

基于改进 Faster R-CNN 的食品包装缺陷检测

Food packaging defect detection by improved network model of Faster R-CNN

夏军勇 王康宇 周宏娣

XIA Junyong WANG Kangyu ZHOU Hongdi

(湖北工业大学机械工程学院, 湖北 武汉 430068)

(School of Mechanical Engineering, Hubei University of Technology, Wuhan, Hubei 430068, China)

摘要: 目的: 对纸质包装盒缺陷进行准确的识别与定位。**方法:** 应用改进 Faster R-CNN 的网络模型自动对包装盒缺陷进行检测。对训练集图片进行数据增强并添加噪声, 提升模型的训练精度和鲁棒性; 将特征提取网络替换为 ResNet50, 并融合特征金字塔网络(FPN), 提高模型多尺度检测的能力; 使用 K-means++ 对数据集中缺陷尺度进行聚类, 优化锚框方案。**结果:** 改进后的 Faster R-CNN 模型在测试集上的平均准确率(AP)达到 93.9%, 检测速度达到 8.65 帧/s。**结论:** 应用改进的 Faster R-CNN 模型能够有效检测出包装盒缺陷并定位, 可应用于包装盒缺陷的自动检测与分拣。

关键词: Faster R-CNN; ResNet50; 缺陷检测; 特征金字塔
Abstract: **Objective:** Accurate identification and location of paper packaging box defects. **Methods:** The improved network model of Faster R-CNN was applied to automatically detect box defects. The data of the training set picture was enhanced and noise was added to improve the training accuracy and robustness of the model. The feature extraction network was replaced with ResNet50, and the feature pyramid network (FPN) was fused to improve the multi-scale detection ability of the model. K-means++ was used to cluster the defect scale in the dataset and optimize the anchor box scheme. **Results:** The average accuracy (AP) of the improved Faster R-CNN model on the test set reached 93.9%, and the detection speed reached 8.65 f/s. **Conclusion:** The improved Faster R-CNN model can effectively detect and locate box defects, which can be applied to the automatic detection and sorting of box defects.

Keywords: Faster R-CNN; ResNet50; defect detection; feature pyramid network (FPN)

食品在生产过程中, 外包装不可避免会出现部分缺

基金项目: 湖北省科技创新人才计划(编号: 2023DJCO68)

作者简介: 夏军勇(1976—), 男, 湖北工业大学教授级高工, 硕士生导师, 博士。E-mail: 20171013@hbut.edu.cn

收稿日期: 2023-05-26 **改回日期:** 2023-10-21

陷^[1], 如撕裂、破损或破洞, 这些缺陷会使包装丧失完整性, 进而导致食品在运输和存储过程中被挤压、碰撞或摔落。传统的人工检测方法不仅效率低, 还会出现漏检的情况^[2]。近年来, 深度学习在工业中的应用越来越广泛, 陈雪纯等^[3]提出了一种改进 MobileNetV2 的轻量化包装缺陷检测方法; 李忠诚等^[4]基于改进的 YOLOv3 算法, 提高了卷纸包装缺陷检测的准确率和速率; 暴泰熳等^[5]采用一种基于深度学习中语义分割任务的表面缺陷检测方法, 实现了对纸质包装表面缺陷进行检测。目前, 深度学习在缺陷检测方面应用较广, 但也存在一些不足, 如对包装盒缺陷进行分割检测的精度较低^[5], 无法满足工业使用要求; 对中小目标检测效果较差^[6], 容易产生漏检等; 一阶段目标检测模型^[7]检测速度快, 但检测精度受限; 二阶段目标检测模型精度较一阶段目标检测模型高^[8], 但检测速度较慢。

为实现对纸质包装盒缺陷进行准确的识别与定位, 研究拟在检测精度较高的二阶段目标检测模型 Faster R-CNN^[9]上进行改进, 提出一种能够对纸质包装盒缺陷进行识别的模型。通过 3 个方面(ResNet50 网络^[10]融合特征金字塔结构、双线性插值法和聚类)的改进提高模型的检测准确性, 以期对食品纸质包装缺陷的检测研究提供参考。

1 材料与方法

1.1 数据预处理

图片数据采集于某纸板生产厂, 共包含 1 000 张包装盒缺陷图片, 图片格式为 jpg, 大小包括 1 080 像素 × 1 440 像素和 1 440 像素 × 1 080 像素两种, 比例约为 1 : 1, 使用 labelImg 软件进行标注, 标注的标签为 VOC 格式。将数据集中的图片按照 8 : 2 的比例随机划分, 得到 800 张用于网络模型训练的图片和 200 张用于模型效果验证的图片, 训练集图片与验证集图片没有交集。由于数据集较小, 为了得到更好的训练效果, 采用随机水平翻转以及垂直翻转对训练集图片进行数据增强处理^[11]。此

