

基于 YOLOv8 改进的下水管道障碍物识别算法

吴裕发, 郑少峰

(福建理工大学 交通运输学院, 福建 福州 350118)

摘要: 为提升下水管道障碍物清理效率和管道障碍物识别准确率, 提出一种基于 YOLOv8 改进的管道障碍物识别算法。通过优化 YOLOv8 目标检测模型, 使其更适用于环境复杂的管道内部障碍物检测任务。在 YOLOv8 网络结构的基础上引入 PGI 模块, 增加辅助可逆支路和多级辅助模块缓解信息瓶颈问题, 减少精度损失; 引入 SCConv 模块来替换 C2f 模块, 在实现模型轻量化的情况下保持检测精度; 引入 Focal-Modulation 模块改进了传统的 SPPF 模块, 使模型的精度得到一定程度的提升。实验结果表明, 改进后的识别算法与 YOLOv8n 模型相比, 在 mAP@0.5 精度上提升 4.6%, 在 mAP@0.5~0.95 精度上提升 3.9%, 参数量降低 33.3%, 计算量减少 17.3%, 更加适用于下水管道障碍物的识别检测。

关键词: 目标检测; 下水管道; 障碍物识别; PGI; SCConv; Focal-Modulation

中图分类号: TP391.4

文献标志码: A

文章编号: 2097-3853(2024)06-0590-08

Identification algorithm of sewer obstruction based on YOLOv8

WU Yufa, ZHENG Shaofeng

(School of Transportation, Fujian University of Technology, Fuzhou 350118, China)

Abstract: In order to improve the cleaning efficiency of sewer pipe obstacles and the accuracy of pipeline obstacle recognition, an improved pipeline obstacle recognition algorithm based on YOLOv8 is proposed. By optimizing the YOLOv8 target detection model, the algorithm is made more suitable for obstacle detection in the complex environment inside the pipeline. Based on the network structure of YOLOv8, the PGI module proposed is introduced. The addition of auxiliary reversible branches and multistage auxiliary module in the module effectively alleviates the information bottleneck problem, as a result significantly reducing the loss of accuracy. The SCConv module is introduced to replace the C2f module to maintain the detection accuracy while realizing the lightweight of the model. The introduction of Focal-Modulation module improves the traditional SPPF module, so that the accuracy of the model is improved to a certain extent. Experimental results show that compared with YOLOv8n model, the improved recognition algorithm improves the accuracy of mAP@0.5 by 4.6%, improves the accuracy of mAP@0.5~0.95 by 3.9%, reduces the number of parameters by 33.3%, and reduces the amount of calculation by 17.3%. It is more suitable for the identification and detection of obstacles in sewer pipes.

Keywords: target detection; sewer pipe; obstacle detection; PGI; SCConv; Focal-Modulation

下水道障碍物检测技术对保障排水系统安全具有重要意义。传统的下水管道障碍物检测方法主要依赖人工和简单的机械设备巡检, 效率低且难以发现隐蔽障碍物。近年来, 深度学习技术逐渐被引入机器视觉检测, 用于识别、定位和评估多

种管道损伤和缺陷^[1-2]。基于深度学习技术, Wei 等^[3]引入卷积神经网络, 通过顺序预测框架加强中间阶段的监督, 有效解决训练过程中梯度消失问题。Zhang 等^[4]提出了一种基于 YOLOv8 的图像自动矫正算法, 有效矫正仪器图像的畸变。Cao

收稿日期: 2024-04-09

基金项目: 福建省科技厅引导性项目(2021H0025)

第一作者简介: 吴裕发(2000—), 男, 福建福州人, 硕士研究生, 研究方向: 人工智能。

等^[5]在 YOLOv8 的基础上采用改进的自动驾驶小目标检测算法,提高对密集小目标的识别灵敏度。Sampath 等^[6]结合一种集成技术更准确地识别和定位天然气管道中的缺陷。

