

# 一种基于森林模型的光伏发电功率预测方法研究

宋小会<sup>1</sup>, 郭志忠<sup>1</sup>, 郭华平<sup>2</sup>, 吴双惠<sup>3</sup>, 王兆庆<sup>3</sup>, 邬长安<sup>2</sup>

(1. 哈尔滨工业大学电气工程及自动化学院, 黑龙江 哈尔滨 150001; 2. 信阳师范学院, 河南 信阳 464000;  
3. 许继电气股份有限公司, 河南 许昌 461000)

**摘要:** 为了有效预测光伏电站发电功率, 提高预测精度, 给出一种基于森林预测模型 FPPG (Forest for Photovoltaic Power Generation)。FPPG 是一个由多个回归树组成的集合预测模型。在学习阶段, FPPG 首先随机抽样方法构建有差异的训练数据集, 进而在不同的训练集上构建有差异的回归树。在预测阶段, 首先, FPPG 将输入信息沿着每棵树的某条路径分派到相应的叶结点, 使用这些叶结点预测发电量, 然后, 平均这些预测结果得到 FPPG 对发电厂系统发电量的预测。在实测运行数据集上的实验结果表明, 较之于神经网络, FPPG 同时表现出更高的预测准确性, 从而提高了光伏发电功率预测精度。

**关键词:** 回归树; 森林预测模型; 发电功率预测; 神经网络; 光伏发电

## A new forecasting model based on forest for photovoltaic power generation

SONG Xiaohui<sup>1</sup>, GUO Zhizhong<sup>1</sup>, GUO Huaping<sup>2</sup>, WU Shuanghui<sup>3</sup>, WANG Zhaoqing<sup>3</sup>, WU Changan<sup>2</sup>

(1. Department of Electrical Engineering, Harbin Institute of Technology, Harbin 150001, China; 2. Xinyang Normal University, Xinyang 464000, China; 3. XJ Electric Co., Ltd., Xuchang 461000, China)

**Abstract:** A novel model called forest for photovoltaic power generation (FPPG) is proposed to effectively predict the generation power of photovoltaic power generation. FPPG is an assembly predict model composed by multi regression tree. In learning stage, FPPG first obtains training sets with diversity using random sample technique, and then, constructs regression trees with diversity. For prediction stage, the leaf that the has been assigned input information along the path of each tree predicts the power generation. Then FPPG obtains the corresponding prediction by averaging the predictions of the corresponding leaves. Experimental results show that, compared with neural network, FPPG performs better generated power forecasting.

**Key words:** regression tree; FPPG; generated power forecasting; neural network; photovoltaic power generation

中图分类号: TM715 文献标识码: A 文章编号: 1674-3415(2015)02-0013-06

## 0 引言

作为利用太阳能的一种有效方式, 大规模光伏并网发电已经被国内外众多发电厂采用<sup>[1]</sup>。然而, 这种发电方式不仅会受到光照强度的影响, 而且会受到环境温度、湿度等条件的影响。因此, 光伏发电系统输出功率往往具有不确定性的特点, 这不利于电网调度部门安排常规电源和光伏发电的协调配合。所以, 需要对光伏系统的输出功率预测进行研究, 预先获得其输出功率曲线, 从而协调电网调度部门统筹安排, 减少光伏发电随机性对电力系统的影响, 提高系统安全性和稳定性<sup>[2-7]</sup>。

目前, 已经有很多方法被应用于预测光伏等新型能源发电站的发电量, 例如, 线性回归模型、神经网络模型<sup>[8-11]</sup>、模式树模型<sup>[12]</sup>、模糊模型<sup>[13]</sup>等。本文提出了一种基于森林的预测模型, 通过在真实数据集上做比对实验的结果表明, 森林模型比神经网络等模型具有更高预测精度。这将更加有利于电网调度部门统筹安排、提高电力系统安全性和稳定性。因此, 提出更有效的面向光伏发电的预测模型是一件非常有意义的研究。

