

基于深度学习的水果缺陷实时检测方法

Real time detection method of fruit defects based on deep learning

周胜安¹黄耿生¹张译匀¹高东发²ZHOU Sheng-an¹ HUANG Geng-sheng¹ ZHANG Yi-yun¹ GAO Dong-fa²

(1. 广东行政职业学院人工智能学院, 广东 广州 510800;

2. 广东外贸外语大学计算机科学学院, 广东 广州 510665)

(1. Guangdong Vocational Institute of Public Administration Electronic Information System, Guangzhou, Guangdong 510800, China; 2. School of Computer Science, Guangdong University of Foreign Studies, Guangzhou, Guangdong 510665, China)

摘要:目的:对 CenterNet 方法进行优化改进。方法:使用 MobileNetV3 的轻量化卷积神经网络替代 CenterNet 原有的骨干网络,加快检测速度,对 MobileNetV3 模块进行改进,增强模型对水果中小缺陷块的检测能力,并对 CenterNet 的预检测阶段进行优化,提高其检测准确度。结果:试验方法对显著缺陷如直径 >4 mm 的苹果识别率高达 99.7%,检测速度为 113 帧/s,模型体积为 1.31 MB。结论:与 CenterNet_ResNet18 和 CenterNet_Shuffler 模型相比,MO-CenterNet 模型检测水果缺陷在训练时间、检测速度和准确率方面均衡性更好。

关键词:水果缺陷;实时检测;深度学习;卷积神经网络;轻量级

Abstract; Objective: This study aimed to optimize and improve the CenterNet method for detecting fruit defects. **Methods:** the lightweight convolutional neural network of MobileNetV3 was used to replace the original backbone network of CenterNet accelerate the detection speed, improve the module of MobileNetV3, enhance the detection ability of the model for small and medium-sized defective blocks of fruit, and optimize the pre detection stage of CenterNet to increase its detection accuracy. **Results:** The recognition rate of significant defects such as apples with diameter > 4 mm was 99.7%, and the detection speed was 113 FPS, with the model volume of 1.31 MB. **Conclusion:** Compared with models CenterNet _ Resnet18 and CenterNet _ Shuffler, model MO-CenterNet has better balance in training

基金项目:广东省普通高校特色创新类项目(编号:2019GKTSCX053);广东省普通高校青年创新人才类项目(编号:2018GkQNCX125);中国高校产学研创新基金“新一代信息技术创新项目”(编号:2020ITA03013)

作者简介:周胜安(1978—),男,广东行政职业学院副教授,硕士。E-mail:zhou_sa01@163.com

收稿日期:2021-07-15

time, detection speed and accuracy.

Keywords: fruit defect; real-time detection; deep learning; convolution neural network; lightweight

基于机器视觉自动检测具有较强的可执行性和非接触工作模式的优势^[1]。左兴健等^[2]研制了一套实用的猕猴桃自动分级设备,该设备包括单行定位输送系统、图像采集系统、分级执行系统和控制系统,通过多特征提取和融合分级的方法对猕猴桃实现了自动分级。项辉宇等^[3-4]使用基于图像处理方法对苹果的大小、颜色和缺陷进行了检测,该类方法主要是基于水果形状、边缘、纹理等普通特征来定位缺陷目标。高辉等^[5]采用自动亮度校正技术和加权矢量机相结合,进一步提高了水果缺陷检测准确率和检测速度,但该方法需要进行光照系统的配置,成本较大。薛勇等^[6]采用 GoogLeNet 深度迁移模型对苹果缺陷进行检测,获得了较好的泛化能力与鲁棒性,但该卷积网络模型复杂、参数多且检测效率低。夏雪等^[7]构建了用于苹果检测的轻量级无锚点深度学习网络模型 M-CenterNet,该方法通过改进轻量级的 MobileNetV3 网络,结合关键点预测的目标检测网络(CenterNet),为非结构环境下果园作业平台的轻量化果实目标检测模型研究提供了新的思路。但该方法适用于检测目标具有大小适中、外形和颜色较相近的特征,如场景中苹果目标的检测。

