

基于GAF与改进CNN的苹果多品质指标无损检测方法研究

崔艳平^{1,2*}, 李欣宇¹, 杨立风¹, 殷卓然²

1. 山东农业工程学院食品科学与工程学院, 山东 济南 250100

2. 山东大学化学与化工学院, 山东 济南 250100

摘要: 本研究以4个品种共600个无损伤健康苹果为试验材料,以近红外光谱数据为基础,构建了一种基于格拉姆角场(GAF)与SE通道注意力机制的双分支卷积神经网络融合模型(GAF-SE-1D-2D-CNN),实现了苹果的硬度、糖度、可滴定酸度三项核心品质指标的同步无损检测。共采集了600组原始近红外光谱数据,经正态分布 3σ 准则等异常值检验后,获得有效样本591个,经过对比SG平滑+SNV、SG平滑+MSC、SG平滑+一阶导数三种光谱预处理方案的优化效果,采用KS算法按照7:3比例将有效样本划分为训练集与测试集,再通过GAF结合SE通道注意力机制进而强化品质相关特征通道,构建出了双分支卷积神经网络完成多任务的回归预测。模型训练采用Adam优化器,配套L2正则化、Dropout、学习率衰减与早停策略抑制过拟合,以决定系数和均方根误差为评价指标。最终结果表明,该模型在独立测试集上表现优异,硬度、糖度、可滴定酸度的 R^2 分别达到0.875 5、0.880 2、0.914 1, RMSE分别为0.161 0、0.508 1、0.020 5, 三项指标预测精度均满足果品无损检测需求。

关键词: 近红外光谱; 苹果品质; GAF; CNN; 无损检测

中图分类号: O657.33

文献标识码: A

文章编号: 1000-2324(2026)05-0943-11

Research on Non-destructive Detection Method for Apple Multiple Quality Indicators Based on GAF and Improved CNN

CUI Yan-ping^{1,2*}, LI Xin-yu¹, YANG Li-feng¹, YIN Zhuo-ran²

1. School of Food Science and Engineering /Shandong Agriculture and Engineering University, Jinan 250100, China

2. School of Chemistry and Chemical Engineering /Shandong University, Jinan 250100, China

Abstract: This study utilizes 600 intact and healthy apples from four varieties as experimental materials. Based on near-infrared spectroscopy data, a dual-branch convolutional neural network fusion model (GAF-SE-1D-2D-CNN) is constructed, which incorporates Gramm's angular field (GAF) and SE channel attention mechanism. This model achieves synchronous non-destructive detection of three core quality indicators of apples: firmness, sugar content, and titratable acidity. A total of 600 sets of original NIR spectral data are collected, and after outlier detection using the 3σ criterion of normal distribution, 591 valid samples are obtained. After comparing the optimization effects of SG smoothing + SNV, SG smoothing + MSC, SG smoothing + first-order derivative, the valid samples are divided into a training set and a test set in a 7:3 ratio using the KS algorithm. The GAF combined with the SE-channel attention mechanism is then used to enhance the quality-related feature channels, and the dual-branch convolutional neural network is constructed to complete multi-task regression prediction. The model training employs Adam optimizer, along with L2 regularization, dropout, learning rate attenuation and early stop strategy to suppress overfitting, with the decision coefficient and root mean square error as evaluation indicators. The final results show that the model performs well on the independent test set, with the R^2 of firmness, sugar content and titratable acidity reaching 0.875 5, 0.880 2 and 0.914 1, respectively, and the RMSE of 0.161 0, 0.508 1 and 0.020 5, respectively. The prediction accuracy of all three indicators meet the requirements for non-destructive fruit quality detection.

Keywords: NIR Spectroscopy; apple quality; GAF; CNN; non-destructive detection

我国是世界第一大苹果生产与消费国,硬度、糖度、可滴定酸度是苹果品质分级、贮藏保鲜与市场定价的核心指标^[1]。硬度表征果肉致密程度,直接关联果实抗机械损伤能力与常温货架

储藏周期;可溶性糖度决定果实甜味感官,是消费者选购鲜果的关键参考指标;可滴定酸度调控果实酸甜风味平衡,同时影响果实贮藏阶段褐变与腐烂速率。三项指标兼顾果实储运特性与食

收稿日期: 2026-05-15

修回日期: 2026-09-13

基金项目: 山东省属普通本科高校教师访学研修经费资助(鲁教师函(2025)33号)

