

自适应 VMD 与多头注意力 PCNN 融合的小电流接地故障选线方法^{*}

韩冠行¹ 韩如月¹ 贾雅君² 江俊杰²

(1. 内蒙古工业大学电力学院 呼和浩特 010000; 2. 上海交通大学电子信息与电气工程学院 上海 200240)

摘 要: 传统小电流接地系统单相接地故障选线方法,通常采用基于一维信号的选线模型,存在选线准确率低、抗噪性弱等问题。基于上述问题,本研究提出了一种基于优化 VMD 及双通道 PCNN-MATT 的配网小电流接地系统单相接地故障选线方法:采用霜冰算法对 VMD 的分解层数与惩罚因子进行寻优,利用模糊熵算法选取模糊熵值最小的 IMFs 分量作为降噪输出信号;运用格拉姆角场算法将降噪后的信号变换为二维空间域图像,构建故障数据库;将 GASF、GADF 图像作为双通道神经网络的输入,用 PCNN-MATT 提取和学习图像所蕴含的故障特征,并进行故障线路的选取。为验证所提方法的有效性,本研究使用 MATLAB/Simulink 和配网 RTLAB 闭环仿真平台,在加入噪声的前提下,将所提模型与 3 种选线模型相比较。实验结果表明本研究算法准确率高达 99.4%,在不同噪声条件下能够维持 95% 以上的准确率,优于其它 3 种选线模型,克服了传统故障选线方法准确率低、抗噪性差的问题。

关键词: 小电流接地系统;故障选线;霜冰算法;变分模态分解;格拉姆角场;PCNN 卷积神经网络

中图分类号: TM771; TN876.3 **文献标识码:** A **国家标准学科分类代码:** 470.40

Low current grounding fault line selection method based on the fusion of adaptive VMD and multi-head attention PCNN

Han Guanxing¹ Han Ruyue¹ Jia Yajun² Jiang Junjie²

(1. School of Electric Power, Inner Mongolia University of Technology, Huhhot 010000, China;

2. School of Electronic Information and Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: The traditional method of line selection for single-phase grounding fault in small current grounding system usually adopts the line selection model based on one-dimensional signal, which has some problems such as low line selection accuracy and weak noise resistance. Based on the above problems, this paper proposes a line selection method for single-phase grounding fault of distribution network small current grounding system based on optimized VMD and dual-channel CNN-MATT: frost and ice algorithm is used to optimize the decomposition layer number and penalty factor of VMD, and fuzzy entropy algorithm is used to select the IMFs component with minimum fuzzy entropy as the noise reduction output signal. Gram-angle field algorithm is used to transform the denoised signal into two-dimensional spatial domain image, and the fault database is constructed. The GASF and GADF images are taken as the input of dual-channel neural network, and the fault features contained in the images are extracted and learned by CNN-MATT, and the fault lines are selected. In order to verify the effectiveness of the proposed method, MATLAB/Simulink and RTLAB closed-loop simulation platform are used in this paper, and the proposed model is compared with three kinds of line selection models under the premise of adding noise. The experimental results show that the accuracy rate of the proposed algorithm is as high as 99.4%, and it can maintain an accuracy of more than 95% under different noise conditions, which is superior to the other three line selection models, and overcomes the problems of low accuracy and poor noise resistance of traditional fault line selection methods.

Keywords: small current grounding system; fault line selection; frost and ice algorithm; variational mode decomposition; gram angle field; PCNN convolutional neural network

0 引 言

我国配电网通常采用小电流接地系统(中性点不接地

或经消弧线圈接地),在提高供电可靠性的同时,也给故障选线带来困难。系统单相接地故障占配电网故障的 80% 以上^[1],故障发生时信号较为微弱,导致故障选线面临诸多

难题。若不能及时处理,可能致使故障进一步恶化。因此,针对单相接地故障精准选线方法的研究,对于配电网的平稳运行至关重要^[2]。

配电网单相接地故障选线方法分为稳态法和暂态法。稳态法包括零序电流比幅比相法^[3-4]、零序功率法^[5]和零序五次谐波法^[6]等,但此类方法对于消弧线圈接地系统适用性不强,且对于高阻接地故障识别效果较差。暂态法包括首半波法^[7]、小波法^[8-10]和暂态能量法^[11-12]等,暂态选线方法凭借其高灵敏度、快速响应和丰富的信息提取能力,成为现行主流研究方向。文献[13-14]采用经验模态分解(empirical mode decomposition, EMD)法对零序电流信号进行分解,提取反映故障特征的关键信息,实现准确选线。但 EMD 分解存在模式混叠问题,易引起故障特征信息丢失,导致选线出现偏差;文献[15]采用变分模态分解(variational mode decomposition, VMD)对零序电流信号进行分解,但 VMD 分解对于分解层数和惩罚因子的参数组合要求较高,参数组合设置不合理易影响去噪效果。文献[16]提出了一种将零序电流进行格拉姆角场(gramian angular fields, GAF)二维变换融合深度学习的故障选线方法,GAF 图像包含了更多的特征信息以便于被神经网络学习,提高了选线准确率,但缺乏独立的降噪算法,在噪声干扰存在的情况下选线结果不理想。

随着计算机算力不断增强,深度学习算法被广泛应用于配网接地故障选线领域中,文献[17]利用 GoogLeNet 网络对数据集进行训练分类,从而实现故障选线。文献[18]将迁移学习应用到故障选线中,提高了训练效率,但同样在噪声干扰存在的情况下选线结果不理想。卷积神经网络作为经典的网络框架,其性能在图像识别领域中难以满足日益增长的需求,双通道卷积神经网络(parallelizing convolutional neural network, PCNN)是卷积神经网络一次较大革新,具有对复杂图像识别处理能力强,抗干扰性好的特点,在图像识别领域取得较大进展。多头注意力机制(multi-head attention, MATT)的多个注意力头能够从不同维度解耦特征,减少噪声干扰,且 MATT 可分别关注高频(细节)和低频(整体结构)信息,结合 PCNN 的双通道特性,增强模型对复杂数据的适应能力。