针对水果中存在复杂多样的缺陷块,为提高缺陷的检测准确度,文章拟设计一种实时的 MO-CenterNet 水果缺陷检测方法,先采用 MobileNet^[8]的高效架构代替 CenterNet 原有的 Hourglass^[9]编码解码全卷积网络,再用可形变卷积改造为深度的可形变卷积,扩大模型的感受野,增加小型缺陷块的检测目标数,并对 CenterNet 的检测头进行预测优化,通过位置阈值过滤非缺陷块预测目标,旨

在为满足农产品自动化处理系统对于轻量化水果缺陷检测模型的需求提供依据。

1 检测方法

1.1 基于深度学习的目标检测方法

基于深度学习的目标检测包括目标分类和目标定位 2 个任务。按其算法可以分为两类：① 基于 Region Proposal 的 R-CNN 系算法如 Fast R-CNN、Mask-RCNN 等的 Two-stage 算法，即先用算法产生目标候选框，即目标位置，再对候选框进行分类与回归。Two-stage detectors 对每个框重新计算图像特征并进行分类。后处理，即非极大值抑制(NMS)，通过计算锚点(Bbox)间的 IOU 来删除同个目标的重复检测框^[10-11]，Two-stage detectors 这种预测目标后处理很难区分和训练，因此现有检测器大多不是端到端可训练的。② Yolo、SSD、RetinaNet、CornerNet 和 CenterNet 这类的 One-stage 算法。One stage detectors 在图像上滑动复杂排列的可能 Bbox，然后直接对框进行分类，而不会指定框中内容^[12-16]。

如图 1(a)所示，YOLO 方法先通过卷积网络进行特征提取，生成 $S \times S$ 的 feature maps(7×7)，特征图上的每个点映射在原图上为一个方格。对于一个真实的目标框其中心点所落的网格负责预测此目标，每个 bounding box 除了要回归自身的位置(x, y, w, h)外，还要附带预测一个 confidence 值，每个网格要预测 B 个 bounding box，网络预测后的 Bbox 通过 NMS 进行过滤，得到最终的检测框。

如图 1(b)所示，CornerNet 方法的原图经过卷积网络得到 128×128 大小的输出，然后经特征提取网络 Hourglass network 提取特征，Hourglass module 后会有两个输出分支模块，分别表示左上角点预测分支和右下角点预测分支，每个分支模块经过 Corner pooling 层后输出

3 个信息：Heatmaps、Embeddings 和 Offsets。Heatmaps 用来预测角点位置信息，一个支路预测左上角，一个支路预测右下角，Embeddings 用来对预测的角点进行分组，即找到属于同一个目标的左上角角点和右下角角点，同一个预测框的一对角点的角距离最短。Offsets 用来调整角点位置，使得获得的边界框更紧密。

CenterNet 是基于 CornerNet 的改进。如图 1(c)所示，与 CornerNet 不同的是，CenterNet 预测的是目标的中心点，而不再是 CornerNet 中的 2 个角点，然后再预测目标框的宽和高来生成预测框。

与 CornerNet 一样，CenterNet 也是采用热力图(heatmap)来实现，均引入了预测点的高斯分布区域计算真实预测值，同损失函数一样。此外，CenterNet 也不包含 corner pooling 等操作，因为一般目标框的中心点落在目标上的概率比较大，因此常规的池化操作能够提取到有效的特征。

1.2 CenterNet 骨干网络

CenterNet 网络模型是通过目标中心点来呈现目标，如水果缺陷块中心，然后在中心点位置回归出缺陷块的大小，如图 2 所示，因此目标检测问题变成了一个缺陷块的关键点估计问题。CenterNet 网络先将水果图像传入全卷积网络，得到一个热力图，然后取热力图峰值点看作是缺陷块的可选中心点，同时通过该点的位置来预测目标的宽高信息。

由图 2 可知，CenterNet 骨干网络由于采用全卷积网络将水果图下采样得到 4 倍的热力图，由于不需要提前设定预定区域，大大提高了计算速度。将水果热力图的通道数初始值设置为要检测的缺陷区域种类数。取热力图的前 100 个峰值作为网络提取的待检测缺陷块目标中




