doi:10.6041/j.issn.1000-1298.2024.03.038

基于 SIRI 和 CNN 的苹果隐性损伤检测方法

王玉伟[1]　杨玲玲[1]　朱浩杰[1]　饶　元[2]　刘　路[1]　侯文慧[1]
(1.安徽农业大学工学院，合肥 230036；2.农业农村部农业传感器重点实验室，合肥 230036)

摘要：苹果从采摘到销售过程中易发生机械损伤，需要及时剔除以避免腐烂变质。然而机械损伤早期苹果外观颜色变化不明显，通常表现为隐性损伤，检测比较困难。提出了一种基于结构光反射成像(SIRI)和卷积神经网络(CNN)的苹果隐性损伤检测方法。通过搭建 SIRI 系统，采集待测苹果调制的结构光图像，再利用三相位解调法提取交流分量，增强苹果隐性损伤对比度；然后利用交流分量图像制作苹果隐性损伤数据集，并使用基于 CNN 的语义分割网络 FCN、UNet、HRNet、PSPNet、DeepLabv3 + 、LRASPP 和 SegNet 训练损伤检测模型，多组试验结果表明上述模型均能有效地检测出不同情况下的苹果隐性损伤。其中 HRNet 模型精确率、召回率、F1 值和平均交并比较高，分别为 97.96% 、97.52% 、97.74% 和 97.58% ，但检测速度仅为 60 f/s；PSPNet 模型检测速度较快，可达到217 f/s，但其检测精度略低，精确率、召回率、F1 值和平均交并比分别为 97.10% 、94.57% 、95.82% 和 95.90% 。

关键词：苹果；隐性损伤检测；结构光反射成像；三相位解调法；语义分割；卷积神经网络
中图分类号：S436.611　　**文献标识码**：A　　**文章编号**：1000-1298(2024)03-0383-09　　**OSID**：

Detection Method for Implicit Apple Damages Based on SIRI and CNN

WANG Yuwei[1]　YANG Lingling[1]　ZHU Haojie[1]　RAO Yuan[2]　LIU Lu[1]　HOU Wenhui[1]
(1. *School of Engineering*, *Anhui Agricultural University*, *Hefei* 230036, *China*
2. *Key Laboratory of Agricultural Sensors*, *Ministry of Agriculture and Rural Affairs*, *Hefei* 230036, *China*)

Abstract: During the process from harvest to sales, apples are susceptible to mechanical damage, which can have detrimental effects on their quality and lead to rotting. Detecting and removing this damage in a timely manner is crucial to prevent further deterioration. However, early-stage mechanical damage in apples often manifests as subtle color changes, making it challenging to detect. To address this issue, an apple implicit damage detection method was presented based on structured-illumination reflectance imaging (SIRI) and convolutional neural network (CNN). By building an SIRI system to acquire modulated structured light images of the measured apples, and utilizing three-phase demodulation method to extract the alternating current component, the image contrast of the apple implicit damage can be enhanced. The dataset of apple implicit damages was produced by using the images of alternating current components. Several CNN-based semantic segmentation networks, including FCN, UNet, HRNet, PSPNet, DeepLabv3 + , LRASPP, and SegNet were employed to train the damage detection models, respectively. Several groups of experimental results demonstrated that these models can effectively detect the apple implicit damages in different situations. In contrast, the precision (P), recall (R), F1 score, and mean intersection over union (MIoU) of the HRNet model were respectively 97.96% , 97.52% , 97.74% and 97.58% . However, its detection speed was only 60 frames per second. The PSPNet model had a faster detection speed, reaching up to 217 frames per second. However, it had slightly lower detection accuracy, with precision (P), recall (R), F1 score, and mean intersection over union (MIoU) of 97.10% , 94.57% , 95.82% , and 95.90% , respectively.

Key words: apple; implicit damage detection; structured-illumination reflection imaging; three-phase demodulation; semantic segmentation; convolutional neural network

收稿日期：2023-07-18　修回日期：2023-12-18
基金项目：安徽省自然科学基金项目(2308085ME169)、安徽省高校科研计划项目(2022AH050872)和农业农村部农业传感器重点实验室开放项目(KLAS2022KF020)
作者简介：王玉伟(1991—)，男，副教授，博士，主要从事智慧农业研究，E-mail：wyw@ahau.edu.cn
通信作者：侯文慧(1985—)，女，讲师，博士，主要从事智慧农业研究，E-mail：hwh303@ahau.edu.cn

0 引言

苹果在采摘、分装、贮藏、运输等环节,易受到碰撞、挤压、振动、摩擦等机械载荷影响,引起果实变形、汁液流失、果皮果肉破损等机械损伤现象,进而导致细菌侵染和果肉腐烂等危害,甚至感染周围的健康果实,构成食品安全隐患,影响果实的经济效益[1]。机械损伤会改变果皮和果肉组织的生理、物理和化学特性等,这构成了机械损伤检测的理论基础[2]。相比于传统人工、机械或化学等检测技术,光学检测技术具有非接触、成本低、速度快等优势,逐渐成为果蔬品质检测的重要手段。但机械损伤早期通常表现为隐性损伤,外观特征与正常果实差异较小,肉眼难以辨别,导致检测比较困难[3]。因此准确、快速、客观地检测苹果隐性损伤对于提升其食用安全性和消费者认可度至关重要。

近红外光谱技术通过分析反射、散射或透射光合适波段的光谱特征,提取含氢基团的倍频和合频信息,测定与含氢基团有关的样品组分及物理、化学性质,其中透射光谱更适用于内部品质检测,漫反射光谱更适用于表面或亚表面品质检测,但单点或多点采样方式仅能获取样品局部区域的光谱信息,缺失空间信息,难以全面地检测果蔬品质[4-6]。多光谱或高光谱成像技术将光谱技术和成像技术相结合,通过采集待测果蔬的窄波段连续光谱图像,同时获取空间信息和光谱信息,有利于果蔬隐性损伤检测[7-10],但存在成本偏高、信息冗余、数据采集和处理时间缓慢等问题,商用化较为困难。此外,拉曼光谱[11]、荧光光谱[12]、X 射线[13]、热成像[14]等技术均已应用于果蔬检测领域,并取得了较好的研究进展,但仍存在仪器昂贵、实时性差、适用性弱等问题[15]。

