

DOI: 10.19650/j.cnki.cjsi. J2615068

# 基于各向异性三维空洞卷积神经网络的 桥梁缆索断丝定量识别方法<sup>\*</sup>

王润雨<sup>1</sup>, 孙令司<sup>1</sup>, 刘焕泽<sup>1</sup>, 蒋立军<sup>2</sup>, 武新军<sup>1</sup>

(1. 华中科技大学机械科学与工程学院 武汉 430074; 2. 柳州欧维姆机械股份有限公司 柳州 545006)

**摘 要:**为解决桥梁缆索漏磁检测中断丝缺陷的数量难以准确定量的问题,根据桥梁缆索漏磁检测(MFL)信号沿缆索轴向、周向和径向上的分布特性,提出一种基于缆索专用各向异性三维空洞卷积神经网络(Cable-AD3D-CNN)的桥梁缆索断丝定量方法。该方法依托缆索漏磁检测平台,制作含不同断丝数量以及断丝数量相同时分布位置不同的桥梁缆索试件,并采集缆索试件在不同轴向位置、周向位置及径向提离条件下的漏磁场轴向分量构建数据集;针对采集所得漏磁检测信号的分布特性以及数据规模差异,采用各向异性卷积核,保证模型具有一定的分辨率的同时增强模型对断丝空间特征的提取能力,并在轴向上引入递增且互质的空洞率,增大模型对漏磁检测信号的感受范围,进而搭建 Cable-AD3D-CNN 模型。在此基础上对模型进行训练,利用训练好的模型对含有断丝的桥梁缆索漏磁信号进行识别,实现断丝数量判别。研究结果表明,所提方法收敛性较好,对断丝数量识别准确率可达 96.94%,与基于三维卷积神经网络(baseline 3D-CNN)模型的识别方法相比,准确率提高了 13.61%,且所提 Cable-AD3D-CNN 的桥梁缆索断丝定量方法能够有效抑制断丝数量相近类别之间的混淆,提高不同断丝数量样本间的区分能力,可为桥梁缆索损伤的精确定量评估和运维决策提供参考。

**关键词:** 缆索断丝; 定量识别; 三维卷积神经网络; 各向异性空洞卷积; MFL

**中图分类号:** TG115.28 TH165.3 **文献标识码:** A **国家标准学科分类代码:** 460.40

## A quantitative identification method for broken wires in bridge cables based on anisotropic 3D dilated convolutional neural networks

Wang Runyu<sup>1</sup>, Sun Lingsi<sup>1</sup>, Liu Huanze<sup>1</sup>, Jiang Lijun<sup>2</sup>, Wu Xinjun<sup>1</sup>

(1. School of Mechanical Science and Engineering, Huazhong University of Science and Technology, Wuhan 430074, China;  
2. Liuzhou OVM Machinery Co., Ltd., Liuzhou 545006, China)

**Abstract:** To address the difficulty in accurately quantifying the number of broken wires in bridge-cable magnetic flux leakage (MFL) testing, a quantitative identification approach for broken wires in bridge cables based on Cable-convolutional neural network anisotropic dilated three dimensional (Cable-AD3D-CNN) is proposed according to the distribution characteristics of MFL signals along the axial, circumferential, and radial directions of bridge cables. This method uses a bridge-cable MFL testing platform to fabricate specimens containing different numbers of broken wires and different broken-wire locations under the same broken-wire number. The axial component of the leakage magnetic field is acquired at different axial positions, circumferential positions, and radial lift-off distances to establish the dataset. Considering the directional distribution characteristics and data-scale differences of the acquired MFL signals, anisotropic convolution kernels are adopted to preserve directional resolution while enhancing the extraction of spatial features associated with broken wires. In addition, progressively increasing and pairwise coprime dilation rates are introduced along the axial direction to enlarge the receptive field for the MFL signals. Based on these designs, the Cable-AD3D-CNN model is established. The model is then trained and deployed to identify the MFL signals of bridge-cable specimens containing broken wires, thereby determining the number of broken wires. Experimental results demonstrate that the proposed method exhibits good convergence and achieves an accuracy of 96.94% for broken-wire-number identification. Compared with the method based on the baseline three-dimensional convolutional neural network

收稿日期: 2026-03-24 Received Date: 2026-03-24

<sup>\*</sup> 基金项目: 国家自然科学基金区域创新发展联合基金(U21A20139)项目资助

(baseline 3D-CNN), the accuracy is increased by 13.61%. In addition, the proposed approach effectively reduces confusion among categories with similar broken-wire numbers and improves the discriminability of samples with different broken-wire numbers, providing a useful reference for accurate quantitative evaluation and maintenance decision-making for bridge-cable damage.

