

基于改进 YOLOv4 的焊接件表面缺陷检测算法

付思琴¹, 邱涛², 王权顺¹, 黄德丰¹, 余华云¹

(1.长江大学 计算机科学学院, 湖北 荆州 434023; 2.重庆大学 计算机学院, 重庆 400044)

摘要: **目的** 针对真实复杂的工业场景下焊接件表面缺陷检测精度低、速度慢和图像噪声大等问题, 提出一种基于卷积神经网络的改进 YOLOv4 焊接件表面缺陷检测算法。**方法** 该模型基于 YOLOv4 算法, 首先, 考虑到存储和计算资源的限制, 使用了轻量级网络 GhostNet 替换 YOLOv4 的主干特征提取网络 (Backbone) CSPDarknet53; 其次, 在 GhostNet 网络结构中嵌入改进的通道注意力机制, 能够提高模型的学习能力且减少参数量; 最后, 引入 K-means++ 聚类算法对焊接件表面缺陷数据集中待检测的标注框宽高进行聚类, 使网络模型更容易检测到样本中的缺陷。**结果** 实验结果表明, 改进后的 YOLOv4 算法平均精度 (mean Average Precision, mAP) 为 91.07%, 检测速度达到 48.11 帧/s, 模型尺寸为 43.2 MB, 比原始 YOLOv4 算法平均精度提升了 4.61%, 检测速度提高了 26.59 帧/s, 模型尺寸缩减了 82.37%。**结论** 所提模型提高了焊接件表面缺陷检测的精度和速度, 在工业表面缺陷检测中具有现实意义。

关键词: 焊接件; 缺陷检测; YOLOv4; GhostNet; K-means++

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 1001-3563(2022)15-0023-10

DOI: 10.19554/j.cnki.1001-3563.2022.15.003

Surface Defect Detection Algorithm of Weldment Based on Improved YOLOv4

FU Si-qin¹, QIU Tao², WANG Quan-shun¹, HUANG De-feng¹, YU Hua-yun¹

(1. School of Computer Science, Yangtze University, Hubei Jingzhou 434023, China;

2. College of Computer Science, Chongqing University, Chongqing 400044, China)

ABSTRACT: The work aims to propose a surface defect detection algorithm improved based on convolutional neural network, so as to solve the problems of low precision, slow speed and large image noise of weldment surface defect detection in complex industrial scenes. The model was established based on the YOLOv4 algorithm. Firstly, considering the limitation of storage and computational resources, the lightweight network GhostNet was used to replace the YOLOv4 backbone feature extraction network (Backbone) CSPDarknet53. Secondly, an improved channel attention mechanism was embedded in the GhostNet network structure, which improved the learning ability of the model and reduced the parameter quantity. Finally, the K-means++ clustering algorithm was introduced to cluster the width and height of the labeled frames to be detected in the weldment surface defect dataset, so that the network model could detect the defects in the samples. From the experimental results, the improved YOLOv4 algorithm had an average precision (mean Average Precision, mAP) of 91.07%, a detection speed of 48.11 frame/s, and a model size of 43.2 MB. Compared with the original YOLOv4 algorithm, the detection precision was increased by 4.61%, the detection speed was improved by 26.59% frame/s and the model size was reduced by 82.37%. The proposed model improves the detection precision and speed of weldment surface defect, which is of practical significance in industrial surface defect detection.

收稿日期: 2022-02-18

基金项目: 国家自然科学基金 (61440023); 中国高校产学研创新基金-新一代信息技术创新项目 (2020ITA03012)

作者简介: 付思琴 (1998—), 女, 长江大学硕士生, 主攻深度学习和图像处理。

通信作者: 余华云 (1968—), 男, 长江大学副教授, 主要研究方向为计算机视觉、人工智能等。

KEY WORDS: weldment; defect detection; YOLOv4; GhostNet; K-means++

在焊接件制造及生产过程中,产品表面难免存在多种类型的缺陷,常见的焊接件表面缺陷有冲孔、焊缝、月牙弯和水斑等,影响焊接件的美观和质量,因此,表面缺陷检测是焊接件生产的重要环节之一。在真实复杂的工业环境中,表面缺陷检测往往面临着缺陷成像与背景差异小、对比度低和缺陷尺度变化大等挑战,此时传统的基于机器视觉的表面缺陷检测方法很难获得较好的检测效果^[1-3]。

随着深度学习技术的快速发展,可以通过学习数据来实现参数的自动更新,从而避免了烦琐的手工设计过程。由于深度学习具有良好的学习性能和对海量数据的特征抽取能力,所以许多学者都将它用于产品缺陷的识别^[3]。目前,基于深度学习的缺陷检测网络从结构上可以划分为以 Faster R-CNN^[4]为代表的两阶段网络和以 SSD (Single Shout Multibox Detector)^[5] 或 YOLO (You Only Look Once)^[6-9]系列为代表的一阶段网络。在相关研究领域,He 等^[10]提出基于深度学习的 Faster R-CNN 目标检测算法,改进后的算法在采用主干网络为 ResNet-50 时,对带钢表面缺陷检测精度的达到 82.3%。程婧怡等^[11]提出一种基于改进 YOLOv3 的金属表面缺陷检测模型,解决了缺陷检测中存在的目标尺寸较小及特征不清楚而造成的漏检问题。王淑青等^[12]提出一种基于 YOLOv5 的瓷砖表面缺陷检测模型,提高了生产线上瓷砖表面缺陷检测速率,在实际工业生产中具有一定的实际意义。

虽然上述改进算法在端对端目标检测中已经取得了较好的效果,但仍难满足焊接件表面缺陷检测的

精度需求,并且模型尺寸对机器性能要求较为严格。针对上述问题,文中提出了改进的轻量级网络——YOLOv4-GhostNet,提高焊接件表面缺陷检测精度的同时减小模型尺寸。该网络基于 YOLOv4 模型,使用了 GhostNet^[13]替换 YOLOv4 中的主干网络 CSPDarknet53,不仅提升了模型提取特征信息的能力,而且利用 Ghost 瓶颈结构 (Ghost Bottleneck) 降低计算成本。使用 2 个 1×1 卷积代替 SENet^[14]中的全连接层,改进通道注意力模块并将其嵌入 GhostNet 结构中,保持网络表征能力的同时有效减少模型的参数量。通过 K-means^[15]聚类算法生成的锚框参数可以准确表征焊接件表面缺陷的位置分布,解决了原始 YOLOv4 默认的 anchor 设定引起的网络收敛速度缓慢且精度低下问题。实验结果表明,改进算法能够提高焊接件检测精度,且满足实时性要求。

