

基于动态多模态融合的电力变压器故障诊断方法

张若泉¹, 冉慧娟¹, 谢 军¹, 汤铠铭²

(1. 华北电力大学 电力工程系, 河北 保定 071003;

2. 国网山东电力有限公司烟台供电公司, 山东 烟台 264001)

摘要:为适配不同现场监测条件、充分利用多模态监测信息,提升变压器故障诊断方法的灵活性及准确性,本文提出一种基于动态多模态融合的电力变压器故障诊断方法。该方法引入动态融合策略,首先构建一层模态选择网络,可自主筛选输入的监测信息,动态选择诊断的模式,以适配现场不同监测条件;然后针对不同输入模式建立对应的诊断模型,非单模态条件下采用相应的融合方式予以诊断,实现各模态监测信息的充分利用;最后通过采用多地市局收集的实际案例进行验证。结果表明:本文方法能有效提升变压器故障诊断结果的灵活性与准确性,可适配现场不同监测条件,相较其他方法识别准确率更高,最高可达97.33%,且误报率、漏报率最低。

关键词:变压器;故障诊断;灵活性;动态多模态融合

A fault diagnosis method based on dynamic multimodal fusion for power transformer

ZHANG Ruoquan¹, RAN Huijuan¹, XIE Jun¹, TANG Kaiming²

(1. Department of Electric Engineering, North China Electric Power University, Baoding 071003, China;

2. Yantai Power Supply Company, State Grid Shandong Electric Power Co., Ltd., Yantai 264001, China)

Abstract: In order to adapt to different on-site monitoring conditions, make full use of multimodal monitoring information, and improve the flexibility and accuracy of transformer fault diagnosis methods, a fault diagnosis method of power transformer based on dynamic multimodal fusion was proposed in this paper. The method introduced a dynamic fusion strategy, which firstly constructed a layer of modal selection network that can autonomously screen the input monitoring information and dynamically select the diagnostic modes to adapt to the different monitoring conditions on site. Secondly, it established corresponding diagnostic models for different input modes, and adopted the corresponding fusion method to diagnose under the non-single modal conditions for achieving the full utilization of the monitoring information of each modality. Finally, actual cases collected from multiple municipal bureaus were used for verification. The results show that the method proposed in this paper can effectively improve the flexibility and accuracy of transformer fault diagnosis results, and can be adapted to different monitoring conditions on site. Compared with other methods, the recognition accuracy of this method is higher, up to 97.33%, and the false alarm rate and missed alarm rate are the lowest.

Key words: transformer; fault diagnosis; flexibility; dynamic multimodal fusion

0 引言

变压器在电力系统中承担着极其关键的作用,保障其安全稳定运行尤为重要^[1-2]。然而变压器故障类型多样^[3],为了及时准确地发现其潜在缺陷,给后续运维提供丰富且有效的信息,需要提高变压器故障诊断方法的准确性^[4-5]。

传统的单模态变压器故障诊断方法主要针对某种特定监测信息进行分析,例如较为典型的油中

溶解气体分析(dissolved gas analysis, DGA)^[6-8]、局部放电(partial discharge, PD)监测^[9]、红外(infrared, IR)识别技术^[10]等方法。虽然这些单模态方法在特定场景下较为有效,但在诊断过程中不同模态间的诊断方法缺乏耦合^[11-12],故障判定界限模糊,诊断存在一定局限性,诊断结果准确性难以达到实际工况要求。为解决上述问题,许多学者将多源信息融合技术应用于变压器中的故障诊断。李刚等^[13]以油色谱数据为主体,结合变压器的局部放电量、历史故障信息、家族质量史等数据,采用多级决策融合的

基金项目:国家重点研发计划项目(2023YFB2408203)。

方法进行变压器故障诊断。黄新波等^[14]以电气试验数据与油色谱数据作为数据源进行特征级融合,然后输入至同一模型中进行多次诊断,对所有输出信息利用改进证据理论方法融合后得到最终诊断结果。詹仲强等^[15]则通过扩展模糊逻辑对油色谱数据及铁心接地电流数据进行映射计算后,利用证据理论进行决策融合完成故障诊断。以上研究均能有效证明,不同来源信息间具有互补性,相较于单一信息的故障诊断方法,多种类信息融合诊断方法可以有效提升变压器故障诊断的准确性。

然而以上多源信息融合类诊断技术采用的信息源多为以油中溶解气体含量为主的结构化数据,红外图像等非结构化数据并未考虑。针对热性质类故障仅依靠油中溶解气体数据进行诊断,会导致变压器信息利用不够充分,诊断准确率提升空间较大。另外,在现场实际采集条件下,部署的传感器种类与数据的采集频率均不同,监测数据存在异常或丢失的问题,造成同一时段下,实际可用的多模态信息种类并不固定。同时目前的诊断方法均是静态的,且诊断模式固定,诊断灵活性不足。例如:当某模态缺失时,诊断方法不再适用;当数据异常时,诊断准确率下降,难以应对现场的高监测要求。因此需要在充分考虑各类多模态信息的同时,提高诊断方法的灵活准确性以及对现场多样数据采集条件的适配性。

