

DOI: 10.19783/j.cnki.pspc.211282

基于相空间重构和迁移学习的配电网高阻接地故障检测

杨耿杰, 王康, 高伟

(福州大学电气工程与自动化学院, 福建 福州 350116)

摘要: 配电网中高阻接地故障(High Impedance Fault, HIF)时常发生, 其故障特征微弱而难以检测, 严重情况下可能导致火灾或人身事故。提出了一种基于相空间重构和迁移学习的故障识别方法, 实现对谐振接地系统中 HIF 的辨识。首先, 使用基于综合策略的小波阈值降噪方法对零序电流信号进行处理, 以降低噪声的影响。随后, 对降噪后的仿真信号及实测信号进行相空间重构, 获取重构轨迹图, 以此作为故障识别的特征量。最后, 在辨识模型构建上, 先使用仿真信号的重构轨迹图训练 GoogLeNet 模型, 再使用实测信号对模型进行微调, 实现迁移学习。所提算法的优点是使用相空间重构进行了信号转换, 故障信号与干扰信号的重构轨迹图差异明显, 且实测信号与仿真信号的重构轨迹图相似度较高。在进行迁移学习后, 实现了对实测小样本数据较为准确的检测。实验结果表明, 无论是故障实测数据还是故障仿真数据, 识别准确率均达到 95% 以上。此外, 在强噪声干扰、采样数据点缺失及故障回路间歇性导通情况下, 所提算法也取得了较好的结果。

关键词: 配电网; 高阻接地故障; 相空间重构; 小波阈值降噪; 迁移学习

High impedance fault detection in a distribution network based on phase space reconstruction and transfer learning

YANG Gengjie, WANG Kang, GAO Wei

(College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350116, China)

Abstract: High impedance faults (HIFs) occur frequently in a distribution network, and their fault characteristics are weak and difficult to detect. In serious cases, they may lead to fires or accidents. A fault identification method based on phase space reconstruction and transfer learning is proposed to identify an HIF in a resonant grounding system. First, the wavelet threshold denoising method based on a comprehensive strategy is used to process the zero sequence current signal to reduce the influence of noise. Then, the simulated signal and the measured signal after noise reduction are reconstructed in phase space, and the reconstructed trajectory is obtained as the characteristic quantity of fault identification. Finally, in the construction of an identification model, the reconstructed trajectories of simulation signals are investigated to train a GoogLeNet model, and then the measured signals are adopted to fine tune the model to realize transfer learning. The advantages of the proposed algorithm are that the phase space reconstruction is used for signal conversion, the reconstructed trajectories of fault signal and interference signal are obviously different, and the reconstructed trajectories of measured signal and simulated signal are highly similar; after the transfer learning, more accurate detection of the measured small sample data is realized. The experimental results show that the recognition accuracy of both fault measured data and fault simulation data is more than 95%. The proposed algorithm also achieves good results in the case of strong noise interference, missing sampling data points and intermittent conduction of the fault circuit.

This work is supported by the Natural Science Foundation of Fujian Province (No. 2021J01633).

Key words: distribution network; high impedance fault; phase space reconstruction; wavelet threshold denoising; transfer learning

0 引言

随着社会经济的发展, 对配电网的运行可靠

性要求越来越高, 准确、快速地识别配电网中的各类故障并及时做出反应是提升配电网运行有效性的有效途径^[1-6]。在配电网故障检测中, 高阻接地故障(High Impedance Fault, HIF)的检测一直都是重点与难点。据统计, HIF 在所有中压配电网故障中占比

基金项目: 福建省自然科学基金项目资助(2021J01633)

为 5%~10%^[7]，由于报告为永久性故障的 HIF 才被记录，实际占比可能更高。

HIF 通常由线路断线接触杆塔、地面或是线路与树枝的接触导致，通常伴随着电弧燃烧，产生火灾隐患。然而 HIF 的接地介质大多为水泥、沙地、草地等，其过渡电阻为几百甚至上千欧姆，故障电流微弱，故障特征不明显^[8]。此外，受大风等环境因素影响，故障回路有时会出现间歇性导通的情况，故障具有一定的随机性，这使得对 HIF 的排查十分困难^[9]。发生 HIF 时，接地介质的等效电阻大多为非线性，且通常会出现电弧的重燃与熄灭现象。故障电流波形在过零点出现明显畸变，这种现象被称为“零休”，HIF 的非线性畸变特征是判别 HIF 与其他干扰的重要特征^[9]。通过对现有文献资料的总结，本研究将 HIF 检测方法分为两类。

第一类为阈值法。通过波形分析寻找特征规律或进行特征量提取，并设定阈值对 HIF 进行检测。文献[9]利用零序电流的凹凸性来检测 HIF；文献[10]利用零序电流区间斜率曲线的“M”型特征来检测 HIF。在“零休”发生偏移以及燃、熄弧现象不明显时，这类方法准确率将会降低。

文献[11]对电流信号进行小波分解，根据各频段能量分布提出一种特征值计算公式，通过特征值的变化规律来检测 HIF；文献[12]对零序电流进行变分模态分解，计算特征模态的 Teager-Kaiser 能量算子时间熵来检测 HIF。上述时频域方法对噪声较为敏感，且确定阈值的方法较为复杂。

第二类为人工智能法。引入人工智能算法实现故障特征的自动提取和分类。文献[13-15]均使用时频域分析进行特征提取，训练神经网络模型以实现故障检测，解决了阈值设定困难的问题。

文献[16]引入变分原型自编码器对零序电流进行特征提取，利用得到的特征训练决策树，实现故障检测；文献[17]利用稀疏编码提取电流电压特征，训练随机森林实现 HIF 的准确检测。以上方法的特征提取及 HIF 检测过程均使用人工智能算法，为故障特征提取提出新的解决方案。

但由于实测数据难以获取，无法达到传统神经网络对数据集样本量的要求，实现小样本实测数据的准确检测是目前 HIF 检测领域的难点。

谐振接地系统中发生 HIF 时，具有故障信息量微弱、消弧线圈补偿、非线性特征显著等特点^[8]，此类 HIF 的检测难度较大，故本文提出算法对谐振接地系统中的 HIF 进行检测。针对 HIF 故障微弱的特特点，使用相空间重构提取故障特征，其重构轨迹

图能显示不同 HIF 的共性特征；为降低噪声干扰，提出一种针对零序电流的小波阈值降噪策略，在保留故障特征的同时，相空间轨迹变得更为平滑；为实现小样本实测数据集的准确检测，引入迁移学习，借助仿真数据预训练得到的网络来实现该目标。综上，本研究提出一种基于迁移学习、相空间重构与 GoogLeNet 的故障检测方法，并采用小波阈值降噪以降低噪声的影响。实现了小样本实测数据集的准确检测，并验证了该算法的强抗干扰能力及高灵敏性。

1 高阻接地故障的检测

1.1 仿真模型的搭建

使用 PSCAD/EMTDC 软件搭建了一个 10 kV 配电网模型。如图 1 所示， C_L 代表电缆线路， O_L 代表架空线路， L_1 为纯电缆线路， L_2 为纯架空线路， L_3 — L_6 为缆线混合线路。T 为主变压器，L 为中性点处电感。F1—F20 为设置的故障点位置，零序电流互感器放置在每条馈线的首端。