**Keywords:** broken wires of bridge cables; quantitative identification; 3D convolutional neural network; anisotropic dilated convolution; MFL

## 0 引言

缆索作为悬索桥、斜拉桥重要的承载构件,长期在交变载荷中工作,容易出现断丝缺陷,削弱索体的结构完整性,改变其受力特性,降低钢丝疲劳寿命,进而严重影响桥梁的安全服役状态与工作性能<sup>[1-2]</sup>。因此,需要对在役缆索开展断丝缺陷定量识别,判断缆索是否达到更换标准,进而为桥梁的安全运行提供决策支持。目前桥梁缆索的检测方法主要有视觉检测法和漏磁检测法等。视觉检测法可实现缆索表面护套破损等外观缺陷检测,邓小龙等<sup>[3]</sup>采集缆索近景影像,采用改进的分割一切模型(segment anything model, SAM)对缆索表面损伤类型进行分类。Li等<sup>[4]</sup>采用机器视觉检测系统提取图象特征,根据基于粒子群优化的支持向量机(particle swarm optimization-based support vector machine, PSO-SVM)算法对缆索表面缺陷进行分类。由于缆索表面包覆有高密度聚乙烯(high-density polyethylene, HDPE)护套,视觉检测法无法获取缆索内部断丝信息;而漏磁检测法能够采集内部钢丝断裂产生的漏磁场,是实现缆索内部断丝检测的有效手段。

研究者们已经对漏磁检测法所得信号开展大量研究,并在钢丝绳、管道等铁磁性构件中取得较多成果。现有针对漏磁信号的研究主要可归纳为4类:第1类是基于传统信号处理的方法,如Zhang等<sup>[5]</sup>提出一种基于集合经验模态分解与小波变换相结合的信号处理方法,通过多尺度分解有效滤除噪声,并引入超分辨率重建技术显著提升剩磁图像的空间分辨率,实现钢丝绳断丝缺陷检出;曹辉等<sup>[6]</sup>提出基于数据融合的小波变换漏磁异常边缘检测算法,利用数据层融合、特征融合以及决策层融合相结合的方法,实现管道边缘缺陷的检出;第2类是基于人工特征构造与机器学习相结合的方法,如Zheng等<sup>[7]</sup>将采集到的钢丝绳漏磁信号进行变模态分解后转化为灰度图象,并依据图像特征采用K近邻算法实现钢丝绳断丝数量分类;赵翰学等<sup>[8]</sup>提取漏磁信号中峰峰值等特征量,采用支持向量机(support vector machine, SVM)等传统机器学习方法对管道缺陷类型进行区分;Zhang等<sup>[9]</sup>将漏磁信号转换为伪彩色图像,提取颜色矩和纹理特征并结合反向传播神经网络进行分析,实现钢丝绳断丝数量的定量分析;第3类是传统方法与卷积神经网络

相结合的识别方法,如Liu等<sup>[10]</sup>采集钢丝绳漏磁信号并降噪,从中提取10个特征量送入一维卷积神经网络(one-dimensional convolutional neural network, 1D-CNN)中对钢丝绳缺陷类型进行识别;任建浩等<sup>[11]</sup>采用1D-CNN提取漏磁检测信号中的特征量并送入SVM中实现对钢丝绳断丝数量的识别;第4类则是基于端到端深度学习的方法,这类方法直接以信号作为输入,通过深层神经网络自动完成多层次特征学习与缺陷判别,如Jiang等<sup>[12]</sup>搭建THMS-Net模型,引入轴向与径向异构信号的互监督机制,提出缺陷样本和非缺陷样本分两阶段训练的策略,并结合改进的非极大值抑制算法对候选缺陷进行筛选,从而在不同缺陷尺寸、缺陷数量及噪声干扰条件下实现对缺陷的稳定检出;Yang等<sup>[13]</sup>在单次多框检测算法中引入空洞卷积与残差模块,提高特征图像分辨率,实现管道周向焊缝等缺陷位置的识别;李春晖等<sup>[14]</sup>提出基于人工标注经验的自动化训练数据集生成方法,并采用自适应图像增强策略将数据转化为标准化灰度图像,利用YOLOv8对缺陷进行定位并精确标注出缺陷边界。前3类方法虽取得了一定的成效,但均在不同程度上依赖人工设计特征,或经模型提取特征后再在既定特征空间中完成分析,对复杂工况下漏磁响应深层特征的挖掘能力仍然有限;第4类端到端深度学习方法减少了对人工特征构造的依赖,能够学习漏磁响应中的深层非线性特征,从而在复杂工况下展现出更强的缺陷识别精度与鲁棒性。此外,在其他复杂信号识别与故障诊断任务中,贾康康等<sup>[15]</sup>、吕轶等<sup>[16]</sup>、应万明等<sup>[17]</sup>、冯李航等<sup>[18]</sup>、Yang等<sup>[19]</sup>分别通过引入注意力机制模块、跨传感器特征融合、嵌入S变换、数据增强与增量补偿、多源信号融合等方式,结合具体研究任务对深度学习模型进行改进,在复杂信号深层特征提取和识别稳定性提升方面取得了较好效果。

然而,目前桥梁缆索漏磁信号的分析,仍采用传统信号分析方法,提取其中的特征量进行缺陷定性以及定位,如辛荣亚等<sup>[20]</sup>采集一维轴向漏磁信号,结合短时能量与有效互相关法对缆索表层及深层断丝进行定位,其轴向平均定位误差为3.5 cm。张艺潇等<sup>[21]</sup>则通过分析二维漏磁场的空间分布特征,实现缆索全截面缺陷检测与定位。尽管现有研究在断丝检出和定位方面取得了一定成果,但尚未建立漏磁信号特征与断丝数量之间的定量关系。断丝的量化分析面临两方面难题:一方面,随着缆

