

文章编号: 1006-3080(2025)06-0843-07

DOI: 10.14135/j.cnki.1006-3080.20250214001

## 基于多尺度 WideResNet 的铁轨缺陷小样本检测算法

李耀<sup>1</sup>, 李梅<sup>2</sup>

(1. 华东理工大学材料科学与工程学院, 上海 200237; 2. 苏州科技大学土木工程学院, 江苏苏州 215011)

**摘要:**铁轨缺陷检测对铁路安全和降低维护成本非常重要。面对铁路网络扩张和缺陷样本稀少的挑战, 尤其是小样本条件下的过拟合问题, 本文提出了一种基于多尺度 WideResNet (Wide Residual Network) 的小样本铁轨表面缺陷检测算法, 通过数据增强等图像处理技术扩大有限的训练集, 提高模型的泛化能力; 利用迁移学习策略, 通过预训练的 WideResNet 模型提取多尺度特征, 并将其用于铁轨缺陷检测任务, 减少对大量标注数据的依赖, 加快小样本模型训练快速收敛; 设计小样本深度学习模型策略, 构建度量学习模块, 从有限的标注数据中快速学习并进行有效泛化。结果表明, 该算法在 10-shot 小样本条件下能够有效地检测铁轨表面缺陷, 模型平均精度达到 83.6%, 召回率高达 93.8%。

**关键词:**铁轨缺陷检测; 小样本学习; 深度学习; 图像处理; 机器视觉

**中图分类号:** TP391.41

**文献标志码:** A

传统铁轨缺陷检测依赖人工检查和物理检测, 存在效率低、成本高、覆盖不全和监测非实时的问题。随着技术的发展, 自动化检测技术如超声波检测、红外热成像和激光扫描等被引入, 提高了检测的效率和准确性<sup>[1]</sup>。近年来, 机器视觉技术在铁轨缺陷检测中的应用日益广泛, 通过图像处理和模式识别技术, 实现了对铁轨表面缺陷的自动识别, 能检测裂纹和磨损等损伤<sup>[2]</sup>, 但这些方法仍存在高成本、环境影响大和鲁棒性不足等问题。

深度学习技术, 尤其是卷积神经网络 (Convolutional Neural Network, CNN), 在图像识别和缺陷检测领域取得了显著的进展<sup>[3-5]</sup>。在工业检测中, 深度学习模型被用于自动识别产品表面的缺陷, 如裂纹、凹陷和腐蚀等<sup>[6-7]</sup>。江琴等<sup>[8]</sup>开发出针对小目标的 YOLOv4 变体, 有效提高了白车身焊点检测的精度。向宽等<sup>[9]</sup>提出改进的 Faster RCNN (Faster Region-based Convolutional Neural Network) 深度学习网络, 通过数据增强、FPN (Feature Pyramid Network) 结构等优化,

提升了对铝材小缺陷的检测能力。陈雪纯等<sup>[10]</sup>提出基于迁移学习的改进 MobilenetV2 轻量化网络, 实现了快速且准确的包装缺陷检测。尽管这些模型提高了检测的准确性和速度, 并具有良好的泛化能力, 但它们通常需要大量标注数据进行训练, 这在数据稀缺的场景下可能难以实现。

在铁轨缺陷检测等实际应用中, 收集到的缺陷样本往往有限。小样本学习对于数据稀缺场景如铁轨缺陷检测至关重要<sup>[11-12]</sup>。该领域研究包括数据增强技术、迁移学习策略和元学习等, 旨在通过生成新样本、利用预训练模型和快速适应新任务来构建高效检测模型<sup>[13]</sup>。宋涛等<sup>[14]</sup>引入元学习方案并设计基于元特征增强的检测算法, 提升小样本条件下 PCB (Printed Circuit Board) 缺陷检测的性能。刘金海等<sup>[15]</sup>利用轻量级网络, 挖掘价值样本, 用更少样本提高了管道焊缝缺陷检测精度。黄健等<sup>[16]</sup>采用小样本度量迁移学习, 通过预训练和知识迁移解决深度学习对大量样本的需求。小样本学习方法在提升模型

收稿日期: 2025-02-14

基金项目: 江苏省高等学校自然科学研究项目(24KJB560021)

作者简介: 李耀(1991—), 男, 湖北随州人, 硕士生, 主要研究方向为计算机视觉、缺陷检测及多模态。E-mail: liyaoecust@sina.com

通信联系人: 李梅, E-mail: 784271219@qq.com

引用本文: 李耀, 李梅. 基于多尺度 WideResNet 的铁轨缺陷小样本检测算法[J]. 华东理工大学学报(自然科学版), 2025, 51(6): 843-849.

