

doi:10.6041/j. issn. 1000-1298. 2024. 01. 035

# 基于改进 Faster R – CNN 的马铃薯发芽与表面损伤检测方法

刘毅君<sup>1,2</sup> 何亚凯<sup>3,4</sup> 吴晓媚<sup>1,2</sup> 王文杰<sup>3,4</sup> 张丽娜<sup>1,2</sup> 吕黄珍<sup>1,2</sup>(1. 中国农业机械化科学研究院集团有限公司, 北京 100083; 2. 农业装备技术全国重点实验室, 北京 100083;  
3. 中国包装和食品机械有限公司, 北京 100083; 4. 农业农村部农产品加工装备重点实验室, 北京 100083)

**摘要:** 发芽与表面损伤检测是鲜食马铃薯商品化的重要环节。针对鲜食马铃薯高通量分级分选过程中, 高像素图像目标识别准确率低的问题, 提出一种基于改进 Faster R – CNN 的商品马铃薯发芽与表面损伤检测方法。以 Faster R – CNN 为基础网络, 将 Faster R – CNN 中的特征提取网络替换为残差网络 ResNet50, 设计了一种融合 ResNet50 的特征图金字塔网络(FPN), 增加神经网络深度。采用模型对比试验、消融试验对本文模型与改进策略的有效性进行了试验验证分析, 结果表明: 改进模型的马铃薯检测平均精确率为 98.89%, 马铃薯发芽检测平均精确率为 97.52%, 马铃薯表面损伤检测平均精确率为 92.94%, 与 Faster R – CNN 模型相比, 改进模型在检测识别时间和内存占用量不增加的前提下, 马铃薯检测精确率下降 0.04 个百分点, 马铃薯发芽检测平均精确率提升 7.79 个百分点, 马铃薯表面损伤检测平均精确率提升 34.54 个百分点。改进后的模型可以实现对在高分辨率工业相机采集高像素图像条件下, 商品马铃薯发芽与表面损伤的准确识别, 为商品马铃薯快速分级分等工业化生产提供了方法支撑。

**关键词:** 马铃薯; 发芽; 表面损伤; Faster R – CNN; 高分辨率

中图分类号: S532 文献标识码: A 文章编号: 1000-1298(2024)01-0371-08

OSID:



## Potato Sprouting and Surface Damage Detection Method Based on Improved Faster R – CNN

LIU Yijun<sup>1,2</sup> HE Yakai<sup>3,4</sup> WU Xiaomei<sup>1,2</sup> WANG Wenjie<sup>3,4</sup> ZHANG Li'na<sup>1,2</sup> LÜ Huangzhen<sup>1,2</sup>

(1. Chinese Academy of Agricultural Mechanization Sciences Group Co., Ltd., Beijing 100083, China

2. National Key Laboratory of Agricultural Equipment Technology, Beijing 100083, China

3. China National Packaging and Food Machinery Corporation, Beijing 100083, China

4. Key Laboratory of Agricultural Product Processing Equipment, Ministry of Agriculture and Rural Affairs, Beijing 100083, China)

**Abstract:** Germination and surface damage detection are crucial steps in the commercialization of fresh table potatoes. To address the low accuracy rate of high-pixel image object recognition in the high-throughput grading and sorting process of fresh table potatoes, a method for detecting potato sprouting and surface damage based on improved Faster R – CNN was proposed. Using Faster R – CNN as the baseline network, the feature extraction network in Faster R – CNN was replaced with the residual network (ResNet50), and a feature pyramid network (FPN) integrated with ResNet50 was designed to increase the depth of the neural network. A comparative model assessment and ablation studies were performed to empirically validate the efficacy of the proposed model and its modifications. The findings delineated that the enhanced algorithm demonstrated an average precision rate of 98.89% in identifying potatoes, 97.52% in discerning sprouting events, and 92.94% in recognizing surface defects. When benchmarked against the Faster R – CNN model, the adapted model incurred no additional computational time or memory overhead while manifesting a marginal decline of 0.04 percentage points in potato identification accuracy. Notably, it significantly elevated the average precision in detecting sprouting and surface imperfections by 7.79 percentage points and 34.54 percentage points, respectively. This augmented model was robust in high-resolution imaging environments facilitated by industrial-grade cameras and

收稿日期: 2023-05-22 修回日期: 2023-08-02

基金项目: 国家马铃薯产业技术体系项目(CARS-10-P28)、国有资本金项目(GZ202007)和农业农村部农产品产地初加工重点实验室开放项目(KLAPPP2022-01)

作者简介: 刘毅君(1998—), 男, 硕士生, 主要从事智能化农业装备技术研究, E-mail: l6611j@163.com

通信作者: 吕黄珍(1979—), 男, 研究员, 博士生导师, 主要从事农产品加工机械及关键技术研究, E-mail: lvhz@caams.org.cn

served as a cornerstone for the methodological advancement of automated grading and sorting processes in the commercial potato industry.

