

基于逐步聚类分析的短期光伏发电预测方法

宋 煜¹, 郭军红¹, 袁 荔², 李 薇¹

(1. 华北电力大学 资源环境系统优化教育部重点实验室, 北京 102206;

2. 国网智能电网研究院有限公司, 北京 102206)

摘 要: 光伏发电功率与气象因素密切相关, 可靠的功率预测对光伏入网和电网安全运行具有重要意义。为提高光伏短期发电功率预测的准确率, 基于某 40 MW 光伏电站历史功率和气象数据, 在不同季节和天气类型下利用逐步聚类分析方法(SCA)搭建光伏短期预测模型, 实现分季节和天气类型的光伏功率预测。模型对比结果表明: 逐步聚类分析方法具有较高的预测精度, 在四季、单一天气类型和复合天气类型 3 方面预测精度分别提高了 11.13%、9.51% 和 8.26%。

关 键 词: 光伏功率预测; 逐步聚类分析(SCA); 气象因素; 天气类型

中图分类号: TM615 文献标识码: A DOI: 10.16146/j.cnki.rndlgc.2023.10.019

[引用本文格式] 宋 煜, 郭军红, 袁 荔, 等. 基于逐步聚类分析的短期光伏发电预测方法[J]. 热能动力工程, 2023, 38(10): 158-166. SONG Yu, GUO Jun-hong, YUAN Li, et al. Short-term photovoltaic power generation prediction method based on stepwise clustering analysis [J]. Journal of Engineering for Thermal Energy and Power, 2023, 38(10): 158-166.

Short-term Photovoltaic Power Generation Prediction Method based on Stepwise Clustering Analysis

SONG Yu¹, GUO Jun-hong¹, YUAN Li², LI Wei¹

(1. Key Laboratory of Resources and Environment System Optimization of Ministry of Education,

North China Electric Power University, Beijing, China, Post Code: 102206;

2. State Grid Smart Grid Research Institute Co., Ltd., Beijing, China, Post Code: 102206)

Abstract: Photovoltaic power is closely related to meteorological factors, and reliable power prediction is of great significance for photovoltaic grid connection and safe operation of power grid. In order to improve the accuracy of short-term photovoltaic power forecast, based on the historical power and meteorological data of a 40 MW PV power station, under different seasons and the weather types using the method of stepwise clustering analysis (SCA), short-term photovoltaic forecasting model was built to implement photovoltaic power prediction classified by season and weather types. The results show that the stepwise clustering analysis method has high prediction accuracy, and the prediction accuracies of four seasons, single weather type and composite weather type are improved by 11.13%, 9.51% and 8.26%, respectively.

Key words: photovoltaic power prediction, stepwise clustering analysis (SCA), meteorological factors, weather types

收稿日期: 2022-11-02; 修订日期: 2022-12-12

基金项目: 国家重点研发计划(2018YFE0208400); 国家电网有限公司总部科技项目—“支撑供电+能效服务的需求侧碳减排方法体系与增值服务技术研究及应用(5400-202140500A-0-5-ZN)

Fund-supported Project: National Key Research and Development Program (2018YFE0208400); Research and Application of Carbon Emission Reduction Methodology and Value-added Service Technology in the Demand Side supporting "Power Supply and Energy Efficiency Service" (5400-202140500A-0-5-ZN)

作者简介: 宋 煜(1995-), 男, 华北电力大学硕士研究生。

引 言

大力发展光伏发电是我国可再生能源开发利用的重点,也是实现碳达峰、碳中和的重要途径和手段。光伏发电具有波动性大、随机性强等特点,准确的功率预测可以提高光伏发电并网运行的稳定性,提高电网调度的能力^[1]。

