

基于高光谱成像技术和近红外光谱技术的金冠苹果货架期判别及其品质分析

赵昕, 郑树亮, 牛晓颖, 曹建康, 陈晗, 赵志磊

Shelf Life Identification and Quality Analysis of Golden Delicious Apples Based on Hyperspectral Imaging and Near Infrared Spectroscopy

ZHAO Xin, ZHENG Shuliang, NIU Xiaoying, CAO Jiankang, CHEN Han, and ZHAO Zhilei

在线阅读 View online: <https://doi.org/10.13386/j.issn1002-0306.2024080030>

您可能感兴趣的其他文章

Articles you may be interested in

水果成熟度近红外光谱及高光谱成像无损检测研究进展

Research Progress on Nondestructive Detection of Fruit Maturity by Near Infrared Spectroscopy and Hyperspectral Imaging

食品工业科技. 2021, 42(20): 377–383 <https://doi.org/10.13386/j.issn1002-0306.2020070074>

基于近红外高光谱成像技术的花生冻伤检测方法研究

Peanut Frostbite Detection Method Based on Near Infrared Hyperspectral Imaging Technology

食品工业科技. 2024, 45(6): 226–233 <https://doi.org/10.13386/j.issn1002-0306.2023030252>

基于高光谱成像技术的山楂产地判别研究

Identification of Geographical Origin for Hawthorn Based on Hyperspectral Imaging Technology

食品工业科技. 2024, 45(10): 282–291 <https://doi.org/10.13386/j.issn1002-0306.2023090074>

基于高光谱成像技术的白茶储藏年份判别

Discrimination of Storage Time of White Tea Using Hyperspectral Imaging

食品工业科技. 2021, 42(18): 276–283 <https://doi.org/10.13386/j.issn1002-0306.2020110299>

基于近红外高光谱成像快速无损检测注胶肉研究

Rapid Nondestructive Detection of Glue-injected Meat by NIR Hyperspectral Imaging Technology

食品工业科技. 2020, 41(10): 219–223 <https://doi.org/10.13386/j.issn1002-0306.2020.10.036>

基于高光谱成像技术的陈皮年份快速鉴别

Rapid Discrimination of Aging Year of Chenpi Based on Hyperspectral Images

食品工业科技. 2024, 45(24): 243–251 <https://doi.org/10.13386/j.issn1002-0306.2024010229>



关注微信公众号，获得更多资讯信息

赵昕, 郑树亮, 牛晓颖, 等. 基于高光谱成像技术和近红外光谱技术的金冠苹果货架期判别及其品质分析 [J]. 食品工业科技, 2025, 46(11): 302–312. doi: 10.13386/j.issn1002-0306.2024080030

ZHAO Xin, ZHENG Shuliang, NIU Xiaoying, et al. Shelf Life Identification and Quality Analysis of Golden Delicious Apples Based on Hyperspectral Imaging and Near Infrared Spectroscopy[J]. Science and Technology of Food Industry, 2025, 46(11): 302–312. (in Chinese with English abstract). doi: 10.13386/j.issn1002-0306.2024080030

· 分析检测 ·

基于高光谱成像技术和近红外光谱技术的金冠苹果货架期判别及其品质分析

赵 昕^{1,2,3}, 郑树亮¹, 牛晓颖¹, 曹建康⁴, 陈 晗¹, 赵志磊^{1,2,3,*}

(1.河北大学质量技术监督学院,河北保定 071002;

2.计量仪器与系统国家地方联合工程研究中心,河北保定 071002;

3.河北省能源计量与安全检测技术重点实验室,河北保定 071002;

4.中国农业大学食品科学与营养工程学院,北京 100083)

摘要:为实现金冠苹果的货架期及可溶性固形物含量 (SSC) 和酸度 (pH) 的无损分析, 利用高光谱成像系统 (400~1000 nm) 和近红外 (800~2500 nm) 光谱仪分别采集了金冠苹果的六个不同货架期 (采后 0、7、14、21、28 和 35 d) 的光谱信息, 采用了卷积平滑 (Savitzky-Golay, SGS)、一阶导数平滑 (Savitzky-Golay First Derivative, 1D)、标准正态变换 (Standard Normal Variate, SNV) 和归一化 (Area Normalize, Normalize) 四种预处理方法, 利用竞争性自适应重加权采样算法 (Competitive Adaptive Reweighted Sampling Aglorithm, CARS) 和无信息变量消除法 (Uninformative Variable Elimination, UVE) 提取特征波长, 并建立了反向传播神经网络 (Back Propagation Neural Network, BP) 和最小二乘支持向量机 (Least Squares-Support Vector Machine, LS-SVM) 货架期分类模型。在对 SSC 和 pH 的预测中, 采用灰度共生矩阵 (Gray Level Cooccurrence Matrix, GLCM) 提取金冠苹果高光谱图像中的 8 种纹理特征, 采用 CARS 对预处理后的高光谱图像的光谱数据、高光谱图像的光谱与纹理融合数据以及近红外光谱数据提取特征变量, 建立偏最小二乘 (Partial Least Squares Regression, PLSR) 和最小二乘支持向量机两种模型。结果表明, 近红外光谱和高光谱成像技术均可实现对金冠苹果货架期的判别, 判别最优模型为基于高光谱图像的 1D+UVE+BP 模型, 判别准确率为 100%; 对金冠苹果 SSC 的定量预测中, 基于近红外光谱的 1D+CARS+PLSR 模型预测效果最好, 预测集相关系数 (R_p) 和均方根误差 (Root Mean Square Error of Prediction Set, RMSEP) 值分别为 0.9323 和 0.4036; 对金冠苹果的 pH 定量预测中, 基于近红外光谱的 SNV+CARS+LS-SVM 模型预测效果最好, R_p 和 RMSEP 值分别为 0.8749 和 0.0417, 研究结果为金冠苹果的无损检测提供了技术支持和依据。

关键词:近红外光谱技术, 高光谱成像系统, 苹果, 货架期, 定性判别, 定量预测

中图分类号:TS255.1

文献标识码:A

文章编号:1002-0306(2025)11-0302-11

DOI: 10.13386/j.issn1002-0306.2024080030

本文网刊:



Shelf Life Identification and Quality Analysis of Golden Delicious Apples Based on Hyperspectral Imaging and Near Infrared Spectroscopy

ZHAO Xin^{1,2,3}, ZHENG Shuliang¹, NIU Xiaoying¹, CAO Jiankang⁴, CHEN Han¹, ZHAO Zhilei^{1,2,3,*}

(1. College of Quality and Technology Supervision, Hebei University, Baoding 071002, China;

2. National and Local Joint Engineering Research Center for Metrology Instruments and Systems, Baoding 071002, China;

3. Key Laboratory of Energy Metering and Safety Testing Technology of Hebei Province, Baoding 071002, China;

4. College of Food Science and Nutritional Engineering, China Agricultural University, Beijing 100083, China)

收稿日期: 2024-08-06

基金项目: 国家自然科学基金项目 (32272371, 32402230); 2024 年省级大学生创新训练计划项目 (S202410075089)。

作者简介: 赵昕 (1992-), 女, 博士, 讲师, 研究方向: 食品药品光学无损快检技术与装置研究, E-mail: zhaoxinjz@hbu.edu.cn。

* 通信作者: 赵志磊 (1977-), 男, 博士, 教授, 研究方向: 食品药品计量检测, E-mail: 15930721279@163.com。

Abstract: In order to achieve non-destructive analysis of shelf life, soluble solid content (SSC) and pH of Golden Delicious apples, the spectral information of six different shelf life (postharvest 0, 7, 14, 21, 28 and 35 d) of apple was collected by hyperspectral imaging system (400~1000 nm) and near-infrared spectroscopy (800~2500 nm), respectively. The spectroscopy data was pro-processed by savitzky-golay (SGS), savitzky-golay first derivative (1D), standard normal variate (SNV), and area normalize (Normalize), competitive adaptive reweighted sampling algorithm (CARS) and uninformative variable elimination (UVE) were used to extract characteristic wavelengths, and the shelf-life classification models were established by back propagation neural network (BP) and least squares support vector machine (LS-SVM). In order to predict SSC and pH of apple, gray level cooccurrence matrix (GLCM) was used to extract 8 texture features from the hyperspectral images of apple. Feature variables were extracted from the spectral data of pre-processed hyperspectral images, spectral and texture fusion data of hyperspectral images, and near-infrared spectral data by CARS, and predictive models were established by partial least squares regression (PLSR) and LS-SVM. The results showed that both NIR and hyperspectral imaging techniques could determine the shelf life of Golden Delicious apples. The optimal model was established by 1D+UVE+BP based on hyperspectral images, and the accuracy rate was 100%. The quantitative prediction models for SSC were established using a 1D+CARS+PLSR approach based on near-infrared spectroscopy, which demonstrated the most effective predictive performance. The correlation coefficient of the prediction set (R_p) and the root mean square error of prediction set (RMSEP) values were found to be 0.9323 and 0.4036, respectively. The SNV+CARS+LS-SVM model, utilizing near-infrared spectroscopy, demonstrated the most effective predictive performance, with R_p and RMSEP values of 0.8749 and 0.0417, respectively. The findings of this research offer valuable technical support and a foundational basis for the non-destructive testing of Golden Delicious apples.