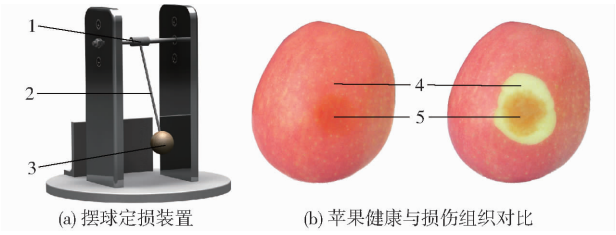
结构光反射成像(Structured-illumination reflectance imaging, SIRI)具有宽场非接触、成像深度辨析和有效信号增强等优点,引起学者们广泛关注[16]。面向果蔬品质检测需求,文献[17-18]开展了前沿性研究工作。文献[19]搭建了空间频域成像(Spatial-frequency domain imaging, SFDI)系统,并使用两步法和逐步法测得苹果、芒果、猕猴桃等果蔬的吸收系数和约化散射系数。文献[20]使用相位轮廓术重建出梨子的三维轮廓,用于校正空间漫反射率,有效地提升了组织光学特性参数的反演精度。文献[21]利用人工神经网络建立了空间漫反射率与吸收系数、约化散射系数的映射模型。文献[22]搭建了 SIRI 系统,通过优选空间频率实现光透射深度的动态调节,探测到均匀光照射下难以判别的隐性损伤,并成功应用于苹果[23]、桃子[24]、黄瓜[22]、脐橙[25]等多种果蔬的内部品质检测。

本文采用结构光反射成像(SIRI)和卷积神经网络(Convolutional neural network, CNN)进行隐性损伤检测。首先使用 SIRI 系统采集待测苹果调制的结构光图像,然后利用三相位解调法提取交流分量,最后构建语义分割网络 FCN、UNet、HRNet、PSPNet、DeepLabv3 + 、LRASPP 和 SegNet 模型检测苹果隐性损伤,并通过多组试验对比分析各网络模型的检测性能。

1 苹果隐性损伤数据集

1.1 苹果样本准备

原始苹果样本包括 4 种不同品种的健康苹果,均购买于安徽农业大学校园内的水果超市,苹果表面均无机械损伤和病虫害。试验采用摆球定损装置制作损伤苹果样本,该装置包括一根长度为 35 cm 的铁质摆杆和一个直径 3 cm、质量 112 g 的金属摆球。铁质摆杆的一端连接水平转轴,另一端连接金属摆球,如图 1a 所示。通过控制铁质摆杆与水平面呈一定夹角,释放金属摆球并使其自由下落。金属摆球下落至最低点时冲击健康苹果,使得苹果发生机械损伤,冲击处苹果表皮无破裂,外观仅出现轻微凹陷,颜色变化不明显,肉眼难以观测。图 1b 对比了苹果健康与损伤组织图像,表皮颜色差异较小,但组织颜色差异较大,损伤组织的颜色明显暗于健康组织。



(a) 摆球定损装置 (b) 苹果健康与损伤组织对比

图 1 摆球定损装置及损伤苹果样本

Fig. 1 Pendulum loss determination device and damaged apple samples

1. 水平旋转轴 2. 铁质摆杆 3. 金属摆球 4. 健康组织 5. 损伤组织

1.2 SIRI 系统搭建

文中所搭建的 SIRI 系统如图 2 所示,该系统主要包括投影仪、摄像机、偏振片、滤光片等。投影仪型号为 NEC NP-CD1100H,其采用 0.65 英寸的 DLP 芯片,分辨率为 1 920 像素 × 1 080 像素,光源类型为高压汞灯,工作功率 240 W,标准工作模式下投影亮度为 3 200 lm,作用是投射结构光图案。摄像机型号为 Basler a2A1920-160 μm PRO,其采用 1/2.3 英寸的 CMOS 芯片,分辨率为 1 920 像素 ×

1 200 像素，安装有焦距为 16 mm 的 M1614－MP2 型镜头，曝光时间设置为 100 ms，作用是采集结构光图像。为了避免镜面反射引起的图像过曝现象，投影仪和摄像机镜头前方均安装了型号为 GSP－50B 的线性偏振片。摄像机镜头前方还安装了型号为 HNIF－010－750－D25、中心波长 700 nm、半带宽 10 nm 的带通滤光片，用于收集经苹果反射的特定波段光线。投影仪和摄像机的光轴夹角约为 15°，整个 SIRI 系统置于暗室内，以避免外界环境光干扰。待测苹果受到金属摆球撞击后 10 min 内，将其置于投影仪正前方约 35 cm 距离处，且位于投影仪和摄像机的公共视场和景深范围内，然后使用 SIRI 系统采集包含苹果隐性损伤信息的结构光图像数据。

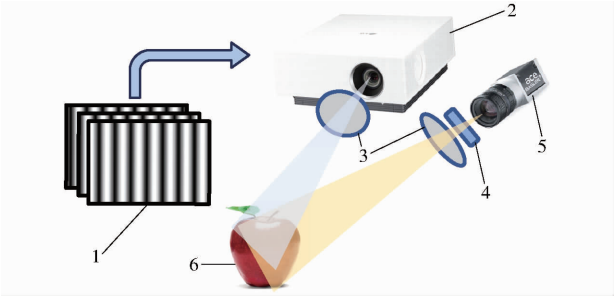


图 2　结构光反射成像原理图

Fig. 2　Schematic of SIRI system

1. 三步相移条纹　2. 投影仪　3. 偏振片　4. 滤光片　5. 摄像机　6. 待测苹果

1.3　结构光图像解调

根据 SIRI 原理，投影仪将 3 幅不同相移量的结构光图案依次投射至待测苹果表面，摄像机同步采集待测苹果调制的结构光图像，其空间频率约为 0.25 mm^{-1}，相移量分别为 0、$2\pi/3$、$4\pi/3$。为了增强苹果隐性损伤，需要对结构光图像进行解调，恢复出直流分量和交流分量。常用的结构光图像解调方法包括三相位解调法[26]、单快照解调法[27]和螺旋相位解调法[28]。本文采用三相位解调法，其不涉及频域运算，解调精度较高。一般地，结构光图像的强度分布可描述为

