

DOI:10.19651/j.cnki.emt.2209951

基于 DeepLabV3+的轮对踏面损伤分割算法^{*}

孙耀泽^{1,2} 高军伟^{1,2}

(1. 青岛大学自动化学院 青岛 266071; 2. 山东省工业控制技术重点实验室 青岛 266071)

摘要: 针对轨道交通轮对踏面损伤图像存在边界识别效果差,分割精度低的问题,提出一种改进的 DeepLabV3+ 算法对损伤区域进行识别分割。首先将轻量化网络 MobileNetV2 作为主干特征提取网络,加快语义分割的速度;然后将空洞空间卷积池化金字塔模块中的膨胀卷积以及特征融合后的普通卷积替换为深度可分离卷积,减少参数量,降低模型复杂度;最后在主干网络输出的浅层与深层特征层添加 ECA 机制,加强网络特征学习能力,使模型对损伤区域更加敏感,从而提升模型分割精度。实验结果表明,改进后的 DeepLabV3+ 模型大小缩减为原来的 5%,mPA 值达到 90.70%,mIoU 值达到 84.33%,在模型更轻量化的同时保证了踏面损伤图像的分割效果。

关键词: 轮对踏面损伤;DeepLabV3+ 算法;MobileNetV2;ECA 注意力机制

中图分类号: TP391.41 文献标识码: A 国家标准学科分类代码: 510.4050

Image segmentation of wheel set tread damage based on DeepLabV3+

Sun Yaoze^{1,2} Gao Junwei^{1,2}

(1. School of Automation, Qingdao University, Qingdao 266071, China;

2. The Shandong Province Key Laboratory of Industrial Control Technology, Qingdao 266071, China)

Abstract: Aiming at the problems of poor boundary recognition effect and low segmentation accuracy of rail transit wheel set tread damage image, an improved DeepLabV3+ algorithm is proposed to recognize and segment the damage area. Firstly, the lightweight network MobileNetV2 is used as the backbone feature extraction network to speed up the speed of semantic segmentation; Then, the expansion convolution in Atrous Spatial Pyramid Pooling module and the ordinary convolution after feature fusion are replaced by Deep Separable Convolution, so as to reduce the amount of parameters and reduce the complexity of the model; Finally, ECA mechanism is added to the shallow and deep feature layers of the backbone network output to strengthen the network feature learning ability and make the model more sensitive to the damaged area, so as to improve the segmentation accuracy of the model. The experimental results show that the size of the improved DeepLabV3+ model is reduced to 5%, the mPA value is 90.70%, and the mIoU value is 84.33%. While the model is lighter, the segmentation effect of tread damage image is ensured.

Keywords: wheel set tread damage; DeepLabV3+ algorithm; MobileNetV2; ECA attention mechanism

0 引言

轨道交通轮对作为重要的支撑和走行部件,长期在复杂环境下与轨道发生高速滚动接触,可能出现踏面局部被磨成平面以及疲劳剥离等损伤,踏面损伤成为影响轨道交通运行安全性和舒适性的重要因素之一^[1-2]。因此,实现踏面损伤图像精确分割对于保证机车安全运行尤为重要。

传统图像分割利用图像中的颜色、纹理等特征将图像分割成不同的区域^[3],赵勇^[4]针对轮对踏面轮缘磨损问题,采用量子粒子群优化算法进行轮对踏面光截曲线图像的有效分割。史倩等^[5]提出一种基于区域生长的轮对图像分割

算法,根据不同情况下的轮对图像特点确定合适的生长准则,有效地提取轮对轮廓图像。随着深度学习的快速发展与广泛应用,基于大量数据进行特征提取并学习特征的图像语义分割^[6-8]算法在性能与效果上较传统算法有了很大的提升。当前广泛使用的语义分割网络以 Long 等^[9]提出的全卷积神经网络(fully convolutional network, FCN)为代表,利用卷积层代替全连接层,将具有空间特征的图像保留输出,完成对图像像素级别端到端的预测。秦松岩^[10]为了更加快速的检测轮对踏面,先采用 Canny 边缘检测对边缘信息进行提取,得到踏面占据大区域的图像,后对 U-Net

