

基于 PCA-BLS 的三相整流装置故障诊断

张世奇¹, 王荣杰^{1,2}, 司玉鹏¹, 王礼宝¹, 曾超俊¹

(1. 集美大学轮机工程学院, 福建 厦门 361021; 2. 福建省船舶与海洋工程重点实验室, 福建 厦门 361021)

[摘要] 针对三相整流装置突发故障时, 检测复杂及诊断困难的问题, 以三相桥式全控整流电路为研究对象, 提出一种基于主元分析和宽度学习系统的故障诊断方法。提取负载输出电压为特征向量, 经主元分析, 对特征矩阵降维, 消除数据相关性, 保留数据基本特征; 选择合适的初始参数, 输入到宽度学习系统的网络中, 构建故障诊断模型, 对故障进行诊断。对比实验表明, 基于主元分析和宽度学习系统相结合的故障诊断方法能够准确、高效、快速地获得故障诊断结果。

[关键词] 三相桥式全控整流电路; 故障诊断; 主元分析; 宽度学习系统

[中图分类号] TM 461

Fault Diagnosis of Three Phase Rectifier Based on Principal Component Analysis and Broad Learning System

ZHANG Shiqi¹, WANG Rongjie^{1,2}, SI Yupeng¹, WANG Libao¹, ZENG Chaojun¹

(1. School of Marine Engineering, Jimei University, Xiamen 361021, China;

2. Fujian Provincial Key Laboratory of Naval Architecture and Ocean Engineering, Xiamen 361021, China)

Abstract: Aiming at the problems of complex detection and difficult diagnosis when three-phase rectifying device breaks down suddenly, a fault diagnosis method based on principal component analysis and broad learning system is proposed in this paper. Firstly, the load output voltage is extracted as the feature vector, and the dimension of the feature matrix is reduced by principal component analysis to eliminate the data correlation and retain the basic characteristics of the data. Then, the appropriate initial parameters are selected and input into the network of the broad learning system to construct the fault diagnosis model for diagnosing the fault. Comparative experiments show that the fault diagnosis method based on PCA and broad learning system can obtain the fault diagnosis results accurately, efficiently and quickly.

Keywords: whole-controlled three-phase bridge rectification circuit; fault diagnosis; principal component analysis; broad learning system

0 引言

整流装置作为电力电子器件的主要装置, 其运行状态对设备安全稳定的运行有着重要作用。一旦

[收稿日期] 2020-12-1

[基金项目] 国家自然科学基金项目 (51879118); 福建省科技拥军项目 (B19101); 福建省高等学校新世纪优秀人才支持计划 (B17159); 农业部渔业装备与工程技术重点实验室基金项目 (2016002, 2018001); 人工智能四川省重点实验室基金项目 (2017RJY02); 江苏省输配电装备技术重点实验室项目 (2017JSSPD01)

[作者简介] 张世奇 (1996—), 男, 硕士生, 从事电力系统故障诊断研究。通信作者: 王荣杰 (1981—), 男, 教授, 博士, 从事智能信息处理与电力系统故障诊断研究。E-mail: roger811207@163.com

整流装置发生故障, 轻则造成电子元器件的损坏及相关设备的瘫痪, 重则造成人命安全问题或重大财产损失^[1-2], 因此, 对整流装置进行有效的故障诊断具有重要的意义。目前, 针对故障信号的特征提取方法主要有小波变换^[3]、奇异值分解 (singular value decomposition, SVD)^[4]、经验模态分解 (empirical mode decomposition, EMD)^[5]、快速傅里叶变换 (fast fourier transform, FFT)^[6-7]、K-SVD^[8]等, 以及在这些方法的基础上做出改进的变体形式, 如: 卷积神经网络^[9]、RBF 神经网络^[10]、BP 神经网络^[11]、随机森林^[12]、支持向量机^[13-15]等诊断方法, 虽然这些方法被成功地应用于不同的故障诊断领域, 但实现起来较为复杂。为此本文提出了一种基于主元分析 (principal component analysis, PCA) 和宽度学习系统 (broad learning system, BLS) 相结合的三相整流装置故障诊断方法, 并以 MATLAB 仿真实验验证了该方法的有效性。

1 PCA 原理

根据 PCA 原理^[16], 基于 PCA 的整流装置故障信号特征提取算法如下。

1) 计算样本均值, 假设 n 类故障训练样本 $X = [x_1, x_2, \dots, x_n]$, 则 X 的均值为

$$m = \sum_{i=1}^n x_i / n. \quad (1)$$

2) 计算样本的协方差矩阵为

$$C_X = (1/n) \sum_{i=1}^n (x_i - m)(x_i - m)^T. \quad (2)$$

3) 计算样本协方差矩阵的特征值 λ 和特征向量 A 为

$$C_X \cdot A = \lambda \cdot A. \quad (3)$$

式中: 特征值 λ 有 n 个, 每个 λ_i 对应一个特征向量 A_i 。

4) 计算累计方差贡献率, 并根据累计方差贡献率的大小确定所要降维的主元, 有

$$p = \sum_{i=1}^q \lambda_i / \sum_{j=1}^n \lambda_j. \quad (4)$$

式中: p 为前 q 行主元数的累计方差贡献率, 且 $p \geq 0.9$, 对于所得到的降维矩阵, 合理选择 p 的值, 确定降维后的 q 行主元数 ($q \leq n$), 依照特征值大小将特征向量重新排序, 取前 q 行形成降维之后的特征矩阵 A_q 。

