

## 基于改进 YOLOv5l 的印刷品缺陷检测

刘海文<sup>1\*</sup>, 郑元林<sup>1\*\*</sup>, 钟崇军<sup>2</sup>, 廖开阳<sup>1</sup>, 孙帮勇<sup>1</sup>, 赵含香<sup>1</sup>, 林杰<sup>1</sup>, 王豪强<sup>1</sup>, 韩善翔<sup>1</sup>, 解博<sup>2</sup><sup>1</sup>西安理工大学印刷包装与数字媒体学院, 陕西 西安 710054;<sup>2</sup>渭南日报社印刷厂, 陕西 渭南 714099

**摘要** 针对印刷生产中传统人工缺陷检测耗时耗力、小缺陷区域不易检测,以及传统图像处理方法鲁棒性差等问题,提出一种基于改进 YOLOv5l 模型的印刷品缺陷检测算法。首先,通过增加浅层特征图拓展检测尺度,以捕获微小缺陷信息,从而提高网络对小目标的检测能力;然后,使用全维度动态卷积替换 Neck 区中的普通卷积,以增强网络对印刷缺陷上下文信息的捕获能力;最后,为解决前两项工作带来的检测速度下降的问题,采用 C3Ghost 替换 Neck 中的 C3 模块,在检测精度损耗极低的情况下尽可能地提高检测速度。实验结果表明:改进后的 YOLOv5l 算法的平均精度均值(mAP)达到 97.3%,较原 YOLOv5l 算法和现有的印刷品缺陷检测算法 Siamese-YOLOv4 的精度分别提高 2.9 个百分点和 2.7 个百分点;检测速度为 44.1 frame/s。所提算法对印刷品缺陷的分类和定位效果优于原 YOLOv5l 和 Siamese-YOLOv4 算法,具有较高的检测精度和检测速度,可以应用于印刷质检来提高生产质量管控水平、降低人工成本。

**关键词** 机器视觉; 缺陷检测; YOLOv5 算法; 多尺度融合; 动态卷积

中图分类号 TP391.4

文献标志码 A

DOI: 10.3788/LOP231826

## Defect Detection of Printed Matter Based on Improved YOLOv5l

Liu Haiwen<sup>1\*</sup>, Zheng Yuanlin<sup>1\*\*</sup>, Zhong Chongjun<sup>2</sup>, Liao Kaiyang<sup>1</sup>, Sun Bangyong<sup>1</sup>,  
Zhao Hanxiang<sup>1</sup>, Lin Jie<sup>1</sup>, Wang Haoqiang<sup>1</sup>, Han Shanxiang<sup>1</sup>, Xie Bo<sup>2</sup><sup>1</sup>College of Faculty of Printing, Packaging Engineering and Digital Media Technology,  
Xi'an University of Technology, Xi'an 710054, Shaanxi, China;<sup>2</sup>Weinan Daily Printing Factory, Weinan 714099, Shaanxi, China

**Abstract** Herein, to address the issues associated with traditional manual defect detection in printing production, such as time and effort consumption, difficulty in detecting small defect areas, and poor robustness, an improved YOLOv5l-based printing defect detection algorithm is proposed. First, by expanding the detection scale by adding shallow feature maps to capture small defect information, the ability of the network to detect small targets is improved. Subsequently, the ordinary convolution in the Neck area is replaced with full-dimensional dynamic convolution to enhance the ability of the network to capture contextual printing defect information. Finally, to address the issue of reduced detection speed caused by the aforementioned two modifications, the C3 module in the Neck area is replaced with C3Ghost to improve detection speed to the maximum extent possible with considerably low detection accuracy loss. Experimental results show that the proposed algorithm has a detection speed of 44.1 frame/s, and its mean average precision (mAP) reaches 97.3%, which is 2.9 percentage points and 2.7 percentage points higher than those of the original YOLOv5l algorithm and an existing printing defect detection algorithm-Siamese-YOLOv4, respectively. The proposed algorithm outperforms the original YOLOv5l and Siamese-YOLOv4 algorithms in classifying and locating defects in printed products with high detection accuracy and speed. Thus, the proposed algorithm can be applied to print quality inspection to improve production quality control levels and reduce labor costs.

**Key words** machine vision; defect detection; YOLOv5 algorithm; multi-scale fusion; dynamic convolution

## 1 引言

在现如今复杂多变的发展环境中,印刷行业也面

临着许许多多新的机遇和挑战。印刷品缺陷检测是印刷行业的一个经典问题,传统人工缺陷检测由于耗时耗力、主观性强,且不容易发现一些小目标缺陷,已经

收稿日期: 2023-07-31; 修回日期: 2023-09-21; 录用日期: 2023-10-09; 网络首发日期: 2023-10-23

基金项目: 国家自然科学基金(62076199)、渭南市重点研发计划(2021ZDYF-GYCX-150)

通信作者: \*2418700609@qq.com; \*\*zhengyuanlin@xaut.edu.cn

不适应现代化工业生产发展。

在印刷智能制造中,基于机器视觉的技术已经用于印刷品的缺陷检测中,相比于传统人工检测的方法,基于机器视觉的缺陷检测方法客观稳定、标准统一、检测效率和准确性更高且不会对印刷品造成接触损伤。传统图像处理算法需要人工设计特征,鲁棒性差。随着深度学习的发展,出现了 Faster R-CNN<sup>[1]</sup>、SSD<sup>[2]</sup>、YOLO 系列<sup>[3-5]</sup>等经典的目标检测算法,这些算法被广泛应用到各个领域并展现出卓越的性能优势<sup>[6-9]</sup>。

