

引用格式:黄冬梅,张佳慧,时帅,等.基于爬坡特征与改进PRAA的深远海风电功率短期预测研究[J].电力科学与技术学报,2024,39(3):187-198.

Citation: HUANG Dongmei, ZHANG Jiahui, SHI Shuai, et al. Short-time prediction of long-distance offshore wind power based on ramp characteristics and improved PRAA[J]. Journal of Electric Power Science and Technology, 2024, 39(3): 187-198.

基于爬坡特征与改进 PRAA 的深远 海风电功率短期预测研究

黄冬梅¹, 张佳慧^{1,2}, 时 帅¹, 宋 巍³, 杜伟安⁴

(1. 上海电力大学电气工程学院, 上海 200090; 2. 国网冀北电力有限公司张家口供电公司, 河北 张家口 075000;

3. 上海海洋大学信息学院, 上海 201306; 4. 华能(浙江)能源开发有限公司清洁能源分公司, 浙江 杭州 310014)

摘 要: 深远海海域情况复杂, 海面风速极易受海洋中尺度事件影响。所造成的异常数据点和 Bump 事件将导致爬坡检测准确率下降, 影响深远海风电功率短期预测精度。因此, 提出了一种同时考虑爬坡事件以及深远海气象因素的深远海风电功率短期预测方法。首先, 设计基于状态标记和滑动窗口改进的参数和分辨率自适应算法 (parameter and resolution adaptive algorithm, PRAA) 实现爬坡事件检测并完成特征量提取; 其次, 分析深远海风速、风向及温度等多因素关联关系, 扩充深远海气象因素特征样本维度, 并通过主成分分析法 (principal component analysis, PCA) 深度挖掘潜在特征; 最后, 基于某海上风电场的实测数据, 采用考虑爬坡和深远海气象因素的轻量梯度提升机 (light gradient boosting machine, LightGBM) 算法完成深远海风电功率的短期预测, 仿真结果验证了所提方法的有效性。

关 键 词: 深远海风电; 风电功率爬坡事件; PRAA; 爬坡特征量; 风电功率短期预测

DOI: 10.19781/j.issn.1673-9140.2024.03.021 中图分类号: TM614 文章编号: 1673-9140(2024)03-0187-12

Short-time prediction of long-distance offshore wind power based on ramp characteristics and improved PRAA

HUANG Dongmei¹, ZHANG Jiahui^{1,2}, SHI Shuai¹, SONG Wei³, DU Weian⁴

(1. College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China; 2. Zhangjiakou Power Supply Company,

State Grid Jibei Electric Power Co., Ltd., Zhangjiakou 075000, China; 3. College of Information, Shanghai Ocean University, Shanghai

201306, China; 4. Clean Energy Branch of Huaneng (Zhejiang) Energy Development Co., Ltd., Hangzhou 310014, China)

Abstract: The conditions in long-distance offshore areas are complex, and surface wind speeds are highly susceptible to the influence of mesoscale oceanic events. The resulting anomalous data points and bump events will decrease the accuracy of ramp-up detection, affecting the short-term forecasting precision of offshore wind power in long-distance sea areas. Therefore, a short-term forecasting method for offshore wind power in long-distance sea areas is proposed, which simultaneously considers ramp-up events and long-distance sea meteorological factors. Firstly, an improved parameter and resolution adaptive algorithm (PRAA) based on state marker and sliding window is designed to detect ramp-up events and extract features. Secondly, the correlation of multiple factors such as wind speed, wind direction and temperature in the long-distance offshore is analyzed to expand the dimension of the feature samples of the meteorological factors, and the potential features are deeply explored by principal component analysis (PCA). Finally, based on the measured data of a domestic offshore wind farm, the light gradient boosting machine (LightGBM)

收稿日期: 2023-03-31; 修回日期: 2024-04-25

基金项目: 国家重点研发计划 (2021YFC3101602); 华能集团总部科技项目 (HNKJ20-H66)

通信作者: 时 帅 (1987—), 男, 博士, 讲师, 主要从事风电并网可靠性研究; E-mail: shishuai@shiep.edu.cn

considering ramp-up and meteorological factors in long-distance sea areas is used to complete the short-term prediction of long-distance offshore wind power. Simulation results verify the effectiveness of the proposed method.

Key words: long-distance offshore wind power; wind power ramp-up events; PRAA; ramp-up characteristic quantities; short term prediction of wind power

随着“双碳”目标的提出,以光伏、风电等新能源为主的新型电力系统构建迎来了快速发展,促进了海上风电装机容量的进一步累积增加,但受可使用面积等资源限制,陆上和近海风电逐渐趋于饱和^[1-5]。为满足不断增长的负荷用电需求,突破深远海发电选址以及消纳缺少支撑的难题,研究深远海风电功率预测已经成为当下亟须解决的热点问题。

与近海风电场相比,深远海海域更广,风能资源更加丰富,风速更加稳定^[6-11],但由于受到复杂海洋环境的影响更大,深远海风速、温度等气象因素与近海或陆上相比有明显差异,以爬坡事件为代表的短时大幅度风电功率变化特征事件频发^[12-15],存在着众多作用不明的潜在因素影响着深远海风电功率的预测精度,使得现有的近海风电功率预测方法在面对深远海风电功率预测问题时存在较大误差,难以满足深远海风电功率预测精确度要求。考虑深远海爬坡事件与气象因素影响的风电功率短期预测方法尚缺乏深入研究^[16]。

现有风电功率短期预测方法按照建模机理的不同可分为物理建模方法和数据驱动方法^[17]。物理建模方法主要依据深远海风电场周围的地貌信息,建立风机模型并求解非线性方程组,得到风速风向、输出功率等信息来实现预测。但由于深远海风电场所处环境复杂,功率波动没有固定变化规律,导致风机建模困难、计算量大,难以建立准确的模型实现功率预测^[18]。数据驱动方法主要以数值天气预报信息作为输入数据,直接对数据特征进行分析,深度挖掘气象信息与深远海风电输出功率之间的关系以实现风电功率的准确预测^[18],可以有效避免复杂的物理建模过程。文献[19]提出一种基于气象时段划分的海上风电功率预测方法,针对不同的时段分别采用轻量梯度提升机(light gradient boosting machine, LightGBM)、核密度估计概率预测风电功率,提高预测精度。文献[20]提出一种考虑出力波动的卷积神经网络实现海上风电功率预测模型,针对不同的出力波动类型建立对应的误差修正模型,以此实现更精确的预测。上述文献均在一定程度上提高了预测精度,在近海风电功率预测中具有较高的准确度。然而,面对深远海风电场在

风速、风向等气象因素上的差异以及深远海风电功率爬坡事件,使用上述预测方法的预测误差较大,预测稳定度较差。因此,本文针对深远海风电功率预测中存在的问题与难点,在已有研究基础上进行深入分析。

目前,解决深远海风电功率短期预测问题,主要通过深度挖掘深远海风电功率预测的影响因素,提高爬坡事件的准确识别检测来实现。文献[21]提出一种具有自适应选择特征的小波深度置信算法检测爬坡事件,但由于计算过于复杂导致检测准确率不高。文献[22]提出一种基于旋转门算法(swinging door algorithm, SDA)与趋势标记相结合的风电爬坡事件检测方法,通过趋势标记避免漏检、处理不重要的分段,但由于未考虑所检测出的爬坡事件是否为该时间段内的完整爬坡事件,导致检测稳定性波动大。文献[23]为得到完整的爬坡事件,提出一种动态规划算法改进的旋转门算法(optimized swinging door algorithm, OPSDA),将具有相同爬坡方向和相似爬坡率的子区间进行整合,但由于操作过程并未考虑异常数据点对检测准确性的影响,在检测小幅反向非爬坡事件时的精度不高。