Key words: near infrared spectroscopy; hyperspectral imaging system; apple; shelf life; qualitative discrimination; quantitative prediction

金冠苹果果面金黄、色泽鲜艳、外形美观,深受消费者喜爱,然而金冠苹果不耐贮藏,常温货架期较短,硬度和酸度快速下降^[1],导致果实的品质下降。苹果的质地、酸度(pH)、可溶性固形物(SSC)等是直接影响消费者购买决策的重要质量参数^[2-3]。金冠苹果在货架期内表面颜色变化并不明显,肉眼难以准确判断其货架期和内在品质。因此,无损预测苹果所处的货架期十分重要。传统的水果品质检测方法效率低下、操作复杂且具有破坏性^[4]。近年来,光谱技术因其能够提供农产品质量的快速和非破坏性测量而受到欢迎^[5]。高光谱成像集成了机器视觉和光谱学,能够从被检查的物体中同时获取空间和光谱信息^[6]。近红外光谱技术作为一种快速、无损的检测技术广泛应用于食品的贮藏时间和质量检测研究^[7]。Guan 等^[7]用近红外光谱法检测香榧籽粒贮藏时间,成功区分不同贮藏时间的香榧籽粒,准确率达到了 97.33%。Weng 等^[8]用高光谱成像技术对草莓贮藏时间进行无损检测,区分不同贮藏时间的草莓,准确率为 100%。Bobelyn 等^[9]用近红外光谱预测苹果采后品质,基于不同季节、产地、品种和贮藏条件的苹果数据集,构建了近红外预测模型,预测 SSC 的 RMSEP 值在 0.6~0.8 范围。Zeng 等^[10]利用近红外光谱预测苹果果肉的可溶性固形物含量,取得了较好的预测结果, R_p 最高为 0.96。Li 等^[11]利用高光谱成像技术研究了樱桃果实不同成熟期的 SSC 与 pH 关系,证明了通过近红外高光谱成像技术检测樱桃果实的质量是可行的。Ma 等^[12]利用可见光-近红外空间分辨光谱快速无损地预测猕猴桃的硬度、可溶性固形物含量和 pH。Xuan 等^[13]利用可见光-近红外高光谱成像技术测定秋葵采收成熟度及水分含量。上

述研究和现有金冠苹果光谱检测研究主要集中在单一系统下的病害、损伤识别及 SSC 等无损检测^[14-15],但利用近红外光谱技术和高光谱成像技术同时对金冠苹果货架期及品质进行预测鲜有报道。

高光谱成像技术将光谱信息与图像信息相结合,能够获得每个像素点的光谱数据,可避免近红外光谱技术点采集的平均化,且基于模型,可实现预测指标的空间可视化反演。800~2500 nm 波长范围的近红外光谱包含更多的内部成分信息,通常比可见光波段具有更好的预测性能,故本文选取了 800~2500 nm 的近红外光谱。尽管 1000~2500 nm 范围的高光谱图像同样具有相同的波段优势,但成本远高于 400~1000 nm 的高光谱相机。且苹果的外观特征常常与内部指标(如 SSC 和 pH)之间存在关联,基于高光谱图像中提取的纹理特征也有助于内部指标的预测。综合成本和技术特点,本文选取了 800~2500 nm 的近红外光谱技术和 400~1000 nm 的高光谱成像技术进行对比研究,探讨一种对于苹果品质指标更有效且更具性价比的检测方法。

已有研究证实通过高光谱成像技术和近红外光谱技术对苹果的 SSC 和 pH 的预测是可行的,并且 SSC 和 pH 是苹果质地的重要评价指标^[16-17]。同时 SSC 和 pH 也是消费者购买后最直接的感官评价,所以对 SSC 和 pH 进行无损测定是非常有必要的^[18]。尽管已有大量文献对多种苹果的品质指标预测进行了研究,然而大部分均基于单一技术,并没有针对单一品种的具体检测问题,同时对基于高光谱成像技术和近红外光谱技术的检测方法进行对比分析和讨论。本文针对金冠苹果的货架期分类问题,常见品质指标 SSC 和 pH 的定量预测问题,确定一种最佳的

检测方法,为苹果质量的无损检测提供理论参考。

综上所述,本文以金冠苹果为研究对象,利用高光谱成像(400~1000 nm)技术和近红外光谱(800~2500 nm)技术建立金冠苹果货架期判别模型和SSC、pH回归模型,对比选取较合适的模型,为无损检测金冠苹果的货架期及品质预测提供技术支持。

1 材料与方法

1.1 材料与仪器

金冠苹果 保定市易县商品果园,采后的金冠苹果挑选无病虫害和机械伤的果实,在室温($18\pm2^{\circ}\text{C}$)和相对湿度60%下贮藏35 d,每隔7 d(0、7、14、21、28和35 d)取出79个果实,共474个样本用于金冠苹果货架期的判别;从474个样品中随机选取81个样品用于SSC的预测;从474个样品中随机选取79个样品用于pH的预测。

MPA 傅里叶变换近红外光谱仪(800~2500 nm)
德国 Bruker 公司;FX10 高光谱相机(400~1000 nm)
芬兰 SPECIM 公司;PAL-1 数显手持式折光计
日本 Atago 公司;AZ8601 酸碱度计 台湾衡欣公司。

1.2 实验方法

1.2.1 光谱数据采集及提取

1.2.1.1 高光谱数据采集及提取 使用漫反射模式下的线扫描高光谱成像系统采集样品的高光谱图像。参数如下:波段范围为397.01~1004.01 nm,曝光时间13 ms,系统包含6个光源,每个光源强度为20 W,光谱和空间分辨率分别为2.68 nm和1 mm/pixel。将每个苹果样品放置在平移台上,让苹果侧面朝上并且茎尊端水平垂直于扫描线,得到三维高光谱图像(400, 400, 224)。所使用的系统控制软件为LUMOScanner。

为了减少相机的电流噪声及光源分布不均匀等因素对高光谱图像的影响,在采集高光谱图像前进行黑白校正。在原始图像(R1)采集相同条件下,关闭相机镜头盖采集获得的黑色参考图像(D);在采集平台上放置一块标准白板(反射率为99%的白色聚四氟乙烯瓦)获得白色参考图像(W)。校正后高光谱图像(R)计算如式(1),所有校正后的图像用于后续的图像分析,提取光谱数据和数据处理。

$$R(\%) = \frac{R1 - D}{W - D} \quad \text{式 (1)}$$

1.2.1.2 近红外光谱数据采集及提取 使用MPA近红外光谱仪采集样品的漫反射光谱,参数如下:波段范围为800~2500 nm,Pbs检测器,扫描次数64,分辨率 8 cm^{-1} ,背景光谱为仪器内置的金背景^[19]。在苹果样品赤道部分均等分布的三个点处各采集一次光谱,每个果实得到3条光谱,取其平均光谱作为该样品的原始光谱进行后续分析。所使用的光谱采集软件为布鲁克公司的OPUS6.0。

1.2.2 SSC 和 pH 的测定

1.2.2.1 SSC 的测定 随机选取81个苹果进行SSC测定,每个苹果从高光谱相机照射面取2.5 g左右的果肉用榨汁器挤出果汁,用PAL-1数字折光计进行测定^[20],每个样本重复2次,取平均值作为其真实值。

1.2.2.2 pH 的测定 随机选取79个苹果进行pH测定,每个苹果从ROI区域取适量果肉榨汁在10 mL离心管中,用AZ8601酸度计进行pH测定,每个样本重复2次,取平均值作为其真实值。

1.2.3 光谱数据预处理 对于高光谱图像数据,首先利用ENVI 5.1软件手动选取所照苹果整个表面作为感兴趣区域(ROI),对每个样品ROI内所有像素值自动平均,作为苹果样品的平均光谱。从每个苹果样品获取波段数为224的高光谱图像光谱数据和波段数为2203的近红外光谱数据。为了提高数据信噪比,截取首尾部分波段数据,选取其400~1000 nm范围共222个波段的高光谱数据和800~2500 nm范围共1903个波段的近红外光谱数据为有效信息进行分析处理。为了消除或最小化噪声,采用卷积平滑(SGS)、一阶导数(1D)、标准正态变换(SNV)和归一化(Normalize)四种方法进行预处理。

1.2.4 特征波长提取方法

1.2.4.1 竞争性自适应重加权采样算法 竞争性自适应重加权采样算法(CARS)模仿达尔文的“适者生存”原则,主要通过蒙特卡罗模型进行等概率采样和指数衰减函数,经过自适应加权采样(ARS)技术自适应调整各波段的选择概率^[21],通过迭代过程不断调整和优化波段选择,从而保留对模型预测最有贡献的波段。本研究将其用于定量和定性模型的特征筛选。使用CARS算法时,将蒙特卡罗采样次数设置为100次,通过5倍交叉验证法选择RMSECV最小的特征波长作为最优特征波长。

