

DOI:10.3969/j.issn.1003-5060.2025.09.006

一种钢轨表面缺陷检测网络 PS-Unet

许建军¹, 胡祥涛¹, 张勇乐¹, 李子怡¹, 湛红晖²

(1. 安徽大学 电气工程与自动化学院, 安徽 合肥 230601; 2. 华中科技大学 无锡研究院, 江苏 无锡 214174)

摘要:文章提出一种基于 Unet 网络的缺陷分割模型 PS-Unet, 该模型在 Unet 网络结构基础上, 设计金字塔池化模块(pyramid pooling module, PPM)和尺度感知模块(scale-aware module, SAM), 并将其嵌入深层特征提取层中, 用于提升模型的性能; 针对缺陷和背景像素比例失衡导致的模型精度降低问题, 提出一种改进的损失函数, 使训练过程聚焦在不易识别的缺陷上, 加快模型收敛。实验证明, 该文提出的 PS-Unet 网络显著改善了检测性能, 相较 Unet 检测网络, 平均交并比(mean intersection over union, mIOU)、平均像素精度(mean pixel accuracy, mPA)、精确率 P 在高速轨道缺陷数据集上分别提高 2.06%、4.98%、3.18%, 在普通/重型运输轨道缺陷数据集上分别提高 4.79%、4.35%、6.28%。

关键词:钢轨缺陷; 编解码; 金字塔池化; 尺度感知

中图分类号: TP391.4 **文献标志码:** A **文章编号:** 1003-5060(2025)09-1192-10

PS-Unet: A rail surface defect detection network

XU Jianjun¹, HU Xiangtao¹, ZHANG Yongle¹, LI Ziyi¹, ZHAN Honghui²

(1. School of Electrical Engineering and Automation, Anhui University, Hefei 230601, China; 2. HUST-Wuxi Research Institute, Wuxi 214174, China)

Abstract: A defect segmentation model named PS-Unet based on Unet network is proposed. On the basis of Unet structure, pyramid pooling module (PPM) and scale-aware module (SAM) are developed and embedded in the deep feature extraction layer to improve the performance of the model. In addition, to address the model accuracy degradation caused by the defect-background pixel imbalance, an improved loss function is proposed to make the training process focus on the defects that are not easy to identify, and accelerate the model convergence. The experimental results show that the proposed PS-Unet network significantly improves the detection performance. Compared with Unet network, the mean intersection over union (mIOU), mean pixel accuracy (mPA) and precision (P) increase by 2.06%, 4.98%, and 3.18% respectively on the high-speed rail defect datasets, and by 4.79%, 4.35%, and 6.28% respectively on the ordinary/heavy-duty transport rail defect datasets.

Key words: rail defects; codec; pyramid pooling; scale-aware

0 引言

随着我国铁路行业的不断发展, 铁路的运输效率逐步提升, 钢轨磨损和伤损等问题也日益凸显, 严重影响了铁路列车的正常运行与行车安

全^[1-2]。因此, 钢轨缺陷检测成为保障铁路安全行车的重要环节, 及时发现钢轨缺陷能够保障铁路维修工作顺利开展, 对铁路行业具有十分重要的意义。

传统钢轨缺陷检测主要采用人工检测和接触

收稿日期: 2023-06-30; 修回日期: 2023-11-28

基金项目: 国家自然科学基金资助项目(52175210)

作者简介: 许建军(1996—), 男, 河南信阳人, 安徽大学硕士生;

胡祥涛(1981—), 男, 安徽桐城人, 博士, 安徽大学教授, 博士生导师, 通信作者, E-mail: hust-hoo@ahu.edu.cn.

