

孙可欣, 王影. 改进 YOLOv7 的零件目标检测算法[J]. 智能计算机与应用, 2025, 15(2): 175-181. DOI: 10.20169/j.issn.2095-2163.24091206

# 改进 YOLOv7 的零件目标检测算法

孙可欣, 王影

(吉林化工学院 信息与控制工程学院, 吉林 吉林 132022)

**摘要:** 为了在不增加计算复杂度的情况下提升零件的识别精度, 本文提出一种基于改进 YOLOv7 的零件目标检测算法。首先, 引入 SA 注意力机制帮助模型更好地聚焦于图像中的关键特征, 抑制不必要的特征, 使模型能够更精确地聚焦于图像的最重要方面, 从而提高检测精度; 其次, 引入高效卷积模块 ConvNeXt 替换部分 ELAN 模块, 降低模型的计算复杂度; 最后, 引入 NAM 注意力机制构建 MP-NAM 模块, 提高算法对零件的检测能力。实验结果表明, 改进 YOLOv7 算法在自制数据集上的精确率和均值平均精度分别达到 0.964 和 0.925, 相比原始 YOLOv7 算法有较大的提升; 同时计算复杂度有显著的下降, 约为原始算法的 37.4%; 与主流目标检测算法相比, 改进 YOLOv7 算法具有更好的检测性能, 也证明了改进算法在零件目标检测的有效性。

**关键词:** 零件; 目标检测; YOLOv7; 注意力机制; ConvNeXt

**中图分类号:** TP391.41 **文献标志码:** A **文章编号:** 2095-2163(2025)02-0175-07

## Research on part target detection of improved YOLOv7

SUN Kexin, WANG Ying

(College of Information and Control Engineering, Jilin Institute of Chemical Technology, Jilin 132022, Jilin, China)

**Abstract:** In order to significantly enhance the recognition accuracy of various parts without increasing the overall computational complexity, an advanced part target detection methodology predicated on the improved YOLOv7 algorithm was introduced. This method incorporates several key advancements to optimize performance. In the first place, the Shuffle Attention Mechanism is introduced to help the model better focus on key features in the image and suppress unnecessary features. This adjustment allows the model to focus more precisely on the most important aspects of the image, leading to improved detection accuracy. Further more, the efficient ConvNeXt convolutional module is introduced to replace some ELAN modules to reduce the computational complexity of the model. The ConvNeXt module helps streamline processing, making the model more efficient and faster. In conclusion, the NAM attention mechanism is introduced to construct MP-NAM module to improve the detection ability of the algorithm. The effectiveness of the improved YOLOv7 algorithm is clearly demonstrated through comprehensive experiments conducted on a custom dataset. The results show that the enhanced algorithm achieves a precision of 0.964 and a mean average precision (mAP) of 0.925. These metrics indicate a substantial improvement over the original YOLOv7 model. At the same time, the computational complexity of the improved model is reduced to approximately 37.4% of that of the original, highlighting a significant reduction in resource usage. Compared to other mainstream target detection algorithms, the improved YOLOv7 algorithm demonstrates notably superior detection performance, which effectively proves the high effectiveness and reliability of the improved algorithm in parts target detection.

**Key words:** part; target detection; YOLOv7; Attention Mechanism; ConvNeXt

## 0 引言

由于生产多种类小批量零件的柔性生产技术快

速发展, 零件归类分拣面临种类繁多、数目庞大、识别困难等难题<sup>[1]</sup>。传统的零件分类采用人工分拣, 不仅效率低且错误率高; 采用机器与计算机视觉相

**基金项目:** 吉林市科技局项目(201750244, 20190502118); 吉林化工学院科研项目(2018064); 吉林化工学院重大科技项目(2016033, 2018017)。

**作者简介:** 孙可欣(1999—), 女, 硕士研究生, 主要研究方向: 单片机, 智能机器人。

**通信作者:** 王影(1978—), 女, 硕士, 教授, 主要研究方向: 单片机, 智能机器人。Email: 1144191007@qq.com。

**收稿日期:** 2024-09-12

结合的方式不仅更加高效、客观、准确,同时也减少了人工成本<sup>[2]</sup>。

针对零件的分类问题,Yu等<sup>[3]</sup>提出了一种基于Inception-SSD(Single Shot MultiBox Detector)框架的零件检测方法,在一定程度上提高了对小目标的检测精度;Fang等<sup>[4]</sup>通过引入边缘检测头和注意力机制的方法,对YOLOv5s算法进行改进,提升目标检测的精度和准确性;Liu等<sup>[5]</sup>提出了一种基于深度学习架构的图像细节提取方法,对YOLOv3算法进行改进,使其更适合工业零件小目标分类检测;朱文博等<sup>[6]</sup>提出了一种基于轻量级的YOLOv4算法网络的零件检测方法,解决零件检测任务在复杂工况下存在实时性差、硬件资源占用大等问题。

