

# 基于RGB图像生成的CNN-CBAM-BiLSTM 配网接地故障分类方法

聂祥论, 李义, 吴瑀, 刘庆, 申江兰, 蔡镫升, 李宇航, 马旭东, 毛业涛

贵州电网有限责任公司毕节供电局, 贵州 毕节

收稿日期: 2025年7月8日; 录用日期: 2025年7月28日; 发布日期: 2025年8月12日

## 摘要

准确地识别故障相是实现故障快速隔离、恢复的重要手段。为提高故障选相精度, 文章提出了基于RGB图像生成的CNN-CBAM-BiLSTM配网接地故障选相方法。首先利用序列-图像转换方法将馈线的三相电流转换为二维图像对应映射到R、G、B三通道生成RGB图像。然后将生成的RGB图像输入到CNN-CBAM-BiLSTM故障选相模型中, 利用CNN提取RGB图像的空间局部特征, 进一步利用CBAM自适应聚焦和挖掘RGB图像中蕴含的关键特征信息, 最后通过BiLSTM提取RGB图像的时序特征, 进而实现高精度的故障选相。仿真结果表明, 所提方法具有较高的选相精度, 且在网络拓扑和中性点运行方式改变情况下具有较强的鲁棒性。

## 关键词

故障选相, RGB图像生成, CBAM, 序列-图像转换方法, 特征提取

# CNN-CBAM-BiLSTM Distribution Network Ground Fault Classification Method Based on RGB Image Generation

Xianglun Nie, Yi Li, Yu Wu, Qing Liu, Jianglan Shen, Dengsheng Cai, Yuhang Li, Xudong Ma,  
Yetao Mao

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

Received: Jul. 8<sup>th</sup>, 2025; accepted: Jul. 28<sup>th</sup>, 2025; published: Aug. 12<sup>th</sup>, 2025

## Abstract

Accurately identifying the faulty phase is an important means to achieve rapid fault isolation and

文章引用: 聂祥论, 李义, 吴瑀, 刘庆, 申江兰, 蔡镫升, 李宇航, 马旭东, 毛业涛. 基于 RGB 图像生成的 CNN-CBAM-BiLSTM 配网接地故障分类方法[J]. 智能电网, 2025, 15(4): 73-81. DOI: 10.12677/sg.2025.154008

restoration. To improve the accuracy of fault phase selection, a CNN-CBAM-BiLSTM distribution network ground fault phase selection method based on RGB image generation is proposed in this paper. Firstly, the three-phase currents of the feeder are converted into two-dimensional images through a sequence-image conversion method and mapped to the R, G, and B three channels to generate RGB images. Then, the generated RGB images are input into the CNN-CBAM-BiLSTM fault phase selection model. The CNN is used to extract the spatial local features of the RGB images, and the CBAM is further utilized to adaptively focus and mine the key feature information contained in the RGB images. Finally, the BiLSTM is used to extract the temporal features of the RGB images, thereby achieving high-precision fault phase selection. Simulation results show that the proposed method has high phase selection accuracy and strong robustness under changes in network topology and neutral point operation mode.

## Keywords

Fault Phase Selection, RGB Image Generation, Convolutional Block Attention Module (CBAM), Sequence-Image Conversion Method, 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

随着配网规模的扩大以及对供电可靠性要求的提高，配电网故障的快速检测和准确定位成为确保电力系统稳定运行的关键。故障选相方法通过准确识别故障相，能够在故障发生后及时实现故障隔离和恢复，减少停电时间，提高电网的可靠性与运行效率。

