

DOI: 10.19783/j.cnki.pspc.231395

考虑阵列间时空相关性的超短期光伏出力预测

韩晓¹, 王涛¹, 韦晓广², 王军¹

(1. 西华大学电气与电子信息学院, 四川 成都 610039; 2. 西南交通大学电气工程学院, 四川 成都 610031)

摘要: 随着我国光伏产业建设步伐的加快, 光伏出力预测对于优化电网调度和提高新能源消纳的意义日益凸显。基于光伏站点中不同阵列之间的空间相关性和光伏功率输出的时序特性, 提出一种基于图卷积神经网络和长短期记忆网络(graph convolution network and long short-term memory, GCN-LSTM)的超短期光伏出力预测方法。该方法首先以图的形式刻画出光伏站点中不同阵列的连接关系。然后利用图卷积神经网络(graph convolution network, GCN)实现图模型的空间特征提取, 并得到包含不同阵列之间空间特征的时序信息。最后将时序数据输入长短期记忆网络(long short-term memory, LSTM)进行光伏出力预测。实验结果表明, 基于 GCN-LSTM 的光伏出力预测方法具有较高的精确性与稳定性, 在一定程度上弥补了基于时序信息预测方法的固有缺陷, 并且展现出在大规模电站上的良好应用前景。

关键词: 光伏发电; 超短期预测; 时空相关性; 图卷积神经网络; 长短期记忆网络

Ultrashort-term photovoltaic output forecasting considering spatiotemporal correlation between arrays

HAN Xiao¹, WANG Tao¹, WEI Xiaoguang², WANG Jun¹

(1. School of Electrical Engineering and Electronic Information, Xihua University, Chengdu 610039, China;
2. School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: Photovoltaic (PV) output forecasting is crucial for optimizing power grid dispatching and enhancing new energy consumption, especially with the rapid development of the PV industry in China. To capture the spatial correlation among different arrays in a PV site and the temporal dynamics of PV power outputs, a novel ultra-short-term PV output forecasting method based on a graph convolutional network and long short-term memory (GCN-LSTM) network is proposed. The proposed method first constructs a graph model to represent the connection relationships of different arrays on the PV site. Then the graph convolutional network is used to extract spatial features from the graph model to obtain time series data that incorporate the spatial relationships among different arrays. Finally, time series data is input into the LSTM network to perform PV output prediction. Experiments demonstrate that the GCN-LSTM-based PV output forecasting method achieves high accuracy and stability, which makes up for the inherent limitations of prediction methods based on time series data and shows promising application potential in large-scale power plants.

This work is supported by the National Key R & D Program of China (No. 2021YFB2601500).

Key words: photovoltaic power generation; ultra-short-term forecasting; spatio-temporal correlation; graph convolution network; long short-term memory network

0 引言

作为最丰富和最具发展前景的可再生能源之一, 太阳能的开发与利用已经成为我国能源发展的主要方向。在“碳达峰、碳中和”及构建新型电力

系统的背景下, 光伏产业迎来了巨大的发展机遇。国家能源局发布的 2022 年电力工业统计数据显示, 截至 2022 年 12 月底, 全国太阳能发电装机容量约为 3.9 亿 kW, 同比增长 28.1%^[1]。光伏能源的大规模渗透, 毫无疑问地加速了我国电力系统的清洁化进程。但是, 光伏能源的波动性和不确定性又在很大程度上阻碍了光伏能源的深度消纳, 同时也为电力系统的调度和调节带来了巨大挑战。目前, 光伏

基金项目: 国家重点研发计划项目资助(2021YFB2601500);
成都市科技局揭榜挂帅科技项目资助(2023-JB00-00002-SN)

发电功率预测是解决上述问题最为经济可行的途径之一。

按照预测的时间尺度, 光伏功率预测方法可以分为中长期^[2-3]、短期^[4-7]和超短期预测^[8-11]三大类。其中, 中长期预测主要关注以月、季度为时间尺度的光伏电站出力情况, 用于指导光伏电站的建设和电力系统的长期规划。而短期预测则主要关注未来几小时到一天内的光伏出力情况, 主要用来指导制定日前调度计划。与前两类方法相比, 超短期预测方法则关注未来 0~6 h 的光伏出力情况, 并且预测的时间粒度通常为 15 min 甚至更低, 主要用来辅助调度人员实时地调整日内调度计划。

由于超短期预测的时间尺度短且时间粒度较小, 因此对预测结果的精确度要求更高, 预测难度也更大, 逐步引起了学者的广泛关注。比如, 文献[12]提出了卷积神经网络-长短期记忆网络(convolution neural network-long short-term memory, CNN-LSTM)与 XGBoost 组合预测的方法, 综合了不同模型的优势, 弥补了单一模型精度较低的缺陷。文献[13]利用自组织映射网络对天气情况进行了聚类分型, 并针对不同天气类型结合奇异谱分解和变分模态分解光伏功率数据, 最后利用 BiGRU 实现光伏功率的超短期预测, 相比于多数经典预测方法有效提升了预测精度。但是上述方法并未考虑云层或运动型云团等影响因素^[14-15]。

于是, 部分研究开始采用基于地基云图或卫星云图的方法来实现光伏出力的超短期预测。例如, 文献[16]通过提取地基云图特征, 跟踪云团运动轨迹实现了辐照度系数的预测, 并基于改进注意力机制(improved attention mechanism, IAM)的卷积-长短期记忆混合神经网络 IAM-CNN-LSTM 进一步实现了光伏电站输出功率的预测。文献[17]则利用图像处理技术来提取地基云图关键特征, 并将直接图像处理特征作为光伏功率预测模型的输入数据, 然后利用梯度提升决策树模型实现了光伏功率的超短期预测。文献[18]首先利用质心移动算法预测未来时刻的卫星云图, 并在此基础上实现了云图中云遮挡区域的实时定位, 然后采用卷积神经网络(convolution neural network, CNN)获取云遮挡特征并将其作为输入特征量, 通过多层神经网络实现了光伏功率的超短期预测。文献[19]基于高时空分辨率的卫星云图, 实现了云团的识别以及轨迹的跟踪与预测, 并在此基础上构建了光伏电站云遮挡模型, 有效提高了光伏功率超短期预测的精度。

上述基于地基云图和卫星云图的超短期预测方法虽然有效提升了光伏功率预测的精度, 但是在实

际应用中仍然存在一定限制。比如, 地基云图的观测范围有限, 而且全天空成像仪的安装和维护成本较高。此外, 卫星云图数据获取困难且空间精度较低, 定位到某一具体电站时容易产生误差。于是, 文献[20]利用光伏电站内不同光伏阵列之间输出功率的差异, 反向推导出云层遮挡情况, 并构建了电站内的虚拟云图, 然后基于虚拟云图的形状及运动轨迹实现了光伏功率的秒级预测。文献[20]从光伏阵列自身的功率情况反推出虚拟云图, 证明了不同光伏阵列各自的出力情况之间存在的时空关系已经包含了云层遮挡的影响特征。因此, 可以充分利用不同光伏阵列之间功率输出的时空相关性来实现光伏电站功率的超短期预测。

在预测模型方面, 现有研究多数采用 CNN 与一些时序模型如长短期记忆网络(long short-term memory, LSTM)、循环神经网络(recurrent neural network, RNN)等相结合的方式来提取时空特征^[21-24]。虽然 CNN 在提取空间特征上表现出了较好的性能, 但是它只能处理如音频、图像和视频等规则数据, 限制了其在一些特定领域的应用^[25]。对光伏电站而言, 电站中光伏板的排布不一定规则, 因此无法利用 CNN 有效提取不同光伏阵列之间的空间特征。

综上所述, 本文提出一种考虑不同光伏阵列间出力的时空相关性的超短期光伏出力预测方法。此方法使用不同光伏阵列的历史出力数据的时间和空间相关信息来预测未来短时间内的功率输出, 不需要基于太阳辐照度值, 而仅仅基于光伏电站的历史出力数据实现对未来出力的预测^[26-28]。这种预测方法不需要高分辨率的未来数值天气预报数据, 便可获得满足超短期尺度预测精度要求的结果。首先, 将光伏站点中光伏阵列的排布情况抽象为图, 并以图的形式表示各光伏阵列之间的连接关系; 然后, 采用图卷积神经网络(graph convolution network, GCN)提取不同阵列之间的空间相关信息; 最后, 利用 LSTM 的时序预测能力实现光伏站点的超短期功率预测。为了验证所提方法的可行性和有效性, 本文首先在一个澳大利亚 9 阵列站点上进行仿真实验。此外, 为了进一步挖掘所提方法在大规模电站上的应用潜力, 本文在一个具有 80 个阵列的光伏数据上对所提方法进行仿真实验和分析。

