

DOI: 10.13382/j.jemi.2407442

反激式开关电源故障非侵入式 AI 诊断方法研究*

唐圣学¹ 谭立强¹ 李从宏² 严金晶¹ Muhammad Ehtsham Akram¹ 赵金泽¹

(1. 河北工业大学 省部共建电工装备可靠性与智能化国家重点实验室 天津 300401;

2. 南京工业职业技术大学 南京 210023)

摘要:将人工智能技术应用到故障诊断领域可以实现电力设备的自动化、智能化诊断,提高诊断精度和效率。以单输入多输出的反激式开关电源为例,针对其因脆弱元件失效而引起的电路工作性能异常的问题,通过分析不同故障模式的信号特性和可分性,提出了融合输入电流和输出电压信息的非侵入式开关电源故障诊断方法。构建了由时域特征及频带小波包奇异熵特征组成的融合时频域信息的多维特征矢量,建立了故障特征与故障模式之间的映射关系。进而,提出了基于人工智能技术的深度神经网络(DNN)故障诊断方法,实时监测反激式开关电源的运行状态,并通过数据分析及时识别故障位置,对潜在故障进行预警。实验结果表明,所提出的方法对单故障和多故障模式均具有良好的诊断效果,诊断准确率可达97.9%,并且,在不同工况下,该方法均可表现出较高的诊断准确率和较强的抗干扰性能。

关键词: 人工智能;反激式开关电源;时域特征;小波包奇异熵;故障诊断;DNN 辨识

中图分类号: TM13;TN86 **文献标识码:** A **国家标准学科分类代码:** 470.4017

Research on non-invasive AI diagnosis method for flyback switching power supply faults

Tang Shengxue¹ Tan Liqiang¹ Li Conghong² Yan Jinjing¹ Muhammad Ehtsham Akram¹ Zhao Jinze¹

(1. State Key Laboratory of Reliability and Intelligence of Electrical Equipment, School of Electrical Engineering, Hebei University of Technology, Tianjin 300401, China; 2. Nanjing Vocational University of Industry Technology, Nanjing 210023, China)

Abstract: The application of artificial intelligence technology to the field of fault diagnosis can realize the automation and intelligent diagnosis of power equipment and improve diagnosis accuracy and efficiency. Taking the single-input multiple-output flyback switching power supply as an example, for the problem of abnormal circuit performance caused by the failure of its fragile components, a non-intrusive switching power supply fault diagnosis method fusing the input current and output voltage information is proposed by analyzing the signal characteristics and divisibility of different fault modes. A multidimensional feature vector fusing time-frequency domain information consisting of time-domain features and frequency-band wavelet packet singular entropy features is constructed, and the mapping relationship between fault features and fault modes is established. Then, a deep neural network (DNN) fault diagnosis method based on artificial intelligence technology is proposed to monitor the operation status of the flyback switching power supply in real time, identify the fault location in time through data analysis, and provide early warning for potential faults. The experimental results show that the method proposed in this paper has a good diagnostic effect on both single-fault and multi-fault modes, the diagnostic accuracy can reach 97.9%, and the method can show high diagnostic accuracy and strong anti-interference performance under different working conditions.

Keywords: artificial intelligence; flyback switching power supply; time-domain feature; wavelet packet singular entropy; fault diagnosis; DNN recognition

0 引言

反激式开关电源因其高效、简洁的设计而在现代电子设备应用中越发广泛。作为一种电力转换装置,它能够将输入的交流电转换为稳定的直流电,以供设备使用。然而,尽管反激式开关电源的设计旨在提供稳定可靠的电源输出,但在实际应用中,由于元器件老化、设计缺陷、环境因素(如温度、湿度、电磁干扰)等原因使得它们仍然可能遇到各种故障和问题,如果不及时发现和解决,可能会导致设备性能下降,甚至完全失效,从而影响整个系统的稳定性和安全性^[1-3]。因此,对反激式开关电源进行状态监测和实时精准的故障诊断和维护,不仅是提高设备效率的关键,也是确保其长期稳定运行的必要条件。

目前,开关电源状态监测与故障诊断主要成果有:文献[4-7]指出故障失效主要由功率器件、电解电容、整流二极管、保护二极管等引起。文献[4]分析了具有 APFC 功能的开关电源元器件老化失效引起的故障模式,对由单个器件引起的硬故障及软故障进行状态监测与故障辨识。文献[5-6]研究了开关电源中的电解电容故障,指出了其是引起开关电源频繁故障的主要因素。文献[5]针对电解电容的失效问题,根据电源电压畸变程度判断滤波电容的故障率,并进行故障预警;文献[6]利用等效串联电阻(equivalent series resistance, ESR)作为反映电解电容性能退化的特性参数,建立纹波电压和 ESR 的映射关系,监测电解电容的退化情况和进行实时故障诊断。以上方法利用在线方式提取电压信号,可实现实时在线监测。文献[7]针对故障字典法不能有效诊断软故障的缺陷,提出了节点电压灵敏度序列的概念,同时实现了开关电源的软故障和硬故障诊断。

