文章编号：1005-0523(2025)03-0117-10

基于改进YOLOv8n的轻量化路面裂缝检测算法

杨 烨[1,2]，徐 霈[2]，徐 峰[2]

（1. 同济大学道路与交通工程教育部重点实验室，上海 201804；2. 招商局集团重庆交通科研设计院有限公司，重庆 400067）

摘要：针对现有路面裂缝检测模型在识别精度和推理速度方面的不足，提出一种改进的网络模型YOLOv8-Crack。该模型在YOLOv8n的基础上进行了多项改进：引入NWD损失函数，降低对目标框长宽比的依赖，从而提升对不规则形状裂缝的检测能力；采用Slimneck轻量化结构，显著降低模型参数量和计算复杂度，加快推理速度；嵌入CA模块，增强关键特征信息的提取能力。在RDD2022开源数据集上的实验结果表明，与YOLOv8n相比，YOLOv8-Crack模型的精确率，召回率，平均精度分别提高了1.8%，3.7%，2.6%；参数量和计算量分别降低了6.7%和11.0%。

关键词：YOLOv8n；路面裂缝；注意力机制；轻量化网络；损失函数

中图分类号：TP391.4；U416 **文献标志码：**A

本文引用格式：杨烨，徐霈，徐峰. 基于改进YOLOv8n的轻量化路面裂缝检测算法[J]. 华东交通大学学报，2025，42(3)：117-126.

Lightweight Road Crack Detection Algorithm Based on Improved YOLOv8n

Yang Ye[1,2], Xu Pei[2], Xu Feng[2]

(1. The Key Laboratory of Road and Traffic Engineering, Ministry of Education, Tongji University, Shanghai 201804, China;
2. China Merchants Chongqing Communications Technology Research & Design Institute Co., LTD., Chongqing 400067, China)

Abstract: To address the limitations in detection accuracy and inference speed in current road crack detection models, this paper proposes a novel YOLOv8-Crack network model. Based on YOLOv8n, this model incorporates multiple key structural optimizations, including the introduction of the NWD loss function to reduce dependency on aspect ratios of bounding boxes, thus improving detection capability for irregularly shaped cracks. The Slimneck lightweight structure is used to significantly reduce the number of parameters and computational complexity of the model, and accelerate the inference speed. The model also integrates a CA module to enhance the capture of critical feature information. Experimental results on the open-source dataset RDD2022 demonstrate that the YOLOv8-Crack model achieves improvements over the original YOLOv8n, with precision, recall, and mean average precision increased by 1.8%, 3.7%, and 2.6%; respectively, while parameters and computation are reduced by 6.7% and 11.0%.

Key words: YOLOv8n; pavement cracks; attention mechanism; lightweight network; loss function

收稿日期：2024-12-05

基金项目：国家重点研发计划项目(2022YFC3002603)；中国科协青年人才托举工程(2023QNRC001)

Citation format: YANG Y, XU P, XU F. Lightweight road crack detection algorithm based on improved YOLOv8n[J]. Journal of East China Jiaotong University, 2025, 42(3): 117−126.

路面裂缝和坑槽等道路病害直接影响交通安全和道路的使用寿命。传统的道路病害检测方法通常采用Haar[1]、SIFT[2]、LBP[3]等算法进行图像特征的人工提取，再利用SVM[4]和Adaboost[5]等分类器用于对提取的特征进行分类。尽管这些方法在某些场景下可以完成检测任务，但由于步骤复杂、计算开销大，且泛化能力和鲁棒性较差，难以适应复杂的道路场景，无法满足实际检测中对实时性和准确性的要求。

随着深度学习技术的迅猛发展，卷积神经网络（CNN）等深度学习模型在目标检测任务中取得了显著突破和进展。当前基于深度学习的目标检测算法分为以R-CNN、Fast R-CNN等为代表的二阶算法和以SSD、YOLO为代表的一阶算法。在检测任务中，二阶算法提前生成候选框，随后利用卷积神经网络对候选框内的物体特征进行分类，一阶算法则是在一个阶段内直接预测边界框和目标类别，由于算法特性的不同，一阶算法的检测速度优于二阶算法，更适用于实时检测任务。一阶算法中的YOLO[6]系列算法将目标检测问题精简为端到端的回归问题，进一步提高检测精度和推理速度，已成为路面病害检测的主要方法。安学刚等[7]通过对YOLOv4进行损失函数优化和嵌入动态空间特征融合模型，有效提高了路面裂缝识别的鲁棒性；周双喜等[8]在YOLOv5算法中引入CBAM注意力机制，有效增强了路面裂缝的检测精度；倪昌双等[9]结合聚类算法和F-ReLu激活函数改进YOLOv7算法，有效解决了卷积网络在沥青路面裂缝检测中的漏检和误检问题；张利丰等[10]将改进后的BiFPN引入YOLOv8网络，增强了特征融合能力，解决了传统检测模型在检测精度低、重叠目标漏检率高等方面的挑战。

上述研究通过对实时分割网络算法（you only look once，YOLO）进行改进，进而提高路面病害检测的精度，然而改进模块的加入会造成模型的参数量增加，进而影响检测速度。因此，许多学者针对模型轻量化方面进行了研究，如Yu等[11]专注于道路裂缝检测提出了一种改进的YOLOv5算法，通过引入轻量化模块，减少了模型参数量，提升了模型整体检测速率；杜娟等[12]将CoordConv与P-ELAN结构引入YOLOv7网络，以实现轻量化设计并增强位置信息感知，从而提升了复杂道路场景下的目标定位速度。通过采用轻量化模块可以提升模型的检测速度，但其会使特征信息弥散，使卷积神经网络无法聚焦关键信息，导致检测精度下降。

