基于改进 YOLOv5 的试剂卡印刷缺陷检测算法

刘国庆¹, 方成刚^{1*}, 黄德军², 龙超¹

(1.南京工业大学 机械与动力工程学院,南京 211800; 2.南京紫城工程设计有限公司,南京 211800)

摘要:目的 针对试剂卡生产企业采用人工分选印刷缺陷的试剂卡存在效率低、成本高、易漏检的问题, 提出一种基于深度神经网络 YOLOv5s 的改进试剂卡印刷缺陷检测算法 YOLOv5s-EF。方法 通过图像预 处理算法获得高质量的缺陷图像数据集,在 YOLOv5s 的主干特征提取网络中添加高效通道注意力 (Efficient Channel Attention, ECA)机制,增强特征图中重要特征的表示能力;引入焦点损失函数(Focal Loss)来缓解正负样本不均衡的影响;结合印刷区域的定位结果,二次精确定位并构建方位特征向量, 提出一种特征向量相似度匹配方法。结果 实验结果表明,本文提出的试剂卡印刷缺陷检测算法在测试 集上的检测平均准确度可以达到 97.3%,速度为 22.6 帧/s。结论 相较于其他网络模型,本文提出的方 法可以实现对多种印刷缺陷的识别与定位,模型具有较好的检测速度和鲁棒性,有利于提高企业生产的 智能化水平。

关键词:缺陷检测;YOLOv5s;深度学习;高效通道注意力机制;焦点损失函数 中图分类号:TP391 文献标识码:A 文章编号:1001-3563(2023)17-0197-09 DOI: 10.19554/j.cnki.1001-3563.2023.17.024

Reagent Card Printing Defect Detection Algorithm Based on Improved YOLOv5

LIU Guo-qing¹, FANG Cheng-gang^{1*}, HUANG De-jun², LONG Chao¹

School of Mechanical and Power Engineering, Nanjing Tech University, Nanjing 211800, China;
 Nanjing Zicheng Engineering Design Co., Ltd., Nanjing 211800, China)

ABSTRACT: The work aims to propose an improved reagent card printing defect detection algorithm LOv5s-EF based on deep neural network YOLOv5s to solve the problems of low efficiency, high cost and easy to miss detection in manual sorting of reagent cards with printing defects in reagent card manufacturers. High-quality defect image data sets were obtained by image preprocessing algorithm. Efficient Channel Attention (ECA) mechanism was added to the backbone feature extraction network of YOLOv5s to enhance the representation ability of important features in feature maps. Focal loss function was introduced to alleviate the influence of imbalance between positive and negative samples. Combined with the positioning results of the printing area, a method of similarity matching of feature vectors. The experimental results showed that the average detection accuracy of the reagent card printing defect detection algorithm proposed in this paper could reach 97.3% and the speed was 22.6 FPS on the test set. Compared with other network models, it can identify and locate various printing defects. The model has good detection speed and robustness, which is beneficial to improve the intelligent level of enterprise production.

KEY WORDS: defect detection; YOLOv5s; deep learning; ECA mechanism; focal loss function

检测试剂卡是一种医疗产品,因其操作简单,非 专业医疗技术人员也能轻松掌握,同时可为患者提供 快速的检测服务,得到了广泛应用。检测试剂卡可分 为上盖、底盖、试剂条三部分。尽管在生产过程中有 完整成熟的工艺流程,且有专业技术人员进行把控, 但在大批量生产时由于现有工艺的限制,印刷标志仍 可能会出现露白、缺损、漏印、偏移、歪斜等缺陷, 进而影响试剂卡的正常使用,甚至造成检测结果错误 等严重影响。

基于机器视觉的缺陷检测方法因稳定性高、不受 人为因素干扰等优点被广泛应用于印刷缺陷检测领 域。常用的图像缺陷检测算法主要有图像差分法、归 一化互相关系数法、直方图分析法^[1]。但这些方法对 灰度变化、旋转、形变以及遮挡等影响因素比较敏感, 且不易对缺陷直接定位,具有一定的局限性。很多学 者因此提出了不同的方法,胡方尚等^[2]将二叉决策树 与向量支持机相结合,采用改进的多类分类算法实现 印刷缺陷的准确识别,但其对检测精度要求高,对难 分割的缺陷检出率较低。冯秋歌等^[3]通过提取 SIFT 特征点,并设计滤波算子的方法,对印刷字符出现的 漏印、字符缺失、污渍进行检测,但算法鲁棒性较差, 无法识别更加复杂的缺陷。

