

# 基于近红外光谱和 SSA-ELM 的苹果糖度预测

Prediction of sugar content in apple based on near-infrared spectroscopy of SSA-ELM

乔正明<sup>1</sup> 詹 成<sup>2</sup>

QIAO Zheng-ming<sup>1</sup> ZHAN Cheng<sup>2</sup>

(1. 常州纺织服装职业技术学院, 江苏 常州 213164; 2. 苏州科技大学, 江苏 苏州 215000)

(1. Changzhou Vocational Institute of Textile and Garment, Changzhou, Jiangsu 213164, China;

2. Suzhou University of Science and Technology School of Business, Suzhou, Jiangsu 215000, China)

**摘要:**目的:剔除近红外光谱存在大量冗余信息以及提高苹果糖度预测模型的精度,建立快速无损检测苹果糖度的方法。方法:提出一种基于小波包变换的特征波长筛选和樽海鞘算法改进极限学习机的苹果糖度预测模型。针对苹果光谱数据具有维度高而复杂的特点,对光谱数据进行降维处理,分别对比全波段和偏最小二乘法、连续投影法和小波包变换等筛选特征波长的结果,确定苹果光谱特征波长筛选方法;针对极限学习机(extreme learning machine, ELM),模型性能受其初始权值和隐含层偏置选择的影响,运用樽海鞘群算法进行 ELM 模型的初始权值和隐含层偏置优化,提出一种基于樽海鞘算法改进极限学习机的苹果糖度预测模型。结果:与遗传算法(genetic algorithm, GA)改进 ELM(GA-ELM)、粒子群算法改进 ELM(PSO-ELM)和 ELM 相比,基于 SSA-ELM 的苹果糖度预测模型的预测精度最高。结论:通过智能算法优化 ELM 模型的参数可以有效提高 ELM 模型的苹果糖度预测精度。

**关键词:**近红外光谱; 苹果; 糖度; 极限学习机; 樽海鞘算法; 特征波长; 小波包变换

**Abstract: Objective:** In order to eliminate a large amount of redundant information in near infrared spectrum, and improve the accuracy of sugar degree in apple of the prediction model, a method for fast and non-destructive testing of the sugar content of apples was established. **Methods:** A prediction model of apple sugar content based on wavelet packet transform and bottle ascidian algorithm was proposed. Firstly, according to the characteristics of apple spectral data with high and complex dimensions, the spectral data was reduced, and the characteristic wavelength

screening method was determined by comparing the results of full band and partial least squares method, continuous projection method and wavelet packet transform. Secondly, in view of the influence of extreme learning machine (ELM), the model performance was affected by its initial weight and hidden layer bias selection. The bottle salp swarm algorithm was used to optimize the initial weight and hidden layer bias of ELM model, and an prediction model for sugar content in apple was proposed based on bottle ascidian algorithm improved extreme learning machine. **Results:** Compared with GA-ELM, PSO-ELM and ELM, the prediction model based on SSA-ELM had the highest accuracy. **Conclusion:** The parameters of ELM model optimized by intelligent algorithm can effectively improve the prediction accuracy of ELM, and provide a new method for the prediction of sugar content in apple.

**Keywords:** near infrared spectroscopy; apple; sugar content; extreme learning machine; salp swarm algorithm; characteristic wavelength; wavelet packet transform

随着近红外光谱技术与化学计量方法的快速发展,近红外光谱技术被广泛地应用于农产品品质分析领域<sup>[1]</sup>。苹果糖度是苹果质量的重要评价指标,运用预测相关系数(correlation of prediction, CP) $R_p$ 预测均方根误差(root mean square error of prediction, RMSEP) $\sigma_p$ 作为苹果糖度预测结果的性能评价指标,很多学者利用近红外光谱技术进行了苹果糖度预测研究。赵杰文等<sup>[2]</sup>提出运用傅里叶变换近红外光谱仪采集苹果光谱,建立了基于偏最小二乘(partial least squares, PLS)的苹果糖度预测模型,其中 $R_p$ 和 $\sigma_p$ 分别为 0.938 7 和 0.505 4。Zhang 等<sup>[3]</sup>运用 Nexus FT-IR 光谱仪为苹果光谱采集仪器,建立了基于 PLS 的苹果糖度预测模型, $R_p$ 和 $\sigma_p$ 分别为 0.906 和 0.272,该方法主要用于测试套袋评估的精度,且要求苹果颜色均匀,因此整体预测精度不高。刘燕德

