

基于卷积神经网络和格拉姆角差场的 四象限脉冲整流器故障诊断方法

翟道宇 孙燕楠

(大连交通大学詹天佑学院, 辽宁 大连 116028)

摘要 为充分发挥卷积神经网络(CNN)在图像识别分类中的优势,提出一种基于卷积神经网络和格拉姆角差场(GADF)的四象限脉冲整流器故障诊断方法。首先利用格拉姆角差场将整流器网侧电流一维时间序列转换为二维特征图,保留数据对时间的依赖性,识别出信号在不同时间间隔内的时间相关性;然后利用卷积神经网络对生成的特征图进行整流器开路故障特征提取与分类,并与其他常见故障诊断方法比较。仿真分析结果表明,相较于其他故障诊断方法,所提方法具有更高的诊断准确率。

关键词: 四象限脉冲整流器; 格拉姆角差场(GADF); 卷积神经网络(CNN); 故障诊断

Fault diagnosis method for four-quadrant pulse rectifiers based on convolutional neural network and Gramian angular difference field

ZHAI Daoyu SUN Yannan

(Zhan Tianyou College of Dalian Jiaotong University, Dalian, Liaoning 116028)

Abstract To fully exert the advantages of the convolutional neural network (CNN) in image recognition and classification, a fault diagnosis method for four-quadrant pulse rectifiers based on CNN and Gramian angular difference field (GADF) is proposed. GADF is utilized to transform the one-dimensional time series of rectifier current into a two-dimensional feature map, preserving the temporal dependency of the data and identifying the temporal correlations of the signal over different time intervals. The CNN then extracts and classifies the features of open circuit faults in the rectifier from the generated feature maps. This method is compared with other common fault diagnosis methods. Simulation analysis results indicate that this proposed method achieves higher diagnostic accuracy compared to other fault diagnosis methods.

Keywords: four-quadrant pulse rectifiers; Gramian angular difference field (GADF); convolutional neural networks (CNN); fault diagnosis

0 引言

四象限脉冲整流器作为列车牵引变流系统的关键组成部分,其可靠性对列车的安全运行具有至关重要的影响。如果四象限脉冲整流器出现故障,就可能对列车的安全运行造成严重威胁,进而影响铁路运输的安全。调查研究表明,功率器件绝缘栅双极型晶体管(insulated gate bipolar transistor, IGBT)作为整流器主电路的组成部分,其开路、短路故障在所有整流器故障类型中占比较高^[1]。IGBT短路可

能引发过电流问题,这类故障可以通过过电流检测迅速诊断出来。然而,IGBT开路故障通常不会引发明显的过电流、过电压或欠电压等现象,其诊断和相应保护更加困难和复杂。因此,对IGBT开路故障进行快速、有效且准确的诊断,对于四象限脉冲整流器控制系统的稳定运行及列车行车安全具有决定性的影响。

对四象限脉冲整流器IGBT开路故障的诊断方法主要有三类:基于信号处理、解析模型及知识的诊断方法。基于信号处理的诊断方法通过分析逆变

器的输出电流或电压信号来实现故障诊断,该方法简单易行,但在具体应用中的诊断实时性较差^[2-3]。基于解析模型的诊断方法通过建立逆变器的数学模型并获得残差信号来实现故障检测,该方法的诊断准确度取决于所建立数学模型的准确度^[4]。伴随着机器学习、深度学习等算法的不断发展,相较于前两种诊断方法,基于知识的诊断方法成为当下的研究热点。基于知识的诊断方法主要包括特征处理和故障识别两部分。

特征处理包括信号采集、数据分析和特征提取等环节,其中特征提取环节的结果影响最终的 IGBT 故障识别准确性。文献[5]利用快速傅里叶变换(fast Fourier transform, FFT)提取信号故障特征,但 FFT 无法分析信号的局部特征,使其对故障的识别准确率较低。文献[6]对逆变器输出电流信号进行小波包分解,并对各个节点进行重构,获取可用于诊断的故障特征,诊断效果良好,但小波变换的计算复杂度较高,在处理大规模数据时,计算时间较长。文献[7]通过主成分分析(principal component analysis, PCA)法进行特征提取,在进行多种类别的 IGBT 开路故障诊断时,诊断效果良好,但由于传统 PCA 均匀化分布数据的特性,使故障特征不明显,导致相似故障无法被区分。

在进行特征处理后,可以采用多种智能算法进行故障识别。近年来,支持向量机(support vector machines, SVM)、K 最近邻法(k-nearest neighbor, KNN)、朴素贝叶斯(naive Bayes, NB)法及决策树等机器学习算法被广泛应用,但这些算法均属于浅层学习,对复杂分类问题的泛化能力不足^[8-10]。随着深度学习的不断发展,在无监督学习方式下,深度学习可实现特征自动提取,特征学习与分析能力更强,从而可以提升分类与预测的准确性。文献[11]利用误差反向传播神经网络(back propagation neural network, BPNN)对故障特征向量进行训练并实现故障诊断。文献[12]采用一维卷积神经网络(one-dimensional convolutional neural network, 1D-CNN)实现 IGBT 开路故障诊断,具有较好的诊断效果,1D-CNN 适用于处理一维时序数据,主要关注数据中局部空间上的数值变化,在应对多种故障类型和复杂工况时的准确率较低。

二维卷积神经网络(two-dimensional convolutional neural network, 2D-CNN)在图像的特征提取方面具有巨大优势,与 1D-CNN 对比,2D-CNN 具有更高的识别准确率与稳定性^[13]。将 2D-CNN 应