综上所述，尽管许多学者对YOLO算法进行多次优化，但在针对特定路面裂缝和坑槽的多目标检测任务中，其性能仍有提升的空间，尤其在平衡算法的检测精度及推理速度方面仍要进一步研究。

本研究基于注意力机制的轻量化路面病害检测算法，在充分利用YOLOv8n算法的基础上，融合各个改进策略，有效提升路面裂缝病害检测的精度和推理速度。

1 YOLOv8-Crack

1.1 改进算法整体结构

尽管YOLOv8n模型在常规目标检测任务中表现出色，但在道路场景中遇到尺度变化显著、背景复杂等挑战时，其性能有所限制。道路场景中的目标包括形状不规则的裂缝和坑槽，易受光照变化和背景干扰[13]，导致漏检和误检的可能性较高。为此，本文在YOLOv8n基础上进行了针对性改进，以提升模型在道路病害检测方面的适应性和准确性。首先，采用标准化检测距离（normalized width distance，NWD）损失函数替代传统的完全交并比（complete intersection over union，CIoU）损失函数，减少对目标框长宽比的依赖，从而提高不规则裂缝和坑槽的检测精度；其次，引入Slimneck轻量化结构，替换YOLOv8n的颈部网络，显著减少参数量和计算复杂度，在加速推理的同时保持高效特征提取能力。此外，网络中嵌入了注意力机制（coordinate attention，CA）模块，加强模型对裂缝和坑槽等病害区域的关键信息捕捉能力，增强了复杂背景下的抗干扰能力和多目标检测的可靠性。CA模块通过引入坐标信息，帮助模型更准确地聚焦重要区域，提

升特征表达效果。改进后的YOLOv8-Crack整体结构显著增强了多尺度特征融合和边界框回归精度，实现了检测精度提升与计算开销降低的平衡，为道路裂缝和坑槽检测提供了更高效、精准的解决方案。改进后的算法整体结构如图1所示，图中红色虚线框内为本文所采用的改进模块。

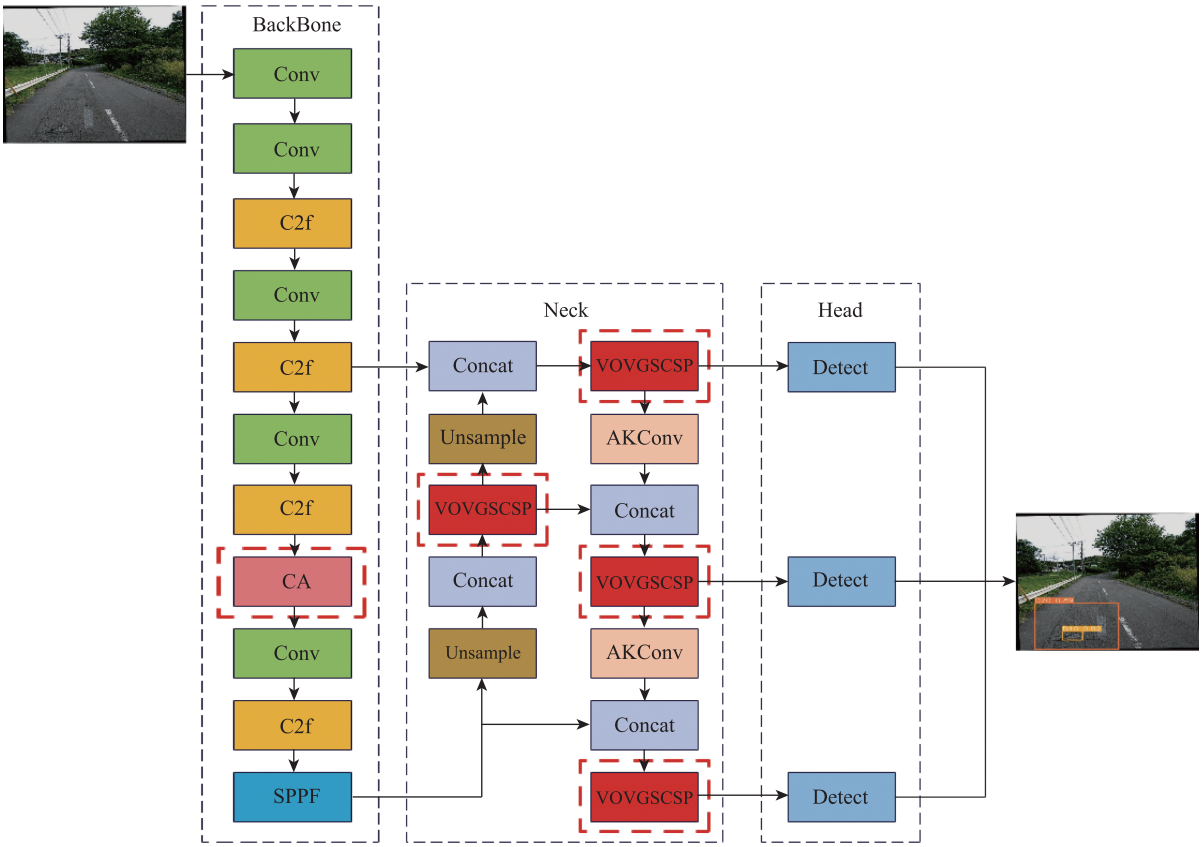


图1　YOLOv8-Crack结构图

Fig. 1　YOLOv8-Crack structure diagram

1.2　改进损失函数

YOLOv8n使用CIoU损失函数，通过重叠、中心距和长宽比提升定位精度，但其对长宽比敏感，导致检测形态不规则的小目标（如裂缝、坑槽）时易定位不准，影响复杂背景下的检测鲁棒性。

