吴立群, 吴青锦, 李立明,等. 基于语义分割的扣件状态识别方法研究[J]. 智能计算机与应用,2026,16(7):18-25. DOI:10.20169/j. issn. 2095-2163. 24121301

基于语义分割的扣件状态识别方法研究

吴立群[1], 吴青锦[2], 李立明[2], 谢 省[2,3]

(1 中国铁路上海局集团有限公司科学技术研究所, 上海 200333; 2 上海工程技术大学 城市轨道交通学院, 上海 201620; 3 上海铁大电信科技股份有限公司, 上海 201802)

摘 要: 轨道扣件是轨道线路中重要的基础部件,运营过程中受轨道车辆轮对挤压、冲击等,会出现断裂、移位、丢失等异常情况,影响列车行驶稳定和安全,对其状态的检测是一项必要工作。基于深度学习语义分割模型提出了轨道扣件分割模型 Fastener-SSN。为提高模型计算速度采用 PFPA 特征金字塔模块进行网络轻量化设计,网络整体参数减少了 0. 15 M,浮点运算次数(FLOPs)下降了 0. 22 G,并采用高效的通道注意力机制(ECA)提高双分支通道信息特征提取能力,提高扣件语义分割的鲁棒性,并进一步采用连通域面积、数量特征进行分析,实现了对扣件状态的检测。实验结果表明:设计的轨道扣件语义分割模型每秒帧数(FPS)为 184. 3,平均交并比(mIoU)为 92. 69%,平均精度(mAcc)为 95. 66%,同时设计的扣件状态分类器可有效实现扣件状态分类检测,具有较强的适用性。

关键词: 深度学习; 语义分割; 扣件检测; 连通域分析

中图分类号: TP391 **文献标志码**: A **文章编号**: 2095-2163(2026)07-0018-08

Research on the method of fastener state recognition based on semantic segmentation

WU Liqun[1], WU Qingjin[2], LI Liming[2], XIE Xing[2,3]

(1 Science and Technology Research Institute of China Railway Shanghai Bureau Group Co., Ltd., Shanghai 200333, China; 2 School of Urban Railway Transportation, Shanghai University of Engineering Science, Shanghai 201620, China; 3 Shanghai Tieda Electronic and Information Technology Co., Ltd., Shanghai 201802, China)

Abstract: Track fasteners are important basic components in rail lines. During operation, these fasteners endure the squeeze and impact from vehicle wheelsets. Such forces can cause fractures, displacement, loss, and other issues, which can compromise train travel stability and safety. Therefore, detection of fastener status is essential work. A deep learning-based semantic segmentation model, Fastener-SSN (Fastener-Semantic Segmentation Network), has been developed specifically for the segmentation of railway fasteners. To enhance computational efficiency, the network incorporates a lightweight design through the Partial Feature Pyramid Attention (PFPA) module, reducing overall parameters by 0. 15 M and FLOating Point operations (FLOPs) by 0. 22 G. The integration of the Efficient Channel Attention (ECA) module improves dual-branch channel information extraction, thereby increasing robustness in fastener segmentation. Further analysis is conducted using the characteristics of connected domain area and quantity, achieving the detection of fastener status. Experimental results show that the designed railway fastener segmentation model achieves a frame rate of 184. 3 Frames Per Second (FPS), with a mean Intersection over Union (mIoU) of 92. 69% and a mean pixel Accuracy (mAcc) of 95. 66%. The devised fastener condition classifier effectively performs classification and detection of fastener states, demonstrating strong applicability.

Key words: deep learning; semantic segmentation; fastener inspection; connected domain analysis

基金项目: 国家自然科学基金(51975347)。

作者简介: 吴立群(1985—),男,硕士,高级工程师。主要研究方向:机器视觉检测; 吴青锦(2000—),男,硕士研究生。主要研究方向:计算机视觉; 谢 省(1997—),男,硕士。主要研究方向:计算机视觉。

通信作者: 李立明(1982—),男,博士,高级实验师。主要研究方向:计算机视觉,人工智能,轨道设备状态检测技术与理论。Email:liliming@sues. edu. cn。

收稿日期: 2024-12-13

0　引　言

截至 2023 年，中国的铁路总里程已超过 10 万公里，其中高速铁路里程超过 4 万公里，轨道线路是轨道交通系统的重要组成部分。其中，轨道扣件不仅起着固定钢轨保持轨距的作用，同时也有助于防止钢轨在列车行驶过程中的纵向、横向和垂直移动，但同时扣件由于受轨道车辆轮对挤压、冲击等，会发生断裂、移位、丢失等扣件失效现象[1]。

