

基于 SDAE-PSOSVM 的航空变压整流器 故障诊断方法研究

石旭东¹, 徐海义¹, 吴东华², 杨占刚¹, 李运富¹

(1. 中国民航大学 电子信息与自动化学院, 天津 300300;
2. 航空工业陕西航空电气有限责任公司, 陕西, 西安 710065)

摘要: 针对不同故障模式下航空变压整流器二极管故障特征相似程度高导致不易区分的问题, 提出一种基于堆叠降噪自动编码器(stacked denoising auto encoder, SDAE)与粒子群优化支持向量机(partical swarm optimization support vector machine, PSOSVM)相结合的故障诊断方法. 首先搭建航空变压整流器仿真模型, 通过对不同故障模式进行仿真, 获取故障数据; 然后运用 SDAE 方法对高维故障信号进行故障特征提取, 建立故障特征集; 最后采用 PSOSVM 方法进行故障诊断, 并且与常用的故障诊断方法进行对比分析. 诊断结果表明 SDAE-PSOSVM 故障诊断方法准确性达到 96%, 可以对高维故障数据信号进行特征提取, 提高不同故障模式之间的区分度.

关键词: 航空变压整流器; 堆叠降噪自动编码器; 粒子群优化支持向量机; 故障诊断

中图分类号: TM461 **文献标志码:** A **文章编号:** 1001-0645(2021)10-1069-09

DOI: 10.15918/j.tbit1001-0645.2020.176

Fault Diagnosis Method for Aviation Transformer Rectifier Unit Based on SDAE-PSOSVM

SHI Xudong¹, XU Haiyi¹, WU Donghua², YANG Zhangang¹, LI Yunfu¹

(1. College of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China;
2. AVIC Shaanxi Aero Electric Co., Ltd., Xi'an, Shaanxi 710065, China)

Abstract: Due to the high similarity of the fault characteristics of aviation transformer rectifier diodes in different fault modes, it is difficult to distinguish the fault characteristics. To solve the problem, a fault diagnosis method was proposed based on stacked denoising auto encoder (SDAE) combined with particle swarm optimization support vector machine (PSOSVM). Firstly, a simulation model of aviation transformer rectifier was built to get the fault data from simulation of different fault modes. Then the SDAE method was used to extract the fault features from high-dimensional fault signals and establish fault feature sets. Finally, PSOSVM method was used to diagnose fault and to compare the effectiveness with common fault diagnosis methods. The fault diagnosis results show that the accuracy of the SDAE-PSOSVM method can reach up to 96% and functionally extract the features of high-dimensional fault data signals to improve the discrimination between different fault modes.

Key words: aviation transformer rectifier unit; stacked denoising auto encoder; particle swarm optimization support vector machine; fault diagnosis

收稿日期: 2020-10-21

基金项目: 国家自然科学基金资助项目(51377161); 航空科学基金资助项目(20170267002); 中央高校基本科研业务费项目中国民航大学
专项资助项目(3122018D005); 天津市高等学校创新团队培养计划资助项目(TD13-5071)

作者简介: 石旭东(1972—), 男, 博士, 教授, E-mail: xdshi@cauc.edu.cn.

航空变压整流器 (transformer rectifier unit, TRU) 作为多电飞机电源系统中的主要部件, 对飞机二次电源系统的正常运行具有十分重要的意义. 在波音 787 飞机电源系统中有 8 台 TRU^[1-2]; 其中 4 台 TRU 实现 235VAC 向 28VDC 转换, 为直流负载供电; 另外 4 台自耦型 TRU 实现 235VAC 向 ± 270 VDC 转换, 为大功率电机控制器供电. 随着多电飞机的快速发展, 飞机二次电源系统对 TRU 的可靠性要求也相应提升. 根据 2019 年各大航空公司的飞机电源系统故障统计数据, 二次电源系统的故障案例共 86 起, 其中 TRU 故障 76 起, 占二次电源系统故障的 88.37%, 因此对 TRU 进行故障诊断具有重要意义. 二极管作为 TRU 的主要元件, 数量较多, 且易于受温度、机械应力等因素影响而不能正常工作, 从而导致 TRU 整流器故障, 可靠性降低. 单个二极管开路故障时, 输出直流电压减小且存在波动, 将直接导致大量谐波注入飞机电网; 短路故障时, TRU 变压器原边输入三相电流大幅增加且存在大量谐波, 影响汇流条上其它部件正常工作. 由于不同位置以及不同类型的二极管故障对 TRU 输出电压与输入电流波形影响程度较小, 这对故障特征提取和诊断方法提出了较高要求.

目前, 对于 TRU 的故障诊断主要是基于模式识别方法: 通过采集不同故障模式的故障数据, 选择合适方法提取故障数据特征向量, 利用神经网络或者支持向量机对故障进行分类. 常用的特征提取方法有时域、频域、时频分析以及深度学习等. 时域分析, 如设定阈值方法^[3], 无法对 TRU 中故障二极管进行故障定位分析. 频域分析, 如快速傅里叶变换法 (fast Fourier transform, FFT), 对局部特征提取

效果较差. 时频分析是目前应用最广泛的信号处理方法, 主要有经验模态分解 (empirical mode decomposition, EMD)、希尔伯特黄变换 (Hilbert-Huang transform, HHT)^[4]、小波变换 (wavelet transform, WT)^[5-6] 等, WT 依赖于小波基与分解层的选择, HHT 以 EMD 方法为前提, 导致 HHT 具有 EMD 存在的模态混叠问题, 虽然集成经验模态分解 (ensemble empirical mode decomposition, EEMD) 解决了 EMD 存在的问题^[7-9], 但是噪声分量在降噪处理中被丢弃, 会造成有用信息丢失. 综上所述, 时域、频域以及时频分析方法都具有一定的局限性.