针对以上问题,本文通过考虑爬坡事件与气象因素相关性特征影响提出一种基于改进参数和分辨率自适应算法(parameter and resolution adaptive algorithm, PRAA)检测爬坡事件的深远海风电功率短期预测方法,以提高深远海风电预测的精度,实现深远海风电选址与消纳能力提升、机组组合出力优化以及避免发生大范围停电。该方法首先基于状态标记^[22]以及滑动窗口^[24]PRAA,完成对爬坡事件的检测以及特征量的提取,实现不同状态爬坡事件的快速识别;其次,通过引入风速、风向等气象因素的最值、均值等多维特征,增加训练样本维度,提升数据训练过程特征因素拟合精度;然后,通过相关性、互信息量方法深度挖掘深远海风电功率与潜在影响因素之间的线性/非线性关系,并完成基于主成分分析法(principal component analysis, PCA)的潜在有效特征提取,降低数据的冗余性。最后,基于中国某海上风电场数据,采用LightGBM作为基

础预测工具,验证所提预测方法的有效性与精确性。

1 基于改进 PRAA 的爬坡事件检测

1.1 爬坡事件定义及表征量

由于风速、风向以及温度的影响,风电尤其深远海风电较火电厂在输出功率上存在更剧烈且随机的波动,通常称其为风电爬坡事件。

现有研究中,有关风电爬坡定义共 5 种。本文后续研究均以其中较为常用的定义 1 为例进行分析。

定义 1: 观测时间段 $[t, t + \Delta T]$ 内,末端时刻与初始时刻对应的风电功率差值的绝对值,若其大于阈值则认为在该观测时间段内发生了风电爬坡事件,即

$$|P(t + \Delta T) - P(t)| > \lambda_{\text{val}} \quad (1)$$

式中, $P(t)$ 与 $P(t + \Delta T)$ 分别为 2 个时刻所对应的风电功率; λ_{val} 为人为提前设定好的阈值。

定义 2: 将风电功率最大、最小值的差值与阈值进行比较,若大于阈值,则认为在该观测段内发生了风电爬坡事件,即

$$\max(P[t, t + \Delta T]) - \min(P[t, t + \Delta T]) > \lambda_{\text{dif}} \quad (2)$$

式中, $\max(P[t, t + \Delta T])$ 、 $\min(P[t, t + \Delta T])$ 分别为风电功率最大、最小值; λ_{dif} 为设定的功率阈值。

定义 3: 用观测时间段 $[t, t + \Delta T]$ 内的爬坡率(爬坡率即观测时间段内初始时刻与末端时刻对应的功率差值的绝对值与观测时长 ΔT 之比)与设定的爬坡率阈值进行比较,若爬坡率大于阈值则判断为发生了爬坡事件,即

$$\frac{|P(t + \Delta T) - P(t)|}{\Delta T} > \lambda_{\text{PRR}} \quad (3)$$

式中, λ_{PRR} 为爬坡率阈值。

定义 4: 采用平均功率变化量与阈值进行比较,若超过阈值,则判断为爬坡事件,即

$$\frac{1}{n} \sum_{t_i \in [t, t + \Delta T]} \Delta P(t_i) > \lambda_{\text{sl}} \quad (4)$$

$$\Delta P(t_i) = \frac{1}{2} (P(t_{i+1}) - P(t_{i-1})) \quad (5)$$

式(4)、(5)中, n 为观测时间 ΔT 内功率序列中采样间隔的个数; t_i 为功率时间序列的时间间隔; $\Delta P(t_i)$ 为第 i 个采样间隔的功率变化量; λ_{sl} 为阈值。

上述 4 种定义均直接利用风电功率进行定义,并未考虑噪声的干扰问题,为此提出利用滤波信号

的定义 5。

定义 5: 当滤波绝对值大于阈值,则为爬坡,即

$$P_t^f > \lambda_{\text{fl}} \quad (6)$$

式中, $P_t^f = \text{mean} \{ P_{t+h} - P_{t+h-n_{\text{am}}} ; h = 1, 2, \dots, n_{\text{am}} \}$, h 为平均差分估计量; n_{am} 为最大值; $\text{mean} \{ \cdot \}$ 为平均值; λ_{fl} 为阈值。

本文使用爬坡起止时间、持续时间、爬坡率、幅值变化以及爬坡方向等表征量来描述一次爬坡事件,与现有研究中使用的特征量一致,各个特征量的表示如图 1 所示。

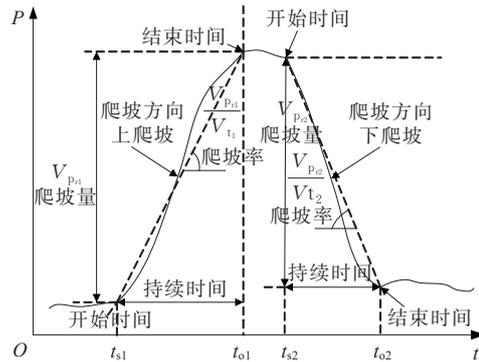


图 1 风电爬坡事件表征量

Figure 1 Characterization of wind power ramp-up events

1.2 基于改进 PRAA 检测爬坡事件

文献[25]将爬坡过程中相邻的同向趋势中小幅度反方向的趋势段称为 Bump 事件。如图 2 中 bc 段即为一个 Bump 事件,若 ab 段和 cd 段均满足爬坡定义,则使一次完整的爬坡事件 ad 分割成 2 个小的爬坡事件,从而造成多检;若 ab 段和 cd 段均不满足爬坡定义,但在时间间隔内 ad 段满足爬坡定义,则因 Bump 事件造成爬坡事件的漏检。为此,本文提出基于状态标记以及滑动窗口 PRAA。通过对经过 PRAA 压缩后的数据集中各数据点按照所处爬坡段的状态进行分类标记,采用滑动窗口完成最终爬坡事件的动态检测。

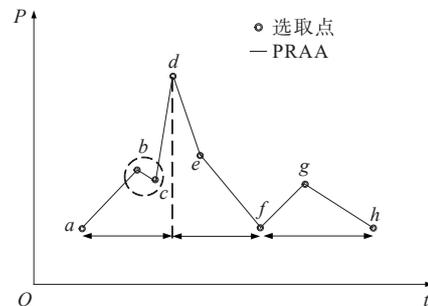


图 2 基于 PRAA 的爬坡检测

Figure 2 The ramp-up events detection based on PRAA

1.2.1 PRAA 检测爬坡事件

SDA通过不断构造平行四边形或三角形,保留平行四边形或三角形上及以外的数据点,忽略所构造图形内的数据点,起到一种趋势化压缩数据的作用。PRAA则是对SDA的改进,即将SDA与异常算法相结合,也可称之为异常旋转门算法^[26]。在对原数据进行趋势化拟合的同时对异常数据点进行处理,既进行了数据的预处理、保留了原数据的变化趋势,又减少了数据的储存量,提高了计算速度。SDA的检测公式为

$$V_{lb} < V_c < V_{ub} \quad (7)$$

$$V_{ub} = V_o + \frac{(\varepsilon + V_g - V_o)(t_c - t_o)}{t_g - t_o} \quad (8)$$

$$V_{lb} = V_o + \frac{(-\varepsilon + V_g - V_o)(t_c - t_o)}{t_g - t_o} \quad (9)$$