近年来，深度卷积神经网络（DCNN）在铁路扣件检测领域得到了广泛的应用[2-4]。如文献[5]采用卷积神经网络自动提取扣件的浅层和深层特征进行扣件状态分类。文献[6]利用全卷积网络对扣件的高度抽象特征进行提取和扣件类型识别。Wei 等学者[7]使用 Faster R-CNN 和改进的 YOLO 模型[2]实现扣件正常、损坏和丢失检测。同时三维激光成像技术[8-10]在扣件检测中也得到广泛应用，利用点云数据能实现定量检测[11-13]，但检测速度较低。采用深度学习进行扣件检测时，存在正负样本不平衡的问题，这通常通过翻转、尺度变换等数据增强技术来增加负样本数量，缓解样本不平衡问题。然而，即使经过这样的处理，模型在不同线路中的泛化能力有所不同，影响检测性能。为了解决扣件检测样本不平衡的问题，本文提出了基于扣件语义分割的状态检测新方法，具体地，首先仅利用正常扣件的数据来训练 Fastener-SSN 语义分割模型，避免训练过程中正负样本不平衡问题，保证扣件弹条前景分割的准确度；然后，对弹条分割结果采用连通域面积、数量特征进行分析，实现对扣件状态（正常、异常）检测，该方法如图 1 所示。

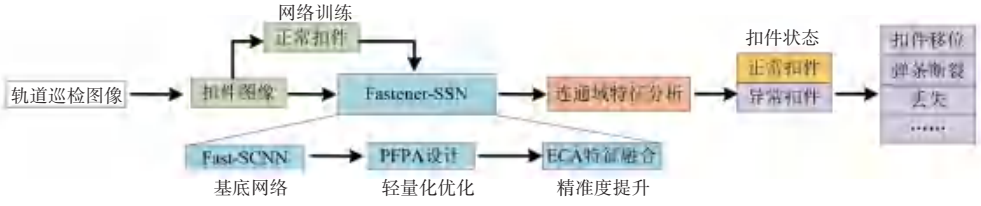


图 1　轨道扣件状态检测框图

Fig. 1　Block diagram of track fastener state detection

1　Fastener-SSN 扣件语义分割网络

为对轨道扣件实现快速精确分割，提出了基于 Fast-SCNN（Fast Semantic Segmentation Network）[14] 改进的轨道扣件分割网络 Fastener-SSN（Fastener-Semantic Segmentation Network）。在该网络中采用部分卷积构成特征金字塔特征选择模块 PFPA（Partial Feature Pyramid Attention）优化原先网络中 SPP 模块，降低网络参数；为弥补在 2 个分支特征融合过程中扣件图像细节信息丢失的状况，在分支结合时引入 ECA 通道特征选择模块[15]，聚焦于轨道扣件弹条区域特征，并抑制背景信息，同时进一步提取 2 个不同分支的通道的语义特征与扣件边缘特征，从而提高特征表达能力，提升网络分割的精准度，其网络结构如图 2 所示。

