

基于小波包和支持向量机的逆变器故障诊断

田 维, 崔博文

(集美大学轮机工程学院, 福建 厦门 361021)

[摘要] 针对逆变器功率元件经常出现的开路故障, 提出一种基于小波包分解和支持向量机的故障诊断方法。利用小波包对逆变器输入电流进行分解, 获得电流信号各层细节系数、能量以及偏移量。对分解得来的参数进行相应的归一化处理, 得到逆变器功率开关元件不同故障状态下的故障特征。将其各自作为多分类支持向量机的输入量来训练多分类支持向量机。通过模拟实验证明, 该方法在诊断和定位故障上具有较高精度和效率。

[关键词] 逆变器; 开路故障; 故障诊断; 小波包; 支持向量机

[中图分类号] TM 464

Faults Diagnosis of Inverter Based on Wavelet Packet Decomposition and SVM

TIAN Wei, CUI Bowen

(School of Marine Engineering, Jimei University, Xiamen 361021, China)

Abstract: Aimed at open-circuit (OC) fault of power device in the inverter, the paper proposed a fault diagnosis method to isolate OC faults occurred in the inverter. Wavelet Packet was used to decompose three-phase current of the inverter, detail coefficients, energy and offset with current in different layer were obtained. Normalizing all these parameters, fault features with different OC faults occurred in the inverter were obtained. Multi-class classification Support Vector Machine (SVM) was trained by using all these fault features. Experimental results of simulation show that the method can diagnose and locate fault power device with high precision and efficiency.

Keywords: inverter; open-circuit faults diagnosis; fault diagnosis; wavelet packet decomposition; SVM

0 引言

随着新能源技术的发展, 逆变器应用日趋广泛, 功率开关元件作为逆变器核心元件之一, 其工作的稳定性十分重要, 因此对功率开关元件故障诊断的研究显得尤为必要。文献 [1-2] 提出输出三相电流转换到 $d-q$ 坐标, 并进行帕克变换的开路故障诊断方法, 这种方法主要是对比正常情况下的电流和逆变器瞬时输出电流。采用帕克变换进行故障诊断比较简单而且及时, 但这种方法对测量和观察设备要求很高, 加大了故障诊断的成本。文献 [3-4] 采用了基于主成分分析法的开路故障诊断方法, 能快速发现逆变器是否出现故障, 但当出现两个故障元件时, 难以准确定位故障。文献 [5-

[收稿日期] 2018-12-05

[基金项目] 国家自然科学基金资助项目 (51779102)

[作者简介] 田维 (1986—), 男, 硕士生, 从事逆变器故障诊断。通信作者: 崔博文 (1966—), 男, 教授, 博士, 从事电力系统状态监控与参数估计研究

6], 采用单个多分类支持向量机的分类方法, 能比较准确的对故障进行定位, 但在故障种类较多时, 会出现分类次数多, 故障诊断时间长的问题。

本文提出了基于小波包分解的多个多分类支持向量机故障定位方法。通过获取逆变器三相离散电流波形, 再利用最小描述长度准则 (MDL)^[7], 选取适合的小波包函数, 对获得的电流波形进行三维小波包分解, 获得多种故障特征值, 不同的故障特征值用于训练不同多分类支持向量机 (SVM), 再结合每个多分类 SVM 的分类结果, 共同定位故障。本文方法对比于单个多分类支持向量机的方法, SVM 的训练数据具有更高区分度, 寻优时间更短, 分类次数更少。

1 逆变器故障模式

以功率开关元件为基础的 (PWM) 三相逆变系统为模型进行讨论。电路按文献 [8] 设计, 逆变器驱动的电动机变频调速系统如图 1 所示。其中: V_d 为电压; a, b, c 为三相绕组与逆变桥联结点。由于功率开关元件技术的发展, 其故障存在如下几种类别: 一只功率开关元件断路故障; 两只功率开关元件同时断路故障; 为了更全面的分类, 本文将无故障也设为一类。

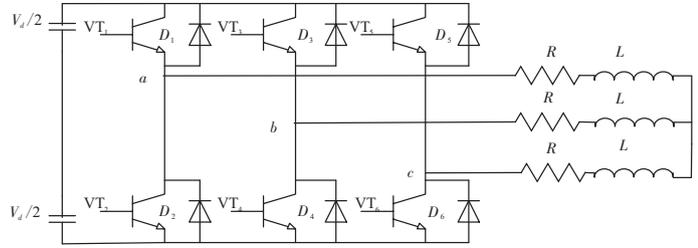


图 1 逆变器驱动的电动机系统

Fig.1 Schematics of inverter-fed motor drive system

为方便分类, 将元件状态分为以下 5 类:

- 1) 无故障, 故障编码设为 F_0 。
 - 2) 同一桥臂两个功率开关元件同时开路故障, 有 3 种故障, 即 VT_1 和 VT_2 、 VT_3 和 VT_4 、 VT_5 和 VT_6 开路故障, 故障编码分别设为 F_1 、 F_2 、 F_3 。
 - 3) 一个功率开关元件开路故障, 有 6 种故障, 即 VT_1 、 VT_2 、 VT_3 、 VT_4 、 VT_5 、 VT_6 开路故障, 故障编码分别设为 F_4 、 F_5 、 F_6 、 F_7 、 F_8 、 F_9 。
 - 4) 上、下两组元件各一只功率开关元件开路故障, 有 6 种故障, 即 VT_1 和 VT_3 、 VT_1 和 VT_5 、 VT_3 和 VT_5 、 VT_2 和 VT_4 、 VT_2 和 VT_6 、 VT_4 和 VT_6 开路故障, 故障编码分别设为 F_{10} 、 F_{11} 、 F_{12} 、 F_{13} 、 F_{14} 、 F_{15} 。
 - 5) 交叉两只功率开关元件开路故障, 有 6 种故障, 即 VT_1 和 VT_4 、 VT_2 和 VT_3 、 VT_1 和 VT_6 、 VT_2 和 VT_5 、 VT_3 和 VT_6 、 VT_4 和 VT_5 开路故障, 故障编码分别设为 F_{16} 、 F_{17} 、 F_{18} 、 F_{19} 、 F_{20} 、 F_{21} 。
- 一共 21 种故障状态和一种正常状态, 本文以这 22 种状态为研究对象。

2 基于最小描述长度准则的多维小波包分解

逆变器输出电流信号由各种频率的电流组成, 其中高频和低频部分都含有重要信息, 可以进一步分解。选取小波包变换有利于故障定位, 小波包分解结构如图 2 所示。为了更好地选择小波包分解函数, 用最小描述长度 (MDL) 数据准则来选择最佳小波滤波器和保留用于信号重建的最佳小波系数。MDL 函数定义为:

$$MDL(j, n) = \min \{ 3j(\log N)/2 + N \| \alpha - \alpha_n^j \|^2 / 2 \} \tag{1}$$

式中: n 为小波包滤波器的数量; j 为要保留的系数的大小, $0 \leq j \leq N, 1 \leq j \leq M$, N 和 M 分别表示信号的长度和小波包滤波器的总数; α 表示通过小波滤波器的离散信号 $f(n)$ 的分解系数的矢量, $\alpha_n^j = \alpha \Theta^j$ 表示包含的第 j 个非零元素矢量, Θ^j 是一个硬阈值^[9]操作, 它将 α 的第 j 个最大元素保持绝对值, 并将所有其他元素保持为零。通过使用式 (1) 的准则进行了搜索, 选取了小波基 “db11” 作为本次分解的最优母小波。

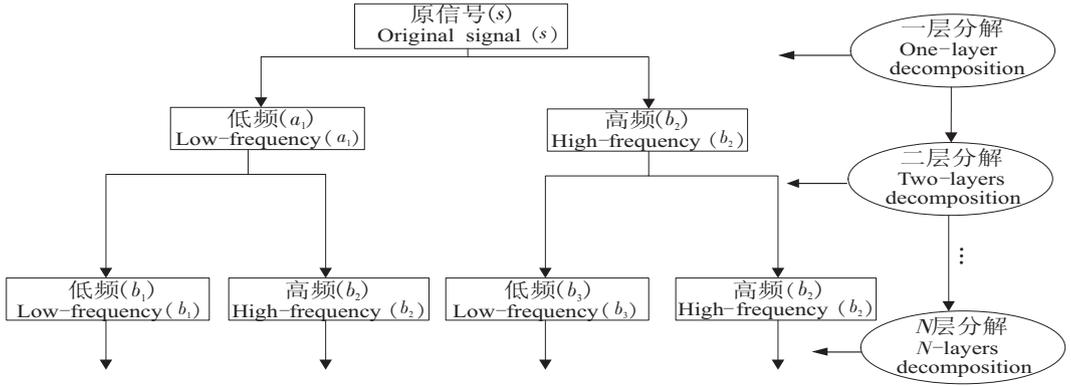


图2 小波包分解结构图

Fig.2 A decomposition structure diagram of a wavelet packet

然后把采集的 a 、 b 、 c 三相离散电流信号, 作为小波包函数的 3 组输入信号, 进行 3 层小波包分解。其中: a 相电流为第一维; b 、 c 分别对应二、三维。VT₂ 故障信号分解如图 3 所示。图 3 是对 VT₂ 故障的第一维的 3 层小波分解, 得到 $S_{30} \sim S_{37}$ 8 个子频带。其他故障状态也是以同样方式进行分解。

