

新能源

面向台风天气的海上风电爬坡事件预测方法

王恩荣¹, 苏向敬^{2,3}, 龚骏豪¹, 刘正羽¹, 符杨^{2,3}

- (1. 上海电力大学 电气工程学院, 上海 200090;
2. 上海电力大学 海上风电研究院, 上海 200090;
3. 海上风电技术教育部工程研究中心(上海电力大学), 上海 200090)

摘要: 台风天气易引发海上风电功率剧烈波动, 严重威胁电力系统的安全稳定运行, 实现精准的风电爬坡事件预测对保障电网安全具有重要意义。针对现有方法在挖掘海上风电场复杂动态时空关联方面存在不足、爬坡预测精度有限的问题, 提出了一种面向台风天气的海上风电爬坡事件预测方法。首先, 利用AGCN(自适应图卷积网络)挖掘复杂变化的海上风电场空间特征; 其次, 采用BiLSTM(双向长短期记忆网络)提取时间序列中的双向依赖关系, 并引入AM(注意力机制)强化对重要特征和时序信息的学习; 在此基础上, 结合Bump事件合并与极值点修正策略对传统SDA(旋转门算法)进行改进, 提升爬坡事件的检测精度; 最后, 基于上海某风电场SCADA数据的实验结果表明, 所提出的AGCN-BiLSTM-AM组合模型能够有效挖掘海上风电场的复杂动态时空关系, 在台风天气下风电爬坡事件预测中表现出较高的精度和良好的适用性。

关键词: 台风天气; 风电爬坡事件预测; 自适应图卷积网络; 双向长短期记忆网络; 注意力机制

DOI: 10.19585/j.zjdl.202602008

开放科学(资源服务)标识码(OSID):



A prediction method for offshore wind power ramp events in typhoon weather conditions

WANG Enrong¹, SU Xiangjing^{2,3}, GONG Junhao¹, LIU Zhengyu¹, FU Yang^{2,3}

- (1. School of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China;
2. Offshore Wind Power Research Institute, Shanghai University of Electric Power, Shanghai 200090, China;
3. Offshore Wind Power Technology Engineering Research Center of the Ministry of Education, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: Typhoon weather conditions induce severe fluctuations in offshore wind power generation, posing a significant threat to the secure and stable operation of power systems. Accurate prediction of wind power ramp events is therefore crucial for ensuring grid security. To address the limitations of existing methods in capturing the complex and dynamic spatiotemporal correlations of offshore wind farms and their limited ramp prediction accuracy, this paper proposes a novel prediction method for offshore wind power ramp events in typhoon weather conditions. Firstly, an adaptive graph convolutional network (AGCN) is employed to capture the complex and varying spatial features of the offshore wind farm. Secondly, a bidirectional long short-term memory (BiLSTM) network is adopted to extract bidirectional dependencies within the time series, while an attention mechanism (AM) is introduced to enhance the learning of critical features and temporal information. Building on this, the traditional swing door algorithm (SDA) is improved by incorporating a Bump event merging strategy and an extreme point correction strategy to enhance the detection accuracy of ramp events. Finally, experimental results based on SCADA data from a wind farm in Shanghai demonstrate that the proposed combined AGCN-BiLSTM-AM model can effectively capture the complex dynamic spatiotemporal relationships of the offshore wind farm, exhibiting high accuracy and strong applicability for predicting wind power ramp events under typhoon conditions.

Keywords: typhoon weather; wind power ramp event prediction; AGCN; BiLSTM; AM

0 引言

“双碳”背景下,风能由于其清洁、高效等优点,已成为我国能源结构转型的重要支撑^[1]。《全球风能报告2023》指出,中国在海上风电领域累计装机规模已超越英国等传统海上风电强国,位居世界第一^[2]。然而,海上风电固有的随机性和间歇性,在台风天气下易引发功率剧烈波动,导致爬坡事件频发,严重威胁电网稳定运行^[3]。因此,实现精准的风电功率预测和爬坡事件检测对提升电网调峰能力、保障系统可靠性具有重要意义^[4]。

从预测方法的实现原理来看,风电爬坡预测可分为直接法与间接法,二者核心区别在于是否进行风电功率预测。直接法不通过功率预测结果检测爬坡事件,而通过构建历史爬坡事件样本库,采用机器学习算法直接建立爬坡事件的预测模型^[5-7]。然而,实际应用中爬坡事件发生概率较低,难以获取充足训练样本。

与直接法相比,当前主流的间接法通过分析风电功率预测结果并结合爬坡事件定义进行判别。因此,风电功率爬坡预测结果很大程度上依赖于风电功率预测准确度。在风电功率预测方面,物理建模法通过建立风电机组与大气环境之间的物理关系模型,得到风电场的功率输出预测。该方法对高精度的NWP(数值天气预报)数据依赖性强,且建模计算过程比较复杂,已有研究将其与统计模型结合以提高爬坡事件预测精度^[8]。统计建模法通过挖掘历史数据的统计规律构建预测模型,考虑风电功率与历史数据间的多维非线性关系。其中,深度学习对非线性特征具有更好的挖掘能力,LSTM(长短期记忆神经网络)^[9]等方法因其优异的时序动态非线性建模能力而被广泛采用。文献^[10]针对极端天气条件提出了一种改进LSTM的混合模型,融合气象数据和风电爬坡事件对风电功率预测模型进行了重构。

由于海上风电场风速变化的间歇性和波动性,单一的预测模型难以充分挖掘出力与特征之间高维度的非线性关系,组合模型能够充分利用多个模型的优势,可有效提高预测精度。文献^[11]提出基于经验模态分解与深度LSTM结合的方法,虽提升了预测精度,但台风天气下海上风电分解

的复杂性给爬坡预测实时性带来挑战。文献^[12]提出基于CNN-LSTM-AM(卷积神经网络-长短期记忆神经网络-注意力机制)的组合模型,利用CNN挖掘数据局部特征和AM以强化对爬坡特征的关注,从而提升了爬坡预测的准确性。CNN虽擅长提取局部空间特征,但难以准确建模海上风电场中风机间复杂且不规则的空间依赖关系。

