



计算机科学

COMPUTER SCIENCE

基于YOLOv5的湿润沥青路面裂缝检测

张恩华, 王卫杰, 段楠, 康楠

引用本文

张恩华, 王卫杰, 段楠, 康楠. [基于YOLOv5的湿润沥青路面裂缝检测](#)[J]. 计算机科学, 2023, 50(11A): 220900155-5.

ZHANG Enhua, WANG Weijie, DUAN Nan, KANG Nan. [Asphalt Pavement Crack Detection in Wetting Conditions Based on YOLOv5](#) [J]. Computer Science, 2023, 50(11A): 220900155-5.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于边缘引导的多尺度医学影像分割方法](#)

Medical Image Segmentation Based on Multi-scale Edge Guidance

计算机科学, 2023, 50(11A): 220900059-7. <https://doi.org/10.11896/jsjcx.220900059>

[基于语义注意力的医学图像超分辨率方法](#)

Medical Image Super-resolution Method Based on Semantic Attention

计算机科学, 2023, 50(11A): 221200107-6. <https://doi.org/10.11896/jsjcx.221200107>

[一种基于因果推理的垃圾分类方法](#)

Novel Method for Trash Classification Based on Causal Inference

计算机科学, 2023, 50(11A): 220800218-6. <https://doi.org/10.11896/jsjcx.220800218>

[接诉即办智能派单业务调度算法研究](#)

Study on Scheduling Algorithm of Intelligent Order Dispatching

计算机科学, 2023, 50(11A): 230300029-7. <https://doi.org/10.11896/jsjcx.230300029>

[基于LSTM神经网络的QPSK智能接收机设计](#)

Design of QPSK Intelligent Receiver Based on LSTM Neural Network

计算机科学, 2023, 50(11A): 230200219-5. <https://doi.org/10.11896/jsjcx.230200219>

基于 YOLOv5 的湿润沥青路面裂缝检测

张恩华 王卫杰 段楠 康楠

南京工业大学交通运输工程学院 南京 211816

(1813631150@qq.com)

摘要 为探究湿润环境对沥青路面裂缝自动检测效果的影响,文章通过 YOLOv5 深度学习目标检测算法,建立了沥青路面裂缝检测模型;并在此基础上,设置了湿润与干燥环境下的裂缝检测对比实验,对比了在两种环境下沥青路面裂缝检测结果的准确度与置信度。研究表明,湿润环境扩大了沥青路面裂缝在深度学习网络中的识别特征,提高了裂缝检测的效果。干燥路面裂缝检测的准确度为 80.70%,湿润路面裂缝检测的准确度为 89.47%,湿润环境下的沥青路面裂缝检测模型准确率提升了 8.77%。同时,统计同一裂缝两种环境下检测的置信度发现,置信度平均值在干燥环境下为 0.72,在湿润环境下为 0.78,且湿润与否与裂缝检测的置信度存在显著正相关关系。研究成果为沥青路面裂缝自动检测效果的提升提供了新的思路,为路面养护管理的决策提供了有效工具。

关键词: 智能交通;裂缝检测;深度学习;YOLOv5;湿润

中图分类号 U416.217

Asphalt Pavement Crack Detection in Wetting Conditions Based on YOLOv5

ZHANG Enhua, WANG Weijie, DUAN Nan and KANG Nan

School of Transportation Engineering, Nanjing Tech University, Nanjing 211816, China

Abstract To investigate the influence of wet environment on automatic crack detection of asphalt pavement, through YOLOv5 target detection algorithm that based on the principle of deep learning, an asphalt pavement crack detection model is established. Based on the model, a comparison experiment of crack detection under wet and dry conditions is set up, the accuracy and confidence of crack detection results of asphalt pavement under the two conditions are compared. The research results show that the wet environment expands the identification features of pavement cracks in the deep learning network, improves the effect of pavement crack detection. The accuracy of crack identification on dry pavement is 80.70%, the accuracy of crack detection on wet pavement is 89.47%, the accuracy of crack detection model on asphalt pavement under wet conditions is improved by 8.77%. At the same time, It is found that the average value of confidence is 0.72 in dry environment and 0.78 in wet environment, and there is a significant positive correlation between wetting and the confidence of crack detection. The research results provide a new idea for the improvement of automatic crack detection of asphalt pavement and an effective tool for pavement maintenance management.

