

DOI: 10.19783/j.cnki.pspc.241190

## 基于图神经网络的短期风电功率群体预测方法

杨茂<sup>1</sup>, 郭镇鹏<sup>1</sup>, 王达<sup>1</sup>, 张薇<sup>1</sup>, 王勃<sup>2</sup>, 江任贤<sup>1</sup>, 苏欣<sup>1</sup>

(1. 现代电力系统仿真控制与绿色电能新技术教育部重点实验室(东北电力大学), 吉林 吉林 132011;  
2. 中国电力科学研究院有限公司新能源与储能运行控制国家重点实验室, 北京 100192)

**摘要:** 为降低风电波动性对电力系统的影响, 提出了计及时空关联性的大规模风电场群短期功率预测方法, 同步输出所有风电场的短期功率预测结果。首先, 提出了综合考虑风速、风向的空间相关性评价指标, 进一步建立表征风电场群时空相关性的图拓扑结构。然后, 构建一种深度残差图注意力网络挖掘多风电场间的时空相关特征, 在训练过程中保存数据中蕴含的时空价值信息。最后, 提出了虚假预测评价指标, 评估场站预测功率在汇聚成集群预测功率时的虚假预测成分, 使场群预测结果评价更加公平。以中国吉林省的某 20 个风电场组成的风电场群为研究对象开展实验, 实验结果表明提出的风电功率预测模型的日前功率预测准确率达到 91.68%。

**关键词:** 图注意力网络; 深度残差网络; 时空相关性; 短期风电功率预测; 误差评估

### Short-term wind power group forecasting method based on graph neural networks

YANG Mao<sup>1</sup>, GUO Zhenpeng<sup>1</sup>, WANG Da<sup>1</sup>, ZHANG Wei<sup>1</sup>, WANG Bo<sup>2</sup>, JIANG Renxian<sup>1</sup>, SU Xin<sup>1</sup>

(1. Key Laboratory of Modern Power System Simulation and Control & Renewable Energy Technology, Ministry of Education (Northeast Electric Power University), Jilin 132011, China; 2. State Key Laboratory of Operation and Control of Renewable Energy & Storage Systems, China Electric Power Research Institute, Beijing 100192, China)

**Abstract:** To reduce the impact of wind power fluctuations on power systems, a short-term power forecasting method for large-scale wind farm clusters is proposed, which accounts for spatiotemporal correlation and simultaneously outputs short-term power predictions for all wind farms. First, an evaluation index that comprehensively considers the spatial correlation of wind speed and direction is proposed, and a graph topology structure is further established to characterize the spatiotemporal correlation of wind farm clusters. Then, a deep residual graph attention network is constructed to mine the spatiotemporal correlation features between multiple wind farms, preserving the valuable spatiotemporal information embedded in the data during training. Finally, a false prediction evaluation index is proposed to assess the false prediction components of the predicted power at the station when aggregated into cluster prediction power, making a fairer evaluation of cluster prediction results. Experiments are conducted using a cluster composed of 20 wind farms in Jilin province, China. Results show that the proposed wind power forecasting model achieves a day-ahead power prediction accuracy rate of 91.68%.

This work is supported by the National Key Research and Development Program of China (No. 2022YFB2403000).

**Key words:** graph attention network; deep residual network; spatiotemporal correlation; short-term wind power forecasting; error evaluation

## 0 引言

截止到 2024 底, 我国风电装机规模已经达到 5.2 亿 kW, 风电开发规模居于世界首位<sup>[1]</sup>。风电开发体量使其从备用电源向主力电源转变, 在保障电

力供应方面承担着重要地位, 然而风电出力的不确定性使其难以为电力系统所调度, 无法将其直接纳入到发电计划<sup>[2]</sup>。特别在极端天气下, 风电出力难以准确预知, 过度依赖风电出力可能导致巨大电力缺口。2021 年 9 月 25 日, 东北 3500 万 kW 风电总出力仅 3.4 万 kW, 调度部门下达“电网事故拉闸限电”指令, 导致大范围停电<sup>[3]</sup>。

基金项目: 国家重点研发计划项目资助(2022YFB2403000)

集群级的短期风电功率预测技术提供了区域未来 1—3 天的风电出力预测曲线,为电力系统把风电合理纳入到发电计划提供了技术支撑。特别在负荷高峰时段,风电功率预测精度直接影响着电力系统供电可靠性,对于提升电力系统的安全、稳定运行具有重要意义<sup>[4-5]</sup>。

由于我国电力系统结构的特殊性,调度侧可收集风电场上报的短期功率预测结果并进行叠加得到集群级的功率预测结果<sup>[6]</sup>。因此当前主要研究也集中于场站级风电功率预测的研究,核心技术路线包括基于物理的预测方法、基于统计学习的预测方法和组合预测方法等<sup>[7]</sup>。其中基于物理的预测方法通过求解高维大气运动方程组进而得到风电场风速预报数据,并通过空间降尺度求解风机轮毂高度处的风速,最后通过风速-功率转换得到风电场出力。物理预测方法可以充分考虑风电场的局地特性,但是对硬件的依赖程度较高,求解效率低下<sup>[8]</sup>。

基于统计分析的预测方法以风电场的历史观测数据为样本,通过统计算法研究风速及功率序列从历史到未来的延续规律,得到风电功率未来一段时间的预测结果。主要包括自回归移动平均、自回归积分移动平均算法等,此类预测算法建模简单,但是一般仅适用于未来 6 h 之内的功率预测建模,对于更长时间尺度的预测业务适用性较差。近年来,神经网络算法<sup>[9]</sup>、核函数法<sup>[10]</sup>和回归方法等人工智能算法因建模高效、长期工作性能稳定、便于部署和维护等方面的优势,在工程上得到广泛应用。特别是以循环神经网络为代表的深度学习模型的引入,极大地丰富了统计学习方法在风电功率预测领域的应用范围<sup>[11-12]</sup>。

近年来,研究普遍认为单一的人工智能算法适用场景较为局限,以智能算法为基础的组预测模型成为了研究重点。文献[13]构建卷积神经网络(convolutional neural network, CNN)、门控循环单元和全连接神经网络 3 个预测模型,使用 Harris Hawks 算法优化模型的组合权重。文献[14]提出了特征选择—神经网络—参数优化的技术方案,从数值天气预报(numerical weather prediction, NWP)降维、预测器搭建、预测器优化等多个环节提升建模精度。文献[15]通过将转子等效风速、失效率及风廓线等和风速相关的特征加入到输入特征集内,使模型可参考机组状态对功率输出进行决策。文献[16]采用混合经验模态分解算法将输入风速分解为若干频率不同的分量作为建模输入,并提出了非迭代式的功率预测模型,实验结果表明简单的非迭代模型在某些场景下比深度学习模型精度更高。

