

基于卷积神经网络和高光谱成像技术的芒果成熟度判别

邱邹全^{1,2}, 蒙庆华^{1,2,3*}, 吴哲锋^{1,2,3}, 姚嘉炜^{1,2}, 桑丽婷^{1,2}, 马煜雯^{1,2}, 黄玉清⁴, 李钰⁵

(1. 南宁师范大学物理与电子学院, 广西南宁 530001) (2. 广西华谱红外科技有限公司, 广西南宁 530299)
(3. 南宁师范大学, 广西信息功能材料与智能信息处理重点实验室, 广西南宁 530001) (4. 南宁师范大学, 北部湾环境演变与资源利用教育部重点实验室, 广西地表过程与智能模拟重点实验室, 广西南宁 530001)
(5. 广西壮族自治区水果技术指导站, 广西南宁 530022)

摘要: 为了无损判别芒果成熟度, 本研究着力探索利用可见近红外高光谱成像技术与深度学习方法结合。通过漫反射高光谱成像系统, 采集 400~1 000 nm 波长范围内未熟、成熟和过熟芒果的高光谱数据, 运用 SPXY 算法按 6:2:2 划分为训练、验证和测试集。经小波阈值去噪 (Wavelet Threshold Denoising, WTD)、多元散射校正 (Multiplicative Scatter Correction, MSC) 等光谱预处理后, 构建一维卷积神经网络 (1-Dimensional Convolutional Neural Network, 1DCNN) 模型。同时, 采用主成分分析 (Principal Component Analysis, PCA) 和自举软收缩 (Bootstrapping Soft Shrinkage, BOSS) 提取特征波段, 搭建偏最小二乘判别分析 (Partial Least Squares-Discriminant Analysis, PLS-DA) 与极限学习机 (Extreme Learning Machine, ELM) 的分类模型。对比分析表明, 基于多元散射校正预处理的 1DCNN 模型性能最佳, 在测试集上分类准确率达 98.30%, Kappa 系数为 0.97。研究结论表明, 高光谱成像技术与神经网络算法相结合, 能高精度无损判别芒果成熟度, 为芒果自动化分拣的实际应用提供理论基础。

关键词: 高光谱成像; 芒果; 无损检测; 特征波长; 卷积神经网络; Kappa 系数

文章编号: 1673-9078(2025)12-313-322

DOI: 10.13982/j.mfst.1673-9078.2025.12.0996

Mango Fruit Ripening Degree Assessment Based on Convolutional Neural Network and Hyperspectral Imaging Technology

QIU Zouquan^{1,2}, MENG Qinghua^{1,2,3*}, WU Zhefeng^{1,2,3}, YAO Jiawei^{1,2},

SANG Liting^{1,2}, MA Yuwen^{1,2}, HUANG Yuqing⁴, LI Yu⁵

(1.College of Physics and Electronics, Nanning Normal University, Nanning 530001, China)

(2.Guangxi Huapu Infrared Technology Co. Ltd., Nanning 530299, China)(3.Guangxi Key Laboratory of Information Functional Materials and Intelligent Information Processing, Nanning Normal University, Nanning 530001, China)(4.Key Laboratory of Environmental Evolution and Resource Utilization of the Beibu Gulf, Ministry of Education & Guangxi Key Laboratory of Earth Surface Processes and Intelligent Simulation, Nanning Normal University, Nanning 530001, China)

(5.Guangxi Zhuang Autonomous Region Fruit Technical Guidance Station, Nanning 530022, China)

引文格式:

邱邹全,蒙庆华,吴哲锋,等.基于卷积神经网络和高光谱成像技术的芒果成熟度判别[J].现代食品科技,2025,41(12):313-322.

QIU Zouquan, MENG Qinghua, WU Zhefeng, et al. Mango fruit ripening degree assessment based on convolutional neural network and hyperspectral imaging technology [J]. Modern Food Science and Technology, 2025, 41(12): 313-322.

收稿日期: 2024-07-12; 修回日期: 2025-01-19; 接受日期: 2025-02-14

基金项目: 广西科技基地和人才专项 (AD20238059); 中央专项彩票公益金 - 南宁师范大学 2025 年创新创业教育专项课题 (2025SCKT03); 广西普通本科高校示范性现代产业学院 - 南宁师范大学智慧物流产业学院建设项目 (6020303891823)

