

油气管道焊缝缺陷智能识别方法研究

李进涛¹, 罗仁泽^{1,2,3}, 刘琪¹

(1. 西南石油大学 电气信息学院; 2. 西南石油大学油气藏地质及开发工程全国重点实验室;
3. 西南石油大学 地球科学与技术学院, 四川 成都 610500)

摘要: 随着工业智能化的发展, 焊缝缺陷检测任务对检测精度和模型效率提出了更高要求。为提升 YOLO11 在焊缝缺陷检测中的性能, 提出一种结合多结构优化的改进 MPC-YOLO11 模型。首先, 构建全新的 C2PSA-MKP 结构, 以增强特征提取的多尺度建模能力; 其次, 提出基于 Pinwheel 卷积的改进型 C3k2-AP 结构, 增强模型对方向性特征和细粒度缺陷的感知能力; 再次, 在 3 个检测头前引入 ECAFM 注意力机制模块, 增强特征分配与目标表示能力; 最后, 通过在焊缝缺陷数据集上的实验, 验证了改进效果。结果表明, 改进后模型 mAP@0.5、mAP@0.5:0.95 及召回率分别提升 5.6%、6.9%、10.2%, 焊缝缺陷检测能力显著增强。

关键词: 焊缝缺陷识别; YOLO11; 目标检测; C2PSA; Bottleneck; ECA

DOI: 10.11907/rjdk.251693

中图分类号: TP391.41

文献标识码: A

文章编号: 1672-7800(XXXX)0XX-0001-09

扫描二维码阅读全文: 

Research on Intelligent Recognition Methods for Oil and Gas Pipeline Weld Defects

LI Jintao¹, LUO Renze^{1,2,3}, LIU Qi¹

(1. School of Electrical and Information, Southwest Petroleum University;
2. National Key Laboratory of Oil and Gas Reservoir Geology and Development Engineering, Southwest Petroleum University;
3. School of Earth Sciences and Technology, Southwest Petroleum University, Chengdu 610500, China)

Abstract: With the advancement of industrial intelligence, higher requirements for detection accuracy and model efficiency have been raised in weld defect detection tasks. To enhance the performance of MPC-YOLO11 in weld defect detection, an improved YOLO11 model combining multiple structural optimizations is proposed. First, a completely new C2PSA-MKP structure is constructed to enhance the multi-scale modeling capability of feature extraction. Second, an improved C3k2-AP structure based on Pinwheel convolution is designed to strengthen the perception of directional features and fine-grained defects. Third, the ECAFM module is embedded before the three detection heads to enhance feature allocation and object representation. Finally, experiments on a weld defect dataset verify the effectiveness of the proposed improvements. Results show the improved model increases mAP@0.5, mAP@0.5:0.95, and recall by 5.6%, 6.9%, and 10.2% respectively, significantly enhancing weld defect detection.

Key Words: weld defect recognition; YOLO11; object detection; C2PSA; Bottleneck; ECA

0 引言

油气管道是国家能源输送体系的重要组成部分, 而焊缝区域作为加工应力集中、结构稳定性薄弱的部位, 是最

容易产生裂纹、气孔、咬边、未熔合等多类型缺陷的关键位置^[1]。一旦焊缝缺陷未能及时发现与处理, 可能导致管道泄漏、爆裂、停输等严重事故, 造成巨大的经济损失和安全风险。因此, 开展焊缝缺陷检测研究对于保障油气管网的安全稳定运行具有重要意义。

收稿日期: 2025-12-18

作者简介: 李进涛(2000-), 男, 西南石油大学电气信息学院硕士研究生, 研究方向为基于深度学习的目标检测算法; 罗仁泽(1973-), 男, 博士, 西南石油大学电气信息学院教授、博士生导师, 研究方向为油气储层智能预测方法、油气勘探开发数据人工智能分析方法; 刘琪(2000-), 男, 西南石油大学电气信息学院硕士研究生, 研究方向为基于深度学习的目标检测算法。本文通讯作者: 李进涛。

传统无损检测方法如超声波^[2]、射线检测^[3]、磁粉检测等在工业领域得到广泛应用。然而,这些方法依赖昂贵设备和专业人员,检测效率有限,且对复杂环境下的多类型缺陷识别能力仍存在不足。随着工业数字化与智能化的发展,基于计算机视觉的焊缝图像检测方法逐渐成为研究热点。随着深度学习技术的飞速发展,将其应用于油气管道焊缝缺陷检测已成为研究热点^[4]。深度学习通过构建复杂的神经网络模型,能够从大量数据中自动学习特征,尤其在图像识别领域取得了显著的效果^[5]。

