

基于 EEMD-GRU 网络模型的短期风速预测^①



杨 芮, 徐 虹, 文 武

(成都信息工程大学 计算机学院, 成都 610225)

通信作者: 徐 虹, E-mail: xuhong@cuit.edu.cn

摘 要: 为了克服因风速信号固有的震动性、非线性特性引起的预测精度不高的问题, 本文提出了使用集合经验模态分解算法和门控循环单元两种方法相结合的组合模型对风速进行预测. 该模型首先对数据进行归一化处理, 使用孤立森林算法, 剔除异常点, 然后用 EEMD (ensemble empirical mode decomposition) 方法, 将风速拆分成不同尺度的信号, 消除数据的非平稳性, 将分解得到的相对平稳的分量信号分别送入 GRU (gated recurrent unit) 模型进行训练, 获得各自的预测结果, 最终风速由所有分量各自预测的结果累加得到. 实验中采用实地采集数据进行实验, 结果证实, EEMD-GRU 方法相较于目前主流的 EEMD-LSTM、EMD-LSTM 等方法, 预测精度有明显提升.

关键词: 风速预测; EEMD; GRU; 分解; 组合预测模型

引用格式: 杨芮, 徐虹, 文武. 基于 EEMD-GRU 网络模型的短期风速预测. 计算机系统应用, 2022, 31(6): 231-237. <http://www.c-s-a.org.cn/1003-3254/8538.html>

Short-term Wind Speed Prediction Based on EEMD-GRU Network Model

YANG Rui, XU Hong, WEN Wu

(School of Computer Science, Chengdu University of Information Technology, Chengdu 610225, China)

Abstract: For the low prediction accuracy caused by the inherent vibration and nonlinear characteristics of wind speed signal, a combined model of the ensemble empirical mode decomposition (EEMD) and the gated recurrent unit (GRU) is proposed to predict the wind speed. Firstly, the model normalizes the data and removes outliers by isolated forest. The wind speed is then resolved into signals of different scales by EEMD to obtain stable component signals with the non-stationary data removed. The component signals are trained by the GRU model, from which the predictions are accumulated to obtain the final wind speed. The data collected in the field are applied for the experiment. The results show that the EEMD-GRU method has a significant improvement in the prediction accuracy compared with the dominated EEMD-LSTM and EMD-LSTM methods.

Key words: wind speed prediction; ensemble empirical mode decomposition (EEMD); gated recurrent unit (GRU); decomposition; combined forecasting model

化石燃料正处在耗尽的边缘, 世界各国都意识到开发和利用可再生的清洁能源才是持久之道^[1]. 目前, 可再生能源发电形式有很多, 风电是所有方法中最成熟的一种, 将风电大规模加入到电网中, 可以大大减轻社会的能源负担^[2]. 对短期风电功率的准确预测, 不但

能够节约电网运行的本钱, 同时使电网系统可靠性更上一层楼^[3]. 风速的短期预测, 能够在一定程度上为电网调度提供参考, 是现代风电场以及电网运行和维护中不可缺少的一大助力.

早期的风速预测, 物理方法占据了半壁江山, 另一

① 收稿时间: 2021-09-09; 修改时间: 2021-10-14; 采用时间: 2021-10-25; csa 在线出版时间: 2022-05-26

半为统计学方法. 物理方法需要采集大量的风机及天气信息, 利用数学表达式计算出风速预测值, 由于数据量庞大, 需要使用高性能计算机进行运算, 预测难度和经费预算都比较大; 统计学方法需根据历史信息建立模型, 预测精度受样本量限制, 样本量越大, 预测精度越高. 统计学方法擅长处理线性数据, 而风速数据是非线性的, 使用统计学方法预测风速准确度不够高.

