

DOI: 10.19783/j.cnki.pspc.231417

基于格拉姆角场与 ResNet 的输电线路故障辨识方法

赵启^{1,2}, 王建³, 林丰恺³, 陈军^{1,2}, 南东亮^{1,2}, 欧阳金鑫³

(1. 国网新疆电力有限公司电力科学研究院, 新疆 乌鲁木齐 830011; 2. 新疆电力系统全过程仿真重点实验室, 新疆 乌鲁木齐 830011; 3. 重庆大学输变电装备技术全国重点实验室, 重庆 400044)

摘要: 针对如何利用实际故障录波数据, 提取和放大故障特征差异, 开展故障类型与故障原因辨识的问题, 提出了基于格拉姆角场与迁移学习-ResNet 的输电线路故障辨识方法。首先, 统计分析了输电线路故障类型和故障原因的分布特征, 用于指导构建适用于类不平衡问题的故障分类器。然后, 利用格拉姆角场变换将采集得到的故障电压、电流时序信号转化为格拉姆角场图像, 放大故障特征差异, 作为故障分类器的输入。进一步, 将生成的图像集输入搭建好的故障分类器进行网络训练和测试, 输出输电线路故障类型和故障原因。最后, 完全采用真实故障录波数据开展了算例分析。结果表明: 所提方法对故障类型的辨识准确率达到了 97.51%, 对故障原因的辨识准确率达到了 94.23%。并且将训练的故障辨识网络迁移至其他地区时, 仍然具有较好的故障辨识效果和泛化性能。所提方法为基于暂态波形数据驱动的故障辨识提供了新方法, 可以用于实际电网的输电线路故障辨识。

关键词: 输电线路; 故障辨识; 格拉姆角场; 残差神经网络; 迁移学习

Transmission line fault identification method based on Gramian angular field and ResNet

ZHAO Qi^{1,2}, WANG Jian³, LIN Fengkai³, CHEN Jun^{1,2}, NAN Dongliang^{1,2}, OUYANG Jinxin³

(1. Electric Power Research Institute of State Grid Xinjiang Electric Power Co., Ltd., Urumqi 830011, China; 2. Xinjiang Key Laboratory of Whole Process Simulation for Power System, Urumqi 830011, China; 3. State Key Laboratory of Power Transmission Equipment Technology, Chongqing University, Chongqing 400044, China)

Abstract: There is a problem of how to use actual fault recorded data to extract and amplify fault feature differences, and carry out fault type and cause identification. Thus a fault identification method for transmission lines based on Gramian angular field (GAF) and transfer learning-ResNet is proposed. First, the distribution characteristics of fault type and cause on transmission lines are analyzed. These are used to guide the construction of fault classifiers suitable for a class imbalance problem. Second, the collected fault voltage and current time sequence signals are converted into GAF images by GAF transform, so that the fault feature differences are amplified as the input of the fault classifier. The generated GAF image set is then fed into an established fault classifier for network training and testing, and the type and cause of transmission line faults are output. Finally, an example analysis using real fault recorded data shows that the proposed method has achieved 97.51% accuracy for fault type identification and 94.23% accuracy for fault cause identification; the trained fault identification network still achieves good fault identification and generalization performance when transferred to other regions. The proposed method provides a novel method for fault identification based on transient waveform data. It can be used for transmission line fault identification in practical power grids.

This work is supported by the National Natural Science Foundation of China (No. 52277079).

Key words: transmission line; fault identification; Gramian angular field; ResNet; transfer learning

0 引言

输电线路作为电力系统中最为重要的一部分,

基金项目: 国家自然科学基金项目资助(52277079); 重庆市留学人员回国创业创新支持计划项目资助(cx2021036)

其分布范围广泛, 跨越区域地形复杂, 运行环境多变, 因此在运行过程中容易遭受恶劣天气或自然灾害的影响, 会发生各种类型的故障^[1]。及时准确地识别故障类型和原因, 对于指导线路自动重合闸、恢复供电、缩短停电时间、确保电力系统安全稳定运行具有重要意义。

目前,在国内外有关输电线路故障检测、原因辨识的研究中,根据特征输入的类型,可以分为基于信号处理的方法^[2]和基于故障波形图像识别的方法^[3];根据使用的辨识分类器,又可以分为基于机器学习的方法^[4-5]和基于深度学习的方法^[6-7]。

基于信号处理的方法是根据故障发生时电气量的变化来实现故障辨识。文献[8]通过小波变换来直接分析不同性质的信号,以达到故障检测与分类的目的。文献[9]利用离散傅里叶变换来分析频率特性急剧变化的电压、电流信号的相位,通过其相位差异区分故障。这类方法在故障类型辨识方面取得了较好的表现,但在辨识过程中会遇到频谱能量阈值设置困难的问题,因此很难用于实际情况下的故障辨识。

相比之下,机器学习算法不需要设置阈值,仅依靠网络对不同类型和原因故障特征的提取即可实现故障辨识,其计算速度快、效率高,受线路参数及运行方式的影响较小^[10]。文献[11-12]利用经小波变换过后的故障信号作为特征参数,通过与支持向量机(support vector machines, SVM)、广义回归神经网络、K 邻近算法(K-nearest neighbor, KNN)和随机森林等机器学习算法相结合的方式,实现了输电线路的故障辨识。文献[13]利用人工神经网络对输电线路故障进行了识别和定位,证明了该网络在输电线路故障辨识中的可行性。这类方法提取的特征量往往比较单一,故障辨识的效果很大程度上取决于设计的神经网络结构和参数,当网络设置不合理时便难以实现故障的准确辨识。

近年来,随着深度学习的不断发展,越来越多的深度学习算法被应用到图像识别领域中来。文献[14]运用胶囊网络(capsule net, CN)和稀疏滤波技术,将经过小波变换后的故障电压、电流信号转换成二维图像输入网络,实现故障的辨识。文献[15]提出了使用格拉姆角场变换将变压器油中溶解的气体数据转化为特征图像集,然后送入后续改进的深度压缩模型实现变压器故障的准确识别。文献[16]利用变压器稳态运行时的振动信号存在周期性的特点,提出基于格拉姆角场与迁移学习-AlexNet 的变压器绕组松动故障诊断方法。

实际情况中数据会存在标签丢失或数量不足的问题,这给深度学习模型的训练带来了困扰。迁移学习能够充分提取缺少标签或残缺的数据特征,将原先训练的模型特征迁移至新的模型中来,进而优化模型的训练^[17]。文献[18]针对输电线路故障类型和故障原因中存在的类不平衡性,提出了基于迁移学习的 AlexNet 故障辨识方法,提高了对类不平衡

