

# 基于 $I-V$ 曲线逆推法的光伏组件故障诊断策略

朱青云<sup>1</sup>, 刘凡<sup>2</sup>, 曾伟<sup>3</sup>

(1.青海省产品质量检验检测院, 青海 西宁 810003; 2.南昌工程学院 电气工程学院, 江西 南昌 330099;  
3.国网江西省电力有限公司电力科学研究院, 江西 南昌 330096)

**摘要:** 光伏组件故障诊断一般依赖于对辐照度和温度等环境变量的测量, 对分散的组件故障判别不够精确。文章提出了基于逆推  $I-V$  曲线法的光伏组件故障诊断策略。该策略事先提取光伏组件模型参数, 然后计算不同辐照度及太阳能电池温度下的  $I-V$  曲线, 形成  $I-V$  曲线库; 在运行时无须实时监测太阳能电池运行时表面辐照度及平均温度, 仅测量光伏组件的开路电压、短路电流和最大功率点电压、电流, 即可判断出组件是否发生故障。搭建实验平台对典型故障进行模拟并利用该策略进行判别, 结果表明, 文章提出的策略能够有效判断组件的故障。利用该策略研发了单板故障监测模块, 实现了光伏组件在线故障判断, 提高了光伏组件故障判断的精确性及光伏电站运行的可靠性和经济性。

**关键词:** 太阳能电池; 参数辨识; 最大功率点; 逆推  $I-V$  曲线

**中图分类号:** TK51; TM615 **文献标志码:** A **文章编号:** 1671-5292(2024)08-1029-08

## 0 引言

太阳能发电作为可再生能源发电的重要形式, 近年来迅速发展<sup>[1]</sup>, 但是光伏电站中的光伏组件众多, 故障特征不明显。对故障预测不准确和排查不及时, 会影响组件的性能和寿命, 致使组件提前报废, 造成较大的经济损失<sup>[2]</sup>。因此, 对光伏组件的故障判断方法进行研究具有重要的理论价值和现实意义。

现有的光伏组件在线故障诊断方法基本采取功率特征比较法, 即比较组件最大功率点 (Maximum Power Point Tracking, MPPT) 功率实测值与组件模型 MPPT 计算值, 如两者存在较大特征差, 则可判断组件发生故障。用于计算的组件模型主要为基于光伏组件物理规律建立的数值模型和利用智能算法对太阳能组件进行建模得到的人工智能模型。文献[3]将实测的温度和辐照度输入到实时通用电路混合模型中计算太阳能系统功率损耗来分析故障。文献[4]基于每种电池连接方式下光伏系统的等效参数分析和功率损耗进行故障诊断。文献[5, 6]基于不同的神经网络算法提出了相应的光伏阵列故障诊断方法。文献[7]提出了用于光伏阵列早期故障检测和诊断的随机森林集成学习算法。文献[8]采用混合算法提取光伏模型

参数来进行故障诊断。

无论依据数值模型或人工智能模型计算 MPPT 功率理论值, 都依赖于准确测量组件运行时的温度和辐照度。但数量众多的光伏组件分散在大面积的光伏电站内, 无法做到准确测量所有组件的温度和辐照度, 造成故障诊断结果存在较大误差。

本文提出了一种基于逆推  $I-V$  曲线的光伏组件故障诊断策略, 该策略通过测试组件短路电流与开路电压, 在事先生成的  $I-V$  曲线库中匹配得到对应的  $I-V$  曲线, 使用该曲线 MPPT 点功率与实测 MPPT 点功率的特征差判断组件是否存在故障。

## 1 $I-V$ 曲线库构建方法

### 1.1 太阳能电池参数模型

由于太阳能电池内部存在光电损耗, 实际的太阳能电池产生的电流会与理想情况存在偏差。为了表征这些偏差, 研究者已经提出了多种光伏电池模型, 由于单二极管电路结构简单, 参数数量少并保证了良好的仿真精度<sup>[9]</sup>, 本文即采用该模型。单二极管等效电路如图 1 所示。