$$I_1(x,y)=I_{DC}(x,y)+I_{AC}(x,y)\cos(2\pi f_x x) \quad (1)$$

$$I_2(x,y)=I_{DC}(x,y)+I_{AC}(x,y)\cos(2\pi f_x x+2\pi/3) \quad (2)$$

$$I_3(x,y)=I_{DC}(x,y)+I_{AC}(x,y)\cos(2\pi f_x x+4\pi/3) \quad (3)$$

式中　I_1——相移量为 0 的结构光反射图像强度

I_2——相移量为 $2\pi/3$ 的结构光反射图像强度

I_3——相移量为 $4\pi/3$ 的结构光反射图像强度

(x,y)——图像像素坐标

I_{DC}——直流分量

I_{AC}——交流分量

f_x——沿 x 轴方向上的空间频率

联立求解式(1)～(3)，可解调出直流分量 I_{DC} 和交流分量 I_{AC}，即

$$I_{DC}=(I_1+I_2+I_3)/3 \quad (4)$$

$$I_{AC}=\sqrt{2(I_1-I_2)^2+2(I_1-I_3)^2+2(I_2-I_3)^2}/3 \quad (5)$$

图 3 展示了基于三相位解调法的结构光图像解调过程。交流分量 I_{AC} 中隐性损伤区域与周围区域相比较暗，而直流分量 I_{DC} 中隐性损伤区域与周围区域差异不大，因此本文选择交流分量 I_{AC} 作为苹果隐性损伤的判别依据，用于隐性损伤分割模型训练与测试。

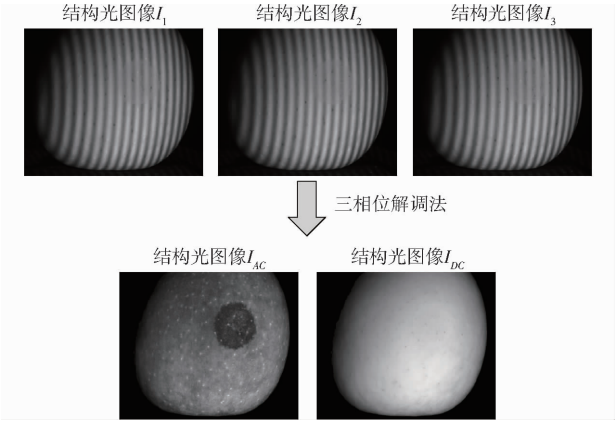


图 3　结构光图像解调

Fig. 3　Structured light image demodulation

1.4　苹果隐性损伤数据集制作

使用 SIRI 系统采集 200 组损伤苹果的结构光图像，经过三相位解调法获得 200 幅交流分量 I_{AC} 图像构建苹果隐性损伤图像数据集。随机选择 80 幅交流分量 I_{AC} 图像作为测试集，并利用剩余 120 幅交流分量 I_{AC} 图像构建训练集。为了提高数据集多样性和模型泛化能力，采用上下翻转、左右翻转、随机旋转(旋转角为 30°～150°和 210°～330°)以及随机缩放(缩放比为 0.5～0.8 和 1.5～2.0)等图像数据增强方法，将训练集的图像数量扩充至 840 幅，部分图像增强实例如图 4 所示。

2　卷积神经网络

2.1　语义分割网络

语义分割是给输入图像的每个像素赋予特定的标签或类别的深度学习算法，本文利用基于 CNN 的语义分割网络，包括 FCN[29]、UNet[30]、HRNet[31]、PSPNet[32]、DeepLabv3＋[33]、LRASPP[34]和 SegNet[35]，实现苹果隐性损伤的语义分割，判断交流分量图像中属于损伤区域的像素，所采用的语义

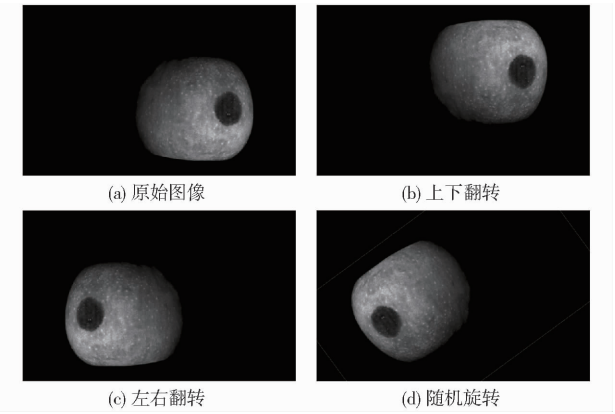


图 4 图像增强实例

Fig. 4 Examples of image enhancement

分割网络概述如下:

FCN 全称是 Fully convolutional network,由 LONG 等[29]于 2015 年提出,通过将传统 CNN 中全连接层替换为全卷积层,并使用跳跃连接来融合多层次特征,实现从输入图像到像素级别预测的端到端映射。

UNet 命名源于其 U 形状的网络结构,由 RONNEBERGER 等[30]于 2015 年提出,利用编码器和解码器捕获多尺度的上下文信息,并通过跳跃连接机制将低级别的细节信息与高级别的语义信息相结合,具有强大的特征表达能力和细节保留能力。

HRNet 全称是 High-resolution network,由 WANG 等[31]于 2020 年提出,通过多分辨率特征融合和自顶向下与自底向上相结合的策略,兼顾具有丰富语义信息的全局特征和具有精确位置信息的局部特征。

PSPNet 全称是 Pyramid scene parsing network,由 ZHAO 等[32]于 2017 年提出,通过金字塔池化和特征融合来实现对图像的细粒度语义分割,有效地利用不同尺度的上下文信息,并具有较大的感受野。

DeepLabv3 + 由谷歌公司研究团队[33]开发,利用空洞空间金字塔池化和编码器-解码器结构来增强语义分割性能,捕获多尺度的上下文信息,保持较高分辨率的特征,是图像分割领域的重要网络模型。