基于计算机视觉的目标检测算法主要分为两类,分别是RCNN(Region-based Convolutional Neural Network)、Faster-RCNN为代表的两阶段目标检测算法(two-stage)和YOLO(You Only Look Once)系列、SSD为代表的单阶段(One-stage)目标检测算法<sup>[7-9]</sup>。两阶段目标检测算法相较于单阶段目标检测算法虽然准确性较高但检测速度慢,无法达到实时监测。目前,YOLO系列算法是单阶段目标检测算法主流。

YOLOv7算法与之前的版本相比较,在检测精度和检测速度方面有了显著的提升,但仍存在缺陷。原始YOLOv7特征提取不足,网络模型较复杂,计算复杂度较高,不利于实时检测,也不利于部署在便捷的设备上。本文提出一种基于改进YOLOv7的零件检测方法,改进后的算法能够降低模型计算复杂度,进一步提高零件检测精度。首先,添加SA(Shuffle Attention)注意力机制来提高网络的特征提取能力,使模型的均值平均精度提升;其次,引入ConvNeXt模块,降低模型的计算量,实现模型的轻量化;最后,设计MP-NAM(MaxPooling-based Normalization Attention Module)模块进一步提升模型的检测性能。

## 1 YOLOv7 目标检测算法

YOLOv7作为单阶段目标检测算法继承了YOLO系列算法检测速度快,精度高等特点,并对其进行了进一步的完善及提高<sup>[10]</sup>。

YOLOv7算法主要由输入层(Input)、主干网络(Backbone)和头部网络(Head)3部分构成<sup>[11]</sup>。输入层将图像缩放为640×640大小,并将其输入到主干网络中。主干网络中共有4个卷积模块(Convolution Bacth\_Normalization SiLu, CBS)、4个可扩展高效层聚

合网络模块(Efficient Layer Aggregation Network, ELAN)和3个下采样模块(MaxPooling and Convolution, MP)。CBS模块将卷积层Conv、批量归一化BN、激活函数SiLU进行整合,提高了速度。ELAN模块将6个卷积进行拼接后再连接一个卷积,使网络可以提取到更多的特征,具有更强的鲁棒性。MP模块通过最大池化Maxpooling和卷积共同进行下采样,提高下采样的效果,有助于网络学习到更加全局的信息。在Backbone网络进行特征提取后,将进入Head网络进行特征融合。此外,在Head网络中还引入了部分特征的最大池化来增加感受野的SPPCSPC(Spatial Pyramid Pooling Cross Stage Partial Connection)模块、使用最邻近插值法进行上采样的UP(UpSample)模块、与ELAN模块相类似的E-ELAN(Extended Efficient Layer Aggregation Network)模块和调整网络输出特征图像通道数的RepConv模块。SPPCSPC模块由负责提取不同尺度特征的SPP层、负责信息共享的CSP层和负责进一步特征提取的卷积层3部分组成。

## 2 改进YOLOv7目标检测算法

### 2.1 SA注意力机制

注意力机制能更好的帮助神经网络提取关键特征信息,抑制非必要的特征信息,通常应用于目标检测领域<sup>[12]</sup>。目前,注意力机制主要分为空间注意力机制和通道注意力机制,SA注意力机制采用混洗单元有效地将这两种类型的注意力机制进行融合,在不增加计算开销的情况下取得更好的效果<sup>[13]</sup>。SA注意力机制的工作原理是将输入特征图沿通道维度划分为多个子特征图,进行并行计算处理,采用混洗单元同时构建通道注意和空间注意;对所有子特征进行融合,采用通道混合机制使不同子特征的信息进行通信<sup>[14]</sup>。SA注意力机制示意图如图1所示。

