

基于 GA-SVR 的苹果可溶性固形物质量分数的高光谱检测

查启明, 顾宝兴, 姬长英*

(南京农业大学 工学院, 江苏 南京 210031)

摘要: 以建立一种高精度的无损苹果可溶性固形物含量的检测模型为目标, 通过提取高光谱图像中圆形 150 像素感兴趣区域(ROI)内的平均光谱反射率, 分别使用 Savitzky-Golay 平滑处理(S-G)、标准正态变量变换(SNV)和小波变换(Wavelet-Transform)对原始光谱数据进行预处理, 然后利用连续投影算法(successive projection algorithm, SPA)提取特征波长, 基于特征波长建立 BP 神经网络(BPNN)和遗传支持向量机(GA-SVR)预测模型。在 GA-SVR 建模过程中, 采用遗传算法获取支持向量机的最优惩罚参数和核函数参数。研究结果表明, S-G 预处理后的 GA-SVR 模型预测效果最佳, 模型的预测相关系数为 0.850 5, 预测均方根误差为 0.303 1, 所以基于该 ROI 内数据建立的 GA-SVR 模型在提高模型性能方面是可行的。

关键词: 苹果; 高光谱; BPNN; 支持向量机; 连续投影算法

中图分类号: TS 255.1 文章编号: 1673-1689(2019)09-0125-08 DOI: 10.3969/j.issn. 1673-1689.2019.09.018

Hyperspectral Detection of Soluble Solids Content on Apple Based on GA-SVR

ZHA Qiming, GU Baoxing, JI Changying*

(College of Engineering, Nanjing Agricultural University, Nanjing 210031, China)

Abstract: In order to established a high precision method for the determination of soluble solids content in apple. In this study, the average spectral reflectance in the region of interest (ROI) of 150 pixels in the hyperspectral image is extracted. To reduce the noise in spectral, the extracted reflectance spectra were preprocessed by Savitzky-Golay smoothing (S-G), Standard Normal Variable Transform(SNV), and Wavelet Transform(WT) methods. The preprocessed spectra were then used to select sensitive wavelengths by Successive Projections Algorithm (SPA) method. Back-propagation neural network (BPNN) and genetic support vector machine (GA-SVR) were applied to build discriminant models with the selected wavelength variables. In the process of establishing GA-SVR model, GA method was used to select the optimal parameters of SVR automatically. The results indicated that the GA-SVR model preprocessed by S-G method was the best model. The prediction correlation coefficient of the model was 0.850 5, and the root mean square error of prediction was 0.303 1. The results show that the GA-SVR model based on the data

收稿日期: 2017-01-10

基金项目: 江苏省自然科学基金项目(BK20140720); 中央高校基本科研业务专项基金项目(KYZ201325)。

*通信作者: 姬长英(1957—), 男, 博士, 教授, 主要从事智能化农业装备研究。E-mail: chyji@njau.edu.cn

引用本文: 查启明, 顾宝兴, 姬长英. 基于 GA-SVR 的苹果可溶性固形物质量分数的高光谱检测[J]. 食品与生物技术学报, 2019, 38(09): 125-132.

extracted from this interest region was feasible to improve the performance of the model.

Keywords: apple, hyperspectral, BP neural network, support vector machine, successive projections algorithm

中国是苹果的生产大国,每年苹果的种植面积和总产量均为世界第一,但是中国却不是苹果贸易强国,国产苹果的价格及质量远远不及进口苹果,主要原因就是我国苹果的采后分级技术落后,不仅在国际市场上缺乏竞争力,而且不能满足国内高端市场的需求。人们在选用苹果时,会比较看重苹果的甜度,也就是苹果内部可溶性固形物的质量分数。高光谱成像技术既能够反映苹果的外部特征,例如颜色、表明缺陷等肉眼可以看见的特征,又能反映苹果内部的物质结构和化学成分等。

由于高光谱成像技术的优越性,近年来国内外在采用高光谱成像技术检测农产品方面展开了很多的研究。其中,黄文倩等基于400~1 000 nm的苹果高光谱图像采用不同的降维方法提取特征波长,然后建立最小二乘支撑向量机(LS-SVM)建模定量预测苹果的可溶性固形物质量分数(SSC)。Lu等对苹果的硬度进行高光谱图像技术检测,利用PCA和ANN相结合的方法对两种产地的苹果建立模型,模型的相关系数分别为0.76和0.55。侯宝路等利用连续投影算法(SPA)和多元线性回归算法(MLR)对梨的高光谱图像进行建模分析,来预测梨的可溶性固形物含量(SSC)和硬度。罗霞等利用高光谱成像技术对火龙果进行可溶性固形物质量分数检测,采用PLS和BP神经网络分别建立预测模型。