收稿日期:2022-05-05

*基金项目:山东省自然科学基金(ZR2019MF063)、山东省重点研发计划(2017GGX10115)项目资助

算法进行了改进,实现轮对踏面图像的分割。杨玲等^[11]针对传统的图像处理方法在检测轮对踏面上的磨损区域时容易产生误识别问题,对 FCN-32S、FCN-16S、FCN-8S 模型进行训练,利用全卷积神经网络检测踏面轮廓图以识别磨损区域。

为了解决轨道交通轮对踏面损伤分割精度低,效果差的问题,本文提出一种改进的 DeepLabV3+^[12-15] 算法用于踏面损伤图像分割;通过替换 MobileNetV2^[16]为主干特征提取网络,解决 Xception^[17] 网络带来的训练速度较慢的问题,使网络结构更加轻便,模型训练速度提升;再采用深度可分离卷积^[18] 替换 ASPP 结构中的膨胀卷积以及深层与浅层特征融合后的普通卷积,减少计算量和模型大小;为了使模型对目标对象更加敏感,增强模型对损伤区域的分割判别能力,从而更大化地提高网络性能,在浅层与深层特征层后添加

ECA^[19] 注意力机制,提高了踏面损伤图像的分割效果。

1 DeepLabV3+ 结构

DeepLabV3+ 是一种用于语义分割的典型网络,该网络基于 DeepLabV3^[20] 增添一个用于解码的模块,将深层特征与浅层特征进一步融合,通过恢复空间信息获得清晰的对象边界,从而优化边界分割^[21]。DeepLabV3+ 网络利用 Xception 对输入图像进行特征提取,随后分别采用两次和四次下采样输出一个高宽较大的浅层特征层和一个高宽较小的深层特征层,深层特征层输入到 ASPP 中进一步提取并融合目标特征,在维持特征图大小的同时保证了更大的感受野,使得图像语义信息更加完整,最终将浅层与深层特征层进行特征融合,再经过上采样得到分割结果,网络结构如图 1 所示。

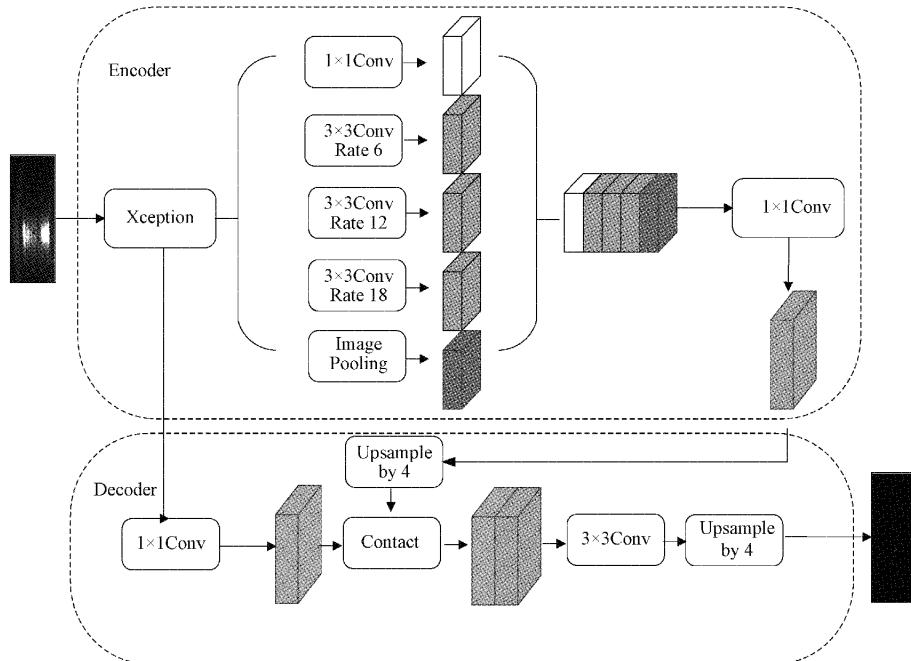


图 1 DeepLabV3+ 结构

2 改进的 DeepLabV3+ 结构

2.1 MobileNetV2

MobileNetV2 网络是由 Inverted resblock 组成, Inverted resblock 包含两部分,其中主干通过对输入特征层进行 1×1 卷积将通道数进行扩张,随后利用 3×3 逐层卷积完成目标跨特征点的特征提取,最后利用 1×1 卷积对通道数进行缩减,残差边部分直接将输入与输出相连。MobileNetV2 网络的具体参数如表 1 所示。

