

基于IMIFS-VMD和ROA-LSTM的日前电价预测方法

陈逸嘉¹, 陶力^{2,3}, 李凯¹, 刘镇杨¹

(1. 广东电网有限责任公司信息中心, 广东 广州 510000;

2. 北京科东电力控制系统有限责任公司, 北京 100194;

3. 华北电力大学 经济与管理学院, 北京 102206)

摘要:为了深度挖掘电价序列中所蕴含的特征与信息,进一步提升日前电价的预测准确率,提出一种基于改进互信息特征选取(improve mutual information feature selection, IMIFS)、变分模态分解(variational mode decomposition, VMD)和红鸢优化算法(red kite optimization algorithm, ROA)优化长短记忆网络(long short term memory, LSTM)相结合的混合日前电价预测模型。首先,通过IMIFS对原始多元特征集进行降维,提取出包含维度最小且电价信息丰富的特征集,同时,利用VMD对电价序列进行有效分解,减轻电价序列的波动性;其次,引入ROA对LSTM中阈值与权重进行优化,提升算法的全局搜索与局部寻优能力;最后,通过算例验证IMIFS-VMD和ROA-LSTM日前电价预测模型效果,结果表明所提模型 X_{RMSE} 、 X_{MAE} 和 R^2 分别为2.532元/(MW·h)、1.956元/(MW·h)和98.06%,较其他电价预测模型具有较高的预测准确率。

关键词: 日前电价预测;改进互信息特征选取;变分模态分解;长短记忆网络;红鸢优化算法

中图分类号: TP181 文献标识码: A 文章编号: 1003-7241(2025)09-0023-06

Day-ahead Electricity Price Forecasting Method Based on IMIFS-VMD and ROA-LSTM

CHEN Yijia¹, TAO Li^{2,3}, LI Kai¹, LIU Zhenyang¹

(1. Guangdong Power Grid Co., Ltd., Information Center, Guangzhou 510000, China;

2. Beijing Kedong Power Control System Co., Ltd., Beijing 100194, China;

3. School of Economics and Management, North China Electric Power University, Beijing 102206, China)

Abstract: In order to deeply excavate the features and information contained in the electricity price series and further improve the accuracy of the day-ahead electricity price, a hybrid day-ahead electricity price forecasting model based on improved mutual information feature selection (IMIFS), variational mode decomposition (VMD) and red kite optimization algorithm (ROA) is proposed, firstly, the original multivariate feature set is reduced by IMIFS, and the feature set containing the least dimension and abundant information of electricity price is extracted. At the same time, the VMD is used to decompose the electricity price series effectively, secondly, ROA is introduced to optimize the threshold and weight of LSTM to improve the global search and local search ability of the algorithm, the results show that the proposed models X_{RMSE} , X_{MAE} and R^2 are 2.532 yuan/(MW·h), 1.956 yuan/(MW·h) and 98.06% respectively, compared with other electricity price forecasting models, it has higher forecasting precision.

Keywords: day-ahead electricity price forecasting; improve mutual information feature selection; variational mode decomposition; long short term memory; red kite optimization algorithm

0 引言

随着电网清洁低碳转型的步伐加速,电力系统中新能源占比不断攀升,新能源呈现的随机性与电能无法大量直接储存的特性对日前出清价格造成巨大影响^[1]。而日前出清价格直接影响电力市场的整体收益。因此,快速准确预测日前电价对合理配置资源、促进市场主体制定规划及把握市场规律等方面具有重要意义。

随着深度学习的不断发展,其深度特征提取和自学

习的能力得到不断强化,逐渐被应用于电价预测研究。文献[2]构建基于循环神经网络日前电价预测模型,但该模型在对长时间序列进行处理时会出现梯度消失状况;文献[3]提出一种变分模态分解和adam优化LSTM相结合的日前电价预测方法,该方法能够有效捕捉电价波动行为,准确预测日前电价;文献[4]构建一种趋势指标和LSTM结合的日前电价预测模型,并通过算例验证模型的有效性;文献[5]利用最大信息系数相关性对原始数据进行分析,并对门控结构进行改进,构建改进后的多级门控长短记忆电价预测模型,并通过实验验证模型具有较高