故障的辨识准确度。文献[19]基于迁移学习理论,将输电线路分为源线路和目标线路,提出一种基于深度-迁移学习的输电线路故障类型辨识方法。这些方法大多都是使用仿真数据来进行模型的训练与测试,当使用真实故障录波数据时,由于不同故障原因下有些故障的暂态波形具有相似性,故障特征差异在波形形态上的表达不明显,因此模型不能够准确地辨识故障。

综上所述,为了克服直接使用暂态波形图像作为输入,对于某些高阻性、轻微故障波形差异不够明显、辨识效果欠佳的问题,本文提出了一种基于格拉姆角场(gramian angular fields, GAF)与迁移学习-ResNet 的输电线路故障辨识方法。利用格拉姆角场将变电站内采集到的一维故障电压、电流时序信号转换为二维彩色图像,通过改变数据维度、放大暂态波形特征的方式使深度神经网络从“视觉上”对波形图像进行识别和学习。最后,使用国内不同省区在 2018—2022 年 220 kV 及以上电压等级的输电线路故障录波数据进行算例分析,对所提方法的效果进行检验,实现了对输电线路故障类型和故障原因的准确辨识。

1 输电线路故障样本特征分析

1.1 输电线路故障类型分布特征

从 2018—2022 年间在国网、南网三家省市区电网公司搜集到的 1149 起输电线路故障跳闸记录可以发现,单相接地、两相短路、三相短路等输电线路故障类型的分布存在类不平衡性,其中单相接地短路共发生 1057 起,占故障总数的 91.99%,两相短路共发生 61 起,占故障总数的 5.31%,两相接地短路共发生 20 起,占故障总数的 1.74%,三相短路共发生 11 起,仅占故障总数的 0.96%。

进一步分析可以发现:在同一类型的故障中,故障发生的相别也存在类不平衡问题。由于输电线路是水平排列或者是三角形排列的,使得 B 相导线通常是位于 A 相导线和 C 相导线之间。因此,当因雷击、树闪、山火等自然因素引起单相接地短路故障时, B 相发生故障的概率要比 A 相和 C 相较小一些。例如,在对某省电网的故障相别统计中发现, A 相和 C 相发生单相接地短路故障的占比分别约为 32.55%和 31.52%,而 B 相接地故障仅占 25.32%。

1.2 输电线路故障原因分布特征

导致输电线路发生故障的原因分布同样具有类不平衡的特点,并且少数类和多数类故障发生的数量规模相差巨大。通常,导致输电线路发生故障的原因主要有雷击、山火、风偏、外力破坏、异物、

鸟害等。以南方电网为例, 据统计其 2018—2022 年间共发生 500 kV 输电线路故障 387 起, 其中雷击、山火为主要故障原因, 分别占故障总数的 50.90% 和 22.74%, 覆冰和风偏故障分别占故障总数的 8.53% 和 8.27%, 异物等其他故障占故障总数的 9.56%, 最高发生频次的故障原因和最低发生频次的故障原因占比差可达 50.54%。

不同原因导致的输电线路接地短路故障, 其过渡电阻的阻值也存在较大的差异^[20-21]。对于雷击故障, 其过渡电阻阻值通常由电弧电阻和杆塔组成, 因此其阻值较小, 大多低于 5 Ω, 并且基本呈线性。鸟害故障是由于大量高导电率的鸟粪倾泻在绝缘子串表面而造成的沿面闪络, 由于鸟类排泄物的导电率较高, 因此其过渡电阻也呈现低阻特性。树闪故障通常是由线路对树木放电所致, 过渡电阻主要由树木构成, 因此表现为高阻特性。对于山火故障, 由于其故障的导电通道是由固体燃烧颗粒组成, 且燃烧物的阻值远大于金属物质, 因此其过渡电阻的阻值往往较大, 通常会在 80 Ω 以上。

由此可见, 输电线路的故障样本在故障类型和故障原因的分布方面存在着较大的类不平衡问题。因此, 如何构造和训练准确有效的故障分类器, 降低类不平衡问题所带来的故障辨识混淆的风险, 提高故障辨识的准确度, 是需要解决的关键问题。

2 输电线路故障辨识模型的构建

如引言部分所述, 输电线路故障辨识需要构造合适的特征输入, 以及选取合适的分类器。现有以暂态波形图像作为输入的故障辨识方法, 对于某些故障, 例如图 1 中的风偏和鸟害故障, 其波形图像的差异不够明显, 容易导致辨识的混淆。为此, 亟需构造一种新的故障辨识模型的输入, 以便于后续神经网络能够更容易地提取出故障特征。格拉姆角场作为一种能够将时间序列信号转化为图像的方法, 其既能保留信号完整的信息, 又能保持信号对时间的依赖性。通过该变换将故障录波数据转换为二维格拉姆角场图像后, 就可以充分利用神经网络在图像分类识别上的优势, 实现故障的辨识。

2.1 格拉姆角场原理

格拉姆角场变换^[22]是一种能够将时间序列信号转化编码为具有丰富特征信息的图像的方法。同时, 通过 GAF 变换方法后, 原始数据对时间序列的依赖性问题也得到了解决, 从而有利于后续使用计算机视觉技术对数据进行分类, 具体计算步骤如下。

对于一个由 n 个时刻幅值构成的时间序列 $X = \{x_1, x_2, \dots, x_n\}$, 为了能够方便将其进行直角坐

标与极坐标的转换, 通常会对 X 的时间序列利用式 (1) 进行归一化处理。

$$\tilde{x}_i = \frac{(x_i - \max(X)) + (x_i - \min(X))}{\max(X) - \min(X)} \quad (1)$$

式中: \tilde{x}_i 为通过归一化后得到的新时间序列中的数据点; x_i 为原始时间序列中的数据点。

将归一化后的 X 记为 \tilde{X} , 再通过式(2)将其转换到极坐标下。

$$\begin{cases} \phi_i = \arccos(\tilde{x}_i), -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r_i = \frac{i}{n}, i \in n \end{cases} \quad (2)$$

