

基于 IDRSN 的高噪声环境下小电流接地系统故障选线方法研究

王 强^{1,2}, 吕鸿浩¹, 周小超¹, 张 安¹

(1. 三峡大学电气与新能源学院, 湖北 宜昌 443002; 2. 智慧能源技术湖北省工程研究中心, 湖北 宜昌 443002)

摘要: 小电流接地系统发生单相接地故障时, 暂态零序电流信号持续时间短、衰减快、易受电磁噪声干扰。针对现有选线方法抗噪能力不足的问题, 文中提出一种基于改进深度残差收缩网络(improved deep residual shrinkage network, IDRSN)的故障选线新方法。首先, 提出了一种收缩因子动态调节的改进阈值函数, 以减少有效特征的损失; 其次, 设计了基于高效通道注意力机制的自适应阈值模块(adaptive threshold block, ATB)与自适应收缩模块(adaptive shrinkage block, ASB), 并将两者嵌入到改进的残差收缩块(improved residual shrinkage building unit, IRSBU)中。该设计实现了阈值参数与收缩因子的自适应获取、模型去噪能力的增强和计算效率的优化。为验证所提选线方法的有效性, 在配网 10 kV 辐射型线路及 IEEE-34 节点仿真系统上进行了多种复杂干扰场景下的测试。结果表明, 所提 IDRSN 模型在-5 dB 强噪声下, 平均 F_1 分数较 DRSN 提升了 3.11%。

关键词: 小电流接地系统; 故障选线; 改进深度残差收缩网络; 阈值函数; 高效通道注意力机制

Research on Fault Line Selection Method for Small Current Grounding System in High Noise Environment Based on IDRSN

WANG Qiang^{1,2}, LYU Honghao¹, ZHOU Xiaochao¹, ZHANG An¹

(1. College of Electrical and New Energy, China Three Gorges University, Hubei Yichang 443002, China; 2. Hubei Provincial Engineering Research Center of Intelligent Energy Technology, Hubei Yichang 443002, China)

Abstract: In small current grounding systems, transient zero-sequence current signals during single-phase ground faults are characterized by short duration, fast decay, and susceptibility to electromagnetic noise interference. Addressing the insufficient noise robustness of existing line selection methods, this paper proposes a novel fault line selection method based on an Improved Deep Residual Shrinkage Network (IDRSN). Firstly, an improved threshold function with dynamically regulated shrinkage factors is proposed to reduce the loss of effective features. Secondly, an Adaptive Threshold Block (ATB) and an Adaptive Shrinkage Block (ASB), based on an efficient channel attention mechanism, are designed. These blocks are incorporated into an Improved Residual Shrinkage Building Unit (IRSBU). This design enables the adaptive acquisition of threshold parameters and shrinkage factors, enhances the model's denoising capability, and optimizes computational efficiency. To validate the effectiveness of the proposed line selection method, tests were conducted under various complex interference scenarios on a 10 kV radial distribution line system and the IEEE-34 node simulation system. The results demonstrate that the proposed IDRSN model achieves an average F_1 -score improvement of 3.11% compared to the DRSN model under strong noise conditions of -5 dB.

Key words: low current grounding system; fault line selection; improved deep residual contraction network; threshold function; efficient channel attention

0 引言

为提升配电网运行可靠性, 中性点采用小电流接地方式已成为主流趋势^[1]。然而, 伴随中国新能源技术的快速发展与相关政策的支持, 大量电力电子设备在配电网中广泛使用, 其中包括间

歇性清洁能源发电装置、电动汽车充电设施及非线性负荷。此类设备的频繁投切、出力波动及随机充电行为, 向系统注入了大量高次谐波、间谐波和随机噪声^[2]。这些复杂干扰相互叠加使得当代配电网被动地置于高噪声环境中。在此背景

基金项目: 国家自然科学基金资助项目(52277012)。

Project Supported by National Natural Science Foundation of China(52277012).

下,配网故障选线准确率受到影响,尤其对故障占比超过 80%的单相接地选线的准确率影响更甚^[3]。

具体而言,高噪声环境是指上述电力电子设备产生的电磁干扰叠加环境噪声,导致信号在采集传输过程中质量严重下降、关键特征难以识别。目前大多学者采用暂态零序电流信号作为单相接地故障选线的特征量^[4-5],其具有的持续时间短和衰减快的特点。这些特点使其在高噪声环境下故障特征极易被噪声淹没,进而导致基于暂态信号相关分析理论的故障选线方法准确率降低。因此,在高噪声干扰背景下,研究如何提升配电网单相接地故障选线的准确率具有重要的研究意义。

针对暂态零序电流信号降噪,已有多种算法被提出。包括经验模态分解(EMD)^[6]、小波阈值分解^[7]和变分模态分解(VMD)^[8]等。如文[8]利用智能算法动态优化VMD中的分解层数 K 与惩罚因子 α ,避免人工参数设置偏差导致噪声分量残留。文[9]则提出一种基于CEEMD结合自相关阈值的去噪方法,利用互补噪声对的多次添加与平均运算抑制模态混叠,再通过自相关函数筛选出最优本征模态分量以实现信号降噪。归根结底,上述算法的核心思想都是将目标信号分解为一系列相对简单、物理意义相对明确的子分量,通过预设的筛选机制舍弃噪声主导分量以实现信号的去噪重构。其差异仅仅是分解和筛选机制的不同。分解机制的关键参数往往需要人工专家经验来确定调整,预设的筛选机制在面对现实更

