

基于S变换相关度和深度学习的配电网 单相接地故障选线新方法

殷浩然^{1,2}, 苗世洪^{1,2}, 郭舒毓^{1,2}, 韩 佶^{1,2}, 王子欣^{1,2}

(1. 华中科技大学 电气与电子工程学院 强电磁工程与新技术国家重点实验室, 湖北 武汉 430074;

2. 华中科技大学 电气与电子工程学院 电力安全与高效湖北省重点实验室, 湖北 武汉 430074)

摘要:针对配电网发生单相接地故障时特征信息不明显,且现有选线方法易受故障条件和环境噪声影响的问题,基于S变换相关度和深度学习,提出一种具有强抗噪声能力和高泛化水平的配电网单相接地故障选线新方法。首先,利用S变换获取零序电流时频信息,基于各线路零序电流的全频段信息计算线路故障信息相关度;其次,为提高故障特征的可辨识度和抗干扰性,提出一种S变换相关度图形(SCF)构建方法;在此基础上,建立含SCF层的卷积神经网络深度学习模型(S-CNN),并利用Simulink仿真模型生成的故障数据对其结构参数和超参数进行分步训练;最后,通过S-CNN提取配电网故障零序电流深层特征,实现故障选线,并测试了S-CNN在配电网不同运行状况和故障条件下的选线效果。仿真结果和实际配电网故障数据测试表明:在强噪声干扰场景中,基于S-CNN的故障选线模型在不同故障位置、故障相角、过渡电阻条件下可实现高正确率选线,且在各线路零序电流采样不同步条件下仍具有较强的鲁棒性。

关键词:配电网;故障选线;深度学习;S变换;卷积神经网络

中图分类号:TM 773

文献标志码:A

DOI:10.16081/j.epae.202105028

0 引言

我国配电网一般采用小电流接地方式,即中性点不接地或经消弧线圈接地,且单相接地故障占故障总数的80%以上^[1]。当配电网发生单相接地故障时,线电压仍保持对称,且故障电流较小,因此规程规定系统可继续运行1~2 h,但非故障相的相电压会增大为原来的 $\sqrt{3}$ 倍,使设备运行在过电压下。若不及时切除故障线路,易引发电力设备绝缘击穿^[2],还可能引起两点或多点接地短路故障^[3],导致故障范围扩大和故障性质劣化,带来较大的安全隐患。因此,必须及时识别故障线路并予以切除。

在已有的研究中,配电网故障选线原理主要分为基于稳态信号和基于暂态信号的故障选线2类。由于发生故障时暂态分量幅值更大、突变更明显、信息更丰富^[4],近年来相关研究多倾向于基于暂态信号特征的故障选线方法。已有学者提出直接以零序电流首半波相位作为特征^[5]或利用小波变换WT(Wavelet Transform)^[6]、希尔伯特-黄变换^[7]、动态时间弯曲距离^[8]、S变换^[9-10]等数学方法提取暂态电流的能量、相位、信息熵等信息作为特征,并基于聚类算法、负选择算法、支持向量机(SVM)等智能分类算

法对故障线路进行识别。文献[11]根据故障线路与非故障线路的零序电流特征的差异,基于改进动态时间弯曲距离计算发生故障后各线路零序电流的相关度,并利用模糊C均值聚类FCM(Fuzzy C-Means clustering)算法筛选出故障线路,但该方法直接基于零序电流时序数据计算相关度,对零序电流的测量准确度和数据质量要求很高,抗噪声干扰能力有限;文献[12]采用小波包对故障期间的暂态电流进行多分辨分析,确定特征频带,并计算各线路特征频带内零模电流的多刻度形态谱,据此判断故障线路,但该方法仅选取能量较大的频带作为选线特征,难以应对实际工程中可能存在的特定频段干扰;文献[13]利用S变换提取零序电流的幅值和相位信息,并基于幅值和相位信息判别故障线路,但其仅以单个频带信息作为判别依据,且未考虑线路类型差异的影响;文献[14]利用经验模态分解EMD(Empirical Mode Decomposition)提取零序电流的高频分量,基于故障线路与非故障线路的零序电流高频分量之间的相关度识别故障线路,由于判据的单一性,该方法的识别效果易受配电网运行条件和环境干扰的影响。综合上述研究可见,已有的故障选线方法多以零序电流或其特定频带信息作为故障特征,抗噪声能力较差,难以应对复杂的运行环境和故障条件,限制了其在实际工程中的应用。因此,为实现具有强抗噪声能力和强泛化能力的故障选线方法,需进一步改进故障特征提取方法和选线判据。

深度学习不依赖于人工设计特征提取环节,通

收稿日期:2020-07-28;修回日期:2021-03-27

基金项目:国家电网有限公司总部科技项目(SGHADK00PJJS2000026)

Project supported by the Science and Technology Project of Headquarters of State Grid Corporation of China (SGHADK00PJJS2000026)

过海量数据训练,构建深层神经网络,自动提取输入数据特征并进行归纳分类^[15],近年来受到了学者的广泛关注^[16]。目前,已有学者将深度学习算法应用于输电线路故障选相^[17]、区内外故障判别^[18]、配电网故障线路判定^[19]和故障定位^[20]等问题,并取得了良好的效果,但将深度学习应用于配电网故障选线的相关研究还很少。卷积神经网络 CNN(Convolutional Neural Network)作为一种深度学习模型,具有强大的深层特征提取能力,通过构建深层卷积神经网络模型,可以学习故障数据中的隐含特征与故障线路间的映射关系,有助于提高配电网故障选线方法的抗噪声能力和泛化能力。因此,本文提出一种基于S变换相关度和深度学习的配电网单相接地故障选线方法。通过构建S变换相关度图形 SCF(S-transform Correlation Figure),将一维零序电流数据构建为二维相关度图形,提升故障特征的可辨识度,并建立含 SCF 层的卷积神经网络深度学习模型(S-CNN),通过学习故障期间各线路零序电流的深层特征与故障线路之间的映射关系,实现故障线路的精确识别。仿真结果和实际配电网数据测试结果表明:S-CNN 的故障选线效果不受系统运行状况和故障条件的影响,且在强噪声干扰和采样不同步的条件下具有较强的鲁棒性。

1 配电网单相接地故障特征

1.1 配电网单相接地故障下的零序电流特征分析

配电网发生单相接地故障时,零序电流存在明显的暂态过程,本文以图 1 所示的谐振接地系统为例分析配电网单相接地故障下的零序电流特征。图中,母线共有 n 条出线,线路 L_1 发生单相接地故障; $u_{(0)}$ 为母线处的零序电压; $u_{f(0)}$ 、 $i_{f(0)}$ 分别为故障点等值零序电压、零序电流; $i_{f1(0)}$ 为故障线路 L_1 的首端暂态零序电流; $i_{fj(0)}$ ($j=2,3,\dots,n$) 为非故障线路 L_j 的首端暂态零序电流; $i_{n(0)}$ 为消弧线圈电感暂态零序电流。

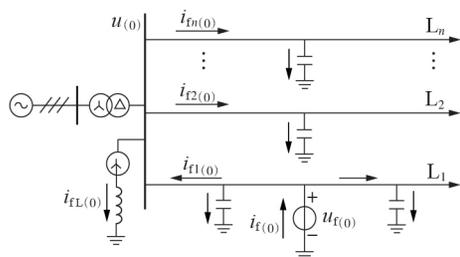


图 1 谐振接地系统发生单相接地故障时的零序电流分布

Fig.1 Distribution of zero-sequence current during single-phase grounding fault of resonant grounding system

