

基于CEEMDAN-MFO-RBF的风电功率短期预测*

谷凯文, 魏霞[†], 黄德启, 叶家豪, 王赛

(新疆大学 电气工程学院, 新疆 乌鲁木齐 830017)

摘要: 文中提出一种基于自适应噪声完整集成经验模态分解与飞蛾扑火算法优化径向基神经网络的短期风电功率预测方法. 首先, 利用自适应噪声完整集成经验模态分解对风电功率信号进行分解, 以获得不同时间尺度的固有模态函数分量和剩余分量, 该方法相较于经验模态分解与集成经验模态分解具有更好的收敛性和完整性. 其次, 利用飞蛾扑火算法优化径向基神经网络的结构参数来提高网络的泛化能力, 构建风电功率预测模型. 最后, 将分解后的各个分量分别输入风电功率预测模型, 得到各分量的预测结果, 再将各分量的预测结果线性组合得到最终的风电功率预测结果. 算例结果表明, 文中的预测模型对风力发电功率具有更好的预测性能.

关键词: 风电功率预测; 自适应噪声完整集成经验模态分解; 飞蛾扑火; 径向基神经网络

DOI: 10.13568/j.cnki.651094.651316.2020.12.17.0001

中图分类号: TM614 **文献标识码:** A **文章编号:** 2096-7675(2022)01-0111-08

引文格式: 谷凯文, 魏霞, 黄德启, 叶家豪, 王赛. 基于CEEMDAN-MFO-RBF的风电功率短期预测[J]. 新疆大学学报(自然科学版)(中英文), 2022, 39(1): 111-118.

英文引文格式: GU Kaiwen, WEI Xia, HUANG Deqi, YE Jiahao, WANG Sai. Short-term prediction of wind power based on CEEMDAN-MFO-RBF[J]. Journal of Xinjiang University(Natural Science Edition in Chinese and English), 2022, 39(1): 111-118.

Short-Term Prediction of Wind Power Based on CEEMDAN-MFO-RBF

GU Kaiwen, WEI Xia, HUANG Deqi, YE Jiahao, WANG Sai

(School of Electrical Engineering, Xinjiang University, Urumqi Xinjiang 830017, China)

Abstract: This paper proposes a short-term wind power prediction method based on complete ensemble empirical mode decomposition with adaptive noise and moth-flame optimization to optimize the radial basis function neural network. Firstly, complete ensemble empirical mode decomposition with adaptive noise is used to decompose the wind power signal to obtain the intrinsic modal function components and residual components of different time scales. Compared with empirical mode decomposition and ensemble empirical mode decomposition, this method has better convergence and completeness. Secondly, use moth-flame optimization to optimize the structural parameters of the radial basis function neural network to improve the generalization ability of the network and build a wind power forecast model. Finally, input the decomposed components into the wind power prediction model to obtain the prediction results of each component, and linearly combine the prediction results of each component to obtain the final wind power prediction result. The calculation example shows that the prediction model in the article has better prediction performance for wind power generation.

Key words: wind power forecasting; complete ensemble empirical mode decomposition with adaptive noise; moth-flame optimization; radial basis function neural network

0 引言

为了积极响应国家低碳环保的号召, 传统的发电模式逐渐减少, 新能源发电逐渐成熟, 其中风力发电依靠其特有的方式被大众认可. 但风力发电受风速、风向、温度、湿度、大气压等自然因素影响呈现出不稳定性, 给

* 收稿日期: 2020-12-17

基金项目: 国家自然科学基金(51468062).

作者简介: 谷凯文(1994-), 男, 硕士生, 从事智能控制理论与应用的研究, E-mail: 457894173@qq.com.

† 通讯作者: 魏霞(1977-), 女, 硕士, 副教授, 主要从事工业大数据技术和控制的研究, E-mail: kevinguu@qq.com.

电力系统安全运行带来很大影响. 因此, 需要提前对风力发电场作出相对准确的功率预测, 进而制定合理的发电计划, 从而使电力系统安全稳定运行^[1-3].