外,为了增强模型的鲁棒性,对训练集图片随机添加高斯噪声^[12]。经过数据增强后的训练集图片为 4 000 张,预处理后的图片如图 1 所示。



图 1 预处理后图片

Figure 1 Preprocessed picture

1.2 网络模型的改进

1.2.1 原始网络模型 Faster R-CNN Fast R-CNN 是二阶段目标检测模型中的经典,而 Faster R-CNN 是其改进版。Faster R-CNN 模型分为 4 个主要部分:特征提取网络(卷积)、区域候选网络(region proposal network)、兴趣域池化层(RoI pooling)及分类与回归,其中 RPN 网络预先产生大量候选框,使得 Faster R-CNN 相比于 SSD^[13]、YOLOv3^[14] 和 YOLOv4^[15] 等一阶目标检测算法能够实现更好的检测精度^[16-17]。其工作原理:利用特征提取网络提取图像特征,将特征输入 RPN 网络,RPN 网络根据预先设定的锚框尺度和比例,在特征图上生成一系列的建议框,经过 NMS 极大值抑制后获取最终建议区域。将建议区域与图像特征融合后输入到 RoI pooling 对建议区域进行池化,以便将尺寸不固定的特征图转变为固定的尺寸^[18],用于后续的全连接层进行目标分类和边界框回归。Faster R-CNN 模型结构如图 2 所示。

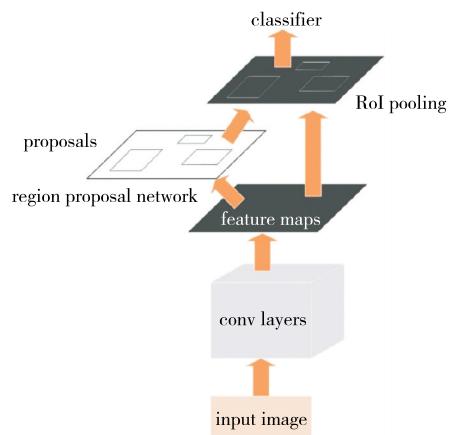


图 2 Faster R-CNN 模型结构

Figure 2 Faster R-CNN network structure

1.2.2 改进 Faster R-CNN 后的模型 图像特征图层次越浅,细节信息越丰富,语义信息越弱;图像特征图层次越深,细节信息越少,语义信息越强。为了更好地提取包装盒缺陷的特征,提高模型的泛化能力,选择使用更加深层次的特征提取网络,但是深层次的网络可能会造成梯度消失或梯度爆炸,并且产生网络退化。在 ResNet50 网络中,引入 BN 层(batch normalization)解决梯度消失或梯度爆炸的问题,并且引入残差(residual)解决网络退化的问题。故采用层次较深且性能较好的 ResNet50 替换 Faster R-CNN 中的特征提取网络,ResNet50 网络结构如图 3 所示。

数据集中部分缺陷尺度较小,采用深层次的特征提取网络可能会造成信息丢失,影响模型的精度,FPN (feature pyramid networks) 网络中采用自下而上和自上

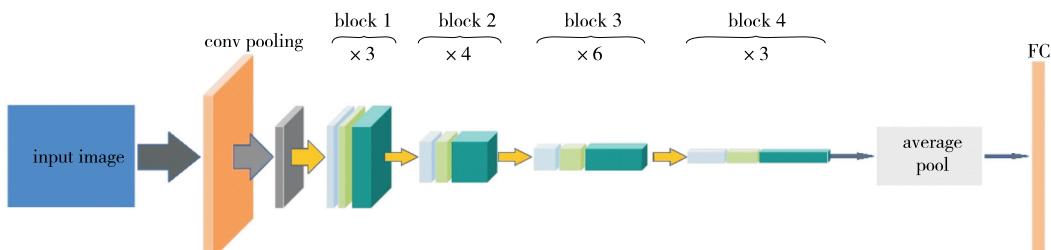


图 3 ResNet50 网络结构

Figure 3 ResNet50 network structure

而下的结构对图片特征进行处理^[19],使得包含小目标特征的尺度较大的特征层参与后续的预测与回归,提高模型的精度,FPN 网络结构如图 4 所示。为了进一步提高模型的性能,引入 FPN 结构,将 ResNet50 与 FPN 进行融合,在提取更强语义信息的同时减少信息的丢失,图 5 为融合后的网络结构。

