

DOI:10.16136/j.joel.2022.11.0074

基于深度学习的路面缺陷自动检测系统

王 鑫, 李 琦*

(内蒙古科技大学 信息工程学院, 内蒙古 包头 014010)

摘要:路面缺陷自动检测对公路养护和路况等级评估具有重要意义。为此,使用YOLOv5x结合透视变换和图像分割设计了路面缺陷检测系统。首先,为证明系统可行性采集并制作了多类型路面缺陷数据集(pavement defect dataset, PDD)。然后,使用SSD(single shot multibox detector)、Faster R-CNN、YOLOv5x(you only look once v5x)和YOLOX 4种模型对PDD进行训练检测。经过训练,4种模型的mAP(mean average precision)均超过了77%,其中YOLOv5x的结果最优,mAP达到了91%,同时证明创建的数据集PDD有效。最后,使用YOLOv5x作为系统主要检测方法结合透视变换、图像分割和骨架提取获取缺陷的长度、宽度和面积等信息,进而计算路面状况指数(pavement condition index, PCI)得到路面破损等级,以及相应的维修建议,提高了路面缺陷检测的实用性。

关键词:路面缺陷检测; YOLOv5; 图像分割; 深度学习**中图分类号:**TP391 **文献标识码:**A **文章编号:**1005-0086(2022)11-1165-08

Automatic detection of pavement defects based on deep learning

WANG Xin, LI Qi*

(College of Information Engineering, University of Science and Technology of Inner Mongolia, Baotou, Inner Mongolia 014010, China)

Abstract: Automatic detection of pavement defects is of great importance for road maintenance and road condition rating assessment. To this end, a pavement defect detection system was designed using YOLOv5x combined with perspective transformation and image segmentation. First, a multi-type pavement defect dataset (PDD) was collected and produced to demonstrate the feasibility of the system. Then, four models single shot multibox detector (SSD), Faster R-CNN, you only look once v5x (YOLOv5x) and YOLOX, were used to train the PDDs for detection. After training, the mean average precision (mAP) of all four models exceeded 77%, with YOLOv5x showing the best results with 91% mAP, while proving the validity of the created dataset PDDs. Finally, YOLOv5x was used as the main detection method of the system combined with perspective transformation, image segmentation and skeleton extraction to obtain information such as length, width and area of defects, and then calculating the pavement condition index (PCI) to obtain the pavement damage level and the corresponding repair suggestions, improving the practicality of pavement defect detection.

Key words:pavement defect detections; YOLOv5; image segmentation; deep learning

1 引言

随着我国交通运输量的激增,产生了大量路面缺陷,标志着我国公路已进入大面积检测和养护阶段。这些路面缺陷在很大程度上减少的道路

使用寿命,极大地增加了事故发生率。因此,能够及时发现、修复和阻止进一步恶化成为了交通部门的一项重要任务。早期的道路缺陷检测主要采用传统的图像处理技术和人工检测,包括探地雷达、激光和红外线测量等技术^[1]。这些方法费时

* E-mail: richey@imust.edu.cn

收稿日期:2022-02-12 修订日期:2022-03-21

基金项目:内蒙古关键技术攻关项目(2020GG0316)资助项目

费力,精度和速度都达不到要求。随后的检测技术主要以机器学习为主,其中包括支持向量机^[2]、Canny 边缘检测^[3]、Otsu 阈值分割、以及一些基于区域生长的检测方法,这种基于阈值的检测方法在简单背景下检测效果较好,但在一些诸如油渍、阴影和异物等背景下检测效果依然不佳。

