

基于时序自适应方法的配电网高阻接地故障检测模型

林系紊 林建新

(福建省新能源发电与电能变换重点实验室(福州大学电气工程与自动化学院), 福州 350108)

摘要 高阻接地故障(HIF)的故障电流幅值较小且易与开关事件混淆,导致HIF检测难度较大。现有研究主要基于固定时间窗口的数据进行检测,往往难以兼顾HIF检测准确性和快速性。鉴于此,本文提出一种时序自适应HIF检测模型。首先,将故障馈线的零序电流数据制成变长数据集;然后,结合代价敏感系数法,利用变长数据集训练门控循环单元(GRU)模型,使模型具有倾向性;最后,将两个倾向性相反的GRU模型集成为一个组合模型进行HIF检测。在PSCAD/EMTDC仿真平台的测试结果表明,本文所提HIF检测模型的检测准确率可以达到99.13%,且检测速度相对于固定时间窗口的方法提高了至少37.52%。本文方法通过延迟决策提高了HIF检测的准确性,并降低了因不及时检测导致伤害的风险。

关键词: 代价敏感; 时序自适应; 高阻接地故障(HIF); 变分模态分解(VMD)

Sequence-adaptive high impedance fault detection model

LIN Xiwen LIN Jianxin

(Fujian Key Laboratory of New Energy Generation and Power Conversion

(College of Electrical Engineering and Automation, Fuzhou University), Fuzhou 350108)

Abstract High impedance fault (HIF) is difficult to detect because of the low fault current amplitude and they can be easily confused with switching events. Existing HIF detection methods mainly rely on fixed time-window data. However, a fixed decision time often fails to balance the accuracy and speed of HIF detection. Thus, a sequence-adaptive HIF detection model is proposed in this paper. Firstly, zero-sequence current data of the faulty feeder are processed into variable-length training set. Then, a gated recurrent unit (GRU) model is trained based on variable-length data and cost-sensitive coefficient method to construct biased models. Two GRU models with opposite propensities are combined into an evaluation model. The test results on the PSCAD/EMTDC simulation platform show that the detection accuracy rate of this proposed model can reach 99.13%, and the detection speed is improved by at least 37.52% compared to the fixed time-window method. Delayed decision-making improves the accuracy of HIF detection and reduces the risk of harm.

Keywords: cost-sensitive; sequence-adaptive; high impedance fault (HIF); variational mode decomposition (VMD)

0 引言

中压配电网结构复杂,与居民区紧密相连。由于运行条件恶劣^[1],中压配电网容易发生高阻接地故障(high impedance fault, HIF)。当架空线路的导线断裂或下垂触碰到具有高阻抗特性的材料表面

(如沙土、草地和树枝等)时,就会发生高阻接地故障,其产生的燃弧和击穿现象^[2]会释放大量能量,可能引发火灾和人身触电事故^[3]。高阻接地故障的故障电流具有幅值小、非线性的特点,因此高阻接地故障相对于其他接地故障更难检测。

对于高阻接地故障,现有的一些传统HIF识别

方法主要基于 HIF 波形的零序分量^[4]、电流各次分量^[5]或波形特征^[6]、波形畸变^[7]来进行故障特征分析和判据构造,通过设置阈值或指标进行 HIF 识别。然而,传统方法对暂态特征的提取能力较弱,阈值和指标的选择灵活性差且极度依赖人工经验。当故障电阻较大时,故障电流的幅值非常小,仅依赖单一阈值很难区分 HIF 和正常运行工况。

近年来,人工智能和深度学习技术迅速发展。深度学习凭借强大的特征提取能力和对复杂情况的适应能力,被应用于配电网故障检测中。现有机器学习检测方法的主要思路为:首先对故障信号进行特征提取,然后将故障特征输入机器学习算法进行分类。特征提取方法包括离散小波变换(discrete wavelet transform, DWT)^[8]、连续小波变换^[9]、经验模态分解(empirical mode decomposition, EMD)^[6]、S 变换^[10]等。早期的机器学习检测算法主要基于浅层学习技术,如 K 最邻近算法(k-nearest neighbor, KNN)^[11]、支持向量机(support vector machine, SVM)^[12]、随机森林(random forest, RF)^[13]等。现有的检测方法主要采用固定时间延迟,这种方法并不适用于所有故障。在本文中,电流幅值较小的 HIF 被定义为临界故障,其他故障被定义为非临界故障。非临界故障的电流较大,因此热量积累更迅速,即使决策时间较短,也能实现快速检测。与非临界故障相比, HIF 电流与开关事件电流相似,因此临界故障的特征在早期并不明显,检测结果可靠性不足。此外, HIF 电流较弱,在短期内造成的损害有限,因而允许更长的检测时间,以便捕获更多故障信息,实现更精准的评估。综上所述,不同严重程度故障需要采用不同的检测时间,以确保故障检测的准确性和快速性。

