基于改进 YOLOv5s 的腌制蔬菜真空包装缺陷检测

叶宇星¹, 孙志锋^{1,2}, 马风力^{1,2}, 陆玲霞¹, 黄颖²

(1.浙江大学 电气工程学院, 杭州 310007; 2.杭州力超智能科技有限公司, 杭州 310014)

摘要:目的 针对传统的基于人工的腌制蔬菜真空缺陷包装剔除效率低、漏检率高等问题,提出一种基于改进 YOLOv5s 的腌制蔬菜真空包装缺陷检测方法。方法 首先,使用 Ghost 卷积替换 CSP 模块中的 卷积,在提高模型特征提取能力的同时降低网络的参数量;其次,利用空间换深度(Space-to-Depth, SPD) 和深度可分离卷积(Depthwise-Separable Convolution, DSConv)组合操作 SPD-DSConv 进行下采样,减 少下采样造成的特征信息损耗;最后,在网络中引入 SE 注意力机制,提高算法的精确率。结果 在自制的腌制蔬菜真空包装数据集上,改进后的网络平均精度(man Average Precision, A_{mAP})为 93.88%,模型 尺寸为 3.91 MB,相比原网络精度提高了 2.05%,模型尺寸缩减了 44.38%。结论 文中方法能够实现腌制蔬菜真空缺陷包装的分类和定位,为基于机器人的缺陷包装剔除奠定了基础。

关键词: 食品真空包装; YOLOv5s; 缺陷检测

中图分类号: TP391.4 文献标识码: A 文章编号: 1001-3563(2023)09-0045-09 DOI: 10.19554/j.cnki.1001-3563.2023.09.006

Vacuum Packaging Defect Detection of Pickled Vegetables Based on Improved YOLOv5s

YE Yu-xing¹, SUN Zhi-feng^{1,2}, MA Feng-li^{1,2}, LU Ling-xia¹, HUANG Ying²

College of Electrical Engineering, Zhejiang University, Hangzhou 310007, China;
 Hangzhou Lichao Intelligent Technology Co., Ltd., Hangzhou 310014, China)

ABSTRACT: The work aims to propose a vacuum packaging defect detection method for pickled vegetables based on YOLOv5s network to solve the low efficiency and high leakage rate of manual-based vacuum defect packaging rejection of pickled vegetables. Firstly, Ghost Convolution was used to replace the convolution in the CSP module, which reduced the number of parameters in the network while improving the feature extraction capability of the model; Secondly, in order to reduce the loss of feature information in down sampling, the space-to-depth (SPD) and depthwise-separable convolution (DSConv) were used in down sampling; Finally, the SE attention mechanism module was introduced in the network to improve the accuracy of the algorithm. On the dataset of homemade pickled vegetable packaging, the mean average precision (A_{mAP}) of the improved network reached 93.88 and the model size reached 3.91 MB. Compared with the original model, the mAP was increased by 2.05% and the model was reduced by 44.38%. The method in the paper enables the classification and localization of the defective vacuum packages of pickled vegetables, and lays a foundation for robot-based defective package rejection.

KEY WORDS: food vacuum packaging; YOLOv5s; defect detection

收稿日期: 2023-02-24

基金项目:宁波市现代农业专项(2022Z176);国家重点研发计划项目(2016YFD0400405)

作者简介:叶宇星(1998—),男,硕士生,主攻计算机视觉。

通信作者:孙志锋(1963—),男,硕士,副教授,主要研究方向为微电网技术,人工智能等。

传统腌制蔬菜作为老百姓餐桌的风味佳肴历史 悠久,其生产环节包括:腌制、发酵、起池、剪筋、 切丝、漂淡、脱水、拌料、小包装罐装、包装封口、 巴氏灭菌、产品检验。目前传统腌制蔬菜的真空包装 通过罐装机实现了一体化的自动上袋、称量加料、封 口、抽真空的包装流程,但是对缺陷包装的检测和剔 除主要还是依赖于人工。

