

DOI: 10.19783/j.cnki.pspc.211196

基于 CNN-SVM 的高压输电线路故障识别方法

田鹏飞¹, 于游¹, 董明², 姜志筠³, 包鹏宇³, 吴国鼎³, 张天东³, 胡钊³

(1. 国网辽宁省电力有限公司, 辽宁 沈阳 110006; 2. 国网大连供电公司, 辽宁 大连 160033;
3. 武汉大学, 湖北 武汉 430072)

摘要: 高压输电线路故障识别对保证电网安全稳定运行具有重要意义。提出了一种基于 CNN-SVM 的高压输电线路故障分段识别方法。针对传统故障识别方法数据特征提取过程复杂的问题, 通过深度学习的 CNN 模型, 将故障特征以时序矩阵形式输入其卷积层与池化层, 从而简化特征提取与计算过程。此外, 针对高压输电线路故障特征不明显导致相间故障识别率较低的问题, 提出将故障相间电流差及非故障相负序与零序分量作为特征, 输入到 SVM 模型, 进而判断相间故障接地类型。仿真结果表明, 所提方法准确率高, 与其他深度学习方法相比, 在相间故障识别的准确率上提升尤为显著。

关键词: 故障识别; 序分量特征提取; CNN; SVM

A CNN-SVM-based fault identification method for high-voltage transmission lines

TIAN Pengfei¹, YU You¹, DONG Ming², JIANG Zhijun³, BAO Pengyu³, WU Guoding³, ZHANG Tiandong³, HU Po³

(1. State Grid Liaoning Electric Power Co., Ltd., Shenyang 110006, China; 2. State Grid Dalian Power Supply Company, Dalian 160033, China; 3. Wuhan University, Wuhan 430072, China)

Abstract: High-voltage transmission line fault identification is of great significance in ensuring the safe and stable operation of a power grid. This paper proposes a high-voltage transmission line fault segmentation method based on CNN-SVM. Given the complex problem of the data feature extraction process of traditional fault recognition methods, the fault features are input into convolutional and pooling layers in the form of a time series matrix through a deep learning CNN model, thereby simplifying the feature extraction and calculation process. In addition, given the problem that the fault characteristics of high-voltage transmission lines are not obvious (leading to a low recognition rate of phase-to-phase faults), it is proposed to take the current difference between the fault phases and the negative and zero sequence components of the non-fault phase as features and input them into the SVM model to determine the type of fault grounding between phases. The simulation results show that the method has a high accuracy rate. Compared with other deep learning methods, the accuracy of phase-to-phase fault recognition is improved significantly.

This work is supported by the National Natural Science Foundation of China (No. 51477121).

Key words: fault identification; sequence component feature extraction; CNN; SVM

0 引言

输电线路故障严重影响电网的安全稳定运行, 因此, 诸多学者对如何准确进行线路故障识别开展了多方面的研究。传统方法通过提取序分量特征, 采用选相元件识别故障类型^[1-2], 文献[3]通过负序差和正序差电流之间的相位关系判断故障类型; 文献[4]利用S变换提取各模量特征, 据此确定故障类型。

传统方法具有计算简单、辨识速度快等优点, 但由于数据提取能力较差, 导致容易受到故障电流、过渡电阻、故障位置等因素干扰, 因而准确性较差。

近年来, 深度学习方法也广泛应用于故障识别, 传统深度学习方法, 如支持向量机(Support Vector Machines, SVM)^[5-8]、人工神经网络^[9-11]、随机森林^[12]等, 能够有效处理特征数据, 拟合非线性映射。文献[13]以希尔伯特黄变换处理数据, 通过SVM进行高压输电线路的故障识别; 文献[14]通过变分经验模态分解处理电流信号, 采用极限学习机

基金项目: 国家自然科学基金项目资助(51477121)