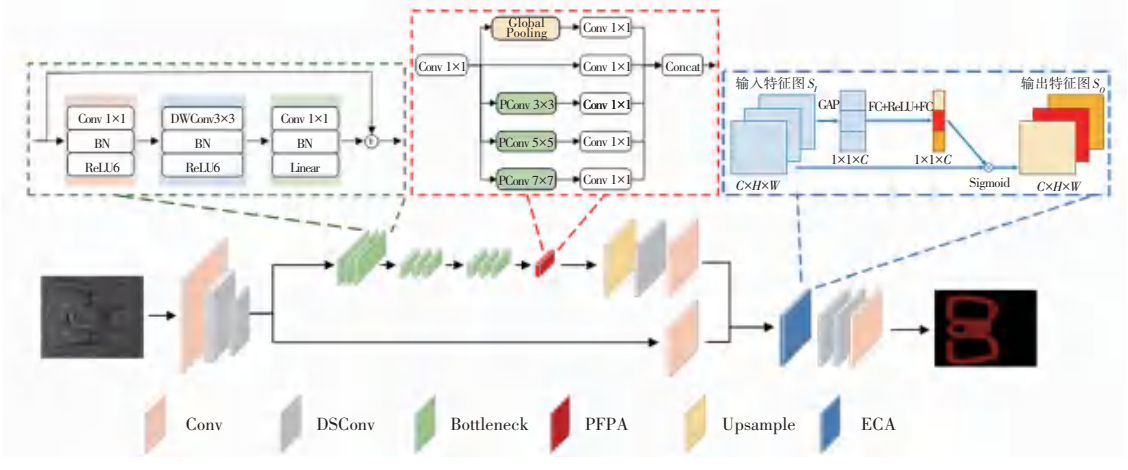


图 2　Fastener-SSN 网络结构图

Fig. 2　Digram of Fastener-SSN architecture

1.1 Bottleneck 模块

Fast-SCNN 采用双分支结构,同时将学习引入到下采样,在浅层网络中的底层和高层分支上共享特征计算,将高分辨率图像的空间细节与低分辨率下的深度特征有效结合,使得网络能够在保持高分辨率图像丰富细节的同时,利用低分辨率图像的深度特征进行更准确的分类和分割,该方法在不牺牲分割精度的前提下,显著提高处理速度。在 Fastener - SCNN 网络中,采用 MobilenetV2 的 Bottleneck 结构[16],先利用 Conv 1×1 的卷积层将低维空间映射到高维空间,然后使用 BN 层和 ReLU6 对通道进行归一化处理;接着,经过 DWConv 3×3 提取通道特征信息,再使用 BN 层和 ReLU6 对通道进行归一化处理;最后,经过一个 Conv 1×1 的卷积层将高维空间映射到低维空间,并使用 Linear 线性激活函数,其网络结构如图 3 所示。

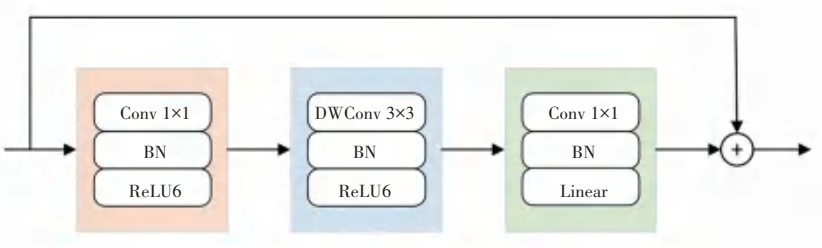


图 3 Bottleneck 网络结构图

Fig. 3 Diagram of Bottleneck network structure

1.2 PFPA 轻量化特征金字塔模块

在处理轨道扣件图像分割这样的单目标语义分割任务时,SPP 模块由于采用不同尺度的池化方式导致轨道扣件边缘信息丢失较多,从而影响了分割结果的精确度和准确性。并且不同尺度池化操作,导致训练和推理过程的时间和资源消耗增加,降低了分割效率。针对 SPP 模块在扣件分割任务中存在的不足,提出了基于部分卷积的特征金字塔特征选择模块 PFPA,其结构如图 4 所示。

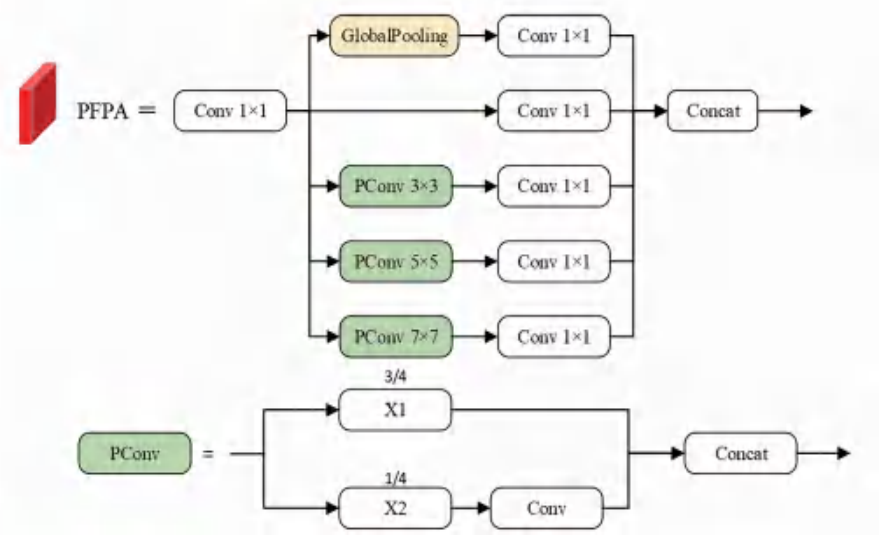


图 4 PFPA 网络结构图

Fig. 4 Diagram of PFPA network structure

PFPA 模块采用 PConv 3×3、PConv 5×5 和 PConv 7×7 的卷积模块构成特征提取金字塔结构,不仅有效地降低计算成本,使得模型在实际应用中能够高效运行,而且实现了在不同尺度上捕获更广泛扣件弹条特征信息,从而提高特征的丰富性和准确性。同时为了进一步增强全局上下文信息,在 PFPA 模块中引入全局平均池化。通过全局平均池化操作,抑制轨道扣件图像中的背景和环境信息,在此基础上有效提取弹条的前景信息,从而更好地理解图像内容的语境和语义。

