

融合改进深度卷积神经网络和光谱技术的猕猴桃内部品质无损检测

陈 玮¹ 费文源² 栗 超² 魏晨曦³

(1. 湖南外贸职业学院, 湖南 长沙 410114; 2. 华中农业大学, 湖北 武汉 430070;

3. 武汉科技大学, 湖北 武汉 430081)

摘要: [目的] 干物质、糖度是影响猕猴桃果实品质的两个重要指标, 为实现猕猴桃干物质、糖度快速准确检测, 提出一种融合改进深度卷积神经网络和光谱技术的猕猴桃内部品质关键指标无损检测方法。[方法] 运用光谱仪采集猕猴桃光谱数据, 并利用格拉姆角场 (GAF) 变换将光谱数据转换为两类二维图像。构建多空卷积改进卷积神经网络模型预测分析猕猴桃品质关键指标, 模型具备两个独立的 CNN 模块并联处理两类二维图像。通过设计多空卷积策略、聚类剪枝方法和引入通道注意力机制, 以提升模型检测分析能力。[结果] 相比于其他模型, 所提检测方法的干物质、糖度平均均方根误差分别降低了 20.59%, 13.04%, 平均决定系数分别提高了 6.45%, 4.34%, 平均相对预测偏差分别提高了 6.99%, 12.78%。[结论] 所提方法具有良好的猕猴桃内部品质关键指标检测分析能力, 对猕猴桃内部品质无损检测具有一定的借鉴意义。

关键词: 猕猴桃; 光谱技术; 卷积神经网络; 干物质; 糖度

Non-destructive detection of kiwifruit internal quality based on improved deep convolutional neural network and spectral technology

CHEN Wei¹ FEI Wenyuan² LI Chao² WEI Chenxi³

(1. Hunan International Business Vocational College, Changsha, Hunan 410114, China; 2. Huazhong Agricultural University, Wuhan, Hubei 430070, China; 3. Wuhan University of Science and Technology, Wuhan, Hubei 430081, China)

Abstract: [Objective] Dry matter and sugar content are two important indicators affecting the quality of kiwifruit. To achieve rapid and accurate detection of these indicators, a non-destructive detection method for key internal quality indicators of kiwifruit is proposed, integrating improved deep convolutional neural network with spectral technology. [Methods] A spectrometer was used to collect spectral data of kiwifruit, and the data were transformed into two types of two-dimensional images using Gramian Angular Field (GAF) transformation. An improved convolutional neural network model with multi-dilated convolutions was constructed to predict and analyze key quality indicators of kiwifruit. The model consists of two independent CNN modules connected in parallel to process the two types of two-dimensional images. Multi-dilated convolution strategies, clustering pruning methods, and channel attention mechanisms were incorporated to enhance the model's detection and analysis performance. [Results] Compared with other models, the proposed method reduced the average root mean square errors of dry matter and sugar content by 20.59% and 13.04%, respectively, increased the average determination coefficients by 6.45% and 4.34%, respectively, and improved the average relative prediction deviations by 6.99% and 12.78%, respectively. [Conclusion] The proposed method demonstrates good capability in detecting and analyzing key internal quality indicators of kiwifruit, and provides a valuable reference for non-destructive internal quality testing of kiwifruit.

基金项目: 教育部高等学校科学研究发展中心专项课题 (编号: ZJXF20236031)

通信作者: 陈玮 (1981—), 女, 湖南外贸职业学院讲师, 硕士。E-mail: cfgse56@yeah.net

收稿日期: 2025-02-13 **改回日期:** 2025-06-03

引用格式: 陈玮, 费文源, 栗超, 等. 融合改进深度卷积神经网络和光谱技术的猕猴桃内部品质无损检测[J]. 食品与机械, 2025, 41(6): 136-143.

Citation: CHEN Wei, FEI Wenyuan, LI Chao, et al. Non-destructive detection of kiwifruit internal quality based on improved deep convolutional neural network and spectral technology[J]. Food & Machinery, 2025, 41(6): 136-143.

