

计算机应用

基于YOLOv4算法的冲压件缺陷检测

孙永鹏^{1,2}, 钟佩思^{1,2}, 刘梅², 曹爱霞³, 李梁^{1,2}

(1. 山东科技大学 先进制造技术研究中心, 山东 青岛 266590; 2. 山东科技大学 机械电子工程学院, 山东 青岛 266590;
3. 青岛黄海学院 智能制造学院, 山东 青岛 266427)

摘要: 针对冲压件缺陷检测目前存在的人工检测强度大、效率低等问题, 提出了一种基于改进YOLOv4 (You Only Look Once) 模型的快速检测算法 (YOLOv4-Mobile)。该方法使用改进的MobileNetV3网络代替YOLOv4结构中的CSPDarknet53网络, 改进的MobileNetV3网络结合了深度可分离卷积、具有线性瓶颈的倒残差结构以及SE结构 (轻量级注意力结构)。利用车间采集的冲压件图像, 建立缺陷数据集并进行数据增强, 使用K均值 (K-means) 聚类算法得到一组对应冲压件缺陷数据集的先验框参数, 提高了先验框与特征图层的匹配度。实验结果表明: 基于改进YOLOv4模型的快速检测算法的平均精度达到89%, 高于SSD算法; 同时, 单张检测时间达到0.15 s, 优于原有的YOLOv4算法。

关键词: 冲压件; 缺陷检测; YOLOv4; K-means; MobileNetV3

DOI: 10.13330/j.issn.1000-3940.2022.01.032

中图分类号: TP391.41; TG38

文献标志码: A

文章编号: 1000-3940 (2022) 01-0222-07

Defect detection of stamping parts based on YOLOv4 algorithm

Sun Yongpeng^{1,2}, Zhong Peisi^{1,2}, Liu Mei², Cao Aixia³, Li Liang^{1,2}

(1. Advanced Manufacturing Technology Center, Shandong University of Science and Technology, Qingdao 266590, China;
2. College of Mechanical and Electronic Engineering, Shandong University of Science and Technology, Qingdao 266590, China;
3. College of Intelligent Manufacturing, Qingdao Huanghai University, Qingdao 266427, China)

Abstract: For the problems of high manual detection intensity and low efficiency in defect detection of stamping parts at present, a fast detection algorithm (YOLOv4-Mobile) based on the improved YOLOv4 (You Only Look Once) model was proposed, which used the improved MobileNetV3 network to replace the CSPDarknet53 network in YOLOv4 structure, and the improved MobileNetV3 network combined a depthwise separable convolution, an inverted residual structure with a linear bottleneck and SE (Squeeze and Excitation) structure. Then, the image of stamping parts collected in the workshop was used to establish the defect data set and enhance the data set, and a set of prior frame parameters corresponding to the defect data set of stamping parts was obtained by K-means clustering algorithm to improve the matching degree of prior frame and feature layer. The test results show that based on the improved YOLOv4 model, the *mAP* (mean Average Precision) of the fast detection algorithm reaches 89%, which is higher than that of SSD algorithm. Meanwhile, the detection speed reaches 0.15 s per sheet, which is better than the original YOLOv4 algorithm.

Key words: stamping parts; defect detection; YOLOv4; K-means; MobileNetV3

随着我国制造业水平和工业水平的不断提升, 机械加工行业对产品质量提出了更高的要求, 同时, 产品表面质量对产品的直接使用和再加工均有重要影响。目前, 自动化生产线已成为冲压行业发展的

主要方向, 但在后期的质量检测环节仍然依靠传统的人工目视检测, 不但检测质量无法得到保证, 长时间的目视检测还会导致效率低下。北京有色金属研究总院的邓凡等^[1]引入视觉算法检测金属裂痕, 实现了良好的识别率。因此, 在产品的质量检测环节引入机器视觉和深度学习检测方法, 对冲压件表面缺陷进行准确识别、实现冲压生产线的自动化检测具有重要意义。

随着以卷积神经网络 (Convolutional Neural Networks, CNN) 为代表的深度学习模型在诸多计算机视觉领域的成功应用, 不少工业场景下的缺陷检测

收稿日期: 2020-12-05; 修订日期: 2021-02-20

基金项目: 山东省重点研发计划资助项目 (2019GGX104102);
山东省自然科学基金资助项目 (ZR2017MEE066)

