第 50 卷 第 1 期：65-74 高电压技术 Vol.50, No.1: 65-74
2024 年 1 月 31 日 High Voltage Engineering January 31, 2024
**DOI**: 10.13336/j.1003-6520.hve.20230605

# 无气象信息条件下基于 AGCRN 的分布式光伏出力超短期预测方法

赵洪山，孙承妍，温开云，吴雨晨
（河北省分布式储能与微网重点实验室(华北电力大学)，保定 071003）

**摘　要**：针对分布式光伏普遍缺少气象量测装置而导致功率预测精度不足的问题，提出了一种基于自适应图卷积循环网络的分布式光伏出力超短期预测方法，可以在无气象数据的条件下，仅基于历史出力数据实现光伏出力精准预测。首先，分析了光伏出力数据兼具时序性和空间相关性，利用门控循环网络提取时序特征，利用自适应图卷积网络挖掘传统图卷积网络无法捕捉的光伏出力潜在空间相关性。然后，融合门控循环单元和自适应图卷积网络，构建自适应图卷积循环网络以提取多光伏站点出力的时空相关性，并利用注意力机制为不同时刻的时空特征分配权重。最后，通过全连接层输出最终的预测结果。采用某地区屋顶光伏实际出力数据在不同预测时间尺度下比较所提方法与其他方法的预测性能，结果表明，在没有气象数据的情况下，当预测尺度为 15、30、60 min 时，相比于传统门控循环网络，所提方法的平均绝对误差分别减少了 16.9%、19.8%和 30.5%。
**关键词**：分布式光伏；超短期预测；时空相关性；无气象信息；自适应图卷积；门控循环单元

## Ultra-short-term Prediction of Distributed Photovoltaic Power Method Based on AGCRN in the Absence of Meteorological Information

ZHAO Hongshan, SUN Chengyan, WEN Kaiyun, WU Yuchen
(Hebei Key Laboratory of Distributed Energy Storage and Micro-grid, North China Electric Power University, Baoding 071003, China)

**Abstract**: To address the problem of low accuracy for distributed photovoltaic power forecasting due to the general lack of meteorological monitoring devices, this paper proposes an ultra-short-term prediction of distributed photovoltaic power method based on an adaptive graph convolution recurrent network that can realize accurate power output prediction in the absence of meteorological data. Firstly, it is analyzed that the photovoltaic output data have both temporal and spatial correlation. Secondly, the temporal correlations are extracted by gated recurrent unit and an adaptive graph convolution network is utilized to mine potential spatial correlations that traditional graph convolution networks can't capture. Thirdly, an adaptive graph convolution recurrent network is proposed to extract the temporal and spatial correlations of multiple distributed photovoltaics by combining the adaptive graph convolution network and the gated recurrent unit, and the attention mechanism is used to assign weights to the spatio-temporal characteristics at different time. Finally, the final prediction result is output through the fully connected layer. Compared with other methods in different forecasting horizons by using the actual photovoltaic output data, the results show that, compared to traditional gate recurrent network, the average absolute error of the proposed method is reduced by 16.9%, 19.8%, and 30.5% when the forecasting horizon is 15 minutes, 30 minutes, and 60 minutes, respectively.
**Key words**: distributed photovoltaic; ultra-short-term prediction; spatio-temporal correlation; without meteorological information; adaptive graph convolution network; gated recurrent unit

## 0　引言

随着我国“碳达峰、碳中和”目标的提出以及能源转型战略的持续推进[1-2]，新能源发电迅速发展。分布式光伏由于具有清洁高效、随发随用的优点，装机容量逐年上升。精准的超短期光伏发电功率预测对于电网的安全稳定、优化调度与经济性发挥着重要作用[3-4]。因此针对分布式光伏电站的超短期功率预测具有重要意义。

**基金资助项目**：国家电网公司总部科技项目(5700-202255222A-1-1-ZN)。
Project supported by Science and Technology Project of SGCC (5700-202255222A-1-1-ZN).

国内外针对集中式光伏预测做了较多研究，现有方法主要分为物理模型法和数据驱动法。物理模型法是利用气象数据和光伏电站的系统参数建立物理模型，通过计算得到光伏发电出力，目前比较完善的物理模型包括美国采暖、制冷与空调工程师学会(ASHRAE)[5]、Heliosat[6]、太阳辐射参考评估模型(reference evaluation of solar transmittance，REST)[7]及云遮系数模型[8]等。数据驱动法利用历史功率数据和气象数据，通过学习已知量与待预测量之间的关系进行预测[9-12]。

与集中式光伏不同，分布式光伏普遍缺少气象量测装置，气象数据短缺限制了分布式光伏预测精度。现有分布式光伏预测技术主要分为 3 种思路：插值法、参考电站法、历史出力法。

插值法是通过对卫星气象数据进行插值推算分布式站点所在地理位置的气象数据，再利用物理模型法或数据驱动法预测发电功率。文献[13]基于卫星遥感数据利用 Res-UNet 结合双线性插值的方法估算地面分布式站点未来辐照度，并构建长短期记忆网络(long short-term memory，LSTM)预测光伏出力。文献[14]提出通过卫星气象资源插值得到分布式光伏的气象特征，通过迁移学习算法将数据充足的分布式光伏的预训练模型迁移至与之具有相似气象特征的其余分布式光伏。但卫星气象数据空间分辨率较低，气象插值结果误差较大，导致功率预测结果误差较大。

参考电站法是将分布式光伏站点邻近的某个集中式光伏电站作为参考站点，建立两者的相关性，借助参考电站的气象或功率预测值推算分布式光伏功率预测值。文献[15]基于 Copula 函数构建了各类天气下分布式光伏和邻近集中式光伏的出力相关性模型。文献[16]利用皮尔逊相关系数构建分布式光伏与参考电站的出力关系，利用参考电站的功率预测值推算分布式光伏功率预测值。但实际中无法确保所有分布式光伏电站周围都有集中式光伏电站，因此适用性有限。

历史出力法仅基于历史出力数据，在无气象数据的条件下实现光伏出力预测，由于分布式光伏普遍缺少气象量测装置，因此研究在无气象数据的条件下仅基于历史出力数据实现光伏出力精准预测具有重要意义。对此，文献[17]提出一种支持向量回归-长短期记忆网络-逆向传播(support vector regression-long short-term memory-back propagation，SVR-LSTM-BP)组合模型提取历史出力的时序特征；文献[18]仅基于历史出力，提出了基于双层深度学习模型的分布式光伏功率预测方法；但文献[17-18]着重挖掘光伏出力序列的时序特征，缺乏对各个电站出力之间空间相关性的考虑，导致预测误差较大。对此，一些研究将多个邻近站点的出力数据作为输入，挖掘站点间出力的时空相关性以提高无气象数据的条件下光伏出力预测精度。文献[19]以多个邻近站点出力序列为输入，提出了一种基于自回归的时空预测模型；文献[20]提出了基于遗传算法改进的双向长短期记忆模型来提取多个邻近光伏出力序列的时序特征和空间特征；但文献[19-20]将多个邻近光伏站点出力直接输入时序模型，缺少对邻近光伏出力之间空间特征的针对性建模。