用于 IGBT 开路故障诊断中,需要将采集到的一维时间序列转换为二维图像。

格拉姆角差场(Gramian angular difference field, GADF)是一种将一维时序信号进行二维图像化编码的全新方法^[14-16],其在将一维时间序列转换为图像的过程中,既能保留信号的完整信息,也能保留信号对时间的依赖性。

本文提出一种结合 GADF 和 2D-CNN 的四象限脉冲整流器 IGBT 开路故障诊断方法。在特征处理阶段,采用 GADF 代替传统的特征提取方法,将一维时间序列数据转换为二维图像,以此作为 2D-CNN 的输入,从而实现故障诊断。

1 四象限脉冲整流器 IGBT 开路故障分析

1.1 列车四象限脉冲整流器主电路

我国列车(如 CRH5)牵引变流系统所使用的脉冲整流器为单相两电平脉冲整流器,其主电路如图 1 所示。

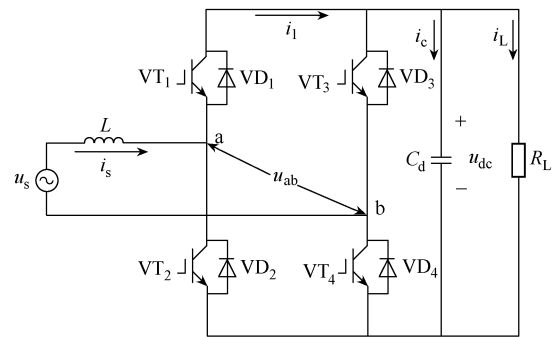


图 1 单相两电平脉冲整流器主电路

图 1 中, u_s 、 i_s 和 u_{ab} 分别为网侧电压、网侧电流及整流器输入电压, u_{dc} 为直流侧电压, i_1 为流过 a 桥上桥臂电流, L 、 R_L 、 C_d 分别为网侧电感、直流侧电阻负载及直流侧支撑电容, i_c 、 i_L 分别为直流侧支撑电容电流、电阻负载电流, VT_1 、 VT_2 、 VT_3 、 VT_4 分别代表 4 个 IGBT 开关模块, VD_1 、 VD_2 、 VD_3 、 VD_4 分别代表 4 个续流二极管。定义整流器桥臂 a、b 的理想开关函数 S_a 、 S_b 分别为

$$\begin{cases} S_a = \begin{cases} 1 & VT_1 \text{ 或 } VD_1 \text{ 导通} \\ 0 & VT_2 \text{ 或 } VD_2 \text{ 导通} \end{cases} \\ S_b = \begin{cases} 1 & VT_3 \text{ 或 } VD_3 \text{ 导通} \\ 0 & VT_4 \text{ 或 } VD_4 \text{ 导通} \end{cases} \end{cases} \quad (1)$$

则四象限脉冲整流器共 00、11、10、01 四种工作模式。

1.2 四象限脉冲整流器单管开路故障分析

当 VT_1 开路,即a桥臂上半桥臂IGBT开路时,仅影响 $S_a=1$ 的工作模式,即 $S_aS_b=11$ 和 $S_aS_b=10$ 两种工作模式。此时,若 $i_s > 0$,可经 VD_1 续流通过a桥臂上半桥臂,所以整流器工作模式不受影响;若 $i_s < 0$, $S_aS_b=11$ 和 $S_aS_b=10$ 两种工作模式下经 VD_2 续流,则整流器拓扑发生变化。 $i_s < 0$ 时 VT_1 正常与开路状态的整流器工作模式对比如图2所示。

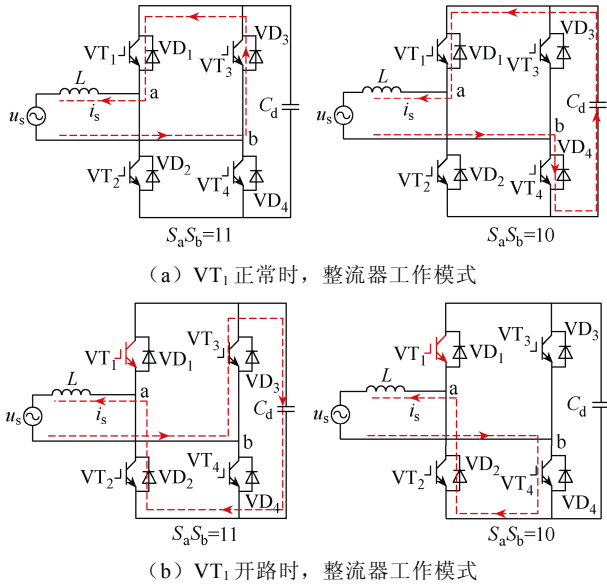


图2 $i_s < 0$ 时 VT_1 正常与开路状态的整流器工作模式对比

正常运行情况下, $S_aS_b=11$ 时,电流通过 VT_1 和 VD_3 导通,此时整流器网侧输入电压 u_s 对网侧电感 L 充电,网侧电流 i_s 幅值增大;当 VT_1 开路时,输入电压 u_s 及网侧电感 L 都对直流侧电容 C_d 充电,相比于正常模式下,网侧电流 i_s 幅值有所减小。正常运行情况下, $S_aS_b=10$ 时,电流通过 VT_1 和 VT_4 导通,此时 u_s 及 C_d 都对 L 充电;当 VT_1 开路时,仅 u_s 对 L 充电,所以网侧电流 i_s 幅值相比于正常模式下有所减小。