如何在复杂的配网拓扑结构、各种类型的故障条件下，实现高效且精确的故障选相，成为当前研究的重点。文献[1]采用扩展 Prony 算法确定相电压的组距范围并结合贝塞尔公式求取各相电压的频数分布值，通过比较频数分布值的大小实现故障选相。文献[2]对故障附加状态的三相电流进行相空间重构，利用重构相轨迹图之间的差异进行故障选线。文献[3]对电压、电流故障分量进行分析，计算得到暂态能量比，进行阈值比较，实现故障选相。文献[4]分析注入电流与各相电压相位差异，对比电流电压特征相位差，进而实现高阻接地故障相识别。文献[5]对比健全相与故障相特征电流变化量辐角主值的特性差异实现故障选相。然而，在面对配网日益增加的复杂性和海量数据，基于简单线性模型和人工检测的传统电力系统保护方法性能有限[6]。随着配网数字化、智能化水平的提高，获取海量故障信息变得愈发容易。基于人工智能理论的方法越来越多地应用到故障诊断领域，其中包括支持向量机、人工神经网络、模糊神经网络、卷积神经网络、卷积深度置信网络等方法。文献[7]对三相电流的故障分量进行小波变换并构建具有统计意义的特征向量输入到自适应神经模糊推理系统进行故障选相。文献[8]结合局部特征尺度分解法和希尔伯特变换获取配网电压、电流信号的时频矩阵并进行奇异值分解获取奇异谱均值、奇异熵等特征向量，输入到多级 SVM 实现故障选相。文献[9]计算通过经验模态分解获取的三相电流高频分量的标准差和相关系数作为特征向量实现故障选相。然而，特征向量的构建过度依赖人工专家经验，较难满足复杂配网拓扑结构和各类故障条件下的选相精度要求。深度学习方法能自适应地提取历史故障数据的特征并进行学习，弥补了传统机器学习特征提取能力较弱的缺点。文献[10]对三相电压、电流和零序电流进行离散小波包变换获取时频矩阵并转换时频谱图，输入到卷积深度置信网络中实现故障选相。文献[11]对三相电压、电流和零序电流进行 HHT 变换获取时频矩阵输入到卷积神经网络中实现故障选相。然而，

经信号处理方法处理或提取的故障特征缺乏完备性，无法适应于高阻抗和强噪声的极端故障条件。文献 [12] 提出了基于原始电流的二维灰度图和 RIME-CBAM-CNN 的故障选相检测方法，但该方法缺乏对原始电流数据时序特征的提取，故障选相精度有待提高。此外，现有深度学习方法缺少对关键特征的挖掘和关注，导致现有深度学习方法选相精度有待提高。

针对上述问题，本文提出基于 RGB 图像生成的 CNN-CBAM-BiLSTM 配网接地故障选相方法。首先利用序列 - 图像转换方法将馈线的三相电流转换为二维图像对应映射到 R、G、B 三通道生成 RGB 图像。然后将生成的 RGB 图像输入到 CNN-CBAM-BiLSTM 故障选相模型训练，最后获得高精度的故障选相模型。仿真结果表明，所提方法具有较高的选相精度，且在网络拓扑和中性点运行方式改变情况下具有较强的鲁棒性。

## 2. RGB 图像生成原理

配网发生接地故障时，采集故障发生后两个工频周期内的三相电流信号，利用信号 - 图像转换方法 [13] 可将对应的电流信号转换为二维灰度图像，转换方法具体如式(1)所示：

$$P(m,n) = \text{round} \left( \frac{X[(m-1) \times N + n] - \min(X)}{\max(X) - \min(X)} \times 255 \right) \quad (1)$$

式中， $P(i,j)$  为二维灰度图中第  $i$  行、第  $j$  列的像素强度， $N \times N$  为所转换的图片大小， $X$  为相电流信号的取值，其长度为  $N^2$ ， $X(i)$  为  $X$  中的第  $i$  个数据点的取值； $\text{round}(\bullet)$  的作用是将数据取整，以保证转换后的数据取值为 0~255 之间的整数。

