

基于智能手机的农村公路路面破损检测方法

章洋¹,何莉²,汤青洲¹,张德津^{3*}

(1.湖北工业大学 电气与电子工程学院,湖北 武汉 430068;2.深圳大学 机电与控制工程学院,广东 深圳 518060;

3.深圳大学 建筑与城市规划学院,广东 深圳 518060)

摘要:农村公路路面破损自动检测是科学养护的重要前提。针对利用智能手机进行路面破损检测存在较高的误检、漏检以及破损无法量化等问题,该文提出一种新的路面破损检测方法。该方法利用智能手机采集路面图像,首先在图像中选取一个感兴趣区域,进行加权最小二乘滤波、Canny边缘检测以及Hough变换直线检测以识别路面,消除环境对识别结果的影响,降低误检率,再对路面区域使用透视变换的方法得到正射图,降低漏检率,最后利用Mask-RCNN模型对破损进行识别。试验结果表明:与SSD检测模型相比,该方法对裂缝、坑洞、修补3种破损的平均误检率、漏检率分别降低15.4%、19.6%,此外,还能测量裂缝的长度、宽度以及坑洞、修补的面积参数,较好地满足了农村公路破损检测的实际需求。

关键词:农村公路;智能手机;破损检测;深度学习

中图分类号:U416.2

文献标志码:A

0 引言

截至2021年底,中国公路总里程为528.07万km,其中农村公路里程为446.60万km,占总里程的84.6%。农村公路路网规模大,养护需求旺盛,及时、准确地检测路面破损可以节约维修成本、增加路面的使用寿命和保障行车安全。据统计,农村公路以水泥混凝土路面为主,占比高达95%以上,水泥混凝土路面破损常见形式有裂缝、坑洞和修补等^[1],其中裂缝为路面损坏最主要的形式之一。路面破损检测技术在过去20多年得到了广泛研究,快速路面检测装备采用线扫描相机或者面阵相机获取路面二维灰度图像^[2-5],或者利用激光线扫描三维测量传感器获取路面三维断面数据^[6-7],再采用相应的方法进行分析处理,完成对路面破损的识别,这些技术能够高精度、高效率检测路面破损,在国省干线得到了广泛应用。然而,农村公路由于养护要求相对较低、经费投入不足等原因,快速路面检测装备并不被广泛使用,因此,研究一种新的满足农村公路路面养护工作需求的低成本、高效的路面检测技术具有重要意义。

随着智能手机的发展,现代智能手机内置摄像头、GPS、具备通信功能,成本低、易于使用,使得基于智能手机的路面破损检测成为可能,形成了诸多的数据采集手段和相应的数据处理方法。其中,Mertz团队^[8]开发了一个智能手机裂缝监测系统,通过智能手机摄像头采集路面图像数据,再通过超像素的方法识别路面裂缝,以低于1 000美元的成本实现了城市范围的路面裂缝监测。最近几年,随着深度学习在图像处理领域取得的巨大进步,有学者将深度学习方法应用到智能手机路面检测中。Maeda等^[9]使用目标检测模型SSD对路面破损进行识别与分类,取得了较好的检测结果。限于智能手机的硬件条件,当汽车以较快的速度行驶时,智能手机摄像头无法清晰地获取路面正射图像,因此,上述方法中智能手机摄像头均为非正射姿态获取全景图像数据,对路面破损进行定性分析。由于是全景数据,非路面区域的环境部分造成了一定的误检,并且路面损坏的形状特征发生了变化,距离越远,变化越大,可能造成较远区域的破损无法准确识别,发生漏检情况,同时,在实际路面养护工作中,养护工作人员除了要知道破损的类型,还需要清楚破损的参数大小,以便

收稿日期:2022-06-15(修改稿)

基金项目:国家重点研发计划项目(编号:2019YFB2102703);深圳市科创委面上项目(编号:20200125)

作者简介:章洋,男,硕士研究生.E-mail:736295623@qq.com

*通信作者:张德津,男,博士,教授.E-mail:djzhang@szu.edu.cn

养护工作更加准确地进行。

本文在观察大量路面图像的基础上,提出一种新的基于智能手机的破损检测方法,主要包括以下两方面内容:路面区域畸变矫正以及基于 Mask-RCNN 深度学习模型的路面破损识别。前者能够检测出路面边缘,并利用透视变换得到路面正射图,后者能够自动提取破损的各种特征,根据图像数据标记注释进行参数训练,完成对破损的识别与分割。

