

基于改进 YOLOv8n 的管道超声图像缺陷识别方法研究

张仙伟¹, 张阳¹, 尤杰²

(1. 西安石油大学 计算机学院, 西安 710065;

2. 中海油(天津)管道工程技术有限公司, 天津 300450)

摘要: 管道缺陷检测作为管道安全管理的重要组成部分, 对保障管道安全至关重要, 超声波检测技术可用于识别和评估管道的内部缺陷; 针对人工分析检测数据存在的执行效率低、漏检误检等问题, 提出了一种基于改进 YOLOv8n 的管道超声图像缺陷识别方法; 在 YOLOv8 的 C2f 模块中引入动态蛇形卷积, 增强对缺陷的特征提取能力, 将空洞卷积集成到 SPPF 模块, 以减少缺陷信息损失, 通过共享组卷积检测头, 降低模型复杂度的同时提高对缺陷的定位能力; 实验结果表明, 改进的 YOLOv8n 算法能够实现管道超声图像自动缺陷检测, 且改进后的模型与原模型相比, mAP50 提升了 2.1%, 计算量和参数量下降了 15% 和 7%; 较其他主流检测算法, 综合表现最佳。

关键词: 超声波检测; 管道; 自动缺陷检测; 超声图像; YOLOv8 算法

Recognition Method for Pipeline Ultrasound Image Defects Based on Improved YOLOv8n

ZHANG Xianwei¹, ZHANG Yang¹, YOU Jie²

(1. School of Computer Science, Xi'an Shiyou University, Xi'an 710065, China;

2. Tianjin Pipeline Engineering Technology Co., Ltd., CNOOC, Tianjin 300450, China)

Abstract: As an important component of pipeline safety management, it is crucial for pipeline defect detection to ensure pipeline safety, and ultrasonic testing technologies can be used to identify and assess internal defects in pipelines. To address issues such as low execution efficiency and false or missed detection in manual analysis of testing data, a defect recognition method for pipeline ultrasonic images based on an improved YOLOv8n model is proposed. The dynamic serpentine convolution is introduced into the C2f module of the YOLOv8 to enhance feature extraction capabilities for defects. Dilated convolutions are integrated into the spatial pyramid pooling fast (SPPF) module to reduce the information loss of defects, and a shared group convolution detection head is used to reduce the complexity of the model while improving the accuracy of defect localization. Experimental results demonstrate that the improved YOLOv8n algorithm can automatically detect defects in pipeline ultrasonic images. Compared to the original model, the improved model increases the mAP50 by 2.1% and reduces the computational complexity and parameters by 15% and 7%, respectively. The improved model outperforms other main-stream detection algorithms in overall performance.

Keywords: ultrasonic testing; pipeline; automatic defect detection; ultrasonic image; YOLOv8 algorithm

0 引言

管道是长距离运输石油、天然气等资源最常用的设备, 在工业领域有着不可替代的地位。然而随着使用年限的增加和环境的变化, 管道会受到腐蚀、磨损、意外

损伤等因素产生缺陷, 这不仅会成为安全隐患, 严重可能发生泄漏或爆炸等安全事故。超声检测、漏磁检测等无损检测方法能够在不对材料结构造成任何损害的情况下检测缺陷^[1], 有效预防潜在的管道安全事故。

超声波检测是一种成熟的无损检测技术, 可用于识

收稿日期:2025-03-18; 修回日期:2025-04-23。

作者简介:张仙伟(1973-),男,博士,教授。

引用格式:张仙伟,张阳,尤杰. 基于改进 YOLOv8n 的管道超声图像缺陷识别方法研究[J]. 计算机测量与控制, 2026, 34(3):130-137,145.

别和评估管道的内部缺陷。超声波检测因其多功能性在多种无损检测方法中脱颖而出^[2], 其具有两个突出优势, 例如对大多数材料的高灵敏度, 以及更易于提取缺陷位置和尺寸规格^[3]。超声成像的基本原理是利用超声波在不同物质之间的介质特性差异及其在物质内部的传播特性产生扫查图像^[4]。在管道检查过程中, 超声内检测器常用的探头类型称为相控阵探头, 使用相控阵探头可以提高检查的可靠性。当超声内检测器沿着管道移动时, 在每个时钟方向, 探头都会发射和接收超声能量。在超声 A 扫描的表示中, 接收到的能量通常显示为回波信号振幅随时间的变化。当探头沿管道移动时, 通过提取不同位置的回波信号特征, A 扫描波形可以可视化为 B 扫描图像和 C 扫描图像。其中, B 扫描图像反映管道剖面特征, C 扫描则提供其特征的俯视图。与 A、C 扫描相比, B 扫描的优点是保留了缺陷的空间信息, 并有助于将缺陷与噪声或其他几何形状产生的回波区分开来。

超声波检测对缺陷进行定量定位分析^[5]是其关键内容, 过程主要分为采集和分析所采集的数据两个阶段, 而对数据进行判读是评估管道缺陷的重中之重。近年来, 超声数据采集都是利用机器设备自动进行的, 但分析检测数据仍然是人工完成的。人工分析检测数据存在着主观性强、耗时长、执行效率低、漏检误检等诸多问题。为了解决这些挑战, 通过自动化的分析手段, 不仅能够提高检测效率, 还能显著降低人工误差, 提升诊断的准确性和可靠性。

