

基于时空图卷积神经网络的光伏发电功率 超短期预测方法

李立刚,孙立群,戴永寿,李林

(中国石油大学(华东) 海洋与空间信息学院,山东 青岛 266555)

摘要:为了解决传统光伏电站超短期功率预测方法不能同时准确提取发电功率的时间和空间特征的问题,提出一种基于时空图卷积神经网络的光伏发电功率超短期预测方法。针对同一区域内的多个光伏电站,首先对电站进行图建模,利用图卷积网络(GCN)与门控线性单元(GLU)提取发电功率的时空特征。利用提取到的时空特征信息以及区域内光伏电站的历史发电功率数据训练预测模型,最终实现对多个光伏电站发电功率超短期预测。实验结果表明,该方法能够将超短期功率预测均方根误差减小至1.122%,对工作人员根据实际情况进行电网的调度管理具有重要意义。

关键词:时空图卷积;光伏电站;功率预测

中图分类号:TM615 文献标识码:A DOI:10.16146/j.cnki.rndlge.2023.09.018

[引用本文格式]李立刚,孙立群,戴永寿,等.基于时空图卷积神经网络的光伏发电功率超短期预测方法[J].热能动力工程,2023,38(9):152-157. LI Li-gang, SUN Li-qun, DAI Yong-shou, et al. Ultra-short-term prediction method of photovoltaic power based on spatio-temporal graph convolutional neural network [J]. Journal of Engineering for Thermal Energy and Power, 2023, 38(9): 152-157.

Ultra-short-term Prediction Method of Photovoltaic Power based on Spatio-temporal Graph Convolutional Neural Network

LI Li-gang, SUN Li-qun, DAI Yong-shou, LI Lin

(College of Oceanography and Space Informatics, China University of Petroleum (East China),
Qingdao, China, Post Code: 266555)

Abstract: To solve the problem that traditional ultra-short-term power prediction methods for PV power plants cannot accurately extract both temporal and spatial characteristics of power generation rate, an ultra-short-term prediction method of PV power generation based on spatio-temporal graph convolutional neural networks was proposed. For multiple PV plants in the same area, firstly, graph modeling of the power plants was conducted. The spatio-temporal features of power generation were extracted using graph convolutional networks (GCN) with gated linear units (GLU). Then, based on the extracted spatio-temporal feature information and the historical power generation data of PV plants in the region, the prediction model was trained. Finally, the ultra-short-term prediction of generated power of multiple PV plants was realized. The experimental results show that the method can reduce the RMSE of the ultra-short-term power prediction to 1.122%. It is important for the staff to arrange the dispatch management of the power grid according to the actual situation.

Key words: spatio-temporal graph convolutional network, photovoltaic power plants, power prediction

引言

光伏发电作为利用太阳能的重要方式之一,如今正在被广泛应用于生产生活之中^[1]。但是由于光伏发电功率具有不确定性,导致光伏电站无法像传统发电站一样向电力系统稳定地输送电能,接入公共电网会对电网产生较大的冲击^[2]。因此,在光伏电站运行阶段,进行光伏电站发电功率超短期(0~4 h)预测,对帮助工作人员进行电网的调度管理具有重要意义^[3]。

近些年国内外专家学者利用机器学习算法针对光伏发电功率超短期预测进行了许多研究^[4]。机器学习预测方法大多数采用智能算法对样本数据进行训练,进而得到光伏电站所在地的气象数据与未来发电功率之间的关系^[5]。常见的机器学习方法有神经网络^[6]、支持向量机^[7]、粒子群算法^[8]和遗传算法^[9]等。文献[10]采用一种 PVPNet 高精度深度神经网络模型来预测具有复杂时间序列的光伏发电功率。文献[11]构建了多个机器学习算法嵌入的 Stacking 集成学习负荷预测模型。文献[12]利用神经网络预测方法对光伏发电功率进行分类预测。但是由于机器学习预测模型无法同时准确提取光伏电站发电功率时间和空间的特征,导致预测模型的误差函数在进行梯度下降计算时难以确定大量模型参数。所以,使用普通的机器学习算法进行预测会导致训练出的模型过拟合、降低预测精度。同时,由于光伏电站发电功率主要受到太阳辐照度影响,太阳辐照度受到多种气象因素的影响具有一定的时空关联,因此同一地区内不同位置光伏电站的发电功率也具有较高的时空相关性。

