

# 基于完备经验模态分解与深度学习的短期风电功率预测

帅一民<sup>1</sup>, 李润<sup>2</sup>, 杜玉杰<sup>1</sup>, 黄超安<sup>3</sup>, 唐黎<sup>1</sup>

<sup>1</sup>国家电投集团江西电力有限公司高新清洁能源分公司, 江西 南昌

<sup>2</sup>北京东润环能科技股份有限公司, 北京

<sup>3</sup>国家电投集团江西水电检修安装工程有限公司, 江西 南昌

Email: lirun0621@hotmail.com

收稿日期: 2021年6月25日; 录用日期: 2021年7月9日; 发布日期: 2021年7月26日

---

## 摘要

根据各因素对风电场输出功率的影响, 建立了基于CEEMD-GRU短期风电场输出功率的预测模型。通过与单模型BPNN、SVM、GRU和组合模型EMD-GRU、CEEMD-BP的预测结果进行对比, 最终通过误差评价指标得出对风电功率预测结果精度较高的组合模型, 以此来提高短期风功率预测精度。

## 关键词

风电场短期功率, 预测精度, CEEMD-GRU, 评价指标

---

# Short-Term Wind Power Forecasting Based on CEEMD and Deep Learning Model

Yimin Shuai<sup>1</sup>, Run Li<sup>2</sup>, Yujie Du<sup>1</sup>, Chaoan Huang<sup>3</sup>, Li Tang<sup>1</sup>

<sup>1</sup>SPIC Jiangxi Electric Power Co., Ltd., High-Tech Clean Energy Branch, Nanchang Jiangxi

<sup>2</sup>Beijing East Environment Energy Technology Co., Ltd., Beijing

<sup>3</sup>SPIC Jiangxi Hydropower Maintenance & Installation Engineering Co., Ltd., Nanchang Jiangxi

Email: lirun0621@hotmail.com

Received: Jun. 25<sup>th</sup>, 2021; accepted: Jul. 9<sup>th</sup>, 2021; published: Jul. 26<sup>th</sup>, 2021

---

## Abstract

According to the influence of various factors on the output power of wind farms, a short-term wind farm output power prediction model based on CEEMD-GRU is established. By comparing with the

文章引用: 帅一民, 李润, 杜玉杰, 黄超安, 唐黎. 基于完备经验模态分解与深度学习的短期风电功率预测[J]. 智能电网, 2021, 11(4): 297-304. DOI: 10.12677/sg.2021.114028

**prediction results of the single model BPNN, SVM, GRU and the combined model EMD-GRU, CEEMD-BP, the combined model with higher accuracy for the wind power prediction results is obtained through the error evaluation indicators, so as to improve the short-term wind power prediction accuracy.**

## Keywords

**Wind Farm Short Term Power, Prediction Accuracy, CEEMD-GRU, Evaluation Indicators**

Copyright © 2021 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

现如今全世界正处于不可再生能源濒危的状态，而风能作为可再生能源之一，成为目前最具开发性的代表能源。风力发电具有成本低廉、绿色可持续发展、经济规模显著等优点。但是，由于其受到海拔、气压、温度、地形等环境因素的影响，风速具有随机性、不稳定性 and 波动性等特性，而风机的运行效率与风速有着密不可分的关系。另外，大规模的风电并网必定会对电网调度产生消极影响，从而导致电网的鲁棒性下降。因此，完备的风电功率预测系统不仅可以为风电场制定合适的发电、配电和维护策略，而且可以提高风电并网的稳健性。提升风电功率的预测精度不仅有助于电网调峰工作，增强电网的风电接纳能力，改善电力系统运行的安全性与经济性，而且对于保障风电一体化和电力系统的稳定运行起到至关重要的作用。