复杂的环境时是否还能达到其理想效果有待验证。

针对上述局限性,基于数据驱动的神经网络方法为信号去噪提供了新的思路。这类方法优势在于摒弃了传统方法对信号进行显式分解和预设筛选规则的限制,转而构建了一个端到端的映射函数,直接学习含噪信号到干净信号的隐藏规律。在大量数据的训练下,模型可泛化到多个未知场景,这一优势已经在电力系统故障诊断中得到验证。目前,针对配电网单相接地故障选线这一领域,已有多种神经网络模型得到应用。如文[10]选择残差网络(ResNet)作为故障选线模型,网络中残差思想有效解决了网络层数增加引发的梯度消失现象,增强了特征提取能力。文[11]提出了一种基于改进DenseNet故障选线方法。通过在网络中嵌入SE注意力机制^[12]以进一步提升网络对故障特征的挖掘能力。虽然上述模型已具备优异的选线性能,但是其模型架构中缺乏针对性的抗干扰机制。随着背景噪声的增加,仅依赖网络自身的抗噪能力难以维持理想的选线性能。为增强模型的抗噪性,文[13]提出了深度残差收缩网络(deep residual shrinkage network, DRSN)。该网络通过引入软阈值函数以及SE注意力机制实现了自适应滤波降噪与特征增强的一体化。文[14]已将此网络用于电力系统暂态稳定评估中,有效解决了噪声干扰导致的分类准确率下降问题。然而,DRSN所采用的软阈值函数具有恒定收缩的局限性,对此文[15]提出了一种改进半软阈值函数,缓解了模型去噪过程中部分

有效特征的丢失的问题。但此函数仍然采用固定收缩度,无法根据输入特征重要程度进行自适应收缩,需要进一步改进以提升模型性能。

为此,针对高噪声环境下现有选线方法准确率低、抗噪性弱的问题。文中提出一种基于改进深度残差收缩网络(improved deep residual shrinkage network, IDRSN)的故障选线新方法。首先,提出一种采用收缩因子调节的改进阈值函数,用于解决软阈值函数在降噪过程中部分有效特征丢失的问题。其次,为了将改进阈值函数嵌入网络中,在RSBU块中设计了基于高效通道注意力机制(efficient channel attention, ECA)^[16]的自适应阈值模块(adaptive threshold block, ATB)和自适应收缩模块(adaptive shrinkage block, ASB),实现阈值参数与收缩因子的双获取、模型去噪能力的增强和计算效率的优化。最终,在仿真软件中搭建两类配电网模型并构建故障数据集,用于所提模型测试与验证。通过与ResNet、DRSN两个基线模型的多方面对比,验证了文中方法在故障选线方面的优越性。

1 噪声对暂态零序电流的影响

在当代智能配电网中,多数单相接地故障的选线方法依赖暂态零序电流,其主要通过同步相量测量单元(PMU)等电气设备进行实时采集^[17]。然而此采集装置常安装于结构紧凑的一次设备间隙中,或直接放置在设备外壳^[18]。这种恶劣的安装环境使得故障信号在采集、传递和处理的过程中易受到各种电磁谐波和环境噪声干扰,从而导致信号变形或失真。此外,当发生高阻接地

时,暂态零序电流幅值显著衰减,使得有效信号更易湮没于噪声背景中。

为评估噪声对暂态信号的影响,文中建立含噪声的暂态零序电流数学模型:

$$i_{ts}(t) = \beta i_t(t) + S(t) \quad (1)$$

$$\begin{cases} i_t(t) = i_1(t) + i_2(t) + i_3(t) + i_4(t) \\ i_1(t) = \cos(2\pi \times 50t + 60^\circ) \\ i_2(t) = 4e^{-56t} \cos(2\pi \times 250t + 30^\circ) \\ i_3(t) = 7.2e^{-102t} \cos(2\pi \times 315t) \\ i_4(t) = e^{-5.5t} \end{cases} \quad (2)$$

式(1)、(2)中: $i_t(t)$ 为理想的暂态零序电流^[19]; β 为表征过渡电阻影响幅值的衰减因子; $S(t)$ 为符合正态分布的高斯白噪声。

根据 IEEE C37.118 标准^[20], PMU 相量测量误差应小于 1%, 按照信噪比计算式

$$SNR(\text{dB}) = 10 \log_{10} \left(\frac{P_{\text{signal}}}{P_{\text{noise}}} \right) \quad (3)$$

含有 1% 的噪声干扰对应信噪比大小约为 20 dB。因此,文中设置 $\beta=1/0.25$, 信噪比为 20 dB/10 dB/-1 dB, 形成图 1 所示的 6 种典型干扰场景。同时采用皮尔逊相关系数 P 量化噪声污染下的波形畸变规律,皮尔逊相关系数定义如下

$$P = \frac{\text{Cov}(i_t, i_{ts})}{\sigma_{i_t} \cdot \sigma_{i_{ts}}} \quad (4)$$

式(4)中: $\text{Cov}(\cdot)$ 为协方差; $\sigma_{i_t} \cdot \sigma_{i_{ts}}$ 分别为其标准差。皮尔逊相关系数取值范围在(-1, 1), 其值越大,相关性越强。不同干扰场景下的含噪电流 $i_{ts}(t)$ 波形见图 1, 对应的相关系数见表 1, 相关程度的判定标准见文[21]。




图 1 不同场景下的暂态零序电流波形

Fig. 1 Transient zero-sequence current waveforms in different scenarios

表 1 不同场景下的相关系数

Table 1 Correlation coefficients in different scenarios

β	信噪比 (SNR)/dB	相关系数 P	相关程度
1.00	20	0.995 0	极强相关
	10	0.953 5	极强相关
	-1	0.665 3	强相关
0.25	20	0.928 5	极强相关
	10	0.620 2	强相关
	-1	0.217 5	弱相关

从图 1 和表 1 中可得：在 SNR 与 β 的共同作用下，暂态零序电流波形发生明显变化。观察图 1(a)-(c)可见：在固定 β 值时， SNR 越低，噪声对波形特征的干扰越强，表现为波形失真加剧

与相关系数 P 的持续下降，其降幅最高可达 33.2%；同时，对比图 1(a)-(c)与图 1(d)-(f)发现：在相同噪声背景下，随着 β 值减小，波形振幅均呈现一致性的衰减。表明较大的故障接地电阻会显著削弱信号自身的固有强度，使得本就微弱的有效信息更易被噪声所淹没。综上，高阻接地降低了信号的自身强度，强噪声则直接破坏波形的形态特征。当这两种不利因素同时发生时，信号特征破坏程度最甚。

2 深度残差收缩网络理论分析

深度残差收缩网络(deep residual shrinkage network, DRSN)^[13]是一种能有效处理含噪信号、提升故障诊断性能的深度神经网络结构，见图 2。