为提升现有变压器故障诊断方法的灵活性、准确性,本文提出一种基于动态多模态融合的电力变压器故障诊断方法。首先在模型前端构建一层模态选择网络作为第一层决策,可自主筛选现场输入的监测信息,动态选择诊断的模式;其次,建立并训练不同模式输入条件下的诊断模型;最后针对各种输入信息,采用相应的融合策略模型进行故障诊断,实现不同数据监测条件下,信息利用率与诊断准确率的提升。

1 多模态信息收集及预处理

1.1 多模态信息选择及故障划分

变压器故障按照性质可分为热故障和电故障,按照发生位置可分为内部与外部^[16]。内部故障主要发生在绕组、铁心等部件上,外部故障主要发生在套管上。热故障通过DGA技术与红外技术相互辅助进行诊断,电故障则在DGA技术与局部放电监测的基础上,再辅助红外技术(如果引起发热)进行诊

断。综上,可选择将油中溶解气体数据、局部放电数据、红外热图像3种模态数据进行融合。

由于目前各种技术检测故障类型以及划分不一致,本文以实际案例为依据,按照故障种类与位置重新对变压器故障种类进行划分,如表1所示。

表1 基于多模态信息变压器故障类型划分

Table 1 Type classification of transformer fault based on multimodal information

发生部位	故障性质	故障类型
外部(套管)	热性质故障	高温过热
		中低温过热
	电性质故障	局部放电
		高低能放电
内部(油箱内部故障)	热性质故障	高温过热
		中低温过热
	电性质故障	局部放电
		高低能放电 放电兼过热


1.2 多模态信息预处理

首先,从多地收集的大量实际案例中抽选相同时间段的多组样本作为数据库。以数据库中某地市局为例,DGA数据采集频率为1个/h,当DGA数据存在时,以DGA数据采集时间为中心,设定时间窗口为1h,即DGA数据采集时间前后各为0.5h,认为在此段时间内的其他模态数据与DGA属于同时间段数据;当DGA数据缺失时,则采用红外/局部放电进行单模态故障诊断。考虑到现场多模态数据间具有采集难的问题,未对后续运维排查出的相关报告缺失数据作填补(可反映现场监测条件中数据的缺失情况),应采用其他模态数据进行后续故障识别。

其次,由于外部与内部部件相互独立监测,两者数据不共通,模型将分别进行诊断。为使模型区分内外数据,将内部数据添加标签“0”,外部数据添加标签“1”。

最后,为了使模型训练效果更佳,需对原始数据进行预处理。在油中溶解气体分析中,常用的三比值法存在编码不全、边界过于绝对等问题^[17-18],诊断准确率较一般深度学习方法低;直接将特征气体含量输入会因为数值分散程度大而导致训练效果不佳^[19]。因此本文选择将H₂、CH₄、C₂H₂、C₂H₄、C₂H₆ 5种特征气体的体积分数作为模型输入,以优化训练效果。

红外图像不同于油中溶解气体分析方法,通常以过热点与其他正常点的温差大小来判断故障的严重程度^[20],且由于红外现场数据驳杂^[21-22],受限于设备、环境等因素,低像素图片会影响深度学习模型的训练效果。本文利用增强型超分辨率生成对抗网络(ESRGAN)^[23]方法对红外图像进行超分辨率重建,以提升图片清晰度,方便后续识别,处理效果如图1所示。



(a) 处理前 (b) 处理后

图1 红外图像处理前后对比

Fig.1 Comparison of infrared images before and after processing

采用自适应加权分帧快速稀疏表示去噪方法^[24]提高局部放电数据的质量。每个局部放电样本的数据来源是一个5 s的原始信号(约为250周波),去噪后提取其脉冲和相位,将 $0\sim 360^\circ$ 的相位及 $0\sim v_{\max}$ (5 s内最大放电幅值)的放电幅值离散化为90个区间谱图,以放电次数为矩阵元素,形成 90×90 的矩阵作为PRPD谱图,如图2所示。

2 动态多模态融合故障诊断原理及方法

2.1 动态多模态融合原理

假设需要融合的模态共 m 个,由 m 个模态形成的集合表示为全模态 X ,如式(1)所示。


$$X = (x_1, x_2, \dots, x_m) \quad (1)$$

考虑到所有的输入情况,为每种输入条件下的网络设计其独有的融合策略 F ,表示为 $F_i(A)$,如式(2)所示。

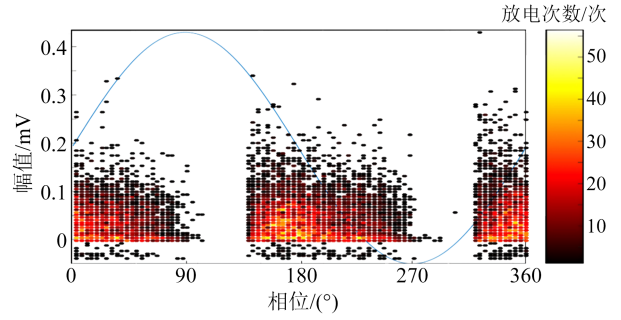
$$F_i(A) (i = 1, 2, \dots, 2^{m-1}) \quad (2)$$