然而,焊缝缺陷具有小尺寸、细长形状和背景噪声复杂等特点,直接应用通用检测模型常面临小目标难以检出、特征表达不充分以及复杂纹理干扰显著等问题。因此,如何在保持实时性的前提下增强模型的细粒度特征提取能力、方向敏感性与抗噪性,是当前焊缝缺陷检测研究的主要挑战。基于此,本文提出一种基于深度学习的油气管道焊缝缺陷智能识别方法,旨在实现高精度、高效率的缺陷检测,从而降低管道泄漏风险,并保障管道运行安全^[6]。

1 相关工作

传统焊缝检测依赖人工操作,耗时长且工作强度大。通过引入深度学习技术,可大幅提升油气管道焊缝缺陷检测的效率与精度,克服传统检测方法效率低、误检漏检率高的不足,实现检测过程的智能化和自动化,从而有效降低人工成本和安全隐患。YOLO(you only look once)是由 Redmon 等^[7]于 2015 年提出的,是深度学习领域第一个单级检测器。YOLO 算法虽然速度较快,但也存在网格最多只会检测出一个目标、小目标检测效果较差,定位准度不足的缺点。Zhou 等^[8]提出了一种改进的 YOLOv7 方法,针对钢表面缺陷检测中存在的小缺陷难以识别和整体检测精度不足的问题,引入多尺度特征融合与注意力机制,以增强不同尺度缺陷的特征表达能力。此外,通过轻量化设计在保证检测性能的同时,有效降低了计算开销。Wang 等^[9]在焊缝图像处理中提出了一种基于多尺度策略的特征提取方法。该方法利用自适应高斯滤波对焊缝噪声进行预处理,并通过多尺度形态学结构元素提取焊缝的宏观轮廓与细节特征。不同尺度的结构元素能够增强焊缝在宽度、成形变化及局部细节上的表达能力,在焊缝成形识别中取得了较好效果。然而,该方法的多尺度机制仍存在不足:①结构元素由人工设定,尺度选择依赖先验经验,难以适应复杂多变的焊缝缺陷;②多尺度结构较为固定,对于形态差异大、背景噪声强的小缺陷,特征提取能力有限。Su 等^[10]在 MSA-YOLO 中提出多尺度条形卷积注意力(MS-CAM),利用不同尺度与方向的条形卷积来增强特征表达,从而提高模型在多尺度场景下的检测能力。同时,改进的 GS-PANet 采用 GSConv 与 GSC3 模块降低特征融合的计算

冗余,实现精度与效率的平衡。但该方法仍存在局限,如条形卷积对小目标的刻画能力有限,且在密集、遮挡场景中的鲁棒性不足,整体轻量化和跨尺度建模仍有改进空间。Han 等^[11]提出了 EDN-YOLO 方法,针对多尺度交通标志在复杂道路场景中易出现误检与漏检的问题,采用 EfficientViT 替换 YOLOv5s 原有骨干网络,以提升全局特征感知能力且不增加模型复杂度。同时,引入高效解耦检测头,将分类与回归任务分离处理,以增强模型对不同尺度目标的检测表现,并结合 CIoU 与 NWD 的混合损失,提高模型对小尺度交通标志的定位敏感度。尽管该方法在多尺度检测性能上取得显著提升,但其对极端小目标仍存在一定检测瓶颈,且解耦检测头在复杂背景中可能引入额外训练不稳定性。Haris 等^[12]提出了一种基于非对称卷积的 AK-CNN 车道线检测方法,针对传统卷积结构在复杂场景中计算量大、难以兼顾实时性与检测精度的问题,对网络首层卷积进行结构性改进。该方法采用 7×3、5×5 与 3×7 等多组非对称卷积核替代常规对称卷积,并结合不同方向的长条形卷积提升纵向特征提取能力,既保持了对车道线细长结构的敏感性,又显著降低了模型计算量,提高了整体处理速度。然而,该方法主要在首层卷积上进行轻量化设计,深层特征提取结构仍较为常规。Liao 等^[13]提出的 YOLO-DRS 在注意力机制方面的创新主要体现在设计 LEC(LDW-EMA-C3)轻量化多尺度注意力模块。该模块在 EMA 注意力的基础上,通过引入轻量化 LDW 卷积,增加 3×3 与 5×5 多尺度分支,并强化跨空间注意力建模,使网络能够在复杂背景中更有效地捕获小目标的通道与空间关键信息,从而提升多尺度特征表达能力。但 LEC 的注意力结构较为复杂,包含多卷积分支与跨空间注意力操作,导致部署成本上升。同时,该注意力模块对特征尺度和分组设计较敏感,不同场景下需重新调整参数,泛化性仍有限。