如图2所示，绿色矩形代表真实框，红色矩形代表预测框。CIoU损失函数定义如下

$$L_{\mathrm{CIoU}}=1-S_{\mathrm{IoU}}+\frac{\rho^2\left(b_{\mathrm{g}},b_{\mathrm{p}}\right)}{l^2}+\alpha V \tag{1}$$

$$\alpha=\frac{V}{1-S_{\mathrm{IoU}}+V} \tag{2}$$

$$V=\frac{4}{\pi^2}\left(\arctan\frac{w_{\mathrm{g}}}{h_{\mathrm{g}}}-\arctan\frac{w_{\mathrm{p}}}{h_{\mathrm{p}}}\right)^2 \tag{3}$$

式中：L_{CIoU}为CIoU损失函数；b_{g}，b_{p}分别表示真实框和预测框的中心点；l为包围真实框和预测框的最小闭包框的对角线长度；ρ为两框中心点之间的欧氏距离；w_{g}和h_{g}分别为真实框的宽度和高度；w_{p}和h_{p}分别为预测框的宽度和高度；S_{IoU}为预测框与真实框的重叠面积比。

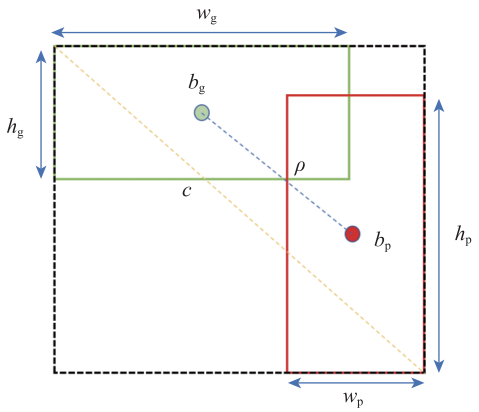


图2　CIoU

Fig. 2　CIoU

为提高路面裂缝和坑槽检测的精度，本文引入NWD损失函数，NWD损失函数通过精确度量目标框与预测框的中心位置偏差，显著提升了裂缝和坑槽等小目标的定位精度，同时减少了对目标框长宽比的依赖，克服了CIoU在不规则形状检测中的不足[14]。此外，NWD引入归一化系数，自适应调整不同尺度目标的损失值，提升了多尺度目标检测中的一致性和鲁棒性。

如图3所示，绿色矩形代表真实框，红色矩形代表预测框。

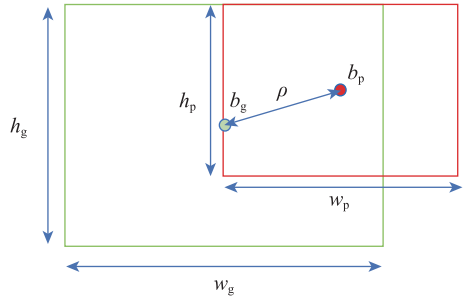


图3 NWD
Fig. 3 NWD

本文利用最优输运理论中的Wasserstein距离来衡量两个分布之间的差异。对于两个二维高斯分布，其二阶Wasserstein距离定义如下

$$W_2^2(\mu_1,\mu_2)=\|m_1-m_2\|_2^2+\left\|\sum_1^{1/2}-\sum_2^{1/2}\right\|_F^2 \tag{4}$$

式中：$\|\cdot\|_F$ 为Frobenius范数；m_1，m_2 分别为分布 μ_1，μ_2 的均值；$\sum_1$，$\sum_2$ 分别为分布 μ_1，μ_2 的协方差。

将边界框 $A=(b_{gx},b_{gy},h_g,w_g)$ 和边界框 $B=(b_{px},b_{py},h_p,w_p)$ 分别构建为高斯分布 N_a 和 N_b。其中：b_{ga}，b_{ga}，h_g，w_g 分别为边界框 A 的中心点横坐标，纵坐标，宽度，高度；b_{pb}，b_{pb}，h_p，w_p 分别为边界框 B 的中心点横坐标，纵坐标，宽度，高度；边界框 A 为真实框，a 为边界框 A，g为真实框；边界框 B 为预测框，b 为边界框 B，p为预测框；x，y 分别为中心点横坐标，纵坐标。式(4)可简化为

$$W_2^2(N_a,N_b)=\left\|\begin{bmatrix}b_{gx}\\b_{gy}\\\frac{h_g}{2}\\\frac{w_g}{2}\end{bmatrix}-\begin{bmatrix}b_{px}\\b_{py}\\\frac{h_p}{2}\\\frac{w_p}{2}\end{bmatrix}\right\|_2^2 \tag{5}$$

由于该距离无法直接作为相似度度量，因此需要将其进行指数形式的归一化处理，定义NWD函数为

$$\mathrm{NWD}(N_a,N_b)=\exp\left(-\frac{\sqrt{W_2^2(N_a,N_b)}}{l}\right) \tag{6}$$

基于NWD度量设计的NWD损失函数 L_{NWD} 为

$$L_{\mathrm{NWD}}=1-\mathrm{NWD}(N_g,N_p) \tag{7}$$

式中：N_g 为预测框的高斯分布模型；N_p 为真实框的高斯分布模型。

NWD损失函数通过精准计算预测框与真实框之间的距离，提高了模型在复杂场景中对小目标的检测能力，尤其是在处理道路裂缝和多变目标时，展现出了更加优越的性能。

1.3 引入CA模块

本文在YOLOv8n网络结构中引入CA模块[15]。该模块通过将经卷积操作的特征图在横向和纵向2个维度上对各通道采取编码操作，有效地构建空间上的远端互联关系，缓解由于拍摄角度、光线和复杂背景等因素导致的误检、漏检问题，在保证模型轻量化的同时提升路面裂缝识别模型的鲁棒性。CA的结构如图4所示，其中：X 和 Y 分别为进行纵向和横向的最大池化。