综上所述,当 VT_1 开路时,整流器在 $i_s > 0$ 时不受影响,在 $i_s < 0$ 时网侧电流 i_s 幅值减小,其他各类故障情况的分析类似。

VT_1 开路时整流器网侧电流仿真波形如图3所示, $t=1s$ 时设置 VT_1 开路故障,当 $i_s > 0$ 时电流波形不变,当 $i_s < 0$ 时电流波形发生畸变,且幅值减小,与上述分析相符。其他单管开路故障的分析方法与 VT_1 开路故障一致,不再详细描述。




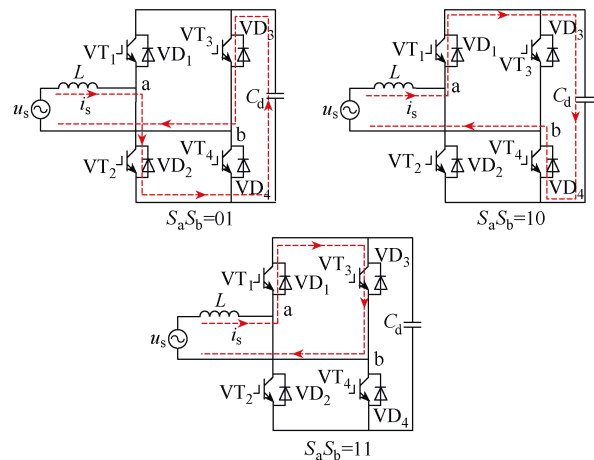
图3 VT_1 开路时整流器网侧电流仿真波形

1.3 四象限脉冲整流器双管开路故障分析


当 VT_1 和 VT_3 同时开路,即a、b桥臂上半桥臂IGBT开路时,影响 $S_aS_b=11$ 、10及01三种工作模式。此时,在 $i_s > 0$ 和 $i_s < 0$ 的情况下,整流器工作模式均受到影响,电路拓扑发生变化。

图4为 $i_s > 0$ 时 VT_1 和 VT_3 正常与开路状态的整流器工作模式对比。在 VT_1 和 VT_3 正常运行状态下,当 $S_aS_b=01$ 时,电流通过 VT_2 和 VT_3 导通,输入电压 u_s 及直流侧电容 C_d 都对网侧电感 L 充电;当 $S_aS_b=10$ 时,电流通过 VD_1 和 VD_4 导通,输入电压 u_s 及网侧电感 L 都对直流侧电容 C_d 充电;当 $S_aS_b=11$ 时,电流通过 VD_1 和 VT_3 导通,输入电压 u_s 对网侧电感 L 充电。

在 VT_1 和 VT_3 开路状态下,当 $S_aS_b=01$ 时,电流通过 VT_2 和 VD_4 续流,仅输入电压 u_s 对网侧电感 L 充电,导致网侧电流 i_s 与正常情况相比有所减小;当 $S_aS_b=10$ 时,电流通过 VD_1 和 VD_4 续流,开路故障对网侧电流无影响;当 $S_aS_b=11$ 时,电流通过 VD_1 和 VD_4 续流导通,输入电压 u_s 及网侧电感 L 都对直



(a) VT_1 和 VT_3 正常时,整流器工作模式



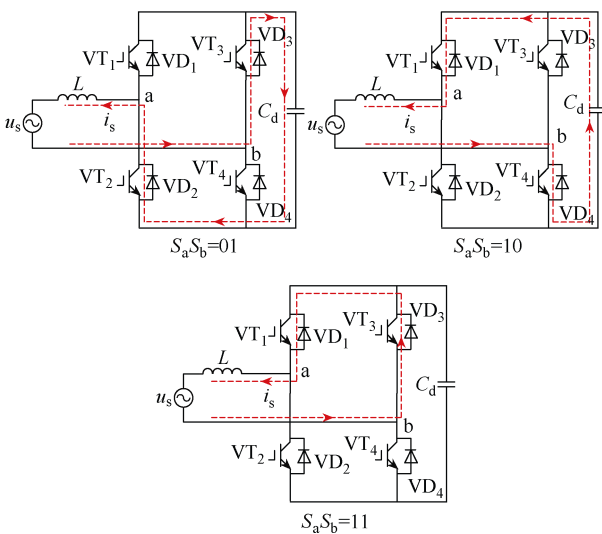
(b) VT_1 和 VT_3 开路时, 整流器工作模式

图 4 $i_s > 0$ 时 VT_1 和 VT_3 正常与开路状态的整流器工作模式对比


流侧电容 C_d 充电, 导致网侧电流 i_s 与正常情况相比有所减小。

图 5 为 $i_s < 0$ 时 VT_1 和 VT_3 正常与开路状态的整流器工作模式对比。在 VT_1 和 VT_3 正常运行状态下, 当 $S_a S_b = 01$ 时, 电流通过 VD_2 和 VD_3 , 输入电压 u_s 对直流侧电容 C_d 和网侧电感 L 充电; 当 $S_a S_b = 10$ 时, 电流通过 VT_1 和 VT_4 , 输入电压 u_s 及直流侧电容 C_d 都对网侧电感 L 充电; 当 $S_a S_b = 11$ 时, 电流通过 VT_1 和 VD_3 , 输入电压 u_s 对网侧电感 L 充电。

在 VT_1 和 VT_3 开路状态下, 当 $S_a S_b = 01$ 时, 电流通过 VD_2 和 VD_3 续流, 开路故障对网侧电流无影响; 当 $S_a S_b = 10$ 时, 电流通过 VT_4 和 VD_2 续流, 输



