

基于 WPD-SCA-ELM 模型的天然气负荷短期预测

成琳琳*

中国石油天然气股份有限公司西南油气田分公司集输工程技术研究所, 成都 610000

* 通信作者, cnpc_cll@163.com

收稿日期: 2022-12-19

摘要 随着天然气消耗量的不断增加, 准确预测未来天然气的日负荷用量对于天然气资源的合理配置具有重要意义。针对此问题, 在“分解—预测—重构”的思想建立了基于 WPD-SCA-ELM 模型的天然气负荷预测模型, 对影响小波包分解的小波基函数和分解层数进行优选, 选取了对日负荷影响较大的因素, 并针对气温因素的滞后性进行了平移修正, 最后与其余模型算法进行了对比验证。结果表明, 供暖期的日负荷数据是非正态分布, 具有较大的波动性; Fk4 阶 2 层分解更能反映日负荷的变化趋势和特征; 日最高气温和日最低气温的相关系数均大于平均气温, 通过对气温进行平移滑动操作, 可提高气温与日负荷的相关性; WPD-SCA-ELM 模型的 MAPE、RMSE、DS 分别为 0.59、7321.87、0.9205, 与其他模型相比评价指标最优, 证明了该模型的科学性。

关键词 小波分解; 正余弦; 极限学习机; 天然气; 负荷预测

中图分类号: TE64; TP18

Short-term prediction of natural gas load based on WPD-SCA-ELM model

CHENG Linlin

PetroChina Southwest Oil & Gasfield Company Gathering & Transportation Engineering Technology Institute, Chengdu 610000, China

Abstract With increasing natural gas consumption, it is of great significance to accurately predict the daily consumption load of natural gas in the future for the rational allocation of natural gas resources. To solve this problem, a natural gas load prediction model based on the WPD-SCA-ELM model was established based on the idea of “decomposing-prediction-reconstruction”. The wavelet basis function and decomposition layers affecting the wavelet packet decomposition were optimized, and the factors affecting the daily load were selected, and the temperature factor hysteresis was corrected by a translation operation. Finally, the algorithm is compared with other models. The results show that the daily load data in the heating period is not normally distributed and has great fluctuation. The Fk4-order two-layer decomposition can better reflect the variation trends and daily load characteristics. The correlation coefficients of daily maximum temperature and daily minimum temperature are larger than average temperature, and the correlation between temperature and daily load can be improved by translating and sliding the temperature. The MAPE, RMSE and DS of WPD-SCA-ELM model are 0.59, 7321 and 0.920, respectively. Compared with other models, the evaluation index is the best, which proves that the model is useful.

Keywords wavelet decomposition; sines and cosines; extreme learning machine; natural gas; load forecasting

doi: 10.3969/j.issn.2096-1693.2024.02.025

引用格式: 成琳琳. 基于 WPD-SCA-ELM 模型的天然气负荷短期预测. 石油科学通报, 2024, 02: 346-353

CHENG Linlin. Short-term prediction of natural gas load based on WPD-SCA-ELM model. Petroleum Science Bulletin, 2024, 02: 346-353. doi: 10.3969/j.issn.2096-1693.2024.02.025

0 引言

随着我国经济的日益增长，人口数量的不断增多，天然气作为一种清洁能源被广泛使用，其年消耗量不断增加。我国的天然气消耗总量预计在 2025 年底达到世界总量的 40%，且天然气进口量也在不断增加，因此对其使用负荷进行准确预测显得尤为重要^[1-2]。根据天然气负荷的走向趋势，可提前做好相应设备设施的建设规划，对于优化管存量和储气库存储量，降低燃气公司的采购和存储成本等方面具有重要意义。