然而,在复杂的下水道环境中,现有研究在障碍物识别检测上仍然存在检测速度慢、识别精度不够高等问题。综上,本研究通过改进现有的 YOLOv8 算法提升其对下水管道障碍物检测的精度,以更好适应下水管道障碍物检测的需求。

1 改进 YOLOv8 算法

本研究对 YOLOv8 中的 n 模型进行改进和对

比,后续统称 YOLOv8n 模型。YOLOv8 算法引入了全新的主干网络、特征融合网络以及新的检测层结构^[7]。本研究在 YOLOv8 的基础上,引入了一种新的辅助监督框架——可编程梯度信息 (programmable gradient information, PGI)^[8],在不增加参数量和计算量的情况下提高检测精度;用 SCConv^[9] 模块替换骨干网络中的 C2f 模块,对模型进行轻量化改进;用 Focal-Modulation^[10] 模块来替换主干网络中的 SPPF 层,进一步提高模型的检测性能。改进后的 YOLOv8 的网络结构如图 1 所示。

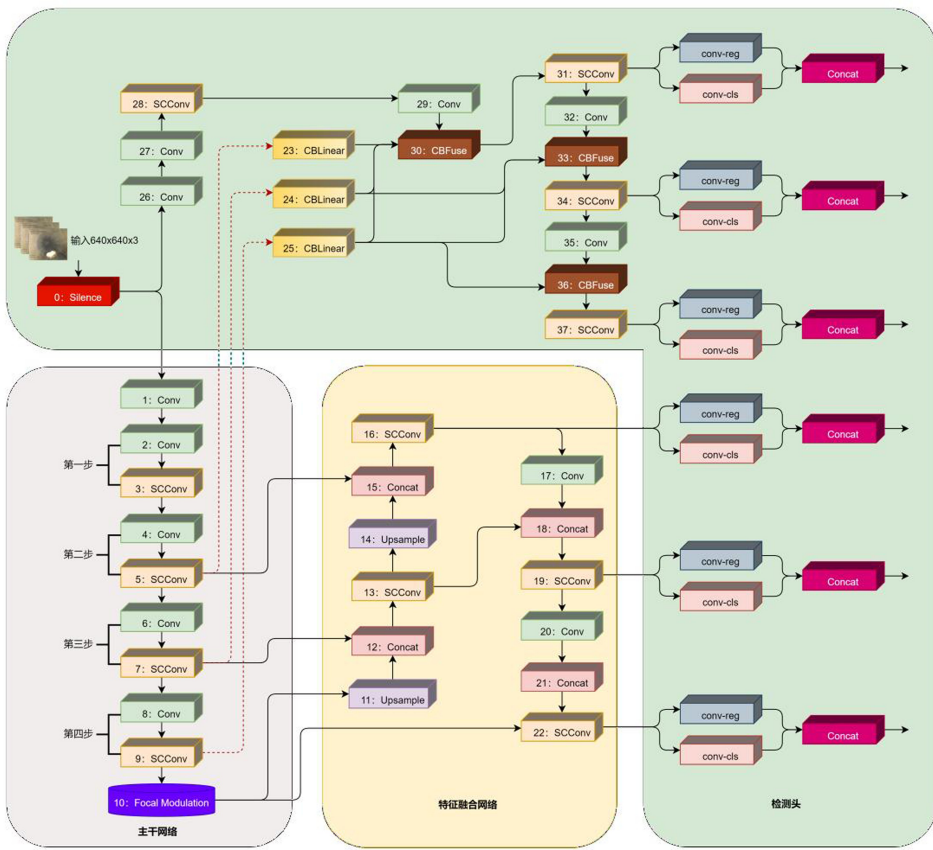


图 1 改进 YOLOv8 网络结构图

Fig.1 Improved YOLOv8 network structure diagram

1.1 PGI 模块

深度学习网络中,输入数据 X 在变换时可能会丢失信息,这种输入数据在前馈过程中丢失信息现象一般称为信息瓶颈,如式(1)所示。

$$I(X, X) \geq I[X, f_{\theta}(X)] \geq I[X, g_{\varphi}(\cdot)](f_{\theta}(X)) \quad (1)$$

