

基于 CEEMDAN 与回声状态网络的风速预测方法

韩宏志¹, 唐振浩²

(1. 新疆新能集团有限责任公司乌鲁木齐电力建设调试所, 新疆 乌鲁木齐 830001;

2. 东北电力大学自动化工程学院, 吉林 吉林 132012)

摘要: 为了对风速进行准确预测, 结合分类与回归树(Classification and Regression Tree, CART)、自适应噪声完备集成经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN)、回声状态网络与非线性误差修正策略, 提出了一种基于回声状态网络(Echo State Network, ESN)的混合期风速预测方法。其中, CART 用于对原始数据进行重构, 得到建模数据集。CEEMDAN 用于提取输入特征信息。ESN 根据输入特征建立风速预测建模。最后, 利用误差修正策略对所得到的模型进行修正。基于国内某风电场的实验数据表明, 所提出方法能够准确预测风速, 可以指导风场生产, 提高生产自动化水平。

关键词: 风速预测; 回声状态网络; CEEMDAN; CART; 预测值修正

Wind speed prediction method based on CEEMDAN and echo state network

HAN Hongzhi¹, TANG Zhenhao²

(1. Xinjiang Xinneng Group Co., Ltd. Urumqi Electric Power Construction Debugging Institute, Urumqi 830001, China;

2. School of Automation Engineering, Northeast Electric Power University, Jilin 132012, China)

Abstract: In order to predict wind speed accurately, this paper combines CART, CEEMDAN, echo state network and error correction strategy to propose a short-term wind speed prediction method with a multi-processing strategy. CART is applied to reconstruct the original dataset to get the training data. CEEMDAN is employed to extract the feature information. Then, ESN is used to model the wind speed based on the features. Finally, the model is modified by an error correction strategy. The proposed method can predict wind speed accurately, guide the production of a wind farm and improve the automation level of production.

This work is supported by National Key Research and Development Program of China (No. 2018YFB1500803).

Key words: wind speed prediction; echo state network; CEEMDAN; CART; prediction value correction

0 引言

风电具有清洁性、可再生性的特点, 其装机容量得到了快速发展。全球风能理事会发布的风电报告显示, 2018 年全球风电新增装机容量达到了 51.3 GW, 同比增长 7%^[1]。然而由于风能的间歇性、不稳定性与随机性, 给风机高效控制带来很大挑战^[2-4]。风机的发电量主要由风速决定, 因此, 准确的风速预测对于风能预测、风电并网调控等都至关重要^[5-7]。

风速预测方法主要分为三类: 物理建模、统计学模型与人工智能模型。物理模型^[8-10]主要利用数

值天气预报数据, 通过建立风速与气压、空气密度、空气湿度等的关系表达式, 完成对风速的预测。由于风速本身的复杂性与地区差异, 难以建立适用于不同地区的高精度短期预测。因此, 物理模型通常用于特定地区的长期风速预测。

相较于物理模型, 统计学模型在建模时间与精度上均表现的更为出色。因此, 统计学模型被广泛地应用于短期风速预测中。文献[11]利用自回归移动平均(Auto Regressive and Moving Average, ARMA)模型, 对风速进行预测; 文献[12]综合多元季节时变阈值自回归模型与阈值季节性自回归条件异方差模型, 设计了混合模型对风速与气压进行联合预测。然而, 由于风速具有强非线性特点, 统计

学模型的预测精度仍有较大的改进空间。随着机器学习算法的不断进步, 人工智能模型得到了广泛的应用^[13]。文献[14]利用最小二乘支持向量机对风速进行预测, 所获得模型的精度明显高于 ARMA 等统计学模型, 取得较好的短期预测结果。文献[15]利用回声状态网络(Echo State Network, ESN)对风速进行预测, 其精度要高于普通前馈或反馈神经网络。因此, 在已有基础上, 本文选择了精度较高、训练速度较快的回声状态网络, 作为所提出的综合预测算法的基础预测模型。

除了建模算法的选取, 模型训练数据集的构造和数据信息的提取也对预测精度有显著的影响。有研究表明, 对数据分解、提取原始数据的有效信息, 能够提高模型的预测精度^[16-17]。文献[18]利用小波变换对风速数据进行分解建模; 文献[19]利用集成经验模态分解对风速数据进行分解, 利用小波神经网络对分解数据进行建模; 文献[20-21]利用自适应完全集成经验模态分解算法对风速数据进行分解, 这些研究说明通过信号分解提取原始数据的有效信息对预测模型精度有很大提升。因此, 在权衡上述信号分解算法的基础上, 利用 CEEMDAN 算法作为 ESN 网络输入处理算法, 对输入信号进行特征分解与信息提取。