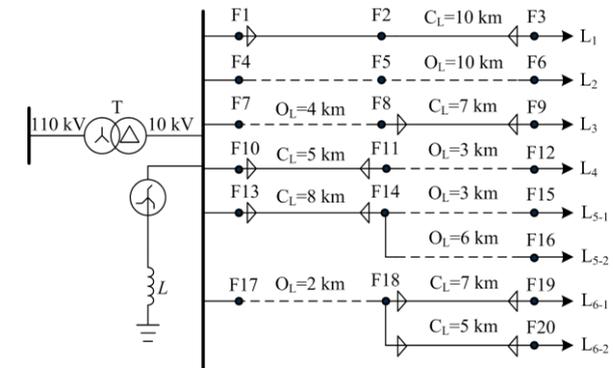


图 1 仿真模型网络结构

Fig. 1 Network structure of simulation model

本文使用 Emanuel 模型作为 HIF 模型，其结构如图 2 所示，该模型由两个二极管、两个电压源及两个电阻反并联组成^[11]。为模拟实际情况中电弧电压与电弧电阻的随机波动现象， V_p 、 V_n 、 R_p 及 R_n 均随时间随机波动，其波动范围均为所设置中心值 $\pm 10\%$ ，通过改变其参数可以对不同接地介质情况进行模拟。

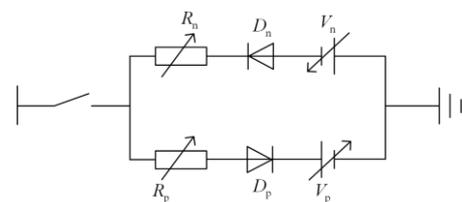


图 2 Emanuel 模型

Fig. 2 Emanuel model

1.2 通过相空间重构提取故障特征

配电网出现 HIF 时故障信息微弱, 受故障位置、接地介质等因素影响较大, 且一些电网操作事件或故障会产生与 HIF 相类似的特征。本研究利用相空间重构对零序电流进行分析, 挖掘发生 HIF 与各类干扰时系统在变化规律及特征上的区别。其能够有效提取各类 HIF 的共性特征, 所得到的重构轨迹图可较为直观地表示故障特征, 即便是不同情况下的 HIF 也有着较为相似的轨迹图, 在结合图像识别算法后能够实现各类 HIF 的有效辨识。

相空间重构的基本思想为: 系统中任意变量的变化过程由与之相互作用的分量共同决定, 其发展过程也隐含着其他变量的变化规律, 故可从变量的变化过程中构建和恢复整个系统的变化规律^[18-19]。利用相空间重构对非线性、非平稳系统进行分析在电力领域已有较广泛的应用^[19-21]。

针对序列 x_1, x_2, \dots, x_N , 通过坐标延迟重构法, 可以将序列映射到一个 m 维的相空间中, 重构后的轨迹矩阵为^[21]

$$\mathbf{X} = \begin{bmatrix} x_1 & x_{1+\tau} & \cdots & x_{1+(m-1)\tau} \\ x_2 & x_{2+\tau} & \cdots & x_{2+(m-1)\tau} \\ \vdots & \vdots & & \vdots \\ x_p & x_{p+\tau} & \cdots & x_{p+(m-1)\tau} \end{bmatrix} \quad (1)$$

式中, τ 为时间延迟参数; m 为嵌入维数, 每一行可视作相空间中的一个相点坐标; 重构相空间轨迹由 P 个相点共同构成, P 的大小取决于 m 与 τ 的大小, $N = P + (m-1)\tau$ 。

相空间重构的核心问题在于 τ 与 m 的选取。 τ 太小会使相点分布过于密集, 太大则过于分散; m 过大会增大计算量, 过小则难以显示隐藏特征。

本研究采用互信息法求解 τ : 首先计算 x_n 和 $x_{n+\tau}$ ($n=1, 2, \dots, P$) 两者之间的互信息函数 $M(x_n, x_{n+\tau})$, 得到关于 τ 的函数 $M(\tau)$, 将第一个极小值点所对应的时间延迟参数称为最佳 τ_0 ^[21]。每个序列计算出的最佳 τ_0 存在差异, 为降低算法的复杂度和每个样本重构轨迹的差异性, 选取所有样本的最佳 τ_0 的平均值作为设定的 τ 值。通过计算, 最终本研究的 τ 取 10。由于本研究使用二维轨迹图来提取特征, 故嵌入维数 m 直接取为 2。

对于在谐振接地系统中不同情况下的 HIF 及各类干扰的零序电流序列, 以 $\tau = 10$, $m = 2$ 进行相空间重构, 其采样频率为 4 kHz, 时间窗口是 3 个工频周期。仿真与实测数据的零序电流波形和相空间重构轨迹如图 3 和图 4 所示, 为模拟不同接地介质及故障位置情况下的 HIF, 图 3(a)、图 3(b)及图 3(c)中所

示的 HIF, 其故障模型相关参数的设置如表 1 所示。

表 1 故障模型参数设置

Table 1 Parameter setting of fault model					
	故障点	V_p /kV	V_n /kV	R_p / Ω	R_n / Ω
HIF1	F6	2	3	350	350
HIF2	F14	1.3	1.6	450	450
HIF3	F17	2.4	3.4	650	650

