

DOI: 10.19783/j.cnki.pspc.241729

基于多模态残差网络融合波形与天气信息的输电线路故障原因辨识方法

林丰恺¹, 王建¹, 赵启², 薛汉¹, 彭寅章², 南东亮²

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

摘要: 针对现有基于暂态波形图像识别的输电线路故障原因辨识, 因使用的输入特征相对单一而无法进一步细分故障原因的问题, 基于多模态残差网络, 提出了一种融合暂态波形与天气特征的输电线路故障原因辨识方法。首先, 统计分析不同原因的输电线路故障在暂态波形和天气条件方面的特征差异。其次, 以暂态波形图像和故障发生时天气情况的独热编码作为改进多模态残差网络分类器的输入。然后, 利用通道注意力机制对网络提取得到的故障暂态波形图像特征和天气特征进行特征融合, 实现多模态输电线路故障辨识模型的训练与测试。最后, 完全采用真实故障录波数据开展了算例验证。结果表明: 所提方法对故障原因的辨识准确率达到94.87%。相比于传统的故障辨识方法, 网络所需的故障特征量更少、对易混淆故障的辨识效果更好、辨识准确度更高。

关键词: 输电线路; 故障辨识; 多模态; 残差网络; 天气特征

Transmission line fault cause identification method based on multimodal residual network integrating waveform and weather information

LIN Fengkai¹, WANG Jian¹, ZHAO Qi², XUE Han¹, PENG Yinzhong², NAN Dongliang²

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

Abstract: To address the limitation of existing transient waveform image-based transmission line fault cause identification methods, namely, that the use of single-type input features prevents fine-grained fault cause classification, this paper proposes a novel fault cause identification method based on multimodal residual network (ResNet). The method integrates transient waveform features with weather characteristics. First, the characteristics of different causes of transmission line faults are analyzed statistically in terms of both transient waveform and weather conditions. Second, transient waveform images and one-hot codes for weather conditions at the time of the fault are used as inputs to an improved multimodal ResNet classifier. A channel attention mechanism is used to fuse the extracted fault transient waveform image features and weather features, enabling training and testing of the fault identification model. Finally, real fault recording data are used to perform case study verification. The results show that the proposed method achieves a fault cause identification accuracy of 94.87%. Compared with traditional fault identification methods, it requires fewer fault features, offers superior discrimination for easily confusable fault types, and provides significantly higher identification accuracy.

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

Key words: transmission line; fault identification; multimodal; residual network (ResNet); weather feature

0 引言

输电线路分布范围广、跨区域面积大, 在运行

过程中易受恶劣自然环境影响而发生各种类型的故障^[1-3]。快速准确地辨识出故障原因, 对指导安全自动装置采取自适应重合闸和指导调度人员的强送决策, 以及线路运维人员查找和处置故障, 恢复电力供应, 保障电网安全运行, 具有重要意义^[4-7]。

现有的输电线路故障辨识研究, 通常会利用傅

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)

里叶变换^[8]、希尔伯特黄变换^[9]、经验模态分解^[10]等方法对采集到的故障电压、电流数据进行信号分解,以提取故障波形的特征来辨识故障。传统的信号分析方法在辨识单相接地、相间短路等故障类型时有较好效果^[11],但是用于辨识引起故障的原因时,易受输电线路运行环境和运行方式的影响^[12]。随着机器学习的发展,将信号分析与机器学习相结合的故障辨识方法被不断提出和试用,例如支持向量机(support vector machines, SVM)^[13-14]、人工神经网络(artificial neural network, ANN)^[15]、随机森林^[16]、决策树^[17]和概率神经网络(probabilistic-based neural network, PNN)^[18]等。但是这些方法都是浅层的学习方法,对数据特征提取能力较弱,在实际应用中无法取得较好的辨识效果。

近年来,随着深度学习的发展,众多深度学习算法被应用到了输电线路故障辨识领域。文献[19]提出了一种卷积神经网络(convolutional neural network, CNN)和长短期记忆(long short term memory, LSTM)网络相结合的模型,以故障信号傅里叶变换后的特征作为模型的输入,提升了故障辨识的效果。文献[20]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,研究故障类型与故障原因辨识,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。针对输电线路故障样本集中存在的类不平衡问题,文献[21-22]分别构建了长短期记忆多头卷积神经网络(MCNN-LSTM)和迁移学习-AlexNet 网络,以暂态波形图像为输入,提升了输电线路故障类型和故障原因的辨识正确率。虽然这些基于深度学习的故障辨识方法都能够较为准确地辨识出故障原因,但是由于模型输入相对单一,仅能够对山火、雷击、树闪等故障机理、故障特征差别较大的原因实现准确辨识,对于覆冰舞动和风偏、冰闪和污闪这些故障机理或故障特征较为类似的易混淆故障辨识效果却不佳。

在基于多源数据特征融合的输电线路故障原因辨识方面,文献[23]将故障天气、时间、季节、过渡电阻性质、零序电流谐波与直流含量以及重合闸情况组成的故障综合特征向量作为BP网络的输入,实现了对雷击、污闪、山火、鸟闪、异物接线和吊车碰线 6 类单相接地故障原因的辨识。文献[24]针对输电线路在台风、冰冻等极端条件下发生故障时难以辨识的问题,将标准遥信及广域测量系统数据与线路的保护动作情况相结合,作为 AlexNet 模型的特征输入。文献[25]将故障发生时的零序量时频特征、小波能量特征、重合闸特征、季节特征、地

理环境特征等与故障原因最为相关的 11 维特征量作为 SVM 的输入,实现了对雷击、异物、风偏、山火、鸟害 5 类故障原因的辨识。这类方法对故障信息获取的要求较高,在实际的工程应用中通常无法获得如此完善的数据开展故障原因的辨识。同时这些方法所用的网络模型较为简单,无法有效提取故障特征,影响模型的效果。

此外,现有研究的故障样本集大都通过仿真得到,鲜有完全使用真实的故障录波数据来进行模型的训练与测试。文献[26-27]利用电弧特性的经验公式,在 PSCAD/EMTDC 中搭建了一、二次电弧动态模型,分别实现了对晋东南-南阳段 1000 kV 输电线路和真双极柔性直流系统的单相接地故障仿真。文献[28]搭建了故障相静电耦合回路,实现了对带有并联电抗器的 750 kV 超高压交流输电系统的单相接地故障仿真。在配电网故障建模分析方面,文献[29]基于改进的控制论电弧模型,在 PSCAD 中搭建了典型 10 kV 配电网故障仿真模型。虽然这些故障电弧仿真模型能够较好地复现出故障相电压和故障相电流的波形特征,然而现实情况下的高压交流输电系统复杂多样,故障电阻统计分布差异大,仅使用上述方法仿真得到的故障波形并不能全面代表真实的故障波形。同时,上述方法均仅对单相接地故障的波形进行了复现,对于相间短路、两相接地短路等故障,还未见仿真与真实波形的对比研究报道。因此,基于仿真波形训练的故障辨识模型,应用到实际线路中,会存在效果降低的问题。