综上, 研究提出一种结合分类与回归树(Classification and Regression Tree, CART)特征选择、自适应噪声完备集成经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN)与回声状态网络的风速预测方法。首先, 利用 CART 对输入数据维度进行特征选择; 然后, 利用 CEEMDAN 分解对输入风速序列进行特征信息提取, 以提取输入序列的时频域信息; 利用回声状态网络对输入信息进行建模, ESN 建模后, LSSVM 对 ESN 建模结果进行误差修正, 得到更加准确的预测结果。最后, 研究利用实际风电场数据进行实验, 以对模型精度进行验证。

1 基于 CART 的建模数据重构

将经过数据预处理的数据进行数据重构, 构成历史时刻风速输入-未来时刻风速输出数据对, 是进行风速预测的基础。选取历史时刻风速序列的长度, 即风速嵌入维数, 对于模型的精度至关重要。研究采用 CART 算法对前 20 时刻的历史风速序列对未来时刻风速序列的重要性分别进行计算, 然后根据计算结果对嵌入维数进行选择。

分类回归树(CART)^[22-23]是一种典型的非参数

二叉树分类器, 用于对输入数据嵌入维数进行选择。CART 算法通过计算不同时刻的历史风速 x_{t-i} 与未来时刻风速 x_t 之间的 Gini 指数, 进而计算 x_{t-i} 对 x_t 的重要性并进行排序, 通过设定重要性阈值, 来对输入嵌入维数进行选择。为了分析每个历史时刻风速对未来时刻风速的影响, 利用式(1)计算预测变量重要性。

$$I(a_i) = \sum_{t=1}^T \frac{N_t}{N_{\text{CART}}} \Delta \text{Gini}(z(a_j, t)) \quad (1)$$

式中: $\text{Gini}(z(a_j, t))$ 代表第 t 个内部节点的第 j 个属性的 Gini 指数; N_{CART} 指总观测数; N_t 代表在第 t 个内部节点的观测数。

针对风速预测输入嵌入维数的选择问题, 经过 CART 计算的前 20 时刻历史风速序列重要性排序如图 1 所示。

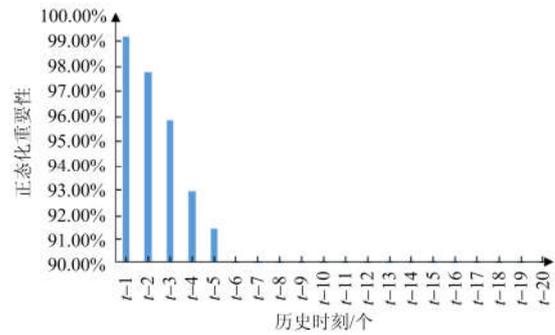


图 1 输入重要性分析结果

Fig. 1 Results of input importance

在兼顾建模精度等级与效率的前提下, 研究选择重要性大于 90% 的前 5 时刻作为历史风速的长度, 即风速预测模型的嵌入维数为 5, 如图 1 所示。

2 原始信号分解与信息提取

选定输入风速输入维度后, 利用分解算法对输入风速进行分解能够提高模型预测精度。研究选用自适应完备噪声集成经验模态分解, 对输入风速序列分别进行分解, 提取输入序列的趋势信息。

CEEMDAN 算法是由 Torres M E 等^[24-26]于 2011 年提出的一种新型信号分解算法, 较好地解决了经验模态分解存在的模态混叠现象。CEEMDAN 算法的具体分解流程如图 2 所示。