1.3 ECA 通道特征选择模块

Fastener-SCNN 通过双分支结构来同时学习扣件在图像中空间信息和类别信息,但在分支的信息融合过程中,为弥补扣件图像通道信息的丢失,在分

支结合时引入 ECA[15]（Efficient Channel Attention）特征选择模块，帮助模型聚焦于轨道扣件弹条区域特征，并抑制背景信息，从而提高特征的表达能力，结构如图 5 所示。

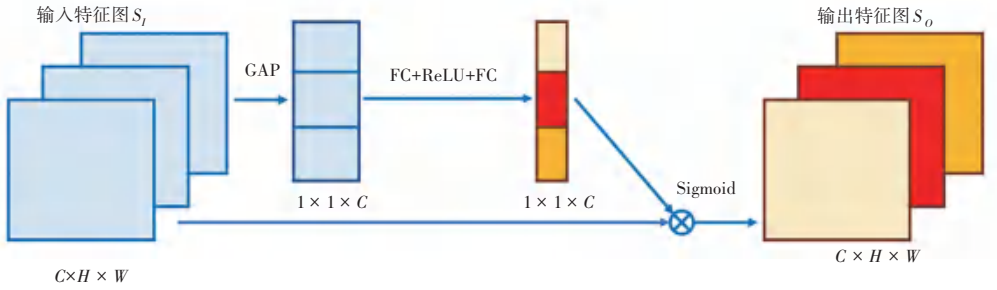


图 5　ECA 模块

Fig. 5　The process of ECA module

2　基于连通域特征的扣件分类器

在得到扣件弹条语义分割检测结果后，设计了一种基于连通域特征的扣件状态识别方法：

（1）将轨道扣件的 RGB 图像转换为 HSV 色彩空间；

（2）二值化处理提取出图像中的连通域区域；

（3）提取连通域面积、数量特征；

（4）判断识别扣件状态（正常或者异常）。

该方法通过对 1 300 张正常轨道扣件图像的连通域面积进行统计分析，得到面积基准阈值：若连通域的面积小于基准阈值的 90% 或大于基准阈值的 110%，则判定为扣件异常；连通域数量为 0 个或大于等于 2 个，同样直接判定为扣件异常。正常与异常扣件分类流程见图 6。

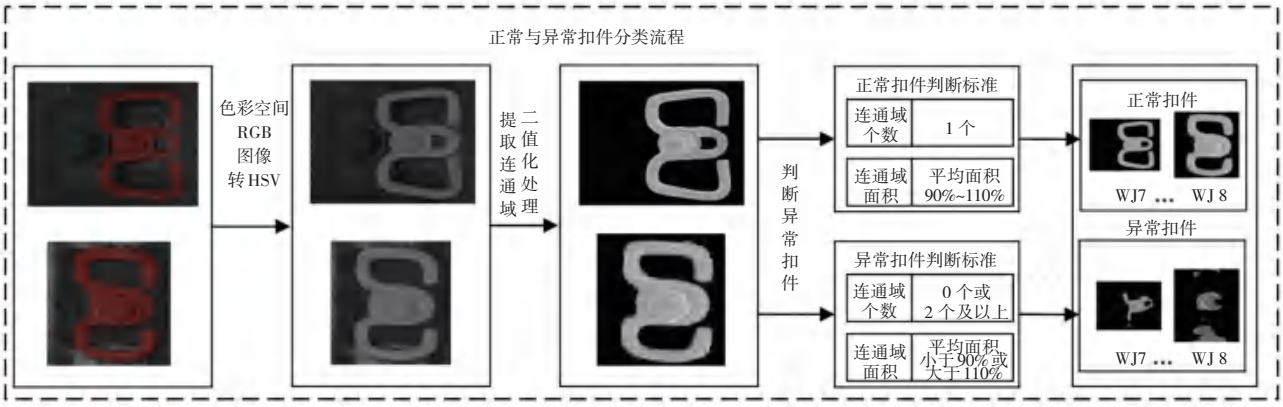


图 6　正常与异常扣件分类流程

Fig. 6　Normal and defective fastener classification process

3　实验结果及分析

本文采用数据集为 WJ-7 型和 WJ-8 型轨道扣件，一共 3 600 张扣件图片，划分为 2 880 张训练集、360 张验证集与 360 张测试集，表 1 为实验环境及参数配置。

3.1　语义分割效果

（1）mIoU 和 mAcc。在语义分割中，通常使用所有类别的 IoU 平均值 mIoU（mean Intersection over Union）和所有在像素上预测正确像素比例的平均值 mAcc（mean pixel Accuracy）这 2 个评价指标，用于衡量模型像素级别分类准确性。指标对应公式为：

