

基于YOLOv8n改进的混凝土裂缝识别研究

白嘉莹

应急管理大学研究生处, 河北 廊坊

收稿日期: 2026年4月21日; 录用日期: 2026年5月18日; 发布日期: 2026年5月27日

摘要

混凝土裂缝是评估结构安全性的关键指标, 但传统人工检测方法存在效率低、主观性强等问题。研究旨在解决基于YOLOv8n的裂缝识别模型存在的对小裂缝敏感度不足的问题。通过引入注意力机制、优化多尺度特征融合网络及改进损失函数等方法, 对YOLOv8n模型进行针对性改进。消融实验表明, 改进的YOLOv8n-BiFPN-CA-FocalLoss模型相比基线, mAP50提升11.89%, 召回率与精确率分别提升11.78%和12.68%, 同时保持95.14 FPS的实时推理速度, 各模块协同增益, 有效提升了混凝土裂缝检测性能。

关键词

混凝土裂缝识别, YOLOv8n, 目标检测

Research on Concrete Crack Identification Based on Improved YOLOv8n

Jiayun Bai

Graduate School, University of Emergency Management, Langfang Hebei

Received: April 21, 2026; accepted: May 18, 2026; published: May 27, 2026

Abstract

Concrete cracks are critical indicators for evaluating structural safety. However, traditional manual detection methods suffer from problems such as low efficiency and strong subjectivity. This study aims to address the insufficient sensitivity to small cracks in the YOLOv8n-based crack detection model. The YOLOv8n model is specifically improved by introducing an attention mechanism, optimizing the multi-scale feature fusion network, and modifying the loss function. Ablation experiments show that the proposed improved model, YOLOv8n-BiFPN-CA-FocalLoss, achieves a 11.89% increase in mAP50 compared with the baseline model, while recall and precision are improved by 11.78% and 12.68%, respectively. Meanwhile, it maintains a real-time inference speed of 95.14 FPS.

The synergistic effect of each module effectively enhances the performance of concrete crack detection.

Keywords

Concrete Crack Identification, YOLOv8n, Object Detection

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

1.1. 研究背景与意义

混凝土是现代建筑的主要建筑用料，但在长期荷载与环境因素共同作用下容易产生裂缝，及时检测与维护，是延长建筑使用寿命和保障结构安全的必要措施。

裂缝是基础建设中常见的缺陷类型，及时检测与评估对于提升基础设施安全性具有重要意义[1]。墙体裂缝作为最常见的结构病害，其定期巡检与安全评估需求巨大。传统人工检测方法效率低、主观性强且存在安全风险。近几年，随着人工智能技术的发展，裂缝的自动识别技术精度得到进一步提高[2]。深度学习成为一种理想的智能检测途径。相较于传统数字图像处理，深度学习算法避免了复杂的图像预处理过程，可有效应对形态各异、背景复杂的裂缝[3]。

传统检测主要依赖人工目视、裂缝尺测量等方法，不仅效率低下、成本高昂，且受检测人员经验影响大，难以实现全面、客观的评估。随着图像处理技术的进步，计算机视觉和深度学习技术已成为裂缝智能识别的新兴研究领域[4]。本研究聚焦于 YOLOv8n 这一轻量级网络，针对混凝土微小裂缝难度大进行改进，具有重要的工程应用价值和现实意义。

1.2. 国内外研究现状

近年来，图像处理技术在结构裂缝识别中得到广泛应用，其中阈值分割和边缘检测最为常见[5]。Jiang [6]等提出了一种结合 Canny 算子与 OTSU 自适应阈值分割的岩面裂缝检测算法；郭运冲等[7]提出了一种改进 Canny 算子的建筑物裂缝边缘检测算法。谭兆等[8]提出将裂缝边缘作为目标关键特征进行感知学习，通过构建一种新的裂缝边缘预测分支网络，并与裂缝主干分割网络联合训练，形成一种基于双任务学习的裂缝检测与识别模型。王建峰等[9]提出基于自适应分块综合滤波和形态学方法的衬砌图像裂缝分割方法，能有效地完成裂缝提取和裂缝参数计算。传统图像方法虽然在理想状态下有一定的效果，但是其鲁棒性差，易受噪声干扰。