步骤 1: 将待分解信号 $x(t)$ 添加 K 次均值为 0 的高斯白噪声, 构造共 K 次实验的待分解序列 $x_i(t) (i=1, 2, \dots, K)$ 。

$$x_i(t) = x(t) + \varepsilon \delta_i(t) \quad (2)$$

式中: ε 为高斯白噪声权值系数; $\delta_i(t)$ 为第 i 次处理

时产生的高斯白噪声。

步骤 2: 对上述序列 $x_i(t)$ 进行 EMD 分解, 分解得到第 1 个模态分量(IMF)并取其均值作为 CEEMDAN 分解得到的第 1 个 IMF。

$$IMF_1(t) = \frac{1}{K} \sum_{i=1}^K IMF_1^i(t) \quad (3)$$

$$r_1(t) = x(t) - IMF_1(t) \quad (4)$$

式中: $IMF_1(t)$ 表示 CEEMDAN 分解得到的第 1 个模态分量; $IMF_1^i(t)$ 表示 $x_i(t)$ 进行 EMD 分解后得到的第 1 个 IMF; $r_1(t)$ 表示第 1 次分解后的余量信号。

步骤 3: 将分解后得到的第 j 阶段余量信号添加特定噪声后, 继续进行 EMD 分解。

$$IMF_j(t) = \frac{1}{K} \sum_{i=1}^K E_i(r_{j-1}(t) + \varepsilon_{j-1} E_{j-1}(\delta_i(t))) \quad (5)$$

$$r_j(t) = r_{j-1}(t) - IMF_j(t) \quad (6)$$

式中: $IMF_j(t)$ 表示 CEEMDAN 分解得到的第 j 个模态分量; $E_{j-1}(\cdot)$ 表示对序列进行 EMD 分解后的第 $j-1$ 个 IMF 分量; ε_{j-1} 表示 CEEMDAN 对第 $j-1$ 阶段余量信号加入噪声的权值系数; $r_j(t)$ 表示第 j 阶段余量信号。

步骤 4: 迭代停止, 如果满足 EMD 停止条件, 第 n 次分解的余量信号 $r_n(t)$ 为单调信号, 则迭代停止, CEEMDAN 算法分解结束。

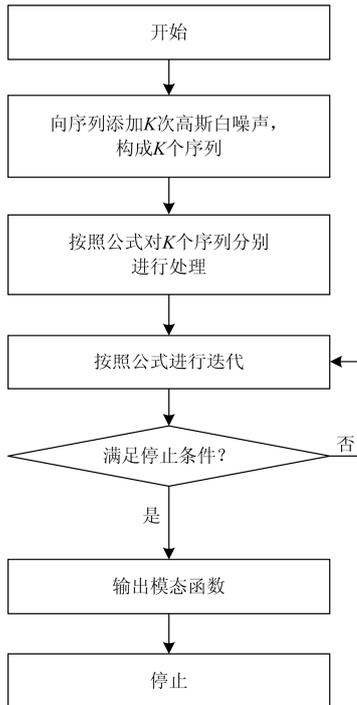


图 2 CEEMDAN 算法流程

Fig. 2 Flowchart of CEEMDAN

针对风速预测输入分解问题, 研究利用 CEEMDAN 算法, 将每一维输入序列分解为 6 维输入子模态, 如图 3 所示。

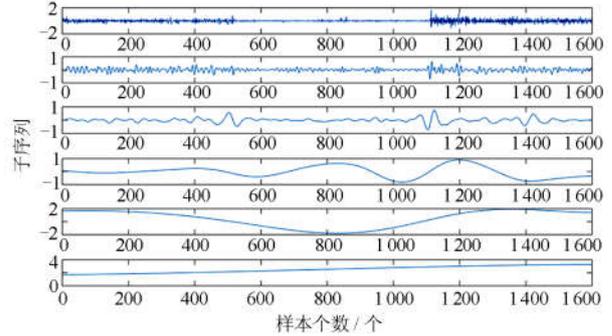


图 3 CEEMDAN 分解结果

Fig. 3 Results of CEEMDAN decomposition

3 回声状态网络(ESN)

回声状态网络是由 Jager^[27]提出的一种深度循环神经网络, 其以一种储备池来代替多层隐含层, 储备池包含了大量稀疏连接(包括自连接)的神经元。回声状态网络的网络结构如图 4 所示。

