

利用深度度量学习提取差动电流非涌流特征的 变压器保护方法

何安阳, 焦在滨

(西安交通大学电气工程学院, 710049, 西安)

摘要: 为了避免励磁涌流对变压器故障识别的不利影响,提出一种利用改进深度度量学习提取差动电流非涌流特征的变压器智能保护方法。首先,受电力专家能够通过波形比较区分差动电流涌流部分和非涌流部分的启发,提出利用改进深度度量学习框架,以成对差动电流图像作为输入,最小化网络提取的正常差动电流与励磁涌流特征的差异以实现非涌流特征提取。其中,改进深度度量学习框架通过引入相似性鉴别损失,以避免经典深度度量学习损失中参数难以人工选取的问题。然后,基于提取的差动电流非涌流特征训练故障识别模块并构建变压器智能保护方法。最后,通过仿真及实验数据进行测试验证。结果表明:所提保护方法能够忽略励磁涌流干扰准确识别区内故障,对噪声、故障变压器合闸、电流互感器饱和、过励磁等场景均具有良好的适应性,其在各仿真场景下准确率均为 100%,在实验场景下准确率达到 99.20%,且满足变压器保护动作时间要求。

关键词: 变压器保护;差动电流;励磁涌流;深度度量学习

中图分类号: TM77 **文献标志码:** A

DOI: 10.7652/xjtuxb202605019 **文章编号:** 0253-987X(2026)05-0194-12

A Transformer Protection Method Based on Non-Inrush Feature Extraction of Differential Current Using Deep Metric Learning

HE Anyang, JIAO Zaibin

(School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To avoid the adverse effects of magnetizing inrush current on transformer fault identification, an intelligent transformer protection method based on non-inrush feature extraction of differential current using improved deep metric learning is proposed. First, inspired by the ability of power experts to distinguish between the inrush and non-inrush components of differential current through waveform comparison, the proposed method utilized an improved deep metric learning framework that takes paired differential current images as input and minimizes the feature differences between normal differential current and magnetizing inrush current, thereby achieving non-inrush feature extraction. The improved deep metric learning framework introduced a similarity discrimination loss to overcome the difficulty of manually selecting parameters in classical deep metric learning loss functions. Subsequently, based on the extracted non-inrush features of the differential current, a fault identification module was trained to construct the intelligent transformer protection method. Finally, the method was validated through simulations and experimental data. The results show

that the proposed protection method can accurately identify internal faults while ignoring magnetizing inrush interference, demonstrating good adaptability in scenarios such as noise, transformer energization under fault conditions, current transformer saturation, and over-excitation. The method achieves an accuracy of 100% in all simulated scenarios and 99.20% in experimental scenarios, while also meeting the action time requirements for transformer protection.

Keywords: transformer protection; differential current; inrush current; deep metric learning

电力变压器是电力系统中电能转换和传输的重要元件。目前,利用差动电流大小识别故障的电流差动保护被广泛用作电力变压器主保护。但由于变压器铁芯的非线性磁化特性,当变压器端电压突变时铁芯磁通增加以致饱和时,差动电流中会产生幅值数倍于额定电流的励磁涌流^[1],进而导致差动保护误动。因此,避免励磁涌流影响,准确识别区内故障是变压器保护的关键问题。

目前基于电气量的变压器保护方法可以分为3类。第1类方法通过提取励磁涌流与故障差动电流的不同特征以识别励磁涌流,如工业中通常采用基于二次谐波制动或间断角原理的涌流制动方法^[1],在检测到励磁涌流时将保护闭锁。此外,小波变换^[2]、数学形态学^[3]、泰勒级数^[4]、变分模态分解^[5]等信号处理方法被用于提取差动电流特征并构造涌流识别判据。但此类方法的整定常基于工程经验,缺乏理论支持,且涌流制动策略可能导致保护在涌流和故障同时存在时无法迅速动作,延长故障切除时间。第2类方法通过构建描述变压器状态的动态模型,通过模型参数辨识^[6-8]或模型匹配程度^[9]识别区内故障。此类方法受励磁涌流影响较小,但高度依赖构建模型的精确性,且可能需要额外的测量设备。第3类方法利用人工智能(AI)技术数据驱动地区分励磁涌流和内部故障。早期研究基于支持向量机(SVM)^[10]、回归模型^[11]、随机森林(RF)^[12]、人工神经网络(ANN)^[13]等机器学习算法,但这些方法仍需人工构造算法输入特征,存在特征难以选择和输入信息损失的缺陷。随着深度学习在电力系统故障检测领域得到广泛关注^[14],文献[15-18]利用卷积神经网络(CNN)、循环神经网络(RNN)等深度学习算法构建变压器智能保护方法,自动发掘差动电流信号中的故障特征,既能综合多故障特征,又无需人工特征选择和整定。但有限的变压工程数据难以满足深度学习对大量训练数据的需求,研究中通常采用仿真数据训练模型。而现场开放环境下的励磁涌流具有比封闭边界条件下的仿真数据更复杂的特征分布,导致基于仿真数据训练的模型在现

场应用中泛化能力受限。

事实上,尽管差动电流涌流特征复杂,但一个周期的差动电流中总是存在非涌流部分,电力专家能够通过差动电流的非涌流部分判断变压器是否故障。因此,可以设计特定的网络结构或训练流程,引导算法关注差动电流非涌流部分,构建抗励磁涌流干扰的变压器智能保护方法^[19-20]。文献[19]将差动电流涌流部分视作噪声,利用降噪自编码器滤除差动电流涌流部分再进行故障识别。文献[20]首先利用卷积网络区分差动电流的涌流和非涌流部分,再对非涌流部分进行参数辨识以检测故障。上述方法的性能依赖于逐采样点标签,但获取精细标签的时间和人力成本高昂,且人工标注过程的主观性可能在数据中引入标注噪声甚至偏差,因此其实际应用受到限制。

