

doi: 10.3969/j.issn.0490-6756.2020.06.011

基于改进的 RetinaNet 医药空瓶表面气泡检测

吴华运, 任德均, 吕义钊, 胡彬, 付磊, 邱吕

(四川大学机械工程学院, 成都 610065)

摘要: 医药空瓶在生产过程中瓶身表面会产生大量的气泡缺陷, 但现有的方法对医药空瓶表面气泡检测存在各种问题, 例如对复杂场景变化的鲁棒性不强, 抗噪声干扰能力弱等。针对现有医药空瓶表面的气泡缺陷, 提出了一种改进的深度学习目标检测算法 RetinaNet 对瓶身气泡进行检测。对原始 RetinaNet 算法中的特征金字塔网络结构进行了优化, 在特征融合过程中引入了特征增强模块, 用来提高网路对图像语义特征的提取, 增强网络特征提取能力。为了减少模型的参数数目和计算时间, 考虑到空瓶表面气泡均为小目标缺陷, 去掉原始特征金字塔网络中用于检测大目标的网络结构, 提高了算法检测速度。通过对标准的 ResNet50 网络进行重新组合, 并引进了膨胀卷积模块, 扩大特征图感受野, 提高了模型检测的精度。通过在注塑空瓶数据集上对本文的方法进行了验证, 其准确率为 99.72%, 漏检率为 0.12%, 误检率为 0.16%, mAP 为 99.49%, 相比原始的 RetinaNet 的 mAP 提高了接近 2.4%。

关键词: 缺陷检测; 特征增强模块; 膨胀卷积模块; 卷积神经网络; 特征金字塔网络

中图分类号: TP399 **文献标识码:** A **文章编号:** 0490-6756(2020)06-1090-06

Bubble detection on the surface of medical empty bottles based on improved Retina Net

WU Hua-Yun, REN De-Jun, LÜ Yi-Zhao, HU Bin, FU Lei, QIU Lü

(College of Mechanical Engineering, Sichuan University, Chengdu 610065, China)

Abstract: In the production process of medical bottles, a large number of bubble will be generated on the surface of the empty bottle body, but the existing methods have various problems in the detection of bubbles on the surface of empty medical bottles such as the week robustness to complex scene changes, and the poor anti-noise ability and so on. Aiming to the existed bubble defects on the surface of medical empty bottles, an improved deep learning target detection algorithm RetinaNet is proposed to detect the bubbles on the bottle body. This paper mainly improves the feature pyramid network structure in the original RetinaNet algorithm, and introduces the feature enhance module in the process of the feature fusion, which effectively improves the extraction of semantic features and expands the receptive field of feature maps. In order to reduce the number of parameters and calculation time of the model, considering that the bubbles on the surface of the empty bottle are all small objects, the network structure to detect large objects in the original feature pyramid network is removed, which effectively improves the detection speed. By recombining the standard ResNet50 network, a dilation convolution module is introduced to expand the feature map receptive field and the accuracy of model detection is improved. The proposed method is validated on the empty dataset of injection molding, and the accuracy is 99.72%, the

收稿日期: 2019-08-29

作者简介: 吴华运(1991—), 男, 河南信阳人, 硕士研究生, 研究方向为机器视觉和图像处理. E-mail: 875972102@qq.com

通讯作者: 任德均. E-mail: rendejun@scu.edu.cn

missed rate was 0.12%, the false detection rate was 0.16%, the mAP is 99.49% which is higher by nearly 2.4% compared with the original RetinaNet.