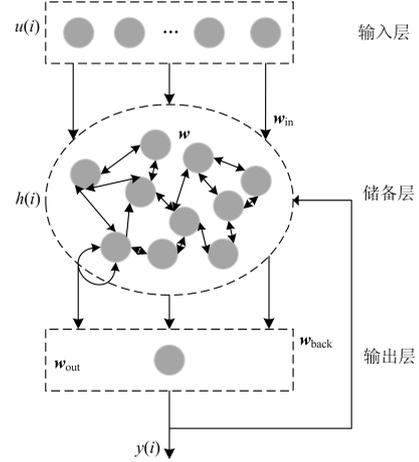


图 4 ESN 网络结构

Fig. 4 Structure of ESN

由图 4 可知, 回声状态网络输入层维度为 K , 储备池中含有 N 个隐含层神经元, 输出层中含有 L 个神经元。其中, $w_{in} (K \times N)$ 为输入层与储备池之间的权值连接矩阵; $w (N \times N)$ 为储备层的内部连接权值矩阵; $w_{back} (N \times L)$ 为从输出层到隐含层的反向连接矩阵; 这三个权值矩阵在训练开始就被设置完毕且在迭代的过程中不再更改; $w_{out} (L \times (K + N + L))$ 为储备池、输入层以及上一次迭代输出层到本次迭代输出层的连接权值矩阵, 迭代过程中主要对 w_{out} 进行更改, 进而完成对网络的训练。

在迭代过程中, 隐含层、输出层的更新公式如下。

$$h(i+1) = f(\mathbf{w}_{in} \cdot u(i+1) + \mathbf{w} \cdot h(i) + \mathbf{w}_{back} \cdot y(i)) \quad (7)$$

$$y(i+1) = g(\mathbf{w}_{out} \cdot [u(i+1); h(i+1); y(i)]) \quad (8)$$

式中: $i=1, 2, \dots, I$ 为迭代次数; $u(i+1)$ 为第 $i+1$ 时刻的输入数据; $h(i)$ 为第 i 时刻的储备池输出; $y(i)$ 是第 i 时刻输出层输出; $f(\cdot)$ 为储备池神经元激活函数; $g(\cdot)$ 为输出层神经元激活函数。

4 基于 LSSVM 的误差修正策略

LSSVM 是基于 SVM^[28]提出的一种建模算法。相较于 SVM, LSSVM 从计算时间和建模精度上均有所提高。LSSVM 的线性回归函数^[14]如式(9)所示。

$$y(x) = \boldsymbol{\omega}^T \boldsymbol{\phi}(x) + b \quad (9)$$

式中: $\boldsymbol{\omega}$ 为权值向量; b 为偏置量; $\boldsymbol{\phi}(x)$ 是输入向量 x 的特征函数, 将 x 从低维空间转换至高维特征空间, 从而将低维空间的非线性回归问题转化为高维空间的线性回归。

基于结构风险最小化原理, LSSVM 的目标函数为

$$\begin{cases} \min J(\boldsymbol{\omega}, e) = \frac{1}{2} \boldsymbol{\omega}^T \boldsymbol{\omega} + \frac{1}{2} \gamma \sum_{i=1}^N e_i^2 \\ \text{s.t. } y_i = \boldsymbol{\omega}^T \boldsymbol{\phi}(x_i) + b + e_i \end{cases} \quad (10)$$

式中: γ 为正则化参数且 $\gamma > 0$; e_i 为误差变量; $\boldsymbol{\phi}(x_i)$ 为时间点 i 的真实输出与其拟合值的残差。

LSSVM 所建立的拉格朗日函数如式(11)所示。

$$L(\boldsymbol{\omega}, b, e, a) = J(\boldsymbol{\omega}, e) - a \sum_{i=1}^N (\boldsymbol{\omega}^T \boldsymbol{\phi}(x_i) + b + e_i - y_i) \quad (11)$$

式中, a 为保证约束条件严格成立的拉格朗日乘子。

经过对参数求偏导数与消除参数后, 式(11)可表示为

$$\begin{bmatrix} 0 & \mathbf{P}^T \\ \mathbf{P} & K(x_i, x_j) + \frac{1}{\gamma} \mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{Y} \end{bmatrix} \quad (12)$$

式中: $\mathbf{P} = [1, 1, 1, \dots, 1]^T$; $K(*)$ 为核函数, $K(x_i, x_j) = \boldsymbol{\phi}(x_i)^T \boldsymbol{\phi}(x_j)$ ($i, j = 1, 2, \dots, N$ 且 $i \neq j$); \mathbf{I} 为单位阵; $\mathbf{Y} = [y_1, y_2, \dots, y_N]$ 。