式中, I 为互信息, f 和 g 为变换函数, θ 和 φ 分别

为 f 和 g 的参数。

PGI 模块由主分支、辅助可逆分支和多级辅助信息模块 3 个模块组成,如图 2 所示。对于 YOLOv8 算法来说,引入 PGI 模块作为辅助监督框架能够在不增加推理成本的情况下提升模型的检测精度,进而解决在一定条件下训练结果的不稳定、不可靠以及收敛性差的问题。

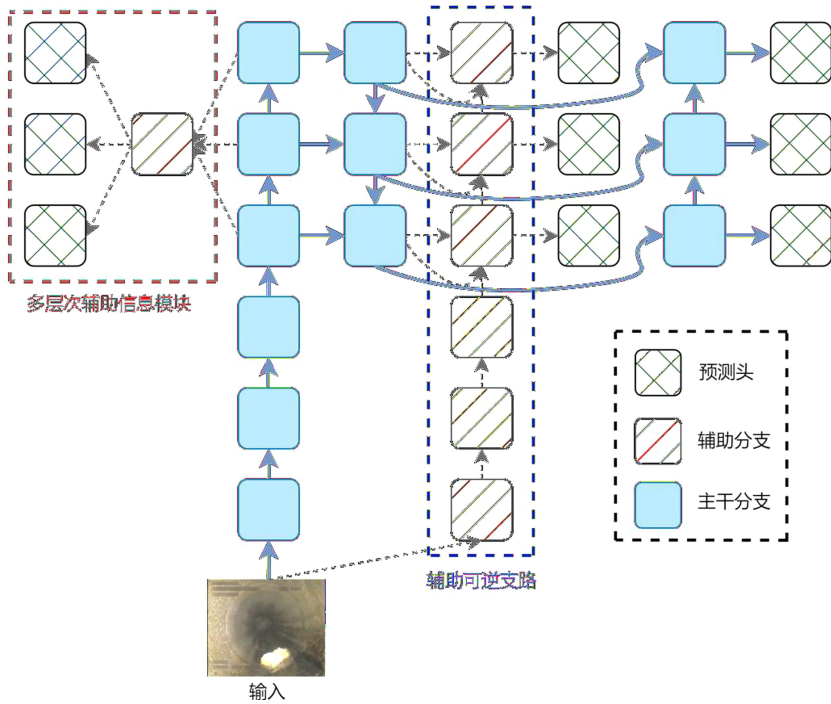


图 2 PGI 模块

Fig.2 Programmable gradient information module

1.1.1 辅助可逆支路

PGI 模块使用了辅助可逆支路来生成可靠的梯度信息,并据此更新网络参数,从而避免因不完整的前馈特征误判与目标不相关的虚假关联。该模块的核心目标是利用可逆架构生成可靠的梯度信息,但引入可逆体系结构又会增加大量的推理成本。而鉴于“可逆”在推理阶段并非必要的条件,PGI 模块将可逆分支作为深度监督分支的拓展,设计出辅助可逆支路,如图 2 所示。

PGI 模块不强制主分支保留完整的原始信息,而是通过辅助监督机制生成有用的梯度信息来更新原始信息。因信息瓶颈而丢失重要信息的主分支深度特征,将从辅助可逆分支接收到可靠的梯度信息,驱动参数学习,帮助提取正确的信息,使主分支获得对目标任务更有效的特征。

1.1.2 多级辅助信息模块

多层辅助信息模块通过集成多个预测分支,使得网络能够更高效地应对复杂的任务。在目标检测任务中,不同的特征金字塔层次能够承担差异化的职责,例如同步检测不同尺寸的对象。通过引入深度监督分支,浅层特征专注于捕捉小目标检测所需的特性,其他尺寸目标的位置被视为

背景信息。然而,该做法可能导致深层特征金字塔在预测目标物体时损失关键信息,进而降低整体性能。因此,PGI 模块提出了多级辅助信息的概念,在辅助监督的特征金字塔层次与主分支之间插入一个集成网络,旨在融合来自不同预测分支的梯度信息,如图 2 所示。

