

# 基于改进 Faster R-CNN 的冬枣新鲜度判别

戴浩天<sup>1</sup> 刘文联<sup>2</sup> 朱美燕<sup>2</sup> 张玲<sup>3</sup> 朱良<sup>2</sup>

(1. 湖北工业大学计算机学院, 湖北 武汉 430068; 2. 华南理工大学食品科学与工程学院, 广东 广州 510640;

3. 广东石油化工学院生物与食品工程学院, 广东 茂名 525000)

**摘要:** [目的] 针对冬枣新鲜度判别需求, 提出一种基于深度学习的判别方法, 将冬枣分为 5 个新鲜度阶段, 旨在提高判别准确性并减少光线反射影响。[方法] 提出了一种结合高效 ResNet、注意力机制与 Faster R-CNN 的冬枣新鲜度判别方法。利用 ResNet 对图像进行卷积处理, 提取全局特征图; 通过通道注意力模块强化关键特征, 结合特征金字塔网络 (FPN) 提取多尺度信息。Faster R-CNN 从中选取候选区域, 经过 ROI 池化后输入全连接层, 通过多角度损失函数优化模型性能。通过硬度、电导率、维生素 C 和多酚含量等理化指标验证模型效果。[结果] 改进的 Faster R-CNN 模型在新鲜度判别上的准确率达到 98.60%。[结论] 改进的 Faster R-CNN 模型在小规模样本下的表现优于现有方法。

**关键词:** 冬枣; 新鲜度判别; Faster R-CNN; 注意力机制; 特征金字塔; 小规模

## Freshness determination of winter jujube based on improved Faster R-CNN

DAI Haotian<sup>1</sup> LIU Wenlian<sup>2</sup> ZHU Meiyan<sup>2</sup> ZHANG Ling<sup>3</sup> ZHU Liang<sup>2</sup>

(1. School of Computer Science, Hubei University of Technology, Wuhan, Hubei 430068, China; 2. School of Food Science and Engineering, South China University of Technology University, Guangzhou, Guangdong 510640, China; 3. College of Biology and Food Engineering, Guangdong University of Petrochemical Technology, Maoming, Guangdong 525000, China)

**Abstract:** [Objective] To propose a deep learning-based method for the freshness determination of winter jujube by dividing the fruit into five freshness stages, aiming to improve determination accuracy and reduce the influence of light reflection. [Methods] In this study, a freshness determination method is proposed for winter jujube by combining an efficient ResNet, an attention mechanism, and Faster R-CNN. First, ResNet is used for convolutional processing on the image to extract the global feature map. Next, key features are enhanced through a channel attention module, and multi-scale features are extracted using a feature pyramid network (FPN). Then, Faster R-CNN selects candidate regions from the features, followed by region of interest (ROI) pooling before inputting to fully connected layers. Therefore, the model performance is optimized through a multi-angle loss function. The model's effectiveness is validated using physicochemical indicators such as hardness, conductivity, as well as vitamin C (VC) and polyphenol content. [Results] In freshness determination, the improved Faster R-CNN model achieves an accuracy of 98.60%. [Conclusion] The improved Faster R-CNN model outperforms existing methods in small-scale samples.

**Keywords:** winter jujube; freshness determination; Faster R-CNN; attention mechanism; feature pyramid; small scale

冬枣因其高经济价值和丰富的营养成分, 已在中国及全球范围内广受欢迎<sup>[1]</sup>。据报道, 2023 年全球冬枣市场的主要价值已达 35 亿美元, 预计到 2030 年将增至 65.3 亿美元, 年均复合增长率为 7.45%<sup>[2]</sup>。推动冬枣需求增长的主要因素包括冬枣在功能性食品的应用扩展, 以及消费者对新鲜冬枣市场的需求。新鲜冬枣富含维生素、钾、

**基金项目:** 广东省重点领域研发计划项目 (编号: 2019B020222001); 茂名市科技计划项目 (编号: 2023S017082)

**通信作者:** 朱良 (1975—), 男, 华南理工大学副教授, 硕士生导师, 博士。E-mail: zhuliang@scut.edu.cn

**收稿日期:** 2024-11-16 **改回日期:** 2025-08-11

**引用格式:** 戴浩天, 刘文联, 朱美燕, 等. 基于改进 Faster R-CNN 的冬枣新鲜度判别[J]. 食品与机械, 2026, 42(1): 93-100.

**Citation:** DAI Haotian, LIU Wenlian, ZHU Meiyan, et al. Freshness determination of winter jujube based on improved Faster R-CNN[J]. Food & Machinery, 2026, 42(1): 93-100.

