

# 基于传感器最优布置的光伏阵列阴影诊断与定位

唐 冀, 朱永强, 郝嘉诚

(新能源电力系统国家重点实验室, 华北电力大学, 北京 102206)

**摘 要:** 基于太阳电池典型数学模型, 分析光伏阵列中某块太阳电池被阴影遮蔽时, 阵列所有太阳电池输出电压和电流的变化情况, 并由此提出一种通过单刀多掷模拟开关与电压传感器配合使用的光伏阵列阴影定位法。该方法不仅可避免带电测量线路的交叉, 而且能通过增加布线复杂度从而成倍地减少电压传感器的数量。根据PSCAD仿真得到的数据, 利用BP神经网络对该方法的可行性进行验证, 结果表明该方法可准确进行故障定位。

**关键词:** 光伏阵列; 阴影定位; 传感器最优布置

**中图分类号:** TM914.43

**文献标识码:** A

## 0 引 言

光伏发电是目前对太阳能最有效的利用手段之一, 而局部阴影是光伏发电中最常遇到的故障类型, 长时间的局部阴影会产生热斑效应, 热斑不仅会加速太阳电池板的损坏, 而且将导致系统运行在局部最大功率点, 严重影响光伏电站的发电效率, 因此有必要对光伏阵列局部阴影进行诊断和定位, 以提高阵列的使用寿命和发电效率<sup>[1]</sup>。

目前国内外对光伏阵列故障诊断的方法主要有红外法和电气量法两大类。其中红外法的工作原理是不同工作状态下的太阳电池板存在明显温差, 通过红外识别和图像处理即可对故障进行识别和定位<sup>[2-4]</sup>。电气量法可分为实时监测和离线诊断两类, 其中对地电容检测法和时域反射法属于离线诊断方式, 需要系统停止工作<sup>[5-8]</sup>; 而实时监测主要通过通过对电流和电压传感器的信息进行分析从而对阴影进行诊断和定位<sup>[9,10]</sup>。

本文介绍一种改进的电气量实时监测法, 推导局部阴影对光伏阵列中各太阳电池输出电压和电流的影响, 并由此提出一种通过单刀多掷开关与电压传感器配合使用的光伏阵列阴影定位法, 该方法不仅可避免带电测量线路的交叉, 而且可通过增加布线复杂度成倍减少电压传感器的数量。

## 1 局部阴影输出特性

### 1.1 太阳电池典型数学模型

作为一种非恒压源, 太阳电池的等效电路模型如图1所示, 其输出关系为<sup>[11]</sup>:

$$I = I_{sc} - I_{D0} \left\{ \exp \left[ \frac{q(U_L + IR_s)}{AkT} \right] - 1 \right\} - \frac{U_L + IR_s}{R_{sh}} \quad (1)$$

式中,  $I$  —— 电池总输出电流;  $I_{sc}$  —— 光子在太阳电池中激发的电流;  $I_{D0}$  —— 太阳电池在无光照时的饱和电流;  $q$  —— 电子电荷量 ( $1.6 \times 10^{-19}$  C);  $U_L$  —— 电池输出电压;  $A$  —— 二极管排放系数 (正偏电压较大时  $A$  为 1, 正偏电压较小时  $A$  为 2);  $k$  —— 玻尔兹曼常数 ( $1.38 \times 10^{-23}$  J/K);  $T$  —— 太阳电池温度;  $R_s$  —— 串联电阻;  $R_{sh}$  —— 旁漏电阻。




图1 太阳电池等效电路模型

Fig. 1 Equivalent circuit model of photovoltaic cells

在一般的太阳电池中, 串联电阻  $R_s$  很小, 旁漏

电阻  $R_{sh}$  很大,且  $R_s$  串联在电路中, $R_{sh}$  并联在电路中,故在进行理想电路计算时  $R_s$  和  $R_{sh}$  可忽略不计,从而得到理想太阳电池的输出关系为<sup>[11]</sup>:

$$I = I_{sc} - I_{D0} \left[ \exp \left( \frac{qUL}{AkT} \right) - 1 \right] \quad (2)$$