通过信号 - 图像转换方法得到的 3 张二维灰度图像映射到 RGB 图像的三个通道得到 RGB 图像，映射示意图如图 1 所示。

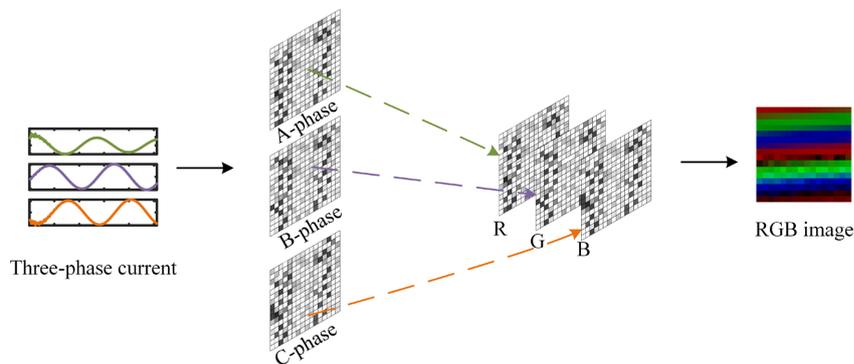


Figure 1. Schematic diagram of RGB image generation mapping  
图 1. RGB 图像生成映射示意图

由图 1 可知，发生 A 相接地故障时，A 相电流幅值会远大于 B、C 两相电流幅值，在 RGB 图像中的 R 通道会保留该特征。值得注意的是，发生其他接地故障，RGB 图像中的相应的通道仍会保留独特的故障特征信息。

## 3. CNN-CBAM-BiLSTM 神经网络原理

### 3.1. CNN

CNN 具有局部连接、权值共享和空间相关等特性，适用于深层数据特征提取。CNN 通常由输入层、

卷积层、池化层和输出层组成[14]。卷积层对第  $l-1$  层的特征图  $\mathbf{M}_{in}^{l-1}$  进行卷积操作，得到第  $l$  层的特征图  $\mathbf{M}_{out}^l$ ，如式(2)所示：

$$\mathbf{M}_{out}^l = \delta(\mathbf{M}_{in}^{l-1} * \mathbf{K}_{core}^l) \quad (2)$$

式中， $\mathbf{K}_{core}^l$  为第  $l$  层卷积核矩阵； $\delta$  表示 ReLU 函数； $*$  表示 CNN 中的滑步卷积过程。

随后，最大池化层执行下采样，具有减少学习参数和避免过拟合的优点，具体如式(3)所示：

$$\mathbf{M}_{out}^{l+1} = \psi(\mathbf{M}_{in}^l) \quad (3)$$

式中，函数  $\psi(\bullet)$  表示池化运算。

### 3.2. CBAM

CBAM 被证明能够使 CNN 专注于重要特征并抑制不必要的特征，它由通道注意力模块和空间注意力模块组成，可以根据需要在通道和空间方面灵活地学习“关注什么”和“关注何处”[15]。

给定一个中间特征图  $\mathbf{F} \in \mathbb{R}^{C \times H \times W}$  作为输入，通道注意力模块在特征图的空间区域上执行池化操作，包括平均池化和最大池化。随后，将它们传递到共享网络中，并使用逐元素求和的方式进行合并得到最终的通道注意力图  $\mathbf{M}_c(\mathbf{F}) \in \mathbb{R}^{C \times 1 \times 1}$ ，如式(4)所示：

$$\mathbf{M}_c(\mathbf{F}) = \sigma\left(W_2 \delta\left(W_1\left(\mathbf{F}_{avg}^c\right)\right) + W_2 \delta\left(W_1\left(\mathbf{F}_{max}^c\right)\right)\right) \quad (4)$$

式中， $\mathbf{F}_{avg}^c$  和  $\mathbf{F}_{max}^c$  分别表示经过平均池化和最大池化操作后的通道轴上的特征， $W_1$  和  $W_2$  为全连接层的学习权重， $\delta$  表示 ReLU 函数， $\sigma$  表示 sigmoid 函数。

对于空间注意力模块，对特征图的通道区域进行池化操作，随后使用卷积层进行级联和卷积，得到最终的空间注意力图  $\mathbf{M}_s(\mathbf{F}) \in \mathbb{R}^{1 \times H \times W}$ ，如式(5)所示：

$$\mathbf{M}_s(\mathbf{F}) = \sigma\left(f\left[\mathbf{F}_{avg}^s \oplus \mathbf{F}_{max}^s\right]\right) \quad (5)$$