目前针对风功率预测模型的研究越来越多，主要有四种：物理方法，统计方法，人工智能法与组合预测法。随着风速或风电功率预测技术的不断推进，国内外研究学者意识到单一预测模型的不足，提出了组合预测方法[1] [2] [3]。文献[1]提出了一种基于完备总体经验模态分解和随机森林(RF)的短期风电功率预测模型，先将原始风电功率序列分解，再对新的分量进行随机森林预测模型，最后通过具体算例验证了该模型的有效性；文献[2]提出了一种将随机森林与门控循环单元神经网络相结合的超短期风电预测模型，通过最终结果表明其预测精度有了很大的提高与改进，来进一步提高风电并网功率规模；文献[3]建立了一种结合小波分解和 BP 神经网络的风电功率预测方法，并通过实证结果验证混合模型要比单一预测模型的精度高；文献[4]提出了基于经验模态分解和支持向量机(SVM)的组合预测模型，其预测精度要高于单模型支持向量机；文献[5]提出了一种基于经验模态分解(EMD)与径向基神经网络的短期风电功率预测方法，结果表明分解后的风功率分量序列具有较强的规律性，其预测精度也要高于传统的预测方法。经验模态分解方法和小波分解方法分解结果存在严重频率混叠现象，本文基于文献[1] [6]提出的 CEEMD 分解方法结合门控循环(GRU)深度神经网络构建了新型的预测系统。首先将历史风功率数据进行 CEEMD 分解后，得到特征互异的 IMF 分量和残余项，接着依据不同分量的数据特征，通过引入 GRU 深度网络模型对各分量进行预测，最后将各分量预测结果整合得到最终的预测结果，并与现有的预测模型进行误差对比研究。最后通过算例分析，结合误差评价指标验证该模型的合理性和有效性。

## 2. 完备总体经验模态分解(CEEMD)

### 2.1. 经验模态分解(EMD)

经验模态分解是将原始的复杂信号分解成若干个简单并且独立的 IMF 分量。根据以下两个条件来判

断所分解的分量是否为 IMF 分量：首先，所选取的整个数据当中，极值点的数量与过零点的数量的差值小于或等于 1；其次，被选取数据当中的任何时间段，由局部上极值点组成的上包络线与局部下极值点所构成的下包络线的平均值为零。

其具体流程如下：

- (1) 通过原始信号，找出上下极值点，并画出上下包络线；
- (2) 由画出的上下包络线，求解出上下包络线的均值，从而画出均值包络线；
- (3) 用原始信号减去均值信号，得出中间信号；
- (4) 通过 IMF 的两个约束条件来判断均值信号是否为 IMF 信号；如果满足要求，则将该信号记为第一个分量；如果不满足条件，则以该信号为新的原始信号，并进行步骤(1)~(3)，直到满足条件为止。
- (5) 将分解出的第一个分量记为  $IMF_1$ ，然后用原始信号减去分量  $IMF_1$  得到新的原始信号，再重复进行步骤(1)~(3)，得到分量  $IMF_2$ 。以此类推，直到原始信号被完全分解。

## 2.2. 集合经验模态分解(EEMD)

相较于 EMD 方法而言，EEMD 方法解决了 EMD 其本身的模态混叠问题。

其具体分解流程如下：

- (1) 将原始信号处理次数设定为  $m$ ；
- (2) 将不同幅值的随机白噪声分别添加到这  $m$  个原始信号当中，从而形成一系列新的原始信号；
- (3) 对新得到的原始信号进行 EMD 分解后，得到一系列新的最终 IMF 分量；
- (4) 对得出的 IMF 分量分别求取平均值，导出 EEMD 分解的最终结果。

## 2.3. 完备总体经验模态分解(CEEMD)

与 EEMD 算法相比，CEEMD 算法则是通过将一对符号一正一负的白噪声作为辅助噪声加入源信号当中。这一技术不仅可以清楚原本 EEMD 方法分解后的重组信号当中所残存的过多的辅助白噪声，而且还可以降低分解时的迭代次数。