Keywords: Defect detection; Feature enhance Module; Dilation bottleNeck Module; CNN; FPN

1 引言

医药空瓶在生产制造过程中表面会出现气泡类缺陷。气泡的存在不仅会影响产品外形包装的美观,而且会影响产品的销售和使用。因此,对表面存在气泡的空瓶进行检测在工业生产过程中有着重要意义。传统的检测往往由人工来完成,不仅工作量大、劳动强度高,而且容易受到检测人员主观因素的影响,导致检测效率和检测精度都不能够保证。基于机器视觉的检测系统由于检测精度高等优点已经被广泛的应用在瓶体表面缺陷检测领域,但在实际应用中也遇到许多问题和挑战^[1]。传统特征提取算子提取的特征通常处于较低水平,在针对复杂的场景变化,如光照变换,透视失真,遮挡,物体变形等情况下,所提取的特征通常不足以应对这种情况,因此许多算法在实际环境中并不适用。除此之外,医药空瓶在拍摄过程中,由于气泡缺陷自身的透明特性和瓶身位置的不确定性,使其在图片上成像并不明显,给传统的特征提取带来很大的挑战。

深度学习,特别是卷积神经网络^[2],已经被证明在提取图像特征方面有着强大的能力,在各种监督问题上都达到了最高的精度,如物体分类^[3],目标检测^[4],语义分割^[5]等。相比传统的空瓶表面缺陷检测,深度学习提取的特征可以达到更好的效果,同时它不需要将特征提取和分类训练分开进行,它可以在训练过程中实现自动提取最优特征。近年来,深度学习已经广泛应用与工业检测,文献[6]提出一种基于正样本训练的新型缺陷检测框架,他们将GAN和自动编码器结合起来用于缺陷图像重建,并使用LBP^[7]进行图像局部对比以检测缺陷。文献[8]提出使用两个FCN语义分割网络来检测物体表面缺陷,一个FCN用来粗略定位,另一个FCN用来精准定位,实现了准确地绘制缺陷轮廓,并达到实时检测缺陷的效果。

本文针对传统算法在医用空瓶表面缺陷检测中存在的局限性进行了简单的分析,首先提出将深度学习目标检测算法 RetinaNet^[9]应用于空瓶表面缺陷检测,并对 RetinaNet 网络进行改进,大大提高了检测精度。本文主要工作如下。

(1) 对特征金字塔网络进行了改进。传统的 FPN 仅将高层和底层输出网络简单的合并,并未考虑对融合后特征图的进行语义特征的提取。针对这种情况,本文在特征融合过程中增加了膨胀卷积操作,增强对语义特征的提取,提高特征的判别性和鲁棒性;

(2) 本文以 RetinaNet 作为基础检测算法,在训练和测试过程中,本文仅利用 FPN 网络中 P_3 , P_4 , P_5 和 P_6 等四个阶段的特征图来分类和定位缺陷,并去除了原网络中用来检测较大目标的网络结构,降低网络的计算量,加快模型的训练速度;

(3) 对 ResNet50 网络结构进行了优化。在 ResNet50 骨干网络中增加了 Layer5,并使用膨胀瓶颈模块替换 Layer4 和 Layer5 中的普通瓶颈模块。这样可以保证特征图尺寸不变的基础上增大特征图的感受野。

2 基于 RetinaNet 的空瓶表面缺陷检测

本文采用 RetinaNet 算法实现对医药空瓶表面缺陷的检测,具体结构如图 1 所示。由图可知,RetinaNet 算法由 ResNet 网络^[10],FPN 网络^[11]和分类定位子网络构成,ResNet 网络主要用来提取特征,FPN 网络将提取的特征图进行重新组合,实现特征的精细化提取,分类定位子网络用于目标的分类和定位。输入图片首先经过 ResNet 网络提取特征,然后通过 FPN 网络实现高层特征和低层特征之间的融合。最后使用分类定位子网络完成分类和定位。

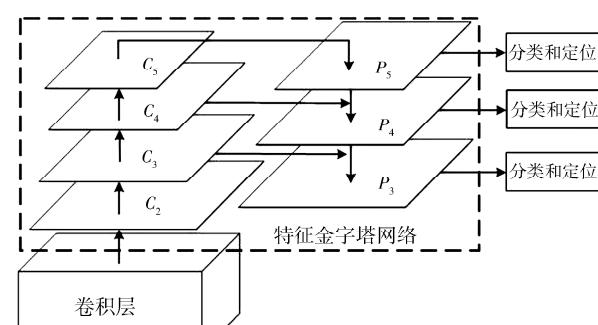


图 1 RetinaNet 网络结构
Fig. 1 The structure of RetinaNet

RetinaNet 算法借鉴了 Faster R-CNN^[12] 中 Anchor 机制,在 Anchor 生成上使用了{1:2,1:1,2:1}3 种不同纵横比和{2⁰,2¹,2²}三种不同的尺度,共得到 9 个 Anchor,其中 Anchor 面积从 P_3 到 P_7 依次为 32²,64²,128²,256²,512²。