作者简介: 邱邹全 (1998-), 男, 硕士研究生, 研究方向: 高光谱无损检测, E-mail: 2191364546@qq.com

通讯作者: 蒙庆华 (1970-), 女, 博士, 教授, 研究方向: MEMS 红外传感技术, E-mail: mqhgx@163.com

Abstract: In order to non-destructively determine mango ripeness, this study focused on exploring the combined use of visible near-infrared hyperspectral imaging and deep learning methods. The hyperspectral data of unripe, ripe and overripe mangoes were collected in the wavelength range of 400~1 000 nm using a diffuse reflectance hyperspectral imaging system. The SPXY algorithm was used to divide the data into training, validation and testing sets in a ratio of 6:2:2. After the spectral pre-processing such as Wavelet Threshold Denoising (WTD) and Multiplicative Scatter Correction (MSC), a 1-Dimensional Convolutional Neural Network (1DCNN) model was constructed. Meanwhile, Principal Component Analysis (PCA) and Bootstrapping Soft Shrinkage (BOSS) were used to extract the feature bands, and the classification models of Partial Least Squares-Discriminant Analysis (PLS-DS) and Extreme learning machine (ELM) were constructed. Comparative analysis shows that the 1DCNN model based on multiple scatter correction preprocessing performed the best, with a classification accuracy of 98.30% and a Kappa coefficient of 0.97 on the test set. The study concludes that the combination of hyperspectral imaging technology and neural network algorithm can reliably and accurately determine mango ripeness, providing a theoretical basis for the practical application of automated mango sorting.

Key words: hyperspectral imaging; mango; non-destructive testing; characteristic wavelength; convolutional neural network; kappa coefficient

芒果作为中国广西的特色水果品类之一, 富含诸如可溶性糖、可滴定酸、胡萝卜素以及可溶性固形物等多种物质, 深受广大消费者的青睐与喜爱^[1-3]。成熟度指标在衡量芒果采摘时机以及采后自动分拣流程中, 占据着至关重要的地位。契合农产品市场的实际需求, 精准确定适宜的成熟度, 对于保障芒果品质及其货架期而言, 具有无可替代的重要意义。传统的芒果成熟度检测手段, 主要依赖果农凭借自身经验, 在现场对芒果成熟度展开分类; 或者由农产品技术员借助化学分析仪器, 通过检测果肉组织中的糖含量, 进而判别芒果的成熟度。然而, 此类方法存在诸多弊端, 不仅属于劳动密集型作业, 检测耗时较长, 而且对样品具有破坏性, 难以满足现代高效、精准的检测需求^[4,5]。近年来, 随着高光谱技术在农产品成熟度检测领域的广泛推广, 成像技术与光谱分析相结合的无损检测方法, 正日益广泛地应用于果实成熟度分级系统之中^[6-10]。鉴于此, 研发一种无损、高效且精准的芒果成熟度分类方法, 已然成为该领域亟待解决的重要课题。

近年来, 国内外诸多学者围绕高光谱成像技术与传统机器学习算法模型相结合, 针对水果成熟度的无损检测展开深入研究。例如, Alessandro 等^[11]运用覆盖 400~1 000 nm 波段的高光谱成像技术, 对田间葡萄的成熟状态进行检测。在对光谱数据实施预处理后, 构建偏最小二乘判别分析模型, 该模型在训练集、验证集以及预测集上所取得的分类准确率分别为 89.00%、89.00% 与 91.00%。刘金秀等^[12]借助近红外高光谱成像系统, 采集 4 种不同成熟度等级小白杏的光谱信息, 并选用多种光谱预处理手段以及特征波长选择算法构建判别模型, 其中极限学习机模型在测试

集上的准确率达 94.00%。此外, 高光谱成像技术在李果实和油茶果的成熟度无损检测方面, 均展现出较为理想的分类效果^[13,14]。然而, 光谱数据集规模、波段间的共线性以及判别模型的泛化能力等诸多因素, 给高光谱成像结合传统机器学习算法模型在成熟度判别领域的应用推广带来了显著阻碍^[15]。鉴于此, 众多研究者开始积极探索将深度学习算法引入光谱分析相关研究^[16-19]。周晨昕等^[20]提出一种专门用于青梅成熟度分类的卷积神经网络, 该网络的分类准确率高达 92.72%。上述深度学习算法在处理光谱数据方面所取得的研究成果, 为光谱无损检测芒果成熟度奠定了一定的理论基础。

在本项研究中, 借助高光谱成像技术, 对芒果的光谱数据进行精确采集, 并创新性地构建了一种卷积神经网络分类模型。通过与传统光谱分类模型展开系统性对比分析, 致力于探寻最为适宜的芒果成熟度无损判别模型。该研究成果不仅为芒果品质分级体系提供了极具价值的参考依据, 更为芒果产业的高科技赋能注入了全新动力, 对于推动广西地区经济的进一步提升具有积极的意义。

1 材料与方法

1.1 芒果样本

实验材料芒果均为 2023 年 6~7 月从广西壮族自治区百色市田阳区芒果园采摘的, 其中未熟、成熟和过熟的样本各 50 个。挑选的芒果是形状均匀、无瘀伤和无虫害的, 被带回南宁师范大学武鸣校区的高光谱成像实验室。所有样本清洁并顺序编号, 放在 26 ℃ 的恒温实验环境下, 立即采集样本的高光谱数据。在芒果

成熟过程中，由于叶绿素降解以及类胡萝卜素等代谢物的产生，芒果的颜色和硬度将发生变化^[21,22]。因此，芒果成熟度是按照果皮颜色和果实硬度进行定义的，果皮颜色微黄中带有绿色且果实较硬的则视为未熟，果皮颜色几乎全黄且果实紧实的则视为成熟，而全黄的果皮中带有黑斑且果实明显松软的则视为过熟，如图 1 所示。