1.2.4.2 无信息变量消除算法 无信息变量消除算法(UVE)核心是基于PLS回归系数分析进行变量选择^[22],利用噪声的无关变量信息统计去选择光谱自身的特征变量,能够去除对建模共效率较小的波长变量,选出特征波长变量,减少了建模所用的变量个数,降低了模型复杂性。本研究将其用于定性模型的特征筛选。使用UVE算法时,最佳主因子数设置为10。

1.2.5 图像主成分分析 主成分分析法(Principal Component Analysis, PCA)是一种多元统计分析方法,广泛应用于数据的降维、压缩等方面^[23]。PCA是将N维高维特征通过正交变换转换到K维低维空间。其K维的变量即为主成分。本研究对基于手动选取的ROI区域构建掩膜(用来屏蔽图像上不参加处理的区域,使感兴趣区域内的图像值保持不变,而区外图像值为0)后的图像进行PCA分析,选取前

7 个 PC 结果图用于纹理特征的提取。

1.2.6 高光谱图像纹理特征提取 纹理是表征图像特征的重要参数^[24], 本研究采用纹理特征用于金冠苹果的品质分析, 采用灰度共生矩阵法(Gray Level Cooccurrence Matrix, GLCM)提取图像纹理信息, 其利用二阶组合条件概率密度函数来统计图像特征, 能够综合反映出图像灰度关于相邻间隔、方向以及变化幅度的相关信息^[25]。纹理特征参数分别为均值、方差、同质性、对比度、差异性、熵、角二阶矩、相关性。

1.3 模型建立及评价

1.3.1 判别模型和回归模型建立 反向传播神经网络(Back Propagation, BP)是一种按照误差逆向传播算法训练的多层前馈神经网络^[26]。利用梯度搜索技术, 使网络的实际输出值和期望输出值的误差均方差为最小。具备较强的非线性拟合能力, 以及较好的泛化性与容错性^[27]。本文利用 BP 方法构建金冠苹果货架期的判别模型。

偏最小二乘(PLSR)是一种线性预测方法, 结合了多元线性回归分析、相关分析和主成分分析技术的建模方法^[9], 能够高效解决因变量和自变量之间存在的多重共线性问题。本文利用 PLSR 方法构建金冠苹果 SSC 和 pH 的回归预测模型。

最小二乘支持向量机(LS-SVM)是一种改进的支持向量机, 以 RBF 核函数为映射函数, LS-SVM 模型的训练误差和复杂度由惩罚参数 γ 决定, 输入空间到高维特征空间的非线性映射能力受核参数 σ 影响^[21], 可以处理非线性分类和回归问题。本文利用 LS-SVM 方法构建了金冠苹果货架期的判别模型, 以及 SSC 和 pH 的回归预测模型。

1.3.2 模型评价 以训练集的相关系数(R_c)及其均方根误差(RMSEC)和预测集的相关系数(R_p)及其均方根误差(RMSEP)作为判别模型性能的指标。一个理想的分析模型, 其决定系数或者相关系数越大且越接近于 1, 回归性越好; 同时还需满足 RMSEC 和 RMSEP 的值越小且 RMSEC 值应小于 RMSEP, 建模效果的实用性越理想^[21]。计算公式如下:

$$R_c = \sqrt{1 - \frac{\sum_{i=1}^{N_c} [Y_a(i) - Y_c(i)]^2}{\sum_{i=1}^{N_c} [Y_a(i) - Y_m(i)]^2}} \quad \text{式 (2)}$$

$$R_p = \sqrt{1 - \frac{\sum_{i=1}^{N_p} [Y_a(i) - Y_c(i)]^2}{\sum_{i=1}^{N_p} [Y_a(i) - Y_m(i)]^2}} \quad \text{式 (3)}$$

$$\text{RMSEC} = \sqrt{\frac{1}{N_c} \sum_{i=1}^{N_c} [Y_a(i) - Y_c(i)]^2} \quad \text{式 (4)}$$

$$\text{RMSEP} = \sqrt{\frac{1}{N_p} \sum_{i=1}^{N_p} [Y_a(i) - Y_p(i)]^2} \quad \text{式 (5)}$$

式中: N_c 和 N_p 为建模集和预测集中的样品数,

Y_a 和 Y_m 为样品参考值及其平均值, Y_c 和 Y_p 为训练集和预测集中的 SSC 和 pH 预测值。

2 结果与分析

2.1 金冠苹果货架期判别分析

2.1.1 原始光谱特性 图 1(a)和(b)为 474 个苹果样本的高光谱图像原始光谱图和 6 个货架期(0、7、14、21、28、35 d)的平均光谱图。不同样本在 400~

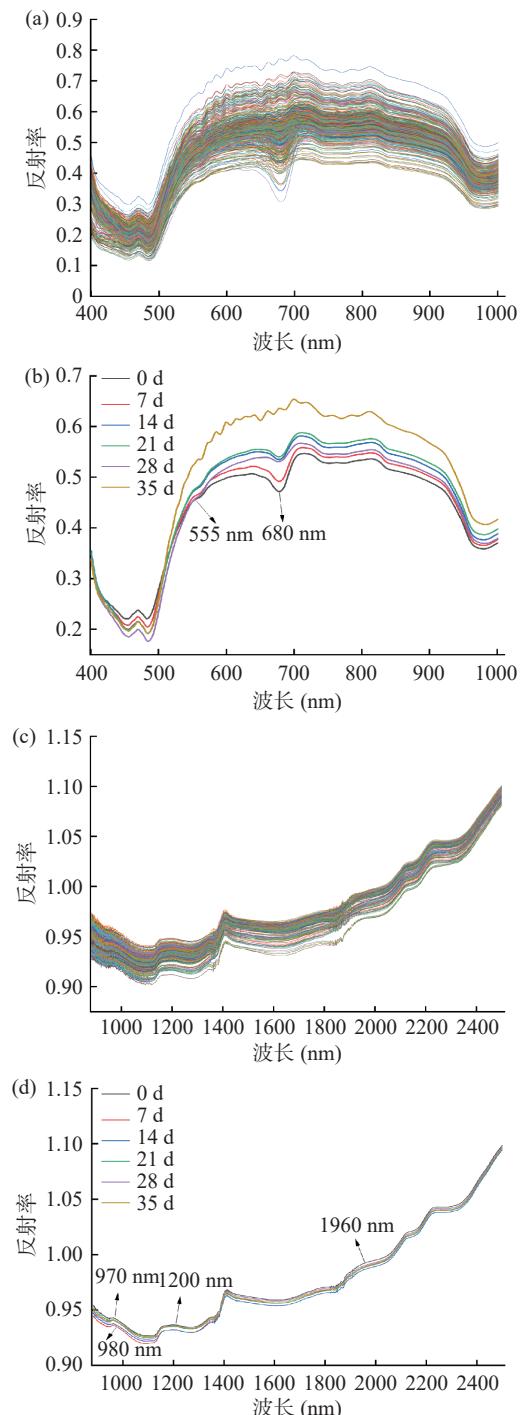


图 1 金冠苹果高光谱和近红外的原始光谱图和平均光谱图

Fig.1 Original and average spectra of hyperspectral and near-infrared spectra of Golden Delicious apples

注: (a)高光谱图像的原始光谱图, (b)不同货架期的平均高光谱图, (c)近红外的原始光谱图, (d)不同货架期的平均近红外光谱图。

1000 nm 波段范围内反射率变化较大,但变化趋势基本一致。对比不同货架期的平均光谱,第 35 d 的光谱 513~936 nm 范围的反射率值明显高于其他货架期的光谱。这可能是由于贮藏时间过长,金冠苹果的叶绿素含量会随着果皮颜色的变化而降低^[26],苹果对光吸收减少所造成的。在 680 nm 波长近红外范围吸收峰是叶绿素含量逐渐降低所导致,在 555 nm 波长近红外范围的吸收峰是花青素对光的吸收较大所导致^[27]。

图 1(c)和(d)为 474 个苹果样本的近红外原始光谱图和 6 个货架期(0、7、14、21、28、35 d)的平均光谱图。在 833~2500 nm 波长范围的样品光谱曲线变化趋势基本一致, 总体呈现上升的走势。这是因为随着苹果样品贮藏时间的增加, 糖度、酸度等指标均发生了变化。苹果中的可溶性固形物、可滴定酸含量含有影响光谱吸收的官能团, 光谱的吸收峰与苹果中这类物质的变化有关^[26]。在 980 nm 附近存在较强的碳水化合物吸收带, 它们与 970 nm 处的强水带相互缠绕, 形成了所观察到的宽峰^[9], 在 1200 nm 左右的吸收峰与水中 O-H 键的第一个泛音有关^[27], 约在 1960 nm 处的吸收峰与 O-H 的拉伸和弯曲振动有关^[28]。

