

DOI: 10.19650/j.cnki.cjsi.J2412761

基于多源融合图与 SE-BiGRU-ResNet 模型的 MMC 子模块开路故障诊断

刘述喜, 刘 科, 黄思源, 王乾蕴, 王 震
(重庆理工大学电气与电子工程学院 重庆 400054)

摘 要:人工智能算法现广泛应用于模块化多电平换流器 (MMC) 故障诊断中,但现有算法均需大量目标域样本来训练模型,针对小样本下难以精确诊断的问题,提出基于多源融合图与 SE-BiGRU-ResNet 模型的 MMC 小样本分立化故障诊断方法。首先,根据开路故障特性,选择输出相电流和桥臂电压作为关键故障参量;其次,利用递归图、马尔可夫转移场和格拉姆角场算法将一维故障参量映射为相应的二维特征图像,为全面加强图像的特征显著性,将各图按通道维度增广叠加为多源融合图;最后,以残差网络 (ResNet) 为基础,为提高模型捕捉关键时空特征的能力,引入挤压-激励 (SE) 模块和双向门控循环单元 (BiGRU) 模块,建立 SE-BiGRU-ResNet 模型对多源融合图进行训练和测试。实验结果表明:相比其他方法,在小样本情况下诊断故障桥臂与定位子模块中故障 IGBT 的准确率达到 98.10% 和 99.13%,诊断精度高;测试过程拥有秒级响应时间;在极端条件扰动下仍具备较好的诊断性能与较强的泛化能力。

关键词:模块化多电平换流器;故障诊断;小样本;多源融合图;SE-BiGRU-ResNet 模型

中图分类号: TH165.3 TM464 TM407 **文献标识码:** A **国家标准学科分类代码:** 470.40 460.40

Open-circuit fault diagnosis of MMC sub-module based on multi-source fusion graph and SE-BiGRU-ResNet model

Liu Shuxi, Liu Ke, Huang Siyuan, Wang Qianyun, Wang Zhen

(School of Electrical and Electronic Engineering, Chongqing University of Technology, Chongqing 400054, China)

Abstract: Artificial intelligence algorithms are widely used in fault diagnosis of modular multilevel converter (MMC). However, the existing algorithms require a large number of target domain samples to train the model. To address the problem that it is difficult to diagnose accurately under small samples, a MMC small sample discrete fault diagnosis method based on a multi-source fusion graph and SE-BiGRU-ResNet model is proposed. Firstly, according to the characteristics of an open-circuit fault, the output phase current and bridge arm voltage is selected as the key fault parameters. Secondly, the 1D fault parameters are mapped into the corresponding 2D feature images by using the recurrence plot, Markov transition field, and the Gramian angular field algorithm. To comprehensively strengthen the feature saliency of the image, the multi-source fusion graph is obtained by adding each graph according to the channel dimension. Finally, based on the residual network (ResNet), to improve the ability of the model to capture key spatiotemporal features, the squeeze-excitation (SE) module and the bidirectional gated recurrent unit (BiGRU) module are introduced. The SE-BiGRU-ResNet model is formulated to train and test the multi-source fusion graph. Compared with other methods, the experimental results show that the accuracy of fault diagnosis of IGBT in the fault bridge arm and positioning sub-module reaches 98.10% and 99.13% in the case of small samples, and the diagnostic accuracy is high. The test process has a second-level response time. It still has good diagnostic performance and strong generalization ability under extreme conditions.

Keywords: modular multilevel converter; fault diagnosis; small sample; multi-source fusion graph; SE-BiGRU-ResNet model

0 引言

近年来,我国电力系统的复杂程度在日益增大,其内部发生各式各样的故障的可能性越来越大,关于电力系统中相关仪器的故障诊断研究越来越重要。模块化多电平换流器(modular multilevel converter, MMC)拥有扩展能力强、多端口互联方便和输出电压等级灵活等优点^[1],目前在新能源电力输送和柔性直流输电工程等相关领域应用非常广泛。随着 MMC 输出电平数的升高,MMC 中子模块(sub-module, SM)个数也在不断增加,每个子模块中的开关器件都成为了潜在故障点,相关研究表明换流器故障主要集中于绝缘栅双极型晶体管(insulated-gate bipolar transistor, IGBT)中^[2]。MMC 中常见的 IGBT 故障包括短路故障和开路故障,短路故障破坏性虽然较强,但在驱动电路均会包含保护装置对短路部分及时切除,进而保护 MMC 的正常运行;开路故障特征较微弱且不易被检测,如果没有可靠灵敏的故障诊断方法可能造成三相不对称和输出电压电流波形畸变等问题,进而威胁到电力系统的正常运行。因此,研究 MMC 中 IGBT 开路故障诊断方法是 MMC 稳定运行的关键。

目前 MMC 中 IGBT 开路故障诊断的研究分为硬件、模型和人工智能 3 类^[3],基于硬件法通常缺乏对故障深层次原因的分析能力,基于模型法往往受限于对动态系统的精确把握和对相关参数的变化及其敏感,现基于人工智能的方法逐渐取代其他方法,因其在克服高维、时变和非线性诊断问题上具有优异学习与处理能力,利用 MMC 中的相关状态变量进行特征工程的建立和诊断模型的设计。

在特征工程的建立方面,其可按特征维度分为两类,即一维时序信号和二维图像信号。一维信号无法显著表征出 MMC 发生故障后的高耦合特征,且大多数诊断模型对于高维信号有着更好的适应性^[4]。灰度图^[5]、傅里叶变换^[6]和小波变换^[7]等传统方法均可进行信号转换,但是传统方法很难反映信号中隐藏时间关联性且受人工阈值影响。文献[8]利用递归图(recurrence plot, RP)将不同故障模式下的一维电信号转变为二维图像,从中提取换流器等电力仪器的故障特征。文献[9]利用马尔可夫转移场(Markov transition field, MTF)将故障信号转换为可视化特征图像。文献[10]利用格拉姆角场(Gramian angular field, GAF)将并网逆变器发生开路故障后的仿真数据进行转换,利用格拉姆角和场(Gramian angular summation field, GASF)图像和格拉姆角差场(Gramian angular difference field, GADF)图像对并网逆变器中 IGBT 的健康状态进行诊断,现有研究多依赖单一图像转换技术以实现信号的升维处理,但此种情况在样本数量不足

或质量不均衡的情况下,可能会导致诊断准确率的显著下降。文献[11]利用多源信号融合思想将换流器在不同时间内故障数据映射为特征图像并融合,使其内部故障特征显性化,相比于单一信息更能真实反映电力仪器中故障信息。

在诊断模型设计方面,深度学习在模式识别、缺陷检测和故障诊断等领域都有应用。文献[12]利用子模块电容电压等原始数据,利用 CNN 实现了对 MMC 的诊断与定位,但直接使用原始数据进行特征提取容易引起过拟合,诊断准确率会下降,且采集子模块电容电压进行训练及测试,当子模块数目较多时,数据采集量过于庞大,可能会出现“维度灾难”的问题。文献[13]提出了基于挤压-激励(squeeze-excitation, SE)模块的深度可分离卷积网络,通过深度网络提取丰富的特征,具有参数少、便于区分耦合特征的特点,但在训练过程中要进行大量浮点数运算,资源占用较大。文献[14]提出了基于 1D-CNN-LSTM 模型的开关管故障诊断方法,既避免因专家经验导致可能出现的特征遗失问题,还深度发掘故障数据时空中的隐藏特征,但是由于模型的特殊性,导致输入数据为一维数据,无法获取故障信息中的所有信息。文献[15]将子模块电容电压信号组合成 24 通道序列信号的“数据带”样本,输入到栈式稀疏自动编码器进行学习,最后用 Softmax 分类器输出故障诊断结果,但是该法采用的序列信号通道数是 MMC 电平数目的 6 倍,计算量太大。文献[16]将小波极限学习机-自动编码器用于子模块电容电压的特征提取与故障诊断,诊断精度高,但处理数据量会伴随着子模块的增加而增加,使得操作难度加大,无法精确定位故障 IGBT 位置。