1 焊接件表面缺陷检测方法

1.1 基于 YOLOv4 的焊接件缺陷检测模型

YOLOv4 是文献[9]在文献[8]的基础上改进的目标检测模型,与 YOLOv3 相比较,YOLOv4 在保证检测速度的前提下,模型的检测精度也有很大的提升。YOLOv4 的主要思想是将输入的特征图像分割为不同尺度大小的网格,若检测对象位于某个网格中,则由对应网格负责完成该对象的检测。YOLOv4 的网络结构见图 1,主要由主干网络、Neck 和预测部分组成

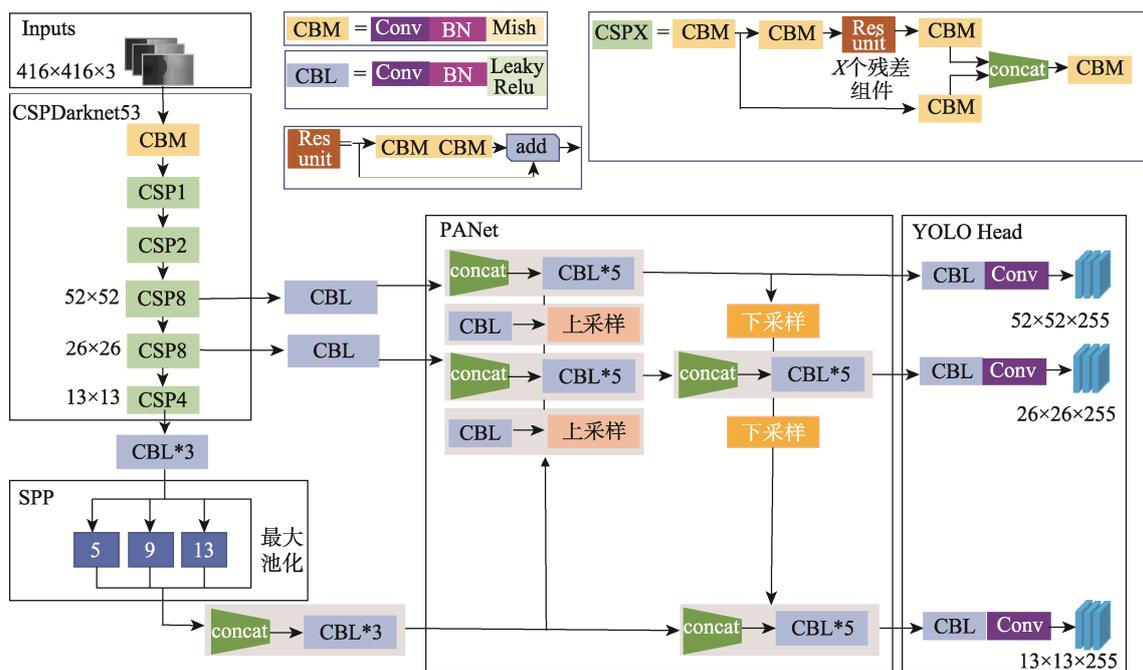


图 1 YOLOv4 网络结构
Fig.1 YOLOv4 network structure

成。主干网络为 CSPDarknet53, 对输入图片进行特征提取; Neck 包括 SPP 和 PANet, 进行多尺度特征融合; YOLOv3 Head 作为预测部分, 用于目标检测及输出^[16]。

相较于 YOLOv3, YOLOv4 主要的改变体现在以下部分: YOLOv4 的主干网络使用 CSPDarknet53 替换掉 YOLOv3 中的 Darknet53, 而且采用 Mish 激活函数替换了初始卷积层后的 Leaky ReLU 激活函数, 极大程度上提高了网络提取特征信息的能力; 在 YOLOv4 的 Backbone 后增加了空间金字塔池化 (Spatial Pyramid Pooling, SPP) 模块, 并且将其放置在第 5 个残差组件后, 可以明显提高感知范围, 从多个尺度进行特征融合; 基于“自上而下”的路径聚合网络 (PANet) 重复抽取特征, 增加特征的丰富性; 除此之外, 还引入了马赛克 (Mosaic) 数据增强, 可以同时 4 张样本图片拼接在一起, 增强训练样本的多样性。

1.2 GhostNet 模型

GhostNet 是文献[13]提出的一个轻量级网络, 它的核心模块是 Ghost 模块 (Ghost Module)。通常情况下, 使用普通卷积神经网络来训练输入数据, 在训练完成后会生成许多冗余的特征图。在输出相同大小特征图的前提下, 与常规卷积神经网络相比较, Ghost 模块的卷积方式大幅度减少了卷积计算量和参数量, 并且可以简便地嵌入其他网络中。Ghost 模块就是首先对输入的特征图利用 1×1 卷积 (Conv2d 1×1) 进行通道的缩减, 完成通道缩减之后获得一个特征浓缩, 再对每个通道进行逐层卷积来获得额外的特征图, 然后把 1×1 卷积生成的特征图与逐层卷积获得的特征图进行堆叠操作, 最后就可以获得输出的特征层。Ghost 模块与普通卷积模块的区别见图 2。

假设输入特征图片为 $D_1 \times D_1 \times W$, 宽和高均为 D_1 ,

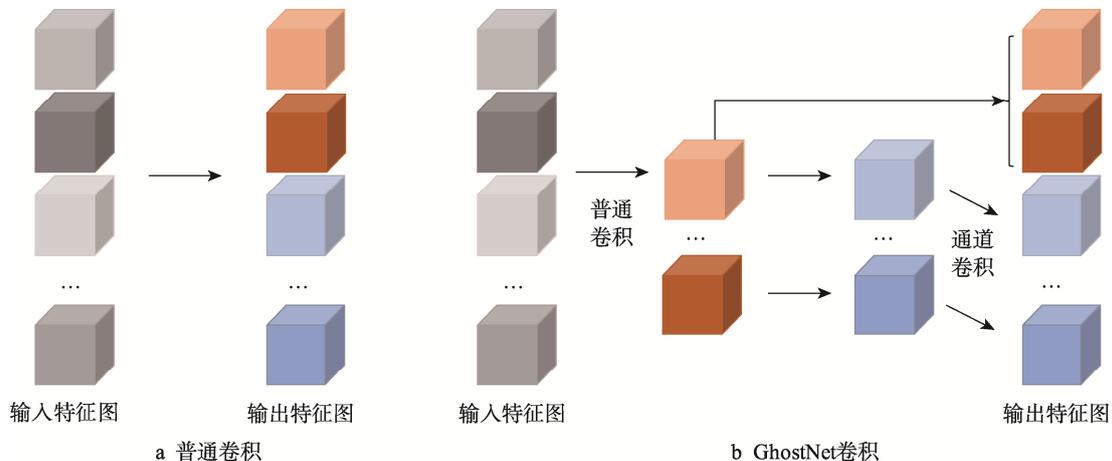


图 2 普通卷积与 GhostNet 卷积
Fig.2 Ordinary convolution and GhostNet convolution

常规卷积核的大小为 D_k , GhostNet 卷积的第 1 部分传统卷积核的宽和高为 $D_{k'}$, 第 2 部分扩展卷积核的宽和高为 $D_{k''}$, 输出特征图尺寸为 $D_o \times D_o \times N$ ^[17]。由此可以得知, 常规卷积层的卷积计算量为:

$$C_{flops} = D_k \times D_k \times W \times N \times D_o \times D_o \quad (1)$$

常规卷积层的卷积参数量为:

$$C_{params} = D_k \times D_k \times W \times N \quad (2)$$

Ghost 模块卷积计算量为:

$$G_{flops} = \left(D_{k'} \times D_{k'} \times W \times \frac{N}{2} \times D_o \times D_o \right) + \left(D_{k''} \times D_{k''} \times 1 \times \frac{N}{2} \times D_o \times D_o \right) \quad (3)$$

Ghost 模块卷积参数量为:

$$G_{params} = D_{k'} \times D_{k'} \times W \times \frac{N}{2} + D_{k''} \times D_{k''} \times 1 \times \frac{N}{2} \quad (4)$$

利用 Ghost Module 的优势, 文献[13]又提出了 Ghost 瓶颈结构。Ghost Bottleneck 是由主干部分和残差边部分组成, 包含 Ghost 模块的称之为主干部分。第 1 层 Ghost 模块起到扩展层的作用, 用来增加通道数, 第 2 层 Ghost 模块用来减少通道数, 并且利用 shortcut 将输入和输出连接起来。Ghost 瓶颈结构的架构见图 3, 当设置 Ghost Bottleneck 的步长为 1 时, 对输入特征层不做压缩操作, 在主干部分利用了 2 个 Ghost Module 进行特征提取, 而在残差边的部分不进行任何处理, 直接将输入和输出进行相加。当设置 Ghost Bottleneck 的步长为 2 时, 首先利用 1 个 Ghost Module 对输入的特征层进行特征提取, 然后使用步长为 2 的逐通道卷积 (Depthwise Convolution) 对上一层特征层进行高和宽的压缩, 之后再次利用 1 个 Ghost Module 进行特征提取过程, 最后再加上残差边, 整个过程中只有在第 1 层 Ghost Module 后面加上了 ReLU 激活, 之后均只用了 BN。

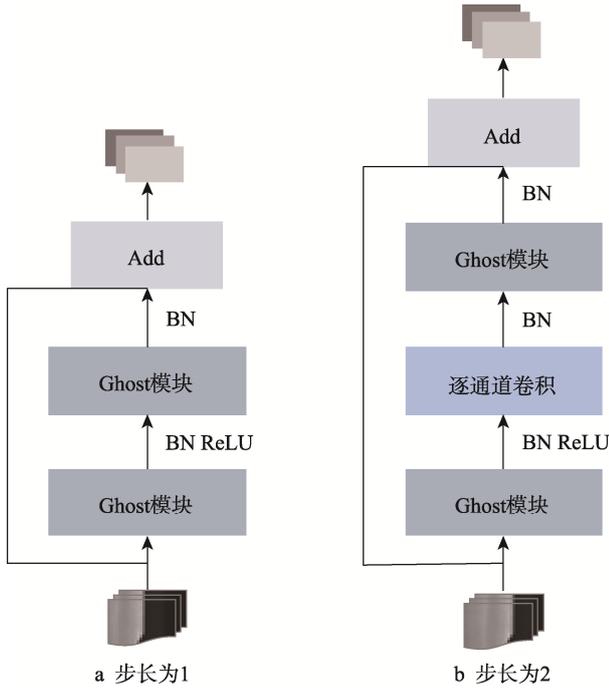


图3 Ghost 瓶颈结构
Fig.3 Ghost bottleneck

2 改进 YOLOv4 目标检测算法

文中改进 YOLOv4-GhostNet 的整体结构框架见图 4，用 GhostNet 替代 YOLOv4 原来的主干网络，分别在瓶颈结构的第 5 层、第 11 层和第 16 层进行特征提取^[18]。

2.1 主干网络改进

YOLOv4 相对于 YOLOv3 虽然提高了精度和鲁棒性，但是对一般的处理器模型尺寸还是相对较大。由于存储和计算资源的限制，所以文中采用 GhostNet 这种轻量级网络来取代 YOLOv4 的 Backbone 进行特征提取操作。对于 YOLOv4，必须使用 3 个有效特征层来构造特征金字塔。当输入 GhostNet 网络的特征图片大小为 $416 \times 416 \times 3$ 时，通过普通卷积和 Ghost Bottleneck 可以取出 3 个有效特征层，分别为 $52 \times 52 \times 40$ 、 $26 \times 26 \times 112$ 、 $13 \times 13 \times 160$ ，之后再利用这 3 个有效特征层替换掉原来 YOLOv4 主干网络 CSPDarkNet53 提取出的 3 个有效特征层。文中改进的 GhostNet 网络结构见表 1，其中 GBN 代表 Ghost Bottleneck，去掉了原始 GhostNet 的最后 4 层网络结构，分别为 Conv2d 1×1 （卷积层），Average Pooling 7×7 （平均池化层），Conv2d 1×1 （卷积层），FC（全连接层）。

2.2 通道注意力机制

焊接件表面背景复杂，在模型的检测过程中会造成一定的干扰，从而导致最终的检测效果不佳。为了降低图像中的噪声，将注意力模块引入主干网络中，能够更好地提取出图像的特征，同时增加了与缺陷相关的特征权重^[19]。GhostNet 在部分网络层结构中加入了 SE 通道注意力模块，SE 模块可以很容易地扩展到已有的网络结构中。文中将 SENet 结构中的全连接层替换为卷积层，改动了嵌入模型中的注意力机制，

