

引用格式:裴东锋,刘勇,闫柯柯,等.一种基于 CNN 与 FFT-ELM 的输电线路故障识别与定位方法[J].电力科学与技术学报,2024,39(1):164-170.

Citation: PEI Dongfeng, LIU Yong, YAN Keke, et al. A method based on CNN and FFT-ELM for fault identification and location of transmission lines [J]. Journal of Electric Power Science and Technology, 2024, 39(1): 164-170.

一种基于 CNN 与 FFT-ELM 的输电线路 故障识别与定位方法

裴东锋¹, 刘勇¹, 闫柯柯¹, 郭威¹, 宋福如², 田志杰¹

(1. 国网河北省电力有限公司邯郸供电公司, 河北邯郸 056002; 2. 河北硅谷研究院, 河北邯郸 057151)

摘要:及时、准确地检测输电线路故障类型与位置是提高电力系统可靠性最重要的问题之一,为此提出一种基于卷积神经网络(convolutional neural networks, CNN)与基于快速傅里叶变换(fast Fourier transform, FFT)的极限学习机(extreme learning machine, ELM)分类模型并行的输电线路故障识别及定位方法。首先,以故障电压时序图作为输入,构建 CNN;然后,利用 FFT 将时域故障电压数据分解,提取各频段的电压峰值与相角作为故障特征样本;接着,以提取的故障特征样本集作为输入,构建 ELM 网络;最后,通过特征融合层将 2 个神经网络进行融合,输出故障类型和定位结果。实验结果表明,此方法对输电线路故障识别的准确率为 99.95%、故障定位误差在 500 m 以内、平均误差为 263.5 m,可靠性优于其他模型。

关键词:故障识别及定位;输电线路;并行神经网络;卷积神经网络;快速傅里叶变换;极限学习机

DOI: 10.19781/j.issn.1673-9140.2024.01.016 中图分类号:TM863 文章编号:1673-9140(2024)01-0164-07

A method based on CNN and FFT-ELM for fault identification and location of transmission lines

PEI Dongfeng¹, LIU Yong¹, YAN Keke¹, GUO Wei¹, SONGFuru², TIAN Zhijie¹

(1. Handan Electric Power Supply Company, State Grid Hebei Electric Power Co., Ltd., Handan 056002, China;

2. Hebei Silicon Valley Academy, Handan 057151, China)

Abstract: It is one of the most important problems in power system reliability to detect the fault types and locations of transmission lines in time and accurately. This paper presents an approach for fault identification and location of transmission lines based on convolutional neural networks (CNN) parallel with extreme learning machine (ELM) based on fast Fourier transform (FFT). First, CNN is constructed with fault voltage sequence diagram as input. Then FFT is used to decompose the fault voltage data in time domain and extract the peak voltage and phase angle of each frequency band as fault feature samples. The ELM network is then constructed by taking the extracted fault feature sample set as input. Finally, the two neural networks are fused by the feature fusion layer to output the fault type and location results. Experimental results show that the accuracy of the method is 99.95%, the error of fault location is less than 500 m and the average error is 263.5 m; the reliability of the method is better than other models.

Key words: fault identification and location; transmission lines; parallel neural networks; convolutional neural network; fast Fourier transformation; extreme learning machine

收稿日期:2023-05-12;修回日期:2023-10-11

基金项目:国网河北省电力有限公司科技项目(kj2021-042)

通信作者:郭威(1996—),男,硕士,中级工程师,主要从事电网变电运维研究;E-mail:583370680@qq.com

随着构建以新能源为主体的新型电力系统的提出以及用户对获得安全、可持续和高质量电力的需求上升,电力系统的复杂性大大增加^[1-2]。输电线路的性能提升对持续供电起着重要作用,线路故障的准确识别和定位有利于缺陷点的即时检测,从而缩短排除故障所需的时间并快速恢复电力服务^[3-4]。

