

基于二层分解的 PSO-LSTM 模型风电功率超短期预测

蒲娴怡^{1,2}, 毕贵红¹, 王凯¹, 谢旭¹, 陈仕龙¹

(1. 昆明理工大学 电力工程学院, 云南 昆明 650500;

2. 云南电网有限责任公司玉溪供电局, 云南 玉溪 653199)

摘要: 为提升风电功率预测精度, 提出基于二层分解技术和粒子群优化长短期记忆(PSO-LSTM)神经网络组合的超短期风电功率预测模型。对风电功率原始数据, 采用快速集合经验模态分解(FEEMD)方法将其分解为一系列本征模态函数(IMF)分量和余项, 针对高频分量采用变分模态分解(VMD)进行二层分解。运用样本熵来解决分量个数过多、计算量繁杂的问题。通过偏自相关函数(PACF)筛选出与预测值关联程度高的元素确定输入维数。最后, 选用PSO来优化LSTM相关参数建立预测模型并叠加获得最终值。试验结果表明, 该组合模型有效提高了预测精度。

关键词: 风电功率预测; 快速集合经验模态分解; 偏自相关函数; 二层分解; 粒子群优化; 深度学习

中图分类号: TM 744 文献标志码: A 文章编号: 1673-6540(2021)05-0086-07

doi: 10.12177/emca.2020.241

Ultra-Short-Term Wind Power Prediction Based on Two-Layer Decomposition Technique and PSO-LSTM Model

PU Xianyi^{1,2}, BI Guihong¹, WANG Kai¹, XIE Xu¹, CHEN Shilong¹

(1. College of Electric Power Engineering, Kunming University of Science and Technology, Kunming 650500, China;

2. Yuxi Power Supply Bureau of Yunnan Power Grid Co., Ltd., Yuxi 653199, China)

Abstract: In order to improve wind power prediction accuracy, an ultra-short-term wind power prediction model based on the combination of two-layer decomposition technique and particle swarm optimization long short-term memory (PSO-LSTM) neural network is proposed. The fast ensemble empirical mode decomposition (FEEMD) method is used to deconstruct the original wind power sequence into a series of intrinsic mode function (IMF) components and the remainder term. The high frequency IMF is decomposed by the variational mode decomposition (VMD) of two-layer decomposition technology. The sample entropy is used to solve the problem of too many components and complicated calculation. The input dimension is determined by selecting the elements of high correlation degree with the predicted value through partial autocorrelation coefficient function (PACF). PSO-LSTM is used to construct the prediction model, and the final value is obtained by superposition. The experimental results show that the combined model can effectively improve the prediction accuracy.

Key words: wind power prediction; fast ensemble empirical mode decomposition (FEEMD); partial autocorrelation coefficient function (PACF); two-layer decomposition; particle swarm optimization (PSO); deep learning

收稿日期: 2020-12-15; 收到修改稿日期: 2021-03-24

作者简介: 蒲娴怡(1995—), 女, 硕士研究生, 研究方向为数据分析和功率预测。

毕贵红(1968—), 男, 博士, 教授, 研究方向为人工智能在电力系统中的应用。

0 引言

近年来风力发电量持续上升,保持稳步增长势头。风电功率预测最突出的问题是间歇性和不确定性带来的输出大幅度波动。风力发电技术想要突破大规模并网运行问题,需要提高风电场输出功率的可控性。风电功率时间序列是受随机因素影响的非平稳性序列。对风电功率的预测技术已经日趋成熟化和多样化。为了进一步提升预测精度,研究者们一直在不断改进预测方法。

