

改进型 DSSD 算法在道路损伤检测中的应用研究*

苏可¹, 郭学俊², 杨莹³, 陈泽华²

(1. 太原理工大学 电气与动力工程学院, 山西 太原 030024;

2. 太原理工大学 大数据学院, 山西 晋中 030600; 3. 山西省交通科技研发有限公司, 山西 太原 030006)

摘要: 在自动检测中, 由于道路损伤数据集存在小目标损伤难检测与类别不平衡问题, 导致道路损伤检测的准确率、虚假率高。为此, 在 DSSD(Deconvolutional Single Shot Detector)网络模型的基础上, 提出一种结合注意力机制和 Focal loss 的道路损伤检测算法。首先, 采用识别精度更高的 ResNet-101 作为 DSSD 模型的基础网络; 其次, 在 ResNet-101 主干网络中添加注意力机制, 采用通道域注意力和空间域注意力相结合的方式, 实现特征在通道维度上的加权与空间维度上的聚焦, 提升对小目标道路损伤的检测效果; 最后, 为了减少简单样本的权重, 增大难分类样本的权重, 使用 Focal loss 来提高整体的检测效果。在 Global Road Damage Detection Challenge 比赛所提供的数据集上进行验证, 实验结果表明, 该模型的平均精度均值为 83.95%, 比基于 SSD 和 YOLO 网络的道路损伤检测方法的准确率更高。

关键词: 道路损伤检测; DSSD 目标检测算法; 小目标检测; 注意力机制; 类别不平衡; 焦点损失函数

中图分类号: TP391.41

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.211684

中文引用格式: 苏可, 郭学俊, 杨莹, 等. 改进型 DSSD 算法在道路损伤检测中的应用研究[J]. 电子技术应用, 2021, 47(12): 64-68, 99.

英文引用格式: Su Ke, Guo Xuejun, Yang Ying, et al. Research on application of improved DSSD algorithm in road damage detection[J]. Application of Electronic Technique, 2021, 47(12): 64-68, 99.

Research on application of improved DSSD algorithm in road damage detection

Su Ke¹, Guo Xuejun², Yang Ying³, Chen Zehua²

(1. College of Electrical and Power Engineering, Taiyuan University of Technology, Taiyuan 030024, China;

2. College of Data Science, Taiyuan University of Technology, Jinzhong 030600, China;

3. Shanxi Transportation Technology Research and Development Co., Ltd., Taiyuan 030006, China)

Abstract: In the automatic detection, the road damage data set has the problems of difficult detection of small target damage and imbalance of categories, resulting in low accuracy and high false rate of road damage detection. For this reason, based on the DSSD(deconvolutional single shot detector) network model, a road damage detection algorithm combining attention mechanism and Focal loss is proposed. First of all, ResNet-101 with higher recognition accuracy is used as the basic network of the DSSD model. Secondly, an attention mechanism is added to the ResNet-101 backbone network, and the channel domain attention and spatial domain attention are combined to achieve the weighting of features in the channel dimension and the focus on the spatial dimension, and improve the detection effect of small target road damage. Finally, in order to reduce the weight of simple samples and increase the weight of difficult-to-classify samples, Focal loss is used to improve the overall detection effect. It is verified on the data set provided by the Global Road Damage Detection Challenge competition. The experimental results show that the average accuracy of the model is 83.95%, which is more accurate than the road damage detection method based on SSD and YOLO network.

Key words: road damage detection; DSSD target detection algorithm; small target detection; attention mechanism; category imbalance problem; Focal loss

0 引言

道路建设是衡量国家现代化水平的重要指标之一, 我国道路交通网庞大复杂, 道路养护问题凸显。如何从道路图像快速准确地检测出损伤区域及类型成为学者

研究的热点。

随着深度学习的快速发展, 使用卷积神经网络(Convolution Neural Network, CNN)^[1]自主地从数据集中提取相应特征信息成为主流方法, 如快速的 R-CNN^[2]、SSD^[3]、YOLO^[4]等。这些网络能够定位和识别图中具有边界框的对象, 为复杂背景下道路检测提供了有效的框架。