式中: ϕ_i 为 \tilde{x}_i 经过反余弦函数变换后的极角; r_i 为极径。

最终, GAF 即可利用极坐标变换后时间序列点的相角和(或差)来计算得到。格拉姆角场可以分为格拉姆和角场(Gramian angular summation field, GASF)与格拉姆差角场(Gramian angular difference field, GADF)两种形式, 具体计算分别如式(3)与式(4)所示。

$$\mathbf{G}_{\text{ASF}} = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \cos(\phi_1 + \phi_2) & \cdots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \cos(\phi_2 + \phi_2) & \cdots & \cos(\phi_2 + \phi_n) \\ \vdots & \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cos(\phi_n + \phi_2) & \cdots & \cos(\phi_n + \phi_n) \end{bmatrix} \quad (3)$$

$$\mathbf{G}_{\text{ADF}} = \begin{bmatrix} \sin(\phi_1 + \phi_1) & \sin(\phi_1 + \phi_2) & \cdots & \sin(\phi_1 + \phi_n) \\ \sin(\phi_2 + \phi_1) & \sin(\phi_2 + \phi_2) & \cdots & \sin(\phi_2 + \phi_n) \\ \vdots & \vdots & \ddots & \vdots \\ \sin(\phi_n + \phi_1) & \sin(\phi_n + \phi_2) & \cdots & \sin(\phi_n + \phi_n) \end{bmatrix} \quad (4)$$

式中, ϕ_n 为 \tilde{x}_i 经过反余弦函数变换后的极角。

图 1 显示了山火、异物、风偏、鸟害 4 种原因引起的输电线路故障暂态波形信号经过 GAF 变换后的故障样本示意图。格拉姆角场图像颜色的深浅代表了原始故障录波数据在波形上的幅值大小。因此, 可以通过格拉姆角场图像颜色的变化来反映故障波形的变化。由图 1 可知, GAF 变换很好地保留了时域信号的时间相关性, 即使不同故障的暂态波形相似度很高, GAF 变换也能够很好地将时域信号中的不同故障特征放大, 十分有利于对输电线路故障暂态波形特征的提取。因此, 本文采用 GAF 变换, 将输电线路故障暂态波形的一维时序信号转换为 $224 \times 224 \times 3$ 的二维彩色图像 (224×224 为输入图像的尺寸, 3 表示 RGB 3 个颜色通道), 并将其作为后续故障辨识网络的输入, 模型的每一个通道通过抓取图像的 RGB 值进行卷积操作, 实现对故障图像的特征提取。

