

光伏发电系统发电功率预测

吴攀

(国网浙江台州市路桥区供电有限公司, 浙江省 台州市 318050)

Power Forecasting of Photovoltaic Power Generation System

WU Pan

(State Grid Zhejiang Taizhou Luqiao District Power Supply Co., Ltd., Taizhou 318050, Zhejiang Province, China)

摘要: 为解决光伏发电系统发电功率在不同条件下误差较大问题, 提出光伏发电系统发电功率预测新方法。通过分析光伏发电系统结构, 研究光伏发电系统发电功率影响因素; 以季节和天气类型作为历史样本选取样本源, 针对气象部门提供的预测日分时气象数据在历史数据库中寻找相似数据点作为历史样本; 依据历史样本构建离线参数寻优数据总集, 使用核函数极限学习机算法构建发电系统发电功率预测模型, 通过粒子群算法优化模型参数。实验结果表明: 所提方法在不同条件下预测太阳能光伏发电系统发电功率的平均绝对百分比误差分别为 1.47% 和 6.39%, 光伏组件在综合异常条件下发电功率预测误差相对变化均低于 1%, 证明所提方法满足实际预测要求。

关键词: 光伏; 功率预测; 粒子群算法; 核函数极限学习机

ABSTRACT: In order to solve the problem of large errors in the power generation of solar photovoltaic system under different conditions, a new method for power generation prediction of solar photovoltaic system was proposed. By analyzing the structure of solar photovoltaic power generation system, the influencing factors of solar photovoltaic power generation system were studied. Seasons and weather types were used as historical samples to select sample sources, and similar data points were searched in the historical database for predicting daily time-sharing meteorological data provided by meteorological departments as historical samples. The off-line parameter optimization data set was constructed with historical samples, and the generation power prediction model of power generation system was constructed with the kernel function limit learning machine algorithm, and the model parameters were optimized by the particle swarm optimization algorithm. The experimental results show that the mean absolute percent errors of the proposed method are 1.47% and 6.39% respectively under different conditions,

and the relative variation of the power prediction errors of solar photovoltaic modules is less than 1% under comprehensive abnormal conditions. It is proved that the proposed method meets the actual prediction requirements.

KEY WORDS: photovoltaic; power forecasting; particle swarm optimization; kernel function limit learning machine

0 引言

太阳能是一种清洁的可再生能源, 光伏发电是太阳能利用的主要方式之一。光伏发电能够减轻化石能源使用过程中产生的空气、水污染等环境问题^[1]。自 20 世纪 80 年代起, 光伏发电量占不同国家总发电量的比例持续提升, 世界主要发达国家均研究光伏发电技术, 以提升光伏发电能力。光伏发电系统受太阳辐射强度与气象条件影响较大^[2-7], 导致系统发电功率存在较高随机性、波动性以及间歇性, 这些均对电网稳定运行产生不利影响, 因此预测光伏发电功率有重大意义。

文献[8]提出基于改进相似样本选取与特征提取的光伏发电功率预测方法。该方法通过对样本的野值剔除和补正, 获取不同时间点气象因子的干扰权重, 再对相似样本进行特征提取, 引入广义回归神经网络算法对一日发电功率进行短期预测。该方法可有效提升预测的性能, 但在进行相似样本特征提取时易受到外界因素影响, 提取的准确性较低。文献[9]提出基于特征筛选与 ANFIS-PSO 的光伏发电功率预测方法。通过分析随机森林中增益状况, 筛选影响发电系统电功率的参数, 结合自适应神经模糊推理算法训练输入

数据,引入粒子群算法优化 ANFIS 模型,建立基于离线训练和在线预测的 ANFIS-PSO 光伏发电功率预测模型。该方法可以有效提高光伏发电功率预测的工作效率,模拟结果准确性较好,但未过多考虑现实因素的影响,需要进一步完善才可利用到实际中。文献[10]提出基于二次自适应支持向量机的光伏输出功率预测。该方法针对传统相似度函数在聚类过程中存在的问题,提出改进灰色-欧氏距离相似度函数,并将历史样本日模糊聚类分为若干类。该方法可有效对光伏数据进行处理,处理效果较好,但未过多考虑外界条件对预测模型的限制,存在预测效率及准确率较低的问题。