基金项目:江苏省高校专项课题(编号:2020JDKT158)

作者简介:乔正明(1979—),男,常州纺织服装职业技术学院副教授,硕士。E-mail:qizm79@126.com

收稿日期:2021-06-23

等<sup>[4]</sup>运用 Antaris FT-IR 光谱仪采集苹果光谱,建立了基于遗传—偏最小二乘的苹果糖度预测模型,  $R_p$  和  $\sigma_p$  分别为 0.954 和 0.797, 该方法可以有效解决苹果颜色对于预测精度的影响,但是光谱冗余信息造成的误差过大。夏阿林等<sup>[5]</sup>建立了基于遗传—区间偏最小二乘的苹果糖度预测模型,运用 Nexus 670 FT-IR 光谱仪采集苹果光谱,  $R_p$  和  $\sigma_p$  分别为 0.932 和 0.384, 该方法虽然对比以往研究整体的预测精度有大幅提升,且算法的执行效率较高,但对光谱冗余信息的处理仍然是个难题,整体收敛性差,复杂度较高。

为了进一步改善苹果糖度预测模型的精度,研究拟提出一种基于小波包变换的特征波长筛选和樽海鞘算法(salp swarm algorithm, SSA)改进极限学习机(extreme learning machine, ELM)的苹果糖度预测模型,以期为苹果糖度预测提供新的方法。

## 1 试验仪器

试验仪器采用美国 Thermo Fisher 公司的型号为 Antaris II 的近红外检测仪。该仪器集成了透射、反射、漫透射以及漫反射等不同检测模块,采用了 Nicolet 专利的高光通量、高速动态准直电磁式干涉仪,可以实现不同状态下的样品高效的、精准的检测与分析。

## 2 研究方法

### 2.1 建模思路

基于近红外光谱的 SSA-ELM 的苹果糖度预测模型的建模思路如图 1 所示。

### 2.2 SSA 算法

**2.2.1 种群初始化** 在标准 SSA 算法中,樽海鞘算法的种群规模为  $N$ , 搜索空间维数为  $D$ , 樽海鞘的位置为  $\mathbf{X} = [X_{n1}, X_{n2}, \dots, X_{nD}]^T$ ,  $n = 1, 2, \dots, N$ , 食物位置为  $\mathbf{F} = [F_1, F_2, \dots, F_D]^T$ , 搜索空间上限为  $\mathbf{ub} = [ub_1, ub_2, \dots, ub_D]^T$ 、搜索空间下限为  $\mathbf{lb} = [lb_1, lb_2, \dots, lb_D]^T$ , 樽海鞘算法的种群随机初始化公式为<sup>[6]</sup>:

$$\mathbf{X}_{N \times D} = \mathbf{R}(N, D) \times (\mathbf{ub} - \mathbf{lb}) + \mathbf{lb}, \quad (1)$$

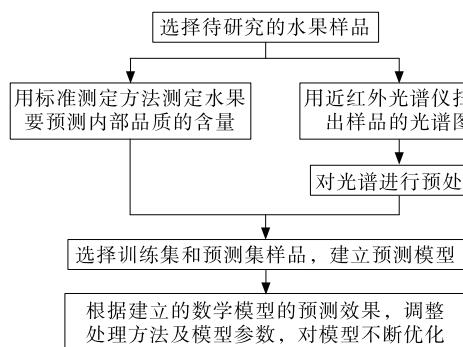


图 1 苹果糖度预测建模流程

Figure 1 Apple sugar content predictive modeling process

式中:

$\mathbf{X}_{N \times D}$ ——樽海鞘位置向量(向量维数为  $N \times D$ );

$\mathbf{R}(N, D)$ —— $N \times D$  维的随机向量。

在樽海鞘算法的种群中,领导者的状态为  $X_d^1; d=1, 2, 3, \dots, D$  为领导者的维数;追随者的状态  $X_d^m; m=2, 3, \dots, N$  为追随者的编号。