作者简介: 孙永鹏 (1995-), 男, 硕士研究生

E-mail: sunyongpeng@163.com

通信作者: 钟佩思 (1966-), 男, 博士, 教授

E-mail: pszhong@163.com

也尝试使用深度学习的方法并初见成效^[2]。目前,有许多利用深度学习领域的目标检测算法来进行表面缺陷的检测。青岛理工大学奚舒舒等^[3]提出了一种改进的 SSD 算法检测模型,该模型提出了一种 DH-MobileNet 网络,并用其代替原有的 VGG16 网络, DH-MobileNet 网络将 MobileNet 原有的深度可分离卷积加入空洞卷积和层级融合特征,简化了模型,减少了计算量,其结果表明,该算法检测工件的表面缺陷速度更快、精度更高。南京航空航天大学的袁野、谭晓阳^[4]提出了一种复杂环境下的冰箱金属表面缺陷检测方法,该方法引入了基于完整交并比(CIoU)的损失函数,利用 K 均值聚类算法得到更适合现有数据的先验框组合,并选取最优阈值应用于非极大值抑制算法,该算法检测时间是 Faster R-CNN 算法的 1/14,其鲁棒性与泛化性能良好。太原科技大学的李春霖等^[5]提出了一种基于 YOLOv3-Tiny 的算法,该算法将 Dense Block 模块、SPP-Net 模块加入到特征提取网络,在偏光片缺陷检测方面的精度较原算法提高了 7%。

以上研究在精度方面对深度学习模型进行了提升,但现有工业环境下无法使用大型服务器,嵌入式移动设备将更符合需求,因此,将模型部署到算力较差的移动端必须要提升算法本身的速度。在硬件算力有限的情况下想要达到一定的检测速度,只能对模型本身进行改进,而目标检测模型决定其速度的部分即为特征提取网络。针对以上思路,本文提出了一种基于 YOLOv4 的快速检测模型,将其基础特征提取网络进行改进,运用目前速度较快的轻量级网络,并对轻量级网络作出改进,保证其能适配于现有的 YOLOv4 模型,将其应用于现有的冲压件缺陷数据集,在保证精度的同时也能够满足速度要求。

1 基于 YOLOv4 的快速检测模型

YOLO 系列是一种单阶段目标检测模型,其算法的核心思想是将物体检测作为回归问题求解,基于一个 End-to-End (端到端) 网络,实现将原始图像输入到模型后输出物体的位置和类别信息^[6]。YOLOv4^[7]模型经过 YOLOv1、v2、v3 的不断优化更新,在精度和速度方面均有提升。YOLOv4 模型力求在网络分辨率、卷积层数、参数量和输出特征图数量中寻求最佳平衡。YOLOv4 的主干网络包括基础特征网络以及 Neck 增强部分,其中基础特征提取

网络为 CSPDarknet53, Neck 增强部分包括 SPP^[8] (Spatial Pyramid Pooling) 特征增强模块、PANet^[9] (Feature Pyramid Networks) 路径聚合模块。首先,基础特征网络进行目标物体初步信息特征的提取;其次经过 Neck 增强部分进行特征信息的进一步增强,更强的信息表征能力能够大大地提升模型的检测精度;最后,3 个不同大小特征层的信息进行一个解码过程,将原图输出为物体的位置和类别。

YOLOv4 基础网络在感受野、参数量以及速度方面相比于 CSPResNext50 网络以及 EfficientNet-B3 网络更加优异。如图 1 所示, CSPDarknet53 网络输入大小为 416×416 的 3 通道图像,第 1 层为含有卷积、批归一化、Mish 激活函数的模块,其后连接数量分别为 1、2、8、8、4 的 Resblock_Body 模块。