上述研究中大部分是在整个高光谱波段内进行特征波长提取,部分是通过经验判断优选波段后再采用算法提取特征波长,导致输入数据精度不足。作者将预处理后的高光谱数据先进行一阶微分后优选出噪声小的波段,再通过连续投影算法提取特征波长,以此提高模型的预测精度。

1 材料与方法

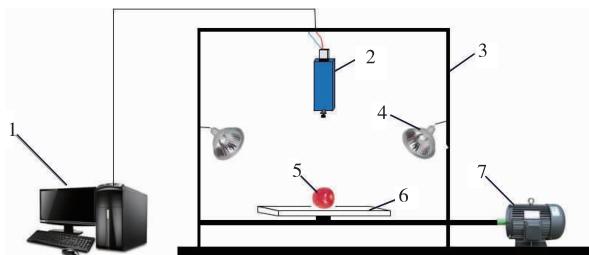
1.1 实验材料

以山东烟富、洛川元帅、洛川富士为研究对象,在实验中所使用的苹果均为2016年7月份在南京浦口水果批发市场购买。挑选的苹果表面没有缺陷、直径范围为65~85 mm,大小形状均匀,共计198

个。购买来的苹果放置在冰柜中保存,实验前分批拿出,待其恢复至室温后开始实验。实验中随机选取150个样本作为建模校正集,其余48个样本作为建模预测集。

1.2 高光谱图像采集与校正

实验中所用的高光谱系统包括:Inspector型光谱仪(芬兰Specim公司产品)、CCD相机(美国Imperx公司产品)、镜头、21V/150W线性卤素灯(美国Illumination公司产品)、暗箱、电控移动平台以及计算机等部件。高光谱成像波长范围为358~1 021 nm。参数设置如下:曝光时间52 ms,样本与镜头的距离为330 mm,传送带移动速度为0.7 mm/s。每个样本均在赤道部位标记3点(间隔约为)采集3张高光谱图像,198个样本共计594幅高光谱图像。



1.电脑;2.高光谱成像仪;3.暗箱;4.光源(卤素灯);5.样本(苹果);6.载物台;7.步进电机

图1 高光谱系统组成图

Fig. 1 Composition diagram of hyperspectral system

为了减少部分噪声的影响,使用样本采集相同的参数条件,经行黑白校正,公式为:

$$R = \frac{(R_0 - B)}{(W - B)}$$

式中: R_0 为采集的样本原始图像, B 为盖住镜头采集到的图像, W 为反射率为1的校正白板的采集图像, R 为黑白校正后的图像

1.3 可溶性固形物质量分数的测定

使用日本ATAGO公司的PAL-1型糖度仪(误差在±0.2%之内)进行可溶性固形物(SSC)的测定,每个样本测量赤道面均匀间隔的3处,挖取适量的果肉,压成汁液后进行测量,3个数值的平均值作为

该样本的SSC值。

1.4 感兴趣区域(ROI)的选取

使用ENVI软件提取苹果的不同波段反射率,提取之前要先确认高光谱图像的兴趣区域(ROI)。从图2可以看出同一样本,相同像素中心区域的不同像素大小的反射率存在明显差异,因此在选取ROI时,像素的形状及大小的选择显得尤为重要。郭志明等的研究结果表明当采用圆形150像素点的ROI时,模型效果最佳。因此本文在选取ROI时,在苹果高光谱图像的赤道部位,间隔取3处圆形150像素的ROI。以上述3处的平均反射光谱作为该样本的最终光谱。

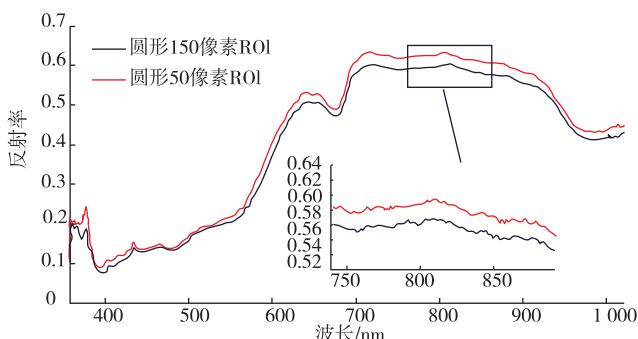


图2 不同像素 ROI 的反射光谱

Fig. 2 Reflectance spectra of ROI in different pixel

1.5 连续投影算法

连续投影算法(SPA)是一种选择波长变量的方法,能够在大量的波长变量中找出共线性最小的变量组合,从而降低模型输入变量的复杂性,提高模型的精度。样本数M和波长数N组成的矩阵是原始光谱变量, $A_{M \times N}$ 为原始光谱变量矩阵,L为最佳波长个数($L < M - 1$),连续投影算法的步骤如下:

(1) 初始化: $n=1$ (第一次迭代)在 $A_{M \times N}$ 中任选一个列向量(第j列),记为 $a_{k(0)}$ (即 $K(0)=j$);

(2) 定义一个集合 $S:S=\{j, 1 \leq j \leq N, j \notin \{k(0), \dots, k(n-1)\}\}$,这个集合包含未被选中的列向量的位置,分别计算 a_j 对所有未被选中向量的投影:

$Pa_j=a_j-(a_{k(n-1)}^T a_j) * a_{k(n-1)} * (a_{k(n-1)}^T a_{k(n-1)})^{-1}, (j \in S, P$ 是投影算子)

(3) 把步骤(2)中计算的投影值最大的记为 $k(n)$:

$$k(n)=\arg(\max \|Pa_j\|), (j \in S)$$

(4) 把步骤(3)中求得的最大投影值作为下一个迭代过程中的初始值,即:

$$a_j=P a_j, (j \in S)$$

(5) 进行下一次迭代:即令 $n=n+1$,如果 $n < L$,返回步骤(2)。

上述循环结束后,即得到选取出的特征波长: $\{k(n), n=0, 1, \dots, N-1\}$ 。这样总共可以得到 $L \times N$ 对波长组合,将预测均方根误差作为所建模型的优劣依据,以此选择出最佳波段。

1.6 建模方法和评价标准

1.6.1 BP 神经网络 BP神经网络是一种多层前馈网络,它通过误差逆向传播算法进行训练,在当前科学的研究中得到了广泛的应用,该网络模型共包含3个部分,分别为输入层、隐含层和输出层。BP网络能够保存大量的输入输出映射关系,并且具有自主学习的能力,并且使用者不用提前掌握这种映射关系的数学方程。它通过不断调整网络内部的权值和阈值来达到降低网络误差平方和的目的。

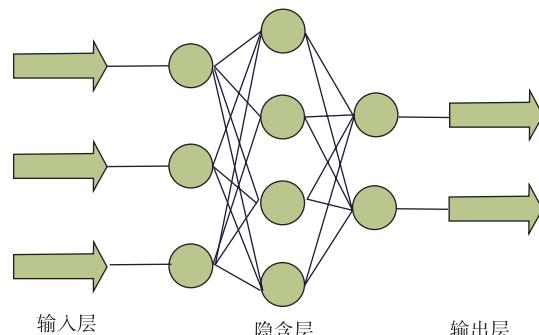


图3 BP 神经网络结构示意图

Fig. 3 Schematic of BP neural network

BP神经网络的学习过程如下:

(1) 输入模式由输入层经隐含层向输出层传播计算

(2) 输出的误差由输出层经隐含层传递给输入层

(3) 按照上述步骤反复运行

(4) 判别全局误差是否趋向极小值

1.6.2 GA-SVR模型 遗传算法(Genetic algorithm, GA)是通过模拟自然界生物进化过程构造出来的一种全局自适应搜索方法,根据适应度值的大小对个体进行选择、交叉、变异及复制等遗传操作步骤。在操作中去除适应度低的个体,产生比前代适应度高的种群。SVR是一种基于统计学习理论的机器学习算法,能够用来处理非线性回归问题等问题。它的主要思想是通过将向量投映到高维空

间,构建最大间隔的分类超平面,以此解决庞杂数据的回归问题。在 SVR 模型中,核函数的类型、惩罚参数和核函数参数在一定程度上影响着模型的泛化能力及预测精度。作者采用径向基函数作为核函数,采用 GA 搜索确定全局最佳的参数和。

使用 GA 算法优化 SVR 模型参数的过程如下:

(1) 设置初始参数,即遗传算法种群规模、进化代数、交叉概率和变异概率

(2) 初始化种群,随机产生一个给定规模的二进制代码种群

(3) 对种群的每个个体进行运算,采用 SVR 计算模型的预测值,并分别分析群体每个个体的适应度

(4) 以遗传适应度为导向,对种群进行复制、交叉和变异操作,并以此生产下一代

(5) 判别是否满足 GA 的停止条件,即训练误差和迭代次数是否满足条件,从而选择是折回步骤(3)还是继续向下执行

(6) 得到最优的 SVR 惩罚参数和核函数参数,建立 GA-SVR 参数

1.6.3 评价标准 采集到的高光谱图像经 ENVI 提取数据后,采用 S-G 平滑、SNV 和小波降噪进行预处理,再利用 SPA 算法提取出特征波长,分别建立 BP 神经网络和 GA-SVR 模型。通过模型的校正集相关系数(R_c)、预测集相关系数(R_p)、校正集均方根误差(RMSEC)、预测集均方根误差(RMSEP)和交叉验证均方根误差(RMSECV)来评价模型的性能。其中, R_c 、 R_p 的值越接近 1,RMSEP、RMSECV 的值越小,则模型的性能越好。