近年来,由于计算机硬件技术的不断发展,使得 深度学习等神经网络技术在图像处理、目标检测领域 有了迅速的发展,基于深度学习的图像识别已经广泛 应用于缺陷检测等领域。以区域卷积神经网络 (Regions with CNN Features, R-CNN)^[4]、Fast R-CNN、Faster R-CNN 等算法为代表的两阶段算法 (Two-Stage)),以YOLO(You Only Look Once)系 列^[5-7]、单激发多盒检测器(Single-Shot MultiBox Detector SSD)、RetinaNet等算法为代表的单阶段算 法(One-Stage)在缺陷检测领域都得到了广泛应用。

周玮等^[8]利用滤波抑噪等方法对采集图像进行 预处理,结合 YOLOv3 与 AlexNet 网络实现了对包装 袋字符喷码缺陷的定位与识别,但模型复杂计算量较 大。Feng 等^[9]将可见光图像分割与红外图像故障定位 相结合,使用 YOLOv5 与残差神经网络(ResNet) 实现了对大型光伏电站中光伏组件缺陷的快速检测, 准确率达到 95%。王恩芝等^[10]在 YOLOv5 的主干网 络上添加卷积注意力模块,并结合自适应空间特征 融合的方法增强网络的特征融合能力,在纺织品表 面的缺陷检测中达到 98.8%的精度。但该算法严重依 赖大量有明显差异的样本,对样本集较少的情况,其 鲁棒性较差。

本文研究的试剂卡缺陷可分为形状缺陷和位置 缺陷。露白、缺损、漏印等形状缺陷由改进的 YOLOv5s 网络直接检出,网络输出结果结合后续图 像处理算法对偏移、歪斜等位置缺陷进行检测。试剂 卡的露白缺陷特征细小而隐蔽,且容易受到光照变化的影响而与正常图像混淆。样本数量少导致的数据样本不均衡等原因使得原始 YOLOv5 算法对露白缺陷检出率不高,精度以及速度无法达到现代化生产线的检测要求。为了解决上述问题,本文提出一种针对试剂卡印刷缺陷的检测算法,在 YOLOv5s 中引入 Focal Loss 损失函数,并嵌入 ECA 机制使得网络更加关注缺陷目标的特征,进一步加速收敛并提升性能。针对YOLO 系列目标检测算法无法识别目标位置和角度偏移的问题,设计一种可以对试剂卡的形状与位置缺陷进行检测的算法。

1 预处理

本文算法流程如图 1 所示,由工业相机采集试剂 卡图像后需要经过预处理,以增强目标特征。在与模 板图像配准后制作缺陷数据集训练改进的 YOLOv5s 网络模型,通过该模型对缺损、露白、漏印 3 种缺陷 进行识别,同时输出印刷区域坐标信息。利用图像处 理算法精确定位印刷字符的位置,并构建方位特征向 量,通过相似度计算判定是否有偏移和歪斜缺陷,从 而实现对试剂卡常见缺陷的快速检测。



图 1 本文算法流程 Fig.1 Algorithm flow chart of this paper

1.1 图像增强

工业相机直接采集的图像由于工厂环境复杂、光 照变化大等因素易引起噪声和图像模糊。为了使露白 缺陷更易被检出,需要对图像进行增强处理突出缺陷 特征。首先选择中值滤波的方法去除噪声的干扰。然 后进行图像锐化以突出灰度的过渡部分,增强图像边 缘信息提高对比度。对图像采用二值化处理方法,考 虑到光照变化,因此选用最大类间方差法(OTSU)。 未经拉普拉斯锐化的露白特征明显少于锐化后的图 像,最后通过 Hough 直线检测进行倾斜校正,并提 取试剂卡 ROI。各类试剂卡缺陷部分图像具体如图 2 所示。



1.2 图像配准

在试剂卡图像的实际采集过程中,由于摄像机的 机械振动、传感器噪声等因素,导致获取的图像与标 准模板存在一定差异^[11]。为了降低这种差异,避免对 后续方位特征向量的提取造成不良影响,有必要将待 检测图像与标准模板进行图像配准。