在分类子网络中,常用的损失函数为交叉熵损失函数。在 RetinaNet 网络中,为了解决正负样本不平衡现象,引入参数 α ,用来控制正负样本对总分类损失的贡献权重,新损失函数定义如下^[13]:

$$CE(P_t) = -\alpha_t \log(p_t) \quad (1)$$

其中,定义 P_t 为

$$P_t = \begin{cases} p, & \text{if } y=1 \\ 1-p, & \text{otherwise} \end{cases} \quad (2)$$

式中, $y \in \{\pm 1\}$ 为真实标签类别; $p \in [0,1]$ 为类标签 $y=1$ 的概率值。

针对难例问题,在新损失函数中加入调节因子 $(1-p_t)^\gamma$,其中, γ 为聚焦参数,因此,Focal Loss 损失函数定义为

$$FL(P_t) = -\alpha_t(1-p_t)^\gamma \log(p_t) \quad (3)$$

在定位子网络中,RetinaNet 采用了平滑 L_1 损失函数。假定 l 代表预测框与 Anchor 之间的变换关系; g 代表真实框与 Anchor 之间的变换关系; 则 \hat{l}_j^m 表示第 j 个预测框与 Anchor 之间的偏差; \hat{g}_j^m 表示第 j 个目标的真实框与 Anchor 之间的偏差; $m \in \{c_x, c_y, w, h\}$, (c_x, c_y) 表示边界框中心点的坐标; (w, h) 表示边界框的宽和高。

$$\begin{aligned} \hat{l}_j^x &= (l_j^x - d_i^x) / d_i^w, \hat{l}_j^y = (l_j^y - d_i^y) / d_i^h, \\ \hat{l}_j^w &= \log(l_j^w / d_i^w), \hat{l}_j^h = \log(l_j^h / d_i^h) \\ \hat{g}_j^x &= (g_j^x - d_i^x) / d_i^w, \hat{g}_j^y = (g_j^y - d_i^y) / d_i^h, \\ \hat{g}_j^w &= \log(g_j^w / d_i^w), \hat{g}_j^h = \log(g_j^h / d_i^h) \end{aligned} \quad (4)$$

其中, d_i^m 为第 i 类缺陷的真实区域; 本文中 $i=0$, \hat{l}_j^m , \hat{g}_j^m 分别为第 j 个预测区域和 Anchor。定义 $smooth_{L1}$ 如下式:

$$smooth_{L1} = \begin{cases} 0.5 (\hat{l}_j^m - \hat{g}_j^m)^2, & \text{if } |\hat{l}_j^m - \hat{g}_j^m| < 1 \\ |\hat{l}_j^m - \hat{g}_j^m| - 0.5, & \text{otherwise} \end{cases} \quad (5)$$

3 模型结构

3.1 膨胀瓶颈模块

随着网络层数的增加,使用标准卷积层将要训

练大量的参数,模型参数越多,运行所需要的消耗的资源越多。针对这种现象,常用的解决方法是将标准卷积层和 1×1 的卷积相结合,通过中间产生一个瓶颈层,达到减少参数和计算量,加快网络模型的收敛,如图 2(a)所示^[14]。在本文中,为了扩大特征图的感受野,引进了一种新的瓶颈模块结构,即替换标准瓶颈模块中的 3×3 标准卷积层为卷积核为 3,膨胀系数为 2 的膨胀卷积,形成了膨胀瓶颈模块^[15],如图 2(b)所示。除此之外,在膨胀卷积模块的 shortcut 的分支中加入 1×1 的卷积映射得到 1×1 卷积映射的膨胀瓶颈模块,如图 2(c)所示。这种模块结构可以在不增加参数量的条件下,可以有效的扩大特征图的感受野。