图 2 深度残差收缩网络(DRSN)结构

Fig. 2 Deep residual shrinkage network (DRSN) framework

从图 2 可以看到，DRSN 的核心在于所构造的残差收缩模块(residual shrinkage building unit, RSBU)，其结构见图 3。图 3 中该模块集成了软阈值函数与 SE 注意力机制，利用软阈值函数的收缩特征性将阈值区域内的输入特征置 0、阈值区域外的特征进行恒定收缩以实现特征图非线性滤波与降噪。同时，阈值函数中的阈值参数无需人工设定，而是通过 SE 机制自动学习获得，该机制通过学习与调整通道间的重要程度为每个通道生成最优阈值。




图3 残差收缩单元(RSBU)

Fig. 3 Residual shrinkage building unit (RSBU)

3 改进深度残差收缩网络(IDRSN)选线模型的构造

文中所提的 IDRSN 模型是以 DRSN 为主干, 对其中的软阈值函数与 SE 机制进行改进优化。

3.1 改进阈值函数的收缩性分析

RSBU 块利用软阈值函数消除输入特征图中噪声等无关信息, 其函数表达式为

$$y = \begin{cases} \text{sgn}(x) \cdot (|x| - \tau), & |x| \geq \tau \\ 0, & |x| < \tau \end{cases} \quad (5)$$

从式(5)可以看到, 软阈值函数是一个连续的函数, 能保证处理后的数据具有良好的平滑性。当 $|x| \geq \tau$ 时即输入在阈值区域外时, 输出 y 与输入 x 之间存在恒定偏差 τ 。这种恒定收缩会导致网络在训练过程中部分有效特征被丢弃, 影响网络的性能。为克服上述缺陷, 需要调整收缩程度来避免有效特征损失, 为此文中提出一种改进阈值函数以实现自适应收缩, 其公式为

$$y = \begin{cases} \text{sgn}(x) \cdot \left(|x| - \alpha\tau - \frac{(1-\alpha)\tau}{e^{\frac{|x|-\tau}{\alpha}}} \right), & |x| \geq \tau \\ 0, & |x| < \tau \end{cases} \quad (6)$$

式(6)中, α 为收缩因子, 取值范围在 $(0, 1)$ 。

在连续性方面, 分析函数在 $|x| = \tau$ 处的左、

右极限值

$$\begin{cases} \lim_{x \rightarrow \tau^+} y = \tau - \alpha\tau - \frac{(1-\alpha)\tau}{e^0} = 0 \\ \lim_{x \rightarrow \tau^-} y = 0 \end{cases} \quad (7)$$

由式(7)可得, 函数在 $|x| = \tau$ 处的左、右极限值均为零, 保证了改进阈值函数仍然具有良好的连续性。

在收缩性方面, 分析 $|x| \geq \tau$ 时 α 分别趋近于

左右极限值对改进阈值函数的影响:

$$\begin{cases} \lim_{\alpha \rightarrow 1^-} y \approx \text{sgn}(x) \cdot (|x| - \tau) \\ \lim_{\alpha \rightarrow 0^+} y \approx x \end{cases} \quad (8)$$

由式(8)可得, 当 $\alpha \rightarrow 1^-$ 时, 改进阈值函数特性与软阈值函数类似即最大收缩度削弱特征。而当 $\alpha \rightarrow 0^+$ 时, 其函数特性与硬阈值函数类似即最小收缩度完全保留特征。改进阈值函数在正半轴的示意图见图4, 负半轴曲线可根据奇偶性得到。当 α 取 0.05、0.1、0.3、0.5、0.7、0.9 时, 其函数均在软、硬阈值函数间变动, 同时具有软、硬阈值函数的优点。




图 4 改进阈值函数示意图

Fig. 4 Improved threshold function diagram

3.2 注意力机制的优化

SE 机制通过堆叠两个全连接层来捕捉通道间的交互权重,旨在自适应地确定阈值函数中的阈值参数。然而,在此过程中,为了控制模型参数量,全连接层通常会对特征图进行降维操作。这种操作不可避免地会损害通道间信息的直接交流,造成通道信息损失。针对这一局限,文中引入高效通道注意力机制 ECA,该机制采用大小为 k 的一维卷积核进行跨通道局部交互来捕获通道关系,规避了全连接层可能造成的通道信息损失。为了直观对比两种机制,其原理图见图 5。




图 5 两种注意力机制的原理对比图

Fig. 5 Comparison of schematic diagrams of two attention mechanisms

图 5 中,信息流在“降维”和“升维”的过程中发生了较大变化,信息损失便源于此过程中。若 SE 机制不进行降维操作,假设特征图经全局平均池化(global average pooling, GAP)处理后输出的特征尺寸为 $C \times 1 \times 1$,则依次经过两个全连接层后所需的总参数量高达 $2C^2$ 。与之相比,ECA 机制采用一维卷积核对特征图进行操作,该卷积作用于每个通道及其 k 个相邻通道,所需总参数量仅为 kC 。其中 k 的计算式为

$$k = \psi(C) = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{\delta}{\gamma} \right\rfloor_{\text{odd}} \quad (9)$$

式(9)中: $\lfloor \cdot \rfloor_{\text{odd}}$ 为输出最近的奇数值; δ 与 γ 分别是超参数,分别设置为 1 和 $2^{[16]}$ 。对比两种机制的参数量可以发现:通过采用局部跨通道交互的一维卷积,ECA 机制成功避免了降维操作带来的信息损失,同时在计算复杂度上从 $O(C^2)$ 降低到 $O(C)$,实现了性能与复杂度之间的平衡。

3.3 残差收缩模块的改进

首先,文中将 RSBU 中的 SE 机制替换更好的 ECA 机制以优化模型性能与复杂度,并据此设计了自适应阈值模块 ATB。其次,将第 3.1 节所提的改进阈值函数替代软阈值函数以减少有效特征损失。为最优保留有效特征不丢失,文中借鉴了注意力机制用于获取阈值参数的思想,将改进阈值函数中的收缩因子 α 同样采用 ECA 机制学习获得。此时收缩因子 α 便能动态感知通道间的重要程度,并自适应调整函数收缩度以最优

