

Short Term Prediction of Photovoltaic Generation Output Based on Similar Days

Cui Hanjun*, Yao Lixiao

Institute of Water Resources and Hydro-Electric Engineering, Xi'an University of Technology, Xi'an, China

Email address:

344403813@qq.com (Cui Hanjun), ylx@xaut.edu.cn (Yao Lixiao)

*Corresponding author

To cite this article:

Cui Hanjun, Yao Lixiao. Short Term Prediction of Photovoltaic Generation Output Based on Similar Days. *Science Discovery*. Vol. 4, No. 6, 2016, pp. 380-386. doi: 10.11648/j.sd.20160406.16

Received: November 3, 2016; Accepted: November 22, 2016; Published: December 1, 2016

Abstract: Based on the analysis of the main weather factors that affect the output of the PV generation, a feedback based neural network prediction model based on similar days is proposed. From the historical data of the weather, the weather similar days are selected, the Elman neural network prediction model is established to predict the output power of the photovoltaic power generation combined with the similar days of the power generation and the similar days and the weather data.

Keywords: Photovoltaic Power Generation, Power Prediction, Neural Network

基于相似日的光伏发电出力短期预测

崔寒珺*, 姚李孝

水利水电学院, 西安理工大学, 西安, 中国

邮箱

344403813@qq.com (崔寒珺), ylx@xaut.edu.cn (姚李孝)

摘要: 在分析影响光伏发电出力的主要天气因素下, 提出了一种基于相似日的反馈型神经网络预测模型。从天气的历史数据中选择出天气相似日, 结合相似日的发电功率和相似日与预测日的天气数据建立Elman神经网络预测模型, 来预测光伏发电的出力。

关键词: 光伏发电, 功率预测, 神经网络

1. 引言

在可持续发展的战略的指导下, 在传统能源消耗殆尽的威胁下, 新能源发电上网电量占有越来越大的比例[1]。光伏发电是新能源发电的典型代表。光伏发电出力受自然环境的影响较大, 光伏电池所处的自然环境中的光照和温度等气象因素都会影响到光伏电池的出力。当一个容量较大的光伏电站接入传统大电网后, 由自然环境变化带来的光伏出力的波动将影响到传统大电网的安全性和稳定

性, 所以要光伏发电出力预测就显的至关重要[2-5]。如果能较准确预测传统大电网接入的光伏电站的出力, 就可以根据光伏电站的出力来调整其他电站的出力, 不仅能为调度提供依据, 还可以为各种电站出力的时空互补提供依据。

光伏发电出力的预测方法主要可分为两类: 间接法和直接法[6]。间接预测法是先利用光伏电站的历史气象观测数据预测太阳辐照度, 然后采用神经网络或工程计算公式预测电站的输出功率或发电量; 而直接法是利用光伏电

站发电量的历史数据及天气预报数据直接预测光伏系统或阵列的输出功率或发电量。近年来针对以上问题,在科学研究和实际生产中,国内外的研究学者在光伏发电出力预测方面取得了许多成果。文献[7-10]建立了BP神经网络光伏发电预报模型来预测光伏发电的出力。其中,文献[7-8]将光伏发电预测模型分为四个子模型,分别建立了春季、夏季、秋季和冬季的模型,以天气预报数据和预测日前一日的光伏发电出力数据作为BP神经网络的输入变量,这种方法依赖于预测日和前一日的日类型是否连续,对与日类型不连续的天气类型预测精度不高;文献[9-10]重点关注对天气类型的分类,对不同天气类型采用了不同的BP神经网络,相较于前面的方法有一定的改进,但是又增加的预测模型的数量;文献[11]中结合大量的实验数据,采用Elman神经网络来预测光伏发电出力,验证了在光伏出力预测领域Elman神经网络相比于BP神经网络具有计算速度更快、准确性更高的优点。Elman神经网络是反馈神经网络,其联想记忆功能更好,并且稳定性比较好,对于时间序列预测问题准确性BP神经网络好。文献[12]将极端学习机法和相似日法结合使用,建立了预测模型。本文综合相似日的方法和Elman神经网络方法和进行光伏出力预测。首先,通过后一日的天气预报从历史气象数据中选取天气的相似日,结合相似日的发电出力数据和相似日与预测日的天气数据建立Elman神经网络预测模型来进行光伏发电出力预测。