单二极管模型中输出电流  $I$  的计算式为

$$I = I_{ph} - I_0 \left[ \exp \left( \frac{V + IR_s}{V_{tn}} \right) - 1 \right] - \frac{V + IR_s}{R_{sh}} \quad (1)$$

收稿日期: 2023-11-06。

基金项目: 国家自然科学基金项目(52267007)。

作者简介: 朱青云(1966-), 男, 正高级工程师, 研究方向为光伏产品及新能源。E-mail: zqy7890@163.com




图1 单二极管等效电路

Fig.1 Single diode equivalent circuit

式中： $V_i$  为太阳能电池阵列热电压， $V_i=NkT/q$ ； $N_s$  为串联的电池组数量<sup>[10]</sup>； $k$  为玻尔兹曼常数， $k=1.381 \times 10^{-23}$  J/K； $T$  为太阳能电池的开氏温度，K； $q$  为电子电荷， $q=1.602 \times 10^{-19}$  C。

模型中有 5 个参数： $n$  为二极管理想因子， $I_{ph}$ 、 $I_0$ 、 $R_s$ 、 $R_{sh}$  分别为光生电流、二极管饱和电流、串联电阻和并联电阻。这 5 个参数可以用式(2)~(6)计算非标工况条件下的参数值，式(1)利用这些参数值就可以得到任意辐照度和温度下的输出电流<sup>[11]</sup>。

$$n=n_{ref} \left( \frac{T}{T_{ref}} \right) \quad (2)$$

$$I_{ph}=\frac{S}{S_{ref}} [I_{ph,ref}+K_1(T-T_{ref})] \quad (3)$$

$$I_0=I_{0,ref} \left( \frac{T}{T_{ref}} \right)^3 e^{\{(N_s \cdot T_{ref}/a_{ref})[(E_{g,ref}/T_{ref})-(E_g/T)]\}} \quad (4)$$

$$R_{sh}=\frac{S_{ref}}{S} R_{sh,ref} \quad (5)$$

$$R_s=R_{s,ref} \quad (6)$$

式中：下标 ref 表示标准条件下 (Standard Test Conditions, STC) 的参数； $S$  为被吸收的太阳辐射； $K_1$  为电流温度系数； $E_g$  为光伏电池材料的带隙能，可通过式(7)计算任意温度下的  $E_g$ ，常数  $3.174 \times 10^{-4}$  适用于单晶硅<sup>[12]</sup>。

$$E_g=E_{g,ref} \left[ 1-0.0003174 \left( \frac{T}{T_{ref}} \right) \right] \quad (7)$$

光伏组件生产商一般不会直接提供模型参数，面板上通常只有组件 3 个特征点的数值：开路电压、短路电流以及 MPPT 电压、电流，需要从这 3 个特征点求解出 5 个模型参数。由于式(1)是隐式超越方程，无法直接计算出未知模型参数，而且各参数之间数值相差很大，从而使得模型参数的求解变的异常困难<sup>[13]</sup>。

因此，研究者开发出许多参数辨识方法，其中智能优化算法被广泛应用于参数辨识。本文选取差分进化算法与禁忌搜索算法混合算法来求解太

阳能电池的模型参数。

### 1.2 禁忌搜索优化的差分进化算法

差分进化算法 (Differential Evolution, DE) 是由 Store 和 Price 于 1997 年提出的一种基于群体差异的启发式并行搜索方法，通过交叉、变异、选择等操作进行寻优，具有收敛快、控制参数少且设置简单、优化结果稳健等优点，但容易出现局部寻优<sup>[14]</sup>。禁忌搜索算法 (Tabu Search, TS) 基于对局部领域搜索算法的优化，使领域搜索有较大概率跳出局部极值点获得最优解<sup>[15]</sup>。禁忌搜索的优点在于强大的局部搜索能力，通过维护一个禁忌表，记录搜索过程中已尝试过的一些移动，暂时禁止再次执行这些移动保持一定的多样性，避免陷入局部最优解。