1 相关工作

1.1 路面数据采集

快速路面检测装备利用硬件优势在汽车高速行驶状态下可以获得清晰的路面正射图像,在利用智能手机进行路面正射数据采集工作时发现,当汽车移动速度超过 15 km/h 时,图像会出现较大幅度的模糊,人工识别路面损坏都存在偏差,因此,在较高速度下利用智能手机采集清晰正射图像数据存在困难。通过调整手机至一定高度和拍摄角度,使手机相机视野恰好不会被引擎盖遮挡,其中 h 为手机与地面垂直距离(不同车型一般为 1.3~1.5 m), α 为相机视野下界线与地面的角度,一般为 $25^\circ\sim 35^\circ$,此时汽车能在最大约 40 km/h 的速度下获取清晰的路面图像数据。人工观察数据发现,图片中前方约 10 m 的路面清晰度较高,可以作为后续处理的感兴趣区域,因此,在利用 Fast300Shots 应用软件采集数据时,设置相机采集频率为 1 张/s,采集分辨率为 $4\,000\times 3\,000$ 像素的路面图像,同时记录下 GPS 定位信息,路面数据采集如图 1 所示。



图 1 智能手机路面数据采集

1.2 路面区域畸变矫正

路面区域畸变矫正就是将因视角原因发生畸变

的路面区域转换为其正射图。有学者利用透视投影的原理^[10-12]对畸变图像进行了透视变换,取得了良好的效果,其中 4 个畸变图坐标点以及 4 个正射图坐标点的确定是透视变换的关键步骤,上述学者^[10-12]应用场景相对简单,利用经典的边缘检测算法就能够获取坐标点。本文数据场景相对复杂,采用经典的边缘检测算法能够获取路面边缘,但是由于环境部分以及路面本身存在一定的复杂性,检测结果中存在大量的噪声边缘,为了减少这些噪声,有学者提出了基于形态学^[13-14]的方法,然而,在对采集的路面图像进行试验时,上述方法虽然能够消除噪声边缘,但是同时也破坏了路面边缘的完整性,路面边缘不连续,从而导致畸变坐标点获取不准确,畸变矫正参数获取失败。本文提出一种基于加权最小二乘滤波的路面边缘检测方法,在进行边缘检测前对图像进行加权最小二乘滤波,保留图像中边缘梯度变化较大的地方而使其他地方尽可能平滑,以达到增强路面边缘信息的效果,再采用 Canny 边缘检测得到边缘信息,最后利用 Hough 变换检测出边缘中的直线部分,延长至与感兴趣区域边界相交,得到 4 个畸变图坐标点。该方法不仅能够大幅减少边缘中的噪声部分,还能使路面边缘保持完整,准确得到畸变坐标点。正射图坐标点可根据畸变点坐标围成的区域实际尺寸确定,代入透视变换公式,求得畸变矫正参数,进而完成畸变矫正。

1.3 目标检测技术

目标检测是在给定的图像中精确地找到物体所在位置,并且标注出物体类别,可以看作是图像分类任务加定位任务。最近几年基于深度卷积神经网络的目标检测技术在 ILSRVC^[15]、COCO^[16]等公共数据集上表现出了较高的检测精度。COCO 数据集中包含的刀、叉等检测目标和裂缝类似,具有一定的线性特征,飞盘、碗等目标和坑洞、修补类似,是块状类目标,具有较大的面积,Mask-RCNN^[17-18]模型在同时检测上述 COCO 数据集中的目标时,已表现出最高的检测精度。因此,本文利用 Mask-RCNN 模型对水泥路面上的裂缝、坑洞、修补等破损进行检测。

2 路面破损检测算法

通过智能手机采集的全景数据,环境部分较为

复杂,会造成破损的误检,并且由于视角原因,破损特征发生了变化,造成较远区域特征不明显破损的漏检,因此,需要将原始全景图像中的路面区域识别出来并矫正为正射图,再利用高检测精度的Mask-RCNN模型对路面破损进行准确识别与分割。