**2.2.2 更新领导者位置** 在标准 SSA 算法中,领导者引领整个樽海鞘群体的移动,用来搜索食物,这一操作的主要目的是使得领导者位置更新方式具有很强的随机性,领导者更新策略按式(2)计算:

$$X_d^1 = \begin{cases} F_d + c_1[(ub_d - lb_d)c_2 + lb_d], & c_3 \geqslant 0.5 \\ F_d - c_1[(ub_d - lb_d)c_2 + lb_d], & c_3 < 0.5 \end{cases}, \quad (2)$$

式中:

$X_d^1$ ——引领者位置;

$ub_d, lb_d$ ——引领者个体在  $d$  维上的搜索上限和搜索下限;

$c_1, c_2$ ——随机数,处于  $[0, 1]$ ;

$c_3$ ——搜索平衡因子(主要用于平衡全局搜索和局部搜索能力,增强引领者的随机性和多样性)。

收敛因子按式(3)计算:

$$c_1 = 2e^{(-4t/T)^2}, \quad (3)$$

式中:

$c_1$ ——收敛因子;

$t$ ——樽海鞘算法的当前迭代次数;

$T$ ——樽海鞘算法的最大迭代次数。

**2.2.3 更新追随者位置** 根据文献[7]可知,初始位置、速度和加速度直接关系到追随者的位置,跟随者根据牛顿运动方程更新位置:

$$X_d^m = 0.5at_a^2 + v_0 t_a + X_d^m (i \geqslant 2), \quad (4)$$

$$R = \frac{1}{2}(X_d^{m-1} - X_d^m), \quad (5)$$

$$X_d^{m'} = X_d^m + R = \frac{1}{2}(X_d^m + X_d^{m-1}), \quad (6)$$

式中:

$a$ ——加速度;

$v_0$ ——初始速度;

$t_a$ ——迭代步长;

$R$ ——运动距离;

$X_d^m, X_d^{m'}$ ——更新后和更新前第  $m$  个追随者第  $d$  维位置。

### 2.3 基于 SSA-ELM 的苹果糖度预测模型的建立

**2.3.1 极限学习机** 与传统的神经网络相比,ELM 模型结构如图 2 所示<sup>[8]</sup>。

对于  $N$  个训练样本  $(X_i, T_i)$ , ELM 模型的输入向量  $\mathbf{X}_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in \mathbf{R}^n$ , ELM 模型的目标向量  $\mathbf{T}_i = [t_{i1}, t_{i2}, \dots, t_{in}]^T \in \mathbf{R}^m$ ,  $\mathbf{X}$  为  $n \times Q$  的矩阵,  $\mathbf{T}$  为  $m \times Q$  的

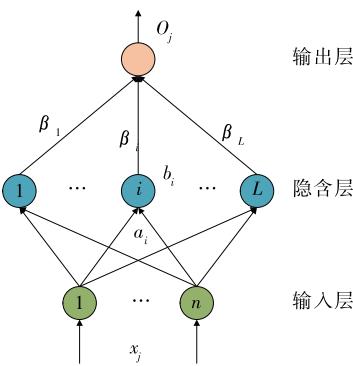


图 2 ELM 模型结构示意图

Figure 2 ELM model structure diagram

矩阵,  $Q$  为训练样本数量。因此,  $L$  个隐含层神经元的 ELM 模型输出为<sup>[9]</sup>:

$$\sum_{i=1}^L \beta_i g(W_i \cdot X_j + b_i) = o_j, j = 1, 2, \dots, N, \quad (7)$$

式中:

$W_i$ ——ELM 模型的输入权重,  $W_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ ;

$W_i \cdot X_j$ —— $W_i$  和  $X_j$  的内积;

$\beta_i$ ——ELM 模型的输出权重;

$g(x)$ ——激励函数;

$b_i$ ——ELM 模型的第  $i$  个隐含层神经元的偏置。

ELM 模型训练目的就是使式(8)的误差最小<sup>[10]</sup>。

$$\sum_{j=1}^N \|o_j - t_j\| = 0, j = 1, 2, \dots, N. \quad (8)$$

由式(7)和式(8)可知, 存存在一组参数  $\beta_i$ 、 $W_i$  和  $b_i$  使得式(9)成立。

$$\sum_{i=1}^L \beta_i g(W_i \cdot X_j + b_i) = t_j, j = 1, 2, \dots, N. \quad (9)$$