近年来, 使用机器学习(如 SVM^[4]、随机森林^[5]、极限学习机^[6]等)、深度学习(如 BP^[7]、RNN^[8]、LSTM^[9]等)预测方法受到国内外学者的偏爱. 文献[10]在对短期风速进行预测时, 使用到了支持回归向量机(SVR)方法, 具有较好的仿真效果. 文献[11]使用了 SVM 预测模型, 其中核函数选择了 RBF, 并通过算法对惩罚因子(C)和 RBF 自带参数(gamma)进行寻优, 预测结果较为理想. 文献[12]提出一种基于正则化极限学习机的风电场短期风速预测新方法, 相较于标准的 ELM 和 BP 神经网络, 该方法具有更好的预测精度. 文献[13]使用了 BP 预测模型, 不同于一般做法, 在使用了风速历史数据的同时, 还收集了风速周围的时空信息, 将这两种数据同时使用到风速预测中, 取得了较好的结果. 上述机器学习、深度学习方法在对风速数据进行预测时, 均取得了不错的结果, 但在实际场景的风速预测中, 仅运用单一模型, 预测的精度很难满足需求.

针对上述方法存在的问题, 组合预测模型目前被大量使用, 通过对不同单一预测模型的组合, 实现各模型之间优势互补, 以此提高预测精度. 文献[14]为了使非平稳风电功率信号相对平稳化, 使用 EMD 方法对其进行分解, 得到 n 个平稳序列, 分别送入 ARIMA 预测模型, 累加所有模型预测结果, 得到风速预测值. 文献[15]采用 LSTM 结构的循环神经网络对超短期风力发电进行预测. 文献[16]使用 EMD 方法和堆叠的长短期记忆网络的组合模型, 对短时风速进行预测. 上述组合模型均在一定程度上提升了预测精度, 但也存在一些问题, 文献[14]和文献[16]采用的 EMD 分解方法分解风速信号, 容易被异常信号干扰, 导致模态混叠现象, 文献[15]仅采用 LSTM 网络预测, 在一些风速数据预测上可能存在滞后问题.

本文提出基于 EEMD-GRU 的短期风速预测模型. 首先, 对原始风速时间数据进行异常数据剔除操作, 使用 EEMD 分解方法, 将原始数据分解成若干分量, 然

后将分解得到的分量分别送入 GRU 模型进行预测, 接着将所有分量的预测结果进行累加, 风速预测最终结果由此得到. 对于 EMD 分解方法产生的模态混叠现象, 本文使用 EEMD 分解方法来解决此问题; 对于单一 LSTM 预测方法可能产生的预测结果滞后现象, 使用 EEMD 与 GRU 相结合的组合预测方法来解决. 最后与 EEMD-LSTM、EMD-LSTM、EMD-GRU 等模型对比, 进行指标分析与评价, 实验证明本文的方法, 在对时间序列预测时, 准确度更高, 预测能力更强.

1 相关理论

1.1 经验模态分解

经验模态分解是一种比较智能的自适应算法(empirical mode decomposition, EMD), 在对原信号进行拆分时, 分解得到的分量能够自动匹配自己应在的尺度, 若分解得到分量还可继续拆分, 则继续分解, 直到不可分解为止, 这时就得到了原始信号经 EMD 方法分解后的所有分量^[17]. 这种分解方法能够挖掘出信号内部更详细的细节, 非常适用于处理不稳定的数据. EMD 分解的具体步骤如下:

(1) 将原始风速时间数据 $Y(t)$ 里面包含的全部局部极大值以及极小值找出来;

(2) 对原始数据进行插值操作, 求得上下包络线 $U(t)$ 和 $D(t)$;

(3) 求出上下包络线的平均值 $M(t)$;

$$M(t) = \frac{[U(t) - D(t)]}{2} \quad (1)$$

(4) 用 $Y(t)$ 减去 $M(t)$, 求得类距平值 $H(t)$;

$$H(t) = Y(t) - M(t) \quad (2)$$

(5) 对步骤(4)得到的序列 $H(t)$ 进行检查, 看其能否达到 IMF 标准, 若不达标, 则将 $H(t)$ 作为新的初始序列, 从头进行步骤(1)–(4), 直到所得结果都达到标准, 若条件达标, 则得到初始风速时间序列分解的 t 时刻第 n 个分量 $C_n(t)$;

$$C_n(t) = H(t) \quad (3)$$

(6) 从原始序列中将 $C_n(t)$ 去除, 得到剩余序列 $R(t)$;

$$R(t) = Y(t) - C_n(t) \quad (4)$$

(7) 将 $R(t)$ 作为新的初始序列, 循环执行上述步骤, 直到得到所有不可拆分的分量;