图 1 不同成熟度的芒果样本

Fig.1 Mango samples of different ripeness levels

1.2 高光谱图像采集与光谱提取

实验中所用的高光谱图像采集系统为原始全息衍射光栅高光谱成像系统（Headwall Photonics Inc, USA），包括：光谱仪（Micro-Hyperspec® VNIR A-Series, Headwall Photonics Inc, USA）、Silicon 型 CCD 相机、镜头、150 W 线性卤素灯、暗箱以及计算机等，如图 2 所示。首先将准备好的芒果样品放在载物台上，调整参数以获得清晰的图像。每个芒果正面反面各采集 1 张高光谱数据，所有样品总计采集 300 次。光源以垂直倾角 45° 放置在待测样品上方，相机的曝光时间为 33.17 ms，样本与镜头的距离为 300 mm。光谱测定的范围为 400~1 000 nm，光谱分辨率为 5 nm，采样波段间隔为 1.9 nm/pixel。为了减少杂散光和暗电流噪声的影响，在图像采集之前需要对高光谱成像系统进行校正，黑白校正的公式为：

$$R = \frac{H-D}{W-D}$$

（1）

式中：

- R——黑白校正后的高光谱图像数据；
- H——高光谱成像系统采集的原始数据；
- D——黑色参考图像数据；
- W——标准白板参考图像数据。

对于校正后的光谱图像，使用 ENVI 软件在每张芒果高光谱图像的花萼端、赤道区域和茎端各选取一个固定的 20×20 像素的感兴趣区域（Region of Interest, ROI），采样位置如图 2 所示。将其平均反射率作为样本的光谱反射率，总共获得 900 条芒果光谱曲线。为了确保训练集、验证集和测试集的样品具有代表性，

采用基于联合 x-y 距离算法（Sample Set Partitioning Based on Joint X-y Distance, SPXY）^[23]将所有光谱样本按 6:2:2 划分为训练集、验证集和测试集。




图 2 高光谱成像系统

Fig.2 Hyperspectral imaging system

1.3 光谱预处理及特征波长选择

由于光谱检测中的随机因素导致原始光谱数据中存在噪声，WTD 是一种可以准确去除高频噪声的方法，具有效率高且计算量小的优点而广泛应用于光谱预处理中^[24]。WTD 将光谱信号分解为高频部分和低频部分，然后对高频部分进行阈值处理，最终重构信号。本研究选择 WTD 的小波基函数为 dobechies4，采用软阈值函数，分解层数为 2。MSC 是通过校正每个光谱的散射来增强了与水果品质含量相关的光谱特征信息^[12]。另外的光谱预处理方法有 baseline^[25]和 detrending^[26]。光谱特征波长选择也是传统机器学习应用于光谱分析中需要考虑的问题，光谱数量可以反映物质的成分及含量信息，同时数据存在冗余性。为了降低模型的复杂度，减少光谱数据之间的共线性因素对模型性能的影响，采用 PCA 和 BOSS 对光谱数据进行特征提取并参与建模。PCA 通过对光谱数据降维后结合载荷信息进一步分析变量重要程度的一种方法^[27]。BOSS 是基于加权自举抽样（Weighted Bootstrap Sampling, WBS）和模型总体分析（Model Population Analysis, MPA）来选择特征波长^[28]。

1.4 模型构建

PLS-DA 是光谱分析化学计量法中最常用的定性分析方法，可用于多分类的有监督机器学习算法^[11]。为了获得最佳的 PLS-DA 判别模型，本研究通过验证集数据上的分类准确率确定 PLS-DA 模型的最佳潜在变量（Latent Variables, LVs），从而提高测试集中的 PLS-DA 模型性能。

ELM 是在单隐藏层前馈神经网络的架构基础上，

通过随机初始化输入权重和偏置的神经网络算法,在解决光谱数据分类中具有收敛速度快和泛化能力好的优点^[29]。本研究中 ELM 激活函数的选择是 sigmoid 函数,该函数可以对每一个神经元的输出进行归一化,提高 ELM 模型自身的稳定性。ELM 中的单隐层神经元个数 (Num) 是由验证集的分类准确率确定的。