式(9)的矩阵形式为<sup>[11]</sup>:

$$H\beta = T, \quad (10)$$

式中:

$H$ ——ELM 模型的隐含层神经元的输出;

$\beta$ ——ELM 模型的输出权重矩阵。

通过求解式(10), 可以得到 ELM 模型的输出层权值

矩阵  $\beta$  的估计值  $\hat{\beta}$ :

$$\min_{\beta} \|T - \beta^T H\|_2^2, \quad (11)$$

$$\hat{\beta} = (HH^T)^{-1}HH^T. \quad (12)$$

2.3.2 适应度函数 ELM 模型的性能直接取决于初始输入权值  $W_i$  和隐含层偏置  $b_i$  的选择。为提高 ELM 模型的性能, 运用 SSA 算法优化选择 ELM 模型的初始输入权值  $W_i$  和隐含层偏置  $b_i$ , 将均方差作为适应度函数, 即当均方差误差最小时, 所对应的初始输入权值  $W_i$  和隐含层偏置  $b_i$  作为 ELM 模型的最优参数:

$$\begin{cases} \min f(W_i, b_i) = \sqrt{\frac{1}{n} \sum_{i=1}^n [x(i) - x_p(i)]^2}, \\ s.t. W_i \in [W_{i\min}, W_{i\max}] \\ b_i \in [b_{i\min}, b_{i\max}] \end{cases}, \quad (13)$$

式中:

$n$ ——训练样本数量;

$x(i)$  和  $x_p(i)$ ——第  $i$  个样本的实际值和预测值;

$[W_{i\min}, W_{i\max}]$  与  $[b_{i\min}, b_{i\max}]$ ——ELM 模型第  $i$  个初始输出权值  $W$  和第  $i$  个隐含层偏置  $b$  的上下限值, 且  $W \in [-1, 1]$  和  $b \in [-1, 1]$ 。

### 2.3.3 算法步骤

Step1: 读取苹果光谱数据和含量数据, 预处理并进行特征波长筛选, 将数据划分为训练集和测试集, 并进行归一化处理;

Step2: 种群初始化。设定最大迭代次数  $T$ 、种群规模  $N$ , 根据式(1)随机初始化樽海鞘种群;

Step3: 计算适应度。针对训练集, 将训练集代入 ELM 模型, 按适应度函数式(12)计算每个樽海鞘个体的适应度;

Step4: 选定领导者、追随者和食物。计算适应度大小, 将适应度最优的樽海鞘位置设定为当前食物位置; 剩下的  $N-1$  个樽海鞘, 将排在前一半的樽海鞘作为领导者, 剩下的作为追随者;

Step5: 更新领导者位置和追随者位置;

Step6: 计算更新之后的樽海鞘个体适应度  $f_s$ 。比较  $f_s$  与当前食物的适应度  $f_{food}$ , 如果  $f_s > f_{food}$ , 则将  $f_s$  所对应的樽海鞘位置作为新的食物位置;

Step7: 重复 Step3~Step6, 如果  $t > T$ , 输出最优食物位置, 最优食物位置所对应的结果即为 ELM 模型的最优初始输入权值和隐含层偏置。将最优初始权值和隐含层偏置代入 ELM 模型进行苹果糖度预测。基于红外光谱的 SSA-ELM 的苹果糖度预测流程如图 3 所示。

## 3 结果与分析

### 3.1 数据预处理

光谱的预处理方法有: 一阶导数算法(FD)预处理、二阶导数算法(SD)预处理、标准正态变量变换算法预处理(SNV)和多元散射校正(MSC)预处理<sup>[12~13]</sup>, 不同预处理结果如表 1 所示。苹果原始光谱图像如图 4 所示。由表 1 可知, 多元散射校正(MSC)处理结果最好。其预处理结果如图 5 所示。

选择均方根误差( $E_{RMSE}$ )和相关系数  $C^2$  评价苹果糖度预测模型的性能<sup>[14~15]</sup>:

$$E_{RMSE} = \sqrt{\frac{1}{n} \sum_{k=1}^n (x_k - p_k)^2}, \quad (14)$$

$$C^2 = \frac{\sum_{k=1}^n x_k p_k}{\sqrt{\sum_{k=1}^n x_k^2} \sqrt{\sum_{k=1}^n p_k^2}}, \quad (15)$$