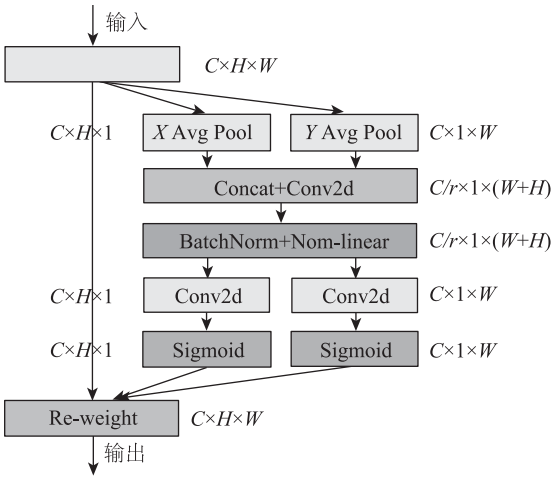


图4 CA模块结构图
Fig. 4 CA module structure diagram

CA模块计算过程如下：输入特征图，其维度为 $C\times H\times W$，被分别沿着横向和纵向两个方向进行平均池化操作，并从两个不同的空间维度上提取每个通道的特征信息，横向和纵向方向上的平均池化操作分别产生2个输出，定义如下

$$z_c^h(h)=\frac{1}{W}\sum_{0\leqslant i\leqslant W}t_c(h,i) \tag{8}$$

$$z_c^w(w)=\frac{1}{H}\sum_{0\leqslant j\leqslant H}t_c(j,w) \tag{9}$$

式中：C为特征图的通道数量；H为特征图的高度；W为特征图的宽度；$z_c^h(h)$表示在第c通道上，高度为h的位置处沿横向所提取的局部特征的集合，其中包含该通道、该高度位置上所有纵向局部特征信息；$z_c^w(w)$表示在第c通道上，宽度为w的位置处沿纵向所提取的局部特征的集合，该集合则包含该通道、该宽度位置上所有纵向方向的局部特征信息；$t_c(h,i)$表示横向第c通道上高度为h，宽度为i的特征，$0\leqslant i<W$；$t_c(j,w)$表示垂直方向第c通道上高度为j，宽度为w的特征，$0\leqslant j<H$。

在经过特征集合的处理流程之后，该模块会执行一个关键步骤，即将来自两个不同空间方向上的特征信息进行自适应拼接。这一步骤旨在融合来自不同维度的空间特征，从而增强模型对于空间结构的理解能力。随后，利用卷积变换对这些拼接后的特征进行处理。这个函数通过采用非线性映射，能够提取出包含丰富空间信息的中间特征图f，表达式为

$$f=\delta\left(F_1\left(\left[z^h,z^w\right]\right)\right) \tag{10}$$

式中：f为一个特征图，其维度为$\frac{C}{r}\times H\times W$；$r$为下采样比例，用于调整模块的大小以适应不同的网络结构和需求；δ为非线性激活函数，使得网络能够学习和模拟特征中的非线性关系；F_1为1*1卷积变换函数，共同作用于f上，实现对特征图的变换和处理。

将f沿着空间维度分割为$C\times 1\times W$和$C\times H\times 1$的特征图。通过另外两个1*1的卷积层分别处理分裂后的特征图。对两个卷积后的特征图应用Sigmoid激活函数，生成两个注意力图，这两个图将分别在宽度和高度上对输入特征图进行重标定。将通过Sigmoid激活的注意力图乘以原始的$C\times H\times W$输入特征图，由此得到特征强化后的输出特征图。

1.4　轻量化颈部网络

Slimneck是一种为实现检测器更高的成本效益而提出的设计范式[16]。Slimneck采用了一阶段聚合策略来构建其跨级局部网络模块，即VoV-GSCSP，其结构示意图参见图5。其中c_1和c_2分别为该模块输入和输出的通道数量。该过程用以实现对特征图的变换和特征提取。该模块能够减少运算开销，降低网络结构复杂度，并保持足够的精度。因此本文通过将VoV-GSCSP代替颈部网络中的C2f层，将Slimneck模块集成到YOLOv8n颈部网络，以增强YOLOv8n捕捉路面裂缝特征信息的能力。

2　实验环境及评价指标

2.1　实验环境及数据集

本文实验在Windows 11操作系统下，使用Python 3.11进行模型训练。本文用于模型训练的数据集是开源的RDD2022数据集。RDD2022数据集由东京大学发布，包含多个国家的道路图像[17]。图像一共有了55 000多个道路病害标记。本次采用的是数据集中典型的4种道路病害类型，分别为D00（纵向裂缝），D10（横向裂缝）D20（网状裂缝），D40（坑槽）。为保证道路病害数据集的初步类别平衡，根据4种标记类别分别随机抽取1 000张数据集（共4 000张）进行训练，并将其以比例8:2划分为训练集3 200张和测试集800张。