图 1 YOLO、CenterNet 和 CornerNet 目标检测

Figure 1 Target detection of YOLO, CenterNet and CornerNet




图 2 CenterNet: 基于中心点检测

Figure 2 CenterNet: center point detection

心点,然后设定一个阈值进行筛选得到最终的目标中心点。CenterNet 中所有的上采样前都有 deformable 卷积,4 倍的下采样 feature map 使得网络不需要多尺度预测和特征金字塔的感受野也能更精确地检测缺陷块。

CenterNet 尽管不需要 NMS,但是所有检测缺陷块的中心点是由热力图的峰值得到,因此会出现一个十分耗时的非极大值抑制过程,此外,CenterNet 未采用分组卷积,进一步延迟了缺陷块的检测时间,很难应用到实际场景中进行实时检测。

1.3 轻量化网络

针对 CenterNet 的骨干网络无法满足在移动设备上的应用需求,Xiao 等^[17-19]研究了更轻的模型设计来获得更快的速度。轻量化模型设计主要思想在于设计更高效的卷积计算方式,从而使网络参数减少的同时,不损失网络性能。假设 $H \times W$ 为输出 feature map 的空间大小, C_1 为输入通道数, $H_1 \times W_1$ 为卷积核大小, C_2 为输出通道数,标准卷积的计算量与输出特征图的空间大小、卷积核的大小和输入输出通道的数量呈正比。当在空间域和通道域进行卷积时,需要 $H_1 \times W_1 \times C_1 \times C_2$ 计算量。通过分解该卷积,可以加速卷积神经网络的计算,分组卷积将输入特征图按通道数分成 g 组,则每组输入特征图的尺寸为 $H \times W \times (C_1/g)$,对应的卷积核尺寸为 $H_i \times W_i \times (C_1/g)$,每组输出特征图尺寸为 $H \times W \times (C_2/g)$ 。将 g 组结果拼接(concat),得到最终尺寸为 $H \times W \times C_2$ 的输出特征图,分组卷积层的参数量为 $H_1 \times W_1 \times C_1 \times C_2/g$,计算量为原计算量的 $1/g$ 。

为了进一步降低卷积计算量,采用深度可分离卷积,假设输入特征图尺寸为 $D_F \times D_F \times M$,卷积核尺寸为 $D_K \times D_K \times M$,输出特征图尺寸为 $D_F \times D_F \times N$,标准卷积层的参数量为 $D_K \times D_K \times M \times N$ 。将深度卷积和逐点卷积两者合起来就是深度可分离卷积。深度卷积负责滤波,尺寸为 $(D_K, D_K, 1)$,共 M 个,作用在输入的每个通道上;逐点卷积负责转换通道,尺寸为 $(1, 1, M)$,共 N 个,作用在深度卷积的输出特征映射上。深度卷积参数量为 $D_K \times D_K \times 1 \times N$,逐点卷积参数量为 $1 \times 1 \times M \times N$,所以深度可分离卷积参数量是标准卷积的 $1/N + 1/(D_K)^2$ 。针对卷积计算特点,对分类算法进行优化,具有代表性的有 ResNet、ShuffleNet 和 MobileNet。如 ResNet 中使用的带有 bottleneck 架构的残差单元是与其他未采用残差单元模型进行比较,具有更好的识别准确率。ShuffleNet 在分组卷积中对通多次卷积,在组间的顺序进行“shuffles”,提高精度。MobileNetV3 采用类似 ResNet2 中带有 bottleneck 架构残差单元的模块架构,用深度可分离卷积代替 $\text{conv}3 \times 3$,是残差单元的改进版本。MobileNetV3 为了在保留高维特征的前提下减小延时,将平均池化前的层移除并用 1×1 卷积来计算特征图。特征生

成层被移除后,先前用于瓶颈映射的层也不再需要,将减少 10 ms 的开销,在提速 15% 的同时减小了 30 ms 的操作数^[20]。

2 MO-CenterNet 目标检测网络

2.1 网络结构

文中受到 MobileNet 网络模型和 CenterNet 目标检测的启发,在尽可能减小网络计算量并保持较高的识别率的原则下,设计一个基于改进的 CenterNet 网络模型 MO-CenterNet,其网络框架如图 3 所示,第 1 部分是图片输入,第 2 部分是骨干网络,用于图像特征提取,第 3 部分是图像的热力图,第 4 部分是检测头,包括目标中心点位置、目标高度、宽度和目标中心高斯分布。与原 CenterNet 网络相比,① 采用 MobileNetV3(Bneck)模块单元作为骨干网络快速提取图像的特征,并尽量保证精度;② 对原有的检测头进行优化,检测头的所有普通卷积替换为 depth-wise 卷积,并将可形变卷积改造为深度的可形变卷积。

