

DOI: 10.19783/j.cnki.pspc.250672

基于时间卷积网络的配电网高阻接地故障检测及可解释性分析方法

刘畅宇¹, 王小君¹, 张大海¹, 刘 翌¹, 尚博阳¹, 张永杰²

(1. 北京交通大学电气工程学院, 北京 100044; 2. 国网四川省电力公司经济技术研究院, 四川 成都 610095)

摘要: 数据驱动型算法可有效降低配电网多重随机性及噪声干扰对高阻故障检测阈值的影响, 但由于模型“黑箱”特性致使其可解释性不足。为此, 提出一种基于时间卷积网络(temporal convolutional networks, TCN)的配电网高阻接地故障检测及可解释性分析方法。首先, 利用改进自适应噪声完备集合经验模态分解对零序电流进行分解与重构, 过滤噪声干扰的同时增强故障特征表达。其次, 构建 TCN 对处理后的波形进行时序特征提取, 提升模型对高阻故障及典型扰动工况的识别能力。然后, 构建分数加权的类激活映射方案对模型的检测依据展开分析, 结合波形关键区域的归因指标刻画高阻“零休”特性与模型决策关注区域的匹配度, 提升模型可解释性。最后, 在 MATLAB/Simulink 仿真模型及真型试验场数据的基础上, 进一步验证了所提方案的有效性和可靠性。

关键词: 配电网; 高阻接地故障; 改进自适应噪声完备集合经验模态分解; 时间卷积网络; 可解释性

High-impedance ground fault detection and interpretability analysis in distribution networks based on temporal convolutional networks

LIU Changyu¹, WANG Xiaojun¹, ZHANG Dahai¹, LIU Zhao¹, SHANG Boyang¹, ZHANG Yongjie²

(1. School of Electrical Engineering, Beijing Jiaotong University, Beijing 100044, China; 2. Economic Research Institute of State Grid Sichuan Electric Power Company, Chengdu 610095, China)

Abstract: Data-driven algorithms can effectively reduce the influence of multiple uncertainties and noise interference on detection thresholds for high-impedance faults in distribution networks. However, the “black-box” nature of these models limits their application interpretability. Thus, a method for high-impedance ground fault detection and interpretability analysis in distribution networks based on temporal convolutional networks (TCNs) is proposed. First, an improved adaptive noise-complete ensemble empirical mode decomposition is employed to decompose and reconstruct the zero-sequence current, suppressing noise interference while enhancing fault feature expression. Then, a TCN is developed to extract temporal features from the processed waveforms, thereby improving the model’s ability to distinguish high-impedance faults from typical disturbance conditions. Subsequently, a fractional-weighted class activation mapping scheme is designed to analyze the model’s decision basis. By combining attribution indicators of key waveform regions, the method characterizes the correspondence between the distinctive “zero-off” features of high-impedance faults and the model’s decision-focused regions, thereby enhancing interpretability. Finally, based on MATLAB/Simulink simulation models and field test data, the effectiveness and reliability of the proposed method are validated.

This work is supported by the General Program of National Natural Science Foundation of China (No. 52377071).

Key words: distribution network; high-impedance ground fault; improved adaptive noise-complete ensemble empirical mode decomposition; temporal convolutional network; interpretability

0 引言

配电系统网架结构复杂、线路分布密集且距地

较近, 易接触地表植被、混凝土、树枝等非金属导电介质引发高阻故障(high impedance fault, HIF)。HIF 过渡电阻较大导致其故障特征微弱, 且与电容投切(capacitor switching, CS)、负荷投切(load switching, LS)、励磁涌流(inrush current, IC)等常规开关操作产

基金项目: 国家自然科学基金面上项目资助(52377071)

生的暂态扰动信号存在一定的相似性,导致传统方案难以实现有效检测^[1]。若 HIF 长期存在且未被合理处置,可能导致设备绝缘性能下降,引发火灾事故,甚至引发系统级连锁故障,造成重大经济损失和社会影响^[2]。因此,研究高精度、高可靠性的高阻接地故障检测方案,对保障配电网安全可靠运行具有重要工程价值和现实意义。

根据特征分析维度的差异,配电网高阻故障检测方案主要可分为两类:一类是基于电气量特征的指标阈值法,另一类是基于数据驱动的人工智能法^[3]。指标阈值法通过对故障前后电压、电流等电气信息量在时域、频域、时频域方面的差异进行量化分析,设定特征阈值以检测高阻接地故障。其中,时域法如伏安特性分析法^[4]、零序电流波形畸变凹凸性法^[5]、波形区间斜率曲线法^[6]等,通过故障前后的电气量参数变化或波形特点进行特征构造。此外,数学形态学^[7]、相空间重构^[8]、信号分形特征^[9]等也常用于揭示时域信号蕴含的混沌特征。频域法如高频谐波法^[10]、小波能量矩算法^[11]、谐波能量和波形畸变法^[12]等,通过分析不同谐波和频带构建检测判据。在此基础上,有学者引入小波变换^[13]、S变换^[14]、变分模态分解^[15]等时频分析方法,以增强故障特征的表达能力。上述方案均依靠单特征量或局部特征构建判据,其阈值通常由人工经验整定,在系统结构愈发复杂、量测噪声干扰等复杂运行场景下易出现分类盲区,通用性有待进一步拓展。

近年来,基于数据驱动的人工智能技术不断发展,为解决高阻故障检测问题提供新的研究思路。人工智能法不依赖于复杂的机理分析,可从海量数据中拟合输入样本与输出结果之间的非线性映射关系,从而实现快速准确的故障检测。已有学者将人工智能应用于配电网故障诊断领域,如支持向量机(support vector machine, SVM)^[16]、人工神经网络(artificial neural network, ANN)^[17]、卷积神经网络(convolutional neural networks, CNN)^[18]、长短期记忆网络(long short term memory, LSTM)^[19]、残差网络(residual network, ResNet)^[20]及复合模型^[21]等。然而上述方法普遍关注人工智能的直接应用,模型类似于“黑箱”,存在决策依据弱、可解释性差的问题,导致运维人员难以理解模型决策过程与判断依据,因而在实际部署应用中存在安全隐患^[22]。

自国务院公开印发《新一代人工智能发展规划》以来,已有电力领域的研究人员围绕可解释人工智能开展研究^[23]。文献[24]通过可解释分析模块量化配电网量测点信息在故障区段定位结果中的贡献度,从而验证输出结果的合理性。文献[25]基于梯

度加权类激活映射方法量化特征重要性、可视化模型识别依据,并以此提出自适应的负荷辨识模型调优方法。文献[26]以沙普利值加法性解释方法为总框架,结合局部近似可解释性方法获取光伏阵列故障诊断模型输入特征的贡献,分析模型决策机制并对输出结果进行解释分析。总体上看,虽然针对电力人工智能的可解释性研究已在多个领域得到初步尝试,但在配电网故障诊断领域尚处于起步阶段。

针对传统配电网高阻接地故障检测方法在复杂运行场景下的通用性不足,以及人工智能算法存在可解释性不足的问题,本文提出一种基于时间卷积网络的配电网高阻接地故障检测及可解释性分析方法。首先,采用改进自适应噪声完备集合经验模态分解(improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN)对暂态零序信号进行分解与重构,降低量测噪声的影响。其次,构建时间卷积网络(temporal convolutional network, TCN),实现准确而可靠的高阻接地故障识别。然后,使用分数加权的类激活映射(score-weight class activation mapping, Score-CAM)方法分析模型决策机制。一方面,通过可视化结果直观呈现模型对零序电流序列的关注片段,为超参数选取提供定性与调参指导;另一方面,结合量化评价指标,解释分类结果中模型对零序波形畸变的依赖程度,增强模型决策过程的可解释性。最后,使用 MATLAB/Simulink 仿真数据及真型试验场的实测样本进行测试,验证了所提高阻故障检测方案的有效性及其在工程场景中的适用性。