综上,如何选取合适的特征输入以及构造和训练故障分类器来提高模型对不同故障原因的辨识准确度,是需要解决的关键问题之一。为此,本文以完全真实的故障录波数据为样本集,基于多模态残差网络,提出了一种融合暂态波形与天气特征的输电线路故障原因辨识方法。首先,分析了不同原因所导致的输电线路故障的机理和故障在暂态波形、天气条件方面的特征差异。其次,搭建了改进多模态残差网络的输电线路故障原因辨识模型,以暂态波形图像和故障发生时天气情况的独热编码作为分类器的输入,分别提取故障的电气量特征与天气特征。然后,利用通道注意力机制对网络提取的故障暂态波形的图像特征和天气特征进行特征融合,实现多模态输电线路故障辨识模型的训练与测试。最后,使用从电网公司中搜集得到的 2018—2024 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原因的准确辨识。

1 输电线路故障波形特征分析

输电线路常常受到恶劣天气^[30]、动植物活动或外力破坏等因素的影响而发生故障^[31]。不同因素所引起的输电线路故障,其接地通道过渡电阻的性质往往具有较大的差异性,所以故障电压、电流波形以及频谱特征通常会有不同。本文从电网公司的保信系统中搜集统计了华东、华中、西南、西北4个地区的4055条输电线路故障样本,其中包含完整波形记录、天气条件和巡线结果的共有2857条。这些故障样本所记载的原因标签包括雷击、山火、树闪、

外力破坏、鸟害、污闪、风偏、覆冰、异物等。由于有些原因的故障机理和故障暂态波形特征相似,因此,对它们进行优化组合,最终分类得到雷击故障、山火故障、污秽故障、风偏故障、覆冰故障和异物故障6种原因类型的故障。本文从归类整理的样本库中选择了上述6种典型原因故障的案例,并对其故障波形特征做出了分析,不同故障原因的典型录波波形如图1所示。图中纵坐标表示输电线路二次侧电压、电流,横坐标表示故障时间。具体的分类标签优化过程,将在后文进行详细阐述。

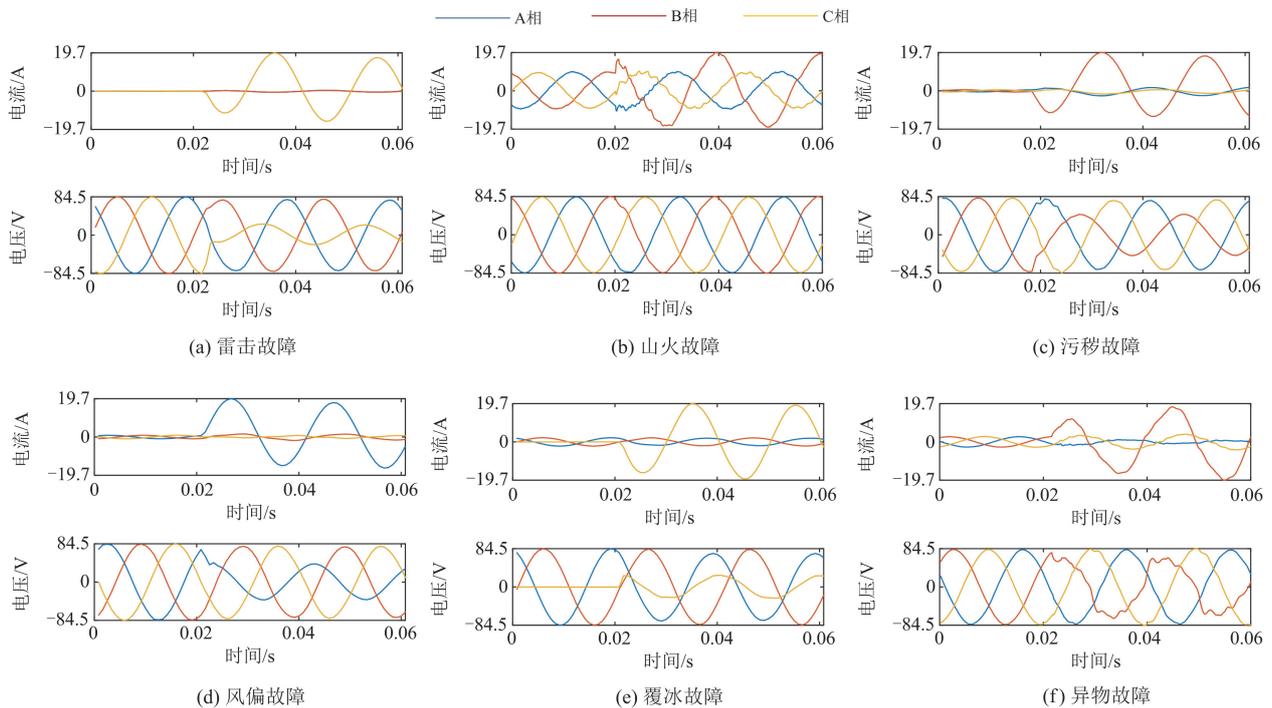


图1 典型原因导致的输电线路故障波形

Fig. 1 Fault waveforms of transmission lines caused by typical reasons

1) 雷击故障。雷击故障多发生于雷雨天气。其故障机理是由于雷电流幅值过大而引起过电压,导致绝缘子串的击穿^[32]。图1(a)显示了雷击故障的典型波形,该故障的过渡电阻阻值较小并呈线性,故障发生后故障相电流大幅增加,故障相电压降低,故障波形呈正弦波,故障电流几乎不含高频分量,但含有一定量的直流分量。

2) 山火故障。山火故障多发生于晴天。它是由于输电线路下方的火焰燃烧产生导电烟雾颗粒,触发电形形成电弧并且击穿导线与大地之间的空气间隙而产生的故障^[21,33]。图1(b)显示了山火故障的典型波形,该故障的过渡电阻阻值较大并呈非线性,故障发生后故障相电压几乎没有变化,故障相电流