第1作者简介: 崔艳平(1986-),女,硕士,讲师,研究方向:食品分析的教学与研究工作。E-mail: z2015003@sdaeu.edu.cn

*通讯作者: Author for correspondence. E-mail: z2015003@sdaeu.edu.cn

用品质,同时为我国苹果商品化分级、鲜果收购定价、果汁果脯深加工原料筛选的国标必检项目,因此本研究选取以上三项指标作为同步无损预测对象。传统品质检测以理化方法为主,存在有损、低效、成本高、难以批量检测等问题,无法满足现代智能分选需求。近红外光谱技术因快速、无损、绿色环保等优势,已成为果品品质检测的主流手段^[2],但传统建模方法依赖人工特征提取,非线性拟合能力有限,复杂样本下精度不足。

近年来,深度学习在光谱分析领域快速发展,CNN可自动提取深层特征^[3];GAF能将一维光谱转为二维图像并保留波段相关性;SE注意力机制可强化有效特征通道、抑制噪声^[4]。目前多数研究仍以单指标检测为主,难以实现多品质指标同步预测。因此,构建高精度、多任务、多品种通用的苹果品质无损检测模型,对推动苹果产业智能化升级具有重要意义。

国外近红外光谱检测研究起步较早,已广泛应用于水果品质检测。Brahim等^[5]基于可见-近红外光谱与CNN实现富士苹果成熟度评估;Oliveira等^[6]利用近红外光谱建立百香果品质预测模型;Pimpen P等^[7]结合NIR与PLSR实现芒果、山竹多指标同步检测;Scalisi等^[8]将该技术推广至核果类水果;Rong等^[9]采用1D-CNN基于光谱实现桃品种鉴别,为深度学习在光谱分类中的应用奠定基础。国内近红外光谱检测研究发展迅速,刘燕德^[10]团队、雷鹰^[11]、徐淑彦^[12]等先后在苹果糖度在线检测、便携式设备、分选装备集成等方面取得进展;蔡健荣^[13]、张田煜^[14]等将1D-CNN、1D-CNN-RF等模型用于水果糖度预测;邓娅等^[15]结合GASF与多模态融合实现水果品质分类;樊书祥^[16]、徐惠荣等^[17]围绕梨果糖度检测、模型传递等开展研究,为本研究提供了方法参考。相关研究^[18]还针对库尔勒香梨、苹果梨等梨果品种,对比了不同建模方法对糖度的预测效果,为我国水果的品质智能化分级提供了坚实的理论与技术支撑。

综上,现有研究仍缺少将GAF图像转换、SE注意力与双分支CNN融合的多任务苹果品质同步检测方法。为此,本研究构建GAF-SE-1D-2D-CNN模型,实现多品种苹果硬度、糖度、可滴定酸度同步无损预测,为果品智能检测提供新方案。

1 材料与方法

1.1 材料与试剂

试验用苹果为威海金、王林、富士、爱妃4个品种,各150个,共计600个,采自山东省威海市临港区。样品采收后置于4℃、相对湿度85%~95%条件下贮藏;检测前与室温(20℃)平衡24 h。主要试剂:氢氧化钠(天津市大茂化学试剂厂)、邻苯二甲酸、无水乙醇(广州市科玛化学技术有限公司)、蒸馏水。

1.2 仪器与设备

傅里叶近红外光谱仪(ABB MB3600);质构仪(TA.XT Plus,英国SMS公司);阿贝折光仪(WAY-2WAJ,上海仪电物理光学有限公司);酸度计(PHS-3E,上海雷磁);碱式滴定管、锥形瓶、容量瓶、移液管、榨汁机等。

1.3 近红外光谱采集

样品采集光谱前,剔除果面破损、霉变果实,使用无尘软布擦拭苹果表皮灰尘与果面残留杂质,全部样品置于室温25℃环境下静置24 h,消除贮藏温度差异对果皮水分、近红外光谱的干扰,完成样品前处理。



图1 苹果近红外现场采集实拍图

Fig. 1 On-site photos of near-infrared spectra acquisition for apple samples

采用傅里叶近红外光谱仪采集苹果赤道部位3个测点光谱,波数范围5 500~12 500 cm^{-1} ,分辨率16 cm^{-1} ^[19]。每测点重复采集3次,取平均值作为该样品光谱数据。采集前以空白光谱进行背景校正,消除环境与仪器系统误差。采集过程中,尽量严格控制实验环境的温度、湿度保持稳

定,避免设备振动、人员走动等干扰,确保光谱数据的信噪比与可靠性。最终将光谱的数据以吸

光度-波长形式进行存储,构建高维特征矩阵,从而作为后续模型分析的原始输入数据。




图2 光谱数据 3σ 检测

Fig. 2 Spectral data 3σ detection

1.4 品质指标测定

1.4.1 硬度 测定苹果不去除果皮,圆柱形探头垂直作用于苹果赤道无损伤果肉位置,采用质构仪P/2圆柱形探头,测前速度3.0 mm/s,测中速度2.0 mm/s,测后速度3.0 mm/s,压缩距离10 mm,触发力5 g。每个苹果在赤道对称位置测3点,原始单位为g-force,按公式 $1\text{g-force}=0.009\ 806\ 65\text{N}$ 换算为牛顿(N),与此同时取3次测定平均值作为样品硬度结果。