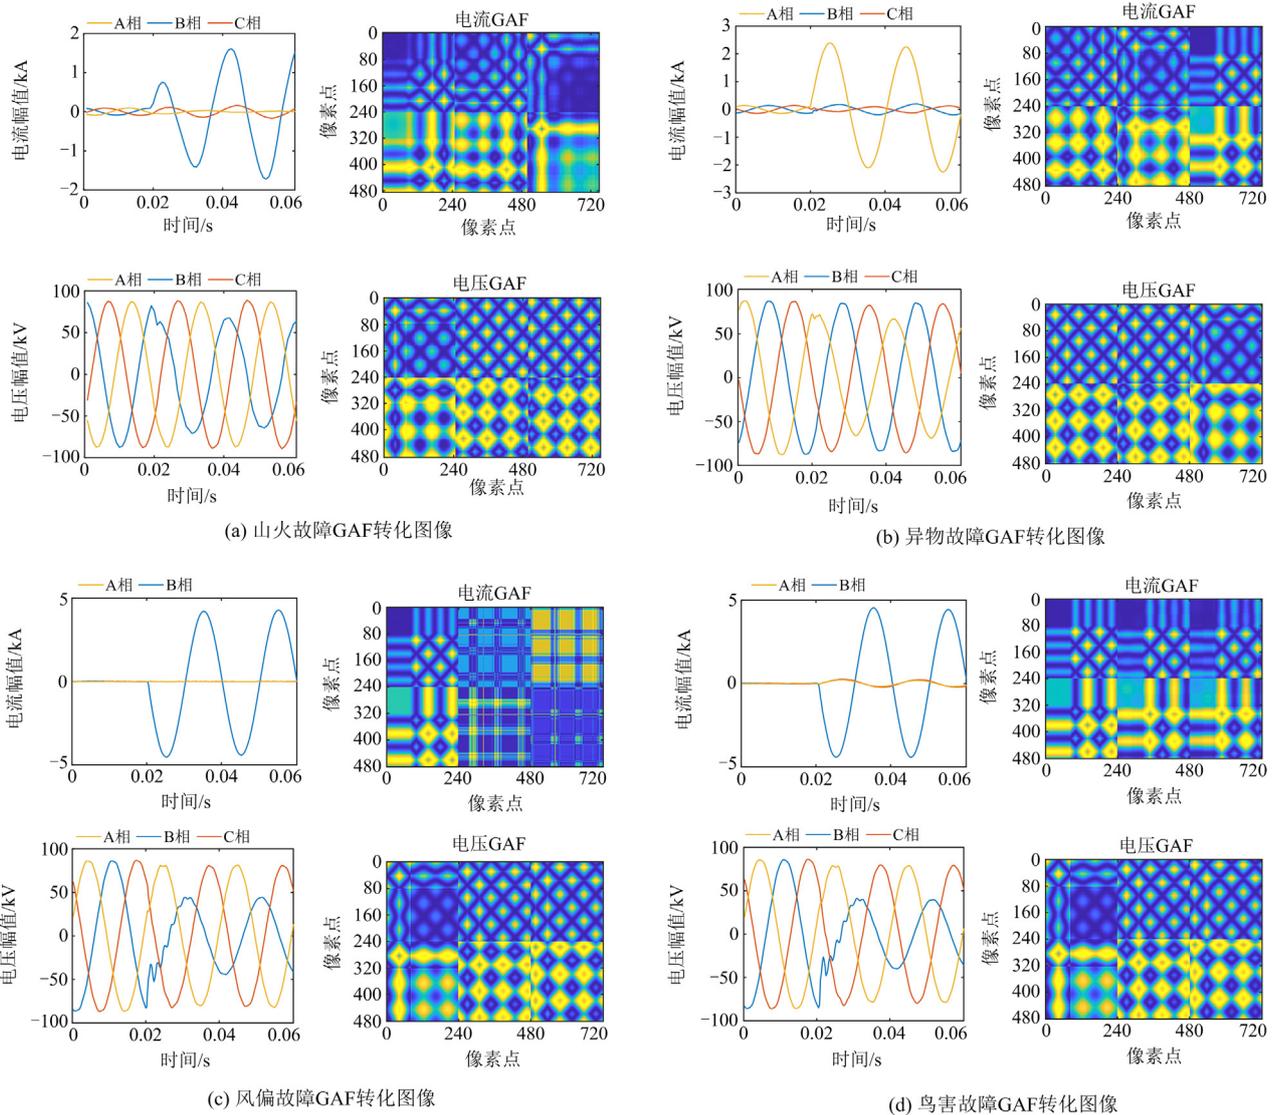


图 1 4 种故障原因的电流电压波形及其 GAF 图像

Fig. 1 Current and voltage waveforms and their GAF image of four fault causes

2.2 ResNet 网络构建

随着卷积神经网络的不断发展,深度学习在图像识别领域得到了广泛的应用,不断有准确率更高、学习能力更强的网络被提出^[23]。同时,网络模型的层数也在朝着越来越深的方向发展,但是层数的堆叠也带来了梯度爆炸以及梯度消失等问题,从而使得网络模型不易收敛,模型的训练效果不佳。针对这些问题,文献[24]通过引入残差模块单元来构建深度残差网络(residual network, ResNet),以此在增加网络模型深度的同时提高模型训练的准确率。

残差模块单元的基本结构如图 2 所示。在图 2 中,输入变量 a 进入第一层权重层后得到其映射输

出 $F(a)$; 然后通过使用 ReLU 激活函数进入第二层权重层。同时,再对输入变量引入 Shortcut(跳远连接),最终得到映射输出 $F(a) + a$ 。当模型的输出结果优于不含残差模块单元的输出时便保留残差模块,当模型的输出结果逊于不含残差模块单元的输出时便去掉残差模块,仅保留跳远连接(输出即为原网络的输入 a)。这种结构的优势在于能使浅层特征直接映射到深层,从而加深了两层之间的沟通。

ResNet-18 作为 ResNet 网络中的一种,具有网络层数适中,模型训练速度快,不易出现过拟合等优点,在图像识别领域得到了较为广泛的应用^[25]。该网络由若干个残差模块单元堆叠而成,网络的输

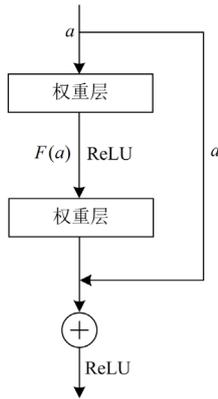


图 2 残差模块示意图

Fig. 2 Residual module schematic diagram

入为一幅 224×224 的三通道 RGB 图像, 图片在经过若干个卷积层和池化层后会得到一个尺寸大小为 $H \times W \times 7 \times 7$ (H 为 batchsize 的尺寸, W 为输出的类别数) 的特征图。然后再通过一个 7×7 的自适应平均池化层将其维度降为 $H \times W \times 1 \times 1$, 最后把提取得到的图片特征通过 Softmax 分类器计算得到预测类别。本文在 ResNet-18 网络的基础之上, 将其最后一层依次替换为 Flatten 层、Softmax 层、全连接层, 前面的网络结构不变, 建立输电线路故障辨识模型, 实现基于格拉姆角场与迁移学习-ResNet 的输电线路故障辨识。本文所提故障辨识网络的结构如图 3 所示, 其结构参数如表 1 所示。

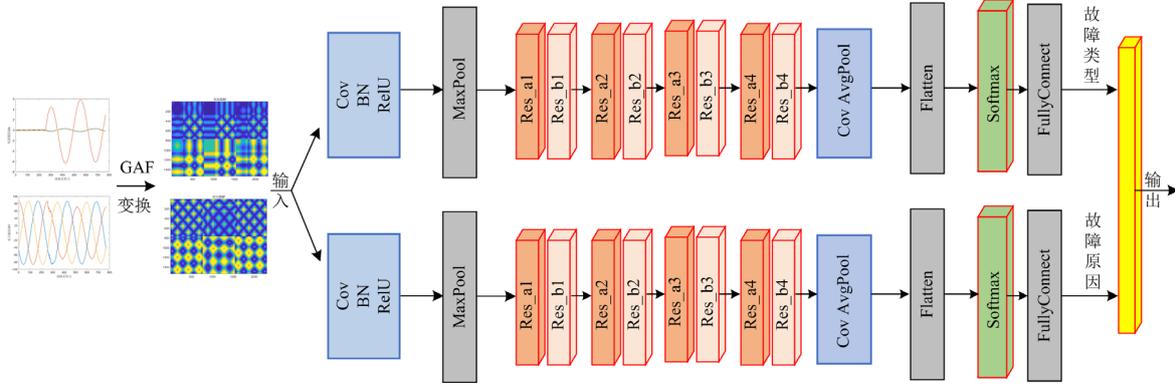


图 3 故障辨识网络结构

Fig. 3 Fault identification network structure

表 1 故障辨识网络参数设置

Table 1 Parameter settings of fault identification network

层类型	故障类型输出尺寸	故障原因输出尺寸
Convolution	$64 \times 112 \times 112$	$64 \times 112 \times 112$
MaxPool	$64 \times 56 \times 56$	$64 \times 56 \times 56$
Res_a1	$64 \times 56 \times 56$	$64 \times 56 \times 56$
Res_b1	$64 \times 56 \times 56$	$64 \times 56 \times 56$
Res_a2	$128 \times 28 \times 28$	$128 \times 28 \times 28$
Res_b2	$128 \times 28 \times 28$	$128 \times 28 \times 28$
Res_a3	$256 \times 14 \times 14$	$256 \times 14 \times 14$
Res_b3	$256 \times 14 \times 14$	$256 \times 14 \times 14$
Res_a4	$512 \times 7 \times 7$	$512 \times 7 \times 7$
Res_b4	$512 \times 7 \times 7$	$512 \times 7 \times 7$
ConvAvgPool	$512 \times 1 \times 1$	$512 \times 1 \times 1$
Flatten	$512 \times 1 \times 1$	$512 \times 1 \times 1$
Softmax	512×10	512×9
FullyConnect	512×10	512×9

2.3 基于迁移学习的模型适应性提升

深度学习模型的构建与训练往往需要大量具有样本标签的数据, 然而在实际工程中经常会出现数

据量不足或样本标签缺失的情况, 导致故障辨识模型的性能也将有所下降。此外, 由于模型的训练需要海量的数据, 模型在训练过程中也存在资源耗费大, 历时时间长等问题。