根据罐装机的加工流程,可以将具有缺陷的腌制 蔬菜包装分为以下2类:由封口不完全造成的漏包; 由自动上袋开口失败或称量加料失误造成的次包。受 限于人眼的视觉敏锐度,基于人工的缺陷包装检测存 在效率低、漏检率高等问题。

随着计算机技术的进步,机器视觉在食品包装 缺陷检测上的应用也越发的广泛。食品包装材料具 有多样性,常见的包装材料有塑料、金属、玻璃、 纸质等[1],其对应的缺陷类型也存在差异,但在检 测方法上有一定的共通性。马志刚等^[2]结合中值滤 波、Canny 算子等图像预处理和图像匹配的方法, 搭建了机器视觉系统,实现了对条烟外包装的缺陷 检测; Xiong 等^[3]提出了基于水平集映射(LSM)的 方法,利用图像灰度值表示包装轮廓和缺陷位置信 息,实现了对饼干缺陷包装的检测;Gao 等^[4]选取梯 度直方图 (Histogram of Oriented Gradient, HOG)特 征作为图像的识别特征,并基于支持向量机(Support Vector Machine, SVM)对特征进行分类,实现了对 不同表面缺陷程度的红酒包装检测; Bin-roslan 等^[5] 将单阶段目标检测网络 YOLOv5 应用于塑料包装缺 陷检测中,实现了高精度的塑料包装表面缺陷的实 时检测。

相较于基于人工的包装缺陷检测,上述机器学习 算法可以实现对特定包装缺陷的精确检测。腌制蔬菜 的真空包装缺陷差异性较小,且其在传送带上运输的 速度较快,目前针对食品包装检测的传统机器学习算 法难以实现对其快速检测与精确定位。针对以上问 题,文中提出一种基于改进 YOLOv5s 的腌制蔬菜真 空包装缺陷检测方法,在提高缺陷包装检测精度的同 时缩小模型的尺寸。首先,在 CPS 模块中引入 Ghost 卷积,在提高模型特征提取能力的同时降低网络的参 数量;其次,利用空间换深度(Space-to-Depth, SPD) 和深度可分离卷积(Depthwise-Separable Convolution, DSConv)的组合操作 SPD–DSConv 进行下采样,减 少下采样过程中特征信息的损耗;最后,引入 SE 注 意力机制,提高算法的精确率。

1 YOLOv5s 模型

YOLO (You Only Look Once)系列在单阶段目标检测网络中占据了重要地位,可以快速准确地得到物体的类别和位置信息^[6]。YOLOv5 模型是 Ultralytics

团队于 2020 年 6 月提出的具有更优检测精度和速度 的 YOLO 系列模型^[7]。本文采用的 YOLOv5s 模型由 YOLOv5 按照一定比例缩小网络宽度和深度得到,兼 顾了精度和速度上的要求。YOLOv5 网络结构如图 1 所示。

YOLOv5 网络结构包括输入端(Input)、主干特征提取网络(Backbone)、特征融合颈部(Neck)和输出预测端(Head)^[8]。

Input 部分对图像进行数据增强操作,包括 Mosai 增强方法,旋转、平移、缩放、错切等仿射 变换方法以及 HSV 色彩空间增强方法。在训练时, 对输入图像以一定概率进行以上数据增强方法,可 以丰富数据集样本,使得训练的模型具有更好的鲁 棒性^[9]。

Backbone 部分包括 CBS 模块、CSP 模块^[10]和 SPPF 模块。CBS 模块为常规的卷积、批标准化(Batch Normalization, BN)和 SiLU 激活函数,主要负责下 采样工作,Backbone 的第1个 CBS 模块的卷积核大 小为 6×6,输入图像分辨率较大,采用大卷积核可 以更好地获取全局特征^[11],其余 CBS 模块的卷积核 大小均为 3×3。CSP 模块主要负责特征的提取,通 过跨阶段结构将不同层次的特征信息进行融合,减 少梯度信息的重复。SPPF 模块是空间池化金字塔 (Spatial Pyramid Pooling, SPP)^[12]模块的改良版, 将输入特征依次经过 3次 5×5 的最大池化操作,保 留了 SPP 模块可以有效减少重复特征的提取优点并 减少了计算成本。