目前，对于天然气负荷的预测从时间上可分为中长期和短期预测，中长期预测受政策、用户、气源和市场价格的影响波动较大，其结果不具备直接指导意义；短期预测通常为 1~120 天的预测，预测天数越长，对预测精度的要求越高^[3-5]。由于天然气供需不平衡阶段主要发生在北方冬季供暖期，故针对供暖期进行短期负荷预测。负荷预测属于时间序列预测，迄今为止已有诸多学者进行了研究，刘春霞等^[6]将遗传算法优化小波神经网络用于预测短期天然气负荷，但未考虑节假日和下载气量用户数对负荷趋势的影响；付川等^[7]采用残差修正的方式对冬季天然气日负荷的累计误差进行了调整，相对误差降低至 2.98%，但只考虑了温度的影响，未考虑其余因素；孙相博等^[8]对灰色 GM(1,1) 模型进行了改进，用于预测天然气负荷，虽然该模型结合了新陈代谢思想，用最邻近数据预测最新数据，但本身灰色模型在处理大量历史数据前需要对其进行奇异点筛选，因此适用性有待验证；邱静等^[9]采用最小二乘支持向量机对短期燃气负荷进行了预测，但支持向量机只适用于小样本数据。综上所述，以上研究的天然气负荷预测未形成完整体系，无论是神经网络、灰色模型还是支持向量机均存在收敛速度慢、算法效率低下的问题。当前，基于“分解—预测—重构”思想的多种组合预测方法在径流时间预测^[10]、电力负荷预测^[11]等领域广泛应用，为提高天然气短期负荷的预测精度，同时平衡模型的计算效率和计算规模，采用小波包分解(WPD)—正余弦优化(SCA)—极限学习机(ELM)回归的组合优化算法，将其用于天然气负荷的短期预测，考察最优小波基函数和分解层数，并采用统计学定量评价方法比较其计算精度。研究结果可为燃气公司的生产调度优化提供实际参考。

1 理论方法

1.1 小波包分解(WPD)

WPD 算法解决了小波分解在高频处频率分辨率

差、低频处时间分辨率差的问题，适合天然气负荷这类非平稳时间序列信号^[12-13]。分解公式如下：

$$\begin{cases} d_l^{j,2n} = \sum_k h_{k-2l} d_k^{j-1,n} \\ d_l^{j,2n+1} = \sum_k g_{k-2l} d_k^{j-1,n} \end{cases} \quad (1)$$

式中： $d_l^{j,2n}$ 、 $d_l^{j,2n+1}$ 为小波包的低频系数和高频系数； l 、 k 为平移尺度参数； n 为频率参数， $n = \{2^l - 1, 2^l - 2, \dots, 0\}$ ； h_{k-2l} 、 g_{k-2l} 分别为低通和高通滤波器。

1.2 ELM

ELM 是一种广义前馈型神经网络，由训练误差项和输出层权重范数的正则项组成损失函数，通过随机选取输入层权重和隐含层偏差使其保持通用逼近能力。从训练和学习效率上看，ELM 相较于 BP、SVM、GRNN 等算法具有训练参数少、学习效率高、泛化能力强等特点。公式如下：

$$y_i = \sum_{j=1}^l g(\omega_j \cdot x_i + b_j) \beta_j, i = 1, \dots, N \quad (2)$$

式中： y_i 为输出参数； x_i 为输入参数； ω_j 为输入层权重； b_j 为隐含层偏差； β_j 为输出层权重； $g(x)$ 为激励函数； l 为隐含层数目； N 为样本数量。训练目标是得到最优 β_j 使 y_i 的误差最小。

1.3 SCA

在 ELM 算法中需更新权重和偏差，常规采用穷举法更新，但速率太慢，容易陷入局部最优解，故采用 SCA 算法对权重和偏差进行优化。SCA 算法是通过变换正弦或者余弦函数的绝对值大小，逼近全局最优解^[14-15]。种群中个体位置的更新公式如下：

$$X_i^{t+1} = \begin{cases} X_i^t + r_1 + \sin r_2 + |r_3 P_i^t - X_i^t|, r_4 < 0.5 \\ X_i^t + r_1 + \cos r_2 + |r_3 P_i^t - X_i^t|, r_4 \geq 0.5 \end{cases} \quad (3)$$

$$r_1 = a - t \frac{a}{T} \quad (4)$$

式中： X_i^t 为当前个体第 i 维在 t 次迭代时的位置； r_2 为 0 到 2π 的随机数； r_3 为 0 到 2 的随机数； r_4 为 0 到 1 的随机数； P_i^t 为最优个体第 i 维在 t 次迭代时的位置； r_1 为下一个目标解的位置区域； a 为常数； t 为当前迭代次数； T 为最大迭代次数。