在实际工程中,MMC 中子模块 IGBT 发生开路故障较低,即一个具有充足目标域样本的数据集需耗费大量精力去采集。当缺乏目标域样本时,诊断模型很难从有限的样本中学习准确的故障特征。现存解决方法是对样本数据集进行数据扩充,以获取足量训练数据。对于进行故障诊断的一维时序信号,可以采用对原始信号附加高斯白噪声、数据平移和时间伸缩等方法来制造新数据,其对小样本任务有一定的帮助,但仅仅靠对一维数据变化得到新数据,并没有对数据的多样性产生质变,因此效果仍有待进一步提升。因此,研究一种适用于小样本条件下 MMC 子模块单管开路故障诊断更有实际意义。

综上所述,本文以三相 MMC 为研究对象,提出一种多源融合图和 SE-BiGRU-ResNet 模型的 MMC 故障诊断方法。首先,研究 MMC 在正常和故障情况下的工作机制,选择能体现不同故障类别的信号特征作为故障参量;其次,为提升故障参量的丰富性、增强故障特征的互补显示和减少诊断模型在训练与测试过程中的数据传输量,结合 RP、MTF 和 GAF 算法将各参量映射为相应二维特

征图并将其按通道维度增广叠加为多源融合图;最后,以残差网络(residual network, ResNet)为基础,结合 SE 注意力机制模块和双向门控循环单元(bidirectional gated recurrent unit, BiGRU)模块,创新性地建立 SE-BiGRU-ResNet 诊断模型,提升辨识精度,验证了该方法在小样本情况下对桥臂故障和子模块故障 IGBT 的诊断与定位能力。实验结果表明,所提方法能减少训练过程中的数据量,使模型实时诊断速度加快,还能精准定位到子模块中的故障 IGBT 位置,迭代训练次数少,定位精度高,在极端条件下,仍能够保证较高的诊断准确率。

1 MMC 运行原理及其故障特征分析

1.1 MMC 结构及基本运行原理

图 1 为 MMC 主电路及其子模块的拓扑结构,其中, U_{dc} 和 I_{dc} 分别为直流电压和电流; u_{jp} 、 u_{jn} 、 i_{jp} 和 i_{jn} 分别为 $j(j=A,B,C)$ 相上、下桥臂电压和电流; u_c 为子模块电容电压; i 为子模块电流。MMC 三相独立,每相由两个桥臂组成,每个桥臂由 N 个子模块串联而成,上下桥臂之间串联 2 个电抗器 L ,起到在 MMC 开始工作时抑制充电电流、运行时抑制环流及发生故障后减小电流上升率的作用。每个子模块均由开关管 T_1 、 T_2 和二极管 D_1 、 D_2 与电容 C 并联构成。




图 1 MMC 主电路及其子模块拓扑

Fig. 1 MMC main circuit and its sub-module topology

MMC 在正常工作时必须满足交流侧对称输出和直流电压恒不变。子模块内部电流路径如表 1 所示。

表 1 中,MMC 子模块工作状态为投入时,该子模块的电容电压和输出电压保持一致,如果某个子模块发生意外切除,则它的输出电压会变为 0。MMC 每一相上桥臂和下桥臂的子模块正常互补运行,上下桥臂电压之和永远为 U_{dc} 。要想控制 MMC 交流侧输出正常电压波形,通过控制每个子模块的投切状态即可。

表 1 子模块电流流向路径
Table 1 Sub-module flow path

模式	T_1	T_2	i	流经元件	电容状态	工作状态
1	开	断	>0	D_1-C	充电	投入
2	开	断	<0	$C-T_1$	放电	投入
3	断	开	>0	T_2	旁路	切除
4	断	开	<0	D_2	旁路	切除
5	断	断	>0	D_1-C	充电	闭锁
6	断	断	<0	D_2	旁路	闭锁

1.2 MMC 故障特性分析及特征变量选取

MMC 在工作时,子模块中 T_1 发生开路故障,则在表 1 中的模式 2 下对 MMC 造成影响;子模块中 T_2 发生开路故障,则在表 1 中模式 3 下对 MMC 造成影响。如图 2(a)中正常工作时电容应该放电,但当 T_1 发生开路故障时,电流将会通过二极管 D_2 ,导致电容不能经 T_1 放电,此时故障子模块电容电压会高于正常子模块电容电压;图 2(b)中模式 3 下 T_2 发生开路故障,电流将会通过二极管 D_1 ,子模块中电容将会被串联到电路中,导致电容不能被 T_2 旁路致使被迫充电,此刻故障子模块电容电压高于正常子模块电容电压。




图 2 子模块开路故障运行情况

Fig. 2 Sub-module open circuit fault operation

通过对 IGBT 开路故障后子模块内部运行特性的分析,当子模块中 IGBT 开路故障时,桥臂电流在子模块内部的流通路径在特定模式下将会改变,使桥臂电流、桥臂电压和子模块电容电压等物理量发生变化。当负载较小时,子模块中电容充电与放电过程较为缓慢,且 MMC 中子模块数量较多,直接利用其电容电压特征作为故障参量会导致计算量过大,不利于故障诊断中的快速定位。又因 MMC 桥臂在数量上远小于子模块且每一个桥臂处均有电压传感器,桥臂电压可直接测量,使用桥臂电压作为故障参量不仅能大幅减少计算量,还能有效提高故障诊断速度。

2 MMC 故障诊断基本算法

2.1 基于多源融合图的特征增强算法

图像信息融合是对多个图像源获得信息进行综合利用的理论参考体系,使用多图像源互补感知更能贴近研究目标的整体状态^[17],可有效解决小样本情况下使用单一故障信息源无法充分反映 MMC 中各故障类别的问题。本文基于 RP、MTF、GASF 和 GADF 算法来构建二维多源融合图,多源融合图中蕴含的纹理信息和颜色分布都是对数据信息与时间特性的映射,保留了原始数据的特征,作为后续诊断模型的输入。

RP 算法通过重构相空间理论来分析时序信号,能直观展示周期性和相似性,并易于识别信号中的异常、噪声及非线性特征现象^[8];MTF 算法在传统 Markov 模型中结合时空位置因素,利用 Markov 转移概率构建转移矩阵,保留信号的时间相关性和时频域动态信息,通过模糊内核聚合映射二维图像^[9]。其时刻保留动态特性,但对静态信息保留能力较弱,易丢失;GAF 算法通过 GASF 和

GADF 两种形态记录信号波动和突出隐藏特征,将数据信号从笛-极坐标转换,利用特定内积和三角函数克服高斯噪声干扰,并生成图像以揭示信号状态和信息。GADF 和 GASF 图像分别显示信号幅度变化,保留故障静态信息,蕴含潜在联系,完美解决 MTF 算法的不足^[10]。

在 MMC 故障诊断的研究中,往往面临着样本稀缺、成本高昂以及噪声干扰等多重挑战,传统特征提取方法会受限于样本数量和质量,对于故障特征的复杂性与多样性无法充分获取的问题,为了解决这些问题,本文创新性地引入了 RP、MTF、GADF 和 GASF 这 4 种图像转化算法,将一维故障数据转换为二维图像,从而显著增强了故障特征的表达力。结合 4 种算法的优势,在融合图像中不仅可体现故障的动静态特征,还可实现时频域特征的极大互补,提升模型对故障特征的敏感性和抗噪声能力。基于多源融合图的特征增强算法的提出不仅丰富故障特征的信息量,也为后续诊断模型提供更为全面的输入,使其能够更准确地捕捉数据间的内在联系和规律。例如正弦波时序信号在 4 个图融合后得到多源融合图的过程如图 3 所示。