索中断丝数量增加,断丝产生的漏磁场呈现出复杂的非线性叠加关系,仅基于一维或二维信号难以完整表征断丝数量变化引起的多维特征差异;另一方面,缆索检测中传感器提离较大,加上缆索表面 HDPE 护套厚度不均匀导致提离波动影响漏磁信号,进而增大特征提取的难度。单纯依靠人工提取缆索一维或二维漏磁信号中的特征量,难以充分刻画漏磁信号与损伤程度之间的复杂定量关系。

为解决上述问题,本文采集桥梁缆索漏磁信号,搭建端到端识别架构,构建缆索专用各向异性三维空洞卷积网络 (cable-targeted anisotropic dilated three-dimensional convolutional neural network, Cable-AD3D-CNN) 模型并提出一种桥梁缆索断丝数量识别方法,实现对缆索断丝定量判断;与随机森林 (random forest, RF)、多层感知机 (multi-layer perceptron, MLP)、AdaBoostM2 等传统机器学习方法及基于基准三维卷积神经网络 (baseline three-dimensional convolutional neural network, baseline 3D-CNN) 的方法进行对比,结果表明,所提方法在准确率与宏平均指标等方面表现更为优异,可为缆索损伤分级与运维决策提供可靠的量化依据。

1 理论介绍

1.1 三维卷积神经网络

三维卷积神经网络 (three-dimensional convolutional neural network, 3D-CNN) 通常由输入层、卷积模块、池化模块、全连接模块以及输出层组成,基本结构如图 1 所示。




图 1 3D-CNN 基本结构

Fig. 1 Basic structure of 3D-CNN

3D-CNN 的输入可表示为“ $H \times W \times D \times C$ ”,其中  $H$ 、 $W$ 、 $D$  表示输入数据的 3 个维度,  $C$  表示通道数。在卷积运算中,三维卷积核在  $H$ 、 $W$ 、 $D$  这 3 个维度上进行局部感受并逐步滑动,实现对三维邻域信息的特征提取。卷积层、批量归一化 (batch normalization, BN) 层及非线性激活函数 (如 ReLU 函数) 组合形成卷积模块,在卷积运算提取局部空间关联特征的同时,借助 BN 层稳定特征分布并配合非线性激活增强表达能力,使网络能够通过多层堆叠逐级抽象输入信息。池化模块通过选取数据中的统计

值对特征图进行下采样,降低空间分辨率与维度,减少计算冗余。随后,全连接模块中各全连接 (fully connected layer, FC) 层将高层特征展平并融合,最终通过输出层映射至目标空间,完成分类或回归。

1.2 空洞卷积

空洞卷积 (dilated convolution) 又名膨胀卷积,是在常规卷积中引入空洞率 (dilation rate, DR) 的一种卷积方式。空洞卷积通过在采样点之间插入 DR-1 个间隔,以间隔采样的方式增大等效卷积核尺寸,从而在不增加参数量的前提下显著增大感受野,捕获更大范围内的特征信息。图 2 为三维卷积中的空洞卷积原理,其中红色采样点表示卷积核在输入特征图上的实际采样位置,以基准核尺寸为 3 为例,当 DR 由 1 增大至 3 时,有效感受野可由 3 扩展至 7。




图 2 空洞卷积原理

Fig. 2 Principle of dilated convolution

由图 2 可知,随 DR 增大,采样点之间的间距增大,感受野增大,但采样点个数及卷积参数量保持不变,仅改变有效感受野的覆盖范围。但 DR 并非越大越好,过大的 DR 会导致边界填充主导,影响信号特征的提取。同时,在深层网络中,若持续叠加相同 DR 的空洞卷积,会出现采样栅格化现象,导致局部信息连续丢失。因此,为兼顾长程上下文与局部细节表征通常通过逐层变化 DR 来填补采样空洞。对于桥梁缆索断丝识别,由断丝产生的漏磁信号呈现出一定的空间分布特性,常规卷积感受野有限,难以充分提取特征,故在所搭网络中引入互质且递增的空洞卷积,增大其对漏磁信号的感受范围,从而增强对断丝漏磁特征的提取能力。

1.3 各向异性卷积

3D-CNN 通常基于各向同性卷积核构建,即认为输入数据在各个方向上具有相似的特征尺度与统计分布,在所有空间维度上采用尺寸一致的各向同性卷积核。但对于特征尺度不对称三维数据,采用各向同性卷积核易导致某些维度过度平滑而细节信息受损,或为扩大主导维度感受野而被迫同步增大其他维度核尺寸,从而带来冗余计算与表征偏差。对于此类特征尺度不对称信号,



若采用如图 3(a) 所示各向同性卷积核,则难以兼顾不同维度上特征尺度的差异性需求,当卷积核在 3 个方向同步取较大尺寸时,虽能扩大感受野并增强对长程上下文变化的表征,但会在特征尺度较小的维度引入过度平滑,削弱局部细节响应;当卷积核在 3 个方向同步取较小尺寸时,虽有利于保留局部差异,却会使长程上下文特征提取能力受限,难以捕捉更大尺度范围内的特征;采用如图 3(b) 所示各向异性卷积核,在输入数据的尺寸较大的维度上增大核尺寸,在其他维度上保持较小核尺度,即可实现保留局部细节的同时在特定维度上扩展感受野。因本文所采缆索漏磁信号在轴向、周向、径向上数据规模差异较大,故所搭网络采用各向异性卷积核以满足信号在不同维度上的感受野需求,提升对断丝空间特征的提取能力。