使用 ResNet50+FPN 网络进行特征提取时,特征图尺寸对比原图缩小 32 倍,RoI pooling 经过两次浮点数取

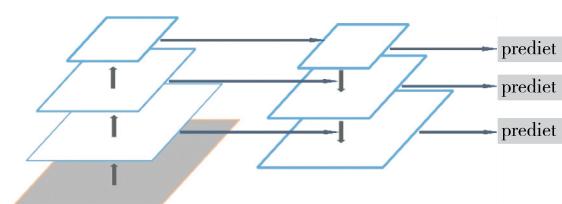


图 4 FPN (feature pyramid networks) 网络结构

Figure 4 FPN (feature pyramid networks) network structure

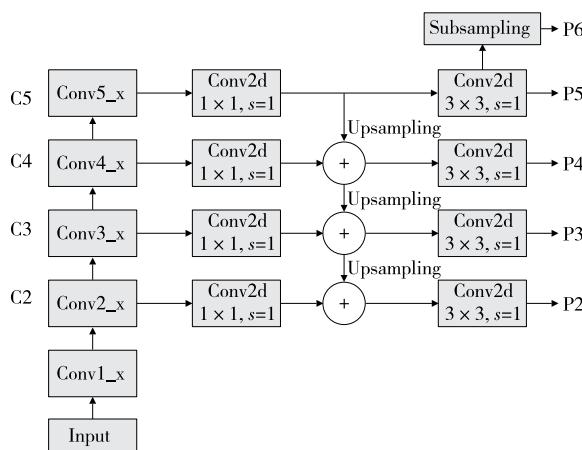


图 5 ResNet50+FPN 网络结构

Figure 5 ResNet50+FPN network structure

整量化,会造成后续回归精确度下降。为了解决这一问题,Mask R-CNN 中使用了 RoI Align^[20](图 6),通过双线性插值法,保留浮点数,避免取整对精度带来的不良影响。在模型中引入 RoI Align 结构,避免其精度下降。

Faster R-CNN 中的锚框尺度与数据集不同,原始锚框比例为 0.5,1.0,2.0,但数据集中标注框的尺度不一定与原始锚框相同,不合适的锚框尺度可能需要更多的训练迭代才能收敛,这样会增加训练时间和计算成本,而且锚框的尺度设置可能会影响模型对目标的敏感性,如果锚框的尺度过大或过小,可能会导致目标的漏检或误检。

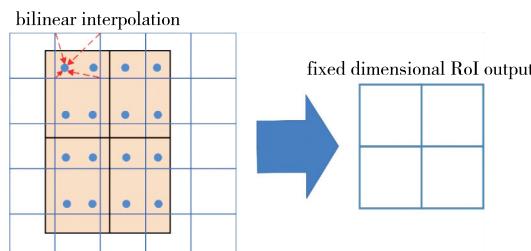


图 6 RoI Align

Figure 6 RoI Align

为了得到更加接近真实标注框的锚框尺度,选择使用 K-means++对数据集中的标注框进行聚类,聚类后结果如图 7 所示,得到 3 个聚类中心(552,1 113)、(352,337)、(1 126,426),故将锚框比例由原始的 0.5,1.0,2.0 修改为 0.49,1.0,2.6。

改进后的网络模型如图 8 所示。

1.2.3 损失函数 在模型训练过程中损失函数用来对模型进行评估和对参数进行优化,Faster R-CNN 网络结构中包含分类损失和回归损失,损失函数公式定义为:

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_c} \sum_i L_c(p_i, p_i^*) + \lambda \frac{1}{N_r} \sum_i p_i^* L_r(t_i, t_i^*), \quad (1)$$

式中:

p_i ——第 i 个锚框预测为真实标签的概率;

p_i^* ——正样本为 1,负样本为 0;

t_i ——第 i 个锚框的边界框回归参数;

t_i^* ——第 i 个锚框对应的真实框回归参数;

N_c ——分类样本数;

N_r ——回归样本数;

L_c ——分类层损失;

L_r ——回归层损失;