海上风电出力受海面低粗糙度、大气惯性、风机地理邻近等因素影响。风电场及风机之间在时空上具有较强相关性,尾流效应会引起下游风机风速扰动,进一步强化了这种依赖关系。因此,在爬坡预测中引入时空相关性建模,有助于提升预测精度。文献^[13]考虑风电场的时空关联性,提出基于半监督GAN-LSTM(生成对抗网络-长短期记忆网络)组合模型的爬坡预测方法,在一定程度上提升了爬坡预测性能。文献^[14]提出基于时空注意力卷积网络的超短期风电功率预测模型,通过构建静态图,引入时空注意力模块和时空卷积模块来挖掘时空特征,提高预测精度。然而,上述模型对海上风电场复杂且动态变化的爬坡时空关系的表征能力仍存在不足。文献^[15]提出基于SDA(旋转门算法)和正确爬坡合并策略的爬坡检测框架,基于趋势预测方法优化了海上风电爬坡检测性能,提高了爬坡预测的精度。

综上,现有研究在海上风电场爬坡预测建模中,对各风机变量之间潜在关联性的挖掘仍不充分^[16],主要面临以下挑战:海上风机间空间关联受风速、尾流效应等动态环境因素影响,导致不同风机之间的爬坡存在时变的空间依赖性,传统CNN或预定义静态拓扑模型无法反映这种动态空间相关性;爬坡事件具有突变性,预测难度较大,传统单向LSTM模型对爬坡起始时间及波动幅度的识别容易出现滞后或偏差,限制了爬坡预测的精度;风电爬坡事件占比低,其关键特征易被高维特征淹没,影响预测精度。

针对上述挑战,本文提出基于AGCN-BiLSTM-AM(自适应图卷积网络-双向长短期记忆网络-注意力机制)的台风天气下海上风电爬坡预测方法。首先,依据地理坐标数据和风速空间关联特性,构建了海上风电场空间关系的图拓扑结构,采用AGCN挖掘复杂变化的海上风电场空

间特征；其次，引入BiLSTM双向挖掘风机时序数据特征，并利用AM加强对重要特征和时序信息的学习；接着，结合Bump事件合并与极值点修正策略改进传统SDA，以提高爬坡事件的检测精度。最后，以上海某真实风电场数据验证本文所提出的预测方法，结果表明该方法能够有效挖掘海上风电场的复杂动态时空关系，在台风天气下表现出较高的风电爬坡事件预测精度与良好的适用性。

1 海上风电爬坡事件预测流程

本文所提出的海上风电爬坡事件预测流程如图1所示，主要包括海上风电场图拓扑构建、数据预处理、风电功率预测和风电功率爬坡事件检测四个模块。具体流程如下：首先，针对SCADA系统在数据采集与传输过程中可能产生的异常数据，采用数据预处理技术进行清洗和校正，并将处理后的归一化数据集划分为训练集和测试集；其次，基于风机地理坐标和风速空间关联特性，构建风电场网络拓扑，并引入自适应图学习算法量化由台风、尾流等因素引起的图拓扑动态变化；进一步利用本文所提出的AGCN-BiLSTM-AM预测模型，充分挖掘海上风电场中复杂的动态时空相关性；然后，使用归一化后数据进行模型训练，通过迭代优化模型参数使得模型收敛；在模型测试阶段，利用独立测试数据集评估模型性能，获得台风天气下自适应风电场出力预测结果；最后，构建爬坡事件检测框架，使用改进SDA对功率预测结果进行事件检测，并评估模型爬坡预测性能，得到海上风电场爬坡事件的预测结果。

2 海上风电场功率预测模型

2.1 AGCN模型

GCN(图卷积网络)在海上风电场功率预测中表现出良好的空间特征信息提取能力^[17]。本文的图拓扑构建方法通过邻接矩阵来反映海上风电场不同风机之间的相关性，从而实现各风机之间空间相关性的构建。具体将海上风电场看作一个无向图， $G=(V,E)$ 表示风机之间相关性的网络，其中 V 表示顶点集(单风机)， E 表示边集(风机之间形成的连接)，邻接矩阵表示风机之间的拓扑

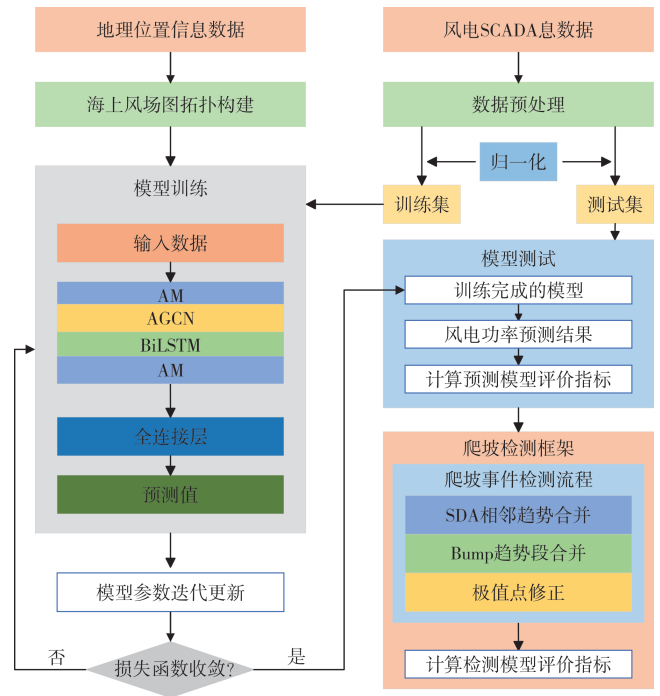


图1 海上风电爬坡事件预测流程

Fig.1 Flowchart of offshore wind power ramp event prediction

连接。

GCN核心原理建立在卷积定理之上，即时域卷积运算的傅里叶变换等价于频域傅里叶变换的乘积：

$$f_1(t)*f_2(t)=f^{-1}[F_1(\omega)\cdot F_2(\omega)] \quad (1)$$

式中： $f(t)$ 为时域信号； $F(\omega)$ 为频域信号； f 为傅里叶变换； $*$ 表示卷积； \cdot 为乘积。

傅里叶变换的核心特性体现在时频域转换关系上，即时域卷积对应于频域乘积。对图网络进行傅里叶变换和反变换得：

$$x*_G g_\theta=f^{-1}(f(x)\odot f(g)) \quad (2)$$

式中： $*_G$ 为图卷积； x 为输入信号； g_θ 为卷积核； \odot 为元素积； f^{-1} 代表傅里叶反变换。

不关心时域上滤波器信号，只关心在频域的情况下，令滤波器 $g_\theta=\text{diag}(U^T g)$ ，式(2)可简化为：

$$x*_G g_\theta=U g_\theta U^T x=U \begin{pmatrix} \hat{g}(\lambda_1) & & \\ & \ddots & \\ & & \hat{g}(\lambda_n) \end{pmatrix} U^T x \quad (3)$$