式(7)~(9)中, V_c 为原始风电功率数据; V_{ub} 为上边界; V_{lb} 为下边界; V_o 为起点的信号幅值; ε 为旋转门的门宽限值; V_g 为门点的信号幅值; t_g 为门点的时刻; t_c 为当前时刻; t_o 为起始点的时刻。

设 $P = ((t_1, y_1), (t_2, y_2), \dots, (t_n, y_n))$ 为原始风电功率时间序列, y_i 为第 i 个时刻所对应的实际风电功率数据, $i = 1, 2, \dots, n$ 。

$P^{PRAA} = ((T_1, Y_1), (T_2, Y_2), \dots, (T_s, Y_s), \dots, (T_m, Y_m))$ 即为经过 PRAA 压缩后的风电功率数据集, 其中 Y_s 为时刻 s 所对应的压缩后的实际风电功率, $s = 1, 2, \dots, m$, m 为压缩后的总数据量 ($m < n$)。所得到的经过处理后的数据集 P^{PRAA} 代表了原始数据的趋势, 通过爬坡定义 1 对数据集 P^{PRAA} 中每 2 个数据点进行判断, 即可进行初步的爬坡检测。

1.2.2 基于状态标记的爬坡事件检测

将数据集 P^{PRAA} 中的数据点, 按照所处的状态将其分为上升、平稳、下降, 如图 3 所示。

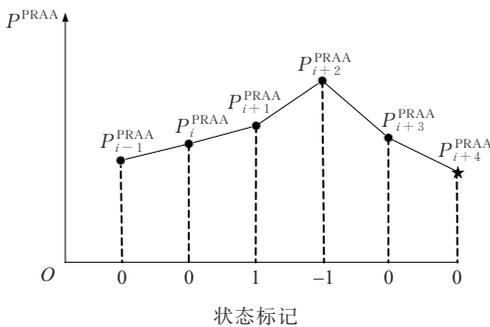


图 3 基于数据点状态分类的爬坡事件检测

Figure 3 The ramp-up events detection based on data points state classification

$$S_i = \begin{cases} 1, & P_i^{PRAA} < P_{i+1}^{PRAA}, \Delta P_i^{PRAA} > M_{up} \\ 0, & |\Delta P_i^{PRAA}| \leq M_{discontinuous} \\ -1, & P_i^{PRAA} > P_{i+1}^{PRAA}, \Delta P_i^{PRAA} < -M_{down} \end{cases} \quad (10)$$

式中, P_i^{PRAA} 即为 i 时刻所对应压缩后的风电功率数据, $\Delta P_i^{PRAA} = P_{i+1}^{PRAA} - P_i^{PRAA}$ 为功率变化量; M 为阈值, 一般设定为额定容量的 50% 或上爬坡取额定容量的 20%, 下爬坡取 15%, M_{up} 为上爬坡阈值, M_{down} 为下爬坡阈值; $M_{discontinuous}$ 为上爬坡或下爬坡阈值。

当某数据点与下一个数据点之间为上升趋势, 且幅值变化满足上爬坡定义则将该数据点标记为 1; 若为下降趋势, 则标记为 -1; 其余不满足爬坡定义的数据点全部标记为 0。为保证数据点状态标记的完整性, 使每一个数据点都有与之对应的状态, 本文将最后一个点规定为处于平稳状态的点, 标记为 0, 在图 3 中用星号标出。

1.2.3 基于滑动窗口的爬坡事件检测

为了较准确地检测完整的爬坡事件, 尽量避免漏检以及多检, 本文采用某一相对固定宽度的时间窗口 Δt 进行滑动式扫描, 已有文献表明, 一般爬坡持续时间为 4 h, 因此本文选取滑动窗口为 4 h^[27], 如图 4 所示, 借此来完成完整爬坡事件的最终检测, 具体检测流程如下。

1) 以固定时间窗口 Δt 检测当前时刻 t 所对应的风电功率变化, 若满足定义 1, 则判断 $t - \Delta t$ 时刻为一个爬坡事件的起始时刻 t_{start} 。

2) 若相邻的下一数据点仍满足定义 1, 则将其合并为同一个爬坡事件, 起始时刻仍为 t_{start} , 即 $t - 2\Delta t$ 。

3) 重复步骤 2), 直到当前时刻 t_s 所对应的风电功率波动满足:

$$|P(t_s + \Delta t) - P(t_s)| < \lambda_{val} \quad (11)$$

则判断为当前爬坡事件结束, 此时所对应的时刻 t_s 即为这一完整爬坡事件的终止时间 t_{end} 。

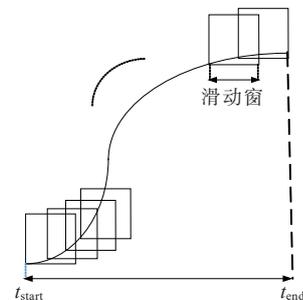


图 4 滑动窗检测示意图

Figure 4 Sketch of sliding window detection

通过上述滑动窗口,即可得到若干个相对完整的风电功率爬坡事件,从而可以提取或计算出对应各完整爬坡事件的起止时间、爬坡率、持续时间等表征量。为后期分析深远海风电功率预测的影响因素提供了多个可参考特征,更能从多方面挖掘深远海风电功率与海洋气象因素之间的关系,以有效提取特征,提高短期深远海风电功率预测精度。

2 基于相关性分析和PCA提取有效特征

深远海所处地理环境特殊,除上述爬坡事件对深远海风电功率有影响外,海洋风速、风向以及温度等气象因素也需考虑在内^[28]。其中,风速、风向虽相较近海相对稳定,但海上大风则是海洋危害性较大的气象因素,往往作用在水面上形成风暴潮、灾害性海浪等^[29]。另外,海水的温度普遍低于大陆且温度差较小,冬季海洋温度高于陆地,夏季则相反。为了更准确地挖掘深远海风电功率与潜在影响因素之间的关系,考虑深远海与近海在气象方面的差异,本文选取对风电功率预测影响较大的风速、风向以及温度等核心数据,除了将其原数据作为特征外,引入平均值、最大值、最小值、方差以及差值等特征,增加了训练样本数据;之后采用相关性、互信息量分析深远海风电功率与各特征之间的线性/非线性关系;最后,通过PCA降维,提取影响深远海风电功率预测的有效特征,将与风电功率相关程度低的维度剔除,降低数据的冗余性,以此减少训练数据大小,加快模型训练速度;减少模型复杂度,避免过拟合,提高深远海风电功率预测的准确性。

2.1 相关性分析

以文2中检测到的所有爬坡事件的表征量作为相关性分析的特征量,得到爬坡事件对应的向量矩阵为

$$A = \begin{bmatrix} R_{RR1} & R_{RM1} & R_{RD1} & R_{RS1} & R_{RE1} \\ R_{RR2} & R_{RM2} & R_{RD2} & R_{RS2} & R_{RE2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ R_{RRm} & R_{RMm} & R_{RDm} & R_{RSm} & R_{REm} \end{bmatrix} \quad (12)$$

式中, m 为最终检测得到的完整爬坡事件总数; R_{RR} 为爬坡率; R_{RM} 为爬坡幅值; R_{RD} 为爬坡持续时间; R_{RS} 为爬坡开始时间; R_{RE} 为爬坡结束时间。

与之对应进行相关性分析的气象数据表示为

$$W_H = [\mathbf{w}_{H1} \quad \mathbf{w}_{H2} \quad \cdots \quad \mathbf{w}_{Hq}] \quad (13)$$

式中, q 为风速、温度、风向等气象指标的总数; \mathbf{w}_{H1} 、 \mathbf{w}_{H2} 、 \mathbf{w}_{H3} 等分别为风速、风向以及温度的平均值、最大值以及差值。