式测量技术,由于存在效率低、成本高、容易误判漏判等问题,无法满足当前的检测需求^[3]。深度学习的检测方法具有实时性高、成本低、迁移学习效果好、可学习深层次特征等特点,被国内外学者广泛应用于钢轨表面缺陷检测,逐渐成为现阶段钢轨表面缺陷检测的主要算法。文献[4]提出一种基于更快速区域卷积神经网络(faster region convolutional neural network, Faster R-CNN)的检测方法,对 Gabor 滤波去噪和 HSV 特征增强后的钢轨表面裂纹、剥落、磨损 3 种缺陷进行检测,能够同时兼顾检测精度和检测速度;文献[5]提出一种传统图像处理算法与卷积神经网络相结合的方法,对轨道表面缺陷进行图像识别和分类,实验证明该模型具有较好的鲁棒性;文献[6]提出一种端到端的轨道表面缺陷检测方法,采用 YOLOv2 对缺陷进行定位和检测,平均准确率可

达 97.11%,平均每帧处理时间为 0.006 4 s;文献[7]采用一维卷积神经网络提取高铁和普通列车轨道的缺陷特征,采用长短期记忆网络提取上下文信息,证明该方法的有效性,并提出迁移学习的可能性。

以上研究结果表明,深度学习在钢轨表面缺陷检测方面具有一定优势,然而没有解决缺陷部分语义分割的问题,繁琐的图像处理和机器视觉方法也加大了检测难度。为了能够更直观地检测出缺陷轮廓,本文提出一种基于改进 Unet 网络的深度学习框架,能够端到端地处理像素级别的分类任务。Unet 网络由文献[8]提出,是一种基于编码-解码结构的语义分割模型,其结构简单且稳定、通用性强、检测效果好,因此在生物医学、工农业、遥感图像分析等领域有着广泛应用^[9-13]。Unet 网络模型如图 1 所示。




图 1 Unet 网络模型

从图 1 可以看出,Unet 网络呈 U 型对称结构,输入特征的尺寸大小为 572×572 ,输出特征的尺寸大小为 388×388 。图 1 左侧是一个编码器,为特征提取部分,其中有 4 个子模块,每个子模块包含 2 个卷积层,在每个子模块之后通过最大池化层实现下采样。图 1 右侧是一个解码器,为上采样部分,同样包含 4 个子模块,图像分辨率通过上采样操作依次上升,并与编码器过程形成结构对称。底部为最深层次的特征模块,层次化的特征表达使网络不仅能够提取到低层次特征,如边缘、轮廓、线条、色块等特征,还能提取到高层次的语义特征^[14]。此外,左右对称的 4 个模块采用拼接的方式进行特征融合,保留更多的通道信息和位置信息。然而在钢轨表面缺陷复杂的背景下,深层次特征提取的尺度过于单一且不能被有

效学习,因此本文在 Unet 网络底部嵌入新的模块对特征进行提取。

1 数据收集和预处理

1.1 RSDDs 数据集

为了验证本文模型的有效性,本文搜集了铁轨表面缺陷数据集(rail surface discrete defects, RSDDs)^[15],如图 2 所示。RSDDs 包括如下 2 种类型子数据集:① I 型 RSDDs 数据集包含 67 张从高速轨道捕获的缺陷样本,其中有 $1\ 000 \times 160$ 、 $1\ 260 \times 160$ 共 2 种分辨率的图像;② II 型 RSDDs 数据集包含 128 张分辨率均为 $1\ 250 \times 55$ 从普通/重型运输轨道捕获的缺陷图像,数据集的每幅图像都含有 1 个或 1 个以上分散的缺陷。从图 2 可以看出,采集的原图样本和含有缺陷信息的标

签样本,该数据集是典型的轨道表面缺陷数据集,存在严重的类不平衡问题,缺陷区域与背景的像

素比例很小,而且背景复杂、噪声较大,这些问题对缺陷检测的准确性提出挑战。




图 2 RSDDs 数据集

1.2 数据扩充

深度学习模型在训练过程中需要大量的样本数据,收集到的样本数量有限,导致样本多样性变低、泛化能力变弱^[16],因此本文采用翻转和剪裁的方式对数据进行扩充。图像翻转如图 3 所示,

首先将缺陷图像进行水平翻转、垂直翻转、水平垂直翻转;然后对数据集中的每张缺陷图片进行顺序剪裁,依次对最终的检测结果进行相应顺序的拼接,每张图片剪裁 10 等份。高速轨道图像和普通/重型运输轨道图像的剪裁效果如图 4 所示。