保留有效信息。据此同样设计了自适应收缩模块 ASB。

将 ATB 与 ASB 这两个模块共同嵌入到

RSBU 中，最终得到改进残差收缩块 IRSBU(improved residual shrinkage block)，其结构见图 6。




图 6 改进残差收缩块结构图(IRSBU)

Fig. 6 Improved residual shrinkage block frame(IRSBU)

改进阈值函数的自适应收缩特性需要阈值参数与收缩因子的联合调控。因此如图 6 所示，在 IRSBU 模块中 ATB 和 ASB 两个模块为并行架构，这样阈值参数与收缩因子会同时输入到改进阈值函数中，进而实现特征信息的有效过滤或保留。

IRSBU 实现去噪的具体步骤如下：

1)特征提取：输入特征图 $X \in \mathbb{R}^{C \times W \times 1}$ 经过两层卷积核大小与步长均相同的一维卷积层进行特征的初步学习，输出得到相同维度的中间特征图 $X' \in \mathbb{R}^{C \times W \times 1}$ 。

2)获取自适应阈值：在 ATB 模块中，首先对特征图 X' 沿空间维度 w 进行绝对值 ABS 和 GAP 处理，得到一维通道特征向量 β

$$\begin{aligned} \beta_c &= \text{GAP}(|X'_c|) \\ &= \frac{1}{W} \sum_{i=1}^W |x'_{c,i}|, \forall c \in \{1, 2, \dots, C\} \end{aligned} \quad (10)$$

随后利用 ECA 机制学习通道间依赖关系，即对 β 进行一维卷积操作并通过 Sigmoid 激活函数输出得到通道阈值算子 Z

$$Z = \text{Sigmoid}(W_k^{ATB} * \beta) \quad (11)$$

式(11)中， W_k^{ATB} 为卷积核大小为 k 的一维卷积对应的权重矩阵。其卷积核大小 k 的计算公式参考式(9)。

最后，将通道特征向量 β 与通道阈值算子 Z 进行元素逐级相乘，得到最终的通道自适应阈值向量 τ

$$\tau = \beta \otimes Z \quad (12)$$

由于 $\beta_c \geq 0$ 且 $Z_c \in (0, 1)$ ，保证计算得到的每

个通道阈值 $\tau_c \geq 0$ 。

3)获取自适应收缩因子: 与 ATB 模块类似, 在 ASB 模块中, 首先对 X' 沿维度 W 应用 GAP, 得到一维通道特征向量 β' :

$$\begin{aligned}\beta'_c &= \text{GAP}(X'_c) \\ &= \frac{1}{W} \sum_{i=1}^W x'_{c,i}, \forall c \in \{1, 2, \dots, C\}\end{aligned}\quad (13)$$

其次为了学习每个通道的特征信息, 同样利用 ECA 机制对 β' 进行核大小为 k 一维卷积操作。并通过 Sigmoid 激活函数输出得到收缩因子向量 α

$$\alpha = \text{Sigmoid}(W_k^{\text{ASB}} * \beta') + T \quad (14)$$

式(14)中, T 是一个非常小的数, 文中取

10^{-7} , 以防止后续除零导致梯度爆炸。

4)自适应收缩去噪: 将上述步骤得到的特征图 X' 、阈值向量 τ 与收缩因子 α 一起输入到改进阈值函数中得到去噪后的特征图 X'' 。

5)残差连接输出: 最后, 利用残差机制将原始输入 X 与去噪后的特征 X'' 相加, 得到 IRSBU 的最终输出:

$$\text{Output} = X + X'' \quad (15)$$

3.4 基于 IDRSN 的接地故障选线模型

为有效抑制噪声干扰并准确提取其故障特征, 文中构建了基于 IDRSN 的故障选线模型, 其结构详见图 7。该模型可分为输入层、自适应去噪与特征提取层、分类层 3 部分组成。




图 7 故障选线流程图

Fig. 7 Flowchart of the fault line selection

输入层由一维卷积、BN 和 ReLU 构成。其功能是初步提取故障信号中提取浅层特征。

自适应去噪与特征提取层为文中模型的核心, 由 12 个级联的 IRSBU 组成。经过 12 层 IRSBU 的逐级、深度处理, 模型能够从初始的浅层特征中逐步提取出更深层次、更纯净的故障

特征。

分类层由 BN、ReLU、GAP 和全连接输出层 FC 构成, 负责将深层特征映射为故障结果。IDRSN 的具体架构参数详见表 2。

表 2 IDRSN 模型的网络参数

Table 2 Network parameters of IDRSN

层名称	层数量	输出尺寸	参数(卷积核, 通道数, 步长)
-----	-----	------	------------------

卷积层	1	4×256	(3, 4, 2)
IRSB _{U1}	1	4×128	(3, 4, 2)
IRSB _{U2}	3	4×128	(3, 4, 1)
IRSB _{U3}	1	8×64	(3, 8, 2)
IRSB _{U4}	3	8×64	(3, 8, 1)
IRSB _{U5}	1	16×32	(3, 16, 2)
IRSB _{U6}	3	16×32	(3, 16, 1)
BN, ReLU, GAP	1	16	—
FC	1	2	—

基于 IDRSN 的故障选线流程如下：

1)样本库构建。基于仿真软件搭建配电网模型，设置不同故障工况，采集故障发生前后共两个半周期内所有出线首端零序电流信号，形成故障样本数据库。

2)数据预处理与划分。对采集的故障零序电流数据进行归一化处理以消除量纲差异。随后，将处理后的样本数据集按照一定比例划分为训练集、验证集与测试集。

3)模型训练。将训练集输入 IDRSN 模型持续优化网络权重参数，迭代更新直至模型性能达到稳定收敛状态，保存最优模型参数。

4)模型性能评估。使用预留的测试集对训练完成的模型进行全面测试，以验证模型的实际泛化能力与选线性能。

3.5 模型评价指标

接地故障选线本质上是一个二分类问题，即目标馈线是否被正确研判为故障线路。因此，文中引入混淆矩阵(见表 3)对模型输出结果进行清晰表征，并计算混淆矩阵中的统计量得到准确率(Accuracy)、精确率(Precision)、召回率(Recall)和 F_1 分数(F_1 -Score)四项性能评估指标见式(16)-(19)。