2.1 路面区域畸变矫正

2.1.1 路面边缘检测

根据透视变换原理^[19-20],只要得到路面区域中畸变图像的4个坐标点以及正射图像中对应的4个坐标点即可求解透视变换线性方程组,得到透视变换参数。透视变换公式为:

$$\begin{bmatrix} u_1 \\ v_1 \\ u_2 \\ v_2 \\ u_3 \\ v_3 \\ u_4 \\ v_4 \end{bmatrix} = \begin{bmatrix} x_1 & y_1 & 1 & 0 & 0 & 0 & -u_1x_1 & -u_1y_1 \\ 0 & 0 & 0 & x_1 & y_1 & 1 & -v_1x_1 & -v_1y_1 \\ x_2 & y_2 & 1 & 0 & 0 & 0 & -u_2x_2 & -u_2y_2 \\ 0 & 0 & 0 & x_2 & y_2 & 1 & -v_2x_2 & -v_2y_2 \\ x_3 & y_3 & 1 & 0 & 0 & 0 & -u_3x_3 & -u_3y_3 \\ 0 & 0 & 0 & x_3 & y_3 & 1 & -v_3x_3 & -v_3y_3 \\ x_4 & y_4 & 1 & 0 & 0 & 0 & -u_4x_4 & -u_4y_4 \\ 0 & 0 & 0 & x_4 & y_4 & 1 & -v_4x_4 & -v_4y_4 \end{bmatrix} \times \begin{bmatrix} a \\ b \\ c \\ d \\ e \\ f \\ g \\ h \end{bmatrix} \quad (1)$$

其中 (x_1, y_1) 、 (x_2, y_2) 、 (x_3, y_3) 、 (x_4, y_4) 为畸变图的像素坐标; (u_1, v_1) 、 (u_2, v_2) 、 (u_3, v_3) 、 (u_4, v_4) 为正射图的像素坐标; a, b, c, d, e, f, g, h 为透视变换参数。畸变图坐标点位于路面与环境的分界线上,因此,第

一步需要准确检测路面边界线。在相关工作中提出前方10 m路面可以作为后续处理的感兴趣区域,如图2(a)中虚线矩形框所示,感兴趣区域的确定使得处理区域范围缩小,更有利于路面边缘的检测。

本文提出一种基于加权最小二乘滤波的边缘检测方法,加权最小二乘滤波器是一种保边滤波器^[21],能够使图像中一些梯度变化较大地方的边缘保持良好,而其他地方尽可能平滑。首先将图像进行灰度化处理,经过加权最小二乘滤波,效果如图2(b)所示,再通过Canny边缘检测算法检测路面边缘,如图2(c)所示,路面边缘几乎完整保留且环境噪声边缘较少。观察检测结果发现,路面的左右边缘大致成一条直线,而环境部分中的边缘呈现出不规则的曲线状态,因此,可以利用这一特征进一步去除噪声边缘。Hough变换^[22]是一种利用图像全局特征将特定形状连接起来的算法,能够检测边缘中的直线部分,如图2(d)所示,左右两侧直线(白色粗线)均能反映其所在边界的趋势,但两侧可能出现多条直线共存的状态,如图2(d)中左侧为两条不连续,右侧为两条相交,为了解决这个问题,本文以直线长度作为筛选依据,从左右两侧分别选择出长度较长的直线,因为其更能代表路面边界的发展趋势,进而将其延长至图像边界,形成完整的路面边缘,如图2(e)所示。

