

基于光伏组件内部参数辨识的故障诊断模型

杨宏超, 程若发, 吕彩艳, 李家佳

(南昌航空大学 信息工程学院, 南昌 330063)

摘要: 光伏组件出现故障时, 其内部参数应该最能反映其故障特性, 基于此通过比较不同故障状况下的光伏组件内部参数特性, 提取相应的故障特征; 首先通过 MATLAB 建立光伏组件各故障模型, 通过改进量子粒子群算法对不同故障类型下的光伏组件进行参数辨识并获取相应的数据, 利用数据建立 BP 神经网络故障诊断模型并对故障类型进行诊断; 仿真结果证明所用参数辨识方法可以准确对光伏组件内部参数进行辨识, 诊断结果也表明所选取的故障特征是合理的, 通过此模型可以准确的对光伏组件故障进行诊断。

关键词: 光伏组件; 参数辨识; 量子粒子群; BP 神经网络; 故障诊断

Fault Diagnosis Model of PV Modules Based on Parameter Identification

Yang Hongchao, Cheng Ruofa, Lv Caiyan, Li Jiajia

(School of Information Engineering, Nanchang University of Aeronautics, Nanchang 330063, China)

Abstract: When the PV module fails, its internal parameters should reflect the fault characteristics of the PV module. Based on the comparison of the internal parameters of the PV modules under different fault conditions, the corresponding fault characteristics are extracted. First, the fault models of PV modules are established by MATLAB. Quantum particle swarm algorithm is used to identify the PV modules under different fault types and obtain the corresponding data. The BP neural network fault diagnosis model is established by using the data and the fault type is diagnosed. The simulation results show that the parameter identification method can accurately identify the PV modules parameter characteristics, the diagnostic results also show that the selected fault feature is reasonable, through this model can accurately diagnose the PV module failure.

Keywords: photovoltaic module; parameters identification; QPSO; BP neural network; parameters identification

0 引言

近几年, 随着生态问题的日益突出, 不可再生能源的过度使用, 对环境造成了不小的影响, 比如近几年我国雾霾尤其严重, 这就凸显出清洁可再生能源的重要性了。近年来, 光伏产业作为可再生能源工业的代表, 一直在我们生活的各个领域得到快速发展和应用。但光伏组件的故障直接影响光伏电池输出功率, 所以准确检测光伏组件故障是十分有必要的。

不同型号的光伏组件是由不同特定数量且型号相同的光伏电池单体串联而成, 为了防止光伏电池单体出现故障而成为负载, 通常需要将光伏组件分组并在每组并联一个旁路二极管, 以达到保护电路和降低功率损失。目前对光伏组件进行故障诊断的大部分都是通过提取光伏组件外部特性, 建立光伏组件故障诊断模型进行故障诊断。文献 [1] 采用 S 、 T 、 I_{mp} 和 U_{mp}

作为光伏阵列故障特征, 对光伏组件进行短路和老化的故障诊断; 文献 [2-3] 通过光伏组件故障时组件温度升高的特性, 采用红外图形特性进行光伏组件故障类型诊断。这些故障诊断方法都是通过外部特性, 对光伏组件进行故障诊断的; 本文采用光伏组件内部参数作为故障特征值, 根据不同故障下内部参数变化规律对故障那光伏组件进行故障诊断。利用改进量子粒子群算法对各状况下光伏组件内部参数进行准确辨识, 将辨识数据记录并建立故障诊断模型, 从而准确诊断光伏组件故障类型。

1 光伏组件数学模型与故障输出特性分析

1.1 光伏电池理论模型的提出

光伏电池是利用光生伏特效应对太阳能转变为电能的装置, 其单二极管模型如图 1 所示^[4-5]。




图 1 光伏组件内部参数等效模型

由图 1 得出光伏组件内部参数等效电流和电压表达式:

收稿日期: 2017-07-13; 修回日期: 2017-08-23。

基金项目: 国家基金项目 (51567019); 江西省教育厅项目 (GJJ150757); 江西省科技支撑计划项目 (GB200404114)。

作者简介: 杨宏超 (1991-), 男, 安徽滁州人, 硕士研究生, 主要从事光伏组件参数辨识与故障检测方向的研究。

程若发 (1971-), 男, 安徽六安人, 副教授, 主要从事微电网运行与控制技术方向的研究。

$$I = I_{ph} - I_o \left\{ \exp \left[\frac{q(U + IR_s)}{AKT} \right] - 1 \right\} - \frac{U + IR_s}{R_{sh}} \quad (1)$$

式中, U 为负载两端电压, I 为通过负载的电流, I_{ph} 为光生电流, I_o 为二极管反向饱和电流, A 为二极管影响因子, R_s 为电池串联电阻, R_{sh} 为电池并联电阻, T 为电池的绝对温度, K 为波尔兹曼常数 ($1.38e-23J/K$), q 为电荷常数 ($1.6e-19C$)。

其中 I_{ph} , I_o , A , R_s , R_{sh} 为待辨识参数。光伏组件外部输出电压 V 以及组件外部回路中输出电流 I 可以通过仿真或实验测得。适应值是将识别到模型中的 5 个参数和输出电压计算而得到的电流值和实际电流值的均方根误差。基于以上考虑, 首先应将 (1) 关系式转换为电流的显示表达式, 以便进行适应度值计算。

1.2 目标函数的建立

基于上述光伏组件的理论模型特点, 将改进量子粒子群算法引入其中, 从而准确提取该模型中的未知五参数的值。文献 [6] 引用 Lambert W 函数简化光伏电池电流 I 的显式表达式:

$$I = \frac{R_s R_{sh} (I_{ph} + I_o) - V}{R_s + R_{sh}} - \frac{AV_{th}}{R_s} \times W \left(\frac{R_s R_{sh} I_o}{AV_{th} (R_s + R_{sh})} \exp \left(\frac{R_s R_s (I_{ph} + I_o) + R_{sh} V}{AV_{th} (R_s + R_{sh})} \right) \right) \quad (2)$$

其中:

$W \left(\frac{R_s R_{sh} I_o}{AV_{th} (R_s + R_{sh})} \exp \left(\frac{R_s R_s (I_{ph} + I_o) + R_{sh} V}{AV_{th} (R_s + R_{sh})} \right) \right)$ 为 Lambert W 函数, $V_{th} = KT/q$ 。由式 (2) 进行参数辨识计算。适应度函数如下式 (3) 所示:

$$f(X) = \sqrt{\sum_{i=1}^N (I_{cal} - I_{mea})^2} \quad (3)$$

其中: $X = (I_{ph}, I_o, A, R_s, R_{sh})$, 为每个粒子的位置向量代表 5 个电池模型的参数值。 I_{cal} 和 I_{mea} 分别为算法辨识的参数带入公式 (2) 中所得到的辨识电流值和实际的电流值。适应度值越小表示辨识参数越准确。

1.3 光伏组件故障输出特性分析

设某一光伏组件由 36 个光伏电池串联而成, 其中每 12 个光伏电池并联一个旁路二极管, 如图 2 所示^[7], 图中 I 为光伏组件中流过的电流。




图 2 光伏组件一般结构示意图

光伏组件常见的故障类型主要有短路、开路和老化, 下面对上述 3 种故障类型的故障特性进行分析。

1.3.1 短路故障分析

如图 2 所示, 光伏组件发生短路故障时, 故障所在组对应的旁路二极管不导通, 等效光伏组件的内部参数与短路电池个数满足如下关系:

$$Y_s = (36 - x)Y \quad (4)$$

式中, Y_s 为光伏组件短路时对应的内部参数值; Y 为正常状况下的光伏电池单元内部参数值; x 为光伏电池短路个数; Y 分别代表 A , R_s , R_{sh} 。图 3 为光伏电池短路个数不同条件下的输出特性曲线。