1DCNN 是计算机视觉领域传统二维卷积神经网络的创新,旨意在降低计算成本和满足实时性要求的前提下处理一维的信号^[15]。1DCNN 具有从原始数据中自动化地学习数据潜在特征的能力,在光谱分析领域受到了关注。在光谱数据的分类问题中,1DCNN 主要由输入层、卷积层、全连接层和输出层组成,根据实际应用需求对该神经网络架构进行调整。1DCNN 是一种端到端的光谱分析方法,可以通过卷积核提取原始光谱数据的不同特征,再进行人工神经网络的学习。本研究根据芒果成熟度判别分析的现实场景,设计了 1DCNN 分类的网络架构。该网络如图 3 所示,主要包括 1 个输入层、2 个卷积层、2 个池化层、2 个全连接层、1 个 Softmax 层和 1 个输出层,其中卷积核数量分别为 64 和 32,卷积核大小均为 3×1。输入层的数据格式需要将一维光谱数据升维度到二维空间,以满足 1DCNN 模型的输入要求。一个具有 327 个变量的光谱样本数据升维度后是一张高为 327 宽和通道数均为 1 的二维图像数据,经过卷积层的卷积核操作后,进行批量归一化以增加模型的稳定性减少训练过程中的震荡。池化层采用最大池化的方式,池化大小为 2×1,池化步长为 2。在卷积层提取光谱数据的特征之后,需要通过全连接层将各个通道的特征数据融合学习。为了防止模型训练出现过拟合,在两个全连接中间增加了一个 Dropout 正则化处理,在训练过程中有 40% 的失活概率。修正线性单元 (Rectified Linear Unit, ReLU) 在网络训练中计算梯度的速度快,因此作为激活函数可以加快 1DCNN 模型训练的收敛速度。在输出层和全连接层之间加一个 Softmax 是为了更好的定义多分类问题的每一类预测概率,然后计算预测概率与真实类别的 one-hot 编码值之间的交叉熵损失函数,进而重新调整训练权重。初始学习率设置为 0.001,训练周期为 500 轮,在训练周期 400 轮后将学习率降至 0.000 1。每轮的迭代次数为 4,每 10 次迭代就进行一次模型验证,每轮训练都会随机打乱数据集。为了避免训练过程中梯度函数出现以指数级递增或递减的情况,采用自适应矩估计 (Adaptive Moment Estimation, Adam) 对网络参数进行优化,减少到达最小值路径上的摆动。




图 3 基于芒果成熟度判别的 1DCNN 分类框架

Fig.3 A 1DCNN classification framework based on mango ripeness discrimination

1.5 模型评价

为了验证模型的性能,本研究中采用训练集、验证集和测试集的准确率来评估分类模型的性能,准确率的具体计算公式如下:

$$Acc = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \quad (2)$$

式中:

Acc——准确率;

T_p ——模型正确识别出正样本的数量;

T_n ——模型正确识别出负样本的数量;

F_p ——模型将负样本错误预测为正样本的数量;

F_n ——模型将正样本错误预测为负样本的数量。

为了全面评估分类模型在测试集上的表现结果,采用精确率(Precision)、召回率(Recall)、F1分数(F1-Score)和Kappa系数来综合衡量模型的性能。它们的计算公式分别如下:

$$\text{Precision} = \frac{T_p}{T_p + F_p} \quad (3)$$

$$\text{Recall} = \frac{T_p}{T_p + F_n} \quad (4)$$

$$\text{F1-Score} = \frac{2\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (5)$$

$$\text{Kappa} = \frac{\text{Acc} - P}{1 - P} \quad (6)$$

$$P = \frac{\sum_{i=1}^C [(T_p + F_n)(T_p + F_p)_i]}{(T_p + T_n + F_p + F_n)^2} \quad (7)$$

式中:

C——分类类别总数。

精确率也叫查准率,预测为正例的样本中预测正确的比例。召回率也叫查全率,表示被预测正确的正例占总实际正例样本的比例。F1分数则是对精确率和召回率的调和平均。Kappa系数是一种衡量分类精度的指标,数值越高表示模型预测性能的可靠性和稳健性就越高。

1.6 数据分析

用ENVI 5.1软件进行高光谱图像中的ROI选取,用Unscrambler X 10.4软件进行光谱数据预处理。在MATLAB R 2023a中编程建模和数据图形绘制。

2 结果与讨论

2.1 芒果的光谱分析

图4为不同成熟度芒果的原始光谱曲线和平均光谱曲线。芒果组织中的共同物质与光的相互作用的结果导致光谱曲线表现出相似的轮廓和走势如图4a所述。在图4b中,在可见光的400~600 nm波段内,平均反射率差别较小。而在600~700 nm的波段内,平均光谱曲线存在明显的波谷,在近红外波段内平均光谱曲线存在较明显的波峰,不同成熟度芒果光谱的差异是因为芒果内部的组分和含量不同造成的。其中平均光谱曲线在675、810和970 nm处反映出不同成熟度反射率的差距更为明显。675 nm附近的波谷与芒果果实中的叶绿素吸收带是相关的^[30]。芒果果实中的糖分导致光谱曲线在810 nm附近存在波峰^[31]。970 nm附近的吸收峰源于芒果果实中水分子O-H伸缩振动的二次泛音^[32]。不同成熟度芒果样品的光谱曲线中包含着