幅值增加不大,但含有大量的高频谐波。

3) 污秽故障。原始故障记录中的鸟害^[34]、污闪^[35]和绝缘子覆冰闪络^[36],都是因为潮湿或雾霾天气下污染物在工频电压下发生闪络引起的,因此本文将它们统称为污秽故障。图1(c)显示了污秽故障的典型波形,该故障的过渡电阻阻值较小且呈线性,故障发生后故障相电压明显减小,故障相电流明显增大,故障波形呈正弦波,几乎不含有高次谐波。但由于故障前绝缘子上存在泄漏电流,因此故障相电流中含有较多的直流分量。

4) 风偏故障。风偏故障的直接原因是强风作用下输电线路的导线发生偏移或者摇摆,导线与导线或导线与杆塔间的安全距离不足甚至直接接触或短

路而发生故障^[23]。图 1(d)显示了风偏故障的典型波形。该类故障多为金属性故障，过渡电阻较小，故障发生后故障相电压显著降低，故障相电流大幅增加，且含有少量的高次谐波和直流分量。

5) 覆冰故障。覆冰故障多发生在雪天或者冻雨天气。其故障机理是积满冰或雪的导线在重力作用下发生舞动或者脱冰跳跃，导线与导线间的安全距离不足导致空气间隙被击穿而发生故障。图 1(e)显示了覆冰故障的典型波形，该类故障的过渡电阻阻值较小，故障发生后故障相电压显著降低，故障相电流大幅增加，几乎不含高次谐波和直流分量。

6) 异物故障。异物触碰导线引发故障的情况有很多且多发生在晴天与大风天气。根据异物的电阻值不同，又可以细分为高阻异物故障和低阻异物故障。高阻异物故障是由于树木生长过高与带电导线之间的安全距离减小，导致它们之间的空气击穿，导线对外部物体放电而引起的故障^[37]。图 1(f)显示了典型的高阻异物故障波形，该故障的过渡电阻呈高阻值和非线性特性，故障发生后故障相电压变化不大，故障相电流和零序电流波形畸变，故障相电流略有增加，并且电压、电流谐波含量明显。低阻异物故障是由于薄膜、风筝线、外飘物等低阻性异物被风吹起飘挂或缠绕在导线上而引起的故障。低阻异物故障的过渡电阻阻值较小且呈线性，故障发生后故障相电流增大，故障相电压降低，故障波形呈正弦波，基本不含高次谐波。

此外，从图 2 中也可以看出，不同的天气情况在某些特定的故障原因下的占比会明显高于其他的天气情况。以本文的 6 类故障原因为例，发生雷击故障的天气情况为雷雨天和雨天，占比分别为 74.5%和 25.5%；发生山火故障的天气情况大多为晴

天，占比为 89.3%；发生污秽故障的天气情况多为阴天，占比为 80.3%；发生风偏故障的天气情况多为大风，占比为 86.2%；发生覆冰故障的天气多为雪天和冻雨天气，两类共占比为 82.8%；发生异物故障的天气多为晴天和大风天气，两类共占比为 86.7%。

由此可见，不同原因所导致的故障，其暂态波形和对应的天气条件都存在差异，特别是有些故障机理相似的故障原因(例如风偏和覆冰舞动，污闪和覆冰闪络)，其天气条件有较大差异，可以作为新的特征引入到故障辨识模型里，提高对易混淆故障原因的辨识效果。

2 模型的构建

2.1 输入集的构建

输电线路的故障辨识需要构造合适的输入特征，以及选取合适的分类器。对于输入集的构建，故障电压、故障电流的畸变情况可以有效地反映故障时过渡电阻和高次谐波的特征^[31]，因此本文将各变电站内采集得到的单端三相故障电压、故障电流数据，融合在一张大小为 224×224 的 RGB 图片上，作为一个故障样本。由于采集得到的故障数据在量纲和取值范围上存在着一定的差异，在作为后续网络模型的输入时电气量数值较小的数据特征不易被提取。因此，在得到输入的故障波形的样本集后，还需要对其进行归一化处理。本文利用式(1)对各组电气量进行归一化，将各电气量的幅值归算至 0 到 1 之间，从而保证故障特征的最大化。

$$x_i = \frac{x_i - \min(X)}{\max(X) - \min(X)} \quad (1)$$

式中： x_i 为各电气量所采集得到的故障数据点； X 为各电气量向量。

本文所采用的归一化图像中横坐标为对应的故障时刻，采样区间为故障发生前一周波至故障发生后两周波；纵坐标的取值则需要兼顾不同故障下波形的最大值。

在构造非电气量特征作为故障辨识模型的输入集时，由于不同天气条件下输电线路发生故障的原因概率不同，因此其对不同故障原因也存在着一些隐含的映射效果，含有帮助辨识不同故障原因的关键信息。本文将故障简报中的故障天气情况进行标准化，共统计得到晴天、雷雨、雨天、雪天、冻雨、大风、阴天、雾霾等 8 类天气情况，并将这些天气情况转化为独热编码的形式，作为故障原因辨识网络的非电气量特征输入。表 1 展示了不同天气情况的独热编码表示形式。

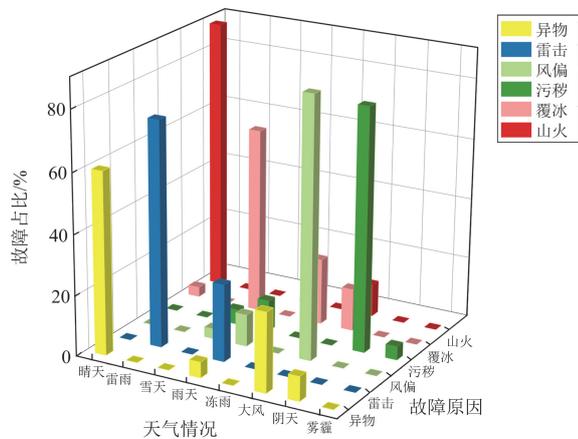


图 2 不同故障原因的天气情况统计图

Fig. 2 Weather statistics of different fault causes

表 1 不同天气情况的独热编码形式

Table 1 One-hot codes for different weather conditions

天气情况	独热编码表示
晴天	[1,0,0,0,0,0,0]
雷雨	[0,1,0,0,0,0,0]
雪天	[0,0,1,0,0,0,0]
雨天	[0,0,0,1,0,0,0]
冻雨	[0,0,0,0,1,0,0]
大风	[0,0,0,0,0,1,0]
阴天	[0,0,0,0,0,0,1]
雾霾	[0,0,0,0,0,0,0,1]