现有的风电功率预测主要有物理模型和统计分析2类方法^[1-3]。目前,国内外学者在风电功率预测方面较常采用统计方法来建立历史数据和实时输出功率数据之间的联系,主要有时间序列分析法^[4]、卡尔曼滤波模型^[5]、神经网络模型^[6-7]等方法。风电功率的随机性、波动性、突变性等特征使单一模型往往难以取得预期的精确预测。在单一模型的基础上结合不同算法的优点,能有效提高预测精度,如采用小波变换算法和BP神经网络的组合^[8]、差分自回归移动平均模型(ARIMA)与埃尔曼神经网络(Elman)的组合^[9]、自适应噪声完整集成经验模态分解(CEEMDAN)和核极限学习机组合等通过分解集成的风电功率预测方法^[10],能够更多地挖掘风电功率序列中的隐藏信息,获得比单一模型更好的预测效果。文献[11]中对比了不同的预测模型,最终结果为快速集合经验模态分解(FEEMD)的效果优于小波分解与经验模态分解(EMD)。文献[12-13]在不同的领域均采用二层分解技术,对第一次分解产生的高频分量采用不同的分解方式进行二次分解,以降低复杂的高频分量对预测结果的影响。文献[14]提出针对风电时间序列的长依赖性问题,通过长短时记忆(LSTM)神经网络对数据进行训练预测,并用粒子群优化(PSO)算法优化模型参数省去人工选取的繁琐步骤,最终获得最佳的预测效果。另外,网络输入变量个数的选取会影响整个预测模型的好坏,输入层神经元个数可以由时间序列的滞后期决定,因此计算时间序列的滞后期尤为重要。利用偏自相关函数(PACF)^[15]、赤池信息准则(AIC)^[16-17]等方法可以确定模型输入变量个数选取问题,提高网络的收敛效率和预测精度。

结合上述方法具有的优点,提出一种新的混合预测方式,即基于二层分解技术和PSO-LSTM神经网络的风电功率超短期预测模型。把原始风电功率数据利用FEEMD分解为一系列本征模态函数(IMF)分量和余项,针对分解出的风电功率高频分量采用变分模态分解(VMD)方法进行二次分解。采用样本熵(SE)计算各分量的熵值进行分量重构,再利用PACF确定模型输入变量的个数。利用自适应学习策略的PSO选择LSTM神经网络的超参数,分别对风电数据各个IMF和余量进行训练预测,叠加各分量的预测结果即为最终超短期功率预测结果,提高预测精度。

1 算法原理

1.1 基于FEEMD和VMD的二层信号分解

1.1.1 FEEMD

EMD用来处理实际生活中的非稳定信号,但非稳定信号的极值点分布不均匀会使分解分量产生混叠现象,或是因包含差异极大的特征时间尺度而出现伪分解现象。集合经验模态分解(EEMD)^[18]在不同的序列中多次添加强度相同的白噪声,使有缺失的信号得到补充,改善模态混叠并且对产生的新信号进行有效分解。FEEMD^[11,19]通过减少取样来降低计算时间,处理速度更快,提高了EEMD算法执行效率。可将风电功率序列内部蕴含的不同规律特性通过自身的分解角度分解为一系列更为简单稳定的IMF分量,利于后续预测模型挖掘信息,提高预测精度。

采用FEEMD将复杂的风电功率信号分解为一系列分量,原始信号表示如下:

$$X_{(i)} = \sum_{i=1}^N \text{IMF}(i) + r_i(t) \quad (1)$$

式中:N为被分解出来的IMF总个数; $r_i(t)$ 为余量。

1.1.2 VMD

VMD是一种新的混沌数据处理技术,在产生主信号的时候具有特定的稀疏特性,可以根据序列确定模态分解个数,通过约束匹配到各种模态的最佳中心频率和有限带宽,对风电复杂信号进行最优化划分。

对于FEEMD分解原始风电功率序列产生的

较为复杂的高频 IMF 分量,通过 VMD 方法分解成 K 个基本模式分量,得到不同频率尺度且相对平稳的风电功率序列,利于后续预测模型得到较好的预测结果^[20]。