本文研究核心主要包括:①小目标与微细纹理难以提取,而焊缝中内凹、咬边、圆形等缺陷,尺寸小且结构细,容易在下采样过程中被淹没;②油气管道焊缝缺陷形态复杂且具有明显方向性,其中,裂纹与咬边通常呈细长分布,普通卷积对方向特征的感知能力较弱,难以有效提取其关键特征;③焊缝表面纹理、焊道光照及金属噪声等背景干扰较强,容易引发误检,进而对模型的特征选择与抗干扰能力提出了更高要求。为提升油气管道焊缝缺陷检测的精度与准确率,本文在 YOLO11 框架基础上进行了系统性改进,主要贡献为:①设计 C2PSA-MKP 结构;②提出基于 Pinwheel 卷积的改进型 C3k2-AP 结构;③在检测头部分嵌入 ECAFM 注意力机制。

2 MPC-YOLO11 算法

2.1 MPC-YOLO11 模型结构设计

YOLO11 是 Ultralytics 推出的 YOLO 系列实时目标检

测器的最新版本,其在架构设计与训练策略上实现了多项重要突破,以更高的精度、更快的速度与更优的效率重新定义了目标检测的性能标杆。该模型在继承前几代 YOLO 优秀特性的基础上,进一步强化了特征提取与多尺度信息融合能力,并显著减少了参数量,成为适用于多种视觉任务的强大工具。然而,尽管 YOLO11 在精度、速度与效率上均取得了显著提升,但在应对焊缝缺陷检测任务时仍然存在一定不足。例如,焊缝缺陷往往表现为尺度差异显著、边缘模糊、特征细粒度强等特点,导致模型在复杂背景下容易出现漏检情况。

针对上述问题,本文提出了一种结合多结构优化的改进 YOLO11 模型(MPC-YOLO11)。该方法在保持原有 YOLO11 高效性的基础上,设计了 C2PSA-MKP 模块。通过并行卷积核的多尺度特征提取能力,使模型能够更全面地捕获焊缝缺陷在不同尺度下的细节与结构信息,从

而提升对小目标缺陷和不规则形态的感知能力。此外,提出了基于 Pinwheel 卷积的细粒度特征增强结构 C3k2-AP,该模块通过多方向非对称填充与特征拼接的方式,有效补充了卷积在方向敏感性上的不足,进一步增强了局部细粒度特征的表达能力。该设计在保证网络计算复杂度基本不变的前提下,显著提升了模型对焊缝缺陷边界与纹理特征的刻画能力。在特征融合阶段,引入了跨层自适应特征注意力机制 ECAFM(ECA-augmented CAFM)。该模块通过在局部分支后嵌入高效通道注意力(ECA)机制,对特征图进行通道级的自适应重标定,并与全局自注意力分支进行互补融合。这种设计不仅增强了模型对关键缺陷通道的响应能力,而且提升了在复杂背景下的鲁棒性与泛化性,从而在焊缝缺陷检测任务中实现了更高的检测精度与召回率。整体的 MPC-YOLO11 算法网络结构如图 1 所示。




Fig. 1 Network structure of MPC-YOLO algorithm
图1 MPC-YOLO11算法网络结构

2.2 C2PSA-MKP结构设计

针对小目标难以检测,原 YOLO11 的 C2PSA (Cross Stage Partial with Pyramid Squeeze Attention)虽具备自注意力机制,但缺乏对局部细粒度多尺度结构的感知能力。为此,本文在 C2PSA 中引入多尺度卷积金字塔,通过 3×3、5×

5、7×7 的多尺度深度卷积构建多感受野特征,以增强模型对微小缺陷与复杂纹理的捕获能力。C2PSA 作为 yolo11 中新改进的结构,在原有的 C2f 模块上引入自注意力机制,来增强模型对全局依赖关系和关键区域的建模能力。这种设计在保证参数量与计算量较低的同时,有效提升了模

型对复杂背景和长距离依赖特征的捕捉能力。该模块依赖于特征单元间相似度计算的自注意力机制,在处理复杂焊缝缺陷图像时会带来较高的计算开销。此外,该机制在应对小尺度、低对比度及形态复杂的缺陷区域时,容易出现注意力分散与特征响应不足的问题,从而限制了模型的特征表达能力与检测精度^[14]。

针对上述不足,在 C2PSA 模块的基础上设计 C2PSA-MKP 模块。该模块引入多尺度卷积 MKP,通过增强特征提取能力的同时保持模块的轻量化^[15]。MKP 的核心思想是将 DWConv (Depthwise Convolution)^[16]与 PWConv (Pointwise Convolution)^[17]相结合,并通过多种卷积核尺寸(3×3、5×5、7×7),实现对局部细粒度特征与大尺度上下文信息的同时建模。首先,通过一个 3×3 的 DWConv 来捕捉基本的