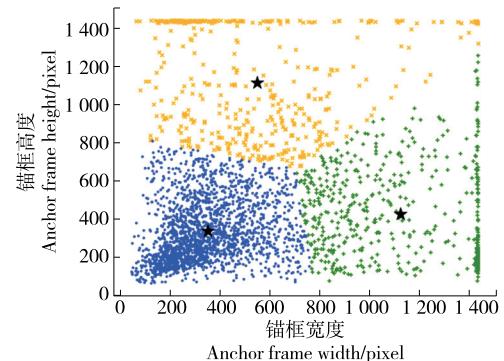


图 7 K-means++聚类结果

Figure 7 K-means++ clustering results

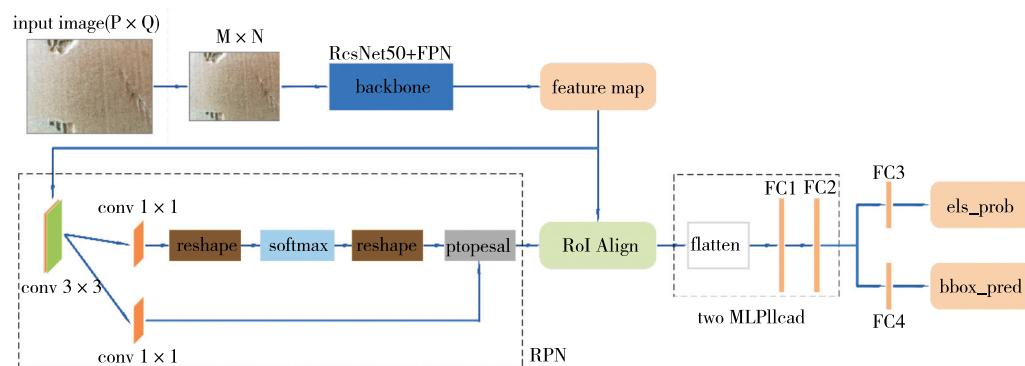


图 8 改进后的网络模型

Figure 8 Improved network model

λ ——权重系数。

分类损失公式定义为：

$$L_c(p_i, p_i^*) = -\lg(p_i p_i^* + (1-p_i^*)(1-p_i))。 \quad (2)$$

回归损失公式定义为：

$$L_r(t_i, t_i^*) = \sum_i \text{smooth}_{L_1}(t_i - t_i^*) , \quad (3)$$

$$\text{smooth}_{L_1}(t_i - t_i^*) = \begin{cases} 0.5(t_i - t_i^*)^2 (|t_i - t_i^*| < 1) \\ |t_i - t_i^*| - 0.5(|t_i - t_i^*| \geq 1) \end{cases} \quad (4)$$

1.3 试验方法及模型评估方法

1.3.1 试验模型对比 为验证网络模型的有效性,将其与不同的目标检测网络进行对比。选取一阶段目标检测模型中的 YOLOv3 和 YOLOv4 作为对比对象,YOLOv3 由于其速度快,适合在实时检测场景中使用,检测精度较高,对小目标也具有一定的检测能力,但是在复杂场景中检测精度可能会降低;YOLOv4 在 YOLOv3 的基础上进行了改进,在复杂场景中的表现优于 YOLOv3。研究所选二阶段目标检测模型 Faster R-CNN 在检测精度上有优势,但是检测速度较一阶段目标检测模型慢,对比使用 VGG16 和 ResNet50 作为特征提取网络的 Faster R-CNN 模型,由于 ResNet50 网络层次较深,所以提取深层次特征信息能力较强,但检测速度稍慢;在 ResNet50 网络中融入特征金字塔网络可以进一步提升其提取特征的能力,防止小目标特征信息丢失,提高模型的检测精度;使用 K-means++对模型候选框尺度进行优化后,可以使建议框的尺度更加接近真实的区域,减少训练时间,并提高检测精度。

1.3.2 试验方法及参数设置 对不同网络模型使用相同训练集与测试集,对比在测试集上的表现。所有模型训练环境为 Linux 系统,训练框架为 Pytorch,版本为 1.11.0,CUDA 版本为 11.4。所有试验模型均使用迁移学习的方法进行训练,训练时 batch size 设为 4,训练 30 个 epoch,初始学习率设置为 0.01,对学习率使用 SGD 优化器进行优化(每经过 3 个 epoch 学习率衰减为原来的 0.33 倍),其中动量(momentum)设置为 0.9,权重衰退(weight_decay)参数设置为 0.0001。经过多次试验后发现,Faster R-CNN 系列模型 RPN 中进行 NMS 处理时使用的 IoU(预测框与真实框重叠部分占两者集合区域的比例)阈值设置为 0.7 时能取得较好的效果。试验模型见表 1。

1.3.3 模型评估方法 目标检测算法的检测结果共 4 类: T_p (正样本预测为正)、 T_n (负样本预测为负)、 F_p (负样本预测为正)、 F_n (正样本预测为负)。为对比所提算法模型与其他算法模型的性能,采用精确率 P (precision)、分类召回率 R (recall)、平均精度 A_p (average precision)对模型性能进行评估^[21]。

精确率计算公式如式(5),用于评估模型检测缺陷的准确性。

表 1 试验模型

Table 1 Experimental models

模型	模型框架	特征提取网络
A	YOLOv3	Darknet53
B	YOLOv4	CSPDarknet53
C	Faster R-CNN	VGG16
D	Faster R-CNN	ResNet50
E	Faster R-CNN+FPN	ResNet50
F	Faster R-CNN+FPN+RoI Align	ResNet50
G	Faster R-CNN+FPN+RoI Align+K-means++	ResNet50

$$P = \frac{T_p}{T_p + F_p}, \quad (5)$$

式中:

P ——精确率, %。

召回率计算公式如式(6),用于评估模型找到缺陷正样本的能力。

$$R = \frac{T_p}{T_p + F_n}, \quad (6)$$

式中:

R ——精确率, %。

平均精度计算:

$$A_p = \int_0^1 P dR, \quad (7)$$

式中:

A_p ——平均精度, %;

P ——准确率, %;

R ——召回率, %。

2 结果与分析

2.1 检测精度对比

如表 2 所示,一阶段网络模型 YOLOv3 和 YOLOv4 在 IoU 为 0.5 时的 AP 值明显低于二阶段网络模型 Faster R-CNN。分别使用 VGG16 和 ResNet50 作为 Faster R-CNN 特征提取网络时,AP 值无明显差别,但是使用 ResNet50 融合特征金字塔作为特征提取网络时,精度和召回率有明显的提升。进一步使用 RoI Align 后,IoU 为 0.5 时的 AP 值对比只使用 ResNet50 作为特征提取网络的模型提升了 3.3 个百分点,而 IoU 为 0.75 时的 AP 值提升了 16.9 个百分点,IoU 为 0.5/0.95(预测框与真实框重叠部分占两者集合区域的比例从 0.5 以 0.05 的增量到 0.95)的召回率提升了 6.8 个百分点。使用 K-means++对锚框尺度进行修改后 IoU 为 0.5 和 IoU 为 0.5/0.95 时的 AP 值进一步提高了 0.5 个百分点,IoU 为 0.5/0.95 的召回率提高了 0.4 个百分点,但是在 IoU 为 0.75 时的 AP 值反而下降了 1.5 个百分点。由结果分析

表 2 缺陷 AP 和召回率
Table 2 AP and recall for defect

模型	AP 值/%			召回率(IoU 为 0.5/0.95)
	IoU 为 0.5	IoU 为 0.75	IoU 为 0.5/0.95	
A	79.3	52.2	48.0	0.552
B	83.3	53.5	46.3	0.579
C	89.5	54.6	51.4	0.602
D	90.1	56.0	53.1	0.609
E	93.1	71.2	61.2	0.671
F	93.4	72.9	61.6	0.677
G	93.9	71.4	62.1	0.681

可知,二阶段检测模型在检测精度上的表现更加出色,明显高于一阶段检测模型;使用 ResNet50+FPN 作为特征提取网络时模型精度和召回率均有明显提升,证明特征金字塔网络对小目标检测的有效性。

2.2 训练损失结果对比

图 9 为模型 G 与模型 F 训练时损失结果对比,可以看出,在同样的学习率下,初始训练时模型 G 损失低于模型 F,证明使用 K-means++ 对数据集进行聚类后得到的锚框尺度与真实标注框更加接近,对加快网络训练起到了积极的作用。

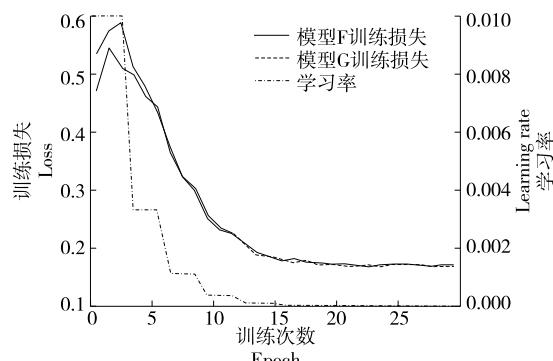


图 9 训练损失结果
Figure 9 Training loss results

2.3 检测速度对比

如表 3 所示,模型 G 检测速度为 8.65 帧/s,由于 Faster R-CNN 检测模型在进行目标预测时需要经历区分前景与背景和提取对应特征图上特征这两个阶段,而 YOLO 系列模型只需要一次性产生预测结果,所以 YOLO 系列的检测速度明显比 Faster R-CNN 系列模型高。