人工智能技术具有强大的数据搜索、处理以及决策能力,将人工智能的理论和方法应用于故障诊断技术成为近些年的研究热点[8-10]。文献[8]提出了一种基于深度学习的模块化多电平换流器(modular multilevel converter, MMC)的 IGBT 开路故障诊断方法,在不损害检测准确率的前提下,提升了故障检测速度。但该方法需要大量数据进行训练和测试,消耗了大量的计算资源。文献[9]提出了基于粒子群算法(particle swarm optimization, PSO)优化深度置信网络(deep belief network, DBN)的故障诊断方法,文献[10]提出了一种基于特征优选和深度学习的电源微小故障诊断方法。这些方法有效减低了噪声扰动,提升了诊断效率。

利用开关电源的人工智能(artificial intelligence, AI)故障诊断方法,可以提升故障诊断智能化和效率。通过以在中小功率高精度电源中具有广泛应用的反激式开关电源为例,因为目前关于其状态监测与故障分析相关研

究成果较少。与其他开关电源相比,反激式开关电源因工作频率较高,器件热应力较大,高频干扰强,导致信号波形复杂,且内部可观察点少,输出电压精度高,使早期故障后输出信号变化不明显,给监测增加了挑战^[11-13]。

综上,针对反激式开关电源中发生单个或多个脆弱元器件的软、硬故障问题,提出通过采集输入端电流以及输出端电压信号,提取时域特征以及频带小波包奇异熵特征共同构成融合时域与时频域信息的多维特征向量,并分析论证了故障特征与故障模式之间的可分性,进而提出利用深度学习技术的大数据处理与分析能力构建基于人工智能的深度神经网络(deep neural network, DNN)模型的故障诊断方法。

1 反激式开关电源

图1为高可靠电源设备所用的一个高精度单输入多输出的多路反激开关电源。其输入电压为220 V, 50 Hz的交流电,输出电压为 ± 15 V、+24 V 高稳定的直流电。

分析图1可知,高精度开关电源由桥式整流电路、单开关反激电路、高频稳压电路、控制电路、反馈电路、保护电路等构成,故障模式较复杂。电源运行的核心为控制芯片 UC3844,且 UC3844 直接驱动功率 MOSFET。UC3844 芯片原理是一种高性能的单端输出的电流控制型脉宽调制器芯片,能防止开机瞬间或负载短路时变压器可能出现的饱和现象,使用该芯片构成电源时所用外接元件少,结构简单,成本低。但是,只要控制芯片性能下降或出现故障,整个电路将无法工作。

输入交流电压经过整流、反激、整流、集成稳压后,并利用电压内部反馈调节和线性稳压模块以实现高精度稳定电压输出。然而,由于这种稳压机制降低了输出电压对内部电路元件参数的灵敏度,从而增加了利用输出端电压、电流来进行故障检测与诊断的难度。因此,仅采集输出端电压或者电流信号作为故障信息来源,故障可观测性较低。

基于上述分析,利用综合采集输入端电流信号、输出端电压信号的反激式开关电源的故障监测与诊断方法。该方法不影响设备运行,还可实现在线状态监测与故障诊断。

2 故障特性分析

根据市场调研报告显示,开关电源中功率器件、电解滤波电容、整流二极管、保护二极管等元件引起的故障超六成。电解电容、功率半导体开关管是目前公认的最易发生故障的器件。

开关电源故障可分为两种,一种是元件参数值偏离




图 1 反激式开关电源电路原理图

Fig. 1 Flyback switching power supply circuit diagram

标称值容差范围的软故障,如器件导通电阻增大、反向电阻减小;另一种是元件发生开路或短路情况下的硬故障。例如:分析图 1 电路元件可知,其中 C_1 、 $C_7 \sim C_9$ 为电解电容。电解电容内部容易发热使工作温度升高,从而加速电容电解液的蒸发造成电解电容性能下降,进而产生软故障,也可能产生开路或短路故障;整流二极管 $D_1 \sim D_4$ 、 $D_6 \sim D_8$ 和保护二极管 D_5 会受到脉冲冲击电流或电压,非常容易出现退化,也会出现软故障和硬故障;MOSFET 功率管 M_1 ,则会发生导通损耗和开关损耗,产生热应力而产生软故障和硬故障。根据图 1 所示电路和上述故障类型,搭建 Pspice 仿真电路,进行故障类型可检测与可诊断分析。仿真设置如下:三路输出负载电阻为 $20\ \Omega$,无源元件容差为 $\pm 5\%$,以 $220\ \text{V}$ 、 $50\ \text{Hz}$ 的正弦交流电为输入,运行仿真,通过采集输入电流和输出电压进行数据分析。

