光电技术及应用

DOI：10.16818/j.issn1001－5868.2024060301

基于深度学习的桥梁表观病害检测

侯周阳[1]，杨莉琼[2*]，张桂荧[2]，肖宇峰[1]

（西南科技大学 1. 信息工程学院；2. 土木工程与建筑学院，四川 绵阳 621010）

摘　要： 混凝土桥梁表观病害检测对桥梁维护至关重要。然而，现有基于机器视觉的方法在处理小尺寸病害和复杂背景时存在检测效率低、精度不高的问题。文章基于YOLOv5提出了一种新型检测网络，通过优化YOLOv5主干网络、引入全局注意力机制以及多尺度金字塔空间池化结构，有效提升了检测精度与效率，尤其在面对复杂背景下小尺寸病害检测方面表现出色。实验结果表明：改进后模型的平均检测精度较原网络结构提升了4.1%；同YOLOv7相比，所提出方法的平均检测精度高了2.3%、检测速度快了30%。

关键词： 桥梁工程；损伤识别；深度学习；表观病害；注意力机制

中图分类号： TP391.4　**文章编号：** 1001－5868(2024)06－0990－08

Deep Learning-Based Apparent Defect Detection in Bridges

HOU Zhouyang[1], YANG Liqiong[2], ZHANG Guiying[2], XIAO Yufeng[1]

(1. Faculty of Information Engineering; 2. Faculty of Civil Engineering and Architecture, Southwest University of Science and Technology, Mianyang 621010, CHN)

Abstract: Detection of concrete bridge surface damage is crucial for bridge maintenance. However, existing machine vision-based methods suffer from low detection efficiency and accuracy when dealing with small-scale damages and complex backgrounds. In this paper, a novel detection network based on YOLOv5 is proposed. By optimizing the YOLOv5 backbone network and introducing a global attention mechanism along with a multiscale pyramid spatial pooling structure, detection accuracy and efficiency are effectively improved, especially in the detection of small-scale damages in complex backgrounds. Experimental results show that average detection accuracy of the improved model increased by 4.1% compared to that of the original network structure, surpassing that of YOLOv7 and YOLOv5 in detection performance on small-scale damages, such as holes and complex backgrounds. The proposed method achieved a 2.3% increase in average detection accuracy and a 30% improvement in detection speed over YOLOv7.

Key words: bridge engineering; damage identification; deep learning; apparent defects; attention mechanism

0　引言

桥梁作为公共设施的重要组成部分，随着服役年限的增加，会出现各种病害问题，极易对公共安全产生严重威胁[1]。目前，桥梁的维护检测仍依赖于人工观测，但桥梁结构作为跨越物，工作环境复杂，使得维护检测工作开展困难且有较大安全隐患[2]。我国存在大量待检桥梁，但专业检修人员有限，客观上增加了管养部门的压力和桥梁养护工作的难度[3]。因此，对桥梁检测进行优化，使其更高效、智

收稿日期：2024－06－03.

基金项目：中央引导地方科技发展项目(2022ZYDF083).

* **通信作者：**杨莉琼

能化和信息化显得尤为重要。

混凝土桥梁表观病害主要包括裂缝、风化、孔洞、剥落掉角以及麻面等，其中裂缝和剥落掉角对桥梁结构强度和稳定性产生重大影响[4]。随着计算机技术的发展，研究者开始利用数字图像信息对桥梁表观病害或桥梁整体健康情况进行分析[5]。有研究者将 Canny 边缘检测算子同 Otsu 算法相结合对裂缝实现识别分割[6]，还有通过监测工作状态下桥梁的伸缩缝变化来实现对桥梁宏观上的安全性监控[7]。近年来，由于基于深度学习的检测技术越来越成熟，将基于深度学习的检测算法应用到桥梁病害识别任务上备受关注。Zhang 等[8]对 VGG-16 模型进行优化调整最终实现了对裂缝和破损这两种病害的分类。Cha 等[9]基于双阶段经典检测网络 Faster-RCNN 对混凝土裂缝和两级钢腐蚀等五种病害均实现较高精度的检测，但在检测速度上，双阶段网络要弱于单阶段网络。周清松等[10]向 YOLOv3 的特征提取网络引入 DenseNet 密集型连接网络结构，有效提高了桥梁病害特征在网络中的传播率和利用率，在减少训练时间的基础上实现了更高的检测精度。Yu 等[11]在 YOLOv4 的基础上提出了 YOLOv4-FPM 网络检测算法，针对不同类型的裂缝病害，通过 Focal Loss 提高裂缝的分类精度，同时利用减枝技术有效地减少了模型参数量，降低模型复杂度，提高检测速率，但并不能对非裂缝病害进行有效识别，可用性不高。廖延娜等[12]在 YOLOX 算法基础上进行优化实现了对腐蚀、裂纹、风化和露筋脱落等病害的检测，平均检测精度较原模型提升了 4.40%，但并未考虑检测速度。