* 基金项目: 山西交通控股集团有限公司重点研发科技项目(19-JKKJ-2); 国家自然科学基金(11305115)

Li^[5]等人运用 R-CNN 自动定位和识别了不同照明条件下的 6 种道路损伤,稳定性较高,但是实时性很差。路雪^[6]等人使用 Fast R-CNN 网络对特征进行规格化和并行回归计算得到非机动车的目标检测模型,但不适用于目标检测。Yuan^[7]等使用灰度值阈值分割法对道路裂缝进行识别,但不适合于裂缝与背景差异不明显的情况。阮小丽^[8]等使用连通区域的方法识别较小裂缝的宽度,但不能排除灰度差异的干扰。YANG^[9]等使用全卷积网络(FCN)来检测不同裂缝,存在较大误差。王森^[10]等使用 Crack FCN 模型解决了复杂背景下的裂缝检测,但是检测效率有待提高。Zhou^[11]等使用裂缝碎片拼接和图像处理办法,实现了对裂缝宽度的高精度测量,但是在复杂背景下的裂缝识别准确度较低。YOLO 网络最先实现了实时检测目标,但是没有生成先验框,所以定位误差较大。沈新烽^[12]等人使用 SSD 目标检测算法,减小了原始图像的输入尺寸并引入了特征金字塔网络,能实现多个分辨率不同的特征映射预测,并在单个网络中实现了区域分类和坐标回归的封装。因此,SSD 的速度和精确度优于 YOLO。但是 SSD 算法的浅层特征图的表示能力不强,导致其在复杂背景的道路损伤检测中对难分类目标会出现漏检。

综上,在道路损伤图像检测中,主要存在如下问题:(1)网络对道路损伤类型识别精度不高;(2)小目标损伤存在漏检;(3)道路损伤数据集样本类别不平衡问题。

针对上述问题,受到注意力机制和 Focal loss 的启发,本文提出使用 DSSD 算法,将注意力机制与主要特征提取网络结构 ResNet-101 相结合,使不同模块的特征随着网络的加深产生适应性改变,保留小目标损伤的位置信息。同时,采用了焦点损失函数(Focal loss),通过调整简单样本和复杂样本的权重,降低了简单样本对复杂样本的影响,同时也降低了裂缝在图像中占比远远少于背景

像素的问题,加速了模型的收敛,提高了难分类损伤的检测准确率,使整体的检测精度有效提高。

1 相关技术

1.1 SSD 算法原理

Wei Liu 在 ECCV2016 上提出基于 SSD 的目标检测算法,算法提取特征的骨干网络为 VGG16^[13],采用多种尺度的特征进行目标检测。网络以 300 px×300 px 的图像作为输入。网络中 Conv4_3、FC7 层作为浅层特征,特征尺寸较大,包含的细节信息较多,用来检测小目标物体。网络中 Conv8_2、Conv9_2、Conv10_2、Conv11_2 层作为深层特征,这些层感受野比较大,包含的语义信息比较多,用来检测大目标物体。SSD 的算法框架如图 1 所示。

从图 1 中可以看出,SSD 算法虽然采用了多尺度特征进行目标检测,但是 Conv4_3 层网络比较浅,能够得到的语义信息就会减少,对难分类道路损伤特征的提取能力下降,最终导致整个网络对难分类损伤的检测精度较差,无法满足对道路损伤中难分类损伤的检测精度要求。

1.2 DSSD 算法原理

DSSD 算法^[14]框架如图 2 所示。

对比 SSD 网络,DSSD 网络用 ResNet-101 替换 VGG 网络,在分类回归之前引入了残差模块,并且在 SSD 的辅助卷积层后添加了反卷积层,使 DSSD 网络的整体结构呈现为“宽-窄-宽”的“沙漏”结构,即“encoder-decoder”结构。其目的是将高层语义信息和低层语义信息进行融合,丰富预测回归位置框和分类任务输入的多尺度特征图,以此提高精度。