HINTON 等提出了深度学习的基本理论和实现框架, 依靠自动编码器构建深层次模型, 完成数据学习并提取特征向量, 被广泛应用于故障诊断领域. 基于此, LU 等^[10-12] 进一步研究了编码器的变形结构并提出 SDAE 模型, 对 SDAE 各参数选择进行了深入对比研究. 目前, 基于 SDAE 方法的故障特征提取已经应用于不同对象中^[13-15], 但是应用于 TRU 故障诊断的研究尚为空白, 且现有研究中采用其他方法对 TRU 故障诊断的准确率并不理想. 因此, 本文提出一种基于 SDAE 与 PSO 优化 SVM 相结合的方法对 TRU 进行故障诊断, 并通过与其他诊断模型的准确率进行对比, 验证改进方法的优越性.

1 TRU 建模与故障诊断

1.1 TRU 拓扑结构与故障类型

本文以 12 脉波 TRU 为研究对象, 搭建 TRU 仿真模型, 电气原理如图 1 所示. 两组三相整流模块并联构成整流部分, 共有 12 个整流二极管, 为方便后续故障分类研究, 按照顺序对二极管标号 $d_1 \sim d_{12}$.

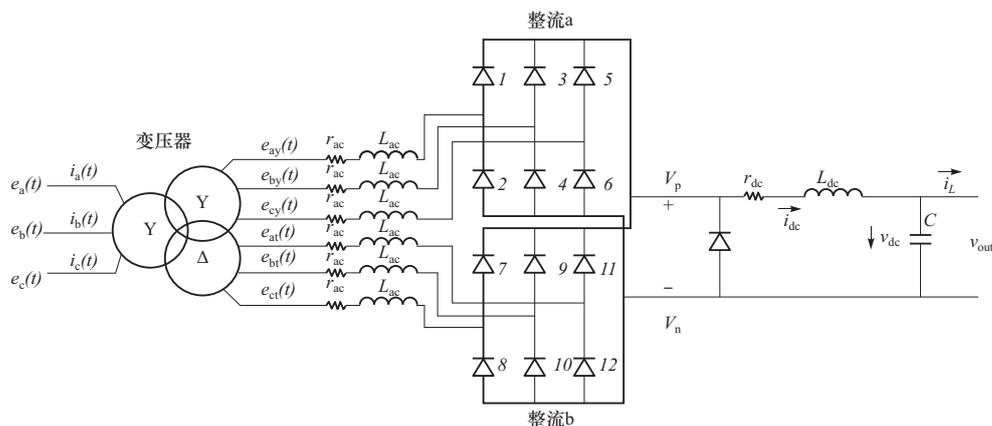


图 1 TRU 电气原理图

Fig. 1 TRU electrical schematic diagram

以航空直流电机为负载,仿真输出电压为直流 28 V,奇次谐波含量较少,总谐波失真率 7.6%。仿真模型输出电压与电流幅值、纹波等参数均符合 EMC 试验标准 DO-160G,满足机载设备供电要求。

额定负载时,TRU 在正常情况与不同二极管故障情况下的输入电流波形如图 2 所示,依次为 A、B、C 三相。在不同二极管开路故障中,输入电流波形相似程度高,与正常情况波形与幅值接近,而在不同二极管短路故障中,输入电流波形差异较明显,且与正常情况波形与幅值有较大差异。

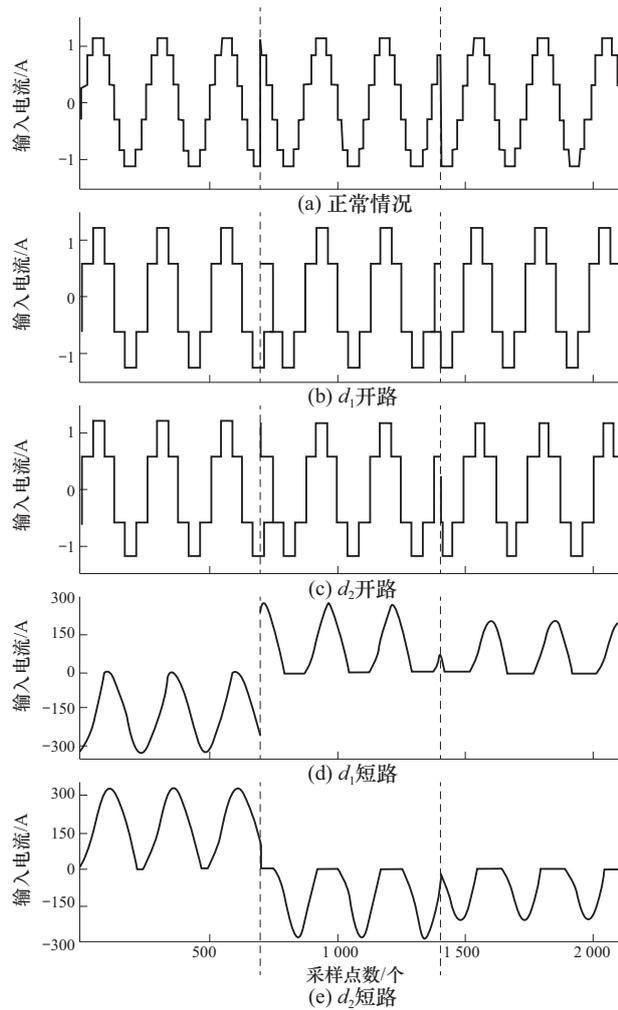


图 2 典型故障输入电流波形

Fig. 2 Typical fault input current waveforms

额定负载时,TRU 在不同故障模式下的输出电压与电流幅值如图 3 所示。图 3 中故障类别 1~12 对应每个二极管开路状态,故障类别 13~24 对应每个二极管短路状态。在不同类型故障模式下,输出电流幅值变化程度较小,输出电压幅值差异较大。此外,不同二极管出现同类故障

