

## 高光谱成像的猕猴桃糖度无损检测方法

许丽佳<sup>1</sup>, 陈 铭<sup>1</sup>, 王玉超<sup>1</sup>, 陈晓燕<sup>2,3</sup>, 雷小龙<sup>1\*</sup>

1. 四川农业大学机电学院, 四川 雅安 625014
2. 四川农业大学信息工程学院, 四川 雅安 625014
3. 四川农业大学农业信息工程四川省重点实验室, 四川 雅安 625014

**摘 要** 猕猴桃糖度是重要的猕猴桃内部品质衡量指标。传统的糖度检测耗时且有损样品, 有效无损检测猕猴桃糖度含量对于其品质分级、储藏销售具有重大意义。基于高光谱成像技术的常见果蔬品质无损检测方法多数是采用竞争性自适应重加权算法(CARS)、连续投影算法(SPA)、主成分分析(PCA)、迭代保留信息变量法(IRIV)等算法中的某个单一算法提取特征光谱变量, 而这些算法单独使用易导致预测结果的稳定性不足。对此, 开展了基于高光谱成像技术的猕猴桃糖度的无损检测方法研究。以四川省雅安市“红阳”猕猴桃为研究对象, 依次对猕猴桃样本编号并采集其在 400~1 000 nm 波长范围内的高光谱图像, 计算感兴趣区域的平均光谱作为样本的有效光谱信息; 分别采用多元散射校正(MSC)、标准正态变量变换(SNV)、直接正交信号校正(DOSC)等 3 种光谱数据预处理方法分析对预测模型精度的影响, 对比结果显示 DOSC 的预处理效果最好; 对预处理后的光谱分别采用一次降维(CARS, SPA, IRIV)、一次组合降维(CARS+SPA, CARS+IRIV)算法和二次组合降维算法((CARS+SPA)-SPA, (CARS+IRIV)-SPA)等 7 种算法提取特征光谱变量, 并分别构建了预测猕猴桃糖度的 3 种模型, 即支持向量回归机(SVR)、最小二乘支持向量机(LSSVM)和极限学习机(ELM)模型; 最后对比了基于不同特征提取方法的 3 种模型的预测精度。研究结果表明: ELM 模型具有最好的预测性能, 而 SVR 模型的预测性能最差; (CARS+IRIV)-SPA 所选特征光谱变量输入 LSSVM、ELM 模型, 其获得的预测结果均优于其他算法所选特征光谱变量输入对应模型所得的预测结果, 证明了(CARS+IRIV)-SPA 算法在提高猕猴桃糖度含量检测精度方面的有效性。对比不同方法的预测结果可知, (CARS+IRIV)-SPA-ELM 对猕猴桃糖度的预测性能最优, 其相关系数  $R_c=0.945 1$ ,  $R_p=0.839 0$ , 均方根误差  $RMSEC=0.450 3$ ,  $RMSEP=0.598 3$ , 预测相对分析误差  $RPD=2.535 1$ , 该方法为猕猴桃糖度的检测无损化、精准化、智能化发展提供了可靠的理论依据和技术支撑。

**关键词** 猕猴桃; 高光谱成像; 糖度; 特征光谱变量; 极限学习机

**中图分类号:** O433.4 **文献标识码:** A **DOI:** 10.3964/j.issn.1000-0593(2021)07-2188-08

### 引 言

猕猴桃亦称奇异果, 含有多种微量元素和丰富的有机物, 营养价值高且口感酸甜, 拥有“水果之王”的美誉。糖度是猕猴桃主要的内部参数之一, 猕猴桃内部品质参数直接影响其口感, 也是决定猕猴桃采摘时间及储存时间的重要指标, 猕猴桃的糖度中 85% 左右的成分是可溶性固形物, 因此常用的传统糖度检测方法是采用折射仪测量被挤出的果汁中

的可溶性固形物含量(soluble solid content, SSC)来反映糖度值, 该方法繁琐、耗时且破坏样本, 无法实现快速的工业化检测。

高光谱成像技术因其信息量大、光谱分辨率高、操作方便等特点, 已广泛用于如苹果、樱桃、柿子、芝麻菜、梨、荔枝等<sup>[1-6]</sup> 果蔬内部参数的无损检测。李瑞等<sup>[7]</sup> 用偏最小二乘回归法建立基于高光谱图像的蓝莓糖度和硬度无损测量模型, 糖度和硬度的验证集相关系数分别为 0.774 和 0.871, 但主成分数有所增加, 且糖度预测精度不高; Li 等<sup>[8]</sup> 采集李

收稿日期: 2020-07-09, 修订日期: 2020-11-18

基金项目: 国家自然科学基金项目(31901413), 国家重点研发计划项目(2018YFD0301204), 四川省科技厅重点研发面上项目(20ZDYF2384), 四川省教育厅自然科学重点项目(17ZB0333), 市校合作项目(2018ssxz02)资助

