

一种轻量化网络的道路病害检测方法研究

刘鹏杰, 姚金杰, 高 晶, 郭钰荣

(中北大学 信息探测与处理山西省重点实验室, 太原 030051)

摘要: 针对道路病害检测中道路情况复杂、实时检测较为困难, 缺检漏检等问题, 采集并制作了多类型道路病害数据集 R-CRACK, 在 YOLOv5s 模型基础上, 在 Neck 模块上使用轻量化卷积 GSConv 模块替换部分标准卷积构建轻量化网络颈部; 在 Head 模块上利用 SimSPPF 对空间金字塔池化方式进行改进并应用轻量级上采样算子 CARAFE, 而后得到 GSC-YOLO 模型; 将 GSC-YOLO 模型利用矩形推理、图像加权, 标签平滑处理方式对数据集 R-CRACK 中训练集部分进行训练; 模型训练后的结果表明, 与 YOLOv5s 基础模型相比, GSC-YOLO 参数量减少 6.8%、计算量减少 4.8%、 mAP (@.5) 上涨了 9.2%; 利用改进前后的网络模型分别对单一及复杂环境下的道路病害进行检测, 通过对比不同模型的检测效果, 证明了 GSC-YOLO 模型针对 YOLOv5s 缺检漏检等问题有所改进, 此类轻量化检测网络对解决道路病害检测有着重要意义。

关键词: 道路病害检测; YOLOv5; 缺陷漏检; CARAFE; GSConv

Study on Road Defect Detection Method for Lightweight Networks

LIU Pengjie, YAO Jinjie, GAO Jing, GUO Yurong

(Shanxi Key Laboratory of Information Detection and Processing, North University of China,
Taiyuan 030051, China)

Abstract: In response to the challenges of complex road conditions, difficult real-time detection, and missing detection and inspection in road distress detection, a multi-type road distress dataset R-CRACK is collected and presented. Based on the YOLOv5s model, lightweight GSConv modules are used to replace some standard convolutions in the Neck module to construct a lightweight network neck. In the Head module, the SimSPPF is applied to improve the spatial pyramid pooling method, utilize the lightweight upsampling operator CARAFE, and obtain the GSC-YOLO model. The rectangle inference, image weighting, and label smoothing techniques are used to train the GSC-YOLO model on the training part in the dataset R-CRACK. The results of the trained model show that compared with the base YOLOv5s model, the GSC-YOLO model reduces the parameter by 6.8%, the computation by 4.8%, and improves the mAP (@.5) by 9.2%. The improved network models are used to detect road defects in both single and complex environments. Comparison results of different models show that the GSC-YOLO model improves the shortcomings of YOLOv5s in terms of defect missing detection. It is of significance for this lightweight detection network to solve road defect detection.

Keywords: road defect detection; YOLOv5; defect missing detection; CARAFE; GSConv

0 引言

交通产业在我国经济发展中起着重要作用。在国家交通运输部发布的最新报告《2022 年交通运输行业发展统计公报》中显示, 到 2022 年底, 全国公路养护里

程占到公路总里程的 99.9%^[1]。由此可知, 我国对公共道路已经进入大范围养护阶段。

人工检测和传统图像处理技术在早期传统的道路缺陷检测中占据主流, 例如在道路检测过程使用红外线测量技术^[2]或者是探地雷达, 这些方法很难在精度和速度

收稿日期:2024-01-29; 修回日期:2024-03-04。

基金项目:山西省重点研发计划项目(202102010101002);内蒙古自治区科技计划项目(2022YFSJ0031)。

作者简介:刘鹏杰(2001-),男,硕士研究生。

姚金杰(1982-),男,博士,副教授。

引用格式:刘鹏杰,姚金杰,高 晶,等.一种轻量化网络的道路病害检测方法研究[J].计算机测量与控制,2025,33(4):40-47.