图 3 4 图融合过程

Fig. 3 The four image fusion process

图 3 中,利用 RP、MTF、GADF 和 GASF 4 种图像转化算法将正弦波信号依次转化为对应的图像,现将每张图像中的 RGB 三原色灰度图按通道维度叠加起来作为新的融合图像即多源融合图。因像素点的位置变化和各颜色通道的灰度值共同编码了图像信息,灰度值的变化随着像素点位置的变化,揭示彩色图像的时频特性,像素点矩阵的变化则反映了丰富的颜色信息。单一图像的数据

结构被组织为 $(3, P_{i1}, P_{i2})$, 表明每个图像由 3 个通道组成,每个通道的像素尺寸为 $P_{i1} \times P_{i2}$ 。为了增强特征的表达力,将这 4 种单一图像在通道维度上进行融合,数据结构为 $(12, P_{i1}, P_{i2})$ 的多源融合图,其包含 12 个通道的灰度图信息。为了便于图像的可视化和后续处理,对多源融合图的数据结构进行重组,将其转换为数据结构为 $(3, 2 \times P_{i1}, 2 \times P_{i2})$, 不仅可保留原始 4 个图的所有信息,而且通过在空间维度上扩展图像尺寸,提高了图像的分

分辨率和细节表现力,且训练数据减小为原信号数据的 1/4,可提高训练效率和降低数据预处理的复杂度。后续智能诊断模型可根据多通道融合图内部特征的抽象与组合对不同故障类别进行诊断。此过程中无需复杂坐标变换,也无需丰富的专家知识与人工经验。只需将原始信号映射到图像上,采用“端对端”即可高效诊断不同故障类别。

2.2 SE-BiGRU-ResNet 模型

针对在 MMC 故障诊断问题中随着网络层数的加深会出现梯度消失或爆炸的问题,ResNet 作为一种带“快速连接”残差结构的深度网络,相比浅层神经网络拥有数量过多的非线性结构,非线性表达能力随着网络层数的加深而变的更强,可以有效避免因反向传播导致的梯度消亡问题。

针对 MMC 故障诊断中故障参量存在较多冗余信息,

这些信息会分散诊断模型的注意力,从而降低故障诊断的准确率,本文引入可嵌入式 SE 注意力机制模块,该模块自适应学习所有特征通道的重要参数,根据学习到的参数对故障特征进行提取,降低冗余特征对诊断模型的影响,同时减少模型的复杂度和运算负担,提高模型整体性能。

在卷积后得到的每个特征通道都会分配相同的权值来处理。但在实际特征提取过程中,经过卷积后每个特征通道提取的故障信息不尽相同,重要程度也不一样。SE 模块采用特征重标定策略^[18],通过压缩部分与激励部分来实现对不同的特征通道给予不同权值因子,实现特征通道的最优选择和模型性能的极大利用。SE 模块基本结构如图 4 所示,其中 $F_{ir}(\cdot, \theta)$ 为卷积部分, $F_{sq}(\cdot)$ 为压缩部分, $F_{ex}(\cdot, w)$ 为激励部分, $F_{scale}(\cdot)$ 为重构部分。




图 4 SE 基本结构
Fig. 4 SE basic structure

图 4 中的 SE 模块作为相对独立的子网络结构,可以与其他网络相结合,从而提升整体网络结构对重要故障特征的敏感程度,细化故障特征表示,能够明显抑制冗余信息的干扰,突出 MMC 在工作中的关键故障和通道位置。

针对 MMC 发生故障后的数据拥有强时序性的特点,采用循环神经网络(recurrent neural network, RNN)有助于加强数据间的时序信息,进一步挖掘数据中的联系。GRU 作为改进 RNN,既能兼顾时序数据的关联性,又在长短期记忆网络的基础上大大减少了参数量,加快模型训练速度和不易出现过拟合现象,如图 5 所示的 BiGRU 网络是由正向 GRU 网络和反向 GRU 网络共同构建而成,这两层 GRU 网络分别负责捕获历史信息与未来信息。最终,将两层网络的输出按照各自的位置进行整合,能提高记忆能力和预测精度。

为实现小样本下 MMC 故障 IGBT 位置的精确定位,充分提取出多源融合图中的故障特征,结合上述模块提出如图 6 所示的 SE-BiGRU-ResNet 诊断模型结构。

图 6 中,本文提出了一种新型深度学习模型旨在解决基于多源融合图的 MMC 故障诊断研究的问题。该模型的设计旨在充分利用 SE 模块的强化注意力机制、ResNet 模块在图像特征提取方面的优势和 BiGRU 在处




图 5 BiGRU 基本结构
Fig. 5 Basic structure of BiGRU

理时序数据方面的能力,以实现高精度诊断。

首先,多源融合图通过包括如卷积层、BN 层、ReLU 层和池化层等网络层进行处理,卷积层通过不间断滑动卷积核提取图像局部特征,BN 层负责标准化输出,ReLU 层引入非线性状态量,池化层降低数据维度。引入改进 ResNet 模块,利用分支 1 与分支 2 构成相应映射来学习不同的权值,实现双分支路特征规律互补,使故障特征在空间耦合特征上得到进一步增强同时解决梯度爆炸与消失问题,将提取到的故障耦合特征输入到 SE 模块中,突出重要故障信息,增强模型泛化性能,提升诊断模型整体表现能力,然后通过 Flatten 层将所有像素值(考虑所有通道)展平为一维长向量同时保留通道间的独立性,有




图 6 SE-BiGRU-ResNet 基本结构

Fig. 6 Basic structure of SE-BiGRU-ResNet

助于模型捕捉更复杂的依赖关系,这个一维向量序列会增加一个时间步维度,以满足 BiGRU 的输入要求, BiGRU 层能够捕获输入向量序列中的上下文依赖关系,进而输出每个时间步的特征表示,提取包含了整个时间序列的信息汇总的最后一个时间步输出,用作全连接层的输入,进行 MMC 故障诊断分类任务。

综上所述,本文所提模型通过改进 ResNet 模块提取重点且深层次特征,并利用 BiGRU 模块捕获这些特征中的时序依赖关系,输出汇总特征向量用于 MMC 故障诊断任务中。这种结构的设计不仅提高了故障诊断的准确性,而且为处理更为复杂的故障诊断问题提供了一种有效的解决方案,为故障诊断问题的解决提供新视角。

3 MMC 故障诊断流程

为实现 MMC 中子模块故障 IGBT 的定位,本文提出了“先诊断出发生故障的桥臂,再定位子模块中故障 IGBT”的分立化故障诊断与定位方法,主要包括 3 个阶段:特征工程的建立、离线训练模型和在线诊断应用。具体步骤如下:

1) 根据诊断思路,以九电平 MMC 为诊断对象,利用实验平台模拟 7 种桥臂运行状态,对不同桥臂故障下的输出相电流 i_{jo} 进行采样,将其作为诊断桥臂的原始信号;确定 MMC 发生故障的桥臂后,以故障桥臂为诊断对象,基于实验平台模拟桥臂中 17 种子模块中 IGBT 运行状态,对不同 IGBT 故障下桥臂电压 u_{jp} 进行采样,将其作为定位故障 IGBT 的原始信号。