(8) 原始风速序列经过 EMD 分解后可表示为:

$$Y(t) = \sum_{i=1}^n C_i(x) + R_n(t) \quad (5)$$

1.2 集合经验模态分解

EMD 分解方法处理非平稳数据时表现良好,但也存在问题,分解得到的有些分量会重叠在一起,即模态混叠. Huang 等人为了解决这个缺陷,在 EMD 方法的基础上不断改进,经过大量试验,发现在原信号中加入噪声,利用噪声自身的特点,可以解决模态混叠问题,由此集合经验模态分解 (ensemble empirical mode decomposition, EEMD) 方法被提出^[18]. EEMD 方法的改进之处,就是将高斯白噪声放到了原始信号中(之所以选择高斯白噪声,是因为其具有随机性、且频谱均匀分布的特点),之后就是多次使用 EMD 方法分解新信号^[19]. EEMD 的具体步骤如下:

- (1) 向风速时间序列中添加噪声,噪声为服从正态分布的白噪声^[20];
- (2) 使用 EMD 方法,对新序列进行拆分,结果就是新序列由 n 个 IMF 分量和 1 个残差组成;
- (3) 重复步骤 (1) 和步骤 (2),每次执行时,将新的正态分布的白噪声序列添加到信号中;
- (4) 对所有 IMF 分量,做集成平均操作,得到风速时间序列的 IMF 分量.

1.3 门控循环单元

GRU (gated recurrent unit) 是 LSTM (long short-term memory) 的一种变体^[21],从结构上看,两者还是有着很大的差别.与 LSTM 的三门结构不同,GRU 只有两个门,分别是重置门和更新门^[22].因为少了一个门结构,计算时参数数量相比于 LSTM 会少一些,训练速度更快. GRU 整体结构如图 1 所示.




图 1 GRU 网络基本单元

GRU 的迭代公式如下:

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (6)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (7)$$

$$\tilde{h}_t = \tanh(W \cdot [r_t * h_{t-1}, x_t]) \quad (8)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \quad (9)$$

其中,下标 t 代表 t 时刻、更新门由 z 指代,重置门由 r 指代. 权重矩阵由 W 指代, Sigmoid 函数由符号 σ 指代,输出值由 h 指代. $*$ 代表哈达玛积 (Hadamard product).

2 基于 EEMD-GRU 的短期风速预测模型实现

2.1 EEMD-GRU 模型

风速序列通常随着时间的变化一直震荡,呈不平稳状态,且极容易受现实中周围环境影响,传统预测方法效果较差. 本文为克服仅使用单一模型预测精度不够高的问题,使用两种方法相结合的组合模型对风速进行预测. 组合模型由 EEMD 和 GRU 方法构成. 首先用孤立森林算法剔除原始风速中的异常点,然后使用 EEMD 方法,将其拆分成不同尺度的信号,从而大大降低风速信号的震动性、非平稳性,其次,将分解得到的各分量信号分别送入 GRU 模型进行训练得到各自的预测结果,预测风速最后由所有分量结果累加得到. 具体预测流程如图 2 所示.