1 基于 GCN-LSTM 的光伏功率预测模型

1.1 图卷积神经网络

本文提出的考虑光伏阵列间的时空相关性的方法需要提取不同阵列之间的空间特征, 目前大多数针对空间特征提取的研究均采用 CNN 来实现。而

CNN 只能处理分布规则的数据,并不适用于提取光伏站点内不同阵列之间的空间特征,如图 1 所示,当光伏站点内的光伏阵列排布不规则时,如图中红框处,CNN 便无法处理。

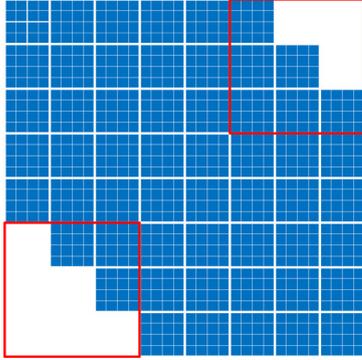


图 1 光伏阵列排布示意图

Fig. 1 Schematic diagram of photovoltaic arrays arrangement

为了解决这一问题,本文将光伏阵列的排列情况以图的方式刻画出来。如图 2 所示,将每一个光伏阵列视为一个节点,相邻的光伏阵列以边相连,这样便可使用 GCN 来替代 CNN 实现光伏阵列之间的时空特征提取。

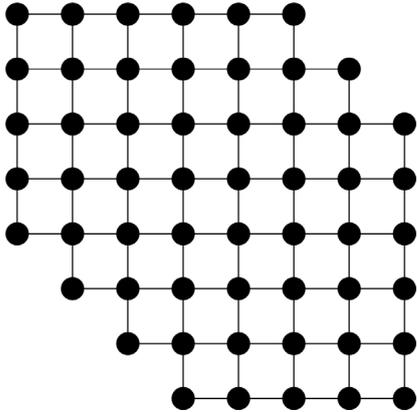


图 2 图结构的光伏阵列排布图

Fig. 2 Graph of photovoltaic arrays arrangement

无论是规则数据还是不规则数据,都可以采用图结构 $G=(V,E)$ 来表示,其中 V 表示图 G 的顶点集合, E 表示图 G 的边集合。

常用的 GCN 方法包含图谱域与空间域两种,本文采用文献[29]提出的图谱域的 GCN 模型,具体计算方法如式(1)所示。

$$H^{(l+1)} = f(H^{(l)}, A) = \sigma(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)}) \quad (1)$$

式中: $H^{(l)} \in \mathbf{R}^{n \times d}$ 是第 l 层的网络输出,其中 n 为图 G 中的节点数量, d 为每个节点的特征向量维度, $H^{(0)}$ 为初始输入数据; A 为图 G 的邻接矩阵,只包

含每一节点与其他节点的连接信息; $\tilde{A} = A + I_N$, I_N 为 N 阶单位矩阵,加入单位矩阵之后, \tilde{A} 就可以表示整个图的连接信息; \tilde{D} 为对角矩阵,其元素 $\tilde{D}_{ii} = \sum_j \tilde{A}_{ij}$ 为图 G 的度矩阵,其中 \tilde{A}_{ij} 表示 \tilde{A} 中第 i 行第 j 列的元素; $W^{(l)}$ 为可训练参数, $W^{(l)} \in \mathbf{R}^{d \times c}$,其中 c 为输出维度; σ 为激活函数。

简单来说,GCN 的特征提取本质上是利用图的顶点与边的连接信息,以及一些附属于其结构的属性信息来对图结构数据进行特征提取。图 3 所示为 GCN 的网络结构图,图中 X 为每一个输入节点,包含每一个节点的输入信息。在本文中,每一个 X 包含对应阵列的历史出力信息, Y 为经过卷积计算后的节点信息,即网络的输出值。每一层卷积采用式(1)进行计算,通过监督或半监督学习对权重 W 进行更新,达到利用中心节点自身及其邻域信息对节点的信息进行更新的目的。

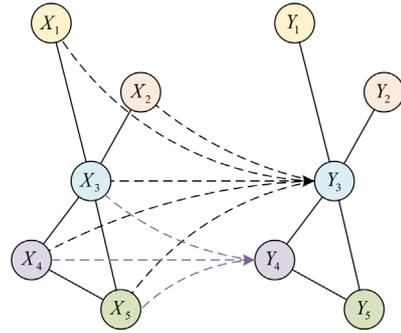


图 3 GCN 网络结构图

Fig. 3 Architecture of GCN network

1.2 长短期记忆网络

LSTM 是一种特殊的 RNN,它解决了 RNN 在训练过程中的梯度消失和梯度爆炸问题^[30-31]。LSTM 的神经元结构如图 4 所示,LSTM 通过引入门机制实现了记忆和遗忘神经元中信息的功能,因此其在处理较长序列时比 RNN 具有更好的表现。

在图 4 所示的神经元结构计算过程中,通过计算 $t-1$ 时刻的神经元状态 C_{t-1} 与遗忘门输出值 f_t 的哈达玛积,可以得到遗忘部分信息后的新状态 C'_t ,计算过程为

$$C'_t = f_t \odot C_{t-1} \quad (2)$$

$$f_t = \text{sigmoid}(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3)$$

式中: h_{t-1} 为 $t-1$ 时刻隐藏层输出值; x_t 为 t 时刻的数据输入; $[h_{t-1}, x_t]$ 表示将 h_{t-1} 和 x_t 拼接; W_f 和 b_f 为待训练参数; sigmoid 为激活函数。

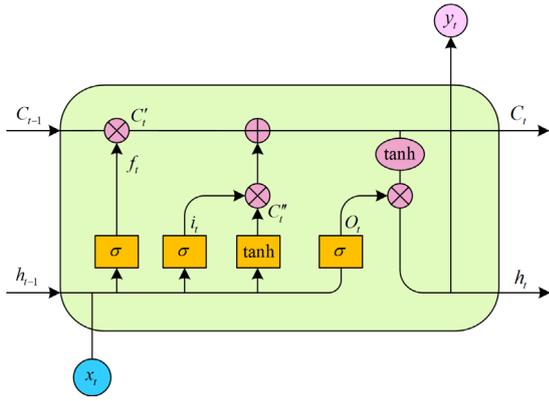


图4 LSTM 神经元结构

Fig. 4 Architecture of LSTM neurons

输入门则用来控制 t 时刻 \tilde{C}_t 中的哪些信息被输入到神经元, 计算过程为

$$i_t = \text{sigmoid}(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_g \cdot [h_{t-1}, x_t] + b_g) \quad (5)$$

式中: i_t 为输入门输出值; W_i 、 W_g 、 b_i 和 b_g 均为待训练参数; \tilde{C}_t 为未经处理的输入信息; \tanh 为激活函数。

通过遗忘门遗忘部分过去时刻的信息且输入门引入 t 时刻的输入信息完成神经元状态的更新, 计算过程为

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (6)$$

通过激活函数计算输出门状态 O_t , 计算过程为

$$O_t = \text{sigmoid}(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (7)$$

式中, W_o 、 b_o 为待训练参数。

基于 O_t 计算隐藏层状态 h_t 与神经元输出 y_t , 计算过程如式(8)所示。

$$y_t = h_t = O_t \odot \tanh(C_t) \quad (8)$$

1.3 GCN-LSTM 时空预测算法

一个光伏电站通常由大量光伏阵列组成, 从空间上看光伏阵列分布范围较大, 在受到一些不均匀因素影响时, 不同阵列之间的功率输出会产生一定差异。例如在有风天气, 受空气流动影响, 迎风面光伏组件散热能力强, 输出功率上升, 而背风面光伏组件散热能力弱, 输出功率略低^[32]。此外, 移动云团的遮挡也是导致光伏阵列间输出功率差异的主要原因。虽然云团移动速度较快, 但是在预测分辨率要求较高的超短期预测中, 移动云团的影响是一个不得不考虑的不确定因素^[33]。然而, 无论是风还是云团造成的影响, 在相邻的光伏阵列之间表现出的差异较小, 并且云团的移动和风向的改变所引起的光伏阵列出力波动在相邻阵列之间呈现出随时间变化的规律。此外, 光伏功率输出曲线通常具有早晚低、中午高的特点, 而且一天之内的波动幅度不大, 从超短期的时间尺度来看, 其功率输出在短时间内几乎没有剧烈降低或剧烈升高的情况, 具有明显的时序特征^[34]。

考虑到光伏阵列之间功率输出存在的这种时空相关特性, 本文将基于电站的光伏阵列功率相关性与光伏阵列分布情况, 搭建 GCN-LSTM 时空预测模型。在搭建模型前, 需要先构建光伏阵列邻接矩阵, 最直接的方法就是采用光伏阵列的空间拓扑结构来实现。如图 5 所示, 直接从光伏阵列的空间结构上抽象出其拓扑结构, 从而得到图的邻接矩阵。