2 结果与分析

2.1 样本划分

在所有样本中随机选取 150 个苹果样本作为建模校正集,其余 48 个样本作为建模预测集。校正集及预测集样本可溶性固形物质量分数真实值的统计结果如表 1。

表 1 苹果可溶性固形物的统计结果

Table 1 Statistical results of soluble solid content in apples

| 样本集 | 可溶性固形物质量分数/% | | | |
|-----|--------------|-------|-------|------|
| | 最小值 | 最大值 | 均值 | 标准差 |
| 校正集 | 8.31 | 15.96 | 13.11 | 1.58 |
| 预测集 | 8.23 | 15.43 | 13.16 | 1.39 |

2.2 高光谱数据预处理

采集到的高光谱数据存在噪声信号,这些噪声信号会降低模型的预测性能。所以需要对采集的数据经行预处理,作者采用的预处理方法有 Savitzky-Golay 平滑(S-G)、标准正态变量变换(SNV)和小波降噪(Wavelet-Denoising),结果如表 2 所示。

表 2 不同预处理方法的预测结果

Table 2 Prediction results of different pretreatment methods

| 预处理算法 | 校正集 | | 预测集 | |
|-------------|-------|-------|-------|-------|
| | R_c | RMSEC | R_p | RMSEP |
| 原始光谱 | 0.827 | 0.693 | 0.776 | 0.635 |
| S-G 平滑 | 0.874 | 0.453 | 0.832 | 0.427 |
| 标准正态变换(SNV) | 0.819 | 0.521 | 0.794 | 0.645 |
| 小波降噪 | 0.865 | 0.589 | 0.781 | 0.683 |

由表 2 可以看到,采用不同预处理算法后,有的算法可以提升模型的性能,而有的算法却降低了模型的性能。采用 SNV 预处理后,相较于原始光谱而言,模型的校正集吻合度有了提升,但预测集的预测精度基本无改善。采用小波降噪预处理后,校正集和预测集改善均不明显。而采用 S-G 平滑处理后建立的模型相较于原始光谱而言具备较强的预测分析能力。

所有样本在圆形 150 像素 ROI 内的平均反射光谱如图 4 所示,通过 S-G 一阶微分处理后的反射光谱图 5 可以看到,720~1 010 nm 范围内的数据较为平滑,故选取该范围内的数据用于建立糖度分析的模型。

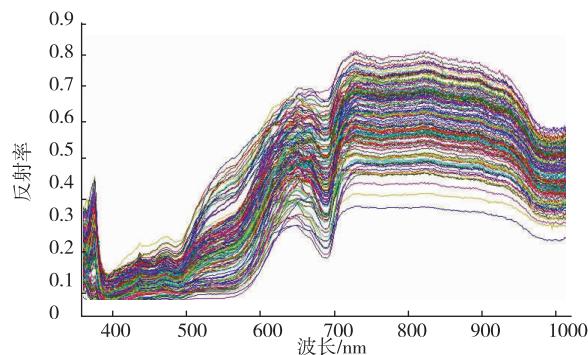


图 4 所有样本 ROI 区域原始光谱

Fig. 4 Original spectra of all samples in ROI region

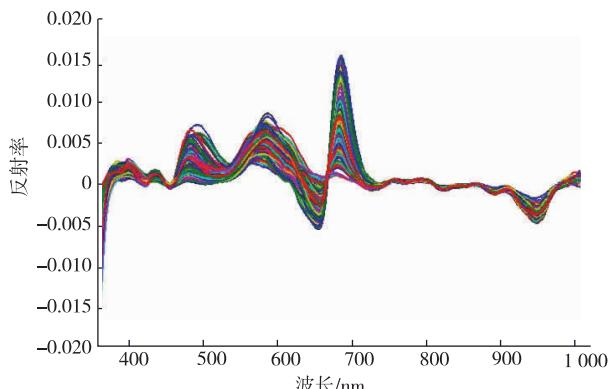


图 5 S-G 一阶微分处理光谱

Fig. 5 Spectra of S-G first derivative processing

2.3 特征波长变量的选取

通过高光谱仪采集到的苹果数据,含有数目巨大的变量,即便通过上述处理后,仍旧保留数百个变量。大量的变量数会降低模型的运行时间,不便于今后的平台移植,也不利于降低苹果无损检测的速度和精度。

通过比较各种降维算法后,选择使用 SPA 进行特征波长的选取,因为 SPA 选取出来的特征波长数目相对较少,且建立的模型的性能较好。先按照随机样本划分法,将样本分成 150 个校正集和 48 个预测集。利用 SPA 对 720~1 010 nm 范围内的光谱特征进行变量选择,根据样本内部的交叉验证均方根误差 RMSECV 值来确定最佳的变量数。如图 6(a) 所示,随着选取波长数目的增加,RMSECV 逐渐降低,波长数目为 12 后,RMSECV 降低不显著,且随着波长数的增加,模型的复杂度则变大,所以综合考虑,选择 12 个有效波长作为模型的输入变量如图 6 (b), 他们是 740.86、752.95、785.99、800.34、813.59、835.70、842.34、860.05、883.30、897.71、938.70 和 950.89 nm。