作者简介: 许丽佳, 1973 年生, 四川农业大学机电学院教授 e-mail: xulijia@sicau.edu.cn

\* 通讯作者 e-mail: leixl1989@163.com

子图像,对比分析了可见近红外波段和短波近红外(short wave near infrared, SWIR)的两类高光谱图像,并建立偏最小二乘回归(partial least squares regression, PLSR)预测模型,结果表明该模型可以准确预测可溶性固形物含量,预测集的相关系数 $R_p > 0.8$ ;刘燕德等<sup>[9]</sup>采用高光谱成像技术,建立偏最小二乘定量回归模型预测黄桃的可溶性固形物含量,预测集的相关系数为 0.792,检测精度有待提高。

常见的基于高光谱成像技术的果蔬无损检测方法大多是采用竞争性自适应重加权算法(competitive adaptive reweighted sampling, CARS)、连续投影算法(successive projections algorithm, SPA)、主成分分析(principal component analysis, PCA)、迭代保留信息变量法(iteratively retains informative variables, IRIV)等<sup>[10-11]</sup>单一算法进行特征提取,并结合支持向量回归(support vector regression, SVR)建立检测模型<sup>[10]</sup>,而这些算法单独使用时易存在稳定性不足。例如,CARS算法中蒙特卡罗采样过程具有随机性,故其提取的特征光谱变量具有一定随机性;SPA算法选择的特征光谱变量中易掺杂无信息变量,可降低预测模型的可靠性。故寻找一种更优的高光谱数据特征提取方法和一种更适合的检测模型来解决猕猴桃糖度含量的无损检测问题显得十分必要。

为此,本文采用各算法间优缺点互补的思路,利用IRIV算法剔除光谱变量中的无信息变量和干扰变量,与CARS算法所精选的特征光谱变量直接组合,增加富含猕猴桃糖度信息的光谱变量,再用SPA算法对由CARS+IRIV形成的组合特征光谱变量进行二次降维,以便消除变量间的共线性,提高算法稳定性;通过将不同降维方法所选特征光谱变量分别构建预测猕猴桃糖度的极限学习机(extreme learning machine, ELM)模型<sup>[12]</sup>,并与支持向量回归(SVR)、最小二乘支持向量机(least square support vector machine, LSSVM)<sup>[13]</sup>所建模型的预测结果相比较,确定出最优预测方法。在猕猴桃品质检测领域,此(CARS+IRIV)-SPA-ELM方法尚未见报道,以期对猕猴桃糖度的无损检测提供新的技术手段。

## 1 实验部分

### 1.1 材料

实验材料为四川雅安市某猕猴桃基地现采的“红阳”猕猴桃。选取 120 个大小相近、表面无损伤和疤痕的猕猴桃样本并依次编号,静置于实验室 24 h,等待采集其高光谱图像并随后测量其糖度,实验期间的环境温度 $(26 \pm 1)^\circ\text{C}$ 。

### 1.2 仪器与设备

SKY107 手持式糖度折射仪,上海雨沃仪器设备有限公司;Gaia Sorter“盖亚”高光谱分选仪,包括 1 台 CCD 光谱相机(Image- $\lambda$ “谱像”系列高光谱相机),4 个 200 W 的溴钨灯光源、1 个电动平移台及计算机等,由 AC220 V 电源供电。高光谱分选仪的光谱波段范围为 387~1 034 nm,分辨率为 2.8 nm,共计 256 个波长。

采集光谱所用软件为 Spec View 图像采集软件(芬兰

Specimen 公司),数据提取软件为 ENVI 5.1(美国 Research System 公司),数据处理分析软件为 MATLAB 2017a(美国 Math Works 公司)。

### 1.3 高光谱图像信息采集

高光谱分选仪预热 30 min 后开始采集图像,以保证采集时的环境温度和光源强度在采集初期和后期保持一致。将标准白板的高度调整至与猕猴桃样本在同一焦面上,光谱相机曝光时间为 13.5 ms,样本平台与镜头的距离为 170 mm,电控移动平台前进距离为 11 cm,其前进速度及回退速度分别为 0.46 和 5  $\text{cm} \cdot \text{s}^{-1}$ 。高光谱分选仪如图 1 所示。



图 1 高光谱分选仪

Fig. 1 Hyperspectral sorter

### 1.4 猕猴桃糖度测定

采集完所有样本的高光谱图像后,当天进行并完成猕猴桃糖度测定。根据行业规定,常以猕猴桃赤道部位的糖度来代表整体糖度,参照 NT/T2637—2014《水果、蔬菜制品可溶性固形物含量的测定-折射仪法》,对每个猕猴桃样本依次将其赤道上的果皮削掉,取出适量果肉榨汁,随后用一次性滴管将汁液滴到 SKY107 手持式糖度折射仪的检测槽中,读出该样本的糖度理化值示数。每个样本以两次平行测定结果的算术平均值作为该样本的糖度理化测量值。

### 1.5 高光谱数据的提取

采用 Spec View 软件对猕猴桃样本的原始高光谱图像进行黑白校正,利用 ENVI 5.1 软件从校正后的图像中选择猕猴桃整个赤道区域作为感兴趣区域(region of interest, ROI)并提取光谱,以 ROI 区域的平均光谱作为此猕猴桃的原始光谱信息,如图 2(a)所示。