针对上述问题,本研究提出一种基于优化 VMD 及双通道 PCNN-MATT 的配网小电流接地系统单相接地故障选线方法。采用霜冰算法(rime optimization algorithm, RIME)对 VMD 的分解参数组合进行寻优,以确保滤除噪声干扰的同时保留波形中的故障特征。利用模糊熵算法对 VMD 分解出的 IMF_s 分量进行熵值计算,选取模糊熵值最小的 IMF 分量作为降噪输出;运用 GAF 将降噪输出波形变换为二维图像,制备故障数据集;将 GASF、GADF 图像作为双通道神经网络的输入,用 PCNN-MATT 提取和学习图像所蕴含的故障特征,并进行故障线路的判别。最后,在 MATLAB/Simulink 和配网 RTLAB 闭环仿真平台上验

证所提方法的有效性。

1 零序电流优化原理

1.1 霜冰算法优化 VMD

VMD 在多分量信号分离、噪声抑制和特征提取等方面有着广泛的应用^[19]。但在变分模态分解的过程中,分解层数 K 和惩罚因子 α 的参数组合设定通常依赖于经验,对 VMD 分解精度有极大影响,易导致分解效果不理想。为解决此问题,本研究采用 RIME 对这两个参数进行最优值求解。

RIME 设计灵感来源于霜冰环境中软冰针与硬冰针的生长过程。设计软冰针遍历策略和硬冰针穿刺机制,以指导空间内的探索和开发活动,并采用经过改良的正向贪婪选择机制来进行全局最优解的搜寻^[20]。RIME 霜冰粒子种群 R 位置如式(1)所示。

$$R = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1j} \\ x_{21} & x_{22} & \cdots & x_{2j} \\ \vdots & \vdots & \ddots & \vdots \\ x_{i1} & x_{i2} & \cdots & x_{ij} \end{bmatrix} \quad (1)$$

式中: x_{ij} 表示霜冰粒子群; i 表示霜冰晶体序号; j 表示霜冰颗粒序号。霜冰粒子适应度值 $F(S_i)$ 如式(2)所示。

$$F(S_i) = \begin{bmatrix} f([x_{11} & x_{12} & \cdots & x_{1j}]) \\ f([x_{21} & x_{22} & \cdots & x_{2j}]) \\ \vdots & \vdots & \ddots & \vdots \\ f([x_{i1} & x_{i2} & \cdots & x_{ij}]) \end{bmatrix} \quad (2)$$

式中: f 为霜冰粒子适应度。霜冰粒子 x_{ij} 会在全局进行规律运动,直至运动到软冰针附近凝聚。霜冰粒子位置如式(3)所示。

$$\begin{cases} R_{ij}^{new} = R_{best,j} + r_1 \cdot \cos\theta \cdot \beta \cdot (\psi \cdot (Ub_{ij} - Lb_{ij}) + Lb_{ij}) \\ r_2 < E \\ E = \sqrt{(h/H)} \end{cases} \quad (3)$$

式中: R_{ij}^{new} 为最新霜冰位置; $R_{best,j}$ 为软冰针凝聚区域 R 的最优霜冰位置; r_1 为方向因子,取值范围为 $(-1, 1)$,指示软冰针的凝聚趋向; β 为外部影响因子; ψ 为软冰针凝聚力,取值范围为 $(0, 1)$,指示霜冰间凝聚效果; Ub_{ij} 、 Lb_{ij} 指示霜冰凝聚空间范围的上下边界; E 为霜冰凝聚系数,其值会根据算法迭代逐步增大,使得霜冰趋于凝结; r_2 为取值范围为 $(0, 1)$ 的随机因子,通过与 E 比较,来体现霜冰是否处于凝结状态; h 为迭代次数; H 最大迭代次数。为避免凝聚过程中粒子移动方向 $\cos\theta$ 出现发散情况,需要对 θ 进行约束,具体如式(4)所示。

$$\theta = \pi \cdot \frac{h}{10 \cdot H} \quad (4)$$

软冰针凝结面积的扩展,反映了算法对整个搜索空间的高效遍历能力。硬冰针的凝聚过程会随着算法迭代而逐

渐向固定方向延伸,不同的硬冰针种群之间会发生交叉,从而促使不同冰针种群的最优霜冰位置进行信息交换,避免了陷入局部最优解的问题。不同冰针种群的最优霜冰位置进行信息交换,最优霜冰位置更替如式(5)所示。

$$\begin{cases} R_{ij}^{new} = R_{best,j} \\ r_3 < F^{norm}(S_i) \sqrt{b^2 - 4ac} \end{cases} \quad (5)$$

式中: $F^{norm}(S_i)$ 为粒子所在位置归一化适应度; r_3 为 $(-1, 1)$ 的随机数。

1.2 模糊熵

模糊熵(fuzzy entropy, FuzzyEn)采用模糊隶属度函数作为评估信号复杂性的阈值标准,用来量化信号在特定尺度上的不规则性。主要用于分析非线性和非平稳故障信号,有效捕捉故障特征。设定一段长度为 N 的时间序列,模糊熵定义如式(6)所示。

$$FuzzyEn(m, n, r, N) = \ln \frac{\phi^m(n, r)}{\phi^{m+1}(n, r)} \quad (6)$$

式中: m 、 n 、 r 分别为迭代次数、边界梯度和宽度。由式(6)可知,模糊熵能够通过一个具体的数值来衡量序列的不规则程度,随着序列复杂性的增加,其熵值也会相应增大。