Neck 部分包含特征金字塔(Feature Pyramid Networks, FPN)^[13]和感知对抗网络(Perceptual Adversarial Networks, PAN)^[14]。首先通过上采样方式融合自下而上的特征信息,再通过下采样方式将特征信息作进一步提取,实现了多层次信息的交互。

Head 部分主要完成对物体类别信息和特征信息的预测。在训练过程中通过 GIOU^[15]损失函数对模型 参数进行修正,在预测过程中通过非极大值抑制 (Non-Maximum Supression, NMS)对预测的不同类 别的物体的坐标信息进行校正和筛选。

2 改进 YOLOv5s 模型

改进的 YOLOv5s 网络结构如图 2 所示。在网络 Backbone 和 Neck 部分的 CSP 模块中引入 Ghost 卷积, 替换其中的普通卷积,在提高模型特征提取能力的同 时降低网络的参数量。将 Backbone 和 Neck 部分中的 下采样卷积用 SPD-DSConv 代替,减少下采样过程 中特征信息的损耗并使得网络更加轻量化,但保留 Backbone 中 6×6 的卷积,使网络可以更好地融合输 入图像的局部特征。在 Backbone 中引入一个 SE 模块, 增加模型的特征提取能力。



图 1 YOLOv5 网络结构 Fig.1 YOLOv5 network structure



图 2 改进 YOLOv5s 网络结构 Fig.2 Improved YOLOv5s network structure

2.1 Ghost 卷积

腌制蔬菜完成罐装后,需要在传送带上运输到下 一杀菌环节,实现运输过程中缺陷包装的实时精确检 测,对进一步实现基于机器人的缺陷包装剔除有重要 意义。YOLOv5s 网络相较于 YOLOv5 网络,在深度 上已经进行了极大的压缩,但要实现传送带上包装的 不间断检测对网络的轻量化有更进一步的要求。

Ghost 卷积利用普通卷积生成的特征图中具有冗

余性的特征,采用低成本的线性变换方式在普通卷积 生成的特征图基础上得到新的特征图^[16]。在保持模型 特征提取能力的同时减少网络的参数量。

Ghost 卷积的过程如图 3 所示。假设输入的特征 图大小为 W×H×C,经过普通卷积后生成不含冗余的 W×H×(C/2)的中间特征图;再以廉价的线性操作即分 组卷积,使中间特征图的每个通道形成冗余特征图; 最后将冗余特征图和中间特征图在通道上进行拼接, 生成完整的 W×H×C 的特征图。假设使用的普通卷积 和分组卷积的卷积核大小均为 *K*×*K*,则 Ghost 卷积中 常规卷积的参数量见式(1)。

$$G_{C_{\text{params}}} = K \times K \times C \times (C/2)$$
(1)

分组卷积的参数量见式(2)。

$$G_{cc} = K \times K \times (C/2)$$
 (2)

$$G_{\text{params}} = G_{\text{C}_{\text{params}}} + G_{\text{GC}_{\text{params}}} =$$
(3)

$$K \times K \times C \times (C/2) + K \times K \times (C/2)$$

当完全由传统卷积获得 W×H×C 输出特征图时, 卷积的参数量见式(4)。

$$C_{\text{params}} = K \times K \times C \times C \tag{4}$$

对比式(3)和式(4),可以发现 Ghost 卷积的 参数量大约为普通卷积的 1/2。CSP 模块负责网络的 特征提取,包含整个网络的大部分参数,将 Ghost 卷 积替换 CSP 模块中的普通卷积可以有效降低网络的 参数量。



Fig.3 Ghost convolution

2.2 SPD-DSConv

腌制蔬菜包装采用真空包装的形式,在罐装机 刚完成抽真空后,漏包和正常包装的差异性较小, 封口不严引起的缺陷在一开始仅表现为封口处的细 小差异,在杀菌等后续环节完成后才会逐渐引起包 装整体的漏气,放大缺陷差异,要实现对罐装之后 缺陷包装的剔除,需要实现对封口处细小差异特征 的准确提取。

