

基于RCGELAN-YOLOv11的路面损伤检测算法

殷 波

贵州交通职业大学/智能制造学院, 贵州 贵阳

收稿日期: 2025年11月5日; 录用日期: 2025年12月22日; 发布日期: 2025年12月31日

摘 要

本文针对路面损伤检测任务中传统方法效率低、易受环境干扰的痛点, 提出了一种基于RCGELAN-YOLOv11的改进算法。在YOLOv11算法的基础上改进网络结构, 通过设计RC-G-ELAN模块替代YOLOv11中的C3k2模块, 实现了检测精度与计算效率的双重优化。具体而言, RC-G-ELAN模块引入重参数化卷积RepConv增强特征提取能力, 采用Conv 3×3 模块替代C3k模块简化网络结构, 将串行结构改为并行结构减少冗余计算, 并在网络后端添加Conv 1×1 模块促进通道间信息交互。实验采用GRDDC2020数据集(含14,569张标注图像, 覆盖10类损伤类型), 以7:1:2比例划分训练集、验证集和测试集。实验结果表明, 改进后的算法与YOLOv11算法的检测精度相当, 但是改进算法的网络层数降低19.33%, 参数量减少15.84%, 梯度计算量降低22.81%, GFLOPs降低6.15%, 大幅地降低了计算复杂度, 为复杂场景下的路面损伤检测提供了高效可靠的技术支撑。

关键词

路面损伤检测, YOLOv11, 重参数卷积, 计算复杂度

Road Surface Damage Detection Algorithm Based on RCGELAN-YOLOv11

Bo Yin

School of Intelligent Manufacturing, Guizhou Communications Polytechnic University, Guiyang Guizhou

Received: November 5, 2025; accepted: December 22, 2025; published: December 31, 2025

Abstract

This paper addresses the pain points of low efficiency and environmental interference in traditional

road surface damage detection methods by proposing an improved algorithm based on RCGELAN-YOLOv11. Building upon the YOLOv11 framework, we optimize the network architecture by replacing the C3k2 module with the RC-G-ELAN module, achieving dual improvements in detection accuracy and computational efficiency. Specifically, the RC-G-ELAN module introduces RepConv (reparameterized convolution) to enhance feature extraction capabilities, adopts Conv 3×3 modules to simplify the network structure, converts serial architecture to parallel architecture to reduce redundant computations, and adds Conv 1×1 modules in the backend to facilitate channel interaction. Experiments were conducted using the GRDDC2020 dataset (containing 14,569 labeled images covering 10 damage types), with training, validation, and test sets divided in a 7:1:2 ratio. Results demonstrate that the improved algorithm achieves comparable detection accuracy to YOLOv11 while reducing network layers by 19.33%, parameter volume by 15.84%, gradient computation by 22.81%, and GFLOPs by 6.15%. This significant reduction in computational complexity provides efficient and reliable technical support for road surface damage detection in complex scenarios.

Keywords

Road Surface Damage Detection, YOLOv11, Heavy Parameter Convolution, Computational Complexity

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着智慧交通系统的快速发展，路面损伤检测作为保障道路安全与维护效率的关键环节，受到了广泛关注。传统的路面损伤检测方法主要依赖人工巡检，不仅效率低下，且难以保证检测的全面性和准确性。近年来，基于计算机视觉的目标检测技术为路面损伤检测提供了新的解决方案，通过自动识别和分析路面图像中的损伤特征，实现了高效、精准的检测[1]。

深度学习作为人工智能领域的一个热门研究方向，已经在图像识别、目标检测和分割等方面取得了显著进展，特别是在图像处理领域，深度学习技术能够自动从数据中学习特征和规律，表现出强大的特征提取和分类能力。深度学习技术的崛起为路面损伤检测提供了新的思路，特别是基于卷积神经网络(CNN)的目标检测算法，在路面损伤检测领域得到了广泛应用[2]。这些算法通过自动提取图像特征，能够实现对路面损伤目标的快速、准确检测，其中，YOLO (You Only Look Once)系列算法以其高准确性和高效率的特点，成为实时目标检测领域的佼佼者[3]。

文献[4]针对道路检测任务优化了 YOLOv5s 模型，通过引入 CBAM 注意力机制替代主干网络中的 C3 模块以强化关键信息提取能力，并采用 EIoU 损失函数替代传统 GIoU，在减少定位误差的同时加速模型收敛并提升回归精度。文献[5]则提出融合 Transformer 与 SimAM 的轻量化路面损伤检测方案，在显著降低模型计算量与参数规模的同时，实现了检测精度的提升。文献[6]聚焦中国乡镇及社区街道场景，基于 YOLOv3 算法开发了路面病害检测方法，可快速识别裂缝、坑洼等损伤类型，并构建了适配本土场景的增补数据集。文献[7]设计的 AUG-YOLOv8-D 轻量化检测算法通过多项创新优化：采用 Adown 模块替代 YOLOv8n 卷积模块，引入 UIB 模块优化 C2f 结构，在骨干网络末端集成多模态注意力机制，并构建 Ghost-Head 检测头配合通道级知识蒸馏提升性能。文献[8]基于无人机巡检场景，构建了 16,000 张增广数据集，通过三阶段优化策略改进 YOLOv8s-G 模型，在保持检测精度的同时提升推理效率，为轨道基础设施维护