2.2 基于改进 ResNet 的故障辨识模型

CNN 具有较强的特征提取和分类能力, 不同原因的输电线路故障特征也存在着较大的差异。可以利用变电站内搜集得到的故障暂态录波数据的图像和 CNN 强大的特征提取能力, 挖掘故障特征, 实现故障辨识。

然而, 故障样本间的类不平衡性对使用浅层 CNN 进行故障辨识带来了挑战^[38]。需要搭建更深层次的网络来提取故障特征, 提高分类准确率。但是层数的堆叠也带来了一系列梯度爆炸、梯度消失等问题, 这使得模型不易收敛, 训练效果不佳。针对这些问题, 本文搭建了改进的 ResNet 网络和全连接网络来分别提取不同故障原因的暂态波形图像特征和天气特征, 并利用通道注意力机制实现两种故障特征的融合, 提升故障原因的辨识效果。故障原因辨识模型如图 3 所示, 该模型的结构包括如下几个部分。

1) 改进 ResNet 网络

网络的输入部分, 主要由一个卷积层以及一个最大池化层组成。式(2)给出了卷积层的计算公式, 其作用是对输入数据进行卷积计算以生成特征图。

$$y_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} * w_{ij}^l + b_j^l\right) \quad (2)$$

式中: y_j^l 表示在卷积层 j 中第 l 个滤波器的输出; $f(\cdot)$ 表示非线性函数; 运算符 $*$ 表示卷积; w_{ij}^l 是第 l 层的第 i 个输入和第 j 个输出映射之间的卷积核; b_j^l 是偏置。

在通过卷积计算后, 批量归一化层 (batch normalization, BN) 和 ReLU 层会将卷积层提取出来的特征形成一个新的特征图, 但是这些携带了大量特征量的特征图会阻碍计算操作。为了保留图片的明显特征, 同时减少冗余特征, 本文选用最大池化层来与卷积层共同组成网络特征提取的关键部分, 最大池化的计算公式如式(3)所示。

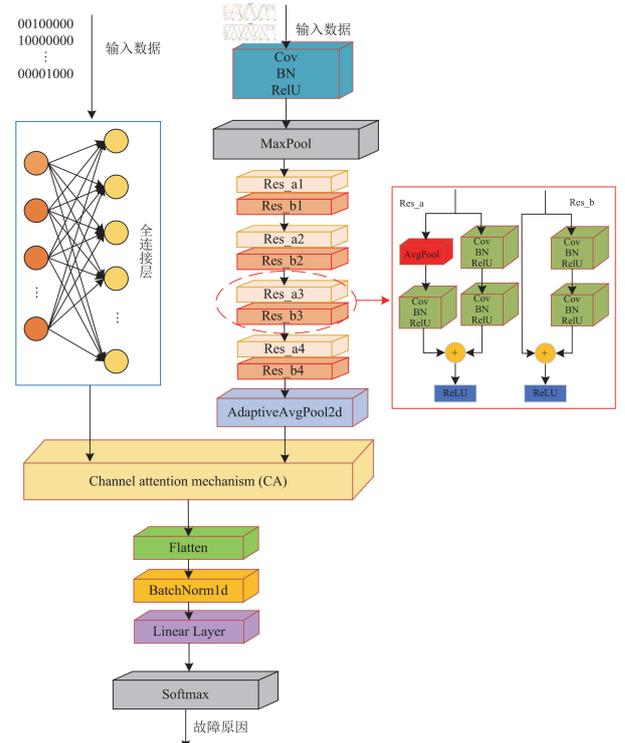


图 3 输电线路故障原因辨识模型

Fig. 3 Identification model of transmission line fault cause

$$h_{j+1}^l = \max(y_j^l(t)), (z-1) \times d + 1 \leq t \leq z \times d \quad (3)$$

式中: h_{j+1}^l 是池化层结果; d 是池化的局部区域长度; z 是池化层的输入特征的数量; t 是通过最大池化收集的特征的数量。

网络的中间层部分, 主要由 4 个残差网络组成。传统的残差网络主要由两个尺寸为 3×3 的卷积核、步长为 1 的卷积层以及一个卷积核尺寸为 1×1 、步长为 2 的跳远连接组成。当输入数据通过跳远连接进行降采样时, 由于其会经历一个步长为 2、卷积核尺寸为 1×1 的卷积层, 其特征图尺寸将减小为原先的一半, 因此原先特征图中 $3/4$ 的信息将不会被利用。所以本文在原残差模块单元的跳远连接中的卷积层前加入了一个池化核尺寸为 2×2 、步长为 2 的平均池化层, 并将原卷积层的步长改为 1, 以提高输入到残差网络中的特征图信息的提取和利用率。最终, 故障暂态波形图像在经过残差网络模块的计算后, 其输出结果将通过全局自适应平滑池化层的池化操作, 将所有特征图的尺寸处理为 $1 \times 1 \times 512$ 。

2) 全连接网络

CNN 通常使用固定大小的卷积核来提取数据特征, 这种通过局部窗口来进行卷积操作的方式使得它在对一维数据(如时间序列数据或文本数据)进行特征提取时只能够捕捉数据的局部特征, 无法实

现对一维数据全局特征的有效提取^[39]。全连接网络(fully connected network, FCN)能够通过每一层的神经元与上一层的所有神经元相连接,实现对一维数据全局特征的提取。通常情况下,全连接网络有输入层、隐藏层和输出层3种结构。隐藏层中的每个神经元将通过式(4)来加权连接,实现对输入数据的组合,形成更高维的数据特征。

$$z_j^{(k)} = \sum_{i=1}^N w_{ij}^{(k)} x_i + b_j^{(k)} \quad (4)$$

式中: $w_{ij}^{(k)}$ 是输入 x_i 到第 k 个隐藏层神经元 j 的权重; $b_j^{(k)}$ 是偏置项; $z_j^{(k)}$ 是激活值。然后,通过 ReLU 激活函数,得到该神经元的输出为

$$a_j^{(k)} = \sigma(z_j^{(k)}) \quad (5)$$

式中: σ 表示激活函数。

本文将采用全连接网络的输入层和隐藏层实现对一维气象数据的特征提取。网络的输入层神经元个数为8,第一隐藏层的神经元个数为50,第二隐藏层的神经元个数为200。最终尺寸为 1×8 的一维气象数据通过全连接网络的逐层加权求和与非线性变换操作后,其输出的尺寸将变为 $1 \times 1 \times 512$ 。