LSSVM 的预测函数为

$$\hat{y}(x) = \sum_{i=1}^N a_i K(x, x_i) + b \quad (13)$$

其中 a_i 、 b 可通过式(12)求出, 核函数 $K(*)$ 选择径向基函数。

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|_2^2}{2\sigma^2}\right) \quad (14)$$

式中, σ 为核函数宽度。

为了进一步提高所建立模型的精度, 研究设计一种 LSSVM 误差修正策略, 用于对所建立的 ESN 预测模型进行误差修正。LSSVM 的拟合目标为 DBN 预测模型的误差, 训练输入为 ESN 模型的训练输入, 输出则为 DBN 模型的训练误差。其核心是为了通过 LSSVM 对 ESN 预测模型的误差建立预测模型, 进而提高模型的预测精度。

基于 LSSVM 误差修正的 DBN 模型输出可以表示为

$$y_{pre} = y_{ESN} + y_{LSSVM} \quad (15)$$

式中: y_{pre} 为基于 LSSVM 修正的 ESN 预测模型输出; y_{ESN} 为 ESN 模型输出; y_{LSSVM} 为 LSSVM 修正模型的输出。

5 短期风向混合预测算法整体结构

结合前文所述第 1—第 4 节, 本文提出的 CEEMDAN-ESN 算法整体流程如下。

1) 针对输入的历史数据维度, 采用 CART 算法遴选适应输入维度, 保证在精度一定的前提下, 提高建模效率, 避免过拟合。

2) 选定输入维度后, 针对每一维输入数据, 采用 CEEMDAN 分别对其进行特征分解与信息提取, 构成子序列输入矩阵。

3) 针对子序列输入与对应输出, 利用回声状态网络进行拟合并预测。

4) ESN 完成预测后, 利用 LSSVM 对预测误差进行预测, 并将误差预测结果与前文的预测结果相加, 得到 CEEMDAN-ESN 算法的整体预测结果。

6 实验

为了验证所提出算法的有效性, 研究利用白城某风电场 2017 年风速数据进行实验。实验数据分为三组, 其中, 每组训练数据为 1 600 个, 测试数据为 400 个, 数据间隔为 2 min。为了对比验证模型精度, 研究采用 ARIMA、LSSVM、BP、ESN 作为对比算法进行实验。实验结果如图 5 所示, 其误差评价指标被列于表 1 中, 对比实验算法的参数设置如表 2 所示(其中, σ 为 LSSVM 模型的核参数, C 为 LSSVM 模型的惩罚因子)。

由表 1 结合图 5, 经研究可得以下结论。

1) CEEMDAN-ESN 与其他算法的对比

对于第一组实验, 在所有提出的模型实验中, CEEMDAN-ESN 具有最好的预测效果。其绝对平均百分比误差为 6.23%, 比预测表现次好的模型低了

17.5%；其绝对平均误差低于 0.8，而其他几种对比算法的绝对平均误差均高于 0.8%；其均方根误差也是所有模型试验中均方根误差唯一小于 1 的风速预测算法。

表 1 误差指标

Table 1 Error indicator

组号	评价指标	CEEMDA N-ESN	LSSVM	BP	ESN	ARIMA
第一组	MAPE	0.062	0.073	0.078	0.076	0.086
	MAE	0.727	0.855	0.906	0.897	1.005
	MSE	0.866	1.204	1.316	1.243	1.570
第二组	MAPE	0.070	0.106	0.095	0.109	0.121
	MAE	0.402	0.610	0.557	0.629	0.697
	MSE	0.246	0.587	0.479	0.612	0.794
第三组	MAPE	0.066	0.135	0.104	0.128	0.137
	MAE	0.331	0.640	0.514	0.652	0.686
	MSE	0.168	0.628	0.428	0.671	0.710

表 2 对比模型参数(阶数)设置

Table 2 Parameters (orders) of the comparative model

模型	ARIMA	LSSVM	BP	ESN
阶数设置	2-1-2	—	30-18-1	30-70-1
参数设置	—	$\sigma = 2.47$ $C = 1.83$	—	—