2.1.2 金冠苹果货架期判别模型建立 将每种货架期(0、7、14、21、28 和 35 d)的样本按照大约 3:1 的比例随机分为训练集和预测集, 得到训练集样本共 355 个, 预测集样本共 119 个。

2.1.2.1 基于全波段的金冠苹果货架期判别模型为筛选出最佳预处理方法并比较不同判别模型效果，分别采用 SGS、1D、SNV、Normaliaze 四种方法对高光谱图像光谱和近红外光谱数据进行预处理。构建金冠苹果货架期的基于全波段的 BP 和 LS-SVM 判别模型，模型结果如表 1 所示。

基于高光谱图像数据的 Normaliaze+BP 模型预测集判别准确率为 99.15%, 基于高光谱图像数据经过其余预处理的 BP 模型的预测集判别准确率均达

表1 基于全波段的金冠苹果货架期判别模型结果
 Table 1 Results of the shelf-life discrimination model
 of Golden Delicious apples based on all bands

| 预处理方法 | 建模方法 | 变量数 | 高光谱图像光谱数据 | | 近红外光谱数据 | |
|-----------|--------|-----|-----------|---------|---------|---------|
| | | | 训练集 (%) | 预测集 (%) | 变量数 | 训练集 (%) |
| None | | 222 | 100 | 100 | 1903 | 86.19 |
| SGS | | 222 | 100 | 100 | 1903 | 90.98 |
| 1D | | 222 | 100 | 100 | 1903 | 74.92 |
| SNV | BP | 222 | 100 | 100 | 1903 | 60.28 |
| Normalize | | 222 | 100 | 99.15 | 1903 | 87.60 |
| None | | 222 | 85.63 | 68.90 | 1903 | 100 |
| SGS | | 222 | 83.38 | 68.06 | 1903 | 100 |
| 1D | | 222 | 100 | 95.79 | 1903 | 100 |
| SNV | LS-SVM | 222 | 99.43 | 83.19 | 1903 | 100 |
| Normalize | | 222 | 98.02 | 81.51 | 1903 | 100 |
| | | | | | | 65.56 |

到 100%。基于高光谱图像数据的 1D+LS-SVM 模型预测集判别准确率为 95.79%。与近红外光谱判别模型结果相比,高光谱图像数据判别模型较好。基于近红外光谱的 SGS+LS-SVM 判别模型较好,准确率为 73.94%。在基于高光谱的判别模型中,1D 预处理为最佳预处理方式,BP 模型判别性能优于 LS-SVM 模型。这可能是由于 1D 预处理能够提高光谱分辨率,且 BP 为非线性拟合模型,有较强的容错性。在基于近红外的判别模型中,SGS 为最佳预处理方式,且 LS-SVM 模型判别性能优于 BP 模型。这可能是由于对于本实验数据 SGS 的去噪效果更优,LS-SVM 的非线性拟合能力优于 BP。高光谱图像光谱数据(400~1000 nm)模型的判别效果总体上优于近红外光谱(800~2500 nm)模型,这可能是因为不同货架期金冠苹果外观变化较内部含量变化更明显(400~1000 nm 波段与颜色相关性较高,800~2500 nm 波段与内部品质相关性较高^[26])。基于高光谱图像光谱数据的 1D+BP 模型和基于近红外光谱的 SGS+LS-SVM 模型预测集分类结果的混淆矩阵如图 2 所示。基于高光谱图像光谱数据的 1D+BP 模型的分类结果全部正确,基于近红外光谱的

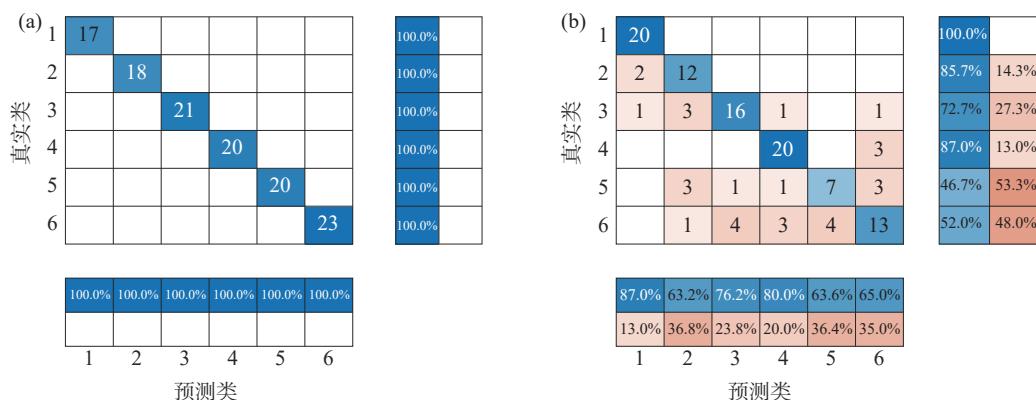


图 2 预测集分类结果的混淆矩阵图

Fig.2 Confusion matrix plot of the classification results of the prediction set

注: (a) 基于高光谱图像光谱数据的 1D+BP 模型预测集分类结果的混淆矩阵, (b) 基于近红外光谱的 SGS+LS-SVM 模型预测集分类结果的混淆矩阵。

SGS+LS-SVM 模型预测集分类结果中, 货架期 1 中有 3 个判别错误, 货架期 2 和货架期 6 中均有 7 个判别错误, 货架期 3 和货架期 4 中均有 5 个判别错误, 货架期 5 中有 4 个判别错误。

2.1.2.2 特征波长提取分析 由表 2 可知, 采用 CARS、UVE 两种变量选择方法, 对经过 1D 预处理的全波段高光谱图像光谱数据筛选出的特征波长个数分别为 12 和 148 个。基于高光谱特征波长的金冠苹果货架期判别模型均展现出较好的性能, 且与全波长模型判别结果并无显著差异。说明两种变量方法对全波长高光谱均能够很好地筛选出用于分类的相关信息^[9], 且仅通过 CARS 方法提取十几个波段也能产生很好的分类结果。两种变量选择方法筛选出的共有高光谱特征波长为 709、669、500、487、484、

表 2 基于特征波长的金冠苹果货架期判别模型结果

Table 2 Results of shelf-life discrimination model of Golden Delicious apples based on characteristic wavelength

| 数据来源 | 预处理方法 | 特征选择方法 | 建模方法 | 变量数 | 训练集(%) | 预测集(%) |
|---------|-------|--------|--------|-----|--------|--------|
| 高光谱图像数据 | 1D | CARS | BP | 12 | 99.43 | 99.15 |
| | | UVE | | 148 | 100 | 100 |
| | SGS | CARS | LS-SVM | 12 | 96.61 | 95.79 |
| | | UVE | | 148 | 100 | 97.47 |
| 近红外光谱 | 1D | CARS | BP | 157 | 82.81 | 60.50 |
| | | UVE | | 51 | 47.88 | 39.49 |
| | SGS | CARS | LS-SVM | 157 | 91.83 | 69.74 |
| | | UVE | | 51 | 41.97 | 31.09 |

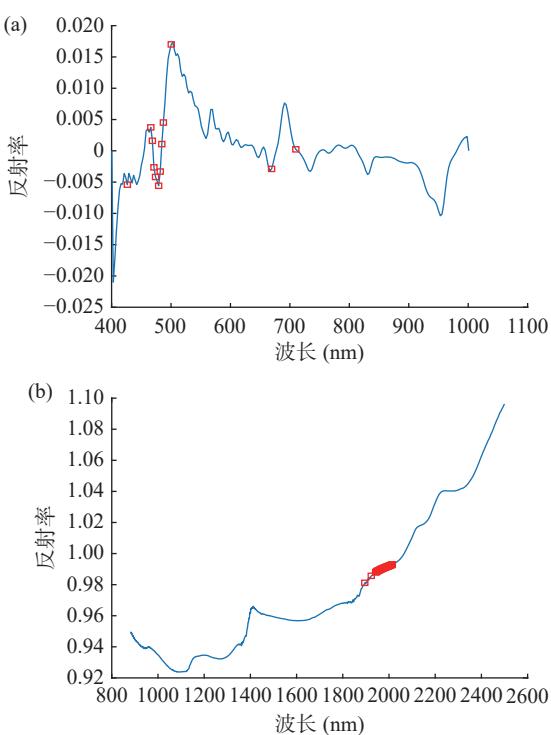


图 3 特征波长选择图

Fig.3 Characteristic wavelength selection diagram

注: (a)两种算法筛选出的共有高光谱特征波长分布图, (b)基于 SGS 预处理的全波段近红外光谱数据的 UVE 算法结果分布图。

481、479、473、471、468、466、426 nm, 如图 3(a)所示分布在全波长范围内。

基于 SGS 预处理的全波段近红外光谱数据的 UVE 算法结果如图 3(b)所示。采用 CARS、UVE 两种变量选择方法, 对经过 SGS 预处理的近红外光谱数据筛选出的特征波长个数分别为 157 和 51 个。基于近红外光谱的 SGS+UVE+BP 模型和 SGS+UVE+LS-SVM 模型较全波长模型判别结果明显降低。表明 UVE 方法使得关键信息丢失, 降低了模型的精确度。