表 3 混淆矩阵

Table 3 Confusion matrix

线路状态	研判结果	
	故障线路	正常线路
故障线路	T_P	F_N
正常线路	F_P	T_N

$$\text{Accuracy} = \frac{T_P + T_N}{T_P + F_P + T_N + F_N} \quad (16)$$

$$\text{Precision} = \frac{T_P}{T_P + F_P} \quad (17)$$

$$\text{Recall} = \frac{T_P}{T_P + F_N} \quad (18)$$

$$\text{F1-Score} = \frac{2T_P}{2T_P + F_P + F_N} \quad (19)$$

式(16)-(19)中：真正例 T_P 为模型正确的将故障馈线判别为故障的数量。真负例 T_N 为模型正确的将正常馈线判别为正常的数量。假正例 F_P 为模型将正常馈线误判为故障的数量(误报)。假负例 F_N 为模型将故障馈线误判为正常的数量(漏报)。

4 实验仿真结果与分析

文中在配备了 Intel(R) Core(TM) i9-12900HX CPU 与 NVIDIA GeForce RTX 4060 GPU 硬件的计算机上搭建实验仿真平台，选线模型采用 PyTorch 2.0 深度学习框架开发搭建。

4.1 故障数据集的建立

为验证文中所提方法的通用性，在 MATLAB/Simulink 仿真平台搭建了两个典型的配电网模型：10 kV 辐射型配网模型(见图 8)和 IEEE-34 节点系统模型(见图 9)。辐射型配网模型包含架空线、电缆线以及架空—电缆混合线路共计 5 条出线，其具体线路参数详见表 4。系统中性点采用消弧线圈接地方式，补偿度设置为过

补偿 8%。IEEE-34 节点系统则划分为 4 个分区，用以模拟不同馈线上的故障场景。文中引入分布式电源 DG 以模拟实际工况：在辐射型网络中，逆变型电源 DG_1 、 DG_2 通过公共耦合点(PCC)接入；在 IEEE-34 节点系统中，在节点 812 接入光伏电站，节点 890 与 848 接入风力发电系统。




图 8 10 kV 辐射型配电网模型

Fig. 8 10 kV radial distribution network model




图 9 IEEE-34 节点系统模型

Fig. 9 IEEE-34 node system model

表 4 线路正序和零序参数

Table 4 Line positive sequence and zero sequence

parameter				
馈线类型	相序	$R/(\Omega \cdot \text{km}^{-1})$	$L/(\text{mH} \cdot \text{km}^{-1})$	$C/(\mu\text{F} \cdot \text{km}^{-1})$
架空	正序	0.170	1.017	0.115
	零序	0.320	3.560	0.006
电缆	正序	0.270	0.255	0.376
	零序	2.700	1.109	0.276

基于上述仿真模型，文中系统地构建故障数据集。首先，在每条馈线首端安装 PMU 用来采集故障发生前后的暂态零序电流信号。由于暂态零序电流信号的有效频段集中在 3 kHz 以内^[22]，

依据奈奎斯特采样定理，文中采样频率设置为 10 kHz。其次，设置不同的接地故障工况包括：故障位置、过渡电阻大小、故障初相角等，辐射型配网模型接地故障工况参考表 5。采用单变量控制法编写脚本程序进行循环仿真。最终，在辐射型配电网模型上采集到 3 600 组故障样本数据，在 IEEE-34 节点系统上采集到 576 组样本数据。

表 5 辐射型配电网模型故障工况参数表

Table 5 Fault condition parameter table for radial distribution network model

故障参数	参数取值
故障线路	L_1, L_2, L_3, L_4, L_5
故障初相角/(°)	0, 30, 60, 90, 120, 150
故障位置	距线路首端 10%、50%、90%处
过渡电阻/ Ω	0~2 000

4.2 模型参数选定

模型共进行 100 次迭代训练。优化器选用 SGD-M 算法，动量系数设为 0.9。学习率采用分段衰减：前 40 个周期设为 0.1，中间 40 个周期降至 0.01，最后 20 个周期进一步降至 0.001。批大小为 128。为抑制过拟合，引入 L2 正则化，其系数设定为 0.000 1。

4.3 IDRSN 的训练结果与测试

基于 4.2 节参数配置，IDRSN 模型首先在辐射型配电网数据集上进行训练。数据集按 8:2 比例随机划分为训练集与独立测试集，其中训练集内部进一步依据 8:2 比例细分为训练子集与验证子集。模型通过训练子集进行参数优化，并利用验证子集实时监控过拟合风险。训练与验证过程的损失函数及性能指标变化见图 10。




图 10 辐射型配网数据集训练过程指标变化

Fig. 10 Index changes in training process of radial distribution network data set

如图 10(a)所示, 训练损失与验证损失曲线收敛趋势高度一致。在训练前期损失值均出现一定程度的波动, 随着轮次增加模型约在 45 个周期时达到收敛, 损失趋近于零, 后期未出现波动。这表明文中模型在单相接地故障选线问题上具备快速收敛特性。对于训练前期损失函数的波动, 分析认为与文中采用的分段衰减学习率策略有关: 训练初期设置较大的学习率虽可加速模型初步收敛, 但可能因参数更新步幅过大, 在最优解附近产生震荡; 随着训练轮次增加, 学习率逐步减小, 模型得以稳定收敛至全局最优解附近, 损失值亦随之趋于平稳。图 10(b)进一步显示, 四项评价指标虽在前期存在小幅波动, 但同样在 45 个周期附近四项指标均达到 100%。上述现象