式中,  $I_{D0}$ 、 $q$ 、 $A$  和  $k$  为定值;当环境温度确定时,可忽略光照强度对  $T$  的影响,将  $T$  近似看作定值。

此时式(2)即表示输出电流  $I$ 、输出电压  $U_L$  和光生电流  $I_{sc}$  三者之间的关系,且这 3 个变量并非线性无关,当其中 2 个变量被确定后,第 3 个变量的值便也被唯一确定。

## 1.2 光伏阵列局部阴影时各电池板输出特征

如图 2 所示,现以  $m \times n$  的 SP 型光伏阵列(每列串联  $m$  块太阳电池, $n$  列并联输出)为例分析阴影对各电池板输出电压和电流的影响。

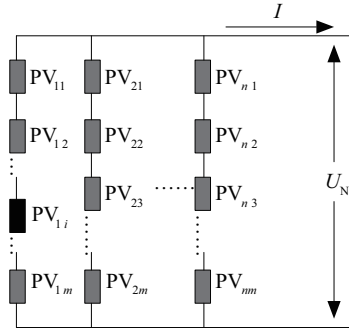


图2 光伏阵列

Fig. 2 Photovoltaic array

正常情况:光伏阵列上电池板的光照强度均为  $S$ ,太阳电池温度均为  $T$ ,最大功率点跟踪(maximum power point tracking, MPPT)控制外电路钳位电压为  $U_N$ ,总输出电流为  $I$ ,太阳电池的总输出功率为  $P$ ,各并联支路输出电流为  $I_1, I_2, \dots, I_n$ ,各电池板输出电压为  $U_{11}, U_{12}, \dots, U_{nm}$ ,各电池板输出功率为  $P_{11}, P_{12}, \dots, P_{nm}$ ,各电池板输出电压、电流之间的关系为:

$$\begin{cases} U_{11} = U_{12} = \dots = U_{nm} = \frac{1}{m} U_N \\ I_1 = I_2 = \dots = I_n = \frac{1}{n} I \end{cases} \quad (3)$$

局部阴影:假设阵列中  $PV_{ji}$  (第 1 列第  $i$  块太阳电池)受阴影遮蔽光照强度减小为  $S_g$ ,其他太阳电池板的光照强度仍为  $S$ ,温度仍为  $T$ ,MPPT 经最大功率跟踪调整后外电路钳位电压变为  $U_g$ ,总输出电流为  $I_g$ ,太阳电池的总输出功率为  $P_g$ ,

各并联支路输出电流为  $I_{g1}, I_{g2}, \dots, I_{gn}$ ,各电池板输出电压为  $U_{g11}, U_{g12}, \dots, U_{gnm}$ ,各电池板输出功率为  $P_{g11}, P_{g12}, \dots, P_{gnm}$ 。

光伏阵列吸收的太阳能功率等于电路的输出功率,局部阴影时  $PV_{ji}$  受阴影遮蔽导致  $P_{gji}$  减小,第一列输出功率将小于其余各列,又外部电路输出电压钳位为  $U_g$ ,故  $I_{g1} < I_{g2}$ 。对比  $PV_{11}$  与  $PV_{21}$ ,吸收太阳能功率相同,但输出电流  $I_{g1} < I_{g2}$ ,故  $U_{g11} > U_{g21}$ ,又外电路钳位电压为  $U_g$ ,有  $U_{g11} < U_{g21}$ 。局部阴影时各电池输出电压、电流关系为:

$$\begin{cases} I_1 < I_2 = I_3 = \dots = I_n \\ U_{11} = \dots = U_{1(i-1)} = U_{1(i+1)} = \dots = U_{1n} \\ U_{21} = U_b = \dots = U_{nm} = \frac{1}{m} U_g \\ U_{11} > U_{21} > U_{1i} \end{cases} \quad (4)$$