进行高压输电线路故障识别；文献[15]通过随机森林算法对电流故障分量特征进行识别。但这些传统深度学习方法的特征提取能力较弱，故而故障量的特征提取过程较为复杂，并且过度依赖于人为参数设定，通常还需要对分类器进行初始参数寻优，增加了计算的复杂度。因此，人们提出了一些新的深度学习方法，如卷积神经网络(CNN)^[16-20]、深度置信网络^[21-23]等，它们在含图像在内的信号特征提取、非线性拟合等方面具有较大优势，对于故障识别中的多维时序信号，可以依据其特征将其等效为二维图像进行特征提取。文献[24]利用希尔伯特变换和 CNN 进行故障识别，将时序信号以二维矩阵形式输入模型，文献[25]提出了利用小波变换和 CNN 的故障识别方法，但是，这些方法和传统深度学习方法用于识别高压输电线路是否发生相间短路接地故障的准确率较低。因此，本文提出一种基于 CNN-SVM 的高压输电线路故障分段识别方法。利用 CNN 的特征提取优势对故障类型作初步识别，再通过提取故障相间电流差和非故障相负序、零序电流，利用 SVM 模型进一步确定相间故障是否接地，准确识别高压输电线路故障。对比目前常用的输电线路故障识别方法，本文方法准确率高，尤其是在相间故障识别准确率上提升显著。

1 故障识别原理

输电线路故障示意图如图 1 所示。由于高压线路置于大电网中，发生故障时其端电压变化极小，故而仅能从变化的电流中提取故障特征来识别故障类型。当线路发生单相接地故障、三相接地故障时，反映这类故障的电流特征明显；但是当线路发生相间故障时，却难以判别其为接地或不接地故障，尤其是当过渡电阻较高时，易出现误判情况。

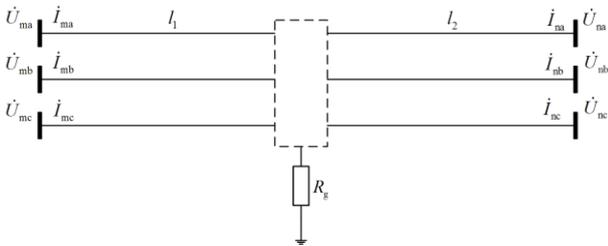


图 1 输电线路故障示意图
Fig. 1 Schematic diagram of transmission line failure

对此，本文提出了一种基于故障相间电流差来识别相间故障的方法。相间故障示意图如图 2 所示。发生相间短路接地故障时会产生对地电流，以图 2(a) 中 AB 相间故障为例，当 AB 相间故障不接地时，根