图卷积神经网络在交通预测[21]、气象预测[22]、风电预测[23]等非欧式结构数据空间特征提取方面显示出了卓越的能力，多光伏站点出力属于典型非欧式结构数据，因此本文引入图卷积网络对光伏出力的空间相关性建模，以提升预测精度。但传统的图卷积网络需要预先定义邻接矩阵表征光伏电站出力的空间相关关系，光伏站点之间的相关关系受地理位置、大气运动、风速等多种复杂因素影响，很难通过先验知识定量地确定，且不能保证预定义的邻接矩阵能够充分表征站点出力间的空间相关关系，因此图卷积网络应用于光伏出力空间特征提取存在一定局限性。

本文提出一种基于自适应图卷积循环网络的分布式光伏出力超短期预测方法：(1)针对大多数研究只对光伏出力时序特征建模，缺少空间特征建模的问题，本文融合图卷积网络与循环网络，构建图卷积循环网络提取光伏出力时空相关性；(2)针对传统图卷积网络应用于光伏出力空间特征提取的局限性，引入自适应图卷积网络，将图的邻接矩阵设置为可学习的模型参数，在模型训练的过程中动态优化调整邻接矩阵，挖掘传统图卷积网络无法捕捉的潜在空间相关关系。采用某地区屋顶光伏实际出力数据在不同预测时间尺度下比较所提方法与其他方法的预测性能，结果表明对于多时间尺度预测任务，本文方法均有最优的预测性能。

## 1 邻近光伏站点出力数据特征分析

绘制邻近站点 1、2 在 2018 年 7 月 1 日至 4 日的光伏出力如图 1 所示。

如图 1 所示，光伏出力存在以下特征：

1）时序特征

光伏出力随时间动态变化，具有趋势性、周期性、随机性等时序特征。

2）空间相关性

站点 1 和站点 2 的光伏出力有相似的波动趋势。由于光伏发电功率主要受辐照度影响，而光伏电站接收到的辐照度与其所处的地理位置、天气状况密切相关，同一地区内邻近光伏电站由于地理位置相近，天气状况相似，因此光伏发电功率呈现空间相关性。

## 2 时序特征建模和空间相关性建模

### 2.1 时序特征建模

门控循环单元(gated recurrent unit, GRU)擅长捕捉时序特征，同时兼具结构简单、参数较少的优点，因此采用 GRU 提取光伏出力的时序特征，具体计算过程为：

$$\begin{cases} \boldsymbol{R}_t = \sigma(\boldsymbol{W}_{\mathrm{R}}(\boldsymbol{X}_t \bullet \boldsymbol{H}_{t-1}) \oplus \boldsymbol{B}_{\mathrm{R}}) \\ \boldsymbol{Z}_t = \sigma(\boldsymbol{W}_{\mathrm{Z}}(\boldsymbol{X}_t \bullet \boldsymbol{H}_{t-1}) \oplus \boldsymbol{B}_{\mathrm{Z}}) \\ \tilde{\boldsymbol{H}}_t = \tanh(\boldsymbol{W}_{\mathrm{H}}(\boldsymbol{X}_t \bullet (\boldsymbol{R}_t \odot \boldsymbol{H}_{t-1})) \oplus \boldsymbol{B}_{\mathrm{H}}) \\ \boldsymbol{H}_t = ((\boldsymbol{1} - \boldsymbol{Z}_t) \odot \boldsymbol{H}_{t-1}) \oplus (\boldsymbol{Z}_t \odot \tilde{\boldsymbol{H}}_t) \end{cases} \tag{1}$$

式中：$\boldsymbol{X}_t$ 为 $t$ 时刻 GRU 单元的输入矩阵；$\boldsymbol{H}_t$ 为 $t$ 时刻 GRU 单元的输出矩阵；$\boldsymbol{R}_t$、$\boldsymbol{Z}_t$ 分别为 $t$ 时刻的重置门和更新矩阵；$\tilde{\boldsymbol{H}}_t$ 为 $t$ 时刻候选隐藏状态矩阵；$\boldsymbol{W}_{\mathrm{R}}$、$\boldsymbol{W}_{\mathrm{Z}}$、$\boldsymbol{W}_{\mathrm{H}}$ 为权重参数矩阵；$\boldsymbol{B}_{\mathrm{R}}$、$\boldsymbol{B}_{\mathrm{Z}}$、$\boldsymbol{B}_{\mathrm{H}}$ 为偏置矩阵 $\bullet$ 为矩阵拼接运算符；$\odot$ 为哈达玛积运算符；$\oplus$ 为矩阵相加运算符；$\sigma$ 为激活函数。

### 2.2 空间相关性建模

#### 2.2.1 图卷积网络

图卷积网络(graph convolution networks, GCN)基于预定义的静态图结构 $G=(V,\boldsymbol{A})$ 提取空间特征[24]，其中 $V$ 为 $N$ 个光伏站点的集合，$\boldsymbol{A}$ 为预定义的静态邻接矩阵，表征各个站点之间的空间相关关系，即：

$$a_{ij} = \begin{cases} -q_{ij}, & i \neq j, q_{ij} \leq \xi \\ 0, & i \neq j, q_{ij} > \xi \\ 1, & i = j \end{cases} \tag{2}$$

式中：$a_{ij}$ 为站点 $i$、$j$ 的空间相关关系；$q_{ij}$ 为站点的地理距离；$\xi$ 为阈值。

图卷积网络分层传播式为：

$$\boldsymbol{X}^{(l+1)} = \sigma(\overline{\boldsymbol{A}}\boldsymbol{X}^{(l)}\boldsymbol{W}^{(l)}) \tag{3}$$

式中：$\overline{\boldsymbol{A}} = \tilde{\boldsymbol{D}}^{-1/2}\tilde{\boldsymbol{A}}\tilde{\boldsymbol{D}}^{-1/2}$ 表示归一化的邻接矩阵；$\tilde{\boldsymbol{A}} = \boldsymbol{A} + \boldsymbol{E}_N$ 为加上自连接的邻接矩阵；$\tilde{\boldsymbol{D}}$ 为度矩阵，其元素 $\tilde{d}_{ii} = \sum_j \tilde{a}_{ij}$；$\boldsymbol{X}^{(l)} \in \boldsymbol{R}^{N \times M^{(l)}}$ 为第 $l$ 层的特征矩阵，$N$ 为节点个数，每个节点用 $M^{(l)}$ 维的特征向量表示；$\boldsymbol{W}^{(l)}$ 为第 $l$ 层的参数矩阵；$\boldsymbol{X}^{(l+1)} \in \boldsymbol{R}^{N \times M^{(l+1)}}$ 为更新后的特征矩阵。