5) 用得到的 A_q 实现原始数据的降维, 有

$$Y = A_q \cdot X. \quad (5)$$

2 BLS 网络模型

BLS 是基于随机向量函数链接神经网络和单层前馈神经网络提出的一种单层增量式神经网络^[17-19], 相较于传统的深层网络模型, 该网络在保证一定精度的同时, 具有快速、简洁、支持增量式的在线模型更新等性质。BLS 的网络结构见图 1。

BLS 实现步骤如下。

1) 设样本输入数据 X 为 $m \times n$ 的矩阵, m 为样本维数, n 为样本个数。将输入数据集 X 通过线性映射和激活函数 Φ_i 输入到 BLS 网络的特征映射层, 则有

$$Z_i = \Phi_i(XW_{ei} + \beta_{ei}), i = 1, \dots, n. \quad (6)$$

式中: Z_i 表示第 i 个特征节点; W_{ei}, β_{ei} 分别为连接于特征映射层随机生成的权重和偏置。

2) 由映射节点经过线性映射和激活函数变换得到增强节点, 则有

$$H_j = \xi_j(Z^n W_{hj} + \beta_{hj}), j = 1, \dots, m. \quad (7)$$

式中: H_j 表示第 j 个增强节点; W_{hj}, β_{hj} 分别为连接于增强层随机生成的权重和偏置。

3) 将所有的映射节点集合 $Z^n = [Z_1, Z_2, \dots, Z_n]$ 和增强节点集合 $H^m = [H_1, H_2, \dots, H_m]$ 输出至输出层 Y , 所有权重的集合定义为 W^m , 则有

$$Y = [Z^n \mid H^m] W^m. \tag{8}$$

4) 通过伪逆的运算得到输出层的权重, BLS 网络构建完成, 即有

$$W^m = [Z^n \mid H^m]^+ Y. \tag{9}$$

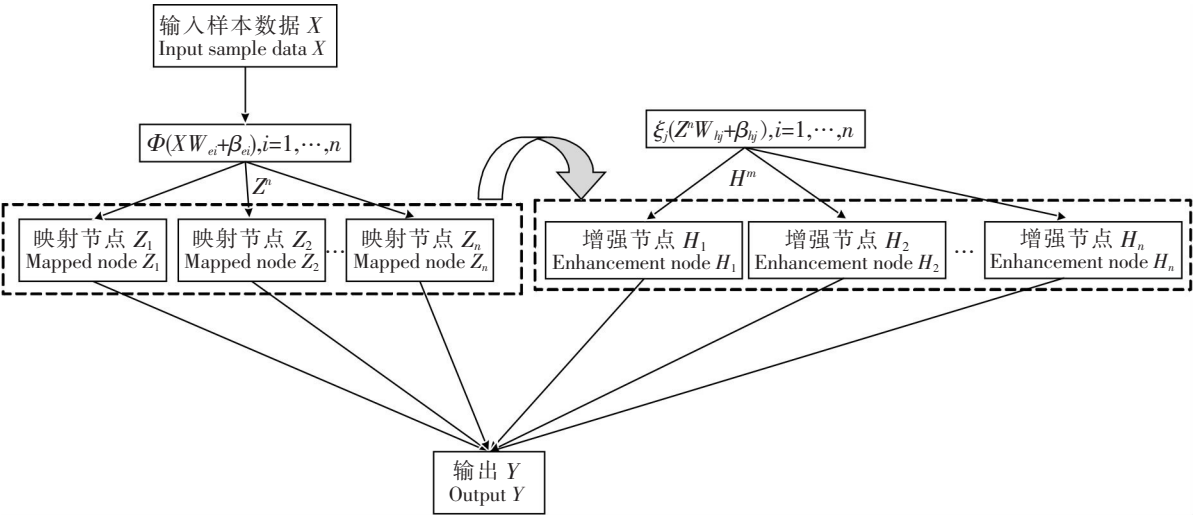


图 1 BLS 网络结构
Fig.1 Network structure of BLS

3 基于 PCA-BLS 的故障诊断方法

电子元器件是电力电子电路的核心部件, 具有十分重要的地位。目前, 电力电子电路发生的故障主要为整流元器件断开或直通故障, 其特征表现为负载的输出波形的突变, 在不同故障状态下所对应的波形极其相似, 特征向量的相关性高, 信息量繁杂, 故障类型的辨别难度大。所以, 为了减少特征向量的相关性, 提出了基于 PCA-BLS 的诊断方法, 将 PCA 和 BLS 相结合, 应用于电力电子电路的故障诊断,