根据图 1 所示的电路图设计原理,三路输出均值电压分别为 $+24\ \text{V}$ 、 $+15\ \text{V}$ 和 $-15\ \text{V}$ 。由于三路输出结构相同,后续以第一路输出为例进行分析,图 2 给出了其正常状态下输出电压的暂态波形。在容差允许范围内,利用暂态波形,可计算出最大输出电压 $24.296\ \text{V}$,最小电压 $24.071\ \text{V}$,均值 $24.096\ \text{V}$,纹波电压 $\Delta V = 0.225\ \text{V}$ 。

在电路正常状态下,输入电流波形如图 3 所示。当达到稳定状态时,最大值为 $7.73\ \text{A}$,最小值为 $-7.69\ \text{A}$,输入电流是脉冲冲击波形。




图 2 输出电压示意图

Fig. 2 Schematic diagram of output voltage

2.1 硬故障

以电气隔离高频变压器为分析点,当后级输出回路中脆弱元件发生开路或短路的硬故障时,输出电压波形图如图 4 所示。

开关管发生开路故障,会导致电源无明显输出,故只考虑开关器件 M_1 的短路故障,故障后波形如图 4(b) 所示。由图 4(a) 和 (b) 可知,输出电压与正常状态下相比会有大幅度的下降,且此时电压存在延时,之后便处于不断启停状态,震荡状态。




图3 输入电流示意图

Fig. 3 Schematic diagram of the input current

输出回路滤波电容 C_7 发生开路 and 短路故障后,参考电源电路输出电压波形分别如图4(c)和(d)所示。由波形经过计算可得,滤波电容 C_7 开路时,最大电压变为




图4 各故障模式下输出电压波形

Fig. 4 Output voltage waveform under various fault modes

高频变压器前级输入回路中脆弱元件发生软、硬故障时,输出电压信号暂态波形如图5所示。由图5可知,输出电压只在波形的暂态部分有微弱变化,且变化时间很短。在几种典型故障模式下,输出电压信号对输入回路故障不灵敏,容易导致故障误判。

为了实现非侵入式的输入回路故障诊断,经过分析,由于输入电压受交流输入电源钳制,因而利用输入电流进行输入回路故障检测与诊断。

输入回路滤波电容和整流管发生硬故障后,输入电流波形如图6所示。由图6(a)可知,当滤波电容 C_1 发生开路故障时,导致输入电流幅值减小,波形明显不同,其中谐波含量明显增加。由图6(b)可知,当滤波电容 C_1 短路时,输入电流信号呈正弦周期性变化。

42.982 V,最小电压变为-5.442 V,均值 37.518 V,纹波电压 $\Delta V=48.424$ V。可知,因电容滤波稳压较小,以致纹波电压剧增,输出电压波形明显变坏。当 C_7 短路时,输出电压波形凌乱,且输出值较小,最大电压变为 320.0 mV,最小电压变为 -26.739 mV,电压均值为 234.603 mV,纹波电压 $\Delta V=346.739$ mV,此时没有输出电压。另外,如果电解电容出现参数退化的情况则只会影响电路性能。

输出回路整流管 D_6 发生开路或短路故障后,输出电压波形分别如图4(e)和(f)所示。可知,当整流管 D_6 开路时,输出电压波形杂乱、不稳定,且电压值很低。经计算得,输出电压均值为-357.22 nV。当整流管 D_6 发生短路故障时,最大电压变为 83.977 mV,最小电压变为 -461.226 mV,电压均值为 49.791 mV,纹波电压 $\Delta V=545.203$ mV,整流管 D_6 短路后,输出电压波形变为高频交流输出。




图5 输入回路故障的输出电压波形

Fig. 5 Output voltage waveform when the input circuit fails

由图 6(c) 可知,当整流桥二极管 D_1 发生开路故障时,整流桥的一个路径被切断,每个周期内只有半周期的输入交流电转化为直流电,使得整流效率降低,从而导致输出电流的有效值减少。由图 6(d) 可知,当二极管 D_1 发生短路故障时,会导致电流持续流过,不受交流输入电压的控制,使得电流急剧增加。显然,故障波形与正常波形明显不同。




图 6 C_1 、 D_1 硬故障时输入电流波形

Fig. 6 Input current waveform of C_1 and D_1 hard faults

2.2 软故障

电容软故障建模为等效参数退化,即容值降低、等效串联电阻增大。二极管软故障建模为内阻逐渐变大,反向漏电流逐渐增大。利用故障灵敏度分析,采用输入电流诊断前级故障,输出电压诊断后级故障。

