

基于二维灰度图与CNN-GRU的单相接地故障选线方法

胡祥谢¹, 聂祥论², 谢宪源³

¹贵州大学电气工程学院, 贵州 贵阳

²贵州电网有限责任公司毕节供电局, 贵州 毕节

³贵州乌江清水河水电开发有限公司, 贵州 贵阳

收稿日期: 2024年12月7日; 录用日期: 2024年12月30日; 发布日期: 2025年1月6日

摘要

针对配电网单相接地故障特征提取困难和现有检测方法精度低的问题, 本文提出一种基于原始数据生成的二维灰度图和CNN-GRU的故障选线方法。首先, 获取原始的电流波形进行截取并生成二维灰度图, 以有效地保留明显而全面的故障特征原始信息; 然后, CNN自适应提取时频灰度图像的局部特征, GRU从CNN层学习到的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。仿真结果表明, 本文所提方法的选线准确率为99.41%, 与现有方法相比准确率更高。

关键词

故障选线, 卷积神经网络, 循环神经网络

Single-Phase Ground Fault Line Selection Method Based on Two-Dimensional Grayscale Image and CNN-GRU

Xiangxie Hu¹, Xianglun Nie², Xianyuan Xie³

¹School of Electrical Engineering, Guizhou University, Guiyang Guizhou

²Bijie Power Supply Bureau of Guizhou Power Grid Co., Ltd., Bijie Guizhou

³Guizhou Wujiang Qingshui River Power Development Co., Ltd., Guiyang Guizhou

Received: Dec. 7th, 2024; accepted: Dec. 30th, 2024; published: Jan. 6th, 2025

Abstract

Aiming at the difficulty of single-phase grounding fault feature extraction in distribution network

文章引用: 胡祥谢, 聂祥论, 谢宪源. 基于二维灰度图与 CNN-GRU 的单相接地故障选线方法[J]. 建模与仿真, 2025, 14(1): 1-10. DOI: 10.12677/mos.2025.141001

and the low accuracy of existing detection methods, this paper proposes a fault line selection method based on two-dimensional grayscale generated by original data and CNN-GRU. Firstly, the original current waveform is obtained and intercepted to generate a two-dimensional grayscale image, so as to effectively retain the obvious and comprehensive original information of fault characteristics. Then, CNN adaptively extracts the local features of the time-frequency grayscale image, and GRU learns the context dependency from the local features learned by the CNN layer. Finally, the fault line selection is realized through the SoftMax layer. The simulation results show that the accuracy of the proposed method is 99.41%, which is higher than that of the existing methods.

Keywords

Fault Line Selection, Convolutional Neural Network, Recurrent Neural Network

Copyright © 2025 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

电力网络的结构正日益复杂化,这是由于电缆接入和用户数量的增加所引起的。这种复杂性对于提升电力网络的稳定性和安全性提出了迫切的需求。在整个电力系统中,配电系统作为连接电力公司和用户的末端环节,其安全性和可靠性显得尤为重要。然而,配电网络的供电可靠性面临着多种故障的挑战,其中单相接地故障是最为普遍的,据研究统计占据了所有故障的 80% [1]。一旦发生故障,故障线路的选择成为进一步服务(如故障定位和隔离)的基础。谐振接地系统中的故障条件复杂,故障电流容易受到噪声等因素的影响[2]。这表明,提出高效准确的故障检测对于保持配电网络长期可靠性和稳定性至关重要。

当故障条件或网络结构发生变化时,传统的故障检测方法的性能会显著下降,这就导致了馈线检测的误差。为了解决传统相位检测方法的无效性,专家学者们提出了利用深度学习进行故障识别。卷积神经网络(CNN)可以融合多种故障特征,提高检测精度。文献[3]应用人工神经网络和深度学习技术自动提取和处理故障特征。简化了故障分类过程,证明了深度学习技术在准确分类故障线路方面的有效性。本文提出了一种基于原始数据的二维灰度图和 CNN-GRU 的选线方法,能在一定程度上提高单相接地故障选线准确率的方法,这能为配电网的稳定性和安全性提供更多保障。