式中， $\mathbf{F}_{avg}^s$  和  $\mathbf{F}_{max}^s$  分别表示经过平均池化和最大池化操作后的空间轴上的特征， $\oplus$  是级联算子， $f$  表示卷积操作， $\sigma$  表示 sigmoid 函数。

将通道注意力模块和空间注意力模块依次堆叠形成最终的 CBAM，CBAM 的输出  $\mathbf{F}'$  可由式(6)表示：

$$\mathbf{F}' = (\mathbf{F} \otimes \mathbf{M}_c(\mathbf{F})) \otimes \mathbf{M}_s(\mathbf{F} \otimes \mathbf{M}_c(\mathbf{F})) \quad (6)$$

式中， $\otimes$  表示元素乘法。

### 3.3. BiLSTM

LSTM 通过学习时序数据的长时间相关性，使网络可以更好、更快地收敛，有助于提高预测精度。但 LSTM 在训练过程中通常采用单向的数据流，即信息只从序列的开始流向结束。这种单向训练方式可能会导致数据的时间序列特征没有得到充分利用。为了克服这一限制，BiLSTM 网络被提出，对应的网络结构如图 2 所示[16]。

BiLSTM 在  $t$  时刻的隐藏状态  $h_t$  包括前向  $\bar{h}_t$  和后向  $\bar{h}_t$ 。前向  $\bar{h}_t$  和后向  $\bar{h}_t$  的表达式如式(7)、(8)所示：