基于深度学习的缺陷检测已经在工业上得到了广泛研究与应用<sup>[10-14]</sup>,在钢材表面缺陷检测、印刷电路板缺陷检测等各个领域取得了不错的效果。纸质印刷品包含丰富的颜色信息和亮度信息,图像的背景较为复杂,这些都给印刷品缺陷的检测带来了巨大的困难。

针对上述问题,文献[15]结合模板匹配中的对比思想与深度学习中的语义特征,提出用于印刷缺陷检测任务的深度对比网络,但对细微缺陷的检测效果有待提高。针对此问题,文献[16]提出一种基于深度卷积生成对抗网络的印刷缺陷检测方法,提高了对细微缺陷的检测效果。文献[17]将 Siamese 网络与 YOLOv4 结合来检测印刷品缺陷,先利用相似性检测网络预测待检图像与原稿图像的相似性,按照相似度阈值对缺陷区域进行粗定位,再将可能存在缺陷的区域输入 YOLOv4 网络进行精确定位和分类。文献[18]在此

基础上进一步增加缺陷种类。虽然 Siamese-YOLOv4 在印刷品缺陷数据集上的平均精度达到 94.6%,但对脏点、漏印、裂痕等 3 种缺陷的检测效果并不理想,尤其是对漏印和裂痕的检测精度分别只有 92.0% 和 91.7%,漏检现象时有发生。

为了解决以上问题,本文将印刷生产中 4 种常见的印刷品缺陷(卫星墨滴、脏点、漏印、裂痕)作为检测目标,并以 YOLOv5l 作为基准模型进行研究。针对原 YOLOv5l 算法 3 种尺度的检测层无法充分利用浅层特征中的信息、小目标检测效果差的问题,增加 160×160 大小的特征图,变为 4 种尺度的检测层,提高对小缺陷区域的检测精度。使用全维度动态卷积(ODConv)替换 Neck 中的普通卷积模块,增强网络对缺陷上下文信息的捕获能力,提高检测精度。针对前两项工作带来的检测速度下降的问题,将 Neck 中的 C3 模块替换为 C3Ghost 模块,提高检测速度。

## 2 YOLOv5l 算法

YOLOv5 因体积小、准确率高和速度快等优势而被广泛地应用到许多工业上的缺陷检测场景。根据网络深度和宽度的不同,其可以分为 YOLOv5s、YOLOv5m、YOLOv5l、YOLOv5x 等多个版本。为满足印刷品缺陷检测的需要,本文采用速度与精度相对均衡的 YOLOv5l 作为基础网络结构。

YOLOv5l 的模型结构如图 1 所示,由 Input(图 1 中

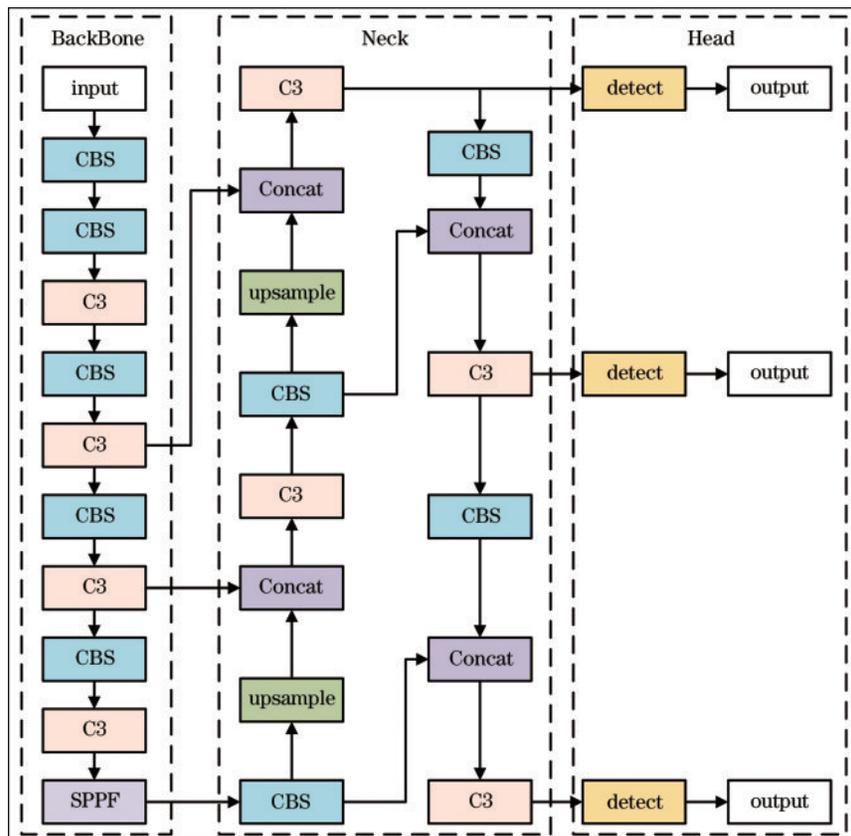


图 1 YOLOv5l 网络框架

Fig. 1 Architecture of YOLOv5l network

未画出)、Backbone、Neck、Head 等 4 部分组成。Input 的作用是对图像进行 Mosaic 数据增强,并根据数据集的类型优化锚框大小,最后将图像缩放到相同尺寸输入 Backbone。YOLOv5 V6.0 的 Backbone 中,移除了 Focus 模块,主要由 Conv+BN+SiLU (CBS) 模块、CSP Bottleneck with 3 Convolutions (C3) 模块和 Spatial Pyramid Pooling-Fast(SPPF)模块组成。C3 模块能够利用 Shortcut 连接深层特征和浅层特征,充分利用浅层特征的几何信息和分辨率、深层特征的感受野和语义信息。SPPF 模块能够不考虑输入特征图的大小,将特征图转换成固定大小的特征向量,它的作用是减少产生候选框的速度,降低过拟合。Neck 部分结合使用 Feature