1 高阻接地故障特性分析

本节以中性点经消弧线圈接地方式为例,推导高阻接地故障发生时的暂态零序电流表达式,结合仿真分析配电网高阻故障特征,为后续基于时序波形的故障检测方法提供理论基础。

配电网经高阻抗接地时,由于故障接地阻抗远大于其他线路中的阻抗,可忽略其他线路参数的影响,只考虑接地阻抗 R_{HIF} 进行分析。在中性点经消弧线圈(电感参数为 L_p , 电流为 i_L) 接地运行方式下,其暂态分析等效电路如图 1 所示。

图 1 中: C_0 和 C_f 分别为故障点前、后的零序分布电容; u_C 为端电压; i_{C0} 、 i_{Cf} 分别为流过的电流; i_{HIF} 为故障零序电流; i_R 为流经接地高阻的电流。电源电压 $e(t)$ 满足式(1)。

$$e(t) = U_m \sin(\omega t + \varphi) \quad (1)$$

式中: U_m 为故障相电压幅值; ω 为网络运行工频

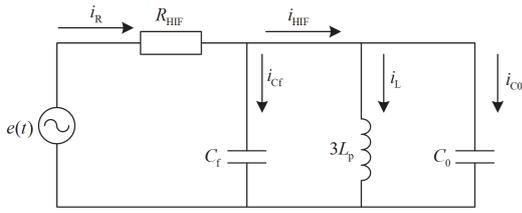


图1 谐振接地系统的故障分析等效电路

Fig. 1 Equivalent circuit for fault analysis of resonant grounding system

频率; φ 为初相角。

根据电感、电容的电压电流关系及基尔霍夫定律可建立如式(2)所示的方程。

$$\begin{cases} e(t) = R_{\text{HFF}} \times [(C_f + C_0) \times \frac{du_C}{dt} + i_L] + u_C \\ u_C = 3L_p \times \frac{di_L}{dt} \end{cases} \quad (2)$$

联立式(1)、式(2)可得二阶微分方程表达式为

$$a \times \frac{d^2 i_L}{dt^2} + b \times \frac{di_L}{dt} + c \times i_L = U_m \sin(\omega t + \varphi) \quad (3)$$

其中, 相关的参数表达式为

$$a = R_{\text{HFF}} \times 3L_p \times (C_f + C_0), \quad b = 3L_p, \quad c = R_{\text{HFF}} \quad (4)$$

求解该微分方程, 可得此电路临界阻尼 R_{HFF}^* 为

$$R_{\text{HFF}}^* = \frac{1}{2} \sqrt{3L_p / (C_f + C_0)} \quad (5)$$

以欠阻尼状态 ($R_{\text{HFF}} > R_{\text{HFF}}^*$) 下的高阻故障为例, 此时故障零序电流 i_{HFF} 的解析表达式如式(6)所示。

$$\begin{aligned} i_{\text{HFF}} &= i_L + i_{C_0} = i_L + C_0 \times \frac{du_C}{dt} = \\ & i_L + 3L_p C_0 \times \frac{d^2 i_L}{dt^2} = \end{aligned} \quad (6)$$

$$Ae^{-\delta t} \sin(\omega_f t + \varphi_1) + B \sin(\omega t + \varphi_2) + \gamma$$

式中: A 、 B 、 φ_1 、 φ_2 、 γ 均为常数, 与配电网的参数和初相角有关^[1]; δ 为衰减因子, 可反映故障暂态过程的持续时间, 其表达式如式(7)所示; ω_f 为暂态主谐振频率, 由系统对地分布电容、消弧线圈参数及接地点阻抗参数决定, 其表达式如式(8)所示。

$$\delta = 1 / [2R_{\text{HFF}}(C_f + C_0)] \quad (7)$$

$$\omega_f = \sqrt{1 / [3L_p(C_f + C_0)] - \delta^2} \quad (8)$$

分析式(6)可知, 在中性点经消弧线圈接地配电网中, 故障零序电流是稳态正弦分量和暂态衰减分量的叠加, 而其具体的振荡特性会受到系统运行条件与接地介质类型的影响, 通常具有随机性、不对称性、非线性和高频成分多等特点^[4]。

图2分别给出高阻故障和扰动发生时的零序电流波形与频谱分析结果。由图2可见, 当发生高阻故障时, 由于电弧电阻的随机变化, 暂态过程变得更加复杂。电弧的间歇性熄灭和重燃类似于三次谐波叠加对基波的影响, 表现为随着电压的变化出现接近平行于水平轴的电流量畸变, 即“零休”现象。而对于其他扰动, 例如电容器或负载投切时, 由于三相断路器不完全同步, 在开关瞬间产生不同的高频暂态信号, 并在短时间内迅速衰减。当轻负载或空载变压器通电时, 由于励磁电感的非线性特性, 会产生大量的二次谐波分量。因此, 可将零序电流时域波形作为数据驱动模型的输入, 并重点关注其波形中的零休部分, 实现高阻接地故障的有效检测。然而, 受高频环境噪声随机性的影响, 畸变特征的提取面临较大挑战, 所以必须采用合适的信号处理技术消除暂态信号中的噪声干扰, 从时域波形数据中恢复关键故障特征, 以进一步区分高阻故障和扰动事件, 保证更可靠的故障检测。

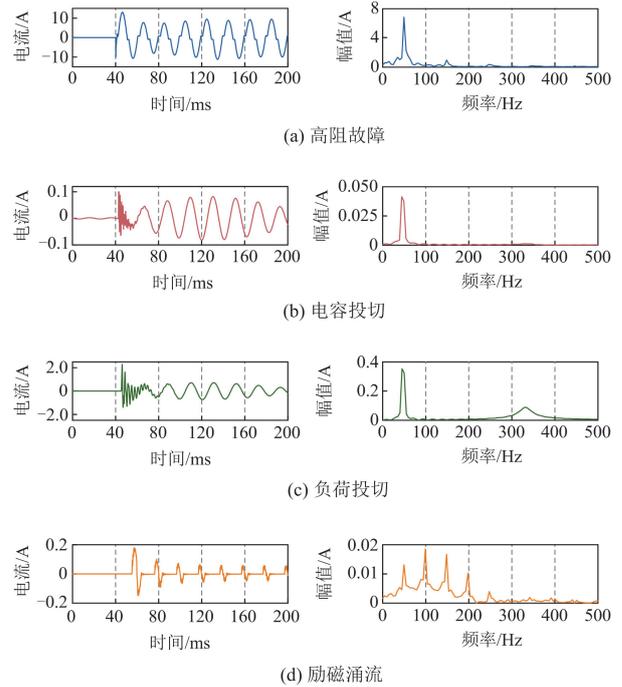


图2 不同工况下的零序电流波形及频谱分析结果

Fig. 2 Zero-sequence current signal with different operating conditions and spectrum analysis result

由此可见, 高阻故障与其他扰动工况的零序电流信号在时域和频域中存在一定的区分度。1) 时域方面: 高阻故障的“零休”特性可看作分类问题的排他性特征, 与其他工况进行区分。2) 频域方面: 高阻故障下, 基频附近的故障分量最大, 且含有一定比例的高次谐波分量(主要为奇次谐波)。扰动工

况中, 电容投切基频附近的故障分量最大, 高频故障分量相对较少; 负荷投切在 300~400 Hz 内有明显的频带聚集; 励磁涌流则含有较多的偶次谐波分量(尤其是二次谐波分量)。

因此, 可将零序电流时域波形作为数据驱动模型的输入^[21], 重点关注波形中的零休部分, 并加以挖掘低频段的故障特征表达, 实现高阻接地故障的有效检测。然而, 高频环境噪声的随机性阻碍了零休畸变特征的提取, 所以必须采用合适的信号处理技术消除暂态信号中的噪声干扰, 从时域波形中全面提取故障特征, 进一步区分高阻故障和扰动事件, 保证更可靠的故障检测。

2 高阻故障检测及可解释性分析方法

2.1 基于 ICEEMDAN 的信号分解与重构

与传统的经验模态分解(empirical mode decomposition, EMD)方法不同, ICEEMDAN 通过优化噪声添加和分解过程, 提高了分解过程的稳定性与准确性, 可在有效解决模态混叠的基础上, 降低本征模态分量的残余噪声, 进一步凸显各分量的时、频域特征^[27]。本文采用 ICEEMDAN 方法对暂态零序电流进行分解与重构, 步骤如下。