随着深度学习的发展,各种目标检测网络被用于道路缺陷检测领域,能够挖掘出更深层次的特征,在很大程度上滤除复杂背景带来的影响,成为了道路缺陷检测领域的主流趋势。典型的目标检测算法有 Faster R-CNN^[4]、SSD (single shot multibox detector)^[5] 和 YOLO (you only look once)^[6] 等。Faster R-CNN^[4] 在目标检测领域应用广泛,是经过 R-CNN 和 Fast R-CNN^[7] 演变而来的。它与 VGG (visual geometry group) 等特征提取网络一样先从 CNN 结构中提取图像特征,然后提取出目标候选区域,最后再进行目标分类和边界坐标回归。SUH^[8] 和 CHA^[9] 使用 ZF-Net 替换 Faster R-CNN 中的特征提取网络,使得特征提取更加快速。FANG^[10] 将 Faster R-CNN 与贝叶斯概率分析结合起来对路面裂缝进行检测。该方法有效地提高了裂纹检测率,并降低了误检率。SSD^[5] 由 LIU 等提出,是一种利用单一深度卷积神经网络 (deep convolution neural network, DCNN) 检测图像中目标的方法。MAEDA 在文献 [11] 和 [12] 中比较了 SSD MobileNet、SSD Inception 和 SSD ResNet50 之间的性能,三者将原始 SSD 中的 Backbone 做了相应的替换。结果表明,SSD MobileNet 要比其他两种 SSD 的性能好,速度甚至超过 SSD Inception 两倍。但是,SSD MobileNet 没有很好地利用浅层特征信息,所以对小物体不敏感。YOLO^[6] 算法使用深度神经网络进行对象的位置检测以及分类,主要的特点是速度够快,而且准确率也很高。与 Faster R-CNN 不同的是,YOLO 将检测问题转化为了回归问题,采用直接预测目标对象的边界框的方法,将候选区和对象识别这两个阶段合二为一,大大提高了检测速率。YOLO 在经过 YOLOv2^[13] 和 YOLOv3^[14] 的发展变迁之后,YOLOv4^[15]、YOLOv5 以及 YOLOX^[16] 相继出现,不仅继承了前几代优良的性能,而且在体积上变得更小,最小的 YOLOv5 模型大小仅几十 MB。MANDAL^[17] 分别使用了 YOLOv4、CenterNet^[18] 和 EfficientDet^[19] 对路面缺陷进行检测与分类,并且分析了 3 种检测器的主干网络 DarkNet、Hourglass 和 EfficientNet 对模型检测和分类性能的影响,结果表明 YOLO 算法的效果优于其他两种算法。

随着目标检测技术在诸多工业领域的广泛应用以及理论研究的不断发展,利用图像的深层特征信息进行路面缺陷检测已成为一种趋势。因此,本文设计了一种基于深度学习的路面缺陷检测系统。为了增加缺陷检测的泛化能力以及证明系统的可行性,采集制作了多类型路面缺陷数据集 (pavement defect dataset, PDD)。比较了 SSD、Faster R-CNN、YOLOv5x 和 YOLOX 在 PDD 上的训练检测效果。随后使用最优的 YOLOv5x 模型结合透视变换和图像分割设计了路面缺陷检测系统。

2 PDD

对路面缺陷进行正确的分类,不仅能够减少公路维修成本,而且便于更全面地分析路面状况。因此,结合 2018 年底发布的公路技术状况评定标准 (JTG5210-2018) 对路面缺陷类型进行研究分析,以进行全面的路面缺陷数据采集。

2.1 缺陷类型

常见的路面缺陷主要有裂纹、坑洞和各种修补等。如图 1(a)–(c) 所示,裂纹是最常见的一种缺陷,是由路面老化以及环境因素导致的路面开裂。

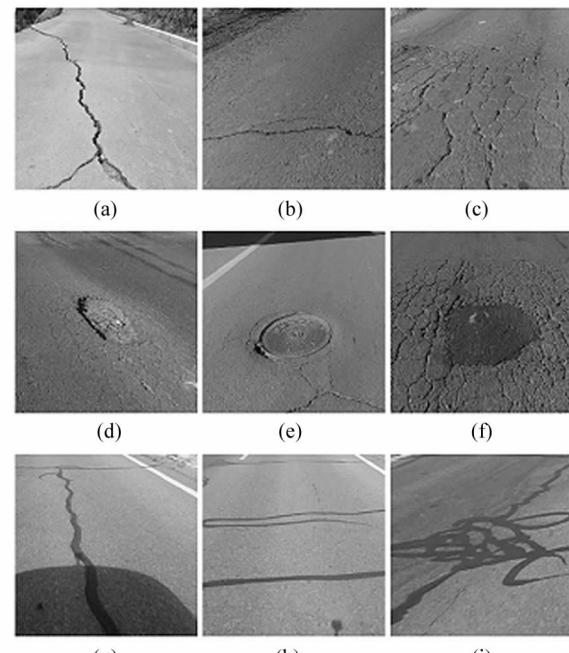


图 1 路面缺陷图像:(a) 纵向裂纹;(b) 横向裂纹;(c) 网状裂纹;(d) 坑洞;(e) 井盖;(f) 坑洞补丁;(g) 纵纹补缝;(h) 横纹补缝;(i) 网纹补缝
Fig. 1 Pavement defect images:(a) Longitudinal crack;(b) Transverse crack;(c) Mesh crack;(d) Pothole;(e) Manhole cover;(f) Pothole patch;(g) Longitudinal patch;(h) Transverse patch;(i) Mesh patch