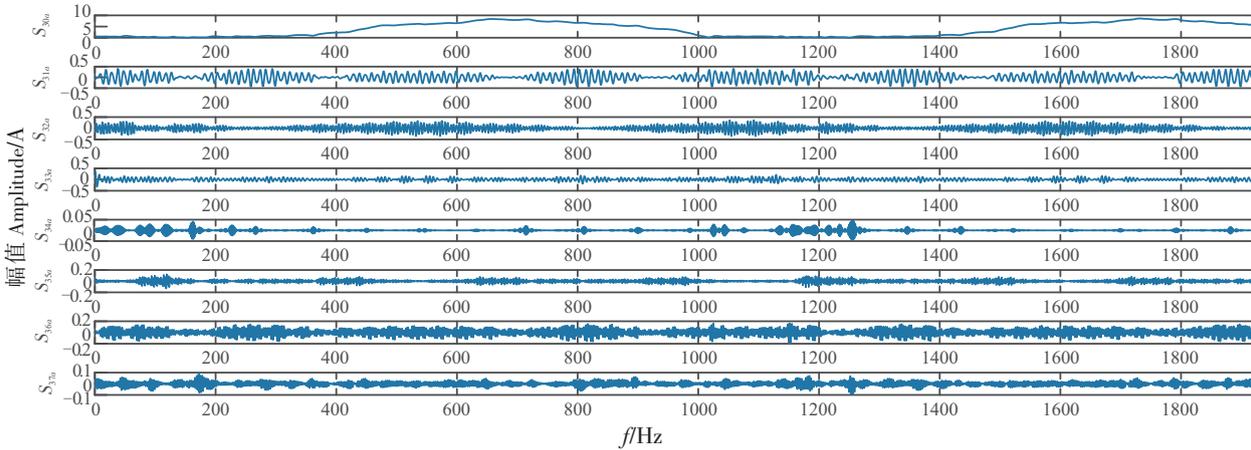


图3 VT₂ 故障第一维 3 层小波包分解

Fig.3 The first dimension 3-layer wavelet packet decomposition of VT₂ fault

3 逆变电路故障特征提取

利用小波包对三相电流进行 3 层分解, 得到 8 个频带成分系数, 用系数构成矩阵, 表示为, $S_{3j} = (s_{3ja} \quad s_{3jb} \quad s_{3jc})$, 其中 $j = 0, 1, \dots, 7$ 。本文提取了 3 组故障特征值, 分别作为分类器的输入量, 其步骤如下。

1) 计算局部能量向量组: $E_{3j} = (e_{3ja} \quad e_{3jb} \quad e_{3jc})$, 其中 $j = 0, \dots, 7$ 。根据正交小波包性质, 分解后信号可以表示为:

$$g_j^n = \sum_l d_l^n u_n (2^j t - l)^{[9]} \quad (2)$$

式中: n 表示采集信号长度; t 为采集信号对应的时间; j 表示子频带; l 表示离散点; d_l^n 是分解信号序列 S_{3j} 第 l 个离散点所得的系数; u_n 是所选小波包函数。

因此其中一维某一个子频带能量计算式可表示为:

$$E_{3j} = \sum_{i=1}^n |d_i^j|^2 \quad (3)$$

式中: j 表示子频带, $i = 1, 2, \dots, 7$ 表示采样点; d_i^j 为分解得到的系数。

按式 (3) 求得能量矩阵 E_{3j} ，再求每一列的矩阵元素和，令其为 $E_{sum} = (e_{suma} \quad e_{sumb} \quad e_{sumc})$ ，然后对各频带能量进行归一化处理，即 $E_{noj} = (e_{3ja}/e_{suma} \quad e_{3jb}/e_{sumb} \quad e_{3jc}/e_{sumc})$, $j = 0, \dots, 7$ 。部分故障小波包分解后能量归一化处理如图 4 所示，根据数据分析，其中当 $j=0, 4$ 时， E_{no0}, E_{no4} 能作为故障特征值。