首先, 对故障信号进行采样, 每类故障提取的特征向量构成故障数据的特征矩阵, 然后采用 PCA 对特征矩阵进行处理, PCA 特征提取方法仅通过方差确定信息, 且各主成分之间相互正交, 消除了特征矩阵出现的低秩、或者原始数据成分间相关的情况, 降低了数据的相关性, 且 PCA 计算简单, 易于实现, 通过线性投影将高维的数据映射到低维的空间中, 保留了原数据绝大多数基本特性, 使投影维度上数据的信息量尽可能大而数据维度减少, 再将 PCA 降维数据作为 BLS 网络的输入层, 通过浅层拓宽网络的构建, 以及特征节点与增强节点的映射再次对特征矩阵进行特征提取, 同时所有的节点与输出层相连, 通过伪逆的运算得到相应输出层的权值, 最后建立故障预测信息与故障元器件的对应关系, 对诊断模型进行学习训练。基于 PCA-BLS 的故障诊断方法通过浅层网络的对应关系, 高效、快速地进行故障识别, 大大的缩短了运算的时间, 该方法不仅在诊断精确度上有一定的保证, 而且大大减少了数据的复杂度和相关度。

应用 PCA-BLS 方法的三相整流电路故障诊断流程如图 2 所示, 具体操作步骤如下。

- 1) 选择合适的故障信号进行特征提取, 并作为输入数据的特征矩阵;
- 2) 合理选择累计方差贡献率, 确定主元数, 对原始输入数据进行降维, 将该数据作为 BLS 的输入层;
- 3) 为故障诊断模型选择初始参数, 构建故障源编码, 使之与 BLS 网络输出值一一对应, 并根据输入与输出的数据确定 BLS 网络的结构和规模;

- 4) 将步骤 2) 中得到的 BLS 输入层经线性映射和激活函数构造出特征层的特征节点, 并由特征层的特征节点对应地生成增强层的增强节点, 所有节点均输出至输出层;
- 5) 通过伪逆的运算生成 BLS 网络的输出权值, 完成基于 PCA-BLS 故障诊断模型的构建, 实现故障诊断。