的普适性;文献[6]构建一种基于图卷积神经网络和LSTM的日前市场边际电价预测模型,该模型可以将电力市场的地域信息作为特征条件,在一定程度上提升预测模型的性能;文献[7]将小波包分解和LSTM相结合,提出一种短期电价预测方法,该方法能够将电价序列中无效信息和波动性相对较高的高频部分进行有效剔除,使电价预测精度得到提升;文献[8]利用奇异谱分析对LSTM进行优化,提出一种日前电价预测方法,该方法能够将原始序列分解为多个平稳序列,具有良好的预测精度;文献[9]构建集合经验模态分解、SVM和自回归移动平均模型相结合的电价预测模型,该模型可以有效规避递归计算中的误差。

综上所述,现有的研究虽使模型预测性能得到一定提升,但电价时序的内部规律还有待深入挖掘,且分解后的电价序列难以趋于稳定,从而造成预测效果不佳。因此,本文提出一种基于IMIFS-VMD和ROA优化LSTM结合的日前电价预测模型,利用IMIFS对原始多元特征集进行降维,通用VMD对电价序列进行分解,构建每个电价分量的LSTM预测模型,并采用ROA对预测模型进行优化,从而实现日前电价快速精准预测,提升电力市场的竞争力。

1 基于改进互信息特征选取方法

1.1 互信息特征选取方法

1.1.1 互信息理论

两个变量之间的依赖程度可以通过互信息理论来进行度量,可以揭示变量之间相关性大小。连续随机的两个变量与的互信息为:

$$I(X;Y) = \iint p(x,y) \log \frac{p(x,y)}{p(x)p(y)} dx dy \quad (1)$$

式中, $I(X;Y)$ 表示 X 与 Y 的互信息量,具有非负性和互易性($I(X;Y)=I(Y;X)$),当 $I(X;Y)=0$ 时,表明 X 与 Y 完全无关,其值越大,表明 X 与 Y 的相关性越大; $p(x)$ 与 $p(y)$ 表示边缘概率分布; $p(x,y)$ 表示 X 与 Y 的联合概率分布。

1.1.2 互信息特征选取方法

互信息特征选取^[10](mutual information feature selection, MIFS)特征选取步骤:

(1) 设 $X=\{x_1, x_2, \dots, x_M\}$ 为待选输入变量集, y 为输出变量, S 为最优输入变量集,最初该集合为空集。

(2) 计算 $x_m, m=1, 2, \dots, M$ 和 y 变量间的互信息 $I(x_m; y)$,并将最大互信息所对应的变量 x_s 从待选输入变量集 X 中剔除,移至最优输入变量集 S 中。

(3) 更新获得 $I(x_m; S), m=1, 2, \dots, M-1$,根据 $J(x_m)$

最大原则选取下一个重要变量,并将其移至 S 中, $J(x_m)$ 的表达式为

$$J(x_m) = I(x_m, y) - \beta \sum_{s \in S} I(x_m, s) \quad (2)$$

式中, $J(x_m)$ 表示变量评价函数; β 表示惩罚因子, $\beta \in (0.5, 1)$; s 表示已选变量; $I(x_m; y)$ 表示因变量和待选变量间互信息; $I(x_m; s)$ 表示每个已选变量和待选变量间互信息。

(4) 基于贪心算法对其他待选变量进行搜索,重复步骤(3)直至搜索结束。

(5) 输出最优输入变量集 S 。

MIFS在实际应用中往往忽视筛选效果受已选变量数量的影响,从而导致筛选效果不佳。针对上述MIFS不足,引入回归系数来评估变量的重要性,对互特征选取进行改进。

1.2 改进互信息特征选取方法

设数据集 (X, y) 中包含 n 个样本,其中 X 表示样本特征, y 表示样本标签,利用 N 次蒙特卡罗采样选取 X 中的 M 个属性,且选取次数 N 需保证 X 中属性均有机会选中。假设每次采样选取 z 个属性,则获得数据集 (F, y) ,那么 N 次采样后获得数据集 $(F, y)_i$,其中 $i=1, 2, \dots, N$ 。

任意一次采样得到的属性集合 F 中任一属性 x_m 的评价函数为

$$W(x_m) = b_m \left[I(x_m, y) - \frac{\beta}{|S|} \sum_{s \in S} I(x_m, s) \right] \quad (3)$$