2. 光伏出力分析

由于光伏电池的并联电容对光伏电池的动态特性影响很小,所以在分析时通常将其忽略。光伏电池输出电压 U_{pv} 与输出电流 I_{pv} 的关系可用下式进行描述:

$$I_{pv} = I_{\lambda} - I_0 e^{\frac{q(U_{pv} + I_{pv}R_p)}{AKT}} - \frac{U_{pv} + I_{pv}R_p}{R_p} \quad (1)$$

式中: A为二极管理想因子, $A=1 \sim 2$; K为玻尔兹曼常数, $K=1.38 \times 10^{-23} \text{ J/K}$, T为绝对温度(K); q为电子电荷, $q=1.6 \times 10^{-19}$; λ 为光照强度(kW/m^2); I_0 为反向饱和电流(A); I_{λ} 为光生电流(A)。

式(1)是光伏电池最基本、在理论分析中被广泛应用的、在实际生产中被广泛采取的、基于物理模型的数学表达式。但是式(1)中的 I_{λ} 、 I_0 、 R_s 、 R_p 、A等技术参数并不是光伏电池厂商提供给用户的技术参数,而且这些技术参数确定起来相对困难,在实际研究和应用中并不方便。

以式(1)为基础,并假设以下两点近似:

①将 $\frac{U_{pv} + I_{pv}R_p}{R_p}$ 项忽略;

②假定 $I_1 = I_{sc}$, 并假定:

(1)开路状态下: $I_{pv}=0$; $U_{pv}=U_{oc}$;

(2)最大功率下: $I_{pv}=I_m$; $U_{pv}=U_m$;

工程实际中应用的光伏电池数学模型为:

$$I_{pv} = I_{sc} \left[1 - C_1 \left(e^{\frac{U_{pv}}{C_2 U_{oc}}} - 1 \right) \right] \quad (2)$$

式中:

$$C_1 = \left(1 - \frac{I_m}{I_{sc}} \right) e^{-\frac{U_m}{C_2 U_{oc}}} \quad (3)$$

$$C_2 = \left(\frac{U_m}{U_{oc}} - 1 \right) \frac{1}{\ln \left(1 - \frac{I_m}{I_{sc}} \right)} \quad (4)$$

因此,该工程用光伏阵列的模型只需要输入供应商提供的几个常用的技术参数 I_{sc} 、 U_{oc} 、 I_m 、 U_m , 就可以根据式(3)、式(4)得出 C_1 和 C_2 。式(2)决定最后的太阳电池的I-U特性曲线。

2.1. 日类型对光伏出力的影响

常见的日类型分类为:晴天、阴天、雨天等。不同的日类型对光伏电站的出力有影响,某光伏电站在晴天、阴天、雨天的光伏电站出力对比如图1所示。




图1 不同日类型下某光伏电站出力对比。

2.2. 季节对光伏出力的影响

我国大部分国土属于温带气候,四季交替循环,与人类在一年四季的体表感受相类似,一年四季对光伏电站的影响是显而易见的,某光伏电站在春季、夏季、秋季和冬季的光伏电站出力对比如图2所示。