1) 将待分解的原始暂态零序电流信号定义为 i_0 , $E_\zeta(\cdot)$ 代表 EMD 分解后的 ζ 阶固有模态函数(intrinsic mode function, IMF)分量, 向 i_0 中添加高斯白噪声 w , 计算第 1 次分解的残差值 R_1 和第 1 个模态分量 D_1 。

$$i_0^{(n)} = i_0 + \varepsilon E_\zeta(w^{(n)}) \quad (9)$$

$$R_1 = \frac{1}{N} \sum_{n=1}^N (i_0 + \varepsilon E_\zeta(w^{(n)})) \quad (10)$$

$$D_1 = i_0 - R_1 \quad (11)$$

式中: $i_0^{(n)}$ 表示第 n 次添加噪声后形成的信号; ε 为高斯白噪声的信噪比; $w^{(n)}$ 为第 n 次添加的高斯白噪声; N 为添加的总次数。

2) 重复步骤 1) 中叠加噪声, 计算第 λ 次分解后的残差值 R_λ 和模态分量 D_λ , 直至不能继续分解。通过上述步骤, 原始的暂态零序电流信号被分解为多个 IMF 分量与残差之和。

对分解得到的每个 IMF 分量进行频谱分析可知, 部分 IMF 分量所包含的信号为量测噪声特征, 与原始故障信号的相关性较弱。因而本文选取 5 阶以上的 IMF 分量进行信号叠加形成重构信号, 在充分保留故障特征的同时, 有效滤除噪声干扰。

2.2 时间卷积网络

在保留一维卷积神经网络特征提取能力的基

础上, 时间卷积网络增加了因果空洞卷积, 适合处理暂态时间序列^[28]。因果卷积中的全部数据按时间顺序严格单向排列, 确保了序列模型中 t 时刻的数据输出仅与前层网络中 $t-1$ 时刻之前的元素相关, 这意味着因果卷积需要更多的层数或滤波器来增加感受野。而空洞卷积引入扩张因子, 通过增大扩张因子的方式使感受野指数级扩张, 可从更大范围感知历史信息。因果空洞卷积的表达式如式(12)所示。

$$Q(t) = \sum_{i=0}^{k-1} \phi(i) P_{t-d \times i} \quad (12)$$

式中: $Q(t)$ 为 t 时刻的数据输出; $\phi(i)$ 为第 i 个卷积核; $P_{t-d \times i}$ 为 $t-d \times i$ 时刻的数据输入; k 为卷积核大小; d 为空洞卷积的扩张系数。

为使模型能够处理更长的历史信息, TCN 通过堆叠卷积层和残差结构来解决信息丢失、梯度消失等问题。本文 TCN 中使用的残差块结构如图 3 所示, 由因果空洞卷积、ReLU 激活函数层和丢弃层(Dropout)组成。在 TCN 残差块之后, 通过数据展平层(Flatten)将多维数据转化为一维, 然后使用全连接层(Dense)将前层所有神经元与当前层神经元连接。考虑到本文研究内容为分类问题, 使用 Softmax 激活函数进行概率输出。

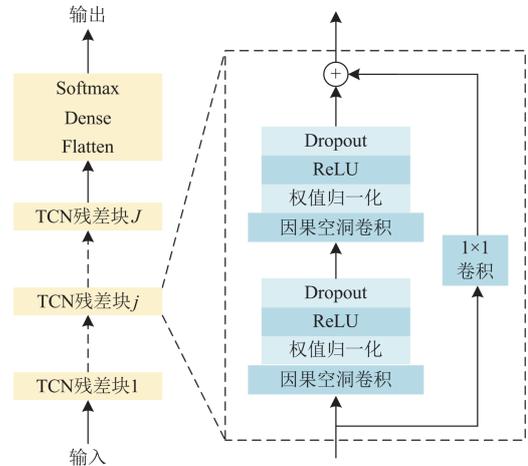


图 3 TCN 中的残差块结构

Fig. 3 Structure of residual block in TCN

2.3 基于 Score-CAM 的可解释分析

深度学习存在黑箱属性, 导致其决策依据弱、可解释性较差。为此, 本文采用 Score-CAM 方法, 对 TCN 模型进行事后可解释分析。Score-CAM 采用特征融合权重与特征图线性加权融合的方式生成类激活映射图, 以实现更稳定的解释效果^[29-30]。对于某 TCN 模型, 令其输入、输出分别为 x 、 Y , 满足映射关系 $Y = f(x)$ 。从中选取第 l 个卷积层的第

m 个通道, 对应的激活值为 A_i^m 。对于某输入样本 x_i , A_i^m 对输出 Y 的贡献 $C(A_i^m)$ 表示为

$$C(A_i^m) = f(x \circ H_i^m) - f(x_i) \quad (13)$$

式中: \circ 表示哈达玛积; H_i^m 为一个与 x_i 形状相同的向量, 其定义为

$$H_i^m = s[U_p(A_i^m)] \quad (14)$$

式中: 函数 $s[\cdot]$ 表示归一化操作, 将每一个元素映射至 $[0, 1]$ 区间; 函数 $U_p(\cdot)$ 表示对 A_i^m 进行上采样。

选定感兴趣的类别 τ , 则 Score-CAM 的类激活图计算式可定义为

$$L = \text{ReLU}(\sum_m \alpha_m^\tau A_i^m) \quad (15)$$

式中: $\alpha_m^\tau = C(A_i^m)$ 为各通道的权重, 可决定类激活图中包含的特定类别信息; $\text{ReLU}(\cdot)$ 为激活函数, 用于去除对感兴趣的类别 τ 无用的神经元。

Score-CAM 生成的类激活图可提供稳定的可视化效果, 展示模型在分类决策过程中关注的关键区域, 从而为模型超参数调优提供指导。在此定性分析的基础上, 本文基于生成的归因结果数值进一步构建量化评价指标, 从而为运维人员提供更加直观的决策支持。首先, 对于时间窗大小为 T 的零序电流波形, 定义信号过零点时刻(取相邻采样点电流符号变化的时间点)为 t_0 , 分别取 t_0 前后大小为 ΔT 的时间窗 $[t_0 - \Delta T, t_0 + \Delta T]$ 进行分析, 并将其定义为波形过零点关键区域集合 Ω_1 , 如式(16)所示。

$$\Omega_1 = \{t | t \in [t_0 - \Delta T, t_0 + \Delta T]\} \quad (16)$$

由式(13)一式(15)计算零序电流时间序列中采样点时刻 t 处的归因值 $S(t) \in [0, 1]$, 定义高归因区域集合 Ω_2 如式(17)所示。

$$\Omega_2 = \{t | S(t) > \xi\} \quad (17)$$

式中: ξ 为归因值阈值, 本文取 0.6。

进一步定义高归因区域与关键区域匹配度指标 Z_{AM} 、关键区域归因全局占比指标 K_{AR} , 分别如式(18)和式(19)所示。

$$Z_{AM} = \langle \Omega_1 \cap \Omega_2 \rangle / \langle \Omega_2 \rangle \quad (18)$$

$$K_{AR} = \sum_{t \in \Omega_1} S(t) / \sum_{t \in T} S(t) \quad (19)$$

式中: $\langle \cdot \rangle$ 表示集合中含有的元素数量。

分析式(18)和式(19)可知, Z_{AM} 通过评估高归因值点是否集中在关键区域, 衡量模型是否精准关注了波形过零点附近的畸变特征。若 Z_{AM} 的值较大, 表明模型的高贡献归因值点主要分布在关键区域, 说明模型在该区域提取到了更具判别力的特征; 反之, 若 Z_{AM} 值较低, 则说明模型的高贡献归因值点

较为分散, 可能依赖其他区域的信息进行分类, 降低了对过零点关键特征的依赖性。 K_{AR} 则反映了关键区域归因值在全局归因值中的占比, 衡量模型在整体决策过程中对过零点关键区域的依赖程度。 K_{AR} 的值越大, 说明模型在分类决策中更优先依赖过零点关键区域的波形特征, 而非其他非关键区域的噪声或冗余信息, 从而体现了模型对关键区域特征的全局重要性。