由图 2(a)可知,原始光谱曲线的首尾两端存在明显噪声,故选取每个样本 400~1 000 nm 波长范围内的高光谱信息作为有效光谱,如图 2(b)所示,该范围共计 237 个波长。

### 1.6 模型评价

利用 5 个指标值即校正集的相关系数( $R_c$ )及其均方根误差(RMSEC)、预测集的相关系数( $R_p$ )及其均方根误差(RMSEP)、相对分析误差(RPD)来评价模型的预测性能。其中, $R_c$ 和 $R_p$ 越接近于 1,表明模型的稳定性及拟合度越高;RMSEC和RMSEP越接近于 0,表明模型的预测能力越强;RPD定义为样本的标准差与其均方根误差之比,若 $\text{RPD} < 1.4$ ,模型对样本无法实施预测, $1.4 \leq \text{RPD} < 1.8$ ,模型可对样本进行粗略预测, $1.8 \leq \text{RPD} < 2.0$ ,模型可对样本进行较好预测, $\text{RPD} \geq 2$ ,模型可对样本进行极好预测<sup>[11]</sup>。




图 2 猕猴桃样本的光谱信息

Fig. 2 Spectral information of kiwi samples

## 2 结果与讨论

### 2.1 样本划分

对 120 个猕猴桃样本利用拉依达准则方法进行异常值的判别和剔除, 结果显示无异常值, 随后将其按照 3 : 1 比例用 KS(Kennard-Stone)算法<sup>[14]</sup>将其划分为 90 个校正集样本、30 个预测集样本, 猕猴桃样本糖度测量值结果见表 1。

表 1 猕猴桃糖度的测量结果统计 (单位/°Brix)

Table 1 The statistical results of kiwi fruit sugar

content measurement (unit: /°Brix)

| Data set        | Samples | Min   | Max   | Mean  | S. D |
|-----------------|---------|-------|-------|-------|------|
| Calibration set | 90      | 9.50  | 18.10 | 13.17 | 1.93 |
| Prediction set  | 30      | 10.40 | 16.50 | 13.56 | 1.52 |

### 2.2 光谱及预处理

为了减少提取的光谱数据中掺杂的噪声和光谱倾斜, 以便提高光谱分辨的灵敏度, 进行合理的光谱预处理是必要的。利用多元散射校正 (multiplicative scatter correction, MSC)、标准正态变量变换 (standard normal variate, SNV)、直接正交信号校正 (direct orthogonal signal correction, DOSC) 等 3 种方法对有效光谱进行预处理, 并分别建立对应的 ELM 预测模型, 其预测结果见表 2。由表 2 可知, DOSC-ELM 模型的  $R_c$  和  $R_p$  值最大且 RMSEC 和 RMSEP 值最小, 预测效果好, 故后续均基于 DOSC 预处理方法进行。

表 2 采用不同预处理方法的全波段 ELM 预测模型

Table 2 All-band ELM prediction model using different pretreatment methods

| Pretreatment method | Number of hidden neurons | Calibration set |         | Prediction set |         |
|---------------------|--------------------------|-----------------|---------|----------------|---------|
|                     |                          | RMSEC           | $R_c$   | RMSEP          | $R_p$   |
| Raw valid data      | 92                       | 1.076 2         | 0.673 4 | 1.126 0        | 0.539 9 |
| SNV                 | 72                       | 1.418 2         | 0.410 2 | 1.414 9        | 0.342 1 |
| MSC                 | 71                       | 1.345 7         | 0.469 0 | 1.154 7        | 0.561 8 |
| DOSC                | 35                       | 0.518 4         | 0.927 3 | 0.753 2        | 0.744 9 |