它可以细分为纵向裂缝、横向裂缝和网状裂缝。网状裂缝呈不规则网状结构,而横向和纵向分别表现为与行车方向基本保持垂直和平行。

图 1 中路面坑洞图 1(d)通常是由其他病害未得到及时处理而逐渐发展形成的,如密集的网状裂缝和表面破損等。坑洞的深度深浅不一,浅的坑洞仅限于路面表层,往往是表面松散发展的结果。而深的坑洞可深至整个面层结构,一般是由网裂发展而成。这种类型的坑洞多发生在面层较厚的高级沥青公路上,这也意味着它对行车安全的威胁是最大的。路面修补(图 1(f)–(i))就是对各种裂纹和坑洞等缺陷进行修复。将受损部分移除并进行更换,或直接在路面上添加新材料。一般经过修复的部分路面坚固程度与原始路面相当,但是当补丁恶化时会严重影响行车安全,所以将修补列为缺陷的其中一类。施工井盖(图 1(e))的特征与一些坑洞以及坑洞补丁非常相似,因此为了不影响目标检测模型的检测效果将施工井盖单独分为一类。

2.2 数据获取

路面缺陷数据采集自冬季的中国内蒙古包头市部分路段。由于冬季昼夜温差大加上雨雪等因素,导致这段公路缺陷繁多,因此采用 DJI OSMO 运动相机连续拍摄沥青路面。

如图 2 所示,相机是放置在车辆后备箱上方,由于后备箱的遮挡,相机角度只能大于 55° 。当角度 α 为 55° 时,相机拍摄的最小尺寸约为 2650 mm。而现在公路的一条车道最小宽度是 3000 mm 左右,因此将相机角度设置为 70° ,帧率设置为 60。然后以速度 v 大约 60 km/h 对路面进行拍摄。在获得视频后,根据车辆的速度和有效距离来获取图像。由于摄像机

的有效距离 d 约为 4 m,为了不丢失信息,每秒获取的图像数应大于或等于 v/d 约为 4.17,因此取 5。

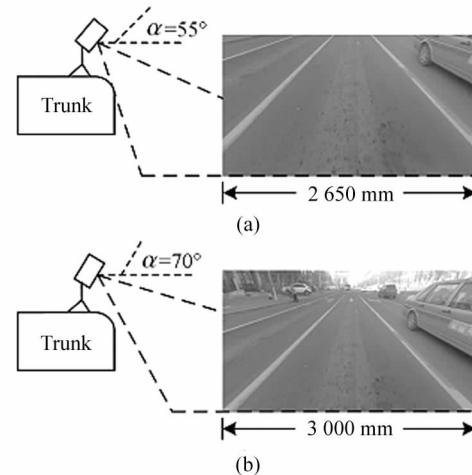


图 2 不同角度下的数据获取:(a) 55° ; (b) 70°

Fig. 2 Data collection from different angles:

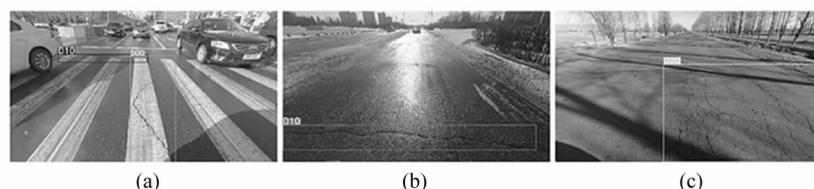
(a) 55° ; (b) 70°

采集到的图像经过人工筛选,得到 1437 幅仅包含明显路面缺陷的图像,再经过简单的数据增强一共得到 2874 幅路面缺陷图像,分辨率为 1920×1080 。最后标注这些数据形成了路面缺陷数据集 PDD。如表 1 和图 3 所示。PDD 缺陷类型丰富,共包含 5762 个缺陷目标。其中包括 1674 个纵向裂纹、1360 个横向裂纹、1418 个网状裂纹、728 个坑洞、188 个施工井盖以及各种修补 394 个。这些数据含有更加丰富的背景干扰,包括图 3(a)中的车道线、(b)中的雨雪污渍和眩光、(c)、(g)、(h)中的阴影。因此,可以很好地反映道路状况,更具有代表性。