提供高效技术方案。文献[9]提出了轻量化的道路损伤检测算法 DFS-YOLO，其包含三大创新点：C2f-DWR 模块增强高层语义信息利用，快速层次尺度特征金字塔 FHSFPN 优化特征融合效率，ShapeIoU 损失函数聚焦损伤形状尺度特性以提升模型鲁棒性。

YOLOv11 作为最新一代模型，通过融合创新架构与多项优化技术，在目标检测精度和速度上实现了平衡突破，成为路面损伤检测的理想选择[10]。然而，针对路面损伤检测任务的特殊性，如损伤类型多样、尺度变化大、背景复杂等，对检测算法的特征提取能力和计算效率提出了更高要求。为此，本文在 YOLOv11 的基础上，设计了一种新型的 RC-G-ELAN 模块，旨在通过优化网络结构，进一步提升特征提取效率并降低计算复杂度，从而满足路面损伤检测的实际需求。本文首先介绍了 YOLOv11 的网络结构和优势，随后详细阐述了 RC-G-ELAN 模块的设计思路和创新点，最后通过仿真实验验证了所提算法的性能。

2. 本文总体方案

2.1. YOLOv11 网络结构

YOLOv11 是由位于美国和西班牙的 Ultralytics 团队开发并推出的最新一代 YOLO 算法模型，于 2024 年 9 月 30 日正式发布，该模型通过融合创新架构与多项优化技术，在目标检测领域实现了精度与速度的平衡突破。YOLOv11 的网络结构如图 1 所示，在核心架构层面，YOLOv11 采用模块化设计，包含三大核心组件：主干网络(Backbone)以 C3K2 模块为基础，通过分割特征图并结合 Bottleneck Block、SPPF(空间金字塔池化)和 C2PSA(部分空间注意力)模块，显著提升特征提取效率；颈部网络(Neck)专注于多尺度特征融合，增强模型对复杂场景的解析能力；头部网络(Head)则负责生成最终预测结果，支持多任务处理。此外，模型还集成 Transformer 块以捕捉全局上下文信息，采用 Mosaic 数据增强技术提升泛化性能，并引入动态锚点与置信度阈值机制，使检测过程更加灵活精准。

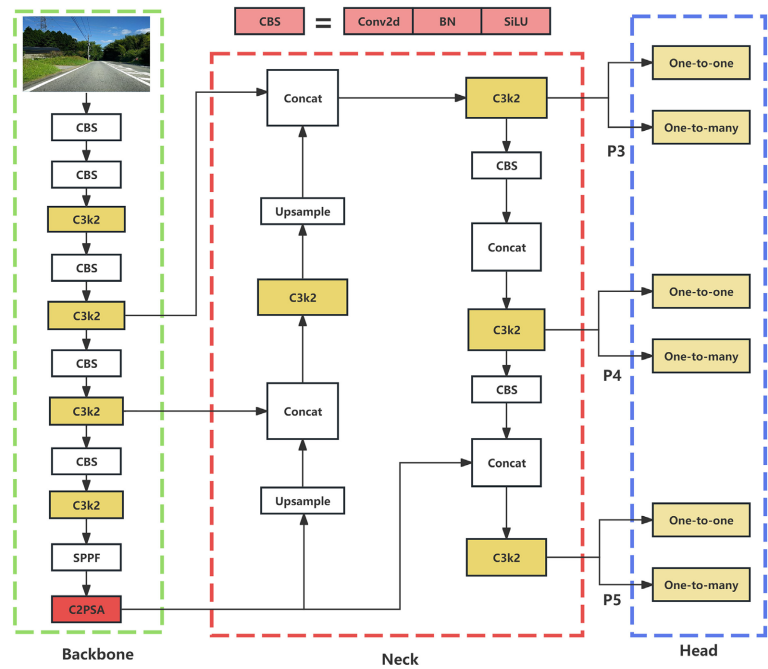


Figure 1. Network structure of YOLOv11
图 1. YOLOv11 网络结构

YOLOv11 的优势体现在多个维度：在精度方面，其中型版本(YOLOv11m)在 COCO 数据集上以比 YOLOv8m 减少 22% 的参数规模，实现了更高的平均精度(mAP)；速度层面，经过 GPU 优化后，推理速度较 YOLOv10 提升 2%，延迟降低 25%，充分满足实时应用需求；功能扩展上，模型支持目标检测、实例分割、姿态估计及定向边界框检测(OBB)等多种任务，展现出强大的多任务处理能力；部署兼容性方面，YOLOv11 可无缝适配边缘设备、云平台 and NVIDIA GPU 系统，为不同场景提供灵活解决方案。