DOSC 方法通过将光谱矩阵与待测浓度矩阵正交, 在不

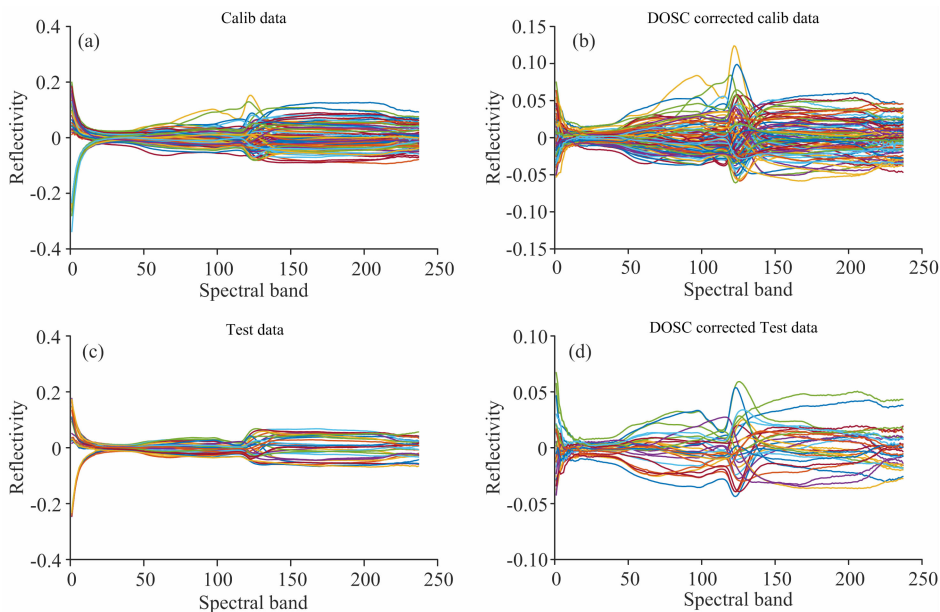


图 3 DOSC 预处理前后的光谱反射率图像

Fig. 3 Spectral reflectance images before and after DOSC preprocessing

损害数据结构特性的前提下滤除原始光谱中与糖度不相关的信息，保留最相关的信息用于构建预测模型<sup>[15]</sup>。DOSC 预处理前的校正集和预测集的光谱反射率分别如图 3(a)和图 3(c)所示，DOSC 预处理后的校正集和预测集的光谱反射率分别如图 3(b)和图 3(d)所示。

从图 3 可知，相较于未经过预处理的高光谱图像，DOSC 预处理后的光谱图像线条更加紧密，图 3(b)和图 3(d)中所凸起的波峰也反映了预处理后的光谱数据与待测成分即糖度的相关性得到了良好的提升。DOSC 预处理前后各高光谱波段与猕猴桃糖度的相关系数如图 4 所示。通常相关系数  $0.5 \leq |r| < 0.8$  时为显著相关， $|r| \geq 0.8$  时为高度相关，由图 4 可知，经 DOSC 预处理后大量光谱数据与糖度呈现显著甚至高度相关。

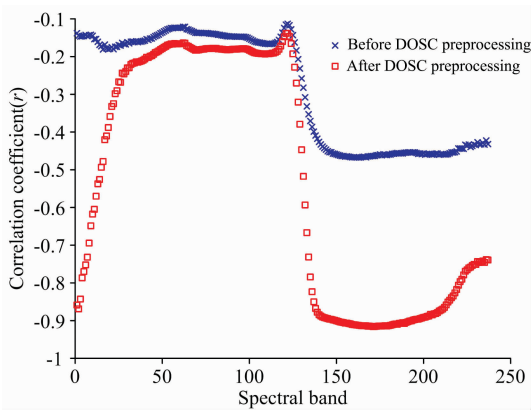


图 4 DOSC 预处理前后各光谱波段与糖度的相关性

Fig. 4 The correlation coefficient between spectral band and sugar content before and after DOSC preprocessing

### 2.3 特征光谱变量的提取与组合

#### 2.3.1 基于 IRIV 的特征光谱变量提取

对预处理后的光谱用 IRIV 算法提取特征光谱变量时，设定 IRIV 算法的交叉验证次数为 5，PLS 模型中的最大主成分个数为 10。IRIV 算法一共进行了 7 轮迭代，如图 5 所示。在图 5 中，前 4 轮迭代过程中特征光谱变量的个数迅速减少，变量个数从 237 个缩减到 36 个，随着特征光谱变量个数减少的速度放缓，经第 6 轮迭代后完全剔除了其中的无信

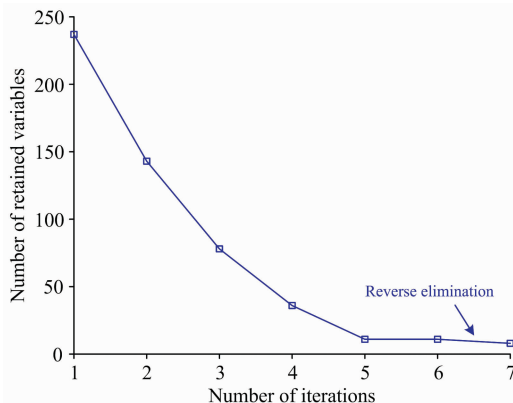


图 5 IRIV 提取特征变量过程

Fig. 5 Extracting characteristic variables by IRIV

息变量和干扰变量，变量缩减到 10 个，在反向消除 2 个变量后，最终得到 8 个特征光谱变量，占全光谱波段的 3.4%。经过 IRIV 提取的特征光谱变量分布如图 6 所示。