按照文献[14]中的暂态等效和求解方法,可求得线路 L_1 的首端暂态零序电流 $i_{f1(0)}$ 为:

$$i_{f1(0)} = (I_{Cm} - I_{Lm}) \cos(\omega t + \phi) + I_{Lm} \cos \phi e^{-t/\tau_L} + I_{Cm} \left[\frac{\omega_f}{\omega} \sin \phi \sin(\omega t) - \cos \phi \cos(\omega_f t) \right] e^{-t/\tau_C} \quad (1)$$

其中, I_{Cm} 和 I_{Lm} 分别为电容电流和电感电流的幅值; ω 为工频角频率; ϕ 为故障相角; τ_C 和 τ_L 分别为电容和电感回路的时间常数; $\omega_f = \sqrt{\frac{1}{LC} - \left(\frac{R}{2L}\right)^2}$,为振荡分量的角频率, R 为过渡电阻, L 为消弧线圈电感。

设电流流出母线方向为正方向,则由图 1 可得故障线路与非故障线路的首端零序电流满足:

$$i_{f1(0)} = - \left(i_{n(0)} + \sum_{j=2}^n i_{fj(0)} \right) \quad (2)$$

$$i_{fj(0)} = C_j \frac{du_{(0)}}{dt} \quad j=2,3,\dots,n \quad (3)$$

其中, C_j 为线路 L_j 的等效对地电容。

由式(1)可知,谐振接地系统发生单相接地故障后,故障暂态零序电流由振荡衰减分量、直流衰减分量和工频分量组成,且振荡衰减分量的角频率与线路参数、消弧线圈、过渡电阻有关。由图 1 和式(2)、(3)可知,由于受同一母线零序电压的作用,各非故障线路的零序电流波形基本一致,大小与线路自身的参数相关,因此发生故障时同一母线外接的电缆线路和架空线路的零序电流差异较大;故障线路零序电流的极性与非故障线路零序电流的极性相反,大小等于各非故障线路和消弧线圈的零序电流之和,因此故障线路的零序电流幅值较大。此外,中性点不接地系统不存在电感电流,暂态零序电流中不存在直流衰减分量,其余特征与谐振接地系统相似。因此,本文以各线路的故障零序电流特征和故障线路与非故障线路的零序电流之间的差异性作为配电网单相接地故障故障选线的特征信息。

1.2 零序电流 S 变换特征

S 变换是由连续小波变换和短时傅里叶变换结合发展而来的一种时序信号分析方法,其同时具有短时傅里叶变换处理局部时频信息的能力和小波变换通过改变时间窗的宽度和高度得到不同时频分辨率的优点,且其特征提取量基本不受噪声影响。与小波变换相比,S 变换可随频率变化调整窗函数宽度,从而获得更丰富的时频信息和更强的抗噪声能力^[21-22]。连续时序信号 $x(t)$ 的 S 变换为:

$$S_x(\tau, f) = \int_{-\infty}^{\infty} x(t) w(t - \tau, f) e^{-j2\pi ft} dt \quad (4)$$

$$w(t - \tau, f) = \frac{|f|}{2\pi} e^{-\frac{f^2(\tau-t)^2}{2}} \quad (5)$$

其中, $S_x(\tau, f)$ 为 $x(t)$ 的 S 变换, τ 为高斯窗在时间轴 t 上的位置控制参数, f 为频率; $w(\tau - t, f)$ 为高斯窗函数。

设连续时序信号 $y(t)$ 与 $x(t)$ 的幅值相等、极性

相反,即 $y(t) = -x(t)$,代入式(4)可得 $y(t)$ 的S变换 $S_y(\tau, f)$ 见式(6)。

$$S_y(\tau, f) = -\int_{-\infty}^{\infty} x(t) w(t-\tau, f) e^{-j2\pi ft} dt = -S_x(\tau, f) \quad (6)$$

式(6)表明,对于极性相反的2个时间序列,其S变换的极性也相反。

对于离散时序信号 $x[i](i=0, 1, \dots, N-1)$,其S变换的离散形式为:

$$S_x \left[\frac{k}{f_s}, \frac{hf_s}{N} \right] = \begin{cases} \sum_{k=0}^{N-1} X[h+k] e^{-2\pi^2 k^2 h^2} e^{j2\pi kh/N} & h \neq 0 \\ \frac{1}{N} \sum_{k=0}^{N-1} x[k] & h = 0 \end{cases} \quad (7)$$

其中, $\frac{hf_s}{N}$ 表示频率点, N 为采样点数, h 为整数,考虑采样定理, h 的取值范围为 $0 \sim \frac{N}{2}$; $\frac{k}{f_s}$ 表示时间点, k 为整数且其取值范围为 $0 \sim N-1$, f_s 为离散信号采样频率; $X[h] = \frac{1}{N} \sum_{k=0}^{N-1} x[k] e^{-j2\pi kh/N}$ 。

基于上述分析,利用S变换可以获取配电网单相接地故障期间各线路暂态零序电流的全频段时频信息,且经过S变换求取时频特征后,故障线路与非故障线路的零序电流极性相反的性质能够被保留,有助于增强零序电流中隐含的故障选线特征信息的可辨识度。

2 基于S-CNN的故障选线模型

2.1 SCF

CNN模型为深度学习模型,其具有局部连接、权值共享和空间相关等特性,以及强鲁棒性和容错能力,适用于提取深层数据特征。经典的CNN模型结构包含输入层、隐含层、全连接层和输出层,其特征提取效果受输入层数据特征的可辨识度影响很大。

CNN模型的输入层为二维图形,现有研究多直接对一维时序数据进行采样排列,生成输入层样本矩阵,即构建一维CNN 1D-CNN(one-Dimensional signal based CNN)^[17-18],其应用效果很大程度上取决于原始数据本身的特征的可辨识度。

根据第1节的分析,各线路端口采集的零序电流时间序列包含了配电网的单相接地故障选线特征信息。对于传统的1D-CNN,其输入层样本矩阵构建过程为:首先对各线路的零序电流时序数据进行归一化、采样等预处理,形成零序电流时间序列;然后按照线路编号排列各线路的零序电流时间序列,从而构建输入层样本矩阵。1D-CNN时序样本矩阵构建过程如图2所示(图2仅用于说明,对应的彩图见附录中图A1)。图中, $I_{n1} \sim I_{nm}$ 为对各线路零序电流相量采样后得到的时间序列向量;每个色块表示样本矩阵中的一个元素。