2 基于 WPD-SCA-ELM 的建模流程

基于 WPD-SCA-ELM 的天然气负荷短期预测流程为：

(1)收集研究对象历史数据,利用Matalab小波分解工具箱进行数据分解,对小波基函数和分解层数进行优选。

(2)将小波包分解后的函数进行最大最小值归一化处理。

(3)将2018—2019年、2019—2020年冬季供暖期的数据作为训练集,2020—2021年冬季供暖期的数据作为测试集。

(4)利用SCA-ELM模型对训练集进行训练,将均方误差(MSE)作为SCA优化ELM的适应度函数,设定优化期望目标值 <0.001 。

(5)对测试集的数据进行预测,并进行反归一化处理。

(6)将预测结果按照小波包的层级和阶数反向重构,将预测结果与实际值进行对比,并验证算法的准确性。

3 实例分析

3.1 数据来源

采用北方某燃气公司在某地区的天然气日负荷数

据(以民用燃气数据为主),数据范围为2018—2021年冬季供暖期(当年11月15日至次年3月15日),见图1,数据的统计描述见表1。在供暖初期,每年的日负荷先急速增加,这与居民用户逐渐供暖有关,反映了初期由于气源调节能力不够带来的“气荒”;在供暖中期,日负荷在一定范围内波动,时常出现用气局部高峰点,这可能与部分日期(如法定节假日、休息日)的天然气市场需求增大有关;在供暖后期,由于气温回升,日负荷迅速下降,形成平台区,此时天然气的的需求达到最小。从年份上看,2020—2021年供暖期的日负荷量大于其余两年,且数据波动也较大,这与国家大面积推广“煤改气”工程,用户数量增多有关。此外,根据表1,三年供暖数据的偏度不为0、峰度不为3,说明数据为非正态分布,具有较大的波动性。

3.2 小波包参数优选

常用的小波基函数有Sym、Db和Fk等3种,以2018—2019年的数据为例,对比不同阶数、不同分解层数的重构信号与原始信号误差,误差评价指标采用平均绝对百分比误差(MAPE)表示,见表2。Fk4阶2层分解的MAPE最小,Fk函数与其余两种函数相比更




图1 2018—2021年供暖期天然气负荷数据

Fig. 1 Natural gas load data during the 2018—2021 heating period

表1 数据统计描述

Table 1 Description of data statistics

| 年份 | 均值/($\times 10^4 \text{ Nm}^3$) | 标准差 | 偏度 | 峰度 | 最小值/($\times 10^4 \text{ Nm}^3$) | 最大值/($\times 10^4 \text{ Nm}^3$) |
|-----------|-----------------------------------|----------|----------|-----------|------------------------------------|------------------------------------|
| 2018—2019 | 9.066 98 | 0.573 63 | 0.185 41 | -1.765 79 | 8.17 | 10.12 |
| 2019—2020 | 9.822 22 | 0.514 72 | 0.743 98 | 2.089 01 | 9.00 | 11.99 |
| 2020—2021 | 11.284 46 | 0.932 38 | 0.152 33 | -1.621 53 | 10.00 | 12.99 |

能反应日负荷的趋势和特征。

Fk4 阶 2 层分解见图 2，第 2 层第 1 个高频分量反映天然气负荷的周期性，即温度越低、负荷越大；第 2 层第 2 个低频分量反映天然气负荷的稳定部分；第 2 层第 3 个高频分量和第 4 个低频分量具有明显波动细节，波动范围越大，说明天然气的消耗量越大，且第 4 个低频分量出现波峰和波谷的时刻与原数据基本对应，其细节刻画更加明显。

3.3 影响因素分析

经研究表明，天然气负荷受气温、GDP、人口数

量、空气质量、国家政策、宏观经济等方面的影响，其中气温的影响程度最大。选择供暖期对应日期的日最高气温、日最低气温、日平均气温、降雨量、平均风速、相对湿度等数据，同时考虑节假日(工作日、休息日和法定节假日分别编码为 0、1、2)和每日下载气用户数量的影响，采用 Spearman 秩相关系数法计算影响因素与日负荷之间的相关性^[16]，见表 3。

从表 3 中可知，除节假日和用户数量与天然气日负荷的相关系数为正相关，其余因素皆为负相关，日最高气温和日最低气温的相关系数大于平均气温，降雨量、平均风速和相对湿度的相关系数小于 0.5，用户