当前, 国内外对于风力发电都有广泛研究, 使用方法各不相同, 主要分为物理方法和统计方法^[4]. 其中, 数值天气预报(NWP)是物理方法中非常重要的一种方法, 该方法根据大气及风电场周围的实际情况, 在一定的初值和边值条件下, 通过计算机作数值计算, 构建流体力学和热力学模型进行风电功率预测, 但该方法受模型和参数的影响比较大, 不符合精确的短期风电功率预测研究^[5-6]. 统计方法则利用各种影响风机出力的历史数据与功率数据构建相应的非线性预测模型, 然后对数据进行相应处理, 再输入到预测模型中进行风电功率预测^[7]. 主要的预测方法包括神经网络法、支持向量机法、极限学习机法等^[8-10]. 文献[11]利用LSTM方法构建风电功率预测模型, 通过与ARIMA时序预测算法对比, 从性能误差指标证明了LSTM方法预测的相对高效性. 文献[12]利用CEEMDAN-FE对数据进行分解, 然后构建KELM预测模型, 通过仿真实验对比发现, 文中所提方法的预测精度更高. 文献[13]利用EEMD对数据进行分解处理, 构建了ACS-LSSVM预测模型, 通过仿真实验表明文中所用方法优越的动态性能和精准的预测性能. 文献[14]构建了MS-RBF预测模型, 通过仿真实验对比发现, 文中所提方法相比单一的径向基神经网络(Radial Basis Function, RBF)预测模型大大提高了预测精度. 文献[15]通过自适应噪声的完备经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN)对原始数据进行分解, 构建GRU-XGBoost预测模型, 通过仿真实验证明了CEEMDAN-GRU-XGBoost预测模型的预测精度相比于LSTM和ANN有明显的优势.

文中提出基于自适应噪声完整集成经验模态分解与飞蛾扑火算法优化径向基神经网络的短期风电功率预测方法. 首先, 利用自适应噪声完整集成经验模态分解对风电功率原始数据进行分解, 获得不同时间尺度的固有模态函数分量和剩余分量, 在此基础上利用飞蛾扑火算法寻找径向基神经网络的最优参数, 以提高径向基神经网络的预测精度, 将分解后的各个分量输入到构建的风电功率预测模型中进行预测, 并将各分量的预测结果进行线性叠加从而得到最终的预测结果. 最后利用新疆某风电场的实际数据进行仿真实验, 实验结果表明, 文中所提方法相比于经典方法具有更高的预测精度.

1 预测模型原理及建立

1.1 自适应噪声完整集成经验模态分解原理

自适应噪声完整集成经验模态分解(CEEMDAN)是对经验模态分解(Empirical Mode Decomposition, EMD)和集成经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)的一种改进方法. EMD方法可以将数据信号分解为有限个本征模态函数(Intrinsic Mode Function, IMF), 每个IMF分量代表了不同时间尺度上的样本特征, 但其容易出现“模态混叠”问题. 在EMD方法的基础上逐渐提出了EEMD方法, 该方法将正态分布的白噪声加到了原来的数据信号中, 进而对数据信号进行分解, 然后将每次得到的IMF做集成平均处理, 从而降低了模态混叠效应, 但其不具完备性, 而且计算量比较大. CEEMDAN方法则是在EEMD的基础上, 通过自适应加入白噪声, 既提高了预测精度, 又减少了计算量, 因此, 文中选用该方法对数据信号进行处理. CEEMDAN方法的分解过程如下所述:

(1) 在最初的数据信号 $y(n)$ 中添加不同幅值 ε 的高斯白噪声 $w_i(n)$, 即:

$$y_i(n) = y(n) + \varepsilon w_i(n) \quad (1)$$

式中: $y_i(n)$ 为最初的数据信号加入高斯白噪声以后的信号.

(2) 对加入高斯白噪声的信号 $y_i(n)$ 进行EMD分解, 得到第一个模态分量和第一个剩余分量:

$$IMF_1(n) = \frac{1}{t} \sum_{i=1}^t IMF_{i1}(n) \quad (2)$$

$$r_1(n) = y(n) - IMF_1(n) \quad (3)$$

(3) 定义 $E_k(\cdot)$ 为EMD分解所产生的第 k 个阶段的模态分量, 对信号 $r_1(n) + \varepsilon_1 E_1(w_i(n))$ 进行EMD分解, 则第二个IMF模态分量和第二个剩余分量计算如下:

$$IMF_2(n) = \frac{1}{t} \sum_{i=1}^t E_1\{r_1(n) + \varepsilon_1 E_1[w_i(n)]\} \quad (4)$$

$$r_2(n) = r_1(n) - IMF_2(n) \quad (5)$$

(4) 对其余每个阶段, 即 $k=2, \dots, K$, 与步骤3的计算过程一致, 计算第 k 个剩余分量和第 $k+1$ 模态分量为:

$$r_k(n) = r_{k-1}(n) - IMF_k(n) \quad (6)$$

$$IMF_{k+1}(n) = \frac{1}{t} \sum_{i=1}^t E_1\{r_k(n) + \varepsilon_k E_k[w_i(n)]\} \quad (7)$$