图2 不同季节下某光伏电站出力对比。

2. 3. 光照强度对光伏出力的影响

由光伏发电出力计算公式可知, 不同光照下会影响光伏发电出力, 由于光伏电站拥有最大功率跟踪环节, 在光

伏出力限制范围内, 光伏出力与光照量同增同减。某光伏电站在晴朗夏季光伏出力与光照的关系如图3所示。




图3 不同光照下某光伏电站出力曲线。

2. 4. 温度对光伏出力的影响

前面已经讨论了光照、季节、日类型对光伏出力的影响, 在上述条件近似相同的前提下, 不同温度下, 光伏出力也不同。从而温度也是光伏出力的影响因子。如图4所示。




图4 不同温度下某光伏电站出力对比。

由上述分析可知, 光伏发电系统的输出功率受诸多因素的影响, 在本文中通过对发电出力数据的处理, 将这些影响因素映射为相似日指数作为预测模型的输入。

3. 天气类型

描述天气状态可以有多种不同的方式, 例如晴朗的程度、温度的高低、湿度的大小、降水的多寡、风力的强弱、空气的质量等。天气类型作为描述大气物理状态的标签, 综合了各种气象因素在时间和空间上的分布, 能够比较全面地表征天气状态的特点。中国气象局制订的国家标准 GB/T22164——2008将天气状态分为33种不同的类型。但是考虑到光伏电站应该建设到日照时间较长和日照强度较大的地区, 应该重点考虑晴朗天气的光伏发电出力预测, 而较少考虑阴雨天气的光伏发电出力预测。基于以上原因, 将日类型分为晴朗天气、晴天偶尔多云、多云偶尔晴天、多云天气、阴天、雨天等6种典型天气类型。

4. 光伏发电功率预报模型

本文首先基于一个自然年的春、夏、秋和冬的不同天气情况来分别建立日特征向量, 然后根据相似日原理, 利用前面建立的日特征向量来选取对应的相似日, 其次结合所选取的相似日的发电功率数据和相似日与预测日的气象数据建立Elman神经网络预测模型, 并且对Elman神经网络进行训练, 来形成不同季节下的光伏发电出力预测模型, 最后将四个季节得到的光伏发电出力预测模型整合成一个自然年的光伏发电出力短期预测模型。

4. 1. 相似日原理

在已有的文献中, 发电量的预测模型将预测日前一段时间的历史发电数据作为输入变量。这种方法在预测天气情况基本不变的晴天的光伏发电出力有着较好的准确性, 但是当日类型不连续或者出现多云天气、雨雪天气等复杂天气情况时, 预测将失去其原有的准确性。

针对以上这些不足, 本文将一年按照一年4个季度分别建立子模型, 将气象因素和各个子模型的日特征向量联系起来, 包括气温、辐照时间和日类型等指数, 设日特性向量为:

$$X_i = [i, T_l, T_h, \bar{T}, t, e] \quad (5)$$

式中: i 为日期序号, T_l 为最低温度K, T_h 为最高温度K, \bar{T} 为平均温度K, t 为日照时间h, e 为日类型指数 (日类型分为晴朗天气、晴天偶尔多云、多云偶尔晴天、多云天气、阴天、雨天, 分别对应1~6)。

天气预报提供的气象信息往往会比较粗略, 只能判断出大致粗略的天气类型, 故本文在做日类型指数训练映射时, 在天气预报提供的信息前提下, 根据欧式距离表达式对天气类型进一步归类, 如式 (6)。的欧式距离是一种绝对的距离定义, 表示在 m 维空间中两个点之间的绝对距离。拓展使用欧式距离定义来判断不同天气预报信息之间的相似度差异, 对天气类型进行区分归类。

$$\begin{cases} D_{ij} = \sqrt{\sum_{k=1}^8 (x_{ki} - x_{kj})^2} \\ O_{ij} = 1 - \alpha D_{ij} \end{cases} \quad (6)$$

式中, k 为日特征向量的元素序号, x_k 为日特征向量的第 k 个元素。一般情况下取归一化因子 $\alpha = \frac{1}{\max(D_{ij})}$ 。因此, 日特征相似度 O_{ij} 越高, 表示两天之间的气象参数等因素越相似。