电源软故障时输入电流和输出电压波形变化趋势如图 7 所示。由图 7(a) 和(b) 可知,当输入回路中电解电容和整流二极管等元件发生参数退化时,电路稳定后不同故障模式下输入电流的波形和幅值均存在明显的差异;由图 7(c) 和(d) 可知,当输出回路中电解电容和整流二极管等元件发生参数退化时,电路稳定后输出电压波形凌乱,存在纹波电压,但输出电压有效值相差不大。

根据以上分析,将输入和输出回路中由单个元器件引起的软故障称为单故障 I 型,硬故障称为单故障 II 型;由多个元器件引起的软故障称为多故障 I 型,硬故障称为多故障 II 型,多故障主要考虑输入和输出同时发生故障。表中 $\downarrow$ 表示元器件相对于标称值下降 20% 以上, $\uparrow$ 表示元器件相对于标称值上升 20% 以上。可诊断的故障模式如表 1 所示。




图 7 软故障信号波形

Fig. 7 Signal waveforms for soft faults

表 1 反激式开关电源的故障类型

Table 1 Fault types of flyback switching power supply			
故障标签	故障模式	故障类别	诊断信号
F1	—	正常	I_{in} 、 V_{out}
F2	$C_1 \downarrow$	单故障 I 型	I_{in}
F3	$D_1 \uparrow$	单故障 I 型	I_{in}
F4	C_1 开路	单故障 II 型	I_{in}
F5	C_1 短路	单故障 II 型	I_{in}
F6	D_1 开路	单故障 II 型	I_{in}
F7	D_1 短路	单故障 II 型	I_{in}
F8	$C_7 \downarrow$	单故障 I 型	V_{out}
F9	$M_1 \uparrow$	单故障 I 型	V_{out}
F10	$D_6 \uparrow$	单故障 I 型	V_{out}
F11	C_7 开路	单故障 II 型	V_{out}
F12	C_7 短路	单故障 II 型	V_{out}
F13	M_1 短路	单故障 II 型	V_{out}
F14	D_6 开路	单故障 II 型	V_{out}
F15	D_6 短路	单故障 II 型	V_{out}
F16	$M_1 \uparrow$ 、 $C_7 \downarrow$	多故障 I 型	V_{out}
F17	$C_1 \downarrow$ 、 $D_6 \uparrow$	多故障 I 型	I_{in}
F18	M_1 短路、 D_6 开路	多故障 II 型	V_{out}
F19	C_1 短路、 D_6 开路	多故障 II 型	V_{out}
F20	D_1 开路、 C_7 短路	多故障 II 型	I_{in}

3 特征提取

目前,故障特征提取方法分为时域法、频域法和时-频域法。采用多域特征组成的混合特征向量作为故障特征向量,可以更全面地捕捉故障特征,从而提高故障检测和诊断的准确性。

3.1 时域特征

时域特征分为有量纲特征值和无量纲特征值。有量纲特征值如最值、有效值、均值等易受工况等影响,无量纲特征值则被影响不明显,如波形因数、冲击因数、裕度因数等,可很好反映故障状态。综合考虑反激式开关电源电路发生软、硬故障信号特点,选取综合2种量纲的11种时域特征为故障特征,其数学表达式如表2所示。

表2 时域特征
Table 2 Time-domain features

时域特征	计算方式
平均值	$\bar{s} = \frac{1}{N} \sum_{i=1}^N s_i$
标准差	$\rho t = \left(\frac{1}{N} \sum_{i=1}^N (s_i - \bar{s})^2 \right)^{\frac{1}{2}}$
有效值	$s_{rms} = \left(\frac{1}{N} \sum_{i=1}^N s_i^2 \right)^{\frac{1}{2}}$
偏度	$s_{ske} = \frac{\frac{1}{N} \sum_{i=1}^N (s_i - \bar{s})^3}{\rho t^3}$
峭度	$s_{kur} = \frac{\frac{1}{N} \sum_{i=1}^N (s_i - \bar{s})^4}{\rho t^4}$
峰-峰值	$\Delta s = s_{max} - s_{min}$
振幅因数	$C_f = s_{max} / s_{rms}$
波形因数	$W_f = s_{rms} / \left(\frac{1}{N} \sum_{i=1}^N s_i \right)$
冲击因数	$I_f = s_{max} / \left(\frac{1}{N} \sum_{i=1}^N s_i \right)$
裕度因数	$M_f = s_{max} \left(\frac{1}{N} \sum_{i=1}^N s_i \right)^2$
峭度因数	$K_f = s_{kur} / s_{rms}^4$