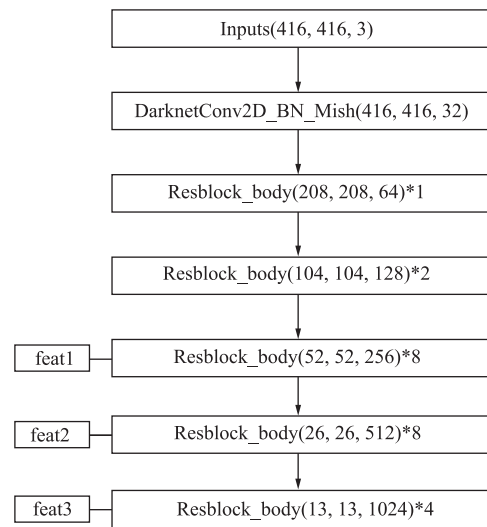


图 1 CSPDarknet53 网络结构图

Fig. 1 CSPDarknet53 network structure diagram

2 YOLOv4 基础特征网络改进

现有的 YOLOv4 算法采用更为精确的 CSPDarknet53 作为基础的特征提取网络,模型的分类精度表现优异,但是,层数过多带来的问题是模型参数过多、计算量变大,因此,参数量与预测速度两个需求无法达到最优平衡。为了将模型部署到计算处理能力受限的移动平台,本文采用层次浅、参数少的轻量级网络 MobileNetV3^[10], MobileNetV3 模型由结合硬件感知的神经架构搜索 (Neural Architecture Search, NAS)^[11]得到,其基础模块继承自 MobileNetV1^[12]的深度可分离卷积, MobileNetV2^[13]具有线性瓶颈的倒残差结构, MobileNetV3 还引入了 SE^[14]结构 (轻量级注意力结构)。MobileNetV3 应用了多

个更为新颖的 Bottleneck 模块, Bottleneck 融合了深度可分离卷积、倒残差结构、注意力模块等。

MobileNetV1 中的深度可分离卷积包括深度卷积和逐点卷积两个步骤。深度卷积 (Depthwise Convolution) 和标准卷积 (Standard Convolution Filters) 不同, 对于标准卷积, 其卷积核是作用在所有的输入通道上, 而深度卷积是针对每个输入通道采用不同的卷积核, 一个卷积核对应一个输入通道, 所以, 深度卷积是深度级别的操作。深度可分离卷积 (Depthwise Separable Convolution) 首先采用深度卷积对不同输入通道分别进行卷积, 然后采用逐点卷积 (Pointwise Convolution) 将上面的输出再进行结合, 其整体效果和一个标准卷积相似, 但计算量和模型参数量会大大减少。深度可分离卷积与标准卷

积计算量之比的计算公式如式 (1) 所示。

$$\frac{D_K \cdot D_K \cdot M \cdot D_F \cdot D_F + M \cdot N \cdot D_F \cdot D_F}{D_K \cdot D_K \cdot M \cdot N \cdot D_F \cdot D_F} = \frac{1}{N} + \frac{1}{D_K^2} \quad (1)$$

式中: D_K 为卷积核尺寸; D_F 为输入大小; M 为输入通道数; N 为卷积核个数。

为了克服 MobileNetV1 中直筒型网络对图像特征利用不完全的缺点, 在 MobileNetV2 中提出了具有线性瓶颈的倒残差结构, 其原理是通过复用图像特征来提升网络的性价比。如图 2 所示, 输入经过 1×1 的卷积核提升通道数, 中间 3×3 的深度卷积负责特征提取, 最后通过 1×1 的卷积核恢复原来的通道数, 结合倒残差结构将得到的特征图与输入融合, 通过较小的计算量得到了较好的性能。

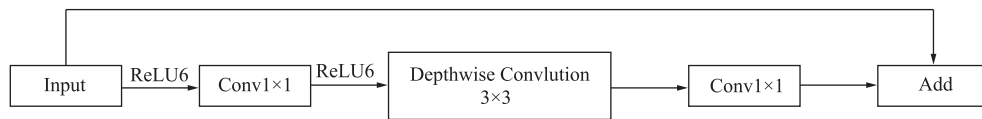


图 2 具有线性瓶颈的倒残差结构

Fig. 2 Inverted residual structure with linear bottleneck

MobileNetV3 中引入的 SE (Squeeze and Excitation) 结构, 其原理为按照重要性进行通道间的特征重标定, 将不同重要性的输入通道进行加权并重新输出。如图 3 所示, 输入通道经过 Pool (全局平均池化) 进行了通道的压缩 (Squeeze), 后接两个 FC (全连接) 层建模通道间的相关性, 首个 FC 层进行通道的调整, 经由 Relu 函数激活后衔接第 2 个 FC 层, 两个 FC 层具有更多的非线性, 可以减少因压缩通道带来的相关性误差, 通过 hard- σ 激活函数将权重进行 0~1 之间的归一化, 最后将得到的权重通过乘法通道加权到先前的特征上, 完成在通道维度上的特征重标定。

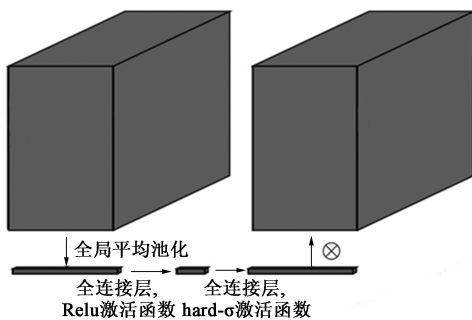


图 3 SE 结构图

Fig. 3 SE structure diagram

特征图输入后续网络, 每层特征图作为后续网络的输入, 其大小为固定值, 而原始的 MobileNetV3 网络的中间层特征图的大小并不匹配, 且其卷积核大小以及卷积步长与 CSPDarknet53 网络不同, 所以, 其后续特征层大小不能与 YOLOv4 匹配。依据需要最终提取的 13×13 、 26×26 以及 52×52 大小的特征图, 改进的 MobileNetV3 网络的具体结构如表 1 所示。