情况下输出电压波形相似度较高,如图 4 所示。可见开路故障模式下,不同输出电压波形幅值基本一致,差异在于相位不同。综上所述,选择 TRU 三相输入电流与直流输出电压作为故障数据样本。

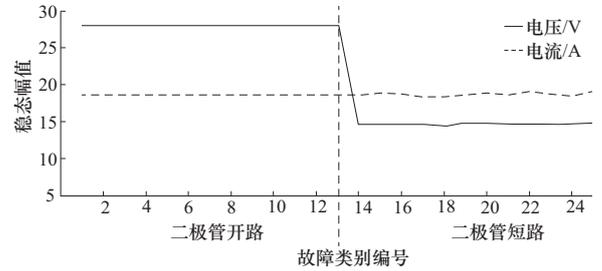


图 3 不同故障模式输出幅值

Fig. 3 Output amplitude in different fault modes

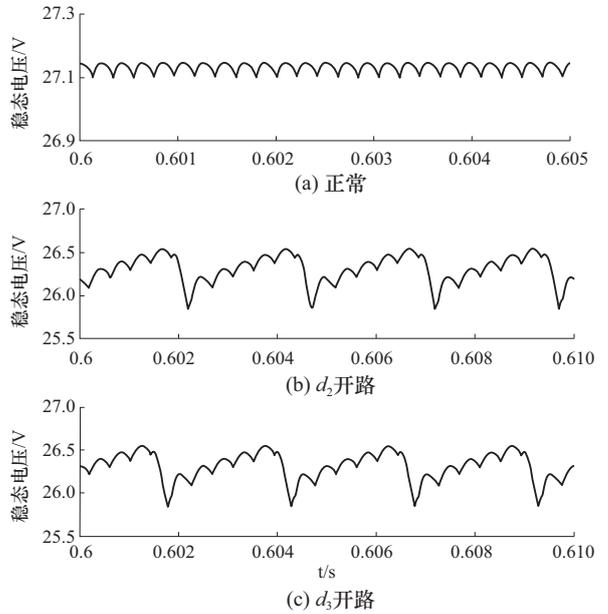


图 4 不同开路故障输出电压波形图

Fig. 4 Output voltage waveforms of different open-circuit fault

2 数据采集与 SDAE 特征提取算法

2.1 故障仿真数据

由于实际情况中两个及以上二极管同时发生故障的概率极低^[16-17],因此本文对单个二极管进行故障诊断,包括 24 种故障状态与正常状态,共 25 种类别。结合图 3 图 4 波形情况,采用 TRU 三相输入电流与输出电压共 4 种数据信号构建原始诊断数据样本。采样频率为 100 kHz,采样时间为 0.6 s,每组样本数据 240 000 点,每种诊断类别采集 30 组数据,共采集 750 组诊断

数据,即原始 $750 \times 240\,000$ 的样本特征矩阵. 采集得到部分电压、电流数据如表 1 所示,由数据

可见,当不同位置二极管发生相同类型故障时,故障数据差异较小.

表 1 原始输入电流与输出电压数据

Tab. 1 Original input current data and output voltage data

数据采集	SDAE 输入	无故障	d_1 开路	d_2 开路	d_8 开路	d_1 短路	d_2 短路	d_8 短路
A 相输入 电流 i_a/A	x_1	-0.211	-0.275	-0.290	-0.291	-0.293	-0.293	-0.293
	x_2	-0.173	-0.290	-0.295	-0.297	-0.298	-0.298	-0.298
	x_3	-0.110	-0.172	-0.176	-0.179	-1.097	0.827	0.549
	x_4	0.078	0.025	0.012	0.009	-2.989	3.006	2.679
B 相输入 电流 i_b/A	$x_{60\,001}$	1.080	1.134	1.120	1.118	1.119	1.119	1.120
	$x_{60\,002}$	1.047	1.135	1.122	1.121	1.121	1.121	1.121
	$x_{60\,003}$	1.024	1.073	1.062	1.062	2.214	1.118	2.451
	$x_{60\,004}$	0.944	0.974	0.967	0.966	4.110	1.110	4.581
C 相输入 电流 i_c/A	$x_{120\,001}$	-0.869	-0.827	-0.830	-0.827	-0.827	-0.827	-0.826
	$x_{120\,002}$	-0.873	-0.818	-0.826	-0.823	-0.822	-0.822	-0.822
	$x_{120\,003}$	-0.914	-0.873	-0.886	-0.882	-1.116	-1.946	-3.000
	$x_{120\,004}$	-1.022	-0.974	-0.979	-0.976	-1.121	-4.122	-7.260
输出电压 U_o/V	$x_{180\,001}$	27.932	26.474	26.466	26.944	25.842	22.139	21.992
	$x_{180\,002}$	27.922	26.491	26.481	26.894	25.744	22.146	21.958
	$x_{180\,003}$	27.903	26.498	26.495	26.849	25.644	22.153	21.914
	$x_{180\,004}$	27.890	26.515	26.508	26.804	25.541	22.157	21.875

由于原始诊断数据相似,不同故障模式下的故障特征难以区分,因此需要依靠 SDAE 特征提取算法从故障数据中更深入地挖掘故障特征,便于更高效准确地实现故障诊断与故障定位.

