

基于1DCNN-BiLSTM的配网单相接地故障选线方法

聂祥论, 张 焱, 申江兰, 毛业涛, 聂 晶, 李 义, 饶雪梅

贵州电网有限责任公司毕节供电局, 贵州 毕节

收稿日期: 2024年1月26日; 录用日期: 2024年2月15日; 发布日期: 2024年3月27日

摘 要

针对单相接地故障特征信息难以充分挖掘导致故障选线精度不高、鲁棒性差的问题, 提出了一种基于一维卷积神经网络(one-dimensional convolutional neural network, 1DCNN)-双向长短期记忆网络(bi-directional long short-term memory, BiLSTM)的配网单相接地故障选线方法。首先, 利用序列特征融合方法对同一工况下各线路的暂态零序电流, 获取序列融合特征向量。其次, 采用1DCNN提取序列融合特征向量的局部特征, BiLSTM进一步从局部特征中学习上下文依赖关系, 最后通过SoftMax层实现故障选线。仿真表明, 所提方法的选线精度为100%。与现有方法相比, 所提方法同时兼顾选线精度高和鲁棒性强的优点。

关键词

序列特征融合, 故障选线, 一维卷积神经网络, 双向长短期记忆网络, 特征提取, 上下文依赖关系

Line Selection Method for Single-Phase Grounding Fault in Distribution Network Based on 1DCNN-BiLSTM

Xianglun Nie, Yao Zhang, Jianglan Shen, Yetao Mao, Jing Nie, Yi Li, Xuemei Rao

Bijie Power Supply Bureau of Guizhou Power Grid Co., Ltd., Bijie Guizhou

Received: Jan. 26th, 2024; accepted: Feb. 15th, 2024; published: Mar. 27th, 2024

Abstract

Aiming at the problem that the single-phase grounding fault feature information is difficult to be

文章引用: 聂祥论, 张焱, 申江兰, 毛业涛, 聂晶, 李义, 饶雪梅. 基于 1DCNN-BiLSTM 的配网单相接地故障选线方法[J]. 智能电网, 2023, 13(5): 83-91. DOI: 10.12677/sg.2023.135008

fully mined leading to low line selection accuracy and poor robustness, a single-phase grounding line selection method based on a one-dimensional convolutional neural network-bi-directional long and short-term memory for distribution networks is proposed. First, the transient zero-sequence currents of each line under the same operating condition are spliced using the serial feature fusion method to obtain the sequence fusion feature vector. Second, 1DCNN is used to extract the local features of sequence fusion feature vectors, BiLSTM further learns the contextual dependencies from the local features, and finally line selection is implemented through SoftMax layer. Simulation shows that the proposed method has line selection accuracy of 100%. Compared with the existing methods, the proposed method combines the advantages of high line selection accuracy and robustness at the same time.

Keywords

Serial Feature Fusion, Fault Line Selection, One-Dimensional Convolutional Neural Network, Bi-Directional Long Short-Term Memory, Feature Extraction, Contextual Dependencies

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

故障选线是配电系统智能故障诊断的关键步骤，是故障定位和故障恢复的重要基础，是提高电能质量和用户满意度的重要一环。研究表明，大多数故障是由配电网故障引起的，其中单相接地故障占有故障的 80% [1]。如果不能可靠地辨识单相接地故障线路，可能会发生严重故障，导致设备损坏、人员伤亡和停电。然而，由于配网发生单相接地故障的故障电流较小且故障暂态过程复杂，很难准确确定具体的故障馈线。因此，快速准确地辨识故障线路对配网的安全稳定运行具有重要意义。