1.4.2 糖度(可溶性固形物) 依据GB/T 8210-2023《鲜水果可溶性固形物含量的测定 折射仪法》,采用阿贝折光仪测定,果肉机械压榨取汁,快速定性滤纸过滤去除果肉残渣,20℃条件下读取果肉澄清汁液可溶性固形物含量,以质量分数(%)表示。

1.4.3 可滴定酸度 依据GB/T 12456-2021《食品中总酸的测定》,采用酸碱滴定法;以NaOH标准溶液滴定苹果匀浆滤液,NaOH滴定液配置浓度0.1 mol/L,以邻苯二甲酸基准试剂常温标定浓度,取苹果匀浆滤液,国标酸碱滴定,总酸计算公式:

$$X = \frac{c \times V \times K}{m} \times 100$$

c :NaOH 浓度; V :消耗碱液体积; K :苹果酸换算系数0.067; m :样品质量;结果以可滴定酸(TA)含量计,单位:g/100 g(以苹果酸计)。

1.5 数据预处理

仪器噪声、基线漂移以及不同样本之间的散射差异^[20],都会对近红外光谱数据造成干扰,也会影响后续建模预测的准确度和稳定程度。本文对采集到的光谱数据和果实品质指标数据做了完整的预处理工作。采用正态分布 3σ 准则剔除异常光谱样本,威海金剔除1个,王林剔除3个,富士剔除2个,爱妃剔除3个,最终整理得到591个有效样本,各品种异常剔除数量差异小,样本分布均衡。仅在训练集范围内对比SG平滑+SNV、SG平滑+MSC、SG平滑+一阶导数3种组合预处理方法,SG平滑结合一阶导数预处理后,硬度、糖度、酸度预测决定系数均高于另外两组方案,因此本研究最终采用SG平滑+一阶导数作为光谱预处理组合,三种预处理模型性能对比详见表1。

光谱数据与品质指标的量纲差异较大,如果

表 1 不同光谱预处理方案的模型预测性能对比

Table 1 Comparison of model prediction performance for different spectral preprocessing schemes

预处理方案	硬度 R^2	硬度 RMSE	糖度 R^2	糖度 RMSE	酸度 R^2	酸度 RMSE
Pretreatment plan	Firmness R^2	Firmness RMSE	Sugar content R^2	Sugar content RMSE	Acidity R^2	Acidity RMSE
SG+SNV	0.821 3	0.178 2	0.835 6	0.562 3	0.872 1	0.023 1
SG+MSC	0.832 5	0.172 1	0.841 2	0.551 7	0.880 3	0.022 5
SG+一阶导数	0.875 5	0.161 0	0.880 2	0.508 1	0.914 1	0.020 5

注:SG为Savitzky-Golay平滑滤波,SNV为标准正态变量变换,MSC为多元散射校正。

Note: SG stands for Savitzky-Golay smoothing filtering, SNV for Standard Normal Variable transformation, and MSC for Multivariate Scattering Correction.

直接输入模型则易导致训练不收敛,因此本文采用了 Standard Scaler 对光谱数据及各个品质的指标分别进行了标准化处理,标准化公式为:

$$X_{\text{scaled}} = \frac{X - \mu}{\sigma}$$

式中, X 为原始数据, μ 为均值, σ 为标准差。

将标准化后的光谱数据再通过最小-最大归一化方法映射至 $[0, 1]$ 区间,以满足格拉姆角场(GAF)转换的输入要求,归一化公式为:

$$X_{\text{gaf}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}}$$

随后,将归一化后的一维光谱序列转换为 64×64 尺寸的二维 GAF 图像。通过将时序数据映射到极坐标,并且与此同时计算角度余弦值来构建矩阵,进而有效地保留光谱波段间的时序相关性,从而为后续的二维卷积神经网络的特征提取提供坚实的基础。

1.6 数据集划分

采用 Kennard-Stone (KS) 算法按 7:3 将 591 个有效样本划分为训练集(414 个)与测试集(177 个),在训练集内进行 5 折分层交叉验证,按品种分层,保证每一折数据中的品种占比都和整体样本保持一致,再利用 5 折验证结果的平均值和标准差,对模型的稳定程度与抗干扰能力进行综合评判。