表 2 不同小波包的重构误差

Table 2 Reconstruction errors of different wavelet packets

| 小波基函数 | 阶数 | 分解层数 | MPAE/% | 小波基函数 | 阶数 | 分解层数 | MPAE/% | 小波基函数 | 阶数 | 分解层数 | MPAE/% |
|-------|----|------|--------|-------|----|------|--------|-------|----|------|--------|
| Sym | 2 | 2 | 1.39 | Db | 2 | 2 | 0.82 | Fk | 4 | 2 | 0.63 |
| | 2 | 3 | 2.22 | | 2 | 3 | 0.90 | | 4 | 3 | 1.99 |
| | 3 | 2 | 0.65 | | 3 | 2 | 1.93 | | 6 | 2 | 3.17 |
| | 3 | 3 | 1.43 | | 3 | 3 | 0.88 | | 6 | 3 | 3.17 |
| | 4 | 2 | 2.06 | | 4 | 2 | 0.93 | | 8 | 2 | 3.18 |
| | 4 | 3 | 0.69 | | 4 | 3 | 2.22 | | 8 | 3 | 2.74 |
| | 5 | 2 | 0.84 | | 5 | 2 | 2.70 | | 14 | 2 | 3.29 |
| | 5 | 3 | 0.82 | | 5 | 3 | 1.71 | | 14 | 3 | 3.28 |
| | 6 | 2 | 2.36 | | 6 | 2 | 1.22 | | 18 | 2 | 3.71 |
| | 6 | 3 | 1.05 | | 6 | 3 | 1.79 | | 18 | 3 | 3.75 |
| | 7 | 2 | 1.06 | | 7 | 2 | 1.20 | | 22 | 2 | 4.12 |
| | 7 | 3 | 2.35 | | 7 | 3 | 1.10 | | 22 | 3 | 3.98 |




图 2 Fk4 阶 2 层分解图 (2018—2019 年天然气负荷)

Fig. 2 Fk4 Level 2 decomposition diagram (2018—2019 gas load)

数量的相关系数随年份的增长而增加,这可能与用户数量逐年上升有关。

此外,通过对比气温和日负荷的关系发现,当气温发生突变时,日负荷并没有立即发生突变,而是有1~3日的时间滞后,这可能与人体对体感温度的适应程度滞后有关。因此,对气温数据进行1~3日的滑动平移,并再次计算与日负荷的相关系数,见表4。气温经平移修正后,相关系数明显增大,且平移2天的效果最好。

3.4 组合模型预测结果

根据上述研究,将日最高气温、日最低气温、日

平均气温、节假日和用户数量作为ELM的输入(气温均为向后平移两天后的数据),将日负荷经Fk4阶2层分解的4个分量分别作为输出,采用SCA算法对ELM模型的权重和偏差进行更新,获得最优SCA-ELM模型。ELM模型网络结构为5-10-1型(隐含层节点数通过试错法确定),激励函数选择Sigmoid,搜索空间设置为[0,1],SCA算法中最大迭代次数设置为200,初始个体数目为50,SCA算法幅值在[-2,2]之间波动。分别采用2018—2019年和2019—2020年的数据,对2020—2021年供暖期的日负荷数据进行预测,并进行反归一化处理,见图3、图4。为了验证本文组合模型的算法精度,与ELM、粒子群算法(PSO)优

表3 天然气负荷与各因素间的相关系数

Table 3 Correlation coefficients between natural gas load and various factors

| 年份 | 相关系数 | | | | | | | |
|-----------|--------|--------|--------|--------|--------|--------|-------|-------|
| | 日最高气温 | 日最低气温 | 平均气温 | 降雨量 | 平均风速 | 相对湿度 | 节假日 | 用户数量 |
| 2018—2019 | -0.643 | -0.601 | -0.543 | -0.143 | -0.023 | -0.018 | 0.507 | 0.607 |
| 2019—2020 | -0.689 | -0.587 | -0.521 | -0.129 | -0.044 | -0.024 | 0.582 | 0.645 |
| 2020—2021 | -0.622 | -0.635 | -0.555 | -0.159 | -0.022 | -0.013 | 0.595 | 0.681 |