已有研究针对桥梁表观病害检测取得了一定的成果，但仍存在不足。针对桥梁表观病害检测多局限于裂缝检测，而基于深度学习的检测算法在检测精度、速度都还有提升空间，特别是面对复杂背景以及小尺寸病害检测时，漏检率较高。鉴于此，本文基于 YOLOv5s 模型，提出了一种更高效、更准确的表观病害检测网络 F-YOLOv5-SPGS。实验结果表明，改进后的算法有效解决了面对复杂环境下病害检测的不足和面对小多尺寸病害时的漏检问题。

1　网络模型与改进

1.1　桥梁表观病害检测网络结构

根据算法的实际工作环境与检测目标的特性，针对 YOLOv5 原网络进行优化改进，使改进后的网络在检测桥梁表观病害时，检测精度更高，检测速率更快，面对复杂环境和小尺寸病害的漏检率更低。改进后的网络结构如图 1 所示。

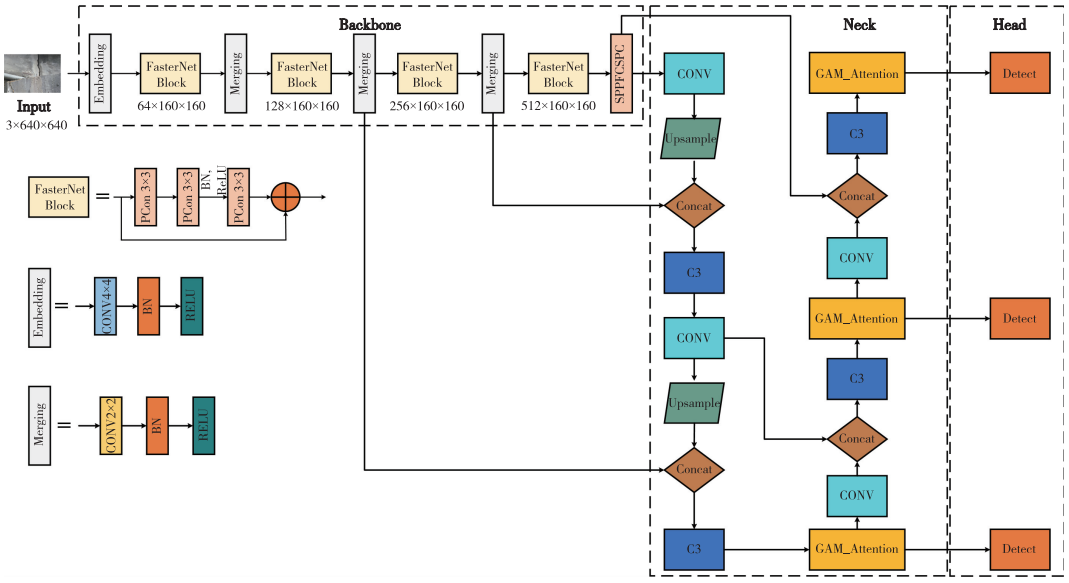


图 1　整体网络结构图

改进后的网络结构仍然由主干网络、颈部网络和检测头三个部分构成。主要针对 YOLOv5s-6.2 改进了四个部分。首先将原本网络的主干网络 CSPDarkNet53 替换为速度更快的 FasterNet 网络结构，降低对内存的访问频率以及特征图的冗余计算，提高检测速率；然后为弥补轻量化主干网络特征

提取能力较弱的问题，使用 SPPFCSPC 替换掉原网络结构中的 SPPF，以此来弥补轻量化主干网络带来的特征提取能力不足的问题，提升对不同尺度病害的感知能力；为提高检测精度与效率，在颈部网络末尾处引入全局注意力机制 GAM[13]，提高检测算法在复杂背景下对病害的聚焦程度，提高网络对；最后，结合检测数据特点将原网络使用的 CIoU Loss 更换为更全面的 SIoU loss[14]，加快模型训练时收敛速度，提高检测效率和整体的检测效果。

1.2 基于 FasterNet 更快的主干网络

在当前主流的轻量化检测网络的结构设计中，如：ShuffleNet[15]，GhostNet[16] 和 MobileNet[17] 均只关注如何得到更小的 FLOPs（Floating Point Operations）以此来提升算法的检测速度，而忽略了 FLOPS（Floating Point Operations Per Second）。由于对内存频繁的访问以及特征图的冗余计算，使得 FLOPS 并不高，在 FLOPs 降低到一定程度后，检测速度的提升便出现了瓶颈。因此，FasterNet 提出了 PConv[18] 卷积结构，以降低检测网络对内存反复的访问，以及对特征图卷积计算的计算量，提高检测速率。其结构如图 2 所示。