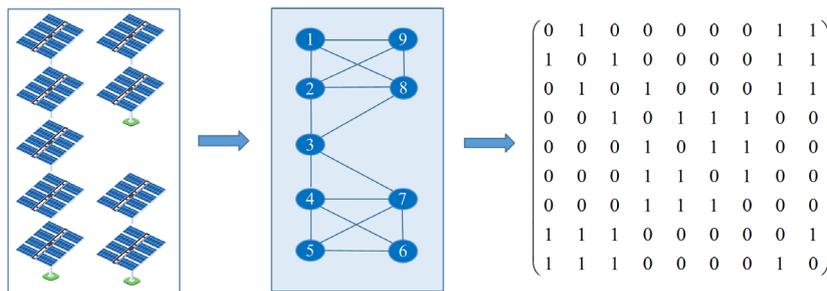


图5 光伏阵列抽象图及其邻接矩阵

Fig. 5 Abstract diagram of PV arrays and its adjacent matrix

然后, 利用 GCN 提取图的空间特征得到包含空间相关信息的时序数据, 并采用 LSTM 完成最终预测, 具体网络结构如图 6 所示。

本文搭建的 GCN-LSTM 网络主要包含输入层、空间特征提取层、时间序列预测层和输出层 4 个部分。输入层负责输入光伏电站内所有光伏阵列的历

史功率信息 $X \in \mathbf{R}^{B \times n \times \sigma}$, 其中 B 为批训练的样本数, n 为阵列数, 即图结构中的节点数, σ 为历史时间长度。

在空间特征提取层输入图的邻接矩阵 $A \in \mathbf{R}^{n \times n}$, 以提取每个节点与其周围节点之间的关联信息, 同时为了扩大模型接收信息的感受野, 在空间特征提

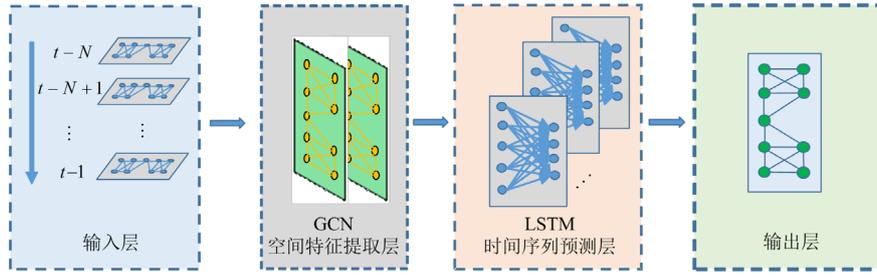


图 6 GCN-LSTM 网络结构图

Fig. 6 Structure of GCN-LSTM network

取层采用两层 GCN 堆叠的方式。两层 GCN 提取数据空间特征后, 将数据更新为 $B \times n \times c$ 维数据, 其中输出维度 c 可以为任意正整数。

时间序列预测层包含 LSTM 层和全连接层, 其中 LSTM 层采用了两层 LSTM 堆叠。输入数据经过空间特征提取层得到融合了空间相关信息的时序数据 $X' \in \mathbf{R}^{B \times n \times c}$, 将 X' 输入 LSTM 层并通过全连接层降维, 最终得到预测值 $y' \in \mathbf{R}^{B \times n \times s}$, s 为预测步长。

2 实验分析

本文首先在一个具有 9 个阵列的不规则小规模电站上验证所提方法的可行性和有效性, 然后进一步在具有 80 个阵列的光伏电站数据上挖掘本文所提方法在大规模电站上的应用潜力。

2.1 9 阵列光伏功率预测

实验数据来源于澳大利亚 Alice-Spring 光伏电站的实测数据, 包含 2020 年 1 月 1 日至 2020 年 12 月 31 日一年的光伏发电数据, 采样间隔为 5 min。

2.1.1 数据预处理

在数据采集时, 由于设备故障或日常维护等原因会导致部分数据缺失或数据值异常。本文对于连续缺失不超过 12 个采样点的数据, 采用 3 次样条插值的方法插补, 对于连续缺失超过 12 个采样点的则直接删除该天数据, 最终剩余 354 天共 50 976 条数据; 对于数据中包含的异常值, 使用广义极端学生化偏差检验法检测剔除, 并采用 3 次 Hermite 插值法插补。最后, 将数据归一化到 [0,1] 区间内。

2.1.2 模型参数设置

本文采用的 GCN-LSTM 模型包含 GCN 空间特征提取模块与 LSTM 时间序列预测模块两部分。对于 GCN 模块设置两个 GCN 层, 激活函数为 Relu; 对于时间序列预测部分, 设置两层 LSTM, 激活函数为 tanh, 历史时间序列长度为 24 个数据点, 即以历史 2 h 的数据作为输入特征预测未来功率输出。采用 Adam 优化算法更新参数, 学习率设置为 0.01,

训练过程样本的批量大小为 64, 最大迭代次数为 100 次。选取 300 天数据作为训练集, 54 天数据作为验证集。同时为了可复现实验结果, 将随机数种子固定为 42。

2.1.3 预测结果分析

本文选用平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)和平均绝对误差百分比(mean absolute percentage error, MAPE)来评估预测结果, 计算方法依次如式(9)~式(11)所示。如式(11)所示, 若 y_i 为零, 则公式无法计算, 但是光伏出力在白天为零数据较少, 所以在计算 MAPE 时, 舍去少部分真实值为零的数据。

$$e_{\text{MAE}} = \frac{1}{m} \sum_{i=1}^m |y_i - y'_i| \quad (9)$$

$$e_{\text{RMSE}} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - y'_i)^2} \quad (10)$$

$$e_{\text{MAPE}} = \sum_{i=1}^m \frac{|y_i - y'_i|}{y_i} \quad (11)$$

式中: y_i 为真实值; y'_i 为预测值; m 为预测样本数。

为了证明 GCN-LSTM 模型的优越性, 设置 4 组对照实验来对比分析预测效果, 其中包含仅考虑空间特性的 GCN 模型, 仅考虑时序特性的 RNN 与 LSTM 模型以及考虑时空特性的 GCN-RNN 模型。

本文从预测结果中选取了 4 种不同的天气情况进行分析, 功率预测波形及评价指标如图 7 所示。从图 7 中可以看出, 在晴天和多云天气下, 不同方法预测结果与实际值的偏差均不大, 除了 GCN 和 RNN 表现较差外, 其余曲线波动趋势与实际值基本吻合。在阴雨和雨天由于天气情况较为恶劣, 导致光伏输出功率波动较大, 虽然预测结果的波动趋势与实际值大体一致, 但是在变化较为剧烈处仍有较大偏差。总的来说, 功率曲线图显示 GCN-LSTM 的预测结果在晴天、多云条件下与真实值基本吻合, 在阴雨、雨天功率变化较为剧烈的情况下仍有较好的拟合效果。