2) 将 i_{jo} 和 u_{jp} 进行归一化处理,不同故障类别下的 i_{jo} 和 u_{jp} 通过滑动窗口特征提取算法分割构造样本,得到

原始电流样本数据集 1 和原始电压样本数据集 2。

3) 对 2) 中原始电流数据样本和原始电压数据样本分别进行转换映射。每组样本生成 4 种图像即 RP、MTF、GADF 和 GASF 图,将 4 个图按通道维度增广融合为维度更深和故障特征更明显的多源融合图。对多源融合图进行预处理后得到故障桥臂诊断数据集 1 和故障 IGBT 定位数据集 2,随机划分为训练集和测试集,二者互不干扰。训练集用于输入到设置好参数的 SE-BiGRU-ResNet 诊断模型中进行训练,当训练到达设定迭代次数后,将训练模型保存,用于后续测试。

4) 将测试集输入到步骤 3) 中保存的训练模型中,对模型诊断与定位的准确率进行评估,如果评估结果显示此时模型诊断与定位的能力并未达到最优,接着返回 3) 中再次模型训练,直到模型诊断与定位准确率达到一定的标准,则此刻已经离线训练出性能最优的诊断模型,该模型后续可投入到实际 MMC 运行中进行在线诊断与实时监测。

通过上述步骤,可有效诊断与定位 MMC 中的故障 IGBT 状态,为后续制定 MMC 的保护策略提供参考理论与技术支撑。

4 实验与分析

4.1 MMC 分立化故障诊断与定位数据集制作

为了验证所提方法有效性及正确性,基于 MATLAB/Simulink 平台搭建了三相九电平 MMC 系统,表 2 为 MMC 系统的部分参数,并通过如图 7 所示的实时数字半实物平台 (real time digital semi-physical laboratory, RT-LAB) 来验证基于 Simulink 平台所搭建 MMC 系统的合理性,根据

示波器中波形结果与仿真波形对比观察已保持一致,证明所搭建 MMC 系统具有合理性,可应用于后续故障诊断过程中。表 3 为故障类别样本标签及样本数量,其中 A_{up} 表示 A 相上桥臂, SM_1-T_1 代表第 1 个子模块中的第 1 个 IGBT。

表 2 MMC 系统部分参数

Table 2 MMC system partial parameters			
参数	取值	参数	取值
子模块总数量/个	48	负载电感 L/mH	15
直流母线电压 U_{dc}/V	800	开关频率 f_s/Hz	1 500
桥臂电抗 L/mH	4.7	基频/ Hz	50
子模块电容 C/mF	3.5	额定功率 P/kW	20
负载电阻 R/Ω	15	调制比 m	0.95

表 3 不同故障下样本标签和数量

Table 3 Sample labels and quantities for different fault					
桥臂故障类别	样本标签	样本数量	子模块中 IGBT 开路故障类别	样本标签	样本数量
正常	0	313	正常	0	313
A_{up}	1	313	SM_1-T_1	1	313
A_{down}	2	313	SM_1-T_2	2	313
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
C_{down}	6	313	SM_8-T_2	16	313






图 7 RT-LAB 验证 MMC 可行性的过程
Fig. 7 RT-LAB process to verify MMC feasibility

利用搭建 MMC 系统来模拟 IGBT 故障类别,进而获取各故障类别下参量来构成初始样本集。在桥臂故障诊断过程中,设定 MMC 系统运行 0.5 s,在 0.1 s 时发生 IGBT 开路故障。由表 3 得可收集 7 组不同桥臂故障类别下输出相电流数据,其中第 1 组信号在正常运行产生,其余 6 组信号由 MMC 故障运行产生,部分故障类别下的输出相电流如图 8 所示;当故障桥臂被成功诊断出来后,只需对故障桥臂进行单独研究就能定位到子模块中故障 IGBT,以 MMC 中 A 相上桥臂发生故障为例,由表 3 得可收集到 17 组不同 IGBT 开路故障类别下桥臂电压数据,


其中 1 组信号由 MMC 正常运行产生,16 组信号由 MMC 故障运行产生。部分故障类别下桥臂电压如图 9 所示。




(a) Normal



(b) A_{up}



(c) A_{down}



(d) B_{up}

图 8 部分故障下的 MMC 输出相电流
Fig. 8 MMC output phase current under partial fault




图 9 部分故障下的 MMC 桥臂电压

Fig. 9 MMC bridge arm voltage under partial fault

故障参量,可能会导致因计算量过大而出现维数灾难的问题。为了简化计算量,提取各故障模式下的故障相电流作为故障参量,通过时域波形观察 MMC 在正常工作时、 A 相上桥臂故障后和 B 相上桥臂故障后差异性较大,可提取出有效故障信息,但 A 相上下桥臂的电流波形在时域上观察区别不大,难以提取有效的故障信息,需要更加精细的特征提取方法来进行处理。文献[19]中提出一种滑动窗口特征提取算法来对离线数据进行处理,动态更新所得故障数据,在综合考虑下设计滑动窗口大小为 2 000 个采样点,滑动步长为 250 个采样点,则不同故障类别下的相电流信号可分为 313 个样本,总样本数为 $313 \times 7 = 2\,191$ 个,记为诊断故障桥臂数据集 1。图 9 中,相同子模块中不同位置上 IGBT 故障的桥臂电压在发生故障后有不同的畸变,但不同子模块相同位置上 IGBT 故障的桥臂电压在发生故障后极其相似,在时域性能上同样难以区分,按照前述也可进行滑动划分为 313 个样本,总样本数为 $313 \times 17 = 5\,321$ 个,记为定位故障 IGBT 数据集 2。

通过上述已划分的样本数据集,对诊断故障桥臂数据集 1 和定位故障 IGBT 数据集 2 中样本进行二维纹理图像映射,如图 10 所示为部分故障类别下第 100 个样本的转换效果。图 10 中,无论是诊断故障桥臂数据集 1 和定位故障 IGBT 数据集 2,各种故障类别之间不同图像像素点之间具有一定的差异性,但差异不显著不明显,在小样本故障诊断问题中,这种不显著不明显的差异可能会使得诊断精度下降。例如在数据集 1 中,正常情况下与 A 相下桥臂的 MTF 图像特征比较相似,容易使诊断模型产生误判,无法有效诊断出故障桥臂。

为使得诊断模型在小样本下 MMC 分立化故障诊断问题中获得较高准确率,将不同故障类别下的四图图像按通道维度增广叠加。即在诊断桥臂过程中,每种桥臂故障类别下可生成 313 张多源融合图,共 $313 \times 7 = 2\,191$ 张多源融合图,将其构建为故障桥臂诊断数据集 1;当故障桥臂成功诊断出后再定位子模块中故障 IGBT 时,每种 IGBT 故障类别下生成 313 张多源融合图,共 $313 \times 17 = 5\,321$ 张多源融合图,将其构建为子模块故障 IGBT 定位数据集 2。

为避免计算机算力浪费和加快模型训练速度,设置每张多源融合图分辨率为 80×80 。在故障诊断问题中,小样本通常指当训练集样本数量与总样本(训练集+测试集)数量的比值 $\alpha \leq 0.5$ 的情况^[20],则将数据集 1 和数据集 2 分别按 2:3 随机划分为训练集和测试集,二者互不干扰,以供后续模型训练、保存和测试,如图 11 所示为数据集 1 和数据集 2 中的多源融合图示例。

图 11 中,当 MMC 发生故障后,无论是数据集 1 或数据集 2,多源融合图中细节描述、彩色纹路和线条比例

图 8 中,直接利用输出相电流作为深度学习模型的




图 10 MMC 部分故障下二维纹理图像

Fig. 10 2D texture images under MMC partial fault




图 11 数据集 1 和数据集 2 中部分故障类别下多源融合

Fig. 11 Multi-source fusion graph under selected fault categories in dataset 1 and dataset 2