LRASPP 是由 HOWARD 等[34]基于 MobileNetv3 于 2019 年提出,面向语义分割任务的轻量级网络架构,融合了轻量级的空洞卷积模块和密集连接单元,兼具模块化的灵活性和多尺度信息的表达能力。

SegNet 由剑桥大学研究团队[35]开发,通过编码器-解码器结构和最大池化索引实现高效准确的像素级别图像语义分割,保持较高准确性的同时,仅需要较低的计算和内存消耗。

2.2 训练方案设置

本文语义分割网络训练时均未采用预训练模型,仅采用初始随机参数,以公平且准确地评估各个网络在苹果隐性损伤分割任务中的性能和表现。训练轮数(Epoch)设置为 100 轮,批次大小(Batch_size)设置为 8,选择 Adam 算法作为优化器。所采用的图形工作站安装有 Windows 10 操作系统和 PyTorch 深度学习框架,图形处理器 GPU 为 NVIDIA GeForce RTX 4090,显存为 24 GB,中央处理器 CPU 为 Intel Core i9 - 13900KF,内存为 32 GB。

3 试验

3.1 精度和速度评价指标

语义分割网络的精度评价指标包括精确率 P、召回率 R、F1 值和平均交并比(Mean intersection over union,MIoU)。MIoU 数值越高,表示模型分割效果越好。语义分割网络检测速度,即每秒能够处理的图像数量,通常检测速度越快、实时性越好。

3.2 损伤分割定性分析

图 5 展示了 7 种不同语义分割网络在 6 个不同苹果样本的隐性损伤检测结果。对比不同网络的损伤检测结果可以看出,对于不同数量、不同位置、不同分布的苹果隐性损伤,所选的 7 种网络均能够准确识别并分割出苹果隐性损伤区域。

为了更清晰地对比不同语义分割网络的损伤检测效果,图 6 展示了 2 个苹果样本的隐性损伤分割细节,其中图 6 中第 1 行图像与图 5 中第 2 行图像相对应,图 6 中第 2 行图像与图 5 中第 4 行图像相对应。图 6 中灰色部分表示正确分割区域,绿色部分表示错误分割区域,蓝色部分表示未分割区域,所选的 7 种网络在隐性损伤边缘区域均存在细微分割误差。综合来看,尽管存在细微分割误差,但所选的 7 种网络均能有效地分割出绝大部分的苹果隐性损伤区域,实现了对苹果隐性损伤的准确识别与定位。

热力图作为深度学习模型解释性的重要可视化手段,通过不同颜色显示模型对不同区域的响应程度,有助于理解模型关注的视觉模式及决策过程。颜色条可用于反映颜色深浅与响应权重大小的对应关系,颜色越偏红表示该区域响应更高。与图 5 相对应,图 7 展示了 7 种不同语义分割网络的热力图。对比结果表明,对于不同数量、不同位置、不同分布的苹果隐性损伤,所选的 7 种网络对苹果隐性损伤区域均具有较高的响应,损伤区域相对于正常区域热力图颜色对比度明显。