(5) 重复步骤4, 直到剩余分量不能再进行分解, 即余量信号的极值点不超过两个, 则最终的剩余分量为:

$$R(n) = y(n) - \sum_{k=1}^k IMF_k(n) \quad (8)$$

式中: k 为所有模态分量的数量.

1.2 飞蛾扑火算法原理

飞蛾扑火 (Moth-Flame Optimization, MFO) 算法是Seyedali通过观察飞蛾利用月光飞行这一导航方式提出的新型群智能优化算法^[16]. 简单来说, 该算法就是固定数量的飞蛾在解空间中寻找更合适的位置, 即目标函数的解, 而火焰就是最优解. 目前该算法应用于电力系统经济调度、轨迹寻优以及网络安全等各个领域, 且取得了非常好的效果, 表明了该算法的有效性^[17-18].

在MFO算法中, 矩阵 M 代表飞蛾的集合, 矩阵 F 代表火焰的集合, OM 是飞蛾的适应度值, OF 是火焰的适应度值, 该算法可以用下述三元组进行表述:

$$MFO = (I, P, T) \quad (9)$$

函数 I 代表飞蛾种群以及对应的适应度值. 其系统模型如下所示:

$$I: \Phi \rightarrow \{M, OM\} \quad (10)$$

函数 P 影响飞蛾在解空间中的运动轨迹, 通过不断迭代, 进而更新自己的位置.

$$P: M \rightarrow M \quad (11)$$

函数 T 是为了判断是否达到预期结果, 达到预期结果则为true, 否则为false.

$$T: M \rightarrow \{true, false\} \quad (12)$$

上述流程总结: 初始化飞蛾位置, 不断进行迭代, 最终达到预期效果.

利用式 (13) 更新每只飞蛾相对于火焰的位置:

$$M_i = S(M_i, F_j) \quad (13)$$

式中: 第 i 只飞蛾用 M_i 表示, 第 j 个火焰用 F_j 表示, S 为螺旋形函数.

该算法中的对数螺旋函数如式 (14) 所示:

$$S(M_i, F_j) = D_i \cdot e^{bt} \cdot \cos(2\pi t) + F_j \quad (14)$$

式中: 飞蛾 i 与火焰 j 的距离用 D_i 表示, b 为常数, t 为随机数, 从 $[-1, 1]$ 中选取.

通过式 (15) 可以求出距离 D :

$$D_i = |F_j - M_i| \quad (15)$$

因为最终的火焰位置是全局最优解, 而且为了算法更好的寻优能力, 所以要在迭代过程中逐渐减少火焰的数量, 如式 (16) 所示:

$$flameno = \text{round}(N - l \times \frac{N-1}{T}) \quad (16)$$

式中:当前迭代次数用 l 表示,火焰数量的最大值用 N 表示,最大迭代次数用 T 表示.该算法的迭代过程如下所述:

(1) 用式(10)随机散布飞蛾的位置,设置相关参数,开始进行迭代;

(2) 根据式(16)计算火焰的数量;

(3) 将飞出搜索空间的飞蛾位置进行重置,计算每只飞蛾的个体适应度值;

(4) 当为第1次迭代时,将飞蛾的适应度值进行从优到劣排列,进而更新火焰的位置和适应度值;当为第1次迭代之后的迭代时,将火焰和上一次迭代的飞蛾的适应度值进行排序,进而更新火焰的位置和适应度值,从而取最优解作为最优火焰;

(5) 根据式(15)计算火焰与飞蛾之间的距离,进而用式(14)逐个更新飞蛾的位置;

(6) 本次迭代结束后返回第(2)步,直至达到最大迭代次数或找到全局最优解.

1.3 径向基神经网络原理

径向基(RBF)神经网络是一种性能良好的前馈式神经网络,可以有效解决系统内部相对复杂的规律性问题,具有高效的输入、输出映射能力,相比其他前向网络,具有结构简单、训练简洁、学习收敛速度快等特点,因此被广泛应用于非线性优化、时间序列预测和模式识别等领域^[19-20].