钠、铁、铜等微量元素,有助于保持血管弹性并降低心血管疾病风险;其丰富的糖类和环磷酸腺苷能够减轻化学药物对肝脏的损害,促进蛋白质合成,适合慢性肝炎患者<sup>[3]</sup>。然而,冬枣的品质和营养成分对新鲜度较为敏感,随着贮藏时间延长,其水分、糖类、多酚类和维生素等成分减少,进而影响其营养价值和风味<sup>[1]</sup>。因此,食品行业亟需准确、无损的检测方法精准评估冬枣新鲜度,以确保冬枣品质和消费者的食用体验<sup>[4]</sup>。

当前冬枣新鲜度的判别研究主要分为两类方法:① 基于物理化学特性的传统检测方法,通常通过测量果实糖分、酸度和硬度等指标来反映其内部品质<sup>[5]</sup>。尽管该方法能提供直接的品质信息,但操作复杂、耗时,且对果实具有破坏性。② 基于图像处理与机器学习算法的非侵入式识别方法<sup>[6]</sup>。随着计算机视觉技术的发展,基于图像处理的非侵入式方法提供了更为高效和自动化的解决方案,能够在避免损害果实的前提下,快速评估新鲜度<sup>[7]</sup>。

近年来,研究人员越来越关注计算机视觉和深度学习在冬枣新鲜度判别中的应用,尤其是通过选择合适的卷积神经网络(convolutional neural network, CNN)模型,以提高特征提取能力和判别精度,实现更低的误差率<sup>[6]</sup>。王铁伟等<sup>[4]</sup>提出了一种基于数据平衡的 Faster R-CNN (region-based convolutional neural networks) 的冬枣识别方法,该方法对片红冬枣识别的平均精度达到 98.50%,模型总损失值低于 0.5。Ban 等<sup>[8]</sup>按照 3 个基础的理化指标(可溶性固形物、总酸和果实穿刺力)对冬枣新鲜度进行识别,将其分为 5 个等级,并使用 ResNet-50 和 iResNet-50 模型对不同成熟度等级的冬枣图片进行训练,改进后的 iResNet-50 模型拥有较高的精确度以及召回率。

在冬枣新鲜度识别中,表面光泽、颜色和纹理等细微的外观差异是关键判别因素<sup>[9]</sup>。通常情况下,仅需关注具体的目标区域,即冬枣的表面特征,而不必依赖复杂的区域生成过程<sup>[10]</sup>。然而, Faster R-CNN 的特征提取依赖于卷积神经网络(如 VGG16 或 ResNet)对整张图像进行一次性提取,对冬枣的局部细节特征缺乏灵活的关注能力,难以动态调整注意力来识别不同新鲜度等级间的细微差异。这导致 Faster R-CNN 在处理模糊边界和相邻新鲜度等级的样本时,特征提取精度不足,从而影响分类准确性<sup>[9]</sup>。此外, Faster R-CNN 依赖的选择性搜索算法在生成候选区域时精度较低,且速度较慢,导致检测效率不高<sup>[11]</sup>。对于需要高效、准确识别冬枣表面特征的任务,选择性搜索的复杂性增加了计算负担,不利于模型的快速响应<sup>[12]</sup>。

为了解决上述问题,研究拟通过引入通道注意力机制增强对表面细微特征的敏感性,利用区域提议网络(RPN)替代选择性搜索以提升检测效率并降低模型复杂度。通过结合硬度、相对电导率、维生素 C 和多酚含量等理化指标进一步验证改进模型的检测精度和可靠性。

## 1 冬枣图像数据集

从市场上购买不同品种的冬枣(如成武冬枣、鲁北冬枣、薛城冬枣、锥木枣、九月青),根据外观色泽将其新鲜度划分为 5 个等级<sup>[13]</sup>(图 1):青果(A 级),果皮变红范围为 0~1/8,整体呈近全绿;初熟果(B 级),果皮变红 1/8~1/4,逐渐显露少量红色斑点,整体呈浅绿或黄绿色;半红果(C 级),果皮变红 1/4~3/4,表皮大面积转红,仍留有少量绿色区域;全红果(D 级),果皮变红 3/4~全部,果实呈现饱满、光滑的全红表皮;软果(F 级),表皮呈深褐或黑褐色,伴随腐烂斑点,严重起皱,甚至出现霉斑,失去商品价值。

在开展研究前,需对数据集进行系统性的收集与预处理,以此获取能够高度贴近真实应用场景的冬枣图像。并且,所有图像的采集均需保证在统一的光照环境下进行,使用 iPhone 15 Pro Max 以统一角度拍摄冬枣照片,并保存为 .jpg 格式。此外,还从互联网收集了不同新鲜度的冬枣图像,以丰富数据来源。训练数据集中共包含 1 200 张图像,每种新鲜度类别包含 400 张,在数据集构建方面,训练集共纳入 150 张冬枣图像,其中源于互联网渠道的有 150 张。验证集由 300 张图像构成,按类别均匀划分,每类各含 100 张,而来自互联网的图像数量为 40 张。测试集包含 90 张图像,同样以类别均分,每类 30 张,互联网采集的图像占 10 张。所有用于试验的图像均经过筛选,确保反映最真实的冬枣新鲜状态。

数据集中图像尺寸统一为 2 400 像素×1 600 像素,比例为 3:2,水平和垂直分辨率均为 72 dpi。图像在预处理中经过了归一化、裁剪和增强处理,以提升模型的泛化性能。尽管未详细列出每种新鲜度类别的图像数量,但在数据准备中尽量确保类别平衡,以避免数据不平衡对新鲜度判别精度的影响。对于从互联网获取的图像,采用了数据增强技术,如旋转、缩放和水平翻转,以扩展训练数据集的多样性。

来自数据集的冬枣样本图像如图 1 所示。

## 2 冬枣新鲜度判别框架

### 2.1 Faster R-CNN 深度学习算法概述

Faster R-CNN 算法是一种基于卷积神经网络的快速目标检测算法,主要由特征提取网络、候选区域生成网络和目标检测网络共同组成<sup>[14]</sup>。