Keywords Intelligent transportation, Crack detection, Deep learning, Object detection, YOLOv5, Wetting conditions

裂缝作为路面病害最主要的形式,会严重影响公路的服务水平。随着时间推移,裂缝会破坏路基的正常结构,引起路面沉降或坍塌,不仅使公路使用寿命缩减,对行驶车辆来说也是巨大的安全隐患^[1]。及时进行路面养护以防止裂缝状况恶化,可以减少养护费用,节省车辆燃油消耗,提高行车安全性与舒适性^[2]。准确高效地获取路面裂缝信息是道路养护的重要任务,而以人工监测为主的传统裂缝检测方式耗时耗力,受环境因素影响较大,且检测过程会妨碍正常道路交通,已经不能满足我国建立高效公路网的需求^[3]。

近年来,随着计算机技术的快速发展,基于数字图像处理的自动检测技术因其检测精度高、速度快等特点,迅速成为裂缝检测研究的热点^[4]。传统的机器学习方法已被广泛应用于裂缝的图像分类与检测等研究。Dong 等^[5]通过 k -均值聚类、

谱聚类等多级聚类算法来提取裂缝对象,进行了裂缝宽度的计算。Fujita 等^[6]使用 SVM 分类器训练路面图像的多尺度特征,实现了像素级路面裂缝图像的分类。以卷积神经网络为代表的深度学习方法可以自动进行图像特征学习,在裂缝自动检测研究中逐渐成为新的关注点。Mei 等^[7]将考虑像素连通性的深度神经网络用于裂缝自动检测,通过转置卷积层进行多层特征融合,提出了一种新的基于深度学习的路面裂缝自动检测方法。Li 等^[8]利用重叠滑动窗口切割裂缝图像建立裂缝数据集,提出了一种基于交错低秩群卷积混合深度网络的裂缝分类算法。Chen 等^[9]利用 segNet 体系结构,提出了一种具有全卷积神经网络的编码器-解码器结构模型用于裂缝检测。

裂缝图像获取与预处理方法的改进可以提高图像处理

基金项目:全球道路安全合作伙伴基金(GRSP)(CHNXX-RD16-1185);江苏省研究生科研与实践创新计划(SJCX21_0547)

This work was supported by the Global Road Safety Partnership(CHNXX-RD16-1185) and Postgraduate Research&Practice Innovation Program of Jiangsu Province(SJCX21_0547).

通信作者:王卫杰(wangwj2009@qq.com)

效率,其发展也受到关注。路面裂缝检测的图像中受到路面纹理等噪声的影响,Wang 等^[10]利用多方向拟合的区域生长方法联合 HSV 颜色空间阈值进行路面区域分割,结合显著性分析的边缘检测算法识别路面裂缝片段,实现对复杂裂缝与路面纹理噪声的区分。Fan 等^[11]利用中层结构信息和监督学习策略进行边缘检测,以从噪声中更准确地识别裂缝。增加裂缝图像获取的角度,利用三维图像识别的方法能帮助算法更加高效地提取裂缝特征。Song 等^[12]利用映射变换关系突出裂缝信息以提高裂缝识别精度,使用双相机立体摄像测量进行路面损坏裂缝识别,实现了路面裂缝图像的快速识别。Qiu 等^[13]设计了一种多特征检验方法从 4 个方向的图像截面获取裂缝截面,提升了路面三维裂缝识别精度。

裂缝图像特征提取与学习的效率是提高路面裂缝检测准确度的关键,路面环境的湿润与否同样会影响裂缝的图像特征。因此,本文采集干燥与湿润两种环境下的沥青路面裂缝图像,运用 YOLOv5 深度学习目标检测算法建立沥青路面裂缝检测模型,并通过对比实验以比较湿润与干燥环境下的裂缝检测效果,初步探讨湿润环境对沥青路面裂缝自动检测效果的影响,为沥青路面养护工作的有效开展提供支持。