图 3 短路故障输出特性

1.3.2 开路故障分析

如图 2 所示, 光伏组件发生开路故障时, 其对应的旁路二极管导通, 等效光伏组件的内部参数与对应导通二极管满足如下关系:

$$Y_k = (36 - 12n)Y \quad (5)$$

式中, Y_k 为光伏组件开路是对应的内部参数值; Y 为正常状况下的光伏电池单元内部参数值; n 为二极管导通个数; Y 分别代表 A , R_s , R_{sh} 。图 4 为光伏组件开路状况下导通不同二极管个数的输出特性曲线。




图 4 路故障输出特性

1.3.3 老化故障分析

光伏组件发生老化时, 旁路二极管不导通, 组件发生老化时对应的串联电阻会增加, 光伏组件串联电阻存在如下关系:

$$R_s = 36R_c + R_1 + R_2 + \dots + R_i \quad (6)$$

式中: R_s 为光伏组件串联电阻; R_c 为光伏电池单体的串联电阻; R_i 为老化组件对应增加的串联电阻。图 5 为不同串联电阻对应的输出特性曲线。

此外, I_{ph} 和 I_o 随外界变化的计算公式 [] 为:

$$I_{ph} = I_{sc} \left(\frac{S}{1000} \right) + C_T (T - T_{ref}) \quad (7)$$

$$I_o = I_{o-STC} \left(\frac{T}{T_{ref}} \right)^3 e^{\left[\frac{qE_g}{Ak} \left(\frac{1}{T_{ref}} - \frac{1}{T} \right) \right]} \quad (8)$$

式中, I_{sc} 为短路电流, S 为光照强度, C_T 为温度系数, T 为绝对温度, T_{ref} 为标况下的绝对温度, I_{o-STC} 为标况下的反向饱和电流, E_g 能带系能量。

综上所述, 通过参数辨识出的参数值作为故障特征可以准




图 5 老化故障输出特性

确区分出各故障类型。

2 算法介绍

2.1 改进量子粒子群参数辨识算法

由于在 QPSO 算法中的种群初始化是采用随机分布的, 所以种群初始化存在一定的局限性, 无法遍历整个区域。从而提出对其种群进行混沌初始化, 以提高粒子初始化遍历范围, 同时在寻优过程中对局部最优解进行混沌化处理, 以防止陷入局部最优解。混沌学由 E. N. 洛伦兹提出, 由于混沌状态与一般的无规则状态不同, 其主要特征有规律性, 随机性和遍历性, 所以混沌理论已经成为一个新的和潜在的优化工具。由于混沌序列具有上述优点, 因此利用混沌序列用于初始化粒子, 可以提高粒子初始化的遍历性, 从而为寻优精度和收敛速度奠定基础。Logistic 混沌方程^[8]如公式 (10) 所示:

$$Z_{i+1} = \mu Z_i (1 - Z_i), i = 0, 1, 2, \dots, \mu \in [0, 4] \quad (10)$$

式中, $0 \leq Z_i \leq 1, Z_i$ 为第 i 个变化量。 μ 为控制系数。

综上, 改进 QPSO 算法步骤如下:

- 1) 初始化算法的相关参数, 如种群的大小、变量的个数、惯性因子、迭代次数、速度和位置的范围限定等。
- 2) 采用式 (10) 对种群进行混沌初始化, 增加初始种群整体的遍历性。
- 3) 通过适应度函数计算每个粒子的当前适应度值, 并与对应于个体历史最优解的值进行比较。如果当前适应度值优于对应个体历史最优解对应的适应度值时, 就把当前解替换成为个体最优解 $pBest_i$, 否则就不替换。
- 4) 将所有粒子最优的适应值进行比较从而确定当前种群的最优解 $gBest$ 。
- 5) 更新每个粒子的位置, 计算每个粒子的适应值, 保留群体中最优适应度值对应的粒子位置。
- 6) 对群体中的最佳粒子再执行一次混沌优化算法, 并更新其 $pBest$ 和群体 $gBest$ 。
- 7) 根据算法中设置的精度要求和最大迭代次数确定当前迭代是否满足要求, 如果没有达到, 就返回 3) 继续迭代; 相反则停止迭代, 输出全局最优解是

$$X = (I_{ph}, I_o, A, R_s, R_{sh})$$

2.2 BP 神经网络故障诊断算法

BP 网络是一种按误差反向传播的多层前馈网络。其学习规则是使用最速下降法, 通过反向传播来不断调整网络的权值和阈值, 使网络的误差平方和最小。BP 网络的优点是只要有

