

DOI: 10.13382/j.jemi.B2104013

基于交叉自编码网络的故障漏电电流分离方法

杨帆¹ 宿磊¹ 沈煜¹ 徐丙垠^{2,3} 薛永端⁴ 王玮² 邹国锋²

(1. 国网湖北省电力有限公司电力科学研究院 武汉 430077; 2. 山东理工大学电气与电子工程学院 淄博 255049;
3. 山东科汇电力自动化股份有限公司 淄博 255087; 4. 中国石油大学(华东)新能源学院 青岛 266580)

摘要:从剩余电流中分离故障支路电流是典型的新数据预测问题,目前故障支路电流分离方法匮乏且准确度较低。本文提出一种小规模交叉自编码深度网络模型构建策略,并将其用于剩余电流中准确分离故障支路电流。首先,在剩余电流和故障漏电电流数据集上分别独立训练自动编码网络;然后,截取剩余电流数据集的特征编码模块和故障漏电电流数据集的特征解码模块,将两者级联构成交叉自编码网络;最后,采用成对剩余电流-故障漏电电流数据微调训练交叉自编码网络,获得剩余电流到故障漏电电流的分离映射模型。误差阈值设置为5时,分离平均准确率达77.33%;误差阈值为15时,平均准确率达88.67%,能较好地实现了故障漏电电流分离,为智能化电流分离式剩余电流保护器设计提供了技术支持。

关键词:故障漏电电流;电气火灾;触电;深度学习;自动编码网络;交叉融合

中图分类号: TM72; TN0 **文献标识码:** A **国家标准学科分类代码:** 470.40

Fault leakage current separation method based on cross auto encoder network

Yang Fan¹ Su Lei¹ Shen Yu¹ Xu Bingyin^{2,3} Xue Yongduan⁴ Wang Wei² Zou Guofeng²

(1. Electric Power Research Institute of State Grid Hubei Electric Power Co., Ltd., Hubei, Wuhan 430077, China;
2. School of Electrical and Electronic Engineering, Shandong University of Technology, Zibo 255049, China;
3. Shandong Kehui Power Automation Co., Ltd., Zibo 255087, China;
4. College of New Energy, China University of Petroleum (East China), Qingdao 266580, China)

Abstract: Accurate separation of fault leakage current from residual current was a typical new data prediction problem, the methods of fault leakage current separation were scarce and the accuracy was low. In this paper, we proposed a construction strategy of small scale cross auto encoder deep network, and applied the model to separate fault leakage current from the residual current. First, two independent auto encoder networks were learned on the residual current dataset and the fault leakage current dataset respectively. Then, the feature encoding module of residual current and the feature decoding module of fault leakage current were cascaded to form a cross auto encoder network. Finally, separation mapping model of residual current to fault leakage current was obtained by using the paired residual current and fault leakage current for fine-tuning training of the cross-auto encoder network. Experiment results showed that the average separation accuracy was 77.33% when the error threshold was set to 5. When the error threshold was 15, the accuracy was up to 88.67%. Obviously, the method can realize the separation of fault leakage current and provide the technical support for the design of intelligent current separation residual current protection device.

Keywords: fault leakage current; electrical fire; electric shock; deep learning; sparse auto encoder network; cross fusion

0 引言

低压电网的故障漏电是引发电气火灾和人身触电的重要原因^[1-2]。剩余电流保护装置(residual current protection device, RCD)作为漏电保护的主要措施而被广泛采用,现行 RCD 多采用剩余电流幅值作为防护动作的唯一依据^[3],由于受到系统正常剩余电流的干扰,使 RCD 在识别故障支路电流上效果欠佳,存在负荷投运、恶劣天气时易出现误动作,在发生接地漏电和触电事故时出现拒动作的问题,使 RCD 的正确投运率和可靠性大大降低。

为克服系统正常剩余电流影响,提高保护动作灵敏度,研究者提出了脉冲型 RCD、鉴幅鉴相型 RCD 和电流分离式 RCD 等解决方法^[2]。其中,电流分离式 RCD 是通过总的剩余电流分离出故障漏电电流,然后直接基于故障漏电电流幅值与 RCD 整定值比较,判定 RCD 是否需要执行防护动作。电流分离式 RCD 能消除动作死区,实现 RCD 可靠动作,因此已成为剩余电流保护技术领域的研究热点之一。