1.1.3 SE

经过分解后的风电功率分量能细致地表达原始分量的特征,但分量个数过多会使计算工作量变大,计算时间变多,可以用 SE^[21]对功率分解后的分量进行重构。SE 在比较时添加了自身比较数值,是一种在近似熵的基础上优化了时间序列复杂性计算的度量方法,有效避免了统计量的不一致性。将分解后得到的风电功率分量经过 SE 计算通过熵值和分解曲线来确定模型重构分量,以降低计算量。

1.2 PSO-LSTM 神经网络模型

1.2.1 LSTM 神经网络

本文采用 LSTM^[22]神经网络对风电功率进行超短期预测。对经过二层分解处理后的风电功率复杂序列分量采用 LSTM 神经网络进行预测能够获得较好的预测结果,可以将较长时间之前的信息输送给后面时间步长的细胞,利于预测时间间隔较大的信息,有较大的记忆容量,有更强的泛化能力和自适应能力,可解决长时间依赖问题。LSTM 是循环神经网络(RNN)的一种特殊变体。链式结构中重复的细胞单元包含 4 个相互作用的激活函数,可以进行学习和信息交互。LSTM 神经网络结构包括遗忘门、输入门、输出门和细胞状态。LSTM 记忆单元结构如图 1 所示。

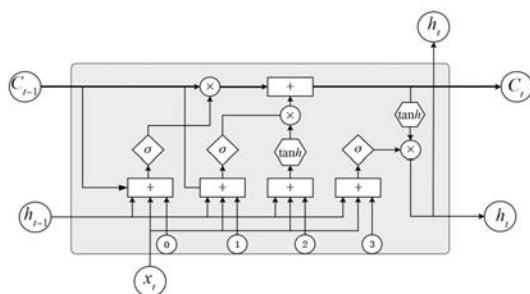


图 1 LSTM 记忆单元结构

图 1 中,上方的粗水平线是信息传递的关键,控制信息向下一个细胞 C_t 传递,被称为单元状态。 σ 代表激活函数 sigmoid,输入门与激活函数决定可以让多少新的信息加入单元,遗忘门是以上一单元的输出信息 h_{t-1} 和本单元的新输入 X_t ,

— 88 —

通过激活函数缩放单元状态来控制信息被丢弃或留下。输出门控制单元通过考虑当前输入 X_t 、先前输出 h_{t-1} 和遗忘门来做出决定,产生一个新的输出 C_t 并改变单元的输出信息 h_t 。图 2 为本文采用的 LSTM 网络结构,由输入层、全连接层、2 层 LSTM 层和输出层构成。

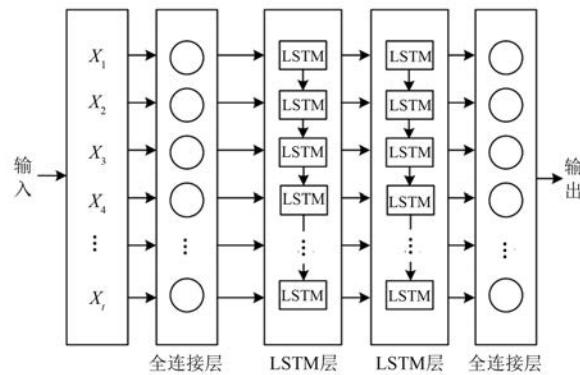


图 2 LSTM 预测模型的网络结构

1.2.2 PSO

PSO^[23]基本核心是利用每个个体所提供的信息分享到整体中,使整体在掌握了所有信息后对问题做出最佳判断,解的评价标准是粒子适应度。PSO 初始化生成若干个随机粒子(随机解),带着速度与位置的 2 个极值,通过每一次迭代更新找到最优解。第一个极值就是每个粒子的最优解 pbest,另一个是整个种群全局最优解 gbest。