配准过程中首先使用 ORB (Oriented FAST and Rotated BRIEF)算法提取 2 幅图像的特征点,保留 最匹配的特征点并计算描述子。然后通过汉明距离 (Hamming Distance)度量 2 个特征点描述子的相似 度。最后通过暴力匹配法 (Brute Force)筛选汉明距 离满足要求的特征点,建立匹配特征对。采用随机抽样一致 (Random Sample Consensus, RANSAC)算 法剔除误匹配点对,优化后的特征点对如图 3a 所示。选择 3 对最优匹配的特征点计算校正待测图像的单 应性矩阵 *T*。

$$\boldsymbol{T} = \begin{bmatrix} a_1 & a_2 & t_x \\ a_3 & a_4 & t_y \\ 0 & 0 & 1 \end{bmatrix}$$
(1)

其中,参数 a_i (i = 1, 2, 3, 4)反映图像旋转和缩放 变换; t_i (j = 1, 2)反映图像的平移。 通过式(2)进行仿射变换,将待检测图像变换 到标准图像的坐标系上实现图像的配准。配准前后图 像如图 3b、c所示。

$$\begin{bmatrix} x' \\ y \\ 1 \end{bmatrix} = T \begin{bmatrix} x \\ y \\ 1 \end{bmatrix}$$
(2)

式中:(x, y)为待检测图像的像素点坐标;(x', y')为配准后的图像像素点坐标。



Fig.3 Registration results

2 改进 YOLOv5 算法

2.1 网络结构

YOLO (You Only Look Once) 系列算法的核心 思想是将目标的边界框、置信度和类别视为数值回归 的问题。YOLOv5 算法的网络结构包括输入、 Backbone 主干网络、Neck 网络和 Head 预测头部^[12]。 本文拟提出一种实现模型轻量化的设计方法,在保证 检测精度的同时,尽可能减少模型大小和计算量,因 此选择 YOLOv5s 进行改进。Backbone 主干网络将原 先使用的 Focus 模块替换为 6×6 大小的卷积层, 在得 到同等大小下采样特征图的同时降低了浮点运算量。 采用 SPPF 模块代替原先的空间金字塔池化 (Spatial Pyramid Pooling, SPP),将并行的最大池化层改为串 行,缩小了卷积核的大小,显著提高了运行速度。结 合跨阶段局部网络(Cross Stage Partial Network, CSPNet),从同一个特征图中提取不同尺度的特征, 提高检测精度。随后的特征金字塔网络(feature Pyramid Network, FPN)将高层特征通过下采样的方 式向下传递,路径聚合网络(Path Aggregation Network, PAN)将低层特征向上传递,两者特征在传递 过程中不断融合,从而增强网络的特征提取能力^[13]。 Head 预测头部输出预测边界框,并使用非极大值抑 制(Non-Maximum Suppression, NMS)去除冗余框, 得到最终检测目标的边界框。

2.2 改进损失函数

YOLOv5s 的损失函数由置信度损失(Confidence Loss, l_{obj})、分类损失(Classification Loss, l_{cls})和 边框回归损失(Bounding Box Regression Loss, l_{box}) 三部分组成。使用二元交叉熵作为置信度和分类的损 失函数^[14], 交叉熵损失定义如下:

$$L = -y \log y' - (1 - y) \log(1 - y') = \begin{cases} -\log y', y = 1 \\ -\log(1 - y'), y = 0 \end{cases}$$
(3)

式中: *L* 为交叉熵损失,正样本时 *y*=1,负样本时 *y*=0; *y*'为激活函数的输出, 0<*y*'<1。

YOLOv5s 在进行目标检测时会生成大量的先验 框,但只有少数区域包含检测目标,这些大量产生在 图片背景区域的先验框会导致正负样本不均匀。在交 叉熵损失计算中,每个训练样本的权重是相等的,大 量负样本会提高网络计算量并使检测精度下降。为此 本文引入焦点损失函数(Focal Loss)代替置信度损 失,通过降低易分类样本的权重,使模型更专注于困 难样本^[15], Focal Loss 的计算见式(4)。

$$L_{\rm F} = \begin{cases} -\alpha (1-y')^{\beta} \log y' & y=1\\ -(1-\alpha)y'^{\beta} \log(1-y') & y=0 \end{cases}$$
(4)

引人因子 a 来平衡正负样本的权重(0 < a < 1), 降低数量较大的负样本的权重比例。若数据集中正样 本数量较少,则可降低 a 的值来增大模型预测错误的 惩罚。引入因子 β 以减少易分类样本的损失。露白缺 陷不易识别,且样本数量占比相对少,属于困难样本, 其 y'很小,此时 $(1-y')^{\beta}$ 趋向于 1,不影响损失权重; 对于较易分类的样本,即 y'较大时,则 $(1-y')^{\beta}$ 趋向 于 0,以降低其损失权重占比。对比交叉熵损失函数 可见,Focal Loss 在模型训练中可以调整易分类样本 与难分类样本在损失函数中的权重,使模型更加关注 难学习样本。经过多次实验比较,当 a=0.25、 $\beta=2$ 时 损失最低。