输入特征图设为 $X \in R^{C \times H \times W}$ , $C$ 为通道数, $H$ 为图像高度, $W$ 为图像宽度。SA注意力机制沿通道维度将 $X$ 划分为 $G$ 组,通道数为 $C/G$ ,即 $X = [X_1, \dots, X_G]$ , $X_k \in R^{C/G \times H \times W}$ ;每组进入注意力模块后,再将 $X_k$ 根据通道间的相互关系和特征的空间关系划分为 $X_{k1}, X_{k2}$ 两个分支,通道数变为 $C/2G$ , $X_{k1}, X_{k2} \in R^{C/2G \times H \times W}$ 。

在通道注意力模块中采用全局平均池化GAP(Global Averaging Pooling)和sigmoid激活函数,得到通道注意力机制增强后的特征 $X'_{k1}$ ,公式如下:

$$X'_{k1} = \sigma(F_c(s)) \cdot X_{k1} = \sigma(W_1 s + b_1) \cdot X_{k1} \quad (1)$$

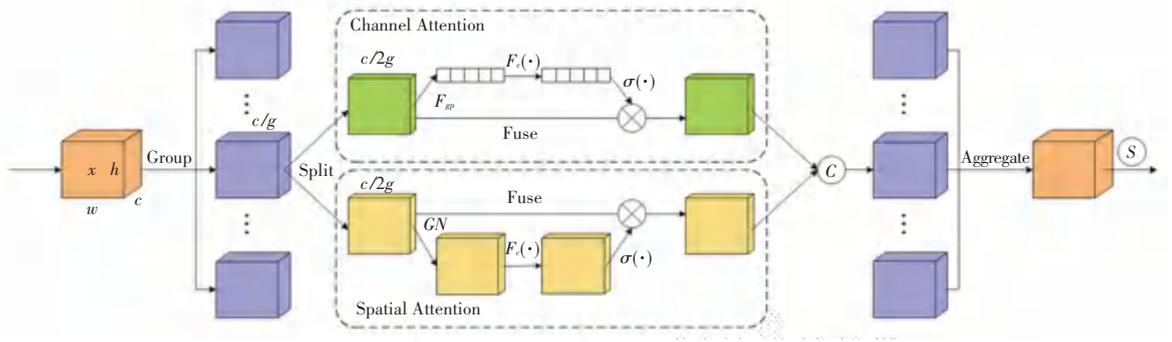


图 1 SA 注意力机制

Fig. 1 Shuffle Attention

其中,  $W_1 \in R^{C/2G \times 1 \times 1}$ ,  $b_1 \in R^{C/2G \times 1 \times 1}$  用于缩放和移动参数,  $\sigma$  用于归一化生成注意力权重,  $s$  为通道统计特征。

在空间注意力模块中, 对输入  $X_{k2}$  使用组归一化 GN (Group Norm) 获得空间特征, 再使用  $F_c(\cdot)$  来对输入  $X_{k2}$  进行增强, 输出空间注意力增强后的特征  $X'_{k2}$ , 如下式所示:

$$X'_{k2} = \sigma(W_2 \cdot GN(X_{k2}) + b_2) \cdot X_{k2} \quad (2)$$

其中,  $W_2 \in R^{C/2G \times 1 \times 1}$ ,  $b_2 \in R^{C/2G \times 1 \times 1}$ 。

将两个分支进行合并, 使得通道数与输入数相同, 记为  $X'_k = [X'_{k1}, X'_{k2}] \in R^{C/G \times H \times W}$ 。GN( $X_{k2}$ ) 是对输入特征  $X_{k2}$  进行组归一化的结果。

### 2.2 ConvNeXt 模块

ConvNeXt 模块结构是以深度残差网络 ResNet 为骨干架构, 基于 Swin Transformer 结构而改进的纯卷积神经网络, 引入交叉操作, 增加模型的感受野, 有效地提高模型的特征提取能力<sup>[15]</sup>。

ConvNeXt 模块使用卷积核大小为  $7 \times 7$  的卷积层进行特征提取, 采用层标准化 (Layer Normalization, LN) 替代批标准化 (Batch Normalization, BN) 对提取的特征图进行归一化操作, 以保持模型的稳定性。使用卷积核大小为  $1 \times 1$  的卷积层对提取的特征进行增强, 使网络能够提取更加丰富的信息。使用基于高斯误差的激活函数 GELU (Gaussian Error Linear Unit) 来提高模型的泛化性能。GELU 激活函数公式如下:

$$GELU(x) = x \int_{-\infty}^x \frac{e^{-\frac{(x-\mu)^2}{2\sigma^2}}}{\sqrt{2\pi}\sigma} dx \quad (3)$$