表 1 MobileNetV3 网络结构

Table 1 MobileNetV3 network structure

特征层	操作	exp size	out	是否使用 SE	激活函数类型	s
0	conv2d, 3×3	—	16	—	HS	2
1	bneck, 3×3	16	16	✓	RE	1
2	bneck, 3×3	72	24	—	RE	2
3	bneck, 3×3	88	24	—	RE	1
4	bneck, 5×5	96	40	✓	HS	2
5	bneck, 5×5	240	40	✓	HS	1
6	bneck, 5×5	240	40	✓	HS	1
7	bneck, 3×3	120	48	✓	HS	1
8	bneck, 5×5	144	48	✓	HS	1
9	bneck, 5×5	288	96	✓	HS	2
10	bneck, 5×5	576	96	✓	HS	1
11	bneck, 5×5	576	96	✓	HS	1
12	conv2d, 1×1	96	1024	—	HS	1

CSPDarknet53 网络如图 1 所示, 提取最后 3 层

如表1所示,改进后的MobileNetV3网络共有12层,对应CSPDarknet53网络提取3个不同大小的特征层,改进的MobileNetV3网络分别提取Layer3、Layer8和Layer12作为特征层输入后续网络;exp size表示经过Bottleneck扩展后的通道数;out表示本层最终的输出通道数;HS表示h-swish激活函数,RE表示ReLU (Rectified Linear Unit) 激活函数;s表示卷积步长;conv2d为二维卷积;bneck为Bottleneck卷积模块。

3 实验结果与分析

3.1 实验数据集

本文所采用的数据集收集自冲压件生产车间,缺陷种类分为6类:划痕、毛刺、孔变形、压痕、拉伤、裂纹。缺陷图像标注软件为LabelImage,标注完成后进行数据增强,具体为上下翻转、镜像、平移和缩放等。增强后数据集图片的总数量为2000张,训练集与验证集划分比例为9:1,即训练集为1800张,验证集为200张。

3.2 先验框聚类

YOLOv4网络的Head部分为3个不同尺度的特征层,3种不同尺度下,每个网格点包含对层大小的3个先验框。初始的先验框大小对应VOC数据集,所以,为了满足冲压件缺陷数据集的目标框尺寸的分布,利用K-Means聚类算法重新得到一组先验框的大小,其在原图大小具体为对应小尺寸特征图(89, 85)、(121, 165)、(155, 114),对应中尺寸特征图(178, 172)、(230, 253)、(386, 297),对应大尺寸特征图(527, 633)、(947, 864)、(2611, 2565)。

3.3 实验平台与训练细节

本文所使用的计算机配置为:操作系统Ubuntu18.04, CPU型号i7-9700F,内存为16 GB, GPU型号RTX2070,显存为8 GB。深度学习框架选用Pytorch1.2,深度学习GPU加速库Cuda10.0, Cudnn7.5。

本次训练的初始权重为基于迁移学习的ImageNet下训练的MobileNetV3权重,ImageNet数据集规模庞大,包括120万张图片,因此,其训练后的权重通用性更强,预训练的权重在其他小规模的数据集上表现出的泛化性能也更好。

设置early-stopping(早停)参数,early-stopping能够获得网络模型最好的泛化性能,当网络在测试

集上的loss(损失)不再有变化时即停止训练。如图4所示,YOLOv4-Mobile模型的loss值随着迭代次数的增加不断减小,其验证集的loss值在第86个epoch后不再增加,因此停止训练,第86个epoch训练集的loss值收敛于1.149。

