

文章编号: 2095-2163(2020)08-0062-05

中图分类号: U279.3+23

文献标志码: A

基于复合特征提取的大功率逆变器状态识别方法研究

陆朱剑, 李小波, 程岳梅, 田世贺

(上海工程技术大学 城市轨道交通学院, 上海 201620)

摘要: 本文针对城市轨道交通列车大功率逆变器中 IGBT 开路故障问题, 提出了一种基于复合特征提取的状态识别方法。以大功率逆变器输出端的三相电流作为切入点, 对其信号的时域和频域特征进行提取, 综合两者建立新的复合特征向量组, 并运用自组织特征映射神经网络(Self-Organizing Feature Map)实现故障状态识别。结果表明: 相比于传统的小波分析特征提取方法和单一的 EEMD 分析特征提取方法, 该方法训练次数更少, 时间更短, 对故障的识别比传统方法准确率更高。

关键词: 状态识别; 时域分析; 频域分析; 复合特征

Research on state recognition method of high power inverter based on compound feature extraction

LU Zhuojian, LI Xiaobo, CHENG Yuemei, Tian Shihe

(College of Urban Rail Transportation, Shanghai University of Engineering Science, Shanghai 201620, China)

[Abstract] To solve the problem of IGBT open circuit fault in urban rail train high-power inverter, a state recognition method based on composite feature extraction is proposed. Taking the three-phase current at the output end of the high-power inverter as the starting point, the time-domain and frequency-domain features of the signals are extracted, and a new composite feature vector group is established by synthesizing the two, and the fault state recognition is realized by using the self-organizing feature map neural network. The results show that compared with the traditional wavelet analysis feature extraction method and the single EEMD analysis feature extraction method, the proposed method has fewer training times, shorter time and higher accuracy in fault recognition than the traditional method.

[Key words] state recognition; time domain analysis; frequency domain analysis; composite features

0 引言

辅助供电系统作为地铁车辆的核心系统之一, 对车辆能否安全舒适地运行起着决定性作用, 但辅助供电系统中大功率逆变器的故障率相对较高。在整个大功率逆变器中, 绝缘栅双极型晶体管(IGBT, Insulated Gate Bipolar Transistor)的故障是最频繁的, 其主要形式有短路故障和开路故障。短路故障通常采用硬件保护电路来完成, 而开路故障在短时间内不易被察觉, 而且长时间容易引发二次故障, 造成严重的列车故障。针对 IGBT 开路故障的诊断方法有很多, 国内外诸多学者对其进行了相关研究。文献[1]利用小波变换和粗糙集获取特征向量确定变流器的故障位置, 但是此方法仅用于单相故障的诊断; 文献[2]利用归一化三相电流平均法对变频器 IGBT 开路故障进行诊断, 但此方法在突加、突减负载时容易出现误诊断; 文献[3]建立了电力电子电路混合逻辑动态模型, 但其对模型的依赖

性很大, 有些模型易受外界干扰; 文献[4]提出将脉冲信号和三相桥臂的中点电压信号相结合, 用逻辑分析找出其逻辑关系的表达式进行故障诊断, 但是此方法需要额外的控制信号, 增加了电路复杂性。

针对上述研究的不足, 本文综合考虑了时域特征与频域特征的提取。以大功率逆变器输出端的三相电流作为切入点, 在时域内直接分析三相电流波形的波形因子与偏度因子两个时域指标, 建立时域内故障信号特征向量; 在频域内利用集合经验模态分析(Ensemble Empirical Mode Decomposition, EEMD)^[5]方法, 进行故障信号特征的提取, 并建立特征向量, 结合两者建立新的复合特征向量。在此基础上, 运用自组织特征映射神经网络(Self-Organizing Feature Map)进行训练, 实现故障状态识别。