上达到实际工程要求^[3]。而相关科学技术发展到下一阶段后, 道路病害检测主要通过支持向量机^[4]或基于区域生长的检测方法, 但此类机器学习方法在环境复杂时难以满足实际的检测要求^[5]。随着人工智能领域的快速发展, 诸多国内外学者利用人工智能相关方法解决道路病害检测问题。文献 [6] 首次利用卷积神经网络的通过研究证明卷积神经网络在复杂场景中道路病害的检测性能可以满足实际工程要求, 文献 [7] 通过深度学习提取道路表面裂缝, 在很大程度上代替了人工工作, 但此类模型泛化能力弱, 难以在复杂路面投入使用; 此后, Cha 等人利用 Faster-CNN^[8] 识别道路病害, 但算法模型过大, 难以实现实时检测要求。当前, 目标检测算法主要分为两类: 1) 以 Fast R-CNN 为代表的 Two-Stage 算法, 算法精度高, 文献 [9] 通过拟合值填充方式优化 Faster R-CNN 卷积层, 提升网络监测准确性, 但模型较大, 不能实现实时检测; 2) 以 SSD^[10] 及 YOLO^[11] 算法为代表的 One-Stage 算法, 模型较小, 可以实现实时检测, 但在检测过程中会损失一部分精度。针对缺陷、病害等目标检测任务, 文献 [12] 基于针对提取特征的主干部分对 SSD 模型进行改进, 文献 [13] 利用 YOLOv3^[14] 检测框架将模型输出优化改进, 而在文献 [15-17] 中, 国内学者尝试在 YOLOv5 上加入多种注意力机制加强对缺陷、病害中小目标信息的学习, 但在处理多类复杂数据集时仍未很好地解决其由于使用较大基础网络和较大感受野检测大尺寸目标, 对小目标不敏感的问题, 文献 [18] 通过引入 SE 注意力机制及 Transformer 模型解决图像在训练过程中因分辨率降低所造成的信息丢失, 文献 [19-20] 通过改进损失函数及引入 MobileNetV2 等模块对 YOLO 模型实现平衡轻量化, 文献 [21] 则通过 GhostNet 实现模型轻量化。

YOLO 和 Fast R-CNN 系列算法仍是目标检测领域内最常用的基础模型, 但如何权衡模型复杂程度与检测精度的问题仍需解决。在道路病害检测问题中, 时常需要面对坑洞、裂缝、标线模糊等道路病害在路面所占比例较小、不明显, 或坑洞, 井盖等病害特征与背景相似等问题, 需要在面对道路情况复杂或病害不明显等问题的同时进行实时性检测。为解决以上问题, 本文采集制作多类型道路病害数据集 R-CRACK, 基于 YOLOv5s 模型, 以轻量化卷积 GSConv^[22] 替换部分标准卷积, 构建更小的网络“颈部”, 通过其他改进方式做对比后证明模型以更低的参数量及计算量, 达到了更高的准确率, 而后通过 SimSPPF 及轻量化上采样算子 CARAFE^[23] 构建 GSC-YOLO 模型, 通过矩形推理及图像加权进行模型训练, 验证了该模型在训练过程中可以达

到更高的训练精度, 实际检测过程中针对多类病害表现出相较其他模型更细致的标注, 对解决道路病害检测问题有实际工程意义。

1 YOLOv5 网络结构及原理

1.1 YOLOv5s 网络模型

YOLO 系列算法作为目标检测领域 One-stage 系列算法的代表之作, 经过不断发展, 推出了 YOLOv4、YOLOv5, YOLOX^[24] 等经典算法。以 YOLOv5 为例, 其模型的最小权重文件仅有几十 MB 的同时性能优越, 这表明网络结构已经得到了显著的优化和压缩。本文选择 YOLOv5 6.1 版本中轻量化模型 YOLOv5s 进行实验及后续的改进, 其网络结构如图 1 所示。YOLOv5 网络结构可划分为 4 个部分, 即 Input、Backbone、Neck 以及 Prediction。