表中 s_i 为信号的采样数据点幅值, N 为每个样本的采样数据点数。上述 11 维的特征矢量表示为:

$$FV = [\bar{s} \ \rho t \ s_{rms} \ s_{ske} \ s_{kur} \ \Delta s \ C_f \ W_f \ I_f \ M_f \ K_f] \quad (1)$$

为了说明时域特征的故障可分性,图8给出了均值、有效值、峰-峰值三维特征下的输入回路故障分布图。由图8可知,故障可观测性较强,容易区分。除此外,故障F5、F6、F7的峰-峰值或平均值为正常状态的十几倍以上,特征差异明显。因数值过大,图8中没有画出。

相对于硬故障,电源软故障特征具有一定的重叠和模糊性。图9为不同软故障下输出电压均值、有效值以及纹波量的三维特征分布图。由图9可知,在输出电压均值、有效值、纹波量3种特征下,软故障也具有可区分性,但同时也会存在故障重叠的现象,如F1、F9和F16的3种特征值较为接近,容易混淆,不利故障分类。

3.2 小波包奇异熵

为了进一步区分软故障,提取时频域小波包奇异熵




图8 输入回路故障的三维特征分布
Fig. 8 3D feature distribution during input circuit failure




图9 电源软故障时的三维特征分布
Fig. 9 3D feature distribution during power supply soft faults

作为特征矢量,用于量化信号在频域上的复杂性或不规则性,可降低故障的重叠性^[14]。

计算小波包奇异熵的具体步骤如下:首先对信号 $S(N)$ 进行小波包分解,再对各分解频段系数进行重构得到小波包重构系数矩阵 A ,并对其进行奇异值变换得到对角矩阵 Λ ,其对角元素 $\{\lambda_1, \lambda_2, \dots, \lambda_r\}$ 即为矩阵 A 的奇异特征值 (r 为矩阵 A 的秩),进而建立 λ_i 的概率分布量 p_i ,计算公式如式(2)所示。

$$p_i = \lambda_i / \sum_{j=1}^k \lambda_j \quad (2)$$

其中, j 为经小波包分解后所得的频段数量,则信号 $S(N)$ 的 k 阶小波包奇异熵的表达式为:

$$W_{SE}(k) = - \sum_{i=1}^k p_i \ln p_i \quad (k \leq r) \quad (3)$$

为增加故障可分性,构建了融合时频域信息的20维特征向量,其具体组成为:表2中11种时域特征、三层小波包分解后的9个小波包奇异熵特征,将其依次编号为1~20,作为故障诊断的特征向量。

图10为一个典型的时频特征下的故障分布。图10所示为电源输出回路的5种软故障。由图10可知,融合时频信息的故障特征可观测性较强,容易区分。

对比图 10 和 9 可知,虽然故障 F1、F9 和 F16 电压平均值和纹波量特征较为接近,但小波包奇异熵特征区别明显。因此,引入小波包奇异熵构成的融合时频信息的特征矢量在不同故障模式下特征重叠性较低,可分性较好。




图 10 融合时频信息的三维特征分布

Fig. 10 3D feature distribution integrating time-frequency information

4 基于 AI 技术的故障诊断方法

基于上述故障分析和特征,基于人工智能技术的开关电源的故障诊断方法被提出,方法流程图如图 11 所示。




图 11 AI 诊断方法流程图

Fig. 11 AI diagnostic method flowchart

采集开关电源的输入电流和输出电压信号,对其进行数据处理提取故障特征,进而采用人工智能领域的深度学习技术构建故障诊断模型,实现对不同的故障模式

的分类识别,利用网络算法对大量的数据信息进行分析及时识别故障类型,并对潜在故障发出预警。

由于深度神经网络(DNN)在人工智能领域中技术成熟、应用广泛,因此选用深度神经网络进行故障识别分类。包含两个隐藏层的 DNN 各层结构设计如图 12 所示。输入层、隐藏层和输出层的层与层之间是全连接的,隐藏层是 DNN 的核心组成部分,每个隐藏层中的神经元用于对上一层输出进行处理,提取特征信息,由输出层得出预测结果^[15-16]。




图 12 DNN 结构示意图

Fig. 12 Structure of DNN

上述提出的开关电源故障 AI 诊断方法的具体步骤如下:

步骤 1)采集反激式开关电源的输入电流和输出电压,获取不同故障模式下的诊断信号。

步骤 2)对诊断信号进行数据处理,分析反激式开关电源的信号特性和故障可分性。

步骤 3)提取信号时域特征、时频域小波包奇异熵特征,组成融合时频信息的 20 维特征矢量;进而构建数据集,并划分训练集和测试集。

步骤 4)学习训练 DNN 模型并将特征数据输入到 DNN 诊断模型,根据最大输出确定故障类型归属。

5 实验测试

为了验证基于人工智能技术的深度神经网络诊断方法,对反激式开关电源进行了故障诊断实验,实验测试平台如图 13 所示。

为了模拟复杂电源变化和负载情况,平台采用可调交流电源和可编程电子负载模拟工况,同时对分立元件故障采用故障注入法模拟故障情况。由于本文篇幅所限,以电解电容 C_1 的软、硬故障为例,采集实验测试波形如图 14 所示。