Pyramid Network (FPN)<sup>[19]</sup> 和 Path Aggregation Network (PAN)<sup>[20]</sup>,增强网络的多尺度特征融合能力。最后,经过特征融合的 3 个大小不同的检测层被输入 Head 进行识别和分类。

### 3 改进的 YOLOv5l 算法

所提基于改进 YOLOv5l 的印刷品缺陷检测方法框架图如图 2 所示。首先,在 Neck 中增加了经过主干网络 4 倍下采样得到的特征图,并与深层特征融合得到 4 种尺度的检测层;然后,将 Neck 中的普通卷积用全维度动态卷积替换;最后,将 Neck 中的 C3 模块用 C3Ghost 模块替换。

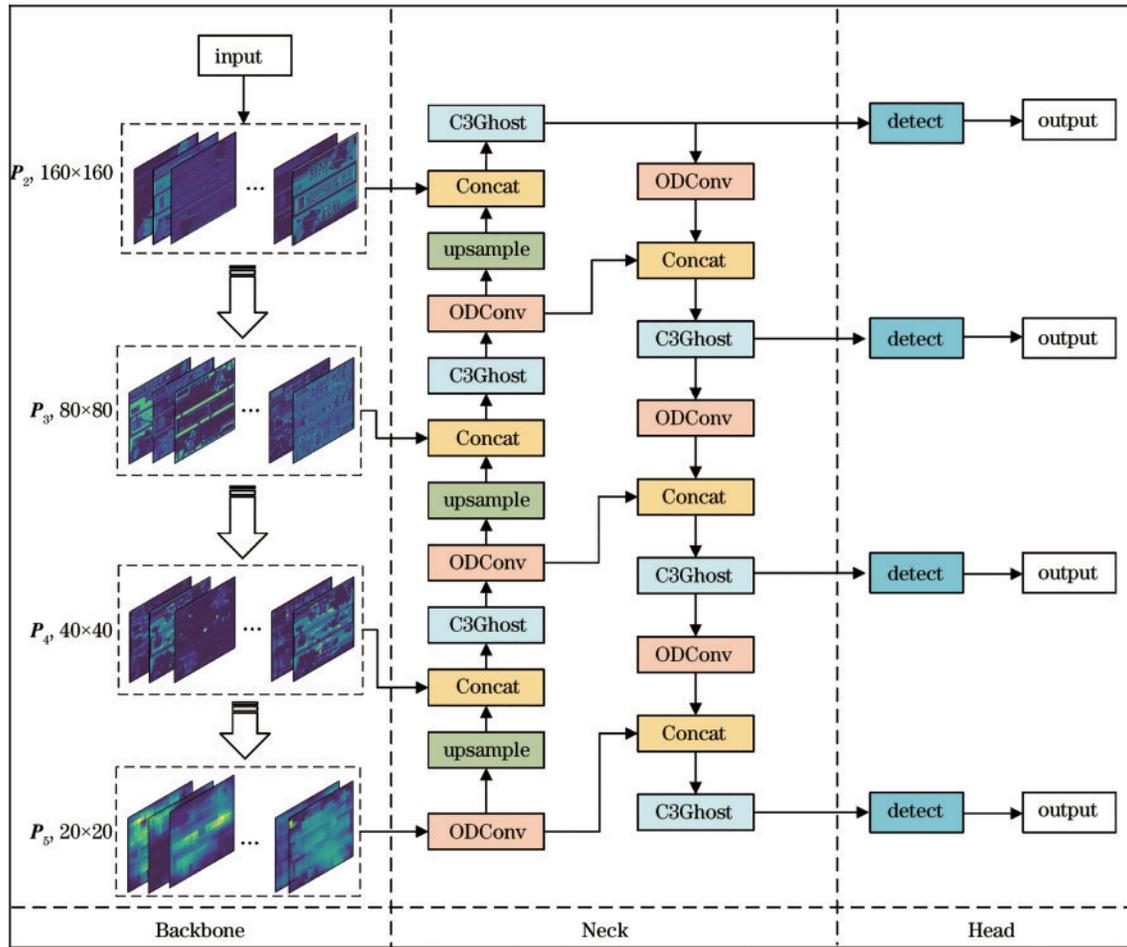


图 2 改进后的 YOLOv5l 网络框架

Fig. 2 Architecture of improved YOLOv5l network

#### 3.1 增加多尺度目标检测层

YOLOv5l 采用多尺度的检测方法,具体做法是将 Backbone 提取的特征经过 Neck 部分融合后输出不同尺度的检测层,最后通过不同尺度的检测层来检测不同大小的目标。当输入图像大小为  $640 \times 640$  时,输出  $20 \times 20$ 、 $40 \times 40$ 、 $80 \times 80$  等 3 种尺度的检测层: $20 \times 20$  的检测层感受野大,包含丰富的语义信息,适合检测大目标缺陷区域; $80 \times 80$  的检测层包含丰富的纹理和位置等细节信息,适合检测小目标缺陷区域; $40 \times 40$  的

检测层介于二者之间。由于在印刷过程中,会随机出现一些本身尺寸很小的缺陷,例如因压力不足、印版不平整或印版吸附尘埃而出现的漏印,只使用原 YOLOv5l 的 3 种尺度的检测层无法充分利用浅层特征中的信息,导致细微缺陷漏检。