Keywords: kiwifruit; spectral technology; convolutional neural network; dry matter; sugar content

中国猕猴桃种植面积和产量均居世界首位,猕猴桃产业在中国县域经济、乡村振兴、生态保护等领域发挥了重要作用^[1]。糖度、干物质是评价猕猴桃内部品质和感官的重要参数指标^[2],高效实现糖度、干物质检测对提升猕猴桃食用价值和经济效益具有重要意义^[3-4]。

传统有损式检测方法不仅效率低,而且难以开展大规模样本检测。随着光谱技术的快速发展,利用高光谱或近红外光谱检测猕猴桃内部品质已成为当前研究热点:杨涵等^[5]在猕猴桃高光谱数据基础上,使用多元散射校正等技术对原始高光谱数据进行预处理,并采用线性回归方法预测干物质含量,试验结果论证了该方法的可行性,但该方法采用线性方程建模,模型预测误差相对较大。张珮等^[6]利用便携式近红外光谱设备对内部品质进行无损检测,但受近红外光谱信号弱等影响,检测结果对环境依赖度较高。章恺等^[7]采用改进的最小二乘支持向量机模型对猕猴桃高光谱数据进行预测分析,猕猴桃糖度指标预测均方根误差达到了0.880 5,但该方法利用竞争性自适应重加权采样算法(competitive adaptive reweighted sampling, CARS)方法提取高光谱数据特征,计算复杂度高,容易出现过拟合,模型泛化性较差。刘子涵等^[8]采用MSC+CARS+PSO-SVR组合模型,实现了猕猴桃内部品质关键指标的较高准确率检测,但该模型对噪声和异常值敏感,影响了检测结果的可信性。随着人工智能理论的发展成熟,卷积神经网络(convolutional neural network, CNN)^[9]等深度学习技术在图像处理、目标识别等领域得到了广泛应用,CNN能够从原始数据中获取层次化特征,为基于高光谱数据的猕猴桃内部品质检测提供了更高效的解决方案。但是,卷积层特征感知能力较弱、网络结构相对复杂以及重要特征容易被忽视等仍是CNN需要解决的问题。

为进一步深度挖掘猕猴桃光谱数据特征信息,克服内部品质关键指标预测模型泛化能力弱、结果不稳定等缺陷,提出一种基于改进深度卷积神经网络和光谱技术的猕猴桃内部品质检测方法,该方法通过建立多空卷积改进卷积神经网络模型,引入多空卷积策略、聚类剪枝方法和引入通道注意力机制,以实现猕猴桃干物质、糖度等关键指标预测分析。并通过试验验证所提方法性能。

1 材料与方法

1.1 试验材料

为进一步预测、分析猕猴桃内部干物质、糖度指标特性,以陕西省宝鸡市岐山县盛产的“徐香”猕猴桃为研究对象,在成熟期内(2024年8月26日—10月25日),按照时间顺序每间隔5 d得到一个批次猕猴桃样本(样本外表

无疤痕、无损伤),每个批次含500个猕猴桃样本,共有12个批次样本。采用Kennard-Stone算法^[10]将每个批次猕猴桃样本按照3:1的比例划分为训练样本和测试样本。

1.2 光谱采集系统

参考文献[2]、文献[7]和文献[8],选取波长400~1 000 nm范围的光谱分析猕猴桃干物质、糖度的含量,建立如图1所示的高光谱采集系统,该系统由Specim IQ型智能光谱仪、暗箱、卤素灯、光电传感器和数据采集计算机等部件组成,光谱仪下方对应光电传感器,当猕猴桃样本到达光电传感器位置时,光谱仪自动采集样本光谱信息。在每次采集样本光谱数据前,先利用标准白板进行校正。光谱仪曝光时间设置为20 ms,传送带速度设置为0.04 m/s。为提高光谱数据采集的质量,每个样本重复采集5次,取平均光谱数据作为样本对应的光谱数据,并设置波长间隔为3 nm,则共有194个波段。




图1 猕猴桃高光谱采集系统

Figure 1 Hyperspectral acquisition system for kiwifruit

利用多元散射校正(multiplicative scatter correction, MSC)方法^[11]对样本光谱数据进行预处理,进一步降低基线漂移、光散射造成的影响。