其具体操作步骤如下：

- (1) 在原始信号  $x(t)$  中加入一组符号为一正一负的白噪声  $n_1^+(t)$  和  $n_1^-(t)$ ，得到  $m_1^+(t)$  和  $m_1^-(t)$ ，计算公式如下所示：

$$m_1^+(t) = x(t) + n_1^+(t)$$

$$m_1^-(t) = x(t) + n_1^-(t)$$

- (2) 对  $m_1^+(t)$  和  $m_1^-(t)$  进行 EMD 分解，分别得出一列模态函数(IMF)，公式如下所示：

$$m_1^+(t) \xrightarrow{EMD} C_{i1+}(t) + r_{i+}$$

$$m_1^-(t) \xrightarrow{EMD} C_{i1-}(t) + r_{i-}$$

- (3) 在原始信号  $x(t)$  中加入不同高斯白噪声信号，重复步骤(1)、(2)，得到  $N$  组本征模态函数  $C_{iN+}$ 、 $r_{N+}$  和  $C_{iN-}$ 、 $r_{N-}$ ；

- (4) 分别对本征模态函数和剩余分量求取均值，公式如下所示，导出最终的模态分量 IMF。

$$C_i(t) = \frac{1}{2N} \sum_{j=1}^N (C_{ij+} + C_{ij-})$$

$$r(t) = \frac{1}{2N} \sum_{j=1}^N (r_{j+} + r_{j-})$$

### 3. 门控循环单元深度网络(GRU)

#### 3.1. 模型概述

GRU 即 Gated Recurrent Unit。GRU 是 LSTM 网络的一种实证操作效果较好的变体网络模型，可以解决 RNN 网络中的长依赖问题。相较 LSTM 网络的结构，GRU 结构更加简洁有效，而且预测效果也很好。因此，本文选取 GRU 深度网络模型作为基础预测模型。

#### 3.2. 操作流程

在 GRU 模型中引入了两个门：更新门和重置门。具体结构如图 1 所示。




Figure 1. GRU network topology  
图 1. GRU 网络拓扑结构

图 1 中的  $z_t$  和  $r_t$  分别表示更新门和重置门。更新门用于控制前一时刻的状态信息被带入到当前状态中的程度，更新门的值越大说明前一时刻的状态信息进入的越多。重置门控制前一状态有多少信息被写入到当前的候选集  $\tilde{h}_t$  上，重置门越小，前一状态的信息被写入的越少。计算公式为：

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

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

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

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

$$y_t = \sigma(W_o * h_t)$$

其中\*表示矩阵内积运算， $\tanh()$ 和  $\sigma()$ 为模型的激活函数。GRU 是通过门结构来控制重要信息的存储与传递，此结构可以保证在长期历史数据传播的时候不会丢失。此外，GRU 网络相对于 LSTM 网络少了一个门函数，因此在参数的数量上也是要少于 LSTM 的，所以整体上 GRU 的训练速度要快于 LSTM 的。

### 4. 数据选取

#### 4.1. 广西某风电场测风塔概况

本文对广西某风电场测风塔监测到的实时数据进行分析，采样频率为每 15 分钟一次。检测时间从 2019 年 7 月 1 日 0 点到 2019 年 7 月 21 日晚上 19 点 45 分，取这 2000 个数据作为样本进行分析。监测对象分别为测风塔风向、测风塔风速、测风塔温度、测风塔气压以及测风塔空气密度。除此之外，由于处于 70 m 层高的监测效果较为良好，因此选处于 70 m 层高的监测数据。具体分析结果如表 1 所示。

**Table 1.** Basic statistics of wind tower data**表 1.** 测风塔数据概况

	极小值 统计量	极大值 统计量	均值 统计量	标准差 统计量	偏度 统计量
测风塔风向(°)	3.82	356.73	161.9692	98.51969	0.83
测风塔风速(m/s)	0.04	9.14	5.3679	1.52418	-0.055
测风塔气温(°C)	6.13	23.24	15.2162	3.82169	-0.268
测风塔气压(KPa)	79.54	99.85	98.931	0.62803	-18.311
测风塔湿度(RH)	46.53	97.31	82.1449	13.18049	-1.002
测风塔空气密度(kg/m <sup>3</sup> )	0.9911	1.2366	1.196137	0.0196402	-0.441