RBF神经网络由输入层、隐含层和输出层构成.从输入空间到隐层空间的变换是非线性的,输入层的作用是为了传输信号,输入层和隐含层之间可以看作连接权值为1的连接,而从隐层空间到输出层空间变换是线性的,隐含层是对基函数参数的调整,输出层是所有隐含层输出的线性加权和.但RBF神经网络存在自身泛化能力不足的问题,因此,在风电功率预测中一般采用优化算法为RBF神经网络寻找最优参数,提高预测模型的泛化能力.RBF神经网络结构图如图1所示.




图1 RBF神经网络结构图

RBF神经网络需要选取三组参数:基函数的中心 c 、宽度 σ 、隐含层到输出层的权值 ω .RBF神经网络中常用的径向基函数采用高斯函数,则RBF的激活函数可以表达如下:

RBF神经网络需要选取三组参数:基函数的中心 c 、宽度 σ 、隐含层到输出层的权值 ω .RBF神经网络中常用的径向基函数采用高斯函数,则RBF的激活函数可以表达如下:

$$R_i(x) = \exp\left(-\frac{\|x - c_i\|^2}{2\sigma_i^2}\right) \quad (17)$$

式中: x 为输入样本; c_i 为基函数的中心; σ_i 为基函数的方差; $\|x - c_i\|$ 为欧氏范数.

由RBF神经网络的结构图可知网络输出为:

$$y_j = \sum_{i=1}^h w_{ij} \exp\left(-\frac{\|x - c_i\|^2}{2\sigma_i^2}\right), j = 1, 2, \dots, n \quad (18)$$

式中: y_j 为输出层第 j 个节点输出; w_{ij} 为隐含层第 i 个节点到输出层第 j 个节点的权值; h 为隐含层的节点数.

1.4 预测模型的建立

文中所提的CEEMDAN-MFO-RBF风电功率短期预测流程图如图2所示,具体过程如下所述:

(1) 设置CEEMDAN算法中的噪声标准偏差、训练周期和迭代次数,然后将风电功率信号分解为多个固有模态分量和剩余分量;

(2) 设置MFO算法参数,初始化飞蛾的位置,计算火焰的数量和飞蛾个体适应度值,对飞蛾种群和飞蛾个体适应度值排序,获取最优火焰位置和火焰适应度值,当找到最优解或达到最大迭代次数时,获得最终全局最优解;

(3) 设置RBF神经网络中的参数(动量因子、学习因子、输入层数、隐含层数和输出层数),以均方根误差作为适应度函数,寻找其最小值作为全局最优解,将MFO算法找到的全局最优解优化RBF神经网络的基函数中

心、宽度和权值, 建立MFO-RBF预测模型. 均方根误差公式如下所示:

$$X_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - t_i)^2} \quad (19)$$

式中: p_i 表示第*i*次预测时的预测值; t_i 表示第*i*次预测时样本的实际值; n 为预测样本数.

(4) 将CEEMDAN算法分解的模态分量和剩余分量分别输入到MFO-RBF预测模型中进行预测, 将各个分量的预测值线性组合进而得到最终的预测结果.

