛速度快等优点。WOA优化VMD算法的实现步骤如下^[22-23]

1) 初始化鲸鱼群体

生成 N 头鲸鱼作为初始群体,每个鲸鱼位置 \mathbf{X}_i 包含VMD的参数 K 和 α ,其中 \mathbf{X}_i 定义如下

$$\mathbf{X}_i = (K_i, \alpha_i). \quad (4)$$

其中: K_i 为第 i 头鲸对应的 K 值; α_i 为对应的 α 值; K_i 的取值范围为 $[K_{\min}, K_{\max}]$; α_i 的取值范围为 $[\alpha_{\min}, \alpha_{\max}]$ 。 K_i 和 α_i 生成公式为

$$K_i = K_{\min} + r \cdot (K_{\max} - K_{\min}), \quad (5)$$

$$\alpha_i = \alpha_{\min} + r \cdot (\alpha_{\min} - \alpha_{\max}), \quad (6)$$

其中, r 表示 $[0,1]$ 区间内的随机数。通过对 K 和 α 的随机初始化, 可以使鲸鱼群体位置 \mathbf{X}_i 在定义域内均匀分布, 保持种群多样性。

2) 适应度计算

对当前的 \mathbf{X}_i 进行 VMD 分解, 计算最小包络熵作为适应度函数进行参数寻优, 适应度函数为

$$f(\mathbf{X}_i) = \frac{1}{E_i}, \quad (7)$$

其中, E_i 为当前位置各模态分量包络的熵值, E_i 越小表示分解效果越好。

3) 迭代更新位置

根据随机概率值 p 决定更新方式, p 是一个在 $[0,1]$ 区间内生成的随机数。

$$\mathbf{A} = 2a \cdot r_1 - a, \quad (8)$$

$$\mathbf{C} = 2 \cdot r_2, \quad (9)$$

$$a = 2 - 2 \left(\frac{t}{t_{\max}} \right), \quad (10)$$

其中: \mathbf{A} 和 \mathbf{C} 为系数向量; r_1, r_2 均为 $[0,1]$ 区间的随机数; t 表示迭代次数; t_{\max} 表示最大迭代次数, a 表示收敛因子。

当 $p < 0.5$, 且 $|\mathbf{A}| < 1$ 时, 执行气泡网捕食机制, 当前个体更新位置公式如下

$$\mathbf{X}_i^{t+1} = \mathbf{X}_{\text{best}}^t - \mathbf{A} \cdot \mathbf{D}, \quad (11)$$

$$\mathbf{D} = |\mathbf{C} \cdot \mathbf{X}_{\text{best}}^t - \mathbf{X}_i^t|, \quad (12)$$

其中: $\mathbf{X}_{\text{best}}^t$ 是搜索第 t 代时种群取得全局最优解的个体位置; \mathbf{X}_i^t 就表示第 t 代第 i 个个体的位置; \mathbf{D} 表示包围步长; b 是控制对数螺旋形状的常数; l 是 $[-1, 1]$ 上的一个随机数。

当 $p < 0.5$, 且 $|\mathbf{A}| \geq 1$ 时, 执行螺旋更新机制, 当前个体使用螺旋气泡袭击的方式更新位置

$$\mathbf{X}_i^{t+1} = \mathbf{D} \cdot e^{bl} \cdot \text{ecos}(2\pi l) + \mathbf{X}_{\text{best}}^t, \quad (13)$$

$$\mathbf{D} = |\mathbf{X}_{\text{best}}^t - \mathbf{X}_i^t|,$$

其中, b 是控制对数螺旋形状的常数, l 是 $[-1, 1]$ 上的一个随机数。

当 $p \geq 0.5$ 时, 执行全局随机搜索猎物, 更新公式如下

$$\mathbf{X}_i^{t+1} = \mathbf{X}_{\text{rand}}^t - \mathbf{A} \cdot \mathbf{D}, \quad (14)$$

$$\mathbf{D} = |\mathbf{C} \cdot \mathbf{X}_{\text{rand}}^t - \mathbf{X}_i^t|, \quad (15)$$