1.3 干物质、糖度含量实测

猕猴桃样本完成光谱数据采集后,如图2所示,去除猕猴桃表皮,沿赤道区域切取3个质量约10 g的薄片。取部位1和部位3用于测量干物质含量,即将切片置于洁净培养皿中,在干燥箱内持续烘干24 h(干燥温度50 ℃),利用电子天平记录切片在培养皿中干燥前后的质量,最后根据式(1)计算两切片的干物质含量,并取两者均值作为样本干物质实测值。取部位2榨汁,利用糖酸一体机分别测量5次汁液糖度,取均值作为样本糖度实测值。

$$P = \frac{m_2 - m_0}{m_1 - m_0} \times 100\%, \quad (1)$$

式中:

P ——干物质含量,%;

m_0 ——培养皿质量,g;

m_1 ——干燥前培养皿和切片质量,g;

m_2 ——干燥后培养皿和切片质量,g。




图2 猕猴桃样本切片选取示意图

Figure 2 Schematic diagram of kiwifruit sample slice selection

$$D_i^j = \begin{bmatrix} 0 & \sin(\alpha_i^{j,1} - \alpha_i^{j,2}) & \cdots & \sin(\alpha_i^{j,1} - \alpha_i^{j,194}) \\ \vdots & \vdots & \vdots & \vdots \\ \sin(\alpha_i^{j,194} - \alpha_i^{j,1}) & \sin(\alpha_i^{j,194} - \alpha_i^{j,2}) & \cdots & 0 \end{bmatrix}, \quad (2)$$

$$S_i^j = \begin{bmatrix} \cos(\alpha_i^{j,1} + \alpha_i^{j,1}) & \cos(\alpha_i^{j,1} + \alpha_i^{j,2}) & \cdots & \cos(\alpha_i^{j,1} + \alpha_i^{j,194}) \\ \vdots & \vdots & \vdots & \vdots \\ \cos(\alpha_i^{j,194} + \alpha_i^{j,1}) & \cos(\alpha_i^{j,194} + \alpha_i^{j,2}) & \cdots & \cos(\alpha_i^{j,194} + \alpha_i^{j,194}) \end{bmatrix}, \quad (3)$$

$$k_i^{j,m} = \frac{[k_i^{j,m} - \max(K_i^j)] + [k_i^{j,m} - \min(K_i^j)]}{\max(K_i^j) - \min(K_i^j)}, \quad (4)$$

$$\alpha_i^{j,m} = \arccos(k_i^{j,m}), \quad (5)$$

式中:

D_i^j —— K_i^j 对应的格拉姆角差场矩阵;

S_i^j —— K_i^j 对应的格拉姆角和场矩阵;

$k_i^{j,m}$ —— $k_i^{j,m}$ 归一化后数据;

$\alpha_i^{j,m}$ —— $k_i^{j,m}$ 对应编码角度值,rad。

1.4.2 多空卷积改进CNN模型

(1) 多空卷积策略:构建多空卷积改进卷积神经网络模型(multi empty convolution improved CNN, MEC-ICNN),模型具有两个独立的CNN模块并联处理两类二维图像。每个CNN模块具有5个卷积层(conv)和3个池




图3 多空卷积改进卷积神经网络模型示意图

Figure 3 Schematic diagram of the improved CNN model with multi-dilated convolution

(2) 聚类剪枝策略:每层多空卷积层提取到的特征存在一定的冗余度^[12],为精简网络结构,提出聚类剪枝策略,即利用密度峰值聚类算法(density peak clustering, DPC)^[13]对多空卷积层提取到的特征进行聚类压缩。DPC作为一种新型聚类算法,对绝大多数形状的数据集都有良好的聚类性能。分别定义第 $C(1 \leq C \leq 5)$ 个多空卷积层提取到的特征集合为 $T_c = (g_1^c, \dots, g_{n_c}^c)$,剪枝率为 $p_c(0 < p_c < 1)$,则第 C 个多空卷积层需要压缩的通道个