基于 DE 和 TS 算法的优缺点，本文提出了一种基于禁忌搜索优化的差分进化算法 (TS-DE) 对光伏组件的参数进行提取。

算法的适应度函数如式(8)所示，计算 3 个特征点 RMSE 误差和功率/电压 ( $P-V$ ) 曲线 MPPT 处的斜率之和。

$$error=\sqrt{\frac{\sum_{i=1}^3 [I_m(V_i)-I_e(V_i)]^2}{3}} + \left| \frac{dP}{dV} \right|_{MPP} \quad (8)$$

算法的步骤如下。

步骤一：初始化种群大小为  $N$ ，维度为  $D$ ，产生  $N$  个维度为  $D$  的初始种群， $ub$  为上边界， $lb$  为下边界，计算式为

$$X=(ub-lb)rand(0,1)+lb \quad (9)$$

步骤二：变异操作，种群通过变异产生新的个体。

$$v_{i+1}=x_{r1}+F \times (x_{r2}-x_{r3}) \quad (10)$$

随机选择的序号  $r_1 \neq r_2 \neq r_3$ ，由于差分进化中  $F$  的取值决定了种群的搜索能力，当  $F$  较大时可以提高搜索速度，较小时容易出现“早熟”的现象，于是将  $F$  的取值更改为根据迭代次数进行取值，加强算法前期的全局搜索能力。

$$F=e^{-\left(\frac{2G}{G_{max}}\right)^2} \quad (11)$$

式中： $G$  为当前迭代次数； $G_{max}$  为最大迭代次数。

步骤三：交叉操作，增加种群多样性。

$$u_G=\begin{cases} v_{G+1} & rand \leq CR \\ x_G & rand > CR \end{cases} \quad (12)$$

$u_G$  为交叉后产生的新个体，交叉概率  $CR$  将

影响进化信息的调整权重,为尽量保证种群大小的多样性,采用随机函数生成 CR,计算式为

$$CR=0.3+rand(0,1) \quad (13)$$

式中:rand(0,1)为(0,1)中的随机数。

步骤四:选择操作,选择适应度较好的值作为下一个个体。

$$u_{(i)G+1} = \begin{cases} u_{(i)G}, & f(u_{(i)G}) \leq f(x_{(i)}) \\ x_{(i)}, & \text{otherwise} \end{cases} \quad (14)$$

步骤五:更新最优解,判断是否更新解决方案。当最优解在一定的迭代次数内保持不变,且迭代次数超过设定的参数,则将此次最优解作为禁忌搜索的初始,反之输出最优解。

步骤六:判断是否满足终止条件,若不满足条件,则返回到步骤二;否则算法结束,输出最优解。

算法步骤流程如图 2 所示。

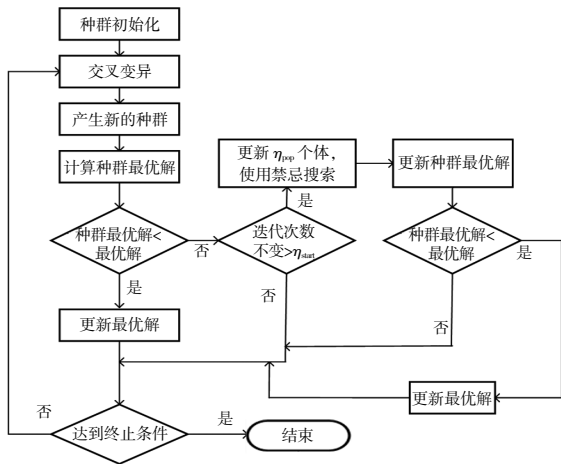


图 2 TS-DE 算法流程图

Fig.2 TS-DE algorithm flowchart

将改进后的 TS-DE 算法与粒子群算法 (Particle Swarm Optimization, PSO) 和 DE 算法进行对比,3 种算法分别迭代 200 次,结果见图 3。