本文提出的森林预测模型(Forest for Photovoltaic Power Generation, FPPG)是一个由多个回归树构成的组合模型。在训练阶段, FPPG 迭代地构建不同的回归树; 对于每次迭代, FPPG 使用随机抽样的方法为当前需要学习的回归树构建不同的训练数据集, 进而保证回归树间的差异性。在学习每棵回归树时, FPPG 使用最小化训练数据标准差搜索回归

基金项目: 河南科技厅研究项目 (14A520016, 14B520045, 12A520035)

树中结点的划分条件。在预测阶段，输入信息沿着 FPPG 的每棵树的某条路径到达叶结点后，相应的叶结点直接预测相应的发电量，然后，FPPG 平均这些预测结果得到最终的预测结果。在宁夏金阳新能源有限公司中卫市第三光伏电站收集到的真实数据集上的实验结果表明，与神经网络等传统方法相比，该模型具有更好的预测性能。

## 1 回归树模型

### 1.1 回归树预测方法

面向光伏发电的回归树模型(Regression Tree, RT)是简单树模型。它的内部结点为测试条件，叶子结点直接给出预测结果，即：预测时，输入样本沿着树的一条路径到达一个叶结点，然后，叶结点直接给出相应的预测。图 1 给出了回归树的工作方式。

图 1:  $W$ 、 $T$ 、 $R$ 、 $A$  和  $P$  分别表示风力、温度、光照强度、光线入射角和发电功率预测值(标准化)，图 1 给出了在训练数据集上(随机抽样历史数据)学习到的 RT。假设一个新实例在  $W$ 、 $T$ 、 $R$  和  $A$  上的取值分别(0.054, 0.676, 0.722, 0.529)。注：实验数据已经被规范化。由于  $R=0.722$ ，其大于 0.34、0.56(具有最大 SDR 的划分点)，所以，该实例沿树的最右路径到达最右端叶结点，该叶结点给出的功率预测值  $P$  为 0.7。

值得注意的是，在图 1 给出的模式树中，大部分内部结点的测试属性都为  $R$ (光照强度)，这表明，光伏发电功率与光照强度关系最为密切。该结果与我们研究的光伏发电系统的实际情况相符。

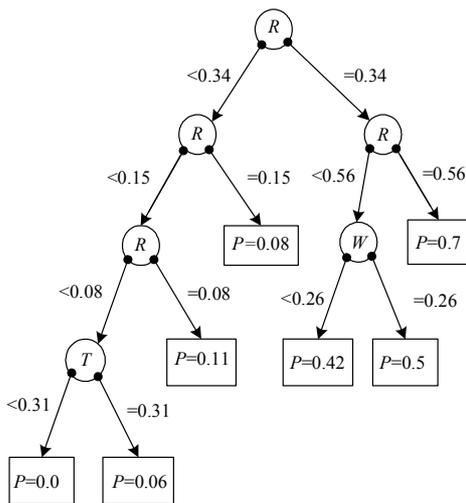


图 1 使用训练数据构建的预测树

Fig. 1 Regression tree constructed from learning data set

### 1.2 回归树构建方法

设  $D$  是训练实例集，回归树(RT)的构建过程是

一个贪心的递归过程：(1)构建一个结点；(2)若  $D$  标准差为 0 或  $D$  包含实例数小于固定阈值，则设该结点为叶结点，其预测值为  $D$  中目标值的平均值；(3)否则，选择一个属性测试条件关联到该结点，根据测试条件，创建它的子结点并将  $D$  中的实例划分到不同子集，然后对于每个子结点和相应的数据子集，在执行步骤(2)和步骤(3)。

算法 1 RT——回归树模型的构建

输入： $D$ ——训练实例集

返回：回归树  $T$

开始：

$T=createNode()$

if  $|D| < 4$  or  $sd(D) < 0.05 * SD$  then

$T.type = LEAF$

$T.prediction = mean(D)$

else

$T.type = TEST$

for 每个属性 do

for 对于每个划分点 do

根据式(1)，计算当前的 SDR

end for

end for

$SDR_m = \text{最大的 SDR} // \text{参考式 1}$

if  $SDR_m < threshold$  then

$T.type = LEAF$

$T.prediction = mean(D)$

else

$T.split = \text{具有最大 SDR 的划分点}$

根据  $T.split$  划分  $D$  为  $D_{left}$  和  $D_{right}$

$T.left = RP(D_{left})$

$T.right = RP(D_{right})$

end if

return  $T$

在选择属性测试条件过程中(过程 3)，一个重要问题是测试条件应该具备何种输出形式。存在两种常用的输出方法，一种是具有形如  $A < v$ (或  $A \geq v$ ) 的二元输出比较测试(如图 1)，另外一种形如  $v_i \leq A < v_{i+1} (i=1, 2, \dots, k)$  的多元输出。本文使用二元输出形式划分结点中的实例(如图 1 所示)。