3.3 损伤分割定量评价

为了定量地评价 7 种不同语义分割网络在苹果隐性损伤数据集上的检测效果,表 1 展示了不同语义分割网络的量化结果,包括检测精度指标精确率、

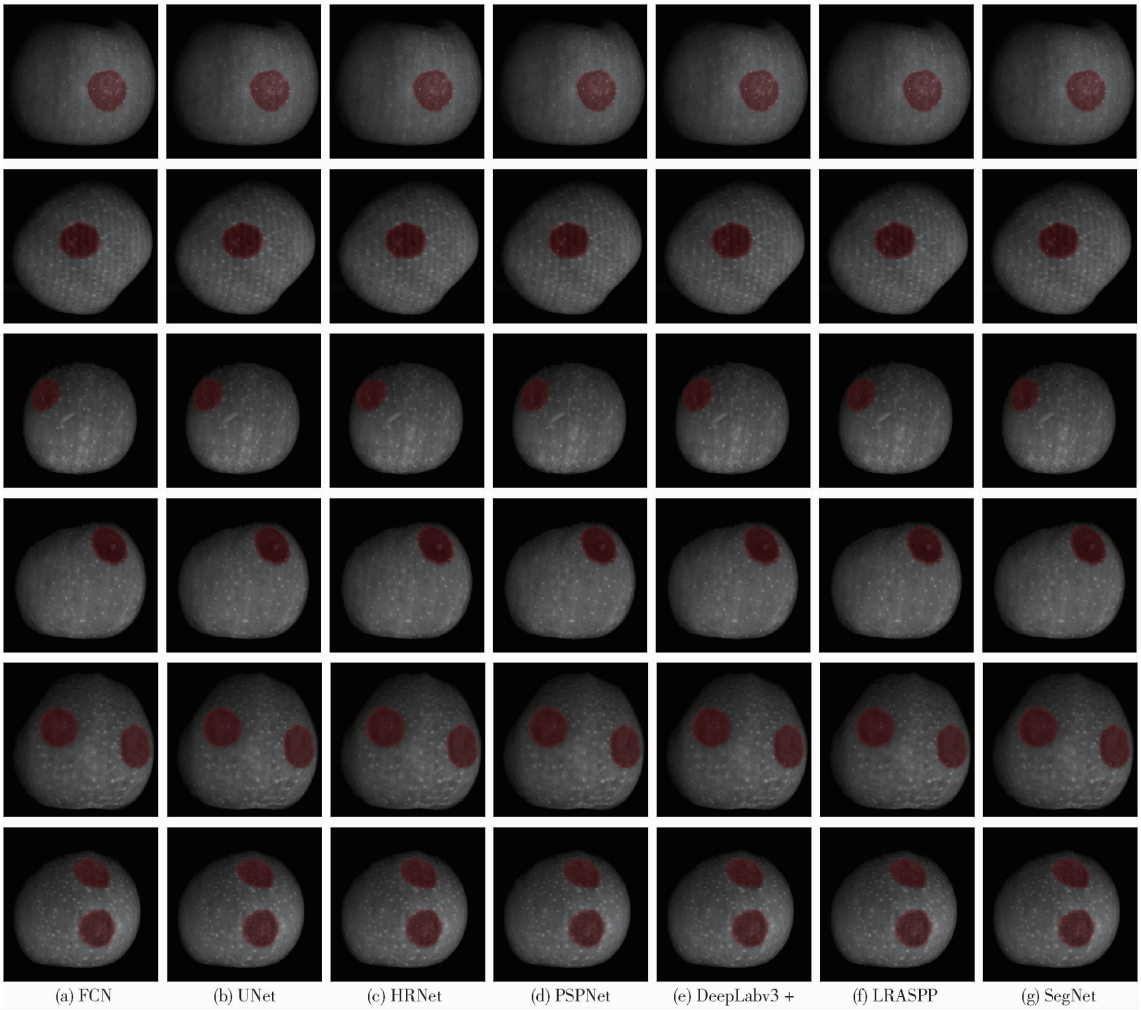


图 5　不同语义分割模型的苹果隐性损伤检测结果

Fig. 5　Implicit apple damage detection results by using different semantic segmentation models

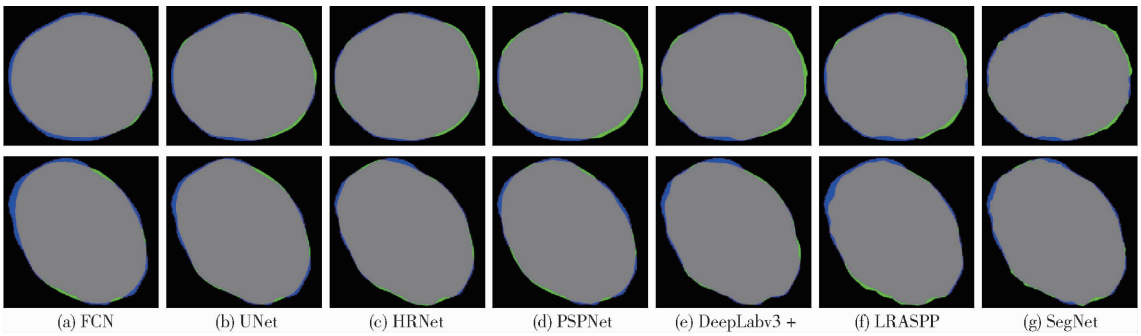


图 6　不同语义分割网络的苹果隐性损伤分割细节对比

Fig. 6　Comparison of implicit apple damage segmentation details by using different semantic segmentation networks

召回率、F1 值、平均交并比和检测速度。每个网络均进行了 3 次独立训练与测试，并计算各项指标的平均值来量化各网络的性能和表现。

检测精度方面，HRNet 整体上优于其他网络，其精确率、召回率、F1 值和平均交并比分别为 97.96%、97.52%、97.74% 和 97.58%，表明 HRNet 对苹果隐性损伤具有较强的识别和定位能力。DeepLabv3 + 的精确率 P 达到了 98.05%，表明 DeepLabv3 + 模型预测的真正例样本精准，模型整体预测性能良好。检测速度方面，PSPNet 优于其他网络，可达到 217 f/s，更适用于实时在线检测。FCN、UNet、HRNet、LRASPP 和 SegNet 这 5 个网络在检测精度和检测速度方面，则取得了较为平衡的效果。

