



# 基于 EEMD-CNN-GRU 的短期风向预测

## 摘要

为了提高短期风向的预测精度,提出一种基于集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)、卷积神经网络(Convolutional Neural Network, CNN)和门控循环单元网络(Gated Recurrent Unit, GRU)的混合模型:EEMD-CNN-GRU.针对风向序列的随机性和不平稳性等特点,先利用 EEMD 将数据分解成多个分量;再运用 CNN 的局部连接和权值共享来提取分量中的潜在特征;最后,使用 GRU 对 CNN 所提取的潜在特征进一步构建特征,叠加各分量的预测值,得到最终预测结果.实验结果表明:相对于 BP 神经网络和长短期记忆网络(Long Short-Term Memory, LSTM)等其他模型,本文所提出的预测方法取得了良好的性能.

## 关键词

风向预测;集合经验模态分解;卷积神经网络;门控循环单元网络;长短期记忆网络

中图分类号 TM614

文献标志码 A

收稿日期 2022-11-15

资助项目 国家重点研发计划(2018YFB15029 02);陕西省自然科学基金(2021JM-378, 2021JQ-493)

作者简介

史加荣,男,教授,研究方向为机器学习和可再生能源预测.shijiarong@xauat.edu.cn

1 西安建筑科技大学 理学院,西安,710055

## 0 引言

近年来,不可再生能源日益匮乏.除了积极提高能源效率外,从自然界中直接获得的可再生能源引起了许多学者的关注.风能、太阳能和潮汐能等均已被用于电力转换<sup>[1]</sup>,因此可再生发电的部署是低碳经济的关键推动力<sup>[2]</sup>.由于对风力发电的需求不断增长,加上社会、环境以及经济因素的制约,使得目前风力涡轮和风电场规模增加<sup>[3]</sup>.风向变化是影响风力涡轮机运行最重要的环境因素之一,风向预测可用于设计最佳偏航控制的风力涡轮机.受台风、复杂地形以及上游风力发电机产生尾流等因素的影响,风力发电的来风方向总是在变化,导致每个风力涡轮机的进入风向也不同.针对风向变化,大型风力涡轮机对偏航控制系统采用不同的控制策略<sup>[4]</sup>.动态偏航过程是由连续的静态偏航过程形成的,因此对静态偏航的研究是动态偏航的基础.国内外学者对静态偏航风力发电机的空气动力学性质进行了许多研究,通过对风向角度的研究可知:当风速不变时,短时间内的风向变化导致迎面风速降低,风力涡轮机转子速度也随之降低.

目前,国内外学者针对短期风向的预测做了大量的研究并提出了很多方法.在风向预测方面,建立混合模型来寻找最优预测方法是比较常见的研究策略,例如:唐振浩等<sup>[5]</sup>提出一种基于数据解析的混合风向预测算法;Sari 等<sup>[6]</sup>基于 3DCNN 和深度卷积 LSTM 提出短期风速和风向预测方法;Chitsazan 等<sup>[7]</sup>基于非线性函数的回波状态网络来预测风向.

风向数据具有随机性、不确定性等特点<sup>[8]</sup>.为提高风向测量的准确性,本文提出了一种基于 EEMD-CNN-GRU 的混合预测模型.此模型先运用集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)算法对原始风向序列进行分解,得到更能反映风向序列变化特性的多个分量,以降低不平稳性和间歇性;其次使用卷积神经网络(Convolutional Neural Network, CNN)提取潜在特征,使得各分量简单化;最后利用门控循环单元网络(Gated Recurrent Unit, GRU)拟合输入数据,输出各分量的预测值,通过叠加得到最终的风向预测值.

## 1 EEMD-CNN-GRU 混合模型

### 1.1 EEMD 模型

EEMD 本质上是叠加高斯白噪声的多重经验模态分解(EMD)<sup>[9]</sup>.

它先利用频率分布均匀的高斯白噪声的统计特性,通过每次添加的白噪声来改变信号的极值点特征,然后对多个 EMD 得到的对应的基本模态分量(IMF)进行整体平均,以抵消加入的白噪声,从而有效抑制模态混叠的产生.记加入噪声的总次数为  $N$ , EEMD 的步骤如下:

1) 对原始信号  $x(t)$  加一个标准正态分布的白噪声  $n_i(t)$ :

$$x_i(t) = x(t) + n_i(t), \quad (1)$$

其中,  $n_i(t)$  表示第  $i$  次加入的白噪声序列,  $x_i(t)$  表示第  $i$  次实验的附加噪声信号.