目前，故障选线方法主要分为稳态法和暂态法。稳态法包括零序电流比较法、零序导纳法和五次谐波法等，但此类方法易受网络结构、故障电流微弱、电磁干扰等因素的影响导致选线精度不佳[2]。暂态零序电流比稳态零序电流的幅值大数倍，包含有丰富的故障信息[3]。因此，许多基于暂态零序电流的选线方法被提出。暂态法通常采用现代信号处理方法提取暂态故障特征，从而提高故障选线精度。文献[4]利用 HHT 变换和时频谱带通滤波法获取时频能量矩阵，并计算各线路的综合相似系数进行故障选线。文献[5]结合 VMD 分解和 FFT 变换获取暂态零序电流非工频分量实现故障选线。文献[6]利用 S 变换获取暂态零序电流的时频矩阵，通过计算时频矩阵的相似度实现故障选线。暂态零序电流文献[7]对零序电流使用小波包变换提取暂态特量，输入到 GA-SVM 中学习得到选线结果。文献[8]对零序电流使用 GAF 变换获取 GASF 和 GADF 特征图并输入到 CNN 中完成故障选线。文献[9]对各馈线零序电流进行 VMD 分解，并将计算得到的各分量分段能量值输入到 LSTM 中实现故障选线。文献[10]构建 S 变换相关度图形结合 CNN 实现故障选线。文献[11]利用 VMD-HHT 和 GAF 算法获取零序电流的多域图像并输入到 CBAM-ResNet 网络进行选线，提高了选线精度。尽管暂态法在提高故障选线精度方面具有明显的效果，但现代数字信号处理方法往往采用固定的基函数，会造成提取的故障特征不充分，导致选线模型鲁棒性较差的问题。

针对上述问题，本文提出了一种基于 1DCNN-BiLSTM 的配网单相接地故障选线方法。利用序列特征融合方法对同一工况下各线路的暂态零序电流进行拼接获取序列融合特征向量。将序列融合特征向量归一化处理后作为输入，通过 1DCNN 提取特征向量的局部特征，BiLSTM 进一步从局部特征中学习上

下文依赖关系，然后通过 SoftMax 层实现故障选线。结果表明，所提方法具有较强的鲁棒性。

2. 单相接地故障特征分析

当配网发生单相接地故障时，其零序网络等效图[12]如图 1 所示。

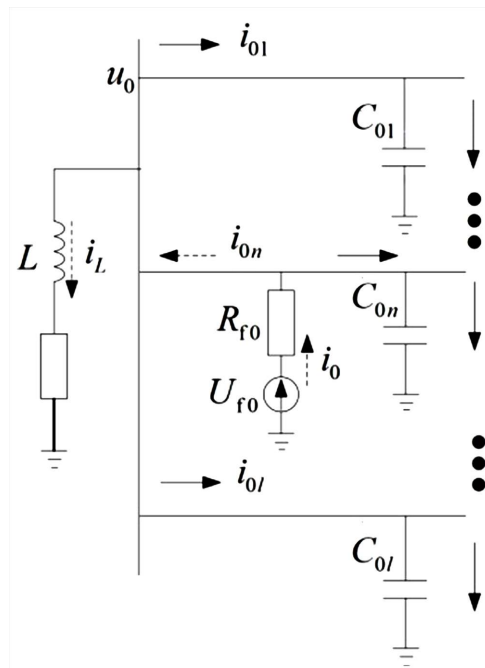


Figure 1. Zero-sequence equivalent diagram of single-phase ground fault in distribution network system

图 1. 配网系统单相接地故障零序等效图

图 1 中， i_{0n} 为故障线路 n 的零序电流， $i_{0l(l \neq n)}$ 为正常线路的零序电流， C_{0n} 为线路 n 的零序电容； R_{f0} 为接地电阻， u_0 为零序母线电压， L 为消弧线圈的等效电感， i_L 为消弧线圈电感电流。

分析图 1 可知，故障线路的暂态零序电流等于所有正常线路的对地电容电流与消弧线圈电感电流之和，其幅值大于正常线路的暂态零序电流幅值，且两者之间的零序电流极性相反[13]。

综上分析，故障线路和正常线路间的暂态零序电流间的幅值、极性差异可作为故障选线的特征信息。

3. 相关理论

3.1. 序列特征融合方法

假设配电网中有 k 条线路，当发生单相接地故障时，采集各线路故障发生后首个工频周期的暂态零序电流 $i_{f1(0)}, i_{f2(0)}, \dots, i_{fk(0)}$ 。根据序列特征融合方法[14]的定义，获取对应的序列融合特征向量

$$I_f = (i_{f1(0)}, i_{f2(0)}, \dots, i_{fk(0)})^T。$$

以 4 出线的配网系统发生 A 相接地故障为例，各线路的故障初始相角设置为 0° 、过渡电阻为 50Ω 、故障距离为 5 km 。不同线路发生单相接地故障对应的序列融合特征波形如图 2 所示。