为了增强模型对微小缺陷区域的检测能力,增加了 Backbone 中经过 4 倍下采样得到的  $160 \times 160$  大小的特征图,因为只经过浅层网络的处理,所以其包含了丰富的小目标位置信息,最后经过 Neck 部分与深层特

征融合,输出 4 种尺度的检测层,并利用 K-means 聚类方法重新生成更加准确的锚框,从而提高对印刷品小缺陷的检测精度。

### 3.2 全维度动态卷积

为获得更加充分的上下文信息,使用全维度动态卷积<sup>[21]</sup>替换 Neck 中的普通卷积,使网络更加关注缺陷信息。

常规卷积只有 1 个静态卷积核,即卷积核的参数保持不变,因此与输入无关。动态卷积使用  $n$  个动态加权的卷积核的线性组合,并带有注意力机制,使卷积操作与输入相关,可以提高卷积对上下文信息的捕获能力。常规动态卷积公式为

$$\mathbf{y} = (\alpha_{w1}W_1 + \dots + \alpha_{wn}W_n) * \mathbf{x}, \quad (1)$$

式中:  $\mathbf{x} \in \mathbf{R}^{h \times w \times c}$ 、 $\mathbf{y} \in \mathbf{R}^{h \times w \times n}$  分别表示输入特征图和输出

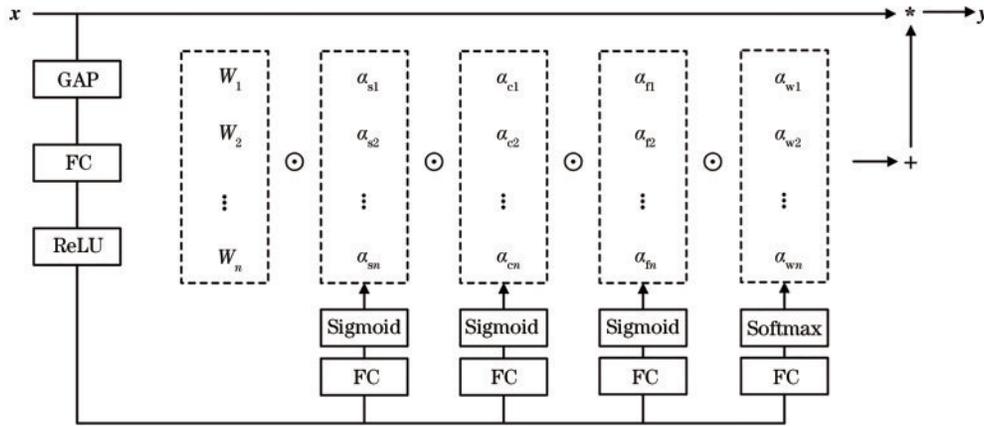


图 3 全维度动态卷积

Fig. 3 Omni-dimensional dynamic convolution

全维度动态卷积的公式为

$$\mathbf{y} = (\alpha_{w1} \odot \alpha_{f1} \odot \alpha_{c1} \odot \alpha_{s1} \odot W_1 + \dots + \alpha_{wn} \odot \alpha_{fn} \odot \alpha_{cn} \odot \alpha_{sn} \odot W_n) * \mathbf{x} \quad (2)$$

式中:  $\alpha_{si} \in \mathbf{R}^{k \times k}$ 、 $\alpha_{ci} \in \mathbf{R}^{cn}$ 、 $\alpha_{fi} \in \mathbf{R}^{c \times n}$  分别表示沿核空间、输入通道和输出通道等 3 个维度的注意力标量;  $\odot$  代表沿核空间不同维度的乘法运算。

### 3.3 C3Ghost

#### 3.3.1 Ghost 卷积

Ghost 卷积<sup>[22]</sup>考虑到普通卷积生成的特征图含有大量的冗余,有些特征图是相似的,可以用一些简单线性操作来代替卷积生成这部分相似的特征图,从而在损失较小精度的情况下降低计算量和参数量。

普通卷积操作过程可表示为

$$\mathbf{Y} = \mathbf{X} * \mathbf{f} + \mathbf{b}, \quad (3)$$

式中:  $\mathbf{X} \in \mathbf{R}^{c \times h \times w}$ , 表示通道数为  $c$ 、高为  $h$ 、宽为  $w$  的输入特征图;  $\mathbf{Y} \in \mathbf{R}^{n \times h' \times w'}$ , 表示通道数为  $n$ 、高为  $h'$ 、宽为  $w'$  的输出特征图;  $\mathbf{b}$  为偏置;  $\mathbf{f} \in \mathbf{R}^{c \times k \times k \times n}$ , 表示卷积核大小为  $k$  的卷积滤波器。则普通卷积的计算量  $F_1$  可表示为

$$F_1 = n \cdot h' \cdot w' \cdot c \cdot k \cdot k. \quad (4)$$

Ghost 卷积先用普通的卷积滤波器生成  $m$  ( $m < n$ )

特征图;  $h$ 、 $w$  表示特征图的高度和宽度,  $c$  和  $n$  分别表示输入特征图和输出特征图的通道数;  $W_i$  表示第  $i$  个卷积核;  $\alpha_{wi} \in \mathbf{R}$  是卷积核  $W_i$  的注意力标量;  $*$  表示卷积操作。