1 方法原理

1.1 湿润粗糙表面的光线传播

Angstrom 等^[14]认为粗糙材料表面导致的漫反射使得光线在水膜的液气交界处发生内部反射,增加了表面吸收光线的可能性,并建立模型验证了粗糙表面的材料在潮湿时的颜色较深的现象。Lekner 等^[15]扩展该模型,计算了内部反射的概率,并估算了相对折射率降低对光线吸收的影响,减小湿润表面的反照率,提高了模型的一致性,进一步分析了湿润条件下粗糙表面变暗的现象。光线在覆有液体的粗糙表面传播会发生内部反射与折射,导致光线多次被吸收而减弱了最终被观察到的光线强度(见图 1)。




图 1 粗糙表面上液体层的光线传播

Fig. 1 Light propagation within a liquid layer on a rough surface

在完好的沥青路面上,相较于干燥条件,湿润条件下的成像会呈现整体图像更暗、颜色更深的特点。而在有裂缝的

沥青路面上,光线在湿润条件下的裂缝中传播时会造成更多的损失(见图 2)。除了内部反射造成的光线损失,在湿润条件下,因水膜存在,光线折射后的传播角度相较于干燥情况下的反射角度明显减小,部分光线无法传播或无法直接传播到裂缝外,加重了光线损失的程度。




图 2 裂缝中无液体层与有液体层的光线传播对比

Fig. 2 Comparison of light propagation in cracks with and without a liquid layer

因此,在存在裂缝的湿润沥青路面上,裂缝处的图像变暗程度相较于平整区域更重,这意味着湿润环境下的裂缝在视觉效果上相比于干燥环境下更加突出。深度学习目标检测算法中卷积层的特征提取是关键环节之一,而湿润环境使裂缝“突出”,从理论上扩大了裂缝在深度卷积神经网络中的识别特征。

1.2 YOLOv5 目标检测算法

YOLO 算法是由 Redmon 等^[16]提出的一种单阶段目标检测算法,该算法用整张图片训练的方式将目标检测转换为回归问题,可以更好地区分目标与背景。相较于“两阶段”的 R-CNN 系列算法,YOLO 算法仅通过一个卷积神经网络(Convolutional Neural Networks, CNN)来预测目标的类别与位置,检测速度快,更适用于实时目标检测场景。

YOLO 算法经历了多次改进。Redmon 等^[17]引入锚框机制提高算法召回率,提出了 YOLOv2 算法,随后将特征提取网络更换为 Darknet-53 网络推出了 YOLOv3 算法,提高了算法的检测速度与精度。Bochkovskiy 等^[18]在 YOLOv3 的基础上,将多通道网络与 Darknet-53 结合,添加金字塔池化结构与路径聚合网络形成 YOLOv4 的特征提取网络,提出了 YOLOv4 算法。Yu 等^[19]在 YOLOv4 基础上优化了损失函数,改进了多尺度数据集,实现了无人机对桥梁裂缝的实时检测。Li 等^[20]提出了一种基于三维探底雷达和深度学习模型的沥青路面隐藏裂缝自动识别定位方法,验证了引入 YOLOv4 作为深度学习模型进行检测的可行性。可见,YOLOv4 在裂缝检测研究中已经表现出很好的效果。

与 YOLOv4 类似,YOLOv5 网络结构分为输入端、骨干网络、颈部网络、预测输出层 4 个部分,YOLOv5 整体网络架构图如图 3 所示。

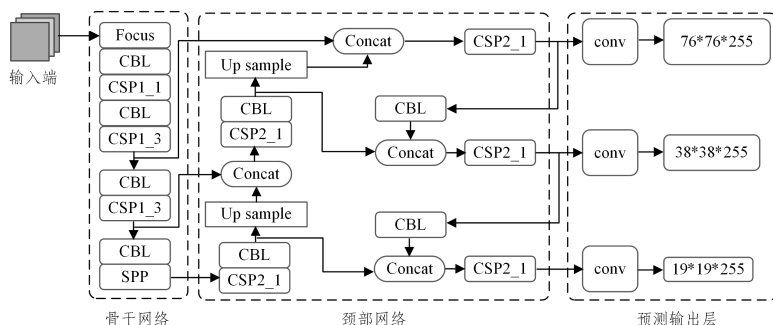


图 3 YOLOv5 网络架构

Fig. 3 YOLOv5 network structure

相比YOLOv4, YOLOv5在输入端增加了Mosaic数据增强、自适应锚框计算以及自适应图片缩放功能;在骨干网络中采用了Focus结构与两种CSP结构;在颈部网络中改进了FPN+PAN结构的卷积操作;在输出层改进了损失函数,将完全交并比损失函数改进为广义交并比损失函数,并采用NMS运算在检测后的处理过程中对多个目标锚框进行筛选,进一步提升算法检测精度。