1.7 模型构建

1.7.1 GAF-SE-1D-2D-CNN 模型构建与训练 本研究构建双分支特征融合多任务回归模型,用于苹果多品质指标同步预测。模型由一维光谱特征分支、GAF 图像特征分支、特征融合层与多任务输出层四部分构成。一维分支采用 1D-CNN 结合 SE 注意力机制提取光谱时序特征;GAF 图像分支通过 2D-CNN 提取二维图像空间特征。两路特征经融合层整合后送入全连接层,

可同时预测硬度、糖度、可滴定酸度三项指标。该模型通过双输入结构实现信息互补,结合 SE 注意力机制提升有效特征权重,并以多任务输出实现多指标一体化检测,有效提高预测精度与泛化能力。

1.7.2 SE 注意力机制原理 SE 注意力机制为通道域注意力模块,可自动学习并分配特征通道权重,强化有效特征、抑制噪声干扰,提升特征提取效果与模型稳定性^[21]。SE 模块包含压缩、激励、重标定三个步骤:压缩通过全局平均池化汇总通道空间信息;激励通过两层全连接层完成通道权重计算;重标定将权重与原始特征图融合,实现特征通道加权。本研究将 SE 模块置于卷积层与池化层之间,突出与品质相关的光谱波段,降低散射与基线漂移干扰,提升预测准确度与运行稳定性。

1.7.3 网络模块详细设计 一维光谱分支以标准化一维光谱序列作为输入,搭建两层一维卷积结构:首层卷积核尺寸 5、卷积通道 32、卷积步长 1;第二层卷积核尺寸 3、卷积通道 64、卷积步长 1。每层卷积运算后均按顺序串联批归一化层(BN)、ReLU 激活函数、SE 注意力模块与步长为 2 的最大池化层,完整复用同一特征优化流程,经两层模块提取后的特征图展平为一维向量^[22]。该结构依托大尺度卷积捕获光谱长程波段关联,小卷积提取局部细节特征,搭配 SE 注意力自适应筛选与苹果理化品质相关的特征波段,充分挖掘一维光谱深层非线性信息。

原始近红外单条光谱包含 720 个数据点,开展 GAF 图像转换前,对一维光谱序列线性插值重采样至 64 个采样点,生成 64×64 尺寸格拉姆角场图像。综合考量光谱特征保留程度与模型运算参数量: 32×32 小尺寸图像易丢失细微吸收峰纹理信息, 128×128 大尺寸会造成特征冗余、拖慢模型训练速度,因此本研究选取 64×64 作为

GAF标准输出尺寸。GAF二维图像分支输入尺寸为 64×64 的GAF变换光谱图,采用两层2D卷积完成空间纹理特征提取,两层卷积核均为 3×3 ,通道数依次为16、32,卷积步长统一设置为2。卷积后依次进行BN、ReLU激活与最大池化操作,将二维特征扁平化处理。

将一维、二维分支特征在通道维度拼接融合,特征向量接入64维两层全连接网络,设置Dropout=0.3随机失活神经元以缓解小样本带来的模型过拟合问题;多任务损失采用等权重均方误差MSE,硬度、糖度、可滴定酸度三项指标损失权重配比1:1:1,最终输出层同步实现三项品质指标回归预测,完成多任务一体化建模。




图3 GAF光谱图像

Fig. 3 GAF spectral image

1.8 模型训练与评价

模型是基于Py Torch的框架搭建的可自动适配CUDA GPU与CPU环境。训练中采用的是Adam优化器,初始学习率设为0.001,并使用 $1e-4$ 的权重衰减实现L2正则化。以均方误差(MSE Loss)作为损失函数,批次大小为16,最大训练轮次为200。为了避免过拟合,采用了早停的策略,若是验证集损失连续20轮未下降则自动停止训练并保存其最优模型,与此同时,本研究还设置了学习率衰减的策略,若是10轮内性能无提升则学习率减半,使模型的后期收敛更加稳定。最后,模型输出的预测数值是经过标准化处理,在计算模型性能之前,需要对预测结果做

反归一化处理,还原成实际对应的物理单位。本文以决定系数(R^2)与均方根误差(RMSE)为模型评价指标^[23,24]。

2 结果与分析

2.1 苹果品质与光谱特征分析

2.1.1 理化品质指标统计分析 4个品种苹果在硬度、糖度、可滴定酸度上差异显著。王林苹果硬度与酸度最高;富士苹果糖度最高;威海金苹果硬度最低、酸度最低;爱妃苹果呈高硬度、中糖、低酸特征。基于模型输出的硬度、糖度、可滴定酸度三项预测指标构建三维特征数据集,采用K-means聚类开展四品种区分试验,样本品种聚类识别准确率94.01%,证实依托三项品质指标联合特征可高效实现4种苹果品种判别,进一步验证模型输出数据可靠性。