$$\bar{h}_t = \text{LSTM}(h_{t-1}, x_t) \quad (7)$$

$$\bar{h}_t = \text{LSTM}(h_{t+1}, x_t) \quad (8)$$

通过结合这两个方向的信息，BiLSTM 能够更全面地理解数据在时间序列上的特征联系，从而提高模型对数据的利用率和预测精度。

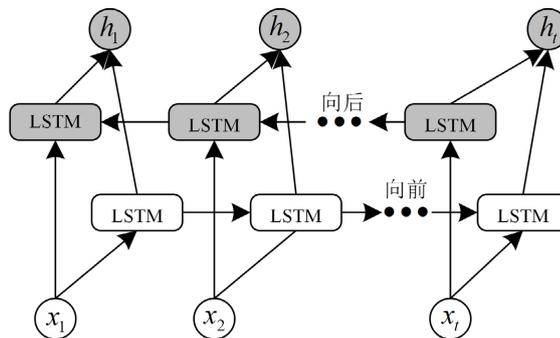


Figure 2. Structure of BiLSTM  
图 2. BiLSTM 结构

#### 4. 接地故障选相模型

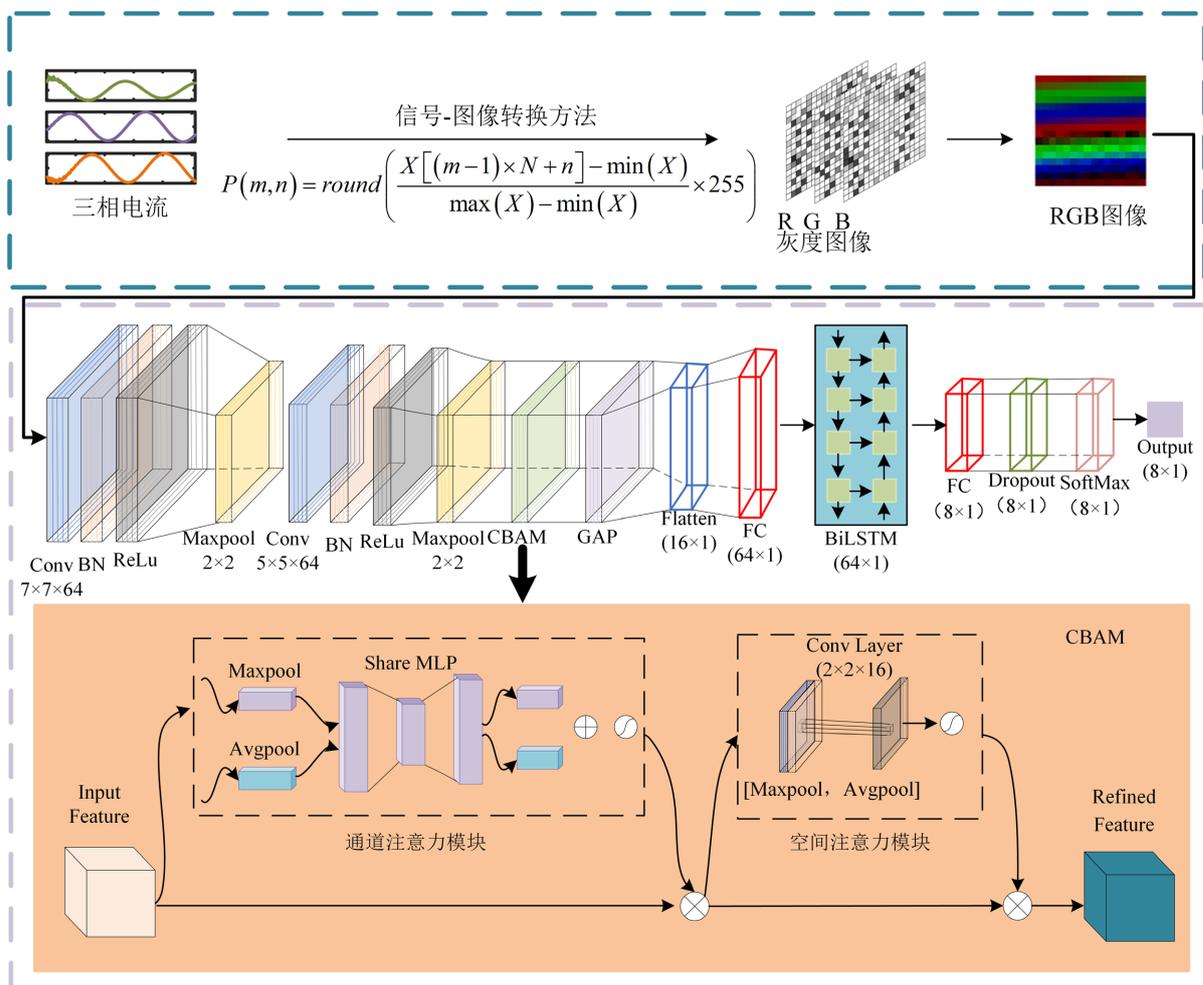


Figure 3. Ground fault classification method of CNN-CBAM-BiLSTM  
图 3. CNN-CBAM-BiLSTM 接地故障分类方法

为更好地提取故障三相电流中完备的故障信息,采用 CNN 提取 RGB 图像的局部特征,采用 BiLSTM 提取 RGB 图像中蕴含的时序特征,同时考虑到 RGB 图像通道中蕴含的独特信息,采用 CBAM 的通道注意力和空间注意力关注关键的通道特征和空间特征,提高模型的性能。为此,提出了基于 RGB 图像生成的 CNN-CBAM-BiLSTM 接地故障选相方法,如图 3 所示。模型参数设置:初始学习率为 0.001,训练轮数为 40 次,每轮训练对数据进行随机打乱,防止模型过度拟合。

## 5. 算例仿真

### 5.1. 仿真模型的搭建

本文利用 MATLAB/SIMULINK 仿真软件搭建 110 kV/10 kV 配网单相接地系统,仿真模型如图 4 所示。其中,  $O_L$  表示架空线路长度,  $C_L$  表示电缆线路长度。其中,消弧线圈补偿度为 8%,采样频率为 6.4 kHz。