图 3 各向同性与各向异性卷积核

Fig. 3 Isotropic and anisotropic convolution kernel

2 数据集构建与模型设计

2.1 数据集构建

1) 数据采集

为模拟桥梁缆索实际服役过程中的断丝损伤工况,本文选取 PESC7-127 规格的缆索作为实验对象。根据《城市桥梁养护技术标准》<sup>[22]</sup>,当缆索内部已断裂的钢丝面积超过缆索钢丝总面积 2% 时,或钢丝锈蚀造成该缆索总面积损失超过 10% 时,必须更换缆索,计算可知 PESC7-127 规格的缆索断丝更换临界值为 2.54 根。为覆盖更换阈值及其上下区间的典型损伤状态,本文设置

2~5 根断丝工况开展研究。在断丝缺陷工况设置中,除考虑断丝数量外,还进一步考虑断丝在缆索截面上的分布位置。由于缆索结构较为复杂,断丝引起的漏磁场并非简单线性叠加,而会随着断丝相对位置和间隔方式的不同呈现出明显差异。为模拟实际服役条件下断丝随机分布的特征,针对相同断丝数设置多种不同位置和间隔形式,共布置 31 处断丝缺陷,各断丝缺陷采用相同的加工方式制作,并保持断丝断口宽度一致,缆索中部分断丝分布如图 4 所示。





图 4 缆索部分缺陷示意图

Fig. 4 Schematic diagram of partial cable defects

采用实验室自研桥梁缆索磁性检测系统<sup>[23]</sup>搭建如图 5(a) 所示实验平台,对 PESC7-127 缆索进行数据采集,实验平台主要由缆索、漏磁检测装置、系统主机、网桥及远程计算机组成。漏磁检测装置搭载高灵敏度霍尔元件阵列,如图 5(b) 所示,霍尔元件沿缆索周向均匀布置且沿径向由内向外依次排布为 4 层,第 1 层霍尔元件提离为 3 mm,径向相邻两霍尔元件净距为 1 mm。阵列所用霍尔元件型号为 Allegro A1302-KUA-T,线性工作范围为  $\pm 100$  mT。检测系统以 4 m/min 的速度、1 mm/点的轴向采样间隔沿缆索轴向扫查,采集缆索在不同轴向位置、周向位置及径向提离条件下的漏磁场轴向分量。



(a) 桥梁缆索漏磁检测实验平台

(a) Experimental platform for bridge cable MFL testing






图5 桥梁缆索漏磁检测实验平台及霍尔元件分布示意图  
Fig. 5 Experimental platform for bridge cable MFL testing and distribution of Hall elements

2) 数据集构建

采集所得原始漏磁信号中常包含趋势项和随机噪声,无法直接用于断丝缺陷的定量分析,故首先对采集到的原始漏磁信号进行相邻通道内数据差分处理,抑制背景场的干扰;然后采用 Savitzky-Golay 滤波去除趋势项;最后采用滑动平均滤波对信号进行平滑处理。因完整扫

查信号长度较大,而断丝漏磁响应主要集中在缺陷附近,为减少冗余信息,降低模型训练难度,以峰值为中心,在每层霍尔元件信号中截取包含漏磁响应的信号片段。考虑不同缺陷窗口的原始尺寸存在差异,为保证网络输入尺寸一致,对截取的信号片段进行插值重采样,将尺寸统一为  $155 \times 45$ ,其中 155 为轴向采样点数,45 为周向采样点数。再将同一处缺陷在单次扫描中得到的第 1~4 层霍尔元件信号片段,按径向提离顺序组合,形成“轴向×周向×径向”结构的三维漏磁信号。该三维漏磁信号中各方向信号具有不同物理含义,即轴向维度上的信号反映断丝缺陷沿缆索轴向方向的响应变化过程;周向维度上的信号体现漏磁响应沿缆索截面圆周方向的变化情况;径向维度上的信号则反映漏磁场强度随提离变化的衰减规律。

图4中J-J缺陷(5根断丝)的第1~4层霍尔元件漏磁信号波形如图6所示,随着层数增加,霍尔元件提离逐渐增大,漏磁信号幅值逐渐衰减,同时波形沿轴向、周向逐渐展宽。




图6 J-J截面5根断丝工况下第1~4层霍尔元件典型漏磁信号  
Fig. 6 Typical magnetic flux leakage signals of layers 1~4 Hall elements under the J-J section with five wire breaks

图4中L-L和K-K缺陷的第1层霍尔元件信号分别如图7(a)和(b)所示,这两处缺陷断丝数量均为5根,但由于断丝所在位置和间隔不同,漏磁信号存在明显差异,说明相同断丝数量下的漏磁响应并不唯一,该结果也印证了前文针对相同断丝数设置多种不同位置和间隔形式。





图7 不同空间分布下5根断丝缺陷的第1层霍尔元件漏磁信号对比  
Fig. 7 Comparison of first-layer Hall element MFL signals for five-wire-break defects with different spatial distributions