故障识别和定位技术通常分为两部分:常规技术和机器学习方法。传统技术包括统计方法、基于小波变换的方法以及包含注入脉冲波、瞬态波形和稳态相量的电气测量^[5-9],统计和优化方法需要大量的数学计算,除了根据所需的计算来识别故障的类型或位置外,还依赖人为经验。科学技术的进步,使得机器学习广泛地应用在故障识别及故障定位领域,且取得了较好效果。针对输电线路故障数据集的非均衡性问题,文献[10]提出一种基于小波奇异信息和改进合成少数类过采算法进行故障识别,具有较强的泛化性能和鲁棒性。文献[11]提出一种基于全卷积神经网络和卷积注意力模块相结合的故障识别方法,提高了传统全卷积神经网络聚焦关键信息的能力。文献[12]提出一种深度置信网络的无监督学习框架,用于输电线路的故障检测和分类,通过独特的两阶段学习策略从受不确定性影响的信号中学习有益的特征信息。

数字信号处理方法具有从故障信号中提取隐藏信息的能力。因此,它们不仅提高了故障特征的质量,而且减少了训练机器学习工具所需的特征数量,从而以较低的计算实现更好的准确性。文献[13]采用小波分解法提取故障特征,再利用卷积神经网络进行故障识别。文献[14]通过离散傅里叶变换提取故障特征来训练极限学习机(extreme learning machine, ELM)。文献[15]提出一种基于李萨如模式叠加分量的特征提取技术,用于识别输电线路故障的类型和位置。以上文献在故障识别与定位领域取得了一些进展,但存在一些局限性,传统方法由于依赖人工经验存在限制,单一的机器学习方法的特征表达能力受限,容易在训练数据上过拟合。

新型输电技术的发展给电网安全运行带来了更为复杂的问题^[16-17],输电线路故障类型更加多变且采集的故障数据存在干扰信号,采用单一的故障识别和定位模型难以满足工程对输电线路故障识

别及定位的精度要求。为此,本文提出一种不同深度神经网络并行的故障识别方法,分别为卷积神经网络(convolutional neural networks, CNN)和ELM, CNN的输入为故障电压时序图,ELM的输入为通过快速傅里叶变换(fast Fourier transform, FFT)得到的故障特征,最后构造融合层,采用Softmax函数完成结果输出。

1 CNN

CNN是最成功的深度学习应用之一,端到端结构使其成为特征提取的强大工具,其网络结构由输入层、卷积层、池化层和全连接层组成^[18]。原始故障数据由具有相关特征的卷积层提取,这些特征将通过池化层进一步减小特征图的大小,并提供稳健的学习结果,全局特征被扩展为矩阵,输入到全连接层进行分类或回归。CNN通过权重共享的方式显著降低了网络结构的复杂性。

1.1 卷积层

卷积层执行从输入数据中提取特征的功能。卷积运算使用ReLU激活函数执行,如下:

$$f(x) = \begin{cases} x, & x > 0 \\ 0, & \text{其他} \end{cases} \quad (1)$$

特征图由滤波器生成,如下:

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

式中, y_j^l 为卷积层 j 中第 l 个滤波器的输出; $f(\cdot)$ 为激活函数;*为卷积; x_i^{l-1} 为第 $l-1$ 层卷积核的第 i 个输入; w_{ij}^{l-1} 为第 i 个输入和第 j 个输出映射之间的第 l 层中的卷积核; b_j^l 为偏置。

1.2 池化层

卷积层提取的特征形成了一个新的特征图,但是这些特征图携带了大量的特征,池化层在保持明显特征的同时减少冗余特征。本文采用最大池化计算特征图,如下:

$$y_j^l = f\left(\sum_{i \in M_j} \alpha x_i^{l-1} + b_j^l\right) \quad (3)$$

式中, α 为最大池化; M_j 为卷积层 j 的数据集合。

1.3 全连接层

全连接层是具有互联神经元的前馈神经网络,卷积层和池化层提取的特征为全连接层的输入,如下:

$$O^j = f\left(\sum_{i=1}^n w_{ij}' x_i' + c_j\right) \quad (4)$$

式中, c_j 为偏置。

2 基于FFT的ELM分类模型

2.1 FFT

FFT是离散傅里叶变换的一种快速计算方法^[19],离散信号的采样点数 N 越大,FFT的计算速度越快。

对于任何周期性电压或电流信号 $f(t)$,它可以表示为周期 T 的函数:

$$f(t) = f(t + kT), k = 0, 1, 2, \dots \quad (5)$$

傅里叶级数表示为

$$f(t) = a_0 + \sum_{n=1}^{\infty} (a_n \cos(n\omega t) + b_n \sin(n\omega t)) \quad (6)$$

