

DOI: 10.19650/j.cnki.cjsi.J2311956

基于振动-电流广域特征与软共享机制的 断路器多故障诊断*

孙曙光¹, 杨飞龙¹, 陈静², 黄光临², 王景芹³

(1. 河北工业大学人工智能与数据科学学院 天津 300401; 2. 温州聚星科技股份有限公司 温州 325062;
3. 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 300130)

摘要: 万能式断路器机械结构复杂,其产生的故障具有多源性,对多源故障进行失效溯源分析是十分必要的。然而,传统的多任务诊断方法不能很好地处理任务间存在的干扰问题,导致故障识别率降低。针对此问题,提出一种基于振动-电流广域特征与软共享机制的多故障诊断方法。首先利用 TKEO 与 DTM,实现分合闸振动信号片段的精准分割,在此基础上分别融合触头动作关联振动信号和附件电流信号的广域特征信息合成彩色图像样本以丰富故障表征信息。然后基于多任务学习的软共享机制构建多故障诊断模型,并通过自适应加权方法来自动的调整两个任务损失函数的权重比例,消除了任务间的相互干扰,进而提高了故障诊断的性能。最后分别从合闸和分闸两个过程进行实例分析,结果表明本文所提方法在两个任务的分类准确率分别达到了 99.78% 和 99.85%,可以有效地实现万能式断路器多故障诊断。

关键词: 万能式断路器;广域信息融合;多任务学习;多故障诊断

中图分类号: TM561 TH165.3 **文献标识码:** A **国家标准学科分类代码:** 470.40

Multi-fault diagnosis of circuit breaker based on vibration-current wide-domain features and soft sharing mechanism

Sun Shuguang¹, Yang Feilong¹, Chen Jing², Huang Guanglin², Wang Jingqin³

(1. School of Artificial Intelligence, Hebei University of Technology, Tianjin 300401, China; 2. Wenzhou Juxing Technology Co., Ltd, Wenzhou 325062, China; 3. State Key Lab Reliability and Intelligence of Electrical Equipment, Hebei University of Technology, Tianjin 300130, China)

Abstract: The mechanical structure of conventional circuit breaker is complex, and the faults caused by it are attributed to multi-source, so it is necessary to analyze the multi-source faults. However, the traditional multitask diagnosis method cannot deal with the interference between tasks well, which leads to the decrease of fault recognition rate. To solve this problem, a multi-fault diagnosis method based on wide-area features of vibration-current and soft sharing mechanism is proposed. Firstly, TKEO and DTM are used to achieve the accurate segmentation of vibration signal segments of the opening and closing process, and on this basis, the wide-area features of the vibration signal associated with the contact action and the attachment current signal are fused to synthesize color image samples to enrich the fault characterization information. Then, a multi-fault parallel diagnosis model is constructed based on the soft sharing mechanism of multitask learning, and automatically adjusts the weight ratio of the loss function of two tasks is automatically adjusted by adaptive weighting method to eliminate the mutual interference between tasks, thus improving the performance of fault diagnosis. Finally, examples are analyzed based on the two processes of closing and breaking respectively, and the results show that the classification accuracy of proposed method in this paper reaches 99.78% and 99.85% for two tasks respectively, which can effectively realize the multi-fault diagnosis of conventional circuit breakers.

Keywords: conventional circuit breaker; wide-area information fusion; multitask learning; multi-fault diagnosis

0 引言

随着全球环保意识的普及,我国力争到2030年实现碳达峰,到2060年实现碳中和,这一目标促进了智能电网的发展^[1]。在此背景下,对设备状态的高精度在线监测和结构健康监测(structural health monitoring, SHM)提出了要求。万能式断路器作为重要的电气设备,主要用于低压配电网中。当其处于运行状态时可能发生各种故障,这对整个配电网的安全造成巨大威胁,严重时可能导致操作人员伤亡^[2]。此外,断路器作为一个整体其是否能够稳定工作不仅取决于触头系统也在很大程度上与操作附件的运行状态直接相关。故本文面向断路器不同部位进行多故障诊断,这对确保整个低压配电网的可靠运行具有重要的现实意义。

断路器在分合闸过程中,产生的振动与电流信号蕴含着触头系统与操作机构丰富的状态信息,对机械状态的变化具有较高的敏感性^[3-4]。利用振动或电流信号进行断路器机械故障诊断,相关学者已经进行了较为深入的研究。其中深度学习模型,尤其是卷积神经网络(convolutional neural network, CNN),提供了一种端到端的解决方案,同时具有较强的非线性特征学习和故障特征分析能力^[5-6],能够克服传统机器学习依赖于专家知识,难以提取到有效故障特征等缺点^[7],已广泛应用于断路器的故障诊断。上述方法均是利用电流或振动信号进行单一部位故障诊断,而断路器作为一个复杂整体,诱发故障的原因是多样的,需面向不同部件进行联合分析。触头系统和分合闸附件作为万能式断路器的关键部件,如何协同利用振动与电流信号进行多故障分析尚需深入研究。

针对多故障诊断,多任务学习(multitask learning, MTL)作为一种可行的解决方案,是一种旨在共同处理多个任务的机器学习方法,已经在许多领域得到了应用。如Shao等^[8]同时使用振动和电流信号的时频图作为输入,通过深度模型学习故障特征,实现了异步电机的多故障识别。赵晓平等^[9]为了对齿轮箱内齿轮及轴承的故障进行诊断,提出了一种基于多任务硬共享机制的多故障诊断方法。上述研究中基于MTL的多故障诊断方法,已经证明具有一定的泛化能力。但由于断路器触头振动信号与附件电流信号具有较低的相关性,从而导致硬共享机制中共享层存在强干扰,无法产生与单任务学习一样好的诊断结果^[10]。针对MTL任务间的相互干扰问题,MTL的软共享机制作为迁移学习领域的一种新策略被提出来,成为解决此问题的有效方法。该框架的主要思想是使用多个任务在多个数据源上进行并行训练,然后通过跨任务间的特征共享,能够使不同的任务学习它们擅

长的内容^[11]。Wang等^[12]使用软共享机制来搭建能够实现发动机剩余寿命预测和故障识别的CNN模型,并提出了一种新的多任务损失函数来实现多任务之间的交互。因此,软共享机制可能是解决任务间相互干扰的一种潜在解决方案^[13]。

此外,对于万能式断路器而言,分合闸附件为交流短时工作制,附件线圈回路合闸相位存在随机性;振动信号对机械状态的差异非常敏感,故障发生前触头系统机械状态的差异会降低诊断结果的稳定性与鲁棒性,以上问题对利用振动与电流信号进行多故障诊断提出了挑战^[14]。对此相关学者通过选择合适的信号处理方法来揭示信号中的故障特征。其中,基于信号到图像的方法将一维时间序列转换为二维图像,能够全面反映机械故障的状态信息,已经证明具有一定的泛化能力^[15]。而信号堆叠法在时域信号到图像转换中得到了广泛的应用,其直接对时域信号中采样点的幅值进行顺序排列,最终形成灰度图像。能够克服传统时频分析法在母函数族、参数等设置上存在困难等问题。Wen等^[16]将时域信号转换为灰度图,该方法不需要任何预定义参数,尽可能地消除了专家经验。但这些方法仍存在问题。首先,由于诊断对象为轴承所以其均着眼于整体振动信号分析,而断路器振动信号由一系列振动事件相互叠加,这样会降低有效振动事件特征的识别。其次它们均从信号单一分析域入手,所包含的故障信息往往是有限的、不准确的和不完整的,这些问题的解决仍具有挑战性^[17]。