1 辅助逆变电路故障分析

为了对辅助供电系统中大功率变流器故障的分

作者简介: 陆朱剑(1994-), 男, 硕士研究生, 主要研究方向: 载运工具故障诊断与控制; 李小波(1974-), 女, 博士, 副教授, 主要研究方向: 轨道交通车辆电力牵引、电气状态检测与故障诊断; 程岳梅(1993-), 女, 硕士研究生, 主要研究方向: 载运工具故障诊断与控制; 田世贺(1995-), 男, 硕士研究生, 主要研究方向: 载运工具故障诊断与控制。

收稿日期: 2020-02-15

析, 基于 MATLAB 环境搭建了辅助逆变电路仿真模型, 如图 1 所示。该电路为一个三相桥式逆变电路,

主要由直流电源、滤波电路、IGBT 逆变桥、三相负载等构成。

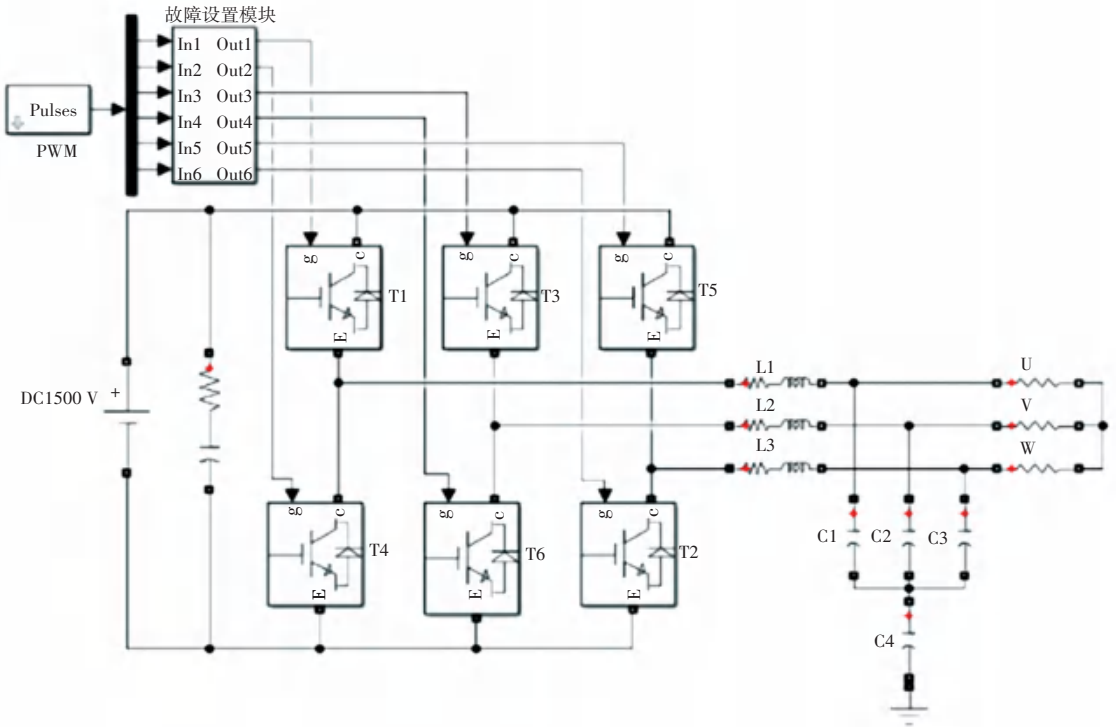


图 1 仿真模型图

Fig. 1 Simulation model diagram

地铁车辆运行过程中, 辅助逆变电路共 6 个桥臂, 分别定义为 T1、T2、T3、T4、T5、T6。其中单个 IGBT 的开路故障发生居多; 2 个 IGBT 同时故障也会发生, 并且会造成更严重的后果; 3 个以上 IGBT 的开路故障同时发生的概率较小。因此, 本文只考虑前两种 IGBT 发生故障的情况, 并进行分类。具体分类情况见表 1。