电流分离式 RCD 的技术难点是如何从总剩余电流中准确分离出故障漏电电流,已有分离方法可归纳为数学变换法和机器学习法两类。数学变换方法是通过一种数学变换或分解算法将捕获的时域电流信号变换到新空间,然后在新空间中执行特征参数提取或频谱分析,从而实现故障漏电电流检测。其中,主要涉及小波包变换和混沌理论^[4-5]、局部均值分解算法^[6-7]、Hilbert-Huang 变换法^[8]、半波真有效值计算法^[9]、自适应滤波算法^[10]等。机器学习法是通过时域电流信号训练集学习一种机器学习模型,然后将测试电流信号作为模型输入数据,可直接实现从剩余电流中分离检测漏电电流。该方法的代表性算法包括 BP 神经网络法^[5,11]、最小二乘支持向量机法^[12]、支持向量机(SVM)-神经网络融合算法^[13-14]等。尽管故障漏电电流分离算法已有较多研究,但电流分离式 RCD 对故障漏电信号分离精度的要求较高,因此需要借鉴先进机器学习算法拓宽故障漏电电流分离的技术思路,提升电流分离的准确度和可靠性。

深度学习作为一种主流机器学习方法,得到学术界和工业界广泛关注,在电力设备和机械故障诊断中得到较多应用^[15-18],并取得了优异效果。自动编码器(autoencoder, AE)^[19]作为一种经典无监督深度网络模型,在特征提取和数据重构领域得到广泛应用,但该模型不具有数据分离和未知数据预测功能。因此,基于自动编码器的重构功能,设计一种新的网络构建策略用于实现关键数据分离或新数据预测具有重要的理论意义和实用价值。

综上所述,本文借鉴自动编码器和迁移学习思想,提出一种交叉自编码网络模型构建策略,并将其用于剩余电流中分离故障漏电电流,实现关键数据分离和新数据预测。首先,基于采集的剩余电流和故障漏电电流数据集,分别独立训练堆叠稀疏自动编码网络。然后,将剩余电流数据对应的特征编码模块与故障漏电电流数据对应的特征解码模块交叉级联,构成交叉自编码网络。该交叉网络同时具备了剩余电流的特征提取能力和故障漏电电流的重构能力,是实现从剩余电流分离故障漏电电流的基础架构。最后,采用成对的剩余电流和故障漏电电流数据对交叉自编码网络执行微调训练,达到优化基础映射模型的效果,获得故障漏电电流分离模型。测试试验表明,在误差阈值设置为 5 时,该分离模型的平均预测准确率达到 77.33%,较好地实现了故障漏电电流分离,为电流分离式 RCD 设计提供了可借鉴的理论算法。

1 堆叠稀疏自动编码网络

深度网络作为一种多层神经网络架构,通过逐层学习可实现输入数据的多尺度非线性特征提取。自动编码器因其优异的特征学习和重构能力受到研究者的青睐^[20],本文将以此为基础设计一种新的网络架构,用于从剩余电流中分离故障漏电支路电流。

1.1 稀疏自动编码器

自动编码器结构如图 1 所示。其中,输入层对应输入数据 x ,经编码单元运算获得隐含层特征 h ;特征 h 作为解码单元输入,经解码运算获得重构输出数据 x' 。编解码单元训练是在解码重构输出与实际输入数据的误差指导下,通过反向传播不断修正和调整网络参数来实现的。




图 1 自动编码器网络

Fig. 1 Network structure diagram of auto encoder

假设输入数据 $x \in R^{n \times 1}$,经过非线性编码映射获得隐含层输出特征 $h \in R^{d \times 1}$,该非线性编码映射为:

$$h = s_f(W_1 x + b_1) \quad (1)$$

式中: s_f 为隐含层神经元激活函数,本文采用 sigmoid 函数 $s_f(t) = 1/(1 + \exp(-t))$; $W_1^{d \times n}$ 是编码单元权重矩阵; $b_1 \in R^{d \times 1}$ 为输入层神经元偏置向量。