基于式(12)、(13),则可以通过线性相关性系数 ρ_{ij} 表征两者之间的线性相关程度,如下:

$$\rho_{ij} = \frac{\text{cov}(\mathbf{a}_j, \mathbf{w}_{Hj})}{\sqrt{D(\mathbf{a}_j)} \cdot \sqrt{D(\mathbf{w}_{Hj})}} \quad (14)$$

式中, \mathbf{a}_j 为爬坡事件特征矩阵 A 中的第 j 列向量; $\text{cov}(\cdot)$ 为2个向量之间的协方差; $D(\cdot)$ 表示向量的方差; ρ_{ij} 的取值范围为 $[0, 1]$,该值的绝对值越大,则说明2个向量之间的线性相关程度越大。

2.2 互信息量分析

互信息(mutual information, MI)是基于信息熵理论来表示2个或多个系统间的非线性关系的信息度量法^[30]。本文相继使2种方法,深度挖掘爬坡事件特征量与气象指标之间的关系,提取最有效的气象特征,便于后期提高深远海风电功率预测精度。

该方法将熵作为量化信息的度量,主要利用概率统计的方法,具体计算公式如下:

$$I_{xy} = \int \int p_c(x, y) \ln \left(\frac{p_c(x, y)}{p(x)p(y)} \right) dx dy \quad (15)$$

式中, x 、 y 分别为第 i 个爬坡所对应的特征量和第 j 个气象指标的向量; $p_c(x, y)$ 为 x 和 y 的联合概率密度; $p(x)$ 、 $p(y)$ 分别为 x 、 y 的边缘概率密度。 I_{xy} 反映了2个变量之间相关度的大小,若 I_{xy} 数值越大,则2个变量之间的相关性越大,反之仍成立。

2.3 提取有效特征

在建立深远海风电功率预测模型时,过多的特征将导致内存需求的增加和欠拟合风险,从而影响模型预测的泛化能力。此外,由于高维数据包含大量冗余特征,如果不做去冗余处理而直接用于模型训练,将会加剧模型训练的复杂度,影响模型学习效果。

为解决以上问题,本文通过使用PCA将原始数据投影到低维空间,忽略非关键成分的同时保留含信息量较大的成分,从而去除噪声和冗余特征影响,实现对高维数据的降维处理。通过PCA降维处理后的数据,不仅可以精简数据维度,还能够降低噪声和冗余特征带来的干扰,更好地满足模型学习的需求,从而提高深远海风电功率预测的准确性。一般情况下,新的低维特征向量将由累计贡献率达到90%的主成分组成^[6]。

3 基于爬坡特征与改进PRAA的深远海风电功率短期预测方法

3.1 建立预测模型

本文综合考虑爬坡事件以及多气象因素对深远海风电功率的影响,提出通过状态标记以及滑动窗口改进PRAA来尽可能检测到完整爬坡事件;进而分析深远海风电功率与潜在影响因素之间的关系,最终PCA提取有效特征并通过LightGBM实现深远海风电功率的预测,提高深远海风电功率的预测精度,本文整体思路的基本框架如图5所示。

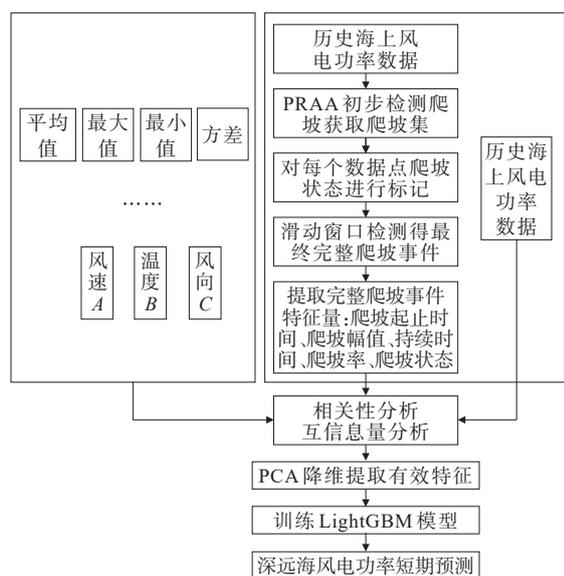


图5 模型基本框架

Figure 5 Basic framework of model

基于爬坡特征与改进PRAA的深远海风电功率短期预测流程描述如下。

1) 针对因异常数据点与Bump事件造成爬坡事件多检、漏检的问题,本文提出基于状态标记以及滑动窗口改进PRAA检测爬坡事件,分别对经过PRAA初次检测出的每个数据点进行1、-1、0标记,随后采用4h的滑动窗口进行最终完整爬坡事件的检测,提取爬坡表征量,实现不同状态爬坡事件的快速识别。

2) 深远海风电场受海洋环境影响,其风速、风向和温度相较于陆地上有明显差异。如冬季海水温度高于陆地或近海,低气压的存在导致风由陆地吹向海洋,夏季则相反。针对这一问题,本文考虑利用特征工程将风速、风向以及温度的方差、平均值、最大值、最小值以及前后数据之间的差值等多个特征引入,增加训练样本维度,提升数据训练过程特征因素拟合精度。

3) 通过相关性、互信息量方法深度挖掘深远海风电功率与潜在影响因素之间的线性/非线性关系,并完成基于PCA的潜在有效特征提取,降低数据的冗余性。

4) 将降维后得到的特征作为LightGBM的输入,实现最终的深远海风电功率短期预测。

5) LightGBM也可以称为改进的梯度提升决策树算法(gradient boosted decision tree, GBDT),是集成学习算法的一种,其核心思想是将容易得到的弱学习器经过反复训练并组合提升为强学习器,可表示如下:

$$F(x) = \sum_{m=1}^M f_m(x) \quad (16)$$

式中, $F(x)$ 为最终的输出值; $f_m(x)$ 为第 m 个弱学习器的输出值。

6) 以中国某海上风电场为例,将本文的预测结果和其他方法的预测结果进行对比,通过误差指标分析验证本文所提预测方法的有效性。

3.2 评价指标

常用的评价指标有:均方误差(mean square error, MSE)、平均相对误差(mean relative error, MRE)、平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)、平均绝对百分比误差(mean absolute percentage error, MAPE)等,其中MSE、MRE、MAE以及RMSE用得最多,将上述4个常用指标用公式表示为

$$e_{\text{MSE}} = \frac{\sum e_i}{nP} \quad (17)$$

$$e_{\text{MRE}} = \frac{\sum \left| \frac{e_i}{y_i} \right|}{n} \quad (18)$$

$$e_{\text{MAE}} = \frac{\sum |e_i|}{nP} \quad (19)$$

$$e_{\text{RMSE}} = \frac{1}{P} \sqrt{\frac{\sum e_i^2}{n}} \quad (20)$$

式(17)~(20)中, y_i 为实测数据序列; P 为风电场单台风机额定容量; n 为样本数量; e_i 为预测绝对误差, $e_i = y'_i - y_i$, y'_i 为预测数据序列。

由于误差有正负之分,则有可能出现正负相抵的情况,此时若单独用MSE来评价预测模型,可能会出现数值较小的情况,导致对预测效果的错误判断,因此MSE不适合单独作为评价指标,需要与其他指标相互配合使用^[31]。另外,由于风电出力具有波动性、间歇性极大的特点,当用MRE来评价预测模型时,很有可能出现因实际风电出力为0而导