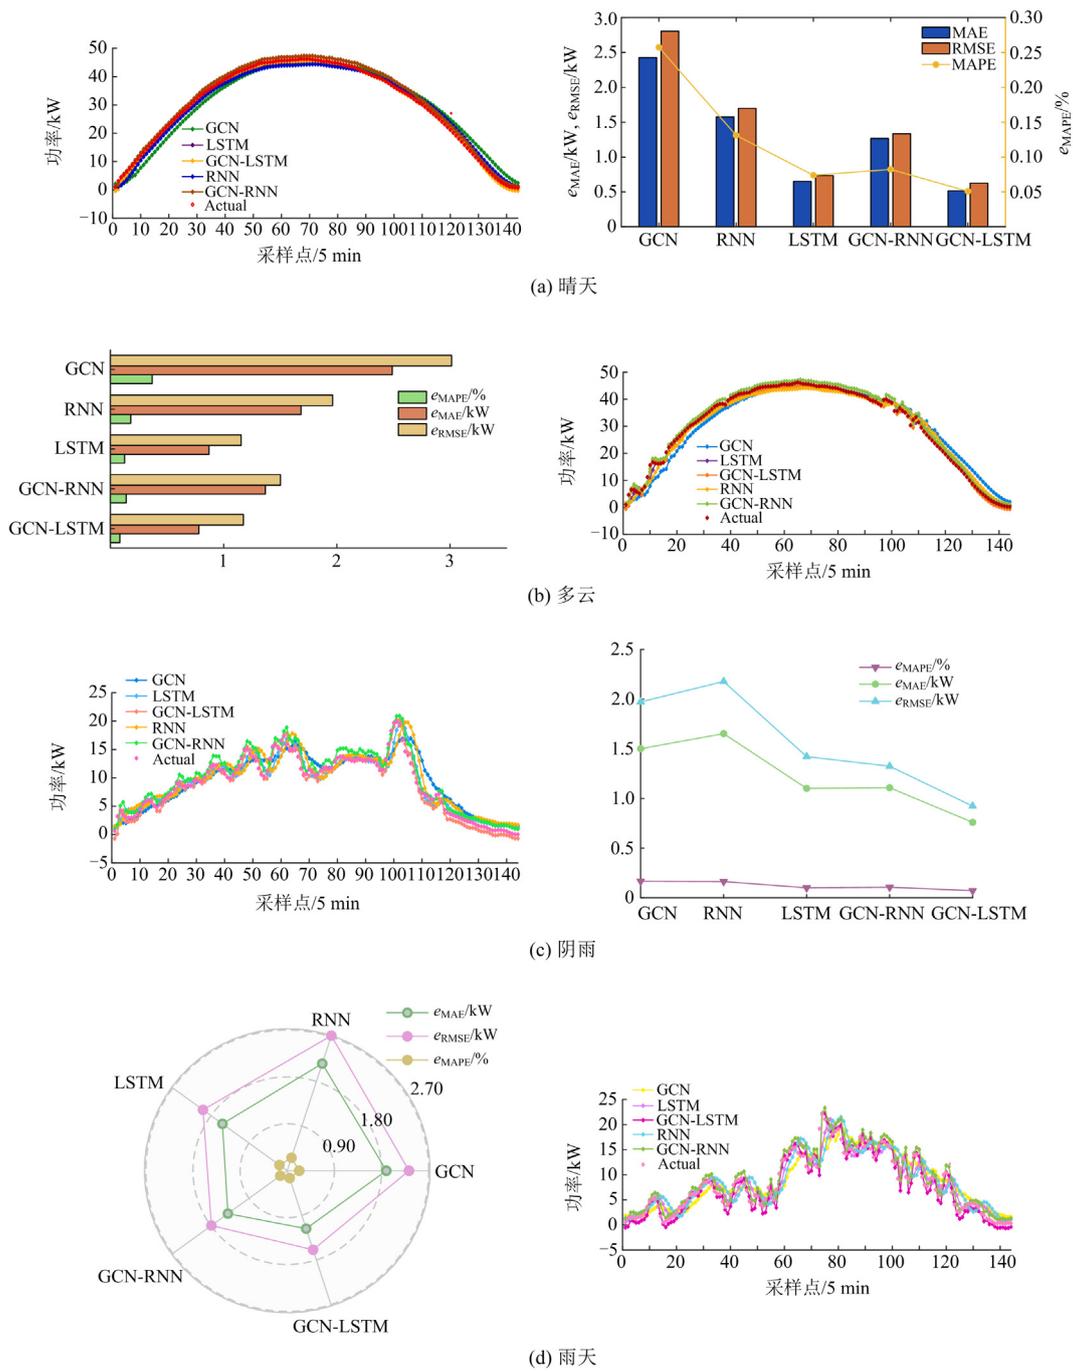


图 7 不同天气情况预测结果及评价指标

Fig. 7 Forecasting result and evaluation indicators under different weather conditions

从评价指标上看, 上述 4 种天气情况下, GCN-LSTM 模型的 3 种预测评价指标均要优于其他模型。也就是说, 采用 GCN-LSTM 时空预测模型得到的预测值更加接近真实值, 预测精度更高, 在光伏功率输出预测中要优于其他模型, 并且这种优越性在阴雨和雨天条件下更加明显。

表 1 为不同模型在 4 种天气情况下的预测评价

指标。表 1 显示, GCN-LSTM 在阴雨天气下的 MAE 和 RMSE 指标要低于多云天气的指标。这是由于阴雨天气光伏站点输出功率值低, 而 MAE 与 RMSE 都是有量纲的值, 所以其 MAE 与 RMSE 值也较低。但是从 MAPE 指标来看, 基于 GCN-LSTM 时空预测方法的预测精度虽然会随着天气情况的恶化出现一定程度的下降, 但是相比于其他模型的预测效果

仍然有着较为明显的优越性。综上所述，基于 GCN-LSTM 的时空预测方法在不同天气情况下都拥有较高的预测精度，相较于仅考虑空间关系或时序特性的模型而言，本文方法具有更高的精确性和稳定性。但是，从雨天的预测精度来看，本文所提

方法仍有 14.85% 的预测误差，预测精度较差。这一问题可能是由于光伏阵列数量太少，提供的空间特征不足导致的，为了验证这一猜想，本文继续在一个含有 80 个光伏阵列的电站数据上进行实验分析。

表 1 不同天气下评价指标对比

Table 1 Comparison of evaluation indicators under different weather conditions

| 天气 | 方法 | e_{MAE}/kW | e_{RMSE}/kW | $e_{MAPE}/\%$ |
|----|----------|---------------|---------------|---------------|
| 晴天 | GCN | 2.4256 | 2.8050 | 25.73 |
| | RNN | 1.5762 | 1.6988 | 13.12 |
| | LSTM | 0.6513 | 0.7340 | 7.39 |
| | GCN-RNN | 1.2669 | 1.3351 | 8.23 |
| | GCN-LSTM | 0.5160 | 0.6262 | 5.10 |
| 多云 | GCN | 2.4890 | 3.0134 | 36.86 |
| | RNN | 1.6836 | 1.9627 | 17.97 |
| | LSTM | 0.8707 | 1.1543 | 12.65 |
| | GCN-RNN | 1.3683 | 1.5021 | 13.96 |
| | GCN-LSTM | 0.8134 | 1.0124 | 8.30 |
| 阴雨 | GCN | 1.5012 | 1.9718 | 16.75 |
| | RNN | 1.6530 | 2.1780 | 16.40 |
| | LSTM | 1.1015 | 1.4216 | 10.08 |
| | GCN-RNN | 1.1089 | 1.3248 | 10.69 |
| | GCN-LSTM | 0.7601 | 0.9235 | 7.17 |
| 雨天 | GCN | 1.8910 | 2.3234 | 22.81 |
| | RNN | 2.1614 | 2.7239 | 26.20 |
| | LSTM | 1.5299 | 1.9881 | 18.48 |
| | GCN-RNN | 1.4005 | 1.7894 | 16.58 |
| | GCN-LSTM | 1.1682 | 1.5947 | 14.85 |

2.2 80 阵列光伏功率预测

由于上述实验采用的数据只包含 9 个光伏阵列，这与实际的电站规模还存在一定差距。为了体现基于 GCN-LSTM 的时空预测方法的泛化性，本文将上述方法应用于一个拥有 80 个阵列的光伏电站上，以挖掘此方法在大型光伏电站上的应用潜力。

该电站数据包含了一年内采样间隔为 5 min 的光伏数据，在数据处理过程中仍然采用与小规模数据相同的处理方法。不同之处在于，基于 GCN-LSTM 的时空预测方法需要从光伏阵列的地理位置分布上抽象出图结构，才能得到相应的邻接矩阵作为输入；而该数据不包含光伏阵列的空间排布信息，所以不能直接从空间分布上抽象出图结构，也就不能直接得到数据的邻接矩阵。

对于上述这种情况，相关的研究采用基于各节点间的相关系数来构建邻接矩阵^[35-36]。但是由于目前考虑光伏阵列之间的时空关系的文献较少，所以在采用相关系数法构建邻接矩阵之前，本文首先利用 Pearson 相关系数法对 2.1 节中使用的 9 阵列光伏

数据中不同阵列之间的相关性进行分析，计算结果如图 8 所示。

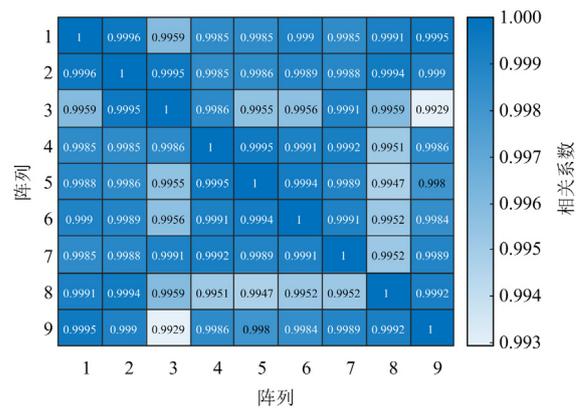


图 8 9 阵列 Pearson 相关系数

Fig. 8 Pearson correlation coefficient of 9 arrays

从图 8 中可以看出，不同阵列之间的功率输出存在很高的相关性，并且结合该电站光伏阵列的空间排布可以发现，在该电站中相邻阵列之间的功率

相关系数要更高。以阵列 1 为例, 在空间位置上, 阵列 1 与阵列 2、阵列 8 和阵列 9 相邻, 其相关系数分别为 0.9996、0.9991 和 0.9995, 均要高于阵列 1 与其余阵列之间的相关系数。

此外, 文献[35]在研究中指出, 基于相关系数来构建邻接矩阵可以在一定程度上消除虚假信息的影响。因此, 本文对 80 阵列数据集的实验, 将通过计算不同阵列之间功率输出的 Pearson 相关系数并在此基础上构建邻接矩阵来实现。对此, 类似的研究如文献[35-36]中采用了如式(12)所示的方法。

$$A = \begin{cases} a_{i,j} = 1, R_{i,j} > \rho \\ a_{i,j} = 0, \text{Otherwise} \end{cases} \quad (12)$$