2.2　网络模型的评价指标

本文采取的模型评价指标分别为平均精度、准

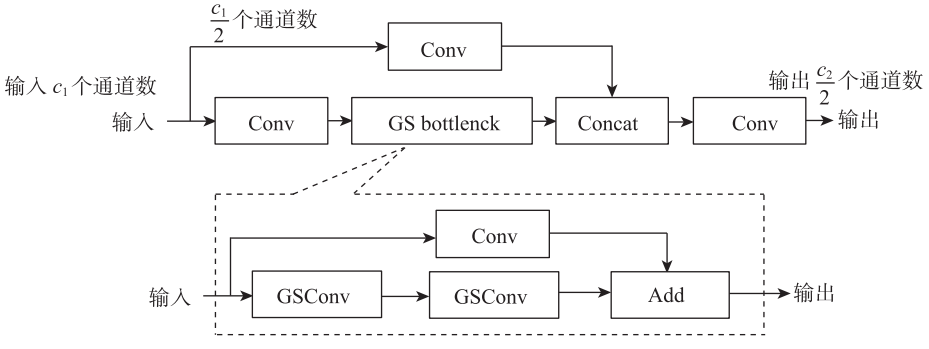


图5　VoV-GSCSP模块结构

Fig. 5　VoV-GSCSP module structure

确率、召回率，具体定义如下。

平均精度 R_{mAP} 为裂缝检测的平均精度，计算式为

$$R_{\mathrm{mAP}}=\frac{1}{I}\sum_{i=1}^{I}P_{a,i} \tag{11}$$

式中：I 为类别数量；$P_{a,i}$ 为第 i 个类别的平均精度。

准确率 $P_{\mathrm{precision}}$ 为检测出的正样本数占所有检测出的样本数的比例，计算式为

$$P_{\mathrm{precision}}=\frac{T_{\mathrm{p}}}{T_{\mathrm{p}}+F_{\mathrm{p}}} \tag{12}$$

式中：T_{p} 为样本集合中被正确地归类为正例的原本就为正例的实例数量；F_{p} 为那些原本为负例却被错误地划分为正例的实例数量。

召回率 R_{recall} 检测出的正样本数占所有实际正样本数的比例，计算式为

$$R_{\mathrm{recall}}=\frac{T_{\mathrm{p}}}{T_{\mathrm{p}}+F_{\mathrm{n}}} \tag{13}$$

式中：F_{n} 为样本中原是正例但被错误划分为负例的数量。

3 实验结果与可视化分析

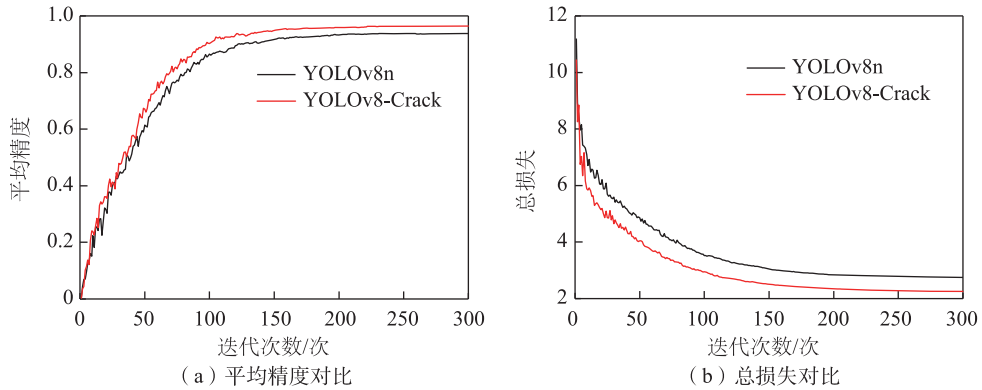
3.1 模型训练分析

YOLOv8-Crack是在YOLOv8n基础上进行改进的，首先对损失函数进行了调整，将CIoU损失函数替换为NWD损失函数，以有效捕捉目标框的分布特征及其边界关系。接着，在主干网络的中间层引入CA，以增强模型对细节和局部特征的关注能力。最后，采用Slimneck结构对颈部网络层进行轻量化处理，从而显著减少模型的参数量和计算复杂度，提升整体模型的推理效率。此改进方案旨在提高目标检测任务中的精度与效率，使得模型在复杂场景下表现更加优越。

为了深入分析改进模块对网络性能和收敛速度的影响，本文比较了改进前后网络的平均精度和总损失（类别损失、置信度损失和空间损失的总和）的变化，如图6所示。改进后的网络在经过200轮训练后逐渐开始收敛，平均精度达到了最高值。此外，改进后的网络在整个训练过程中，其平均精度始终高于原始YOLOv8n网络，同时总损失也显著降低。改进模块有效提升了网络的检测性能和稳定性。

3.2 模型对比分析

为进一步验证YOLOv8-Crack对路面裂缝检测的先进性，本文选取典型目标检测网络与改进网络在RDD2022数据集上进行对比实验。实验结果如表1所示，从中可看出，相较于其他对比模型（SSD，Faster R-CNN，YOLOv3-tiny[18]，YOLOv5，YOLOv6[19]，YOLOv8n，YOLOv9s[20]，YOLOv10n），本文改进模型在评价指标方面，拥有更高性能；检测精度分别提高了5.1%，6.3%，4.1%，4.8%，17.7%，1.8%，4.5%，2.4%；召回率分别提升了2.1%，5.8%，5.6%，7.2%，19.4%，3.7%，3.7%，2.1%；平均精度分别提升了2.1%，5.0%，4.9%，4.5%，18.2%，2.6%，2.2%，0.7%；计算复杂度（GFLOPs）相比YOLOv8n减少0.9×10^{9}，仅比YOLOv10n高0.5×10^{9}；模型参数量（Parameters）相比YOLOv8n减少0.2×10^{6}个，仅比参数量最小的YOLOv10n高0.8×10^{6}个。各个对比模型的训练曲线如图7所示，可以看出YOLOv8-Crack网络在训练过程中保持着更高的二分类模型平衡分数以及



