

DOI: 10.13652/j.spjx.1003.5788.2025.60003

基于改进 YOLOv11 与 GWO-ELM 的食品生产线黄桃自动分级方法

彭永杰¹ 赵良军² 龙绪明³(1. 宜宾职业技术学院, 四川 宜宾 644001; 2. 四川轻化工大学, 四川 宜宾 644001;
3. 西南交通大学, 四川 成都 610016)

摘要: [目的] 提高食品生产线黄桃自动分级方法的准确率和效率。[方法] 在黄桃自动分级系统(机器视觉和高光谱技术)的基础上, 提出一种融合改进 YOLOv11 与改进极限学习机的黄桃品质自动检测方法。外部品质图像通过 CMOS 传感器相机进行采集, 通过改进 YOLOv11 模型识别缺陷, 并结合果型指数与色泽判定外部品质。内部品质则通过高光谱仪采集, 经特征筛选后, 输入改进灰狼算法优化的极限学习机模型中检测可溶性固形物和硬度指标判定内部品质。结合外部品质和内部品质对黄桃进行分级。通过试验对其性能进行验证。[结果] 试验方法可以实现食品生产线黄桃内外品质的有效检测, 综合内部品质具有较高的分级准确率和效率, 分级准确率大于 95.00%, 平均分级时间小于 0.3 s。[结论] 将机器视觉、高光谱技术以及智能算法相结合, 可实现食品品质的快速无损检测。

关键词: 食品生产线; 黄桃; 自动分级; 机器视觉; 高光谱技术; YOLOv11; 极限学习机

Automatic grading method of yellow peaches on food production line based on improved YOLOv11 and GWO-ELM

PENG Yongjie¹ ZHAO Liangjun² LONG Xuming³

(1. Yibin Vocational and Technical College, Yibin, Sichuan 644001, China; 2. Sichuan University of Science & Engineering, Yibin, Sichuan 644001, China; 3. Southwest Jiaotong University, Chengdu, Sichuan 610016, China)

Abstract: [Objective] To improve the accuracy and efficiency of the automatic grading method for yellow peaches on the food production line [Methods] Based on the yellow peach automatic grading system (machine vision and hyperspectral technology), a new method for automatic detection of yellow peach quality is proposed, which integrates an improved YOLOv11 and an improved extreme learning machine (ELM). External quality images are captured by a CMOS sensor camera, and defects are identified using the improved YOLOv11 model. The external quality is determined by the fruit shape index and color. Internal quality is detected using a hyperspectral instrument, and after feature selection, the data is input into an ELM model optimized by an improved grey wolf algorithm to detect soluble solids and hardness as internal quality indicators. The yellow peach is graded based on both external and internal qualities. The performance of the method is verified through experiments. [Results] The experimental method effectively detects both the internal and external qualities of yellow peaches on the food production line, with a high grading accuracy and efficiency, achieving a grading accuracy greater than 95.00% and an average grading time of less than 0.3 seconds. [Conclusion] By combining machine vision, hyperspectral technology, and intelligent algorithms, rapid and non-destructive detection of food quality can be achieved.

Keywords: food production line; yellow peach; automatic grading; machine vision; hyperspectral technology; YOLOv11; extreme learning machine

基金项目: 四川省中央引导地方科技发展专项项目(编号: 2024ZYD0300); 宜宾市科技计划项目(编号: 2021ZYY001)

通信作者: 彭永杰(1983—), 男, 宜宾职业技术学院副教授, 硕士。E-mail: mmgagf@163.com

收稿日期: 2025-02-16 改回日期: 2025-05-03

引用格式: 彭永杰, 赵良军, 龙绪明. 基于改进 YOLOv11 与 GWO-ELM 的食品生产线黄桃自动分级方法[J]. 食品与机械, 2025, 41(5): 89-97.

Citation: PENG Yongjie, ZHAO Liangjun, LONG Xuming. Automatic grading method of yellow peaches on food production line based on improved YOLOv11 and GWO-ELM[J]. Food & Machinery, 2025, 41(5): 89-97.

随着消费者对食品安全及品质期望的持续攀升,水果品质自动分级已成为食品生产企业把控产品质量、增强市场竞争力的核心环节^[1]。黄桃作为深受欢迎的水果品类,其品质分级至关重要。近年来,机器视觉与高光谱技术在黄桃自动分级领域已得到广泛运用,极大提升了分级的效率与准确性^[2]。然而,随着技术的迭代更新,如何进一步优化黄桃品质自动分级的精度与效率,依旧是亟待解决的重要问题^[3]。