本文选择 CIoU_Loss^[16]作为边框回归损失,综合 考虑了预测框与真实框之间的重叠率、中心点距离、 长宽比,加速了网络的收敛,并得到更高的回归定位 精度,有效提高了缺陷目标在遮挡情况下的检出率。 其公式如下:

$$l_{\rm box} = 1 - I_{\rm IoU} + \frac{\rho^2(b, b^{\rm gt})}{c^2} + \alpha v$$
 (5)

$$\alpha = \frac{v}{(1 - I_{\rm IoU}) + v} \tag{6}$$

$$v = \frac{4}{\pi^2} \left(\arctan\frac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan\frac{w}{h}\right)^2 \tag{7}$$

式中: *b* 和 *b*st 分别为预测框和真实框的中心点; (*w*, *h*)、(*w*st, *h*st)分别为预测框的宽、高与真实框的 的宽、高; *ρ* 为欧氏距离; *c* 为相交的预测框与真实 框之间构成的最小外界矩形的对角线距离; α 为权重 函数,不参与梯度计算; ν用来描述预测框和真实框 长宽比的一致性。

2.3 ECA 注意力机制

通道注意力更加注重各个通道的相关性对网络的影响,并可在网络训练的不断迭代中获得不同通道的权重系数,从而提高目标特征的权重。SE(Squeeze-Excitation)模块^[17]是一种常用的通道注意力机制,但其先降维再升维的操作不利于捕获不同通道之间的关系,且结构复杂带来较重的计算负担。Wang等^[18]在改进SE模块的基础上提出了ECA(Efficient Channel Attention)模块,其核心思想是不降维的局部跨通道交互策略以及自适应确定一维卷积核的大小,降低复杂度的同时带来性能的提升。

ECA 模块首先对输入特征图进行全局平均池化 (Global Average Pooling, GAP),获得未降维的特征; 再通过大小为 k 的一维卷积核获取跨通道交互信息; 最后使用 sigmoid 函数生成各通道的权重占比,将原 始输入特征与通道权重结合从而加强露白、缺损的特 征,其结构如图 4 所示。ECA 模块用一维卷积操作 代替全连接层,避免了对特征通道的压缩,卷积核的 大小 k 代表了局部跨通道交互的覆盖率,根据网络结 构的变化自适应改变,如式(8)所示。



图 4 ECA 模块结构 Fig.4 ECA module structure

$$k = \psi(C) = \left| \frac{\log_2 C}{\gamma} + \frac{b}{\gamma} \right|_{\text{odd}}$$
(8)

式中: *C* 为输入特征图通道数; ||_{odd} 为离 *k* 最近 的奇数; *γ*和*b* 分别设置为 2 和 1。*k* 大小确定后,第 *i* 个通道 *γ* 的权重 *ω* 可以表示为:

$$\omega_i = \sigma(\sum_{j=1}^k \alpha^j \gamma_i^j), \gamma_i^j \in \mathcal{Q}_i^k$$
(9)

式中: Q^k 为 γ_i 与相邻 k个通道的集合; α^j 为所 有通道共享的学习参数。

本文将 ECA 模块嵌入 PAN 结构中的 concat 之 后,对融合后的不同尺度特征图进行重要特征的加 强,以获得更高的缺陷目标检出率。改进后的 YOLOv5s-EF 算法框架如图 5 所示。



图 5 改进的 YOLOv5s 网络结构 Fig.5 Improved YOLOv5s network structure

3 印刷缺陷识别

3.1 特征提取与构建特征向量

待检测图像在送入 YOLOv5s-EF 网络之前已进 行配准校正。由于网络输出的印刷区域定位框是一个 只能表示大致位置的水平矩形,无法检出位置缺陷。 所以需要在定位框的基础上进行二次精准定位,并提 取方位特征向量,将其与标准模板进行相似度判定, 从而判断是否存在偏移和歪斜缺陷。具体流程如下:

1)印刷区域定位框裁剪。根据 YOLOv5s-EF 给出的定位框位置信息,对图像相应位置进行裁剪。

2) 二次精确定位。对于连通域完整的水滴和箭头标志图像块,用 Canny 算子提取轮廓边缘,检测到轮廓后使用 cv.minAreaRect 函数获得连通域的最小外接矩形,从而实现精确定位。对于 2 块字符彼此独立的区域,则采用形态学梯度运算中的基本梯度并进行膨胀处理,最后计算最小外接矩形。二次定位的结果如图 6 所示。