3) 通道注意力机制

通道注意力机制允许网络模型执行特征的重新校准,实现对不同通道重要性的自主学习,有选择性地强化某些重要特征,改进模型的表现^[40]。本文采用 SENet 网络中的挤压激励(squeeze-and-excitation, SE)模块,通过对通道间的依赖关系进行建模,实现通道注意力机制。该模块利用挤压操作中的全局平均池化来计算每一个通道上所有元素的平均值,生成一个通道级的全局特征描述。利用激励操作来学习通道之间的依赖关系,为每个通道生成权重。最后,将得到的通道权重与原有特征的每个通道相乘,实现对原特征的重标定。最终两个模态的特征利用通道注意力机制进行融合后,其特征尺寸将变为 $1 \times 1 \times 1024$ 。

4) 输出部分

在经过 SE 模块的特征融合后,输出结果将通过展平层(Flatten)以及 BN 的正则化处理来防止模型的过拟合,最后连接线性层和 Softmax 层,输出对应的辨识结果。对于故障原因辨识模型,网络的输出则是雷击、山火、污秽、风偏、覆冰和异物故障6种故障原因。

3 算例分析

3.1 模型的训练与测试

为验证算模型法的有效性,本文以第1节所述

故障样本集开展算例研究,实验在进行数据划分时将随机抽取各故障原因类别下70%的样本作为训练集,30%的样本作为测试集,开展模型的训练与测试。在训练过程中模型的损失函数采用与 Softmax 分类器相结合的交叉熵损失函数,优化器则采用 Adam 算法来进行参数的优化。同时,为了能够更加客观地评价模型的辨识性能,本文使用总精度来衡量模型的辨识准确率,其计算公式如式(6)所示。

$$A = \frac{N_{PT}}{N_{PF} + N_{PT}} \quad (6)$$

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。

与此同时,为了能够探究不同训练参数对模型辨识效果的影响,本文运用控制变量法,在相同的参数设置下,分别调整学习率 $L = 0.1$ 、 0.01 、 0.001 、 0.0001 ,模型批训练量 $B = 32$ 、 64 、 128 、 256 ,训练轮数 $E = 10$ 、 15 、 20 、 25 、 30 ,进行模型的训练与测试。

最终实验的结果如图4—图6所示。分析图4—图6可得:当学习率 $L = 0.001$ 时训练效果最佳,当学习率 L 减小至 0.0001 时故障辨识的准确率开始下降,这是因为过小的学习率会使得模型的损失函数无法收敛于全局的最小值。而过大的学习率则会导致模型的损失函数无法收敛,进而降低模型的辨识准确率。对于批训练量的选取, $B = 64$ 时模型的辨识效果最佳,当 B 达到或超过 128 时,模型的辨识效果会略微下降,这是因为过大的批训练量会导致梯度的消失,进而影响训练的稳定性与准确率。通常情况下,较低的训练轮数会使得模型训练不充分,从而导致故障的辨识准确率不高。随着训练轮数的

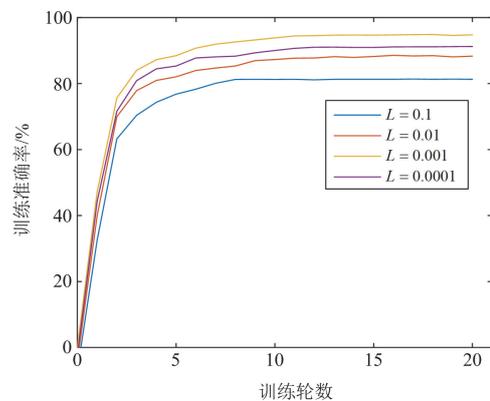


图4 不同学习率下的故障原因辨识准确率

Fig. 4 Fault cause identification accuracy under different learning rates

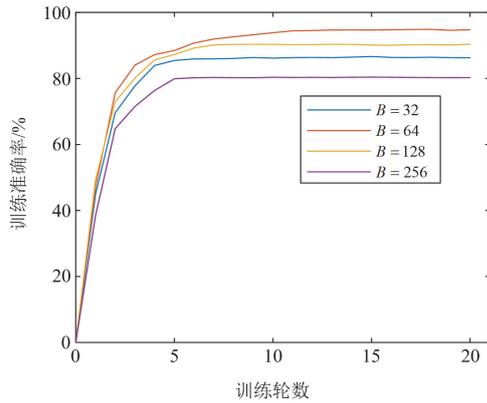


图 5 不同批训练量下的故障原因辨识准确率

Fig. 5 Fault cause identification accuracy under different batch training quantities

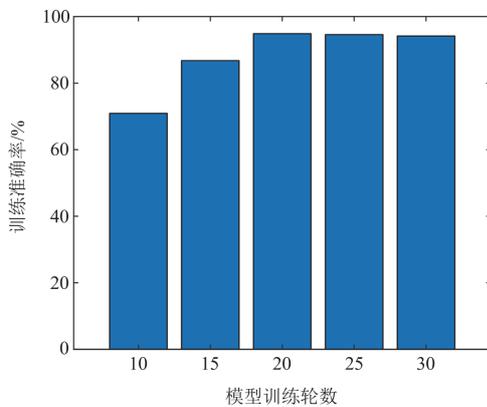


图 6 不同训练轮数下的故障原因辨识准确率

Fig. 6 Fault cause identification accuracy under different training epochs

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 $L = 0.001$, 模型批训练量 $B = 64$, 本地训练轮数 $E = 20$ 。此时模型对对故障原因辨识准确率为 94.87%, 网络故障辨识的混淆矩阵如图 7 所示。由图 7 可知本文方法在进行故障原因的辨识时出现了少许错误, 其原因是发生混淆的这几类故障的过渡电阻性质相近, 发生故障时的故障暂态波形的特征较为相似。同时, 又由于在发生故障当天的天气情况相同, 所以最终导致了某些故障原因辨识的混淆。因此, 在后续的研究中若能够将录波数据与气温、故障发生时间、重合闸信息等其他非电气量特征相结合, 将有效解决该问题。