2.4 模型预测结果

利用训练好的网络模型对缺陷图片进行预测,预测结果包含预测框和置信度,分别表现模型的回归准确性和分类准确性。模型 A 和模型 B 预测结果见图 10。

使用 VGG16 和使用 Resnet50 作为 Faster R-CNN

表 3 检测速度对比
Table 3 Comparison of detection speeds

模型	检测速度/(帧·s ⁻¹)
A	22.70
B	22.99
C	9.19
D	7.72
E	7.70
F	7.89
G	8.65

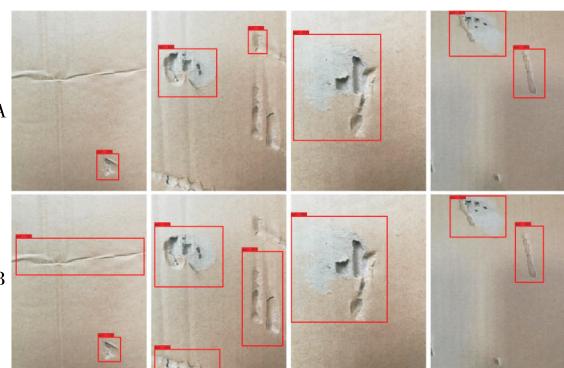


图 10 模型 A 和 B 预测结果
Figure 10 Model A and B predicted results

模型的特征提取网络时,相比较于 YOLOv3 和 YOLOv4,漏检情况有很大的提升,每个缺陷的置信度比较接近,均能够准确识别出缺陷。但是定位不够准确,某些框图尺度过大,与实际缺陷位置差别较大。模型 C 和模型 D 预测结果见图 11。

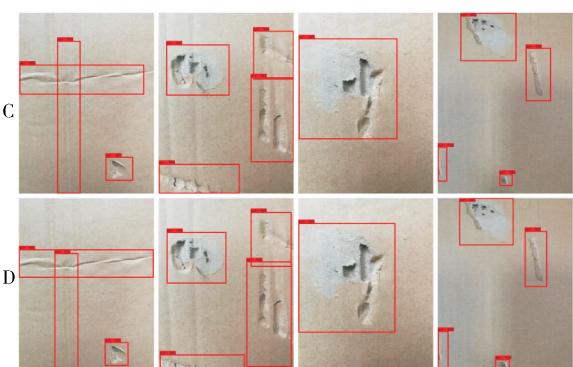


图 11 模型 C 和 D 预测结果
Figure 11 Model C and D predicted results

使用特征金字塔结构后,缺陷检测的定位准确率对比如模型 D 有所提升,证明特征金字塔结构能够提升网络对包装盒缺陷的检测能力。模型 E 预测结果见图 12。

对比模型 F 和模型 G 的预测结果可以看出,是否使用 K-means++ 在检测精度上无明显的差别,但是使用

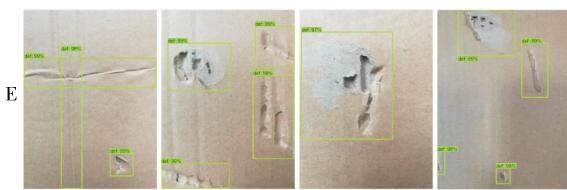


图 12 模型 E 预测结果

Figure 12 Model E predicted results

K-means++的模型 G 在某些缺陷上生成的标注框比模型 F 更加接近真实缺陷范围,由此可见,对数据集进行聚类对提升模型的回归精度有一定的帮助。模型 F 和模型 G 的预测结果见图 13。

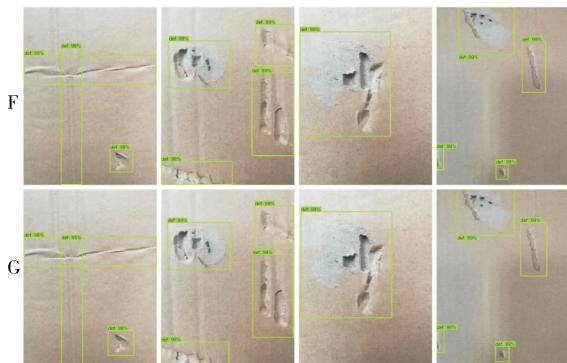


图 13 模型 F 和 G 预测结果

Figure 13 Model F and G predicted results

3 结论

使用改进的 Faster R-CNN 网络模型对包装盒缺陷进行检测,改进后的模型在验证集上的平均准确率达到了 93.9%,检测速度达到了 8.65 帧/s,满足工业使用的需求。使用特征金字塔网络后的模型在精度和召回率上都有明显的提升,证明特征金字塔网络在小目标检测中的有效性,对数据集使用聚类之后,模型的训练速度以及回归精度都有所提升。虽然研究使用的模型在精度上的表现比较出色,但是在检测速度上还有提升的空间,一阶段目标检测模型的速度基本能够满足实时检测的需求,但是精度不高。因此,下一步需要研究的是如何在保证检测精度的同时提升检测速度。

参考文献

- [1] 李建明, 杨挺, 王惠栋. 基于深度学习的工业自动化包装缺陷检测方法[J]. 包装工程, 2020, 41(7): 175-184.
LI J M, YANG T, WANG H D. Industrial automation packaging defect detection method based on deep learning [J]. Packaging Engineering, 2020, 41(7): 175-184.
- [2] 楚晗, 王爱霞, 高尊华, 等. 食品多层包装内包缺陷的问题分析及处理[J]. 包装工程, 2019, 40(15): 200-205.
CHU H, WANG A X, GAO Z H, et al. Analysis and treatment of

defects in inner packaging of food multi-layer package [J]. Packaging Engineering, 2019, 40(15): 200-205.