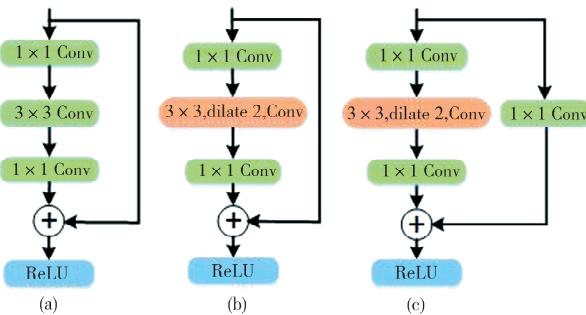


图 2 网络的基本结构模块

(a) 普通瓶颈模块; (b) 膨胀瓶颈模块;
(c) 1×1 卷积映射的膨胀瓶颈模块

Fig. 2 The basic structural module of the network

(a) Original bottleNeck; (b) dilated bottleNeck;
(c) dilated bottleNeck with 1×1 conv projection

3.2 改进 FPN 网络

特征金字塔网络(FPN)通过自上而下的路径和横向连接可以实现网络特征提取更加精细化,网络从单分辨率输入图像中可以有效地构建一个丰富的多尺度的特征金字塔。FPN 的设计思想就是同时利用低层特征和高层特征,在不同的层上同时进行预测。因此其检测过程是通过在原始图像上先进行深度卷积,然后分别在不同的特征层上面进行预测。传统 FPN 的低层特征和高层特征融合方式简单地将高层语义特征和低层细节特征相加,但这种方式获得的特征鲁棒性不强,都是一些弱特征。为了提取到尺度和形状不变的强特征图,本文在特征融合之后增加了特征增强模块(Feature Enhance Module),通过采用具有不同扩张率($r=1, 3, 5, 7$)的膨胀卷积来捕获不同感受野的语义信息。然后让不同膨胀卷积得到的特征与 1×1 卷积后特征组合起来,得到最终用于检测的特征图,如图 3 所示。

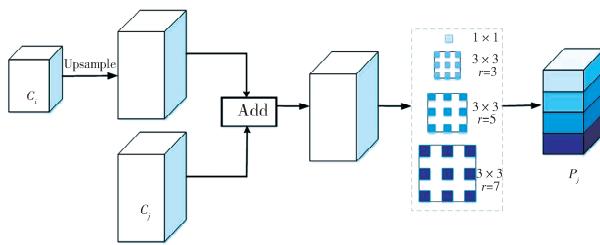


图 3 改进的 FPN 特征融合方式
Fig. 3 Improved FPN feature fusion

定义改进后的 FPN 计算方式为

$$P_j = f_{\text{concat}}(f_{\text{dilation}}(f_{\text{add}}(C_j, f_{\text{up}}(C_i)))) \quad (6)$$

式中, C_i 表示高层特征图; C_j 表示低层特征图; $f_{\text{up}}(\cdot)$ 表示特征图 C_i 上采样函数; $f_{\text{Add}}(\cdot, \cdot)$ 表示特征融合函数; $f_{\text{dilation}}(\cdot)$ 表示膨胀卷积操作; P_j 表示经过上采样, 特征融合以及膨胀卷积后得到的特征图.

3.3 ResNet 网络

深度学习目标检测对骨干网络的设计通常存在两大难题:(1)保持深度神经网络的空间分辨率会极大地消耗时间和内存;(2)减小下采样因子将会导致有效感受野的减少.为了解决这两个难题,本文的网络结构单元采用了 DetNet^[15] 中的膨胀

瓶颈模块结构.除此之外,在使用原始 RetinaNet 算法对空瓶气泡缺陷进行研究中发现,较小的气泡缺陷在经过多次降采样后,特征逐渐消失.为了解决这种现象,本文对 ResNet50 进行重新组合形成改进后 ResNet50 网络,如图 4 所示.