多级辅助信息模块通过聚合包含所有目标对象的梯度信息并将其传递给主分支,确保主分支的空间特征金字塔层次结构不会受到特定对象信息的过度影响,从而有效缓解深度神经网络中信息破碎现象。此外,多级辅助信息的引入能够根据实际需求灵活选择集成网络的能力,以指导不同规模网络架构的学习过程,更好地适应各种复杂场景。

1.2 SCConv 模块

深度学习网络在模型参数、特征图的空间维度以及通道维度上普遍存在较大的冗余性。本研究引入 SCConv 模块对 YOLOv8 中的 C2f 模块进行轻量化改进。SCConv 模块旨在利用特征图之间的空间和通道冗余来实现卷积神经网络的压缩,以减少冗余计算并促进代表性特征的学习。SCConv 模块主要由空间重构单元(SRU)和信道重构单元(CRU)组成,SRU 采用分离重

构的方法来抑制空间冗余,CRU 采用分离变换融合的策略来减少信道冗余,其结构如图 3 所示。

1.2.1 SRU 结构

SRU 使用分离和重构操作来利用特征的空间冗余,其结构如图 4 所示。




图 3 SCConv 体系结构
Fig.3 SCConv architecture

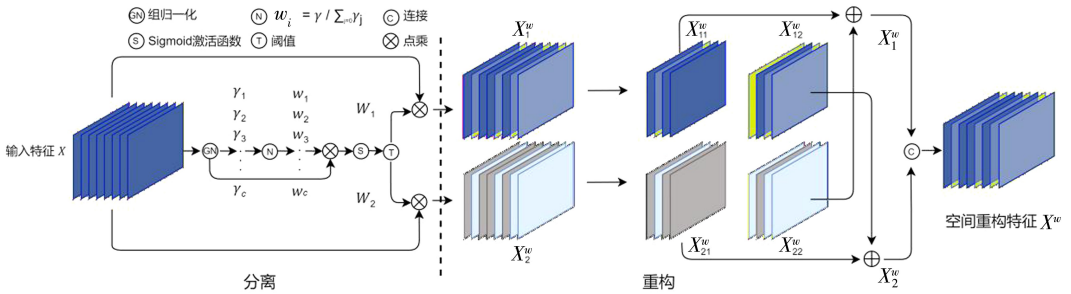


图 4 空间重构单元
Fig.4 Spatial reconstruction unit

分离操作是给定一个中间特征映射 $X \in R^{N \times C \times H \times W}$, 其中 N 为批轴, C 为通道轴, H 和 W 为空间高度和宽度轴, GN 层代表着组归一化层, μ 和 σ 为 X 的平均值和标准差, ε 是一个极小的正常数, γ 和 β 是可训练参数。首先通过减去平均值 μ 并除以标准差 σ 对输入特征 X 进行标准化, 如式(2)所示。

$$X_{out} = GN(X) = \gamma \frac{X - \mu}{\sqrt{\sigma^2 + \varepsilon}} + \beta \quad (2)$$

式中, 可训练参数 $\gamma \in R^C$ 作为测量每个批次和通道的空间像素方差的方法。归一化相关权 $W_\gamma \in R^C$ 由式(3)得到, 表示不同特征映射的重要性。

$$W_\gamma = \{w_i\} = \frac{\gamma_i}{\sum_{j=1}^C \gamma_j}, \quad i, j = 1, 2, \dots, C \quad (3)$$