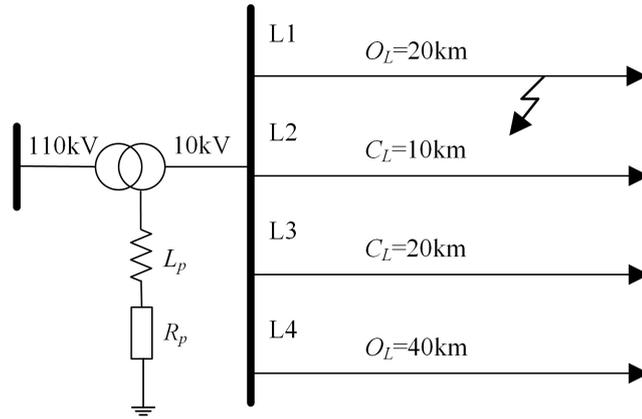


Figure 4. Simulation model diagram of distribution network faults  
图 4. 配网故障仿真模型图

架空线路和电缆线路的正序参数分别为:

$$\begin{aligned} R_{o1} &= 0.125 \Omega/\text{km}, R_{c1} = 0.27 \Omega/\text{km} \\ C_{o1} &= 0.0096 \mu\text{F}/\text{km}, C_{c1} = 0.339 \mu\text{F}/\text{km} \\ L_{o1} &= 1.3 \text{ mH}/\text{km}, L_{c1} = 0.25 \text{ mH}/\text{km} \end{aligned}$$

架空线路和电缆线路的零序参数分别为:

$$\begin{aligned} R_{o0} &= 0.275 \Omega/\text{km}, R_{c0} = 2.7 \Omega/\text{km} \\ C_{o0} &= 0.0054 \mu\text{F}/\text{km}, C_{c0} = 0.28 \mu\text{F}/\text{km} \\ L_{o0} &= 4.6 \text{ mH}/\text{km}, L_{c0} = 1.019 \text{ mH}/\text{km} \end{aligned}$$

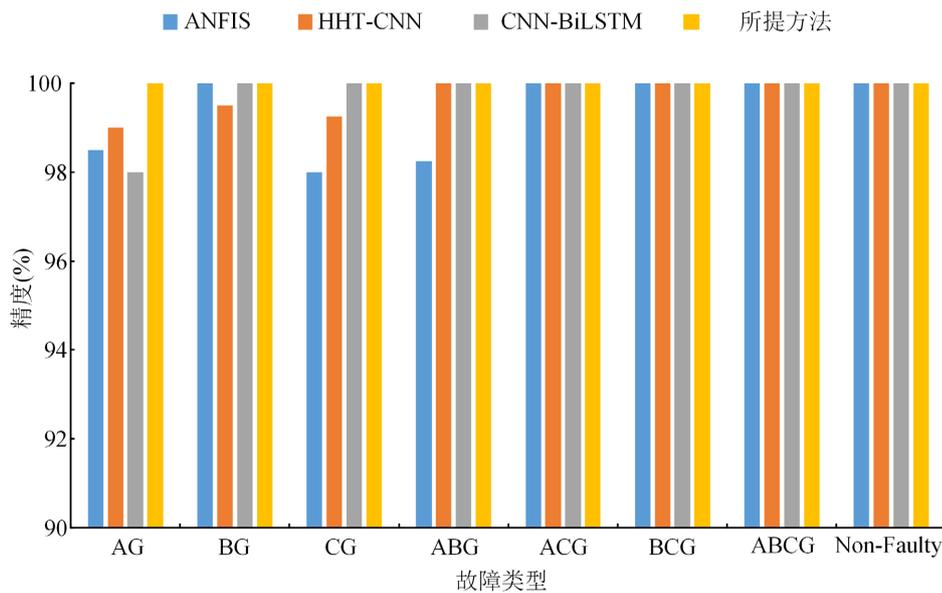
### 5.2. 故障集的获取

为获取批量故障数据,本文编写 MATLAB 脚本程序调用 SIMULINK 仿真模型实现不同故障相角、故障距离、过渡电阻和故障相别的自动仿真,模型遍历参数表如表 1 所示,仿真获得 22,400 组故障数据。当仿真模型正常运行时,对每条线路按照相位每隔  $1^\circ$  仿真一次,相位取值范围为  $[0^\circ:360^\circ]$ ,获得 1444 个正常数据。共计获得 23,844 个样本。