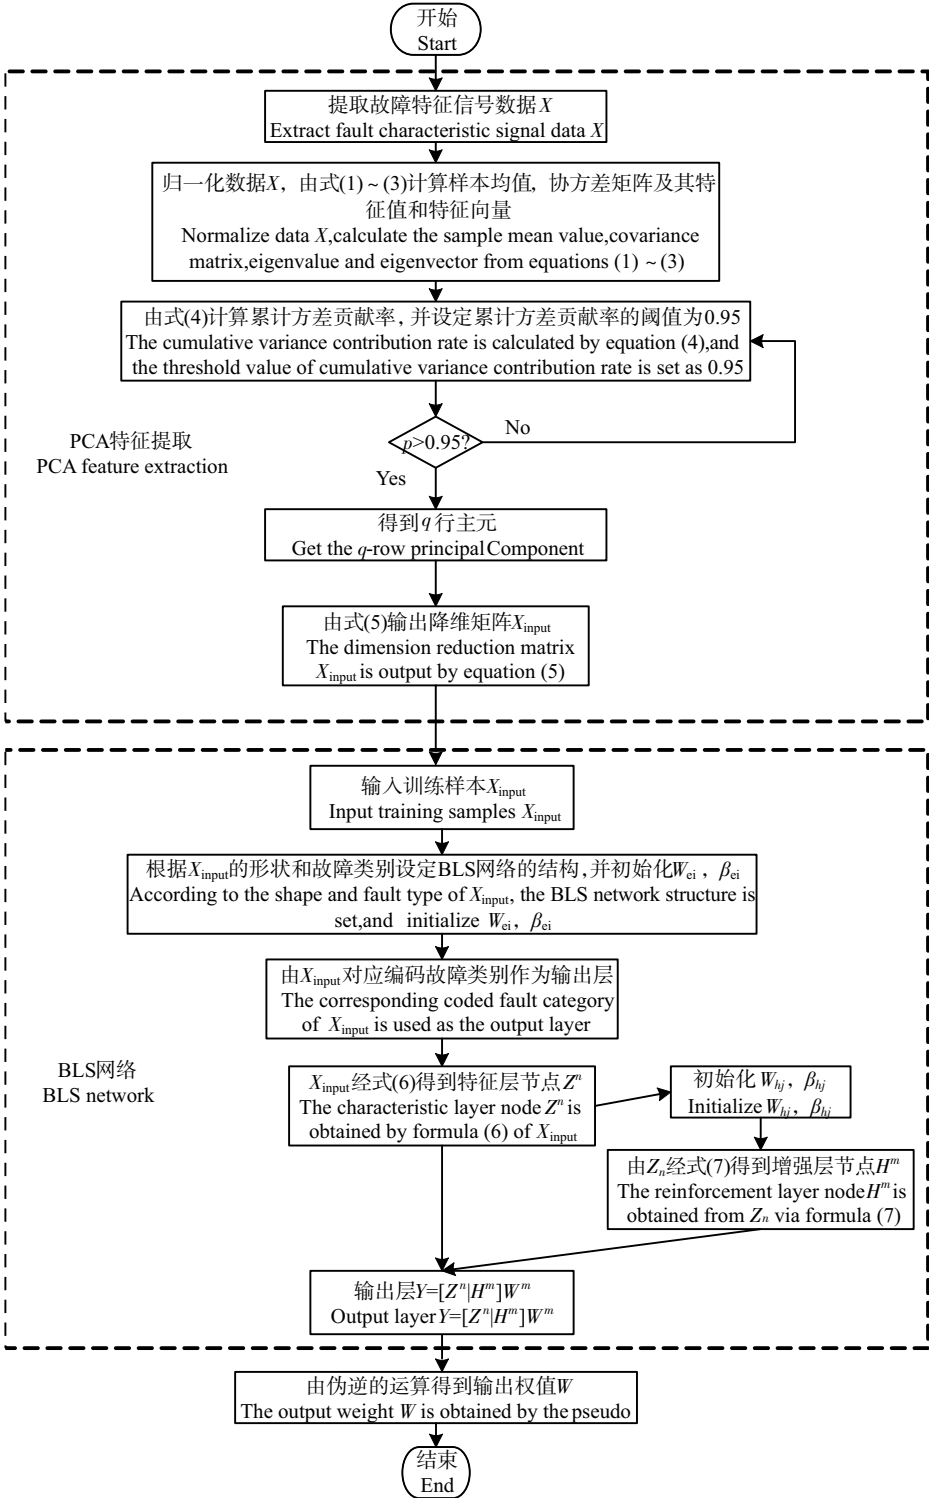


图 2 基于 PCA-BLS 的故障诊断流程

Fig.2 PCA and BLS based fault diagnosis process

4 仿真实验分析

4.1 仿真模型

本实验对三相桥式全控整流电路进行具体地研究及分析，其基本的电路图如图 3 所示。在 MATLAB Simulink 上构造的仿真图如图 4。

图 3 中，当三相电源向该电路提供交流电压时，根据三相电流的特性和桥式电路特性，晶闸管导通顺序依次为 $VT_1 \rightarrow VT_2 \rightarrow VT_3 \rightarrow VT_4 \rightarrow VT_5 \rightarrow VT_6$ ，且不管晶闸管如何导通，负载均处于在线电压的正半周期的运行线路中。




图 3 三相桥式全控整流电路

Fig.3 Whole-controlled three-phase bridge rectification circuit

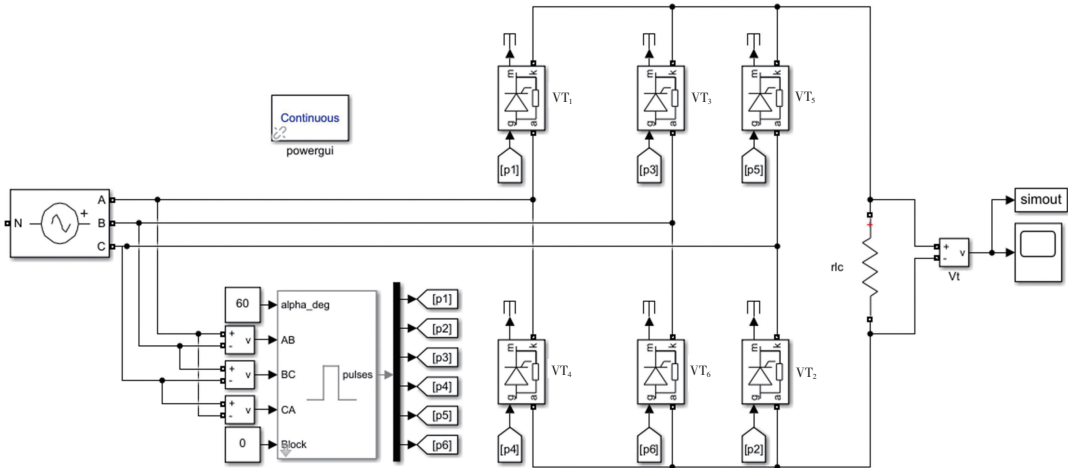


图 4 三相桥式全控整流电路仿真

Fig.4 Simulation of whole-controlled three-phase bridge rectification circuit

4.2 三相整流装置故障分析

在本仿真实验中，所有的元件都为理想的器件，只有在晶闸管的阳极 A 和阴极 K 间有正向电压提供的电流通过，并且在门极有触发脉冲时才能使其导通，除去该条件外，晶闸管不会导通。在三相整流电路的实际运行中，晶闸管的断路和短路所引发的故障最为常见，当电路中有一个晶闸管短路时，会产生过电压，从而导致另一个晶闸管也被击穿而短路，并产生连锁反应，进而使整个电路短路。一般在工程上，均配备硬件短路保护电路进行保护^[10]，在发生短路情况下快速切断故障单元，等效为开路故障处理，因此本文仅对晶闸管的断路故障进行研究，且后文所提到的故障均为断路故障。