3.4　不同视角的损伤检测试验

为了验证上述语义分割网络对不同视角下苹果隐性损伤的检测效果，将苹果样本放置在旋转台上，每隔 30°旋转一次，并利用 SIRI 系统采集 4 个不同

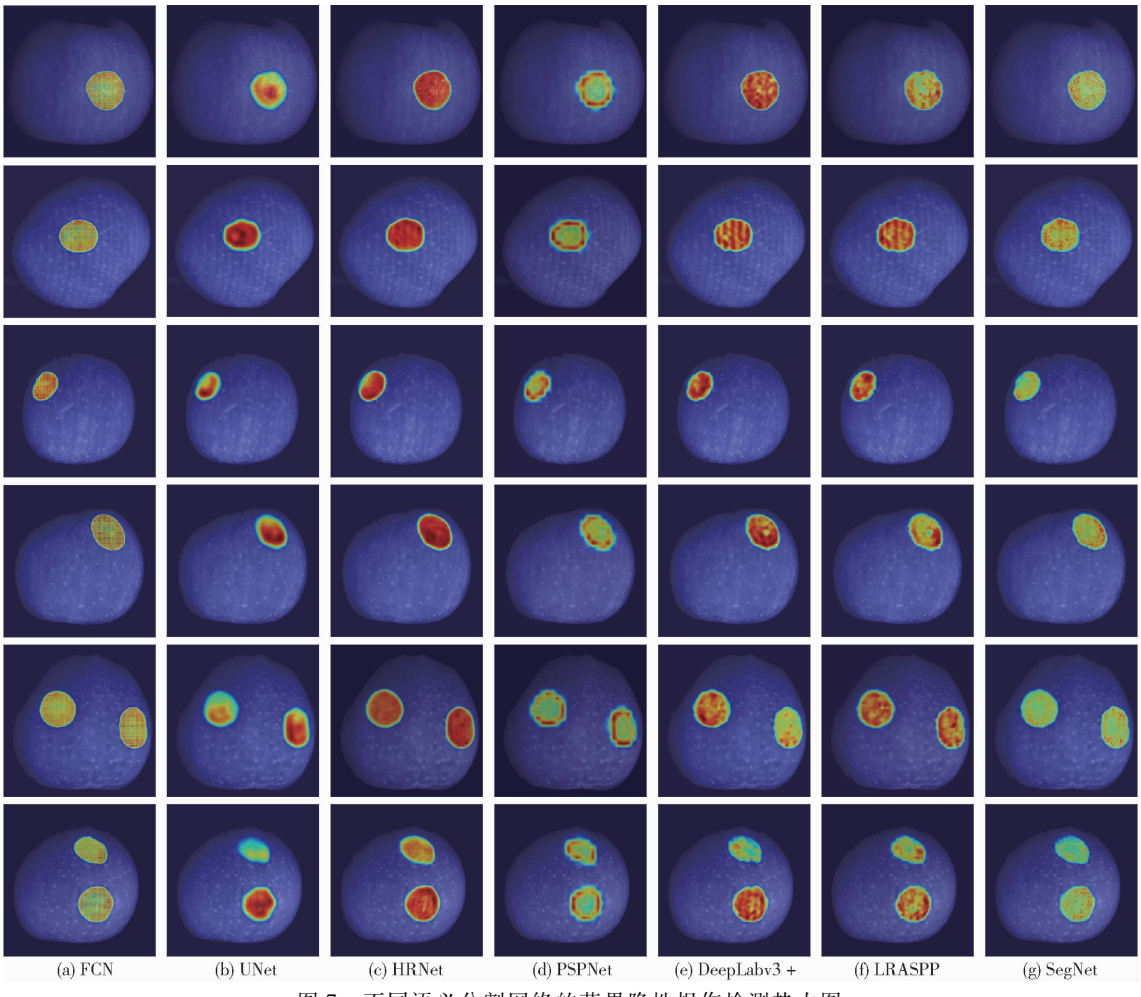


图 7 不同语义分割网络的苹果隐性损伤检测热力图

Fig. 7 Heatmaps of implicit apple damage segmentation by using different semantic segmentation networks

表 1 不同语义分割网络的量化结果

Tab. 1 Quantitative results of different semantic segmentation networks

模型	*P*/%	*R*/%	F1 值/%	MIoU/%	检测速度/(f·s^{-1})
FCN	97.18	94.93	96.04	96.11	154
UNet	97.51	96.61	97.06	97.08	79
HRNet	97.96	97.52	97.74	97.58	60
PSPNet	97.10	94.57	95.82	95.90	217
DeepLabv3 +	98.05	96.82	97.43	97.44	182
LRASPP	97.33	95.40	96.36	96.41	202
SegNet	97.94	97.12	97.53	97.54	95

视角下苹果图像。图 8 展示了不同视角下苹果隐性损伤检测结果,且每 1 行苹果图像对应的拍摄角度都是一致的。试验结果表明,即使损伤区域位于苹果边缘且不易观测时,所选的 7 个网络仍表现出良好的检测效果。

3.5 不同类型的损伤检测试验

为了验证所提方法的适用性,开展了 3 种不同类型的机械损伤试验:通过两个苹果相互挤压产生挤压损伤,通过两个苹果相互碰撞产生碰撞损伤,通过苹果自由落体撞击地面产生跌落损伤。图 9 展示了 3 种不同类型的机械损伤检测效果。其中,第 1 行是挤压损伤;第 2 行是碰撞损伤;第 3 行是跌落损伤。3 种不同类型的机械损伤程度不同,其中挤压损伤的图像颜色较浅,跌落损伤的区域面积较大,且图像颜色深浅不均。试验结果表明,所选的 7 种网络均能够准确识别并分割出不同程度的苹果隐性损伤区域,能够满足实际生产线的检测需求。

4 结论

(1)提出了一种基于结构光反射成像(SIRI)和卷积神经网络(CNN)的苹果隐性损伤检测方法,利用 SIRI 技术和三相位解调法解调出能够增强苹果隐性损伤的结构光图像的交流分量,并利用基于 CNN 的语义分割网络实现苹果隐性损伤区域分割,对于不同数量、不同位置、不同分布的苹果隐性损伤均表现出良好的检测效果,可为构建非接触、准确、快速的苹果隐性损伤检测系统提供技术参考。