凭借上述优势，YOLOv11 在诸多领域展现出广阔的应用前景。在智慧交通领域，它可助力自动驾驶系统精准识别行人、车辆及交通标志，同时实现交通流量监测与事故预防；智能安防场景中，模型支持人脸识别、异常行为检测及远程监控，提升安全管理效率；医疗健康方面，YOLOv11 可用于医学影像分析(如肿瘤检测)、细胞计数与分类等任务；工业制造环节，它能实现生产线产品质量检测、机器人视觉导航及仓库货物管理；零售商业领域，则可应用于顾客行为分析、库存盘点及虚拟试衣/试妆等场景；此外，在教育和文化遗产保护领域，YOLOv11 也为资源分类与图像分析提供了技术支持。

2.2. 改进方案

YOLOv11 算法相较于 YOLOv10 算法的改进主要在于：提出了新的核心模块 C3k2(如图 1 深黄色模块所示)，并以此替代了 YOLOv10 算法中的核心模块 C2f。YOLOv11 的 C3k2 模块相比 YOLOv10 的 C2f 模块，在结构设计、计算效率、特征提取能力等方面均有显著提升。结构设计上，C3k2 采用双并行卷积层，将输入特征分为两部分处理，一部分直接传递保留浅层细节，另一部分通过 Bottleneck 或 C3k 子模块进行深度特征提取后融合。这种设计增强了特征多样性和层次性，并通过可变卷积核(如 3×3 、 5×5)扩展感受野，提升复杂场景下的多尺度目标检测能力。此外，C3k2 还提供灵活性参数，允许调整模型性能与计算效率的平衡。计算效率方面，C3k2 结合分组卷积技术，显著减少参数量和计算复杂度。相比 C2f，其并行结构和分组卷积设计降低冗余计算，提高推理速度，更适合自动驾驶、智能监控等实时应用场景。同时，多尺度特征融合优化也提升了计算效率，减少特征信息丢失。特征提取能力上，C3k2 的多尺度特征融合和可变卷积核设计，使其在遮挡严重、姿态变化大的目标场景中仍能提取丰富上下文信息，提高检测精度。此外，C3k2 常与 C2PSA 模块结合，动态调整特征权重，增强对关键区域的关注，提升复杂场景检测性能。轻量化与部署优势方面，C3k2 通过分组卷积和通道压缩技术，在保持精度的同时大幅减少参数量，更适合资源受限的移动端或嵌入式设备部署，降低了硬件资源需求，提高了模型实用性和可扩展性。与 C2f 相比，C3k2 在结构设计、特征提取能力、计算效率和灵活性上均表现出明显优势，使其能更好地适应复杂场景中的目标检测任务，提高计算效率和部署优势，在自动驾驶、工业检测等实时性和精度要求较高的应用中表现出色。

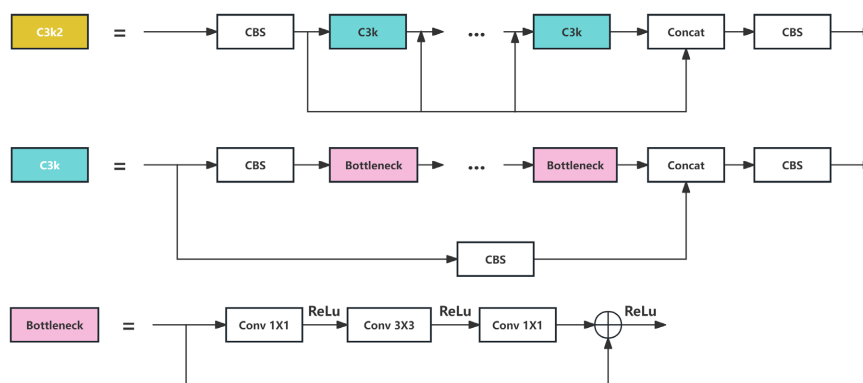


Figure 2. Network structure of C3k2

图 2. C3k2 网络结构

C3k2 模块的网络结构如图 2 所示, 虽然 C3k2 模块相较于 C2f 模块有较大的改进和性能提升, 但是其核心组成依然是 Bottleneck 子模块, Bottleneck 子模块是 CSP (Cross Stage Partial) 网络的基础结构, 通过两个卷积层提取特征, 并可选 shortcut 连接以增强梯度传播。虽然 Bottleneck 模块本身设计轻量, 但在 C3k2 中结合多个 Bottleneck 或 C3k 子模块可能增加模型复杂度, 影响训练速度和部署效率。另外在一些特定场景下, 如简单目标检测任务中, 使用多个 Bottleneck 子模块可能引入冗余计算, 增加不必要的参数, 导致模型过拟合或推理速度下降。为了进一步降低算法的复杂度和降低计算量, 本文设计了一种新的 RC-G-ELAN (RepConv-Ghost-ELAN) 模块取代 C3k2 模块。