针对以上研究的不足,本文提出基于相似日的光伏发电功率预测方法,在不同环境条件下均能准确预测光伏发电系统的发电功率。

1 光伏发电系统发电功率预测方法

1.1 光伏发电系统结构

光伏发电系统由直流子系统、交流子系统以及升压并网子系统共同组成,其系统结构如图 1 所示。

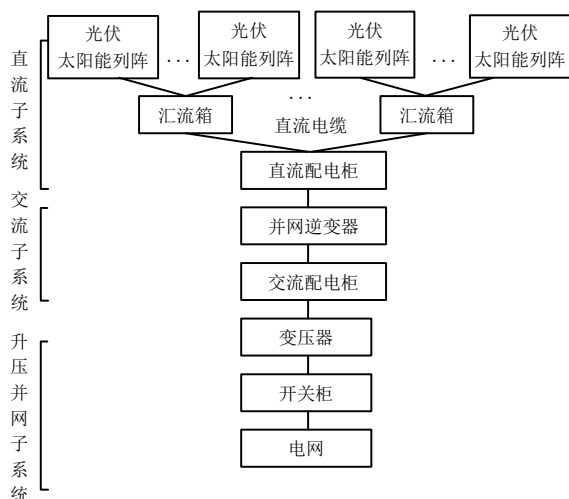


图 1 光伏发电系统结构图

Fig. 1 Photovoltaic generation system architecture

直流子系统包括 2 级汇流过程:一级汇流指直流电缆将光伏电池产生的直流电传输至汇流箱中;二级汇流指固定数量的汇流箱并入直流配电柜。直流子系统将直流电传输至交流子系统内,经并网逆变器转变成低压交流电;交流电进入升

压并网子系统内,经变压器升压后并入电网。

1.2 光伏发电系统发电功率影响因素

光伏发电系统可将太阳能转换为电能,但太阳能转换过程受外界环境因素影响较为严重。

单位面积光伏电池输出功率为

$$P_s = \eta SI[1 - 0.005(T - 25)] \quad (1)$$

式中: η 、 S 、 I 和 T 分别表示额定转换效率、光伏阵列面积、光伏组件倾斜面上太阳辐照强度和组件温度。根据上述各参数得到影响系统光电转换的各因素。太阳辐照强度受太阳辐照度和光伏组件清洁度影响^[11],太阳辐照度受雨量、云量、空气湿度等因素影响,而光伏组件清洁度受雨量、雾霾指数、清洗频率等因素影响。组件温度受气温、风速、湿度与积灰等因素影响^[12-13]。

光伏发电系统实际运行过程中,影响太阳能光电转换的因素较多,且各因素间存在较为复杂的关联,考虑全部参数预测系统发电功率较为困难。光伏电站历史数据中已含太阳辐照度、光伏组件清洁度及组件温度等信息样本,依据这些样本可构建完整历史数据库。环境湿度对太阳辐照度、组件清洁度及温度都有一定影响^[14],以季节和天气类型作为历史样本选取样本源,以太阳辐照度、环境湿度和环境温度作为历史样本选择依据,选取相似度较高的历史样本构建发电功率预测模型。

1.3 历史样本选取

1.3.1 相似度计算

根据整点气象特征信息确定历史样本相似点,光伏发电系统发电功率影响因素为

$$\mathbf{Y} = [Y_1 \ Y_2 \ Y_3] \quad (2)$$

式中 Y_1 、 Y_2 和 Y_3 分别为太阳辐照度、环境温度和湿度。

预测整点与历史整点的气象特征向量分别用 \mathbf{Y}_P 和 \mathbf{Y}_N 表示,则:

$$\begin{cases} \mathbf{Y}_P = [Y_{P(1)} \ Y_{P(2)} \ Y_{P(3)}]^T \\ \mathbf{Y}_N = [Y_{N(1)} \ Y_{N(2)} \ Y_{N(3)}]^T \end{cases} \quad (3)$$