2) 对新的信号序列  $x_i(t)$  执行 EMD, 得到  $J$  个模态分量和 1 个残差分量:

$$x_i(t) = \sum_{j=1}^J \text{IMF}'_j + e_i(t), \quad (2)$$

其中,  $\text{IMF}'_j$  和  $e_i(t)$  分别为  $x_i(t)$  由 EMD 产生的第  $j$  个模态分量以及残差分量,  $e_i(t)$  代表信号的平均趋势.

3) 将步骤 1) 和 2) 重复  $N$  次, 得到 IMF 的集合为

$$\{c_{1,j}(t), c_{2,j}(t), \dots, c_{N,j}(t)\}, j = 1, 2, \dots, J. \quad (3)$$

4) 根据不相关序列的统计平均值为零这一原则, 将上述对应的 IMF 进行集合平均运算, 得到 EEMD 的最终分量, 即:

$$c_j(t) = \frac{1}{N} \sum_{i=1}^N c_{i,j}(t), \quad (4)$$

其中,  $c_j(t)$  是 EEMD 的第  $j$  个 IMF.

### 1.2 CNN 模型

作为一类包含卷积计算的前馈神经网络, CNN 是深度学习的代表性算法之一<sup>[10]</sup>. 人工神经元可以响应周围单元, 进行大型数据处理, 它通过数据的转换以及降维将原始输入映射为新的特征. 与标准的全连接网络不同的是, CNN 具有特殊的网络结构, 它包括卷积层和池化层组成的特征提取器, 利用局部连接和权值共享来提取原始数据的特征, 使得网络模型变得简单, 从而加快训练速度、提高泛化性能. 在 CNN 网络中卷积层之后会跟上一个池化层, 其作用是提取局部均值或最大值, 一般常见的多为最大值池化层<sup>[11]</sup>.

本文选用一维卷积神经网络, 将风向建模为一系列时间序列数据. CNN 通过减少权值输入提取时间序列特征, 挖掘数据之间的联系, 再将处理后的特征传入 GRU 网络中.

一维卷积经常用在信号处理中, 以计算信号的

延迟累计. 假设在每个时刻  $t$  都会产生一个信号  $p_t$ , 其衰减系数为  $w_k$ , 即在  $k-1$  个时间延迟后为原来的  $w_k$  倍. 在时刻  $t$  收到的信号  $q_t$  为当前信息和以往信息产生的累加和, 计算公式如下:

$$q_t = w_1 p_t + w_2 p_{t-1} + \dots + w_k p_{t-k+1}. \quad (5)$$

一般把  $w_1, w_2, w_3, \dots$  称为滤波器或者卷积核. 假设滤波器的长度为  $K$ , 它与一个信号序列  $p_1, p_2, p_3, \dots$  的卷积和为

$$q_t = \sum_{k=1}^K w_k p_{t-k+1}. \quad (6)$$

### 1.3 GRU 网络

GRU 是 LSTM 网络的一种变体<sup>[12]</sup>, 其结构更加简单, 而且效果也很好. 因此, GRU 是目前非常流行的一种网络, 可以解决循环神经网络(RNN)中的长依赖问题, 广泛应用于时间序列的预测.

GRU 与 LSTM 具有相似的数据流<sup>[13]</sup>, 但 GRU 缺少单独的存储单元, 使其在训练过程中效率更高. LSTM 引入了输入门、遗忘门和输出门三个门函数, 分别控制输入值、记忆值和输出值. 而在 GRU 模型中只有两个门: 更新门和重置门, 其具体结构如图 1 所示. 在图 1 中,  $z_t$  和  $r_t$  分别表示更新门和重置门. GRU 的输入为前一时刻隐藏层的输出和当前的输入, 输出为下一时刻隐藏层的信息. 重置门计算候选隐藏层的输出, 其作用是控制保留前一时刻的隐藏层的数量. 更新门是控制加入特定数量候选隐藏层的输出信息, 从而得到当前隐藏层的输出.




