

# 沥青路面内部裂缝雷达图像智能判识算法研究

董明书<sup>1</sup>, 陈俐企<sup>1</sup>, 马川义<sup>2</sup>, 张珠皓<sup>1</sup>, 孙仁娟<sup>1</sup>, 管延华<sup>1</sup>, 庄培芝<sup>1\*</sup>

(1. 山东大学齐鲁交通学院, 山东 济南 250002; 2. 山东高速集团有限公司, 山东 济南 250098)

**摘要:**采用探地雷达对典型路段的路面裂缝识别并定位。通过钻芯取样与铣刨观察结合的方法验证,构建了包含728张雷达图像的数据库;采用YOLO v8l算法学习裂缝特征,通过在YOLO v8l算法的基础上引入注意力机制和修改激活函数,克服了路面裂缝图像特征多变、噪声杂波明显等对于智能判识造成的干扰,同时消除了模型的过拟合现象;对算法修正后,模型的计算参数增多,计算效率提升,修正算法的识别精确度和召回率分别达到99.4%和92.3%。训练过程中平均精度均值与损失函数的震荡幅度较小,表示该数据集标注原则统一,证明了采用该方法识别路面裂缝的有效性与可靠性。

**关键词:**探地雷达;人工智能;目标检测;深度学习算法;卷积神经网络

**中图分类号:**U418.6; P631.3 **文献标志码:**A

**引用格式:**董明书,陈俐企,马川义,等. 沥青路面内部裂缝雷达图像智能判识算法研究[J]. 山东大学学报(工学版),2025,55(3):72-79.

DONG Mingshu, CHEN Liqi, MA Chuanyi, et al. Deep learning-based intelligent judgment for radar detection of pavement cracks[J]. Journal of Shandong University (Engineering Science), 2025, 55(3):72-79.

## Deep learning-based intelligent judgment for radar detection of pavement cracks

DONG Mingshu<sup>1</sup>, CHEN Liqi<sup>1</sup>, MA Chuanyi<sup>2</sup>, ZHANG Zhuohao<sup>1</sup>, SUN Renjuan<sup>1</sup>, GUAN Yanhua<sup>1</sup>, ZHUANG Peizhi<sup>1\*</sup>

(1. School of Qilu Transportation, Shandong University, Jinan 250002, Shandong, China; 2. Shandong Hi-Speed Group Co., Ltd., Jinan 250098, Shandong, China)

**Abstract:** This study employed GPR (ground penetrating radar) to identify and locate surface cracks in typical road segments. The method combined core drilling sampling and milling observation for validation, resulting in the construction of a database containing 728 radar images. The YOLO v8l algorithm was used to learn crack features. By incorporating an attention mechanism and modifying the activation function within the YOLO v8l framework, the study overcame the interference caused by the variability of road crack image features and significant noise, while also eliminating model overfitting. After modifying the algorithm, the model's computational parameters increased, and the computational efficiency improved. The precision and recall rates of the revised algorithm reached 99.4% and 92.3%, respectively. During training, the mean average precision and loss function fluctuations were minimal, indicating that the dataset annotation principles were consistent. This proved the effectiveness and reliability of the proposed method for identifying road surface cracks.

**Keywords:** ground penetrating radar; artificial intelligence; object detection; deep learning algorithm; convolutional neural network

## 0 引言

截至2022年底,中国公路总里程已超过535万km,其中低等级公路超过375万km,占总里程的70%以上。低等级公路路面普遍存在较为严

重的路表损坏和内部隐蔽病害,其中裂缝类病害约占60%以上<sup>[1]</sup>,裂缝病害导致路面服役水平降低和寿命缩短,造成巨大的交通安全隐患。探地雷达(ground penetrating radar, GPR)作为一种高效、可穿透、成像分辨率高的无损检测手段,已广泛应用于道路隐蔽病害、隧道衬砌等检测中<sup>[2-4]</sup>。使用探地雷达检测道路

收稿日期:2024-04-25

基金项目:国家重点研发计划资助项目(2023YFB2604004)

第一作者简介:董明书(1999—),男,山东济宁人,硕士研究生,主要研究方向为探地雷达病害智能识别。E-mail:202215410@sdu.edu.cn

\*通信作者简介:庄培芝(1988—),男,山东青岛人,教授,博士生导师,博士,主要研究方向为路基岩土及道路智能养护。

E-mail:zhuangpeizhi@sdu.edu.cn

病害生成大量图像数据,人工解译雷达图像数据对经验要求高,且解译效率低、周期较长。因此,构建探地雷达特征数据库,获取典型雷达图像特征,实现雷达图像的智能化识别,具有重要意义。