图 3 中每层图络的设计如表 1 所示。

由表 1 可知,Conv2d/s1/s2 代表深度卷积,卷积步距为 $1/2$ 。卷积核 3×3 代表卷积核大小为 3×3 。Bneck 表示采用 Mobilenet V3 中的 block 块,由 4 部分组成:① 膨胀,由 1×1 卷积将原来的 feature map 膨胀;② 深度可分




图 3 MO-CenterNet 的网络框架图

Figure 3 MO-CenterNet network framework diagram

表 1 MO-CenterNet 网络层
Table 1 MO-CenterNet network layer

网络层	卷积/步长	卷积核	输入尺寸
0	Conv2d/s2	3×3	$512 \times 512 \times 3$
1	Conv2d/s2	Bneck 3×3	$256 \times 256 \times 16$
2	Conv2d/s2	Bneck 3×3	$128 \times 128 \times 16$
3~7	Conv2d/s1	Bneck 3×3	$128 \times 128 \times 16/32/64$
8~9	Conv2d/s1	Bneck 5×5	$128 \times 128 \times 64$
10	Conv/s1	1×1	$128 \times 128 \times 64$
11	Pool/s1	7×7	$128 \times 128 \times 64$
12	reg	Bneck 1×1	$128 \times 128 \times 2$
13	wh	Bneck 3×3	$128 \times 128 \times 2$
14	hm	Bneck 1×1	$128 \times 128 \times 2$

离卷积,由 3×3 卷积核逐层卷积每层特征,经 1×1 卷积融合成新的 feature map;③ SE(Squeeze and Excitation,)结构的轻量级注意力模块,获取新的 feature map 后,利用 SE 的注意力机制获取空间权重来优化性能;④ Residual,利用残差结构做残差。

在 MO-CenterNet 网络中,先将输入水果特征图通过一个标准卷积层,然后通过第 0~10 个改进后的 Conv/s 操作后,经第 11 层的池化和全连接层提取特征。为了更好地提取特征和使网络快速收敛,Conv/s 操作卷积层处理后的输出均要经过 BN 层和 ReLU 非线性激活函数处理,从而增加复杂缺陷块的表达能力。

2.2 中心点预测

假设输入图像

$$I \in R^{W \times H \times 3}, \quad (1)$$

式中:

R, H ——图像的宽和高。

热点图(keypoint heatmap):

$$\hat{Y} \in [0, 1]^{(W/R) \times (H/R) \times C}, \quad (2)$$

式中:

R ——输出对应原图的步长;

C ——目标检测中对应检测点数量(苹果检测中 C 为 3,代表有苹果不同大小的 3 个缺陷类别)。

如图 4 所示, $\hat{Y}_{x,y,c}$ 是一个缺陷块通过高斯核生成的中心点,在中心点 $\hat{Y}_{x,y,c} = 1$,但是在中心点周围扩散会由 1 慢慢变小,但并不是直接为 0。对于 $\hat{Y}_{x,y,c} = 1$,表示对于类别 C ,当前 (x, y) 坐标中检测到了缺陷块 C ,而 $\hat{Y}_{x,y,c} = 0$ 表示当前坐标点不存在缺陷块类别为 C 的物体。因为整个训练流程中对于每个标签图中的某一 C 类,需将真实关键点 $P \in R_2$ 计算出来用于训练,中心点的计算方式:

$$P[(x_1 + x_2)/2, (y_1 + y_2)/2]. \quad (3)$$

对于下采样后的坐标,设 $\hat{P} = [P/R]$ 是文中提到的下采样因子,因此最终计算出的中心点是对应缺陷块低分辨率的中心点。利用 $\hat{Y} \in [0, 1]^{(W/R) \times (H/R) \times C}$ 对图像进行标记,在下采样的 $[128, 128]$ 图像中将 ground

truth point 以式(4)的形式,用一个高斯核将关键点分布到特征图上。

$$Y_{xyc} = \exp[-(x - \hat{P}_x)^2 + (y - \hat{P}_y)^2] \times 2 \times \sigma_p^2, \quad (4)$$