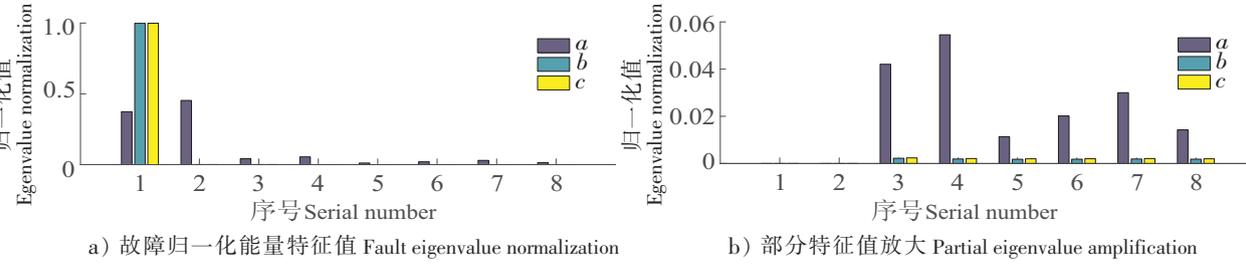


图 4 VT₁, VT₂ 故障特征值归一化
Fig.4 VT₁, VT₂ fault eigenvalue normalization

2) 根据文献 [11 - 12]，直流偏移量可以作为故障特征值，其矩阵表达式为：

$$F_1 = [\bar{M}_{a>0}/(\bar{M}_{a>0} + \bar{M}_{a<0}) \quad \bar{M}_{b>0}/(\bar{M}_{b>0} + \bar{M}_{b<0}) \quad \bar{M}_{c>0}/(\bar{M}_{c>0} + \bar{M}_{c<0})]。 \quad (4)$$

式中： $\bar{M}_{x>0}$ ($x = a, b, c$) 表示电流正值平均值； $\bar{M}_{x<0}$ ($x = a, b, c$) 表示电流负值平均值； x 为 a, b, c 三相电流其中一相。根据小波包分解性质，分解的频率越低，越能表现出直流的部分特征，因此这里把 S_{30} 作为偏移量的特征值。结合小波包分析理论得低频偏移值

$$S_{Njx} = \sum_{i=1}^n d_i^j = \bar{M}_{x>0}(x = a, b, c)。 \quad (5)$$

式中： N 为分解层数， $j = 1, \dots, 2^N$ ； n 为采样总数。结合式 (4)，式 (5)，取 $N = 3, j = 0$ 时，可得偏移量矩阵 $F_{30} = (S_{30a} \quad S_{30b} \quad S_{30c})$ 。

图 5 为 VT₁ 和 VT₄ 发生故障时低频的三维偏移图，可以看到，一维和二维都发生了相应的偏移。

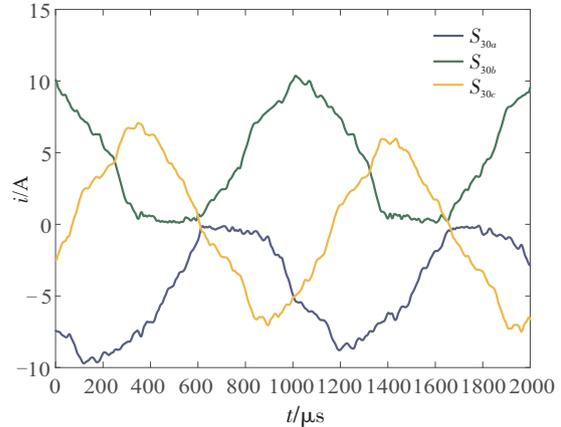


图 5 VT₄ 故障 S_{30} 特征偏移波形
Fig.5 VT₄ fault eigenvalue shifting waveform

4 基于支持向量机 (SVM) 的故障分离

支持向量机是基于二分类的分类器，其算法的关键在于，“支持向量” $x(i)$ 和输入空间抽取的向量 x 之间的内积和，用于寻找最优分割面。该算法在理论上比较完善，设计比较简单，在模式分类问题上有较好的泛化性能，具有通用性和鲁棒性，适合解决分类问题。SVM 模型训练流程如图 6 所示。

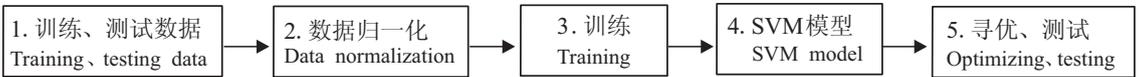


图 6 SVM 模型训练流程图
Fig.6 SVM model training flow-process diagram

SVM 的训练^[13-14]最终可以转化为拉格朗日凸函数二次寻优问题，其函数 $w(\alpha)$ 表达式如下：

$$\begin{cases} \min & w(\alpha) = \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) / 2 - \sum_{i=1}^n \alpha_i; \\ \text{s. t.} & \sum_{i=1}^n y_i \alpha_i = 0, \quad 0 \leq \alpha_i, \quad i = 1, \dots, n。 \end{cases} \quad (6)$$