丰富的物质化学组分和含量信息,这为机器学习或深度学习从波段共线性的冗余信息中提取成熟度判别信息提供了一种可能。




图4 不同成熟度的芒果光谱曲线

Fig.4 Spectral curves of mango at different maturity levels

注:(a)原始光谱曲线;(b)平均光谱曲线。

2.2 全波长分类模型

图5呈现了芒果样本原始光谱数据分别经WTD、MSC、detrending和baseline预处理后的光谱曲线形态。经WTD预处理后,原始光谱曲线显著平滑化,然而其轮廓总体保持一致。MSC与detrending处理后的光谱曲线,相较于原始光谱,在形状方面发生了较为明显的改变;而经baseline预处理后的光谱曲线,其变化程度相对较小。依据原始光谱数据及预处理后的光谱数据,构建基于全波段的1DCNN、PLS-DA和ELM分类模型,其结果汇总于表1。从中可见,不同的预处理方式对1DCNN模型的准确率影响较为有限,却对PLS-DA和ELM模型的准确率产生较大影响。LVs作为PLS-DA模型中的关键参数,当将其均设定为7时,在各类光谱数据条件下,PLS-DA模型的训练集准确率差异较小。多数情况下,该模型验证集的准确率略高于训练集,而测试集准确率则低于训练集,此情形符合模型正常拟合的一般规律。在PLS-DA模型中,经detrending预处理的光谱数据在测试集上的准确率达到91.67%,与原始光谱数据相比,准确率提升

了 4.45%。Num 是 ELM 模型的重要参数，本研究将其起始值设定为 10，终点值设定为 100，步长为 10。通过选择验证集准确率达最大值时对应的 Num，进一步分析其对测试集的分类效果。结果显示，不同数据集下验证集的准确率存在较大差异，测试集的准确率受光谱数据规模以及 Num 的显著影响。在 ELM 模型中，经 MSC 预处理的光谱数据在测试集的准确率为 93.33%，相较于原始光谱数据，准确率提高了 7.22%。在 1DCNN 模型中，经 MSC 预处理的光谱数据在测试集的准确率为 98.30%，较原始光谱数据的准确率仅提升了 2.19%。在所有数据集中，1DCNN 模型的训练集准确率均达到 100.00%。其中，未经预处理的 Raw-1DCNN 模型，其验证集和测试集的准确率分别为 97.78% 和 96.11%，该模型性能优于 MSC-ELM 和 detrending-PLS-DA 模型。鉴于光谱数据变量繁多且波段信息间存在复杂的关联性，PLS-DA 模型在处理大数据量时能力受限，其训练准确率难以达到 100.00%。由于 ELM 模型的隐藏层神经元在对光谱数据的非线性信息进行拟合时展现出较强能力，故而 ELM 模型的训练能力优于 PLS-DA 模型。为有效降低全波段光谱数据间的相关性对传统机器学习模型造成的影响，后续将深入探讨基于特征波段的 PLS-DA 和 ELM 分类模型的效能表现。




图 5 不同预处理的光谱曲线

Fig.5 Spectral curves of different pre-treatments

注：(a) WTD；(b) MSC；(c) detrending；(d) baseline。

表 1 基于全波长的分类结果

Table 1 Classification results based on full wavelength

预处理	模型	参数	准确率/%		
			训练集	验证集	测试集
Raw	PLS-DA	LVs=7	90.74	93.33	87.22
WTD		LVs=7	91.67	93.89	89.44
MSC		LVs=7	90.37	88.89	88.33
detrending		LVs=7	91.48	92.22	91.67
baseline		LVs=7	90.00	92.78	82.22
Raw	ELM	Num=50	90.00	88.89	86.11
WTD		Num=60	95.37	95.00	92.78
MSC		Num=90	95.74	95.00	93.33
detrending		Num=60	95.00	94.44	92.22
baseline		Num=70	89.44	90.00	87.22
Raw	1DCNN	None	100.00	97.78	96.11
WTD		None	100.00	99.44	97.78
MSC		None	100.00	98.33	98.30
detrending		None	100.00	98.33	96.67
baseline		None	100.00	99.44	93.89

表 2 光谱特征波长提取的结果			
Table 2 Results of spectral feature wavelength extraction			
预处理	算法	数量	特征波长/nm
Raw	PCA	8	438、492、529、598、675、724、818、966
WTD		8	449、492、527、596、675、733、822、963
MSC		8	434、509、577、614、675、711、903、926
detrending		10	446、496、536、585、648、675、738、816、913、961
baseline		8	483、509、527、594、675、725、931、972
Raw	BOSS	11	430、455、516、636、673、675、677、814、938、940、955
WTD		13	460、473、510、512、514、630、633、673、675、898、936、938、994
MSC		11	430、516、630、673、675、807、931、940、955、960、972
detrending		15	430、468、485、494、516、518、583、673、675、688、807、809、813、826、913
baseline		9	430、447、455、462、485、673、675、913、955

2.3 特征波长分类模型

鉴于全光谱波段间存在显著的高度冗余信息，在应对海量光谱数据分类问题时，PLS-DA 与 ELM 的训练成效未达预期。故而，借助 PCA 与 BOSS 特征波长选择算法，提取与芒果成熟度判别信息紧密相关的特征，构建基于特征波长的传统机器学习成熟度分类模型。经 PCA 与 BOSS 算法处理，从 327 个波段信息中筛选出数量小于 20 的特征波长。总体而言，PCA 所提取的特征波长数量少于 BOSS，具体结果详见表 2。在 PCA 提取的特征波长中，仅 675 nm 为相同值。不同数据集在 BOSS 提取的特征波长中存在多个共同波长，诸如 430、516、673、675 及 955 nm，这些波长蕴含着关键的判别信息。基于特征波长的 PLS-DA 和 ELM 模型性能呈现于表 3。由此可见，经 WTD 与 BOSS 算法处理后的 WTD-BOSS-PLS-DA 模型，在训练集上的准确率高达 94.63%，在验证集上的准确率亦达 97.22%。相较于 WTD-PLS-DA 模型，其在测试集上的准确率提升了 2.78%，且模型输入从 327 个变量精简至 12 个变量，显著降低了模型的复杂度。此外，未经预处理的 Raw-BOSS-ELM 模型在测试集上的准确率在所有基于特征波长构建的分类模型中位居第一，达 92.78%，较 Raw-ELM 模型提高了 6.67%。在