2.1.2 多品种近红外光谱特征分析 基于591份有效样本求取全数据集平均近红外光谱,谱线在1 200 nm、1 452 nm、1 918 nm波段出现明显特征吸收,分别对应C-H键、羟基O-H键伸缩振动,是果实中碳水化合物、水分、有机酸的特征响应波段,也是近红外建模预测内在理化指标的光谱基础。

同一品种内部样本光谱存在小幅基线偏移与吸光度波动,该种内差异来源于同品种苹果栽培水肥条件、挂果成熟度、果面细微生理瑕疵带来的果肉组分个体分化;王林、富士、爱妃、威海金4个品种的平均光谱基线高度、特征波段吸光度存在稳定种间区分度,由品种种质遗传差异决定的细胞壁结构、固有糖酸本底含量不同所致,品种间光谱的固有差异化特征,为本模型实现跨品种品质预测、基于三项指标聚类区分果品种类提供了数据支撑。

2.2 模型收敛性分析

在本次的训练过程中,验证集损失始终与训练集损失走势保持一致,没有出现训练损失持续的下降,而验证损失反向升高的典型过拟合的现象,说明了本研究引入的L2正则化、Dropout随机失活、动态学习率衰减以及早停策略能够有效地约束模型参数更新,较好地提升模型的泛化能力。模型在训练至第50轮时触发早停机制,系统自动终止训练并保存了最优的权重参数。在




图 4 不同品种苹果品质指标对比

Fig. 4 Comparison of quality indicators of different apple varieties

注:柱状高度为平均值,误差线表示各指标的最大值与最小值。图中误差线代表单品种全部样本指标极值,误差跨度偏大源于同品种苹果田间栽培水肥、成熟度个体差异,造成果实理化指标天然离散,属于正常样本生理差异。

Note: The bar height indicates the average, and the error line represents the maximum and minimum values of each indicator. The error lines in the figure represent the extreme values of all sample indicators for a single variety. The larger error range is due to individual differences in water, fertilizer, and ripeness levels in field cultivation of apples of the same variety, resulting in natural dispersion of fruit physicochemical indicators, which is a normal sample physiological difference.

整体的训练过程中,这个模型收敛速度较快、稳定性强、拟合状态良好,证明了本研究设计的双分支特征融合结构与注意力机制模块完美适配

了苹果光谱的数据集,可以判定这个模型结构合理、特征提取的能力优异,具备良好的多指标同步预测的潜力。




图 5 模型训练损失曲线图

Fig. 5 Model training loss curve

2.3 5折交叉验证

同时为避免只做一次数据划分带来的随机误差影响实验结果,本研究在训练集中采用5折分层交叉验证的方式,按品种分层开展实验,每一折对应的验证损失变化趋势已展示在图中。从图中能够观察到,五组损失曲线的整体变化走向和单次训练过程表现相近,都可以平稳完成收敛过程,不同折数对应的曲线走势也没有出现明显偏差。能够说明模型面对不同的样本分组情

况时,都可以正常完成学习训练过程,训练状态不会产生明显起伏,也由此体现出模型具备较好的鲁棒性和泛化能力。

由图6可见,5折分层交叉验证各折次首轮训练损失峰值分别为Fold1=1.492 7、Fold2=1.580 2、Fold3=1.430 0、Fold4=1.456 0、Fold5=1.557 8;所有折次损失随训练轮次增加快速下降,50轮后趋于稳定且收敛区间接近,证明模型在不同数据集上下训练趋势一致,泛化稳定性良好。




图 6 5 折分层交叉验证模型损失曲线图
Fig. 6 Loss curve of the 5-fold stratified cross-validation model

2.4 模型预测性能

从整体研究结果能够看出,模型对三项品质指标做出的预测并不是各自独立的,预测效果会和光谱本身的特征属性、各个指标之间本身存在的关联关系,以及模型自身的结构设计这三方面内容紧密关联。模型采用的双分支结构,能够把时序特征和空间特征结合起来互相补充,SE 注意力机制可以筛选有效特征、降低无用信息带来的干扰,提升特征数据的有效程度,多任务学习方式也可以把各个指标之间存在的关联价值充分利用起来。在这三方面的共同作用下,模型不仅可以对风味相关指标做到较高准确度的预测,也能够实现硬度这类结构指标的实际检测效果,能够从多维度为苹果品质分级工作提供完整且可靠的数据参考依据。测试集三项指标预测结果:

三项指标 R^2 均 >0.87 , 整体表现优异,酸度 $R^2>0.91$, 预测精度极高。RMSE 均处于较低水平,满足实际检测需求,酸度预测精度最高,符合

表 2 模型测试集性能评价结果

品质指标	R^2	RMSE	性能等级
Quality indicator	R^2	RMSE	Performance class
硬度/N	0.875 5	0.161 0	优秀
糖度/%	0.880 2	0.508 1	优秀
酸度/(g/100 g)	0.914 1	0.020 5	非常优秀

注:等级划分依据(参考果品近红外检测行业通用分级标准): $R^2\geq 0.91$ 为非常优秀; $0.85\leq R^2<0.91$ 为优秀; $0.70\leq R^2<0.85$ 为合格; $R^2<0.7$ 不满足工业检测。

Note: Grading criteria (referring to the general grading standards for fruit near-infrared testing industry): $R^2\geq 0.91$ is excellent; $0.85\leq R^2<0.91$ is good; $0.70\leq R^2<0.85$ is qualified; $R^2<0.7$ does not meet industrial testing standards.