第 i 个粒子的第 k 次速度和位置更新式为

$$\begin{aligned} v_i^{k+1} &= \omega \times v_i^k + c_1 \times r_1 \times (pbest_i^k - x_i^k) + \\ &\quad c_2 \times r_2 \times (gbest^k - x_i^k) \end{aligned} \quad (2)$$

$$x_i^{k+1} = x_i^k + v_i^{k+1} \quad (3)$$

式中: v 为速度矢量; ω 为惯性因子,是保持原来速度的系数; c_1, c_2 分别为粒子的个体、群体学习因子; r_1, r_2 为 $[0,1]$ 之间的随机数。

搜索过程达到指定迭代次数或最优位置满足最小适应阈值则结束。

1.2.3 PSO-LSTM 神经网络

LSTM 模型的参数设置对风电功率预测精度结果有直接影响。采用 PSO-LSTM 模型,将 LSTM 模型的参数作为粒子优化对象^[24-25],对风电功率数据进行寻优训练获得模型的最优超参数,这个过程没有人为调参影响,随机性小,优化效果相对稳定。

PSO-LSTM 模型算法流程简述如下。

步骤 1: 将试验数据分为训练数据和测试数据。

步骤 2: 将 LSTM 模型中神经网络隐藏层单元数目、迭代次数和学习率作为粒子群优化对象, 初始化粒子种群速度与位置, 确定 PSO 的最大迭代次数与种群数量。

步骤 3: 计算每个粒子的适应度值。以各粒子对应参数构建 LSTM 模型, 通过训练数据进行训练, 结果的均方根误差作为各粒子的适应度值。

步骤 4: 根据粒子适应度值更新位置。根据 PSO 算法的式(2)和式(3)分别对单个粒子和种群最优粒子位置进行实时更新。

步骤 5: 终止条件判断。重复迭代, 直到满足终止条件, 将输出的超参数值代入 LSTM 模型进行预测。否则返回步骤 4。

PSO-LSTM 模型算法流程如图 3 所示。

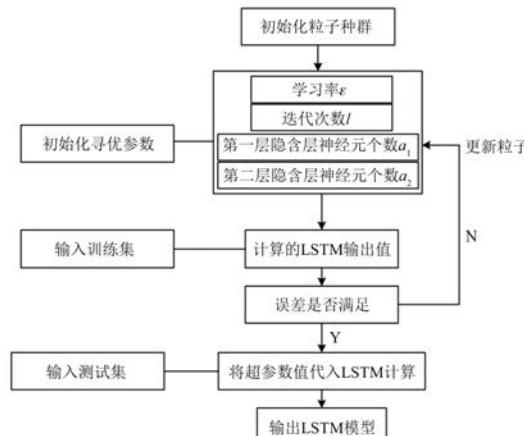


图 3 PSO-LSTM 模型算法流程

2 基于二层分解-PSO-LSTM 的风电功率超短期预测模型

基于二层分解与 PSO-LSTM 组合预测超短期功率模型的算法整体流程如图 4 所示。

主要步骤如下。

(1) 获取原始风电功率数据, 采用二层分解技术分解分量, 即采用 FEEMD 算法将原始风电功率序列分解为 8 个 IMF 和余量 r ; 利用 VMD 将难以分析的高频 IMF1 分量进行二次分解。