2.2 SDAE 特征提取算法

SDAE 由多个自动编码器叠加建立,结构包括输

入层 X 、隐藏层 H 与输出层 Y ,如图 5 所示. SDAE 可通过编码器将 TRU 真实故障数据映射为低维特征输出,解码器将低维特征重构回原始数据. 隐藏层为故障数据的低维特征表示,每一个隐藏层都将成为一个输入层,以此对数据进行逐层训练学习. 经训练获得的故障特征用于后续 SVM 分类器的优化与诊断.

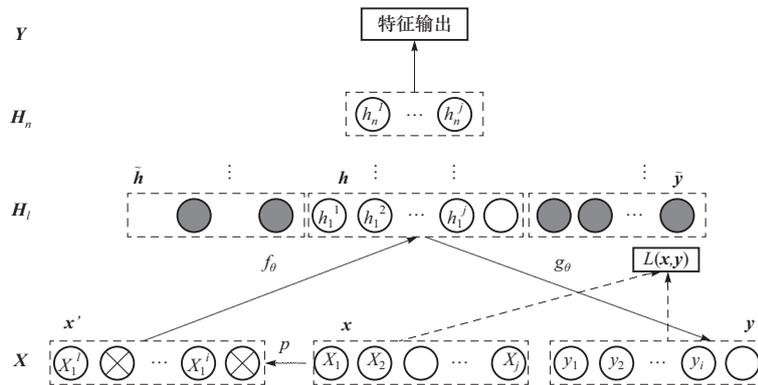


图 5 SDAE 结构模型

Fig. 5 SDAE structural model

如图 5 所示, f_θ 即为编码过程,隐藏层表示为

$$\mathbf{h}_{m \times 1} = f_\theta(\mathbf{x}_{n \times 1}) = \sigma(\mathbf{W}_{m \times n} \mathbf{x}_{n \times 1} + \mathbf{b}_{m \times 1}) \quad (1)$$

式中: \mathbf{x} 为采集的故障数据输入; \mathbf{h} 为低维故障特征输出; \mathbf{W} 为编码器连接权值矩阵; \mathbf{b} 为编码器偏置向量; $\sigma(\cdot)$ 为非线性激活函数 Sigmoid 函数

$$\sigma(t) = \frac{1}{1 + \exp(-t)} \quad (2)$$

g_θ 即为解码过程,重构输出表示为

$$\mathbf{y}_{n \times 1} = g'_\theta(\mathbf{h}_{m \times 1}) = \sigma(\mathbf{W}'_{n \times m} \mathbf{h}_{m \times 1} + \mathbf{b}'_{n \times 1}) \quad (3)$$

式中: \mathbf{y} 为重构故障数据; \mathbf{W}' 为解码器连接权值矩阵; \mathbf{b}' 为解码器偏置向量. 但是在数据重构过程中,

需保证重构误差最小化,自动编码的重构误差成本函数为

$$L(\mathbf{x}, \mathbf{y}) = \frac{1}{2N} \sum_{i=1}^N \|\mathbf{x} - \mathbf{y}\|_2^2 \quad (4)$$

式中: N 为训练样本数量; $\|\cdot\|_2$ 为二范数. 利用梯度下降法对 $\mathbf{W}, \mathbf{W}', \mathbf{b}, \mathbf{b}'$ 进行迭代更新, 迭代终止条件为达到预设迭代次数或重构误差 $L < 10^{-4}$. 权重与偏置矩阵直接影响故障特征的准确性与代表性, 根据重构误差迭代计算权重与偏置能够确保二极管故障诊断更加准确.

SDAE 算法在特征提取过程中主要受隐藏层数、隐藏层节点数等结构参数影响, 文献[10]中实验表明, 当隐藏层数 > 3 , 而且各层网络节点数逐层减半时, 数据重构误差较小. 因此本文参考该文献设定 SDAE 网络结构参数, 网络隐含层为 3 层结构, 设置隐含层节点数为 [150 75 20], 稀疏系数为 0.15, 惩罚项权重为 3.

经图 5 中过程 p 对输入层 240 000 点原始电流电压故障数据 \mathbf{x} 添加高斯白噪声破坏, 利用混入噪声后的数据 \mathbf{x}' 进行 SDAE 特征网络逐层训练. 对二极管正常工作时采集的数据进行特征提取, 逐层降维输出结果如图 6 所示.

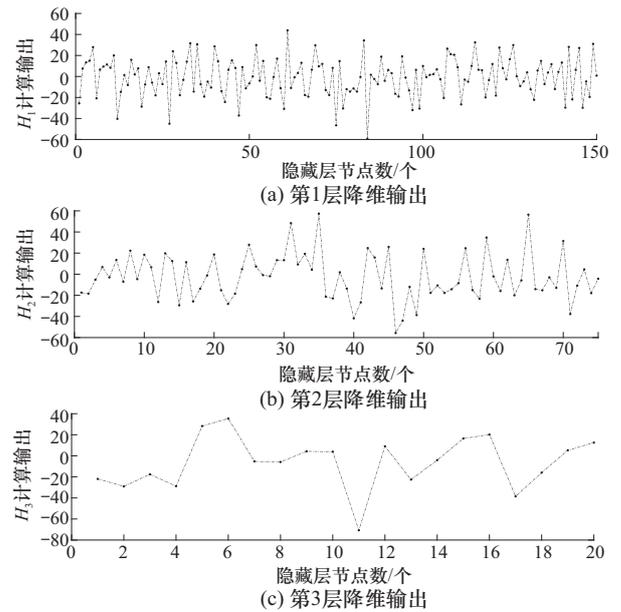


图 6 数据逐层降维

Fig. 6 Data dimension reduction

训练可得到 750×20 的特征值矩阵, 部分特征值数据如表 2 所示. $y_1 \sim y_5$ 为 A 相电流特征信息, $y_6 \sim y_{10}$ 为 B 相电流特征信息, $y_{11} \sim y_{15}$ 为 C 相电流特征信息, $y_{16} \sim y_{20}$ 为整流输出电压特征信息.