深度学习方法凭借强大的特征提取与端到端建模能力，在裂缝识别中表现出更高的精度与鲁棒性，推动了裂缝检测由人工检测向自动化智能识别的转变。特别是 YOLOv 系列，被广泛应用于裂缝识别领域。Yang 等[10]在 YOLOv5 网络结构的基础上进行了改进，提出了一种新型的跨层加权级联聚合网络(W-PAN)来代替原始的 YOLOv5 网络。Teng 等[11]基于 YOLOv3，通过引入迁移学习模型和数据增强，提高模型的特征提取性能和鲁棒性，实现了桥梁表面裂缝和钢筋裸露在不同图像分辨率下的精确高效识别。Wu 等[12]提出了一种基于改进实例分割模型的轻量级、实时的像素级裂缝检测方法，提出了一个轻量级的骨架和一个新的高效的原型掩码分支，以降低模型的复杂度并保持模型的准确性，适用于低性能的器

件。陈逵等[13]在 YOLOv8n 基础架构上,通过引入 SPD Conv 卷积模块、增设小目标检测头并嵌入 SAFM 注意力机制模块,有效提升砖砌墙体裂缝形态的识别检测精度。

2. YOLOv8 模型

YOLOv8 是 Ultralytics 公司 2023 年发布的最新版本,相比 YOLOv5/v7,在架构、训练策略、推理效率上都有大幅优化,支持目标检测、实例分割、姿态估计、分类等多任务,是目前工业界和学术界应用最广泛的目标检测模型之一。YOLOv8 有 5 种不同的版本,分别为 YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l、YOLOv8x,不同版本的算法深度和参数量都不同[14]。在衡量了五种模型的检测精度与大小之后,本研究选用了检测精度相对出色且模型体量偏小的 YOLOv8n 作为基准模型进行改进。

3. 基于 YOLOv8n 的改进方法设计

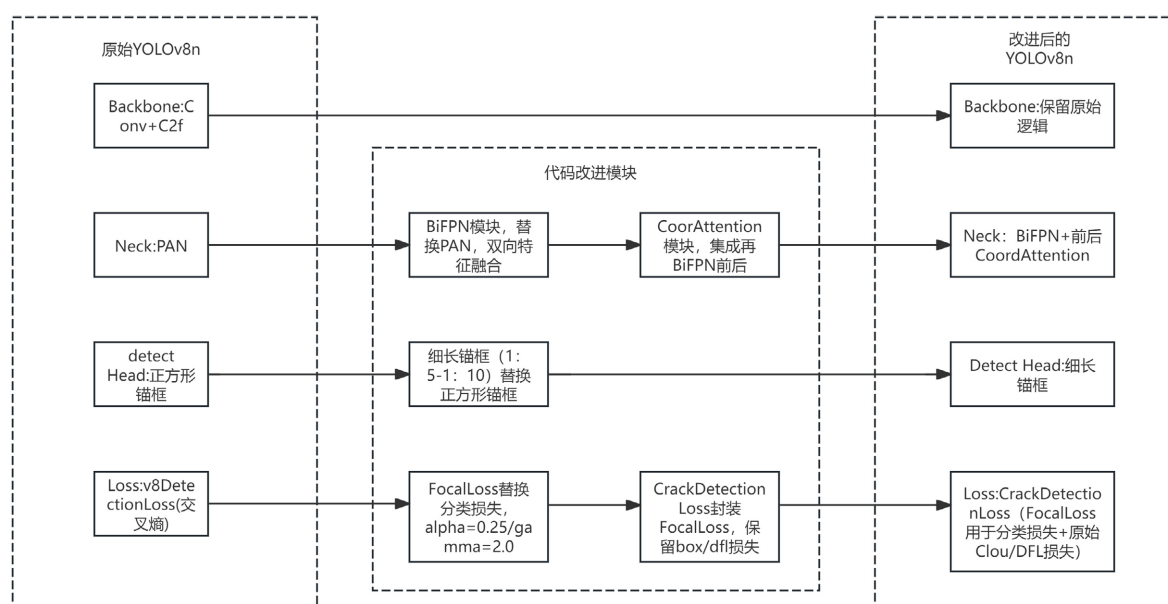


Figure 1. Diagram of model architecture improvement

图 1. 模型架构改进图

本文提出一种基于 BiFPN、CoordAttention、细长锚框与优化 Focal Loss 的 YOLOv8n 混凝土裂缝检测方法(YOLOv8n-BiFPN),模型改进核心关联图如图 1 所示。主要从锚框设计、特征融合、损失函数、训练策略进行优化:

1) 设计适配裂缝形态的细长锚框(1:5~1:10 长宽比),替换原始正方形锚框,提升小裂缝和细长裂缝的锚框匹配度。

2) 在原始 PAN Neck 的特征处理流程中嵌入 BiFPN 模块(保留 Backbone 与 Head 核心结构),通过双向特征融合强化小尺度裂缝特征表达;在 BiFPN 特征融合前后集成 CoordAttention 坐标注意力模块,聚焦裂缝区域的空间位置特征,抑制背景干扰。

3) 优化 Focal Loss 核心参数($\alpha = 0.25$, $\gamma = 2.0$),将其集成到自定义 CrackDetectionLoss 中替换原始分类损失,平衡正负样本学习。

4) 优化学习率、损失权重等训练超参数,提升模型收敛稳定性与检测性能。

模型改进图如图 1 所示。

YOLOv8n 主干网络提取多尺度特征，经嵌入的 BiFPN + CoordAttention 模块进行特征增强与双向融合；采用适配裂缝的细长锚框(1:5~1:10)提升匹配度；检测头对融合特征进行预测，损失函数采用自定义 CrackDetectionLoss，其中分类损失使用 Focal Loss ($\alpha = 0.25, \gamma = 2.0$)，Box 与 DFL 损失保持原始结构，实现正负样本均衡学习。

3.1. 适配裂缝的细长锚框设计

混凝土裂缝的核心形态特征是“细长型”，通过对数据集中标注的裂缝样本进行统计分析，发现裂缝的长宽比主要集中在 1:5~1:10 之间，而 YOLOv8n 默认锚框多为接近正方形的比例(如[10, 13]、[16, 30]、[33, 23]等)，与裂缝形态严重不匹配，导致小裂缝和细长裂缝的锚框匹配度低，召回率不足。因此，需要设计针对性的细长锚框以提升检测性能。

针对 640×640 输入分辨率，结合裂缝的尺度分布(小裂缝： $5 \times 25 \sim 20 \times 100$ 像素、中裂缝： $20 \times 100 \sim 40 \times 200$ 像素、大裂缝： $40 \times 200 \sim 50 \times 200$ 像素)，按 P3、P4、P5 三个特征层设计细长锚框：

P3 层(感受野 8×8 ，对应小裂缝)：[10, 50]、[20, 100]、[30, 150] (长宽比 1:5~1:6)；

P4 层(感受野 16×16 ，对应中裂缝)：[40, 200]、[50, 250]、[60, 300] (长宽比 1:5)；

P5 层(感受野 32×32 ，对应大裂缝)：[70, 350]、[80, 400]、[90, 450] (长宽比 1:5~1:5.6)。

锚框整体形状为 reshape (3, 3, 2)，与 YOLOv8n 锚框维度一致，确保兼容模型结构。

3.2. BiFPN-CA 特征融合模块设计

原始 YOLOv8n 的 Neck 模块采用 PAN 结构进行特征融合，虽然能够实现多尺度特征的双向传递，但存在对不同尺度特征贡献权重无法自适应调整、对细长裂缝特征的感知能力不足等问题。为此，本研究将 BiFPN 特征融合模块与 CoordAttention 坐标注意力模块相结合，构建 BiFPN + CoordAttention 特征增强模块，替换原始 YOLOv8n 的 Neck 模块，强化多尺度细长裂缝特征的提取与融合能力。

3.2.1. CoordAttention 模块

CoordAttention 模块是针对裂缝细长型、方向性特征优化的注意力机制，与传统的注意力机制不同，CoordAttention 是一种基于空间和通道信息的注意力机制，旨在通过对输入特征图的空间位置进行编码，增强网络对不同空间位置特征的关注能力，从而提高特征表达的准确性和多样性[15]。CoordAttention 通过以下步骤生成注意力权重：

- 1) 坐标信息嵌入

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i < W} x_c(h, i) \quad (\text{水平方向池化})$$

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq j < H} x_c(j, w) \quad (\text{垂直方向池化})$$

- 2) 坐标注意力生成

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

$$g^h = \sigma\left(F_h\left(f^h\right)\right), \quad g^w = \sigma\left(F_w\left(f^w\right)\right)$$

