

DOI: 10.13382/j.jemi.B2508467

全线路串联电弧故障在线检测方法及装置研究*

田世岗¹ 王智勇² 高洪鑫² 李海嘉² 郭凤仪³ 王健¹

(1. 华北电力大学新能源电力系统国家重点实验室 北京 102206; 2. 辽宁工程技术大学电气与控制工程学院 葫芦岛 125105; 3. 温州大学电气与电子工程学院 温州 325035)

摘要:为提升低压交流电力系统中串联电弧故障(SAF)的检测效率与精度,以工业电动机配电线路为对象,通过电弧故障实验构建数据集,并设计了基于 MobileViT 架构的轻量级 SAF 识别模型。该识别模型采用轻量级卷积模块和 Transformer 模块分别提取电流信号中的局部特征和全局特征,并使用 Unfold-Transformer-Fold 机制以及全局平均池化层减少模型参数数量和计算复杂度。进一步通过 TensorRT 推理优化器和推理引擎对该模型进行部署优化,大幅提升了其在嵌入式设备中的推理速度,并据此研制了全线路 SAF 在线检测装置。该检测装置具备灵活的部署特性,当安装于变频器前端时,可同时监测变频器前端和后端的 SAF;安装于后端时也能实现后端 SAF 的精准监测。测试结果表明,该装置平均运行时间不超过 0.874 ms,识别准确率在 97.20% 以上,能够满足 IEC62606 标准的要求和工业场景应用需求。此外,对比实验表明该装置优于现有电弧故障探测器产品,能够为研发工业电弧故障断路器提供参考。

关键词: 串联电弧故障;轻量级模型;嵌入式设备;在线检测

中图分类号: TM501; TN06; TH89 **文献标识码:** A **国家标准学科分类代码:** 460.40

Research on on-line detection method and device for full-circuit series arc fault

Tian Shigang¹ Wang Zhiyong² Gao Hongxin² Li Haijia² Guo Fengyi³ Wang Jian¹

(1. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Beijing 102206, China; 2. Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China; 3. College of Electrical and Electronic Engineering, Wenzhou University, Wenzhou 325035, China)

Abstract: To improve the detection efficiency and accuracy of series arc fault (SAF) in low-voltage alternating current power system, this study takes industrial motor distribution circuits as the object, constructs datasets through arc fault experiments, and designs a lightweight SAF identification model based on MobileViT architecture. The model uses lightweight convolution modules and transformer modules to extract local and global features from the current signal respectively, and uses the unfold-transformer-fold mechanism and global average pooling to achieve parameter and complexity reduction. Further, the TensorRT inference optimizer and engine are used to deploy and optimize the model, which significantly improves the inference speed of the model in embedded devices, and based on this, the full-circuit SAF on-line detection device is developed. The detection device has flexible deployment characteristics; when installed at the front end of the frequency converter, it can simultaneously monitor the SAF of the front and back end of the frequency converter. It can also achieve precise monitoring of the SAF of the back end when installed at the back end. The test results show that the average runtime of the device is less than 0.874 ms, and the accuracy is above 97.20%, which can meet the requirements of IEC62606 standard and industrial scenarios. In addition, the comparison experiments show that the device is superior to the existing arc fault detector products and can provide a reference for the development of industrial arc fault circuit breakers.

Keywords: series arc fault; lightweight model; embedded device; on-line detection

收稿日期: 2025-06-17 Received Date: 2025-06-17

* 基金项目: 辽宁省教育厅基金(LJ242410147030, LJ212410147022)项目资助

0 引言

低压交流电力系统是工业生产的核心能源载体,其安全性与可靠性直接关系到工业生产过程的连续性。其中,工业电动机配电线路因其大电流、高功率的特点,成为电气故障的高发环节。特别是近年来随着变频调速技术的普及,三相电动机与变频器构成的驱动系统已广泛应用于机械、矿山、冶金等关键领域。这类线路在提升能效的同时,也因其复杂的工况环境面临着新的安全隐患—恶劣环境因素(包括机械振动、外力拉伸、高温等)会显著增加电连接器松动、电缆绝缘碳化的风险,进而引发串联电弧故障(series arc fault, SAF)与火灾事故。

相较于其他负载线路,电动机+变频器负载线路中的 SAF 具有更显著的检测难度:一方面,变频器输出的高频 PWM 调制波形会产生宽频谐波干扰,从而淹没电弧特征信号;另一方面,由于 SAF 与负载串联导致线路电流有效值降低,使传统过流保护装置无法有效动作^[1]。更值得注意的是,变频器前端(电网侧)与后端(电机侧)线路往往存在不同的工况特征,现有电弧故障检测装置难以实现全线路覆盖。因此,针对三相电动机+变频器负载(three-phase motor with frequency converter load, TMFCL)线路的特殊工况,亟需建立兼顾变频器前端与后端线路的 SAF 检测方法 with 装置。

目前,针对低压交流系统中的 SAF 识别方法已经开展了大量研究。主流的研究思路有两种,分别是针对故障电弧的物理特性和电流特性。电弧发生时伴随着弧声^[2-3]、弧光^[4]、电磁辐射^[5]以及其他物理特性。这些基于物理特性的检测方法由于受到传感器安装位置的限制,并不能有效检测到线路中未知位置发生的电弧故障,因此这种方法往往只能适用于低压开关柜等设备,具有较大的局限性。由于回路电流信号兼具线路状态表征能力和测量便利性,因此现有 SAF 检测研究主要围绕该信号展开分析。文献[6-13]提出了基于电流信号+特征提取+机器学习的检测方法。然而,这类方法存在以下局限性:首先,其性能高度依赖于人工设计的信号分析算法、特征工程策略以及分类器选择;其次,这类方法往往针对具有特定负载和拓扑结构的线路,通用性表现不佳。

随着人工智能的迅速发展,许多基于深度学习算法的串联电弧故障检测方法被提出。文献[14]分析了多工况下干路电流波形的变化特性与机理,并采用分组可分离卷积和递进式网络结构,较好地平衡了电弧故障识别模型的准确率与效率。文献[15]分别使用卷积神经网络(convolutional neural network, CNN)和长短期记忆网络提取电源侧信号的静态特征和动态时变特征,并后结合全连接网络实现电弧故障预测。文献[16]通过新型

高频耦合传感器采集电流特征信号,并根据时域序列将信号转换成二维灰度图像后作为模型输入,最后设计了 CNN 来检测 SAF。文献[17]手动选取了 29 个电弧特征,提出了多尺度卷积神经网络检测电弧故障,并对比了多种识别模型的复杂度与单样本预测时间。文献[18]提出了基于 CNN 的 SAF 检测模型,并在基于 Raspberry Pi 3B 的硬件平台上评估了模型的运行时间和检测精度。文献[19]提出了基于 EffNet building blocks 的轻量级 SAF 检测模型,并将模型转化为 TF-Lite 格式在 Raspberry Pi 4B 中评估了单个样本的检测时间。文献[20]提出了一种采用深度可分离卷积结构的轻量级电弧故障检测方法,并基于 Jetson nano 平台实现了 SAF 在线监测。文献[21]提出了一种基于特征映射相似性分析的神经网络轻量化思路,并开发了集成轻量级卷积网络与边缘计算平台的 SAF 实时检测装置。