4.2. 预测模型的输入层节点的确定

在预测模型中, 基于相似日的7:00~18:00每个整点发电时间序列作为预测模型的12个输入变量; 预测日和相似日的平均温度作为预测模型其中的2个输入量; 预测日和相似日的日类型指数为模型的另外2个输入量, 预测模型输入变量确定为有16个。

4.3. 预测模型的输出层节点的确定

预测模型所求得的输出是后一天的12个小时整点时间点的光伏发电出力序列, 所以输出层的节点数确定为12个。

4.4. 预测模型的隐含层节点的确定

隐含层单元的数目与问题的要求、输入和输出单元的数目有着直接的关系, 若隐含层数目太少, 网络所得到的数据量太少; 若隐含层数目过多, 会增加训练的繁琐程度, 导致训练的时间大大增加, 本文通过经验公式 (7), 并进行多次试验, 隐含层节点数确定为14个。

$$n_y = \sqrt{n + m} + a \quad (7)$$

式中: n_y 为隐含层单元数; n 为输入单元数; m 为输出单元数; a 为[1, 10]之间的常数。

4.5. Elman神经网络模型结构

本文采用的Elman神经网络预测模型拓扑结构图如图5所示, x 向量为神经网络预测模型输入向量, z 向量为神经网络预测模型隐含层的输出向量, y 向量为神经网络预测模型输出层输出向量。 a_1 、 b_1 和 a_2 、 b_2 分别为神经网络预测模型隐含层和输出层的权值和阈值, a_3 为神经网络预测模型承接层权值, D 为神经网络预测模型反馈支路的延迟单元, $\log\text{sig}$ 为激活函数, n_1 和 n_2 分别为激活函数的输入向量。




图5 Elman神经网络预测模型拓扑结构图。

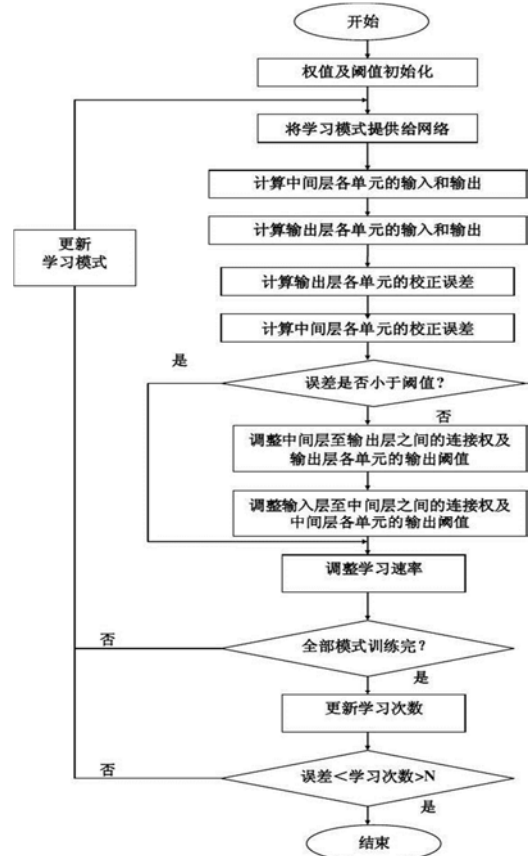


图6 Elman神经网络预测模型流程图。

5. 预报模型训练和评估

对建立好的Elman神经网络需要反复多次的训练, 而选取的样本的质量和数量影响着整个Elman神经网络的预测结果的精度和速度。

光伏发电出力并非只受到前述日类型、季节、光照和温度几种主要因素的影响, 由于光伏电站处于自然环境中, 光伏发电出力受到了更多的自然界的影响, 比如海拔、气压、湿度和空气质量等。所以仅考虑影响光伏发电的主要因素而忽略一些次要的影响因素来预测光伏发电出力是不可行的。