为了强化调度侧对区域风电出力的观测能力,部分研究关注于直接预测区域的风电出力,发挥调度侧收集的气象、功率大数据的优势。考虑风电场之间的空间相关性可以融合多源数据信息来综合决策,具有空间相关性的风电场之间信息可以互相补充,起到数据增强的作用。文献[17]采用多个观测点的气象数据对风电场的整体气象信息进行表征,研究表明空间多源数据的融合可有效提升预测精度。文献[18]中采用 k 近邻算法对风电场内部机组进行分组,采用多源数据对单台机组的预测功率进行建模。为了刻画区域间的空间相关性边界,降低建模复杂度,文献[19]通过时间序列聚类法,将区域内的风电场划分为有限个集群,以此来确定区域间的空间相关性边界,然后采用主成分分析算法将 NWP 数据进行降维,实现空间数据融合。

当前研究多通过风速或功率序列之间的相似性指标来评价空间相关性,忽略了风向对风电场间空间相关性的影响,对时空相关性的表征不够全面,对于如何综合利用区域的多源数据直接预测场群的功率缺少相关研究。为此提出了综合考虑风速、风向因素的空间相关性评价指标,并进一步基于图论建立了风电场群空间拓扑图,构建了深度残差图神经网络预测所有风电场的日前功率。在叠加法的集群功率预测架构下,提出了虚假预测率评价指标,评价虚假预测成分在预测功率绝对值中所占的比例。在吉林 20 个风电场组成的风电场群验证所提出模型的有效性。

## 1 问题及方法

### 1.1 风电场群短期功率预测框架

直接预测法和叠加法是风电集群功率预测建模的常见方法,此外也有先集群划分再将预测结果叠加的方法,因其主要受场群规模影响,此处不单独分析,两种常见建模方法的技术路线如图 1 所示。

1) 直接预测区域风电总功率,是一种多对一的技术路线,即将多个场站的数据作为输入直接预测

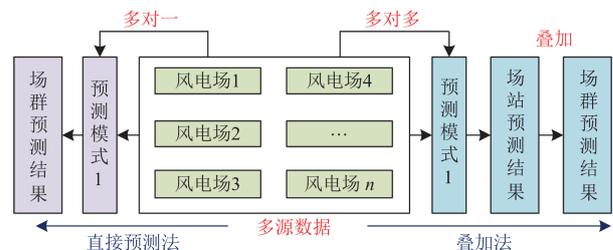


图 1 风电集群短期功率预测技术路线

Fig. 1 Technical route of short-term wind power cluster power forecasting

集群功率, 此技术路线的优点是建模高效, 只需要建立一个模型就可以预测区域风电总功率。其缺点是模型可解释性较差, 区域总功率可以通过叠加得到, 但是区域的气象特性难以统一表征, 风电场分布越分散, 预测模型的可解释性越差。当出现极端误差时, 无法追溯到具体的场站预报误差。

2) 先预测单个风电场的功率, 将各风电场的预测功率叠加得到区域的预测功率。此类建模方法的预测结果可理解性强, 当出现极端预测误差时, 可追溯具体的风电场。缺点是建模效率低, 各风电场需要单独建立预测模型, 此外, 不同风电场的正负预测误差相互叠加, 引起虚假预测现象。

考虑到上述因素, 提出一种集中式的风电场群预测模型。采用一种多对多的建模方法, 将多个风电场的数据作为输入直接预测所有场站的功率, 和单场预测的方式相比可显著提升建模效率, 且有效利用多源数据带来的信息增益。

## 1.2 综合考虑风速-风向的空间相关性评价指标

风电场出力、风速以及风机排列具有因果关系, 风的空间相关性导致风电场出力的相似性, 以往的研究中主要以风速之间的皮尔逊相关系数来描述风电场之间的空间相关性<sup>[20]</sup>, 以吉林的 20 个风电场为研究对象, 2 号风电场和其他风电场间的功率相关系数和风速相关系数散点图如图 2 所示。其中当功率相关系数为 0.5 时, 风速相关系数达到了 0.73, 两者的差值达到了 0.23。可以发现尽管通过相关系数指标能够横向对比相关性的强弱, 但是仅通过预报风速的相关系数反映风电场之间的相关性和实际观测数据相比仍有偏差, 这是由于预报风速低频分量占比较大引起的, 如果能够引入风向因素辅助评价风电场之间的空间相关性, 可以提升空间相关性评价的合理性和准确性。

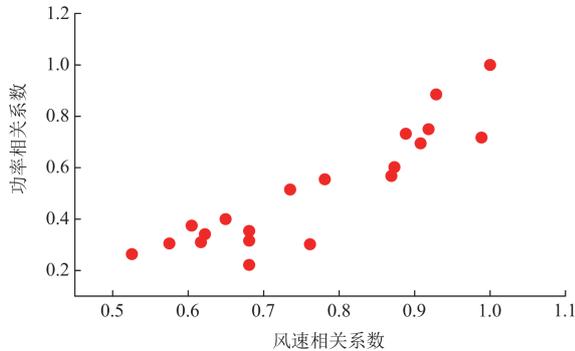


图 2 功率相关系数-风速相关系数散点图

Fig. 2 Scatter diagram of power correlation coefficient and wind speed correlation coefficient

提出风向相关性评价指标, 刻画逐个样本点的风向偏差, 如果两个风电场的预报风向偏差不大于  $10^\circ$ , 则在该时刻将风向偏差编码为 1, 如果风向夹角在  $[10^\circ, 30^\circ]$  内, 将风向偏差编码为 0.5, 如果风向夹角超过  $30^\circ$ , 则编码为 0,  $i$  时刻的风向相关性  $C_{\text{angle}}(i)$  如式(1)所示。

$$C_{\text{angle}}(i) = \begin{cases} 1 & \text{if } |I_{\text{angle}}(i)| \leq 10^\circ \\ 0.5 & \text{if } 10^\circ < |I_{\text{angle}}(i)| \leq 30^\circ \\ 0 & \text{if } |I_{\text{angle}}(i)| > 30^\circ \end{cases} \quad (1)$$

式中:  $I_{\text{angle}}(i)$  表示  $i$  时刻两风电场之间的风向夹角。

通过计算各样本的风向夹角编码的算数平均值, 即可得到风向相关性评估指标  $C_{\text{angle}}$ , 如式(2)所示。

$$C_{\text{angle}} = \frac{1}{n} \sum_{i=1}^n C_{\text{angle}}(i) \quad (2)$$

式中:  $n$  表示风向序列的长度。

绘制 2 号风电场和 20 个风电场之间的功率相关系数、平均风向偏差角散点图, 如图 3 所示。可以发现, 功率相关系数和平均风向偏差角呈明显的反比关系, 而  $C_{\text{angle}}$  将大的平均风向偏差角编码为较小的数值, 存在一定的合理性。

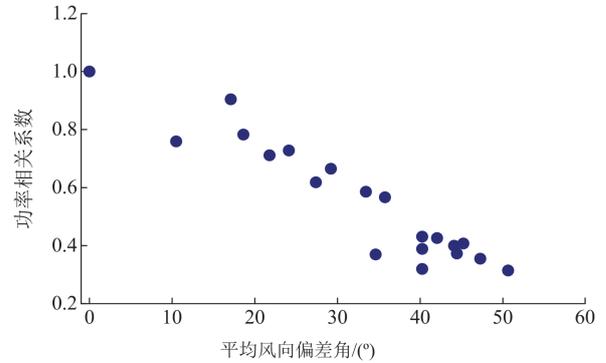


图 3 功率相关系数-平均风向偏差角散点图

Fig. 3 Scatter diagram of power correlation coefficient and average wind direction deviation angle