其中,  $\mu, \sigma$  为正态分布的均值和标准差。

ConvNeXt 模块结构如图 2 所示,  $96-d$  表示输入通道数为 96;  $d7 \times 7, 96$  表示卷积核的大小为  $7 \times 7$ , 通道数为 96;  $1 \times 1, 384$  表示卷积核的大小为  $1 \times 1$ , 通

道数为 384;  $1 \times 1, 96$  表示卷积核的大小为  $1 \times 1$ , 通道数为 96<sup>[16]</sup>。



图 2 ConvNeXt 模块结构

Fig. 2 ConvNeXt module structure

### 2.3 MP-NAM 模块

为进一步提高模型检测精度, 本文设计了 MP-NAM 模块, 将 MP 模块中的部分卷积替换为 NAM (Normalization-based Attention Module) 注意力机制, 如图 3 所示。



图 3 MP-NAM 模块

Fig. 3 MP-NAM module

NAM 注意力机制作为高效且轻量级的归一化注意力机制, 通过应用权重稀疏惩罚来抑制不显著的权重, 使得模型的特征提取能力增加<sup>[17]</sup>。NAM 注意力机制采用了 CBAM (Convolutional Block Attention Module) 的模块集成方式, 重新设计了通道注意力模块和空间注意力模块。在通道注意力模块中, 使用 BN (Batch Normalization) 中的缩放因子, 如下式所示:

$$B_{out} = BN(B_{in}) = \gamma \frac{B_{in} - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} + \beta \quad (4)$$

其中,  $\mu_B$  和  $\sigma_B$  分别为最小批次的均值和标准差,  $\gamma$  和  $\beta$  为可训练的仿射变换参数 (尺度和平移)。

NAM 注意力机制中通道注意力模块的输出特征  $M_c$  和空间注意力模块的输出特征  $M_s$  公式如下:

$$M_c = \text{Sigmoid}(W_\gamma(\text{BN}(F_1))) \quad (5)$$

$$M_s = \text{Sigmoid}(W_\lambda(\text{BN}_s(F_2))) \quad (6)$$

NAM 模块如图 4 所示。

其中,  $F_1$  和  $F_2$  为输入特征,  $W_\gamma$  和  $W_\lambda$  为权重。

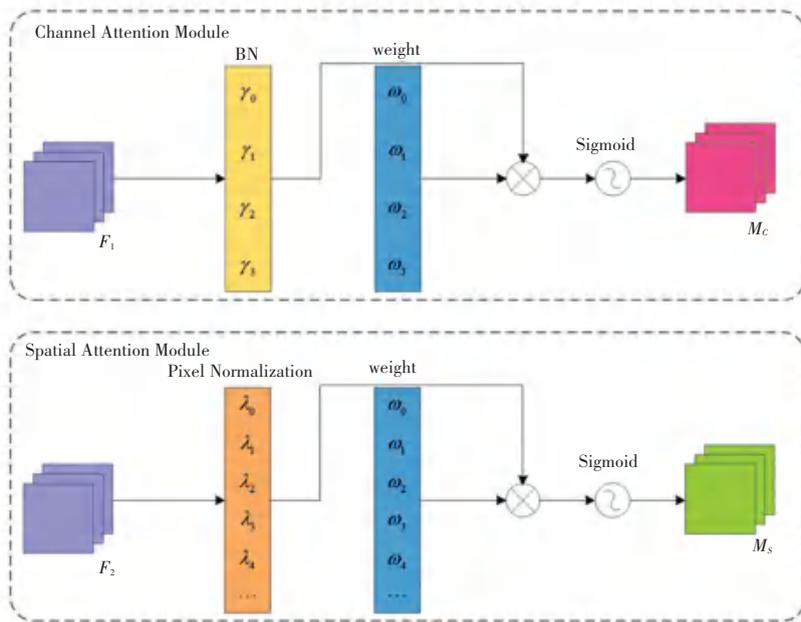


图 4 NAM 模块

Fig. 4 NAM module

### 2.4 改进 YOLOv7 算法

为更好的实现零件的检测,本文对 YOLOv7 算法进行了 3 方面的改进。首先,引入 SA 注意力机制,使得改进 YOLOv7 算法能够更加准确的提取到关键特征,提高零件检测的精度;其次, YOLOv7 算法中使用了 ELAN 模块来提升算法网络性能,但大量堆叠 ELAN 模块会导致模型的计算量增大;将主