局部特征,从而保证感受野扩展的基础;其次,通过 1×1 的 PWConv 来减少参数量的同时,增强非线性表示能力;再次,通过 5×5 DWConv 扩大感受野,建模更大范围的上下文信息;然后,通过 1×1 的 PWConv 对特征再次整合,保持轻量化,并通过 7×7 DWConv 进一步提升网络对大尺度缺陷或复杂模式的感知能力;最后,进行残差连接 F_5+x ,保留输入特征的同时增强梯度流动,从而避免深层网络训练过程中信息丢失。MKP 的计算过程公式如式(1)所示:

$$Y = \text{DWConv}_{7 \times 7}(\text{PWConv}_{1 \times 1}(\text{DWConv}_{5 \times 5}(\text{PWConv}_{1 \times 1}(\text{DWConv}_{3 \times 3}(X)))) + X \quad (1)$$

其中,输入特征 $X \in R^{B \times C \times H \times W}$ 。B 为 batch size, C 为通道数, H 和 W 为特征图的高宽, Y 为最终输出。C2PSA-MKP 结构图如图 2 所示。




Fig. 2 C2PSA-MKP architecture

图2 C2PSA-MKP 结构图

2.3 C3K2-AP 结构设计

针对缺陷方向性强而普通卷积方向敏感性弱,导致难以有效识别细长裂纹与咬边的问题,本文引入 Pinwheel 方向卷积与非对称填充,使模型在多个方向上建立更强的感受野,进而提升特征方向选择性。C3K2 模块是 Ultralytics 在 yolo11 中提出的对 CSP Bottleneck 结构的改进。该模块采用两个并行卷积层,并引入跨层连接和分组卷积(Group convolution)的概念^[18]。不仅提高了数据处理的速度,还保持了较高的精度。C3K2-AP 是在 C3K2 的基础上将 C3K2 中的 Bottleneck 基于 PConv (Pinwheel-shaped Convolution) 改进为 APBottleneck,以增强特征提取方向敏感性和跨通道特征融合能力^[19]。APBottleneck 引入了 4 种方向的非对称零填充 (Asymmetric Padding),将输入特征扩展为具有不同边界感知的特征子空间,并在水平方向和垂直方向上构造出多样化的感受野,使网络在保持轻量化的同时具备更强的方向选择性和空间建模能力^[20]。此外,利用残差增强信息流动,提升复杂纹理和不规则缺陷的建模能力。

APBottleneck 的计算过程如下:首先,将输入特征 $X \in R^{B \times C \times H \times W}$ 经过 4 种不同的非对称填充操作,即 $p = [(2, 0, 2, 0), (0, 2, 0, 2), (0, 2, 2, 0), (2, 0, 0, 2)]$,在左上、右下、左下、右上各填充 2 像素。通过模拟不同方向的感受野扩展,增强方向敏感性。随后,将其分别输入到轻量卷积单元 $\text{Conv}(k \times k)$,得到四组方向特征,并在通道维度进行拼接。其公式表达如式(2)所示:

$$Y_1 = \text{Concat}\left(\left\{\text{Conv}\left(\text{Pad}_i(X)\right)\right\}_{i=1}^4\right) \quad (2)$$

其中,Concat 为拼接操作,Pad 为填充操作,得到的特征 Y_1 通过主分支卷积层进行特征整合得到 Y_2 ,从而提取更高层的上文信息。同时,APBottleneck 在主分支输出的基础上,引入一个投影层 $\text{Proj}(\cdot)$ 对 Y_1 进行通道匹配,并与 Y_2 相加,形成分支增强特征,用于缓解卷积过程中信息丢失的问题。其公式表达如式(3)所示:

$$Y_{\text{branch}} = Y_2 + \text{Proj}(Y_1) \quad (3)$$

其中,Proj 表示用于通道对齐的 1×1 的卷积, Y_{branch} 是

分支残差相加的输出。通过引入全局残差, 将原始输入 X 与 Y_{branch} 相加得到最终的特征输出 Y 。C3K2-AP 结构图如图 3 所示。

2.4 ECAFM 注意力机制

为增强 CAFM (Convolution and Attention Fusion Module) 对通道重要性的自适应建模能力, 提出 ECAFM (ECA-augmented CAFM) [21]。ECAFM 在 CAFM 的局部分支 (local branch) 后嵌入了轻量级的高效通道注意力模块 ECA (Efficient Channel Attention), 以低成本且自适应的方式重标定局部特征的通道响应, 随后, 与原有的全局自注意力分支输出进行融合 [22]。该设计保持了 CAFM 从局部到全局的互补特性, 同时, 通过通道级重加权提高了局部分支对显著语义与细节特征的响应能力, 从而在小目标、复杂背景等场景下, 进一步提升了检测与定位性能。