在此基础上，使用切比雪夫多项式来近似谱域卷积核的计算，即 $U g_\theta U^T=\sum_{k=0}^K \beta_k U T_k(\Lambda) U^T$ 。

为进一步简化, 只考虑一阶切比雪夫多项式, 则:

$$x^*_{G}g_{\theta} = (\beta_0 - \beta_1(D^{-1/2}AD^{-1/2}))x \quad (4)$$

为抑制参数量并避免过拟合, 对每个卷积核只设置 1 个学习参数, 即 $\theta = \beta_0 = -\beta_1$, 于是有:

$$x^*_{G}g_{\theta} = \theta(\tilde{D}^{-1/2}\tilde{A}\tilde{D}^{-1/2})x \quad (5)$$

虽然 GCN 在空间信息挖掘方面表现出色, 但台风、尾流等外界环境使得海上风电机组空间关系在不同时间存在差异, 预定义的静态邻接矩阵^[18]无法全面捕捉风机间的动态相关性; 此外, 海上风机的集中分布使得基于距离定义的拓扑结构与风电功率预测目标关联度无法直接适配。为此, 本文利用 AGCN 对风机间动态空间特征进行挖掘, 其中核心自适应矩阵的理论公式如式(6)所示:

$$\tilde{A}_a = \text{softmax}(\text{ReLU}(W_1A_{(0)}(W_1A_{(0)})^T + W_2A_{(0)}(W_2A_{(0)})^T)) \quad (6)$$

式中: W_1 和 W_2 均为随机初始化节点权重关联矩阵; $A_{(0)}$ 为基于距离信息和风速相关性所建立的邻接矩阵, 作为初始化矩阵; $W_1A_{(0)}$ 和 $W_2A_{(0)}$ 分别为源节点、目标节点的节点嵌入。

通过 $W_1A_{(0)}(W_1A_{(0)})^T$ 和 $W_2A_{(0)}(W_2A_{(0)})^T$ 计算出源节点和目的节点之间的空间相关权值。使用 ReLU 激活函数消除相关性低的连接。然后, 利用 softmax 函数对自适应邻接矩阵进行归一化。在模型训练(前向传播+后向反馈/梯度下降)过程中, W_1 和 W_2 不断被优化更新。优化的目标是 minimized 风电场功率预测的损失函数。因此, \tilde{A}_a 可以随着模型训练自动调整邻接矩阵, 最好地表征那些对提高当前时刻、当前气象条件下功率预测精度最有帮助的风机节点之间的空间依赖关系。

综合上述理论分析, AGCN 模型框架如图 2 所示, 最终得到自适应图卷积如式(7)所示:

$$Z = \tilde{D}^{-1/2}\tilde{A}_a\tilde{D}^{-1/2}XW \quad (7)$$

式中: \tilde{A} 为自适应矩阵; \tilde{D} 为 \tilde{A} 的度矩阵; W 为权重; X 为多风机输入特征。

2.2 BiLSTM 模型

LSTM 作为 RNN(循环神经网络)的重要变体, 通过门控机制解决梯度爆炸问题, 实现了对时序信息的长程依赖建模。其具体运算过程可形式化为:

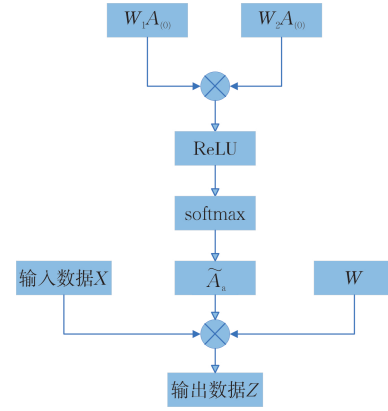


图 2 AGCN 模型框架

Fig.2 AGCN model framework

$$f_t = \sigma(W_{fx}x_t + W_{fh}h_{t-1} + b_f) \quad (8)$$

$$i_t = \sigma(W_{ix}x_t + W_{ih}h_{t-1} + b_i) \quad (9)$$

$$g_t = \sigma(W_{gx}x_t + W_{gh}h_{t-1} + b_g) \quad (10)$$

$$o_t = \phi(W_{ox}x_t + W_{oh}h_{t-1} + b_o) \quad (11)$$

$$S_t = g_t \odot i_t + S_{t-1} \odot f_t \quad (12)$$

$$h_t = \phi(S_t) \odot o_t \quad (13)$$

式中: W_{fx} 、 W_{fh} 、 W_{ix} 、 W_{ih} 、 W_{gx} 、 W_{gh} 、 W_{ox} 、 W_{oh} 分别为各环节的权重; b_f 、 b_i 、 b_g 、 b_o 分别为各环节的偏置; \odot 表示元素积; σ 和 ϕ 分别为 sigmoid、tanh 激活函数。

在海上风电场景中, 台风天气易引发功率剧烈波动。传统单向 LSTM 仅能提取历史时序特征, 无法建模未来时刻对当前功率输出的反向影响。为此, 本文引入 BiLSTM, 并行构建前向与反向 LSTM 网络, 前向层提取海上风电历史出力特征, 而反向层捕捉未来风速突变和气压骤变与当前状态的潜在关联, 修正前向 LSTM 的预测结果。BiLSTM 不仅实现了更全面的数据信息利用, 还有效缓解了波峰提前或滞后到达的问题, 提前修正预测曲线, 从而提升了对爬坡事件进行捕捉与预测的能力。