Faster R-CNN 算法的运行过程主要由 3 个阶段组成:① 将原始图像数据输入卷积神经网络,通过网络的层层运算提取出对应的特征图;② 所生成的特征图会被传递至区域建议网络(RPN),RPN 基于特征图生成潜在的目标候选框,并将这些候选框映射回特征图,以此获取相应的特征矩阵;③ 将每个样本重新投射到整幅图像的特征图中,进而得到用于目标检测与识别的区域特征图,再经过感兴趣区域池化层(RoI pooling)调整尺寸,输入分类网

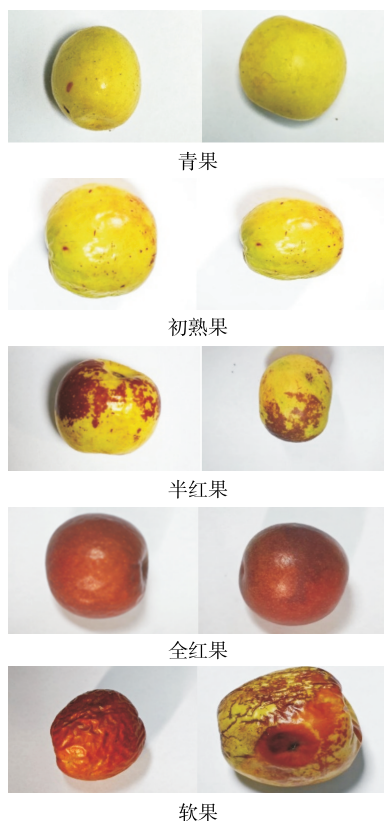


图1 冬枣样本图像

Figure 1 Winter jujube sample images

络和回归网络完成该候选框的分类和预测。

Faster R-CNN 还提供了损失函数计算, Faster R-CNN 的损失为 RPN 的损失和 Fast R-CNN 的损失的和 (Fast R-CNN 是 Ross Girshick 在 Faster R-CNN 之前提出的算法, 如图 2 所示), Fast R-CNN 的损失计算如式 (1) 所示; RPN 的损失计算如式 (2) 所示。损失函数 (1) 是 Faster R-CNN 单样本的多任务损失函数, 融合分类损失与定位损失, 用于衡量 Faster R-CNN 在冬枣新鲜度分类任务中的表现。具体来说, 它确保模型能够准确分类 5 种新鲜度类别 (青果、初熟果、半红果、全红果、软果), 并减少错误

分类 (在没有 softmax 的情况下, 模型可能会错误地将“半红果”识别为“初熟果”); 损失函数 (2) 是 Faster R-CNN 批量样本的多任务损失函数, 用于优化目标边界框的定位精度, 使检测框能够更准确地拟合目标冬枣的真实位置 (避免框偏移、框过大或过小等问题)。

$$L(p, u, t^u, v) = L_{\text{cls}}(p, u) + \lambda [u \geq 1] L_{\text{loc}}(t^u, v), \quad (1)$$

$$L(p_i, t_i) = \frac{1}{N_{\text{cls}}} \sum_i L_{\text{cls}}(p_i, p_i^*) + \lambda \frac{1}{N_{\text{reg}}} \sum_i p_i^* L_{\text{reg}}(t_i, t_i^*), \quad (2)$$

式中:

$p$ ——分类器预测的 softmax 概率分布,  $p = (p_0, \dots, p_k)$ ;

$u$ ——目标真实类别的标签 (若候选框对应目标类别, 则  $u=1$ );

$t^u$ ——对应边界框回归器预测的对应类别  $u$  的回归参数 ( $t_{ux}, t_{uy}, t_{uw}, t_{uh}$ );

$v$ ——对应真实目标的边界框回归参数 ( $v_x, v_y, v_w, v_h$ );

$p_i$ ——第  $i$  个 anchor 预测为真实标签的概率;

$p_i^*$ ——正样本时为 1, 负样本时为 0;

$t_i$ ——预测第  $i$  个 anchor 的边界框回归参数;

$t_i^*$ ——第  $i$  个 anchor 的 GT Box;

$N_{\text{cls}}$ ——单个 mini-batch 的所有样本数量, 256;

$N_{\text{reg}}$ ——anchor 位置的个数 (不是 anchor 个数), 约 2 400。

## 2.2 Faster R-CNN 算法的优化与实现

为了提高已有的冬枣新鲜度判别准确率, 且结合当前冬枣表皮反光容易造成识别困难等实际问题, 对 Faster R-CNN 算法进行优化与改进, 主要包括 3 个部分: ① 将特征提取网络更换为 ResNet-50 网络, 提高特征提取能力; ② 引入注意力机制 (convolutional block attention module, CBAM), 从而使特征覆盖到冬枣的更多部位, 使识别更精准; ③ 引入特征金字塔进行多尺度特征融合<sup>[15]</sup>。