编码特征 $\mathbf{h} \in \mathbf{R}^{d \times 1}$ 作为解码单元输入,经非线性解码映射获得重构输出数据 $\mathbf{x}' \in \mathbf{R}^{n \times 1}$,解码运算为:

$$\mathbf{x}' = s_g(\mathbf{W}_2 \mathbf{h} + \mathbf{b}_2) \quad (2)$$

式中: s_g 为输出层神经元激活函数; $\mathbf{W}_2$ 为解码单元权重矩阵,且 $\mathbf{W}_2 = \mathbf{W}_1^T, \mathbf{b}_2 \in \mathbf{R}^{d \times 1}$ 为隐层神经元偏置向量。

重构结束,计算输入与重构输出的误差损失:

$$J_{\text{MSE}}(\theta) = \frac{1}{m} \sum_{i=1}^m \left(\frac{1}{2} \|\mathbf{x}_i - \mathbf{x}'_i\|^2 \right) \quad (3)$$

式中: m 为输入样本数量; $\mathbf{x}_i$ 为输入向量; $\mathbf{x}'_i$ 为重构输出; $\theta = \{\mathbf{W}_1, \mathbf{W}_2, \mathbf{b}_1, \mathbf{b}_2\}$ 为待求解参数集合。最后,通过误差反向传播实现参数 θ 的自动调整,直至获得最小重构误差。

自动编码器隐层神经元数量通常低于输入数据维数,可实现高维数据压缩。当隐层神经元数量较多时,会导致编码特征携带过多冗余信息,所得网络泛化能力变差。同时,隐层神经元数量增加导致网络参数规模变大,增加了模型学习复杂度。因此,研究者通过隐含层的稀疏性设置,来降低隐含层神经元数量过多的干扰。因此,带稀疏惩罚项的重构误差函数为:

$$J_{\text{cost}}(\theta) = J_{\text{MSE}}(\theta) + J_{\text{sparse}}(\theta) = \frac{1}{m} \sum_{i=1}^m \left(\frac{1}{2} \|\mathbf{x}_i - \mathbf{x}'_i\|^2 \right) + \beta \sum_{j=1}^d KL(\rho \| \rho_j) \quad (4)$$

式中: $J_{\text{MSE}}(\theta)$ 为原重构误差; $J_{\text{sparse}}(\theta)$ 为稀疏惩罚项; β 为惩罚强度调节因子。

稀疏惩罚项 $J_{\text{sparse}}(\theta)$ 计算公式为:

$$J_{\text{sparse}}(\theta) = \sum_{j=1}^d KL(\rho \| \rho_j) \quad (5)$$

式中: $\rho_j = \frac{1}{n} \sum_{i=1}^n \mathbf{h}_i$ 为隐含层平均活跃度; ρ 是接近于 0 的常量。 $KL(\rho \| \rho_j)$ 为变量 ρ 和 ρ_j 间的相对熵:

$$KL(\rho \| \rho_j) = \rho \log \frac{\rho}{\rho_j} + (1 - \rho) \log \frac{1 - \rho}{1 - \rho_j} \quad (6)$$

1.2 堆叠稀疏自动编码网络

堆叠稀疏自动编码网络由多级自动编码器级联构成,如图 2 所示。前级自动编码器的隐层输出作为后级自动编码器的输入,网络架构包含 1 个输入层,若干隐含层和 1 个输出层。堆叠稀疏自动编码网络结构可根据应用需求灵活调整。1) 特征提取模型,截取网络中某一级自动编码器的隐含层输出 $H(i)$ 作为最具代表性的编码特征;2) 分类模型,将前级特征提取模型输出与某分类器级联,实现特征分类;3) 重构模型,采用对称的编解码网络模块,获取输入数据的重构结果。

2 交叉自动编码器网络

借鉴堆叠稀疏自动编码网络结构灵活调整的优势,




图 2 堆叠稀疏自动编码网络

Fig. 2 Stacked sparse auto encoder network

本文提出一种交叉自编码网络模型构建策略。该模型重新组合了两个独立堆叠稀疏自动编码网络的编码模块和解码模块,用于从输入数据中分离或预测新数据。本文将该模型用于从剩余电流中分离故障漏电电流数据,可实现电流数据的特征学习与分离重构。算法流程如图 3 所示。