式(2)中: A 为全模态 X 的子集; F_i 为第 i 个融合策略。

在模型中合适的位置嵌入一个经过训练的门控网络函数 $G(x)$,其能够依据各模态输入数据的特征,自动选择适合参与融合的模态。即往门控网络 $G(x)$ 中输入全模态 X 后,会产生一个离散的 b 维稀疏向量(one-hot编码),表示为 g ,如式(3)所示。



(a) 处理前



(b) 处理后

图2 局部放电信号处理前后对比

Fig.2 Comparison of partial discharge signals before and after processing

$$g = \text{one-hot}(\arg\max_i G(x)_i) \quad (3)$$

通过输出的one-hot编码来决定是否激活某个分支的融合策略 $F_i(A)$,可得到最后的结果^[25]。

以 $m=2$ 为例,具体决策过程如图3所示,图中 w 为权重系数, y 为输出结果。




图3 动态多模态融合示例图

Fig.3 Example diagram of dynamic multimodal fusion

每种融合策略均为提前制定并训练好的模型,由于已经考虑到所有可能的模态组合,继而每次融合只选择最合适的分支策略,最大化地简化计算。

考虑到变压器故障特征信息间差异较大,特征融合方法操作难度较大,不易实现,可使用D-S证据理论^[26]对部分模态数据进行决策融合诊断,通过以下函数实现:

(1)基本概率分配函数,如式(4)所示。

$$\begin{cases} \sum_{A \subseteq \Theta} m(A) = 1 \\ m(\phi) = 0 \\ 0 \leq m(A) \leq 1 \end{cases} \quad (4)$$

式(4)中: Θ 为识别框架; A 为识别框架的子集。

(2)信任函数,如式(5)所示。

$$\text{Bel}(A) = \sum_{B \subset A} m_i(B) \quad (5)$$

式(5)中, B 为 A 的所有子集。

(3)似然函数,如式(6)所示。

$$\text{pl}(A) = 1 - \text{Bel}(\bar{A}) \quad (6)$$

(4)D-S证据理论合成计算规则如式(7)所示。

$$(m_1 \oplus \dots \oplus m_n)(A) = K^{-1} \sum_{A_1 \cap \dots \cap A_n = A} \prod_{1 \leq i \leq n} m_i(A_i) \quad (7)$$

式(7)中: K 为冲突因子。

2.2 动态多模态融合故障诊断方法

考虑到现场不同的数据监测情况,本文共提出3种针对不同输入条件的诊断策略:

策略1:保留单模态模型针对特定问题的解决能力,在仅存在单一可用数据时使用,即三者模态分别利用各自合适的模型进行诊断。

策略2:存在某模态数据异常或缺失时,以油色谱数据为主,与局部放电监测数据或红外图像任一模态采取决策融合方法以提高诊断准确率;若油色谱数据缺失,则局部放电监测数据、红外图像分别利用单模态模型进行诊断。

策略3:数据无缺失且无异常时,采取混合融合的方式,充分利用各模态间的互补性,将油色谱、局部放电数据特征融合后的诊断输出与红外图像模型的识别输出利用证据理论融合进行诊断,得到最终诊断结果。

基于动态多模态融合的变压器故障诊断方法整体流程如图4所示。

总体训练流程如下:

第一步:数据预处理,对真实样本数据进行分类处理,以运维历史数据报告中确认的故障类型为依据,按照本文划分的故障类型为样本添加标签,然后按照规定的时间窗口与实际数据缺失情况,保证同组多模态数据的时间同步性,并按不同训练需求划分出对应的训练集与测试集。