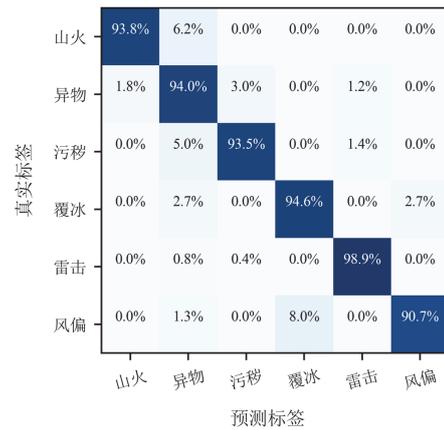


图 7 故障原因辨识混淆矩阵

Fig. 7 Confusion matrix of fault cause identification

3.2 与其他方法的对比讨论

为了进一步验证本文方法的效果, 本文还从不同的网络模型结构、不同的网络模态以及不同的训练和测试样本比例 3 个角度来进行对比实验。

1) 不同网络模型结构的辨识结果对比

在进行网络模型结构的论证时, 本文模型与 ResNet18 网络、AlexNet 网络和普通 CNN 网络进行了对比实验。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 2 所示。

表 2 不同模型的故障辨识效果

Table 2 Fault identification effect of different models

网络模型	准确率/%
本文模型	94.87
ResNet18	91.32
AlexNet	83.58
CNN	78.21

根据表 2 的结果可知, ResNet18 网络、AlexNet 网络和普通 CNN 网络对故障原因的辨识分别取得了 91.32%、83.58% 和 78.21% 的准确率, 三者网络的故障原因辨识准确率均低于本文模型。其根本原因是本文方法中改进的残差网络模块中的跳远连接层能够更好地提取和保留三相故障电压、电流的暂态波形图像的特征。

2) 不同网络模态的辨识结果对比

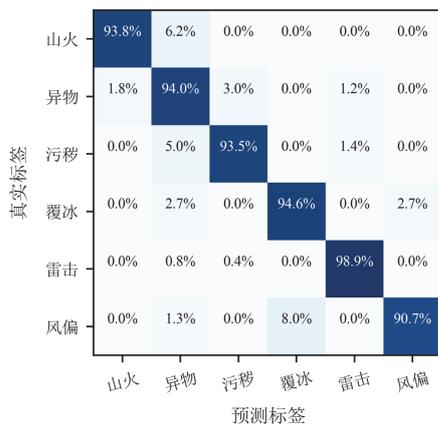
在进行网络模态的论证时, 本文与仅采用故障暂态波形图像作为输入的单模态网络进行了对比实验。对比实验均采用本文方法中同样的网络主体结构和网络参数以及相同的训练集与测试集。最终, 不同网络模态的故障辨识结果如表 3 所示, 图 8 则显

示了以改进 ResNet 网络为主体的多模态网络和单模态网络的故障辨识混淆矩阵。

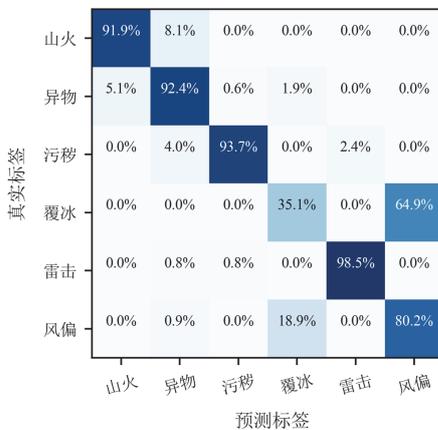
表 3 不同网络模态故障辨识效果

Table 3 Fault identification effect of different network modes

深度学习网络	多模态网络的准确率	单模态网络的准确率
本文模型	94.87	92.39
ResNet18	91.32	89.15
AlexNet	83.58	80.23
CNN	78.21	73.52



(a) 多模态网络故障辨识混淆矩阵



(b) 单模态网络故障辨识混淆矩阵

图 8 不同网络模态的故障原因辨识混淆矩阵

Fig. 8 Confusion matrix of fault cause identification for different network modes

根据表 3 结果可知，当模型仅采用故障暂态录波图像作为单模态网络的特征输入开展故障原因的辨识时，4 种网络模型的辨识准确率均有所下降，分别为 92.39%、89.15%、80.23%和 73.52%。这是因为本文方法同时使用故障暂态波形图像与故障时的天气特征作为多模态网络的输入，多模态网络能

够同时提取故障发生时的电气量特征与气象特征并实现特征的融合，进而能够结合气象特征将原先仅使用暂态波形图像的单模态网络所不能辨识的风偏、覆冰等易混淆故障辨识出来，进一步提升故障原因辨识的准确率。

3) 不同训练和测试样本比例的结果对比

在开展不同训练和测试样本比例对故障辨识效果影响的对比实验时，本文分别对比了 6:4、7:3 与 8:2 的样本比例的训练和测试准确率，辨识结果如表 4 所示。

表 4 不同训练集和测试集样本比例的辨识结果对比

Table 4 Comparison of identification results of different proportion of training sets and test sets

训练集与测试集的比例	训练准确率/%	测试准确率/%
6:4	93.41	92.88
7:3	95.24	94.87
8:2	96.05	95.24

根据表 4 的结果可知，采用 8:2 的样本比例，模型的训练和测试准确率最高，采用 7:3 的结果略低，采用 6:4 的结果再次之。采用 80%的样本集训练，随着训练数据量的增大，故障辨识模型在训练过程中的计算量和时间成本也会显著增加，需要更多的迭代次数才能收敛，也容易导致过拟合现象。当采用 60%的样本集训练，训练和测试准确率均为最低，主要原因是模型所使用的训练数据较少，故障辨识模型没有得到充分的训练，准确率较低。因此，综合考虑模型辨识准确率与训练成本，本文采用 70%的样本作为训练集，30%样本作为测试集，开展模型的训练与测试。

4 结论

针对现有基于暂态波形图像识别的输电线路故障原因辨识，因使用的输入特征相对单一而无法进一步细分故障原因的问题，本文提出了一种融合暂态波形与天气特征的输电线路故障原因辨识方法，经过研究，得出如下结论。

1) 相较于传统的基于多源数据特征融合的故障辨识方法，本文方法以故障暂态波形图像和故障发生时天气情况的独热编码作为输入，所需的故障特征量更少，在实际的工程应用中更加容易获得。

2) 本文搭建的改进 ResNet 故障辨识分类器，在多模态网络的情况下对故障原因的辨识准确率达到 94.87%，在单模态网络的情况下对故障原因的辨识准确率达到 92.39%，相比 ResNet18、AlexNet 和 CNN，辨识准确率更高。

3) 使用多模态网络实现不同故障特征的融合, 不同的网络结构对输电线路故障原因的辨识准确率都得到了提升。相比于传统的单模态网络, 使用气象特征作为网络模型的非电气量特征输入后, 网络对故障机理、故障特征类似的易混淆故障的辨识准确性更高, 可以有效地实现输电线路的故障辨识。