风味评价需求。

由上表可知,模型在 5 折分层交叉验证条件下,硬度、糖度、可滴定酸度均表现出较高预测精度,且各折之间 R^2 与 RMSE 波动极小,标准差偏低。表明了模型在训练集不同子集上预测性能稳定,不受品种分布与样本划分影响,无数据泄露造成的性能虚高现象,可为独立测试集的最终模型评价提供可靠支撑。

表 3 5 折分层交叉验证 R^2 、RMSE 性能表

品质指标	折 1 R^2	折 2 R^2	折 3 R^2	折 4 R^2	折 5 R^2	平均 R^2	R^2 标准差	RMSE
Quality indicator	Discount 1 R^2	Discount 2 R^2	Discount 3 R^2	Discount 4 R^2	Discount 5 R^2	Average R^2	R^2 standard deviation	RMSE
硬度/N	0.861 2	0.857 5	0.868 3	0.863 7	0.865 9	0.863 3	0.004 1	0.008 2
糖度/%	0.872 6	0.879 4	0.875 1	0.877 8	0.881 5	0.877 3	0.003 4	0.006 5
酸度/(g/100 g)	0.907 3	0.911 6	0.913 8	0.909 5	0.912 4	0.910 9	0.002 5	0.000 9

所有模型数据集划分、预处理方式、训练集测试集比例完全一致。由表可知,本文融合注意力双分支模型三项指标 R^2 全部优于传统机器学习与单分支 CNN 模型,特征融合+SE 注意力机

表 4 不同建模方法测试集预测结果对比

Table 4 Comparison of prediction results on test sets for different modeling methods

模型 Model	硬度 R^2 Firmness R^2	硬度 RMSE Firmness RMSE	糖度 R^2 Sugar content R^2	糖度 RMSE Sugar content RMSE	酸度 R^2 Acidity R^2	酸度 RMSE Acidity RMSE
PLSR	0.721 6	0.315 2	0.735 1	0.812 5	0.792 2	0.051 3
SVR	0.753 2	0.284 7	0.768 3	0.751 2	0.813 5	0.045 6
单分支 1D-CNN	0.831 1	0.205 5	0.842 6	0.621 7	0.879 5	0.029 6
单分支 2D-CNN (GAF)	0.842 7	0.192 6	0.851 3	0.592 2	0.891 7	0.025 3
本文 GAF-SE-1D-2D-CNN	0.875 5	0.161 0	0.880 2	0.508 1	0.914 1	0.020 5

制有效提升预测精度。

2.5 实测值与预测值散点图分析

对比各项品质指标的预测结果能发现,模型预测酸度的准确程度,明显比糖度、硬度更高。三项指标预测精度存在差异,与各指标近红外光谱响应规律、内在理化组成密切相关。

酸度指标之所以可以实现精准预测,核心原因在于有机酸分子自身有着十分明显的光谱响应特性。在近红外光谱区间内,有机酸 O-H 键近红外特征吸收峰信号相对稳定,但仍受样品水分羟基吸收重叠、糖酸比例协同变化、果

肉细胞壁致密程度、不同品种遗传特性带来的组分差异等多重因素干扰;相较糖度、硬度多组分耦合光谱叠加干扰,有机酸特征波段辨识度更高,引入 SE 注意力机制搭建的预测模型,能够有效定位到这些稳定性优异的特征波段,同时提升模型对该类波段特征的权重占比与利用程度,依靠这样的特征处理方式,模型可以完成对样品酸度指标的高精度预测分析。糖度受水分、果胶、多糖多重吸收干扰,硬度关联细胞壁结构、果肉致密性等多类理化变化,光谱特征分散,最终两项指标预测精度略低于酸度。




图 7 检验样本酸度真实值和预测值结果对比

Fig. 7 Comparison of actual and predicted acidity values of test samples

和其他指标相比,糖度与硬度的预测结果准确度会稍微差一些,也能看出这两项指标在光谱响应层面本身就更为复杂。糖度的数值主要由果实内部可溶性固形物的含量所决定,糖度对应的 C-H 键光谱吸收信号,很容易受到果实自身水分、果胶等其他成分的光谱影响,使得本身有效