在选择属性测试条件过程中，另一个重要问题是如何选择最优测试条件。与传统使用纯度增益度量搜索最优划分条件<sup>[14-16]</sup>的做法不同，本文使用结点划分前后标准差降低量(SDR)度量划分条件好坏，具体的

$$SDR = sd(D_t) - \sum_i \frac{|D_{ti}|}{|D_t|} \cdot sd(D_{ti}) \quad (1)$$

式中:  $D_t$  表示到达该当前结点的训练集;  $D_{ti}$  表示到达  $t$  的子结点  $i$  的实例集合;  $sd(D)$  表示训练集在输出功率上的标准差。根据式(1),  $RT$  使用使标准差降低最快的属性划分, 作为最优测试条件, 将  $D_t$  划分成较小的子集并创建相应的子结点。注意: 当  $SDR$  小于某个阈值时, 回归树的生长也结束。

算法 1 给出了回归树构建方法  $RT$  的伪代码。 $RT$  首先判断是否设置当前结点为叶节点(行 1), 其中, 判定条件为结点相关联的实例数小于 4 或实例的标准差小于整体训练集标准差的 5%。若满足条件则设置为叶子结点并设置该叶结点的预测为  $D$  中目标值的平均值(行 3~行 4), 否则, 寻找具有最大  $SDR_m$ (参考式(1))(行 6~行 12)。如果  $SDR_m$  小于给定的阈值, 则依然设置该结点为叶节点并设置相应的预测值(行 13~行 15)。如果不小于给定阈值, 则根据相应的划分条件划分  $D$  为两个不相交的子集, 然后在每个子集上递归学习回归树(行 17~行 20)。

## 2 森林预测模型

面向光伏发电的森林预测模型(FPPG)是一个组合模型, 即: FPPG 由多个回归树( $RT$ )组合(参考第 1 节)。预测时, 该模型用式(2)进行预测。

$$f(\mathbf{x}) = \frac{\sum_{i=1}^M T_i(\mathbf{x})}{M} \quad (2)$$

式中:  $T_i(\mathbf{x})$  表示回归树  $T_i$  在实例  $\mathbf{x}$  上的预测(回归树预测方法参考第 1.1 节)。算法 2 展示了 FPPG 训练、预测的具体过程。

算法 2 FPPG——面向光伏发电的森林预测模型

训练阶段

输入:  $D$ ——训练数据集

$M$ ——森林包含回归树的个数

返回: 森林  $F$

开始:

$F = \emptyset$  //初始化森林为空

$i = 0$

while  $i < M$  do

$D_i = \text{sampling}(D)$

$T_i = \text{RT}(D_i)$  //调用算法 1 学习新的回归树  $T_i$

$R = R \cup \{r\}$

end while

return  $F$

预测阶段

输入:  $x$ ——待预测样本

返回: 预测值

$S = 0$

while 每个预测树  $T_i \in F$  do

$S = S + T_i(x)$

end while

return  $S/M$  //  $M$  为  $F$  中回归树的个数

在训练阶段, FPPG 迭代地构建每棵树(行 3~行 7), 对于每次迭代  $i$ , FPPG 首先使用随机抽样的方法得到新的训练数据集  $D_i$ (行 4), 然后, 以  $D_i$  为参数, 调用算法 1 学习回归树  $T_i$ (行 5)并将其作为森林中的一员(行 6)。在预测阶段, FPPG 累积每棵树的预测(行 10~行 12), 然后使用平均策略获得森林对光伏系统发电功率的预测(行 13)。