ECAFM 构建了一种局部分支 (Local branch) 和全局分支 (Global branch) 并行的融合模块。其中, 局部分支用于提取细节丰富的局部空间的光谱特征。首先, 将输入特征 $X \in R^{B \times C \times H \times W}$ 通过一个调整通道维度的 $W_{1 \times 1}$ 卷积层, 并接上通道混洗 CS (Channel Shuffle) 操作以增强通道间的信息交换 [23]。随后, 采用一个 $W_{3 \times 3 \times 3}$ 的卷积来提取细粒度的局部特征。具体公式如式 (4) 所示:

$$F_{conv} = W_{3 \times 3 \times 3} * (CS(W_{1 \times 1}(X))) \quad (4)$$

得到输出结果 F_{conv} 后, ECA 对 F_{conv} 进行通道级重标定。首先, 进行全局平均池化 (GAP), 将 Z 视为长度 C 的序列, 做一维卷积 $Conv1d(1 \times 1, k_size)$, 得到 $S \in R^{B \times C}$; 其次, 用 sigmoid 得到通道权重 W_c ; 最后, 将通道权重与输出结果逐元素相乘, 得到局部分支结果 F_{local} 。具体公式如式 (5)–式 (7) 所示:

$$Z_c = \frac{1}{HW} \sum_{i,j} F_{conv}(b, c, i, j) \quad (5)$$

$$W_c = \sigma(S) \quad (6)$$

$$F_{local} = F_{conv} \odot W_c \quad (7)$$

全局分支主要用于捕获特征图中的长距离依赖关系与全局上下文信息。首先, 将输入特征通过一个 1×1 的卷积和一个 3×3 的深度卷积; 其次, 将张量沿通道维度切分为 3 个部分, 分别为 Query (Q)、Key (K) 和 Value (V), 形状均为 $\hat{H} \times \hat{W} \times \hat{C}$; 然后, 将张量 Q、K、V 分别重塑为 $\hat{Q} \in R^{\hat{H}\hat{W} \times \hat{C}}$ 、 $\hat{K} \in R^{\hat{C} \times \hat{H}\hat{W}}$ 、 $\hat{V} \in R^{\hat{H}\hat{W} \times \hat{C}}$, 在此基础上, 通过矩阵乘法计算通道注意力 A 图; 最终, 得到注意力图后对特征进行加权聚合, 将输出结果重新映射回原始空间尺寸, 同时, 通过一个最终的 1×1 卷积进行投影, 并添加残差连接




Fig. 3 Overall architecture and module structures of C3K2-AP

图 3 C3K2-AP 整体架构及模块结构图

以促进梯度流动。通道注意力图 A 如式(8)所示,全局分支输出公式如式(9)所示:

$$A = \text{soft max} \left(\frac{\hat{K}\hat{Q}}{\alpha} \right) \quad (8)$$

$$F_{\text{att}} = W_{1 \times 1} (\text{Attention}(\hat{Q}, \hat{K}, \hat{V})) + X \quad (9)$$

其中, α 是一个可学习的缩放参数,用于在 Softmax 操作前控制点积的大小,从而稳定训练过程。

最终,将局部分支输出和全局分支输出相融合,使得

ECAFM 同时具备局部卷积分支的细粒度特征建模能力和全局注意力分支的长程依赖捕获能力。ECAFM 保持了局部与全局的互补性,并通过引入 ECA 进一步提升了显著通道特征的选择性响应能力。不仅在小目标检测中增强了局部分辨率的细节保持能力,同时,在复杂背景场景下提供了更鲁棒的上下文建模能力,从而在整体上提升了检测与定位的精度和稳定性。ECAFM 结构图如图 4 所示。




Fig. 4 ECAFM architecture

图 4 ECAFM 结构图

3 实验结果与分析

3.1 评价指标及实验设置

本文实验采用目标检测常用指标查准率 P (Precision)、查全率 R (Recall) 和平均精度均值 mAP (mean average precision) 进行评估。其中, P、R 和 mAP 的计算公式如式(10)–式(13)所示:

$$P = \frac{TP}{TP + FP} \quad (10)$$

$$R = \frac{TP}{TP + FN} \quad (11)$$

$$AP = \int_0^1 P dR \quad (12)$$

$$mAP = \frac{1}{n} \sum_{j=1}^n AP_j \quad (13)$$

其中, TP 表示真正例,即把正例预测正确;FP 表示假正例,即把假例预测成正例;FN 表示假反例,即把正例预测成反例。AP 为某个目标类的平均精度, n 表示类别数量。本次实验结果中采用的 mAP 评价指标均为 mAP50, 其代表 IOU 阈值取 0.5 时 mAP 的值。

本文所有实验均在 NVIDIA GeForce RTX 4070 GPU 环境下完成,深度学习框架采用 PyTorch 2.4.1 (CUDA 12.4), 并基于 Ultralytics YOLO11 框架搭建模型训练平台。训练过程在 Windows 环境下进行,确保训练与验证步骤的稳定性和可重复性。