Citation: LI Yao, LI Mei. A Few-Shot Rail Defect Detection Algorithm Based on Multi-Scale WideResNet Model[J]. Journal of East China University of Science and Technology, 2025, 51(6): 843-849.

性能和适应性上已取得进展,但仍需解决泛化能力、过拟合及数据高效利用等挑战。在铁轨缺陷检测中,小样本学习技术的应用可以显著降低对大量标注数据的依赖,提高检测系统的实用性和经济性。

本文提出了一种基于多尺度 WideResNet (Wide Residual Network) 小样本深度学习模型,用于铁轨表面缺陷检测,以克服现有方法的局限并应对实际挑战。该算法采用 Crop-Paste 实例分割数据增强技术,扩大有限的训练集,利用迁移学习策略提高模型的泛化能力,并通过预训练深度网络 WideResNet,提取多尺度特征,构建度量学习模块,挖掘潜在类别,将知识从大型数据集迁移到铁轨缺陷检测领域,探索适合小样本条件下的深度学习模型结构和训练策略,以实现铁轨表面缺陷识别的高准确率和鲁棒性。

## 1 铁轨缺陷识别算法

### 1.1 迁移学习策略

在小样本条件下,模型训练面临着诸多挑战,例如过拟合风险增加、特征学习不充分等,为有效应对这些问题,采用了迁移学习策略来提升模型性能。选用在大规模图像数据集 ImageNet 预训练的深度学习模型 WideResNet 作为基础,该模型已通过大规模数据集学习到了丰富的特征表示,能够为迁移任务提供有力的特征基础<sup>[17-18]</sup>。ResNet(Residual Network)通过引入残差结构有效缓解了深度神经网络中出现的梯度消失或梯度爆炸等问题,使得网络能够在保持较深层数的同时依旧有良好的训练效果。Wide ResNet 在 ResNet 的基础上引入了加宽因子  $k$ ,将每一层的通道数乘以该因子,增加网络宽度,通过增加网络残差块的宽度来提升模型性能,每种残差块对输入特征进行 2 倍下采样,从而在不同层次提取出不同尺度的特征下。本文中  $k$  设为 2。在相同参数量下, WideResNet 的训练速度更快,且在较少的训练时间内能够取得更高的准确率,两者残差块结构如图 1 所示,图中  $x$  为输入特征,  $C$  为通道数量,  $F(x)$  表示残差函数。

本文采用 3 种残差块输出的特征图,经过上采样后进行叠加,提取了多尺度特征,具体的多尺度特征提取过程如图 2 所示。在特征提取阶段,首先计算各特征图的特征表示,具体公式如下:

$$F_1 = \text{WideResBlock}_1(x), x \in \mathbb{R}^{\frac{H}{4} \times \frac{W}{4} \times C_1} \quad (1)$$

$$F_2 = \text{WideResBlock}_2(F_1), F_2 \in \mathbb{R}^{\frac{H}{8} \times \frac{W}{8} \times C_2} \quad (2)$$

$$F_3 = \text{WideResBlock}_3(F_2), F_3 \in \mathbb{R}^{\frac{H}{16} \times \frac{W}{16} \times C_3} \quad (3)$$

其中,  $\mathbb{R}$  代表实数空间,  $H$ 、 $W$  分别表示输入图像的高度和宽度,  $F_i$  表示第  $i$  个残差块提取的特征,  $\text{WideResBlock}_i$  表示第  $i$  个残差块的特征提取操作。随后,通过双线性差值上采样将  $F_2$  和  $F_3$  对齐至  $F_1$  尺寸,并沿通道维度拼接,得到多尺度特征  $F_{\text{out}}$ :

$$\begin{aligned} F_{\text{out}} &= \text{Concat}(F_1, \text{Upsample}(F_2, \text{scale} = 2), \\ &\quad \text{Upsample}(F_3, \text{scale} = 4)) \\ F_{\text{out}} &\in \mathbb{R}^{\frac{H}{4} \times \frac{W}{4} \times (C_1 + C_2 + C_3)} \end{aligned} \quad (4)$$