为了解决上述问题,本文提出一种基于时序自适应方法和代价敏感系数(cost-sensitive coefficient, CSC)法的配电网高阻接地故障检测模型,该模型兼顾检测准确性和速度,可以根据故障的严重程度自适应地检测 HIF:对于特征明显的故障,采用短时间评估;对于特征不明显的故障,通过延长采样时间来提高检测准确性。

1 时序自适应高阻接地故障检测模型

1.1 门控循环单元模型

门控循环单元(gated recurrent unit, GRU)是传统循环神经网络(recurrent neural network, RNN)的

一个变体。GRU 可以缓解梯度消失问题,优化训练速度,降低过拟合的风险,从而提高 HIF 检测的准确性。在 HIF 的时序数据处理中,不同时刻的序列特征具有相关性,因此本文采用 GRU 作为基分类器来探索时间序列数据内部的相关性。

1.2 评估模型

单一检测模型的泛化性较弱,容易出现过拟合的情况,集成模型的检测准确性和泛化性比单一模型更优。为了区分临界情况和非临界情况,基于集成学习训练一个高可靠性评估模型。一个样本的可靠性评估结果基于基础模型预测结果重叠的部分。集成模型由两个倾向性模型组成,这两个倾向性模型是基于代价敏感系数方法,使用相同的训练集训练而成。其中,一个模型在预测时较保守,倾向于判定为故障情况,本文将其定义为保守评估模型(defensive evaluation model, DEM),另一个模型倾向于判定为正常运行工况,定义为激进评估模型(offensive evaluation model, OEM)。可靠性评估规则见表 1,其中 y_{DEM} 为保守评估模型的预测标签, y_{OEM} 为激进评估模型的预测标签。

表 1 可靠性评估规则

y_{OEM}	y_{DEM}	结果
故障	故障	故障(可靠)
非故障	非故障	非故障(可靠)
故障	非故障	不可靠
非故障	故障	不可靠

模型的倾向可以通过修改损失函数来调整。DEM 的损失函数 L_{DEM} 为

$$L_{DEM} = \sum_{n=1}^N \left[-w_D y^{(n)} \ln y'^{(n)} - (1 - y^{(n)}) \ln(1 - y'^{(n)}) \right] \quad (1)$$

式中: $y^{(n)}$ 为第 n 个训练样本真实运行状态; $y'^{(n)}$ 为第 n 个训练样本运行状态的预测概率; w_D 为 HIF 样本的权重,其值大于 1; N 为训练集样本的数量。HIF 样本的标签为 0,正常运行工况样本的标签为 1。

在式(1)中,故障样本在 DEM 中被赋予比非故障样本更高的权重。因此,DEM 对故障样本的拟合程度更强,更倾向于将一个样本判定为故障,此时正常运行工况的分类准确率会更高。

以相同方法构建 OEM 的损失函数 L_{OEM} 如式(2)所示。在 OEM 中,非故障样本被赋予更高的

权重。

$$L_{\text{OEM}} = \sum_{n=1}^N \left[-y^{(n)} \ln y^{(n)} - w_0 (1 - y^{(n)}) \ln (1 - y^{(n)}) \right] \quad (2)$$

式中, w_0 为正常运行工况样本的权重, 其值与 w_D 相同。

本文采用代价敏感系数来表示模型的倾向程度。CSC 的值与 w_D 和 w_0 相同。CSC 值越大, 两个模型的倾向性越强。

1.3 时序自适应模型

在 HIF 的早期阶段, 检测结果不够可靠, 通过延迟决策, 可以提取更多与故障相关的信息, 从而增强结果的可靠性。为了完成时序自适应评估过程, 本文构建一个时序自适应检测模型。时序自适应模型能够根据对应时间长度的数据自适应地评估样本的可靠性, 然后在每个决策周期输出结果。因此, 需要将时间序列数据处理成变长数据。如果判定结果足够可靠, 则输出该结果, 否则进入下一个采样周期。随着时间的推移, 电弧在故障点会积累大量的热量, 因此决策时间不可无限延长。为了避免因某些临界样本可靠性不足而导致决策时间过度延长, 本文设定一个时间阈值 T 。当采样时间达到阈值 T 时, 使用一个没有倾向性的公正的分类器来对剩余样本进行决策并输出结果。公正的分类器基于完整时间窗数据训练集进行训练。高阻接地故障时序自适应检测流程如图 1 所示。

