周苏华, 黄楚婷, 沙琳川, 等. YOLOv5 在基于探地雷达图像的路基病害智能识别中的应用[J]. 安全与环境学报, 2026, 26(7): 2539 - 2547.

Zhou Suhua, Huang Chuting, Sha Linchuan, et al. Application of YOLOv5 in intelligent recognition of subgrade diseases based on ground penetrating radar images[J]. Journal of Safety and Environment, 2026, 26(7): 2539 - 2547.

YOLOv5 在基于探地雷达图像的路基病害智能识别中的应用*

周苏华[1,2],黄楚婷[1],沙琳川[3],黄明华[1,2]

(1 湖南大学土木工程学院,长沙 410082;2 桥梁工程安全与韧性全国重点实验室,长沙 410082;
3 贵州省质安交通工程监控检测中心有限责任公司,贵阳 550014)

摘 要:针对探地雷达路基病害检测图像人工解译困难的问题,提出一种基于 YOLOv5 的路基裂缝、疏松病害雷达图像识别方法,并使用 1 290 张 VOC 格式标记的雷达图像数据集进行训练和验证。使用卷积注意力模块(Convolutional Block Attention Module,CBAM)、上下文引导模块(Context Guided Block,CG Block)和动态检测头模块(Dynamic Head)对 YOLOv5 模型进行改进,并进行消融试验以探究每个模块的功能。结果显示,在快速空间金字塔池化层(Spatial Pyramid Pooling Fast,SPPF)前添加 CBAM 模块可提高模型对关键特征的捕获能力,即在减少参数量的同时实现模型的轻量化。使用 Context Guided 模块替换 YOLOv5 模型的 neck 部分的 3 个 C3 模块,可提高局部上下文感知能力,减少模型的参数量和内存占用并提高检测精度。改进的 C1 - CG - YOLOv5 算法的 m_{AP50} 达到 90.8%,$m_{AP50-95}$ 达到 64.2%,参数量减少 12.8%,能够有效适用于路基裂缝、疏松病害的识别。

关键词:安全工程;路基病害识别;探地雷达;目标检测;YOLOv5

中图分类号:X45 **文献标志码**:A **文章编号**:1009-6094(2026)07-2539-09

DOI: 10.13637/j.issn.1009-6094.2025.1288

0 引 言

由于自重、行车荷载和各种自然因素的影响,路基内部易形成裂缝、疏松、脱空及富水带等隐性病害,严重影响其整体性和稳定性。探地雷达(Ground Penetrating Radar,GPR)由于高效、无损、高分辨率成像的优势,已成为国内外城市道路病害体检测的主流方法[1-3]。

1989 年,王惠濂等[4]首次系统介绍了国外脉冲时间域探地雷达的发展与应用,并在现场对多种岩土类型的地质问题进行了试验探测[5]。为了理解和识别雷达图像的病害特征,常通过正演模拟[6-7]或室内试验[8]获取不同病害的雷达响应特征,以指导实测数据人工解译。杜衍庆等[6]借助 gprMax 软件[9]模拟疏松病害特征。隋昕展等[7]采用时间域有限差分法(Finite-Difference Time-Domain,FDTD)模拟脱空病害雷达图像特征。然而,GPR 检测通常产生海量数据,人工解译效率低下、成本高昂,且高度依赖解译人员的专业经验,因此,实现对路基雷达图像病害的高效智能识别具有重要意义。

近年来,深度学习技术在计算机视觉领域,尤其在目标检测任务上,取得了革命性进展。支持向量机(Support Vector Machines,SVM)[10]、卷积神经网络(Convolutional Neural Networks,CNN)[11]、区域卷积神经网络(Region-based Convolutional Neural Networks,R - CNN)[12]以及 YOLO(You Only Look Once)[13-15]等算法在探地雷达图像识别方面已取得一定成果。在众多算法中,YOLO 系列算法以其卓越的实时性能及较高的检测精度受到学者的广泛关注。YOLO 系列算法由 Redmon 等[16]于 2016 年首次提出,即将目标检测问题转化为回归问题的思想赋予了其高效又强大的实时处理能力,并在工业中得到了广泛应用。周廷楠[12]发现 YOLOv3 对病害的识别准确率明显优于 YOLOv2。麻哲旭等[14]发现改进的 LS - YOLOv3 在铁路路基病害检测中取得了更高的平均检测精度,且满足实时检测要求。Wang 等[15]开发了 DA - YOLO 网络,并通过特征分布对齐技术提升了利用模拟数据训练的模型在真实 GPR

* **收稿日期**: 2025 - 07 - 23

作者简介: 周苏华,副教授,博士,从事岩土工程风险分析研究,zhousuhua@hnu.edu.cn;黄明华(通信作者),副教授,博士,从事边坡工程研究,huangminghua@hnu.edu.cn。

基金项目:长沙市自然科学基金项目(kq2402072);贵州省科技支撑计划项目(2020 - 4Y047);贵州省交通运输厅科技计划项目(2025 - 112 - 018,2023 - 312 - 030)