表 1　实验环境及参数配置

Table 1　Experimental environment and parameters configuration

参数名称	参数值
操作系统	Windows 10 22H2
CPU	AMD Ryzen5-5600 6核
GPU	NVIDIA GeForce RTX 3060 12 G
Python	3.8.0
Pytorch	2.0.0
CUDA+cuDNN	11.8+8.6.0
Batch size	32
学习率	0.01
权重衰减	0.005
优化器	SGD

$$\mathrm{mIoU} = \frac{1}{N}\sum_{i=1}^{N}\frac{\mathrm{TP}_i}{\mathrm{TP}_i + \mathrm{FP}_i + \mathrm{FN}_i} \tag{1}$$

$$\mathrm{mAcc} = \frac{1}{N}\sum_{i=1}^{N}\frac{\mathrm{TP}_i}{\mathrm{TP}_i + \mathrm{FP}_i} \tag{2}$$

其中，N 表示类别的数量；TP_i 表示模型正确预测第 i 个类别的像素数；FP_i 表示模型错误将第 i 类预测为其他类的像素数；FN_i 表示模型错误将其他类预测为第 i 类的像素数。

(2) FLOPs(FLoating point OPerations)。表示浮点运算次数，用来衡量模型的计算复杂度。

(3) FPS(Frames Per Second)。表示模型每秒可以处理的图片数量。计算公式为：

$$\mathrm{FPS} = N/T \tag{3}$$

其中，N 表示总帧数，T 表示处理 N 帧所需时间(s)。

在图 7 中，正常 WJ-7 扣件和正常 WJ-8 扣件中的弹条及其固定螺栓都被正确且清晰地分割出来，但扣件丢失或者扣件弹条被遮挡，导致语义分割网络无法正确提取弹条特征信息并分割扣件弹条。