2.1.2.3 基于特征波长的金冠苹果货架期判别模型

采用 CARS、UVE 两种变量选择方法, 对经过 1D 预处理的全波段高光谱图像光谱数据和经过 SGS 预处理的全波段近红外光谱数据进行特征提取。基于筛选的特征波长分别构建金冠苹果货架期的 BP 和 LS-SVM 判别模型, 结果如表 2 所示。基于高光谱图像数据的 1D+UVE+BP 和 1D+UVE+LS-SVM 模型判别结果较好, 预测集判别准确率分别达到了 100% 和 97.47%。基于近红外光谱的 SGS+CARS+BP 和 SGS+CARS+LS-SVM 模型判别结果较好, 预测集准确率分别达到了 60.50% 和 69.74%。特征波长数据建模判别结果与全波长数据建模判别结果相比, 总体差异不显著, 建模变量显著减少, 说明 UVE 和 CARS 两种变量方法可以有效简化模型。综上, 金冠苹果货架期判别最优模型为基于高光谱成像技术的 1D+UVE+BP 模型。

2.2 金冠苹果的 SSC 和 pH 回归预测

2.2.1 SSC 和 pH 的测定结果 用于 SSC、pH 指标预测样本的描述性统计分析结果如表 3 所示。81 个金冠苹果的 SSC 值范围在 9.35~13.35°Birx 之间, 79 个金冠苹果的 pH 范围在 3.76~4.18 之间。在建立回归模型时, 将样品按照大约 3:1 的比例随机分为训练集和预测集。从表 3 可得, 两个指标训练集的参考值范围均大于预测集的参考值范围, 有利于构建准确、稳定的模型。

表 3 金冠苹果 SSC 和 pH 的描述性统计分析

Table 3 Descriptive statistical analysis of SSC and pH of Golden Delicious apples

| 指标 | 样本集 | 样本数 | 最小值 | 最大值 | 平均值 |
|------------|-----|-----|------|-------|---------|
| SSC(°Birx) | 训练集 | 61 | 9.35 | 13.35 | 11.3484 |
| | 测试集 | 20 | 9.4 | 13.15 | 11.2350 |
| pH | 训练集 | 59 | 3.76 | 4.18 | 3.9483 |
| | 测试集 | 20 | 3.83 | 4.11 | 3.9785 |

2.2.2 高光谱图像数据的纹理特征提取 为了降低数据维度, 对掩膜后的苹果样本图像进行主成分分析, 提取前 7 个主成分(累计贡献率为 99% 以上)。利用 GLCM 法对前七个主成分进行图像纹理特征提取^[24], 纹理特征参数分别为均值、方差、同质性、对比度、差异性、熵、角二阶矩、相关性。PC1 图像

相应纹理特征结果如图4所示。基于感兴趣区域提取每个苹果样品的平均纹理特征,共生成包含56个纹理变量($7 \times 8 = 56$)的新数据集。将高光谱图像光谱的222个波段与纹理数据融合变成278个波段的融合光谱,为确保不同类型特征具有可比性和一致性,对融合数据进行归一化处理。

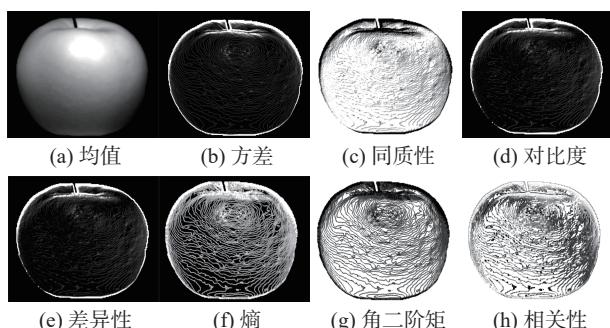


图4 纹理特征图
Fig.4 Texture feature image

2.2.3 金冠苹果可溶性固形物含量无损检测模型

为比较不同的预处理和建模方法对金冠苹果SSC预测的影响,同时简化模型,用CARS对预处理后的高光谱特征、高光谱特征与纹理特征融合、近红外光谱特征三类数据提取特征变量,建立PLSR和LS-SVM两种回归模型对SSC进行预测。

2.2.3.1 特征波长提取分析 基于近红外光谱的1D+CARS+PLSR模型预测结果最好,经过CARS变量选择后,建模变量数由1903个变为222个,筛选后的特征波长分布如图5所示,其中1847 nm波长附近也被Zhang等^[28]用于苹果SSC的无损测量。本研究的预测结果($R_p=0.9323$, RMSEP=0.4036)优于Zhang等^[28]基于高光谱(1000~2500 nm)的CARS-SPA(SPA为逐次投影算法)+PLS模型结果($R_p=0.917$, RMSEP=0.453)。

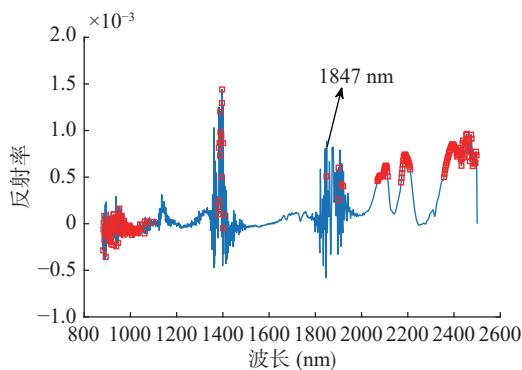


图5 基于1D预处理的近红外光谱筛选后的特征波长分布图

Fig.5 Feature wavelength distribution after NIR spectrum screening based on 1D pretreatment

2.2.3.2 基于高光谱图像数据的金冠苹果可溶性固形物含量无损检测模型 基于高光谱的金冠苹果可溶性固形物含量无损检测结果如表4所示。整体上

LS-SVM模型的预测性能比PLSR模型好,基于高光谱无预处理(None)波段的LS-SVM模型性能最好,预测集 R_p 和RMSEP值分别为0.6983和0.6779,Normalize+CARS+LS-SVM模型性能较好,预测集 R_p 和RMSEP值分别为0.6823和0.6757。这可能是由于LS-SVM是非线性模型,能更好地拟合光谱特征与SSC之间的复杂关系。

表4 基于高光谱的金冠苹果可溶性固形物含量无损检测结果

Table 4 Results of non-destructive detection of soluble solid content in Golden Delicious apples based on hyperspectrum

| 预处理+特征选择方法 | 建模方法 | 变量数 | 训练集 | | 预测集 | |
|----------------|--------|-----|--------|--------|--------|--------|
| | | | R_c | RMSEC | R_p | RMSEP |
| None | | 222 | 0.8110 | 0.5554 | 0.5497 | 1.2614 |
| None+CARS | | 16 | 0.6816 | 0.6869 | 0.5422 | 0.9187 |
| SGS+CARS | | 16 | 0.7288 | 0.6823 | 0.6260 | 0.8245 |
| 1D+CARS | PLSR | 7 | 0.7017 | 0.6791 | 0.5879 | 0.8907 |
| SNV+CARS | PLSR | 12 | 0.7308 | 0.6657 | 0.5604 | 0.8337 |
| Normalize+CARS | | 23 | 0.7862 | 0.6195 | 0.5620 | 0.8265 |
| None | | 222 | 0.7811 | 0.6167 | 0.6983 | 0.6779 |
| None+CARS | | 16 | 0.6399 | 0.8236 | 0.4309 | 0.5522 |
| SGS+CARS | | 16 | 0.6187 | 0.8187 | 0.5757 | 0.6029 |
| 1D+CARS | LS-SVM | 7 | 0.6715 | 0.7277 | 0.6391 | 0.7399 |
| SNV+CARS | LS-SVM | 12 | 0.7011 | 0.6758 | 0.6762 | 0.7855 |
| Normalize+CARS | | 23 | 0.6903 | 0.7197 | 0.6823 | 0.6757 |

2.2.3.3 基于高光谱图像的光谱与纹理融合数据的金冠苹果可溶性固形物含量无损检测模型 为确保不同类型特征具有可比性和一致性,对高光谱融合数据进行归一化(Normalize)处理^[29]。基于融合特征的金冠苹果SSC无损预测结果如表5所示,整体上LS-SVM模型预测性能优于PLSR模型,Normalize+SGS+CARS+LS-SVM模型预测性能最好,预测集结果如图6所示,预测集 R_p 和RMSEP值分别为0.7248和0.7090。融合数据集模型结果与高光谱图像数据结果相比,融合数据建模效果较优。说明在信息融合的过程中,纹理特征携带了部分有效信息,且这些信息与苹果样品中SSC含量相关性较强。