(2) 结合 SE 与分量曲线综合评价, 将得到的分量进行重构。

(3) 通过 PACF 计算与建模, 采用 PACF 计

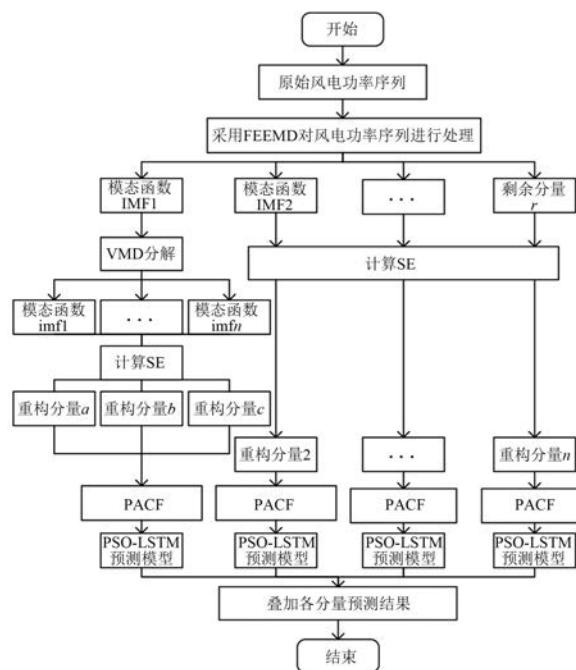


图 4 组合模型算法流程

算滞后阶数, 为每个 IMF 子序列确定输入神经元个数。

(4) 建立 PSO-LSTM 模型, 通过 PSO 对超参数进行寻优, 用寻优结果确定超参数代入 LSTM 中进行计算, 输出当前 IMF 分量的预测值。

(5) 叠加各个分量预测值得到最终预测结果, 通过多种指标对比分析来评估预测模型的预测性能。

3 试验与结果分析

以西班牙某一风电场实际采集的数据为算例, 选取 2020 年 1 月 2—11 日的数据, 风电功率的采样间隔为 10 min, 一共 1 440 个数据。将前 9 天的数据共 1 296 个点作为模型的训练集, 最后 144 个数据作为预测对比数据。

3.1 数据预处理及误差评价

设原始的负荷数据为 x , 数据中的最大值是 x_{\max} , 最小值是 x_{\min} , 把原始数据归一化, 使寻优过程变得平缓, 得到较快的收敛归一化后的数据表示为

$$\hat{x} = \frac{(x - x_{\min})}{(x_{\max} - x_{\min})} \quad (4)$$

将平均绝对误差(MAE)、平均绝对百分比误差(MAPE)和均方根误差(RMSE), 作为风电功率

预测模型的评价标准。计算表达式如下

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (5)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \times 100\% \quad (6)$$

$$RMSE = \sqrt{\left[\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \right]} \quad (7)$$

式中: Y_i 为真实值; \hat{Y}_i 为预测值。

3.2 二层分解

3.2.1 FEEMD 结果

将风电场实测风电功率数据进行分解, 基于 FEEMD 分解的计算结果如图 5 所示, 即 IMF1 ~ IMF8。由图 5 可看出 FEEMD 分解结果未发生模态混叠现象, 把模态分量按高频到低频进行分布, 不同频率的分量表征了风电功率变化的细节趋势。