有所区别,故障特征都清晰易辨,保留了原始故障信号中的重要特征,现利用峰值信噪比(peak signal noise ratio, PSNR)来量化多源融合图的质量变化,PSNR 值越大,表明融合图像失真越小,其质量越好^[21]。如表 4 所示为数据集 1 和数据集 2 下第 100 个样本的多源融合图与原始图像的 PSNR 数值大小。

表 4 部分样本下多源融合图与原始图像的 PSNR 数值大小

Table 4 The PSNR value of the multi-source fusion graph and the original image under some samples (dB)

原始图像	数据集 1 PSNR	数据集 2 PSNR
RP	30. 11	29. 96
MTF	30. 91	30. 02
GADF	30. 22	30. 11
GASF	30. 74	30. 37
均值	30. 50	30. 12

表 4 中,无论是数据集 1 还是数据集 2,多源融合图的 PSNR 均值均超过了 30 dB 的基准线,多源融合图与原始图像之间的高度相似性代表图像保真度非常高,其

确保了原始图像的关键细节和特征得以完整保留,且其还反映出本文所提特征提取方法的有效性,不仅可以精确捕捉图像的细微特征,而且便于后续的 SE-BiGRU-ResNet 诊断模型的训练、保存和测试;通过将四张图像的特征融合为一张,不仅简化了数据结构,还显著减少了模型在数据传输过程中的负担,极大提升了模型处理数据的效率,从而加快辨识不同故障的速度,提高故障诊断实时性。

4. 2 MMC 诊断与定位结果及对比分析

实验模型所用平台参数为: Intel (R) Core (TM) i5-10200H 处理器, NVIDIA GeForce GTX 1650 显卡, 16 G 内存, 使用 CPU 和 GPU 混合训练, 深度学习框架为 Pytorch, 编程语言为 Python3. 11。

不同超参数下的智能模型所拥有的诊断性能有所差异,在实际工程中需要设置与优化相对合适的参数来保证智能模型在故障诊断上具有较优的性能,在诊断模型训练过程中,超参数如批尺寸、优化器和迭代次数的合理选择对于诊断模型是否能达到最优有着关键的影响,为获得最佳超参数,通过选取不同超参数指标对模型重复验证(批尺寸: 4、8、16、32、64、128; 迭代次数: 50、100、150、200、250、300; 优化器: Adam、SGD、Nadam、RMSprop),为节省篇幅,仅展示在进行故障桥臂诊断过程时的如图 12 所示为在部分超参数指标下诊断模型故障准确率。

批尺寸的大小会影响智能模型诊断准确率,过大可能导致梯度计算估计值不准确,影响智能模型的泛化能力,过小则可能使训练过程变得缓慢,难以最大限度的利用计算机硬件资源;优化器的选择决定智能模型中参数的更新规则,在某些情况下可能导致模型过早收敛到次优解;迭代次数过多可能导致模型过拟合,对数据产生依赖性,而迭代次数过少会导致模型无法充分学习数据内部故障特征,影响模型诊断性能。如图 12 所示根据所有实验记录,在批尺寸为 32,优化器为 Adam 梯度下降算法




图 12 部分批尺寸、优化器和迭代次数下诊断准确率
Fig. 12 The accuracy of intelligent model verification under different batchsizes, optimizers and iterations

进行参数优化,迭代次数第 200 次,学习率 0.001,每迭代 10 次,学习率降低 10%时,可达到最优诊断准确率。

4.3 实验与结果分析

为验证在小样本情况下本文特征提取方法与诊断模型可行性,利用 4.1 节中数据集 1 和数据集 2 来进行故障桥臂诊断与子模块故障 IGBT 定位实验。将数据集 1 和数据集 2 输入到 SE-BiGRU-ResNet 模型中,如图 13 所示在诊断模型训练过程中,随着迭代次数的增加,模型准确率在训练中快速上升,损失率快速下降,数据集 1 和数据集 2 分别在迭代次数为第 100 次和第 50 次时,准确率和损失率基本达到收敛状态,在迭代次数为第 200 次时取得最好效果,数据集 1 准确率达到 98.86%,损失率达

到 0.030 00,数据集 2 准确率达到 100.00%,损失率达到 0.000 75,此刻训练模型已经达到收敛且拟合效果非常好,则保存第 200 次迭代模型为诊断故障桥臂与定位故障 IGBT 目标模型。




图 13 训练过程中准确率与损失率曲线
Fig. 13 Plot of accuracy and loss rate during training

为验证在小样本情况下诊断模型的泛化性能,将数据集 1 和 2 中的测试集分别输入到保存目标模型中,平均测试准确率分别达到了 98.10% 和 99.13%。本文利用混淆矩阵对诊断结果进行定量分析,横坐标表示诊断模型预测结果,纵坐标表示 MMC 真实结果,主对角线元素表示预测结果与真实结果相同的样本数量,非主对角线元素为误判样本数量。测试诊断结果混淆矩阵如图 14 所示,图 14 中无论是数据集 1 或 2,不同的故障类别下的样本都能被正确分类,误判样本数极少,分类准确率高,泛化能力强。在整个过程中,不需要复杂的坐标变换,也不需要专家先验知识与人工调试经验,即可成功诊断出故障桥臂和子模块中故障 IGBT,即本文方法在 MMC 故障诊断小样本方面具有一定的可行性。

为验证本文诊断模型的应用价值,现利用诊断模型的测试时间 t 、参数量 WP 、大小 Ws 和消耗算力 F 等指标来进行评估,如表 5 所示为本文模型在诊断故障桥臂和定位故障 IGBT 时相应评估指标大小。

表 5 中,诊断出发生故障的桥臂用时约为 2.11 s,定位子模块中故障 IGBT 用时约为 4.04 s,模型拥有秒级响应时间,满足实时诊断需求,模型大小为 55.062 M,满足模型大小(小于 100 MB)要求,未来该模型可考虑将本文




图 14 测试过程中诊断结果的混淆矩阵

Fig. 14 Confusion matrix of diagnostic results during testing

表 5 模型诊断与定位过程中相应评估指标大小

Table 5 The size of the corresponding evaluation index in the process of model diagnosis and location

评估指标	T/s	WP/M	Ws/MB	F/G
诊断故障桥臂	2.11	14 424 639	55.062	567.57
定位故障 IGBT	4.04	14 424 639	55.062	1 378.38

方法部署在物联网或智能互联网等边缘设备中,在实际 MMC 运行时进行在线诊断与实时监测。

为了进一步突出本文方法对不同数据集中故障类别

的特性学习能力,引入一种 t 分布随机邻域嵌入 (t-distributed stochastic neighbor embedding, t-SNE) 的非监督降维方法,该方法被应用于高维特征可视化和验证样本聚类能力等方面。通过 t-SNE 算法将不同阶段故障特征降维至二维平面中相似程度高的点聚合,相似程度低的点会疏远。如图 15 所示为不同数据集下测试集中未经处理的原始数据、诊断模型输入层和诊断模型输出层经过 t-SNE 可视化的结果。




图 15 数据集 1 和数据集 2 下不同阶段 t-SNE 可视化

Fig. 15 Visualization of t-SNE at different stages of dataset 1 and dataset 2

如图 15 所示,由于原始数据并未进行任何处理,各种故障类型分布都是杂乱无章的,无法形成有效的聚类;当原始数据经过本文特征提取方法后,各种故障类型已大致可以形成聚类,但是在故障边界处仍是杂乱的;当故障数据经过 SE-BiGRU-ResNet 诊断模型输出层后,诊断模型对故障特征再次提取并充分学习,各类故障特征成功完成了分离与汇聚,在输出层可以看出同类特征聚类和不同特征分离,即经过本文所提方法后对原始数据逐步特征提取的效果显著,对 MMC 故障分类的效果好。t-SNE 可视化结果进一步证明了本文所提方法对小样本情况下的 MMC 中 IGBT 开路故障诊断与定位具有较高灵敏度与较强识别能力。