1.3 格拉姆角场

格拉姆角场能够在保持原始信号特征完整性的前提下,将一维的时间序列数据转换为二维图像。核心原理在于把位于笛卡尔坐标系内的一维时间序列映射到极坐标系下,并通过特有的内积计算来捕捉时间序列信息,表征在图像中即为沿图像主对角线对称的 GASF 和 GADF 两类图像^[21-22]。

格拉姆矩阵 G 如式(7)所示,矩阵内元素为向量之间的内积,用于体现向量之间的相关性。

$$G = X^T X = \begin{bmatrix} \langle x_1, x_1 \rangle & \cdots & \langle x_1, x_n \rangle \\ \langle x_2, x_1 \rangle & \cdots & \langle x_2, x_n \rangle \\ \vdots & & \\ \langle x_n, x_1 \rangle & \cdots & \langle x_n, x_n \rangle \end{bmatrix} \quad (7)$$

式中: $\langle \cdot, \cdot \rangle$ 为内积运算。

将时间序列信号 $X = \{x_1, x_2, \dots, x_n\}$ 采用归一化法放缩至区间 $[-1, 1]$, 归一化后的值记为 \tilde{x}_i , 如式(8)所示。

$$\tilde{x}_i = \frac{(x_i - \min(X)) + (x_i - \min(X))}{\max(X) - \min(X)} \quad (8)$$

对归一化后的值进行极坐标变换,如式(9)所示:

$$\begin{cases} \phi = \arccos(\tilde{x}_i), -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r = \frac{t_i}{N}, t_i = 1, 2, \dots, N \end{cases} \quad (9)$$

式中: t_i 为时间序列; N 为正则化极坐标常数因子; ϕ 为极坐标相角; r 为极坐标半径; \tilde{x} 为时间序列元素 X 对应的放缩值。

为消除高斯白噪声对于生成格拉姆角场二维图像的影响,故定义两种带有惩罚项的内积形式,其公式如式(10)和(11)所示。

$$\langle x_i, x_j \rangle = \cos(\phi_i + \phi_j) \quad (10)$$

$$\langle x_i, x_j \rangle = \sin(\phi_i - \phi_j) \quad (11)$$

将上述两种带有惩罚项的内积形式带入到式(7)中可得两种 GASF 图像: GASF (Gramian Angular Summation Fields) 与 GADF (Gramian Angular Difference Fields), 公式如(12)和(13)所示:

$$G_{GASF} = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \cdots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \cdots & \cos(\phi_2 + \phi_n) \\ \vdots & & \\ \cos(\phi_n + \phi_1) & \cdots & \cos(\phi_n + \phi_n) \end{bmatrix} \quad (12)$$

$$G_{GADF} = \begin{bmatrix} \sin(\phi_1 - \phi_1) & \cdots & \sin(\phi_1 - \phi_n) \\ \sin(\phi_2 - \phi_1) & \cdots & \sin(\phi_2 - \phi_n) \\ \vdots & & \\ \sin(\phi_n - \phi_1) & \cdots & \sin(\phi_n - \phi_n) \end{bmatrix} \quad (13)$$

2 基于 PCNN-MATT 的故障选线模型

2.1 PCNN-MATT 网络架构

PCNN 在图像分割和目标识别等领域表现出色,能够在增强重要视觉成分的同时减少背景噪音影响;并模拟了生物神经系统并行处理的能力,可同时处理多个信息通道数据,加速计算过程,提高效率^[23]。

MATT 是一种结合了多个独立注意力单元并通过线性变换整合其输出的技术。通过这种方式, MATT 可以从不同的视角分析数据,使模型能够同时关注来自不同位置的特征,并在不同的表示子空间中分配注意力。它为各个特征向量赋予不同程度的重要性权重,并最终汇总这些加权后的信息,以实现更丰富的表征^[24-25]。

搭建 PCNN 网络,用于对 GASF 变换得到的二维图像进行特征提取。GASF 和 GADF 图像分别被输入到 PCNN 中,产生两组特征向量通过拼接的方式融合在一起,并传递给 MATT 进行处理。最终,通过 Softmax 层实现故障线路的准确判别。PCNN-MATT 网络架构参数如表 1 所示,架构如图 1 所示。

表 1 PCNN-MATT 网络架构参数

层名称	类型	输出维度
输入支路 1、2	图像输入	(None, 227, 227, 3)
卷积 1、2	二维卷积	(None, 114, 114, 64)
BN1、2	批量归一化	(None, 114, 114, 64)
Relu1、2	ReLU	(None, 114, 114, 64)
池化 1、2	二维最大池化	(None, 57, 57, 64)
全连接 1、2	全连接	(None, 1, 1, 128)
展平 1、2	扁平化	(None, 128)
融合	加法	(None, 128)
注意力机制	自注意力	(None, 128)
全连接 3	全连接	(None, 8)
Softmax	Softmax	(None, 8)
输出层	分类输出	(None, 8)

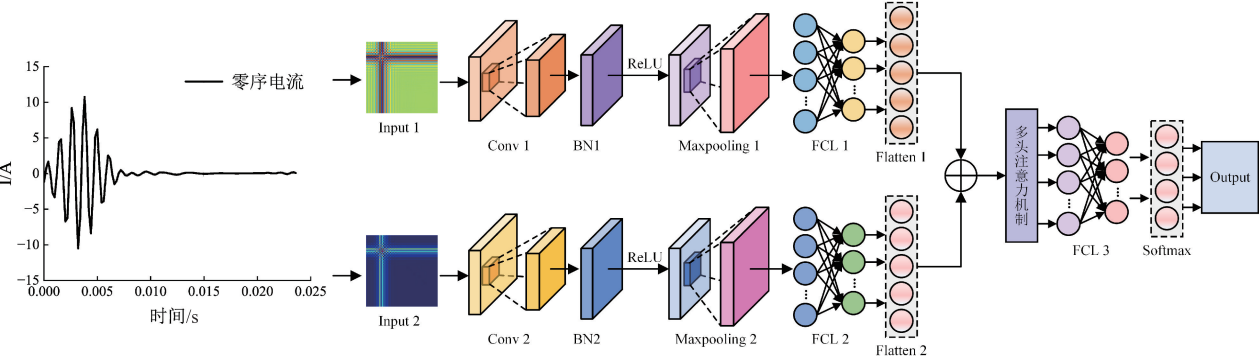


图 1 PCNN-MATT 架构
Fig. 1 PCNN-MATT architecture

2.2 选线模型

RIME-VMD-FuzzyEn 优化模型通过最小模糊熵作为优化算法的适应度函数,利用 RIME 对于整个搜索空间的高效遍历能力与最优参数位置更新机制针对 VMD 分解的最优参数分解层数 K 和惩罚因子 α 进行寻优,以确保达到