采用皮尔逊相关系数评价风电场之间的风速相关性, 以 7:3 进行加权得到风速-风向联合相关系数  $C_{\text{mx}}$ , 如式(3)所示。

$$C_{\text{mx}} = 0.7C_{\text{ws}} + 0.3C_{\text{angle}} \quad (3)$$

式中:  $C_{\text{ws}}$  表示风速相关系数。

绘制 20 个风电场和 2 号风电场之间的功率相关系数、风速相关系数以及风速-风向联合相关系数之间的散点图, 如图 4 所示。可以发现和采用风速

评价相关性相比, 提出的风速-风向联合相关系数的评价结果更加准确。使得采用 NWP 描述风电场间空间相关性的强弱时, 刻画得更为精确合理。

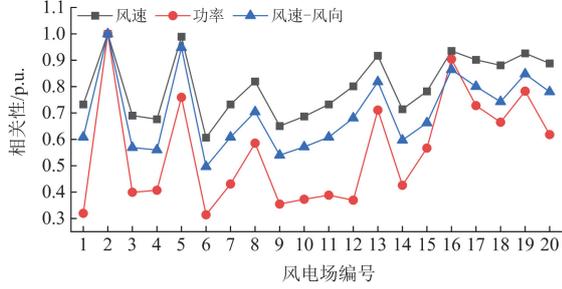


图 4 2 号风电场和各风电场的相关性散点图

Fig. 4 Scatter diagram of correlation between wind farm No. 2 and each wind farm

### 1.3 风电场群短期风电功率预测模型构建

由于风的传播具有惯性, 风速在空间传播过程中不会发生突变, 距离近的风电场之间出力具有相关性。相关研究表明, 将这种空间相关性纳入到建模中来可以有效提升预测精度。在以往的研究中, 有相关研究采用 CNN 模型和图卷积网络提取空间相关特征, 卷积核结构和图拓扑的原理如图 5 所示。CNN 算法需假设数据排列顺序, 容易受主观因素的影响。图理论可以挖掘非欧式空间内的关联关系, 且图结构具有伸展不变性, 不受人为排列因素的影响, 和 CNN 算法相比更适用于挖掘风电场之间的空间相关性。

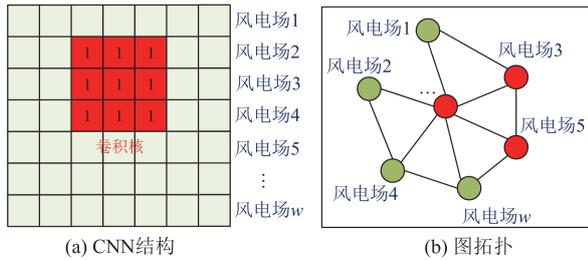


图 5 卷积核结构与图拓扑原理图

Fig. 5 Schematic diagram of convolution kernel structure and graph topology

基于上述分析, 本文采用图注意力神经网络提取多风电场的空间特征。注意力机制可以使网络关注那些对于决策更为关键的特征, 对于弱相关特征赋予低权重来降低噪声干扰<sup>[21]</sup>。图注意力网络首先计算各中心节点与邻域节点的相似性, 然后通过信息聚合对相似性高的信息赋予高权重, 体现出各个相邻节点对中心节点影响的差异性, 对于目标风电场的功率预测而言, 相当于保持自身有用信息的同

时, 聚合其他风电场的有价值信息, 有助于提升功率预测精度。

图注意力层的计算主要包括权重系数求取和特征聚合 2 个步骤。网络的输入为节点的特征向量集合  $F$ , 如式(4)所示。

$$F = \{f_1, f_2, \dots, f_m\} \quad (4)$$

式中:  $f_r$  为节点  $r$  的特征向量;  $m$  为网络节点个数。

对于节点  $l$ , 可根据注意力机制计算出目标节点与邻域节点的相似性, 通过 Softmax 函数归一化后, 其中节点  $l$  和节点  $k$  在特征聚合后的权重系数  $a_{lk}$  如式(5)所示。

$$a_{lk} = \frac{\exp[\text{LeakyReLU}(s(\mathbf{K}\mathbf{v}_l \parallel \mathbf{K}\mathbf{v}_k))]}{\sum_{k \in N_l} \exp[\text{LeakyReLU}(s(\mathbf{K}\mathbf{v}_l \parallel \mathbf{K}\mathbf{v}_k))]} \quad (5)$$

式中:  $N_l$  为节点  $l$  的邻域节点集合; LeakyReLU 为非线性激活函数;  $s$  为节点相似性计算函数, 本文采用全连接层进行计算;  $\mathbf{K}$  为节点特征变换的权重参数矩阵; “ $\parallel$ ”表示深度学习中的张量拼接;  $\mathbf{v}_l$  和  $\mathbf{v}_k$  分别表示节点  $l$ 、 $k$  的特征向量。

通过进行加权求和, 节点  $l$  的新特征向量  $\mathbf{v}'_l$  如式(6)所示。

$$\mathbf{v}'_l = \sigma \left( \sum_{k \in N_l} a_{lk} \mathbf{K}\mathbf{v}_k \right) \quad (6)$$

式中:  $\sigma$  为 Sigmoid 激活函数。

多头注意力机制有助于增强注意力层表达能力的鲁棒性, 分别使用多组相互独立的注意力机制对式(6)进行扩展, 并将得到的输出结果进行拼接, 如式(7)所示。

$$\mathbf{v}'_l = \sum_{h=1}^H \sigma \left( \sum_{k \in N_l} \alpha_{lk}^{(h)} \mathbf{K}^{(h)} \mathbf{v}_k \right) \quad (7)$$

式中:  $H$  为注意力机制的头数;  $\alpha_{lk}^{(h)}$  为第  $h$  组注意力机制计算的权重系数;  $\mathbf{K}^{(h)}$  为对应的权重参数矩阵。

多头注意力的计算流程如图 6 所示, 在本文中注意力头数为 3。图中:  $f'_1$  和  $f_2 - f_6$  表示 1 号节点的输入特征,  $f_1$  表示 1 号节点经多头注意力计算后的输出特征。

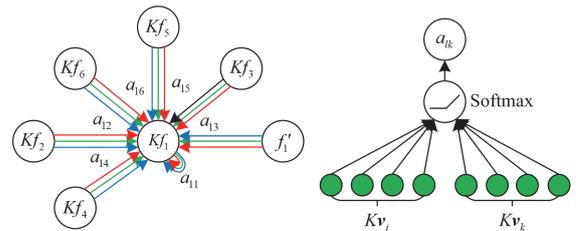


图 6 多头注意力计算

Fig. 6 Multi-head attention calculation

图注意力神经网络可以有效提取各风电场之间的空间特征, 为进一步提取时序特征, 构建一种融合双向循环神经网络的深度残差网络结构, 在网络训练过程中保存信息流, 有效降低网络训练中发生梯度消失和梯度爆炸的风险, 同时提升网络对时序特征的提取能力。其中循环神经网络由简易循环单元(bidirectional simple recurrent unit, Bi\_SRU)实现, SRU 在 RNN 的隐藏层中添加了“细胞”部分, 用于判别和过滤训练过程中的有效信息。