图 3 本文所提算法流程

Fig. 3 The flow chart of our method

1) 基于剩余电流数据集,采用无监督方式训练堆叠稀疏自动编码编码单元 A 和解码单元 A。

2) 基于故障漏电电流数据集,采用无监督方式训练堆叠稀疏自动编码单元 B 和解码单元 B,获得故障漏电电流最小重构误差和网络模型。

3) 分别截取编码单元 A 和解码单元 B,将两个模块级联融合,构成交叉堆叠稀疏自动编码网络。

4) 基于成对剩余电流和故障漏电流数据集,微调训练交叉堆叠稀疏自动编码网络参数。剩余电流为输入数据,故障漏电流为期望输出,基于故障漏电流重构误差对交叉自动编码网络参数进行微调训练,实现剩余电流到故障漏电流映射关系迁移学习。

5) 故障漏电流分离测试。将测试剩余电流输入交叉堆叠自编码网络,经剩余电流编码单元压缩和故障漏电流解码单元重构,输出预测故障漏电流。

交叉级联的自编码网络能够较好保持编码模块对剩余电流的特征提取能力和解码模块对故障漏电流的重构能力,为挖掘剩余电流和故障漏电流支路电流间的映射

关系提供了基础网络架构,降低了故障漏电电流分离网络结构调整和参数学习的复杂度。借鉴迁移学习思想的交叉级联网络微调训练方法,实现了两个模块参数的联合优化与整合,既提升了交叉网络训练效率,也增强了所得模型的泛化能力和鲁棒性。

3 试验与分析

3.1 数据集简介

试验所用剩余电流和故障漏电电流数据通过课题组搭建的故障漏电保护试验平台采集,通过录波器记录故障漏电发生过程前后系统的剩余电流和故障漏电路径电流信号,如图 4 所示。




图 4 故障漏电试验数据

Fig. 4 Fault leakage experiment data

图 4(a) 为故障漏电故障发生前系统无剩余电流,故

障漏电发生后产生剩余电流;图 4(b) 为故障漏电故障发生前系统存在的正常剩余电流,故障漏电发生后正常剩余电流和故障漏电电流叠加,形成总剩余电流。图中横坐标为采样点数,共 10 个周期(1 个周期 1 000 个点),纵坐标为对应采样时刻的电流有效值。试验中截取故障漏电时刻前 1 个周期和故障漏电后 2 个周期电流信号,然后将每个周期数据下采样至 250 点,即 3 个周期 750 个采样数据作为原始输入数据。

故障漏电试验中分别采集剩余电流数据 300 组、故障漏电路径电流 300 组,同步采集的成对剩余电流-故障漏电电流数据 150 组,数据集简况如表 1 所示。

表 1 试验所用数据集

Table 1 Data sets used in the experiment			
类型	数据集	组数	作用
训练集	剩余电流数据集	300	训练编码单元 A
	故障漏电电流数据集	300	训练解码单元 B
	成对剩余电流-故障漏电	75	微调训练交叉
	电流数据集		自编码网络
测试集	成对剩余电流-故障	75	测试模型性能
	漏电电流数据集		

其中,训练集包含 300 组剩余电流数据和 300 组故障漏电路径电流数据,分别用于独立训练堆叠稀疏自动编码网络,获取编码单元 A 和解码单元 B;训练集包含 75 组成对的剩余电流-故障漏电电流数据,是从 150 组成对数据中随机选取获得,用于交叉自编码网络的微调训练。测试集选取了剩余的 75 组成对剩余电流-故障漏电路径电流数据。测试过程中执行 10 次独立重复试验,将 10 次试验准确度的平均值作为本文所提网络模型的分离精确度。

3.2 网络模型参数初始化

试验分别针对剩余电流和故障漏电路径电流设计堆叠稀疏自动编码网络,其中存在多个待优化参数:网络深度、网络宽度(每层神经元个数)、稀疏惩罚控制因子,以及网络训练中的学习率、激活函数、训练次数和批训练样本数等,参数初始设置如表 2 所示。在初始参数配置的模式测试试验中,剩余电流和故障漏电路径电流数据集上重构误差较大,均达到 10^4 数量级。因此,需通过网络参数调优,逐步降低重构误差。


3.3 堆叠稀疏自动编码网络参数调优试验

影响堆叠稀疏自动编码网络性能的参数分为网络架构参数和网络训练参数,其中网络训练参数包括网络预训练和微调两个阶段的参数。


网络架构参数主要指稀疏惩罚控制因子、网络深度和每层网络神经元数量,其中网络深度设置为 5 层。因此,试验中首先对稀疏惩罚项和每层网络神经元数量对重构性能影响开展对比试验,结果如图 5 所示。