式中, a_0 为直流分量; ω 为基波角频率; n 为谐波数, a_n 和 b_n 分别为 n 次谐波的余弦项系数和正弦项系数。

根据欧拉方程:

$$\begin{cases} e^{j\omega t} = \cos(\omega t) + j\sin(\omega t) \\ e^{-j\omega t} = \cos(\omega t) - j\sin(\omega t) \end{cases} \quad (7)$$

式(6)可转换为

$$\begin{aligned} f(t) &= a + \sum_{n=1}^{\infty} \left[\frac{1}{2} a_n (e^{j\omega t} + e^{-j\omega t}) - \frac{1}{2} j b_n (e^{j\omega t} - e^{-j\omega t}) \right] = a + \\ &\sum_{n=1}^{\infty} \left(\frac{a_n - j b_n}{2} e^{jn\omega t} + \frac{a_n + j b_n}{2} e^{-jn\omega t} \right) = \sum_{n=1}^{\infty} F_n e^{jn\omega t} \quad (8) \end{aligned}$$

$$F_n = \frac{1}{2} (a_n - j b_n) \quad (9)$$

对于具有基本角频率的连续函数 $f(t)$,当满足狄利克雷条件且绝对可积时,其傅里叶变换可表示为

$$F(\omega) = \int_{-\infty}^{+\infty} f(t) e^{-j\omega t} dt \quad (10)$$

对于离散信号 $f(n)$,当采样点数为 N 时,离散傅里叶变换公式为

$$F(k) = \sum_{n=0}^{N-1} f(n) e^{-j \frac{2\pi k n}{N}}, k = 0, 1, 2, \dots, N-1 \quad (11)$$

式中, $f(n)$ 为原始离散信号; N 为离散信号采样点数; $F(k)$ 为原始信号离散傅里叶变换后的频谱。

FFT将不同频率的故障电压信号进行分解。本文选取直流分量和前5次谐波分量的电压幅值作

为特征级,将这些特征输入到ELM。

2.2 ELM

ELM是一种单隐含层的前馈网络,且通过广义逆矩阵求解输出值,因而有更好的泛化能力和更强的分类性能,在各领域被广泛应用^[20]。网络包括输入层、隐含层和输出层,从输入到隐藏层的参数是随机计算的,而从隐藏层到输出层的参数是使用伪逆计算的。

假设在单个隐藏层神经网络中有 M 个输入样本,其中 $Z_n = [Z_{n1}, Z_{n2}, \dots, Z_{nm}]^T$ 。那么具有 K 个隐藏层节点的ELM网络表示为

$$p_n = \sum_{n=1}^K \beta_n \cdot g(W_n \cdot Z_n + a_n) \quad (12)$$

式中, $g(\cdot)$ 为激活函数; $W_n = [\omega_{n1}, \omega_{n2}, \dots, \omega_{nm}]^T$ 为输入层与隐藏层的连接权值; β_n 为隐藏层和输出层之间的输出权重; a_n 为第 i 个隐层单元的偏置; p_n 为输出值; \cdot 为内积。

3 并行神经网络模型

融合不同深度的网络模型能得到比单一模型更好的结果^[21],故本文提出并行CNN与FFT-CNN的故障识别模型,与串行结构相比,并行结构同时处理原始数据,可以有效地从原始数据中提取更多信息,提高故障分类和定位的分类精度,并行神经网络模型结构如图1所示。