据基尔霍夫电流定律，流入故障点的线路首端电流 i_{ma} 、 i_{mb} 与末端电流 i_{na} 、 i_{nb} 之和应为零，即

$$i_d = i_{ma} + i_{na} + i_{mb} + i_{nb} = 0 \quad (1)$$

但实际上考虑到杂散电流、分布电容等因素的影响，上述电流之和不会严格等于零而近似为零。

当 AB 相间接地故障时，如图 2(b)所示，将产生较大的对地电流，故障相间电流差 i_d 的值也较大，即

$$i_d = i_{ma} + i_{na} + i_{mb} + i_{nb} \quad (2)$$

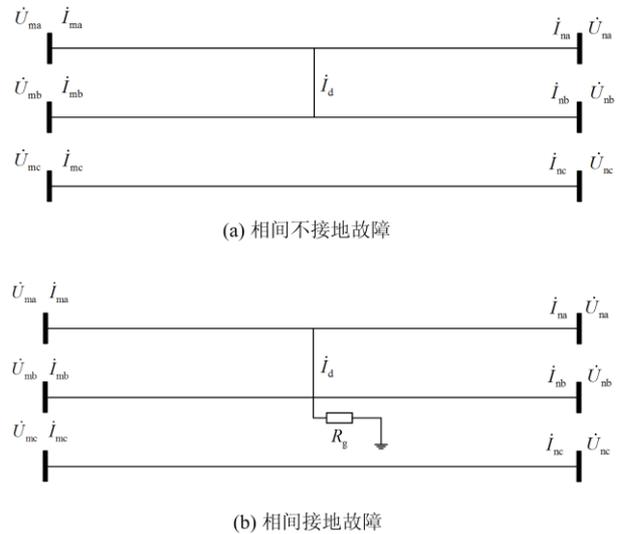


图 2 相间故障示意图

Fig. 2 Schematic diagram of phase-to-phase failure

由于零序和负序电流受线路分布电容电流的影响较小，因此为进一步反映电流的故障特征，本文考虑非故障相电流的序分量，利用它来提高判别的准确性，具体步骤如下述。

当 AB 发生相间故障时，故障点处 C 相的正序电流与负序电流方向相反，而零序电流应为零，即

$$i_{Fc1} = -i_{Fc2} \quad (3)$$

$$i_{Fc0} = 0 \quad (4)$$

当 AB 发生相间接地故障时，故障点处 C 相的电流序分量关系应满足：

$$i_{Fc2} = -\frac{Z_{0\Sigma}}{Z_{2\Sigma} + Z_{0\Sigma}} i_{Fc1} \quad (5)$$

$$i_{Fc0} = -\frac{Z_{2\Sigma}}{Z_{2\Sigma} + Z_{0\Sigma}} i_{Fc1} \quad (6)$$

序分量计算式为

$$i_{a1} = \frac{1}{3}(i_A + \alpha i_B + \alpha^2 i_C) \quad (7)$$

$$\dot{i}_{a2} = \frac{1}{3}(\dot{i}_A + \alpha^2 \dot{i}_B + \alpha \dot{i}_C) \quad (8)$$

$$\dot{i}_{a0} = \frac{1}{3}(\dot{i}_A + \dot{i}_B + \dot{i}_C) \quad (9)$$

式中, $\alpha = e^{j120^\circ}$ 。

2 故障识别方法

2.1 卷积神经网络

卷积神经网络(CNN)是一种特殊的前馈深度学习算法, 具有强大的特征提取能力和非线性运算能力, 可以从原始数据中直接提取其明显特征, 从而能够有效避免传统深度学习需要采取复杂数学方法进行数据特征提取的问题, 其网络结构主要包含输入层、卷积层、池化层、全连接层和输出层, 计算步骤如下所述。

(1) 输入层传播至卷积层

卷积层又称过滤器, 能够通过过滤器对输入数据分块提取特征, 其计算式为

$$a^l = g(a^{l-1} \otimes W^l + b^l) \quad (10)$$

式中: $g(\cdot)$ 为激活函数, 本文采用 ReLU 激活函数; l 为当前网络层数; \otimes 表示卷积运算; a^{l-1} 表示本层输入(上层输出); a^l 表示本层输出; W^l 为本层神经元的权重; b^l 为偏置。

(2) 池化层

池化层的主要作用为对卷积层的输出作进一步特征降维, 再次压缩特征量, 可以有效避免过拟合, 计算式为

$$a^l = \psi(a^{l-1}) \quad (11)$$

式中, 函数 $\psi(\cdot)$ 表示池化运算, 本文所选池化方式为最大池化。

(3) 全连接层

全连接层由多个隐藏层组成, 负责对所提取的特征进行抽象组合, 并将其映射为固定长度的特征向量, 即

$$a^l = g(W^l a^{l-1} + b^l) \quad (12)$$

(4) 输出层

输出层又称分类层, CNN 所使用的 softmax 分类器的分类计算式为

$$y = f(a^{l-1} W^l + b^l) \quad (13)$$

式中: y 为各类别所属概率值, 其最大的类别即为分类器确定的类别; $f(\cdot)$ 为输出层的激活函数, 本文选用 sigmoid 函数。

(5) 损失函数

损失函数表示 CNN 模型拟合的预测值与实际值之间的差异, 用于衡量模型的拟合程度, 本文采用交叉熵损失函数, 对于 n 组样本 $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, 其计算式为

$$L(f(x_i), y_i) = -\frac{1}{n} \sum_{i=1}^n [y_i \ln f(x_i) + (1 - y_i) \ln(1 - f(x_i))] \quad (14)$$

2.2 支持向量机

支持向量机(SVM)是一种基于结构奉献最小化原理的分类算法, 对于非线性的分类问题, 可以通过核函数将数据非线性变换至线性高维空间, 通过计算最优超平面进行分类, 具有所需样本少、分类精度高等优点。对于 n 组样本 $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, 其数学模型为

$$\min \phi(\omega) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^N \xi_i \quad (15)$$

$$\text{s.t. } h(\omega x_i + b) \geq 1 - \xi_i \quad i=1, 2, \dots, n \quad (16)$$

式中: ω 为超平面的法向量; b 为偏差; C 为惩罚因子; ξ_i 为松弛变量。该式可通过拉格朗日函数与对偶原理转化为

$$\max W(\mu) = \sum_{i=1}^N \mu_i - \frac{1}{2} \sum_{i,j=1}^N y_i y_j \mu_i \mu_j K(x_i, x_j) \quad (17)$$

$$\text{s.t. } \begin{cases} \sum_{i=1}^N \mu_i y_i = 0 \\ 0 \leq \mu_i \leq C, \quad i=1, 2, \dots, N \end{cases} \quad (18)$$