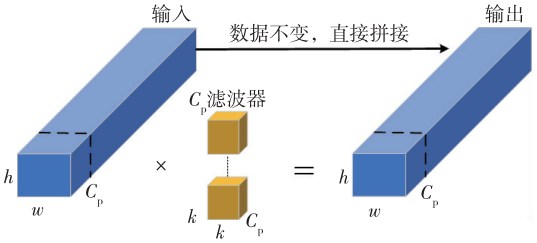


图 2 Pconv 卷积结构

由于输入特征图在不同的通道之间存在较多相似的特征信息，即冗余信息。因此，PConv 卷积计算时将输入分为两个部分，对前端深度 C_p 的部分进行卷积计算，剩余的深度的特征图在全端完成卷积后拼接在其后面，以此减少对冗余信息的重复计算。PConv 的卷积运算量与对内存访问量计算方式分别如式(1)～(2)所示：

$$h \times w \times k^2 \times C_p^2 \tag{1}$$

$$h \times w \times 2C_p + k^2 \times C_p^2 \approx h \times w \times 2C_p \tag{2}$$

式中，h 指输入特征图的高度，w 指输入特征图的宽度，C_p 指 PConv 卷积计算的深度，k 指卷积核大小。通常 C_p 取输入深度的 1/4，相较于经典卷积计算，PConv 卷积运算量减少到了 1/16，对于内存的访问量也相应的减小到了 1/4。这使得基于 FasterNet 需要计算的参数量更少，检测速度更快。

1.3 病害检测的多尺度空间金字塔池化

在实际检测任务中，待检目标尺寸往往多样，因此让网络训练不同尺度信息下的特征，可以使其具有更好的鲁棒性。通过空间金字塔池化（Spatial Pyramid Pooling，SPP）结构[19] 对特征图使用不同尺度的池化操作实现多尺度特征信息的融合从而提高检测网络针对不同尺寸检测目标的检测能力。

YOLOv5 原网络结构中基于 SPP 结构提出了 SPPF 主要改进的地方是将原 SPP 中并联的多个尺度的池化层改为串联结构并将池化层的步长大小统一为 5×5。这使得 SPPF 在获得了更快的处理速度的同时也更好地实现了不同尺度的信息融合。YOLOv7[20] 网络，在 SPP 的基础上增加了 CSP 模块，将经过 SPP 模块处理的数据同未处理数据进行合并。鉴于此，使用 SPPF 模块结构进行替换形成了 SPPFCSPC 结构，保证算法感受野不变的同时有效地提高检测精度。SPPFCSPC 网络结构如图 3 所示。应用 SPPFCSPC 模块后，面对实际桥梁检测的工作效果如图 4 所示。

在加入 SPPFCSPC 后，检测效果明显优于原结构的检测效果。在图 4(a)中，当面对待检测病害特征同环境相似度较高时，均出现了漏检，添加该结构后可以正常识别，同时关于病害检测框的吻合程度也优于原始网络。如图 4(b)和图 4(c)所示，当面对病害尺寸较小以及特征不明显时，原网络结构均出现了漏检，加入 SPPFCSPC 结构有效地解决了这一问题。在图 4(c)中，裂缝由于所处位置在检测边缘区域，特征信息较小且与环境信息相容程度较高，因此原网络结构未能正常识别，但引入 SPPFCSPC 有效解决了本问题。

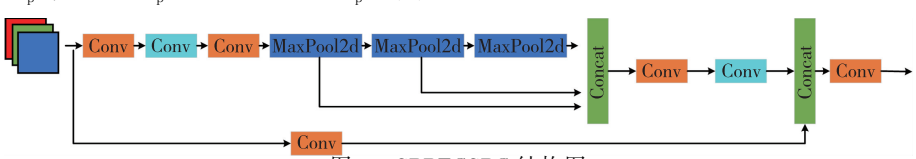
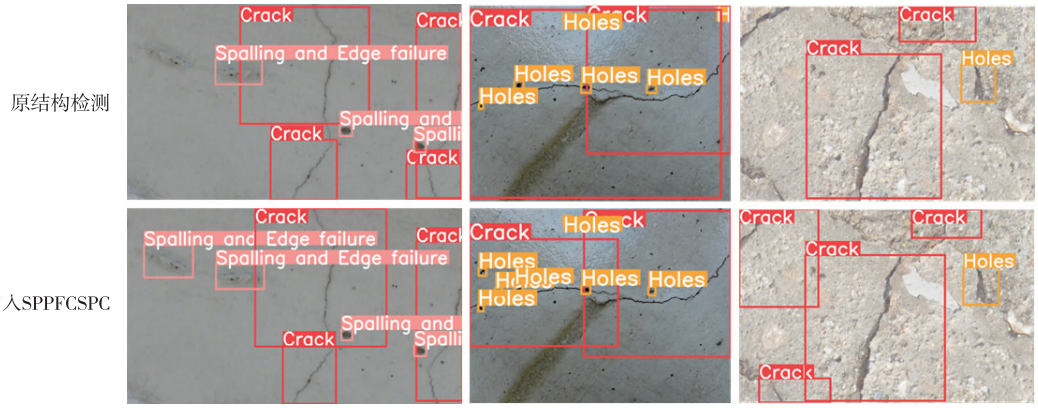