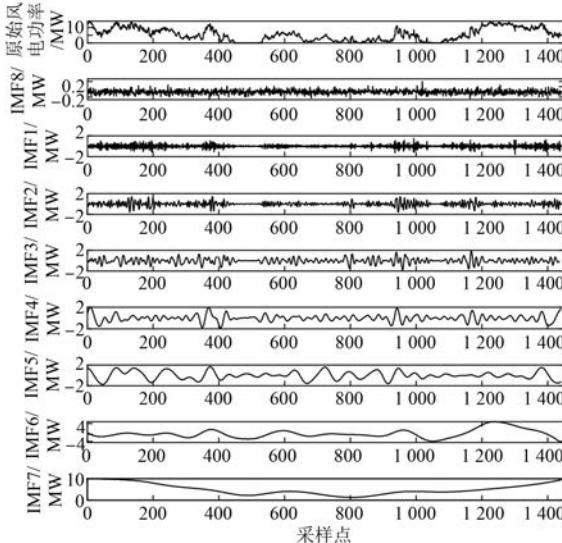


图 5 风电功率原始序列及 FEEMD 分解曲线

3.2.2 VMD 结果

对 IMF1 采用 VMD 二次分解, 利用 VMD 的特性将 IMF1 进行分解, 得到 6 个不同带宽的子模式, 即图 6 中 imf1 ~ imf6。

3.2.3 SE 重构

计算各 IMF 分量的 SE 样本熵值结果如图 7 所示。考虑到 SE 值的大小同时兼顾分解结果, 合并情况如表 1 与表 2 所示。

表 1 FEEMD 重构分量结果

重构分量	RIMF1	RIMF2	RIMF3	RIMF4
原始分量	IMF1	IMF2~IMF3	IMF4~IMF5	IMF6~IMF8

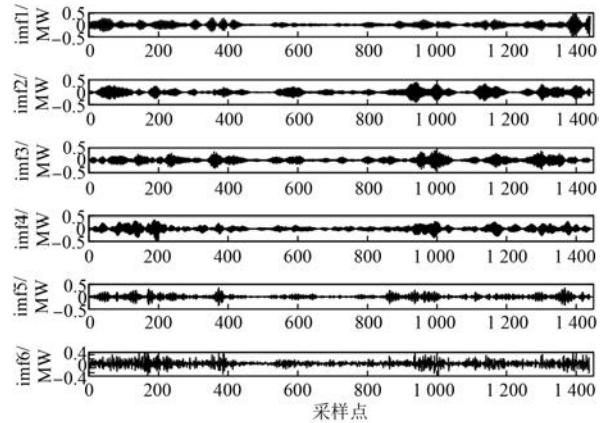


图 6 VMD 分解结果

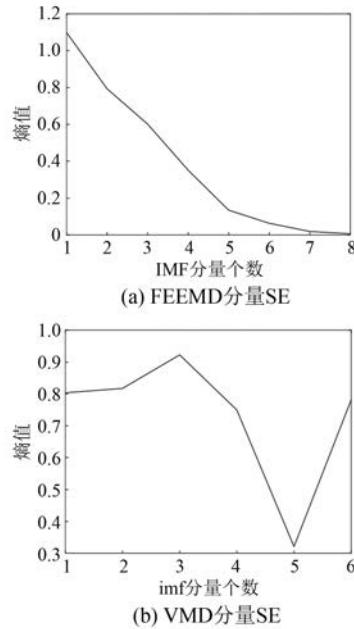


图 7 各分量对应的熵值

表 2 VMD 重构分量结果

重构分量	Rimf1	Rimf2	Rimf3
原始分量	imf1~imf6	imf2~imf4	imf5

3.3 输入个数的选取

利用 PACF 可计算序列与其自身经过某些阶数滞后形成的序列之间存在某种程度的相关性, 比较一组数据中前后 2 个元素与第 3 个随机元素相关的程度。

对 FEEMD 的重构分量采用 PACF 选取模型的输入变量个数, 结果如图 8 和表 3 所示。图 8 显示沿 x 轴的延迟值 $x_{t-\tau}$ 以及 y 轴上的相关性 ($-1 \sim 1$ 之间)。默认情况下, 横虚线为 95% 置信