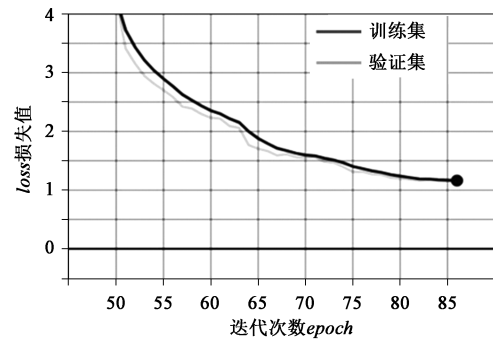


图4 损失函数曲线图

Fig. 4 Curve diagram of loss function

3.4 检测方法实验性能分析

本次实验将目标检测领域中经典的一阶段检测算法SSD^[15]、原有的YOLOv4算法以及改进后的YOLOv4-Mobile算法进行性能对比,其评价指标为检测精度mAP (mean Average Precision)、每秒传输帧数FPS (Frames Per Second) 以及检测时间。mAP、查准率P (Precision) 与查全率R (Recall) 是衡量目标检测模型性能的常用指标。其公式如式(2)所示:

$$P = \frac{TP}{TP + FP} \quad (2)$$

$$R = \frac{TP}{TP + FN} \quad (3)$$

式中:TP (True Positives) 为模型分类为正样本且本身为正样本的实例;FP (False Positives) 为模型分类为正样本但本身为负样本的实例;FN (False Negatives) 为模型分类为负样本但本身为正样本的实例。

SSD算法、YOLOv4算法及YOLOv4-Mobile算法的各类缺陷如表2所示,从检测结果可以得出,YOLOv4算法的mAP达到了91.30%,YOLOv4-Mobile算法的检测精度略低,达到了88.89%,而SSD算法的检测精度仅有64.48%。SSD算法的检测精度较低的原因为:其采用的特征提取网络为较为简单的VGG16网络改进版,其特征提取能力略逊于另外两类算法,且SSD算法的网络整体结构设计较为简单,仅采用了基础网络与金字塔网络的组合,并未与SPPNet、PA-Net等结构进一步地进行特征融

表 2 不同算法各类缺陷检测精度 (%)

Table 2 Detection precisions of various defects for different algorithms (%)

算法	裂纹	拉伤	划痕	压痕	毛刺	孔变形	mAP
SSD	70.00	67.51	64.43	45.43	39.52	100.00	64.48
YOLOv4	100.00	99.78	100.00	84.78	63.27	99.93	91.30
YOLOv4-Mobile	100.00	98.08	96.20	77.24	61.81	100.00	88.89

合。同时, SSD 算法对小目标物体检测性能还有所欠缺, 因此, 将 SSD 算法应用于冲压件缺陷检测, 其性能无法达到要求。

从图 5 中不同种类缺陷检测的结果进行分析, 压痕和毛刺的检测精度均未超过 80%。其余缺陷的检测精度几乎达到 100%, 造成这种结果的主要原因为: 其中检测精度较高的几类缺陷的特征较为明显, 且训练时数据充足, 几种检测模型均能较易提取特征, 因此检测精度较高; 对于其他几类缺陷, 压痕缺陷相的尺寸较小, 因此, 在模型固定输入大小为 416×416 的情况下, 其作为小目标不易被检测出来, 同时, 压痕与划痕即使在人工检测时也不易分辨出具体种类, 容易存在错检的情况; 毛刺缺陷的检测精度较差的原因为其特征形状为边界形变, 尺寸缩放为 416×416 后, 其形变较小, 不易分辨, 同时采集数据较少, 各类数据数量分布不均衡也是造成精度较低的原因之一。

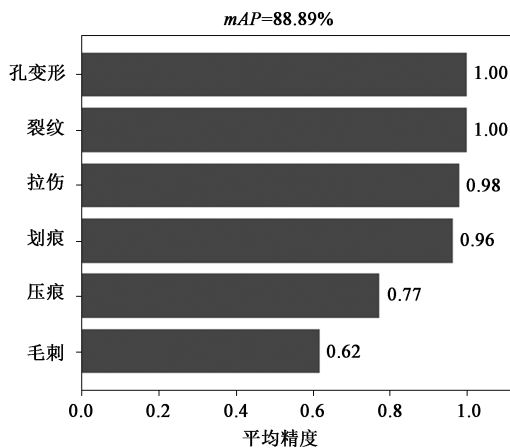


图 5 YOLOv4-mobile 算法 mAP 图

Fig. 5 mAP diagram of YOLOv4-mobile algorithm

由表 3 可知, 将主干网络替换为本文所改进的 MobileNetV3 网络后, 权重文件缩小为原 YOLOv4 算法的 9.2%, 继承了原有算法准确性的同时, 在检测速度上也有所提高, SSD 算法模型的大小仅为 YOLOv4 算法模型的 38%, 但其检测一张图片所耗费的时间为 1.99 s, 是 YOLOv4 算法的 11 倍。改进后的算法的 FPS 值有较为明显的提升, 高于 SSD 算