干网络中的第一个 ELAN 模块和最后一个 ELAN 模块替换为 ConvNeXt 模块,使网络的计算量大幅度下降;最后,引入构建的 MP-NAM 模块,使改进 YOLOv7 算法更好地聚焦于重要特征,从而在复杂的情况下提升零件检测的准确性和鲁棒性。改进后的 YOLOv7 算法结构图如图 5 所示。

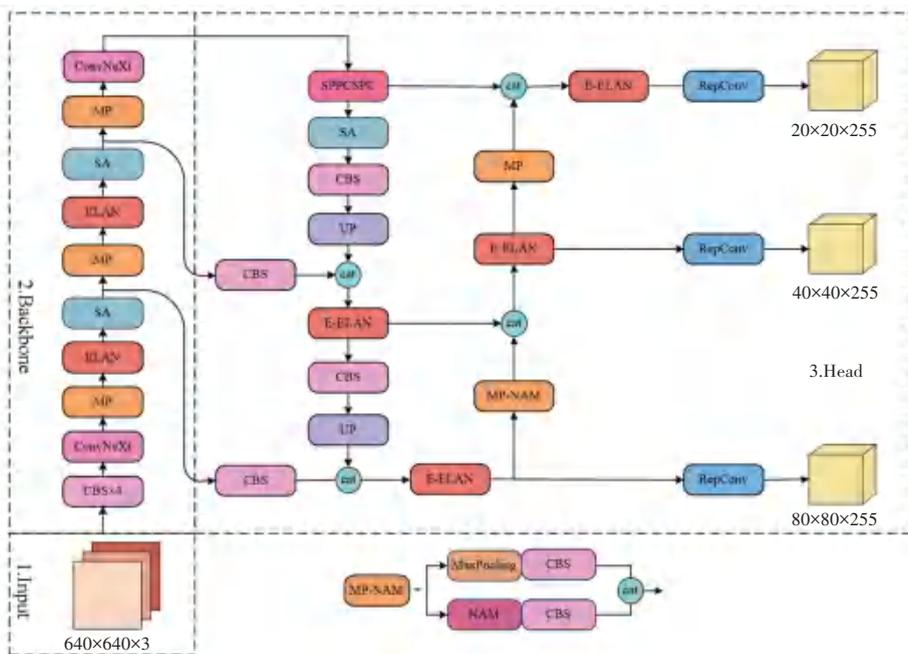


图 5 改进后的 YOLOv7 算法结构

Fig. 5 Improved YOLOv7 structure

### 3 实验与分析

#### 3.1 实验环境及数据集

本文实验使用 ubuntu 18.04 操作系统,以 Pytorch 1.8.1 作为深度学习框架,Python3.8 为编程语言。使用 12vCPU Intel (R) Xeon (R) Platinum 8255C CPU @ 2.50 GHz 的处理器,运行内存为 43 GB,显存为 24 GB 的 RTX3090 显卡。本文设置的输入图形大小为  $640 \times 640$ ,训练时将批处理数 batch size 设置为 16,初始学习率设置为 0.01,循环学习率设置为 0.1,动量系数设置为 0.937,权重衰减系数为 0.0005,训练周期设定为 200。

本文使用自制数据集,该数据集由 2000 张在不同环境下拍摄的图片组成,包括螺丝和螺母两种零件。为了增加数据集的复杂性和适应性,对部分图片进行裁剪和模糊等操作,模拟实际应用中可能出现的多种情况,使模型更好地适应不同的输入条件。使用 labelimg 工具对图片进行精确标注,确保每个目标的边界框位置准确无误。将数据集按 4:1 的比例划分为训练集和测试集,确保模型训练评估的平衡性与科学性。