式中, b_m 表示 x_m 的回归系数; $|\cdot|$ 表示一范数。

X 中的 M 个属性在 N 次采样过程中可以被多次选中,如选中 k 次属性 x_m ,则会计算得到 q 个 $W(x_m)$,那么属性 x_m 的重要性为

$$L(x_m) = \frac{1}{q} \sum_{i=1}^q W(x_m)_i \quad (4)$$

IMIFS将 $L(x_m)$ 替代原来的变量评价函数 $J(x_m)$,提升属性重要度的计算效率,并利用 $|S|$ 消除已选属性数量对最终筛选结果的影响。

2 变分模态分解

为了解决非递归和自适应信号分解问题,Dragomiretskiy等^[11]于2014年提出变分模态分解方法。该方法主要是将信号分解为多个IMF分量,各IMF分量可以看成处于不同中心频率的调频-调幅信号:

$$u_k(t) = A_k(t) \cos \varphi_k(t) \quad (5)$$

式中, $A_k(t)$ 表示 $u_k(t)$ 的瞬时幅值; $\omega_k = \varphi'_k(t)$ 表示 $u_k(t)$ 的瞬时频率。

约束变分问题描述为

$$\begin{cases} \min_{\{\mu_k(t)\}, \{j\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{i-j\omega_k t} \right\|_2^2 \right\} \\ \text{subject to } \sum_{k=1}^K u_k = x(t) \end{cases} \quad (6)$$

式中, $x(t)$ 表示原始信号, $*$ 表示卷积运算, j 表示一个虚数符号。

引入拉格朗日乘数 λ 与惩罚因子 a 对问题进行转换和最优解求解^[12]。

各分量和中心频率在求解过程中不断更新,直到满足以下迭代停止条件:

$$\sum_k \left(\left\| \hat{u}_k^{n+1} - \hat{u}_k^n \right\|_2^2 / \left\| \hat{u}_k^n \right\|_2^2 \right) < \xi \quad (7)$$

式中, \hat{u}_k 表示第 k 个 IMF 傅里叶变换后得到的信号值; ξ 表示判别精度, 取 10^{-6} 。

迭代停止后, 信号经过变换, 最终输出分解的 IMF 分量。

3 基于 ROA-LSTM 的预测模型

3.1 长短记忆网络

LSTM 是以传统循环神经网络为基础的一种改进主体, 利用特有的门控制信息传递, 其原理结构如图 1 所示。其运行流程为

$$\begin{cases} f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \\ G_t = \tanh(W_g \times [h_{t-1}, x_t] + b_g) \\ C_t = f_t \times C_{t-1} + i_t \times G_t \\ O_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o) \\ h_t = O_t * \tanh C_t \end{cases} \quad (8)$$

式中, x_t 表示输入信息; h_{t-1} 表示上一状态输入信息; σ 表示 sigmoid 激活函数; W 表示权重矩阵; b 表示偏差参数; \tanh 表示双曲正切激活函数; f 表示遗忘门; i 表示输入门; C 表示单元状态; O 表示输出门。




图 1 LSTM 原理结构

传统 LSTM 的阈值与权重均采用梯度下降法更新, 易出现早熟或局部最优问题, 本文引入 ROA 算法对 LSTM 的阈值与权重进行优化。

3.2 红鸢优化算法

Raeisi-Gahruei 等^[13]于 2022 年提出一种新元启发式算法—红鸢优化算法, 其具有结构和实现简单、参数少、收敛速度快等优点。

阶段 1: 初始位置生成。

$$\begin{cases} \text{Pos}_{i,j}(t) = V_{ar_{\max}} + \text{rand}(V_{ar_{\max}} - V_{ar_{\min}}) \\ i = 1, 2, \dots, N; j = 1, 2, \dots, d; t = 1, 2, \dots, t_{\max} \end{cases} \quad (9)$$

式中, $\text{Pos}_{i,j}(t)$ 表示 t 次迭代第 i 只红鸢在维度 j 中的位置; $V_{ar_{\max}}, V_{ar_{\min}}$ 表示搜索空间上下限; rand 表示 $[0, 1]$ 内随机数; N 表示红鸢总数; d 表示问题的维度; t_{\max} 表示最大迭代次数。

