

# 基于CWT-CBAM-CNN的配网接地故障选线方法

胡祥谢<sup>1</sup>, 聂祥论<sup>2</sup>, 谢宪源<sup>3</sup>

<sup>1</sup>贵州大学电气工程学院, 贵州 贵阳

<sup>2</sup>贵州电网有限责任公司毕节供电局, 贵州 毕节

<sup>3</sup>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

针对配网单相接地故障特征提取困难, 且现有选线方法选线精度不高的问题, 提出了一种连续小波变换(continuous wavelet transform, CWT)和CBAM-CNN的故障选线方法。首先, 对零序暂态电流进行连续小波变换获取对应的时频灰度图像; 然后, 构建了融合CBAM的CNN故障检测模型, 使模型更加关注有效信息。仿真结果表明, 所提方法的选线精度为99.45%, 与CNN相比, 具有较强的鲁棒性。

## 关键词

故障选线, 连续小波变换, 卷积神经网络, 特征提取

# Distribution Network Grounding Fault Line Selection Method Based on CWT-CBAM-CNN

Xiangxie Hu<sup>1</sup>, Xianglun Nie<sup>2</sup>, Xianyuan Xie<sup>3</sup>

<sup>1</sup>School of Electrical Engineering, Guizhou University, Guiyang Guizhou

<sup>2</sup>Bijie Power Supply Bureau of Guizhou Power Grid Co., Ltd., Bijie Guizhou

<sup>3</sup>Guizhou Wujiang Qingshuihe Hydropower Development Co., Ltd., Guiyang Guizhou

Received: Dec. 7<sup>th</sup>, 2024; accepted: Dec. 30<sup>th</sup>, 2024; published: Jan. 6<sup>th</sup>, 2025

## Abstract

Aiming at the problem that the fault feature extraction of single-phase grounding fault in distribution network is difficult and the accuracy of fault line selection is not high, a fault line selection method based on continuous wavelet transform (CWT) and CBAM-CNN is proposed. Firstly, the corresponding

文章引用: 胡祥谢, 聂祥论, 谢宪源. 基于 CWT-CBAM-CNN 的配网接地故障选线方法[J]. 建模与仿真, 2025, 14(1): 31-38. DOI: 10.12677/mos.2025.141004

time-frequency gray image is obtained by continuous wavelet transform of zero-sequence transient current. Then, a CNN fault phase detection model with CBAM is constructed, which makes the model pay more attention to effective information. The simulation results show that the line selection accuracy of the proposed method is 99.45%. Compared with CNN, it has strong robustness.

## Keywords

Fault Line Selection, Continuous Wavelet Transform, Convolutional Neural Network, Feature Extraction

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

配电系统是连接电力公司和用户的最后一环。许多客户感知的故障通常发生在配电系统中，因此配电系统的可靠性至关重要。配网的供电可靠性受到各种故障的挑战，其中接地故障最为普遍，占所有故障的 80% [1]。当故障发生时，故障选线是进一步进行故障定位、隔离和恢复服务的基础[2]。针对谐振接地系统故障情况复杂，且故障电流易受噪声等因素的影响，快速准确的故障选线对配网长期可靠稳定运行具有重要意义。

配网发生单相接地故障时，故障线路暂态零序电流比稳态零序电流大数倍[3]，包含丰富的故障信息。许多基于暂态零序电流特征的选线方法被提出。传统方法大多是基于支持向量机、BP 神经网络的选线方法，依赖于人工经验提取暂态电流的故障特征，获取的特征往往表现出强烈的不确定性和随机性，很难适用于所有故障条件下，尤其是极端故障条件，如高阻抗和强烈的噪音。

为此，本文提出了一种基于连续小波变换和 CBAM-CNN 的故障选线方法。首先，对零序暂态电流进行连续小波变换获取对应的时频灰度图像；然后，构建了融合 CBAM 的 CNN 故障相检测模型，使模型更加关注有效信息。最后，通过仿真算例验证了所提方法的有效性。

## 2. 连续小波变换

连续小波变换是一种时频分析方法[4] [5]，该方法将信号分为不同的频率成分并通过相应的尺度对每个具有分辨率的成分进行评估。它可以在低频提供高频率分辨率和低时间分辨率，在高频提供高时间分辨率和低频率分辨率。由于配网系统发生单相接地故障时，零序电压对地电容的充放电将导致显著的暂态过程。含有多个高频分量的暂态信号可以反映各线路的故障特征。因此可通过 CWT 将暂态零序电流信号转化为时频域信号，获取暂态零序电流信号在局部时间段内的频率特性。