1.4 多空卷积改进卷积神经网络模型

1.4.1 两类图像转换 对于第 $i(1 \leq i \leq 13)$ 个批次内第 $j(1 \leq j \leq 500)$ 个猕猴桃样本,定义其光谱的数学描述为 $K_i^j = (k_i^{j,1}, \dots, k_i^{j,m}, \dots, k_i^{j,194})$ ($k_i^{j,m}$ 表示 K_i^j 第 m 个波段峰值, $1 \leq m \leq 194$)。为了便于后续卷积神经网络深度学习,利用格拉姆角场(gramian angular field, GAF)变换将 K_i^j 转换为格拉姆角差场(gramian angular difference fields, GADF)和格拉姆角和场(gramian angular summation fields, GASF)两类二维矩阵图像,转换公式分别为:

化层(pool),卷积层卷积核大小、卷积核数量如图3所示,池化层采用最大池化操作,池化步长为2。为了在增大卷积层视野的同时不增加卷积核数量,引入多空卷积策略,即对于第 $C(1 \leq C \leq 5)$ 个卷积层,卷积核数量为 n_c 、卷积核大小为 $w_c \times w_c$,利用式(6)来扩展卷积核大小,图4给出了多空卷积策略示意图。从图4可以看出,引入多空卷积策略后,扩展了卷积层感受野,利于提升卷积层的特征感知提取能力。

$$w_c^h = w_c^h + (w_c^h - 1)(r_c^h - 1), \quad (6)$$

式中:

w_c^h ——扩展后第 h 个卷积核大小;

w_c^h ——扩展前第 h 个卷积核大小;

r_c^h ——第 h 个卷积核对应扩展率,正整数。

数 Z_c 为:

$$Z_c = \lfloor p_c \times n_c \rfloor, \quad (7)$$

式中:

$\lfloor \cdot \rfloor$ ——向下取整操作。

聚类剪枝策略实现过程:利用DPC对 $T_c = (g_1^c, \dots, g_{n_c}^c)$ 进行聚类分析,得到 M 个分类集合和 L_c 个孤立点,其中第 m 个($1 \leq m \leq M$)分类集合内包含 b_m 个特




图4 多空卷积策略示意图

Figure 4 Schematic diagram of multi-dilated convolution strategy

征,则按照式(8)确定第 m 个分类集合需要压缩的特征数。

$$Z'_m = \left\lfloor Z_C \times \left(b_m / \left(\sum_{m=1}^M b_m \right) \right) \right\rfloor, \quad (8)$$

$$L_C + \sum_{m=1}^M b_m = n_C, \sum_{m=1}^M Z'_m \leq Z_C, \quad (9)$$

式中:

Z'_m ——第 m 个分类集合压缩特征数。

对于第 m 个分类集合,当确定 Z'_m 取值后,随机选择集合内 Z'_m 个特征进行压缩,进而完成对 C 层多空卷积层的聚类剪枝。从聚类剪枝策略实现过程可以看出,分类集合内特征压缩个数随分类集合规模自适应变化,避免了均匀剪枝,最大限度地降低了提取特征冗余度。

(3) 通道注意力机制:两个独立 CNN 模块对输入图像深度学习后,将提取到的特征进行组合。为了赋予重要特征更大权重,引入通道注意力机制:首先,采用全局平均池化操作对通道进行压缩,并将压缩后的特征图转换为特征向量 $T' = (g'_1, \dots, g'_J)$ (J 为两个独立 CNN 模块输出特征通道数之和)。其次,将 $T' = (g'_1, \dots, g'_J)$ 引入两个串联的全连接层,两个全连接层输出函数分别为 ReLU 函数和 sigmoid 函数,根据式(10)得到每个特征权重。最

后,根据式(11)将组合特征图与相对应的权重相乘,进而得到加权后的特征图。

$$\omega = \sigma \left(\phi_2 \left(\text{ReLU} \left(\phi_1 \left(\delta(T') \right) \right) \right) \right), \quad (10)$$

$$T'_\omega = \omega \odot T', \quad (11)$$

式中:

ω ——特征权重向量;

$\phi_1(\cdot)$ 、 $\phi_2(\cdot)$ ——两个全连接层操作;

$\sigma(\cdot)$ 、 $\text{ReLU}(\cdot)$ 、 $\delta(\cdot)$ ——sigmoid 函数、ReLU 函数、全局平均池化;