数据上的检测性能。尽管目前已经取得了进展,但现有的 GPR 病害检测方法在同时满足高精度、高推理速度和模型轻量化方面仍存在挑战,许多工作未能实现精度-速度-模型之间的平衡。针对上述问题,本文以实时性优异的 YOLOv5 为基础进行改进。核心思路是通过引入特定的模块化设计,在尽量保持或提升检测效率的同时,提高检测精度并实现模型清理量化。此外,引入卷积注意力模块(Convolutional Block Attention Module,CBAM),提高模型在通道和空间上对病害关键特征的关注能力;使用 Context Guided 模块替换部分标准卷积 Conv 模块,提高模型的全局上下文感知能力和多尺度信息融合能力,以改善复杂背景下病害的识别精度;利用 Dynamic Head 动态检测头的动态多维度特征学习能力进一步提升模型性能。通过系统的消融试验,深入分析各模块的功能,提出一种改进 YOLOv5 模型,实现路基 GPR 图像的疏松与裂缝病害检测任务的高精度、高效率与良好轻量化的有效平衡。

1 YOLOv5 算法

YOLOv5 算法于 2020 年提出,模块化设计的特点使其网络结构定义灵活,且采用了轻量级模型设计和高效的特征提取器,在保持较高检测精度的同时推理速度更快。YOLOv5 目标检测算法的网络结构主要由骨干网络(Backbone)、颈部结构(Neck)和检测头(Prediction)组成。骨干部分负责提取图像的特征,颈部结构通过上采样和下采样将不同层级的特征结合,生成多尺度特征图,检测头部分进行最终的目标检测。YOLOv5 配置了不同网络宽度、深度和预训练权重的模型结构,并分别得到参数量、计算量和性能各不相同的模型。YOLOv5 的网络结构见图 1。

在主干网络中,CBS 模块由卷积层(Convolution)、批归一化层(Batch Normalization,BN)和激活函数(SiLU)组成,C3 模块(CSP Bottleneck with 3 Convolutions)用于学习残差特征,快速空间金字塔池化(Spatial Pyramid Pooling Fast,SPPF)用于提取多尺度特征。YOLOv5 在颈部结构中采用的路径聚合特征金字塔结构(Path Aggregation Feature Pyramid Network,PAFPN)同时结合了特征金字塔结构(Feature Pyramid Network,FPN)和路径聚合网络(Path Aggregation Network,PANet)的优点,即通过自顶向下、自下向上和横向连接实现了更加高效的特征融合。自顶向下表现为高层次特征图经过上采样后再与上一层特征图进行融合,自下向上表现为将卷积后的特征图与上一层特征图进行融合,横向连接表现为 Concat 将同一层级的特征图进行相加,通道数不变。检测头部分由锚框(Anchors)、卷积层、预测层和非极大值抑制(Non-Maximum Suppression,NMS)组成,并采用多层级特征图融合的方法提高检测性能。YOLOv5 各个模块的设计都平衡了速度和精度,使得 YOLOv5 模型适合运用在各种实际场景中的目标检测任务。

2 方法与模型设计

2.1 CBAM 注意力机制

卷积注意力模块 CBAM 是一种用于计算机视

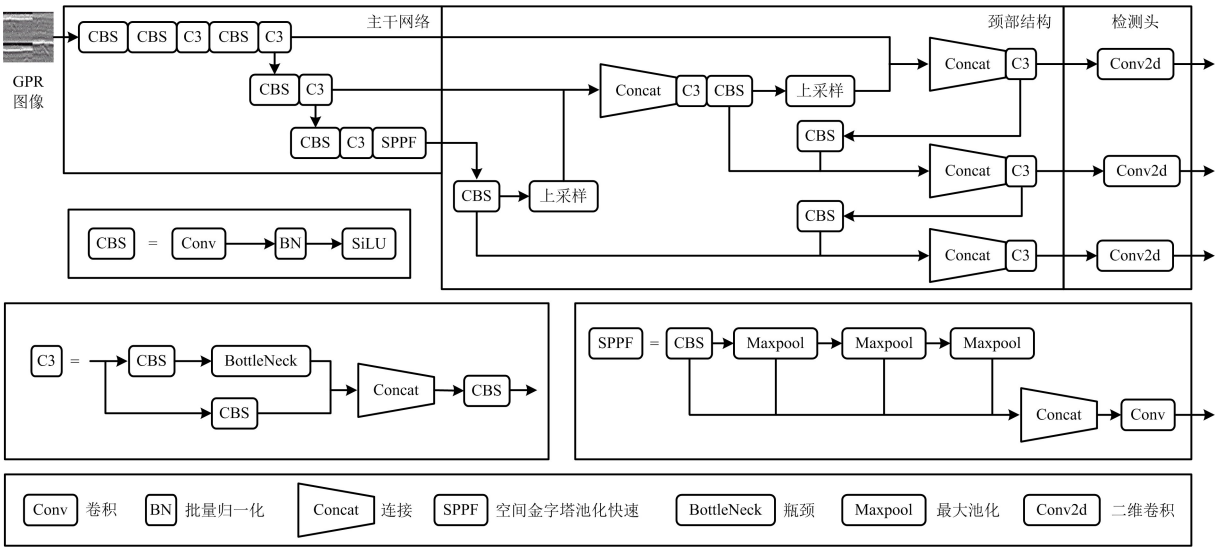

图 1 YOLOv5 网络结构

Fig. 1 Structure of YOLOv5 network

觉的简单有效的注意力模块[17],适用于前馈卷积神经网络,能够序列化地通过通道注意力机制模块(Channel Attention Mechanism,CAM)和空间注意力机制模块(Spatial Attention Mechanism,SAM)全面捕获特征中的关键信息,以提高模型表征能力和决策准确性,且 CBAM 的自适应重标定机制也能帮助模型更好地关注关键特征。作为一种通用的轻量级模块,CBAM 可以嵌入到任何主干网络中以提高识别性能,见图 2(a)。