其中, UpSample 表示双线性差值上采样操作, Concat 表示沿通道维度的拼接操作。

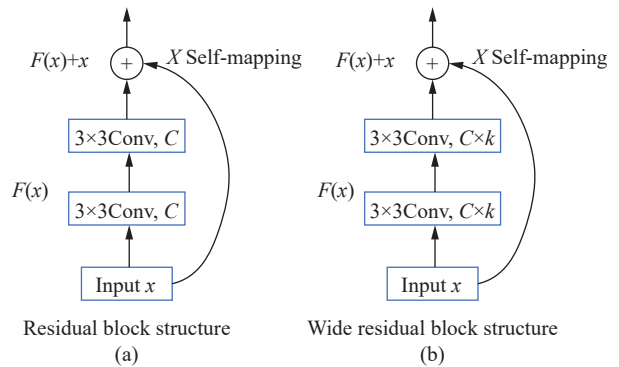


图 1 ResNet (a) 和 WideResNet (b) 残差块结构

Fig. 1 Residual block structure in ResNet (a) and WideResNet (b)

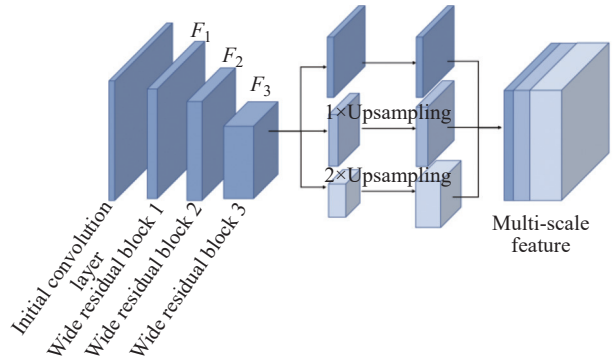


图 2 WideResNet 多尺度特征提取方式

Fig. 2 Multi-scale feature extraction method of WideResNet

将这些预训练的特征迁移到铁轨缺陷检测任务中,不仅可以有效减少对标注数据的依赖,还能以这些特征作为起点进一步训练模型,能够使模型在小样本条件下更好地学习到与任务相关的特征。在迁移学习过程中,通过冻结预训练模型的部分层,只对顶层进行微调,以满足小样本任务的需求。这种策略不仅提高了训练效率,也帮助在数据稀缺的情况下获得更好的性能,从而为铁轨缺陷小样本检测任务提供了有力的支持。

### 1.2 数据增强技术

在铁轨缺陷检测任务中,由于缺陷样本的稀缺性,数据增强技术成为提升模型泛化能力和鲁棒性

的关键手段。为丰富数据集的多样性, 本文通过多种数据增强技术, 有效模拟了不同的拍摄角度、光照条件和缺陷形态。例如, 通过随机旋转和缩放操作, 模拟铁轨在不同视角下的图像, 增强模型对不同视角缺陷的识别能力; 通过颜色变换, 模拟不同光照条件下的图像, 提高模型在不同光照环境下的适应性; 通过裁剪和翻转操作, 生成更多具有不同缺陷位置和形态的样本。

同时, 为了利用轨道检测场景中大量的正常背景图像, 增强小样本数据集并提升模型对缺陷识别的泛化能力, 本文采用改进的 Crop-Paste 实例分割数据增强技术, 具体操作如下: 首先, 根据标注掩膜, 将缺陷实例从原图中剪切出来, 对缺陷实例进行轻微的缩放和旋转, 丰富缺陷的尺度和形态变化; 然后, 将这些实例黏贴到随机选择的正常背景图像上, 并对黏贴区域的轮廓进行泊松融合, 以确保轮廓附近语义信息一致, 增强后的图像  $X_{new}$  由以下公式得到:

$$X_{new} = B \odot (1 - M) + T(D) \odot M \quad (5)$$

其中,  $D$  为从原图提取的缺陷实例;  $T$  表示对缺陷实例进行缩放和旋转等增强操作;  $M \in \{0, 1\}^{W \times H}$  为二值掩膜; 1 表示提取的缺陷实例要黏贴的位置;  $\odot$  表示逐像素乘法;  $B \in \mathbb{R}^{H \times W \times C}$ , 表示随机选择的正常背景图像。