第 n 个历史整点在第 i 个气象因素上的差值 $Z_n(i)$ 为

$$Z_n(i) = |Y_{N(i)} - Y_{P(i)}|, \quad i=1,2,3 \quad (4)$$

差值归一化处理式(4), 得到

$$Z'_n(i) = \frac{Z_n(i) - \min_i Z_n(i)}{\max_i Z_n(i) - \min_i Z_n(i)} \quad (5)$$

Y_P 和 Y_N 在第 i 因素的关联系数 $\varepsilon_N(i)$ 为

$$\varepsilon_N(i) = \frac{\min_N \min_i Z'_n(i) - \rho \max_N \max_i Z'_n(i)}{Z_n(i) + \rho \max_N \max_i Z'_n(i)} \quad (6)$$

式中 ρ 表示分辨系数, 通常取值为 0.5。

汇总不同气象特征的关联系数, 确定总体 Y_P 和 Y_N 的相似度, 如式(7)所示:

$$F_N = \beta^{\text{int}(t/7)} \times [0.7 \times \varepsilon_N(1) + 0.2 \times \varepsilon_N(2) + 0.1 \times \varepsilon_N(3)] \quad (7)$$

式中: β 为缩减系数, 通常取值 0.95 左右; t 为历史数据与预测数据相距天数; 0.7、0.2 和 0.1 分别为太阳辐射度加权值、环境温度加权值和环境湿度加权值。

1.3.2 历史整点重组

排除显著异常数据, 依照四季与晴天、阴天、雨天 3 种天气类型将历史数据分为 12 个子类型^[15], 将其作为选取预测整点相似点的数据集。

在季节与天气类型一致的条件下, 以同预测日最相近的历史数据点为起始点, 反向运算历史整点气象特征信息与预测日整点的一致度^[16]; 以一致度最高的 30 个整点作为预测整点的相似点, 根据时间顺序重新成为新的 30 个相似日, 作为历史样本。

1.4 发电功率预测模型

1.4.1 预测模型的离线参数寻优

以历史样本选取过程获取的 30 个相似日构建离线参数寻优历史数据总集, 利用式(8)构建所需的训练样本与验证样本^[17]:

$$\begin{cases} V \cup M = G \\ V = G_i, M = G_j, j = 1, 2, \dots, 10 \text{ \& } j \neq i \end{cases} \quad (8)$$

式中: G 、 V 和 M 分别表示历史数据总集、验证样本集以及训练样本集。 V 和 M 的表达式如下:

$$\begin{cases} P_i = \{x_i | t_i, A_i\} \in V, i = 1, \dots, v \\ P_j = \{x_j | t_j, A_j\} \in M, j = 1, \dots, 10 \end{cases} \quad (9)$$

式中 x_i 表示发电功率实际值。

确定不同训练样本同验证样本集的平均相似度为

$$S_j = \frac{1}{v} \sum_{i=1}^v \|\{t_j, A_j\} - \{t_i, A_i\}\| \cdot W, \quad j = 1, \dots, 10 \quad (10)$$

式中: S_j 和 W 分别表示第 j 个训练样本与测试样本集的平均相似度和样本属性的权重向量^[18]。

以比例系数为依据选取训练样本集 M 如下:

$$\begin{cases} M = P_j, j = 1, \dots, m \times \alpha \\ \max(S_j) < \min(S_g), g > m \times \alpha \end{cases} \quad (11)$$