式中:

$x_k$ ——第  $k$  个样本的苹果糖度实际值;

$p_k$ ——第  $k$  个样本的苹果糖度预测值;

$n$ ——样本数量;

$E_{RMSE}$ ——均方根误差;

$C^2$ ——相关系数。

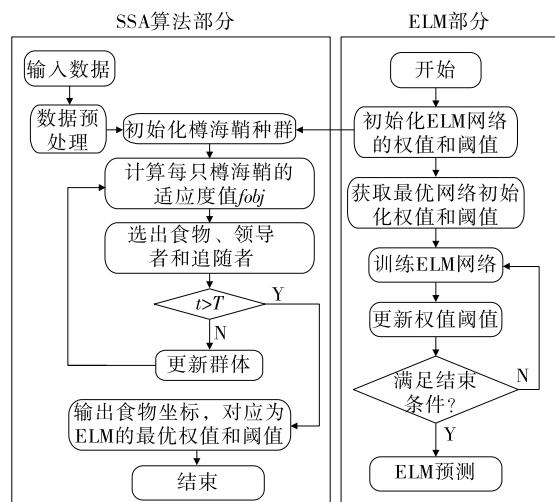


图 3 基于红外光谱的 SSA-ELM 的苹果糖度预测流程

Figure 3 SSA-ELM apple sugar content prediction process based on infrared spectroscopy

表 1 不同预处理建模效果对比

Table 1 Comparison of different preprocessing modeling effects

建模变量	相关系数	均方根误差
原始数据	0.547 8	0.931 8
FD	0.871 6	0.405 2
SD	0.856 1	0.437 2
SNV	0.921 5	0.421 3
MSC	0.933 9	0.410 7

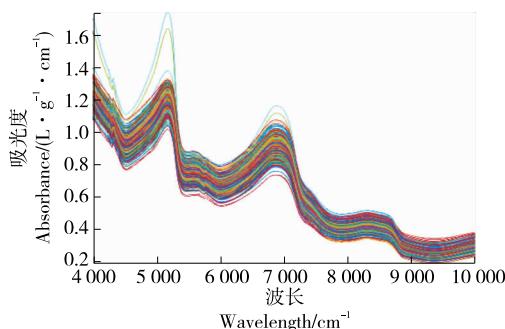


图 4 苹果原始光谱

Figure 4 Apple's original spectrum

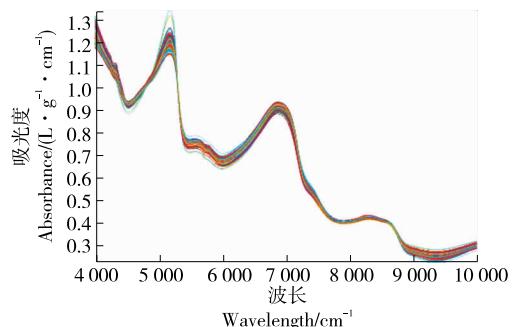


图 5 MSC 预处理结果

Figure 5 MSC preprocessing result graph

### 3.2 特征波长筛选

由于苹果光谱数据具有维度高而复杂的特点,苹果糖度预测模型建立之前先对光谱数据进行降维处理,文中分别对比全波段和偏最小二乘法、连续投影法和小波包变换等筛选特征波长的结果,最终确定苹果光谱特征波长筛选方法。特征波长筛选后建模效果对比如表 2 和图 6 所示。

表 2 特征波长筛选后建模效果对比

Table 2 Comparison of modeling effects after feature wavelength selecting

建模变量	相关系数	均方根误差
全波段数据	0.547 8	0.931 8
偏最小二乘法	0.930 6	0.421 8
小波包变换	0.924 2	0.672 6
连续投影法	0.810 5	0.672 6

由表 2 和图 6 可知,基于小波包变换特征波长筛选之后的建模效果最好,相关系数和均方根误差分别为 0.924 2 和 0.672 6,优于全波段和偏最小二乘法、连续投影法的建模效果。因此选择小波包变换特征波长筛选法进行苹果光谱特征波长筛选。