基于 PCA 提取特征波长构建的模型中，经 MSC 处理的 MSC-PCA-ELM 模型在测试集上的准确率最高，为 90.56%，较 MSC-ELM 模型低 2.77%。基于 PCA 算法的建模效果欠佳，可能归因于在训练集大数据样本条件下，依据前几个主成分信息所习得的判别依据，在测试集上的适用性受限。同理，基于 BOSS 算法的建模效果亦受光谱预处理与建模方法的影响，各模型性能差异显著。例如，经 baseline 处理的 baseline-BOSS-ELM 模型在测试集上的准确率仅为 75.00%，较 baseline-ELM 模型低 12.22%。综上所述，传统分类模型的性能受制于光谱预处理方法、特征波长选择算法等多种因素。部分模型经过特征波长选择后，建模效果优于全波长情形，而部分则相反。对于传统机器学习而言，关键在于探寻光谱预处理与特征波长选择算法的有机结合方式，以实现输入变量数目精简且模型稳健的分类解决方案。

表 3 基于特征波长的分类结果						
Table 3 Classification results based on feature wavelength						
预处理	算法	模型	参数	准确率/%		
				训练集	验证集	测试集
Raw	PCA	PLS-DA	LVs=8	87.04	73.89	80.56
WTD			LVs=7	86.30	73.90	83.34
MSC			LVs=8	82.22	62.22	77.22
detrending			LVs=8	86.48	88.33	84.44
baseline			LVs=8	83.52	72.78	78.89
Raw	BOSS	PLS-DA	Num=17	90.37	88.33	87.22
WTD			Num=13	90.74	85.00	88.33
MSC			Num=15	91.85	90.00	90.56
detrending			Num=18	87.22	92.78	86.11
baseline			Num=19	86.48	81.67	84.44
Raw	PCA	ELM	LVs=10	92.04	93.33	83.33
WTD			LVs=12	94.63	97.22	92.22
MSC			LVs=11	85.00	80.56	83.89
detrending			LVs=7	89.07	92.22	88.33
baseline			LVs=9	81.67	84.44	78.89
Raw	BOSS	ELM	Num=20	93.70	95.56	92.78
WTD			Num=17	92.59	95.00	92.78
MSC			Num=19	91.30	86.67	89.44
detrending			Num=16	91.48	88.89	90.56
baseline			Num=13	82.22	80.00	75.00




图 6 MSC-1DCNN 模型训练过程图

Fig.6 MSC-1DCNN model training process diagram

注: (a) 损失值曲线; (b) 准确率曲线。

2.4 分类模型的对比分析

传统的光谱数据分析流程通常涵盖去噪、降维以及建模等环节。去噪旨在有效消除光谱数据中所包含的噪声干扰，确保数据的纯净度；降维过程中，常借助波长选择方法，以实现对原始光谱数据维度的降低，从而简化数据结构；建模环节则一般采用化学计量学与机器学习方法，构建线性或非线性的校准模型，以此实现对光谱数据的有效分析与解读。与之不同，1DCNN 模型具有独特优势，其无需人工进行数据特征工程的繁琐步骤，能够直接从海量的全光谱信息中，自动学习并提取出有利于判别芒果成熟度的抽象特征。在高光谱成像用于芒果成熟度判别的特定场景下，深入对比分析传统方法与深度学习方法的适用性，具有重要的理论意义与实践价值。在传统方法中，依据测试集准确率，筛选出 detrending-PLS-DA、MSC-ELM、WTD-BOSS-PLS-DA 和 Raw-BOSS-ELM 模型，将其与 MSC-1DCNN 模型进行对比。在测试集层面，MSC-1DCNN 模型的准确率高达 98.30%，相较于 detrending-PLS-DA、MSC-ELM、WTD-BOSS-PLS-DA 和 Raw-BOSS-ELM 模型，分别高出 6.63%、4.97%、6.08% 和 5.52%。MSC-1DCNN 模型在训练过程中，