整体来看, K_{AR} 体现了关键区域特征在整体归因值中的占比, 衡量模型的全局关注偏好; 而 Z_{AM} 则反映模型是否精准聚焦在关键区域的高贡献点, 衡量局部特征捕捉能力。两者结合可有效评估模型在高阻故障检测中的归因特征分布情况及模型决策依据。

3 配电网高阻故障检测流程

本文提出的配电网高阻故障检测流程如图 4 所示, 包括数据预处理、模型训练与参数调优、实际应用和可解释性分析 4 个阶段。

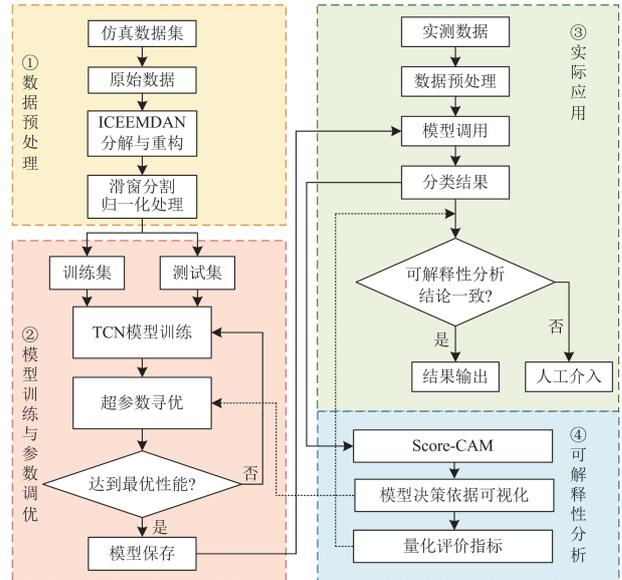


图 4 高阻接地故障检测流程

Fig. 4 Flow chart of high impedance fault detection

1) 数据预处理: 利用量测装置收集高阻故障及正常扰动工况下的零序电流信号, 在其中添加随机噪声以模拟配电系统复杂运行环境, 并经由 ICEEMDAN 算法对信号进行分解与重构。考虑到实际系统故障发生时刻的不确定性及录波装置启动的动作时延, 将原始零序电流信号进行滑动窗口分割(本文采用的时间窗为 40 ms), 并采用式(20)对原始信号 X 进行归一化处理。

$$X'_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (20)$$

式中： X_{\max} 和 X_{\min} 分别为原始信号 X 中的最大值和最小值； X_i 和 X'_i 分别为原始信号 X 和归一化后信号 X' 中的第 i 个元素值。通过上述归一化操作可降低电气量的数量级差异，使模型更关注数据变化趋势，提升模型性能。

2) 模型训练与参数调优：首先将数据预处理后的样本集划分为训练集和测试集；然后将训练样本输入 TCN 模型并开展训练，根据模型性能表现不断地调整超参数以使模型性能趋优。当损失函数与准确率趋于稳定时，保存模型权重，供后续测试调用与应用分析。其中，采用交叉熵作为损失函数，并通过 Adam 优化器使其最小化。

3) 实际应用：通过馈线首端配置的量测装置收集暂态零序电流信号，经数据预处理操作后，调用保存的模型，即可得到分类结果。

4) 可解释性分析：利用 Score-CAM 方法对模型决策结果进行分析，计算时间序列中各采样点的归因值，进一步明确分类结果由哪些部分时间片段主导决定或影响。结合可视化方式，解释模型决策依据及超参数设置对分类结果的影响，从而直观地反映输入特征与输出类别之间的内在关联。

在实际应用过程中，可针对 Z_{AM} 和 K_{AR} 设定合理阈值，以量化模型对高阻故障零序畸变特性的关注程度，并评估模型分类结果的可靠性。通过比较模型输出结果与可解释性分析的归因特征是否一致，增强故障检测流程的可控性和可信度。具体表现为：若模型输出的分类结果为高阻故障，但样本的指标 Z_{AM} 和 K_{AR} 均低于阈值设定，则表明模型的决策并未主要依赖关键区域的特征，说明其对高阻故障的核心特征关注不足，可能存在误判风险；若模型输出判别结果并非高阻故障，但其指标高于阈值设定，则说明模型已精准聚焦于零点畸变特征，但最终分类结果未判定为高阻故障，这可能意味着漏判风险。在上述情况下，可触发人工介入机制，安排技术人员对故障诊断全流程进行深入审查，进一步分析模型的判别依据，明确潜在问题来源。通过这种方式有效降低误判与漏判风险，提升高阻故障检测的精准度和可信度。

4 算例分析

4.1 仿真数据获取及样本库构造

本文基于 MATLAB/Simulink 搭建 10 kV 配电网仿真模型，以模拟高阻故障及扰动事件，如图 5 所示。该模型包含电源、变压器、线路、负荷及分

布式电源。其中：变压器采用 DY_n 接法，变比为 110 kV/10.5 kV，其低压侧中性点采用消弧线圈接地方式(补偿度为 8%)；各线路长度均已在图中标注，线路参数设置参考文献[20]。分布式电源设置为在各自出力的 0.2~0.8 倍范围内波动，且出力的倍率各不相同，以模拟正常情况下分布式电源出力的随机性。监测点处配备零序电流互感器以获取暂态零序电流信号，采样频率为 10 kHz。高阻故障采用图 6 所示的 Emanuel 模型进行模拟。其中： U_p 和 U_n 为直流电压源并设置 $\pm 10\%$ 的波动，用于模拟电弧电压及故障电流的不对称性与非线性； R_p 和 R_n 为时变电阻，用于模拟故障电弧电阻； D_p 和 D_n 为理想二极管，与 U_p 和 U_n 共同组成电路的正负半周电流通路。

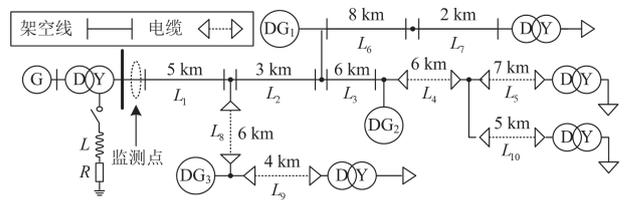


图 5 10 kV 配电网拓扑

Fig. 5 Topology of 10 kV distribution network

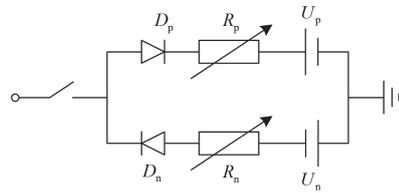


图 6 Emanuel 模型

Fig. 6 Emanuel model

基于上述配电系统仿真模型可建立仿真样本库，通过改变接入位置、初始相角及样本参数可充分获取发生在不同过渡电阻、不同线路类型及位置情况下的样本^[31]，详细参数如表 1 所示。统一截取开关事件发生前后 0.2 s 时间窗内的数据(其中故障前 2 个周波、故障后 8 个周波)，并通过 40 ms 的时

表 1 样本参数

Table 1 Parameters of samples

类型	正常	扰动			高阻故障
		电容投切	负荷投切	励磁涌流	
位置	—	$L_1 - L_{10}$	$L_7 - L_{10}$	$L_7 - L_{10}$	$L_1 - L_{10}$
相角	—		$0^\circ, 30^\circ, 45^\circ, 90^\circ, 180^\circ$		
参数	—	1、3 Mvar	0.1、0.25、1 MW	YNd11、YNd11	U_p, U_n, R_p, R_n
数量	350	400	240	160	600

间窗口对其进行分割, 利用 ICEEMDAN 方法进行分解和重构后, 根据模拟设置赋予标签 0、1 和 2, 分别对应正常、扰动(包括电容投切、负荷投切、励磁涌流)和高阻故障。最后, 将数据集以 4:1 的比例划分为训练集和测试集。

4.2 模型性能分析

本文模型训练与测试实验均在 Windows 10 操作系统上完成, 计算机配置为 AMD Ryzen 7 4800H CPU, 2.9 GHz, 内存为 16 GB, 编程采用 Python 语言, 基于 PyTorch 框架实现。

4.2.1 不同模型层数对模型效果的影响

神经网络的性能表现通常与模型复杂度相关, 而模型复杂度由深度、宽度、参数量及计算量来体现。通常情况下, 结构复杂的模型拟合能力强、准确性高, 但由于模型参数量大、工作机制复杂, 可能引发资源消耗与额外的计算负担。为此, 本节针对不同层数的模型对其性能的影响展开分析。