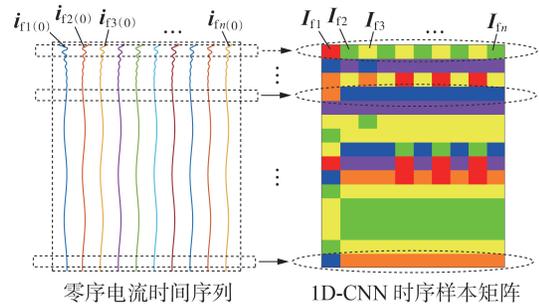


图2 1D-CNN时序样本矩阵构建过程

Fig.2 Construction process of time-series sample matrix for 1D-CNN

经过上述矩阵构建过程后,图2的时序样本矩阵中即包含了故障线路与非故障线路的零序电流之间的幅值差异性和极性差异性等故障选线特征,利用大量样本对1D-CNN进行训练,可以实现样本特征与故障线路的关联,从而实现故障选线。然而,实际工程中各线路的零序采样值易受到环境噪声和采样时间影响,导致1D-CNN时序样本矩阵中的故障选线特征发生改变、偏移或错位,如附录中图A2所示。图A2(a)为各线路零序电流采样时间滞后时的1D-CNN时序样本矩阵,与图2相比,其包含的故障选线特征信息发生了不同程度的偏移;图A2(b)为各线路间的零序电流采样时间不同步时的1D-CNN时序样本矩阵,与图2相比,其包含的故障选线特征信息发生了不同程度的错位。由于图A2中的受干扰样本与图2中的理想样本存在差异,当利用后者对1D-CNN进行训练时,训练后的模型难以正确识别图A2中的受干扰样本,从而影响故障选线正确率,因此1D-CNN应用于实际配电网故障选线时存在不足。

针对1D-CNN应用于配电网单相接地故障选线时存在的不足,本文建立了S-CNN。首先,在配电网发生单相接地故障后的1个周期内采集各线路的零序电流并分别进行归一化处理,以消除线路类型不同导致的零序电流幅值差异的影响;然后,将线路 x 、 y 的零序电流时序数据分别记为 $x_{n \times 1}$ 和 $y_{n \times 1}$,利用S变换计算得到对应的时频信息矩阵,计算2个时频信息矩阵之间的欧氏距离 δ ,并将 $1-\delta$ 作为两者的相关度 s_{xy} ;最后,通过计算两两线路之间的时频信息矩阵的相关度,构建如式(8)所示的相关度矩阵 S_{rel} 。

$$S_{rel} = \begin{bmatrix} s_{11} & \cdots & s_{1n} \\ \vdots & & \vdots \\ s_{n1} & \cdots & s_{nn} \end{bmatrix} \quad (8)$$

与1D-CNN时序样本矩阵相比,利用S-CNN构建的相关度矩阵具有以下优势。

(1)降低噪声影响:利用S变换可以有效提取零序电流全频带时序信息,零序电流采样值中存在的白噪声对全频带时序信息的影响较小。

(2)增强选线特征可辨识度:S-CNN以各线路时

频信息矩阵的相关度而非电气量作为其样本矩阵中的元素,因此当各线路的零序电流采样值存在噪声干扰或采样不同步问题时,故障线路与非故障线路的零序电流之间的差异性仍然存在。

(3)故障选线特征在样本矩阵中的位置固定:1D-CNN时序样本矩阵的故障选线特征可能存在偏移和错位,而利用S-CNN深度学习模型构建的相关度矩阵由各线路时频信息矩阵间的相关度构成,故障选线特征可固定在相关度矩阵中的特定位置。

根据第1节的分析过程,非故障线路零序电流时频信息之间的相关度较大甚至接近1,故障线路与非故障线路的零序电流时频信息之间的相关度较小甚至接近0,从而在 S_{rel} 中形成位置固定、辨识度高的特征信息,如附录中图A3所示。

2.2 基于S-CNN的故障选线模型

本文提出的S-CNN深度学习模型由SCF构建层、深层特征提取层和选线输出层构成,如图3所示(图3仅用于说明,对应的彩图见附录中图A4)。

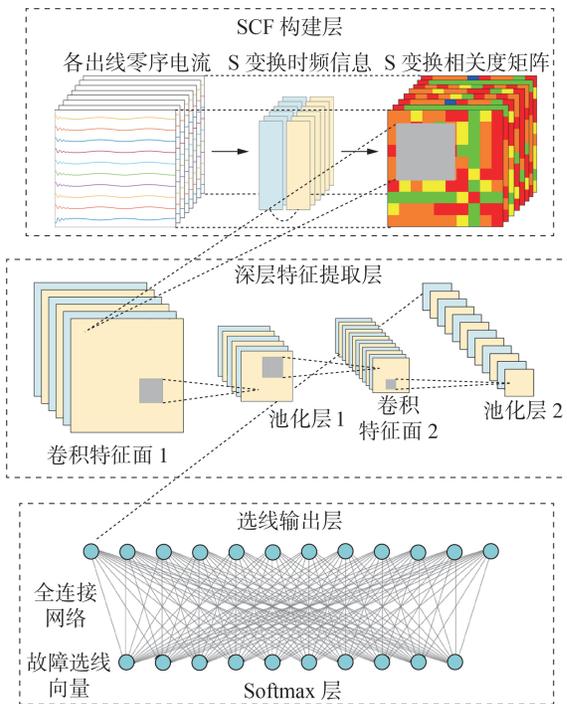


图3 基于S-CNN的故障选线模型

Fig.3 Structure of fault line selection model based on S-CNN

首先,S-CNN以故障后各线路零序电流时序数据 I_0 (阶数为 $m \times n$, m 为各线路零序电流的数据点个数,此处的 n 即为线路条数)作为输入,通过SCF构建层生成阶数为 $n \times n$ 的相关度矩阵 S_{rel} ,然后在深层特征提取层对 S_{rel} 包含的故障选线特征进行提取。深层特征提取层由若干个卷积层和池化层交替构成,该层的具体作用为:根据式(9)由卷积核(阶数为 $k_1 \times k_1$)与相关度矩阵进行滑步卷积运算,并通过激

活函数获取特征面(阶数为 $m \times m$);然后根据式(10)所示的均值池化过程,由池化核(阶数为 $k_2 \times k_2$)对卷积层输出的特征面进行降分辨率采样,获取二次特征面(阶数为 $s \times s$);最后,由选线输出层中的全连接网络对最后的特征面进行整合,形成 n 维故障选线向量 O_L ,向量中各元素分别表示各条线路发生故障的可能性,元素数值越大表示对应线路发生故障的可能性越高,由Softmax层选择可能性最高的线路作为故障选线结果。

$$M_{out}^l = f(M_{in}^{l-1} \otimes K_{core}^l) \quad (9)$$

$$M_{out}^{l+1} = f_{mean}\left(M_{in}^l \otimes \frac{1}{k_2}\right) \quad (10)$$

其中, l 为网络层序号; M_{out}^l 为第 l 层网络输出的特征面; M_{in}^{l-1} 为第 $l-1$ 层网络输出的特征面,其为第 l 层网络的输入; K_{core}^l 为第 l 层网络的卷积核矩阵; \otimes 表示卷积核特征面的滑步卷积运算; $f(\cdot)$ 为激活函数; $f_{mean}(\cdot)$ 为均值函数。