法的 28 帧, 并且相较于 YOLOv4 算法的 30 帧得到了 21% 的提升, 在视频处理时可以进行流畅地检测。23.7 MB 大小的权重文件意味着能够更好地移植到动平台, 即使是运行速度及综合性能远不如大型服务器的情况下, 在保证精度的同时, 也可以保证其性能不变。

表 3 网络权重文件和检测速度对比

Table 3 Comparison of network weight file and detection speed

算法	权重文件/MB	单张检测时间/s	FPS/(f · s ⁻¹)
SSD	98.3	1.99	28
YOLOv4.0	257.0	0.18	30
YOLOv4-Mobile	23.7	0.15	34

图 6 为 3 种算法针对同一图片的帧率测试图, 帧数越高表示画面越流畅, 即算法速度越快, 并且帧率是一个波动的数值。图 6b~图 6d 分别为 SSD 算法、YOLOv4 算法、YOLOv4-Mobile 算法的帧率测试图。由图 6 可知, 本文提出的 YOLOv4-Mobile 算法的 FPS 高于其他两种算法, 其检测速度更快。

图 7 为 3 种算法对同一图片的检测结果图, 对比 3 种算法的检测结果可知: SSD 算法的检测正确率远低于其他两种算法; 而 YOLOv4 算法除个别缺陷未识别外, 其余缺陷均可被正确识别; YOLOv4-Mobile 算法的检测结果图显示其与 YOLOv4 算法相差无几。YOLOv4 算法在图 7f 中显示漏检一处毛刺; 在图 7h 中, YOLOv4-Mobile 算法显示漏检一处划痕。从整体检测结果可以看出, 对应表 2 中各类缺陷的准确率, 压痕的漏检几率较大, 图 7e 中 YOLOv4 算法与图 7g 中 YOLOv4-Mobile 算法均未检测出冲压件下边缘中部的压痕, 且图 7f 与图 7h 中左下边缘中部的小缺陷均被漏检, 因此, 现有算法对小目标缺陷的检测能力还有待提高。