最优分解效果。针对由 RIME-VMD-FuzzyEn 优化分解后的一维零序电流波形数据进行 GAF 转换得到的二维图像数据,提出基于双通道 PCNN 和多头注意力机制的小电流接地系统单相接地故障选线模型。选线模型流程图如图 2 所示。

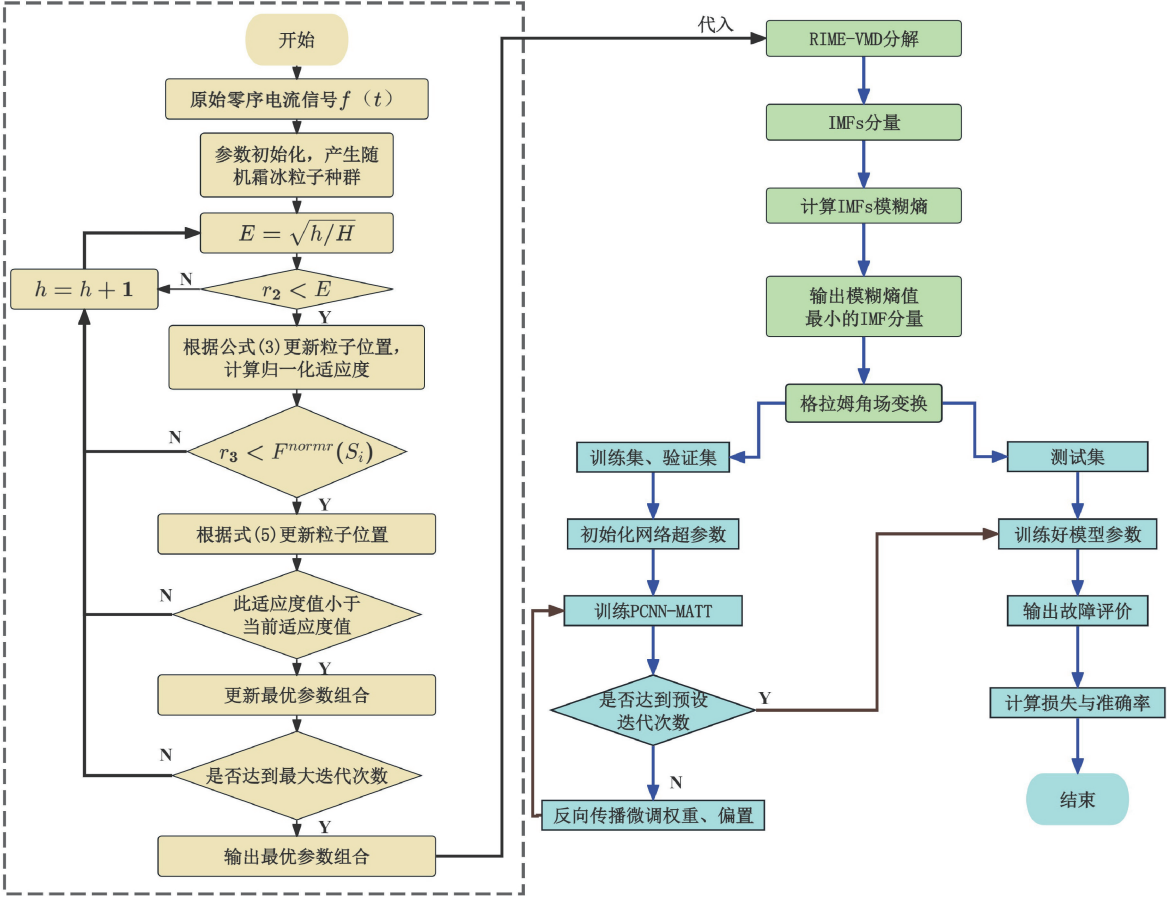


图 2 选线模型流程图
Fig. 2 Line selection model flow chart

1) 初始化 VMD 算法与 RIME 算法的各项参数,预设寻优算法的迭代次数 H 、 K 、界定霜冰凝聚空间范围的上

下边界 Ub_{ij} 、 Lb_{ij} , 产生随机霜冰例子种群;
2) 输入原始零序电流信号;

3)通过判断最新迭代次数 h 与预设总迭代次数 H 的比值来更新霜冰凝聚系数 E ,当 $r_2 < E$ 时根据公式(3)更新最优霜冰位置并计算归一化适应度;

4)当 $r_3 < F^{normal}(S_i)$ 时根据公式(5)更新最新霜冰位置;

5)通过判别最新霜冰位置与当前位置的适应度值,来更新最佳参数组合;

6)若满足循环条件,且当 $h < H$ 时,更新迭代次数 h ,持续进行迭代直至达到最大迭代次数,将最终输出的最优参数组合作为 VMD 的分解参数进行分解;

7)将经过 RIME-VMD 分解后的 IMF_s 分量分别进行模糊熵计算,将模糊熵值最小的 IMF 分量作为优化输出结果;

8)利用 GAF 对最优 IMF 分量进行变换,将一维零序电流 IMF 分量数据转化为二维 GADF 图像与 GASF 图像;