致相对误差很大使 MRE 失去评价意义的情况,所以一般将 MRE 用于负荷预测的评价指标。综上,MAE 与 RMSE 由于不存在正负相互抵消的问题且易于计算,通常被用来作为风电功率预测模型的评价指标。其中,RMSE 一般表示模型效果的分散程度, e_{RMSE} 越小,该模型预测效果越好;MAE 用来表示平均水平, e_{MAE} 越小,则效果越好。

4 算例分析

由于所处季节不同,深远海气象因素与爬坡事件均具有不同的特性。考虑风场由多台风机构成,且每台风机之间互相影响,为了更好地验证所提方法的有效性,本文选取中国某海上风电场某单台风机以及整个风场某年 3 月、8 月、12 月的数据作为典型月分别代表春秋季节、夏季以及冬季,以提前预测 24 h 为例进行分析研究。该风电场中单台风机装机容量为 3 MW,总装机容量为 102 MW,所用数据采集时间分辨率为 10 min。

4.1 爬坡事件检测

为准确预测短期深远海风电功率,本文综合考虑多气象因素与爬坡事件对深远海风电功率的影响,提取有效特征进行预测。为完成以上步骤,首先以海上风电场中单台风机为例进行爬坡事件的检测。将 3 个月的风电功率数据经 PRAA 得到数据集 P^{PRAA} ,分别按照定义 1 直接爬坡检测以及通过本文的改进 PRAA 进行检测,2 次检测的结果统计见表 1。

表 1 滑动窗前后检测爬坡事件对比

Table 1 Comparison of the ramp-up events before and after sliding window

月份	模型	上爬坡/次	下爬坡/次	总爬坡/次
3 月	前	34	52	86
	后	51	58	109
8 月	前	32	21	53
	后	41	33	74
12 月	前	40	26	66
	后	39	25	64

从表 2 可以得知,无论采用哪种爬坡检测方法,爬坡事件在深远海风电场的单台风机中发生频率都较高,因此对深远海风电功率预测的影响不容忽视;同时,通过数据对比可知以 3 月为代表的春秋季节发生爬坡事件的频率高于夏、冬季。

由于数目过多且各月份爬坡检测图类似,本文后续研究均以爬坡事件较多的 3 月份为代表进行研

究。图 6 所示为 3 月份风电功率数据经原始 PRAA 压缩后风电功率的部分曲线。图 7 为 3 月份经改进 PRAA 处理后得到的部分爬坡事件图,爬坡阈值中上爬坡阈值取单机额定装机容量的 20%,即 600 kW;下爬坡阈值取 15% 的额定装机容量,即 450 kW。最终检测出的爬坡事件提取特征量部分统计结果见表 2。由表 2 可得,爬坡事件虽然持续时间较短,但功率变化明显,对深远海风电功率短期预测准确性影响不容忽视。

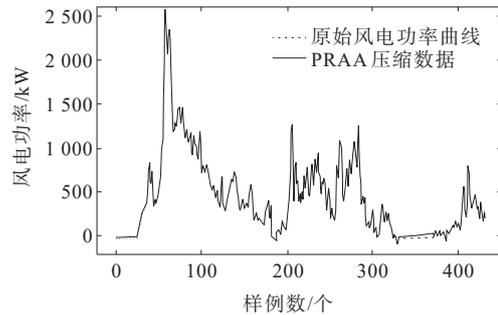


图 6 3 月基于 PRAA 提取的部分风电功率曲线

Figure 6 Partial wind power curve based on the PRAA extraction in March

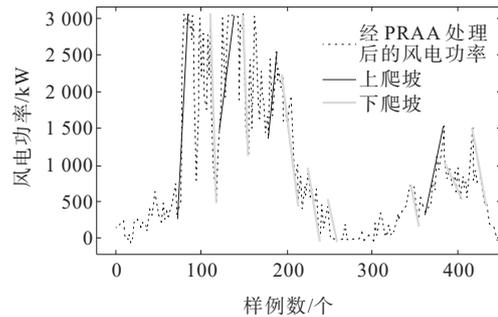


图 7 3 月最终检测出的部分爬坡曲线图

Figure 7 Partial ramp-up curves finally detected in March

表 2 3 月爬坡事件特征值的部分统计结果

Table 2 Partial statistical results of the ramp-up events characteristic values

滑动窗 前后爬 坡事件	爬坡 方向	爬坡状 态标记 (0,1,-1)	爬坡持 续时 间/min	爬坡率/ (kW·min ⁻¹)	幅值变 化/kW
1	↑	1	110	25.086 030 2	2 759.463 32
2	↓	-1	60	-42.353 776 7	-2 541.226 6
3	↑	1	160	9.731 328 1	1 557.012 5
4	↓	-1	50	-38.033 556	-1 901.677 8
5	↑	1	80	14.586 711 25	1 166.936 9
6	↓	-1	190	-9.302 005 263	-1 767.381
7	↓	-1	100	-5.451 174 13	-545.117 413
8	↓	-1	80	-6.677 217 5	-534.177 4
9	↑	1	200	5.976 594 6	1 195.318 92
10	↓	-1	180	-2.636 47	-474.564 6

4.2 最终模型功率预测结果验证

处理后的气象特征、爬坡特征量以及原始风电功率等特征通过相关性、互信息量分析得到的热力图如图8、9所示。其中,A、B、C、D分别表示风速、风向、温度以及风电功率,引入的平均值、最大值、最小值以及差值分别用下标 mean、max、min 以及

var表示,颜色越深则两者之间的相关程度越高,反之越低。综合可知,风电功率与瞬时风速、平均风速以及风速最大、最小值相关程度最高,均可达到0.8左右,且与爬坡率、爬坡幅值等爬坡特征量之间存在一定的相关性。有效说明深远海风电功率与爬坡事件和深远海气象之间存在密切的相互影响关系。