基于上述研究,本文提出了一种基于振动-电流广域特征与软共享机制的断路器多故障诊断方法。针对信号特征提取存在的问题,鉴于断路器复杂机械结构的运动会产生多源信号以及受文献[18-19]中所提方法的启发。本文引入基于Teager-Kaiser能量算子(teager-kaiser energy operator, TKEO)的双门限法(double-threshold method, DTM)来标定触头动作关联振动信号;并在此基础上提出基于广域信息驱动的振动-电流信号到彩色图像处理办法,以最大程度上挖掘信号中所包含的故障表征信息,从而抑制合闸相位随机性及机械状态差异对电流与振动信号特征提取的影响。并基于MTL软共享机制构建多故障诊断模型,其能在消除任务间干扰的同时,对分合闸附件以及触头系统易发故障进行同步识别。此外,考虑到深度神经网络在进行故障分类时,随着网络深度的增加,反向传播很容易导致梯度呈指数下降或增加,产生梯度消失或爆炸问题^[20]。故本文在多任务模型中嵌入ResNeXt模块,其通过分组卷积来挖掘深层次的故障特征信息。同时引入双重注意力网络(dual attention network, DANet)以达到区分重要特征的目的^[21-22]。

1 万能式断路器多故障诊断方法

本文提出了一种新型数据驱动智能诊断模型,其包括两个主要研究部分:广域特征构建和多任务软共享框架下的多故障诊断。该方案的具体流程如图1所示。其具体步骤如下:

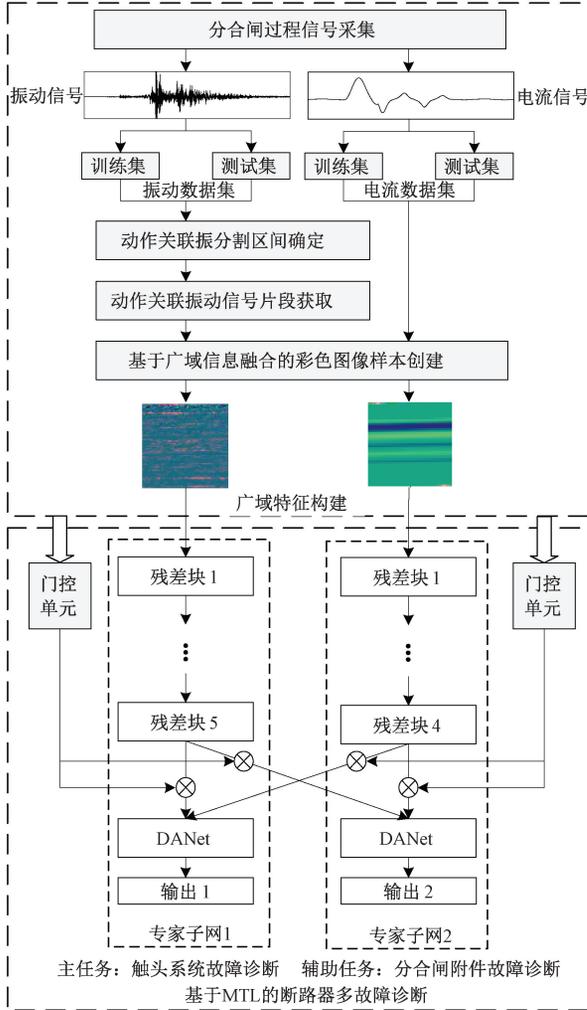


图1 断路器多故障诊断流程

Fig. 1 Diagnosis process for multiple faults in circuit breakers

1) 广域特征构建。首先结合断路器分合闸振动与电流信号进行运动过程分析。然后利用 TKEO 与 DTM 准确分割触头动作关联振动信号片段。然后同时对振动信号片段及电流信号分别进行快速傅里叶变换 (fast fourier transform, FFT)、离散余弦 S 变换 (discrete cosine stockwell transform, DCST) 从而获得信号的频域和时频域信息。最后分别融合振动或电流时域信号本身以及上述变换域内信号灰度图形成三通道彩色图像。

2) 多故障诊断。为了减少任务间的相互干扰,本文

在该部分建立了以 MTL 的软共享机制为主要框架的多故障诊断模型。该模型通过采用门控单元控制不同专家子任务网络的输出权值,并利用同方差不确定性损失函数自动调整各任务损失函数的权值,以提高网络搜索最优解的性能,从而实现触头系统以及分合闸附件处故障的互助学习。其中嵌入的 ResNeXt 通过分组卷积来挖掘深层次的故障特征信息,能够避免网络深度带来的梯度消失现象,同时引入 DANet 以区分重要特征。

1.1 触头动作关联振动信号分割方法

TKEO 对信号中的冲击成分很敏感。应用在断路器振动信号中时,能获得振动事件发生的时间和强度等信息。从而可以利用该方法强化分析对象触头系统产生的振动冲击。触头动作关联振动信号分割的具体过程如下:首先通过预定长度的窗口函数对振动信号进行分段处理,每一段成为一帧,其表达式如下所示:

$$o_i(n) = w(n) * u((i-1) * inc + n) \quad (1)$$

式中: $u(\cdot)$ 是原始振动信号, $w(n)$ 为汉宁窗函数, $o_i(n)$ 表示第 i 帧数据, $n = 1, 2, \dots, L$, $i = 1, 2, \dots, f_n$, L 为帧长, inc 为帧移步长, f_n 为分段后总帧数。

对于第 i 帧数据, TKEO 计算如下:

$$\psi(o_i(n)) = [o_i(n)]^2 - o_i(n-1)o_i(n+1) \quad (2)$$

由式 (2) 可知, $\psi(o_i(n))$ 的计算主要涉及 $[n-1, n+1]$ 范围内的信息,且每次计算只使用 3 个时刻的数据。故利用 TKEO 与 DTM 分割触头关联振动信号具有较好的时间分辨率和运算速度。

1.2 基于广域信息融合的图像样本生成方法

通过融合信号的广域特征信息能够在一定程度上解决噪声干扰所带来的信号差异问题。当分合闸附件与触头系统发生故障时,附件线圈回路合闸相位随机性以及触头系统机械状态的差异相对于合闸相位固定以及同一机械状态下的电流、振动检测信号来说相当于是一种扰动。因此,本文针对触头关联振动信号和分合闸附件电流信号,分别在 3 个分析域内捕获特征信息并生成 RGB 图像,如图 2 所示。图 2 中图像样本的具体生成过程如下:首先利用触头动作关联振动信号和电流信号,以及对两者分别进行 FFT 频域变换和具有良好的时频区分特性的 DCST 变换以提取一维多域信息。其中 DCST 定义为振动信号片段和电流信号经过离散余弦变换 (discrete cosine transform, DCT) 后所得基向量的组合:

$$DCST = \left(\sum_{i=1}^K DCT_{n_i}^{-1} \right) DCT \quad (3)$$

式中: $DCT_{n_i}^{-1}$ 为离散余弦逆变换, n_i 为频率分区, K 表示基向量个数。

其次将振动与电流信号在以上 3 个分析域中长度为 m^2 和 n^2 的所有类型信息分别转换为 $m \times m \times 1$ 和 $n \times n \times 1$ 的灰度图。振动与电流信号在不同分析域所得灰度图像

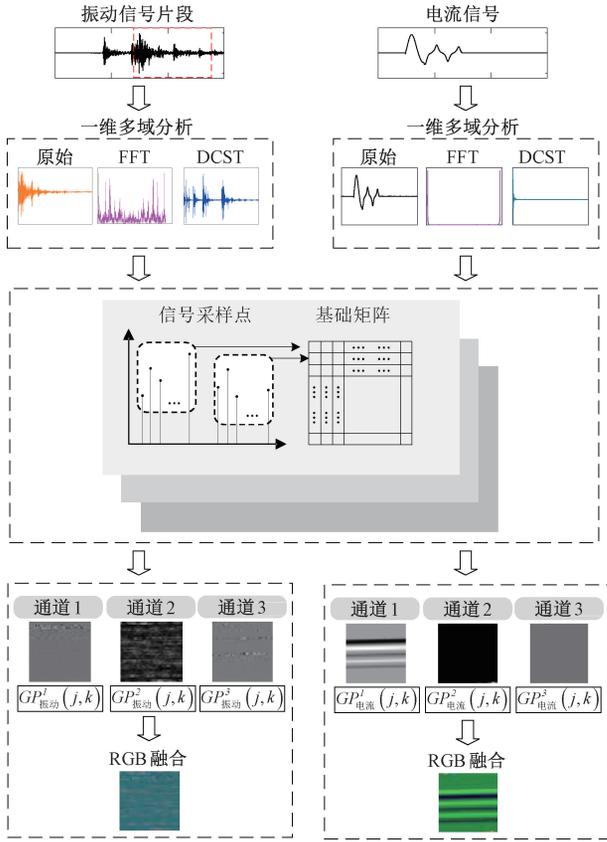


图 2 图像样本生成方法

Fig. 2 Generation method of image sample

素矩阵 $GP^i_{振动}(j,k)$ 和 $GP^i_{电流}(j,k)$ 由下表示:

$$GP^i_{振动}(j,k) = \frac{h^i((j-1) \times m + k) - \text{Min}(h^i)}{\text{Max}(h^i) - \text{Min}(h^i)} \times 255 \quad (4)$$

$$GP^i_{电流}(s,t) = \frac{h^i((s-1) \times n + t) - \text{Min}(h^i)}{\text{Max}(h^i) - \text{Min}(h^i)} \times 255 \quad (5)$$