表4 气温修正后的相关系数

Table 4 Correlation coefficient after temperature modification

| 年份 | 日最高气温 | | | 日最低气温 | | | 平均气温 | | |
|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| | 相关系数 | | | | | | | | |
| | 平移 1d | 平移 2d | 平移 3d | 平移 1d | 平移 2d | 平移 3d | 平移 1d | 平移 2d | 平移 3d |
| 2018—2019 | -0.848 | -0.875 | -0.720 | -0.756 | -0.836 | -0.766 | -0.678 | -0.756 | -0.604 |
| 2019—2020 | -0.760 | -0.873 | -0.762 | -0.758 | -0.845 | -0.839 | -0.683 | -0.760 | -0.611 |
| 2020—2021 | -0.855 | -0.863 | -0.755 | -0.760 | -0.803 | -0.768 | -0.660 | -0.796 | -0.685 |

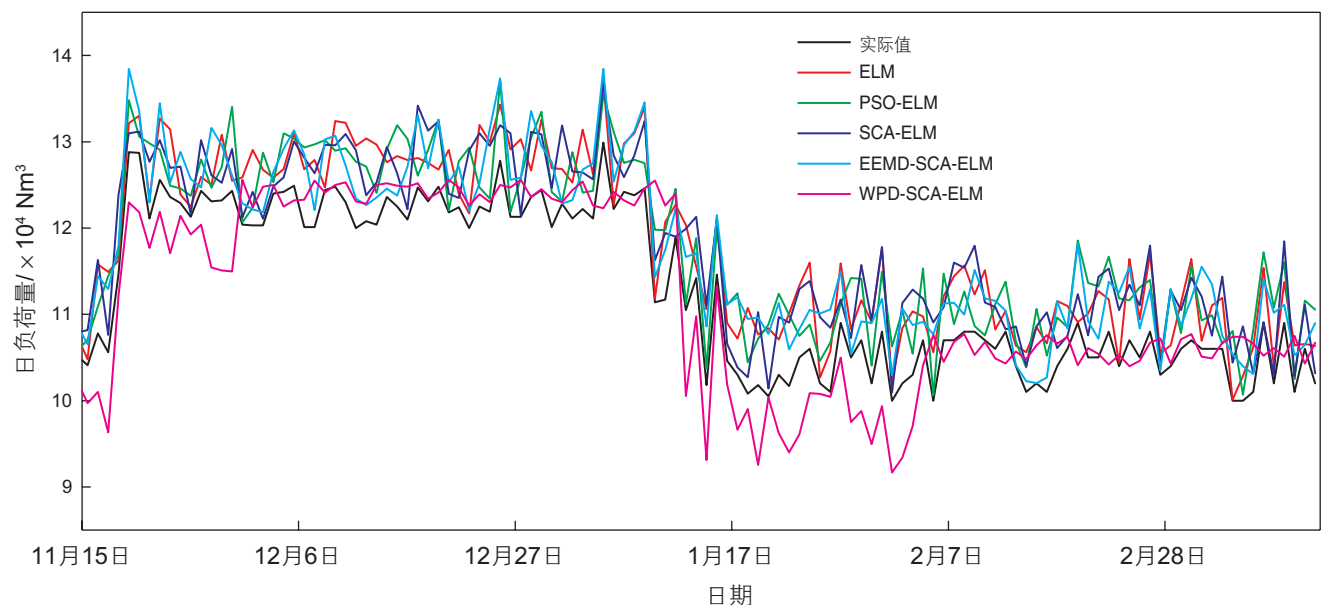


图3 2020—2021年日负荷数据预测结果(采用2018—2019年作为测试集)

Fig. 3 Forecast results of daily load data in 2020—2021 (using 2018—2019 as the test set)

化ELM、SCA-ELM、经验模态分解(EEMD)-SCA-ELM等模型进行对比,其中ELM的设置与前述一致;PSO算法中粒子群个数为20,学习因子均为0.5,权重因子为0.6;EEMD算法经自适应分解为5个IMF分量和1个残差分量,通过与原始数据进行相关性分析,确定IMF3~5为有效分量。