BiLSTM 模型结构如图 3 所示, 其同时运行前向与后向 LSTM 层, 并将两者的隐藏状态 h_t (由 h_t^f 和 h_t^b 拼接而成) 进行融合, 使其能够综合过去和未来的上下文信息。具体计算过程如下:

$$h_t^f = \text{LSTM}(x_t, h_{t-1}^f) \quad (14)$$

$$h_t^b = \text{LSTM}(x_t, h_{t+1}^b) \quad (15)$$

$$h_t = [h_t^f; h_t^b] \quad (16)$$




图3 BiLSTM结构

Fig.3 BiLSTM structure

2.3 AM

AM作为一种动态资源分配策略，能够根据输入数据重要性自动调整权重分布，强化关键信息的表达能力^[19]，其结构如图4所示。




图4 AM结构

Fig.4 AM structure

为进一步提升海上风电出力预测的精度与可信度，本文引入双重注意力机制，加强对重要特征和关键时间点信息的学习与表达，以缓解长时序预测中的信息衰减问题，有效保留爬坡特征信息，从而提升台风天气下爬坡预测的精度。具体而言，特征注意力机制对风机数据特征进行动态权重分配，在训练过程中优先保留台风天气下与风机出力强相关的气象主导因子，抑制无关特征的干扰。针对长时序预测中的信息衰减问题，采用时间注意力机制为不同时间节点动态分配注意力权重，强化关键历史时刻的信息保留，有效缓解预测步长增加导致的风机时序信息丢失问题，更准确地预测未来出力的波动趋势。

在本文模型中，特征注意力机制被整合到AGCN的初始特征提取阶段。具体来说，输入具有 N 个属性的特征向量 $X=[x_1, x_2, \dots, x_N]$ ，特征注意力机制首先通过一个全连接层计算每个特征的注意力得分 $Z_{Fe}=[Z_1, Z_2, \dots, Z_N]$ ，这些特征注意力权重通过softmax函数进行归一化，以确保它

们的和为1。计算得到注意力权重 $\alpha=[\alpha_1, \alpha_2, \dots, \alpha_N]$ ，其中 α_i 为第 i 个节点的注意力权重值，表示为：

$$\alpha_i = \frac{\exp(z_i)}{\sum_{l=1}^m z_{i,l}} \quad (17)$$

式中： m 为第 i 个节点的特征数。

最终，特征向量 X 被加权得到新的特征表示为 X' 。

$$X' = \alpha \odot X = [\alpha_1 x_1, \alpha_2 x_2, \dots, \alpha_N x_N] \quad (18)$$

式中： \odot 为元素积。

时间注意力机制主要用于处理时间序列数据，其目的是在不同时间步上动态调整注意力权重，以捕捉时间序列中的关键时间点。BiLSTM的隐藏层状态 $h_t=[h_1, h_2, \dots, h_k]$ ，其中 h_k 表示第 k 个时间步的特征向量。时间注意力机制计算每个时间步的注意力得分 $l=[l_1, l_2, \dots, l_k]$ 。时间注意力权重也通过softmax函数进行归一化，以确保权重的和为1。式(19)计算了归一化后的时间注意力权重，然后将特征向量加权得到最终的输出特征 h' 。

$$\beta^{(t)} = \frac{\exp(l^{(t)})}{\sum_{i=1}^T l^{(i)}} \quad (19)$$

$$h' = \sum_{t=1}^T \beta^{(t)} h_t \quad (20)$$

3 海上风电场爬坡事件检测方法

3.1 爬坡事件

台风天气下由于气压不稳定和风速急剧变化，风电功率常出现明显的爬坡特征，这种特征主要表现为输出功率在短时尺度上的快速增加或降低，风电功率爬坡事件描述如图5所示。

爬坡事件通常采用爬坡幅度、持续时间、爬坡率、起止时间和爬坡方向这五种特征量进行描




图5 风电功率爬坡事件描述

Fig.5 Description of wind power ramp events

述^[5]。由于风电功率波动性的时空差异以及不同研究场景下的关注重点差异,基于上述表征量,目前普遍采用以下3种定义来判别爬坡事件:

定义1:某一时间段($t, t + \Delta t$)起始点与终止点的功率变化量超出预设阈值,即可判定为爬坡事件发生。其表达式为:

$$|P_{t+\Delta t} - P_t| > P_{\text{threshold}} \quad (21)$$

式中: P_t 和 $P_{t+\Delta t}$ 分别为 t 、 $t + \Delta t$ 时刻的风电功率; $P_{\text{threshold}}$ 为阈值。

定义2:某一时间段($t, t + \Delta t$)内风电功率的峰值与谷值之差超过阈值,即可判定为爬坡事件发生。其表达式为:

$$\max(P(t, t + \Delta t)) - \min(P(t, t + \Delta t)) > P_{\text{threshold}} \quad (22)$$

式中: $\max(P(t, t + \Delta t))$ 和 $\min(P(t, t + \Delta t))$ 分别为($t, t + \Delta t$)内风电功率的峰值、谷值。

定义3:某一时间段($t, t + \Delta t$)内爬坡率超过阈值,即可判定为爬坡事件发生。其表达式为:

$$\frac{|P_{t+\Delta t} - P_t|}{\Delta t} > R_{\text{threshold}} \quad (23)$$

式中: $R_{\text{threshold}}$ 为爬坡率阈值。

在上述三种定义中,定义1难以有效识别风电功率变化特征;定义2无法区分风电功率段的爬坡方向,易出现识别错误;定义3可判断爬坡方向和爬坡率,是目前最常用的定义。定义3的检测效果依赖于时间间隔 Δt 和爬坡率阈值 $R_{\text{threshold}}$ 的选取。基于文献[20],大规模爬坡事件常伴随有大风天气,大部分爬坡事件的功率变化均发生在不超过4 h的时间窗口内。基于该现象,本文选取的有效爬坡事件的持续时间间隔不超过4 h,并将上爬和下爬坡率阈值分别设定为风电场额定容量的20%、15%,以此作为爬坡事件的识别标准。