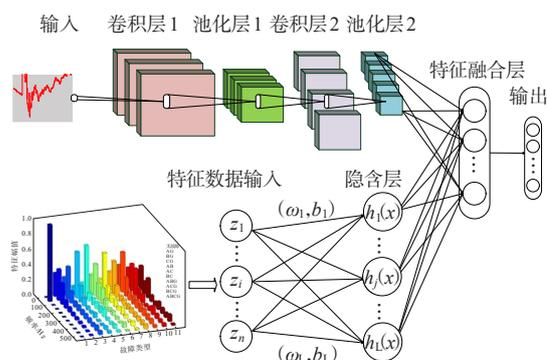


图1 并行神经网络模型结构

Figure 1 Structure of parallel neural network model

并行神经网络的输出通过归一化指数函数实现。与ELM不同的是,CNN需要以反向传播的方式对网络参数进行更新,所以训练网络时,归一化指数函数的损失值将传递到CNN中,模型流程如图2所示。

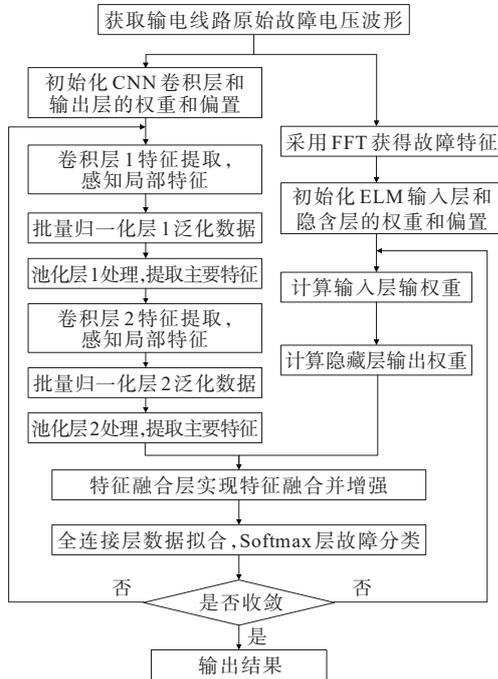


图 2 基于并行神经网络模型的输电线路故障识别与定位
 Figure 2 Fault identification and location of transmission lines based on parallel neural network model

4 实验分析

本文通过 Simulink 建立 110 kV 输电线路仿真模型,线路长度为 100 km,其他参数参考文献[22],对不同情况下的故障进行仿真,其仿真模型如图 3 所示。

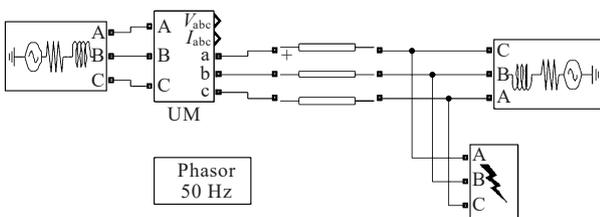


图 3 110 kV 输电线路故障仿真
 Figure 3 Simulation diagram of 110 kV transmission lines with fault

4.1 实验数据获取

为验证所提方法的普适性和有效性,本文对故障点位置、故障类型、过渡电阻和故障相角 4 个参数进行改变,故障点位置的设置步长为 5%,共 20 组;故障类型为 10 种;过渡电阻的变化范围是 1~600 Ω,步长为 30 Ω,共 30 组;故障相角的变化范围为 0°~360°,步长为 30°,共 11 组。此外,本文对无故障发生也进行仿真,电源相角的变化范围为 -15°~15°,步长为 1°,共 30 组。综上获得 66 000 组故障数据和

31 组无故障数据,故障参数设置如表 1 所示。

表 1 输电线路故障参数设置
 Table 1 Fault parameters of transmission lines

类型	单位	变化范围	数量
故障位置	%	1,5,10,⋯,95,99	20
故障类型		AG,BG,CG,ABG,⋯,ABCG	10
过渡电阻	Ω	1,30,60,90,⋯,600	30
故障相角	(°)	0,30,60,⋯,330	11

4.2 卷积神经网络结构参数

本文使用的 CNN 包括 2 个卷积层、2 个池化层和 1 个全连接层。2 个卷积层的卷积核大小为 2×2,卷积核个数分别为 16、24 个,池化层的池化窗口大小为 2×2,步长为 2,2 个全连接层的神经元个数分别为 120 和 150。最后通过 softmax 输出了 10 个分类结果。