T'_ω ——加权后的特征图。

2 猕猴桃干物质、糖度检测试验

试验主要分为猕猴桃样本确定、数据处理和模型验证 3 个部分,实现流程如图 5 所示。试验选取均方根误差 (root meansquares error, RMSE)、决定系数 (coefficient of determination, R^2) 和相对预测偏差 (relative prediction deviation, RPD)、平均检测时间 ($\bar{t}$) 评价所提模型 (MEC-CNN) 的性能,其中, RMSE 值越小、 R^2 越接近 1,模型检测性能越好。RPD 代表了模型可靠性, $\text{RPD} < 1.4$ 时,模型不可靠; RPD 在 $[1.4, 2.0]$ 时,模型相对可靠; $\text{RPD} > 2.0$ 时,模型非常可靠^[14]。




图5 试验流程图

Figure 5 Test flowchart

2.1 检验结果与分析

对 12 个批次样本分别开展干物质、糖度检测验证实验,如前所述,每个批次含 500 个猕猴桃样本,并按照 3:1 的比例划分为训练样本集合和测试样本集合。选取 400~

1 000 nm 范围内的光谱进行分析,图 6(a)给出了经 MSC 预处理后的光谱曲线,图 6(b)给出了 12 个批次样本干物质平均值分布,图 6(c)给出了 12 个批次样本糖度平均值分布。




Figure 6 Spectral curve of kiwifruit MSC pretreatment and distribution of dry matter and sugar content in samples

利用训练样本集对所提多空卷积改进卷积神经网络模型(MEC-ICNN)进行训练,MEC-ICNN采用具有两层结构的全连接层实现对干物质、糖度的检测值输出,隐

含层神经元个数为128,16,最小批次数为16,学习率为[0.001,0.01],训练次数为50,选取RMSE为训练损失函数。表1给出了12个批次样本干物质、糖度检测结果。

表 1 干物质、糖度检测结果
 Table 1 Test results of dry matter and sugar content

内部品质	评价指标	单位	批次											
			1	2	3	4	5	6	7	8	9	10	11	12
干物质	RMSE		0.33	0.36	0.27	0.19	0.41	0.28	0.30	0.22	0.17	0.19	0.22	0.34
	R^2		0.98	0.95	0.96	0.98	0.97	0.96	0.96	0.94	0.97	0.96	0.98	0.97
	RPD		2.41	2.62	2.48	2.18	2.37	2.40	2.22	2.19	2.38	2.65	2.77	2.84
	$\bar{t}$	s	1.07											
糖度	RMSE		0.40	0.51	0.38	0.47	0.61	0.38	0.31	0.39	0.47	0.65	0.58	0.36
	R^2		0.95	0.94	0.98	0.95	0.96	0.97	0.94	0.98	0.96	0.97	0.95	0.99
	RPD		2.77	2.79	2.69	2.70	2.68	2.66	2.59	2.64	2.66	2.71	2.74	2.79
	$\bar{t}$	s	1.11											

由表1可知,对于12个批次猕猴桃样本,MEC-ICNN表现出了良好的检测能力,无论是干物质检测,还是糖度检测, RMSE取值处于较低水平, R^2 取值都在0.94以上, RPD结果都大于2.18,样品平均检测时间达到了1.07 s级别,表明该模型具有优秀的稳定性、高精度的检测结果和较快的检测速度。为进一步分析所提多空卷积策略、聚类剪枝方法和通道注意力机制对模型性能的影响,将不采用多空卷积策略的模型描述为ICNN(该模型仍采用聚类剪枝方法和通道注意力机制)、将不采用聚类剪枝方法和通道注意力机制的模型描述为MEC-CNN(该模型仍采用多空卷积策略),分别采用3种模型对干物质、糖度进行检验,图7、图8分别给出了第1批次(8月26—31日)3种模型干物质、糖度检测值与真实值对比结果,图9、图10给出了第12批次(10月20—25日)3种模型干物质、糖度检测值与真实值对比结果。