### 3.3 模型效果比较

为验证 SSA-ELM 进行苹果糖度预测的有效性和可靠性,将 SSA-ELM 与 GA-ELM、PSO-ELM 和 ELM 进行比较,参数设定:① SSA 算法:樽海鞘种群规模  $N=10$ ,最大迭代次数  $T=100$ ;② 遗传算法<sup>[16]</sup> (genetic algorithm,GA) 算法:最大迭代次数  $T=100$ ,种群规模  $N=10$ ,变异概率  $p_m=0.1$ ,交叉概率  $p_c=0.7$ ;③ 粒子群算法<sup>[17]</sup> (particle swarm optimization algorithm,PSO):学习因子  $c_1=c_2=2$ ,最大迭代次数  $T=100$ ,种群规模  $N=10$ ,惯性权重  $w=0.8$ ;④ ELM 模型<sup>[18-19]</sup>:输入层神经元数量  $N_1=2740$ 、隐含层神经元数量  $N_2=10$  以及输出层神经元数量为  $N_3=1$ ,一共采集到光谱数据 34 组,将前 25 组作为训练集,剩下 9 组作为测试集,苹果糖度预测结果如图 7 和表 3 所示。

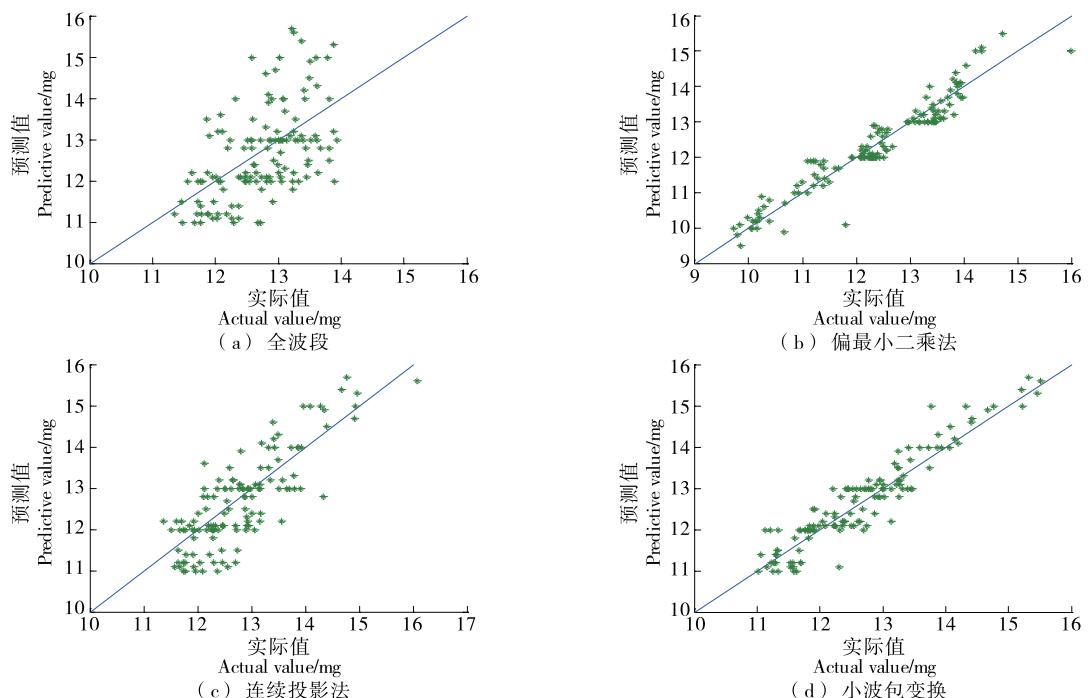


图 6 特征波长筛选后建模效果

Figure 6 Modeling effect diagram after characteristic wavelength selecting

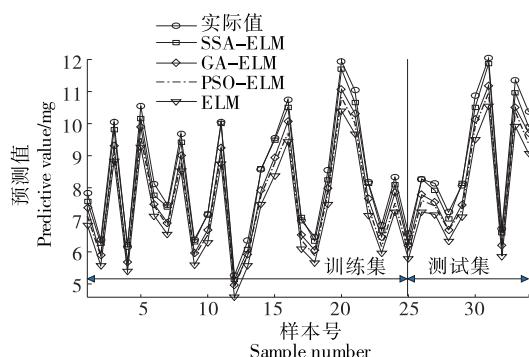


图 7 苹果糖度预测对比

Figure 7 Apple sugar content prediction comparison chart

表 3 苹果糖度预测结果对比

Table 3 Comparison of apple sugar content prediction results