将 W_γ 的特征映射重新加权后得到权值, 再通过 Sigmoid 函数把该权值映射到 $(0, 1)$ 范围, 并通过阈值进行门控。模块中将阈值以上的权重设置为 1, 得到信息权重 W_1 , 将阈值以下的权重设置为 0, 得到非信息权重 W_2 。获取 W 的整个过程如式(4)所示。

$$W = \text{Gate}(\text{Sigmoid}(W_\gamma(\text{GN}(X)))) \quad (4)$$

将输入特征 X 分别乘以 W_1 和 W_2 得到信息

量大的 X_1^w 和信息量小的 X_2^w 。 X_1^w 具有信息性和表现力的空间内容, 而 X_2^w 具有很少或没有信息, 被认为是冗余的。为了减少空间冗余, 进一步提出了一种重构操作, 将信息丰富的特征与信息较少的特征相加, 生成信息更丰富的特征, 从而节省空间。SRU 结构采用交叉重构运算, 将加权后的两个不同的信息特征充分结合起来, 加强它们之间的信息流。然后将交叉重构的特征 X_1^w 和 X_2^w 进行拼接, 得到空间精细特征映射 X^w , 整个过程表示为式(5), 其中, \otimes 表示逐元素相乘, \oplus 表示逐元素相加, \cup 表示 Concat 连接模块。

$$\begin{cases} X_1^w = W_1 \otimes X, \\ X_2^w = W_2 \otimes X, \\ X_{11}^w \oplus X_{22}^w = X^{w1}, \\ X_{21}^w \oplus X_{12}^w = X^{w2}, \\ X^{w1} \cup X^{w2} = X^w. \end{cases} \quad (5)$$

1.2.2 CRU 结构

经过 SRU 重构后模型仍存在一定的信道冗余, 为此在 SCConv 模块中引入了信道重构单元 (CRU), 通过分割-转换-融合策略来充分利用信道冗余。通常使用重复的标准 $k \times k$ 卷积来提取特征, 导致沿着通道维度产生一些相对冗余的特征

映射。设 $M^k \in R^{c \times k \times k}$ 表示一个 $k \times k$ 卷积核, $X, Y \in R^{c \times h \times w}$ 分别表示输入特征和卷积输出特征。标准

卷积可以定义为 $Y = M^k X$ 。具体 CRU 结构如图 5 所示。




图 5 信道重构单元

Fig.5 Channel reconstruction unit

在分割阶段对于给定的空间细化特征 $X^w \in R^{c \times h \times w}$, 首先将 X^w 的通道分成两部分, 一部分具有 αC 个通道, 另一部分具有 $(1-w)C$ 个通道, 本研究取 α 为 0.5。随后利用 1×1 卷积来压缩特征图的通道以提高计算效率, 引入压缩比例 r 来控制 CRU 的特征通道以平衡计算成本。在分割和压缩操作之后, 空间细化特征 X^w 则分为上部分 X_{up} 和下部分 X_{low} 。

在转换阶段, X^w 被输入到上转换阶段, 作为“特征提取器”。采用高效、低计算成本的逐分组卷积 (GWC) 和逐点卷积 (PWC) 来提取特征。本研究设置 GWC 中分组大小为 16, 上转换阶段可以表示为式 (6)。

$$Y_1 = M^G X_{up} + M^{P1} X_{up} \quad (6)$$

式中, M^G 、 M^{P1} 分别是 GWC 和 PWC 的可学习权重。上输入和输出的特征图分别为 X_{up} 和 Y_1 。 X_{low} 被输入到底部转换阶段, 表示为式 (7)。

$$Y_2 = M^{P2} X_{low} \cup X_{low} \quad (7)$$

式中, M^{P2} 是 PWC 的可学习权重, \cup 表示 Concat 模块 X_{low} 和 Y_2 分别是底部输入和输出的特征图。在融合阶段, 利用 SKNet 法自适应地合并上转换阶段和下转换阶段的输出特征 Y_1 和 Y_2 。通过全局平均池化来收集全局空间信息, 全局通道描述子 S_m 计算如式 (8)。

$$S_m = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W Y_c(i, j), \quad m = 1, 2 \quad (8)$$

随后, 将上、下部分的全局通道描述子 S_1 、 S_2 堆在一起, 使用通道注意力操作生成重要性向量 β_1 和 β_2 , 如式 (9) 所示。

$$\beta_1 = \frac{e^{s_1}}{e^{s_1} + e^{s_2}}, \quad \beta_2 = \frac{e^{s_2}}{e^{s_1} + e^{s_2}} \quad (9)$$