由表 1 可以得出, 由于统计数据过程当中的缺失性, 绝大部分特征的有效数量为 1996 个, 只有测风塔空气密度为 2000 个有效数据。除此之外, 测分塔各个指标的偏度标准误与峰度标准误无明显差异, 说明, 各个指标的分布情况以及离散程度十分接近。并且, 通过第一行测风塔风向这一指标, 可以从第二列看出其极大值为 356.73, 而极小值仅有 3.82, 说明尽管在处于 70m 层高的测分塔风向的变化差异幅度很大, 毫无规律可循。

## 4.2. 广西某风电场实际功率概况

对广西某风电场实际功率进行描述性统计分析, 间隔采样时间为 15 min。检测时间从 2019 年 1 月 1 日 0 点开始, 取前 2000 个数据作为样本进行分析。具体分析结果如表 2 所示。

**Table 2.** Basic statistics of real wind power**表 2.** 实际功率数据概况

	极小值 统计量	极大值 统计量	均值 统计量	标准差 统计量	偏度 统计量	峰度 统计量
实际功率(MW)	0	56.18	19.9185	16.56447	0.447	-1.171

根据表 2, 经过数据预处理过后, 实际功率当中所有的负值都变成了 0, 所以实际功率的最小值为 0。除此之外, 最大值为 56.18 兆瓦, 均值为 19.9185 兆瓦, 说明风力发电功率的最大值在某一时刻可以达到 56.18 兆瓦, 平均每一个时刻的实际功率为 19.9185 兆瓦。并且, 方差为 274.382, 标准差为 16.56447, 说明实际功率的变化程度很大, 规律性不强, 具有很强的不稳定性。

## 5. 算例分析

### 5.1. CEEMD 分解结果

完备总体经验模态分解(CEEMD)参数设定为: 白噪声的幅度值为 0.2, 对信号的平均次数为 8。分解结果如图 2 所示。

通过图 2 的结果可以看出, 原始功率经 CEEMD 分解后为 9 个 IMF 分量(IMF<sub>1</sub>~IMF<sub>9</sub>)和一个残余项。

### 5.2. 分量预测

本文所建立的 GRU 模型共含 4 层网络, 包括 2 层隐含层, 每个隐含层包括 100 个神经元, 实际的优化目标为均方误差, 最大迭代次数设置为 2000, 残差收敛条件为 0.0001, L<sub>2</sub> 惩罚(正则项)参数为 0.001,

优化器选择为 Adam。




Figure 2. Wind power original sequence and CEEMD decomposition results  
图 2. 风电功率原始序列及 CEEMD 分解结果

### 5.3. 实证对比分析

通过 EMD、EEMD 以及 CEEMD 对原始数据进行分解后，得出来的各个分量再应用 BP、SVM 算法和 RF 算法进行分析，从而推出最终预测输出结果，如图 3 所示。

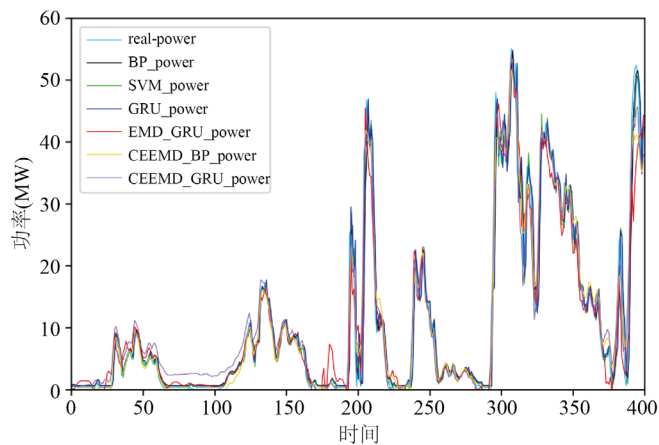


Figure 3. Comparison of EMD series with BP and GRU model  
图 3. EMD 系列与 BP、GRU 组合对比结果

通过图 3 可以看出, 如果将实际功率作为衡量标准(即图中 real\_power 那条线), 由于 CEEMD-GRU 这一曲线与原始功率的曲线贴合程度最高, 因此可以看出 CEEMD-GRU 这一组合模型对风电功率的预测效果最好, 其次就是 CEEMD-BP 以及 EMD-GRU 这两个组合; 由于 BP 以及 SVM 这两个单模型与原始功率的偏差较大, 说明这两个模型的拟合效果相较于其他模型而言较次。