图 3 适应度曲线

Fig.3 Fitness curve

适应度值如表 1 所示。

表 1 算法适应度值

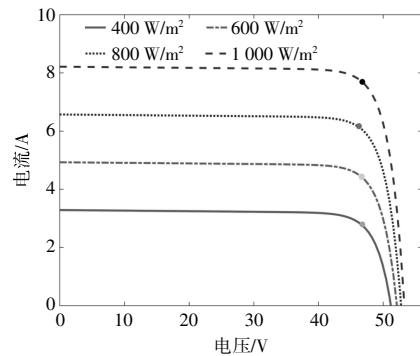
Table 1 Algorithm fitness value

算法	最大值	最小值	平均值
PSO	0.034 20	0.027 50	0.031 46
DE	0.006 54	0.000 31	0.003 12
TS-DE	2.52×10 <sup>-6</sup>	1.03×10 <sup>-6</sup>	1.37×10 <sup>-6</sup>


由表 1 可以看出:PSO 算法的适应度值较差,精确度较低,收敛时间较长;DE 算法适应度比 PSO 好,但在迭代一定次数后保持不变;而 TS-DE 算法在 3 种算法中适应度最好,精确度最高,迭代时间最短。

### 1.3 I-V 曲线库计算方法

在获得标准工况下光伏组件的相关参数后,改变温度和辐照度,通过式(2)~(7)分别计算不同温度和辐照度下的  $R_s, n, I_{ph}, I_0, R_{sh}$ , 再通过式(1)构建 I-V 曲线。一系列不同辐照度和温度的 I-V 曲线如图 4 所示。



(a)不同辐照度下 I-V 曲线



(b)不同温度下 I-V 曲线

图 4 系列 I-V 曲线

Fig.4 I-V characteristic curves

这些曲线有 4 个特征参数:开路电压  $V_{oc}$ 、短路电流  $I_{sc}$ 、MPPT 点电压  $V_{mppt}$  和电流  $I_{mppt}$ 。根据式(1)可以计算出不同温度和辐照度下的 I-V 曲线,

进而得到一系列的 $[V_{oc}, I_{sc}, V_{mppt}, I_{mppt}]$ , 形成  $I-V$  曲线库。通过现场实测的 $[V'_{oc}, I'_{sc}, V'_{mppt}, I'_{mppt}]$ , 可以在  $I-V$  曲线库中找到最接近的  $V_{oc}, I_{sc}$  数据组, 得到对应的  $V_{mppt}$  和  $I_{mppt}$ , 从而计算出  $P_{mppt}$  用于故障判断。这种不需要在线计算 MPPT 功率, 而是通过倒查事先生成的  $I-V$  曲线库得到 MPPT 功率的方法, 就是  $I-V$  曲线逆推法。

## 2 故障监测方法

$I-V$  曲线逆推法的关键在于需要获得光伏组件的开路电压和短路电流, 以便在  $I-V$  曲线库中准确找到对应的  $I-V$  曲线, 然而在运行现场很难取得这些测试数据。在光伏电站中, 组件均通过串联组成光伏组串接入逆变器, 一般的故障监测都是在光伏组串上进行, 监测颗粒度不足<sup>[16]</sup>, 而且只能通过暂时停运逆变器获得光伏组串的开路电压。本文采用了一种组件级监测方案, 研发了单板监测模块, 可以同时获取单块组件的开路电压和短路电流, 电路如图 5 所示。