表 2 特征提取

Tab. 2 Feature extraction

数据降维	正常	d_1 开路	d_2 开路	d_8 开路	d_1 短路	d_2 短路	d_8 短路
y_1	-21.925	-21.625	-21.577	-22.344	84.831	89.436	249.187
y_2	-29.006	-28.577	-28.545	-29.110	258.043	109.367	78.189
y_3	-17.563	-17.676	-17.606	-18.388	-481.320	-192.545	-139.469
y_4	-28.799	-29.359	-29.702	-30.195	-22.986	42.270	9.002
y_5	28.284	28.371	28.235	28.508	-183.544	-106.471	-247.039
y_6	35.402	35.686	35.638	35.604	-219.063	61.600	73.976
y_7	-5.252	-4.545	-4.256	-4.879	141.580	-189.845	30.767
y_8	-5.832	-6.462	-6.445	-6.011	-111.996	507.800	529.556
y_9	4.278	4.097	4.179	4.073	10.249	33.625	6.085
y_{10}	3.967	3.330	3.462	3.341	245.294	-173.926	-93.779
y_{11}	-70.686	-70.413	-70.411	-69.988	-6.885	-51.785	-107.658
y_{12}	9.058	9.030	8.740	8.475	-39.763	-419.753	-285.213
y_{13}	-22.559	-22.792	-22.838	-22.788	20.960	182.595	162.026
y_{14}	-4.079	-3.961	-3.958	-3.400	31.643	7.114	-22.420
y_{15}	16.435	16.142	16.491	16.662	-14.357	139.721	67.53
y_{16}	20.195	19.918	19.902	20.173	15.771	-107.033	-201.282
y_{17}	-38.457	-37.118	-37.113	-37.866	-520.653	-13.730	-238.297
y_{18}	-15.974	-15.737	-15.650	-15.553	-191.132	47.897	43.542
y_{19}	5.203	5.335	5.137	4.835	123.099	11.275	72.113
y_{20}	12.568	12.303	12.257	11.974	-372.963	53.502	99.420

可见不同故障状态与正常工作状态下提取到的特征差异明显,可用于后续 PSOSVM 训练与分类. SDAE 模型的堆叠学习机制优势在于能够减小环境噪声带来的影响,提高模型诊断能力.

3 诊断算法

3.1 PSOSVM 诊断算法

SVM 利用非线性核函数将 SDAE 提取到的电压电流故障特征映射到高维特征空间,构造最优超平面实现 TRU 故障分类. SVM 一般形式为

$$\begin{cases} \min_{\omega, b, \xi} \left(\frac{1}{2} \|\omega\|_2^2 + C \sum_{i=1}^l \xi_i \right) \\ y_i((\omega, \varphi(x_i)) - b) \geq 1 - \xi_i \\ \xi_i \geq 0, i = 1, 2, \dots, l \end{cases} \quad (5)$$

式中: C 为 SVM 惩罚参数; ξ_i 为松弛变量; x_i 为故障特征样本; y_i 为样本标签. 核函数采用径向基函数 (radial basis function, RBF) 可以克服高维特征空间上的内积运算困难

$$K(x_i, x) = \exp\{-g \|x - x_i\|^2\} \quad (6)$$

式中: x_i 为故障特征样本输入; g 为核参数.

径向基核参数 g 与支持向量机惩罚参数 C 的取值大小影响样本训练与测试过程,容易导致 SVM 分类结果陷入局部最优,进而影响故障诊断准确性,所以对参数 C 与 g 的优化采用粒子群算法^[18-20].

每个粒子都代表一个故障特征训练样本的适应度,初始状态下粒子随机分布在整个 D 维搜索空间中,第 i 个粒子的位置表示为 $\mathbf{X}_i = [x_{i1} \ x_{i2} \ \dots \ x_{iD}]$,其飞行速度表示为 $\mathbf{v}_i = [v_{i1} \ v_{i2} \ \dots \ v_{iD}]$, $i = 1, 2, \dots, N$. 粒子的速度和位置状态更新如式(7)所示

$$\begin{cases} \mathbf{v}_{id}^k = \omega \mathbf{v}_{id}^{k-1} + c_1 r_1 (P_{id} - \mathbf{x}_{id}^{k-1}) + c_2 r_2 (P_d - \mathbf{x}_{id}^{k-1}) \\ \mathbf{x}_{id}^k = \mathbf{x}_{id}^{k-1} + \mathbf{v}_{id}^{k-1} \end{cases} \quad (7)$$

式中: $\mathbf{v}_{id}^k, \mathbf{x}_{id}^k$ 分别为粒子 i 第 k 次迭代后第 d 维上的速度矢量和位置矢量; ω 为线性递减的惯性权重,能够逐步提高局部搜索能力; c_1, c_2 为加速度常数,调节学习步长; r_1, r_2 为相互独立的 $[0, 1]$ 上的随机数; 本文取诊断结果误差函数 $f(x)$ 为适应度函数,则 P_{id} 为第 i 个粒子个体到目前为止搜索到的最佳适应度位置; P_d 为整个群体到目前为止搜索到的最佳适应度位置,可由此计算 C, g 值,用式(8)更新

$$\begin{cases} P_{id}^k = \begin{cases} P_{id}^{k-1}, & f(\mathbf{x}_{id}^k) \geq f(P_{id}^{k-1}) \\ \mathbf{x}_{id}^k, & f(\mathbf{x}_{id}^k) < f(P_{id}^{k-1}) \end{cases} \\ P_d = P_{id} |_{\min\{f(P_{id})\}}, \quad i = 1, 2, \dots, N \end{cases} \quad (8)$$

综上,基于 SDAE-PSOSVM 的航空变压整流器故障特征提取与故障诊断过程步骤如下:

① 搭建 TRU 模型,采集 TRU 原始输入电流与输出电压数据.