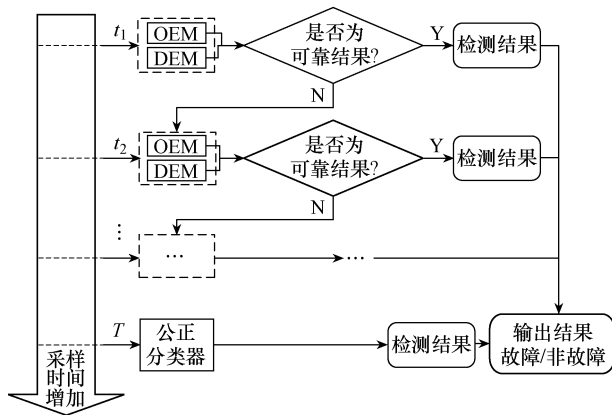


图 1 高阻接地故障时序自适应检测流程

在每个评估周期, 可变长度数据由相应的可靠性评估模型处理。非临界情况可以在早期阶段被检测出来。然而, 在早期时间步骤中, 临界情况的检测结果不够可靠, 通过延长临界样本的决策时间来提高检测结果的可靠性。此外, 通过使用并行结构,

可以显著减少计算时间并提高准确性。

每个评估模型通过并行计算集成一个 DEM 和一个 OEM。每个周期的 DEM 和 OEM 均基于对应周期的数据独立训练, 因此要为模型训练生成可变长度的训练集。可变长度数据生成过程如图 2 所示。

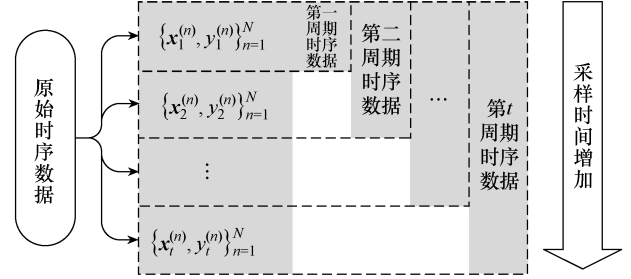


图 2 可变长度数据生成过程

图 2 中, t 为决策周期数, $x_t^{(n)}$ 和 $y_t^{(n)}$ 分别为第 t 决策周期第 n 个样本的数据矩阵和标签。从 HIF 发生到第一个决策周期的数据作为第一个周期的训练集。随着采样的进行, 第二个时间步骤的数据与第一个决策周期的训练数据结合, 作为第二个决策周期的训练数据。因此, 由 HIF 出现到第 t 个决策周期的数据作为最终的时序数据。最终, 训练出 $T-1$ 个 DEM、 $T-1$ 个 OEM 和一个公正分类器。将上述分类器集成到一个集成评估模型中, 构建完整的高阻接地故障时序检测模型。

2 数据处理

2.1 变分模态分解

本文采用 HIF 发生后的故障线路零序电流数据作为初始特征。故障早期的零序电流包含大量的时变信息。变分模态分解 (variational mode decomposition, VMD) 是处理非线性信号和挖掘时变信息的有力工具, 因此本文采用 VMD 来挖掘更多的时变信息。

电流数据被分解为 K 个本征模态函数 (intrinsic mode functions, IMFs)。通过引入拉格朗日乘数 $\lambda(t)$, 分解可以被视为一个无约束优化问题, 如式 (3) 所示。

$$L(\{u_k\}, \{\omega_k\}, \lambda(t)) = \alpha \sum_{k=1}^K \left\| \partial_t \left[\delta(t) + \frac{j}{\pi t} \right] * u_k(t) \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle \quad (3)$$

式中: $u_k(t)$ 和 ω_k 分别为第 k 个模态函数及其中心频

率； α 为二次惩罚因子，它可以增强函数的收敛性； ∂_t 表示求偏导； $\delta(t)$ 为狄拉克函数； $*$ 为卷积运算； $f(t)$ 为输入信号。