其中深度双向循环残差网络结构由残差基本块堆叠构成, 残差基本块的网络结构如图 7 所示。残差基本块由两个 Bi\_SRU 连接 ID-CNN 构成, Bi\_SRU 结构简单, 长 Bi\_SRU 和短 Bi\_SRU 的学习结果进行拼接可以提升网络对时间序列变化趋势的学习能力<sup>[22]</sup>, Concat 代表 Tenforflow 框架下的张量拼接操作, Dropout 层可以使神经元随机失活, 起到降低网络复杂度的作用。为了提升多个场站预测任务的同步收敛性, 在网络输出层引入多门混合专家(multi-gate mixture-of-experts, MMoE)多任务学习框架对网络输出层进行优化, MMoE 模型包括一个共享的底层网络和用于特定任务的门限网络, 可以更好地捕捉和利用任务间的差异性。

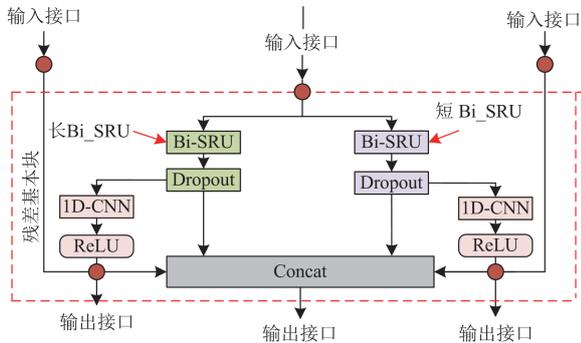


图 7 残差基本块的网络结构

Fig. 7 Network structure of residual basic block

### 1.4 风电场群功率虚假预测成分评估

区域级风电功率预测结果可以由风电场功率预测结果叠加得到。其中风电场功率预测的有效分量为预测模型可解释的部分, 即预测模型有能力根据学习到的规律得到有效预测结果。预测误差为预测模型的不可解释部分, 为完全随机量<sup>[23]</sup>。由于不同预测模型的性能不同, 所以有效预测的成分也存在差别。

如果首先承认预测模型的主导作用, 则预测结果具有可叠加性, 即所有风电场的功率预测结果相加可以得到区域功率预测结果, 预测误差可以由实际功率减去预测功率得到。如果首先承认预测误差

是不可回避的, 且预测误差完全随机, 则评估预测模型性能时, 应该首先分析误差水平。当两个风电场误差符号相反时, 两个风电场的不可控分量叠加之后反而降低, 此时预测精度的提升是一种非模型能力作用下的结果, 属于虚假预测。因此, 本文提出一种量化虚假预测的统计指标, 和传统的误差评估指标一起评估模型的预测性能。

假设  $j$  时刻所有风电场的正误差之和为  $P_{sum+}$ , 负误差之和为  $P_{sum-}$ , 设序列长度为  $m$ ,  $j$  时刻的虚假预测成分  $P_{false}(j)$  定义如式(8)所示。

$$P_{false}(j) = \min(|P_{sum+}(j)|, |P_{sum-}(j)|) \quad (8)$$

假设  $j$  时刻所有风电场的预测功率叠加值为  $\hat{y}_{sum}(j)$ , 定义虚假预测率  $I_{FP}$  如式(9)所示。

$$I_{FP} = \frac{\sum_{j=1}^n P_{false}(j)}{\sum_{j=1}^n \hat{y}_{sum}(j)} \times 100\% \quad (9)$$

当虚假预测率较高时, 证明了场站预测的正负误差叠加成分较多, 尽管均方根误差较低, 但是其精度不完全是预测模型从数据中学习到的知识起作用, 而是因随机误差的叠加作用引起的精度高。因此, 当采用场站叠加的方式获取区域的功率预测结果时, 提出的虚假预测率指标可以有效评估这一成分, 提升了预测模型评价的全面性。

## 2 算例分析

### 2.1 数据集和评价指标

采用中国吉林的 20 个风电场提供的数据验证模型的性能, 风电场群装机容量为 2854.31 MW, 各风电场的装机容量以及相对位置分别如表 1 和图 8 所示。

表 1 20 个风电场的装机容量

Table 1 Installed capacity (MW) of 20 wind farms

| 风电场 | 装机容量/MW | 风电场 | 装机容量/MW | 风电场 | 装机容量/MW | 风电场 | 装机容量/MW |
|-----|---------|-----|---------|-----|---------|-----|---------|
| 1   | 249.9   | 6   | 45      | 11  | 30.06   | 16  | 99      |
| 2   | 148.5   | 7   | 200.5   | 12  | 49.5    | 17  | 198     |
| 3   | 98.8    | 8   | 240     | 13  | 57.35   | 18  | 49.5    |
| 4   | 197.9   | 9   | 99      | 14  | 198     | 19  | 196.5   |
| 5   | 98.8    | 10  | 99      | 15  | 400     | 20  | 99      |

数据集包含实际功率数据以及配套的数值天气预报数据, 其中数值天气预报数据包含了风速、风向、温度、湿度、压强 5 个属性, 数据跨度从 2018 年 1 月 1 日到 2018 年 12 月 31 日, 数据分辨率为 15 min。由于数值天气预报的尺度为提前一天, 因

此本文的预测时间尺度是提前 1 天的短期预测，模型的输出是次日 0—24 h 共 96 个点的功率预测结果。其中 1—8 月的数据为训练集，9 月、10 月的数据为验证集，11 月、12 月的数据为测试集。对数据进行了滑动窗口处理，窗口长度为 16。

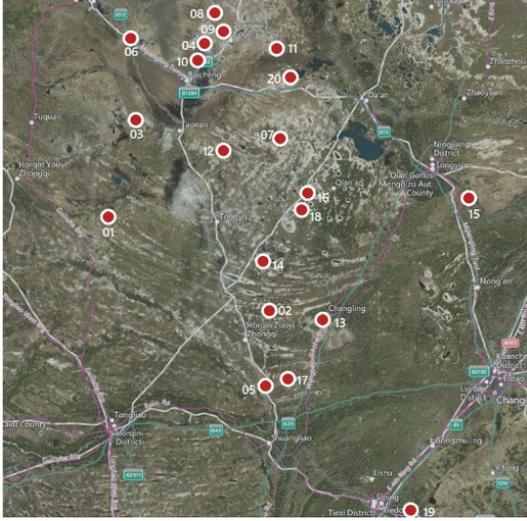


图 8 20 个风电场的位置

Fig. 8 Location of 20 wind farms

为了降低数据量纲对模型训练的影响，将输入数据  $x$  进行归一化，归一化后的数据  $x'$  如式(10)所示。

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (10)$$

式中： $x_{\max}$ 、 $x_{\min}$  分别为输入数据的最大、最小值。

在预测后，通过反归一化算法将预测功率还原到原始的功率区间，反归一化算法如式(11)所示。

$$\hat{p}_{\text{final}} = \hat{p}(p_{\max} - p_{\min}) + p_{\min} \quad (11)$$

式中： $\hat{p}_{\text{final}}$  为最终的功率预测序列； $\hat{p}$  为归一化的预测功率； $p_{\max}$ 、 $p_{\min}$  分别为训练集实际功率的最大、最小值。