式中: $a_{i,j}$ 为矩阵 A 中的元素; $R_{i,j}$ 为节点 i, j 的 Pearson 相关系数; ρ 为相关系数的阈值。

但是, 采用上述方法构建邻接矩阵时对阈值 ρ 的取值较为敏感, 取值过大则可能会损失部分有用的邻属信息, 取值过小则会导致邻接矩阵过于密集加重计算负担。并且, 目前还没有直接的理论指导如何确定相关系数的阈值。所以本文采用直接选取与每一阵列相关系数最高的 x 个阵列作为其邻居来创建邻接矩阵的方式。为了找到最适合此光伏电站中阵列的邻居数量, 本文对比了 x 的取值为 1~60 时的预测误差, 得到如图 9 所示的误差曲线图。最终根据实验结果, 选取与每一个阵列相关性最高的 9 个阵列作为其邻居, 构建邻接矩阵。此外, 由于该数据包含 80 个阵列一年内的功率输出, 数据量较大, 所以为防止训练过程发生过拟合, 进行模型训练时在 GCN-LSTM 的输出层中加入 dropout 层, 其余参数设置均与 9 阵列实验相同。

为了证明 GCN-LSTM 方法拥有应用于大型电站上的潜在优势, 本节同样选取 GCN、RNN、LSTM 和 GCN-RNN 作为对比模型进行实验, 并且为了满

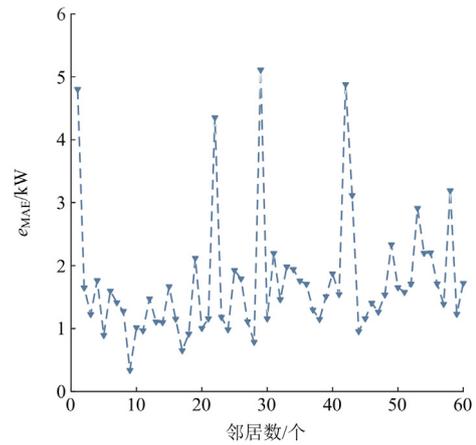
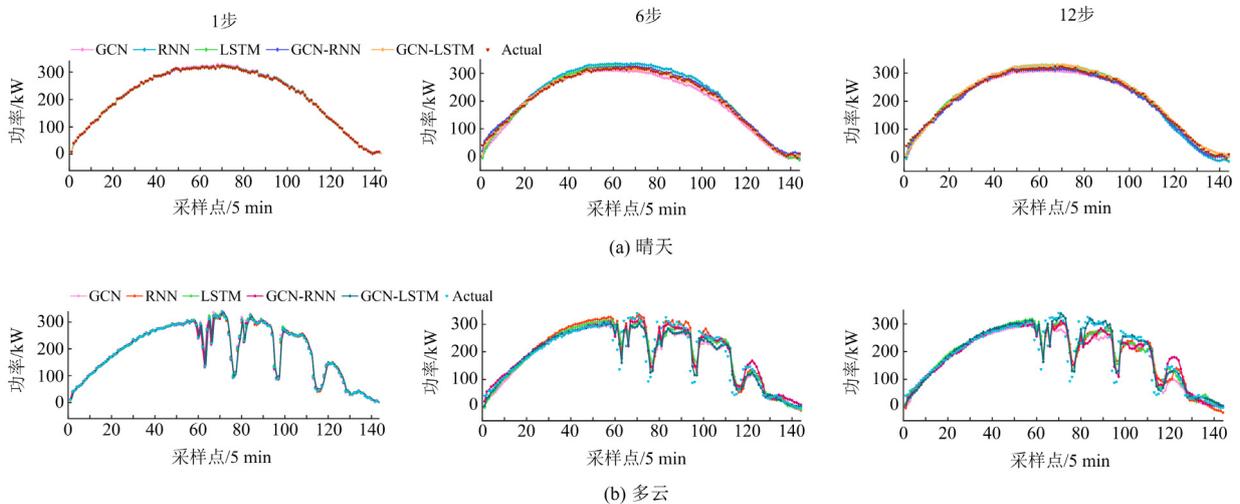


图 9 不同邻居数下的预测误差曲线图

Fig. 9 Curve of forecasting error with different neighbors

足一般情况下超短期预测对时间尺度的要求, 实现了提前 1 步(5 min)、提前 6 步(30 min)和提前 12 步(1 h)的光伏发电功率预测。同样, 为了验证预测结果的稳定性, 从验证数据中选取 4 种不同天气情况下的预测结果进行分析, 5 种模型的预测结果如图 10 所示。

图 10 的预测波形图显示, 不同预测方法在 4 种场景下都有较好的拟合效果, 尤其是在单步预测时, 不同方法的预测结果曲线基本与实际曲线重合。但是在功率输出发生较大波动时, 如在多云天气场景的后半段及阴雨和雨天天气中, 5 种方法均表现出不同程度的偏差, 这在 6 步和 12 步的预测结果中较为明显。导致这种现象的原因是: 一方面在天气情况较为恶劣时, 光伏功率输出的不确定性加剧, 预测难度加大; 另一方面, 在面对数据波动情况加剧时, 基于时序数据的预测方法的预测精度会有所下降。但是, 从图 10 的预测结果也可以看出, 加入 GCN



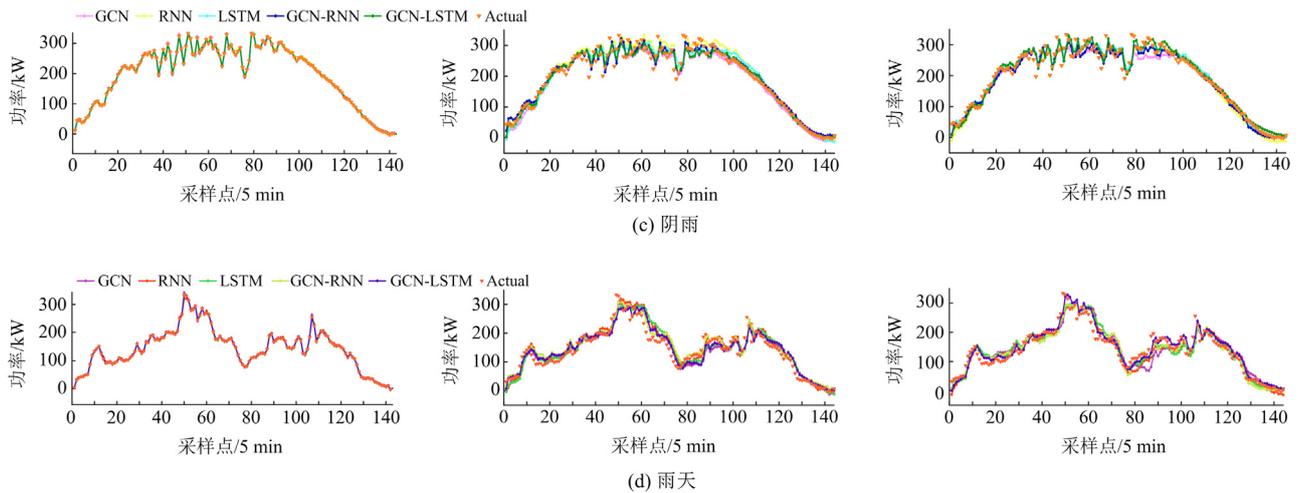


图 10 80 阵列单步、多步预测结果图

Fig. 10 Result of one step and multi step forecasting on 80 arrays

网络层可以有效降低这种由功率波动较大的情况导致的预测误差。

表 2 为 5 种预测方法在 4 种天气场景下的预测评价指标结果,图 11 为 5 种预测方法在不同天气场景下的光伏发电功率预测评价指标柱状堆积图。从表 2 和图 11 可以看出,在单步预测时 5 种预测模型均表现出较好性能,本文所提出的 GCN-LSTM 模

型在 4 种天气状况下的 MAPE 都在 1%以内,具有很好的准确性。

但是随着预测时间尺度的增加,尤其是在功率输出波动较大的场景下,不同方法的误差均表现出不同程度的增大。以波动幅度最大的多云天气为例,单步实验下 GCN、RNN、LSTM、GCN-RNN 和 GCN-LSTM 的 RMSE 指标分别为 3.44、3.13、2.19、