式中: $j=1, \dots, m; k=1, \dots, m; s=1, \dots, n; t=1, \dots, n; i=1, 2, 3; h^i(\cdot)$ 表示信号在不同分析域中的强度值。

最后, 将不同分析域下的二维灰度图在通道维度上合并生成最终的 RGB 图像样本, 尺寸大小分别为 $m \times m \times 3$ 和 $n \times n \times 3$ 。振动与电流信号的 RGB 像素矩阵 $RGBM_{振动}(j,k, P_{rgb})$ 和 $RGBM_{电流}(s,t, P_{rgb})$ 计算如下:

$$RGBM_{振动}(j,k, P_{rgb}) = (GP^i_{振动}(j,k), P_{rgb}) \quad (6)$$

$$RGBM_{电流}(s,t, P_{rgb}) = (GP^i_{电流}(s,t), P_{rgb}) \quad (7)$$

式中: $P_{rgb} i=1, 2, 3$ 表示 RGB 图像的第 i 个通道。

1.3 多故障诊断模型

1) 多任务学习

MTL 是在传统单任务学习基础之上提出的一种机器学习概念, 其包括软和硬两种共享机制。目前大多

数应用于断路器故障诊断方法都基于硬共享机制。其所有输入数据在被馈送到特定任务层之前被馈送到共享层, 意味着网络需要学习到所有任务都具有的相同特性, 也就是说, 硬共享机制适合相互关联、干扰小的子任务。而对于万能式断路器触头系统以及分合闸附件的机械故障来说, 二者本身不具有强相关性。故本文选择软共享机制采用门控单元控制不同专家子网络的输出权值, 从而实现独立专家网络之间的选择性共享, 从而消除任务间的干扰。软共享机制的数学表达式为:

$$y_k = h^k(f^k(x)) \quad (8)$$

$$f^k(x) = \sum_{i=1}^N g^k(x) f_i(x) \quad (9)$$

$$g^k(x) = \text{Softmax}(\mathbf{W}_{gk}x) \quad (10)$$

式中: k 为任务编号; N 为专家子网络的个数; x 为模型的输入特征; y_k 为第 k 个任务的输出; $f^k(x)$ 为第 k 个任务专家子网络的输出; $h^k(\cdot)$ 为特定诊断任务; $f_i(\cdot)$ 代表第 i 个专家子网络; $g^k(x)$ 为门控单元的输出; \mathbf{W}_{gk} 为可训练参数矩阵。

2) 诊断模型结构

诊断模型采用并行网络代替传统的串行网络, 并利用门控单元控制不同专家网络的输出权值, 从而实现并行独立网络之间的选择性共享, 能够在相关性较低的任务中表现出更好的性能, 本文的多故障诊断模型网络结构如图 3 所示。图 3 的模型结构由触头系统诊断任务网络和分合闸附件诊断任务网络组成。触头诊断任务以振动信号经过广域信息融合后的图像样本作为输入, 历经卷积层 (convolutional layer, Conv) 和最大池化 (max-pooling, Maxpool) 操作挖掘浅层故障特征, 又通过四级残差单元、融入 DANet 的残差单元、全连接层和 Softmax 分类层后作为该任务的输出。附件诊断任务网络以电流信号经过广域信息融合后的图像样本作为输入, 除减少一级残差单元外, 其余设置与触头诊断任务一致。最后通过一个特殊的损失函数使两个任务互相提供故障特征信息, 从而更好实现多部位故障诊断。

模型中每个子任务堆叠的多级残差块 ResNeXt 可以自适应挖掘更深层次的故障特征。其本质是分组卷积, 即引入变量基数将瓶颈结构拆分为多个并行分支。其在解决深层网络反向传播带来的梯度消失和梯度弥散问题的同时, 无需设计复杂的 Inception 结构。

此外, 为了能够聚焦有效信息的表达, 实现特征重要性的区分, 从而提高诊断的性能与效率。引入 DANet 模块用于优化特征选择。DANet 的网络结构如图 4 所示, 其中 $\mathbf{y}_{b1} \in \mathbf{R}^{C \times H \times W}$ 为前一级残差输出特征, $\mathbf{E} \in \mathbf{R}^{C \times H \times W}$ 为 DANet 模块的最终输出。