2 改进的 DSSD 网络结构

2.1 注意力机制

注意力机制^[15]的主要思想是给关键特征标识权重,进而获得图像中的有用区域。视觉注意力包括软注意力




图 1 SSD 算法框架

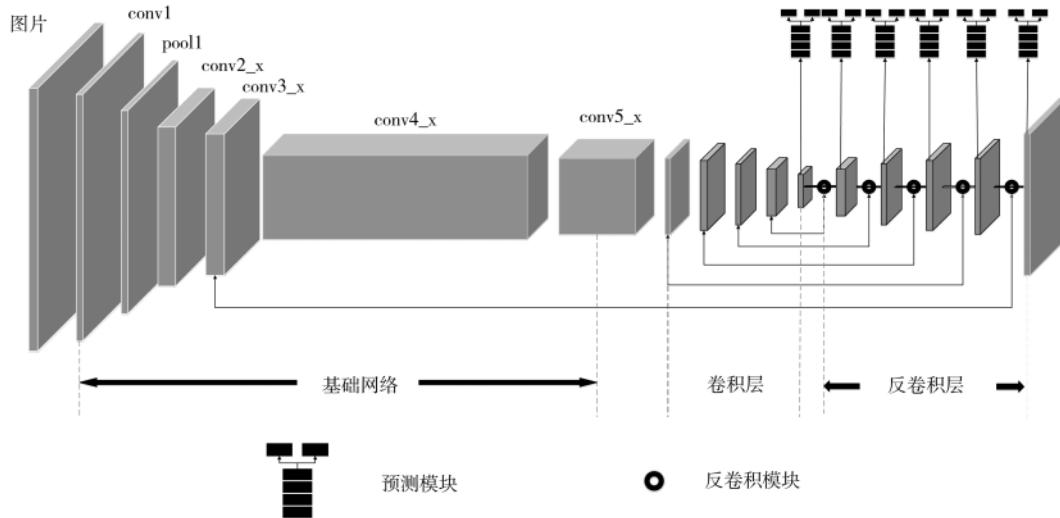


图 2 DSSD 算法框架

和强注意力。软注意力又包括空间域注意力、通道域注意力和混合域注意力。

软注意力中的空间域注意力的实现如图 3 所示。将原始图片中的空间信息变换到另一个空间中,增强了特征在空间中的位置信息,实现了空间维度上的特征聚焦,从而提升了小目标损伤的捕获效果。




图 3 空间注意力模块

空间域注意力的计算公式如下:

$$M_s(F) = \text{BN}(f_3^{1 \times 1}(f_2^{3 \times 3}(f_1^{3 \times 3}(f_0^{1 \times 1}(F)))))) \quad (1)$$

其中, $M_s(F)$ 表示空间注意力, f 代表卷积操作, 1×1 表示滤波器尺寸为 1, BN 表示批标准化 (Batch Normalization), 3×3 是空洞卷积。

通道域注意力的原理如图 4 所示。由于每一张图片都是由 R、G、B 三通道表示的,在神经网络中经过不同的卷积核之后,每一个通道又会生成新的信号,给每个通道上的信号都增加一个权重来调整通道与关键信息的相关度,这个权重越大,则表示相关度越高,这个通道越重要。




图 4 通道注意力模块

通道域注意力的计算公式如下:

$$M_c(F) = \text{BN}(\text{MLP}(\text{AvgPool}(F))) \\ = \text{BN}(W_1(W_0 \text{AvgPool}(F) + b_0) + b_1) \quad (2)$$

其中, $M_c(F)$ 代表通道注意力, MLP 代表多层感知器, $W_0 \in R^{C/r \times C}$, $b_0 \in R^{r \times C}$, $W_1 \in R^{C/r \times C}$, $b_1 \in R^C$, C 表示图像的通道数, r 表示压缩率。图 3、图 4 中的 BN 操作相同,用来保证两个注意力模块输出一致。

2.2 结合注意力的 ResNet-101 网络

DSSD 利用反卷积操作,单向融合高低层特征,提高了整体目标检测效果,但并不适用于小目标道路损伤检测。此时将注意力机制添加到 DSSD 提取特征的骨干网络 ResNet-101 中,对特征信息进行筛选,抑制非目标区域的特征,使得网络在特征提取过程中更关注小目标损伤区域特征,提升检测效果。