- 3) 特征重标定

$$y_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j)$$

尽管原始 CoordAttention 在理论上具有优势，但在混凝土裂缝检测的实际应用中仍存在不足。本文

从以下三个维度进行针对性改进：

1) 轻量化设计(适配 YOLOv8n): 采用 1×1 卷积而非 3×3 卷积, 减少计算量; 降维系数设为 32 (而非 16), 进一步降低参数量, 保证推理速度(裂缝检测需实时性)。

2) 双阶段集成(BiFPN + CA): 为了更好地捕捉混凝土裂缝的细长结构特征, 在 BiFPN 特征融合过程中引入了两次 CoordAttention 模块。第一次位于特征融合之前, 用于增强原始特征中裂缝区域的响应; 第二次位于特征融合之后, 用于强化融合后多尺度特征中的裂缝信息。

流程图如图 2 所示:




Figure 2. Two-stage integrated process flowchart
图 2. 双阶段集成流程图

两次注意力机制分别作用于融合前后, 使网络在早期增强裂缝区域、在后期强化融合特征, 从而提升小裂缝和细裂缝的检测精度。

3) 通道匹配(适配 BiFPN 输出): CoordAttention 的输入/输出通道数与 BiFPN 的特征通道数(256)完全匹配, 保证注意力模块与 BiFPN 的无缝衔接, 不破坏特征维度的一致性。

CoordAttention 通过轴向池化 + 双通道注意力编码, 同时捕捉裂缝的通道依赖和空间坐标信息, 解决传统注意力丢失位置信息的问题; 针对裂缝检测做轻量化设计(1×1 卷积、降维系数 32), 并在 BiFPN 中双阶段集成, 强化多尺度裂缝特征; 在此前提下, 提升细长裂缝的检测精度, 且与 FocalLoss 自定义锚框形成互补, 整体优化裂缝检测效果。

3.2.2. BiFPN 特征模块

BiFPN (Bi-Directional Feature Pyramid Network)是一种加权双向特征金字塔网络, 可以进行高效快速的多尺度特征融合[16]。其核心思想包含两个关键点:

- 1) 高效的双向跨尺度连接: 在 PANet 的双向结构基础上, 进行简化和优化。
- 2) 特征加权融合: 为每个输入特征引入一个可学习的权重, 让网络自己学习不同特征的重要性。跨尺度连接删除冗余节点和边, 简化了结构, BiFPN 的演进过程如图 3 所示。

传统特征金字塔在融合不同分辨率特征时, 通常采用直接相加或拼接, 即:

$$O = \sum_i I_i$$

其中, I_i 表示第 i 个输入特征, 这种方式隐含了所有输入特征重要性相等的假设。

加权特征融合这是 BiFPN 的灵魂。它不再平等地看待所有待融合的特征, 而是为每个特征分配一个权重。主要提出了三种方案:

- 1) 无限制加权融合(Unbounded):

$$O = \sum_i w_i * I_i,$$

其中, w_i 为可学习标量。该方法简单, 但可能导致训练不稳定。

- 2) 基于 Softmax 的融合:

$$O = \sum_i \frac{e^{w_i}}{\sum_j e^{w_j}} * I_i$$

该方案将权重归一化至(0, 1)区间, 但 softmax 运算在硬件上效率较低。

3) 快速归一化融合:

$$O = \frac{\sum_i w_i \cdot I_i}{\epsilon + \sum_j w_j}$$

其中, 每个权重 w_i 通过 ReLU 激活函数确保非负性, $\epsilon = 0.0001$ 为数值稳定项。该方案近似于 softmax 的归一化效果, 但省去了指数运算, 具有更快的速度与更低的内存消耗, 且在实践中表现优异。