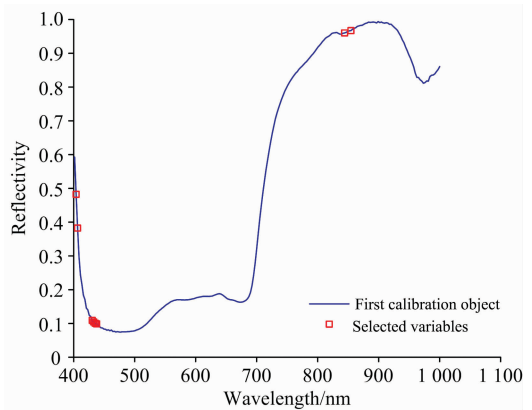


图 6 IRIV 提取的特征光谱变量分布图

Fig. 6 Distribution of IRIV characteristic spectral variables

#### 2.3.2 基于 CARS 的特征光谱变量提取

对预处理后的光谱用 CARS 算法提取特征光谱变量时，设定蒙特卡罗采样 50 次，采用 5 折交叉验证法。图 7(a)为呈现指数衰减函数的选择过程，特征光谱变量的数量随着采样次数的增加先迅速下降然后平缓减少，具有“粗选”和“精选”2 个特征。由图 7(b)可知，随着 Monte-Carlo 采样次数的增加，内部交叉验证均方根误差(RMSECV)呈先缓慢减小后陡然增大的趋势，这是由于选择过度而移除了富含信息的关键变量，导致模型的预测性能下降。图 7(c)是特征光谱变量随着采样次数变化的回归系数路径图，当图 7(b)中 RMSECV 值达到最小值时，各特征光谱变量的回归系数位于图 7(c)中的“\*”所在的垂直线位置，此时采样运行 5 次，最终提取出 49 个特征光谱变量。




图 7 CARS 运行结果

Fig. 7 The results of CARS

#### 2.3.3 基于 SPA 的特征光谱变量提取

对预处理后的光谱用 SPA 算法提取特征光谱变量时，分别计算 SPA 在不同个数的特征光谱变量下的均方根误差

RMSEC, 通常选取最小的 RMSEC 值来确定最佳的特征光谱变量个数。设置特征光谱变量数的变化范围为 1~50, 当 RMSEC=0.876 4 即最小值时, 此时提取了 9 个特征光谱变量, 占全光谱波段的 3.8%。该 9 个特征光谱变量在全光谱波段中的分布如图 8 所示。




图 8 SPA 特征变量分布图

Fig. 8 Distribution diagram of SPA spectral characteristic variables

#### 2.3.4 特征光谱变量的组合

依据前述 3 种方法提取的特征光谱变量, 本文设计了 4 种方法对其组合提取(见表 3), 并分别建立对应的 SVR, LSSVM 和 ELM 模型预测猕猴桃的糖度。

表 3 不同特征提取方法提取到的特征变量数

Table 3 The number of feature variables extracted by different feature extraction methods

| Extraction method | Variable number |
|-------------------|-----------------|
| CARS              | 49              |
| SPA               | 9               |
| IRIV              | 8               |
| CARS+SPA          | 58              |
| CARS+IRIV         | 55              |
| (CARS+SPA)-SPA    | 11              |
| (CARS+IRIV)-SPA   | 19              |

注: 以此为例理解表内所列提取法: CARS+IRIV 表示将 CARS 算法提取的 49 个特征光谱变量与 IRIV 算法提取的 8 个特征光谱变量直接组合; (CARS+IRIV)-SPA 表示用 SPA 算法对由 CARS+IRIV 形成的组合特征光谱变量进行二次降维

Note: For example, CARS+IRIV represents a direct combination of the 49 feature spectral variables extracted by the CARS algorithm and the 8 feature spectral variables extracted by the IRIV algorithm; (CARS+IRIV)-SPA represents the use of the SPA algorithm to perform a second dimensional reduction on the combined feature spectral variable formed by CARS+IRIV

考虑到由 CARS+IRIV 形成的 55 个组合特征光谱变量个数较多, 且相邻波段间仍存在一定的共线性问题, 故利用 SPA 算法对其进行二次降维以便消除其中的共线性。设置特征光谱变量数的变化范围为 1~35, SPA 算法对 55 个组合特征光谱变量降维并提取出了 19 个特征变量, 如图 9(a)所

示。图 9(b)表示所选的 19 个特征变量在原始有效光谱中对应的波长位置, 占全光谱波段的 8%。




图 9 猕猴桃糖度的 SPA 特征光谱变量分布图

Fig. 9 Distribution of SPA characteristic spectral variables for kiwifruit sugar content

## 2.4 预测模型的建立及结果分析

### 2.4.1 LSSVM 和 SVR 模型

选取 RBF 函数作为 LSSVM 的核函数, 利用 PSO 优化 LSSVM 的正则参数  $\gamma$  和 RBF 的核参数  $\sigma^2$ 。设定粒子种群个数为 20, 学习因子  $c_1=c_2=2$ , 惯性因子初值  $\omega_{ini}=0.9$ 、终值  $\omega_{end}=0.4$ , 迭代次数  $K=100$  次。LSSVM 模型的参数寻优结果见表 4。