然而,上述方法仍存在以下不足,如文献[14-21]提出的基于 CNN 的识别模型虽然大幅提高了检测准确率和泛化性能,但 CNN 采用滑动窗口的方式提取图像矩阵的局部特征,缺少对全局信息的感知与提取,因此在面对复杂任务时这类网络的识别性能有待进一步提升。虽然很多用于 TMFCL 线路的 SAF 检测方法已经被提出^[8-9,13,20-21],但这些方法仅考虑了变频器前端或变频器后端的 SAF。目前缺乏能够在线监测整个 TMFCL 线路的 SAF 检测方法。

为解决上述问题,本文提出一种结合 CNN 和 Transformer 架构的轻量级电弧故障识别模型,并研制了全线路 SAF 在线装置。设计了基于 MobileViT 的轻量级电弧故障识别模型。该模型以原始电流信号的时序矩阵作为输入,采用轻量级卷积模块和 Transformer 模块分别提取电流信号中的局部特征表示和全局特征表示,并使用 Unfold-transformer-fold 机制和全局平均池化层降低了参数量和计算复杂度。实验结果表明,该模型在运行速度和识别准确率方面均表现优异,并通过与其他检测方法的对比验证了其优越性。研制了基于嵌入式设备的全线路 SAF 在线检测装置。该检测装置仅通过一个电流互感器采集任意一相电流信号,并通过部署在嵌入式设备中的识别模型进行推理分析,实现了对 TMFCL 线路中变频器前端和后端电弧故障的同时检测。通过多工况实验评估了检测装置的识别精度与实时性,并对比验证了其相较于传统电弧故障探测器的性能优势。

1 SAF 实验与数据集

1.1 SAF 实验

如图 1 所示,实验平台主要由供电主线路和信号获取系统构成。其中,主线路采用 380 V 交流电源作为输

入,依次连接断路器、接触器等保护装置,并串接入 SAF 发生器。主线路末端配置了 VFD110E43A 型变频器驱动 Y160M-6-11kW 型三相异步电动机运行。

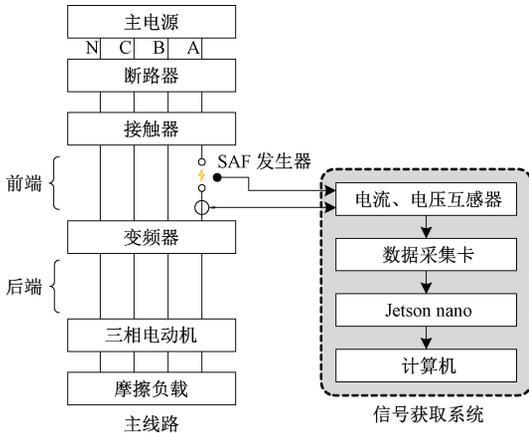


图 1 SAF 实验平台

Fig. 1 SAF experimental platform

信号获取系统由电压互感器、电流互感器 (current transformer, CT)、数据采集卡、Jetson nano 边缘计算终端及上位机构成。CT 和电压互感器分别负责获取主线路电流信号和 SAF 发生器动静电极上的电压信号。该电压信号可以实时反映主线路中的 SAF 状态。获取的电流电压信号经数据采集卡以 10 kHz 采样频率实时存储至 Jetson nano,实验完成后所有采集数据将被导出至上位机进行后续处理。

在工业配电网中,电流互感器的布设方案需依据具体电路拓扑灵活调整。如图 1 所示,CT 可能安装在变频器前端,也可能安装在变频器后端。此外,SAF 具有显著的位置不确定性,其可能出现在 TMFCL 线路的任意位置。鉴于此,实验方案被制定。如表 1 所示,实验总共分为 5 组,每组包含 3 个实验条件,分别在主线路的负载电流被设置为 15、17 和 19 A 时进行。其中, $C_1 \sim C_3$ 条件下电流互感器位于 A 相线路变频器前端,SAF 发生器不接入主线路; $C_4 \sim C_6$ 条件下电流互感器位于 A 相线路变频器后端,SAF 发生器不接入主线路; $C_7 \sim C_9$ 条件下,电流互感器和发生器均位于 A 相线路变频器前端; $C_{10} \sim C_{12}$ 条件下,电流互感器和发生器分别位于 A 相线路的变频器前端和后端; $C_{13} \sim C_{15}$ 条件下,电流互感器和发生器均位于 A 相线路变频器后端。依据电流互感器和 SAF 发生器的位置,以及主线路中是否有 SAF,将表 1 各实验条件下主线路的运行状态分别标记为“前-正常”、“后-正常”、“前前-故障”、“前后-故障”和“后后-故障”。

1.2 SAF 数据集

负载电流设置为 15 A 时各实验条件下的 A 相电流信号的时域波形如图 2 所示。 C_1 、 C_7 和 C_{10} 条件下的电

流信号均来源于变频器前端且均呈现“双峰状”。由 C_1 条件的红色圆形标记,当图 1 所示的主线路处于正常运行状态时,变频器前端电流的双峰高度基本一致。由 C_7 条件的红色圆形标记,当变频器前端出现 SAF 时,变频器前端电流的双峰间距明显增大。由 C_{10} 条件的红色圆形标记,当变频器后端出现 SAF 时,变频器前端电流的双峰间距也增大,但其变化幅度小于变频器前端出现 SAF 时双峰间距的变化幅度。通过对 C_4 和 C_{13} 条件的电流波形分析发现,变频器后端电流呈现近似正弦特性。在线路正常运行的 C_4 条件下,电流峰谷幅值基本相同;而在发生 SAF 的 C_{13} 条件下,电流峰谷幅值则表现出显著的波动特征。

表 1 实验方案

Table 1 Experimental scheme

实验条件	负载电流/A	运行状态	位置	
			CT	发生器
C_1, C_2, C_3	15, 17, 19	前-正常	前端	-
C_4, C_5, C_6	15, 17, 19	后-正常	后端	-
C_7, C_8, C_9	15, 17, 19	前前-故障	前端	前端
C_{10}, C_{11}, C_{12}	15, 17, 19	前后-故障	前端	后端
C_{13}, C_{14}, C_{15}	15, 17, 19	后后-故障	后端	后端