为了避免励磁涌流对变压器保护动作的不利影响,本文提出一种基于改进深度度量学习提取差动电流非涌流特征的变压器智能保护方法。首先,本文提出一种改进深度度量学习框架,以成对差动电流波形作为特征提取模块输入,通过最小化网络提取的正常差动电流与励磁涌流特征的差异,实现差动电流非涌流特征的提取。接着,基于训练好的非涌流特征提取模块构建抗涌流干扰的变压器智能保护方法。最后,通过不同仿真及实验数据验证本文提出方法的有效性。本文提出的保护方法不仅能够可靠识别故障,也可为深度学习在电力系统保护领域的应用提供有价值的参考。

1 基于改进深度度量学习的差动电流非涌流特征提取模块

1.1 基于波形对比的非涌流特征提取

图1为变压器不同运行状态下一个工频周期的差动电流。空载合闸时的励磁涌流与故障电流波形相似,易导致直接应用AI的保护方法出现误判。此外,现场电磁暂态环境下差动电流表现出更复杂的特征,使基于AI的保护方法的泛化能力受到考验。研究注意到,一个周期的差动电流中总是存在

非涌流部分,因此可以引导模型在识别故障时关注非涌流部分特征,以避免励磁涌流干扰。该思路本质上是利用先验知识减小模型的假设空间,从而降低算法对数据的要求,提高算法的准确性和鲁棒性^[21]。






图 1 变压器不同运行状态下的差动电流

Fig. 1 Differential current in different operating state

已有研究采用图 2(a)的方式,通过逐点的涌流/非涌流标签训练网络预测差动电流的不同部分。但实际上,电力专家并不需要依赖精细标签来识别差动电流的不同部分特征。由图 2 可见,通过对比励磁涌流与正常差流的波形可以直观地区分差动电流的不同部分:差动电流非涌流部分与正常运行时差动电流相似,而涌流部分相比正常运行时差动电流具有明显差异。受此启发,本文提出基于波形对比的非涌流特征提取方法,如图 2(b)所示。将成对差动电流(x_1, x_2)作为网络 f 的输入,以最小化提取的正常运行差流特征 $f(x_1)$ 与励磁涌流特征 $f(x_2)$ 的差为目标引导网络参数优化。当 $f(x_1)$ 与 $f(x_2)$ 具有相似的特征表示时,表明网络能够有效提取差动电流波形中与涌流无关的特征,具备抗励磁涌流干扰的能力。



(a) 基于逐点标签预测的非涌流特征提取



(b) 基于波形对比的非涌流特征提取

图 2 两种基于人工智能的差动电流非涌流特征提取思路

Fig. 2 Two AI-based differential current noni-inrush feature extraction frameworks

具体地,本文提出一种改进的深度度量学习方法训练特征提取模块实现差动电流非涌流特征提取。所提方法无需精细人工标注,且避免了度量学习对比损失中参数难以确定的问题。基于提取的差动电流非涌流特征,能够构造抗涌流干扰的变压器智能保护方法。

1.2 深度度量学习

度量学习是一种通过样本对比学习样本相似度的距离度量的机器学习方法^[22]。深度度量学习将度量学习与深度学习相结合,使深度学习的特征嵌入空间中相似样本(正样本对)聚集,不相似样本(负样本对)远离,从而学习具有可区分性的特征空间。对于给定样本集 $X = \{x_1, x_2, \dots, x_N\}$,经典的深度度量学习对比损失^[23]如下

$$L = \sum_{i,j} [(1 - y_{i,j})D_{i,j}^2 + y_{i,j} \max(0, m - D_{i,j})^2] \tag{1}$$

式中: m 为预设参数; $D_{i,j}$ 为样本 x_i 和 x_j 在特征空间的距离; $y_{i,j}$ 为样本对相似性标签, $y_{i,j} = 0$ 表示样本 x_i 和 x_j 为正样本对, $y_{i,j} = 1$ 表示 x_i 和 x_j 为负样本对。对比损失第一项约束正样本对,间距尽可能小,以提取正样本对共性特征。第二项约束负样本对,间距应当大于预设参数 m 以避免模型塌缩,即若所有样本被映射到相邻位置会导致提取的特征失去可区分性。相比预测标签的常规机器学习范式,深度度量学习通过成对样本的比较,能充分利用数据信息,有效挖掘数据内在结构特征,实现有可区分性的特征表征,且在数据较少的工程问题中表现出更好的适应性。

1.3 改进深度度量学习

度量学习对比损失中参数 m 的取值会影响模型性能,过大或过小的参数 m 会导致模型难以收敛或可区分性较差。目前尚缺乏相关理论指导如何在特征空间中选择合适的参数 m 。度量学习对比损失是通过分别约束正样本对和负样本对的距离实现特征空间中正样本对聚集而负样本对远离的特性,以保证提取特征的可区分性。这一特性也可以通过特征向量的差向量来表征:正样本对聚集对应其特征向量的差向量接近零向量,负样本对远离对应其特征向量的差向量为非零向量。因此,本文将度量学习提取特征的可分性问题转化为特征向量差向量的区分问题,提出如图 3 所示的改进深度度量学习框架。




图3 本文所提改进深度度量学习框架

Fig. 3 Framework of the proposed improved deep metric learning

改进深度度量学习框架包含特征提取模块和相似性鉴别模块。特征提取模块由两个参数共享的特征提取器构成。相似性鉴别模块是用于训练特征提取模块的辅助网络。训练阶段中样本对 (x_i, x_j) 被输入特征提取模块,分别提取输入图像的特征 $E(x_i)$ 、 $E(x_j)$ 。两个特征向量差向量的绝对值被输入相似性鉴别模块,输出样本对相似性预测结果 $\hat{y}_{i,j}$ 。以最小化式(2)~(4)的改进损失函数为目标训练特征提取模块

$$L_{\text{Improved}} = L_{\text{Dis}} + L_{\text{Sim}} \quad (2)$$

$$L_{\text{Dis}} = \sum_{i,j} (1 - y_{i,j}) D^2[E(x_i), E(x_j)] \quad (3)$$

$$L_{\text{Sim}} = -\mathbb{E}[\lg P(y_{i,j} | \text{abs}[E(x_i) - E(x_j)])] = -\sum_{i,j} [y_{i,j} \lg \hat{y}_{i,j} + (1 - y_{i,j}) \lg (1 - \hat{y}_{i,j})] \quad (4)$$