采用归一化均方根误差(normalized root mean square error, NRMSE)、归一化平均绝对误差(normalized mean absolute error, NMAE) 2 个指标对短期风电功率预测模型的性能进行评估。 $E_{\text{NRMSE}}$  的计算公式如式(12)所示。

$$E_{\text{NRMSE}} = \sqrt{\frac{\sum_{t=1}^T (y_t - \hat{y}_t)^2}{TC_{\text{ap}}^2}} \quad (12)$$

式中： $y_t$  为  $t$  时刻的实际功率； $\hat{y}_t$  为  $t$  时刻的预测功率； $T$  为测试集长度； $C_{\text{ap}}$  为实际风电场开机容量。由于实际风电场开机容量难以获取，此处以装机容量代替，此外国内一般以  $1 - E_{\text{NRMSE}}$  作为预测准确

率的计算方法。

$E_{\text{NMAE}}$  的计算公式如式(13)所示。

$$E_{\text{NMAE}} = \frac{1}{T} \sum_{t=1}^T \frac{|y_t - \hat{y}_t| \times 100\%}{C_{\text{ap}}} \quad (13)$$

## 2.2 网络结构及参数

网络的残差基本块数量由验证集上的损失进行确定，当残差基本块数量分别为 1—10 时网络损失变化如图 9 所示。当模型共堆叠 4 个残差块时，网络的损失最低，因此最终采用 4 个残差块进行堆叠。网络损失函数采用“mse”，优化函数为“Adam”。算法共迭代 100 次，即 epoch 参数设定为 100，batch\_size 为 256。

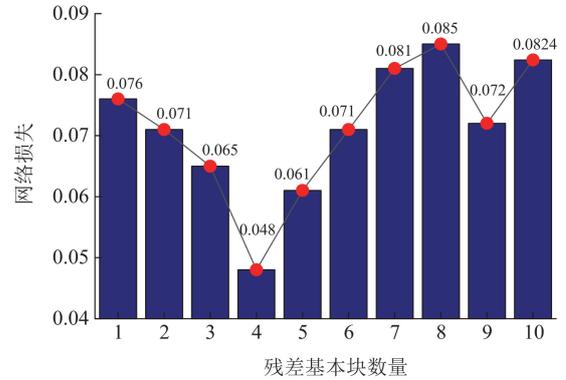


图 9 网络损失随残差基本块数量变化

Fig. 9 Network loss vs. the number of residual basic blocks

在训练过程中采用了提前停止策略，以防止过拟合。如果连续迭代 5 次算法的损失不再下降则提前停止训练。实验平台在 CPU 环境下进行，硬件参数如下：{CPU: Intel(R) Core(TM) i9-10900K CPU@3.7 GHz; Ram: 32 GB}。网络的学习曲线如图 10 所示，在训练初期网络的损失快速下降，网络从数据中快速学习知识，当迭代 8 次之后，损失曲线出现轻微波动，当迭代 46 次时达到收敛。

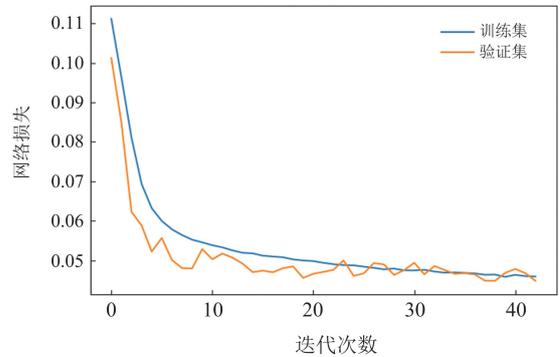


图 10 网络学习曲线

Fig. 10 Network learning curves

节点  $p$ 、 $q$  在邻接矩阵中的数值  $A_{p,q}$  决定了两个节点在图中的连接方式, 计算如式(14)所示。

$$A_{p,q} = \begin{cases} \exp\left(-\frac{d_{vp,vq}^2}{\delta^2}\right), & \text{if } d_{vp,vq} \geq k \\ 0, & \text{otherwise} \end{cases} \quad (14)$$

式中:  $d_{vp,vq}$  为风电场  $p$ 、 $q$  之间的风速-风向联合相关系数;  $\delta$  为风电场间相关性距离的标准差;  $k$  为判断节点是否相连接的阈值, 本文取 0.5。

20 个风电场的空间拓扑结构如图 11 所示, 图结构中不包含孤立节点, 即此建图策略可以有效表征风电场之间的空间相关性, 各风电场可以从相邻节点融合有效信息。

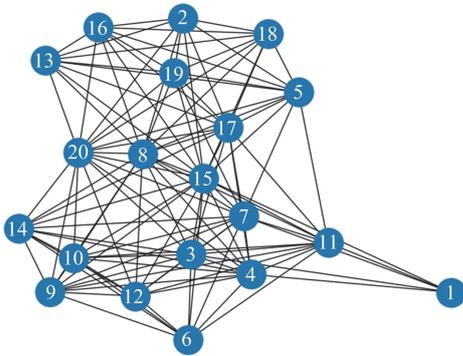


图 11 20 个风电场的空间拓扑结构

Fig. 11 Spatial topological structure of 20 wind farms

### 2.3 预测性能分析

各风电场短期风电功率预测的  $E_{\text{NRMSE}}$  和  $E_{\text{NMAE}}$  如表 2 所示, 如果以  $1 - E_{\text{NRMSE}}$  作为风电功率预测准确率, 则有 15 个风电场的预测准确率达到 85%, 占比达到了 75%。当以  $E_{\text{NMAE}}$  为预测指标时, 取得了类似的结果, 17 个风电场的  $E_{\text{NMAE}}$  低于 0.15。预测模型不能保证所有的风电场预测准确率均高于 85%, 主要是因为气象预报精度限制, 使得场站的