为了对组合模型进行比较详细的评价,从预测误差和方向性两个方面统计平均绝对百分比误差(MAPE)、均方根误差(RMSE)和方向准确率(DS),其中DS值反映了对样本数据对未来趋势预测的延续性。公式如下:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i^* - y_i}{y_i} \right| \times 100\% \quad (4)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i^* - y_i)^2} \quad (5)$$

$$DS = \frac{1}{N} \sum_{i=1}^N d(i) \quad (6)$$

$$d(i) = \begin{cases} 1, & \text{if } (y_{i+1} - y_i)(y_{i+1}^* - y_i^*) \geq 0 \\ 0, & \text{otherwise} \end{cases} \quad (7)$$

式中: y_i 为实际值; y_i^* 为预测值; N 为数据个数。

统计学的平均预测误差见表5。用2019—2020年的数据预测2020—2021年的数据,其效果要远好于2018—2019年的数据预测2020—2021年的数据,说明在没有外界因素影响的前提下,使用越靠近预测时间的数据,其预测结果越准确。优化后的模型(PSO-ELM

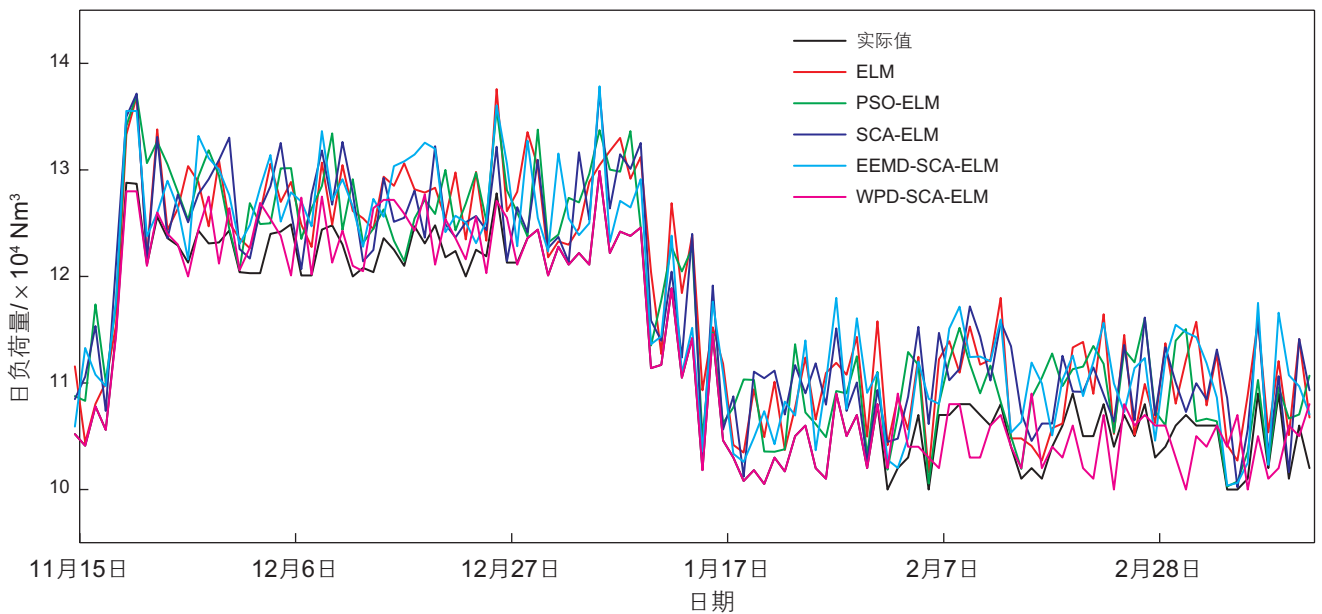


图4 2020—2021年日负荷数据预测结果(采用2019—2020年作为测试集)

Fig. 4 Forecast results of daily load data in 2020—2021 (using 2019—2020 as the test set)