图 3 SPPFCSPC 结构图



（a）弱特征漏检改进　（b）小目标漏检改进　（c）局部特征漏检改进

图 4　SPPFCSPC 效果对比

1.4　全局注意力机制

为了使检测网络可以更加快速高效地锁定检测区域，提高其在复杂环境对表观病害聚焦的能力，引入了 GAM 全局注意力机制。

为获取更全面且可靠的注意力信息，通过自适应地选择通道与空间区域，将图像通道与空间维度信息进行融合。GAM 注意力机制在 CBAM (Convolutional Block Attention Module)[21] 的基础上发展而来，更注重通道与空间之间的相互作用，以弥补 CBAM 在跨维度信息上处理的不足。该注意力机制强调了在全局维度下的特征交互信息，即使在信息弥散较弱的情况下也能有效实现，其实现过程如图 5 所示。

整个过程由输入特征 F_1、中间状态 F_2 和输出状态 F_3 三部分构成。其计算关系式分别为：

$$F_2 = Mc(F_1) \odot F_1 \tag{3}$$

$$F_3 = Ms(F_2) \odot F_2 \tag{4}$$

式中，$F_1 \in R^{C \times H \times W}$，其中 C，H 和 W 分别代表输入特征图像的通道数、高度和宽度，Mc 和 Ms 分别是通道注意力图和空间注意力图，$\odot$ 表示依据元素进行对应的乘法操作。

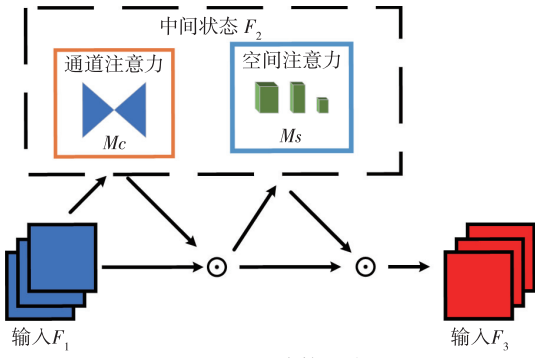
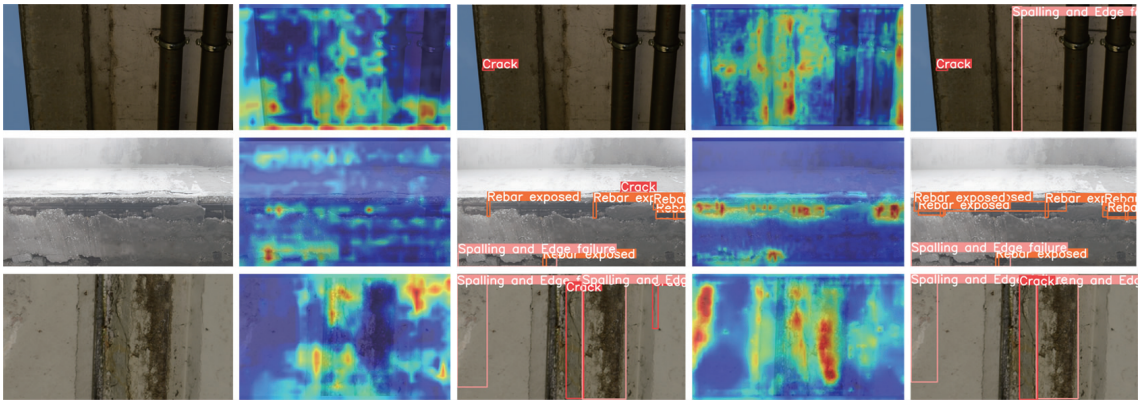


图 5　GAM 计算示意图

分别对引入全局注意力机制前后的网络输出使用 Grad-CAM（Gradient-weighted Class Activation Mapping）算法[22] 将网络对检测画面中各位置的关注程度进行热力图转换，颜色越鲜艳代表对该部分关注程度更高，分配的检测资源更多，如图 6 所示。



（a）检测画面　（b）YOLOv5热力图　（c）YOLOv5检测图　（d）引入GAM热力图　（e）引入GAM检测图

图 6　引入注意力机制效果对比

通过将网络对检测画面的关注度具象化后的热力图可以看出，在引入全局注意力机制后，网络在面

对复杂背景时能更好地关注到病害区域，有效优化了网络对病害区域资源分配，提高对表观病害定位精度，得到更好的检测效果。

1.5 损失函数优化

模型训练过程中，通过损失函数对当前训练结果进行评价，以帮助模型接下来的训练。YOLOv5的损失函数主要由检测框回归损失、目标置信度损失和类别损失三个部分构成。其中检测框回归损失主要基于计算训练过程中预测框和真实标注框间的IoU即交并比来计算。