阶段 2: 选取领导者。

当 $F_{\text{Pos}_i}(t)$ 优于 $F_{\text{Best}}(t)$ 时,

$$\text{Best}(t) = \text{Pos}_i(t) \quad (10)$$

式中, $F_{\text{Pos}_i}(t)$ 表示 t 次迭中第 i 只红鸢位置的代价函数值; $F_{\text{Best}}(t)$ 表示 t 次迭代中最优位置的代价函数值; $\text{Best}(t)$ 表示 t 次迭代的最佳位置。

阶段 3: 全局探索向局部开发转移

$$\text{Newpos}_i(t+1) = \text{Pos}_i(t) + Pm_i(t+1) \quad (11)$$

$$\begin{aligned} Pm_i(t+1) = & D(t) + SC(t) \odot (\text{Pos}_{\text{ByRWS}}(t) - \text{Pos}_i(t)) \\ & + UC(t) \odot (\text{Best}(t) - \text{Pos}_i(t)) \end{aligned} \quad (12)$$

式中, $\text{Pos}_{\text{ByRWS}}(t)$ 表示 t 次迭代中轮盘筛选的红鸢位置; $\text{Newpos}_i(t+1)$ 表示红鸢更新后的位置; $Pm_i(t+1)$ 表示 $t+1$ 次迭代中第 i 只红鸢移动的点数; $D(t)$ 表示红鸢第 t 次迭运动系数; $SC(t)$ 、 $UC(t)$ 表示 t 次迭代中每只红鸢统一的声音与危险的声音, 其表达式为

$$\begin{cases} \text{rand} \leq 0.5 \text{ 时}, \begin{cases} SC(t+1) = r_1 \\ UC(t+1) = r_2 \end{cases} \\ 0.5 < \text{rand} \leq 1 \text{ 时}, \begin{cases} SC(t+1) = r_3 \\ UC(t+1) = r_1 \end{cases} \end{cases} \quad (13)$$

运动系数:

$$D = \left(\exp \left(\frac{t}{t_{\max}} - \frac{t}{t_{\max}} \right) \right)^{-10} \quad (14)$$

如果 $\text{Newpos}_i(t+1)$ 超出问题范围, 则通过式 (15) 再次回到问题的范围内:

$$\begin{aligned} \text{Newpos}_i(t+1) = & \max \left(\min \left(\text{Newpos}_i(t+1), V_{ar_{\max}} \right), V_{ar_{\min}} \right) \end{aligned} \quad (15)$$

由上述可知, LSTM 的阈值与权重的自适应确定是 LSTM 在日前电价预测领域应用的关键, 因此, 在 LSTM 基准预测模型的基础上引入自适应 ROA 算法, 能够有效

规避早熟或局部最优问题,实现日前电价的快速精准预测。ROA算法优化LSTM的具体流程如图2所示。

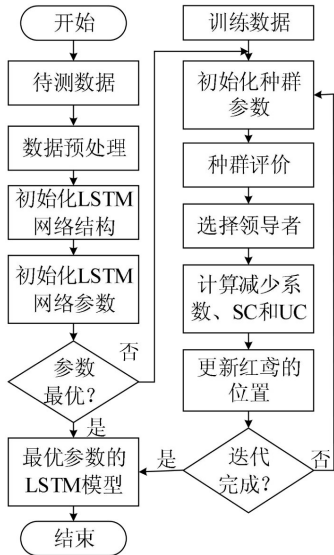


图2 ROA优化LSTM流程

4 日前电价预测整体流程

4.1 数据预处理

为了规避预测模型受数据量纲差异的影响,需对原始数据进行归一化处理,具体表达式为

$$g' = \frac{g - g_{\min}}{g_{\max} - g_{\min}} \quad (16)$$

式中, g' 表示归一化值; g_{\min} 表示数据最小值; g_{\max} 表示数据最大值; g 表示实际值。

4.2 评估指标

为了对预测模型的精度进行量化评估,选用 R^2 、均方根误差(root mean square error, RMSE)及平均绝对误差(mean absolute error, MAE)作为误差评估指标,具体表达式为

$$X_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\tilde{r}_i - r_i)^2} \quad (17)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (r_i - \tilde{r}_i)}{\sum_{i=1}^n (r_i - \bar{r}_i)} \quad (18)$$

$$X_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |\tilde{r}_i - r_i| \quad (19)$$