## 3 实验

### 3.1 数据集及实验设置

实验是在宁夏金阳新能源有限公司中卫市第三光伏电站收集到的真实数据集上进行的, 且对装置采集数据进行了标准化处理。

本文设计了三组实验: 第一组实验算法 2 中, 回归树个数  $M$  对 FPPG 的性能的影响; 第二组实验使用预测绝对误差评估 FPPG 模型性能; 第三组实验使用均方根误差(RMSE)、平均绝对误差(MAE)和根平方相对误差(RRSE)综合评定 FPPG 性能, 其中, RMSE、MAE 和 RRSE 的定义为

$$\begin{aligned} RMSE &= \sqrt{\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{n}} \\ MAE &= \frac{|p_1 - a_1| + \dots + |p_n - a_n|}{n} \\ RRSE &= \sqrt{\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{(a_1 - \bar{a})^2 + \dots + (a_n - \bar{a})^2}} \end{aligned} \quad (3)$$

式中:  $n$  表示测试集实例总数;  $p_i$  表示模型在实例  $\mathbf{x}_i$  的预测功率;  $a_i$  表示在实例  $\mathbf{x}_i$  的真实输出功率;  $\bar{a}$  表示  $n$  个实例真实功率输出的平均值。

在算法 1 中, 设置行 13 中的阈值(threshold)为 0。为了比较, 选定神经网络(Neural Network, NP)以及回归树(RT, 参见算法 1)作为参照算法。注意: 单独学习回归树时, 使用完整的数据集作为训练集。

### 3.2 实验结果

实验 1: 学习回归树个数  $M$  对森林性能的影响, 其中,  $M$  从 1 逐渐增加到 100。相关结果如图 2 所示。在 3 个误差指标上, FPPG 的误差随着  $M$  的增

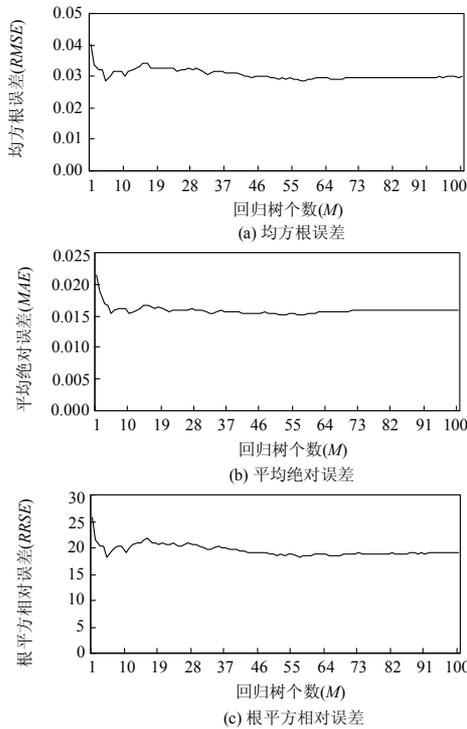


图2 回归树个数对森林性能的影响

Fig. 2 Influence of the number of forest members on the performance of FPPG

表1 FPPG、RT 和 NP 的发电功率预测结果

Table 1 Forecasting results of PV system generated power based on FPPG, RT and NP methods

时间	真实功率输出	FPPG		RT		NP	
		预测	绝对误差	预测	绝对误差	预测	绝对误差
6:30	0.016	0.015	0.001	0.014	0.003	0.074 8	0.058 4
7:30	0.070	0.064	0.005	0.067	0.003	0.102 4	0.032 8
8:30	0.103	0.097	0.006	0.092	0.011	0.118 7	0.015 7
9:30	0.140	0.134	0.008	0.134	0.006	0.152 9	0.013 1
10:30	0.159	0.155	0.009	0.155	0.004	0.167 4	0.008 3
11:30	0.251	0.225	0.026	0.257	0.006	0.234 8	0.016 0
12:30	0.576	0.558	0.038	0.540	0.036	0.549 8	0.026 3
13:30	0.336	0.340	0.004	0.341	0.006	0.359 7	0.023 9
14:30	0.203	0.196	0.007	0.188	0.015	0.238 7	0.035 7
15:30	0.102	0.106	0.007	0.107	0.005	0.129 6	0.027 2
16:30	0.046	0.043	0.003	0.043	0.003	0.075 3	0.029 1
17:30	0.037	0.038	0.006	0.038	0.001	0.065 3	0.028 0
18:30	0.023	0.018	0.006	0.017	0.006	0.050 1	0.026 7
平均绝对误差	——	——	0.007 1	——	0.007 9	——	0.026 3

