

鲸鱼算法改进极限学习机的葡萄酒品质评价研究

Study on wine quality evaluation based on extreme learning machine improved by whale optimization algorithm

窦力¹ 郑巍² 李柏秋³ 李斐⁴

DOU Li¹ ZHENG Wei² LI Baiqiu³ LI Fei⁴

(1. 太原旅游职业学院, 山西 太原 030032; 2. 沈阳药科大学, 辽宁 沈阳 110015;

3. 山西大同大学, 山西 大同 037009; 4. 中北大学, 山西 太原 030051)

(1. *Taiyuan Tourism College, Taiyuan, Shanxi 030032, China*; 2. *Shenyang Pharmaceutical University, Shenyang, Liaoning 110015, China*; 3. *Shanxi Datong University, Datong, Shanxi 037009, China*; 4. *North University of China, Taiyuan, Shanxi 030051, China*)

摘要: [目的] 解决近红外光谱中冗余信息过多的问题, 提升葡萄酒品质评价模型的准确性, 并构建一种快速无损的葡萄酒品质评价方法。 [方法] 运用竞争性自适应重加权采样法进行特征波长筛选, 提出了鲸鱼算法改进极限学习机的葡萄酒品质评价模型。通过自适应重加权采样法等多种特征波长筛选方法, 确定了最适用于葡萄酒光谱特征波长筛选的方法; 针对 ELM 的初值权值与隐含层偏置选取问题, 利用鲸鱼优化方法对初值权值与隐含层偏置进行优化, 从而构建了一种基于鲸鱼优化算法改进的极限学习机葡萄酒品质评价模型。 [结果] 与 GA-ELM、PSO-ELM 和传统的 ELM 模型相比, WOA-ELM 的准确率最高, 达到了 0.944 5, GA-ELM 的准确率为 0.929 0, PSO-ELM 的准确率为 0.906 1, 传统的 ELM 方法准确率为 0.817 7。 [结论] 通过智能算法优化 ELM 模型的参数, 可以有效提高葡萄酒品质评价的准确性。

关键词: 近红外光谱; 极限学习机; 鲸鱼优化算法; 特征波长; 竞争性自适应重加权采样法

Abstract: [Objective] In order to solve the issue of excessive redundant information in near-infrared spectroscopy, enhance the accuracy of wine quality evaluation models, a rapid and non-destructive method was established for wine quality evaluation. [Methods] A wine quality evaluation model was proposed based on competitive adaptive reweighting sampling method for feature wavelength screening and extreme learning machine improved by

基金项目: 山西省教育科学“十三五”规划课题(编号: GH-22015402)

作者简介: 窦力(1984—), 男, 太原旅游职业学院讲师, 硕士。

E-mail: lwpo235@21cn.com

收稿日期: 2024-02-12 改回日期: 2024-05-28

whale optimization algorithm. Various feature wavelength screening methods such as competitive adaptive reweighting sampling was used, and the most suitable method for wine spectral feature wavelength screening was determined. In response to the problem of initial value and hidden layer bias in ELM, the whale optimization method was used to optimize the initial value and hidden layer bias of ELM, and an wine quality evaluation model based on extreme learning machine improved by whale optimization algorithm was constructed. [Results] Compared with GA-ELM, PSO-ELM, and the traditional ELM model, the accuracy of WOA-ELM was the highest, reaching 0.944 5, which was better than GA-ELM (0.929 0), PSO-ELM (0.906 1) and traditional ELM (0.817 7). [Conclusion] The parameters of the ELM model optimized by intelligent algorithms can effectively improve the accuracy of wine quality evaluation.

Keywords: near infrared spectroscopy; extreme learning machine; whale optimization algorithm; characteristic wavelength; competitive adaptive reweighted sampling

随着人们生活水平的提高, 葡萄酒作为一种高品质的饮品, 逐渐受到广大消费者的青睐。葡萄酒的质量评价是确保产品质量、满足消费者需求以及推动葡萄酒产业健康发展的重要环节^[1-2]。传统的葡萄酒质量评价方法主要依赖于感官评价和化学分析, 但这些方法存在主观性强、操作繁琐、耗时耗力等缺点^[3-4]。因此, 开发一种快速、准确、客观的葡萄酒质量评价方法具有重要意义。

由于其非破坏性和快速性, 近红外光谱法已被广泛应用于食品分析中^[5]。它能够通过测量样品在近红外区域的吸收、反射或透射光谱, 获取样品中化学成分的含量

信息。葡萄酒中含有丰富的有机物和无机物,其近红外光谱包含了丰富的化学信息,可以反映葡萄酒的组成和质量。

近年来,机器学习技术的快速发展为数据分析与预测提供了新的思路和方法^[6]。机器学习模型能够从大量数据中学习规律,并对未知数据进行预测。在葡萄酒质量评价中,机器学习模型可以通过学习葡萄酒光谱数据与质量指标之间的关系,建立预测模型,实现对葡萄酒质量的快速、准确评价。

鲸鱼优化算法(WOA)^[7]是一种模拟鲸类捕猎与捕猎的群体智能生物算法,具有计算简单、寻优精度高的优点,被广泛应用于参数优化、工程设计、模式识别、故障诊断和图像处理等领域,目前还未发现其被应用于葡萄酒品质评价。