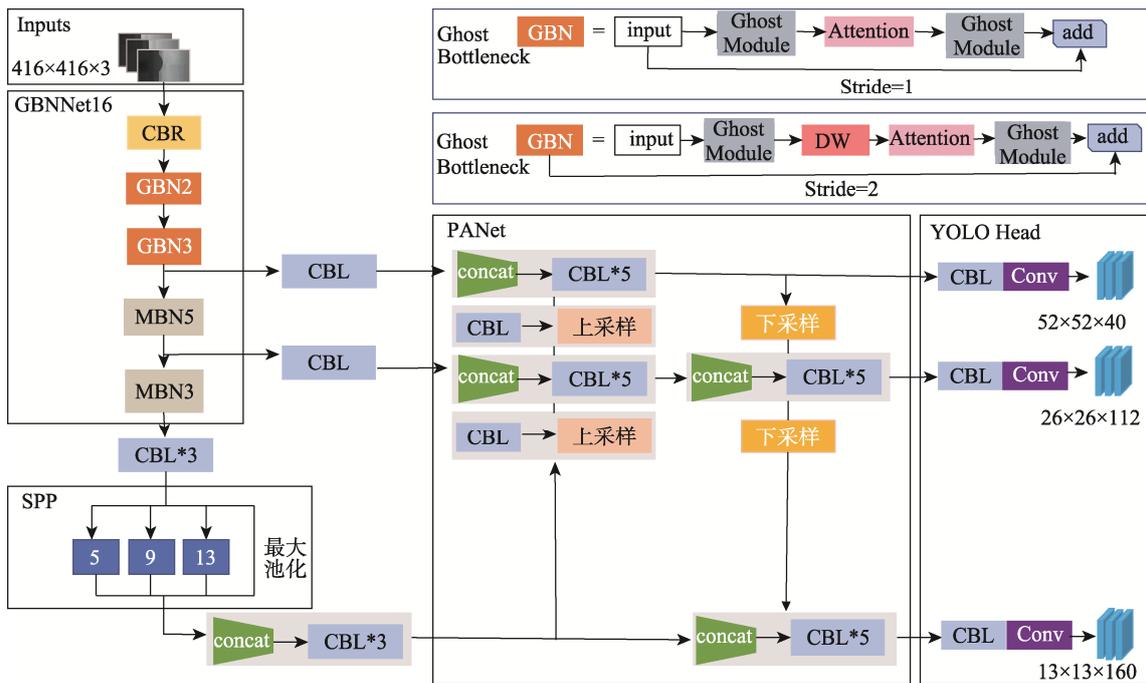


图4 YOLOv4-GhostNet 网络结构
Fig.4 YOLOv4-GhostNet network structure

表 1 GhostNet 网络参数
Tab.1 GhostNet network parameters

输入尺寸	输出尺寸	网络层	通道数	卷积 宽高	步长
416×416×3	208×208×16	Conv2d	16	3×3	2
208×208×16	208×208×16	GBN	16	3×3	1
208×208×16	104×104×24	GBN	24	3×3	2
104×104×24	104×104×24	GBN	24	3×3	1
104×104×24	52×52×40	GBN	40	5×5	2
52×52×40	52×52×40	GBN	40	5×5	1
52×52×40	26×26×80	GBN	80	3×3	2
26×26×80	26×26×80	GBN	80	3×3	1
26×26×80	26×26×80	GBN	80	3×3	1
26×26×80	26×26×80	GBN	80	3×3	1
26×26×80	26×26×112	GBN	112	3×3	1
26×26×112	26×26×112	GBN	112	3×3	1
26×26×112	13×13×160	GBN	160	5×5	2
13×13×160	13×13×160	GBN	160	5×5	1
13×13×160	13×13×160	GBN	160	5×5	1
13×13×160	13×13×160	GBN	160	5×5	1
13×13×160	13×13×160	GBN	160	5×5	1

能够减少模型的参数量并且防止过拟合。改进后的通道注意力模块的结构见图 5, SENet 算法主要包括 Squeeze 和 Excitation 2 项操作。

对于 Squeeze 操作, 首先对接收到的特征图进行全局平均池化, 把 $H \times W$ 的输入特征图转化为 1×1 的特征图, 见式 (5)。

$$S_c = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W X_c(i, j) \quad (5)$$

式中: X_c 为输入特征图; H 和 W 分别为特征图的长和宽。

Excitation 阶段为减少模块的参数计算量, 利用 2 次 1×1 卷积, 第 1 次卷积的通道数较少, 第 2 次卷积的通道数和输入特征层通道数一样。为了满足模型对

各个整体特性之间的非线性关系进行学习, 在 2 个卷积层结构之间采用 ReLU 激活函数。使用 Sigmoid 激活函数把输出的特征图的值固定在 (0, 1), 代表输入特征层每一个通道对应的权值 W_c , 将前面学习到的权重系数乘以对应通道所有元素, 获得输出的特征图 Y_c 为:

$$Y_c = X_c W_c \quad (6)$$

2.3 Anchors 优化

针对 YOLOv4 目标检测算法采用了预先设定的先验锚框参数, 该方法只适合 COCO、VOC 等开放环境下的数据, 而文中的焊接件表面缺陷数据集与这些检测目标有很大的不同, 更何况不同的特征层适合不同大小的先验框, 因此 YOLOv4 算法原有的 anchors 不适用于文中数据集。若使用原有的先验锚框参数进行训练, 不仅模型的收敛速度缓慢, 而且最终检测效果也不理想。

由于 K-means 算法的聚类中心需要提前指定好, 这一点对数据是有局限的; 其次, 若不能正确地选取簇中心, 就会严重影响到聚类结果。在对聚类中心进行初始化的基础上, K-means++ 算法的中心思想是尽量保持簇中心的距离越远越好, 与 K-means 聚类算法相比, 它采用了一种简单、高效的方法来优化 K-means 算法的随机初始点, 即随机抽取一个样本作为当前的初始聚类中心, 再通过计算各采样点与最近一个簇中心的距离, 并将其归类到最接近的聚类中心相对应的类别中。同时对各采样点的设定进行了概率分析, 并选取了最大概率值的采样点作为下一个簇中心, 其概率计算式为:

$$p = \frac{D(x)^2}{\sum_{i=1}^n D(x_i)^2} \quad (7)$$

式中: $D(x)$ 为每个采样点与当前中心之间的最小距离, 每次指定一个目标, 然后按照已存在的聚类目标再进行一次计算, 重复此过程直到没有目标被重新分配到其他聚类中, 最后 K 个聚类中心被筛选出来。文中通过 K-means++ 聚类算法对焊接件表面缺陷数据集中的 4 种标注框的宽高维度进行聚类, 聚类中