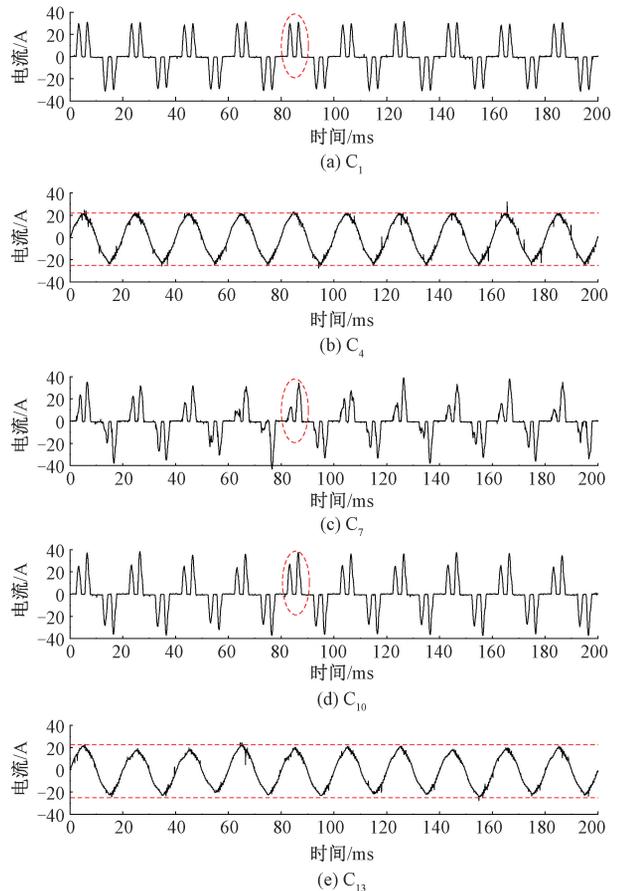


图 2 A 相电流信号的时域波形

Fig. 2 The time-domain waveform of the A-phase current signal

根据上述发现,表 1 中 5 种运行状态下的电流波形各有特点,能够为电弧故障诊断提供重要依据。同时,为提高样本构建效率,本文不采用复杂的信号分析方法与特征矩阵构造方法,而是通过固定宽度的窗口分段截取电流波形,从而快速获取样本。

为确保所构造的样本可以反映电流波形中的所有关键特点(包括正负半周的双峰、波峰、波谷),必须保证每个样本包含不少于 1 个完整周期的电流信号。也就是说,数据样本中包含的数据点数必须大于 200(市电电源工作频率为 50 Hz,信号采样频率为 10 kHz)。此外,考虑到 SAF 识别模型的计算量和推理效率,最终将滑动窗口的长度和步距设置为 256。按照上述方法依次处理了表 1 中各实验条件下获取的电流数据,共得到了 72 000 个数据样本,每个样本的形状为 256×1 。详细的样本分布如表 2 所示。

表 2 数据样本的详细分布

Table 2 The detailed distribution of the data samples

实验条件	样本数量	合计	标签
C_1, C_2, C_3	4 000, 4 000, 4 000	12 000	0
C_4, C_5, C_6	6 000, 6 000, 6 000	18 000	1
C_7, C_8, C_9	4 000, 4 000, 4 000	12 000	2
C_{10}, C_{11}, C_{12}	4 000, 4 000, 4 000	12 000	3
C_{13}, C_{14}, C_{15}	6 000, 6 000, 6 000	18 000	4

为提升 SAF 识别模型的训练效率,通过最大最小归一化方法对样本进行标准化预处理,如式(1)所示。由图 2 可见,当串联电弧故障发生时,电流信号的时域特征主要集中于正、负半周的波峰、波谷幅值。如图 3 所示,以变频器前端电流波形中的双峰为例,每个波峰的宽度均约为 16 个采样点。尽管变频器后端电流的波峰、波谷宽度整体更大,但其幅值最高部分所涵盖的采样点数也不会超过 16。基于这一观测,引入一种针对性的、有益的归纳偏置。如式(2)所示,将归一化后的一维数据样本(形状为 256×1)重塑为二维矩阵(形状为 $16 \times 16 \times 1$),其设计意图在于将每个波峰的幅值最高部分转化为二维矩阵中的一行数据,该行数据的上下相邻两行数据可作为其比较对象,从而形成一种“边缘特征”。这种设计使得幅值变化在二维空间中呈现为类边缘模式,便于卷积核进行有效提取,从而降低识别模型的学习难度,提升识别效率与准确性。

$$M_i = \frac{V_i - V_{\min}}{V_{\max} - V_{\min}} \quad i = 0, 1, 2, \dots, 255 \quad (1)$$

$$[M_0, M_1, \dots, M_{255}] = \begin{pmatrix} M_0 & \cdots & M_{15} \\ M_{16} & \cdots & M_{31} \\ \vdots & \ddots & \vdots \\ M_{240} & \cdots & M_{255} \end{pmatrix} \quad (2)$$

式中: V_i 和 M_i 分别指第 i 个数据的原始值和标准化预处理后的结果; V_{\max} 和 V_{\min} 分别为样本 V 中的最大值和最小值。

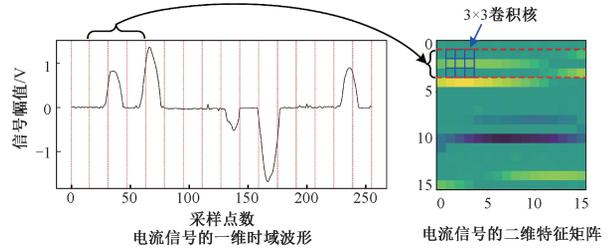


图 3 一维数据样本转换为二维矩阵的示意图

Fig. 3 Schematic diagram of converting one-dimensional data samples into two-dimensional matrices

上述处理完成后,为 $C_1 \sim C_3, C_4 \sim C_6, C_7 \sim C_9, C_{10} \sim C_{12}$ 和 $C_{13} \sim C_{15}$ 条件下的数据样本分别分配整型标签 0、1、2、3 和 4。然后,分别从 $C_1 \sim C_3, C_4 \sim C_6, C_7 \sim C_9, C_{10} \sim C_{12}$ 和 $C_{13} \sim C_{15}$ 条件的数据样本中各随机挑选 1 000 个样本,组成样本数量为 5 000 的数据集 Dataset2,剩余的样本组成样本数量为 67 000 的数据集 Dataset1。

2 轻量级 SAF 识别模型

2.1 移动视觉 Transformer (MobileViT) 模型

MobileViT 模型是一个轻量级、通用和移动设备友好的神经网络,其结合了 CNN 和视觉 Transformer (vision Transformers, ViT) 的优势^[22]。具体来说,虽然轻量级 CNN 已经被广泛应用于图像分类、目标检测和语义分割等任务中,然而这类网络在空间上是局部的,即这类网络在处理输入数据时主要专注于局部特征的提取。因此,为了更好地从输入数据中学习全局表示,MobileViT 提出了 MobileViT 块,能够在张量中有效地编码局部和全局信息。与现有基于 CNN 和基于 ViT 的网络相比,MobileViT 在多个移动视觉任务中实现了更好的性能,泛化能力以及鲁棒性。

MobileViT 主要包括 $n \times n$ 标准卷积 (Conv- $n \times n$)、MobileNetV2 块^[23]、MobileViT 块、全局池化层和线性层。如图 4 所示,MobileNetV2 块包含 Conv- $1 \times 1, 3 \times 3$ 深度卷积 (Dwise Conv- 3×3)、Shortcut 结构、ReLU6 激活函数和批归一化 (batch normalization, BN)。其中,第 1 个 Conv- 1×1 用于扩充输入特征图的通道数量,Dwise Conv- 3×3 用于以较低的计算量进行特征提取操作,第 2 个 Conv- 1×1 用于降低特征图的通道数量,Shortcut 结构用于改善梯度传播的能力。