方法	训练集		测试集	
	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>
SSA-ELM	0.008 7	0.995 4	0.037 4	0.989 2
GA-ELM	0.016 3	0.978 5	0.039 3	0.971 2
PSO-ELM	0.016 9	0.976 4	0.045 8	0.964 6
ELM	0.017 7	0.965 1	0.047 6	0.945 7

对比图 7 与表 3 可知:① 在训练集和测试集上,SSA-ELM 模型的苹果糖度预测结果优于 GA-ELM、PSO-

ELM 和 ELM 模型的苹果糖度预测结果,SSA-ELM 模型的苹果糖度预测评价指标 RMSE 最小且相关系数 R<sup>2</sup> 最大,由此证明 SSA-ELM 模型的苹果糖度预测值和苹果糖度实际值关联程度最高,苹果糖度预测效果最好;② 通过 SSA、GA 和 PSO 等算法对 ELM 模型的初始输入权值和隐含层偏置的优化选择,SSA-ELM、GA-ELM 和 PSO-ELM 模型的苹果糖度预测精度优于 ELM 模型,说明通过智能算法优化 ELM 模型的参数可以有效提高 ELM 模型的苹果糖度预测精度。

#### 4 结论

为提高苹果糖度预测的精度,提出了一种基于红外光谱的樽海鞘算法改进极限学习机的苹果糖度预测算法。针对极限学习机模型预测性能受其初始权值和阈值的影响,运用樽海鞘算法对极限学习机模型的初始权值和阈值进行优化选择。将苹果的红外光谱吸光度作为极限学习机的输入,苹果糖度作为极限学习机的输出,建立红外光谱的苹果糖度预测模型,其对苹果糖度预测的精度高于遗传算法改进极限学习机、粒子群算法改进极限学习机和极限学习机。通过智能算法优化极限学习机模型的参数可以有效提高极限学习机模型的苹果糖度预测精度。