轨道数据增强流程如图 3 所示。这些增强技术不仅提升了模型识别不同类型缺陷的能力, 还增强了其在新场景中的适应性。

### 1.3 小样本深度学习模型构建

针对铁轨缺陷检测任务, 为从有限的标注数据中快速学习并有效泛化, 本文构建了一个小样本深度学习模型, 其框架图如图 4 所示。该模型的核心在于构建度量学习模块, 通过学习特征空间中的相似性度量, 实现对查询图像中缺陷的高效识别。模型的工作流程包括支持集和查询集的处理。支持集图像是带有缺陷标注的少量样本, 用于训练模型识别不同类型的缺陷, 并通过掩膜操作来提取缺陷区域。查询集图像则是待检测的图像, 模型需要识别图像中是否存在缺陷及其位置。采用 WideResNet 作为基础网络, 提取支持集图像和查询图像的多尺度特征。WideResNet 通过增加网络宽度而非深度, 从而高效提取丰富的特征表示, 同时避免过深网络带来的训练难题。

多尺度特征提取模块通过融合不同层次的特征, 进一步增强了模型对缺陷特征的感知能力。度量学习模块是模型的核心部分, 用于计算查询图像

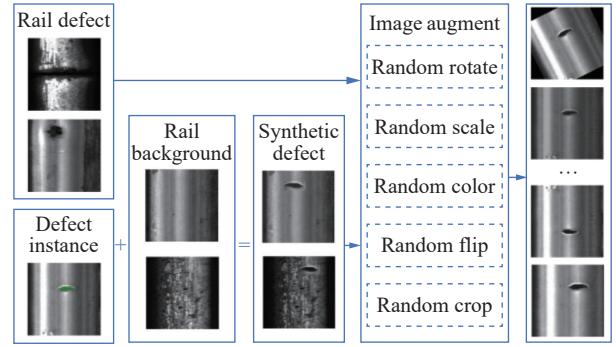


图 3 轨道数据增强流程

Fig. 3 Railway data augmentation process

特征与支持集缺陷特征之间的相似性。通过学习特征空间中的距离度量, 该模型能够有效地匹配查询图像中的特征与支持集中的缺陷特征, 根据特征匹配结果输出预测结果, 包括缺陷的位置和类型。通过度量学习模块的高效匹配机制, 该模型能够在查询图像中快速定位缺陷区域, 并提供准确的缺陷类型预测。这种基于度量学习的策略不仅提高了模型的检测效率, 还增强了模型在小样本条件下的鲁棒性。




图 4 小样本深度学习模型框架图

Fig. 4 Few-shot deep learning model framework diagram

在模型训练过程中, 为了优化小样本学习任务, 采用交叉熵损失函数 ( $L_{ce}$ ), 同时联合 Dice 损失函数 ( $L_{dice}$ ) 来优化模型的分割性能。交叉熵损失函数用于衡量模型预测的类别分布与真实标签之间的差异, 而 Dice 损失函数则专注于优化分割任务中的像素级精度, 在处理不平衡数据时表现出色。通过联合优化这两种损失函数, 模型能够在有限的标注数据下实现更好的学习效果 and 泛化能力, 如下式所示:

$$L_{ce} = - \sum_{i=1}^c y_i \lg(p_i) \quad (6)$$

其中,  $c$  是类别的总数,  $y_i$  是真实标签,  $p_i$  是模型预测样本属于第  $i$  类的概率, 交叉熵损失函数促使模型预测的概率分布与真实标签的概率分布尽可能接近。