(2)共采集 200 组苹果隐性损伤图像数据,其中 120 幅通过数据增强扩增至 840 幅作为训练集,

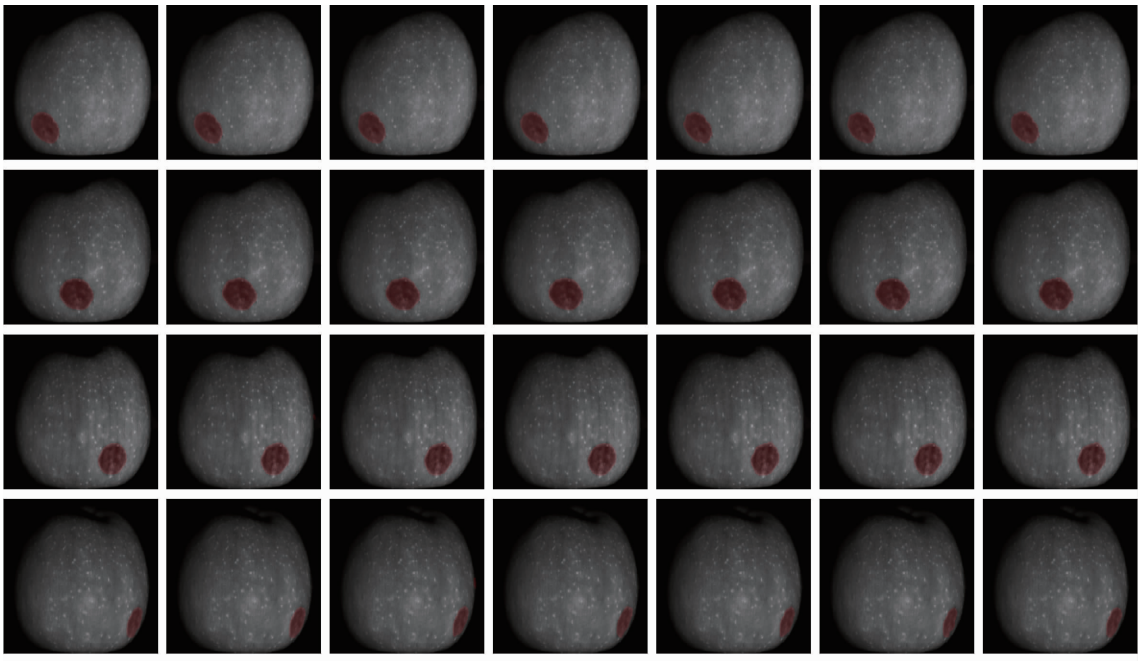


图 8　不同视角下的苹果隐性损伤检测结果

Fig. 8　Implicit apple damage detection results under different perspectives

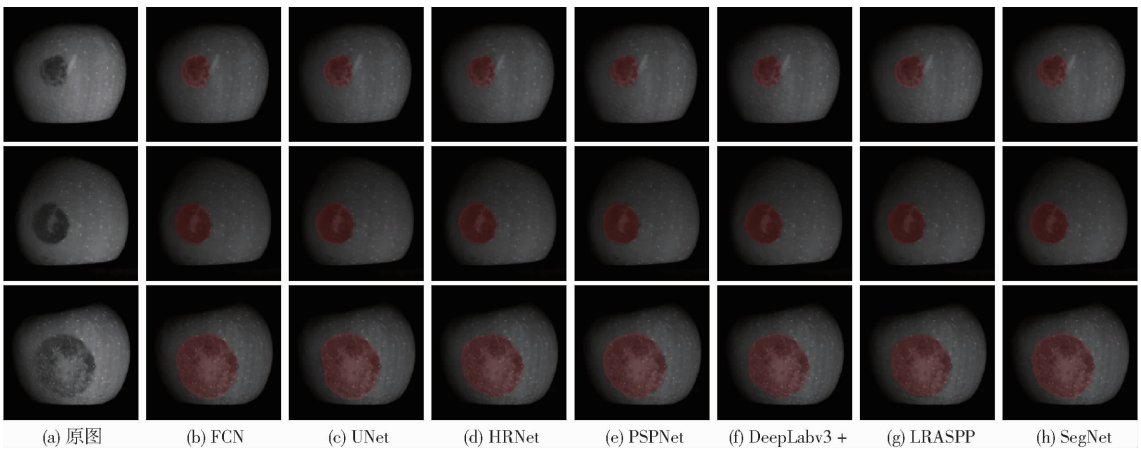


图 9　不同类型的苹果隐性损伤检测结果

Fig. 9　Detection results of different types of apple implicit damages

另外 80 幅作为测试集。利用语义分割网络 FCN、UNet、HRNet、PSPNet、DeepLabv3 + 、LRASPP 和 SegNet 进行训练和测试，试验结果表明上述网络均能准确地检测出苹果隐性损伤。其中 HRNet 的检测精度较高，精确率、召回率、F1 值和平均交并比在测试集分别达到 97.96%、97.52%、97.74% 和 97.58%；PSPNet 的检测速度较高，可达到 217 f/s。可根据实际需求，选择合适的网络模型。

(3)传统多光谱或高光谱成像技术需要采集待测苹果的窄波段连续光谱图像，优选出合适的光谱波段实现苹果隐性损伤检测，虽然检测精度较高，但存在数据量大、信息冗余、数据采集和处理速度较慢等问题；相比之下，基于 SIRI 和 CNN 的方法仅需要采集 3 幅单个波段下结构光图像，数据采集和处理速度较快，同时能够达到较高的检测精度，更适用于实际生产线。

参　考　文　献

[1]　邵志明，王怀彬，董志城，等. 基于近红外相机成像和阈值分割的苹果早期损伤检测[J]. 农业机械学报，2021，52(增刊)：134 – 139.
SHAO Zhiming，WANG Huaibin，DONG Zhicheng，et al. Early bruises detection method of apple surface based on near infrared camera imaging technology and image threshold segmentation method[J]. Transactions of the Chinese Society for Agricultural Machinery，2021，52(Supp.)：134 – 139.(in Chinese)

[2]　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 – 129，148.