式中: L_{Improved} 为改进损失函数,由距离度量损失 L_{Dis} 和相似性鉴别损失 L_{Sim} 两部分组成; D 为特征向量欧氏距离; $\mathbb{E}[\cdot]$ 表示数学期望。 L_{Dis} 约束正样本对在特征空间的欧式距离尽可能小。 L_{Sim} 采用相似性鉴别模块的分类交叉熵损失。和常规的分类问题类似,当 L_{Sim} 最小化时,相似性鉴别模块能够基于样本对特征向量差向量准确区分正、负样本对,从而保证正、负样本对特征向量的差向量的可区分性。由于 L_{Dis} 约束确保正样本对特征向量差向量接近零向量,则当特征向量的差向量具有可区分性时,负样本对特征向量差向量显然远离零向量,因此负样本对特征向量会在特征空间中相互远离。综上,本文提出改进深度度量学习在无需参数 m 的情况下约束负样本相互远离,进而保证提取特征的可区分性。

1.4 差动电流非涌流特征提取模块

给定变压器差动电流样本集 $X = \{(x_i, z_i)\}_{i=1}^N$, 其中: x_i 为差动电流波形图像; z_i 为样本故障标签, $z_i = 0$ 表示无内部故障, $z_i = 1$ 表示存在内部故障; N 为样本总数。由 X 中样本两两组合获得差动电流

样本对集合 $X' = \{((x_i, x_j), y_{i,j}) | x_i, x_j \in X\}$, 样本对相似性标签 $y_{i,j}$ 为

$$y_{i,j} = \begin{cases} 0, & z_i = z_j \\ 1, & z_i \neq z_j \end{cases} \quad (5)$$

以 X' 作为训练集进行特征提取模块的训练。由于非故障样本包含正常运行时差动电流和励磁涌流,故障样本包含区内故障差动电流和在故障波形上叠加涌流特征的故障变压器合闸差动电流,因此上述样本对划分策略实际上是忽略了差动电流涌流干扰,只根据非涌流部分的相似性进行划分。基于改进深度度量学习框架训练的特征提取模块将学习正样本对的共性特征,从而实现差动电流非涌流特征提取。同时由于提取特征在负样本对间具有可区分性,确保了基于提取特征可以准确识别变压器内部故障。

具体地,特征提取模块采用卷积神经网络结构。使用线性整流函数(ReLU)作为激活函数。在卷积层间使用批标准化技术以优化模型收敛过程。考虑到硬件性能限制,模型中卷积层采用深度可分离卷积网络(DSCNN),从而降低算法的计算资源需求。深度可分离卷积将常规卷积分解为两步,逐通道卷积和逐点卷积。逐通道卷积对输入各通道分别进行卷积,一个滤波器仅提取输入特征图一个通道的特征。计算过程如下

$$F'_{c_{in}}(i, j) = \sum_{x=1}^K \sum_{y=1}^K [I_{c_{in}}(si + x, sj + y) \omega_{c_{in}}(x, y)] \quad (6)$$

式中: $I_{c_{in}}$ 和 $F'_{c_{in}}$ 分别为逐通道卷积输入和输出的第 c_{in} 个通道; $\omega_{c_{in}}$ 为和输入通道对应的滤波器权重; K 和 s 分别为滤波器大小及卷积步长; i, j 为特征图元素坐标。

逐点卷积应用 1×1 的滤波器组将逐通道卷积的结果在深度方向上线性组合及实现特征图通道数的拓展。计算过程如下

$$F_{c_{out}}(i, j) = \sum_{c_{in}=1}^C [F'_{c_{in}}(i, j) \omega_{c_{in}}^{c_{out}}(i, j)] \quad (7)$$

式中: $F_{c_{out}}$ 为逐点卷积输出的第 c_{out} 个通道; $\omega_{c_{in}}^{c_{out}}$ 为滤波器权重; C 为输入总通道数。相同输入输出尺寸下,深度可分离卷积层的计算量减少为常规卷积层的 $1/C_{out} + 1/K^2$ 倍,从而有效提高算法的计算效率。

2 变压器智能保护方法

2.1 故障识别

变压器保护的目标是可靠识别并切除区内故障。本文将特征提取模块提取的差动电流非涌流特

征输入具有全连接神经网络结构的故障识别模块,从而输出故障识别结果 $\tilde{z}$,如图 4 所示。




图 4 基于特征提取模块的故障识别过程

Fig. 4 Fault identification process based on feature extraction module

故障识别模块以最小化分类交叉熵为目标进行训练,损失函数如下

$$L_{\text{Fault}} = -\mathbb{E}[\lg P(z_i | E(x_i))] = -\sum_{i=1}^N [z_i \lg \tilde{z}_i + (1 - z_i) \lg (1 - \tilde{z}_i)] \quad (8)$$

式中: $\tilde{z}_i$ 为故障识别模块对样本 x_i 的故障识别结果。故障识别过程中,仅需要将单个差动电流图像输入特征提取模块孪生网络的一个分支,并由故障识别模块给出故障识别结果,不再使用相似性鉴别模块。该过程和常规的卷积分类网络相同,不存在额外的时间和计算资源消耗。