图 6 二次定位结果 Fig.6 Secondary positioning results

3)构建印刷区域的方位特征向量。从图 6 可以 看出,最小外接矩形表示了印刷区域的绝对位置,可 以反映是否存在位置缺陷。定义一种方位特征向量 $D_{s} = \{P_{0}, P_{1}, P_{2}, P_{3}, P_{4}\}, 其中, P_{0}(x_{0}, y_{0}), P_{1}(x_{1}, y_{1}),$ $P_{2}(x_{2}, y_{2}), P_{3}(x_{3}, y_{3}), P_{4}(x_{4}, y_{4})$ 分别表示最小外接矩形 的中点和 4 个顶点坐标。

3.2 缺陷检测

待检测图像的露白、缺损、漏印缺陷可由 YOLOv5s-EF网络直接检出,偏移、歪斜缺陷可以在 提取印刷区域方位特征向量后,将其与标准模板的方 位向量进行比较,判断的具体方法如下。

 偏移缺陷。计算最小外接矩形 4 个顶点和中 心点与标准模板中对应点的平均距离。如果平均距离 超过阈值δ,则认为存在偏移缺陷。计算式见式(10)。

$$d = \frac{1}{5} \sum_{i=0}^{4} \sqrt{(P_{ix} - Q_{ix})^2 + (P_{iy} - Q_{iy})^2}$$
(10)

$$\sigma = \frac{1}{2}\min(h_t, w_t) \tag{11}$$

式中: *P_{ix}、P_{iy}* 为待测图像上印刷区域方位特征 向量点的横纵坐标; *Q_{ix}、Q_{iy}* 为标准模板图像上相应 点的坐标; *h*_t、*w*_t为最小外接矩形的高和宽。

2) 歪斜缺陷。计算最小外接矩形上边与水平线 的夹角 θ ,如果 $\theta > 10^{\circ}$ 则认为存在歪斜缺陷。 θ 的计 算式见式(12)。

$$\theta = \arctan \frac{\left| \overline{P_x P_2} \right|}{\left| \overline{P_1 P_x} \right|}$$
(12)

式中: P_1 、 P_2 、 P_x 的坐标分别为 (x_1, y_1) 、 (x_2, y_2) 、 (x_2, y_1) 。

4 实验与结果分析

4.1 实验平台

本文采用自制试剂卡缺陷数据集进行训练,搭建 OpenCV 深度学习平台,处理器为 AMD Ryzen 7 5800H,32 G运行内存,显卡为 NVIDIA GEFORCE RTX3060。试剂卡缺陷检测模型在 PyTorch 框架下构 建,开发环境为 python 3.8, opencv 版本为 4.5.1.48。

4.2 数据集与模型训练

本文数据集来自现场拍摄,选用西安维视公司 生产的 MV-EM510M/C 型 CCD 相机,最高分辨率为 2 456×2 058。采集包括无缺陷、字符露白、缺损,印 刷偏移、歪斜、漏印等 5 种常见的缺陷图像共 1 200 张, 各类试剂卡缺陷种类的数量分布如图 7 所示。针对





数据量不足的问题,采用平移、旋转、对比度调节 等方法对数据集进行扩充^[19],扩充后的数据集共有 4 800 张图像,将其按照 6:2:2 的比例划分为训练 集、验证集、测试集进行模型训练。输入图像大小为 640×640,训练中优化器使用随机梯度下降,训练批次 为 32,动量为 0.937,权重衰减系数为 0.000 5。初始学 习率为 0.01,并采用 Warm-up 的方法预热,最后采用 余弦退火算法更新学习率,训练迭代次数为 200。