以我国中部某地区的 10 个分布式屋顶光伏实际数据为例，计算实际邻接矩阵如图 2(a)所示，图 2(a)矩阵元素为任意 2 站点间的皮尔逊相关系数，根据式(2)计算静态邻接矩阵，如图 2(b)所示。

由图 2 可知，预定义静态邻接矩阵和实际邻接矩阵相比有一定偏差，这是因为站点间的出力相关性除了受距离的影响，还与大气运动、风力、风向等外界环境因素有关，很难预先通过先验知识定量确定，因此预定义的静态邻接矩阵并不能充分表征站点出力间的空间相关性。

#### 2.2.2 自适应图卷积网络

针对上述传统图卷积网络提取光伏出力空间相关性的局限性，自适应图卷积网络将图的邻接矩阵设置为可学习的模型参数，在模型训练的过程中

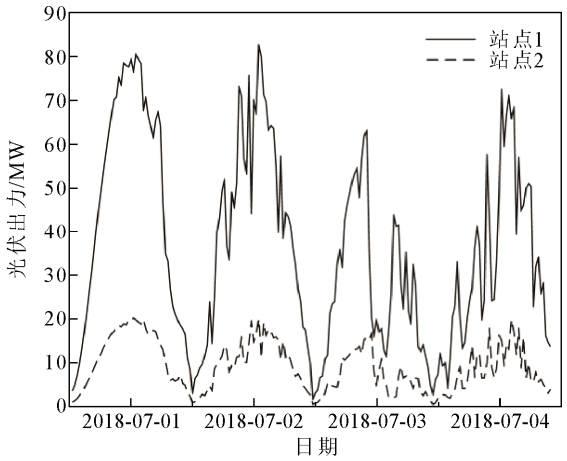
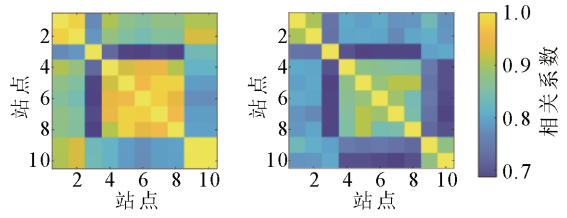



图 1 邻近站点的光伏出力

Fig.1 Photovoltaic output of adjacent stations




(a) 实际领接矩阵 (b) 预定义静态领接矩阵

图 2 邻接矩阵对比

Fig.2 Comparison of adjacency matrices

动态更新调整各节点间相关关系，挖掘传统图卷积网络无法捕捉的潜在空间相关关系，以此提高空间特征提取能力，进而提升预测精度。

构建自适应图卷积网络，即：

$$\boldsymbol{X}^{(l+1)}=\sigma((\overline{\boldsymbol{A}}\oplus\boldsymbol{W}_{\mathrm{A}})\boldsymbol{X}^{(l)}\boldsymbol{W}^{(l)}) \tag{4}$$

式中：$\boldsymbol{W}_{\mathrm{A}}$ 为自适应参数矩阵。

## 3 基于自适应图卷积循环网络的分布式光伏出力预测

为了提取光伏出力的时空相关性，融合自适应图卷积网络和门控循环网络，构建自适应图卷积循环网络(adaptive graph convolution recurrent network, AGCRN)。基于 AGCRN 的分布式光伏出力预测流程图如图 3 所示，其中矩阵 $\hat{\boldsymbol{X}}_{t+1}\in\boldsymbol{R}^{1\times M}$，包括 $M$ 个站点在 $t+1$ 时刻(待预测时刻)的输出。

1）模型输入

模型输入 $\boldsymbol{I}$ 包括 $M$ 个邻近分布式光伏站点在 $T$ 个历史时刻的出力，即：

$$\boldsymbol{I}=\begin{bmatrix} X_{t-T+1}^{1} & X_{t-T+1}^{2} & \cdots & X_{t-T+1}^{M} \\ X_{t-T+2}^{1} & X_{t-T+2}^{2} & \cdots & X_{t-T+2}^{M} \\ \vdots & \vdots & & \vdots \\ X_{t}^{1} & X_{t}^{2} & \cdots & X_{t}^{M} \end{bmatrix}_{T\times M} \tag{5}$$

式中：$X_t^j$ 为站点 $j$ 在历史时刻 $t$ 的出力。

2）AGCRN

构建自适应图卷积循环网络提取多站点出力的时空相关性。AGCRN 结构如图 4 所示，AGCRN 网络提取多站点出力时空相关性的具体步骤如下文所述。

首先构建双层自适应图卷积网络，输入各站点历史时刻出力矩阵 $\boldsymbol{X}_t\in\boldsymbol{R}^{1\times M}$，将各节点出力与其邻近节点出力信息进行融合，以提取 $t$ 时刻分布式光伏的空间特征，即：

$$\boldsymbol{X}_t^{G}=\sigma((\overline{\boldsymbol{A}}\oplus\boldsymbol{W}_{\mathrm{A}})\sigma((\overline{\boldsymbol{A}}\oplus\boldsymbol{W}_{\mathrm{A}})X_t\boldsymbol{W}_0)\boldsymbol{W}_1) \tag{6}$$

然后将含有空间特征的时序序列 $[\boldsymbol{X}_{t-T+1}^{G},\ \boldsymbol{X}_{t-T+2}^{G},\cdots,\ \boldsymbol{X}_t^{G}]$ 输入门控循环单元(gate recurrent unit，GRU)以提取 $M$ 个站点的时空相关性，具体计算过程为：

$$\begin{cases} \boldsymbol{R}_t=\sigma(\boldsymbol{W}_{\mathrm{R}}(\sigma((\overline{\boldsymbol{A}}\oplus\boldsymbol{W}_{\mathrm{A}})\sigma((\overline{\boldsymbol{A}}\oplus\boldsymbol{W}_{\mathrm{A}})X_t\boldsymbol{W}_0)\boldsymbol{W}_1)\bullet\boldsymbol{H}_{t-1})\oplus\boldsymbol{B}_{\mathrm{R}}) \\ \boldsymbol{Z}_t=\sigma(\boldsymbol{W}_{\mathrm{Z}}(\sigma((\overline{\boldsymbol{A}}\oplus\boldsymbol{W}_{\mathrm{A}})\sigma((\overline{\boldsymbol{A}}\oplus\boldsymbol{W}_{\mathrm{A}})X_t\boldsymbol{W}_0)\boldsymbol{W}_1)\bullet\boldsymbol{H}_{t-1})\oplus\boldsymbol{B}_{\mathrm{Z}}) \\ \tilde{\boldsymbol{H}}_t=\tanh(\boldsymbol{W}_{\mathrm{H}}(\sigma((\overline{\boldsymbol{A}}\oplus\boldsymbol{W}_{\mathrm{A}})\sigma((\overline{\boldsymbol{A}}\oplus\boldsymbol{W}_{\mathrm{A}})X_t\boldsymbol{W}_0)\boldsymbol{W}_1)\bullet \\ \qquad(\boldsymbol{R}_t\odot\boldsymbol{H}_{t-1}))\oplus\boldsymbol{B}_{\mathrm{H}}) \\ \boldsymbol{H}_t=((1-\boldsymbol{Z}_t)\odot\boldsymbol{H}_{t-1})\oplus(\boldsymbol{Z}_t\odot\tilde{\boldsymbol{H}}_t) \end{cases} \tag{7}$$