4.4 消融实验与对比分析

消融实验:为验证本文特征提取方法优势所在,保证 SE-BiGRU-ResNet 诊断模型不变来进行实验。即方案①~④:分别用 RP、MTF、GASF 和 GADF 算法映射出二维图像单独作为诊断模型的输入,方案⑤:为突出 4 个图按通道维度增广叠加转换方法的优越性,将 4 个图按像素级别(水平拼接)作为诊断模型的输入。根据单一变量

原则,RP、MTF、GASF 和 GADF 图象样本采用 4.1 节中数据集 1 和 2 中样本,迭代次数、样本数量与划分方法等均与前文一致。为了评估不同图像对故障诊断的性能,选取准确率、精确度、召回率和 F1 分数值作为评价指标^[13],不同图像下故障诊断性能评价指标如表 6 所示。

表 6 不同图像下评价指标

Table 6 Evaluation indicators under different images					
(%)					
类别	方案	准确率	精确度	召回率	F1 分数
数据集 1	①	60.61	60.01	61.20	61.18
	②	55.29	56.12	55.23	55.49
	③	58.66	57.33	59.21	58.29
	④	65.20	65.96	65.36	65.31
	⑤	96.09	96.01	95.29	95.97
	本文	98.10	98.01	97.80	98.04
数据集 2	①	96.71	97.66	97.66	97.56
	②	86.19	84.99	86.00	86.10
	③	95.02	95.01	94.99	95.02
	④	95.27	94.66	95.10	93.34
	⑤	97.01	96.70	94.32	96.55
	本文	99.03	98.90	99.00	99.01

表 6 中,无论是数据集 1 或是 2,本文所提出的故障特征提取方法在不同评价指标上均优于其它方法,这表明 4 个图经过通道维度增广叠加后包含更加丰富的故障特征且特征互补性明显,在诊断模型的识别分类中有着最佳效果。多源融合图可提供更全面的信号特征互补表征,使得诊断模型能够同时接收来自不同方法映射的信息,相比于单一映射方式能更全面地反映出故障信号的内部特性,这种信息互补性有助于诊断模型做出更加准确的诊断分类。将 4 个图按像素级别拼接,会导致特征空间发生混淆与信息之间的相互干扰,特别是在小样本下这种干扰更加明显,而将 4 个图按通道维度增广融合可让诊断模型理解不同特征之间的潜在联系,而按像素级别拼接无法有效地捕获通道间的相关性,本文特征提取方法可有效降低诊断模型在小样本下的过拟合风险。

对比实验:为验证本文所提 SE-BiGRU-ResNet 诊断模型的优势所在,保证特征提取方法的不变来进行对比实验。利用本文模型与模型①~⑧:SE-ResNet、SE-LSTM-ResNet、SE-BiLSTM-ResNet、SE-GRU-ResNet、BiGRU-ResNet、ResNet、SE-DSCNN^[13]、深度置信^[6]和 WELM-AE^[16]模型进行 5 次对比实验,将 4.1 节中数据集 1 和 2 中样本作为各个模型的输入,现采用准确率、精确度、召回率、测试时间和参数量等评估指标来衡量诊断模型的优劣,不同模型下故障诊断性能的评估指标如表 7 所示。

表 7 不同模型下评估指标

Table 7 Evaluation indicators under different models									
类别	模型	准确率/%	精确度/%	召回率/%	F1 分数/%	T/s	WP/M	Ws/MB	F/G
数据集 1	①	91.25	91.11	91.10	90.00	3.99	11 269 183	43.025	560.64
	②	95.06	95.01	93.00	95.01	3.14	13 370 431	51.041	565.25
	③	97.64	98.07	98.21	96.60	3.17	15 475 263	59.070	569.87
	④	96.43	96.00	96.00	96.00	2.64	12 845 119	49.037	564.10
	⑤	92.11	92.00	91.99	91.21	7.84	41 154 119	157.027	608.63
	⑥	94.56	94.22	94.11	94.29	9.58	64 221 377	387.22	997.33
	⑦	90.02	89.88	89.55	89.87	11.02	71 278 661	392.11	1065.39
	⑧	89.96	89.97	89.96	89.96	8.02	40 997 456	211.23	599.64
	本文	98.10	98.01	97.80	98.04	2.11	14 424 639	55.062	567.57
数据集 2	①	90.02	89.88	89.11	89.99	6.67	11 269 183	43.025	1 361.55
	②	94.90	95.11	95.13	95.18	6.55	13 370 431	51.041	1 372.75
	③	97.56	98.19	96.40	98.01	6.27	15 475 263	59.070	1 383.97
	④	97.40	97.00	97.10	97.01	5.08	12 845 119	49.037	1 369.95
	⑤	91.45	91.21	91.00	90.99	9.24	41 154 119	157.027	1 478.09
	⑥	82.74	82.82	81.80	81.94	10.77	64 221 377	387.22	1 877.21
	⑦	85.24	86.43	84.56	84.66	16.78	71 278 661	392.11	2 023.57
	⑧	83.21	83.22	83.12	83.22	8.88	40 997 456	211.23	1 553.9
	本文	99.13	98.90	99.00	99.01	4.04	14 424 639	55.062	1 378.38

表 7 中,本文所提模型在多个关键性能指标上展现出显著优势,在准确率方面,本文模型在数据集 1 和 2 上分别达到了 98.10% 和 99.03%,远超其他对比模型,有着极高的诊断准确性;精确度和召回率的高准确率也证明了所提模型在识别正样本方面的能力;F1 分数作为精确度和召回率的调和平均,也分别在达到了 98.04% 和 99.01%,进一步证实了模型的稳定性和可靠性;在测试时间上,本文模型在数据集 1 上仅需 2.11 s,在数据集 2 上为 4.04 s,这表明模型具有快速的诊断能力,能够进行实时故障诊断。参数量为 55.062 MB,相对较低的参数量使得本文模型在保持高性能的同时也具有较好的泛化能力和较低过拟合风险。具体而言,相比于模型①~④,BiGRU 模块的引入使得诊断模型同时捕获输入序列的正反向信息,在处理复杂时序数据时全面地理解上下文信息,在一定程度上减少计算量;相比于模型⑤,SE 模块的引入使得诊断模型可自适应校准通道特征响应,有助于其更好地关注重要特征,抑制冗余特征;而模型⑥、⑦和模型⑧中,因没有足够的数据进行训练从而发生过拟合,且模型中结构单一化导致无法提取到足够的关键特征,使得准确率下降,且模型数据量过大,消耗资源多,工程应用方面较不易。本文模型结合了 SE 模块和 BiGRU 模

块的优势,在 ResNet 的基础上既能够自适应地调整特征响应,又能够捕获序列中的上下文信息,还能避免梯度消失或爆炸问题。这种模型融合方式让 SE-BiGRU-ResNet 诊断模型在 MMC 小样本故障诊断中的准确性、效率、稳定性和资源消耗等方面表现出色。

4.5 极端条件下诊断方法性能分析

在 MMC 真实运行过程中,在小样本情况发生的同时可能会存在样本不平衡和外界噪声等极端条件的干扰^[22],为了验证本文方法在极端条件下的适用性,进行以下实验:

在 MMC 故障诊断过程中,IGBT 故障发生后危害大但是发生的概率却很小,难以采集到大量的故障样本,会使得正常样本个数与故障样本个数不均衡,难以挖掘内部故障规律。为更好地符合真实工作下的 MMC 故障诊断,训练数据模拟真实工况下的样本不平衡数据进行实验,根据 MMC 中不同故障种类的出现频率进行采样,重新分配 4.1 节中数据集 1 和 2 为正常状态 300 组,其余故障类别下各 150 组,共 $200+150\times 17=2\,750$ 组多源融合图,按 2:3 的比例进行随机划分并送入 SE-BiGRU-ResNet 诊断模型中进行训练和测试,在不平衡数据集下的训练与测试结果如图 16 所示。