3.2 爬坡事件检测

根据爬坡定义3,使用改进的SDA对功率数据进行爬坡段检测,检测流程含以下四个步骤:

1) SDA 趋势初步检测

对于给定的风电出力曲线,传统SDA通过选择一个合适的门宽 ϵ ,并用两个固定轴的“旋转门”连续构建三角形来过滤数据。如果纵轴和两个门的延伸不能形成一个三角形,则压缩结束,并形成功率爬坡段的边界点。对所有功率数据点压缩完成之后,对不同趋势爬坡段进行标签,完

成爬坡事件的初步趋势提取。然而,传统SDA无法自动识别完整爬坡段,且对非线性趋势适应性差^[14],因此,本文在后续步骤中对传统SDA进行了改进。

2) 相邻趋势段合并

经传统SDA初步检测后,出现相邻且方向相同的趋势相同爬坡段,理论上这些趋势爬坡段应该为一个整体的爬坡段。本文将这些初步提取的相邻趋势爬坡段合并,合并后的片段保留原有标签。

3) Bump 趋势段合并

在风电功率波动分析中,伪拐点(Bump事件)常表现为短时、小幅波动,虽不改变宏观趋势,但会中断爬坡连续性,Bump事件如图6所示。为消除此类影响,本文设定当功率波动低于额定容量2%~3%且持续时间不足60 min时,标记为平稳段。若两个同向趋势段被平稳段分隔且整体满足爬坡事件条件,则将其合并为完整爬坡段,该方法有效解决了伪拐点导致的爬坡过程中断问题^[21]。




图6 Bump事件

Fig.6 Bump event

4) 极值点修正

针对爬坡段起止点定位精度不足的问题,提出一种极值点修正的方法:首先定位距离爬坡段起止点最近的局部极值点;随后通过判定条件验证修正后的端点是否满足爬坡事件定义准则;最终确定爬坡事件的精确起止时刻。该方法提升了爬坡事件识别的完整性和准确性。

4 爬坡事件预测性能评价

4.1 风电功率预测模型评价指标

本文采用RMSE(均方根误差)和MAE(平均绝对误差)作为风电功率预测的评估指标。RMSE通过平方误差反映预测精度,避免较大误差值影

响；MAE直接衡量预测误差的绝对大小。两者数值越小，表明模型性能越好。

$$R_{\text{RMSE}} = \frac{1}{N} \sum_{n=1}^N \sqrt{\frac{1}{N_t} \sum_{i=1}^{N_t} (P_{mi}^Y - P_{mi}^R)^2} \quad (24)$$

$$M_{\text{MAE}} = \frac{1}{NN_t} \sum_{n=1}^N \sum_{i=1}^{N_t} |P_{mi}^Y - P_{mi}^R| \quad (25)$$

式中： N_t 为预测步长； N 为风机数量； P_{mi}^Y 和 P_{mi}^R 分别为第 n 台风机第 i 时间步长的归一化预测值、实测数据。

4.2 爬坡事件预测评价指标

基于上述风电场功率预测结果进行爬坡事件检测，完成爬坡事件预测。为评价所提出的爬坡事件预测方法的性能，将对比不同预测模型通过改进检测框架所得预测结果与实际结果的异同。风电爬坡事件预测结果如表1所示。爬坡事件预测结果可分为以下四种类型：

1) 误报(False Positive)：预测存在但实际未发生的爬坡事件，记作 N_{FP} 。

2) 漏报(False Negative)：预测不存在但实际发生的爬坡事件，记作 N_{FN} 。

3) 正确预测(True Positive)：准确预测实际发生的爬坡事件，记作 N_{TP} 。

4) 正确拒绝(True Negative)：准确预测未发生的爬坡事件，记作 N_{TN} 。

根据这四种类型，可以延伸出如下一系列爬坡评价指标。

表1 风电爬坡事件预测结果

Table 1 Prediction results of wind power ramp events

爬坡事件预测结果	爬坡事件实际观测结果	
	发生爬坡	未发生爬坡
发生爬坡	N_{TP}	N_{FP}
未发生爬坡	N_{FN}	N_{TN}

用准确率 A_{ACC} 反映模型正确识别爬坡事件的能力，其值越高代表模型的整体检测性能越优异。

$$A_{\text{ACC}} = \frac{N_{\text{TP}} + N_{\text{TN}}}{N_{\text{TP}} + N_{\text{TN}} + N_{\text{FN}} + N_{\text{FP}}} \quad (26)$$

用成功率 P 衡量模型预测为爬坡的事件中真实发生的比例，该指标越高说明模型的误判率越低，预测可靠性越强。

$$P = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}} \quad (27)$$

召回率 R 体现了实际爬坡事件中被模型成功识别的比例，较高的召回值表明模型具有较低的漏检风险。

$$R = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}} \quad (28)$$

F1分数 F_1 表示成功率和召回率的调和平均值。 F_1 用于平衡模型在误报和漏报之间的表现，该指标值越高代表模型的综合性能越优越。

$$F_1 = \frac{2PR}{P + R} \quad (29)$$

5 算例分析

5.1 实验数据

以中国东海某风电场2020年的SCADA数据作为实验数据集进行验证，数据包输出功率、气象因素及机组运行参数等特征，时间分辨率为15 min。为验证所提出的爬坡预测方法在台风天气下的有效性，选取6月1日—7月27日的数据作为训练集，7月28日—8月5日包含台风天气的数据作为测试集。模型输入时间窗口长度为20个时间步，输出未来16个时间步的风电功率预测值。网络结构参数设置如下：BiLSTM和AGCN的隐藏层维度均为256，层数为1；训练超参数设置为学习率0.001，批量大小64，最大训练轮数50；优化算法采用Adam进行参数更新。时空挖掘层数(由AGCN和BiLSTM组成且模型的超参数保持一致)对模型精度的影响，如表2所示，当层数从1层增加到2层时，模型的RMSE和MAE虽然有所下降，但模型出现过拟合现象。因此，最终确定本文的时空挖掘层数为1。