图 2(b)为通道注意力结构图。首先,输入的特征图(尺寸为 $H \times W \times C$,其中 H 为高度,W 为宽度,C 为通道数)分别在宽度维度 W 上进行最大池化、在高度维度 H 上进行平均池化,即将特征在这两个维度上压缩,得到两个 $1 \times 1 \times C$ 的特征图;其次,将两个特征图输入共享的全连接层进行处理,并将全连接层输出的结果相加后使用 Sigmoid 激活函数生成最终的每个通道的权重。最后,权重通过乘法和输入特征图相乘得到加权后的特征图,即空间注意力模块需要的输入特征。图 2(c)为空间注意力结构图。输入的特征图分别在通道维度 C 上进行最大池化与平均池化,将得到的两张特征图在通道维度进行连接,随后经过 7×7 卷积降维,再使用 Sigmoid 激活函数生成特征图的空间权重,最后得到的权重再与输入特征图相乘。CBAM 注意力机制可以在 Backbone、Neck、Head 等部分添加,本文选择两种改进方法进行研究:在 Backbone 的 SPPF 前添加;将 Backbone 中的 C3 全部替换成 CBAM。

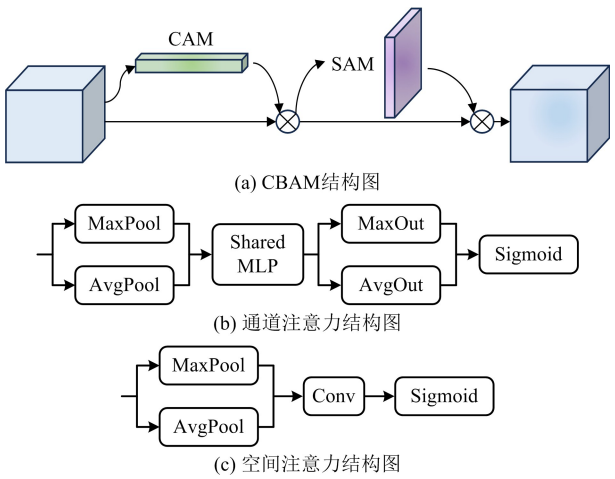

图 2　注意力模块结构

Fig. 2　Structure of the attention module

上下文引导模块(Context Guided Block,CG Block)是上下文引导网络(Context Guided Network,CG Net)的基本单元[18],能够学习局部特征和周围上下文、全局上下文信息来增强特征表示,进而提升模型在复杂场景的特征表达能力[18],在减少参数量和内存占用的前提下能有效提高分割精度。

如图 3 所示,CG Block 由局部特征提取器[$f_{loc}(*)$]、周围上下文特征提取器[$f_{sur}(*)$]、联合特征提取器[$f_{joi}(*)$]和全局特征提取器[$f_{glo}(*)$]4 部分组成。局部特征提取器以常规卷积实现,周围上下文特征提取器通过膨胀卷积实现,联合特征提取器使用连接层连接局部特征和周围上下文特征,再通过 BN 层和 PReLU 激活函数激活,全局特征提取器使用一个全局池化层和两个全连接层获取权重。

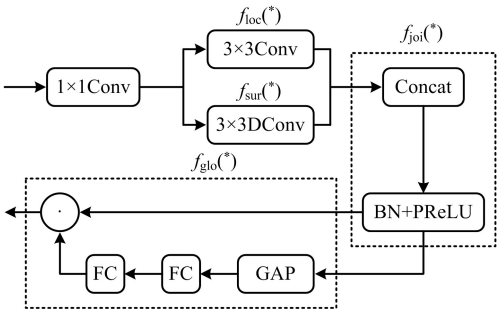

图 3　Context Guided 模块结构

Fig. 3　Structure of Context Guided Block module

CG Block 采用了局部残差学习(Local Residual Learning,LRL)和全局残差学习(Global Residual Learning,GRL),其中残差学习利于模型学习更复杂的特征,促进梯度有效反向传播[19]。局部残差学习增加了从输入到联合特征提取器的连接,全局残差学习增加了从输入到全局特征提取器的连接。试验显示,全局残差学习更能提高分割精度[18]。本文在 Neck 部分将最后 3 个 C3 模块替换成 Context Guided 模块。

2.2　Dynamic Head 动态检测头

Dynamic Head 检测头是一种动态检测头[20],可以同时实现尺度感知、空间感知和任务感知,在特征的 3 个维度上都应用了注意力机制,有效提高了模型对多维度特征的检测性能和速率。尺度感知注意力(Scale-aware Attention,π_L)专注于特征层级,空间感知注意力(Spatial-aware Attention,π_S)专注于空间位置,任务感知注意力(Task-aware Attention,π_C)专注于通道,可以支持不同的任务。图 4 为 Dynamic Head 模块结构图。本文将使用 Dynamic Head 替换