② 对信号进行噪声破坏,制作故障类别标签.

③ 利用 SDAE 进行数据训练,对故障电流电压数据进行特征提取,获取低维特征输出.

④ 将特征提取数据进行归一化处理,并划分为训练样本与测试样本,利用 PSO 对训练样本进行训练,建立训练网络,计算惩罚系数 C 、核参数 g ,建立优化的 SVM.

⑤ 利用 PSOSVM 对测试样本进行故障诊断与分类,并计算诊断正确率.

3.2 诊断分析

PSO 寻优算法利用故障二极管训练样本的训练误差构造适应度目标函数,计算最小误差与最优参数,适应度函数设定如式(9)所示

$$f = \frac{\sum_{i=1}^I (N_i - N_{is})^2}{I^2} \quad (9)$$

式中: I 为群体粒子数量; N_i 为当前粒子代表的故障二极管训练样本诊断编号; N_{is} 为粒子代表的故障样本实际编号. 在故障特征矩阵中随机选择 700 组故障特征向量作为训练样本,训练后得到 PSOSVM 诊断模型,对其余 50 组故障特征向量进行测试,得到故障诊断结果,并对比样本真实故障情况,计算诊断准确率. PSO 参数设定如表 3 所示.

表 3 PSO 参数

Tab. 3 Parameters of PSO

参数	值
迭代次数	200
群体粒子数量	50
c_1	0.5
c_2	0.5
ω_{\max}	0.9
ω_{\min}	0.4

在每次迭代过程中,计算 50 个粒子适应度值,根据平均适应度进行迭代寻优. 适应度曲线如图 7 所示,随着迭代次数增加与粒子群更新,训练误差逐渐下降,参数也逐渐优化. 平均适应度在迭代 35 次后趋于稳定且误差达到最小. 根据粒子群优化算

法,最终确定 SVM 惩罚参数 $C=49.4285$,核参数 $g=100$,最佳适应度达 95.7143% 。

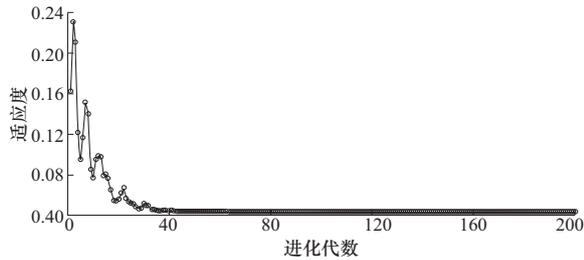


图 7 参数寻优适应度曲线

Fig. 7 Parameter optimization fitness

单次训练模型准确率达到 95.8571% , 单次测试样本诊断结果如图 8 所示, 50 个待测样本中仅第 10, 40, 48 号样本诊断错误, 故障诊断准确率达到 94% 。图中纵轴为每种故障类别编号, 编号 1 代表 TRU 正常状态, 编号 2~13 代表二极管 12 种开路故障, 编号 14~25 代表二极管 12 种短路故障。

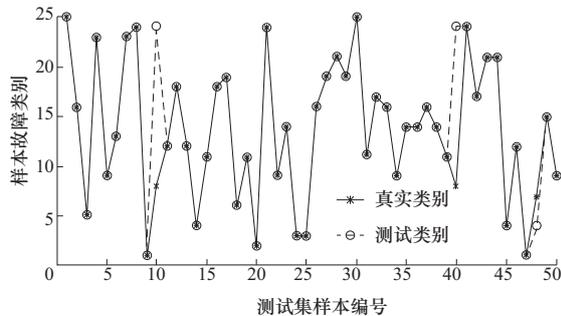


图 8 测试集故障诊断结果图

Fig. 8 Fault diagnosis results of testing set

计算 10 次诊断平均准确率结果作为诊断准确率, 可得训练集诊断准确率为 96.203% , 测试集诊断准确率为 96% , 训练集准确率与测试集准确率差别较小, 表明经过训练后建立的 SVM 分类器性能良好, 也表明此算法对 TRU 故障诊断具有良好的分类效果。

3.3 其它算法对比

为了进一步验证 SDAE-PSOSVM 的故障诊断效果, 同时采用不同诊断方法进行准确率对比。

① FFT+SVM: 在正常情况下, TRU 输入电流的主要谐波次数为 $12k \pm 1$ 次谐波, 当发生故障时, 输入电流的 1 次、 $6k \pm 1$ 次谐波分量的幅值以及输出电压幅值会发生较大变化, 利用 FFT 分析提取特征向量进行诊断分类。

② EEMD+SVM: EEMD 法对输入与输出信

号在不同时间尺度的本征模态分量进行提取, 获得可以作为特征向量的样本熵进行诊断分类。

③ SDAE+Softmax: 由于各故障模式相互独立, 可在 SDAE 最顶层添加 Softmax 层分类器, 采用逻辑回归方法对网络进一步微调, 从而对特征向量进行有监督训练分类。