图 1 GRU 网络基本单元

Fig. 1 Basic unit of GRU network

Sigmoid 函数将数据映射到  $0 \sim 1$ , 用来描述应该传递信息的数量, tanh 函数将值置于  $-1$  和  $1$  之间. GRU 单元的计算公式如下:

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

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]), \quad (8)$$

$$\tilde{h}_i = \tanh(W_{\tilde{h}} \cdot [r_i * h_{i-1}, x_i]), \quad (9)$$

$$h_i = (1 - z_i) * h_{i-1} + z_i * \tilde{h}_i, \quad (10)$$

$$y_i = \sigma(W_{\sigma} \cdot h_i), \quad (11)$$

其中,  $[ ]$  表示两个向量相连,  $*$  表示矩阵的 Hadamard 积,  $\sigma$  为 Sigmoid 函数.

#### 1.4 短期风向预测的 EEMD-CNN-GRU 混合模型

考虑到预测效率和准确率等要求,提出一种基于 EEMD-CNN-GRU 的混合短期风向预测模型.采用集合经验模态分解(EEMD)将数据分解为有限个基本模态分量和 1 个残差分量.卷积神经网络(CNN)具有特征提取能力,挖掘特征向量,从而提升预测性能.门控循环单元网络(GRU)可以学习序列相关性,通过 CNN 和 GRU 的结合得到风向的预测值.

所建立的混合预测模型的流程如下:首先将具有时序特征的数据集作为混合模型的输入;然后对原始风向数据进行归一化处理,并划分出训练集和测试集;最后采用所提出的混合模型进行预测,如图 2 所示.混合模型的网络结构主要分为 3 层:第 1 层为 EEMD,它对原始数据进行分解,提高输入序列的平滑性和可信度;第 2 层为 CNN,通过构造一维卷积层和池化层来提取特征;第 3 层是 GRU,发挥其结构简单、参数较少的优势<sup>[14]</sup>,提高训练速度、缩短训练时间以及预测时间,从而保证混合模型预测的快速性以及准确性.因此,本文提出的 EEMD-CNN-GRU 混合模型采用 EEMD 对数据集进行分解优化,并结合 CNN 预测时间短与 GRU 预测准确性高的特点,优化改进风向的预测.

## 2 实例分析与结果展示

### 2.1 数据来源与分析

选用土耳其 2018 年 4 月的风电场数据进行短期风向预测,采样间隔为 10 min,共 4 305 条数据,得到的风向时间序列如图 3 所示.其中,前 2/3 的数据作为训练集,后 1/3 的数据作为测试集,用前 1 h 风向数据来预测下一时刻的风向,实现风向的滚动预测.为了便于模型训练,在 CNN-GRU 前对数据进行归一化处理,计算方式如下所示:

$$u' = \frac{u - u_{\min}}{u_{\max} - u_{\min}}, \quad (12)$$

其中,  $u$  为原始的数据,  $u_{\min}$  为最小值,  $u_{\max}$  为最大值.

由图 3 可以看出,风向数据具有随机性、不连续性和非平稳性,并发现该风向数据不仅周期性差,而且含有大量的高频分量等,因此需要对所选风向序

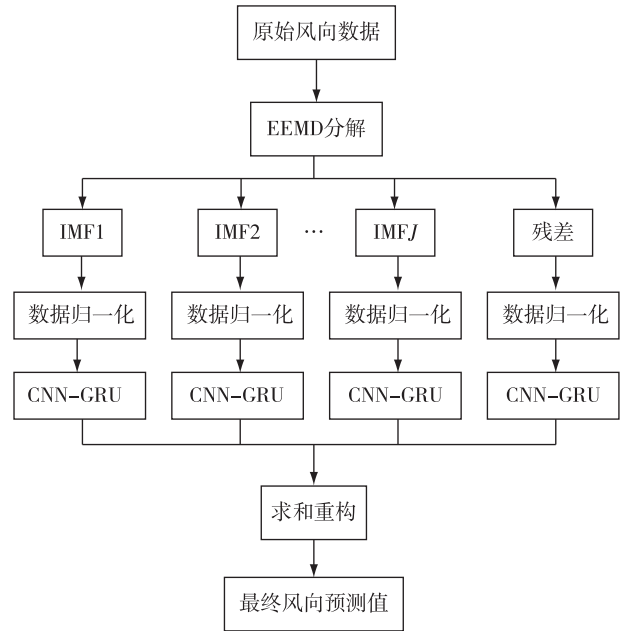


图 2 基于 EEMD-CNN-GRU 的短期风向预测流程

Fig. 2 Flow chart of short-term wind direction prediction via EEMD-CNN-GRU




图 3 风向时间序列

Fig. 3 Time series of wind direction

列进行数据预处理.