考虑到训练与测试样本存在一定的不平衡性, 仅以整体准确率作为评价模型性能的指标显然有偏差, 因而补充精确率、召回率和 F_1 分数对模型性能进行综合评估。将包含不同数量 TCN 残差模块的模型进行训练, 训练结果如图 7 所示, 分析其在测试集上的损失与性能表现(此图以 F_1 分数为例)。其中, TCN1—TCN4 分别表示含有 1—4 个 TCN 残差块的模型结构。

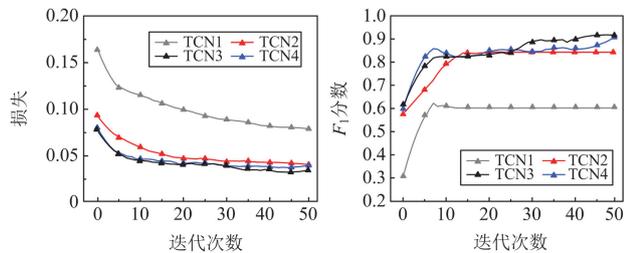


图 7 不同 TCN 残差块数目下的损失函数与模型性能对比
Fig. 7 Comparison of loss function and model accuracy under different numbers of TCN residual block

由图 7 可知, 当仅有 1 个 TCN 残差块时, 模型收敛速度较慢, 且性能表现一般; 而随着残差块数量的增加, 模型性能逐步提升。然而, 并非模块数量越多模型性能越好。当残差块达到 4 个时, 模型需要较多的迭代次数才能达到 3 个残差块下的同等性能。这意味着由于计算复杂度及参数增加, 模型训练难度增大, 在同等迭代次数下的边际收益减少。在综合考虑模型性能与计算资源开销的条件下, 最终选取 3 个 TCN 残差块作为特征提取网络, 以构建高效可靠的故障检测模型。

4.2.2 模型训练结果分析

图 8 展示了模型训练过程中在训练集和测试集上的表现, 其横坐标为迭代次数, 共计 50 次; 纵坐标分别为 F_1 分数与损失。从图中可以观察到, 损失曲线在训练初期下降明显, 而当迭代至 40 次后趋于平稳。为保障模型效果稳定, 本文选取第 48 次迭代时保存的模型为最终模型以开展后续测试工作。

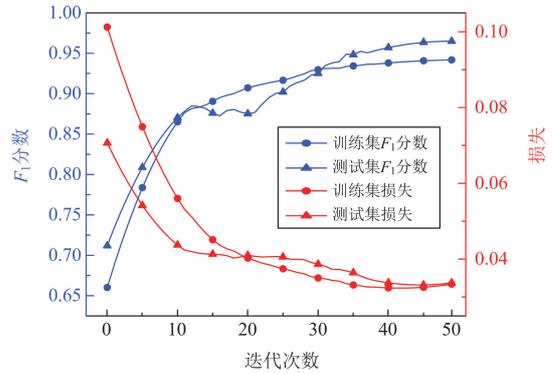


图 8 模型训练过程

Fig. 8 Training process

为评估模型在不同类别上的分类性能, 导出模型在训练集和测试集上的混淆矩阵, 如图 9 所示。可以看出, 模型在测试集上的总体准确率达到 96%, 精确率达到 94.75%, 召回率达到 96.01%, F_1 分数达到 95.32%。说明模型在不同运行工况下均可保持较高水平的泛化能力, 且对高阻故障类别不产生误判、漏判情况, 初步验证了本文所提故障检测方案的有效性。

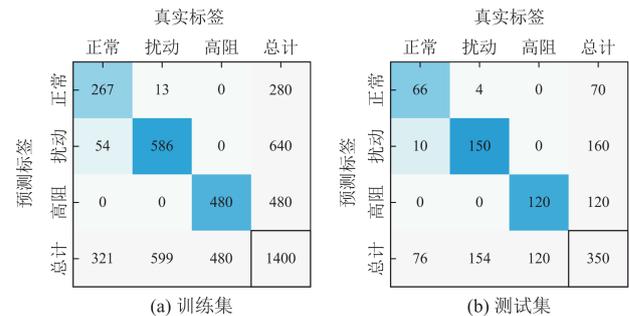


图 9 混淆矩阵

Fig. 9 Confusion matrix

采用 t-SNE 算法进一步验证所提方案的有效性, 对原始数据和经不同 TCN 模块处理后的数据进行降维, 可视化结果如图 10 所示。其中不同颜色代表不同类别; 坐标轴无量纲, 仅代表降维后数据点在平面上的分布。

图 10(a)表明, 原始样本在特征维度和分布模式上都表现出相当大的无序性, 随机分散在低维可视

化空间中, 缺乏明显的聚集趋势。然而, 随着特征提取层深度的增加(如图 10(b)—图 10(d)所示), 样本点开始表现出聚集趋势, 具体表现为: 同一类样本点之间的距离逐渐减小, 形成明显的聚类结构; 不同类别之间的距离显著增大, 逐渐建立明确的分类边界。上述转化过程充分表明样本的聚类程度在特征提取层的作用下逐渐加强, 说明本文设计的 TCN 模型可充分挖掘零序电流时间序列中的隐含特征, 在故障检测任务中表现出优越的特征提取与分类能力。

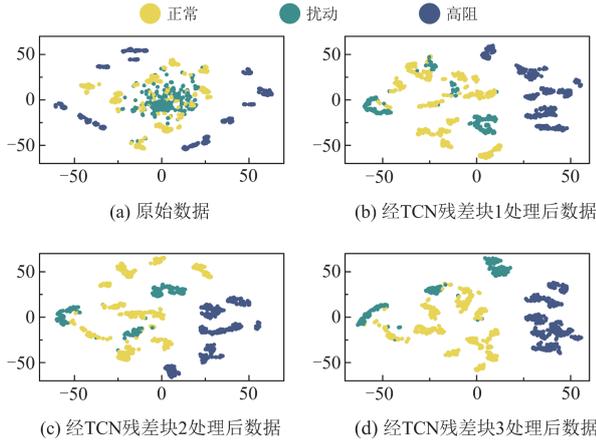


图 10 t-SNE 可视化结果

Fig. 10 Visualization result of t-SNE

4.3 抗噪能力分析

考虑到实际录波信号中往往含有不同程度的量测噪声, 导致波形发生一定变化, 从而影响模型性能。为此, 本节在原测试样本上叠加信噪比为 10、20、30、40 dB 的噪声后重新开展测试实验, 以综合评估本文所提 ICEEMDAN 信号分解与重构方案的有效性及模型抗噪声干扰能力, 结果如表 2 所示。

表 2 噪声对所提方案的影响

Table 2 Impact of noise on the proposed method

噪声/ dB	信号重构	准确 率/%	精确 率/%	召回 率/%	F_1 分 数/%
40	否	96.00	94.75	96.01	95.32
	是	96.86	97.16	95.50	96.25
30	否	94.00	92.30	94.29	93.10
	是	96.00	96.91	93.60	94.95
20	否	92.00	95.04	86.67	88.98
	是	95.29	91.63	96.71	94.49
10	否	89.71	93.88	82.86	85.09
	是	96.29	95.73	96.21	95.96

从表 2 可以看出, 在不采用 ICEEMDAN 对信号进行分解与重构的预处理操作下, 模型性能将随着噪声含量的增大而降低。但在 10 dB 强噪声干扰下, 各评价指标仍能保持在 85%以上, 说明本文构建的 TCN 模型能有效地抵抗噪声干扰。而波形经信

号预处理后, 量测噪声可被有效滤除, 有效地增强了关键故障特征, 使模型性能保持在 95%左右的高水平。因此, 本文所提方案具有较强的抗噪能力。

4.4 不同分类模型效果对比

为全面验证所提方法在高阻接地故障检测任务中的性能优势, 本节引入多种典型分类模型, 分别从分类准确性与测试时间开销两个维度展开对比分析。考虑到模型训练与测试过程中存在一定随机性, 本文对模型进行多次重复测试并求均值, 结果如表 3 所示。其中, 测试时间为测试集单个样本的平均计算时间。