对于故障特征的提取，本实验采用提取负载电压 U_d 的波形。由于在不同种类的故障对应下 U_d 信号波形不一样，且电路运行时，不管晶闸管是否导通，负载均处于在线电压的正半周期的运行线路中，将其作为特征向量，任何一个晶闸管发生故障时，都能立即清晰明了地显示出故障的特征。 U_d 的波形测量简单、提取方便，应用于实际操作中也较易实现，可以简便的分析出各类故障并进行诊断，因而，本实验将 U_d 的信号波形作为特征提取的对象。

在 MATLAB Simulink 的仿真模型中，对各种故障情形进行仿真，应用示波器在输出负载端提取信号波形，取其中一个周期，提取不同故障状态所对应的仿真实验的 U_d 波形数据，对每种故障状态提取合适个数的故障样本（合适个数的样本数即要求这些故障样本点连起来的曲线与原波形形状相似），组成该类故障的特征向量，使该特征向量保留原故障类型的全部特征。

对于晶闸管触发角的选择, 实验仅选取 60° 触发角的情形。一般而言, 同时发生故障的晶闸管数在两只以内, 3 只及 3 只以上晶闸管同时出现故障的概率极小, 不在本文研究范围。

将故障的种类分为以下 5 大类共 22 种小类别:

- 1) 第 1 类, 将无故障状态单独作为一类, 以便区分故障状态与正常工作状态;
- 2) 第 2 类, $VT_1 \sim VT_6$ 其中一个发生故障;
- 3) 第 3 类, 不同组同相的两管同时故障, 如 $VT_{1,4}, VT_{3,6}, VT_{5,2}$;
- 4) 第 4 类, 同组不同相的两晶闸管同时故障, 如 $VT_{1,3}, VT_{1,5}, VT_{3,5}, VT_{2,4}, VT_{2,6}, VT_{4,6}$;
- 5) 第 5 类, 不同组不同相两晶闸管同时故障, 如 $VT_{1,2}, VT_{2,3}, VT_{3,4}, VT_{4,5}, VT_{5,6}, VT_{1,6}$ 。