式中: μ_i 为拉格朗日乘子; K 为核函数, 本文采用 RBF 核函数进行分类。

3 故障建模与分析

高压线路故障识别具有两个难点, 即电压特征变化不明显以及接地故障与不接地故障容易误识别, 对此, 本文基于故障相间电流差和 CNN-SVM 提出了建立高压线路故障识别模型的方法, 如图 3 所示, 其步骤如下所述。

(1) 数据获取与归一化

建立线路模型, 模拟不同故障类型、故障位置、过渡电阻、故障相角时线路故障, 采集故障发生后一个周期内的三相双端电流故障信号, 而后对各类数据均进行归一化, 即

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (19)$$

式中: x' 表示归一化后的数据; x 表示原始数据; x_{\max} 表示原始数据的最大值; x_{\min} 表示原始数据的最小值。

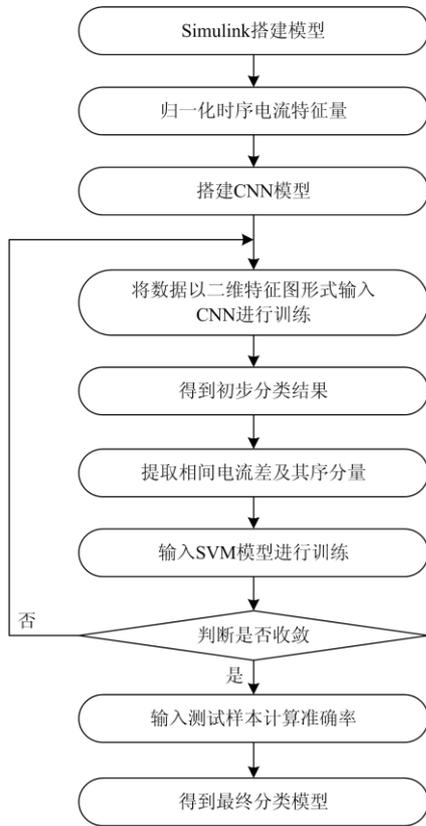


图3 故障建模流程
Fig. 3 Fault modeling chart

(2) CNN 识别

从归一化后的双端三相故障电流数据中随机抽取 70%，并截取故障发生后一个周期的数据，将其代入 CNN 模型作为输入，以 10 种故障类型作为训练输出进行训练。

(3) 采用 SVM 判断故障是否接地

对上述相间故障类型，依据式(1)一式(5)计算其相间电流差并提取非故障相的负序电流与零序电流，将相间电流差及非故障相负序、零序电流作为 SVM 模型的输入，并将接地和不接地作为 SVM 模型的分类型输出来进行训练。

(4) 模型测试与对比分析

通过测试剩余 30%的数据，并与目前常用的希尔伯特黄变换-支持向量机(HHT-SVM)、变分模态分解-极限学习机(VMD-ELM)、希尔伯特黄变换-卷积神经网络(HHT-CNN)、离散小波变换-卷积神经网络(DWT-CNN)等识别方法进行对比分析，验证模型的准确性。

4 仿真结果

本文基于 Simulink 对故障进行建模，如图 4 所

示。设定电压等级为 220 kV，两端电压相角差为 20°，频率为 50 Hz，线路长度为 200 km，单位长度电阻为 0.053 Ω/km，单位长度电感为 9.773×10⁻⁴ H/km，单位长度电容为 1.27×10⁻⁸ F/km，母线处对地杂散电容设为 0.01 μF。

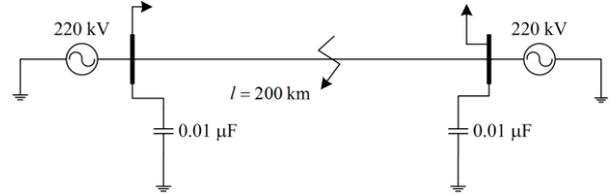


图4 故障模型
Fig. 4 Fault model

(1) 训练数据获取

本文基于 Simulink 做了大量仿真实验，对不同故障位置、故障类型、故障相角、过渡电阻下所测得的故障电流进行了对比分析，最终选定故障位置的步长为线路长度的 10%，共 11 组；故障类型共 10 组；故障相角范围为 0°~360°，以 20°为步长，共 19 组；过渡电阻选定范围为 1~1001 Ω，在 1~300 Ω时以 20 Ω为步长，在 300~1001 Ω时以 50 Ω为步长，共 30 组，据此一共可得 62 700 组实验数据，如表 1 所示。