在 ResNet-101 中添加注意力的方法如图 5 所示。




图 5 添加注意力机制的 ResNet-101

在 ResNet-101 网络的一个阶段结束后,将得到的特征图分别输入空间注意力和通道注意力模块,得到 $M_s(F)$ 和 $M_c(F)$;再将两者进行求和,然后用 sigmoid 函数得到一个取值为 0 到 1 的最终注意力的映射 $M(F)$,公式如下:

$$M(F) = \sigma(M_s(F) + M_c(F)) \quad (3)$$

把最终的注意力图与最初输入的特征图 F 进行逐元素相乘的操作,然后将其加入到原始输入特征图上,得到细化后的特征图 F' ,再输入到 ResNet-101 的下一个阶段中。 F' 的公式如下所示:

$$F' = F + F \otimes M(F) \quad (4)$$

2.3 Focal loss

本文选择的数据集是由手机现场拍摄的图像,存在

以下问题:(1)数据集各种损伤类型的数据复杂度不同,即类内不平衡问题,简单样本(坑洼、明显的长裂缝、人行横道线模糊等)的数量和复杂样本(细小裂缝)的数量相差较大;(2)受裂缝自身宽度、深度、方向的影响,细微裂缝与背景对比度弱且难以表现出完整的几何形态,使目标像素在图像中的占比远远少于背景像素,即类间不平衡问题。为解决这些问题,本文选择使用 Focal loss^[16] (焦点损失函数)替换了 DSSD 网络原本的损失函数。

Focal loss 的函数公式如下:

$$FL(p_i) = -(1 - p_i \times p_g)^\gamma \log(p_i) \quad (5)$$

式中, p_i 为预测样本的预测概率, p_g 为真实样本的预测概率。Focal loss 给经典的交叉熵损失函数添加了调制系数 $(1 - p_i \times p_g)^\gamma$, 其中的 γ 为大于零的聚焦参数。因为调制系数的值在 0~1 之间, 所以整体的 loss 值会变小, 但是简单样本和复杂样本的预测概率 p_i 值相差较大, 所以二者使 loss 值减小的数值经过 γ 调整后 would 相差较大, 最终改变两者对于模型的影响程度。

通过不断调整参数 γ 的值, 使简单样本在图像中的权重减小, 复杂样本在图像中的权重增加, 实现模型整体性能的提升。

3 实验结果与分析

3.1 数据集介绍

表 1 列出了不同的损伤类型及其定义。在本文中, 每种损伤类型都用一个标签(如 D00)表示。

表 1 道路损伤类型

损伤类型	细节描述	损伤标签
裂缝	纵向的	车辙损伤 D00
		施工损伤 D01
	横向的	车辙损伤 D10
		施工损伤 D11
网状裂缝	局部和整体路面	D20
其他损伤	车辙、颠簸、坑洼	D40
	人行横道模糊	D43
	白线模糊	D44
图像误差	雨刷器遮挡	D30

本文的数据集由 5 590 个标记的道路损伤图像组成, 11 639 个损伤边界框被标记。其中, 训练集包含 3 090 幅图像, 测试集包含 2 500 幅图像。

3.2 实验环境与参数

本文实验环境为 Windows 10 的 Intel COREi7, 显卡是 Nvidia GeForce GTX 1660 Ti, 主频是 2.6 GHz, 内存是 8 GB, 基于 pytorch1.2 框架, 用 Python 语言实现。使用标准梯度下降法训练模型, 参数设置: 批处理量为 8, 基础学习率和权重衰减均为 0.000 1。

3.3 评价指标

目标检测的核心是目标识别准确率和实时性。mAP (mean Average Precision) 是衡量算法准确度的重要指标^[17], 其值越大性能越好。Fps (Frames per second) 是每秒识别的图像数, 用来评价算法的检测速度。