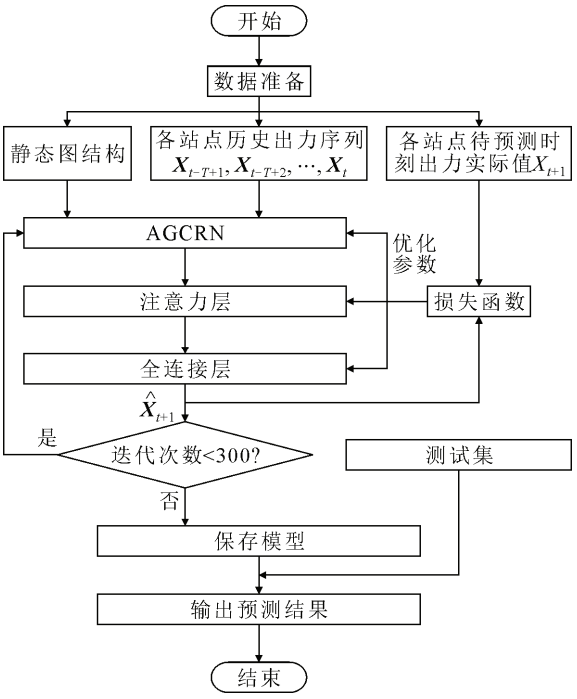



图 3 基于 AGCRN 的分布式光伏出力预测流程图

Fig.3 Flow chart of distributed photovoltaic output forecasting based on AGCRN

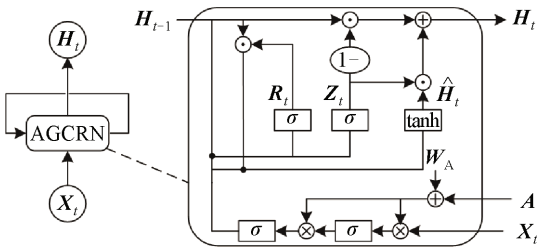



图 4 AGCRN 结构

Fig.4 Structure of AGCRN

式中：$\boldsymbol{H}_t$ 表示 $t$ 时刻 AGCRN 单元的输出矩阵；$\boldsymbol{Z}_t$、$\boldsymbol{R}_t$ 分别表示 $t$ 时刻的更新门和重置门矩阵；$\boldsymbol{W}_{\mathrm{R}}$、$\boldsymbol{W}_{\mathrm{Z}}$、$\boldsymbol{W}_{\mathrm{H}}$、$\boldsymbol{W}_0$、$\boldsymbol{W}_1$ 表示训练过程中的权重参数矩阵；$\boldsymbol{B}_{\mathrm{R}}$、$\boldsymbol{B}_{\mathrm{Z}}$、$\boldsymbol{B}_{\mathrm{H}}$ 表示训练过程中的偏差矩阵。

3）注意力层

注意力层将不同时刻的隐藏层输出分配不同的权重，然后加权求和，即：

$$\boldsymbol{H}=\boldsymbol{W}_{\mathrm{O}}(\boldsymbol{H}_{t-T+1}\bullet\cdots\bullet\boldsymbol{H}_{t-2}\bullet\boldsymbol{H}_{t-1}\bullet\boldsymbol{H}_t) \tag{8}$$

式中：$\boldsymbol{W}_{\mathrm{O}}\in\boldsymbol{R}^{1\times T}$ 为注意力矩阵；矩阵 $\boldsymbol{H}$ 为 $T$ 个时刻隐藏层加权求和的结果。

4）全连接层

通过全连接层输出最终的预测结果为：

$$\hat{\boldsymbol{X}}_{t+1}=\sigma(\boldsymbol{W}_{\mathrm{X}}\boldsymbol{H}\oplus\boldsymbol{B}_{\mathrm{X}}) \tag{9}$$

式中：$\hat{\boldsymbol{X}}_{t+1}=[\hat{X}_{t+1}^{1},\ \hat{X}_{t+1}^{2},\cdots,\ \hat{X}_{t+1}^{M}]$包括 $M$ 个邻近站点在 $T+1$ 时刻(待预测时刻)的出力矩阵；矩阵 $\boldsymbol{W}_{\mathrm{X}}$ 表示训练过程中的权重参数矩阵；矩阵 $\boldsymbol{B}_{\mathrm{X}}$ 表示训练过程中的偏差矩阵

5）损失函数

损失函数 $f_{\mathrm{loss}}$ 由预测值 $\hat{X}_{t+1}$ 和真实值 $X_{t+1}$ 之间差值的平方和惩罚项 $L_2$ 组成，惩罚项 $L_2$ 可以提高模型泛化能力，减少过拟合，即：

$$f_{\mathrm{loss}}=(\hat{X}_{t+1}-X_{t+1})^2+\gamma L_2 \tag{10}$$

式中：$\gamma$ 为调节因子。

## 4 算例分析

### 4.1 数据预处理

选取我国中部某地区内 79 个屋顶光伏所测量的真实数据，包括 2018 年 12 个月的历史出力数据，间隔 15 min，训练集与测试集样本比例为 8:2。光伏的地理位置分布如附录 A 图 A1 所示。采用最大值归一化进行数据预处理，即：

$$\tilde{X}_t^i=\frac{X_t^i}{\max\limits_i X_t^i} \tag{11}$$

式中：$X_t^j$ 为站点 $j$ 在历史时刻 $t$ 的出力；$\tilde{X}_t^i$ 为归一化结果。

### 4.2 评价指标

选取平均绝对误差(mean absolute error，MAE)、均方根误差(root mean square error，RMSE) 和决定系数 $R^2$ 作为预测结果的评价指标。MAE 和 RMSE 用于衡量预测值和真实值之间的差异，值越小预测效果越好，如式(12)、(13)所示。决定系数 $R^2$ 衡量预测结果代表实际数据的能力，越接近 1 代表预测效果越好，即：

$$e_{\mathrm{MAE}}=\frac{1}{N}\sum_{i=1}^{N}\left(\frac{1}{C}\sum_{t=1}^{C}\left|X_t^i-\hat{X}_t^i\right|\right) \tag{12}$$

$$e_{\mathrm{RMSE}}=\frac{1}{N}\sum_{i=1}^{N}\sqrt{\frac{1}{C}\sum_{t=1}^{C}(X_t^i-\hat{X}_t^i)^2} \tag{13}$$

$$e_{\mathrm{R}}=1-\frac{\sum\limits_{t=1}^{C}\sum\limits_{i=1}^{N}(X_t^i-\hat{X}_t^i)^2}{\sum\limits_{t=1}^{C}\sum\limits_{i=1}^{N}(X_t^i-\frac{1}{NC}\sum\limits_{t=1}^{C}\sum\limits_{i=1}^{N}X_t^i)^2} \tag{14}$$