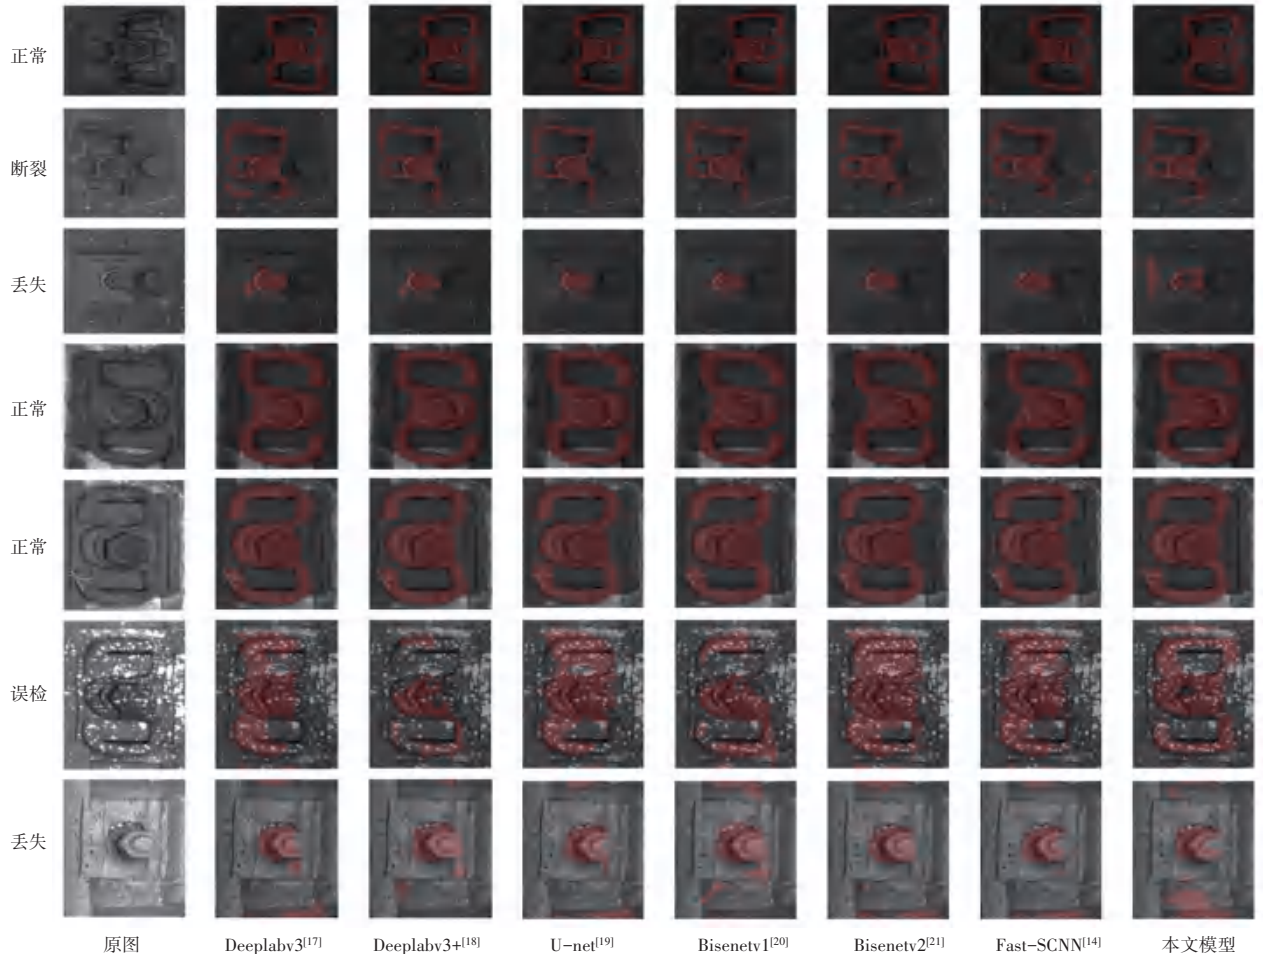


图 7 不同网络检测结果对比

Fig. 7 Comparison of detection results of different networks

3.2 轻量化改进结果对比

为了验证 PFPA 模块的轻量化效果，选择与常见的语义分割网络进行实验效果对比。实验结果见表 2。

从表 2 的实验结果来看，经过改进的 Fastener-SCNN 比 Fast-SCNN[14] 网络参数量降低了 20.7%，FLOPs 降低了 23.6%，FPS 下降了 3.3%，但还是比常见的语义分割网络检测速度要快，并且 mIoU 对比原网络提升了 4.01%，mAcc 也提升了 0.98%。该实验证明了 PFPA 模块对 Fast-SCNN 网络的改进的有效性，在保证网络运行速度的前提下，进一步降低了网络的参数，并且提升了网络的检测精度。各个网络的检测对比结果见图 7。

3.3 特征选择模块对比实验

为了验证 ECA 特征选择模块的效果，本节采用 SE、CA 和 CBAM 这些常见的特征选择模块与 ECA 模块进行实验对比。实验结果见表 3。

表 2　网络优化实验对比

Table 2　Comparison of network improvement experiments

网络	参数/M ↓	FLOPs/G ↓	FPS ↑	mIoU/% ↑	mAcc/% ↑
Deeplabv3[17]	65.74	276.48	16.97	91.75	95.79
Deeplabv3+[18]	41.22	184.32	20.03	91.52	95.59
U-net[19]	28.99	204.80	64.34	90.83	95.17
Bisenetv1[20]	13.27	14.82	156.99	91.73	**95.98**
Bisenetv2[21]	3.36	12.36	139.15	90.21	95.02
Fast-SCNN[14]	1.40	0.93	**190.60**	88.27	94.51
本文模型	**1.11**	**0.71**	184.30	**91.81**	95.44

表 3　特征选择模块实验对比

Table 3　Experimental comparison of feature selection module

网络	参数/M ↓	FLOPs/G ↓	FPS ↑	mIoU/% ↑	mAcc/% ↑
SCNN+PFPA	**1.11**	0.71	**184.3**	91.81	95.44
+SE	1.44	0.86	117.5	90.61	94.07
+CA	1.33	0.80	99.9	91.20	94.72
+CBAM	1.35	0.78	95.8	91.38	95.18
+ECA(本文模型)	1.25	**0.71**	179.6	**92.69**	**95.66**

从表 3 的实验结果来看，添加 ECA 特征选择模块后，在保证网络检测速度的同时，还能在一定程度上提升检测精度，从而有效提高了网络的性能。

3.4　消融实验

为了验证本研究对 Fast-SCNN 网络的改进效果、以及各个模块添加后的效果，消融实验中分别将 PFPA 模块和 ECA 特征选择模块先后嵌入至网络中，进行实验对比。实验结果见表 4。

由表 4 可知，嵌入 PFPA 模块和 ECA 特征选择模块后网络的各部分效果都得到了改进提升。对比 Fast-SCNN 添加 PFPA 模块后，在保证网络运行速度的情况下，网络参数下降了 0.29 M，FLOPs 下降了 0.22 G，mIoU 提高到了 91.81%，mAcc 提高到了 95.44%；在此基础上，添加 ECA 模块后，mIoU 提高到了 92.69%，相比原网络提升了 5.0%，mAcc 提高到了 95.66%，相比原网络提升了 0.98%，网络参数和 FLOPs 都比原网络有所降低，从而证明了该网络改进的有效性。