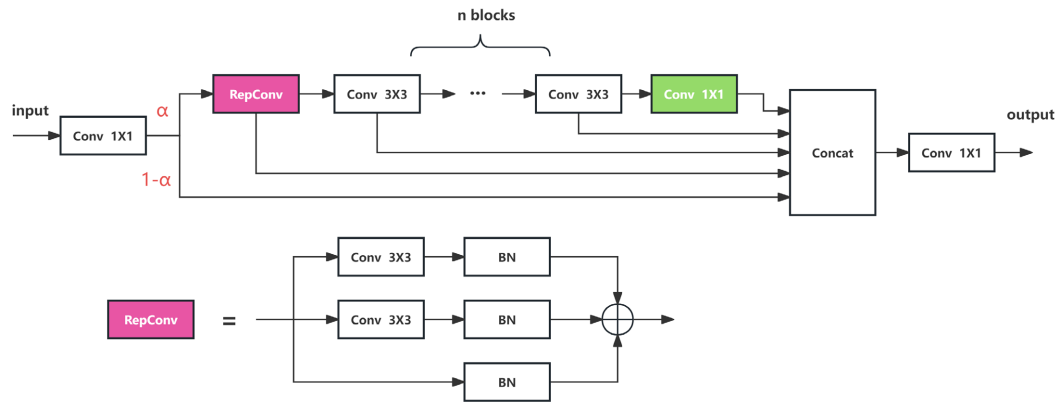


Figure 3. Network structure of RC-G-ELAN

图 3. RC-G-ELAN 网络结构

RC-G-ELAN 模块的网络结构如图 3 所示, 设计的核心思想是: 1) 参考 GhostNet 网络模型中的思想, 即主流 CNN 计算的中间特征映射存在广泛的冗余, 采用廉价的操作生成一部分冗余特征图, 以此来降低计算量和参数量。2) 引入重参数化卷积 RepConv, 弥补因舍弃 Bottleneck 残差块所带来的性能损失, 增强特征提取和梯度流通的能力。3) 引入分流控制因子 α , 针对不同的检测任务, 可以调整网络模型的大小, 找到最适合当前任务的控制因子, 增加整体网络的应用适应性。RC-G-ELAN 模块的创新点主要在以下几个方面:

1) 网络输入前端引入 RepConv 模块

RepConv (Re-parameterizable Convolution) 模块是一种通过结构重参数化技术优化模型效率和性能的卷积模块, 其核心思想是在训练阶段采用多分支结构学习丰富特征, 推理阶段合并分支为高效单分支结构。RepConv 模块的核心优势在于训练阶段采用多分支卷积结构(如 1×1 、 3×3 卷积及恒等映射)增强特征提取能力, 而在推理阶段将多分支参数融合为单个 3×3 卷积层, 显著降低了计算复杂度。该模块将卷积层与批归一化(BN)层的参数高效融合, 进一步减少冗余运算, 同时支持通道数的动态调整, 在保持参数量稳定的前提下提升模型表达能力。在网络前端引入 RepConv 模块的主要目的是在图像特征信息最完整的时候进行特征信息的充分融合和有效提取, 以此弥补因舍弃 Bottleneck 残差块所带来的性能损失。

2) 采用 Conv 3×3 模块替代 C3k 模块

在 C3k2 网络结构中, 其核心组成是 C3k 模块, 而在 RC-G-ELAN 网络结构中, 核心组成为 Conv 3×3 模块。C3k 模块的核心是 Bottleneck 模块, 其主要操作为卷积加残差操作, 而 Conv 3×3 模块表示的是 3×3 的卷积操作, 与 C3k 模块相比, Conv 3×3 模块去掉了残差结构, 减少了大量的残差操作, 因此网络结构更简洁, 计算量更少。

3) 串行结构改为并行结构

如图2所示,在C3k2的网络结构中,数据经过第一个CBS模块后,分别作为后续每一个C3k模块的额外输入数据,而这些额外输入数据在参与完当前级C3k模块的处理后,又会作为下一级的C3k模块的输入,这些由第一个CBS模块产生的额外数据,串行参与了多个C3k模块的数据处理,而且越靠前的CBS分支数据参与的C3k模块数据处理越多,显然这样的串行结构产生了一定的冗余操作。因此,本文将C3k2这种串行结构进行改进,设计了如图3所示的并行结构。在图3中,RepConv模块的输出只会作为第一个Conv 3×3 模块的输入,不会作为后续Conv 3×3 模块的输入,另外将每级的Conv 3×3 模块的输出直接并联到最后的Concat模块,实现数据的拼接,这样的并行结构能够一定程度地减少数据的冗余操作。