图 3 图像翻转



(a) 高速轨道缺陷剪裁



(b) 普通/重型运输轨道缺陷剪裁

图 4 高速轨道、普通/重型运输轨道缺陷剪裁效果图

最终获得 7 800 张含有钢轨表面缺陷信息图像的数据集,其中包括 2 680 张高速轨道图像和 5 120 张普通/重型运输轨道图像,训练集与测试集比例为 8 : 2。

最后将处理好的图像数据和标签送入端到端网络进行训练和测试。

2 PS-Unet 网络

钢轨表面缺陷背景复杂、噪点多,为了挖掘到更深层次的信息,本文设计金字塔池化模块(pyramid pooling module, PPM)和尺度感知模块(scale-aware module, SAM) 2 个子模块,嵌入到 Unet 网络底部的深层特征提取层,用于提升模型的整体性能。改进的 Unet 网络命名为 PS-Unet,如图 5 所示。

金字塔池化模块位于 Unet 下采样过程的最后一层,其中包括 4 层自适应最大池化层,每层的

池化大小分别为 $1 \times 1, 2 \times 2, 3 \times 3, 6 \times 6$ 。对池化后的特征图进行 1 次 1×1 卷积,将各层的通道数降低至原来的 1/4;对上一步得到的特征图分别采用双线性插值上采样将特征图恢复至原特征图大小。使用金字塔池化模块可以提取特征图中不同尺度的信息,加强网络获取全局信息的能力^[17]。

尺度感知模块作用于金字塔池化模块之后,通过空间注意力机制获得不同感受野的信息并对多尺度特征进行权重分配,即对 4 个不同尺度的特征进行权重训练,将不同的权重用于不同的感受野信息,然后对自学习特征进行融合。

最后将金字塔池化模块、尺度感知模块的特征与原特征进行拼接融合,由 1×1 卷积将特征通道数 2 048 缩减为原特征通道数 1 024,再经过上采样过程进入到 PS-Unet 网络的解码环节。




图 5 PS-Unet 网络模型

2.1 金字塔池化模块

深度学习网络中,池化操作一般在卷积层之后,也称下采样层,负责为下一个卷积层降低空间维度,主要作用如下^[18]:① 减少冗余信息,降低计算量;② 防止过度拟合;③ 加快模型收敛;④ 选择合适特征进行学习,改善泛化能力。然而

经过池化后的特征尺寸减小将会导致信息丢失,加大模型的训练难度。

为了解决这一问题,本文提出一种金字塔池化模块,增加特征信息维度,弥补由于下采样过程损失的细节信息。

金字塔池化模块如图 6 所示。




图 6 金字塔池化模块

金字塔池化模块的输入为 PS-Unet、最底层通道数为 1 024 的特征图,首先对输入特征进行自适应最大池化,池化过程填充设置为 0。步长 s 、池化核大小 k 的计算公式为:

$$s = F/(I/O) \tag{1}$$

$$k = I(O - 1)s \tag{2}$$

其中: I 为输入大小; O 为目标输出大小; F 表示向下取整。

分别采用 1×1 卷积将自适应最大池化结果的通道数降低至 256, 然后进行双线性插值上采样, 将特征图恢复至原来大小。双线性插值过程如图 7 所示。




图 7 双线性插值过程

图 7 中: P_{11} 、 P_{12} 、 P_{21} 、 P_{22} 为图像中相邻的 4 个点, 像素值分别为 $f(P_{11})$ 、 $f(P_{12})$ 、 $f(P_{21})$ 、 $f(P_{22})$, 且 $x_2 = x_1 + 1$, $y_2 = y_1 + 1$; R 为双线性插值后的像素点。

首先需要进行 x 方向的线性插值, Q_1 、 Q_2 为 x 方向的插值结果, 其像素值计算公式分别为:

$$f(Q_1) = (x_2 - x)f(P_{11}) + (x - x_1)f(P_{21}) \tag{3}$$

$$f(Q_2) = (x_2 - x)f(P_{12}) + (x - x_1)f(P_{22}) \tag{4}$$

然后进行 y 方向的线性插值, 插值结果计算公式为:

$$f(R) = (y_2 - y)f(Q_1) + (y - y_1)f(Q_2) \tag{5}$$

由式(3)~(5)可得 R 点的像素值 $f(R)$, 计算公式为:

$$f(R) = f(P_{11})(x_2 - x)(y_2 - y) + f(P_{21})(x - x_1)(y_2 - y) + f(P_{12})(x_2 - x)(y - y_1) + f(P_{22})(x - x_1)(y - y_1) \tag{6}$$