根据式(9)和式(10)所示的运算过程,矩阵 S_{rel} 的阶数 n 、卷积特征面的阶数 m 和池化二次特征面的阶数 s 满足关系式(11),其中各变量均为正整数。

$$\begin{cases} m = n - k_1 + 1 \\ s = m/k_2 \end{cases} \quad (11)$$

2.3 S-CNN的参数训练

S-CNN的有监督学习训练过程通过BP算法进行,其与传统人工神经网络类似,包含前向传播和反向传播过程。

(1)初始化网络:训练前,由式(12)对卷积核和池化核参数进行随机初始化,使网络获得学习能力。

$$X_{ij} = \text{rand}([-1, 1]) \quad (12)$$

其中, X_{ij} 为核参数; $\text{rand}(\cdot)$ 表示取随机值。

(2)前向传播:将一组样本矩阵 I_0 作为输入,根据式(13),经过逐层的数据处理、特征提取、分类输出环节,得到实际的故障选线向量 O_L 。

$$O_L = F_s\left(F_c\left(S(I_0)\right)\right) \quad (13)$$

其中, $S(\cdot)$ 表示 S_{rel} 的构建过程; $F_c(\cdot)$ 表示卷积层运算过程; $F_s(\cdot)$ 表示池化层运算过程。

(3)反向传播:通过比较模型输出与训练数据标签之间的误差,并按式(14)反向传播至池化层和卷积层,向降低误差的方向调整核参数。

$$X'_{ij} = X_{ij} + F_{bp}(\alpha E_{12}) \quad (14)$$

其中, X'_{ij} 为调整后的核参数; E_{12} 为实际输出与训练数据标签之间的误差,通常表示为二者的方差; $F_{bp}(\cdot)$ 表示反向传播的运算过程; α 为学习效率,用于改变核参数的调整幅度。

利用大量配电网故障数据对S-CNN进行训练,经过多次反向传播调整核参数,即可形成具备故障选线能力的S-CNN。

3 算例分析

3.1 故障数据生成

训练 S-CNN 需要大量的带标签数据, 本文通过在 Simulink 中构建 10 kV 经消弧线圈接地配电网仿真模型生成训练所需数据。仿真模型拓扑如附录中图 A5 所示。图中, 消弧线圈补偿度为 5%; 共包含 10 条出线, 由架空线和电缆线组合构成, 线路参数如附录中表 A1 所示。

考虑配电网的实际运行情况, 电网电压、节点负荷、线路故障位置、过渡电阻及故障相角的取值均具有一定的随机性, 因此, 制定参数遍历表如附录中表 A2 所示。根据参数遍历表对仿真模型参数进行排列组合, 采集故障发生后各出线端口处的零序电流数据, 采样率设置为 3 200 Hz。在上述仿真条件下, 共获取 10 800 组配电网故障期间各条线路的零序电流时序数据, 构成带标签的训练数据集, 用于对 S-CNN 进行训练。

3.2 S-CNN 训练

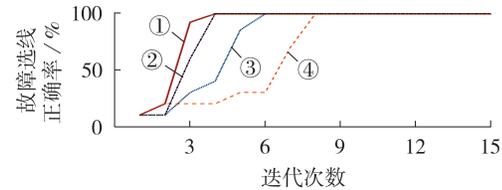
利用仿真生成的带标签训练数据集对 S-CNN 进行训练。本文采用由结构到网络参数的分步训练步骤, 具体如下。

(1) 根据数据样本形式确定深层特征提取层的结构, 包含卷积层与池化层的层数和特征面数目: 本文的结构参数取 LeNet-5 网络典型值, 即网络由 2 个卷积层和 2 个池化层交替组成, 卷积层 1 和池化层 1 各包含 6 个特征面, 卷积层 2 和池化层 2 各包含 12 个特征面。

(2) 根据输入样本的阶数确定卷积核和池化核的阶数的可行取值, 形成多个可行的网络结构: 卷积核和池化核阶数的理论取值由式(11)确定, 并根据经验进行进一步筛选, 本文选取 7-2-2-1、5-3-2-1、5-2-2-1、3-2-2-1 这 4 种网络结构进行测试, 其中结构 7-2-2-1 表示卷积层 1 的卷积核阶数为 7×7, 池化层 1 的池化核阶数为 2×2, 卷积层 2 的卷积核阶数为 2×2, 池化层 2 的池化核阶数为 1×1, 其他网络结构含义依此类推。

(3) 设置典型超参数, 包含学习效率、批训练数目和迭代次数, 对步骤(2)中的 4 种可行结构进行训练测试, 利用控制变量法最终确定本文的 S-CNN 结构及超参数。

图 4 为学习效率为 1、批训练数目为 50 时, 不同结构的 S-CNN 的故障选线正确率随迭代次数的变化情况。根据训练结果, 对 S-CNN 采用网络结构 5-2-2-1 时的训练效果最好, 其样本矩阵构建时间为 183.5 s; 训练过程共迭代 15 次, 用时 44.72 s; 迭代 5 次后故障选线正确率达到 100%。因此确定本文的 S-CNN 采用的网络结构为 5-2-2-1, 具体参数见表 1。



① 5-2-2-1, ② 3-2-2-1, ③ 7-2-2-1, ④ 5-3-2-1

图 4 不同结构 S-CNN 的故障选线正确率随迭代次数的变化

Fig.4 Fault line selection accuracy of S-CNN with different structures varying with number of iterations

表 1 S-CNN 结构及参数

Table 1 Structure and parameters of S-CNN

序号	结构	参数
1	输入样本	阶数为 64×10 的矩阵, 表示共包含 10 条出线, 每条出线含 64 个采样点
2	S_{rel}	阶数为 10×10
3	卷积层 1	卷积核阶数为 5×5 , 滑动步长为 1
4	特征面 1	6 组特征矩阵, 阶数为 6×6
5	池化层 1	池化核阶数为 2×2 , 采样步长为 2
6	卷积层 2	卷积核阶数为 2×2 , 滑动步长为 1
7	特征面 2	12 组特征矩阵, 阶数为 2×2
8	池化层 2	池化核阶数为 1×1 , 采样步长为 1
9	全连接层	10 维选线向量
10	Softmax 层	—

3.3 基于仿真数据的故障选线结果分析

改变附录中图 A5 所示仿真模型的参数, 在不同故障位置、故障相角和过渡电阻条件下生成 400 组区别于训练过程的故障数据, 构成模型测试集, 用于检验训练后的 S-CNN 的故障选线效果。下面以其中 1 组测试数据为例说明基于 S-CNN 的故障选线模型的测试过程。

截取出线 L_2 发生单相接地故障后各出线端口的零序电流时序数据作为 1 组数据样本, 输入训练后的 S-CNN, 得到故障选线向量 O_L 如表 2 所示, 表中用下划线标出了数值最大的元素及对应的线路, 后同。由表 2 可以看出, S-CNN 的 Softmax 层将 O_L 中最大元素对应的出线 L_2 判定为故障线路, 与真实情况一致。

表 2 S-CNN 输出的故障选线向量

Table 2 Fault line selection vector of S-CNN

出线	元素	出线	元素
L_1	0.0472	L_6	0.0146
<u>L_2</u>	<u>0.9267</u>	L_7	0.0007
L_3	0.0532	L_8	0
L_4	0.0005	L_9	0.0059
L_5	0.0102	L_{10}	0.0021

按上述过程对 400 组测试数据进行测试, S-CNN 输出的故障选线结果均与真实故障线路一致, 选线正确率为 100%。这证明对于仿真数据, 训练后的 S-CNN 可以实现小电流接地配电网单相接地故障的正确选线, 且不受系统电压、故障位置、过渡电阻和故障相角的影响。