（a）平均精度对比　（b）总损失对比

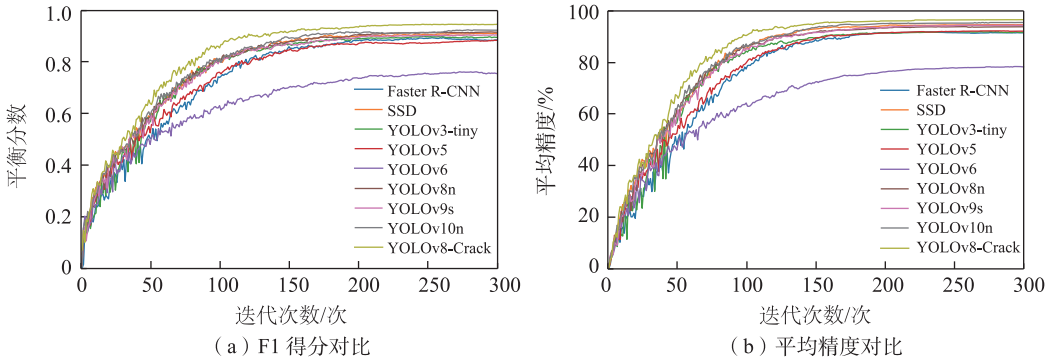
图6 训练曲线趋势

Fig. 6 Trend of training curve

表1　对比实验结果

Tab.1　Results of comparison experiments

模型	检测精度/%	召回率/%	平衡分数	平均精度/%	计算复杂度/($\times10^9$)	模型参数量/($\times10^6$)
SSD	91.6	89.9	90.7	94.3	62.7	23.8
Faster R-CNN	90.4	86.2	88.3	91.4	370.2	41.3
YOLOv3-tiny	92.6	86.4	89.4	91.5	18.9	12.1
YOLOv5	91.9	84.8	88.2	91.9	7.1	2.5
YOLOv6	79.0	72.6	75.7	78.2	11.8	4.2
YOLOv8n	94.9	88.3	91.5	93.8	8.2	3.0
YOLOv9s	92.2	88.3	90.2	94.2	27.6	7.3
YOLOv10n	94.3	89.9	92	95.7	6.5	2.3
YOLOv8-Crack	96.7	92.0	94.3	96.4	7.3	2.8



（a）F1 得分对比　　（b）平均精度对比

图7　对比实验中评价指标的变化

Fig. 7　Change in evaluation index in comparison experiments

平均精度。结合各项评价指标来看，YOLOv8-Crack相较于其他典型网络，其在检测精度及轻量化方面有一定先进性。

3.3　消融实验分析

为了验证YOLOv8-Crack检测网络模型相较于原始YOLOv8n网络的改进效果，并评估各个模块的贡献，本研究通过8组消融实验展示了所采用的3种改进方法的有效性。消融实验中，基准网络与加入各个改进模块后的网络性能对比结果如表2所示，其中●表示采用该策略，○表示不采用该策略。A模型为原始模型，A模型中引入CA注意力机制后（B模型），检测精度提升至95.5%，平均精度提升至94.3%，而召回率略微下降至88.1%，GFLOPs与参数量保持不变；将A模型的损失函数改进为NWD后（C模型），检测精度进一步提升至96.6%，召回率保持不变（88.3%），平均精度上升至94.8%；在A模型中引入Slimneck模块（D模型）则降低了计算复杂度，GFLOPs降至7.3×10^9，参数量减小至2.8×10^6个；当A模型同时采用CA与NWD两种改进策略（E模型）时，各项指标比使用单一改进策略时效果更佳；当A模型同时采用CA与Slimneck两种改进策略时（F模型），模型精度与计算复杂度得到了一定平衡；当A模型同时采用NWD与Slimneck两种改进策略（G模型）时，各项指标比使用单一改进策略时效果更佳。最终，3个模块同时引入时（模型），模型的检测精度达到96.7%，召回率为92.0%，平均精度为96.4%，GFLOPs和参数量分别为7.3×10^9和2.8×10^6个，达到最优性能和效率的平衡。综上所述，原始模型中引入CA注意力机制以及将损失函数改为NWD均可一定程度上提升模型的精度，而Slimneck的加入使模型在保持高精度的同时兼顾轻量化。

3.4　检测结果可视化分析

为了验证YOLOv8-Crack的实际检测性能，对优化后的模型和原始模型（YOLOv8n）都使用相同的数据集进行可视化分析，检测结果如图8所示，从中可以看出YOLOv8-Crack在裂缝检测的精度和覆盖范围上都优于YOLOv8n。在鲁棒性方面，YO-