表 2 各风电场预测的  $E_{\text{NRMSE}}$ 、 $E_{\text{NMAE}}$

Table 2 Predicted  $E_{\text{NRMSE}}$  and  $E_{\text{NMAE}}$  of each wind farm

| 风电场 | $E_{\text{NRMSE}}$ | $E_{\text{NMAE}}$ | 风电场 | $E_{\text{NRMSE}}$ | $E_{\text{NMAE}}$ |
|-----|--------------------|-------------------|-----|--------------------|-------------------|
| 1   | 0.0932             | 0.0733            | 11  | 0.1200             | 0.1037            |
| 2   | 0.1496             | 0.1208            | 12  | 0.1329             | 0.1120            |
| 3   | 0.1595             | 0.1326            | 13  | 0.1680             | 0.1525            |
| 4   | 0.1427             | 0.1274            | 14  | 0.1726             | 0.1587            |
| 5   | 0.1298             | 0.1129            | 15  | 0.1504             | 0.1376            |
| 6   | 0.1158             | 0.0963            | 16  | 0.1437             | 0.1292            |
| 7   | 0.1252             | 0.1069            | 17  | 0.1460             | 0.1296            |
| 8   | 0.1243             | 0.1183            | 18  | 0.1802             | 0.1687            |
| 9   | 0.1365             | 0.1233            | 19  | 0.1168             | 0.0923            |
| 10  | 0.1401             | 0.1289            | 20  | 0.1427             | 0.1270            |

短期功率预测精度较低, 这一现象可以通过和其他预测模型的性能进行对比得到验证。另一方面, 同时预报 20 个风电场的风电功率类似于多目标优化问题, 尽管集群整体的功率预测精度得到提升, 但是很难保证所有风电场的功率预测精度同时都是最优的, 这也是多场站联合预报的局限性所在。

为进一步验证本文提出的图注意力机制-双向简易门控残差网络(GAT-BiSRU-residual network, GBSRN)模型的性能, 将该模型预测的  $E_{\text{NRMSE}}$  指标和其他模型进行对比, 所有对比模型都采用多对多的方式进行建模(传统的随机森林和支持向量机算法无法直接实现多对多建模, 采用 Python 平台下的 Scikit-learn 工具包辅助实现), 对比模型包含线性回归(linear regression, LR)、图注意力网络(graph attention network, GAT)、随机森林(random forest, RF)、支持向量机(support vector machine, SVM)以及长短期记忆网络(long short-term memory network, LSTM)。

为了提升网络性能对比的合理性, 将对比较模型的参数进行优化, 优化的参数如表 3 所示。

表 3 对比模型的超参数调优

Table 3 Hyperparameter tuning of comparison models

| 预测模型 | 超参数调优                |
|------|----------------------|
| LSTM | 学习率、隐含层数量、batch_size |
| RF   | 决策树数量、决策树深度          |
| GAT  | batch_size、隐含层数量、学习率 |
| SVM  | 核函数类型                |

其中, 深度学习的学习率和 batch\_size 决定了网络收敛性, 隐含层数量决定了特征提取的有效性, 决策树数量和决策树深度决定了随机森林算法的拟合精度, SVM 算法的核函数决定了其学习性能, 优化这些参数有利于提升性能对比的公平性。

各模型的性能对比结果如图 12 所示, 其中提出的 GBSRN 模型在 17 个风电场取得了最低误差, 适用于 85% 的风电场。对于 6 号和 14 号风电场, RF

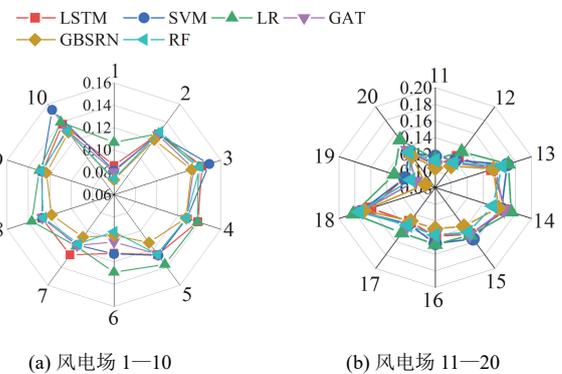


图 12 风电场 1—20 的  $E_{\text{NRMSE}}$  指标分布

Fig. 12  $E_{\text{NRMSE}}$  index distribution of wind farm 1—20

模型取得了最低误差, LSTM 模型在 13 号风电场误差最低。总体来说, GBSRN 模型更适用于此场群的短期功率预测。

以 1 号风电场为例, 验证 GBSRN 模型对于时空特征提取的有效性, 某一周的预测曲线如图 13 所示。其中 GAT 模型和 GBSRN 模型对于高峰拟合能力较好, 但是 GAT 模型的波峰预测存在严重的时序偏差, 这是由于 GBSRN 模型引入了深度循环残差网络结构, 能够更好地提取时序信息, 增强峰谷拟合能力。SVM、LSTM 和 LR 模型预测结果呈现的均态化趋势最为明显, 峰谷拟合能力较差。与 GBSRN 模型相比, RF 模型预测的绝对偏差较低, 风电波动趋势的预测能力较弱。经对比分析, GBSRN 模型更适用于场站级的短期功率预测, 预测曲线质量较高。

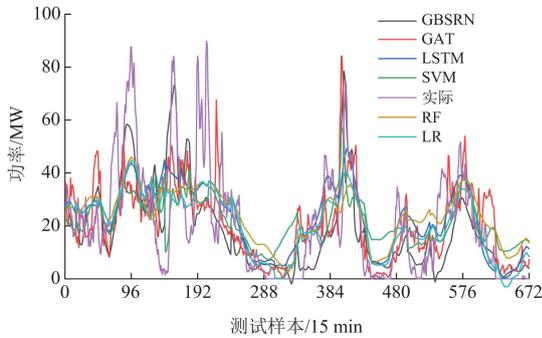


图 13 1 号风电场一周预测曲线

Fig. 13 One-week prediction curve of No. 1 wind farm

由于区域发电计划的制定以风电场总功率的预测结果为依据, 而单个风电场的预测功率以及误差对调度计划提供的价值有限。将 20 个风电场的预测功率进行叠加, 得到区域风电功率预测结果, 预测曲线如图 14 所示。其中本文提出的 GBSRN 模型的  $E_{NMAE}$ 、 $E_{NRMSE}$  最低, 由于正负误差相互抵消, 使得相较于单个风电场, 风电集群的预测  $E_{NMAE}$ 、 $E_{NRMSE}$  和单个风电场相比都较低。和基准模型相比,  $E_{NRMSE}$  降低了 0.03%, 相当于每个样本点降低 85.63 MW 的预报功率偏差。GAT 模型由于缺少时序特征挖掘性能, 精度略低于 GBSRN 模型。集成学习算法中的 RF 模型预测精度也较高, 优于深度学习的 LSTM 模型, 但是统计模型中的 SVM 和 LR 模型由于缺乏特殊的时序特征处理机制, 预测精度较差。