式中: $K(x_i, x_j)$ 为核函数; α_i 为拉格朗日因子; y_i 为分类标签; n 为分类数据个数。

式 (6) 要满足 α_i 大于零, 所有拉格朗日因子与其标签的乘积和为零。

从式 (6) 可以看出, 当 n 取值较大, 也就是分类数据量大时, 计算量会增大, 计算时间因此增多, 导致了部分样本数据互相交叉存在和分类边界不明确的现象, 会带来两方面问题:

1) SVM 的核函数以及参数选择要求较高, 不容易找到最优超平面引起的分类失败或错误, 特别在扰动较多的场合中, 更易导致分类失败;

2) 分组多, 数据区分小, 使得寻优和测试阶段时间加长。

实践中, 采用单个多类 SVM 对 22 种状态进行分类时^[15], 在特征值相同的情况下, 分类模式越多, 训练多分类的 SVM 时间变长, 分类错误和失败率更高。为优化上述问题, 本文提出用多组特征值分别训练多分类 SVM, 每个多分类 SVM 以不同数据训练并分类, 最后结合编程定位故障, 以达到提高准确率和减少整个运行时间的目的, 其模型如 7 所示。

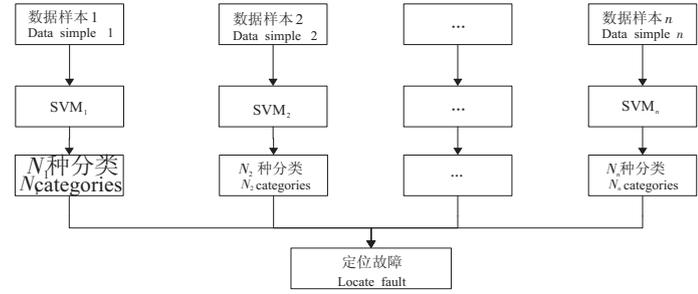


图 7 多个多分类 SVM 故障定位模型

Fig.7 Multi-SVM s fault location model

5 基于小波包和多 SVM 的故障分离实验

以图 1 所示的电机系统为例, 具体参数为: 频率 $f = 50 \text{ Hz}$; 载波比 $R = 18$; 调制深度 $M = 0.85$; 磁极对数 $P = 2$; $R_s = 1.49 \Omega$; $L_s = 0.005839 \text{ H}$; $V = 440 \text{ V}$ 。

为实现减少分类次数的目标, 根据系统的性质和桥臂与电力的关联性, 首先对逆变器功率开关进行分类: 1) VT_1 、 VT_2 对应 a 组, VT_3 、 VT_4 对应 b 组, VT_5 、 VT_6 对应 c 组; 2) VT_1 、 VT_3 、 VT_5 对应上组, VT_2 、 VT_4 、 VT_6 对应下组, 如图 8 所示。

SVM 训练步骤如下。

1) 训练集和测试集准备: 小波包分解得到的数据 E_{no0} 、 E_{no4} 、 F_{30} 作为多个多分类 SVM 的输入量, 为方便表示, 分别用 U 、 V 、 W 按前后顺序代替, 用来分别训练 4 个多分类 SVM。各多分类 SVM 命名、输入参数、分类标签等如表 1 所示。同时 $SVM_3(W)$ 和 $SVM_4(W)$ 虽然是同一组数据, 但它们的训练集是不同的。作为对比, 本文按文献 [16] 方法进行单个多分类 SVM 故障定位, 训练集是 W 组数据。