2.4 模型的建立与结果分析

2.4.1 BP 神经网络模型结果分析 BP 神经网络模型的输入层为经 SPA 筛选出的 12 个特征波长变量。隐含层采用 logsig 型传递函数,训练函数使用 trainlm 函数。输出层就是预测的苹果 SSC 含量,传递函数为 pureline,学习函数为 learngdm。另外,网络的初始参数设置如下:训练次数 epochs 为 1 000,学习率 lr 为 0.05,训练精度 goal 为 0.000 4,测试集 48 个样本的实验结果如图 7,BP 神经网络模型的预测相关系数=0.743 0,预测均方根误差 RMSEP=

0.797 7。

左图为预测值与实际值的对比图,右图为真实值与预测值的 95% 置信区间的散点图,中间的斜线为线性拟合线。从左图可以看出,BP 神经网络模型的预测结果可以预测出真实值的大致趋势,仅在部分点位上存在一定误差。从右图可以看出真实值和预测值的散点图分布较为离散化。

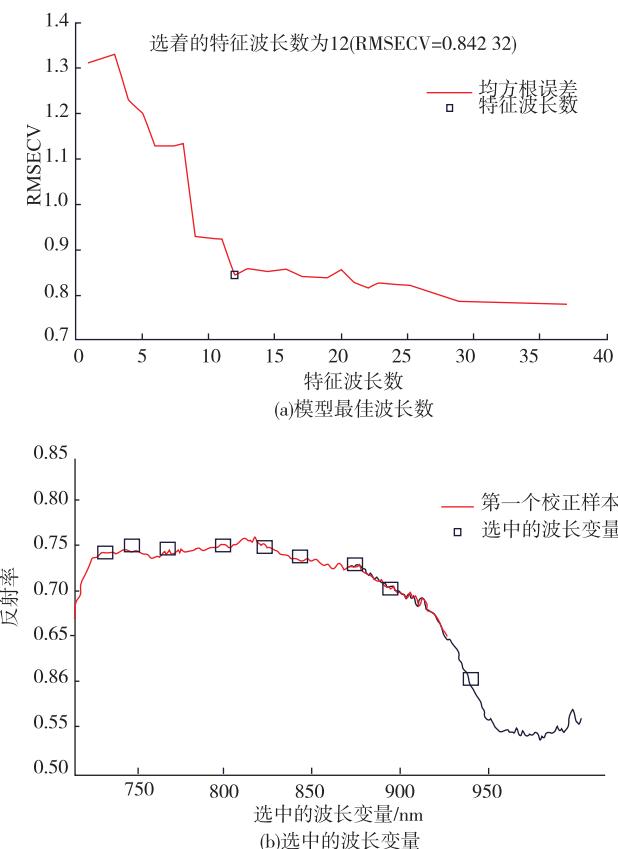
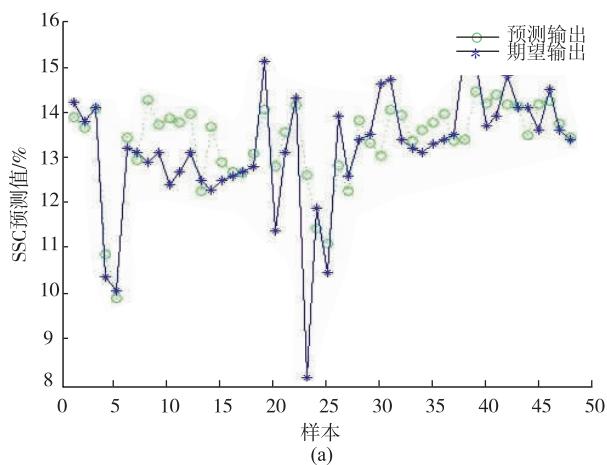