表 1 故障参数设置

Table 1 Fault parameter settings

参数类型	参数范围	数量
故障位置	1%,10%,20%,...,90%,99%	11
故障相角	0,20,40,...,340,360	19
过渡电阻	1,21,41,...,301,351,...,1001	30
故障类型	AG,BG,CG,...,ABCG	10

(2) CNN 初步识别

设定仿真采样间隔为 0.000 2 s，以故障位置为 1%处、故障相角为 0°、过渡电阻为 1 Ω时的 A 相故障为例，采集故障波形所对应的时序图如图 5 所示，将时序图转化为二维图像形式输入，通过 CNN 的卷积层、池化层对输入的矩阵数值分块处理。

CNN 参数设置如下：卷积核大小为 3×10，数量为 32 个，池化层大小为 2×2，采用最大池化原则，随机抽取 70%的数据进行训练，再输入剩余 30%的数据进行测试，得到初步识别结果如图 6 所示。其中故障类型 1~10 依次对应故障类型 AG、BG、CG、AB、BC、AC、ABG、BCG、ACG、ABCG。对图 6 中的分类结果利用准确率计算方法进行计算，便可得到故障识别准确率，如表 2 所示。

表 2 CNN 初步故障识别准确率

Table 2 CNN preliminary recognition accuracy

故障类型	AG	BG	CG	AB	BC	AC	ABG	BCG	ACG	ABCG
初步识别准确率/%	100	100	100	89.79	100	78.13	94.62	79.38	89.21	100

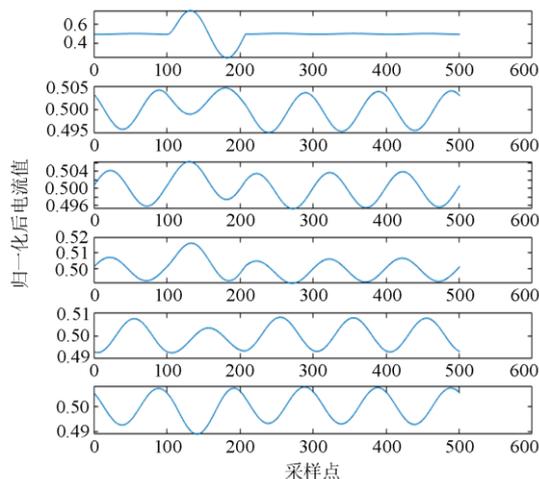


图 5 输入数据波形图

Fig. 5 Input data waveform

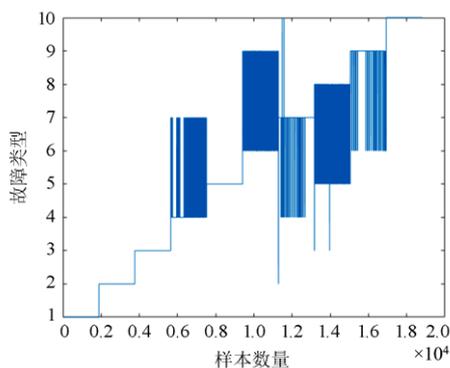


图 6 CNN 初步识别结果

Fig. 6 CNN preliminary recognition results

由图 6 和表 2 可知, 单相故障与三相接地故障识别的准确率很高, A、B、C 相接地故障识别准确率均为 100%, 但相间故障与相间接地故障出现了混淆, 这表明初步识别对于相间故障与相间接地故障的识别率较低, 需要通过步骤(3)和步骤(4)作进一步判别。

表 4 本文方法与 HHT-SVM、VMD-ELM 故障识别准确率对比

Table 4 Fault recognition accuracy comparison of the method in this paper with HHT-SVM and VMD-ELM