4) 网络后端添加Conv 1×1 模块

Conv 1×1 模块不仅能引入非线性特性,增强网络深度学习复杂函数的能力,从而提升模型表达能力,还能通过调整通道数实现网络维度的灵活升降。在网络后端添加Conv 1×1 模块,一方面能够减少计算量,降低运算复杂度,减少过拟合风险;另一方面还能促进了通道间的跨通道信息交互与整合,使得不同通道的特征信息得以融合,有助于网络提取更加丰富的高级特征。

基于本文设计的RC-G-ELAN模块对YOLOv11的网络结构进行重构,用RC-G-ELAN模块替代C3k2模块,重构的网络结构如图4所示,本文改进后的算法称之为RCGELAN-YOLOv11算法。

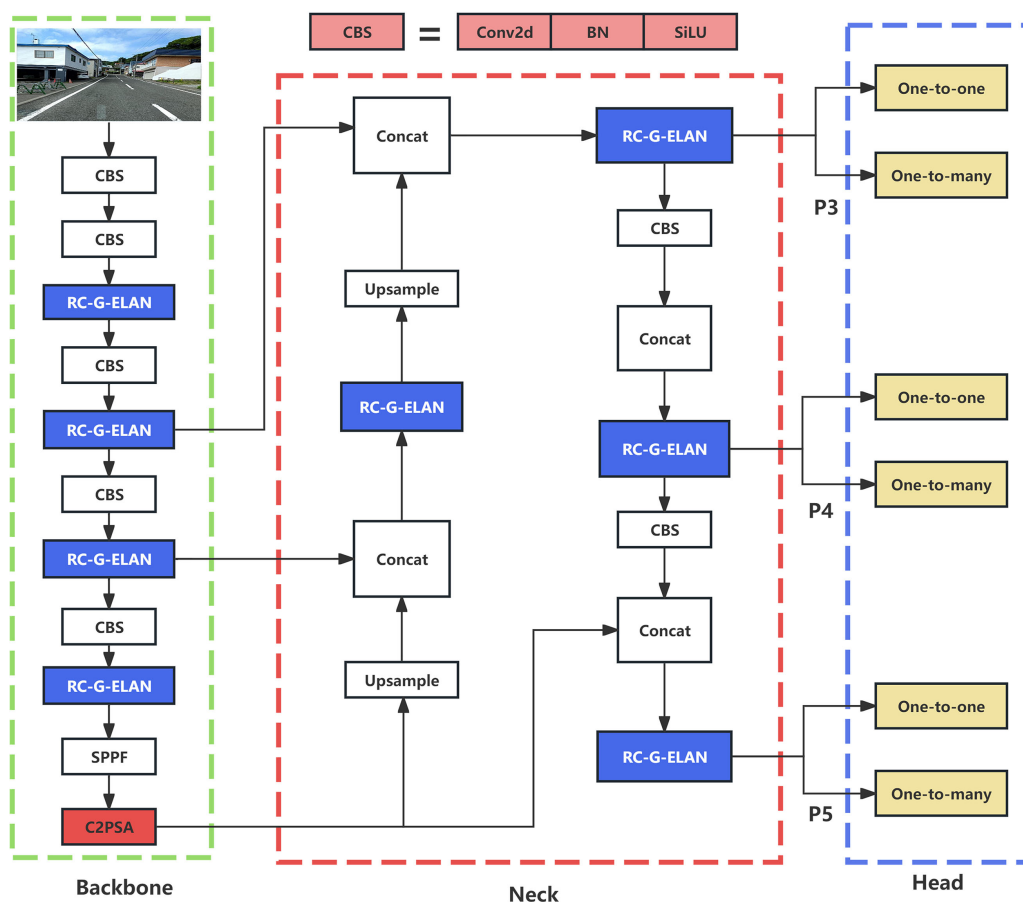


Figure 4. Network structure of proposed algorithm

图4. 本文所提算法的网络结构

3. 仿真实验与结果分析

3.1. 实验数据集

GRDDC2020 数据集汇聚了来自印度、日本和捷克三国的道路图像，专为道路损伤检测挑战赛[11]而设，于 2020 年作为全球道路损伤检测挑战赛的一部分正式发布。数据集中，捷克提供了 2829 个样本，印度 7706 个，日本则贡献了 10,506 个，总计 21,041 个样本。该数据集涵盖了 10 种道路损伤类型，具体包括：d00 (纵向损伤)、d01 (纵向拼接缝，d0w0 为错误标签)、d10 (横向损伤)、d11 (横向拼接缝)、d20 (龟裂)、d40 (坑洞)、d43 (十字路口模糊)、d44 (井盖)、d50 (白线模糊)。在 GRDDC2020 原数据集的 21,041 个图像中，仅 14,569 个带有标注标签。本文研究中，将这 14,569 个数据以 7:1:2 的比例分配为训练集、验证集和测试集，具体数量为训练集 10,198 张、验证集 1457 张、测试集 2914 张。图 5 展示了数据集中部分具有代表性的图像，直观反映了多种道路损伤状况。