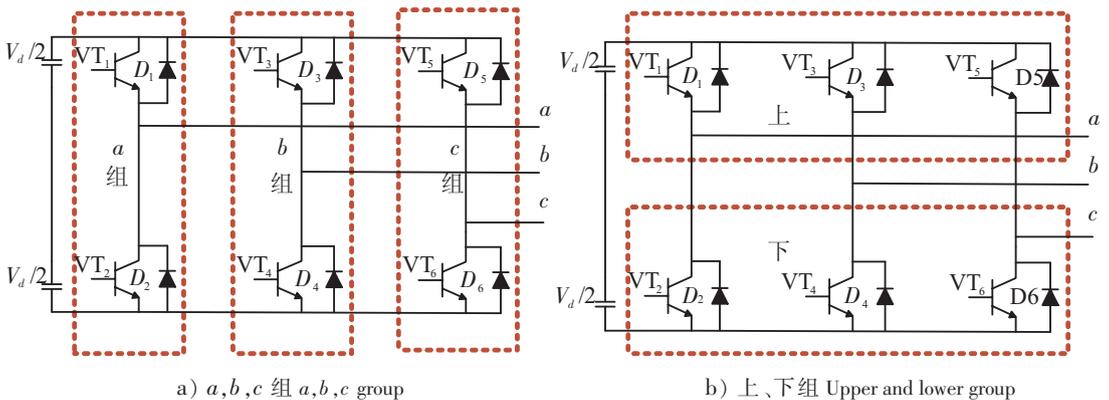


图 8 功率开关分组

Fig.8 Power switch block

表 1 各多分类 SVM 简要说明
Tab. 1 Summary tables for each SVM

输入参数(说明) Input parameters (explanation)	部分元件 Partial element	一维 The Fir - D	二维 The sec - D	三维 The Thir - D	分类标签 Classify Label
SVM ₁ (U) U(同一相) (The same phase)	VT ₁ , VT ₂	0.38	0.99	0.99	30 - 33
	VT ₃ , VT ₄	0.99	0.40	0.99	
SVM ₂ (V) V(a,b,c 组)(a,b,c group)	VT ₁ (a 组)(a group)	0.96	0.31	0.29	40 - 46
	VT ₂ (a 组)(a group)	0.97	0.33	0.29	
	VT ₂ , VT ₅ (a,c 组)(a,c group)	0.97	0.39	0.91	
SVM ₃ (W) W(上、下组) (Upper and lower group)	VT ₁	-0.81	0.21	0.29	50 - 52
	VT ₁ , VT ₅	-0.83	0.22	-0.79	
	VT ₁ , VT ₆	-0.81	0.22	0.79	
SVM ₄ (W) W(上组) (Upper group)	VT ₁ , VT ₄	-0.82	0.83	0.10	60 - 62
	VT ₂ , VT ₃	0.83	-0.83	0.09	

2) 归一化: 本文应用了映射 $f: x \rightarrow y = (x - x_{\min}) / (x_{\max} - x_{\min})$ 作为归一化方式。

3) 训练、寻优: 5 个多分类 SVM 都采用径向基函数作为核函数, 每一个多分类 SVM 的每一种分类都是 20 组训练集数据, 这样利用本文方法有 340 组训练集, 文献 [16] 的方法有 440 组训练集。为了在同样的数据量下对比正确率, 两种方法的测试集都设为 340 组。由于惩罚参数 c 和核函数参数 g 对训练集准确率影响大, 所以为了提高判断的正确率, 本文通过交叉验证进行了两个参数的寻优。

4) 测试: 输入测试集, 获得测试的正确率和程序判断时间。限于篇幅, 仅列出 SVM₄(W) 的测试图, 如图 9 所示。

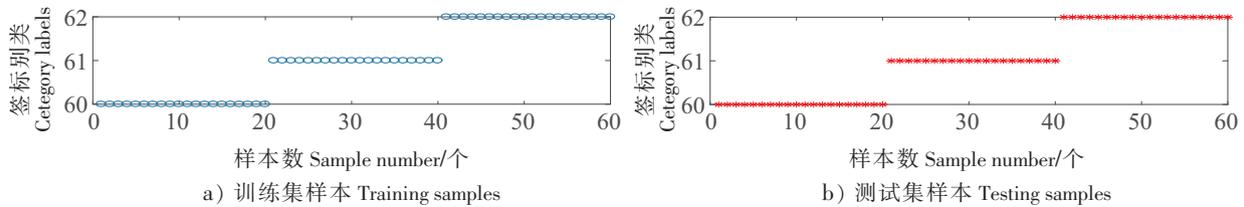


图 9 svm₄(w) 训练测试

Fig.9 svm₄(w) training-testing

4 个多分类 SVM 的训练模式如图 10 所示。其中: a, b, c 分别表示 a 组、 b 组及 c 组中有开关元件发生开路故障, ab 表示 a 组和 b 组中各有一个元件发生故障, ac 表示 a 组和 c 组中各有一个元件发生故障; bc 表示 b 组和 c 组中各有一个元件发生故障。根据这个模式再结合表 2, 编写 MATLAB 程序, 进而定位故障点, 并统计程序运行时间和判断正确率。

表 2 中: \checkmark 代表 SVM 分出该标签; \times 代表 SVM 没有分出该标签; 空格代表该 SVM 分出的标签不影响故障定位。以 F_{15} 为例: SVM₁(U) 分出的标签为 33, SVM₂(V) 分出的标签为 46, SVM₃(W) 分出的标签为 51, 共同定位故障 F_{15} , SVM₄(W) 因程序设置原因, 分类结果不影响定位。

经过 MATLAB 模拟实验, 得到了如下实验结果:

1) SVM₁(U)、SVM₃(W)、SVM₄(W) 分类正确率为 100%, SVM₂(U) 140 个测试集中, 错误判断有 5 个, 分类正确率为 96.4%。而相对于整个程序的 340 组测试集, 本文方法的正确率为 98.5%。用文献 [16] 方法错误判断有 21 个, 分类正确率为 93.8%;