**Key words:** potato; sprouting; surface damage; Faster R-CNN; high-resolution

## 0 引言

马铃薯是我国第四大主粮作物。2021年我国马铃薯种植面积约为 $4.606 \times 10^6 \text{ hm}^2$ ,鲜马铃薯产量 $9.43 \times 10^7 \text{ t}$ ,均居世界第一位<sup>[1]</sup>。受国人消费习惯影响,我国马铃薯消费中鲜食占总量的70%以上。分级分等是提高鲜食马铃薯商品化程度,满足消费者日益增长的个性化需求,增加马铃薯经济价值的重要手段。GB/T 31784—2015《马铃薯商品薯分级与检验规程》将马铃薯的用途分为鲜食、薯条加工、薯片加工、全粉加工和淀粉加工<sup>[2]</sup>。马铃薯发芽与表面损伤是影响马铃薯商品化价值的重要因素,是马铃薯等级判定的重要标准。因此在马铃薯分级分等、马铃薯商品化处理过程中及时准确地检测出马铃薯发芽与表面损伤具有重要价值。

受技术手段和经济性制约,在我国马铃薯大部分产区的新鲜马铃薯分检工作由人工完成,劳动强度大、工作效率低,随着人口老龄化、人力成本上升,实现产地马铃薯机械化快速分级分选成为必然趋势。特别是随着计算机技术快速发展,机器视觉与深度学习在农业领域广泛应用,基于图像的快速识别分选成为新型的马铃薯分选方法。TAO等<sup>[3]</sup>提出机器视觉与机器学习结合的马铃薯分级机,对马铃薯图像二值化提取轮廓,通过傅里叶展开式提取形状特征参数,验证了马铃薯形状分级,并在后续提出了一种基于傅里叶的形状分离器<sup>[4]</sup>,在马铃薯外形分级上准确率达到89%。EIMASRY等<sup>[5]</sup>在上述研究基础上,使用马铃薯圆度、长度与傅里叶展开式提取的4个形状特征参数准确率达96%。刘艳君<sup>[6]</sup>使用中值滤波+Canny算子提取马铃薯轮廓与形状特征参数,使用支持向量机(SVM)将马铃薯分为球形与畸形,准确率达到93.33%。刘馨阳<sup>[7]</sup>提取马铃薯7个不变矩参数作为BP神经网络输入参数建立 $7 \times 5 \times 1$ 马铃薯形状分类神经网络模型,分类准确率达95%。崔胜春<sup>[8]</sup>在7个不变矩基础上引入三角函数法构造出3个新的不变矩描述薯形,以粒子群优化支持向量机建立形状分类模型,准确率达95%。上述方法使用马铃薯的外观特征,如颜色、轮廓和纹理等来进行目标检测,这种特征提取方法存在一定的盲目性和不确定性,适用性受限。这些方法主要通过人工设计特征来进行目标检测,不能很好地适应不同的场景,导致检测效果不稳定。

深度学习方法具有更好的表达能力,从数据中自动学习到高层抽象特征,具有适应性强、鲁棒性高、特征表达能力优等特点,可以克服常规方法的不足,逐渐在农业领域中大量应用<sup>[9]</sup>。许伟栋等<sup>[10]</sup>使用卷积神经网络提取图像特征,再使用特征向量训练支持向量机对马铃薯表面缺陷进行检测,准确率达99.20%。MARINO等<sup>[11]</sup>采用卷积神经网络(CNN)方法对健康、损伤、发绿、黑点、疮痂和黑痣病6个类别马铃薯样进行分类、定位与分割,精度达到91%。MING等<sup>[12]</sup>使用KNN、AdaBoost等手动特征提取与卷积神经网络自动特征提取组合的方式,创建了一个集成多分类器的马铃薯发芽检测模型,准确率达到90.5%。史方青等<sup>[13]</sup>用YOLO v3网络对马铃薯芽眼进行检测,检测准确率达到97.97%。修春波等<sup>[14]</sup>使用YOLO v4网络对马铃薯苗的芽叶进行检测,通过改进特征提取网络使检测识别准确率达95.72%。

目前大多数的研究都处在模型训练与验证中<sup>[15-19]</sup>,对马铃薯图像使用裁剪、插值、降低分辨率等图像处理手段降低图像质量,会出现被检测目标信息损失、被检测目标变形、特征改变等问题。在实际生产中,将上述训练模型应用在经由高分辨率工业相机拍摄的高像素图像时,会出现模型性能下降、检测准确率降低、无法准确识别马铃薯发芽、损伤等问题。

本文提出一种基于改进Faster R-CNN的高像素(2 592像素×2 048像素)马铃薯发芽、表面损伤检测方法,使用ResNet50网络替换Faster R-CNN的特征提取网络,同时对ResNet50网络进行改进,与FPN结构融合,以提高高像素图像中马铃薯发芽、表面损伤的检测准确率。

## 1 试验数据

### 1.1 数据采集

使用希森6号马铃薯作为样本,在市场中随机采集560个马铃薯样本,并将马铃薯分散在不同环境中放置一段时间,观察其发芽与表面损伤情况。不定期对发芽情况(发芽大小和形状)以及损伤程度和损伤面积的马铃薯进行采样,确保马铃薯发芽与表面损伤的样本具有代表性,如图1所示。

使用海康MV-CA050-20GC型工业相机搭配



图 1 不同程度发芽与损伤的马铃薯

Fig. 1 Potatoes with different degrees of sprouting and damage

海康 MVL-KF1628M-12MP 型镜头作为图像采集设备, 图像保存格式为 jpg, 图像分辨率为 2 592 像素  $\times$  2 048 像素。图像采集过程中, 使用 LED 漫反射光源提供照明, 每个马铃薯采集正反两面图像, 采集图像清晰, 无虚化, 保证采集数据的完整性, 共采集 1 120 幅图像。图像采集系统如图 2 所示。