图 3(d)、图 3(e)展示了谐振接地系统励磁涌流和电容器投切的零序电流波形及对应的重构轨迹图。所有重构图均为其上一个波形归一化后的轨迹, 横纵坐标无量纲。

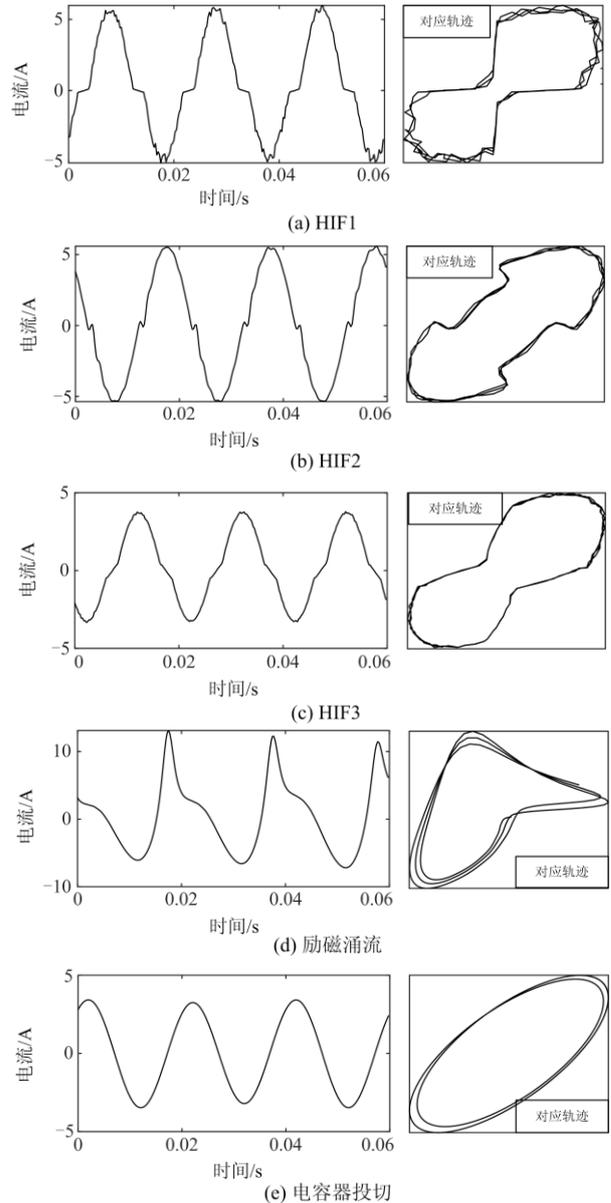


图 3 仿真模型的 HIF 和干扰波形及轨迹

Fig. 3 HIF and disturbance waveforms of simulation model and their trajectories

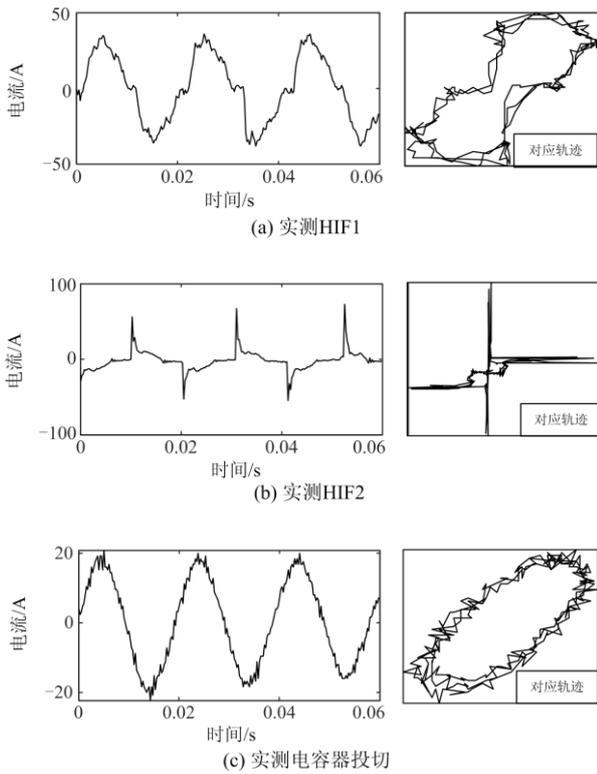


图4 实测 HIF 和干扰信号零序波形及轨迹

Fig. 4 HIF and disturbance waveforms of field measurement and their trajectories

从图3可以看出,在不同网络结构、不同接地介质发生HIF时,故障波形在幅值及零休现象上均存在差别。图3(a)的零休时间保持相对较长,图3(b)的零休现象则较为微弱,图3(c)的零序电流在过零点时变化趋势放缓。但经相空间重构后,上述三者的轨迹均为两侧存在凹陷的椭圆形。多次改变仿真故障模型参数,以模拟实际情况中不同的接地介质情况,所获得的零序电流经相空间重构后亦表现出相同的特征。出现励磁涌流时,零序电流波形出现正向冲击,轨迹图表现为存在单侧凸起的类椭圆形。电容器投切时,零序电流为规则的正弦波,轨迹图表现为规则的椭圆。

从图4可以发现,实测信号噪声含量较大,且不同情况下HIF的零序电流波形可能存在一定的差异。与仿真HIF相同,实测波形经相空间重构后,轨迹两侧均存在凹陷。即使存在严重畸变的故障波形(如图4(b)所示)经重构后亦表现出类似特征。然而,电容器投切时的零序电流重构轨迹图(如图4(c)所示)则仍表现为较规则的椭圆。

尽管图3与图4展示的HIF与干扰在时序波形的幅值上存在一定的区分度,但实际上零序电流的

幅值受接地介质类型、中性点接地方式等因素的影响,幅值变化幅度较大,难以直接分辨。相比时域信号,HIF与干扰波形的相空间轨迹图差异较大,且具有规律性。说明相空间轨迹图能够反映出高阻接地的故障特征,且仿真和实测波形的轨迹图存在较大相似性,这给利用仿真数据实现实测故障的准确检测带来了可能。

1.3 基于综合降噪策略的小波阈值降噪

从上述的相空间轨迹图可以看出,实测信号由于受到环境噪声的影响,相空间轨迹较为混沌,而仿真信号基本不含噪声,重构轨迹较为平滑。为此,本研究采用小波阈值降噪法进行降噪。其原理是通过含噪声信号进行小波分解,信号特征和噪声会被分散到不同幅值的小波系数中。一般而言,信号特征的小波系数都会大于噪声的小波系数,选取合适的阈值即可实现对噪声信号的剥离^[22]。

对于阈值选取,使用Donoho和Johnstone给出的固定阈值^[22],如式(2)所示。

$$\lambda = \sigma \sqrt{2 \ln N} \quad (2)$$

式中: N 为小波分解后各层小波系数的长度; σ 为估计噪声的方差, $\sigma = M/0.6745$, M 为进行第一层小波分解后高频小波系数的均值。

阈值处理方式通常有硬阈值与软阈值两种方法^[23]。对HIF实测数据经过傅里叶变换后,发现其频率峰值主要集中在基波、3次谐波与5次谐波。软阈值降噪会削弱本就微弱的3次与5次谐波分量,导致故障特征缺失。硬阈值处理时,降噪后数据不够平滑。因此本研究提出一种综合降噪策略:在3次和5次谐波所在频段采取硬阈值降噪,将小于阈值的高频噪声系数置0,但对大于阈值的系数不进行处理,降低降噪时对特征的削弱;其他频段的高频系数则采用软阈值降噪,保证降噪完之后的波形保持平滑。最终确定的阈值函数如式(3)所示。

$$\hat{W}_{j,k} = \begin{cases} W_{j,k} & |W_{j,k}| \geq \lambda, j \leq n-1 \\ \text{sgn}(W_{j,k})(|W_{j,k} - \lambda|) & |W_{j,k}| \geq \lambda, j > n-1 \\ 0 & |W_{j,k}| < \lambda \end{cases} \quad (3)$$

式中, $W_{j,k}$ 表示去噪前各层的小波系数,为小波分解后第 j 层第 k 点的值; $\hat{W}_{j,k}$ 为去噪后小波系数; n 为分解层数,对于零序电流的降噪,取为4。

降噪效果通常以信噪比(Signal-noise Ratio, SNR)与均方根误差(Root Mean Squared Error, RMSE)作为评判标准^[24]。SNR指信号功率与噪声功率之比,其单位为dB。SNR越小,噪声含量越高;反之,噪声含

量则越低。本研究噪声强度使用 SNR 表示。一般而言, SNR 越大, RMSE 越小, 则去噪效果越好。实际情况中, 还须结合去噪后的波形进行综合评价。以一组实测 HIF 数据作为示例, 使用不同降噪方式对其进行处理, 对比结果如表 2 及图 5 所示。

表 2 不同阈值处理方式的结果

Table 2 Result of different threshold processing methods

指标	硬阈值	软阈值	所提方法
SNR	19.108	18.089	18.752
RMSE	0.065 1	0.073 0	0.067 8

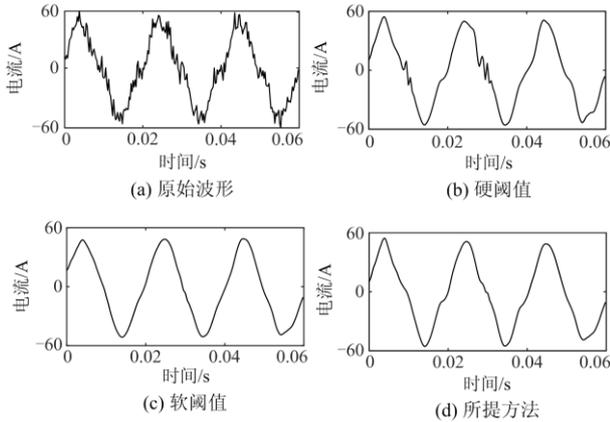


图 5 不同阈值处理方式的降噪效果

Fig. 5 Effect of different threshold processing methods

通过表 2 可以发现: 硬阈值降噪的 SNR 最高而 RMSE 最低, 但图 5(b) 显示其降噪后仍存在较多噪点; 软阈值在降噪后不存在噪点(如图 5(c) 所示), 但其 SNR 最低而 RMSE 最高, 且降噪后波形特征失真较为严重。所提方法在 SNR 及 RMSE 指标上与硬阈值方法相差不大, 但不存在噪点且基本保留了原始序列的特征(如图 5(d) 所示), 相较于其他两种方法有着明显的优势。图 4(a) 的实测 HIF1 信号降噪后的时域波形和相空间轨迹图如图 6 所示, 其时域特征得到较好地保留, 相空间轨迹变得平滑, 与仿真信号相似程度更高。