基于探地雷达的地下隐蔽目标识别方法可分为正演和反演2类。通过正演方式可以生成大量仿真雷达图像数据,从雷达图像的生成原理入手分析雷达的成像特征,但正演方式无法模拟实际道路材料与结构特征,仿真数据与实际数据存在一定差异;反演方式可分为基于雷达时频域信号推测地下结构和基于雷达图像的目标识别2种方式。文献[5]基于模拟数据构建出基于时频融合数据的电磁反演处理框架 GPR-EInet,实现了单、双目标的介电常数反演推算;文献[6]通过卷积神经网络(convolutional neural network, CNN)构建出道路参数与雷达数据之间的映射关系,通过反演实现了对道路病害的快速检测;文献[7]采用数值模拟和模型试验,针对反演算法复杂度高的问题,提出一种自动调整惯性权重的重采样粒子群优化算法,提高了识别效率与精度。然而采用上述反演方式推测地下结构存在严重依赖后续解译工作、对雷达使用经验要求较高等问题。采用探地雷达检测地下构筑物,并通过深度学习对雷达图像进行智能判识的研究初见成效。2005年,文献[8]采用 CNN 与 Transformer 框架相结合的混合结构,通过预测框转化后的中心点与宽、高等数据,将目标检测任务转化为一个序列预测的任务;文献[9]提出一种基于可学习图核的时空对应框架,通过自监督方式进行语义解析和图像预测;文献[10]提出一种基于对抗训练的可变形多粒度特征融合网络,实现了高效目标检索;文献[11]采用迁移学习和卷积神经网络,对地下构筑物在探地雷达图像中显示出的双曲线特征进行了定位和提取;文献[12]通过支持向量机等算法实现了对地下物体的形状尺寸、土体类型等的分类;文献[13]通过  $K$  邻近算法( $K$ -nearest neighbors, KNN)处理降维后的数据,降低计算性能需求的同时实现了目标识别;文献[14]从雷达 B-scan 图像入手构建典型数据集,通过进一步处理的 Faster R-CNN 算法检测出的矩形框,实现道路内部病害的定位;文献[15]采用多种 CNN 模型构建出级联神经网络,进行道路病害的快速识别与定位;文献[16]通过在 Faster R-CNN 算法中引入注意力机制,通过多视图病害分析对道路病害进行分类,显著提升了训练结果的平均准确率和召回率。上述深度学习方法多为双阶段算法,计算效率较

低,难以做到实时监控。文献[17]于2016年提出采用单阶段算法的 YOLO 算法,在训练精度和训练效率等方面比其他算法具有更加明显的优势;文献[18]通过改进的 YOLO v4 模型对城市道路病害与结构物进行了自动识别;文献[19]通过对抗神经网络扩充数据,并采用 YOLO v5 模型进行监督学习,实现了铁路路基病害的智能识别。近年来,YOLO 算法的整体性能得到了进一步提升,广泛应用于交通工程领域的病害识别。

综上,针对探地雷达数据的路面隐蔽病害智能识别方法受到了国内外学者的广泛关注。相关智能识别算法的精度和鲁棒性严重依赖于探地雷达数据的质量和体量。然而,目前相关数据集较少且多集中于服役状态相对较好的高速公路路面结构。低等级公路与高速公路在路面结构形式、设计使用年限、养护维修等方面存在较大不同,导致相应病害数量及分布特征等存在显著差异。针对该问题,本研究通过开展现场试验,获得了低等级沥青路面裂缝的雷达典型图像数据集,通过数据增强和噪声过滤对数据集进行处理,利用 YOLO v8l 模型对雷达图像进行智能判识,解决人工识别雷达图像效率低的问题,并通过在 YOLO 模型中引入注意力机制等方法,消除模型的过拟合问题,提高模型精确度、召回率等指标,达到较高的识别准确度,具有一定的工程意义。

## 1 雷达图像数据库建立

### 1.1 探地雷达图像获取

本研究的数据采自山东省济南市莱芜区某三级路 K258+000~K267+000 路段,检测路段全长 9 km,检测宽度为两车道全宽。该路段路面结构由 8 cm 沥青面层、双层 17 cm 水稳碎石基层组成。该道路使用年限较长,道路存在多种典型的路面裂缝,设计进行铣刨处理。

数据集获取及验证流程如图 1 所示。本研究通过 2 类方法获取并验证道路内部裂缝的典型雷达图像,分别为:(1)通过对雷达图像上显示的典型裂缝定位并取芯验证;(2)根据观测、记录的铣刨病害反推雷达图像对照验证。

通过上述 2 种方式对照验证后,检查误判裂缝病害的原因,并调整验证原则,将经过验证的雷达图像分割、标注后,制作成裂缝数据集,用于 YOLO v8 模型训练。其中,钻芯取样可验证直径小于 10 cm 的病害,但无法观测裂缝水平向的发展程