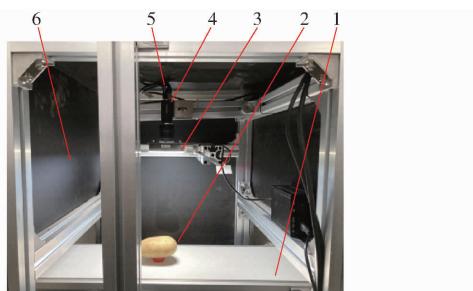


图 2 马铃薯图像采集系统

Fig. 2 Potato image acquisition system

1. 传送带 2. 被检测的马铃薯 3. LED 漫反射光源 4. 镜头
5. 工业相机 6. 半封闭箱体

## 1.2 数据集构建与划分

为丰富图像数据集, 更好地提取图像特征, 提高模型泛化能力, 使用水平和垂直翻转、亮度增强和减弱、运动模糊、对比度增强等图像增强手段扩充马铃薯图像数据集。扩充后马铃薯图像数据集共 6 720 幅图像。数据增强方法为: 水平和垂直翻转图像、在 0.8~1.2 倍范围内对图像亮度随机增强、在  $-45^\circ \sim 45^\circ$  范围内对图像进行随机运动模糊、在 0.8~1.2 倍范围内对图像对比度随机增强。

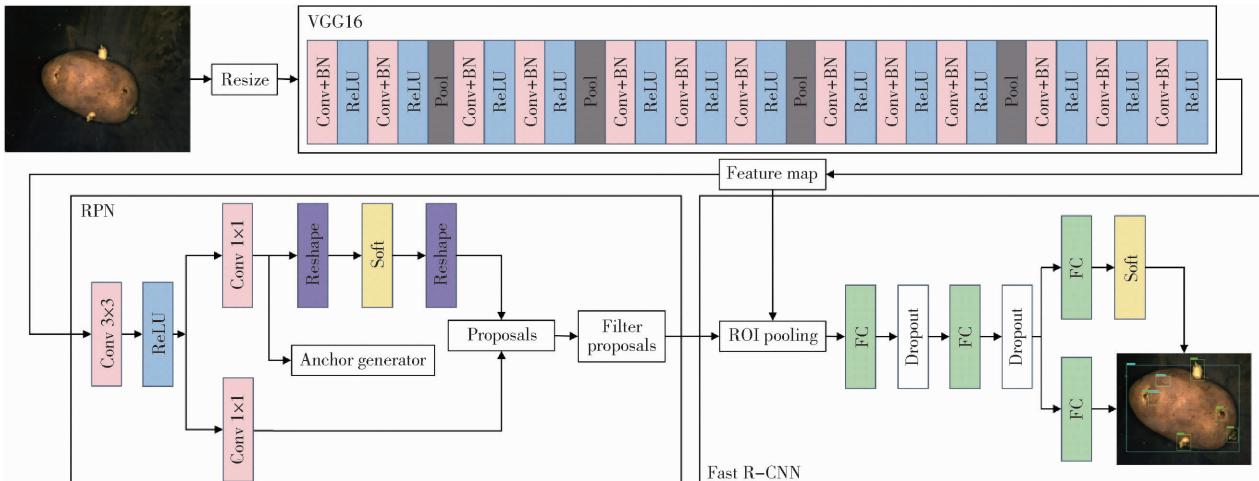


图 4 Faster R-CNN 结构图

Fig. 4 Faster R-CNN structure diagram

使用开源软件 LabelImg 标注马铃薯发芽与表面损伤信息, 图像标注统一保存为 PASCAL VOC 数据集标准格式。标注示例如图 3 所示。

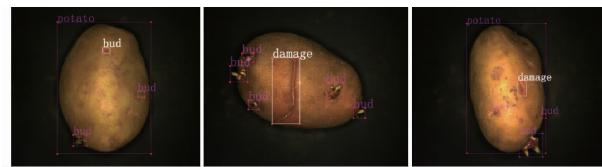


图 3 标注的马铃薯图像

Fig. 3 Labeled potato images

为保证数据集的质量和模型的稳定性, 打乱数据集顺序, 并按照比例 3:1:2 将乱序数据随机划分为训练集、验证集和测试集。划分数据集时, 保证训练集、验证集和测试集的图像之间没有重复。采用上述增强方法对马铃薯图像数据集进行处理, 得到符合要求的数据集, 其中 3 360 幅马铃薯图像用于训练集, 1 120 幅马铃薯图像用于验证集, 2 240 幅马铃薯图像用于测试集。

## 2 识别网络设计

### 2.1 Faster R-CNN 网络

Faster R-CNN 网络<sup>[20]</sup>是典型的 Two-Stage 网络, 相比以 YOLO 系列<sup>[21-25]</sup>为代表的 One-Stage 网络, 具有物体识别准确率高、召回率高、小目标和邻近目标识别效果精准等特点。Faster R-CNN 网络主要结构如图 4 所示, 主要分为特征提取网络 (Backbone)、区域候选网络 (Region proposal network, RPN) 和 Fast R-CNN 网络 (Fast region convolutional neural network)。其中, 特征提取网络负责提取图像高级特征, 为后续的目标检测提供特征图; RPN 网络则是通过在特征图上滑动窗口, 利用锚点 (anchor) 生成候选区域, 然后对这些区域进行分类和回归, 得到真正的目标区域; Fast R-CNN

网络则利用 ROI 池化层对这些目标区域进行特征提取和分类,从而实现目标检测。

特征提取网络截取部分 VGG16 网络,采用 13 个卷积层、13 个批量归一化层 (Batch normalization)、13 个修正线性单元 (Rectified linear unit, ReLU) 和 4 个最大池化层 (Max pooling) 堆叠,使得网络结构非常规整、参数量相对较小。

区域候选网络 (RPN) 是 Faster R - CNN 的一个关键模块,用于快速生成候选目标框、提高 Faster R - CNN 的检测速度。RPN 首先使用  $3 \times 3$  大小的滑动窗口在输入特征图上进行卷积得到一个 256 维的向量。在 RPN 中,使用锚点生成边界框。锚点是一组预定义的边界框,可以覆盖图像中的所有尺度和比例。使用 256 维向量生成尺寸为 64、128、256,比例为 1:1、1:2、2:1 的共 9 个锚点,然后将每个锚点输入到并联的卷积层中,对锚点进行分类和回归,预测锚点是否包含目标及对锚点位置的修正,如图 5 所示。RPN 结构不需要提前生成候选框,在共享卷积特征层的基础上计算目标的位置和类别,从而提高检测准确度。