式中: α 为比例系数; m 和 S_g 分别表示原始训练样本集的样本总数和选取训练样本集过程中清除的训练样本平均相似度。

根据属性值是否完全一致判断选取的训练样本集 M 内冗余属性 f 为

$$\begin{cases} f_1 = f_j, j = 2, \dots, m \times \alpha \\ f_j \in \{t_j, A_j\} \in M \end{cases} \quad (12)$$

清除样本集 M 同 V 内的冗余属性, 在保障算法有效性的基础上, 降低计算维度。

采用核函数极限学习机(ELM_k)算法构建发电功率预测模型 F , 利用样本集 V 验证模型 F :

$$\begin{cases} F = \text{ELM_k}(M, C, \gamma) \\ \hat{x}_i = F(\{t_i, A_i\}), \{t_i, A_i\} \in V \end{cases} \quad (13)$$

在离线参数寻优阶段将平均绝对百分比误差(mean absolute percent error, MAPE)作为预测精度的评价函数^[19]:

$$\begin{cases} E = \frac{100\%}{v} \sum_{i=1}^v \left\| \frac{x_i - \hat{x}_i}{x_i} \right\| \\ x_i > 10\% \times C_{ap} \end{cases} \quad (14)$$

式中: E 表示平均绝对百分比误差; x_i 、 \hat{x}_i 和 C_{ap} 分别表示发电功率实际值、发电功率预测值和预测光伏阵列安装容量。

通过粒子群算法实施参数寻优:

$$(C^{k+1}, \gamma^{k+1}, W^{k+1}, \alpha^{k+1}) = \text{PSO}(E^k, C^k, \gamma^k, W^k, \alpha^k) \quad (15)$$

式中: PSO 为粒子群优化算法; W 和 α 取值范围分别为 $[0, 1]$ 和 $[0.1\%, 10\%]$, 分别表示属性的重要程度和控制选取样本占总样本的比例。 C 和 γ 的表达式为

$$\begin{cases} C = 2^{Z_1} \\ \gamma = 2^{Z_2} \end{cases} \quad (16)$$

式中: Z_1 、 Z_2 均为粒子群算法的实际寻优参数, 两者浮点数取值范围为 $[-5, 25]$ 。

粒子群算法的更新函数为

$$\begin{cases} p_{k+1}^i = p_k^i + v_{k+1}^i \cdot \Delta t \\ v_{k+1}^i = wv_k^i + c_1 r_1 \frac{(q_k^i - p_k^i)}{\Delta t} + c_2 r_2 \frac{(q_k^g - p_k^i)}{\Delta t} \end{cases} \quad (17)$$

式中: p_k^i 和 v_k^i 分别表示第 i 个粒子在第 k 次迭代时所处位置和第 k 次迭代更新前的粒子速度; v_{k+1}^i 和 w 分别表示第 k 次迭代更新后的粒子速度和粒子沿原速度方向移动的趋势; c_1 和 c_2 分别表示粒子的自我信任系数和群体信任系数; r_1 和 r_2 均为随机数, 取值范围为 $[0, 1]$; q_k^i 和 q_k^g 分别表示 k 次迭代时第 i 个粒子的历史最优位置和全部粒子的历史最优位置; 因为需同 c_1 和 c_2 相除, 所以 Δt 表示的迭代时间步长不具备参数实意。设 200 和 40 分别为粒子群算法最大粒子群代数和粒子群大小, 在 50 代预测精度提升持续低于 1% 的条件下, 参数寻优过程结束。由此得到最优参数为 C_b 、 γ_b 、 W_b 和 α_b 。

1.4.2 在线自动预测模型

用 T 和 $\{T, A_{T-1}\}$ 分别描述待预测时刻及其样本属性, $T-1$ 为当前运行时刻, 由此得到在线历史样本:

$$S_t = \{x_t | t, A_{t-1}\} \in M^o, \quad t = 1, \dots, T-1 \quad (18)$$

式中: M^o 与 $t=1$ 分别表示在线历史样本总集和在线采样记录初始时刻。基于式(18)得到在线选取样本集 M^o :

$$\begin{cases} S_t = \|\{t_t, A_t\} - \{t_T, A_T\}\| \cdot W_b, \quad t = 1, \dots, T-1 \\ M^o = P_t, \quad t = 1, \dots, (T-1) \times \alpha_b \\ \max(S_t) < \min(S_g) > (T-1) \times \alpha_b \end{cases} \quad (19)$$