表 3 不同模型分类效果对比

Table 3 Classification performance under different models

方案	准确 率/%	精确 率/%	召回 率/%	F_1 分 数/%	测试 时间/ms
SVM	90.86	93.09	85.30	87.41	1.5
ANN	88.29	93.20	80.48	82.41	3.0
CNN	91.14	94.59	85.24	87.58	0.6
LSTM	94.28	93.62	92.45	93.03	2.8
ResNet	95.18	94.30	92.81	93.55	1.6
本文	96.00	94.75	96.01	95.32	0.9

结果表明, 传统机器学习模型 SVM 和 ANN 在识别精度和响应速度方面均表现一般, 难以满足高精度与快速响应的实际工程需求。CNN 模型借助卷积结构对局部特征的强提取能力, 在一定程度上提升了故障识别的准确性与推理效率。然而由于其感受野有限且缺乏时序建模机制, 在提取时序特征方面仍存在不足, 难以充分刻画高阻故障的动态演化特性。LSTM 和 ResNet 模型分别依托循环结构与残差连接机制, 在时序依赖特征提取与深度特征挖掘方面展现出较强的性能优势, 有效增强了高阻故障特征的表达能力, 但二者的推理效率相对较低。相比之下, 本文所提模型在保留卷积结构对局部特征高效处理的基础上, 进一步提升了对时序依赖关系的建模与提取能力, 可兼顾识别精度与推理效率, 展现出更高的工程适应性与实际应用价值。

4.5 模型可解释性分析

本节利用 Score-CAM 算法对时间卷积网络的运行机制进行分析, 即针对重构零序电流信号, 计算每一个时序片段对分类结果的贡献程度, 并据此构建归因热力图, 进而明确分辨出对决策结果起关键作用的特征片段, 从而帮助运维人员理解模型的决策依据。在归因热力图中, 归因值范围为(0,1), 较大的归因值意味着该采样点对模型决策的影响更为显著, 其大小用不同的颜色表示。根据该标准, 可以定性评估零序电流时间序列的各个片段对模型决策结果的影响。在此基础上, 结合 Z_{AM} 和 K_{AR} 进

行定量分析, 以定量评估模型对波形过零点区间的关注程度, 从而分析不同类型样本在归因模式上的差异性。

4.5.1 模型超参数影响分析

通常情况下, 由于缺乏明确的理论指导, 模型超参数(如卷积核大小 k 、扩张系数 d 等)的选取具有极大的盲目性, 研究人员大多依靠不断地组合、试错来确定合适的超参数。此过程需要投入大量的计算资源与时间成本, 且难以获得最优的参数组合。而本文所提可解释性分析方案, 可以通过直观可视化的方式, 深度揭示模型超参数与模型性能表现之间潜藏的内在联系, 在有效规避盲目试错的同时, 为超参数的合理选取提供清晰、可追溯的依据, 进一步提升模型的优化效率。

在卷积核大小的参数寻优过程中发现, 设置不同卷积核大小的模型存在将一定比例的高阻故障样本误判为扰动类样本的情况。对于某高阻故障样本, 卷积核大小 k 为 1 和 5 的模型将其误判, 而卷积核大小 k 为 3 的模型给出了正确分类结果。图 11 展示了在不同卷积核大小条件下, 使用相应模型对此高阻故障样本进行分类的可视化结果。

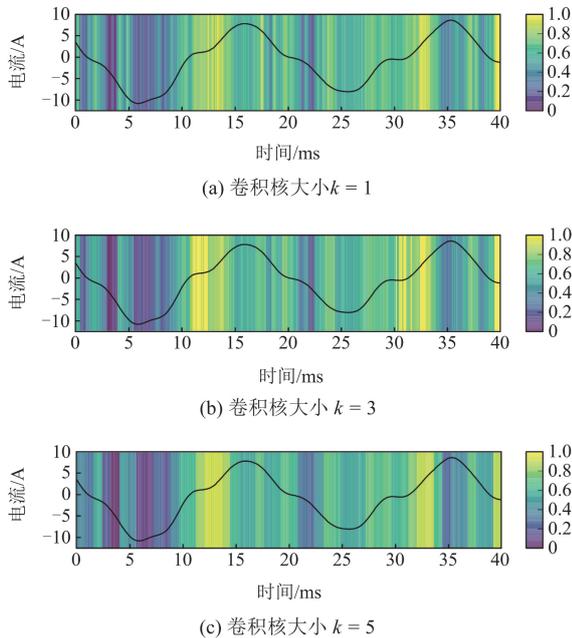


图 11 不同卷积核大小的可视化结果

Fig. 11 Visual results of different convolutional kernel sizes

由图 11 可知, 不同的卷积核大小设置可在不同长度的时间序列片段内提取隐含故障特征。若卷积核过小(如图 11(a)), 则只能捕捉到样本中的局部故障特征, 过于碎片化; 而当卷积核设置过大时(如图

11(c)), 则易捕捉到干扰性特征或使模型关注的关键特征区域发生时序偏移。由图 11(b)可以看出, 当卷积核大小设置为 3 时, 模型可精准地覆盖到决定样本分类为高阻故障的过零点畸变区域, 进而给出正确分类结果。

4.5.2 模型决策依据可视化分析

图 12 展示了 TCN 模型通过 Score-CAM 进行故障分类的可视化结果。可以看出, 影响模型分类结果的关键因素并非波峰或波谷区域, 而是波形过零点附近不同程度的畸变。在图 12(a)所示的高阻故障工况下, 当零序电流在过零点后的一段时间呈现水平趋势并恢复为正弦变化时, 这种零休特性被模型有效检测, 并作为高阻故障检测的关键基础。由此可见, TCN 模型能够有效提取不同运行工况下具有代表性的关键波形特征, 并结合 Score-CAM 可视化方法呈现模型的关注区域, 从而为模型作出相应类别判断提供明确、可解释的依据。

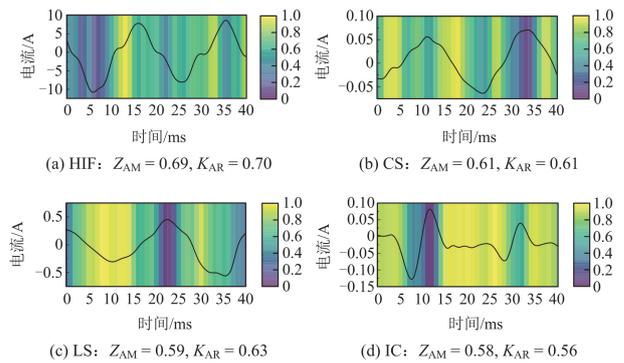


图 12 不同运行工况的可视化结果

Fig. 12 Visual results of different operating conditions

从定量分析的角度看, 对于高阻故障样本, 指标 Z_{AM} 和 K_{AR} 的值分别为 0.69 和 0.70, 显著高于其他扰动类样本。表明模型的高贡献归因值主要集中在波形过零点区域, 与高阻故障的电气特性相吻合, 表明 Score-CAM 的归因结果具有一定的物理可解释性。相比之下, 扰动类样本的两项指标均低于 HIF, 且 IC 样本的指标最小。由图 12(d)可以看出, IC 样本的高归因值区域较为均匀地分布在整个时间轴上, 说明模型对此类扰动样本的分类更加依赖全局特征, 并非局限于波形过零点区域。

从整体上看, 指标 Z_{AM} 和 K_{AR} 具有较强的正相关性。因此, 上述定量指标共同反映了模型在分类决策时对关键区域的关注程度, 可以作为衡量模型决策依据合理性的重要量化指标, 并为运维人员提供更加直观、可靠的决策支持。

5 实测数据验证及可解释性分析

为验证本文方案在实际工程应用中的有效性,采用某 10 kV 真型试验场的实测数据进行了验证。谐振接地系统拓扑如图 13 所示,包含 6 条出线,可通过开关将线路互联以模拟混合线路。实验以各馈线上发生的高阻故障为主,通过接触干土地、湿土地、沥青等接地介质模拟实际故障场景;同时在母线处设置电容投切试验。