YOLOv5 默认检测头。

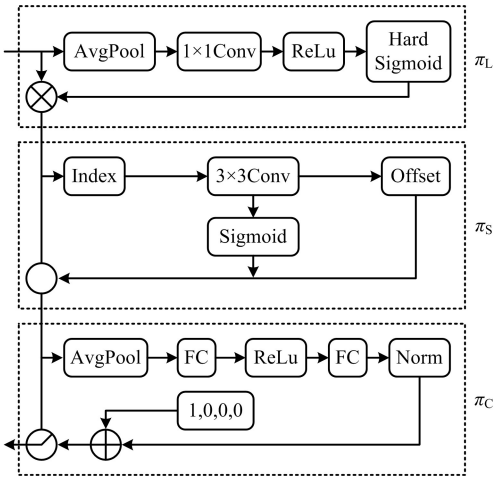

图 4 Dynamic Head 模块结构

Fig. 4 Structure of Dynamic Head module

3 试验与结果分析

3.1 试验环境与参数设置

本文研究的所有模型均在 Windows 11 专业版操作系统下并基于 Tensor Flow 框架实现,并在配置有 NVIDIA GeForce RTX 4090 D(24564MiB)的 PC 机上运行。其他主要环境配置包括: Python - 3.12.8, torch - 2.5.1, cuda - 12.4, cudnn - 8.9.7。使用 CPU 计算每秒帧数时的环境配置为 Python - 3.9.21, torch - 2.6.0, CPU 为 12th Gen Intel(R) Core(TM) i5 - 12400F。所有试验均使用 SGD (Stochastic Gradient Descent)优化器,学习率为 0.03,训练轮次为 300,训练批次为 16,图片尺寸为 640 像素 ×640 像素。使用 GPU 进行训练,其他参数均为默认值。

3.2 试验数据集

本文使用某道路地下目标检测的探地雷达数据,对数据进行拼接、随机加噪声等处理,得到共 1 290 张图像,分辨率为 640 像素 ×640 像素,其中 1 020 张用于训练,270 张用于验证。病害分为疏松与裂缝两种,其中裂缝标记 507 处,共 415 张,疏松标记 1 200 处,共 716 张,背景图有 416 张,即无病害图像。典型疏松、裂缝病害图像见图 5。

3.3 评价指标

混淆矩阵常用于评估分类模型性能,并以真实值和预测值为基础进行统计和汇总。其中,真阳性(True Positive, T_P)表示实际为阳且预测为阳,真阴性(True Negative, T_N)表示实际为阴且预测为阴,假阳性(False Positive, F_P)表示实际为阴但预测为阳,假阴性(False Negative, F_N)表示实际为阳但预测为阴。以混淆矩阵为基础计算精确率(Precision, P)和召回率(Recall, R)。精确率表示预测为阳的样本中预测正确的比例,召回率表示实际为阳的样本被预测为阳的概率,计算公式为

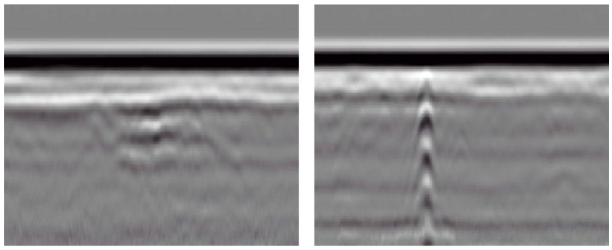

(a) 疏松病害图 (b) 裂缝病害图

图 5 典型路基病害雷达图

Fig. 5 Typical subgrade defect in GPR images

$$P = \frac{T_P}{T_P + F_P} \tag{1}$$

$$R = \frac{T_P}{T_P + F_N} \tag{2}$$

精确率和召回率均越高越好,但有时会出现一个极高一个极低的情况,因此单独用其中一个指标无法中肯地评价模型。F_1分数同时考虑了精确率和召回率,F_1分数越高,表示模型能够在较为严格的条件下保持较高的精确率和召回率。当精确率和召回率的影响同样重要时,F_1分数计算公式为

$$F_1 = \frac{2PR}{P + R} \tag{3}$$

交并比(Intersection over Union, I_{oU})是目标检测中的一个重要概念,表示预测框和真实框的交集和并集的比值,进而量化预测框和真实框的重叠程度。I_{oU}为 0 ~ 1,0 表示不重叠,1 表示完全重叠。通过设置不同 I_{oU}阈值可得到不同阈值下的精确率和召回率。以精确率为 Y 轴、召回率为 X 轴,可绘制精确率-召回率曲线。精确率-召回率曲线下的面积即为平均精度(Average Precision, A_P),为 0 ~ 1,值越大,表示模型效果越好。召回率从 0 ~ 1 以一个步长为距离 m 取 n 个点,相邻两个点的召回率差值与该点精确率的乘积之和即为 A_P。对于复杂情况,通过对精确率-召回率曲线进行数值积分能更准确地计算 A_P。A_P的计算公式为

$$A_P = \sum_{k=0}^{k=n-1} [R(k) - R(k+1)]P(k) \tag{4}$$

平均精度均值(Mean Average Precision, m_{AP})计

算的是每个类别的平均精度的平均值。m_{AP50}代表在I_{oU}阈值为 0.5 时的平均精度均值。$m_{AP50-95}$代表在I_{oU}阈值从 0.5 到 0.95 的每 0.05 个步长的平均精度均值。当有 n 个类别时,则

$$m_{AP} = \frac{1}{n}\sum_{k=1}^{k=n} A_{P,k} \tag{5}$$

F_{PS}(Frames Per Second)表示每秒帧数,在目标检测算法中,F_{PS}越大,代表系统每秒能处理的图像帧数越大,F_{PS}可用 1 s 除以图像预处理时间、推理时间和后处理时间三者之和得到。由于F_{PS}存在波动,取 10 次验证平均值为最终结果。参数量对模型性能有重要影响,参数量同时与权重文件直接相关,参数量越大,权重文件占用的存储空间通常更大,意味着存储需求更大,而磁盘空间占用增加,模型加载时间增加,不适用于移动设备或嵌入式设备等资源有限的设备。本文选择分类精度指标 F_1 分数,综合精度指标 m_{AP50}、$m_{AP50-95}$,运行速度指标每秒帧数及参数量作为评价指标进行探讨。