Figure 5. Road damage dataset images

图 5. 路面损伤数据集图片

3.2. 仿真实验

本节通过仿真实验验证本文所提算法的性能，具体的实验参数如表 1 所示。

Table 1. Experimental parameters
表 1. 实验参数

参数名	参数值
训练集图片	10,198
验证集图片	1457
测试集图片	2914
epoch	300
学习率	0.01
batchsize	32
优化器	SGD

图 6 展示了本文提出算法的训练流程。其中，前三列子图呈现了损失值随训练进程的变化情况，具体地，横轴代表迭代轮次 epoch，纵轴则表示 loss 值；而后两列子图则描绘了准确性的变化趋势，同样以迭代轮次 epoch 为横轴，以准确率为纵轴。在训练期间，可以清晰地观察到，随着迭代轮次 epoch 的逐步增加，分类损失 `clc_loss`、预测边界框损失 `box_loss` 以及分布特征损失 `dfl_loss` 均呈现持续下降态势，而预测精准度 `precision`、召回比率 `recall` 以及全局平均精度 `mAP` 则稳步提升，直至最终趋于稳定。

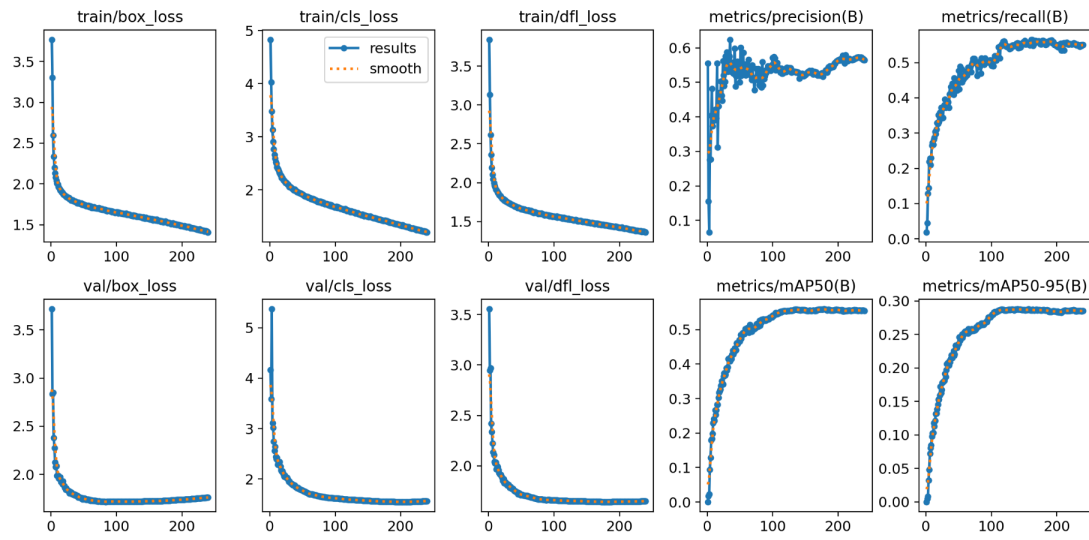


Figure 6. Training procedure of proposed algorithm
图 6. 本文所提算法的训练过程

为了验证本文所提算法的性能，我们将本文所提算法与 YOLOv11 算法在检测精度和复杂度两方面进行了对比，对比结果如图 7 和表 2 所示。从图 7 中可以看到，本文所提算法在检测精度上与 YOLOv11 算法差别不大，对全类型损伤的检测精度 `mAP50` 仅仅降低了 0.7% 左右(0.558→0.551)，在某些道路损伤情况上，如 D01 (纵向拼接缝)、D20 (龟裂)和 D50 (白线模糊)，本文所提算法的检测精度甚至高于 YOLOv11 算法(实验结果表明本文所提算法对横线型的目标识别能力较强，主要原因是本文所提算法简化了网络结构，减少了卷积运算，因此反而对一些特征图像比较直接的目标检测能力较强)。