- [3] 陈雪纯, 方宇伦, 杜世昌, 等. 基于深度学习的包装缺陷快速检测方法[J]. 机械设计与研究, 2021, 37(6): 165-169, 178.
CHEN X C, FANG Y L, DU S C, et al. Rapid packaging defect detection method based on deep learning [J]. Machine Design & Research, 2021, 37(6): 165-169, 178.
- [4] 李志诚, 曾志强. 基于改进 YOLOv3 的卷纸包装缺陷实时检测算法[J]. 中国造纸学报, 2022, 37(2): 87-93.
LI Z C, ZENG Z Q. Real-time defect detection algorithm for roll paper packaging based on improved YOLOv3 [J]. Transactions of China Pulp and Paper, 2022, 37(2): 87-93.
- [5] 暴泰焚, 焦慧敏, 张皓, 等. 基于语义分割的纸质包装产品表面缺陷检测[J]. 制造业自动化, 2023, 45(3): 216-220.
BAO T F, JIAO H M, ZHANG H, et al. Surface defect detection of paper packaging products based on semantic segmentation [J]. Manufacturing Automation, 2023, 45(3): 216-220.
- [6] 邓姗姗, 黄慧, 马燕. 基于改进 Faster R-CNN 的小目标检测算法[J]. 计算机工程与科学, 2023, 45(5): 869-877.
DENG S S, HUANG H, MA Y. A small object detection algorithm based on improved Faster R-CNN [J]. Computer Engineering & Science, 2023, 45(5): 869-877.
- [7] 朱豪, 周顺勇, 刘学, 等. 基于深度学习的单阶段目标检测算法综述[J]. 工业控制计算机, 2023, 36(4): 101-103.
ZHU H, ZHOU S Y, LIU X, et al. Survey of single-stage object detection algorithms based on deep learning [J]. Industrial Control Computer, 2023, 36(4): 101-103.
- [8] 刘寅, 夏舸, 王强, 等. 基于 Faster RCNN 的燃气轮机滑油管红外监测与识别[J]. 激光与红外, 2023, 53(4): 544-550.
LIU Y, XIA G, WANG Q, et al. Infrared monitoring and identification of gas turbine oil pipe based on Faster RCNN [J]. Laser & Infrared, 2023, 53(4): 544-550.
- [9] 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.
- [10] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. [S. l.]: IEEE Press, 2016: 770-778.
- [11] BUSLAEV A, IGLOVIKOV V I, KHVEDCHENYA E, et al. Albumentations: Fast and flexible image augmentations [J]. Information, 2020, 11(2): 125.
- [12] NAZARE T S, DA COSTA G B P, CONTATO W A, et al. Deep convolutional neural networks and noisy images[C]// Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications: 22nd Iberoamerican Congress, CIARP 2017, Valparaíso, Chile, November 7-10, 2017, Proceedings 22. [S. l.]: Springer International Publishing, 2018: 416-424.

(下转第 151 页)