表 2 堆叠稀疏自动编码网络初始参数设置

Table 2 Initial parameters setting of stacked sparse auto encoder network		
主要参数	剩余电流对应网络	故障漏电电流对应网络
网络结构	[750 500 200 500 750]	[750 500 200 500 750]
预训练学习率	0. 5	0. 5
预训练批训练样本数	30	30
预训练训练次数	1	1
稀疏惩罚控制因子	0	0
激活函数	tanh	tanh
微调训练学习率	0. 5	0. 5
微调批训练样本数	20	20
微调训练次数	1	1



(a) 剩余电流数据集重构误差




(b) 故障漏电电流数据集重构误差


图 5 网络结构和稀疏控制因子对重构误差的影响
Fig. 5 Impact of network structure and sparse control factor on reconstruction error

两个数据集中,稀疏惩罚控制因子和各层神经元数量对网络重构性能的影响具有相似变化趋势。当网络各层神经元数量为[750-400-200-400-750],稀疏惩罚控制因子为 0. 003 时,两个数据集上的重构误差均达到最小值。其中,剩余电流数据 750 个采样点的最小累积重构误差为 3 262 mA,故障漏电电流数据最小累积重构误

差为 2 735 mA。
网络架构参数确定后,对影响网络性能的训练过程可调参数开展消融试验。首先对编码网络预训练和微调训练中的学习率进行调优,结果如图 6 所示。



(a) 剩余电流数据集重构误差
(a) Reconstruction error of residual current data set



(b) 故障漏电电流数据集重构误差
(b) Reconstruction error of fault leakage current data set

图 6 学习率对重构误差影响

Fig. 6 Impact of learning rate on reconstruction error

试验数据表明,预训练阶段网络最优学习率为 0. 3,微调阶段学习率最优值为 0. 6 时,剩余电流数据的 750 个采样点的最小累积重构误差降至 985 mA。预训练阶段网络学习率为 0. 3,微调学习率取 0. 7 时,故障漏电电流数据的最小累积重构误差达到最小值 1 600 mA。

其次,针对网络预训练和微调阶段的批训练样本数对重构性能影响进行试验,结果如图 7 所示。剩余电流数据集试验表明,当网络预训练中每批参与训练的样本数为 6,微调阶段每批参与训练的样本数为 10 时,网络在 750 个采样点的最小累积重构误差为 476 mA,训练时间为 23. 627 s。当预训练中批训练样本数为 5,微调批训练样本数为 12 时,故障漏电电流数据集最小累积重构误差为 516 mA,训练时间为 22. 281 s。由图 7 可知,当批训练样本集合规模较小,训练批数增多时,网络能对电流数据中的关键代表特征进行细致学习,以良好的编码特征为基础,通过解码单元可获得较好重构数据。




图 7 批训练样本数对重构误差影响
Fig. 7 Impact of training sample number on reconstruction error

经过参数调优,网络重构误差降至 10^2 数量级,但仍然较大。除通过增大训练批数实现特征细致学习外,设定合理的训练迭代次数能进一步加强对电流数据特征的充分学习。图 8 所示为网络预训练和微调过程中算法迭代次数对重构性能的影响。

试验表明,当堆叠稀疏自动编码网络预训练迭代次数为 10,微调训练迭代次数为 5 时,剩余电流数据的重构效果达到最优,750 个采样点的累积重构误差下降至 6.63 mA,训练时间增加至 173.948 s。故障漏电流数据集中,当网络预训练迭代次数为 10,微调训练迭代次数为 5 时,累积误差下降为 8.77 mA,重构效果达到最优,而训练时间增加至 169.357 s。

经过参数调优,基于两数据集的网络累积重构误差均下降至 10 mA 以下,此时,确定的网络最优参数配置如表 3 所示。

3.4 交叉自编码网络的测试试验

通过剩余电流和故障漏电流数据集的无监督训




图 8 迭代次数对重构误差影响
Fig. 8 Impact of iterations on reconstruction error

表 3 堆叠稀疏自动编码网络最优的参数配置
Table 3 The optimal parameter configuration for stacked sparse auto encoder network