表2 时空挖掘层数对模型精度的影响

Table 2 Impact of spatiotemporal mining layers on model accuracy

层数	评价指标	
	RMSE	MAE
1	0.109 3	0.079 3
2	0.115 6	0.083 8

5.2 数据预处理

由于海上风电场SCADA数据集中含异常值和缺失值，本文采用组合方法对数据进行预处理。首先，基于风电功率散点图，通过规则筛选、线性模型拟合与DBSCAN(基于密度的有噪声空间

聚类)算法检测异常数据: 根据风机切入和切出风速剔除明显异常值; 利用线性模型拟合风速与功率关系, 通过误差阈值识别异常; 采用DBSCAN算法筛选剩余离群点。随后, 使用随机森林算法填补缺失值和异常剔除数据, 并将填补后的数据用于模型训练和测试。最后, 对数据集进行Min-Max标准化处理, 将所有特征值归一化至[0,1]范围内, 以优化模型训练效果并确保特征间的可比性。

5.3 功率预测性能对比分析

为验证本文模型的有效性和优越性, 在相同风电场数据集下, 对比LSTM、BiLSTM、CNN-BiLSTM、GCN-BiLSTM、AGCN-BiLSTM及本文模型(AGCN-BiLSTM-AM), 以RMSE和MAE作为评价指标进行对比分析。不同模型的功率预测误差对比如表3所示。不同模型的集群功率预测对比如图7所示。

表3所列不同单机和风电场功率预测的RMSE与MAE结果表明模型架构的逐步改进显著提升了

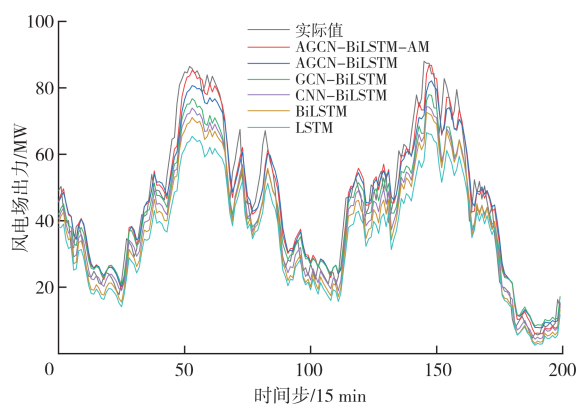


图 7 不同模型的集群功率预测

Fig.7 Cluster power prediction of different models

预测精度。具体而言, LSTM模型的风电场功率预测误差RMSE为0.173 8、MAE为0.131 4。这反映出传统的RNN在复杂风场环境下的预测效果较差。引入BiLSTM后, 预测误差有所降低, RMSE为0.161 9, 降低6.8%, MAE为0.120 2, 降低8.5%。这说明双向结构可同时捕捉历史与未来时刻的功率变化特征, 更适用于功率突变场景。

CNN-BiLSTM通过CNN深度挖掘数据的局部特征后, 模型性能得到明显提升, RMSE较BiLSTM模型降低8.4%, MAE降低10.2%, 表明CNN的局部感受野特性能够捕获部分的风电场空间特征。当采用图卷积结构后, GCN-BiLSTM模型预测误差继续下降, RMSE较CNN-BiLSTM降低8.4%, MAE降低6.1%, 说明建模风机间的拓扑关系能更准确地反映风场的实际物理特性。引入自适应图卷积的AGCN-BiLSTM模型性能进一步提升, RMSE较GCN-BiLSTM降低10.8%, MAE降低11.7%, 证实了固定拓扑结构的局限性, 以及动态调整风机间连接权重的重要性。特别是在风向变化等动态工况下, 自适应图结构能够实时调整风机间的关联程度, 从而更准确地反映风电场的实际出力。

综上, 本文模型达到了最优性能, AM通过加强对重要特征和关键时间点信息的学习, 缓解长时序预测中的信息衰减, 保留爬坡特征的信息, 从而提升台风天气下爬坡预测的精度。由图7可知, 本文模型在功率波峰、波谷及快速变化时均表现出更高的预测精度, 预测曲线更接近真实值。

为进一步验证模型在动态空间关联挖掘方面的优越性及其对单台风机的泛化能力, 选取位于风电场不同位置的9号、15号、23号和26号风机

表 3 不同模型的功率预测误差

Table 3 Power prediction errors of different models

模型	单风机预测								风电场预测	
	9号风机		15号风机		23号风机		26号风机			
	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE
LSTM	0.166 0	0.135 8	0.176 5	0.139 7	0.174 4	0.135 1	0.161 5	0.127 3	0.173 8	0.131 4
BiLSTM	0.155 1	0.112 7	0.162 5	0.126 3	0.160 3	0.117 6	0.147 7	0.115 8	0.161 9	0.120 2
CNN-BiLSTM	0.133 0	0.101 2	0.149 5	0.112 6	0.147 7	0.107 3	0.137 0	0.105 0	0.148 3	0.108 0
GCN-BiLSTM	0.117 1	0.088 4	0.144 9	0.107 6	0.124 4	0.094 3	0.153 4	0.109 2	0.135 9	0.101 4
AGCN-BiLSTM	0.111 2	0.082 5	0.118 5	0.090 7	0.142 3	0.098 1	0.139 1	0.097 5	0.121 2	0.089 5
AGCN-BiLSTM-AM	0.096 1	0.069 0	0.098 2	0.072 9	0.125 2	0.082 1	0.137 9	0.094 7	0.109 3	0.079 3

进行对比分析。海上风机集群分布图如图8所示,其中9号和26号风机位于风电场边缘,15号和23号风机位于集群内部,更易受尾流影响。由表3可知,本文模型对风电场不同位置的风机预测误差均最小,且预测表现稳定。本文模型通过自适应矩阵挖掘风电场风机间复杂的动态空间关系,充分学习风电场拓扑结构,从而有效提升了台风天气下的风电功率预测精度。