#### 3.2 评价指标

为客观的评估改进 YOLOv7 算法在零件识别上的性能,本文将改进 YOLOv7 算法与原始 YOLOv7 算法进行对比实验,采取精确率  $P$ 、召回率  $R$ 、均值平均精度  $mAP$  和浮点运算次数 GFLOPs 作为模型的评价指标。精确率  $P$ 、召回率  $R$ 、均值平均精度  $mAP$  的计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (7)$$

$$R = \frac{TP}{TP + FN} \quad (8)$$

$$mAP = \frac{\sum_{i=1}^n AP}{n} \quad (9)$$

其中,  $TP$  表示正样本被预测为正样本的数量;

$FP$  表示负样本被预测为正样本的数量;  $FN$  表示正样本被预测为负样本的数量;  $n$  为零件类别的数量;  $AP$  为单个类别的平均精度。

$mAP$  值越高,说明模型对零件的识别效果越好,浮点运算次数 GFLOPs 越高,代表模型的复杂度越高。

#### 3.3 不同注意力机制对比实验

为了验证在骨干网络和头部网络中引入 SA 注意力机制对网络性能的影响,以 YOLOv7 算法为基准模型,将 SA 注意力机制与 GE (Gather-Excite) 注意力机制、MLCA (Mixed Mocal Channel Attention) 注意力机制、SE (Squeeze-and-Excitation) 注意力机制进行对比实验,实验结果见表 1。

表 1 不同注意力机制结果对比

Table 1 Comparison of results with different attention mechanism

注意力机制	精确率	召回率	均值平均精度
YOLOv7+SA	0.892	0.883	0.928
YOLOv7+GE	0.950	0.819	0.918
YOLOv7+MLCA	0.909	0.862	0.922
YOLOv7+SE	0.919	0.849	0.926

由表 1 可以看出,在 YOLOv7 网络中添加注意力机制可以使检测效果明显提升,在骨干网络和头部网络中加入 SA 注意力机制的综合性能提升较明显,有助于对零件的检测。

#### 3.4 消融实验

为了验证改进后算法的检测效果,以及各个改进模块对算法性能的影响,以 YOLOv7 为基准模型,进行 4 组消融实验。4 组消融实验均使用相同数据集和训练配置,以确保实验的可靠性。为观察各模块对算法性能的具体影响,本文逐步引入不同的改进模块到原 YOLOv7 算法中,消融实验结果见表 2,第一组为基准模型 YOLOv7 的实验结果,作为后 3 组实验的对照,“√”表示在相对应的实验组中使用该改进模块。

表 2 消融实验结果对比

Table 2 Comparison of ablation study results

组	SA	ConvNeXt	MP-NAM	精确率	召回率	均值平均精度	浮点运算次数
1				0.940	0.836	0.917	103.2
2	√			0.892	0.883	0.928	103.2
3	√	√		0.918	0.867	0.916	38.7
4	√	√	√	0.964	0.848	0.925	38.6

由表2可见,第二组加入了SA注意力机制,尽管加入该机制后,精确率 $P$ 下降到0.892,但召回率 $R$ 和均值平均精度 $mAP$ 分别上升到0.883和0.928,表明SA注意力机制在提高召回率 $R$ 的同时会对精确率 $P$ 产生一定的影响;浮点运算次数GFLOPs保持不变,表明引入SA注意力机制不会增加计算复杂度。第三组引入了SA注意力机制后,将主干网络中的部分ELAN模块替换为ConvNeXt模块,均值平均精度 $mAP$ 下降为0.916,但浮点运算次数GFLOPs明显减少,仅为原模型的37.5%,表明使用ConvNeXt模块替换ELAN模块,可以有效地降低模型的计算量。第四组在第三组的基础上引入了MP-NAM模块,均值平均精度 $mAP$ 上升为0.925,

浮点运算次数GFLOPs为38.6。综合所有评价指标可以看出,本文所提出的改进YOLOv7的零件目标检测算法,在提高均值平均精度 $mAP$ 的同时,大幅度的降低了模型的计算量,模型在整体性能上表现得更优,提升检测精度的同时又有效地减少了计算开销,在实际应用中具有更高的实用价值。

### 3.5 不同算法对比实验

为了客观的验证本文所提出的改进YOLOv7的零件目标检测算法在零件目标检测方面的有效性,选取Faster-RCNN、YOLOv3、YOLOv5、YOLOv7和本文算法,使用自制数据集在配置相同的情况下进行对比实验,结果见表3。