实验 3: 使用均方根误差(RMSE)、平均绝对误差(MAE)和根平方相对误差(RRSE)综合评定 FPPG 的性能。相关结果如表 2 所示, 其中表中的数据表示相应算法在相应时间段内的统计信息。

从表 2 中可以看出, 在三种指标上, FPPG 在

加而逐渐降低, 最后基本稳定。这表明, 森林能有效地提高回归树的预测精度。另外, 当  $M=50$  时, FPPG 性能基本稳定, 因此, 在后面的实验中设置  $M=50$ 。

实验 2: 使用绝对误差评估模型 FPPG 的性能。相关结果如表 1、图 3 和图 4 所示, 其中, 表 1 给出了不同时刻模型的预测具体结果及相应的绝对误差。注: RT 为直接使用全部训练集学习的回归树, NP 表示神经网络, 最后一行给出绝对误差均值。为了清晰, 表 1 只给出了部分时刻的预测结果。图 3 和图 4 中显示了全天的预测结果信息。

从表 1 最后一行的统计信息可以看出: (1) FPPG 能有效地提高 RT 的性能; (2) 与神经网络相比, FPPG 以及 RT 都表现出更好的预测准确性。具体地, FPPG 以 0.007 1 的平均绝对误差排名预测性能第一, 其他依次是 RT(0.007 9)和 NP(0.026 3)。

图 3 和图 4 分别展示了 6:00~19:00 模型的预测具体结果和相应的绝对误差, 其中, 每一小时, 系统采集 4 个样本, 从 6:00 开始采集。图 3 进一步验证了表 1 中的结论: FPPG 能有效地提高 RT 的性能, 并且, 与神经网络相比, FPPG 以及 RT 都表现出更好的预测准确性。

所有的指标上都取得了最好的结果。具体地, 在 RMSE 上, FPPG 以 0.017 9 排名第一, 其他依次是 RT(0.274)和 NP(0.031 3); 在 MAE 上的排名 FPPG (0.153)、RT(0.215)和 NP(0.240); 在 RRSE 上的排名 FPPG(72.759 9)、RT(167.281 4)和 NP(189.266 6)。另