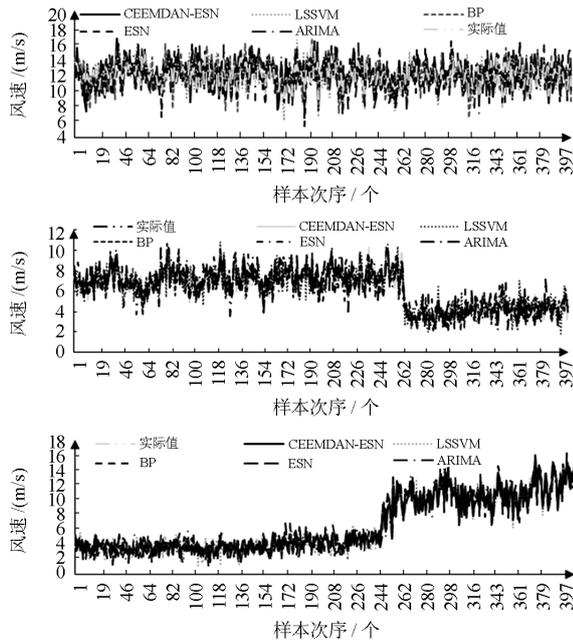


图 5 实验结果图

Fig. 5 Results of experiment

对于第二组实验，在所有提出的模型实验中，CEEMDAN-ESN 具有最好的预测效果，其绝对平均百分比误差为 6.99%，比预测表现次好的模型低了 36.5%；其绝对平均误差低于 0.41，而其他几种对

比算法的绝对平均误差均高于 0.55；其均方根误差也是所有模型试验中均方根误差最小的风速预测算法。

对于第三组实验，在所有提出的模型实验中，CEEMDAN-ESN 具有最好的预测效果。其绝对平均百分比误差为 6.61%，比预测表现次好的模型低了 36.7%；其绝对平均误差低于 0.34，而其他几种对比算法的绝对平均误差均高于 0.51；其均方根误差也是所有模型试验中均方根误差最小的风速预测算法。

2) CEEMDAN 分解算法特性对比

对于第一组实验，在采用 CEEMDAN 进行分解提取后，其输入的平均绝对百分比误差比未进行 CEEMDAN 分解算法的平均绝对百分比误差降低了 18.3%。

对于第二组实验，在采用 CEEMDAN 进行分解提取后，其输入的平均绝对百分比误差比未进行 CEEMDAN 分解算法的平均绝对百分比误差降低了 35.6%。

对于第一组实验，在采用 CEEMDAN 进行分解提取后，其输入的平均绝对百分比误差比未进行 CEEMDAN 分解算法的平均绝对百分比误差降低了 48.1%。

3) LSSVM 算法修正前后对比

由表 3 可知：针对第一组实验，经过 LSSVM 误差修正后，CEEMDAN-ESN 算法精度较修正之前，其 MAPE 降低了 14.2%；MAE 降低了 9.60%；MSE 降低了 13.59%；基于三项误差指标的数据表明，LSSVM 误差修正方法针对第一组实验具有良好的精度提升。

表 3 修正前后误差指标

Table 3 Error indicator before and after self-correcting

组号	评价指标	修正后	修正前
第一组	MAPE	0.062	0.073
	MAE	0.727	0.804
	MSE	0.866	1.002
第二组	MAPE	0.070	0.083
	MAE	0.402	0.535
	MSE	0.246	0.391
第三组	MAPE	0.066	0.092
	MAE	0.331	0.455
	MSE	0.168	0.403

针对第二组实验，经过 LSSVM 误差修正后，CEEMDAN-ESN 算法精度较修正之前，其 MAPE 降低了 15.8%；MAE 降低了 24.8%；MSE 降低了

37.1%；基于三项误差指标的数据表明，LSSVM 误差修正方法针对第二组实验具有良好的精度提升。

针对第三组实验，经过 LSSVM 误差修正后，CEEMDAN-ESN 算法精度较修正之前，其 *MAPE* 降低了 28.4%；*MAE* 降低了 27.24%；*MSE* 降低了 58.2%；基于三项误差指标的数据表明，LSSVM 误差修正方法针对第三组实验效果也很明显。

综上所述，对于风速预测问题，文中提出的所有算法中，CEEMDAN-ESN 具有最高的精度以及稳定性。

7 结论

准确的风速预测是保证风能高效利用、安全利用的基础。针对风速预测问题，研究提出了一种综合预测算法。为了提高模型计算效率，算法利用 CART 筛选输入，在保证精度同时降低建模时间。为了提取原始信号中的深层时频信息，利用 CEEMDAN 提取风速输入中包含的特征信息。最后，综合开发了基于回声状态网络和 LSSVM 的预测模型。以国内某一风电场的实际生产数据为基础，将所提模型在不同数据集集中进行测试，所提算法能够准确预测风速，由于其他对比算法，能够满足实际生产需求。下一步将继续在算法结构设计和算法验证方面开展相关研究。