风电功率预测是一种时间序列预测问题, 预测波形的质量同样是反映预测模型性能的关键参数。选取一个区域风电高出力日和低出力日评价预测波形质量, 如图 15 所示。

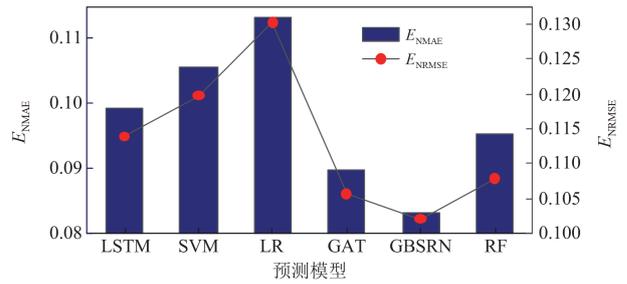
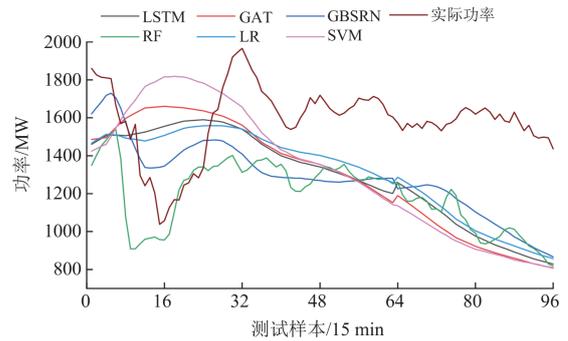
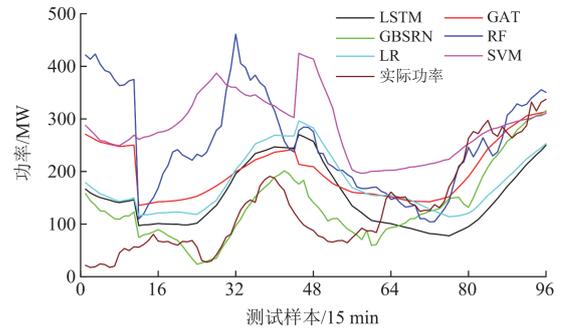


图 14 风电场集群的预测误差分布

Fig. 14 Prediction error distribution of wind farm clusters



(a) 12月18日的预测波形



(b) 12月23日的预测波形

图 15 高出力及低出力日的预测功率曲线

Fig. 15 Predicted power curves of high and low output days

其中高出力日为 2018 年 12 月 18 日, 共 96 个采样点, 其中实际风电功率是先降后升, 然后维持持续的高出力。LSTM、SVM、LR 以及 GAT 模型无法有效预测下降趋势, 对于上升趋势的预测也不够敏感。RF 模型预测的下降趋势过于陡峭, 把缓慢下降过程预测为急剧下降过程。本文提出的 GBSRN 模型可以有效预测出风电集群功率的下降和上升趋势, 在高出力时预测波形质量较好。低出力日为 12 月 23 日, 风电集群维持一个比较低的出力水平, 各预测模型都将 00:00—03:00 时段的缓慢上升趋势预测为下降趋势, 但是 GBSRN 模型的绝对误差较低。对于 08:00—12:00 时段的波峰, GBSRN 模型

也能较好地跟随实际功率曲线。在低出力时段, GBSRN 模型的预测曲线也优于其他预测模型。

进一步考察各预测方法对于风电集群预测的虚假预测问题, 将各预测算法的虚假预测率进行对比, 对比结果如图 16 所示, 其中 GBSRN 模型的虚假预测率为 9.7%, 在所有预测模型中占比最低。LR 模型由于学习能力较弱, 虚假预测的成分也较高。GBSRN、LSTM、GAT 深度学习模型的虚假预测率较低, 而 SVM、LR、RF 机器模型的虚假预测率较高。

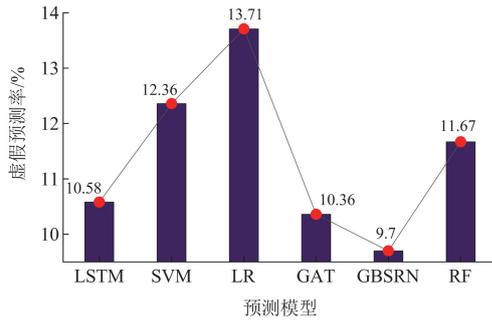


图 16 不同预测模型的虚假预测率

Fig. 16 False prediction rates of different forecasting models

为了验证所提出的 GBSRN 短期风电功率预测模型性能的稳定性, 本文在不固定随机数种子的条件下独立进行了 100 次模型训练, 其在测试集上  $E_{\text{NRMSE}}$  和  $E_{\text{NAME}}$  指标的分布如图 17 所示。可以看出,  $E_{\text{NRMSE}}$  和  $E_{\text{NAME}}$  的波动范围很小, 训练时的随机过程对预测性能的影响较小, 证明了 GBSRN 模型在训练期间性能比较稳定。

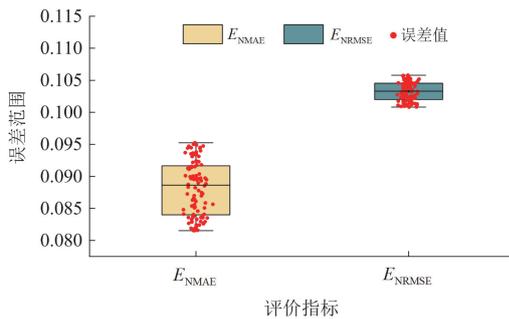


图 17 100 次独立实验的  $E_{\text{NRMSE}}$ 、 $E_{\text{NAME}}$  分布

Fig. 17 Distribution of  $E_{\text{NRMSE}}$  and  $E_{\text{NAME}}$  in 100 independent experiments

### 3 结论

经过实验, 本文提出的基于 GAT 和深度双向循环残差网络的风电场群功率预测模型 GBSRN 在吉林的 20 个风电场上表现出较高的准确性和较强的

稳定性, 得到结论如下。

1) 本文设计的风速-风向联合相关系数对于评估风电场群的空间相关性具有更好的适用性, 对于建立表征风电场间空间相关性的图邻接矩阵具有指导意义。

2) 本文提出的 GBSRN 模型在风电场群短期功率预测方面表现优越, 对吉林的 20 个风电场群短期功率预测准确率达到 91.68%, 同时在 17 个风电场取得了最优性能。

3) 单场叠加的预测模式存在虚假预测问题, 其中本文提出的 GBSRN 模型的虚假预测率为 9.7%, 在对比模型中最低。

综合实验结果, 本文提出的短期风电功率预测模型和方法具有重要的理论和工程意义, 对于调度侧合理利用场站的风电功率预测结果制定发电计划具有重要指导意义。

### 参考文献

- [1] 杨茂, 孙志博, 苏欣. 基于混沌理论的风电功率超短期预测模式改进研究[J]. 中国电机工程学报, 2022, 42(22): 8117-8129.  
YANG Mao, SUN Zhibo, SU Xin. Research on improvement of ultra-short-term wind power forecasting model based on chaos theory[J]. Proceedings of the CSEE, 2022, 42(22): 8117-8129.
- [2] ZHAO S, SHAO C, DING J, et al. Unreliability tracing of power systems for identifying the most critical risk factors considering mixed uncertainties in wind power output[J]. Protection and Control of Modern Power Systems, 2024, 9(5): 96-111.
- [3] 胡宇晗, 朱利鹏, 李佳勇, 等. 融合深度误差反馈学习和注意力机制的短期风电功率预测[J]. 电力系统保护与控制, 2024, 52(4): 100-108.  
HU Yuhang, ZHU Lipeng, LI Jiayong, et al. Short-term wind power forecasting with the integration of a deep error feedback learning and attention mechanism[J]. Power System Protection and Control, 2024, 52(4): 100-108.
- [4] 张倩, 蒙飞, 李涛, 等. 基于周期信息增强的 Informer 光伏发电功率预测[J]. 中国电力, 2023, 56(10): 186-193.  
ZHANG Qian, MENG Fei, LI Tao, et al. Informer photovoltaic power generation forecasting based on cycle information enhancement[J]. Electric Power, 2023, 56(10): 186-193.
- [5] 宋家康, 赵建勇, 孙海霞, 等. 基于多目标协同训练的风电功率预测提升算法[J]. 电力工程技术, 2023, 42(6): 232-240.  
SONG Jiakang, ZHAO Jianyong, SUN Haixia, et al. Wind power prediction and improvement algorithm based on multi-objective collaborative training[J]. Electric Power