按三维卷积神经网络的输入要求,进一步将三维漏

磁信号组织为  $H \times W \times D \times C$  的样本,其中, $H$  为轴向采样点数, $W$  为周向采样点数, $D$  为径向提高层数, $C$  为通道数。本文中  $H=155, W=45, D=4, C=1$ ,故最终输入模型的单个样本尺寸为  $155 \times 45 \times 4 \times 1$ 。以断丝数量作为标签对样本进行标注并构建包含 1 466 个样本的数据集。按断丝数量标签对数据集进行分层随机划分,即分别在标签为 2、3、4、5 根断丝的样本集合内,按照 8:1:1 的比例划分训练集、验证集和测试集,划分结果如表 1 所示。其中训练集用于模型迭代,验证集用于微调参数,测试集用于模型性能评估。

2.2 Cable-AD3D-CNN 模型设计

构建 Cable-AD3D-CNN 模型如图 8 所示,模型采用端到端训练策略,以预处理后的缆索漏磁信号作为输入,建立从漏磁场到断丝数量的映射关系。网络主体由各向异性卷积模块与各向异性空洞卷积模块交替构成,并在模块间引入池化层实现特征尺度的变换。将多层提取得

表 1 不同断丝数量样本数量及占比  
Table 1 Number and proportion of samples with different numbers of broken wires

| 断丝数量 | 训练集样本数量 | 验证集样本数量 | 测试集样本数量 | 总计    | 占比/%   |
|------|---------|---------|---------|-------|--------|
| 2    | 449     | 56      | 57      | 562   | 38.34  |
| 3    | 284     | 35      | 36      | 355   | 24.22  |
| 4    | 231     | 29      | 29      | 289   | 19.71  |
| 5    | 208     | 26      | 26      | 260   | 17.73  |
| 总计   | 1 172   | 146     | 148     | 1 466 | 100.00 |

到的高维特征输入分类头,经全连接层融合,映射得到断丝数量。因输入的缆索漏磁信号在轴向维度上数据量较大,模型必须具备足够大的轴向感受野以捕捉完整的断丝信号沿轴向扩散规律,但信号在周向和径向维度上数




图 8 Cable-AD3D-CNN 模型结构  
Fig. 8 Structure of the Cable-AD3D-CNN model

据量较小,仅需较小的感受野。基于上述理论与输入数据在不同维度上的差异,模型中各核轴向尺寸选取大值,周向和径向核尺寸选取较小值。同时仅在卷积核轴向维度上引入递增且互质的 DR,确保在捕获漏磁信号轴向长距离特征的同时,兼顾到周向与径向微小形态的细节特征,模型结构参数详见表 2。

表 2 Cable-AD3D-CNN 模型结构参数  
Table 2 Parameter settings of the Cable-AD3D-CNN model

| 模块名称     | 模块结构及参数                                                                                                                           |
|----------|-----------------------------------------------------------------------------------------------------------------------------------|
| 卷积模块     | Conv3D (7×3×1, 16, pad=same) + BN + ReLU +MaxPool3D (2×2×1, s=2×2×1)                                                              |
| 空洞卷积模块 1 | { DilatedConv3D (5×3×1,32, DR=1×1×1) + BN+ ReLU } +<br>{ DilatedConv3D (5×3×1,32,DR=2×1×1) +BN+ReLU } +MaxPool3D (2×2×1, s=2×2×1) |
| 空洞卷积模块 2 | { DilatedConv3D (3×3×1,64, DR=2×1×1) +BN+ReLU } + { DilatedConv3D(3×3×1,64,DR=3×1×1) +BN+ReLU }                                   |
| 全连接模块 1  | GAP3D + FC (256) +ReLU+Dropout (0.6)                                                                                              |
| 全连接模块 2  | FC (128) +ReLU+Dropout (0.5)                                                                                                      |
| 全连接层     | FC(4)                                                                                                                             |
| 输出层      | Softmax + ClassificationLayer                                                                                                     |

3 模型训练结果与分析

3.1 Cable-AD3D-CNN 模型训练参数


采用 MATLAB 中的深度学习工具箱训练 Cable-AD3D-CNN 模型,选用 Adam 优化器,设置初始学习率为 0.000 1,采用学习率分段衰减策略,即学习率每 15 轮衰减 10%。设定训练批次大小为 16,最大训练轮数为 60 轮,每轮训练完成后在测试集上评估一次,为防止过拟合,采用早停策略,若连续 8 次评估中损失下降小于 0.001 则终止训练。

3.2 Cable-AD3D-CNN 模型训练结果

Cable-AD3D-CNN 模型训练过程中训练集和测试集损失及准确率散点图如图 9 所示,在第 42 轮迭代完成后模型达到早停要求自动停止训练。

由图 9 可知,模型在训练初期损失快速下降,准确率迅速提升,表明模型能够学习到漏磁信号中与断丝数量相关的特征;随着训练轮数增加,训练集与验证集曲线趋于平稳,最终在第 42 轮时模型达到早停要求训练结束,此时测试集准确率达到 96.94%,损失降至 0.138 3。

选用 t-分布随机近邻嵌入 (t-distributed stochastic neighbor embedding, t-SNE) 法,进一步将模型的分类效果可视化,将 Cable-AD3D-CNN 模型提取到的高维特征降维后映射到二维平面并进行可视化。输入层及输出层测试集样本的 t-SNE 分别如图 10(a)和(b)所示,分析可知,输入层测试集样本在特征空间中杂乱无章,无法直接分类;经所提 Cable-AD3D-CNN 模型提取特征后,不同断丝数量的测试集样本呈现出明显的边界,仅存在极少数误分类样本,进一步证明所提模型具有较强的非线性特征提取能力,能够对输入样本中的断丝数量进行定量识别。