在超声图像的缺陷识别中, 基于深度学习的目标检测方法已经有了应用。由于超声数据可以以图像的形式表示, 因此可以应用计算机视觉算法来分析图像的内容并定位缺陷。如文献 [6] 提出的改进的 YOLOv3 算法对钢轨缺陷 B 扫描图像进行识别, 最终平均精度可达 87.41%。文献 [7] 提出基于调整超参数的 Efficient-Det^[9] 架构对钢块缺陷进行 B 扫描图像识别, 平均准确率达到 89.6%, 此外, 还提出了 DefectDet^[8] 架构, 通过优化特征提取网络和检测头, 在钢块缺陷识别上取得了更好的效果, 平均准确率为 91.3%。文献 [10] 提出改进的 YOLOX 算法, 对相控阵超声缺陷图谱进行智能识别, 实现了对聚乙烯管道电熔接头缺陷的自动识别。在管道缺陷识别方面, 文献 [11] 提出了使用深度卷积神经网络结合预训练的支持向量机分类器的方法识别管道缺陷, 对管道环焊缝缺陷进行了分类实验, 证明了该方法优于传统的超声模式识别方法。文献 [12] 提出了一种基于多特征融合的超声管道缺陷识别模型, 在特征提取步骤中使用不同类型的变换, 如小波包变换或离散变换, 并使用支持向量机作为分类器, 其模型在缺陷识别上的分类准确率达到 96.29%。文献 [13] 提出

了一种基于遗传算法优化的支持向量机方法来识别管道缺陷, 通过筛选和排序超声回波信号的特征以提取缺陷信息, 实现了对管道缺陷类型的精确识别, 对不同缺陷类型的平均识别准确率达到 99%。近年来, 众多学者也提出了不同的算法来自动识别管道缺陷^[14-16], 这些方法主要集中在卷积神经网络、支持向量机等, 通过特征提取和分类模型进行缺陷的自动识别, 很少有研究者将该技术应用在管道超声 B 扫图像缺陷识别领域, 在管道 B 扫图像中自动识别缺陷仍是一个挑战。

本文提出一种基于改进 YOLOv8n 算法的管道超声图像缺陷自动识别方法。该方法基于 YOLOv8n 目标检测网络, 对图像中存在的缺陷进行检测。同时为解决图像中干扰信息多、缺陷纵横比较大等问题, 本文改进了 YOLOv8n 算法, 并进行了实验验证。

1 YOLOv8 网络结构

YOLO (You Only Look Once) 系列算法是目标检测领域最为著名和应用广泛的深度学习算法之一。YOLO 算法的最大特点是采用单次前向传播同时完成目标的分类和定位任务, 实现了端到端的目标检测。随着 YOLO 系列算法的不断发展, YOLOv8 作为一个重要的迭代版本, 在性能和应用范围上取得了显著的提升。除了在通用目标检测任务中表现出色外, YOLOv8 还在工业检测等多个领域中得到了广泛应用。

YOLOv8 模型由主干网络、颈部网络和检测头 3 个关键组件组成, 分别用于特征提取、特征融合和预测输出, 其网络模型结构如图 1 所示。

YOLOv8 采用了与 YOLOv5 类似的主干网络, 其主干网络仍然遵循 CSP (CSPDarkNet-53) 思想, 在对输入特征进行 5 次下采样后, 基于 5 种不同的尺度依次提取图像特征。这一部分与 YOLOv5 的不同之处在于, YOLOv8 将传统的 C3 模块替换为 C2f 模块。C3 模块只能对相邻的 BottleNeck 结构进行简单处理, 提取的特征信息有限, 无法进行跨层传递。相比之下, C2f 模块增强了跨层信息传递, 消除了分支中的卷积操作, 并增加了额外的分割操作。这使得 YOLOv8 在保持轻量化的同时, 能够获得更丰富的梯度流信息, 从而提高了特征提取的能力。此外, 在 YOLOv8 网络的最后一层还加入了 SPPF (Spatial Pyramid Pooling Fast) 结构, 用于将池化输出连接成固定长度的特征向量, 实现自适应尺寸输出。与 SPPF 的加入大大提高了 YOLOv8 对遮挡、模糊和小目标的检测能力, 使其能够在各种复杂环境下实现更为精确的目标检测。

在颈部部分, YOLOv8 继续使用 FPN (Feature Pyramid Network) 和 PAN (Path Aggregation Network) 结构的结合来进行图像特征的多尺度融合, 用