**2.2.1 ResNet-50 特征提取网络** Faster R-CNN 的特征提取网络使用的是 VGG16, VGG16 使用多个较小卷积核的卷积层代替一个卷积核较大的卷积层, 在减小参数的

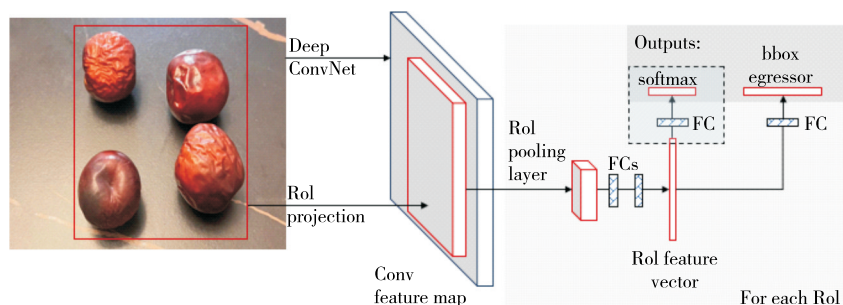


图2 Fast R-CNN 网络结构图

Figure 2 Fast R-CNN network architecture

同时,进行更多的非线性映射,加深网络的层数,从而提高网络的拟合能力,但是由于过多的加深网络层次,VGG16会消耗更多的计算资源,内存占用过大,梯度爆炸等问题也随之出现<sup>[16]</sup>。

为了更好地应对上述问题,引入了残差模块的

ResNet-50 卷积神经网络对图像的特征进行提取。ResNet-50 结构如图 3 所示<sup>[17]</sup>,从接收 $[224, 224, 3]$ 的图像,通过 4 组大的 block,每组分别有 3, 4, 6, 3 个小的 block,每个小的 block 又包含 3 个卷积层,最后再经过 1 个全连接层,最终输出图像。

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
conv2_x	56×56	3×3 max pool, stride 2				
		$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		$1.8 \times 10^9$	$3.6 \times 10^9$	$3.8 \times 10^9$	$7.6 \times 10^9$	$1.13 \times 10^{10}$

图 3 ResNet 架构图

Figure 3 ResNet architecture

神经网络训练过程是不断与目标值进行拟合的过程,直到拟合的误差降低到人们的预期,代表着神经网络训练完毕,但是在实际训练过程中,数据的传递除了从网络前端往后传之外,还需要将最后一层与目标值的误差传回到网络前端,从而进行下一轮的训练,得到更小的误差,这一过程成为神经网络的反向传播。如果卷积层数过多,在经过激活函数时,就会出现梯度消失的问题。ResNet-50 的残差结构(如图 4 所示)通过将网络的输出变为卷积的输出与前面输入的叠加解决了这个问题。其核心思想是在每个残差块中引入 1 条快捷连接(skipconnection),跳过 1 个或多个层,将输入直接传递到输出。

2.2.2 ECA 注意力模块 ECA (efficient channel attention) 模块<sup>[18]</sup>是对 SE (squeeze-and-excitation) 模块<sup>[19]</sup>的改进版本,其结构如图 5 所示。在特征处理与优化领域,

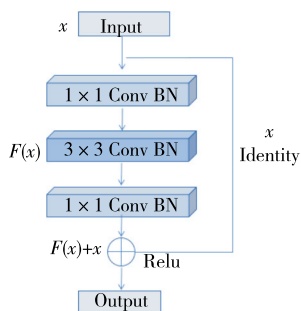


图 4 ResNet-50 残差示意图

Figure 4 ResNet-50 residual

ECA 模块设计了独特的局部跨通道交互机制,该机制摒弃了传统的降维操作。具体而言,该模块先通过全局平均池化(GAP),将注意力集中在每个通道及其周边  $k$  个相邻通道,从而实现局部范围内通道间交互信息的捕捉。其具体运行流程:对输入的特征图实施空间维度压缩,将其转化为  $1 \times 1 \times C$  规格的特征图;运用动态卷积核开展一维卷积运算,在运算过程中深入挖掘通道间的关联性,并通过预设的卷积核自适应函数,精确计算并选择合适的  $k$  值,以此明确跨通道交互的覆盖范围。在完成交互信息提取后,ECA 模块借助激活函数生成通道权重,并将其与原始输入特征图进行逐通道乘法运算,最终输出带有通道注意力机制的特征图,大幅提升模型对有效特征的提取能力。这种革新设计让 ECA 模块不用再降低通道维度,便能帮助模型学习到更为高效的通道注意力。此外,由于模块结构简洁,其含参量主要由卷积核大小  $k$  决定,因而具备轻量化的显著优势。其公式如式(3)所示。

$$k = \psi(C) = \left\lfloor \frac{\ln(C) + b}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}}, \quad (3)$$

式中:

$k$ ——卷积核大小;

$C$ ——通道数;

$b$ ——超参数;