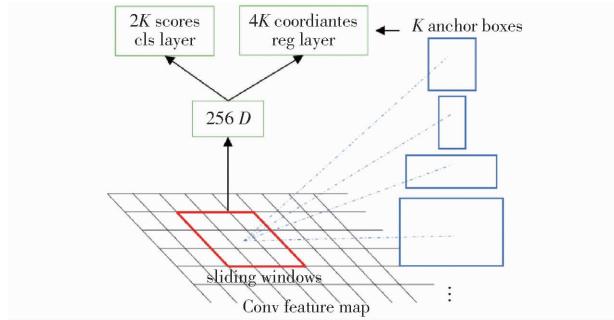


图 5 PRN 网络提取过程

Fig. 5 PRN network extraction process

## 2.2 特征提取网络修改

为了提高高分辨率下马铃薯发芽与表面损伤等小目标的检测能力,本文提出了一种多尺度融合的特征提取方法:使用残差网络<sup>[26]</sup> ResNet50 结合特征金字塔网络 (Feature pyramid networks, FPN)<sup>[27]</sup> 构建新的特征提取网络替换 VGG16。

VGG16 与 ResNet50 的主要结构如图 6 所示。相比 16 层的 VGG16,50 层的 ResNet50 可以学习更深层次和更抽象的特征。ResNet50 的残差网络结构主要由瓶颈结构 (Bottleneck structure) 和残差连接 (Residual connection) 组成,如图 7 所示。瓶颈结构由 3 个连续的卷积层组成,包括第 1 层  $1 \times 1$  卷积、第 2 层  $3 \times 3$  卷积和第 3 层  $1 \times 1$  卷积。输入特征经第 1 层  $1 \times 1$  卷积降低输入通道数,减少计算量;再经第 2 层  $3 \times 3$  卷积执行卷积操作,提取更高维度图像特征;最后,通过第 3 层  $1 \times 1$  卷积恢复输出通道数,作为下一个瓶颈结构输入。使用瓶颈结构可以在保持模型深度的同时,大幅度减少网络参数的数量,降低计算成本,从而加速模型训练和推理。假设输入特征为  $x$ ,经过 3 个卷积层后的输出为  $F(x)$ ,经过残差连接后的输出为  $x + F(x)$ ,残差连接将前 1 层的输出添加到当前层的输出中,从而保留了原始的特征信息,同时也使得网络更容易训练和优化。

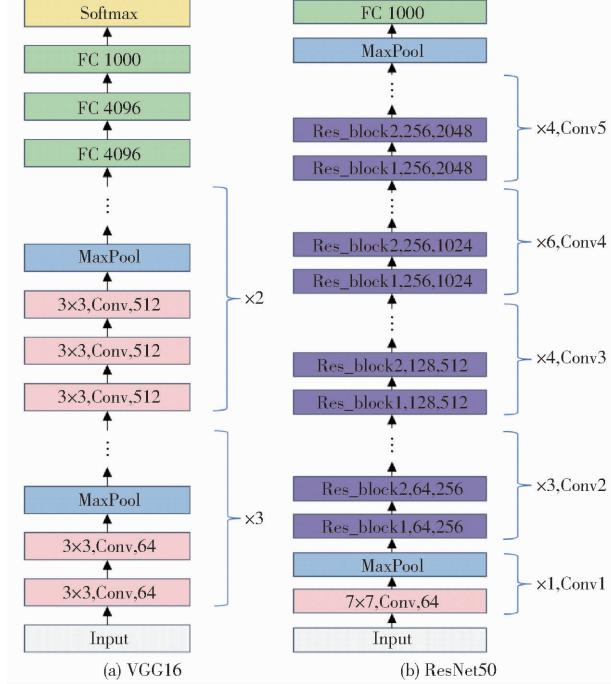


图 6 VGG16 与 ResNet50 的结构图

Fig. 6 Structural diagram of VGG16 and ResNet50

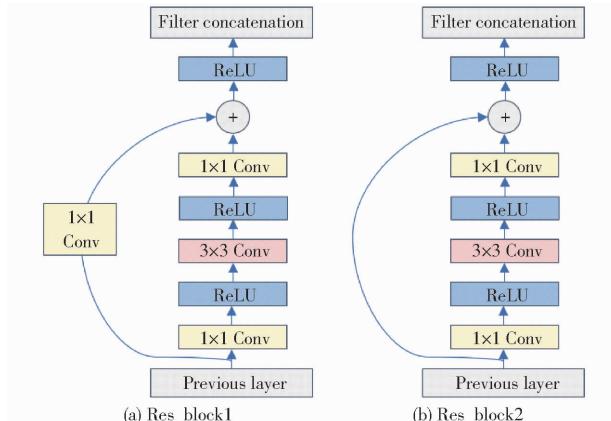


图 7 ResNet 中的两种残差结构

Fig. 7 Two residual structures in ResNet

FPN 是一种特征金字塔网络,采用特殊的多尺度特征组合技术,可以从不同尺度的特征图中提取丰富的语义信息,从而提高目标检测的准确性。ResNet50 和 FPN 的融合过程涉及提取 ResNet50 的中间层 Conv2、Conv3、Conv4 和 Conv5 的输出特征,将其作为 FPN 结构的输入特征。Conv5 的输出特征首先经过  $1 \times 1$  卷积和  $3 \times 3$  卷积,以获得 P5 特征图。P5 特征图进一步通过  $3 \times 3$  卷积进行处理,以