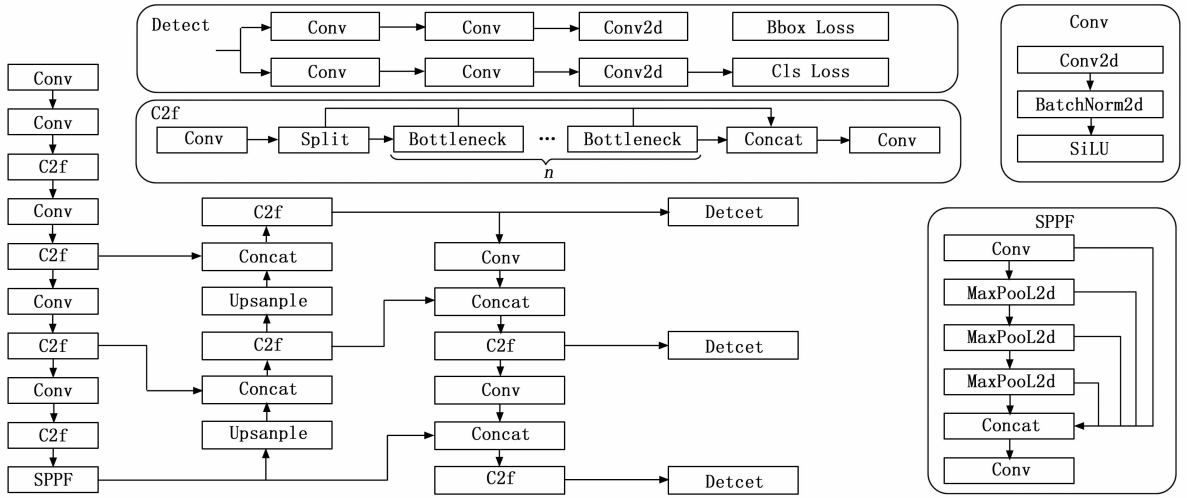


图 1 YOLOv8 网络结构图

于增强对不同尺寸特征图的处理能力。FPN 从上到下进行上采样，而 PAN 则从下到上进行下采样，两者的双向融合有效地实现了位置和语义信息的互补，使得不同尺寸的特征图同时包含图像的语义信息和图像特征信息，从而提高了对不同尺寸图像的检测精度。这种上下结合的方式，确保了网络在处理图像的各个尺度时都能兼顾位置和语义信息。另外，YOLOv8 在 PAN-FPN 上采样阶段不再继续使用卷积结构，这一改变确保了模型在保持高效性能的同时，保持了更高的轻量化。

在检测头部分，YOLOv8 采用了当前主流的解耦头结构，将目标分类头和检测头分开。解耦头为不同尺度设计了独立的检测器，每个检测器由卷积层和全连接层组成，用于该尺度的目标分类和边界框回归任务。目标分类任务使用二元交叉熵损失 (BCE, Binary Cross Entropy)，并参考 VFL (Virtual Field Loss) 的非对称加权操作来处理目标类别的不平衡。BCE 能够有效地衡量每个目标类别的分类误差，并在训练过程中通过梯度下降优化模型，而 VFL 则通过调整类别权重来增强少数类目标的训练效果。对于边界框回归任务，YOLOv8 使用了 CIoU (Complete Intersection over Union) 和 DFL (Distribution Focal Loss)，用于更精确地衡量目标框的回归误差。CIoU 不仅考虑了目标框的重叠区域，还增加了目标框之间的距离和长宽比差异，而 DFL 则通过对框的回归分布进行聚焦处理，以降低容易错误的框回归的影响，进一步提高回归精度。此外，YOLOv8 放弃了传统的基于锚框的方法，转而采用无锚点的设计。这种方式不再依赖先验的锚框，而是通过学习直接预测目标框的位置，从而简化了正负样本的区分和处理流程。无锚点方法不容易受到锚框预设的限制，能够有效处理不同形状和大小的目标。最终，检测头通过使用下采样特征进行多尺度预测，实现了对小型、中型和大

型目标的精确预测。

总之，YOLOv8 相较于前几个版本，融合了多项创新技术，不仅提升了对不同尺寸和复杂环境下目标的检测能力，还保持了实时性和高效性，使其成为一种适应广泛应用场景的先进目标检测模型。

2 改进的 YOLOv8 模型

在 YOLOv8n 框架的基础上从三个方面进行改进：在 C2f 模块引入动态蛇形卷积，通过灵活的特征融合和动态的感受野增强模型特征提取能力；使用空洞卷积改造 SPPF 模块，保留更多细节信息，使其能够更有效地捕获目标的局部特征信息；在检测头应用可共享参数的组卷积，在减少模型参数的同时保留特征共享能力，有效减少了模型中冗余的计算开销。改进模型如图 2 所示。

2.1 改进 C2f 模块

在 YOLOv8 的 C2f 模块中，原始的 Bottleneck 单元由两个常规卷积层堆叠而成，这样的结构在处理复杂任务时容易产生计算冗余，影响特征信息的有效提取。在超声 B 扫图像中，缺陷总是沿垂直方向伸长，且存在背景噪声干扰，所以从管道超声图像中检测缺陷的问题主要是缺陷的细长特征。传统的 Bottleneck 模块的固定卷积核无法灵活适应图像中的细节变化，导致难以提取缺陷特征，从而影响模型的整体检测精度和效率。由于超声图像中的缺陷总是细长的，因此在卷积过程中不需要在两个方向上进行处理，这可以通过特定卷积来实现，从而更关注与缺陷方向一致的特征。

动态蛇形卷积^[17] (DSConv, dynamic snake convolution) 是一种高效、动态可调的卷积神经网络结构，旨在通过动态调整卷积核的形状和尺寸，以适应不同输入特征的多样性。这一技术通过灵活的卷积路径设计，在保持较低计算复杂度的同时显著提高了特征提取的准