2.2 数据标准化

为了降低电流幅值对故障检测准确率的影响，将本征模态函数进行标准化处理，处理过程为

$$x = \frac{\hat{x} - \mu}{\sigma} \quad (4)$$

式中： \hat{x} 为初始特征； μ 为本征模态函数的平均值； σ 为本征模态函数的标准差。

3 仿真算例

3.1 HIF 电弧模型

Emanuel 模型广泛应用于高阻接地电弧模拟研究中，它可以很好地模拟高阻接地故障电弧的不对称现象和“零休”特性。Emanuel 模型结构如图 3 所示，该模型包含两个阻值不同的可变电阻器，以及两个反并联的直流电源和两个反并联的二极管。

两个可变电阻器用于模拟电弧的不对称特性，二极管和直流电源用于模拟“零休”特性。




图 3 Emanuel 模型结构

3.2 10kV 配电网仿真模型

为模拟 HIF 和正常运行工况，基于 PSCAD/EMTDC 平台构建一个中性点经小电阻接地的 10kV 配电网，系统的频率为 50Hz，采样频率为 4kHz。该系统的拓扑结构如图 4 所示，其中 r 为中性点等效零序电阻， L 为中性点等效零序电感， $F_1 \sim F_{18}$ 代表故障点，线路首端均安装有零序电流互感器。该 10kV 配电网线路参数见表 2，样本仿真参数见表 3。用于模型训练的初始特征是故障馈线的零序电流，通过零序电流 VMD 获得 4 个本征模态函数作为数据集。

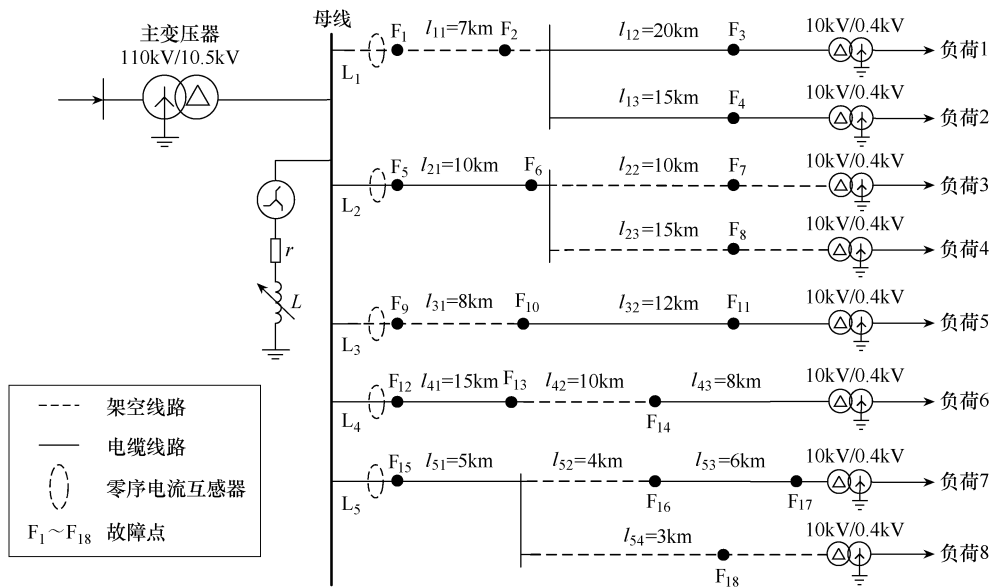


图 4 10kV 配电网仿真拓扑结构

表 2 线路参数

线路类型	序分量	电阻值/ (Ω/km)	电感值/ (mH/km)	电容值/ ($\mu\text{F}/\text{km}$)
架空线路	正序	0.170 0	1.200 0	0.009 7
	零序	0.230 0	5.480 0	0.006 0
电缆线路	正序	0.270 0	0.255 0	0.339 0
	零序	2.700 0	1.019 0	0.280 0

表 3 样本仿真参数

样本类型	初相位	故障电阻	仿真模型	样本数
高阻接地	$0^\circ, 30^\circ, 60^\circ, 90^\circ, 120^\circ, 150^\circ$	$300\Omega \sim 3\text{k}\Omega$	Emanuel	1 613
电容投切		三相电容器	690	
负荷投切			不平衡负载	690
励磁涌流			空载变压器	507