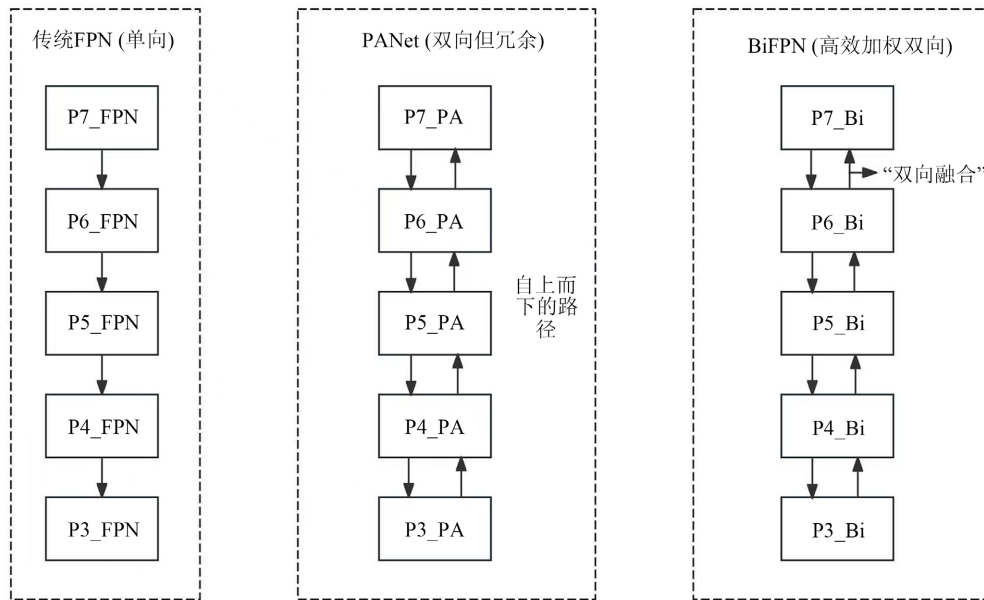


Figure 3. Evolution process diagram of BiFPN
图 3. BiFPN 演进过程图

针对混凝土裂缝小目标特性, 对基础 BiFPN 特征融合层进行适配性改进:

1) 特征融合权重设计: BiFPN 层设置 8 维可学习权重参数(初始值全为 1), 通过 ReLU 激活函数约束权重非负性, 权重参数参与自顶向下(Top-Down)和自底向上(Bottom-Up)双向特征融合计算, 其中前 4 维权重对应 Top-Down 融合阶段, 后 4 维权重对应 Bottom-Up 融合阶段, 融合过程中引入极小值 $\epsilon = 10^{-4}$ 避免分母为零, 保障数值计算稳定性;

2) 插值方式分层优化: 针对小裂缝特征上采样失真问题, 采用分层插值策略——Top-Down 融合阶段保留最近邻插值(mode = 'nearest')以保证小目标位置精度, Bottom-Up 融合阶段采用双线性插值(mode = 'bilinear')以优化小裂缝特征的像素级连续性, 特征融合公式如下式所示:

$$P4_{id} = \frac{w_0 \cdot P4 + w_1 \cdot \text{Interpolate}(P5, \text{size} = P4.\text{shape}[2:], \text{mode} = \text{'nearest'})}{w_0 + w_1 + \epsilon}$$

$$P4_{out} = \frac{w_4 \cdot P4 + w_5 \cdot P4_{id} + w_6 \cdot \text{Interpolate}(P3_{id}, \text{size} = P4.\text{shape}[2:], \text{mode} = \text{'bilinear'})}{w_4 + w_5 + w_6 + \epsilon}$$

3.2.3. BiFPN-CA 特征融合模块

为了保证模型的轻量化特性与整体结构的稳定性，本研究采用“嵌入特征增强模块至模型前向传播流程”的方式集成 BiFPN + CoordAttention 模块，保留原始 YOLOv8n 的 Backbone 与 Head 结构，具体实现：

保留原始 YOLOv8n 的 Backbone 结构，完整执行其前向传播流程以提取多尺度特征(P3/P4/P5)，不改变其特征输出格式与维度，确保多尺度特征的高效提取。

自定义 BiFPN + CoordAttention 模块的前向传播函数，通过 1×1 卷积统一特征通道维度、双向融合策略增强特征表达，确保模块输入与 Backbone 输出、模块输出与 Head 输入的维度完全兼容。

重构模型整体前向传播方法：在保留 Backbone 完整执行逻辑的基础上，嵌入 BiFPN + CoordAttention 模块的特征融合流程，替代原始 Neck 层的特征处理逻辑，实现特征增强模块的集成。

保留原始 YOLOv8n 的 Head 结构，仅适配类别数(nc = 1)以匹配裂缝检测任务，确保检测头对融合后的特征图进行正常的边界框回归与类别预测。

通过这种方式，在最小化修改模型原始结构(仅调整前向传播流程，不重构网络层)的前提下，实现特征增强模块的集成，既保证了模型的轻量化特性(仅增加少量参数量)，又维持了训练过程的稳定性。