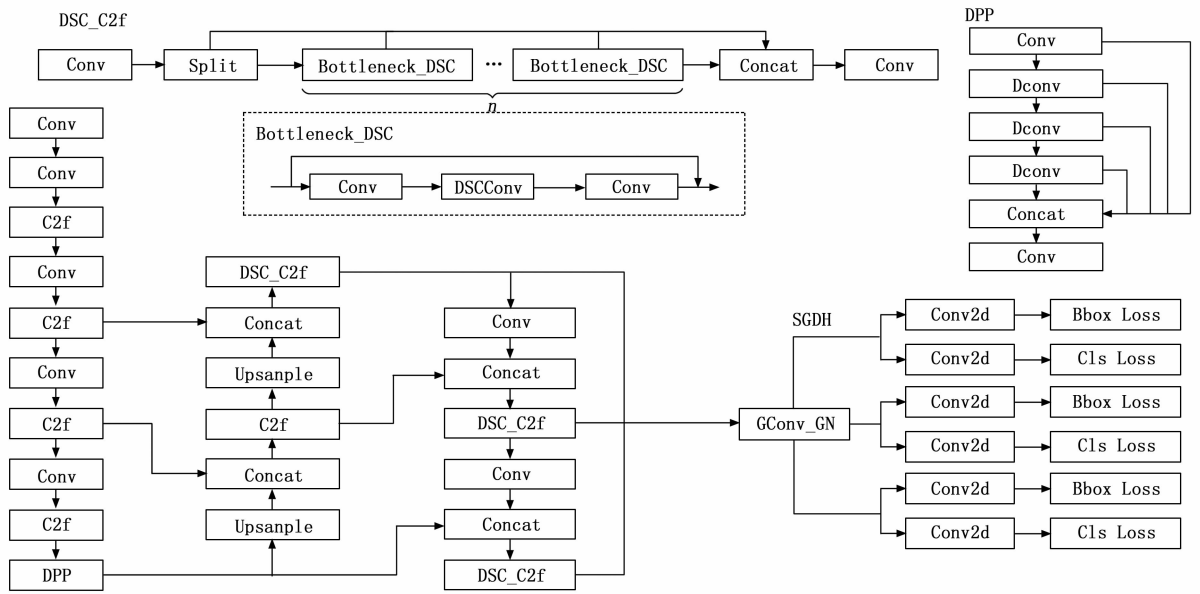


图 2 改进的 YOLOv8n 网络结构图

确性与效率。动态蛇形卷积能够动态适应具有细长、复杂特征的管状结构, 本文将其融入 C2f 中的 Bottleneck 结构, 以增强模型在超声图像中对细长、复杂缺陷特征的捕捉能力, 且不需要大幅增加计算负担。通过在不同卷积路径上集成多层特征信息, 模型能够更加精准地识别并定位缺陷区域, 同时维持较低的计算开销。该改进后的结构被命名为 DSC_C2f, 并如图 3 所示。




图 3 DSC_C2f 结构

在图 3 中, Bottleneck_DSC 模块主要由动态蛇形卷积和普通卷积组成。其采用三层卷积, 输入特征首先经过一个常规卷积, 然后加入动态蛇形卷积, 最后再通过一个常规卷积。第一个卷积提取基础信息, 动态蛇形卷积适应图像中的细长缺陷, 最后一个卷积进一步整合特征。具体而言, 对于一个标准的二维卷积, 卷积核 K 的尺寸为 3×3 , 其中心坐标为 (x_i, y_i) , 这个卷积核将会覆盖以 (x_i, y_i) 为中心的图像区域, 形成 3×3 的邻域, 则卷积核覆盖的点集为:

$$K = \{(x-1, y-1), (x, y-1), \dots, (x+1, y+1)\} \quad (1)$$

这意味着卷积核是以固定形状进行卷积, 可能难以有效捕捉到超声图像中的细长缺陷。而 DSConv 可以根据输入图像的内容, 尤其是细长缺陷的位置、方向和形状来动态调整卷积核的形状, 其卷积核的中心坐标会沿

x 轴和 y 轴进行线性处理, 以 x 轴为例, 动态调整的卷积核计算公式如下表示:

$$K_{\pm c} = \begin{cases} (x_{i+c}, y_{i+c}) = (x_i + c, y_i + \sum_i^{i+c} \Delta y) \\ (x_{i-c}, y_{i-c}) = (x_i - c, y_i + \sum_{i-c}^i \Delta y) \end{cases} \quad (2)$$

其中: $(x_{\pm c}, y_{\pm c})$ 是线性化后的卷积核的中心坐标, $c=0, 1, 2, 3, 4$ 表示与中心坐标的水平距离, 偏移量 $\Delta = \{\delta \mid \delta \in [-1, 1]\}$ 。根据该公式, 卷积核的位置会随着 c 的变化而动态偏移, 而 y 坐标在每次偏移时受到一个累计变化量 Δy 的影响。 (x_{i+c}, y_{i+c}) 表示卷积核在进行偏移时, x 坐标保持线性增长, 而 y 坐标会进行累计变化。同样, (x_{i-c}, y_{i-c}) 表示卷积核在另一个方向上的偏移也会影响 x 和 y 的坐标。由此偏移量需要进行累加, 每个点的位置会依赖于前一个点的位置, 这意味着卷积核的形状会根据超声图像中的局部特征进行变化, 特别是图像中的细长目标形态。

在 y 轴变化的公式如下:

$$K_{\pm c} = \begin{cases} (x_{j+c}, y_{j+c}) = (x_j + \sum_j^{j+c} \Delta x, y_j + c) \\ (x_{j-c}, y_{j-c}) = (x_j + \sum_{j-c}^j \Delta x, y_j - c) \end{cases} \quad (3)$$