5.1. 实际影响光伏发电出力的因素

5.1.1. 温度系数

由于光伏电池组件的温度无法完全跟踪环境温度, 导致光伏电站的实际出力和环境温度下光伏电站预测出力有所不同, 这种特性用温度系数来表示。晶硅光伏电池的溫度系数为 $-0.35\sim-0.45\%/^{\circ}\text{C}$; 非晶硅光伏电池的溫度系数为 $-0.2\%/^{\circ}\text{C}$ 。实际光伏电站出力历史样本数据自动包含温度系数的影响, 在预测中不需要特别考虑。

5.1.2. 日照角度

由于日照强度包含了直接辐射日照、反射辐射日照和散射辐射日照, 这三种辐射照射到光伏电池上并不是都能转化为光电子继而转化为光电流发电的。例如光伏电池在总日照强度为 $50\text{W}/\text{m}^2$ 以上才能向电网供电, 但是在总日照强度为 $100\text{W}/\text{m}^2$ 以下输出功率较低, 即使在我国日照强度较好的西北地区, 总日照中直接辐射日照占有较大的比例, 但是不可用日照辐射也有 $2\sim3\%$ 。实际光伏电站出力历史样本数据自动包含日照角度的影响, 在预测中不需要特别的考虑。

5.1.3. 设计不当

光伏电站设计不当造成的就是“间距设计不当”。由于目前光伏电站大都采用竖向布置, 下沿的少量遮挡往往会造成整个光伏电池组输出功率极具下降。在一些前后间距偏小的电站, 前后遮挡对光伏电站出力影响甚至能达到 3% 。另外, 山地电站除了考虑前后遮挡以外, 还要考量东西方向高差所带来的遮挡。在坡度比较大, 而东西间距较小的电站, 对光伏电站出力影响可达到 2% 。除了间距以外, 我还经常看到在光伏电站场区内, 设计有较高的建(构)筑物, 对周围的光伏阵列造成遮挡。光伏电池组件的相互遮挡在光伏电站历史数据中自动体现, 在预测中不需要特别的考虑, 由于本文模型中选择的光伏电站是位于青海省沙漠中的某光伏电站, 实际考察中并没有发现有高达建筑物遮挡的现象出现, 在预测中不需要特别的考虑。

5.1.4. 设备故障

光伏电站中的所有设备处于自然环境中, 受到自然环境中各种因素的影响, 设备故障是不可避免的, 设备故障造成的光伏电站历史样本数据出现奇异点, 在选取的时候应该排除。

5.1.5. 清扫不当

由于本文选择的光伏电站是位于青海省沙漠中某光伏电站, 受到近年来发生频繁的沙尘天气的影响导致光伏电池上不可避免的积累灰尘, 一次沙尘暴可造成光伏电站的出力下降 5% 以上, 而严重的雾霾天气光伏电站几乎没有出力, 在冬季, 当积雪覆盖在光伏电池上也会大大降低光伏电站的出力。在选取光伏电站的出力样本数据时, 要去当地气象部门了解光伏电站在沙尘天气高发时段的天气情况, 排除那些由于沙尘天气造成的明显异常的数据, 要去光伏电站搜集清扫工作的记录, 以了解灰尘和积雪对光伏电站出力的影响, 如果有清扫不当的情况发生, 应该排除这几日的数据。

5.2. 样本数据的选取

样本数据包括各种日类型下的历史发电量数据, 天气预报的信息数据, 但是出现一些由于前述其它影响光伏发电出力数据的异常噪声, 而这种异常噪声对神经网络的训练没有好处的。例如在某日天气预报预测的日类型为晴朗天气, 但是由于雾霾天气的影响, 真正照射到光伏电池上的光照远不如天气预报预测的那样强烈, 导致这一日的光伏发电出力明显下降, 如果将这一日的样本数据引入神经网络, 会导致晴朗天气的光伏发电出力预测数据偏小; 例如本应到了该清洁光伏电池的时候, 但是由于工作人员的疏忽大意, 导致这几日的光伏发电数据明显偏小, 过了几日工作人员发现了这一问题, 又去清洁光伏点出, 导致光伏发电数据恢复正常, 如果将由于没有及时清洁光伏电池导致的光伏发电出力下降的数据引入神经网络, 会导致这几日任何日类型下光伏发电出力预测数据偏下。所以在选取数据的时候应该排除那些明显异常的数据, 给后面的训练和预测打好基础。