(a) VT_1 和 VT_3 正常时, 整流器工作模式



(b) VT_1 和 VT_3 开路时, 整流器工作模式

图 5 $i_s < 0$ 时 VT_1 和 VT_3 正常与开路状态的整流器工作模式对比

入电压 u_s 对网侧电感 L 充电, 导致网侧电流 i_s 与正常情况相比有所减小; 当 $S_a S_b = 11$ 时, 电流通过 VD_2 和 VD_3 续流, 输入电压 u_s 对网侧电感 L 和直流侧电容 C_d 充电, 导致网侧电流 i_s 与正常情况相比有所减小。

根据以上分析, 当 VT_1 和 VT_3 处于开路故障状态时, 整流器网侧电流在其正负半周, 即 $i_s > 0$ 和 $i_s < 0$ 时都会出现幅值减小的特征。

当 VT_1 和 VT_3 处于开路状态时, 整流器网侧电流仿真波形如图 6 所示, $t=1s$ 时设置 VT_1 和 VT_3 开路故障, 电流正负半周均出现电流畸变、幅值减小的故障特征, 符合理论分析。

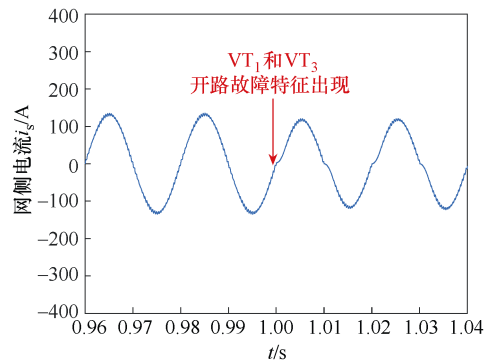


图 6 VT_1 和 VT_3 开路故障时整流器网侧电流仿真波形

基于四象限脉冲整流器单管和双管开路故障的理论分析, 以及图 3 和图 6 所示整流器开路故障电流仿真波形可知, 在整流器发生单管或双管开路故

障时,都可能造成网侧电流 i_s 发生畸变、缺失或幅值降低的现象,不同的故障类型表现出不同的电流波形特征,但在实际运行中,这些波形往往受噪声、电压波动、负载变化等多种因素的影响,使故障特征变得复杂且难以分辨。传统的故障诊断方法可能无法有效捕捉这些复杂的波形特征,导致故障诊断的准确性和可靠性受限。因此,本文选择网侧电流 i_s 为故障特征,通过GADF编码将其转换为更为显著的二维图像特征,并作为CNN的输入,对整流器的IGBT开路故障进行识别。

2 格拉姆角差场原理

格拉姆角场(Gramian angular field, GAF)是一种将一维时序信号转化为二维图像的方法,GAF的具体编码过程如下。

将给定时间序列 $\mathbf{X}=(x_1, x_2, \dots, x_n)$ 缩放到 $[-1, 1]$ 或 $[0, 1]$ 区间内,公式为

$$\tilde{x}_{-1}^i = \frac{(x_i - \max(\mathbf{X})) + (x_i - \min(\mathbf{X}))}{\max(\mathbf{X}) - \min(\mathbf{X})} \quad (2)$$

或

$$\tilde{x}_0^i = \frac{x_i - \max(\mathbf{X})}{\max(\mathbf{X}) - \min(\mathbf{X})} \quad (3)$$

令时间戳作为半径 r ,缩放后的值作为角度 φ ,将 x 转化到极坐标系内,其表达式为

$$\begin{cases} \varphi_i = \arccos \tilde{x}^i & -1 \leq \tilde{x}^i \leq 1 \\ r_i = \frac{t_i}{n} & t_i, n \in \mathbf{N} \end{cases} \quad (4)$$

式中, t_i 为时间戳。

由式(4)可知,GAF对时间序列的编码过程有两个特点:GAF编码是双映射的,给定一段时间序列,通过GAF编码得到的极坐标系下的结果是唯一的,保留了完整的特征信息;极坐标系内通过半径 r 保留了信号对时间的依赖性。

通过式(4)完成一维时间序列到极坐标系的转换,计算转换后每两点之间的角度和/差的三角函数值生成编码图格拉姆角和场(Gramian angular summation field, GASF)及GADF。GAF编码示意图如图7所示。

GADF通过计算各点间的三角函数差,利用角度透视来识别不同时间间隔的时间相关性,具体定义为




图7 GAF编码示意图

$$\mathbf{G} = \begin{bmatrix} \sin(\varphi_1 - \varphi_1) & \cdots & \sin(\varphi_1 - \varphi_n) \\ \sin(\varphi_2 - \varphi_1) & \cdots & \sin(\varphi_2 - \varphi_n) \\ \vdots & & \vdots \\ \sin(\varphi_n - \varphi_1) & \cdots & \sin(\varphi_n - \varphi_n) \end{bmatrix} = \sqrt{\mathbf{I} - \tilde{\mathbf{X}}'^2} \tilde{\mathbf{X}} - \tilde{\mathbf{X}} \sqrt{\mathbf{I} - \tilde{\mathbf{X}}^2} \quad (5)$$

式中: \mathbf{G} 为格拉姆矩阵; \mathbf{I} 为单位向量 $(1, 1, \dots, 1)$; $\tilde{\mathbf{X}}$ 和 $\tilde{\mathbf{X}}'$ 分别为缩放前后的序列。格拉姆矩阵 \mathbf{G} 保留了信号的时间依赖性,经GADF编码后的图像可以更好地揭示在一维时间序列中隐含的状态和信息,将其作为2D-CNN的输入,可以提高分类的准确性。

3 卷积神经网络

卷积神经网络(convolutional neural network, CNN)作为一种典型的深度学习神经网络,一般由卷积层、池化层及全连接层组成,具有强大的特征提取能力,特别是2D-CNN更容易从高维数据中提取特征,在图像识别中具有优势,将其应用在整流器故障诊断中,具备良好的准确性和稳定性。