其中, $\mathbf{X}_{\text{rand}}^t$ 是从当前种群中随机选择一个个体的位置。

4) 返回最优参数

当迭代次数 t 达到最大, 且收敛因子下降至 0 时停止搜索, 输出最终的全局最优解作为 VMD 的最优 K 和 α 。

2.2 LSTM 模型

考虑到电力物资序列长短不一、频率各异, 且有新产生的数据会补充到模型中进行持续学习, 因此, 采用 LSTM 对电力物资分解后的各模态分量分别建立预测模型, 快速捕捉时间序列中长期和短期的依赖关系, 准确有效完成各模态分量的预测任务。

LSTM 作为循环神经网络 (recurrent neural network, RNN) 的一个变种, 通过门单元解决了 RNN 梯度消失和梯度爆炸的问题, 使网络更快更好收敛, 提高预测精确度^[24-26]。LSTM 由一系列 LSTM 单元组成, 每个 LSTM 单元中有 3 种门结构来控制信息的流动和存储, 分别是输入门、遗忘门和输出门, 其基本结构如图 2 所示。

遗忘门和输入门都作用于 LSTM 单元的内部状态, 分别控制遗忘多少前一个时间步内部状态的信息和吸收多少当前时刻的输入信息, 若门的值为 0, 即不遗忘和完全不吸收, 若门的值为 1, 即完全遗忘和全部吸

收。输出门在隐层 h 发挥作用,主要决定该单元的内部状态对系统整体状态的影响。输入门(i_t)、遗忘门(f_t)和输出门(o_t)如式(16)~式(18)。

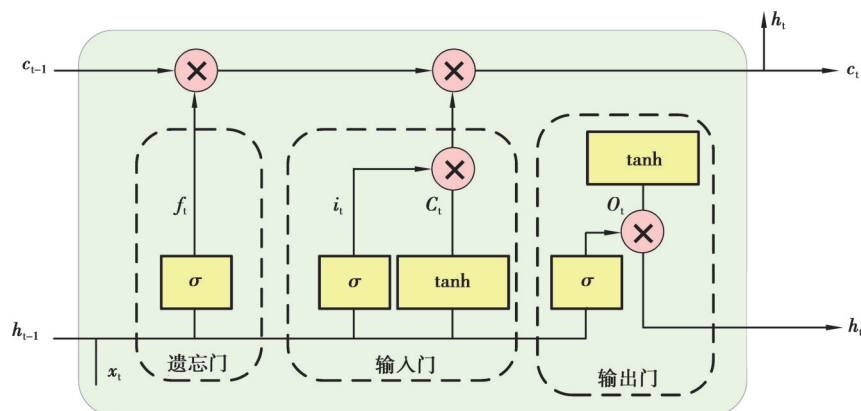


图2 LSTM 结构图

Fig. 2 Structure diagram of LSTM

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \quad (16)$$

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f), \quad (17)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), \quad (18)$$

其中:权重矩阵由 W_i 、 W_f 和 W_o 表示; b_i 、 b_f 和 b_o 表示相应的偏差。LSTM 单元在最后时刻的输出分数表示为 h_{t-1} , 时刻 t 的输入表示为 x_t , σ 是范围为(0,1)的 sigmoid 激活函数。

在 t 时刻 LSTM 的记忆单元 c_t 公式为

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t. \quad (19)$$

在此时刻的输出(h_t)为

$$h_t = o_t * \tanh(c_t). \quad (20)$$

3 数据来源与评价指标

3.1 数据来源

数据以国网重庆市物资分公司 2017-2023 年的电商专区电力物资采购情况为例进行实证分析,数据来自于国网重庆市电商专区和国网重庆市 ERP 采购平台。统计后发现电商平台涉及的电力物资共有 12 572 种不同唯一标识的物资,分为 15 个大类,71 个中类和 686 个小类,根据上报计划表和实际执行情况表,选取执行情况较上报计划偏差大于 5 倍和执行总量大于 1 000 件的典型物资进行预测分析,由于电商平台电力物资采购有效数据长度并不固定,因此选用 2 组较长和 2 组较短的数据作为实验对象,主要电力物资数据如表 1 所示。