各方法取 10 次诊断结果的准确率平均值进行比较, 如表 4 所示。

表 4 4 种方法的诊断准确率

Tab. 4 Diagnostic accuracy of four methods

方法	准确率/%
FFT+SVM	74.2
EEMD+SVM	86.8
SDAE+Softmax	82.4
SDAE+PSOSVM	96.0

分析表 4 可知, 采用不同算法的诊断结果有明显差异。方法 1 为传统诊断方法, 缺点在于需要花费大量时间对原始数据进行特征提取, 另外由于实际电路存在各种噪声, 会对提取的谐波分量造成较大影响, 使得 FFT 提取特征不够准确, 所以这种方法可靠性较低。方法 2 通过提取故障电流电压的样本熵, 提取的故障特征准确性较高, 但是诊断准确率没有本文改进方法高。方法 3 与本文方法均采用 SDAE 方法获取低维特征向量, 但是采用 Softmax 层分类器容易产生过拟合, 准确率明显低于本文方法。

综上所述, 特征提取效率与故障诊断方式均对诊断结果有很大影响。在故障诊断方面, 将 SDAE 与经过改进的 PSOSVM 相结合的故障诊断方法准确率高, 明显优于其他方法。

4 结 论

提出一种基于 SDAE-PSOSVM 的故障诊断改进方法, 通过仿真直接利用原始三相输入电流、输出电压数据信号实现对 TRU 二极管开路、短路故障的有效判断。传统故障诊断与故障定位方法在特征提取时受实际情况影响较大, 并且特征提取时间较长, 而本文方法结合了堆叠降噪自动编码器与粒子群优化算法的优势, 能够更高效进行复杂故障特征提取, 且最大程度保留了原始数据特性, 更准确地完成对 TRU 二极管的故障诊断, 因此本改进方法具有更高的应用价值。

参考文献:

- [1] 陈杰,申朋朋,陈新,等. 新型可变频升压比 18 脉波自耦变压整流器研究[J]. 电工技术学报, 2018, 33(15): 3607 - 3616.
CHEN Jie, SHEN Pengpeng, CHEN Xin, et al. Research on a novel variable step-up ratio 18-pulse auto-transformer rectifier unit[J]. Transactions of China Electrotechnical Society, 2018, 33(15): 3607 - 3616. (in Chinese)
- [2] 葛红娟,杨光,姜帆,等. 无平衡电抗器 24 脉自耦变压整流技术研究[J]. 北京理工大学学报, 2019, 39(2): 209 - 214, 220.
GE Hongjuan, YANG Guang, JIANG Fan, et al. Research on technology of non-balanced reactor 24-pulse auto-transformer rectifier[J]. Transactions of Beijing Institute of Technology, 2019, 39(2): 209 - 214, 220. (in Chinese)
- [3] 崔江,郭瑞东,张卓然,等. 基于改进 DBN 的发电机旋转整流器故障特征提取技术[J]. 中国电机工程学报, 2020, 40(7): 2369 - 2376, 2415.
CUI Jiang, GUO Ruidong, ZHANG Zhuoran, et al. Generator rotating rectifier fault feature extraction technique based on improved DBN[J]. Proceedings of the CSEE, 2020, 40(7): 2369 - 2376, 2415. (in Chinese)
- [4] 张瑶佳,王莉,尹振东,等. 基于 HHT 的航空直流串行电弧特征提取方法[J]. 航空学报, 2019, 40(1): 259 - 271.
ZHANG Yaojia, WANG Li, YIN Zhendong, et al. Characteristics extraction method of aviation DC serial arc fault based on HHT[J]. Acta Aeronautica et Astronautica Sinica, 2019, 40(1): 259 - 271. (in Chinese)
- [5] 白辉,许志红. 基于小波包变换和高阶累积量的电弧故障识别方法[J]. 电力自动化设备, 2020(11): 1 - 9.
BAI Hui, XU Zhihong. Arc fault identification method based on wavelet packet transform and high-order cumulant[J]. Electric Power Automation Equipment, 2020(11): 1 - 9. (in Chinese)
- [6] 周晨阳,沈艳霞. 基于小波分析的二重三相电压型逆变器开路故障诊断[J]. 电机与控制学报, 2020, 24(9): 65 - 75, 94.
ZHOU Chenyang, SHEN Yanxia. Open circuit fault diagnosis of dual three-phase voltage source inverter based on wavelet analysis[J]. Electric Machines and Control, 2020, 24(9): 65 - 75, 94. (in Chinese)
- [7] 魏文军,刘新发. 基于 EEMD 多尺度样本熵的 S700K 转辙机故障诊断[J]. 中南大学学报(自然科学版), 2019, 50(11): 2763 - 2772.
WEI Wenjun, LIU Xinfa. Fault diagnosis of S700K switch machine based on EEMD multiscale sample entropy[J]. Journal of Central South University (Science and Technology), 2019, 50(11): 2763 - 2772. (in Chinese)
- [8] 李继猛,李铭,姚希峰,等. 基于集合经验模式分解和 K-奇异值分解字典学习的滚动轴承故障诊断[J]. 计量学报, 2020, 41(10): 1260 - 1266.
LI Jimeng, LI Ming, YAO Xifeng, et al. Rolling bearing fault diagnosis based on ensemble empirical mode decomposition and K-singular value decomposition dictionary learning[J]. Acta Metrologica Sinica, 2020, 41(10): 1260 - 1266. (in Chinese)
- [9] 周锋,孙廷玺,权少静,等. 基于集合经验模态分解和极限学习机的变压器油中溶解气体体积分数预测方法[J]. 高电压技术, 2020, 46(10): 3658 - 3665.
ZHOU Feng, SUN Tingxi, QUAN Shaojing, et al. Prediction of dissolved gases concentration in transformer oil based on ensemble empirical mode decomposition and extreme learning machine[J]. High Voltage Technology, 2020, 46(10): 3658 - 3665. (in Chinese)
- [10] LU Chen, WANG Zhenya, QIN Weili. Fault diagnosis of rotary machinery components using a stacked denoising autoencoder-based health state identification[J]. Signal Processing, 2017, 130: 377 - 388.
- [11] HUANG Keke, LI Shuo, DAI Penglin, et al. SDARE: a stacked denoising autoencoder method for game dynamics network structure reconstruction[J]. Neural Networks, 2020, 126: 143 - 152.
- [12] YU Jianbo, ZHENG Xiaoyun, WANG Shijin. A deep autoencoder feature learning method for process pattern recognition[J]. Journal of Process Control, 2019, 79: 1 - 15.
- [13] 崔江,唐军祥,龚春英. 一种基于改进堆栈自动编码器的航空发电机旋转整流器故障特征提取方法[J]. 中国电机工程学报, 2017, 37(19): 5696 - 5706, 5847.
CUI Jiang, TANG Junxiang, GONG Chunying. A fault feature extraction method of aerospace generator rotating rectifier based on improved stacked auto-encoder[J]. Proceedings of the CSEE, 2017, 37(19): 5696 - 5706, 5847. (in Chinese)
- [14] 马利洁,朱永利. 基于 SDAE-VPMCD 的变压器故障诊断方法研究[J]. 电测与仪表, 2019, 56(17): 96 - 101.
MA Lijie, ZHU Yongli. Research on the fault diagnosis method of transformer based on SDAE-VPMCD[J]. Electrical Measurement and Instrumentation, 2019, 56(17): 96 - 101. (in Chinese)