特征信号占比下降,干扰信号增多。

硬度指标能够体现出果实细胞壁的结构状态以及果肉脆度情况,硬度对应的光谱响应规律,并不只是由某一种化学基团的吸收峰值单独决定,还和细胞壁多糖聚合程度、果实内部水分分布状态、果肉组织致密程度等多种因素都




图8 检验样本糖度真实值和预测值结果对比

Fig. 8 Comparison of actual and predicted sugar content values of test samples




图9 检验样本硬度真实值和预测值结果对比

Fig. 9 Comparison of actual and predicted firmness values of test samples

有关系。这类指标对应的光谱特征不够突出,分布也更为零散,训练模型时需要同时从多个光谱波段中捕捉关联性较弱的隐含信号,这也在一定程度上加大了预测分析的难度。上述散点图显示:所有指标散点紧密分布在 $y=x$ 理想线附近,无明显偏离点与系统偏差。拟合直线与理想线高度重合,预测值与真实值一致性极高。散点图直观地证明模型稳定可靠,可用于实际检测。

2.6 模型对不同品种的适应性

模型可准确识别4个品种在硬度、糖度和酸

度三项品质指标上的固有品种差异,该种质差异会增加统一模型对多品种苹果同步理化预测的建模难度。分品种预测结果表明,模型可精准捕捉各品种品质本底特征:王林苹果天然硬度偏高;富士苹果糖度、酸度整体处于高位;爱妃苹果硬度与糖度偏高、酸度偏低;威海金苹果清甜适口、酸度偏低。本模型对4个品种的硬度、糖度、酸度均可实现高精度预测,预测误差波动幅度小,验证了本文双分支卷积网络预测稳定性优异,可适配不同品种苹果的理化特征差异。针对硬质型、高糖酸型、清甜低酸型三类差异化种质苹果,该模型均可高效完成光谱特征提取与理化

表 5 分品种测试集预测性能表
Table 5 Prediction performance for test sets of different varieties

品种 Varieties	品质指标 Quality indicator	R^2	RMSE
王林	硬度	0.881 2	0.158 3
	糖度	0.872 6	0.521 7
	酸度	0.917 3	0.019 8
富士	硬度	0.871 5	0.164 2
	糖度	0.883 5	0.502 9
	酸度	0.912 6	0.021 1
爱妃	硬度	0.879 4	0.159 7
	糖度	0.878 1	0.513 6
	酸度	0.908 9	0.022 3
威海金	硬度	0.870 3	0.165 5
	糖度	0.886 2	0.498 5
	酸度	0.915 2	0.020 4

数据拟合,跨品种预测场景下鲁棒性优良,具备果品工业化无损检测应用潜力。

3 讨论

相较于 PLSR、SVR 等传统机器学习与单分支 1D/2D-CNN 模型,本 GAF-SE-1D-2D-CNN 双分支模型无需人工筛选特征,依托一维时序光谱+二维 GAF 图像双特征融合搭配 SE 注意力机制,可同步完成硬度、糖度、酸度多指标一体化预测,在流水线在线分选场景中可大幅缩短单果检测耗时;算法轻量化后可搭载低成本微型近红外光谱芯片,适配田间便携式果品快速检测仪开发。但本研究仍存在局限:试验样本仅包含 4 个苹果品种,未采集梨、柑橘、桃等其他果品样本,暂无试验数据支撑模型跨水果品类泛化使用,后续需扩充多品类鲜果数据集完成模型迁移验证。从预测结果可见,硬度、糖度受果肉细胞壁、果胶、水分多重耦合干扰,预测 R^2 低于酸度,后续可通过多元组合光谱预处理筛选、多尺度卷积模块嵌入、补充不同栽培环境与成熟梯度苹果样本等方式,进一步优化两项指标拟合效果,提升模型决定系数。

4 结论

本研究构建了基于近红外光谱与 GAF-SE-1D-2D-CNN 的双分支多任务模型,实现了多品种苹果硬度、糖度、可滴定酸度的同步无损检测。主要结论如下:

(1)构建 GAF-SE-1D-2D-CNN 双分支融合结构,实现一维光谱与二维 GAF 图像特征互补,提升预测精度与泛化性。SE 通道注意力机制强化品质相关特征,抑制噪声与散射干扰,模型抗干扰能力更强。

(2)模型结构合理,训练至第 50 轮收敛,无过拟合现象,L2 正则化、Dropout、早停等策略有效提升泛化能力。

(3)测试集预测精度优异,硬度 $R^2=0.875\ 5$ 、糖度 $R^2=0.880\ 2$ 、酸度 $R^2=0.914\ 1$,三项指标均满足果品无损检测要求。