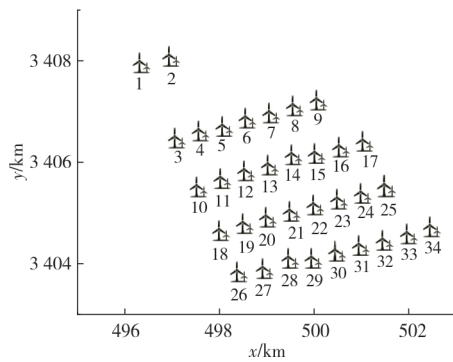


图8 海上风机集群分布图

Fig.8 Layout of offshore wind turbine cluster

为系统评估本文模型对风电场动态空间特征的挖掘能力,本文进一步借助空间注意力权重的可视化分析,揭示了在台风前和台风期间两种工况下,风电场空间关联特征的动态演变规律。台风前和台风期间风电场空间注意力权重图分别如图9、图10所示,热力图坐标轴编号1—34分别对应各台风机,颜色深浅直观反映了风电机组之间的空间关联强度,同时也表示不同风电机组对风电场功率预测的贡献度。




图9 台风前风电场空间注意力权重图

Fig.9 Spatial attention weight map of wind farms before typhoon




图10 台风期间风电场空间注意力权重图

Fig.10 Spatial attention weight map of wind farms during typhoon conditions

在台风来临前,风向以东风为主且风速较低,尾流效应不明显,风能整体由右向左输送。由图9可知,该阶段各风机主要关注自身信息,与其他风机的相互关注度较弱,表现为对角线区域颜色最深。而台风带来的偏东南风,使得风电场南侧风机尾流影响加剧、流向复杂,风机间相互影响显著。如图10所示,在这一阶段,自适应邻接矩阵对各风机自身及其他风机均表现出较高的关注度。其中,30号、33号和34号外部风机与一部分其他风机存在关联,而位于风电场内部的15号风机尾流情况复杂,与众多风机存在关联。

5.4 爬坡事件预测性能评估

为验证本文爬坡事件预测模型的有效性,基于改进的SDA对LSTM、BiLSTM、CNN-BiLSTM、GCN-BiLSTM、AGCN-BiLSTM及本文模型的预测结果进行爬坡事件检测。不同模型的爬坡事件预测性能评价指标对比如表4所示。

从表4中不同模型的评价指标可以看出,六种

表4 不同模型的爬坡事件预测评价指标对比

Table 4 Comparison of evaluation metrics for ramp event prediction by different models

预测模型	评价指标			
	P	R	A_{Acc}	F_1
LSTM	62.13	50.60	70.26	55.78
BiLSTM	71.33	55.44	83.50	62.39
CNN-BiLSTM	72.50	61.80	84.50	66.73
GCN-BiLSTM	74.70	64.25	85.81	69.08
AGCN-BiLSTM	77.53	71.50	87.85	74.39
AGCN-BiLSTM-AM(本文模型)	84.26	75.45	89.13	79.62

预测模型的爬坡检测结果都具有较高的整体准确率 A_{ACC} 。进一步分析其他指标可发现, LSTM模型的成功率 P 和召回率 R 最低, 分别为 62.13%、50.60%, 表明误报和漏报问题最为显著, 说明其单向特征提取能力难以全面捕捉爬坡事件的时空特征。BiLSTM模型与LSTM模型相比, 成功率 P 和召回率 R 得到提升, 分别为 71.33%、55.44%, 证明时序双向建模通过反向时序修正, 使得预测爬坡更准确。通过进一步集成CNN构建的CNN-BiLSTM模型, 将召回率 R 和F1分数 F_1 进一步提升至 72.50% 和 61.80%, 表明局部空间特征提取能有效增强模型的泛化能力。当采用图卷积挖掘空间特征后, GCN-BiLSTM模型相比CNN-BiLSTM模型性能进一步提升, 成功率 P 和召回率 R 分别达到 74.70%、64.25%, 验证了风电场空间关系建模对发现潜在爬坡事件的有效性。AGCN-BiLSTM模型优化了预测结果, 证明动态学习图结构能更精准地捕捉复杂工况的空间关联特征。本文模型(AGCN-BiLSTM-AM)在所有评价指标上均表现最优, 成功率 P 为 84.26%, 召回率 R 为 75.45%, A_{ACC} 准确率为 89.13%, F1分数 F_1 为 79.62%。这表明AM通过注意力权重动态分配机制, 挖掘各风机时序数据的关键信息, 使得表征风电爬坡特征的重要信息得到保留, 提升了模型的预测性能。实验结果证明, 本文模型在成功率和召回率之间取得了良好平衡, 能够有效提升台风天气下风电功率爬坡事件的预测精度与可靠性。

6 结论

针对现有预测方法对海上风电场复杂动态时空关系挖掘不足、功率爬坡预测精度不高的问题, 本文提出基于AGCN-BiLSTM-AM组合模型的台风天气下海上风电爬坡预测方法, 仿真分析表明:

1) AGCN算法能有效解决台风天气下的海上风电场风机间爬坡特征空间信息挖掘不足的问题, 动态捕捉海上风电场的空间关系变化, 有效提升爬坡预测的精度。

2) BiLSTM有效提取了双向时间序列信息, 兼顾台风天气下历史状态与未来趋势对当前时刻

的交互影响, 从而更全面地捕获各风机时序数据中的爬坡特征和依赖关系; 同时, 引入的AM加强了对风电爬坡重要特征的学习和关键时间点信息的表达, 有效提升复杂天气下爬坡预测鲁棒性。