为了解决光伏电站超短期功率预测过程中传统预测模型难以同时准确提取时空特征的问题,本文采用一种基于时空图卷积神经网络(Spatio-temporal Graph Convolutional Network, STGCN)的光伏发电功率超短期预测方法,通过分析同一区域内各光伏电站历史发电功率之间的空间相关性,对光伏电站进行图建模,将历史发电功率数据表示为图结构。采用图卷积网络(GCN)提取空间特征,采用门控线性单元(GLU)提取时间特征。根据提取的时空特征信息以及历史发电功率数据训练预测模型,最终实现对光伏电站发电功率短时预测。解决了传统机器

学习方法预测过程中存在训练模型过拟合的问题。通过利用实际数据进行预测实验与误差对比,验证该方法能够有效提高光伏电站超短期发电功率预测的精度。

1 STGCN 光伏发电功率超短期预测模型

1.1 STGCN 模型框架

采用2个时间模块与1个空间模块叠加构成时空图卷积层进行时空特征提取。将历史发电功率数据集合 $V_t = \{v_{i,t}\}$ 作为时间特征提取模块的输入进行时序卷积,将光伏电站图结构的加权邻接矩阵 $E = \{w_{i,j}\}$ 作为空间特征提取模块的输入进行空间卷积。

输入的历史发电功率数据的集合 $V_t = \{v_{i,t}\}$ 首先经过一层时间特征提取模块进行时间卷积,然后结合加权邻接矩阵 $E = \{w_{i,j}\}$ 经过空间特征提取模块进行空间卷积后,再次输入时间特征提取模块得到光伏电站发电功率的时空特征。经过多个时空图卷积层叠加,最终通过全连接层将光伏电站发电功率的时空特征进行非线性化,提取时间与空间特征之间的关联映射到输出空间中,得到光伏电站未来发电功率预测值 \hat{V}_t 。最后,根据损失函数计算真实值与预测值的误差,经过反向传播后将误差降低。时空图卷积神经网络模型结构如图1所示。

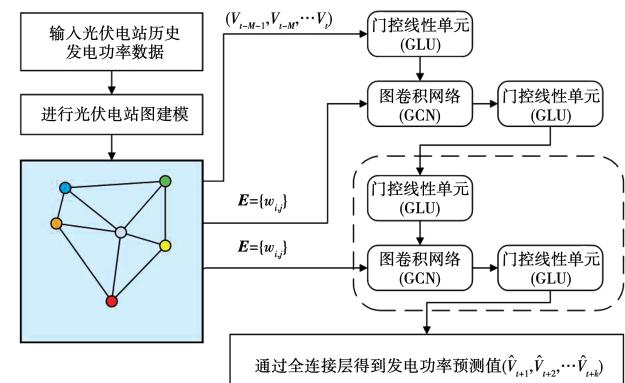


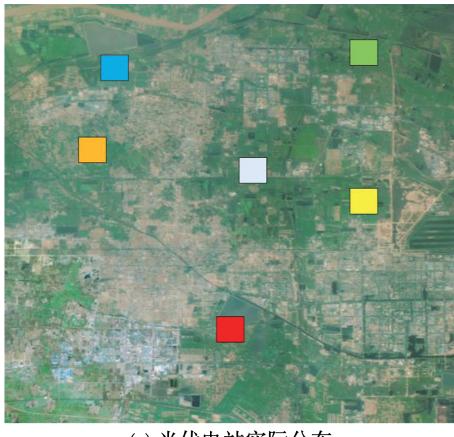
图1 时空图卷积神经网络模型结构图

Fig. 1 Structure diagram of spatio-temporal graph convolutional neural network model