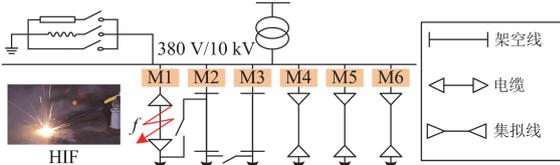


图 13 10 kV 配电网真型试验场拓扑示意图

Fig. 13 Topology of an actual experimental 10 kV distribution network

故障馈线出口处采用采样频率为 10 kHz 的故障录波器 M1—M6 收集零序电流数据,经预处理后输入模型进行测试,结果如表 4 所示。可以看出,本文方案对扰动类(电容投切)样本具有强分辨能力,同时能够在经不同介质接地的高阻故障场景下表现出高可靠性。

表 4 基于现场试验数据的模型性能验证

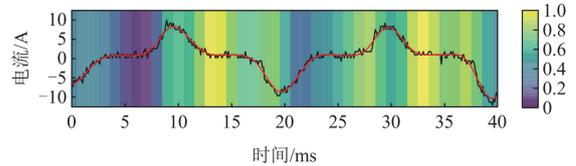
Table 4 Performance of the algorithm based on field test data

事件类型	介质	测试样本数	准确率/%
高阻故障	干土地	13	100
	湿土地	14	100
	沥青	12	100
扰动(电容投切)	—	13	92.31

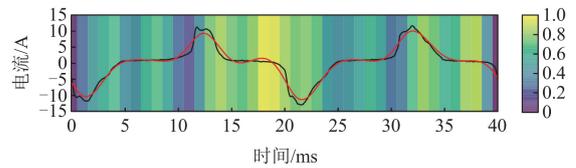
进一步基于实测数据说明本文所提方案的有效性,以接地介质分别为干土地、湿土地的高阻故障为例,采用 Score-CAM 方法开展分析。经不同介质接地的决策依据如图 14 所示,其中,黑色与红色线条分别表示数据预处理前后的零序电流波形。

相较于预处理前的实测波形,经 ICEEMDAN 方法重构的零序电流序列更加平滑,可有效抑制噪声干扰,更利于还原高阻故障的典型零休特性。图 14 还表明,在不同接地介质下,模型的决策依据均聚焦于单个周波内的 3/4 处,对应高阻故障零序电流的零休期。从指标 Z_{AM} 和 K_{AR} 的定量分析角度来看,两种接地介质条件下的归因模式保持一致(干土地接地: $Z_{AM} = 0.69$, $K_{AR} = 0.72$; 湿土地接地: $Z_{AM} = 0.68$, $K_{AR} = 0.70$),说明模型在实际工况下仍能稳定关注过零点关键区域,且归因特性与仿真

数据高度一致。然而在湿土地环境下, K_{AR} 指标略低,说明模型的归因值在该接地介质条件下相对分散,这与较高湿度土壤的导电性导致波形零休期延长有关。但 Z_{AM} 和 K_{AR} 仍保持较强相关性,表明模型在不同接地介质下的关键决策区域保持稳定,进一步证明了所提方案在实际应用中的适用性和鲁棒性。



(a) 经干土地接地: $Z_{AM} = 0.69$, $K_{AR} = 0.72$



(b) 经湿土地接地: $Z_{AM} = 0.68$, $K_{AR} = 0.70$

图 14 经不同介质接地的决策依据

Fig. 14 Decision basis of different grounding media

6 结论

针对高阻故障检测方法易受噪声干扰,数据驱动型诊断方案可解释性差的问题,提出了一种基于时间卷积网络的配电网高阻故障检测方法,并设计 Score-CAM 决策可视化环节对模型展开可解释性分析,增强所提方案的应用可靠性,结论如下。

1) 在故障检测性能方面,所提方案可有效从含噪暂态零序电流中提取高阻故障特征。在 MATLAB/Simulink 仿真数据集中,整体检测准确率达 96%,且在 10 dB 噪声干扰下仍保持良好鲁棒性;在 10 kV 真型试验场典型接地介质条件下可表现出稳定的检测能力,具备良好的工程适应能力。

2) 在模型可解释性方面,通过 Score-CAM 直观地展示了模型对不同类别样本的决策依据,结合 Z_{AM} 和 K_{AR} 的定量分析结果,印证了所提模型对于高阻故障“零休”特性的关注,不仅为模型超参数的优化设计提供了重要依据,还为运维人员提供了直观可靠的决策支持。

参考文献

[1] 王宾, 崔鑫, 董新洲. 配电线路弧光高阻故障检测技术综述[J]. 中国电机工程学报, 2020, 40(1): 96-107, 377. WANG Bin, CUI Xin, DONG Xinzhou. Overview of arc high impedance grounding fault detection technologies in distribution system[J]. Proceedings of the CSEE, 2020, 40(1): 96-107, 377.

- [2] WANG X, WEI X, GAO J, et al. High-impedance fault detection method based on stochastic resonance for a distribution network with strong background noise[J]. *IEEE Transactions on Power Delivery*, 2022, 37(2): 1004-1016.
- [3] 刘科研, 詹惠瑜, 谭云耀, 等. 基于改进极限学习机的配电网高阻接地故障检测方案[J]. *电网技术*, 2023, 47(5): 1886-1899.
LIU Keyan, ZHAN Huiyu, TAN Yunyao, et al. High impedance grounding fault detection scheme in distribution network based on improved extreme learning machine[J]. *Power System Technology*, 2023, 47(5): 1886-1899.
- [4] 王宾, 耿建昭, 董新洲. 配网高阻接地故障伏安特性分析及检测[J]. *中国电机工程学报*, 2014, 34(22): 3815-3823.
WANG Bin, GENG Jianzhao, DONG Xinzhou. Analysis and detection of volt-ampere characteristics for high impedance faults in distribution systems[J]. *Proceedings of the CSEE*, 2014, 34(22): 3815-3823.
- [5] 耿建昭, 王宾, 董新洲, 等. 中性点有效接地配电网高阻接地故障特征分析及检测[J]. *电力系统自动化*, 2013, 37(16): 85-91.
GENG Jianzhao, WANG Bin, DONG Xinzhou, et al. Analysis and detection of high impedance grounding fault in neutral point effectively grounding distribution network[J]. *Automation of Electric Power Systems*, 2013, 37(16): 85-91.
- [6] 韦明杰, 石访, 张恒旭, 等. 基于零序电流波形区间斜率曲线的配电网高阻接地故障检测[J]. *电力系统自动化*, 2020, 44(14): 164-171.
WEI Mingjie, SHI Fang, ZHANG Hengxu, et al. Detection of high impedance grounding fault in distribution network based on interval slope curves of zero-sequence current[J]. *Automation of Electric Power Systems*, 2020, 44(14): 164-171.
- [7] SURESH G, BRAHMA S M. Detection of high impedance fault in power distribution systems using mathematical morphology[J]. *IEEE Transactions on Power Systems*, 2013, 28(2): 1226-1234.
- [8] 杨耿杰, 王康, 高伟. 基于相空间重构和迁移学习的配电网高阻接地故障检测[J]. *电力系统保护与控制*, 2022, 50(13): 151-162.
YANG Gengjie, WANG Kang, GAO Wei. High impedance fault detection in a distribution network based on phase space reconstruction and transfer learning[J]. *Power System Protection and Control*, 2022, 50(13): 151-162.
- [9] MAMISHEV A V, RUSSELL B D, BENNER C L. Analysis of high impedance faults using fractal techniques[J]. *IEEE Transactions on Power Systems*, 1996, 11(1): 435-440.
- [10] 周封, 朱瑞, 王晨光, 等. 一种配电网高阻接地故障在线监测与辨识方法[J]. *仪器仪表学报*, 2015, 36(3): 685-693.
ZHOU Feng, ZHU Rui, WANG Chenguang, et al. Online criterion and identification of single-phase ground fault with high resistance in distribution network[J]. *Chinese Journal of Scientific Instrument*, 2015, 36(3): 685-693.
- [11] 朱晓娟, 林圣, 张姝, 等. 基于小波能量矩的高阻接地故障检测方法[J]. *电力自动化设备*, 2016, 36(12): 161-168.
ZHU Xiaojuan, LIN Sheng, ZHANG Shu, et al. High resistance grounding fault detection method based on wavelet energy moment[J]. *Electric Power Automation Equipment*, 2016, 36(12): 161-168.
- [12] 韦明杰, 张恒旭, 石访, 等. 基于谐波能量和波形畸变的配电网弧光接地故障辨识[J]. *电力系统自动化*, 2019, 43(16): 148-154.
WEI Mingjie, ZHANG Hengxu, SHI Fang, et al. Identification of arcing grounded fault in distribution network based on harmonic energy and waveform distortion[J]. *Automation of Electric Power Systems*, 2019, 43(16): 148-154.
- [13] 王桐, 史雯, 石浩瀚, 等. 基于平稳小波变换的光伏直流串联电弧故障检测[J]. *电力系统保护与控制*, 2024, 52(12): 82-93.
WANG Tong, SHI Wen, SHI Haoyuan, et al. Photovoltaic DC series arc fault detection based on stationary wavelet transform[J]. *Power System Protection and Control*, 2024, 52(12): 82-93.
- [14] 权立, 颜琬滢, 王毅钊, 等. 基于同步挤压 S 变换的谐振接地系统单相接地故障区段定位方法[J]. *电网与清洁能源*, 2024, 40(10): 59-66.
QUAN Li, YAN Wanying, WANG Yizhao, et al. A location method of the single-phase grounding fault section for the resonant grounding system based on synchrosqueezing S-Transform[J]. *Power System and Clean Energy*, 2024, 40(10): 59-66.
- [15] 张海涛, 李文娟, 李雪峰, 等. 基于变分模态分解和时间注意力机制 TCN 网络的光伏发电功率预测[J]. *电测与仪表*, 2024, 61(12): 156-163.
ZHANG Haitao, LI Wenjuan, LI Xuefeng, et al. Photovoltaic power forecasting based on TPA-TCN model and variational modal decomposition[J]. *Electrical Measurement & Instrumentation*, 2024, 61(12): 155-163.
- [16] BOKKA K C, ANAMIKA Y, MOHAMMAD P. An intelligent detection of high-impedance faults for distribution lines integrated with distributed generators[J]. *IEEE Systems Journal*, 2020, 14(1): 870-879.
- [17] HAO Bai, GAO Jianhong, LIU Tong, et al. Explainable incremental learning for high-impedance fault detection in distribution networks[J]. *Computers and Electrical Engineering*, 2025, 122.
- [18] LIU Hao, LIU Shuo, ZHAO Junbo, et al. Dual-channel convolutional network-based fault cause identification for active distribution system using realistic waveform measurements[J]. *IEEE Transactions on Smart Grid*,