- Engineering Technology, 2023, 42(6): 232-240.
- [6] 王勃, 王铮, 刘纯, 等. 风电功率预测技术及应用[M]. 北京: 中国电力出版社, 2019.
- [7] 彭曙蓉, 彭家宜, 杨云皓, 等. 基于时变深度前馈神经网络的风电功率概率密度预测[J]. 电力科学与技术学报, 2023, 38(3): 84-93.  
PENG Shurong, PENG Jiayi, YANG Yunhao, et al. Wind power probability density prediction based on time-variant deep feed-forward neural network[J]. Journal of Electric Power Science and Technology, 2023, 38(3): 84-93.
- [8] 刘新宇, 蒲欣雨, 李继方, 等. 基于贝叶斯优化的 VMD-GRU 短期风电功率预测[J]. 电力系统保护与控制, 2023, 51(21): 158-165.  
LIU Xinyu, PU Xinyu, LI Jifang, et al. Short-term wind power prediction of a VMD-GRU based on Bayesian optimization[J]. Power System Protection and Control, 2023, 51(21): 158-165.
- [9] McKinsey Global Institute. Big data: the next frontier for innovation, competition, and productivity[R]. San Francisco: McKinsey Global Institute, 2011.
- [10] YUAN X, CHEN C, YUAN Y, et al. Short-term wind power prediction based on LSSVM-GSA model[J]. Energy Conversion and Management, 2015, 101: 393-401.
- [11] 李卓, 叶林, 戴斌华, 等. 基于 IDSCNN-AM-LSTM 组合神经网络超短期风电功率预测方法[J]. 高电压技术, 2022, 48(6): 2117-2127.  
LI Zhuo, YE Lin, DAI Binhua, et al. Ultra-short-term wind power prediction method based on IDSCNN-AM-LSTM combination neural network[J]. High Voltage Engineering, 2022, 48(6): 2117-2127.
- [12] 孟安波, 陈顺, 王陈恩, 等. 基于混沌 CSO 优化时序注意力 GRU 模型的超短期风电功率预测[J]. 电网技术, 2021, 45(12): 4692-4700.  
MENG Anbo, CHEN Shun, WANG Chen'en, et al. Ultra-short-term wind power prediction based on chaotic CSO optimized temporal attention GRU model[J]. Power System Technology, 2021, 45(12): 4692-4700.
- [13] HOSSAIN M A, CHAKRABORTTY R K, ELSAWAH S, et al. Predicting wind power generation using hybrid deep learning with optimization[J]. IEEE Transactions on Applied Superconductivity, 2021, 31(8): 1-5.
- [14] RENANI E T, ELIAS M F M, RAHIM N A. Using data-driven approach for wind power prediction: a comparative study[J]. Energy Conversion and Management, 2016, 118: 193-203.
- [15] ALKESAIBERI A, HARROU F, SUN Y. Efficient wind power prediction using machine learning methods: a comparative study[J]. Energies, 2022, 15(7).
- [16] SHAHID F, ZAMEER A, MEHMOOD A, et al. A novel wavenets long short term memory paradigm for wind power prediction[J]. Applied Energy, 2020, 269.
- [17] TORABI A, MOUSAVY S A K, DASHTI V, et al. A new prediction model based on cascade NN for wind power prediction[J]. Computational Economics, 2019, 53: 1219-1243.
- [18] KHALID M, SAVKIN A V. A method for short-term wind power prediction with multiple observation points[J]. IEEE Transactions on Power Systems, 2012, 27(2): 579-586.
- [19] 王勃, 刘纯, 冯双磊, 等. 基于集群划分的短期风电功率预测方法[J]. 高电压技术, 2018, 44(4): 1254-1260.  
WANG Bo, LIU Chun, FENG Shuanglei, et al. Prediction method for short-term wind power based on wind farm clusters[J]. High Voltage Engineering, 2018, 44(4): 1254-1260.
- [20] 王小明, 徐斌, 尹元亚, 等. 基于空间相关性与 Stacking 集成学习的风电功率预测方法[J]. 电力工程技术, 2024, 43(5): 224-232.  
WANG Xiaoming, XU Bin, YIN Yuanya, et al. Wind power prediction method based on spatial correlation and Stacking ensemble learning[J]. Electric Power Engineering Technology, 2024, 43(5): 224-232.
- [21] 赵紫昱, 陈渊睿, 陈霆威, 等. 基于时空图注意力网络的超短期区域负荷预测[J]. 电力系统自动化, 2024, 48(12): 147-155.  
ZHAO Ziyu, CHEN Yuanrui, CHEN Tingwei, et al. Ultra-short-term regional load forecasting based on spatio-temporal graph attention network [J]. Automation of Electric Power Systems, 2024, 48(12): 147-155.
- [22] 吴晨, 姚菁, 薛贵元, 等. 基于 MMoE 多任务学习和长短时记忆网络的综合能源系统负荷预测[J]. 电力自动化设备, 2022, 42(7): 33-39.  
WU Chen, YAO Jing, XUE Guiyuan, et al. Load prediction of integrated energy system based on MMoE multi-task learning and short-duration memory network[J]. Electric Power Automation Equipment, 2022, 42(7): 33-39.
- [23] 雷柯松, 吐松江·卡日, 伊力哈木·亚尔买买提, 等. 基于 WGAN-GP 和 CNN-LSTM-Attention 的短期光伏功率预测[J]. 电力系统保护与控制, 2023, 51(9): 108-118.  
LEI Kesong, TUSONGJIANG Kari, YILIHAMU Yaermaimaiti, et al. Prediction of short-term photovoltaic power based on WGAN-GP and CNN-LSTM-Attention[J]. Power System Protection and Control, 2023, 51(9): 108-118.

收稿日期: 2024-09-03; 修回日期: 2024-11-17

作者简介:

杨茂(1982—), 男, 博士, 教授, 博士生导师, 研究方向为新能源功率预测; E-mail: yangmao820@163.com

郭镇鹏(2001—), 男, 硕士研究生, 研究方向为新能源功率预测; E-mail: 1908656567@qq.com

王达(1995—), 男, 通信作者, 博士研究生, 研究方向为新能源功率预测。E-mail: 1610909212@qq.com

(编辑 张颖)