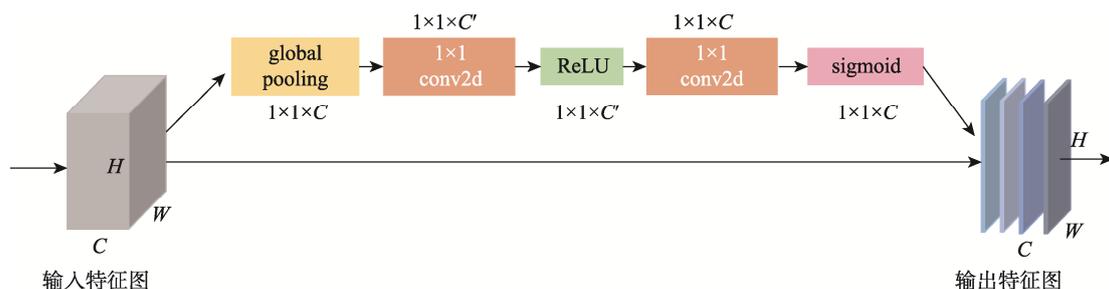


图 5 改进的通道注意力机制
Fig.5 Improved channel attention mechanism

心的个数为9。针对文中数据集, K-means++聚类出的先验锚框宽和高分别为(7, 22)、(20, 21)、(36, 99)、(37, 200)、(77, 171)、(85, 349)、(89, 15)、(205, 16)、(406, 15)等。通过 K-means++聚类算法获取的9个先验框比 YOLOv4 默认的先验框之间差异性更大, 因此在使用上述 anchors 的网络训练时收敛速度更快, 并且缺陷定位和缺陷分类效果更好。

3 实验及结果分析

3.1 数据增强

文中数据集来自 AI Studio 网络平台上公开的焊接件表面缺陷数据集, 过滤掉其中样本太少的缺陷种类后, 选择了包括冲孔、水斑、月牙弯和焊缝等4类, 图像分辨率为2048×1000, 图像格式为jpg, 缺陷图片一共为875张。在数据预处理时, 使用标注工具 LabelImg 对焊接件表面缺陷数据集进行标记, 由于样本数量太小会造成训练过拟合, 从而导致模型的鲁棒性差且泛化性能低, 因此, 文中通过翻转、随机变形缩放和颜色变化等操作增强原始数据, 见图6。通过数据增强, 总样本数目达到4375张, 不仅增加了图片的多样性, 而且易于增强模型的鲁棒性, 并获得更好的实验效果。

3.2 实验平台与参数设定

文中算法的集成开发环境为 PyCharm, 使用 Keras2.1.5 Tensorflow1.13.1-GPU 版本框架实现; 操作系统为 Ubuntu 20.04.1; 硬件为 Intel(R) Core(TM) i7-6900K 型号 CPU, GeForce GTX 1080 8G 型号 GPU。

实验过程中设置输入特征图片格式为 jpg, 无需固定大小, 在训练之前会自动进行 resize, 且灰度图会自动转成 RGB 图片, 标签为 xml 格式。在训练前将训练集、验证集、测试集以 8:1:1 的比例随机划分。在训练阶段采用自适应学习率算法 Adam, 动量项 (Momentum) 设置为 0.937, 学习率下降方式采用

余弦退火 (Cosine Annealing), 初始学习率设置为 0.001。模型的训练过程分为冻结阶段和解冻阶段。冻结阶段模型的主干被冻结了, 特征提取网络不发生改变, 此时 epoch 设置为 50, batch_size 为 16, 单个 epoch 的迭代次数为 221; 解冻阶段采用全网络训练, 特征提取网络会发生改变, 此时 epoch 设置为 50, batch_size 为 8, 单个 epoch 的迭代次数为 442。文中模型训练的损失曲线见图7, 总共训练 100 个 epoch, 焊接件表面缺陷检测模型总的损失在前 10 个 epoch 下降速度很快, 而在 10~20 个 epoch 时下降趋势减缓, 当训练至 50 个 epoch 之后基本趋于稳定, 表明模型已经达到了收敛效果。

3.3 实验评估指标

文中的焊接件表面缺陷检测算法使用 mAP, 精确率 (Precision, P) 和召回率 (Recall, R) 作为评估指标, 单类别平均精度 (P_{ap}) 为 P - R 曲线与坐标轴围成的面积, P_{map} 是所有类别平均精度^[20], 计算式见式 (8) — (11)。

精确率:

$$P = \frac{T_p}{T_p + F_p} \quad (8)$$

召回率:

$$R = \frac{T_p}{T_p + F_n} \quad (9)$$

单类别平均精度:

$$P_{ap} = \int_0^1 P(R) dR \quad (10)$$

平均精度:

$$P_{map} = \frac{\sum P_{ap}}{n} \quad (11)$$

式中: T_p 模型预测正确的正样本数量; F_p 为模型预测错误的负样本数量; F_n 为模型预测错误的正样本数量; n 为检测类别。

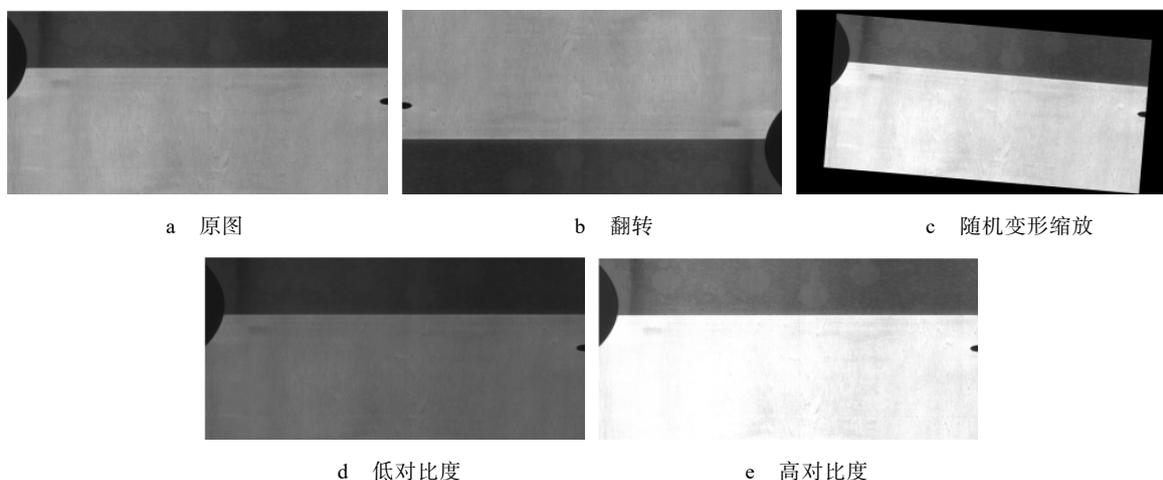


图6 数据增强示例

Fig.6 Example of data augmentation

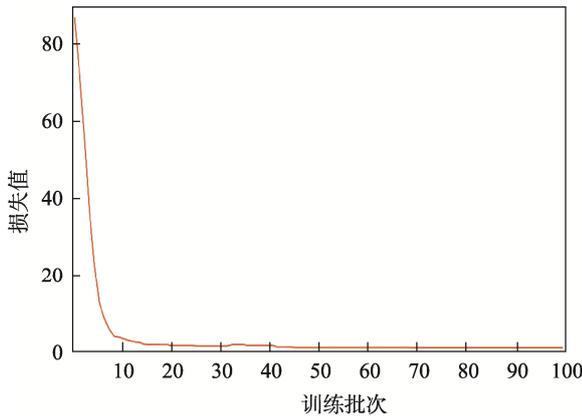


图 7 模型总损失曲线
Fig.7 Total loss curve of model

3.4 实验结果分析

如前文所述, YOLOv4 网络对处理器的性能要求更加严格, 对于同一输入特征图, GhostNet 残差结构在参数量和计算量上都比 YOLOv4 的 Backbone 结构更低。由于存储和计算资源的限制, 所以文中模型采用轻量级网络 GhostNet 来替代 YOLOv4 的 Backbone 结构进行特征提取, 能够将模型部署在计算资源少的设备上。为进一步减少模型的参数量, 且保持网络的表征能力, 文中将通道注意力机制 SENet 结构中的全连接层替换为卷积层, 并将其嵌入到主干特征提取网络中。原始 YOLOv4 的 anchor 值属于开放场景数据集的 anchor 设定, 并不适用文中的焊接件数据集, 因此文中引入 K-means++ 聚类算法对训练前的锚框设定进行优化, 在提升模型精度的同时, 能够加快推理速度。

为验证文中基于改进 YOLOv4 算法的有效性, 在相同训练集和测试集样本上对文中研究算法与各改进内容进行消融实验, 消融实验结果见表 2, 其中, Y 代表 YOLOv4 模型, G 代表 GhostNet 模型, K 代表 K-means++ 算法。从表 2 中可以看出, 在 YOLOv4 算法基础上, 引入 GhostNet 残差结构作为特征提取网络, mAP 值提升了 0.95%, 表明由 GhostNet 代替 CSPDarknet53 能够提升模型的特征提取能力。将 YOLOv4 默认 anchor 设置改成 K-means++ 算法定制的先验锚框, 平均精度值提升了 0.96%, 表明应用 K-means++ 聚类算法设定的 anchors 更加适用文中数据集, 同时加入 GhostNet 和 K-means++ 算法, 平均精度有 2.83% 的提升。文中算法在前面的各项改进基础上添加 SE 注意力模块后, 不仅平均精度提升了 4.61%, 召回率也明显提高, 说明 SENet 能够使模型利用特征的能力更强。综合上述结果, 表明该研究对原 YOLOv4 算法提出的任一改进均能提升模型的检测精度。

表 2 消融实验对比结果
Tab.2 Comparison of ablation results

对比内容	平均精度/%	精确率/%	召回率/%
Y	86.46	94.15	72.84
Y_G	87.41	94.83	73.64
Y_K	87.42	93.99	74.35
Y_G_K	89.29	95.33	78.13
文中算法	91.07	95.34	80.24

为验证文中改进 YOLOv4-GhostNet 模型的优越性, 在相同训练集样本上充分训练 YOLOv4、YOLOv4-Tiny、Faster-RCNN (主干网络为 VGG), 将它们作为对比实验, 对比训练检测精度见图 8, 横坐标为缺陷种类, 纵坐标为单类别精度。由图 8 可知, 改进的 YOLOv4-GhostNet 算法在单类别缺陷检测的精度上比其他对比算法都略高, 其中, YOLOv4-Tiny 和 Faster-RCNN 对冲孔、焊缝、月牙弯和水斑等 4 类缺陷的检测性能都较差, YOLOv4 算法在冲孔和焊缝等较为明显的缺陷特征检测性能较好, 但仍低于文中改进的 YOLOv4-GhostNet 算法。由于水斑与样本灰色背景差距较小, 检测过程中受到的干扰因素较多, 但改进的 YOLOv4-GhostNet 算法平均精度达到了 84.16%, 比 YOLOv4、YOLOv4-Tiny 和 Faster-RCNN 平均精度分别提高了 8.45%、9.52% 和 21.64%。

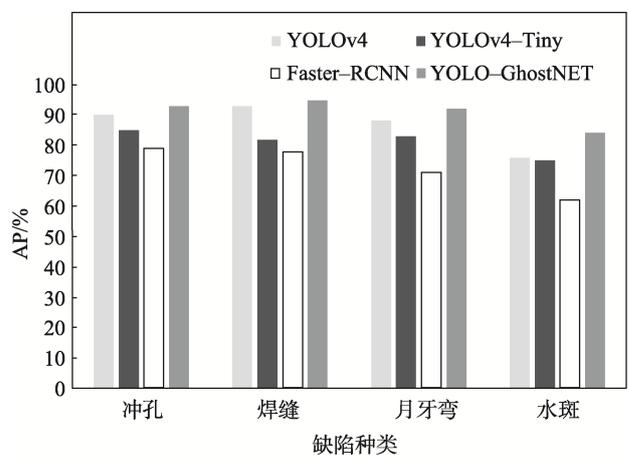


图 8 缺陷检测精度对比
Fig. 8 Comparison of defect detection precision

改进 YOLOv4-GhostNet 算法与 Faster R-CNN、YOLOv4-Tiny 和 YOLOv4 算法的各项性能对比见表 3。对于焊接件表面缺陷检测的平均精度, 文中模型比 Faster-RCNN、YOLOv4-Tiny 和 YOLOv4 分别提高了 18.07%、9.8% 和 4.61%; 文中模型在精确率和召回率上的表现最优; 文中模型检测速度为 48.11 帧/s, 仅次于 YOLOv4-Tiny, 模型尺寸文中模型比 YOLOv4-Tiny 增大了 20.5 MB, 但是比 Faster-RCNN 和 YOLOv4 分别减小了 477.8 MB 和 201.8 MB。

利用训练好的网络来检测焊接件缺陷图像,月牙弯检测效果见图 9,焊缝和冲孔检测效果见图 10,水斑检测效果见图 11。从各图 9—11 中可以看出文中改进的 YOLOv4-GhostNet 算法在每类缺陷