4.3 评价指标

为了验证 YOLOv5s-EF 的性能,本文采用深度学 习常用评价指标,如平均精度(Average Precision, A_P)、平均精度均值(mean Average Precision, A_{mAP}) 和检测速度等。 A_P 指 P-R 曲线的面积, A_{mAP} 的值则 是通过所有类别的 A_P 求均值得到,计算方法如式 (15)、(16)所示^[20]。

$$P = \frac{T_{\rm P}}{T_{\rm P} + F_{\rm P}} \tag{13}$$

$$R = \frac{T_{\rm P}}{T_{\rm P} + F_{\rm N}} \tag{14}$$

$$A_{\rm p} = \int_0^1 P(R) \mathrm{d}R \tag{15}$$

$$A_{\rm mAP} = \frac{\sum_{i=1}^{i} A_{\rm Pi}}{N} \tag{16}$$

4.4 实验结果

为了验证在损失函数中引入Focal Loss 能否加速 网络的收敛,使用改进前后的网络在相同数据集上进 行训练。训练过程中损失变化如图 8 所示,其中点线 为原始 YOLOv5s 的损失,虚线为引入 Focal Loss 后 的损失变化情况。由图 8 可以看出,前 50 轮损失值 下降较快,随后逐渐趋于平缓;在引入焦损函数代替 置信度和分类损失后,在各轮都获得了更低的损失 值,同时相较原始模型更快收敛,最终损失值稳定在 0.016 左右,训练过程均未出现过拟合现象。



为了验证本文提出的试剂卡缺陷检测算法的性能,对原始数据集中的1200张图像进行重复实验,并统计各类缺陷的检出率,如表1所示。

表 1 本文算法对各类缺陷检测性能统计 Tab.1 Performance statistics of various defects detected by the present algorithm

缺陷类别	样本数	检出数	检出率/%
合格	500	491	98.2
露白	150	143	95.3
缺损	250	242	96.8
漏印	100	100	100.0
偏移	100	96	96.0
歪斜	100	95	95.0
总计	1 200	1 167	97.3

由表1可以看出,本文算法在测试集上的总检出 率可以达到97.3%,各类缺陷的检出率均可达到96% 以上,表现出较好的稳定性,可以满足当前对试剂卡 印刷缺陷的检测要求。YOLOv5s-EF 网络结合位置缺 陷检测算法完整检测一张图片的速度平均值为22.6 帧/s,满足实时性要求。

图 9 为 YOLOv5s-EF 在测试集上的缺陷检测结 果。由图 9 可以看出,模型对各印刷区域的检测效果 较好,其中露白(Loubai)和缺损(Defect)缺陷的 置信度均超过 0.9。对露白特征较少的缺陷也能精准 的识别,可见 ECA 注意力机制的添加有效增强了模 型对缺陷细小特征的提取能力,以及与正常字符的区 分能力。



图 9 改进 YOLOv5s 实验结果 Fig.9 Improved YOLOv5s experimental results

4.5 实验对比分析

为验证添加注意力机制和引入Focal Loss 损失函数对检测结果的影响,本文在实验中设置原始网络结构+交叉熵损失函数(YOLOv5s)、添加 ECA 注意力机制+交叉熵损失函数(YOLOv5s-E)、添加 ECA 注意力机制+Focal loss 损失函数(YOLOv5s-EF)3组实验进行对比,对比结果如表2所示。

表 2 不同模型的检测性能对比 Tab.2 Comparison of detection performance of different models

网络结构	4 /0/	检测速度/	<i>A</i> _P /%		
179 26 20 19	$A_{\rm mAP}$ / 70	(帧·s ⁻¹)	露白	缺损	
YOLOv5s	93.5	45.6	92.1	94.8	
YOLOv5s-E	95.3	37.1	94.2	96.3	
YOLOv5s-EF	95.9	36.3	95.7	96.1	

添加 ECA 注意力机制后, AmAP 由 93.5%增加到 95.3%, 增加了 1.8%。其中露白缺陷的检测效果提升 较大,露白的 Ap 提升了 2.1%,缺损的 AP 值也提升 了 1.5%。主要是因为露白缺陷受光照变化影响较大、 特征不显著等使得原始算法易将其误判为正常图像。 高效通道注意力机制的添加使得网络更加关注特征 图中通道位置上的关键信息,更好地提取缺陷特征, 从而提高了检测的准确率。同时也导致检测速度降低 了 8.5 帧/s,但仍然满足实时性的要求。使用 Focal Loss 代替交叉熵损失函数后 mAP 值进一步增加到 95.9%, 增加了 0.6%; 露白的 A_P 提高了 1.5%。可见因子 α 有 效平衡了正负样本的权重,因子β则减少了易分类样 本的损失,使模型更加专注于学习难分类样本。缺损 的 A_p略有下降,主要原因是数据集中缺损样本的数 量较多,特征较露白缺陷更易识别,引入 Focal loss 后其损失权重占比有所下降。综上,引入 Focal Loss 更有利于提高模型检测精度,加速网络收敛。