2.2 保护方法流程

首先,为快速启动故障识别过程,采用差动电流突变量启动保护,启动判据如下

$$|I_r(k) - I_r(k - N)| > I_{\text{set}} \quad (9)$$

式中: $I_r(k)$ 为第 k 个采样点处的变压器差动电流; N 为每周周期采样点数; I_{set} 为保护启动定值。由于提出的保护方法在正常运行场景下不会误动,因此保护启动定值 I_{set} 可以足够小以提高保护灵敏度。

接着,如图 5 所示进行数据处理,将保护启动后各相一个工频周期的差动电流标么值归一化并转化为 64×64 像素的二值图像。其中,双曲正切函数归一化如下

$$\tilde{I}_r^p = \tanh(I_r^p / I_N), p = A, B, C \quad (10)$$

式中: I_N 为变压器额定电流; I_r^p 为一相差动电流标么值。当输入在 $(-0.5, 0.5)$ 的范围时,双曲正切函数近似为恒等映射,输入超出该范围后则会被压缩。由于铁芯未饱和时差动电流幅值通常为额定电流的 $2\% \sim 5\%$,因此差动电流归一化后,涌流或故障产生的较大电流峰值将被压缩,而励磁涌流非涌流部分依旧与正常运行时差动电流波形接近,与区内故障差动电流区别显著,能够用于可靠识别变压器运行状态。此外,该归一化降低了饱和区域波形特征的复杂性,有利于提高算法泛化能力。




图 5 差动电流数据处理

Fig. 5 Data processing of differential current

最后,将各相差动电流图像输入模型,输出各相的故障识别结果。识别结果中若至少一相识别为区内故障,则发出跳闸信号,否则保护不动作。图 6 展示了本文提出的保护方法的完整流程。




图 6 保护方法流程图

Fig. 6 Protection method flowchart

3 仿真及实验分析

3.1 模型训练

3.1.1 训练数据

训练数据由图 7 所示的基于电磁暂态仿真软件 PSCAD 搭建的仿真系统获得。其中变压器为 3 台单相变压器按 YNd11 方式连接组成的三相双绕组变压器组,其变压器变比为 $230 \text{ kV}/11 \text{ kV}$,额定容量为 $40 \text{ MV} \cdot \text{A}$ 。一、二次侧漏感标么值均为 0.1 ,

铜耗标么值为 0.005。CT 为电流互感器。仿真场景及参数设置见附表 A1。仿真中采用两种变压器铁芯磁化特性见附表 A2。训练数据及下文测试数据采样频率均为 10 kHz。




图 7 基于 PSCAD 的仿真系统
Fig. 7 Simulation system based on PSCAD


3.1.2 训练过程

提出模型基于 PyTorch 深度学习框架实现,具体模型参数见表 1。模型训练分为两阶段。第一阶段基于改进深度度量学习框架训练特征提取模块。960 个训练集样本被组合为 460 800 组样本对。分层抽取其中 80% 的样本对用于训练,剩余 20% 的样本对作为验证集用于模型性能评估。第二阶段将特征提取模块参数固定并训练故障识别模块。训练集中 90% 的样本用于训练,剩余 10% 的样本用于模型性能评估。两阶段训练均采用 Adam 优化器,学习率设为 1×10^{-4} ,平滑常数分别为 0.900 和 0.999。根据图 8 所示模型训练过程中损失函数收敛情况,设置特征提取模块和故障识别模块训练迭代次数分别为 10 次和 30 次。


表 1 模型结构及参数

Table 1 Model structure and parameters

模块	层	结构
特征提取模块	Conv1	深度可分离卷积(16×3×3)+最大池化(2×2)
	Conv2	深度可分离卷积(16×3×3)+最大池化(2×2)
	Conv3	深度可分离卷积(16×3×3)+最大池化(2×2)
	Conv4	深度可分离卷积(16×3×3)+最大池化(2×2)
	Flatten5	特征展平层
	FC6	全连接层(1 024,64)
相似性鉴别模块	FC1	全连接层(64,64)
	FC2	全连接层(64,2)
故障识别模块	FC1	全连接层(64,64)
	FC2	全连接层(64,2)



(a)特征提取模块训练过程




(b)故障识别模块训练过程

图 8 模型训练过程

Fig. 8 Training process for the model

3.2 特征提取模块性能分析

为了验证改进深度度量学习框架是否能够避免涌流干扰并提取非涌流特征,采用 t 分布随机近邻嵌入(t -SNE)对训练好的模型进行可视化分析。 t -SNE是一种常用的特征降维方法,能够在低维空间中保留高维空间中样本的特征分布关系。图 9 为训练集原始样本和特征提取模块提取的特征向量经 t -SNE 降维后的结果。其中,星号为各类样本的聚类中心。由图 9 可见,原始数据特征中,由于励磁涌流和故障电流波形相似,这两类样本出现了大量混叠且聚类中心接近,可分性较差。而基于特征提取模块提取的特征,样本形成了和是否故障对应的两个明显的聚类。其中,空载合闸样本与正常运行样本聚类中心接近,与两种故障场景样本聚类中心远离。可视化结果表明:基于提出的改进深度度量学习框架,无需设计损失函数参数,提出特征提取模块即能够忽略涌流波形干扰,可有效提取差动电流的非涌流特征。



(a)原始特征降维结果 (b)提取特征降维结果

图 9 t -SNE 特征降维结果

Fig. 9 Dimensionality-reduced features by t -SNE

3.3 保护方法可靠性分析

变压器保护的基本要求是区内故障时可靠动作,发生区外故障或其他扰动时可靠不动作。本文提出准确率(R_A)、拒动率(R_M)和误动率(R_R)3 个指标来评估保护方法可靠性,计算公式分别为

$$R_A = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{FP} + N_{TN} + N_{FN}} \times 100\% \quad (11)$$

$$R_M = \frac{N_{FP}}{N_{FP} + N_{TN}} \times 100\% \quad (12)$$

$$R_R = \frac{N_{FN}}{N_{TP} + N_{FN}} \times 100\% \quad (13)$$

式中: N_{TP} 、 N_{TN} 分别为正确识别的故障和非故障样本数; N_{FP} 为被错误识别为故障的非故障样本数;