$\gamma$ ——超参数。

用  $\gamma, b$  超参数缩放调整  $C$  和  $k$  之间的比例,通常将取值定为  $\gamma=2, b=1$ 。

研究提出将具有低复杂度与高效能特性的ECA模块集成至ResNet50骨干网络架构中,通过增强模型对特征的表达能力,实现目标识别与定位精度的双重提升。

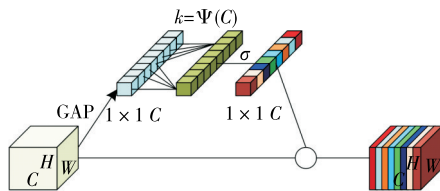


图5 ECA 注意力模块

Figure 5 ECA attention module

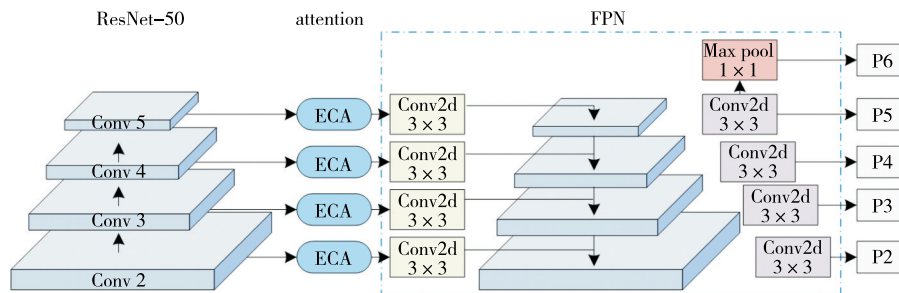


图6 多尺度特征融合FPN结构图

Figure 6 Multi-scale feature fusion FPN architecture

ResNet-50共有4个残差块(C2、C3、C4、C5),将残差块输出的特征图像送入ECA模块借助特征矫正与滤波手段,增强ResNet-50网络提取出的有效特征信息的权重占比,进而实现对图像通道权重信息的精准标定。经筛选后的特征将被输入至FPN结构中进一步处理,然后自顶向下传递信息,FPN通过上采样(up-sampling)操作,将高层特征(如C5)上采样至与较低层特征(如C4)相同的空间尺寸,并与C4进行逐元素相加(element-wise addition),形成新的特征层P4。依次处理C3、C2,最终形成完整的特征金字塔(P2、P3、P4、P5)。FPN最后输出的P2、P5与ResNet-50中的C2、C5一一对应,再对P5最大池化得到更高层次的抽象特征P6,最后将P2、P6输入RPN,开始查找ROI。高层特征图(如P5)适用于检测较大目标(如近距离冬枣),而低层特征图(如P2)适用于较小目标(如远处冬枣)。因此,FPN能够在不同尺度上提取有效的目标信息,提高检测精度。

### 3 模型训练与试验

#### 3.1 试验环境与参数设置

试验运行环境见表1。基于既往研究成果与多次经验性测试,最终确定的试验参数配置见表2。在目标检测判定标准方面,当预测框与真实框的交并比(IoU)达到设定阈值时,即判定为成功检测到目标物体。在模型训练环节,选用随机梯度下降(SGD)算法作为优化策略,设定

2.2.3 特征金字塔网络(FPN) 在实际应用中,冬枣的大小和外观差异可能会很明显,使得检测算法在面对不同尺度的目标时易出现遗漏或误判,为了解决这个问题,引入了经典的特征金字塔网络FPN<sup>[20]</sup>来处理检测中的多尺度问题,FPN在各尺度上都具有强语义的特征,FPN的核心思想是在不同尺度的特征图上构建高分辨率到低分辨率的金字塔结构,使高层特征能够保留更多全局信息,而低层特征则包含更丰富的细节信息,从而提升检测精度。将该模块与ResNet-50网络进行有机融合,深度挖掘ResNet-50在不同阶段提取的特征信息,进而搭建起多尺度特征金字塔网络FPN架构,如图6所示。

每完成4个训练周期,学习率自动衰减10%。

#### 3.2 评价指标与结果

3.2.1 模型的评价指标 在模型训练初期,由于迭代次数较少,容易出现过拟合问题,导致较高的误检率和漏检率。例如模型可能会错误地将树叶识别为冬枣,或者无法正确检测到部分冬枣。随着训练迭代的增加,冬枣的

表1 试验环境的硬件与软件配置

Table 1 Hardware and software configuration of the experimental environment

名称	参数
CPU	Intel(R) Core(TM) i7-11800H @ 2.30GHz
GPU	NVIDIA GeForce RTX 3060
操作系统	Windows 11
深度学习框架	Anaconda3+PyTorch

表2 试验参数

Table 2 Experimental parameters

网络模型参数变量	参数描述	参数值
classes num	目标类别	5
lr	初始学习率	0.001
batch size	批尺寸	8
epoch	训练次数	50
IoU	交并比阈值	0.5

平均识别准确率逐步提升,误检率和漏检率也相应减少<sup>[21]</sup>。同时,模型的损失函数值逐渐下降,表明模型在不断优化。当迭代次数达到某一临界点时,损失值趋于最低,之后即便进一步增加迭代次数,损失值也不会再显著变化<sup>[4]</sup>。

使用平均精度(average precision, AP)和平均精度的均值(mean average precision, mAP)作为冬枣新鲜度判别的评价指标,平均精度与准确率、召回率有关,平均精度的计算式:

$$I_{AP} = \int_0^1 PRdR \times 100\%, \quad (4)$$

$$P = \frac{T_p}{T_p + F_p} \times 100\%, \quad (5)$$

$$R = \frac{T_p}{T_p + F_n} \times 100\%, \quad (6)$$

式中:

$I_{AP}$ ——平均精度, %;

$P$ ——精确率, %;

$R$ ——召回率, %;

$T_p$ ——被正确划分到正样本的数量;

$F_p$ ——被错误划分到正样本的数量;

$F_n$ ——被错误划分到负样本的数量。

3.2.2 模型的识别结果分析 数据平衡采用数据扩增的方式,将各个新鲜度的冬枣图片进行扩增,共扩增出 1 200 张图像,使用冬枣数据集分别用 YOLOv3、Faster R-CNN 和改进后的 Faster R-CNN 模型进行训练,显示测试的结果如图 7 和表 3 所示, YOLOv3、Faster R-CNN 和改进后的 Faster R-CNN 对 5 个新鲜度的冬枣判别平均精度分别为 90.52%, 88.45%, 90.07%, 90.43%, 91.23%; 92.74%, 93.11%, 92.74%, 93.26%, 92.36%; 98.60%, 95.79%, 96.89%, 96.92%, 96.26%, 应用改进后的各个数据集的平均精度均有上升,最高值达到了 98.60%。