式中, r_i 表示原始电价; \tilde{r}_i 表示预测电价; n 表示预测点数量; \bar{r}_i 表示 r_i 的平均值。

4.3 电价预测流程

基于IMIFS-VMD和ROA-LSTM的日前电价预测方法流程如图3所示。由图3可知日前电价预测的步骤:

步骤1,基于IMIFS特征选取方法对原始特征集进行

降维,获得高相关特征集。

步骤2,利用VMD对各电价分量进行分解,得到多个电价分量。

步骤3,将高相关特征集与多个电价分量合并作为输入序列,并建立各电价序列分量的ROA-LSTM预测模型。

步骤4,对ROA-LSTM模型输出的各电价分量预测值进行叠加重构,获得预测电价。

步骤5,选用常用评估指标对预测电价的误差进行评价。

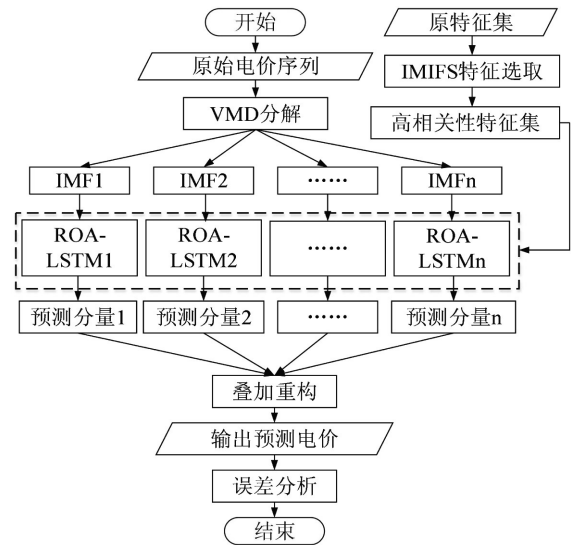


图3 日前电价预测整体流程图

5 算例分析

5.1 数据采集及算法参数设置

5.1.1 数据采集

以某省级电网公司连续100 d共计2 400组小时级日前电价数据作为实验数据,其中前80 d的1 920组数据为训练集数据,其余20 d的480组数据为测试集数据,具体如图4所示。




图4 实验数据集

5.1.2 算法参数设置

算例仿真实验中ROA算法种群大小选取40、设置最大迭代次数为200、维数为50、阶数为30。LSTM算法采用双层堆积层、最大迭代次数为200、隐含层大小为256、批训练的大小为16、学习率设置为0.001、网络层的遗忘

率为0.2、随机种子数为42个。

5.2 特征选取结果分析

利用MIFS与IMIFS对原始特征集进行降维,结果如表1所示。

表1 不同特征选取方法结果对比

序列	MIFS	IMIFS
1	计划流量	生产
2	生产	计划流量
3	市场容量	负荷
4	负荷	市场容量
5	风电	风电
6	储能	光伏
7	光伏	
8	生物质	

由表1可知,MIFS与IMIFS虽然提取过程中特征重要程度的排序有所不同,但提取结果十分相似。MIFS将原始特征集维度降低至8维,而IMIFS降至6维,可以看出IMIFS能够有效剔除冗余与相关性较小的特征,使模型得到进一步简化,在一定程度上缩短运行时间。

为进一步验证IMIFS方法的有效性,分别采用主成分分析(principal component analysis, PCA)、MIFS及IMIFS进行特征提取,构成PCA-LSTM、MIFS-LSTM及IMIFS-LSTM预测模型进行日前电价预测,预测结果如表2所示。

表2 不同特征提取算法结果对比

特征提取算法	$X_{RMSE}/(\text{元} \cdot (\text{MW} \cdot \text{h})^{-1})$	$X_{MAE}/(\text{元} \cdot (\text{MW} \cdot \text{h})^{-1})$	$R^2/\%$
LSTM	4.572	3.336	83.58
PCA-LSTM	4.238	3.157	86.37
MIFS-LSTM	4.026	3.021	88.63
IMIFS-LSTM	3.896	2.994	89.71

