

基于迁移卷积神经网络的 配电网高阻接地故障检测方法

陈恒[†]

(广东电网有限责任公司 湛江供电局, 广东 湛江 524000)

摘要:为解决高阻接地故障导致的配电网运行安全性低的问题,提出了基于迁移卷积神经网络的配电网高阻接地故障检测方法。首先,采用HHT方法提取原始信号中的特征量,将提取结果输入到卷积神经网络结构中,通过训练和学习实现对特征量的分类处理。然后,通过迁移学习将已经训练完成的卷积神经网络模型放在新任务内再次实施检测,提高配电网高阻接地故障检测能力。实验结果表明:该方法在迭代次数达到160次以后,故障检测准确率高达99.9%,且网络训练误差均低于1.5。在噪声环境下,该方法的抗噪能力较强,同时适用于不同类型工况故障的检测,卷积层对迁移CNN的检测精度影响较小,在故障检测方面迁移CNN的稳定性表现较好,可以提高配电网高阻接地故障检测能力。

关键词:迁移学习;卷积神经网络;配电网;高阻接地;故障检测方法;特征提取

中图分类号:TM713

文献标识码:A

High Resistance Grounding Fault Detection Method for Distribution Network Based on Transfer Convolutional Neural Network

CHEN Heng[†]

(Zhanjiang Power Supply Bureau of Guangdong Power Grid Co., Ltd., Zhanjiang, Guangdong 524000, China)

Abstract: To address the issue of low operational safety in distribution networks caused by high resistance grounding faults, a transfer convolutional neural network based high resistance grounding fault detection method for distribution networks is proposed. Firstly, the HHT method is used to extract feature quantities from the original signal, and the extracted results are input into the convolutional neural network structure. Through training and learning, the classification processing of feature quantities is achieved. Then, through transfer learning, the trained convolutional neural network model is put into a new task to detect again, so as to improve the detection ability of distribution network high resistance grounding fault. The experimental results show that after 160 iterations, the fault detection accuracy of this method is as high as 99.9%, and the network training errors are all below 1.5. In noisy environments, this method has strong noise resistance and is suitable for detecting faults in different types of operating conditions. The convolutional layer has a small impact on the detection accuracy of the migrated CNN, and the stability of the migrated CNN in fault detection is good, which can improve the high resistance grounding fault detection ability of the distribution network.

Key words: transfer learning; convolutional neural network; distribution network; high resistance grounding; fault detection methods; feature extraction

配电网为终端电力客户提供电能供应,其稳定性直接关系整体电力系统的正常运行^[1]。配电网分布范围比较广,线路比较多,极易发生故障情况。在配电网故障中,高阻接地故障为比较常见的故障,该种故障是极端天气导致导线掉落与树木接触产生高阻性。该种故障发生时的电流、电压变化量比较小,会加大故障检测的难度^[2]。如果未及时检测出配电网中的高阻接地故障,会导致配电网电力设备存在新接地点,使配电网线路发生短路,可能会发生重大停电事故。同时高阻接地故障也威胁人身安全,因此对配电网高阻接地故障检测研究具有积极的意义^[3]。

目前,相关学者已经开始对配电网高阻接地故障检测方法进行研究,周鹏等人^[4]研究内积变换的故障检测方法,通过该方法提取高阻接地故障特征,并得出异常特征值,完成高阻接地故障检测。但该方法在提取故障特征时需要耗费大量时间实施计算,导致故障检测时效性不高。李浩等人^[5]研究改进变分模态分解的故障检测方法,通过该方法提取配电网线路的零序电流分量,将峰度模态最大值作为主要特征向量并实施分析,完成高阻接地故障检测。但该方法仅以电流分量作为故障检测的主要特征,未考虑电压特征的变化情况,导致检测结果精度不高。邓丰等人^[6]研究行波能量分布特征的故障检测方法,通过小波变换提取时频特征,以行波波形的展示,并生成时频能量矩阵,依据能量变化情况实施故障检测,当能量发生突变时,表明此时为高阻接地故障。但该方法在时频特征提取过程中,受母小波选取因素影响较大,导致故障检测效率降低。

迁移学习是将源域知识迁移至目标域中,从而提高对目标信息的检测效果^[7]。卷积神经网络(convolutional neural networks, CNN)因鲁棒性能较优,目前已在图像检测领域取得较好的应用效果^[8]。因此,针对传统故障检测方法存在的不足,将迁移学习和 CNN 结合在一起,研究迁移卷积神经网络的配电网高阻接地故障检测方法,增强配电网高阻接地故障检测水平。