表 2 4 种场景预测评价指标对比

Table 2 Forecasting evaluation indicators under four scenarios

| 天气 | 方法 | e_{MAE}/kW | | | e_{RMSE}/kW | | | $e_{MAPE}/\%$ | | |
|----|----------|---------------|---------------|---------------|---------------|-------------|-------------|---------------|---------------|----------------|
| | | 1 步 | 6 步 | 12 步 | 1 步 | 6 步 | 12 步 | 1 步 | 6 步 | 12 步 |
| 晴天 | GCN | 1.9382 | 12.2488 | 18.5158 | 2.76 | 11.36 | 20.48 | 2.5568 | 12.4785 | 19.7797 |
| | RNN | 1.3160 | 10.6983 | 8.3819 | 2.1 | 10.68 | 12.92 | 1.6271 | 10.7892 | 10.2843 |
| | LSTM | 0.7882 | 7.5558 | 8.0397 | 1.89 | 10.55 | 11.35 | 0.9542 | 9.6292 | 9.9627 |
| | GCN-RNN | 0.8322 | 6.2953 | 7.6305 | 1.59 | 8.35 | 10.03 | 1.0189 | 7.3527 | 9.3661 |
| | GCN-LSTM | 0.2658 | 4.3624 | 6.494 | 0.48 | 5.59 | 6.39 | 0.3229 | 6.0010 | 8.2234 |
| 多云 | GCN | 2.6794 | 13.197 | 22.0214 | 3.44 | 13.73 | 27.64 | 3.8346 | 14.8693 | 24.4356 |
| | RNN | 2.2291 | 12.4768 | 20.7433 | 3.13 | 12.24 | 26.97 | 3.7611 | 13.9449 | 21.5592 |
| | LSTM | 1.8629 | 10.4228 | 18.9073 | 2.19 | 11.97 | 21.30 | 2.8743 | 12.5499 | 20.1730 |
| | GCN-RNN | 1.4270 | 10.2252 | 17.7684 | 1.54 | 10.13 | 19.54 | 2.0456 | 10.2266 | 18.6273 |
| | GCN-LSTM | 0.3172 | 8.7676 | 9.3262 | 0.83 | 8.84 | 9.74 | 0.4004 | 7.7471 | 9.7124 |
| 阴雨 | GCN | 1.8019 | 19.9132 | 21.6766 | 3.24 | 22.44 | 25.98 | 2.6135 | 18.7973 | 26.9043 |
| | RNN | 2.1531 | 18.6744 | 18.5496 | 2.83 | 20.42 | 22.56 | 3.0510 | 18.8542 | 24.8292 |
| | LSTM | 1.7203 | 17.9659 | 15.7464 | 3.45 | 19.90 | 16.60 | 2.4682 | 18.9601 | 17.0535 |
| | GCN-RNN | 1.1612 | 13.6942 | 12.4748 | 2.73 | 16.05 | 14.18 | 1.4551 | 14.3081 | 15.6307 |
| | GCN-LSTM | 0.2647 | 8.8873 | 9.6595 | 0.49 | 6.80 | 8.18 | 0.3232 | 8.2913 | 10.5811 |
| 雨天 | GCN | 1.9059 | 16.6331 | 21.0207 | 2.42 | 15.64 | 22.22 | 1.9344 | 17.5554 | 22.6777 |
| | RNN | 1.8613 | 15.4455 | 20.3946 | 1.79 | 14.14 | 21.07 | 1.6257 | 16.7616 | 21.0798 |
| | LSTM | 1.4816 | 13.6756 | 14.5700 | 1.59 | 13.88 | 17.52 | 1.3630 | 14.6601 | 16.6772 |
| | GCN-RNN | 0.9314 | 11.8765 | 13.3362 | 1.19 | 13.31 | 12.07 | 1.1582 | 12.3175 | 14.7021 |
| | GCN-LSTM | 0.3284 | 7.5895 | 8.0612 | 0.57 | 7.46 | 7.96 | 0.3821 | 8.2971 | 9.0614 |

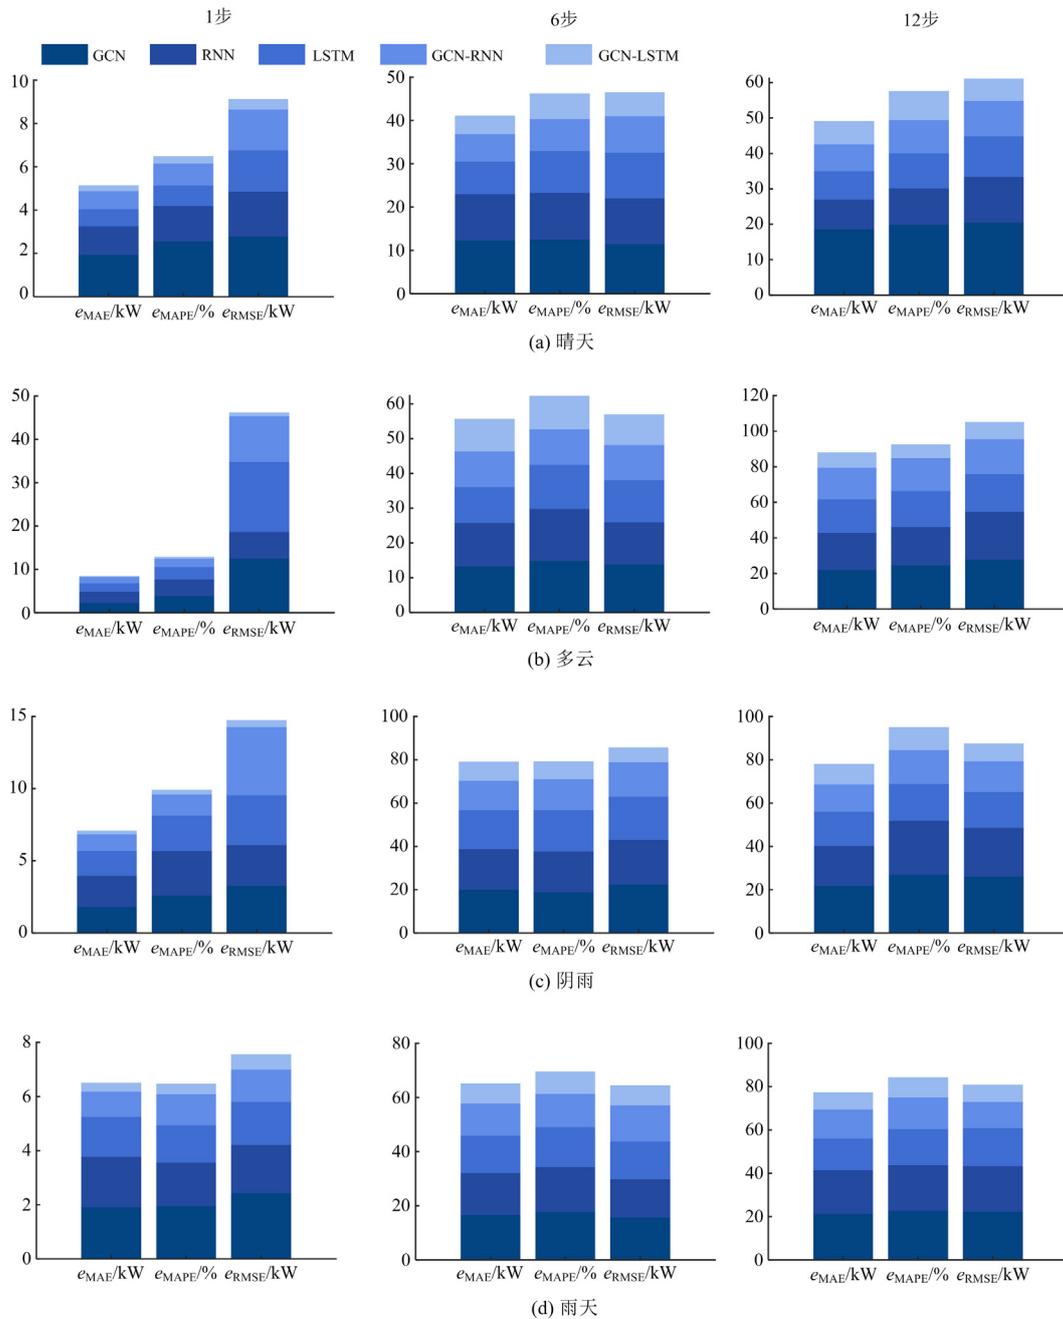


图 11 预测评价指标柱状堆积图

Fig. 11 Histogram stacked of the forecasting evaluation indicator

1.54 和 0.83%，6 步时为 13.73、12.24、11.97、10.13 和 8.84%，在 12 步时则达到了 27.64、26.97、21.30、19.54 和 9.74%。可以看出，随着时间尺度的增加，预测误差明显增大，除本文方法还能保持 10% 以内的预测误差外，其他对比方法的预测精度已经无法满足要求。

从实验结果还可以发现，相比于单一的 RNN 和 LSTM 模型，在加入 GCN 层后，GCN-RNN 和

GCN-LSTM 模型的预测精度均有较大提升。具体来说，在晴天、多云、阴雨和雨天提前 12 步(1 h)的预测场景下，GCN-RNN 的 MAPE 分别比 RNN 降低了 2.33%、2.11%、4.37% 和 0.83%，GCN-LSTM 的 MAPE 分别比 LSTM 降低了 4.96%、11.56%、8.42% 和 6.42%。这也证明了加入 GCN 空间特征提取层后不仅可以有效提升预测精度，而且还能改善基于时序信息的预测方法在数据波动较大时的预测质量，