$$L_{dice} = 1 - \frac{2 \times |A \cap B|}{|A| + |B|} \quad (7)$$

其中,  $|A \cap B|$  表示预测掩码和真实掩码的交集的像素

数,  $|A|$ 和 $|B|$ 分别表示预测掩码和真实掩码的像素数。

为了平衡不同损失函数的影响,提升训练的稳定性和效果,定义一个加权和损失函数  $L$ 。

$$L = L_{ce} + \lambda L_{dice} \quad (8)$$

其中,  $\lambda$  是一个超参数, 设为 0.5, 用于平衡两种损失函数的权重。

## 2 实验设计和结果分析

### 2.1 数据集与模型训练

为提高小目标检测的准确性并增强数据多样性,对原始图像进行了滑动窗口切片处理,从而构建了一个更丰富的缺陷图像数据集。具体方法如图 5 所示,以 144 像素的步长和 160 像素的长度,在原始钢轨表面图像上进行滑动切片,共获得 508 张包含缺陷和背景的图像。通过数据增强技术,数据集进一步扩展至 845 张图像。所有图像均进行了缩放处理,使其像素尺寸统一为  $256 \times 256$ 。数据集按照 8 : 2 的比例划分为训练集和测试集,用于模型的训练和评估,其中小样本  $n$ -shot 为训练集中随机抽取  $n$  张样本数据。

硬件环境: 配备 Intel Core i7 处理器和 NVIDIA GeForce RTX 4080 显卡的工作站,以及用于数据存储和处理的高速 SSD。软件方面,采用 Python 编程语言,深度学习框架选用 Pytorch,图像处理库使用 OpenCV。实验中使用的数据集为钢轨表面图像数据集 RSDDs 中的 Type-I,包含 67 张分辨率为  $160 \times 1000$  的原始图像,每张图像包含正常区域及不同尺寸的缺陷(如凹坑、磨损、腐蚀等),并附有语义标注掩膜<sup>[9]</sup>。




图 5 钢轨滑动窗口数据集构建示意图

Fig. 5 Diagram of steel rail sliding window dataset

模型训练过程中,图像输入像素尺寸为  $256 \times 256$ ,单 GPU 训练批次大小为 16。优化器为随机梯度下降(SGD),初始学习率为 0.01,最大迭代次数为 50。

### 2.2 性能评估指标

在评估轨道缺陷检测模型的定位精度和分割精度时,采用以下关键指标:召回率(Recall,  $R$ )、精度(Precision,  $P$ )、平均精度(Average Precision, AP),其计算公式分别为:

$$R = \frac{TP}{TP + FN} \quad (9)$$

$$P = \frac{TP}{TP + FP} \quad (10)$$

$$AP = \frac{1}{c} \sum_{i=1}^c AP_i \quad (11)$$

其中,真正例 TP 是模型正确预测为正类的样本数,假负例 FN 是模型错误预测为负类的正类样本数,假正例 FP 是模型错误预测为正类的负类样本数。 $R$  用来衡量模型成功识别的缺陷样本占有所有实际缺陷样本的比例, $R$  越高,说明模型漏掉的正类样本越少。 $P$  用来衡量模型预测正确的样本占总预测正样本的比例,反映了模型预测正类样本的准确性,AP 表示单个类别的平均检测精度,是评估检测模型的常用指标。

### 2.3 模型效果

在铁轨缺陷检测任务中,本文提出的模型表现出优异的性能。测试集上,该模型的  $R$  为 93.8%,AP 为 83.6%。本实验设定的迭代步数为 50。图 6 示出了损失和性能变化曲线,从图 6 可知,在迭代步数 0~20 的区间内,损失率呈持续下降态势,精度和召回率快速提升;在迭代步数 0~20 轮期间,尽管曲线存在波动,但总体仍保持下降趋势;迭代步数 40 之后,训练和测试损失率基本趋于稳定,精度和召回率也基本不变。在整个迭代步数区间,虽曲线有所起伏,但损失率总体朝着减小的方向发展并最终趋于平稳。前期损失率变化幅度较大,这表明模型处于学习阶段,正在积极调整参数以适应数据特征,提升精度和召回率。后期曲线趋于平稳,意味着模型逐渐接近收敛状态,逼近最优拟合。此时,如果继续增加训练轮数,不仅难以显著提升模型性能,还可能导致过拟合。从图 6 可见训练后期精度趋于稳定。

综上,本文提出的小样本深度学习模型并未出现欠拟合或过拟合现象。模型成功收敛,并最终实现了 93.8% 的检出召回率,同时模型精度较高,这充分证实了该模型在铁轨缺陷检测任务中泛化和识别性能较好。