式中:

σ_p ——一个与目标大小(即 W 和 H)相关的标准差。

如果某一个类的两个高斯分布发生了重叠,直接取元素间最大的即可。每个点 $\hat{Y} \in [0, 1]^{(W/R) \times (H/R) \times C}$ 的范围为 0~1,而 1 代表这个目标的中心点,即预测要学习的点。

2.3 损失函数

与 CenterNet 的损失函数类似,MO-CenterNet 的损失函数如式(5)所示。

$$L_{\text{det}} = L_k + \lambda_{\text{size}} L_{\text{size}} + \lambda_{\text{off}} L_{\text{off}}, (\lambda_{\text{size}} = 0.1, \lambda_{\text{off}} = 1), \quad (5)$$

式中:

L_k ——关键点的热点图;

L_{size} ——目标长宽预测;

L_{off} ——目标中心点偏移值;

$\lambda_{\text{size}}, \lambda_{\text{off}}$ ——试验设置参数。

$$L_k = -\frac{1}{N} \sum_{xyc} \begin{cases} (1 - \hat{Y}_{xyc})^\alpha \log(\hat{Y}_{xyc}), & \text{if } Y_{xyc} = 1 \\ (1 - Y_{xyc})^\beta (\hat{Y}_{xyc})^\alpha \log(1 - \hat{Y}_{xyc}), & \text{otherwise} \end{cases}, \quad (6)$$

(其中超参数: $\alpha = 2, \beta = 4$)

式中:

N ——图像的关键点数量;

α, β ——超参数(用来均衡难易样本和正负样本);

xyc ——所有关键点热点图上的所有坐标点;

C ——目标类别(每个类别一张 heatmap);

$\hat{Y}_{xyc}$ ——预测值;

Y_{xyc} ——标注真实值。

$$L_{\text{off}} = \frac{1}{N} \sum_p |\hat{O}_p - \left(\frac{p}{R} - \hat{p}\right)|, \quad (7)$$


式中:

$\hat{O}_p$ ——预测的偏移值;


p ——图片中目标中心点坐标;



(a) 可选点



(b) 高斯核



(c) 像素值

图 4 关键点热点图值

Figure 4 Keypoint heatmap value

R ——缩放尺度;

$\tilde{p}$ ——缩放后中心点的近似整数坐标。

$$L_{\text{size}} = \frac{1}{N} \sum_{k=1}^N |\hat{S}_{pk} - s_k|, \quad (8)$$

式中:

$\hat{S}_{pk}$ ——预测尺寸;

s_k ——真实尺寸。

苹果缺陷检测中,采用 $\lambda_{\text{size}}, \lambda_{\text{off}} = 1$ 所使用的 backbone 都有 3 个 head layer,分别产生 $[1, 4, 128, 128]$, $[1, 2, 128, 128]$, $[1, 2, 128, 128]$, 即每个坐标点产生 $C+4$ 个数据,分别为类别以及长、宽、偏置。

2.4 预测优化

预测阶段,先针对一张图像进行下采样,随后对下采样后的图像进行预测,对于每个缺陷块类在下采样的特征图中预测中心点,采用一个 3×3 的 MaxPool,检测当前缺陷块热点的值是否都大于周围的 8 个近邻点,类似于 anchor-based 检测中 NMS 的效果。对于苹果检测,取 60 个点,对这些点按类别分组,比如按缺陷和苹果本身分

成 3 组,在苹果类别取概率最高的点 $\hat{P}_{l1}$ 和 $\hat{P}_{r1}$ 作为基点,实际表示检测到的苹果中缺陷概率最高的 2 个中心点, L 为其他两个缺陷 $\hat{P}_{l1}$ 和 $\hat{P}_{r1}$ 的距离。根据苹果大小,使用 $\hat{Y}_{x_i y_i c}$ 表示当前点为 C 点的概率,通过设定阈值筛选,取 50 mm,可以排除苹果外的类似于缺陷的点。