光伏预测的方法有间接预测法和直接预测法。间接预测法不需要光伏电站的历史运行数据,主要利用太阳辐照度等气象要素和电站发电的物理模型对光伏发电功率进行预测^[2]。直接预测法是利用统计或者智能算法(如神经网络、支持向量机等)构建输入变量和输出变量之间的关系模型,完成光伏发电功率的预测^[3]。其中针对历史气象数据的处理过程,主要采用聚类算法(如 K 均值等)对不同的天气因素进行分类^[4-7]。在模型搭建方面,目前普遍使用神经网络^[8]、支持向量机^[9]等智能算法。文献[10-11]分别利用长短期神经网络和卷积神经网络搭建了不同天气类型下的预测模型,试验结果表明,该方法预测性能比传统神经网络方法有了较好的提升。文献[12-14]基于支持向量机预测模型,耦合了其他方法(如麻雀搜索等),对支持向量机的参数进行优化,提高了光伏发电出力预测的准确性。但是,由于光伏发电主要受天气因素影响,具有随机性、复杂性等特点,目前的方法具有一定的局限性,如神经网络收敛速度慢,支持向量机模型不适合大规模的样本训练,而且不能很好地处理样本数据之间的关联性^[15],所以无法对多种因素影响的光伏预测进行深层次的分析^[16]。此外,当前研究针对的天气类型也以晴、雨等单一天气类型为主,缺少对复合天气类型的预测。

基于此,本文在考虑多种复合天气的情况下,使

用一种逐步聚类分析方法(Stepwise Clustering Analysis, SCA)^[17]搭建短期光伏发电预测模型,该模型可以将输入层与输出层之间的复杂关系通过聚类树呈现出来,可以很好地表征气象要素的随机和离散等特性,以提高光伏预测精度。

1 模型构建

1.1 气象因素相关性分析

光伏发电功率受到许多因素的影响,其设备自身的影响一般保持不变,因为已经运行的光伏电站中太阳能电池板的面积、角度、转换效率等基本上是固定的;而气象因素则是多变的,如天气类型、太阳辐射、环境温度、风速和湿度等气象因素的变化都会造成光伏发电功率波动,导致光伏发电不稳定。因此,在构建光伏发电预测模型前,首先要分析气象因素和光伏发电功率之间的相关性,选取相关性高的因素作为预测模型的输入。

选择 Pearson 相关系数,分析光伏发电功率和气象因素的相关性。计算公式如下^[18]:

$$r_{xy} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}}$$

(1)

式中: X_i, Y_i —两个连续性变量; $\bar{X}, \bar{Y}$ —两个变量的均值; r_{xy} — X 和 Y 的 Pearson 相关系数。

Pearson 相关系数的本质是两组相关因素数据的协方差除以两组数据的标准差,系数的取值范围为 $[-1, 1]$ 。 $r_{xy} > 0$,则两变量呈正相关性, $r_{xy} < 0$,则两变量呈负相关性,且 r_{xy} 绝对值越大两个变量的相关程度越大。

样本数据来源是某光伏电站历史发电和实测气象数据,后者包括太阳辐照度、风速、风向、温度、湿度 5 个气象要素,其与光伏发电功率的相关系数如表 1 所示。

表 1 气象参数与光伏发电功率输出相关性分析结果

Tab. 1 Correlation analysis results between meteorological parameters and PV power output

气象因素	太阳辐照度	风速	风向	温度	湿度	发电功率
太阳辐照度	1	0.15 *	0.10 *	0.57 *	-0.57 *	0.96 *
风速	-	1	0.58 *	0.15 *	-0.63 *	0.14 *
风向	-	-	1	0.02	-0.50 *	0.12 *
温度	-	-	-	1	-0.34 *	0.43 *
湿度	-	-	-	-	1	-0.60 *
功率	-	-	-	-	-	1