原算法使用CIoU作为检测框回归损失计算函数，它在原IoU基础上增加了对预测框和真实框之间纵横比两个框中心距离的计算。但CIoU仅通过参数来反映预测框和真实框的纵横比，而非各个框的宽高与对应置信度的真实差异，且并未考虑预测框和真实框方向上的匹配。因此将原网络使用的CIoU优化为SIoU以得到更为优秀的检测精度、拟合效果以及收敛速度。SIoU如式(5)～(14)所示：

$$SIoU = IoU - \frac{\Delta + \Omega}{2} \tag{5}$$

$$\Delta = \sum_{t=x,y} (1 - e^{-\gamma \rho_t}) \tag{6}$$

$$\Omega = \sum_{t=w,h} (1 - e^{-\omega_t})^{\theta} \tag{7}$$

$$\rho_x = \left(\frac{b_{C_x}^{gt} - b_{C_x}}{C_w} \right)^2 \tag{8}$$

$$\rho_y = \left(\frac{b_{C_y}^{gt} - b_{C_y}}{C_h} \right)^2 \tag{9}$$

$$\gamma = 2 - \Lambda \tag{10}$$

$$\Lambda = 1 - 2 \times \sin^2 \left(\arcsin(x) - \frac{\pi}{4} \right) \tag{11}$$

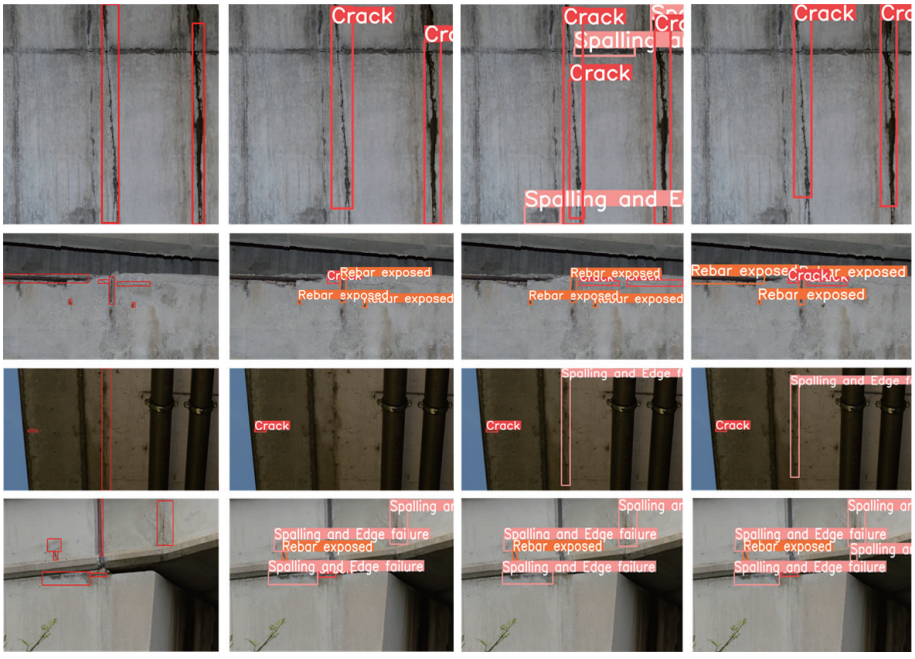
$$x = \frac{C_h}{\sigma} = \sin(\alpha) \tag{12}$$

$$\omega_w = \frac{|w - w^{gt}|}{\max(w, w^{gt})} \tag{13}$$

$$\omega_h = \frac{|h - h^{gt}|}{\max(h, h^{gt})} \tag{14}$$

式中，C_h 和 C_w 分别表示真实框和预测框中心点 Y 轴和 X 轴方向上差值的绝对值，C_x 和 C_y 分别表示能同时包括预测框和准确框的最小矩形的长度与宽度，σ 是两框中心点的连线，α 是中心点连线的夹角，h 和 w 分别代表预测框的高度与宽度，h^{gt} 和 w^{gt} 真实框的高度与宽度。

分别比较了基于SIoU，CIoU和DIoU损失函数训练的网络最终检测框与标注框吻合程度和检测效果，如图7所示。



（a）原始标注数据 （b）CIoU预测结果 （c）DIoU预测结果 （d）SIoU预测结果

图7 IoU检测效果对比

可以看出基于SIoU损失函数的网络要优于其他两种损失函数训练效果。当面对复杂的检测背景时，如第二排所示，基于CIoU和DIoU损失函数的训练网络均出现了对环境的漏检，而基于SIoU损

失函数检测正常；当面对的环境亮度较低时，基于 CIoU 训练模型出现了剥落漏检，SIoU 和 DIoU 均正常检测；当面对小尺寸病害检测时，如第四排所示，基于 CIoU 和 SIoU 损失函数训练网络均检测正常，基于 DIoU 训练模型出现了裂缝漏检。综合分析可以得出 SIoU 损失函数在本检测任务上要优于其他损失函数。

2　实验与分析

2.1　实验环境和数据集

硬件平台采用 Intel Core I7-8700K 处理器和 NVIDIA GeForce RTX3070 显卡；操作系统为 Windows10 专业版；软件环境基于 python3.8.10，采用 Pytorch 深度学习框架，版本为 1.13.1，采用 CUDA11.6 和 CUDNN 加速工具箱。