引入全维度动态卷积来提高网络对于印刷品缺陷信息的挖掘能力。全维度动态卷积不仅赋予了卷积核动态特性,还关注卷积核的空间大小、输入通道数和输出通道数。其结构如图 3 所示。首先,通过通道全局平均池化(GAP)操作将输入特征图  $\mathbf{x}$  压缩为输入通道长度的特征向量;然后,利用全连接层(FC)将压缩后的特征向量映射到更低维的空间,并通过 ReLU 激活函数激活;最后通过 4 个由 FC 层和 Sigmoid 或 Sigmoid 函数组成的分支,分别生成核空间的 4 个注意力标量  $\alpha_{si}$ 、 $\alpha_{ci}$ 、 $\alpha_{fi}$  和  $\alpha_{wi}$ 。

个特征图,再对这  $m$  个特征图进行线性变换,每个线性变换的输出通道为  $s$ ,最后共生成  $m \times s$  个特征图,可表示为

$$\mathbf{Y}' = \mathbf{X} * \mathbf{f}', \quad (5)$$

$$\mathbf{y}_{ij} = \Phi_{i,j}(\mathbf{y}'_i), \forall i = 1, \dots, m, j = 1, \dots, s, \quad (6)$$

式中:  $\mathbf{f}' \in \mathbf{R}^{c \times k \times k \times m}$ , 为所使用的滤波器;  $\mathbf{Y}' \in \mathbf{R}^{h' \times w' \times m}$ , 表示用卷积滤波器生成的特征图;  $\Phi_{i,j}$  表示线性变换;  $\mathbf{y}'_i$  是  $\mathbf{Y}'$  中第  $i$  个特征图,每一个  $\mathbf{y}'_i$  有多个线性映射;  $\mathbf{y}_{ij}$  是最终 Ghost 模块的输出。令每个线性操作的卷积核大小为  $d \times d$ , 则 Ghost 模块的计算量  $F_2$  可表示为

$$F_2 = \frac{s}{n} \cdot h' \cdot w' \cdot c \cdot k \cdot k + (s-1) \cdot \frac{s}{n} \cdot h' \cdot w' \cdot d \cdot d. \quad (7)$$

则普通卷积与 Ghost 卷积计算量比值为

$$r = \frac{F_1}{F_2} = \frac{n \cdot h' \cdot w' \cdot c \cdot k \cdot k}{\frac{s}{n} \cdot h' \cdot w' \cdot c \cdot k \cdot k + (s-1) \cdot \frac{s}{n} \cdot h' \cdot w' \cdot d \cdot d} = \frac{c \cdot k \cdot k}{\frac{1}{s} \cdot c \cdot k \cdot k + \frac{s-1}{s} \cdot d \cdot d} \approx \frac{s \cdot c}{s + c - 1} \approx s, \quad (8)$$

所以 Ghost 卷积计算量大概是普通卷积计算量的  $1/s$ 。

### 3.3.2 C3Ghost 模块

前两项改进使得网络模型的检测速度下降了 9 frame/s,为了平衡速度和精度,引入轻量化的 C3Ghost 模块替换 Neck 区中的 C3 模块来压缩卷积过程的计算量和模型大小,提高模型的缺陷检测速度。C3Ghost 模块结构如图 4 所示,C3Ghost 是在原 YOLOv5l 的 C3 模块上通过修改 Bottleneck 为 Ghost-Bottleneck 得到的。Ghost-Bottleneck<sup>[23]</sup>结构由两部分

组成:左边分支先采用 Ghost 卷积降低特征图的通道数,再通过深度卷积(DWConv)改变特征图尺度,最后采用 Ghost 卷积增加特征图的通道数;右边分支则采用一个深度卷积和一个普通卷积分别来减少特征尺度和增加通道数,最后将左右分支的结果相加。

由于 Ghost 卷积计算量大概是普通卷积的  $1/s$  ( $s$  为每个线性操作输出通道数),因此 C3Ghost 模块能够降低网络的计算量和参数量。

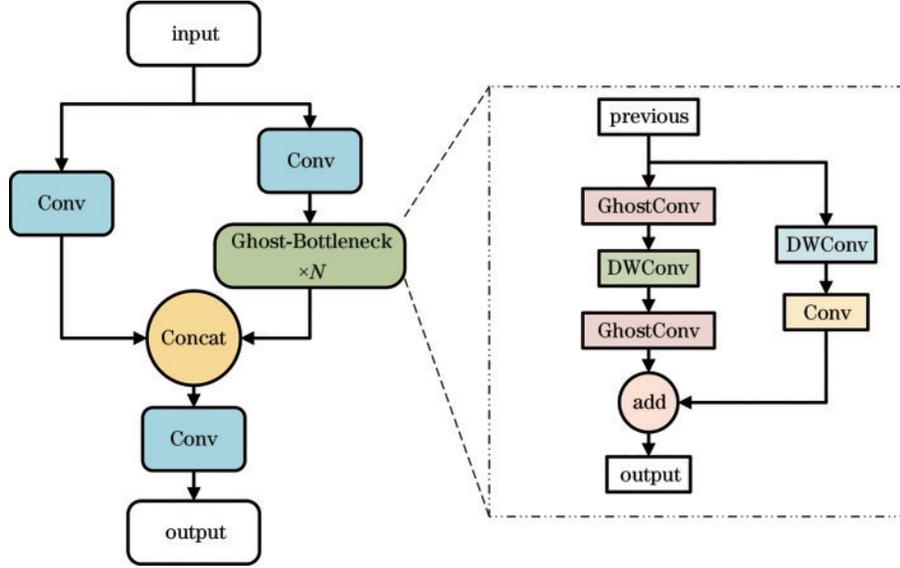


图 4 C3Ghost 模块结构图

Fig. 4 Structure diagram of C3Ghost module

## 4 实验结果与分析

### 4.1 实验环境

本实验采用 PyTorch 1.10.1 框架搭建网络模型,实验环境详细配置如表 1 所示。

表 1 实验环境配置

Table 1 Experimental environment configuration

Category	Parameter	Configuration
Hardware	Video storage	11 GB
	Memory	16 GB
	GPU	NVIDIA GeForce RTX 2080 Ti
	CPU	Intel(R) Core(TM) i5-4590 CPU@3.30 GHz
Software	Operating system	Ubuntu 22.04
	Programming language	Python 3.7
	Graphics card acceleration	CUDA 10.1
	Deep learning framework	PyTorch 1.10.1