注: * 表示通过 0.01 显著性检验。

由表 1 可见,太阳辐照度与光伏发电功率相关性极强,温度和湿度与光伏发电功率之间表现为强相关性,风速和光伏发电功率之间表现为弱相关性。光伏发电功率随着太阳辐照度与温度升高而升高,其关系表现为正相关,而湿度升高会增加空气中水汽对太阳辐射的吸收,输出功率会随之降低,因此其关系表现为负相关,且太阳辐射与温度和湿度也密切相关^[19],这与表中相关性分析结果相对应。但风速会影响云的飘动速度,间接影响光伏电池板受光照的时长,进而对光伏发电产生影响^[20],因此选取辐照度、温度、湿度和风速并结合天气类型作为模型输入构建光伏预测模型。

1.2 逐步聚类分析方法

SCA 的原理是对许多相关和独立变量的样本进行一系列的切割和合并,划分成不可分割的子集^[21]。对于 SCA 来说,整个训练集或者部分训练集就是 1 个单一的聚类,其中包括 1 个样本、 k 个自变量和 q 个因变量,如本文中的样本为某光伏电站 2019~2020 年的历史数据,自变量为时间和 5 个气象因素,因变量为发电功率。样本数据基于 Wilks 准则聚类可以被分割成多个子聚类,直到把所有的样本划分到相应的类中,如图 1 所示。




图 1 逐步聚类分析流程图

Fig. 1 Flowchart of stepwise clustering analysis

对样本进行分割和合并的标准是基于 Wilks 的 Λ 统计量,公式如下^[22]:

$$\Lambda = \frac{|E|}{|E + H|} \tag{2}$$

式中: E, H —组内与组之间的平方和及交叉乘积矩阵。

假设两组变量 x 和 y 分别还有 m 和 n 个样本,两组样本中的每个样本可以单独表示为: $x_i = (x_{i1}, x_{i2}, x_{i3}, \dots, x_{ip}), i = 1, 2, 3, \dots, m$,或者 $y_j = (y_{j1}, y_{j2}, y_{j3}, \dots, y_{jp}), j = 1, 2, 3, \dots, n$ (P 是 x 和 y 的维数)。因此, E 和 H 可以由下式计算^[22]:

$$E = \sum_{i=1}^m (x_i - \bar{x})'(x_i - \bar{x}) + \sum_{j=1}^n (y_j - \bar{y})'(y_j - \bar{y}) \tag{3}$$

$$H = \frac{m \cdot n}{m + n} (\bar{x} - \bar{y})'(\bar{x} - \bar{y}) \tag{4}$$

式中: $\bar{x}, \bar{y}$ — x 和 y 的均值; x —气象因素; y —发电功率。

根据文献[22]的 F 近似理论,Wilks 的 λ 统计量(表示为 Λ)可以转换为 F 统计量,如下式所示^[22]:

$$F(P, m + n - P - 1) = \frac{1 - \Lambda}{\Lambda} \cdot \frac{m + n - P - 1}{P} \tag{5}$$

因此聚类标准被转换为 F 检验,通过 F 检验对子聚类之间样本平均值显著性差异进行评估。当训练集完成所有分割合并和计算检验操作之后,生成每个因变量的聚类树,在每个节点处会生成两个分支,样本经过每个节点的检验到达不可分割也不能合并的末端成为叶子节点,即划分到最终的类中。

逐步聚类分析方法基于电站的历史气象因素数据和发电功率之间的统计关系,预测未来光伏电站的发电功率,需要在气象因素和发电功率之间建立统计函数关系:

$$y = F(x_1, x_2, \dots, x_i) \tag{6}$$

式中: F —建立的气象因素数据和发电功率之间的统计关系。

1.3 预测模型的建立

基于 SCA 的光伏发电功率预测步骤如图 2 所示。根据气象局 2017 年发布的《公共气象服务—天

气图形符号》(GB/T22164-2017)^[23]将天气分为 8 类,将其进行无量纲化处理,按照晴、阴、雨、多云、晴转其他、阴转其他、雨转其他、多云转其他 8 类进行编码处理。样本数据选取某 40 MW 光伏电站 2019 年 1 月~2021 年 5 月的历史数据,时间选取 8:00~18:00,间隔为 1 h。依据不同季节和天气类型,选取 2019 年 1~12 月和 2020 年 1~5 月及 2020 年 6~12 月和 2021 年 1~5 月的历史发电功率和气象数据分别作为训练样本和验证样本。样本数据最终包含有时间、天气类型、太阳辐照度、风速、温度、湿度 6 个输入序列和发电功率 1 个输出序列。在训练期,使用 SCA 方法进行不断的拆分、合并操作,构建光伏发电功率预测模型聚类树。验证样本输入模型得到光伏发电功率模拟值,使用平均绝对误差率 MAPE、均方根误差 RMSE、平均方差 MSE、拟合优度 R^2 和日准确率 5 个指标对构建的模型进行定量评估。其中 MAPE、RMSE 和 MSE 越小预测精度越高, R^2 越接近 1 预测精度越高。




图 2 光伏发电功率预测流程
Fig. 2 PV power prediction process

评价指标的相关计算公式如下:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{x_i - y_i}{y_i} \right| \tag{7}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \tag{8}$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2 \tag{9}$$

$$R^2 = 1 - \frac{\sum_{i=1}^m (x_i - y_i)^2}{\sum_{i=1}^m (\bar{x}_i - y_i)^2} \tag{10}$$

式中: x_i, y_i —功率预测值和功率实际值; n —数据的数量。

日预测准确率计算参考《南方区域光伏电站并网运行及辅助服务管理实施细则》(试行)中的计算方式,公式如下:

$$\text{日准确率} = \left(1 - \frac{\sqrt{\sum_{i=1}^n (P_{Mi} - P_{Pi})^2}}{\text{Cap} \sqrt{n}} \right) \times 100\% \tag{11}$$

式中: P_{Mi} — i 时刻的实际功率; P_{Pi} — i 时刻的日预测值;Cap—光伏电站额定容量; n —日样本个数,取 $n=11$ 。

2 案例分析

2.1 季节分析

图 3 给了不同季节上的 SCA 预测结果和实际的对比,分别进行多项式拟合,形成趋势线表示预测曲线走向。从整体上看,各季节的预测功率与实际功率曲线基本吻合,趋势线走向基本一致。其中,春季拟合效果最好,拟合优度值最高,夏季和冬季拟合效果相同,秋季的拟合效果最差,拟合优度最小,趋势线相差最大。

表 2 给出了四季样本数据经逐步聚类分析的结果。可以看出,春季的聚类树复杂,叶子节点的数量最多,分割和合并的次数也相对较多,说明进行聚类分析的过程更复杂;夏季的聚类树简单,因为夏季的节点数以及分割和合并的次数少。




图 3 四季功率预测和实际值对比

Fig. 3 Comparison of power forecast and actual value in four seasons

表 2 四季逐步聚类结果

Tab. 2 Stepwise clustering results in four seasons

聚类分析	春季	夏季	秋季	冬季
总节点数	2 845	859	1 206	2 530
叶子节点数	874	361	392	793
分割次数	1 239	406	532	1 107
合并次数	366	46	141	315

四季预测分析结果如表 3 所示。从误差分析结果来看,春季的预测效果最好,平均绝对误差率和平

均方差分别为 6.68% 和 3.56,拟合优度最高为 0.95;夏季的预测效果次之,其均方根误差、平均绝对误差率和平均方差比春季稍大;秋季平均误差率与冬季相接近,但均方根误差和平均方差明显大于夏季和春季;冬季的预测效果最差,3 个误差指标都是四季当中最大的。

表 3 四季预测分析结果

Tab. 3 Forecast analysis results in four seasons

季节	MAPE/%	RMSE	MSE	R^2
春	6.68	1.89	3.56	0.95
夏	14.65	2.62	6.88	0.91
秋	15.77	3.05	9.32	0.90
冬	15.78	3.31	10.97	0.91