3 结果与分析

3.1 试验数据集

文中算法通过 keras 实现,操作系统为 Ubuntu18.04.1, CPU I5 2.9 GHz,显卡 1080ti,内存 32 G。为进一步证明改进 MO-CenterNet 目标检测效果,采用随机拍摄的 1 000 个苹果图片。

由于样品源数量有限,为了扩充样本数据规模,防止算法过拟合,对其训练样本进行数据增强(如图 5),将图像缩放至 512×512 的分辨率,再将图像随机旋转 $-30^\circ \sim 30^\circ$,分别以 $0.8 \sim 1.2$ 的随机缩放因子对图像进行缩放,并对其中 50% 的随机图像进行水平镜像,即相当于将整个样品数据量进行了成倍的扩充。




图 5 数据增强效果图

Figure 5 Effect of data enhancement

3.2 网络训练

将苹果数据集按 8:2 分为训练集与测试集(见表 2),从经过处理的训练集中随机抽出 20% 的图片为验证集。训练集数据输入模型训练前,为了使训练出的模型泛化性更高,使用图像增强技术对数据集进行镜像、缩放和旋转处理。

模型训练分为两次:第 1 次训练学习率为 0.000 1,轮次 100 次,每轮迭代次数 100,共迭代 10 000 次,每次迭代训练样本数为 20;第 2 次训练使用减少学习率和提前终止,初始学习率为 0.000 01,最大轮次为 50 次,每轮迭代次数 150,最大迭代次数 7 500,每次迭代训练样本数为 5。

表 2 苹果缺陷数据集信息表

Table 2 Information table of apple defect data set

目标类别/mm	标注目标数	训练集目标数	测试集目标数
2~4	1 280	320	400
≥ 4	640	160	200
≤ 2	640	160	200

由图 6 可知,经第 1、2 次训练后,改进 MO-CenterNet 算法损失值均趋于稳定。

3.3 训练结果及分析

在数据集的测试集中随机抽取两张图片,并将图片输入已建立好的模型中,得到对应的框坐标和类别。为了更好地体现小的缺陷块结果,将 3 类缺陷的 score 初始值设置为 0.25, IOU 的初始值设置为 0.70,检测结果如图 7 所示。由图 7 可知,该模型能分别检测出 ≥ 4 mm、 $2 \sim 4$ mm 和 ≤ 2 mm 3 种缺陷,其中检测出最显著的缺陷概率为 0.997。




图 6 迭代训练损失值

Figure 6 Iterative training loss

为了提高 2~4 mm 和 ≤ 2 mm 两类小缺陷块,采用基于位置特点的距离约束进行检测优化,结果如图 8 所示。

由图 8 可知,当 score 值为 0.30 时,原本要保留的很多候选点被过滤了,如图 8(a)中的红点。当 ≤ 2 mm,2~4 mm 缺陷的 score 值为 0.15 时,出现了更多候选点,如图 8(b)所示;再通过距离约束筛选,获得更精确的




图 7 检测结果
Figure 7 Test results

≤ 2 mm,2~4 mm 缺陷检测点如图 8(c)所示,框外部分的检测点被过滤。

为评估 MO-CenterNet 检测的性能,使用苹果缺陷数据集作为测试数据,采用缺陷检测平均值、检测速度和参数量作为评价指标对模型进行评估,结果如表 3 所示。




图 8 检测优化过程
Figure 8 Detection optimization process

表 3 缺陷数据集各类别缺陷检测平均值
Table 3 Defect data set AP50 of each category

算法	缺陷检测平均值	≥ 4 mm 缺陷	2~4 mm 缺陷	≤ 2 mm 缺陷	检测速度/(帧 $\cdot$ s $^{-1}$)	参数量
MO_CenterNet	0.833	0.949	0.865	0.687	113	1.21M
CenterNet_ResNet18	0.802	0.914	0.831	0.661	86	1.45M
CenterNet_Shuffler(2 $\times$ 1.0)	0.756	0.876	0.794	0.593	97	1.26M