表 1 路面缺陷数据

Tab. 1 Pavement defect data

Type	Label	Num
Longitudinal	D00	1674
Transverse	D10	1360
Mesh	D20	1418
Pothole	D40	728
Manhole cover	D50	188
Patch	D51	394
Total	—	5762



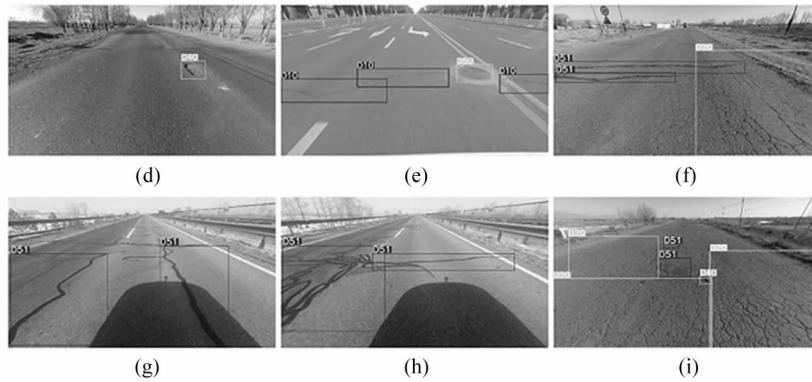


图 3 PDD 部分缺陷数据:(a) D00; (b) D10; (c) D20; (d) D40; (e) D50; (f)、(g)、(h)、(i) D51

Fig. 3 Defect images in PDD:(a) D00; (b) D10; (c) D20; (d) D40; (e) D50; (f),(g),(h),(i) D51

3 目标检测网络结构

使用深度神经网络执行检测分类的 YOLO 系列算法,因其速度快和准确率高等特点受到大量研究学者的追捧。YOLO 算法经历了 4 代的更新,迎来了该系列的第 5 代 YOLOv5 以及目前最新的 YOLOX。

YOLOv5 最大的创新之处在于将网络结构设计成可选择配置的方式,根据网络的深度和宽度可配置成 YOLOv5s、YOLOv5m、YOLOv5l 和 YOLOv5x 4 种网络结构,见图 4(c)。相比于 YOLOv3 和 v4,

YOLOv5 在网络中加入了 Focus 和 CSP(chip scale package)结构,见图 4(b)。Focus 结构的关键之处在于它对图像进行了切片操作。而 CSP 结构是 YOLOv5 借鉴了 CSPNet 的设计思路,将 CSP 结构应用到了 Backbone 和 Neck 中,分别为 CSP1_X 和 CSP2_X。其中 CSP1_X 加入了 X 个残差块和若干卷积操作,而 CSP2_X 中使用 2X 个卷积块代替了残差块。因此根据 CSP1_X 和 CSP2_X 中 X 的大小就决定了 YOLOv5x 结构的深度和宽度,进而形成了 YOLOv5s、YOLOv5m、YOLOv5l 和 YOLOv5x 4 种网络结构。