出波形, 如图 2 所示。

表 1 分类表

Tab. 1 Specific classification table

故障类型	具体分类情况
单个桥臂故障	T1、T2、T3、T4、T5、T6
2 个 IGBT 同时故障	上下桥臂的两个 IGBT T1T4、T3T6、T5T2
同一半桥的两个 IGBT	T1T3、T1T5、T3T5、T4T6、T4T2、T6T2
交叉半桥的两个 IGBT	T1T6、T1T2、T3T4、T3T2、T5T4、T5T6




图 2 部分仿真波形图

Fig. 2 Part of the simulation waveform

上下桥臂的两个 IGBT 同时开路故障时, 系统会出现很大的短路电流, 由系统硬件保护直接实现故障识别, 故不考虑此情况。

由上述故障波形可以看出, 当大功率变流器发生 IGBT 开路故障时, 逆变电路输出端三相电流的输出波形会发生明显变化, 并且不同的故障会引发不同的故障波形, 表现出不同的故障特征。因此, 可以采用输出端的三相电流值作为研究对象来进行故障分析。

本文采用 IGBT 门极信号丢失的方式, 模拟 IGBT 的开路故障, 设置系统在 0.1 s 发生开路故障, 包含正常现象在内共 19 种状态, 各种情况的仿真输

2 复合故障特征提取

大功率变流器的输出电流波形包含了故障位置与故障类型等有效信息,可以从中提取出故障特征进行状态识别^[6]。本文采用时域与频域相结合的特征提取方法,并构建复合故障特征向量。

2.1 基于时域信号的特征提取

时域信号通常分为有量纲参数和无量纲参数,而有量纲参数值通常会随外界因素变化而变化,给故障分析带来一定困难。本文采用波形指标与偏度指标建立故障特征向量^[7]。指标计算公式如下:

(1)波形指标。波形指标参数是脉冲指标与峰值指标的比值,表示实际波形与正弦波的差异与畸变。

$$S_f = \frac{\left(\frac{1}{n} \sum_{i=1}^n x_i^2\right)^{\frac{1}{2}}}{\frac{1}{n} \sum_{i=1}^n |x_i|} \quad (1)$$

(2)偏度指标。偏度指标是信号三阶矩的无量纲统计平均。当原有波形收到故障触发,其偏度指标会发生变化。

$$C_w = \frac{\sqrt{n(n-1)}}{n-1} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left(\frac{1}{n} \sum_{i=1}^n (\lambda_i - \bar{x})^2\right)^{\frac{3}{2}}} \quad (2)$$

基于上述特征指标公式,可得到正常状态下的波形指标参数为 1.111 174,三相电流各偏度指标参数为-0.001 210、-0.000 488、0.001 709。其余 18 种故障时域分析中的部分参数见表 2。

表 2 部分参数表

Tab. 2 Partial parameter table

	T1	T2	T1T3	T1T5	T1T6	T1T2
波形因子	1.151 6	1.151 3	1.273 5	1.272 4	1.215 7	1.216 0
偏度因子	0.324 8	0.116 4	0.306 0	0.307 7	0.405 7	0.399 9
	-0.116 9	0.116 7	0.311 8	-0.481 7	-0.395 9	-0.002 6
	-0.115 5	-0.325 2	-0.485 5	0.301 2	0.003 8	-0.407 2

将 18 种故障信号利用时域分析,提取各个故障信号的波形参数和偏度参数。最后加入正常状态下的三相电流的波形指标与偏度指标,构建 19 组时域统计特征向量:

$$P_T = [S_f, C_{Wu}, C_{Wv}, C_{Ww}]_{1 \times 19}$$

2.2 基于频域信号的特征提取

频域信号的特征提取采用集合经验模态分解(EEMD)方法。由于传统经验模态分析(EMD)在分解过程中会出现模态混叠现象,为了避免此问题

发生,文献[7]中提出了集合经验模态分解(EEMD)的方法。根据信号数据自身的时间尺度来进行分解,从而生成一系列具有特征尺度的数据序列,即 IMF 分量。本文 EEMD 算法中高斯白噪声的标准差设为 0.1,添加白噪声的次数为 50。具体实施步骤如下:

(1)将故障仿真模拟所输出的三相电流波形信号 $x(t)$, 加上给定振幅的白噪声序列 $v_i(t)$;

$$x_i(t) = x(t) + v_i(t), \quad (i = 1, 2, \dots, N). \quad (3)$$

其中, $x_i(t)$ 为第 i 次将高斯白噪声加入原始测试信号中; $v_i(t)$ 为第 i 次加入的高斯白噪声;

(2)将加入白噪声后的数据 $x_i(t)$, 进行 EMD 分解;

(3)重复上述步骤,每次加入振幅相同的白噪声序列从而得到不同的 IMF 分量。

基于本文所研究的故障分析,最终获得 15 个 IMF 分量。然而,并非将所有 IMF 分量进行特征提取就能提高故障状态识别,冗余分量会增大计算量和降低故障状态识别的可靠度。基于本文研究,故障特征信号主要集中在前 8 个 IMF 分量中。因此,选取前 8 个 IMF 分量。提取三相故障电流波的故障特征。

本文中仅以 IGBT 的 T1 故障 U 相做例,其输出三相电流故障信号经过 EEMD 分解,并筛选所得 IMF 分量如图 3 所示。




图 3 T1 故障的 U 相 EEMD 部分分解图

Fig. 3 Partial decomposition diagram of U phase EEMD of T1 fault

特征向量提取的具体步骤:

(1)计算 T1 故障中 U 相的 IMF 分量的能量 $E_{wi(T1)}$, 并计算 $E_{vi(T1)}$ 、 $E_{wi(T1)}$ 的能量系数。能量计算公式为:

$$E_{u(T1)} = \sum_{k=1}^n |I_j|^2, (j = 1, 2, \dots, m). \quad (4)$$

其中, n 为采样点总数, I_j 为 U 相 IMF 分量的混合信号。

(2) 采用能量矩方法, 计算 T1 故障的 U 相 IMF 分量的能量总和 $E_{u(T1)}$, 运用相同方法得到 $E_{v(T1)}$ 、 $E_{w(T1)}$;

(3) 求得 TI 故障的三相 IMF 分量的能量总和 $E_{b(T1)}$;

$$E_{b(T1)} = E_{u(T1)} + E_{v(T1)} + E_{w(T1)}. \quad (5)$$

(4) 最后构建成 T1 故障的特征向量 $P_{F(T1)}$ 。

采用以上提取故障特征向量的方法, 最后得到经 EEMD 分析所得 19 种状态特征向量:

$$P_F = \begin{pmatrix} E_u \\ E_v \\ E_w \\ E_b \\ C_{w_u} \\ C_{w_v} \\ C_{w_w} \\ E_b \end{pmatrix}_{1 \times 19}.$$

2.3 复合特征向量的构造

基于时域的特征分析, 其本质是利用不同的时域统计指标来刻画故障电流波形的“畸变”程度, 进行故障特征的提取; 而基于频域的特征分析, 则是利用 EEMD 对故障电流信号分解成若干个本征模态函数(即 IMF 分量), 进行故障特征的提取。两者相结合, 构建复合故障特征向量 P :

$$P_F = [P_T, P_F]_{1 \times 19} = \begin{pmatrix} E_u \\ E_v \\ E_w \\ E_b \\ C_{w_u} \\ C_{w_v} \\ C_{w_w} \\ E_b \end{pmatrix}_{1 \times 19}. \quad (6)$$

为状态识别提供样本数据。

3 基于 SOM 的变流器故障识别

本文利用自组织映射网络 (Self-Organizing Map, SOM), 进行故障状态的识别。SOM 神经网络采用的无导师、自组织学习方式, 根据输入空间中的向量分组, 通过竞争学习。其可以将高维空间中相似的样本数据映射到网络输出拓扑中的邻近位置, 通过对信息的不断分析, 找出其内在联系, 对有共同特点的信息进行分类, 且 SOM 神经网络能够更直观的表现出分类结果。通过 Simulink 环境对大功率逆变器进行 IGBT 开路故障模拟仿真, 并利用 MATLAB 编程语言构造 SOM 神经网络进行故障状态识别, 其具体流程如图 4 所示。