足够的隐含层和隐节点, BP 网络可以逼近任意的非线性映射关系, 属于全局逼近算法并具有良好的泛化能力^[9]。BP 神经网络的基本结构包括输入层、隐含层和输出层 3 个部分。基于 BP 神经网络光伏组件故障诊断模型的对应关系如图 6 所示




图 6 BP 神经网络故障诊断结构图

通过分析可知, 本文光伏组件故障诊断模型的输入层为参数辨识算法辨识出的内部 5 参数, 对应输出 4 个诊断结果, 故障类型输出定义表如表 1 所示。具体参数训练方法参见文献^[10]。

表 1 故障类型输出层定义表

编号	O3	O2	O1	诊断输出
1	0	0	1	正常
2	0	1	0	短路
3	0	1	1	开路
4	1	0	0	老化

3 仿真结果与分析

3.1 光伏组件参数辨识算法验证

根据光伏组件五参数特性, 在 MATLAB/Simulink 中建立光伏组件仿真模型^[11], 得出相应的参数辨识数据。模型中光伏组件标况下 ($T = 25 \text{ }^\circ\text{C}, S = 1000 \text{ W/m}^2$) 的电气参数为 $I_m = 2.7888, V_m = 18.85, V_{oc} = 23.40, I_{sc} = 3$; 为了验证上述参数辨识方法的精确性和快速性, 对仿真模型在标况下的一组数据采用 PSO, QPSO 和 CQPSO 三种方法分别进行辨识并做对比试验, 试验都迭代 100 次, 由于适应度函数值大小直接可以反映出参数辨识的精度, 图 7 为不同方法迭代后的适应度值变化图, 表 2 为不同算法辨识出的光伏组件参数值, 结合表 2 和图 7 的相关数据和图像显示可得出, CQPSO 算法适应度值

表 2 不同算法辨识的光伏组件参数值

参数	PSO	QPSO	CQPSO
I_{ph}	2.972	2.989	2.998
I_o	$9.86e-6$	$8.134e-7$	$1.285e-8$
A	46.892	47.238	47.682
R_s	0.3546	0.3861	0.3942
R_{sh}	1126.45	982.46	993.57
最优迭代次数	8	36	15
最优适应度值	0.58942	0.18563	0.05286




图 7 不同算法寻优适应度值结果对比图

为 0.052 86, 相比于 PSO 的 0.589 42 收敛精度要高许多, 且迭代次数只需要 15 次便收敛了, 所以改进量子粒子群算法既能避免的陷入局部最优提高了收敛精度又加快了收敛的速度, 说明此算法可以准确地对光伏组件内部参数进行辨识且优化了其他算法易陷入局部最优和迭代次数过多的问题。

3.2 光伏组件故障诊断

在 MATLAB/Simulink 中建立个故障类型的等效模型, 通过参数辨识算法对不同工况下的不同故障类型辨识内部参数并记录, 用作 BP 神经网络的训练数据。本文共记录温度范围在 20~50 C°, 光照强度范围在 200~1 000 W/m² 的 400 组数据, 其中 300 组作为训练样本, 剩余 100 组作为测试样本。由于所选故障特征值变量具有不同的数量单位, 直接进行神经网络训练会使网络的性能和收敛性变差, 因此在训练之前须对各数据值进行归一化处理, 有利于 BP 算法在运行后期加快收敛。本文 BP 神经网络中输入节点数为 5, 输出节点数为 4, 经过多次试验当隐含层节点为 8 时, 模型最为稳定, 网络训练次数为 200 次, 学习效率设为 0.1。完成网络训练后, 利用测试数据对故障模型进行测试。如表 3 为对应不同故障下的部分测试数据, 表 4 为对应的诊断结果。