度;观察铣刨法只能验证裂缝在同一层位横向展布,无法观测裂缝沿竖向的连续发展程度。2种方

法优势互补,将雷达图像与裂缝病害匹配印证,共同建立典型裂缝的雷达图像数据集。

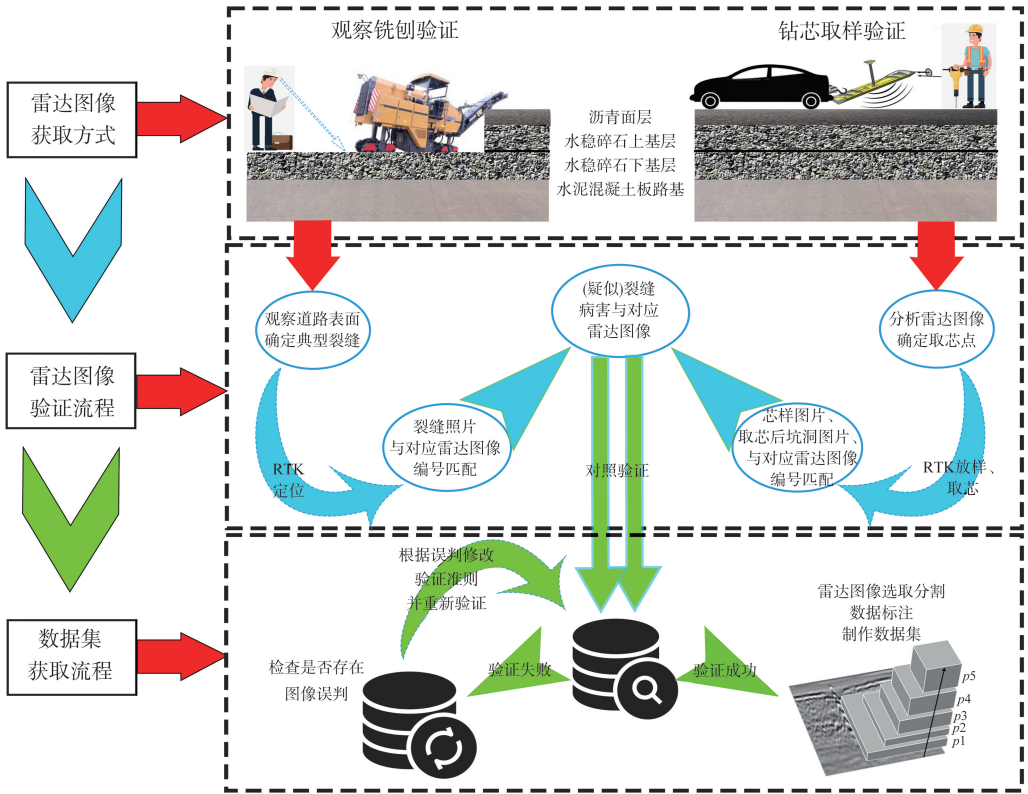


图1 数据集获取及验证流程

Fig.1 Dataset acquisition and validation process

### 1.2 探地雷达图像验证

钻芯取样能够反映出裂缝的竖向联系,从分析裂缝特征得出集中、典型的病害间联系。初步分析采集的雷达图像后,寻找包含典型清晰的裂缝病害雷达图像作为钻芯取样点并对它定位,根据实时动态(real time kinematic, RTK)定位对取样点位放样,再对放样点进行钻芯验证和裂缝特征记录,预测裂缝与实际裂缝的位置与特征对照一致后,将雷达图像存至样本库。

钻芯验证时,将检测路段每隔 1 km 分为一段,共分 9 段。对采集的数据降噪和增益后,筛选和标记出每段最典型的取芯点。本研究共开展钻孔取芯 18 处。同时,通过观察铣刨后揭露的裂缝分布情况,验证流程为:待铣刨清扫完成后,观察铣刨后路表并采用 RTK 定位,将表现较为集中的典型裂缝病害标注在雷达图像中。

本研究通过上述 2 种方式共采集裂缝病害 93 处,雷达图像对比验证如图 2 所示。

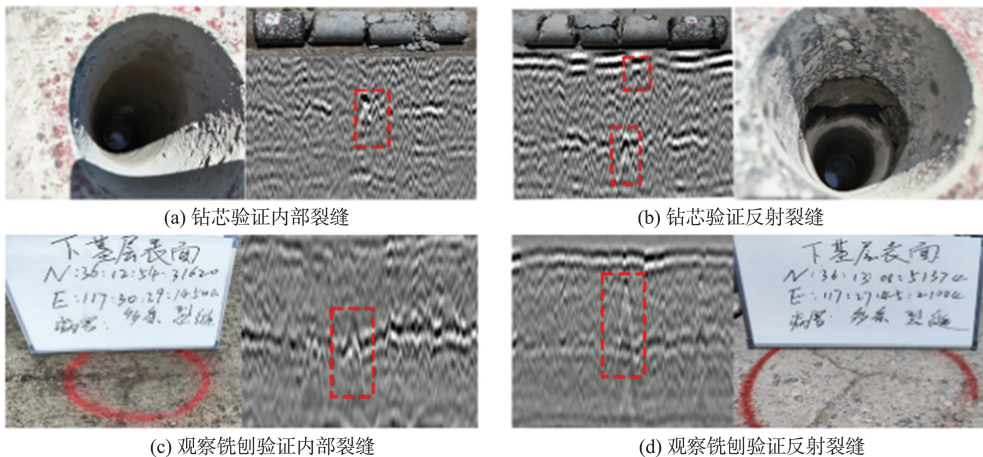


图2 雷达图像对比验证

Fig.2 Comparative validation of radar

裂缝位置的验证通过 RTK 经纬度定位。为保证定位准确性,雷达图像与实测得到的经纬度相差不超过  $0.0005''$  (约为 20 cm)。舍弃由于定位失准、超出检测范围、病害类型或位置不一致造成的裂缝后,选取包含已验证裂缝的通道获取雷达图像。按照每幅宽度 20 m、高度 1.2 m 的尺寸在系统中输出雷达图像,组成裂缝图像数据库,输出图像大小为 967 像素×526 像素,将图像的坐标轴裁剪后,得到图像大小为 926 像素×490 像素。