表 4 PSO 优化后的参数  $\gamma, \sigma^2$

Table 4 PSO optimized parameters  $\gamma, \sigma^2$

| Extraction method | Variable number | $\gamma$       | $\sigma^2$   |
|-------------------|-----------------|----------------|--------------|
| CARS              | 49              | 178 232. 022 6 | 2 315. 787 8 |
| SPA               | 9               | 24 689. 722 8  | 4 419. 308 9 |
| IRIV              | 8               | 68 345. 149 3  | 4 095. 753 5 |
| CARS+SPA          | 58              | 128 353. 819 6 | 519. 357 2   |
| CARS+IRIV         | 55              | 66 321. 544 4  | 3 244. 478 3 |
| (CARS+SPA)-SPA    | 11              | 213 051. 988 1 | 2 541. 380 7 |
| (CARS+IRIV)-SPA   | 19              | 292 698. 908 2 | 810. 048 4   |

将 7 种特征提取方法提取的特征光谱变量分别建立 SVR 及 LSSVM 模型, 其预测结果分别见表 5、表 6。由表 5 可知, SVR 模型中预测集的相关系数  $R_p$  均低于 0.670 0, 其

预测性能不佳。从表 6 中数据可知, CARS, CARS+SPA, CARS+IRIV 和(CARS+IRIV)-SPA 等 4 种特征提取方法建立的 LSSVM 模型的 RPD 值均在[1.8, 2.0]范围内, 表示其预测精度不高; (CARS+IRIV)-SPA-LSSVM 方法的  $R_p = 0.7204$ ,  $RPD = 1.9235$ , 与其他方法相比, 其具有相对较高的预测精度和稳定性。

2.4.2 ELM 模型

选取“tribas”函数作为极限学习机(ELM)的激活函数, 并设置 ELM 的隐含层神经元个数在[1, 100]范围内, 步长为 1。分别计算在不同个数的隐含层节点下的交叉验证均方根误差 RMSECV 值, 选取 RMSECV 为最小值时所对应的隐含层神经元个数。用 7 种特征提取方法提取的特征光谱变量建立对应的 ELM 模型, 其对猕猴桃糖度的预测结果见表 7。

表 5 不同特征提取方法建立的 SVR 模型预测结果

Table 5 Prediction results of SVR model established by different feature extraction methods

| Extraction method | Variable number | RMSEC  | $R_c$  | RMSEP  | $R_p$  | RPD    |
|-------------------|-----------------|--------|--------|--------|--------|--------|
| CARS              | 49              | 0.6583 | 0.8827 | 0.8781 | 0.6533 | 1.7274 |
| SPA               | 9               | 0.6726 | 0.8776 | 0.8816 | 0.6506 | 1.7206 |
| IRIV              | 8               | 0.6525 | 0.8848 | 0.8582 | 0.6688 | 1.7674 |
| CARS+SPA          | 58              | 0.6595 | 0.8823 | 0.8866 | 0.6466 | 1.7109 |
| CARS+IRIV         | 55              | 0.6542 | 0.8842 | 0.8716 | 0.6584 | 1.7403 |
| (CARS+SPA)-SPA    | 11              | 0.6625 | 0.8812 | 0.8959 | 0.6391 | 1.6931 |
| (CARS+IRIV)-SPA   | 19              | 0.6666 | 0.8797 | 0.8831 | 0.6494 | 1.7177 |

表 6 不同特征提取方法建立的 LSSVM 模型预测结果

Table 6 Prediction results of LSSVM model established by different feature extraction methods

| Extraction method | Variable number | RMSEC  | $R_c$  | RMSEP  | $R_p$  | RPD    |
|-------------------|-----------------|--------|--------|--------|--------|--------|
| CARS              | 49              | 0.4515 | 0.9448 | 0.8348 | 0.6867 | 1.8170 |
| SPA               | 9               | 0.6373 | 0.8901 | 0.8745 | 0.6562 | 1.7345 |
| IRIV              | 8               | 0.6240 | 0.8946 | 0.8671 | 0.6620 | 1.7493 |
| CARS+SPA          | 58              | 0.1387 | 0.9948 | 0.8231 | 0.6954 | 1.8428 |
| CARS+IRIV         | 55              | 0.4719 | 0.9397 | 0.8248 | 0.6941 | 1.8390 |
| (CARS+SPA)-SPA    | 11              | 0.5805 | 0.9088 | 0.8707 | 0.6591 | 1.7421 |
| (CARS+IRIV)-SPA   | 19              | 0.4715 | 0.9398 | 0.7885 | 0.7204 | 1.9235 |

表 7 不同特征提取方法建立的 ELM 模型预测结果

Table 7 Prediction results of ELM model established by different feature extraction methods

| Extraction method | Variable number | Number of hidden neurons | RMSEC  | $R_c$  | RMSEP  | $R_p$  | RPD    |
|-------------------|-----------------|--------------------------|--------|--------|--------|--------|--------|
| CARS              | 49              | 46                       | 0.4497 | 0.9453 | 0.6850 | 0.7890 | 2.2144 |
| SPA               | 9               | 89                       | 0.5854 | 0.9072 | 0.7993 | 0.7127 | 1.8977 |
| IRIV              | 8               | 86                       | 0.5573 | 0.9160 | 0.7968 | 0.7145 | 1.9036 |
| CARS+SPA          | 58              | 50                       | 0.4666 | 0.9411 | 0.6372 | 0.8174 | 2.3804 |
| CARS+IRIV         | 55              | 50                       | 0.4492 | 0.9454 | 0.5918 | 0.8425 | 2.5630 |
| (CARS+SPA)-SPA    | 11              | 49                       | 0.5118 | 0.9291 | 0.6886 | 0.7868 | 2.2026 |
| (CARS+IRIV)-SPA   | 19              | 92                       | 0.4503 | 0.9451 | 0.5983 | 0.8390 | 2.5351 |

