

一种基于卷积神经网络的电缆故障识别方法

A Cable Fault Identification Method Based on Convolutional Neural Network

鄢少彪,张可可(华东送变电工程有限公司,上海 201803)

Yan Shaobiao, Zhang Keke (East China Power Transmission and Transformation Engineering Company, Shanghai 201803, China)

摘要:

为加快地下输电线路智能巡检的步伐,针对电缆检修中电缆故障识别和定位问题,构建融合多尺度特征提取与时序注意力机制的一维卷积神经网络电缆故障识别模型。通过在自制6 300组电缆故障数据集上进行训练,模型的故障分类正确率能达到90%,故障距离预测的平均误差达0.8 m,同时对不同材质电缆具有一定的鲁棒性。

关键词:

智能巡检;电缆缺陷识别;多尺度特征提取
doi: 10.12045/j.issn.1007-3043.2025.08.016
文章编号: 1007-3043(2025)08-0081-06
中图分类号: TP389.1
文献标识码: A
开放科学(资源服务)标识码(OSID):



Abstract:

To accelerate the advancement of intelligent inspection for underground power transmission lines, it proposes a 1D CNN-based cable fault identification model integrating multi-scale feature extraction and temporal attention mechanisms to address cable fault recognition and localization challenges in maintenance operations. Trained on a proprietary dataset comprising 6 300 cable fault samples, the model achieved a classification accuracy of 90 percent and demonstrated an average prediction error of 0.8 meters in fault distance estimation. Experimental results indicate that the proposed architecture maintains robust performance across cables with varying material compositions. This approach provides an effective technical solution for enhancing the precision and reliability of cable fault diagnosis in power grid maintenance systems.

Keywords:

Intelligent inspection; Cable fault recognition; Multi-scale feature extraction

引用格式: 鄢少彪,张可可. 一种基于卷积神经网络的电缆故障识别方法[J]. 邮电设计技术, 2025(8): 81-86.

0 引言

随着城市化进程的加快和基础设施建设的不断推进,地下电缆的敷设越来越广泛。但由于其安装位置和安装方式的特殊性,日常维护和检修十分棘手,在这些过程中,电缆和缺陷位置的定位是2个主要问题^[1]。电缆的定位方法有双电源比较法、电磁波辐射法、红外扫描法和高压谐波法等^[2-3],其中,基于电磁波辐射原理的无接触式电缆定位方法目前已经能够实

现,且取得了不错的效果,国内一些科技有限公司也已经研发出相应的寻线仪产品,但仅仅定位目标电缆还不足以完成检修任务。为解决电缆故障定位这一难题,一部分研究人员提出单端检测的方法,即在电缆一端施加信号,通过返回的信号判别出电缆的缺陷类型及位置。在文献[4]中,作者提出使用单端时域反射计^[5]的方法根据不同电缆状况下的反射波形的不同,利用电信号在电缆中的传播速度和反射时间可以计算得到电缆终端距离和简单故障类型(开路、短路)。然而,在实际中,电缆型号多种多样,且电缆故障位置往往在电缆的始端与终端中间的某处,同时,

收稿日期: 2025-06-04

电缆的故障类型十分复杂,尤其是线芯不完全断裂和线芯挤压变形等问题,这几个问题若能被解决,将极大减少电缆维护和检修的时间及成本。

近年来,人工智能发展迅猛,各种改进的机器学习、深度学习算法层出不穷^[6]。卷积神经网络作为深度学习领域最具代表性的模型之一,凭借其强大的特征提取能力和空间建模优势,为解决复杂电缆故障检测问题提供了新的技术路径^[7]。不同于传统阈值判据法对人工经验的依赖,卷积神经网络通过端到端的训练机制,能够从原始反射波形中自动挖掘深层次时空关联特征^[8-9]。因而,本文拟搭建融合多尺度特征提取与时序注意力机制的一维卷积神经网络的故障识别模型,识别不同类型、不同缺陷位置的电缆故障。