其交叉熵损失函数值曲线与准确率曲线呈现出特定的变化趋势，如图 6 所示。随着迭代次数的逐步增加，训练集与验证集的损失值起初快速下降，随后逐渐趋于平稳。同样，准确率在前期 200 次迭代时急剧上升，之后亦趋于稳定状态。此外，针对 MSC-1DCNN 模型与传统机器学习模型，除了对比测试集准确率外，还对其他性能评价指标展开了对比分析，结果如表 4 所示。以 Kappa 系数为衡量指标，将分类模型按照从高到低的顺序排列，依次为 MSC-1DCNN、MSC-ELM、Raw-BOSS-ELM、WTD-BOSS-PLS-DA 和 detrending-PLS-DA。由此可见，在传统机器学习分类模型中，ELM 相较于 PLS-DA 展现出更为优异的建模效果，这主要归因于 ELM 具备处理非线性关系的能力，而 PLS-DA 仅能处理线性关系。经 MSC 预处理后的光谱数据所构建的一维卷积神经网络分类模型，其 Kappa 系数比 MSC-ELM 高出 0.07。综合实验结果表明，在芒果成熟度分类这一应用场景中，MSC-1DCNN 深度学习分类模型相较于传统机器学习分类模型，展现出更为卓越的性能表现。

表 4 1DCNN和传统机器学习分类模型在测试集上的性能对比

Table 4 Performance comparison between 1DCNN and traditional machine learning classification models on prediction sets

分类模型	Kappa 系数	类别	精确率/%	召回率/%	F1 分数/%
MSC-1DCNN	0.97	I	98.33	98.33	98.33
		II	98.36	96.77	97.56
		III	98.31	100.00	99.15
MSC-ELM	0.90	I	96.55	93.33	94.92
		II	93.10	87.10	90.00
		III	90.63	100.00	95.08
Raw-BOSS-ELM	0.89	I	100.00	87.50	93.33
		II	90.54	91.78	91.16
		III	90.63	98.31	94.31
WTD-BOSS-PLS-DA	0.88	I	97.92	97.92	97.92
		II	92.31	86.96	93.65
		III	88.06	93.65	90.77
detrending-PLS-DA	0.87	I	92.73	98.08	95.33
		II	96.36	80.30	87.60
		III	87.14	98.39	92.42

注: I 为未熟芒果, II 为成熟芒果, III 为过熟芒果。

3 结论

在本研究中,选用覆盖 400~1 000 nm 波长范围的高光谱成像系统,针对不同成熟度(未熟、成熟、过熟)的芒果样本,精确采集其光谱数据。随后,运用 SPXY 算法,将所获数据按照特定比例划分为训练集、验证集以及测试集。基于深度学习理论,构建 1DCNN 模型,并与基于全波段及特征波段的传统机器学习分类模型,就模型性能展开系统比较。实验结果清晰显示,传统机器学习分类模型的性能,不仅显著受制于光谱预处理方式以及光谱特征波长的选取,同时亦受数据样本量规模、数据特征变量等诸多因素的影响。从测试集的分类准确率、精确度、召回率、F1 分数以及 Kappa 系数等多维度指标综合评估,1DCNN 模型表现出相较于传统方法更为优异的性能。究其根源,深度学习模型在挖掘全光谱数据中潜在的空间高维信息方面具备独特优势,且无需人工进行特征提取,从而有效提升了判别分析的工作效率。综上所述,应用高光谱成像技术与深度学习算法相结合的方式,对芒果成熟度进行无损判别具备切实可行性。展望未来,研究工作将聚焦于神经网络在硬件实际检测系统中的部署,旨在优化实验室环境下高光谱成像无损检测的操作流程,进而进一步提升芒果成熟度判别的效率。