上的置信度均高于 90%,与其他算法相比,在微小缺陷的检测效果上都有很好的提升,表明文中模型可以很好地鉴别冲孔、焊缝、月牙弯和水斑等缺陷类别。

表 3 各网络模型性能对比
Tab.3 Performance comparison of each network model

网络模型	平均精度/%	精确率/%	召回率/%	检测速度/(帧·s ⁻¹)	模型尺寸/MB
Faster-RCNN	73.00	90.65	53.32	10.66	521
YOLOv4-Tiny	81.27	90.17	75.58	123.19	22.7
YOLOv4	86.46	94.15	72.84	21.52	245
文中模型	91.07	95.34	80.24	48.11	43.2

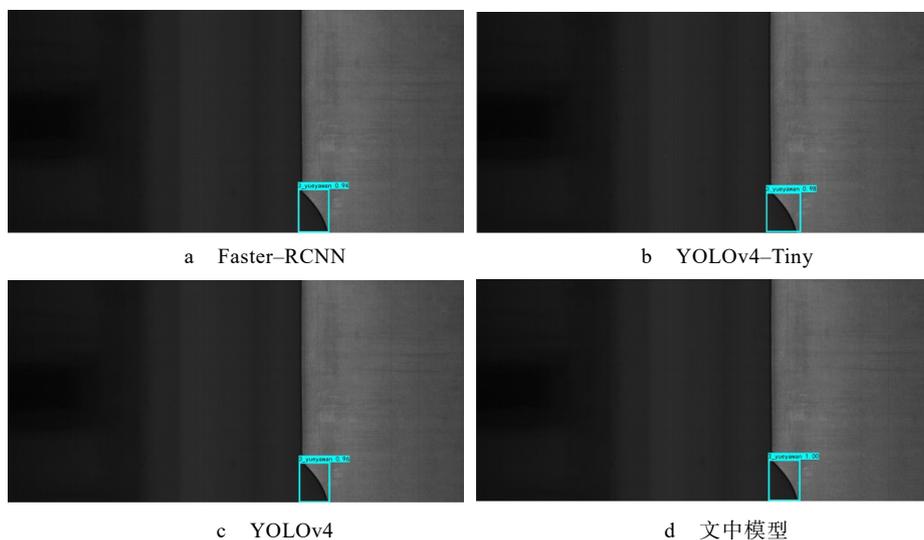


图 9 月牙弯检测效果对比
Fig.9 Comparison of crescent bend detection effect

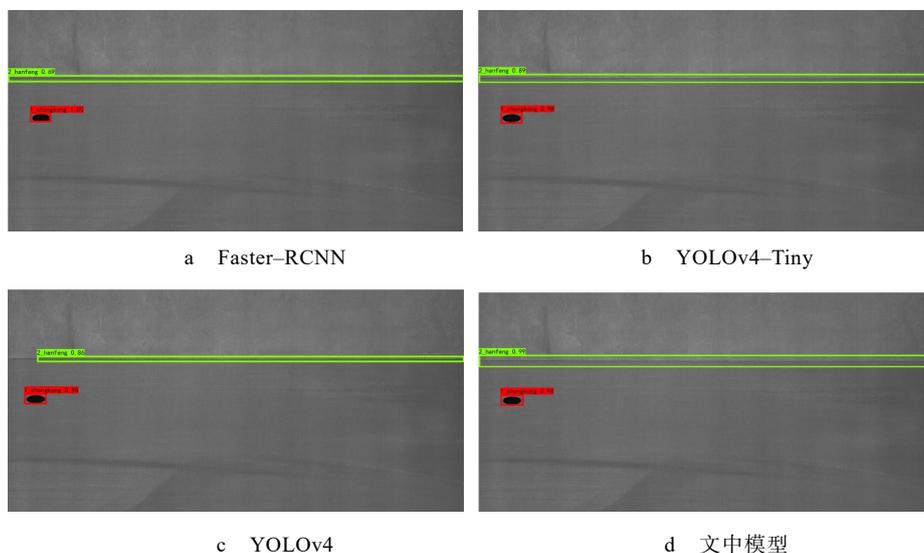


图 10 焊缝和冲孔检测效果对比
Fig.10 Comparison of weld and punch detection effect

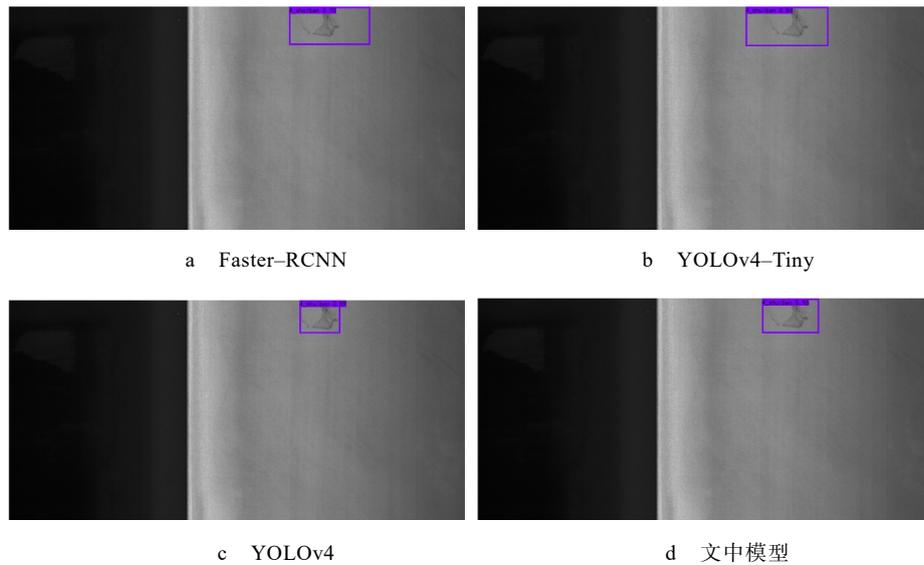


图 11 水斑检测效果对比
Fig.11 Comparison of water spot detection effect

4 结语

文中提出了一种基于改进 YOLOv4 的焊接件表面缺陷检测方法, 采用 GhostNet 轻量级网络替换 YOLOv4 的主干特征提取网络, 能够在提升检测精度的同时有效减小模型尺寸; 通过改进 GhostNet 原有的 SENet 注意力机制, 能够减少模型训练过程中的参数量, 而且避免了灰度背景的干扰; 使用 K-means++ 算法对焊接件表面缺陷数据集进行聚类分析, 得到合适宽和高的先验框, 提高了模型的检测精度, 并且加快训练的收敛速度。实验表明, 改进后的 YOLOv4-GhostNet 模型比 YOLOv4 模型平均精度提升了 4.61%, 模型大小缩减了 82.37%, 检测速度提高了 26.59 帧/s。与主流的目标检测算法相比, 文中模型在减小模型大小的同时提升了精度和检测效率, 为实际工业场景下焊接件表面缺陷检测提供了新思路。下一步将收集更多其他类别的焊接件缺陷(如压痕、丝斑等), 通过数据预处理和数据增强进行模型的训练与优化, 以提高模型的泛化能力, 将对实际工业中的焊接件生产具有一定的实际意义。