证明 IDRSN 在辐射型配电网故障检测任务中具有优异的稳定性。

为验证文中所提出模型的通用性, 用 IEEE-34 数据集对其进行泛化能力测试。该数据集以同样的比例划分为训练集与测试集。模型性能指标变化曲线见图 11。




图 11 IEEE-34 数据集训练过程指标变化

Fig. 11 IEEE-34 data set training process index changes

如图 11 所示, 尽管 IEEE-34 系统的拓扑复杂度更高, IDRSN 仍表现出良好的适应能力, 四项评价指标在初期波动后亦同步收敛至最优水平。

基于训练完成的模型, 采用预留的独立测试集进行最终性能验证。通过混淆矩阵呈现了模型在两个数据集上的分类结果(纵轴为实际标签, 横轴为预测标签)见图 12。

	故障	正常		故障	正常
故障	114	0	故障	29	0
正常	0	576	正常	0	86
(a)辐射型配网研判结果			(b)IEEE-34系统研判结果		

图 12 测试集的混淆矩阵

Fig. 12 Confusion matrix of test set

结果显示: 模型在两个测试集上均没有出现误判, 所有测试样本均被正确分类。证明 IDRSN 对配电网结构变化具有鲁棒性, 其泛化能力不受

特定拓扑限制。

4.4 噪声干扰下的性能测试与消融实验

4.4.1 抗噪性能测试

鉴于配电网实测数据易受环境噪声干扰,评估模型的抗噪性能显得尤为重要。为系统性测试文中所提模型的抗噪性能,将文中模型与 ResNet、DRSN 两个基线模型进行实验对比。为确保实验条件的公平性,接下来所有的对比模型均采用与 IDRSN 相同的网络框架配置与超参数

设置,仅在核心特征提取单元模块设计上存在差异。

为模拟实际工况下的噪声干扰,将不同水平,服从标准正态分布的高斯白噪声注入到辐射型配电网与 IEEE-34 系统两个数据集中。设置 -5、-1、10 dB 3 种典型的信噪比,分别对应极端噪声、强噪声和弱噪声环境,对比实验结果见图 13。




图 13 不同噪声下的对比实验结果

Fig. 13 Comparative experimental results under different noises

图 13 显示,在不同噪声等级下 IDRSN 在准确率、精确率、召回率和 F_1 分数上均优于两个基线模型,且在两个数据集上表现稳定。

具体而言,如图 13(d)所示,当信噪比从 10 dB 降至 -1 dB 时,在两个数据集下 3 个模型的平均 F_1 分数降幅分别为 5.47%(IDRSN)、

8.96%(DRSN)和 11.34%(ResNet)。其中,ResNet 性能下降最为显著。这表明,若模型中未引入针对性的抗噪机制,仅依赖模型自身的抗噪能力难以在高噪声环境下维持其选线性能。当信噪比进一步降至 -5 dB 时, IDRSN 和 DRSN 的 F_1 值降幅已达 13.38%和 16.03%, IDRSN 的降

幅较 DRSN 低了 2.65 个百分点。这证明了在 IDRSN 中采用改进阈值函数与更好的 ECA 机制能够进一步提升模型在高噪声环境下的适应能力，泛化能力得到进一步增强。

在电力系统故障诊断中，漏检故障可能导致设备损坏、停电甚至更加严重的安全事故。因此评估各模型的召回率尤其重要。如图 13(c) 所示，在极端噪声环境-5 dB 下 IDRSN 的在两个数据集上平均召回率约为 80.41%较 DRSN 提升 3.5%，较 ResNet 提升超 8.5%。表明通过 12 层 IRSBU 的逐级、深度处理，文中模型在强噪声干扰下仍能有效捕获暂态信号的关键特征，降低故障线路漏检的风险。

4.4.2 消融实验

为深入评估所提模型中各改进点在高噪声环境下对选线准确率的具体贡献，文中设计了一系列消融实验。通过系统性地添加或替换核心组件，构建了 4 个变体模型，测试-4 dB 到 4 dB 噪声下各模型的准确率、训练时间与计算量。具体而言，针对 IRSBU 中两个核心创新点——改进阈值函数与 ECA 机制，设置了如下变体模型(见表 6)：模型 A 为文中所提的 IDRSN，采用 IRSBU 模块；模型 B 在 RSBU 块的基础上采用改进阈值函数；模型 C 则在 RSBU 块中采用 ECA 机制；模型 D 采用基础的 RSBU 块。消融实验结果见图 14 与表 7。

表 6 消融实验变体模型设置

Table 6 Ablation experiment variant model setting

模型	改进阈值函数	ECA 机制
A	有	有




图 14 消融实验结果

Fig. 14 Ablation experimental results

表 7 各变体模型实验结果

Table 7 Experimental results of each variant model

模型	平均准确率/%	平均训练时间/s	计算量
A	96.13	54.47	711 896
B	95.74	67.27	722 328
C	93.86	34.32	710 736
D	93.51	43.32	716 504

基于图 14 与表 7 的实验结果，采用改进阈值函数的模型 A 与模型 B 相较于采用软阈值函数的模型 C 与模型 D，在平均准确率上分别提升了 2.27%与 2.25%。其原因在于：改进阈值函数通过收缩因子自适应调整函数的收缩度，将大于阈值部分信息尽可能保留，避免有效特征损失，提升了模型在噪声环境下的适应能力。为进一步探究收缩因子对特征保留的具体影响，选取模型 B 与模型 D 架构中处于相同位置的 RSBU 块，可视化展示特征图输入该模块前后，特征图中特征值的处理过程。可视化见图 15。




图 15 特征图在模型 B 与模型 D 中的变化过程

Fig. 15 The change process of feature map in model B and model D

如图 15 所示,在注意力机制的帮助下,阈值参数能根据特征图中特征值的重要性进行针对性处理。部分低于阈值的特征值被视为噪声因此置 0。对于大于阈值的有效特征值:由于采用了软阈值函数,模型 D 中有效特征值无法被完全保留;而采用了改进阈值函数的模型 B,则实现了这一点。

虽然采用改进阈值函数使模型 B 的性能得到提升,但其训练时间、计算量均为四者最高,原因在于函数中的收缩因子也需要通过注意力机制计算获取。与模型 B 相比,模型 A 在训练时间上减少了 19.03%,在计算量上降低了 1.44%,验证了 ECA 机制的优秀性能。综上,

文中所提 IDRSN 模型将改进阈值函数的抗噪优势与 ECA 机制的轻量化相结合,实现了精度与效率上的良好平衡。

4.4.3 噪声与高阻接地耦合环境下抗干扰能力分析

由于高阻接地与噪声的耦合效应会显著破坏故障信号的关键特征,因此评估模型在此类环境下的抗干扰能力至关重要。以辐射型配电网为例,调整表 5 中的过渡电阻参数,生成如表 8 所示的 4 个故障数据集。同时,为模拟高阻接地与噪声的耦合,所有样本均添加了-1 dB 的白噪声进行干扰。测试结果见表 8。