从图7~图10可以看出,对猕猴桃干物质、糖度检测,所提MEC-CNN模型检测结果都要优于ICNN(该模型不采用多空卷积策略)和MEC-CNN(该模型不采用聚类剪

枝方法和通道注意力机制)。以第12批次糖度检测为例, MEC-CNN 的 RMSE、 R^2 、RPD 取值分别为 0.36、0.99、2.79, 优于 ICNN 的 (0.41、0.86、2.04) 和 MEC-CNN 的 (0.43、0.91、2.06)。表明多空卷积策略的引入使得模型能够以更广阔的视角挖掘光谱数据特征,提升了模型特征提取能力;聚类剪枝方法精简了模型结构,改善了模型收敛性能;通道注意力机制赋予重要特征更大权重,进一步提高了模型检测能力,得到的检测结果质量更高。

2.2 对比试验结果与分析

为对比分析所提MEC-ICNN检测性能,选取文献[8]提出的MSC+CARS+PSO-SVR的组合模型和文献[14]提出的FD+SNV+PLS模型(一阶导数FD+SNV数据预处理和偏最小二乘PLS)进行对比试验。其中, MSC+CARS+PSO-SVR 组合模型采用多元散射校正(multiplicative scatter correction, MSC)对光谱数据进行预处理,利用CARS提取光谱特征,并采用PSO优化SVR模型进行检测分析。对比结果如表2所示。




图7 第1批次3种模型干物质检测值与实测值对比结果

Figure 7 Comparison results between the predicted and actual dry matter values of three models in the first batch




图8 第1批次3种模型糖度检测值与实测值对比结果

Figure 8 Comparison results between the predicted and actual sugar content values of three models in the first batch




图9 第12批次3种模型干物质检测值与实测值对比结果

Figure 9 Comparison results between the predicted and actual dry matter values of three models in the 12th batch




图10 第12批次3种模型糖度检测值与实测值对比结果

Figure 10 Comparison results between the predicted and actual sugar content values of three models in the 12th batch

表 2 干物质、糖度检测结果

Table 2 Test results of dry matter and sugar content

内部品质	模型	评价指标	单位	批次											
				1	2	3	4	5	6	7	8	9	10	11	12
干物质	MEC-ICNN	RMSE		0.33	0.36	0.27	0.19	0.41	0.28	0.30	0.22	0.17	0.19	0.22	0.34
		R^2		0.98	0.95	0.96	0.98	0.97	0.96	0.96	0.94	0.97	0.96	0.98	0.97
		RPD		2.41	2.62	2.48	2.18	2.37	2.40	2.22	2.19	2.38	2.65	2.67	2.54
		$\frac{\bar{t}}{t}$	s	1.07											
	文献[8]	RMSE		0.41	0.46	0.33	0.32	0.48	0.37	0.40	0.39	0.22	0.37	0.41	0.45
		R^2		0.94	0.93	0.92	0.93	0.91	0.92	0.90	0.91	0.92	0.92	0.91	0.93
		RPD		2.17	2.11	2.13	2.16	2.07	2.03	2.09	2.15	2.08	2.16	2.19	2.17
		$\frac{\bar{t}}{t}$	s	1.32											
	文献[14]	RMSE		0.39	0.40	0.31	0.28	0.31	0.38	0.41	0.29	0.26	0.28	0.30	0.42
		R^2		0.96	0.92	0.91	0.95	0.94	0.93	0.92	0.91	0.93	0.91	0.94	0.95
		RPD		2.22	2.45	2.31	2.09	2.25	2.27	2.18	2.15	2.24	2.48	2.19	2.32
		$\frac{\bar{t}}{t}$	s	1.87											
糖度	MEC-ICNN	RMSE		0.40	0.41	0.38	0.47	0.41	0.38	0.31	0.39	0.47	0.45	0.38	0.36
		R^2		0.95	0.94	0.98	0.95	0.96	0.97	0.94	0.98	0.96	0.97	0.95	0.99
		RPD		2.77	2.79	2.69	2.70	2.68	2.66	2.59	2.64	2.66	2.71	2.74	2.79
		$\frac{\bar{t}}{t}$	s	1.11											
	文献[8]	RMSE		0.51	0.58	0.44	0.53	0.56	0.45	0.48	0.46	0.56	0.55	0.49	0.47
		R^2		0.93	0.92	0.94	0.92	0.91	0.93	0.92	0.94	0.92	0.93	0.91	0.94
		RPD		2.11	2.17	2.21	2.16	2.17	2.13	2.21	2.20	2.19	2.24	2.18	2.24
		$\frac{\bar{t}}{t}$	s	1.56											
	文献[14]	RMSE		0.45	0.47	0.46	0.52	0.47	0.46	0.37	0.42	0.52	0.48	0.46	0.43
		R^2		0.92	0.91	0.94	0.92	0.91	0.93	0.91	0.94	0.92	0.95	0.91	0.93
		RPD		2.14	2.21	2.19	2.31	2.24	2.17	2.24	2.18	2.14	2.20	2.16	2.11
		$\frac{\bar{t}}{t}$	s	2.03											