- 2022, 13(6): 4899-4908.
- [19] RAMESHRAO A G, KOLEY E, GHOSH S. A LSTM-based approach for detection of high impedance faults in hybrid microgrid with immunity against weather intermittency and N-1 contingency[J]. *Renewable Energy*, 2022, 198: 75-90.
- [20] 尚博阳, 罗国敏, 刘畅宇, 等. 小样本条件下基于深度特征融合的配电网高阻接地故障识别方法[J]. *电力系统保护与控制*, 2025, 53(6): 101-112.
SHANG Boyang, LUO Guomin, LIU Changyu, et al. High-impedance fault identification method for distribution networks based on deep feature fusion in small sample conditions[J]. *Power System Protection and Control*, 2025, 53(6): 101-112.
- [21] 史鸿飞, 邓丰, 钟航, 等. 基于暂态时-频特征差异的配电网高阻接地故障识别方法[J]. *中国电机工程学报*, 2024, 44(16): 6455-6470.
SHI Hongfei, DENG Feng, ZHONG Hang, et al. Identification method of high impedance fault in distribution network based on transient time-frequency characteristic difference[J]. *Proceedings of the CSEE*, 2024, 44(16): 6455-6470.
- [22] 蒲天骄, 乔骥, 赵紫璇, 等. 面向电力系统智能分析的机器学习可解释性方法研究(一): 基本概念与框架[J]. *中国电机工程学报*, 2023, 43(18): 7010-7030.
PU Tianjiao, QIAO Ji, ZHAO Zixuan, et al. Research on interpretable methods of machine learning applied in intelligent analysis of power system (Part I): basic concept and framework[J]. *Proceedings of the CSEE*, 2023, 43(18): 7010-7030.
- [23] 王小君, 窦嘉铭, 刘翌, 等. 可解释人工智能在电力系统中的应用综述与展望[J]. *电力系统自动化*, 2024, 48(4): 169-191.
WANG Xiaojun, DOU Jiaming, LIU Zhao, et al. Review and prospect of explainable artificial intelligence and its application in power systems[J]. *Automation of Electric Power Systems*, 2024, 48(4): 169-191.
- [24] 刘畅宇, 王小君, 张大海, 等. 融合时空图信息的配电网故障区段定位及可解释性分析方法[J/OL]. *电工技术学报*: 1-14[2025-12-12]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.250260>
LIU Changyu, WANG Xiaojun, ZHANG Dahai, et al. Research on fault section location method in distribution networks integrating spatio-temporal graph information and interpretability[J/OL]. *Transactions of China Electrotechnical Society*: 1-14[2025-12-12]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.250260>
- [25] 刘熙鹏, 罗庆全, 余涛, 等. 基于多尺度特征融合的负荷辨识及其可解释交互增强方法[J]. *电力系统自动化*, 2024, 48(2): 105-117.
LIU Xipeng, LUO Qingquan, YU Tao, et al. Load identification and its interpretable interactive enhancement method based on multi-scale feature fusion[J]. *Automation of Electric Power Systems*, 2024, 48(2): 105-117.
- [26] 陈泽, 刘文泽, 王康德, 等. 光伏阵列故障诊断的可解释性智能集成方法[J]. *电力自动化设备*, 2024, 44(6): 18-25.
CHEN Ze, LIU Wenze, WANG Kangde, et al. Interpretable intelligent integration method for photovoltaic array fault diagnosis[J]. *Electric Power Automation Equipment*, 2024, 44(6): 18-25.
- [27] 陈光宇, 张盛杰, 杨里, 等. 基于多维场景划分的台区线损率异常研判及关联用户精准追踪方法[J]. *电力系统保护与控制*, 2024, 52(16): 162-177.
CHEN Guangyu, ZHANG Shengjie, YANG Li, et al. Station line loss rate anomaly identification and accurate tracking method of associated users based on multi-dimensional scene division[J]. *Power System Protection and Control*, 2024, 52(16): 162-177.
- [28] BAI S J, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J]. *arxiv preprint*, arxiv: 1803.01271, 2022.
- [29] WANG H, WANG Z, DU M, et al. Score-CAM: score-weighted visual explanations for convolutional neural networks[C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 14-19, 2020, Seattle, USA.
- [30] 梁郑秋, 郝亮亮, 周艳真, 等. 基于卷积神经网络的核电多相无刷励磁系统旋转整流器故障诊断[J]. *电工技术学报*, 2023, 38(20): 5458-5472.
LIANG Zhengqiu, HAO Liangliang, ZHOU Yanzhen, et al. Fault diagnosis of rotating rectifier in nuclear multi-phase brushless excitation system based on convolutional neural network[J]. *Transactions of China Electrotechnical Society*, 2023, 38(20): 5458-5472.
- [31] 罗国敏, 杨雪凤, 尚博阳, 等. 基于改进堆叠降噪自编码器的配电网高阻接地故障检测方法[J]. *电力系统保护与控制*, 2024, 52(24): 149-160.
LUO Guomin, YANG Xuefeng, SHANG Boyang, et al. High impedance grounding fault detection method of a distribution network based on an improved stacked denoised autoencoder[J]. *Power System Protection and Control*, 2024, 52(24): 149-160.

收稿日期: 2025-06-23; 修回日期: 2025-12-12

作者简介:

刘畅宇(1997—), 男, 博士研究生, 研究方向为配电网故障诊断、人工智能在电力系统中的应用;

王小君(1978—), 男, 通信作者, 博士, 教授, 研究方向为配电网故障诊断、主配网协同优化运行。E-mail: xjwangl@bjtu.edu.cn

(编辑 许威)