BiFPN-CA 结构如图 4 所示：




Figure 4. Structure of BiFPN-CA
图 4. BiFPN-CA 结构图

3.3. FocalLoss 集成的损失函数设计

损失函数是指导模型训练的核心，原始 YOLOv8n 采用 v8DetectionLoss 作为损失函数，其分类损失采用交叉熵损失，在混凝土裂缝检测的正负样本不平衡场景下，容易导致模型偏向背景类别，裂缝漏检率偏高。为此，本研究引入 FocalLoss 替换传统交叉熵分类损失，构建自定义的 CrackDetectionLoss 损失函数。

Focal Loss 的核心思想是动态调整不同样本的损失权重[17]。其数学表达式如下：

$$FL(p_t) = -\alpha_t (1 - p_t)^\gamma \log(p_t)$$

其中，各参数的含义如下：

p_t ：表示模型对样本类别的有效预测概率，针对正负样本有不同定义：对于正样本， $p_t = p$ (p 为模型预测该样本属于裂缝类别的概率，取值范围为(0, 1))；对于负样本(背景)， $p_t = 1 - p_t$ ， $1 - p_t$ 为模型预测该样本不属于裂缝类别的概率。

α_t ：平衡系数，用于平衡正负样本的数量差异(裂缝样本远少于背景样本)。本研究取 $\alpha = 0.25$ 对正样本(裂缝)赋予更大的损失权重，对负样本(背景)赋予更小的权重，缓解样本数量不平衡带来的影响。

γ ：调制系数(聚焦参数)，用于调整简单样本与困难样本的损失权重，本研究取 $\gamma = 2.0$ ，其作用机制为：当样本为简单样本时(如无裂缝的背景)， p_t 接近 1。此时 $(1 - p_t)^\gamma$ 接近 0，该样本的损失权重被大幅降低，减少其对模型训练的干扰；当样本为困难样本时(如微小/模糊裂缝)， p_t 接近 0， $(1 - p_t)^\gamma$ 接近 1，该样本的损失权重被完整保留，迫使模型重点学习这类难检测的裂缝样本。

通过引入 α_i 与 γ 两个参数, Focal Loss 能够有效缓解混凝土裂缝检测任务中正负样本极度不平衡带来的模型偏置问题, 提升模型对裂缝样本的检测能力, 降低漏检率。本研究将 YOLOv8 原始的交叉熵分类损失替换为上述 Focal Loss, 并集成到自定义的 CrackDetectionLoss 损失函数中, 保留了原有的 CIoU 边框损失和 DFL (Distribution Focal Loss) 分布损失, 保证裂缝框回归的精度。

3.4. 训练策略优化

保留 SGD 优化器, 将初始学习率从 0.005 降至 0.003 (适配 Focal Loss 训练, 避免震荡), 权重衰减保持 0.0005 不变。

调整检测任务损失权重: 将边界框损失权重(box)设置为 7.5, 分类损失权重(cls)从 0.5 升至 1.0 (强化 Focal Loss 对裂缝分类的学习), 分布损失权重(dfl)保持 1.5 不变。

固定随机种子(seed = 42), 关闭 cudnn.benchmark (设为 False), 在保证训练结果完全可复现的前提下, 维持模型训练稳定性。

4. 实验与结果分析

4.1. 实验数据集与环境

4.1.1. 数据集

本文实验采用幽络源平台公开的混凝土裂缝裂纹 YOLO 专用数据集[18], 该数据集为面向工程场景的自制标注数据集, 适用于墙体、边坡、桥梁等混凝土结构的裂缝检测任务。原始数据集包含 5964 张已完成 YOLO 格式边界框标注的图像, 裂缝实例总数为 16,865, 无预设验证集与测试集, 本文依据裂缝检测领域通用划分策略, 按 7:2:1 的比例对原始数据进行随机划分, 最终得到训练集 4332 张、验证集 1143 张、测试集 489 张, 所有图像统一调整为 640×640 分辨率以适配模型输入要求。

4.1.2. 实验环境

硬件: NVIDIA GeForce RTX 4060Ti GPU、12th Gen Intel (R) Core (TM) i5-12600KF (3.70 GHz) CPU、32 GB 内存。