获得 P6 特征图。Conv5 的输出特征也在  $1 \times 1$  卷积后进行下采样, 并在  $1 \times 1$  卷积后与 Conv4 的输出特征相加, 随后进行  $3 \times 3$  卷积, 以获得 P4 特征图。类似地, Conv4 和 Conv3 的输出特征通过  $1 \times 1$  卷积、下采样、相加和  $3 \times 3$  卷积进行处理, 以分别获得 P3 和 P2 特征图。最后, ResNet50 和 FPN 的融合可以提取 5 个具有相同维度但不同尺寸的特征图, 如图 8 所示。特征图在 RPN 网络中计算候选框位置并在 Fast R-CNN 网络中计算目标的位置和类别。RPN 网络通过在特征图上滑动一个小网络来生成候选框, 根据它们的分数过滤候选框。

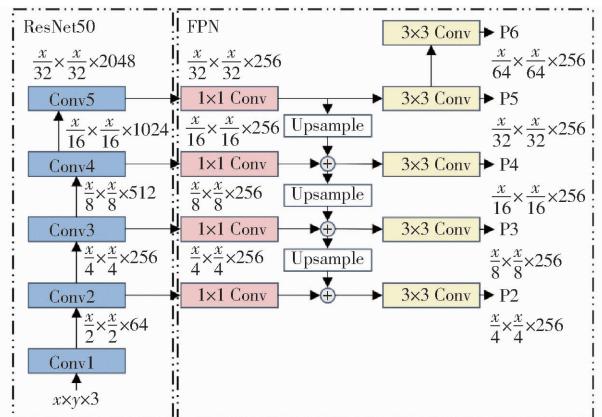


图 8 ResNet50 与 FPN 融合网络

Fig. 8 ResNet50 and FPN converged network

### 3 试验结果与分析

#### 3.1 试验平台

试验基于 Python 3.9, 使用 PyCharm 开发平台在 Windows 11 中进行, CPU 为 Inter Core i3 –

12490F, 显卡为 NVIDIA GeForce RTX 3080 10GB。

#### 3.2 评价指标

为衡量模型检测性能, 以平均精确率(AP)、平均召回率(AR)、检测时间、模型内存占用量作为评价指标。

#### 3.3 试验结果

模型试验结果如图 9 和表 1 所示。表 1 中 AP<sub>50</sub> 表示交并比为 0.5 时的平均精度, AP<sub>75</sub> 表示交并比为 0.75 时的平均精度, AP<sub>s</sub> 表示小物体(面积小于  $32^2$  像素)的平均精度, AP<sub>L</sub> 表示中等物体(面积在  $32^2 \sim 96^2$  像素之间)的平均精度, AP<sub>M</sub> 表示大型物体(面积大于  $96^2$  像素)的平均精度, AR<sub>1</sub> 表示每次检测 1 幅图像的平均召回率, AR<sub>10</sub> 表示每次检测 10 幅图像的平均召回率, AR<sub>100</sub> 表示每次检测 100 幅图像的平均召回率, AR<sub>s</sub> 表示小物体(面积小于  $32^2$  像素)的平均召回率, AR<sub>M</sub> 表示中等物体(面积在  $32^2 \sim 96^2$  像素之间)的平均召回率, AR<sub>L</sub> 表示大型物体(面积大于  $96^2$  像素)的平均召回率。

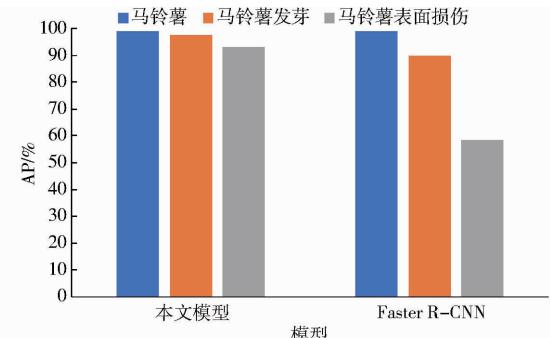


图 9 不同模型 3 个类别检测的平均精确率

Fig. 9 Three categories' AP for different models

表 1 模型检测性能指标对比

Tab. 1 Comparison of model detection performance indicators

模型	AP <sub>50</sub> /%	AP <sub>75</sub> /%	AP <sub>s</sub> /%	AP <sub>L</sub> /%	AP <sub>M</sub> /%	AR <sub>1</sub> /%	AR <sub>10</sub> /%	AR <sub>100</sub> /%	AR <sub>s</sub> /%	AR <sub>M</sub> /%	AR <sub>L</sub> /%	检测时间/s	模型内存占用量/MB
本文模型	96.4	88.8	68.0	66.8	84.0	59.3	87.4	87.4	72.5	71.5	88.7	0.23	315
Faster R-CNN	82.4	61.3	0	10.6	62.6	48.1	64.2	64.2	0	14.4	67.8	0.23	334

由图 9 可知, 本文模型对马铃薯检测精确率为 98.89%, 马铃薯发芽检测平均精确率为 97.52%, 马铃薯表面损伤检测平均精确率为 92.94%。Faster R-CNN 马铃薯检测平均精确率为 98.93%, 马铃薯发芽检测平均精确率为 89.73%, 马铃薯表面损伤检测平均精确率为 58.40%。对比本文模型和 Faster R-CNN, 马铃薯检测精确率基本相同(下降 0.04 个百分点), 马铃薯发芽检测平均精确率提升 7.79 个百分点, 马铃薯表面损伤检测平均精确率提升 34.54 个百分点。