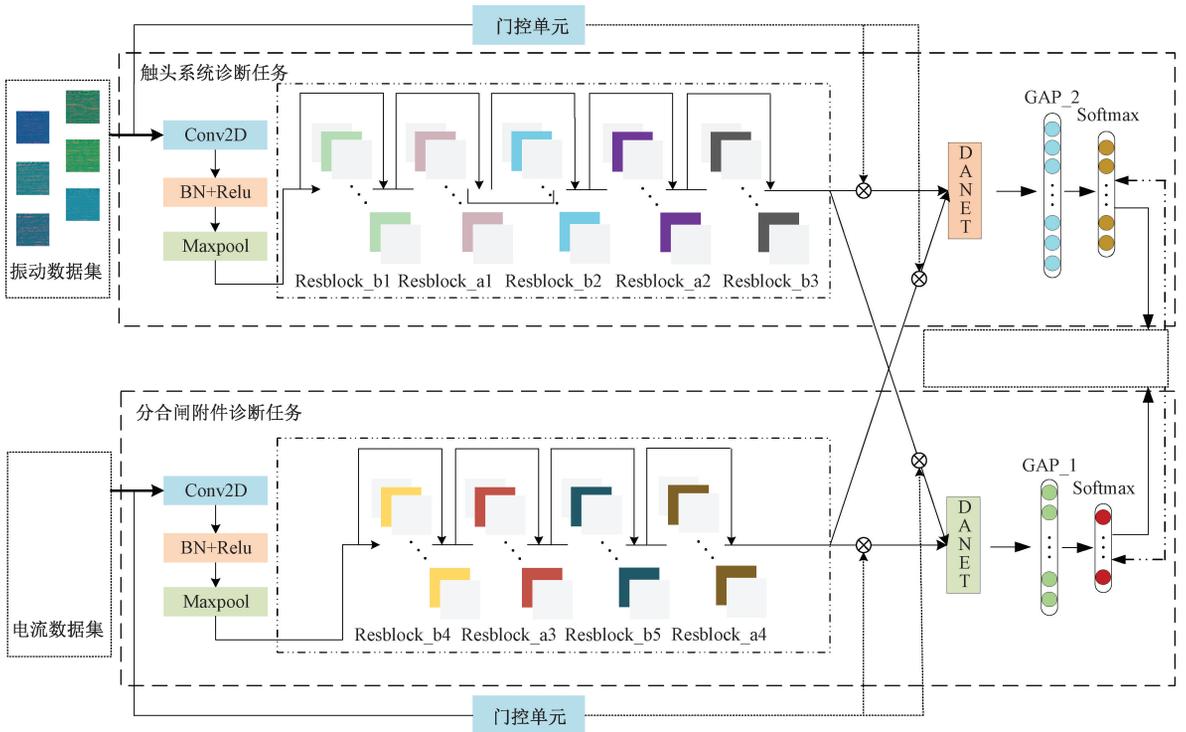


图3 多故障诊断模型网络结构

Fig.3 Network structure of multiple fault diagnosis model

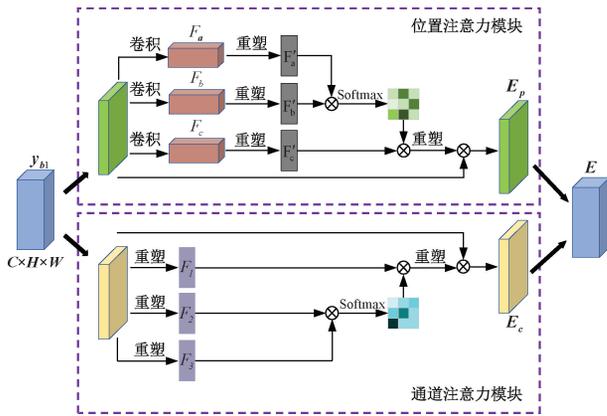


图4 DANet网络结构

Fig.4 DANet network structure

3) 多任务损失函数与模型训练

本文所提多故障诊断模型的具体结构参数如表1所示。模型均建立在TensorFlow2.0 GPU框架下,电脑配置为Intel(R) Core(TM) i5-12500H CPU @ 4.70 GHz + NVIDIA GeForce RTX 3050。

在MTL模型中,不同任务对不同的权重设置非常敏感,若设置不恰当,会导致单个任务主导网络的整体性能。由于传统方法大多通过手动调整任务之间的权重,该方法往往效率低下且困难。因此本文考虑每个任务的同方差不确定性的损失函数作为总函数。

表1 模型结构

Table 1 Model structure

| 任务 | 命名 | 层 | 卷积核 | 卷积核数目 | 步长 |
|-------------|-------------|------------|-----|-------|----|
| 触头系统 | Conv2D | 卷积 | 3×3 | 32 | 1 |
| | Maxpool | 最大值池化 | 2×2 | - | 2 |
| | ResBlock_b1 | ResBlock_b | - | 64 | - |
| | ResBlock_a1 | ResBlock_a | - | 64 | - |
| | ResBlock_b2 | ResBlock_b | - | 128 | - |
| | ResBlock_a2 | ResBlock_a | - | 128 | - |
| | ResBlock_b3 | ResBlock_b | - | 256 | - |
| | GAP_1 | 全局平均池化 | 2×2 | 64 | 1 |
| | 输出1 | Softmax | - | 6 | - |
| | 分合闸附件 | Conv2D | 卷积 | 3×3 | 32 |
| Maxpool | | 最大值池化 | 2×2 | - | 2 |
| ResBlock_b4 | | ResBlock_b | - | 64 | - |
| ResBlock_a3 | | ResBlock_a | - | 64 | - |
| ResBlock_b5 | | ResBlock_b | - | 128 | - |
| ResBlock_a4 | | ResBlock_a | - | 128 | - |
| GAP_2 | | 全局平均池化 | 2×2 | 128 | 1 |
| 输出2 | Softmax | - | 5 | - | |

头系统和分合闸附件的各故障状态及其模拟方式如表 2 所示。考虑到振动信号对动作次数的敏感性,触头系统同一故障在不同动作次数下离散设置,各相不同期是指某一相触头与另两相动作不同步,即一相触头动作异常,而另外两相触头动作正常,每类故障状态下各采集 360 组样本,共采集 2 160 组。由于断路器分合闸动作时线圈回路合闸相位具有随机性,因此分合闸附件处的每种故障分别在 0° 、 30° 、 60° 、 90° 、 120° 、 150° 、 180° 相位下进行故障模拟,每种相位下各采集 20 组样本,共采集 1 260 组。

表 2 多故障模拟方式
Table 2 Multi-fault simulation mode

| 故障部位 | 故障类型 | 模拟方式 |
|-------|---------------------|-----------------------|
| 触头系统 | A 相不同期 | 通过连杆调节某相触头与另外两相触头超程大小 |
| | B 相不同期 | |
| | C 相不同期 | 通过悬臂调节三相触头超程大小 |
| | 虚假合闸 | |
| 分闸不彻底 | 在分闸挡板加垫片调整三相触头开距的大小 | |
| 分合闸附件 | 铁芯卡涩 | 铁芯轴部与线圈间塞入细铁丝 |
| | 机械结构卡涩 | 滑动连杆椭圆空间内塞入小木棒 |
| | 铁芯行程不足 | 动铁芯顶部加入适量的橡胶垫 |
| | 顶杆阻力异常 | 利用弹性绳拴住顶杆推片 |
| | 衔铁行程不足 | 分闸电磁衔铁上粘贴硬纸片 |

考虑到断路器合闸与分闸是两个独立的动作过程,均涉及触头系统与对应的附件,因此面向两个过程分别构建数据集如图 1 所示的诊断流程进行测试。

合闸过程包括正常合闸以及 A 相不同期、B 相不同期、C 相不同期和虚假合闸 4 种故障类型。合闸附件释能电磁铁包含正常工作状态和铁芯卡涩、机械结构卡涩、铁芯行程不足 3 种故障。分别随机选取全部电流与振动信号的 20% 为测试集,称为数据集 1。数据集 1 中的样本信息和相应的故障类别标签如表 3 所示。此外,针对合闸电流信号额外设计了两种数据集以验证所提方法在不同相位下的泛化能力:

1) 数据集 2: 合闸附件在 30° 、 60° 、 90° 、 120° 、 150° 相位下 4 类工作状态各取 20 组样本,总计 400 组样本作为训练集,以 0° 、 180° 相位下共 160 组样本作为测试集。

2) 数据集 3: 合闸附件以 0° 、 30° 、 60° 、 90° 、 120° 、 150° 、 180° 相位下的共 560 组样本作为训练集。在 15° 、 45° 、 75° 、 105° 、 135° 、 165° 相位下,4 种状态各取 5 组样本,总计 120 组样本作为测试集。

分闸过程包括正常分闸及分闸不彻底故障类型。分闸附件分励脱扣器故障有衔铁行程不足和顶杆阻力

表 3 数据集 1

Table 3 Data set 1

| 故障部位 | 工作状态 | 训练样本数 | 测试样本数 | 类别标签 |
|------|--------|-------|-------|------|
| 触头系统 | 正常 | 288 | 72 | 0 |
| | A 相不同期 | 288 | 72 | 1 |
| | B 相不同期 | 288 | 72 | 2 |
| | C 相不同期 | 288 | 72 | 3 |
| | 虚假合闸 | 288 | 72 | 4 |
| 合闸附件 | 正常 | 112 | 28 | 0 |
| | 铁芯卡涩 | 112 | 28 | 1 |
| | 机械结构卡涩 | 112 | 28 | 2 |
| | 铁芯行程不足 | 112 | 28 | 3 |

异常。分别随机选取全部样本的 20% 为测试集,记为数据集 4,如表 4 所示。与合闸电流数据集 2 和 3 类似,也对分闸电流在相同相位设置下额外设计了两种数据集进行测试,记为数据集 5 和 6。

表 4 数据集 4

Table 4 Data set 4

| 故障部位 | 工作状态 | 训练样本数 | 测试样本数 | 类别标签 |
|------|--------|-------|-------|------|
| 触头系统 | 正常 | 288 | 72 | 0 |
| | 分闸不彻底 | 288 | 72 | 1 |
| 分闸附件 | 正常 | 112 | 28 | 0 |
| | 衔铁行程不足 | 112 | 28 | 1 |
| | 顶杆阻力异常 | 112 | 28 | 2 |

2.3 振动-电流信号特点分析

为了更好地突出振动与电流信号在时序上存在的并发性,故对触头系统 4 种故障状态下的合闸振动信号以及不同相位下合闸附件线圈电流信号进行协同分析,同时将振动与电流信号按时间先后在同一图形中进行展示,如图 7 所示。从图中可以看出,由于断路器的工作机制,振动与电流信号在时序上存在并发性,这也恰恰契合了本文所设计的诊断模型架构,且合闸相位的随机性对电流波形产生影响。此外,A 相不同期故障状态时断路器在不同动作次数下的振动信号波形如图 8 所示,可以看出同一故障下波形存在差异,表明振动信号对机械状态的差异敏感。