模型训练阶段使用输入尺寸 640×640, Batch Size 设置为 64, 总训练轮数 300 Epochs。优化器采用 SGD 确保训练

的稳定性,初始学习率为 0.01,并结合 Cosine 学习率衰减策略 (lr=0.01) 进行动态调整;动量设置为 0.937,权重衰减为 0.000 5。为避免训练初期模型不稳定,采用 3 轮 Warmup 策略,并启用 AMP 自动混合精度训练和 Deterministic 确定性训练策略,以提高训练效率并保证可复现性。

实验数据集为自主构建的油气管道焊缝缺陷数据集,共有 304 8 张图片,分为 6 种缺陷,如图 5 所示。




Fig. 5 Defects in oil and gas pipeline welds

图 5 油气管道焊缝缺陷

3.2 对比实验及结果分析

为验证 MPC-YOLO11 模型的有效性与优越性,本文在焊缝缺陷检测数据集上开展对比实验,并与主流目标检

测算法及其改进版本进行性能比较。实验主要从检测精度(mAP@50、mAP@50:95)、召回率(Recall)以及模型复杂度(参数量、GFLOPs)等多个指标对模型性能进行评估,以全面衡量模型在精度与效率之间的平衡性。不同算法检测结果对比,如表1所示。

Table 1 Comparison of detection results from different algorithms

表 1 不同算法检测结果对比

算法	Recall	mAP@50	mAP@50:95	Parameters/10 ⁶	GFLOPs
Yolov5n	0.827	0.879	0.581	1.76	4.2
YOLO10n	0.799	0.905	0.656	2.70	8.2
YOLO11n	0.802	0.894	0.617	2.58	6.3
MGSF-YOLO ^[24]	0.832	0.917	0.675	2.81	7.8
CACS-YOLO ^[25]	0.879	0.925	0.661	2.65	7.0
MPC-YOLO11	0.904	0.950	0.686	3.00	7.4

由表1可知,不同检测算法在焊缝缺陷检测数据集上的性能表现存在明显差异。在检测精度方面,MPC-YOLO11模型在 Recall、mAP@50 和 mAP@50:95 三个指标上

均取得最佳结果,分别达到 0.904、0.950 和 0.686,相较于 YOLO11n 分别提升了 10.2%、5.6% 和 6.9%。尤其在 Recall 指标上的提升,表明 MPC-YOLO11 有效缓解了漏检问题,具备更强的缺陷捕获能力。

从模型复杂度来看,MPC-YOLO11 的参数量和计算量分别为 3.00M 和 7.4GFLOPs,仅略高于 YOLO11n,但与 CACS-YOLO、MGSF-YOLO 等改进模型处于同一量级。这说明,提出的改进并未显著增加计算开销,仍能保持较好的轻量化特性。

综合对比可见,MPC-YOLO11 在保证较低模型复杂度的同时显著提升了检测精度,实现了精度与效率的良好平衡。这一结果验证了所提出的多尺度特征增强与轻量化结构设计的有效性,为焊缝缺陷的智能检测提供了更具鲁棒性和实用性的解决方案。

为进一步验证所提出 MPC-YOLO11 模型在复杂焊缝缺陷场景下的检测效果,选取典型缺陷样本对 YOLO11 与改进模型的检测结果进行可视化对比,图像测试比较如图6所示。




Fig. 6 Comparison of oil and gas pipeline weld defect images

图 6 油气管道焊缝缺陷图像测试比较

从图6可以看出,MPC-YOLOv11在缺陷区域的定位精度更高,检测框更加贴合目标边界。模型输出的置信度显著高于YOLO11,说明其特征提取能力更强。此外,在一些尺寸较小、对比度较低的缺陷上,YOLO11往往存在漏检或低置信度的问题,而MPC-YOLOv11依然能够稳定识别。结果表明,MPC-YOLO11在复杂焊缝背景下能够更加准确地定位缺陷区域,对小目标缺陷与边缘模糊缺陷具有更高的识别精度,同时,有效降低了漏检情况。

3.3 消融实验及结果分析

本文在YOLO11基础网络上设计了消融实验,分别在基线模型中逐步引入C3K2-AP模块、C2PSA-MKP模块以及ECAFM注意力机制,并在相同的数据集和训练策略下进行对比实验。通过对比不同组合下的Recall、mAP@50和mAP@50:95指标,可以定量分析各改进模块对检测性能的提升效果。消融实验结果如表2所示;消融实验结果对比图如图7所示。

由表2和图7可知,所有提出的模块均能有效提升模型性能。在Recall、mAP@50和mAP@50:95指标上,模型分别提升了10.2%、5.6%和6.9%,显著优于基线模型,证明