(下转 1083 页)

- 2020,69(12):9645-9656.
- [10] MA J, WEI Y, LIANG P, et al. FusionGAN: a generative adversarial network for infrared and visible image fusion[J]. Information Fusion, 2019, 48: 11-26.
- [11] MA J, ZHANG H, SHAO Z, et al. GANMcC: a generative adversarial network with multiclassification constraints for infrared and visible image fusion[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 70: 1-14.
- [12] LI H, WU X J. Densefuse: a fusion approach to infrared and visible images [J]. IEEE Transactions on Image Processing, 2018, 28(5): 2614-2623.
- [13] ZHAO Z, XU S, ZHANG C, et al. DIDFuse: deep image decomposition for infrared and visible image fusion [C]//Proceedings of Twenty-Ninth International Joint Conference on Artificial Intelligence and Seventeenth Pacific Rim International Conference on Artificial Intelligence. [S. l.]: IEEE, 2020.
- [14] ZHANG Y, TIAN Y, KONG Y, et al. Residual dense network for image super-resolution [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. [S. l.]: IEEE, 2018: 2472-2481.
- [15] XU H, MA J, JIANG J, et al. U2Fusion: a unified unsupervised image fusion network[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020(7): 1-10.
- (责任编辑:李兵)

(上接第 1076 页)

- [15] 叶壮,余建波.基于多通道一维卷积神经网络特征学习的齿轮箱故障诊断方法[J].振动与冲击,2020,39(20): 55-66.
YE Zhuang, YU Jianbo. Gearbox fault diagnosis based on feature learning of multi-channel one-dimensional convolutional neural network[J]. Journal of Vibration and Shock, 2020, 39(20): 55-66. (in Chinese)
- [16] 黄宇剑,林圣,吴鉴舟,等.基于波形特征的地铁牵引整流器二极管开路故障诊断方法[J].电力自动化设备,2020,40(5):195-204.
HUANG Yujian, LIN Sheng, WU Jianzhou, et al. Fault diagnosis method of diode open circuit in metro traction rectifier based on waveform characteristics[J]. Electric Power Automation Equipment, 2020, 40(5): 195-204. (in Chinese)
- [17] 刘建强,刘传铎,王轶欧,等.单相 PWM 整流器 IGBT 及直流侧电容故障诊断方法[J].电工技术学报,2019,34(增刊 1):244-257.
LIU Jianqiang, LIU Chuanduo, WANG Yiou, et al. Fault diagnosis method for IGBT and DC-link capacitor of single-phase PWM rectifier[J]. Transactions of China Electrotechnical Society, 2019, 34 (suppl 1): 244-257. (in Chinese)
- [18] 王红军,邹安南,左云波.基于电流的主轴性能退化评估方法[J].北京理工大学学报,2019,39(1):22-27.
WANG Hongjun, ZOU Annan, ZUO Yunbo. Evaluation method of spindle performance degradation based on current [J]. Transactions of Beijing Institute of Technology, 2019, 39(1): 22-27. (in Chinese)
- [19] 石志炜,张丽萍,钟成豪,等.改进 PSO 优化 SVM 的滚动轴承故障诊断[J].福州大学学报(自然科学版),2020,48(3):333-340.
SHI Zhiwei, ZHANG Liping, ZHONG Chenghao, et al. Fault diagnosis of rolling bearing based on improved PSO optimized SVM[J]. Journal of Fuzhou University (Natural Science ed), 2020, 48(3): 333-340. (in Chinese)
- [20] 张子豪,郭俊康,洪军,等.航空发动机高压转子装配偏心预测和相位优化的智能算法应用研究[J].西安交通大学学报,2021(2):1-10.
ZHANG Zihao, GUO Junkang, HONG Jun, et al. Application study of intelligent algorithms for prediction and phase optimization of assembly eccentricity of aero-engine high pressure rotor[J]. Journal of Xi'an Jiaotong University, 2021(2): 1-10. (in Chinese)
- (责任编辑:李兵)