表 4　消融实验对比

Table 4　Comparison of ablation experiments

优化方式	PFPA	ECA	参数/M ↓	FLOPs/G ↓	FPS ↑	mIoU/% ↑	mAcc/% ↑
Fast-CNN			1.40	0.93	**190.6**	88.27	94.51
+PFPA	√		**1.11**	0.71	184.3	91.81	95.44
+ECA		√	1.53	0.96	175.4	90.75	94.81
本文模型	√	√	1.25	**0.71**	179.6	**92.69**	**95.66**

3.5　扣件弹条分类结果分析

为验证扣件状态检测模型的准确性，将验证集 360 个扣件样本进行验证检测，得到的检测结果见表 5。表 5 中，其中 WJ-7 型异常扣件的检测准确率为 100%，WJ-7 正常扣件误检率为 0.67%；WJ-8 型异常扣件的检测准确率为 100%，正常扣件误检率为 0.56%。

表 5　测试集检测结果

Table 5　Inspection results of test set

数据集大小	正常 WJ7	异常 WJ7	正常 WJ8	异常 WJ8
样本构成(360)	150	10	180	20
检测结果(360)	149	11	178	22

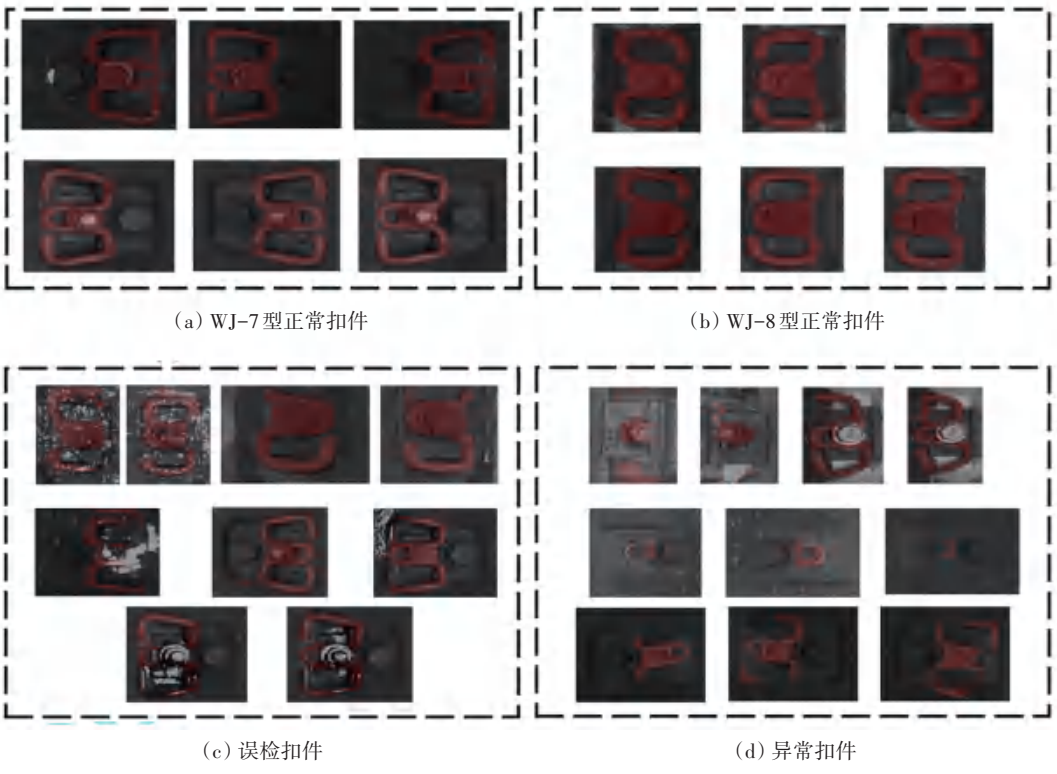
从轨道巡检图像随机分割 7 000 个扣件样本进行测试，测试结果见表 6。在共计 7 000 个 WJ7/WJ8 型混合扣件样本中，76 个异常扣件的检测正确率为 100%，正常扣件的误检率为 0.16%，误检样本如图 8 所示。

表 6　实际铁路扣件检测结果

Table 6　Inspection results of actual railway fasteners

数据集大小	正常 WJ7	异常 WJ7	正常 WJ8	异常 WJ8
样本构成(7 000)	5 800	51	1 124	25
检测结果(7 000)	5 791	60(9)	1 119	30(5)