表 1 典型物资执行情况表

Table 1 Table of implementation of typical materials

物资	物资类别	执行偏差倍数/倍	执行总量/件	数据量/个
A 物资	五金材料	55.10	57 607	70
B 物资	五金材料	81.50	382 144	64
C 物资	劳保用品	13.80	3 495	40
D 物资	工器具	6.79	9 728	40

由于实际线上采购过程中会出现单个订单请购数量过大的情况,会对后续建立的预测模型产生不利影响,因此采用四分位间距(IQR)法进行异常值筛选,即利用上下四分位数来构建正常的区间范围,将不在正常区间的数据进行剔除。

同时考虑到电网物资采购数据存在不规律的时间间隔,个别月份没有任何采购记录,即原始数据存在严重的缺失值问题,笔者主要研究年度电力物资需求趋势,因此对原始数据进行月度重采样,将其重构为月度的时间序列数据,为保证时间序列数据的完整性,采用空值填充的策略将无采购记录的月份请购数量赋值为0。数据预处理后的典型物资A消耗曲线如图3所示。




图3 典型电力物资A消耗曲线

Fig. 3 Typical power material A consumption curve

3.2 评价指标

由于不同组的电力物资序列的量级和数值范围存在差异,为公平比较不同模型的表现,采用最小—最归一化方法对各组电力物资数据进行归一化处理

$$X^* = \frac{X - X_{\min}}{X_{\max} - X_{\min}}, \quad (21)$$

其中: X^* 为归一化后的值; X_{\min} 为当前序列中数据的最小值; X_{\max} 为当前序列中数据的最大值。

综合多种评价指标的评价预测性能,采用平均绝对误差(MAE)、均方根误差(RMSE)和平均绝对百分误差(MAPE)作为评价指标,其计算公式如式(22)

$$\begin{cases} \text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|, \\ \text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2}, \\ \text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right|, \end{cases} \quad (22)$$

其中: n 表示总体样本数量; y_i 和 \hat{y}_i 分别表示电力物资归一化后的实际值和预测值。

4 实验与分析

4.1 基于WOA-VMD的电力物资模态分解结果

由于需要预测年度电力物资的消耗曲线,因此将实验数据中的最后12个点用于测试,其余点用于训练。设置鲸鱼个数为30, t_{\max} 设置为100, K 取值为[2,10]的整数, α 取值[100,5 000],对4组数据进行WOA-VMD算法的最优参数如表2所示。以A物资为例,经过WOA优化后,VMD最优参数为 $K = 7, \alpha = 1 000$,分解后的IMF分量如图4所示。

从表2可以看出,使用WOA-VMD分别对多个电力物资进行分解后,分别产生对应序列最优的 K 和 α 值,同时由图4可以看出分解后的各模态分量频率区分明显,分解后的每个模态分类既能保证电力物资原始序列的特征又能抑制模态的混叠。

表2 WOA-VMD最优参数表
Table 2 WOA-VMD optimal parameter list

物资	K	α
A物资	7	1 000
B物资	9	1 253
C物资	8	1 000
D物资	9	4 093




图4 WOA-VMD分解A物资序列效果

Fig. 4 Rendering of A material sequence based on WOA-VMD decomposition

4.2 基于参数优化的VMD-LSTM的电力物资预测


在WOA-VMD模态分解的基础上,采用LSTM对VMD提取的IMF序列分量进行分别建模。LSTM模型能学习时间序列的长短期依赖关系,能更好构建每个IMF序列分量的内在规律。在LSTM中,迭代次数设置为100,训练批次大小为12,隐藏层为64,步长为4,学习率为0.001,采用Adam优化器。为验证模型的有效性

和准确性,分别构建 LSTM, EMD-LSTM, VMD-LSTM, PSO-VMD-LSTM, SSA-VMD-LSTM, WOA-VMD-LSTM 在 4 组数据上进行对比实验,多次实验后整理误差评价指标结果如表 3 所示,对比图如图 5-6 所示。