如图 5 所示,MobileViT 块由局部表示、全局表示和融合操作 3 部分组成。局部表示包含 Conv- $n \times n$ 和 Conv-

1×1 。全局表示包含 Unfold 操作、 L 个 transformers 和 Fold 操作。融合操作包含 Conv- 1×1 、连接操作以及 Conv- $n \times n$ 。 H 、 W 和 C 分别代表特征图的高、宽及通道数。

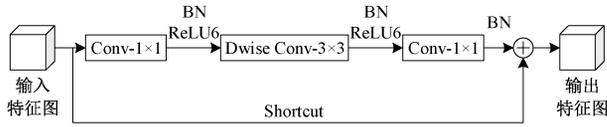


图 4 MobileNetV2 块的结构

Fig. 4 The structural illustration of MobileNetV2

对于一个给定的输入特征图 $X \in \mathbf{R}^{H \times W \times C}$ ，MobileViT 块的运算流程包括如下 3 个步骤。

- 1) 应用 Conv- $n \times n$ 编码 X 的局部空间信息并通过 Conv- 1×1 调整其通道数量,生成 $X_L \in \mathbf{R}^{H \times W \times d}$ 。
- 2) 首先,将 X_L 拆分为 N 个不重叠的 Patches,得到 $X_U \in \mathbf{R}^{P \times N \times d}$ 。其中, $P = h \times w$ 为 Patch 的大小, h 和 w 为 Patch 的高和宽, $N = H \times W / P$ 为 Patches 的数量。其次,如式(3)所示,通过 Transformers 分别编码 $X_U(p) \in \mathbf{R}^{1 \times N \times d}$,

$p \in \{1, \dots, P\}$ 中 Patch 间的关系,得到 $X_C \in \mathbf{R}^{P \times N \times d}$ 。最后,将 X_C 折叠为 $X_F \in \mathbf{R}^{H \times W \times d}$ 。

$$X_C(p) = \text{Transformer}(X_U(p)), 1 \leq p \leq P \quad (3)$$

式中: $X_U(p)$ 为 Unfold 操作的输出结果; $X_C(p)$ 为 Transformer 的输出结果。

3) 首先通过 Conv- 1×1 将 X_F 的通道数量调整为 C , 然后通过连接操作将其与 X 组合,得到 $X_C \in \mathbf{R}^{H \times W \times 2C}$ 。最后,应用 Conv- $n \times n$ 对 X_C 进行特征融合,得到输出特征图 $Y \in \mathbf{R}^{H \times W \times C}$ 。

上述流程中,输入特征图 X 的局部信息首先通过 Conv- $n \times n$ 被编码,然后其全局信息通过 Unfold-Transformer-Fold(其保留了卷积属性并能够进行全局处理)被编码。最后,编码得到的信息 X_F 在融合操作中与原始输入信息 X 合并,并通过 Conv- $n \times n$ 与 X 进行深度融合。通过这种方式,MobileViT 块同时具备了 CNN 和 ViT 的属性,这使得其能够利用更少的参数实现对输入特征图中局部和全局信息的有效建模。

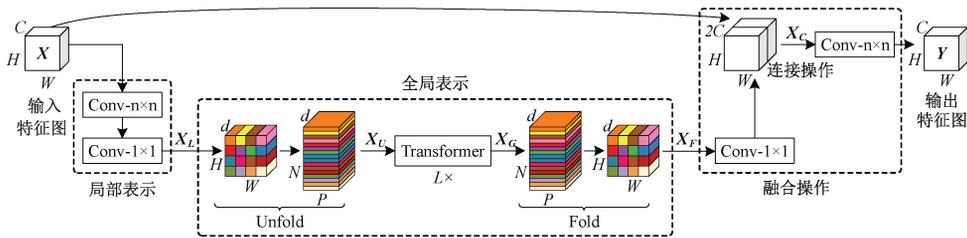


图 5 MobileViT 块的结构

Fig. 5 The structure diagram of MobileViT block

2.2 SAF 识别模型的设计与训练

基于 MobileViT 的原理,在 Pytorch 中搭建了轻量级

SAF 识别模型,并将其简记为 AFNet。AFNet 的整体结构与详细参数分别如图 6 和表 3 所示。

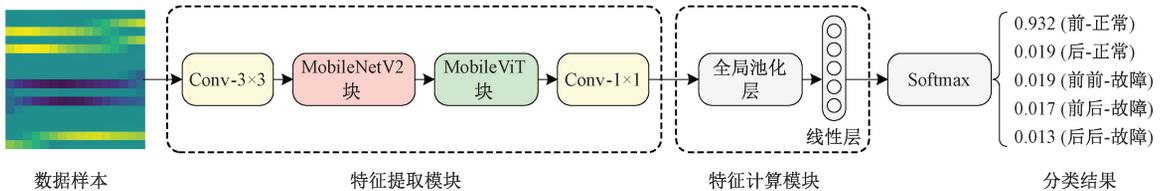


图 6 AFNet 的整体结构

Fig. 6 The overall structure of AFNet

AFNet 由特征提取模块和特征计算模块组成,使用 Swish 激活函数。特征提取模块包含 1 个 Conv- 3×3 、1 个 MobileNetV2 块、1 个 MobileViT 块和 1 个 Conv- 1×1 ,负责从数据样本中充分挖掘局部与全局特征。特征计算模块首先通过全局池化层对空间特征进行全局聚合,随后利用具有 5 个神经元节点的线性层实现特征的非线性映射与融合,并最终输出分类预测结果。线性层的 5 个神经元依次对应“前-正常”、“后-正常”、“前前-故障”、“前后-

故障”和“后后-故障”5 种运行状态,其含义见 1.1 节。如式(4)所示,当 AFNet 推理样本时,5 个神经元的输出值将被输入 Softmax 激活函数以得到上述 5 种状态的概率值。拥有最大概率值的状态即为该样本的分类结果。

$$\text{Softmax}(x_i) = \frac{\exp(x_i)}{\sum_{j=0}^4 \exp(x_j)} \quad i = 0, 1, 2, 3, 4 \quad (4)$$

式中: x_i 和 x_j 分别为第 i 和 j 个神经元的输出值。

表 3 AFNet 的详细参数

运算模块	输出特征尺寸	步长	参数
输入	16×16×1	-	-
Conv-3×3	16×16×16	1	-
MobileNetV2 块	16×16×16	1	-
			$h=w=4, n=3$
MobileViT 块	8×8×48	2	$d=72, P=16,$ $N=4, L=1$
Conv-1×1	8×8×192	1	-
全局池化层	1×192	-	-
线性层	1×5	-	-

AFNet 的训练方法如下。随机打乱 1.2 节的 Dataset1, 并将其按 80% 和 20% 的比例分为训练集和测试集。迭代次数和 Batch size 分别设为 40 和 16。使用 AdamW 算法优化模型参数的更新过程, 学习率设为 0.000 2。采用交叉熵损失函数计算样本的真实标签与 AFNet 的预测值间的损失。