5.3. 样本数据的处理

神经元网络的输出通常会被限制在一定的范围内, 典型的限制范围为 $(0, 1)$ 或 $(1, -1)$ 。

但是得到的日类型样本数据不可能完全分布在这个较小的范围内, 直接用得到的日类型样本数据进行Elman神经网络的训练会造成神经元饱和, 因此需要对数据进行处理。本文在训练之前对数据进行归一化处理, 给后面的训练和预测做好准备, 如式(8)。

$$x_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (8)$$

式中: x_i 为实际获得的输入数据或预测得到的输出数据。

5.4. 预测数据的评估

虽然采取了以上各种方法来增强预测的准确性, 但预测的数据还是会和实际的数据有一定细微的偏差。本文在训练之后对数据进行均方根误差分析, 来评价预测的准确性, 如式(9)。

$$E_e = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (9)$$

式中： x_i 为预测得到的数据， y_i 为实际的数据。

6. 算例

在前面所做的工作的基础上，本文利用待预测日的日特征向量求取相似日，将相似日的各项数据和预测日的天气预报数据输入到已经训练好的Elman神经网络模型，来求得预测日的光伏出力数据。验证了结合日类型利用Elman神经网络来预测不同的日类型下的光伏电站出力预测的准确性。

表1 日类型为晴天光伏电站出力预测。

晴天	实际出力	预测出力	误差
8:00	2	0	2
9:00	29	30	-1
10:00	38	40	-2
11:00	40	42	-2
12:00	44	45	-1
13:00	42	42	0
14:00	41	41	0
15:00	35	34	1
16:00	28	26	2
17:00	10	9	1
18:00	5	4	1
19:00	3	3	0
20:00	1	0	1
21:00	1	0	1




图7 日类型为晴天光伏电站出力预测。

表1和图7是日类型为晴天光伏电站出力预测与实际出力对比，预测数据与实际数据比较接近，在清晨和傍晚时预测数据和实际数据误差较大，可能是由于清晨和傍晚时光照量和温度变化较快引起的，影响了Elman神经网络的学习过程和准确性，影响了预测的准确性。但总体来看，晴天时候结合利用Elman神经网络来预测光伏电站出力是十分可靠的。

表2 日类型为阴天光伏电站出力预测。

阴天	实际数据	预测数据	误差
8:00	1	0	1
9:00	5	5	0
10:00	8	9	-1
11:00	11	12	-1
12:00	12	13	-1
13:00	14	15	-1
14:00	15	13	2

阴天	实际数据	预测数据	误差
15:00	9	14	-5
16:00	12	8	4
17:00	4	6	-2
18:00	3	4	-1
19:00	2	2	0
20:00	1	1	0
21:00	1	0	1




图8 日类型为阴天光伏电站出力预测。

表2和图8是日类型为阴天光伏电站出力预测与实际出力对比，比日类型为晴天时误差较大，其原因可能是阴天时由于云层对太阳光线的遮蔽，难以预测云层的位置和厚度，难以预测云层飘到光伏电站上空的时间，影响了预测的准确性，这是由于所有神经网络都有一定的惯性造成的。但总体来看，阴天时候结合利用Elman神经网络来预测光伏电站出力是比较可靠的。