(4)模型可捕获品种固有品质特征,在 4 个受试苹果品种上预测稳定,鲁棒性与实用性良好。

该模型将一维光谱时序特征与二维 GAF 空间特征融合,结合 SE 注意力强化有效通道,实现多任务同步输出,无需人工特征工程,检测效率与精度显著优于传统方法,可应用于分选线、仓储监测与产地快速评价。

参考文献

- [1] 王嘉琪,张 洁,任玉锋,等.宁夏不同地域产区嘎啦系苹果果实品质比较分析[J].经济林研究,2025,43(03):242-251.
- [2] 曾小松,宦克为,刘小溪,等.基于竞争性自适应重加权采样和格拉姆角差场的二维卷积神经网络近红外光谱分析模型研究[J].分析化学,2025,53(06):955-966.
- [3] 毕钲发,刘 杨,伍新明,等.基于深度学习的海底线缆大规模快速普查[J].地球物理学报,2025,68(12):4881-4894.
- [4] Liu J, Wu J, Xie H, et al. Semantic segmentation of urban remote sensing images based on deep learning [J]. Applied Sciences, 2024, 14(17):7562.
- [5] Brahim B, Ginés M G, Sajad S, et al. Convolutional neural networks for estimating the ripening state of Fuji apples using visible and near-infrared spectroscopy[J]. Food and Bioprocess Technology, 2022, 15(10):2226-2236.
- [6] Oliveira-Folador G, Bicudo O D M, Andrade D F E, et al. Quality traits prediction of the passion fruit pulp using NIR and MIR spectroscopy[J]. LWT, 2018, 95:172-178.
- [7] Pimpen P, Sneh S, Thitima P, et al. Non-destructive quality evaluation of tropical fruit (Mango and Mangosteen) purée using near-infrared spectroscopy

- combined with partial least squares regression[J]. Agriculture,2022,12(12):2017.
- [8] Alessio S,Glenn M O.Relationships between soluble solids and dry matter in the flesh of stone fruit at harvest[J].Analytica,2021,2(1):14-24.
- [9] 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.
- [10] 刘燕德,王军政,姜小刚,等.多模式可调节光学机构的苹果可溶性固形物近红外光谱检测[J].光谱学与光谱分析,2021,41(07):2064-2070.
- [11] 雷 鹰,刘翠玲,周子彦.应用便携式近红外光谱仪研究苹果糖度的快速分析模型[J].食品科学技术学报,2018,36(06):95-100.
- [12] 徐淑彦,王 伟,李世雄.基于近红外光谱的苹果内部糖度快速检测方法[J].中国农机装备,2025(11): 22-25.
- [13] 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(09):2792-2798.
- [14] 张田煜,张晓蕾,刘少华,等.基于1D-CNN-RF的梨果可见/近红外糖度预测模型[J].南京农业大学学报,2026,49(02):433-441.
- [15] 邓 娅,王新越,黄 洋,等.基于近红外光谱与格拉姆角场多模态融合的水果品质分类模型[J].物联网技术,2026,16(03):116-122.
- [16] 樊书祥,王庆艳,杨雨森,等.水果糖度可见-近红外光谱手持式检测装置开发与试验[J].光谱学与光谱分析,2021,41(10):3058-3063.
- [17] 徐惠荣,李青青.皇冠梨糖度可见/近红外光谱在线检测模型传递研究[J].农业机械学报,2017,48(09): 312-317.
- [18] 刘鸿阳,孔德国,罗华平,等.基于多光谱图像角度融合测定库尔勒香梨理化指标[J].光谱学与光谱分析,2024,44(03):649-655.
- [19] 陈建新.基于近红外光谱的苹果硬度便携式检测设备研究[D].杨凌:西北农林科技大学,2018.
- [20] 杨光辉,张永立,王美蟠,等.近红外光谱检测鲜食玉米可溶性固形物含量[J].光谱学与光谱分析,2025, 45(07):1932-1939.
- [21] 黄永明,谢 怡,缪发军,等.基于注意力机制和轻量 Inception的一维卷积地震事件分类方法(英文)[J]. Applied Geophysics,2025,22(04):1387-1398+1501.
- [22] 孙伟哲,李 含,陈希源,等.电力电缆绝缘材料型号的近红外光谱快速识别方法研究[J].光谱学与光谱分析,2025,45(11):3153-3159.
- [23] Meng L,Chen G,Liu D,et al.Universal modeling for non-destructive testing of soluble solids content in multi-variety blueberries based on hyperspectral imaging technology[J].Applied Sciences,2025,15(7): 3128.
- [24] 董诗佳.基于近红外光谱技术的梨成熟度判别模型构建[D].杨凌:西北农林科技大学,2025.