3.4 实验结果对比

在 DSSD 网络中添加注意力机制后, 实现了特征在通道维度上的加权与空间维度上的聚焦, 使网络可以更好地对小目标道路损伤进行检测, 图 6 所示为对比效果。



图 6 改进的 DSSD(左)与原 DSSD(右)

与 DSSD 相比, 改进的 DSSD 可以检测到更多较小的道路损伤(左图目标框变多), 且精确度提升。

为比较 Focal loss 中不同 γ 值对模型检测不同类型损伤平均精度值(AP)的影响, 将基于不同 γ 值的模型在道路损伤数据集上进行测试, γ 的值分别取 0、0.1、0.5、1、2、5。得到的实验结果如表 2 所示。

从表 2 中可以得出, 综合各类损伤的平均精度均值, 当 γ 的取值为 2 时, Focal loss 效果最好。

为了验证道路损伤检测模型的可行性, 将目前用于道路损伤检测的算法与小目标检测算法以及本文模型进行对比, 包括 SSD 算法^[18]、YOLOv3 算法^[19]以及原始的 DSSD 算法^[14]。其中, 对比网络的参数设置与原论文中相同。在道路损伤图像数据集上进行目标检测, 表 3 展示了

表 2 不同取值下各类损伤的 AP 值

γ	D00	D01	D10	D11	D20	D40	D43	D44	D30
0	0.854 7	0.851 9	0.478 3	0.497 3	0.875 9	0.806 2	0.881 2	0.902 7	0.693 1
0.1	0.865 8	0.862 6	0.494 1	0.537 9	0.895 5	0.816 7	0.889 7	0.924 3	0.738 9
0.5	0.869 9	0.871 4	0.540 7	0.549 0	0.907 9	0.821 7	0.904 3	0.913 3	0.762 5
1	0.886 0	0.889 1	0.601 8	0.628 9	0.921 9	0.847 7	0.912 4	0.909 2	0.796 5
2	0.912 8	0.908 6	0.638 4	0.669 7	0.911 7	0.863 3	0.916 2	0.897 8	0.837 2
5	0.899 5	0.894 6	0.632 7	0.685 6	0.908 3	0.841 7	0.925 3	0.888 5	0.807 9

表 3 不同算法平均精度(AP)对比

算法	D00	D01	D10	D11	D20	D40	D43	D44	D30
SSD	0.731 6	0.877 8	0.385 6	0.481 6	0.897 5	0.749 2	0.856 5	0.931 3	0.545 5
YOLO	0.889 4	0.913 2	0.448 7	0.584 9	0.872 6	0.827 9	0.899 1	0.917 3	0.663 5
原 DSSD	0.854 7	0.851 9	0.478 3	0.497 3	0.875 9	0.806 2	0.881 2	0.902 7	0.693 1
本文	0.912 8	0.908 6	0.638 4	0.669 7	0.911 7	0.863 3	0.916 2	0.897 8	0.837 2

道路损伤数据集中各类损伤的平均精度对比。从表中可以看出,改进的 DSSD 算法比 SSD 算法、YOLOv3 算法和原 DSSD 算法在大部分损伤检测的平均精度上均有提高。

表 4 为 3 种算法的平均精度均值与实时性的对比。由于本文在原 DSSD 网络的基础上添加了注意力机制,加大了网络的计算量,网络的检测速率为 15.4 帧/s,但是与原 DSSD 网络的检测速率相差不大,同样可以满足实时性的需求。然而本文方法的 mAP 值比 SSD 算法、YOLO 算法与 DSSD 算法分别提高了 12.21%、5.99% 与 7.94%。

表 4 平均精度均值与实时性对比

算法	mAP	Fps/(帧/s)
SSD	0.717 4	21.7
YOLO	0.779 6	23.9
原 DSSD	0.760 1	16.5
本文	0.839 5	15.4

3.5 检测效果对比

在不同场景下,改进的 DSSD 算法、SSD 算法、YOLO 算法对道路损伤检测结果如图 7 所示。从图中可以直观地看出,改进的 DSSD 算法比 SSD 算法与 YOLO 算法检测到了更多类型的缺陷,包括目标更小的道路损伤,而且准确度更高,直观地证明了本文提出的改进的 DSSD 算法能有效提高对复杂场景下各种类型道路损伤的检测精度。