2.2 深度可分离卷积

深度可分离卷积是一种可分解卷积操作,其可以分解为深度卷积和逐点卷积。深度卷积将卷积核拆分为单通道形式,在不改变输入特征图像深度的情况下,对每一通道进行卷积操作,得到与输入特征图通道数相符的输出特

表 1 MobileNetV2 网络参数

输入尺寸	操作	通道扩张倍数	通道维度	步长
$512 \times 512 \times 3$	Conv_bn3 $\times 3$	—	32	2
$256 \times 256 \times 32$	Bottleneck	1	16	1
$256 \times 256 \times 16$	Bottleneck $\times 2$	6	24	2
$128 \times 128 \times 24$	Bottleneck $\times 3$	6	32	2
$64 \times 64 \times 32$	Bottleneck $\times 4$	6	64	2
$32 \times 32 \times 64$	Bottleneck $\times 3$	6	96	1
$32 \times 32 \times 96$	Bottleneck $\times 3$	6	160	2
$16 \times 16 \times 160$	Bottleneck	6	320	1
$16 \times 16 \times 320$	Conv_bn1 $\times 1$	—	1 280	—

征图;逐点卷积即 1×1 卷积, 主要进行特征图的升维和降维操作。相比普通卷积深度可分离卷积可以使用更少的参数以及更少的运算量来进行特征学习, 提升网络的迭代效率, 深度可分离卷积如图 2 所示。深度卷积操作中一个卷积核只负责一个通道数, 输入通道数为 M , 则输出 M 个特征图; 逐点卷积操作中的卷积核尺寸为 $1 \times 1 \times M$, 通过将上一步得到的特征图在深度方向上进行加权组合, 从而扩展得到新的特征图。

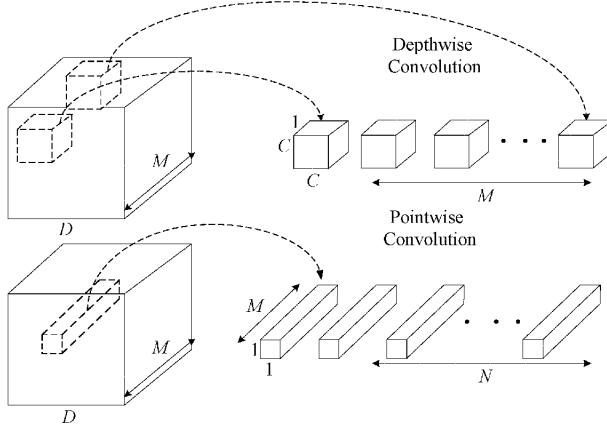


图 2 深度可分离卷积

2.3 ECA 注意力模块

由于引入轻量化网络 MobileNetV2 进行特征提取, 在加快网络分割任务速度的同时不可避免的会对分割精度产生一定影响, 为了弥补精度损失, 在网络结构中添加了注意力模块^[22-23]。ECA 模块是一种基于 SE^[24] (squeeze and excitation) 模块提出的轻量型注意力机制。SE 通道注意力机制通过压缩和激励操作专注于通道之间的相互关系, 使网络根据损失值自主学习目标特征的权重。ECANet 通过剖析 SE 模块, 去除了原来 SE 模块中的 FC (fully connected) 层, 直接在 GAP(global average pooling) 之后的特征上通过一个可以权重共享的一维卷积进行学习, 提升网络性能并减少参数量, 通过避免通道数的降维并进行适当的跨通道交互, 提高通道注意力的学习能力和效率。ECA 模块更轻量, 增加的模型复杂度小, 提升效果显著, 结构如图 3 所示。ECANet 在经过全局平均池化操作后, 对每个通道及其 k 个相邻通道之间进行了局部的跨通道信息交互, 其中 k 值通过自适应的方法进行调节, 最后通过快速的一维卷积产生通道注意。