由表 1 可知, 在马铃薯发芽和表面损伤检测中,

本文模型相较于 Faster R-CNN 网络, 在 IoU 大于 0.5 时不同类别目标检测的平均精确率提升 14 个百分点, 在 IoU 大于 0.75 时不同类别目标检测的平均精确率提升 27.5 个百分点; 在检测高分辨率图像时, Faster R-CNN 网络无法检测出小尺寸目标, 本文模型平均精确率达到 68.0%, 对于中尺寸的目标, 本文模型的平均精确率提升 56.2 个百分点, 对于大尺寸目标, 本文模型平均精确率提升 21.4 个百分点; 在单幅图像检测时间上, 本文模型与 Faster R-CNN 相同; 与未改进 Faster R-CNN 网络相比, 本文模型单幅图像检测时间不变, 模型内存占用量明显降低。

图 10 为本文模型与 Faster R - CNN 网络的损失值变化曲线, Faster R - CNN 网络在前 15 个迭代周期内损失值迅速下降, 在前 15 ~ 20 个迭代周期内损失值趋于收敛; 本文模型在前 10 个迭代周期内损失值迅速下降, 在前 10 ~ 15 个迭代周期内损失值趋于稳定。表明本文模型损失值能在更少的训练周期内趋于收敛。

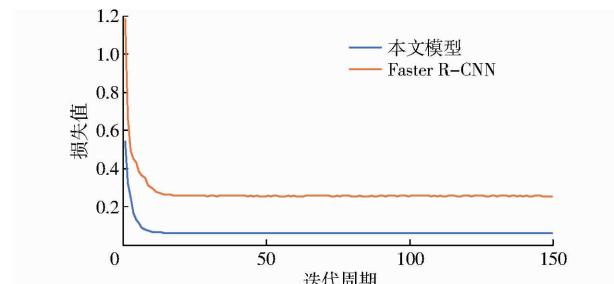


图 10 损失值变化曲线

Fig. 10 Loss value change curves

图 11 为马铃薯发芽与表面损伤在不同模型下的检测结果。在马铃薯发芽检测中, Faster R - CNN 模型没有检测出马铃薯上方的芽, 本文模型正确检测出该芽; 在马铃薯表面损伤检测中, Faster R - CNN 模型的马铃薯表面损伤候选框与表面损伤中心位置的偏差大于本文模型的候选框位置; 在马铃薯检测中, Faster R - CNN 模型的马铃薯候选框出现了上边界与马铃薯重合的现象, 边界框的左侧与马铃薯的距离大于右侧与马铃薯的距离, 本文模型马铃薯边界框与马铃薯的距离更接近。

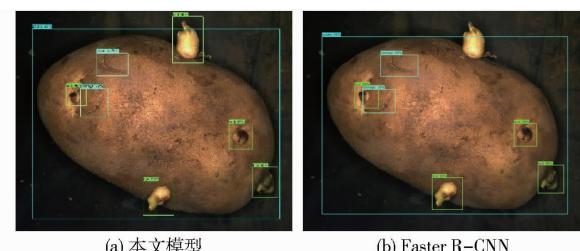


图 11 马铃薯发芽与损伤在不同模型下的识别结果

Fig. 11 Identification of potato germination and damage under different models

### 3.4 消融试验

特征提取网络在神经网络中起着至关重要的作用, 对本文模型进行消融试验, 验证所采用的各项改进策略的有效性。

模型 1 为将 Faster R - CNN 网络特征提取部分更换为 ResNet50, 通过与本文模型的对比验证本文采用 FPN 改进策略的有效性; 模型 2 为 Faster R - CNN 网络, 通过与本文模型进行对比验证本文采用 ResNet50 改进策略的有效性。

表 2 为消融试验结果。模型 1 的多项目标检测平均精确率均低于模型 2, 检测时间高于模型 2, 模型内存占量高于模型 2; 将本文模型与模型 1 和模型 2 对比, 本文模型 AP<sub>50</sub> 分别提高了 31 个百分点和 14 个百分点, AP<sub>75</sub> 分别提高了 39.1 个百分点和 27.5 个百分点, 在 AP<sub>S</sub>, AP<sub>L</sub>, AP<sub>M</sub> 3 个指标上均有大幅提升, 提升了在检测小目标时的准确性, 验证了本文改进策略的有效性。

表 2 消融试验结果

Tab. 2 Ablation experiment results

模型	AP <sub>50</sub> /%	AP <sub>75</sub> /%	AP <sub>S</sub> /%	AP <sub>L</sub> /%	AP <sub>M</sub> /%	AR <sub>I</sub> /%	AR <sub>10</sub> /%	AR <sub>100</sub> /%	AR <sub>S</sub> /%	AR <sub>M</sub> /%	AR <sub>L</sub> /%	检测时间/s	模型内存占用量/MB
本文模型	96.4	88.8	68.0	66.8	84.0	59.3	87.4	87.4	72.5	71.5	88.7	0.23	315
模型 1	65.4	49.7	0	6.3	49.4	40.6	53.1	53.1	0	10.0	55.7	0.26	538
模型 2	82.4	61.3	0	10.6	62.6	48.1	64.2	64.2	0	14.4	67.8	0.23	334

图 12 为 3 个模型对不同类别的检测精确率, 本文模型对马铃薯检测平均精确率为 98.89%, 马铃薯发芽检测平均精确率为 97.52%, 马铃薯表面损伤检测平均精确率为 92.94%。模型 1 马铃薯检测平均精确率为 97.89%, 马铃薯发芽检测平均精确率为 84.96%, 马铃薯表面损伤检测平均精确率为 13.49%。模型 2 马铃薯检测精确率为 98.93%, 马铃薯发芽检测平均精确率为 89.73%, 马铃薯表面损伤检测平均精确率为 58.40%。对比模型 1 与模型 2, 模型 1 马铃薯检测精确率下降 1.04 个百分点, 马铃薯发芽检测精确率下降 4.77 个百分点、马铃薯表面损伤检测精确率下降 44.91 个百分点; 对比本文模型与模型 2, 本文模型马铃薯检测精确率下降 0.04 个百分点、马铃薯发芽检测精确率提升 7.79 个百分点、马铃薯表面损伤检测精确率提升