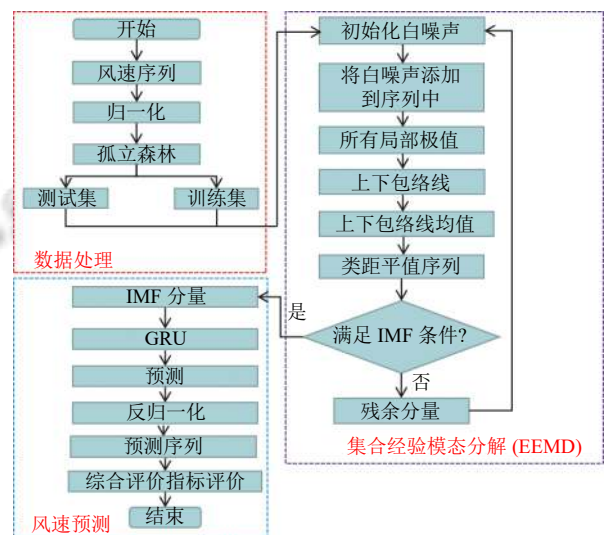


图 2 EEMD-GRU 组合模型基本结构

具体步骤如下:

- (1) 获取原始风速时间数据,归一化处理,归一化公式如下:

$$X_i^* = \frac{X_i - \min}{\max - \min} \quad (10)$$

其中, i 为风速序列的第 i 个元素; 风速的初始值、最大值、最小值由 X 、 max 、 min 分别指代; X^* 为归一化操作后得到的序列;

(2) 对归一化的数据, 使用孤立森林算法, 标注出全部异常点、剔除全部异常点;

(3) 使用 EEMD 方法对上述操作得到的结果进行拆分, 得到不同尺度的 IMF;

(4) 按照 19:1 的占比, 将步骤 (3) 得到的序列划分为训练集和测试集;

(5) GRU 网络初始化, 将步骤 (4) 所得数据分别送入 GRU 网络进行训练;

(6) 将步骤 (5) 得到的全部预测结果累加求和, 得到最终风速预测结果.

2.2 模型评价指标

为更加直观的评估 EEMD-GRU 模型在实际问题预测中的表现, 选用了 4 种评价指标进行评测. 分别是 $RMSE$ (均方根误差)、 R^2 (决定系数)、 MAE (平均绝对误差)、 $MAPE$ (平均绝对百分误差)^[23]. 其中, $RMSE$ 、 $MAPE$ 、 MAE 数值越小代表模型预测误差越小, R^2 数值越接近于 1, 代表模型表现越好. 4 项指标计算公式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{true}(i) - y_{pred}(i))^2} \quad (11)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{true}(i) - y_{pred}(i))^2}{\sum_{i=1}^n (y_{true}(i) - \bar{y})^2} \quad (12)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{true}(i) - y_{pred}(i)| \quad (13)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_{true}(i) - y_{pred}(i)}{y_{true}(i)} \right| \quad (14)$$

3 实验与分析

3.1 数据预处理

本文算例为我国新疆某地风场 2017 年的风速实地采样数据, 以 15 min 对风速数据采样, 每小时提取 4 条数据. 本次实验使用的 2017 年 5 月 1 日至 6 月 2 日的数据, 一共 3 072 条, 原始样本数据如图 3. 首先

对数据进行归一化操作, 缩小数据之间的量纲差距, 避免训练中产生误差过大. 归一化结果如图 4 所示.




图3 原始风速序列




图4 归一化结果

原始数据在采集时, 可能因为各种各样的原因 (风机故障、操作失误等), 导致样本中存在脏数据, 直接将数据送入网络学习, 网络会将错误信息一起学习, 预测时会产生一定的误差, 因此对异常数据处理显得尤为重要. 对归一化数据, 采用孤立森林算法, 找出异常点 153 个, 如图 5 所示, 将异常点去除, 结果如图 6 所示.




图5 异常点分布




图6 去除异常点结果

3.2 EEMD 分解

异常点去除后, 样本剩余 2919, 根据 19:1 的占比, 将数据划为训练集和测试集. 如图 7 所示, 原始的震动性极强的序列, 现在由 9 个 IMF 和 1 个残差分量所代替, 并且按照信号频率的大小, 由高到低依次排列, 原始风速序列波动性大、非平稳的缺点被大大克服, 同时经过分解操作得到的分量, 具备较强的稳定性.