### 4.2 实验数据集

所使用的实验数据集为文献[14]中的印刷品缺陷数据集,由 4000 张带有标注的印刷缺陷图片组成,包括卫星墨滴、脏点、漏印、破裂等 4 种印刷品常见缺陷,

如图 5 所示。按 9:1:1 的比例将其划分训练集、验证集、测试集,4 类缺陷的数量接近 1:1:1:1,表 2 展示了数据集中各类缺陷的数量。

表 2 各类缺陷的数量

Table 2 Number of various defects

Types of printing defects	Number of defects
Satellite droplet	976
Spots	985
Missing print	1041
Crack	998

### 4.3 模型评价指标

采用平均精度均值(mAP)作为模型的精度指标,检验印刷品缺陷目标检测模型的效果,计算公式为

$$P = \frac{N_{TP}}{N_{FP} + N_{TP}} \times 100\%, \quad (9)$$

$$R = \frac{N_{TP}}{N_{FN} + N_{TP}} \times 100\%, \quad (10)$$

$$P_{mAP} = \frac{1}{N_c} \sum_{i=1}^{N_c} \int_0^1 P(R) dR, \quad (11)$$

式中: $P$  为准确率; $R$  为召回率; $N_c$  表示缺陷类别数; $N_{TP}$  表示缺陷区域被正确检测的个数; $N_{FP}$  表示正常区

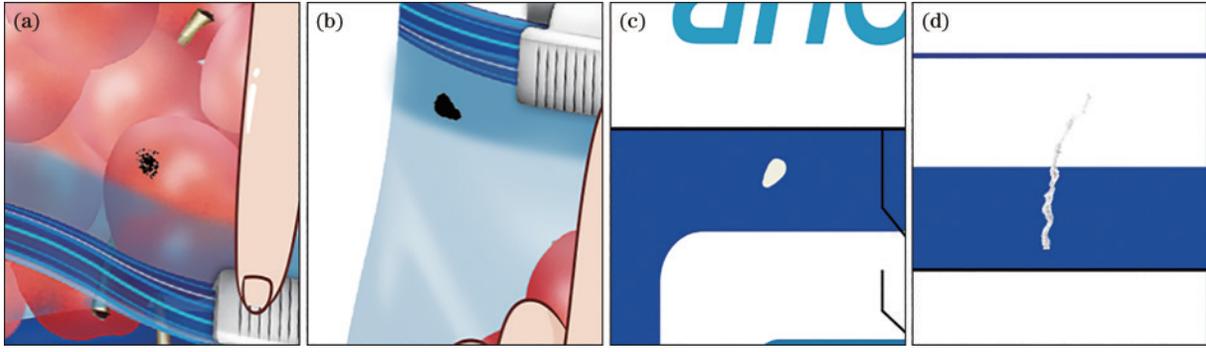


图5 印刷品缺陷类型。(a)卫星墨滴;(b)脏点;(c)漏印;(d)裂痕

Fig. 5 Types of printing defects. (a) Satellite droplet; (b) spots; (c) missing print; (d) crack

域被误检的个数;  $N_{FN}$  表示缺陷区域被漏检的个数。

同时采用FPS作为模型的速度指标, 检验印刷品缺陷目标检测模型的检测速度。FPS表示每秒钟能够检测图片的数量, 公式为

$$F_{FPS} = \frac{N}{T}, \quad (12)$$

式中:  $N$ 代表检测图片的数量;  $T$ 代表检测总时间。

#### 4.4 实验结果分析

为了验证所提YOLOv5l算法对印刷品缺陷检测的有效性, 设计了2组实验: 第1组实验验证不同改进模块对模型性能的影响; 第2组实验比较所提算法与现有算法的印刷品缺陷检测性能。

本实验采用YOLOv5l的预训练模型进行迁移学习, 输入尺寸为  $640 \times 640$ 。YOLOv5l模型和所提改进的缺陷检测算法在训练过程中的损失函数变化情况如图6所示, 可以看出, 损失值在开始时下降较快, 在25轮之后波动起伏开始变小, 损失曲线逐渐降低并趋于平稳, 当迭代次数达到200时损失值趋于稳定, 模型收敛, 并且改进后的算法在训练过程中的收敛速度更快、损失函数值更小。

##### 4.4.1 不同改进模块对模型性能的影响

表3为不同改进方法对于网络性能影响的实验结

表3 不同改进模块的实验结果

Table 3 Experimental results of different improvement modules

Model	Four detection scales	ODConv	C3Ghost	mAP / %	Speed / (frame · s <sup>-1</sup> )
YOLOv5l	—	—	—	94.4	48.1
Improvement 1	✓	—	—	96.5	40.8
Improvement 2	✓	✓	—	97.7	39.1
Improvement 3	✓	✓	✓	97.3	44.1