3.4 不同程度的噪声干扰下不同故障选线方法的对比分析

实际工程中, 各线路测量的故障暂态零序电流通常会受到噪声干扰, 可能会削弱故障线路与非故障线路零序电流之间的差异性, 从而降低故障选线的正确率。为测试 S-CNN 的抗干扰能力, 在 3.3 节的 400 组测试数据中叠加不同信噪比的高斯白噪声, 形成噪声干扰数据集, 信噪比 V_{snr} 的计算方法如式 (15) 所示。信噪比越小, 表示噪声越大。

$$V_{snr} = 10 \lg(P_s/P_n) \quad (15)$$

其中, P_s 为源信号; P_n 为噪声信号。

以出线 L_2 发生单相接地故障时的 1 组零序电流数据为例, 叠加 10 dB 高斯白噪声后的零序电流幅值如图 5 所示。

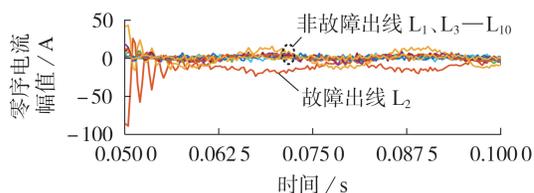


图 5 叠加高斯白噪声后各出线零序电流幅值

Fig.5 Amplitude of zero-sequence current of each line with Gaussian white noise

利用噪声干扰数据集分别测试了本文方法、基于小波变换与模糊 C 均值聚类选线方法^[6,81](WT-FCM) 及直接以零序电流时序数据作为输入的 1D-CNN 方法的故障选线效果, 结果如图 6 所示。为便于直观显示信噪比与故障选线正确率的关系, 制图时特意将横轴刻度按照从大到小的顺序排列, non 表示不叠加噪声。由图 6 可见, 在信噪比大于 30 dB 时, 3 种故障选线方法均能准确选线; 当信噪比减小, 即噪声增大时, WT-FCM 方法的故障选线正确率迅速下降; 1D-CNN 方法和本文方法均具有一定的抗干扰能力,

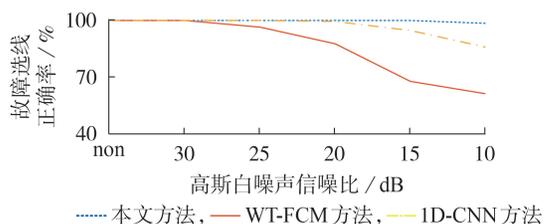


图 6 不同程度的噪声干扰下不同故障选线方法的对比

Fig.6 Comparison among different fault line selection methods under different levels of noise interference

当信噪比降低至 10 dB 时, 1D-CNN 方法选线正确率为 86%, 本文方法的选线正确率为 98.5%。

3.5 各出线零序电流采样时间不同步时不同选线方法的对比分析

实际工程中, 各出线零序电流采样时间难以绝对同步, 导致故障发生时故障出线与非故障出线的零序电流特征发生变化, 影响故障选线正确率^[8,11]。

为了测试本文提出的基于 S-CNN 的故障选线模型在各出线的零序电流采样时间不同步时的鲁棒性, 针对 3.3 节所述的 400 组测试数据, 在叠加 20 dB 高斯白噪声的基础上, 对出线 L_1-L_5 与 L_6-L_{10} 设置零序电流采样时间差 T_d , 生成带噪声的采样不同步数据集, 模拟各出线存在的采样不同步场景。利用生成的带噪声采样不同步数据集分别对 WT-FCM 方法、1D-CNN 方法和本文方法进行测试, 3 种方法的故障选线正确率如表 3 所示。

表 3 各出线零序电流采样不同步时不同选线方法对比

Table 3 Comparison of different fault line selection methods when zero-sequence current sampling of each line is not synchronized

T_d / ms	故障选线正确率 / %		
	WT-FCM 方法	1D-CNN 方法	本文方法
0	87.75	99.50	100
1.25	85.75	98.50	100
2.50	76.50	91.75	100
5.00	65.00	59.75	100

3.6 基于实际配电网故障录波数据的故障选线结果分析

利用某配电网故障录波数据对本文方法进行验证。该配电网拓扑如附录中图 A6 所示, 共包含 6 条出线, 其中出线 4 为电缆线, 其余线路为架空线, 运行方式为经消弧线圈接地。根据记录, 该配电网在出线 2 的架空线中段发生 3 次单相接地故障, 分别为 A 相经阻抗接地、C 相经高阻接地、A 相经高阻接地故障, 故障发生时出线 5、6 未投入。从故障录波中提取故障后 0.06 s 内出线 1—4 首端测得的零序电流时序数据, 如图 7 所示。

由于本文是基于 10 条出线的配电网模型训练 S-CNN 的, 其相关度矩阵阶数为 10×10 。而该实际配电网仅有 4 条出线的零序电流时序数据, 经过 S-CNN 的数据处理环节后, 获得的相关度矩阵 (记为 S_{rel-1}) 的阶数仅为 4×4 , 以出线 2 发生 A 相经阻抗接地故障为例, 对应的样本矩阵 S_{rel-1} 为:

$$S_{rel-1} = \begin{bmatrix} 0 & 0.9981 & 0.0809 & 0.0819 \\ 0.9981 & 0 & 0.9958 & 1 \\ 0.0809 & 0.9958 & 0 & 0.1710 \\ 0.0819 & 1 & 0.1710 & 0 \end{bmatrix} \quad (16)$$

因此, 需将 S_{rel-1} 扩展为阶数为 10×10 的矩阵。本文利用去首尾均值法对其进行扩展, 即选取各行

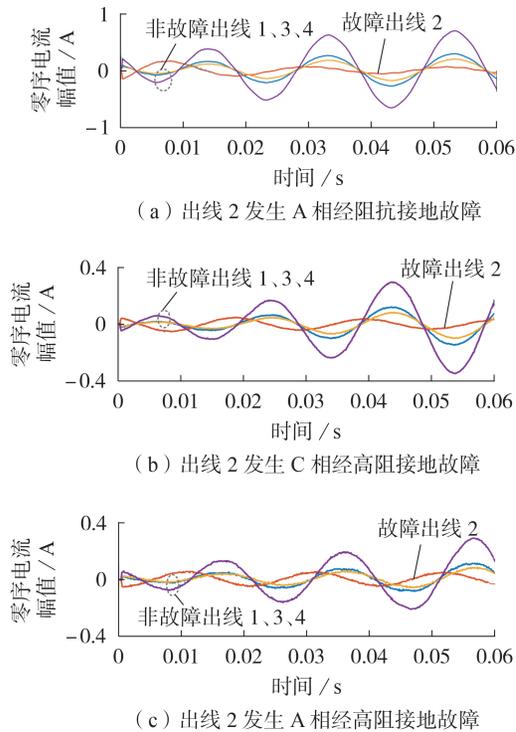


图7 出线2发生单相接地故障时的零序电流录波
Fig.7 Recording waveforms of zero-sequence current when single-phase grounding fault occurs on Line 2