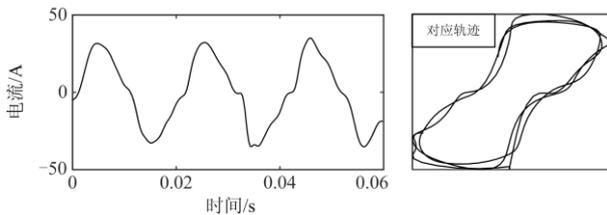


图 6 降噪后时域波形及轨迹

Fig. 6 Waveform and trajectory after denoising

1.4 结合迁移学习的故障识别

获得轨迹图后, 就可使用常见的图像识别模型

进行故障辨识。考虑到 HIF 的实测数据数量较少、仿真数据能够大量获取这一现实问题, 本研究应用迁移学习(Transfer Learning)^[25]机制进行训练, 力求所训练的模型在应对实测数据时也能够具备较高的辨识准确率。

含有大量标记样本的学习域称为源域, 标记数据较少的学习域称为目标域, 迁移学习的目标是利用在源域中学到的知识帮助学习目标域中的知识。其认为通过大量标记数据监督学习得到的特征提取器通常可以适用于其他目标领域^[26]。进行迁移学习后能够有效地提高分类准确率, 并且能大幅减少模型训练时间。

$$P_s = f_s(X_s, \theta_s) \quad (4)$$

$$P_t = f_t(X_t, \theta_t) \quad (5)$$

式中: X_s 与 X_t 分别代表源域与目标域数据; P_s 与 P_t 分别代表源域与目标域的预测值; f_s 与 f_t 分别代表源域与目标域到预测值的映射; θ_s 与 θ_t 代表源域和目标域的模式参数。模型训练目标如式(6)、式(7)所示。

$$\theta_s^* = \arg \min_{\theta_s} \frac{1}{N_s} \sum_{i=1}^{N_s} L(y_{s_i}, f(x_{s_i}, \theta_s)) \quad (6)$$

$$\theta_t^* = \arg \min_{\theta_t} \frac{1}{N_t} \sum_{i=1}^{N_t} L(y_{t_i}, f(x_{t_i}, \theta_t)) \quad (7)$$

式中: y_s 与 y_t 分别代表源域与目标域数据的实际标签; L 为损失函数; N_s 与 N_t 分别代表源域与目标域数据的训练样本总数。网络模型的训练目的是为了找到网络参数使得损失函数最小, 即预测值与实际标签之间的误差尽可能的小。

迁移学习步骤可概括为 4 步: ① 选定一个神经网络模型作为迁移学习的载体; ② 使用大量带标签源域数据训练该模型, 得到针对源域数据集的模型最优参数 θ_s^* ; ③ 将 θ_s^* 中适用于目标域的通用参数冻结; ④ 使用目标域数据对模型的未冻结参数进行训练, 以获得能够对目标域数据集进行准确辨识的模型最优参数 θ_t^* 。神经网络深层提取的信息通常为专有信息, 而前几层提取的信息通常为通用信息^[27], 故一般选择冻结网络的前几层参数作为通用参数。

HIF 仿真数据是通过数学模型生成的, 在对 HIF 故障机制和影响因素无法准确还原的情况下, 已有的数学模型只能是对真实故障的近似, 难以保证所获得的仿真样本和实测样本一模一样且满足相同的数据分布。考虑到仿真数据与实测数据之间存在很大的相似性, 将借助仿真数据实现实测小样本数据集的准确检测。具体的迁移过程如下: 首先使用仿

真数据训练一个基础网络；接着冻结网络的前几层参数；使用少量实测数据对网络进行训练，对未冻结的网络参数进行微调；最后得到一个能对实测数据集进行准确辨识的模型。模型结构如图 7 所示。

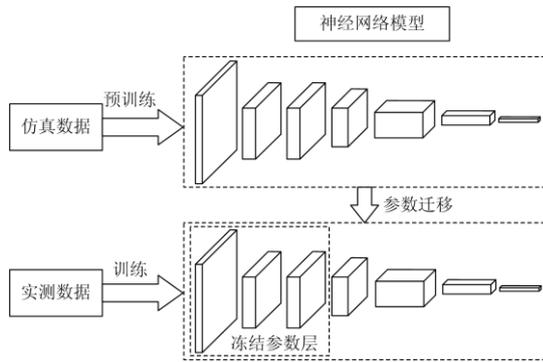


图 7 迁移学习结构图

Fig. 7 Structure diagram of transfer learning

1.5 HIF 识别流程

综上所述，本文所提算法的流程如图 8 所示。具体如下：① 首先获取仿真数据及实测数据，并各自分割为训练集及测试集；② 对所有样本进行小波阈值降噪，并绘制出每个样本对应的相空间重构轨迹图；③ 使用仿真训练数据的重构轨迹图对网络模型进行预训练；④ 冻结模型的部分参数，使用实测训练数据的重构轨迹图训练该模型实现迁移学习，最终所获得的模型即为本文所需的故障检测模型。将待检测样本的重构轨迹图输入到迁移后的神经网络模型中，模型即可判定该样本是否为 HIF。

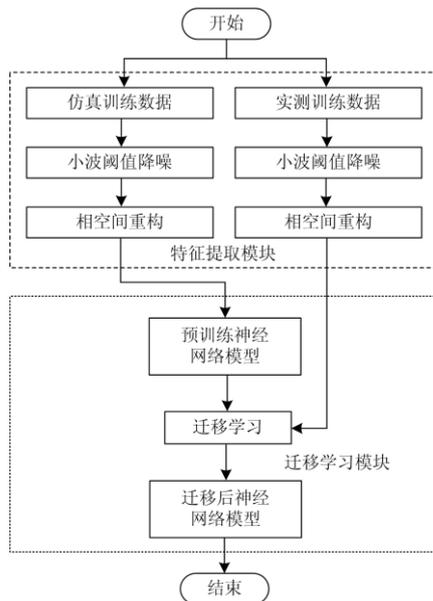


图 8 算法处理流程

Fig. 8 Processing flow of the algorithm

2 算例分析

2.1 仿真及实测数据的获取

本研究设计的干扰项包括谐振接地系统中发生的单相接地故障、电容器投切、励磁涌流及铁磁谐振^[28]4 种过电压。铁磁谐振包括基频谐振、高频谐振与分频谐振。在图 1 所示的谐振接地系统配电网模型中仿真得到 4 种干扰的零序电流波形如图 9 所示。尽管图 9 中各类干扰与图 3 所示的 HIF 波形在幅值上有一定的区分度，但在不同接地介质下，HIF 的零序电流在几安到几十安之间，仅从幅值上难以将干扰与 HIF 区分开来。

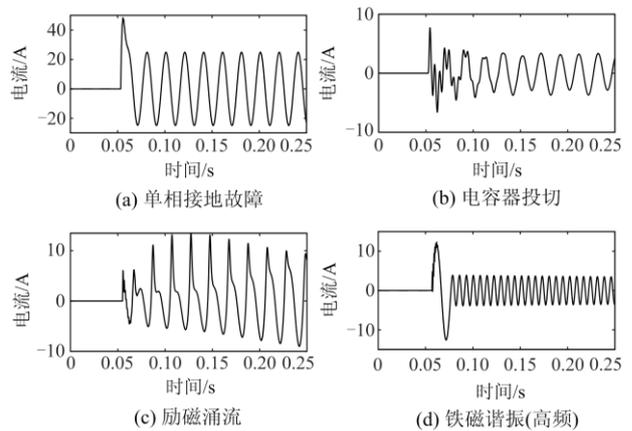


图 9 各类干扰的零序电流波形

Fig. 9 Zero-sequence current waveforms of various interferences

通过改变故障模型参数、故障点位置以及故障发生相角来获取相应的数据，最终收集到各类干扰样本 600 组，每个类别各 150 组，HIF 样本也为 600 组。采样频率为 4 kHz，每组数据均从故障或干扰发生前 2 周波开始记录，总时长为 0.30 s。