3.4　注意力机制对比

CBAM 注意力机制可以在 Backbone、Neck、Head 等部分添加,为了证明本文中的注意力机制方法的有效性,选择两种改进方法进行对比试验,第一种是在 Backbone 的 SPPF 前添加 CBAM 模块,为 C1 - YOLOv5 模型,第二种是将 Backbone 中的 C3 全部替换成 CBAM,为 C2 - YOLOv5 模型。试验结果见表 1。

从表 1 发现,C1 - YOLOv5 模型和 C2 - YOLOv5 模型的 F_1 分数均有所提高,表明添加 CBAM 模块提高了模型的分类精度。在 3 个模型中,C1 - YOLOv5 模型的分类精度最高,两个综合精度指标的均值最高,参数量与 YOLOv5 模型相比持平,每秒帧数也保持在较高水平,综合性能最优。因此,选择 C1 - YOLOv5 模型进行后续试验。

3.5　消融试验结果

消融试验的结果见表 2。其中,C1 - YOLOv5 模型在 SPPF 层前添加 CBAM 模块进行改进;在 C1 - YOLOv5 模型基础上,C1 - DH - YOLOv5 模型使用 Dynamic Head 模块替换原有检测头,C1 - CG - YOLOv5 模型使用 Context Guided 模块进行改进,C1 -CG - DH - YOLOv5 模型使用 Dynamic Head 模块和 Context Guided 模块进行改进。

通过对比 C1 - YOLOv5 模型与 C1 - DH - YOLOv5 模型可以发现,使用 Dynamic Head 模块改

表 1　CBAM 模块结果对比

Table 1　Comparative results of CBAM module

模型	精确率/%	召回率/%	F_1 分数/%	m_{AP50}/%	$m_{AP50-95}$/%	每秒帧数(GPU)	每秒帧数(CPU)	参数量/10^6
YOLOv5	90.5	86.9	88.66	89.2	**62.8**	**263.306**	13.183	7.02
C1 - YOLOv5	93.8	85.4	**89.40**	**90.1**	62.6	230.923	**13.598**	7.05
C2 - YOLOv5	91.4	87	89.14	89.8	60.5	194.775	13.443	**6.70**

表 2　消融试验结果

Table 2　Results of ablation experiments

模型	精确率/%	召回率/%	F_1 分数/%	m_{AP50}/%	$m_{AP50-95}$/%	每秒帧数(GPU)	每秒帧数(CPU)	参数量/10^6
YOLOv5	90.5	86.9	88.66	89.2	62.8	**263.306**	13.183	7.02
C1 - YOLOv5	93.8	85.4	89.40	90.1	62.6	230.923	**13.598**	7.05
C1 - DH - YOLOv5	94.4	83.5	88.62	89.1	60.7	75.094	0.733	12.33
C1 - CG - YOLOv5	93.5	86.3	**89.76**	90.8	64.2	202.294	12.806	**6.12**
C1 - CG - DH - YOLOv5	91.4	87.6	89.41	**91.3**	**65.1**	72.485	0.734	11.9

进的模型每秒帧数大幅下降,检测速度显著降低,参数量也较改进前的模型翻倍。因此,虽然 C1 - CG - DH - YOLOv5 模型在综合精度指标上表现优异,但不适用于实时检测和在小型移动设备上部署。C1 - CG - YOLOv5 模型较 C1 - YOLOv5 模型分类精度和综合精度都有所提升,每秒帧数虽然有少许下降,但仍保持在较高水平,且参数量最小,实现了模型的轻量化。

图 6(a)对比了各个模型的运行速度指标。从图 6(a)可以看出,添加了 Dynamic Head 模块改进的模型检测速率最慢,YOLOv5、C1 - YOLOv5、C1 - CG -YOLOv5 模型在使用 GPU 运行时每秒帧数都超过 200。图 6(b)对比了各个模型的综合精度指标,其中越接近右上角位置的模型表现越好。可以看出,C1 - CG - DH - YOLOv5、C1 - CG - YOLOv5 模型的 m_{AP50} 和 $m_{AP50-95}$ 表现突出,其次是 C1 - YOLOv5 模型,YOLOv5 模型和 C1 - DH - YOLOv5 模型的 m_{AP50} 表现较差。图 6(c)是各个模型的 F_1 分数图。F_1 分数图的横轴是置信度阈值,纵轴表示 F_1 分数。当置信度与 F_1 分数均较高时,即曲线越靠近右上角,模型表现越好。从图 6(c)可以看出,C1 - CG - DH - YOLOv5 模型表现较好,C1 - CG - YOLOv5 模型、C1 - DH - YOLOv5 模型处于中等水平。如图 6(d)所示,各个模型的精确率-召回率曲线图中越接近右上角表现越好,其中 C1 - CG - YOLOv5 模型和 C1 - CG - DH - YOLOv5 模型表现较好。

综合上述讨论,C1 - CG - DH - YOLOv5 模型在分类精度、综合精度上表现优异,但其较低的运行速度和较大的参数量不适合实时检测与部署。而 C1 - CG - YOLOv5 模型实现了精度和速度上的平衡,取得了较好效果,即通过在 SPPF 层前添加 CBAM 模块和使用 Context Guided 模块替换 Neck 部分最后 3 个 C3 模块对 YOLOv5 模型进行改进,改进模型的网络结构见图 7。