3) 对比实验验证表明, 本文构建的海上风电场功率预测和爬坡事件检测模型, 相较于其他传统爬坡预测模型表现出更优越的爬坡预测性能。

参考文献

- [1] 刘吉臻, 马利飞, 王庆华, 等. 海上风电支撑我国能源转型发展的思考[J]. 中国工程科学, 2021, 23(1): 149-159.
LIU Jizhen, MA Lifei, WANG Qinghua, et al. Offshore wind power supports China's energy transition[J]. Strategic Study of CAE, 2021, 23(1): 149-159.
- [2] 夏云峰. 2022年全球风电新增装机77.6 GW[J]. 风能, 2023(5): 56-60.
XIA Yunfeng. In 2022, the new installed capacity of global wind power will be 77.6 GW[J]. Wind Energy, 2023(5): 56-60.
- [3] 谢善益, 杨强, 谢恩彦, 等. 考虑受端电网运行安全的台风条件下海上风电场协调运行策略[J]. 浙江电力, 2023, 42(10): 17-24.
XIE Shanyi, YANG Qiang, XIE Enyan, et al. The coordinated operation strategy for offshore wind farms with energy storage under typhoon conditions considering the operation safety demand of receiver grid[J]. Zhejiang Electric Power, 2023, 42(10): 17-24.
- [4] 叶林, 路朋, 滕景竹, 等. 考虑风电功率爬坡的功率预测—校正模型[J]. 电力系统自动化, 2019, 43(6): 49-56.
YE Lin, LU Peng, TENG Jingzhu, et al. Power prediction and correction model considering wind power ramping events[J]. Automation of Electric Power Systems, 2019, 43(6): 49-56.
- [5] 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.
- [6] 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.
- [7] ZHA X M, OUYANG T H, QIN L, et al. Selection of

- time window for wind power ramp prediction based on risk model [J]. *Energy Conversion and Management*, 2016, 126:748-758.
- [8] 欧阳庭辉, 查晓明, 秦亮, 等. 基于相似性修正的风电功率爬坡事件预测方法[J]. *中国电机工程学报*, 2017, 37(2): 572-581.
OUYANG Tinghui, ZHA Xiaoming, QIN Liang, et al. Wind power ramps prediction method based on amendment of similar events[J]. *Proceedings of the CSEE*, 2017, 37(2):572-581.
- [9] 张群, 唐振浩, 王恭, 等. 基于长短时记忆网络的超短期风电功率预测模型[J]. *太阳能学报*, 2021, 42(10):275-281.
ZHANG Qun, TANG Zhenhao, WANG Gong, et al. Ultra-short-term wind power prediction model based on long and short term memory network [J]. *Acta Energiæ Solaris Sinica*, 2021, 42(10):275-281.
- [10] CUI Y, CHEN Z H, HE Y J, et al. An algorithm for forecasting day-ahead wind power via novel long short-term memory and wind power ramp events [J]. *Energy*, 2023, 263:125888.
- [11] ZHOU B B, SUN B, GONG X, et al. Ultra-short-term prediction of wind power based on EMD and DLSTM[C]// 2019 14th IEEE Conference on Industrial Electronics and Applications (ICIEA). June 19-21, 2019. Xi' an, China. IEEE, 2019:1909-1913.
- [12] 景惠甜, 韩丽, 高志宇. 基于卷积神经网络特征提取的风电功率爬坡预测[J]. *电力系统自动化*, 2021, 45(4): 98-105.
JING Huitian, HAN Li, GAO Zhiyu. Wind power ramp forecast based on feature extraction using convolutional neural network [J]. *Automation of Electric Power Systems*, 2021, 45(4):98-105.
- [13] 段浩然. 基于半监督生成对抗网络的风电功率与爬坡预测方法[D]. 长沙: 湖南大学, 2021.
DUAN Haoran. Wind power and ramp prediction method based on semi-supervised generative adversarial network [D]. Changsha: Hunan University, 2021.
- [14] 吕云龙, 胡琴, 熊俊杰, 等. 基于时空注意力卷积模型的超短期风电功率预测[J]. *电网技术*, 2024, 48(5): 2064-2073.
LÜ Yunlong, HU Qin, XIONG Junjie, et al. Ultra-short-term wind power prediction based on spatiotemporal attention convolution model [J]. *Power System Technology*, 2024, 48(5):2064-2073.
- [15] HE Y Y, ZHU C, AN X L. A trend-based method for the prediction of offshore wind power ramp [J]. *Renewable Energy*, 2023, 209:248-261.
- [16] 钟吴君, 李培强, 涂春鸣. 基于尾流关联的动态超图风电功率超短期预测方法[J]. *中国电机工程学报*, 2025, 45(12):4693-4707.
ZHONG Wujun, LI Peiqiang, TU Chunming. Dynamic hypergraph wind power ultra short term prediction method based on wake correlation [J]. *Proceedings of the CSEE*, 2025, 45(12):4693-4707.
- [17] LIAO W L, BAK-JENSEN B, PILLAI J R, et al. A review of graph neural networks and their applications in power systems [J]. *Journal of Modern Power Systems and Clean Energy*, 2022, 10(2):345-360.
- [18] JI Shan, 姜巍, 景鑫. 基于余弦相似度和图卷积网络的电力负荷预测方法[J]. *浙江电力*, 2025, 44(1):68-75.
JI Shan, JIANG Wei, JING Xin. A power load forecasting method using cosine similarity and a graph convolutional network [J]. *Zhejiang Electric Power*, 2025, 44(1):68-75.
- [19] 苏向敬, 周汶鑫, 李超杰, 等. 基于双重注意力 LSTM 神经网络的可解释海上风电出力预测[J]. *电力系统自动化*, 2022, 46(7):141-151.
SU Xiangjing, ZHOU Wenxin, LI Chaojie, et al. Interpretable offshore wind power output forecasting based on long short-term memory neural network with dual-stage attention [J]. *Automation of Electric Power Systems*, 2022, 46(7):141-151.
- [20] 郭燕玲, 赵晶, 周林, 等. 山东半岛风电爬坡事件的识别与天气分析研究[J]. *气候与环境研究*, 2017, 22(1):97-107.
GUO Yanling, ZHAO Jing, ZHOU Lin, et al. A study on the identification and synoptic analysis of wind ramp events in Shandong Peninsula [J]. *Climatic and Environmental Research*, 2017, 22(1):97-107.
- [21] 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.

收稿日期: 2025-05-20; 修回日期: 2025-06-24

作者简介:

王恩荣(1998), 男, 工学硕士, 主要研究方向为基于人工智能的海上风电爬坡事件预测。

符杨(1968), 男, 博士, 教授, 博士生导师, 主要研究方向为风力发电与并网技术、变压器状态监测与故障诊断。(通信作者)

(本文编辑: 张瑞敏)