主要参数	剩余电流对应网络	故障漏电流对应网络
网络结构	[750-400-200 -400-750]	[750-400-200 -400-750]
预训练学习率	0.3	0.3
预训练批训练样本数	6	5
预训练训练次数	10	10
稀疏惩罚控制因子	0.003	0.003
激活函数	tanh	tanh
微调训练学习率	0.6	0.7
微调批训练样本数	10	12
微调训练次数	5	5

练,分别获得了堆叠稀疏自动编码网络 A 和网络 B,较好地实现了剩余电流和故障漏电流重构。然后,截取剩余电流重构网络 A 的编码模块[750-400-200]和故障漏电流重构模型 B 的解码模块[200-400-750],将两个模块交叉级联构建得到交叉堆叠稀疏自动编码网络,网络结构为[750-400-200-200-400-750]。该网络前级编码模块能实现剩余电流的有效特征学习,后级解码模块能实现故障漏电流的可靠重构,而中间 [200-200]

模块为全连接交叉结构,实现了两个模块的级联融合。最终形成的网络架构可实现剩余电流-故障漏电电流映射,达到从剩余电流中分离故障漏电电流的目的。

交叉自编码网络微调涉及的参数包括学习率、稀疏惩罚控制因子、训练次数和批训练样本数。本文针对参数对模型分离性能的影响执行消融试验,确定了最优网络参数配置,如表 4 所示。

表 4 交叉自编码网络的最优参数配置

Table 4 The optimal parameter configuration for cross-encoder-decoder module

主要参数	交叉自编码网络
网络结构	[750-400-200-200-400-750]
稀疏惩罚控制因子	0.003
激活函数	tanh
微调训练学习率	0.6
微调批训练样本数	5
微调训练次数	8

构建交叉网络模型后,从 150 组成对的剩余电流-故障漏电电流数据中随机选取 75 组用于交叉自编码网络微调训练,剩余的 75 组成对数据用于故障漏电电流的分离测试试验。为验证所提算法的鲁棒性,分别进行了 10 次交叉验证试验,并取分离准确度平均值作为最终分离精度。

为计算交叉自编码网络的分离准确度,本文采用分离输出故障漏电电流 I_o 与实际故障漏电电流 I_r 的均方根误差值作为评价标准

$$E = \sqrt{\frac{1}{750} \sum_{i=1}^{750} (I_o^{(i)} - I_r^{(i)})^2}$$

(7)

式中: $I_o^{(i)}$ 为分离输出故障漏电电流的第 i 个分量; $I_r^{(i)}$ 为实际故障漏电电流的第 i 个分量。

当误差值 E 小于设定阈值 THR 时,表示分离准确,被准确分离的电流数据个数占测试样本总数(75)的比率定义为分离准确度。本文所提交交叉自编码网络在不同误差阈值下的分离准确度曲线如图 9 所示。




图 9 不同误差阈值下的预测准确度曲线

Fig. 9 Prediction accuracy curve under different error thresholds

图 9 所示为 10 次交叉验证试验中,不同误差阈值下的分离准确度曲线。针对随机选择的 75 组成对测试数据,10 次试验结果曲线具有相似的变化趋势,在不同误差阈值下,分离准确度具有小幅度波动。当误差阈值由小变大时,满足阈值标准的分离输出电流个数逐渐增多,准确度逐步升高。试验数据显示,当累积误差阈值设置为 5 mA 时,10 次交叉试验的平均分离准确率为 77.33%;当累积误差阈值调整为 15 mA 时,平均分离准确率提升至 88.67%,能较好地实现剩余电流中分离故障漏电电流。

另外,为了更好的说明所提方法的有效性,基于本文构建的剩余电流数据集和电流分离准确度评价标准,分别采用 Hilbert-Huang 变换^[8]和最小二乘支持向量机^[12]方法进行了比较实验。结果表明,当累积误差阈值设置为 5 mA 时,文献[9,12]的分离准确度分别为 70.67%和 66.67%,与本文方法相差较远。当阈值设置为 15 mA 时,文献[8,12]的分离准确度均达到 85.33%,与本文所提方法相近。

4 结 论

本文提出一种基于交叉自编码网络的故障漏电电流分离方法。基于堆叠自动编码网络优异的特征提取和数据重构能力,结合自动编码网络结构可灵活截取和迁移学习的思想,设计了将剩余电流特征编码模块和故障漏电电流特征解码模块交叉级联的融合网络架构。通过成对的剩余电流-故障漏电电流数据集微调学习实现了交叉融合网络的联合优化和最优参数配置,获得剩余电流到故障漏电电流的分离映射关系。该方法为实现从剩余电流中分离故障漏电电流提供了一种有效算法,为设计基于故障漏电电流的电流分离式 RCD 提供了可借鉴的理论方法。

参考文献

[1] 李天友,徐丙垠,薛永端,等. 配电网触电保护技术[R]. 北京:中国电机工程学会专题报告,2018.
LI T Y, XU B Y, XUE Y D, et al. Electric shock protection technology of distribution network [R]. Beijing: Special Report of the Chinese Society of Electrical Engineering, 2018.