由于偏移量是分数值, 因此它们的整数坐标通过双线性插值计算得到, 公式表示为:

$$K = \sum_{K'} B(K', K) \cdot K' \quad (4)$$

在这里, K 表示公式 (2) 和 (3) 中的分数位置, 而 K' 列举了所有的整数空间位置。 B 是双线性插值核, 目的是在进行卷积时, 对分数位置的坐标进行插值计算, 以保证能够准确地映射到实际的空间位置。重要的是, 双线性插值核可以分解为两个一维核, 分别在水平方向和垂直方向进行插值, 从而实现精确的空间位置

映射。

基于上述公式的分析，DSConv 可以在 x 轴和 y 轴方向上动态调整，在其变形过程中能够灵活覆盖更多区域。这样的设计基于动态结构，能够更准确地匹配细长的管状结构，从而更精确地捕捉关键特征。总的来说，累积偏移量增强了卷积核对不同结构的适应性，能够灵活调整卷积过程，而双线性插值核则通过平滑过渡，减少信息损失，提供更加精确的特征提取。两者分别从不同的角度优化了特征提取过程，有效提升了模型的性能。

将动态蛇形卷积融入 C2f 模块，在多尺度特征融合方面，在保持高效的计算性能的同时，可以更精确地适应超声图像中形态复杂的目标，尤其在面对小目标、细长目标或复杂背景时，能够大幅提高模型的检测精度和鲁棒性。通过实验验证，动态蛇形卷积不仅能提升特征提取的能力，还能在多尺度任务中优化检测效果，进一步增强 C2f 模块的优势。

2.2 改进 SPPF 模块

在 SPP 结构出现之前，卷积神经网络要求输入图像的大小是固定的。这一固定尺寸的限制主要来源于全连接层，这种限制降低了对不同尺寸或大小的图像的识别准确性。为了克服这一问题，文献 [18] 提出了在全连接层之前加入空间金字塔池化层，这样的改进使得模型不再依赖输入图像的大小，并且通过多尺度池化增强了网络的特征提取能力，显著提高了边界框预测速度。SPPF 是 SPP 的改进版本，该结构将大感受野分解为多个小感受野，形成 SPP 结构的串联结构，从而降低了 SPP 的时间复杂度。

SPP 和 SPPF 都采用最大池化作为下采样操作，最大池化易于使用和理解，但仍有改进空间。最大池化操作通过选取区域内的最大值来代表该区域，从而实现降维的效果。然而，这种方法仅保留了最大值的信息，导致许多细节信息丢失，同时在抗噪声能力上表现较差。在超声图像缺陷检测中，由于缺陷的形状规则、样式简单，如果采用最大池化，可能无法充分保留细节信息，从而导致较多的误检和漏检。同时大多数超声图像中存在较多噪声，最大池化操作可能会影响特征信息的准确表达，导致检测结果的不准确。因此，尽管最大池化能够有效降低特征图的维度，但它可能会忽略重要的局部信息，影响模型的整体表现。

针对这一问题，本文借鉴文献 [19] 中的 SPPF 改进策略，使用空洞卷积^[20] (Dconv, dilated convolution) 改造 SPPF。空洞率的设置直接影响感受野的大小以及对细节的保留，不同的空洞率对感受野的扩展也有所影响。空洞卷积如图 4 所示，图 4 (a) 对应空洞率为 1 的 3×3 卷积，和普通的卷积操作一样，感受野

仅为 3×3 。图 4 (b) 对应空洞率为 2 的 3×3 卷积，每个元素有一个间隔，感受野增大为 5×5 。图 4 (c) 对应空洞率为 3 的 3×3 卷积，每个元素有两个间隔，感受野增大为 7×7 。较高的空洞率可以进一步增加感受野，但可能会在某些情况下导致细节丢失，较小的空洞率可以避免因过度扩展感受野而丧失局部信息。考虑到超声图像中噪声和复杂纹理可能导致缺陷特征难以识别，本文设置空洞率为 2，其能够在扩大感受野的同时，保持适度的细节保留，有效平衡感受野的扩展与图像信息的保留，从而提高缺陷检测的精度。




图 4 空洞卷积

改进后的结构被命名为 DPP (Dilated Pyramid Pooling)，并如图 5 所示。在原始的 SPPF 模块中，其将输入通过不同大小的最大池化层并行处理，然后进行进一步的特征融合。将最大池化替换成空洞卷积，主要目的是利用空洞卷积的扩张感受野能力，使得模型能够在不同采样的情况下捕捉更大范围的上下文信息。虽然卷积操作的计算量大于最大池化操作，但空洞卷积能够有效地扩展感受野，而不会丢失重要的空间信息。DPP 结构相较于 SPPF 结构有更大的感受野，能够更好地处理多尺度特征并保持较高的细节保留，有助于提高检测精度，在实际检测中表现更好。




图 5 DPP 结构

2.3 轻量化检测头

YOLOv8 在不同尺寸的特征层级上分别使用了独立的检测头，这导致了检测头部分占据了整个模型大部分的参数量。由于超声图像缺陷样式单一，为避免计算冗余，实现模型轻量化设计，本文基于分组卷积和共享卷积思想，提出了共享组卷积检测头 (SGDH, shared group convolutional detection head)。