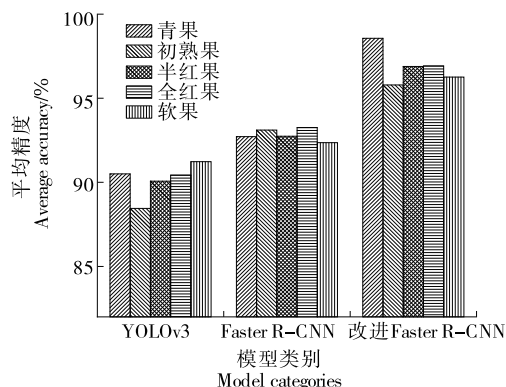


图 7 3 种模型冬枣判别的平均精度

Figure 7 Average accuracy of winter jujube determination using three models

表 3 不同网络模型对比

Table 3 Comparison of different network models

改进方式	AP/%					mAP/%
	青果	初熟果	半红果	全红果	软果	
YOLOv3	90.52	88.45	90.07	90.43	91.23	90.14
Faster R-CNN	92.74	93.11	92.74	93.26	92.36	92.84
改进Faster R-CNN	98.60	95.79	96.89	96.92	96.26	96.89

为了评估改进的 Faster R-CNN 模型在冬枣新鲜度判别任务中的训练效果,绘制了训练损失和验证损失曲线,如图 8 所示。

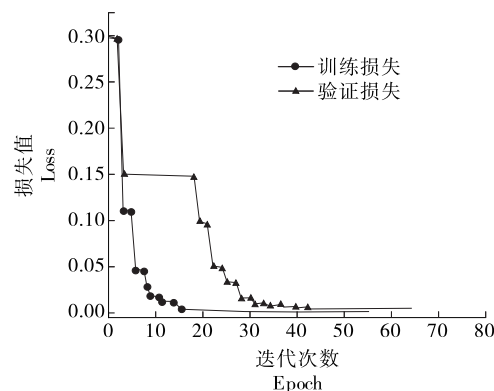


图 8 训练损失和验证损失曲线图

Figure 8 Training loss and validation loss curves

训练损失和验证损失均随着训练轮次的增加而下降,表明模型在持续优化。训练到第 35 轮(Epoch 35)左右时,损失值趋于稳定,说明模型已经收敛,未出现明显的过拟合现象。最终训练损失收敛至 0.010,验证损失收敛至 0.015,表明改进后的 Faster R-CNN 在该任务上的表现较好。

### 3.3 改进 Faster R-CNN 模型检测后冬枣的理化指标

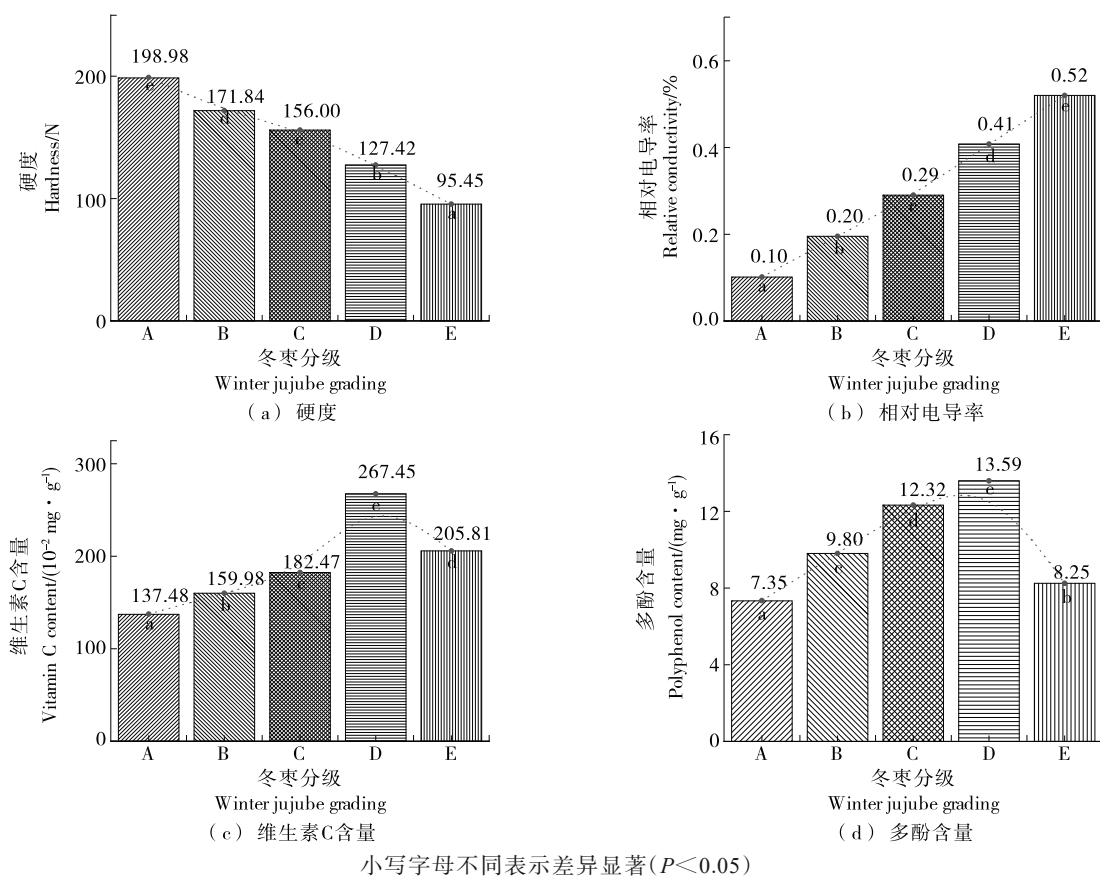
在冬枣的贮藏过程中,果肉逐渐软化、结构破损,导致果实硬度显著下降,内部细胞液渗漏至外部。此外,随着贮藏时间的延长,冬枣中的氧化反应和变质过程加剧,导致维生素 C 和多酚含量逐渐减少<sup>[7]</sup>。因此,通过监测果实硬度、相对电导率、维生素 C 含量和多酚含量 4 个理化指标,可以较全面地反映冬枣的新鲜度、营养价值及其抗氧化性能的变化<sup>[22]</sup>。