YOLOv5的各部分网络结构由CBL, CSP, Focus等基础组件构成(见图4)。输入端表示输入的图片,包含图像预处理操作,如自适应图像缩放、归一化等。在进行网络训练时, YOLOv5使用Mosaic数据增强,将多张图片组合成一张,来提升模型的训练速度和网络精度。骨干网络中, YOLOv5引入了Focus结构通过切片对输入图片进行裁剪,可以提升输出深度,更多地保留图像信息。YOLOv5在YOLOv4的基础上设计了两种CSP结构CSP1_x和CSP2_x,分别应用于骨干网络和颈部网络,以加强网络间的特征融合。SPP则是采用最大池化方式进行多尺度特征融合。

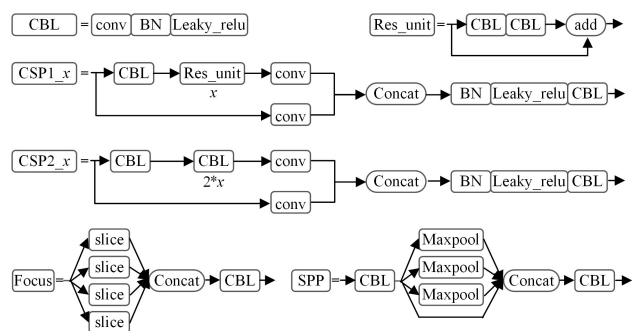


图4 YOLOv5基础组件构成


Fig. 4 Composition of YOLOv5 basic components

YOLOv5算法包括4个版本:YOLOv5s, YOLOv5m, YOLOv5l以及YOLOv5x。算法的耗时依次增加,准确度也相应提升。本文主要关注干燥和湿润环境下的对比检测效果,研究任务对算法本身的要求为高运算速度而非高精度,因此选择YOLOv5s作为裂缝检测基本算法。

2 沥青路面裂缝自动检测模型

YOLOv5s中自带已训练好的目标检测模型,在YOLOv5s已有模型的基础上进行沥青路面裂缝检测模型的训练可以提高训练的速度与精度。首先需要创建一个沥青路面裂缝检测的训练集,本文选择校园内沥青铺装道路为数据采集区域,随机选取不同的地点及拍摄角度,人工拍摄干燥

沥青路面的裂缝照片74张、湿润沥青路面裂缝照片77张,照片分辨率均为 4000×3000 像素。为对比干湿条件下的裂缝检测精度,选取两种条件下的等量照片作为训练集,人工剔除模糊、被遮挡等质量较低照片后,最终选取干燥和湿润条件的裂缝照片各60张,共120张图像作为训练集数据(见图5)。



(a)干燥

(b)湿润

图5 干燥与湿润条件下采集的训练集示例

Fig. 5 Examples of training sets collected under dry and wet conditions

训练集图片首先需要进行人工标注,Make Sense标注工具可以方便地批量处理训练图片,并直接导出YOLOv5训练所需的txt格式文件,因此本文选用Make Sense作为标注工具。通过人工标注导出的图片标注数据如表1所列。其中,编号表示检测的目标类别,本文仅以裂缝作为检测对象,用0表示裂缝这一类别的编号,X, Y, M, N分别表示归一化后的裂缝锚框角点坐标。

表1 部分YOLOv5格式的标注数据

Table 1 Partially labeled data in YOLOv5 format

类别	X	Y	M	N
0	0.907552	0.377604	0.184896	0.081597
0	0.786458	0.470486	0.148438	0.065972
...