最终, 信道重构特征可以表示为 $\beta_1 Y_1 + \beta_2 Y_2$ 。

在 SCConv 模块中, 所有参数都集中在转换阶段, 相比传统的卷积操作可以大幅减少参数量。

1.3 Focal-Modulation 模块

由于 YOLOv8 中的 SPPF 模块涉及多个层级的特征融合, 可能会增加计算量进而影响到模型的实时性能。本研究将 YOLOv8 中的 SPPF 模块替换成 Focal-Modulation 模块, 具体结构如图 6 所示。

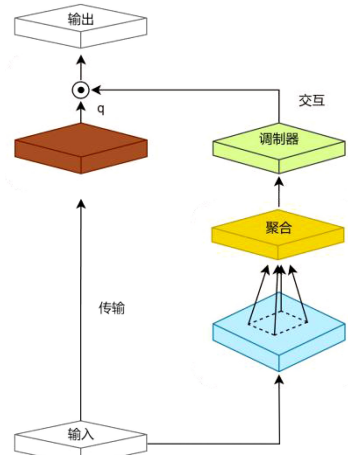


图 6 聚焦调制模块

Fig.6 Focal-modulation module

其中, 在通过交互 $T_1 T$ 计算查询和目标之间的注意力得分之后, 执行上下文 X 的聚合 M_1 。在焦点汇聚上下文步骤时, 给定一个视觉特征映射 $X \in R^{H \times W \times C}$ 作为输入, 为每个视觉标记 $x_i \in R^C$ 生成一个通用的特征表示 $y_i \in R^C$ 。由于交互过程中的输入特征映射是简单的线性投影, 并且单个键不包含上下文的信息, 导致使用自注意来计算注意力分数的计算成本较高, 如式 (10) 所示。

$$y_i = M_1(T_1(x_i, X), X) \quad (10)$$

而焦点调制则是使用 M_2 在每个位置 i 处聚

合上下文特征,查询基于 T_2 与聚合的特征交互以形成 y_i ,具体如式(11)所示。

$$y_i = T_2(M_2(i, X), x_i) \quad (11)$$

虽然在本质上自注意力和焦点调制都涉及相互作用和聚合操作,但因操作顺序不同,提升了焦点调制的精细度和计算效率。

2 实验结果与分析

2.1 实验环境与参数

使用的操作系统为 Windows11(专业版),CPU 为英特尔 i3-12100F,内存为 16 GB,显卡为 Nvidia Geforce RTX 4060,显存为 8 GB。平台为 PyCharm,开发语言为 Python3.10,深度学习框架选用 Pytorch-GPU 2.1.1,使用的 CUDA 版本为 11.8,并使用版本为 v8.9.2.26 的 cuDNN 进行 GPU 加速。实验中图像输入尺寸(imges Size)为 640×640,迭代时模型处理的样本数(Batch)设置为 16,训练次数(Epochs)设为 300 次,使用 SGD 优化器优化参数,其他参数则使用为 YOLOv8 官方默认参数。

2.2 实验数据与评价指标

2.2.1 实验数据

数据集来源于国外的开源数据集 Sewer-ML^[11],其中包含 130 万张下水管道缺陷的图像以及来自 3 个丹麦自来水公司 9 a 来收集的 75 618 个视频,从中选取了 600 张管道障碍物图片,其中数据集以 7 : 2 : 1 的比例分为训练集 420 张、测试集 120 张、验证集 60 张。每张图片的样本标签都经过 Labeling 标注软件的人工精细标注,确保准确性。随后,将这些原本为 xml 格式的标签数据转换成更为简洁的 txt 格式,以便于后续的处理和分析工作,以确保数据的通用性和易用性,为后续的模型训练和评估提供了便利。