从电路开始运行, 再到运行完一个周期, 用示波器采集相应的输出电压波形, 则上述 5 大类别故障的电压输出波形图如图 5 ~ 图 9 所示。




图 5 第 1 类故障输出波形图
Fig.5 Fault output waveform of the first type

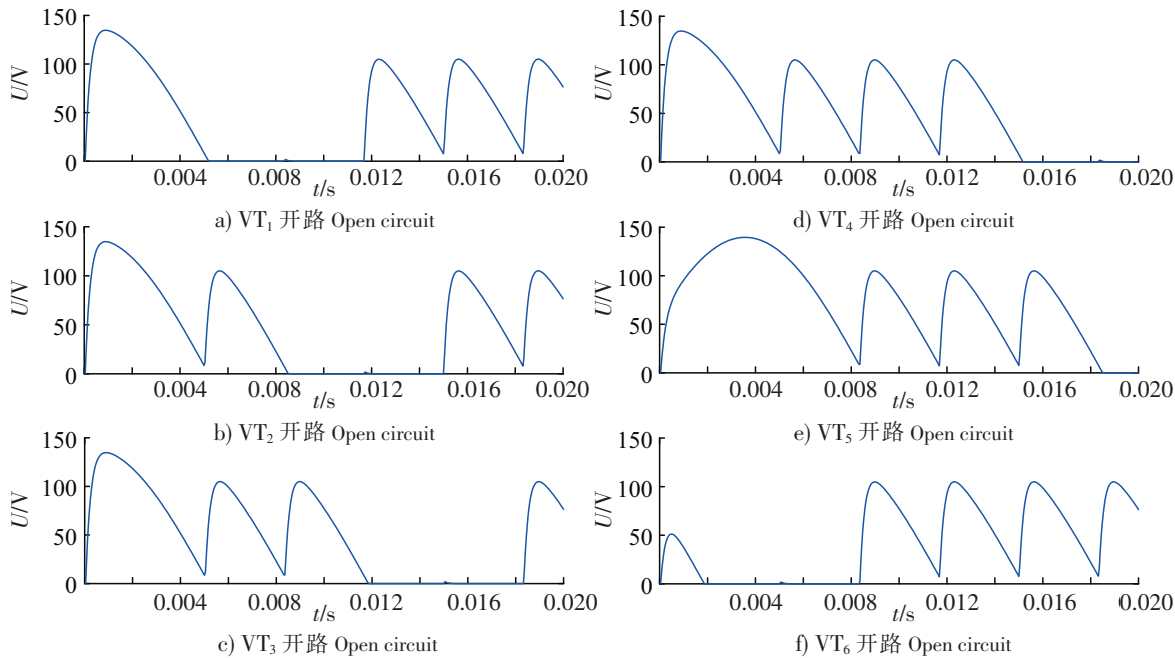


图 6 第 2 类故障电路输出
Fig.6 Fault circuit output of the second type




图 7 第 3 类故障电路输出
Fig.7 Fault circuit output of the third type




图 8 第 4 类故障电路输出

Fig.8 The fourth type of fault circuit output

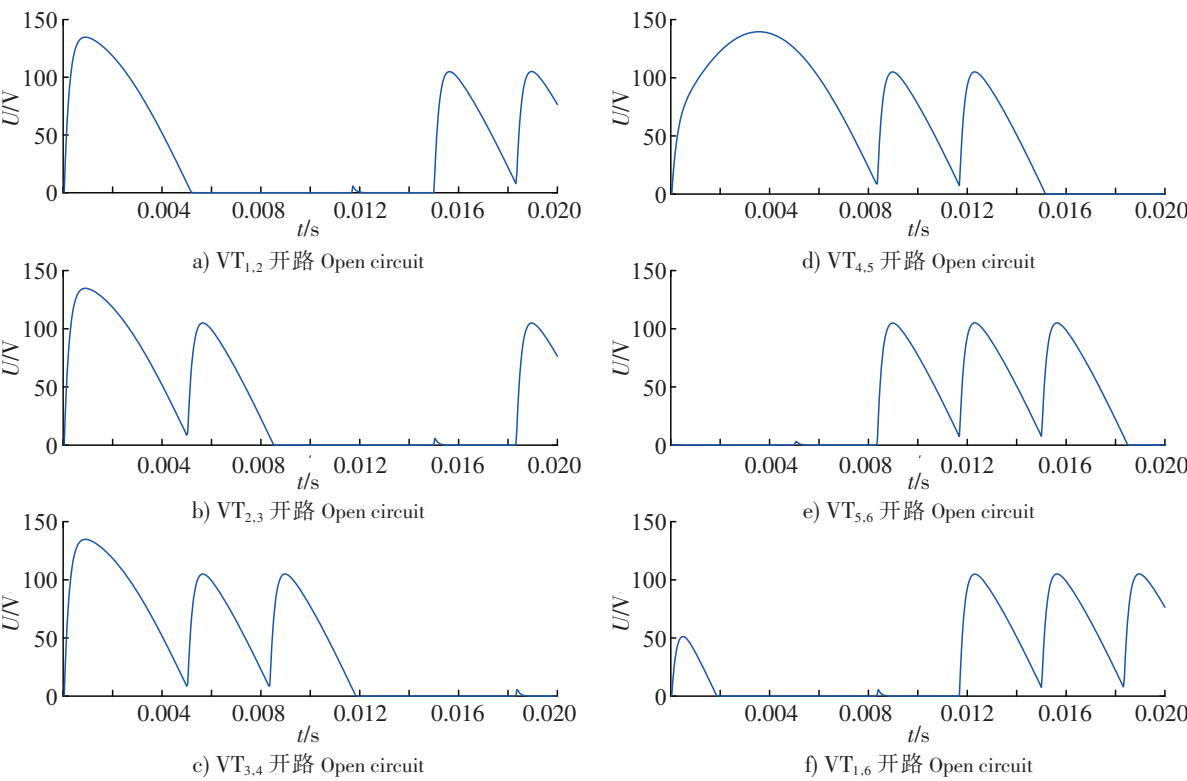


图 9 第 5 类故障电路输出

Fig.9 Fault circuit output of the fifth type

从所有故障类型的整流电路输出电压波形可以看出, 虽然 VT_1 、 VT_2 、 VT_3 、 VT_4 各自发生故障, 以及 4 个晶闸管两两组合发生故障时, 其电压输出波形均呈一定的规律性, 可从缺失波段对应的时间间隔来进行判别, 但识别起来需要将每个波形进行一一对应, 计算量和工作量较大, 不利于故障快速准确的识别, 而且 VT_5 、 VT_6 发生故障时, 在一个周期内的故障特征毫无规律性可言, 无法从时间间隔中找到根据。综合所有的故障波形图, 仅仅通过采集波形缺失的时间间隔来判断故障类型无法实现所有故障类别的识别。

4.3 实验分析

为了保证采样点能够完整的表现出故障特征, 一方面取样的数据点要达到一定的数量才能提取故障的相应特征, 另一方面为了避免提取特征的冗余, 要减少取样的数据。通过大量实验确定在每种故障对应的整流电路输出电压波形中提取20 个数据点最为合适。

通过仿真模型得到 22 种故障的输出信号波形, 在每种故障下的 U_d 波形图中等时间间隔提取20 个 U_d 的值, 作为故障诊断的特征向量。对每种故障类型进行仿真实验, 每一种故障得到 8 组样本数据, 共得到 176 组样本数据。在进行分类实验时, 选取每种故障类型中的 4 组样本数据为训练样本, 其余 4 组样本数据为测试样本。然后将所有的样本数据整合起来作为原始特征矩阵, 并将该矩阵经 PCA 降维, 主贡献率取 95%, 使原始数据的维数由 20 维变为 5 维, 得到的降维特征矩阵作为 BLS 网络的输入层, 再将每种故障类型进行编码, 组成 BLS 网络的输出层, 使样本数据与输出层编码一一对应。最后选择合适网络结构并初始化相关参数, 对输入层数据进行训练和测试, 得到 PCA-BLS 的故障诊断模型的精确度。