迁移学习作为人工智能领域最新发展出来的又一重要分支, 它可以在已经训练好的模型基础之上, 将原有网络迁移到特定的任务中进行模型的训练与微调, 从而达到理想的训练效果。该方法具有运算速度快、模型收敛好、初始性能优异以及节省计算资源的特点, 能够有效地解决传统机器学习领域中存在数据标签丢失、模型计算能力弱、泛化性不佳等问题^[26-27]。本文将使用南网地区故障数据训练好的网络模型迁移至国网新疆和重庆两地, 并利用当地的故障录波数据对网络模型再次进行参数微调, 以此提高网络在不同地区的泛化能力。

3 算例分析

3.1 数据处理与数据划分

本文选取的输入数据为从各变电站内采集得到

的故障发生时单端三相故障电压、电流数据。在截取故障样本时，为了能够充分包含故障发生前后的波形特征信息，本文设置的采样区间为故障发生前一周波至故障发生后两周波。然后，通过 GAF 方法将截取得到的三相电压、电流数据转换为二维彩色图像，作为一个故障样本。算例中故障类型涉及到单相接地故障(AG、BG、CG)、两相短路故障(AB、AC、BC)、两相接地短路故障(ABG、ACG、BCG)和三相短路故障(ABC)。故障原因按照国网和南网对于输电线路故障跳闸巡线记录的原因进行分类，包括施工外破、山火、异物、雷击、覆冰、风偏、鸟害等。

图 4 为 AG、BG 和 CG 的故障电压、电流信号的 GAF 变换图。最后，将变换得到的故障电压、电流信号的 GAF 图像送入搭建完成的网络作为输入。在进行数据划分时，本文将输入数据按照 7:3 的比例划分为训练集和测试集，从而实现网络的训练与测试。

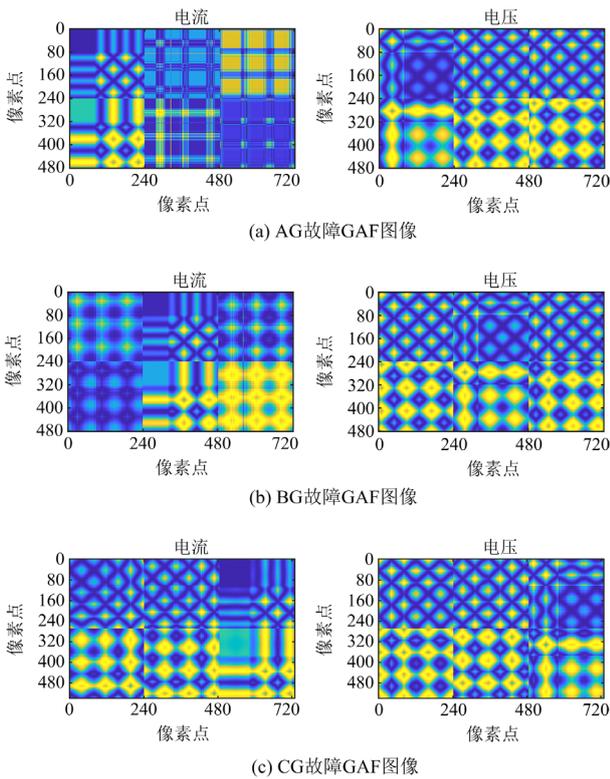


图 4 不同故障类型的电压、电流 GAF 图

Fig. 4 Voltage and current GAF images of different fault types

此外，为了能够更加客观地评价不同训练参数对模型训练的影响，使用总精度 A 来衡量模型的辨识准确率，其计算公式如式(5)所示。

$$A = \frac{N_{PT}}{N_{PF} + N_{PT}} \tag{5}$$

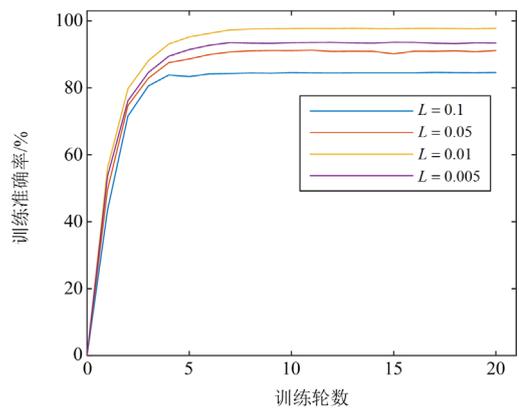
式中： N_{PT} 为预测分类正确的样本数量； N_{PF} 为预测分类错误的样本数量。

3.2 模型的训练与测试效果分析

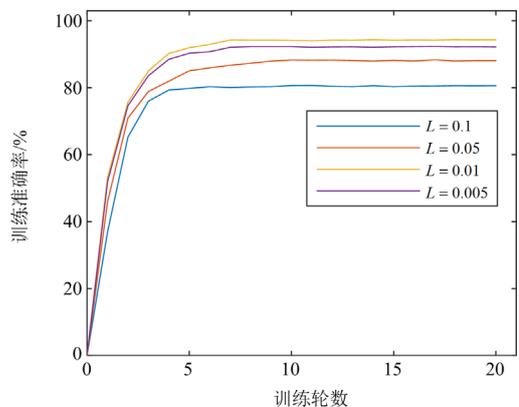
1) 模型的训练与测试

为了验证算法模型的有效性，本文在进行网络模型训练时，分类模型的优化器选择随机梯度下降算法(stochastic gradient descent, SGD)，损失函数采用与 Softmax 分类器相结合的交叉熵损失函数。同时，为了探究不同训练参数对模型训练效果的影响，本文利用控制变量法，在相同的参数设置下，分别调整学习率 $L = 0.1$ 、 0.05 、 0.01 、 0.005 ，模型批训练量 $B = 16$ 、 32 、 64 、 128 以及训练轮数 $E = 5$ 、 10 、 15 、 20 、 25 、 30 ，进行模型的训练与测试。最终实验的结果如图 5—图 7 所示。

分析图 5—图 7 所得结论如下：当学习率 $L = 0.01$ 时训练效果比学习率 $L = 0.005$ 时更好，因为过小的学习率会使得网络的损失函数无法收敛于