2. 二维灰度图的生成原理

基于完整原始数据的直接数据挖掘和深度学习势必会简化分类算法的设计难度,提高识别的准确率。为了充分发挥 CNN 对小电流接地系统故障检测的最佳性能,应提出一种故障电流图像生成与组合方法,将三相电流信号的信息完整地以图像的形式呈现出来。因此,本文提出基于原始电流数据生成二维灰度图,这样可以避免经数字信号处理后造成数据的缺失,有效地保留了数据的完备性,从而提升故障选线精度。具体实现步骤如图 1 所示:

步骤 1: 截取不同故障类型下的原始电流波形;

步骤 2: 提取的电流信号的 256 个采样点,并将其分为 16 段,每段 16 个采样点;

步骤 3: 将每一时相的电流段按时间顺序分段,自上而下拼接成 16×16 的二维灰度图。

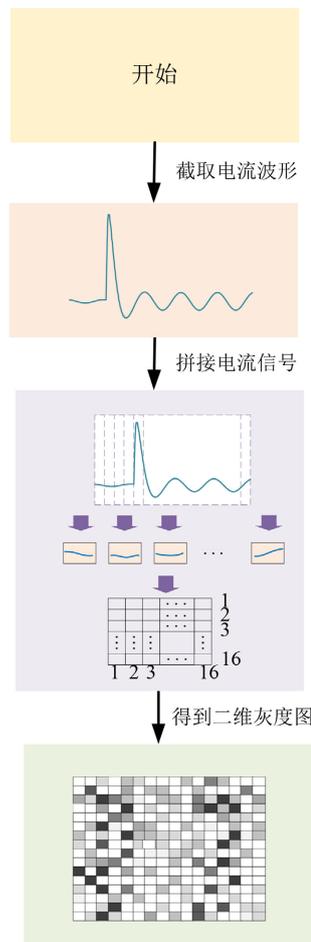


Figure 1. Generation principle of two-dimensional gray image
图 1. 二维灰度图生成原理

3. CNN-GRU 神经网络

3.1. CNN

本文提出的 CNN-GRU 网络中的 CNN 层作为局部特征提取器[4]。由 CNN 层组成的局部特征提取模块如图 2 所示。

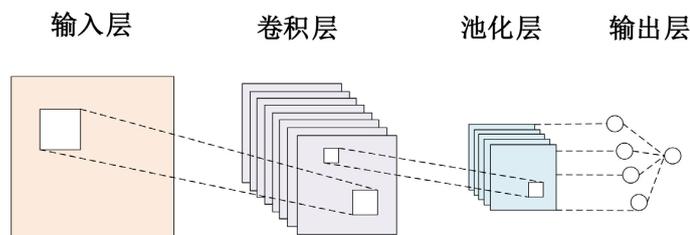


Figure 2. Local feature extraction module
图 2. 局部特征提取模块

设输入信号为 $x(i, j)$ ，则将信号 $x(i, j)$ 与大小为 $a \times b$ 的卷积核 $w(i, j)$ 卷积，即可得到结果 $z(i, j)$ 。

$$z(i, j) = x(i, j) * w(i, j) = \sum_{s=-a}^a \sum_{t=-b}^b x(s, t) \cdot w(i-s, j-t) \quad (1)$$

然后将卷积后的特征输入到 BN 层中，BN 层对每一批次上一层的激活进行归一化。BN 层采用保持卷积特征均值接近于零，卷积特征方差接近于 1 的变换。当归一化后的特征输入到激活层时，输出特征可以表示为

$$z_i^l = f \left(\text{BN} \left(b_i^l + \sum_j z_j^{l-1} * w_{ij}^l \right) \right) \quad (2)$$

式中， z_i^l 和 z_j^{l-1} 分别表示第 l 层的第 i 个输出特征和第 l 层的第 j 个输入特征； w_{ij}^l 表示第 i 个和第 j 个特征之间的卷积核，函数 $\text{BN}(\cdot)$ 对卷积层学习到的特征进行归一化处理， $f(\cdot)$ 表示激活函数，本文选择 Rule 函数。

然后将特征传递到最大池化层。池化层执行非线性下采样功能，降低特征的分辨率。最大池化层产生的特征可以表示为

$$z_k^l = \max_{p \in \Omega_k} z_p^l \quad (3)$$

其中， Ω_k 表示索引为 k 的池化区域， z_k^l 和 z_p^l 表示索引为 k 和 p 的第 l 个最大池化层的输出和输入特征。

3.2. GRU

LSTM 和 GRU 都属于广泛使用的循环神经网络(RNN) [5]。这种网络的特点是一组输入序列的输出与前一时刻的隐藏层状态相关，因此广泛用于处理与时间序列相关的数据[6] [7]。GRU 是 LSTM 的一种变体，它基于 LSTM 模型将“遗忘门”、“输入门”和“输出门”简化为“更新门”和“重置门”，同时在保证原始性能的基础上加速了模型的计算速度[8] [9]。GRU 的神经结构如图 3 所示。