通过实地拍摄和网络收集，共采集混凝土桥梁各位置病害图像 2 462 张。利用 Albumentations 专业处理库，对采集到的图像进行了多方面处理，包括随机角度旋转；等比例添加高斯噪声、ISO 噪声以及乘法噪声；通过模拟运动模糊、中值模糊和普通模糊等方法等概率对图像进行模糊处理；此外，还对图像进行色彩增强，包括随机选择颜色抖动、对比度限制和自适应直方图均衡化以及通道重排的方法对图片进行增广。共获得 12 310 张图像作为数据集，用于训练。旨在提高训练网络的鲁棒性与泛用。

完成数据增强后将数据集按 8∶1∶1 的比例划分为训练集、测试集和验证集。训练时，每个批次输入 8 张图像，通过 Mosaic 算法对训练图片进行随机缩放与随机左右翻转的拼接操作，初始学习率和周期学习率均设为 0.01，权重衰减系数为 0.000 5，使用 SGD（Stochastic Gradient Descent）作为整体优化器以防止出现局部最优情况。共进行 200 轮训练，依据最终训练所得权重进行比较和检测效果对比。本算法的训练流程如图 8 所示。

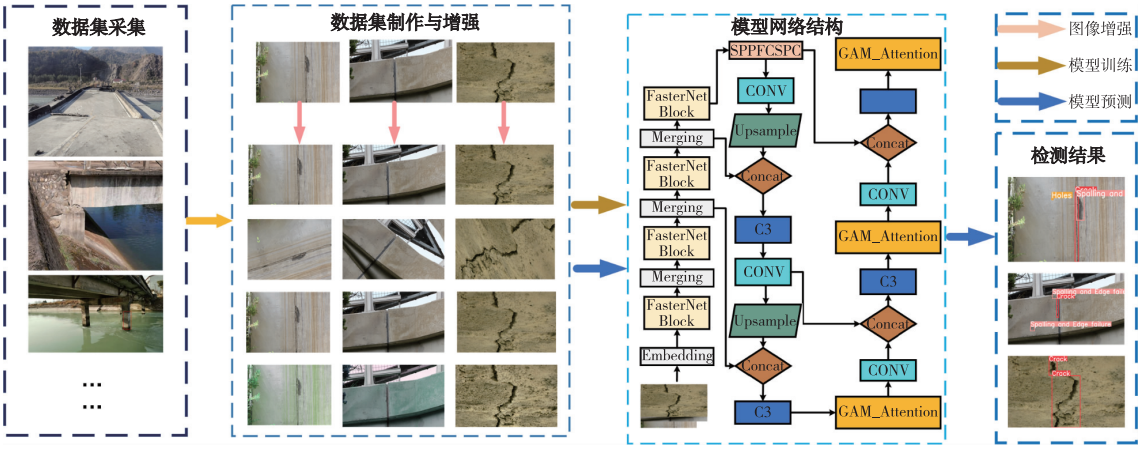


图 8　算法训练流程

2.2　模型评价标准

实验所得数据均由算法在相同实验环境下基于随机划分的验证集进行测量，每批次输入 8 张图片。

关于网络模型检测结果的评判标准，选取了准确率（P）、召回率（R）、平均精度（mAP），作为模型训练结果的评判标准，这也是当前主流的评价指标。各指标计算如式（15）～（17）所示：

$$P=\frac{TP}{TP+FP} \tag{15}$$

$$R=\frac{TP}{TP+FN} \tag{16}$$

$$mAP=\frac{\sum_{i=1}^{C}AP_i}{C} \tag{17}$$

式中，TP 为正确预测的正例，FP 为错误预测的负例，FN 为错误预测的正例，P 为准确率，R 为召回率，mAP 为平均精确均值。

2.3　消融实验

为直观了解各个优化环节对检测效果的提升程度与作用大小，对优化后的网络结构进行消融实验。

YOLOv5 为原始网络结构，损失函数仍然为 CIoU；YOLOv5s 为使用 SIoU 作为损失函数；F-YOLOv5 为将主干网络替换为 FasteNet-L1 网络结构；F-YOLOv5-SP 为使用 SPPFCSPC 模块替换掉原始的 SPPF 结构后的模型；F-YOLOv5-SP-G 指最后在颈部网络引入三个 GAM 注意力机制后最终的网络结构。最终实验效果如表 1 所示。

表 1 消融实验结果

算法	P/%	R/%	mAP/%
YOLOv5	86.4	80.8	86.6
YOLOv5s	87.2	80.9	87.1
F-YOLOv5s	85.5	81.6	87.6
F-YOLOv5s-G	88.5	82.9	89.1
F-YOLOv5s-SP	90.4	84.5	90.4
F-YOLOv5-SPGS	91.0	84.5	90.7

通过消融实验结果可以看出，在使用更轻量化的网络结构 FasterNet 对主干网络进行替换后，检测网络的检测精度下降了近 2%，但平均检测精度相差不大；在引入注意力机制和使用 SPPFCSPC 模块后检测网络的平均精度均得到了较大提升，最终模型的平均检测精度相较原网络提升了 4.1%。