由图 2 可知，序列融合特征波形能突出显示故障线路的幅值特征[15]。因此，可采用序列融合特征向量的这一优势进行故障选线。




Figure 2. Sequence fusion characteristic waveforms of different lines
 图 2. 不同线路的序列融合特征波形

3.2. 1DCNN

CNN 被认为是计算机视觉领域的重大突破，与机器学习算法相比，CNN 最大的特点是在提取有效特征的同时实现智能分类，可以克服特征提取和分类器选择困难的问题。文献[16]通过连续小波变换将暂态零序电流波形转换成时频图像，然后使用 CNN 对图像进行特征提取。然而，在信号处理过程中，信号信息的完备性无法得到保证，这可能会削弱原始故障信号的特征[17]。值得注意的是，1DCNN 可以直接提取原始故障信号的局部特征[18]，在处理时间序列方面具有良好的表现。相比于 2DCNN 而言，具有调整参数少、训练速度快的优点。1DCNN 由输入层、卷积层、池化层、全连接层和输出层七层组成。1DCNN 和 2DCNN 的主要区别在于输入数据的维度不同，其中 1DCNN 使用一维序列而不是二维矩阵。

一维卷积神经网络的卷积层可以定义为：

$$x_j^l = f \left(\sum_{i \in M_j} x_i^{l-1} \cdot K_{ij}^l + b_j^l \right) \quad (1)$$

式中， l 表示网络层数， K 为卷积核， b 为偏置， x_j^l 表示第 l 个卷积层的输出， x_i^{l-1} 表示 l 层的输入， M_j 表示特征的输入集， f 为激活函数，本文中激活函数选择 Relu 函数。

池化层执行下采样过程，得到分辨率更低的特征图，在一定程度上可以通过减少参数来避免过拟合。本文中采用平均池化，平均池化可表示为：

$$x_j^l = f \left(a_j^l \cdot \frac{1}{kt} \sum_{i \in M_j} x_i^{l-1} + b_j^l \right) \quad (2)$$

式中， a 和 b 是权重和偏置， k 和 t 是池化矩阵的维度。

然后全连接层将池化层提取的特征逐个扩展为单列特征向量，并将其映射到对应的标签。全连接层可表示为：

$$y_k = \text{softmax}(\omega_k \cdot x + b_k) \tag{3}$$

式中, y_k 为全连接层的输出, ω_k 和 b_k 分别为权重和偏置。

3.3. BiLSTM

BiLSTM 模型实际上是 LSTM 的变形, 它由前向和后向两个 LSTM 组成序列[19]。被输入到前向和后向两个 LSTM 单元中, 然后将 LSTM 的输出进行线性组合得到最终结果, 如图 3 所示。




Figure 3. Struct of BiLSTM
图 3. BiLSTM 结构

在 BiLSTM 网络中, 数据可以被向前和向后处理。时间 t 既可以利用 $t-1$ 时刻的信息, 也可以利用 $t+1$ 时刻信息。因此, BiLSTM 可以更好地分析数据的内部特征以及数据前后之间的关联性[20], 比单向 LSTM 更具检测精确。BiLSTM 在 t 时刻的隐藏状态 h_t 包括前向 \vec{h}_t 和后向 \overleftarrow{h}_t 。前向 \vec{h}_t 和后向 \overleftarrow{h}_t 的表达式如下:

$$\vec{h}_t = \text{LSTM}(h_{t-1}, x_t) \tag{4}$$

$$\overleftarrow{h}_t = \text{LSTM}(h_{t+1}, x_t) \tag{5}$$

式中, x_t 表示为 LSTM 当前时刻的输入。

4. 1DCNN-BiLSTM 故障选线模型

故障选线模型由 1DCNN 模块和 BiLSTM 模块组成。1DCNN 模块能很好地提取序列特征向量的局部特征, 但难以学习到序列特征向量的上下文依赖关系。BiLSTM 模块凭借独特的门控机制和前后向 LSTM 结构能更好地分析数据的内部特征以及数据前后之间的关联性, 能高效地学习到序列特征向量的上下文依赖关系, 弥补了 1DCNN 模块的不足。为此, 提出了基于 1DCNN-BiLSTM 故障选线方法。