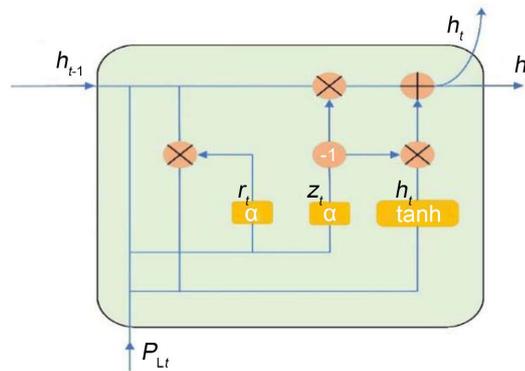


Figure 3. GRU neuron structure
图 3. GRU1 神经元结构

其中， α 代表 Sigmoid 激活函数， \tanh 代表 tanh 激活函数。 -1 表示由 $1 - z_t$ 向前传输的数据； z_t 和 r_t 分别表示更新门和重置门； P_{L_t} 代表输入； h_t 表示隐含层的输出。GRU 的内部计算结构满足以下公式：

$$\begin{aligned} z_t &= \alpha(W^{(z)} P_{L_t} + U^{(z)} h_{t-1}) \\ r_t &= \alpha(W^{(r)} P_{L_t} + U^{(r)} h_{t-1}) \\ \tilde{h}_t &= \tanh(r_t \odot U h_{t-1} + W P_{L_t}) \\ h_t &= (1 - z_t) \odot \tilde{h}_t + z_t h_{t-1} \end{aligned} \quad (4)$$

其中, \tilde{h}_i 是输入 P_L 和上一隐含层状态 P_L 的汇总; $U^{(z)}$ 、 $U^{(r)}$ 、 U 、 $W^{(z)}$ 、 $W^{(r)}$ 、 W 均为可训练参数矩阵; \odot 表示向量中按元素相乘。

3.3. CNN-GRU

卷积神经网络只能提取图像的局部特征,无法学习时频矩阵中的上下文依赖关系,而 GRU 网络可以弥补卷积神经网络的不足。为此,本文提出了一种基于 CNN-GRU 神经网络的故障选线模型[10]。首先,CNN 层自适应提取二维灰度图像的局部特征;然后,GRU 层再从 CNN 层学到的局部特征中学习上下文依赖关系,用以提高故障选线精度。本文使用的 CNN-GRU 模型如图 4 所示。

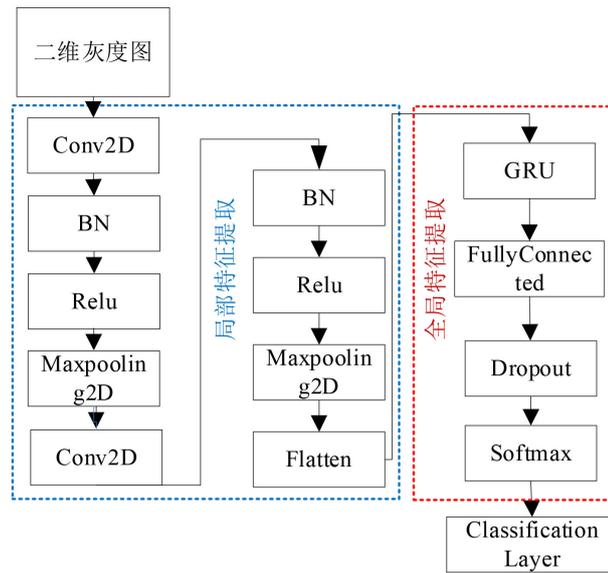


Figure 4. CNN-GRU model
图 4. CNN-GRU 模型

全连接层将 GRU 学习到的特征扩展成列向量,并将其输入 softmax 层。对应当前的样本,计算出的每种类型的概率为:

$$p_i = \text{softmax}(z)_i = \frac{\exp(z_i)}{\sum_i \exp(z_i)} \quad (5)$$

$$z_i = \sum_j h_j W_{ji} \quad (6)$$

式中,其中 z_i 是 softmax 的输入, h_j 是倒数第二层的激活, W_{ji} 是连接倒数第二层和 softmax 层之间的权重。

因此,预测标签 \hat{y} 为

$$\hat{y} = \arg \max_i p_i \quad (7)$$

4. 基于二维灰度图和 CNN-GRU 的故障线路检测

本文提出的二维灰度图和 CNN-GRU 故障线检测方法流程如图 5 所示。传统数字信号处理方式会使得故障特征在提取时丢失部分数据,而获取基于原始数据的二维灰度图,可以保证故障特征的完备性;卷积神经网络只能提取时频图像的局部特征,无法学习时频矩阵中的上下文依赖关系,而 GRU 网络可以弥补卷积神经网络的不足。从而提升了选线的精度。GRU-CNN 具体步骤如下:

- 1) 搭建 10kV 配网系统模型，改变模型的故障相角、故障电阻和故障距离，获取故障线路和非故障线路的暂态零序电流。
- 2) 采集电流波形，采样点 256 个，获取其对应的二维灰度图，图像大小为 16×16 ，从而得到故障数据集，并分为训练集和测试集。
- 3) 将训练集的二维灰度图像输入 CNN-GRU 模型进行训练，得到故障选线模型。
- 4) 最后实现故障线检测。