3.6 模型部署

本文将训练好的模型进行封装部署并基于 Pyside 2 5.15.2 开发了路基疏松与裂缝病害检测可视化程序,见图 8。系统支持图片检测、模型加载、模型推理、结果可视化、结果保存等操作,在检测结果面板可显示目标数量、目标类别、位置和置信度。本文选取 YOLOv5 模型与 C1 - CG - YOLOv5 模型的检测结果进行了对比,见图 9。

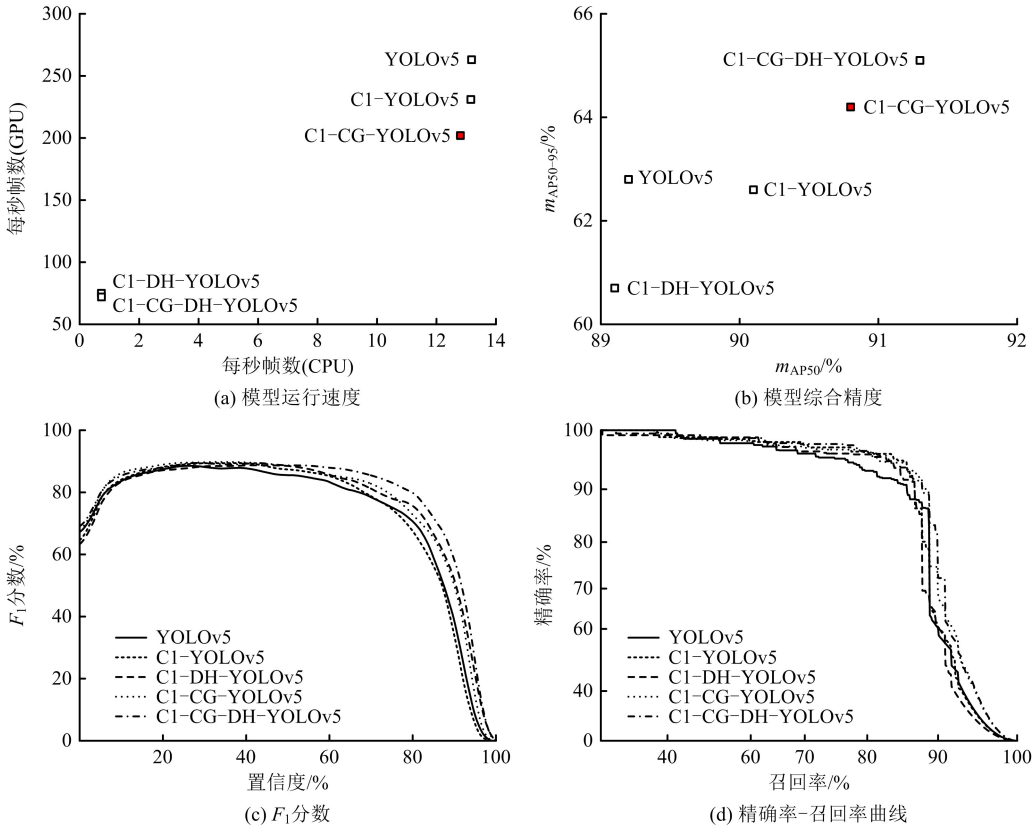

图 6 模型性能比较

Fig. 6 Comparison of model performance

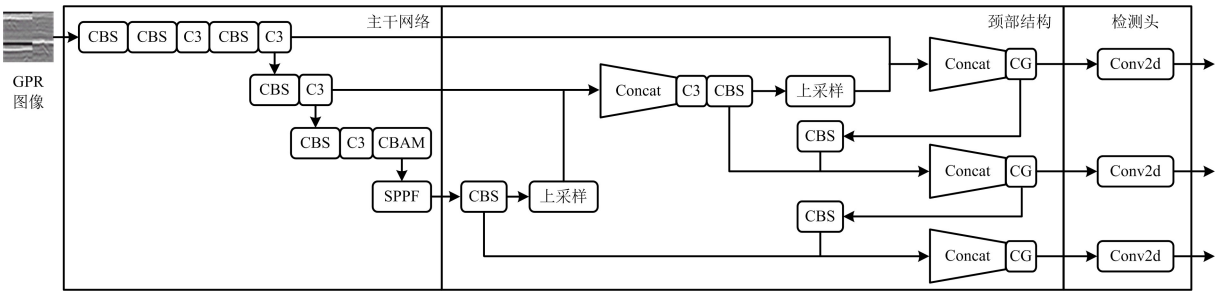

图 7　C1 – CG – YOLOv5 网络结构

Fig. 7　Structure of C1 – CG – YOLOv5 network

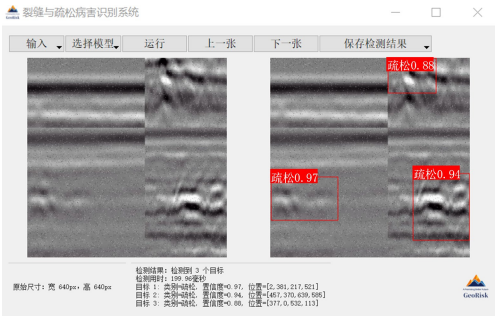

图 8　路基疏松与裂缝检测系统

Fig. 8　Subgrade loosening and cracking defect detection system

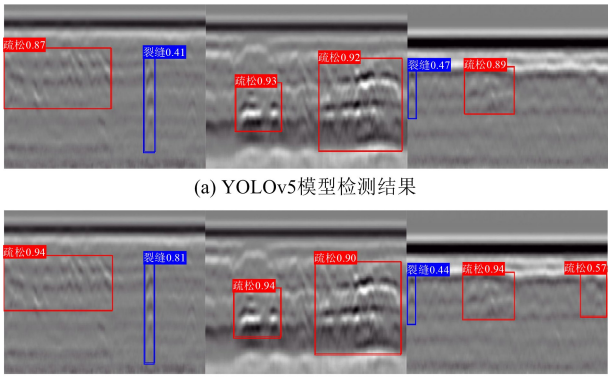

(a) YOLOv5模型检测结果

(b) C1-CG-YOLOv5模型检测结果

图 9　路基疏松与裂缝病害检测结果

Fig. 9　Detection results for subgrade loosening and cracking defect

4　结　论

针对路基裂缝与疏松病害的探地雷达图像识别中精度与实时性平衡问题,本文对 YOLOv5 模型进行了改进。首先,通过设计卷积注意力模块提高模型对关键特征的捕获能力,并对比确定了卷积注意力模块的添加位置。之后,通过消融试验分析了 Context Guided 模块与 Dynamic Head 模块的性能影响。得到主要结论如下。

(1)本文提出的改进模型 C1 – CG – YOLOv5 相较于基准模型 YOLOv5 在精度方面有所提升,其中精确率提高了 3 百分点,m_{AP50} 提升了 1.6 百分点,$m_{AP50-95}$ 提升了 1.4 百分点。同时,模型实现了轻量化,参数量降低了 12.8%,推理速度与 YOLOv5 模型相当。

(2)消融试验表明 Context Guided 模块能够在保持较高检测速率的同时提升检测精度。Dynamic Head 模块虽然能提升精度,但增加了模型计算量与参数规模,导致推理速度下降。Context Guided 模块复杂的多尺度注意力机制设计增加了计算负担和内存访问成本。因此,Context Guided 模块在实际应用中需进一步优化结构或限制适用范围,如将其作为辅助分支仅在特定尺度上应用。

(3)本文最终开发了一个基于改进 YOLOv5 的路基病害实时检测应用程序,且支持单张或批量图像处理及结果保存等功能。

参考文献(References):

[1]　刘欢, 李晋平, 王伟. 有砟铁路路基病害在探地雷达图像上的时域特征[J]. 铁道建筑, 2021, 61(3): 65 – 68.
Liu Huan, Li Jinping, Wang Wei. Time domain characteristics of ballast railway subgrade defects in GPR images[J]. Railway Engineering, 2021, 61(3): 65 – 68.

[2]　夏思茹, 张恒兵, 刘升传, 等. 探地雷达在沈阳某区市政道路病害检测中的应用[J]. 勘察科学技术, 2023(6): 54 – 56.
Xia Siru, Zhang Hengbing, Liu Shengchuan, et al. Application of ground penetrating radar in municipal road disease detection in an area in Shenyang City[J]. Site Investigation Science and Technology, 2023(6): 54 – 56.