在常见的目标检测网络模型中,多用步长为2的 卷积进行下采样,而对分辨率较小的特征来说,这种 下采样方式会导致特征图细粒度信息的丢失^[17]。

SPD 具体方法如图 4 所示。采用空间换深度的操作,利用切片组合的方式将图像进行下采样,再通过卷积将通道维度信息进行融合,可以减少下采样过程中细粒度信息的丢失。

DSConv 方法如图 5 所示。其包括逐通道卷积和 逐点卷积,首先利用逐通道卷积对输入特征图每个通 道进行分组卷积,生成中间特征图,再对中间特征图 进行逐点卷积,采用卷积核大小为 1×1,步长为 1 的 普通卷积得到最终的特征图。假设输入和输出特征图 大小为 W×H×C,卷积核大小为 K×K,则普通卷积操 作所需参数量见式(5)。

$C_{\text{params}} = K \times K \times C \times C$	(5)
深度可分离卷积操作所需参数量见图(6)。	
$D_{\text{params}} = K \times K \times 1 \times C + 1 \times 1 \times C \times C$	(6)

综合式(5)和式(6),对通道数较多的特征来 说,DSConv可以大幅减少卷积所需的参数量。SPD 虽然有利于特征信息的融合,但会带来通道维度翻 倍,对于普通的卷积来说,其参数量也会成倍增长, 因此在 SPD 操作后利用 DSConv 来对通道维度信息 进行融合,可以大幅度减少所需的参数量。



图 5 深度可分离卷积 Fig.5 Depthwise-separable convolution

2.3 SE 注意力机制

腌制蔬菜包装在传送带上的姿态并非规则整齐 的,会出现不同的形态,甚至不同的包装之间会出现 不同程度的堆叠导致缺陷特征被部分遮挡,因此需要 对网络的特征提取能力作进一步的增强。

SE 模块是一种通道注意力, 它对输入特征图进 行通道特征加强,而不改变特征图的大小^[18]。本文将 SE 模块放在 Backbone 的末尾,加强整体的通道特征, 使后续的 Neck 部分能更好地对重要特征进行融合, 提高模型性能。SE模块的结构如图 6 所示,其结构 包含压缩、通道特征学习和激励。假设输入特征图的 大小为 W×H×C, 压缩部分通过全局池化平均在空间 维度上将输入特征图压缩成 1×1×C 的特征图;通道 特征学习部分首先利用卷积核大小为 1×1、步长为 1 的卷积和 SiLU 激活函数得到 1×1×(C/r)的特征图,其 中 r 为通道缩放因子,本文采用 r=16,再通过卷积核 大小为1×1、步长为1的卷积和 Sigmoid 激活函数得 到 1×1×C 的通道权重系数;激励部分将原始输入特 征逐通道乘上通道权重系数,得到带有通道注意力的 特征图,其中不同的通道权重系数反映了该通道特征 的重要性。



图 6 SE 注意力机制 Fig.6 SE attention mechanism

3 实验结果与分析

3.1 数据集介绍

本文采用自制腌制蔬菜包装数据集,包装样本由

浙江宁波某公司提供,其中缺陷包装由生产线上6d 内人工筛选而得。根据罐装机自动包装的流程,将缺 陷样本类型分为漏包、次包,其中漏包的主要特征为 包装封口不严密,易于漏气;次包的主要特征为包装 虽然密封,但计量不准或少于设定的包装物料质量, 乃至空包。根据腌制蔬菜种类的不同,数据集中包含 榨菜丝、榨菜芯、榨菜片、腌萝卜等不同外观包装。 根据传送带上运输包装的真实情况,同一批次中包含 多个分布不均匀的包装,数据集中包含多个正常包装 和缺陷包装以不同数量和不同堆叠方式放置。根据以 上方式对包装样本进行数据采集,最后获得3374张 图片,并利用 LableImg 工具对图片中的目标进行标 注,分为正常包(Normal)、次包(Defect)和漏包 (Leakage), 其目标数量分别为 3 140、1 619、2 943。 数据集中的部分图像如图7所示,其中文本表示 该样本所属的类别。