表 3 对比分析了当前主流的目标检测算法与本 文算法在试剂卡表面缺陷数据集上的性能。在包括了 合格、露白、缺损共 900 张图像上,用平均精度均值 以及检测速度来衡量各算法的性能。

表 3 改进 YOLOv5s 与其他目标检测模型性能比较结果 Tab.3 Performance comparison results of improved YOLOv5s and other target detection models

算法	主干网络	$A_{\rm mAP}$ /%	检测速度/ (帧·s ⁻¹)
Faster RCNN	ResNet50	90.2	9.15
SSD	VGG19	88.4	54
YOLOv5s	CSPDarkNet53	93.5	45.6
YOLOv5s-EF	CSPDarkNet53+ECA	95.9	36.3

由表3可知,在同样的测试集上,YOLOv5s-EF 的平均精度为95.9%,比 Faster RCNN、SSD、 YOLOv5s算法分别提高了5.7%、7.5%、2.4%,检测 精度为各算法中最高。从检测速度看,YOLOv5s-EF 平均每秒可以检测36.3 张图片,因其添加了ECA注 意力机制,增加了算法的部分计算量,使其较 YOLOv5s算法降低了9.3 帧/s。虽然帧率有所降低, 但 A_{mAP}提高了2.4%。YOLOv5s-EF 较 Faster RCNN 提升了27.15 帧/s,而较 SSD则有所降低,但其检测 精度更高。综上,本文提出的改进算法能获得很好的 检测精度、平均精度均值,满足试剂卡缺陷检测对精 度的要求,同时在检测时间上仍有较大优势。

为了进一步验证 YOLOv5s-EF 的稳定性,采用 PASCAL VOC 2007 数据集对改进模型进行训练。数 据集共9 963 张图片,包含 20 个种类。在相同实验 环境下使用改进前后的算法进行实验,检测性能数据 如表4所示。从表4可以看出,所提方法的*A*_{mAP}较 原始算法的提高了4.2%。ECA 注意力机制的添加增 强了网络的检测能力,同时检测速度有所下降,客观 反映了所提算法具有较好的泛化性和稳定性。

表 4 实验对比结果 Tab.4 Experimental comparison results

算法	主干网络	$A_{\rm mAP}$ /%	检测速度/ (帧·s ⁻¹)
YOLOv5s	CSPDarkNet53	75.4	33
YOLOv5s-EF	CSPDarkNet53+ECA	79.6	26.3

5 结语

针对生产线上试剂卡露白等缺陷的特征细小而 隐蔽,难以在复杂环境下进行高精度检测的问题,提 出一种试剂卡缺陷检测算法。该方法在原 YOLOv5s 模型的基础上,通过嵌入 ECA 注意力机制,使网络 更加关注目标特征,以获得更高的缺陷目标检出率; 采用 Focal loss 代替原有的置信度损失函数来缓解 正负样本不平衡的问题,加速网络的收敛。本文算 法在测试集上的总检出率可以达到 97.3%,速度为 22.6 帧/s,表现出较好的稳定性,实现了多类试剂卡 缺陷的高精度快速检测。下一步将围绕如何将试剂卡 缺陷检测算法部署在工控机上,并对模型进行进一步 的剪枝和性能改进,以实现生产线上试剂卡缺陷的实 时检测。

参考文献:

 胡宜笑.印刷品缺陷检测研究与应用[D].长沙:湖南 大学,2020:27-28.

HU Yi-xiao. Research and Application of Printing De-

fect Detection[D]. Changsha: Hunan University, 2020: 27-28.

 [2] 胡方尚,郭慧.基于改进多类支持向量机的印刷缺陷 检测[J]. 华东理工大学学报(自然科学版), 2017, 43(1):143-148.

HU Fang-shang, GUO Hui. Printing Defects Inspection Based on Improved Multi-Class Support Vector Machine[J]. Journal of East China University of Science and Technology (Natural Science Edition), 2017, 43(1): 143-148.

 [3] 冯秋歌, 吴禄慎, 王晓辉. 基于视觉的印刷字符缺陷 自动检测方法[J]. 南昌大学学报(工科版), 2018, 40(4): 385-389.

FENG Qiu-ge, WU Lu-shen, WANG Xiao-hui. Design of Automatic Printing Character Defects Detection System Based on Machine Vision[J]. Journal of Nanchang University (Engineering & Technology), 2018, 40(4): 385-389.