### 2.4 小样本性能

表 1 示出了训练集小样本数量对模型平均精度和召回率的影响。从表中可以看出,当样本量为 5-shot(5 个样本)时,模型具有较高的召回率 95.8%,说明模型的检出较高,但是模型的误检相对较多。当样本量从 5-shot 增加到 10-shot 时,模型的平均精度显著提高,从 67.5% 增至 83.6%,而召回率略有下降,从 95.8% 降至 93.8%。这表明在样本量较少的情况

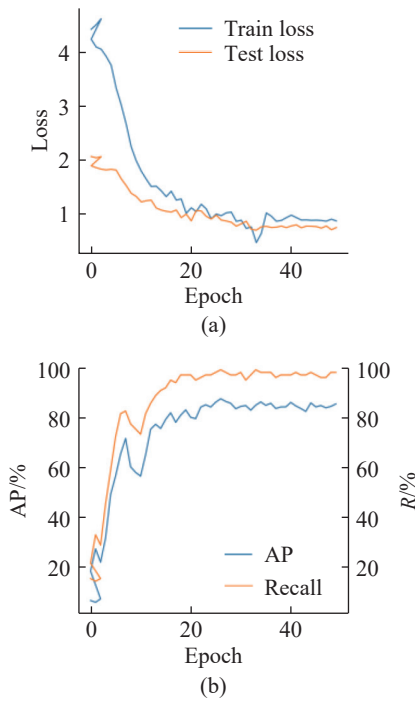


图 6 损失(a)和性能变化(b)曲线

Fig. 6 Loss (a) and performance variation (b) curves

下,增加样本量可以显著提高模型的识别精度。进一步增加样本量至 20-shot 时,识别精度和召回率无提升,说明样本量为 10-shot 时,模型达到较好的性能。实验结果表明,所提出的模型能够有效检测铁轨表面缺陷,并在小样本条件下保持较高的性能表现。

表 1 不同训练集样本数量的模型平均精度和召回率

Table 1 Average precision and recall with different training samples

Sample	AP/%	R/%
5-shot	67.5	95.8
10-shot	83.6	93.8
20-shot	80.5	92.6

### 2.5 消融实验

在 10-shot 训练样本的基础模型上对各个模块进行消融实验,实验结果如表 2 所示。当采用标准残差块(ResBlock)作为基础结构时,模型 AP 与 R 分别为 7.8% 和 33.0%,说明在有限样本条件下,基础模型的性能有限。使用更宽的残差块(WideResBlock)代替传统的残差块,AP 提升至 11.6%,R 提升至 39.2%,这表明增加模型宽度可以提高模型在小样本学习任务中的性能。引入多尺度特征提取模块,模型性能获得显著提升,AP 与 R 分别提升至 47.1% 和 80.4%,说明多尺度特征对于提高小样本模型的识别能力非常重要。进一步应用中数据增强技术,AP 提升至

表 2 不同条件 10-shot 模型平均精度和召回率

Table 2 Average precision and recall of 10-shot model with different conditions

Method	AP/%	R/%
ResBlock	7.8	33.0
WideResBlock	11.6	39.2
Multi-scale feature	47.1	80.4
Data augment	57.6	88.7
Dice loss	83.6	93.8

57.6%, R 提升至 88.7%,这表明数据增强技术在小样本学习任务中的有效性。使用 Dice 损失函数联合交叉熵损失函数,优化模型掩码目标级别的检出性能,AP 达到 83.6%,R 达到 93.8%,说明 Dice 损失函数对于提高模型的精度和召回率非常有效。

综上,各模块通过不同机制协同提升模型性能:网络宽度扩展增强了特征表达能力,多尺度模块优化了空间感知能力,数据增强策略提高了模型泛化性,而联合损失函数特别是 Dice 损失函数的引入,使模型在保持高召回率的同时显著提升了检测精度。