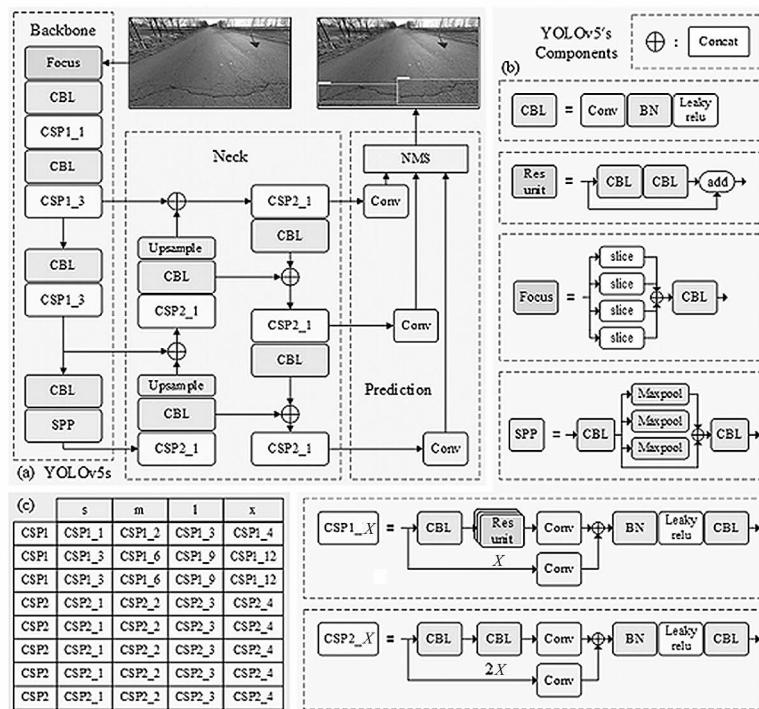


图 4 YOLOv5 网络结构图

Fig. 4 Network structure of YOLOv5

4 实验过程与结果

在实验部分使用了目前目标检测领域较为流行的 SSD、Faster R-CNN、YOLOv5 和 YOLOX 进行比较。其中 YOLOv5 使用了 x 模型。数据集使用了自行建立的 PDD。

4.1 实验设备与超参数设置

模型训练使用的服务器配置为 GPU: 2×Nvidia GeForce RTX2080Ti, 22 GB。在训练过程中,为了更有效地进行对照实验,设置超参数 Batch size 为 8,每次训练设置 500 个 epoch,初始学习率 (learning rate, LR) 为 0.001。使用 Adam 优化器来收敛网络,并使用 Adam 的动量和自适应学习率来加快收敛速度。Adam 替代了经典随机梯度下降法 (stochastic gradient descent, SGD),可以更有效更新网络权重。

4.2 数据集与评价指标

PDD 包含 1920×1080 共 5762 幅缺陷图像,划分训练集 2069 幅、验证集 230 幅和测试集 575 幅。使用该数据集对 SSD、Faster R-CNN、YOLOv5x 和 YOLOX 4 种目标检测网络进行训练和测试。一般地,目标检测性能评价指标主要是 AP (average precision) 和 mAP (mean average precision),计算式如下:

$$precision = \frac{TP}{TP + FP}, \quad (1)$$

$$AP = \frac{\sum precision}{M}, \quad (2)$$

$$mAP = \frac{\sum AP}{N}, \quad (3)$$

式中, TP 为交并比 (intersection over union, IoU)^[16] 大于阈值的检测框数量,这里真实框只计算一次,FP 为 IoU 小于阈值的检测框数量,包括同一检测框多余的检测框数量, $\sum precision$ 为某一类别所有目标的精确率求和,M 为该类别目标总数, $\sum AP$ 为所有类别的 AP 值之和,N 为类别数。

4.3 实验结果

使用 4 种目标检测网络对数据集 PDD 进行训练和测评,并进行实验结果对比分析。如图 5 为 4 种目标检测网络模型在 PDD 上的训练 mAP 曲线,由图可以看出,Faster R-CNN 的收敛速度最快,大约 100 个 epoch 之后 mAP 就达到了 80% 以上,但是之后 mAP 达到 80.6% 不再增加。YOLOv5x 收敛速度较慢,大约 200 个 epoch 之后 mAP 达到了 90%,之后收敛在 87.5%。而 YOLOX 和 SSD 的收敛速度最慢,都是大约在 400 个 epoch 之后才收敛,mAP 最终分别稳定在 83.6% 和 72.7%。因此,从训练过程中可以看出,YOLOv5x 结合 mAP 和收敛速度来看为最优。

表 2 为 4 种网络在 PDD 上的测试结果。从表中可以看到经过训练的 4 种模型在 PDD 上的测试 mAP 指标都达到了 77% 上。从单类 AP 上看,YOLOv5x 对横向、纵向和网状裂纹以及井盖的检测效果最好,AP 分别为 91.7%、93.8%、96.1% 和 96.6%。YOLOX 对坑洞和补丁的效果最好,AP 分别为 90.0% 和 88.3%。而 YOLOv5x 对坑洞和补丁的检测仅次于 YOLOX,AP 分别为 86.4% 和 81.3%,并且 YOLOv5x 的 mAP 为 91%。从整体上看,YOLOv5x 在训练和检测方面为最优。因此,选择 YOLOv5x 进行后续的系统设计。