3.1 CNN结构

将GADF特征图像输入卷积层,利用卷积核在图像上以特定步长滑动,进行卷积运算,捕捉图像不同区域的特征。卷积层基本结构如图8所示。




图8 卷积层基本结构

通过激活函数处理提取局部特征,以实现特征增强,其数学模型可以表达为

$$z_j^l = f \left(\sum_{i \in M_j} z_i^{l-1} * k_{ij}^l + b_j^l \right) \quad (6)$$

式中: z_j^l 为网络第 l 层中第 j 个节点的输出; M_j 为

输入映射的选择; k 为 $S \times S$ 大小的核矩阵; k_{ij}^l 为第 l 层中核矩阵的元素; $*$ 代表卷积运算; b_j^l 为第 l 层中第 j 个节点的偏置项; $f(\cdot)$ 为非线性激活函数。

为避免过拟合, 在每个卷积层后增加池化层, 对输入数据进行降维采样、压缩特征去除冗余信息、减小数据量处理。池化层基本结构如图 9 所示。




图 9 池化层基本结构

最大池化和全局平均池化是最常用的两种池化方法, 分别定义为如式 (7) 和式 (8) 所示。

$$y^{(l)} = \max(x_{ij}^{(l)}) \quad (7)$$

$$y^{(l)} = \frac{1}{m \times n} \left(\sum_{i=0}^m \sum_{j=0}^n x_{ij}^{(l)} \right) \quad (8)$$

式中: $y^{(l)}$ 为池化层的输出; $x_{ij}^{(l)}$ 为池化层的输入; $m \times n$ 为最后一个卷积层的特征图的大小。

全连接层的作用是将卷积层和池化层输出的二维图像转换为一维特征向量, 最终输出每个可能类别的概率分布, 从而实现分类预测。在输出时需要使用与识别故障类型相同数量的神经元, 并利用 Softmax 函数将最终的分类型结果以概率的形式输出。Softmax 函数的定义为

$$h_{\theta}(x_i) = \begin{bmatrix} p(y_i = 1) | x_i; \theta \\ p(y_i = 2) | x_i; \theta \\ \vdots \\ p(y_i = K) | x_i; \theta \end{bmatrix} = \frac{1}{\sum_{j=1}^K e^{\theta_j x_i}} \begin{bmatrix} e^{\theta_1 x_i} \\ e^{\theta_2 x_i} \\ \vdots \\ e^{\theta_K x_i} \end{bmatrix} \quad (9)$$




图 10 ResNet18 网络结构

式中: K 为类别的索引; $p(y_i = K)$ 为 Softmax 层输出的概率, 取值范围为 $[0, 1]$; θ 为 Softmax 分类器的参数; $1 / \sum_{j=1}^K e^{\theta_j x_i}$ 为输出的概率归一化, 即输出的总概率为 1。

3.2 ResNet18 模型

为解决传统神经网络随层数加深而出现的网络退化现象, 深度残差网络 (residual network, ResNet) 模型应运而生。本文采用 ResNet18 模型, 共有 18 层网络结构, 包括 1 个卷积层、1 个全连接层及 8 个残差模块, 每个残差模块包含 2 个卷积层^[17]。ResNet18 模型结构参数见表 1, 网络结构如图 10 所示。

表 1 ResNet18 模型结构参数

层名称	输出尺寸	网络结构
Conv1	112×112	$\begin{bmatrix} 7 \times 7, & 64 \end{bmatrix} \times 2$ 最大池化层
Conv2_x	56×56	$\begin{bmatrix} 3 \times 3, & 64 \\ 3 \times 3, & 64 \end{bmatrix} \times 2$
Conv3_x	28×28	$\begin{bmatrix} 3 \times 3, & 128 \\ 3 \times 3, & 128 \end{bmatrix} \times 2$
Conv4_x	14×14	$\begin{bmatrix} 3 \times 3, & 256 \\ 3 \times 3, & 256 \end{bmatrix} \times 2$
Conv5_x	7×7	$\begin{bmatrix} 3 \times 3, & 512 \\ 3 \times 3, & 512 \end{bmatrix} \times 2$
输出层	1×1	平均池化层 全连接层 Softmax

4 基于 GADF-CNN 的故障诊断模型

基于 GADF-CNN 的故障诊断模型主要由信号采集、信号二维化编码、模型训练、故障分类四大部分组成, GADF-CNN 的故障诊断流程如图 11 所示, 具体如下。