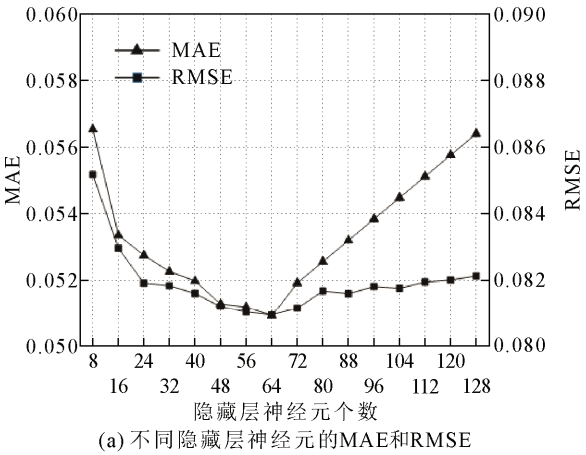
式中：$\hat{X}_t^i$ 为站点 $i$ 在时刻 $t$ 的光伏出力预测值；$C$ 为测试集样本个数。

### 4.3 超参数选择

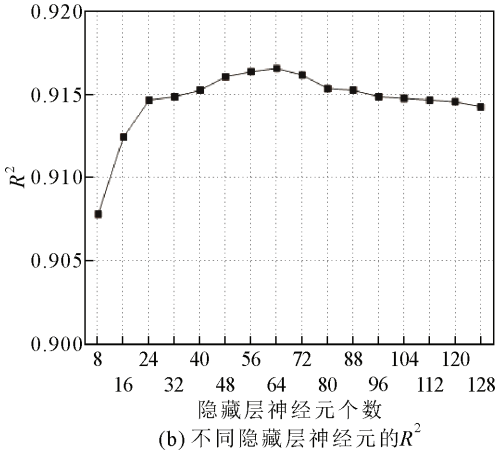
实验在 Windows 11 系统的 Python 3.8.5 环境下运行，深度学习框架选用的是 TensorFlow 框架，实验平台配置为 NVIDIA GeForce RTX 3050 Ti Laptop GPU 和 AMD Ryzen 7 5800H，内存 16 GB。

为了选择 AGCRN 网络的最佳隐藏层神经元个数，采用不同的隐藏神经元数：8、16、24、32、40、48、56、64、72、80、88、96、104、112、120、128 进行实验，比较预测结果来选择最佳值。图 5(a)为 RMSE 和 MAE 随不同隐藏层神经元个数的变化，图 5(b)为决定系数 $R^2$ 随不同隐藏层神经元个数的变化。

如图 5 所示，当隐藏层神经元较少时，网络无法充分学习样本数据的特征，导致模型欠拟合，预测性能不佳。随着隐藏层神经元个数的增加，网络学到的特征增多，预测性能提高，增加至 64 个神经元时预测性能达到最佳，之后由于隐藏层神经元较多，训练样本中包含的有限信息量不足以训练隐藏层中的所有神经元，导致网络过拟合，泛化能力差，预测性能降低。




(a) 不同隐藏层神经元的MAE和RMSE




(b) 不同隐藏层神经元的$R^2$

图 5 不同隐藏层神经元的预测性能比较

Fig.5 Comparison of predicted performance under different hidden units

AGCRN 网络训练参数配置如表 1 所示。

### 4.4 算法对比

#### 4.4.1 对比模型

为了验证本文所提 AGCRN 网络的优越性，采用了 5 种模型作为对比，如表 2 所示。

如表 2 所示，对比模型包括 2 种多站预测模型：图卷积循环网络(graph convolution recurrent network，GCRN)、adj-GRU；3 种单站预测模型：GRU、卷积神经网络(convolutional neural networks，CNN)、深度神经网络(deep neural networks，DNN)。多站预测模型将多个邻近光伏站点的出力数据作为模型输入，提取多个光伏站点出力的时空相关性，而单站预测模型仅提取单个站点出力的时序特征。

1）GCRN

为了验证自适应机制对于提取多站点出力空间特征的优势，将传统图卷积网络和循环网络融合构成 GCRN 作为对比方法，GCRN 仅利用预定义的静态图结构提取空间特征，不能自适应地调整邻接矩阵元素大小，其他部分和 AGCRN 相同。

2）adj-GRU

adj-GRU 将多个邻近光伏站点的出力数据作为输入，采用 GRU 网络捕捉多个光伏出力序列的时空相关性。

GCRN 和 adj-GRU 模型的输入 $\boldsymbol{I}_{\text{multi}}$ 为 $M$ 个邻近站点 $T$ 个历史时刻出力组成的矩阵，即：

$$\boldsymbol{I}_{\text{multi}}=\begin{bmatrix} X_{t-T+1}^{1} & X_{t-T+1}^{2} & \cdots & X_{t-T+1}^{M} \\ X_{t-T+2}^{1} & X_{t-T+2}^{2} & \cdots & X_{t-T+2}^{M} \\ \vdots & \vdots & & \vdots \\ X_{t}^{1} & X_{t}^{2} & \cdots & X_{t}^{M} \end{bmatrix}_{T\times M} \tag{15}$$

3）单站预测模型

单站预测模型 GRU、CNN、DNN 的输入 $\boldsymbol{I}_{\text{single}}$ 为单个站点的历史出力序列，即：

$$\boldsymbol{I}_{\text{single}}=\begin{bmatrix} X_{t-T+1}^{j} & X_{t-T+2}^{j} & \cdots & X_{t}^{j} \end{bmatrix}_{1\times T} \tag{16}$$

各个对比模型的参数配置如表 3 所示。

#### 4.4.2 不同预测尺度性能对比结果

为了对比各模型在不同预测时间尺度的预测性能，设置不同的预测时间尺度：15、30、60 min 进行实验，在 3 种预测尺度下分别计算各方法的评价指标 MAE、RMSE 和 $R^2$，如图 6 所示。由图 6 可知：

1）在各个时间尺度下，AGCRN 相较于其他 5 种对比模型均有最小的平均绝对误差 MAE、均方根误差 RMSE 和最高的决定系数 $R^2$，说明本文所提 AGCRN 模型在光伏发电功率预测中有较好的预测效果，且适用于多种时间尺度。