(列)的4个数值中除最大值和最小值外的2个数值,求取这2个数值的平均值,利用该平均值将该行(列)扩展至10维。扩展后的相关度矩阵 S'_{rel-1} 如式(17)所示。

$$S'_{rel-1} = \begin{bmatrix} 0 & 0.9981 & 0.0809 & 0.0819 & 0.0814 & \cdots & 0.0814 \\ 0.9981 & 0 & 0.9958 & 1 & 0.9969 & \cdots & 0.9969 \\ 0.0809 & 0.9958 & 0 & 0.0171 & 0.0490 & \cdots & 0.0490 \\ 0.0819 & 1 & 0.0171 & 0 & 0.0495 & \cdots & 0.0495 \\ 0.0814 & 0.9969 & 0.0490 & 0.0495 & 0 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0.0814 & 0.9969 & 0.0490 & 0.0495 & 0 & \cdots & 0 \end{bmatrix} \quad (17)$$

需要说明的是,上述矩阵扩展过程可以在模型中自动实现,且不具有特殊性;本文算例中的故障选线模型基于10条出线的配电网仿真模型故障数据训练生成,适用于出线不超过10条的实际配电网故障选线,当实际配电网出线数目超过10条时,只需利用出线条数更多的仿真模型重新训练即可,易于在不同变电站间推广。

在3次测试中,分别提取图3中选线输出层的故障选线向量 O_1 如表4所示,表中出线1—4对应的数据为选线向量的有效部分。测试结果表明,S-CNN可以正确判定实际配电网发生单相接地故障时的故障线路。

表4 利用实际配电网故障录波数据的测试结果
Table 4 Testing results by using recording data from actual distribution network

出线	元素		
	测试1	测试2	测试3
1	0.0415	0.0451	0.0429
2	<u>0.9545</u>	<u>0.9522</u>	<u>0.9527</u>
3	0.0371	0.0346	0.0364
4	0.0204	0.0182	0.0201
5	0	0	0
6	0	0	0
7	0	0	0
8	0	0	0
9	0.0001	0.0002	0.0001
10	0.0006	0.0007	0.0006

4 结论

本文通过构建SCF,将一维零序电流数据转换为二维相关度图形,以提升故障选线特征的可辨识度,并建立S-CNN,提取各线路零序电流深层特征,实现故障选线。利用仿真生成的干扰数据和实际配电网故障数据对S-CNN进行测试,由测试结果可以得出以下结论:

(1)通过将各出线零序电流构建为SCF,可有效降低噪声干扰对零序电流特征的影响,提高零序电流特征的可辨识度;

(2)基于大量故障数据训练的S-CNN具有较强的泛化能力,其故障选线准确度不受系统运行状态、线路参数、故障位置、相角以及过渡电阻等因素的影响;

(3)与WT-FCM、1D-CNN方法相比,本文方法具有更强的抗噪声能力,且在各出线零序电流采样不同步时具有更强的鲁棒性。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 殷志华,孙国强,丁建忠,等. 基于极点对称模式分解的配电网单相接地故障区段定位技术[J]. 电力自动化设备,2019,39(6):173-178,191.
YIN Zhihua, SUN Guoqiang, DING Jianzhong, et al. Fault section location method for single-phase grounding fault in distribution network based on ESMD[J]. Electric Power Automation Equipment, 2019, 39(6): 173-178, 191.
- [2] SOHEILI A, SADEH J, LOMEI H. A new high impedance fault detection scheme: Fourier based approach[C]//IEEE International Conference on Power System Technology (POWERCON). Wollongong, NSW, Australia: IEEE, 2016: 1-6.
- [3] 陈小青. 小电流接地系统配电网故障选线方法的研究[D]. 重庆:重庆理工大学,2020.
CHEN Xiaoqing. Research on fault line selection method of distribution network in small current grounding system[D]. Chongqing: Chongqing University of Technology, 2020.
- [4] 薛永端,李娟,徐丙垠. 中性点经消弧线圈接地系统小电流接地故障暂态等值电路及暂态分析[J]. 中国电机工程学报,

- 2015,35(22):5703-5714.
XUE Yongduan,LI Juan,XU Bingyin. Transient equivalent circuit and transient analysis of single-phase earth fault in arc suppression coil grounded system[J]. Proceedings of the CSEE, 2015,35(22):5703-5714.
- [5] 姜博,董新洲,施慎行. 配电网单相接地故障选线典型方法实验研究[J]. 电力自动化设备,2015,35(11):67-74.
JIANG Bo,DONG Xinzhou,SHI Shenxing. Experimental research on typical single-phase grounding line selection methods of distribution network[J]. Electric Power Automation Equipment,2015,35(11):67-74.
- [6] 叶宝柱,薛超宇,张惠娟,等. 基于特征频带小波包分析的配电网故障选线的研究[J]. 电气工程学报,2018,13(2):24-28.
YE Baozhu,XUE Chaoyu,ZHANG Huijuan,et al. Research on fault line selection in distribution network based on feature band wavelet packet analysis[J]. Journal of Electrical Engineering,2018,13(2):24-28.
- [7] SONG Xiaohui,GAO Fei,CHEN Zhenning,et al. A negative selection algorithm based identification framework for distribution network faults with high resistance[J]. IEEE Access, 2019(7):109363-109374.
- [8] 邵翔,郭谋发,游林旭. 基于改进DTW的接地故障波形互相关度聚类选线方法[J]. 电力自动化设备,2018,38(11):69-77,84.
SHAO Xiang,GUO Moufa,YOU Linxu. Faulty line selection method using mutual correlation cluster of grounding fault waveforms based on improved DTW method[J]. Electric Power Automation Equipment,2018,38(11):69-77,84.
- [9] 易汗林. 基于S变换的配电网单相接地故障选线及定位方法[D]. 长沙:湖南大学,2017.
YI Hanlin. Single-phase-to-ground fault selection and location method for distribution network based on S-transform[D]. Changsha:Hunan University,2017.
- [10] 王旭强,杨青,张耀,等. 基于多源信息融合的配电网故障选线新方法[J]. 智慧电力,2019,47(9):97-103.
WANG Xuqiang,YANG Qing,ZHANG Yao,et al. A new fault line selection method for distribution network system based on multidimensional information fusion[J]. Smart Power,2019,47(9):97-103.
- [11] 庄胜斌,缪希仁,江灏,等. 基于改进欧氏-动态时间弯曲距离的谐振接地配电网单相高阻接地故障选线方法[J]. 电网技术,2020,44(1):273-281.
ZHUANG Shengbin,MIAO Xiren,JIANG Hao,et al. A line selection method for single-phase high-impedance grounding fault in resonant grounding system of distribution network based on improved Euclidean-dynamic time warping distance[J]. Power System Technology,2020,44(1):273-281.
- [12] 束洪春,龚振,田鑫萃,等. 基于故障特征频带及形态谱的单相接地故障选线[J]. 电网技术,2019,43(3):1041-1048.
SHU Hongchun,GONG Zhen,TIAN Xincui,et al. Single line-to-ground fault line selection based on fault characteristic frequency band and morphological spectrum[J]. Power System Technology,2019,43(3):1041-1048.
- [13] HAN Lei,LIU Shihan,CHEN Haowei,et al. A new method of fault line selection for resonant grounding system based on improved S transform parameters[C]//2019 IEEE Sustainable Power and Energy Conference (iSPEC). Beijing, China:IEEE, 2019:465-468.
- [14] 刘谋海,方涛,姜运,等. 基于高频分量相关度分析的故障选线方法[J]. 电力系统及其自动化学报,2017,29(2):101-106.
LIU Mouhai,FANG Tao,JIANG Yun,et al. Fault line selection method based on correlation analysis of high-frequency components[J]. Proceedings of the CSU-EPSA,2017,29(2):101-106.
- [15] 周飞燕,金林鹏,董军. 卷积神经网络研究综述[J]. 计算机学报,2017,40(6):1229-1251.
ZHOU Feiyan,JIN Linpeng,DONG Jun. Review of convolutional neural network[J]. Chinese Journal of Computers,2017,40(6):1229-1251.
- [16] 周念成,廖建权,王强钢,等. 深度学习在智能电网中的应用现状分析与展望[J]. 电力系统自动化,2019,43(4):267-284.
ZHOU Niancheng,LIAO Jianquan,WANG Qianggang,et al. Analysis and prospect of deep learning application in smart grid[J]. Automation of Electric Power Systems,2019,43(4):267-284.
- [17] 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.
- [18] 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):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(Supplement):21-28.
- [19] YANG Dongsheng,PANG Yongheng,ZHOU Bowen,et al. Fault diagnosis for energy internet using correlation processing-based convolutional neural networks[J]. IEEE Transactions on Systems,Man and Cybernetics:Systems,2019,49(8):1739-1748.
- [20] CHEN Y,FINK O,SANSAVINI G. Combined fault location and classification for power transmission lines fault diagnosis with integrated feature extraction[J]. IEEE Transactions on Industrial Electronics,2018,65(1):561-569.
- [21] 秦瑜瑞. 基于机器学习和小波包变换的故障选线方法研究[D]. 郑州:郑州大学,2019.
QIN Yurui. Research on fault line selection based on machine learning and wavelet packet transform[D]. Zhengzhou:Zhengzhou University,2019.
- [22] 刘保童. S变换与小波变换检测信号突变性研究[J]. 天水师范学院学报,2006(2):28-30.
LIU Baotong. Research on detecting abrupt changes via S transform and wavelet transform[J]. Journal of Tianshui Normal University,2006(2):28-30.