### 2.6 特征分析

从测试集中随机抽取 3 张原始图像,对在 10-shot 训练样本的各模块策略模型特征进行热力图可视化,分析不同模块对模型性能的影响,如图 7 所示。可以看出,ResBlock 模块特征对全局区域进行响应,背景和前景特征区分不明显,对复杂背景识别性能有限。WideResBlock 模块的热力图背景和前景特征有初步区分,能够响应明显缺陷特征。多尺度

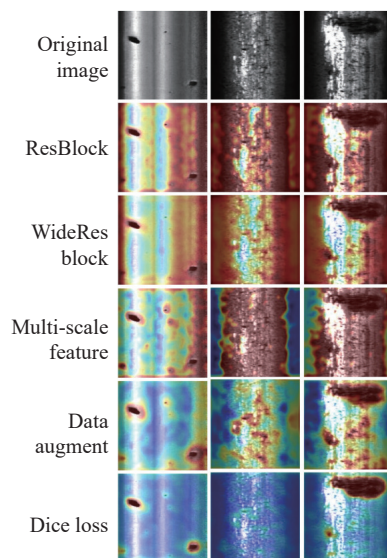


图 7 不同条件下 10-shot 模型特征热力图

Fig. 7 Feature heatmaps of 10-shot model with different conditions

特征提取模块的热力图显示了对不同尺度缺陷的响应,背景和前景特征有一定区分,部分背景识别准确。数据增强后的热力图显示了更为准确的特征响应,背景和前景特征区分程度进一步提高,表明模型学习到有效的特征表示,增强了模型的泛化能力。Dice 损失函数的热力图显示了对缺陷区域的精确定位,热力图的响应更加集中和精确,背景区分明显,反映出模型性能较高。这些结果验证了所提出改进模型中各模块的有效性,并为铁轨缺陷检测提供了有力的技术支持。

## 2.7 结果分析

针对 10-shot 模型预测结果的可视化分析如图 8 所示。对比两组图像,可以发现模型预测的缺陷位置与真实标注(真值)的缺陷位置之间存在较高的一致性。这表明,即使在样本量有限的情况下,模型依然能够在复杂场景有效地学习和识别铁轨缺陷,进一步验证了小样本检测方法在铁轨缺陷检测任务中的有效性和实用。此外,图中还存在一些预测与真值不完全匹配的情况,模型在某些情况下,如复杂缺陷、和背景难区分等场景,存在漏检或误检。未来的工作可以集中在进一步优化模型结构、提高特征提取能力以及增强模型的鲁棒性,以减少这些误差并提高检测的准确性。




图 8 模型预测值和真值对比

Fig. 8 Comparison of model prediction values and true values

## 3 结 论

本文针对铁轨表面缺陷检测任务,提出了一种基于多尺度 WideResNet 的小样本深度学习模型。主要结论如下:

(1) 构建度量学习模块,学习特征空间中的相似性度量,高效识别查询图像中的缺陷,显著提高小样本数据下对缺陷的识别能力;

(2) 模拟不同的拍摄角度、光照条件和缺陷形态,采用改进的 Crop-Paste 实例分割数据增强技术,增强了数据集的多样性,提高模型对各种条件下的检出

性能;