2）由于自适应图卷积网络在训练过程中对分布式站点图结构进行动态优化调整，能够挖掘传统图卷积无法捕捉的潜在空间相关性，提高模型的空间特征提取能力，进而提升预测性能。因此在各个时间尺度下，AGCRN 相较于 GCRN 有更好的预测性能。

3）图卷积网络在提取空间特征方面具有优势，因此将其与循环网络相结合可以更充分提取多站点光伏出力的时空相关性，从而有效减少预测误差。

表 1 AGCRN 网络参数配置

Table 1 AGCRN network parameters configuration

| 参数 | 配置 |
|---|---|
| 隐藏层神经元个数 | 64 |
| $T$ | 20 |
| 学习率 | 0.001 |
| 训练次数 | 300 |
| 批量 | 32 |
| 优化器 $\gamma$ | Adam，0.0015 |

表 2 对比模型

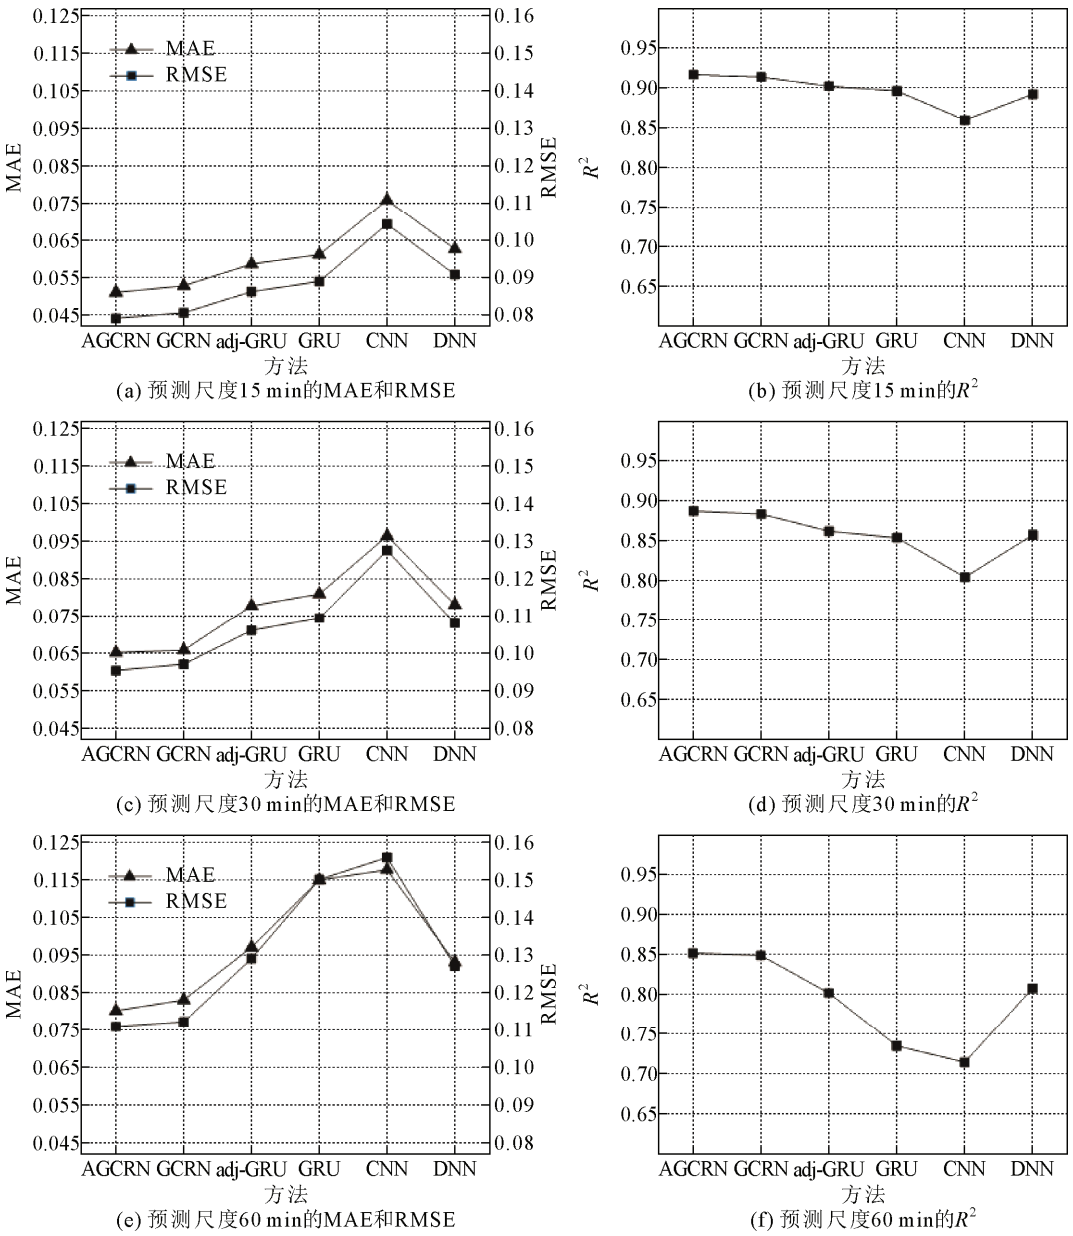
Table 2 Comparison models

| 多站预测模型 | 单站预测模型 |
|---|---|
| GCRN | GRU |
| adj-GRU | CNN |
| | DNN |

表 3 对比模型参数配置

Table 3 Parameters configuration of comparison models

| 模型 | 参数 | 数值或函数 |
|---|---|---|
| GCRN | 隐藏层神经元个数 | 64 |
| | 激活函数 | Relu |
| adj-GRU | 隐藏层神经元个数 | 64 |
| | 激活函数 | Relu |
| GRU | 隐藏层神经元个数 | 64 |
| | 激活函数 | Relu |
| CNN | 滤波器数量 | 16 |
| | 卷积核大小 | 5 |
| | 激活函数 | Relu |
| DNN | 第 1 层神经元个数 | 100 |
| | 激活函数 | Relu |
| | 第 2 层神经元个数 | 10 |
| | 激活函数 | Relu |
| | 神经元失活概率 | 0.2 |




(a) 预测尺度15 min的MAE和RMSE　(b) 预测尺度15 min的$R^2$

(c) 预测尺度30 min的MAE和RMSE　(d) 预测尺度30 min的$R^2$

(e) 预测尺度60 min的MAE和RMSE　(f) 预测尺度60 min的$R^2$

图 6　不同预测尺度的预测性能

Fig.6　Prediction performance under different forecasting horizons

所以在各个时间尺度下，基于图卷积循环网络的 AGCRN 和 GCRN 相较基于传统循环网络的 adj-GRU 有更好的预测性能。

4）单站预测模型只能提取单个站点出力的时序特征，而多站模型可以提取多个邻近分布式站点出力序列的时空相关性，进而提升预测性能。因此在各个时间尺度下，多站预测模型 AGCRN、GCRN、adj-GRU 相较单站预测模型 DNN、GRU、CNN 有更好的预测性能。