### 2.2 误差评价指标

预测结果的误差评价采用均方根误差(Root Mean Squared Error, RMSE)、绝对平均误差(Mean Absolute Error, MAE)和决定系数(R-square,  $R^2$ ),公式如下:

$$e_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{d}_i - d_i)^2}, \quad (13)$$

$$e_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |\hat{d}_i - d_i|, \quad (14)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (d_i - \hat{d}_i)^2}{\sum_{i=1}^n (d_i - \bar{d})^2}, \quad (15)$$

其中,  $\hat{d}_i$  表示时刻  $i$  的预测值,  $d_i$  表示真实值,  $\bar{d}$  表示真实值的平均值,  $n$  为样本数量。

### 2.3 EEMD 风向数据分解

对风向数据集进行 EEMD, 分解成 12 个 IMF 和 1 个残差(Res), 结果如图 4 所示。IMF 反映风向数据在不同影响因素下的分布, 数据逐渐趋于平稳, Res 能够反映风向序列的变化规律, 并且整体的变化趋势比较一致<sup>[15]</sup>。

EEMD 将风向数据进行平稳化处理, 各个 IMF 分量包含了原始序列的不同时间尺度的局部特征信号, 使用 GRU 模型对各分量特征进行单独预测, 从而降低预测难度。

### 2.4 CNN 和 GRU 网络设置

将 EEMD 分解后的数据分别输入 CNN-GRU 模型进行训练, 设置循环步长为 6, 即用前 6 个时刻的数据预测当前数据。CNN 的卷积层个数为 32, 各层都有卷积核, 使用 BN 层对每个神经元做归一化处理, 池化窗口的大小为 1, 激活函数为 ReLU。GRU 的神经元个数分别为 128 和 32, 选用 ReLU 作为激活函数, Adam 作为优化器, 迭代轮数为 100。

### 2.5 实验结果及对比

分别使用 BP 神经网络、LSTM、GRU、CNN-GRU、EMD-GRU、EEMD-GRU、VMD-CNN-GRU、EMD-CNN-GRU、EEMD-CNN-LSTM、EEMD-CNN-GRU 进行仿真实验, 其中 VMD 是变分模态分解<sup>[16]</sup>。对各网络模型进行参数调优, 使用相同的训练集进行训练, 并选取同样的测试集来预测风向, 计算其 RMSE、MAE 以及  $R^2$ , 结果如表 1 所示。通过观察表 1, 可以得到如下结论: 选用模型的  $R^2$  都大于 0.77, 表明这 10 种模型都是有效的, 且 EEMD-CNN-GRU 的 RMSE、MAE 和  $R^2$  表现优异。

为了更好地对比预测结果与原始数据的拟合程度, 对 EEMD-GRU、VMD-CNN-GRU、EMD-CNN-GRU、EEMD-CNN-LSTM、EEMD-CNN-GRU 在同一数据集绘制风向预测曲线, 结果如图 5 所示。为了更直观地对比预测结果, 将局部曲线进行了放大处理。从图 5 可以明显地看出: EEMD-GRU 在峰值区域出现大幅偏差, 而其他 4 种模型则能够较好地接近真实




图 4 EEMD 的结果

Fig. 4 Results of EEMD

曲线。此外, EEMD-CNN-GRU 模型的预测结果不仅在峰值区域与真实值更吻合, 在其他区域与实际变化曲线也比较贴近。其主要原因是风向序列的非平稳性导致 GRU 对原始序列的变化趋势不能很好地预测, 而加入 EEMD 进行分解重构, 并用 CNN 进行转换及降维, 就可以大大缓解此问题, 使得模型的预测精度更高。

在表 1 中, EEMD-CNN-LSTM 与 EEMD-CNN-GRU 的预测性能接近, 且显著优于其他模型。下面比

表 1 不同模型预测结果对比

Table 1 Forecasting performance comparison of different models

模型	RMSE	MAE	$R^2$
BP	35.654 6	16.983 2	0.782 0
LSTM	36.506 4	16.533 4	0.771 5
GRU	36.606 7	18.296 4	0.770 2
CNN-GRU	31.040 2	12.648 2	0.834 8
EMD-GRU	38.304 0	22.450 9	0.748 4
EEMD-GRU	33.407 1	17.129 3	0.808 6
VMD-CNN-GRU	15.964 9	8.488 1	0.956 3
EMD-CNN-GRU	17.833 0	10.544 0	0.945 5
EEMD-CNN-LSTM	12.514 1	6.741 1	0.973 1
EEMD-CNN-GRU	12.414 3	6.647 8	0.973 6




图 5 不同模型的风向预测曲线

Fig. 5 Wind direction curves predicted by different models

较这两种模型在预测阶段的运行时间,结果如表 2 所示.从表 2 可以看出,所提出混合模型的预测时间大约是 EEMD-CNN-LSTM 的 68%,即 EEMD-CNN-GRU 具有较短的计算时间.