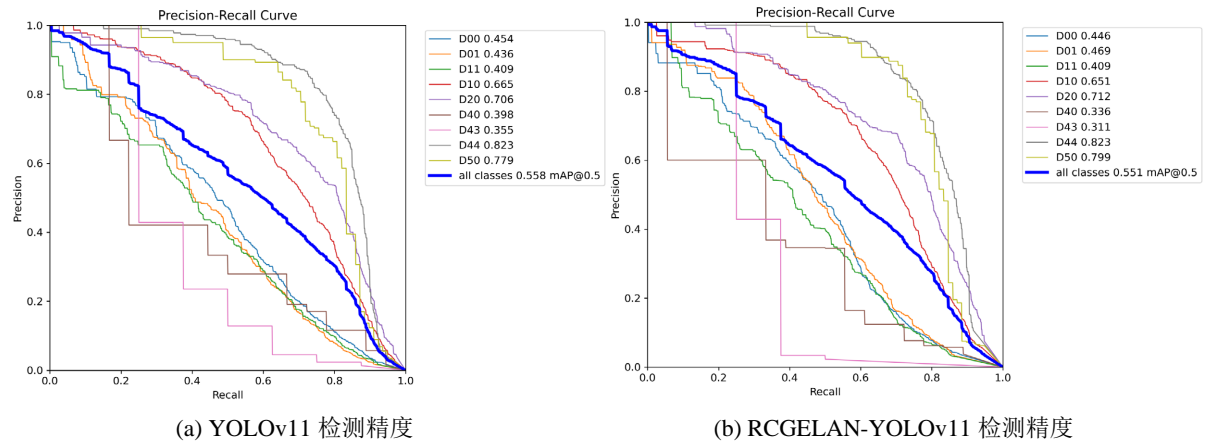


Figure 7. Comparison of the algorithm detection accuracy (mAP50)
图 7. 算法检测精度对比(mAP50)

本文所提算法的重要价值是在复杂度上的降低，为比较两种算法的复杂度，以网络层数(Layers)参数量(Parameters)、梯度计算量(Gradients)和每秒 10 亿次浮点运算数(Giga Floating-point Operations Per Second, GFLOPs)作为评估指标，本文算法和 YOLOv11 算法的最小模型 YOLOv11n 进行比较，比较结果如表 2 所示。从表 2 中可以看到，与 YOLOv11n 算法对比，本文所提算法在上述的四个指标中都有大幅度的下降，其中 Layers 降低了 19.33%，Parameters 降低了 15.84%，Gradients 降低了 22.81%，GFLOPs 降低了 6.15%。因此本文所提算法能够大幅度地降低 YOLOv11 的网络层数、参数量与计算量，大幅度地降低算法的复杂度。

Table 2. Comparison of the algorithm complexity
表 2. 算法复杂度对比

模型	Layers	Parameters	Gradients	GFLOPs
YOLOv11n	238	2616248	2616232	6.5
本文所提算法	192★	2201818★	2019560★	6.1★

为了进一步验证本文所提算法的性能，在测试数据集上对不同类型的路面损伤情况进行检测，检测结果如图 8 所示。从图 8 中可看出，本文所提的算法能精准识别横纵向裂缝、拼接缝、龟裂、井盖、白线模糊等各类路面损伤。另外，对于一张图像中存在有多种不同类型路面损伤的情况，该算法也能实现准确识别。

4. 结论

本文提出了一种基于 RCGELAN-YOLOv11 的路面损伤检测算法，通过设计 RC-G-ELAN 模块替代 YOLOv11 中的 C3k2 模块，实现了网络结构的优化和计算复杂度的降低。在 GRDDC2020 数据集上的实验结果表明，与 YOLOv11 相比，本文所提算法在保持检测精度的同时，显著减少了网络层数、参数量、梯度计算量和每秒十亿次浮点运算数，有效提升了算法的效率和实用性，因此本文所提算法在一些存储空间有效、运行能力较差的移动终端上更有竞争力和实际应用价值。未来的工作集中在两方面：一是优化网络结构和模块功能，提高对微弱模糊目标的检测能力，以提高检测精度；另一方面进一步简化