2.2 尺度感知模块

尺度感知模块类似于注意力机制, 能够自主分配权重到特征图的像素点中。尺度感知模块使金字塔池化层中的信息学习更加有效, 对这些信息进行更为密切的跟踪, 保证特征信息学习的有效性。

尺度感知模块如图 8 所示。




图 8 尺度感知模块

经过金字塔池化过程的 4 个特征图进入到 SAM,首先经过 Concat 拼接进行融合,然后经过卷积层降低特征通道数量,使模型轻量化,再经过归一化函数 Softmax 进行处理,得到像素点分类的概率分布 $P(A_i)$ 、 $P(B_i)$ 、 $P(C_i)$ 、 $P(D_i)$,计算公式为:

$$\begin{aligned} P(A_i) &= \frac{e^{A_i}}{e^{A_i} + e^{B_i} + e^{C_i} + e^{D_i}}, \\ P(B_i) &= \frac{e^{B_i}}{e^{A_i} + e^{B_i} + e^{C_i} + e^{D_i}}, \\ P(C_i) &= \frac{e^{C_i}}{e^{A_i} + e^{B_i} + e^{C_i} + e^{D_i}}, \\ P(D_i) &= \frac{e^{D_i}}{e^{A_i} + e^{B_i} + e^{C_i} + e^{D_i}} \end{aligned} \quad (7)$$

其中, i 为 $H \times W$ 大小的特征图中像素点的位置, $i=1, 2, 3, \dots, H \times W$ 。

特征分布矩阵与原特征图进行点乘运算,最终将 4 个点乘运算的特征图进行求和得到特征融合图 E 。

2.3 损失函数

在二分类的语义分割实验中,一般使用含有 Sigmoid 层的交叉熵损失函数进行网络模型训练,即

$$L_{\text{oss}}(p, l) = -\frac{1}{n} \sum_{i=1}^n \left\{ l[i] \lg(\sigma(p[i])) + [1 - l[i]] \lg(1 - \sigma(p[i])) \right\} \quad (8)$$

其中: n 为训练的总样本数量; $p[i]$ 为未经过 Sigmoid 激活的第 i 个样本被预测为真实类别的概率; $l[i]$ 为第 i 个样本的标签; σ 为 Sigmoid 函数;

$L_{\text{oss}}(p, l)$ 为将 Sigmoid 层与 BCELoss 结合成一种形式的损失函数,此操作将两者组合到一类函数中,采用了 log-sum-exp 的技巧,因此该方法比单独使用 Sigmoid、BCELoss 的数值稳定性更好^[19]。

然而,在缺陷区域远小于背景区域的情况下,即缺陷与背景像素比极度不平衡,训练过程由于没有侧重点而使损失值很大程度上浪费在背景的训练中,弱化了缺陷自身的学习。为了解决上述问题,本文在交叉熵损失函数的基础上加入平衡因子、调节因子,使训练过程更加偏重于小目标缺陷的损失情况,即

$$F_{\text{Loss}}(p, l) = -\frac{1}{n} \sum_{i=1}^n \left\{ \alpha [1 - \sigma(p[i])]^\gamma l[i] \times \lg[\sigma(p[i])] + (1 - \alpha) \times \sigma(p[i])^\gamma (1 - l[i]) \lg[1 - \sigma(p[i])] \right\} \quad (9)$$

其中: α 为损失函数的平衡因子,用于解决钢轨表面缺陷和背景不平衡的问题; $[1 - \sigma(p[i])]^\gamma$ 、 $\sigma(p[i])^\gamma$ 为调节因子,用于调控缺陷和无关背景的损失部分,提高不易分割的缺陷样本在训练中的贡献; $\gamma \geq 0$ 为可调节的聚焦参数。文献[20]的研究表明,当 $\alpha=0.25$ 、 $\gamma=2$ 时,此类损失函数可以在 COCO 数据集上得到最好的检测效果。FLoss 函数的损失值如图 9 所示。