外, 表 2 结果进一步验证了实验 1 的结论: FPPG 能很好地保持模式预测树的优越特性, 而又能很好地缓解其不足之处。

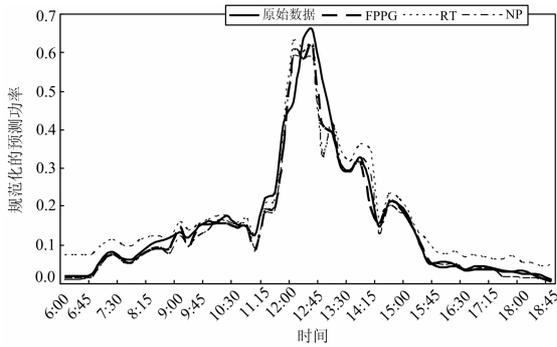


图 3 模型的发电功率预测结果

Fig. 3 Forecast result of models

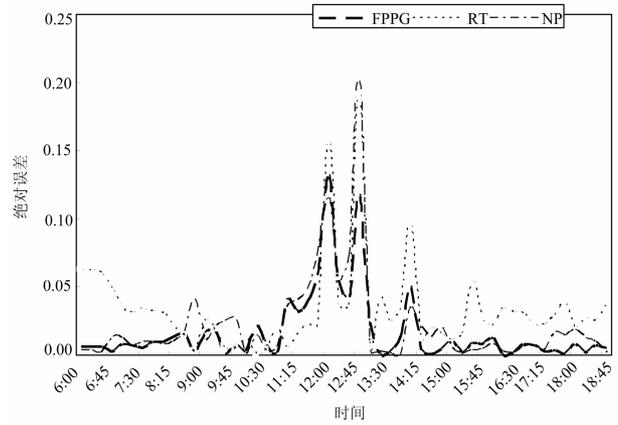


图 4 模型预测绝对误差

Fig. 4 Absolutely error of models' forecasting

表 2 FPPG、RT 和 NP 的性能  
Table 2 Performance of FPPG RT and NP

时间	RMSE			MAE			RRSE		
	FPPG	RT	NP	FPPG	RT	NP	FPPG	RT	NP
6:00~6:45	0.005	0.034	0.042	0.004	0.023	0.023	60.544	442.606	538.672
7:00~7:45	0.005	0.020	0.024	0.005	0.014	0.017	67.192	239.668	288.871
8:00~8:45	0.011	0.021	0.016	0.009	0.014	0.018	84.068	160.018	121.202
9:00~9:45	0.011	0.012	0.014	0.010	0.010	0.015	67.448	72.208	84.522
10:00~10:45	0.012	0.011	0.012	0.009	0.009	0.008	106.817	101.642	103.851
11:00~11:45	0.031	0.027	0.025	0.026	0.021	0.036	29.139	25.520	23.674
12:00~12:45	0.096	0.102	0.112	0.087	0.090	0.111	126.463	134.733	146.744
13:00~13:45	0.010	0.022	0.022	0.007	0.017	0.017	20.895	44.275	45.419
14:00~14:45	0.020	0.034	0.038	0.018	0.024	0.026	55.518	94.595	106.945
15:00~15:45	0.012	0.021	0.024	0.008	0.015	0.013	24.182	40.698	47.355
16:00~16:45	0.006	0.018	0.021	0.006	0.013	0.014	90.741	253.098	303.962
17:00~17:45	0.007	0.019	0.021	0.006	0.015	0.014	129.827	346.112	389.639
18:00~18:45	0.006	0.017	0.020	0.006	0.013	0.014	83.044	219.484	259.610
平均值	0.017 9	0.027 4	0.031 3	0.015 3	0.021 5	0.024 0	72.759 9	167.281 4	189.266 6

#### 4 结论

论文提出一种基于森林的光伏发电功率预测模型(FPPG)。FPPG 迭代地学习一个回归树集合, 预测时, 每个回归树返回一个预测值, 然后 FPPG 平均这些预测值得到最终的预测结果。在真实数据集上的实验结果表明, FPPG 能有效提高回归树的预测性能, 同时, 与神经网络相比, FPPG 和回归树能更准确地预测光伏发电功率。

#### 参考文献

[1] 孙浩, 张曼, 陈志刚, 等. 并网光伏发电系统的通用性

机电暂态模型及其与电池暂态模型的对比分析[J]. 电力系统保护与控制, 2014, 42(3): 127-133.

SUN Hao, ZHANG Man, CHEN Zhigang, et al. Comparative study on electromechanical and electromagnetic transient model for grid-connected photovoltaic power system[J]. Power System Protection and Control, 2014, 42(3): 127-133.

[2] 姜世公, 李琰, 王卫. 一种微网系统孤岛运行条件下的能量管理策略[J]. 电子技术学报, 2014, 27(2): 130-135.