### 4.5　灵敏度分析

为了分析各个方法对于预测尺度的敏感性，绘制不同预测时间尺度下各个方法的 MAE，如图 7 所示。由图 7 可得：

1）随着预测时间尺度的增大，各个模型的预测误差逐渐增大，主要是因为预测尺度增大，光伏出力的不确定性增加，预测难度增加。

2）本文所提 AGCRN 模型在各个预测尺度下均有最小预测误差，表明 AGCRN 模型对预测尺度不敏感，在 15、30、60 min 的出力预测中均有一定适应性。

## 5　结论

分布式光伏普遍缺少气象数据采集装置，导致气象数据缺乏。因此本文针对无气象数据条件下分

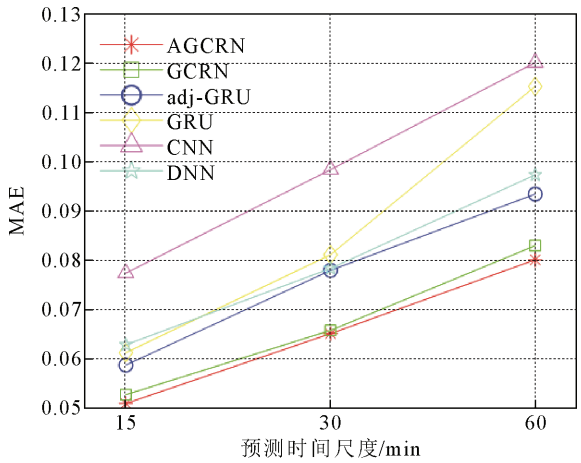



图 7 不同预测时间尺度各个方法的 MAE

Fig.7 MAE of different models under different prediction horizons

布式光伏出力预测问题，提出了一种基于 AGCRN 的分布式光伏出力预测方法，可以仅基于历史出力数据，在无气象数据的条件下实现分布式光伏出力精准预测。本文主要工作和结论归纳为：

1）提出了基于自适应图卷积循环网络的分布式光伏出力预测方法，并在不同预测时间尺度(15、30、60 min)下与不同模型(GCRN、adj-GRU、GRU、CNN、DNN)进行对比。结果表明，对于多时间尺度预测任务，AGCRN 模型均有最优的预测性能。相对于 GCRN、adj-GRU、GRU、CNN、DNN 模型，AGCRN 模型的平均绝对误差在预测尺度 15 min 时分别减少了 3.4%、13.3%、16.9%、34.2%、19.0%，在预测尺度 30 min 时分别减少了 1.0%、16.5%、19.8%、33.8%、16.9%，在预测尺度 60 min 时分别减少了 3.5%、14.3%、30.5%、33.3%、17.7%。

2）提出了自适应图卷积提取多站点光伏出力空间相关性，通过动态优化调整分布式光伏站点邻接矩阵，挖掘传统图卷积网络无法捕捉的潜在空间相关关系，提高了模型的空间特征提取能力，进而提高了预测性能。结果表明，预测尺度分别为 15、30、60 min 时，相对于传统图卷积循环网络，基于自适应图卷积循环的光伏预测结果的平均绝对误差分别减少了 3.4%、1.0%、3.5%。

3）对比了多站预测模型 AGCRN、GCRN、adj-GRU 和单站预测模型 GRU、CNN、DNN，结果表明，与单站预测模型相比，多站预测模型可以提取多个邻近站点出力序列的时空相关性，进而提升预测性能。

4）进行了灵敏度分析，结果表明，AGCRN 模型对预测时间尺度不敏感，在时间尺度 15、30、60 min 的出力预测中均有一定适应性。

附录见本刊网络版(http://hve.epri.sgcc.com.cn)。

## 参考文献 References

[1] 黎静华，骆怡辰，杨舒惠，等. 可再生能源电力不确定性预测方法综述[J]. 高电压技术，2021，47(4)：1144-1155.
LI Jinghua, LUO Yichen, YANG Shuhui, et al. Review of uncertainty forecasting methods for renewable energy power[J]. High Voltage Engineering, 2021, 47(4): 1144-1155.

[2] 万 灿，宋永华. 新能源电力系统概率预测理论与方法及其应用[J]. 电力系统自动化，2021，45(1)：2-16.
WAN Can, SONG Yonghua. Theories, methodologies and applications of probabilistic forecasting for power systems with renewable energy sources[J]. Automation of Electric Power Systems, 2021, 45(1): 2-16.

[3] 黎静华，谢育天，曾鸿宇，等. 不确定优化调度研究综述及其在新型电力系统中的应用探讨[J]. 高电压技术，2022，48(9)：3447-3464.
LI Jinghua, XIE Yutian, ZENG Hongyu, et al. Research review of uncertain optimal scheduling and its application in new-type power systems[J]. High Voltage Engineering, 2022, 48(9): 3447-3464.

[4] 康重庆，张 宁. “高比例可再生能源电力系统规划与运行”专题特约主编寄语[J]. 电工技术学报，2019，34(10)：1985-1986.
KANG Chongqing, ZHANG Ning. “Planning and operation of power system with high proportion of renewable energy” message from the special editor-in-chief[J]. Automation of Electric Power System, 2019, 34(10): 1985-1986.

[5] 马 原，张雪敏，甄 钊，等. 基于修正晴空模型的超短期光伏功率预测方法[J]. 电力系统自动化，2021，45(11)：44-51.
MA Yuan, ZHANG Xuemin, ZHEN Zhao, et al. Ultra-short-term photovoltaic power prediction method based on modified clear-sky model[J]. Automation of Electric Power Systems, 2021, 45(11): 44-51.

[6] MOUHAMET D, TOMMY A, PRIMEROSE A, et al. Improving the Heliosat-2 method for surface solar irradiation estimation under cloudy sky areas[J]. Solar Energy, 2018, 169: 565-576.

[7] ALAM S. Prediction of direct and global solar irradiance using broadband models: validation of rest model[J]. Renewable Energy, 2006, 31(8): 1253-1263.

[8] 赵书强，王明雨，胡永强，等. 基于不确定理论的光伏出力预测研究[J]. 电工技术学报，2015，30(16)：213-220.
ZHAO Shuqiang, WANG Mingyu, HU Yongqiang, et al. Research on the prediction of PV output based on uncertainty theory[J]. Transactions of China Electrotechnical Society, 2015, 30(16): 213-220.

[9] 王育飞，杨启星，薛 花. 考虑混沌特征的增强型大脑情绪神经网络光伏发电功率超短期预测模型[J]. 高电压技术，2021，47(4)：1165-1175.
WANG Yufei, YANG Qixing, XUE Hua. Ultra-short-term prediction model of enhanced brain emotional neural network considering chaotic characteristics for photovoltaic power generation[J]. High Voltage Engineering, 2021, 47(4): 1165-1175.