3 应用实例与测试分析

考虑到逐层特征可视化和 t-SNE 是两种典型的可视化分析工具,因此利用这两类可视化工具分别对分合闸

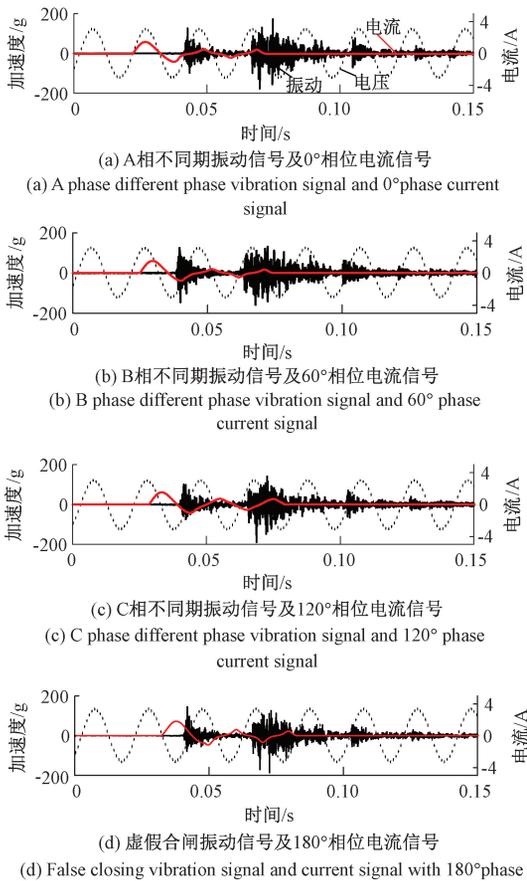


图 7 不同故障状态下合闸振动及电流波形

Fig. 7 Closing vibration and current waveforms under different fault conditions

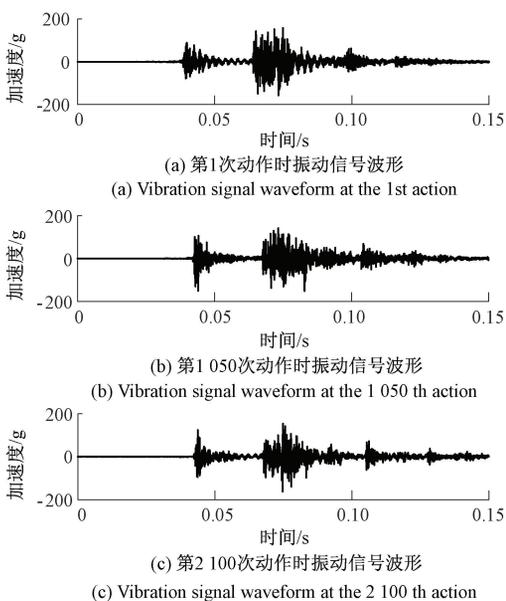


图 8 不同动作次数下的振动信号波形

Fig. 8 Vibration signal waveform under different operation times

过程的诊断结果进行多角度可视化分析,以证明本文所提方法具有极佳泛化能力。

3.1 合闸过程诊断实例

首先利用数据集 1 中的样本对图 1 的多故障诊断模型进行测试。

1) 合闸关联振电信号区间的确定

本节从振动信号所反映的断路器机构动作时刻出发,对合闸过程所产生振动子事件进行分析,并确定触头合闸振动信号区间。断路器合闸过程中所测量的信号波形如图 9 所示。图 9 中各子图从上到下依次为通过直流回路法测得的触头状态电压信号、合闸线圈电流信号和合闸触头振动信号。

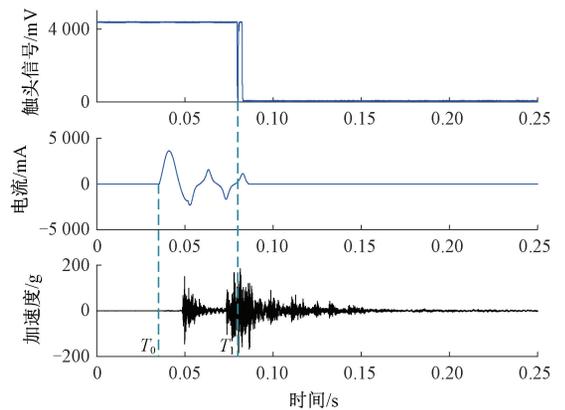


图 9 断路器合闸过程测量信号

Fig. 9 Measurement signal during the closing process of circuit breaker

结合文献[18-19]中的分析,可知在断路器合闸过程中, T_0 是释能电磁铁开始通电的时刻; T_1 是触头状态电压跳变以及动弧触头与静弧触头发生碰撞的时刻,代表着触头合闸动作的开始。本节针对的是释能电磁铁和触头系统在合闸动作过程中的故障,但考虑到操作附件为短时工作制,且电流成分单一,因此选取全电流波形进行后续分析;而振动信号具有非平稳性以及复杂性,对机械状态更为敏感,所以对振动信号要进行分割处理,选择 T_1 时刻作为触头合闸振动信号片段分析的起点,并考虑到振动信号的衰减时长以及后续进行频域、时频域特征提取的需要,在 T_1 之后截取 4 096 个数据采样点作为触头合闸振动信号片段。

2) 触头合闸振动信号提取

设定汉明窗长度为 40, 帧移为 20, 利用 TKEO 和 DTM 对不同故障状态下的触头合闸振动信号起始位置进行标定。本节以虚假合闸为例阐述标定过程,其结果如图 10 所示。图 10(b) 中 T'_1 表示标定后有效子事件的开始时刻。其具体标定过程为: 针对振动信号的 TKEO, 通过测试确定双门限上下阈值的最佳设置 L_2 和

L_1 , 且 $L_2 > L_1$ 。然后搜索大于 L_2 的 TKEO 范围, 即图中 AB 段, 其必然是触头合闸振动信号片段所在区间。再从 A 和 B 向两端搜索, 并根据 L_1 可精确判定 C 为该振动信号片段的初始起点。

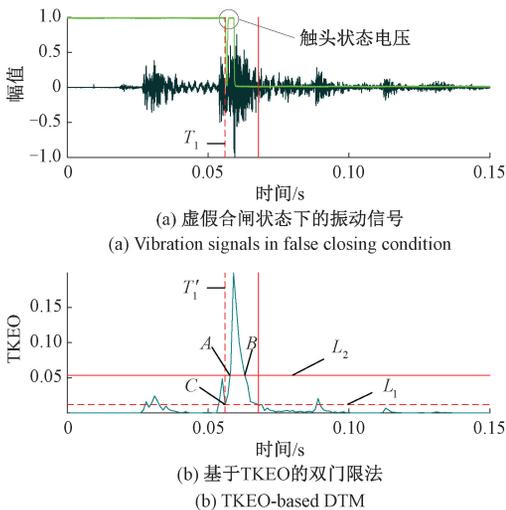


图 10 触头合闸振动信号片段标定

Fig. 10 Contact closing vibration signals segment calibration

3) 合闸过程 RGB 图像样本

根据 1.2 节方法, 不同故障状态下触头合闸振动信号片段和 0° 相位下合闸附件电流信号转换得到的 RGB 图像如表 5 所示, 以上振动与电流信号获得的图像像素大小均为 $128 \times 128 \times 3$ 。从表 5 可以看出, 不同故障状态的图像样本存在一定差异, 有助于所提出方法进行多故障诊断。

表 5 合闸过程的图像转换结果

Table 5 The image conversion result of the closing process

| 故障部位 | 不同故障状态下的 RGB 图像 | | | |
|------|-----------------|--|--|--|
| 触头系统 | | | | |
| 合闸附件 | | | | |