1 迁移卷积神经网络的高阻接地故障检测方法

1.1 特征量提取

首先,采集配电网零序电压与母线三相电压信号,并将其作为初始信号。然后,引入希尔伯特-黄变换(Hibert-Huang Transform, HHT)过程,提

取初始信号的特征,通过迁移卷积神经网络的训练与学习过程,对提取结果展开分析,从而实现配电网高阻接地故障的检测。

通过 HHT 提取原始信号中特征量的具体过程如下。

设置子频带数量用 β 描述,采样点数量用 α 描述,得出原始信号时频矩阵如下:

$$\mathbf{D} = \begin{bmatrix} d_{11} & d_{12} & \cdots & d_{1\alpha} \\ d_{21} & d_{22} & \cdots & d_{2\alpha} \\ \vdots & \vdots & \ddots & \vdots \\ d_{\beta 1} & d_{\beta 2} & \cdots & d_{\beta \alpha} \end{bmatrix} \quad (1)$$

其中:原始信号时频矩阵用 \mathbf{D} 描述。

HHT 带通滤波方法计算公式如下:

$$\hat{y}(t) = \sum_{f_1}^{\times f_2} g(t) \quad (2)$$

其中:IMF 瞬时幅值用 $g(t)$ 描述;输出信号用 $\hat{y}(t)$ 描述;某个子频带界限分别用 f_1 、 f_2 描述,同时 $f_1 < f_2 \in [0, \frac{f_s}{2}]$;采样频率用 f_s 描述;时频用 t 描述。随机在时频矩阵中选择一个子频带,将其划分为 P 个数据点的 L 个时频块^[9],计算出第 β 个子频带的第 l 时频能量块表达式如下:

$$e_{\beta}^l = \sum_{\gamma=1}^P |o_{\beta}^l(\gamma) \times \Delta t| \quad (3)$$

其中:数据点幅值用 o 描述;采样周期用 Δt 描述;时频块内数据点用 γ 描述。

\mathbf{D} 分块时频矩阵如下:

$$\mathbf{E} = \begin{bmatrix} e_1^1 & e_1^2 & \cdots & e_1^L \\ e_2^1 & e_2^2 & \cdots & e_2^L \\ \vdots & \vdots & \ddots & \vdots \\ e_{\beta}^1 & e_{\beta}^2 & \cdots & e_{\beta}^L \end{bmatrix} \quad (4)$$

原始信号分块时频能量谱 E_{total} 如下:

$$E_{total} = \begin{bmatrix} E_{U_0} \\ E_{U_a} \\ E_{U_b} \\ E_{U_c} \end{bmatrix} \quad (5)$$

其中:零序电压能量用 E_{U_0} 描述;母线三相电压能量分别用 E_{U_a} 、 E_{U_b} 、 E_{U_c} 描述。通过拼接每行的 E_{total} 完成能量特征向量的提取。

1.2 卷积神经网络训练过程

将提取后的能量特征量作为迁移卷积神经网络的输入,通过网络训练输出配电网的高阻接地故障检测结果。卷积神经网络输入层用 $x = \{x_1, x_2, \dots, x_n\}$ 描述,其中 1 维向量用 x 描述。卷

积层负责提取数据特征^[10-12], 第 j 层偏置矢量用 b^j 描述, 卷积层求解公式如下:

$$h^j = (b^j + x \times W^j) \times \delta \quad (6)$$

其中: 激活函数用 δ 描述; 第 j 层卷积核大小用 W^j 描述。

池化层依据卷积层卷积求解结果实施下采样, 池化层表达式为:

$$h^{j+1} = \text{down}(h^j) \quad (7)$$

将池化层实施全连接集中在 1 个相同维度上, 全连接层表达式如下:

$$h^{j+2} = (b^{j+2} + h^{j+1} \times W^{j+2}) \times \delta \quad (8)$$

输出层主要包括多个 softmax 分类器, 对数据实施分类后得出预测结果, 即故障分类结果, 其具体表达式如下:

$$h^{j+3} = \text{soft max}(b^{j+3} + h^{j+2} \times W^{j+3}) \quad (9)$$

CNN 网络训练过程如下。

第一步: CNN 开始训练之前, 对每个节点参数实施初始化^[13]。

第二步: 更新参数。通过反向传播方法使每个节点参数向最优解靠近。各节点参数初始化后, 通过前向求解出模型预测结果, 按照预测值求解出网络每层的残差, 再从最后 1 层反向求解出每个节点的残差, 求出偏导数, 完成参数更新^[14]。