软件: Python 3.10.19、PyTorch 2.4.1、Ultralytics 8.3.241、CUDA 11.8。

4.2. 实验设置

对比模型: 原始 YOLOv8n、YOLOv8n-BiFPN、YOLOv8n-BiFPN-CA、YOLOv8n-BiFPN-CA-FocalLoss。

评价指标: mAP50 (IoU = 0.5 时的平均精度)、召回率(Recall)、精确率(Precision)、FPS (每秒帧率)。

训练参数: epochs = 200, batch_size = 16, 输入尺寸 640×640 , 重复实验 3 次取平均值。

4.3. 实验结果与分析

为验证各改进模块的贡献, 进行消融实验, 结果如表 1 所示:

Table 1. Ablation experiment results

表 1. 消融实验结果

模型	mAP50	召回率	精确率	FPS
YOLOv8n_vanille	0.7175	0.6518	0.7122	106.56
YOLOv8n-BiFPN	0.7824	0.7144	0.7613	77.89
YOLOv8n-BiFPN-CA	0.7843	0.7232	0.7587	109.99
YOLOv8n-BiFPN-CA-FocalLoss	0.8364	0.7696	0.8384	95.14

在基线模型中引入 BiFPN 后, 模型 mAP50 提升至 0.7824 (+6.49%), 召回率提升至 0.7144 (+6.26%), 精确率提升至 0.7613 (+4.91%), 验证了双向特征融合能有效增强多尺度裂缝特征的表达, 但推理速度降至 77.89 FPS; 在 BiFPN 基础上集成 CoordAttention 后, 模型 mAP50 和召回率提升不明显, 但推理速度回升。

为验证 CoordAttention 模块对推理速度的影响是否具备偶然性, 本实验在相同硬件环境下, 对 YOLOv8n-BiFPN 与加入 CA 后的模型进行了连续 10 轮推理测速。实验结果如表 2 所示:

Table 2. FPS comparison table
表 2. FPS 对比表

模型	平均 FPS	标准差
YOLOv8n-BiFPN	71.06	4.440
YOLOv8n-BiFPN + CA	69.05	4.150

结合数据分析可知, 二者的标准差差异较小, 且单次测试结果存在交叉。这说明在 YOLOv8n-BiFPN 结构中引入 CoordAttention 并未带来推理速度的提升, 反而由于特征融合维度的增加, 带来了轻微的计算开销。这一现象表明, CoordAttention 的加速效果并非普适性的必然结果, 其性能表现与具体的 Neck 结构及特征图维度高度相关。

在 BiFPN + CA 的基础上引入优化后的 FocalLoss 后, 模型性能达到最优: mAP50 提升至 0.8364 (+5.21%), 召回率提升至 0.7696 (+4.64%), 精确率提升至 0.8384 (+7.97%), 推理速度稳定在 95.14 FPS。这说明 FocalLoss 有效缓解了裂缝检测中正负样本不平衡问题, 大幅提升了模型对裂缝目标的识别能力, 同时保持了良好的实时性。

4.4. 可视化对比图

为直观验证本文提出的 YOLOv8n-BiFPN + CoordAttention + FocalLoss + 自定义细长锚框改进模型在混凝土裂缝检测任务中的有效性, 选取细长连续裂缝、密集网状裂缝、低对比度细微裂缝、复杂背景干扰裂缝 4 类典型场景, 如图 5 所示, 将原始 YOLOv8n 模型(图 5 中第一行)与本文改进模型(图 5 中第二行)的检测结果进行可视化对比分析。



Figure 5. Visual comparison chart
图 5. 可视化对比图

可视化对比实验表明, 相较于原始 YOLOv8n, 本文改进模型在细长裂缝完整性、小尺度裂缝检出率、

复杂背景抗干扰性等方面均实现了显著提升。

5. 结论和展望

各改进模块均对混凝土裂缝检测性能有正向增益：BiFPN 通过双向特征融合显著提升多尺度裂缝检测精度，CoordAttention 在轻量化约束下进一步强化空间特征表达，FocalLoss 则有效解决正负样本不平衡问题。最终组合模型(YOLOv8n-BiFPN-CA-FocalLoss)相比基线模型，mAP50 提升 11.89%，召回率提升 11.78%，精确率提升 12.68%，同时保持 95.14 FPS 的实时推理速度，在精度与效率间实现了最优平衡，验证了本文改进方案的有效性。

该改进模型虽结合 BiFPN、CoordAttention、FocalLoss 与细长锚框提升了混凝土裂缝检测效果，但仍存在模块集成僵化、损失函数优化不全面、训练策略缺乏针对性、工程兼容性差、泛化验证不充分等问题。同时，模型未实现自适应锚框聚类、专属数据增强与轻量化效率平衡，在复杂工程场景下的检测精度、鲁棒性与部署实用性仍有较大提升空间。