区间边界,统计出当 PACF 值超过置信区间对应的阶数,从而将这一数值确定为模型的输入变量个数。

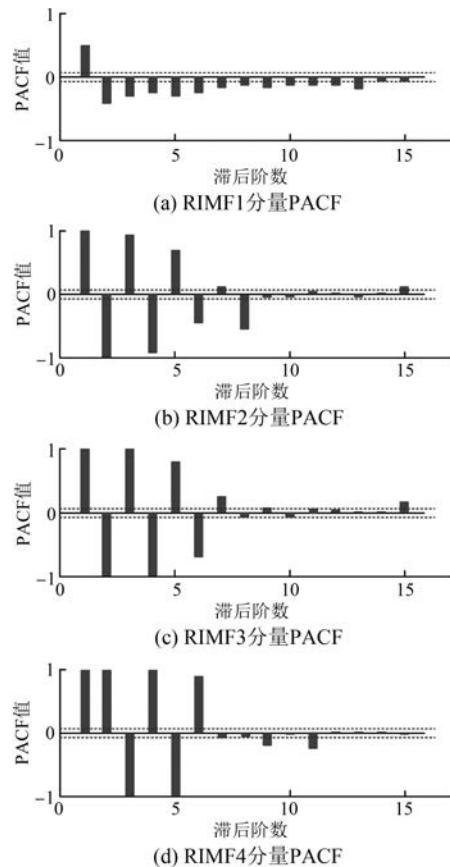


图 8 重构分量偏自相关图

表 3 输入变量选择结果

分量	RIMF1	RIMF2	RIMF3	RIMF4
输入个数	13	8	10	9

在本算例中,对各个 IMF 分量结果,用 PACF 来分析每个 IMF 中数据之间的相关性,继而选择模型的最优输入,参照表 3 确定了分量输入的个数。VMD 分解的高频分量在模型中的输入个数遵循 RIMF1。

3.4 试验结果分析

试验采用 Python3.6 编程语言,LSTM 模型由 Tensorflow 框架实现,构建 4 层 LSTM 的网络,包括输入层和 2 层隐藏层,最后是输出层。损失函数使用均方根误差,输出维数设为 1。PSO-LSTM 模型中设置 PSO 迭代次数取 10,种群规模取 5,每个分量输入 PSO-LSTM 模型中迭代次数、学习

率及隐藏层粒子群个数由粒子群计算误差损失情况直接确定。构建了 4 种不同的预测模型,具体结果如图 9 所示。各模型的误差如表 4 所示。

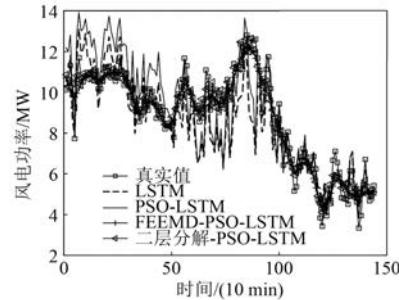


图 9 各模型预测结果对比

表 4 各预测模型误差

模型	MAPE/%	RMSE	MAE
LSTM	12.260	1.385	1.075
PSO-LSTM	11.830	1.372	1.070
FEEMD-PSO-LSTM	6.815	0.669	0.523
二层分解-PSO-LSTM	5.360	0.524	0.486

由表 4 可知,PSO-LSTM、FEEMD-PSO-LSTM 和二层分解-PSO-LSTM 模型比 LSTM 单一模型,预测结果的 MAPE 分别降低了 0.43、5.45 和 6.9 个百分点, RMSE 分别降低了 0.94%、51.70% 和 62.17%, MAE 分别降低了 0.47%、51.35% 和 54.79%。4 种模型的预测结果基本符合实际值的变化曲线,而其中二层分解-PSO-LSTM 模型在数据集中各个评价指标上均优于其他 3 个模型,整体提高了预测模型的预测精度与泛化性。

4 结语

本文针对风电功率的非线性、非平稳性和时间依赖性,通过对风电功率 FEEMD 分解结果的物理意义思考,从不同分解方法对模式分解的理解不同角度,对复杂波动的高频分量采用 VMD 进行二次分解,提高了输入分量的平稳性。并采用 SE 来衡量时间序列的复杂性,为 FEEMD 分解的分量重构提供了有力依据。利用 LSTM 在更长的序列中有更好的表现,构建 PSO-LSTM 预测模型,运用 PSO 算法对 LSTM 模型的参数进行超参数寻优,省去人工调参。试验证明,与其他模型相比,二层分解-PSO-LSTM 模型可获得较高的预测精度。