由图 14 可知,实验测试波形与仿真波形一致,但是因在实验过程中受电阻热噪声、半导体器件的散粒噪声和闪烁噪声等干扰,测试波形存在高频噪声。




图 13 实验测试平台

Fig. 13 Experimental test platform




图 14 实验测试波形

Fig. 14 Experimental test waveform

5.1 方法说明

为了获取各种数据,用 Cadence Orcad/Pspice17.4 软件搭建主电路仿真模型,对电路进行仿真和故障模拟,模拟电路中无源器件的容差设置为 $\pm 5\%$,利用 Monte-Carlo 获取每个故障的 50 个样本数据集,进而利用 MATLAB 2022a 进行数据处理,提取 20 维特征向量。

故障诊断测试实验在 MATLAB 2022a 平台及其智能工具箱进行。利用相同的数据集对 DNN 模型与反向传播 (back propagation, BP)、PSO-BP、长短时记忆 (long short term memory, LSTM)、卷积神经网络 (convolutional neural network, CNN) 等网络模型^[17-20]进行对比分析。各模型参数设置如下:

DNN 模型采用 Adam 梯度下降算法学习优化,初始学习率为 0.002,模型大小设置为 100,模型的训练迭代次数设置为 500,激活函数为 ReLU;BP 网络采用 3 层神

经网络,隐含层神经元个数为 20 个;CNN 网络、LSTM 网络均采用 Adam 梯度下降算法学习优化,CNN 网络的初始学习率为 0.001,学习率下降因子为 0.1,激活函数 ReLU,最大迭代次数为 500 次;LSTM 网络初始学习率为 0.01,学习率下降因子为 0.1,学习率下降周期为 750,最大迭代次数为 1 000 次。

将含有 20 维特征向量样本数据集的 80% 划分为训练集,20% 划分为测试集。利用训练集和测试集进行训练和测试 DNN 模型,经过一次运行的诊断结果和混淆矩阵如图 15 和 16 所示。

根据图 15 和 16 可得,经过一次运行的 DNN 模型诊断准确率达 98%。在 200 个测试样本中,有 4 个样本出现了误判,将输出回路中的 F14 故障(整流二极管 D_o 开路)错误识别为其他种类的故障。通过分析可知,误判故障为输出回路元件,输入回路中没有发生误判现象,这是因为输入回路通过采集输入电流来区分故障,电流灵敏度高,故障特征区别明显。




图 15 测试集故障诊断结果

Fig. 15 Fault diagnosis result of test set

在模型训练过程中,作为评估模型的泛化能力的指标,准确度能够衡量模型在所有预测样本中预测正确的比例,损失值则能够衡量模型预测结果与真实值之间差异。准确度越高、损失值越小,且二者出现一致的稳定变化趋势时,说明模型的性能越好^[17]。采用 DNN 模型学习训练过程中准确度和损失变化情况如图 17 所示。

由图 17 可知,模型的准确度随迭代次数递增,损失随迭代次数递减。当迭代次数达到 2 000 次左右时,模型准确率和损失值都逐渐趋于稳定,其后波动很小,说明了训练过程中学习数据的效果良好,过拟合风险较低。

5.2 实验结果分析

为了验证 DNN 模型的诊断效果,将 DNN 模型与 5.1 小节中所列模型进行对比分析,各模型诊断结果如表 3 所示。表中数据为 10 次测试的平均值,以减少诊断模型




图 16 测试集混淆矩阵
Fig. 16 Confusion matrix for test set




图 17 DNN 模型训练过程
Fig. 17 DNN model training process

表 3 诊断模型性能对比

Table 3 Diagnostic model performance comparison				
辨识模型	训练集样本数	测试集样本数	训练精度/%	测试精度/%
BP	800	200	84.29	82.20
PSO-BP	800	200	87.13	85.65
LSTM	800	200	93.19	90.55
CNN	800	200	98.19	96.75
DNN	800	200	98.73	97.90

由表 3 分析可知,利用 DNN 故障诊断模型测试平均分类精度可达 97.9%,比 BP、PSO-BP、LSTM、CNN 分别高 15.7%、12.25%、7.35%、1.15%,优势明显,说明诊断效果良好。这是因为 DNN 诊断模型能够自动从原始数据中学习到有用的特征,通过多层结构能够捕捉数据中的非线性和复杂模式。BP 网络参数量较大,在训练数据不充分的情况下容易发生过拟合,经过 PSO 优化 BP 网络,参数调优复杂,训练模型耗时较长、诊断准确率较低;