[2] 李天友,郭峰. 低压配电的触电保护技术及其发展[J]. 供用电, 2019, 36(12): 2-8.
LI T Y, GUO F. Electric shock protection technology and its development of low-voltage distribution [J]. Distribution & Utilization, 2019, 36(12): 2-8.

[3] 关海鸥,郭元建,杜松怀,等. 农村低压电网触电电流

- 数字特征描述与分析[J]. 中国农业大学学报, 2014, 19(3): 202-207.
- GUAN H O, GUO Y J, DU S H, et al. Description and analysis of shock current digital features for low-voltage rural power grid [J]. Journal of China Agricultural University, 2014, 19(3): 202-207.
- [4] 李春兰, 夏兰兰, 王成斌, 等. 基于椭圆域分割的触电电流混沌检测方法研究[J]. 电力系统保护与控制, 2017, 45(15): 69-76.
- LI CH L, XIA L L, WANG CH B, et al. Study on chaos detection method of electric shock current based on elliptic domain segmentation [J]. Power System Protection and Control, 2017, 45(15): 69-76.
- [5] 李春兰, 苏娟, 杜松怀, 等. 基于小波分析和 BP 神经网络的触电信号检测模型[J]. 农业工程学报, 2010, 26(S2): 130-134.
- LI CH L, SU J, DU S H, et al. Detecting model of electric shock signal based on wavelet analysis and BP neural network[J]. Transactions of the Chinese Society of Agricultural Engineering, 2010, 26(S2): 130-134.
- [6] 韩晓慧, 杜松怀, 苏娟, 等. 基于局部均值分解的触电故障信号瞬时参数提取[J]. 农业工程学报, 2015, 31(17): 221-227.
- HAN X H, DU S H, SU J, et al. Extraction of biological electric shock signal instantaneous amplitude and frequency based on local mean decomposition [J]. Transactions of the Chinese Society of Agricultural Engineering, 2015, 31(17): 221-227.
- [7] 李春兰, 高阁, 张亚飞, 等. 基于局部均值分解(LMD)的单通道触电信号盲源分离算法[J]. 农业工程学报, 2019, 35(12): 200-208.
- LI CH L, GAO G, ZHANG Y F, et al. Single channel electric shock signals blind source separation algorithm based on local mean decomposition[J]. Transactions of the Chinese Society of Agricultural Engineering, 2019, 35(12): 200-208.
- [8] 关海鹰, 李伟凯, 杜松怀, 等. 基于 Hilbert-Huang 变换的生物触电电流检测模型[J]. 农业工程学报, 2017, 33(14): 202-209.
- GUAN H O, LI W K, DU S H, et al. Detection model of biological electric shock current based on Hilbert-Huang transform[J]. Transactions of the Chinese Society of Agricultural Engineering, 2017, 33(14): 202-209.
- [9] 左金威, 赵恒, 陈重佑, 等. 基于半波真有效值的触/漏电故障电流检测[J]. 四川电力技术, 2017, 40(3): 66-72.
- ZUO J W, ZHAO H, CHEN CH Y, et al. Touch/leakage fault current detection based on half-wave true RMS [J]. Sichuan Electric Power Technology, 2017, 40(3): 66-72.
- [10] 熊晓祎, 肖先勇, 赵恒. 基于自适应算法的触电事故电流检测[J]. 电力系统保护与控制, 2017, 45(4): 139-144.
- XIONG X Y, XIAO X Y, ZHAO H. Adaptive algorithm based electrical shock current detection method [J]. Power System Protection and Control, 2017, 45(4): 139-144.
- [11] 关海鹰, 杜松怀, 苏娟, 等. 一种触电信号的自动快速检测模型[J]. 电网技术, 2013, 37(8): 2328-2335.
- GUAN H O, DU S H, SU J, et al. An automatic and quick detection model of electric shock signals [J]. Power System Technology, 2013, 37(8): 2328-2335.
- [12] 韩晓慧, 杜松怀, 苏娟, 等. 基于参数优化的最小二乘支持向量机触电电流检测方法[J]. 农业工程学报, 2014, 30(23): 238-245.
- HAN X H, DU S H, SU J, et al. Determination method of electric shock current based on parameter-optimized least squares support vector machine[J]. Transactions of the Chinese Society of Agricultural Engineering, 2014, 30(23): 238-245.
- [13] 刘永梅, 杜松怀, 盛万兴. 基于 SVM-神经网络融合反馈的触电电流检测方法[J]. 电网技术, 2020, 44(5): 1972-1977.
- LIU Y M, DU S H, SHENG W X. Prediction method of electric shock current based on SVM and neural network fusion feedback [J]. Power System Technology, 2020, 44(5): 1972-1977.
- [14] LIU Y M, DU S H, SHENG W X. Classification and identification of electric shock current for safety operation in power distribution network [J]. IET Cyber-Physical Systems: Theory & Applications, 2020, 5(2): 145-152.
- [15] 温江涛, 闫常弘, 孙洁娣, 等. 基于压缩采集与深度学习的轴承故障诊断方法[J]. 仪器仪表学报, 2018, 41(1): 171-179.
- WEN J T, YAN CH H, SUN J D, et al. Bearing fault diagnosis method based on compressed acquisition and deep learning [J]. Chinese Journal of Scientific Instrument, 2018, 41(1): 171-179.
- [16] 余琼芳, 黄高路, 杨艺, 等. 基于 AlexNet 深度学习网络的串联故障电弧检测方法[J]. 电子测量与仪器学报. 2019, 33(3): 145-152.
- YU Q F, HUANG G L, YANG Y, et al. Series arc fault detection method based on AlexNet deep learning network[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(3): 145-152.
- [17] 宫文峰, 陈辉, 张美玲, 等. 基于深度学习的电机轴承