表 8 不同过渡电阻阻值下的各模型准确率

Table 8 The accuracy of each model under different

		transition resistance values		
过渡电阻大小/ Ω	样本数量	准确率/%		
		IDRSN	DRSN	ResNet
1 000	360	95.53	93.81	91.96
1 200	360	95.01	92.11	90.84
1 500	360	94.44	91.78	90.25
2 000	360	92.98	89.04	86.36
平均值		94.49	91.69	89.85

由表 8 可知,尽管在噪声环境下过渡电阻阻值的增加加剧了信号特征的破坏,导致所有模型的准确率均呈现下降趋势,但文中模型仍有平均 94.49%的较高准确率优于对比模型。

4.4.4 不同采样频率对选线准确率的影响

实际采样的暂态零序电流信号受采集装置性能限制,其采样频率可能不足,导致在较低采样频率下故障信息丢失,进而影响选线准确率。为验证文中所提方法在低采样频率下的有效性,以辐射型配电网模型为例,分别以 4、2、1、0.5 kHz 的采样频率对故障信号进行重

采样构建数据集，并统一添加 0 dB 白噪声以模拟噪声影响。模型测试结果见表 9。

表 9 不同采样频率下的各模型准确率
Table 9 Accuracy of each model at different sampling frequencies

采样频率/kHz	准确率/%		
	IDRSN	DRSN	ResNet
4.0	94.09	93.03	92.2
2.0	92.46	91.87	90.36
1.0	89.32	89.01	88.62
0.5	86.18	86.15	85.99

从表 9 可以看到，采样频率的不足严重影响了各模型的选线性能。尽管如此，在 4 kHz 的采样频率下，IDRSN 的准确率仍优于 DRSN 和 ResNet 两个基准模型，分别高出 1.06%与 1.89%。随着采样频率的逐步降低，模型间的性能差异逐渐缩小。在最低的 0.5 kHz 采样频率下，准确率差异已几乎消失。其原因在于过低的采样频率导致信号中的有效信息大量丢失，在信息严重缺乏的情况下，不同模型的抗噪能力差异已不明显。

5 结论

1)文中所提的改进阈值函数通过收缩因子缓解了有效特征丢失的问题。其中收缩因子由 ASB 模块自适应获取，避免人工设置的不合理。与采用软阈值函数的 DRSN 相比，所提模型在高噪声环境下准确率提升 2.62%。

2)为平衡改进阈值函数引入的计算开销，文中设计了基于 ECA 机制的 ATB 与 ASB 模块，模型抗干扰能力得到提升的同时，仍然保持良好的计算效率。相较于 SE 机制，模型采用 ECA 机制后在训练时间上减少了 19.03%，

在计算量上降低了 1.44%。

3)文中模型与 DRSN、ResNet 两个基线模型相比，在噪声等级为-5 dB 时，平均 F_1 分数分别提升了 3.11%与 6.38%。在噪声环境下发生高阻接地时，选线平均准确率仍提升了 2.8%与 4.64%。在采样频率不足的场景下，模型准确率也分别提高了 1.06%与 1.89%。

未来将进一步收集实际配电网中单相接地故障现场数据，扩大故障数据集，以更全面地验证文中模型在实际工程下的可靠性。

参考文献:

- [1] 朱晓红, 杨伟荣, 张 蓉, 等. 基于 RNN-LSTM 神经网络的小电流接地故障选线方法[J]. 高压电器, 2023, 59(7): 213-220.
ZHU Xiaohong, YANG Weirong, ZHANG Rong, et al. Line selection method of low current grounding fault based on RNN-LSTM neural network[J]. High Voltage Apparatus, 2023, 59(7): 213-220.
- [2] 牛胜锁, 王春鑫, 梁志瑞, 等. 基于改进强跟踪无迹卡尔曼滤波的电力信号同步相量跟踪算法[J]. 电工技术学报, 2021, 36(11): 2255-2264.
NIU Shengsuo, WANG Chunxin, LIANG Zhirui, et al. An algorithm for tracking synchronous phasor of power SignalsBased on improved strong tracking unscented kalman filter[J]. Transactions of China Electrotechnical Society, 2021, 36(11): 2255-2264.
- [3] 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 Huiyu, LIU Keyan, SHENG Wanxing, et al. Review and prospects of fault diagnosis and location method in active distribution network[J]. High Voltage Engineering, 2023, 49(2): 660-671.