参考文献

- [1] QU Z, ZHANG K, MAO W, et al. Research and application of ensemble forecasting based on a novel multi-objective optimization algorithm for wind-speed forecasting[J]. *Energy Conversion and Management*, 2017, 154(8): 440-454.
- [2] 琚垚, 祁林, 刘帅. 基于改进乌鸦算法和 ESN 神经网络的短期风电功率预测[J]. *电力系统保护与控制*, 2019, 47(4): 58-64.
JU Yao, QI Lin, LIU Shuai. Short-term wind power forecasting based on improved crow search algorithm and ESN neural network[J]. *Power System Protection and Control*, 2019, 47(4): 58-64.
- [3] 吴宇杭, 温步瀛, 江岳文. 基于变分模式分解和深度门控循环网络的风速短期预测模型[J]. *电网与清洁能源*, 2018, 34(12): 59-64, 70.
WU Yuhang, WEN Buying, JIANG Yuewen. Short-term wind speed prediction based on VMD and deep GRU network[J]. *Power System and Clean Energy*, 2018, 34(12): 59-64, 70.
- [4] SONG D, YANG J, FAN X, et al. Maximum power extraction for wind turbines through a novel yaw control solution using predicted wind directions[J]. *Energy Conversion and Management*, 2018, 157: 587-599.
- [5] BAO L, GNEITING T, GRIMIT E P, et al. Bias correction and Bayesian model averaging for ensemble forecasts of surface wind direction[J]. *Monthly Weather Review*, 2010, 138(5): 1811-1821.
- [6] 吴忠强, 贾文静, 吴昌韩, 等. 基于 PSO-BSNN 的短期风速预测[J]. *电力系统保护与控制*, 2015, 43(15): 36-41.
WU Zhongqiang, JIA Wenjing, WU Changhan, et al. Short-term wind speed forecasting based on PSO-BSNN[J]. *Power System Protection and Control*, 2015, 43(15): 36-41.
- [7] 赵征, 王晓亮, 张亚刚. 基于 ARMA-ARCH 模型和 BP 模型的短期风速组合预测方法研究[J]. *电网与清洁能源*, 2018, 34(11): 45-51.
ZHAO Zheng, WANG Xiaoliang, ZHANG Yagang. Short-term wind speed combined prediction based on ARMA-ARCH model and BP model[J]. *Power System and Clean Energy*, 2018, 34(11): 45-51.
- [8] 符杨, 郑紫宸, 时帅, 等. 考虑气象相似性与数值天气预报修正的海上风功率预测[J]. *电网技术*, 2019, 43(4): 1253-1260.
FU Yang, ZHENG Zichen, SHI Shuai, et al. Offshore wind power forecasting considering meteorological similarity and NWP correction[J]. *Power System Technology*, 2019, 43(4): 1253-1260.
- [9] CHENG Y Y, LIU Y B, BOURGEOIS A J, et al. Short-term wind forecast of a data assimilation/weather forecasting system with wind turbine anemometer measurement assimilation[J]. *Renewable Energy*, 2017, 107: 340-351.
- [10] SOMAN S S, ZAREIPOUR H, MALIK O, MANDAL P. A review of wind power and wind speed forecasting methods with different time horizons[J]. *North American Power Symposium*, September 26-28, 2010, Arlington, TX, USA: 1-8.
- [11] ERDEM E, SHI J. ARMA based approaches for forecasting the tuple of wind speed and direction[J]. *Applied Energy*, 2011, 88(4): 1405-1414.
- [12] AMBACH D, SCHMID W. A new high-dimensional time series approach for wind speed, wind direction and air pressure forecasting[J]. *Energy*, 2017, 135: 833-850.
- [13] TANG Z, ZHANG Z. The multi-objective optimization of combustion system operations based on deep data-driven models[J]. *Energy*, 2019, 182: 37-47.
- [14] ZHOU J, SHI J, LI G. Fine tuning support vector machines for short-term wind speed forecasting[J].