对于 ResNet 详细改进细节说明如下.(1) 将原始 ResNet50 中 Layer3 中的 6 个瓶颈层减小为 3 个,并在 Layer4 后面增加一个 layer5,Layer5 设置为 3 个膨胀瓶颈模块.因此,改进后 ResNet 从 Layer1 到 Layer5 的瓶颈模块数依次为 3,4,3,3,3;(2) 保持前 3 个 Layer 的瓶颈模块类型不变,对 Layer4 和 Layer5 中的瓶颈模块使用膨胀瓶颈模块进行替换,这样可以有效地扩大感受野.为了减小膨胀卷积带来的时间损耗,本文设置 Layer4 和 Layer5 拥有和 Layer3 相同的输入通道数(256 个输入通道);(3) 修改了 ResNet50 网络每一阶段输出特征图的空间尺寸.相比较于原始的 ResNet50 的输出步长[2, 4, 8, 16, 32],修改后的 ResNet 的输出步长为[2, 4, 8, 16, 16, 32],保持 Layer3 和 Layer4 有着相同的特征图输出尺寸,有效地防止因下采样而造成感受野的减小.

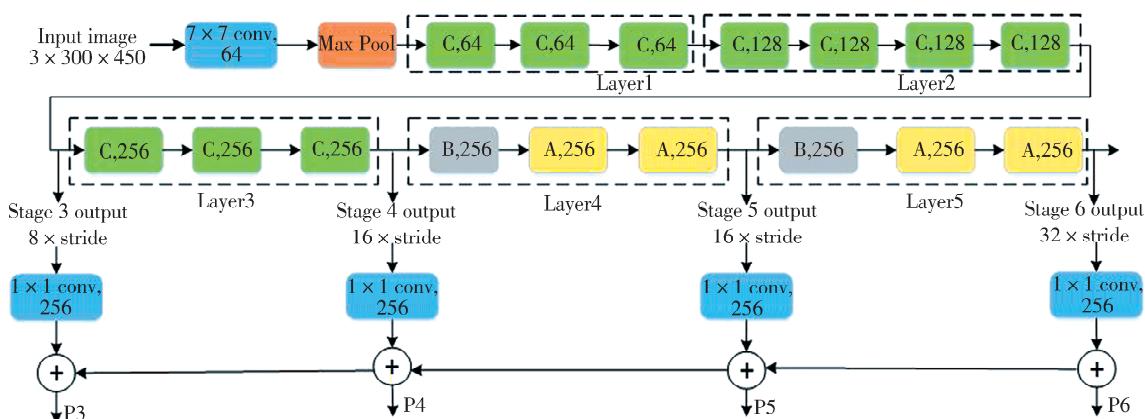


图 4 优化后 ResNet50 网络详细结构
A: 膨胀瓶颈模块; B: 带 1×1 卷积映射的膨胀瓶颈模块; C: 原始瓶颈模块
Fig. 4 Detail structure of improved ResNet50
A: Dilated bottle Neck; B: dilated bottle Neck with 1×1 conv projection; C: original bottle Neck

4 实验

4.1 实验设置

数据集:本文数据集为在线采集的瓶身气泡缺陷图片,对图片缺陷使用 LabelImg 进行标注,对被标注后的数据集进行训练测试设置如表 1 所示,其中在训练设置中,训练集和验证集均为带有气泡缺陷的图片,而测试数据集中含有 500 张正常图片.

表 1 训练测试数据详细设置

Tab. 1 The detailed settings of train data and test data

训练设置	测试设置	图片尺寸
3 000 张训练集 和 500 张验证集	2 500 张测试, 其中 500 张为正常图片	$300 \times 450 \times 3$

性能评价指标:为了评估检测的效果,我们通过使用准确率(Accuracy),漏检率,误检率和均值平均精度(mAP)等性能评价指标对检测效果进行

了评估.

$$\text{Accuracy} = \frac{TP + FN}{TP + FP + TN + FN} \quad (7)$$

$$AP = \int_0^1 \text{precision}(\text{recall}) \text{Drecall} \quad (8)$$

$$mAP = \frac{\sum AP}{N(\text{class})} \quad (9)$$

其中, TP 表示被正确预测为缺陷数目; FP 表示为错误预测为背景的数目; FN 表示错误预测为缺陷的数目; TN 表示正确预测背景的数目; AP 表示平均精度, precision 表示精准率; recall 表示召回率.