假设  $\psi(t) \in L^2(R)$  是一个平方积分函数，其傅里叶变换为  $\psi(\omega)$ ，并且  $\psi(\omega)$  满足条件：

$$C_\psi = \int_R \frac{|\psi(\omega)|^2}{|\omega|} d\omega < \infty \quad (1)$$

因此，将  $\psi(t)$  定义为母小波函数，对母小波函数  $\psi(t)$  进行伸缩和平移，可以得到一组小波基函数。连续小波变换的小波基函数为：

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (2)$$

式中,  $a, b \in R, a \neq 0$ ,  $a$  为尺度因子,  $b$  为平移因子。

零序暂态电流信号  $x(t)$  的连续小波变换定义为:

$$CWT_x(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt \quad (3)$$

本文选择 db5 作为小波基函数。各线路的零序电流采样频率为 6.4 kHz。当发生单相接地故障时, 采集各线路的前半周(64 个采样点)波形数据。对采集到的暂态零序电流进行连续小波变换获取对应的二维时频灰度图像。二维时频灰度图像的生成方法为:

1) 设定尺度因子  $a$ , 则  $a$  对应的实际频率为

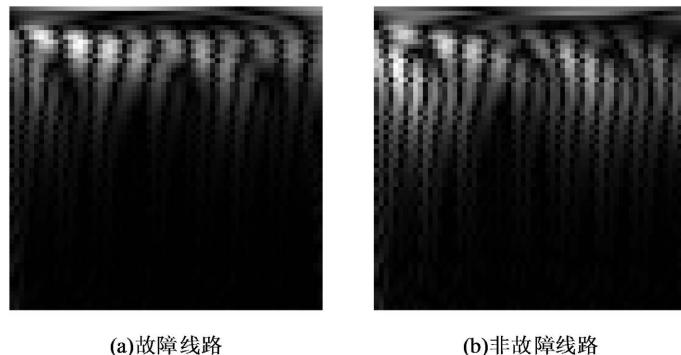
$$F_a = F_c * f_s / S \quad (4)$$

式中,  $F_c$  为小波的中心频率,  $f_s$  为零序暂态电流的采样频率。

2) 计算变换后的尺度序列  $C$

$$C = 2 * F_c * totalscal / num \quad (5)$$

式中,  $totalscal = 64$  表示为序列尺度长度,  $num$  为整数序列, 取值范围  $[1, totalscal]$ 。根据式(2)~(5)对暂态零序电流进行小波变换, 获取对应的时频灰度图像。根据以上方法获得的时频灰度图像如图 1 所示。



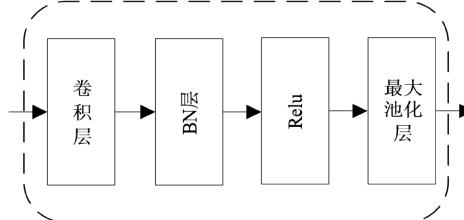
**Figure 1.** Gray image of time and frequency corresponding to faulty line and non-faulty line

**图 1.** 故障线路和非故障线路对应的时频灰度图像

### 3. CBAM-CNN

#### 3.1. CNN

本文所提 CNN-LSTM 网络中 CNN 层起到局部特征提取器的作用。由 CNN 层构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  $z(i, j)$ 。

$$\begin{aligned} z(i, j) &= x(i, j)^* w(i, j) \\ &= \sum_{s=-a}^a \sum_{t=-b}^b x(s, t) \cdot w(i-s, j-t) \end{aligned} \quad (6)$$

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

$$z_i^l = f \left( BN \left( b_i^l + \sum_j z_j^{l-1} w_{ij}^l \right) \right) \quad (7)$$