从表 2 可以得到,在猕猴桃干物质检测方面,3 种方法都取得了不错的检测结果,RPD 均大于 2。其中,MEC-ICNN 性能最优,12 个批次下的 RMSE、 R^2 、RPD 平均值为 0.27、0.97、2.43,相比 MSC+CARS+PSO-SVR 方法的 RMSE 平均值降低了 28.95%、 R^2 平均值提高了 5.15%、RPD 平均值提高了 14.08%,较 FD+SNV+PLS 方法的 RMSE 平均值降低了 20.59%、 R^2 平均值提高了 6.45%、RPD 平均值提高了 6.99%。在猕猴桃糖度检测方面,所提 MEC-ICNN 性能仍最优,12 个批次下的 RMSE、 R^2 、RPD 平均值为 0.40、0.96、2.47,相比 MSC+CARS+PSO-SVR 方法的 RMSE 平均值降低了 21.57%、 R^2 平均值提高了 6.25%、RPD 平均值提高了 15.18%,较 FD+SNV+PLS 方法的 RMSE 平均值降低了 13.04%、 R^2 平均值提高了 4.34%、RPD 平均值提高了 12.78%。在检测时间上,无论是干物质检测还是糖度检测,所提 MEC-ICNN 都要快于其他两种方法。试验结果表明,MEC-ICNN 表现出了较高的检测性能,这是因为采用格拉姆角场(GAF)变换将

光谱数据转换为两类二维图像,并利用两个独立的 CNN 模块并联处理两类二维图像,增加了数据信息丰富度;多空卷积策略的引入,进一步扩展了卷积层感受野,提升了卷积层的特征感知提取能力;聚类剪枝方法和通道注意力机制的提出,在优化模型网络结构的同时,赋予了重要特征更大权重,使得 MEC-ICNN 具有更强的特征提取能力,检测结果更优。

3 结语

对猕猴桃干物质、糖度高效检测进行研究,提出了一种基于改进深度卷积神经网络和光谱技术的猕猴桃内部品质关键指标检测方法,该方法引入了两类转换高光谱数据二维图像,增加了信息丰富度;构建了具有两个独立模块的改进 CNN 模型,通过设计多空卷积策略、聚类剪枝方法和通道注意力机制,有效改善了模型特征感知能力,优化了网络结构,并赋予重要特征更大权重,实现了对高光谱数据的深度学习,猕猴桃干物质、糖度检测分析能力

进一步提高,试验结果表明,所提方法在猕猴桃干物质、糖度检测方面性能更优,干物质、糖度检测平均均方根误差降低了约63.55%,51.35%。下一步,将重点验证模型对不同年份下猕猴桃内部品质检测的适用性。