3.1 基于复合特征向量的故障识别

利用仿真辅助逆变器, 模拟 19 种 IGBT 状态进行数据采集。仿真时长为 0.2 s, 取 0.08 s~0.12 s 之间输出端的三相电流作为原始信号, 采样点数为 40 001 个。利用提出的构造复合特征向量方法(式(6)), 为 SOM 神经网络状态识别提供 19 组特征向量数据。

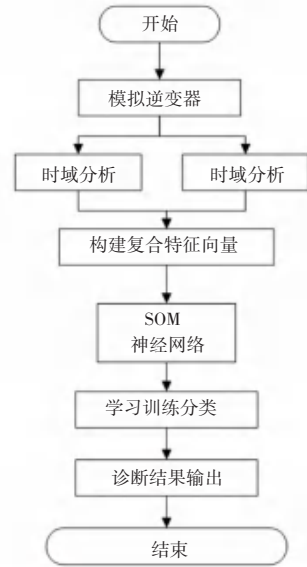


图 4 流程图

Fig. 4 Flow chart

创建 SOM 神经网络, 确定网络的拓扑结构。因本文设置的故障特征向量位数为 7, 而输入层神经元数量与训练集样本的类别数相关, 所以输入层的神经元个数为 7。经对比分析, 最终竞争层选择 15×15 个神经元, 神经元的位置由布局函数设定, 这里选定 hextop 函数设置为六边形。将故障的复合特征向量输入网络中, 由 10 次开始训练, 并增加训练次数, 当 Epoch=40 时, SOM 已经将数据分成 19 类, 即分别出 19 种状态, 最终竞争结果如图 5 所示, 其竞争数据, 见表 3。

由表 3 可以看出, 10 次训练结果, 分成了 10 类; 20 次训练结果, 分成了 12 类; 30 次训练结果, 分成了 17 类; 40 次训练结果, 分成了 19 类; 50、100、200 次训练结果, 均分成了 19 类。因此, 最终选取训练次数为 40, 且不必再增加训练次数。

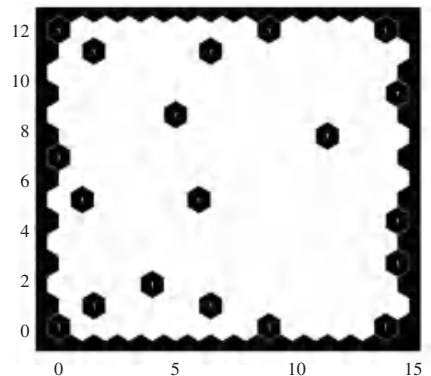


图 5 竞争结果

Fig. 5 Results of the competition

表3 竞争结果

Tab. 3 Results of the competition

故障类别	训练次数						
	10	20	30	40	50	100	200
正常	1	211	207	212	60	183	15
T1	1	225	156	112	129	96	97
T2	1	212	215	110	120	125	90
T3	1	212	221	136	105	186	60
T4	1	182	43	131	80	204	156
T5	1	211	85	211	15	211	10
T6	1	108	98	216	30	121	22
T1T3	209	209	181	10	222	11	225
T1T5	135	90	2	1	181	1	92
T3T5	120	3	15	135	1	180	211
T4T6	120	4	12	225	76	210	121
T4T2	150	209	211	60	225	15	220
T6T2	210	210	16	2	217	6	17
T1T6	211	120	16	31	215	35	35
T1T2	209	209	153	8	190	53	180
T3T4	165	182	211	90	38	105	202
T3T2	165	212	212	26	180	86	147
T5T4	16	3	14	195	16	224	197