本文所提方法虽然能够较为准确地辨识出输电线路的故障原因, 但仅使用了输电线路发生故障时的 8 类典型天气情况作为非电气量特征, 因此故障辨识模型的泛化性不足, 模型迁移至其他地区后可能会出现辨识效果降低的现象。在今后的研究中, 将深入探究输电线路发生故障时其他的非电气量特征, 同时考虑不同地区输电线路故障样本间的特征差异, 使用联邦学习算法来消除不同地域之间的故障特征差异, 提高故障辨识模型的泛化性。

参考文献

- [1] 元臻康, 王浩宗, 董新洲, 等. 不依赖 GNSS 的输电线路双端行波故障测距[J]. 中国电机工程学报, 2024, 44(10): 3766-3776.
QI Zhenkang, WANG Haozong, DONG Xinzhou, et al. A GNSS-independent two-terminal traveling wave fault location scheme for transmission lines[J]. Proceedings of the CSEE, 2024, 44(10): 3766-3776.
- [2] 常康, 薛禹胜, 郁琛, 等. 整体还原论视角下的输电线路复合灾害故障率评估——(二)算法及应用[J]. 电力系统自动化, 2025, 49(4): 32-41.
CHANG Kang, XUE Yusheng, YU Chen, et al. Evaluation of compound-disaster failure rate for transmission lines from perspective of whole reductionism thinking —— part two algorithm and application[J]. Automation of Electric Power Systems, 2025, 49(4): 32-41.
- [3] 张广斌, 陈柏宇, 束洪春, 等. 基于时域波形特征认知的输电线路近端故障辨识与定位[J]. 电力系统自动化, 2024, 48(5): 146-156.
ZHANG Guangbin, CHEN Boyu, SHU Hongchun, et al. Identification and location of near-end faults in transmission lines based on time-domain waveform characteristic recognition[J]. Automation of Electric Power Systems, 2024, 48(5): 146-156.
- [4] 徐舒玮, 邱才明, 张东霞, 等. 基于深度学习的输电线路故障类型辨识[J]. 中国电机工程学报, 2019, 39(1): 65-74.
XU Shuwei, QIU Caiming, ZHANG Dongxia, et al. A deep learning approach for fault type identification of transmission line[J]. Proceedings of the CSEE, 2019, 39(1): 65-74.
- [5] 梁远升, 徐征, 丁佳彦, 等. 基于复域暂态解析的柔性直流输电线路单端故障测距方法[J]. 电力系统自动化, 2024, 48(24): 155-165.
LIANG Yuansheng, XU Zheng, DING Jiayan, et al. Single-ended fault location method for flexible DC transmission lines based on complex-domain transient analysis[J]. Automation of Electric Power Systems, 2024, 48(24): 155-165.
- [6] 伊博宇, 陈益广, 张少凡, 等. 输电网同时故障下基于多时段安德森加速的协同恢复策略[J]. 电力系统自动化, 2024, 48(20): 159-170.
YI Boyu, CHEN Yiguang, ZHANG Shaofan, et al. Collaborative recovery strategy based on multi-period Anderson acceleration under simultaneous failures in transmission and distribution network[J]. Automation of Electric Power Systems, 2024, 48(20): 159-170.
- [7] 赵欣洋, 邹洪森, 杨晨, 等. 基于模量反向行波的接地极线路故障类型识别与定位方法[J]. 中国电力, 2025, 58(2): 33-42.
ZHAO Xinyang, ZOU Hongsen, YANG Chen, et al. Fault type recognition and localization method for grounding electrode line based on modulus backward traveling wave[J]. Electric Power, 2025, 58(2): 33-42.
- [8] GUILLEN D, SERNA JA, ZAMORA-MENDEZ A, et al. Taylor-Fourier filter-bank implemented with O-splines for the detection and classification of faults[J]. IEEE Transactions on Industrial Informatics, 2021, 17(5): 3079-3089.
- [9] OSMAN S, WANG W. A morphological Hilbert-Huang transform technique for bearing fault detection[J]. IEEE Transactions on Instrumentation and Measurement, 2016, 65(11): 2646-2656.
- [10] TAO J, FENG Z, MOHAMED M A. A novel approach based on CEEMDAN to select the faulty feeder in neutral resonant grounded distribution systems[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(7): 4712-4721.
- [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, 311.
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, 311.
- [12] 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): 1-14.
- [13] 包金山, 杨定坤, 张靖, 等. 基于特征提取与 INGO-SVM 的变压器故障诊断方法[J]. 电力系统保护与控制, 2024, 52(7): 24-32.
BAO Jinshan, YANG Dingkun, ZHANG Jing, et al. Transformer fault diagnosis method based on feature extraction and INGO-SVM[J]. Power System Protection and Control, 2024, 52(7): 24-32.
- [14] 石万宇, 魏军强, 赵云灏. 基于改进麻雀算法-支持向量机的输电线路故障诊断[J]. 浙江电力, 2021, 40(11): 38-45.
SHI Wanyu, WEI Junqiang, ZHAO Yunhao. Transmission line fault diagnosis based on support vector machine optimized by improved sparrow search algorithm[J]. Zhejiang Electric Power, 2021, 40(11): 38-45.
- [15] BISWAS S, NAYAK P K. A fault detection and classification scheme for unified power flow controller compensated transmission lines connecting wind farms[J]. IEEE Transactions on Power Delivery, 2021, 15(1): 297-306.
- [16] 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.
- [17] 王娜娜, 栗文义, 李小龙. 基于不平衡小样本 DGA 数据与改进 CatBoost 决策树的油浸式变压器故障诊断方法[J]. 电力系统保护与控制, 2024, 52(23): 167-176.
WANG Nana, LI Wenyi, LI Xiaolong. An oil-immersed transformer fault diagnosis method based on DGA unbalanced limited sample processing and improved CatBoost[J]. Power System Protection and Control, 2024, 52(23): 167-176.
- [18] PAZOKI M. A new fault classifier in transmission lines using intrinsic time decomposition[J]. IEEE Transactions on Industrial Informatics, 2018, 14(2): 619-628.
- [19] MORADZADEH A, TEIMOURZADEH H, MOHAMMADI-IVATLOO B, et al. Hybrid CNN-LSTM approaches for identification of type and locations of transmission line faults[J]. International Journal of Electrical Power and Energy Systems, 2022, 135: 1-13.
- [20] 赵启, 王建, 林丰恺, 等. 基于格拉姆角场与 ResNet 的输电线路故障辨识方法[J]. 电力系统保护与控制, 2024, 52(10): 95-104.
ZHAO Qi, WANG Jian, LIN Fengkai, et al. Transmission line fault identification method based on Gramian angular field and ResNet[J]. Power System Protection and Control, 2024, 52(10): 95-104.
- [21] WU H, WANG J, NAN D, et al. Transmission line fault cause identification method based on transient waveform image and MCNN-LSTM[J]. Measurement, 2023, 15(4): 22-36.
- [22] 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.
- [23] 张虹. 输电线路故障原因综合辨识研究[D]. 济南: 山东大学, 2016
ZHANG Hong. Research on comprehensive identification of transmission line fault causes[D]. Jinan: Shandong University, 2016.
- [24] 邓祥力, 吴高珍, 魏聪聪, 等. 基于多源数据融合的 Alexnet 神经网络大电网故障诊断[J]. 现代电力, 2023, 40(2): 161-169.
DENG Xiangli, WU Gaozhen, WEI Congcong, et al. Fault diagnosis of large grid with Alexnet neural network based on multi-source data fusion[J]. Modern Electric Power, 2023, 40(2): 161-169.
- [25] 董毓毓. 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.
- [26] 范李平, 袁兆强, 张凯. 基于小波变换的单相接地故障电弧模型及其 PSCAD/EMTDC 仿真研究[J]. 电力系统保护与控制, 2011, 39(5): 51-56.
FAN Liping, YUAN Zhaoqiang, ZHANG Kai. Simulation on arc model of single phase earth fault and PSCAD/EMTDC based on wavelet transformation[J]. Power System Protection and Control, 2011, 39(5): 51-56.
- [27] 宁家兴, 和敬涵, 李猛, 等. 真双极柔性直流系统单极接地故障熄弧时刻识别策略[J]. 电力系统自动化, 2022, 46(13): 121-129.
NING Jiaying, HE Jinghan, LI Meng, et al. Identification strategy for arc extinction time of single-pole grounding fault in true bipolar flexible DC system[J]. Automation of Electric Power Systems, 2022, 46(13): 121-129.
- [28] 何柏娜, 宁家兴, 黄桂春, 等. 基于积分比分布的单相接地故障熄弧时刻识别策略[J]. 电力自动化设备, 2020, 40(4): 178-184.
HE Baina, NING Jiaying, HUANG Guichun, et al. Identification strategy of arc extinguishing time of single-phase grounding fault based on integral ratio