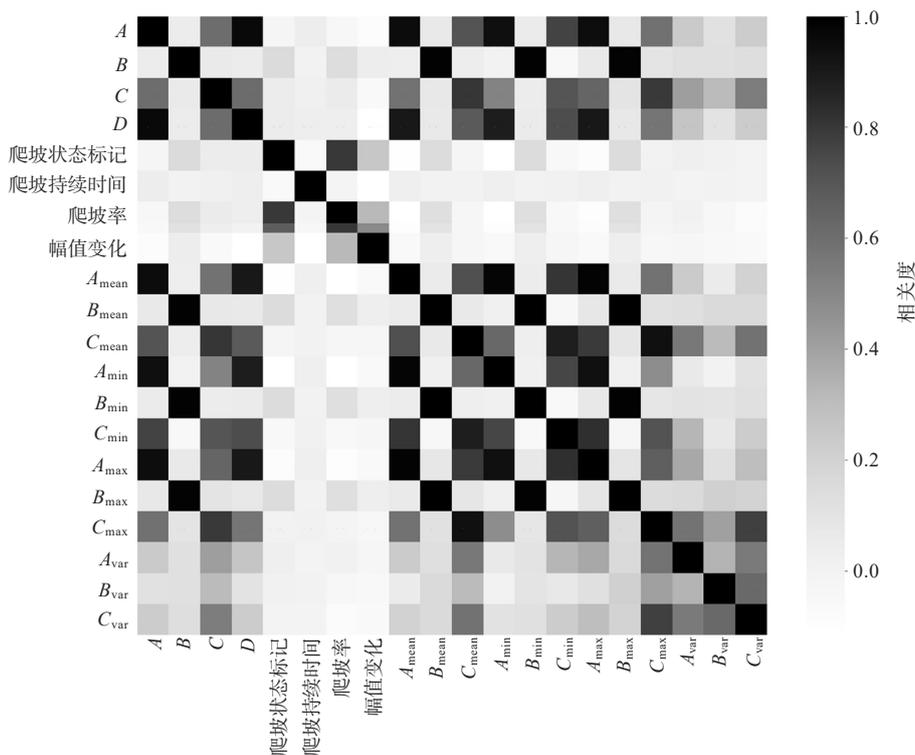


图8 相关性分析热力图

Figure 8 Correlation analysis heat map

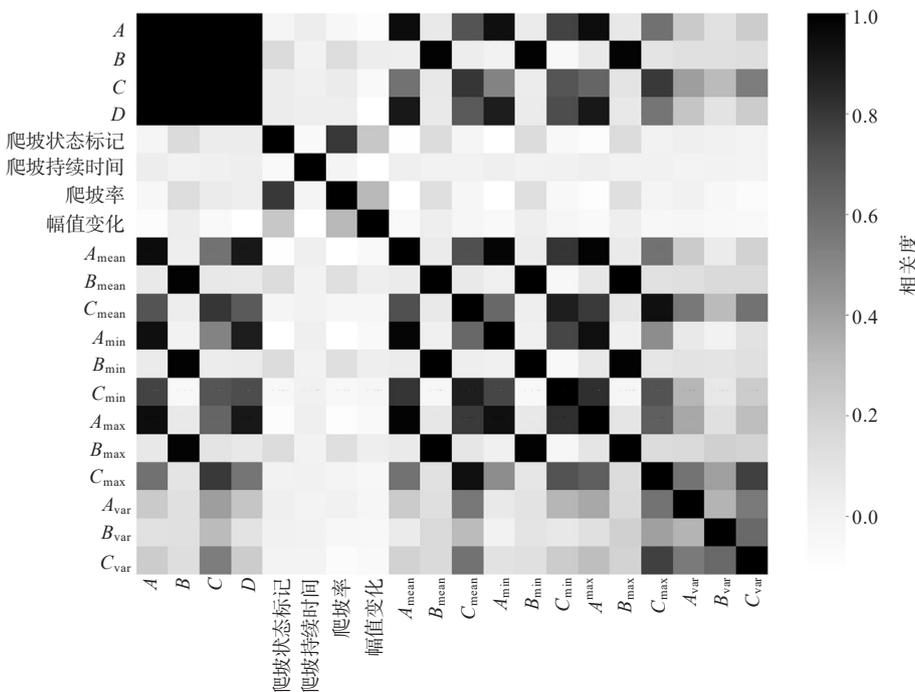


图9 互信息量分析热力图

Figure 9 Mutual information quantitative analysis heat map

经过上述过程引入爬坡特征量以及风速、风向的均值、平均值等容易因为维度的增加导致数据冗余,预测精度下降。为此,本文采用 PCA 提取有效特征,选取前 2 个主成分作为降维结果,所得各主成分贡献率见表 3。

随后利用 Python 平台调用 LightGBM 机器学习库来进行 24 h 深远海风电功率预测。为了定量评价本文所提方法的预测效果,使用 RMSE、MAE 和 ρ_{ij} 进行误差分析。为进一步验证所提方法的有效性,本文分别采用 PCA 降维前后预测以及不经过特征工程处理直接预测 3 种方法进行对比,最终单台风机以及整个风电场各个月份不同模型的预测结果如表 4~9 以及图 10~15 所示。

表 3 各主成分贡献率

Table 3 Contribution rate of each principal component

主成分	贡献率/%	累计贡献率/%
第一主成分	91.483 00	91.480 0
第二主成分	7.668 00	99.140 0
第三主成分	0.809 80	99.949 8
第四主成分	0.033 29	99.983 1

表 4 3 月单风机预测结果对比

Table 4 Comparison of prediction results of single fan in March

模型	MAE	RMSE	ρ_{ij}
LightGBM 模型	5.69	7.68	0.27
未经 PCA 降维预测模型	1.83	2.70	0.91
本文所提预测模型	1.65	2.46	0.93

表 5 8 月单风机预测结果对比

Table 5 Comparison of prediction results of single fan in August

模型	MAE	RMSE	ρ_{ij}
LightGBM 模型	6.51	7.04	0.36
未经 PCA 降维预测模型	4.98	6.36	0.45
本文所提预测模型	2.32	2.83	0.89

表 6 12 月单风机预测结果对比

Table 6 Comparison of prediction results of single fan in December

模型	MAE	RMSE	ρ_{ij}
LightGBM 模型	1.31	1.93	0.94
未经 PCA 降维预测模型	2.48	3.16	0.87
本文所提预测模型	1.08	1.58	0.97

表 7 3 月整个风场预测结果对比

Table 7 Comparison of overall prediction results of wind farm in March

模型	MAE	RMSE	ρ_{ij}
LightGBM 模型	3.81	3.22	0.41
未经 PCA 降维预测模型	3.13	2.82	0.29
本文所提预测模型	2.92	2.62	0.88

表 8 8 月整个风场预测结果对比

Table 8 Comparison of overall prediction results of wind farm in August

模型	MAE	RMSE	ρ_{ij}
LightGBM 模型	2.81	3.77	0.29
未经 PCA 降维预测模型	2.73	3.27	0.55
本文所提预测模型	2.28	2.79	0.63

表 9 12 月整个风场预测结果对比

Table 9 Comparison of wind prediction results of wind farm in December

模型	MAE	RMSE	ρ_{ij}
LightGBM 模型	1.21	2.32	0.46
未经 PCA 降维预测模型	1.81	2.96	0.52
本文所提预测模型	1.11	2.16	0.68