微小故障智能诊断方法[J]. 仪器仪表学报, 2020, 41(1): 195-205.

GONG W F, CHEN H, ZHANG M L, et al. Intelligent diagnosis method for incipient fault of motor bearing based on deep learning[J]. Chinese Journal of Scientific Instrument, 2020, 41(1): 195-205.

- [18] 张朝龙, 何怡刚, 杜博伦, 等. 基于深度学习的电力变压器智能故障诊断方法[J]. 电子测量与仪器学报. 2020, 34(1): 81-89.

ZHANG CH L, HE Y G, DU B L, et al. Intelligent fault diagnosis method of power transformer using deep learning[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(1): 81-89.

- [19] NGIAM J, COATES A, LAHIRI A, et al. On optimization methods for deep learning[C]. Proceedings of the 28th International Conference on Machine Learning (ICML-11), 2011: 265-272.

- [20] 傅桂霞, 魏文辉, 邹国锋, 等. 融合子区域局部二值模式特征与深层聚合网络的人脸识别[J]. 科学技术与工程, 2018, 18(19): 237-243.

FU G X, WEI W H, ZOU G F, et al. Face recognition based on fusion of sub-region local binary pattern features and deep aggregation network[J]. Science Technology

and Engineering, 2018, 18(19): 237-243.

作者简介



杨帆, 2011 年于武汉大学获得博士学位, 现为国网湖北省电力有限公司电力科学研究院教授级高级工程师, 主要研究方向为智能配电网与故障检测。

E-mail: yangf_82@163.com

Yang Fan received his Ph. D. degree from Wuhan University in 2011. He is now a professor level senior engineer of Electric Power Research Institute of State Grid Hubei Electric Power Co., Ltd.. His main research interests include intelligent distribution network and fault detection.



邹国锋 (通信作者), 2013 年于哈尔滨工程大学获得博士学位, 现为山东理工大学讲师, 主要研究方向为智能信息处理、复杂系统健康检测与诊断技术。

E-mail: zgf841122@163.com

Zou Guofeng (Corresponding author) received his Ph. D. degree from Harbin Engineering University in 2013. Now he is a lecturer at Shandong University of Technology. His main research interests include intelligent information processing, complex system health detection and diagnosis technology.