构建在线发电功率自动预测模型, 预测 T 时刻发电功率为

$$\begin{cases} F^o = \text{ELM_}k(M^o, C_b, \gamma_b) \\ \hat{x}_T = F^o(\{t_T, A_T\}) \end{cases} \quad (20)$$

式中: F^o 与 \hat{x}_T 分别表示在线发电功率自动预测模型和 T 时刻发电功率预测值。预测 $T+1$ 时刻发电功率时, 需在 T 时刻发电功率预测值基础上实施更新计算^[20]。

2 实例验证

为验证本文提出的基于光伏太阳能的分布式发电功率自动预测方法的预测性能, 以某市分布式光伏电站为研究实例, 分别研究其在晴天、阴天(阴转多云)和光伏组件综合异常条件下发电功率的预测值与实际值。

2.1 晴天条件

研究对象在晴天条件下发电功率预测值与实际值如图 2 所示。

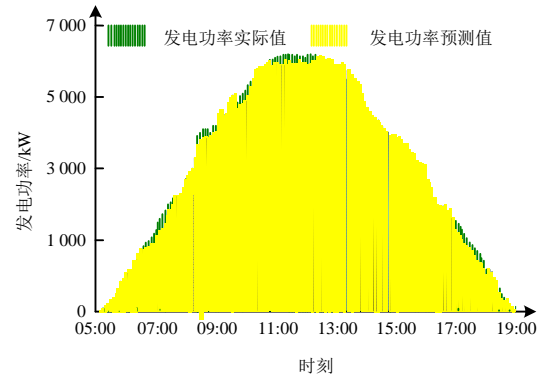


图 2 晴天条件下发电功率预测值与实际值

Fig. 2 Predicted value and actual value of generating power on sunny days

计算图 2 中不同时刻发电功率预测值与实际值的平均绝对百分比误差, 结果如表 1 所示。

表 1 晴天条件下发电功率预测值与实际值 MAPE
Tab. 1 MAPE between predicted value and actual value of generating power on sunny days

时刻	预测发电功率/kW	实际发电功率/kW	MAPE/%
05:00	728.54	734.92	0.87
06:00	1 446.28	1 395.74	3.62
07:00	2 216.71	2 219.66	0.13
08:00	4 105.6	3 962.53	3.61
09:00	5 381.92	5 306.7	1.42
10:00	5 840.62	5 863.71	0.39
11:00	6 135.33	6 072.94	1.03
12:00	5 762.78	5 684.28	1.38
13:00	4 618.29	4 640.37	0.48
14:00	3 876.92	3 804.68	1.90
15:00	2 576.08	2 545.36	1.21
16:00	1 506.44	1 451.62	3.78
17:00	696.84	691.28	0.80
18:00	173.69	172.81	0.51
19:00	728.54	734.92	0.87

根据图 2 和表 1 可知, 采用本文方法预测晴天条件下基于光伏太阳能的分布式发电站各时刻

发电功率效果较好, 平均绝对百分比误差为1.47%, 完全满足实际应用需求。其中几次较大的预测误差分别出现在清晨和傍晚, 主要是因为此时环境温度无法实际体现光伏组件温度。

2.2 阴天(阴转多云)条件

研究对象在阴天(阴转多云)条件下发电功率预测值与实际值如图3所示, 不同时刻发电功率预测值与实际值的平均绝对百分比误差见表2。

分析图3和表2可知, 采用本文方法预测阴天(阴转多云)条件下基于光伏太阳能的分布式发电站各时刻发电功率得到的平均绝对百分比误差为6.39%, 与晴天条件下相比提升了4.92%, 同样满足实际应用需求。阴天(阴转多云)条件下发电功率预测平均绝对百分比误差高于晴天的主要原因是: 天气变化导致环境温度与湿度等均发生