图 1 网络结构

要获得一个表现良好的神经网络模型, 往往需要大量的数据作支撑, 使用数据增强技术可以充分利用计算机来生成数据, 以此来增加数据量, 如采用缩放、平移、旋转、色彩变换等。数据增强的好处在于增加训练样本的数量, 同时添加合适的噪声数据, 提高模型的泛化能力。而在 YOLOv5 算法中, 输入端采用 Mosaic 数据增强, 其可以同时利用 4 幅不同照片随机排列、缩放及裁剪拼接等方式得到新图, 即选择 4 张原始图像 A、B、C、D 进行拼接, 假设每个图像尺寸为 (H, W, C) , 其中 H 为高度, W 为宽度, C 为通道数。首先, 选择一个目标位置作为 Mosaic 图像中心点, 表示为 (c_x, c_y) , c_x 和 c_y 为中心点的 x 和 y 坐标。例如将图像 A 的中心点作为新图像中心点, 计算每个原始图像在新图像中的位置和相对偏移量。假设 A 在新图像中占据的位置为 $(0, 0)$, B 的位置为 $(0, W)$, C 的位置为 $(H, 0)$, D 的位置为 (H, W) 。相对偏移量可以表示

为 $(0, 0)$ 、 $(0, W)$ 、 $(H, 0)$ 、 (H, W) 。原图像按照计算得到的位置和相对偏移量拼接在一起, 形成新图像。将 A 的像素复制到 Mosaic 图像的对应位置, 之后将 B 的像素复制到 Mosaic 图像的对应位置加上偏移量等, 则新图像的可以表示为:

$$Mosaic(x, y, c)_A = A(x, y, c) \quad (1)$$

$$Mosaic(x, y, c)_B = B\left(x, y - \frac{W}{2}, c\right) \quad (2)$$

$$Mosaic(x, y, c)_C = C\left(x - \frac{H}{2}, y, c\right) \quad (3)$$

$$Mosaic(x, y, c)_D = C\left(x - \frac{H}{2}, y - \frac{W}{2}, c\right) \quad (4)$$

其中: $Mosaic(x, y, c)$ 表示新图像在位置 (x, y) 处通道 c 的值。 $A(x, y, c)$ 、 $B(x, y, c)$ 、 $C(x, y, c)$ 和 $D(x, y, c)$ 分别表示原始图像 A、B、C 和 D 在相应位置处通道 c 的值。所以通过 Mosaic 操作, 在传入网络后相当于一次传入 4 张图片进行学习, 极大丰富了图像数据背景, 增加了训练数据的多样性和复杂度。在 Backbone 阶段, Focus 将输入的特征图切分, 假设输入特征图为 F , 形状为 (H_{in}, W_{in}, C_{in}) , 其中 H_{in} , W_{in} 分别为输入特征图的高度和宽度, C_{in} 为输入特征图通道数, Focus 对切分后小块进行卷积, 最后将卷积结果拼接, 形成输出特征图, 输出特征图的形状为 $(H_{out}, W_{out}, C_{out})$, 其中 H_{out} , W_{out} 分别为输出特征图的高度和宽度, C_{out} 为输出特征图的通道数, 而输入输出特征图的关系可以由下式表示:

$$H_{out} = \frac{H_{in}}{2} \quad (5)$$

$$W_{out} = \frac{W_{in}}{2} \quad (6)$$

$$C_{out} = C_{in} * 4 \quad (7)$$

由此可见, 这样可以有效减少计算量, 增加网络感受野。在 YOLOv5 6.0 中, 利用 SPPF 代替掉了 5.0 版本的 SPP 结构, 两种结构如图 2 所示。SPP 使用 5×5 、 9×9 、 13×13 , 步长为 1 的池化核, 只在最后一个卷积层特征图上执行金字塔池化; SPPF 使用多个 5×5 , 步长为 1 的池化核, 对整个图像执行金字塔池化操作。相比之下, SPPF 可以捕获到更多的上下文信息, 在目标与周围环境密切相关时具有更高的精度。而在 YOLOv6 中提出的 SimSPPF 中做出关于 ReLU 激活函数的改进, 该操作再一次提升了速度, 经测试, 单个 ConvBNReLU 速度比 ConvSiLU 快 18%。

在 YOLOv5 算法中, $batchsize$ 是批次大小, 表示每次训练时在训练集取样本进行训练的数量, 本文中 $batchsize$ 取 32; $epoch$ 指使用训练集中全部样本训练一次, 本文中 $epoch$ 取 300; 除此之外, 在训练过程中,