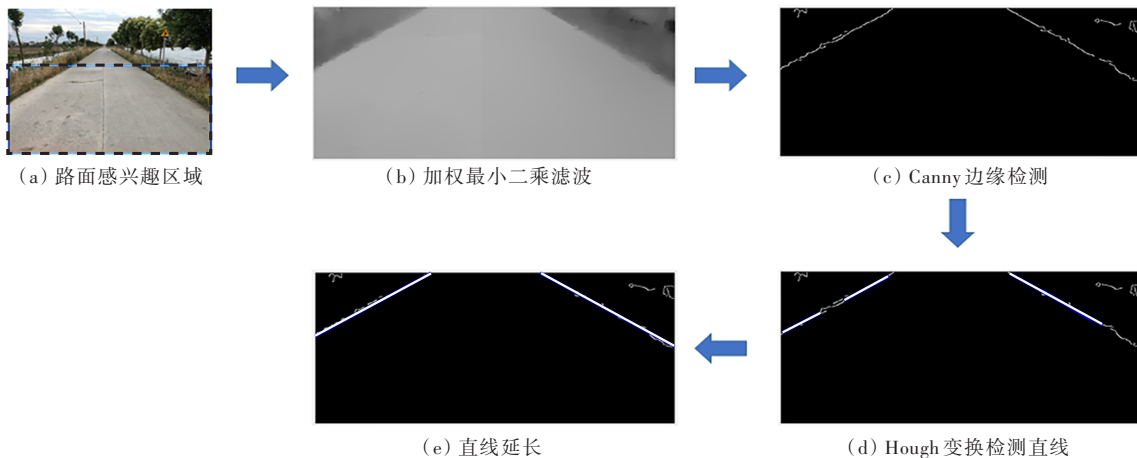


图2 路面边缘检测过程

2.1.2 畸变坐标点动态确定

从路面边界线上能够很容易得到畸变图像的4个点,如图3所示,阴影部分为道路区域。最理想的情况就是车辆刚好处于道路正中间,如图3(a)所示,

四边形 $ABCD$ 为等腰梯形,此时畸变图像中的4个点即为 A, B, C, D ,等腰梯形 $ABCD$ 在正射图中的矩形长宽比也能得到(例如路宽 $b_{CD}=5$ m,路长 $L_{AD}=10$ m,长宽比即为2:1), CD 线段所占像素为4 000,测量

精度即为 $5\,000/4\,000=1.25\text{ mm}$, 根据比例正射图尺寸可以设定为 $8\,000\times4\,000$, 再确定相应的正射图坐标点, 求得透视参数。然而实际情况中, 车辆基本不会位于车道正中间行驶, 如图 3(b) 所示, 车辆偏向于右车道, 路面区域在图像中呈现的状态为 D 点上移, C 点下移, 正射图长宽比 ($l_{AD}:b_{AB}$) 动态变化, 尺寸难以确认。针对这种情况, 本文提出一种基于道路边界线趋势的畸变坐标点确定方法, 基本思想就是固定正射图尺寸 (车辆位于道路正中间时的计算值), 在动态的路面区域中找到相应的畸变坐标点。以图 3(a) 中 A 、 B 、 C 、 D 4 个点作为参考点, 通过延长图 3(b) 中 AD 与 EF [EF 与图 3(a) 中 CD 横坐标相同] 交于点 F , 此时畸变坐标点即为 A 、 B 、 E 、 F , 正射图尺寸仍为 $4\,000\times8\,000$, 正射图坐标点不变, 从而可求得透视变换参数。车辆偏向左车道行驶时的情况与右车道类似, 通过延长另一边得到畸变坐标点。




图 3 手机拍摄效果示意图

2.1.3 路面区域矫正

根据透视变换参数完成的矫正效果如图 4 所示, 其中图 4(a) 为原始畸变图像, 可以看出此时车辆稍微偏向于右车道, 直接经过透视变换后的正射图像是不连续的, 如图 4(b) 所示, 为了解决这种不连续现象, 在矫正过程中每计算一个点, 就将其右方、下方以及右下方的像素点用计算得到的点代替, 得到最终的正射图, 如图 4(c) 所示, 可以看出距离较远的坑洞经过透视变换后, 其特征更加明显, 有利于进一步识别。




图 4 畸变矫正过程

2.2 基于 Mask R-CNN 模型的路面破损检测

2.2.1 建立数据集

通过智能手机采集的 10 608 张图像中, 需人工挑选出具有破损的图像, 构建破损数据集, 数据集包含 1 392 张路面破损图像, 一共 1 696 个破损实例, 各类破损的实例统计结果如表 1 所示。破损分为 3 种类型, 其中裂缝类破损是路面最为常见的病害, 裂缝图像占有破损图像的 77%, 实例个数占有实例个数的 79.7%, 图 5 展示了各类破损的例子。为了验证该算法的有效性, 将数据通过前文的畸变矫正方法得到路面正射图, 制作成两种不同的数据集。原始全景数据制作成全景图数据集, 正射图数据制作成正射图数据集, 按照 7:3 的比率将数据集随机分成训练集和测试集, 其中各类破损数据按照比例进行划分, 则训练集包含 974 张图像 (裂缝 745 张, 坑洞 173 张, 修补 56 张), 测试集包含 418 张图像 (裂缝 327 张, 坑洞 75 张, 修补 16 张), 由于是随机划分, 破损实例个数会有少许差异。