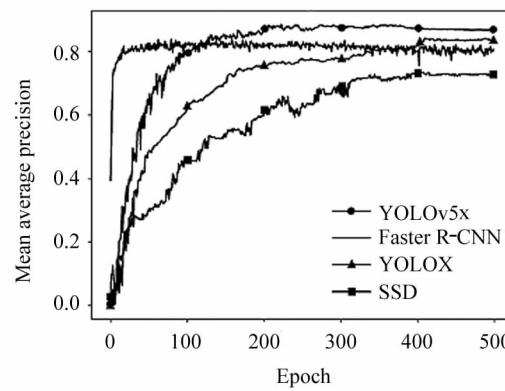


图 5 训练过程中 mAP 曲线

Fig. 5 The mAP curves during training

表 2 目标检测模型测试结果对比

Tab. 2 Comparison of target detection model test results

Methods	AP						mAP
	D00	D10	D20	D40	D50	D51	
SSD	0.810	0.857	0.908	0.672	0.840	0.548	0.772
Faster R-CNN	0.805	0.877	0.895	0.768	0.948	0.697	0.831
YOLOX	0.904	0.906	0.905	0.900	0.900	0.883	0.900
YOLOv5x	0.917	0.938	0.961	0.864	0.966	0.813	0.910

5 路面缺陷检测系统

路面缺陷检测系统框图如图 6 所示。缺陷图像经过 YOLOv5x 的检测得到每个缺陷的类别与位置坐标信息,如图 7(a)所示。为了还原缺陷的真实轮廓信息,根据拍摄高度与角度使用透视变换将每个缺陷图像从源倾斜视平面变换到新俯视平面,如图 7(b)所示,这样图像像素与真实尺寸就会有一个固定比例,便于计算图像分割后的缺陷量化信息。如图 7(c)所示,之后各种缺陷图像块经过 U-Net 分割得到黑白二值图像,黑色区域表示背景干扰,白色区域表示缺陷区域。使用轮廓提取算法提取缺陷区域计算缺陷的长度、宽度和面积参数,最后根据这些参数计算路面状况指数 (pavement condition index, PCI)。

对图像分割后的缺陷图像进行量化参数计算。根据缺陷图像像素数量 N 与缺陷实际尺寸 D 得到换算比例 ρ 为 N/D 。缺陷区域的像素数量为 n_1 ,则缺陷面积为 A_i 为 $\rho^2 \cdot n_1$ 。使用中轴法提取缺陷骨架如图 7(d)所示,则长度为 l 为 $\rho \cdot n_2$,其中 n_2 为提取后像素数量,那么等效宽度 w 为 A_i/l 。

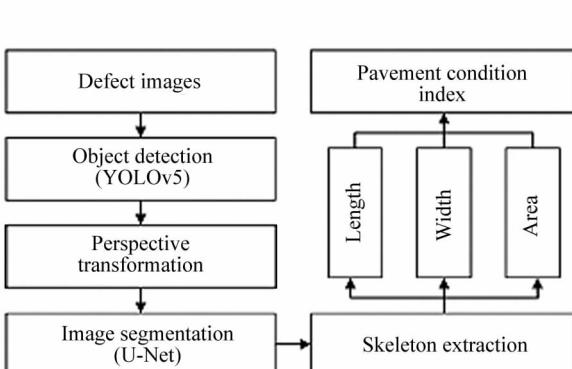


图 6 路面缺陷检测系统框图

Fig. 6 Framework of pavement defect detection system

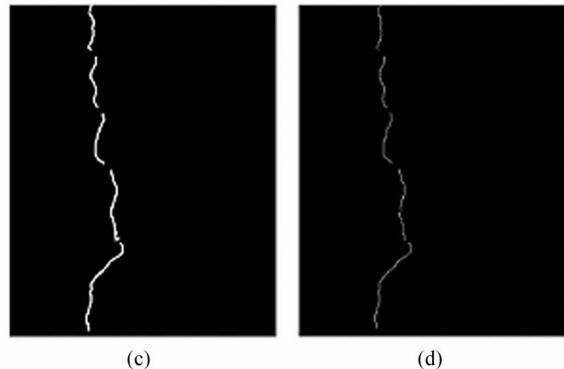
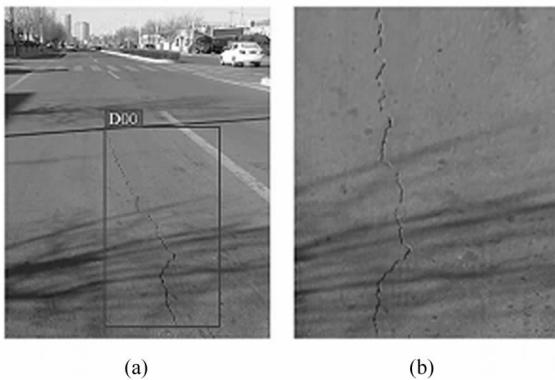