在 CNN 前向传播时, 通过正则化操作解决模型训练过程内过于拟合的问题^[15]。在分类过程中, 采用 softmax 函数, 其表达式如下:

$$\text{softmax}(y_i) = \frac{\exp(y_i)}{\sum_{k=1}^n \exp(y_k)} \quad (10)$$

其中: 第 i 种出现可能性输出用 y_i 描述; 样本数量用 n 描述。

交叉函数表达式如下:

$$F(y_-, y) = - \sum_k^n (1b_{y_i} \times y_i) \quad (11)$$

其中: 第 i 种期望输出用 y_i 描述。

参数更新中残差计算至关重要, 节点残差计算公式为:

$$\sigma_x^{(j)} = \partial Q / \partial v_x^{(j)} \quad (12)$$

其中: 第 j 层第 χ 个节点用 $v_x^{(j)}$ 描述; 损失函数用 Q 描述。

最后 1 层中每个节点残差表达式如下:

$$\sigma_x^{(K)} = -(y_x - \delta) \times f'(v_x^{(K)}) \quad (13)$$

其中: 实际值用 y_x 描述; 导数用 f' 描述; 第 K 层第 χ 个节点用 $v_x^{(K)}$ 描述。

其他层残差求解公式如下:

$$\sigma_x^{(j-1)} = f'(v_x^{(j-1)}) \times \left(\sum_{\mu=1}^{n_j} w_{\mu x}^{(j-1)} \right) \quad (14)$$

其中: 第 $j-1$ 层第 χ 个节点用 $v_x^{(j-1)}$ 描述; 权值用 $w_{\mu x}^{(j-1)}$ 描述; 节点用 μ 描述。

通过各节点残差, 求解出偏导数, 具体求解公式为:

$$\partial Q / \partial w_{\mu x}^{(j)} = \sigma_x^{(j)} \times \delta \quad (15)$$

$$\partial Q / \partial b_x^{(j)} = \sigma_x^{(j)} \quad (16)$$

其中: 第 j 层第 χ 个节点偏置用 $b_x^{(j)}$ 描述。

按照公式(17)与公式(18)实施参数的更新, 其表达式如下:

$$w_{\mu x}^{(j)} = w_{\mu x}^{(j)} - \epsilon \times (\partial Q / \partial w_{\mu x}^{(j)}) \quad (17)$$

$$b_x^{(j)} = b_x^{(j)} - \epsilon \times (\partial Q / \partial b_x^{(j)}) \quad (18)$$

其中: 学习率用 ϵ 描述。

1.3 利用迁移卷积神经网络建立配电网高阻接地故障检测模型

因配电网的高阻接地故障检测中样本数量比较少, 将迁移学习和卷积神经网络结合在一起构建迁移卷积神经网络的配电网高阻接地故障检测模型, 通过迁移学习将已经训练完成的 CNN 模型放在新任务内再次实施检测, 提高配电网高阻接地故障检测效率。在学习迁移过程中, 通过最大均值差异(maximum mean discrepancy, MMD)实施迁移适配, 为降低负迁移情况发生, 设置目标域用 Z_k 描述, 源域用 Z_s 描述, MMD 距离表达式如下:

$$\begin{aligned} \text{MMD}(Z_s, Z_k) = & \left\| (1/n_s) \sum_{i=1}^{n_s} x_{si} - \right. \\ & \left. (1/n_k) \sum_{l=n_s+1}^{n_s+n_k} x_{ki} \right\|_H \end{aligned} \quad (19)$$

其中: RKHS 范数用 $\| \cdot \|$ 描述; 目标域样本数量用 n_k 描述; 这两个域的样本分别用 x_{si} 、 x_{ki} 描述; 源域样本数量用 n_s 描述。MMD 值越小, 迁移适配最佳, 适合迁移学习。

迁移卷积神经网络的配电网高阻接地故障检测模型进行迁移训练的过程如下。

第一步: 采用适宜的迁移预训练模型。

第二步: 提取 CNN 中参数并迁移值目标域模型。

第三步: 将迁移后的模型实施微调训练。

通过迁移 CNN 的训练实现配电网高阻接地故障检测, 输出故障检测结果。

2 实验与结果分析

为了验证基于迁移卷积神经网络的配电网高

阻接地故障检测方法的实际应用效果,设计如下实验。

实验以 M 地区的配电网为对象,首先分析该配电网模型的架构,如图 1 所示。




图 1 配电网模型

由图 1 可知,该配电网模型将 220 kV 经变压器转换为 10 kV,为用电客户供电,配电网共包括 6 条母线和 14 条支路。母线中,线路 1 为架空线路,线路 3 为电缆线,线路 2、4、5、6 均为混合线路。