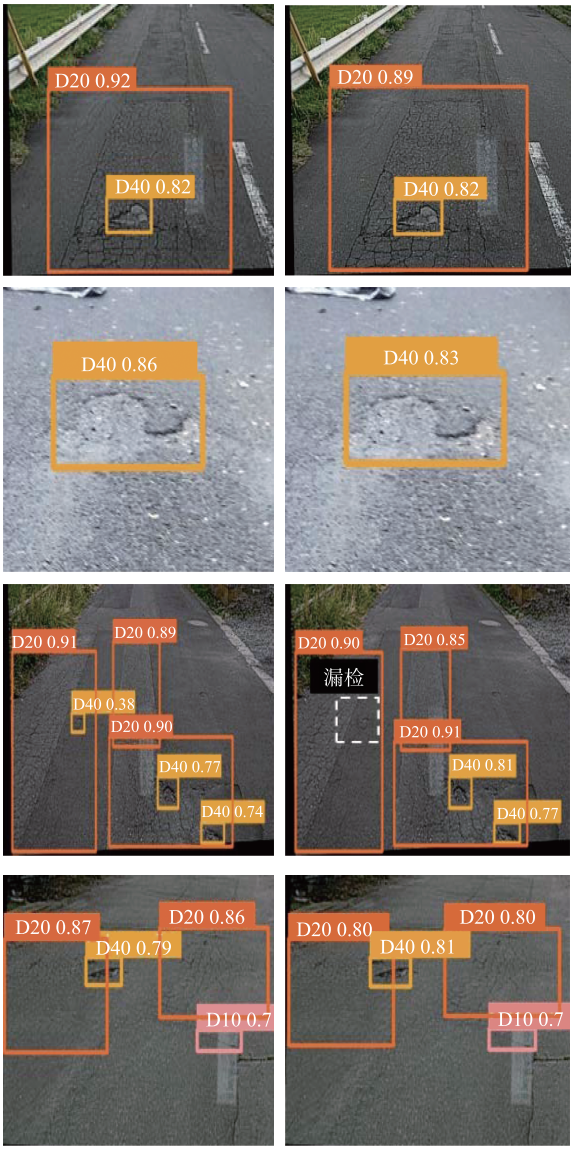
表2 消融实验结果

Tab.2 Results of ablation experiments

编号	CA	NWD	Slimneck	检测精度/%	召回率/%	平均精度/%	计算复杂度/(×10⁹)	模型参数量/(×10⁶个)
A	○	○	○	94.9	88.3	93.8	8.2	3.0
B	●	○	○	95.5	88.1	94.3	8.2	3.0
C	○	●	○	96.6	88.3	94.8	8.2	3.0
D	○	○	●	94.8	86.2	93.8	7.3	2.8
E	●	●	○	96.0	90.1	94.5	8.2	3.0
F	●	○	●	95.3	89.3	94.5	7.3	2.8
G	○	●	●	95.5	90.9	95.2	7.3	2.8
H	●	●	●	**96.7**	**92.0**	**96.4**	**7.3**	**2.8**

LOv8-Crack的置信度普遍较高，如在图8(a)中D20与D40类别中有0.92，0.86等较高的置信度。相比之下，YOLOv8n的置信度分数稍低，如图8(b)的0.89，0.83等，证明改进后的网络在鲁棒性方面优于YOLOv8n。在检测精度方面，YOLOv8-Crack也展示出更优效果，例如在图8(a)D20区域附近，YOLOv8-Crack不仅能检测到主要裂缝，还能识别周围一些较小的裂缝特征，而YOLOv8n发生了漏检现象，显示出在特征学习能力上的差距。此外，YOLOv8-Crack在检测框数量和分布上的表现也优于YOLOv8n，YOLOv8-Crack在裂缝区域生成了更多的检测框，并在各个检测框中保持了置信度递减的合理性。这种多层次的检测框分布，说明优化后的模型能够更细致地对裂缝进行分级处理，有效提升了裂缝检测的整体精度。此次实验结果表明，通过优化后的YOLOv8-Crack模型在实际应用中能够提供更可靠的检测结果。

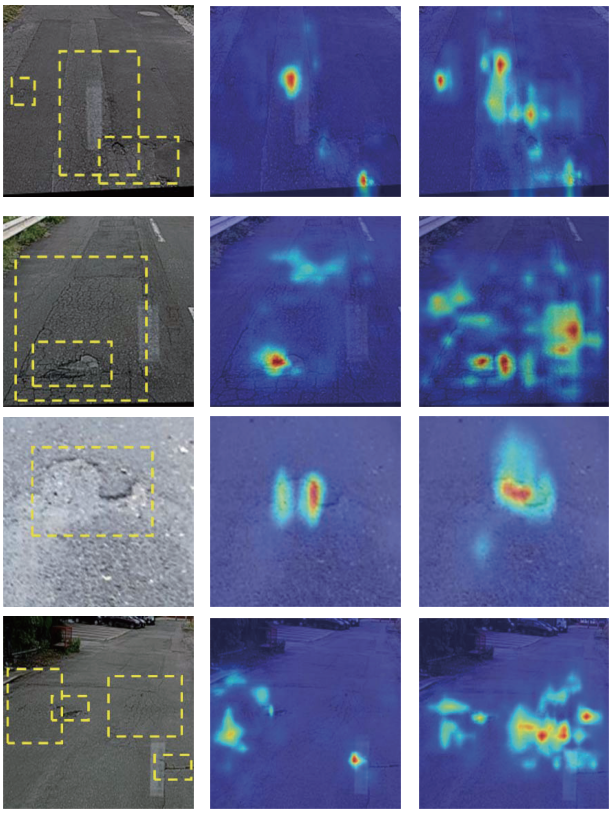
使用GradCAM[21]对改进前后的模型进行检测热力区域分析，可视化结果如图9所示。图片分为4行3列，每行表示不同的道路场景，第1列为原始图像及标注，其中用黄色虚线框标出了路面裂缝的位置，第2列为YOLOv8n的检测热力图，第3列为本文模型YOLOv8-Crack的检测热力图。可以看出，YOLOv8-Crack比YOLOv8n能够捕捉到更多的裂缝细节，覆盖范围更广，因此其适用在裂缝检测要求严格的场景中，能够识别出更多微小的裂缝或不易察觉的损坏区域。YOLOv8-Crack的热力图中，裂缝的热力响应更为集中和清晰。综上，可视化结果表明模型在裂缝位置的检测精度更高，缓解了误检和漏检的问题，有助于在实际应用中准确定位裂缝位置。



(a) YOLOv8-Crack 检测结果　(b) YOLOv8n 检测结果

图8 检测结果可视化对比

Fig. 8 Comparison of detection results visualization



（a）原图及标签　（b）YOLOv8n 热力图　（c）YOLOv8-Crack 热力图

图9　检测热力图可视化对比

Fig. 9　Comparison of detection heatmap visualization

4　结论

本文针对路面裂缝检测模型在识别精度和推理速度方面的不足，提出了一种兼顾推理速度与精度的YOLOv8-Crack网络模型。

1）与YOLOv8n相比，YOLOv8-Crack模型在精确率，召回率和平均精度上均有所提升。同时，模型的参数量和计算复杂度却有所减少。

2）与SSD，Faster R-CNN，YOLOv3-tiny，YOLOv5，YOLOv6，YOLOv8n，YOLOv9s，YOLOv10n相比，YOLOv8-Crack模型的平均精度均有所提升，参数量变小，精确率，召回率，平均精度却达到了较高水平。

3）原始YOLOv8n模型通过引入CA注意力机制，改用NWD损失函数，集成Slimneck模块，显著改善了模型性能。尤其当3个改进策略同时应用时，模型达到了精度与效率的最优平衡，验证了YOLOv8-Crack模型的显著改进效果。

4）可视化分析显示，相较于YOLOv8n，YOLOv8-Crack模型在裂缝检测中展现出更高的精度，热力区域响应集中且清晰，适用于裂缝检测要求严格的场景。

参考文献：

[1] VIOLA P, JONES M J. Robust real-time face detection[J]. International Journal of Computer Vision, 2004, 57(2): 137-154.