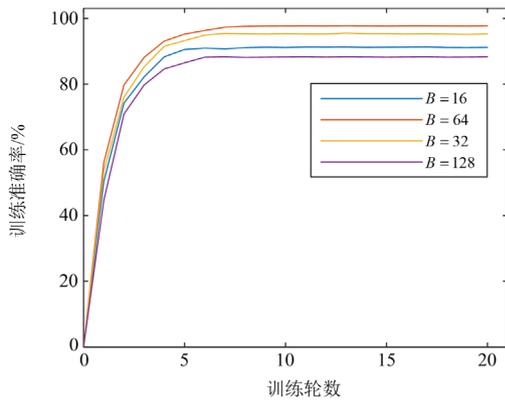
(a) 故障类型辨识训练过程



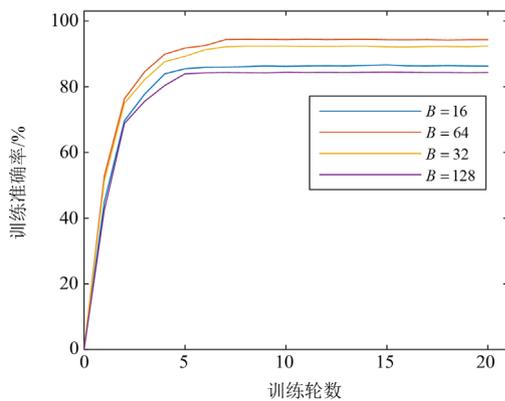
(b) 故障原因辨识训练过程

图 5 不同学习率下的故障辨识准确率

Fig. 5 Fault identification accuracy under different learning rates



(a) 故障类型辨识训练过程



(b) 故障原因辨识训练过程

图 6 不同批训练量下的故障辨识准确率

Fig. 6 Fault identification accuracy under different batch training quantity

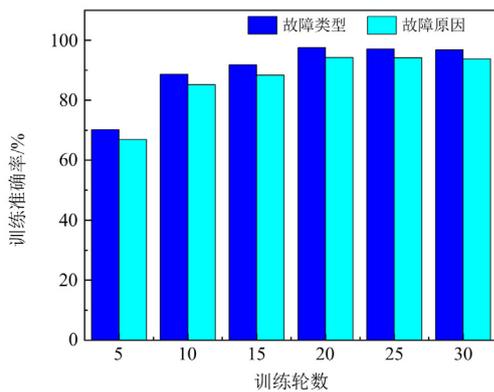


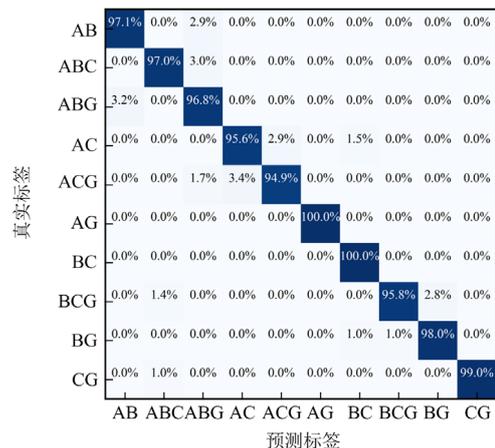
图 7 不同训练轮数下的故障辨识准确率

Fig. 7 Fault identification accuracy under different training epochs

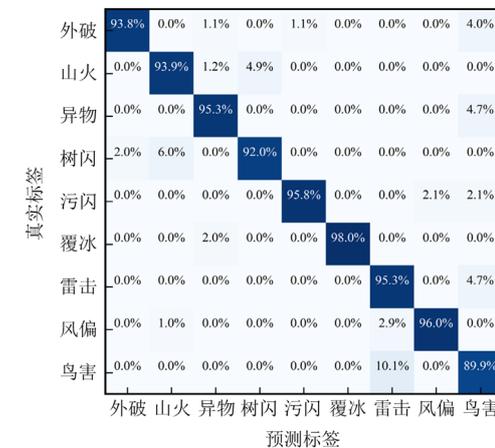
全局的最小值。但如果学习率取的过大时则会导致网络的损失函数无法收敛, 进而降低网络的辨识准确率。当批训练量取 64 时 ResNet-18 网络的迁移学习训练效果最佳, 当 B 达到或超过 128 时, 模型的辨识效果相比于 $B = 16$ 时会略微下降, 这是因为过

大的批训练量不利于模型的训练。当训练轮数过少时, 模型的故障辨识准确率不高。随着训练轮数的增加, 当 $E = 20$ 时模型对故障辨识的准确率达到最佳。当 E 超过 20 时, 其准确率出现了略微下降, 这是因为过多的训练轮数会导致模型在训练时发生过拟合。

综上所述, 最终本文选用的模型参数为: 学习率 $L = 0.01$, 模型批训练量 $B = 64$, 本地训练轮数 $E = 20$ 。此时模型对故障类型辨识准确率为 97.51%, 对故障原因辨识准确率为 94.23%, 网络故障辨识的混淆矩阵如图 8 所示。由图 8 可知, 本文方法在进行故障类型辨识时, 对两相短路故障和两相接地短路故障存在误判, 其原因是部分两相短路故障的过渡电阻阻值较高或者两相接地短路故障的过渡电阻阻值较低, 从而产生了两类故障类型辨识的混淆。在进行故障原因的辨识时, 本文方法对山火、树闪这类高阻性故障的辨识以及雷击、鸟害、外力破坏、



(a) 故障类型辨识混淆矩阵



(b) 故障原因辨识混淆矩阵

图 8 故障辨识混淆矩阵

Fig. 8 Fault identification confusion matrix

污闪这类低阻性故障的辨识出现了少许错误，其原因可能是发生混淆的几类故障的过渡电阻阻值相近，因此仅依靠真实的故障录波数据难以准确辨识，若能够将录波数据与气象参数相结合，将可有效解决该问题。

2) 模型迁移效果分析

通常情况下，不同地区输电线路故障样本的分布和特征会存在一定的差异，若直接使用其他地区训练好的模型进行故障辨识，其辨识效果往往会不理想。为此，本文将已训练完成的故障辨识分类器分别迁移至新疆和重庆两地，使用当地的故障录波数据对网络进行模型参数的训练和微调，得到迁移学习后的故障辨识模型。最终 3 个地区的故障辨识效果如表 2 所示，从表 2 中可以看出，经过迁移学习参数微调和训练过后的网络对故障类型和故障原因也能够实现有效的辨识，具有较好的泛化能力。

表 2 模型迁移至不同地区的故障辨识准确率

Table 2 Fault identification accuracy when the models are transferred to different regions

地区	准确率/%	
	故障类型	故障原因
新疆	97.35	93.66
重庆	97.26	92.13
南网	97.51	94.23

3.3 不同方法的对比实验

此外，为了更进一步验证本文方法的优越性，本文还从不同的网络模型以及不同的特征输入两个角度来进行方法的论证。

1) 不同网络模型的辨识结果对比

在进行网络模型的论证时，本文与另外两种网络(AlexNet 网络和普通 CNN 网络)进行了对比实验。对上述模型均采用与本文方法相同的数据集与训练参数以减少除模型本身以外的因素对实验的影响。最终，各模型的故障辨识结果如表 3 所示。