四季预测结果的差异性主要由以下原因造成:

(1) 以夏季验证样本数据中 332 ~ 386 数据段为例(图 3(b)中用黑框标出),该数据段包含 2020 年的 7 月 1 ~ 5 日的天气类型为阴转中雨、中雨转小雨、小雨转阵雨、阴转阵雨 4 类,天气情况恶劣严重影响太阳辐照度,且电站实测的数据中也显示这 7 天的太阳辐照度明显低于其余日期。该数据段的平均绝对误差率为 12%,明显高于夏季整体的误差率,且拟合优度 R^2 仅为 0.72,因此导致模拟异常。(2) 夏、秋季节天气多变,尤其是夏季变化更快,因此这两个季节的光伏发电功率波动变化较为明显,但基于逐步聚类分析方法构建的预测模型在夏季预报上仍具有较高的预测精度。

表 4 为四季单日预测率高于 0.95 占比。由表 4 可知,四季的单日预测准确率都比较高,达到 0.90 以上的比例为 91%。其中,四季准确率大于 0.95 的比例分别为春季 73%、秋季 33%、夏季 29%、冬季 16%。

表 4 四季日准确率高于 0.95 占比(%)

Tab. 4 The daily accuracy rate in four seasons over 0.95 ratio (%)

模型	春季	夏季	秋季	冬季	整体
SCA	73	29	33	16	38
LSTM	54	29	16	1	26
RF	55	53	25	13	37

2.2 天气类型分析

图 4 和图 5 给出了不同天气类型的预测结果与实际的对比结果。从整体上看,各天气类型的功率预测值和实际值基本吻合,但也存在一定差异。具体来说,单一天气类型中晴天的预测效果最好,拟合度最高。因为晴天光照足,光伏电池板的转换效率稳定。雨天和多云预测效果次之,光照时间虽短但气象条件稳定。而多云天气的拟合效果最差。复合类型的天气预测效果虽然趋势上基本一致,但没有单一天气类型好,其中晴转其他预测效果最好,多云转其他次之,雨转其他和阴转其他较差,拟合度整体上没有单一天气类型效果好,阴转其他拟合度最差。




图 4 单一天气类型预测效果

Fig.4 Prediction effects of single weather type

表 5 给出不同天气类型样本数据经逐步聚类分析的结果。从结果可以看出,单一天气中晴天的聚类树复杂,叶子节点的数量最多,分割和合并的次数也相对较多,说明进行聚类分析的过程更复杂。多云的聚类树简单,因为多云的节点数以及分割和合

并的次数少。复合天气类型中多云转聚类树复杂,阴转的聚类树简单。




图 5 复合天气类型预测效果

Fig.5 Prediction effects of composite weather type

表 5 不同天气类型聚类结果

Tab.5 Clustering results of different weather types

聚类分析	晴	雨	多云	晴转	雨转	阴转	多云转
总节点数	2 147	1 416	963	484	455	380	1 231
叶子节点数	681	464	323	169	171	141	382
分割次数	942	626	428	217	208	173	537
合并次数	262	163	106	49	38	33	156

不同天气类型分析结果如表 6 所示。从误差分析的结果来看,单一天气类型中晴天预测效果最好,

MAPE 和 RMSE 误差分别为 10.25% 和 2.50, 拟合优度 R^2 为 0.93; 雨天预测效果次之, 多云较差, RMSE 和 MSE 值最大, 分别为 5.54 和 30.74, 拟合优度 R^2 最低为 0.68; 复合类型天气中晴转其他的预测效果最好, MAPE 和 RMSE 误差分别为 14.05% 和 3.38, 拟合优度 R^2 为 0.88; 阴转其他的预测效果最差, 各项分析结果值都偏大; 单一天气日准确率大于 0.90 比例为 72.5%, 复合类型天气为 51%。