训练: 本文实验基于 PyTorch 实现, 所有实验均使用 Xavier 初始化方法对网络模型进行初始化. 输入图像大小为 $300 \times 450 \times 3$, . 训练过程中, 采用多尺度训练方法, 并对图片进行随机旋转、平移、剪切等数据增强操作. 训练时使用随机梯度下降优化方法进行迭代优化, 设置动量为 $\text{momentum} = 0.9$, 权重退化率为 $\text{weight_decay} = 0.0005$, 输入批次 $\text{batchsize} = 16$, 初始学习率为 $\text{learning_rate} = 0.00001$, 其中每经过 60 次迭代后学习率下降为原来的十分之一, 总共迭代次数为 200 次.

4.2 模型改进前后结果对比

为了验证改进后的模型结构对注塑空瓶表面气泡检测的有效性, 本文分别对原始 RetinaNet 模型, RetinaNet 加改进后的 FPN, RetinaNet 加改进后的 ResNet 网络以及本文方法在测试集上的检测效果进行了对比, 结果如表 2 所示.

表 2 模型改进前后检测结果

Tab. 2 Detection results between the improved algorithm and original RetinaNet

方法	mAP/%	准确率/%	漏检率/%	误检率/%	检测时间/ms
RetinaNet	97.13	98.12	0.84	1.04	41.6
RetinaNet + 改进 FPN	99.03	99.40	0.32	0.28	45.3
RetinaNet + 改进 ResNet50	97.64	98.48	0.60	0.92	31.8
本文方法	99.49	99.72	0.12	0.16	35.7

由表 2 可知, 在检测精度方面, 改进后的模型相比改进前的模型 mAP 提升接近 2.4%, 准确度提高了 1.6%, 漏检率和误检率分别降低到 0.12% 和 0.16%; 在检测速度方面, 改进后的模型速度提升了 14.18%. 对比改进前后的特征金字塔网络的检测结果, 可以看出改进后的特征金字塔网络相较于原始特征金字塔网络有更好的特征提取能力. 对比

ResNet 50 网络, 改进后的网络也有较小幅度的提升.

本文算法在医药空瓶数据集上的部分检测结果和原始 RetinaNet 检测结果如图 5 所示.

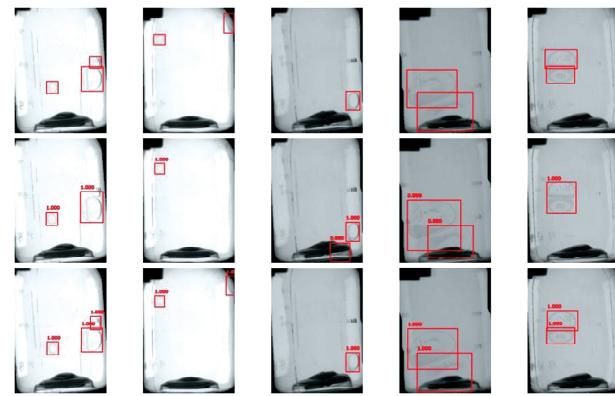


图 5 本文算法检测结果和原始 RetinaNet 检测结果对比

第一行图片为 Ground Truth; 第二行图片为 RetinaNet 算法检测结果; 第三行图片为本文算法检测结果.

Fig. 5 Comparison of detection results between the algorithm in this paper and the original RetinaNet

The first row: Ground Truth; the second row: the detection results of RetinaNet; the third row: the detection results of ours.

由图 5 可知, 相较于原始 RetinaNet 网络, 本文算法有更好的定位能力, 尤其对于粘连气泡缺陷.

4.3 不同目标检测模型检测效果对比

为了进一步验证本文检测算法对于医药空瓶表面气泡缺陷检测的有效性, 本文通过将本文算法与当前主流的目标检测算法 Faster RCNN、SSD 以及 YOLOV3 等算法进行了对比, 通过在医药空瓶气泡数据集上对上述算法进行训练和测试, 结果如表 3 所示. 由表 3 数据可知, 相较于 Faster RCNN、SSD 和 YOLOV3, 本文提出的算法有更高的 mAP 和准确率; 在检测速度上, 本文算法优于 Faster RCNN 和 SSD 算法, 但略低于 YOLOV3 的检测速度.