线路参数如表 1 所示。

表 1 线路参数

配电线路形式	电相顺序	电容/ ($\mu\text{F}/\text{km}$)	电感/ (mH/km)	电阻/ (Ω/km)
架空线	零序	0.0531	4.598	0.274
	正序	0.0952	1.198	0.124
电缆线	零序	0.2791	1.101	2.701
	正序	0.3381	0.254	0.271

为了测试本文方法的性能,实验设置高阻接地故障和 2 种正常暂态扰动工况实施测试,样本参数具体如表 2 所示。

采用本文方法检测试验对象的高阻接地故障,得出故障检测准确率迭代曲线,如图 2 所示。

分析图 2 可知,采用迁移 CNN,在迭代次数为 160 次时,故障检测准确率高达 99.9%;在迭代次数达到 160 次以后,网络模型训练趋势收敛,说明

本文方法可快速实现高阻接地故障检测。

表 2 样本参数

样本种类	空载线路投入	电容器投切	高阻接地故障
投入位置	线路 1~ 线路 6	母线处	R1~R14 线路末端 各设置 1 个故障点
投入相位	—	—	ABC
扰动初相角	$0^\circ\sim 160^\circ$	$0^\circ\sim 160^\circ$	$0^\circ\sim 160^\circ$
参数值	—	3600kvar、 4800kvar	500 Ω 、1000 ~5000 Ω
样本数量	45	85	1300




图 2 故障检测准确率迭代曲线

考虑到网络参数对网络训练误差的影响较大,经相关测试得出迁移 CNN 的训练误差曲线,如图 3 所示。




图 3 迁移 CNN 网络的训练误差曲线

分析图 3 可知, 在 CNN 中加入迁移学习, 构建迁移 CNN, 通过迁移学习提高 CNN 网络能力, 提高网络训练效率。在迭代次数达 160 次以后, 网络训练误差均低于 1.5, 说明本文方法的训练误差较小, 可快速实现高阻接地故障检测, 提高检测精度。

卷积层作为迁移 CNN 的主要层, 对故障检测精度影响较大, 因此在原有迁移 CNN 的卷积层基础上, 减少或增加卷积层后, 测试本文方法的故障检测精度, 测试结果如图 4 所示。




图 4 卷积层层数对迁移 CNN 的检测精度影响

分析图 4(a)可知, 减少卷积层后, 网络收敛曲线波动较大, 准确率虽然在前期出现下降趋势, 但是在迭代次数达到 160 次以后, 准确率又和原网络

保持一致; 分析图 4(b)可知, 增加卷积层后, 故障检测准确率几乎和原网络一致。综合分析图 4 可知, 卷积层对迁移 CNN 的检测精度影响较小, 迁移 CNN 的检测能力表现出较好的稳定性。

在配电网中进行数据采集时, 可能会受不同噪声的干扰, 导致数据中存在噪声。在不同信噪比下, 测试本文方法的性能, 噪声功率用 P_g 描述, 信噪比表达式为:

$$S_{NR} = \lg(P_s/P_g) \quad (20)$$

其中: 信号功率用 P_s 描述。信噪比值越小, 表示噪声干扰越强烈。

在试验测试集样本中, 分别添加信噪比为 10 dB、30 dB、50 dB 的白噪声, 测试本文方法在噪声环境下的抗干扰能力。将加入不同信噪比的噪声信号输入迁移 CNN 中, 得出本文方法在噪声环境下的故障检测准确率, 结果如图 5 所示。




图 5 本文方法在噪声环境下的故障检测准确率

分析图 5 可知, 在噪声环境下, 采用本文方法对高阻接地故障和 2 种扰动工况实施检测, 得出故障检测准确率均大于 0.970。在信噪比为 10 dB, 噪声干扰比较强烈, 此时本文方法在噪声环境下的故障检测准确率比无噪声添加时本文方法的检测准确率有小幅下降趋势, 但随着信噪比的增加, 本文方法的检测准确率逐渐上升。这说明本文方法的抗噪能力较强, 同时适用范围比较广, 适合不同类型工况故障的检测。

采用本文方法对高阻接地故障和 2 种正常暂态扰动工况实施检测, 得出时域和频域能量曲线如图 6 所示。

分析图 6(a)可知, 高阻接地故障波形在 $75 \mu s$ 以后呈现出下降趋势, 同时趋于平稳态势, 能量分布值在 $75 \mu s$ 以后一直保持在 0.008 左右, 空载线路切入和电容器切入工况曲线在时域上存在显著