图 6 SPA 选取特征波长结果

Fig. 6 Characteristic wavelength results of SPA



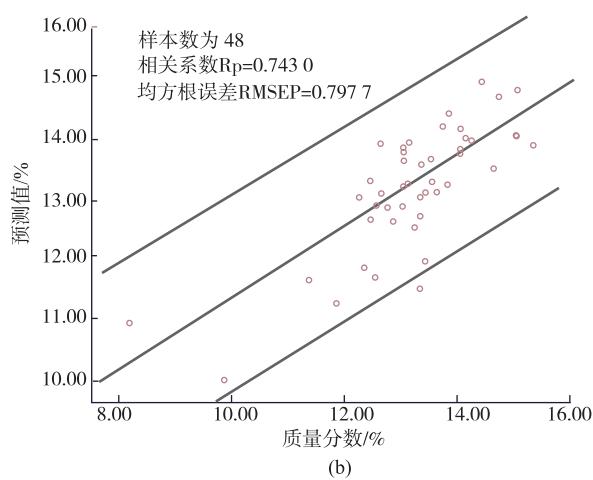


图 7 BP 模型结果

Fig. 7 Results of BP model

2.4.2 GA-SVR 模型结果分析 遗传算法的初始设置为, 种群规模为 20, 进化次数为 100, 交叉概率为 0.5, 变异概率为 0.01, 独立运行多次, 选取出现频率较高的结果作为 SVR 模型的和参数。如图 8 所示, 大约迭代 20 次时, 适应度值趋于稳定, 达到最佳参数值, 分别为 $c=26.587\ 9$ 和 $g=64.643$ 。

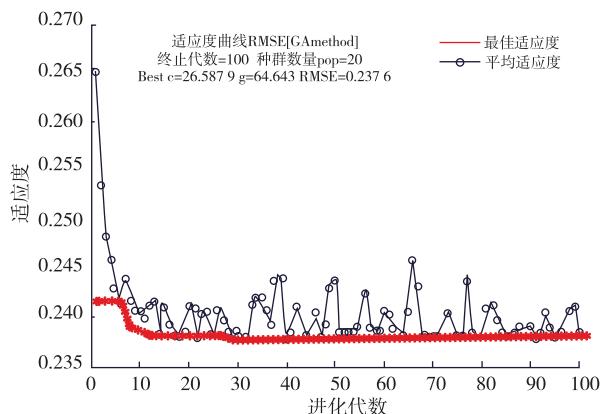
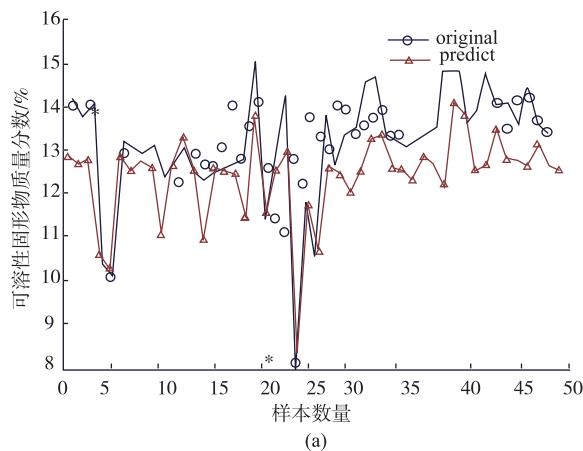


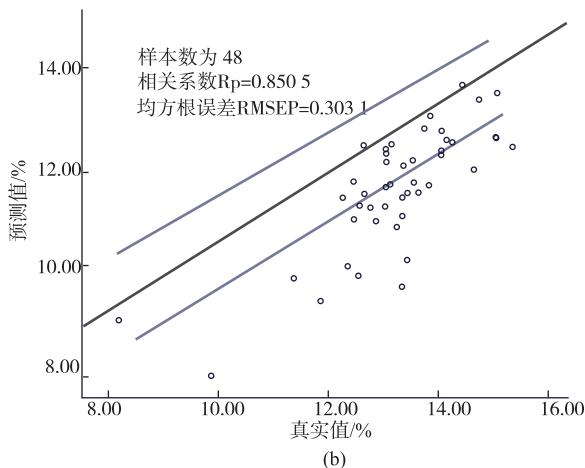
图 8 GA 优化 SVR 参数迭代过程

Fig. 8 SVR parameters optimized by GA

使用 GA 算法优选出来的参数值作为 SVR 模型的输入参数, 对 48 个预测集样本进行预测分析, 实验结果如图 9 所示。左图中横坐标为样本数量, 纵坐标为可溶性固形物的质量分数, 右图为使用 SPSS 做的预测集散点图, 横坐标为预测集可溶性固形物的真实值, 纵坐标为预测值, 其中斜线是线性拟合线。模型的相关系数 $R_c=0.880\ 6$, $R_p=0.850\ 5$, 均方根误差 RMSEC=0.260 7, RMSEP=0.303 1。



(a)



(b)

图 9 GA-SVR 模型结果

Fig. 9 Results of GA-SVR model

从左图可以看出预测结果和真实值在趋势上基本吻合, 在部分点位上存在些许误差。从右图可以看出, 真实值和模型预测值的散点分布集中在拟合线的两侧, 在 SPSS 中做回归分析得出的判定系数 $R^2=0.847$, 拟合优度高, 预测效果好。

3 结语

1) 在 ENVI 中, 通过圆形 150 像素 ROI 提取出的数据, 经由 S-G 平滑处理后, 筛选出 720~1 010 nm 范围内的数据作为模型的输入变量, 此范围的数据平滑性较好。