根据式(3)和式(4)可得出结论:正常情况下,SP 型光伏阵列中各支路输出电流相等,各电池板输出电压相同;局部阴影情况下,受阴影遮蔽支路的输出电流将小于正常支路,该支路受阴影遮蔽的太阳电池板输出电压将小于正常支路电池板,而该支路未被阴影遮蔽的太阳电池板输出电压将大于正常支路电池板。

## 2 局部阴影检测与定位方法

### 2.1 常规方法介绍

目前光伏阵列最常见的布置方法为 SP 型,如图 2 所示为  $m \times n$  的 SP 型光伏阵列。现有的故障诊断和定位方法中可靠性最高的为图 3a 中所示的方法,在每条支路都串联电流传感器,在每块电池板两端均并联电压传感器,通过算法处理收集到的信息即可得出故障电池板的位置,共需  $m \times n$  个电压传感器和  $n$  个电流传感器,这种方法的成本高,工程实用价值低;文献[9]中提出的诊断方法如图 3b 所示,每个传感器测量  $m/2$  块电池板的电压,在每条支路上设置  $m/2$  个电压传感器,共需  $m \times n/2$  个电压传感器;文献[10]中提出的方法如图 3c 所示,将相邻电池板之间的线路视作 1 个权值节点,每 2 个权值节点之间安装 1 个电压传感器,共需  $(m-1) \times n/2$  个电压传感器。这些减少电压传感器数量的改进方法理论上效果很好,但实际工作过程中带电测量线路相互交叉将影响系统工作的可靠性。

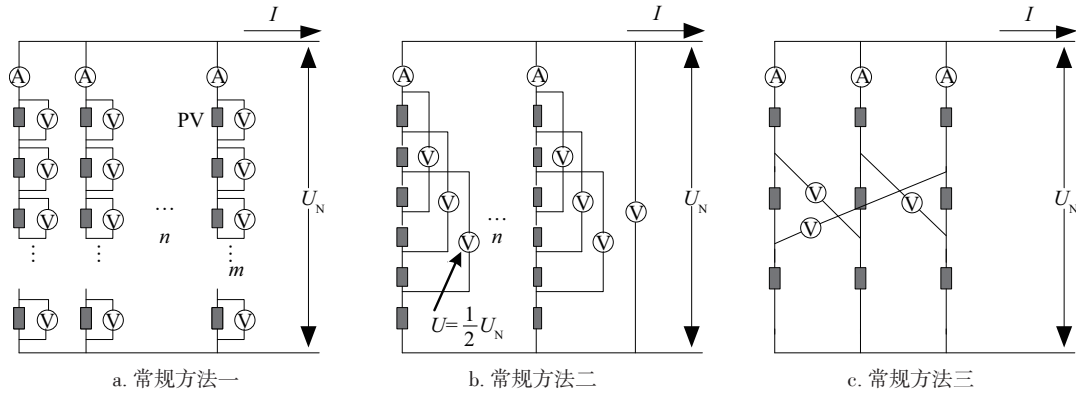


图3 光伏阵列故障诊断常规方法

Fig. 3 Conventional method for fault diagnosis of photovoltaic array

## 2.2 电压传感器与单刀多掷模拟开关配合法

相比于传统的单刀多掷机械开关,单刀多掷模拟开关具有动作时间短、倒闸无安全问题、自动化程度高等优点,故本文采用单刀多掷模拟开关来实现光伏阵列的阴影诊断和定位。

图4a为电压传感器与单刀双掷模拟开关配合检测的电路图(为便于说明工作原理,图中用机械开关代替模拟开关,下同),图4a中每条支路都串联1个电流传感器,每两块相邻的太阳电池共用1个电压传感器,通过单刀双掷模拟开关的动作可自动读入各电池板的电压数据。该方案可在无任何线路交叉的情况下将电压传感器的数量减少为 $m \times n/2$ 。

将图4a中方案作为1个子模块应用在相邻的2条支路上即可得到图4b中方案,通过单刀三掷模拟开关的动作即可得到各太阳电池板的电压数据,

该方案将电压传感器的数量减少为 $m \times n/4$ ,虽然图4b中所示测量线路在空间布置时有交叉,但实际工作时,带电线路不会交叉。

图4a中方案作为子模块仍可继续优化,如图4c所示,通过单刀双掷开关和单刀三掷开关的配合使用即可实现1个电压传感器分别测量同一支路上4块太阳电池的电压,该方案可以将电压传感器的数量减少为 $m \times n/4$ 。