2) 在执行时间上, 采用本文方法在训练和寻优阶段所用时间一共为 2.67 s, 而采用文献 [16] 方法的分类训练和寻优共用时 5.33 s。采用 4 个多分类 SVM 一共分类 17 次, 而采用单个多分类 SVM, 少则分类 22 次, 多则分类 44 次。

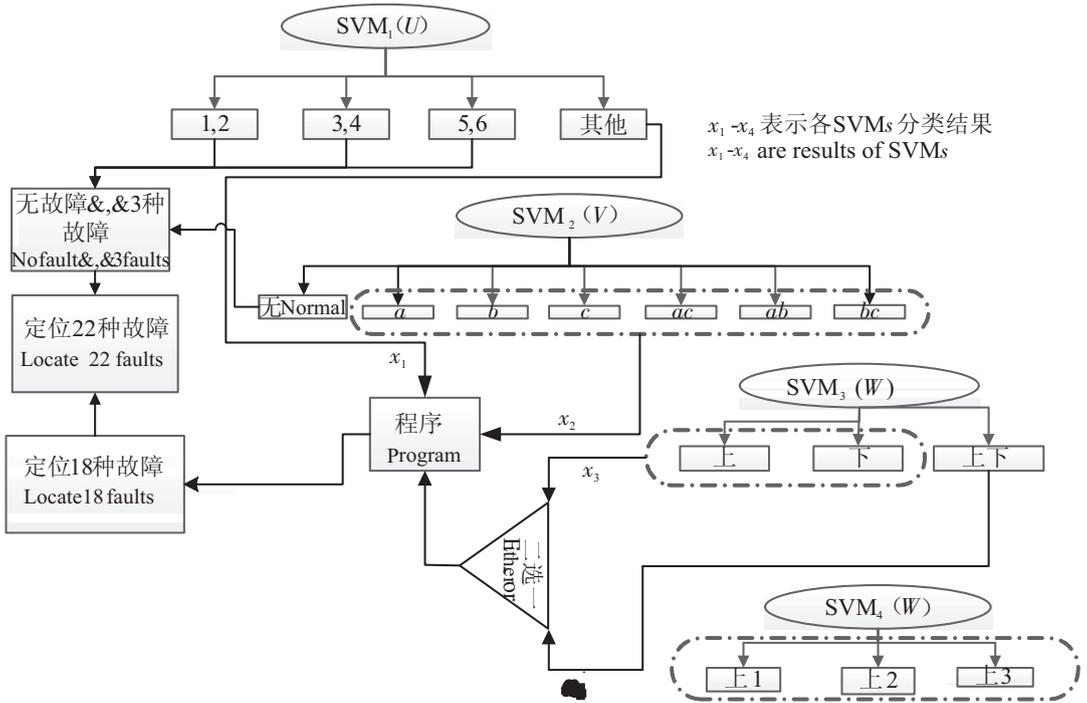


图 10 多个多分类 SVM 故障定位模型

Fig.10 Fault locating model for multi-SVMs model

表 2 故障定位参考表格

Tab.2 Fault locating reference table

故障 Fault	SVM ₁ (U)				SVM ₂ (V)								SVM ₃ (W)			SVM ₄ (W)		
	30	31	32	33	40	41	42	43	44	45	46	50	51	52	60	61	62	
F_0	×	×	×	√	√	×	×	×	×	×	×	×	×	×				
F_1	√	×	×	×	×	×	×	×	×	×	×	×	×	×				
F_2	×	√	×	×	×	×	×	×	×	×	×	×	×	×				
F_3	×	×	√	×	×	×	×	×	×	×	×	×	×	×				
F_4	×	×	×	√	×	√	×	×	×	×	×	√	×	×				
F_5	×	×	×	√	×	√	×	×	×	×	×	×	√	×				
F_6	×	×	×	√	×	×	√	×	×	×	×	√	×	×				
F_7	×	×	×	√	×	×	√	×	×	×	×	×	√	×				
F_8	×	×	×	√	×	×	×	√	×	×	×	√	×	×				
F_9	×	×	×	√	×	×	×	√	×	×	×	×	√	×				
F_{10}	×	×	×	√	×	×	×	×	√	×	×	√	×	×				
F_{11}	×	×	×	√	×	×	×	×	×	√	×	√	×	×				
F_{12}	×	×	×	√	×	×	×	×	×	×	√	√	×	×				
F_{13}	×	×	×	√	×	×	×	×	×	√	×	×	√	×				
F_{14}	×	×	×	√	×	×	×	×	×	×	√	×	√	×				
F_{15}	×	×	×	√	×	×	×	×	×	×	√	×	√	×				
F_{16}	×	×	×	√	×	×	×	×	√	×	×	×	×	√	√	×	×	
F_{17}	×	×	×	√	×	×	×	×	√	×	×	×	×	√	×	√	×	
F_{18}	×	×	×	√	×	×	×	×	×	√	×	×	×	√	√	×	×	
F_{19}	×	×	×	√	×	×	×	×	×	√	×	×	×	√	×	×	√	
F_{20}	×	×	×	√	×	×	×	×	×	×	√	×	×	√	×	√	×	
F_{21}	×	×	×	√	×	×	×	×	×	×	√	×	×	√	×	×	×	