N_{FN} 为被错误识别为非故障的故障样本数。准确率衡量保护方法在所有场景下正确动作的概率;拒动率反映区内故障场景下没有正确动作的概率;误动率反映在非故障场景下错误动作的概率。准确率越高,拒动率和误动率越低说明保护方法可靠性越强。考虑到提出保护方法应当在不同场景下具有泛化能力,本文以仿真测试数据、含噪声数据、电流互感器饱和数据、不同电源电压-频率比(V/f)的过励磁数据、动模实验数据等与训练集变压器参数及场景不同的数据作为测试集来评估提出保护方法的性能。不同测试集中典型的差动电流波形如图 10 所示。表 2 为各数据集的测试结果。




图 10 不同测试集中差动电流波形

Fig. 10 Differential current waveform in test datasets

表 2 不同数据集测试结果比较

Table 2 Comparison of test results of different datasets															%
方法	仿真测试数据			含噪声数据			CT 饱和数据			过励磁数据		实验数据			
	R_A	R_F	R_R	R_A	R_F	R_R	R_A	R_F	R_R	R_A	R_F	R_A	R_F	R_R	
本文方法	100.00	0	0	100.00	0	0	100.00	0	0	100.00	0	99.20	0.65	1.06	
SHR	72.29	0	36.94	72.29	0	36.94	95.33	2.22	8.33	100.00	0	81.85	1.47	30.15	
SVM	88.75	45.00	0	88.33	46.67	0	72.00	46.67	0	100.00	0	84.68	24.75	0	
ANN	100.00	0	0	100.00	0	0	90.33	16.11	0	98.75	1.25	88.51	17.92	1.06	
CNN	100.00	0	0	100.00	0	0	95.33	7.78	0	96.25	3.75	98.39	2.27	0.53	
sCNN	100.00	0	0	100.00	0	0	89.00	16.67	2.50	93.75	6.25	95.78	6.80	0	

3.3.1 仿真测试数据

仿真测试数据通过图 7 的仿真系统获取,但采用了与训练集参数不同的变压器,其变压器变比为 230 kV/35 kV,额定容量 100 MV · A,变压器磁化特性见附表 A2,采用 YNd11、Yny0 两种接线形式。具体仿真场景及参数设置见附表 A3。由表 2 可见,本文提出保护方法在仿真测试数据集上准确率为 100%,误动率和拒动率均为 0。表明本文方法对于不同参数及连接方式的变压器均具有良好的泛化能力。

3.3.2 含噪声数据

含噪声数据集通过给仿真测试集数据增加谐波噪声和高斯白噪声获取,以验证提出方法在系统噪声环境下的可靠性。考虑到非线性负载在系统中引入的奇数次谐波的影响,根据相关标准在仿真测试集数据中增加占比为 2.2% 的 3 次谐波和占比为 1.4% 的 5 次谐波^[24]。此外,增加信噪比分别为 30、28、25 dB 的高斯白噪声以模拟信号采集时的随机噪声。由表 2 可见,所提方法在含噪声数据集上准确率为 100%,误动率和拒动率均为 0。表明本文方

法对系统噪声具有鲁棒性,在存在谐波噪声和高斯噪声的场景下能够准确识别变压器运行状态。

3.3.3 电流互感器饱和数据

现场保护装置的数据由 CT 测量获得。变压器故障或励磁涌流过程的暂态直流分量可能导致 CT 饱和,CT 二次侧电流无法正常传变,从而影响差动保护的可靠动作。在仿真系统中使用考虑磁滞的 Jiles-Atherton CT 模型采集电流数据,获取 CT 饱和场景下的测试数据。具体仿真场景及参数设置见附表 A4。由图 10 可见,当 CT 饱和时,差动电流出现明显的畸变,对差动保护的可靠性带来挑战。

表 2 结果表明,本文方法在 CT 饱和数据集上准确率为 100%,误动率和拒动率均为 0,不易受到 CT 饱和影响。

3.3.4 变压器过励磁数据

当系统电压升高或频率降低时,变压器处于过励磁运行状态,此时变压器铁芯磁通增大甚至饱和,差动电流中也会出现偏向时间轴两侧的双向励磁涌流,如图 10 所示。变压器纵差保护在过励磁时不应误动作。因此,调整仿真系统电源电压-频率比分别为 1.1、1.2、1.3 和 1.4,获取过励磁场景下的差动电流数据。由表 2 可见,本文方法在变压器过励磁数据集上准确率为 100%,误动率为 0。测试结果表明,本文方法不会在过励磁场景下误动,符合相关技术规程要求。

3.3.5 实验数据

搭建图 11 所示的动模实验系统以模拟现场变压器更复杂的电磁暂态环境。其中,变压器为 3 台单相模拟变压器以 YNd11 方式连接成的三相双绕组变压器组,其变压器变比为 380 V/220 V,额定容量为 6 kV·A。实验测得其短路电压为 11.2%,短路损耗占额定容量的 1.0%;空载电流 $i_0 = 1.17\%$,空载损耗 p_0 占额定容量的 0.7%。附表 A5 给出了实验数据集的运行场景及参数设置。由表 2 可见,本文方法在实验数据集上准确率为 99.20%,拒动率为 0.65%,误动率为 1.06%。测试结果表明,本文方法具有良好的泛化能力,仅通过仿真数据训练


的模型在实际场景中受涌流影响较小,表现出较高的准确率。

3.4 方法性能比较

为了验证提出方法的优势,表 2 还将本文提出保护方法与基于二次谐波制动的涌流闭锁方法(SHR)及支持向量机(SVM)、人工神经网络(ANN)、常规卷积神经网络(CNN)、深度可分离卷积神经网络(DSCNN)等基于 AI 的智能保护方法进行比较,对照方法的具体设置见附表 A6。对照 AI 方法和本文提出的方法采用同样的训练集,以最小化故障分类损失为目标进行训练。