表 6 不同天气类型分析结果

Tab.6 Analysis results of different weather types

天气类型	MAPE/%	RMSE	MSE	R^2
晴	10.25	2.50	6.27	0.93
雨	20.51	2.92	8.56	0.82
多云	26.15	5.54	30.74	0.68
晴转	14.05	3.38	11.45	0.88
雨转	20.78	3.47	12.08	0.86
阴转	40.17	6.26	39.24	0.61
多云转	15.55	3.64	13.27	0.85

2.3 模型对比分析

为进一步证明 SCA 模型的优越性, 使用长短期神经网络 (LSTM) 和随机森林 (Random Forest, RF) 两种常见的预测模型进行对比分析, 对比结果如表 7 和表 8 所示。从整体上看, SCA 在四季和不同天气类型下的结果都优于另外两种模型。结果显示, SCA 的平均绝对误差率明显低于 LSTM 和 RF, 尤其在冬季和晴天的结果中尤为突出。在均方根和拟合优度方面, SCA 模型结果也是普遍优于 LSTM 和 RF。3 种模型在四季日准确率高于 0.95 以上的比例分别为 38%, 37% 和 26%, 也反映出 SCA 模型在进行日出力预报上具有一定优势。

表 7 不同模型四季结果对比

Tab.7 Comparison of results of different models in four seasons

季节	模型	MAPE/%	RMSE	MSE	R^2
春	LSTM	14.02	2.79	7.83	0.89
	RF	12.65	2.19	4.81	0.93
夏	LSTM	26.05	3.61	13.10	0.82
	RF	14.45	2.28	5.21	0.92
秋	LSTM	34.73	3.73	13.97	0.84
	RF	31.22	3.09	9.56	0.89
冬	LSTM	34.75	3.50	12.30	0.89
	RF	39.10	3.09	9.01	0.92

表 8 不同模型不同天气类型结果对比

Tab.8 Comparison of results of different models in different weather types

天气类型	模型	MAPE/%	RMSE	MSE	R^2
晴	LSTM	23.10	2.77	7.70	0.92
	RF	101.30	5.20	27.04	0.73
雨	LSTM	40.40	3.38	11.44	0.74
	RF	65.80	3.57	12.74	0.74
多云	LSTM	21.93	3.27	10.72	0.86
	RF	41.63	5.20	27.13	0.65
晴转	LSTM	14.58	2.61	6.85	0.93
	RF	49.54	5.66	32.09	0.67
雨转	LSTM	46.46	4.55	20.77	0.76
	RF	66.44	5.63	31.73	0.62
阴转	LSTM	34.77	4.79	23.01	0.70
	RF	46.21	4.96	24.69	0.67
多云转	LSTM	27.78	3.59	12.92	0.85
	RF	51.31	5.16	26.62	0.69

3 结 论

考虑了天气因素对光伏功率预测的影响, 基于逐步聚类分析方法建立了预测模型, 分析了不同季节和天气类型的预测结果, 结论如下:

(1) SCA 模型在春季预测效果最好, 夏季、秋季次之, 冬季最差。春季的 MAPE 比其他季节低 7.97%, MSE 低 3.32, 且预测曲线的拟合优度 R^2 为 0.95, 而冬季的误差比其他季节更大, 曲线拟合优度 R^2 为 0.91。

(2) 单一天气类型的预测结果好于复合天气类型, 其 MAPE 和 MSE 的均值比复合天气类型分别低 3.67% 和 3.82。单一天气类型中, 晴天预测拟合程度最好, 复合天气类型中, 晴转其他的拟合程度最好。

(3) 与 LSTM 和 RF 模型对比发现, SCA 模型在四季、单一天气类型和复合天气类型 3 方面的预测精度更优, 预测精度分别提高了 11.13%, 9.51% 和 8.26%。

(4) 聚类树复杂程度影响模型预测的准确度, 复合天气类型的预测后期可通过增加训练样本的数量来进一步提高预测精度。

参考文献:

[1] 崔佳豪,毕 利. 基于混合神经网络的光伏电量预测模型的研究[J]. 电力系统保护与控制,2021,49(13):142-149.
CUI Jia-hao, BI Li. Research on photovoltaic power forecasting model based on hybrid neural network[J]. Power System Protection and Control,2021,49(13):142-149.