- [4] WANG Yuanyuan, CHEN Qiaoshan, ZENG Xiangjun, et al. Faulty feeder detection based on space relative distance for compensated distribution network with IIDG injections[J]. IEEE Transactions on Power Delivery, 2021, 36(4): 2459-2466.
- [5] 袁嘉玮, 焦在滨. 基于零序信号全波形识别的小电流接地系统故障选线方法[J]. 电网技术, 2024, 48(2): 839-850.
- YUAN Jiawei, JIAO Zaibin. Faulty feeder detection in small current grounding system based on complete waveform recognition of zero-sequence signals[J]. Power System Technology, 2024, 48(2): 839-850.
- [6] 韩祥民, 刘晓波, 刘敏, 等. 基于改进 EEMD 与 GA-BP 的谐振接地故障选线方法[J]. 智慧电力, 2021, 49(12): 80-87.
- HAN Xiangmin, LIU Xiaobo, LIU Min, et al. Resonant grounding fault line selection method based on improved EEMD and GA-BP model[J]. Smart Power, 2021, 49(12): 80-87.
- [7] 范小龙, 谢维成, 蒋文波, 等. 一种平稳小波变换改进阈值函数的电能质量扰动信号去噪方法[J]. 电工技术学报, 2016, 31(14): 219-226.
- FAN Xiaolong, XIE Weicheng, JIANG Wenbo, et al. An improved threshold function method for power quality disturbance signal de-noising based on stationary wavelet transform[J]. Transactions of China Electrotechnical Society, 2016, 31(14): 219-226.
- [8] 张浩, 张大海, 刘乃毓, 等. 基于改进 VMD 及 ConvNeXt 的小电流接地系统单相接地故障选线方法[J]. 高电压技术, 2025, 51(2): 730-741.
- ZHANG Hao, ZHANG Dahai, LIU Naiyu, et al. Line selection method of single-phase grounding faults for low-current grounding system based on improved VMD and ConvNeXt[J]. High Voltage Engineering, 2025, 51(2): 730-741.
- [9] 毕胜, 耿蒲龙, 张建花, 等. 基于 CEEMD 与自相关阈值去噪的单相接地故障选线方法研究[J]. 煤炭工程, 2022, 54(7): 153-158.
- BI Sheng, GENG Pulong, ZHANG Jianhua, et al. Line selection method for single-phase ground fault based on CEEMD and autocorrelation threshold denoising[J]. Coal Engineering, 2022, 54(7): 153-158.
- [10] 缪欣, 张忠锐, 郭威, 等. 基于信号图像化和 CNN-ResNet 的配电网单相接地故障选线方法[J]. 中国测试, 2024, 50(6): 157-166.
- MIAO Xin, ZHANG Zhongrui, GUO Wei, et al. Single-phase ground fault line selection method for distribution network based on signal imaging and CNN-ResNet[J]. China Measurement & Testing Technology, 2024, 50(6): 157-166.
- [11] 方豪, 魏业文, 张子洵, 等. 基于格拉姆角和场和改进 DenseNet 的配电网故障选线方法[J/OL]. 电力系统及其自动化学报, 1-12[2025-08-08].<https://link.cnki.net/doi/10.19635/j.cnki.csu-epsa.001546>.
- FANG Hao, WEI Yewen, ZHANG Zixun, et al. Fault line selection method of distribution network based on gramian angular summation field and improved DenseNet[J/OL]. Proceedings of the CSU-EPSA, 1-12[2025-08-08].<https://link.cnki.net/doi/10.19635/j.cnki.csu-epsa.001546>.
- [12] 孙坚, 杨宇兵. 基于 Tri-SE-CNN 的风电机组叶片结冰检测研究[J]. 太阳能学报, 2024, 45(12): 360-369.
- SUN Jian, YANG Yubing. Research on icing detection of wind turbine blades based on Tri-SE-CNN[J]. Acta Energiae Solaris Sinica, 2024, 45(12): 360-369.
- [13] ZHAO Minghang, ZHONG Shisheng, FU Xuyun, et al. Deep residual shrinkage networks for fault diagnosis[J]. IEEE Transactions on Industrial

- Informatics, 2020, 16(7): 4681-4690.
- [14]卢锦玲, 郭鲁豫. 基于改进深度残差收缩网络的电力系统暂态稳定评估[J]. 电工技术学报, 2021, 36(11): 2233-2244.
- LU Jinling, GUO Luyu. Power system transient stability assessment based on improved deep residual shrinkage network[J]. Transactions of China Electrotechnical Society, 2021, 36(11): 2233-2244.
- [15]TONG Jinyu, TANG Shiyu, WU Yi, et al. A fault diagnosis method of rolling bearing based on improved deep residual shrinkage networks[J]. Measurement, 2023(206): 112282.
- [16]WANG Qilong, WU Banggu, ZHU Pengfei, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]//Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition.[S.l.]: IEEE, 2020, 11531-11539.
- [17]DING Can, MA Pengcheng, JIANG Changhua, et al. Fast fault line selection technology of distribution network based on MCECA-CloFormer[J]. Applied Sciences, 2024, 14(18): 8270-8270.
- [18]陈朝晖, 袁康健, 丁晓兵, 等. 高压强磁环境下电气信号的小波分频降噪方法[J/OL]. 南方电网技术, 1-10[2025-08-08].<https://link.cnki.net/urlid/44.1643.TK.20240730.1606.017>.
- CHEN Zhaohui, YUAN Kangjian, DING Xiaobing, et al. Wavelet Frequency Division Method for Noise Reduction of Electrical Signals in High Voltage and Strong Magnetic Field Environments[J/OL]. Southern Power System Technology, 1-10[2025-08-08].<https://link.cnki.net/urlid/44.1643.TK.20240730.1606.017>.
- [19]郭威, 史运涛. 基于空间域图像生成和混合卷积神经网络的配电网故障选线方法[J]. 电网技术, 2024, 48(3): 1311-1321.
- GUO Wei, SHI Yuntao. Fault line selection for distribution network based on spatial domain image Generation and hybrid convolutional neural network[J]. Power System Technology, 2024, 48(3): 1311-1321.
- [20]MARTIN K E, HAMAI D, ADAMIAK M G, et al. Exploring the IEEE standard C37.118 — 2005 synchrophasors for power systems[J]. IEEE Transactions on Power Delivery, 2008, 23(4): 1805-1811.
- [21]黄悦华, 张子豪, 陈庆, 等. 基于多头注意力机制的 CNN-BiLSTM 高海拔多因素输电线路可听噪声预测[J]. 高压电器, 2024, 60(12): 160-169.
- HUANG Yuehua, ZHANG Zihao, CHEN Qing, et al. Prediction of audible noise of CNN-BiLSTM high altitude multi-factor transmission line based on multi-head attention mechanism[J]. High Voltage Apparatus, 2024, 60(12): 160-169.
- [22]陈家乐, 梁志坚. 基于 ESMD 能量相对熵的谐振接地配网故障选线研究[J]. 广西电力, 2021, 44(5): 8-15.
- CHEN Jiale, LIANG Zhijian. Research on fault line selection of resonant grounded distribution network based on the relative entropy of ESMD energy[J]. Guangxi Electric Power, 2021, 44(5): 8-15.
- 王强(1974—), 男, 副教授, 主要研究方向为电力系统电力电子装置、新能源发电及并网技术、工业智能检测及控制(E-mail: 306371334@qq.com)。
- 吕鸿浩(2000—), 男, 硕士研究生, 研究方向为人工智能算法在电力系统中的应用(E-mail: 1285244191@qq.com)。
- 周小超(2001—), 男, 硕士研究生, 研究方向为电力系统负荷频率控制(E-mail: 2223129298@qq.com)。
- 张安(1999—), 男, 硕士研究生, 研究方向为新

能源系统优化(E-mail: 1985366727@qq.com)。