图 5 光伏组件监测电路

Fig.5 PV module monitoring circuit

监测模块从光伏组件取电, 供微控制器工作。测试时, 首先读取 PV 板的电压、电流; 断开  $H_1$ , 即可测量光伏组件开路电压; 再闭合  $H_2$ , 微控制器读取太阳能电池短路电流。当  $H_2$  闭合时, 组件电压为 0, 由于储能电路和防反二极管, 后级电路不掉电正常工作。测完后断开  $H_2$  合上  $H_1$ , 太阳能电池正常输出。

测试完毕后, 利用式(15), (16)计算短路电流和开路电压计算值和测量值之差:

$$\Delta I = |I_{sc} - I'_{sc}| \quad (15)$$

$$\Delta V = |V_{sc} - V'_{sc}| \quad (16)$$

利用式(17)计算加权矢量距离:

$$\Delta D = \sqrt{\alpha_I \times \Delta I^2 + \alpha_V \times \Delta V^2} \quad (17)$$

式中:  $\alpha_I$  和  $\alpha_V$  分别为  $\Delta I$  和  $\Delta V$  对应的权重。

若  $\Delta D$  小于预设阈值, 即可定位对应曲线。定位  $I-V$  曲线后, 计算曲线上最大功率点与实测最大功率点的功率偏差, 即特征差。如果特征差小于阈值, 说明太阳能电池处于正常状态, 如大于阈值, 说明太阳能电池存在故障。

综上所述, 故障监测流程如图 6 所示。

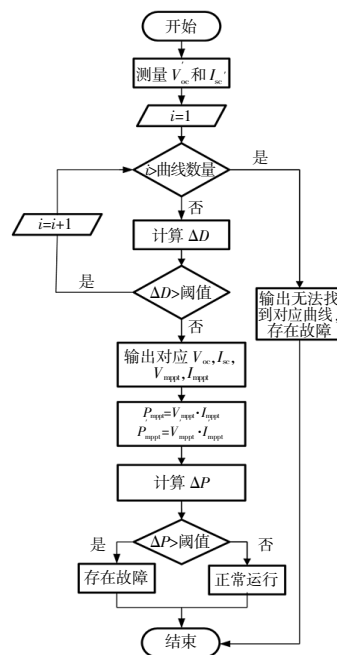


图 6 故障监测流程图

Fig.6 Flow chart of fault monitoring

由于曲线库中包含了所有正常工作条件下的短路电流和开路电压, 若无法找到对应曲线, 则可判断为故障组件。

## 3 结果和讨论

### 3.1 实验平台

实验平台如图 7 所示。测试用太阳能发电系统由 8 块最大输出功率为 400 W 的单晶硅太阳能电池板组成, 总容量为 3 200 W, 安装在楼顶。每块电池板后安装一个背板监测单元, 监测数据




图 7 实验平台

Fig.7 Experimental platform

通过数据网关无线传输到后台系统集中监控。太阳能电池板的参数如表 2 所示。应用 TS-DE 算法辨识的光伏组件模型参数如表 3 所示。在每个太阳能电池板上安装监测单元,分别对模拟老化故障、阴影遮挡故障进行了测试。

表 2 标准工况下太阳能电池板参数  
Table 2 Parameters of the solar array under standard working conditions

参数	数值
$V_{oc}/V$	53.1
$I_{sc}/A$	9.73
$V_{mppt}/V$	43.7
$I_{mppt}/A$	9.16
$P_{max}/W$	400.29
$K_1/V \cdot K^{-1}$	-0.002 8
$K_2/A \cdot K^{-1}$	0.000 4
$N_s$	72

表 3 标准工况下光伏组件模型参数  
Table 3 Parameters of the PV module model under standard working conditions

参数	$n$	$R_s/\Omega$	$R_{sh}/\Omega$	$I_0/A$	$I_{ph}/A$
数值	1.3	0.262	1 158.46	$2.51 \times 10^{-9}$	9.73