[2] LOWE D G. Distinctive image features from scale- invariant keypoints[J]. International Journal of Computer Vision, 2004, 60(2): 91-110.

[3] OJALA T, PIETIKAINEN M, MAENPAA T. Multiresolution gray- scale and rotation invariant texture classification with local binary patterns[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(7): 971-987.

[4] AKATA Z, PERRONNIN F, HARCHAOUI Z, et al. Good practice in large-scale learning for image classification[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(3): 507-520.

[5] 曹莹, 苗启广, 刘家辰, 等. AdaBoost算法研究进展与展望[J]. 自动化学报, 2013, 39(6): 745-758.
CAO Y, MIAO Q G, LIU J C, et al. Advance and prospects of AdaBoost algorithm[J]. Acta Automatica Sinica, 2013, 39(6): 745-758.

[6] LIN C J, JHANG J Y. Intelligent traffic-monitoring system based on YOLO and convolutional fuzzy neural networks[J]. IEEE Access, 2022, 10: 14120-14133.

[7] 安学刚, 党建武, 王阳萍, 等. 基于改进YOLOv4的无人机影像路面病害检测方法[J]. 无线电工程, 2023, 53(6): 1285-1294.
AN X G, DANG J W, WANG Y P, et al. UAV image pavement disease detection based on improved YOLOv4[J]. Radio Engineering, 2023, 53(6): 1285-1294.

[8] 周双喜, 杨丹, 潘远, 等. 基于注意力机制的YOLOv5路面裂缝检测与识别[J]. 华东交通大学学报, 2024, 41(2): 56-63.
ZHOU S X, YANG D, PAN Y, et al. Detection and recognition of YOLOv5 pavement cracks based on attention mechanism[J]. Journal of East China Jiaotong University, 2024, 41(2): 56-63.

[9] 倪昌双, 李林, 罗文婷, 等. 改进YOLOv7的沥青路面病害检测[J]. 计算机工程与应用, 2023, 59(13): 305-316.
NI C S, LI L, LUO W T, et al. Disease detection of asphalt pavement based on improved YOLOv7[J]. Comput-

er Engineering and Applications, 2023, 59(13): 305-316.

[10] 张利丰, 田莹. 改进YOLOv8的多尺度轻量型车辆目标检测算法[J]. 计算机工程与应用, 2024, 60(3): 129-137.
ZHANG L F, TIAN Y. Improved YOLOv8 multi-scale and lightweight vehicle object detection algorithm[J]. Computer Engineering and Applications, 2024, 60(3): 129-137.

[11] YU G, ZHOU X L. An improved YOLOv5 crack detection method combined with a bottleneck Transformer[J]. Mathematics, 2023, 11(10): 2377.

[12] 杜娟, 崔少华, 晋美娟, 等. 改进YOLOv7的复杂道路场景目标检测算法[J]. 计算机工程与应用, 2024, 60(1):96-103.
DU J, CUI S H, JIN M J, et al. Improved complex road scene object detection algorithm of YOLOv7[J]. Computer Engineering and Applications, 2024, 60(1): 96-103.

[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, 2021, 22(13): 1659-1672.

[14] XU C, WANG J W, YANG W, et al. Detecting tiny objects in aerial images:a normalized Wasserstein distance and a new benchmark[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2022, 190: 79-93.

[15] XU K , HAO Z , ZHU M , et al. An efficient lane detection network with channel-enhanced coordinate attention[J]. Machines, 2024, 12(12): 870.

[16] LI H, LI J, WEI H, et al. Slim-neck by GSConv:a lightweight-design for real-time detector architectures[J]. Journal of Real-Time Image Processing, 2024, 21(3): 62.

[17] ARYA D, MAEDA H, GHOSH S K, et al. RDD2020:an annotated image dataset for automatic road damage detection using deep learning[J]. Data in Brief, 2021, 36:107133.

[18] MUJAHID A, AWAN M J, YASIN A, et al. Real-time hand gesture recognition based on deep learning YOLOv3 model[J]. Applied Sciences, 2021, 11(9): 4164.

[19] GUPTA C, GILL N S, GULIA P, et al. A novel finetuned YOLOv6 transfer learning model for real-time object detection[J]. Journal of Real-Time Image Processing, 2023, 20(3): 42.

[20] 胡晓伟, 闫奕昕, 王大为, 等. 基于YOLOM算法的路面病害轻量化检测方法[J]. 中国公路学报, 2024, 37(12): 381-391.
HU X W, YAN Y X, WANG D W, et al. Lightweight pavement disease detection based on YOLOM algorithm[J]. China Journal of Highway and Transport, 2024, 37(12): 381-391.

[21] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM:visual explanations from deep networks via gradient-based localization[J]. International Journal of Computer Vision, 2020, 128(2): 336-359.



通信作者:杨烨(1983—),男,正高级工程师,博士,研究方向为道路与机场工程。E-mail:7428217@qq.com。

(责任编辑:姜红贵)