第二步:第一级决策训练,全模态数据输入训练门控网络,使门控网络 $G(x)$ 作为第一级决策,通过输入数据特征识别输出one-hot编码。

第三步:第二级决策训练,建立不同输入条件下的融合策略并编码,选择对应的训练集与测试集为各融合模型进行训练,作为第二级决策进行故障诊断。

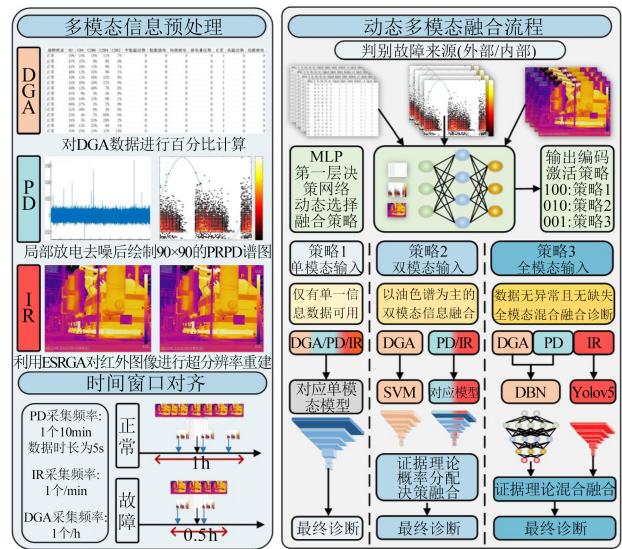


图4 基于动态多模态融合的变压器故障诊断方法流程

Fig.4 Transformer fault diagnosis methodology flow based on dynamic multimodal fusion

第四步:整体网络测试,将待诊断的测试集数据输入门控网络 $G(x)$,使其选择合适的融合诊断策略进行故障诊断,得到最终故障诊断结果。

3 算例分析

3.1 识别模型选择及训练参数设置

为了充分体现本文动态多模态融合效果,单模态诊断模型选择各技术中发展成熟的方法。红外技术选用Yolov5算法^[20];局部放电监测选用repVGG模型^[27],其学习率为 1×10^{-4} ,矩估计因子为(0.9, 0.999);油中溶解气体分析选用支持向量机(SVM)^[28],采用径向基核函数(RBF),RBF参数为0.5,规则化系数为500;油中溶解气体分析和局部放电监测特征融合诊断采用深度置信网络(DBN)^[13],选取经典的5层模型,受限玻尔兹曼机(RBM)的最大迭代次数为100,学习率为0.1,动量参数为0.9;门控网络则选择多层感知机(MLP)。

3.2 样本数据

从多地市分公司收集多组实际案例数据与相关报告,以案例和报告的诊断结果为依据,划分各数据故障类型,同时划分训练集与测试集样本。其中门控网络的训练集、测试集中包含各种类型的异常数据与缺失数据,训练门控网络可识别各种监测条件下的不同输入,并输出正确的编码,激活对应的诊断模式。在诊断模型测试集中,随机加入少量异常数据以模拟实际监测条件中可能出现的情况。具体故障数据划分如表2所示。其中,在单模态输

表2 训练集和测试集数据总量

Table 2 The total number of data in the training and testing sets

模型	输入数据组成	testing sets	
		训练集+异常数据量	测试集+异常数据量
门控网络	DGA/PD/IR	1 000+500	600+300
	DGA	1 300	400+40
	PD	800	400+40
单模态输入监测条件	IR	800	400+40
	DGA/PD	1 300	400+40
双模态输入监测条件	DGA/IR	1 300	400+40
	DGA/PD/IR	1 300	400+40

入监测条件下,各模型训练集与测试集的各类型样本数量划分如表3所示。

表3 单模态输入监测条件下训练集和测试集数据量

Table 3 The amount of data in the training and testing sets under unimodal input monitoring conditions

故障类型	训练集			测试集			
	DGA	PD	IR	DGA	PD	IR	
正常	200	200	200	100	100	100	
高温过热	100	0	100	25	0	50	
外部	中低温过热	100	0	100	25	0	50
	局部放电	100	200	0	25	100	0
	高低能放电	100	0	0	25	0	0
异常数据	0	0	0	20	20	20	
内部	正常	200	200	200	100	100	100
	高温过热	100	0	100	20	0	50
	中低温过热	100	0	100	20	0	50
	局部放电	100	200	0	20	100	0
	高低能放电	100	0	0	20	0	0
	放电兼过热	100	0	0	20	0	0
	异常数据	0	0	0	20	20	20

在对比验证本文方法与其他方法时,为防止过多的异常数据大幅降低故障诊断的准确率,以及重复异常数据影响结果的可信度,采取随机加入少量异常数据的方式,并重复做3次实验进行对比,结果取平均值。

双模态与全模态输入监测条件下,训练集与测试集的样本数量划分与单模态输入监测条件下的DGA划分一致。

3.3 异常数据筛选效果验证

在实际现场监测条件下,偶尔会因为环境或设备的影响出现异常数据,例如红外图片中存在遮挡物,局部放电信号噪声过大,去噪后依然不能正常

使用,DGA中某气体含量采集异常等。

为验证本文异常数据筛选的有效性,在数据缺失与数据异常的输入条件下,验证模型是否能识别并选择正确的决策。在本次验证中,数据缺失和异常数据均为非输入模态数据(即除输入数据以外的其他模态数据,例如双模态输入策略中,DGA/PD为正常数据,IR模态数据存在缺失或异常的情况,IR即为非输入模态数据)。各种策略下均采用200组非输入模态数据(缺失、异常数据各100组)进行测试,结果如图5所示。从图5可以看出,对于数据缺失的情况,第一层决策网络完全可以准确地识别并激活正确的诊断模式;对于异常数据加入的情况,选择正确诊断模式的成功率最低也在96%以上,说明第一层决策网络具有可筛选异常数据的作用。