图 7 不同阶段的结果图:(a) 目标检测;
(b) 透视变换;(c) 图像分割;(d) 骨架提取

Fig. 7 The results of different stages:

- (a) Object detection; (b) Perspective transformation;
(b) Image segmentation; (d) Skeleton extraction

在路况评定中,一般采用破损类型和破损程度两个指标对其进行评定,但路况复杂,一段公路中各种缺陷类型的破损程度判定标准不一。为此,采用 PCI 进行评估。PCI 计算式如下:

$$PCI = 100 - a_0 DR^{a_i}, \quad (4)$$

$$DR = 100 \times \frac{\sum_{i=1}^{i_0} \omega_i A_i}{A}, \quad (5)$$

式中, A_i 为第 i 类缺陷区域面积, A 为路面总面积; ω_i 为第 i 类缺陷换算系数(横纵缝为 2、网缝和坑洞为 1、修补为 0.2),沥青路面 a_0 为 15, a_i 为 0.412。

PCI 的值域范围为 [0, 100],采用扣分机制来反映路面破损程度。各区间指标及维修意见见表 3。

路面缺陷自动检测系统对几种缺陷的检测效果如图 8 所示。从图中可以看出,纵向、横向、网状裂纹和坑洞缺陷图像分别经过系统中目标检测、透视变换、图像分割和 PCI 计算之后显示到被检测图像中,并根据 PCI 给出该路段的维修建议。

表 3 路面破损状况评价指标及养护意见^[1]

Tab. 3 Pavement damage evaluation indicators
and maintenance advice^[1]

Level	PCI	Maintenance advice
Excellent	(80, 100]	No repair, maintenance
Good	(70, 80]	Minor repairs
Middle	(50, 70]	Medium repairs, special maintenance
Poor	(30, 50]	Medium repairs, special maintenance
Worse	[0, 30]	Medium repairs, remodeling

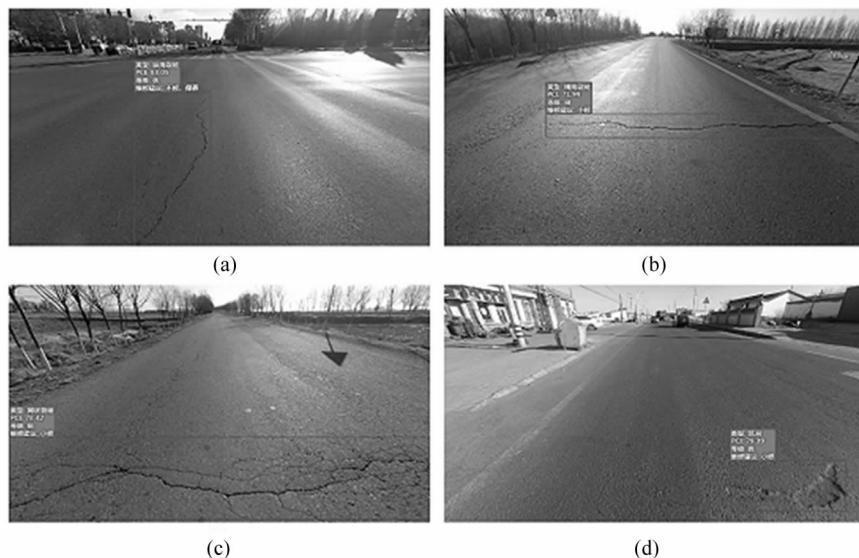


图8 系统检测效果图:(a) 纵向裂纹;(b) 横向裂纹;(c) 网状裂纹;(d) 坑洞

Fig.8 System detection results:(a) Longitudinal crack; (b) Transverse crack; (c) Mesh crack; (d) Pothole

6 结 论

路面缺陷的自动检测对路面状况评估意义重大。为了给路面维修提供理论依据,设计基于深度学习的路面缺陷自动检测系统,采集制作了多类型缺陷数据集PDD。为寻求优异模型,对比SSD、Faster R-CNN、YOLOv5x和YOLOX在PDD上的训练测试结果。经比较YOLOv5x最优,mAP为91%。路面缺陷图像首先经过YOLOv5x获取缺陷类别以及位置坐标。然后对检测后的图像经过透视变换和图像分割得到仅包含缺陷的黑白二值图像。最后进行裂缝骨架提取获取路面缺陷的长度、宽度和面积等信息,通过计算PCI得到路面破损等级,并给出相应的维修意见。本文设计的路面缺陷检测系统不仅能够对路面缺陷进行检测,而且根据路面图像可以直接得出路面状况以及相应的维修建议,增强了路面缺陷检测的实用性。