作者简介:



殷浩然

殷浩然(1997—),男,河北保定人,硕士研究生,研究方向为人工智能在电力系统中的应用(E-mail:hr_yin@126.com);

苗世洪(1963—),男,湖北随州人,博士研究生导师,教授,博士,通信作者,研究方向为电力系统保护与控制、配电网及微电网新技术、电网智能调度与自动化技术、压缩空气储能建模及应用等(E-mail:shmiao@hust.edu.cn);

郭舒毓(1996—),男,山西临汾人,硕士研究生,主要研究方向为电力系统规划、输电线路故障定位(E-mail:sy_guo@hust.edu.cn)。

(编辑 任思思)

Novel method for single-phase grounding fault line selection in distribution network based on S-transform correlation and deep learning

YIN Haoran^{1,2}, MIAO Shihong^{1,2}, GUO Shuyu^{1,2}, HAN Ji^{1,2}, WANG Zixin^{1,2}

(1. State Key Laboratory of Advanced Electromagnetic Engineering and Technology, School of Electrical and Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China;

2. Hubei Electric Power Security and High Efficiency Key Laboratory, School of Electrical and Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: The fault characteristics of single-phase grounding faults in small current grounding systems are not obvious, and the existing line selection methods are susceptible to fault conditions and environmental noise. A novel line selection method based on S-transform correlation and deep learning is proposed, which has strong anti-noise ability and high generalization level. Firstly, the time-frequency information of the zero-sequence current is obtained by S-transform, which is used to calculate the fault characteristic information correlation between each line. Then, a construction method of SCF(S-transform Correlation Figure) is proposed to improve the identifiability and anti-interference of the fault characteristics, based on which, the S-CNN (Convolutional Neural Network deep learning model with SCF construction layer) is constructed, and its structural parameters and hyperparameters are trained step by step with the fault data generated by the Simulink simulation model. Finally, S-CNN is used to extract the deep features of the fault zero-sequence current to select the fault line, and the effect of S-CNN under different operating conditions and fault conditions are tested. Simulative results and actual distribution network data test show that the fault line selection model based on S-CNN can achieve high accuracy under different fault locations, fault phase angles, transition resistances, load fluctuations or strong noise interference conditions, and still has strong robustness under the condition of unsynchronized zero-sequence current sampling of each line.

Key words: distribution network; fault line selection; deep learning; S-transform; CNN

(上接第80页 continued from page 80)

Restoration control strategy of distribution network based on dynamic evaluation of restoration value

HAO Lili¹, CHEN Congshuang¹, WANG Chuan¹, CAI Jilin¹, HAO Sipeng², LIU Haitao²

(1. College of Electrical Engineering and Control Science, Nanjing Tech University, Nanjing 211816, China;

2. School of Electric Power Engineering, Nanjing Institute of Technology, Nanjing 211167, China)

Abstract: The power outage scenario, restoration process and load functions under emergency situations may affect the power supply restoration urgency of load during distribution network restoration. Usually, the importance level or degree of the object to be restored is statically set according to its own restoration value, which restricts the refined management of limited restoration resources. Considering the impact of cold load pick-up characteristic and functional coupling relationship among loads on load unit restoration value, considering the impact of controllability of intermittent power output on generation restoration value, combining with the potential restoration value provided by bus restoration to other surrounding objects to be restored, together with the sufficiency of system, the cost of restoration and the uncertainty of restoration operations, a dynamic evaluation approach for load and generator importance degree is proposed with comprehensive restoration benefits, costs and risks. Based on this, a multi-process optimization model for power supply restoration of the distribution network and a partition parallel restoration decision-making method are developed. Finally, simulative results verify that the proposed strategy can effectively improve the utilization of resources.

Key words: distribution network; restoration value; uncertainty; dynamic evaluation; restoration control strategy

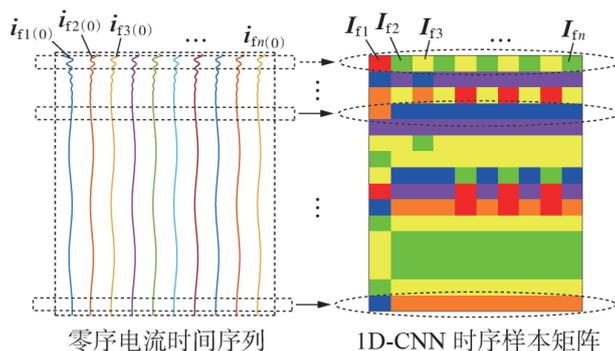
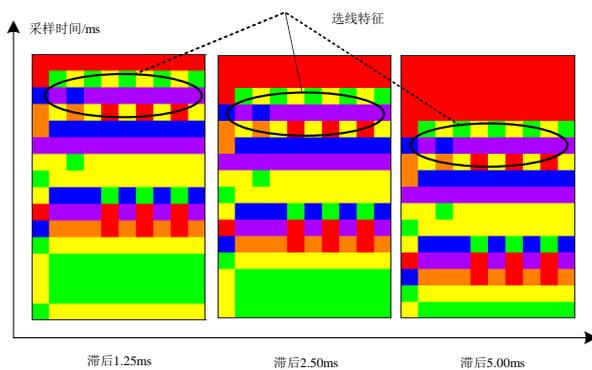
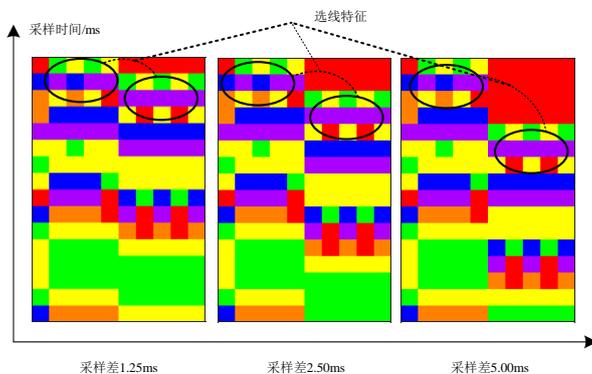