将正确分类概率大于 0.6 时的样本看作易分类样本,反之看作难分类样本。从图 9a 可以看出, α 虽然可以解决类别不平衡的问题,但没有区分难易样本。从图 9b 可以看出,聚焦参数 γ 可以调节

易分类样本的权重,使损失聚焦在难分类样本上。当 $\alpha=0.25, \gamma=2$ 时,可以使损失聚焦在难分类样本,并且在难分类情况下,各样本的聚焦程度缓慢变化,保证了损失值在难分类样本上的均衡。




图9 FLoss函数的损失值

3 实验与分析

3.1 实验平台

硬件环境:12th Gen Intel Core i5-12400F 六核处理器,显卡为 NVIDIA GeForce RTX3060,主板为华硕 B660M-P D4,主硬盘为西数 500 GiB 固态硬盘。

软件环境:基于 64 位的 Windows10 操作系统,基于 PyTorch1.11、CUDA10.3、OpenCV2 软件库及 PyCharm 集成开发环境。

3.2 评价指标

平均交并比(mean intersection over union, mIOU)为所有类别真实值和预测值的交集与其并集之比的平均值,平均像素精度(mean pixel

accuracy, mPA)为计算所有类别被正确分类像素数量比例的平均值,即先求各类别被正确分类的像素数量占各类别真实值的像素数量,再求和计算平均值。精确率 P 为预测值为正样本且真实值也为正样本的数量在预测值为正样本的数量中所占的比例。

以上 3 种评价指标为常见的语义分割评价指标,计算公式为:

$$U_{\text{mIOU}} = \frac{1}{k} \sum_{i=1}^k \frac{p_{ii}}{\sum_{j=1}^k p_{ij} + \sum_{j=1}^k p_{ji} - p_{ii}} \quad (10)$$

$$A_{\text{mPA}} = \frac{1}{k} \sum_{i=1}^k \frac{p_{ii}}{\sum_{j=1}^k p_{ij}} \quad (11)$$

$$P = \frac{T_p}{T_p + F_p} \quad (12)$$

其中: k 为类别数;若 p_{ab} 表示将 a 预测为 b 的像素点数量, a 为真实值, b 为预测值,则式(10)~(12)中, p_{ii} 表示将 i 预测为 i 的像素点数量, p_{ij} 表示将 i 预测为 j 的像素点数量, p_{ji} 表示将 j 预测为 i 的像素点数量; T_p 为判断正确的钢轨缺陷像素点数量; F_p 为判断错误的钢轨缺陷像素点数量。

3.3 实验结果及分析

为了验证本文提出的 PS-Unet 网络模型性能以及 FLoss 函数在缺陷占比少的 RSDDs 数据集上的有效性,分别对 Unet、P-Unet、PS-Unet、PS-Unet+FLoss 4 个模型进行对比实验,训练 300 批次,并依次在高速轨道表面缺陷数据集和普通/重型运输轨道表面缺陷数据集上进行测试。训练损失值变化如图 10 所示。

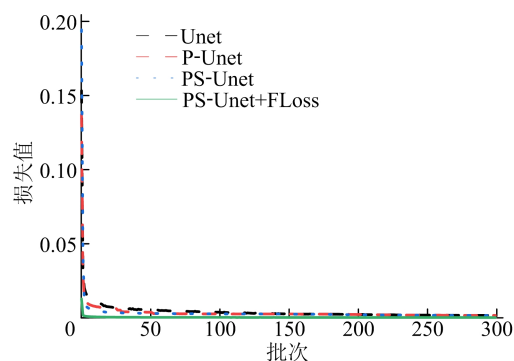


图10 训练损失值

从图 10 可以看出,相比 Unet 网络,P-Unet、PS-Unet 能够加快模型的收敛速度,提升模型学习的能力,最终的收敛结果趋于一致;PS-Unet+FLoss 相比前 3 种模型,除了能够显著提升收敛速度之外,还能够提高模型的收敛能力,降低最终