图7 EEMD 分解结果(横坐标表示采样点个数, 纵坐标表示信号幅值大小)

3.3 GRU 模型参数选择

深度学习发展至今, 网络结构以及网络参数选择

问题, 至今没有定性的理论可参考, 学者们大多根据经验或在实验过程中确定参数. 过于复杂或简单的网络结构、过大或过小的神经元个数, 会导致过拟合或欠拟合现象, 因本文数据量只有 3000 条左右, 样本量不大, 故 GRU 网络考虑单层或双层结构, 隐藏层神经元考虑 30 或 50. 为排除随机性误差, 采用 10 次实验的平均值作为模型结构选择的参考. 如表 1 所示.

表1 GRU 网络参数

网络结构	单层GRU		双层GRU	
	30 neuron	50 neuron	30 neuron	50 neuron
RMSE	0.8148	0.8140	0.8366	0.8384
MAE	0.6325	0.6352	0.6525	0.6471

网络结构确定后, 接下来探索时间步长 (TIME_STEP) 的合适值. TIME_STEP 用来重构风速序列, 形成新的输入集合. TIME_STEP 为 6, 意思是用前 6 个风速数据作为模型的输入, 预测第 7 个风速数据的输出. 不同大小的 TIME_STEP, 对模型的预测结果会产生不同的影响, 因此在不同 TIME_STEP 下, 进行实验.

表2 时间步长

TIME_STEP	RMSE	MAE
6	0.8106	0.6321
8	0.7980	0.6155
10	0.8067	0.6212
12	0.8188	0.6338
14	0.7868	0.6019
16	0.7872	0.6010
18	0.8265	0.6357
20	0.7841	0.5996
22	0.7889	0.6089
24	0.8593	0.6799
26	0.7962	0.6076
28	0.8009	0.6147
30	0.7912	0.6046
32	0.8139	0.6236

从表 2 可以看出, TIME_STEP=32 时, 模型的预测误差比 TIME_STEP=20 时还要高, 这说明时间步长并不是越大越好. 随着时间步长的增加, 误差呈波浪式变化, 当 TIME_STEP 为 20 时 RMSE 和 MAE 值均为最小, 故本文时间步长设定为 20.

3.4 不同模型对比

本文选用 EEMD-LSTM、EMD-GRU、EMD-LSTM、LSTM、GRU、BP 网络作为 EEMD-GRU 模型的对比模型. 其中所有模型的网络结构与 GRU 模型相同, 均为单层结构, 神经元均设为 50, Dropout 率设

为 0.2, epoch 为 50, batch_size 为 16, 预测结果如图 8、图 9 所示。

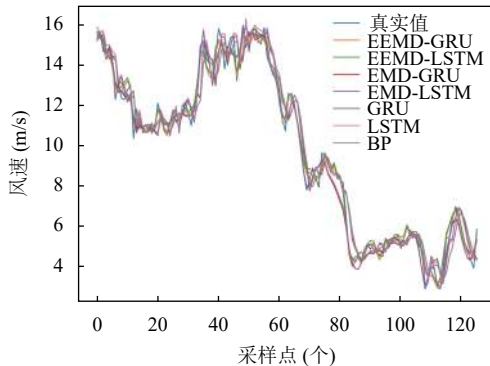


图 8 不同模型预测结果

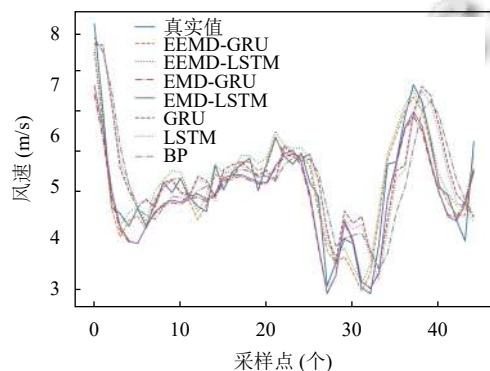


图 9 不同模型预测结果放大图

从图 9 可以明显看出 EEMD-GRU 模型预测的曲线能够更好地跟随真实数据变化, 拟合效果最好. 为了更加直观的比较模型预测精度, 计算了所有模型在相同输入条件下的 4 种评价指标, 见表 3.