为了佐证 SOM 神经网络可以识别出故障信号,测试随机故障信号 T1、T1T2、T1T6 为例,经特征提取之后,输入 SOM 神经网络输入层进行运算,最终识别结果见表 4。

表4 识别结果

Tab. 4 Identification results

故障类别	T1	T1T2	T1T6
分类序号	112	8	31

3.2 对比分析

分别使用小波分析方法、EEMD 方法提取故障数据特征向量,将计算得到的故障特征数据向量输入 SOM 神经网络的输入层,对比本文提出的复合特征提取的方法,结果如图 6 所示。

由图 6 可见,基于复合特征提取,进行 SOM 神经网络故障分析的方法,明显优于另外两种特征提取方法。相同训练次数下,本文提出的复合特征提取方法能在 40 次训练次数下仅需时间 1 s,优先分类出 19 种状态;而基于 EEMD 特征提取方法则需要 100 次训练,需用时间 2 s,基于小波分析的特征提取则无法在 100 次训练内分出 19 种类别。




图6 对比分析图

Fig. 6 Comparative analysis diagram

4 结束语

针对辅助供电系统中大功率逆变器的 IGBT 开路故障,本文提出基于时频域相结合的复合特征提取方法。该方法在时域内提取输出端三相电流波形的波形因子,与偏度因子构建故障特征向量;在频域内运用 EEMD 方法对三相电流波形进行分解并运用能量矩的方法提取的故障特征向量,组合成新的复合特征向量。运用 SOM 神经网络,进行故障状态识别。经实验证明,该方法可有效识别并定位出地铁辅助供电系统大功率逆变器的 IGBT 开路故障的位置与种类,提高了故障诊断的准确性和速度,有良好的实际应用价值。

参考文献

- [1] 田树仁. 基于小波变换和粗糙集的风电变频器故障诊断[J]. 沈阳工业大学学报, 2018, 40(6): 620-626.
- [2] 蔡小玲. 变频器 IGBT 开路故障诊断方法[J]. 自动化应用, 2018(4): 66-67, 75.
- [3] 李宁, 李颖晖, 朱喜华. 混杂系统理论及其在三相逆变电路开路故障诊断中的应用[J]. 电工技术学报, 2014, 29(6): 114-119.
- [4] 郭立炜, 周昇龙, 安国庆. 基于中点电压信号分析的逆变器功率管开路故障诊断研究[J]. 河北科技大学学报, 2015, 36(1): 45-51.
- [5] 袁兵, 余佳翰, 邹永向. 基于 EEMD-SVM 的液压泵故障诊断[J]. 起重运输机械, 2019(20): 90-95.
- [6] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and nonstationary time series analysis[J]. Proceedings Mathematical Physical & Engineering Sciences, 1998, 454(1971): 903-995.
- [7] 徐红梅, 李夏青, 张毅. 电气化铁路馈线故障特征提取方法研究[J]. 铁道机车车辆, 2010, 30(3): 89-92.
- [8] 蔡维华, 马乐, 王华, 等. 基于 IGES 文件的舰船航行性能数值仿真模型[J]. 计算机应用与软件, 2012, 29(2): 192-194, 236.

(上接第 61 页)

- [27] MAGGIORI E, TARABALKA Y, CHARPIAT G, et al. Fully convolutional neural networks for remote sensing image classification[C]// IEEE International Geoscience & Remote Sensing Symposium. IEEE, 2016.
- [28] WU Z, GAO Y, LI L, et al. Semantic segmentation of high-resolution remote sensing images using fully convolutional network

with adaptive threshold[J]. Connection Science, 2019, 31(2): 169-184.

- [29] Geoffrey E. Hinton. Learning in parallel networks[J]. Byte, 1985, 10(4): 265-273.
- [30] JOHNSON J L, PADGETT M L. PCNN models and applications[J]. IEEE Transactions on Neural Networks, 1999, 10(3): 480-498.