Table 2 Ablation experiment results

表 2 消融实验结果

C2PSA-MKP	C3K2-AP	ECAFM	Recall	mAP@50	mAP@50:95	Parameters/10 ⁶	GFLOPs
×	×	×	0.802	0.894	0.617	2.58	6.3
√	×	×	0.874	0.918	0.659	2.62	6.3
×	√	×	0.808	0.903	0.633	2.46	6.2
×	×	√	0.848	0.916	0.675	3.09	7.5
√	√	×	0.868	0.936	0.675	2.50	6.2
√	×	√	0.864	0.94	0.682	3.12	7.5
×	√	√	0.779	0.869	0.568	2.96	7.4
√	√	√	0.904	0.950	0.686	3.00	7.4

了模块间协同设计的有效性。

此外,C2PSA-MKP特征融合模块将召回率显著提升了7.2%,且几乎不增加模型复杂度。而C3K2-AP轻量化瓶颈结构独具特色,在实现mAP指标稳定提升的同时,使参数量减少4.7%,体现了减参增效的效果。ECAFM注意力机制作为性能提升的核心驱动力,单独使用即可显著将mAP@50和mAP@50:95分别提升2.2%和5.8%,尽管参数量与计算量分别增加了19.8%和19.0%,但收益远超成本。




Fig. 7 Comparison of ablation experiment result

图7 消融实验结果对比图

这表明, C2PSA-MKP 和 C3K2-AP 的多尺度特征提取能力与 ECAFM 的全局上下文建模优势形成互补, 使模型在所有精度指标上均达到顶峰。C2PSA-MKP 和 ECAFM 组合虽在 mAP 指标上表现优异, 但计算代价最大。C2PSA-MKP 与 C3K2-AP 模块协同作用, 在实现卓越检测性能的同时, 使 mAP@50 提升了 4.2%, 且模型参数量与计算量均低于基准模型, 展现出良好的精度与效率平衡能力。C3K2-AP 和 ECAFM 组合因 C3K2-AP 的轻量化操作破坏了 ECAFM 所需的特征结构, 导致性能显著退化, 这一结果凸显了模块间兼容性设计的关键性。

4 结语

本文针对油气管道焊缝缺陷检测任务提出了一种结合多结构优化的改进模型 MPC-YOLO11。在保持原始 YOLO11n 轻量化与高效性的基础上, 引入了 3 种改进策略: 多核卷积特征建模 C2PSA-MKP、C3k2-AP 结构以及跨层自适应特征注意力 ECAFM。同时, 3 个改进模块分别从多尺度特征增强、方向敏感性提升以及特征选择优化 3 个角度, 针对性解决了焊缝缺陷检测中的核心难点, 使改进后的 YOLO11 模型在精度与鲁棒性上均显著优于原始网络。实验结果表明, 在油气管道焊缝缺陷数据集上, MPC-YOLO11 相较于基础 YOLO11n, 召回率由 0.802 提升至 0.904, mAP@50 由 0.894 提升至 0.950, mAP@50:95 由 0.617 提升至 0.686, 整体性能提升显著。与此同时, 参数量仅由 2.58M 增加至 3.00M, 计算量由 6.3GFLOPs 增加至 7.4GFLOPs, 保持了较好的轻量化与计算效率。

尽管 MPC-YOLO11 在检测精度和召回率上均优于基础模型, 但其在参数量和计算复杂度上仍有一定提升。此外, 在极端复杂背景或模糊图像下, 仍存在一定的漏检现象。未来的工作将从以下 3 个方面展开: ①进一步优化模型结构, 实现更高效的特征提取与表示, 从而降低计算开销; ②探索更合理的样本划分与正负样本平衡策略, 以进一步提升召回率; ③构建更大规模、多场景的焊缝缺陷数据集, 以增强模型在实际工业场景中的泛化能力。本文提

出的 MPC-YOLO11 在保证轻量化的同时有效提升了焊缝缺陷检测的精度, 为油气管道的智能化检测提供了一种高效可行的解决方案。

参考文献:

- [1] ZHAO S Q. Research on risk and inspection of corrosion behavior of offshore pressure vessels [J]. China Equipment Engineering, 2023 (24): 168-170.
赵士奇. 海上压力容器腐蚀行为的风险与检验研究[J]. 中国设备工程, 2023 (24): 168-170.
- [2] CHEN Y, CHEN L, WANG Y, et al. Prediction model of weld ultrasonic testing results based on EasyEnsemble and XGBoost algorithm [J]. Ship Engineering, 2022, 44(4): 134-139.
陈毓, 陈亮, 汪琰, 等. 基于 EasyEnsemble 和 XGBoost 算法的焊缝超声波检测结果预测模型[J]. 船舶工程, 2022, 44(4): 134-139.
- [3] ZHANG X F, YAN Y, ZHOU W L, et al. Technical equivalence of phased array ultrasonic testing and traditional radiographic testing for welds of fine-grained ferritic steel pipes in nuclear power plants [J]. Non-destructive Testing, 2021, 43(3): 21-26.
张晓峰, 严宇, 周伟璐, 等. 核电细晶铁素体钢管道焊缝相控阵超声检测与传统射线检测的技术等效性[J]. 无损检测, 2021, 43(3): 21-26.
- [4] ZOU Z, CHEN K, SHI Z, et al. Object detection in 20 years: a survey [J]. Proceedings of the IEEE, 2023, 111(3): 257-276.
- [5] SUN J Y, XU M J, ZHANG J P, et al. Optimization and improvement of YOLOv8 target detection algorithm from drone perspective [J]. Computer Engineering and Applications, 2025, 61(1): 109-120.
孙佳宇, 徐民俊, 张俊鹏, 等. 优化改进 YOLOv8 无人机视角下目标检测算法[J]. 计算机工程与应用, 2025, 61(1): 109-120.
- [6] GUO Q M, LIU N B, WANG Z X, et al. Review of object detection algorithms based on deep learning [J]. Journal of Detection & Control, 2023, 45(6): 10-20, 26.
郭庆梅, 刘宁波, 王中训, 等. 基于深度学习的目标检测算法综述[J]. 探测与控制学报, 2023, 45(6): 10-20, 26.
- [7] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C]//IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [8] ZHAO C, SHU X, YAN X, et al. RDD-YOLO: a modified YOLO for de-

- tection of steel surface defects[J]. Measurement, 2023, 214: 112776.
- [9] WANG L, LIU X, MA J, et al. Real-time steel surface defect detection with improved multi-scale YOLO-v5 [J]. Processes, 2023, 11 (5): 1357.
- [10] SU Z, YU J, TAN H, et al. MSA-YOLO: a remote sensing object detection model based on multi-scale strip attention [J]. Sensors, 2023, 23 (15): 6811.
- [11] HAN Y J, WANG F P, WANG W, et al. EDN-YOLO: multi-scale traffic sign detection method in complex scenes [J]. Digital Signal Processing, 2024, 153: 104615.
- [12] HARIS M, MALIK A, HOU X, et al. Lane line detection and departure estimation in a complex environment by using an asymmetric kernel convolution algorithm [J]. The Visual Computer, 2022, 39(2): 1-20.
- [13] LIAO H, ZHU W. YOLO-DRS: a bioinspired object detection algorithm for remote sensing images incorporating a multi-scale efficient lightweight attention mechanism [J]. Biomimetics, 2023, 8(6): 458.
- [14] XU J, JIA Y A, WANG Z F. Steel surface defect detection algorithm based on improved YOLO11n [J/OL]. Progress in Laser and Optoelectronics, 2025-08-15. <https://link.cnki.net/urlid/31.1690.TN.20250815.1532.052>.
- 徐洁,贾宇昂,汪志锋. 基于改进YOLO11n的钢材表面缺陷检测算法 [J/OL]. 激光与光电子学进展, 2025-08-15. <https://link.cnki.net/urlid/31.1690.TN.20250815.1532.052>.
- [15] XIAO Y, XU T, XIN Y, LI J. FBRT-YOLO: faster and better for real-time aerial image detection [C]// Proceedings of the AAAI Conference on Artificial Intelligence, 2025: 8673-8681.
- [16] CHOLLET F. Xception: deep learning with depthwise separable convolutions [C]// IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1800-1807.
- [17] ZHANG H, MA Y, ZHANG K, et al. FMGNet: an efficient feature-multiplex group network for real-time vision task [J]. Pattern Recognition, 2024, 156: 110698.
- [18] WEI H, WANG Z, HUA G. Dynamically mixed group convolution to lighten convolution operation [C]// International Conference on Artificial Intelligence and Big Data, 2021: 203-206.
- [19] YANG J, LIU S, WU J, et al. Pinwheel-shaped convolution and scale-based dynamic loss for infrared small target detection [C]// AAAI Conference on Artificial Intelligence, 2025: 9202-9210.
- [20] DING X H, ZHANG X Y, MA N N, et al. RepVGG: making vgg-style convnets great again [C]// 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021: 13728-13737.
- [21] HU S, GAO F, ZHOU X, et al. Hybrid convolutional and attention network for hyperspectral image denoising [J]. IEEE Geoscience and Remote Sensing Letters, 2024, 21: 1-5.
- [22] WANG Q, WU B, ZHU P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks [C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11531-11539.
- [23] ZHANG X, ZHOU X, LIN M, et al. ShuffleNet: an extremely efficient convolutional neural network for mobile devices [C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 6848-6856.
- [24] MA S, LI R, HU H. Train track fastener defect detection algorithm based on MGSF-YOLO [J]. The Journal of Supercomputing, 2025, 81 (3): 494.
- [25] CAO Z, CHEN K, CHEN J, et al. CACS-YOLO: a lightweight model for insulator defect detection based on improved YOLOv8m [J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 3530710.

(责任编辑:陈维捷)