因此可以有效提升预测结果的稳定性。

2.3 9 阵列与 80 阵列预测结果对比分析

从图 7 与图 10 的预测结果波形图可以看出, 5 种预测方法在 80 阵列光伏数据上的预测曲线的拟合情况要明显优于 9 阵列的预测结果。此外, 对比表 1、图 11 及表 2 的统计数据可以看出, 基于大规模数据预测结果的 MAPE 指标要明显低于在 9 阵列光伏站点上的表现。主要原因是: 1) GCN、RNN、LSTM、GCN-RNN 和 GCN-LSTM 均是多输入多输出模型, 9 个光伏阵列提供的可供训练数据量较少, 无法使模型得到更好的训练效果; 2) 9 阵列的数据包含的不同阵列之间的空间相关信息较少, 无法使模型充分利用不同光伏阵列之间的时空相关信息, 也就无法充分发挥本文方法提取空间特征的能力。这也在一定程度上证明了本文所提出的基于 GCN-LSTM 的超短期光伏功率预测方法能够有效应用于大规模光伏电站, 并且在大规模电站上可以获得更好的预测效果。

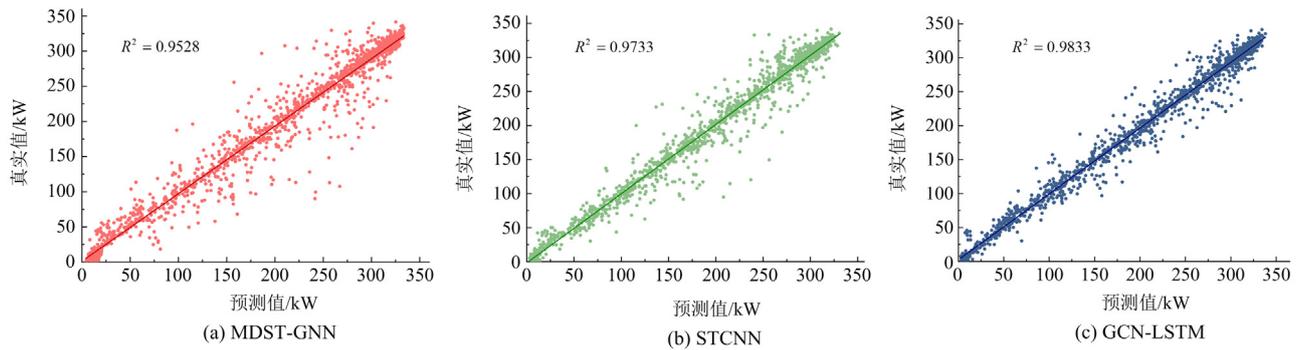


图 12 预测结果拟合分析图

Fig. 12 Fitting analysis of forecasting result

表 3 不同时空预测方法对比

Table 3 Comparison of different spatio-temporal methods

| 方法 | e_{MAE}/kW | $e_{MAPE}/\%$ | e_{RMSE}/kW |
|----------|--------------|---------------|---------------|
| STCNN | 0.7465 | 1.37 | 0.8371 |
| MDST-GNN | 2.3721 | 2.62 | 3.2856 |
| GCN-LSTM | 0.2795 | 0.65 | 0.3762 |

而 MDST-GNN 模型预测结果较低的原因可能是该模型是针对交通网络和大型光伏集群设计的, 网络加入了过多特征提取层, 在相对较小的数据集上可能出现了过拟合的情况。

3 结论

本文提出了一种基于 GCN-LSTM 的超短期光

2.4 与其他时空预测算法对比

为了证明本文所提方法的优越性, 本文还选取了两种同样考虑时空相关性的方法: 时空卷积神经网络 (space-time convolutional neural network, STCNN)^[37]和基于图神经网络的多元时间序列深度时空预测模型 (multivariate time series deep spatiotemporal forecasting model with a graph neural network, MDST-GNN)^[38], 在单步预测下与本文方法的预测结果进行对比, 并对 3 种方法的预测结果进行了拟合分析, 并用决定系数 R^2 描述不同模型的拟合性能, 拟合分析结果如图 12 所示。

表 3 为 3 种模型在相同数据集下的预测结果指标, 从图 12 和表 3 结果可以看出, GCN-LSTM 模型在该数据集上的表现要优于 STCNN 与 MDST-GNN。从模型结构的分析来说, 造成 STCNN 模型预测结果较低的原因是 STCNN 模型采用传统的卷积网络来提取不同序列之间的空间特征, 所以需要在预测前将序列排序以满足卷积网络的计算要求, 而这一操作很可能打乱原有数据之间的空间关联, 造成预测结果精度较低。

伏功率时空预测方法。首先基于光伏站点内的光伏阵列排布情况或不同阵列功率输出的相关性, 以图的形式刻画不同阵列之间的联系, 并利用 GCN 提取图中所含不同阵列之间的空间相关信息。然后, 将包含空间信息的时序数据输入 LSTM 以进行光伏电站的超短期功率预测。最后, 在一个 9 阵列站点和一个 80 阵列的光伏数据集上对所提方法进行实验验证, 得出以下结论。

1) GCN-LSTM 模型无论在精确性和稳定性上的表现都要优于比对模型 GCN、RNN、LSTM 和 GCN-RNN。此外, 在与时序预测模型 RNN 和 LSTM 的对比实验中可以看出, 加入 GCN 网络层不仅可以提高模型的预测精度, 而且有效改善了单纯利用时序信息进行预测时预测结果稳定性差的问题。

2) 在 80 阵列光伏数据上的实验结果证明了基于 GCN-LSTM 的超短期功率预测方法在大规模的电站中会获取到更多的空间信息, 可以进一步提升模型的预测水平, 因此所提方法在大规模电站中拥有良好的应用前景。