当前,国内外学者及研究机构针对食品品质自动分级方法展开了深入且广泛的研究,研究重点聚焦于内部品质与外部品质的检测^[4-5]。国外在技术应用方面较为成熟,普及范围广泛且构建了完备的标准体系^[6]。国内则处于新技术积极应用探索阶段,持续精进检测水平与精度。随着技术的演进,食品品质检测将更加智能化、精准化,为食品安全保驾护航,提升消费者信心^[7]。文韬等^[8]为了进一步提高食品分级性能,通过融合机器视觉和光谱技术设计了一种柑橘品质无损检测分级系统,该系统能够准确识别柑橘的外观品质和内部品质,具有很高的分级精度和效率。孙潇鹏等^[9]为了降低损耗和提高品质,利用近红外透射光谱和机器视觉技术对蜜柚汁胞进行粒化分级检测,该方法能够有效区分不同成熟度的蜜柚汁胞,为蜜柚的品质评估提供了新的技术手段。郭德超等^[10]为了进一步提高食品分级性能,利用机器视觉和光谱技术进行番茄综合品质评估,该方法能够准确预测番茄的多个品质指标,如糖度、酸度、硬度等。靳学萌等^[11]提出了一种改进 YOLOv10 模型,有效解决了现有目标检测模型在干制黄花菜分级任务中精度不足及参数过多的问题,该方法能在不同光照条件下对干制黄花菜进行精准分类,实时性好,平均精度均值为 85.7%,参数量为 2.45 M。Li 等^[12]为了实现黄桃不同贮藏时间检测,提出一种结合高光谱、机器视觉和极限梯度提升模型的黄桃贮藏时间检测方法,该方法可以实现轻度瘀伤黄桃的不同贮藏时间的检测,检测精度 > 95%。虽然食品品质分级领域的现有研究已取得一定成果,但在实际应用中仍存在检测准确

率和实时性有待提高等不足之处。

相比传统的黄桃外部品质检测方法,YOLOv11 能够在复杂的背景环境下,依然保持较高的检测准确率和效率,有效减少误检和漏检情况的发生。相比传统的黄桃内部品质检测方法,极限学习机(ELM)无需进行繁琐的迭代训练,大大节省了训练时间,提高了检测效率。这对于大规模的黄桃品质检测任务来说尤为重要,能够在有限的时间内完成对大量黄桃的品质评估。为进一步提升食品品质自动分级的准确率和效率,研究拟提出一种融合机器视觉与高光谱技术的食品内外品质自动检测方法,通过改进 YOLOv11 模型完成外部缺陷检测,结合果型指数及色泽评估外部品质;通过改进灰狼算法优化的极限学习机(GWO-ELM)模型完成可溶性固形物与硬度预测,完成内部品质评估;结合内、外部品质对黄桃进行分级,并通过试验验证其性能,旨在为食品自动化生产与安全提供助力。

1 食品分级系统

食品分级系统呈集成化、智能化特性,是一个检测与分类系统,依据食品外观品质(涵盖颜色、形状、大小、表面缺陷等)和内部品质(如成分含量、新鲜度等)特征,迅速且精准地将食品划分成不同级别,以满足市场与生产所需,其结构如图 1 所示^[13-14]。该系统集成高光谱采集、机器视觉采集、传送装置、执行机构以及计算机控制等核心部分,各部分协同运作,达成高效精确分级。通过 Green Vision USB1080 相机负责采集食品外部品质图像,镜头型号为 BQ0550-3MP,通过 SOC710-VP 高光谱仪采集食品内部品质信息(光谱范围 400~1 000 nm),对应镜头型号为 C-Mount。

2 黄桃分级方法

试验以黄桃为研究对象,依据《锦绣黄桃质量等级标准》对黄桃进行分级。果面缺陷:无损伤和三级果,有缺陷统一为三级果。果型:特级果的果型指数处于[0.8, 1.0],一级果在[0.6, 0.8),二级果在[0.4, 0.6),其余为三级




图 1 食品分级系统

Figure 1 Food grading system

果;色泽方面,特级果的着色面积在 $[0.85, 1.00]$,一级果在 $[0.70, 0.85]$ 范围,二级果在 $[0.50, 0.70)$,其他为三级果;可溶性固形物含量:特级果 $\geq 13.0\%$,一级果 $\geq 12.0\%$,

二级果 $\geq 11.0\%$,其余为三级果;硬度:特级果硬度 ≥ 0.294 MPa,一级果 ≥ 0.196 MPa,二级果 ≥ 0.098 MPa,其余为三级果。黄桃分级标准如图2所示。