【参考文献】

- [1] 张文秀,武新芳,陆豪乾. 风电功率预测技术综述与改进建议[J]. 电力与能源,2014,35(4):436.
- [2] 冯双磊,王伟胜,刘纯,等. 风电场功率预测物理方法研究[J]. 中国电机工程学报,2010,30(2):1.
- [3] AMIRKHANI S, NASIRIVATAN S H, KASAEIAN A B, et al. ANN and ANFIS models to predict the performance of solar chimney power plants [J]. Renewable Energy,2015,83:597.
- [4] 马国旗,陈心远. 基于 ARIMA 的风电功率预测[J]. 信息系统工程,2012(8):89.
- [5] 赵攀,戴义平,夏俊荣,等. 卡尔曼滤波修正的风电场短期功率预测模型[J]. 西安交通大学学报,2011,45(5):47.
- [6] 周斌,文亮,杨力,等. BP 神经网络在风电功率预测中的应用[J]. 宜宾学院学报,2012,12(6):30.
- [7] 彭怀午,杨晓峰,刘方锐. 基于 SVM 方法的风电场短期风速预测[J]. 电网与清洁能源,2009,25(7):48.
- [8] 冯桂玲. 基于小波变换和 BP 神经网络的时序风电功率预测[J]. 电力大数据,2019,22(4):30.
- [9] 张江昆,常太华,孟洪民,等. 基于 ARIMA 与 Elman 神经网络的短期风速组合预测方法[J]. 电子世界,2013(18):79.
- [10] 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.
- [11] LIU H, TIAN H, LI Y. Comparison of new hybrid FEEMD-MLP, FEEMD-ANFIS, wavelet packet-MLP and wavelet packet-ANFIS for wind speed predictions [J]. Energy Conversion and Management,2015,89:1.
- [12] 殷豪,曾云,黄圣权,等. 二层分解技术在电价预测中的应用研究[J]. 计算机应用研究,2019,36(4):1101.
- [13] LIU H, TIAN H, LIANG X, et al. Wind speed forecasting approach using secondary decomposition algorithm and Elman neural networks [J]. Applied Energy,2015,157:183.
- [14] 彭秀艳,张彪. 基于 EMD-PSO-LSTM 组合模型的船舶运动姿态预测[J]. 中国惯性技术学报,2019,27(4):421.
- [15] 刘强,胡志强,周宇,等. 基于 CEEMD 和随机森林算法的短期风电功率预测[J]. 智慧电力,2019,47(6):71.
- [16] 谢赤,郑林林,孙柏,等. 基于 EMD 和 Elman 网络的人民币汇率时间序列预测[J]. 湖南大学学报(自然科学版),2009,36(6):89.
- [17] 叶敏. 基于经验模态分解和神经网络的人体姿势识别技术研究[D]. 北京:北京邮电大学,2018.
- [18] KANG A, TAN Q, YUAN X, et al. Short-term wind speed prediction using EEMD-LSSVM model [J]. Advances in Meteorology,2017,2017: 6856139.
- [19] 徐圆,张伟,张明卿,等. 基于 FEEMD-AE 与反馈极限学习机组合模型预测研究与应用[J]. 化工学报,2018,69(3):1064.
- [20] 邢恩恺. 基于改进 VMD 预处理与双向 LSTM 的风功率预测研究[D]. 吉林:东北电力大学,2019.
- [21] 权波,杨博辰,胡可奇,等. 基于 LSTM 的船舶航迹预测模型[J]. 计算机科学,2018,45(增刊2):126.
- [22] DENG X, SHAO H, HU C, et al. Wind power forecasting methods based on deep learning: a survey [J]. Computer Modeling in Engineering & Sciences,2020,122(1): 273.
- [23] 纪震,廖惠连,吴青华. 粒子群算法及应用[M]. 北京:科学出版社,2009.
- [24] 宋刚,张云峰,包劳勋,等. 基于粒子群优化 LSTM 的股票预测模型[J]. 北京航空航天大学学报,2019,45(12):2533.
- [25] 刘博. 基于 PSO-LSTM 算法的短期电力负荷预测应用研究[D]. 长春:吉林大学,2020.

~~~~~

欢迎订阅 2021 年《电机与控制应用》

联系地址: 上海市武宁路 505 号《电机与控制应用》编辑部

邮编: 200063

电话: 021-62574990-462

邮箱: eec@seari.com.cn

国内邮发代号: 4-199

每册定价: 12.00 元

全年定价: 144.00 元