本文采用的模型如图 4 所示, 包含了 3 个卷积层、2 个平均池化层、1 个全局最大池化层、1 个 BiLSTM 层、1 个全连接层和一个 SoftMax 层, 模型的相关结构参数如表 1 所示。




Figure 4. Struct of 1DCNN-BiLSTM
图 4. 1DCNN-BiLSTM 模型结构

Table 1. Related structural parameters
表 1. 相关结构参数

类型	卷积核大小	步长	输出大小
输入层	-	-	512-1
卷积层 1	5	1	508-64
池化层 1	2	2	254-64
卷积层 2	5	1	250-32
池化层 2	2	2	125-32
卷积层 3	5	1	121-32
全局平均池化层	-	-	32-1
BiLSTM 层	-	-	32-1
全连接层	-	-	4-1

5. 仿真分析

5.1. 数据集获取

搭建 10 kV 配网接地故障模型，仿真模型如图 5 所示。线路阻抗参数如表 2 所示，消弧线圈补偿度取 10%。

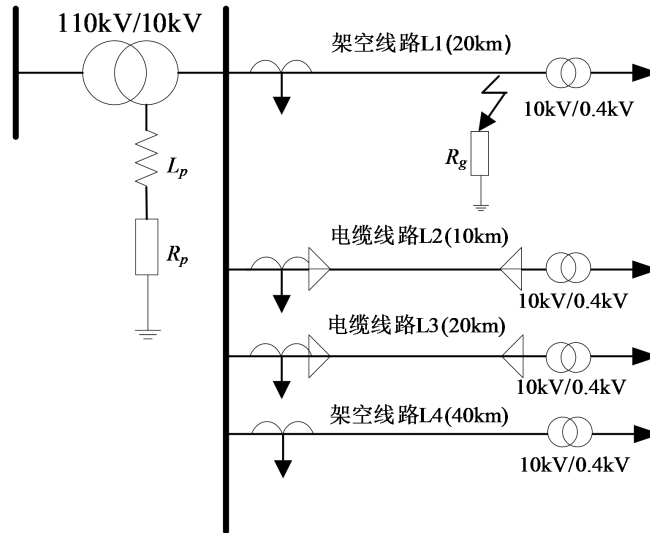


Figure 5. Simulation model of single-phase grounding fault in distribution network

图 5. 配网单相接地故障仿真模型

Table 2. Line impedance parameters
表 2. 线路阻抗参数

线路类型	电阻 Ω/km		电感 mH/km		电容 $\mu\text{F}/\text{km}$	
	正序	零序	正序	零序	正序	零序
架空线路	0.125	0.275	1.3	4.6	0.0096	0.0054
电缆线路	0.27	2.7	0.25	1.019	0.339	0.28

为获取大量数据训练 1DCNN-BiLSTM，考虑了不同故障接地相、过渡电阻、故障初始角和故障距离的故障情况，详细的故障场景设置如表 3 所示。

Table 3. Fault scenario simulation details
表 3. 故障场景仿真明细表

参数	取值
故障线路	L1-L4
故障类型	A-G, B-G, C-G
故障相角	0°~360°, 每隔 0°
过渡电阻/ Ω	1, 10, 50, 100, 200, 500, 1000, 1500, 1800, 2000, 5000, 10,000, 20,000
故障位置/km	10%~80%, 每隔 10%