图 16 在不平衡数据下的相关评价指标

Fig. 16 Related evaluation index map under unbalanced data

图 16 中,在诊断模型训练过程中,随着迭代次数的增加,模型准确率在训练中快速上升,损失率快速下降,数据集 1 和 2 分别在迭代次数为第 100 和 75 次时,准确率和损失率基本趋于稳定并达到收敛状态,在迭代次数为第 200 次时取得最好效果,数据集 1 准确率达到 98.63%,损失率达到 0.035 36,数据集 2 准确率达到 100.00%,损失率达到 0.003 67,此刻训练模型已经达到收敛且拟合效果非常好。训练完成后,数据集 1 和 2 的平均测试准确率达到了 97.58% 和 98.01%,比非极端条件下的测试准确率仅低了 0.52% 和 1.12%。测试过程中由混淆矩阵得本文所提方法在样本不平衡情况下各类故障的识别精度均比较高,误判率低,可以精确诊断出故障 IGBT 的位置,证明所提 MMC 故障诊断方法对于小样本下不平衡问题也有很好的泛化性能与适应性。

MMC 作为电力系统中的核心设备之一,其工作环境不会处于理想环境,内部元件的振动和摩擦都会产生噪声,在故障诊断过程中采集电信号易受到污染,因此对诊断模型的抗噪能力有一定的要求,为了验证本文诊断模型在现实工作中的鲁棒性与适应性,选用第 4.1 节中的多源融合图,向数据集中加入不同信噪比的高斯白噪声来模拟实际工作中的噪声,选用-5、0、5 和 10 dB 的噪声信号加入数据集中来对本文模型和第 4.4 节对比实验中的模型进行训练和测试,迭代训练次数、样本数量与划分方法等均与前文一致,实验测试 5 次并计算平均准确率,结果如表 8 所示。

表 8 中,在不同的噪声背景下,本文模型准确率均高于其他模型。当 SNR=-5 dB 的极高噪声干扰下,本文模型在诊断故障桥臂和定位故障 IGBT 位置的平均准确率为 84.17% 和 80.06%,远高于其他模型。随着 SNR 的增加,其他模型的平均准确率虽有不同程度的上升,但仍然不及本文模型,因为本文所提多源融合图与 SE-BiGRU-ResNet 模型的结合可以全面提取故障信息,摒弃冗余信息干扰,在一定程度上降低了噪声的干扰,使其获得更好的抗噪能力。所以通过实验可知,本文所提方法能够针对 MMC 发生 IGBT 开路故障后实现有效诊断,具有较强的抗噪声能力。

5 结 论

本文将特征融合与深度学习引入 MMC 故障诊断中,提出一种基于多源融合图与 SE-BiGRU-ResNet 诊断模型的 MMC 小样本开路故障诊断方法。解决了因缺乏充足目标域样本而导致 MMC 故障诊断过程中模型泛化能力低、准确率下降和无法精准定位到故障 IGBT 位置的问题。可为相关对称换流器等仪器中 IGBT 开路故障提供诊断思路。具体得出以下结论:

表 8 不同模型的抗噪性能分析
Table 8 Anti-noise performance analysis of different models (%)

类别	模型	-5 dB	0 dB	5 dB	10 dB
数据集 1	①	52.77	70.11	77.24	89.88
	②	62.71	74.17	79.88	93.94
	③	64.45	76.99	80.21	95.68
	④	63.11	75.55	88.88	95.66
	⑤	60.11	71.12	85.66	88.65
	⑥	52.10	69.99	75.29	84.32
	⑦	49.29	59.98	65.66	78.11
	⑧	47.24	48.22	50.97	55.42
数据集 2	本文	84.17	85.26	92.21	96.23
	①	69.99	76.59	78.66	88.65
	②	71.19	79.21	85.01	92.99
	③	71.17	80.10	85.12	93.64
	④	70.32	79.24	84.32	93.23
	⑤	69.22	77.12	79.22	87.63
	⑥	50.17	67.29	74.43	80.12
	⑦	52.21	66.22	75.18	82.26
	⑧	50.01	52.21	54.55	59.87
	本文	80.06	81.18	85.41	94.24

1) 在小样本情况下,因缺乏训练样本,创新性地引入多源融合图将单一映射故障图像按通道维度增广融合,实现了 MMC 多通道故障特征的互补加强显示,增强了小样本下训练样本的质量,为后续诊断模型提供了丰富的特征基础。

2) 在 ResNet 的基础上结合 SE 模块与 BiGRU 模块,创新性的构建基于 SE-BiGRU-ResNet 诊断模型。ResNet 中双支路结构以不同尺度空间视角来提取有效故障特征,有效的解决了梯度爆炸和网络参数退化的问题;将其与 SE 模块进行融合,以此降低冗余信息的干扰,实现局部特征细节的互补,利用 BiGRU 模块对全局时间信息进行提取,提高诊断精度。且模型测试时间短,可快速锁定故障位置,在 IGBT 发生开路故障造成实质危害前将子模块切除。

3) 本文所提 MMC 故障诊断方法能够很好地应对小样本情况下的影响,相比于其他方法,对故障类型的诊断准确率更高,抗扰动能力强,可将其投入到实际 MMC 运行中进行在线诊断与实时监测中。