在 SGDH 中，卷积层在所有特征层之间共享，使用相同的卷积核和权重，如图 6 所示。该共享结构不仅有效减少了模型中的冗余参数，还增强了不同尺度间特征的一致性。通过将相同的卷积核应用于不同尺度的特

征层, 模型被迫学习这些尺度之间的一致特征表示。这种方法对于检测形态相似但尺寸不同的目标尤为重要。共享参数使得模型能够有效地捕捉不同尺度间的共同特征, 从而提高了目标识别能力并增加了检测准确率。

SGDH 接收多个特征图作为输入, 表示为 x_i 。为了减少卷积层中的冗余, SGDH 采用了共享卷积策略, 在多个特征层之间应用相同的卷积核和权重。通过此策略, 参数量将大大减少, 每个输入特征层的 x_i 会通过共享卷积模块。具体来说, 所有特征会先通过一个分组卷积进行通道调整, 该分组卷积使用 3×3 的卷积核, 将输入通道分为若干组, 每个组内独立地进行卷积操作, 以确保所有特征层的通道数统一。随后通过组归一化 (GN, group normalization) 对卷积操作的输出进行处理, 以提高网络训练的稳定性, 同时使用非线性激活函数 SiLU (Sigmoid Linear Unit) 对特征进行固定, 使输出具有非线性变换能力。这样的设计能够有效捕捉多尺度和复杂特征, 降低过拟合风险, 同时减少了模型的计算量和内存消耗。SGDH 检测头如图 6 所示, GConv_GN 过程可以表示为:

$$Y_i = SiLU\{GN[GConv_{3 \times 3} \cdot (x_i)]\} \quad (5)$$

其中: $GConv_{3 \times 3}$ 表示 3×3 的组卷积, GN 表示组归一化, SiLU 表示激活函数。

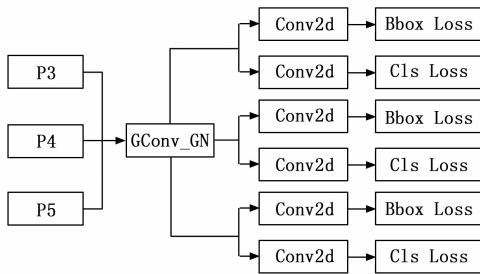


图 6 SGDH 结构

与传统的批归一化相比, 组归一化在小批量训练场景中提供了更优越的稳定性和适应性。其基于特征的通道维度进行归一化, 并且与批次大小无关, 从而即使在小批量情况下也能保持稳定的性能。这增强了训练效率并加速了收敛过程。此外, GN 基于每个样本对特征进行归一化, 消除了批次之间的依赖, 促进了稳定的梯度流。

通过将共享卷积层与组归一化结合, SGDH 有效地平衡了模型复杂性和检测性能。共享卷积层通过权重共享减少了参数冗余, 从而改善了特征一致性并增强了多尺度检测能力。同时, 组归一化在小批量训练过程中提供了强健的特征归一化, 促进了有效的梯度流, 并提高了训练效率和泛化能力。这种设计不仅优化了计算资源的使用, 而且确保了模型在保持高效性的同时, 能够提供准确的预测和稳定的性能。

3 实验与分析

3.1 数据集

本实验使用的数据是通过超声内检测器采集两条 12 英寸海底管道获得的, 缺陷是由于工业实际生产过程中导致的, 其类型主要是腐蚀性内缺陷。扫描数据原始为 DAT 数据文件, 通过超声分析软件转换为 B 扫描图像。经过数据清洗, 实验共建立 1 650 张超声图像作为数据集, 每张图像的大小均为 320×320 像素。收集了所有数据后, 采用 LabelImg 软件对缺陷进行标注, 并以 $8:2:1$ 比例划分训练集、验证集和测试集, 数量分别为 1 200、300 和 150。数据集中的一些示例图像如图 7 所示。




图 7 部分管道 B 扫描图像示例图

3.2 实验环境

所有实验基于 PyTorch 深度学习框架, 均在表 1 的软硬件环境中进行, 数据增强由 YOLO 默认的方法实现。

表 1 实验环境

名称	配置
操作系统	Windows10
CPU	Inter(R) Core(TM)i5-12400F
GPU	NVIDIA GeForce RTX 2080Ti
编译环境	python3.10+pytorch2.1.2+cuda11.8

网络模型使用随机梯度下降 (SGD) 优化器, 其中初始学习率设为 0.01, 初始动量设置为 0.937, batch-size 设置为 16, 最大训练轮数为 100, 并在训练过程中使用权衰策略, 权重系数为 0.000 5, 不加载预训练权重。在训练过程中, 数据集被增强, 这通常是为了提高模型的泛化能力和精度。使用了以下增强方法: Mosaic 混合增强、模糊、随机翻转和视觉效果 (对比度、亮度、颜色增强) 等, 这些增强操作均为 YOLOv8 检测器默认配置。

3.3 评估指标

在本研究使用平均精度均值 (mAP) 来评估模型的准确性。此外, 我们还使用模型参数数量 (Params) 和计算复杂度 (FLOPs) 作为定量指标, 评估模型的复杂程度。这些指标提供了一个全面且客观的评估, 衡量模型在指定检测任务中的表现。具体而言, mAP50 表