图 2 部分网络结构

使用矩形推理加速模型的推理过程, 这有利于模型在训练过程中减少一部分冗余信息; 启用加权图像策略, 针对每一轮训练效果不好的图片在下一轮增加一些权重, 解决样本不平衡问题; 对标签进行平滑处理, 若某个样本标注错误, 就可能产生“负面印象”, 平滑处理的作用便是“告诉”模型样本的标签不一定正确, 那么训练出的模型对于少量的样本错误就会有“免疫力”, 本文中对标签输入 95% 的正确率。

1.2 评价指标

一般地, 目标检测性能评价指标主要是 $Precision$ 、 $Recall$ 、 mAP , 其计算式如下:

$$Precision = \frac{TP}{TP + FP} \quad (8)$$

$$Recall = \frac{TP}{TP + FN} \quad (9)$$

$$AP = \frac{\sum Precision}{M} \quad (10)$$

$$mAP = \frac{\sum AP}{N} \quad (11)$$

式中, TP (True Positive) 表示模型正确地找到了目标并将其判别为正样本的情况; FP (False Positive) 表示模型错误地将不是目标的物体判别为目标的情况; FN (False Negative) 表示模型错误地将其分类为负样本或未检测到目标的情况。由此计算出的 $Precision$ (准确率) 用于衡量模型在所有被识别为正样本的样本中, 是真正的正样本的比例; $Recall$ (召回率) 用于衡量模型在所有正样本中正确检测出的比例; AP 代表数据集中某一类别的精确率, M 表示这一类的目标数, 而由 AP 计算出的 mAP 为整个模型的精确率, N 表示类别总数。 mAP 综合了各项参数的表现, 是衡量模型训练效果的重要参数。

2 YOLOv5 算法改进

YOLOv5 在提取特征的过程中涉及多次下采样操作, 这使特征信息出现丢失, 生成了大量冗余, 导致了 YOLOv5 对小目标的检测性能较差, 增加了模型复杂度的同时降低了模型计算速度, 影响训练后网络模型的实时性能。对于道路病害检测来说, 面对病害与背景相似、病害面积较小, 病害不明显等问题不能有效解决。因此, 为了改善 YOLOv5 在道路病害检测时对小目标或不明显目标不敏感等问题, 需要针对模型的缺陷进行调整。

特征上采样是现代卷积神经网络架构中的关键操作, 其设计对于目标检测任务至关重要。而在检测算法的上采样过程中, 轻量级 CARAFE 算子可以通过对输入特征图进行卷积核插值操作后生成高分辨率的特征图, 可以拥有更大的感受野及更快的计算速度, 而计算开销几乎可以忽略不计, 图 3 是 CARAFE 算子的整体框架。

CARAFE 算子由两个关键组件构成, 即内核预测模块和内容感知重组模块, 在对数据集中图片进行操作时, 大小为 $C * H * W$ 的特征图被上采样了 σ ($=2$) 倍。CARAFE 作为内容感知内核的重组运算符, 第一步根据每个目标的内容预测一个重组核, 第二步用预测的核对特征进行重组。卡拉菲作为内容感知内核的重组运算符。针对给定大小为 $C * H * W$ 的特征图 X 和上采样率 σ (假设 σ 是整数), CARAFE 将生成大小为 $C * \sigma H * \sigma W$ 的新特征图 X_1 。对于输出 X_1 的任意目标位置 $l' = (i', j')$, 在输入 X 处都有对应的源位置 $l = (i, j)$, 其中 $i = [i' / \sigma]$, $j = [j' / \sigma]$ 。将 $N(X_l, k)$ 表示为以位置 l 为中心的 X 的 $k * k$ 子区域, 即 X_l 的邻居。在第一步中, 核预测模块 φ 根据 X_l 的邻居预测每个位置 l' 的位置核 $W'_{l'}$, 如下式所示:

$$W'_{l'} = \varphi[N(X_l, k_{\text{encoder}})] \quad (12)$$

$$X'_{l'} = \varphi[N(X_l, k_{\text{up}}), W'_{l'}] \quad (13)$$

带有 CARAFE 算子的 FPN 架构, 在自上而下的路径中将特征图上采样 2 倍, 通过无缝替换最近邻插值集成到 FPN 中, 参数量 S 计算如下:

$$S = 2(C_{\text{in}} + 1)C_m + 2(C_m k_{\text{encoder}}^2 \sigma^2 k_{\text{up}}^2 + 1) \sigma^2 k_{\text{up}}^2 + 2 \sigma^2 k_{\text{up}}^2 C_{\text{in}} \quad (14)$$