为了验证本文所提方法的抗噪性能, 在原始数据的测试样本中分别加入 SNR (signal noise ratio) 为 20, 15, 10, 5, 0 dB 的加性高斯白噪声来模拟工业环境下的噪声污染, 共得到 440 组噪声测试样本。 P_{signal} 、 P_{noise} 分别为信号与噪声的能量, 信号中的噪声污染越严重, SNR 的值越小, SNR 的表达式为

$$\text{SNR} = 10 \cdot \lg(P_{\text{signal}}/P_{\text{noise}})。$$

(10)

对于 PCA 特征提取的有效性, 实验选择了基于 PCA 和 BLS 的 PCA-BLS 方法、基于小波变换和 BLS 的 WT-BLS 方法、基于 SVD 和 BLS 的 SVD-BLS 方法作为对比, 来验证基于 BLS 的不同特征提取方法在不同噪声环境下的诊断性能。通过不同的特征提取方式使原始数据的维度降为 5, 将其作为 BLS 网络的输入层, 再通过 BLS 模型对输入层数据进行分类, 其中 BLS 网络结构保持不变。同时每种方法进行 10 次实验, 所得测试样本的精确度取均值, 所得诊断率见表 1。

表 1 基于 BLS 的不同特征提取方法在不同噪声环境下的诊断率

Tab.1 Diagnosis rate of different feature extraction methods based on BLS under different noise environments

方法 Methods	无噪声 No noise	SNR/dB				
		0	5	10	15	20
WT-BLS	90.12	80.25	82.12	83.11	84.58	88.50
SVD-BLS	93.32	85.67	86.54	87.56	89.66	93.22
PCA-BLS	100.00	98.86	99.12	99.13	99.43	100.00

由于小波变换常用于大数据的压缩, 常会忽略数据中不重要的部分 (高频分量), 从而导致数据特征部分的缺失, 对于小数据样本的处理效果不是很好。而 SVD 通过原始数据直接构建方阵, 舍弃较小的奇异值, 从而达到数据降维的目的。PCA 则是利用去中心化的原始数据进行分解, 通过计算原始数据的协方差矩阵的特征值及特征向量, 选择合适累计方差贡献率来确定主元数, 然后对原始数据变换降维, 在较大程度上保留了原始数据的特征, 且经 PCA 处理的数据较契合 BLS 网络, 两者结合可更好地降低数据间的相关性, 可以更加准确、高效地诊断出故障。由表 1 可知, 虽然其他两种方法都能对数据降维, 但 PCA-BLS 方法精确度最高, 这表明基于 PCA 的特征提取方法能较好地去除数

据相关性，较大程度上保留原始数据特性。在抗噪性能上，随着 SNR 值得增加，3 类诊断方法的诊断率都有所提升，但 PCA-BLS 方法的抗噪性能最好，即使在 SNR = 0 dB 的噪声影响下仍得到了 98% 以上的诊断率。实验结果表明，基于 PCA 的特征提取方法具有良好的数据处理效果，PCA-BLS 方法在不同噪声环境下具有最佳的诊断精度。

对于 BLS 的故障分类方法，实验选取了基于 PCA 和 BP 神经网络的 PCA-BPNN 分类方法、基于 PCA 和 SVM 的 PCA-SVM 分类方法、基于 PCA 和 BLS 的 PCA-BLS 分类方法，在不同噪声环境下对这 3 种方法的诊断性能进行对比。其中：PCA-BPNN 中 BP 神经网络的隐藏层节点数设置为 10，网络结构设置与 BLS 模型一致；PCA-BLS 网络结构设置为 5-10-5；PCA-SVM 采用二分类模型。构建 22 个故障诊断模型，然后按流程逐一对故障样本进行诊断，对比实验结果为 10 次重复实验所得测试精确度的均值，所得诊断率见表 2。

表 2 基于 PCA 的不同分类模型在不同噪声环境下的诊断率

Tab.2 Diagnosis rate of different classification models based on PCA under different noise environments						
方法 Methods	无噪声 No noise	SNR/dB				
		0	5	10	15	20
PCA-BPNN	93.64	18.18	27.87	37.67	68.98	80.24
PCA-SVM	98.18	91.25	93.54	94.25	96.87	97.23
PCA-BLS	100.00	98.86	99.12	99.13	99.43	100.00

虽然 BP 神经网络应用广泛，在训练样本较多的情况下可以实现故障分类，但对于小样本的分类不利，且存在精确度不高，训练时间长等缺点。而对于 SVM 分类方法，需要构建 22 个诊断模型，然后一一组建起来，对故障逐一进行判断，进行流程式的诊断，且参数的选择具有一定的难度，得到诊断结果的时间具有不确定性，操作起来较为麻烦。BLS 模型通过增量学习高效重建扩展网络，避免了大规模耗时的网络训练，在保证训练速度的情况下，在浅层的模型下可以精准快速地对故障进行诊断。由表 2 中数据可知，基于 BLS 的故障诊断模型的测试精度在噪声环境 and 无噪声环境的情况下均优于其他方法，PCA-BLS 方法诊断精度最高。