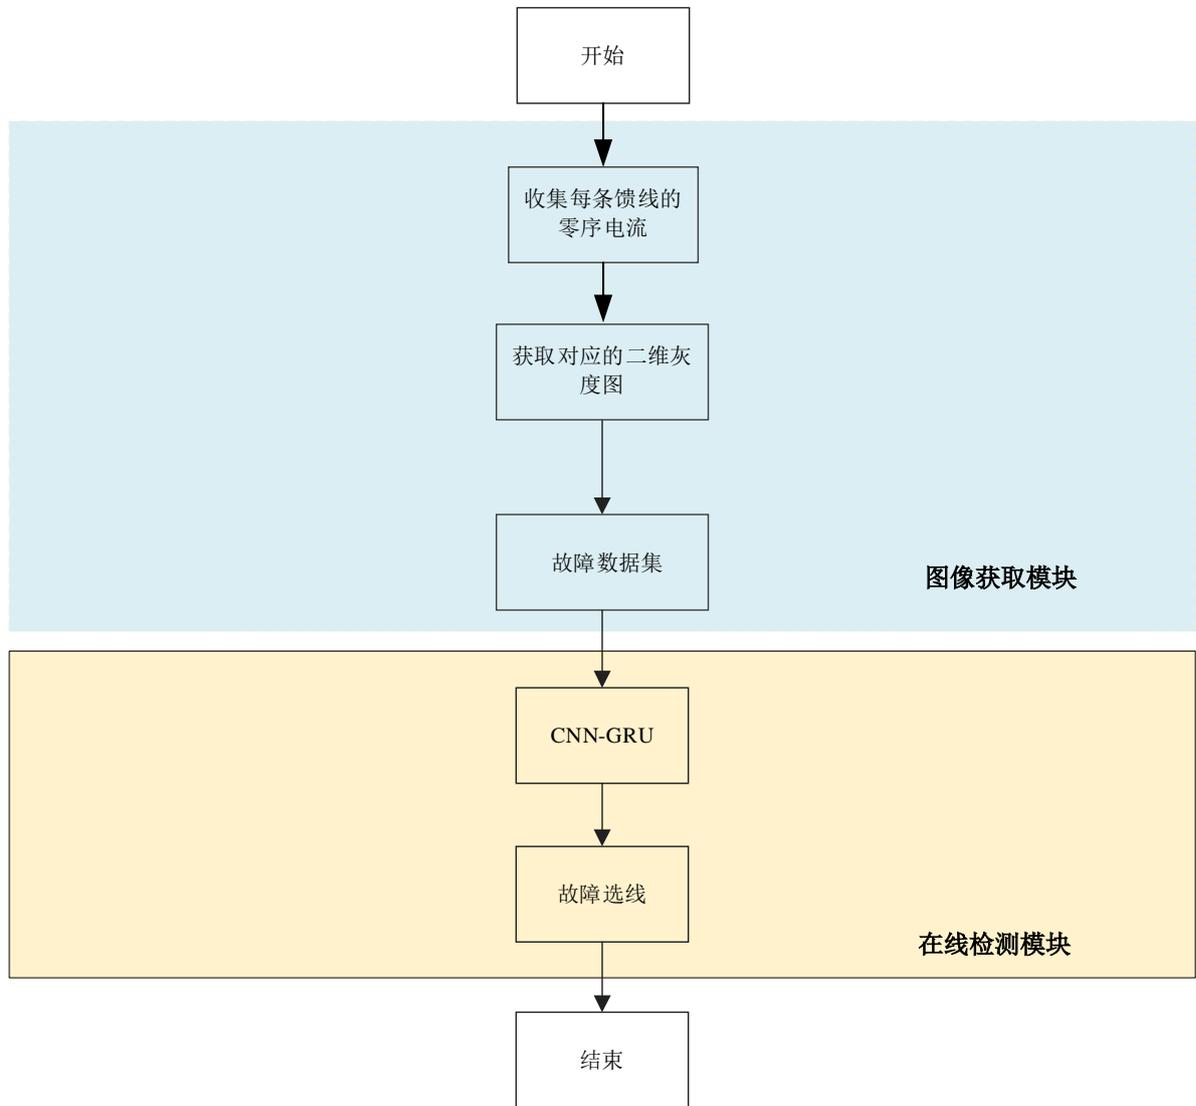


Figure 5. Flow chart
图 5. 流程图

5. 仿真分析

在 Intel(R) Core(TM)i7-9700CPU, 3.00 GHz 硬件条件下，使用 Matlab R2022b 软件在计算机上测试所有模型的性能。模型参数设置：初始学习率为 0.01，历元数为 100 次。学习率每 20 个历元乘以 0.5，并在每个历元中重新随机化样本。MiniBatchSize 为 256，优化求解器采用 sdgm 算法。

5.1. 仿真模型的构建

本文在 MATLAB/SIMULINK 上搭建小电流接地仿真系统，仿真模型如图 6 所示。其中， O_L 表示架空线路长度， C_L 表示电缆线路长度，消弧线圈补偿度为 5%，采样率为 6.4 kHz。

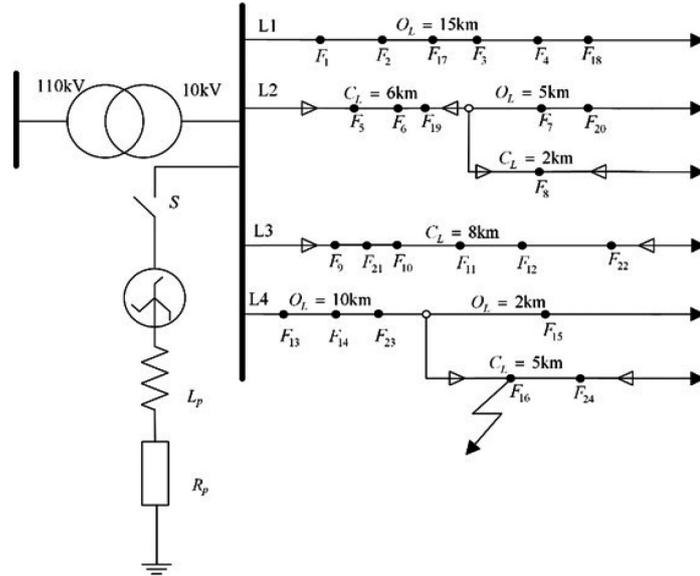


Figure 6. Distribution network grounding simulation diagram
图 6. 配电网接地仿真图

5.2. 数据集的获取

为获得故障数据集，分别对电网电压、接地电阻、故障初始角和故障距离进行仿真。训练集参数设置为：电压为 9.5kV、10kV、10.5 kV，故障类型为 AG、BG、CG，故障相角为 0°、30°、45°、60°、90°，过渡电阻为 1Ω、50Ω、100Ω、200Ω、500Ω、1000Ω、1500Ω、2000Ω，故障位置 16 种情况，样本总数为 23,040 个，其中故障样本 5760 个，非故障样本 17,280 个。测试集参数设置为：电压为 10kV，故障类型为 AG、BG、CG，故障相角为 20°、40°、50°、70°、80°，过渡电阻为 1Ω、300Ω、800Ω、1200Ω、2000Ω、3000Ω，故障位置 8 种情况，样本总数 2880 个，其中故障样本 720 个，非故障样本 2160 个(表 1)。