### 1.3 探地雷达图像处理

为使裂缝图像具有足够的分辨率以保证训练框分割的精确性,需要对雷达图像进行像素扩充。为尽量保持操作前后像素比例一致,通过线性插值将图像扩充为 1 800 像素×1 000 像素。为使数据集中每张图像包含经由验证的完整病害图像,将图像分割为 450 像素×500 像素的小块,即每张图片对应实际道路长 5.0 m、深 0.6 m 内的病害。通过该方法,基于钻芯取样验证得到 193 张雷达图像,通过铣刨观察获得 535 张雷达图像,共计 728 张。

由于该道路裂缝类型较多且程度严重,导致雷达图像噪音较大,容易出现误判和标注边界不清晰等问题,需设定明确的标注原则。基于雷达图像的生成原理,结合模型的训练结果中显示出的一致特性,调整原有的标注原则,最终总结出标注裂缝应遵循的原则为:

(1) 标注框应以代表强正波的高亮白色或代表负波的黑色为边界<sup>[20]</sup>;

(2) 框出部分应具有双曲线特征<sup>[21]</sup>,双曲线顶部边缘无需对称;

(3) 水平向的连续双曲特征应分开框选<sup>[22]</sup>,否则会影响特征提取;

(4) 由于竖向会产生同相轴现象<sup>[23]</sup>,在同一水平位置且双曲特征一致的异常点应一起框选;

(5) 框选裂缝时图像内应包括双曲线顶端且至少包含双曲线的 2/3。

## 2 训练及模型修改方案

### 2.1 模型参数介绍

本研究采用 YOLO v8 模型进行初始训练。YOLO v8 模型由训练准备部分、特征提取骨干网络和特征综合检测头部网络 3 部分组成。在训练准备中完成数据增强,并通过聚类算法推断标注框的大小;在骨干网络中通过对图像进行 5 次下采样特征

提取,并采用 C2f 对上一层输入的信息进行特征提取与融合;头部网络采用双向特征金字塔结构,通过 2 次上采样和 2 次下采样在大、中、小 3 个不同的尺度上形成特征层,并使每个特征层都具备其他 2 个特征层的特征信息,实现特征融合,提升检测的准确率和速度。

采用迁移学习方法提高训练效率。以 4 张图片为一组进行训练,将带有标注的 728 张数据集及 60 张与数据集格式相同、但不包含异常点的雷达图像按照 7:2:1 的比例分别分配至训练集、测试集与验证集进行训练。使用软件为:PyCharm Community Edition 2020.2.2 x64, Python 3.8, CUDA 12.2.79。

### 2.2 模型结构比选

YOLO v8 模型对于目标检测任务给出 5 个子版本,按照模型参数量由小到大依次为 n、s、m、l、x。采用不同版本进行雷达图像训练,与平均精度均值  $m_{AP}$  对比。平均精度均值表征模型的整体表现,最大为 1.0,  $m_{AP}$  越大,说明模型的训练效果越好,通常在其后添加数字表示计算该参数时考虑的置信度范围,例如  $m_{AP50}$  表示在计算平均精度时,采用交并比阈值为 0.50,即当预测框与真实框的重叠度大于或等于 50% 时,认为该预测是正确的。 $m_{AP50-95}$  是一种综合评价指标,通过对交并比阈值以 0.05 为一个间隔、在 0.50~0.95 内逐步增加,计算模型在不同交并比阈值下的平均精度,因此  $m_{AP50-95}$  比  $m_{AP50}$  更加严格,数值上一般更低。不同模型  $m_{AP50-95}$  对比结果如表 1 所示。由表 1 可知,YOLO v8l 模型对于雷达图像数据库的训练效果最好,故采用该版本进行后续训练。

表 1 不同模型  $m_{AP50-95}$  对比  
Table 1 Comparison of  $m_{AP50-95}$  values obtained from different models

结构名称	$m_{AP50-95}$
YOLO v8n	0.799
YOLO v8s	0.863
YOLO v8m	0.902
YOLO v8l	0.926
YOLO v8x	0.902

### 2.3 YOLO v8l 训练结果

采用 YOLO v8 模型的 l 版本进行训练,结果如图 3 所示。在图 3(a) 中,训练集与验证集的损失  $L_{oss}$  (损失是衡量模型预测输出与实际标签之间差异的指标)随训练轮次提升逐渐稳定下降。预测框损失代表预测出的边界框与实际目标边界框之间的差异,分类损失表示模型对不同目标及同一目标的

不同特征分类的准确程度。图3(b)表示精确率、召回率以及  $m_{AP}$  随训练轮次提升的变化,训练过程中,精确率、召回率以及  $m_{AP}$  稳定提升,但在训练末尾有一定程度的下降,说明产生了过拟合现象。