表 3 不同模型预测误差比较

Table 3 Comparison table of prediction errors of different models


物资	模型	MAE	RMSE	MAPE/%
A 物资	LSTM	0.177 4	0.185 4	118.75
	EMD-LSTM	0.052 1	0.057 2	58.49
	VMD-LSTM	0.026 2	0.032 0	8.97
	PSO-VMD-LSTM	0.026 0	0.029 4	7.50
	SSA-VMD-LSTM	0.020 1	0.025 6	6.52
	WOA-VMD-LSTM	0.016 5	0.018 5	4.73
B 物资	LSTM	0.220 5	0.300 1	116.03
	EMD-LSTM	0.076 7	0.077 1	12.54
	VMD-LSTM	0.024 3	0.029 2	5.63
	PSO-VMD-LSTM	0.021 2	0.024 4	5.24
	SSA-VMD-LSTM	0.014 4	0.016 8	8.52
	WOA-VMD-LSTM	0.011 1	0.014 7	2.88
C 物资	LSTM	0.140 2	0.177 7	805.24
	EMD-LSTM	0.018 1	0.018 4	72.77
	VMD-LSTM	0.020 2	0.025 1	4.30
	PSO-VMD-LSTM	0.015 6	0.021 1	5.65
	SSA-VMD-LSTM	0.027 7	0.031 8	10.01
	WOA-VMD-LSTM	0.015 6	0.017 0	2.86
D 物资	LSTM	0.401 2	0.517	106.26
	EMD-LSTM	0.025 7	0.031 6	28.51
	VMD-LSTM	0.019 9	0.022 2	7.57
	PSO-VMD-LSTM	0.012 1	0.011 7	1.90
	SSA-VMD-LSTM	0.017 0	0.019 0	4.19
	WOA-VMD-LSTM	0.009 8	0.010 0	1.86




(a) A物资预测结果对比图



(b) B物资预测结果对比图



(c) D物资预测结果对比图



(d) D物资预测结果对比图

图5 不同物资模型预测结果对比图

Fig. 5 Comparison of prediction results of different material models

从表3中A物资的实验结果中可以看出,直接将原始数据输入LSTM模型实验误差很大,使用EMD和VMD进行模态分解后效果有不同程度提升,各项误差评价指标值均有大幅度降低。而在此实验中也表明VMD-LSTM相对于EMD-LSTM有更好表现,与LSTM相比,这2种模型的MAE分别降低240.40%和577.10%,RMSE分别降低224.13%、479.37%,MAPE分别降低60.26和109.78个百分点,这表明进行模态分解后的序列比原始序列获得了更多的信息,使预测精度大幅提升,也表明VMD具有自适应和完全非递归的特点,分解效果更好。对VMD分别加入PSO、SSA、WOA参数优化算法后,模型预测精度得到了明显提升,与VMD-LSTM相比,PSO-VMD-LSTM、SSA-VMD-LSTM和WOA-VMD-LSTM这3种模型的MAE分别降低0.77%、30.35%、58.79%;RMSE分别降低8.84%、25.00%、72.97%;MAPE分别降低1.47%、2.45%、4.24%,实验结果显示WOA-VMD-LSTM在这3项评价指标中均获得最好效果,采用WOA进行VMD的参数优化能最好

适应电力物资数据的特点,有效解决因参数设置而造成序列分解不当问题,有效降低模型的误差。纵向来看,从图5中可以看出,在4组不同长短的电力物资序列上,所提的基于WOA-VMD-LSTM电力物资预测模型较其余模型有最好表现。与VMD-LSTM模型的预测效果相比,对于较长A物资和B物资序列来说,WOA-VMD-LSTM模型分别将MAPE降低了4.24%和2.75%;对于较短的C物资和D物资序列来说,MAPE也分别降低了1.44%和5.71%。这表明模型在不同长度的序列均有显著优势,较好鲁棒性。




图6 优化VMD参数后A物资模型预测结果对比图

Fig. 6 Comparison of prediction results of A material model after optimizing VMD parameters

5 结 语

提出基于参数优化的VMD-LSTM电力物资需求预测算法,通过WOA对VMD进行参数寻优计算最佳模态分解个数 K 和惩罚因子 α ,使分解后的电力物资采购序列既能保持信息完整又能提取出序列不同频段的模态分量,将各模态分量分别输入LSTM进行训练并预测,将预测结果叠加重构后得到最终结果。为验证模型有效性和优越性,选取4组电力物资数据进行实验,实验表明在不同长度的序列上本模型都有较好的预测效果,具有较高准确度和鲁棒性,一定实际工程意义。研究只选用了较为典型的电力物资采购数据作为实验对象,实际电商平台的电力物资采购数据种类繁多且序列波动情况各异,未来将研究泛化性更高的电力物资预测算法。