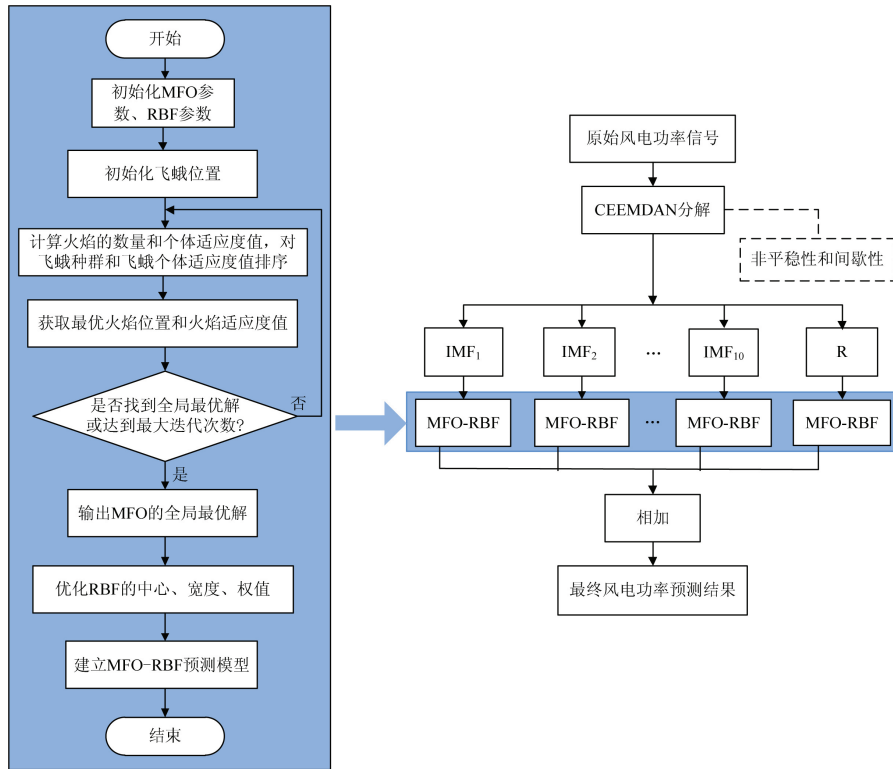


图 2 基于CEEMDAN-MFO-RBF的预测流程图

2 算例分析

文中采用新疆某风电场的实际数据进行CEEMDAN-MFO-RBF风电功率短期预测. 选择2017年1月1日到2017年1月31日的2 976组数据, 每一个采样点的时间尺度为15 min, 将2017年1月1日到2017年1月30日的2 880组数据作为模型的训练集, 将2017年1月31日的96组数据(24小时)作为模型的测试集, 进行预测仿真实验. 该仿真实验选择使用MATLAB 2019a平台, 预测未来24小时的功率, 进而验证文中所提预测模型的预测精度.

文中选取均方根误差(Root Mean Square Error, RMSE)、均方误差(Mean Square Error, MSE)和平均绝对误差(Mean Absolute Error, MAE)作为风电功率预测的误差评价指标^[21], 其公式如下所示:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (20)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2 \quad (21)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - y_i| \quad (22)$$

式中: x_i 表示第*i*次预测时的预测值; y_i 表示第*i*次预测时样本的实际值; n 为预测样本数.

2.1 基于CEEMDAN的风电功率信号分解

在实验中,对原始风电功率信号序列进行CEEMDAN分解,分解时添加500组噪声标准偏差为0.2的白噪声信号,由于序列的非平稳性使得原始风电功率信号序列被分解为10个固有模态分量(IMF)和1个剩余分量(R),分解结果如图3所示。




图 3 CEEMDAN方法的分解结果

为了验证CEEMDAN方法的高效性,文中分别使用EMD方法、EEMD方法和CEEMDAN方法对原始风电功率信号序列进行分解,并将分解后的各个分量输入到MFO-RBF预测模型中,利用误差评价指标对三种分解方法进行对比,结果如表1所示。

表 1 三种分解方法误差指标对比

预测方法	RMSE	MSE	MAE
EMD-MFO-RBF	2.831 3	8.016 5	1.782 6
EEMD-MFO-RBF	2.498 2	6.241 2	1.419 0
CEEMDAN-MFO-RBF	1.501 1	2.253 3	1.057 9

由表1可知, CEEMDAN方法的均方根误差指标RMSE相比EMD和EEMD方法分别降低了46.98%和39.91%, 均方误差指标MSE相比前两种方法分别降低了71.89%和63.89%, 平均绝对误差指标MAE相比前两种方法分别降低了40.65%和25.45%, 表明CEEMDAN方法对原始风电功率信号分解的有效性和收敛性.

2.2 预测模型结果及对比分析

为了验证文中所提出预测模型的预测精度是否优越, 在本次实验中分别构建了 PSO-RBF、GA-RBF、MFO-RBF、EMD-MFO-RBF、EEMD-MFO-RBF 和 CEEMDAN-MFO-RBF 预测模型, 为了增加仿真结果的可靠性, 文中将仿真10次的误差评价指标数值的平均值作为各个预测模型的误差评价结果, 各预测模型的预测结果对比如图4所示.