- 蛋白质结构变化的差异[J]. 现代食品科技, 2021, 37(5): 160-168.
- YU X P, YUAN Y M, YE Y, et al. Differences of shrimp meat quality and protein structure changes under different heat treatment methods[J]. Modern Food Science and Technology, 2021, 37(5): 160-168.
- [14] MAHSA M, MOLOUD N, REZA E, et al. Effect of thawing under an alternating magnetic field on rainbow trout (*Oncorhynchus mykiss*) fillet characteristics [J]. Food Chemistry, 2023, 402: 134255.
- [15] 张喜才. 石斑鱼冷藏过程中品质评价、蛋白变化以及内源性蛋白酶作用机制研究[D]. 上海: 上海海洋大学, 2020.
- ZHANG X C. Quality evaluation, protein changes and action mechanism of endogenous protease in grouper during cold storage [D]. Shanghai: Shanghai Ocean University, 2020.
- [16] CHANADDA S, PANPRADUB S, KASARAT P, et al. Effects of β -alanine and L-histidine supplementation on carnosine contents in and quality and secondary structure of proteins in slow-growing Korat chicken meat[J]. Poultry Science, 2022, 101: 101776.
- [17] 王琳涵, 乔凯娜, 丁奇, 等. 不同煮制时间对鸡汤中呈味物质的影响[J]. 精细化工, 2018, 35(10): 1 683-1 690.
- WANG L H, QIAO K N, DING Q, et al. Effect of different cooking time on flavoring substances in chicken soup [J]. Fine Chemical Industry, 2018, 35(10): 1 683-1 690.
- [18] 熊大林, 段亚飞, 陈成勋, 等. 高温与氨氮复合胁迫对凡纳滨对虾渗透调节的影响[J]. 水产科学, 2021, 40(4): 475-482.
- XIONG D L, DUAN Y F, CHEN C X, et al. Effects of combined stress of high temperature and ammonia nitrogen on osmotic regulation of Litopenaeus vannamei[J]. Aquatic Sciences, 2021, 40(4): 475-482.
- [19] 陈桂平. 草鱼低温贮藏期间质构及风味物质变化研究[D]. 长沙: 湖南农业大学, 2014.
- CHEN G P. Study on texture and flavor changes of grass carp during cryogenic storage [D]. Changsha: Hunan Agricultural University, 2014.
- [20] 林瑞榕, 袁红飞, 钟小清, 等. 不同熬制工艺对“佛跳墙”营养成分及风味物质的影响[J]. 食品科学, 2023, 44(4): 240-246.
- LIN R R, YUAN H F, ZHONG X Q, et al. Effects of different cooking techniques on nutrient composition and flavor of "Fotiao Wall"[J]. Food Science, 2023, 44(4): 240-246.
- [21] REN S, LI P P, GENG Z M, et al. Lipolysis and lipid oxidation during processing of chinese traditional dry-cured white amur bream (*Parabramis pekinensis*) [J]. Journal of Aquatic Food Product Technology, 2017, 26(6): 719-730.
- [22] ZHAO D D, HU J, CHEN W X. Analysis of the relationship between microorganisms and flavour development in dry-cured grass carp by high-throughput sequencing, volatile flavour analysis and metabolomics[J]. Food Chemistry, 2022, 368: 130889.
- [23] 刘瑶, 乔海军, 贾志龙, 等. 气相色谱—离子迁移谱结合化学计量学分析成熟时间对牦牛乳干酪挥发性风味物质的影响[J]. 分析与检测, 2022, 48(17): 265-272.
- LIU Y, QIAO H J, JIA Z L, et al. Effects of gas chromatography-ion-migration spectrometry combined with stoichiometry on volatile flavor compounds of yak milk cheese [J]. Analysis and Detection, 2022, 48(17): 265-272.

(上接第 136 页)

- [13] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]// Computer Vision-ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11-14, 2016, Proceedings, Part I 14. [S. l.]: Springer International Publishing, 2016: 21-37.
- [14] REDMON J, FARHADI A. YOLOv3: An incremental improvement [C]// IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 18040276.
- [15] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection [C]// IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 10934.
- [16] 范加利, 田少兵, 黄葵, 等. 基于 Faster R-CNN 的航母舰面多尺度目标检测算法[J]. 系统工程与电子技术, 2022, 44(1): 40-46.
- FAN J L, TIAN S B, HUANG K, et al. Multi-scale object target detection algorithm for aircraft carrier surface based on Faster R-CNN[J]. Systems Engineering and Electronics, 2022, 44(1): 40-46.
- [17] 王昊, 查涛, 乜灵梅, 等. 基于改进 Faster R-CNN 的隐形眼镜表面缺陷检测算法[J]. 激光与光电子学进展, 2023, 60(20): 141-147.
- WANG H, ZHA T, NIE L M, et al. Contact lens surface defect detection algorithm based on improved Faster R-CNN[J]. Laser & Optoelectronics Progress, 2023, 60(20): 141-147.
- [18] 常莉莉, 王贤敏, 王春胜. 基于改进 Faster R-CNN 的码头自动识别[J]. 遥感学报, 2022, 26(4): 752-765.
- CHANG L L, WANG X M, WANG C S. Automatic dock identification based on improved Faster R-CNN [J]. National Remote Sensing Bulletin, 2022, 26(4): 752-765.
- [19] XIE J, PANG Y W, PAN J, et al. Complementary feature pyramid network for object detection[J]. Acm Transactions on Multimedia Computing Communications and Applications, 2023, 19(6): 1-15.
- [20] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN [C]// Proceedings of the IEEE International Conference on Computer Vision. Los Alamitos: IEEE Computer Society Press, 2017: 2 980-2 988.
- [21] 张志凯, 韩红章, 赵雪芊, 等. 基于改进 YOLOv3 模型的软包装食品自动识别方法[J]. 食品与机械, 2023, 39(5): 95-100.
- ZHANG Z K, HAN H Z, ZHAO X Q, et al. Automatic recognition method for soft packaged food based on improved YOLOv3 model [J]. Food & Machinery, 2023, 39(5): 95-100.