表 3 不同模型效果对比

方法	RMSE	MAPE	R^2	MAE
EEMD-GRU	0.3470	0.0323	0.9926	0.2695
EEMD-LSTM	0.3750	0.0367	0.9913	0.2913
EMD-GRU	0.4147	0.0389	0.9897	0.3358
EMD-LSTM	0.3958	0.0365	0.9906	0.3179
GRU	0.8007	0.0791	0.9617	0.6195
LSTM	0.8215	0.0794	0.9597	0.6300
BP	0.8574	0.0852	0.9561	0.6634

从 RMSE、MAPE、MAE 三项指标来看, EEMD-GRU 模型相较于 EEMD-LSTM 模型, 误差分别降低了 7.47%、11.99%、7.48%; 相较于 EMD-GRU 模型, 误差分别降低了 16.33%、16.97%、19.74%; 相较于 EMD-LSTM 模型, 误差分别降低了 12.33%、11.51%、

15.22%; 相较于 GRU 模型, 误差分别降低了 56.66%、59.17%、56.50%; 相较于 LSTM 模型, 误差分别降低了 57.76%、59.32%、57.22%; 相较于 BP 模型, 误差分别降低了 59.53%、62.09%、59.38%. 从 R^2 来看, EEMD-GRU 模型相对于其他模型 R^2 的值更接近 1, 综合 4 种指标, 足以证明 EEMD-GRU 方法在预测精度上表现的最好.

4 结论

本文针对风速的随机性、震动性以及仅使用 LSTM 预测可能出现的滞后性等问题, 提出了一种基于 EEMD-GRU 的短期风速预测方法, 采用实地采集的数据进行预测, 得出以下结论:

(1) 对原始风速时间序列分解, 能够很大程度上降低风速数据自身的不稳定性.

(2) EEMD-GRU 模型克服了 EMD 方法在分解非平稳数据 (风速序列) 时产生的模态混叠问题, 提高了预测精度.

(3) EEMD-GRU 模型有效地改善了单一 LSTM 模型预测出现的滞后性问题.

(4) 通过与 EEMD-LSTM、EMD-LSTM、EMD-GRU、LSTM、GRU、BP 模型进行比较, 证明了本文提出的 EEMD-GRU 组合模型在对风速数据预测时, 预测曲线更贴合实际曲线, 预测精度更高, 预测能力更强.

参考文献

- 薛阳, 张宁, 俞志程, 等. 基于 BiLSTM 和 Bootstrap 方法的风电功率区间预测. 可再生能源, 2020, 38(8): 1059-1064.
- 纪洁, 胡汉, 高远, 等. 基于遗传算法优化参数的支持向量机风电功率预测. 电子测试, 2020, (21): 32-35. [doi: 10.3969/j.issn.1000-8519.2020.21.011]
- 温钊, 张方红, 刘冰冰, 等. 基于小波分析和高斯过程的短期风速预测. 船舶工程, 2020, 42(S2): 192-195, 221.
- 陈岩, 周晨, 侯群. SVM 算法在风力发电机功率预测中的应用研究. 电子世界, 2021, (4): 100-102.
- Vassallo D, Krishnamurthy R, Sherman T, et al. Analysis of random forest modeling strategies for multi-step wind speed forecasting. Energies, 2020, 13(20): 5488. [doi: 10.3390/en13205488]
- Zhang YJ, Chen L. A hybrid forecasting model based on modified bat algorithm and ELM: A case study for wind speed forecasting. 2018 2nd International Workshop on Renewable Energy and Development (IWRED 2018). Guilin:

- IOP Publishing, 2018. 32–37.
- 7 梅雨, 王红蕾, 王瑾. 基于 PSO-BP 组合改进模型的短期风电功率预测仿真. 软件, 2020, 41(12): 7–10. [doi: [10.3969/j.issn.1003-6970.2020.12.003](https://doi.org/10.3969/j.issn.1003-6970.2020.12.003)]
 - 8 夏文泽, 冯骁, 王喆, 等. 基于新型联合循环神经网络 (RNN) 模型的出水总氮预测. 净水技术, 2021, 40(8): 107–113.
 - 9 李艳, 彭春华, 傅裕, 等. 基于 CNN-LSTM 网络模型的风电功率短期预测研究. 华东交通大学学报, 2020, 37(4): 109–115.
 - 10 李霞. 支持向量回归机在风电场短期风速预测中的应用研究 [硕士学位论文]. 北京: 华北电力大学, 2013.
 - 11 赵斌, 宋建丽. 基于 SVM 回归方法的风速预测研究. 电子世界, 2013, (6): 83–84.
 - 12 袁翀, 戚佳金, 王文霞, 等. 采用正则化极限学习机的短期风速预测. 电网与清洁能源, 2016, 32(11): 62–68. [doi: [10.3969/j.issn.1674-3814.2016.11.011](https://doi.org/10.3969/j.issn.1674-3814.2016.11.011)]
 - 13 周建强, 李玉娜, 屈卫东, 等. 基于风速时空信息的 BP 神经网络超短期风速预测研究. 电网与清洁能源, 2015, 31(1): 109–112. [doi: [10.3969/j.issn.1674-3814.2015.01.019](https://doi.org/10.3969/j.issn.1674-3814.2015.01.019)]
 - 14 仇琦, 杨兰, 丁旭, 等. 基于改进 EMD-ARIMA 的光伏发电系统短期功率预测. 电力科学与工程, 2020, 36(8): 42–50. [doi: [10.3969/j.issn.1672-0792.2020.08.007](https://doi.org/10.3969/j.issn.1672-0792.2020.08.007)]
 - 15 王伟, 刘宏伟, 陈永杰, 等. 基于 LSTM 循环神经网络的风力发电预测. 可再生能源, 2020, 38(9): 1187–1191. [doi: [10.3969/j.issn.1671-5292.2020.09.009](https://doi.org/10.3969/j.issn.1671-5292.2020.09.009)]
 - 16 黄元生, 杨磊, 高冲, 等. 基于经验模态分解和误差校正的短期风速预测. 智慧电力, 2020, 48(1): 35–41.
 - 17 甘迪, 柯德平, 孙元章, 等. 基于集合经验模式分解和遗传-高斯过程回归的短期风速概率预测. 电工技术学报, 2015, 30(11): 138–147. [doi: [10.3969/j.issn.1000-6753.2015.11.017](https://doi.org/10.3969/j.issn.1000-6753.2015.11.017)]
 - 18 Huang NE, Shen Z, Long SR, *et al.* The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903–995. [doi: [10.1098/rspa.1998.0193](https://doi.org/10.1098/rspa.1998.0193)]
 - 19 于婷, 孙景云. 基于 EEMD 和 PSO 方法的我国港口集装箱吞吐量预测. 物流技术, 2021, 40(5): 56–64. [doi: [10.3969/j.issn.1005-152X.2021.05.010](https://doi.org/10.3969/j.issn.1005-152X.2021.05.010)]
 - 20 Sun HY, Wu J, Wu J, *et al.* Hybrid SVM and ARIMA model for failure time series prediction based on EEMD. International Journal of Performability Engineering, 2019, 15(4): 1161–1170. [doi: [10.23940/ijpe.19.04.p11.11611170](https://doi.org/10.23940/ijpe.19.04.p11.11611170)]
 - 21 黄伟建, 李丹阳, 黄远. 基于深度学习的 PM_{2.5} 浓度长期预测. 计算机应用研究, 2021, 38(6): 1809–1814.
 - 22 余本功, 张培行. 基于双通道特征融合的 WPOS-GRU 专利分类方法. 计算机应用研究, 2020, 37(3): 655–658.
 - 23 胡汉. 风电场风电功率概率预测研究 [硕士学位论文]. 南京: 东南大学, 2016.