4) 诊断结果和特征可视化分析

本节首先使用断路器合闸振动与电流图像数据集 1 同时作为输入进行多故障诊断。并将最终结果以混淆矩阵的形式进行输出, 如图 11 所示。

由图 11 可以看出, 触头系统和释能电磁铁在合闸过程中的大多数易发故障类型都可以被精确识别。从图 11(a) 的混淆矩阵中可以看出对于触头系统, 1% 的 B 相不同期被错误分类为 A 相不同期, 1% 的 C 相不同

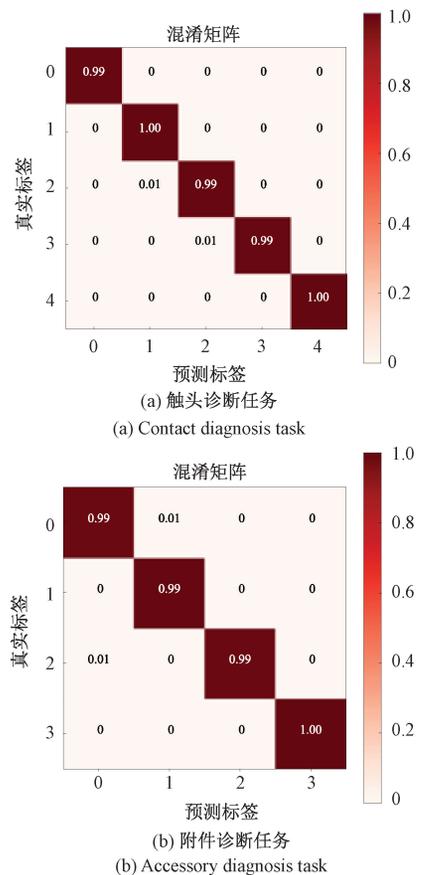
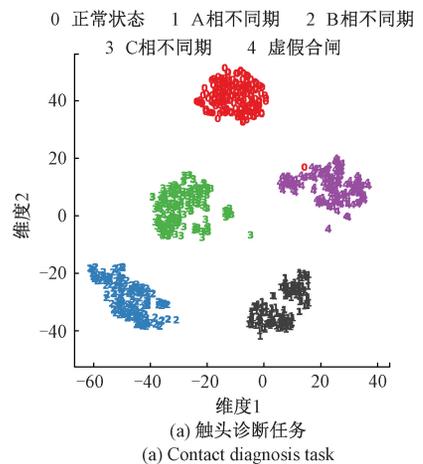


图 11 混淆矩阵

Fig. 11 Confusion matrix

期被错误分类为 B 相不同期。同理从图 11(b) 可以看出, 1% 的正常合闸状态被错误分类为铁芯行程不足。此外, 为了进一步验证模型逐层提取故障特征的能力, 利用 t-SNE 对不同任务的最后一层输出特征进行可视化, 结果如图 12 所示。可以看出, 本文网络结构具有极佳的聚类效果, 表明本文故障诊断模型具有较强的特征提取能力。



(a) 触头诊断任务
(a) Contact diagnosis task

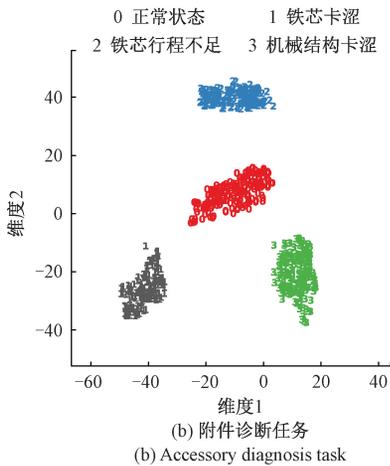


图 12 特征可视化结果

Fig. 12 Feature visualization results

为证明所提方法能有效解决合闸相位随机性对电流信号的影响, 分别利用电流数据集 2 和 3 的样本对图 1 的诊断模型进行测试, 实验结果如表 6 所示。可以看出两种电流数据集在本文模型下的测试结果仍具有较高识别率且所用训练时间较短, 可见提出方法可以很好地适应附件线圈回路合闸相位的随机性。

表 6 合闸过程的泛化实验结果

Table 6 Generalization experiment results of the opening process

| 数据集 | 平均识别率/% | 标准差/% | 训练时间/s |
|-------|---------|-------|--------|
| 数据集 2 | 98.83 | 1.380 | 312 |
| 数据集 3 | 97.52 | 0.737 | 304 |

3.2 分闸过程诊断实例

利用数据集 4 中的样本对图 1 的多故障诊断模型进行测试。

1) 分闸关联振电信号区间的确定

与图 9 类似, 图 13 从上到下依次为分闸过程中所测触头状态电压信号、分闸线圈电流信号和分闸振动信号。结合文献[18-19]中的分析, 可知在断路器分闸过程中, t_0 是分励脱扣器线圈开始通电的时刻; t_1 是触头状态电压发生跳变且动主触头开始运动的时刻, 代表着触头分闸动作的开始。故选择 t_1 时刻作为触头分闸振动片段分析的起点, 同时在其后截取 4 096 个数据采样点作为分闸振动信号片段。

2) 分闸振动信号的提取

设定汉明窗长度为 40, 帧移为 20, 利用基于 TKEO 与 DTM 对不同故障的合闸关联振动信号片段进行起点标定。本节以虚假合闸为例阐述合闸振动信号的标定过程, 其标定结果如图 14 所示。根据 L_1 可精确判定 t'_1 为触头分闸振动信号片段的起点。

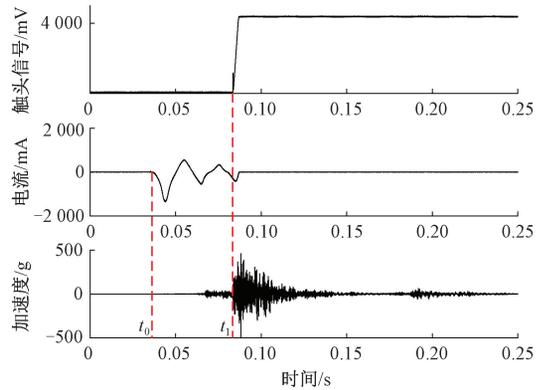
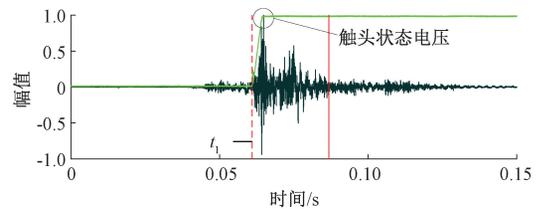


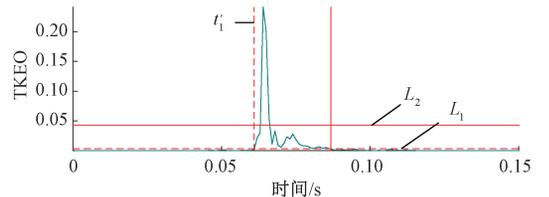
图 13 断路器分闸过程测量信号

Fig. 13 Measurement signal in the opening process of circuit breaker



(a) 分闸不彻底状态下的振动信号

(a) Vibration signals in case of incomplete opening



(b) 基于TKEO的双门限法

(b) TKEO-based DTM

图 14 触头分闸振动信号片段标定

Fig. 14 Contact opening vibration signals segment calibration

3) 分闸过程 RGB 图像样本

同样根据 1.2 节方法, 分闸触头振动信号片段和 0° 相位下分励脱扣器电流信号转换得到的 RGB 图像如表 7 所示, 以上获得的图像像素大小均为 $128 \times 128 \times 3$ 。

表 7 分闸过程图像转换结果

Table 7 The image conversion of the opening process

| 故障部位 | 不同故障状态下的 RGB 图像 |
|------|-----------------|
| 触头系统 | |
| 分闸附件 | |

4) 诊断结果和特征可视化分析

本节使用断路器分闸振动与电流图像数据集同时作为输入利用本文模型进行故障诊断。为避免结果的偶然性,本节进行了10次测试实验,取平均值作为诊断结果。图15分别显示了触头诊断任务和附件诊断任务的受试者工作特征曲线(receiver operating characteristic, ROC)曲线。其反映了真阳性率和假阳性率间的变换趋势。对于多类别分类,ROC曲线下的面积越大意味着模型的诊断性能越佳。