1 传输线理论

1.1 传输线模型及特性阻抗

传输线理论是分析电缆中电信号传播的核心,其研究基于传输线模型^[10]。传输线模型由离散的电阻、电感、电容和电导组成(见图1)。传输线的每一小段长度 dz 可以看作是由串联电阻 R' 、串联电感 L' 、并联电导 G' 和并联电容 C' 构成的,其中, R' 、 L' 、 G' 都与信号源频率相关,如 R' 、 L' 的值会因集肤效应和邻近效应而变化, G' 的值则会因频率相关的介质损耗而变化^[11]。




图1 传输线模型

传输线的特性阻抗 Z_0 可以通过式(1)来描述:

$$Z_0 = \frac{U_i(\omega)}{I_i(\omega)} = \frac{\sqrt{R' + j\omega L'}}{\sqrt{G' + j\omega C'}} \quad (1)$$

其中, ω 为角频率, R' 是单位长度串联电阻, L' 是单位长度串联电感, G' 是单位长度并联电导, C' 是单位长度并联电容。对于理想的无损传输线, R' 和 G' 为零,特性阻抗可简化为:

$$Z_0 = \frac{\sqrt{L'}}{\sqrt{C'}} \quad (2)$$

1.2 电压反射系数与负载阻抗的关系

在无损传输线中,假设特性阻抗为 Z_0 ,负载阻抗为 Z_L ,根据传输线理论,电压反射系数 Γ_0 为:

$$\Gamma_0 = \frac{Z_L - Z_0}{Z_L + Z_0} \quad (3)$$

当终端开路时, $Z_L \rightarrow \infty$,则:

$$\Gamma_0 = \lim_{Z_L \rightarrow \infty} \frac{Z_L - Z_0}{Z_L + Z_0} = 1 \quad (4)$$

反射电压波与入射电压波同相位。同理,当终端短路时($Z_L \rightarrow 0$), $\Gamma_0 = -1$,反射电压波与入射电压波相位相反;当终端阻抗匹配时($Z_L = Z_0$), $\Gamma_0 = 0$,反射电压波不会发生反射。图2所示为一个简单的示例,A点为电缆始端,B点为分岔点,C点为终端开路状态,D点为终端短路状态,在电缆始端施加一窄脉冲电压信号,并测量该点电压。由于激励源发射的信号为极窄脉冲信号,且电缆内芯本身有阻值,故信号在每次反射都会存在衰减,最终形成如图2所示的波形。




图2 终端开路及短路的情况下电压反射波波形

基于传输线理论,电压反射波波形中携带着与电缆状态有关的信息,电缆的故障状态、电缆内芯材料和长度等都融合在电压反射波中,因而为后文利用卷积神经网络构建电缆故障检测提供了理论依据^[12]。

2 电缆状态识别模型结构

2.1 模型整体设计

针对电缆反射波形的时空特性,本文拟构建一种融合多尺度特征提取与时序注意力机制的一维卷积神经网络,该模型输入为反射波数据 $x_{\text{raw}} \in \mathbb{R}^{N \times 1}$,输出为故障类型概率向量 $p \in \mathbb{R}^{2 \times 1}$ (开路、短路)和故障位置与电缆始端的距离 l_{pred} (电缆路径下故障距离始端的距离)。模型的预测流程如图3所示,整个预测分为故障缺陷类型预测和故障距离预测2个分支,数据预处理和时空特征提取为共享层。

2.2 共享层

为消除电缆型号差异引起的特征偏移,对原始反射波形数据 x_{raw} 进行归一化处理,得到预处理后的输入




图3 模型预测流程

波形数据：

$$x(t) = \frac{x_{\text{raw}}(t) - \mu_{x_{\text{raw}}}}{\sigma_{x_{\text{raw}}}}, t = 1, 2, \dots, N \quad (5)$$

其中, $\mu_{x_{\text{raw}}}$, $\sigma_{x_{\text{raw}}}$ 分别为 x_{raw} 的均值和标准差。对于预处理后的波形数据 $x \in \mathbb{R}^{N \times 1}$, 采用式(6)对其进行时空特征提取：

$$\begin{aligned} h &= \mathcal{B}_4 \circ \dots \circ \mathcal{B}_1(x) \in \mathbb{R}^{512 \times N} \\ M_i(x) &= \bigcup_{k \in \{3, 5, 7\}} \text{ReLU}(W_{i,k} \times x) \\ \hat{h}_i &= \alpha_i \times h_i \\ h &= h + M_i(x) \end{aligned} \quad (6)$$