表3 日类型为雨天光伏电站出力预测。

	实际数据	预测数据	误差
8:00	0	0	0
9:00	2	2	0
10:00	3	3	0
11:00	4	3	1
12:00	4	4	0
13:00	4	5	-1
14:00	5	5	0
15:00	6	5	1
16:00	5	6	-1
17:00	4	5	-1
18:00	4	4	0
19:00	3	2	1
20:00	2	1	1
21:00	0	0	0




图9 日类型为雨天光伏电站出力预测。

表3和图9是日类型为雨天光伏电站出力预测与实际出力对比，虽然绝对误差量较小，但这是由于雨天光伏电站出力本来就小，预测数据的曲线和实际数据的曲线相差较大，说明相对误差较大。可能因为雨天天气本就属于强对流天气，天气变化较晴天和阴天更难以预测，另外一个确切的原因是本文所选的光伏电站本就建设在日照充足的自然环境下，在这种环境下，日类型为晴天的数量较多，而日类型为雨天的数量较少，所能得到的Elman神经网络训练的样本也较少，利用十分有线的光伏发电出力样本数据来预测雨天的光伏发电出力本就误差较大，影响了训练的准确性。

7. 结语

日类型分别为晴天、阴天和雨天的光伏电站出力预测数据与实际数据的均方根误差对比如表4和图10所示。

表4 不同日类型下预测数据与实际数据的均方根误差。

日类型	晴天	阴天	雨天
误差	4.796	7.483	2.646




图10 不同日类型下预测数据与实际数据的均方根误差。

由表4和图10分析可知，相似日与Elman神经网络联合预测有着较高的准确度。在日类型为晴天时预测准确性较高。在多云天气条件下，预测效果波动最大，因为多云天气变化比较剧烈，随机波动剧烈。虽然雨天的相对均方根误差较小，是由于雨天时光伏出力本身就较小导致的。

致谢

本文为青海省电力公司与西安理工大学共同研究项目《规模化接入下青海电网动态无功协调控制》(441215064)的阶段性成果之一。

参考文献

[1] Paatero J V, Lund P D. Effects of large-scale photovoltaic power integration on electricity distribution networks [J]. Renewable Energy, 2007, 32 (2): 216-234.

[2] Rikos E, Tselepis E, Hoyer Klick C, et al. Stability and power quality issues in microgrids under weather disturbances study of photovoltaic integration [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2008, 1 (3): 170-180.

[3] Paatero J V, Lund P D. Effects of large-scale photovoltaic power integration on electricity distribution networks [J]. Renewable Energy, 2007, 32 (10): 216-234.

[4] Alquthami T, Ravindra H, Farnque M, et al. Study of photovoltaic integration impact on system stability using custom model of PV arrays integrated with PSS//E[C]//2010 North American Power Symposium, Arlington, TX, USA: IEEE, 2010: 1-8.

[5] 林少伯, 韩民晓, 赵国鹏, 等. 基于随机预测误差的分布式光伏配网储能系统容量配置方法[J]. 中国电机工程学报. 2013, 33(4): 25-33.

[6] 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.

[7] 陈昌松, 段善旭, 殷进军. 基于神经网络的光伏阵列发电预测模型的设计[J]. 电工技术学报, 2009, 24(9): 153-158.

[8] 张岚, 张艳霞, 郭嫦敏, 等. 基于神经网络的光伏系统发电功率预测 [J]. 中国电力, 2010, 43(9): 75-78.

[9] 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.

[10] 王飞, 米增强, 甄钊, 等. 基于天气状态模式识别的光伏电站发电功率分类预测方法[J]. 中国电机工程学报, 2013, 33(34): 75-82.

[11] 张艳霞, 赵杰. 基于反馈型神经网络的光伏系统发电功率预测 [J]. 电力系统保护与控制, 2011, 39(15): 96-101.

[12] 刘士荣, 李松峰, 宁康红, 等. 基于极端学习机的光伏发电功率短期预测 [J]. 控制工程, 2013, 20(2): 372-376.