识别方法	AG	BG	CG	AB	BC	AC	ABG	BCG	ACG	ABCG
本文方法	100	100	100	99.87	100	99.70	99.97	100	100	100
HHT-SVM	100	100	100	87.71	94.11	87.32	84.97	84.41	82.37	99.40
VMD-ELM	100	99.73	99.48	81.20	92.27	88.04	89.60	91.21	84.36	99.25
HHT-CNN	100	100	100	94.53	92.91	89.11	95.41	87.43	87.48	100
DWT-CNN	96.42	100	100	95.68	94.67	92.75	94.89	87.35	84.66	100

(3) 计算相间电流差并提取负序、零序电流
基于由 CNN 所得的发生相间故障的故障相, 根据式(1)、式(2)计算相间电流差, 再通过式(3)一式(9)计算非故障相负序与零序电流。

(4) 利用 SVM 判别相间故障是否接地

以相间电流差和非故障相负序、零序电流作为故障特征, 利用 SVM 判别相间故障是否接地, 各相间接地与不接地故障识别准确率如表 3 所示。

表 3 各相间接地与不接地故障识别准确率

Table 3 Recognition accuracy rate of indirect and non-ground faults of each phase

故障类型	AB	BC	AC	ABG	BCG	ACG
准确率/%	99.87	100	99.70	99.97	100	100

将利用 SVM 后判别相间接地与不接地故障的准确率与之前的结果进行对比, 如图 7 所示。

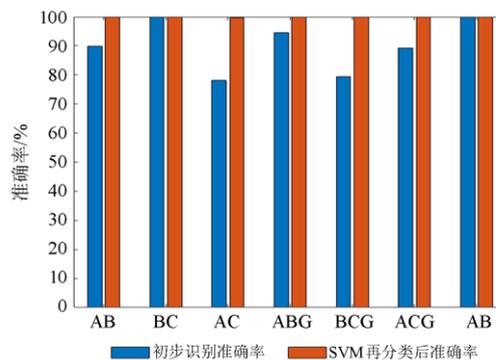


图 7 相间故障识别准确率对比

Fig. 7 Comparison of the accuracy of phase-to-phase fault recognition

本文所提方法与目前较常用于高压输电线路故障识别的深度学习 HHT-SVM、VMD-ELM 以及用于故障识别、新近的深度学习 HHT-CNN、DWT-CNN 的对比结果如表 4 所示, 可以看出, 本文

所提方法准确率较高,特别是对于相间故障的识别准确率更高。例如对于 AB 相间故障,本文方法准确率为 99.88%, HHT-SVM 准确率为 87.71%, VMD-ELM 准确率为 81.20%, HHT-CNN 准确率为 94.53%, DWT-CNN 准确率为 95.68%。

5 结论

针对传统故障识别方法提取故障特征方法复杂而准确率不高的问题,本文提出了一种基于相间电流差和 CNN-SVM 的高压输电线路故障识别方法。

(1) 采用 CNN 模型针对二维时序数据进行学习,利用 CNN 模型强大的特征提取能力,从而避免了特征提取方法过于复杂的问题;

(2) 提出了一种分段识别法,即针对高压线路相间故障识别准确率较低,难以区分的问题,在采用 CNN 初步判别故障类型的基础上,再通过相间电流差及非故障相的负序、零序分量并利用 SVM 判别相间故障是否接地来有效识别高压输电线路故障;