检测速度和检测精度在目标检测中同样重要。在卷积神经网络 (CNN) 工作中, 输入的图像信息被通道传输, 每一次对空间的压缩都会导致部分信息的丢失, 在传输过程中, 若是采用标准卷积 (SC), 保证信道间最大程度连接的同时增加了时间复杂度和冗余; 但深度可分离卷积 (DSC) 则是几乎切断了信道间的连接^[22]。轻量化卷积模块 GSConv 通过组合两种卷积方式, 以较低的时间复杂度保留了大部分信道间的连接, 3 种卷积方式的结构如图 4 所示。通过 SC 及 DSC 组合的 GSConv, 整体结构和输出结果都更接近 SC。

而 3 种卷积方式的时间复杂度计算如:

$$\text{Time}_{\text{SC}} \sim O(W * H * K_1 * K_2 * C_1 * C_2) \quad (15)$$

$$\text{Time}_{\text{DSC}} \sim O(W * H * K_1 * K_2 * 1 * C_2) \quad (16)$$

$$\text{Time}_{\text{GSConv}} \sim O[W * H * K_1 * K_2 * \frac{C_2}{2}(C_1 + 1)] \quad (17)$$

式中, W 为输出特征图宽度, H 为输出特征图高度; $K_1 * K_2$ 为卷积核大小; C_1 为输入特征图通道数, C_2 为输出特征图通道数。通过比较时间复杂表达式可得, GSConv 的时间复杂度只有 SC 的 50% 左右, 但让大部分图像信息以更少的复杂度及更少的冗余传输下去, 从而更好捕捉目标的细节和结构信息, 提高模型准确性。所以在合适的位置使用 GSConv, 可以使 YOLOv5 在道路病害检测过程时减少其在特征传输过程中的冗余, 改




图 3 轻量级上采样算子框架

- 1) 将道路病害图像大小设为 640×640 , 图像深度 24 位;
- 2) 将道路病害图像进行随机裁剪、角度翻转等几何变换;
- 3) 将道路病害图像进行 ISO 曝光度降低、加入随机噪点、透视变换等方式进行数据增强, 以此模拟在采集过程中阴天、雨雪天等不同天气情况^[25]。

通过对道路病害图像进行预处理及多次筛选, 构建道路病害数据集 R-CRACK, R-CRACK 数据集中有丰富的道路病害图像及车辆、路牌、电线杆、楼房, 树木等背景干扰, 可以有效反映道路状况。R-CRACK 道路病害数据集中包含 6 类共 22 571 幅道路病害图像, 图 7 为部分数据集中病害图像数据。^[26]将 R-CRACK 数据集中道路病害图像数据随机划分为训练集、验证集、测试集 3 部分, 3 部分图像数量分别为: 训练集 19 185 幅, 验证集 2 257 幅, 测试集 1 129 幅。



图 7 部分道路病害图像数据

使用 make sense 对 3 部分图像数据进行数据标注, 病害标签数据量如表 1 所示。

表 1 R-CRACK 中各类数据标签

病害类型	标签	数量/幅
纵向裂缝	D00	7 936
横向裂缝	D10	5 656
龟裂	D20	8 381
坑洞	D40	6 381
标线模糊	D44	5 477
井盖高差	D50	3 764

3.3 不同网络结构训练参数对比

采用 R-CRACK 中训练集部分对模型进行训练, 训练过程中, Batch size 设为 32、epoch 为 300, 图片大小为 640×640 , 本文中将 YOLOv5s 作为基础模型, 分别在基础模型上:

- 1) 加入 SEnet 注意力机制, 命名为 SE-YOLO;