**Table 1.** Simulation traversal parameter table  
**表 1.** 仿真遍历参数表

参数	取值	数量
故障线路	L1~L4	4
故障类型	AG, BG, CG, ABG, ACG, BCG, ABCG	7
故障相角	0°~180°, 每隔 20°	10
过渡电阻/ $\Omega$	1, 10, 50, 100, 200, 500, 1000, 1500, 1800, 2000	10
故障位置/km	10%~80%, 每隔 10%	8

故障数据集随机按照 7:1 比例划分训练集和测试集, 选择 ANFIS [17]、HHT-CNN [11]、CNN-BiLSTM 三种方法进行对比, CNN-BiLSTM 与所提方法采用相同的参数, 对比结果如图 5 所示。



**Figure 5.** Comparison results of different methods  
**图 5.** 不同方法的对比结果

由图 5 可知, 本文所提方法识别 7 种接地故障和系统正常运行状态的分类精度均为 100%, 明显优于其他三种方法。与 CNN-BiLSTM 方法相比, 所提方法的 A 相接地故障识别精度高出了 2%。这说明融合 CBAM 注意力机制能自适应聚焦和挖掘 RGB 图像中蕴含的关键特征信息, 提高故障选相精度。

### 5.3. 鲁棒性对比

为验证所提方法的鲁棒性, 考虑网络拓扑改变、中性点接地方式改变和噪声干扰对模型精度的影响。

#### 5.3.1. 调整网络拓扑

配电网拓扑结构由于平衡负荷、降低网损等原因而发生变化。针对图 4 所示的配电网, 设定 2 种拓扑结构测试拓扑调整对所提方法模型精度的影响, 即删减线路 L4、新增 1 条 5 km 的架空线路 L5, 测试结果如表 2 所示。

**Table 2.** Classification results of network topology changes

**表 2.** 网络拓扑改变的分类结果

网络拓扑变化情况	样本数量	精度/%
删减线路 L4	320	100
新增线路 L5	320	98.75

由表 2 可知, 改变配网拓扑结构, 所提方法仍有较高的选相精度。对拓扑结构的改变具有良好的适应性。

### 5.3.2. 中性点接地方式改变

将图 4 中的配网系统调整为中性点不接地方式。设置线路 L4 发生故障, 仿真参数如表 3 所示。获取中性点不接地方式运行后的 224 个测试样本。

**Table 3.** Classification results of a change in the ground mode at the neutral point

**表 3.** 中性点接地方式改变的分类结果

参数	故障取值	正常运行取值	样本数量
故障类型	AG, BG, CG, ABG, ACG, BCG, ABCG	/	224
故障相角	0°, 30°, 45°, 90°	0°~180°	
过渡电阻/ $\Omega$	1, 100, 500, 1000, 1500, 2000	/	
故障位置/km	40%	/	

由表 3 可知, 测试样本输入训练好的模型中, 故障识别精度为 100%。这说明所提方法不受中性点接地方式的影响。

### 5.3.3. 噪声干扰

将不同信噪比(SNR)的高斯白噪声叠加在 5.2 节的 3161 个测试样本上, 以测试模型的抗噪性, 并重复实验 10 次, 以平均准确率作为评价指标, 测试结果如表 4 所示。

**Table 4.** Test results under noise interference

**表 4.** 噪声干扰下的测试结果

信噪比/dB	30	20	10
平均选相精度%	100	99.99	99.97

由表 4 可知, 当 SNR 等于 30 dB 时, 平均精度为 100%; 当 SNR 等于 10 dB 时, 平均精度为 99.97%。随着 SNR 的减小, 模型的平均精度下降较小, 说明所提方法具有较强的抗噪声能力。