建立三个单模型 BP、SVM、GRU 以及三个组合模型 EMD-GRU、CEEMD-BP、CEEMD-GRU, 共计六个模型, 对风电功率进行短期预测, 并对比不同模型预测结果的精确度。最终的评价结果如表 3 所示。

**Table 3.** Comparison of EMD series with BP and GRU model

**表 3.** EMD 系列与 BP, GRU 组合预测结果对比分析

	MAE	MAPE	MSE	RMSE
BP	2.0861	0.5395	15.1898	3.8974
GRU	2.0184	0.5180	13.9663	3.7372
SVM	1.8992	0.5522	13.5103	3.6756
EMD-GRU	1.8176	0.5252	10.0089	3.1637
CEEMD-BP	1.3933	1.1358	5.7735	2.4028
CEEMD-GRU	1.6963	0.5055	5.6032	2.3671

由表 3 可知, 最后一行的 CEEMD-GRU 该模型的效果相较于其他五个模型而言, 其四种误差结果最小, 表示预测效果最好。通过比较 SVM 与 BP 网络的误差评价指标, 可以看出 SVM 模型的 MAE、MAPE、MSE 和 RMSE 误差都低于 BP 神经网络的误差值, 因为 BP 神经网络模型的精度易受到模型结构与参数的影响, 容易陷入局部最优解。在所有的模型当中, CEEMD-GRU 这一混合组合的预测效果最好, 说明该模型的预测值与实际风电功率的真实值更加贴近, 预测精度最高。除此之外, 相较于 CEEMD-BP 与 CEEMD-GRU 这两个组合模型的预测误差, 也同样说明了采用 GRU 模型的预测精度要比 BP 神经网络的预测精度有所提升。同时, 在比较 EMD-GRU 以及 CEEMD-GRU 这两个组合模型当中, CEEMD-GRU 的效果最好, 其次是 EMD-GRU 模型, 由此可以说明在同一种神经网络学习方法的条件下, 基于 CEEMD 分解方法分解原始数据后的预测效果要比 EMD 分解方法的最终预测效果更佳。

## 6. 结论

为有效提升风电功率预测效果, 本文采用 EMD 分解方法、CEEMD 分解方法以及 BP 神经网络、SVM 模型和 GRU 算法的组合模型, 来寻找出预测效果最佳的混合模型。首先, 采用 EMD 以及 CEEMD 对原始风电功率进行分解, 得到各个不同的分量, 实证结果表明通过 CEEMD 分解方法改善了分量间严重频率混叠的现象。其次, 将各个分量应用 BP、SVM 以及 GRU 模型进行了建模, 从而得出最终的短期风电功率预测结果。通过采取四种误差评价指标对最终预测结果进行评估, 结果表明本文提出的 CEEMD-GRU 模型可以有效提高短期风电功率预测精度。此外, 相较于 EMD 与 EEMD 分解方法, 基于 CEEMD 的混合预测模型的预测误差更小, 预测精度更高; 同时基于 GRU 深度学习的短期风功率混合预测模型的预测效果优于基于 BP 网络混合模型的预测效果。

## 参考文献

- [1] 赏益, 高志球, 韩威. 基于 RF 和 GRU 组合算法的超短期风电功率预测[J]. 中国科技论文, 2020, 15(9): 987-992.

- [2] 刘强, 胡志强, 周宇, 吕朋朋, 王金鑫. 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): 71-76+94.
- [3] 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): 30-36.
- [4] 黄焘, 陈建国, 范强, 雷金勇, 杨苹. 基于 EMD 和 SVM 的风电功率组合预测方法[J]. 电气应用, 2015, 34(21): 24-29.
- [5] 王信宣, 邓斌, 王江. 基于经验模态分解与 RBF 神经网络的短期风功率预测[J]. 电力系统及其自动化学报, 2020, 32(11): 109-115.
- [6] 谢碧霞, 林丽君, 白阳振. 基于 EEMDCAN 的 SVM 短期风电功率预测[J]. 电力科学与工程, 2019, 35(7): 62-67.