(3) 加宽 ResBlock,提取多尺度特征,构建联合损失函数等策略,使深度学习模型在 10-shot 小样本条件下能达到较高的精度和召回率。

## 参考文献:

- [1] 周志新. 机械裂纹无损检测方法综述 [J]. 机电工程, 2017, 34(10): 1138-1143.
- [2] 闵锐, 黄楚云, 张晓峻, 等. 轨道缺陷图像检测算法的优化 [J]. 物理实验, 2022, 42(2): 9-15.
- [3] SABERIRONAGHI A, REN J, EL-GINDY M. Defect detection methods for industrial products using deep learning techniques: A review[J]. *Algorithms*, 2023, 16(2): 95.
- [4] 邵浙梁, 戚知宽, 周邵萍. 基于改进注意力机制的 CNN 的齿轮箱故障诊断 [J]. 华东理工大学学报(自然科学版), 2024, 50(6): 920-928.
- [5] 孙俊静, 顾幸生. 基于注意力机制多尺度卷积神经网络的轴承故障诊断 [J]. 华东理工大学学报(自然科学版), 2024, 50(2): 247-256.
- [6] 冉蓉, 徐兴华, 邱少华, 等. 基于深度卷积神经网络的裂纹检测方法综述 [J]. 计算机工程与应用, 2021, 57(9): 23-35.
- [7] 方宇伦, 陈雪纯, 杜世昌. 基于轻量化深度学习 VGG16 网络模型的表面缺陷检测方法 [J]. 机械设计与研究, 2023, 39(2): 143-147.
- [8] 江琴, 戴伟, 唐鼎. 基于 YOLOv4 及其变体的白车身焊点外观检测 [J]. 机械设计与研究, 2021, 37(4): 150-153.
- [9] 向宽, 李松松, 栾明慧, 等. 基于改进 Faster RCNN 的铝材表面缺陷检测方法 [J]. 仪器仪表学报, 2021, 42(1): 191-198.
- [10] 陈雪纯, 方宇伦, 杜世昌. 基于深度学习的包装缺陷快速检测方法 [J]. 机械设计与研究, 2021, 37(6): 165-169.
- [11] ANTONELLI S, AVOLA D, CINQUE L, *et al.* Few-shot object detection: A survey[J]. *ACM Computing Surveys*, 2022, 54(11s): 1-37.
- [12] DUAN R, LI D, TONG Q, *et al.* A survey of few-shot learning: An effective method for intrusion detection[J]. *Security and Communication Networks*, 2021, 2021: 4259629.
- [13] KÖHLER M, EISENBACH M, GROSS H M. Few-shot object detection: A comprehensive survey[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 35: 11958-11978.
- [14] 宋涛, 李程, 熊海龙, 等. 基于元特征增强的小样本 PCB 缺陷检测 [J/OL]. 计算机集成制造系统, (2024-05-16) [2025-02-14]. <https://doi.org/10.13196/j.cims.2023.0731>.
- [15] 刘金海, 赵真, 付明芮, 等. 基于主动小样本学习的管道焊缝缺陷检测方法 [J]. 仪器仪表学报, 2022, 43(11): 252-261.

- [16] 黄健, 郑春厚, 章军, 等. 基于小样本度量迁移学习的表面缺陷检测 [J]. 模式识别与人工智能, 2021, 34(5): 407-414.
- [17] DENG J, DONG W, SOCHER R, *et al.* Imagenet: A large-scale hierarchical image database[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition. Miami, FL, USA: IEEE, 2009: 248-255.
- [18] ZAGORUYKO S, KOMODAKIS N. Wide residual networks[EB/OL]. (2016-05-23)[2016-11-28]. <https://doi.org/10.48550/arXiv.1605.07146>.
- [19] GAN J, LI Q, WANG J, *et al.* A hierarchical extractor-based visual rail surface inspection system[J]. *IEEE Sensors Journal*, 2017, 17(23): 7935-7944.

## A Few-Shot Rail Defect Detection Algorithm Based on Multi-Scale WideResNet Model

LI Yao<sup>1</sup>, LI Mei<sup>2</sup>

(1. School of Materials Science and Engineering, East China University of Science and Technology, Shanghai 200237, China; 2. School of Civil Engineering, Suzhou University of Science and Technology, Suzhou 215011, Jiangsu, China)

**Abstract:** Rail defect detection is crucial for railway safety and reducing maintenance costs. Faced with the challenges posed by the expansion of the railway network and the scarcity of defect samples, particularly the issue of overfitting under few-shot conditions, this study proposes a few-shot deep learning algorithm for the detection of rail surface defects based on multi-scale WideResNet (Wide Residual Network), which employs data augmentation techniques to expand the finite training set, thereby improving the model's generalization capability. By leveraging transfer learning strategies, it applies pre-trained deep learning models to rail defect detection tasks with extracting multi-scale features, reducing reliance on large annotated datasets. The study designs few-shot deep learning model strategies and constructs a metric learning module that enable rapid learning from limited annotated data and effective generalization. Experimental results demonstrate that the algorithm can effectively detect rail surface defects under 10-shot conditions, achieving a model average precision of 83.6% and a recall rate as high as 93.8%. This research provides a new technology for the automated detection of rail surface defects, which is of great significance for enhancing the safety and economy of railway transportation.

**Key words:** rail defect detection; few-shot learning; deep learning; image processing; machine vision

(责任编辑: 李娟)