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  $BN(\cdot)$  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：

$$z_k^l = \max_{\forall p \in \Omega_k} z_p^l \quad (8)$$

其中， $\Omega_k$  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. CBAM

在传统 CNN 的特征提取过程中，图像各部分的特征提取权重是相等的。这阻碍了 CNN 集中于图像的有意义特征的能力，可能导致注意力集中在不相关的特征上。因此，这种情况增加了过拟合的风险，并在实际应用中降低了性能。为解决这个问题，有必要在卷积神经网络中引入一种专门的结构，称为“注意力”。基于 CNN 的原始特征提取过程，已经证明“注意力”的具体架构设计能够使 CNN 更专注于有意义的特征并抑制不必要的特征。

如图 3 所示，CBAM 模型包括空间注意力和通道注意力。这种设计能够让模型更专注于重要特征，而忽略无关的特征。首先，输入特征通过通道注意力模块进行处理。随后，加权输出经过空间注意力模块处理。最终结果通过加权获得。

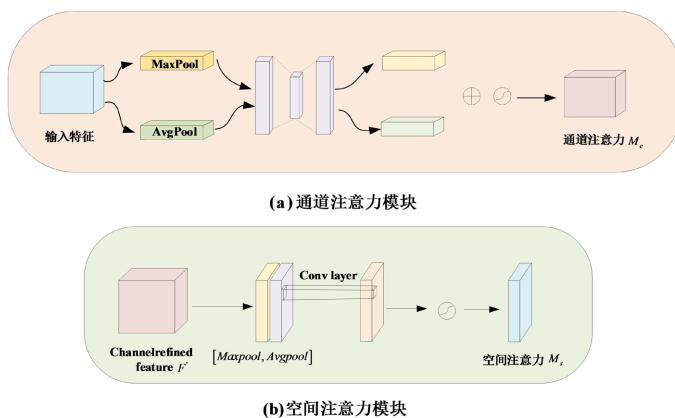


Figure 3. CBAM mode

图 3. CBAM 模型

### 3.3. CBAM-CNN 神经网络

为了实现更准确的故障选相, 本文构建了如图 4 所示的 CBAM-CNN 模型结构。该网络主要由卷积特征提取模块和注意力机制模块组成。首先, 通过图像输入层将故障特征图像输入到 CNN 模块中。然后, 经过 4 层卷积和池化后, 输入注意力机制模块, 通过注意力机制模块分配图像中不同区域的特征权重。最后, 通过全连接层将数据调整为指定格式, 再由 softmax 层输出分类结果。

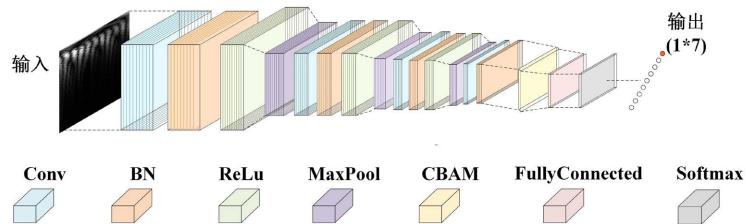


Figure 4. CBAM-CNN mode  
图 4. CBAM-CNN 模型

### 4. 基于 CWT-CBAM-CNN 的故障选线流程

为解决传统选线方法无法有效地聚焦于图像有意义特征, 可能会关注到不必要的特征从而导致神经网络性能下降这一缺点, 本文提出基于 CWT-CBAM-CNN 模型的选线方法, 可以通过融入注意力机制避免以上缺点, 从而达到提高选线精度的目的。流程如图 5 所示。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) 对采集到信号进行连续小波变换, 得到时频灰度图像, 图像大小为  $64 \times 64$ , 从而获取故障数据集, 并划分训练集和测试集。
- 3) 将训练集的时频灰度图像输入到 CBAM-CNN 模型中进行训练, 获取故障选线模型。
- 4) 最后实现故障选线。

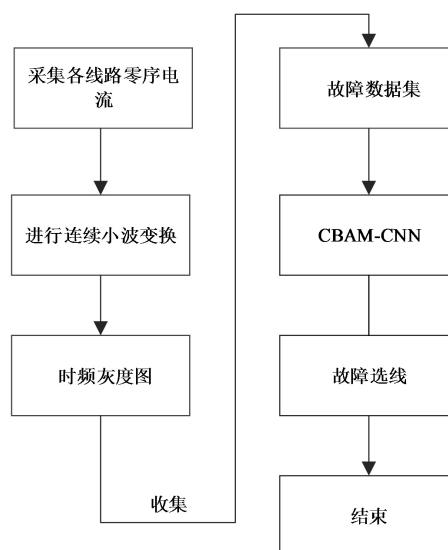


Figure 5. Flowchart of the proposed method  
图 5. 所提方法流程图

## 5. 仿真分析

在 Intel (R) Core (TM) i7-9700 CPU, 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. 仿真模型的搭建