不同情况下各类工况的暂态过程存在较大差异，模型应能够在故障发生的任何时刻进行准确辨识，故训练样本同时包括了暂态及稳态数据。为避免同一组独立数据的信息同时存在于训练数据和测试数据中，随机选取 1 000 组作为仿真训练数据，剩下的 200 组作为仿真测试数据。事实上，HIF 故障特征一般会持续 8~10 周波^[16]，故本研究以 3 周波作为输入样本长度。将每组数据按 3 个工频周期(240 个点)依次无重叠分割，最终获得 4 800 个样本。考虑到实际测量时通常含有热噪声和测量噪声^[13]，热噪声属于高斯白噪声，测量噪声也常用高斯白噪声进行模拟。为增加模型的鲁棒性和抗噪能力，每个样本中分别加入信噪比为 30 dB、20 dB、15 dB 的高斯白噪声实现样本增强。最终获得共 19 200 组数据，

其中 16 000 组构成仿真训练样本集, 3 200 组构成仿真测试样本集。

从实际系统收集了 60 组实测数据, 包括 HIF 与各种干扰。每组数据均从故障或干扰发生前 2 周波开始, 录波总时长为 0.30 s。其中 HIF 样本为 31 组, 干扰数据 29 组。与仿真数据集相同, 先随机选取 40 组作为实测训练数据, 剩下的 20 组作为实测测试数据。按照上文分割方式, 最终获得 191 组实测训练样本, 99 组实测测试样本。随后对所有样本进行小波阈值降噪, 使用相空间重构算法绘制轨迹图。

2.2 图像识别网络的选取

利用仿真训练数据集, 分别对 VGG、AlexNet、LetNet、ResNet 以及 GoogLeNet 五类模型进行训练, 迭代次数设置为 100 次。训练完成后, 用仿真测试集以及全部实测数据对模型进行测试, 结果如图 10 所示。

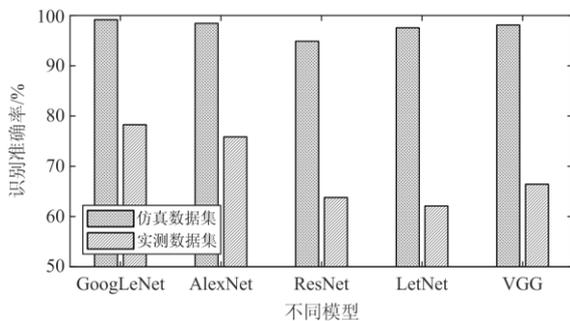


图 10 各类模型测试结果

Fig. 10 Test results of various models

从图 10 可以看出仅使用仿真数据训练得到的各个模型对仿真测试数据的识别准确率均在 95% 以上。各模型对实测数据集的识别准确率均较低, 这是由于实测数据与仿真数据存在着较大差异, 其中只有 GoogLeNet 和 AlexNet 的识别准确率在 70% 以上。GoogLeNet 网络模型不仅对仿真数据识别准确率最高, 对实测数据的识别率也最高, 说明该模型能够较好地地区分 HIF 与干扰之间的差异, 故选定其作为本研究的识别模型。

2.3 冻结层数确定

GoogLeNet 网络共 22 层, 主要优点是采用了 Inception 架构, 参数数量少, 且从多尺度提取特征, 识别效果较好, 其具体结构见文献[29]。冻结不同网络层数, 随后使用实测训练集进行训练, 迭代次数均设为 50 次, 识别结果如图 11 所示, 为验证迁移后模型的识别效果, 同时使用了仿真和实测测试集进行测试。

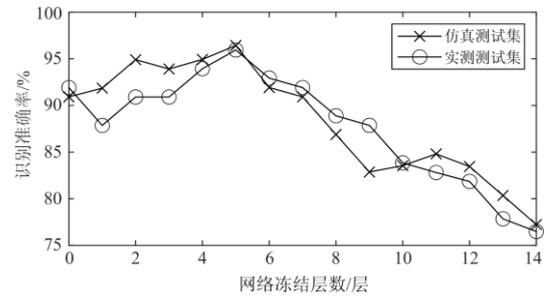


图 11 冻结不同层数的测试结果

Fig. 11 Test results of freezing different layers

由图 11 可见, 当冻结层数为 0 时, 即使用实测训练集对模型进行再次训练, 由于仿真样本和实测样本存在差异, 故仿真测试集的准确率较低。而实测训练样本比较少, 故实测测试集的准确率也低。冻结第 1 层时, 加入了仿真数据训练模型得到的参数, 模型出现不适应, 实测测试集的准确率下降。但是对于仿真测试集而言, 由于模型保留了从仿真样本提取初始信息的方式, 因此准确率提高。通常深度学习网络前端各层用于提取粗粒度信息, 后端各层用于提取细粒度信息。因此, 随着冻结层数的增加, 模型提取仿真样本和实测样本共同特征的能力不断地增强, 仿真和实测训练集的准确率均不断地提升。从第 6 层开始主要处理细节特征提取工作。随着冻结层数的增加, 模型提取仿真及实测数据共同特征的能力基本稳定不变。在参数冻结后, 细节特征提取前端使用仿真样本训练得到的参数, 后端则使用实测样本进行训练, 冻结前后两层的特征提取方式差异较大, 这使得后端网络模型训练的效果变差。因此无论对于仿真还是实测样本而言, 测试的准确率均呈下降趋势。从图中可以看出, 最佳冻结参数为 5 层, 故在仿真数据训练完成后, 将前 5 层参数冻结, 将其作为通用参数, 使用实测训练数据对其余网络层参数进行调整。

为验证迁移学习的有效性, 与其他两类训练方式进行了对比: (1) 仅使用实测训练数据训练模型; (2) 将实测、仿真训练数据混合, 使用混合数据训练模型。最终三类训练方式对实测测试集的识别结果如图 12 所示。

从图 12 可以看出: 使用迁移学习的训练方式能够获得最佳辨识效果, 对于干扰与故障的辨识率都在 95% 以上; 仅使用实测数据训练时, 由于其样本数量过少, 模型通常会陷入过拟合; 使用混合数据训练模型时, 由于仿真数据的数量远大于实测数据, 造成数据不平衡, 得到的模型对仿真数据辨识率高, 而对实测数据辨识效果欠佳。

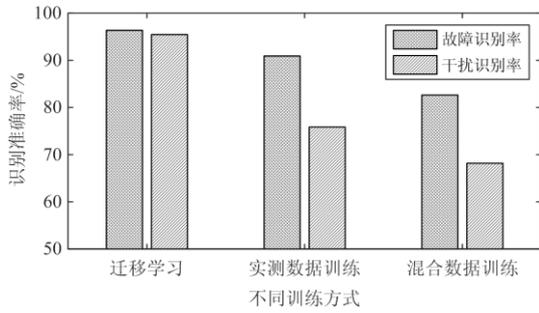
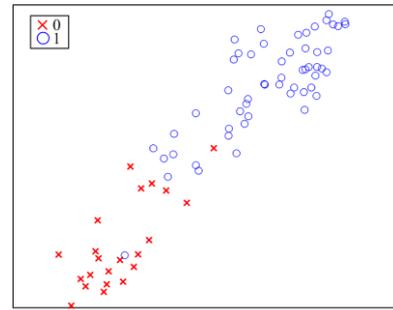


图 12 不同训练方式结果对比

Fig. 12 Comparison results of different training methods

2.4 特征可视化及识别结果

t 分布-随机近邻嵌入(t-SNE)是一种非线性的降维算法,其能实现高维数据向低维空间的映射,通过该算法可对高维数据进行可视化,常用来验证特征提取的效果。本文使用它对仿真、实测测试集以及对二者进行特征提取的结果进行二维展示,结果如图 13 所示。



(d) 实测数据集的特征量

图 13 原始数据与它的特征量可视化结果对比

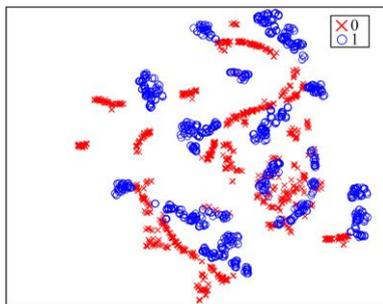
Fig. 13 Comparison of visualization results between original data and its characteristic quantity