2.4 改进的结构

原 DeepLabV3+ 网络采用 Xception 作为主干特征提取网络, 随着网络深度的加强会伴随大量参数, 这会加大系统对硬件性能的要求; ASPP 中的膨胀卷积虽然能够保证更大的感受野, 但对于轮对踏面损伤这类较小目标的识别分割, 其本身不需要那么大的感受野。针对以上问题, 本文先采用 MobileNetV2 进行主干特征提取网络的替换,

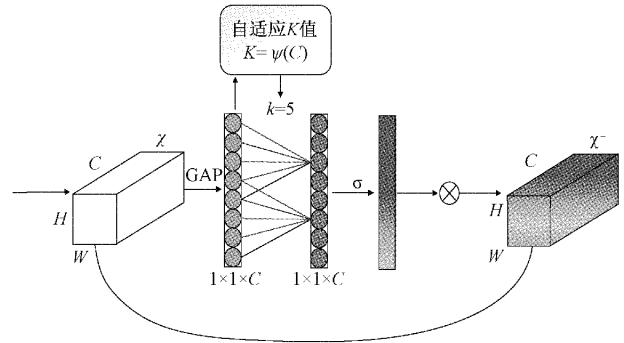


图 3 ECA 注意力机制

降低主干参数量从而提高模型运算效率; 然后将 ASPP 中膨胀率为 6, 12, 18 的膨胀卷积替换为深度可分离卷积, 保证局部信息连续性的同时减少模型复杂度; 将浅层和深层特征层融合后的普通卷积也替换为深度可分离卷积, 得到更轻量化的模型; 最后在主干输出的浅层和深层特征层后分别添加 ECA 通道注意力机制, 加强踏面损伤特征的提取能力, 得到效果更好的分割模型, 网络结构如图 4 所示。

3 实验与分析

3.1 实验环境

实验所用的操作系统为 64 位 Windows 10, CPU 为 Intel(R) Core(TM) i5-10300H CPU @ 2.50 GHz, RAM 为 16 GB, GPU 为 英伟达 GTX1660Ti, cudnn8.0.05, pytorch1.9.0+cuda11.1。

3.2 评价指标

为了对模型进行分割性能评估, 实验选取均像素准确率(mPA)、平均交并比(mIoU)评估网络分割性能; 模型参数量、模型大小表达模型复杂度。mPA 在 PA 基础上做了提升, 表示类别内像素正确分类概率的平均值, 公式为:

$$mPA = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij}} \quad (1)$$

mIoU 的取值方式为先计算所有类别真实值和预测值的交集和并集之比, 再对其求取平均值, 公式为:

$$mIoU = \frac{1}{k} \sum_{j=1}^k \frac{p_{ii}}{\sum_{j=1}^k p_{ij} + \sum_{i=1}^k p_{ji} - p_{ii}} \quad (2)$$

式中: k 为类别数, p_{ii} 表示预测结果为正确的像素数, p_{ij} 和 p_{ji} 分别表示 i 类被预测为 j 类, j 类被预测为 i 类两种错误。

3.3 数据集制作

训练数据选用 533 张踏面损伤图像, 采用数据增强方式增大数据集, 得到由 2312 张图像组成的轮对踏面损伤数据集, 采用 Labelme 对损伤区域进行标注, 如图 5 所示, 其中图 5(a)、(c) 为踏面损伤图像, 图 5(b)、(d) 为图像标签。