由表2可以看出:

(1) PCA-LSTM、MIFS-LSTM及IMIFS-LSTM模型较LSTM模型, X_{RMSE} 分别降低了7.31%、11.94%及14.79%; X_{MAE} 分别降低了5.37%、9.44%及10.25%; R^2 分别提升2.79%、5.05%及6.13%,由此可知,利用特征选取算法,能够有效筛选出与电价重要程度较高的相关特征,进一步降低模型的难度,提升模型的预测效果。

(2) IMIFS-LSTM较其他模型的预测误差最小,原因在于PCA是一种提取线性特征的分析方法,仅能度量变量间的线性相关;MIFS虽然能够对变量间的非线性进行度量,但忽视了筛选效果受已选变量数量的影响,故在MIFS基础上提出的IMIFS较MIFS的互信息评估准确性高。

5.3 VMD分解结果分析

为了对VMD方法有效性进行验证,在IMIFS特征选取的基础上,分别构建LSTM、EEMD-LSTM及VMD-LSTM

模型对电价进行预测,结果如表3所示。

由表3可以看出:

(1) EEMD-LSTM与VMD-LSTM模型较LSTM模型, X_{RMSE} 分别降低了23.95%和32.88%; X_{MAE} 分别降低了23.61%和32.46%; R^2 分别提升3.16%和4.85%。可以看出电价序列通过模式分析,可以变得更为平稳,在一定程度上降低电价预测的难度。

表3 不同分解方法的结果对比

预测模型	$X_{RMSE}/(\text{元} \cdot (\text{MW} \cdot \text{h})^{-1})$	$X_{MAE}/(\text{元} \cdot (\text{MW} \cdot \text{h})^{-1})$	$R^2/\%$
LSTM	3.896	2.994	89.71
EEMD-LSTM	2.963	2.287	92.87
VMD-LSTM	2.615	2.022	94.56

(2) VMD-LSTM较其他模型的预测误差最小,原因在于EEMD与VMD的原理不同,其中EEMD采用非递归的方式,在分解的过程中易产生噪音误差;VMD采用递归方式,能够有效规避噪音误差,具有高效的信号分解能力。

经过大量实验可知,EEMD和VMD分解层分别为5和4时,预测效果最佳。基于VMD分解得到的电价分量如图5所示。




图5 VMD分解结果

5.4 ROA-LSTM模型预测结果分析

在上述特征筛选与VMD分解的基础上,为进一步验证ROA-LSTM模型的有效性,针对分解得到的电量,分别构建BP神经网络(back propagation neuron network, BPNN)、循环神经网络(recurrent neural network, RNN)、LSTM、PSO-LSTM及ROA-LSTM进行电价预测,具体电价预测结果如表4所示。

表4 不同预测模型的结果对比

预测模型	$X_{RMSE}/(\text{元} \cdot (\text{MW} \cdot \text{h})^{-1})$	$X_{MAE}/(\text{元} \cdot (\text{MW} \cdot \text{h})^{-1})$	$R^2/\%$
RNN	3.028	2.241	86.75
BPNN	2.796	2.154	91.31
LSTM	2.615	2.022	94.56
PSO-LSTM	2.587	1.997	96.72
ROA-LSTM	2.532	1.956	98.06

由表4可以看出:

(1) LSTM较RNN与BPNN预测模型, X_{RMSE} 分别降低了13.64%和6.47%; X_{MAE} 分别降低了9.77%和5.99%; R^2 分别提升7.81%和3.25%,可以看出LSTM针对时间序列的学习能力优于RNN与BPNN,能够深入挖掘电价序列当中的时间规律,同样也验证在电价预测问题中LSTM的有效性。

(2) PSO-LSTM与ROA-LSTM预测模型较LSTM预测模型, X_{RMSE} 分别降低了1.07%和3.17%; X_{MAE} 分别降低了1.24%和3.26%; R^2 分别提升2.16%和3.5%,可以看出利用优化算法优化LSTM模型的阈值与权重,可使模型的预测精度得到一定程度的提升。