其中 0 和 1 分别代表干扰与 HIF,横纵坐标表示映射到低维空间的对应位置,无实际意义。从图中可以看出,经特征提取后,仿真及实测数据集的可区分度更高。完成特征提取后,通过分类层实现故障识别,检测结果如表 3 所示。仿真和实测数据的识别准确率分别为 96.81%和 95.96%,无论是故障还是干扰,算法均能够准确识别。

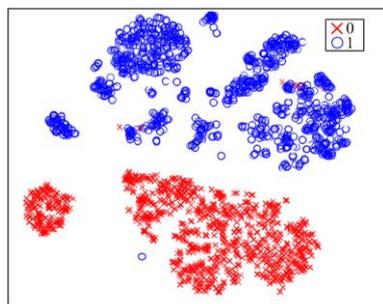
表 3 所提算法检测结果

Table 3 Detection results of the proposed algorithm

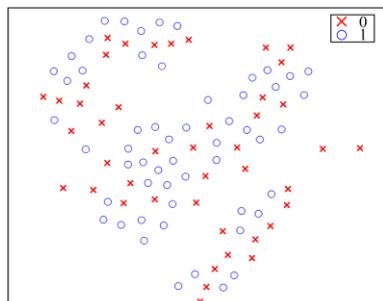
	故障识别率/%	干扰识别率/%	总识别率/%
仿真数据	97.06	96.56	96.81
实测数据	96.36	95.45	95.96



(a) 仿真原始数据集



(b) 仿真数据集的特征量



(c) 实测原始数据集

3 算法性能检验

由于上述的仿真测试集中部分样本已含有较高强度的噪声,会给后续的分析造成干扰。故从初始的仿真测试集中随机获取了 1 000 组不含噪声的仿真样本构成新的仿真测试集,其中 500 组为干扰,500 组为 HIF,而实测测试集则仍使用与上述一致的数据集。

3.1 抗噪能力分析

实测信号一般都含有较大噪声,电磁环境的差异也会导致同样本的噪声含量存在较大差异。所提方法利用小波阈值降噪,有必要进一步评价其抗噪性能。图 14 是仿真信号分别加入 SNR 为 20 dB、15 dB、10 dB 的高斯白噪声后的波形。可以看出加入高强度噪声后特征基本完全被掩盖,识别含噪数据对算法的要求极高。

图 15 展示了不同强度噪声对测试集识别准确率的影响,随着噪声含量增大,识别准确率逐渐降低。对仿真数据而言,即便是在 SNR 为 10 dB 的噪声强度下模型仍能有 82.97%的识别准确率;对实测数据而言,在 SNR 为 13 dB 的噪声环境下识别准确

率降低到 81.82%。经计算发现, 所获取的实测数据大多含有 20 dB 左右的噪声, 故其受噪声影响更大。综上, 所提算法抗噪能力较强, 在强噪声情况下仍能够保持较高的准确率。

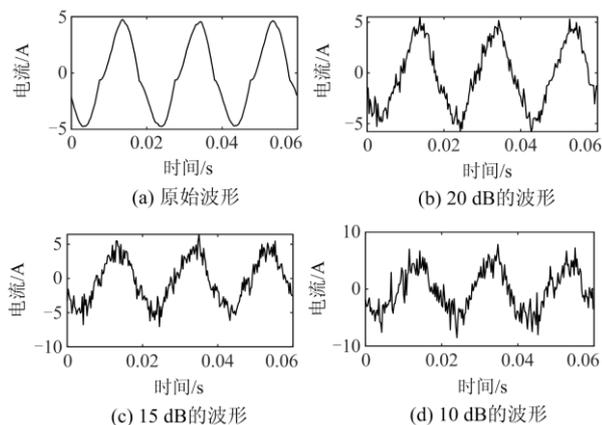


图 14 加入不同强度噪声后的波形

Fig. 14 Waveforms after adding noise of different intensity

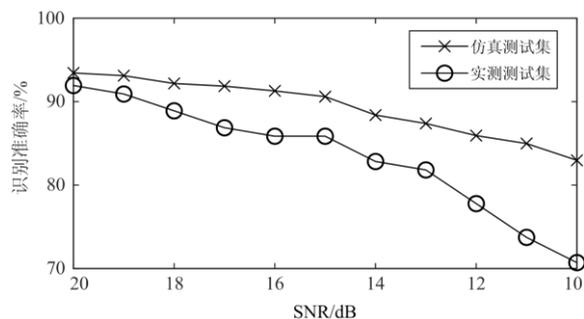


图 15 不同噪声强度下的识别结果

Fig. 15 Recognition results under different noise intensity

3.2 数据缺失的影响

数据在采集和记录过程中可能会出现数据缺失。由于故障波形具有不可补录性, 需要通过数据填充的方式进行处理。然而数据填充可能无法准确还原其实际特征状态, 引起误判或是漏判。相空间重构生成的轨迹图, 在少量数据缺失时轨迹轮廓基本不发生改变, 无需填充处理, 使用存在缺失的数据生成轨迹图也可实现故障的检测。

为评价数据缺失对故障辨识的影响, 本研究考虑了随机缺失与连续缺失两种情况。① 随机缺失: 随机将测试样本中的 10~60 个点置为 0。② 连续缺失: 随机选取缺失起始位置, 将连续的 10~60 个点置为 0。两类情况示例如图 16 所示。

两类情况的检测结果如图 17 和图 18 所示。通过对比发现, 相较于连续缺失, 随机缺失对检测准确率的影响更大, 原因是其对轨迹图的影响更大。

在随机缺失或是连续缺失 20 个点内, 所提算法的识别准确率均在 90% 以上; 即便是在 240 个点缺失了 40 个点的极端情况下, 仍能够保持 80% 以上的准确率。证明了所提方法在部分数据缺失情况下依然能够保持一定的准确率。

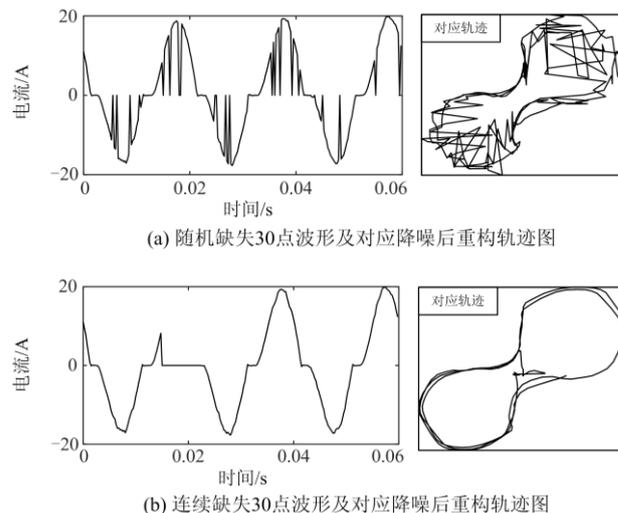


图 16 数据缺失时的波形及轨迹

Fig. 16 Waveforms and trajectories when data is missing

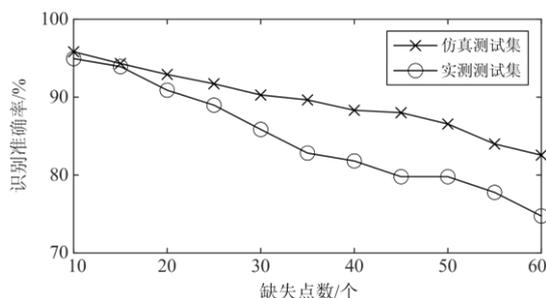


图 17 数据随机缺失检测结果

Fig. 17 Detection results of random missing data

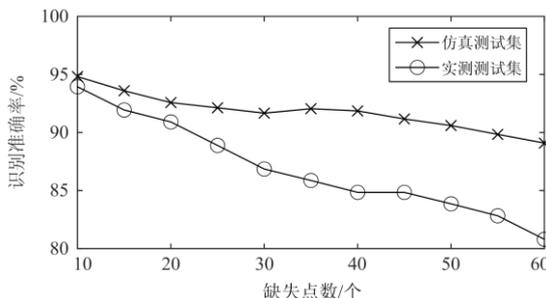


图 18 数据连续缺失检测结果

Fig. 18 Detection results of continuous missing data

3.3 故障回路间歇性导通的影响

为验证所提方法在故障回路间歇性导通时的识别效果, 仿真时使用随机方波生成器控制故障回路

的开断,模拟了故障回路的间歇性导通现象。图 19 为在谐振接地系统中模拟的间歇性导通 HIF 波形,0.1 s 开始随机导通,导通时零序电流出现零休现象,开断时零序电流基本为 0。