将训练集图片和标注数据导入到YOLOv5中进行训练,训练的基础模型设定为YOLOv5s并将训练轮数设定为200轮。训练过程中的所有模型运行均基于Pytorch1.10.1环境,并使用cuda10.2进行加速处理。结果文件中对训练结果各项指标做出了可视化展示(见图6)。其中每个折线图的横轴表示训练的轮数,Box表示GIOU损失函数的均值;Objectness表示目标检测的损失均值;Precision表示模型的精度,Recall表示召回率,二者的值越高代表模型的目标检测效果越好;mAP是使用精度和召回率为横纵轴作图后围成的面积,用于整体评价训练的精度与召回率。可见,200轮训练后的模型有较好的训练效果,可以满足沥青路面裂缝检测的需求。

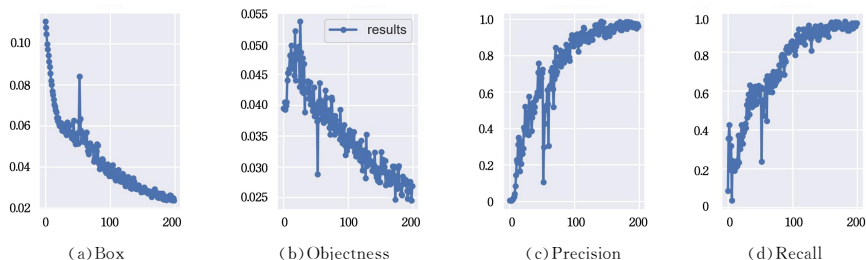


图6 可视化训练结果

Fig. 6 Visualize training results

3 对比实验与分析

3.1 实验对象

实验数据采集区域为校内环路东北部路段,该部分路段为沥青路面,具有若干已修补后开裂以及 10 处暂未修补的路面裂缝。选取 10 处未修补裂缝作为研究对象进行图像数据采集。

3.2 实验方案设计

对裂缝图像数据进行采集时,采用人工模拟洒水车打湿路面的方式,以降低天气、光线强度和光线角度等环境变量的影响。同时,为控制因路面坡向不同导致光线方向改变而可能对实验结果产生的影响,每处裂缝均选取 3 个不同角度进行拍摄。实验利用可调刚性手机支架固定机位与拍摄角度获取洒水前后的图像。主要分为以下步骤:

(1)选取拍摄机位。在裂缝外围选取底边垂直路缘石、边长为 1.5 m 的等边三角形的 3 个角点作为拍摄机位,记录每个角点手机支架底座的朝向与位置。

(2)获取干燥沥青路面裂缝图像。调整支架,选取摄像机的拍摄高度与拍摄角度并固定,使用同一设备拍摄 3 个不同角度的干燥沥青路面裂缝照片。

(3)获取湿润沥青路面裂缝图像。使用自制模拟洒水装置将路面打湿,从同一高度、角度获取湿润沥青路面裂缝的图像,并做好文件标记与干燥图像一一对应。

(4)将干燥与湿润沥青路面裂缝图像分别对应编号,通过训练后的沥青路面裂缝检测模型,对比两种条件下裂缝检测的精度与置信度。

实验图像数据采集时间为 13:30-15:30,光照条件较好,共采集到干燥沥青路面裂缝图像 30 幅,对应湿润沥青路面裂缝图像 30 幅,图像分辨率均为 4000×3000 像素。

3.3 干湿条件下沥青路面裂缝检测对比

将干燥沥青路面裂缝图像分别编号为 1-30,湿润沥青路面裂缝图像对应编号为 w1-w30,图像 1 与图像 w1 分别为同一裂缝在相同拍摄机位获取的干燥条件图像与湿润条件图像,依次对应。将两组图像分别输入训练好的

沥青路面裂缝检测模型进行裂缝检测,设定 IoU 损失阈值为 0.45(即两个预选锚框交并比大于 0.45 时被认为是同一目标锚框),置信度阈值为 0.50(即输出置信度大于 0.50 的预选目标锚框),得到两组检测结果,部分检测结果如图 7 所示。




图 7 干燥与湿润条件下裂缝检测结果示例

Fig. 7 Examples of crack detection results under dry and wet conditions

3.3.1 裂缝检测置信度对比

YOLOv5 目标检测结果将输出目标类型、位置与置信度,其中置信度表示模型认为该预选锚框区域为对应检测目标的概率。通过控制置信度阈值筛除低置信度锚框可以排除与目标类似的纹理等噪声的干扰,目标检测的置信度整体提高则可控制置信度阈值的增大,从而减小噪声的干扰。