表5 不同模型的预测误差

Table 5 Prediction errors of different models

| | 模型 | MAPE | RMSE | DS | 最大相对误差/% |
|-----------------------------|--------------|------|-----------|--------|----------|
| 用2018—2019年 预测2020—2021年 | ELM | 3.52 | 12 465.78 | 0.4875 | 10.78 |
| | PSO-ELM | 1.79 | 11 785.21 | 0.4937 | 4.62 |
| | SCA-ELM | 1.74 | 10 437.56 | 0.5012 | 2.35 |
| | EEMD-SCA-ELM | 1.11 | 9765.11 | 0.5548 | 1.78 |
| | WPD-SCA-ELM | 0.97 | 7415.38 | 0.6103 | 1.01 |
| 用2019—2020年 预测2020—2021年 | ELM | 2.17 | 11 011.36 | 0.6074 | 9.52 |
| | PSO-ELM | 1.12 | 9987.56 | 0.6482 | 4.09 |
| | SCA-ELM | 0.88 | 8754.31 | 0.6574 | 3.51 |
| | EEMD-SCA-ELM | 0.76 | 7389.45 | 0.8849 | 1.29 |
| | WPD-SCA-ELM | 0.59 | 7321.87 | 0.9205 | 0.95 |

和SCA-ELM)与ELM相比, MAPE、RMSE和 DS 均有显著提升, 说明采用优化算法对ELM的权重和偏差进行寻优可提升模型拟合精度, 证明了优化算法在回归预测中的必要性; PSO-ELM和SCA-ELM模型的对比结果说明, SCA算法在搜索优化效率和全局平衡能力上优于PSO算法; EEMD-SCA-ELM模型与SCA-ELM模型相比, MAPE、RMSE和 DS 分别提升了13.6%、15.6%、25.7%, 说明采用数据预分解的方式可有效降低数据复杂性和维度; EEMD-SCA-ELM和WPD-SCA-ELM模型的对比结果说明, WPD算法可从根本上杜绝EEMD算法引发的模态混叠和端点效应, 且不用进行分量筛选, 在保持原始数据完整性的前提下, 可充分挖掘信息的隐藏性和可用性。综上所述, WPD-SCA-ELM算法在预测误差和方向性两个方面均具有一定优越性, 证明该算法适合用于天然气日负荷的短期预测。

4 结论

(1)在“分解—预测—重构”的思想建立了基于WPD-SCA-ELM模型的天然气负荷预测模型, Fk4阶2层分解更能反映日负荷的变化趋势和特征。

(2)计算了不同日负荷影响因素的相关系数, 日最高气温和日最低气温的相关系数均大于平均气温, 而降雨量、平均风速和相对湿度对日负荷的影响较小, 通过对气温进行平移滑动操作, 可提高气温与日负荷的相关性。

(3)对比了不同模型的预测误差和方向性, 说明在没有其余因素影响的前提下, 采用越靠近预测时间的数据训练其结果的预测精度越高, WPD-SCA-ELM模型的MAPE、RMSE、 DS 分别为0.59、7321.87、0.9205, 证明了该模型用于天然气负荷预测的科学性。