表 2 两种模型预测时间对比

Table 2 Prediction time comparison of two models

模型	预测时间/s
EEMD-CNN-LSTM	1 546
EEMD-CNN-GRU	1 051

### 3 结论

为了更好地预测短期风向,本文提出了一种基

于 EEMD-CNN-GRU 的混合风向预测模型.经实验验证,得到以下结论.

1) 对风向序列使用 EEMD,得到更能反映风向序列变化特性的多个模态分量和残差分量,从而降低风向的不平稳性、间歇性和非线性对预测结果的不利影响.

2) 引进 CNN-GRU 混合预测模型,先使用 CNN 提取潜在特征,使数据简单化,再利用 GRU 时序依赖的特性,对输入数据进行拟合,直接输出各分量的预测值,最终通过叠加得到风向预测值.相比于其他的分解预测方法,所提模型降低了预测难度;与 EEMD-CNN-LSTM 相比,EEMD-CNN-GRU 缩短了预测时间.

3) 所提混合模型结合了 EEMD、CNN 和 GRU 各自的特点.实验结果表明,相比于其他预测模型,EEMD-CNN-GRU 的风向短期预测精度较高,验证了模型的可行性以及一定的优越性,为后续风力发电中风向的预测问题提供了一种新的方法.

### 参考文献

#### References

- [1] 侯成伟,单小彪,宋汝君,等.风向自适应型涡激振动压电俘能器的试验研究[J].机械工程学报,2022,58(20):120-127  
HOU Chengwei, SHAN Xiaobiao, SONG Rujun, et al. Experimental study of orientation adaptive piezoelectric energy harvester based on vortex induced vibration [J]. Journal of Mechanical Engineering, 2022, 58 (20): 120-127
- [2] Pearre N, Swan L. Combining wind, solar, and in-stream tidal electricity generation with energy storage using a load-perturbation control strategy [J]. Energy, 2020, 203:117898
- [3] Gaumont M, Réthoré P E, Ott S, et al. Evaluation of the wind direction uncertainty and its impact on wake modeling at the Horns Rev offshore wind farm [J]. Wind Energy, 2014, 17(8):1169-1178
- [4] Zhao S, Wang J W, Han Y X, et al. Research on the rotor speed and aerodynamic characteristics of a dynamic yawing wind turbine with a short-time uniform wind direction variation [J]. Energy, 2022, 249:123580
- [5] 唐振浩,赵赓楠,曹生现,等.一种基于数据解析的混合风向预测算法[J].太阳能学报,2021,42(9):349-356  
TANG Zhenhao, ZHAO Gengnan, CAO Shengxian, et al. A data analytic based hybrid wind direction prediction algorithm [J]. Acta Energiæ Solaris Sinica, 2021, 42(9): 349-356
- [6] Sari A P, Suzuki H, Kitajima T, et al. Short-term wind speed and direction forecasting by 3DCNN and deep convolutional LSTM [J]. IEEJ Transactions on Electrical and