根据上述图4a方案改进为图4b的思路,可将图4c中的方案作为子模块应用于相邻的2条支路,从而将电压传感器的数量减少为 $m \times n/8$ 。根据上述图4a方案改进为图4c的思路,可通过改变单刀多掷模拟开关的类型将该子模块所需电压传感器数量减少为 $m \times n/8$ 。如此往复改进子模块和将子模块应用于相邻2条支路可继续减少光伏阵列所需电压传感器的数量。




图4 光伏阵列故障诊断改进方法

Fig. 4 Improvement method for fault diagnosis of photovoltaic array

表1为上述各种方案的综合对比(布线复杂度由线路交叉程度确定),可明显看出:当所需电压传

感器数量接近时,如图3b、图3c、图4a,本文方案图4a布线最简单;选定相同布线复杂度,如图3a与

图 4a、图 3b 与图 4b, 本文方案图 4a、图 4b 所需电压传感器数量仅为原方案一半。

表 1 方案综合对比

Table 1 Comprehensive comparison of schemes

方案序号	传感器数	布线复杂度
图 3a	$m \times n$	低
图 3b	$m \times n/2$	中
图 3c	$(m-1) \times n/2$	高
图 4a	$m \times n/2$	低
图 4b	$m \times n/4$	中
图 4c	$m \times n/4$	中

由此, 本文提出的方案不仅可大大减少电压传感器的用量, 简化布线复杂程度, 而且有可扩展性, 根据实际情况可通过增加单刀多掷开关和提高布线复杂度进一步减少电压传感器的数量。

本文方案的阴影检测和定位流程如图 5 所示, 通过单刀多掷模拟开关动作读入全部数据, 之后对比各支路输出电流, 对比各电池板输出电压, 通过算法确定是否有局部阴影以及阴影位置。

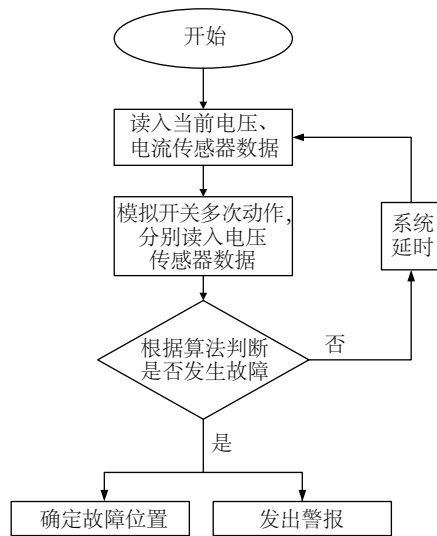


图 5 诊断流程图

Fig. 5 Diagnostic flow chart

### 2.3 合理分组配置电压传感器

在  $m \times n$  的 SP 型光伏阵列中, 每条支路均需要 1 个电流传感器, 但并不是每个电池板的电压都需要测量, 故可根据实际情况对电池板进行分组, 对每组电池板的电压进行测量, 既可减少电压传感器的数量, 又能减少数据量。

其中最简单的方法就是在串联支路上将每  $s$  个电池板分为 1 组, 仅测量各组的电压即可, 如果采用图 4b 所示的排布方式, 所需电压传感器的数量为  $m \times n/(4s)$ , 此时故障检测的分辨度为  $s$ 。

当然, 在实际工程中可根据运行一段时间后各电池板故障发生的频率来调整分组方式, 在不常发生故障的位置将分辨度设得大一些, 在经常发生故障的位置分辨度设得小一些, 甚至可以在故障频率极高的位置使分辨度为 1。