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。

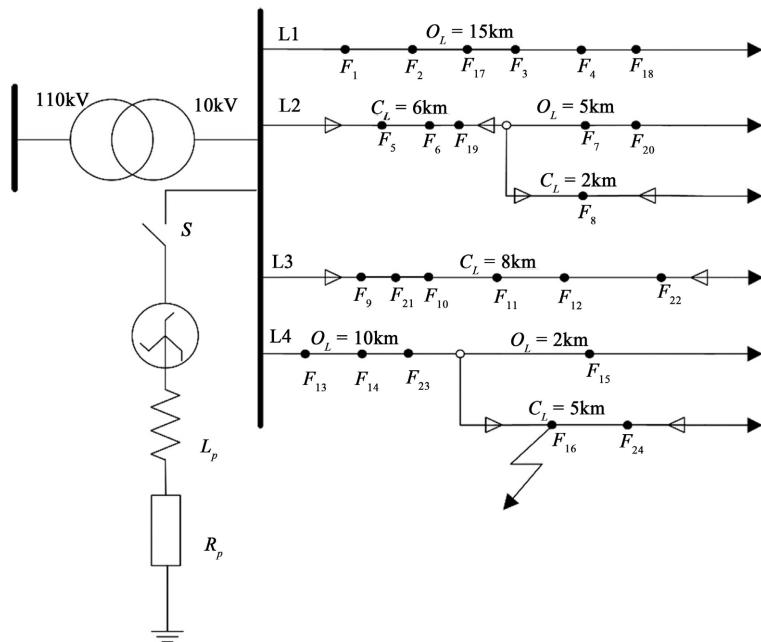


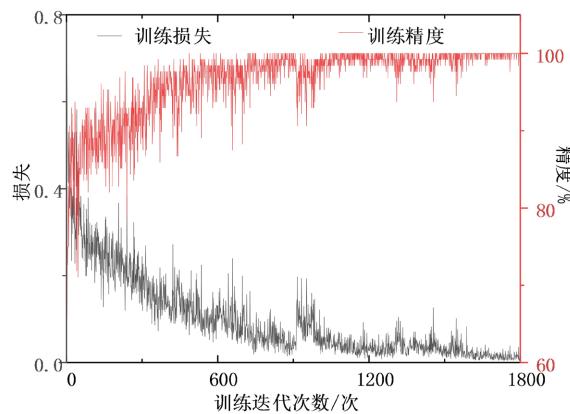
Figure 6. Distribution network grounding simulation diagram  
图 6. 配网接地仿真图

### 5.2. 数据集的获取

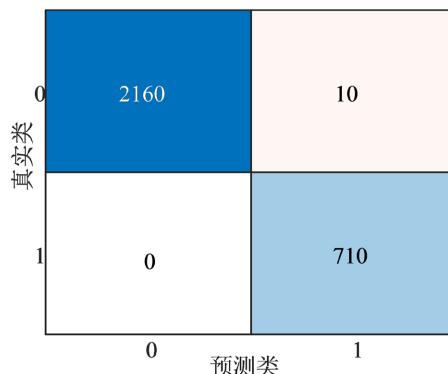
为获得故障数据集, 分别对电网电压、接地电阻、故障初始角和故障距离进行仿真。训练集参数设置为: 电压为 9.5 kV、10 kV、10.5 kV, 故障类型为 AG、BG、CG, 故障相角为 0°、30°、45°、60°、90°, 过渡电阻为 1 Ω、50 Ω、100 Ω、200 Ω、500 Ω、1000 Ω、1500 Ω、2000 Ω, 故障位置 16 种情况, 样本总数为  $3 \times 3 \times 5 \times 8 \times 16 \times 4 = 23040$  个, 其中故障样本 5760 个, 非故障样本 17,280 个。测试集参数设置为: 电压为 10 kV, 故障类型为 AG、BG、CG, 故障相角为 20°、40°、50°、70°、80°, 过渡电阻为 1 Ω、300 Ω、800 Ω、1200 Ω、2000 Ω、3000 Ω, 故障位置 8 种情况, 样本总数  $1 \times 3 \times 5 \times 8 \times 6 \times 4 = 2880$  个, 其中故障样本 720 个, 非故障样本 2160 个。