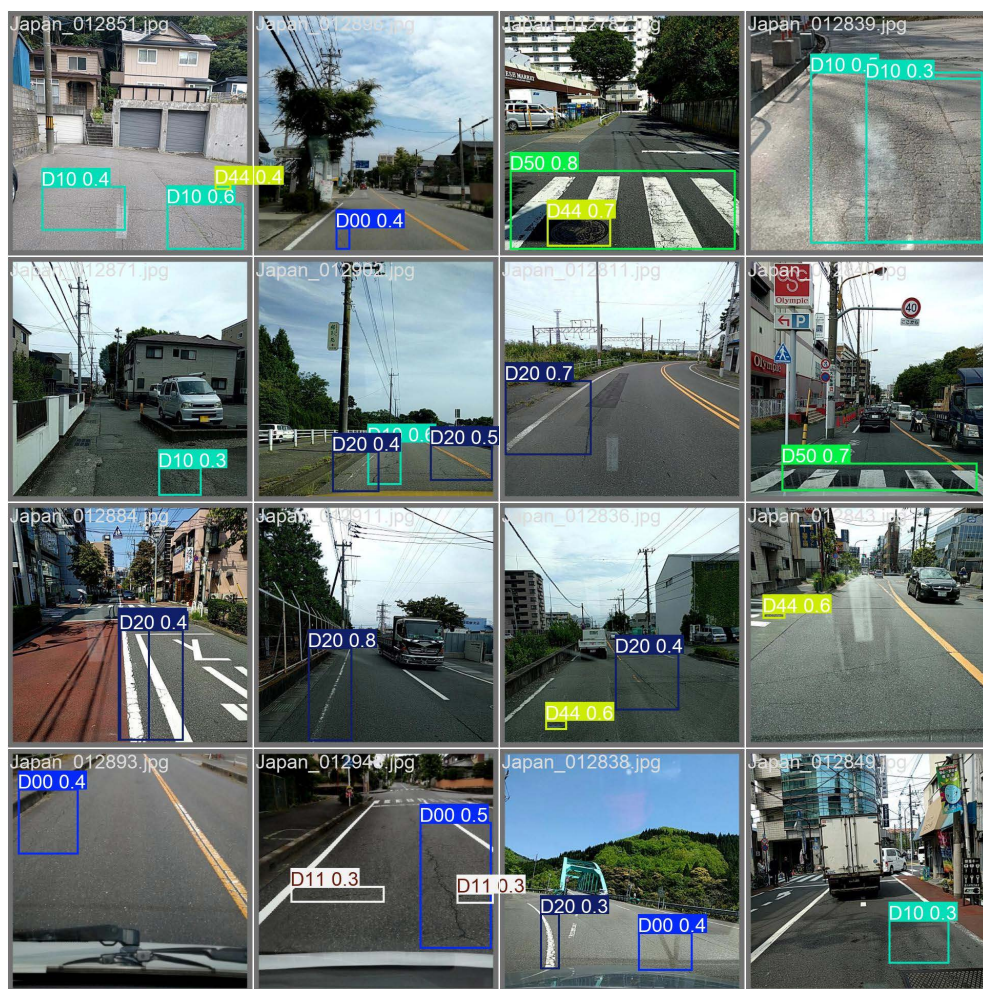


Figure 8. Testing situation of the proposed algorithm

图 8. 本文所提算法的测试情况

RC-G-ELAN 模块的结构和参数, 探索其在其他目标检测任务中的应用潜力, 并推动算法在实际道路检测系统中的部署和测试, 为智慧交通系统的发展贡献力量。

基金项目

贵州交通职业大学高层次人才科研启动基金项目: 复杂交通环境下的多目标检测研究 (KYQD2022004)。

参考文献

- [1] 宋浩辉. 基于深度学习的路面损伤识别及评估[D]: [硕士学位论文]. 西安: 西安工业大学, 2024.
- [2] 周臣. 基于深度学习的自然场景路面损伤检测研究[D]: [硕士学位论文]. 济南: 齐鲁工业大学, 2025.
- [3] Redmon, J., Divvala, S., Girshick, R. and Farhadi, A. (2016) You Only Look Once: Unified, Real-Time Object Detection. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 779-788. <https://doi.org/10.1109/cvpr.2016.91>
- [4] 王梦梦, 黄德启, 刘爽娜. 基于改进 YOLOv5s 的路面损伤检测[J]. 激光杂志, 2023, 44(5): 66-71.
- [5] 杨杰, 蒋严宣, 熊欣燕. 结合 Transformer 和 SimAM 轻量化路面损伤检测算法[J]. 铁道科学与工程学报, 2024,

- 21(9): 3911-3920.
- [6] 孔超. 基于 YOLO 算法深度学习的路面病害检测方法研究[J]. 建筑机械化, 2024, 45(7): 24-27.
- [7] 邵军, 潘道远, 高清振, 等. AUG-YOLOv8-D 面向路面损伤轻量化检测算法[J]. 佳木斯大学学报(自然科学版), 2025, 43(7): 5-8, 69.
- [8] 罗一纯, 翁程亮, 胡海心, 等. 基于 YOLOv8s-G 与无人机的智轨路面损伤自动检测方法研究[J]. 施工技术(中英文), 2025, 54(16): 142-145, 153.
- [9] 张亚军, 苗皓源, 马薇, 等. 基于 YOLOv8 改进的无人机航拍路面损伤检测算法[J/OL]. 电子测量技术: 1-12. <https://link.cnki.net/urlid/11.2175.TN.20250901.0954.002>, 2025-11-05.
- [10] Nyi Myo, N., Boonkong, A., Khampitak, K. and Hormdee, D. (2025) A Two-Point Association Tracking System Incorporated with YOLOv11 for Real-Time Visual Tracking of Laparoscopic Surgical Instruments. *IEEE Access*, **13**, 12225-12238. <https://doi.org/10.1109/access.2025.3529710>
- [11] 黄展鹏. 基于改进 YOLOv5 的路面病害检测方法研究[D]: [硕士学位论文]. 成都: 电子科技大学, 2024.