(3) 对比目前常用的识别方法,本文方法故障识别准确率较高,尤其是在相间故障识别准确率上提升显著。

参考文献

- [1] 陈朝晖,黄少锋,陶惠良,等. 新型阻抗选相方法[J]. 电力系统自动化, 2005, 29(3): 51-56.
CHEN Zhaohui, HUANG Shaofeng, TAO Huiliang, et al. Research on the new phase selector based on impedance measurement[J]. Automation of Electric Power Systems, 2005, 29(3): 51-56.
- [2] 程志友,李小静,汤明金,等. 一种故障分量选相元件接地短路判据的修正[J]. 电力系统保护与控制, 2018, 46(16): 19-24.
CHENG Zhiyou, LI Xiaojing, TANG Mingjin, et al. A correction of ground short-circuit criterion of phase selection element based on faulty components[J]. Power System Protection and Control, 2018, 46(16): 19-24.
- [3] 刘凯,索南加乐. 基于故障支路电流序分量相位关系的选相元件[J]. 电力自动化设备, 2013, 33(3): 77-83.
LIU Kai, SUONAN Jiale. Phase selection element based on phase relationship between sequence components of faulty branch current[J]. Electric Power Automation Equipment, 2013, 33(3): 77-83.
- [4] 刘栋,邹贵彬,王昕,等. 基于 S 变换的输电线路故障快速选相方法[J]. 电网技术, 2015, 39(12): 3603-3608.
LIU Dong, ZOU Guibin, WANG Xin, et al. A fast faulty phase selection method based on S-Transform[J]. Power System Technology, 2015, 39(12): 3603-3608.
- [5] 张鑫,徐遵义,何慧茹,等. 基于 RBM 和 SVM 的风电机组叶片开裂故障预测[J]. 电力系统保护与控制, 2020, 48(15): 134-140.
ZHANG Xin, XU Zunyi, HE Huiru, et al. Wind turbine blade cracking fault prediction based on RBM and SVM[J]. Power System Protection and Control, 2020, 48(15): 134-140.
- [6] 谢国民,倪乐水. 基于 IABC 优化 SVM 的变压器故障诊断[J]. 电力系统保护与控制, 2020, 48(15): 156-163.
XIE Guomin, NI Leshui. Transformer fault diagnosis based on an artificial bee colony-support vector machine optimization algorithm[J]. Power System Protection and Control, 2020, 48(15): 156-163.
- [7] 贾志成,张智晟,刘远龙,等. 基于 RS-SVM 算法的配电网故障诊断方法[J]. 广东电力, 2019, 32(9): 107-114.
JIA Zhicheng, ZHANG Zhisheng, LIU Yuanlong, et al. Fault diagnosis method based on RS-SVM algorithm for power distribution network[J]. Guangdong Electric Power, 2019, 32(9): 107-114.
- [8] EL-SAADAWI M, HATATA A. A novel protection scheme for synchronous generator stator windings based on SVM[J]. Protection and Control of Modern Power Systems, 2017, 2(3): 257-268.
- [9] 阮羚,谢齐家,高胜友,等. 神经网络和信息融合技术在变压器状态评估中的应用[J]. 高电压技术, 2014, 40(3): 822-828.
RUAN Ling, XIE Qijia, GAO Shengyou, et al. Application of artificial neural network and information fusion technology in power transformer condition assessment[J]. High Voltage Engineering, 2014, 40(3): 822-828.
- [10] 李龙,魏靖,黎灿兵,等. 基于人工神经网络的负荷模型预测[J]. 电工技术学报, 2015, 30(8): 225-230.
LI Long, WEI Jing, LI Canbing, et al. Prediction of load model based on artificial neural network[J]. Transactions of China Electrotechnical Society, 2015, 30(8): 225-230.
- [11] 邹京希,曹敏,董立军,等. 基于总体测辨和人工神经网络的负荷建模及预测方法[J]. 电力系统及其自动化学报, 2018, 30(8): 108-112.
ZOU Jingxi, CAO Min, DONG Lijun, et al. Load modeling and forecasting method considering measurement-based method and artificial neural network[J]. Proceedings of the CSU-EPSCA, 2018, 30(8): 108-112.
- [12] 王毅,陈进,李松浓,等. 基于时频域分析和随机森林的故障电弧检测[J]. 电子测量与仪器学报, 2021, 35(5): 62-68.
WANG Yi, CHEN Jin, LI Songnong, et al. Arc fault detection based on time and frequency analysis and random forest[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(5): 62-68.