- distribution[J]. *Electric Power Automation Equipment*, 2020, 40(4): 178-184.
- [29] 俞小勇, 秦丽文, 欧阳健娜. 间歇性电弧接地故障建模分析[J]. *南方电网技术*, 2019, 13(12): 67-73.
YU Xiaoyong, QIN Liwen, OUYANG Jianna. Modeling analysis of intermittent arc grounding fault[J]. *Southern Power System Technology*, 2019, 13(12): 67-73.
- [30] DOBAKSHARI A S, RANJBAR A M. A novel method for fault location of transmission lines by wide-area voltage measurements considering measurement errors[J]. *IEEE Transactions on Smart Grid*, 2015, 6(2): 874-884.
- [31] LIU H, LIU S, ZHAO J, et al. Dual-channel convolutional network-based fault cause identification for active distribution system using realistic waveform measurements[J]. *IEEE Transactions on Smart Grid*, 2022, 13(6): 4899-4908.
- [32] LONG Y, YAO C, MI Y, et al. Identification of direct lightning strike faults based on Mahalanobis distance and S-transform[J]. *IEEE Transactions on Dielectrics and Electrical Insulation*, 2015, 22(4): 2019-2030.
- [33] 郭伯森, 李天友, 王连辉, 等. 基于层次分析法的中压配电线路森林火灾故障预警辨识模型[J]. *供用电*, 2023, 40(3): 55-62.
GUO Bosen, LI Tianyou, WANG Lianhui, et al. An early warning evaluation model for forest fire faults in medium-voltage distribution lines based on analytic hierarchy process[J]. *Distribution & Utilization*, 2023, 40(3): 55-62.
- [34] 黄道春, 余俊, 张宇, 等. 220 kV 线路悬式绝缘子串异物临近放电机制研究[J]. *中国电机工程学报*, 2014, 34(24): 4161-4170.
HUANG Daochun, YU Jun, ZHANG Yu, et al. 220 kV study on discharge mechanism of suspension insulator string of 220 kV AC transmission line with external object approaching[J]. *Proceedings of the CSEE*, 2014, 34(24): 4161-4170.
- [35] SANTOS H, SANZ-BOBI M A. A Cumulative pollution index for the estimation of the leakage current on insulator strings[J]. *IEEE Transactions on Power Delivery*, 2020, 35(5): 2438-2446.
- [36] FAN C, JIANG X, XIE Y, et al. Novel DC flashover model for predicting flashover voltage of the iced insulators[J]. *High Voltage*, 2021, 6: 149-159.
- [37] CONG Z, LIU Y, YAN Y, et al. Study on the mechanism and electrical characterization of the tree-contact incipient fault in the non-effectively grounded system[J]. *IEEE Transactions on Power Delivery*, 2023, 38(3): 1709-1719.
- [38] MADUAKO I, CHUKWUEMEKA F I, ABAH J E, et al. Deep learning for component fault detection in electricity transmission lines[J]. *Journal of Big Data*, 2022, 9: 1-34.
- [39] 张淑清, 杜灵韵, 王册浩, 等. 基于格拉姆角场与改进的 CNN-ResNet 风电功率预测方法[J]. *电网技术*, 2023, 47(4): 1540-1549.
ZHANG Shuqing, DU Lingyun, WANG Cehao, et al. Wind power forecasting method based on GAF and improved CNN-ResNet[J]. *Power System Technology*, 2023, 47(4): 1540-1549.
- [40] 胡宇晗, 朱利鹏, 李佳勇, 等. 融合深度误差反馈学习和注意力机制的短期风电功率预测[J]. *电力系统保护与控制*, 2024, 52(4): 100-108.
HU Yuhan, ZHU Lipeng, LI Jiayong, et al. Short-term wind power forecasting with the integration of a deep error feedback learning and attention mechanism[J]. *Power System Protection and Control*, 2024, 52(4): 100-108.

收稿日期: 2024-12-24; 修回日期: 2025-04-09

作者简介:

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

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

(编辑 石晋美)