3.4 模型训练

训练按照 8 : 1 : 1 划分训练集、测试集、验证集, 训练

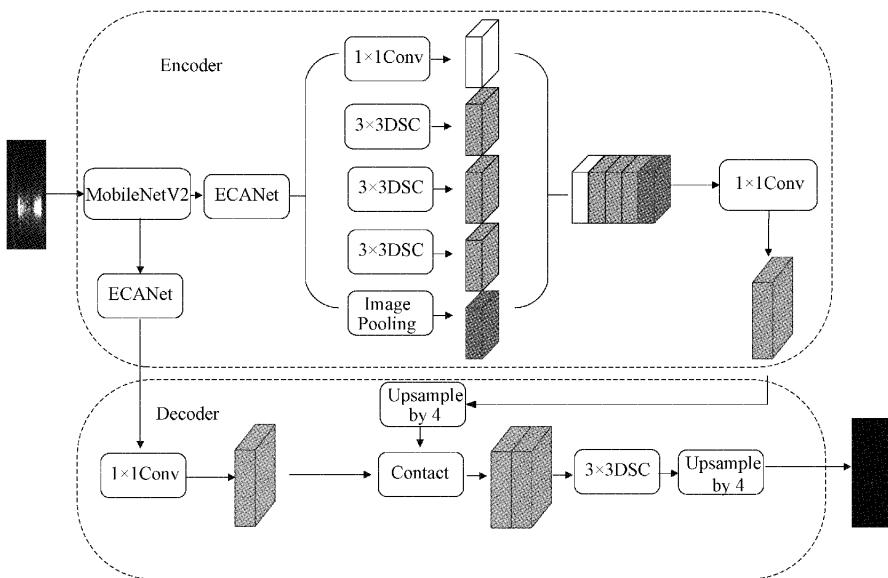


图 4 改进后的网络结构

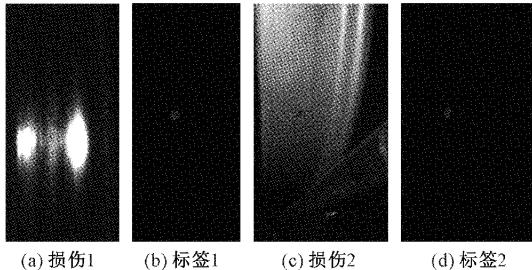


图 5 损伤图像对应标签

输入图像大小为 512×512 , 下采样倍数为 16, 为了提高模型精度, 模型训练过程加载网络的预训练权重参数, 迭代 100 次。采用冻结与解冻训练方式结合, 前 50 次训练冻结主干进行训练, 学习率 0.000 5, 特征提取网络未改变, 显存占用减少; 后 50 次为解冻训练, 学习率 0.000 05。

改进后的 DeepLabV3+ 训练损失曲线如图 6 所示, 由图 6 可知, 模型训练开始时, 损失值波动较大, 随着训练次数的增多, 损失值曲线幅度逐渐平稳; 在 80 次迭代附近开始逐渐趋于稳定, 模型收敛。

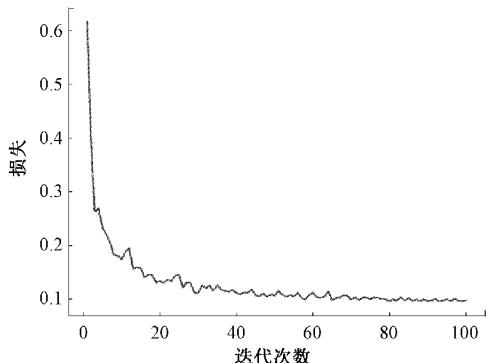


图 6 损失曲线

4 消融实验

为了验证改进策略作用于原 DeepLabV3+ 的效果, 设置总参数量、模型大小为模型复杂度指标, mPA、mIoU 为分割评价指标, 按照不同改进方法, 并通过添加不同注意力机制进行对比实验。实验结果如表 2 所示。其中模型 1 代表在原 DeepLabV3+ 网络的基础上, 将特征提取网络改为更轻量级的 MobileNetV2 网络; 模型 2 代表在模型 1 的基础上, 使用深度可分离卷积替换 ASPP 结构中的膨胀卷积, 并将特征融合后的普通卷积替换为深度可分离卷积。