2.2.2 评价指标

为了实现管道障碍物检测任务,采用了 5 个核心评价指标:平均精度(mAP)、准确率(P)、召回率(R)、参数量(Params)、计算量(GFLOPs)。在管道障碍物检测任务中,mAP 值越高,说明模型在检测障碍物误检和漏检的情况越少,具体如式(12)(13)所示。准确率 P 越大,意味着模型越能够准确地将障碍物从背景或其他非障碍物中区分出来,误报的可能性越小, P 的计算如式(14)所示。高召回率 R 意味着模型能够识别大多数

实际存在的障碍物,减少漏检的可能性,从而确保管道障碍物检测的全面性和准确性, R 的计算如式(15)所示。

$$mAP = \frac{1}{C} \sum_{i=1}^C AP_i \quad (12)$$

$$AP = \int_0^1 P(R) dR \quad (13)$$

$$P = \frac{TP}{TP+FP} \quad (14)$$

$$R = \frac{TP}{TP+FN} \quad (15)$$

式中,TP 表示真正例,FN 表示假反例,FP 表示假正例, C 表示所需识别的种类, mAP 为平均精度, AP 为单种类精度, P 表示准确率, R 表示召回率。

2.3 实验结果分析

2.3.1 对比实验

将改进后的 YOLOv8n 算法与现阶段主流的目标检测算法 YOLO 系列、SSD^[12]、RT-DETR 进行了性能上的对比,结果如表 1 所示。可见,改进算法的 mAP@0.5 对比 SSD 算法提升 7.7%,对比 RT-DETR 检测算法提升 7.0%。同时,改进后的 YOLOv8 模型的精度不仅高于基准模型,参数量降低 33.3%,模型计算量减少 17.3%,兼顾了精度和轻量化之间的平衡,符合下水管道障碍物识别检测所需求轻量化、高精度的特点。

表 1 各种主流检测算法对比结果

Tab.1 Comparison results of various mainstream detection algorithms

模型	mAP@	mAP@ 0.5~	Recall/	Params/	FLOPs/
	0.5/%	0.95/%	%	M	G
YOLOv8n (baseline)	81.7	54.2	86.0	3.0	8.1
YOLOv7tiny	81.2	52.7	85.4	5.9	13.2
YOLOv5n	80.8	51.4	84.1	2.5	7.1
SSD	78.6	51.2	82.3	26.3	87.7
RT-DETR	79.3	51.6	83.1	32.0	110.2
改进后 YOLOv8n	86.3	58.1	92.0	2.0	6.7

2.3.2 消融实验

输入图像尺寸为 640×640 的条件下进行消融实验,在 YOLOv8n 模型的基础上添加 PGI 模

块、替换 C2f 模块以及改进 SPPF 模块,并对 4 种实验样本进行编号。编号 0 为没有改进的 YOLOv8n 模型;编号 1 为引入了 PGI 模块的改进样本;编号 2 为引入 PGI 模块并且用 SCConv 模块替换 C2f 模块的样本;编号 3 为所提出的 3 种方式同时改进的模型样本。结果表明,添加 PGI 模块后 mAP 提升 3.9%;同时添加 PGI 模块

并且替换 C2f 模块后, mAP 提升 4.0%; 3 种方式同时改进时 mAP@ 0.5 相较于原模型提升 4.6%, mAP@ 0.5 ~ 0.95 提升 3.9%, 参数量降低 33.3%, 计算量减少 17.3%。综上所述, YOLOv8 改进的识别算法确实有效。具体实验结果如表 2 所示, 其中“√”代表应用该改进模块, “×”代表没有应用该改进模块。

表 2 消融实验对比结果

Tab.2 Comparison results of ablation experiment

编号	PGI	SCConv	Focal-Modulation	mAP@ 0.5/%	mAP@ 0.5~0.95/%	Recall/%	Params/M	FLOPs/G
0	×	×	×	81.7	54.2	86.0	3.0	8.1
1	√	×	×	85.6	57.6	87.0	4.3	10.1
2	√	√	×	85.7	56.5	91.0	2.6	7.1
3	√	√	√	86.3	58.1	92.0	2.0	6.7