表 1 路面破损类型结果统计

破损类型	图像数量/张	占比/%	实例数量/张	占比/%
裂缝	1 072	77.0	1 352	79.7
坑洞	248	17.8	272	16.0
修补	72	5.2	72	4.3
合计	1 392	100.0	1 694	100.0



图 5 水泥路面破损

图像数据需要进行标注, 形成标注文件, 才能进行模型训练, 本文利用 VGG Image Annotator (VIA) 图像标注工具进行标注工作, 以 .json 格式导出, 训练过程中遵循 Mask-RCNN 模型原文^[17]中的参数设置, 并使用 Mask-RCNN 模型在 COCO 数据集上的预训练权重作为网络模型的初始权重参数, 完成模型训练。

2.2.2 破损参数测量

通过路面图像畸变矫正以及 Mask-RCNN 模型识别后, 对于裂缝而言, 需计算长度、宽度参数, 如图

6所示,建立其最小面积外接矩形模型(虚线矩形框),将长边作为裂缝的长度参数,沿短边方向任取5处位置(箭头),统计每一处裂缝所占像素并求平均值,作为裂缝的宽度参数。对于坑洞以及修补类损坏,将分割后的像素点累加作为面积参数。




图6 裂缝参数的计算


3 试验结果与分析

试验硬件平台为:Ubuntu 16.04操作系统,处理器为Intel(R) Core(TM) i7-7700K CPU @ 4.2 GHz,内存16 GB,硬盘2 TB,GPU为NVIDIA GeForce GTX 1080 Ti;软件平台为利用anaconda3搭建的Tensorflow深度学习环境,编译器采用spyder。


3.1 破损识别试验

将两种不同的数据集训练完成后,将预训练权重应用于破损测试中,为了更好地验证本文算法的有效性,与Hiroya Maeda等的SSD模型^[10]进行了对比,检测效果如图7所示。从图7可以看出:全景图、正射图下,两种模型均能检测出3种破损,但Mask-RCNN对破损的检测框比SSD更加完整、准确,分类评分更高,正射图下3种破损的检测准确性相比于全景图检测框更加准确,评分更高,尤其是纵向裂缝,正射图下检测框的非裂缝区域减小,检测准确性提高。同时,Mask-RCNN模型不仅能以边界框形式对正射图中目标进行检测,同时对每个目标完成了分割,以便下一步进行破损参数计算。

为了更好地评估试验结果,采用交并比 R_{iou} 指标衡量目标是否检测准确,区域 A 为测试时生成的检测框,区域 B 为标签时的真值框,交并比 R_{iou} 定义为区域 A 与区域 B 交集和并集的比值,即:



(a) 全景图检测结果



(b) 正射图检测结果

图7 路面破损检测结果

$$R_{iou} = \frac{A \cap B}{A \cup B} \quad (2)$$

交并比阈值一般设置为0.5,当大于0.5时,则认为检测准确,反之,则检测失败。在此阈值下对测试集中的所有样本进行测试与评估,表2为破损识别结果,其中精确率($R_{precision}$)为正确检测出的实例个数占检测结果的比例;召回率(R_{recall})为正确检测出的实例个数占实际实例个数的比例;误检率为检测错误的实例个数占检测结果的比例;漏检率为未检测到的实例个数占实际实例个数的比例,其中误检率=1-精确率,漏检率=1-召回率, F_1 为综合考虑召回率和精确率的评价指标,即:

$$F_1 = (2 \times R_{precision} \times R_{recall}) / (R_{precision} + R_{recall}) \quad (3)$$