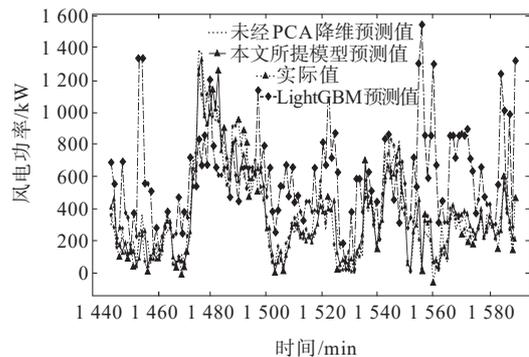


图 10 3 月单风机预测结果对比

Figure 10 Comparison of forecast results of single fan in March

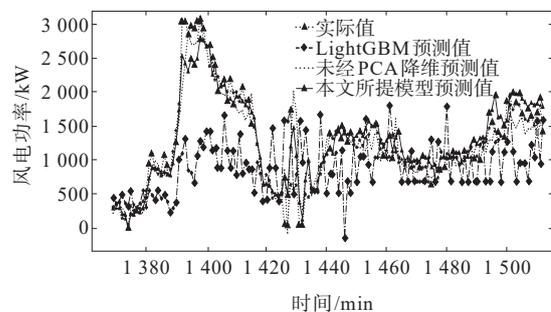


图 11 8 月单风机预测结果对比

Figure 11 Comparison of forecast results of single fan in August

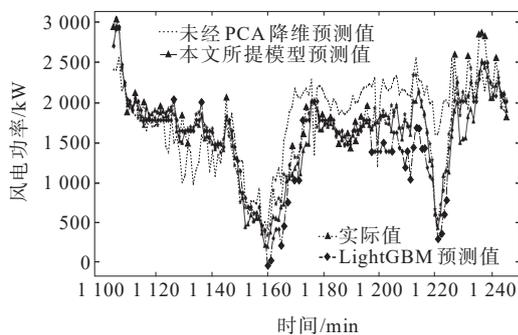


图12 12月单风机预测结果对比

Figure 12 Comparison of forecast results of single fan in December

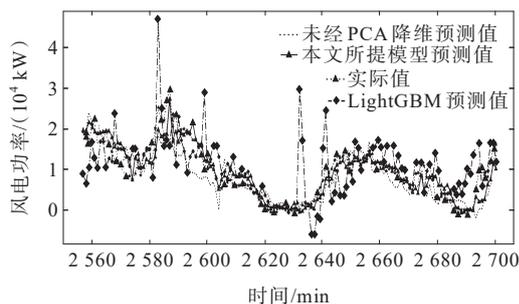


图13 3月整个风电场预测结果对比

Figure 13 Comparison of forecast results of wind farm in March

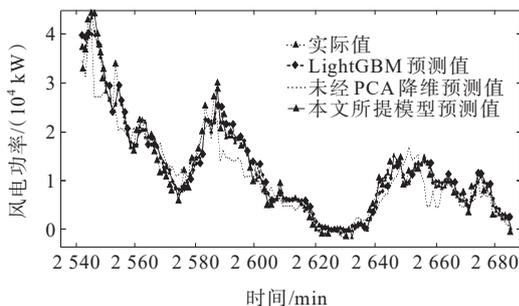


图14 8月整个风电场预测结果对比

Figure 14 Comparison of forecast results of wind farm in August

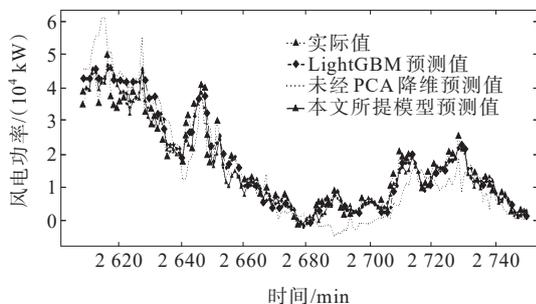


图15 12月整个风电场预测结果对比

Figure 15 Comparison of forecast results of wind farm in December

本文所提出的预测方法较未考虑多影响因素直接预测以及未经PCA降维预测均有较好的拟合

效果,尤其在爬坡事件较多的3月,相较直接预测,MAE值下降4.04%,RMES下降了5.22%,线性相关系数提升0.66;且相较未经PCA降维预测,各个评价指标均有一定程度的提高。说明考虑深远海风电功率与潜在影响因素之间的关系并采用PCA降维提取有效特征预测,对于提高预测精确度是有效的,也进一步验证了本文所提方法具有较高的预测准确性,尤其在对于深远海复杂气象影响出现的功率波动时仍然具有较理想的预测效果。

另外,对比表4~6可得出,传统直接预测时,虽然以12月为代表的冬季有较好的预测效果,但是其他月份预测效果较差,更加突出了本文预测方法在以3个月份为代表的春秋、夏、冬季各个时间区间内,相较其他2种方法均具有较稳定的预测效果。综上可以得出,该方法对于多气象因素对风电功率影响原因复杂、深远海特征事件频发的深远海风电场单台风机电功率短期预测具有较稳定、较好的预测效果。

本文所提方法不仅对深远海风电场中单台风机具有良好的预测性能,对整个风电场亦可保持较高的准确性和适用性。但是,对比单台风机以及整个风场3个指标的结果可知,单台风机相较整个风场具有更好的效果。进一步验证了本文所提出的同时考虑完整爬坡事件以及深远海气象因素的深远海风电功率短期预测方法的普适性。同时,也说明了单台风机相较整个风场在预测时忽略了机组之间的影响,因此具有更高的准确性和稳定性。

5 结语

为了提高深远海风电功率短期预测精度,本文提出一种考虑爬坡特征与深远海气象特征的改进PRAA的深远海风电功率短期预测方法,并基于某海上风电场的实测数据对本文所提方法进行验证。

1) 通过引入深远海中尺度事件对爬坡多检、漏检的影响因素,本文提出的基于状态标记以及滑动窗口改进传统的PRAA能够有效地提升对不同状态爬坡事件的快速准确识别能力,并实现爬坡特征量的有效提取。

2) 通过分析深远海气象因素关联特征,本文通过扩充深远海气象因素特征维度及PCA降维方法能深度挖掘潜在在深远海气象特征,提高深远海风电功率短期预测精度。

3) 根据上述特征提取因素,通过改进型的混合

算法组合应用于深远海这一新的场景下,并通过算例与其他方法进行对比,验证了本文所提方法对于考虑爬坡事件与气象因素影响的深远海风电功率短期预测具有良好预测效果,为深远海风电的大规模发展提供技术支撑。

未来工作可考虑中尺度涡、台风等因素对深远海风电功率的影响,另外还可以进一步研究本文所提方法对中长期功率预测的适用性。

参考文献:

- [1] 祁和生. 深远海域风电技术——海上风电新的制高点[J]. 太阳能,2018(6):5.
QI Hesheng. Deep sea wind power technology is the new commanding point of offshore wind power[J]. Solar Energy,2018(6):5.
- [2] 孙丽平,易晓亮,宋子恒. 我国海上风电发展面临的挑战和相关建议[J]. 中外能源,2022,27(11):30-35.
SUN Liping, YI Xiaoliang, SONG Ziheng. Challenges and suggestions for development of offshore wind power in China[J]. Sino-Global Energy,2022,27(11):30-35.
- [3] 王帅,任军辉,姜彦涛,等. ± 525 kV/2 GW海上风电柔性直流送出系统海上换流站设备选型探讨[J]. 高压电器,2022,58(7):11-17.
WANG Shuai, REN Junhui, LOU Yantao, et al. Discussion on equipment selection of offshore converter station of ± 525 kV/2 GW offshore wind power flexible DC transmission system[J]. High Voltage Apparatus,2022,58(7):11-17.
- [4] 李战龙,王祥君,王海云,等. 基于直流风电机组的风电全直流输电系统综述[J]. 电测与仪表,2022,59(12):14-24.
LI Zhanlong, WANG Xiangjun, WANG Haiyun, et al. Review of wind power ALL-DC transmission system based on DC wind turbine[J]. Electrical Measurement & Instrumentation,2022,59(12):14-24.
- [5] 俞露杰,付子玉,朱介北,等. 远海风电DRU-HVDC送出系统构网控制与启动方法综述[J]. 电力系统自动化,2023,47(24):63-79.
YU Lujie, FU Ziyu, ZHU Jiebei, et al. Review on grid-forming control and start-up method of diode-rectifier-unit based HVDC transmission system for remote offshore wind farm[J]. Automation of Electric Power Systems,2023,47(24):63-79.
- [6] 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.
- [7] 高晨,赵勇,汪德良,等. 海上风电机组电气设备状态检修技术研究现状与展望[J]. 电工技术学报,2022,37(S1):30-42.
GAO Chen, ZHAO Yong, WANG Deliang, et al. Research status and prospect of condition based maintenance technology for offshore wind turbine electrical equipment[J]. Transactions of China Electrotechnical Society,2022,37(S1):30-42.
- [8] 李国庆,徐亚男,江守其,等. 海上风电经柔性直流联网系统受端交流故障穿越协调控制策略[J]. 电力系统保护与控制,2022,50(7):111-119.
LI Guoqing, XU Yanan, JIANG Shouqi, et al. Coordinated control strategy for receiving-end AC fault ride-through of an MMC-HVDC connecting offshore wind power[J]. Power System Protection and Control, 2022, 50(7):111-119.
- [9] 高小童,秦志龙,高新宇. 含海上风电—光伏—储能的多能源发输电系统可靠性评估[J]. 发电技术,2022,43(4):626-635.
GAO Xiaotong, QIN Zhilong, GAO Xinyu. Reliability evaluation of multi-energy generation and transmission system with offshore wind power-photovoltaic-energy storage[J]. Power Generation Technology, 2022, 43(4):626-635.
- [10] 陈鸿琳,刘新苗,余浩,等. 基于近似动态规划的海上风电制氢微网实时能量管理策略[J]. 电力建设,2022,43(12):94-102.
CHEN Honglin, LIU Xinmiao, YU Hao, et al. Real-time energy management strategy based on approximate dynamic programming for offshore wind power-to-hydrogen microgrid[J]. Electric Power Construction, 2022,43(12):94-102.
- [11] 宋伟业,刘灵玥,阎洁,等. 基于深度强化学习的海上风电集群自进化功率平滑控制方法[J]. 中国电力,2023,56(3):36-46.
SONG Weiye, LIU Lingyue, YAN Jie, et al. Self-evolving power smooth control method for offshore wind power cluster based on deep reinforcement learning[J]. Electric Power,2023,56(3):36-46.
- [12] 张东英,代悦,张旭,等. 风电爬坡事件研究综述及展望[J]. 电网技术,2018,42(6):1783-1792.
ZHANG Dongying, DAI Yue, ZHANG Xu, et al. Review and prospect of research on wind power ramp events[J]. Power System Technology,2018,42(6):1783-1792.
- [13] 崔明建,孙元章,柯德平,等. 考虑电网侧频率偏差的风电功率爬坡事件预测方法[J]. 电力系统自动化,2014,38(5):8-13.
CUI Mingjian, SUN Yuanzhang, KE Deping, et al. Prediction method for wind power ramp events considering frequency deviation of power grid side[J]. Automation of Electric Power Systems,2014,38(5):8-13.