5.2. 模型的训练与测试

对上述采集的 12,480 组暂态零序电流数据采用 3.1 节的序列特融合方法得到对应的序列融合特征向量数据集，并随机按照 8:2 比例划分训练集和测试机，获得 9984 组训练样本，2496 组测试样本。为了模拟环境干扰，增强模型的鲁棒性，在训练数据中加入信噪比 20 dB 的高斯白噪声。设置初始学习率为 0.001，批大小设置为 128，优化求解器采用 Adam 算法。对训练数据进行 min-max 归一化处理，输入到 1DCNN-BiLSTM 模型中进行训练，训练迭代收敛的损失函数曲线和选线精度曲线如图 6 所示。1DCNN-BiLSTM 共迭代 400 次，当迭代 140 次后训练精度达到了 100%，损失函数值下降到 0.052。将测试集数据进行归一化处理输入到训练好的 1DCNN-BiLSTM 选线模型中进行测试，测试的选线精度达到了 100%，这说明本文所提的选线方法具备良好的故障选线性能。




Figure 6. Training iteration curve
图 6. 训练迭代曲线图

5.3. 算例对比

为验证 1DCNN-BiLSTM 模型的选线精度优势，选取了常用的机器学习方法和深度学习方法作为对比，相关选线方法介绍如下：

(1) SVM [16]

SVM 方法提取暂态零序电流的波形相似度、时频相似度等特征，并输入到 SVM 中实现故障选线。

(2) CNN [21]

CNN 方法采用连续小波变换获取暂态零序电流的时频矩阵输入到 CNN 网络中实现故障选线，选取 db5 小波作为小波基函数。

(3) 1DCNN-LSTM

在 1DCNN-LSTM 方法中，LSTM 和本文所提方法 1DCNN-BiLSTM 使用相同的参数，有 32 个隐藏节点，采用相同的学习率、批大小、损失函数、优化求解器和输入。

不同方法的选线结果如表 4 所示。

Table 4. Results of different route selection methods

表 4. 不同选线方法的选线结果

选线方法	SVM	CNN	1DCNN-LSTM	1DCNN-BiLSTM
选线精度/%	86.10	95.83	99.84	100

由表 4 可知，1DCNN-BiLSTM 的选线精度均高于其他选线方法。相比于 SVM、选线 CNN 方法，本文所提方法能避免信号处理方法提取故障特征不充分的问题，直接从序列融合特征向量中提取故障特征提高选线精度。相比 1DCNN-LSTM 选线方法，本文所提方法中的 BiLSTM 能更好地分析数据的内部特征以及数据前后之间的关联性，具有优于 LSTM 的选线性能。

为验证所提方法的抗噪声能力，对测试集数据叠加信噪比(Signal-to-Noise Ratio, SNR)不同的高斯白噪声，所有模型均运行 10 次，取平均选线精度作为评价指标，不同方法的平均选线精度如图 7 所示。




Figure 7. Average line selection accuracy of different methods

图 7. 不同方法的平均选线精度

由图 7 可知，在测试集中叠加不同的高斯白噪声，1DCNN-BiLSTM 的平均选线精度明显高于其他三种方法。

6. 结论

本文提出了一种 1DCNN-BiLSTM 的故障选线方法，通过仿真实验，得到以下结论：

- (1) 序列特征融合方法能突出显示故障线路的幅值特征, 有助于 1DCNN-BiLSTM 模型的学习。
- (2) 1DCNN-BiLSTM 模型具有同时学习序列特征向量的局部特征和上下文依赖关系的优点, 能有效提高故障选线精度。
- (3) 与其他选线方法相比, 具有较高的选线精度和较强的噪声鲁棒性。