Table 1. Data set parameters

表 1. 数据集参数

	参数	数值	样本数量
训练集	电压/kV	9.5, 10.0, 10.5	
	故障类型	A-G, B-G, C-G	
	故障相角/°	0, 30, 45, 60, 90	5760
	故障电阻/Ω	1, 50, 100, 200, 500, 1000, 1500, 2000	
	故障位置	$F_1 \sim F_{16}$	
测试集	电压/kV	10.0	
	故障类型	A-G, B-G, C-G	
	故障相角/°	20, 40, 50, 70, 80	720
	故障电阻/Ω	10, 300, 800, 1200, 2000, 3000	
	故障位置	$F_{17} \sim F_{24}$	

5.3. 模型的训练和测试

将二维灰度图像作为 CNN-GRU 网络的输入，并对网络进行训练。训练迭代结果如图 7 所示。

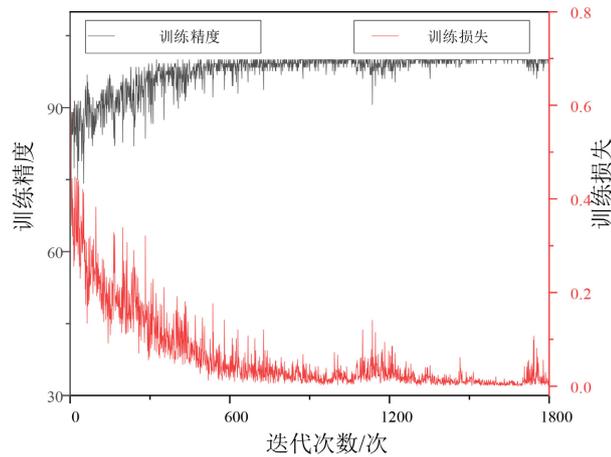


Figure 7. Training iteration diagram
图 7. 训练迭代图

从图 7 可以看出，经过 1800 次迭代训练后，模型的训练准确率达到 100%，损失为 0.0053。将 5.2 节中的 2880 个测试样本输入训练好的 CNN-GRU 中进行测试，选线正确率为 99.41%。这说明本文提出的故障线检测方法具有较高的选线准确率。

5.4. 方法适应性比较

为了进一步体现本文方法的有效性，使用 CNN 和 CNN-LSTM 与本文中提出的网络进行比较，其中表 2 展示了无噪声情况下的比较结果，而图 8 展示了有噪声情况下的比较结果。

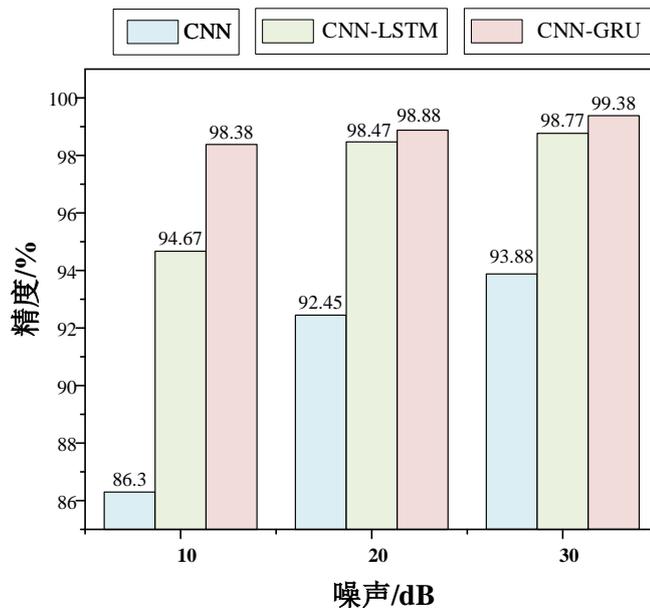


Figure 8. Feeder detection results under different noises
图 8. 不同噪声下馈线检测结果

由表 2 可以看出, 本文提出的 CNN-GRU 方法的准确率比 CNN-LSTM 的准确率高 0.51, 比无噪声 CNN 的准确率高 5.49。

Table 2. Feeder detection results of different methods without noise

表 2.1 无噪声下不同方法的馈线检测结果

类型	精度/%
CNN-LSTM	98.89
CNN-GRU	99.41
CNN	93.92

从图 8 可以看出, 在噪声为 10 dB 的情况下, 本文提出的 CNN-GRU 方法的精度比 CNN-LSTM 高 3.71, 比 CNN 高 12.08; 在 20 dB 噪声情况下, 本文提出的 CNN-GRU 方法的精度比 CNN-LSTM 高 0.41, 比 CNN 高 6.43; 在噪声为 30 dB 的情况下, 本文提出的 CNN-GRU 方法的精度比 CNN-LSTM 高 0.61, 比 CNN 高 5.5。