- Electronic Engineering, 2022, 17(11): 1620-1628
- [ 7 ] Chitsazan M A, Fadali M S, Trzynadlowski A M. Wind speed and wind direction forecasting using echo state network with nonlinear functions [ J ]. Renewable Energy, 2019, 131: 879-889
- [ 8 ] 郑祚芳, 范水勇, 高华. 风向偏差角对风机功率预测的影响 [ J ]. 电网与清洁能源, 2022, 38(5): 104-108, 119  
ZHENG Zuofang, FAN Shuiyong, GAO Hua. The influence of wind direction deviation angle on wind power prediction [ J ]. Power System and Clean Energy, 2022, 38(5): 104-108, 119
- [ 9 ] 张瑞成, 曹志新. 基于 EEMD-LSTM 的冷连轧机振动预测研究 [ J ]. 锻压技术, 2022, 47(9): 174-181  
ZHANG Ruicheng, CAO Zhixin. Research on vibration prediction for tandem cold rolling mill based on EEMD-LSTM [ J ]. Forging & Stamping Technology, 2022, 47(9): 174-181
- [ 10 ] Zha W S, Liu Y P, Wan Y J, et al. Forecasting monthly gas field production based on the CNN-LSTM model [ J ]. Energy, 2022, 260: 124889
- [ 11 ] 吴香华, 华亚婕, 官元红, 等. 基于 CNN-Attention-BP 的降水发生预测研究 [ J ]. 南京信息工程大学学报(自然科学版), 2022, 14(2): 148-155  
WU Xianghua, HUA Yajie, GUAN Yuanhong, et al. Application of CNN-Attention-BP to precipitation forecast [ J ]. Journal of Nanjing University of Information Science & Technology ( Natural Science Edition ), 2022, 14(2): 148-155
- [ 12 ] 史加荣, 赵丹梦, 王琳华, 等. 基于 RR-VMD-LSTM 的短期风电功率预测 [ J ]. 电力系统保护与控制, 2021, 49(21): 63-70  
SHI Jiarong, ZHAO Danmeng, WANG Linhua, et al. Short-term wind power prediction based on RR-VMD-LSTM [ J ]. Power System Protection and Control, 2021, 49(21): 63-70
- [ 13 ] 薛阳, 王琳, 王舒, 等. 一种结合 CNN 和 GRU 网络的超短期风电预测模型 [ J ]. 可再生能源, 2019, 37(3): 456-462  
XUE Yang, WANG Lin, WANG Shu, et al. An ultra-short-term wind power forecasting model combined with CNN and GRU networks [ J ]. Renewable Energy Resources, 2019, 37(3): 456-462
- [ 14 ] 王佳钰, 郝思鹏, 李森文, 等. 基于 ES-GRU-LSTM 的风电场群功率预测 [ J ]. 计算技术与自动化, 2022, 41(3): 37-41  
WANG Jiayu, HAO Sipeng, LI Senwen, et al. Power prediction of wind farm group based on ES-GRU-LSTM [ J ]. Computing Technology and Automation, 2022, 41(3): 37-41
- [ 15 ] 徐岩, 向益锋, 马天祥. 基于 EMD-CNN-LSTM 混合模型的短期电力负荷预测 [ J ]. 华北电力大学学报(自然科学版), 2022, 49(2): 81-89  
XU Yan, XIANG Yifeng, MA Tianxiang. Short-term power load forecasting method based on EMD-CNN-LSTM hybrid model [ J ]. Journal of North China Electric Power University, 2022, 49(2): 81-89
- [ 16 ] 韩莹, 王乐豪, 魏平慧, 等. 水库水位的 VMD-CNN-GRU 混合预测模型 [ J/OL ]. 南京信息工程大学学报(自然科学版): 1-11 [ 2022-11-11 ]. <http://kns.cnki.net/kcms/detail/32.1801.N.20221030.1813.002.html>  
HAN Ying, WANG Lehao, WEI Pinghui, et al. VMD-CNN-GRU hybrid prediction model of reservoir water level [ J/OL ]. Journal of Nanjing University of Information Science & Technology ( Natural Science Edition ): 1-11 [ 2022-11-11 ]. <http://kns.cnki.net/kcms/detail/32.1801.N.20221030.1813.002.html>

## Short-term wind direction forecast via EEMD-CNN-GRU

SHI Jiarong<sup>1</sup> GOU Fan<sup>1</sup>

<sup>1</sup> School of Science, Xi'an University of Architecture and Technology, Xi'an 710055, China

**Abstract** To improve the accuracy of short-term wind direction forecasting, a hybrid model, named EEMD-CNN-GRU, is proposed based on Ensemble Empirical Mode Decomposition (EEMD), Convolutional Neural Network (CNN) and Gated Recurrent Unit (GRU). The EEMD is used to decompose the data into multiple components to address the randomness and unsteadiness of wind direction series, then the local connection and weight sharing of CNN are employed to extract the potential features in each component, and the GRU is adopted to reconstruct the extracted features and superpose the predicted values of each component to obtain the final prediction results. The experimental results show that the proposed method outperforms models of BP neural network and long short-term memory (LSTM).

**Key words** wind direction forecasting; ensemble empirical mode decomposition (EEMD); convolutional neural network (CNN); gated recurrent unit (GRU); long short-term memory (LSTM)