[2] 吴 硕. 光伏发电系统功率预测方法研究综述[J]. 热能动力工程,2021,36(8):1-7.
WU Shuo. Review of power forecasting methods of photovoltaic power generation system[J]. Journal of Engineering for Thermal Energy and Power,2021,36(8):1-7.

[3] 李光明,郑丽娜,范 威,等. 基于神经网络的光伏电站出力超短期预测研究[J]. 电源技术,2021,45(8):1052-1054,1065.
LI Guang-ming, ZHENG Li-na, FAN Wei, et al. Research on ultra-short term output forecasting of PV station based on BP neural network[J]. Chinese Journal of Power Sources,2021,45(8):1052-1054,1065.

[4] 李秉晨,于惠钧,刘靖宇. 基于 Kmeans 和 CEEMD-PE-LSTM 的短期光伏发电功率预测[J]. 水电能源科学,2021,39(4):204-208.
LI Bing-chen, YU Hui-jun, LIU Jing-yu. Prediction of short-term photovoltaic power generation based on Kmeans and CEEMD-PE-LSTM[J]. Water Resources and Power,2021,39(4):204-208.

[5] 张 娜,任 强,刘广忱,等. 基于 VMD-GWO-ELMAN 的光伏功率短期预测方法[J]. 中国电力,2022,55(5):57-65.
ZHANG Na, REN Qiang, LIU Guang-chen, et al. PV power short-term forecasting method based on VMD-GWO-ELMAN[J]. Electric Power,2022,55(5):57-65.

[6] 陆 爽,徐伟明,刘维亮,等. 基于聚类再回归方法的光伏发电量短期预测[J]. 浙江电力,2020,39(7):48-54.
LU Shuang, XU Wei-ming, LIU Wei-liang, et al. Short-term forecasting of PV power generation based on clustering and later regression[J]. Zhenjiang Electric Power,2020,39(7):48-54.

[7] NAJIBI F, APOSTOLOPOULOU D, ALONSO E. Enhanced performance Gaussian process regression for probabilistic short-term solar output forecast[J]. International Journal of Electrical Power & Energy Systems,2021,130:106916.

[8] 刘如慧,姜 军,王剑峰,等. 基于 BP 神经网络的双模型光伏发电量预测[J]. 天津理工大学学报,2020,36(1):25-30.
LIU Ru-hui, JIANG Jun, WANG Jian-feng, et al. Prediction of dual model photovoltaic power generation based on BP neural network[J]. Journal of Tianjin University of Technology,2020,36(1):25-30.

[9] 于秋玲,许长清,李 珊,等. 基于模糊聚类和支持向量机的短期光伏功率预测[J]. 电力系统及其自动化学报,2016,28(12):115-118,129.
YU Qiu-ling, XU Chang-qing, LI Shan, et al. Application of fuzzy clustering algorithm and support vector machine to short-term forecasting of PV power[J]. Proceedings of the CSU-EPSCA,2016,28(12):115-118,129.

[10] ZHOU N R, ZHOU Y, GONG L H, et al. Accurate prediction of photovoltaic power output based on long short-term memory network[J]. IET Optoelectronics,2020,14(6):399-405.

[11] APRILLIA H, YANG H T, HUANG C M. Short-term photovoltaic power forecasting using a convolutional neural network - salp swarm algorithm[J]. Energies,2020,13(8):1-20.