图 7 自制腌制蔬菜包装数据集 Fig.7 Dataset of homemade pickled vegetable packaging

3.2 环境配置

实验环境为 Windows 10 操作系统,选用 Python 语言的 PyTorch 1.7 深度学习框架; CPU 处理器为 Intel(R) Core(TM) i7–10700 CPU @ 2.90GHz; GPU 为 NVIDIA GeForce RTX 3060。

训练时,将数据集中图片随机划分,最终选用 2 618 张图片作为训练集,756 张图片作为验证集, 设置 Batch_size 为 4。训练过程中,模型输入图片的 分辨率为 640×640;采用 SGD 优化器训练网络,动 量参数设置为 0.937,权重衰减系数为 0.000 5。文中 模型的学习率和损失值随迭代次数变化如图 8 所示。 模型一共训练 400 批次,学习率下降策略采用余弦 退火,初始学习率设置为 0.01,在第 300 批次时降 低至 0.001,同时在开始训练时开启热身训练,帮助 模型更好的收敛。关于热身训练的具体内容参考文 献[19]。根据损失值随迭代批次的变化可以发现在迭 代批次达到 300 时,模型在训练集上趋于收敛,因 此,在 300~400 批次时利用验证集验证模型的效果, 并保存在验证集上表现最好的模型权重,避免模型过 拟合。



Fig.8 Model learning rate and loss value change curve in the paper

3.3 评价指标

文中采用平均精度(mean Average Precision, A_{mAP})、参数量(Parameters)、浮点运算数(Floating Point Operations, FLOPs)分别评价模型的精度、空间 复杂度和时间复杂度。

A_{mAP} 是所有目标类别 A_P 的均值,可以同时评价 模型的分类和定位性能。A_P 为该目标类别在不同置信 度下准确率 P 和召回率 R 绘制曲线所围面积,公式 如下:

$$P = \frac{T_{\rm P}}{T_{\rm P} + F_{\rm P}} \tag{7}$$

$$R = \frac{T_{\rm p}}{T_{\rm p} + F_{\rm N}} \tag{8}$$

$$A_{\rm mAP} = \frac{\sum A_{\rm p}}{N} \tag{9}$$

式中: T_p 为预测为正样本且实际为正样本的样本 数量; F_p 为预测为正样本但实际为负样本的样本数 量; F_N 为预测为负样本但实际为正样本的数量; A_p 为类别精度; N 为样本类别数。

3.4 结果分析

根据实际的腌制蔬菜在传送带上运输的情况,在 不同的堆叠程度下验证本文算法的检测效果。实验结 果如图9所示,图9中的数值为对应类别的置信度。 训练好的网络可以精确地实现榨菜丝、榨菜片、榨菜 芯、萝卜干等不同腌制蔬菜包装在复杂堆叠环境下的 分类和定位。

为验证本文算法的有效性,在相同的验证集和 训练环境配置下,通过消融实验验证所添加的各个 模块效果,实验结果见表 1。 其中 YOLOv5s-G 表示 在原网络中仅加入 Ghost 卷积, YOLOv5s-SD 表示 在原网络中加入 SPD-DSConv 模块, YOLOv5s-SE 表示在原网络中加入 SE 注意力机制, YOLOv5s-G-SD 表示在原网络中同时加入 Ghost 卷积和 SPD-DSConv 模块。由表 1 可知,在 YOLOv5s 算法 基础上加入 Ghost 卷积后, A_{mAP} 提升了 2.53%, 同时 模型参数量下降了 27.03%。表明引入 Ghost 卷积后 的 CSP 模块不仅能降低网络参数量,还提高了网络 的特征提取能力。用 SPD-DSConv 替换原本的下采 样卷积后,网络在保持精度的同时还降低了网络的 参数量。同时加入 Ghost 卷积和 SPD-DSConv 模块 后,在不损失精度的条件下,模型尺寸下降了 44.81%; 在此基础上加入 SE 注意力机制, 进一步提 升了网络的特征提取能力。对比原 YOLOv5s 算法, 本文算法各类别精度均获得了提升,且对设备的算 力和内存要求较小,模型的平均精度提升了 2.05%, 尺寸下降了 44.38%。