图 9 显示了经改进的 Faster R-CNN 模型分级筛选后的冬枣在上述理化指标上的变化趋势。具体而言,硬度在新鲜度下降(从 A~E 级)过程中逐渐减弱,从 198.98 N 降至 95.45 N,表明冬枣在贮藏过程中逐步软化,结构强度下降,尤其在 E 级(软果)时表皮和果肉的结构发生了显著变化,以此硬度为冬枣新鲜度的重要判别指标。相对电导率随新鲜度的降低逐渐增大,从 A 级的 0.10% 增至 E 级

的0.52%,反映出细胞膜完整性的损伤程度。随着细胞膜破损,电解质渗漏增加,电导率上升,这也是冬枣新鲜度的敏感指标<sup>[23]</sup>。维生素C含量在不同新鲜度等级间呈先升后降的趋势,从A级的137.48 mg/100 g增至D级的267.45 mg/100 g,之后在E级降至205.81 mg/100 g,表明维生素C含量的变化受冬枣成熟和氧化代谢影响<sup>[24]</sup>。多酚含量也表现出相似趋势,从A~D级逐步增至13.59 mg/g,随后在E级降至8.25 mg/g,反映了多酚在成熟期积累而

在贮藏后期因氧化降解而减少,这与Yu等<sup>[25]</sup>的研究类似。

综上所述,改进后的Faster R-CNN模型筛选分级出的冬枣在硬度、相对电导率、维生素C含量和多酚含量方面均表现出显著的变化趋势( $P<0.05$ ),各新鲜度等级间差异显著。同时,同组数据的标准误差小于均值的5%,表明具有统计学一致性。上述结果间接验证了改进的Faster R-CNN模型在冬枣新鲜度分级中的准确性,证明其在不同新鲜度等级的区分上具备较高的可靠性。



小写字母不同表示差异显著 ( $P<0.05$ )

图9 不同新鲜度冬枣的理化指标

Figure 9 Physicochemical indicators of winter jujube at different freshness stages

## 4 结论

该研究提出了一种基于改进Faster R-CNN的冬枣新鲜度判别方法,显著提升了新鲜度分级的准确性。通过引入ResNet-50作为特征提取网络,并结合通道注意力机制ECA和特征金字塔网络FPN,该模型在小规模数据集上表现出优异性能,分级准确率达98.60%。此外,通过硬度、相对电导率、维生素C含量和多酚含量等理化指标,验证了分级后的青枣的理化差异。该方法不仅适用于小规模数据集,还在青果、初熟果、半红果、全红果、软果5个新鲜度等级的分级上展现了较强的泛化能力。与传统理化检测方法相比,该方法具备非侵入性、操作便捷、自动

化程度高等优点,能够帮助农产品管理者在库存管理中实现冬枣的实时保鲜监测,具有广泛的应用前景<sup>[26]</sup>。未来研究可进一步扩大数据集规模,结合更多环境因素,并探索该方法在其他果蔬新鲜度判别上的应用,以推动农产品质量控制和供应链管理的优化。

## 参考文献

- [1] LU Y, BAO T, MO J L, et al. Research advances in bioactive components and health benefits of jujube (*Ziziphus jujuba* Mill.) fruit[J]. Journal of Zhejiang University-Science B, 2021, 22(6): 431-449.
- [2] CAI W T, ZHUANG H N, WANG X Y, et al. Functional