由表 3 可知,改进的 MO-CenterNet 算法的 AP50 值相比于 CenterNet_ResNet18 的提高了 3%,比 CenterNet_Shuffler 的提高了 9%,速度相比于 CenterNet_ResNet18,CenterNet_Shuffler 分别快 23%,14%。MO-CenterNet 模型所使用的参数量也是最低的。

4 结论

提出了一种新的基于机器视觉的水果缺陷检测方法 MO-Centernet。该方法通过使用 MobileNetV3 针对移动端优化的轻量化神经网络模替代原有 CenterNet 骨干网络检测模块,并对 Centern 的检测头进行了轻量化改进,解决了深度卷积计算速度慢的问题,提高了网络的特征提取速度。此外,对于多个候选区域采用了距离约束进行筛选,进一步提高了网络对于苹果缺陷的检测速率。由于水果种类繁多,形状和缺陷要求不一,加上采集大量复杂的数据存在一些难度,自制的苹果数据图像集种类较为单一。为进一步增强检测模型的泛化性能,后续将针对类问题进行克服改善,以适用其在不同水果种类检测的适应性。

参考文献

[1] 周伟亮,王红军,邹湘军. 基于机器视觉的荔枝品质快速自动

检测[J]. 中国农机化学报, 2020, 41(1): 144-147, 204.
ZHOU Wei-liang, WANG Hong-jun, ZOU Xiang-jun. Rapid automatic detection of litchi quality based on machine vision[J]. China Journal of Agricultural Chemistry, 2020, 41(1): 144-147, 204.
[2] 左兴健,武广伟. 猕猴桃自动分级设备设计与试验[J]. 农业机械学报, 2014, 45(S1): 287-295.
ZUO Xing-jian, WU Guang-wei. Design and test of kiwifruit automatic grading equipment [J]. Journal of Agricultural Machinery, 2014, 45(S1): 287-295.
[3] 项辉宇,薛真,冷崇杰,等. 基于 Halcon 的苹果品质视觉检测试验研究[J]. 食品与机械, 2016, 32(10): 123-126.
XIANG Hui-yu, XUE Zhen, LENG Chong-jie, et al. Experimental study on visual inspection of apple quality based on Halcon[J]. Food & Machinery, 2016, 32(10): 123-126.
[4] 李红娟,杨颖辉. 基于混沌多宇宙算法的苹果表面缺陷检测研究[J]. 江苏农业科技, 2017, 45(15): 202-205.
LI Hong-juan, YANG Ying-hui. Research on apple surface defect detection based on chaotic multiuniverse algorithm[J]. Jiangsu Agricultural Science and Technology, 2017, 45(15): 202-205.
[5] 高辉,马国峰,刘伟杰. 基于机器视觉的苹果缺陷快速检测方法研究[J]. 食品与机械, 2020, 36(10): 125-148.
GAO Hui, MA Guo-feng, LIU Wei-jie. Research on rapid detection