在图 1 所示的谐振接地系统中,进行了 50 组实验,录波时长为 1 s。从故障前 1 周期开始,对样本进行分割,最终获得了 750 组样本直接进行测试,检测成功率为 95.33%。图 19 示例波形的判定结果在其下方展示。

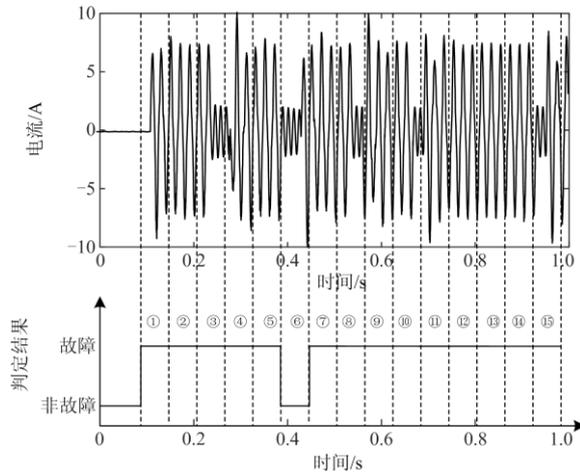


图 19 故障回路间歇性导通时单次故障判定结果

Fig. 19 Single fault judgment results when intermittent conduction of fault loop

该故障录波被分割为 15 个样本,其中第 6 个样本被判别为非故障,事实上,这个阶段,故障回路基本处于断开状态,只存在极少部分的故障波形,最终导致漏判。而其他被分割的样本均含有至少一个完整周波的故障波形,均准确提取其故障特征,得到正确的判别结果。也就是说在故障回路出现间歇性导通情况下,所提方法依然能准确识别出 HIF 事件。

3.4 算法对比验证

文献[13]使用小波变换提取电流特征,将小波变换得到的时频图作为特征,利用改进的 CNN 网络对时频图进行识别以判定 HIF 的发生。文献[14]通过快速傅里叶变换对连续的 6 个电流时间窗序列进行处理,将得到的频域信息分成 8 个频段,使用频段范围内能量的平均值作为每个频段的特征值,得到一个 6×8 的特征矩阵。使用该特征矩阵训练了一个轻量级的 CNN 网络,实现 HIF 的检测。为评价本研究所提方法的性能,将其与上述两种方法进行对比。分别使用不同的训练方式、测试集准确率进行综合对比,结果如表 4 所示。

表 4 各种方法辨识准确率对比结果

Table 4 Comparison results of identification accuracy of various methods

测试集	实测数据		仿真数据	
	仿真数据 训练	迁移学习	仿真数据 训练	迁移学习
所提方法	77.78%	95.96%	99.22%	96.44%
文献[13]	55.56%	70.71%	98.25%	78.13%
文献[14]	62.63%	84.85%	97.59%	88.47%

从表 4 可以看出,若仅使用仿真数据进行训练和测试,3 种方法的辨识准确率均超过 97%,其中所提方法具有最高的辨识准确率。然而所训练的模型对实测数据的辨识准确率均不超过 80%。说明仿真和实测数据的差异性会对机器学习算法造成影响,但所提方法仍有着最高的辨识准确率。此外,引入迁移学习机制后,3 种方法对仿真数据的辨识准确率均下降了,但所提方法依然保持 96.44% 的辨识准确率,而文献[13]的方法最低,仅为 78.13%。当使用迁移学习得到的模型对实测数据进行检测时,结果较非迁移学习有所改善。所提方法最高,达到 95.96%,文献[14]次之,文献[13]最低。上述说明所提方法相较于其他两种方法有着明显的优势。

4 结语

在谐振接地系统中,针对高阻接地故障(HIF)特征微弱,且与非故障干扰相似性较高的问题,提出一种新的 HIF 检测方法。以零序电流相空间重构的轨迹图为特征,将迁移学习和 GoogLeNet 相结合实现小样本下的实测 HIF 辨识。同时,使用小波降噪方法提高轨迹图的辨识度。

所提方法有着较高的可靠性,对仿真以及实测测试集识别准确率分别为 96.44% 和 95.96%。在 13 dB 的强噪声下仿真及实测测试集仍能够达到 80% 以上的准确率。在考虑故障回路间歇性导通时,识别准确率仍能够超过 95%。

简言之,所提方法能够通过小样本实测数据集训练一个具有较高识别能力的诊断模型,面对各种干扰仍能保持检测的准确性,具有较高的工程应用价值。当燃熄弧出现强烈的随机波动时,所提方法可能会失效,有效提高算法识别的可靠性将是下一步研究的工作。