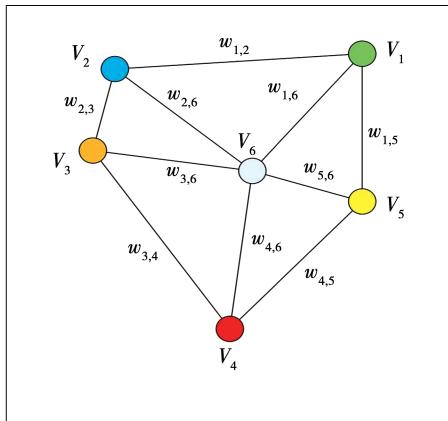
1.2 光伏电站图建模

为了使图卷积神经网络可以处理光伏发电功率数据,通过分析区域内多个光伏电站发电功率之间

的相关性,对光伏电站进行图建模。图 2(a)为光伏电站实际分布图,图 2(b)为通过图建模得到的光伏电站点线拓扑结构图。



(a) 光伏电站实际分布



(b) 光伏电站拓扑结构

图 2 光伏电站图建模示意图

Fig. 2 Schematic diagram of photovoltaic power plant graph modeling

将区域内各光伏电站表示为节点,节点之间的相关性通过具有权重值的连线表示。区域内 t 时刻的光伏电站通过时空图可以表示为:

$$\dot{G}_t = \langle V_t, E \rangle \quad (1)$$

$$V_t = \{v_{i,t}\} (i = 1, 2, 3, \dots, n) \quad (2)$$

$$E = \{w_{i,j}\} (i, j = 1, 2, 3, \dots, n) \quad (3)$$

式中: $V_t = \{v_{i,t}\}$ —时空图中所有节点在 t 时刻发电功率数据的集合; $E = \{w_{i,j}\}$ —时空图中连线的加权邻接矩阵; $w_{i,j}$ —节点 v_i 与节点 v_j 之间权重系数。

只有节点 v_i 与节点 v_j 之间具有较高相关性时,节点 v_i 与节点 v_j 才能够相互连接。节点之间的权重系数可以表示为:

$$w_{i,j} = \begin{cases} e^{-(v_i, v_j)}, & r_{i,j} > k \\ 0, & r_{i,j} \leq k \end{cases} \quad (4)$$

式中: $r_{i,j}$ —两节点的相关系数; (v_i, v_j) —两节点之间的欧氏距离。

若 $r_{i,j} > k$, 则证明两个光伏电站之间相关性较高, 节点 v_i 与节点 v_j 可以通过连线相连接。若 $r_{i,j} \leq k$, 则表示节点之间不存在连接关系。

2 光伏发电功率时空特征提取

2.1 基于门控线性单元的时间特征提取

采用门控线性单元对不同长度的发电功率时间序列数据进行时间特征提取^[13]。时间特征提取模块结构如图 3 所示。

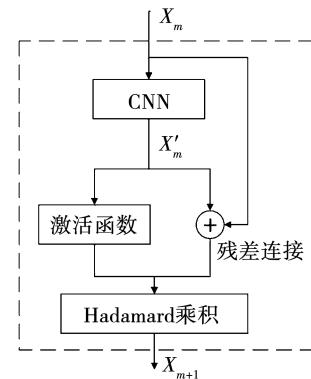


图 3 时间特征提取模块结构图

Fig. 3 Structure diagram of spatio-temporal feature extraction module

门控线性单元的输入为历史发电功率数据 $X_m \in R^{N \times C_i}$, C_i 表示输入时间序列的通道个数, N 代表输入时间序列的长度。采用 $\Gamma \in R^{K_t \times C_i \times 2C_o}$ 作为卷积核, 对输入序列 X_m 通过 CNN 进行一维卷积, 得到输出:

$$X'_m = \Gamma * X_m \in R^{(N-K_t+1) \times 2C_o} \quad (5)$$

式中: K_t —卷积核的大小; C_o —为输出通道的个数。

将 X'_m 分为相同的两部分,一部分与输入进行残差连接,另一部分采用 Sigmoid 函数作为激活函数进行激活。最终,将各部分卷积计算结果通过 Hadamard 乘积进行拼接,得到时间卷积模块的输出 $X_{m+1} \in R^{(N-K_t+1) \times C_o}$ 。

2.2 基于图卷积神经网络的空间特征提取

采用图卷积网络提取光伏电站点线拓扑结构图

中各节点的空间特征^[14-15],同时在频谱域上采用归一化拉普拉斯矩阵,将光伏电站图结构定义为:

$$\mathbf{L} = \mathbf{I} - \mathbf{D}^{-\frac{1}{2}} \mathbf{E} \mathbf{D}^{\frac{1}{2}} \quad (6)$$

式中: \mathbf{I} —单位矩阵; $\mathbf{E} = \{w_{i,j}\}$ —光伏电站发电功率图结构的加权邻接矩阵; $\mathbf{D} = \{d_{i,i}\} \in \mathbf{R}^{N \times N}$ —光伏电站发电功率图结构的度矩阵,其中 $d_{i,i} = \sum_j w_{i,j}$ 。

对归一化的拉普拉斯矩阵进行特征分解可以得到 $\mathbf{L} = \mathbf{U} \Lambda \mathbf{U}^T$, $\mathbf{U} \in \mathbf{R}^{N \times N}$ 为 \mathbf{L} 的特征向量构成的矩阵,通过对 \mathbf{L} 进行特征分解得到。 $\Lambda = [\lambda_1, \lambda_2, \dots, \lambda_n]$ 是由 \mathbf{L} 的特征值构成的特征值矩阵。简化图卷积的运算操作,能够得到图卷积公式为:

$$(\mathbf{X}_m * \mathbf{g}) = \mathbf{U}((\mathbf{U}^T \mathbf{g}) \odot (\mathbf{U}^T \mathbf{X}_m)) \quad (7)$$

式中: \mathbf{X}_m —图卷积神经网络输入,即时间卷积模块输出; \mathbf{g} —卷积核; \odot —Hadamard 乘积。采用 $\mathbf{g}_\theta = \mathbf{U}^T \mathbf{g}$ 作为卷积核,并且 $\theta \in \mathbf{R}^{N \times N}$,得到图卷积公式为:

$$(\mathbf{X}_m * \mathbf{g}) = \mathbf{U} \mathbf{g}_\theta \mathbf{U}^T \mathbf{X}_m \quad (8)$$

由于进行图卷积过程中计算量较大,为了提高空间特征提取速度,采用切比雪夫多项式对卷积核进行拟合,可以得到卷积核为^[16]:

$$\mathbf{g}_\theta = \mathbf{g}_\theta(\Lambda) \approx \sum_{H=0}^{H-1} \boldsymbol{\theta}_H \mathbf{T}_H(\tilde{\Lambda}) \quad (9)$$

式中: $\tilde{\Lambda} = \Lambda$ 经过缩放后的特征值矩阵,并且 $\tilde{\Lambda} = \frac{2\Lambda}{\lambda_{\max}} - \mathbf{I}$; λ_{\max} —矩阵 \mathbf{L} 特征值的最大值; $\boldsymbol{\theta}_H$ —对应切比雪夫多项式的系数向量; $\mathbf{T}_H(x)$ —切比雪夫多项式, $\mathbf{T}_H(x)$ 可以表示为:

$$\mathbf{T}_H(x) = 2x \mathbf{T}_{H-1}(x) - \mathbf{T}_{H-2}(x) \quad (10)$$

式中: $\mathbf{T}_0(x) = 1$, $\mathbf{T}_1(x) = x$; H —切比雪夫多项式的阶数。

通过引入切比雪夫多项式可将图卷积公式转换为:

$$\mathbf{g} * x = \sum_{H=0}^{H-1} \boldsymbol{\theta}_H \mathbf{T}_H(\tilde{\mathbf{L}}) x \quad (11)$$