## 6. 结论

本文提出一种基于 RGB 图像生成的 CNN-CBAM-BiLSTM 配电网接地故障选相方法。通过时序 - 图像转换方法构建三相电流的 RGB 图像包含故障相位和非故障相位之间的差异特征, 能充分发挥深度学习的优势。设计 CNN-BiLSTM-CBAM 复合网络架构, 通过 CNN 捕捉空间局部特征、BiLSTM 建模时序关联特性, 结合注意力机制实现关键特征的自适应聚焦, 形成空间 - 时序特征协同提取机制。仿真结果表

明：该方法在拓扑结构变化、中性点运行方式切换和噪声干扰等复杂工况下，展现出优越的鲁棒性。

## 参考文献

- [1] 于群, 陈志慧. 电网不对称条件下基于频数分布理论的谐振接地系统故障相辨识[J]. 电力系统保护与控制, 2018, 46(7): 96-104.
- [2] 赵建文, 胡雨佳, 张鸿波, 等. 基于重构相图相似性检测的单相接地故障选相方法[J]. 科学技术与工程, 2022, 22(4): 1480-1486.
- [3] 黄明伟, 王力, 周仕豪, 等. 基于暂态能量比的交流输电线路故障选相方法[J]. 智慧电力, 2023, 51(2): 98-104.
- [4] 朱虹洁, 兰宇婷, 贺世庚, 等. 基于特征相位差的配电网高阻接地故障主动选相方法[J/OL]. 电力系统及其自动化学报: 1-10. <https://doi.org/10.19635/j.cnki.csu-epsa.001609>, 2025-07-02.
- [5] 钱信君, 郭祺, 涂春鸣, 等. 基于特征电流变化量的配电网高阻接地故障主动选相选线方法[J]. 电网技术, 2025, 49(5): 2156-2166.
- [6] Zhou, M., Kazemi, N. and Musilek, P. (2024) Distribution Grid Fault Classification and Localization Using Convolutional Neural Networks. *Smart Grids and Sustainable Energy*, 9, Article No. 24. <https://doi.org/10.1007/s40866-024-00205-5>
- [7] 张钧, 李小鹏, 何正友. 采用自适应神经模糊推理系统的配电网故障分类方法[J]. 中国电机工程学报, 2010, 30(25): 87-93.
- [8] 郭谋发, 游林旭, 洪翠, 等. 基于 LCD-Hilbert 谱奇异值和多级支持向量机的配电网故障识别方法[J]. 高电压技术, 2017, 43(4): 1239-1247.
- [9] 孙鹏, 曹雨晨, 刘洋, 等. 采用二进制蚁群模糊神经网络的配电网故障分类方法[J]. 高电压技术, 2016, 42(7): 2063-2072.
- [10] 洪翠, 付宇泽, 郭谋发, 等. 基于卷积深度置信网络的配电网故障分类方法[J]. 电力自动化设备, 2019, 39(11): 64-70.
- [11] Guo, M.F., Yang, N.C. and Chen, W.F. (2019) Deep-Learning-Based Fault Classification Using Hilbert-Huang Transform and Convolutional Neural Network in Power Distribution Systems. *IEEE Sensors Journal*, 19, 6905-6913. <https://doi.org/10.1109/jsen.2019.2913006>
- [12] 胡祥谢. 基于数据驱动的接地故障选相方法研究[D]: [硕士学位论文]. 贵阳: 贵州大学, 2024.
- [13] 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.
- [14] 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.
- [15] 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 109663. <https://doi.org/10.1016/j.asoc.2022.109663>
- [16] 聂祥论, 张垚, 申江兰, 等. 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.
- [17] Zhang, J., He, Z.Y., Lin, S., Zhang, Y.B. and Qian, Q.Q. (2013) An ANFIS-Based Fault Classification Approach in Power Distribution System. *International Journal of Electrical Power & Energy Systems*, 49, 243-252. <https://doi.org/10.1016/j.ijepes.2012.12.005>