由表 7 可知, 有 5 种方法提取的特征光谱变量对应建立的 ELM 模型的 RPD 均大于 2.20。其中, CARS+IRIV-ELM, (CARS+IRIV)-SPA-ELM 的 RPD 均大于 2.5, 与其他方法相比预测精度最高, 此 2 种方法对应校正集的  $R_c$  分别为 0.9454 和 0.9451、RMSEC 分别为 0.4492 和 0.4503, 对应预测集的  $R_p$  分别为 0.8425 和 0.8390、RMSEP 分别为 0.5918 和 0.5983。

CARS+IRIV-ELM 的  $R_p$  比(CARS+IRIV)-SPA-ELM 的  $R_p$  略高, 但前者需要 55 个特征光谱变量导致计算负荷大, 且 CARS+IRIV 提取的特征光谱变量具有一定随机性, 造成该方法的检测结果不太稳定; 而(CARS+IRIV)-SPA 的

二次组合降维方法能减少特征光谱变量的个数且消除变量间的共线性, 还能进一步减小由 CARS 算法导致的随机性, 从而使得对应的 ELM 模型具有高精度且较稳定可靠的预测性能。由表 6、表 7 数据可知, (CARS+IRIV)-SPA 在 LSSVM、ELM 两种模型下的预测精度都很高, 表明该特征提取方法的适用性较强。

表 5—表 7 中各种方法的模型评价  $R_c$  与  $R_p$  之间存在一定差异, 源于校正集与预测集的样本数不多、数据量小所致, 在实际应用中可以通过扩大样本数据量来改善模型预测结果。综合表 5—表 7 中的预测结果, 可以确定(CARS+IRIV)-SPA-ELM 为猕猴桃糖度的最佳预测方法。

### 3 结 论

以四川省雅安市“红阳”猕猴桃为研究对象, 本文利用高光谱成像技术结合不同特征光谱变量提取方法构建不同模型, 对猕猴桃糖度进行无损检测。研究结果如下:

(1)对猕猴桃原始有效光谱分别采用 MSC, SNV 和 DOSC 预处理后, 结合 ELM 模型的预测结果, 分析不同预处理方法对模型预测精度的影响, 对比结果显示 DOSC 预处理效果最好。

(2)对 DOSC 预处理后的光谱分别采用一次降维、一次组合降维和二次组合降维共 7 种特征提取方法, 提取到的特征光谱变量个数分别为 49, 9, 8, 58, 55, 11 和 19, 占全光谱波段的 20.7%, 3.8%, 3.4%, 24.5%, 23.2%, 4.6% 和 8%。

(3)基于前述 7 种特征提取方法, 分别建立预测猕猴桃糖度的 SVR, LSSVM 和 ELM 模型。实验结果表明, ELM 模型具有最好的预测性能, 而 SVR 模型的预测性能最差; (CARS+IRIV)-SPA 算法提取的特征光谱变量输入 LSSVM 和 ELM 模型, 其获得的预测结果均优于其他方法所提取的特征光谱变量输入对应模型所得的预测结果。对比不同方法的预测准确度和稳定性, 最终确定 (CARS+IRIV)-SPA-ELM 为检测猕猴桃糖度的最优预测方法, 其相关系数  $R_c = 0.945 1$  和  $R_p = 0.839 0$ , 均方根误差  $RMSEC = 0.450 3$ ,  $RMSEP = 0.598 3$ , 预测相对分析误差  $RPD = 2.535 1$ 。

(4)由此可见, 与其他现有特征提取方法相比, (CARS+IRIV)-SPA 算法具有明显的优势, 结合 ELM 模型可实现对猕猴桃糖度的最佳预测, 为猕猴桃糖度提供了一种有效可靠的无损检测新方法。