产生误检的因素主要有：扣件表面异物覆盖(油漆、道砟等)；处于图像边缘的扣件图像信息不完整。在实际的工程应用中，这 2 个原因导致可接受的误检。



(a) WJ-7型正常扣件 (b) WJ-8型正常扣件

(c) 误检扣件 (d) 异常扣件

图 8 正常扣件与异常扣件分类

Fig. 8 Classification of normal and defective fasteners

4 结束语

针对目前轨道扣件检测算法中负样本不足的问题,提出了基于正样本语义特征的扣件状态检测方法,通过轻量化轨道扣件语义分割模型 Fastener-SSN 精确提取扣件弹条语义特征后,并利用连通域面积与数量特征设计扣件状态分类器,实现了对扣件的正常与异常分类检测。在测试数据集中扣件语义分割的 mIoU 与 mAcc 分别达到了 92.69%、95.66%,表现出良好的性能,同时对扣件异常状态的准确率为 100%,但由于环境因素等影响存在对正常扣件状态检测的误判情况。

本文的工作仍存在一定的改进空间。围绕环境因素引起的语义分割精度下降,后续可以采用特征提取更强的网络来研发设计基于连续特征去“遮挡”的语义分割模型,进一步提升语义分割的精度。

参考文献

[1] 王辛月. 钢轨扣件自动识别与定位研究[D]. 成都:电子科技大学, 2021.

[2] Wei X K, Wei D, Suo D, et al. Multi-target defect identification for railway track line based on image processing and improved YOLOv3 model[J]. IEEE Access, 2022, 8: 61973-61988.

[3] Gibert X, Patel V M, Chellppa R. Deep multitask learning for railway track inspection[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18(1): 153-164.

[4] 龙炎. 基于深度学习的铁路扣件检测系统的研究[D]. 北京:北京交通大学, 2018.

[5] 王兵水. 基于卷积神经网络的扣件弹条状态检测研究[D]. 上海:上海工程技术大学, 2020.

[6] 蒋欣兰. 结构化区域全卷积神经网络的钢轨扣件检测方法[J]. 计算机科学与探索, 2020, 14(11): 1888-1898.

[7] Wei X K, Yang Z M, Liu Y X, et al. Railway track fastener defect detection based on image processing and deep learning techniques: A comparative study[J]. Engineering Applications of Artificial Intelligence, 2019, 80: 66-81.

[8] 代先星, 阳恩慧, 丁世海, 等. 基于三维图像的铁路扣件缺陷自动识别算法[J]. 铁道学报, 2017, 39(10): 89-96.

[9] 李明森, 李林,张超, 等. 基于三维激光成像技术的扣件缺损自动检测[J]. 激光与红外, 2022, 52(5): 670-677.

[10] 李胜腾, 薛亚东, 迟胜超, 等. 基于3D相机的轨道扣件部件丢失与松动智能检测[J]. 铁道科学与工程学报, 2024, 21(1): 386-395.

[11] Lorente A G, Lorca D F, Velasco M G, et al. Detection of range-based ail gage and missing rail fasteners[J]. Transportation Research Record, 2014, 2448(1): 125-132.

[12] 陈文婷, 罗文婷, 李林, 等. 基于2D与3D激光图像的轨道扣件状态智能检测[J]. 仪表技术与传感器, 2022 (11): 88-95.

[13] 赵渊, 薛浩飞, 邱江洋, 等. 基于2D&3D融合算法的扣件故障检测系统[J]. 铁道车辆, 2024, 62(3): 191-196.

[14] Poudel R P K, Liwicki S, Cipolla R. Fast-SCNN: Fast semantic segmentation network[J]. arXiv preprint arXiv, 1902.04502, 2019.

[15] Wang Q L, Wu B G, Zhu P F, et al. ECA-Net: Efficient Channel Attention for Deep Convolutional Neural Networks[C]//

Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2020: 11531-11539.

[16] Sandler M, Howard A, Zhu M L, et al. MobileNetv2: Inverted residuals and linear bottlenecks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2018: 4510-4520.

[17] Chen L C, Papandreou G, Schroff F, et al. Rethinking atrous convolution for semantic image segmentation[J]. arXiv preprint arXiv, 1706.05587v3, 2017.

[18] 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. Cham: Springer, 2018, 11211: 833-851.

[19] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation[C]//Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2015, 9351: 234-241.

[20] Yu C Q, Wang J B, Peng C, et al. BiSeNet: Bilateral segmentation network for real-time semantic segmentation[M]// Lecture Notes in Computer Science. Cham: Springer, 2018: 334-349.

[21] Yu C Q, Gao C X, Wang J B, et al. BiSeNetV2: Bilateral network with guided aggregation for real-time semantic segmentation[J]. International Journal of Computer Vision, 2021, 129(11): 3051-3068.