基于上述模型和参数,制作 3 500 个样本,包括 1 613 个 HIF 样本和 1 887 个正常运行工况样本。正常运行工况样本包含 690 个电容投切样本、690 个负荷投切样本和 507 个励磁涌流样本。数据集按照 3:1:3 的比例划分为训练集、验证集和测试集。

3.3 CSC 值的影响

为了确定最有效的 CSC 值,在训练过程中为模型配置不同的 CSC 值,根据模型的性能确定最优值。对于时序自适应高阻接地故障检测模型,其综合性能应基于准确性和检测时间进行评估。基于表 1 的可靠性评估规则,得到组合模型的可靠性评估结果见表 4,其中 TN、FP、FN、TP 均为确定样本,UC 为不确定样本。本文采用的性能评估指标包括不确定样本的比例 P_{UC} 、准确率 P_{acc} 、HIF 样本误判率 P_{FD} 和正常运行工况样本误判率 P_{FA} 。上述指标的计算方法如式(5)~式(8)所示。

表 4 组合模型可靠性评估结果

实际标签	预测标签		
	HIF	非故障	不确定
HIF	TN	FP	UC
非故障	FN	TP	

$$P_{UC} = \frac{U_C}{T_p + T_N + F_p + F_N + U_C} \times 100\% \quad (5)$$

$$P_{acc} = \frac{T_p + T_N}{T_p + T_N + F_p + F_N} \times 100\% \quad (6)$$

$$P_{FD} = \frac{F_p}{T_N + F_p} \times 100\% \quad (7)$$

$$P_{FA} = \frac{F_N}{T_p + F_N} \times 100\% \quad (8)$$

式中, T_N 、 F_p 、 F_N 、 T_p 和 U_C 分别为真负类、假正类、假负类、真正类和不确定样本的数量。

第一个周期(对应 3.75ms)不同 CSC 值下模型的性能如图 5 所示,是基于验证集数据得到。根据图 5,随着 CSC 值的增大,验证集中不确定样本的比例和确定样本的准确率都有所提高;当 CSC 值大于 6 时,虽然不确定样本的比例增加,但确定样本的准确率并未提高。不确定样本数量增加,模型会在更晚的周期做出决策,不利于故障的快速检测,因此为平衡准确性和快速性,本文取 CSC 值为 6。

3.4 仿真算例验证

本文所提时序自适应高阻接地故障检测模型中




图 5 不同 CSC 值下模型的性能

的 DEM、OEM 和公正分类器 3 种基分类器的网络结构均相同。每个基分类器由 3 个线性层、2 个 GRU 层和 1 个 softmax 输出层组成。GRU 层有 4 个神经元;第一个线性层有 4 个输入神经元、128 个输出神经元;第二个线性层有 128 个输入神经元、256 个输出神经元;第三个线性层有 256 个输入神经元、2 个输出神经元。使用 Adam 优化器对参数进行优化调整。对模型进行 300 轮训练。首个决策周期为 3.75ms,每个决策周期之间的时间间隔为 1.25ms,最大决策时间阈值 $T=10ms$ 。

将本文所提模型与几种固定观测窗口的人工智能检测模型进行对比,包括分布式梯度增强库(XGboost classifier, XGBC)^[14]、卷积神经网络(convolutional neural network, CNN)^[15]、分类提升(Catboost)^[16]和 GRU 模型,并检验其在 6.25ms 和 10ms 观测窗口下的表现。不同模型的检测性能见表 5,其中平均检测时间 t_{avg} 的计算方式为

$$t_{avg} = \frac{\sum_{n=1}^N t^{(n)}}{N} \quad (9)$$

式中, $t^{(n)}$ 为第 n 个样本的检测时间。

表 5 不同模型检测性能

模型	平均检测时间/ms	$P_{FD}/\%$	$P_{FA}/\%$	准确率/%
XGBC ($T=6.25ms$)	6.250	3.03	2.86	97.07
Catboost ($T=6.25ms$)	6.250	2.88	2.74	97.20
CNN ($T=6.25ms$)	6.250	2.27	2.02	97.87
GRU ($T=6.25ms$)	6.250	1.97	2.42	98.07
XGBC ($T=10ms$)	10.000	1.82	1.91	98.13
Catboost ($T=10ms$)	10.000	1.52	1.55	98.47
CNN ($T=10ms$)	10.000	1.37	1.55	98.53
GRU ($T=10ms$)	10.000	0.91	0.83	99.13
本文模型	3.905	0.15	1.43	99.13