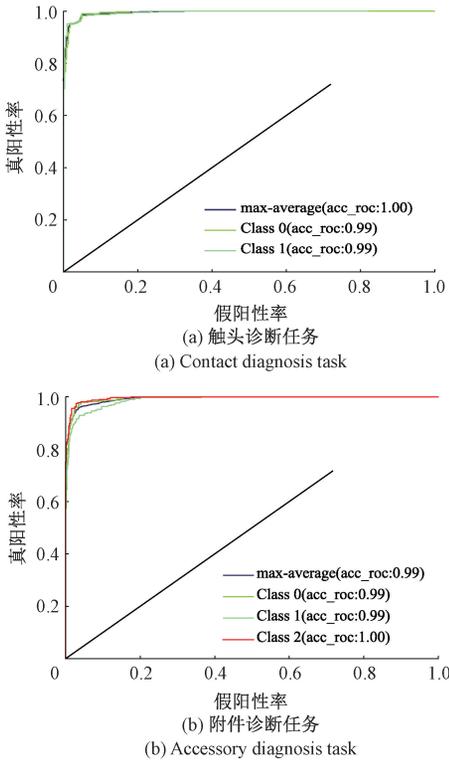


图15 ROC曲线

Fig. 15 ROC curve

由图15可知,该方法下触头诊断任务和附件诊断任务的ROC曲线都非常靠近左上角坐标。且该模型的测试平均AUC值分别达到99.73%和99.84%,这表明该方法可以准确识别触头系统及分励脱扣器处的机械故障。

此外,利用数据集5和6对本文模型进行测试以验证在不同相位下所提方法的泛化能力,测试结果如表8所示。从表8可以看出,本文所提方法此时亦具有较高的识别率且与较短的训练时间。

表8 分闸过程的泛化实验结果

Table 8 Generalization experiment results of the opening process

| 数据集 | 平均识别率/% | 标准差/% | 训练时间/s |
|------|---------|-------|--------|
| 数据集5 | 98.83 | 1.38 | 314 |
| 数据集6 | 97.79 | 1.44 | 338 |

综合分合闸过程之所以能取得如此好的诊断性能,归功于信号处理方式与诊断模型。对于前者,触头动作关联振动信号片段和电流信号的广域融合信息能在最大程度挖掘信号中所包含的故障表征信息,从而克服合闸相位随机性以及振动信号对机械状态差异敏感性所带来的影响。针对后者,以触头诊断网络为例,逐一对特征提取层进行可视化,在分闸不彻底状态下的可视化结果如图16所示。可以发现,原始图像经过Conv后提取的是图像边缘低级特征,随着网络层数的加深,经过残差单元后,由于引入了分组卷积因素及DANet注意力机制,摒弃了无用特征,放大细化了有用特征,最终实现了相应的触头系统诊断任务。

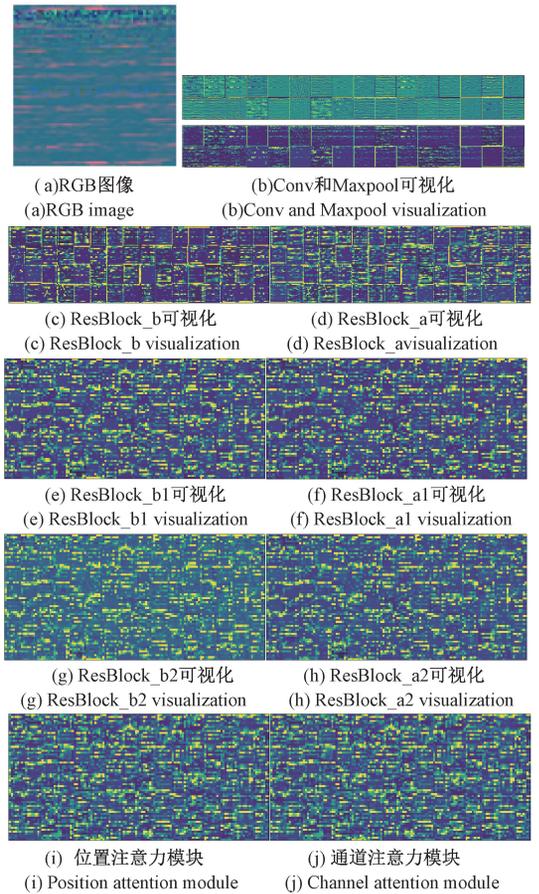


图16 模型特征可视化

Fig. 16 Model feature visualization

3.3 对比实验

在本节中,为了研究本文所提诊断方法的优越性,讨论了多任务软共享机制下本文模型的优势。利用合闸过程产生的振动与电流信号对所提方法进行了测试与讨论。并设置了DCNN^[10]、MTL-SEResNet^[23]、CSDT和SADT4种网络结构。其中DCNN以振动和电流信号转换得到的二维时频图同时作为模型的输入,且尺寸大小

均为 $128 \times 128 \times 3$,在此验证本文模型较其他并行诊断模型的优势。而CSDT为本文模型的触头诊断任务,SADT为本文模型的附件诊断任务。对比结果如表9所示。

表9 多任务学习模型对比结果

Table 9 Comparison results of multitask learning model

| 模型 | 输入 | 准确率/% | | 运行时间/s |
|--------------|--------|-------|-------|--------|
| | | 触头诊断 | 附件诊断 | |
| DCNN | 二维时频图 | 99.07 | 98.54 | 313.62 |
| MTL-SEResNet | 广域融合数据 | 98.15 | 98.97 | 299.03 |
| CSDT | 广域融合数据 | 98.62 | - | 320.13 |
| SADT | 广域融合数据 | - | 98.71 | 316.98 |
| 本文模型 | 原始振电信号 | 97.97 | 98.24 | 297.16 |
| 本文模型 | 广域融合数据 | 99.78 | 99.85 | 309.66 |

从实验结果来看,较之CSDT和SADT两种单分支结构,多任务学习可以增强泛化能力,从而使得两个任务的分类准确率和运行效率都有进一步提高。其次,与基于多任务硬共享机制的MTL-SEResNet模型相比,本文提出的模型利用软共享机制,采用并行运行网络代替传统的串行运行网络,能够有效的抑制任务间干扰,从而具有更高的诊断准确率,进一步体现了多任务软共享机制引入的意义所在。而当本文模型的输入为原始振动与电流信号时,两个任务的诊断准确率分别下降了1.81%和1.61%,这说明广域融合方式能够避免特征的丢失,最大限度地保留了原始信号中所包含的信息,可以凸显更有效的特征。本文模型与其他多故障诊断模型相比,训练时间缩短了3.96 s,两个任务的训练准确率分别提高了0.71%和1.31%,取得如此好的诊断效果原因在于本文模型采用门控单元控制不同子任务的输出权值,从而实现独立子任务之间的选择性共享。同时采用同方差性不确定性损失函数自动调整各任务损失函数的权重,从而解决了多任务损失函数贡献不平衡和人为调整的困难。

4 结论

本文提出了一种基于振动-电流广域特征与软共享机制的断路器多故障诊断方法,主要结论如下:

1)提出的基于广域信息驱动的信号到彩色图像处理方法,该方法较之单一分析域包含更多有效特征,丰富了断路器故障信息量,从而实现了振动与电流信号特征深层提取,克服了合闸相位随机性对电流信号特征的影响以及振动信号对机械状态的差异更为敏感

等问题。

2)所提诊断模型基于多任务软共享机制,采用两个并行网络代替传统硬共享机制的共享串行网络。并通过自适应加权的损失函数自动的调整两个任务的权重比例,使各任务诊断性能达到最佳,消除了消除任务间的干扰。与单任务学习模型相比,本文方法通过借助软共享机制特有的信息迁移能力更能兼顾断路器不同部位故障的并发性,使得两个任务的平均准确率分别提高了1.16%和1.14%。较其他多故障诊断模型来说,其通过门控单元对子任务进行合理的共享信息分配,避免弱相关信息对子任务的干扰,两个任务的分类准确率分别达到了99.78%和99.85%,且模型的运行耗时更短,在大数据处理时优势更加明显,降低了对处理器的依赖性。