示在 IoU 阈值设置为 0.5 时的平均精度均值, 参数量 (Params) 反映了模型内参数的总数以及存储需求, 计算复杂度 (FLOPs) 衡量模型每秒执行的浮点运算次数, 是衡量其计算需求的指标。计算 mAP 的公式如下:

$$P = \frac{TP}{TP + FP} \quad (6)$$

$$R = \frac{TP}{TP + FN} \quad (7)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (8)$$

3.4 消融实验

为了验证改进模型中各模块在超声图像检测任务中的有效性, 本节进行了详细的消融实验。通过依次去除或替换关键组件, 本节中分析了 3 种不同的改进方式对整体模型的贡献和影响, 其中改进的 C2f 模块、改进的 SPPF 模块、轻量化检测头模块分别用 A、B、C 代替。这些消融实验旨在评估每个组件的独立性能贡献和协同效应, 从而提供对模型设计的全面理解。实验结果如表 2 所示。

表 2 消融实验

YOLOv8n	A	B	C	P/%	R/%	mAP 50/%	Params /M	FLOPs /G
√				84.6	85.0	92.2	3.0	8.1
√	√			85.8	86.9	93.3	3.3	8.6
√		√		88.6	84.3	93.7	3.1	8.5
√			√	83.7	85.6	93.0	2.3	5.5
√	√	√		85.0	86.9	94.2	3.5	9.0
√		√	√	86.9	84.5	93.5	2.5	5.9
√	√	√	√	88.3	86.4	94.3	2.8	6.2

如表 2 所示, 将颈部网络中原始的 C2f 模块替换为 DSC_C2f 模块, 准确率、召回率和 $mAP50$ 分别提升了 1.2%、1.9% 和 1.1%, 尽管计算成本相对增加。这表明 DSC_C2f 在提高模型性能的同时, 并未显著增加计算负担。在此基础上加入 SPPF 改进, 模型精度提升为 2%, 尽管计算量和参数量有所增加, 但相较于其他单独改进, 这一组合有效提升了模型的整体性能。单独改进 SPPF 模块时, 其效果在三种单独改进中最好, 准确率和 $mAP50$ 显著提升了 4.0% 和 1.5%, 其计算负担略有增加, 但在提升检测精度方面表现出了显著的优势。在此基础上改进检测头时, 模型复杂度降低, 相较于基线模型, 计算量和参数量分别下降了 27% 和 16%。单独改进检测头时, 模型复杂度降至最低, 相较于基线模型 $mAP50$ 提升了 0.8% 的同时, 计算量和参数量分别下降了 32% 和 23%, 适用于计算资源有限的应用场景。最后, 同时添加三种改进方式时, 模型达到了最优的综合性能, 准确率、召回率和 $mAP50$ 均达到了最高值, 同时保持了较低的计算开销, 相较于基线模型, 模

型精度提升了 2.1%, 计算量和参数量分别下降了 15% 和 7%。总体而言, DSC_C2f 和 DPP 主要用于提高模型的检测精度, SGDh 能够在降低模型计算成本的同时提高检测精度, 且三种改进方式对精度提升均有一定的效果, 实验证明了最终的改进模型相较于基线模型具有显著的有效性和效率。

3.5 对比实验

为了进一步验证本研究提出的改进的 YOLOv8 模型的检测性能, 我们进行了与几种流行物体检测算法的对比实验。选定的对比模型包括多个版本的 YOLO。对比结果总结如表 3 所示。

表 3 对比实验

算法	P/%	R/%	mAP 50/%	Params /M	FLOPs /G	FPS
YOLOv3-tiny	82.6	87.8	91.9	12.1	19.0	215
YOLOv5n	84.6	86.4	92.4	2.5	7.2	261
YOLOv6n	85.1	85.8	91.0	4.2	11.9	236
YOLOv8n	84.6	85.0	92.2	3.0	8.1	248
YOLOv9t	84.2	87.3	92.5	2.0	7.8	214
YOLOv10n	80.7	85.1	88.8	2.7	8.4	267
YOLO11n	85.4	84.6	92.7	2.5	6.3	282
本文	88.3	86.4	94.3	2.8	6.2	194

从表 3 中可以看出, 本文所提出的改进的 YOLOv8n 算法在管道超声图像缺陷检测任务中的精确度、召回率和 mAP 均表现优异, 精确的达到了 88.3%, $mAP50$ 为 94.3%, 较原模型分别提升了 3.7% 和 2.1%, 且均超越了其他主流模型。相较于同尺寸的 YOLOv10n、YOLO11n 模型, 检测性能实现较大提升, mAP 分别增长 5.5% 和 1.6%。尽管在参数量和计算量上略高于一些小型模型, 但其在计算效率和检测性能之间取得了良好的平衡。在检测速度方面, 虽然低于其他模型, 但每秒 194 帧的检测速度仍能满足检测需求。整体来看, 本文模型在保持较低参数量和计算需求的同时, 显著提升了目标检测的准确性。

如图 8 是 YOLOv8n 和改进的 YOLOv8n 两种检测模型在 $mAP@50$ 的变化情况, 在训练初期, 两个模型的 $mAP@50$ 值都经历了显著的提升。不过, 改进模型的 $mAP@50$ 提升速度更快, 在前 20 个 epoch 内迅速增高, 表现出了更快的收敛速度。另外, 改进 YOLOv8n 模型的精度大部分都高于 YOLOv8n 模型。相较之下, YOLOv8n 在前期的提升稍微平缓, 收敛速度较慢。这表明本文提出的模型有着更好的训练效率和性能。