### 3.2 I-V 曲线库精度

根据实验地区温度辐照度变化范围,构造 I-V 曲线库的辐照度设定为 100~1 200 W/m<sup>2</sup>,差值为 10 W/m<sup>2</sup>,温度设定为 5~60 °C,差值为 5 °C,共生成 1 332 条 I-V 曲线。为了检验 I-V 曲线的准确度,在不同温度和辐照度下测试组件的最大功率,逆推对应的 I-V 曲线并计算最大功率误差值,部分结果如表 4 所示。

表 4 逆推法误差测试数据  
Table 4 measured data during normal operation

曲线	数据来源	$V_{oc}/V$	$I_{sc}/A$	$P_{max}/W$	特征差/%
1	实测值	48.87	6.41	236.52	2.72
	曲线库值	49.03	6.44	243.63	
2	实测值	48.13	7.29	260.21	0.35
	曲线库值	47.28	7.25	259.31	
3	实测值	48.04	7.31	262.41	2.90
	曲线库值	48.33	7.34	270.24	
4	实测值	48.09	7.51	275.46	1.60
	曲线库值	48.37	7.44	279.81	

本文选择单晶硅、多晶硅、半片大功率及薄膜等 4 种不同类型组件的 I-V 曲线库,分别在不同季节选择 6 个典型日,每个典型日根据辐照度变化取 10 个时间点进行误差测试,误差统计结果如图 8 所示。3 种晶硅组件的 I-V 曲线 MPPT 功率




图 8 不同光伏组件测量误差  
Fig.8 Measurement error of different photovoltaic modules

误差最大值为 3.0%,考虑现场测试误差裕度,采用 3.5%作为晶硅组件故障判别特征差阈值。

### 3.3 老化故障实验

老化故障的主要表现形式为串联电阻增大。对太阳能组件串联附加电阻进行模拟,将滑动变阻器串联到组串线路中,模拟光伏组件使用后产生的附加电阻,逐步增加滑动变阻器电阻值,由背板检测单元采集试验数据,试验接线如图 9 所示。对应的实测数据与曲线库数据如表 5 所示。




图 9 老化故障接线图  
Fig.9 Aging fault wiring diagram

表 5 老化故障数据  
Table 5 Data of aging failure

电阻/ $\Omega$	数据来源	$V_{oc}/V$	$I_{sc}/A$	$P_{max}/W$	特征差/%
0.225	实测值	48.13	7.29	260.21	3.71
	曲线库值	48.33	7.34	270.24	
0.375	实测值	48.04	7.31	258.95	4.17
	曲线库值	48.33	7.34	270.24	
0.625	实测值	48.40	7.53	277.58	7.79
	曲线库值	48.75	7.58	301.03	

图 10(a)为曲线库中匹配的曲线、串联 0.225  $\Omega$  和 0.375  $\Omega$  电阻的实测 I-V 曲线,A,B 和 C 点分别是 3 条曲线对应的最大功率点;图 10(b)为曲线库曲线和串联 0.625  $\Omega$  电阻的实测 I-V 曲线,E 点是该曲线的最大功率点。从图 10 中可以




图 10 老化故障实测  $I-V$  曲线与  $I-V$  曲线库曲线

Fig.10 Measured  $I-V$  curve under aging fault and  $I-V$  curve database

清晰地看到发生老化故障时曲线的变化。在串联  $0.225\ \Omega$  时,曲线未发生较大的变化,最大功率点从 A 点位移到 B 点,其引起的功率变化较小,在与  $I-V$  曲线库中的曲线拟合后,特征差为 3.71%,超出 3.5% 的故障阈值。串联  $0.375\ \Omega$  及  $0.625\ \Omega$  时,由于损失功率增大,拟合后特征差进一步增大至 4.17% 和 7.79%。