[3]　Shapovalov V, Vasilchenko A, Yavna V, et al. GPR

method for continuous monitoring of compaction during the construction of railways subgrade[J]. Journal of Applied Geophysics, 2022, 199: 9.

[4] 王惠濂, 李大心. 脉冲时间域探地雷达讲座(第一讲)[J]. 国外地质勘探技术, 1989(10): 26 - 31.
Wang Huilian, Li Daxin. Lecture series on pulsed time-domain ground penetrating darae (Lecture 1)[J]. Foreign Geoexploration Technology, 1989(10): 26 - 31.

[5] 王惠濂, 李大心, 祁明松, 等. pulse - EKKOIV 脉冲时域探地雷达工程地质现场的试验[J]. 物探与化探, 1992(4): 267 - 274.
Wang Huilian, Li Daxin, Qi Mingsong, et al. Tests of the pulse - EKKOIV pulse time-domain grpund-probing radar on the engineering-geological sites[J]. Geophysical & Geochemical Exploration, 1992(4): 267 - 274.

[6] 杜衍庆, 隋昕展, 师海, 等. 公路路基浅层疏松病害地质雷达正演模拟及复信号分析[J]. 北京交通大学学报, 2023, 47(6): 147 - 153.
Du Yanqing, Sui Xinzhan, Shi Hai, et al. GPR forward simulation and complex signal analysis of shallow layer loosening defects in highway subgrade[J]. Journal of Beijing Jiaotong University, 2023, 47(6): 147 - 153.

[7] 隋昕展, 杜衍庆, 师海, 等. 道路路基脱空病害雷达波场数值模拟与瞬时属性分析[J]. 科学技术与工程, 2024, 24(2): 782 - 788.
Sui Xinzhan, Du Yanqing, Shi Hai, et al. Numerical simulation and instantaneous attribute analysis of ground penetring radar wave field for road subgrade void disease[J]. Science Technology and Engineering, 2024, 24(2): 782 - 788.

[8] 李永翔, 亢夏桐, 宋小强, 等. 沥青路面基层松散病害的三维雷达图谱特征分析[J]. 北京工业大学学报, 2025, 51(10): 1221 - 1228.
Li Yongxiang, Kang Xiatong, Song Xiaoqiang, et al. 3D - radar mapping characterization of loose asphalt pavement subgrade diseases[J]. Journal of Beijing University of Technology, 2025, 51(10): 1221 - 1228.