- [14] OUYANG T H, HUANG H M, HE Y S. Ramp events forecasting based on long-term wind power prediction and correction[J]. IET Renewable Power Generation, 2019,13(15):2793-2801.
- [15] XIONG Y, ZHA X M, QIN L, et al. Research on wind power ramp events prediction based on strongly convective weather classification[J]. IET Renewable Power Generation, 2017,11(8):1278-1285.
- [16] DONG C, HUANG G G, CHENG G H. Offshore wind can power Canada[J]. Energy, 2021,236:121422.
- [17] 王鑫,李慧,叶林,等.考虑风速波动特性的VMD-GRU短期风电功率预测[J].电力科学与技术学报,2021,36(4):20-28.
WANG Xin, LI Hui, YE Lin, et al. VMD-GRU based short-term wind power forecast considering wind speed fluctuation characteristics[J]. Journal of Electric Power Science and Technology, 2021,36(4):20-28.
- [18] 张帅可,罗萍萍.基于混合分布模型的风电功率超短期预测误差分析[J].电力科学与技术学报,2020,35(5):111-118.
ZHANG Shuaike, LUO Pingping. Ultra short-time prediction error analysis of wind power based on mixed distribution model[J]. Journal of Electric Power Science and Technology, 2020,35(5):111-118.
- [19] 张爱枫,段新宇,何泉峰.基于CNN和LightGBM的新型风电功率预测模型[J].电测与仪表,2021,58(11):121-127.
ZHANG Aifeng, DUAN Xinyu, HE Xiaofeng. A new wind power prediction model based on CNN and LightGBM[J]. Electrical Measurement & Instrumentation, 2021,58(11):121-127.
- [20] 余光正,陆柳,汤波,等.考虑转折性天气的海上风电功率超短期分段预测方法研究[J].中国电机工程学报,2022,42(13):4859-4871.
YU Guangzheng, LU Liu, TANG Bo, et al. Research on ultra-short-term subsection forecasting method of offshore wind power considering transitional weather[J]. Proceedings of the CSEE, 2022,42(13):4859-4871.
- [21] 唐振浩,孟庆煜,曹生现,等.基于小波深度置信网络的风电爬坡预测方法[J].太阳能学报,2019,40(11):3213-3220.
TANG Zhenhao, MENG Qingyu, CAO Shengxian, et al. Wind power ramp prediction algorithm based on wavelet deep belief network[J]. Acta Energetica Sinica, 2019,40(11):3213-3220.
- [22] 张颖超,宗阳,邓华,等.基于趋势特征的风电功率爬坡事件检测方法[J].电测与仪表,2020,57(18):122-127+132.
ZHANG Yingchao, ZONG Yang, DENG Hua, et al. Wind power ramp event detection method based on trend feature[J]. Electrical Measurement & Instrumentation, 2020,57(18):122-127+132.
- [23] 乔妍,韩丽,李梦洁.基于爬坡特征和云模型的风电功率预测误差区间评估[J].电力系统自动化,2022,46(11):75-84.
QIAO Yan, HAN Li, LI Mengjie. Interval estimation of wind power forecasting error based on ramp features and cloud model[J]. Automation of Electric Power Systems, 2022,46(11):75-84.
- [24] OUYANG T, ZHA X M, QIN L, et al. Optimisation of time window size for wind power ramps prediction[J]. IET Renewable Power Generation, 2017,11(8):1270-1277.
- [25] 屈尹鹏,徐箭,姜尚光,等.基于频繁模式挖掘的风电爬坡事件统计特性建模及预测[J].电力系统自动化,2021,45(1):36-43.
QU Yinpeng, XU Jian, JIANG Shangguang, et al. Frequent pattern mining based modeling and forecasting for statistical characteristics of wind power ramp events[J]. Automation of Electric Power Systems, 2021, 45(1): 36-43.
- [26] QU Y P, XU J, SUN Y Z, et al. A parameter and resolution adaptive algorithm for rapid detection of ramp events in different timescale databases of the power system[J]. International Journal of Electrical Power & Energy Systems, 2019,112:393-403.
- [27] 熊予涵,彭小圣,杨子民,等.基于参数自适应旋转门和Bump事件筛选的风电爬坡事件识别[J].南方电网技术,2023,17(2):101-110.
XIONG Yuhan, PENG Xiaosheng, YANG Zimin, et al. Identification of wind power ramp events based on parameter adaptive swinging door and bump event selection[J]. Southern Power System Technology, 2023,17(2):101-110.
- [28] 迟永宁,梁伟,张占奎,等.大规模海上风电输电与并网关键技术研究综述[J].中国电机工程学报,2016,36(14):3758-3771.
CHI Yongning, LIANG Wei, ZHANG Zhankui, et al. An overview on key technologies regarding power transmission and grid integration of large scale offshore wind power[J]. Proceedings of the CSEE, 2016, 36(14): 3758-3771.
- [29] 熊音笛,刘开培,秦亮,等.基于时序数据动态天气划分的短期风电功率预测方法[J].电网技术,2019,43(9):3353-3359.
XIONG Yindi, LIU Kaipei, QIN Liang, et al. Short-term wind power prediction method based on dynamic wind power weather division of time sequence data[J]. Power System Technology, 2019,43(9):3353-3359.
- [30] 李俊卿,李秋佳,石天宇,等.基于数据挖掘的风电功率预测特征选择方法[J].电测与仪表,2019,56(10):87-92.
LI Junqing, LI Qiujia, SHI Tianyu, et al. Feature selection method for wind power prediction based on data mining [J]. Electrical Measurement & Instrumentation, 2019, 56(10):87-92.
- [31] LANDBERG L. Short-term prediction of local wind conditions[J]. Journal of Wind Engineering and Industrial Aerodynamics, 2001,89(3/4):235-245.