通过模型检测得到干燥条件图像 1-30 与湿润条件图像 w1-w30 锚框位置对应的裂缝条数共 34 条,即认为同一裂缝在干燥与湿润条件下均被检测出的共有 34 条。分别统计同一裂缝在干燥与湿润条件下的置信度,可以得到沥青路面裂缝检测模型对同一裂缝的在干湿条件下的检测效果对比(见图 8)。结果显示,干燥条件下模型检测裂缝的平均置信度为 0.72,湿润条件下模型检测裂缝的平均置信度为 0.78,湿润条件下的沥青路面裂缝检测模型在平均置信度上优于干燥条件。




图 8 干燥与湿润环境下置信度检测效果对比

Fig. 8 Comparison of confidence metrics in dry and wet environments

相关分析可以衡量两个变量的相关密切程度,若是否湿润与置信度之间存在显著相关关系,则表示是否湿润对置信度有显著影响。是否湿润为二分类变量,置信度为连续变量,需用点二列相关系数求解变量间的相关性,具体方法为将是否湿润转化取值为 1 和 0,再通过 SPSS 计算变量间的 Pearson 相关系数。对干燥与湿润环境下的置信度进行相关性分析(见表 2),结果显示,是否湿润与路面裂缝检测置信度显著正相关,表明湿润环境下的裂缝检测可以以更高的

置信度阈值筛除噪声干扰。

表 2 是否湿润与置信度的相关性分析

Table 2 Correlation analysis between wetness or not and confidence

		score	
		是否湿润	置信度
是否湿润	Pearson 相关性	1	0.246 *
	显著性(双侧)		0.044
置信度	Pearson 相关性	0.246 *	1
	显著性(双侧)	0.044	

3.3.2 裂缝检测准确度对比

通过人工计数统计干燥条件下与湿润条件下采集到的图像中的裂缝数量,结果均为57条。通过沥青路面裂缝检测模型输出裂缝条数,共检测到干燥条件下裂缝53条,湿润条件下裂缝57条。由于模型对于裂缝断点识别标准不明确,存在将一条裂缝检测为两段的情况,从而输出为两条裂缝,因此本文采用总裂缝数量减去未检出裂缝数量作为准确度计算标准。统计未检出裂缝数量,分别得到干燥条件下未检出裂缝11条,湿润条件下未检出裂缝6条,因此得到,干燥条件下沥青路面裂缝检测准确率约为80.70%,湿润条件下沥青路面裂缝检测准确率约为89.47%。相较于干燥条件,沥青路面裂缝检测模型的准确度比湿润条件下提升了8.77%。

结束语 本文通过YOLOv5深度学习目标检测算法建立了一个沥青路面裂缝自动检测模型,并在此基础上设计对比实验,分析了干燥与湿润环境下的沥青路面裂缝检测效果,探讨了湿润环境对沥青路面裂缝自动检测效果的影响。主要结论如下:

(1)使用YOLOv5算法训练得到的沥青路面裂缝自动检测模型,其训练的精度和召回率等指标均满足裂缝检测需求,可以适用于各环境的裂缝检测研究。

(2)湿润与干燥环境下的沥青路面裂缝自动检测对比实验中,湿润环境下的裂缝检测效果整体优于干燥环境。湿润沥青路面的裂缝检测丢失数较少,裂缝检出率更高,湿润环境可以提高裂缝检测的准确度,并且湿润环境下的沥青路面裂缝检测置信度优于干燥沥青路面。

(3)在实际的检测工作中,可以考虑将裂缝检测与市政道路管养工程(如洒水、增湿等)相结合,减少裂缝检测人力财力资源等的消耗,并且市政道路管养车辆具有低速行驶、发车频率高的特性,也适合作为沥青路面裂缝检测的载体。

本文的研究成果有助于沥青路面裂缝检测工作在获得更优的检测效果的同时减少资源的消耗,丰富了碳中和背景下可持续发展路面技术。同时本文的研究也存在一定的局限性,大量、多样的训练集数据和更先进的算法对于模型的训练效果仍然是至关重要的,在下一步的研究工作中,将扩大训练集的样本数量、改进算法以提升模型性能,并在更广泛的模型中验证路面环境对裂缝检测效果的影响。