表3 不同目标检测算法结果对比

Table 3 Comparison of results from different object detection algorithms

算法	精确率	召回率	均值平均精度	浮点运算次数
Faster-RCNN	0.444	0.942	0.883	370.2
YOLOv3	0.953	0.864	0.917	154.6
YOLOv5	0.939	0.849	0.906	15.8
YOLOv7	0.940	0.836	0.917	103.2
本文	0.964	0.848	0.925	38.6

由表3可见,本文所提出的算法在零件检测方面与其它主流的目标检测算法相比有较大的优势。本文算法与Faster-RCNN、YOLOv3、YOLOv5和YOLOv7相比分别提升了52%、1.1%、2.5%和2.4%的精确率;改进后的算法计算量减少为38.6,最大的均值平均精度增加为0.925,且召回率相较于YOLOv7提升了1.2%。虽然YOLOv5的计算量仅为15.8,但是检测精度较低,其均值平均精度仅为0.906。本文所提出的改进YOLOv7算法在整体性能上要优于其他目标检测算法。

### 3.6 实验结果分析

为了验证改进YOLOv7算法对零件的检测效果,在自制数据集上对原始YOLOv7算法与改进YOLOv7算法进行训练,训练结果如图6所示,可见改进YOLOv7算法精度比原始YOLOv7模型的精度略高,在更少的迭代次数下效果更好,表明改进YOLOv7算法在提高精确率的同时提高了训练效率。

### 3.7 可视化分析

为了进一步验证改进YOLOv7算法对零件的检测效果,引入热力图对检测图像进行可视化呈现,比较原始YOLOv7算法与改进YOLOv7算法的检测情

况。在自制零件测试集中随机选取4张图像,使用Grad-CAM(Gradient-weighted Class Activation Mapping)可视化来生成原始YOLOv7算法和改进YOLOv7算法的可视化热力图,如图7所示。改进YOLOv7算法可视化热力图相较于原始YOLOv7算法可视化热力图,热力图的颜色更深,更关注目标本身的特征,表明改进YOLOv7模型检测零件时准确性更高。