AFNet 的准确率及损失函数曲线如图 7 所示, 经过 29 次训练迭代后, AFNet 表现出优异的分类性能, 其在训练集、测试集上的准确率均持续维持在 99% 以上。同时, AFNet 的损失函数值在训练过程中也已收敛至稳定状态。这表明 AFNet 在 Dataset1 上的训练效果良好, 能够被用于 TMFCL 线路的 SAF 在线检测。

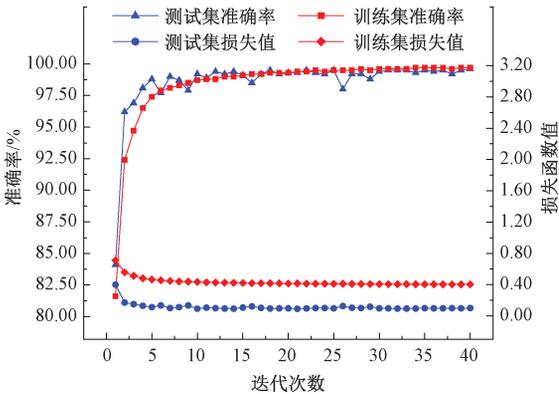


图 7 AFNet 的准确率及损失函数曲线

Fig. 7 The accuracy rate and loss function curve of AFNet

3 全线路 SAF 检测装置及其性能测试

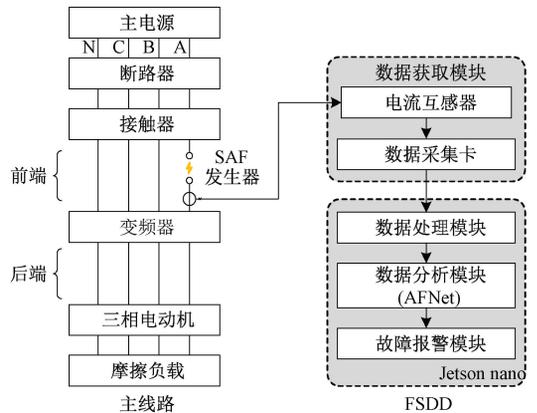
3.1 全线路 SAF 检测装置

1) 整体结构

利用英伟达 TensorRT 将 2.2 节训练好的 AFNet 部署到嵌入式设备 Jetson nano 中, 研制了全线路 SAF 检测装置。该装置简称为 FSDD, 其结构示意与实物照片如图 8 所示。需要说明的是, 在当前研究阶段, 选用 Jetson

nano 作为测试平台, 主要是基于其在算法验证阶段的实用性与便利性。如图 8(a) 所示, FSDD 针对图 1 中主线路进行实时监测, 并采用模块化架构设计; 数据获取模块由 1 个 CT 与数据采集卡构成, 负责电流信号的实时采集; 后续数据处理环节集成于 Jetson nano 中, 数据处理模块将原始电流数据进行归一化预处理, 并将其转换为二维矩阵; 数据分析模块基于 AFNet 实现主线路运行状态的智能诊断; 故障报警模块则根据诊断结果触发相应预警信号。

由于训练 AFNet 所使用的数据集 Dataset1 来自变频器前端和后端的电流数据, 因此 FSDD 在主线路中的安装方式有两种。如图 8(a) 所示, 安装方式 1 指的是 FSDD 的电流互感器安装在变频器前端, 采集变频器前端的电流信号。安装方式 2 指的是电流互感器安装在变频器后端, 采集变频器后端的电流信号。实际使用过程中可以根据需要灵活选择 FSDD 的安装方式, 而不需要对 AFNet 进行重新训练或微调等操作。



(a) FSDD 的结构

(a) Structural diagram of FSDD



(b) FSDD 的性能测试平台

(b) The performance testing platform of FSDD

图 8 FSDD 的相关图片

Fig. 8 Relevant pictures of FSDD

2) 工作流程

如图 9 所示, 当主线路和 FSDD 启动以后, 数据获取

模块对任意一相电流进行实时采集。随后,数据处理模块对原始电流数据执行归一化预处理,并将其构造为二维矩阵。该矩阵随后被输入数据分析模块,即 AFNet,以判定线路运行状态。最后,故障报警模块根据分类结果执行相应操作,若为故障状态,则触发 Jetson nano 的引脚输出高电平报警信号;若为正常状态,则维持低电平。FSDD 采用循环检测机制,完成每次状态判定后将自动启动新一轮数据采集流程,从而实现主电路运行状态的持续监测与实时故障诊断。

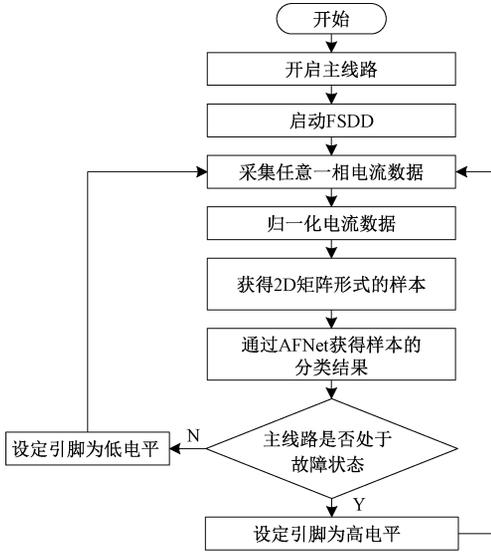


图 9 FSDD 的工作流程

Fig. 9 The workflow of FSDD

3.2 FSDD 的性能评估

为了尽量减少 SAF 可能引发的电气火灾所带来的损失,电弧故障探测器需要具备高准确率、低误报率、低漏报率和快速响应速度。因此,本研究在 TMFCL 线路的不同运行工况下进行了系统测试,重点考察了 FSDD 在故障识别准确性和响应实时性两个关键指标上的表现,同时将其与市场上的电弧故障探测产品进行了性能对比。

1) 测试条件

如表 4 所示,测试方案总共分为 5 组,每组包含 4 个测试条件,分别为主线路负载电流被设置为 15、17、19 和 15~19 A 波动变化时进行。 $T_1 \sim T_4$ 、 $T_9 \sim T_{12}$ 和 $T_{13} \sim T_{16}$ 条件下 FSDD 采用安装方式 1, $T_5 \sim T_8$ 和 $T_{17} \sim T_{20}$ 条件下 FSDD 采用安装方式 2。具体来说, $T_1 \sim T_4$ 条件下,电流互感器位于 A 相线路的变频器前端,SAF 发生器不接入主线路。 $T_5 \sim T_8$ 条件下,电流互感器位于 A 相线路的变频器后端,发生器不接入主线路。 $T_9 \sim T_{12}$ 条件下,电流互感器和发生器均位于 A 相线路的变频器前端。 $T_{13} \sim T_{16}$ 条件下,电流互感器和发生器分别位于 A 相线路的变