参考文献:

- [1] LUO Q R. Research on detection and recognition algorithm of pavement crack in complex background[D]. Chengdu:Xihua University,2019:1-11.
罗秋容.复杂背景下路面裂缝与识别算法研究[D].成都:西华大学,2019:1-11.
- [2] CHEN F C, JAHANSHAHI M R, WU R T, et al. A texture-based video processing methodology using Bayesian data fusion for autonomous crack detection on metallic surfaces [J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(4):271-287.
- [3] CUBERO-FERNANDEZ A, RODRIGUEZ-LOZANO F, Villalatoro R, et al. Efficient pavement crack detection and classification[J]. EURASIP Journal on Image and Video Processing, 2017, 2017(1):1-11.
- [4] 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.
- [5] LIU W, Anguelov D, Erhan D, et al. SSD:single shot multi-box detector[C]//European Conference on Computer Vision, October 11-14, 2016, Amsterdam, The Netherlands. Singapore:Springer, 2016:21-37.
- [6] 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, June 27-30, 2016, Las Vegas, NV, USA. New York:IEEE, 2016: 779-788.
- [7] GIRSHICK R. Fast R-CNN[C]//IEEE International Conference on Computer Vision, December 7-13, 2015, NW Washington, DC, United States. New York: IEEE, 2015: 1440-1448.
- [8] SUH G, CHA Y J. Deep faster R-CNN-based automated detection and localization of multiple types of damage [C]//Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2018, March 4-8, 2018, Denver, Colorado, United States. Washington: SPIE, 2018, 10598:105980T.
- [9] CHA Y J, CHOI W, SUH G, et al. Autonomous structural visual inspection using region-based deep learning for de-

- tecting multiple damage types[J]. Computer-Aided Civil and Infrastructure Engineering, 2018, 33(9):731-747.
- [10] FANG F, LI L, GU Y, et al. A novel hybrid approach for crack detection [J]. Pattern Recognition, 2020, 107: 107474.
- [11] MAEDA H, SEKIMOTO Y, SETO T, et al. Road damage detection and classification using deep neural networks with smartphone images[J]. Computer-Aided Civil and Infrastructure Engineering, 2018, 33(12):1127-1141.
- [12] MAEDA H, KASHIYAMA T, SEKIMOTO Y, et al. Generative adversarial network for road damage detection[J]. Computer-Aided Civil and Infrastructure Engineering, 2021, 36(1):47-60.
- [13] REDMON J, FARHADI A. YOLO9000:better, faster, stronger[C]//IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Hawaii, USA. New York: IEEE, 2017:7263-7271.
- [14] REDMON J, FARHADI A. Yolov3:an incremental improvement[EB/OL]. (2018-04-08)[2022-02-12]. <http://arxiv.org/abs/1804.02767>.
- [15] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4:optimal speed and accuracy of object detection[EB/OL]. (2020-04-23)[2022-02-12]. <http://arxiv.org/abs/2004.10934>.
- [16] GE Z, LIU S, WANG F, et al. Yolox:exceeding yolo series in 2021[EB/OL]. (2021-07-18)[2022-02-12]. <http://arxiv.org/abs/2107.08430>.
- [17] MANDAL V, MUSSAH A R, ADU-GYAMFI Y. Deep learning frameworks for pavement distress classification: A comparative analysis[C]//2020 IEEE International Conference on Big Data (Big Data), December 10-13, 2020, Atlanta, GA, USA. New York: IEEE, 2020:5577-5583.
- [18] ZHOU X, WANG D, KRAHENBUHL P. Objects as points [EB/OL]. (2019-04-16)[2022-02-12]. <http://arxiv.org/abs/1904.07850>.
- [19] TAN M, PANG R, LE Q V. Efficientdet:scalable and efficient object detection[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 13-19, 2020, Seattle, USA. New York: IEEE, 2020:10781-10790.

作者简介:

李 琦 (1973—),男,硕士,教授,硕士生导师,主要从事复杂工业过程优化控制方面的研究。