图5 各策略正确激活的概率

Fig.5 The probability of correct activation for each strategy

3.4 动态多模态融合故障诊断效果评价

为验证本文动态融合策略的有效性,在不同数据监测输入条件下对比其他模型与本文模型的诊断准确率,引入多分类问题中的经典指标 $F1_{macro}$ 来定量评估模型的识别准确率,公式如式(8)所示。

$$\begin{cases} P_{macro} = \frac{1}{n} \sum_{i=1}^n \frac{TP_i}{TP_i + FP_i} \\ R_{macro} = \frac{1}{n} \sum_{i=1}^n \frac{TP_i}{TP_i + FN_i} \\ F1_{macro} = \frac{2 \cdot P_{macro} \cdot R_{macro}}{P_{macro} + R_{macro}} \end{cases} \quad (8)$$

式(8)中: n 为故障类型个数; TP_i 表示第 i 类下正确识别为第 i 类的个数; FP_i 表示将非第 i 类故障类型识别为第 i 类的个数; FN_i 表示将第 i 类故障类型识别为其他类的个数; P_{macro} 为宏观精确度,表示模型查准的能力; R_{macro} 为宏观召回率,表示模型查全的能力; $F1_{macro}$ 为二者调和平均值,可反映模型识别能力。

(1) 单模态输入监测条件

在不同数据输入监测条件下,3种模态数据中,

缺失其二,仅存在单一可用模态数据,采用对应测试集进行验证,与单模态诊断模型进行对比,某次实验中各故障类型识别情况如表4~6所示。

表4 DGA模型的 $F1_{macro}$ 值
Table 4 $F1_{macro}$ value of DGA model

DGA	个数				$F1_{macro}/\%$	
	TP	FP	FN	异常	SVM	动态多模态
外部	正常	95	5	5		
	高温过热	23	2	2		
	中低温过热	21	3	4	85.62	91.05
	局部放电	23	1	2		
	高低能放电	23	4	2		
内部	正常	94	4	6		
	高温过热	19	2	1		
	中低温过热	17	2	3	83.84	89.27
	局部放电	19	2	1		
	高低能放电	17	3	3		
	放电兼过热	17	4	3		

表5 IR模型的 $F1_{macro}$ 值
Table 5 $F1_{macro}$ value of IR model

IR	个数				$F1_{macro}/\%$	
	TP	FP	FN	异常	Yolov5	动态多模态
外部	正常	95	5	5		
	高温过热	50	3	0	89.93	94.33
	中低温过热	44	3	6		
内部	正常	69	21	31		
	高温过热	47	6	3	67.01	70.36
	中低温过热	25	32	25		

表6 PD模型的 $F1_{macro}$ 值
Table 6 $F1_{macro}$ value of PD model

PD	个数				$F1_{macro}/\%$	
	TP	FP	FN	异常	repVGG	动态多模态
外部	正常	94	5	6		
	局部放电	95	6	5	90.01	94.50
内部	正常	95	9	5		
	局部放电	91	5	9	88.57	93.03

加入随机少量异常数据进行实验,重复3次取平均值,平均 $F1_{macro}$ 结果如表7~8所示。由表7~8可以看出,经过第一层网络筛选后,有效剔除了异常数据,本文方法在单模态输入下的诊断准确率较单模态模型有明显提升,最高可提升5.50%,但准确率最高仅为94.51%。这是因为单模态方法能获取的信息有限,难以进一步提升准确率,仅在现场急需诊断而缺乏其他数据时,提供更具针对性的诊断

表7 各单模态模型多次实验后的平均 $F1_{macro}$

Table 7 The average $F1_{macro}$ of each unimodal model after multiple experiments

发生部位	repVGG	Yolov5	SVM
外部	90.03	89.72	85.58
内部	89.21	70.60	83.75

表8 本文方法在单模态输入条件下多次实验后的平均 $F1_{macro}$

Table 8 The average $F1_{macro}$ of the method proposed in this paper after multiple experiments under unimodal input conditions

发生部位	repVGG	Yolov5	SVM
外部	94.51	94.18	91.08
内部	93.69	74.21	89.08

方式。

(2)双模态输入监测条件

在该条件下,3种模态数据中,缺失其一,仅存在两个可用模态数据,采用对应测试集进行验证,本文方法以油色谱为主,与局部放电或红外数据进行融合诊断。从电故障角度对比验证,选用单模态诊断模型(PD-repVGG)、李刚等^[13]提出的多级决策融合模型(DBN-DS)、黄新波等^[14]提出的多源多分类相关向量机模型(MRVM-DS)与本文方法进行对比。前者采用DGA与局部放电早期融合结果、家族故障史决策融合的诊断模式(早期融合),后者采用多个诊断模型得出的多个子结果决策融合的诊断模式(晚期融合),为多源融合诊断常用且具有代表性的融合形式。