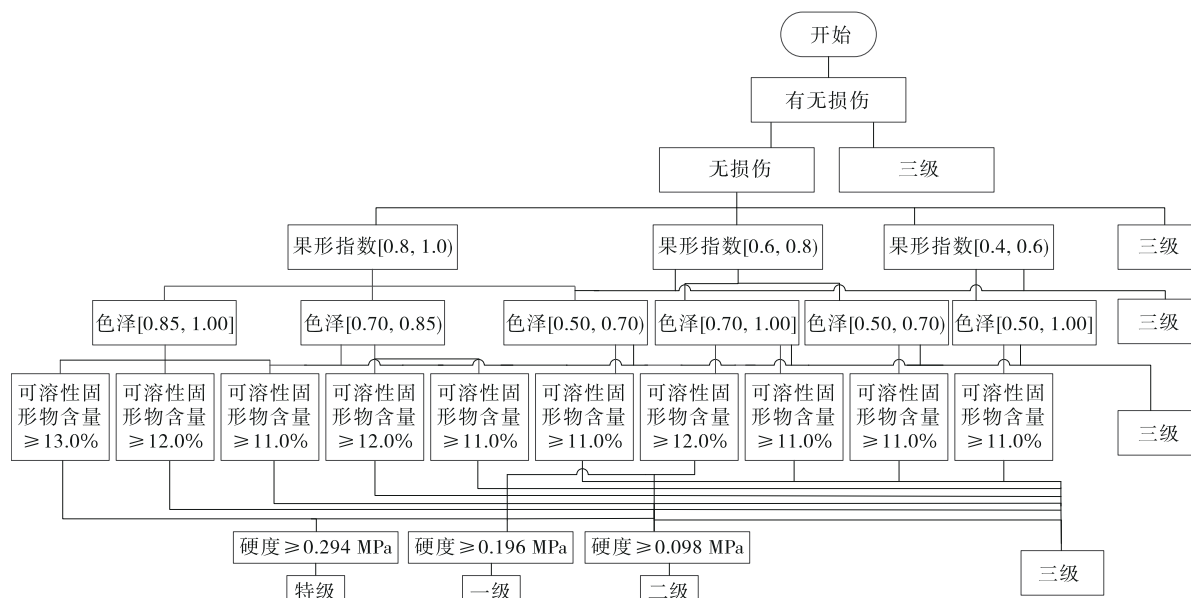


图2 黄桃分级标准

Figure 2 Yellow peach grading standards

试验将黄桃缺陷、果型指数以及色泽作为外部品质的衡量指标。利用CMOS传感器相机采集黄桃图像信息,在预处理环节运用高斯算法与亮度调整手段,随后采用改进的YOLOv11模型开展外部缺陷检测工作,再结合果形指数与色泽完成外部品质分级任务。对于内部品质,将黄桃的可溶性固形物含量和硬度作为考量指标,通过高光谱仪进行数据采集,预处理采用Savitsky-Golay平滑与标准正态变量变换方法,特征提取选用窗口竞争性自适应加权采样(WCARS)方式,经过特征选择后将数据输入改进的GWO-ELM模型进行内部可溶性固形物和硬度检测。结合外部品质和内部品质对黄桃进行分级。

2.1 黄桃外部品质

2.1.1 数据预处理方法 在相机采集黄桃图像过程中,受诸多因素干扰,所获原始图像存在一定的噪声。此类噪声可掩盖黄桃真实特性,干扰后续对其外部品质的精准分析与评估。因此,采用高斯滤波与亮度调整对采集图像做预处理以削减或消除噪声影响^[15]。

2.1.2 改进YOLOv11 YOLOv11模型在黄桃外部品质检测中凭借高精度、良好实时性、灵活性与适应性以及模型优化和训练方面的优势,可提供高效精准的黄桃品质检测方案,助力提升黄桃生产效率与产品质量。该模型主要由输入层、骨干网络、颈部网络和检测头构成^[16-17]。

输入层:承担接收原始图像数据并作为模型输入的

任务。在数据进入骨干网络前,通常要对输入图像做预处理,例如调整图像大小、归一化等操作,以此满足模型训练与推理的要求。

骨干网络:作为模型的基础架构,用于提取图像基本特征。YOLOv11的骨干网络采用C3k2块替代之前版本中的C2f块,这一设计提升了计算效率,使YOLOv11处理图像时能更迅速地提取特征。

颈部网络:处于骨干网络与检测头之间,其作用在于特征融合和增强。通过整合多尺度特征信息,它能够更有效地捕捉不同尺寸目标的信息,进而提升小物体识别率与整体定位精度。

检测头:YOLOv11借鉴了YOLOv10的设计思路,采用深度可分离策略来降低冗余计算量并提升计算效率。这种方法不但简化了计算过程,还降低了模型的参数数量和计算量。YOLOv11模型结构如图3所示。

试验利用YOLOv11模型检测黄桃外部品质,综合性能与资源消耗因素,在YOLOv11模型基础上开展如下改进。

(1) 除现有的SPPF(空间金字塔池化)模块外,还结合了自适应空间特征融合(ASFF)。SPPF能提供丰富的多尺度特征表示,而ASFF则依据特征的重要性与相关性进行自适应融合,二者协同使用可进一步提高黄桃外部品质检测的准确性与鲁棒性。

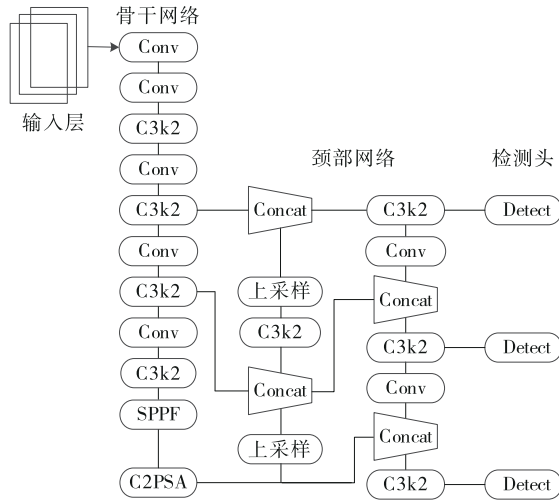


图 3 YOLOv11 模型
Figure 3 YOLOv11 model

(2) 在 YOLOv11 模型中, C3K2 模块后引入 SG 模块。SG 模块的设计灵感源于移动点卷积 (self-moving points conv, SMPCConv) 与卷积门控线性单元 (convolutional gated linear unit, CGLU) 的融合。具体而言, SG 模块的结构是在 SMPCConv 之后堆叠添加 CGLU。这种设计使 SG 模块既能捕捉有效特征, 又能借助门控机制选择性地通过信息通道, 从而提升特征提取的有效性与灵活性。