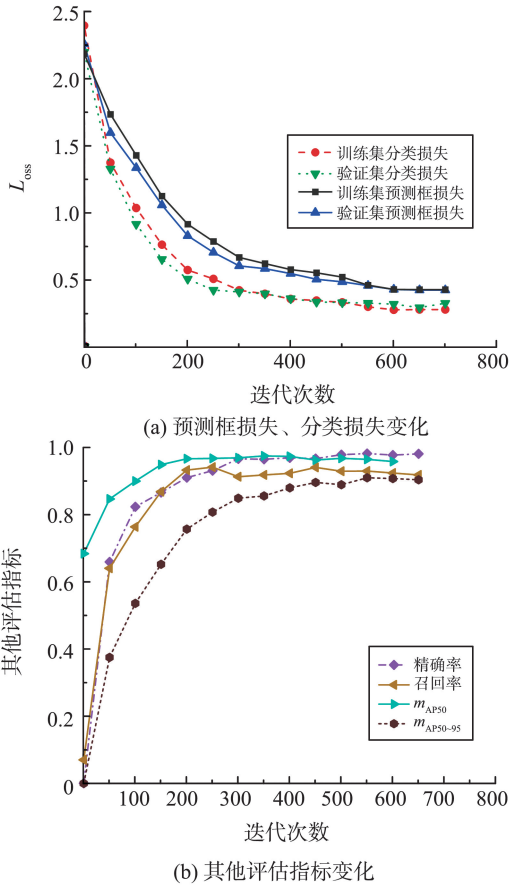


图3 YOLO v8l 模型训练效果

Fig.3 Training results of YOLO v8l model

## 2.4 模型结构修改

为进一步提升训练效果,并消除训练中产生的过拟合现象。本研究在骨干网络末尾引入 MPCA<sup>[24]</sup>、SegNext Attention、Bi-Level Routing Attention<sup>[25]</sup> 3 种在深度学习领域的经典注意力机制<sup>[26]</sup>,并将原函数的激活函数修改为 SELU 函数<sup>[27]</sup>,与原模型以及该模型前一个版本(YOLO v5)的训练效果对比分析。

## 3 试验结果分析

为避免过拟合现象,并进一步提高识别效率与精度,引入注意力机制,将算法对图片不同位置的关注度分配权重。在 YOLO v8l 的模型结构基础上添加 MPCA、SegNext Attention、Bi-Level Routing Attention 三种不同的注意力机制,并与 YOLO v5l、YOLO v8l 以及修改激活函数为 SELU 函数的 YOLO v8l-SELU 进行对比,各种模型的计算复杂度如表 2 所示,其中时间复杂度取决于网络中的乘加

计算(multiply-accumulate operations, MACs),也就是模型的十亿次浮点计算次数(giga floating point operations per second, GFLOPs)  $G_{FLOPs}$ ,空间复杂度采用计算参数量来表征。

表2 不同模型的计算复杂度

Table 2 Comparison of  $m_{AP50}$  computational complexity from different models

模型名称	$G_{FLOPs}$	参数量
YOLO v8l-SELU	164.8	43.61
YOLO v8l-MPCA	164.9	44.92
YOLO v8l-SegNext	165.1	43.93
YOLO v8l-Bi-Level Routing Attention	165.7	44.66
YOLO v5l	134.7	53.13
YOLO v8l	164.8	43.61

$G_{FLOPs}$  表征了模型在处理数据时的计算效率,模型的  $G_{FLOPs}$  越高,代表模型在相同时间内计算次数更多,从而处理更复杂的任务。参数量的大小表征模型运行时消耗的计算资源,模型参数量较小说明计算时消耗的计算资源较少。由表 2 可知,YOLO v5l 模型的计算效率最低,运行模型消耗的计算资源最大,YOLO v8l 模型在 YOLO v5l 模型的基础上进行了很多优化,使模型在保持高精度的同时,减少了计算量,提高了检测速度。表 2 中采用 SELU 激活函数替换 YOLO v8l 模型原始激活函数后  $G_{FLOPs}$  与参数量均未发生改变,说明修改激活函数对于计算复杂度无影响,将不同注意力机制引入 YOLO v8l 模型中导致模型参数量与计算效率均得到不同程度的提高。其中,引入 Bi-Level Routing Attention 的 YOLO v8l 模型在消耗额外计算资源较小的情况下拥有最高的计算效率,证明它对雷达图像的识别具有一定的适配性。

每隔 50 训练轮次将不同模型的  $m_{AP50}$  与  $m_{AP50-95}$  分别对比,结果如图 4 所示。

图 4 中,相同的训练轮次下,YOLO v8l 模型的 2 种  $m_{AP}$  均始终比 YOLO v5l 模型更高,说明 YOLO v8l 比 YOLO v5l 在计算效率、计算精度等方面都有了明显的提升。如图 4(a) 所示,YOLO v8l 框架的算法  $m_{AP}$  在迭代至 200 轮时开始收敛,且增速差距不大并且由于训练最终  $m_{AP50}$  较高,难以继续提升,具体体现为在 0.97 附近震荡。

由图 4(b) 可知,各模型  $m_{AP50-95}$  增速差异明显。其中,修改激活函数的 SELU 模型的  $m_{AP}$  前期增速最快,收敛最早,但稳定后的  $m_{AP}$  终值不高,说明改用 SELU 激活函数可以帮助模型前期快速收敛,在短时间内达到较好的训练效果。添加了 3 种注意力机制的 YOLO v8l 模型训练初期  $m_{AP}$  提升速度与原始