4.3 FFT 电压特征提取

为验证 FFT 对故障特征提取的有效性,以故障位置在 20% 处、过渡电阻为 1 Ω、故障相角为 30°为例,10 种故障和无故障的归一化特征提取结果如图 4 所示。

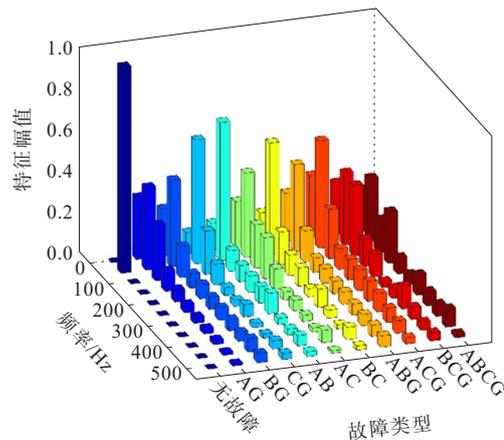


图 4 不同故障类型的 FFT 特征提取结果
 Figure 4 Feature extraction results of FFT under different fault types

由图 4 可知,部分故障特征存在一定相似性,例如 AG 故障和 BG 故障在 0~200 Hz 的特征幅值及波动情况类似。但整体而言不同故障类型的故障电压特征具有明显差异,可为 ELM 故障分类提供更可靠的特征数据。

进一步地,以 A 相接地故障、过渡电阻为 1 Ω、故障相角为 30°为例,当故障发生在线路不同位置时,FFT 特征提取结果如图 5 所示。

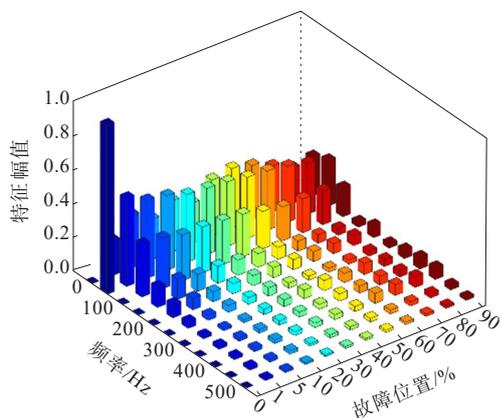


图5 不同故障位置的FFT特征提取结果

Figure 5 Feature extraction results of FFT under different fault locations

由图5可知,当同一故障类型发生在不同位置时,其特征的总体变化规律具有一定相似性。差异主要源自不同频段分量传播速度不同,对比可知,故障位置越近,在低频段的分量越高,这是由于低频分量的传播速度较慢,距离越远,传播时间较长,能获取的暂态信号较少;故障位置越远,在高频段的分量相对较高,这是由于高频分量的传播速度较快,且在远距离传播过程中,遇到波阻抗发生折射和反射,生成了新的高频分量叠加。

4.4 故障识别结果分析

通过文4.1仿真所获得大量故障数据,随机抽取每种故障类型的10%作为测试集,另外选取10%的无故障数据作为测试集,其他90%的故障数据和无故障数据作为训练集。基于本文所提方法的识别准确率如表2。

表2 不同故障类型的故障识别准确率

Table 2 Fault identification accuracy under different fault types

故障类型	准确率/%	故障类型	准确率/%
无故障	100.00	BC	100.00
AG	100.00	ABG	100.00
BG	99.85	ACG	99.85
CG	100.00	BCG	100.00
AB	100.00	ABCG	100.00
AC	99.85		

由表2可知,本文所提方法的平均识别准确率达到99.95%。测试集中共6603个样本,有3个样本识别错误,分别是BG故障、AC故障和ACG故障,由图3可知,这3类故障与其他故障存在一定相似特征。