表5 基于高光谱图像的光谱与纹理融合数据的金冠苹果可溶性固形物含量无损检测结果

Table 5 Non-destructive testing results of soluble solid content of Golden Delicious apples based on spectral and texture fusion data of hyperspectral images

| 预处理+特征选择方法 | 建模方法 | 变量数 | 训练集 | | 预测集 | |
|--------------------|--------|-----|--------|--------|--------|--------|
| | | | R_c | RMSEC | R_p | RMSEP |
| Normalize | | 278 | 0.8132 | 0.5511 | 0.5094 | 1.0300 |
| Normalize+CARS | | 22 | 0.7340 | 0.6491 | 0.5467 | 0.8623 |
| Normalize+SGS+CARS | | 22 | 0.8448 | 0.5184 | 0.4527 | 1.0105 |
| Normalize+1D+CARS | PLSR | 4 | 0.7313 | 0.6659 | 0.5472 | 0.8459 |
| Normalize+SNV+CARS | | 10 | 0.7256 | 0.6416 | 0.5113 | 0.9910 |
| Normalize | | 278 | 0.9930 | 0.1158 | 0.5517 | 0.7894 |
| Normalize+CARS | | 22 | 0.7711 | 0.6284 | 0.5855 | 0.7692 |
| Normalize+SGS+CARS | | 22 | 0.7568 | 0.6112 | 0.7248 | 0.7090 |
| Normalize+1D+CARS | LS-SVM | 4 | 0.6831 | 0.7629 | 0.6501 | 0.5332 |
| Normalize+SNV+CARS | | 10 | 0.6722 | 0.7007 | 0.6163 | 0.8430 |

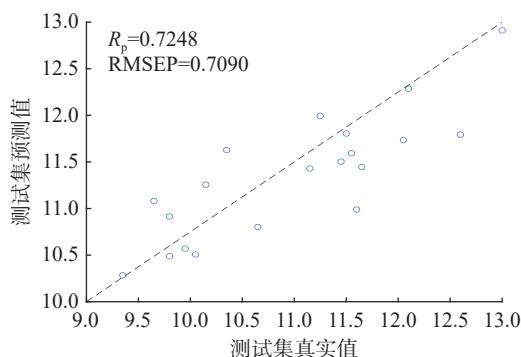


图 6 Normalize+SGS+CARS+LS-SVM 模型预测集结果

Fig.6 Normalize+SGS+CARS+LS-SVM model prediction set results

2.2.3.4 基于近红外光谱的金冠苹果可溶性固形物含量无损检测模型 基于近红外光谱的金冠苹果可溶性固形物含量无损检测结果如表 6 所示。全波长与特征波长建模结果相比, 特征波长数据预测集结果较优。CARS+1D+PLSR 模型性能最高, 预测集结果如图 7 所示, 预测集 R_p 和 RMSEP 值分别为 0.9323 和 0.4036。这可能是由于全波长近红外光谱数据包含了许多无关信息, 降低了模型的预测精度。

表 6 基于近红外光谱的金冠苹果可溶性固形物含量无损检测结果

Table 6 Non-destructive testing results of soluble solid content of Golden Delicious apples based on near-infrared

| 预处理+特征选择方法 | 建模方法 | 变量数 | 训练集 | | 预测集 | |
|----------------|--------|------|--------|--------|--------|--------|
| | | | R_c | RMSEC | R_p | RMSEP |
| None | | 1903 | 0.9990 | 0.4285 | 0.1030 | 1.1032 |
| None+CARS | | 73 | 0.9920 | 0.1210 | 0.9097 | 0.4262 |
| SGS+CARS | | 73 | 0.9896 | 0.1425 | 0.8785 | 0.4751 |
| 1D+CARS | PLSR | 222 | 0.9975 | 0.0669 | 0.9323 | 0.4036 |
| SNV+CARS | | 52 | 0.9851 | 0.1597 | 0.8511 | 0.5860 |
| Normalize+CARS | | 84 | 0.9920 | 0.1220 | 0.9060 | 0.4291 |
| None | | 1903 | 0.9903 | 0.1297 | 0.1438 | 1.0325 |
| None+CARS | | 73 | 0.9314 | 0.3779 | 0.8166 | 0.4261 |
| SGS+CARS | | 73 | 0.9242 | 0.3739 | 0.7775 | 0.6144 |
| 1D+CARS | LS-SVM | 222 | 0.9998 | 0.0176 | 0.8380 | 0.5867 |
| SNV+CARS | | 52 | 0.9842 | 0.1819 | 0.8959 | 0.3571 |
| Normalize+CARS | | 84 | 0.9639 | 0.2696 | 0.8761 | 0.4086 |

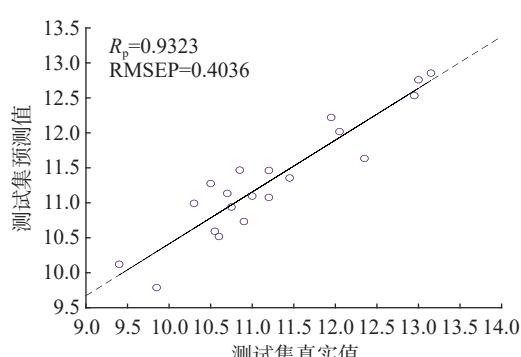


图 7 1D+CARS+PLSR 模型预测集结果

Fig.7 1D+CARS+PLSR model prediction set results

综上所述, 基于高光谱的 LS-SVM 模型的预测性能比 PLSR 模型好, 基于融合数据的 LS-SVM 模型的预测性能比 PLSR 模型好。这可能是由于 LS-SVM 是非线性模型, 相较于线性建模算法 PLSR, 能更好地拟合数据中的复杂关系。基于近红外光谱建模预测集效果比高光谱图像数据好, 这可能是因为近红外光谱范围内包含较多与 SSC 的相关信息。与全波长相比, 特征波长建模预测集效果较优, 这可能是由于全波长有冗余信息导致模型精度的降低。与高光谱图像数据预测集结果相比, 融合建模效果较优, 说明纹理特征携带了部分有效信息, 有利于模型对 SSC 的预测。

2.2.4 金冠苹果 pH 无损检测模型 为比较不同的预处理和建模方法对金冠苹果 pH 预测的影响, 同时简化模型, 用 CARS 对预处理后的高光谱特征、高光谱特征与纹理特征融合、近红外光谱特征三类数据提取特征波长, 建立 PLSR 和 LS-SVM 两种回归模型对 pH 进行预测。

2.2.4.1 特征波长提取分析 基于近红外光谱的 SNV+CARS+LS-SVM 模型预测结果最好, 经过 CARS 变量选择后, 建模变量数由 1903 个变为 39 个, 筛选后的特征波长分布如图 8 所示, 其中 965 nm 波长附近也被 Dong 等^[30] 用于苹果 pH 的无损测量。本研究的预测结果 ($R_p=0.8749$, RMSEP=0.0417) 与 Dong 等^[30] 基于高光谱(900~1700 nm)的 SPA+LS-SVM 模型结果 ($R_p=0.882$, RMSEP=0.057) 相当。

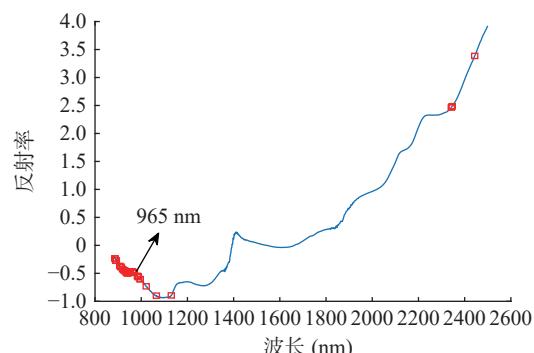


图 8 基于 SNV 预处理的近红外光谱筛选后的特征波长分布图

Fig.8 Feature wavelength distribution after NIR spectrum screening based on SNV pretreatment

2.2.4.2 基于高光谱图像数据的金冠苹果 pH 无损检测模型 基于高光谱的金冠苹果 pH 无损检测结果如表 7 所示。SNV+CARS+LS-SVM 模型性能最好, 预测集 R_p 和 RMSEP 值分别为 0.4027 和 0.0835。SNV+CARS+PLSR 模型性能较好, 预测集 R_p 和 RMSEP 值分别为 0.3037 和 0.0882。各个模型对 pH 预测的总体效果都不太理想, 说明本研究利用高光谱成像技术对 pH 的预测还需进一步提高。