的收敛值。高速轨道、普通/重型运输轨道表面缺陷的 P - R 曲线如图 11 所示。

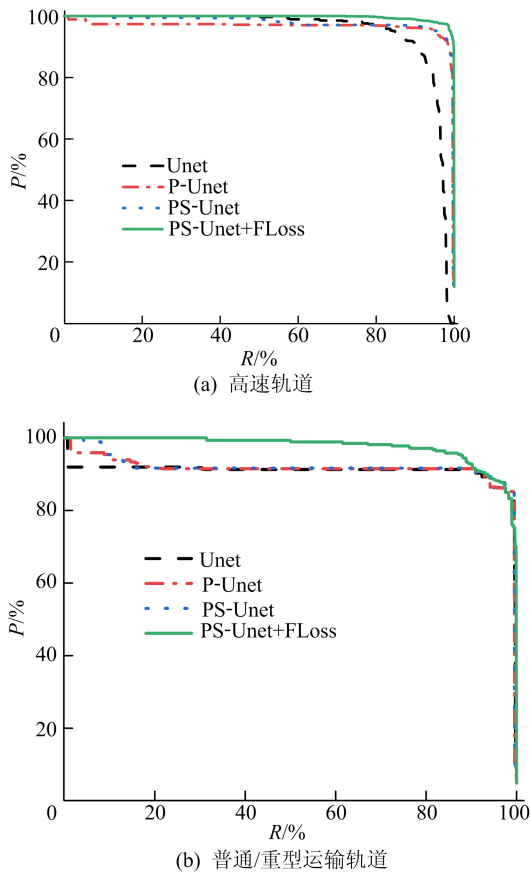


图 11 高速轨道、普通/重型运输轨道表面缺陷的 P - R 曲线

从图 11a 可以看出,不同阈值下召回率和精确率取值是变化的, P - R 曲线在坐标轴上包围的区域越广,说明该模型的性能越好。从图 11b 可以看出,PS-Unet+FLoss 在高速轨道表面缺陷和普通/重型运输轨道表面缺陷的检测均有最好的性能表现,PS-Unet、P-Unet、Unet 的模型性能

水平依次降低。

高速轨道表面缺陷和普通/重型运输轨道表面缺陷在 3 种常见指标上的检测结果见表 1、表 2 所列。


表 1 不同模型检测高速轨道表面缺陷的指标 %

网络模型	mIOU	mPA	P
PSPnet	71.78	75.82	84.34
HRnet	76.73	81.12	85.07
DeepLabv3+	75.82	79.89	85.60
Unet	83.02	83.35	95.86
P-Unet	83.66	86.55	96.17
PS-Unet	84.15	86.44	96.96
PS-Unet+FLoss	85.08	88.33	99.04

表 2 不同模型检测普通/重型运输轨道表面缺陷的指标 %

网络模型	mIOU	mPA	P
PSPnet	69.55	70.06	77.46
HRnet	71.98	72.01	79.97
DeepLabv3+	69.49	70.17	78.98
Unet	74.46	76.81	90.83
P-Unet	74.82	80.55	91.14
PS-Unet	75.10	80.87	91.33
PS-Unet+FLoss	79.25	81.16	97.11

本文通过对 Unet、P-Unet、PS-Unet、PS-Unet+FLoss 4 种网络模型与近几年流行的 PSPnet^[17]、HRnet^[21]、DeepLabv3+^[22] 3 种语义分割网络模型进行比较,结果发现,PS-Unet+FLoss 网络模型能够在 mIOU、mPA、 P 3 个指标上均取得最好结果,不同网络模型检测高速轨道表面缺陷和普通/重型运输轨道表面缺陷的效果如图 12 所示。



(a) 高速轨道

原图			
标签			
PSPnet			
HRnet			
DeepLabv3+			
Unet			
P-Unet			
PS-Unet			
PS-Unet+FLoss			

(b) 普通/重型运输轨道

图 12 不同网络模型检测的缺陷效果

从图 12 可以看出, PSPnet、HRnet、DeepLabv3+、Unet 网络均出现了误检和漏检的情况, P-Unet、PS-Unet、PS-Unet+FLoss 网络的检测结果都较为接近标签真实值, 其中 PS-Unet+FLoss 网络对缺陷边缘部分的检测效果更好, 对于缺陷像素点的分类更精确, 评价指标值更高。