(3) ROA-LSTM较PSO-LSTM预测模型, X_{RMSE} 降低了2.13%; X_{MAE} 降低了2.05%; R^2 提升1.34%,原因在于PSO算法存在易陷入局部最优值和易早熟的问题,而ROA算法则具有优秀的全局搜索与局部寻优能力,且收敛速度快,能够有效地处理电价预测问题。

(4) ROA-LSTM模型 X_{RMSE} 和 X_{MAE} 指标均为最小, R^2 指标最大,较RNN、BPNN、LSTM及PSO-LSTM模型 X_{RMSE} 降低了16.38%、9.44%、3.17%和2.13%; X_{MAE} 降低了12.72%、9.19%、2.26%和2.05%; R^2 分别提升11.31%、6.75%、3.5%和1.34%,可以看出ROA-LSTM模型在处理电价预测问题上具有一定的优势。

6 结束语

针对电价序列特征,提出一种基于IMIFS-VMD和ROA-LSTM的日前电价预测方法,首先,引入回归系数对MIFS进行改进,筛选出维度最小且电价信息丰富的特征集,并采用VMD对原始电价序列进行分解,获得更为平稳的电价序列分量;其次,利用ROA对LSTM中阈值与权重进行优化,构建ROA-LSTM日前电价预测模型,获得电力市场日前电价预测值。通过实验分析可知,较其他日前电价预测方法, R^2 、均方根误差及平均绝对误差均为最优,提升了日前电价的预测精度。随着电力市场耦合程度的不断深化,电价在一定程度上会受到跨区域电力交易的影响,探究耦合电力市场对电价影响的多特征属性,是进一步提升日前电价预测模型预测精度和泛化能力的关键。

参考文献:

- [1] 时维帅, 孙欣, 谢敬东, 等. “双碳”目标下风氢联合系统参与现货市场的优化运行与效益分析[J]. 电力建设, 2022, 43(7): 1-12.
- [2] UGURLU U, OKSUZ I, TAS O. Electricity price forecasting using recurrent neural networks[J]. Energies, 2018, 11(5): 1255.
- [3] 马丽莹, 魏云冰. 一种变分模态分解与Adam优化的LSTM

电价预测方法[J]. 智能计算机与应用, 2022, 12(12): 142-146.

[4] 郭贺宏, 武灵耀, 赵庆生, 等. 基于趋势指标与长短时记忆网络的电力市场日前电价预测[J]. 智慧电力, 2022, 50(9): 97-103.

[5] 赵雅雪, 王旭, 蒋传文, 等. 基于最大信息系数相关性分析和改进多层级门控LSTM的短期电价预测方法[J]. 中国电机工程学报, 2021, 41(5): 135-146.

[6] 韩升科, 胡飞虎, 陈之腾, 等. 基于GCN-LSTM的日前市场边际电价预测[J]. 中国电机工程学报, 2022, 42(9): 3276-3286.

[7] 刘达, 雷自强, 孙堃. 基于小波包分解和长短期记忆网络的短期电价预测[J]. 智慧电力, 2020, 48(4): 77-83.

[8] 殷豪, 丁伟锋, 陈顺, 等. 基于长短时记忆网络-纵横交叉算法的含高比例新能源电力市场日前电价预测[J]. 电网技术, 2022, 46(2): 472-480.

[9] 张金良, 王明雪. 基于EEMD, SVM和ARMA组合模型的电价预测[J]. 电力需求侧管理, 2020, 22(3): 63-68.

[10] 黄伟, 李阳. 基于MCS-MIFS与LightGBM的燃气轮机功率预测方法[J]. 电力科学与工程, 2020, 36(5): 23-31.

[11] 郑义, 岳建海, 焦静. 基于参数优化变分模态分解的滚动轴承故障特征提取方法[J]. 振动与冲击, 2021, 40(1): 86-94.

[12] 夏鹏. 基于经验模态分解的水力发电机组故障自动化诊断技术[J]. 自动化技术与应用, 2023, 42(4): 37-40.

[13] RAEISI-GAHRUEI J, BEHESHTI Z. The electricity consumption prediction using hybrid red kite optimization algorithm with multi-layer perceptron neural network[J]. Journal of Intelligent Procedures in Electrical Technology, 2022, 60(15): 1-22.

作者简介: 陈逸嘉(1995—), 女, 本科, 助理工程师, 研究方向: 信息系统项目管理、数字化管理。