## 3 BP 神经网络模型

### 3.1 BP 神经网络概述

BP 神经网络是一种按误差逆传播算法训练的多层前馈网络, 可以通过学习和存储大量某种映射的输入、输出数据, 从而在不需该映射具体数学方程的基础上直接由给定的输入数据得出输出结果<sup>[12]</sup>。

BP 神经网络包括输入层、隐含层和输出层<sup>[13]</sup>, 所建立的光伏阵列故障检测和定位模型结构如图 6 所示。




图 6 BP 神经网络模型

Fig. 6 Model of BP neural network

BP 神经网络的隐含层需要选取合适的节点数, 节点数太少会影响训练精度, 节点数太多不仅会增长训练时间而且容易陷入局部极小点。隐含层节点数的确定可参考式(5)<sup>[14]</sup>:

$$l < \sqrt{(b+c)} + a \quad (5)$$

式中,  $b$  ——输入层节点数;  $l$  ——隐含层节点数;  $c$  ——输出层节点数;  $a$  ——0~10 之间的常数。

由于输入层的 10 个变量单位不同, 数量级相差也比较大, 将原始数据直接进行神经网络训练会



使得网络的性能和收敛性变差,故需在对 BP 神经网络进行训练之前,将输入、输出数据进行归一化处理,其公式如式(6)<sup>[15]</sup>:

$$y_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (6)$$

式中,  $x_i$  ——原始输入数据;  $x_{\max}$ 、 $x_{\min}$  ——原始输入数据中的最大值与最小值;  $y_i$  ——归一化后的输入数据。

表2 光伏阵列故障诊断与定位模型的部分训练样本

Table 2 Part training sample of fault diagnosis and positioning model for photovoltaic array

故障位置	$S$	$T$	$I_1$	$I_2$	$U_{11}$	$U_{12}$	$U_{13}$	$U_{14}$	$U_{21}$	$U_{22}$	$U_{23}$	$U_{24}$	目标向量
无	1000	25	1.79	1.79	15.00	15.00	15.00	15.00	15.00	15.00	15.00	15.00	0000
无	1000	35	1.60	1.60	15.00	15.00	15.00	15.00	15.00	15.00	15.00	15.00	0000
PV <sub>11</sub>	900	25	1.74	1.79	14.78	15.09	15.09	15.09	15.00	15.00	15.00	15.00	0001
PV <sub>12</sub>	800	25	1.66	1.79	15.18	14.4	15.18	15.18	15.00	15.00	15.00	15.00	0010
PV <sub>13</sub>	700	25	1.56	1.79	15.32	15.32	14.1	15.32	15.00	15.00	15.00	15.00	0011
PV <sub>14</sub>	600	25	1.40	1.79	15.49	15.49	15.49	15.50	15.00	15.00	15.00	15.00	0100
PV <sub>21</sub>	900	35	1.60	1.55	15.00	15.00	15.00	15.00	14.78	15.09	15.09	15.09	0101
PV <sub>22</sub>	800	35	1.60	1.49	15.00	15.00	15.00	15.00	15.18	14.4	15.18	15.18	0110
PV <sub>23</sub>	700	35	1.60	1.40	15.00	15.00	15.00	15.00	15.32	15.32	14.1	15.32	0111
PV <sub>24</sub>	600	35	1.60	1.30	15.00	15.00	15.00	15.00	15.49	15.49	15.49	15.50	1000

通过上述分析,本文模型的输入层变量共 10 个:  $I_1, I_2, U_{11}, \dots, U_{24}$ ; 输出层变量共 4 个:  $O_1, O_2, O_3, O_4$ , 输出层变量定义如表 3 所示; 根据式(5), 经过多次试验, 隐含层节点数为 9 时, 性能最佳。在 Matlab 软件中使用 BP 神经网络工具箱中的 newff、train 和 sim3 个神经网络函数, 使用 newff 中默认节点传递函数、训练函数等相关函数, 学习效率为 0.05。