其中, $\mathcal{B}_1$ 、 $\mathcal{B}_2$ 、 $\mathcal{B}_3$ 、 $\mathcal{B}_4$ 分别为4个特征块, 都包括多尺度卷积 $M_i(x)$ 、时序注意力机制 $\hat{h}_i$ 和残差连接 h , $\circ$ 表示网络连接, ReLU 为斜坡激活函数, k 为卷积核宽度, 对应不同空间尺度(3、5、7采样点), $W_{i,k}$, α_i 均为网络参数, 在后续网络训练时确定。多尺度特征通过通道拼接实现信息融合^[13], 增强模型对近端快速脉冲(小尺度)和远端衰减震荡(大尺度)的联合建模能力。此环节得到的 h 将用于电缆故障类型预测和故障距离预测2个分支。

2.3 电缆状态类型预测

针对电缆故障类型预测, 在进行时空特征提取后, 通过池化层进行全局特征压缩：

$$h_{\text{pool}} = \frac{1}{N} \sum_{t=1}^N h[:, t] \in \mathbb{R}^{512 \times 1} \quad (7)$$

其中, $h[:, t]$ 表示 h 的第 t 列数据。式(7)可将时域特征压缩为全局描述符^[14], 保留通道维度信息。接着利用全连接层进行全连接映射：

$$z_c = \sum_{d=1}^{512} W_{\text{cls}}[d, c] \times h_{\text{pool}}[d] + b_{\text{cls}}[c], c = 1, 2 \quad (8)$$

其中, z_1 、 z_2 分别为开路和短路的类别得分, 是全局特征的线性组合。最后使用 Softmax 函数进行概率归一化：

$$p_c = \frac{e^{z_c}}{e^{z_1} + e^{z_2}}, c = 1, 2 \quad (9)$$

其中, p_1 、 p_2 分别为开路、短路的概率。最后取概率最大者作为最终的电缆状态类型。

2.4 故障距离预测

针对故障距离的预测, 在进行时空特征提取后通过卷积层进行时序特征增强^[15]：

$$\begin{aligned} h_{\text{reg}} &= \text{ReLU}[C_{\text{reg}}(h)] \in \mathbb{R}^{128 \times N} \\ C_{\text{reg}} &: \text{Conv1D}(k = 3, C_{\text{out}} = 128) \\ h_{\text{pool}} &= \frac{1}{N} \sum_{t=1}^N h_{\text{reg}}[:, t] \in \mathbb{R}^{128 \times 1} \end{aligned} \quad (10)$$

其中, C_{reg} 是一维卷积层, 卷积核宽度 $k = 3$, h_{pool} 为全局池化层。然后通过全连接层进行映射：

$$\hat{d} = W_{\text{reg}}^T h_{\text{pool}} + b_{\text{reg}} \in \mathbb{R} \quad (11)$$

其中, $W_{\text{reg}}^T \in \mathbb{R}^{128 \times 1}$, $b_{\text{reg}} \in \mathbb{R}^{1 \times 1}$ 均为全连接层参数, 在后续训练过程中再进行选择。最后通过解码即可获得预测距离 d_{pred} ：

$$d_{\text{pred}} = \frac{v_p}{2} \times \frac{1}{1 + e^{-\hat{d}}} \times T_{\text{max}} \quad (12)$$

其中, v_p 为光速, $v_p = 2 \times 10^8$ m/s, T_{max} 为最大时间窗口, 由采样率和点数决定, $T_{\text{max}} = N/f$ 。

2.5 混合损失函数设计

为联合优化电缆状态分类与故障位置预测任务, 定义混合损失函数如下：

$$\begin{aligned} \mathcal{L} &= \lambda \mathcal{L}_{\text{cls}} + (1 - \lambda) \mathcal{L}_{\text{reg}} \\ \mathcal{L}_{\text{cls}} &= - \sum_{c=1}^C y_c \log(p_c) \\ \mathcal{L}_{\text{reg}} &= \begin{cases} \frac{1}{2} (d - d_{\text{pred}})^2, & |d - d_{\text{pred}}| \leq \delta \\ \delta |d - d_{\text{pred}}| - \frac{1}{2} \delta^2, & \text{其他} \end{cases} \end{aligned} \quad (13)$$