[10] 殷 豪，张 铮，丁伟锋，等. 基于生成对抗网络和 LSTM-CSO 的少样本光伏功率短期预测[J]. 高电压技术，2022，48(11)：4342-4351.
YIN Hao, ZHANG Zheng, DING Weifeng, et al. Short-term prediction of small-sample photovoltaic power based on generative adversarial network and LSTM-CSO[J]. High Voltage Engineering, 2022, 48(11):

4342-4351.

[11] 吴春华，董阿龙，李智华，等. 基于图相似日和 PSO-XGBoost 的光伏功率预测[J]. 高电压技术，2022，48(8)：3250-3259.
WU Chunhua, DONG Along, LI Zhihua, et al. Photovoltaic power prediction based on graph similarity day and PSO-XGBOOST[J]. High Voltage Engineering, 2022, 48(8): 3250-3259.

[12] 王振浩，王　翀，成　龙，等. 基于集合经验模态分解和深度学习的光伏功率组合预测[J]. 高电压技术，2022，48(10)：4133-4142.
WANG Zhenhao, WANG Chong, CHENG Long, et al. Photovoltaic power combined prediction based on ensemble empirical mode decomposition and deep learning[J]. High Voltage Engineering, 2022, 48(10): 4133-4142.

[13] 刘晓艳，王　珏，姚铁锤，等. 基于卫星遥感的超短期分布式光伏功率预测[J]. 电工技术学报，2022，37(7)：1800-1809.
LIU Xiaoyan, WANG Jue, YAO Tiechui, et al. Ultra short-term distributed photovoltaic power prediction based on satellite remote sensing[J]. Transactions of China Electrotechnical Society, 2022, 37(7): 1800-1809.

[14] 张童彦，廖清芬，唐　飞，等. 基于气象资源插值与迁移学习的广域分布式光伏功率预测方法[J]. 中国电机工程学报，2023，43(20)：7929-7939.
ZHANG Tongyan, LIAO Qingfen, TANG Fei, et al. Wide-area distributed photovoltaic power forecast method based on meteorological resource interpolation and transfer learning[J]. Proceedings of the CSEE, 2023, 43(20): 7929-7939.

[15] 张家安，王琨玥，陈　建，等. 基于空间相关性的分布式光伏出力预测[J]. 电力建设，2020，41(3)：47-53.
ZHANG Jiaan, WANG Kunyue, CHEN Jian, et al. Research on prediction of distributed photovoltaic output considering spatial relevance[J]. Electric Power Construction, 2020, 41(3): 47-53.

[16] 邵尹池，袁绍军，孙荣富，等. 基于空间相关性的分布式光伏实用化功率预测及误差分析[J]. 中国电力，2021，54(7)：185-191，207.
SHAO Yinchi, YUAN Shaojun, SUN Rongfu, et al. Practical method and error analysis for distributed photovoltaic power prediction based on spatial correlation[J]. Electric Power, 2021, 54(7): 185-191, 207.

[17] 李俊伟，龚新勇，朱元富，等. 基于 SVR-LSTM-BP 的分布式光伏短期出力预测方法研究[J]. 电气应用，2023，42(2)：79-84.
LI Junwei, GONG Xinyong, ZHU Yuanfu, et al. A research on short-term distributed photovoltaic power prediction model based on SVR-LSTM-BP[J]. Electrotechnical Application, 2023, 42(2): 79-84.

[18] 甄　皓. 有限信息下基于深度学习模型的小型分布式光伏电站功率预测[J]. 上海节能，2020(4)：302-308.
ZHEN Hao. Power prediction of small distributed photovoltaic power plant based on deep learning model with limited information[J]. Shanghai Energy Conservation, 2020(4): 302-308.

[19] YANG C, THATTE A A, XIE L. Multitime-scale data-driven spatio-temporal forecast of photovoltaic generation[J]. IEEE Transactions on Sustainable Energy, 2015, 6(1): 104-112.

[20] ZHEN H, NIU D X, WNAG K K, et al. Photovoltaic power forecasting based on GA improved Bi-LSTM in microgrid without meteorological information[J]. Energy, 2021, 231: 120908.

[21] ZHAO L, SONG Y J, ZHANG C, et al. T-GCN: a temporal graph convolutional network for traffic prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(9): 3848-3858.

[22] QI Y L, LI Q, KARIMIAN H, et al. A hybrid model for spatiotemporal forecasting of $PM_{2.5}$ based on graph convolutional neural network and long short-term memory[J]. Science of the Total Environment, 2019, 664: 1-10.

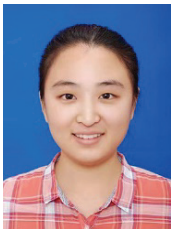
[23] DONG X C, SUN Y Y, LI Y, et al. Spatio-temporal convolutional network based power forecasting of multiple wind farms[J]. Journal of Modern Power Systems and Clean Energy, 2022, 10(2): 388-398.

[24] KIPF T N. WELLING M. Semi-supervised classification with graph convolutional networks[C] // Proceedings of the 5th International Conference on Learning Representations. Toulon, Frances: OpenReview. net, 2017.



**赵洪山**
1965—，男，博士，教授，博导
主要从事电力系统动态分析与控制、主动配电网以及故障预测等方面的研究
E-mail: zhaohshcn@126.com

ZHAO Hongshan
Ph.D., Professor



**孙承妍**
1999—，女，硕士生
主要从事光伏发电功率预测方面的研究
E-mail: 2510068513@qq.com

SUN Chengyan



**温开云**(通信作者)
1996—，男，博士生
主要从事电气设备物联感知和在线监测方面的研究
E-mail: ncepu_wky@163.com

WEN Kaiyun
Ph.D. candidate
Corresponding author



**吴雨晨**
1998—，女，硕士生
主要从事负荷预测方面的研究
E-mail: 1450685267@qq.com

WU Yuchen

收稿日期　2023-04-14　修回日期　2023-07-13　　编辑　程子丰

# 附录 A

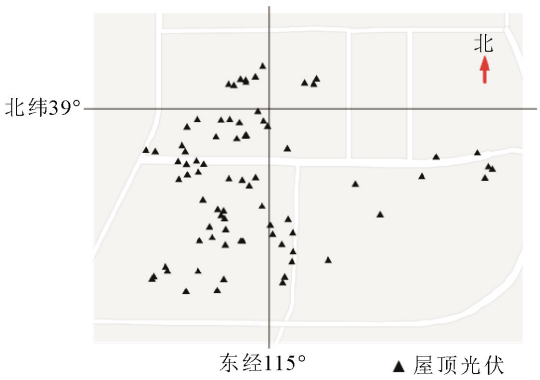



图 A1　光伏分布示意图

Fig.A1　Distribution of photovoltaic station