GAO Hui, MA Guofeng, LIU Weijie. Research on a rapid detection of apple defects based on mechanical vision[J]. Food & Machinery, 2020, 36(10): 125 - 129,148. (in Chinese)
[3] OPARA U L, PATHARE P B. Bruise damage measurement and analysis of fresh horticultural produce—a review[J]. Postharvest Biology and Technology, 2014, 91: 9 - 24.
[4] HUANG Y, LU R, CHEN K. Detection of internal defect of apples by a multichannel Vis/NIR spectroscopic system[J]. Postharvest Biology and Technology, 2020, 161: 111065.
[5] RONG D, WANG H, YING Y, et al. Peach variety detection using VIS - NIR spectroscopy and deep learning[J]. Computers and Electronics in Agriculture, 2020, 175: 105553.
[6] ZHANG Y, YANG X, CAI Z, et al. Online detection of watercore apples by Vis/NIR full-transmittance spectroscopy coupled with ANOVA method[J]. Foods, 2021, 10(12): 2983.
[7] LI J, LUO W, HAN L, et al. Two-wavelength image detection of early decayed oranges by coupling spectral classification with image processing[J]. Journal of Food Composition and Analysis, 2022, 111: 104642.
[8] LUO W, FAN G, TIAN P, et al. Spectrum classification of citrus tissues infected by fungi and multispectral image identification of early rotten oranges[J]. Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 2022, 279: 121412.
[9] PANG Q, HUANG W, FAN S, et al. Detection of early bruises on apples using hyperspectral imaging combining with YOLOv3 deep learning algorithm[J]. Journal of Food Process Engineering, 2022, 45(2): e13952.
[10] HUANG W, LI J, WANG Q, et al. Development of a multispectral imaging system for online detection of bruises on apples [J]. Journal of Food Engineering, 2015, 146: 62 - 71.
[11] HARA R, ISHIGAKI M, OZAKI Y, et al. Effect of Raman exposure time on the quantitative and discriminant analyses of carotenoid concentrations in intact tomatoes[J]. Food Chemistry, 2021, 360: 129896.
[12] MA T, INAGAKI T, TSUCHIKAWA S. Development of a sensitivity-enhanced chlorophyll fluorescence lifetime spectroscopic method for nondestructive monitoring of fruit ripening and postharvest decay[J]. Postharvest Biology and Technology, 2023, 198: 112231.
[13] LOOVERBOSCH T, HE J, TEMPELAERE A, et al. Inline nondestructive internal disorder detection in pear fruit using explainable deep anomaly detection on X-ray images[J]. Computers and Electronics in Agriculture, 2022, 197: 106962.
[14] LIN P, YANG H, CHENG S, et al. An improved YOLOv5s method based bruises detection on apples using cold excitation thermal images[J]. Postharvest Biology Technology, 2023, 199: 112280.
[15] TIAN S, XU H. Nondestructive methods for the quality assessment of fruits and vegetables considering their physical and biological variability[J]. Food Engineering Reviews, 2022, 14: 380 - 407.
[16] 王忠, 胡栋, 孙志忠, 等. 空间频域成像在农产品品质检测中的应用现状与展望[J]. 农业工程学报, 2021, 37(15): 275 - 288.
WANG Zhong, HU Dong, SUN Zhizhong, et al. Application status and perspective of spatial-frequency domain imaging in quality evaluation of agricultural products[J]. Transactions of the CSAE, 2021,37(15): 275 - 288. (in Chinese)
[17] HU D, FU X, HE X, et al. Noncontact and wide-field characterization of the absorption and scattering properties of apple fruit using spatial-frequency domain imaging[J]. Scientific Reports, 2016, 6(1): 37920.
[18] LU Y, LI R, LU R. Structured-illumination reflectance imaging (SIRI) for enhanced detection of fresh bruises in apples[J]. Postharvest Biology and Technology, 2016, 117: 89 - 93.
[19] HU D, LU R, YING Y. Spatial-frequency domain imaging coupled with frequency optimization for estimating optical properties of two-layered food and agricultural products[J]. Journal of Food Engineering, 2020, 277: 109909.
[20] HE X, HU D, FU X, et al. Spatial frequency domain imaging for determining absorption and scattering properties of bruised pears based on profile corrected diffused reflectance[J]. Postharvest Biology and Technology, 2021, 179: 111570.
[21] SUN Z, XIE L, HU D, et al. An artificial neural network model for accurate and efficient optical property mapping from spatial-frequency domain images[J]. Computers and Electronics in Agriculture, 2021, 188: 106340.
[22] LU Y, LU R, ZHANG Z. Detection of subsurface bruising in fresh pickling cucumbers using structured-illumination reflectance imaging[J]. Postharvest Biology and Technology, 2021, 180: 111624.
[23] LU Y, LU R. Fast bi-dimensional empirical mode decomposition as an image enhancement technique for fruit defect detection [J]. Computers and Electronics in Agriculture, 2018, 152: 314 - 323.
[24] SUN Y, LU R, LU Y, et al. Detection of early decay in peaches by structured-illumination reflectance imaging[J]. Postharvest Biology and Technology, 2019, 151: 68 - 78.
[25] LI J, LU Y, LU R. Detection of early decay in navel oranges by structured-illumination reflectance imaging combined with image enhancement and segmentation[J]. Postharvest Biology and Technology, 2023, 196: 112162.
[26] LU Y, LU R. Structured-illumination reflectance imaging coupled with phase analysis techniques for surface profiling of apples [J]. Journal of Food Engineering, 2018, 232: 11 - 20.
[27] LU Y, LU R. Structured-illumination reflectance imaging for the detection of defects in fruit: analysis of resolution, contrast and depth-resolving features[J]. Biosystems Engineering, 2019, 180: 1 - 15.
[28] LU Y, LI R, LU R. Fast demodulation of pattern images by spiral phase transform in structured-illumination reflectance

imaging for detection of bruises in apples[J]. Computers and Electronics in Agriculture, 2016, 127: 652 – 658.
[29] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431 – 3440.
[30] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]// Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015: 18th International Conference, Proceedings, Part Ⅲ 18. Springer International Publishing, 2015: 234 – 241.
[31] WANG J, SUN K, CHENG T, et al. Deep high-resolution representation learning for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 43(10): 3349 – 3364.
[32] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2881 – 2890.
[33] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]// Proceedings of the European Conference on Computer Vision (ECCV), 2018: 801 – 818.
[34] HOWARD A, SANDLER M, CHU G, et al. Searching for MobileNetv3[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 1314 – 1324.
[35] BADRINARAYANAN V, KENDALL A, CIPOLLA R. Segnet: a deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2017,39(12):2481 – 2495.

(上接第 289 页)

[16] JIANG B, WU Q, YIN X, et al. FLYOLO v3 deep learning for key parts of dairy cow body detection[J]. Computers and Electronics in Agriculture, 2019, 166: 104982.
[17] JOCHER G. YOLO v5 release v6[EB/OL]. 2021 – 10 – 12[2023 – 07 – 06]. https://github.com/ultralytics/YOLOv5/releases.
[18] JOCHER G. Ultralytics YOLOv8[EB/OL]. 2023 – 01 – 11[2023 – 07 – 06]. https://github.com/ultralytics/ultralytics.
[19] WANG Z, PAN W, CUPPENS-BOULAHIA N, et al. Image quality assessment: from error visibility to structural similarity[J]. IEEE Transactions on Image Processing,2004, 13(4): 600 – 612.
[20] WANG C Y, LIAO H Y M, WU Y H, et al. CSPNet: a new backbone that can enhance learning capability of CNN[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020.
[21] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. Transactions on Pattern Analysis & Machine Intelligence, 2014, 37(9): 1904 – 1916.
[22] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2017.
[23] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR),2018.
[24] QIN Z, ZHANG P, WU F, et al. FcaNet: frequency channel attention networks[C]// International Conference on Computer Vision, 2020: 783 – 792.
[25] HU J, SHEN L, ALBANIE S,et al. Squeeze-and-Excitation networks[C]//2019 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2019.
[26] TAN M, PANG R, LE V Q, et al. EfficientDet: scalable and efficient object detection[C]//2020 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2020.
[27] BOLYA D, ZHOU C, XIAO F,et al. YOLACT + + better real-time instance segmentation[C]//2022 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2022.
[28] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R – CNN[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018,42(2):386 – 397.
[29] WOO S, PARK J, LEE J, et al. CBAM: convolutional block attention module[C]//2018 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018.