其中, $\mathcal{L}_{\text{cls}}$ 为分类损失, 采用交叉熵损失^[16]; $\mathcal{L}_{\text{reg}}$ 为

回归损失,这里采用Huber损失; d 为故障距离真值; d_{pred} 为网络预测值; λ 为任务权重系数, $\lambda = 0.7$; y_c 为电缆真实故障状态的独热标签^[16]; δ 为Huber损失阈值, $\delta = 0.1$ 。

3 模型训练

3.1 数据集的获取

由于本文建立的模型针对性较强,为较为具体的场景,无现成数据集对模型进行训练,故本文将搭建平台制作数据集。实验平台如图4所示,通过发射器发送上升时间为350 ps左右的约90 V窄脉冲信号至待测电缆线芯,而后通过示波器捕捉到反射波,并将数据存储到U盘内。

实验的重点在于电缆故障状态的制作过程,在本实验中,用到RVV2型、BVV4型及BV6型电缆各500 m,首先将电缆摊开,避免成团的情况,然后按照图4中的接线方式接线,并将示波器改成阈值触发捕捉模式,然后打开发射器发射信号至待测电缆,最后将示波器捕捉到的波形数据保存到U盘内,每次实验重复捕捉30次波形数据作为该类条件下的样本数据。本实验所用电缆为多芯线,包括三色主芯线及其各自分芯线,取各色分芯线的一半切断或短接以模拟实际场景中电缆不完全断裂或短路的情况。此外,本文在三色线芯的不同位置处制作开路 and 短路的故障以提高材料的利用率,加上终端断路的情况,每一电缆长度下故障位置共有4类,将其选取在靠近电缆终端的位置,这样在做完某一长度电缆实验时可以将含故障的

后段切除,即可得到新长度且无中间故障的电缆实验材料(如500 m电缆分别在410、440、470 m处设置开路和短路故障,后将原500 m电缆的后100 m切除得到400 m电缆),最终得到的数据集如表1所示。

图5为100 m RVV2型电缆在终端开路情况下得到的反射波波形,从图5可以清楚看到2个反射波区域,它们所包含的模态相同,只是后者强度较小,原因是电缆线芯有一定阻值且发射电压信号能量较小(幅值大但持续时间短)。对于无损耗电缆线而言,其反射波强度之间的差异会更小,但最终也会逐渐趋向于0(每次反射都会向外辐射一部分能量)。

3.2 参数说明

基于前文构建的网络结构,还需要配置模型的一些超参数,具体如表2所示。在数据划分方面,选择训练集:验证集:测试集=7:1.5:1.5的配置。另外,本实验模型使用pytorch作为训练平台并使用GPU加速,笔记本配置如下:CPU型号i7-9700,显卡型号RTX2060Ti。

3.3 训练结果分析

经过多次训练,网络在迭代800次左右后训练损失几乎保持不变,但在600~800迭代轮次中可能会出现模型性能突然下降的情况,原因可能是模型正在适配某一型号电缆(主要是BVV4型号电缆)的缺陷检测而导致另外2种型号电缆的结果变差,为保险起见,本文选择迭代轮次为1 000,训练结果表明,在迭代轮次为1 000的情况下,可在兼顾训练时长下极大程度避免模型适配的情况发生。其中一次的训练结果如图6




图4 实验平台(以上实验电缆均为多芯线,且带屏蔽层)

表1 数据集概况

电缆长度/m	电缆故障类别	故障位置/m	总样本数量/组
500	开路	500	30
		470	60
		440	60
		410	60
	短路	500	30
		470	60
		440	60
		410	60
...			
100	开路	100	30
		70	60
		40	60
		10	60
	短路	100	30
		70	60
		40	60
		10	60