式中: $\tilde{\mathbf{L}} = \frac{2\mathbf{L}}{\lambda_{\max}} - \mathbf{I} = \mathbf{U} \tilde{\Lambda} \mathbf{U}^T$ 。

将光伏电站历史发电功率数据经过时间特征提取模块后的输出 $\mathbf{X}_{m+1} \in \mathbf{R}^{(N-K_t+1) \times C_i}$ 与加权邻接矩阵 $\mathbf{E} = \{w_{i,j}\}$ 输入图卷积,经过空间卷积可以得到输出为 $\mathbf{X}_{m+2} \in \mathbf{R}^{(N-K_t+1) \times C_o}$ 。

3 数据处理与结果分析

为了验证基于时空图卷积神经网络的光伏发电

功率超短期预测方法应用于短期发电功率预测的有效性与优越性,利用实测数据对方法进行验证。以位于东营市中石化胜利油田分公司所建的 20 所分布式光伏电站为研究对象,总装机容量 350 MW。对 20 所光伏电站进行图建模,将不同时刻的发电数据信息与电站地理位置信息表示在光伏电站点线拓扑结构图中。

3.1 实验准备与数据预处理

该实验研究时段为每日 07:00 ~ 17:00 共 10 h。采用 2021 年 8 月至 2022 年 10 月的光伏电站历史发电功率数据与研究区域内其中 1 所光伏电站内气象站所采集的历史气象数据作为实验样本,时间间隔为 15 min。将光伏电站发电功率样本数据分为 2 组,70% 作为训练集,30% 作为验证集,利用 2022 年 11 月的历史发电功率数据作为测试集。

对数据进行预处理,将样本数据进行归一化处理:

$$x = \frac{(y_{\max} - y_{\min})(x_i - x_{\min})}{x_{\max} - x_{\min}} + y_{\min} \quad (12)$$

式中: x_i —样本初始数据; x_{\max} 与 x_{\min} —样本中数据的最大值与最小值; x —对样本归一化之后数据; y_{\max}, y_{\min} —1 与 -1。

3.2 对比模型参数与评价指标选取

选取平均绝对误差百分比 MAPE% (Mean Absolute Percentage Error) 与均方根误差 RMSE (Root Mean Square Error) 两种误差指标作为模型预测效果的评价指标:

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{P_i - \hat{P}_i}{P_i} \right| \times 100\% \quad (13)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - \hat{P}_i)^2} \quad (14)$$

式中: P_i —实际功率; \hat{P}_i —预测功率; n —测试集样本个数。

选取适用于时间序列处理的长短期记忆网络 (LSTM) 和适用于空间特征提取的卷积神经网络, (CNN) 与时空图卷积神经网络 (STGCN) 进行基于发电功率历史数据与基于气象数据的发电功率预测对比实验。LSTM 能够通过门控结构保证时间序列按照演进方向进行递归运算,在处理发电功率时序数据时具有较好的效果。CNN 采用类似矩阵的网

格结构构造卷积核,通过卷积核水平与竖直方向的平移进行空间卷积。但 CNN 在处理光伏电站发电功率图结构这类不具有规则网格结构数据时效果不理想。STGCN 能够根据图结构中相邻节点之间的

空间相关性判断两节点之间的权重,相较于 CNN 在处理不具有规则网格结构数据时具有一定优势。两种预测模型主要参数设置如表 1 所示。

表 1 预测模型参数设置

Tab. 1 Specific parameters of prediction model

Input shape	LSTM				Batch size	CNN		
	隐含层层数	隐含层神经元个数	隐含层激活函数	epoch		卷积层卷积核个数	卷积层卷积核大小	池化层卷积核大小
(20,1)	1	30	Sigmoid	500	100	64	4×4	2×2
								ReLU