#### 参考文献

- [1] 李速专,童何馨,袁雷明,等.间隔连续投影算法应用于近红外光谱苹果糖度模型的优化[J].食品安全质量检测学报,2019

- (14): 4 608-4 612.
- LI Su-zhuan, TONG He-xin, YUAN Lei-ming, et al. Optimization of near infrared spectroscopy model for sugar content in apple by intervals successive projection algorithm[J]. Journal of Food Safety & Quality, 2019(14): 4 608-4 612.
- [2] 赵杰文, 张海东, 刘木华. 利用近红外漫反射光谱技术进行苹果糖度无损检测的研究 [J]. 农业工程学报, 2005, 21(3): 162-165.
- ZHAO Jie-wen, ZHANG Hai-dong, LIU Mu-hua. Non-destructive determination of sugar contents of apples using near infrared diffuse reflectance[J]. Transactions of the Chinese Society of Agricultural Engineering, 2005, 21(3): 162-165.
- [3] ZHANG Y, NOCK J F, SHOFFE Y A, et al. Non-destructive prediction of soluble solids and dry matter contents in eight apple cultivars using near-infrared spectroscopy[J]. Postharvest Biology and Technology, 2019, 15(1): 111-118.
- [4] 刘燕德, 周延睿. 基于 GA-LSSVM 的苹果糖度近红外光谱检测 [J]. 西北农林科技大学学报(自然科学版), 2013, 41(7): 229-234.
- LIU Yan-de, ZHOU Yan-rui. GA-LSSVM based near infrared spectroscopy detection of apple sugar content[J]. Journal of Northwest A&F University (Natural Science Edition), 2013, 41(7): 229-234.
- [5] 夏阿林, 周新奇, 叶华俊, 等. 近红外光谱相似性评估结合局部回归方法无损检测苹果糖度 [J]. 分析测试学报, 2010, 29(12): 1 173-1 177.
- XIA A-lin, ZHOU Xin-qi, YE Hua-jun, et al. Non-destructive determination of sugar content in apple by near infrared spectroscopy with similarity evaluation combined with local regression method [J]. Journal of Instrumental Analysis, 2010, 29(12): 1 173-1 177.
- [6] 郭志明, 赵春江, 黄文倩, 等. 苹果糖度高光谱图像可视化预测的光强度校正方法 [J]. 农业机械学报, 2015, 46(7): 227-232.
- GUO Zhi-ming, ZHAO Chun-jiang, HUANG Wen-qian, et al. Intensity correction of visualized prediction for sugar content in apple using hyperspectral imaging[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(7): 227-232.
- [7] SAYED G I, DARWISH A, HASSANIEN A E. A new chaotic multi-verse optimization algorithm for solving engineering optimization problems[J]. Journal of Experimental & Theoretical Artificial Intelligence, 2018, 30(2): 293-317.
- [8] BABAEI F, LASHKARI Z B, SAFARI A, et al. Salp swarm algorithm-based fractional-order PID controller for LFC systems in the presence of delayed EV aggregators[J]. IET Electrical Systems in Transportation, 2020, 10(3): 259-267.
- [9] ZHAO J, VITTAYAPADUNG S, CHEN Q, et al. Nondestructive measurement of sugar content of apple using hyperspectral imaging technique[J]. Maejo International Journal of Science and Technology, 2009, 3(1): 130-142.
- [10] FANG L J, GUO W C. Nondestructive measurement of sugar content and firmness in korlafragrant pears by using their dielectric spectra[J]. Modern Food Science and Technology, 2016, 32(5): 295-301.
- [11] ALCIN O F, SENGUR A, GHOFRANI S, et al. GA-SELM: Greedy algorithms for sparse extreme learning machine[J]. Measurement, 2014, 55(3): 126-132.
- [12] FENG G, HUANG G B, LIN Q, et al. Error minimized extreme learning machine with growth of hidden nodes and incremental learning[J]. IEEE Transactions on Neural Networks, 2009, 20(8): 1 352-1 359.
- [13] 董学锋, 戴连奎, 黄承伟. 结合 PLS-DA 与 SVM 的近红外光谱软测量方法 [J]. 浙江大学学报(工学版), 2012, 46(5): 824-829.
- DONG Xue-feng, DAI Lian-kui, HUANG Cheng-wei. Near-infrared spectroscopy soft-sensing method by combining partial least squares discriminant analysis and support vector machine[J]. Journal of Zhejiang University (Engineering Science), 2012, 46(5): 824-829.
- [14] 贺凯迅, 曹鹏飞. 基于智能优化算法的软测量模型建模样本优选及应用 [J]. 化工进展, 2018, 37(7): 67-74.
- HE Kai-xun, CAO Peng-fei. Training sample selection method based on intelligent optimization algorithms for soft sensor and its application[J]. Chemical Industry and Engineering Progress, 2018, 37(7): 67-74.
- [15] 张海红. 水果中茶多酚的近红外光谱软测量方法研究 [D]. 西北农林科技大学, 2013.
- [16] ZHANG H. Determination of tea polyphenols content in puertea using near-infrared spectroscopy combined with extreme learning machine and GA-PLS algorithm[J]. Laser & Optoelectronics Progress, 2013, 50(4): 180-186.
- [17] ZHAO J, OUYANG Q, CHEN Q, et al. Simultaneous determination of amino acid nitrogen and total acid in soy sauce using near infrared spectroscopy combined with characteristic variables selection[J]. Food Science & Technology International, 2013, 19(4): 305-314.
- [18] YANG I C, TSAI C Y, HSIEH K W, et al. Integration of SIMCA and near-infrared spectroscopy for rapid and precise identification of herbal medicines[J]. Journal of Food and Drug Analysis, 2013, 21(3): 268-278.
- [19] 单亚锋, 高振彪. 基于双自适应 AIS-PSO 的瓦斯浓度软测量模型 [J]. 计算机仿真, 2020, 37(1): 338-342.
- SHAN Ya-feng, GAO Zhen-biao. Study on double adaptive AIS-PSO based model for gas concentration soft-sensing[J]. Computer Simulation, 2020, 37(1): 338-342.