表 2 两种模型数据集下识别结果

破损类型	检测方法	精确率/%		召回率/%		F_1 /%		误检率/%		漏检率/%	
		全景图	正射图	全景图	正射图	全景图	正射图	全景图	正射图	全景图	正射图
裂缝	Mask-RCNN	67.1	72.8	65.6	73.6	66.3	73.2	32.9	27.2	34.4	26.4
	SSD	54.0	61.9	51.2	60.8	52.6	61.3	46.0	38.1	48.8	39.2
坑洞	Mask-RCNN	82.5	88.2	80.6	90.5	81.5	89.3	17.5	11.8	19.4	9.5
	SSD	76.0	79.9	73.6	82.0	74.8	80.9	24.0	20.1	26.4	18.0
修补	Mask-RCNN	81.5	88.5	79.5	91.3	80.5	89.9	18.5	11.5	20.5	8.7
	SSD	73.2	80.4	71.7	79.5	72.4	79.9	26.8	19.6	28.3	20.5

从表 2 可以看出:正射图数据集下 3 种破损的识别精确率、召回率以及 F_1 分值比全景图数据集普遍要高,并且在同一数据集下,Mask-RCNN 模型比 SSD 模型的测试评估结果要高。本文采用的正射图数据集+Mask-RCNN 模型对 3 种破损达到了较好的识别结果。试验结果说明:路面全景图会影响破损识别的准确性,尤其是精确率指标,裂缝类损坏提升了约 8%,坑洞以及修补类损坏分别提升了约 7%、9%,这是因为出现了误检情况;对于召回率指标,裂缝类损坏提升了约 12%,坑洞以及修补类损坏分别提升了 12%、15%,这是因为远处破损特征不明显而无

法准确识别的漏检情况。

3.2 破损参数测量结果

Mask-RCNN 模型的 Mask 分支实际上是一个语义分割模型,能够对检测框中的每个目标实现分割。本文从已识别的结果中抽取了 100 张破损图片来测试本文算法的有效性。如表 3 所示,将测试样本分为 5 组,根据规范,裂缝分为轻、中、重 3 种不同程度的破损,坑洞以及修补不区分严重程度,记人工测量值为真值,并与人工测量结果进行了对比,其中裂缝测量按长度、宽度计算,分别记为 L 、 W ,坑洞以及修补均按面积计算,记为 S ,表中记录数据为统计均值。

表 3 破损参数测量结果

项目	轻度裂缝 ($W < 3 \text{ mm}$)		中度裂缝 ($3 \text{ mm} \leq W \leq 10 \text{ mm}$)		重度裂缝 ($W > 10 \text{ mm}$)		坑洞 S/m^2	修补 S/m^2
	L/m	W/mm	L/m	W/mm	L/m	W/mm		
算法测量	1.728	2.92	2.252	6.56	4.155	17.84	0.126	0.167
人工测量	1.853	2.45	2.142	5.94	4.037	16.64	0.133	0.176
算法误差	-0.125	0.47	0.110	0.62	0.118	1.20	-0.007	-0.009
相对误差/%	-6.7	19.2	5.1	10.4	2.9	7.2	-5.2	-5.1

表 3 结果表明:轻度裂缝由于宽度太小,显著度不够,分割准确率降低,测量误差也会增加,随着裂缝严重程度的加深,裂缝显著度增加,相对误差随之减小,而坑洞、修补类破损特征显著,分割效果较好,测量误差相对较小。

4 结论

(1) 分析农村公路破损检测所面临的问题,提出一种新的基于智能手机的路面破损检测方法,针对路面常见的裂缝、坑洞以及修补类损坏,利用智能手

机采集路面全景图像,并通过畸变矫正等方法获取路面正射图,再采用最先进的深度学习目标检测技术对路面破损进行识别,相比之前的方法,不仅在定性检测方面降低了误检率、漏检率,提升了检测准确率,而且能够对检测出的目标进行定量分析,较好地满足农村公路高效、便捷、低成本的检测需求。

(2) 本文方法对裂缝、坑洞、修补等灰度特征明显的破损进行了检测,对其他具有一定深度特征的变形类破损如拱起、错台等并不具备检测能力,同时对坑洞类损坏进行参数测量时,只能获取其面积参数,深度参数未能获取。当前农村公路以水泥路面