2.1.3 果形指数和色泽 在运用改进的 YOLOv11 模型精准检测到图像中的黄桃后, 采用自适应阈值分割技术来实现黄桃前景与背景的高效分离。随后, 对提取出的黄桃轮廓执行椭圆拟合操作, 从而精确获取椭圆的长轴与短轴半径。果形指数则通过计算长轴半径与短轴半径的比值得出。关于色泽评估, 在明确界定黄桃区域后, 进一步计算该区域内所有像素在特定颜色空间中的均值颜色向量, 该向量能够表征水果的整体颜色特性。最终, 通过线性归一化处理来计算色泽值。

2.2 黄桃内部品质

2.2.1 数据预处理和特征选择 在高光谱数据采集进程中, 不可避免地会受到多种因素的干扰, 进而引入噪声。这些噪声来源广泛, 涵盖了仪器自身产生的电子噪声、环境因素 (例如温度、湿度的波动对仪器性能的影响) 以及被测对象表面存在的不均匀性等方面。因此, 为了提高数据质量, 需要对采集到的数据进行预处理操作。高光谱数据通常包含大量波段, 每个波段均可视为一个特征维度。这导致数据的维度极高, 使得数据处理和模型训练过程变得极为复杂且耗时冗长。因此, 采用 Savitsky-Golay 平滑算法进行数据平滑处理, 并结合标准正态变量变换完成预处理^[18]。随后, 运用 WCARS 方法进行特征选择, 该方法能够在保留关键信息的同时, 显著降低数据

的维度。通过 WCARS 方法的特征选择, 成功将原本的 410 个特征波长缩减至 17 个, 极大地简化了后续的数据分析和模型构建过程^[19]。

2.2.2 改进 GWO-ELM 模型 有别于传统的神经网络, ELM 以随机的方式生成输入层与隐藏层间的连接权重 ω 以及隐藏层的偏置 b 。这种随机初始化的方式使得网络不需要像传统神经网络那样通过反复迭代来调整权重和偏置, 从而大大提高了训练速度^[20]。ELM 网络结构示意图如图 4 所示。




图 4 ELM 网络结构示意图
Figure 4 ELM network structure

在图 4 中, 样本集 X 作为神经网络输入。从输入层到隐含层之间全连接。输入层和隐含层之间的连接权值 (输入层与隐含层) ω 和偏置 b (隐层) 如式 (1) 和式 (2) 所示。

$$\omega = \begin{bmatrix} \omega_{11} & \cdots & \omega_{1n} \\ \vdots & \vdots & \vdots \\ \omega_{L1} & \cdots & \omega_{Ln} \end{bmatrix}_{L \times n}, \tag{1}$$

$$b = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_L \end{bmatrix}_{L \times 1}, \tag{2}$$

式中:

$\omega_{L,n}$ ——连接权值 (输入 n 和隐层 L);

b_L ——偏置 (隐层 L)。

连接权值 (隐含层与输出层) β 如式 (3) 所示。

$$\beta = \begin{bmatrix} \beta_{11} & \cdots & \beta_{1m} \\ \vdots & \vdots & \vdots \\ \beta_{L1} & \cdots & \beta_{Lm} \end{bmatrix}_{L \times m}, \tag{3}$$

式中:

$\beta_{L,m}$ ——连接权值 (隐层 L 和输出 m)。

隐含层输出 $H(x)$ 和网络输出 t_j 如式 (4) 和式 (5) 所示。

$$H(x) = \begin{bmatrix} g(v_{1,1}) & \cdots & g(v_{L,1}) \\ \vdots & \vdots & \vdots \\ g(v_{1,n}) & \cdots & g(v_{L,n}) \end{bmatrix}_{L \times n}, \tag{4}$$

$$t_j = \sum_{i=1}^N g(v_{i,j}) \beta_i, j = 1, 2, \dots, N, \tag{5}$$

式中:

$g(x)$ ——激活函数(隐含层)。

为增强模型的预测准确性与学习性能,试验采取了一种创新性的优化策略,即运用灰狼优化(grey wolf optimizer, GWO)算法来精细调整ELM模型的参数(ω 和 b)。尽管GWO算法在缓解局部最优解问题上颇具成效,但其优化能力仍有一定限度。因此,进一步整合差分进化算法对GWO算法进行深化优化,以期更有效地规避陷入局部最优解。具体实施步骤:

步骤1 数据采集与分配:通过高光谱技术采集数据,并按照预定比例对数据集进行划分。

步骤2 数据预处理与特征提取:对获取的数据进行必要的预处理,以确保数据质量,并通过特征选择方法提炼出关键特征。

步骤3 模型参数初始化:将ELM模型的参数(包括权重 ω 和偏置 b)设定为狼群个体的初始状态,为后续的优化流程设定起点。

步骤4 适应度评估:对每个个体的适应度进行计算,并筛选出适应度最高的前3个个体,将它们定义为“上层狼”,代表当前种群中的优秀个体。

步骤5 差分进化增强:应用差分进化算法对选出的上层狼进行进一步优化,通过变异和交叉等操作产生新一代的狼群子代,以此增强种群的多样性和全局搜索能力。

步骤6 终止条件判断:当达到预设的终止条件(如最大迭代次数或适应度收敛)时,输出最优的参数权重 ω 和偏置 b 值。

步骤7 ELM模型构建与测试:利用优化后的参数权重 ω 和偏置 b 构建ELM模型,并在测试集上进行验证,最后输出测试结果以评估模型的性能。

内部品质检测流程如图5所示。

3 试验分析

3.1 试验参数

为了验证试验所提品质分级方法的优越性,以黄桃为试验对象,通过实际测量来评估其品质。外部指标如

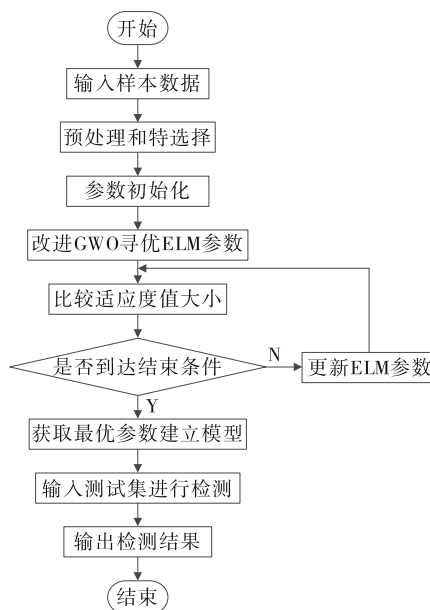


图5 内部品质检测流程

Figure 5 Internal quality inspection process

黄桃的缺陷通过人眼观察确定,果形指数则使用数显游标卡尺(DL90150B型,得力集团有限公司)进行测量,色泽由水果测色仪(MiniScan EZ型,美国亨特立公司)测定。对于内部指标,可溶性固形物含量通过折射仪(PAL-1型,日本爱拓公司)测量,硬度通过质构仪(TA.XT Express型,英国Stable Micro Systems公司)进行测量。

在样品分级方面,共设置了4个等级(特级、一级、二级、三级),每个等级各选取250个样本,总计1000个样本。根据3:1:1(训练集:验证集:测试集)的比例对其进行划分,被划分为训练集、验证集和测试集,黄桃外部采集图像如图6所示,黄桃原始高光谱图像如图7所示。算法参数如表1所示。

试验通过一系列指标对黄桃的内部和外部品质进行了全面评估。对于内部品质模型,采用了决定系数(R^2)、均方根误差(R_{MSE})以及平均检测时间 t_p 作为评估标准。而对于外部品质模型,则通过准确率(A)、召回率(R)、平均精度均值(M_{AP})以及平均检测时间 t_A 来进行评价。计




图6 黄桃外部采集图像

Figure 6 External image acquisition of yellow peaches




图 7 黄桃原始光谱图

Figure 7 Original spectrum of yellow peaches

表 1 试验参数

Table 1 Test parameters

参数	数值	参数	数值
种群	30	激活函数	Sigmoid
迭代次数	100	学习率	0.001
维数	2	图像大小	640 像素 × 640 像素
交叉概率因子	0.2	迭代次数	100
缩放因子	0.8, 0.2	批大小	16
权重	[0, 1]	优化器	SGD
偏置	[0, 1]	优化器动量	0.937
隐含层层数	9		

算如式(6)~式(11)所示。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \tag{6}$$

$$R_{MSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}, \tag{7}$$

$$M_{AP} = \sum_{i=1}^N \frac{P_i(r)}{N}, \tag{8}$$

$$R = \frac{T_p}{T_p + F_N}, \tag{9}$$

$$A = \frac{T_p + T_N}{T_p + T_N + F_p + F_N}, \tag{10}$$

$$t_A = \frac{T}{n}, \tag{11}$$

式中:

$y_i, \hat{y}_i, \bar{y}_i$ ——实际值、预测值、预测平均值;

T_p, T_N, F_p, F_N ——真正例、真负例、假正例、假负例,个;

n ——样本数,个;

T ——检测时间, s。

3.2 结果分析

为了全面验证试验所提改进 YOLOv11 模型在黄桃外部损伤检测任务中的优越性,将试验方法与优化前 YOLOv11 模型、文献[10]改进 YOLOv8 模型、文献[11]改进 YOLOv10 模型进行对比分析。为确保试验结果的可比性,对数据集实施了统一的预处理操作,包括图像的归一化、裁剪和增强等步骤,以消除数据差异对试验结果可能带来的影响。不同方法随迭代变化的损失值曲线如图 8 所示。