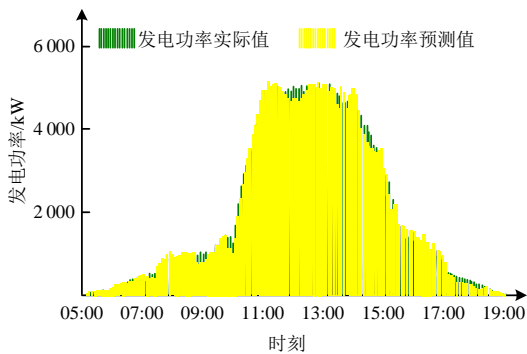


图3 阴天条件下发电功率预测值与实际值
Fig. 3 Predicted value and actual value of generating power on cloudy days

表2 阴天条件下发电功率预测值与实际值 MAPE
Tab. 2 MAPE between predicted value and actual value of generating power on cloudy days

时刻	预测发电功率/kW	实际发电功率/kW	MAPE/%
05:00	0	0	0
06:00	189.37	188.25	0.60
07:00	506.38	472.96	7.07
08:00	1 052.41	1 009.66	4.23
09:00	856.37	1 084.29	21.02
10:00	1 356.81	1 421.36	4.54
11:00	5 166.29	5 008.84	3.14
12:00	4 817.50	5 147.20	6.40
13:00	5 120.94	4 992.71	2.56
14:00	5 091.15	4 810.37	5.84
15:00	3 126.38	2 958.86	5.66
16:00	1 753.36	1 702.46	2.99
17:00	1 210.22	1 260.54	3.99
18:00	260.04	342.73	24.13
19:00	96.30	92.85	3.72

改变, 对光伏组件影响较显著。

2.3 光伏组件综合异常条件

光伏发电系统在工作工程中, 存在光伏组件覆尘或逆变器损坏等现象, 在此条件下, 系统发电功率预测误差如表3所示, 其中, NRMSE 为标准均方根误差(normalized root mean square error)。

表3 光伏组件综合异常条件下的预测误差

Tab. 3 Errors of photovoltaic modules under comprehensive abnormal conditions

时段	MAPE/%	MAPE 相对变化/%	NRMSE/%	NRMSE 相对变化/%
清晨	14.96	0.44	5.25	0.39
晌午	12.08	0.32	3.96	0.30
傍晚	16.99	0.35	7.75	0.55

由表3可知, 采用本文方法预测光伏组件综合异常条件下, 在清晨、晌午和傍晚的发电功率预测误差的相对变化均低于1%, 实验结果表明本文方法预测结果在光伏太阳能组件综合异常条件下同样具备较低的预测误差。

3 结论

光伏发电系统发电功率预测严重依赖气象信息, 为此提出光伏发电功率自动预测方法, 在全面分析影响光伏组件发电功率因素的基础上, 将历史数据重新组合成为新的相似日作为历史样本, 采用核函数极限学习机构建发电功率在线自动预测模型, 实现光伏发电系统发电功率预测。所提方法在晴天和阴天条件下预测光伏发电系统发电功率的平均绝对百分比误差分别为1.47%和6.39%, 在光伏组件综合异常条件下发电功率预测误差相对变化均低于1%。实验结果表明所提方法可在不同环境条件下预测光伏发电系统发电功率, 满足实际预测要求。

参考文献

[1] 王以笑, 崔丽艳, 雷振锋, 等. 分布式光伏电站区域智能调控系统的研究[J]. 电力系统保护与控制, 2016, 44(4): 118-122.
[2] Takahashi A, Yamagata A, Imai J, et al. Decomposition