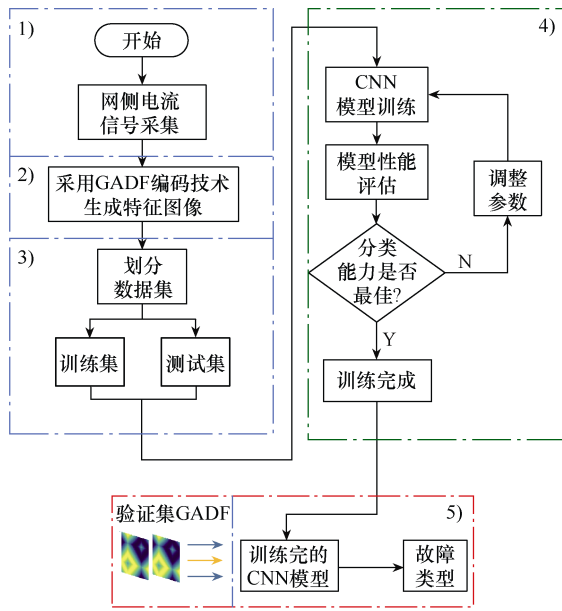


图 11 GADF-CNN 故障诊断流程

1) 搭建仿真模型, 设置四象限脉冲整流器正常、故障工作状态, 采集不同状态下的整流器网侧电流信号。

2) 通过 GADF 编码技术将采集的网侧电流一维时序信号转换为二维特征图, 制作数据集。

3) 为数据集标注标签并按照 6:2:2 的比例划分训练集、测试集及验证集。

4) 将训练集、测试集输入 ResNet18 模型进行训练, 并根据训练结果调整模型参数, 保留测试结果最好的模型。

5) 将验证集输入训练完成的 CNN 模型, 完成故障诊断。

5 结果分析

5.1 四象限脉冲整流器的 Simulink 建模

本文在 Matlab/Simulink 中建立四象限脉冲整流器模型, 采集整流器在不同工作状态下的网侧电流数据, 用于 CNN 训练。四象限脉冲整流器 Simulink 仿真模型如图 12 所示。

为尽可能接近真实工况, 仿真模型的网侧电压、网侧等效电感、直流侧支撑电容等参数均参考 CRH5 列车四象限脉冲整流器, 具体参数见表 2。

四象限脉冲整流器工作状态包括 1 种正常工作状态和 10 种开路故障状态, 共计 11 种。其中, 开路故障分为单管故障和双管故障, 双管故障又分为同相桥臂双管故障、同半桥双管故障、交叉桥臂双管故障。故障类型见表 3。

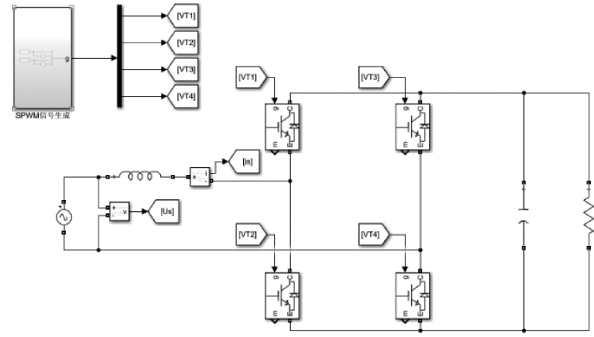


图 12 四象限脉冲整流器 Simulink 仿真模型

表 2 四象限脉冲整流器参数

参数	数值
网侧电压有效值/V	1 770
直流侧电压参考值/V	3 600
网侧电感/mH	5.5
直流侧支撑电容/mF	9.02
基波频率/Hz	50
等效开关频率/Hz	2 500

表 3 四象限脉冲整流器故障类型

故障类型	故障 IGBT
正常	无
单管开路	VT ₁ 或 VT ₂ 或 VT ₃ 或 VT ₄
同相桥臂双管开路	VT ₁ VT ₂ 或 VT ₃ VT ₄
相同半桥双管开路	VT ₁ VT ₃ 或 VT ₂ VT ₄
交叉桥臂双管开路	VT ₁ VT ₄ 或 VT ₂ VT ₃

5.2 整流器故障数据集构建

在四象限脉冲整流器的 Simulink 仿真模型中, 对 11 种工作状态进行仿真, 仿真时长 10s, 采样频率 100kHz, 得到不同工作状态下的网侧电流的一维时序数据, 每种状态的一维时序数据共有 1 000 000 个数据点, 将网侧电流信号按工频交流周期 0.02s 的时间间隔等分为不同的样本, 即以每 2 000 个数据点作为一段样本, 将其转化成分辨率为 64×64×3 的 GADF 图像, 每种状态可以得到 500 张 GADF 图像, 11 种状态共 5 500 张 GADF 图像作为数据集, 按 6:2:2 的比例划分为训练集、测试集、验证集。GADF 特征图如图 13 所示。

5.3 模型训练与验证

搭建算法模型的平台为 Pytorch 1.10.0, 编译语言为 Python 3.9。计算机硬件采用 Intel 13500hx CPU, RTX4060 GPU, Win11 系统。

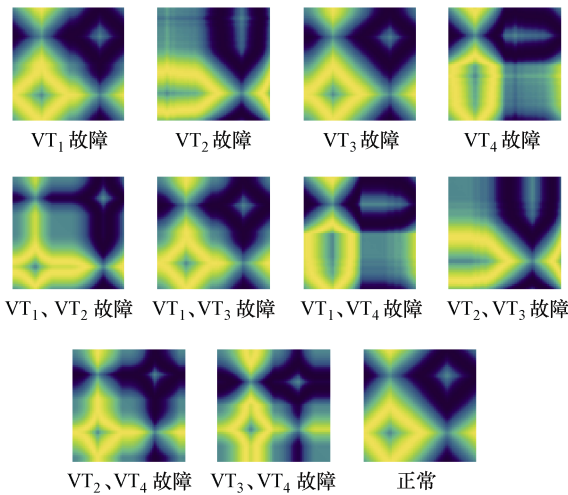




图 13 GADF 特征图

以随机分配的方式将数据集以 6:2:2 划分为训练集、测试集、验证集，即将 4 400 张 GADF 特征图输入模型进行训练。ResNet18 模型的学习率设置为 1×10^{-3} ，批次大小为 32，迭代次数为 100 次。

训练过程中训练集、测试集的准确率及损失值曲线如图 14 所示。迭代至第 70 次时，模型收敛，测试集的准确率达到 99.56%，损失值降低至 0.01，模型准确率曲线和损失值曲线都逐渐稳定。