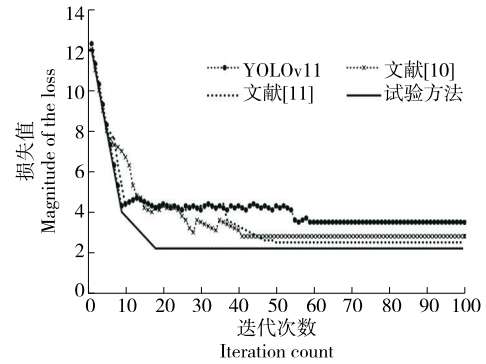


图 8 不同方法损失值变化曲线

Figure 8 Loss value variation curves of different methods

由图 8 可以看出,试验改进 YOLOv11 模型在黄桃外部损伤检测任务中展现出了较为明显的优势。收敛速度方面,试验所提改进 YOLOv11 模型的收敛速度明显快于文献[10]改进 YOLOv8 模型和文献[11]改进 YOLOv10 模型。表明在相同的训练条件下,它能够更快地找到更优的模型参数,减少训练时间,提高训练效率。在损失值稳定性方面,试验所提改进 YOLOv11 模型在训练过程中的损失值相对较为稳定。与文献[10]改进 YOLOv8 模型和文献[11]改进 YOLOv10 模型相比,其损失值的波动范围较小。表明试验所提模型在训练过程中能够更加平稳地优化模型参数,避免了因损失值大幅波动而导致的训练不稳定问题。为黄桃外部损伤检测提供了一种更有效、更准确的检测方法。不同方法外部损伤检测结果如

表 2 不同方法外部损伤检测结果

Table 2 External damage detection results using different methods

方法	准确率	召回率	平均精度均值	平均检测时间/s
YOLOv11	0.930	0.935	0.931	0.021
文献[10]	0.935	0.935	0.932	0.022
文献[11]	0.945	0.945	0.942	0.019
试验方法	0.960	0.955	0.950	0.016

表2所示,平均检测时间为建模计算时间。

由表2可以看出,试验方法在黄桃外部损伤检测任务中表现出色,相较于其他对比模型具有更高的准确率、较高的召回率、更优的平均精度均值以及更快的检测速度,能够更高效、准确地检测出黄桃的外部损伤情况,在黄桃品质检测等方面具有较大优势。试验方法的准确率为0.960,召回率为0.955,平均精度均值为0.950,平均检测时间为0.016 s。与优化前YOLOv11模型、文献[10]模型和文献[11]模型相比,试验方法准确率分别提高了3.22%,3.22%,1.59%,召回率分别提高了2.14%,2.14%,

1.06%,平均精度均值分别提高了2.04%,1.93%,0.85%,平均检测时间降低了23.80%,27.27%,15.79%。

为了全面验证试验所提改进GWO-ELM模型在黄桃内部品质检测任务中所具有的优越性,将试验方法与优化前GWO-ELM模型、文献[8]改进偏最小二乘法模型、文献[10]改进PSO-LSSVM模型和文献[12]极限梯度提升模型进行对比分析。为了保证试验结果的可比性,对数据集进行了统一的预处理和特征选择,以消除数据差异对试验结果可能产生的影响。不同方法内部指标检测结果如表3所示。

表3 不同方法内部指标检测结果

Table 3 Internal indicator detection results using different methods

指标	模型	训练集		测试集		平均检测时间/s
		均方根误差	决定系数	均方根误差	决定系数	
可溶性固形物	GWO-ELM	0.402 8	0.944 3	0.521 5	0.935 8	0.120
	文献[8]	0.341 5	0.941 2	0.464 5	0.931 2	0.123
	文献[10]	0.321 2	0.950 1	0.431 2	0.955 2	0.120
	文献[12]	0.300 1	0.948 9	0.398 8	0.941 2	0.120
	试验方法	0.221 2	0.967 9	0.312 0	0.969 2	0.116
硬度	GWO-ELM	0.040 5	0.937 8	0.051 3	0.930 5	0.120
	文献[8]	0.034 7	0.935 5	0.046 6	0.930 6	0.123
	文献[10]	0.030 8	0.947 8	0.044 2	0.943 2	0.119
	文献[12]	0.028 4	0.948 8	0.038 7	0.940 5	0.119
	试验方法	0.022 8	0.963 2	0.031 9	0.960 5	0.115

由表3可以看出,试验方法在可溶性固形物和硬度的内部指标检测中,无论是在检测均方根误差(R_{MSE})还是决定系数(R^2)方面,都表现出了优越的性能,相较于其他对比模型具有更高的精度和更强的解释能力。在检测速度方面,试验方法在所有模型中平均检测时间最短,显示出较好的实时检测潜力。试验方法相比于GWO-ELM模型、文献[8]、文献[10]和文献[12]方法,在可溶性固形物检测中,测试集均方根误差(R_{MSE})分别降低了40.17%,32.83%,27.64%,21.77%,测试集决定系数(R^2)分别提高了3.57%,4.09%,1.47%,2.97%,平均检测时间分别降低了3.33%,5.69%,3.33%,3.33%;在硬度检测中,测试集均方根误差(R_{MSE})分别降低了37.90%,31.69%,27.97%,17.60%,测试集决定系数(R^2)分别提高了3.22%,3.21%,1.83%,2.13%,平均检测时间分别降低了4.17%,6.50%,3.36%,3.36%。表明试验所提改进GWO-ELM模型在黄桃内部品质检测任务中具有明显的优越性,能够更准确、快速地评估黄桃的内部品质。