图 10 测试集样本 t-SNE 可视化结果

Fig. 10 t-SNE visualization results of test set samples

图 11 为基于所搭建 Cable-AD3D-CNN 模型的方法与 RF、MLP、AdaBoostM2 等传统机器学习方法在不同断丝数量下定量识别的准确率。





图 11 不同方法准确率对比

Fig. 11 Comparison of accuracy among different methods


分析图 11 可知,所有方法识别准确率均在 85% 以上;基于所搭建 Cable-AD3D-CNN 模型的方法在不同断丝数量下定量识别准确率均为最高,3 根断丝识别准确率可达 100%,且准确率随断丝数量变化时波动较小,稳定性强;传统机器学习方法中,RF 识别准确率最高,但存在一定的波动;MLP 与 AdaBoostM2 识别准确率较低,尤其是在断丝数量较少时准确率更低,不利于工程应用中缆索断丝的早期识别;因此基于 Cable-AD3D-CNN 模型的方法在准确率与稳定性方面更具优势,可为工程中缆索更换提供参考。

3.3 消融实验

为探究空洞卷积对 Cable-AD3D-CNN 模型断丝定量识别性能的影响,设计消融实验,在同一数据划分与相同训练参数下对 baseline 3D-CNN 模型和 Cable-AD3D-CNN 模型进行训练与测试,混淆矩阵见图 12。



(a) baseline 3D-CNN模型混淆矩阵  
(a) Confusion matrix of the baseline 3D-CNN model



(b) Cable-AD3D-CNN模型混淆矩阵  
(b) Confusion matrix of the Cable-AD3D-CNN model

图 12 baseline 3D-CNN 模型与 Cable-AD3D-CNN 模型混淆矩阵

Fig. 12 Confusion matrices of the baseline 3D-CNN model and the Cable-AD3D-CNN model

因 2、3、4、5 根断丝样本数量分布不均衡,故计算各类别精确率 (Precision)、召回率 (Recall) 后,再计算等权算术平均得到宏平均精确率 (macro-precision) 与宏平均召回率 (macro-recall),评价指标详见表 3。

表 3 baseline 3D-CNN 模型与 Cable-AD3D-CNN 模型性能对比

| Table 3 Performance comparison between the baseline 3D-CNN model and the Cable-AD3D-CNN model |          |                 |              |
|-----------------------------------------------------------------------------------------------|----------|-----------------|--------------|
| (%)                                                                                           |          |                 |              |
| 模型类型                                                                                          | Accuracy | macro-precision | macro-recall |
| baseline 3D-CNN                                                                               | 83.33    | 85.02           | 86.11        |
| Cable-AD3D-CNN                                                                                | 96.94    | 98.64           | 96.86        |

其中 Accuracy 为准确率,由混淆矩阵可知,baseline 3D-CNN 模型在 2 根断丝与 3 根断丝类别间误判较多,表明其对相邻断丝数量样本的区分能力有限;而所搭建 Cable-AD3D-CNN 模型对输入样本断丝定量识别结果集中在混淆矩阵主对角线上,非对角线元素较少,表明所提模型有效减少类别混淆,提高不同断丝数量样本的可分性。由表 3 可知,所搭建模型 Accuracy 为 96.94%,相较

于基于 baseline 3D-CNN 模型的识别方法,显著提高 13.61%,而 macro-precision、macro-recall 分别提高 13.62%、10.75%,有效提升模型对输入数据中断丝定量识别的精度。

所搭建 Cable-AD3D-CNN 模型误判、漏检的减少及各项指标显著提升是由于空洞卷积在不增加卷积核的数量下扩大感受野,使网络能够融合更大范围内的波形特征;同时,所提各向异性空洞卷积核设计策略增强了模型对轴向漏磁信号进行特征提取的同时保证周向及径向分辨率,避免传统卷积核在盲目扩大轴向感受野时牺牲周向和径向分辨率的弊端,为高精度识别奠定基础。

## 4 结 论

为解决桥梁缆索漏磁检测中断丝定量的难题,搭建 Cable-AD3D-CNN 模型并据此提出桥梁缆索断丝定量方法。最终实验结果表明,所提方法能够以较高的准确率实现桥梁缆索断丝定量。本文主要结论为:

1) 依托漏磁检测平台获取含不同断丝数量的桥梁缆索漏磁信号,经预处理后构建数据集。针对漏磁信号沿缆索轴向、周向和径向的分布差异,在 3D-CNN 中引入空洞卷积与各向异性卷积,构建 Cable-AD3D-CNN 模型,有效增强对漏磁信号空间特征的提取能力,在此基础上提出桥梁缆索断丝数量识别方法。利用含断丝桥梁缆索的漏磁信号对所提方法进行验证,结果表明,所提方法收敛性较好,对断丝数量识别的准确率可达 96.94%。

2) 与 RF、MLP、AdaBoostM2 等传统机器学习模型相比,所搭建 Cable-AD3D-CNN 模型具有端到端的架构,无需人工提取特征量,即可直接从漏磁信号中挖掘非线性特征,且在断丝定量识别任务中表现出更高的检测精度与稳定性;

3) 消融实验结果表明,所搭建 Cable-AD3D-CNN 模型性能显著优于 baseline 3D-CNN 模型,Accuracy、macro-precision、macro-recall 分别提升至 96.94%、98.64%、96.86%;这一性能提升是因为各向异性空洞卷积核设计策略增大感受野,提升模型对波形的捕捉能力。

## 参考文献

[1] 张婷婷,谢旭,潘晓宇. 考虑断丝影响的平行钢丝索拉伸力学特性[J]. 浙江大学学报(工学版), 2016, 50(5):841-847.  
ZHANG T T, XIE X, PAN X Y. Tensile mechanical behavior of parallel wire cables with wire breaks[J].