本文的时序自适应方法共设置 6 个决策周期，每个周期的评估结果见表 6。

表 6 本文模型评估结果

时间窗/ms	不确定样本数	正确结果数	误判数	准确率/%
3.75	100	1 396	4	99.71
5.00	45	1 447	8	99.45
6.25	19	1 472	9	99.39
7.50	11	1 477	12	99.19
8.75	11	1 477	12	99.19
10.00	0	1 487	13	99.13

通过比较表 5 和表 6 可知，除了 GRU 模型外，本文所提模型比固定观测窗口的模型具有更高的准确率。与 6.25ms 固定时间窗的方法相比，本文模型的平均检测时间减少了 37.52%，与 10ms 的方法相比则减少了 60.95%，这是因为本文模型的检测时间可以根据 HIF 的严重程度进行自适应调整。本文模型可以及时检测出非临界故障，由于应用了高可靠性评估规则，本文模型可以减少对临界故障的误判。因此，通过模型结构的多维度改进，可以提升检测模型的整体性能。

4 结论

本文提出了一种时序自适应高阻接地故障检测模型，以平衡 HIF 检测的准确性和快速性。该模型能够自适应且准确地区分 HIF 和正常运行工况，其性能在 PSCAD/EMTDC 仿真平台中得到了验证。

1) 本文基于代价敏感系数方法训练了两种具有倾向性的 GRU 模型。通过修改特定类别的误分类损失，可以改变模型的倾向性。

2) 本文提出了一个组合评估模型，通过增加 CSC 值可以增强检测结果的可靠性。然而，这同样会导致不确定样本的比例增加。当 CSC 值设定为 6 时，该模型在 PSCAD/EMTDC 仿真平台中的准确率可以达到 99.13%。

3) 所提出的模型可以时序自适应地检测 HIF，在检测的准确性和速度之间取得了良好的平衡。

参考文献

[1] 姚福星, 苗世洪, 涂青宇, 等. 考虑强对流天气的乡镇配电网树线矛盾风险预警及优化处理[J]. 电工技术学报, 2023, 38(22): 6188-6203.

[2] 钟逸涵, 邓丰, 史鸿飞, 等. 基于动态电阻串联的高

阻接地故障精确建模[J]. 电工技术学报, 2024, 39(7): 2046-2059.

- [3] 李君, 何敏, 黄守道, 等. 基于相位差的小电阻接地有源配电网接地故障保护算法[J]. 电工技术学报, 2024, 39(23): 7418-7429.
- [4] LI Jie, LIU Yinliang, LI Chengxin, et al. An FTU-based method for locating single-phase high-impedance faults using transient zero-sequence admittance in resonant grounding systems[J]. IEEE Transactions on Power Delivery, 2022, 37(2): 913-922.
- [5] WANG Xiaowei, GAO Jie, WEI Xiangxiang, et al. Faulty feeder detection under high impedance faults for resonant grounding distribution systems[J]. IEEE Transactions on Smart Grid, 2023, 14(3): 1880-1895.
- [6] 唐钧益, 曾肖枫, 高伟. 一种基于经验模态分解和局部极大值点数的配电网高阻接地故障检测方法[J]. 电气技术, 2024, 25(6): 14-23.
- [7] 袁涛, 杨庆, 周桐, 等. 基于零序电流非线性畸变特性的弧光高阻接地初期故障辨识方法[J/OL]. 中国电机工程学报, 1-12 [2024-12-24]. <https://doi.org/10.13334/j.0258-8013.pcsee.232806>.
- [8] 刘科研, 詹惠瑜, 谭云耀, 等. 基于改进极限学习机的配电网高阻接地故障检测方案[J]. 电网技术, 2023, 47(5): 1886-1896.
- [9] 王康, 高伟, 杨耿杰. 基于高频分量的配电网高阻接地故障识别[J]. 电气技术, 2022, 23(2): 61-66, 87.
- [10] ZENG Xiaofeng, GAO Wei, YANG Gengjie. High impedance fault detection in distribution network based on S-transform and average singular entropy[J]. Global Energy Interconnection, 2023, 6(1): 64-80.
- [11] 刘炳南, 郭谋发, 陈永往. 基于 KNN 的配电网高阻接地故障识别[J]. 电气技术, 2019, 20(1): 18-23.
- [12] 张君琦, 杨帆, 郭谋发. 配电网高阻接地故障时频特征 SVM 分类识别方法[J]. 电气技术, 2018, 19(3): 37-43.
- [13] 肖启明, 郭谋发. 基于变分模态分解与图信号指标的配电网高阻接地故障识别算法[J]. 电气技术, 2021, 22(5): 50-55.
- [14] 柯亮, 李波, 廖凯, 等. 基于 XGBoost 的配电网高阻接地故障检测方法[J]. 电力系统保护与控制, 2024, 52(6): 88-98.
- [15] GUO Moufa, LIU Wenli, GAO Jianhong, et al. A data-enhanced high impedance fault detection method under