9)将所以经 GAF 变换后的 GASF、GADF 图像按设定比例划分为训练集、验证集输入至 PCNN 模型中进行训练。将由 PCNN 提取到的特征图卷积、池化、展平、融合送入到 MATT 中得到最终的训练模型;

10)最后通过测试集进行测试,送入训练模型中,对模型的故障选线准确率进行评估。

3 实验分析

3.1 配网选线模型

在 MATLAB/Simulink 仿真平台搭建如图 3 所示 10 kV 含分布式电源配电网模型,通过中性点开关切换中性点接地方式,模型包含 4 条分支线路,设置不同线路类型,在线路 L1、L3、L4 上设置光伏 DG。消弧线圈为过补偿,补偿度为 8%,具体线路参数如表 2 所示。

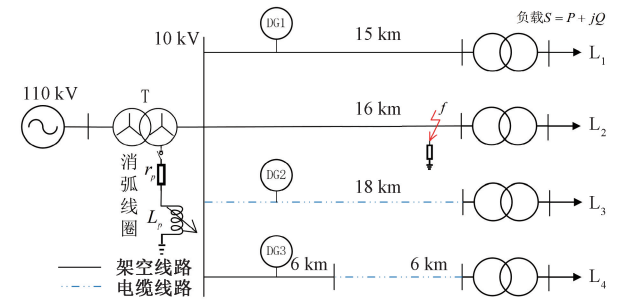


图 3 配网仿真模型

Fig. 3 Distribution network simulation model

设置仿真时长为 25 ms,故障发生时刻为 1 ms,采样频率为 100 kHz。设置中性点接地方式、故障初相角、DG 接入、故障线路、过渡电阻等故障参数,每次只改变一个参数进行循环仿真,可采集到样本 1 920(2×8×2×3×20)个,故障参数设置如表 3 所示。

数据集按中性点接地方式分成两个数据集。数据集

表 2 架空与电缆线路参数

Table 2 Parameters of overhead and cables lines

线路类型	相序	电阻/ (Ω·km ⁻¹)	电感/ (mH·km ⁻¹)	电容/ (μF·km ⁻¹)
架空线路	正序	0.17	1.21	0.11
	零序	0.3	5.48	0.005
电缆线路	正序	0.27	0.255	0.339
	零序	2.7	1.019	0.28

表 3 配电网模型不同工况参数表

Table 3 Parameter table of different operating conditions for distribution network model

故障参数	参数取值
中性点接地方式	中性点不接地、中性点经消弧线圈接地
故障初相角	0°、60°、90°、180°
分布式电源	有 DG 接入、无 DG 接入
故障线路	L1 架空线路、L3 电缆线路、 L4 架空和电缆混连线路
过渡电阻	10~3 000 Ω

类别划分如表 4 所示,每种中性点接地方式下,分别进行 4 次实验,对应 4 种故障初相角,每一次不同故障工况的仿真实验记录两组数据,即故障线路数据和健全线路数据,合计 8 个类别。将数据集按 4:1:1 的比例随机分为训练集、验证集和测试集,通过 Matlab 训练模型。

表 4 实验数据类别划分

Table 4 Classification of experimental data categories

实验	线路状态	类别	训练集	验证集	测试集
实验一	故障	1	80	20	20
	健全	5	80	20	20
实验二	故障	2	80	20	20
	健全	6	80	20	20
实验三	故障	3	80	20	20
	健全	7	80	20	20
实验四	故障	4	80	20	20
	健全	8	80	20	20

3.2 训练结果与选线准确率验证

如图 4、5 所示,仅需 20 次左右的迭代,选线准确率就可以提高到 90% 以上。完成训练后,中性点不接地系统最终选线准确率为 99.4%,中性点经消弧线圈接地系统最终选线准确率为 98.8%。

测试集测试训练好的选线模型,用混淆矩阵来体现结果。如图 6、7 所示,混淆矩阵纵坐标为实际类别,横坐标为预测类别,对角线的值即为预测类别与真实类别相符合的数量,非对角线的值为预测类别与真实类别不符的数量。




图 4 中性点不接地系统训练准确率与损失函数
Fig. 4 Training accuracy and loss function of neutral ungrounded system




图 5 中性点经消弧线圈接地系统训练准确率与损失函数
Fig. 5 Training accuracy and loss function of neutral point grounding system through arc suppression coil

分析测试集混淆矩阵结果可知,中性点不接地系统测试集 120 组数据仅误判 1 组,类别 5 误判为类别 1,即将 1 组在故障初相角为 0° 时的健全线路样本误判为故障线路;中性点经消弧线圈接地系统测试集 120 组数据误判 2 组,类别 2 误判为类别 6,类别 5 误判为类别 1,即将在故障初相角为 30° 时的故障线路样本漏判为健全线路,将在故障初相角为 0° 时的健全线路样本误判为故障线路。

3.3 消融实验及结果分析

由于本研究选线方法设计多个环节,为研究每个环节不同算法对于整体方法的贡献程度,进行消融实验。通过控制变量法将单一算法剔除,针对各个变体模型在同一测试集上进行准确率对比。

表 5 消融实验结果

Table 5 Melting experiment results

实验模型	No-RIME	No-GAF	No-MATT	No-PCNN	本研究模型
中性点不接地系统准确率/%	94.41	93.12	96.9	98.12	99.4
中性点经消弧线圈接地系统准确率/%	93.51	92.5	96.25	97.5	98.8