2) 在利用 SPA 算法提取输入数据的特征变量时, 在参考模型均方根误差的同时兼顾模型的复杂度, 选取的特征波长位: 740.86、752.95、785.99、800.34、813.59、835.70、842.34、860.05、883.30、897.71、938.70 和 950.89 nm 共计 12 个。降低了模型的复杂度, 提高了模型的预测性能。

3) 通过 GA 算法优化 SVR 模型的惩罚参数和核函数参数,遗传算法的初始设置为:种群规模为 20,进化次数为 100,交叉概率为 0.5,变异概率为 0.01。优化得到 $c=26.587\ 9, g=64.643$,此时 SVR 模型的性能最佳。

4)BP 神经网络模型的预测相关系数 $R_p=0.743$ 0,预测均方根误差 RMSEP=0.797 7;GA-SVR 模型

的预测相关系数 $R_p=0.850\ 5$, 预测均方根误差 RMSEP=0.3031。结果表明基于 SPA 算法优选出的波长建立的模型预测精度更高,模型复杂度得到明显降低。从 GA-SVR 模型的散点图得到调整后的判断系数为 0.847,拟合优度较高,不被解释的变量较少,拟合效果较好。

参考文献:

- [1] LI Jiangbo, RAO Xiuqin, YING Yibin. Advance on application of hyperspectral imaging to nondestructive detection of agricultural products external quality[J]. **Spectroscopy and Spectral Analysis**, 2011(8):2021-2026.(in Chinese)
- [2] DONG Jinlei, GUO Wenchuan. Nondestructive detection of soluble solid content of postharvest kiwifruits based on hyperspectral imaging technology[J]. **Food Science**, 2015, 16: 101-106.(in Chinese)
- [3] GUO Zhiming, HUANG Wenqian, PENG Yankun, et al. Impact of region of interest selection for hyperspectral imaging and modeling of sugar content in apple[J]. **Modern Food Science & Technology**, 2014(8):59-63.(in Chinese)
- [4] BERBEDO J G A, TIBOLA C S, FERNANDES J M C. Detection Fusarium head blight in wheat kernels using hyperspectral imaging[J]. **Biosystems Engineering**, 2015, 131:65-76.
- [5] SIVAKUMAR S S, QIAO J, GARIEPY Y, et al. Detecting maturity parameters of mango using hyperspectral imaging technique: American Society of Agricultural and Biological Engineers, ASAE Annual Meeting, 2006[C]. New York: ASAE, 2006.
- [6] LU R F. Nondestructive measurement of firmness and soluble solids content for apple fruit using hyperspectral scattering images [J]. **Sensing and Instrumentation for Food Quality and Safety**, 2007, 1(1):19-27.
- [7] LUO Xia, HONG Tiansheng, LUO Kuo, et al. Application of hyperspectrum technology in non-destructive measurement of soluble solid content in Pitaya[J]. **Laser & Optoelectronics Progress**, 2015(8):315-323.(in Chinese)
- [8] SUN Jun, JIN Xiaming, MAO Hanping, et al. A model for predicting nitrogen of lettuce leaves based on hyperspectral imaging[J]. **Chinese Journal of Analytical Chemistry**, 2014(5):672-677.(in Chinese)
- [9] ZHANG Chu, LIU Fei, KONG Wenwen, et al. Fast identification of watermelon seed variety using near infrared hyperspectral imaging technology[J]. **Transactions of the Chinese Society of Agricultural Engineering**, 2013, 20:270-277.(in Chinese)
- [10] 史峰,王小川,郁磊. MATLAB 神经网络 30 个案例分析[M].北京:北京航空航天大学出版社,2010.
- [11] 赵文曼.成熟苹果的图像识别及其位姿的获取研究[D].南京:南京农业大学,2012.
- [12] 刘文涛.基于高光谱成像技术的苹果品质无损检测研究[D].保定:河北农业大学,2015.
- [13] MA Yujuan, ZHAO Jianjun, DENG Hong, et al. Construction of comprehensive quality evaluation and grading system for fresh fuji apple in Luochuan, Shaanxi[J]. **Food Science**, 2015(1):69-74.(in Chinese)
- [14] HE Yong, LI Xiaoli, SHAO Yongni. Discrimination of varieties of apple using near infrared spectra based on principal component analysis and artificial neural network model[J]. **Spectroscopy and Spectral Analysis**, 2006(5):850-853.(in Chinese)
- [15] ZHANG X L, LIU F, HE Y, et al. Application of hyperspectral imaging and chemometric calibrations for variety discrimination of maize seeds[J]. **Sensors**, 2012, 12(12):17234-17246.
- [16] ZHU Q B, HUANG M, ZHAO X, et al. Wavelength selection of hyperspectral scattering image using new semi-supervised affinity propagation for prediction of firmness and soluble solid content in apples[J]. **Food Analytical Methods**, 2013, 6(1):334-342.
- [17] XUE Long, LI Jing, LIU Muhua, et al. Nondestructive detection of soluble solids content on navel orange with Vis/NIR based on genetic algorithm[J]. **Laser & Optoelectronics Progress**, 2010, 12:109-113.(in Chinese)
- [18] CHEN Bin, MENG Xianglong, WANG Hao. Application of successive projections algorithm in optimizing near infrared spectroscopic calibration model[J]. **Journal of Instrumental Analysis**, 2007(1):66-69.(in Chinese)
- [19] ZHAO Guilin, ZHU Qibing, HUANG Min. LLE-SVM classification of apple mealiness based on hyperspectral scattering image [J]. **Spectroscopy and Spectral Analysis**, 2010, 10:2739-2743.(in Chinese)