- of fluctuating photovoltaic generation power in frequency bands and analysis of chaotic properties [J]. *Electrical Engineering in Japan*, 2017, 201(4): 26-33.
- [3] 武永鑫, 王虎, 李世杰, 等. 灰尘沉积对光伏组件发电性能的影响[J]. *分布式能源*, 2017, 2(5): 55-59.
- [4] 石磊, 侯学良. 并网光伏电站发电效率快速估算实用模型[J]. *电网与清洁能源*, 2018, 34(2): 161-166.
- [5] 于秩彬, 王春芳, 周钊正, 等. 青岛地区四季天气对光伏发电量的影响[J]. *广东电力*, 2019, 32(6): 48-54.
- [6] 严华江, 章坚民, 胡瑛俊, 等. 考虑空间相关性的分布式光伏发电出力预测及误差评价指标研究[J]. *浙江电力*, 2020, 39(3): 54-60.
- [7] 史洁, 刘晓飞. 新能源功率预测算法优化研究[J]. *发电技术*, 2019, 40(1): 78-82.
- [8] 陈世游, 左为恒. 基于改进相似样本选取与特征提取的光伏发电功率预测方法[J]. *计算机测量与控制*, 2019, 27(2): 165-169.
- [9] 时珉, 王强, 王铁强, 等. 基于特征筛选与 ANFIS-PSO 的分布式光伏发电功率预测方法研究[J]. *可再生能源*, 2019, 37(7): 989-994.
- [10] 殷豪, 陈云龙, 孟安波, 等. 基于二次自适应支持向量机的光伏输出功率预测[J]. *太阳能学报*, 2019, 40(7): 1866-1873.
- [11] 张玉, 黄睿, 张振涛, 等. 基于克里格模型的光伏发电量预测[J]. *热力发电*, 2017, 46(4): 27-32.
- [12] 徐敏姣, 徐青山, 袁晓冬. 基于改进 EMD 及 Elman 算法的短期光伏功率预测研究[J]. *现代电力*, 2016, 33(3): 8-13.
- [13] Li Q, Sun Y, Yu Y, et al. Short-term photovoltaic power forecasting for photovoltaic power station based on EWT-KMPMR[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2017, 33(20): 265-273.
- [14] 侯松宝, 王侃宏, 石凯波, 等. 基于相似日和主成分分析的光伏发电系统短期出力预测[J]. *可再生能源*, 2018, 36(1): 15-21.
- [15] 王昕, 黄柯, 郑益慧, 等. 基于萤火虫算法广义回归神经网络的光伏发电功率组合预测[J]. *电网技术*, 2017, 41(2): 455-461.
- [16] 王昕, 黄柯, 郑益慧, 等. 基于 PNN/PCA/SS-SVR 的光伏发电功率短期预测方法[J]. *电力系统自动化*, 2016, 40(17): 156-162.
- [17] 黎嘉明, 艾小猛, 文劲宇, 等. 光伏发电功率持续时间特性的概率分布定量分析[J]. *电力系统自动化*, 2017, 41(6): 30-36.
- [18] 王冰, 卢舟鑫. 一种基于多时段综合相似日的光伏发电功率预测方法[J]. *电源技术*, 2017, 41(1): 103-106.
- [19] 温润, 谭丽. 结合 HS 算法与 ESN 算法的光伏发电短期出力预测[J]. *计算机科学*, 2017, 44(6): 226-231.
- [20] Simon C, Michiorri A, Kariniotakis G. Optimal offer of automatic frequency restoration reserve from a combined PV/wind virtual power plant[J]. *IEEE Transactions on Power Systems*, 2018, 33(6): 6155-6170.
-
- 收稿日期:** 2019-11-13.
- 作者简介:**
-
- 吴攀(1982), 男, 高级工程师, 研究方向为电网调度、电网运行、配网设计改造, 627526761@qq.com。
- 吴攀
- (责任编辑 辛培裕)