参考文献

- [1] 张家康. 基于 1DCNN-LSTM 的谐振接地系统故障选线技术研究[D]: [硕士学位论文]. 焦作: 河南理工大学, 2023.
- [2] Zeng, X.D., Guo, M.F. and Chen, D.Y. (2017) Machine-Learning-Based Single-Phase-to-Ground Fault Detection in Distribution Systems. 2017 *IEEE Conference on Energy Internet and Energy System Integration (EI2)*, Beijing, 26-28 November 2017, 1-6. <https://doi.org/10.1109/EI2.2017.8245233>
- [3] Wei, K., Zhang, J., He, Y., Yao, G. and Zhang, Y. (2020) Faulty Feeder Detection Method Based on VMD FFT and Pearson Correlation Coefficient of Non-Power Frequency Component in Resonant Grounded Systems. *Energies*, **13**, 4724. <https://doi.org/10.3390/en13184724>
- [4] 田晶京, 耿芳, 赵峰, 等. 谐振接地系统的配电线路接地故障选线新方法[J]. 重庆大学学报, 2022, 45(1): 59-67.
- [5] 魏科文, 张靖, 何宇, 等. 基于 VMD 和相关性聚类的谐振接地系统单相接地故障选线[J]. 电力系统保护与控制, 2021, 49(22): 105-113.
- [6] 蔡军, 周波, 黄跃, 等. 基于 S 变换时频特性的谐振接地系统故障选线新方法[J]. 电力科学与技术学报, 2022, 37(3): 109-116.
- [7] 张祚溟, 王利恒. 基于小波分析和 GA-SVM 的小电流接地故障选线方法[J]. 自动化与仪表, 2021, 36(8): 8-12+23.
- [8] 雷静, 李晨婧, 郭亮, 等. 基于 GAF 与卷积神经网络的配电网故障选线新方法[J]. 电力系统及其自动化学报, 2023, 35(2): 53-62.
- [9] 翟二杰, 舒征宇, 汪俊, 等. 基于 VMD-LSTM 的小电流接地系统故障选线方法[J]. 电工电能新技术, 2021, 40(1): 70-80.
- [10] 殷浩然, 苗世洪, 郭舒毓, 等. 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[J]. 电力自动化设备, 2021, 41(7): 88-96.
- [11] 刘会家, 肖懂, 滕杰, 等. 基于 CBAM-ResNet 和多域特征融合的配电网故障选线方法[J]. 国外电子测量技术, 2023, 42(8): 10-18.
- [12] 邓志祥, 潘建兵, 黄灿英, 等. 基于傅里叶变换与最大关联距离相结合的配电网故障选线新方法[J]. 电网与清洁能源, 2022, 38(4): 95-103.
- [13] 马如伟. 含有分布式电源的配电网故障检测与识别研究[D]: [硕士学位论文]. 西安: 西安理工大学, 2018.
- [14] Lu, Z., et al. (2003) Feature Fusion: Parallel Strategy vs. Serial Strategy. *Pattern Recognition*, **36**, 1369-1381.
- [15] 聂祥论, 张靖, 何宇, 等. 基于序列特征融合和深度置信网络的配网故障选线方法[J]. 电网与清洁能源, 2023, 39(5): 66-75+84.
- [16] Guo, M., Zeng, X., Chen, D. and Yang, N. (2018) Deep-Learning-Based Earth Fault Detection Using Continuous Wavelet Transform and Convolutional Neural Network in Resonant Grounding Distribution Systems. *IEEE Sensors Journal*, **18**, 1291-1300. <https://doi.org/10.1109/JSEN.2017.2776238>
- [17] Wei, X., Yang, D., Wang, X., et al. (2021) Faulty Feeder Detection Based on Fundamental Component Shift and Multiple-Transient-Feature Fusion in Distribution Networks. *IEEE Transactions on Smart Grid*, **12**, 1699-1711. <https://doi.org/10.1109/TSG.2020.3026390>
- [18] 魏佳恒, 郭惠勇. 基于贝叶斯优化 BiLSTM 模型的输电塔损伤识别[J]. 振动与冲击, 2023, 42(1): 238-248.
- [19] Zhang, D.D., Chen, B.A., Zhu, H.Y., et al. (2023) Short-Term Wind Power Prediction Based on Two-Layer Decomposition and BiTCN-BiLSTM-Attention Model. *Energy*, **285**, Article ID: 128762. <https://doi.org/10.1016/j.energy.2023.128762>
- [20] 李东洋, 吕明泽, 郭艳蓉, 等. ALO 优化下 1DCNN-BiLSTM-Attention 锂电池 SOH 预测[J]. 电工技术, 2023(4): 33-40.
- [21] 郝帅, 张旭, 马瑞泽, 等. 基于改进 GoogLeNet 的小电流接地系统故障选线方法[J]. 电网技术, 2022, 46(1): 361-368.