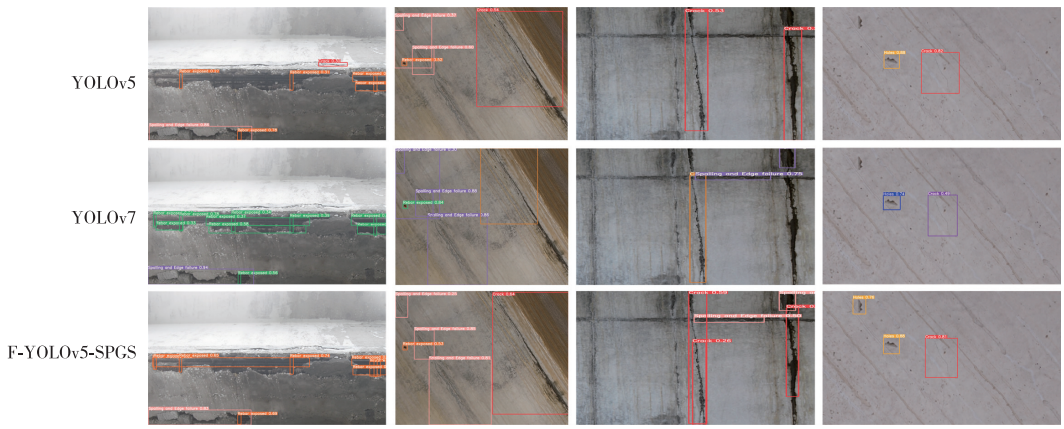
2.4 对比实验

在相同实验环境、参数设置和数据集下，对其他检测算法进行对比，结果如表 2 所示。通过与当前其他主流的检测算法横向对比，可以看出针对选取的几个重要的桥梁表观病害检测，本文提出的优化后的检测网络普遍优于其他检测网络。

通过与其他检测算法进行对比，在相同的环境和超参数设置下，本算法具有更为优秀的检测精度与速度。各算法实际效果对比如图 9 所示。当检测环境较为复杂、待检病害与背景相似度较高以及病害特征不突出时，如图 9(a)和图 9(b)所示，YOLOv5 和 YOLOv7 均出现了不同程度的漏检，在图 9(a)中 YOLOv5 和 YOLOv7 均出现了针对环境的错误识别；当面对多尺度病害待检时如图 9(c)和图 9(d)所示，YOLOv5 和 YOLOv7 均出现了不同程度的漏检，特别是面对如图 9(d)中的小尺寸病害检测时 YOLOv5 漏检更为严重。由此可以看出，在复杂背景、小尺寸病害的目标检测上，所提出的网络有着不错的检测效果。

表 2 对比试验

算法	P/%	R/%	mAP/%	FPS
YOLOv7	86.7	80.7	88.0	49
YOLOv7-tiny	74.1	67.6	73.9	52
Faster-RCNN	78.3	84.2	78.3	25
F-YOLOv5-SPGS	91.0	84.5	90.7	65



(a) 复杂环境(露筋) (b) 复杂环境(裂缝) (c) 多尺度病害(剥落、裂缝) (d) 多尺度病害(孔洞)

图 9 各算法检测效果对比

3 结论

本文提出了一种改进算法 F-YOLO-SPGS，在经过数据增强后的桥梁表观病害数据集上，进行分类型识别检测并取得较为优异的检测效果。检测结果表明，改进后模型的平均检测精度相较于原结构提高了 4.1%；同 YOLOv7 相比，平均检测精度提高了 2.3%，检测速度提高了约 30%；在面对复杂背景、小尺寸病害条件下均有不错的检测效果。

在接下来的工作中，使用 SPPFCSPC 可以有效地提高对小目标以及多尺度病害的检测精度，但会大幅增加模型的参数量。SPPFCSPC 结构对检测精度起着重要正向推动作用，但如何在增加检测精度的同时合理地降低参数量，是后续优化的方向。另外，在对主干网络进行修改后，尽管引入了基于 GAM 全局的注意力机制以弥补检测精度的损失，但网络的检测速率仍有很大的提升空间，值得在后续研究中深入探索。

参考文献：

[1] 彭卫兵，沈佳栋，唐 翔，等. 近期典型桥梁事故回顾、分析与启示[J]. 中国公路学报，2019，32(12)：132-144.
Peng Weibing，Shen Jiadong，Tang Xiang，et al. Review，analysis，and insights on recent typical bridge accidents[J]. China Journal of Highway and Transport，2019，32(12)：132-

144.

[2] 徐　强，宋建永，赵　安. 公路桥梁病害智能诊断分析方法及模块开发[J]. 公路交通科技，2022，39(S1)：53-58.
Xu Qiang，Song Jianyong，Zhao An. Intelligent diagnosis analysis method and system development of highway bridge disease[J]. Journal of Highway and Transportation Research and Development，2022，39(S1)：53-58.