区别;在 $75 \mu\text{s}$ 以后,空载线路切入和电容器切入均呈现出快速下降的态势,同时在 $120 \mu\text{s}$ 时正常暂态扰动工况的能量分布比较低。由图 6(b)可知,空载线路切入和电容器切入工况频域分量位于 $0 \sim 0.012 \text{ MHz}$ 低频区域;高阻接地故障频域分量在 $0.006 \sim 0.018 \text{ MHz}$ 频段内能量值最高,均高于其他两种工况的能量值。采用希尔伯特-黄变换提取原始信号中的特征量,将提取后的特征量输入迁移 CNN 中,实现配电网的高阻接地故障和其他两种正常暂态扰动工况检测,其应用效果较好。




图 6 时域和频域能量曲线

3 结论

用电需求的日益增长对电力系统的电力供给能力提出严峻的考验。配电网是电力系统供电的主要通道,配电网的故障检测对于整个电力系统的安全运行具有重要的意义。配电网故障主要包括

设备故障、线路故障、施工质量导致的故障等。其中高阻接地故障因其受继电保护器的保护,检测难度较大,但是该种故障的危害较大,必须及时处理,否则会引起线路起火等事故。因此,研究基于迁移 CNN 的配电网高阻接地故障检测方法,以提高故障检测效率。实验结果表明:迁移 CNN 在迭代次数达到 160 次以后,网络模型训练趋势收敛,说明本文方法可快速实现高阻接地故障检测,提高配电网高阻接地故障检测效率。

参考文献

- [1] 刘宝稳,曾祥君,张慧芬,等. 有源柔性接地配电网弧光高阻接地故障检测方法[J]. 中国电机工程学报,2022,42(11): 4001-4013.
- [2] 庄胜斌,缪希仁,江灏,等. 基于改进欧氏-动态时间弯曲距离的谐振接地配电网单相高阻接地故障选线方法[J]. 电网技术,2020,44(1):273-281.
- [3] 曾祥君,黄慧,喻锴,等. 基于柔性调控零序电压的配电网高阻接地及单相断线故障的选相方法[J]. 电力系统保护与控制,2022,50(3):9-18.
- [4] 周鹏,刘伟博,王交通,等. 基于综合内积变换的小电阻接地系统高阻故障检测方法[J]. 电网与清洁能源,2021,37(9): 70-76.
- [5] 李浩,张禄亮. 基于改进 VMD 和特征分布系数的配电网高阻接地故障检测方法[J]. 南方电网技术,2022,16(12):109-117.
- [6] 邓丰,徐帆,冯思旭,等. 基于行波全波形能量分布特征的高阻接地故障检测方法[J]. 中国电机工程学报,2022,42(22): 8177-8190.
- [7] 杨耿杰,王康,高伟. 基于相空间重构和迁移学习的配电网高阻接地故障检测[J]. 电力系统保护与控制,2022,50(13): 151-162.
- [8] 李宗博,焦在滨,何安阳. 基于卷积神经网络特征迁移策略的变压器智能保护方法[J]. 中国电机工程学报,2021,41(15): 5201-5212.
- [9] 王建,吴昊,张博,等. 不平衡样本下基于迁移学习-AlexNet 的输电线路故障辨识方法[J]. 电力系统自动化,2022,46(22):182-191.
- [10] 王艳新,闫静,王建华,等. 基于域对抗迁移卷积神经网络的小样本 GIS 绝缘缺陷智能诊断方法[J]. 电工技术学报,2022,37(9):2150-2160.
- [11] 王浩,杨东升,周博文,等. 基于并联卷积神经网络的多端直流输电线路故障诊断[J]. 电力系统自动化,2020,44(12):84-92.
- [12] 陈祝云,钟琪,黄如意,等. 基于增强迁移卷积神经网络的机械智能故障诊断[J]. 机械工程学报,2021,57(21):96-105.
- [13] 岳昕,张新慧,王敬华,等. 基于 VMD 和灰色综合关联度的谐振接地故障选线[J]. 计算机仿真,2022,39(4):76-79+267.
- [14] 杨为,朱太云,张国宝,等. 电力物联网下基于卷积神经网络和迁移学习的 GIS 局部放电模式识别分类方法研究[J]. 高压电器,2020,56(9):20-25+32.
- [15] 徐浩,刘利强,吕超. 基于迁移学习的配电网内部过电压识别方法[J]. 中国电力,2021,54(8):52-59.