表 3 不同网络模型下的故障辨识准确率对比

Table 3 Fault identification accuracy comparison under different network models

网络模型	准确率/%	
	故障类型	故障原因
本文模型	97.51	94.23
AlexNet	93.89	85.13
CNN	84.17	73.67

根据结果可知，AlexNet 网络和普通 CNN 网络对故障类型的辨识分别取得了 93.89%和 84.17%的准确率，对故障原因的辨识分别取得了 85.13%和

73.67%的准确率，其根本原因是本文方法中残差网络能够更好地提取故障的特征，故更加适用于处理通过 GAF 变换后的三相故障电压、电流图像。

2) 采用不同特征输入的辨识结果对比

在进行网络输入方式的论证时，本文还与采用故障暂态波形、小波能量谱两种特征输入进行了对比实验。对比实验均采用本文方法中同样的网络模型和网络参数以及相同的训练集与测试集。最终，不同特征输入的故障辨识结果如表 4 所示。

表 4 不同特征输入的故障辨识准确率对比

Table 4 Fault identification accuracy comparison under different feature inputs

特征输入	准确率/%	
	故障类型	故障原因
本文方法	97.51	94.23
小波能量谱 ^[28]	91.62	85.32
故障暂态波形 ^[18]	94.88	89.77

根据结果可知，当网络采用小波能量谱和故障暂态波形图像作为输入时，其故障类型的辨识准确率分别为 91.62%和 94.88%，对故障原因的辨识准确率分别为 85.32%和 89.77%。两种特征输入的准确率均低于使用格拉姆角场图像作为特征输入的准确率，其原因是 GAF 方法更加适用于处理具有时间相关性的序列，可以更加完整地将故障信号中丰富的特征信息体现出来。

4 结论

本文针对如何利用实际故障录波数据，提取和放大故障特征差异，开展故障辨识的问题，提出了基于格拉姆角场与迁移学习-ResNet 的输电线路故障辨识方法，经过研究，得出以下结论。

1) GAF 图像在输电线路故障电压、电流数据的图像变换中表现出良好的适用性，能够放大输电线路故障录波数据的故障特征，可以作为故障辨识的特征输入。

2) 搭建的 ResNet 故障辨识分类器，对故障类型的辨识准确率达到 97.51%，对故障原因的辨识准确率达到 94.23%，相比 AlexNet、CNN 网络，辨识准确率更高。

3) 所提方法具有较好的适应能力，网络模型迁移至其他地区，经过参数微调后都能具有较好的故障分类性能，其对故障类型的辨识准确率达到 97%以上，对故障原因的辨识准确率也达到 92%以上。

本文所提的方法虽然能够较为准确地辨识输电线路的故障类型和故障原因，但是对某些小样本

类的故障仍然不能实现准确的辨识,对波形特征量的提取还不够充分,因此导致了故障类型和原因的辨识出现了偏差。在今后的研究中,将深入探究输电线路发生故障时的其他特征量,例如进一步考虑零序电压、零序电流在故障波形中的差异特征,以此来提高故障辨识的准确度。

参考文献

- [1] 王春明, 李杰, 徐正清, 等. 基于暂态信息融合的输电线路单端故障定位方法[J]. 电力科学与技术学报, 2022, 37(2): 62-71.
WANG Chunming, LI Jie, XU Zhengqing, et al. Research on single-ended fault location of transmission line based on transient information fusion[J]. Journal of Electric Power Science And Technology, 2022, 37(2): 62-71.
- [2] QUISPE J C, MORALES J, ORDUNA E, et al. Time-frequency multiresolution of fault-generated transient signals in transmission lines using a morphological filter[J]. Protection and Control of Modern Power Systems, 2023, 8(2): 348-362.
- [3] 饶超平, 肖博文, 严星, 等. 基于 Seq2Seq 技术的输电线路故障类型识别方法[J]. 智慧电力, 2020, 48(5): 99-105, 110.
RAO Chaoping, XIAO Bowen, YAN Xing, et al. Fault type recognition method of transmission line based on Seq2Seq technology[J]. Smart Power, 2020, 48(5): 99-105, 110.
- [4] 毛鹏, 孙雅明, 张兆宁. 具有冗余神经元神经网络模型系统的输电线路故障测距的研究[J]. 中国电机工程学报, 2020, 20(7): 28-33.
MAO Peng, SUN Yaming, ZHANG Zhaoning. Study of fault location for high voltage over-head transmission line using neural networks model system with redundant neuron[J]. Proceedings of the CSEE, 2020, 20(7): 28-33.
- [5] 王桥梅, 吴浩, 胡潇涛, 等. 基于 VMD 多尺度模糊熵的 HVDC 输电线路故障识别方法[J]. 电力系统及其自动化学报, 2021, 33(5): 134-144.
WANG Qiaomei, WU Hao, HU Xiaotao, et al. Fault recognition method for HVDC transmission line based on VMD multi-scale fuzzy entropy[J]. Proceedings of the CSU-EPSA, 2021, 33(5): 134-144.
- [6] YADAV A, DASH Y, ASHOK V. ANN based directional relaying scheme for protection of Korba-Bhilai transmission line of Chhattisgarh state[J]. Protection and Control of Modern Power Systems, 2016, 1(2): 128-144.
- [7] 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.
WANG Hao, YANG Dongsheng, ZHOU Bowen, et al. Fault diagnosis of multi-terminal HVDC transmission line based on parallel convolutional neural network[J]. Automation of Electric Power Systems, 2020, 44(12): 84-92.
- [8] ZAKI M, EI S R, AMER G, et al. Sensitive/stable complementary fault identification scheme for overhead transmission lines[J]. IET Generation, Transmission, and Distribution, 2019, 13(15): 3252-3263.
- [9] FERRIRA V, ZANGHI R, FOTES M, et al. A survey on intelligent system application to fault diagnosis in electric power system transmission lines[J]. Electrical Power System Resistance, 2016(136): 135-153.
- [10] CHEN K, HUANG C, HE J. Fault detection, classification and location for transmission lines and distribution systems: a review on the methods[J]. High Voltage, 2016, 1(1): 25-33.
- [11] 黄建明, 李晓明, 瞿合祚, 等. 考虑小波奇异信息与不平衡数据集的输电线路故障识别方法[J]. 中国电机工程学报, 2017, 37(11): 45-53.
HUANG Jianming, LI Xiaoming, QU Hezuo, et al. Method for fault type identification of transmission line considering wavelet singular information and unbalanced dataset[J]. Proceedings of the CSEE, 2017, 37(11): 45-53.
- [12] FARSHAD M, SADEH J. Transmission line fault location using hybrid wavelet-Prony method and relief algorithm[J]. International Journal of Electrical Power and Energy Systems, 2014(61): 127-136.
- [13] BISWAS S, NAYAK P. A fault detection and classification scheme for unified power flow controller compensated transmission lines connecting wind farms[J]. IEEE System, 2021, 15(1): 297-306.
- [14] FAHIM S R, SARKER S K, MUYEEN S M, et al. A deep learning based intelligent approach in detection and classification of transmission line faults[J]. International Journal of Electrical Power and Energy Systems, 2021, 133: 1-11.
- [15] 刘志坚, 何蔚, 刘航, 等. 基于格拉姆角场变换和深度压缩模型的变压器故障识别方法[J]. 电网技术, 2023, 47(4): 1478-1490.
LIU Zhijian, HE Wei, LIU Hang, et al. Fault identification method for power transformer based on Gramian angular field transformation and deep compression model[J]. Power System Technology, 2023, 47(4): 1478-1490.
- [16] 薛健侗, 马宏忠, 杨洪苏, 等. 基于格拉姆角场与迁移学习-AlexNet 的变压器绕组松动故障诊断方法[J]. 电力系统保护与控制, 2023, 51(24): 154-163.
XUE Jiantong, MA Hongzhong, YANG Hongsu, et al. A fault diagnosis method for transformer winding looseness based on Gramian angular field and transfer learning-