##### 4.4.2 主流目标检测模型性能对比实验

表4为不同目标检测算法的性能对比实验结果。从表4可以看出, 所提改进YOLOv5l算法要优于EfficientDet、Faster R-CNN、SSD、YOLOv3、YOLOv4、YOLOv5l等主流目标检测算法, mAP相比于现有的印刷品缺陷检测算法Siamese-YOLOv4提高2.7百分点, 其中, 卫星墨滴缺陷提高1.2百分点, 脏点缺陷提

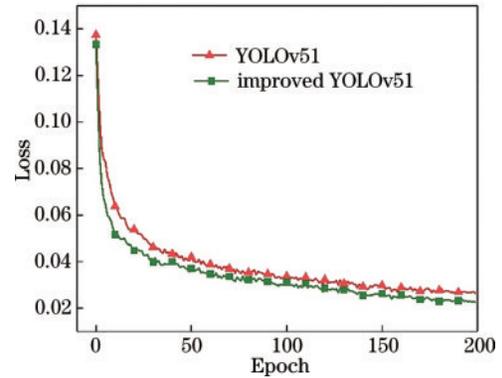


图6 损失变化曲线

Fig. 6 Loss variation curve

果, “✓”表示在网络模型中使用此方法, “—”表示在模型中不使用此方法。从表3可以看出: 在原YOLOv5l网络中增加多尺度检测后, 检测精度提升2.1百分点, 表明新增检测尺度的方法可以增强对小缺陷区域的检测能力; 在此基础上将Neck中的普通卷积替换为全维度动态卷积, mAP值又上升1.2百分点, 说明全维度动态卷积能够提高网络的上下文信息挖掘能力, 让网络更加关注印刷品缺陷信息; 在此基础上将Neck中的C3模块替换为C3Ghost模块, 速度提高5 frame · s<sup>-1</sup>, mAP仅降低0.4百分点。

高3百分点, 漏印缺陷提高3.6百分点, 裂痕缺陷提高3百分点。

所提算法的mAP比原始YOLOv5l算法提高2.9百分点, 其中, 卫星墨滴缺陷提高3.5百分点, 漏印缺陷提高1.4百分点, 裂痕缺陷提高6.8百分点, 脏点缺陷的检测精度未提升, 这可能是该类缺陷与背景信息重叠导致的。尽管脏点缺陷的检测精度并未提

表 4 不同目标检测算法的性能对比

Table 4 Performance comparison of different target detection algorithms

unit: %

Model	AP( $R_{iou}=0.5$ )				mAP
	Satellite droplet	Spots	Missing print	Crack	
EfficientDet <sup>[18]</sup>	89.1	88.7	84.3	79.8	85.5
Faster R-CNN <sup>[18]</sup>	90.3	93.8	87.1	84.2	88.8
SSD <sup>[18]</sup>	82.5	90.4	54.0	63.7	72.7
YOLOv3 <sup>[18]</sup>	87.2	90.9	82.3	83.2	85.9
YOLOv4 <sup>[18]</sup>	90.5	92.1	87.5	85.7	88.9
Siamese-YOLOv4 <sup>[18]</sup>	98.2	96.5	92.0	91.7	94.6
YOLOv5l	95.9	99.5	94.2	87.9	94.4
Proposed model	99.4	99.5	95.6	94.7	<b>97.3</b>

升,但对于其他缺陷,所提算法均取得了较好的效果。

为了更加直观地观察改进 YOLOv5l 算法与原算法的性能区别,分别使用两种算法在同一张印刷品缺

陷图上进行检测,检测结果如图 7 所示。从图 7(a)、(b)可以看出,原 YOLOv5l 算法漏检了一个裂痕缺陷,改进后的 YOLOv5l 算法将印刷品上的缺陷区域全部检出。

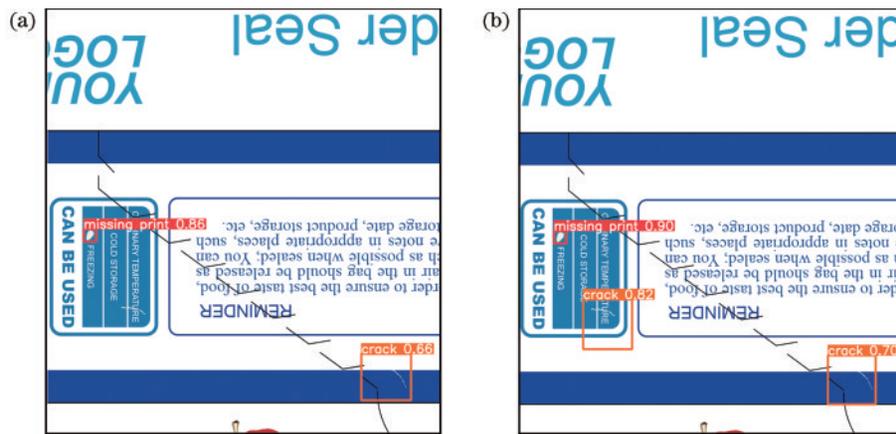


图 7 YOLOv5l 与改进 YOLOv5l 的印刷缺陷检测效果对比图。(a) YOLOv5l 的检测结果;(b)改进 YOLOv5l 的检测结果

Fig. 7 Comparison of printing defect detection effects between YOLOv5l and improved YOLOv5l. (a) Detection results of YOLOv5l; (b) detection results of improved YOLOv5l