- [4] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation[C]// 2014 IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [5] 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, Las Vegas, 2016: 779-788.
- [6] REDMON J, FARHADI A. YOLO9000: Better, Faster, Stronger[C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops, Honolulu, 2017: 6517-6525.
- [7] REDMON J, FARHADI A. YOLOv3: An Incremental Improvement[EB/OL]. 2018: arXiv: 1804.02767. https:// arxiv.org/abs/1804.02767
- [8] 周玮, 门耀华, 辛立刚. 基于机器视觉的柔性包装袋 喷码缺陷检测研究 [J]. 包装工程, 2022, 43(9): 249-256.
 ZHOU Wei, MEN Yao-hua, XIN Li-gang. Inspection of Coding Defects in Flexible Packaging Bags Based on Machine Vision[J]. Packaging Engineering, 2022, 43(9): 249-256.
- [9] FENG Hong, JIE Song, HANG Meng, et al. A Novel Framework on Intelligent Detection for Module Defects of PV Plant Combining the Visible and Infrared Images[J]. Solar Energy, 2022, 236: 406-416.
- [10] 王恩芝, 张团善, 刘亚. 基于改进 Yolo v5 的织物缺陷 检测方法[J]. 轻工机械, 2022, 40(2): 54-60.

WANG En-zhi, ZHANG Tuan-shan, LIU Ya. Fabric Defect Detection Method Based on Improved Yolo V5[J]. Light Industry Machinery, 2022, 40(2): 54-60.

- [11] 胡方尚,郭慧,邢金鹏,等. 基于印刷缺陷检测的图像配准方法研究[J]. 光学技术, 2017, 43(1): 16-21.
 HU Fang-shang, GUO Hui, XING Jin-peng, et al. Image Registration Based on Label Printing Defect Detection[J]. Optical Technique, 2017, 43(1): 16-21.
- [12] 杨其晟,李文宽,杨晓峰,等.改进 YOLOv5 的苹果 花生长状态检测方法[J].计算机工程与应用,2022, 58(4):237-246.

YANG Qi-sheng, LI Wen-kuan, YANG Xiao-feng, et al. Improved YOLOv5 Method for Detecting Growth Status of Apple Flowers[J]. Computer Engineering and Applications, 2022, 58(4): 237-246.

- [13] 于娟, 罗舜. 基于 YOLOv5 的违章建筑检测方法[J]. 计算机工程与应用, 2021, 57(20): 236-244.
 YU Juan, LUO Shun. Detection Method of Illegal Building Based on YOLOv5[J]. Computer Engineering and Applications, 2021, 57(20): 236-244.
- [14] 李志军,杨圣慧,史德帅,等.基于轻量化改进
 YOLOv5 的苹果树产量测定方法[J].智慧农业(中英 文), 2021(2): 100-114.

LI Zhi-jun, YANG Sheng-hui, SHI De-shuai, et al. Yield Estimation Method of Apple Tree Based on Improved Lightweight YOLOv5[J]. Smart Agriculture, 2021(2): 100-114.

[15] YING Zhi-ping, LIN Zhong-tao, WU Zhen-yu, et al. A

Modified-YOLOv5s Model for Detection of Wire Braided Hose Defects[J]. Measurement, 2022, 190: 406-416.

- [16] ZHENG Zhao-hui, WANG Ping, REN Dong-wei, et al. Enhancing Geometric Factors in Model Learning and Inference for Object Detection and Instance Segmentation[J]. IEEE Transactions on Cybernetics, 2021, 26(8): 1-13.
- [17] HU J, SHEN L, SUN G. Squeeze-and-Excitation Networks[C]// USA: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018.
- [18] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient Channel Attention for Deep Convolutional Neural Networks[C]// 2020 IEEE CVF Conference on Computer Vision and Pattern Recognition (CVPR), Piscataway, 2020: 11531-11539.
- [19] 周宇杰,徐善永,黄友锐,等. 基于改进 YOLOv4 的 输送带损伤检测方法[J]. 工矿自动化, 2021, 47(11): 61-65.

ZHOU Yu-jie, XU Shan-yong, HUANG You-rui, et al. Conveyor Belt Damage Detection Method Based on Improved YOLOv4[J]. Industry and Mine Automation, 2021, 47(11): 61-65.

[20] 王静, 孙紫雲, 郭苹, 等. 改进 YOLOv5 的白细胞检测算法[J]. 计算机工程与应用, 2022, 58(4): 134-142.
WANG Jing, SUN Zi-yun, GUO Ping, et al. Improved Leukocyte Detection Algorithm of YOLOv5[J]. Computer Engineering and Applications, 2022, 58(4): 134-142.

责任编辑:曾钰婵