### References

- [ 1 ] Dong J L, Guo W C, Wang Z W, et al. Food Analytical Methods, 2016, 9(5): 1087.
- [ 2 ] Malegori C, Nascimento Marques E J, De Freitas S T, et al. Talanta, 2017, 165: 112.
- [ 3 ] Munera S, Besada C, Aleixos N, et al. Food Science and Technology, 2017, 77: 241.
- [ 4 ] Chaudhry M M, Amodio M L, Babellahi F, et al. Journal of Food Engineering, 2018, 238: 122.
- [ 5 ] Yu X J, Lu H D, Wu D. Postharvest Biology and Technology, 2018, 141: 39.
- [ 6 ] Pu H B, Liu D, Wang L, et al. Food Analytical Methods, 2016, 9(1): 235.
- [ 7 ] LI Rui, FU Long-sheng(李 瑞, 傅隆生). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2017, 33(S1): 362.
- [ 8 ] Li B, Cobo-Medina M, Lecourt J, et al. Postharvest Biology and Technology, 2018, 141: 8.
- [ 9 ] LIU Yan-de, HAN Ru-bing, ZHU Dan-ning, et al(刘燕德, 韩如冰, 朱丹宁, 等). Spectroscopy and Spectral Analysis(光谱学与光谱分析), 2017, 37(10): 3175.
- [ 10 ] SHAO Yuan-yuan, WANG Yong-xian, XUAN Guan-tao, et al(邵园园, 王永贤, 玄冠涛, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2019, 35(18): 245.
- [ 11 ] YU Lei, ZHANG Tao, ZHU Ya-xing, et al(于 雷, 章 涛, 朱亚星, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2018, 34(16): 148.
- [ 12 ] Bao Y D, Mi C X, Wu N, et al. Applied Sciences, 2019, 9(19): 4119.
- [ 13 ] Huang H, Shen Y, Guo Y L, et al. Journal of Food Engineering, 2017, 205: 47.
- [ 14 ] Xu Y, Wang J J, Xia A Q, et al. Remote Sensing, 2019, 11(3): 254.
- [ 15 ] RAO Li-bo, CHEN Xiao-yan, PANG Tao(饶利波, 陈晓燕, 庞 涛). Chinese Journal of Luminescence(发光学报), 2019, 40(3): 389.

# Study on Non-Destructive Detection Method of Kiwifruit Sugar Content Based on Hyperspectral Imaging Technology

XU Li-jia<sup>1</sup>, CHEN Ming<sup>1</sup>, WANG Yu-chao<sup>1</sup>, CHEN Xiao-yan<sup>2,3</sup>, LEI Xiao-long<sup>1\*</sup>

1. College of Mechanical and Electrical Engineering, Sichuan Agricultural University, Ya'an 625014, China

2. College of Information Engineering, Sichuan Agricultural University, Ya'an 625014, China

3. Lab of Agricultural Information Engineering, Sichuan Key Laboratory, Sichuan Agricultural University, Ya'an 625014, China

**Abstract** The sugar content of kiwifruit is an important measure of its internal quality. Traditional sugar content detection is time-consuming and destructive sampling, and it is of great significance to non-destructive detect the sugar content of kiwifruit effectively for its quality classification, storage and sales. The common non-destructive detection methods of fruit and vegetable quality based on hyperspectral imaging technology mostly use a single algorithm of competitive adaptive reweighted sampling (CARS), successive projections algorithm (SPA), principal component analysis (PCA) and iteratively retains informative variables (IRIV) to extract features. However, using these algorithms alone will lead to insufficient stability of prediction results. This study designs a non-destructive detection method for kiwifruit sugar content based on hyperspectral imaging technology. The "Red Sun" kiwifruit samples in Ya'an city of Sichuan province were numbered, their hyperspectral images in the wavelength range of 400~1 000 nm were collected, and the average spectrum of the region of interest was calculated as the effective spectral information of the samples. Then, three spectral data preprocessing methods including Multiplicative Scatter Correction (MSC), Standard Normal Variate (SNV), and Direct Orthogonal Signal Correction (DOSC), were used to analyze the influence on the accuracy of the prediction models, respectively. The comparison results showed that DOSC had the best preprocess effect. Further, for the preprocessed spectrum, 7 dimensionality reduction methods including CARS, SPA and IRIV from one-time dimensional-reduction algorithms, CARS+SPA and CARS+IRIV from the first-order combined dimensional reduction algorithms, and (CARS+SPA)-SPA, (CARS+IRIV)-SPA from the second-order combined dimensional-reduction algorithms respectively, were used to extract characteristic spectral variables, and three models for predicting the sugar content of kiwifruit were constructed i. e. Support Vector Regression (SVR), Least Square Support Vector Machine (LSSVM) and Extreme Learning Machine (ELM) models. Finally, the prediction accuracy of the three models based on different feature extraction methods was compared through experiments. This study shows that the ELM model has the best prediction performance, while the SVR model has the worst prediction performance. When the characteristic spectral variables extracted by (CARS+IRIV)-SPA were input into LSSVM and ELM models, respectively, the prediction results are better than those obtained by other methods. Then (CARS+IRIV)-SPA is verified to be effective in improving the prediction accuracy of the models. Comparing the prediction results of these methods, the prediction performance of (CARS+IRIV)-SPA-ELM is better than other methods, with the correlation coefficient  $R_c=0.945\ 1$ ,  $R_p=0.839\ 0$ ,  $RMSEC=0.450\ 3$ ,  $RMSEP=0.598\ 3$ , and  $RPD=2.535\ 1$ , which will provide reliable theoretical basis and technical support for the non-destructive, precise and intelligent development of kiwifruit sugar content detection.

**Keywords** Kiwi; Hyperspectral imaging; Sugar content; Characteristic wavelength; Extreme learning machine

(Received Jul. 9, 2020; accepted Nov. 18, 2020)

\* Corresponding author