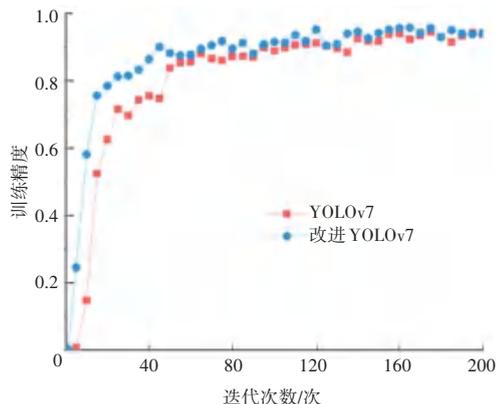


图6 改进前后训练精度图

Fig. 6 Precision comparison of YOLOv7 before and after the improvements

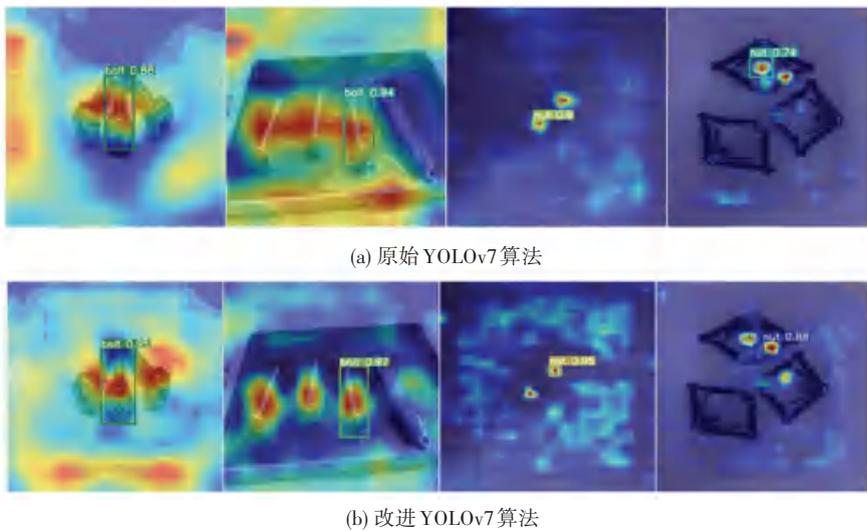


图7 热力图可视化结果

Fig. 7 Heatmap visualization results

## 4 结束语

针对零件尺度小、识别困难等问题,以 YOLOv7 为基准算法,本文提出一种改进 YOLOv7 的零件目标检测算法。为了提升算法对零件的检测性能,从以下 3 个方面对原始 YOLOv7 模型进行改进。首先,引入 SA 注意力机制,在不增加计算开销的情况下增强网络的特征提取能力,更好地捕捉和处理零件图像中的关键信息,从而提高对零件的检测性能;其次,使用 ConvNeXt 模块替换主干网络中的部分 ELAN 模块,降低了模型计算复杂度,实现了网络轻量化,在保持高性能的同时,显著减少了计算资源的消耗,提高处理效率;最后,结合轻量级的归一化注意力机制 NAM 设计 MP-NAM 模块,有效地增强了改进 YOLOv7 算法对关键特征的提取能力,使网络能够更加注意重要特征,提高零件目标检测的精度。实验结果表明,改进的 YOLOv7 算法的检测性能明显优于其他目标检测算法,与原始 YOLOv7 算法相比较,其精确率  $P$  和召回率  $R$  分别提升了 2.4% 和 1.2%,均值平均精度  $mAP$  值提升至 0.926,浮点运算次数 GFLOPs 显著减少,仅为 YOLOv7 基准模型的 37.5%。可以为零件检测研究提供必要的技术支持。

## 参考文献

- [1] 宋小飞,晁永生. 基于改进 YOLOv5s 网络的机械零件目标检测[J]. 组合机床与自动化加工技术, 2023, 65(8): 84-88.
- [2] 马敬,刘溪,杨勇,等. 计算机视觉技术在零件识别中的应用[J]. 中国设备工程, 2020, 36(21): 244-246.
- [3] YU Y, HAN X, DU L. Target part detection based on improved SSD algorithm[J]. Journal of Physics: Conference Series. IOP Publishing, 2020, 1486(3): 32024-32030.
- [4] FANG Y, WU Q, LI S, et al. Enhanced YOLOv5s - based algorithm for industrial part detection[J]. Sensors, 2024, 24(4): 1183-1200.
- [5] LIU L, QIN P, WU X. Detail extraction of mechanical component image based on depth learning[J]. Journal of Physics: Conference Series, 2023, 2476(1): 12063-12071.
- [6] 朱文博,陈龙飞,余琦. 基于协调注意力机制的轻量级 YOLOv4 零件检测[J]. 计算机技术与发展, 2024, 34(8): 23-29.
- [7] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6): 1137-1149.
- [8] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2016: 779-788.
- [9] LIU W, ANGELOV D, ERHAN D, et al. SSD: Single shot multibox detector[J]. arXiv, 1512.02325, 2015.
- [10] 梁秀满,李然,于海峰,等. 改进 YOLOv7 的水下目标检测算法[J]. 计算机工程与应用, 2024, 60(6): 89-99.
- [11] 戚玲珑,高建瓴. 基于改进 YOLOv7 的小目标检测[J]. 计算机工程, 2023, 49(1): 41-48.
- [12] 卞长庚,郝万君,马文琪. 基于 Xception 和 SA 的 YOLOv5 建筑裂缝检测方法[J]. 计算机技术与发展, 2023, 33(8): 159-164.
- [13] ZHANG Q L, YANG Y B. Sa-net: Shuffle attention for deep convolutional neural networks [C]//Proceedings of the IEEE International Conference on Acoustics. Piscataway, NJ: IEEE, 2021: 2235-2239.
- [14] 韩辉,孙熙庆,陈一君,等. 基于 SA-YOLOv5 的交通标志目标检测研究[J]. 微电子学与计算机, 2023, 40(2): 94-100.
- [15] LIU Z, MAO H, WU C Y, et al. A convnet for the 2020s[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2022: 11976-11986.
- [16] 赵泽华,王亚超,赵江平,等. 基于改进 YOLOv7-x 的多场景火灾识别算法[J]. 中国安全生产科学技术, 2023, 19(12): 115-120.
- [17] LIU Y, SHAO Z, TENG Y, et al. NAM: Normalization-based attention module[J]. arXiv preprint arXiv, 2111.12419, 2021.