为进一步验证本文所提故障识别方法的有效性,利用CNN、ELM、FFT-ELM、变分模态分解(variational mode decomposition, VMD)-ELM和支持向量机(support vector machine, SVM)7种方法与本文所提方法对比,其中CNN和ELM网络设置相同的网络参数,实验数据相同。对比结果见表3。

由表3可知,本文所提的并行神经网络故障识别模型,既保留了原始数据的直接输入,同时采用FFT进行故障特征提取避免干扰信号对网络的影响,相比VMD特征提取,FFT对电压波形的特征提取更强。在单一神经网络中,CNN具有较高的识别准确率,识别错误的样本数为182个,这是由于CNN为深度学习网络,网络的特征提取能力较浅层神经网络更强,相比同为深度学习的循环神经网络(recurrent neural network, RNN),CNN对电压波形图像的特征提取能力更强;并行神经网络故障识别准确率优于单一模型,这是由于并行神经网络可以同时独立学习不同的特征表示,从而提高模型的表达力、提高整体模型的识别性能;同时,通过分解法提取的频谱信息能够得到输电线路原始故障数据更直接有效的规律,避免无关信息对神经网络的干扰,能够提升识别准确率,在6603个测试样本中,错误识别的样本数均低于150个,识别准确率超过98%。

表3 不同识别方法的故障类型识别准确率对比

Table 3 Accuracy comparison of fault type identification methods

识别方法	平均准确率/%	错误识别数量
CNN	97.24	182
ELM	95.70	364
SVM	94.49	284
RNN	96.67	200
FFT-ELM	98.56	95
VMD-ELM	98.14	123
ELM-CNN并行	98.85	69
本文方法	99.95	3

4.5 故障定位结果分析

不同故障点的电压波形会发生异常变化,故可以采用神经网络学习训练进行故障定位。通过文4.1仿真所获得的大量故障数据作为训练集,再随机生成50个故障位置点作为测试集。利用CNN、ELM、FFT-ELM、VMD-ELM和SVM5种方法与本文所提方法对比,其中CNN和ELM网络设置相同的网络参数,实验数据相同。对比结果见表4。

表4 不同识别方法的故障定位误差对比

Table 4 Comparison of fault location errors with different identification methods

定位方法	平均误差/m	最大误差/m	最小误差/m
CNN	943.4	1 212.3	343.7
ELM	1 521.7	2 865.6	504.2
SVM	1 376.6	1 576.4	467.7
RNN	1 078.4	1 663.5	391.8
FFT-ELM	669.5	954.8	195.9
VMD-ELM	793.7	1 276.5	325.3
ELM-CNN并行	467.5	849.1	211.7
本文方法	263.5	486.5	92.3

由表4可知,本文所提方法故障定位误差在500 m以内,平均误差为263.5 m,最小定位误差为92.3 m,可靠性优于其他模型。这是由于单一神经网络难以全面地学习原始数据的特征,本文采用了FFT特征提取技术和不同深度神经网络模型组合,充分发挥各自的优势,融合2种方法的优点,能够从原始数据中学习到更高级的抽象特征,提高了故障定位的准确性和鲁棒性。

5 结语

输电线路故障的准确识别和定位有利于提高电力系统的可靠性,为此本文提出了一种基于并行CNN和FFT-ELM的输电线路故障检测和定位方法。采用CNN对原始故障图像进行识别,此外利用FFT提取故障特征,利用ELM根据故障特征进行故障识别,最后构造特征融合层,采用Softmax函数完成识别结果输出。

1) 采用FFT进行特征提取可以从原始故障电压数据中提取到更高级的抽象特征,提高浅层神经网络的输出准确性,相比VMD进行特征提取,FFT对电压波形的特征提取更强。

2) 融合2种不同深度学习网络的特点,可以充分发挥2种神经网络的优势,完成故障识别和定位结果的输出。

根据实验分析,本文所提方法故障识别准确率达99.95%,故障定位最大误差为486.5 m,优于传统方法,验证了本文所提方法的有效性。

实际输电线路故障受到多种因素影响,如天气、负载变化等,这些因素可能导致数据的变化和噪声,因此如何提高模型对于这些干扰的鲁棒性也是未来需要探索的问题。

参考文献:

- [1] 周劫英,张骁,邵立嵩,等.面向高比例新能源的新型电力系统网络安全防护挑战与展望[J/OL].电力系统自动化:1-10[2023-03-14].<http://kns.cnki.net/kcms/detail/32.1180.TP.20230310.1123.002.html>.
ZHOU Jieying, ZHANG Xiao, SHAO Lisong, et al. Challenges and prospects for cyber security protection of a new power system facing high proportion of new energy[J/OL]. Automation of Electric Power Systems: 1-10[2023-03-14].<http://kns.cnki.net/kcms/detail/32.1180.TP.20230310.1123.002.html>.
- [2] 夏中原,李威,兰光宇,等.某220 kV GIS母线跳闸故障分析与处理[J].高压电器,2023,59(6):223-228.
XIA Zhongyuan, LI Wei, LAN Guangyu, et al. Analysis and treatment on busbar trip of 220 kV GIS[J]. High Voltage Apparatus, 2023, 59(6): 223-228.
- [3] 余建宁,江波,唐玲,等.一种三芯电缆状态在线监测与短路故障定位方法的研究[J].智慧电力,2023,51(11):91-97+105.
SHE Jianning, JIANG Bo, TANG Ling, et al. Method for on-line monitoring and short-circuit fault location of three-core cables[J]. Smart Power, 2023, 51(11): 91-97+105.
- [4] 王尧,马桐桐,赵宇初,等.基于电磁辐射时延估计的串联光伏直流电弧故障定位方法[J].电工技术学报,2023,38(8):2233-2243.
WANG Yao, MA Tongtong, ZHAO Yuchu, et al. Series DC arc-fault location method based on electromagnetic radiation delay estimation for photovoltaic systems[J]. Transactions of China Electrotechnical Society, 2023, 38(8): 2233-2243.
- [5] 陈晓龙,余联课,裴东锋,等.一种基于故障支路判定和迭代计算的单回T型输电线路故障测距新方法[J].电力系统保护与控制,2022,50(20):1-11.
CHEN Xiaolong, YU Lianke, PEI Dongfeng, et al. A new fault location method for single-circuit three-terminal transmission lines based on fault branch determination and iterative calculation[J]. Power System Protection and Control, 2022, 50(20): 1-11.
- [6] 陈池瑶,苗世洪,殷浩然,等.基于注意力机制-卷积神经网络的配电网单相接地故障选线方法[J].电力建设,2023,44(4):82-93.
CHEN Chiyao, MIAO Shihong, YIN Haoran, et al. Single-phase grounding-fault line selection method based on attention mechanism-convolution neural network for distribution network[J]. Electric Power Construction, 2023, 44(4): 82-93.
- [7] 刘健,张志华,张小庆.中性点非有效接地系统单相接地故障处理新技术[J].供用电,2022,39(5):48-53.
LIU Jian, ZHANG Zhihua, ZHANG Xiaoqing. New technology of single-phase grounding fault processing in