3.4.1 与二次谐波制动方法比较

如图 12 所示,涌流和故障同时存在的场景下,差动电流中含有的大量二次谐波分量,二次谐波制动将保护闭锁,故障无法迅速切除。因此,在仿真测试数集、CT 饱和数据集和实验数据集上,基于二次谐波制动的变压器保护方法表现出较高的拒动率,分别为 36.94%、8.33% 和 30.15%。相反,本文提出的保护方法在这些数据集下拒动率仅为 0、0 和 1.06%,说明本文提出保护方法能够在涌流和故障同时存在的场景下实现故障切除。



(a)故障变压器空载合闸 (b)区内故障且 CT 饱和

图 12 二次谐波制动保护方法错误动作场景

Fig. 12 Incorrect operation scenes of SHR-based protection

3.4.2 与其他基于 AI 保护方法的比较

相比其他基于 AI 保护方法,本文提出方法表现出更强的准确性和泛化性。采用非神经网络结构的 SVM 特征表征能力有限,受励磁涌流干扰明显,在各数据集上误动率均高于 20%。采用浅层网络的 ANN 泛化能力有限,因此在具有更复杂特征分布的实验数据集上准确率仅为 88.51%。基于深度学习的 CNN 和 sCNN 在实验数据上准确率均大于 95%。但在出现双向涌流特征的 CT 饱和场景下,CNN 和 sCNN 仍受到涌流干扰,误动率分别为




图 11 动模实验系统

Fig. 11 Dynamic simulation experimental system

7.78%和 16.67%。而本文提出保护方法通过提取非涌流特征,忽略涌流影响,在所有数据集上均具有最高的准确率。本文方法在所有仿真场景下准确率均为 100%,在实验数据上准确率达到 99.20%。同时,相比基于精细标签监督实现的非涌流特征提取,本文方法的性能实现无需高成本的标签标注。

图 13 给出不同保护方法在测试集上的受试者工作特征(ROC)曲线。ROC 曲线展示了模型在不同分类阈值下的性能,ROC 曲线下的面积 A_{UC} 越接近 1,表明模型的准确率和泛化性越高。由图 13 可见,本文方法的 ROC 曲线在其他方法的 ROC 曲线之上,且具有最大的 A_{UC} ,说明相比其他基于 AI 的保护方法,本文方法具有更优越的性能。




图 13 不同保护方法的 ROC 曲线
Fig. 13 ROC curves of different methods

3.5 运行效率及时间实验分析

为了评估深度可分离卷积模型对模型计算资源及运行效率的提升效果,本文采用模型参数量衡量网络计算资源需求,采用模型总浮点运算次数衡量神经网络的计算复杂度。采用表 1 的特征提取器结构,常规卷积神经网络参数量为 98.43×10^3 ,浮点运算次数为 9.47×10^6 ,而深度可分离卷积神经网络参数量为 70.44×10^3 ,浮点运算次数为 1.91×10^6 。说明采用深度可分离网络能有效降低模型参数和计算复杂度,提升网络的运行效率。

进一步地,在图 14 所示的 NVIDIA Jetson AGX Xavier 开发者组件上部署提出的变压器保护方法以测试其运行时间是否满足实际运行需求。NVIDIA Jetson AGX Xavier 是具有强大计算能力的工业级模组,其搭载了具有高计算性能的 NVIDIA Volta GPU,可以作为人工智能算法边缘计算设备集成进保护装置。




图 14 运行时间测试平台
Fig. 14 Platform for runtime test

表 3 为所提故障识别算法在所有测试样本上统计的运行时间。可以看出,算法故障识别过程平均用时 1.94 ms,具有实际应用的潜力。包含采样时间的完整保护方法的平均识别用时为 25.26 ms。最极端情况下保护方法也能在 30 ms 内完成动作,满足变压器差动保护的動作时间要求^[25]。

表 3 故障识别算法运行时间

Table 3 Runtime of the fault identification algorithm ms			
类别	最小时间	最大时间	平均时间
图像处理	3.50	4.28	3.32
故障识别	1.09	4.54	1.94
合计	4.59	8.82	5.26

4 结 论

(1)所提变压器智能保护方法能够忽略励磁涌流干扰,可靠识别变压器区内故障。所提保护方法在故障变压器合闸、系统噪声、CT 饱和、变压器过励磁等场景干扰下能够准确识别变压器运行状态。其在各仿真场景下准确率均为 100%,在实验场景下准确率达到 99.20%,且运行时间满足变压器保护要求,具有良好的工程应用前景。

(2)相比基于涌流闭锁策略的传统保护方法,本文方法能够在涌流和故障同时存在的场景下有效识别故障,避免涌流闭锁导致的故障延时切除。相比支持向量机、人工神经网络、常规卷积神经网络、常规深度可分离卷积神经网络等其他基于 AI 的保护方法,本文方法通过波形对比的思路实现差动电流非涌流特征的提取,无需高成本的精细人工标签,具有更强的准确性和泛化能力。

本文对深度度量学习框架的改进解决了经典度量学习对比损失函数人工参数选取的问题,提高了深度度量学习的适应性和实用性,对其他电力系统故障识别问题也具有借鉴意义。

参考文献:

[1] 张保会,尹项根. 电力系统继电保护 [M]. 2 版. 北京:

- 中国电力出版社, 2010.
- [2] 李晓. 基于小波变换的励磁涌流识别方法研究 [J]. 电工技术, 2022(6): 144-145.
- LI Xiao. Research on inrush current identification method based on wavelet transform [J]. Electric Engineering, 2022(6): 144-145.
- [3] 张运驰, 高厚磊, 杜士昌. 基于综合形态算法的变压器励磁涌流识别方法 [J]. 电力系统自动化, 2021, 45(24): 165-173.
- ZHANG Yunchi, GAO Houlei, DU Shichang. Identification method of transformer magnetizing inrush current based on comprehensive morphological algorithm [J]. Automation of Electric Power Systems, 2021, 45(24): 165-173.
- [4] 宋九渊, 符玲, 熊思宇, 等. 基于二阶泰勒系数的励磁涌流识别方法 [J]. 中国电机工程学报, 2020, 40(3): 1020-1029.
- SONG Jiuyuan, FU Ling, XIONG Siyu, et al. Magnetizing inrush current identification method based on second-order Taylor derivative [J]. Proceedings of the CSEE, 2020, 40(3): 1020-1029.
- [5] 赵学文, 付泽宇, 李乐, 等. 基于 VMD 和 PSO-SVM 模型的和应涌流识别 [J]. 电工技术, 2021(19): 30-34.
- ZHAO Xuwen, FU Zeyu, LI Le, et al. Sympathetic inrush current identification based on VMD and PSO-SVM model [J]. Electric Engineering, 2021(19): 30-34.
- [6] 焦在滨, 马涛, 屈亚军, 等. 基于励磁电感参数识别的快速变压器保护 [J]. 中国电机工程学报, 2014, 34(10): 1658-1666.
- JIAO Zaibin, MA Tao, QU Yajun, et al. A novel excitation inductance-based power transformer protection scheme [J]. Proceedings of the CSEE, 2014, 34(10): 1658-1666.
- [7] 潘超, 金明权, 蔡国伟, 等. 基于漏感辨识的变压器交直流混合运行保护方法 [J]. 电工技术学报, 2018, 33(4): 771-780.
- PAN Chao, JIN Mingquan, CAI Guowei, et al. Protection for transformer in AC-DC hybrid operation mode based on leakage inductance identification [J]. Transactions of China Electrotechnical Society, 2018, 33(4): 771-780.
- [8] 孙德娟, 孙士云, 范小红, 等. 基于励磁电感计算的双馈风电场送出变差动保护 [J]. 电工技术学报, 2020, 35(2): 395-407.
- SUN Dejuan, SUN Shiyun, FAN Xiaohong, et al. Doubly-fed wind farm outgoing transformer differential protection based on excitation inductance calculation [J]. Transactions of China Electrotechnical Society, 2020, 35(2): 395-407.
- [9] FAN Rui, LIU Yu, MELIOPOULOS S, et al. Comparison of transformer legacy protective functions and a dynamic state estimation-based approach [J]. Electric Power Systems Research, 2020, 184: 106301.
- [10] 黄永红, 马锋, 沈敏. 基于最小二乘支持向量机的变压器励磁涌流识别方法研究 [J]. 电力系统保护与控制, 2010, 38(23): 93-96.
- HUANG Yonghong, MA Feng, SHEN Min. Research of magnetizing inrush current identification method based on LS-SVM [J]. Power System Protection and Control, 2010, 38(23): 93-96.
- [11] 丁晓兵, 周红阳, 黄佳胤, 等. 基于逻辑斯蒂回归的变压器涌流识别 [J]. 电力系统及其自动化学报, 2020, 32(12): 77-84.
- DING Xiaobing, ZHOU Hongyang, HUANG Jiayin, et al. Transformer inrush current identification based on logistic regression [J]. Proceedings of the CSU-EP-SA, 2020, 32(12): 77-84.
- [12] OZGONENEL O, KARAGOL S. Power transformer protection based on decision tree approach [J]. IET Electric Power Applications, 2014, 8(7): 251-256.
- [13] 李宗博, 焦在滨, 何安阳. 基于等效磁化曲线智能识别的变压器保护原理 [J]. 电工技术学报, 2020, 35(7): 1464-1475.
- LI Zongbo, JIAO Zaibin, HE Anyang. Equivalent magnetization curve intelligent recognition based transformer protection [J]. Transactions of China Electrotechnical Society, 2020, 35(7): 1464-1475.
- [14] 俞小勇, 秦丽文, 桂海涛, 等. 新一代人工智能在配电网智能感知与故障诊断中的应用 [J]. 南方电网技术, 2022, 16(5): 34-43.
- YU Xiaoyong, QIN Liwen, GUI Haitao, et al. Application of new generation artificial intelligence technology in intelligent sensing and fault detection of power distribution network [J]. Southern Power System Technology, 2022, 16(5): 34-43.
- [15] AFRASIABI S, AFRASIABI M, PARANG B, et al. Integration of accelerated deep neural network into power transformer differential protection [J]. IEEE Transactions on Industrial Informatics, 2020, 16(2): 865-876.
- [16] MURUGAN S K, SIMON S P, EAPEN R R. A novel

signal localized convolution neural network for power transformer differential protection [J]. IEEE Transactions on Power Delivery, 2022, 37(2): 1242-1251.

[17] AFRASIABI S, AFRASIABI M, PARANG B, et al. Fast GRNN-based method for distinguishing inrush currents in power transformers [J]. IEEE Transactions on Industrial Electronics, 2022, 69(8): 8501-8512.

[18] 张国栋, 刘凯, 蒲海涛, 等. 基于长短时记忆神经网络的励磁涌流与故障电流识别方法 [J]. 上海交通大学学报, 2024, 58(5): 730-738.

ZHANG Guodong, LIU Kai, PU Haitao, et al. Identification of inrush current and fault current based on long short-term memory neural network [J]. Journal of Shanghai Jiao Tong University, 2024, 58(5): 730-738.

[19] LI Zongbo, JIAO Zaibin, HE Anyang, et al. A denoising-classification neural network for power transformer protection [J]. Protection and Control of Modern Power Systems, 2022, 7(1): 52.