AlexNet[J]. Power System Protection and Control, 2023, 51(24): 154-163.

[17] 欧阳福莲, 王俊, 周航霞. 基于改进迁移学习和多尺度 CNN-BiLSTM-Attention 的短期电力负荷预测方法[J]. 电力系统保护与控制, 2023, 51(2): 132-140.
OUYANG Fulian, WANG Jun, ZHOU Hangxia. Short-term power load forecasting method based on improved hierarchical transfer learning and multi-scale CNN-BiLSTM-Attention[J]. Power System Protection and Control, 2023, 51(2): 132-140.

[18] 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.
WANG Jian, WU Hao, ZHANG Bo, et al. Fault Identification method for transmission line based on transfer learning-AlexNet with imbalanced samples[J]. Automation of Electric Power Systems, 2022, 46(22): 182-191.

[19] 杨毅, 范栋琛, 殷浩然, 等. 基于深度-迁移学习的输电线路故障选相模型及其可迁移性研究[J]. 电力自动化设备, 2020, 40(10): 165-172.
YANG Yi, FAN Dongchen, YIN Haoran, et al. Transmission line fault phase selection model based on deep-transfer learning and its transferability[J]. Electric Power Automation Equipment, 2020, 40(10): 165-172.

[20] 黄骥. 输电线路故障类型辨识研究[D]. 广州: 华南理工大学, 2014.
HUANG Jian. Research on fault type identification of transmission line[D]. Guangzhou: South China University of Technology, 2014.

[21] 董桓毓. 基于故障录波数据特征的输电线路故障原因辨识[D]. 北京: 华北电力大学, 2022.
DONG Huanyu. Fault cause identification of transmission lines based on fault recording data characteristics[D]. Beijing: North China Electric Power University, 2022.

[22] WANG Z, OATES T. Imaging time-series to improve classification and imputation[C]// 24th International Joint Conference on Artificial Intelligence, 2015: 3939-3945.

[23] 黄冬梅, 王玥琦, 胡安铎, 等. 融合多维度特征的绝缘子状态边缘识别方法[J]. 中国电力, 2022, 55(1): 133-141.
HUANG Dongmei, WANG Yueqi, HU Anduo, et al. An edge recognition method for insulator state based on multi-dimension feature fusion[J]. Electric Power, 2022, 55(1): 133-141.

[24] 李海英, 孙越, 张笑, 等. 模态时频图与 ResNet50 融合的真​​空接触器故障诊断方法[J]. 高电压技术, 2023, 49(5): 1831-1840.
LI Haiying, SUN Yue, ZHANG Xiao, et al. Fault diagnosis of vacuum contactor based on modal time-frequency diagram and ResNet50[J]. High Voltage Engineering, 2023, 49(5): 1831-1840.

[25] 兰名扬, 刘宇龙, 金涛, 等. 基于可视化轨迹圆和 ResNet18 的复合电能质量扰动类型识别[J]. 中国电机工程学报, 2022, 42(17): 6274-6285.
LAN Mingyang, LIU Yulong, JIN Tao, et al. An improved recognition method based on visual trajectory circle and ResnetN18 for complex power quality disturbances[J]. Proceedings of the CSEE, 2022, 42(17): 6274-6285.

[26] 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.
YANG Gengjie, WANG Kang, GAO Wei. High impedance fault detection in a distribution network based on phase space reconstruction and transfer learning[J]. Power System Protection and Control, 2022, 50(13): 151-162.

[27] 韦汶妍, 刘晓立, 杨传凯, 等. 一种基于深度学习网络的输电杆塔智能检测算法[J]. 广东电力, 2020, 33(9): 166-173.
WEI Wenyan, LIU Xiaoli, YANG Chuankai, et al. An intelligent detection algorithm for transmission tower based on deep learning network[J]. Guangdong Electric Power, 2020, 33(9): 166-173.

[28] 吴昊, 肖先勇, 沈睿佼. 小波能量谱和神经网络法识别雷击与短路故障[J]. 高电压技术, 2007, 33(10): 64-68.
WU Hao, XIAO Xianyong, SHEN Ruijiao. Lightning strike and fault identification by the wavelet energy spectrum and neural network method[J]. High Voltage Engineering, 2007, 33(10): 64-68.

收稿日期: 2023-11-05; 修回日期: 2024-01-29

作者简介:

赵 启(1984—), 男, 硕士, 高级工程师, 研究方向为电力系统继电保护; E-mail: 56365799@qq.com

王 建(1986—), 男, 通信作者, 博士(后), 副教授, 博士生导师, 研究方向为电力系统保护与控制、电网风险评估与气象灾害预警; E-mail: wangrelay@foxmail.com

林丰恺(2000—), 男, 硕士研究生, 研究方向为电力系统保护与控制。E-mail: franklittlep@foxmail.com

(编辑 张颖)