综上所述,在发生老化故障时,本文所提出的方法能够准确判断存在故障。

### 3.4 阴影遮挡故障实验

阴影遮挡主要是由于物体遮住光伏组件导致功率衰减,实验用纸板遮住光伏组件来模拟阴影遮挡故障并通过背板监测单元来读取试验数据,试验接线如图 11 所示。

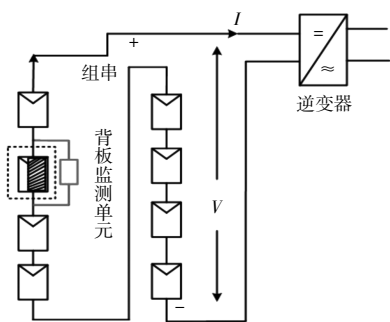


图 11 阴影遮挡示意图

Fig.11 Shadow occlusion diagram

阴影遮挡故障实验对应的实测数据与曲线库数据如表 6 所示。

表 6 阴影遮挡故障数据

Table 6 Data of shadow occlusion failure

曲线	数据来源	$V_{oc}/V$	$I_{sc}/A$	$P_{max}/W$	特征差/%
1	实测值	45.88	4.49	48.65	69.39
	曲线库值	46.04	4.51	158.97	

续表 6

曲线	数据来源	$V_{oc}/V$	$I_{sc}/A$	$P_{max}/W$	特征差/%
2	实测值	45.91	4.75	51.21	69.80
	曲线库值	46.20	4.80	169.59	
3	实测值	46.97	7.45	69.44	74.27
	曲线库值	47.38	7.55	269.98	
4	实测值	46.4	4.55	43.78	73.06
	曲线库值	46.09	4.61	162.50	

图 12 中,实线为曲线库  $I-V$  曲线,虚线为实测数据的  $I-V$  曲线,其中 A, B 分别是两条曲线的最大功率点。从图 12 中可以清晰地看到,当发生阴影遮挡时  $I-V$  曲线的变化,最大功率点发生了较大的变化,从 A 点位移到了 B 点。两者之间偏差较大,大于 69%,远超过设定的 3.5% 的阈值,能够准确判断存在故障。




图 12 阴影遮挡实测数据  $I-V$  曲线与  $I-V$  曲线库曲线

Fig.12 Measured  $I-V$  curve under shadow and  $I-V$  curve database

## 4 结论

本文提出了一种在线监测太阳能组件故障的方法。基于禁忌搜索优化的差分进化算法,提出了模型参数辨识方法。利用模型参数与辐照度、温度的关系,事先构建组件  $I-V$  曲线库,然后测量组件的开路电压及短路电流,匹配库中对应的  $I-V$

曲线,以此逆推出最大功率点功率,并设定3.5%的功率差阈值以判断故障。通过实际的3 200 W太阳能发电系统对本文的研究方法进行验证,相比于文献[17]中采用的功率误差5%阈值,降低了功率误差,提高了故障的识别率。该方法与在线测量太阳能组件运行环境计算理论值的方法相比,消除了环境参数测量带来的误差,提高了故障监测精度,提高了光伏电站运行的可靠性和经济性。