4 结 论

在 Unet 网络模型基础上, 本文进行了 3 种改进, 提出一种改进的 PS-Unet 网络用于轨道表面缺陷检测, 得出如下结论:

1) 在 Unet 网络下采样最后一层加入金字塔池化模块 PPM, 增加特征信息维度, 弥补由于下采样过程损失的细节信息。

2) 在 PPM 之后使用尺度感知模块 SAM, 通过空间注意力机制获得不同感受野的信息, 并对多尺度特征进行权重分配, 对不同的感受野信息进行自学习。

3) 使用 FLoss 函数解决钢轨表面缺陷像素与背景像素比例不平衡问题, 将学习侧重点聚焦于缺陷自身。

通过消融实验证实 3 种改进网络模型都是有效的, 与 Unet 相比, 本文提出的 PS-Unet 网络显著改善了检测性能, 在高速轨道表面缺陷数据集上, mIOU、mPA、 P 分别提升 2.06%、4.98%、3.18%; 在普通/重型运输轨道表面缺陷数据集上, mIOU、mPA、 P 分别提升 4.79%、4.35%、6.28%。

综上所述, 本文提出的 PS-Unet 网络为钢轨表面的缺陷检测提供了有效解决方案。

[参 考 文 献]

- [1] 刘云涛. 基于轮轨弹塑性接触模型的钢轨疲劳裂纹分析及钢轨疲劳寿命预测[D]. 兰州: 兰州交通大学, 2022.
- [2] 郭战伟. 重载铁路钢轨损伤机理及防控措施研究[D]. 北京: 北京交通大学, 2021.
- [3] 金侠挺. 基于深度学习的高铁钢轨表面缺陷检测方法研究[D]. 长沙: 湖南大学, 2020.
- [4] 罗晖, 徐广隆. 基于图像增强与深度学习的钢轨表面缺陷检测[J]. 铁道科学与工程学报, 2021, 18(3): 623-629.
- [5] SHANG L, YANG Q, WANG J, et al. Detection of rail surface defects based on CNN image recognition and classification[C]// 2018 20th International Conference on Advanced Communication Technology (ICACT). [S. l.]: IEEE, 2018: 45-51.
- [6] YANG H, WANG Y, HU J, et al. Deep learning and machine vision-based inspection of rail surface defects[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 71: 1-14.
- [7] ZHANG D, SONG K, WANG Q, et al. Two deep learning networks for rail surface defect inspection of limited samples with line-level label[J]. IEEE Transactions on Industrial Informatics, 2020, 17(10): 6731-6741.
- [8] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]// 18th International Conference Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. Munich: Springer International Publishing, 2015: 234-241.
- [9] FALK T, MAI D, BENSCH R, et al. U-net: deep learning for cell counting, detection, and morphometry[J]. Nature Methods, 2019, 16(1): 67-70.
- [10] SMITH A G, PETERSEN J, SELVAN R, et al. Segmentation of roots in soil with U-net[J]. Plant Methods, 2020, 16(1): 1-15.

(下转第 1217 页)

SOS2 参与到拟南芥的盐胁迫中^[4],拟南芥 SOS2 基因编码一种耐盐性所需的蛋白激酶^[7],其能够与 SCABP8/CBL10 相互作用,保护拟南芥的茎免受盐胁迫^[8],EIN3 和 SOS2 协同调节植物的耐盐性^[9]。但有关 WRKY12 与 SOS2 基因之间的关系与功能尚不清楚。因此研究植物盐耐受性,寻找并阐明响应盐胁迫应答的 WRKY12 与 SOS2 基因之间的关系及其功能具有重要的理论及实践意义。研究表明,WRKY12 基因参与了植物对盐胁迫的响应,为了进一步研究基因 WRKY12 与 SOS2 基因在拟南芥响应盐胁迫应答之间的关系,通过基因工程技术构建 35S:SOS2 重组载体,将其转入野生型拟南芥中,并和 WRKY12-OE5 过表达植株双杂交,从而获得 35S:SOS2/WT 和 35S:SOS2/WRKY12-OE5 转基因植株。为研究基因 WRKY12 和 SOS2 在植物体中响应缺铁胁迫的遗传关系奠定了良好的基础。