频器前端和后端。 $T_{17} \sim T_{20}$ 条件下,电流互感器和发生器均位于 A 相线路的变频器后端。按照 1.1 节的相关描述, $T_1 \sim T_4$ 、 $T_5 \sim T_8$ 、 $T_9 \sim T_{12}$ 、 $T_{13} \sim T_{16}$ 和 $T_{17} \sim T_{20}$ 条件下主线路的运行状态分别为“前-正常”、“后-正常”、“前前-故障”、“前后-故障”和“后后-故障”。

表 4 中所有测试条件下 FSDD 的信号采样频率都设置为 10 kHz,数据样本的长度都设置为 256。

表 4 测试方案

Table 4 Test scheme

测试条件	负载电流/A	运行状态	位置	
			CT	发生器
$T_1 \sim T_4$	15、17、19、15~19	前-正常	前端	-
$T_5 \sim T_8$	15、17、19、15~19	后-正常	后端	-
$T_9 \sim T_{12}$	15、17、19、15~19	前前-故障	前端	前端
$T_{13} \sim T_{16}$	15、17、19、15~19	前后-故障	前端	后端
$T_{17} \sim T_{20}$	15、17、19、15~19	后后-故障	后端	后端

2) 识别性能与实时性能测试

在 T_1 、 T_5 、 T_9 、 T_{13} 和 T_{17} 条件下,分别对数据处理、数据分析模块的执行时间进行 1 000 次重复测量,并据此计算其平均运行时间,结果如表 5 所示。

表 5 FSDD 的实时性能测试结果

Table 5 The real-time performance test results of FSDD

测试条件	平均运行时间/ms		
	数据处理	数据分析 (AFNet)	合计
T_1	0.14	0.732	0.872
T_5	0.14	0.734	0.874
T_9	0.14	0.732	0.872
T_{13}	0.14	0.732	0.872
T_{17}	0.14	0.731	0.871

分别在 $T_1 \sim T_{20}$ 条件下各记录了 1 000 次 FSDD 的数据分析模块(即 AFNet)的分类结果,并据此计算 FSDD 在各测试条件下的准确率,结果如表 6 所示。

表 6 FSDD 的识别性能测试结果

Table 6 The identification performance test results of FSDD

测试条件	运行状态	准确率/%
$T_1 \sim T_4$	前-正常	98.00、99.00、99.80、99.40
$T_5 \sim T_8$	后-正常	100.00、100.00、100.00、100.00
$T_9 \sim T_{12}$	前前-故障	99.80、98.40、97.80、99.20
$T_{13} \sim T_{16}$	前后-故障	99.40、99.40、98.40、99.80
$T_{17} \sim T_{20}$	后后-故障	97.20、98.40、97.60、97.80

由表 5 可知,不同测试条件下,数据处理模块的平均运行时间均为 0.14 ms,数据分析模块的平均运行时间在 0.731~0.734 ms。因此,FSDD 完成一次电流数据处理与分析的平均总运行时间在 0.871~0.874 ms。

由表 6 可知, $T_1 \sim T_4$ 条件的准确率表明当 CT 位于

TMFCL 线路的变频器前端时,FSDD 的误报率最高为 2.00%。 $T_5 \sim T_8$ 条件的准确率表明当 CT 位于 TMFCL 线路的变频器后端时,FSDD 的误报率为 0%。 $T_9 \sim T_{12}$ 条件的准确率表明当 CT 和 SAF 发生器均位于 TMFCL 线路的变频器前端时,FSDD 的漏报率最高为 2.20%。 $T_{13} \sim T_{16}$ 条件的准确率表明当 CT 位于 TMFCL 线路的变频器前端而 SAF 发生器位于变频器后端时,FSDD 的漏报率最高为 1.60%。 $T_{17} \sim T_{20}$ 条件的准确率表明当 CT 和 SAF 发生器均位于 TMFCL 线路的变频器后端时,FSDD 的漏报率最高为 2.80%。

上述结论表明无论采用安装方式 1 还是 2,FSDD 在 TMFCL 线路的多种运行工况下都具备较高的准确率、较低的误报率和漏报率以及极快的运行速度。当采用安装方式 1 时,FSDD 能够通过采集变频器前端的电流信号实

时检测出变频器前端、后端发生的 SAF;当采用安装方式 2 时,FSDD 能够通过采集变频器后端的电流信号实时检测出变频器后端发生的 SAF。

3) 与电弧故障探测器产品对比

在主线路运行状态处于“前前-故障”、“前后-故障”和“后后-故障”时(即在 T_9 、 T_{13} 和 T_{17} 3 种典型工况下),选取了两款商用三相电弧故障探测器 AFDD-I 和 AFDD-II 作为对象,开展了性能对比测试。

以 AFDD-I 为例,详细的对比方案如下。如图 8(b)所示,将 AFDD-I 接入 TMFCL 线路,并分别在 T_9 、 T_{13} 和 T_{17} 条件下各重复产生 25 次 SAF 事件。利用示波器同步记录 AFDD-I 和 FSDD 的报警次数与响应时间,并计算其平均报警时间。与 AFDD-II 的对比测试采样相同方案,对比结果如表 7 所示。

表 7 FSDD 与商用电弧故障探测器的对比结果

Table 7 The comparison results between FSDD and commercial arc fault detectors

测试条件	发出报警次数			平均报警时间 (ms)		
	FSDD	AFDD-I	AFDD-II	FSDD	AFDD-I	AFDD-II
T_9	25	25	25	66.80	993.77	929.47
T_{13}	25	0	0	58.37	-	-
T_{17}	25	0	0	63.08	-	-

由表 7 可知,对于 T_9 条件下的 25 次 SAF 事件,FSDD 与商用探测器均实现了完全检出。这表明,FSDD 和商用探测器一样,具备良好的 SAF 检测效果。此外,FSDD 的平均报警时间(不超过 66.80 ms)远低于商用探测器的,这表明其具备更优异的实时性能。对于 T_{13} 条件下的 25 次 SAF 事件,FSDD 实现了完全检出,而商用探测器的报警次数为 0。这表明,FSDD 能够仅通过采集变频器前端的电流信号,实现对变频器前端和后端发生的 SAF 的同时检测。因此,FSDD 在检测范围方面更具优势。对于 T_{17} 条件下的 25 次 SAF 事件,FSDD 实现了完全检出。这表明,FSDD 能够通过采集变频器后端的电流信号,实现对变频器后端 SAF 的有效检测。因此,FSDD 具备更灵活的现场安装方式。

根据 IEC62606 标准,在 400 V 额定电压下,当负载电流为 32、16 和 10 A 时,电弧故障探测设备的断开时间分别不应超过 0.12、0.15 和 0.25 s^[24]。根据 FSDD 报警时间的统计结果,其在 T_9 、 T_{13} 和 T_{17} 条件下的最长报警时间不超过 95.60 ms。因此,FSDD 能够满足 IEC62606 标准的要求。

T_9 、 T_{13} 和 T_{17} 条件下 FSDD 和 AFDD 产品的报警示例如图 10 所示。图 10 中 4 条曲线依次为由电压互感器采集的电弧电压信号(红色)、由 FSDD 的 CT 采集的电流信号(蓝色)、FSDD 的报警信号(绿色)、AFDD 产品的报警信号(浅紫色)。需要指出,FSDD 是通过将报警引脚置为高电平的方式发出报警信号,而 AFDD 产品是通过