参考文献

[1] 姚忠胜,钱虹,吴文军,等.基于多因素综合评价和改进灰色关联的供电可靠性研究[J].电力系统保护与控

- 制, 2021, 49(11): 28-34.
YAO Zhongsheng, QIAN Hong, WU Wenjun, et al. Research on power supply reliability based on multi-factor comprehensive evaluation and improved gray relation[J]. Power System Protection and Control, 2021, 49(11): 28-34.
- [2] TAVAKOLI M, NAFAR M. Human reliability analysis in maintenance team of power transmission system protection[J]. Protection and Control of Modern Power Systems, 2020, 5(4): 270-282.
- [3] 高鑫, 唐飞, 张童彦, 等. 配电网防风抗灾加固措施优化决策方法[J]. 发电技术, 2021, 42(1): 78-85.
GAO Xin, TANG Fei, ZHANG Tongyan, et al. Optimal decision-making method of wind-proof and disaster-resistant reinforcement measures for distribution network[J]. Power Generation Technology, 2021, 42(1): 78-85.
- [4] 杨楠, 崔伟, 王智伟, 等. 含风电特高压直流系统单极接地故障暂态特性研究[J]. 高压电器, 2020, 56(2): 142-149, 157.
YANG Nan, CUI Wei, WANG Zhiwei, et al. Research on transient characteristics of monopolar grounding fault for wind power integrated UHVDC[J]. High Voltage Apparatus, 2020, 56(2): 142-149, 157.
- [5] 金晶, 殷勤. 含电阻型超导限流器的南澳柔性直流系统故障特性分析[J]. 高压电器, 2020, 56(12): 286-291.
JIN Jing, YIN Qin. Fault characteristics analysis of Nan'ao flexible DC system with resistance superconducting current limiter[J]. High Voltage Apparatus, 2020, 56(12): 286-291.
- [6] 李福志, 郑卫宾, 张文海, 等. 基于回路直流电阻测量的输电线路单相接地故障离线故障定位[J]. 中国电力, 2021, 54(2): 140-146.
LI Fuzhi, ZHENG Weibin, ZHANG Wenhai, et al. Fault path direct-current resistance based off-line single-phase-to-ground fault location[J]. Electric Power, 2021, 54(2): 140-146.
- [7] AMIN G, HOSSEIN M, HERBERT G, et al. High-impedance fault detection in the distribution network using the time-frequency-based algorithm[J]. IEEE Transactions on Power Delivery, 2015, 30(3): 1260-1268.
- [8] 王宾, 崔鑫. 中性点经消弧线圈接地配电网弧光高阻接地故障非线性建模及故障解析分析[J]. 中国电机工程学报, 2021, 41(11): 3864-3873.
WANG Bin, CUI Xin. Nonlinear modeling and analytical analysis of arc high resistance grounding fault in distribution network with neutral grounding via arc suppression coil[J]. Proceedings of the CSEE, 2021, 41(11): 3864-3873.
- [9] 耿建昭, 王宾, 董新洲, 等. 中性点有效接地配电网高阻接地故障特征分析及检测[J]. 电力系统自动化, 2013, 37(16): 85-91.
GENG Jianzhao, WANG Bin, DONG Xinzhou, et al. Analysis and detection of high impedance grounding fault in neutral point effectively grounding distribution network[J]. Automation of Electric Power Systems, 2013, 37(16): 85-91.
- [10] 韦明杰, 石访, 张恒旭, 等. 基于零序电流波形区间斜率曲线的配电网高阻接地故障检测[J]. 电力系统自动化, 2020, 44(14): 164-171.
WEI Mingjie, SHI Fang, ZHANG Hengxu, et al. Detection of high impedance grounding fault in distribution network based on interval slope curves of zero-sequence current[J]. Automation of Electric Power Systems, 2020, 44(14): 164-171.
- [11] 朱晓娟, 林圣, 张姝, 等. 基于小波能量矩的高阻接地故障检测方法[J]. 电力自动化设备, 2016, 36(12): 161-168.
ZHU Xiaojuan, LIN Sheng, ZHANG Shu, et al. High-impedance grounding fault detection based on wavelet energy moment[J]. Electric Power Automation Equipment, 2016, 36(12): 161-168.
- [12] WANG X W, GAO J, WEI X X, et al. High impedance fault detection method based on variational mode decomposition and Teager-Kaiser energy operators for distribution network[J]. IEEE Transactions on Smart Grid, 2019, 10(6): 6041-6054.
- [13] WANG S Y, DEHGHANIAN P. On the use of artificial intelligence for high impedance fault detection and electrical safety[J]. IEEE Transactions on Industry Applications, 2020, 56(6): 7208-7216.
- [14] SIROJAN T, LU S, PHUNG B, et al. Sustainable deep learning at grid edge for real-time high impedance fault detection[J]. IEEE Transactions on Sustainable Computing, 2022, 7(2): 346-357.
- [15] CHAITANYA BK, YADAV A, PAZOKI M. An intelligent detection of high-impedance faults for distribution lines integrated with distributed generators[J]. IEEE Systems Journal, 2020, 14(1): 870-879.
- [16] XIAO Q M, GUO M F, CHEN D Y. High-impedance fault detection method based on one-dimensional variational prototyping-encoder for distribution networks[J]. IEEE Systems Journal, 2022, 16(1): 966-976.
- [17] DOUGLAS P S, CAGIL O, ANWAAR U. Vegetation high-impedance faults' high-frequency signatures via sparse coding[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(7): 5233-5242.

- [18] 肖万红, 阎桂荣, 韩宇航. 混沌时序相空间重构参数确定的信息论方法[J]. 物理学报, 2005, 54(2): 550-556.
XIAO Wanhong, YAN Guirong, HAN Yuhang. Information theory approach to determine embedding parameters for phase space reconstruction of chaotic time series[J]. Acta Physica Sinica, 2005, 54(2): 550-556.
- [19] 郭霖徽, 刘亚东, 王鹏, 等. 基于相空间重构与平均电导特征的配电网单相接地故障辨识[J]. 电力系统自动化, 2019, 43(7): 192-198.
GUO Linhui, LIU Yadong, WANG Peng, et al. Single-phase grounding fault recognition in distribution networks based on phase-space reconstruction and average conductance characteristics[J]. Automation of Electric Power Systems, 2019, 43(7): 192-198.
- [20] 武昭旭, 杨岸, 祝龙记. 基于循环神经网络的电能质量扰动识别[J]. 电力系统保护与控制, 2020, 48(18): 88-94.
WU Zhaoxu, YANG An, ZHU Longji. Power quality disturbance recognition based on a recurrent neural network[J]. Power System Protection and Control, 2020, 48(18): 88-94.
- [21] 陈伟, 何家欢, 裴喜平. 基于相空间重构和卷积神经网络的电能质量扰动分类[J]. 电力系统保护与控制, 2018, 46(14): 87-93.
CHEN Wei, HE Jiahuan, PEI Xiping. Classification for power quality disturbance based on phase-space reconstruction and convolution neural network[J]. Power System Protection and Control, 2018, 46(14): 87-93.
- [22] 王维博, 董蕊莹, 曾文入, 等. 基于改进阈值和阈值函数的电能质量小波去噪方法[J]. 电工技术学报, 2019, 34(2): 409-418.
WANG Weibo, DONG Ruiying, ZENG Wenru, et al. A wavelet denoising method for power quality based on an improved threshold and threshold function[J]. Transactions of China Electrotechnical Society, 2019, 34(2): 409-418.
- [23] 马星河, 张登奎, 朱昊哲, 等. 基于 EWT 的高压电缆局部放电信号降噪研究[J]. 电力系统保护与控制, 2020, 48(23): 108-114.
MA Xinghe, ZHANG Dengkui, ZHU Haozhe, et al. Research on noise reduction of a partial discharge signal of a high voltage cable based on EWT[J]. Power System Protection and Control, 2020, 48(23): 108-114.
- [24] 钟建军, 宋健, 由长喜, 等. 基于信噪比评价的阈值优选小波去噪法[J]. 清华大学学报(自然科学版), 2014, 54(2): 259-263.
ZHONG Jianjun, SONG Jian, YOU Changxi, et al. Wavelet denoising method with threshold selection rules based on SNR evaluations[J]. Journal of Tsinghua University (Science & Technology), 2014, 54(2): 259-263.
- [25] 庄福振, 罗平, 何清, 等. 迁移学习研究进展[J]. 软件学报, 2015, 26(1): 26-39.
ZHUANG Fuzhen, LUO Ping, HE Qing, et al. Survey on transfer learning research[J]. Journal of Software, 2015, 26(1): 26-39.
- [26] 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.
YANG Wei, ZHU Taiyun, ZHANG Guobao, et al. Research on partial discharge pattern recognition and classification in GIS based on convolutional neural network and transfer learning in power internet of things[J]. High Voltage Apparatus, 2020, 56(9): 20-25, 32.
- [27] 史凯钰, 张东霞, 韩肖清, 等. 基于 LSTM 与迁移学习的光伏发电功率预测数字孪生模型[J/OL]. 电网技术: 1-10[2021-11-20]. <https://doi.org/10.13335/j.1000-3673.pst.2021.0738>.
SHI Kaiyu, ZHANG Dongxia, HAN Xiaoqing, et al. Digital twin model of photovoltaic power generation prediction based on LSTM and transfer learning[J/OL]. Power System Technology: 1-10[2021-11-20]. <https://doi.org/10.13335/j.1000-3673.pst.2021.0738>.
- [28] 周默, 孙岩洲. 电网中性点不同接地方式下铁磁谐振的消谐研究[J]. 高压电器, 2015, 51(1): 80-85.
ZHOU Mo, SUN Yanzhou. Eliminating ferroresonance for distribution network with different neutral grounding modes[J]. High Voltage Apparatus, 2015, 51(1): 80-85.
- [29] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C] // Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2015, Boston, USA: 1-9.

收稿日期: 2021-09-17; 修回日期: 2022-03-04

作者简介:

杨耿杰(1966—), 男, 教授, 研究方向为电力系统自动化; E-mail: ygj23802@126.com

王康(1997—), 男, 硕士研究生, 研究方向为配电网自动化; E-mail: 729198207@qq.com

高伟(1983—), 男, 通信作者, 副教授, 研究方向为电力系统及设备故障诊断。E-mail: 80201931@qq.com

(编辑 葛艳娜)