YOLO v8l 模型相近,但在 150 轮后超过原始模型,说明引入新的注意力机制可能需要对模型的超参数进行调整,因此训练效果提升不明显;在 YOLO v8l 及添加注意力机制的改进模型中,第 450 轮附近原始模型最先趋于稳定,添加 MPCA 和 SegNext 注意力机制的模型在 500 轮左右趋于稳定,稳定后  $m_{AP}$  高于原始模型,添加 Bi-Level Routing Attention 注意力机制的模型在第 600 轮后趋于稳定,且稳定后  $m_{AP}$  终值最高,证明其训练效果最好,说明添加注意力机制的算法需要更多训练轮次才能收敛到最佳状态。

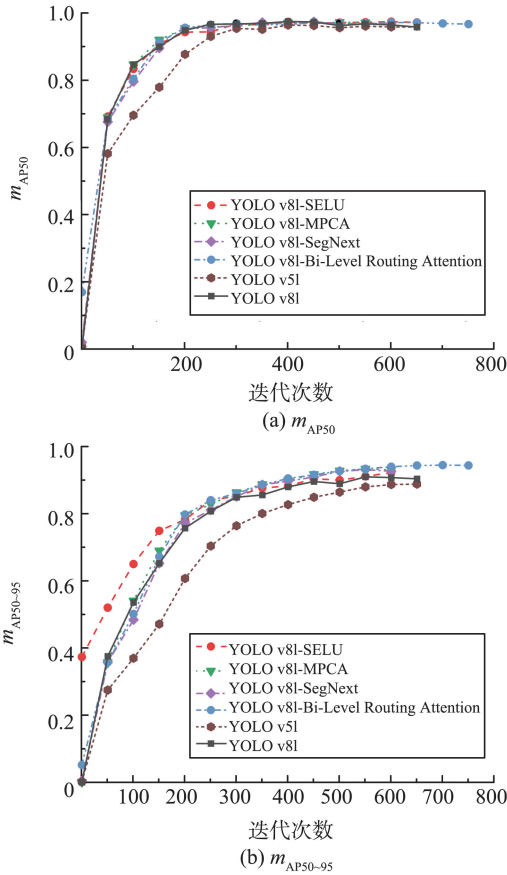


图4 各种模型的  $m_{AP50}$  与  $m_{AP50-95}$  对比  
Fig.4 Comparison of  $m_{AP50}$  and  $m_{AP50-95}$  from various models

在骨干网络后添加 Bi-Level Routing Attention 注意力机制,并对比添加 Bi-Level Routing Attention 注意力机制的模型与原始模型的训练结果,如表 3 所示。

表3 不同模型预测结果对比  
Table 3 Comparison of prediction results between different models

模型	精确率/%	召回率/%	$m_{AP50}$	$m_{AP50-95}$
YOLO v8l	98.5	91.5	0.972	0.923
YOLO v8l-Bi-Level Routing Attention	99.4	92.3	0.974	0.946

由表 3 可知,训练效果精确率达到 99.4%,召回率达到 92.3%, $m_{AP50}$  达到 0.974,  $m_{AP50-95}$  达到 0.946。分析数据可知,在骨干网络中添加 Bi-Level Routing Attention 注意力机制时, $m_{AP50}$  与原模型相差不大, $m_{AP50-95}$  更高,说明添加注意力机制有助于提升模型的训练效果,验证集的 2 种损失均比原始模型更低,证明其与雷达图像的契合度更高。Bi-Level Routing Attention 是一种双层路由注意力机制,能够在不同层次上对输入数据进行精细化的建模与学习,更适合雷达裂缝图像识别。采用 Bi-Level Routing Attention 改进后的训练效果如图 5 所示,对比 YOLO v8l 原模型,有效消除了训练后期的过拟合现象。

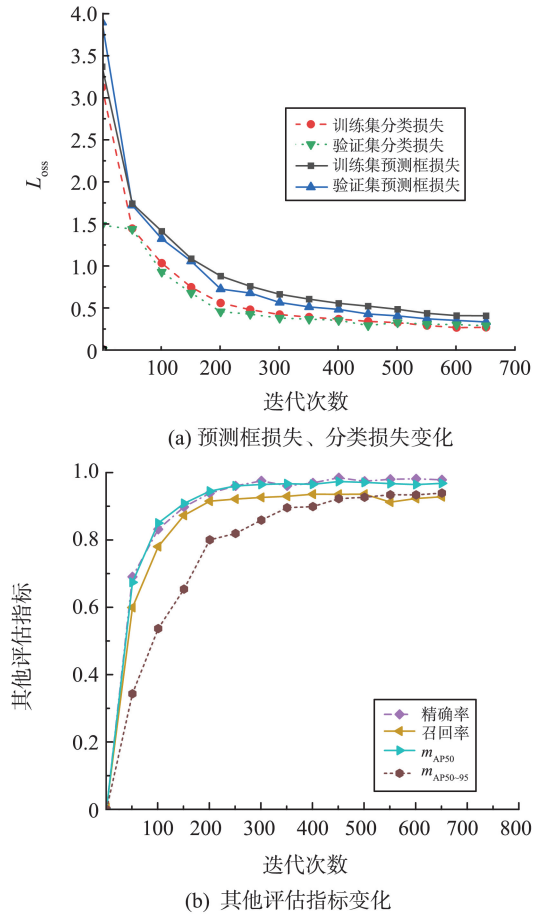




图5 采用 Bi-Level Routing Attention 改进模型的训练效果  
Fig.5 Training results of the model enhanced with Bi-Level Routing Attention