[12] AHMAD A, JIN Y, ZHU C, et al. Support vector machine based prediction of photovoltaic module and power station parameters[J]. International Journal of Green Energy,2020(5):219-232.

[13] ANUWAR F H, ABIDIN A F, OMAR A M. Solar irradiance prediction for voltage variance analysis in the GCPV system using LSSVM[C]// 2021 IEEE International Conference in Power Engineering Application (ICPEA). IEEE,2021.

[14] 魏鹏飞,樊小朝,史瑞静,等. 基于改进麻雀搜索算法优化支持向量机的短期光伏发电功率预测[J]. 热力发电,2021,50(12):74-79.
WEI Peng-fei, FAN Xiao-chao, SHI Rui-jing, et al. Short-term photovoltaic power generation forecast based on improved sparrow search algorithm optimized support vector machine[J]. Thermal Power Generation,2021,50(12):74-79.

[15] 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 Wei-feng, 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.

[16] 李正明,高赵亮,梁彩霞. 基于 FCM 和 CG-DBN 的光伏功率短期预测[J]. 现代电力,2019,36(5):62-67.
LI Zheng-ming, GAO Zhao-liang, LIANG Cai-xia. Short-term prediction of photovoltaic power based on combination of FCM and CG-DBN[J]. Modern Electric Power,2019,36(5):62-67.

[17] 常 淳,冯 平,孙冬梅,等. 基于逐步聚类分析的水库浮游藻类生长预测[J]. 中国环境科学,2015,35(9):2805-2812.

CHANG Chun, FENG Ping, SUN Dong-mei, et al. Prediction of the alga growth in a reservoir based on the stepwise cluster analysis [J]. China Environmental Science, 2015, 35 (9) : 2805 - 2812.

[18] 张雲钦,程起泽,蒋文杰,等. 基于 EMD-PCA-LSTM 的光伏功率预测模型 [J]. 太阳能学报, 2021, 42 (9) : 62 - 69.

ZHANG Yun-qin, CHENG Qi-ze, JIANG Wen-jie, et al. Photovoltaic power prediction model based on EMD-PCA-LSTM [J]. Acta Energiae Solaris Sinica, 2021, 42 (9) : 62 - 69.

[19] 代 倩,段善旭,蔡 涛,等. 基于天气类型聚类识别的光伏系统短期无辐照度发电预测模型研究 [J]. 中国电机工程学报, 2011, 31 (34) : 28 - 35.

DAI Qian, DUAN Shan-xu, CAI Tao, et al. Short-term PV generation system forecasting model without irradiation based on weather type clustering [J]. Proceedings of the CSEE. 2011, 31 (34) : 28 - 35.

[20] 胡雪凯,时 珉,胡文平,等. 光伏电站功率预测影响因素分析及准确率提升方法研究 [J]. 河北电力技术, 2020, 39 (2) : 1 - 6, 14.

HU Xue-kai, SHI Min, HU Wen-ping, et al. Study on power forecast affecting factors of photovoltaic power plant and method of improving accuracy rate [J]. Hebei Electric Power, 2020, 39 (2) : 1 - 6, 14.

[21] 郭颖颖. 基于逐步聚类分析的中国广东省近地表温度高分辨率预测 [D]. 北京:华北电力大学, 2019.

GUO Ying-ying. SCA-based high resolution prediction of near surface temperature in the province of Guangdong [D]. Beijing: North China Electric Power University, 2019.

[22] 杜月文. 基于逐步聚类分析的山东省未来温度变化预测 [D]. 北京:华北电力大学, 2018.

DU Yue-wen. Prediction of future temperature changes in Shandong, China through a stepwise cluster analysis approach [D]. Beijing: North China Electric Power University, 2018.

[23] GB/T 22164 - 2017, 公共气象服务天气图形符号 [S].

GB/T 22164 - 2017, Public meteorological service—weather graphic symbols [S].

(刘 颖 编辑)