真实所属类别	类别1	20 12.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100 0.0%
	类别2	0 0.0%	20 12.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100 0.0%
	类别3	0 0.0%	0 0.0%	20 12.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100 0.0%
	类别4	0 0.0%	0 0.0%	0 0.0%	20 12.5%	0 0.0%	0 0.0%	0 0.0%	100 0.0%
	类别5	1 0.6%	0 0.0%	0 0.0%	0 0.0%	19 11.9%	0 0.0%	0 0.0%	95.0 5.0%
	类别6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	20 12.5%	0 0.0%	100 0.0%
	类别7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	20 12.5%	0 0.0%	100 0.0%
	类别8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	20 12.5%	100 0.0%
		95.2% 4.8%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	99.4% 0.6%
		类别1	类别2	类别3	类别4	类别5	类别6	类别7	类别8
		预测输出类别							

图 6 中性点不接地系统测试集混淆矩阵
Fig. 6 Neutral ungrounded system test set confusion matrix

真实所属类别	类别1	20 12.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100 0.0%
	类别2	0 0.0%	19 11.9%	0 0.0%	0 0.0%	0 0.0%	1 0.6%	0 0.0%	95.0 5.0%
	类别3	0 0.0%	0 0.0%	20 12.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100 0.0%
	类别4	0 0.0%	0 0.0%	0 0.0%	20 12.5%	0 0.0%	0 0.0%	0 0.0%	100 0.0%
	类别5	1 0.6%	0 0.0%	0 0.0%	0 0.0%	19 11.9%	0 0.0%	0 0.0%	95.0 5.0%
	类别6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	20 12.5%	0 0.0%	100 0.0%
	类别7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	20 12.5%	0 0.0%	100 0.0%
	类别8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	20 12.5%	100 0.0%
		95.2% 4.8%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	95.2% 4.8%	100% 0.0%	98.8% 1.2%
		类别1	类别2	类别3	类别4	类别5	类别6	类别7	类别8
		预测输出类别							

图 7 中性点经消弧线圈接地系统测试集混淆矩阵
Fig. 7 Neutral grounding system test set confusion matrix through arc suppression coil

首先,针对零序电流预处理模块,采用经验法固定 VMD 模态分解层数为 4 层替换 RIME 优化算法得到 No-RIME 模型。其次,针对图像转换模块,将零序电流波形数据代替 GAF 图像得到 No-GAF 模型。再次,剔除 MATT 多头注意力机制得到 No-MATT 模型。最后,运用单通道卷积神经网络替换 PCNN 得到 No-PCNN 模型。对比结果如表 5 所示。

由表 5 可知,在两种系统中,完整模型准确率最高。由于中性点经消弧线圈接地系统故障波形复杂度高于中性点不接地系统,故在不同实验模型下的选线准确率普遍低于中性点不接地系统 0.5%~1%。以中性点不接地系统进行分析,本研究模型比 No-RIME 变体模型高出 4.99%,表明本研究引入的霜冰寻优算法相较于经验法固定 VMD 分解层数对于零序电流分解有明显提升,降噪效果显著。和 No-GAF 变体模型相比,高出 6.28%,说明将一维零序电流波形转化为二维 GAF 图像作为神经网络输入更能有效地表征出故障特征,二维数据包含了更多的特征信息得以更好的被 PCNN 所学习。和 No-MATT 变体模型相比,高出 2.5%,表明引入了多头注意力机制可以有效地提升对于图像特征的提取能力。本研究模型相较于 No-PCNN 变体模型准确率提升较小,提升 1.28%,但是训练时间大幅减少,提高选线效率。综上所述,本研究整体算法选线模型中的各个环节均有助于提升选线准确率。

3.4 配网 RTLAB 闭环仿真平台验证抗干扰性能

图 8 所示配网 RTLAB 闭环仿真平台,可以基于 MATLAB/Simulink 所搭建的配网模型进行半实物仿真,通过将电压电流波形数据输出至物理接口显示在实物终端上,并将终端的控制信号反馈回系统,形成闭环仿真。因此基于配网 RTLAB 闭环仿真平台进行测试,结果更为真实可信,可以更加全面地检验本研究所提选线方法的准确率和有效性。



图 8 配网 RTLAB 闭环仿真平台

Fig. 8 Distribution network RTLAB closed-loop simulation platform

在实际的工程项目里,变电站中的电力设备可能会对零序电流信号造成干扰,导致选线准确度下降。为了验证在噪声干扰时本研究选线方法的可靠性,在配网 RTLAB 闭环仿真平台将在 3.1 节中性点不接地系统的 160 组零序电流测试集分别加入信噪比为 10、20、30 dB 的高斯白噪声,输入到训练好的 PCNN-MATT 选线模型中

进行测试,含噪声干扰的配网 RTLAB 闭环仿真选线结果如表 6 所示。

表 6 配网 RTLAB 闭环仿真结果

Table 6 RTLAB closed-loop simulation results of distribution network

实验模型	10 dB	20 dB	30 dB	本研究
	模型	模型	模型	
中性点不接地系统准确率/%	96.25	97.5	98.125	99.4

由表 6 可知,本研究选线方法,即使在故障零序电流伴有 10 dB 信噪比的强噪声干扰下,仍能实现最低 96.25%的选线精度。进一步的研究表明,误选线主要体现在 3 000 Ω 高电阻接地场景中。由于发生高阻接地故障时的零序电流幅值较小,再加上强烈噪声干扰的影响,从而导致误选线。但经比较,同等实验条件下,本模型与其他选线模型相比,选线准确率受噪声干扰的影响最小。

3.5 其他选线模型效果对比

为验证本研究模型的选线性能,在相同试验环境和数据集集情况下,将本研究模型与 1D-GADF-CNN 模型、VMD-GAF-CNN 模型、ResNet 模型进行准确率对比。结果如图 9 所示。