基于深度学习的 LSTM 在小样本数据的情况下容易发生拟合,CNN 在处理高维数据时对时间序列数据的特征捕捉能力相对较弱。

实际运行环境会受负载或环境等混杂噪声干扰。为了说明模型诊断方法抗干扰性能,将不同信噪比白噪声(信噪比 10 dB、15 dB、20 dB)加入到采集信号中以模拟干扰状态,测试验证模型性能,诊断结果如表 4 所示。

表 4 抗干扰性能对比

Table 4 Comparison of anti-interference performance (%)			
辨识模型	诊断准确率		
	10 dB	15 dB	20 dB
BP	75.80	79.30	81.45
PSO-BP	78.85	82.25	83.90
LSTM	83.90	87.55	89.35
CNN	90.75	93.65	95.30
DNN	94.15	96.35	97.15

由表 4 可知,在不同信噪比下,所提方法准确率均高于其它模型。在信噪比为 10 dB 时,受噪声污染严重,各模型诊断准确率均有较大程度的下降,但 DNN 模型诊断准确率仍可达 94.15%,表明 DNN 模型抗干扰性能好,鲁棒性较强。

6 结 论

基于反激式开关电源内部可观察点少,输出电压精度高的监测难点,对不同故障模式,通过采集输入端电流信号并结合输出端电压信号,实现了非侵入式的在线故障诊断,通过融合时域、时频域信息的特征提取方法,提出了基于人工智能技术的深度神经网络诊断模型。实验结果表明,所提方法的诊断准确率达 97.9%,在不同工况下,均可表现出较高的诊断准确率,抗干扰性能较好。与传统的诊断方法相比,所提方法能够捕捉到故障信号中的复杂模式和微弱变化,不需要对开关电源的内部结构进行改动或添加额外的传感器,不会影响电源正常运行状态,实现了无侵入监测,并且该方法的适应性和自动化程度高,适用于开关电源的单故障和多故障诊断,降低了维护成本和人力需求。

参考文献

[1] 姜月明,俞洋,彭喜元. 基于关键特征提取和 Elman 神经网络的开关电源多参数辨识[J]. 电子测量与仪器学报,2021,35(7):11-19.

JIANG Y M, YU Y, PENG X Y. Multi-parameter identification of switch mode power supply based on key features and Elman neural network [J]. Journal of Electronic Measurement and Instrumentation, 2021,