- neutral non-effectively grounded systems[J]. *Distribution & Utilization*,2022,39(5):48-53.
- [8] 廖名洋,张文,袁海,等.基于多脉冲注入法的高压直流输电接地极线路故障测距[J]. *电网与清洁能源*,2022,38(9):98-104+111.
LIAO Mingyang,ZHANG Wen,YUAN Hai,et al.A fault location method for HVDC grounding pole line using multi-pulse injection method[J]. *Power System and Clean Energy*,2022,38(9):98-104+111.
- [9] WU H,WANG J,NAN D L,et al.Transmission line fault cause identification method based on transient waveform image and MCNN-LSTM[J]. *Measurement*, 2023, 220: 113422.
- [10] LIU H W, YANG Q, TANG L J, et al. Fault type identification of arc grounding based on time-frequency domain characteristics of zero sequence current[J]. *Electric Power Systems Research*,2023,223:109689.
- [11] 刘志远,于晓军,罗美玲,等.基于CBAM-FCN的高压输电线路发展性故障识别方法[J]. *电网与清洁能源*,2022,38(9):25-33+44.
LIU Zhiyuan, YU Xiaojun, LUO Meiling, et al. An evolved faults identification method of HV transmission lines based on CBAM-FCN[J]. *Power System and Clean Energy*,2022,38(9):25-33+44.
- [12] FAHIM S R, MUYEEN S M, MANNAN M A, et al. Uncertainty awareness in transmission line fault analysis: a deep learning based approach[J]. *Applied Soft Computing*,2022,128:109437.
- [13] 王鑫明,王祥宇,贾晓卜,等.基于小波包分解卷积神经网络的停运输电线路故障识别方法[J/OL]. *电测与仪表*, 2022: 1-7(2022-06-23). <https://kns.cnki.net/kcms/detail/23.1202.TH.20220622.1456.008.html>.
WANG Xinming,WANG Xiangyu,JIA Xiaobo,et al.Fault identification method of outage transmission line based on convolutional neural network and wavelet packet decomposition[J/OL]. *Electrical Measurement & Instrumentation*, 2022: 1-7(2022-06-23). <https://kns.cnki.net/kcms/detail/23.1202.TH.20220622.1456.008.html>.
- [14] AKMAZ D, MAMICS M S, ARKAN M, et al. Transmission line fault location using traveling wave frequencies and extreme learning machine[J]. *Electric Power Systems Research*,2018,155:1-7.
- [15] BIKASH P. Superimposed components of Lissajous pattern based feature extraction for classification and localization of transmission line faults[J]. *Electric Power Systems Research*,2022,215:1-12.
- [16] 赵国亮,陈维江,邓占锋,等.柔性低频交流输电关键技术及应用[J]. *电力系统自动化*,2022,46(15):1-10.
ZHAO Guoliang,CHEN Weijiang,DENG Zhanfeng,et al. Key technologies and application of flexible low-frequency AC transmission[J]. *Automation of Electric Power Systems*,2022,46(15):1-10.
- [17] 吕鹏飞.交直流混联电网下直流输电系统运行面临的挑战及对策[J]. *电网技术*,2022,46(2):503-510.
LÜ Pengfei.Research on HVDC operation characteristics under influence of hybrid AC/DC power grids[J]. *Power System Technology*,2022,46(2):503-510.
- [18] 王彦彪,陈振勇,郭文萍,等.基于双注意力机制优化CNN架构的GIS局部放电模式识别[J]. *电力科学与技术学报*,2022,37(2):22-29.
WANG Yanbiao,CHEN Zhenyong,GUO Wenping,et al. PD pattern recognition for GIS based on CNN architecture optimized by the double attention mechanism[J]. *Journal of Electric Power Science and Technology*,2022,37(2):22-29.
- [19] 杜太行,陈培颖,弭艳芝,等.基于FFT算法的交流电器选相分合闸技术[J]. *电工技术学报*,2003,18(6):80-83+87.
DU Taihang,CHEN Peiying,MI Yanzhi,et al. Technology of phase selection of AC apparatus based on FFT[J]. *Transactions of China Electrotechnical Society*,2003,18(6):80-83+87.
- [20] 龙干,黄媚,方力谦,等.基于改进多元宇宙算法优化ELM的短期电力负荷预测[J]. *电力系统保护与控制*, 2022,50(19):99-106.
LONG Gan,HUANG Mei,FANG Liqian,et al.Short-term power load forecasting based on an improved multi-verse optimizer algorithm optimized extreme learning machine[J]. *Power System Protection and Control*,2022,50(19):99-106.
- [21] YE Q,LIU S H,LIU C H.A deep learning model for fault diagnosis with a deep neural network and feature fusion on multi-channel sensory signals[J]. *Sensors*,2020,20(15): 4300.
- [22] 田鹏飞,于游,董明,等.基于CNN-SVM的高压输电线路故障识别方法[J]. *电力系统保护与控制*,2022,50(13): 119-125.
TIAN Pengfei,YU You,DONG Ming,et al.A CNN-SVM-based fault identification method for high-voltage transmission lines[J]. *Power System Protection and Control*,2022,50(13):119-125.