表7 基于高光谱的金冠苹果pH无损检测结果

Table 7 Non-destructive testing results of pH of Golden Delicious apples based on hyperspectral

| 预处理+特征选择方法 | 建模方法 | 变量数 | 训练集 | | 预测集 | |
|----------------|--------|-----|--------|--------|---------|--------|
| | | | R_c | RMSEC | R_p | RMSEP |
| None | | 222 | 0.4122 | 0.0819 | 0.1009 | 0.1006 |
| None+CARS | | 6 | 0.2980 | 0.0865 | 0.0683 | 0.1023 |
| SGS+CARS | | 6 | 0.2946 | 0.0871 | -0.0672 | 0.0999 |
| 1D+CARS | | 2 | 0.1717 | 0.0864 | -0.2897 | 0.1105 |
| SNV+CARS | PLSR | 23 | 0.4886 | 0.0806 | 0.3037 | 0.0882 |
| Normalize+CARS | | 4 | 0.2752 | 0.0809 | 0.0866 | 0.1120 |
| None | | 222 | 0.6806 | 0.0653 | 0.2589 | 0.0943 |
| None+CARS | | 6 | 0.2578 | 0.0862 | 0.0655 | 0.0994 |
| SGS+CARS | | 6 | 0.2218 | 0.0913 | 0.1172 | 0.0864 |
| 1D+CARS | | 2 | 0.0780 | 0.0858 | 0.0648 | 0.1075 |
| SNV+CARS | LS-SVM | 23 | 0.4768 | 0.0806 | 0.4027 | 0.0835 |
| Normalize+CARS | | 4 | 0.3688 | 0.0841 | 0.2218 | 0.0935 |

2.2.4.3 基于高光谱图像的光谱与纹理融合数据的金冠苹果pH无损检测模型 基于融合数据的金冠苹果pH无损检测结果如表8所示, Normalize+1D+CARS+LS-SVM模型性能最好, 预测集 R_p 和RMSEP值分别为0.3119和0.0918。融合数据预测结果与高光谱数据预测结果相比, 融合数据建模效果略差, 但总体差异不显著。这可能由于在信息融合过程中, 纹理特征虽携带了部分有效信息, 但这些信息与苹果样品的pH的相关性较小, 增加了部分无用信息。

表8 基于融合数据的金冠苹果pH无损检测结果

Table 8 Non-destructive testing results of pH of Golden Delicious apples based on fusion data

| 预处理+特征选择方法 | 建模方法 | 变量数 | 训练集 | | 预测集 | |
|--------------------|--------|-----|--------|--------|---------|--------|
| | | | R_c | RMSEC | R_p | RMSEP |
| Normalize | | 278 | 0.4155 | 0.0848 | 0.1150 | 0.0932 |
| Normalize+CARS | | 3 | 0.3726 | 0.0821 | 0.1093 | 1.1027 |
| Normalize+SGS+CARS | | 3 | 0.3931 | 0.0795 | 0.1972 | 0.1053 |
| Normalize+1D+CARS | PLSR | 14 | 0.5404 | 0.0793 | 0.0732 | 0.0990 |
| Normalize+SNV+CARS | | 27 | 0.5091 | 0.0801 | 0.1364 | 0.1025 |
| Normalize | | 278 | 0.9734 | 0.0136 | -0.4667 | 0.1239 |
| Normalize+CARS | | 3 | 0.3226 | 0.0804 | 0.1029 | 0.1040 |
| Normalize+SGS+CARS | | 3 | 0.3957 | 0.0845 | 0.1251 | 0.0901 |
| Normalize+1D+CARS | LS-SVM | 14 | 0.5329 | 0.0764 | 0.3119 | 0.0918 |
| Normalize+SNV+CARS | | 27 | 0.5040 | 0.0774 | 0.0466 | 0.0962 |

2.2.4.4 基于近红外光谱的金冠苹果pH无损检测模型 基于近红外的金冠苹果pH无损检测结果如表9所示。全波长与特征波长建模结果相比, 特征波长数据预测集结果较优。SNV+CARS+LS-SVM模型性能最高。预测结果如图9所示, 预测集 R_p 和RMSEP值分别为0.8749和0.0417。基于近红外光谱全波长的PLSR模型预测集 R_p 和RMSEP值分别为0.1327和0.1165。基于近红外光谱全波长的LS-SVM模型预测集 R_p 和RMSEP值分别为0.4752和0.0811。

综上所述, 基于近红外光谱建模预测集效果较

表9 基于近红外的金冠苹果pH无损检测结果

Table 9 Non-destructive testing results of pH of Golden Delicious apples based on near-infrared

| 预处理+特征选择方法 | 建模方法 | 变量数 | 训练集 | | 预测集 | |
|----------------|--------|------|--------|--------|--------|--------|
| | | | R_c | RMSEC | R_p | RMSEP |
| None | | 1903 | 0.8994 | 0.0387 | 0.1327 | 0.1165 |
| None+CARS | | 64 | 0.9790 | 0.0185 | 0.8239 | 0.0603 |
| SGS+CARS | | 64 | 0.9655 | 0.0248 | 0.8287 | 0.0498 |
| 1D+CARS | | 255 | 0.9521 | 0.0270 | 0.5580 | 0.0860 |
| SNV+CARS | PLSR | 39 | 0.9656 | 0.0237 | 0.8132 | 0.0600 |
| Normalize+CARS | | 56 | 0.9911 | 0.0125 | 0.8489 | 0.0493 |
| None | | 1903 | 0.9450 | 0.0214 | 0.4752 | 0.0811 |
| None+CARS | | 64 | 0.8170 | 0.0541 | 0.4995 | 0.0730 |
| SGS+CARS | | 64 | 0.8203 | 0.0546 | 0.3870 | 0.0738 |
| 1D+CARS | | 255 | 0.9998 | 0.0015 | 0.4439 | 0.0762 |
| SNV+CARS | LS-SVM | 39 | 0.9536 | 0.0280 | 0.8749 | 0.0417 |
| Normalize+CARS | | 56 | 0.9171 | 0.0381 | 0.7068 | 0.0564 |

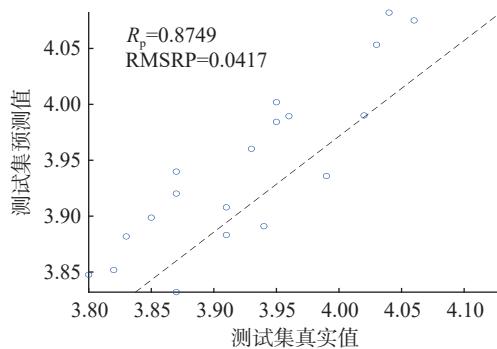


图9 SNV+CARS+LS-SVM模型预测结果

Fig.9 Prediction results of SNV+CARS+LS-SVM model

好, 与全波长相比, 特征波长建模预测集效果较优。高光谱图像数据预测效果稍差, 在本研究中, 高光谱成像技术对pH的预测仍需进一步提升。与高光谱融合数据预测结果相比, 融合建模效果并无显著差异, 说明纹理特征虽携带了部分有效信息, 可这些信息与苹果样品的pH的相关性较小, 不利于模型对pH的预测。

3 结论

本文基于高光谱成像技术和近红外光谱技术对金冠苹果进行货架期判别及其品质分析。在金冠苹果货架期判别模型中, 基于高光谱图像数据的最优模型为1D+UVE+BP模型, 判别准确率为100%。基于高光谱图像数据的最优预处理方法为1D法。UVE和CARS两种方法均适用于高光谱图像数据的特征波长筛选。基于近红外光谱的最优模型为SGS+LS-SVM模型, 判别准确率为73.94%。基于近红外光谱的最优预处理方法为SGS法, CARS方法优于UVE方法, 且UVE方法使得关键信息丢失, 降低了模型的精确度。基于高光谱图像光谱数据(400~1000 nm)模型总体上优于近红外光谱(800~2500 nm)模型。

在金冠苹果SSC无损预测模型中, 基于近红外光谱的CARS+1D+PLSR模型预测效果最好, 预测

集 R_p 和 RMSEP 值分别为 0.9323 和 0.4036。基于近红外光谱建模预测集效果比高光谱图像数据好。全波长与特征波长相比, 特征波长建模预测集效果较优。高光谱融合数据预测结果与高光谱数据预测结果相比, 高光谱融合数据建模效果较优, 表明图像纹理信息能够有效提高模型对 SSC 的预测性能。

在金冠苹果 pH 无损预测模型中, 基于近红外光谱的 SNV+CARS+LS-SVM 模型性能最高, 预测集 R_p 和 RMSEP 值分别为 0.8749 和 0.0417。高光谱成像技术对 pH 的预测还有待提高。全波长与特征波长相比, 特征波长建模预测集效果较优。高光谱融合数据与高光谱数据预测结果相比, 融合数据建模效果略差。本研究利用高光谱相机和近红外光谱仪为金冠苹果货架期判别及 SSC 和 pH 的无损分析提供了理论依据技术支撑。

© The Author(s) 2025. This is an Open Access article distributed under the terms of the Creative Commons Attribution License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).