参考文献

- [1] 胡亚楠,王铁铮,蒋昕晔,等.基于线性回归的电力物资配套采购数量的预测分析[J].农村经济与科技,2019,30(02):138-139.
Hu Y N, Wang T Z, Jiang X Y, et al. Prediction and analysis of purchasing quantity of electric power materials based on linear regression [J]. Rural Economics and Science and Technology, 2019, 30(02): 138-139. (in Chinese)
- [2] Bermúdez D J. Exponential smoothing with covariates applied to electricity demand forecast[J]. European J. of Industrial Engineering, 2013, 7(3): 333-349.
- [3] 丁靖,黄晓明,余乘龙.基于多因素融合与ARIMA的电力物资预测[J].能源与环境,2022,44(07):227-231.
Ding J, Huang X M, Yu C L. Power materials forecast based on multi-factor fusion and ARIMA [J]. Energy and Environmental Protection, 2022, 44(07): 227-231. (in Chinese)
- [4] 宋鑫磊,黎莫林,詹勤辉等.基于SARIMA与ANFIS组合方法的电力物资需求预测[J].机械设计,2022,39(06):66-72.
Song X L, Li M L, Zhan Qinhuai et al. Power material demand forecasting based on SARIMA and ANFIS combination method [J]. Journal of Mechanical Design, 2019, 39(06): 66-72. (in Chinese)
- [5] 杨迪.基于数据空间的电力工程物资需求智能预测[D].北京:华北电力大学,2023.
Yang D. Intelligent prediction of power engineering material demand based on data space [D]. Beijing: North China Electric Power University, 2023. (in Chinese)
- [6] 牛凯,洪芳华,费冬,等.基于Prophet算法的电力物资需求预测方法研究[J].科学技术创新,2020(33):163-164.
Niu K, Hong F H, Fei Det al. Research on power material demand forecasting method based on Prophet Algorithm [J]. Science and Technology Innovation, 2020(33): 163-164. (in Chinese)
- [7] Dai Z, Wang G, Bian R, et al. Power grid material demand forecasting based on pearson feature selection and multi-model fusion[J]. Frontiers in Energy Research. 2022;10:882818.
- [8] 陶加贵,孙毅,赵恒,等.电力物资小样本集的改进长短期需求预测模型[J].电气自动化,2023,45(01):50-53.
TAO J G, Sun Y, Zhao H, et al. Improved long and short term demand forecasting model for small sample set of electric power