参考文献

- [1] 李玉阔,林苗苗,宋哲,等.中国不同地区中猕2号猕猴桃果实品质评价体系的建立[J].果树学报,2024,41(7):1368-1377.
LI Y K, LIN M M, SONG Z, et al. Establishment of comprehensive evaluation system for fruit quality of Zhongmi No.2 kiwifruit from different regions of China[J]. Journal of Fruit Science, 2024, 41(7): 1368-1377.
- [2] 张良英,刘林,于立杰,等.软枣猕猴桃果实发育期品质指标及抗氧化能力的变化[J].食品与机械,2023,39(7):157-164.
ZHANG L Y, LIU L, YU L J, et al. Changes of quality characteristics and antioxidant capacities during fruit development of hardy kiwifruit[J]. Food & Machinery, 2023, 39(7): 157-164.
- [3] 李可,廖茂雯,林籽汐,等.基于多元统计法的不同质量猕猴桃果实品质分析[J].食品工业科技,2023,44(21):285-292.
LI K, LIAO M W, LIN Z X, et al. Analysis of quality in different weight grading kiwifruits based on multivariate statistical method[J]. Science and Technology of Food Industry, 2023, 44(21): 285-292.
- [4] 万畅.基于高光谱技术猕猴桃内部品质的无损检测[D].西安:西北农林科技大学,2024:18-20.
WAN C. Non-destructive testing of internal quality of kiwifruit based on hyperspectral technology[D]. Xi'an: Northwest A & F University, 2024: 18-20.
- [5] 杨涵,陈谦,王宝刚,等.利用高光谱技术预测采前猕猴桃干物质含量的可行性试验[J].农业工程学报,2022,38(13):133-140.
YANG H, CHEN Q, WANG B G, et al. Feasibility of estimating the dry matter content of kiwifruits before being harvested using hyperspectral technology[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2022, 38(13): 133-140.
- [6] 张珮,王银红,江靖,等.便携式近红外光谱仪在果蔬品质定性和定量分析中的应用[J].食品科技,2020,45(5):287-292.
ZHANG P, WANG Y H, JIANG J, et al. Application of portable near-infrared spectrometer in qualitative and quantitative analysis of fruit and vegetable quality[J]. Food Science and Technology, 2020, 45(5): 287-292.
- [7] 章恺,朱丽芳,李入林,等.基于改进WOA-LSSVM和高光谱的猕猴桃糖度无损检测[J].食品与机械,2024,40(5):107-112,226.
ZHANG K, ZHU L F, LI R L, et al. Non destructive detection of kiwifruit sugar content based on improved WOA-LSSVM and hyperspectral analysis [J]. Food & Machinery, 2024, 40(5): 107-112, 226.
- [8] 刘子涵,李明,赵峙尧,等.基于高光谱成像技术和机器学习的猕猴桃果实可溶性固形物含量预测[J].果树学报,2024,41(12):2606-2620.
LIU Z H, LI M, ZHAO S Y, et al. Prediction of soluble solids contents in kiwifruit based on both hyperspectral imaging technology and machine learning[J]. Journal of Fruit Science, 2024, 41(12): 2606-2620.
- [9] 买买提·沙吾提,李荣鹏,蔡和兵,等.基于改进轻量级深度卷积神经网络的果树叶片分类及病害识别模型设计[J].森林工程,2025,41(2):277-287.
SAWUT M, LI R P, CAI H B, et al. Design of classification of fruit leaves and disease identification model based on improved MobileNet-V2[J]. Forest Engineering, 2025, 41(2): 277-287.
- [10] CHEN W H, CHEN H Z, FENG Q X, et al. A hybrid optimization method for sample partitioning in near-infrared analysis[J]. Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 2021, 248: 119182.
- [11] 刘畅,吴丹丹,王宁,等.基于二维相关红外光谱对pH值影响大豆分离蛋白二级结构含量的快速分析[J].食品科学,2024,45(17):26-34.
LIU C, WU D D, WANG N, et al. Two-dimensional correlation infrared spectroscopy for rapid analysis of the effect of pH on the secondary structure content of soybean protein isolate[J]. Food Science, 2024, 45(17): 26-34.
- [12] ZHENG X W, YANG C Y, ZHANG S K, et al. Ddpnas: efficient neural architecture search via dynamic distribution pruning[J]. International Journal of Computer Vision, 2023, 131(5): 1234-1249.
- [13] RODRIGUEZ A, LAIO A. Clustering by fast search and find of density peaks[J]. Science, 2014, 344(6191): 1492-1496.
- [14] 梁子兆,李欣,刘朴,等.基于可见-近红外光谱的多品种猕猴桃贮藏品质的多指标综合预测模型研究[J/OL].食品工业科技.(2024-11-04)[2025-02-16].<https://doi.org/10.13386/j.issn1002-0306.2024070318>.
LIANG Z Z, LI X, LIU P, et al. Comprehensive multi-indicator prediction model for storage quality of multi-cultivar kiwifruit based on visible-near infrared spectroscopy[J/OL]. Science and Technology of Food Industry. (2024-11-04)[2025-02-16]. <https://doi.org/10.13386/j.issn1002-0306.2024070318>.