- [20] RAJKUMAR P, WANG N, EIMASRY G. Studies on banana fruit quality and maturity stages using hyperspectral imaging [J]. **Journal of Food Engineering**, 2012, 108(1): 194-200.
- [21] PENG Yankun, Zhang Leilei. Advancement and trend of hyperspectral imaging technique for nondestructive detection of agro-product quality and safety [J]. **Transactions of the Chinese Society for Agricultural Machinery**, 2013, 04: 137-145. (in Chinese)
- [22] SHI Bolin, ZHAO Lei, LIU Wen, et al. Outlier sample analysis on near infrared spectroscopy determination for apple interior quality [J]. **Transactions of the Chinese Society for Agricultural Machinery**, 2010(2): 132-137. (in Chinese)
- [23] HONG Ya, HONG Tiansheng, DAI Fen, et al. Successive projections algorithm for variable selection in nondestructive measurement of citrus total acidity [J]. **Transactions of the Chinese Society of Agricultural Engineering**, 2010, S2: 380-384. (in Chinese)
- [24] HUANG Wenqian, LI Jiangbo, CHEN Liping, et al. Effectively predicting soluble solids content in apple based on hyperspectral imaging [J]. **Spectroscopy and Spectral Analysis**, 2013, 10: 2843-2846. (in Chinese)
- [25] HOU Baolu, LI Baicheng, ZHOU Yao, et al. Soluble solids content and firmness prediction of pears based on visible-near infrared hyperspectral image [J]. **Laser Journal**, 2015, 10: 70-74. (in Chinese)
- [26] LI Yanxiao, HUANG Xiaowei, ZOU Xiaobo, et al. Optimization of NIR spectroscopy based on ant colony optimization and genetic algorithm for the anthocyanin content in scented tea [J]. **Journal of Food Science and Biotechnology**, 2015 (6): 575-583. (in Chinese)
- [27] LIU Xiaolu, XUE Lu, LU Xiaoxiang, et al. Non-destructive testing of soluble solids and total acidity in blueberry by near-infrared diffuse reflectance spectrometer [J]. **Journal of Food Science and Biotechnology**, 2016(7): 752-756. (in Chinese)

科 技 信 息

欧盟评估 3-植酸酶 FLF1000 作为猪饲料添加剂的安全性和有效性

2019 年 8 月 12 日,据欧盟食品安全局(EFSA)消息,应欧盟委员会要求,欧盟动物饲料添加剂和产品(FEEDAP)研究小组就 3-植酸酶(3 - phytase)FLF1000 作为猪育肥和小型猪种生长饲料添加剂的安全性和有效性发表科学意见。

据了解,该添加剂含有的 3-植酸酶是由转基因巴斯德毕赤酵母(*Komagataella phaffii*)生产。

[信息来源]食品伙伴网. 欧盟评估 3-植酸酶 FLF1000 作为猪饲料添加剂的安全性和有效性
[EB/OL]. (2019-8-13). <http://news.foodmate.net/2019/08/529776.html>

欧盟食品安全局评估一种地衣芽孢杆菌作为青贮饲料添加剂的安全性和有效性

2019 年 8 月 8 日,据欧盟食品安全局(EFSA)消息,应欧盟委员会要求,欧盟动物饲料添加剂和产品(FEEDAP)研究小组就地衣芽孢杆菌 DSM 32457 作为青贮饲料添加剂的安全性和有效性发表科学意见。

经过评估,FEEDAP 小组得出结论认为,此种添加剂对目标物种、饲喂动物人员和环境是安全的。由于缺乏数据,其有效性无法确定。

[信息来源] 食品伙伴网. 欧盟食品安全局评估一种地衣芽孢杆菌作为青贮饲料添加剂的安全性和有效性 [EB/OL]. (2019-8-9). <http://news.foodmate.net/2019/08/529477.html>