目前,本文只在一台断路器试品上进行测试,因此,未来的研究应该进一步提高模型在不同断路器试品之间的迁移测试能力。此外,在分闸过程中考虑故障类型较少,如未考虑分闸不同期问题,在今后的研究中将对相关内容进行补充实验。

参考文献

- [1] 邱海枫,苏宁,田松林.改进支持向量机在电力变压器故障诊断中的应用研究[J].电测与仪表,2022,59(11):48-53.
QIU H F, SU N, TIAN S L. Research on the application of improved support vector machine in power transformer fault diagnosis[J]. Electrical Measurement & Instrumentation, 2022, 59(11): 48-53.
- [2] LU Y, LI Y. A novel fault diagnosis method for circuit breakers based on optimized affinity propagation clustering[J]. International Journal of Electrical Power & Energy Systems, 2020(118): 105651.
- [3] ZHANG H Y, XIE Y Z, YI T Q, et al. Fault detection for high-voltage circuit breakers based on time-frequency analysis of switching transient E-fields [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(4): 1620-1631.
- [4] ZHANG Y, CHUNG C Y, WEN F S, et al. An analytic model for fault diagnosis in power systems utilizing redundancy and temporal information of alarm messages [J]. IEEE Transactions on Power Systems, 2016, 31(6): 4877-4886.
- [5] 慕晓东,魏轩,曾昭菊.基于注意力残差网络的航天器测控系统故障诊断[J].仪器仪表学报,2022,

- 43(9): 81-87.
- MU X D, WEI X, ZENG ZH J. Fault diagnosis method of spacecraft tracking telemetry and control system based on the attention residual network[J]. Chinese Journal of Scientific Instrument, 2022, 43(9): 81-87.
- [6] SUN S G, ZHANG T T, WANG J Q, et al. Fault diagnosis of conventional circuit breaker contact system based on time-frequency analysis and improved Alex-Net[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-12.
- [7] 黄南天, 王斌, 蔡国伟, 等. 基于 Tsallis 熵与层次化混合分类器的含未知故障断路器机械故障诊断[J]. 高电压技术, 2019, 45(5): 1518-1525.
- HUANG N T, WANG B, CAI G W, et al. Mechanical fault diagnosis containing unknown fault of high voltage circuit breaker based on Tsallis entropy and hybrid classifier[J]. High Voltage Engineering, 2019, 45(5): 1518-1525.
- [8] SHAO S Y, YAN R Q, LU Y D, et al. DCNN-based multi-signal induction motor fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(6): 2658-2669.
- [9] 赵晓平, 吴家新, 钱承山, 等. 基于多任务深度学习的齿轮箱多故障诊断方法[J]. 振动与冲击, 2019, 38(23): 271-278.
- ZHAO X P, WU J X, QIAN CH SH, et al. Multi-fault diagnosis for gearboxes based on multi-task deep learning[J]. Journal of Vibration and Shock, 2019, 38(23): 271-278.
- [10] 吴晨, 姚菁, 薛贵元, 等. 基于 MMoE 多任务学习和长短时记忆网络的综合能源系统负荷预测[J]. 电力自动化设备, 2022, 42(7): 33-39.
- WU CH, YAO J, XUE G Y, et al. Load forecasting of integrated energy system based on MMoE multi-task learning and LSTM [J]. Electric Power Automation Equipment, 2022, 42(7): 33-39.
- [11] XIE Z L, CHEN J L, FENG Y, et al. End to end multi-task learning with attention for multi-objective fault diagnosis under small sample [J]. Journal of Manufacturing Systems, 2022, 62: 301-31.
- [12] WANG H Q, LIN T J, CUI L L, et al. Multitask learning-based self-attention encoding atrous convolutional neural network for remaining useful life prediction[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-8.
- [13] 王震, 黄如意, 李霁蒲, 等. 一种用于故障分类与预测的多任务特征共享神经网络[J]. 仪器仪表学报, 2019, 40(7): 169-177.
- WANG ZH, HUANG R Y, LI J P, et al. Multi-task feature sharing neural network used for fault diagnosis and prognosis[J]. Chinese Journal of Scientific Instrument, 2019, 40(7): 169-177.
- [14] 李邦彦, 齐伟强, 杨兆静, 等. 基于多特征选择方法的高压断路器故障诊断[J]. 高压电器, 2020, 56(6): 218-224.
- LI B Y, QI W Q, YANG ZH J, et al. Fault diagnosis of high-voltage circuit breaker based on multi-feature selection approaches [J]. High Voltage Apparatus, 2020, 56(6): 218-224.
- [15] XIONG J B, LI C L, WANG C D, et al. Application of convolutional neural network and data preprocessing by mutual dimensionless and similar gram matrix in fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2022, 18(2): 1061-1071.
- [16] WEN L, LI X Y, GAO L, et al. A new convolutional neural network-based data-driven fault diagnosis method[J]. IEEE Transactions on Industrial Electronics, 2018, 65(7): 5990-5998.
- [17] SUN J D, WEN J T, YUAN C Y, et al. Bearing fault diagnosis based on multiple transformation domain fusion and improved residual dense networks[J]. IEEE Sensors Journal, 2022, 22(2): 1541-1551.
- [18] SUN S G, WEN Z T, WANG J Q, et al. Remaining life prediction of conventional low-voltage circuit breaker contact system based on effective vibration signal segment detection and MCCAELSTM[J]. IEEE Sensors Journal, 2021, 21(19): 21862-21871.
- [19] 孙曙光, 张伟, 王景芹, 等. 基于动作过程振动检测的低压断路器机械寿命预测[J]. 仪器仪表学报, 2020, 41(12): 146-157.
- SUN SH G, ZHANG W, WANG J Q, et al. Mechanical life prediction of low-voltage circuit breaker based on vibration detection during operation[J]. Chinese Journal of Scientific Instrument, 2020, 41(12): 146-157.
- [20] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]. IEEE Conference on

Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016; 770-778.

- [21] TRAN M Q, LIU M K, TRAN Q V, et al. Effective fault diagnosis based on wavelet and convolutional attention neural network for induction motors [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-13.
- [22] JIANG L Q, NING C Y, LI J Y. Glioma classification framework based on SE-ResNeXt network and its optimization[J]. IET Image Process, 2021, 16(2): 596-605.
- [23] 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.
- SUN SH G, ZHANG T T, WANG J Q, et al. Fault degree evaluation of circuit breaker based on continuous wavelet transform and MTL-SEResNet [J]. Chinese Journal of Scientific Instrument, 2022, 43(6): 162-173.

作者简介



孙曙光, 分别在 2002 年、2005 年和 2009 年于河北工业大学获得学士学位、硕士学位和博士学位, 现为河北工业大学副教授, 主要研究方向为智能检测与故障诊断。

E-mail: sunshuguang_2000@163.com

Sun Shuguang received his B. Sc. Degree, M. Sc. degree and Ph. D. degree all from Hebei University of Technology in 2002, 2005 and 2009, respectively. He is currently an associate professor at Hebei University of Technology. His main research interests include intelligent detection and fault diagnosis.



陈静, 现任温州聚星电接触科技有限公司董事长及总经理, 主要研究方向为电接触材料、电触头和电接触元件的研发。

E-mail: jxcj@China-juxing.cn

Chen Jing is now the chairman and general manager of Wenzhou Juxing Technology Co., Ltd. His main research interests include the development of electrical contact materials, electrical contacts and electrical contact components.



王景芹 (通信作者), 分别在 1984 年、1986 年和 1997 年于河北工业大学获得学士学位、硕士学位和博士学位, 现为河北工业大学教授, 主要研究方向为电接触和可靠性。

E-mail: jqwang@hebut.edu.cn

Wang Jingqin (Corresponding author) received her B. Sc. Degree, M. Sc. degree and Ph. D. degree all from Hebei University of Technology in 1984, 1986 and 1997, respectively. She is currently a professor at Hebei University of Technology. Her main research interests include electrical contact and reliability.