[20] LIN Zexuan, YANG Songhao, ZHANG Yubo, et al. A data-aided power transformer differential protection without inrush blocking module [J]. IEEE Transactions on Power Delivery, 2023, 38(3): 2000-2010.

[21] 韩笑, 郭剑波, 蒲天骄, 等. 电力人工智能技术理论基础与发展展望: (一) 假设分析与应用范式 [J]. 中国电机工程学报, 2023, 43(8): 2877-2890.

HAN Xiao, GUO Jianbo, PU Tianjiao, et al. Theoretical foundation and directions of electric power artificial intelligence: (I) hypothesis analysis and application paradigm [J]. Proceedings of the CSEE, 2023, 43(8): 2877-2890.

[22] KAYA M, BILGE H S. Deep metric learning: a survey [J]. Symmetry, 2019, 11(9): 1066.

[23] 刘冰, 李瑞麟, 封举富. 深度度量学习综述 [J]. 智能系统学报, 2019, 14(6): 1064-1072.

LIU Bing, LI Ruilin, FENG Jufu. A brief introduction to deep metric learning [J]. CAAI Transactions on Intelligent Systems, 2019, 14(6): 1064-1072.

[24] 国家技术监督局. 电能质量 公用电网谐波: GB/T 14549—1993 [S]. 北京: 中国标准出版社, 1993.

[25] 中华人民共和国国家质量监督检验检疫总局, 中国国家标准化管理委员会. 变压器保护装置通用技术要求: GB/T 14598.300—2017 [S]. 北京: 中国标准出版社, 2017.

(编辑 亢列梅)

附录 A:

表 A1 训练数据运行场景及参数

Table A1 Operating scenarios and parameters of training data

场景	参数	数值
正常运行	启动时间/s	0.500,0.501,⋯,0.519
	铁耗标幺值	0.05,0.06,0.08
	数量	120
空载合闸	合闸时间/s	0.500,0.501,⋯,0.519
	铁耗标幺值	0.05,0.06,0.08
	数量	120
区内故障	故障时间/s	0.500,0.501,⋯,0.519
	故障匝数	2,3,5
	占比/%	
	铁耗标幺值	0.05,0.06,0.08
	数量	360
	故障时间/s	0.500,0.501,⋯,0.519
故障变压器合闸	故障匝数	2,3,5
	占比/%	
	铁耗标幺值	0.05,0.06,0.08
	数量	360

表 A2 仿真变压器磁化特性

Table A2 Magnetization characteristics of simulated transformers

训练集磁化曲线 1		训练集磁化曲线 2		测试集磁化曲线	
电压标幺值	电流标幺值	电压标幺值	电流标幺值	电压标幺值	电流标幺值
0	0	0	0	0	0
1.000	2.5×10^{-3}	0.60	6.0×10^{-3}	0.324	1.77×10^{-3}
1.100	5.0×10^{-3}	1.00	0.01	0.612	4.88×10^{-3}
1.200	0.02	1.10	0.02	0.825	9.81×10^{-3}
1.250	0.04	1.24	0.04	1.000	0.020
1.320	0.20	1.512	0.20	1.173	0.0652
1.535	1.00	1.941	0.50	1.360	0.602
3.700	10.00	2.655	1.00	1.497	1.244

表 A3 仿真测试数据运行场景及参数

Table A3 Operating scenarios and parameters of simulation test data

场景	参数	数值
正常运行	启动时间/s	0.500,0.501,⋯,0.519
	铁耗标么值	0.05,0.06,0.07
	数量	120
空载合闸	合闸时间/s	0.500,0.501,⋯,0.519
	铁耗标么值	0.05,0.06,0.07
	数量	120
区内故障	故障时间/s	0.500,0.501,⋯,0.519
	故障匝数	2,3,5
	占比/%	
	铁耗标么值	0.05,0.06,0.07
	数量	360
故障变压器 合闸	故障时间/s	0.500,0.501,⋯,0.519
	故障匝数	2,3,5
	占比/%	
	铁耗标么值	0.05,0.06,0.07
	数量	360

表 A4 CT 饱和数据运行场景及参数

Table A4 Operating scenarios and parameters of CT saturation data

场景	参数	数值
区外故障	故障时间/s	0.500,0.501,⋯,0.519
	故障类型	单相接地故障,相间故障, 三相故障
	数量	60
空载合闸	合闸时间/s	0.500,0.501,⋯,0.519
	铁耗标么值	0.05,0.06,0.07
	数量	120
区内故障	故障时间/s	0.500,0.501,⋯,0.519
	故障匝数	2,3,5
	占比/%	
	铁耗标么值	0.05,0.06,0.07
	数量	120

表 A5 实验数据运行场景及参数

Table A5 Operating scenarios and parameters of experimental data

场景	参数	数值
正常运行	负荷容量/%	100,75,50,25
	数量	100
区外故障	故障类型	单相接地故障,相间故障
	接地电阻/ Ω	25,50
	负荷容量/%	100,75,50,25
	数量	72
空载合闸	合闸时间	随机选择
	负荷容量/%	100,75,50,25
	数量	137
区内故障	故障匝数	2.3,4.5,9.1
	占比/%	
	故障位置	原边,副边
	接地电阻/ Ω	25,50
	合闸时间	随机选择
	数量	110
故障变压器 合闸	故障匝数	2.3,4.5,9.1
	占比/%	
	故障位置	原边,副边
	合闸时间	随机选择
	数量	79

表 A6 对照方法的算法设置

Table A6 Algorithm settings of baseline methods

方法	算法设置
SHR	二次谐波制动系数为 0.15
SVM	核函数采用径向基函数,参数 $\gamma=0.1$
ANN	隐含层包括 3 层分别含 512、256、64 个神经元; 输出层含 2 个神经元
CNN	与本文方法网络结构相同,采用常规卷积层
sCNN	与本文方法网络结构相同