JIANG Shigong, LI Yan, WANG Wei. A novel power

- management strategy for microgrid on islanding mode[J]. Transactions of China Electrotechnical Society, 2014, 27(2): 130-135.
- [3] 姚致清, 张茜, 刘喜梅. 基于 PSCAD/EMTDC 的三相光伏并网发电系统仿真研究[J]. 电力系统保护与控制, 2010, 38(17): 76-81.  
YAO Zhiqing, ZHANG Qian, LIU Ximei. Research on simulation of a three-phase grid-connected photovoltaic generation system based on PSCAD/ EMTDC[J]. Power System Protection and Control, 2010, 38(17): 76-81.
- [4] 周念成, 闫立伟, 王强钢. 光伏发电在微电网中接入及动态特性研究[J]. 电力系统保护与控制, 2010, 38(14): 119-127.  
ZHOU Niancheng, YAN Liwei, WANG Qianggang. Research on dynamic characteristic and integration of photovoltaic generation in microgrids[J]. Power System Protection and Control, 2010, 38(14): 119-127.
- [5] 赵新宇. 光伏发电系统功率预测的研究与实现[D]. 北京: 华北电力大学, 2012.  
ZHAO Yinyu. Research and implementation of power prediction of the photovoltaic system[D]. Beijing: North China Electric Power University, 2012.
- [6] 陈昌松, 段善旭, 蔡涛, 等. 基于发电预测的分布式发电能量管理系统[J]. 电工技术学报, 2010, 25(3): 150-156.  
CHEN Changsong, DUAN Shanxu, CAI Tao, et al. Energy management system of distributed generation based on power forecasting[J]. Transactions of China Electrotechnical Society, 2010, 25(3): 150-156.
- [7] 陈权, 李令冬, 王群京, 等. 光伏发电并网系统的仿真建模及对配电网电压稳定性影响[J]. 电工技术学报, 2013, 28(3): 241-247.  
CHEN Quan, LI Lingdong, WANG Qunjing, et al. Simulation model of photovoltaic generation grid-connected system and its impacts on voltage stability in distribution grid[J]. Transactions of China Electrotechnical Society, 2013, 28(3): 241-247.
- [8] 卢静, 翟海清, 刘纯, 等. 光伏发电功率预测统计方法研究[J]. 华东电力, 2010, 38(4): 563-567.  
LU Jing, DI Haiqing, LIU Chun, et al. Study on statistical method for predicting photovoltaic generation power[J]. East China Electric Power, 2010, 34(4): 563-567.
- [9] 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): 96-102.  
ZHANG Yanxia, ZHAO Jie. Application of recurrent neural networks to generated power forecasting for photovoltaic system[J]. Power System Protection and Control, 2011, 39(15): 96-102.
- [10] 范高锋, 王伟胜, 刘纯, 等. 基于人工神经网络的风电功率预测[J]. 中国电机工程学报, 2008, 28(34): 118-123.  
FAN Gaofeng, WANG Weisheng, LIU Chun, et al. Wind power prediction based on artificial neural network[J]. Proceedings of the CSEE, 2008, 28(34): 118-123.
- [11] YONA A, SENJYU T, FUNABASHI T. Application of recurrent neural network to short-term-ahead generating power forecasting for photovoltaic system[C] // IEEE Power Engineering Society General Meeting, 2007.
- [12] 董亚东, 郭华平, 吴双惠, 等. 面向光伏发电的模式预测树模型[J]. 可再生能源, 2014, 32(3): 253-258.  
DONG Yadong, GUO Huaping, WU Shuanghui, et al. Model prediction tree for forecasting photovoltaic power generation[J]. Renewable Energy Resources, 2014, 32(3): 253-258.
- [13] 陈昌松, 段善旭, 蔡涛, 等. 基于模糊识别的光伏发电短期预测系统[J]. 电工技术学报, 2011, 26(7): 83-87.  
CHEN Changsong, DUAN Shanxu, CAI Tao, et al. Short-term photovoltaic generation forecasting system based on fuzzy recognition[J]. Transactions of China Electrotechnical Society, 2011, 26(7): 83-87.
- [14] 何晓群, 刘文卿. 应用回归分析[M]. 北京: 中国人民大学出版社, 2007.
- [15] QUINLAN J R. C4.5: Programs for machine learning[M]. San Mateo, CA: Morgan-Kaufmann Publisher, 1993.
- [16] BREIMAN L, FRIEDMAN J H, OLSHEN R, et al. Classification and regression trees[M]. London: Chapman and Hall, 1983.

收稿日期: 2014-04-11; 修回日期: 2014-05-30

作者简介:

宋小会(1973-), 男, 博士生, 研究方向为智能电网及继电保护原理; E-mail: xiaohui@xjgc.com

郭志忠(1961-), 男, 教授, 博士生导师, 研究方向为电力系统分析与控制、电网络分析、电力系统光学测量技术;

郭华平(1982-), 男, 博士研究生, 讲师, 研究方向为人工智能。E-mail: hpguo.gm@gmail.com