[9] Warren C, Giannopoulos A, Giannakis I. gprMax: open source software to simulate electromagnetic wave propagation for ground penetrating radar[J]. Computer Physics Communications, 2016, 209: 163 - 170.

[10] Amaral L C M, Roshan A, Bayat A. Automatic detection and classification of underground objects in ground penetrating radar images using machine learning[J]. Journal of Pipeline Systems Engineering and Practice, 2023, 14(4): 7.

[11] 谢豪, 王靖宇. 基于 LSTM 神经网络的隧道衬砌病害识别方法研究[J]. 地球物理学进展, 2025, 40(5): 2227 - 2236.
Xie Hao, Wang Jingyu. Research on tunnel lining disease identification method based on LSTM neural network[J]. Progress in Geophysics, 2025, 40(5): 2227 - 2236.

[12] 房振华, 谭治海, 朱哲, 等. 基于 Faster - RCNN 的探地雷达公路病害图像检测[J]. 施工技术(中英文), 2023, 52(24): 76 - 82.
Fang Zhenhua, Tan Zhihai, Zhu Zhe, et al. GPR Image detection of highway diseases based on Faster - RCNN[J]. Construction Technology, 2023, 52(24): 76 - 82.

[13] 周廷楠. 基于神经网络的水泥路面探地雷达病害图像识别研究[D]. 桂林: 桂林电子科技大学, 2021.
Zhou Tingnan. Research on GPR image recognition of cement pavement based on neural network[D]. Guilin: Guilin University of Electronic Technology, 2021.

[14] 麻哲旭, 杨峰, 乔旭. 铁路路基病害智能检测方法[J]. 计算机工程与应用, 2021, 57(9): 272 - 278.
Ma Zhexu, Yang Feng, Qiao Xu. Intelligent detection method of railway subgrade defect[J]. Computer Engineering and Applications, 2021, 57(9): 272 - 278.

[15] Wang Yuanzheng, Qin Hui, Zhang Donghao, et al. Domain adaption YOLO network to enhance target detection in GPR images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 1 - 15.

[16] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27 - 30, 2016, Las Vegas, NV, USA. Piscataway, NJ, USA: IEEE, 2016.

[17] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[C]//15th European Conference on Computer Vision (ECCV), September 8 - 14, 2018, Munich, Bavaria, Germany. Piscataway, NJ, USA: IEEE, 2018.

[18] Wu Tianyi, Tang Sheng, Zhang Rui, et al. CGNet: a light-weight context guided network for semantic segmentation[J]. IEEE Transactions on Image Processing, 2021, 30: 1169 - 1179.

[19] 李一帆. 基于 YOLOv8 的目标鸟种鸣声自动检测研究[D]. 广州: 广州大学, 2024.
Li Yifan. Research on automatic detection of target bird species calla based on YOLOv8[D]. Guangzhou: Guangzhou University, 2024.

[20] Dai Xiyang, Chen Yinpeng, Xiao Bin, et al. Dynamic head: unifying object detection heads with attentions[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 19 - 25, 2021, Nashville, TN, USA. Piscataway, NJ, USA: IEEE, 2021.

Application of YOLOv5 in intelligent recognition of subgrade diseases based on ground penetrating radar images

Zhou Suhua[1,2], Huang Chuting[1], Sha Linchuan[3], Huang Minghua[1,2]

(1 College of Civil Engineering, Hunan University, Changsha 410082, China;
2 State Key Laboratory of Bridge Safety and Resilience, Changsha 410082, China;
3 Guizhou Quality and Safety Traffic Engineering Monitoring and Testing Center Co., Ltd., Guiyang 550014, China)

Abstract: As an advanced non-destructive detection technology and one of the most effective tools available, Ground Penetrating Radar (GPR) has been widely applied in identifying subgrade diseases due to its efficiency and high resolution. However, manual interpretation of GPR images is highly challenging, time-consuming, and susceptible to subjective errors. To address these issues, this study proposes an improved YOLOv5-based method for the automated identification of GPR images depicting subgrade cracks and loosening defects. This method is specifically designed to balance real-time performance with detection accuracy. A carefully constructed dataset comprising 1 290 VOC-format annotated radar images of typical subgrade defects was utilized for model training and validation. Several key architectural enhancements were introduced: the Convolutional Block Attention Module (CBAM) was embedded before the Spatial Pyramid Pooling Fast (SPPF) layer to enhance focus on meaningful features while reducing redundant parameters. Additionally, three C3 modules in the neck of the original YOLOv5 were replaced with Context Guided Blocks (CG Blocks) to strengthen contextual feature perception and improve computational efficiency. Further refinements included a Dynamic Head mechanism to enhance scale-aware representation. Ablation studies demonstrated that the combined improvements from the attention and context-guided modules yielded optimal results. The enhanced C1 − CG − YOLOv5 model achieved a mean Average Precision at I_{oU} threshold of 0.5 (m_{AP50}) of 90.8% and a mean Average Precision at I_{oU} thresholds of 0.5 to 0.95 ($m_{AP50-95}$) of 64.2%, significantly outperforming the baseline model. Moreover, the model parameters were reduced by 12.8%, indicating superior lightweight performance. Finally, we developed real-time subgrade disease detection software based on the improved model, validating its detection performance, processing efficiency, and practical utility in GPR image analysis. The proposed approach offers an efficient and reliable tool for automated GPR image interpretation, demonstrating strong potential for practical application in infrastructure maintenance and non-destructive evaluation.

Key words: safety engineering; subgrade diseases recognition; ground penetrating radar; object detection; YOLOv5