Journal of Zhejiang University (Engineering Science), 2016,50(5):841-847.

- [2] 王春生,李熙,吴一凡. 服役斜拉索钢丝剩余疲劳强度与剩余寿命试验研究[J]. 工程力学, 2026, 43(1): 207-218.  
WANG CH SH, LI X, WU Y F. Experimental study on remaining fatigue strength and remaining fatigue life of existing stay cable wires[J]. Engineering Mechanics, 2026,43(1):207-218.
- [3] 邓小龙,黄志海,郭波. 改进分割大模型的桥梁缆索损伤语义分割方法[J]. 测绘通报, 2025(9): 112-117.  
DENG X L, HUANG ZH H, GUO B. An improved semantic segmentation method for bridge cable damage using large-scale segmentation models[J]. Bulletin of Surveying and Mapping, 2025(9):112-117.
- [4] LI X K, GUO Y C, LI Y M. Particle swarm optimization-based SVM for classification of cable surface defects of the cable-stayed bridges[J]. IEEE Access, 2020,8:44485-44492.
- [5] ZHANG J W, ZHENG P B, TAN X J. Recognition of broken wire rope based on remanence using EEMD and wavelet methods[J]. Sensors, 2018,18(4):1110.
- [6] 曹辉,杨理践,刘俊甫,等. 基于数据融合的小波变换漏磁异常边缘检测[J]. 仪器仪表学报, 2019, 40(12):71-79.  
CAO H, YANG L J, LIU J F, et al. Magnetic flux leakage anomaly edge detection based on data fusion and wavelet transformation[J]. Chinese Journal of Scientific Instrument, 2019,40(12):71-79.
- [7] ZHENG P B, ZHANG J W. Application of variational mode decomposition and k-nearest neighbor algorithm in the quantitative nondestructive testing of wire ropes[J]. Shock and Vibration, 2019, 2019(2): 9828536.
- [8] 赵翰学,张咪,郭岩宝,等. 基于机器学习的管道金属损失缺陷识别方法[J]. 石油机械, 2020, 48(12):138-145.  
ZHAO H X, ZHANG M, GUO Y B, et al. Recognition method of pipeline metal loss defects based on machine learning [J]. China Petroleum Machinery, 2020, 48(12):138-145.
- [9] ZHANG J W, PENG F CH, CHEN J B. Quantitative detection of wire rope based on three-dimensional magnetic flux leakage color imaging technology[J]. IEEE