4 结论

本文提出了一种基于改进 DSSD 的道路损伤识别方法。以 ResNet-101 作为基础网络,结合注意力机制实现

小目标损伤检测精确度的提升,采用 Focal loss 解决了数据集样本类别不平衡导致的检测准确度低的问题。实验结果表明,经过训练,得到改进的道路损伤检测模型 DSSD 的 mAP 为 83.95%,且在大部分道路损伤类型的精确度(AP)均优于 SSD、YOLO 与原 DSSD 等网络的道路损伤检测方法。同时,相比 SSD、YOLO 与 DSSD 等方法,改进的 DSSD 方法在检测小目标道路损伤时也具备更高的准确性。该方法在实际应用中具有一定的实践和现实意义。本文方法的不足之处和未来需要做的工作如下:

(1)本文使用的 DSSD 网络模型结合了注意力机制,计算量有所增加,导致 Fps 下降,虽然满足实时性的需求,但是未来可以通过优化 DSSD 网络模型来提高检测速度。

(2)道路损伤的类型较多,本文算法的 AP 值并不是所有类型都是最优的。因此,未来可以继续研究如何提高其他种类损伤的检测精确度。

参考文献

[1] ALEX K,ILYA S,GEOFFREY E H.ImageNet classification with deep convolutional neural networks[J].Communications of the ACM,2017,60(6):84-90.

[2] REN S,HE K,GIRSHICK R,et al.Faster R-CNN:towards real-time object detection with region proposal networks[J].IEEE Transactions on Pattern Analysis & Machine Intelligence,2017,39(6):1137-1149.

[3] LIU W,ANGUELOV D,ERHAN D,et al.SSD:single shot multibox detector[C]//European Conference on Computer Vision.Springer,Cham,2016:21-37.

[4] REDMON J,DIVVALA S,GIRSHICK R,et al.You only look once:unified,real-time object detection[C].2016 IEEE Con-



图 7 改进的 DSSD(左)、SSD(中)、YOLO(右)算法结果对比

(下转第 99 页)

- 中国科学报, 2016-05-17(001).
- [2] 胡俊, 沈昌祥, 公备. 可信计算 3.0 工程初步[J]. 网络与信息安全学报, 2017, 3(9): 79.
- [3] 陈卫平. 可信计算 3.0 在等级保护 2.0 标准体系中的作用研究[J]. 信息安全研究, 2018, 4(7): 633-638.
- [4] 沈昌祥. 用主动免疫可信计算构筑新型基础设施网络安全保障体系[J]. 网信军民融合, 2020, 35(4): 12-15.
- [5] 徐意泊, 陈富浩, 丁振华, 等. 基于国产龙芯 2K1000 龙芯派的内核系统启动[J]. 现代信息科技, 2018, 2(12): 29-34.
- [6] 王冠. TPCM 及可信平台主板标准[J]. 中国信息安全, 2015(2): 66-68.
- [7] 易平. 基于龙芯处理器的嵌入式可信系统的设计与实现[D]. 南京: 南京航空航天大学, 2018.
- [8] 易平, 庄毅. 基于龙芯处理器的嵌入式可信解决方案[J]. 计算机技术与应用, 2018, 28(5): 112-116.
- [9] 张景桢. 基于 LINUX 的可信软件基的设计与实现[D]. 北京: 北京工业大学, 2017.
- [10] 孙瑜, 王溢, 洪宇, 等. 可信软件基技术研究及应用[J]. 信息安全研究, 2017, 3(4): 316-322.

- [11] 张家伟. 基于 Linux 的可信计算平台研究与实现[D]. 北京: 北京邮电大学, 2018.
- [12] 周培莹. 可信 I/O 资源访问控制策略研究与应用[D]. 南京: 南京理工大学, 2009.
- [13] 曹喆, 王以刚. 基于 USBKey 的身份认证机制的研究与实现[J]. 计算机应用与软件, 2011, 28(2): 284-286.
- [14] 于颖超, 徐宁, 李立新. 一种可信增强的访问控制框架的设计与实现[J]. 电子技术应用, 2009, 35(1): 143-143.
- [15] 郭晋. 基于可信计算的嵌入式 Linux 内核安全性加固的研究[D]. 成都: 电子科技大学, 2011.