为了充分验证试验所提改进GWO-ELM模型+改进YOLOv11模型在黄桃综合品质检测中所具有的优越性,将试验方法与优化GWO-ELM模型+YOLOv11模型和

具有广泛影响力的文献[10]改进PSO-LSSVM模型+改进YOLOv8模型进行对比分析。为了保证试验结果的可比性,对数据集进行了统一的预处理,以消除数据差异对试验结果可能产生的影响。不同方法品质综合检测效果如图9所示,不同方法内外部综合品质检测结果如表4所示。

由图9和表4可以看出,试验所提的改进GWO-ELM




图9 不同方法品质综合检测效果

Figure 9 Comprehensive quality detection effect using different methods

表 4 不同方法内外部综合品质检测结果

Table 4 Internal and external comprehensive quality testing results using different methods

方法	样品数	检测准确数	检测准确率/%	平均检测时间/s
GWO-ELM+YOLOv11	200	189	94.50	0.330
改进 PSO-LSSVM+改进 YOLOv8	200	191	95.50	0.312
试验方法	200	194	97.00	0.285

模型+改进 YOLOv11 模型在黄桃内外部综合品质检测任务中具有明显的优越性和实用价值。与优化前的 GWO-ELM 模型+YOLOv11 模型和文献[10]改进 PSO-LSSVM+改进 YOLOv8 模型相比,试验方法在检测准确率和检测速度两个关键指标上都取得了较好的效果。试验方法的检测准确率达到 97.00%,分别提高了 2.65%, 1.57%, 试验方法的平均检测时间为 0.285 s,分别降低了 13.64%, 8.65%。表明所提方法能够为黄桃品质检测提供更准确、更快速的解决方案,有助于提升黄桃品质检测的整体水平。

4 结论

试验将机器视觉与高光谱技术融入食品品质的综合评估中,通过结合改进的 GWO-ELM 模型与改进的 YOLOv11 模型实现了对黄桃内外部品质的高精度和快速检测。试验所提改进 YOLOv11 模型在黄桃外部损伤检测方面展现出了收敛迅速、训练高效、损失值稳定以及检测性能卓越的显著优势。同时,改进的 GWO-ELM 模型在黄桃内部品质检测上也表现出了高精度和速度快等特点。黄桃综合品质检测的准确率高达 97.00%,平均检测时间仅需 0.285 s。相较于常规方法,试验方法的检测准确率分别提升了 2.65%, 1.57%,而平均检测时间则分别降低了 13.64%, 8.65%。该研究在食品品质分级领域具有重要的实用价值与广阔的应用前景。然而,试验过程中采集的数据与实际生产环境仍存在一定差异,后续将持续优化并完善整个分级系统,以期尽快应用于实际环境。

参考文献

- [1] 邹金萍,章帅,董文韬,等.应用高光谱图像检测鱼肉挥发性盐基总氮含量研究[J].光谱学与光谱分析,2021,41(8):2586-2590.
ZOU J P, ZHANG S, DONG W T, et al. Application of hyperspectral image to detect the content of total nitrogen in fish meat volatile base[J]. Spectroscopy and Spectral Analysis, 2021, 41(8): 2586-2590.
- [2] 丛军,李星.基于电子鼻、电子舌技术的荣昌猪肉及其制品贮藏

过程新鲜度检测研究[J].食品安全质量检测学报,2024,15(7):192-201.

CONG J, LI X. Detection of freshness of Rongchang pork and its products during storage based on electronic nose and electronic tongue technology[J]. Journal of Food Safety & Quality, 2024, 15(7): 192-201.

- [3] 刘美辰,薛河儒,刘江平,等.牛奶蛋白质含量的 SSA-SVM 高光谱预测模型[J].光谱学与光谱分析,2022,42(5):1601-1606.

LIU M C, XUE H R, LIU J P, et al. Hyperspectral analysis of milk protein content using SVM optimized by sparrow search algorithm[J]. Spectroscopy and Spectral Analysis, 2022, 42(5): 1601-1606.

- [4] ERNA K H, ROVINA K, MANTIHAN S. Current detection techniques for monitoring the freshness of meat-based products: a review[J]. Journal of Packaging Technology and Research, 2021, 5(3): 127-141.

- [5] 王俊平,徐刚.机器视觉和电子鼻融合的番茄成熟度检测方法[J].食品与机械,2022,38(2):148-152.

WANG J P, XU G. Research on tomato maturity detection method based on machine vision and electronic nose fusion[J]. Food & Machinery, 2022, 38(2): 148-152.

- [6] 陈伟,张春雨,朱超冉.基于 YOLOv5s 算法的番茄成熟度识别研究[J].安徽科技学院学报,2023,37(1):92-95.

CHEN W, ZHANG C Y, ZHU C R. Research on tomato maturity recognition based on YOLOv5s algorithm[J]. Journal of Anhui of Science and Technology University, 2023, 37(1): 92-95.

- [7] 张凡,淑英,张志胜,等.融合光谱和图像特征信息的羊肉 TVB-N 含量无损检测[J].中国食品学报,2021,21(11):191-200.

ZHANG F, SHU Y, ZHANG Z S, et al. Nondestructive detection of TVB-N content in mutton based on fused spectra and image information[J]. Journal of Chinese Institute of Food Science and Technology, 2021, 21(11): 191-200.