表 2 消融实验

模型	总参数/	模型	mPA/	mIoU/
	M	大小/MB	%	%
DeepLabV3+	54.7	209	92.09	86.21
模型 1	5.8	22.4	89.13	82.37
模型 2	2.72	10.6	90.44	80.75
模型 2+SE	2.73	10.7	90.53	83.31
模型 2+CBAM ^[25]	2.77	10.7	91.50	83.49
模型 2+GAM ^[26]	7.1	20.5	91.13	83.55
模型 2+ECA(本文)	2.72	10.6	90.70	84.33

由表 2 消融实验结果可得, 相较于原 DeepLabV3+ 网络, 模型 1 参数量减少了 89.4%, 模型大小缩减 89.3%, mPA 与 mIoU 降低 2.96% 和 3.84%, 网络在保证分割精度大不下降的情况下模型变得轻量化, 对硬件的要求降低, 表明了将主干替换为 MobileNetV2 的可行性; 为了能够在完整模拟出目标局部特征间联系的同时降低模型复杂度, 在模型 1 基础上替换 ASPP 中的膨胀卷积并将网络

结构中浅层特征与深层特征融合后的普通卷积也替换为深度可分离卷积后得到更轻量化的模型 2, 参数量仅有 2.7 M, 模型大小仅有 10.6 MB, 其分割指标与模型一相比平均像素准确率稍有提升, 但 mIoU 值下降。为了补偿模型轻量化带来的精度损失, 在模型 2 上添加注意力机制, 加强网络特征提取能力, 分别添加 SE、CBAM、GAM 和 ECA 模块后均像素准确率都有不同程度提高, 平均交并比分别得到 2.56%, 2.74%, 2.8% 和 3.58% 的提升, 其中添加 ECA 注意力机制后效果最明显, 且参数量与模型更小, 对模型几乎没有负担。

5 与其他方法对比

利用采集制作的数据集, 将所提算法与部分较经典图像语义分割算法以及文献[11]中采用的轮对踏面检测算法进行对比, 实验结果如表 3 所示。由表 3 数据可得, PspNet^[27](resnet50)相较于原 DeepLabV3+虽模型较小, 但 mPA 值与 mIoU 值相对较低, 将 PspNet 主干改为轻量化 MobileNetV2 后模型大小明显下降, 但同时 mPA 与 mIoU 也随之下降, 相较于原 DeepLabV3+以及 UNet^[28-29]有较大差距; 主干网络为 Resnet50 的 UNet 网络参数量与 PSPNet(Resnet50)相差不多, 但平均交并比高于 PSPNet。本文算法模型大小与 PSPNet(MobileNetV2)比较接近, 但平均交并比更高, mPA 值与 mIoU 值虽低于原 DeepLabV3+, 但模型仅有 10.6 M, 模型复杂度低, 更加轻量化; 与文献[11]中轮对踏面检测算法相比, 模型更轻便且 mIoU 值与 mPA 值更高。实验结果表明, 本文所提算法在提高模型计算效率的同时保证了分割精度, 实现了轻量化网络与分割精度之间较好的平衡, 更有利于快速准确实现踏面损伤图像的分割识别。

表 3 与其他方法对比

模型	主干	总参数/ M	模型 大小/ MB	mPA/ %		mIoU/ %
				mPA/ %	mIoU/ %	
DeepLabV3+	Xception	54.7	209	92.09	86.21	
PspNet	Resnet50	46.7	178	90.36	82.31	
PspNet	MobileNetV2	2.4	9.3	85.48	79.18	
UNet	Resnet50	43.9	167	89.88	85.12	
文献 ^[11]	VGG16	18.6	71.1	78.13	72.82	
本文	MobileNetV2	2.72	10.6	90.70	84.33	

为了验证本文算法对轮对踏面损伤图像分割的效果, 对部分测试集的分割结果进行可视化, 其结果如图 7 所示, 其中图 7(a)为输入图像, 图 7(b)为标签文件, 图 7(c)为原 DeepLabV3+分割结果, 图 7(d)为模型一对踏面损伤的分割结果, 图 7(e)为改进后的 DeepLabV3+算法分割结果。在图 7 第 1 排中模型一与原 DeepLabV3+网络对于