将报警引脚置为低电平的方式发出报警信号。图 10 中各子图的右上角给出了 SAF 事件发生与 FSDD 或 AFDD 产品发出报警信号之间的时间间隔。

4) 在其他相故障与复杂谐波条件下的性能测试

为进一步验证 FSDD 的性能可靠性与泛化能力,在表 4 中的 T_9 、 T_{13} 和 T_{17} 条件下开展测试。分别在 T_9 、 T_{13} 和 T_{17} 条件下,将 SAF 发生器接入 B 相线路以产生 SAF,并统计 FSDD(采集 A 相电流信号)的 1 000 次分类结果。结果表明,FSDD 在上述 3 种情况下的 SAF 识别准确率分别为 96.70%、94.80% 和 93.30%。 T_9 、 T_{13} 和 T_{17} 条件下 B 相线路发生 SAF 时的 A 相线路电流数据样本如图 11 所示。

利用 Chroma 6590 型可编程交流电源,产生两种谐波电源波形如图 12 所示。然后,依次采用这两种谐波电源替换图 8 中的主电源,并分别在 T_9 、 T_{13} 和 T_{17} 条件下统计 1 000 次 FSDD 的分类结果。结果表明,在谐波电源波形 A 下,FSDD 的准确率分别为 85.40%、81.60% 和 80.90%;在谐波电源波形 B 下,FSDD 的准确率分别为 89.20%、82.80% 和 82.30%。

综合分析表明,FSDD 在其他相故障及复杂谐波条件下仍具备一定的鲁棒性。但需要指出的是,其在谐波干扰下的泛化性能下降较为显著,这反映出 FSDD 对复杂工况的适应性仍有提升空间。因此,如何进一步提升 FSDD 在未知相故障条件与非理想供电条件下的泛化能力,将作为后续研究的重点方向。

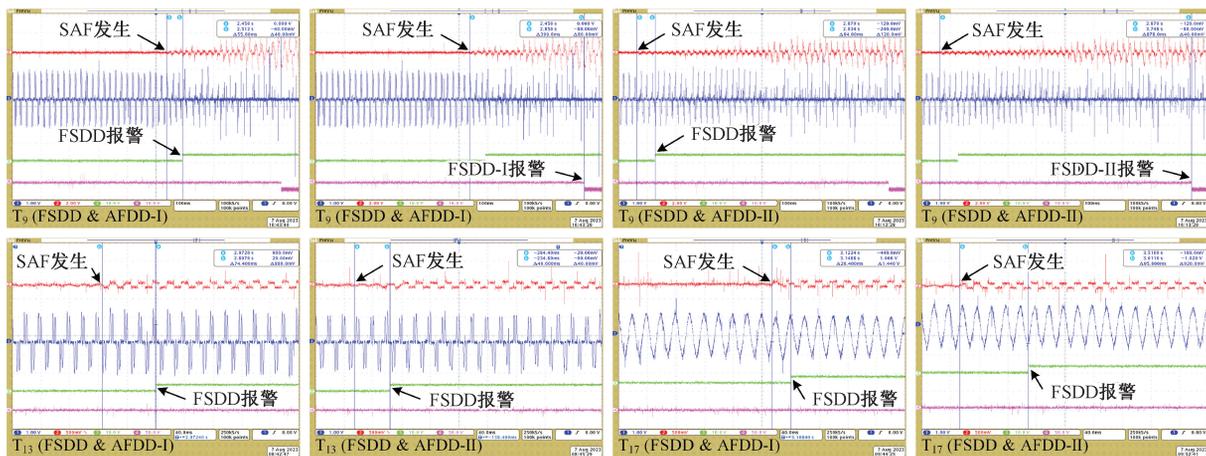


图 10 FSDD、AFDD- I 和 AFDD- II 的报警示例
Fig. 10 Alarm examples of FSDD, AFDD-I and AFDD-II

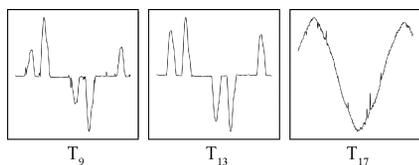


图 11 电流数据样本示例
Fig. 11 Harmonic power supply waveform

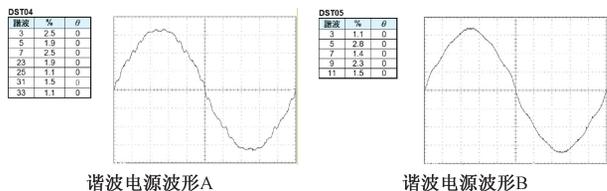


图 12 谐波电源波形示意图
Fig. 12 Diagram of harmonic power supply waveform

3.3 与现有 SAF 检测方法对比

从模型大小、运行时间以及识别准确率 3 个方面,将 FSDD 所使用的 AFNet 与基于 SVM 的检测方法^[12]、基于 CNN 的检测方法^[16,18]进行对比,结果如表 8 所示。表 8 中,深度学习模型的运行时间是通过 TensorRT 加速后在 Jetson nano 中测得的,准确率评估使用的数据集是 1.2 节的 Dataset2。

表 8 AFNet 和其他检测方法的对比结果
Table 8 The comparison results between AFNet and other detection methods

方法	空间/MB	时间/ms	准确率/%
PSO-SVM ^[12]	6.93	26.97	75.70
HCCNN ^[16]	0.11	0.12	96.54
ArcNet ^[18]	0.85	0.55	99.12
AFNet	2.37	0.73	99.28

由表 8 可知, PSO-SVM 和 HCCNN 的识别准确率较低,尤其是 PSO-SVM,其难以满足 SAF 检测需求。虽然 ArcNet 的运行速度稍快一些,但其准确率低于 AFNet。因此,本文提出的 AFNet 整体效果更好,更适合部署到嵌入式设备中来实时检测 SAF。

4 结 论

本文提出了一种用于工业电动机配电线路的 SAF 识别模型和在线检测装置,得出如下结论。

1) 提出了基于 MobileViT 的轻量级 SAF 识别模型。与现有 SAF 识别模型相比,该识别模型能够更好地提取电弧故障特征,具备更高的准确率和更好的泛化性能,运行速度更快,且便于在嵌入式设备中部署运行。

2) 将提出的识别模型与嵌入式平台相结合,研制了 SAF 在线检测装置。该装置具备两种安装方式,能够准确实时地监测 TMFCL 线路的全线路状态。当安装在变频器前端时,该装置能同时检测变频器前端、后端发生的 SAF;当安装在变频器后端时,该装置能准确检测变频器后端发生的 SAF。测试表明,多种运行工况下该装置在线检测变频器前端、后端 SAF 的准确率在 97.20% 以上,完成一次数据处理与分析的平均时间不超过 0.874 ms,报警时间不超过 95.60 ms;在其他相发生 SAF 时,该装置的识别准确率不低于 93.30%;在复杂谐波情况下,该装置的 SAF 识别准确率不低于 80.90%。该装置能够满足 IEC62606 标准要求,并可以为研发工业电弧故障断路器提供参考。