注:①省略部分指线缆长度为400 m、300 m、200 m的情况。
②以上为单型号电缆实验得到的数据集情况,最终得到的数据集应增加至3倍,即 $3 \times 420 \times 5 = 6\,300$ 组。
③当故障位置等于电缆长度时,总样本数量只有30组,而当故障位置不等于电缆长度时有60组,是因为前者只有完全故障,后者分为完全故障和非完全故障,例如,电缆状态为开路且故障位置为480 m时,则电缆内芯的一半断开为非完全故障,完全断开为完全故障。
④电缆的开路状态不严格区分完全开路和部分开路,短路状态亦同,此外,短路状态是指线芯与屏蔽层短接。
⑤故障位置指电缆路径下故障位置距离电缆始端的距离,电缆终端开路或短路的状态下,故障位置等于电缆长度,电缆终端开路或短路的情况与中间故障点共存时,故障位置为中间故障点。
⑥本实验示波器所用采样率为1 GHz,每组数据为8 000个。

所示,从图6可以看到,随着迭代轮次的不断增加,训练损失在不断下降,对于故障分类,训练集和测试集最终分别稳定在93%和90%左右,对于故障距离的预测,也取得了不错的效果,MAE最终稳定在0.8 m左




图5 100 m长RVV2型电缆断路情况下示波器捕捉的波形

表2 模型超参数配置

模块	参数名称	取值	依据
输入层	采样点数 N	8 000	—
卷积模块	卷积核数	64/128/256/512	深层通道递增,捕获多尺度特征
多尺度卷积模块	卷积核宽 k	{3,5,7}	匹配近端(小核)与远端(大核)反射特性
注意力模块	局部信息窗口 $\Delta t=5$	5	覆盖典型脉冲宽度(350 ps $\approx$ 7采样点)
优化器	学习率	10^{-4} (Adam)	实验验证的稳定收敛区间
正则化	Droupout 率	0.3	平衡过拟合抑制与特征保留

右,最大预测误差达1.6 m,对于不同型号的电缆来说,能够达到这样的效果已经是比较好的情况。为检验模型对电缆型号的鲁棒性,本文将训练所得到的模型用于60 m长的VY4型号电缆(终端开路),模型的输出结果为开路,故障距离为58.48 m。真实故障距离与预测值相差2.52m,精度出现一定下降,但属于可接受的范围。本文对另外几类电缆型号进行试验,试验结果显示,故障类别全部识别成功,最大故障距离预测误差为3.45 m(试验电缆长度为700 m,未铺开),因而本




图6 模型训练结果

文构建的模型具有一定的鲁棒性。这里采用平均绝对误差(MAE)来统计:

$$MAE = \frac{1}{n} \sum_{i=1}^n |d^{(i)} - d_{\text{pred}}^{(i)}| \quad (14)$$

其中, n 为样本总数, d 为故障距离真值, d_{pred} 为网络预测值。

此外, 本文还进行了超参数消融实验, 实验结果如表3所示。从表3可以看出, 移除注意力模块后, 模型性能出现断崖式下降, 分类准确率下降 16.1% (90.2%→74.1%), 预测 MAE 激增 1 175% (0.8→10.2 m)。这表明注意力机制对故障特征的长距离关联建模至关重要, 模型依赖注意力进行故障反射波形的关键特征筛选; 单尺度卷积($k=5$)使 MAE 增加 125% (0.8→2.6 m), 说明多尺度卷积能有效捕捉不同传播距离的波形畸变特征, 单一感受野难以适应故障点反射波与终端反射波的叠加干扰; 取消 Dropout 导致 MAE 增加 100% (0.8→1.6 m), 说明模型存在高频噪声过拟合风险(8 000 点波形中的局部干扰), Dropout 通过随机屏蔽局部特征, 迫使模型学习全局传播规律。

表3 超参数消融结果

超参数	分类准确率(测试集)/%	预测 MAE/m
基准配置	90.2	0.8
移除注意力模块	74.1(-16.1)	10.2(+9.4)
单尺度卷积($k=5$)	84.7(-5.5)	2.6(+1.8)
Dropout=0.0	87.5(-2.7)	1.6(+0.8)