较小损伤存在漏检现象, 而对 DeepLabV3+进行改进尤其是添加注意力机制后, 模型对损伤区域特征的学习能力加强, 面对部分较小损伤目标也能实现准确识别; 第 2 排中对于像素级别较低的多目标分割, 中间目标的损伤识别中原 DeepLabV3+检测效果最好, 最上方的较大损伤识别中原 DeepLabV3+识别效果优于模型一, 但模型一与原 DeepLabV3+对于部分边缘细节识别不够精确, 改进后的 DeepLabV3+对于损伤边界的识别更加完整; 第 3 排中虽然原网络识别效果更加饱满, 但在方向上有些偏差, 模型一识别区域相对较小, 识别不够完整, 改进后的 DeepLabV3+识别效果有所改善。实验结果表明, 所提算法提高了对目标对象边界的分割效果, 能够准确且较完整的分割出损伤区域。

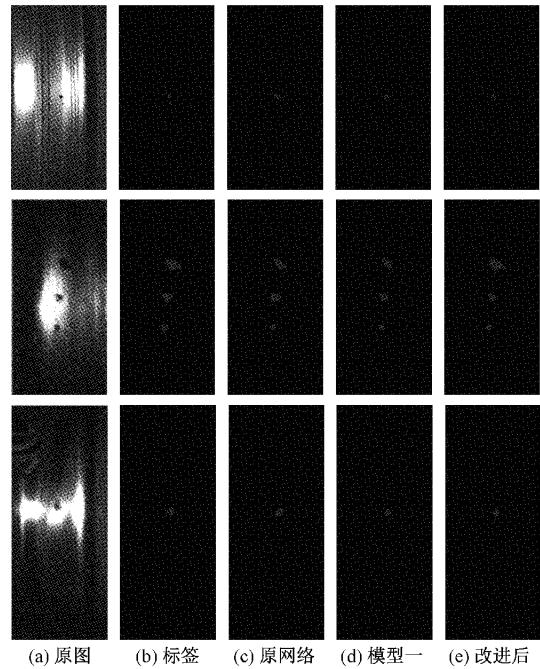


图 7 分割效果对比

6 结 论

本文提出一种改进的 DeepLabV3+ 轮对踏面损伤识别方法, 模型采用 MobileNetV2 网络完成特征提取, 在其输出的深层和浅层特征层上添加 ECA 机制, 避免通道降维并进行跨通道交互, 使模型更加关注重要通道的信息, 其中深层特征层输入到包含深度可分离卷积的 ASPP 中, 经过进一步特征提取后与浅层特征层融合, 后经深度可分离卷积与双线性插值上采样后输出分割结果。改进后的 DeepLabV3+模型对于目标区域的边界识别更加准确, 解决了部分图像存在漏检的情况, 分割效果得到提升。但是本文对于踏面损伤没有进行具体类别上的识别分割, 并且对于数据集包含较少的损伤类型识别效果还有待提升, 今后将继续扩充数据集并对属于不同类别的损伤进行分类,