### 5.3. 模型的训练与测试

首先, 将 5.2 节获取的 5760 个样本进行连续小波获取对应的二维灰度图像, 并对其进行故障类型标记。然后, 将二维灰度图像作为 CBAM-CNN 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

由图 7 可知, 经过 1800 次迭代训练后, 模型的训练精度到达了 100%, 损失为 0.013。将 5.2 节的 2880 个测试样本输入到训练好的 CBAM-CNN 中进行测试, 对应测试集的混淆矩阵图如图 8 所示, 对应的选线正确率为 99.65%。这表明本文所提故障选线方法具有较高的选线正确率。

**Figure 8.** Confusion matrix diagram of the test sample**图 8.** 测试集的混淆矩阵图

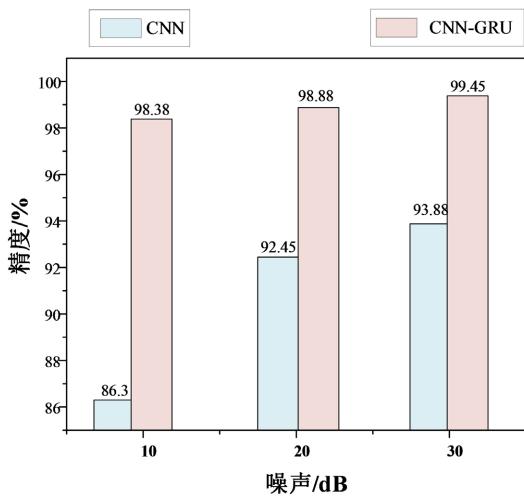
#### 5.4. 方法适应性对比

为了进一步体现本文方法的有效性, 使用 CNN 和 CBAM-CNN 与本文中提出的网络进行比较, 其中表 1 展示了无噪声情况下的比较结果, 而图 9 展示了有噪声情况下的比较结果。

**Table 1.** Noiseless feeder detection results using different methods  
**表 1.** 不同方法无噪声馈线检测结果

类型	精度/%
CBAM-CNN	99.45
CNN	93.92

由表 1 可以看出, 本文提出的 CBAM-CNN 方法的准确率比 CNN 的准确率高。这说明了所提选线方法具有较高的选线精度。



**Figure 9.** Feeder detection results of different methods with noise

**图 9. 不同噪声下馈线检测结果**

从图 9 可以看出, 在噪声为 10 dB 的情况下, 本文提出的 CBAM-CNN 方法的精度比 CNN 高 12.08; 在 20 dB 噪声情况下, 本文提出的 CBAM-CNN 方法的精度比 CNN 高 6.43; 在噪声为 30 dB 的情况下, 本文提出的 CBAM-CNN 方法的精度比 CNN 高 5.57。

## 6. 结论

本文提出了一种基于连续小波变换和 CBAM-CNN 的故障选线方法。具体工作内容如下:

- 1) 通过 Simulink 仿真平台建立了 4 条馈线的谐振接地系统模型, 设置各种类型的故障情况, 获取零序电流信号;
- 2) 通过小波变换获得零序暂态电流对应的时频灰度图像, 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) 在传统 CNN 模型的基础上, 融入了注意力机制, 搭建的 CBAM-CNN 模型能够关注有效信息, 有助于提高识别精度。将获取的故障数据集输入 CBAM-CNN 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] 鲁改凤, 化雨, 金小兵, 任志强. 小电流接地系统单相接地故障选线方法探究[J]. 电力系统保护与控制, 2010, 38(12): 44-49.
- [2] 李洋, 王彦卿, 张岩, 等. 小电流接地系统故障选线综述[J]. 中国标准化, 2016(13): 224+226.
- [3] 栾晓明, 武守远, 贾春娟, 等. 基于改进零序导纳法的单相接地故障选线原理[J]. 电网技术, 2022, 46(1): 353-360.
- [4] 薛蕙, 杨仁刚. 基于连续小波变换的非整数次谐波测量方法[J]. 电力系统自动化, 2003, 27(5): 49-53.
- [5] 常亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络[J]. 自动化学报, 2016, 42(9): 1300-1312.