表 3 光伏组件故障诊断模型的测试样本

故障类型	BP 神经网络输入层数据				
	I_{ph}/A	I_o/A	A	R_s/Ω	R_{sh}/Ω
正常	1.5080	2.3132e-8	45.87	0.3856	957.82
短路	2.2742	3.0068e-8	38.41	0.3161	805.63
开路	2.6352	3.0106e-8	15.89	0.1308	346.45
老化	1.9352	1.3195e-8	45.83	0.4905	876.36

表 4 BP 神经网络算法的诊断结果

编号	BP 神经网络输出层数据			诊断向量	故障类型
	O1	O2	O3		
1	0.9345	0.0263	0.0341	100	正常
2	0.0235	0.8524	0.0582	010	短路
3	0.0467	0.7382	0.8257	011	开路
4	0.0765	0.0428	0.8721	001	老化

对比表 3 和表 4 的仿真结果可知, 诊断结果与测试样本的故障类型一致, 说明 BP 神经网络可以对不同的光伏组件故障

进行准确分类, 同时也证明了本文对光伏组件故障特征的提取是正确且可行的。

4 结论

本文建立了一种基于光伏组件内部参数辨识的故障诊断模型, 首先通过改进量子粒子群算法, 准确辨识出各故障类型下的光伏组件内部参数 (I_{ph} , I_o , A , R_s , R_{sh}), 再通过分析各故障类型下内部参数变化规律, 提取相应的故障特征, 通过仿真建立光伏组件故障诊断模型, 对不同故障类型进行分类和诊断。通过仿真结果可以看出, 本文采取的参数辨识算法能够准确的辨识出光伏组件内部参数; 并通过比较正常、短路、开路、老化的内部参数特性, 建立的故障诊断模型可以很好的区分不同的故障类型, 说明此方法的有效性和可行性。但由于组件短路与开路故障特性有些相似, 只是数量上有些不同, 所以当出现大范围短路时, 通过内部参数建立的故障模型还是不容易区分短路还是开路故障, 所以下一步将进一步研究是否可以通过加入适量外部特性, 从而可以进一步准确诊断光伏组件故障特性。

参考文献:

- [1] 王元章, 吴春华, 周笛青, 等. 基于 BP 神经网络的光伏阵列故障诊断研究 [J]. 电力系统保护与控制, 2013, 41 (16): 108-114.
- [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): 197-201.
- [3] Nian Bei, Fu Zhizhong. Automatic detection of defects in solar modules; image processing in detecting [A]. International Conference on Wireless Communications Networking and Mobile Computing [C]. Chengdu, China: IEEE, 2010: 1-4.
- [4] Green M A. Photovoltaic principles [J]. Physica E: Low-dimensional Systems and Nanostructures, 2002, 14 (1): 11-17.
- [5] Saravanan C, Panneerselvam M A. A comprehensive analysis for extracting single diode PV model parameters by hybrid GA-PSO algorithm [J]. International Journal of Computer Applications, 2013, 78 (8): 16-19.
- [6] 程 泽, 董梦男, 杨添凯, 等. 基于自适应混沌粒子群算法的光伏电池模型参数辨识 [J]. 电工技术学报, 2014, 29 (9): 245-252.
- [7] 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.
- [8] 王振树, 卞绍润, 刘晓宇, 等. 基于混沌与量子粒子群算法相结合的负荷模型参数辨识研究 [J]. 电工技术学报, 2014, 39 (4): 1504-1514.
- [9] 龙 泉, 刘永前, 杨勇平. 基于粒子群优化 BP 神经网络的风电机齿轮箱故障诊断方法 [J]. 太阳能学报, 2012, 33 (1): 120-125.
- [10] 韩力群. 神经网络教程 [M]. 北京: 北京邮电大学出版社, 2006.
- [11] 赵 乐, 张彦晓. 基于 Simulink 光伏电池建模及其输出特性仿真研究 [J]. 现代电子技术, 2014, 33 (11): 125-128.