(下转第 19 页)

- ctions on Instrumentation and Measurement, 2023, 72: 6006010.
- [10] BOZORTH R M, WILLIAMS H J. Effect of small stresses on magnetic properties[J]. *Reviews of Modern Physics*, 1945, 17(1): 72-80.
- [11] CRAIK D J, WOOD M J. Magnetization changes induced by stress in a constant applied field[J]. *Journal of Physics D: Applied Physics*, 1970, 3(7): 1009-1016.
- [12] RUUSKANEN P, KETTUNEN P. Reversible component ΔB_r of the stress-induced change in magnetization as a function of magnetic field strength and stress amplitude[J]. *Journal of Magnetism and Magnetic Materials*, 1991, 98(3): 349-358.
- [13] JILES D C, DEVINE M K. The law of approach as a means of modelling the magnetomechanical effect[J]. *Journal of Magnetism and Magnetic Materials*, 1995, 140: 1881-1882.
- [14] MAYLIN M G, SQUIRE P T. The effects of stress on induction, differential permeability and barkhausen count in a ferromagnet[J]. *IEEE Transactions on Magnetism*, 1993, 29(6): 3499-3501.
- [15] JILES D C. Theory of the magnetomechanical effect[J]. *Journal of Physics D: Applied Physics*, 1995, 28(8): 1537-1546.
- [16] SMITH R C, DAPINO M J, BRAUN T R, et al. A homogenized energy framework for ferromagnetic hysteresis[J]. *IEEE Transactions on Magnetism*, 2006, 42(7): 1747-1769.
- [17] ZHANG Haipeng, WANG Zuoshuai, LONG Jiajie, et al. Research on the magnetomechanical coupling effect of ferromagnetic cavity based on improved Jiles-Atherton theory[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 6007210.
- [18] 李永建, 李宗明, 利雅婷, 等. 考虑磁-力耦合效应的混合磁滞模型研究[J]. *电工技术学报*, 2024, 39(22): 6941-6951.
- [19] 朱育莹, 李琳. 考虑各向异性模型参数应力依赖关系的改进 Sablik-Jiles-Atherton 磁滞模型[J]. *电工技术学报*, 2023, 38(17): 4586-4596.
- [20] 王旭, 张艳丽, 唐伟, 等. 旋转磁化下逆矢量 Jiles-Atherton 磁滞模型改进[J]. *电工技术学报*, 2018, 33(增刊 2): 257-262.
- [21] 李长云, 刘亚魁. 直流偏磁条件下变压器铁心磁化特性的 Jiles-Atherton 修正模型[J]. *电工技术学报*, 2017, 32(19): 193-201.
- [22] 陈利翔, 吴丹岳, 邵振国. 基于 J-A 动态磁滞模型的电流互感器谐波变换建模及实验验证[J]. *电气技术*, 2016, 17(8): 14-18, 23.

收稿日期: 2024-09-19

修回日期: 2024-12-01

作者简介

王作帅(1990—), 男, 博士, 高级工程师, 研究方向为电磁场防护与应用。

(上接第 12 页)

- imbalanced sample scenarios in distribution networks[J]. *IEEE Transactions on Industry Applications*, 2023, 59(4): 4720-4733.
- [16] 高伟, 何文秀, 郭谋发, 等. 基于实测不均衡小样本的配电网高阻接地故障检测方法[J/OL]. *高电压技术*, 1-11 [2024-12-24]. [https://doi.org/10.13336/j.1003-](https://doi.org/10.13336/j.1003-6520.hve.20231972)

6520.hve.20231972.

收稿日期: 2024-11-18

修回日期: 2024-12-03

作者简介

林系条(1999—), 男, 福建省福鼎市人, 硕士研究生, 主要研究方向为配电网高阻接地故障深度学习检测。