## 5 结 论

为了满足印刷生产中对缺陷检测的需求,提出一种基于改进 YOLOv5l 的印刷品缺陷检测算法。该算法通过增加检测尺度来充分利用浅层特征信息,增强对小缺陷区域的检测效果,通过替换 Neck 中的普通卷积为全维度动态卷积增强网络对缺陷上下文信息的捕获能力,最后将 Neck 中的 C3 模块全部用 C3Ghost 模块替换,平衡模型的速度和精度。实验结果表明,所提改进 YOLOv5l 算法的 mAP 相比于原 YOLOv5l 提升 2.9 百分点,比现有的 Siamese-YOLOv4 算法提升 2.7 百分点,3 种改进策略均对网络的印刷品缺陷检测性能有帮助,并且融合后的网络也能较好地发挥各改进的优点。所提算法具有较高的检测精度和检测速度,为印刷生产中的缺陷检测提供了新思路。本文只对印刷品 4 种常见缺陷做了检测研究,在实际的印刷生产中,由于印刷机故障、印版磨损或润湿不良等原因还

会出现其他缺陷,但是由于缺少足够的样本训练,模型无法学习到缺陷的特征。目前,Artificial Intelligence Generated Content(AIGC)在图像生成方面效果惊人,具有广泛的应用潜力,后续可以进一步收集具有代表性的印刷缺陷样本,利用 AIGC 技术扩充数据集,进行更多印刷品缺陷类型的分类识别。

## 参 考 文 献

- [1] Ren S Q, He K M, 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, 2017, 39(6): 1137-1149.
- [2] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[M]//Leibe B, Matas J, Sebe N, et al. Computer vision-ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9905: 21-37.
- [3] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition

- (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 779-788.
- [4] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6517-6525.
- [5] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. (2018-04-08) [2023-04-05]. <https://arxiv.org/abs/1804.02767>.
- [6] Lin J P, Haberstroh F, Karsch S, et al. Applications of object detection networks in high-power laser systems and experiments[J]. High Power Laser Science and Engineering, 2023, 11: e7.
- [7] Shen L Y, Lang B H, Song Z X. CA-YOLO: model optimization for remote sensing image object detection[J]. IEEE Access, 2023, 11: 64769-64781.
- [8] Khan S A, Lee H J, Lim H. Enhancing object detection in self-driving cars using a hybrid approach[J]. Electronics, 2023, 12(13): 2768.
- [9] Ou J H, Wang J G, Xue J, et al. Infrared image target detection of substation electrical equipment using an improved Faster R-CNN[J]. IEEE Transactions on Power Delivery, 2023, 38(1): 387-396.
- [10] Chen M Q, Yu L J, Zhi C, et al. Improved Faster R-CNN for fabric defect detection based on Gabor filter with Genetic Algorithm optimization[J]. Computers in Industry, 2022, 134: 103551.
- [11] Zhao C, Shu X, Yan X, et al. RDD-YOLO: a modified YOLO for detection of steel surface defects[J]. Measurement, 2023, 214: 112776.
- [12] Tian R S, Jia M P. DCC-CenterNet: a rapid detection method for steel surface defects[J]. Measurement, 2022, 187: 110211.
- [13] 孙连山, 魏婧雪, 朱登明, 等. 基于 AM-YOLOv3 模型的铝型材表面缺陷检测算法[J]. 激光与光电子学进展, 2021, 58(24): 2415007.  
Sun L S, Wei J X, Zhu D M, et al. Surface defect detection algorithm of aluminum profile based on AM-YOLOv3 model[J]. Laser & Optoelectronics Progress, 2021, 58(24): 2415007.
- [14] 孙耀泽, 高军伟. 基于改进 YOLOv5 的轮对踏面缺陷检测[J]. 激光与光电子学进展, 2022, 59(22): 2215003.  
Sun Y Z, Gao J W. Wheel tread defect detection based on improved YOLOv5[J]. Laser & Optoelectronics Progress, 2022, 59(22): 2215003.
- [15] 王佑芯, 陈斌. 基于深度对比网络的印刷缺陷检测方法[J]. 计算机应用, 2023, 43(1): 250-258.  
Wang Y X, Chen B. Printing defect detection method based on depth contrast network[J]. Journal of Computer Applications, 2023, 43(1): 250-258.
- [16] 王海涛, 高玉栋, 侯建新, 等. 基于 DCGAN 的印刷缺陷检测方法[J]. 哈尔滨理工大学学报, 2021, 26(6): 24-32.  
Wang H T, Gao Y D, Hou J X, et al. A method of printing defect detection based on DCGAN[J]. Journal of Harbin University of Science and Technology, 2021, 26(6): 24-32.
- [17] 楼豪杰, 郑元林, 廖开阳, 等. 基于 Siamese-YOLOv4 的印刷品缺陷目标检测[J]. 计算机应用, 2021, 41(11): 3206-3212.  
Lou H J, Zheng Y L, Liao K Y, et al. Defect target detection for printed matter based on Siamese-YOLOv4[J]. Journal of Computer Applications, 2021, 41(11): 3206-3212.
- [18] 楼豪杰. 基于少样本学习的印刷品微小缺陷检测方法研究[D]. 西安: 西安理工大学, 2022.  
Lou H J. Research on detection method of small defects in printed matter based on small sample learning[D]. Xi'an: Xi'an University of Technology, 2022.
- [19] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 936-944.
- [20] Liu S, Qi L, Qin H F, et al. Path aggregation network for instance segmentation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 8759-8768.
- [21] Li C, Zhou A J, Yao A B. Omni-dimensional dynamic convolution[EB/OL]. (2022-09-16) [2023-05-06]. <https://arxiv.org/abs/2209.07947>.
- [22] Han K, Wang Y H, Tian Q, et al. GhostNet: more features from cheap operations[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 1577-1586.
- [23] Wang B W, Huang F. A lightweight deep network for defect detection of insert molding based on X-ray imaging[J]. Sensors, 2021, 21(16): 5612.