3.3 结果分析

3.3.1 基于发电功率历史数据的预测对比实验

采用 LSTM,CNN 与 STGCN 3 种预测模型分别对测试集光伏电站未来 0~1 h 的发电功率进行短期预测,预测间隔为 15 min。3 种预测模型的预测效果如图 4 所示,性能指标对比如表 2 所示。

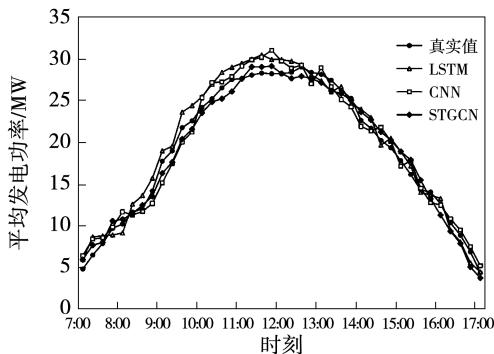


图 4 不同模型未来 1 h 发电功率预测效果对比

Fig. 4 Comparison of generated power forecast effects of different models in next 1 hour

表 2 不同模型未来 1 h 发电功率预测性能指标对比

Tab. 2 Comparison of generated power forecast performance indexes of different models in next 1 hour

模型	MAPE/%	RMSE/%
LSTM	17.981	1.076
CNN	29.815	1.933
STGCN	9.725	0.926

为了进一步对比 3 种预测模型在不同时间尺度上的预测性能,进行光伏电站未来 0~4 h 的发电功率短期预测实验,预测间隔为 15 min。3 种预测模

型的预测效果如图 5 所示,性能指标对比如表 3 所示。

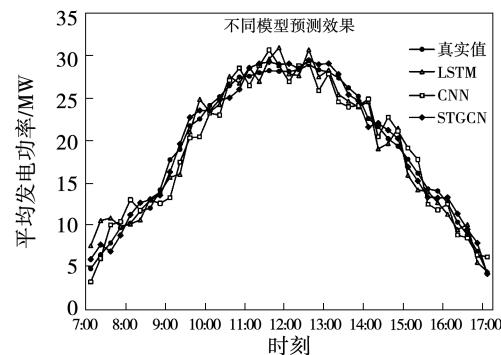


图 5 不同模型未来 4 h 发电功率预测效果对比

Fig. 5 Comparison of generated power forecast effects of different models in next 4 hours

表 3 不同模型未来 4 h 发电功率预测性能指标对比

Tab. 3 Comparison of generated power forecast performance indexes of different models in next 4 hours

模型	MAPE/%	RMSE/%
LSTM	29.227	1.658
CNN	45.532	3.145
STGCN	11.147	1.265

3.3.2 基于气象数据的发电功率预测对比实验

为了验证所提出方法相较于传统预测方法的优越性,根据研究区域内其中 1 所光伏电站的直射太阳辐照度、大气温度、湿度、风速与风向 5 种气象因素的历史数据与历史发电功率数据,采用 LSTM 对该电站进行未来 0~1 h 功率预测,与采用 STGCN

对该电站进行功率预测的结果进行对比。电站额定容量为 38 MW, 预测间隔为 15 min。两种预测方法的预测效果如图 6 所示。两种预测方法的性能指标对比如表 4 所示。

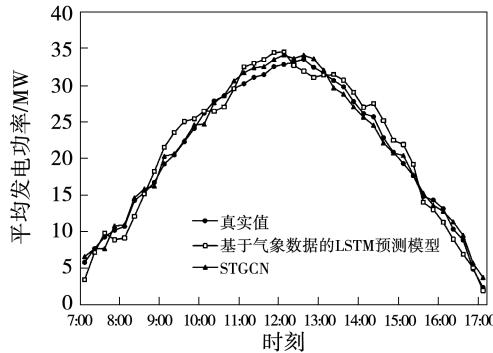


图 6 传统预测模型与 STGCN 模型预测效果对比

Fig. 6 Comparison of prediction effects between traditional prediction model and STGCN model