表3 输出层定义

Table 3 Output layer definition

序号	故障位置	$O_4$	$O_3$	$O_2$	$O_1$	十进制
0	无	0	0	0	0	0
1	PV <sub>11</sub>	0	0	0	1	1
2	PV <sub>12</sub>	0	0	1	0	2
3	PV <sub>13</sub>	0	0	1	1	3
4	PV <sub>14</sub>	0	1	0	0	4
5	PV <sub>21</sub>	0	1	0	1	5
6	PV <sub>22</sub>	0	1	1	0	6
7	PV <sub>23</sub>	0	1	1	1	7
8	PV <sub>24</sub>	1	0	0	0	8

### 3.2 数据采集与处理

在 PSCAD 中建立的 4×2 光伏阵列模型, 采集辐照度范围为 500~1000 W/m<sup>2</sup>、组件温度范围为 25~45 ℃的  $U_{11} \dots U_{24}$ 、 $I_2$ 、 $I_1$  数据, 作为 BP 神经网络的样本。本文共采集 800 组数据, 其中的 700 组数据作为训练样本, 另外 100 组数据作为测试样本, 部分训练样本如表 2 所示。

BP 神经网络训练结束后, 对该网络进行测试。为了直观的体现 BP 神经网络的测试效果, 本文将 8 维的输出数据, 经相应数据转换成 1 维数据, 并计算网络预测误差, 采用的数据转换为: 将  $O_1, O_2, O_3, O_4$  分别乘以 10、20、40、80 再将其相加。图 7 为对应的 BP 网络输出结果, 从图中可看出, 实际输出与预期输出很接近, 说明了本文方法的可行性。




图7 BP网络输出

Fig. 7 Output of BP network

## 4 结 论

1) 基于太阳能电池典型数学模型, 推导出光伏阵列中某块太阳能电池被阴影遮蔽时, 阵列所有太阳能电池输出电压和电流的变化情况: 故障支路的输出电流将小于正常支路, 受阴影遮蔽电池板输出电压小于正常支路电池板, 故障支路未被阴影遮蔽电池板输出电压将大于正常支路电池板。

2) 根据推导得出的结论, 提出一种更实用的光伏阵列故障诊断和定位的方法, 通过单刀多掷模拟开关与电压传感器配合使用, 不仅可大大减少电压传感器的用量, 简化布线复杂程度, 并且具有可扩展性, 可根据实际情况通过增加单刀多掷开关和提高布线复杂度进一步减少电压传感器的数量。