6 结论

本文研究了基于小波包分解的多个多分类 SVM 故障诊断方法。利用小波包分解三相电流值, 得到 E_{30} 、 E_{34} 和 S_{30} 的偏移量作为输入量, 分别训练多个多分类 SVM。再把每一个多分类 SVM 分类的结果结合程序, 最终定位故障点。通过模拟实验证明, 采用本文方法, 数据有更大的分辨率, 分类次数得到减少, 故障诊断时间得到减少, 正确率得到了提高, 适合有扰动的场合。

[参 考 文 献]

- [1] ESTIMA J O, Cardoso A J M. A new approach for real-time multiple open-circuit fault diagnosis in voltage-source inverters [J]. IEEE Transactions on Industry Applications, 2011, 47: 2487-2494.
- [2] BENSOUDA F Z., HADDI A. Detection and localization of the open-circuit fault using the park's approach [C] //International Conference on Electrical and Information Technologies. Tangiers Morocco: ICEIT, 2016: 1-5.
- [3] MARTINS J. F., PIRES V. F., LIMA C, et al. Fault detection and diagnosis of grid-connected power inverters using PCA and current mean value [C] //IECON 2012 - 38th Annual Conference on IEEE Industrial Electronics Society. Montreal: IEEE PKES, 2012, : 5185-5190.
- [4] SHADLU M S. Fault detection and diagnosis in voltage source inverters using principle component analysis [C] //2017 IEEE 4th International Conference on Knowledge-Based Engineering and Innovation (KBEI). Tehran: Tran University of Science Technology, 2017: 0509-0515.
- [5] LEE J, LEE K. An Open-Switch Fault Detection Method and Tolerance Controls Based on SVM in a Grid-Connected T-Type Rectifier With Unity Power Factor [J]. In IEEE Transactions on Industrial Electronics, 2014, 61(12): 7092-7104.
- [6] 王飞, 金毅, 黄细霞. 基于支持向量机的逆变电源故障诊断 [J]. 电测与仪表, 2015, 52(5): 45-51.
- [7] HAMID E Y, KAWASAKI Z I. Wavelet-based data compression of power system disturbances using the minimum description length criterion [J]. IEEE Transactions on Power Delivery, 2002, 17(2): 460-466.
- [8] CUI BOWEN. Simulation of inverter with switch open faults based on switching function [C] //Proceedings of the IEEE International Conference on Automation and Logistics. Jinan:[s. n.], 2007: 2774-2778.
- [9] WRIGHT SJ, NOWAK R D, FIGUEIREDO M A T. Sparse reconstruction by separable approximation [J]. IEEE Transactions on Signal Processing, 2009, 57(7): 2479-2493.
- [10] 杨忠林. 基于小波包分解的逆变器一相开路故障诊断 [J]. 电机与控制应用, 2011, 38(7): 34-37.
- [11] 梅樱, 孙大南, 韦中利, 等. 一种基于矢量控制的变流器故障诊断方法 [J]. 电工技术学报, 2010, 25(3): 177-182.
- [12] 王志远, 张杰, 王雨琦, 等. 基于三相电流检测的逆变器开路故障诊断及容错方案研究 [J]. 机车电传动, 2014(2): 105-109.
- [13] ALY M, AHMED E M, SHOYAMA M. Developing new lifetime prolongation SVM algorithm for multilevel inverters with thermally aged power devices [J]. In IET Power Electronics, 2017, 10(15): 2248-2256.
- [14] 王小川, 史峰, 郁磊, 等. MATLAB 神经网络 43 个案例分析 [M]. 北京: 北京航空航天大学出版社, 2011.
- [15] 吴超, 袁方, 柴玮, 等. 基于多分类支持向量机的逆变器卡件故障诊断模型研究 [J]. 武汉大学学报 (工学版), 2018, 51(9): 842-846.
- [16] 顾晓光. 基于小波变换和支持向量机的电力电子电路故障诊断研究 [D]. 开封: 河南大学, 2011.

(责任编辑 陈 敏 英文审校 郑青榕)