4 结语

冲压件缺陷检测是冲压行业生产质量把控的重要环节, 为了实现其自动化检测的需求, 本文提出了一种基于 YOLOv4 模型的快速检测算法, 其本质

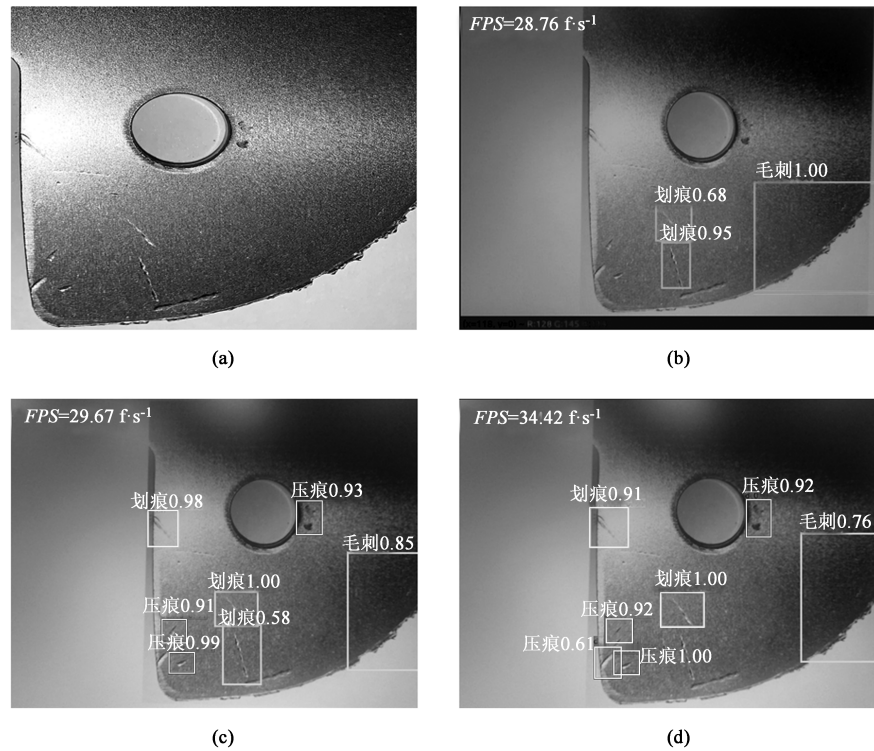


图 6 3 种算法对同一图片的帧率检测结果

(a) 原图 (b) SSD (c) YOLOv4 (d) YOLOv4-Mobile

Fig. 6 Frame test results of the same drawing by three algorithms

(a) Original drawing (b) SSD (c) YOLOv4 (d) YOLOv4-Mobile

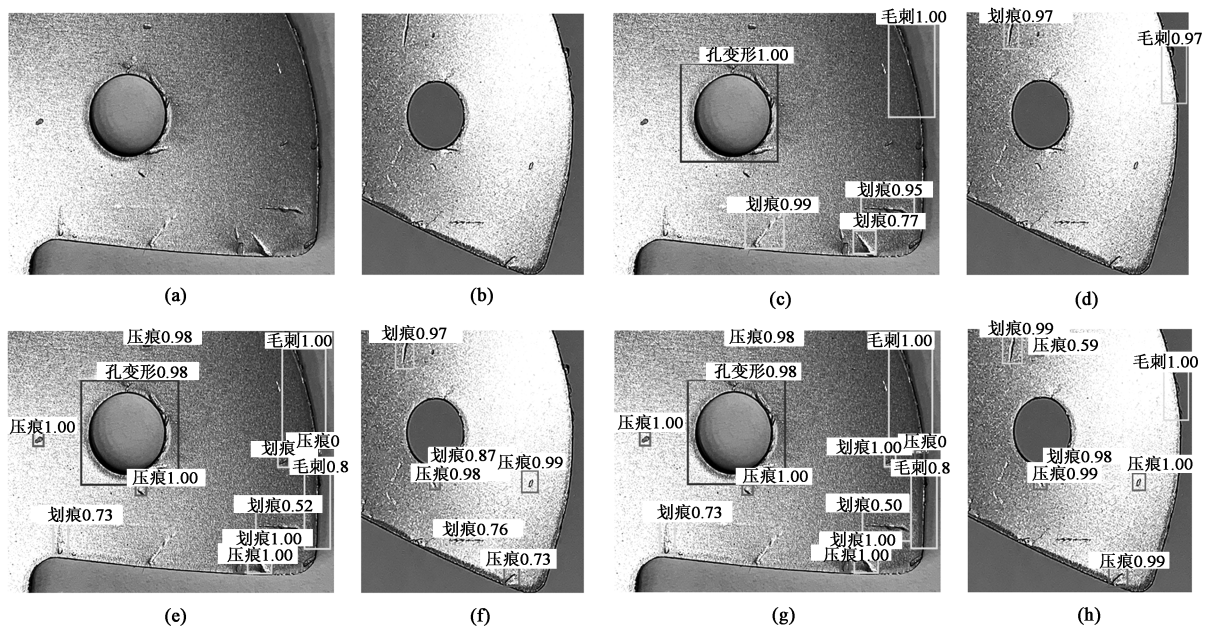


图 7 3 种算法的同一图片的检测结果

(a) 原图 1 (b) 原图 2 (c) SSD 检测结果 1 (d) SSD 检测结果 2 (e) YOLOv4 检测结果 1 (f) YOLOv4 检测结果 2

(g) YOLOv4-Mobile 检测结果 1 (h) YOLOv4-Mobile 检测结果 2

Fig. 7 Test results of the same drawing by three algorithms

(a) Original drawing 1 (b) Original drawing 2 (c) SSD detection result 1 (d) SSD detection result 2 (e) YOLOv4 detection result 1

(f) YOLOv4 detection result 2 (g) YOLOv4-Mobile detection result 1 (h) YOLOv4-Mobile detection result 2

是一种端到端的快速准确检测算法,通过改进其基础特征提取网络,将原有的 CSPDarknet53 网络替换为改进的轻量型 MobileNetV3 网络,在保持精度的同时,大大减少了参数量和计算量,提高了检测效率。实验表明,本文提出的算法对冲压件缺陷检测的平均精度达到了 88.89%,单张检测时间达到了 0.15 s,高于同条件下的 SSD 算法和 YOLOv4 算法,在同等算力的移动平台也可达到检测需求,具有良好的应用前景。目前,其存在的问题为小目标检测精度较低,这是后期有待研究的重点。

参考文献:

- [1] 邓凡,刘彦强,樊建中,等. 基于数字图像相关技术的泡沫铝复合结构的弯曲行为研究 [J]. 稀有金属, 2021, 45 (3): 297-305.
Deng F, Liu Y Q, Fan J Z, et al. Observation of bending behavior of aluminum foam composite structure based on digital image correlation technology [J]. Chinese Journal of Rare Metals, 2021, 45 (3): 297-305.
- [2] 陶显,侯伟,徐德. 基于深度学习的表面缺陷检测方法综述 [J/OL]. 自动化学报: 1-19 [2020-10-11]. <http://kns.cnki.net/kcms/detail/11.2109.TP.20200402.1101.002.html>.
Tao X, Hou W, Xu D. A survey of surface defect detection methods based on deep learning [J/OL]. Acta Automatica Sinica: 1-19 [2020-10-11]. <http://kns.cnki.net/kcms/detail/11.2109.TP.20200402.1101.002.html>.
- [3] 李兰,奚舒舒,张才宝,等. 基于改进 SSD 模型的工件表面缺陷识别算法 [J]. 计算机工程与科学, 2020, 42 (9): 1608-1615.
Li L, Xi S S, Zhang C B, et al. A surface defect recognition algorithm based on improved SSD model [J]. Computer Engineering and Science, 2020, 42 (9): 1608-1615.
- [4] 袁野,谭晓阳. 复杂环境下的冰箱金属表面缺陷检测 [J/OL]. 计算机应用: 1-6 [2020-09-22].
Yuan Y, Tan X Y. Defect detection of refrigerator metal surface in complex environment [J]. Journal of Computer Applications: 1-6 [2020-09-22].
- [5] 李春霖,谢刚,王银,等. 基于 YOLOv3-Tiny-D 算法的偏光片缺陷检测 [J/OL]. 计算机集成制造系统: 1-17 [2020-09-23].
Li C L, Xie G, Wang Y, et al. Defect detection of polaroid based on YOLOv3-Tiny-D [J/OL]. Computer Integrated Manufacturing Systems: 1-17 [2020-09-23].
- [6] Redmon J, Divvala S, Girshick R, et al. You only look once: Unified, real-time object detection [A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. Washington D. C.: IEEE Press, 2016.
- [7] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: Optimal speed and accuracy of object detection [EB/OL]. <https://github.com/AlexeyAB/darknet>, 2020.
- [8] He K, Zhang X, Ren S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 37 (9): 1904-1916.
- [9] Liu S, Qi L, Qin H, et al. Path aggregation network for instance segmentation [A]. IEEE/CVF Conference on Computer Vision and Pattern Recognition [C]. Washington D. C.: IEEE Press, 2018.
- [10] Howard A, Sandler M, Chen B, et al. Searching for MobileNetV3 [A]. 2019 IEEE/CVF International Conference on Computer Vision (ICCV) [C]. Seoul: IEEE, 2020.
- [11] Elsken T, Metzen J H, Hutter F. Neural architecture search: A survey [J]. Journal of Machine Learning Research, 2019, 20: 1-21.
- [12] Howard A G, Zhu M, Chen B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications [A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. Hawaii: IEEE, 2017.
- [13] Sandler M, Howard A, Zhu M, et al. MobileNetV2: Inverted residuals and linear bottlenecks [A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. Salt Lake City: IEEE, 2018.
- [14] Hu J, Shen L, Sun G, et al. Squeeze-and-excitation networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 42 (8): 7132-7141.
- [15] Liu W, Anguelov D, Erhan D, et al. SSD: Single shot multi box detector [A]. Proc of European Conference on Computer Vision [C]. Berlin: Springer, 2016.

(上接第 221 页)

- GB/T 231.1—2018, Metallic materials—Brinell hardness test—Part 1: Test method [S].
- [18] GB/T 228.1—2010, 金属材料 拉伸试验 第 1 部分: 室温试验方法 [S].
GB/T 228.1—2010, Metallic materials—Tensile testing—Part 1: Method of test at room temperature [S].
- [19] GB/T 1172—1999, 黑色金属硬度及强度换算值 [S].
GB/T 1172—1999, Conversion of hardness and strength for ferrous metal [S].
- [20] GB/T 228.2—2015, 金属材料 拉伸试验 第 2 部分: 高温试验方法 [S].
GB/T 228.2—2015, Metallic materials—Tensile testing—Part 2: Method of test at elevated temperature [S].
- [21] Bourham M, Westengen H. Stress and integrity analysis of steam superheater tubes of a high pressure boiler [J]. Materials Science and Technology, 2006, 10 (2): 3-8.
- [22] 潘金平,潘柏定,程宏辉,等. 15CrMoG 钢管的寿命评估新方法 [J]. 金属热处理, 2012, 37 (10): 71-75.
Pan J P, Pan B D, Cheng H H, et al. A new life evaluation method for 15CrMoG steel tube [J]. Heat Treatment of Metals, 2012, 37 (10): 71-75.
- [23] Saha A, Roy H, Shukla A K. Investigation into the probable cause of failure of economizer tube of a thermal power plant [J]. Materials Research, 2010, 10 (3): 187-190.