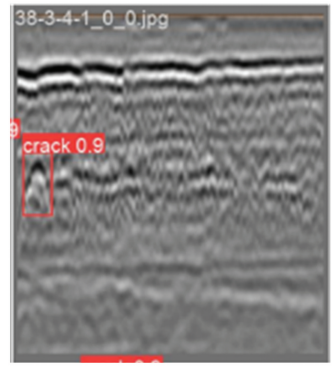
通过 2 种模型预测的裂缝标注图像如图 6 所示。图 6 中识别框上方显示了病害的类别,其后数字为预测的置信度,对比数据集与预测结果可知 YOLO v8l 模型对于裂缝的预测置信度均达到 0.9 以上,而经过 Bi-Level Routing Attention 改进的模型对比原模型多个检测框的置信度都有所提升,具有较强的实用价值。



(a) YOLO v8l模型预测结果a



(b) YOLO v8l模型预测结果b



(c) YOLO v8l模型预测结果c


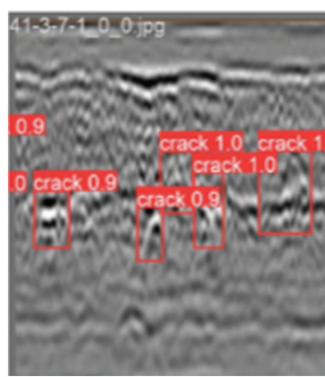
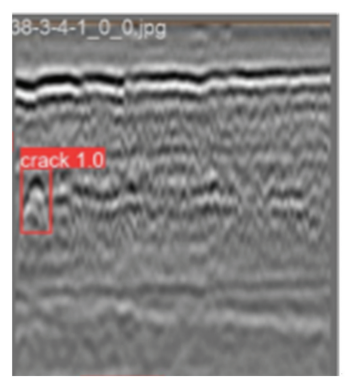
(d) YOLO v8l-Bi-Level Routing Attention  
模型预测结果a(e) YOLO v8l-Bi-Level Routing Attention  
模型预测结果b(f) YOLO v8l-Bi-Level Routing Attention  
模型预测结果c

图6 数据集标注情况及预测效果对比

Fig.6 Comparison of dataset annotation and prediction results

## 4 结论

本研究通过钻芯取样与观察铣刨相结合的方式建立了准确可靠的数据集及对应的标注原则。通过 YOLO v8l 模型训练数据集,可以实现低等级公路的裂缝预测,伴随产生一些过拟合现象。通过引入 MPCA、SegNext attention、Bi-Level Routing Attention 三种注意力机制并分析其训练效果,得出 Bi-Level Routing Attention 注意力机制与雷达图像最为适配,训练精度在 YOLO v8l 的基础上得到了较大提高,精确率提高至 99.4%,召回率提高至 92.3%, $m_{AP50}$  提高至 0.974, $m_{AP50-95}$  提高至 0.946,并消除了原本训练中出现的过拟合现象,满足路面裂缝智能判识的要求,证明了该方法的可行性和可靠性。

### 参考文献:

- [1] 黄哲骁,陶毅荣.基于三维探地雷达的襄荆高速公路路面病害现状分析[J].交通节能与环保,2024,20(2):151-156.  
HUANG Zhexiao, TAO Yirong. Analysis of pavement disease status of Xiangjing expressway based on three-

dimensional ground-penetrating radar [J]. Transport Energy Conservation & Environmental Protection, 2024, 20(2): 151-156.

- [2] 周陈婴.隧道衬砌检测探地雷达图像分析与工程应用[J].山东大学学报(工学版),2018,48(4):61-68.  
ZHOU Chenying. Image analysis and engineering application of ground penetrating radar in tunnel lining detection [J]. Journal of Shandong University (Engineering Science), 2018, 48(4): 61-68.
- [3] 周轮,李术才,许振浩,等.隧道综合超前地质预报技术及其工程应用[J].山东大学学报(工学版),2017,47(2):55-62.  
ZHOU Lun, LI Shucai, XU Zhenhao, et al. Integrated advanced geological prediction technology of tunnel and its engineering application [J]. Journal of Shandong University (Engineering Science), 2017, 47(2): 55-62.
- [4] 高阳,张庆松,原小帅,等.地质雷达在岩溶隧道超前预报中的应用[J].山东大学学报(工学版),2009,39(4):82-86.  
GAO Yang, ZHANG Qingsong, YUAN Xiaoshuai, et al. Application of geological radar to geological forecast in Karst tunnel [J]. Journal of Shandong University (Engineering Science), 2009, 39(4): 82-86.
- [5] 罗诗光,任强,王成浩,等.基于深度学习的GPR时频