表 4 传统 LSTM 预测模型与 STGCN 预测模型
性能指标对比

Tab. 4 Comparison of performance indexes
between traditional LSTM prediction model
and STGCN prediction model

模 型	MAPE/%	RMSE/%
LSTM	19.379	1.224
STGCN	13.495	1.122

通过实验结果可以看出,在预测时间尺度较低的情况下,同一区域内各光伏电站发电功率之间的时空相关性较小,各种方法都能够较为准确地对未来发电功率进行预测。当延长预测时间尺度后,电站发电功率之间的时空相关性增大,由于 STGCN 模型能够同时提取光伏电站发电功率的时空特征,因此误差增长幅度低于其他方法。与根据气象数据进行模型训练的传统发电功率预测方法进行对比,利用历史功率数据进行训练的 STGCN 模型也能够具有较好的预测效果。实验证明,基于时空图卷积神经网络的光伏发电功率超短期预测方法相对于其他方法具有较好的预测效果。

4 结 论

提出一种基于时空图卷积神经网络的光伏发电

功率超短期预测方法。通过研究光伏电站的实测数据,并进行对比实验验证,得到以下结论:

(1) 通过图卷积网络与门控线性单元的结合,实现了对发电功率时空特征的准确提取。

(2) 利用历史发电功率数据进行未来 1 h 功率预测时,STGCN 模型预测结果的 RMSE 相较于 LSTM 与 CNN 分别减小 13.4% 和 50.9%。进行未来 4 h 功率预测时,STGCN 模型预测结果 RMSE 相较于 LSTM 与 CNN 分别减小 23.4% 和 60.2%。一定程度提高了发电功率的预测精度。

(3) STGCN 模型预测结果 RMSE 相较于利用气象数据进行模型训练的 LSTM 发电功率预测结果减小了 7.6%。

参 考 文 献:

- [1] 武明义,焦超凡,瞿博阳,等.基于相似日算法及集成学习的短期光伏预测模型[J].电气技术,2021,22(4):33–37.
WU Ming-yi,JIAO Chao-fan,QU Bo-yang,et al. Short-term photovoltaic power forecasting model based on similarity day algorithm and ensemble learning [J]. Electrical Engineering,2021,22(4):33–37.
- [2] 李斌,张一凡,颜世烨,等.基于改进极限学习机 ELM 的光伏发电预测方法研究[J].热能动力工程,2022,37(10):207–214.
LI Bin,ZHANG Yi-fan,YAN Shi-ye,et al. Research on photovoltaic power generation prediction method based on improved extreme learning machine (ELM) [J]. Journal of Engineering for Thermal Energy and Power,2022,37(10):207–214.
- [3] 张雪松,李鹏,周亦尧,等.基于贝叶斯概率的光伏出力组合预测方法[J].太阳能学报,2021,42(10):80–86.
ZHANG Xue-song,LI Peng,ZHOU Yi-yao,et al. Photovoltaic output combination forecasting method based on Bayesian probability [J]. Acta Energiae Solaris Sinica,2021,42(10):80–86.
- [4] RAZA M Q,MITHULANANTAAN N,LI J M. An ensemble framework for day-ahead forecast of PV output power in smart grids [J]. IEEE Transactions on Industrial Informatics,2019,15(8):4624–4634.
- [5] 武天雨.考虑气象影响因素的光伏出力预测研究[D].秦皇岛:燕山大学,2021.
WU Tian-yu. Study on photovoltaic output prediction considering meteorological factors [D]. Qinhuangdao: Yanshan University,2021.