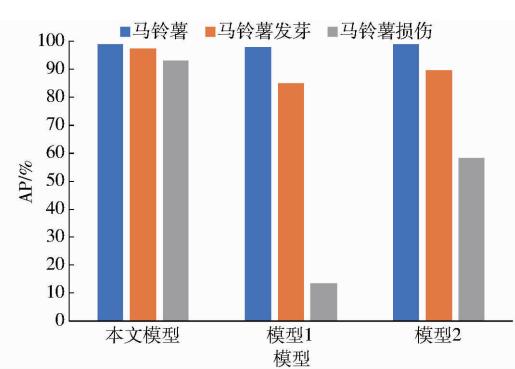


图 12 3 个模型对不同类别检测的平均精确率

Fig. 12 Three models' AP for different classes

34.54个百分点。对比本文模型与模型1,本文模型马铃薯检测精确率提升1个百分点、马铃薯发芽检测精确率提升12.56个百分点、马铃薯表面损伤检测精确率提升79.45个百分点。

对比模型1与模型2,模型1将Faster R-CNN中特征提取网络由VGG16替换为ResNet50,模型1具有更多的参数和更深的网络,模型体积增大、检测时间变长,模型检测性能下降,分析原因为:在高分辨率下,过多的下采样会损失目标的细节,使得小目标和密集目标的检测性能下降。对比本文模型、模型1和模型2,本文模型使用ResNet50避免了深度神经网络中的梯度消失和爆炸问题,使用FPN在每个尺度上执行预测,通过上采样和融合合并预测,使得模型能够在各种尺度上都有良好的性能,同时ResNet50与FPN多尺度融合的特征提取网络,使得特征图在多个尺度上被重复使用,提高了计算效率,提高了模型检测的精确率。

## 4 结论

(1)提出了一种基于改进Faster R-CNN的高分辨率下马铃薯发芽与表面损伤检测方法。试验结果表明,本文方法可以显著提高高分辨率下马铃薯发芽与表面损伤的识别效果。

(2)对Faster R-CNN中的特征提取网络进行改进,使用ResNet50融合FPN的特征提取网络,提高了马铃薯发芽、损伤等小目标的检测能力,马铃薯检测平均精确率达98.89%,马铃薯发芽检测平均精确率达97.52%,马铃薯表面损伤检测平均精确率达92.94%。

(3)基于改进Faster R-CNN的高分辨率下马铃薯发芽与表面损伤检测方法可以实现高分辨率下对马铃薯发芽、表面损伤的有效识别,且不增加额外的运行时间,可为马铃薯分级、马铃薯产地商品化奠定方法基础。

## 参 考 文 献

- [1] 中华人民共和国国家统计局. 中国统计年鉴 2021 [M]. 北京: 中国统计出版社, 2021.
- [2] 全国蔬菜标准化技术委员会(SAC/TC 467). 马铃薯商品薯分级与检验规程: GB/T 31784—2015 [S]. 2015.
- [3] TAO Y, MORROW C T, HEINEMANN P H, et al. Automated machine vision inspection of potatoes [J]. American Society of Agricultural Engineers, 1990, 90-3531:23-27.
- [4] TAO Y, MORROW C T, HEINEMANN P H, et al. Fourier-based separation technique for shape grading of potatoes using machine vision [J]. Transactions of the ASAE, 1995, 38(3):949-957.
- [5] ELMASRY G, CUBERO S, MOLTÓ E, et al. In-line sorting of irregular potatoes by using automated computer-based machine vision system [J]. Journal of Food Engineering, 2012, 112(1-2):60-68.
- [6] 刘艳君. 基于机器视觉的马铃薯等级分类研究[D]. 兰州: 兰州理工大学, 2021.  
LIU Yanjun. Research on potato grade classification based on machine vision [D]. Lanzhou: Lanzhou University of Technology, 2021. (in Chinese)
- [7] 刘馨阳. 基于机器视觉的动态马铃薯外部品质无损检测研究[D]. 银川: 宁夏大学, 2018.  
LIU Xinyang. Dynamic potato external quality based on machine vision non-destructive testing [D]. Yinchuan: Ningxia University, 2018. (in Chinese)
- [8] 崔胜春. 基于机器视觉的马铃薯薯形与外部缺陷算法研究[D]. 徐州: 中国矿业大学, 2017.  
CUI Shengchun. Research on potato shape and external defects based on machine vision [D]. Xuzhou: China University of Mining and Technology, 2017. (in Chinese)
- [9] 傅隆生, 宋珍珍, ZHANG Xin, 等. 深度学习方法在农业信息中的研究进展与应用现状[J]. 中国农业大学学报, 2020, 25(2):105-120.  
FU Longsheng, SONG Zhenzhen, ZHANG Xin, et al. Applications and research progress of deep learning in agriculture [J]. Journal of China Agricultural University, 2020, 25(2):105-120. (in Chinese)
- [10] 许伟栋, 赵忠盖. 基于卷积神经网络和支持向量机算法的马铃薯表面缺陷检测[J]. 江苏农业学报, 2018, 34(6):1378-1385.  
XU Weidong, ZHAO Zhonggai. Potato surface defects detection based on convolution neural networks and support vector machine algorithm [J]. Jiangsu Journal of Agricultural Sciences, 2018, 34(6):1378-1385. (in Chinese)
- [11] MARINO S, BEAUSEROY P, SMOLARZ A. Weakly-supervised learning approach for potato defects segmentation [J]. Engineering Applications of Artificial Intelligence, 2019, 85:337-346.
- [12] MING W, DU J, SHEN D, et al. Visual detection of sprouting in potatoes using ensemble-based classifier [J]. Journal of Food Process Engineering, 2018, 41(3):e12667.
- [13] 史方青, 王虎林, 黄华. 基于卷积神经网络的马铃薯芽眼检测识别研究[J]. 中国农机化学报, 2022, 43(6):159-165.  
SHI Fangqing, WANG Hulin, HUANG Hua. Research on potato buds detection and recognition based on convolutional neural network [J]. Journal of Chinese Agricultural Mechanization, 2022, 43(6):159-165 (in Chinese)
- [14] 修春波, 孙乐乐. 基于改进YOLO v4网络的马铃薯自动育苗叶芽检测方法[J]. 农业机械学报, 2022, 53(6):265-273.