- 35(7):11-19.
- [2] TUMMALA S K, DURAISWAMY L. Switched mode power supply: A high efficient low noise forward converter design topology [C]. 2022 IEEE 2nd International Conference on Sustainable Energy and Future Electric Transportation (SeFeT), 2022.
- [3] 郭志军, 杨亚锋, 吴静波, 等. 基于小波包神经网络的开关电源电路故障诊断研究[J]. 现代电子技术, 2019, 42(7): 125-128.
- GUO ZH J, YANG Y F, WU J B, et al. Research on fault diagnosis of switching power supply circuit based on wavelet packet neural network [J]. Modern Electronics Technique, 2019, 42(7): 125-128.
- [4] TANG S X, WANG H F, WANG W W, et al. A fault diagnosis method for active power factor correction power supply based on seagull algorithm optimized kernel-based extreme learning machine [J]. International Journal of Circuit Theory and Applications, 2024, 52 (3): 1116-1135.
- [5] ZHOU L, YU C, LIU H, et al. Fault diagnosis model of switching power supply based on improved DBN [C]. 2021 16th International Conference on Intelligent Systems and Knowledge Engineering (ISKE), 2021.
- [6] SHI Z Y, LU Y D, NING T, et al. The real-time fault diagnosis of electrolytic filter capacitors in switching mode power supply [C]. Proceedings of the 20th IEEE International Symposium on the Physical and Failure Analysis of Integrated Circuits (IPFA), 2013.
- [7] ZHU M, TONG C M, DAI J Z, et al. The fault diagnosis of switching power supply based on the principle of the sensitivity sequence of node-voltage [C]. 2014 9th IEEE Conference on Industrial Electronics and Applications, 2014.
- [8] 朱琴跃, 于逸尘, 占岩文, 等. 基于短时傅里叶变换和深度网络的模块化多电平换流器子模块 IGBT 开路故障诊断[J]. 电工技术学报, 2024, 39(12): 3840-3854.
- ZHU Q Y, YU Y CH, ZHAN Y W, et al. IGBT open-circuit fault diagnosis of modular multilevel converter submodule based on short-time Fourier transform and deep [J]. Transactions of China Electrotechnical Society, 2024, 39(12): 3840-3854.
- [9] HU Z Q, XIA K, FAN Z F, et al. A novel switch open-circuit fault diagnostic method for three-phase inverter based on PSO-DBN [C]. 2022 9th International Forum on Electrical Engineering and Automation (IFEAA), 2022.
- [10] 李炜, 韩寅龙, 孙晓静. 基于特征优选与深度学习的车载电源微小故障诊断方法[J]. 兵工学报, 2022, 43(11): 2935-2944.
- LI W, HAN Y L, SUN X J. Incipient fault diagnosis method of vehicle power supply based on feature optimization and deep learning [J]. Acta Armamentarii, 2022, 43(11): 2935-2944.
- [11] 胡亮灯, 孙驰, 赵治华, 等. 高电压宽范围输入低电压输出的 DC-DC 辅助电源设计[J]. 电工技术学报, 2015, 30(3): 103-114.
- HU L D, SUN CH, ZHAO ZH H, et al. High voltage wide range input low voltage output DC-DC auxiliary power supply designs [J]. Transactions of China Electrotechnical Society, 2015, 30(3): 103-114.
- [12] 张家刘, 李正权. 基于改进鲸鱼算法优化模糊控制的开关电源[J]. 电子测量技术, 2024, 47(1): 87-92.
- ZHANG J L, LI ZH Q. Optimization of fuzzy control for switching power supply based on improved whale algorithm [J]. Electronic Measurement Technology, 2024, 47(1): 87-92.
- [13] 黄阳强, 许建平, 殷刚, 等. 准谐振软开关双管反激变换器[J]. 电工技术学报, 2018, 33(18): 4313-4322.
- HUANG Y Q, XU J P, YIN G, et al. Quasi-resonant soft-switching two-tube flyback converter [J]. Transactions of China Electrotechnical Society, 2018, 33(18): 4313-4322.
- [14] 唐圣学, 马晨阳, 勾泽. 基于时频特征融合与 GWO-ELM 的棒控电源早期故障状态辨识方法[J]. 仪器仪表学报, 2023, 44(1): 121-130.
- TANG SH X, MA CH Y, GOU Z. Early fault state identification method of the rod control system power equipment based on time-frequency characteristics fusion and GWO-ELM [J]. Chinese Journal of Scientific Instrument, 2023, 44(1): 121-130.
- [15] YUAN Q Y, XIAO N F. Scaling-based weight normalization for deep neural networks [J]. IEEE Access, 2019, 7: 7286-7295.
- [16] 刘钊, 孙洁媿, 温江涛. 基于多层面压缩深度神经网络的轴承故障诊断[J]. 电子测量与仪器学报, 2022, 36(7): 189-198.
- LIU ZH, SUN J D, WEN J T. Bearing fault diagnosis method based on multi-dimension compressed deep neural network [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(7): 189-198.
- [17] 王力, 李振壁, 姜媛媛. 基于 MHHO-BP 算法的 DC-DC 电路软故障诊断[J]. 电子测量技术, 2022, 45(18): 25-31.
- WANG L, LI ZH B, JIANG Y Y. Soft fault diagnosis of DC-DC circuits based on MHHO-BP algorithm [J]. Electronic Measurement Technology, 2022, 45(18): 25-31.
- [18] ZHENG Q H. Retracted: Information system security

evaluation algorithm based on PSO-BP neural network[J]. Computational Intelligence and Neuroscience, 2021, 2021(1): 6046757.

[19] FENG R, DU H, DU T, et al. Fault diagnosis for wind turbines based on LSTM and feature optimization strategies[J]. Concurrency and Computation: Practice and Experience, 2024, 36(1): e7886.

[20] DU T, ZHANG H, WANG L. Analogue circuit fault diagnosis based on convolution neural network[J]. Electronics Letters, 2019, 55(24): 1277-1279.

作者简介



唐圣学(通信作者), 2001 年于吉首大学获得学士学位, 2004 年于湖南大学获硕士学位, 2008 年于湖南大学获博士学位, 现为河北工业大学教授, 主要研究方向为电力电子技术、新能源发电技术。
E-mail: tsx@hebut.edu.cn

Tang Shengxue(Corresponding author) received his B. Sc. degree in 2001 from Jishou university, received his M. Sc. degree in 2004 from Hunan university, received his Ph. D. degree in 2008 from Hunan university. Now he is a professor in Hebei University of Technology. His main research interests include power electronics technology and new energy power generation technology.



谭立强, 2022 年于陕西科技大学获得学士学位, 现为河北工业大学硕士研究生, 主要研究方向为电力电子技术、新能源发电技术。
E-mail: 849328200@qq.com

Tan Liqiang received his B. Sc. degree in 2022 from Shaanxi University of Science & Technology. Now he is a M. Sc. in Hebei University of Technology. His main research interests include power electronics technology and new energy power generation technology.