参考文献

[1] JIANG R, ZHENG Y S. Series arc fault detection using regular signals and time-series reconstruction[J]. IEEE

- Transactions on Industrial Electronics, 2023, 70(2): 2026-2036.
- [2] VASILE C, IOANA C. Arc fault detection & localization by electromagnetic-acoustic remote sensing [J]. IOP Conf. Series: Materials Science and Engineering, 2017, 198: 012009.
- [3] 舒奇航, 刘希喆, 王阳. 基于电弧电流和超声波的串联故障电弧的检测 [J]. 电气自动化, 2023, 45(3): 23-25, 29.
- SHU Q H, LIU X ZH, WANG Y. Detection of series arc fault based on arc current and ultrasonic wave [J]. Electrical Automation, 2023, 45(3): 23-25, 29.
- [4] ZHAO L, ZHOU Y H, CHEN K L, et al. High-speed arcing fault detection; Using the light spectrum [J]. IEEE Industry Applications Magazine, 2020, 26(3): 29-36.
- [5] 李奎, 陈照, 张洋子, 等. 基于聚类分析和电磁辐射信号的电弧故障识别 [J]. 电机与控制学报, 2018, 22(5): 94-101.
- LI K, CHEN ZH, ZHANG Y Z, et al. Arc fault detection based on cluster analysis and electromagnetic radiation [J]. Electric Machines and Control, 2018, 22(5): 94-101.
- [6] 高洪鑫, 王坤远, 王智勇, 等. 三相变频器回路串联故障电弧检测方法研究 [J]. 电子测量与仪器学报, 2025, 39(1): 203-215.
- GAO H X, WANG K Y, WANG ZH Y, et al. Research on series arc fault detection method in three-phase frequency converter circuit [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(1): 203-215.
- [7] GONG Q Y, GAO Q, QU X H, et al. Low-voltage AC series arc fault location method based on RBF neural network [J]. Electric Power Systems Research, 2024, 229:110176.
- [8] GAO H X, WANG ZH Y, TANG A X, et al. Research on series arc fault detection and phase selection feature extraction method [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-8.
- [9] GAO H X, WANG ZH Y, HAN C X, et al. Feature extraction method of series arc fault occurred in three-phase motor with inverter circuit [J]. IEEE Transactions on Power Electronics, 2022, 37(9): 11164-11173.
- [10] 宿磊, 沈煜, 杨帆, 等. 融合 CEEMDAN 分解与敏感 IMF 精选的串联电弧故障检测 [J]. 电子测量与仪器学报, 2022, 36(10): 173-180.
- SU L, SHEN Y, YANG F, et al. Series arc fault detection combining CEEMDAN decomposition and sensitive IMF selection [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(10): 173-180.
- [11] WU N Q, PENG M Y, WANG J J, et al. Research on voltage-current type series arc fault detection method based on composite multi-scale entropy [J]. Electric Power Systems Research, 2025, 242:111445.
- [12] QU N, ZUO J K, CHEN J T, et al. Series arc fault detection of indoor power distribution system based on LVQ-NN and PSO-SVM [J]. IEEE Access, 2019, 7: 184020-184028.
- [13] HAN C X, WANG ZH Y, TANG A X, et al. Recognition method of AC series arc fault characteristics under complicated harmonic conditions [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-9.
- [14] 刘艳丽, 王浩, 张帆. 基于轻量卷积和模型优化的电弧故障检测方法 [J]. 仪器仪表学报, 2024, 45(10): 38-49.
- LIU Y L, WANG H, ZHANG F. Arc fault detection method based on lightweight convolution and model optimization [J]. Chinese Journal of Scientific Instrument, 2024, 45(10): 38-49.
- [15] XING L, WEN Y H, XIAO SH, et al. A deep learning approach for series DC arc fault diagnosing and real-time circuit behavior predicting [J]. IEEE Transactions on Electromagnetic Compatibility, 2022, 64(2): 569-579.
- [16] CHU R B, SCHWEITZER P, ZHANG R CH. Series AC arc fault detection method based on high-frequency coupling sensor and convolution neural network [J]. Sensors, 2020, 20(17): 1-19.
- [17] ZHOU G, HUANG L, LI ZH, et al. Intever public database for arcing event detection; Feature analysis, benchmark test, and multi-scale CNN application [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-15.
- [18] WANG Y, HOU L M, PAUL C K, et al. ArcNet: Series AC arc fault detection based on raw current and convolutional neural network [J]. IEEE Transactions on Industrial Informatics, 2022, 18(1): 77-86.
- [19] PAUL C K, ZHAO T F, CHEN CH, et al. Efficient-ArcNet: Series AC arc fault detection using lightweight

convolutional neural network [C]. 2021 IEEE Energy Conversion Congress and Exposition. IEEE, 2021: 1327-1333.

- [20] WANG ZH Y, TIAN SH G, GAO H X, et al. An on-line detection method and device of series arc fault based on lightweight CNN[J]. IEEE Transactions on Industrial Informatics, 2023, 19(10): 9991-10003.
- [21] WANG ZH Y, TIAN SH G, GAO H X, et al. Efficient detection of series arc fault at the back end of frequency converter using KTDM-optimized lightweight model[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-15.
- [22] MEHTA C, RASTEGARI M. MobileViT: Light-weight, general-purpose, and mobile-friendly vision transformer[C]. 2022 International Conference on Learning Representations, 2022: 1-26.
- [23] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2018: 4510-4520.
- [24] International Electrotechnical Commission. General requirements for arc fault detection devices; IEC 62606[S]. Switzerland: International Electrotechnical Commission, 2017.

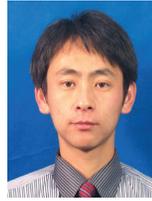
作者简介



田世岗, 2021 年于辽宁工程技术大学获得学士学位, 2024 年于辽宁工程技术大学获得硕士学位, 现为华北电力大学博士研究生, 主要研究方向为电气设备绝缘缺陷智能传感与在线监测。

E-mail: tian_shigang@163.com

Tian Shigang received his B. Sc. degree from Liaoning Technical University in 2021, and M. Sc. degree from Liaoning Technical University in 2024, respectively. Now he is a Ph. D. candidate in North China Electric Power University. His main research interests include intelligent sensing and online monitoring of insulation defects in electrical equipment.



王智勇(通信作者), 2005 年于辽宁工程技术大学获得学士学位, 2008 年于辽宁工程技术大学获得硕士学位, 2017 年于辽宁工程技术大学获得博士学位, 现为辽宁工程技术大学副教授, 主要研究方向为电接触、电弧、智能电器。

E-mail: wangzhiyong@lntu.edu.cn

Wang Zhiyong(Corresponding author) received his B. Sc. degree, M. Sc. degree, and Ph. D. degree from Liaoning Technical University in 2005, 2008, and 2017, respectively. Now he is an associate professor at Liaoning Technical University. His main research interests include electrical contact, electric arc, and intelligent electrical apparatus.