#### 参考文献:

- [1] 沈金荣,惠杰,董炜.基于地理位置相关性的光伏故障监控方法研究[J].可再生能源,2016,34(12):1754-1761.
- [2] 张晓娜,高德东,刘海雄,等.一种新型光伏阵列多传感器故障检测定位方法[J].可再生能源,2016,34(2):166-172.
- [3] Davarifar M, Rabhi A, El-Hajjaji A, et al. Real-time model base fault diagnosis of PV panels using statistical signal processing [A]. International Conference on Renewable Energy Research and Applications(ICRERA) [C].Madrid:IEEE,2013.599-604.
- [4] Kadri R, Andrei H, Gaubert J P, et al. Modeling of the photovoltaic cell circuit parameters for optimum connection model and real-time emulator with partial shadow conditions[J]. Energy,2012,42(23):57-67.
- [5] 刘东,李田泽,刘开石,等.GA-BP神经网络在光伏阵列故障检测中的应用研究[J].电源技术,2021,45(3):370-373.
- [6] 宋文海,李田泽,田晖,等.基于概率神经网络的光伏阵列故障诊断研究[J].电源技术,2019,43(9):1525-1567.
- [7] Chen Z, Han F, Wu L, et al. Random forest based intelligent fault diagnosis for PV arrays using array voltage and string currents [J]. Energy Conversion and Management,2018,178:250-264.
- [8] Wu L, Chen Z, Long C, et al. Parameter extraction of photovoltaic models from measured I-V characteristics curves using a hybrid trust-region reflective algorithm [J]. Applied Energy,2018,232(2):36-53.
- [9] Tifidat K, Maouhoub N, Askar S S, et al. Numerical procedure for accurate simulation of photovoltaic modules performance based on the identification of the single-diode model parameters[J]. Energy Reports,2023(9):5532-5544.
- [10] 徐岩,高兆,朱晓荣.基于人工鱼群和蛙跳混合算法的光伏阵列多场景参数辨识 [J]. 可再生能源,2018,36(4):519-526.
- [11] Siddiqui M, Abido M. Parameter estimation for five- and seven-parameter photovoltaic electrical models using evolutionary algorithms[J]. Applied Soft Computing Journal,2013,13(12):4608-4621.
- [12] Badreddine L, Cherif O, Said D. Modeling and simulation of the thermal behavior and electrical performance of PV modules under different environment and operating conditions [J]. Renewable Energy,2023,219(1):5532-5544.
- [13] Gao X, Cui Y, Hu J, et al. Parameter extraction of solar cell models using improved shuffled complex evolution algorithm [J]. Energy Conversion and Management,2018,157(5):460-79.
- [14] 丁锋,尹晓宇.差分进化算法综述[J].智能系统学报,2017,12(4):431-442.
- [15] 李佳,刘天琪,李兴源,等.改进粒子群-禁忌搜索算法在多目标无功优化中的应用 [J]. 电力自动化设备,2014,34(8):71-77.
- [16] Stein J S, McCaslin S, Hansen C W, et al. Measuring PV system series resistance without full IV curves[A].2014 IEEE 40th Photovoltaic Specialist Conference (PVSC) [C].Denver:IEEE,2014.2032-2036.
- [17] Ducange P, Fazzolari M, Lazzarini B, et al. An intelligent system for detecting faults in photovoltaic fields [A].2011 11th International Conference on Intelligent Systems Design and Applications [C]. Cordoba:IEEE,2011.1341-1346.

## Fault diagnosis method of solar cell based on inverse inference of $I-V$ curves

Zhu Qingyun<sup>1</sup>, Liu Fan<sup>2</sup>, Zeng Wei<sup>3</sup>

(1.Qinghai Provincial Product Quality Inspection and Testing Institute, Xining 810003, China; 2.School of Electrical Engineering, Nanchang Institute of Technology, Nanchang 330099, China; 3.State Grid Jiangxi Electric Power Research Institute, Nanchang 330096, China)

**Abstract:** In this paper, a fault diagnosis strategy for photovoltaic modules based on  $I-V$  curve inverse method is proposed. This strategy does not need to monitor the surface irradiance and average temperature of the solar cell in real time. After extracting the model parameters, the  $I-V$  curve library under different irradiance and solar cell temperature is calculated. The open circuit voltage, short circuit current and maximum power point voltage and current of the photovoltaic module are measured during operation to determine whether the module is faulty. By building experimental equipment to simulate typical faults and using this method to judge, the results show that the method proposed in this paper can effectively monitor the faults of components. Using this method, a single-board fault monitoring module is developed to realize online fault diagnosis of photovoltaic modules, which improves the accuracy of fault diagnosis of photovoltaic modules and the reliability and economy of photovoltaic power station operation.

**Keywords:** solar cell; parameter identification; maximum power point; inverse derivation of  $I-V$  curve