参考文献

- [1] 王煜, 齐宏拓, 杨整涛, 等. 基于联合调优的裂缝检测与分类方法[J]. 仪表技术与传感器, 2025(7): 78-83.
- [2] 张治成, 刘金童. 基于图像配准技术的裂缝变化检测方法[J]. 低温建筑技术, 2023, 45(7): 94-98.
- [3] 沙爱民, 童峥, 高杰. 基于卷积神经网络的路表病害识别与测量[J]. 中国公路学报, 2018, 31(1): 1-10.
- [4] 吴雄华, 周小玲, 王渝清. ResNet+网络模型混凝土裂缝识别方法研究[J]. 公路, 2025, 70(10): 381-388.
- [5] 范琪, 包超, 曹纪兴, 等. 基于轻量化 Light-UNetV3 的混凝土裂缝检测方法研究[J/OL]. 工程科学与技术, 1-14. <https://link.cnki.net/urlid/51.1773.TB.20251114.1716.011>, 2025-12-23.
- [6] Jiang, F., Wang, G., He, P., Zheng, C., Xiao, Z. and Wu, Y. (2022) Application of Canny Operator Threshold Adaptive Segmentation Algorithm Combined with Digital Image Processing in Tunnel Face Crevice Extraction. *The Journal of Supercomputing*, 78, 11601-11620. <https://doi.org/10.1007/s11227-022-04330-9>
- [7] 郭运冲, 李孟军, 刘名果, 等. 基于 Canny 算子的建筑裂缝边缘检测改进算法[J]. 计算机仿真, 2022, 39(11): 360-365+410.
- [8] 谭兆, 王保宪, 秦守鹏, 等. 基于边缘增强感知的混凝土裂缝病害检测方法[J]. 铁道科学与工程学报, 2023, 20(8): 3172-3180.
- [9] 王建锋, 邱雨, 刘水宙. 基于图像补偿的隧道衬砌裂缝检测方法[J]. 浙江大学学报(工学版), 2022, 56(7): 1404-1415.
- [10] Yang, Z., Li, L. and Luo, W. (2022) PDNet: Improved YOLOv5 Nondeformable Disease Detection Network for Asphalt Pavement. *Computational Intelligence and Neuroscience*, 2022, 1-21. <https://doi.org/10.1155/2022/5133543>
- [11] Teng, S., Liu, Z. and Li, X. (2022) Improved YOLOv3-Based Bridge Surface Defect Detection by Combining High- and Low-Resolution Feature Images. *Buildings*, 12, Article 1225. <https://doi.org/10.3390/buildings12081225>
- [12] Wu, Y., Han, Q., Jin, Q., Li, J. and Zhang, Y. (2023) LCA-YOLOv8-Seg: An Improved Lightweight YOLOv8-Seg for Real-Time Pixel-Level Crack Detection of Dams and Bridges. *Applied Sciences*, 13, Article 10583. <https://doi.org/10.3390/app131910583>
- [13] 陈述, 赵亚伟, 王光明, 等. 基于 SSG-YOLOv8n 模型的砖砌墙体裂缝形态识别方法[J]. 工业建筑, 2025, 55(7): 152-161.
- [14] 许靖, 裴树军, 裴洪扬. 改进 YOLOv8 的密集车辆检测算法[J]. 哈尔滨理工大学学报, 2026, 31(1): 24-34.
- [15] 曹莉凌, 胡浩宇, 曹守启. DUIE-YOLO: 一种基于图像增强的水下鱿鱼目标检测算法[J]. 上海海洋大学学报, 2026, 35(1): 254-269.
- [16] 任启超, 吴利刚, 张茗源, 等. 基于轻量化的高帧率块煤检测方法[J/OL]. 太原理工大学学报, 1-9. <https://link.cnki.net/urlid/14.1220.N.20260305.1705.002>, 2026-03-20.
- [17] 刘茜娜, 谢琨, 侯建军, 等. 糖尿病视网膜病变病灶自适应多标签识别模型[J]. 生物医学工程学杂志, 2025, 42(5): 892-900.
- [18] 幽络源. 裂缝裂纹 Yolo 数据集[EB/OL]. <https://www.youluoyuan.com/5634.html>, 2025-12-05.