6. 结论

本文提出了一种基于二维灰度图和 CNN-GRU 的故障选线方法。具体工作内容如下:

1) 搭建 10 kV 配网系统模型, 改变模型的故障相角、故障电阻和故障距离, 获取故障线路和非故障线路的暂态零序电流;

2) 基于原始电流波形, 截取 256 个采样点, 拼接为 16×16 的二维灰度图, 保留了具有完备性的故障特征, 以便利用神经网络在图像识别方面的优势;

3) 搭建了 CNN-GRU 网络模型。GRU 网络可以弥补卷积神经网络的不足, 从而提升了选线的精度。

综上, 本文提出了一种基于原始数据的二维灰度图和 CNN-GRU 的故障线检测方法。通过建立谐振接地系统模型, 设置各种类型的故障情况, 截取零序电流波形, 获得其对应的二维灰度图像, 获取故障数据集并输入 CNN-GRU 网络, 最后得到选线结果。结果表明, 本文所提方法能有效提高选线精度, 且不易受接地电阻和故障相角等因素的影响。

参考文献

- [1] Hao, B. (2022) Single-Phase Grounding Fault Line Selection Method Based on Zero-Sequence Current Increment. *Energy Reports*, **8**, 305-312. <https://doi.org/10.1016/j.egyvr.2021.11.196>
- [2] Guo, M., Chen, D.Y. and Gao, J. (2021) Fault Line Detection Using Waveform Fusion and One-Dimensional Convolutional Neural Network in Resonant Grounding Distribution Systems. *CSEE Journal of Power and Energy Systems*, **7**, 250-260.
- [3] Yuan, J. and Jiao, Z. (2022) Faulty Feeder Detection Based on Image Recognition of Current Waveform Superposition in Distribution Networks. *Applied Soft Computing*, **130**, Article ID: 109663. <https://doi.org/10.1016/j.asoc.2022.109663>
- [4] Gao, J., Guo, M. and Chen, D.Y. (2021) Fault Line Detection Using Waveform Fusion and One-dimensional Convolutional Neural Network in Resonant Grounding Distribution Systems. *CSEE Journal of Power and Energy Systems*, **7**, 11.
- [5] Wang, X., Zhou, P., Peng, X., *et al.* (2022) Fault Location of Transmission Line Based on CNN-LSTM Double-Ended Combined Model. *Energy Reports*, **8**, 781-791. <https://doi.org/10.1016/j.egyvr.2022.02.275>
- [6] Ullah, A., Muhammad, K., Ding, W., *et al.* (2021) Efficient Activity Recognition using Lightweight CNN and DS-GRU Network for Surveillance Applications. *Applied Soft Computing*, **103**, Article ID: 107102. <https://doi.org/10.1016/j.asoc.2021.107102>
- [7] Principi, E., Rossetti, D., Squartini, S., *et al.* (2019) Unsupervised Electric Motor Fault Detection by Using Deep Autoencoders. *IEEE/CAA Journal of Automatica Sinica*, **6**, 441-451.

<https://doi.org/10.1109/JAS.2019.1911393>

- [8] Chung, J., Gulcehre, C., Cho, K.H., *et al.* (2014) Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. arXiv: 1412.3555v1.
- [9] Taheri, B., Salehimehr, S. and Sedighizadeh, M. (2021) A Fault-Location Algorithm for Parallel Line Based on the Long Short-Term Memory Model Using the Distributed Parameter Line Model. *International Transactions on Electrical Energy Systems*, **31**, e13032. <https://doi.org/10.1002/2050-7038.13032>
- [10] Gupta, D., Lenka, P., Bedi, H., *et al.* (2017) Auto Analysis of Customer Feedback using CNN and GRU Network. arXiv: 1710.04600.