参考文献

- [1] MARISTELLA V, ANNA R, MAURIZIO G, et al. Modeling mango ripening during shelf life based on pulp color nondestructively measured by time-resolved reflectance spectroscopy [J]. *Scientia Horticulturae*, 2023, 310: 111714.
- [2] PARIKA R, NIMMITRA C, PRAMOTE K, et al. Comparison of near-infrared spectroscopy and hyperspectral imaging for internal quality determination of 'Nam Dok Mai' mango during ripening [J]. *Journal of Food Measurement and Characterization*, 2023, 17: 1501-1514.
- [3] BUSARAKORN M, PARIKA R, PASINEE Y, et al. Temporal changes in the spatial distribution of physicochemical properties during postharvest ripening of mango fruit [J]. *Journal of Food Measurement and Characterization*, 2020, 14: 992-1001.
- [4] 冯建英,李鑫,原变鱼,等.智能感官技术在水果检测中的应用进展及趋势[J].*南方农业学报*,2020,51(3):636-644.
- [5] PU Y Y, FENG Y Z, SUN D W. Recent progress of hyperspectral imaging on quality and safety inspection of fruits and vegetables: A review [J]. *Comprehensive Reviews in Food Science and Food Safety*, 2015, 14(2): 176-188.
- [6] 孙梦梦,鞠皓,姜洪喆,等.水果成熟度无损检测技术研究进展[J].*食品与发酵工业*,2023,49(17):354-362.
- [7] 常洪娟,蒙庆华,吴哲锋,等.基于反向传播神经网络和高光谱成像的芒果可溶性固形物含量检测[J].*食品安全质量检测学报*,2024,15(2): 141-148.
- [8] SALVADOR G, ALEXANDER W, JAMES U. Spectral filter design based on in-field hyperspectral imaging and machine learning for mango ripeness estimation [J]. *Computers and Electronics in Agriculture*, 2019, 164: 104890.
- [9] MITHUN B S, MILTON M, HARSH V, et al. Detection of artificially ripened mango using spectrometric analysis [J]. *Sensing for Agriculture and Food Quality and Safety IX*, 2017, 10217: 1-9.
- [10] NAYELI V R, JUAN G, JORGE C, et al. Early detection of mechanical damage in mango using NIR hyperspectral images and machine learning [J]. *Biosystems Engineering*, 2014, 122: 91-98.
- [11] ALESSANDRO B, CHIARA C, LUIGI R, et al. In-field and non-destructive monitoring of grapes maturity by hyperspectral imaging [J]. *Biosystems Engineering*, 2021, 207: 59-67.
- [12] 刘金秀,贺小伟,罗华平,等.基于高光谱成像技术的小白杏成熟度判别模型[J].*食品研究与开发*,2022,43(15):158-165.
- [13] 李丽丽,王斌,张学豪,等.基于高光谱成像技术的李果实成熟度判别[J].*现代食品科技*,2019,35(6):258-263.
- [14] 胡逸磊,姜洪喆,周宏平,等.高光谱成像技术检测油茶果成熟度[J].*食品科学*,2022,43(16): 324-331.
- [15] LUO N, XU D M, XING B, et al. Principles and applications of convolutional neural network for spectral analysis in food quality evaluation: A review [J]. *Journal of Food Composition and Analysis*, 2024, 128: 105996.
- [16] 刘文政,周雪健,平凤娇,等.基于可见-近红外光谱的鲜食葡萄成熟品质关键指标检测[J].*农业机械学报*,2024,55(2): 372-383.
- [17] LIU X Y, AN H L, CAI W S, et al. Deep learning in spectral analysis: Modeling and imaging [J]. *Trends in Analytical Chemistry*, 2024, 172: 117612.
- [18] 蔡健荣,黄楚钧,马立鑫,等.一维卷积神经网络的手持式可见/近红外柑橘可溶性固形物含量无损检测系统[J].*光谱学与光谱分析*,2023,43(9):2792-2798.
- [19] 吴德刚,赵利平,陈乾辉.基于近红外光谱的大枣成熟度无损检测方法[J].*激光杂志*,2023,44(7):212-217.
- [20] 周晨昕,刘英,夏海飞,等.基于高光谱数据的青梅成熟度分类方法[J].*林业工程学报*,2025,10(3):146-153.
- [21] BO L, JULIEN L, GERARD B. Advances in non-destructive early assessment of fruit ripeness towards defining optimal time of harvest and yield prediction-A review [J]. *Plants*, 2018, 7(1): 3.
- [22] CORTÉS V, ORTIZ C, ALEIXOS N, et al. A new internal quality index for mango and its prediction by external visible and near-infrared reflection spectroscopy [J]. *Postharvest Biology and Technology*, 2016, 118: 148-158.
- [23] SHAO Y Y, JI S H, SHI Y K, et al. Growth period determination and color coordinates visual analysis of tomato using hyperspectral imaging technology [J]. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 2024, 319: 124538.
- [24] YAO K S, SUN J, ZHOU X, et al. Nondestructive detection for egg freshness grade based on hyperspectral imaging technology [J]. *Journal of Food Process Engineering*, 2020, 43(7): 13422.
- [25] SONG W R, SONG Z Y, JORDAN V, et al. Quantification of extra virgin olive oil adulteration using smartphone videos [J]. *Talanta*, 2020, 216: 120920.

[26] YUAN R R, LIU G S, HE J G, et al. Classification of Lingwu long jujube internal bruise over time based on visible near-infrared hyperspectral imaging combined with partial least squares-discriminant analysis [J]. Computers and Electronics in Agriculture, 2021, 182: 106043.

[27] ZHANG C, GUO C T, LIU F, et al. Hyperspectral imaging analysis for ripeness evaluation of strawberry with support vector machine [J]. Journal of Food Engineering, 2016, 179: 11-18.

[28] DENG B C, YUN Y H, CAO D S, et al. A bootstrapping soft shrinkage approach for variable selection in chemical modeling [J]. Analytica Chimica Acta, 2016, 908: 63-74.

[29] TAN C, CHEN H, CHEN M X, et al. Rapid identification of silk products by attenuated total reflection-mid-infrared spectroscopy and extreme learning machines [J]. Infrared Physics and Technology, 2024, 139: 105334.

[30] GAO S, XU J H. Hyperspectral image information fusion-based detection of soluble solids content in red globe grapes [J]. Computers and Electronics in Agriculture, 2022, 196: 106822.

[31] TIAN P, MENG Q H, WU Z F, et al. Detection of mango soluble solid content using hyperspectral imaging technology [J]. Infrared Physics and Technology, 2023, 129: 104576.

[32] 林娇娇,蒙庆华,吴哲锋,等.基于近红外高光谱技术的芒果可溶性固形物含量无损检测[J].果树学报,2024,41(1):122-132.