- nutrients and jujube-based processed products in *Ziziphus jujuba* [J]. *Molecules*, 2024, 29(14): 3 437.
- [3] HUA Y, XU X X, GUO S, et al. Wild jujube (*Ziziphus jujuba* var. *spinosa*): a review of its phytonutrients, health benefits, metabolism, and applications[J]. *Journal of Agricultural and Food Chemistry*, 2022, 70(26): 7 871-7 886.
- [4] 王铁伟, 赵瑶, 孙宇馨, 等. 基于数据平衡深度学习的不同成熟度冬枣识别[J]. *农业机械学报*, 2020, 51(S1): 457-463, 492.  
WANG T W, ZHAO Y, SUN Y X, et al. Recognition approach based on data-balanced Faster R-CNN for winter jujube with different levels of maturity[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2020, 51(S1): 457-463, 492.
- [5] 韩乃瑄, 曹颖, 刘晓敏, 等. 冬枣保鲜技术的研究进展[J]. *食品工业科技*, 2022, 43(21): 414-421.  
HAN N X, CAO Y, LIU X M, et al. Research progress on preservation technology of *Ziziphus jujuba* Mill. cv. Dongzao[J]. *Science and Technology of Food Industry*, 2022, 43(21): 414-421.
- [6] WU J M, WU C Y, GUO H Y, et al. Research on red jujubes recognition based on a convolutional neural network[J]. *Applied Sciences-Basel*, 2023, 13(11): 6 381.
- [7] DOU J F, KOU X H, WU C E, et al. Recent advances and development of postharvest management research for fresh jujube fruit: a review[J]. *Scientia Horticulturae*, 2023, 310: 111769.
- [8] BAN Z J, FANG C Y, LIU L L, et al. Detection of fundamental quality traits of winter jujube based on computer vision and deep learning[J]. *Agronomy-Basel*, 2023, 13(8): 2 095.
- [9] MAHMOOD A, SINGH S K, TIWARI A K. Pre-trained deep learning-based classification of jujube fruits according to their maturity level[J]. *Neural Computing and Applications*, 2022, 34 (16): 13 925-13 935.
- [10] ZHANG J J, WANG W H, CHE Q L. Innovative research on intelligent recognition of winter jujube defects by applying convolutional neural networks[J]. *Electronics*, 2024, 13(15): 2 941.
- [11] ZHENG Z Z, HU Y H, QIAO Y C, et al. Real-time detection of winter jujubes based on improved YOLOX-nano network[J]. *Remote Sensing*, 2022, 14(19): 4 833.
- [12] LU Z H, ZHAO M F, LUO J, et al. Design of a winter-jujube grading robot based on machine vision[J]. *Computers and Electronics in Agriculture*, 2021, 186: 106170.
- [13] ZHANG B, LIN X D, ZHANG X M, et al. Research on jujube storage and preservation system based on Internet of Things (IoT)[J]. *Scientific Reports*, 2024, 14(1): 19808.
- [14] 周诗捷, 王玉槐, 沈思橙, 等. 基于改进型 Faster R-CNN 的仓储环境物体识别技术研究[J]. *计算技术与自动化*, 2024, 43 (2): 187-191.  
ZHOU S J, WANG Y H, HEN S C, et al. Research on object recognition in warehouse environment based on improved Faster R-CNN[J]. *Computing Technology and Automation*, 2024, 43(2): 187-191.
- [15] 黎冠, 李志伟, 陈浩, 等. 基于改进 YOLOv5s 的轻量化安全帽佩戴检测算法[J]. *华北科技学院学报*, 2024, 21(3): 32-41.  
LI G, LI Z W, CHEN H, et al. Lightweight helmet wearing detection algorithm based on improved YOLOv5s[J]. *Journal of North China Institute of Science and Technology*, 2024, 21 (3): 32-41.
- [16] 谭鹤群, 李玉祥, 朱明, 等. 通过图像增强与改进 Faster-RCNN 网络的重叠鱼群尾数检测[J]. *农业工程学报*, 2022, 38 (13): 167-176.  
TAN H Q, LI Y X, ZHU M, et al. Detecting overlapping fish population using image enhancement and improved Faster-RCNN networks[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2022, 38(13): 167-176.
- [17] SHAFIQ M, GU Z Q. Deep residual learning for image recognition: a survey[J]. *Applied Sciences-Basel*, 2022, 12 (18): 8 972.
- [18] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA: IEEE, 2020: 11 531-11 539.
- [19] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Salt Lake City, UT: IEEE, 2018: 7 132-7 141.
- [20] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// 2017 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI: IEEE, 2017: 936-944.
- [21] LI S L, ZHANG S J, XUE J X, et al. A fast neural network based on attention mechanisms for detecting field flat jujube [J]. *Agriculture-Basel*, 2022, 12(5): 717.
- [22] GUO X H, GUO Y D, YU J T, et al. X-ray irradiation-nonthermal processing and preservation of fresh winter jujube (*Zizyphus jujuba* Mill. cv. Dalidongzao) [J]. *Innovative Food Science & Emerging Technologies*, 2022, 81: 103151.
- [23] NAVEED F, NAWAZ A, ALI S, et al. Xanthan gum coating delays ripening and softening of jujube fruit by reducing oxidative stress and suppressing cell wall polysaccharides disassembly[J]. *Postharvest Biology and Technology*, 2024, 209: 112689.
- [24] WANG L M, ZHANG J, YUN X Y, et al. Effect of poly (*L*-lactic acid)/poly (ethylene glycol)-poly (*L*-lactic acid) block copolymer blend film on preservation of Chinese winter jujube (*Ziziphus jujuba* Mill. cv. Dongzao) [J]. *International Journal of Biological Macromolecules*, 2023, 253: 126216.
- [25] YU Y Y, XU Y J, WEN J, et al. Prunus mume polyphenols maintains the quality and nutrient values of winter jujube (*Zizyphus jujuba* Mill.) fruits during storage[J]. *CYTA-Journal of Food*, 2021, 19(1): 552-559.
- [26] MAHMOOD A, TIWARI A K, SINGH S K. Maturity grading of jujube for industrial applications harnessing deep learning [J]. *Engineering Computations*, 2024, 41(5): 1 171-1 184.