(a) 训练集与测试集准确率



(b) 训练集与测试集损失值

图 14 准确率及损失值曲线

为进一步验证 GADF 结合 CNN-ResNet18 模型进行整流器 IGBT 开路故障诊断的有效性，将验证集输入训练好的模型，并生成混淆矩阵如图 15 所示。

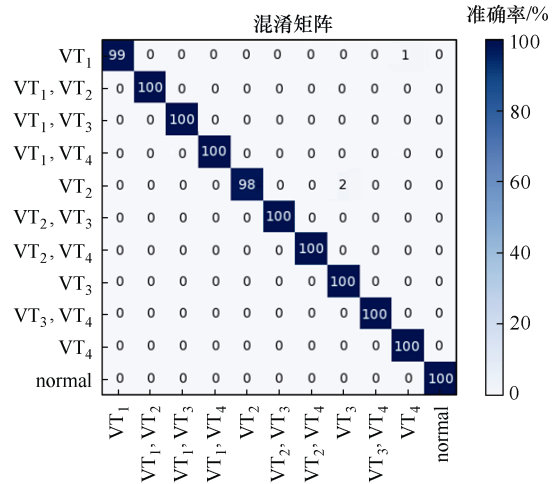


图 15 混淆矩阵

图 15 中对角线上的深色区域代表对验证集每类故障判别的准确率，其中有 1 个 VT₁ 故障被误判为 VT₄ 故障，2 个 VT₂ 故障被误判为 VT₃ 故障；VT₁VT₂、VT₁VT₃、VT₁VT₄、VT₂VT₃、VT₂VT₄、VT₃VT₄ 双管开路故障，以及 VT₃、VT₄ 单管开路故障和正常情况的诊断准确率为 100%，说明 GADF-CNN 故障诊断模型能够在整流器的 IGBT 开路故障诊断中取得较好的诊断效果。

5.4 不同方法的对比分析

1) GADF 与 GASF 的对比实验

图 16 为 GASF 特征图。对比实验不设验证集，按照 8:2 的比例划分训练集与测试集，输入 ResNet18 模型进行训练，其余所有参数的设置均与 GADF 数据集训练时相同，得到的 GADF 与 GASF 的准确率对比见表 4。使用 GADF 数据集训练得到的模型，在测试时的平均准确率比 GASF 高 0.65 个百分点，证明 GADF 的数据处理方法更适用于四象限脉冲整流器 IGBT 开路故障的检测。

2) GADF 和不同信号处理方法的对比实验

不同信号处理方法的准确率对比见表 5。其中，1D-CNN 方法为将故障电流信号经小波包三层分解后，得到小波包分解树末端八个节点的能量占比并将其作为故障特征输入一维卷积神经网络训练；MTF 为使用马尔可夫变迁场 (Markov transition field, MTF) 的方法将一维时序数据二维化。对于灰度图、MTF 特征图均以 8:2 的比例划分训练集、测试集，使用 ResNet18 模型训练，其余参数均与 GADF 特征数据集训练时相同。




图 16 GASF 特征图

表 4 GADF 与 GASF 的准确率对比

实验序号	准确率/%	
	GADF	GASF
1	99.84	99.21
2	99.68	98.93
3	99.72	99.14
平均值	99.75	99.10

表 5 不同信号处理方法的准确率对比

实验序号	准确率/%			
	1D-CNN	灰度图	MTF	GADF
1	81.91	93.12	96.82	99.84
2	85.13	92.41	96.23	99.68
3	82.32	94.62	96.56	99.72
平均值	83.12	93.38	96.53	99.75

1D-CNN 无法有效捕捉同一时刻不同模态特征之间的关联,也无法理解不同时刻相同模态的时间信息,容易忽略某些特征信息,导致其平均分类准确率较低,仅为 83.12%。灰度图保留了过多的重复信息,使 CNN 对特征的学习效率低,平均准确率为 93.38%。MTF 虽然可以保留信号的时间依赖性,但在其转换过程中可能会丢失重要的时间节点信息,因此其平均分类准确率比 GADF 低 3.22 个百分点。GADF 方法的平均准确率最高,为 99.75%,GADF 通过将一维电流信号转换为二维特征图像,能够充分保留信号的时间序列特征,并将信号的复杂模式有效地转化为易于分类的图像特征。与其他方法相比,GADF 方法不仅能够捕捉不同模态特征间的关联,还能深入理解不同时刻信号的时间信息,这使

CNN 在训练过程中能够更加准确地识别出不同故障模式,从而大幅提高分类的准确性。

3) GADF 结合机器学习算法的对比实验

为进一步验证 GADF 结合 CNN-ResNet18 模型的优势,增加与 GADF 结合 BP 网络、SVM 及多层感知机 (multilayer perceptron, MLP) 算法的对比实验。其中, BP 网络和 MLP 均与 CNN 相同,基于 Pytorch 1.10.0 编程实现, SVM 使用 Matlab 语言编程实现,所有算法的输入均采用与 CNN-ResNet18 模型相同的数据集,并按照 9:1、8:2 和 7:3 的比例划分训练集和测试集,所有算法均测试 3 次,结果为 3 次测试的平均值。不同算法的准确率对比见表 6。

表 6 不同算法的准确率对比

方法	准确率/%		
	9:1	8:2	7:3
GADF-CNN	99.87	99.75	99.68
GADF-MLP	96.54	95.66	95.08
GADF-BP	93.22	92.78	91.89
GADF-SVM	90.03	88.32	86.61