[参 考 文 献]

- [1] ZHU J K. Plant salt tolerance[J]. Trends in Plant Science, 2001,6(2):66-71.
- [2] JULKOWSKA M M, TESTERINK C. Tuning plant signaling and growth to survive salt[J]. Trends in Plant Science, 2015,20(9):586-594.
- [3] DEINLEIN U,STEPHAN A B,HORIE T,et al. Plant salt-tolerance mechanisms[J]. Trends in Plant Science, 2014, 19(6):371-379.
- [4] GUO Y, HALFTER U, ISHITANI M, et al. Molecular characterization of functional domains in the protein kinase SOS2 that is required for plant salt tolerance[J]. The Plant Cell,2001,13(6):1383-1400.
- [5] LAKHDAR A,RABHI M,GHNAYA T,et al. Effectiveness of compost use in salt-affected soil[J]. Journal of Hazardous Materials,2009,171(1/2/3):29-37.
- [6] SHI W Y,DU Y T,MA J,et al. The WRKY transcription factor *GmWRKY12* confers drought and salt tolerance in soybean[J]. International Journal of Molecular Sciences, 2018,19(12):4087.
- [7] GONG D, GUO Y, JAGENDORF A T, et al. Biochemical characterization of the *Arabidopsis* protein kinase SOS2 that functions in salt tolerance[J]. Plant Physiology, 2002, 130(1):256-264.
- [8] QUAN R, LIN H, MENDOZA I, et al. SCABP8/CBL10, a putative calcium sensor, interacts with the protein kinase SOS2 to protect *Arabidopsis* shoots from salt stress[J]. The Plant Cell,2007,19(4):1415-1431.
- [9] QUAN R,WANG J,YANG D,et al. EIN3 and SOS2 synergistically modulate plant salt tolerance[J]. Scientific Reports,2017,7(1):44637.
- [11] LIU Z, CAO Y, WANG Y, et al. Computer vision-based concrete crack detection using U-net fully convolutional networks [J]. Automation in Construction, 2019, 104: 129-139.
- [12] 李原,李燕君,刘进超,等.基于改进 Res-UNet 网络的钢铁表面缺陷图像分割研究[J].电子与信息学报,2022, 44(5):1513-1520.
- [13] ZHANG Z,LIU Q,WANG Y. Road extraction by deep residual u-net[J]. IEEE Geoscience and Remote Sensing Letters,2018,15(5):749-753.
- [14] 蓝金辉,王迪,申小盼.卷积神经网络在视觉图像检测的研究进展[J].仪器仪表学报,2020,41(4):167-182.
- [15] 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.
- [16] 赵凯琳,靳小龙,王元卓.小样本学习研究综述[J].软件学报,2021,32(2):349-369.
- [17] ZHAO H,SHI J,QI X,et al. Pyramid scene parsing network[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. [S. l. : s. n.], 2017: 2881-2890.
- [18] VOULODIMOS A,DOULAMIS N,DOULAMIS A,et al. Deep learning for computer vision: a brief review[J]. Computational Intelligence and Neuroscience,2018,1:7068349.
- [19] CHEN F,WANG Y,XU S,et al. Style transfer network for complex multi-stroke text [J]. Multimedia Systems, 2023,29(3):1291-1300.
- [20] LIN T Y,GOYAL P,GIRSHICK R,et al. Focal loss for dense object detection[C]//Proceedings of the IEEE International Conference on Computer Vision. [S. l. : s. n.], 2017:2980-2988.
- [21] SUN K,XIAO B,LIU D,et al. Deep high-resolution representation learning for human pose estimation [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. [S. l. : s. n.], 2019: 5693-5703.
- [22] CHEN L C,ZHU Y K,PAPANDREOU G,et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]//Proceedings of the European Conference on Computer Vision (ECCV). [S. l. : s. n.], 2018:801-818.

(责任编辑 吴 亮)

(责任编辑 张 镛)