- [8] 文韬,代兴勇,李浪,等.基于机器视觉与光谱融合的柑橘品质无损检测分级系统设计与试验[J].江苏大学学报(自然科学版),2024,45(1):38-45.

WEN T, DAI X Y, LI L, et al. Design and experiment of non-destructive testing and grading system for citrus quality based on machine vision and spectral fusion[J]. Journal of Jiangsu University (Natural Science Edition), 2024, 45(1): 38-45.

- [9] 孙潇鹏,刘灿灿,陆华忠,等.基于近红外透射光谱与机器视觉的蜜柚汁胞粒化分级检测[J].食品科学技术学报,2021,39(1):37-45.

SUN X P, LIU C C, LU H Z, et al. Detection of honey pomelo in different granulation levels based on near-infrared transmittance spectroscopy combined with machine vision[J].

- Journal of Food Science and Technology, 2021, 39(1): 37-45.
- [10] 郭德超, 饶远立, 张豪, 等. 结合机器视觉和光谱技术的番茄综合品质检测方法[J]. 食品与机械, 2024, 40(9): 123-130.
GUO D C, RAO Y L, ZHANG H, et al. Comprehensive quality detection method for tomatoes combining machine vision and spectral techniques[J]. Food & Machinery, 2024, 40(9): 123-130.
- [11] 靳学萌, 梁西银, 邓鹏飞. 基于改进YOLOv10的轻量化黄花菜分级检测模型[J]. 智慧农业(中英文), 2024, 6(5): 108-118.
JIN X M, LIANG X Y, DENG P F. Lightweight daylily grading and detection model based on improved YO-LOv10[J]. Smart Agriculture, 2024, 6(5): 108-118.
- [12] LI B, YIN H, LIU Y D, et al. Detection storage time of mild bruise's yellow peaches using the combined hyperspectral imaging and machine learning method[J]. Journal of Analytical Science and Technology, 2022, 13(1): 1-12.
- [13] 许程翔, 赵明岩, 梁喜凤, 等. 基于改进YOLOv8的轻量化甘薯品质分级实验研究[J]. 实验技术与管理, 2024, 41(6): 47-56.
XU C X, ZHAO M Y, LIANG X F, et al. Experimental study on lightweight sweet potato quality grading based on improved YOLOv8[J]. Experimental Technology and Management, 2024, 41(6): 47-56.
- [14] 谢安国, 纪思媛, 李月玲, 等. 基于遗传算法和深度神经网络的近红外高光谱检测猪肉新鲜度[J]. 食品工业科技, 2024, 45(17): 345-351.
XIE A G, JI S Y, LI Y L, et al. Detection of pork freshness using NIR hyperspectral imaging based on genetic algorithm and deep neural network[J]. Science and Technology of Food Industry, 2024, 45(17): 345-351.
- [15] 牛超, 杨卫东, 胡鹏明, 等. Wi-freshness: 基于CSI的猪肉新鲜度检测系统研究[J]. 物联网学报, 2023, 7(2): 143-152.
NIU C, YANG W D, HU P M, et al. Wi freshness: research on CSI-based pork freshness detection system[J]. Chinese Journal on Internet of Things, 2023, 7(2): 143-152.
- [16] 刘小花, 周彬静, 彭菁, 等. 基于电子鼻和高光谱成像技术的冷鲜牛肉微生物的生长模型构建[J]. 南京农业大学学报, 2023, 46(3): 595-605.
LIU X H, ZHOU B J, PENG J, et al. Modeling of microbial growth in chilled beef based on the E-nose and hyperspectral imaging techniques[J]. Journal of Nanjing Agricultural University, 2023, 46(3): 595-605.
- [17] 胡鹏伟, 刘江平, 薛河儒, 等. BP神经网络结合变量选择方法在牛奶蛋白质含量检测中的应用[J]. 光电子·激光, 2022, 33(1): 23-29.
HU P W, LIU J P, XUE H R, et al. Application of BP neural network and variable selection method in protein content detection of milk[J]. Journal of Optoelectronics-Laser, 2022, 33(1): 23-29.
- [18] 李玉花, 史翰卿, 熊赆葳, 等. 融合电子鼻和视觉技术的鸡肉新鲜度检测装置研究[J]. 农业机械学报, 2022, 53(11): 433-440.
LI Y H, SHI H Q, XIONG Y W, et al. Research of chicken freshness detection device based on electronic nose and vision technology[J]. Journal of Agricultural Machinery, 2022, 53(11): 433-440.
- [19] 周雨帆, 李胜旺, 杨奎河, 等. 基于轻量级卷积神经网络的苹果表面缺陷检测方法[J]. 河北工业科技, 2021, 38(5): 388-394.
ZHOU Y F, LI S W, YANG K H, et al. Apple surface defect detection method based on lightweight convolutional neural network[J]. Hebei Journal of Industrial Science and Technology, 2021, 38(5): 388-394.
- [20] 李艳坤, 董汝南, 张进, 等. 光谱数据解析中的变量筛选方法[J]. 光谱学与光谱分析, 2021, 41(11): 3331-3338.
LI Y K, DONG R N, ZHANG J, et al. Variable selection methods in spectral data analysis[J]. Spectroscopy and Spectral Analysis, 2021, 41(11): 3331-3338.