由图4可知, 经典 PSO-RBF 预测模型和 GA-RBF 预测模型与实际值的拟合程度低, 预测前期波动比较大. 而文中所提的 MFO-RBF 预测模型与实际值的拟合程度相对比较高, 但相比经过风电功率信号序列分解的 EMD-MFO-RBF、EEMD-MFO-RBF 和 CEEMDAN-MFO-RBF 预测模型, 与实际值的偏离程度仍然很大. 各预测模型的误差指标对比结果如表2所示.

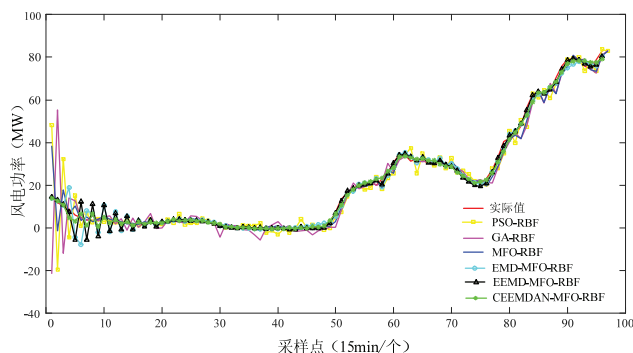


图 4 模型预测结果对比图

表 2 模型误差指标对比

预测方法	RMSE	MSE	MAE
PSO-RBF	6.043 3	36.521 6	3.047 8
GA-RBF	6.771 4	45.851 6	3.202 0
MFO-RBF	3.630 6	13.181 1	1.928 4
EMD-MFO-RBF	2.831 3	8.016 5	1.782 6
EEMD-MFO-RBF	2.498 2	6.241 2	1.419 0
CEEMDAN-MFO-RBF	1.501 1	2.253 3	1.057 9

通过对比表2中的数据可知, 文中所提的 MFO-RBF 预测模型的均方根误差指标 RMSE 相比经典的 PSO-RBF 预测模型和 GA-RBF 预测模型分别降低了 39.92% 和 46.38%, 均方误差指标 MSE 分别降低了 63.91% 和 71.25%, 平均绝对误差指标 MAE 分别降低了 36.73% 和 39.78%, 表明 MFO-RBF 预测模型的预测精度优于经典算法的预测模型. 而文中所提的 CEEMDAN-MFO-RBF 预测模型的误差性能指标低于其他五种预测模型, 表明其预测模型的预测效果最好, 有较高的预测准确率.

表 3 多步预测误差指标对比

预测方法	预测步长	RMSE	MAE
EMD-MFO-RBF	一步	3.656 0	2.722 0
	三步	4.392 6	3.101 6
	六步	5.156 1	3.256 3
EEMD-MFO-RBF	一步	2.900 5	1.458 7
	三步	3.643 8	1.595 2
	六步	4.150 6	2.169 7
CEEMDAN-MFO-RBF	一步	1.814 6	1.078 4
	三步	2.171 0	1.403 4
	六步	2.766 1	1.448 3

为了进一步验证文中所提方法的有效性, 进行了增加预测步长的多步预测仿真实验, 预测步长分别设定为一步、三步和六步, 各预测模型多步预测误差对比结果如表3所示. 在三种预测模型中, CEEMDAN-MFO-RBF 相比 EMD-MFO-RBF, 在一步、三步、六步预测中的均方根误差指标 RMSE 分别降低了 50.37%、50.58%、46.35%, 平

均绝对误差指标MAE分别降低了60.38%、54.75%、55.52%; CEEMDAN-MFO-RBF相比EEMD-MFO-RBF, 在一步、三步、六步预测中的均方根误差指标RMSE分别降低了37.44%、40.42%、33.36%, 平均绝对误差指标MAE分别降低了26.07%、12.02%、33.25%. 实验结果表明, 在各个预测模型中, 一步预测的误差评价指标要优于三步预测和六步预测, 即预测步长越长, 预测误差越大. 相比于其他预测模型, CEEMDAN-MFO-RBF在一步、三步、六步预测中的预测精度最高, 且预测稳定性最好.

3 结论

文中提出基于CEEMDAN-MFO-RBF的风电功率短期预测方法, 通过CEEMDAN对风电功率信号进行分解处理, 在此基础上利用MFO算法寻找RBF神经网络的最优参数, 以提高RBF神经网络的预测精度, 进而构建MFO-RBF预测模型, 经过仿真实验分析表明:

(1) CEEMDAN方法可以非常有效地对风电功率进行处理, 进而降低其非线性和非平稳性, 而且还能克服EMD方法产生模态混叠的问题及EEMD方法计算量大的问题.