根据表 6 结果,所有算法在结合 GADF 后均取得了较高的准确率,其中 GADF-SVM 的准确率最低,主要原因是 SVM 引入核函数,将低维空间数据转换成高维数据,在进行图像分类任务时效果不好。BP 网络为单隐层结构,结构简单,在进行四象限脉冲整流器的开路故障诊断时,无法学习 GADF 图像的深层特征,导致其准确率低于 CNN 和 MLP。MLP 在实验中的表现虽然优于 BP 网络和 SVM,但其准确率仍低于 CNN-ResNet18,这是因为 MLP 虽然具有多层结构,能够学习一定程度的非线性特征,但由于其本质上是全连接网络,缺乏 CNN 的局部感知能力和空间不变性。使用 CNN-ResNet18 模型进行分类任务时,准确率均可保持在 99.5% 以上,尤其当按 9:1 划分训练集与测试集时,其准确率达到了 99.87%。

上述实验结果表明,GADF 结合 CNN-ResNet18 模型在 IGBT 开路故障诊断中优势明显,该模型不仅能有效提取 GADF 特征图中的深层次特征,而且在训练数据量较大时,仍能保持高分类准确率。

6 结论

为充分发挥 CNN 在图像识别分类中的优势,本文提出了一种新的四象限脉冲整流器 IGBT 开路故

障诊断方法,结合2D-CNN与GADF的故障诊断模型实现了对整流器IGBT开路故障的高准确度诊断,通过仿真验证,得出以下结论:

1) GADF将一维时序信号编码为二维图像,既能保留信号的完整特征信息,也能保留信号对时间的依赖性,实现对信号不同特征之间的最大区分,更适合作为CNN的输入,因此结合GADF与CNN对四象限脉冲整流器开路故障进行诊断可以达到较高的准确率。

2)在不同的信号处理方式及不同智能算法下进行对比实验,结果表明,由于2D-CNN对图像特征的深层次的学习能力,使其在处理GADF图像输入时具备明显优势,将GADF与2D-CNN相结合的方法具备较高的诊断准确率,适用于四象限脉冲整流器IGBT开路故障诊断。

参考文献

- [1] 王丹. 动车组牵引变流器故障分析及其诊断方法研究[D]. 兰州: 兰州交通大学, 2020.
- [2] 杨宝顺, 陈权, 胡存刚. 基于电压偏差的三电平逆变器故障诊断与定位[J]. 电力电子技术, 2022, 56(6): 19-22.
- [3] 陈勇, 刘志龙, 陈章勇. 基于电流矢量特征分析的逆变器开路故障快速诊断与定位方法[J]. 电工技术学报, 2018, 33(4): 883-891.
- [4] 柯炎, 樊波. 基于电压残差的三相逆变器故障诊断[J]. 空军工程大学学报(自然科学版), 2020, 21(1): 27-31.
- [5] 田广强, 乔珊珊, 侯奥, 等. 基于快速傅里叶变换和改进T-S模糊神经网络集成模型的逆变器开路故障诊断方法研究[J]. 电力科学与技术学报, 2023, 38(6): 76-86.
- [6] 赵苗苗, 陈小强, 王英, 等. 基于小波包熵及双重优化神经网络的牵引逆变器开路故障诊断[J]. 铁道科学与工程学报, 2022, 19(4): 1101-1110.
- [7] 耿俊超, 王天真, 韩金刚, 等. 基于多级特征提取的并网逆变器故障诊断策略[J]. 电源学报, 2022, 20(4): 28-36.
- [8] 董懿飞, 舒胜文, 陈诚, 等. 基于红外图像分割与SSA-SVM的复合绝缘子缺陷检测方法[J]. 电气技术, 2021, 22(11): 73-79.
- [9] 董志文, 苏晶晶. 基于变分模态分解能量熵混合时域特征和随机森林的故障电弧检测方法[J]. 电气技术, 2024, 25(1): 1-7.
- [10] 魏银图, 张昉, 温步瀛, 等. 基于支持向量机的模块化多电平换流器子模块开路故障诊断方法[J]. 电气技术, 2023, 24(10): 1-7.
- [11] 钱存元, 吴昊, 陈昊然. 基于EMD-BPNN的逆变器IGBT开路故障诊断方法[J]. 电气工程学报, 2024, 19(3): 432-442.
- [12] 李宇昂, 岳朋朋, 李豪. 基于CNN的Buck-Boost变流器开路故障诊断[J]. 电力电子技术, 2023, 57(7): 24-27.
- [13] 丁伟, 宋俊材, 陆思良, 等. 基于多通道信号二维递归融合和ECA-ConvNeXt的永磁同步电机高阻接触故障诊断[J]. 电工技术学报, 2024, 39(20): 6397-6408.
- [14] 刘伟, 杨东风, 王洪志, 等. 基于格拉姆角场-改进残差网络的小电流接地系统故障选线[J]. 电气技术, 2023, 24(12): 14-19.
- [15] KIM B, KANG J W, KIM C S, et al. Hybrid transformer for anomaly detection on railway HVAC systems through feature ensemble of spatial-temporal with multi-channel GADF images[J]. Journal of Electrical Engineering Technology, 2024, 19(4): 2803-2815.
- [16] 张辉, 戈宝军, 韩斌, 等. 基于GAF-CapsNet的电机轴承故障诊断方法[J]. 电工技术学报, 2023, 38(10): 2675-2685.
- [17] 孙曙光, 张婷婷, 王景芹, 等. 基于连续小波变换和MTL-SEResNet的断路器故障程度评估[J]. 仪器仪表学报, 2022, 43(6): 162-173.

收稿日期: 2024-06-19

修回日期: 2024-09-14

作者简介

翟道宇(2000—),男,山东省济南市人,硕士研究生,研究方向为列车牵引变流系统中整流器的控制技术与故障诊断。