3) 选定 4×2 的光伏阵列, 根据 PSCAD 仿真得到的数据, 利用 BP 神经网络根据对该方法的可行性进行了验证。

### [参考文献]

- [1] 胡义华, 陈 昊, 徐瑞东. 基于电压扫描的光伏阵列故障诊断策略[J]. 中国电机工程学报, 2010, (Sup1): 185—191.
- [1] Hu Yihua, Chen Hao, Xu Ruidong. Fault diagnosis strategy for PV array based on voltage scan[J]. Proceedings of the Chinese Society of Electrical Engineering, 2010, (Sup1): 185—191.
- [2] 王培珍, 郑诗程. 基于红外图像的太阳能光伏阵列故障分析[J]. 太阳能学报, 2010, 31(2): 197—202.
- [2] Wang Peizhen, Zheng Shicheng. Fault analysis of solar photovoltaic array based on infrared image[J]. Acta Energaie Solaris Sinica, 2010, 31(2): 197—202.
- [3] 王培珍, 沈玉樑, 杨维翰. 太阳光伏阵列的温度与红外特性分析[J]. 太阳能学报, 2005, 26(1): 86—89.
- [3] Wang Peizhen, Shen Yuliang, Yang Weiha. Analysis of the temperature and infrared characteristics of the solar photovoltaic array[J]. Acta Energaie Solaris Sinica, 2005, 26(1): 86—89.
- [4] 王培珍, 王群京, 杨维翰. 太阳能光伏阵列的红外特性研究[J]. 合肥工业大学学报: 自然科学版, 2004, 27(7): 769—773.
- [4] Wang Peizhen, Wang Qunjing, Yang Weiha. Study on infrared characteristics of solar photovoltaic arrays[J]. Journal of Hefei University of Technology: Natural Science Edition, 2004, 27(7): 769—773.
- [5] Schirone L, Califano F P, Moschella U, et al. Fault finding in a 1 MW photovoltaic plant by reflectometry [A]. IEEE Photovoltaic Specialists Conference [C], Hawaii: IEEE, 1994, 846—849.
- [6] Kaushika N D, Rai A K. An investigation of mismatch losses in solar photovoltaic cell networks[J]. Energy, 2007, 32(5): 755—759.
- [7] Chao Kuei-Hsiang, Ho Sheng-Han, Wang Meng-Hui. Modeling and fault diagnosis of a photovoltaic system [J]. Electric Power Systems Research, 2008, 78(1): 97—105.
- [8] Gautam N K, Kaushika N D. Reliability evaluation of solar photovoltaic arrays [J]. Solar Energy, 2002, 72(2): 129—141.
- [9] 唐佳能. 太阳能光伏阵列故障检测及仿真分析[D]. 北京: 华北电力大学, 2012.
- [9] Tang Jianeng. Fault detection and simulation analysis of solar photovoltaic array [D]. Beijing: North China Electric Power University, 2012.
- [10] 胡义华, 陈 昊, 徐瑞东, 等. 基于最优传感器配置的光伏阵列故障诊断[J]. 中国电机工程学报, 2011, 31(33): 19—30.
- [10] Hu Yihua, Chen Hao, Xu Ruidong, et al. Fault diagnosis of photovoltaic array based on optimal sensor placement[J]. Proceedings of the Chinese Society of Electrical Engineering, 2011, 31(33): 19—30.
- [11] 张 兴, 曹仁贤. 太阳能光伏并网发电及其逆变控制 [M]. 北京: 机械工业出版社, 2010, 41—46.
- [11] Zhang Xing, Cao Renxian. Photovoltaic grid connected power generation and its inverter control [M]. Beijing: Mechanical Industry Press, 2010, 41—46.
- [12] 黄 丽. BP 神经网络算法改进及应用研究[D]. 重庆: 重庆师范大学, 2008.
- [12] Huang Li. BP neural network algorithm improvement and application research [D]. Chongqing: Chongqing Normal University, 2008.
- [13] 王元章, 李智华, 吴春华, 等. 基于 BP 神经网络的光伏组件在线故障诊断[J]. 电网技术, 2013, 37(8): 2094—2100.
- [13] Wang Yuanzhang, Li Zhihua, Wu Chunhua, et al. On line fault diagnosis of PV module based on BP neural network [J]. Power System Technology, 2013, 37(8): 2094—2100.
- [14] 沈花玉, 王兆霞, 高成耀, 等. BP 神经网络隐含层单元数的确定[J]. 天津理工大学学报, 2008, 24(5):

- 13—15.
- [14] Shen Huayu, Wang Zhaoxia, Gao Chengyao, et al. Determination of the number of hidden layer units in BP neural network[J]. Journal of Tianjin University of Technology, 2008, 24 (5): 13—15.
- [15] 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.
- [15] Chen Changsong, Duan Shanxu, Yin Jinjun. Design of photovoltaic array power generation forecasting model based on neural network[J]. Transactions of China Electrotechnical Society, 2009, 24 (9): 153—158.

## SHADOW DIAGNOSIS AND LOCALIZATION OF PV ARRAY BASED ON OPTIMAL SENSOR COLLOCATION

Tang Qi, Zhu Yongqiang, Hao Jiacheng

(State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Beijing 102206, China)

**Abstract:** Based on the typical mathematical model of solar cell, the change of the output voltage and current of all solar cells in the solar PV array were analyzed when one of solar cells was covered by shadow. And then a shadow positioning method of PV array using single-pole multi-throw analog switch and voltage sensor was proposed. This method not only can avoid the cross of live measuring circuit, but also can reduce the number of voltage sensor through increasing the wiring complexity. The feasibility of the method was verified by using BP neural network according to the data obtained from PSCAD simulation. The results showed that the method can accurately locate the fault.

**Keywords:** PV array; shadow positioning; optimal sensor collocation