图 A1 1D-CNN 时序样本矩阵构建过程

Fig.A1 Construction process of time-series sample matrix for 1D-CNN



(a) 各线路零序电流采样时间滞后



(b) 各线路零序电流采样时间不同步

图 A2 1D-CNN 时序样本矩阵特征偏移和错位

Fig.A2 Feature shift and misalignment of 1D-CNN time-series sample matrix

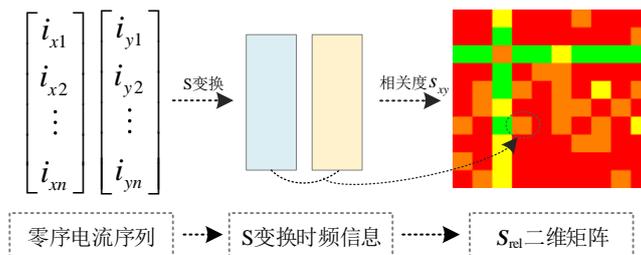


图 A3 S 变换相关度矩阵构建过程

Fig.A3 S-transformation correlation matrix construction process

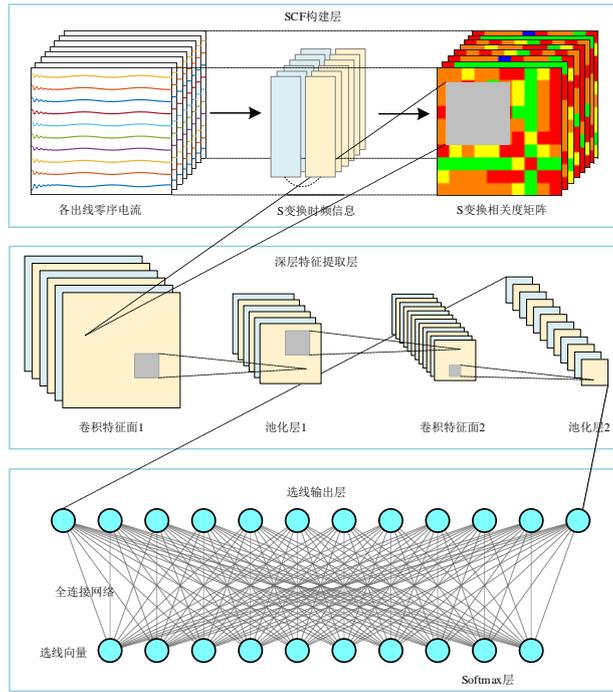


图 A4 基于 S-CNN 深度学习模型的故障选线模型结构

Fig.A4 Structure of fault line selection model based on S-CNN model

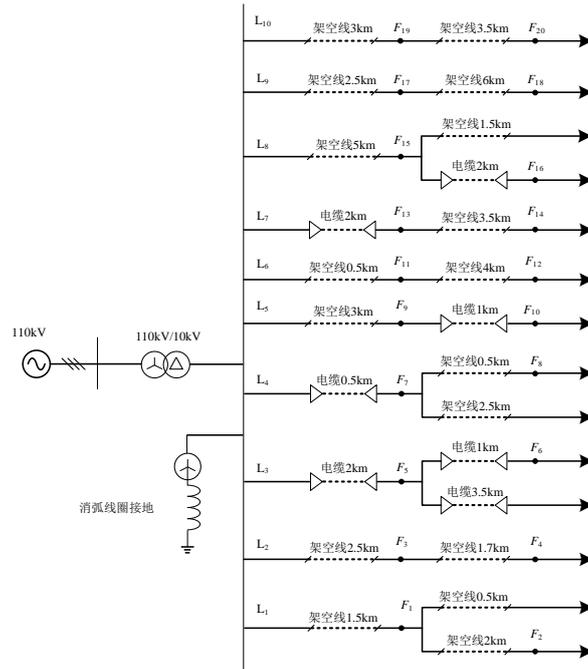


图 A5 配电网单相接地故障仿真模型

Fig.A5 Single-phase grounding fault simulation model for distribution network

表 A1 仿真模型线路参数

Table A1 Line parameters of simulation model

线路参数	参数值	
	架空线	电缆
电阻 (正序, 零序)	0.1250, 0.2750	0.2700, 2.7000
电感 (正序, 零序)	1.3000, 4.6000	0.2550, 1.0190
电容 (正序, 零序)	0.0096, 0.0054	0.2800, 0.3390

表 A2 故障仿真模型参数遍历表

Table A2 Fault simulation model parameter traversal table

参数	取值
电压/kV	9.5, 10.0, 10.5
负荷/MV·A	$1+j0.6$, $0.9+j0.54$, $1.1+j0.66$
故障类型	A-G, B-G, C-G
故障相角	0° , 30° , 60° , 90°
过渡电阻/ Ω	0.1, 1, 10, 100, 1000
故障位置	如图 A5 所示, 共 20 种情况

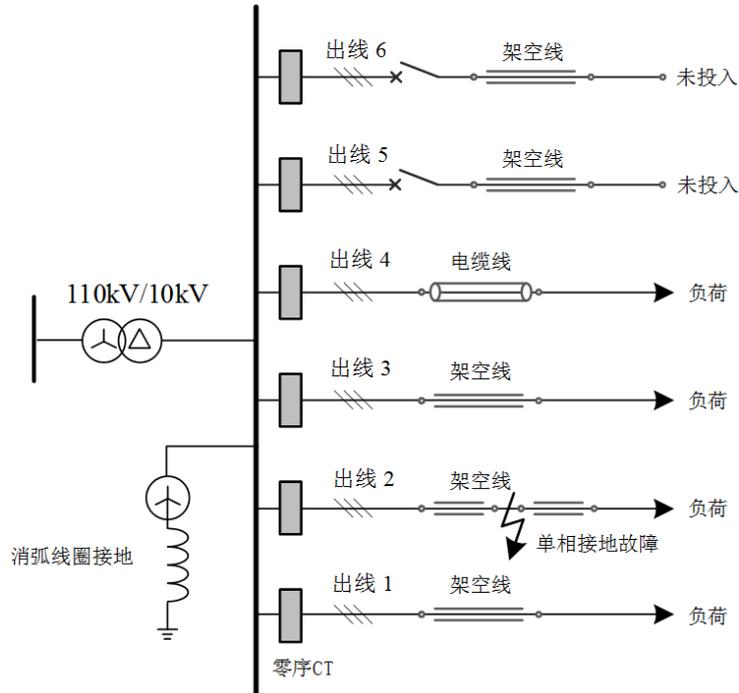


图 A6 某实际配电网拓扑结构

Fig.A6 Topological structure of an actual distribution network