图6是局部放电故障下,本文方法与其他多源信息融合模型检测的识别准确率对比。




图6 局部放电故障下本文方法与其他方法的识别准确率对比

Fig.6 Comparison of identification accuracy between the method proposed in this paper and other methods under partial discharge faults

从图6可以看出,无论是外部还是内部的局部放电故障,在经过双模态融合后,本文方法的识别能力都有所提高,识别准确率最高可达96.69%,高于其他两种方法的识别准确率。这是因为DBN-DS与MRVM-DS两种方法均为静态模型,对于异常数据或缺失数据依然按照固定的融合模式进行诊断;而当本文模型遇到此类情况时,会经由第一层网络首先对异常数据进行筛选,然后动态选择合适的诊断方式,所以本文方法更加灵活,能有效提高模型对特征信息的利用效率,从而提高诊断的准确率。

从热故障角度来看,由于暂无考虑红外模态的融合诊断方法,主要与单模态方法(DGA-SVM)进行验证。图7为热故障下,本文方法与单模态模型检测的识别准确率对比。由图7可看出,在经过数据筛选前,红外与油色谱两个单模态技术诊断准确率均低于90%,且面对内部中低温过热故障时,由于内部的绝缘油阻碍了温度向表面的传递和异常数据的存在,使得红外技术对内部中低温过热故障的识别准确率较低。但在本文方法下通过筛选数据、灵活诊断的方式,在多模态故障诊断下二者充分互补,比单一模态下更能准确地识别故障类型,识别准确率最高为96.65%,故障诊断效果好。




图7 热故障下本文方法与单模态模型的识别准确率对比

Fig.7 Comparison of identification accuracy between the method proposed in this paper and unimodal model under thermal faults

(3)全模态输入监测条件

当存在异常数据时,本文方法会自动采用前述两种工况下合适的策略进行诊断,当不存在异常数据且全模态无缺失数据时,模型会采用混合融合的策略进行诊断,以充分利用各模态信息特征间的互补性,提高模型的诊断能力。因此本次验证选择无异常数据的训练集,与其他模型进行对比,结果如图8所示。由图8可看出,当采用更全面的信息以

及更精细的融合方式后,模型整体识别准确率均有所提升,最高达97.33%。其中热故障下的诊断准确率提升明显,最高为96.95%;局部放电与油色谱数据特征融合进行诊断可有效提升模型对电性质故障的识别能力;加入红外模态后,对放电兼过热故障的诊断准确率有所提升。以上结果充分说明了考虑红外模态的必要性,可通过提高信息丰富度,提升故障诊断的准确性。




图8 本文方法与其他模型的识别准确率对比

Fig.8 Comparison of identification accuracy between the method proposed in this paper and other models

3.5 误判漏报

除了故障诊断准确率以外,在变压器故障诊断的实际案例中,对故障的误判、漏报同样会产生严重后果。为了定量分析本文多模态故障诊断模型的诊断效果,对诊断结果误判率 F_N 及漏报率 F_P 进行计算,两者计算公式分别表示为式(9)、式(10)。

$$F_N = \frac{P_{p \rightarrow n}}{P} \times 100\% \quad (9)$$

$$F_P = \frac{N_{n \rightarrow p}}{N} \times 100\% \quad (10)$$

式(9)~(10)中: P 为正常状态测试样本总数; $P_{p \rightarrow n}$ 为将正常状态误判为故障状态的测试样本总数; N 为故障状态测试样本总数; $N_{n \rightarrow p}$ 为将故障状态漏报为正常状态的测试样本总数^[29]。将本文方法与其他模型进行对比,结果如图9~10所示。

由图9~10可看出,本文方法针对变压器故障




图9 故障误判率对比

Fig.9 Comparison of failure misjudgment rate




图10 故障漏报率对比

Fig.10 Comparison of fault omission rate

的误判率、漏报率均低于其他模型,其故障误判率的平均值为3.50%,故障漏报率的平均值为2.58%,相对其他模型均有所降低。本文的动态融合方法通过动态选择融合诊断策略,能有效应对不同工况,提升故障特征的利用效率,模型的鲁棒性更佳,误判率与漏判率相较其他方法更低。

4 结论

为适配不同现场监测条件、充分利用多模态监测信息,提升变压器故障诊断方法的灵活性及准确性,本文引入动态融合策略,提出一种基于动态多模态融合的变压器故障诊断方法,得到主要结论如下:

(1)基于动态多模态融合的变压器故障诊断方法,可依据输入的监测信息,动态筛选数据并选择合适的融合策略进行故障诊断,能够适配现场不同采集工况,相较于传统诊断模型更加灵活。

(2)基于动态多模态融合的变压器故障诊断方法,考虑更全面的信息,通过模态间的互补性,使得变压器故障诊断在识别准确率上进一步提升,最高达97.33%,尤其在热性质故障上提升明显,识别准确率最高为96.95%。