总之，采用 PCA 的特征提取方法可有效地去除数据的冗余，保持数据的有效性，并且有一定的降噪作用；采用 BLS 的分类算法拥有较好的识别性能，两者相结合可实现故障快速准确的定位。

5 结语

本文提出了一种基于 PCA-BLS 的故障诊断方法，结合了两者优先点，首先采集不同故障类型数据，并整合为矩阵，用 PCA 对原始数据矩阵降维，将 PCA 的输出矩阵作为 BLS 网络的输入，通过建立特征节点和增强节点的浅层模型对特征矩阵进行分类，识别定位故障。通过三相桥式全控整流电路故障仿真实验研究表明，PCA 可以在尽量保证信息不损失的情况下消除特征向量的相关性，并可根据具体求解的问题灵活选取特征提取的维数，简化了 BLS 网络结构，减少了训练时间，BLS 分类模型能快速、稳定、准确、高效地诊断出故障。通过不同噪声环境下的多种诊断方法的对比，基于 PCA-BLS 的故障诊断方法具有一定优势，且该方法可推广至其他电力电子电路的故障诊断中。

[参 考 文 献]

[1] GAO Y, YANG C L. Complex fault modeling based analog-circuit fault diagnosis [J]. Journal of University of Electronic Science and Technology of China, 2017, 46(4): 540-546.

[2] 王荣杰. 电力电子整流装置故障诊断方法的研究 [D]. 广州: 广东工业大学, 2006.

[3] 李俊涛. 基于小波包分析与支持向量机的电力电子整流装置故障诊断 [J]. 北华大学学报 (自然科学版), 2014, 15(4): 548-551.

- [4] LI H, LIU T, WU X, et al. Research on bearing fault feature extraction based on singular value decomposition and optimized frequency band entropy [J]. *Mechanical Systems and Signal Processing*, 2019, 118: 477-502.
- [5] MALIK H, SHARMA R. EMD and ANN based intelligent fault diagnosis model for transmission line [J]. *Journal of Intelligent and Fuzzy Systems*, 2017, 32(4): 3043-3050.
- [6] YAN X A, JIA M P. A novel optimized SVM classification algorithm with multi-domain feature and its application to fault diagnosis of rolling bearing [J]. *Neurocomputing*, 2018, 313: 47-64.
- [7] HUANG D R, CHEN C S, ZHAO L, et al. Hybrid collaborative diagnosis method for rolling bearing composite faults [J]. *Journal of University of Electronic Science and Technology of China*, 2018, 47(6): 853-863.
- [8] WU S M, CHEN X F, ZHAO Z B, et al. Data-driven discriminative K-SVD for bearing fault diagnosis [C] // *Prognostics and System Health Management Conference (PHM)*. Harbin: [s. n.], 2017: 1-6.
- [9] EREN L, INCE T, KIRANYAZ S. A generic intelligent bearing fault diagnosis system using compact adaptive 1D CNN classifier [J]. *Journal of Signal Processing Systems for Signal Image and Video Technology*, 2019, 91(2): 179-189.
- [10] 牛慧芳, 孟青, 庞丽英. 基于RBF网络的三相桥式全控整流电路的故障诊断 [J]. *内蒙古大学学报 (自然科学版)*, 2019, 50(2): 212-217.
- [11] SHAO J Y, XIE Z L, YANG R. Fault diagnosis of compressor gas valve based on BP neural network of a particle swarm genetic algorithm [J]. *Journal of University of Electronic Science and Technology of China*, 2018, 47(5): 781-787.
- [12] WANG Z W, ZHANG Q H, XIONG J B, et al. Fault Diagnosis of a rolling bearing using wavelet packet denoising and random forests [J]. *IEEE Sensors Journal*, 2017, 17(17): 5581-5588.
- [13] PANG B, TANG G J, ZHOU C, et al. Rotor fault diagnosis based on characteristic frequency band energy entropy and support vector machine [J]. *Entropy*, 2018, 20(12): 932.
- [14] VAN M, HOANG D T, KANG H J. Bearing fault diagnosis using a particle swarm optimization-least squares wavelet support vector machine classifier [J]. *Sensors*, 2020, 20(12): 3422-3441.
- [15] ZHU K, CHEN L, HU X J. Rolling element bearing fault diagnosis by combining adaptive local iterative filtering, modified fuzzy entropy and support vector machine [J]. *Entropy*, 2018, 20(12): 926-938.
- [16] ZHAO H M, ZHENG J J, XU J J, et al. Fault diagnosis method based on principal component analysis and broad learning system [J]. *IEEE Access*, 2019, 7: 99263-99272.
- [17] CHEN C L P, LIU Z L. Broad learning system: an effective and efficient incremental learning system without the need for deep architecture [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(1): 10-24.
- [18] CHEN C L P, LIU Z L, FENG S. Universal approximation capability of broad learning system and its structural variations [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2019, 30(4): 1191-1204.
- [19] FENG S, CHEN C L P. Fuzzy broad learning system: a novel neuro-fuzzy model for regression and classification [J]. *IEEE Transactions on Cybernetics*, 2020, 50(2): 414-424.

(责任编辑 陈 敏 英文审校 郑青榕)