- Materials [J]. *Electrical Automation*,2023,45(01):50-53. (in Chinese)
- [9] Liu Y Z , Wu G .Research on the prediction of short time series based on EMD-LSTM[J].*Journal of Computational Methods in Sciences and Engineering*,2023,23(5):2511-2524.
- [10] Yao H , Song G , Li Y . Displacement prediction of channel slope based on EEMD-IESSA-LSSVM cmbined Algorithm[J]. *Applied Sciences*,2023,13(17):9582.
- [11] Wang D, Tian C, Mao J, et al. Forecasting coal demand in key coal consuming industries based on the data-characteristic-driven decomposition ensemble model[J]. *Energy (Oxford)*, 2023,282:128841.
- [12] 赵峰,魏秀业,程海吉.基于 PSO-VMD-小波包阈值降噪的采煤机振动特性研究[J].*煤炭技术*,2022,41(04):147-150.
Zhao F, Wei X Y, Cheng H J. Research on vibration characteristics of shearer based on PSO-VMD-Wavelet packet threshold noise reduction [J]. *Coal Technology*, 2022,41(04):147-150. (in Chinese)
- [13] Liu Z J , Liu H Z . A novel hybrid model based on GA-VMD, sample entropy reconstruction and BiLSTM for wind speed prediction[J].*Measurement*,2023,222:113643.
- [14] 余建平,周新民,陈明.群体智能典型算法研究综述[J].*计算机工程与应用*,2010,46(25):1-4+74.
Yu J P, Zhou X M, Chen M. A review of typical algorithms for swarm Intelligence [J]. *Computer Engineering and Applications*, 2010,46(25):1-4+74. (in Chinese)
- [15] 莫宏毅,徐振洋,刘鑫等.基于 SSA-VMD 的爆破振动信号趋势项去除方法[J].*振动与冲击*,2023,42(11):304-312+330.
MO H Y, Xu Z Y, Liu X, et al. Removal method of Blasting vibration signal trend term based on SSA-VMD [J]. *Journal of Vibration and Shock*, 2019,42(11):304-312+330. (in Chinese)
- [16] Yu M , Niu D X, Gao T , et al. A novel framework for ultra-short-term interval wind power prediction based on RF-WOA-VMD and BiGRU optimized by the attention mechanism[J].*Energy*,2023,269:126738.
- [17] 卢志平,玉晓晶,陆成裕.融合 VMD 和 LSTM 模型的新能源汽车销量预测方法[J].*武汉理工大学学报(信息与管理工程版)*, 2023,45(04):546-551.
Lu Z P, Yu X J, Lu C Y. New energy vehicle sales forecasting method based on VMD and LSTM model [J]. *Journal of Wuhan University of Technology (Information and Management Engineering Edition)*,2023,45(04):546-551. (in Chinese)
- [18] Mingsan O ,Peicheng S .Prediction of remaining useful life of lithium batteries based on WOA-VMD and LSTM[J].*Energies*, 2022,15(23):8918-8918
- [19] Lei B ,Xiao Y, et al.Denoising method of hydro-turbine vibration signal based on Joint WOA-VMD and improved wavelet threshold[J].*Journal of Physics: Conference Series*,2023,2607(1):012005.
- [20] Wang W C , Wang B, Wing K C , et al.Monthly runoff time series interval prediction based on WOA-VMD-LSTM using non-parametric kernel density estimation[J].*Earth Science Informatics*,2023,16(3): 2373-2389
- [21] 戚庭野,卫会汝,冯国瑞,等.基于 WOA-VMD 的瞬变电磁探测信号降噪方法[J].*中南大学学报(自然科学版)*,2021,52(11): 3885-3898.
Qi T Y, Wei H R, Feng G R, et al. Noise reduction method of transient electromagnetic detection signal based on WOA-VMD [J]. *Journal of Central South University (Natural Science Edition)*,2021,52(11):3885-3898. (in Chinese)
- [22] 王彦快,孟佳东,张玉,等.基于参数优化 VMD 和改进 LSSVM 的道岔故障诊断方法[J/OL].*铁道科学与工程学报*:2023,1-13 [2024-02-27].<https://doi.org/10.19713/j.cnki.43-1423/u.T20231237>.
Wang Y K, Meng J D, Zhang Y, et al. Switch fault diagnosis method based on parameter optimization VMD and improved LSSVM [J/OL]. *Journal of Railway Science and Engineering* :2023,1-13 [2024-02-27].<https://doi.org/10.19713/j.cnki.43-1423/u.T20231237>.(in Chinese)
- [23] Lan C F, Song B W, Zhang L, et al.State prediction of hydro-turbine based on WOA-RF-Adaboost[J].*Energy Reports*,2022,8: 13129-13137.
- [24] 张培霄,尹晓红,李少远,等.基于 VMD-CNN-LSTM 的农业大棚园区用电负荷短期预测[J/OL].*信息与控制*:2023,1-11 [2024-02-27].<https://doi.org/10.13976/j.cnki.xk.2024.3021>.
Zhang P X, Yin X H, Li S Y, et al. Short-term forecast of electricity load in agricultural greenhouse park based on VMD-CNN-LSTM [J/OL]. *Information and Control* :2023,1-11[2024-02-27].<https://doi.org/10.13976/j.cnki.xk.2024.3021>..(in Chinese)
- [25] Wang K, Fan X, Yang X, et al. An AQI decomposition ensemble model based on SSA-LSTM using improved AMSSA-VMD decomposition reconstruction technique[J]. *Environmental Research*, 2023, 232: 116365-116365.
- [26] Gao X, Guo W, Mei C, et al. Short-term wind power forecasting based on SSA-VMD-LSTM[J]. *Energy Reports*, 2023, 9: 335-344.