- 2) 移植 YOLOv6 的 Neck 模块, 命名为 Bi-YOLO;
- 3) 将加入 GSConv 的 YOLOv5s 模型命名为 G-YOLO;
- 4) 在 G-YOLO 基础上加入 CARAFE 算子及 Sim-SPPF 的模型命名为 GSC-YOLO。

通过对基础模型 YOLOv5s 及 4 种改进模型通过矩形推理、图像加权及标签平滑处理进行训练, 训练过程中各项参数如表 2 所示。

表 2 不同网络结构参数对比

网络模型	<i>Parameters</i>	<i>GFLOPs</i> /%	<i>Precision</i> /%	<i>Recall</i> /%	<i>mAP</i> @.5 /%	<i>mAP</i> @.5 : 95/%
YOLOv5s	7 225 885	16.6	56.4	56.6	51.9	23.5
SE-YOLO	7 320 583	16.6	60.7	53.9	52.9	23.6
Bi-YOLO	7 388 775	17.0	62.3	58.7	55.1	27.1
G-YOLO	6 605 039	15.5	66.6	60.9	59.7	28.2
GSC-YOLO	6 739 695	15.8	68.5	65.0	61.1	29.9

由表 2 中数据可得, 针对本文基础模型 YOLOv5s 进行改进, 不同改进方式在训练过程中对各项参数有不同效果, 具体如下:

- 1) SE-YOLO 在训练过程中 *Parameters* 增加 1.3%; *GFLOPs* 无明显变化; *Precision* 上涨 4.3%; *Recall* 下降 2.7%; *mAP*@.5 上涨 1.0%; *mAP*@.5 : 95 上涨 0.1%;
- 2) Bi-YOLO 在训练过程中 *Parameters* 增加 2.3%; *GFLOPs* 增加 2.4%; *Precision* 上涨 5.9%; *Recall* 上涨 2.1%; *mAP*@.5 上涨 3.2%; *mAP*@.5 : 95 上涨 3.6%;
- 3) G-YOLO 在训练过程中 *Parameters* 减小 8.5%; *GFLOPs* 减小 6.6%; *Precision* 上涨 10.2%; *Recall* 上涨 4.3%; *mAP*@.5 上涨 7.8%; *mAP*@.5 : 95 上涨 4.7%;
- 4) GSC-YOLO 在训练过程中 *Parameters* 减小 6.8%; *GFLOPs* 减小 4.8%; *Precision* 上涨 12.1%; *Recall* 上涨 8.4%; *mAP*@.5 上涨 9.2%; *mAP*@.5 : 95 上涨 6.4%。

由表 2 可得, GSC-YOLO 在 R-CRACK 数据集上的训练过程中, 各项训练参数都得到了更大的提升。综上所述, GSC-YOLO 模型相比基础模型 YOLOv5s, 以更小的参数量、计算量, 达到了相较于其余改进方法更优的训练参数, 通过观察 YOLOv5s、SE-YOLO、Bi-YOLO、G-YOLO、GSC-YOLO 训练过程中 *mAP*@.5 参数变化曲线图判断模型收敛情况, 如图 8 为 5 种网络模型训练过程中的 *mAP*@.5 曲线。

观察 5 种网络模型 *mAP* (@.5) 曲线的变化情况




图 8 训练过程中参数曲线

可得，基于 YOLOv5s 的 4 种改进方式与 YOLOv5s 相比，SE-YOLO 模型与 Bi-YOLO 模型的 $mAP(@.5)$ 曲线变化情况相较于基础模型差别不明显；G-YOLO 模型约在迭代次数 epoch 达到 100 后， $mAP(@.5)$ 逐渐高于 YOLOv5s、SE-YOLO 及 Bi-YOLO，且逐渐收敛；而 GSC-YOLO 模型的 $mAP(@.5)$ 曲线在开始训练后逐渐高于另外几种模型，且 GSC-YOLO 相较于其他模型收敛速度最快，达到了更高、更优的训练效果。

因此，结合 5 种网络模型训练过程中各项参数及 $mAP(@.5)$ 曲线的变化情况，分析后得出，相比其余 4 种网络模型，GSC-YOLO 在多类型道路病害数据集 R-CRACK 上的训练效果更优。