- 域联合电磁反演方法[J]. 电波科学学报, 2022, 37(4): 555-567.
- LUO Shiguang, REN Qiang, WANG Chenghao, et al. GPR time-frequency domain joint electromagnetic inversion method based on deep learning [J]. Chinese Journal of Radio Science, 2022, 37(4): 555-567.
- [6] 赵勇. 基于CNN的探地雷达数据反演与道路病害自动识别[D]. 长春: 吉林大学, 2022.
- ZHAO Yong. Research on inversion of ground penetrating radar data and automatic detection of road diseases based on CNN [D]. Changchun: Jilin University, 2022.
- [7] 郑金杏. 探地雷达层状介质参数反演算法研究[D]. 桂林: 桂林电子科技大学, 2023.
- ZHENG Jinxing. Research on the inversion algorithm for layered medium parameters in ground penetrating radar [D]. Guilin: Guilin University of Electronic Technology, 2023.
- [8] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers [C]// European Conference on Computer Vision. Cham, Switzerland: Springer International Publishing, 2020: 213-229.
- [9] QIN Z Y, LU X K, NIE X S, et al. Exposing the self-supervised space-time correspondence learning via graph kernels [C]// Proceedings of the AAAI Conference on Artificial Intelligence. Washington, D. C., USA: AAAI Press, 2023: 2110-2118.
- [10] ZHANG X M, ZHAO P, JI J S, et al. Video corpus moment retrieval via deformable multigranularity feature fusion and adversarial training [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2024, 34(8): 6686-6698.
- [11] DINH K, GUCUNSKI N, DUONG T H. An algorithm for automatic localization and detection of rebars from GPR data of concrete bridge decks [J]. Automation in Construction, 2018, 89: 292-298.
- [12] OZKAYA U, MELGANI F, BELETE BEJIGA M, et al. GPR B-scan image analysis with deep learning methods [J]. Measurement, 2020, 165: 107770.
- [13] MEŞECAN İ, BETİM Ç, İ HSAN Ö B. Feature vector for underground object detection using B-scan images from GprMax [J]. Microprocessors and Microsystems, 2020, 76: 103116.
- [14] 薛丽君. 基于探地雷达 B-scan 图像双曲线特征的目标检测与定位研究 [D]. 哈尔滨: 哈尔滨工业大学, 2021.
- XUE Lijun. Research on target detection and location based on hyperbolic-shaped signatures in GPR B-Scan image [D]. Harbin: Harbin Institute of Technology, 2021.
- [15] 童峥. 基于深度学习和探地雷达技术的路面结构病害检测研究 [D]. 西安: 长安大学, 2018.
- TONG Zheng. Research on pavement distress inspection based on deep learning and ground penetrating radar [D]. Xi'an: Changan University, 2018.
- [16] 胡浩帮, 方宏远, 王复明, 等. 基于 Faster R-CNN 算法的探地雷达管线目标智能识别 [J]. 城市勘测, 2020(3): 203-208.
- HU Haobang, FANG Hongyuan, WANG Fuming, et al. Intelligent recognition of pipeline target based on Faster R-CNN algorithm for ground penetrating radar [J]. Urban Geotechnical Investigation & Surveying, 2020(3): 203-208.
- [17] 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). Las Vegas, USA: IEEE, 2016: 779-788.
- [18] 覃紫馨, 姜彦南, 徐立, 等. 基于 YOLO 算法的探地雷达道路图像异常自动检测 [J]. 科学技术与工程, 2023, 23(27): 11505-11512.
- QIN Zixin, JIANG Yannan, XU Li, et al. Automatic detection of anomalies in GPR images based on YOLO algorithm [J]. Science Technology and Engineering, 2023, 23(27): 11505-11512.
- [19] 杨洋, 赵广茂, 张志厚, 等. 铁路路基病害探地雷达智能识别方法 [J]. 地球物理学进展, 2024, 39(6): 2471-2482.
- YANG Yang, ZHAO Guangmao, ZHANG Zhihou, et al. Intelligent detection method for railway subgrade diseases based on ground-penetrating radar [J]. Progress in Geophysics, 2024, 39(6): 2471-2482.
- [20] 赵镇, 黄勇, 冯昆. 三维探地雷达在道路检测中的研究与应用 [J]. 测绘通报, 2024(2): 148-152.
- ZHAO Zhen, HUANG Yong, FENG Kun. Research and application of 3D ground penetrating in road detection [J]. Bulletin of Surveying and Mapping, 2024(2): 148-152.
- [21] 范剑伟. 基于无损检测技术的沥青路面裂缝及结构状态检测评价方法研究 [D]. 南京: 东南大学, 2022.
- FAN Jianwei. Research on detection and evaluation method of asphalt pavement cracks and structural state based on nondestructive testing technology [D]. Nanjing: Southeast University, 2022.
- [22] BARKATAKI N, TIRU B, SARMA U. A CNN model for predicting size of buried objects from GPR B-Scans [J]. Journal of Applied Geophysics, 2022, 200: 104620.
- [23] 周黎明, 张杨, 付代光, 等. 道路地下空洞探地雷达波场和时频特性 [J]. 同济大学学报(自然科学版), 2024, 52(1): 77-85.