(3)由于信息丰富度的提升以及动态融合策略的引入,相较于其他诊断方法而言,本文方法可在诊断前自动剔除异常数据,且通过动态选择合适的诊断模式,能够有效降低故障的误判率、漏报率,误判率最低可降至3.17%,漏报率最低可降至2.33%,能为变压器的运维提供更加详细、准确的信息,提高现场运维效率,确保电力系统安全可靠的运行。

参考文献 References

[1] 李雅欣,侯慧娟,胥明凯,等.基于策略梯度和生成式对抗网络的变压器油色谱案例扩充方法[J].电力自动化设备,2020,40(12):211-218.
LI Yaxin, HOU Huijuan, XU Mingkai, et al. A case expansion

method for transformer oil chromatography based on policy gradient and generative adversarial network[J]. Electric Power Automation Equipment,2020,40(12):211-218.

- [2] MAHMOUDI N, SAMIMI M H, MOHSENI H. Experiences with transformer diagnosis by DGA: case studies[J]. IET Generation Transmission & Distribution,2019,13(23):5431-5439.
- [3] 吴坤,康建设,池阔.基于改进多分类算法和相关向量机的电力变压器故障诊断方法[J].高电压技术,2016,42(9):3011-3017.
WU Kun, KANG Jianshe, CHI Kuo. Fault diagnosis method of power transformers using improved multi-class classification algorithm and relevance vector machine[J]. High Voltage Engineering,2016,42(9):3011-3017.
- [4] TOKUNAGA J, KOIDE H, MOGAMI K, et al. Gas generation of cellulose insulation in palm fatty acid ester and mineral oil for life prediction marker in nitrogen-sealed transformers[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2017,24(1):420-427.
- [5] JIANG Jun, CHEN Ruyi, CHEN Min, et al. Dynamic fault prediction of power transformers based on hidden markov model of dissolved gases analysis[J]. IEEE Transactions on Power Delivery, 2019,34(4):1393-1400.
- [6] RAJESH K, RAO U M, FOFANA I, et al. Influence of data balancing on transformer DGA fault classification with machine learning algorithms[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2022,30(1):385-392.
- [7] 汪可,李金忠,张书琦,等.变压器故障诊断用油中溶解气体新特征参量[J].中国电机工程学报,2016,36(23):6570-6578,6625.
WANG Ke, LI Jinzhong, ZHANG Shuqi, et al. New characteristic parameters of dissolved gases in oil for transformer fault diagnosis[J]. Proceedings of the CSEE,2016,36(23):6570-6578,6625.
- [8] 江军,张文乾,李波,等.电力变压器油中溶解气体离群值识别和数据重构[J].电工技术学报,2024,39(17):5521-5533.
JIANG Jun, ZHANG Wenqian, LI Bo, et al. Identification and data reconstruction of dissolved gas outliers in power transformer oil [J]. Transactions of China Electrotechnical Society, 2024, 39(17): 5521-5533.
- [9] 刘云鹏,杨超杰,赵涛,等.温度对油-纸界面处微水迁移与局部放电的影响[J].电工技术学报,2024,39(16):5182-5193.
LIU Yunpeng, YANG Chaojie, ZHAO Tao, et al. Effect of temperature on micro-water migration and partial discharge at oil-paper interface[J]. Transactions of China Electrotechnical Society, 2024, 39(16):5182-5193.
- [10] 朱惠玲,牛哲文,黄克灿,等.基于单阶段目标检测算法的变电设备红外图像目标识别及定位[J].电力自动化设备,2021,41(8):217-224.
ZHU Huiling, NIU Zhewen, HUANG Kechan, et al. Infrared image target recognition and localization of substation equipment based on single-stage target detection algorithm[J]. Electric Power Automation Equipment,2021,41(8):217-224.
- [11] GONG Y S, BO Z. The fault diagnosis model of transformer which based on the technology of information fusion[C]//2009 Ninth International Conference on Hybrid Intelligent Systems.