在保证模型精度的前提下对网络结构进行优化。

参考文献

- [1] 张昆. 基于 ICP 算法的轨道交通车辆轮对踏面检测方法研究[D]. 武汉: 华中科技大学, 2018.
- [2] 张关震, 任瑞铭, 吴斯, 等. 不均匀组织对高速动车组车轮踏面剥离损伤的影响[J]. 中国铁道科学, 2019, 40(5): 80-86.
- [3] 张鑫, 姚庆安, 赵健, 等. 全卷积神经网络图像语义分割方法综述[J]. 计算机工程与应用, 2022, 58(8): 45-57.
- [4] 赵勇. 一种快速轮对踏面光截曲线图像分割方法[J]. 电子技术应用, 2011, 37 (3): 130-132, 136, DOI: 10.16157/j.issn.0258-7998.2011.03.046.
- [5] 史倩, 吴升华. 区域生长的轮对图像分割[J]. 中国图象图形学报, 2012, 17(9): 1122-1127.
- [6] 景庄伟, 管海燕, 彭代峰, 等. 基于深度神经网络的图像语义分割研究综述[J]. 计算机工程, 2020, 46(10): 1-17, DOI: 10.19678/j.issn.1000-3428.0058018.
- [7] 徐辉, 祝玉华, 颜彤, 等. 深度神经网络图像语义分割方法综述[J]. 计算机科学与探索, 2021, 15(1): 47-59.
- [8] 王溪波, 曹士彭, 赵怀慈, 等. 双边特征聚合与注意力机制点云语义分割[J]. 仪器仪表学报, 2021, 42(12): 175-183, DOI: 10.19650/j.cnki.cjsi.J2108289.
- [9] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431-3440.
- [10] 秦松岩. 基于深度学习的火车轮对踏面图像分割[D]. 石家庄: 石家庄铁道大学, 2019, DOI: 10.27334/d.cnki.gstdy.2019.000292.
- [11] 杨玲, 高军伟. 基于 FCN 的轮对踏面检测技术[J]. 电子测量技术, 2022, 45(1): 117-121, DOI: 10.19651/j.cnki.emt.2108017.
- [12] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 801-818.
- [13] 胡新荣, 龚闯, 张自力, 等. 基于改进 DeepLabv3+ 的服装图像分割网络[J/OL]. 计算机工程: 1-9 [2022-03-27]. DOI: 10.19678/j.issn.1000-3428.0062392.
- [14] 朱昊昱, 孙俊, 陈祺东. 基于 DeepLabv3+ 的多任务图像拼接篡改检测算法[J]. 计算机工程, 2022, 48(1): 253-259, DOI: 10.19678/j.issn.1000-3428.0060026.
- [15] 白欢欢. 一种融合多注意力机制的服饰分割方法研究[J]. 国外电子测量技术, 2021, 40(7): 52-58, DOI: 10.19652/j.cnki.femt.2102625.
- [16] 孟琭, 徐磊, 郭嘉阳. 一种基于改进的 MobileNetV2 网络语义分割算法[J]. 电子学报, 2020, 48(9): 1769-1776.
- [17] 陈德刚, 艾孜尔古丽, 尹鹏博, 等. 基于改进 Xception 迁移学习的野生菌种类识别研究[J]. 激光与光电子学进展, 2021, 58(8): 245-254.
- [18] CHOLLET F. Xception: Deep learning with depthwise separable convolutions [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017.
- [19] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 3-8.
- [20] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 40(4): 834-848.
- [21] 任鸿杰, 刘萍, 岳超, 等. 改进 DeepLabV3+ 网络的遥感影像农作物分割方法[J]. 计算机工程与应用, 2022, 58(11): 215-223.
- [22] 黎万义, 王鹏, 乔红. 引入视觉注意机制的目标跟踪方法综述[J]. 自动化学报, 2014, 40(4): 561-576.
- [23] 程晓悦, 赵龙章, 胡穹, 等. 基于密集层和注意力机制的快速语义分割[J]. 计算机工程, 2020, 46(4): 247-252, 259, DOI: 10.19678/j.issn.1000-3428.0054245.
- [24] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.
- [25] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module [C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3-19.
- [26] LIU Y, SHAO Z, HOFFMANN N. Global attention mechanism: Retain information to enhance channel-spatial interactions [J]. ArXiv Preprint, 2021, ArXiv:2112.05561.
- [27] ZHAO H S, SHI J P, QI X J, et al. Pyramid scene parsing network [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017.
- [28] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [C]. International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer, Cham, 2015: 234-241.
- [29] 何晓云, 许江淳, 陈文绪. 基于改进 U-Net 网络的眼底血管图像分割研究[J]. 电子测量与仪器学报, 2021, 35(10): 202-208, DOI: 10.13382/j.jemi.B2003781.

作者简介

孙耀泽, 硕士研究生, 主要研究方向为智能系统与智能控制。
E-mail: 486695900@qq.com

高军伟, 博士, 教授, 主要研究方向为智能系统与智能控制。
E-mail: qdgao163@163.com