- Access, 2020, 8: 104165-104174.
- [10] LIU SH W, CHEN M CH. Wire rope defect recognition method based on MFL signal analysis and 1D-CNNs[J]. Sensors, 2023, 23(7): 3366.
- [11] 任建浩, 陈实, 薛家杰, 等. 基于 1D-CNN-SVM 的钢丝绳损伤识别方法[J]. 无损检测, 2024, 46(6): 24-29.  
REN J H, CHEN SH, XUE J J, et al. Wire rope damage identification method based on 1D-CNN-SVM [J]. Nondestructive Testing, 2024, 46(6): 24-29.
- [12] JIANG L, ZHANG H G, LIU J H, et al. THMS-Net: A two-stage heterogeneous signals mutual supervision network for MFL weak defect detection [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 3198762.
- [13] YANG L J, WANG ZH J, GAO S W. Pipeline magnetic flux leakage image detection algorithm based on multiscale SSD network [J]. IEEE Transactions on Industrial Informatics, 2020, 16(1): 501-509.
- [14] 李春晖, 吕岩, 孟祥来, 等. 基于 YOLOv8 的油气管道漏磁检测缺陷智能识别技术研究[J]. 仪器仪表学报, 2025, 46(2): 247-254.  
LI CH H, LYU Y, MENG X L, et al. Research on intelligent defect recognition in oil and gas pipeline magnetic flux leakage detection based on YOLOv8[J]. Chinese Journal of Scientific Instrument, 2025, 46(2): 247-254.
- [15] 贾康康, 都军民, 陈飞宇, 等. 基于卷积神经网络注意力机制模块的复合材料损伤自动识别研究[J]. 机械工程学报, 2026, 62(6): 247-256.  
JIA K K, DU J M, CHEN F Y, et al. AM-1DCNN based automatic recognition of mechanical damage in composite material[J]. Journal of Mechanical Engineering, 2026, 62(6): 247-256.
- [16] 吕轶, 祝志荣, 赵天宇. 基于跨传感器特征融合的滚动轴承故障诊断[J]. 电子测量与仪器学报, 2026, 40(3): 114-123.  
LYU Y, ZHU ZH R, ZHAO T Y. Fault diagnosis of rolling bearings based on cross-sensor feature fusion[J]. Journal of Electronic Measurement and Instrumentation, 2026, 40(3): 114-123.
- [17] 应万明, 李伦勇, 李永波, 等. 面向航空发动机故障诊断的时频可解释卷积神经网络[J/OL]. 机械工程学报, 1-14[2026-01-18].  
YING W M, LI L Y, LI Y B, et al. Time-frequency interpretable convolutional neural network for aero-engines fault diagnosis [J/OL]. Journal of Mechanical Engineering, 1-14[2026-01-18].
- [18] 冯李航, 陈铭, 章伟. 基于增强卷积神经网络的电子鼻长期漂移抑制方法[J]. 仪器仪表学报, 2021, 42(2): 207-217.  
FENG L H, CHEN M, ZHANG W. Long-term drift suppression method for electronic nose based on the augmented convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2021, 42(2): 207-217.
- [19] YANG CH, YAN J W, FENG Y X, et al. Hybrid deep learning for hydraulic cylinder fault diagnosis under complex conditions via multi-source signal fusion[J]. Instrumentation, 2026, 13(1): 40-56.
- [20] 辛荣亚, 张启伟. 基于漏磁检测的桥梁拉索断丝识别[J]. 同济大学学报(自然科学版), 2019, 47(4): 458-466.  
XIN R Y, ZHANG Q W. Broken wire identification of bridge stay cables based on magnetic flux leakage inspection [J]. Journal of Tongji University (Natural Science), 2019, 47(4): 458-466.
- [21] 张艺潇, 季子扬, 高智超, 等. 斜拉桥索的全截面漏磁检测[J]. 无损检测, 2025, 47(4): 1-7.  
ZHANG Y X, JI Z Y, GAO ZH CH, et al. Full-section magnetic flux leakage detection of cable-stayed bridge cables[J]. Nondestructive Testing, 2025, 47(4): 1-7.
- [22] 中华人民共和国住房和城乡建设部. 城市桥梁养护技术标准: CJJ 99—2017[S]. 北京: 中国建筑工业出版社, 2017.  
Ministry of Housing and Urban-Rural Development of The People's Republic of China. Technical standard for maintenance of urban bridges: CJJ 99—2017 [S]. Beijing: China Architecture & Building Press, 2017.
- [23] SUN L S, WANG J J, TAO ZH W, et al. A sensor based on multilayer-arranged Hall elements for MFL detection of broken wires in bridge cables [J]. Sensors and Actuators A: Physical, 2025, 391: 116668.

## 作者简介



王润雨, 2024 年于武汉理工大学获得学士学位, 现为华中科技大学硕士研究生, 主要研究方向为桥梁缆索漏磁信号处理。

E-mail: runyuwang@hust.edu.cn

**Wang Runyu** received her B.Sc. degree from Wuhan University of Technology in 2024.



She is currently pursuing her M. Sc. degree at Huazhong University of Science and Technology. Her main research interest includes magnetic flux leakage signal processing for bridge cables.



**孙令司**, 2018 年于吉林大学获得学士学位, 2021 年于哈尔滨工程大学获得硕士学位, 现为华中科技大学博士研究生, 主要研究方向为漏磁检测和信号处理。

E-mail: sunlingsi@ hust. edu. cn

**Sun Lingsi** received his B. Sc. degree from Jilin University in 2018, his M. Sc. degree from Harbin Engineering University in 2021. He is currently pursuing his Ph. D. degree at Huazhong University of Science and Technology. His main research interests include magnetic flux leakage and signal processing.



**刘焕泽**, 2024 年于山东大学获得学士学位, 现为华中科技大学硕士研究生, 主要研究方向为桥梁缆索漏磁信号处理。

E-mail: huanze@ hust. edu. cn

**Liu Huanze** received his B. Sc. degree from Shandong University in 2024. He is currently pursuing his M. Sc. degree at Huazhong University of Science and Technology. His main research interest includes magnetic flux leakage signal processing for bridge cables.



**蒋立军**, 2015 年于沈阳理工大学获得学士学位, 现为柳州欧维姆机械股份有限公司高级工程师, 主要研究方向为预应力钢绞线及索密封、振动控制、无损检测及健康监测。

E-mail: jianglj@ ovm. cn

**Jiang Lijun** received his B. Sc. degree from Shenyang Ligong University in 2015. He is currently a senior engineer in Liuzhou OVM Machinery Co., Ltd. His main research interests include prestressed steel strands and cable sealing, vibration control, nondestructive testing and structural health monitoring.



**武新军** (通信作者), 1993 年于焦作矿业学院获得学士学位, 1996 年于华中理工大学获得硕士学位, 1999 年于华中理工大学获得博士学位, 现为华中科技大学教授、博士生导师, 主要研究方向为工程测试与信号处理、无损检测新技术等。

E-mail: xinjunwu@ hust. edu. cn

**Wu Xinjun** (Corresponding author) received his B. Sc. degree from Jiaozuo Mining Institute in 1993, and his M. Sc. and Ph. D. degrees both from Huazhong University of Science and Technology in 1996 and 1999, respectively. He is currently a professor and Ph. D. advisor at Huazhong University of Science and Technology. His main research interests include engineering testing and signal processing, nondestructive testing.