[3] 张劲泉，晋　杰，汪云峰，等. 公路桥梁智能检测技术与装备研究进展[J]. 公路交通科技，2023，40(1)：1-27，58.
Zhang Jinquan，Jin Jie，Wang Yunfeng，et al. Study progress of intelligent inspection technology and equipment for highway bridge[J]. Journal of Highway and Transportation Research and Development，2023，40(1)：1-27，58.

[4] 皮春辉. 基于深度学习的混凝土桥梁表观病害检测方法研究[D]. 郑州：华北水利水电大学，2023.
Pi Chunhui. Research on apparent disease detection method of concrete bridge based on deep learning[D]. Zhengzhou：North China University of Water Resources and Hydropower，2023.

[5] 刘宇飞，冯楚乔，陈伟乐，等. 基于机器视觉法的桥梁表观病害检测研究综述[J]. 中国公路学报，2024，37(2)：1-15.
Liu Yufei，Feng Chuqiao，Chen Weile，et al. Review of bridge apparent defect inspection based on machine vision[J]. China Journal of Highway and Transport，2024，37(2)：1-15.

[6] 张振海，贾争满，季　坤. 基于改进的 Otsu 法的地铁隧道裂缝识别方法研究[J]. 重庆交通大学学报(自然科学版)，2022，41(1)：84-90.
Zhang Zhenhai，Jia Zhengman，Ji Kun. Crack identification method of subway tunnel based on improved Otsu method[J]. Journal of Chongqing Jiaotong University：Natural Science，2022，41(1)：84-90.

[7] 高少强，刘利生，杨新伟. 数字图像相关法在桥梁伸缩缝监测预警中的应用[J]. 中国安全科学学报，2018，28(S2)：171-175.
Gao Shaoqiang，Liu Lisheng，Yang Xinwei. Application of digital image correlation method on monitoring and warning of bridge expansion joint[J]. China Safety Science Journal，2018，28(S2)：171-175.

[8] Zhang C，Chang C，Jamshidi M. Concrete bridge surface damage detection using a single-stage detector[J]. Computer-Aided Civil and Infrastructure Engineering，2020，35(4)：389-409.

[9] Cha Y J，Choi W，Suh G，et al. Autonomous structural visual inspection using region-based deep learning for detecting multiple damage types[J]. Computer-Aided Civil and Infrastructure Engineering，2018，33(9)：731-747.

[10] 周清松，董绍江，罗家元，等. 改进 YOLOv3 的桥梁表观病害检测识别[J]. 重庆大学学报，2022，45(6)：121-130.
Zhou Qingsong，Dong Shaojiang，Luo Jiayuan，et al. Bridge apparent disease detection based on improved YOLOv3[J]. Journal of Chongqing University，2022，45(6)：121-130.

[11] Yu Z，Shen Y，Shen C. A real-time detection approach for bridge cracks based on YOLOv4-FPM[J]. Automation in Construction，2021，122：103514.

[12] 廖延娜，姚　亮. 改进 YOLOX 的桥梁病害检测识别[J]. 应用光学，2023，44(4)：792-800.
Liao Yanna，Yao Liang. Bridge disease detection and recognition based on improved YOLOX algorithm[J]. Journal of Applied Optics，2023，44(4)：792-800.

[13] Liu Y，Shao Z，Hoffmann N. Global attention mechanism：Retain information to enhance channel-spatial interactions[J]. arXiv preprint arXiv：2112.05561，2021.

[14] Gevorgyan Z. SIoU loss：More powerful learning for bounding box regression[J]. arXiv preprint arXiv：2205.12740，2022.

[15] Zhang X，Zhou X，Lin M，et al. Shufflenet：An extremely efficient convolutional neural network for mobile devices[C]// Proc. of the IEEE Conference on Computer Vision and Pattern Recognition，2018：6848-6856.

[16] Han K，Wang Y，Tian Q，et al. Ghostnet：More features from cheap operations[C]// Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition，2020：1580-1589.

[17] Howard A G，Zhu M，Chen B，et al. Mobilenets：Efficient convolutional neural networks for mobile vision applications[J]. arXiv preprint arXiv：1704.04861，2017.

[18] Chen J，Kao S，He H，et al. Run，Don't Walk：Chasing higher FLOPS for faster neural networks[C]// Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition，2023：12021-12031.

[19] He K，Zhang X，Ren S，et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence，2015，37(9)：1904-1916.

[20] Wang C Y，Bochkovskiy A，Liao H Y M. YOLOv7：Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]// Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition，2023：7464-7475.

[21] Woo S，Park J，Lee J Y，et al. Cbam：Convolutional block attention module[C]// Proc. of the European Conference on Computer Vision (ECCV)，2018：3-19.

[22] Selvaraju R R，Cogswell M，Das A，et al. Grad-cam：Visual explanations from deep networks via gradient-based localization[C]// Proc. of the IEEE International Conference on Computer Vision，2017：618-626.

作者简介：

侯周阳(1999—)，男，四川省成都市人，硕士研究生，主要从事目标检测研究；

杨莉琼(1980—)，女，甘肃省张掖市人，博士，副教授，主要从事建筑管理信息化与智能建造研究。