后续工作可利用真实 MMC 电路装置中的故障数据来验证所提方法的普适性,以拓宽人工智能算法在电力系统相关仪器故障诊断领域中的应用。

参考文献

[1] 白志红, 蒋守赞, 郭咏春. 基于双重滑模观测器的

- MMC 开关管开路故障诊断与定位策略[J]. 电力系统自动化, 2024, 48 (14): 147-156.
- BAI ZH H, JIANG SH Z, GUO Y CH, et al. Open-circuit fault diagnosis and location strategy of switches in modular multilevel converter based on dual sliding mode observer[J]. Automation of Electric Power Systems, 2024, 48 (14): 147-156.
- [2] LIU ZH J, LI K J, WANG J Y, et al. General model of modular multilevel converter for analyzing the steady-state performance optimization [J]. IEEE Transactions on Industrial Electronics, 2021, 68(2): 925-937.
- [3] 刘泽浩, 肖岚. 模块化多电平变流器 IGBT 开路故障诊断与定位方法综述[J]. 中国电机工程学报, 2024, 44(4): 1501-1517.
- LIU Z H, XIAO L. Review of IGBT open-circuit fault diagnosis and localization methods for modular multilevel converter[J]. Proceedings of the CSEE, 2024, 44(4): 1501-1517.
- [4] 李喆, 吐松江·卡日, 范想, 等. 基于双图转换和融合 CRNN 网络的轴承故障诊断[J]. 振动与冲击, 2023, 42(19): 240-248.
- LI ZH, KARI T S J, FAN X, et al. Bearing fault diagnosis based on double-graph conversion and fusion CRNNs[J]. Journal of Vibration and Shock, 2023, 42(19): 240-248.
- [5] 肖雄, 肖宇雄, 张勇军, 等. 基于二维灰度图的数据增强方法在电机轴承故障诊断的应用研究[J]. 中国电机工程学报, 2021, 41(2): 738-749.
- XIAO X, XIAO Y X, ZHANG Y J, et al. Research on the application of the data augmentation method based on 2D gray pixel images in the fault diagnosis of motor bearing[J]. Proceedings of the CSEE, 2021, 41(2): 738-749.
- [6] 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 convertersub-module based on short-time fourier transform and deep networks[J]. Transactions of China Electrotechnical Society, 2024, 39(12): 3840-3854.
- [7] 康守强, 章炜东, 王玉静, 等. 基于信息融合子域适应的不同工况下谐波减速器故障诊断方法[J]. 仪器仪表学报, 2024, 45(3): 60-71.
- KANG SH Q, ZHANG W D, WANG Y J, et al. A fault diagnosis method for harmonic reducers under different operating conditions based on information fusion subdomain adaptation[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 60-71.
- [8] 赵莹莹, 何怡刚, 邢致恺, 等. 基于信息融合与深度残差收缩网络的 DAB 变换器开路故障诊断方法[J]. 电力自动化设备, 2023, 43(2): 112-118.
- ZHAO Y Y, HE Y G, XING ZH K, et al. Open-circuit fault diagnosis method of DAB converter based on information fusion and DRSN[J]. Electric Power Automation Equipment, 2023, 43(2): 112-118.
- [9] 段晓燕, 焦孟萱, 雷春丽, 等. 基于 MTF-MSMCNN 的小样本滚动轴承故障诊断方法[J]. 航空动力学报, 2024, 39(1): 240-252.
- DUAN X Y, JIAO M X, LEI CH L, et al. A rolling bearing fault diagnosis method based on MTF-MSMCNN with small sample [J]. Journal of Aerospace Power, 2024, 39(1): 240-252.
- [10] 李宗源, 陈谦, 钱倍奇, 等. 基于格拉姆角场与并行 CNN 的并网逆变器开关管健康诊断[J]. 电力自动化设备, 2024, 44(8): 153-159.
- LI Z Y, CHEN Q, QIAN B Q, et al. Health diagnosis of switch tube in grid-connected inverter based on Gramian angular field and parallel CNN [J]. Electric Power Automation Equipment, 2024, 44(8): 153-159.
- [11] DU B L, HE Y G, ZHANG CH L. Intelligent diagnosis of cascaded H-bridge multilevel inverter combining sparse representation and deep convolutional neural networks[J]. IET Power Electronics, 2021, 14(6): 1121-1137.
- [12] DENG F J, JIN M, LIU CH K, et al. Switch open-circuit fault localization strategy for MMCs using sliding-time window based features extraction algorithm [J]. IEEE Transactions on Industrial Electronics, 2021, 68(10): 10193-10206.
- [13] 曾昭璐, 何怡刚. 基于 SE-DSCNN 的 MMC 开关管故障诊断方法[J]. 电力自动化设备, 2022, 42(5): 104-111.
- ZENG ZH R, HE Y G. Fault diagnosis method for switches in MMC based on SE-DSCNN [J]. Electric Power Automation Equipment, 2022, 42(5): 104-111.
- [14] 杨彦杰, 董哲, 姚芳, 等. 基于 1D-CNN-LSTM 混合神经网络模型的双桥并联励磁功率单元故障诊断[J]. 电网技术, 2021, 45(5): 2025-2032.
- YANG Y J, DONG ZH, YAO F, et al. Fault diagnosis of double bridge parallel excitation power unit based on 1D-CNN-LSTM hybrid neural network model[J]. Power System Technology, 2021, 45(5): 2025-2032.
- [15] 尹桥宣, 段斌, 沈梦君, 等. 模块化五电平逆变器子模块开路故障的智能诊断方法[J]. 电力系统自动

- 化, 2018, 42(12): 127-133, 147.
- YIN Q X, DUAN B, SHEN M J, et al. Intelligent diagnosis method for open-circuit fault of sub-modules in modular five-level inverter[J]. Automation of Electric Power Systems, 2018, 42(12): 127-133, 147.
- [16] 孔令瑜, 张彼德, 洪锡文, 等. MMC 五电平逆变器故障的深度小波极限学习机诊断方法研究[J]. 电力系统及其自动化学报, 2020, 32(7): 25-32.
- KONG L Y, ZHENG B D, HONG X W, et al. Study on fault diagnosis method for MMC five-level inverter based on DWELM[J]. Proceedings of the CSU-EPSCA, 2020, 32(7): 25-32.
- [17] 黄新波, 马玉涛, 朱永灿. 基于信息融合和 M-RVM 的变压器故障诊断方法[J]. 电力自动化设备, 2020, 40(12): 218-225.
- HUANG X B, MA Y T, ZHU Y C. Transformer fault diagnosis method based on information fusion and M-RVM[J]. Electric Power Automation Equipment, 2020, 40(12): 218-225.
- [18] 杨东儒, 魏建文, 林雄威, 等. 基于自注意力机制的深度学习模拟电路故障诊断[J]. 仪器仪表学报, 2023, 44(3): 128-136.
- YANG D R, WEI J W, LIN X W, et al. A fault diagnosis algorithm for analog circuits based on self-attention mechanism deep learning[J]. Chinese Journal of Scientific Instrument, 2023, 44(3): 128-136.
- [19] 杨贺雅, 邢纹硕, 陈聪, 等. 基于随机森林二分类器的模块化多电平换流器子模块开路故障检测方法[J]. 中国电机工程学报, 2023, 43(10): 3916-3928.
- YANG H Y, XING W SH, CHEN C, et al. A fault detection and location strategy for sub-module open-circuit fault in modular multilevel converters based on random forest binary classifier[J]. Proceedings of the CSEE, 2023, 43(10): 3916-3928.
- [20] ZHANG X, HE CH, LU Y P, et al. Fault diagnosis for small samples based on attention mechanism[J]. Measurement, 2022, 187: 110242.
- [21] 鲁思琪, 周先春, 汪志飞. 改进型自适应全变分图像降噪模型[J]. 电子测量与仪器学报, 2022, 36(6): 236-243.
- LU S Q, ZHOU X CH, WANG ZH F. Improved adaptive total variational image denoising model[J]. Journal of Electronic Measurement and Instrumentation, 2022,

36(6): 236-243.

- [22] 徐卓飞, 李旭东, 张婵婵, 等. 基于孪生网络的小样本滚动轴承故障诊断研究[J]. 仪器仪表学报, 2022, 43(10): 241-251.

XU ZH F, LI X D, ZHANG CH CH, et al. Fault diagnosis of rolling bearings with limited samples based on siamese network[J]. Chinese Journal of Scientific Instrument, 2022, 43(10): 241-251.

作者简介



刘述喜, 1992 年于邵阳学院获得学士学位, 2005 年于重庆大学获得硕士学位, 2010 年于重庆大学获得博士学位, 现为重庆理工大学教授, 主要研究方向为电力传动及其控制、智能控制、电气设备在线监测与故障诊断。

E-mail: shuxi@cqut.edu.cn

Liu Shuxi received his B. Sc. degree from Shaoyang University in 1992, received his M. Sc. degree from Chongqing University in 2005, and received his Ph. D. degree from Chongqing University in 2010. He is currently a professor at Chongqing University of Technology. His main research interests include electric drive and its control, intelligent control, on-line monitoring and fault diagnosis of electrical equipment.



刘科(通信作者), 2022 年于湖北民族大学获得学士学位, 现为重庆理工大学硕士研究生, 主要研究方向为深度学习与电气设备故障诊断。

E-mail: liuke666@stu.cqut.edu.cn

Liu Ke (Corresponding author) received his B. Sc. degree from Hubei Minzu University in 2022. He is currently a master student at Chongqing University of Technology. His main research interests include deep learning and electrical equipment fault diagnosis.



黄思源, 2022 年于西昌学院获得学士学位, 现为重庆理工大学硕士研究生, 主要研究方向为双馈风力发电系统智能控制及故障诊断。

E-mail: 52220712188@stu.cqut.edu.cn

Huang Siyuan received her B. Sc. degree from Xichang University in 2022. she is currently a master student at Chongqing University of Technology. Her main research interests include intelligent control and fault diagnosis of DFIG system.