(2) 通过MFO算法为RBF神经网络寻找最优的参数, 相比传统的优化算法, MFO算法优化后的效果更好, 提高了径向基神经网络的预测精度.

(3) 构建的CEEMDAN-MFO-RBF风电功率预测模型, 预测精度较高, 具有非常好的实用价值, 为以后的短期风电功率预测提供了新的借鉴.

参考文献:

- [1] 杨正瓴, 冯勇, 熊定方, 等. 基于季风特性改进风电功率预测的研究展望[J]. 智能电网, 2015, 3(1): 1-7.
- [2] 余平. 风电场风速及风电功率预测方法研究综述[J]. 电子技术与软件工程, 2019, 147(1): 230.
- [3] CARTA J A, VELAZQUEZ S, CABRERA P. A review of measure-correlate-prediction(MCP) methods used to estimate long-term wind characteristics at a target site[J]. Renewable and Sustainable Energy Reviews, 2013, 27(6): 362-400.
- [4] 黎静华, 桑川川, 甘一夫, 等. 风电功率预测技术研究综述[J]. 现代电力, 2017, 34(3): 1-11.
- [5] 薛禹胜, 郁琛, 赵俊华, 等. 关于短期及超短期风电功率预测的评述[J]. 电力系统自动化, 2015, 39(6): 141-151.
- [6] 张维杰, 田建艳, 王芳, 等. 改进型T-S模糊神经网络风电功率预测模型的研究[J]. 自动化仪表, 2014, 35(12): 39-42.
- [7] 徐遵义, 王俊雪. 基于风速融合和NARX神经网络的短期风电功率预测[J]. 现代电子技术, 2020, 43(9): 166-169.
- [8] 马斌, 张丽艳. 一种基于径向基神经网络的短期风电功率直接预测方法[J]. 电力系统保护与控制, 2015, 43(19): 78-82.
- [9] 王丽婕, 厉虹, 方市彬. 基于人工鱼群优化算法的支持向量机短期风电功率预测模型[J]. 电气工程学报, 2016, 11(10): 7-12.
- [10] 卓泽赢, 曹茜, 李青. 基于EWT-KELM方法的短期风电功率组合预测[J]. 电测与仪表, 2019, 56(2): 83-89.
- [11] 李相俊, 许格健. 基于长短期记忆神经网络的风力发电功率预测方法[J]. 发电技术, 2019, 40(5): 426-433.
- [12] 李军, 李大超. 基于CEEMDAN-FE-KELM方法的短期风电功率预测[J]. 信息与控制, 2016, 45(2): 135-141.
- [13] 姜贵敏, 陈志军, 李笑竹, 等. 基于EEMD-ACS-LSSVM的短期风电功率预测[J]. 太阳能学报, 2020, 41(5): 77-84.
- [14] 周洪煜, 赵乾, 王照阳, 等. 风电机组输出功率超短期预测的组合模型研究[J]. 太阳能学报, 2014, 35(3): 457-461.
- [15] 杨森, 刘三明, 王致杰. 基于GRU-XGBoost的风电场功率短期预测[J]. 仪表技术, 2020, 30(1): 17-21.
- [16] SEYEDALI M. Moth-flame optimization algorithm: a novel nature-inspired heuristic paradigm[J]. Knowledge-Based Systems, 2015, 89(11): 228-249.
- [17] 李志明, 莫愿斌, 张森. 一种新颖的群智能算法: 飞蛾扑火优化算法[J]. 电脑知识与技术, 2016, 12(31): 172-176.
- [18] 薛飞, 张登雨, 石季英, 等. 基于飞蛾扑火优化算法的光伏阵列MPPT研究[J]. 电力电子技术, 2019, 53(5): 60-63.
- [19] 苏尤丽, 汤建国. 人工智能神经网络在新能源微电网中的应用[J]. 新疆大学学报(自然科学版), 2016, 33(4): 444-448.
- [20] 乔远阳, 吴技莲, 冯新龙. MQ径向基函数的理论、方法及应用[J]. 新疆大学学报(自然科学版), 2015, 32(4): 379-387+376.
- [21] 张鑫磊, 李根. 基于IEEMD与LS-SVM组合的短期风电功率多步预测方法[J]. 电测与仪表, 2020, 57(6): 52-60.

责任编辑: 赵新科