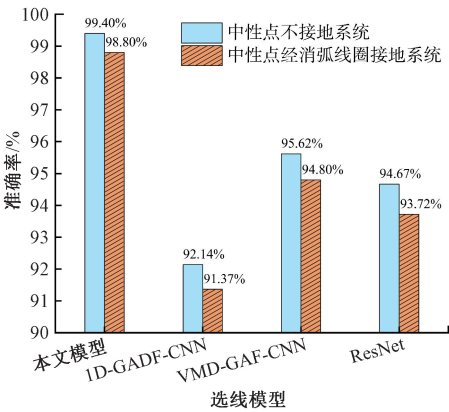


图 9 选线模型准确率对比图

Fig. 9 Comparison of accuracy of line selection model

从准确率柱状图来看,以中性点不接地系统来分析,1D-GADF-CNN 模型的选线准确率最低,为 92.14%。ResNet 模型的准确率为 94.67%,VMD-GAF-CNN 模型准确率为 95.67%,本研究模型准确率为 99.4%。对比实验结果表明本研究模型可以实现对于小电流接地系统单相接地故障发生后的准确选线,且选线准确率明显高于其他模型。

4 结 论

本研究提出了一种基于优化 VMD 及双通道 PCNN-MATT 的配网小电流接地系统单相接地故障选线方法,并

在 MATLAB/Simulink 和配网 RTLAB 闭环仿真平台上进行了仿真实验,得出结论如下:

引入霜冰优化算法,通过对于 VMD 算法参数组合进行寻优,并结合模糊熵算法,选取模糊熵值最小的 IMFs 分量作为优化输出。RIME-VMD-FuzzyEn 优化模型能够很好地去除原始信号中噪声干扰,提高了模型抗噪性。

利用格拉姆角场将一维零序电流信号转换为二维图像,包含了更多的特征信息得以更好的被神经网络学习。

采用的双通道 PCNN 卷积神经网络模型天生具有良好的并行处理能力,可以同时处理多个信息通道的数据,加速计算过程,提高效率。融合多头注意力机制提高神经网络挖掘特征信息的能力,提高了模型选线准确率。

将本研究模型在配网 RTLAB 闭环仿真平台上测试,进一步提高可信度。在添加噪声干扰的环境中进行仿真实验也证明本研究算法具有良好的抗噪能力。

参考文献

- [1] 詹惠瑜,刘科研,盛万兴,等. 有源配电网故障诊断与定位方法综述及展望[J]. 高电压技术, 2023, 49(2): 660-671.
ZHAN H Y, LIU K Y, SHENG W X, et al. Review and prospect of fault diagnosis and location methods for active distribution network [J]. High Voltage Technology, 2023, 49(2): 660-671.
- [2] 高文利,席东民,王晗,等. 基于特征融合与 ELM 的小电流接地选线新方法[J]. 电子测量技术, 2023, 46(13): 176-184.
GAO W L, XI D M, WANG H, et al. Based on feature fusion and ELM, a new method of small current grounding line selection [J]. Electronic Measurement Technology, 2023, 46(13): 176-184.
- [3] 王毅,李曙,李松浓,等. 瞬时特征下极限学习机在接地故障诊断中的应用[J]. 电子测量与仪器学报, 2022, 36(1): 212-219.
WANG Y, LI SH, LI S N, et al. Application of extreme learning machine in ground fault diagnosis with instantaneous characteristics [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1): 212-219.
- [4] 李晓波,张世乐,刘栩鹏,等. 基于零序电流幅值比的灵活接地系统高阻接地故障选线方法[J]. 电网技术, 2025, 49(6): 2595-2604.
LI X B, ZHANG SH L, LIU X P, et al. High resistance grounding fault line selection method for flexible grounding system based on zero sequence current amplitude ratio [J]. Power System Technology, 2025, 49(6): 2595-2604.
- [5] 闫森,黄纯,刘映彤,等. 基于零序功率比的灵活接地系统故障选线方法[J]. 电力系统及其自动化学报, 2023, 35(3): 46-52.
YAN S, HUANG CH, LIU Y T, et al. Fault line selection method for flexible grounding system based on zero sequence power ratio [J]. Journal of Electric Power Systems and Automation, 2023, 35(3): 46-52.
- [6] 徐桂培,吴小宁,张国龙,等. 基于五次谐波特征数据的配网单相接地故障识别方法[J]. 电工技术, 2021(4): 70-72, 76.
XU G P, WU X N, ZHANG G L, et al. Single-phase grounding fault identification method of distribution network based on fifth harmonic characteristic data [J]. Electrotechnical Engineering, 2021(4): 70-72, 76.
- [7] 刘漫雨,吕立平,丁冬,等. 基于 TDFT 非同步采样的首半波法小电流接地故障研究[J]. 电测与仪表, 2018, 55(23): 22-28, 33.
LIU M Y, LYU L P, DING D, et al. Research on small current ground fault with first half wave method based on TDFT asynchronous sampling [J]. Electrical Measurement & Instrumentation, 2018, 55 (23): 22-28, 33.
- [8] 李天友,王超,陈敏维,等. 典型小电流接地故障实例及暂态选线分析[J]. 电测与仪表, 2019, 56(2): 116-122.
LI T Y, WANG CH, CHEN M W, et al. Typical examples of small current grounding faults and analysis on transient fault line selection [J]. Electrical Measurement & Instrumentation, 2019, 56 (2): 116-122.
- [9] 陈晓旭,刘素梅,刘若溪. 计及燃弧频次的配电网单相接地故障分类与辨识[J]. 电子测量与仪器学报, 2024, 38(7): 236-246.
CHEN X X, LIU S M, LIU R X. Classification and identification of single-phase grounding fault in distribution network with ignition frequency [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(7): 236-246.
- [10] 韩笑,罗维真,王春蓓. 基于同步挤压小波变换的配电网单相高阻接地故障选线[J]. 科学技术与工程, 2019, 19(15): 150-156.
HAN X, LUO W ZH, WANG CH H. Fault line selection for single-phase high-impedance grounding faults in distribution network based on synchrosqueezing wavelet transform [J]. Science Technology and Engineering, 2019, 19(15): 150-156.
- [11] 李君,何敏,黄守道,等. 基于相暂态功率方向的有源配电网接地故障区段定位算法[J]. 高电压技术, 2023, 49(8): 3205-3215.