- XIU Chunbo, SUN Lele. Potato leaf bud detection method based on improved YOLO v4 network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(6):265–273. (in Chinese)
- [15] 陈志伟, 张万枝, 张涛, 等. 基于 YOLO v3 算法的马铃薯种薯芽眼识别[J]. 农机化研究, 2022, 44(11):19–23,30. CHEN Zhiwei, ZHANG Wanzhi, ZHANG Tao, et al. Potato seed potato bud recognition based on YOLO v3 algorithm[J]. Journal of Agricultural Mechanization Research, 2022, 44(11):19–23,30. (in Chinese)
- [16] 王飞云, 吕程序, 吴金灿, 等. 基于 Shuffle-Net 的发芽马铃薯无损检测方法[J]. 农业机械学报, 2022, 53(增刊1):309–315. WANG Feiyun, LÜ Chengxu, WU Jincan, et al. Non-destructive detection of sprouting potatoes based on Shuffle-Net[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(Supp.1):309–315. (in Chinese)
- [17] 席芮, 姜凯, 张万枝, 等. 基于改进 Faster R-CNN 的马铃薯芽眼识别方法[J]. 农业机械学报, 2020, 51(4):216–223. XI Rui, JIANG Kai, ZHANG Wanzhi. Recognition method for potato buds based on improved Faster R-CNN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(4):216–223. (in Chinese)
- [18] YANG Yu, LIU Zhenfang, HUANG Min, et al. Automatic detection of multi-type defects on potatoes using multispectral imaging combined with a deep learning model[J]. Journal of Food Engineering, 2023, 336:111213.
- [19] ARSHAGHI A, ASHOURIAN M, GHABELI L. Potato diseases detection and classification using deep learning methods[J]. Multimedia Tools and Applications, 2022, 82(4):5725–5742.
- [20] 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 & Machine Intelligence, 2017, 39(6): 1137–1149.
- [21] 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 (CVPR). IEEE, 2016: 779–788.
- [22] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 7263–7271.
- [23] REDMON J, FARHADI A. YOLO v3: an incremental improvement[J]. arXiv Preprint, arXiv: 1804.02767, 2018.
- [24] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLO v4: optimal speed and accuracy of object detection[J]. arXiv Preprint, arXiv: 2004.10934, 2020.
- [25] GE Z, LIU S, WANG F, et al. YOLOX: exceeding YOLO series in 2021[J]. arXiv Preprint, arXiv: 2107.08430, 2021.
- [26] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770–778.
- [27] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 936–944.

(上接第 202 页)

- [21] 田有文,吴伟,林磊,等. 基于深度学习与高光谱成像的蓝莓果蝇虫害无损检测[J]. 农业机械学报, 2023, 54(1):393–401. TIAN Youwen, WU Wei, LIN Lei, et al. Nondestructive detection of blueberry fruit fly pests based on deep learning and hyperspectral imaging[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(1):393–401. (in Chinese)
- [22] 梁万杰,冯辉,江东,等. 高光谱图像结合深度学习的油菜菌核病早期识别[J]. 光谱学与光谱分析, 2023, 43(7):2220–2225. LIANG Wanjie, FENG Hui, JIANG Dong, et al. Early recognition of sclerotinia stem rot on oilseed rape by hyperspectral imaging combined with deep learning[J]. Spectroscopy and Spectral Analysis, 2023, 43(7):2220–2225. (in Chinese)
- [23] 齐济,杨海涛,孔卓. 基于 CNN 的高光谱和多光谱图像融合方法研究[J]. 兵器装备工程学报, 2022, 43(11):81–87,129. QI Ji, YANG Haitao, KONG Zhuo. Research on hyperspectral and multispectral image fusion methods based on improved convolutional neural networks[J]. Journal of Ordnance Equipment Engineering, 2022, 43(11):81–87,129. (in Chinese)
- [24] 方帅,许漫. 面向误差补偿的高光谱与多光谱图像融合[J]. 中国图象图形学报, 2023, 28(1):277–289. FANG Shuai, XU Man. Hyperspectral and multispectral image fusion focused on error compensation[J]. Journal of Image and Graphics, 2023, 28(1):277–289. (in Chinese)
- [25] 李善军,宋竹平,梁千月,等. 基于 X-ray 和 RGB 图像融合的实蝇侵染柑橘无损检测[J]. 农业机械学报, 2023, 54(1):385–392. LI Shanjun, SONG Zhuping, LIANG Qianyue, et al. Nondestructive detection of citrus infested by *Bactrocera dorsalis* based on X-ray and RGB image data fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(1):385–392. (in Chinese)