(收稿日期: 2021-01-29)

作者简介:

孟祥斌(1995-), 通信作者, 男, 硕士, 主要研究方向: 信息安全、密码学, E-mail: xiangbinmeng@foxmail.com。

刘笑凯(1977-), 男, 硕士, 高级工程师, 主要研究方向: 信息安全、密码学。

郝克林(1992-), 男, 硕士, 工程师, 主要研究方向: 信息安全、密码学。



扫码下载电子文档

(上接第 68 页)

- ference on Computer Vision & Pattern Recognition, 2015.
- [5] LI J, ZHAO X, LI H. Method for detecting road pavement damage based on deep learning[C]//SPIE Smart Structures + Nondestructive Evaluation, 2019.
- [6] 路雪, 刘坤, 程永翔. 一种深度学习的非机动车目标检测算法[J]. 计算机工程与应用, 2019, 55(8): 188-194, 220.
- [7] Yuan Weiqi, Xue Dan. Overview of detection algorithms for tunnel lining cracks based on machine vision[J]. Journal of Instrumentation, 2017, 38(12): 3100-3111.
- [8] 阮小丽, 王波, 荆国强, 等. 桥梁混凝土结构表面裂缝自动识别技术研究[J]. 世界桥梁, 2017, 45(6): 55-59.
- [9] YANG X C, LI H, YU Y T, et al. Automatic pixel-level crack detection and measurement using fully convolutional network[J]. Computer-Aided Civil and Infrastructure Engineering, 2018, 33(12): 1090-1109.
- [10] 王森, 伍星, 张印辉, 等. 基于深度学习的全卷积网络图像裂缝检测[J]. 计算机辅助设计与图形学学报, 2018, 30(5): 859-867.
- [11] Zhou Ying, Liu Tong. Recognition of concrete cracks based on computer vision[J]. Journal of Tongji University(Natural Science), 2019, 47(9): 1277-1285.
- [12] 沈新烽, 姜平, 周根荣. 改进 SSD 算法在零部件检测中的应用研究[J]. 计算机工程与应用, 2021, 57(7): 257-262.
- [13] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv preprint arXiv: 1409.1556, 2014.

- [14] Fu Chengyang, LIU W, RANGA A, et al. DSSD: deconvolutional single shot detector[J]. ArXiv abs/1701.06659, 2017.
- [15] 雷华迪, 陈东方, 王晓峰. 基于级联 SSD 的目标检测算法[J]. 计算机工程与设计, 2020, 41(12): 225-232.
- [16] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//2017 IEEE International Conference on Computer Vision (ICCV). IEEE, 2017: 2999-3007.
- [17] 张琳娜, 陈建强, 陈晓玲, 等. 面向行车视频目标实时检测的轻量级 SSD 网络[J]. 计算机科学, 2019, 46(7): 233-237.
- [18] 陈幻杰, 王琦琦, 杨国威, 等. 多尺度卷积特征融合的 SSD 目标检测算法[J]. 计算机科学与探索, 2019, 13(6): 1049-1061.
- [19] 蔡逢煌, 张岳鑫, 黄捷. 基于 YOLOv3 与注意力机制的桥梁表面裂痕检测算法[J]. 模式识别与人工智能, 2020, 33(10): 62-69.

(收稿日期: 2021-04-22)

作者简介:

苏可(1995-), 男, 硕士研究生, 主要研究方向: 遥感图像处理。

郭学俊(1982-), 男, 博士, 讲师, 主要研究方向: 遥感图像处理。

陈泽华(1974-), 通信作者, 女, 博士, 教授, 主要研究方向: 智能信息处理和智能控制、粒计算和知识工程、图像处理、区块链、工业大数据, E-mail: zehuachen@163.com。



扫码下载电子文档

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所