表 3 不同模型检测效果对比

Tab. 3 Comparison of detection result of different models

方法	mAP/%	准确率/%	时间/ms
Faster RCNN	97.48	98.26	83.5
SSD	96.79	97.54	69.3
YOLOV3	97.82	98.68	27.4
本文方法	99.49	99.72	35.7

5 结 论

本文使用深度学习中最先进的目标检测算法

RetinaNet对医药空瓶表面气泡缺陷进行了检测。为了满足工业检测所需要的准确度,本文先对原始特征金字塔网络的特征融合过程进行优化,增加了语义特征提取模块,有效地增强了对特征图语义信息的提取和扩大特征图的感受野。然后,去掉特征金字塔网络用于检测大目标的网络层,从而减小网络的参数量和降低训练过程中的计算消耗。最后,在ResNet网络中添加了膨胀卷积瓶颈模块,有效地提高了特征图的感受野和特征的鲁棒性。通过上述改进,在满足检测时间的条件下,检测准确率较未改进网络提升了1.60%,漏检率降低到0.12%,误检率降低到0.16%。相较于传统的检测方法,本文提出的方法有较高的优势。

参考文献:

- [1] 邵志敏,张意,张卫华,等.基于机器视觉的瓶装白酒杂质检测[J].四川大学学报:自然科学版,2019,56: 235.
- [2] Krizhevsky A, Sutskever I, Hinton G. Imagenet classification with deep convolutional neural networks[C]//Proceedings of the Advances in neural information processing systems. Nevada, USA: Curran Associates Inc, 2012.
- [3] Zeiler M D, Fergus R. Visualizing and understanding convolutional neural networks[C]//Proceedings of the European Conference on Computer Vision (ECCV). Cham: Springer, 2014.
- [4] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]//Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). [S. l.]: IEEE, 2014.
- [5] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation [J]. IEEE T Pattern Anal, 2015, 39: 640.
- [6] Zhao Z, Li B, Dong R, et al. A surface defect detection method based on positive samples[C]//Proceedings of the Pacific Rim International Conference on Artificial Intelligence. Cham: Springer, 2018.
- [7] Ojala T, Pietikäinen M, Harwood D. A comparative study of texture measures with classification based on featured distributions [J]. Pattern Recogn, 1996, 29: 51.
- [8] Yu Z, Wu X, Gu X. Fully convolutional networks for surface defect inspection in industrial environment[C]. [S. l.]: Springer, 2017.
- [9] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[J]. IEEE T Pattern Anal, 2017(99): 2999.
- [10] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). [S. l.]: IEEE Computer Society, 2016.
- [11] Lin T Y, Dollar P, Girshick R, et al. Feature pyramid networks for object detection[C]//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway. NJ: IEEE, 2017.
- [12] Ren S, He K, Girshick R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [C]// Proceedings of the Advances in Neural Information Processing Systems. Montreal, Canada: Curran Associates Inc, 2015.
- [13] 宋欢欢,惠飞,景首才,等.改进的RetinaNet模型的车辆目标检测[J].计算机工程与应用,2019,55: 225.
- [14] Jiang Y, Tan N. Retinal vessel segmentation based on conditional deep convolutional generative adversarial networks [J/EB]. ArXiv abs/1805.04224.
- [15] Li Z, Peng C, Yu G, et al. DetNet: A backbone network for object detection[C]// Proceedings of the European Conference on Computer Vision. Cham: Springer, 2018.

引用本文格式:

- 中 文: 吴华运,任德均,吕义钊,等. 基于改进的RetinaNet医药空瓶表面气泡检测[J]. 四川大学学报: 自然科学版, 2020, 57: 1090.
- 英 文: Wu H Y, Ren D J, Lü Y Z, et al. Bubble detection on the surface of medical empty bottles based on improved RetinaNet[J]. J Sichuan Univ: Nat Sci Ed, 2020, 57: 1090.