- [13] 李力欣. 高压输电线路的故障识别与测距方法研究[D]. 天津: 天津理工大学, 2021.
LI Lixin. Research on fault recognition and location method of high voltage transmission line[D]. Tianjin: Tianjin University of Technology, 2021.
- [14] 肖贤, 周步祥, 林楠, 等. 结合 H-S 变换和 BSVM 的高压输电线路故障识别[J]. 电力系统及其自动化学报, 2015, 27(2): 70-76.
XIAO Xian, ZHOU Buxiang, LIN Nan, et al. High-voltage transmission line fault identification based on the hyperbolic S-transform and multiple BSVM[J]. Proceedings of the CSU-EPSA, 2015, 27(2): 70-76.
- [15] 杨杰, 吴浩, 董星星, 等. 基于电流故障分量特征和随机森林的输电线路故障类型识别[J]. 电力系统保护与控制, 2021, 49(13): 53-63.
YANG Jie, WU Hao, DONG Xingxing, et al. Transmission line fault type identification based on the characteristics of current fault components and random forest[J]. Power System Protection and Control, 2021, 49(13): 53-63.
- [16] 魏东, 龚庆武, 来文青, 等. 基于卷积神经网络的输电线路区内外故障判断及故障选相方法研究[J]. 中国电机工程学报, 2016, 36(增刊 1): 21-28.
WEI Dong, GONG Qingwu, LAI Wenqing, et al. Research on internal and external fault diagnosis and fault-selection of transmission line based on convolutional neural network[J]. Proceedings of the CSEE, 2016, 36(S1): 21-28.
- [17] 汪颖, 孙建风, 肖先勇, 等. 基于优化卷积神经网络的电缆早期故障分类识别[J]. 电力系统保护与控制, 2020, 48(7): 10-18.
WANG Ying, SUN Jianfeng, XIAO Xianyong, et al. Cable incipient fault classification and identification based on optimized convolution neural network[J]. Power System Protection and Control, 2020, 48(7): 10-18.
- [18] 张大海, 张晓炜, 孙浩, 等. 基于卷积神经网络的交直流输电系统故障诊断[J/OL]. 电力系统自动化: 1-14 [2021-11-29]. <http://kns.cnki.net/kcms/detail/32.1180.TP.20211027.1549.004.html>.
ZHANG Dahai, ZHANG Xiaowei, SUN Hao, et al. Fault diagnosis method for AC-DC hybrid transmission system based on convolutional neural network[J/OL]. Automation of Electric Power Systems: 1-14[2021-11-29]. <http://kns.cnki.net/kcms/detail/32.1180.TP.20211027.1549.004.html>.
- [19] 徐浩, 刘利强, 吕超. 基于迁移学习的配电网内部过电压识别方法[J]. 中国电力, 2021, 54(8): 52-59.
XU Hao, LIU Liqiang, LÜ Chao. An internal overvoltage identification method for distribution network based on transfer learning[J]. Electric Power, 2021, 54(8): 52-59.
- [20] 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.
- [21] 赵光权, 葛强强, 刘小勇, 等. 基于 DBN 的故障特征提取及诊断方法研究[J]. 仪器仪表学报, 2016, 37(9): 1946-1953.
ZHAO Guangquan, GE Qiangqiang, LIU Xiaoyong, et al. Fault feature extraction and diagnosis method based on deep belief network[J]. Chinese Journal of Scientific Instrument, 2016, 37(9): 1946-1953.
- [22] 孔祥玉, 郑锋, 鄂志君, 等. 基于深度信念网络的短期负荷预测方法[J]. 电力系统自动化, 2018, 42(5): 133-139.
KONG Xiangyu, ZHENG Feng, E Zhijun, et al. Short-term load forecasting based on deep belief network[J]. Automation of Electric Power Systems, 2018, 42(5): 133-139.
- [23] 张然, 郭俊宏, 蓝新斌, 等. 基于深度置信网络的电能质量扰动检测与分类[J]. 广东电力, 2020, 33(6): 92-98.
ZHANG Ran, GUO Junhong, LAN Xinbin, et al. Power quality disturbance detection and classification based on deep belief network[J]. Guangdong Electric Power, 2020, 33(6): 92-98.
- [24] GUO M, YANG N, CHEN W. Deep-learning-based fault classification using Hilbert-Huang transform and convolutional neural network in power distribution systems[J]. IEEE Sensors Journal, 2019, 19(16): 6905-6913.
- [25] 陈仁祥, 黄鑫, 杨黎霞, 等. 基于卷积神经网络和离散小波变换的滚动轴承故障诊断[J]. 振动工程学报, 2018, 31(5): 883-891.
CHEN Renxiang, HUANG Xin, YANG Lixia, et al. Rolling bearing fault identification based on convolution neural network and discrete wavelet transform[J]. Journal of Vibration Engineering, 2018, 31(5): 883-891.

收稿日期: 2021-08-30; 修回日期: 2021-11-30

作者简介:

田鹏飞(1979—), 男, 硕士, 高级工程师, 从事继电保护相关工作; E-mail: tian_pengfei@126.com

于游(1975—), 男, 硕士, 高级工程师, 从事继电保护相关工作; E-mail: yuyou999@163.com

董明(1987—), 男, 硕士, 高级工程师, 从事继电保护相关工作。E-mail: dongming.ee@gmail.com

(编辑 魏小丽)