为进一步验证本文算法的优越性,在相同的数据 集和训练环境下,将本文算法与轻量级单阶段目标检 测网络 YOLOv3-tiny、YOLOv4-tiny 进行对比实验, 结果如表 2 所示。

由表 2 可知,本文模型的各类别精度均高于 YOLOv3-tiny 和 YOLOv4-tiny 的各类别精度。相较 于 YOLOv3-tiny 和 YOLOv4-tiny,本文模型的平均 精度分别提高了 3.01%、2.70%,同时模型参数量分 别降低了 54.90%、33.50%。实验证明改进后的 YOLOv5s 网络能够实现快速精确地进行腌制蔬菜包 装的缺陷检测。



图 9 腌制蔬菜包装缺陷检测效果 Fig.9 Defect detection effects of pickled vegetable packaging

表 1 消融实验对比结果 Tab.1 Comparison results of ablation experiments

网络模型 一	各类别精度/%		亚均特亩/0/	/ 樹刊日→/MD	FI ODa 值/10 ⁹	
	Normal	Defect	Leakage	十均相度/70	候型八寸/MB	TLOFS []/10
YOLOv5s	89.52	97.45	88.52	91.83	7.03	16.0
YOLOv5s–G	91.49	98.73	92.86	94.36	5.13	11.3
YOLOv5s-SD	91.81	96.62	89.94	92.79	5.78	13.5
YOLOv5s-G-SD	90.43	95.89	89.97	92.09	3.88	8.9
YOLOv5s-SE	92.87	96.78	89.04	92.90	7.06	16.0
本文模型	92.34	97.96	91.35	93.88	3.91	8.9

表 2 各网络模型性能对比 Tab.2 Performance comparison of network models								
网络模型 -	各类别精度/%			亚切转度/0/	/ 増刑日→/MD	ELOD。 佐/10 ⁹		
	Normal	Defect	Leakage	千均相度/%	候型八引/MD	FLOPS 11/10		
YOLOv3-tiny	85.75	97.66	89.18	90.86	8.67	13.0		
YOLOv4-tiny	92.10	97.71	83.74	91.18	5.88	16.2		
本文模型	92.34	97.96	91.35	93.88	3.91	8.9		

4 结语

为解决传统基于人工腌制蔬菜真空缺陷包装剔除效率低、漏检率高的问题,文中提出了基于改进的YOLOv5s 腌制蔬菜真空包装缺陷检测方法。在网络中引入了 Ghost 卷积,在保持网络特征提取能力的同时降低网络参数量,有利于实现传送带上运输的不同批次腌制蔬菜包装的实时高效检测;引入SPD-DSConv模块进行下采样,减少下采样过程中细粒度信息的丢失,有利于对腌制蔬菜缺陷包装细小缺陷特征的提取;引入 SE 注意力机制,进一步增强了网络对腌制蔬菜缺陷包装的特征提取能力。改进后的网络能够实现高精度的实时缺陷检测,为基于自动化腌制蔬菜缺陷包装剔除系统的构建奠定基础。

参考文献:

 [1] 张红岩, 王永志, 刘庆红. 图像识别技术在食品包装 缺陷检测中的应用[J]. 食品与机械, 2020, 36(8): 225-228.

ZHANG Hong-yan, WANG Yong-zhi, LIU Qing-hong. Application of Image Recognition Technology in Food Packaging Defect Monitoring[J]. Food & Machinery, 2020, 36(8): 225-228.

- [2] 马志刚,赵志强.基于机器视觉的包装品质检测系统 设计[J].包装工程, 2022, 43(21): 193-197.
 MA Zhi-gang, ZHAO Zhi-qiang. Design of Packaging Quality Inspection System Based on Machine Vision[J].
 Packaging Engineering, 2022, 43(21): 193-197.
- [3] XIONG Kun-kun, LI Weng-sheng, DONG Shu-ai, et al. Defect Detection of Biscuit Packaging Based on Level Set Map[C]// 2022 15th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), Beijing, China, 2022: 1-7.
- [4] GAO Cong-rui. Design of Tourism Package with Paper and the Detection and Recognition of Surface Defects-Taking the Paper Package of Red Wine as an Example[J]. Journal of Intelligent Systems, 2021, 30(1): 720-727.
- [5] BIN-ROSLAN M I, IBRAHIM Z, AZIZ Z A, Real-Time

Plastic Surface Defect Detection Using Deep Learning[C]// 2022 IEEE 12th Symposium on Computer Applications & Industrial Electronics (ISCAIE), Penang, Malaysia, 2022: 111-116.