本文所提方法在现有案例中表现出了较好的精确性与稳定性, 后续将进一步将此方法应用于大规模的光伏电站甚至是光伏集群的功率预测中, 以拓宽该方法的应用范围。

参考文献

- [1] 国家能源局. 国家能源局发布 2022 年全国电力工业统计数据[EB/OL]. [2023-10-30]. http://www.nea.gov.cn/2023-01/18/c_1310691509.htm.
- [2] EOM H, SON Y, CHOI S. Feature-selective ensemble learning-based long-term regional PV generation forecasting[J]. *IEEE Access*, 2020, 8: 54620-54630.
- [3] 方鹏, 高亚栋, 潘国兵, 等. 基于 LSTM 神经网络的中长期光伏电站发电量预测方法研究[J]. *可再生能源*, 2022, 40(1): 48-54.
FANG Peng, GAO Yadong, PAN Guobing, et al. Research on forecasting method of mid-and long-term photovoltaic power generation based on LSTM neural network[J]. *Renewable Energy Resources*, 2022, 40(1): 48-54.
- [4] 商立群, 李洪波, 侯亚东, 等. 基于 VMD-ISSA-KELM 的短期光伏发电功率预测[J]. *电力系统保护与控制*, 2022, 50(21): 138-148.
SHANG Liqun, LI Hongbo, HOU Yadong, et al. Short-term photovoltaic power generation prediction based on VMD-ISSA-KELM[J]. *Power System Protection and Control*, 2022, 50(21): 138-148.
- [5] ZHOU Xinyu, AO Y, WANG Xinlu, et al. Learning with privileged information for short-term photovoltaic power forecasting using stochastic configuration network[J]. *Information Sciences*, 2023, 619: 834-848.
- [6] 董志强, 郑凌蔚, 苏然, 等. 一种基于 IGWO-SNN 的光伏出力短期预测方法[J]. *电力系统保护与控制*, 2023, 51(1): 131-138.
DONG Zhiqiang, ZHENG Lingwei, SU Ran, et al. An IGWO-SNN-based method for short-term forecast of photovoltaic output[J]. *Power System Protection and Control*, 2023, 51(1): 131-138.
- [7] 王晓霞, 俞敏, 霍泽健, 等. 基于近邻传播聚类与LSTNet 的分布式光伏电站群短期功率预测[J]. *电力系统自动化*, 2023, 47(6): 133-141.
WANG Xiaoxia, YU Min, HUO Zejian, et al. Short-term power forecasting of distributed photovoltaic station clusters based on affinity propagation clustering and long short-term time-series network[J]. *Automation of Electric Power Systems*, 2023, 47(6): 133-141.
- [8] ZHEN Hao, NIU Dongxiao, WANG Keke, et al. Photovoltaic power forecasting based on GA improved Bi-LSTM in microgrid without meteorological information[J]. *Energy*, 2021, 231.
- [9] 王福忠, 王帅峰, 张丽. 基于 VMD-LSTM 与误差补偿的光伏发电超短期功率预测[J]. *太阳能学报*, 2022, 43(8): 96-103.
WANG Fuzhong, WANG Shuaifeng, ZHANG Li. Ultra short term power prediction of photovoltaic power generation based on VMD-LSTM and error compensation[J]. *Acta Energetica Solaris Sinica*, 2022, 43(8): 96-103.
- [10] LIMOUNI T, YAAGOUBI R, BOUZIANE K, et al. Accurate one step and multistep forecasting of very short-term PV power using LSTM-TCN model[J]. *Renewable Energy*, 2023, 205: 1010-1024.
- [11] 史加荣, 殷诏. 基于 GRU-BLS 的超短期光伏发电功率预测[J]. *智慧电力*, 2023, 51(9): 38-45.
SHI Jiarong, YIN Zhao. Prediction of ultra short term photovoltaic power generation based on GRU-BLS[J]. *Smart Power*, 2023, 51(9): 38-45.
- [12] 汤德清, 朱武, 侯林超. 基于 CNN-LSTM-XGBoost 模型的超短期光伏功率预测[J]. *电源技术*, 2022, 46(9): 1048-1052.
TANG Deqing, ZHU Wu, HOU Linchao. Ultra-short-term photovoltaic power prediction based on CNN-LSTM-XGBoost model[J]. *Chinese Journal of Power Sources*, 2022, 46(9): 1048-1052.
- [13] 董雪, 赵宏伟, 赵生校, 等. 基于 SOM 聚类和二次分解的 BiGRU 超短期光伏功率预测[J]. *太阳能学报*, 2022, 43(11): 85-93.
DONG Xue, ZHAO Hongwei, ZHAO Shengxiao, et al. Ultra-short-term forecasting method of photovoltaic power based on SOM clustering secondary, decomposition and BiGRU[J]. *Acta Energetica Solaris Sinica*, 2022, 43(11): 85-93.
- [14] 张臻, 陈天鹏, 王磊, 等. 基于地基云图的超短期太阳辐照预测方法与装置研究[J]. *太阳能学报*, 2023, 44(1): 133-140.
ZHANG Zhen, CHEN Tianpeng, WANG Lei, et al. Research on ultra-short-term solar irradiance prediction method and device based on ground-based cloud images[J]. *Acta Energetica Solaris Sinica*, 2023, 44(1): 133-140.
- [15] QIN Jun, JIANG Hou, LU Ning, et al. Enhancing solar PV output forecast by integrating ground and satellite observations with deep learning[J]. *Renewable and Sustainable Energy Reviews*, 2022, 167: 112680.
- [16] 余光正, 陆柳, 汤波, 等. 基于云图特征提取的改进混合神经网络超短期光伏功率预测方法[J]. *中国电机工程学报*, 2021, 41(20): 6989-7003.
YU Guangzheng, LU Liu, TANG Bo, et al. An improved hybrid neural network ultra-short-term photovoltaic power forecasting method based on cloud image feature extraction[J]. *Proceedings of the CSEE*, 2021, 41(20): 6989-7003.
- [17] 路志英, 周庆霞, 李鑫, 等. 基于地基云图图像特征的光伏功率预测[J]. *电力系统及其自动化学报*, 2020, 32(8): 70-76.
LU Zhiying, ZHOU Qingxia, LI Xin, et al. Photovoltaic power prediction based on image features of ground cloud image[J]. *Proceedings of the CSU-EPSA*, 2020, 32(8): 70-76.
- [18] 司志远, 杨明, 于一潇, 等. 基于卫星云图特征区域定

- 位的超短期光伏功率预测方法[J]. 高电压技术, 2021, 47(4): 1214-1223.
- SI Zhiyuan, YANG Ming, YU Yixiao, et al. Ultra-short-term photovoltaic power prediction method based on satellite image feature region positioning[J]. High Voltage Engineering, 2021, 47(4): 1214-1223.
- [19] 白捷予, 董存, 王铮, 等. 考虑云层遮挡的光伏发电功率超短期预测技术[J]. 高电压技术, 2023, 49(1): 159-168.
- BAI Jieyu, DONG Cun, WANG Zheng, et al. Ultra-short-term prediction of photovoltaic power generation considering cloud cover[J]. High Voltage Engineering, 2023, 49(1): 159-168.
- [20] MENG Xiangjian, GAO Feng, XU Tao, et al. Inverter-data-driven second-level power forecasting for photovoltaic power plant[J]. IEEE Transactions on Industrial Electronics, 2020, 68: 7034-7044.
- [21] 廖雪超, 陈才圣, 伍杰平. 基于 CNN-LSTM 及深度学习的风电场时空组合预测模型[J]. 信息与控制, 2022, 51(4): 498-512.
- LIAO Xuechao, CHEN Caisheng, WU Jieping. Combined spatiotemporal wind farm prediction model based on CNN-LSTM and deep learning[J]. Information and Control, 2022, 51(4): 498-512.
- [22] 赵妍, 孙硕, 柳旭, 等. 基于改进 CNN-LSTM 的电力系统宽频振荡辨识[J]. 智慧电力, 2022, 50(2): 48-54, 96.
- ZHAO Yan, SUN Shuo, LIU Xu, et al. Identification of power system wide-band oscillation based on improved CNN-LSTM[J]. Smart Power, 2022, 50(2): 48-54, 96.
- [23] 高治军, 顾巧瑜, 陈平, 等. 基于 CNN-LSTM 双流融合网络的危险行为识别[J]. 数据采集与处理, 2023, 38(1): 132-140.
- GAO Zhijun, GU Qiaoyu, CHEN Ping, et al. Dangerous behavior recognition based on CNN-LSTM dual-stream fusion network[J]. Journal of Data Acquisition and Processing, 2023, 38(1): 132-140.
- [24] 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.
- [25] CUI Zhiyong, HENRICKSON K, KE Ruimin, et al. Traffic graph convolutional recurrent neural network: a deep learning framework for network-scale traffic learning and forecasting[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 21: 4883-4894.
- [26] YANG Chen, THATTE A A, XIE Le. Multitime-scale data-driven spatio-temporal forecast of photovoltaic generation[J]. IEEE Transactions on Sustainable Energy, 2015, 6(1): 104-112.
- [27] AGOUA X G, GIRARD R, KARINIOTAKIS G. Short-term spatio-temporal forecasting of photovoltaic power production[J]. IEEE Transactions on Sustainable Energy, 2017, 9(2): 538-546.
- [28] KHODAYAR M, LIU Guangyi, WANG Jianhui, et al. Spatiotemporal behind-the-meter load and PV power forecasting via deep graph dictionary learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(10): 4713-4727.
- [29] KIPF T N, WELLMING M. Semi-supervised classification with graph convolutional networks[C] // Proceedings of 5th International Conference on Learning Representations, April 24-26, 2017, Toulon, France.
- [30] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9: 1735-1780.
- [31] 魏震波, 余雷. 基于 FFT, DC-HC 及 LSTM 的短期负荷预测方法[J]. 智慧电力, 2022, 50(3): 37-43.
- WEI Zhenbo, YU Lei. Short-term load forecasting method based on FFT, DC-HC and LSTM[J]. Smart Power, 2022, 50(3): 37-43.
- [32] DUPLESSIS A A, STRAUSS J M, RIX A J. Short-term solar power forecasting: investigating the ability of deep learning models to capture low-level utility-scale Photovoltaic system behaviour[J]. Applied Energy, 2021, 285.
- [33] SIMEUNOVIC J, SCHUBNEL B, ALET P J, et al. Interpretable temporal-spatial graph attention network for multi-site PV power forecasting[J]. Applied Energy, 2021, 327.
- [34] LIMOUNI T, YAAGOUBI R, BOUZIANE K, et al. Accurate one step and multistep forecasting of very short-term PV power using LSTM-TCN model[J]. Renewable Energy, 2023, 205: 1010-1024.
- [35] JIAO Xuan, LI Xingshuo, LIN Dingyi, et al. A graph neural network based deep learning predictor for spatio-temporal group solar irradiance forecasting[J]. IEEE Transactions on Industrial Informatics, 2022, 18(9): 6142-6149.
- [36] LIU Jiarui, FU Yuchen. Decomposition spectral graph convolutional network based on multi-channel adaptive adjacency matrix for renewable energy prediction[J]. Energy, 2023, 284.
- [37] JEONG J, KIM H. Multi-site photovoltaic forecasting exploiting space-time convolutional neural network[J]. Energies, 2019, 12(23): 4490.
- [38] HE Zhichao, ZHAO Chunna, HUANG Yaqun. Multivariate time series deep spatiotemporal forecasting with graph neural network[J]. Applied Sciences-Basel, 2022, 12.

收稿日期: 2023-10-23; 修回日期: 2024-02-27

作者简介:

韩 晓(1998—), 男, 硕士研究生, 研究方向为新能源出力预测; E-mail: hxxxxiao@163.com

王 涛(1987—), 女, 通信作者, 博士, 副教授, 硕士生导师, 研究方向为人工智能在电力系统中的应用等; E-mail: twang@mail.xhu.edu.cn

韦晓广(1988—), 男, 博士, 讲师, 研究方向为电力系统安全分析。E-mail: wei_xiaoguang@126.com

(编辑 周金梅)