为主,随着经济的发展,农村公路铺设沥青将成为趋势,相应的检测指标和要求也会发生变化,智能手机能否满足其检测要求成为问题。另一方面,公路路面检测指标多,智能手机硬件和软件也不断得到改善,如何最大化利用智能手机搭载多传感器的特点集成检测多项指标也是值得研究的课题。

参考文献:

- [1] 交通运输部公路科学研究院.公路技术状况评定标准:JTG 5210—2018[S].北京:人民交通出版社股份有限公司,2018.
- [2] 张德津,李清泉.公路路面快速检测技术发展综述[J].测绘地理信息,2015,40(1):1-8.
- [3] 魏海斌,武少威,张启帆,等.基于图像处理的沥青路面裂缝识别算法研究[J].中外公路,2020,40(4):1-8.
- [4] 王世芳,车艳丽,李楠,等.一种基于多尺度脊边缘的沥青路面裂缝检测方法[J].中国公路学报,2017,30(4):32-41.
- [5] 李晋惠.用图像处理的方法检测公路路面裂缝类病害[J].长安大学学报(自然科学版),2004,24(3):24-29.
- [6] 李伟,孙朝云,呼延菊,等.基于路面3D数据的裂缝类型判断方法[J].中国公路学报,2015,28(11):21-28.
- [7] 李清泉,邹勤,张德津,等.利用高精度三维测量技术进行路面破损检测[J].武汉大学学报(信息科学版),2017,42(11):1549-1564.
- [8] MERTZ C, VARADHARAJAN Srivatsan, JOSE S, et al. City-wide road distress monitoring with smartphone[C]// World Congress on Intelligent Transport Systems and ITS America Annual Meeting,2014:115-124.
- [9] MAEDA H, SEKIMOTO Y, SETO T, et al. Road damage detection and classification using deep neural networks with smartphone images [J]. Computer-Aided Civil & Infrastructure Engineering,2018,33(12):1127-1141.
- [10] 代勤,王延杰,韩广良,等.基于改进Hough变换和透视变换的透视图像矫正[J].液晶与显示,2012,7(4):552-556.
- [11] TANG Jialin, HUANG Haonan. An improved perspective transform for image distortion correction[C]//Fan CP, Fan YC, Hwang YT. IEEE International Conference on Consumer Electronics. Taiwan: ICCE, 2018: 1164-1172.
- [12] 王颖,李锋.基于改进透视变换的结构光图像校正[J].计算机与数字工程,2019,47(5):1240-1248.
- [13] 郭栋鸿,谭丽.基于MMSE的自适应灰度形态学钢轨边缘检测算法[J].云南大学学报(自然科学版),2019,41(6):1144-1151.
- [14] 罗朝阳,张鹏超,姚晋晋.一种基于形态学的边缘检测算法[J].计算机应用与软件,2020,37(2):177-181.
- [15] RUSSAKOVSKY O, DENG J, SU H, et al. Image net large scale visual recognition challenge[J]. International Journal of Computer Vision, 2015, 115(3): 211-252.
- [16] LIN T, MAIRE M, BELONGIE S, et al. Microsoft COCO: Common objects in context[C]//David J. Fleet, Tomáš Pajdla, Bernt Schiele. Lecture Notes in Computer Science. Zurich: In ECCV, 2014: 740-755.
- [17] HE K, GKIOXARI G, DOLL'AR P, et al. Mask RCNN[C]// Katsushi Ikeuchi, Gérard Medioni, Marcello Pelillo. IEEE International Conference on Computer Vision. Venice: In ICCV, 2017: 770-783.
- [18] 李画,李明晶,李凯,等.Mask RCNN模型在路面缺陷检测中的应用[J].科学技术创新,2020(29):131-132.
- [19] 金勇俊,李言俊,张科.一种透视变换图像金字塔匹配改进算法[J].计算机工程与应用,2007,43(24):78-80,165.
- [20] 张建伟,雷霖.基于透视投影的垂直视角投影算法研究[J].成都大学学报(自然科学版),2017,36(1):47-50.
- [21] 李红云,云利军,高银.基于边界限制加权最小二乘法滤波的雾天图像增强算法[J].中国激光,2019,46(3):255-263.
- [22] 王琦,宋伟东,王竞雪.基于Hough变换的直线提取方法及改进[J].测绘与空间地理信息,2019,42(6):214-221.