- [6] 邵延华,张铎,楚红雨,等. 基于深度学习的 YOLO 目标检测综述[J]. 电子与信息学报, 2022, 44(10): 3697-3708.
 SHAO Yan-hua, ZHANG Duo, CHU Hong-yu, et al. A Review of YOLO Object Detection Based on Deep Learning[J]. Journal of Electronics & Information Technology, 2022, 44(10): 3697-3708.
- [7] 王朕,李豪, 严冬梅,等. 基于改进 YOLOv5 的路面 病害检测模型[J]. 计算机工程, 2023, 49(2): 15-23.
 WANG Zhen, LI Hao, YAN Dong-mei, et al. Pavement Disease Detection Model Based on Improved YO-LOv5[J]. Computer Engineering, 2023, 49(2): 15-23.
- [8] HU Wen-xin, XIONG Jun-tao, LIANG Jun-hao, et al. A Method of Citrus Epidermis Defects Detection Based on an Improved YOLOv5[J]. Biosystems Engineering, 2023, 227: 19-35.
- [9] 王淑青,顿伟超,黄剑锋,等. 基于 YOLOv5 的瓷砖 表面缺陷检测[J]. 包装工程, 2022, 43(9): 217-224.
 WANG Shu-qing, DUN Wei-chao, HUANG Jian-feng, et al. Ceramic Tile Surface Defect Detection Based on YOLOv5[J]. Packaging Engineering, 2022, 43(9): 217-224.
- [10] WANG C Y, LIAO H Y M, YEH I H, et al. CSPNet: A New Backbone that can Enhance Learning Capability of CNN[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Seattle, WA, USA, 2020: 1571-1580.
- [11] DING Xiao-hong, ZHANG Xiang-yu, ZHOU Yi-zhuang, et al. Scaling up your Kernels to 31x31: Revisiting Large Kernel Design in CNNS[C]// 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), New Orleans, LA, USA, 2022: 11953-11965.
- [12] HE Kai-ming, ZHANG Xiang-yu, REN Shao-qing, et al. Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition[J]. IEEE Transactions on

Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916.

- [13] ZHANG Y, HAN J H, KWON Y W, et al. A New Architecture of Feature Pyramid Network for Object Detection[C]// 2020 IEEE 6th International Conference on Computer and Communications (ICCC), Chengdu, China, 2020: 1224-1228.
- [14] CHEN Yu-nian, WANG Yan-jie, ZHANG Yang, et, al. PANet: A Context Based Predicate Association Network for Scene Graph Generation[C]// 2019 IEEE International Conference on Multimedia and Expo (ICME), Shanghai, China, 2019: 508-513.
- [15] REZATOFIGHI H, TSOI N, GWAK J, et al. Generalized Intersection over Union: A Metric and a Loss for Bounding Box Regression[C]// 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, USA, 2019: 658-666.
- [16] HAN Kai, WANG Yun-he, TIAN QI, et al. GhostNet: More Features from Cheap Operations[C]// 2020

IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA, 2020: 1577-1586.

- [17] SUNKARA R, LUO T. No More Strided Convolutions or Pooling: A New CNN Building Block for Low-Resolution Images and Small Objects[C]// European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases (ECML PKDD), Grenoble, France, 2022.
- [18] CHEN Jia-dong, WU Yin-cheng, YANG Yin, et al. An Efficient Memristor-Based Circuit Implementation of Squeeze-and-Excitation Fully Convolutional Neural Networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(4): 1779-1790.
- [19] HE Kai-ming, ZHANG Xiang-yu, REN Shao-qing, et al. Deep Residual Learning for Image Recognition[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016: 770-778.

责任编辑:曾钰婵