- method of apple defects based on machine vision[J]. Food & Machinery, 2020, 36(10): 125-148.
- [6] 薛勇, 王立扬, 张瑜, 等. 基于 GoogleNet 深度迁移学习的苹果缺陷检测方法[J]. 农业机械学报, 2020, 51(7): 30-35.
- XUE Yong, WANG Li-yang, ZHANG Yu, et al. Apple defect detection method based on Google net deep transfer learning[J]. Journal of Agricultural Machinery, 2020, 51(7): 30-35.
- [7] 夏雪, 孙琦鑫, 侍啸, 等. 基于轻量级无锚点深度卷积神经网络的树上苹果检测模型[J]. 智慧农业(中英文), 2020(1): 99-110.
- XIA Xue, SUN Qi-xin, SHI Xiao, et al. Apple detection model on tree based on lightweight anchor free depth convolution neural network[J]. Intelligent agriculture (Chinese and English), 2020(1): 99-110.
- [8] SANDLER M, HOWARD A, ZHU Meng-long, et al. MobileNetV2: Inverted residuals and linear bottlenecks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake: IEEE, 2018: 4 510-4 520.
- [9] BAO Wen-xia, YANG Ya-ping, LIANG Dong, et al. Multi-residual module stacked hourglass networks for human pose estimation[J]. Journal of Beijing Institute of Technology, 2020, 29(1): 110-119.
- [10] REN Shao-qing, HE Kai-ming, GRISHICK 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): 1 137-1 149.
- [11] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN[C]// Proceedings of the IEEE International Conference on Computer Vision. Venice: Computer Society, 2017: 2980-298.
- [12] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]// IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2016: 779-788.
- [13] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multi-box detector [C]// European Conference on Computer Vision. Springer, Cham: IEEE, 2016: 21-37.
- [14] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 99: 2 999-3 007.
- [15] DUAN K, BAI S, XIE L, et al. Centernet: Keypoint triplets for object detection [J/OL]. arXiv. (2019-04-19) [2021-07-08]. <https://arxiv.org/abs/1904.08189>.
- [16] ZHOU Xing-yi, WANG De-quan, KRAHENBUHL P. Objects as points[J/OL]. arXiv. (2019-04-25) [2021-07-08]. <https://arxiv.org/abs/1904.07850v2>.
- [17] XIAO Bin, WU Hai-ping, WEI Yi-chen. Simple baselines for human pose estimation and tracking [J]. European Conference on Computer Vision: Springer, 2018: 472-487.
- [18] HE Kai-ming, ZHANG Xiang-yu, REN Shao-qing, et al. Deep residual learning for image recognition[C]// Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770-778.
- [19] SANDLER M, HOWARD A, ZHU M, et al. Inverted residuals and linear bottlenecks: Mobile networks for classification, detection and segmentation[C]// The IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 4 510-4 520.
- [20] HOWARD A, SANDLER M, CHU G, et al. Searching for mobilenetv3[C]// Proceedings of the IEEE International Conference on Computer Vision. Seoul: [s.n.], 2019: 1 314-1 324.

(上接第 33 页)

- [21] PATEL A K, SINGHANIA R R, PANDEY A, et al. Probiotic bile salt hydrolase: current developments and perspectives [J]. Appl Biochem Biotechnol, 2010, 162(1): 166-180.
- [22] 朱晓. 乳酸菌表层蛋白的性质、结构与功能[D]. 无锡: 江南大学, 2012: 29-31.
- ZHU X. The properties, structure and functions of lactic acid bacteria S-layer proteins[D]. Wuxi: Jiangnan University, 2012: 29-31.
- [23] 王今雨, 满朝新, 杨相宜, 等. 植物乳杆菌 NDC75017 的降胆固
- 醇作用[J]. 食品科学, 2013, 34(3): 243-247.
- WANG J Y, MAN C X, YANG X Y, et al. Cholesterol-lowering capability of probiotic *Lactobacillus plantarum* NDC75017[J]. Food Science, 2013, 34(3): 243-247.
- [24] 张扬, 袁杰利. 模拟消化环境对益生菌制剂的影响[J]. 中国微生物学杂志, 2003, 15(5): 253-255.
- ZHANG Y, YUAN J L. The effect of simulated gastrointestinal circumstance on probiotic [J]. Chinese Journal of Microecology, 2003, 15(5): 253-255.

(上接第 117 页)

- [24] 杜利平, 闫慧娇, 王晓, 等. 牡丹花低温干燥过程中生理特性及功效成分的变化研究[J]. 食品科技, 2016, 41(2): 59-64.
- DU Li-ping, YAN Hui-jiao, WANG Xiao, et al. The physiological property and functional components of peony flower during low temperature drying[J]. Food Science and Technology, 2016, 41(2): 59-64.
- [25] DUAN X, LIU W C, RENG Y, et al. Browning behavior of button mushrooms during microwave freeze-drying [J]. Drying Technology, 2016, 34(11): 1 373-1 379.
- [26] 代建武, 杨升霖, 王杰, 等. 微波真空干燥对香蕉片干燥特性及品质的影响[J]. 农业机械学报, 2020, 51(S1): 493-500.
- DAI Jian-wu, YANG Sheng-lin, WANG Jie, et al. Effect of microwave vacuum drying conditions on drying characteristics and texture structure of banana chips[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(S1): 493-500.
- [27] TEPE T K, TEPE B. The comparison of drying and rehydration characteristics of intermittent-microwave and hot-air dried-apple slices[J]. Heat and Mass Transfer, 2020, 56(11): 3 047-3 057.