参考文献

- [1] 田建文, 叶力勤, 马文平, 等. 不同处理方式对金冠苹果贮藏品质的影响[J]. *保鲜与加工*, 2022, 22(11): 9–13. [TIAN J W, YE L Q, MA W P, et al. Effects of different treatments on storage quality of Jinguan apple[J]. *Preservation and Processing*, 2022, 22(11): 9–13.]
- [2] 邵园园, 王永贤, 玄冠涛, 等. 高光谱成像的猕猴桃货架期快速预测[J]. 光谱学与光谱分析, 2020, 40(6): 1940–1946. [SHAO Y Y, WANG Y X, XUAN G T, et al. Rapid prediction of shelf life of kiwifruit by hyperspectral imaging[J]. *Spectroscopy and Spectral Analysis*, 2020, 40(6): 1940–1946.]
- [3] 何代弟, 张晓, 张楠楠, 等. 苹果内部品质近红外光谱无损检测研究进展[J]. *安徽农学通报*, 2023, 29(16): 136–139. [HE D D, ZHANG X, ZHANG N N, et al. Research progress on NDT of internal quality of apple[J]. *Anhui Agriculture Bulletin*, 2023, 29(16): 136–139.]
- [4] GAO W, CHENG X, LIU X, et al. Apple firmness detection method based on hyperspectral technology[J]. *Food Control*, 2024, 166: 110690.
- [5] SEMYALO D, KWON O, WAKHOLI C, et al. Nondestructive online measurement of pineapple maturity and soluble solids content using visible and near-infrared spectral analysis[J]. *Postharvest Biology and Technology*, 2024, 209: 112706.
- [6] ZHAO Y, ZHANG C, ZHU S, et al. Shape induced reflectance correction for non-destructive determination and visualization of soluble solids content in winter jujubes using hyperspectral imaging in two different spectral ranges[J]. *Postharvest Biology and Technology*, 2020, 161: 111080.
- [7] GUAN S, SHANG Y, ZHAO C. Storage time detection of torreya grandis kernels using near infrared spectroscopy[J]. *Sustainability*, 2023, 15(10): 7757.
- [8] WENG S, YU S, DONG R, et al. Nondestructive detection of storage time of strawberries using visible/near-infrared hyperspectral imaging[J]. *International Journal of Food Properties*, 2020, 23(1): 269–281.
- [9] BOBELYN E, SERBAN A S, NICU M, et al. Postharvest quality of apple predicted by nir-spectroscopy: Study of the effect of biological variability on spectra and model performance[J]. *Postharvest Biology and Technology*, 2010, 55(3): 133–143.
- [10] ZENG S, ZHANG Z, CHENG X, et al. Prediction of soluble solids content using near-infrared spectra and optical properties of intact apple and pulp applying PLSR and CNN[J]. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 2024, 304: 123402.
- [11] LI X, WEI Y, XU J, et al. SSC and pH for sweet assessment and maturity classification of harvested cherry fruit based on NIR hyperspectral imaging technology[J]. *Postharvest Biology and Technology*, 2018, 143: 112–118.
- [12] MA T, ZHAO J, INAGAKI T, et al. Rapid and nondestructive prediction of firmness, soluble solids content, and pH in kiwifruit using Vis-NIR spatially resolved spectroscopy[J]. *Postharvest Biology and Technology*, 2022, 186: 111841.
- [13] XUAN G, GAO C, SHAO Y, et al. Maturity determination at harvest and spatial assessment of moisture content in okra using Vis-NIR hyperspectral imaging[J]. *Postharvest Biology and Technology*, 2021, 180: 111597.
- [14] ZHU Q, GUAN J, HUANG M, et al. Predicting bruise susceptibility of 'Golden Delicious' apples using hyperspectral scattering technique[J]. *Postharvest Biology and Technology*, 2016, 114: 86–94.
- [15] HASANZADEHB, ABBASPOUR-GILANDEHY, SOLTANI-NAZARLOO A, et al. Non-destructive measurement of quality parameters of apple fruit by using visible/near-infrared spectroscopy and multivariate regression analysis[J]. *Sustainability*, 2022, 14(22): 14918.
- [16] 王浩云, 李晓凡, 李亦白, 等. 基于高光谱图像和 3D-CNN 的苹果多品质参数无损检测[J]. *南京农业大学学报*, 2020, 43(1): 178–185. [WANG Haoyun, LI Xiaofan, LI Yibai, et al. Non-destructive testing of multiple quality parameters of apples based on hyperspectral images and 3D-CNN[J]. *Journal of Nanjing Agricultural University*, 2020, 43(1): 178–185.]
- [17] 孙炳新, 匡立学, 徐方旭, 等. 苹果有效酸度的近红外无损检测研究[J]. 食品工业科技, 2013, 34(15): 298–301. [SUN Bingxin, KUANG Lixue, XU Fangxu, et al. Research on near-infrared nondestructive testing of effective acidity of apple[J]. *Science and Technology of Food Industry*, 2013, 34(15): 298–301.]
- [18] 姚亚楠. 红富士苹果品质测定及近红外便携式无损检测仪的研发[D]. 乌鲁木齐: 新疆农业大学, 2022. [YAO Yanan. Research and development of red Fuji apple quality determination and near-infrared portable nondestructive tester[D]. Urumqi: Xinjiang Agricultural University, 2022.]
- [19] 牛晓颖, 贡东军, 王艳伟, 等. 基于近红外光谱和化学计量学的李果实成熟度鉴别方法研究[J]. 现代食品科技, 2014, 30(12): 230–234, 125. [NIU X Y, GONG D J, WANG Y W, et al. Identification method of plum fruit maturity based on near infrared spectroscopy and chemometrics[J]. *Modern Food Science and Technology*, 2014, 30(12): 230–234, 125.]
- [20] 王加华, 韩东海. 便携式近红外水果糖度分析模型简化研究[J]. 食品安全质量检测技术, 2009, 1(1): 32–38. [WANG J H, HAN D H. Simplification of portable near infrared fruit sugar content analysis model[J]. *Food Safety and Quality Detection Technology*, 2009, 1(1): 32–38.]
- [21] 刘翠玲, 秦冬, 凌彩金, 等. 基于内在品质参数的乌龙茶等级判别模型建立[J]. 食品工业科技, 2023, 44(12): 308–318. [LIU C L, QIN D, LING C J, et al. Establishment of a classification mod-

- el for oolong tea based on intrinsic quality parameters[J]. Science and Technology of Food Industry, 2023, 44(12): 308–318.]
- [22] 高升, 徐建华. 高光谱成像的红提总酸与硬度的预测及其分布可视化 [J]. 食品科学, 2023, 44(2): 327–336. [GAO S, XU J H. Prediction and visualization of total acid and hardness of red grapes based on hyperspectral imaging[J]. Food Science, 2023, 44 (2): 327–336.]
- [23] 王琪, 常庆瑞, 李铠, 等. 基于主成分分析和随机森林回归的冬小麦冠层叶绿素含量估算 [J]. 麦类作物学报, 2024, 44(4): 532–542. [WANG Q, CHANG Q R, LI K, et al. Estimation of canopy chlorophyll content of winter wheat based on principal component analysis and random forest regression[J]. Journal of Trimetics Crops, 2024, 44(4): 532–542.]
- [24] 黄锋华, 燕红文, 苗荣慧. 高光谱技术结合 GLCM 的油桃品种判别研究 [J]. 农业技术与装备, 2021(12): 5–7,10. [HUANG F H, YAN H W, MIAO R H. Identification of nectarine varieties by hyperspectral technology combined with GLCM[J]. Agricultural Technology & Equipment, 2021(12): 5–7,10.]
- [25] 王辉, 李辉, 陈金阳, 等. 基于 GLCM 特征木材树种高光谱无损检测识别研究 [J]. 黑龙江科学, 2019, 10(24): 25–27,31. [WANG H, LI H, CHEN J Y, et al. Research on hyperspectral non-destructive detection and identification of wood species based on GLCM characteristics[J]. Heilongjiang Science, 2019, 10(24): 25–27,31.]
- [26] 张鹏, 陈帅帅, 李江阔, 等. 采用近红外光谱进行采后苹果品种及货架期定性判别 [J]. 食品与发酵工业, 2019, 45(19): 200–205. [ZHANG P, CHEN S S, LI J K, et al. Qualitative identification of postharvest apple varieties and shelf life by near infrared spectroscopy[J]. Food and Fermentation Industry, 2019, 45(19): 200–205.]
- [27] PAN L, LI H, ZHAO J. Improvement of the prediction of a visual apple ripeness index under seasonal variation by NIR spectral model correction[J]. Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 2023, 302: 123075.
- [28] ZHANG D, XU Y, HUANG W, et al. Nondestructive measurement of soluble solids content in apple using near infrared hyperspectral imaging coupled with wavelength selection algorithm [J]. Infrared Physics & Technology, 2019, 98: 297–304.
- [29] 沈跃铖, 阮贤萍, 郎春晓, 等. 光谱特征和纹理特征融合的红茶萎凋含水率检测方法 [J]. 茶叶通讯, 2024, 51(3): 376–382. [SHEN Y H, RUAN X P, LANG C X, et al. Detection method of wilting moisture content of black tea based on fusion of spectral features and texture features[J]. Tea Communications, 2024, 51(3): 376–382.]
- [30] DONG J, GUO W. Nondestructive determination of apple internal qualities using near-infrared hyperspectral reflectance imaging[J]. Food Analytical Methods, 2015, 8: 2635–2646.