- LI J, HE M, HUANG SH D, et al. Fault section location algorithm for active distribution network based on phase transient power direction[J]. High Voltage Technology, 2023, 49(8): 3205-3215.
- [12] 冯光, 管廷龙, 王磊, 等. 利用电流-电压导数线性度关系的小电流接地系统接地故障选线[J]. 电网技术, 2021, 45(1): 302-311.
- FENG G, GUAN T L, WANG L, et al. Grounding fault line selection in small current grounding system using the linearity relationship of current-voltage derivative[J]. Power System Technology, 2021, 45(1): 302-311.
- [13] 侯思祖, 郭威, 曹立明, 等. EMD与自适应陷波滤波器的小电流系统单相接地故障仿真研究[J]. 现代电子技术, 2020, 43(19): 134-137, 141.
- HOU S Z, GUO W, CAO L M, et al. Simulation research on single-phase grounding fault of low current system based on EMD and Adaptive notch Filter[J]. Modern Electronic Technology, 2020, 43(19): 134-137, 141.
- [14] 孙蓉, 马寿虎, 葛乐, 等. 基于小波能量和EMD小电流接地故障选线[J]. 中国科技论文, 2017, 12(11): 1247-1251.
- SUN R, MA SH H, GE L, et al. Fault line selection for small current grounding faults based on wavelet energy and empirical mode decomposition(EMD)[J]. China Sciencepaper, 2017, 12(11): 1247-1251.
- [15] 王孔贤, 邵英, 王黎明. 基于改进变分模态分解和小波阈值法的单相接地故障电流降噪[J]. 科学技术与工程, 2023, 23(29): 12556-12566.
- WANG K X, SHAO Y, WANG L M. Noise reduction of single-phase ground fault current based on improved variational mode decomposition and wavelet threshold method[J]. Science Technology and Engineering, 2023, 23(29): 12556-12566.
- [16] 王建元, 张宇辉, 刘铖. 基于参数优化VMD和改进K聚类判据融合的配电网故障选线方法[J]. 南方电网技术, 2023, 17(7): 135-145.
- WANG J Y, ZHANG Y H, LIU CH. Distribution network fault line selection method based on parameter optimization VMD and improved K-cluster criterion fusion[J]. China Southern Power Grid Technology, 2023, 17(7): 135-145.
- [17] 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.
- HAO SH, ZHANG X, MA R Z, et al. A fault line selection method for small current grounding system based on improved GoogLeNet[J]. Power System Technology, 2022, 46(1): 361-368.
- [18] 苏斌, 侯思祖, 郭威. 基于图像融合和双通道卷积神经网络的配电网故障选线方法研究[J]. 电子测量与仪器学报, 2024, 38(9): 54-66.
- SU B, HOU S Z, GUO W. Research on fault line selection method of distribution network based on image fusion and two-channel convolutional neural network[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(9): 54-66.
- [19] 张健宝, 王磊, 江伟建. 基于VMD和Duffing振子算法的配电网差动保护[J]. 中国电力, 2024, 57(11): 26-35.
- ZHANG J B, WANG L, JIANG W J. Differential protection of distribution network based on VMD and Duffing oscillator algorithm[J]. Electric Power of China, 2024, 57(11): 26-35.
- [20] 张超, 张运, 张士勇, 等. RIME-VMD-LSSVM在气体绝缘电器局放故障识别的应用[J]. 电工技术, 2024(19): 178-183.
- ZHANG CH, ZHANG Y, ZHANG SH Y, et al. Application of RIME-VMD-LSSVM in partial discharge fault identification of gas-insulated electrical apparatus[J]. Electric Engineering, 2024(19): 178-183.
- [21] 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.
- LEI J, LI CH J, GUO L, et al. A new fault line selection method for distribution network based on GAF and convolutional neural network[J]. Proceedings of the CSU-EPSA, 2023, 35(2): 53-62.
- [22] ZHANG Q, QI ZH X, CUI P Y, et al. Detection of single-phase-to-ground faults in distribution networks based on gramian angular field and improved convolutional neural networks[J]. Electric Power Systems Research, 2023, 221: 109501.
- [23] 盛世龙, 王淑青, 王云鹤, 等. 基于格拉姆角场和PCNN-BiGRU模型的故障诊断方法及其应用[J]. 中国农村水利水电, 2025(2): 121-128.
- SHENG SH L, WANG SH Q, WANG Y H, et al. A fault diagnosis method based on gramian angular field and PCNN-BiGRU model and its application[J]. China Rural Water and Hydropower, 2025(2): 121-128.
- [24] 张圆梦, 李少波, 周鹏, 等. 基于多头注意力机制的残差网络深度学习推荐模型[J]. 计算机与数字工程, 2024, 52(7): 1955-1958, 1965.
- ZHANG Y M, LI SH B, ZHOU P, et al. A deep

learning recommendation model of residual network based on multi-head attention mechanism [J]. Computer & Digital Engineering, 2024, 52(7):1955-1958, 1965.

[25] 朱张莉, 饶元, 吴渊, 等. 注意力机制在深度学习中的研究进展[J]. 中文信息学报, 2019, 33(6): 1-11.

ZHU ZH L, RAO Y, WU Y, et al. Research progress of attention mechanism in deep learning[J]. Journal of Chinese Information Processing, 2019, 33(6): 1-11.

作者简介

韩冠行, 硕士研究生, 主要研究方向为配电网自动化及接地故障识别与定位。
E-mail: hgx20000825@163. com

韩如月(通信作者), 副教授, 硕士, 主要研究方向为电力系统规划、电力市场。
E-mail: hanry1979@163. com

贾雅君, 高级工程师, 博士, 主要研究方向为配网自动化及设备状态监测。
E-mail: jiayajun@sjtu. edu. cn