4 结论

针对地下电缆缺陷定位的难题, 本文提出了一种融合多尺度特征提取与时序注意力机制的一维卷积神经网络预测模型。试验结果表明, 该模型对电缆故障的识别以及故障的位置预测具有不错的效果, 在本文自制的数据集上, 对验证集的故障类别的识别准确率达 90% 左右, 故障距离平均误差达 0.8 m 左右, 最大误差为 1.6 m, 同时对电缆材料具有一定的鲁棒性。当然, 本文建立的模型也有较多不足之处, 比如未考虑多故障的情况, 即电缆中出现多处开路和短路的情况, 同时对故障类别的分类和故障距离的预测准确度还有待提升等。

参考文献:

[1] 由建, 焦建红. 城市 110kV 电缆线路切改方案[J]. 农村电气化, 2018(5): 11-13.

- [2] 刘世哲, 刘芳园, 王志双. 电力电缆故障定位方法分析[J]. 集成电路应用, 2024, 41(12): 122-123.
- [3] 张浩然, 金辰. 电力电缆故障定位方法研究[J]. 电力设备管理, 2021(5): 170-171.
- [4] 贾诗豪. 电力电缆故障定位及诊断方法研究[D]. 阜新: 辽宁工程技术大学, 2023.
- [5] 佚名. HDTDR——高精度时域反射计[J]. 智能建筑与城市信息, 2005(11): 4-5.
- [6] 伍钰婷, 宋先琴, 伍继红, 等. 基于深度学习的输电线路检测综述[C]//2024 年电力行业技术监督专业技术交流研讨会优秀论文集. 南宁: 中国电力技术市场协会, 2024: 751-756.
- [7] 程曦. 高压输电线路图像缺陷检测方法研究[D]. 呼和浩特: 内蒙古大学, 2021.
- [8] 刘文龙, 文斌, 马梦帅, 等. 多种深度学习融合的网络流量异常检测模型[C]//第 39 次全国计算机安全学术交流会论文集. 西安: 中国计算机学会, 2024: 56-60.
- [9] 韩旭, 段中兴, 尚旭东. 基于多头注意力机制和 CNN-BiGRU 模型的水质预测方法[C]//2024 中国自动化大会论文集. 青岛: 中国自动化学会, 2024: 146-151.
- [10] 叶金平, 陈逸朗, 张云鹏, 等. 传输线特性阻抗测试方法研究[C]//2024 年全国微波毫米波会议论文汇编(上册). 北京: 中国电子学会, 2024: 394-396.
- [11] 周顺利, 王勇, 龚清勇. 基于 Z 平面传输线上电压与电流的求解[C]//2014 年全国电磁兼容与防护技术学术会议论文集. 常德: 中国电子学会微波分会, 2014: 174-177.
- [12] 薛文彦, 马西奎, 赵进全. 机电电缆的传输线时域模型及其瞬态响应分析[C]//电工理论与新技术学术年会论文集. 西安: 中国电机工程学会, 2005: 228-232.
- [13] 关晓岚, 韩文, 杨品舒, 等. 基于非线性通道融合的深度神经网络模型结构[C]//第十八届全国信号和智能信息处理与应用学术会议论文集. 合肥: 中国高科技产业化研究会智能信息处理产业化分会, 2024: 634-637.
- [14] 袁欣如, 吴彤, 刘毅. 基于卷积神经网络的舰载跑道异物检测方法研究[C]//2024 中国自动化大会论文集. 青岛: 中国自动化学会, 2024: 262-267.
- [15] 郑森炜, 张伟伟. 一种基于卷积神经网络的网格离散误差校正模型[C]//第十三届全国流体力学学术会议摘要集(下). 哈尔滨: 中国力学学会流体力学专业委员会, 2024: 676.
- [16] 赵东风, 杨帆, 郭淑文, 等. 基于改进深度卷积神经网络的地震相分析[C]//第六届油气地球物理学学术年会论文集. 三亚: 中国地球物理学会油气地球物理专业委员会, 2024: 10-14.

作者简介:

鄢少彪, 高级工程师, 学士, 主要从事特高压直流工程建设、国内大型换流站直流综合改造等工作; 张可可, 高级工程师, 硕士, 主要从事电力系统施工数字化智能化研究工作。