2.4 检测效果分析

为了进一步验证改进算法对下水管道障碍物识别检测的有效性,在公开数据集 Sewer-ML 的 3 种场景中对比对 YOLOv8 原始算法和改进算法的检测效果,结果如图 7 所示。相对于用

原 YOLOv8 算法训练出的模型存在漏检、重复检测以及置信度偏低等问题,改进后的 YOLOv8 算法在公开数据集 Sewer-ML 上的表现优异,有效减少漏检率,提高了识别检测过程中的置信度。




图 7 下水管道检测对比图

Fig.7 Sewer pipe inspection comparison diagram

3 结束语

本研究主要针对传统下水管道障碍物检测精度不足难以满足实际应用的需求问题,提出一种基于 YOLOv8 模型改进的下水管道障碍物识别检

测算法。在 YOLOv8 基准模型的基础上引入新的 YOLOv9 的 PGI 模块,在不显著增加参数量和计算量的条件下提高检测精度;将 C2f 模块替换为 SCConv 模块,在不损失检测精度的同时对模型进行轻量化处理;最后利用 Focal-Modulation 改进

SPPF 模块,充分融合上下文语义,增强了特征融合准确度。

实验结果表明,改进后的YOLOv8算法在mAP@0.5指标上达到86.3%,相较于原算法提升4.6%,在mAP@0.5~0.95指标上也提升了3.9%,同时参

数量下降了33.3%,计算量也降低了17.3%,在公开数据集上的测试结果也证明改进后的算法减少了漏检以及重复检测等问题,其检测精度能够满足下水管道识别检测的需求,也更适合在计算资源受限的下水管道检测设备上部署。

参考文献:

- [1] LI B Z,JIANG W Z,GU J J. Research on target detection algorithm based on deep learning technology[C]// IEEE International Conference on Power Electronics,Computer Applications. Shenyang: IEEE,2021:137-142.
- [2] 郑远攀,李广阳,李晔. 深度学习在图像识别中的应用研究综述[J]. 计算机工程与应用,2019,55(12):20-36..
- [3] WEI S, RAMAKRISHNA V, KANADE T, et al. Convolutional pose machines[C]// IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV: IEEE,2016:4724-4732.
- [4] ZHANG C L, SHI L, BU N, et al. Automatic correction method of industrial instrument images based on YOLOv8 keypoint detection and perspective transformation[M]// Lecture Notes in Computer Science. Singapore: Springer, 2024:3-11.
- [5] CAO J, ZHANG T, HOU L, et al. An improved YOLOv8 algorithm for small object detection in autonomous driving[J]. Journal of Real-Time Image Processing, 2024,21(4):1-16.
- [6] SAMPATH S, CHAURASIYA K L, ARYAN P, et al. An innovative approach towards defect detection and localization in gas pipelines using integrated in-line inspection methods[J]. Journal of Natural Gas Science and Engineering, 2021, 90:103933.
- [7] 邵延华,张铎,楚红雨,等. 基于深度学习的YOLO目标检测综述[J]. 电子与信息学报,2022,44(10):3697-3708.
- [8] WANG C Y, YE H I, LIAO H Y M. YOLOv9: learning what you want to learn using programmable gradient information [EB/OL]. 2024:2402.13616. <https://arxiv.org/abs/2402.13616v2>.
- [9] LI J F, WEN Y, HE L H. SCConv: spatial and channel reconstruction convolution for feature redundancy[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, BC: IEEE,2023:6153-6162.
- [10] YANG J W, LI C Y, DAI X Y, et al. Focal modulation networks[C]// Proceedings of the 36th International Conference on Neural Information Processing Systems. New Orleans: ACM, 2022: 4203-4217.
- [11] HAURUM J B, MOESLUND T B. Sewer-ML: a multi-label sewer defect classification dataset and benchmark[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, TN: IEEE,2021:13456-13467.
- [12] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot MultiBox detector[M]// Lecture Notes in Computer Science. Cham: Springer International Publishing,2016:21-37.

(责任编辑:方素华)