- Energy Conversion and Management, 2011, 52(4): 1990-1998.
- [15] AMIN C M, SAMI F M, TRZYNADLOWSKI A M. Wind speed and wind direction forecasting using echo state network with nonlinear functions[J]. Renewable Energy, 2019, 131: 879-889.
- [16] 王静, 李维德. 基于 CEEMD 和 GWO 的超短期风速预测[J]. 电力系统保护与控制, 2018, 46(9): 69-74.
WANG Jing, LI Weide. Wind speed forecasting based on complementary ensemble empirical mode decomposition and support vector regression optimized by membrane computing optimization[J]. Power System Protection and Control, 2018, 46(9): 69-74.
- [17] 杨茂, 张罗宾. 基于数据驱动的超短期风电功率预测综述[J]. 电力系统保护与控制, 2019, 47(13): 171-186.
YANG Mao, ZHANG Luobin. Review on ultra-short term wind power forecasting based on data-driven approach[J]. Power System Protection and Control, 2019, 47(13): 171-186.
- [18] 刘建华, 李锦程, 杨龙月. 基于 EMD-SLSTM 的家庭短期负荷预测[J]. 电力系统保护与控制, 2019, 47(6): 40-47.
LIU Jianhua, LI Jincheng, YANG Longyue. Short-term household load forecasting based on EMD-SLSTM[J]. Power System Protection and Control, 2019, 47(6): 40-47.
- [19] SANTHOSH M, VENKAIAH C, KUMAR D M V. Ensemble empirical mode decomposition based adaptive wavelet neural network method for wind speed prediction[J]. Energy Conversion and Management, 2018, 168: 482-493.
- [20] ZHANG W, QU Z, ZHANG K, et al. A combined model based on CEEMDAN and modified flower pollination algorithm for wind speed forecasting[J]. Energy Conversion and Management, 2017, 136: 439-451.
- [21] PENG T, ZHOU J, ZHANG C, et al. Multi-step ahead wind speed forecasting using a hybrid model based on two-stage decomposition technique and AdaBoost-extreme learning machine[J]. Energy Conversion and Management, 2017, 153: 589-602.
- [22] 黄南天, 彭华, 蔡国伟, 等. 电能质量复合扰动特征选择与最优决策树构建[J]. 中国电机工程学报, 2017, 37(3): 776-786.
- HUANG Nantian, PENG Hua, CAI Guowei, et al. Feature selection and optimal decision tree construction of complex power quality disturbances[J]. Proceedings of the CSEE, 2017, 37(3): 776-786.
- [23] 林湘宁, 卓毅鑫, 李正天, 等. 基于风电场动态电压安全决策树体系的 SVC 紧急控制策略[J]. 中国电机工程学报, 2018, 38(1): 41-50, 341.
LIN Xiangning, ZHUO Yixin, LI Zhengtian, et al. Wind farm SVC emergency control strategy based on dynamic voltage security decision trees[J]. Proceedings of the CSEE, 2018, 38(1): 41-50, 341.
- [24] TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise[C] // 2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), May 22-27, 2011, Prague, Czech Republic: 4144-4147.
- [25] LIU Hui, MI Xiwei, LI Yanfei. Smart multi-step deep learning model for wind speed forecasting based on variational mode decomposition, singular spectrum analysis, LSTM network and ELM[J]. Energy Conversion and Management, 2018, 159: 54-64.
- [26] LIANG Z, LIANG J, WANG C, et al. Short-term wind power combined forecasting based on error forecast correction[J]. Energy Conversion and Management, 2016, 119: 215-226.
- [27] JAEGER H, HAAS H. Harnessing nonlinearity: predicting chaotic systems and saving energy in wireless communication[J]. Science, 2004, 304(5667): 78-80.
- [28] MOHANDAS M A, HALAWANI T O, REHMAN S. Support vector machines for wind speed prediction[J]. Renewable Energy, 2004, 29: 939-947.

收稿日期: 2019-07-31; 修回日期: 2019-11-01

作者简介:

韩宏志(1985—), 男, 通信作者, 硕士, 工程师, 研究方向为新能源建模预测; E-mail: hanhongzhi@xj.dky.sgcc.com.cn

唐振浩(1985—), 男, 博士, 副教授, 研究方向为智能建模方法及其在新能源方向的应用。

(编辑 许威)