- Shenyang, China: IEEE,2009:184-187.
- [12] 谢龙君,李黎,程勇,等.融合集对分析和关联规则的变压器故障诊断方法[J].中国电机工程学报,2015,35(2):277-286.
XIE Longjun, LI Li, CHENG Yong, et al. Transformer fault diagnosis method by integrating set-pair analysis and association rules[J]. Proceedings of the CSEE,2015,35(2):277-286.
- [13] 李刚,于长海,范辉,等.基于多级决策融合模型的电力变压器故障深度诊断方法[J].电力自动化设备,2017,37(11):138-144.
LI Gang, YU Changhai, FAN Hui, et al. In-depth diagnosis method of power transformer faults based on multilevel decision fusion model[J]. Electric Power Automation Equipment,2017,37(11):138-144.
- [14] 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.
- [15] 詹仲强,陈文涛,郝建,等.基于模糊逻辑和D-S证据理论的变压器故障诊断方法[J].高压电器,2022,58(11):160-166.
ZHAN Z Q, CHEN W T, HAO J, et al. Transformer fault diagnosis method based on fuzzy logic and D-S evidence theory[J]. High Voltage Apparatus,2022,58(11):160-166.
- [16] TANG W H, SPURGEON K, WU Q H, et al. An evidential reasoning approach to transformer condition assessments[J]. IEEE Transactions on Power Delivery,2004,19(4):1696-1703.
- [17] 江秀臣,盛戈皞.电力设备状态大数据分析的研究和应用[J].高电压技术,2018,44(4):1041-1050.
JIANG Xiuchen, SHENG Gehao. Research and application of big data analysis of power equipment condition[J]. High Voltage Engineering,2018,44(4):1041-1050.
- [18] SARKAR S, SHARMA T, BARAL A, et al. An expert system approach for transformer insulation diagnosis combining conventional diagnostic tests and PDC, RVM data[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2014,21(2):882-891.
- [19] 刘云鹏,许自强,和家慧,等.基于条件式Wasserstein生成对抗网络的电力变压器故障样本增强技术[J].电网技术,2020,44(4):1505-1513.
LIU Yunpeng, XU Ziqiang, HE Jiahui, et al. Data augmentation method for power transformer fault diagnosis based on conditional Wasserstein generative adversarial network[J]. Power System Technology,2020,44(4):1505-1513.
- [20] 刘传洋,吴一全.基于红外图像的电力设备识别及发热故障诊断方法研究进展[J].中国电机工程学报,2025,45(6):2171-2196.
LIU Chuanyang, WU Yiquan. Research progress of power equipment identification and thermal fault diagnosis based on infrared images[J]. Proceedings of the CSEE,2025,45(6):2171-2196.
- [21] GIRARD F, BATTUELLO M, FLORIO M. Multiwavelength thermometry at high temperature: why it is advantageous to work in the ultraviolet[J]. International Journal of Thermophysics,2014,35(6):1401-1413.
- [22] XIA Changjie, REN Ming, WANG Bing, et al. Infrared thermography-based diagnostics on power equipment: state-of-the-art[J]. High Voltage,2020,6(3):387-407.
- [23] WANG X T, YU K, WU S X, et al. Esrgan: enhanced super-resolution generative adversarial networks[C]//15th European Conference on Computer Vision. Munich, Germany: Springer,2018: 63-79.
- [24] 谢军,刘云鹏,刘磊,等.局放信号自适应加权分帧快速稀疏表示去噪方法[J].中国电机工程学报,2019,39(21):6428-6438.
XIE Jun, LIU Yunpeng, LIU Lei, et al. A partial discharge signal denoising method based on adaptive weighted framing fast sparse representation[J]. Proceedings of the CSEE,2019,39(21): 6428-6438.
- [25] XUE Z H, MARCULESCU R. Dynamic multimodal fusion[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Vancouver, Canada: IEEE,2023: 2575-2584.
- [26] 周远翔,李永印,陈健宁,等.基于局部放电相位图谱和油中溶解气体信息融合的油纸绝缘缺陷识别方法[J].绝缘材料,2023, 56(12):43-53.
ZHOU Yuanxiang, LI Yongyin, CHEN Jianning, et al. Defect recognition method of oil-paper insulation based on information fusion of PRPD spectrum and dissolved gas data[J]. Insulating Materials,2023,56(12):43-53.
- [27] 谢庆,王春鑫,张雨桐,等.基于选择性标注与样本平衡的局部放电模式识别在线学习方法[J].中国电机工程学报,2025,45(2):778-791.
XIE Qing, WANG Chunxin, ZHANG Yutong, et al. An online learning method for pattern recognition of partial discharge based on selective labeling and sample balancing[J]. Proceedings of the CSEE,2025,45(2):778-791.
- [28] 张晓晓,宁环宇.基于ReliefF和HPO-SVM的变压器故障检测方法[J].电工技术,2023,17:1-5.
ZHANG Xiaohu, NING Huanyu. Transformer fault diagnosis method based on ReliefF and HPO-SVM[J]. Electric Engineering,2023,17:1-5.
- [29] 张弛,吴东,王伟,等.不平衡样本下基于变分自编码器预处理深度学习和DGA的变压器故障诊断方法[J].南方电网技术, 2021,15(3):68-74.
ZHANG C, WU D, WANG W, et al. Transformer fault diagnosis method based on variational auto-encoders preprocessing deep learning and DGA for unbalanced samples[J]. Southern Power System Technology,2021,15(3):68-74.

收稿日期:2024-06-19;修回日期:2024-08-30。

作者简介:

张若泉(2000-),男(汉族),湖北荆州人,硕士生,研究方向为电气设备的智能诊断和运维;

通信作者:冉慧娟(1979-),女(汉族),河北保定人,副教授,主要从事放电等离子体技术、电气设备智能诊断等的研究工作。