3.4 不同网络结构检测效果对比

训练结束后，将 5 种网络模型训练过程中最优权重 (best. pt) 作为测试过程中的网络模型权重输入，分别对多类道路病害数据集 R-CRACK 中测试集中共 1 129 幅道路病害图像进行道路病害检测实验，表 3 为 5 种网络模型在道路病害检测实验过程中的参数对比。

表 3 不同网络结构测试情况对比

网络模型	$mAP(\text{best. pt})$	图片数量/幅	所用时间/s
YOLOv5s	0.572	1 129	91.83
SE-YOLO	0.579	1 129	88.98
Bi-YOLO	0.583	1 129	44.28
G-YOLO	0.604	1 129	39.69
GSC-YOLO	0.621	1 129	39.89


由于在道路病害检测过程涉及多类病害图像，在检测过程中对不同类型的道路病害通过对 RGB 三原色进行不同程度的吸取及筛选及调整后，对 YOLOv5 算法中检测框颜色规定变量更改，形成多种不同颜色的道路病害识别框，如表 4 为不同类型病害对应色卡。

通过对 6 种病害界定不同色卡，利用 5 种网络模型对 R-CRACK 测试集中道路病害图像进行测试。

表 4 R-CRACK 中各类病害色卡

病害标签	色卡
D00	[0,131,252]
D10	[190,90,92]
D20	[142,154,78]
D40	[2,76,82]
D44	[119,80,5]
D50	[189,163,234]

在道路病害检测问题中，除了正常的病害检测以外，道路两旁的电线、楼房、路牌杆等在对道路病害的检测中有较大干扰；而在大量的车辆使用道路之后所产生的坑洞、裂缝等通常与道路表面的颜色、形状等特征相近，这可能会造成模型的缺检漏检。5 种网络模型在检测测试集中道路病害后，对不同环境情况下的道路病害检测后对效果进行对比，图 9 是部分道路病害检测后的效果对比。



(a) YOLOv5s (b) SE-YOLO (c) Bi-YOLO (d) G-YOLO (e) GSC-YOLO

图 9 检测效果对比

观察图 9 中不同网络模型对道路病害图像的检测效果：

1) 在对没有背景干扰情况下的单一类型及数量病害进行检测时，GSC-YOLO 模型相较其他网络模型可以检测出准确率更高的检测结果；

2) 在对没有背景干扰情况下单一类型、多个数量病害进行检测时，GSC-YOLO 模型可以检测出更多的道路病害及准确率更高的检测结果；

3) 在对有电线杆、房屋等背景干扰的复杂道路情况进行检测时，不论是病害数量或是检测精度，GSC-YOLO 模型都可以给出其余模型所不具有的更好的检

测表现。

因此,通过对比测试集中测试结果可得,GSC-YOLO模型对于背景颜色或形状类似的坑洞、细小的横向及纵向裂缝等,都可以有效改善YOLO系列算法由于其单阶段检测而缺检漏检的问题,且能给出准确率更高的检测结果。

4 结束语

本文通过多种方式采集多类型道路病害数据集R-CRACK,利用轻量化卷积GSConv模块替换YOLOv5s中Neck部分的标准卷积模块以减小网络模型的参数量及计算量,在此基础上在Head部分加入SimSPPF及轻量级上采样算子CARAFE,在降低模型复杂度的同时减少了信息在传输时的冗余,以此提高模型性能。利用改进后的GSC-YOLO模型在R-CRACK上训练、检测,并通过其他改进方式作对比,结果表明,GSC-YOLO模型在减少复杂度的同时可以有效改善YOLOv5模型缺检漏检的问题,验证了模型的有效性,对道路病害检测领域有实际工程意义。

参考文献:

- [1] 交通运输部. 2022年交通运输行业发展统计公报 [N]. 中国交通报, 2023-06-16 (002).
- [2] 丁传鑫. 公路路面检测技术综述 [J]. 市政技术, 2013, 31 (6): 160-163.
- [3] 罗秋容. 复杂背景下面路面裂缝检测与识别算法研究 [D]. 成都: 西华大学, 2019.
- [4] CHENFC, JAHANSHAHIMR, WUR T, et al. A texturebased video processing methodology using Bayesian datafusion for autonomous crack detection on metallic surfaces [J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32 (4): 271-287.
- [5] 王鑫, 李琦. 基于深度学习的路面缺陷自动检测系统 [J]. 光电子·激光, 2022, 33 (11): 1165-1172.
- [6] ZHANG L, YANG F, ZHANG Y D. Road crack detection using deep convolutional neural network [C] //IEEE International Conference in Image Processing, 2016: 3708-3712.
- [7] CHA Y J. Deep learning-based crack damage detection using convolutional neural networks [J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32 (5): 361-378.
- [8] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards realtime object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39 (6): 1137-1149.
- [9] 杨盼盼, 郭杨成. 基于深度学习的城市道路沥青路面病害智能检测仿真实验 [J]. 粘接, 2023, 50 (12): 174-178.
- [10] WEI L, DRAGOMIR A, DUMITRU E, et al. SSD: single shot multibox detector [J]. Computer Vision ECCV, 2016, 9905 (4): 21-37.
- [11] REDMON J, FARHADI A. YOLO9000: better, faster, stronger [C] //IEEE Conference on Computer Vision & Pattern Recognition, 2017: 6517-6525.
- [12] 周秋红. 基于改进SSD模型的道路病害检测研究 [J]. 黑龙江交通科技, 2023, 46 (4): 30-32.
- [13] DU Y C, PAN N, XU Z H, et al. Pavement distress detection and classification based on YOLO network [J]. International Journal of Pavement Engineering, 2020, 22 (13): 1-14.
- [14] REDMON J, FARHADI A. YOLOv3: an incremental improvement [J/OL]. CoRR, 2018, abs/1804.02767. arXiv:1804.02767. <http://arxiv.org/abs/1804.02767>.
- [15] 张用川, 牟凤云, 陈建坤, 等. 基于改进YOLOv5算法的道路损伤检测 [J]. 电子测量技术, 2023, 46 (4): 161-168.
- [16] 吴丽娟, 黄尧, 关贵明. 基于改进YOLOv5的道路目标检测 [J]. 沈阳师范大学学报 (自然科学版), 2023, 41 (1): 85-91.
- [17] 孙泽强, 陈炳才, 崔晓博, 等. 融合频域注意力机制和解耦头的YOLOv5带钢表面缺陷检测 [J]. 计算机应用, 2023, 43 (1): 242-249.
- [18] 李珊. 基于YOLOv5的道路病害检测与分类研究 [J]. 现代计算机, 2021, 27 (35): 75-79.
- [19] 陈实. 轻量化改进的YOLOv5与道路病害实时检测 [D]. 武汉: 武汉大学, 2022.
- [20] 张欢欢. 基于YOLOv5的道路病害检测模型改进方法的研究与应用 [D]. 上海: 华东师范大学, 2022.
- [21] 王毓. 基于YOLOv5的道路缺陷检测算法研究 [D]. 南京: 南京信息工程大学, 2023.
- [22] LI H, LI J, WEI H, et al. Slim-neck by GSConv: a better design paradigm of detector architectures for autonomous vehicles [EB/OL]. (2023-11-12) [2021-11-14]. <https://ui.adsabs.harvard.edu/abs/2022arXiv220602424L/abstract>.
- [23] WANG J, CHEN K, XU R, et al. Carafe: content-aware assembly of features [C] //Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 3007-3016.
- [24] GE Z, LIU S, WANG F, et al. YOLOX: Exceeding YOLO Series in 2021 [J/OL]. CoRR, 2021, abs/2107.08430. arXiv:2107.08430. <https://arxiv.org/abs/2107.08430>.
- [25] 刘宪明, 辛公锋. 国内基于深度学习的道路路面病害检测研究综述 [J]. 电子世界, 2021 (8): 96-98.
- [26] 罗瑞. 基于图像处理的路面裂缝检测算法研究 [D]. 芜湖: 安徽工程大学, 2017.