参考文献

- [1] SONG M. Study on the causes and Treatment measures of Highway Pavement Cracks[J]. Science and Technology Innovation and Application, 201, 11(34):106-109.
- [2] XU Z G, CHE Y L, LI J L, et al. Research progress in automatic image processing of pavement damage[J]. Journal of Traffic and Transportation Engineering, 2019, 19(1):172-190.
- [3] ZHANG J, SHA A M, GAO H G, et al. Automatic Pavement Crack Recognition and Evaluation System Based on Digital Image Processing[J]. Journal of Chang'an University(Natural Science Edition), 2004(2):18-22.
- [4] FUKUHARA T, TERADA K, NAGAO M, et al. Automatic pavement-distress-survey system[J]. Journal of Transportation Engineering, 1990, 116(3):280-286.
- [5] DONG A G, ZHANG X Y, XUE H Z, et al. Multi-level clustering algorithm for crack detection of concrete surface[J]. Journal of Traffic and Transportation Engineering, 2013, 13(6):7-13.
- [6] FUJITA Y, SHIMADA K, ICHIHARA M, et al. A Method

Based on Machine Learning Using Handcrafted Features for Crack Detection from Asphalt Pavement Surface Images[C]// Thirteenth International Conference on Quality Control by Artificial Vision 2017. Bellingham: SPIE, 2017.

- [7] MEI Q M, GÜ L, AZIM M R. Densely connected deep neural network considering connectivity of pixels for automatic crack detection[J]. Automation in Construction, 2019, 110:103018.
- [8] LI G, LIU Q W, REN W, et al. Automatic recognition and analysis system of asphalt pavement cracks using interleaved low-rank group convolution hybrid deep network and SegNet fusing dense condition random field-Science Direct[J]. Measurement, 2021, 170:108693. 1-108693. 17.
- [9] CHEN T, CAI Z, ZHAO X, et al. Pavement Crack Detection and Recognition Using the Architecture of SegNet[J]. Journal of Industrial Information Integration, 2020, 18(2):100144.
- [10] WANG B, WANG X, CHEN F, et al. Road surface crack recognition in aerial image[J]. Acta Optica Sinica, 2017, 37(8):126-132.
- [11] FAN M A, AL A. Pavement Crack Detection Using Sketch Token[J]. Procedia Computer Science, 2018, 139:151-157.
- [12] SONG H X, MA J, WANG J F, et al. Identification of pavement crack based on dual camera stereo photogrammetry[J]. China Journal of Highway and Transport, 2015, 28(10):18-25, 40.
- [13] QIU Y J, WANG G L, YANG E H, et al. Crack Detection of 3D Asphalt Pavement Based on Multi-feature Test[J]. Journal of Southwest Jiaotong University, 2020, 55(3):518-524.
- [14] ANGSTROM A. The Albedo of Various Surfaces of Ground [J]. Geografiska Annaler, 1925, 7(4):323-342.
- [15] LEKNER J, DORF M. Why some things are darker when wet [J]. Applied Optics, 1988, 27(7):1278-1280.
- [16] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]// IEEE Conference on Computer Vision and Pattern Recognition, 2015:779-788.
- [17] REDMON J, FARHADI A. YOLOv3: an incremental improvement[C]// IEEE Conference on Computer Vision and Pattern Recognition, 2018.
- [18] BOCHKOVSKIY A, WANG C Y, LIAO H. YOLOv4: Optimal speed and accuracy of object detection[C]// IEEE Conference on Computer Vision and Pattern Recognition, 2020.
- [19] YU Z W, SHEN Y G, SHEN C K. A real-time detection approach for bridge cracks based on YOLOv4-FPM[J]. Automation in Construction, 2021, 122:103514.
- [20] LI S W, GU X Y, XU X R, et al. Detection of concealed cracks from ground penetrating radar images based on deep learning algorithm[J]. Construction and Building Materials, 2021, 273:121949.



ZHANG Enhua, born in 1998, post-graduate. His main research interests include traffic and transportation safety, intelligent transportation system simulation.



WANG Weijie, born in 1977, Ph.D., professor. His main research interests include transportation safety, traffic behavior modeling, transportation planning and management.