参考文献

- [1] 黄献智, 杜书成. 全球天然气和LNG供需贸易现状及展望[J]. 油气储运, 2019, 38(1): 12-19. [HUANG X Z, DU S C. Status and prospect supply and demand trading of global natural gas and LNG[J]. Oil & Gas Storage and Transportation, 2019, 38(1): 12-19.]
- [2] JIE G, CHEN J, HUI S, et al. Current state and prospect of China natural gas industry[J]. China Oil & Gas, 2016, 23(1): 22-28.
- [3] BALITSKIY S, BILAN Y, STRIELKOWSKI W, et al. Energy efficiency and natural gas consumption in the context of economic development in the European Union[J]. Renewable and Sustainable Energy Reviews, 2016, 55: 156-168.
- [4] FADIRAN G, ADEBUSUYI A T, FADIRAN D. Natural gas consumption and economic growth: Evidence from selected natural gas vehicle markets in Europe[J]. Energy, 2019, 169: 467-477.
- [5] 王中元, 罗东坤, 刘璘璘. 我国城市燃气发展阶段及其主要特征[J]. 油气储运, 2016, 35(2): 115-123. [WANG Z Y, LUO D K, LIU L L. Urban gas development phases in China and its main characteristics[J]. Oil & Gas Storage and Transportation, 2016, 35(2): 115-123.]
- [6] 刘春霞, 李军, 党伟超, 等. 基于遗传算法优化小波神经网络的短期天然气负荷预测[J]. 计算机系统应用, 2020, 29(4): 175-180. [LIU C X, LI J, DANG W C, et al. Short-term natural gas load forecasting based on wavelet neural network optimized by genetic algorithm[J]. Computer Systems & Applications, 2020, 29(4): 175-180.]
- [7] 付川, 刘刚, 赵忠德, 等. 基于残差修正的冬季天然气日负荷预测模型[J]. 油气田地面工程, 2019, 38(10): 25-30. [FU C, LIU G, ZHAO Z D, et al. Forecast model of natural gas daily load in winter based on residual correction[J]. Oil-Gas Field Surface Engineering, 2019, 38(10): 25-30.]
- [8] 孙相博, 王岳. 基于改进灰色GM(1,1)模型的天然气负荷预测[J]. 辽宁石油化工大学学报, 2019, 39(3): 52-57. [SUN X B, WANG Y. Natural gas load forecasting based on improved grey GM(1,1) mode[J]. Journal of Liaoning Petrochemical University, 2019, 39(3): 52-57.]
- [9] 邱静. 基于改进的混合蛙跳算法的短期燃气负荷预测模型研究[D]. 上海: 上海师范大学, 2016. [QIU J. Research on short-term gas load forecasting model based on improved hybrid leapfrog algorithm[D]. Shanghai: Shanghai Normal University, 2016.]
- [10] 杨琼波, 崔东文. WPD-RSO-ESN和SSA-RSO-ESN模型在径流时间序列预测中应用比较[J]. 中国农村水利水电, 2022(2): 61-67. [YANG Q B, CUI D W. Application comparison of WPD-RSO-ESN and SSA-RSO-ESN models in runoff time series forecasting[J]. China Rural Water and Hydropower, 2022(2): 61-67.]
- [11] 赵恩来, 李向阳, 王高峰, 等. 基于模态分解-PSO-DNB深度学习的短期负荷预测研究[J]. 能源与环保, 2022, 44(5): 180-186. [ZHAO E L, LI X Y, WANG G F, et al. Research on short-term load forecasting based on modal decomposition-PSO-DNB deep learning[J]. China Energy and Environmental Protection, 2022, 44(5): 180-186.]
- [12] 朱刘柱, 王绪利, 马静, 等. 基于小波包分解与循环神经网络的综合能源系统短期负荷预测[J]. 电力建设, 2020, 41(12): 135-142. [ZHU L Z, WANG X L, MA J, et al. Short-Term load forecast of integrated energy system based on wavelet packet decomposition and

- recurrent neural network[J]. Electric Power Construction, 2020, 41(12): 135-142.]
- [13] 叶瑞丽, 郭志忠, 刘瑞叶, 等. 基于小波包分解和改进 Elman 神经网络的风电场风速和风电功率预测[J]. 电工技术学报, 2017, 32(21): 34-42. [YE R L, GUO Z Z, LIU R Y, et al. Wind speed and wind power forecasting method based on wavelet packet decomposition and improved elman neural network[J]. Transactions of China Electrotechnical Society, 2017, 32(21): 34-42.]
- [14] 骆正山, 姚梦月, 王小完. 基于 RS-SCA-PPR 的充填管道失效风险预测精度研究[J]. 有色金属工程, 2020, 10(1): 87-94. [LUO Z S, YAO M Y, WANG X W. Precision of failure risk prediction of filling pipeline based on RS-SCA-PPR[J]. Nonferrous Metals Engineering, 2020, 10(1): 87-94.]
- [15] 朱静, 何玉珠, 崔唯佳. 正弦余弦算法优化的 SVM 模拟电路故障诊断[J]. 导航与控制, 2018, 17(4): 33-40. [ZHU J, HE Y Z, CUI W J. Analog circuit fault diagnosis based on SVM optimized by SCA[J]. Navigation and Control, 2020, 10(1): 87-94.]
- [16] 李世强, 杨国栋, 金龙, 等. 基于 Spearman-CS-ELM 的油气管道腐蚀预测模型[J]. 油气田地面工程, 2022, 41(12): 17-22. [LI S Q, YANG G D, JIN L, et al. Oil and gas pipeline corrosion prediction model based on Spearman-CS-ELM[J]. Oil-Gas Field Surface Engineering, 2022, 41(12): 17-22.]

(责任编辑 马桂霞 编辑 杨雅露)