参考文献:

- [1] 陶显, 侯伟, 徐德. 基于深度学习的表面缺陷检测方法综述[J]. 自动化学报, 2021, 47(5): 1017-1034.
TAO Xian, HOU Wei, XU De. A Survey of Surface Defect Detection Methods Based on Deep Learning[J]. Acta Automatica Sinica, 2021, 47(5): 1017-1034.
- [2] KONOVALENKO I, MARUSCHAK P, BREZINOVÁ J, et al. Steel Surface Defect Classification Using Deep Residual Neural Network[J]. Metals, 2020, 10(6): 846.
- [3] 李少波, 杨静, 王铮, 等. 缺陷检测技术的发展与应用研究综述[J]. 自动化学报, 2020, 46(11): 2319-2336.
LI Shao-bo, YANG Jing, WANG Zheng, et al. Review of Development and Application of Defect Detection Technology[J]. Acta Automatica Sinica, 2020, 46(11): 2319-2336.
- [4] REN S, HE K, 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.
- [5] LIU WEI, ANGUELOV D, ERHAN D, et al. SSD: Single Shot MultiBox Detector[C]// European Conference on Computer Vision, Springer, Cham, 2016: 21-37.
- [6] REDMON J, DIVVALA S, GIRSHICK R, et al. You only Look Once: Unified, Real-Time Object Detection[J]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [7] REDMON J, FARHADI A. YOLO9000: Better, Faster, Stronger[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 7263-7271.
- [8] REDMON J, FARHADI A. YOLOv3: An Incremental Improvement[EB/OL]. (2018-04-08)[2021-07-18]. <https://arxiv.org/1804.02767>.
- [9] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal Speed and Accuracy of Object Detection[EB/OL]. (2020-04-23)[2021-07-18]. <https://arxiv.org/abs/2004.10934>
- [10] HE Yu, SONG Ke-chen, MENG Qing-gang, et al. An End-to-End Steel Surface Defect Detection Approach-

- via Fusing Multiple Hierarchical Features[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69: 1493-1504.
- [11] 程婧怡, 段先华, 朱伟. 改进 YOLOv3 的金属表面缺陷检测研究[J]. 计算机工程与应用, 2021, 57(19): 252-258.
CHENG Jing-yi, DUAN Xian-hua, ZHU Wei. Research on Metal Surface Defect Detection by Improved YOLOv3[J]. Computer Engineering and Applications, 2021, 57(19): 252-258.
- [12] 王淑青, 顿伟超, 黄剑锋, 等. 基于 YOLOv5 的瓷砖表面缺陷检测[J/OL]. 包装工程: 1-10[2022-04-16]. <http://h-s.kns.cnki.net/forest.vpn358.com/kcms/detail/50.1094.TB.20220218.1422.010.html>
WANG Shu-qing, DUN Wei-chao, HUANG Jian-feng, et al. Ceramic Tile Surface Defect Detection Based on YOLOv5[J/OL]. Packaging Engineering: 1-10[2022-04-16]. <http://h-s.kns.cnki.net/forest.vpn358.com/kcms/detail/50.1094.TB.20220218.1422.010.html>
- [13] HAN K, WANG Y, TIAN Q, et al. GhostNet: More Features from Cheap Operations[J]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2020, Issue: 1577-1586.
- [14] HU J, SHEN L, SUN G. Squeeze-and-Excitation Networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [15] ARTHUR D, VASSILVITSKII S. K-Means++: The Advantages of Careful Seeding [C]// Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms, New Orleans, Louisiana, USA, 2007.
- [16] 董豪, 李少波, 杨静, 等. 基于 YOLOv4 算法的药用空心胶囊表面缺陷检测方法[J]. 包装工程, 2022, 43(7): 254-261.
DONG Hao, LI Shao-bo, YANG Jing, et al. Surface Defect Detection Method for Pharmaceutical Hollow Capsules Based on YOLOv4 Algorithm[J]. Packaging Engineering, 2022, 43(7): 254-261.
- [17] 曹远杰, 高瑜翔. 基于 GhostNet 残差结构的轻量化饮料识别网络[J]. 计算机工程, 2022, 48(3): 310-314.
CAO Yuan-jie, GAO Yu-xiang. Lightweight Beverage Recognition Network Based on GhostNet Residual Structure[J]. Computer Engineering, 2022, 48(3): 310-314.
- [18] 李文婧, 徐国伟, 孔维刚, 等. 基于改进 YOLOv4 的植物叶茎交点目标检测研究[J]. 计算机工程与应用, 2022, 58(4): 221-228.
LI Wen-jing, XU Guo-wei, KONG Wei-gang, et al. Research on Target Detection of Plant Leaf-Stem Intersection Based on Improved YOLOv4[J]. Computer Engineering and Applications, 2022, 58(4): 221-228.
- [19] 丛明, 卢长奇, 刘冬, 等. 基于 Refine-ACTDD 的铸件外观微小缺陷检测方法[J/OL]. 计算机集成制造系统: 1-19[2022-04-17]. <http://h-s.kns.cnki.net/forest.vpn358.com/kcms/detail/11.5946.TP.20220120.1725.003.html>.
CONG Ming, LU Chang-qi, LIU Dong, et al. Detection Method for Tiny Defects in Casting Appearance Based on Refine-ACTDD[J/OL]. Computer Integrated Manufacturing Systems: 1-19[2022-04-17]. <http://h-s.kns.cnki.net/forest.vpn358.com/kcms/detail/11.5946.TP.20220120.1725.003.html>.
- [20] 东辉, 陈鑫凯, 孙浩, 等. 基于改进 YOLOv4 和图像处理的蔬菜田杂草检测[J/OL]. 图学学报: 1-12[2022-03-28]. <http://h-s.kns.cnki.net/forest.vpn358.com/kcms/detail/10.1034.T.20220303.1948.006.html>.
DONG Hui, CHEN Xin-kai, SUN Hao, et al. Weed Detection in Vegetable Field Based on Improved YOLOv4 and Image Processing[J/OL]. Journal of Graphics: 1-12[2022-03-28]. <http://h-s.kns.cnki.net/forest.vpn358.com/kcms/detail/10.1034.T.20220303.1948.006.html>.

责任编辑: 曾钰婵