为了直观展现改进后的算法相较于原算法检测精度的提升, 本文将以原网络与改进后的网络在测试集上的表现进行对比。如图 9 所示, 图 9 (a) 表示原始 YOLOv8n 网络检测结果, 图 9 (b) 表示改进后的网络

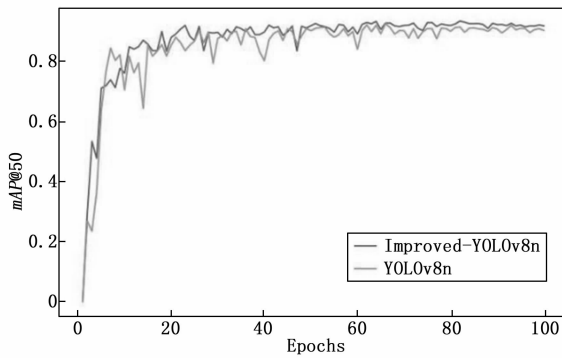


图8 精度对比曲线图

检测结果。从对比分析结果可以明显观察到, 原网络在识别缺陷点时存在漏检、误检现象, 改进后的网络检测置信率有所提升, 减少了漏检、误检现象, 具有良好的检测效果。在实际检测中, 延迟和内存占用是影响 YOLOv8n 模型工程实用性的关键因素。虽然改进后的 YOLOv8n 略显逊色, 但凭借其较低的计算需求和较高的检测精度, 依然能够满足大多数实时检测的需求。通过进一步的优化, 如硬件加速、模型压缩等, 未来可以在保证检测精度的前提下, 进一步提高推理速度, 增强模型在工程中的适用性。




图9 YOLOv8n 网络与改进后网络效果对比图

4 结束语

针对管道超声图像识别中存在的问题, 本文提出一种基于改进 YOLOv8n 的管道超声图像缺陷自动检测算法。从 C2f 模块、SPPF 模块、检测头 3 个方面对模型进行全面改进, 通过在 C2f 模块引入动态蛇形卷积网络, 显著增强模型捕捉细长目标特征的能力; 在 SPPF 中集成空洞卷积网络, 有效扩大模型感受野, 减少信息丢失, 提升模型对缺陷的敏感度; 采用共享组卷积检测头, 增强网络在多尺度目标检测中的表现, 有效提高检测精度和效率。改进的 YOLOv8n 算法实现超声图像中缺陷的有效检测, 缺陷识别的精度较原模型有较大的提

升, 模型平均检测精度达到 94.3%。通过消融实验和对比试验证明, 本文提出的算法相较于现有的主流算法在识别精度和计算量上均具有明显优势。随着超声检测应用的增加和超声检测设备的进步, 数据分析正成为超声缺陷检测的主要挑战, 本文所提出的方法对于减少数据分析所需的时间有很大的帮助。缺陷自动检测可以提高分析数据的效率, 提升数据分析的准确性, 并将在超声检测中发挥更加重要的作用。

参考文献:

- [1] DWIVEDI S K, VISHWAKARMA M, SONI PROF A. Advances and researches on non destructive testing: a review [J]. Materials Today: Proceedings, 2018, 5 (2): 3690-3698.
- [2] POSILOVIC L, MEDAK D, SUBASIC M, et al. Flaw detection from ultrasonic images using YOLO and SSD [C] //2019 11th International Symposium on Image and Signal Processing and Analysis (ISPA). Dubrovnik, Croatia: IEEE, 2019: 163-168.
- [3] YE J, ITO S, TOYAMA N. Computerized ultrasonic imaging inspection: from shallow to deep learning [J]. Sensors, 2018, 18 (11): 3820.
- [4] 陈秋华, 王怀江. 基于多尺度超声成像的缺陷识别与量化分析 [J]. 化工自动化及仪表, 2024, 51 (5): 929-933, 944.
- [5] 翟昕玥. 管道超声波检测数据处理与缺陷识别方法研究 [D]. 沈阳: 沈阳工业大学, 2020.
- [6] CHEN Z, WANG Q, YANG K, et al. Deep learning for the detection and recognition of rail defects in ultrasound B-scan images [J]. Transportation Research Record: Journal of the Transportation Research Board, 2021, 2675 (11): 888-901.
- [7] MEDAK D, POSILOVIC L, SUBASIC M, et al. Automated defect detection from ultrasonic images using deep learning [J]. IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control, 2021, 68 (10): 3126-3134.
- [8] MEDAK D, POSILOVIC L, SUBASIC M, et al. Defect-Det: a deep learning architecture for detection of defects with extreme aspect ratios in ultrasonic images [J]. Neurocomputing, 2022, 473: 107-115.
- [9] TAN M, PANG R, LE Q V. Efficientdet: Scalable and efficient object detection [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10781-10790.
- [10] 陈天亮, 王强, 许卫荣, 等. 基于改进 YoloX 算法的 HDPE 管接头 TFM 相控阵超声图谱缺陷识别 [J]. 声学技术, 2024, 43 (4): 495-502.

(下转第 145 页)