为了提高评价模型的精度,研究拟提出一种基于竞争性自适应重加权采样法(CARS)^[8]和鲸鱼优化算法改进极限学习机(ELM)的评价模型。

1 研究方法

1.1 建模思路

基于近红外光谱的 WOA-ELM 的基本思路为:① 葡萄酒样本的选取;② 采集葡萄酒样品的近红外光谱(NIR);③ 光谱预处理(MSC)、特征波长的筛选等;④ 以 WOA-ELM 为基础,构建评估模型;⑤ 评估模型的检验。

1.2 WOA 算法

在标准的 WOA 算法中,假设鲸的数量是 N ,寻找的空间为 d ,则第 i 头鲸的位置为 $X_i = (x_i^1, x_i^2, \dots, x_i^d)$, $i = 1, 2, \dots, N$ 。算法由两个步骤组成:环绕式捕食和发泡网攻击。

1.2.1 环绕式捕食 假设目前的最优鲸定位为被捕食点,然后将整个鲸群都包围起来,其位置更新策略如下:

$$X(t+1) = X^*(t) - A \cdot |C \cdot X^*(t) + X(t)|, \quad (1)$$

式中:

A, C ——随机系数, $[0, 1]$;

t ——当前迭代次数;

$X(t)$ ——第 t 次迭代次数的鲸鱼的位置向量;

$X^*(t)$ ——第 t 次迭代次数的鲸鱼的最佳位置向量。

A 和 C 数学公式如下:

$$A = 2a \cdot r_1 - a, \quad (2)$$

$$C = 2r_2, \quad (3)$$

$$a = 2 - 2t/T_{\max}, \quad (4)$$

式中:

r_1, r_2 ——随机向量, $[0, 1]$;

T_{\max} ——最大迭代次数。

1.2.2 发泡网攻击 包含缩小的环绕机构和螺旋形的定位。

(1) 收缩包围机制:当 $A = [-1, 1]$ 时,鲸鱼的搜寻地点为食物的所在地,这时鲸鱼们正在接近食物。相反,鲸会避开猎物。

(2) 螺旋式更新机制:先估算猎物之间的距离,然后开始盘旋,更新公式为:

$$X(t+1) = D' \cdot e^{bl} \cdot \cos(2\pi l) + X^*(t), \quad (5)$$

式中:

D' ——当前最佳位置与猎物之间距离, $D' = |X^*(t) - X(t)|$;

l ——随机数, $[-1, 1]$;

b ——对数螺旋形状参数。

捕食时,座头鲸以 50% 的几率通过螺旋游动和收缩环绕运动来更新自己的位置,更新公式为^[9]:

$$X(t+1) = \begin{cases} X(t) - A \cdot D & (p < 0.5) \\ D' \cdot e^{bl} \cdot \cos(2\pi l) + X^*(t) & (p \geq 0.5) \end{cases} \quad (6)$$

(3) 捕食:当 $A > 1$ 或 $A < -1$ 时,远离猎物,寻找新的猎物,更新公式为:

$$X(t+1) = X_{\text{rand}} - A \cdot |C \cdot X_{\text{rand}}(t) - X|, \quad (7)$$

式中:

X_{rand} ——随机鲸群个体。

1.3 基于 WOA-ELM 的评价模型

1.3.1 极限学习机 ELM 模型如图 1 所示^[10]。

在 N 个训练样本 (X_i, T_i) 中,一个输入矢量 $X_i = [x_{i1}, x_{i2}, \dots, x_{im}]$, $T \in R_m$, X 表示 $n \times Q$ 的一个矩阵,而一个目标矢量 $T_i = [t_{i1}, t_{i2}, \dots, t_{in}]$, $T \in R_m$, T 表示 $m \times Q$ 的一个矩阵, Q 代表训练样本的数量。由 L 个隐含层神经元组成的 ELM 模型如下:

$$\sum_{i=1}^L \beta_i g(W_i \cdot X_j + b_i) = o_j, \quad j = 1, 2, \dots, N, \quad (8)$$

式中:




图 1 ELM 模型结构

Figure 1 ELM model structure

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

β_i ——ELM 模型的输出权重;

$W_i \cdot X_j$ —— W_i 和 X_j 的内积。

$g(x)$ ——激励函数;

b_i ——第 i 个隐含层神经元的偏置。

ELM 模型是以使得式(9)的误差最小为目的进行训练^[11]。

$$\sum_{j=1}^N \|o_j - t_j\| = 0, j = 1, 2, \dots, N. \quad (9)$$

将式(8)和式(9)结合,使参数 β_i, W_i, b_i 的集合符合式(10)。

$$\sum_{i=1}^L \beta_i g(W_i \cdot X_j + b_i) = t_j, j = 1, 2, \dots, N. \quad (10)$$

式(10)的矩阵形式为^[12]:

$$H\beta = T, \quad (11)$$

式中:

H ——隐含层神经元的输出;

β ——输出权重矩阵。

运用最小二乘法求解式(12),得到 ELM 模型的输出权重矩阵的估计值如式(13)。

$$\min_{\beta} \|T - \beta^T H\|_2^2, \quad (12)$$

$$\hat{\beta} = (HH^T)^{-1}HH^T. \quad (13)$$

1.3.2 适应度函数 对 ELM 模型进行改进,包括初始权重和隐含层偏置的选择。为了达到这个目的,引入 WOA 算法,对 ELM 模型参数进行优化选取。通过将均方差作为适应度函数,能够在算法运行过程中寻找使得均方差误差达到最小的权值和偏置组合。一旦找到这样的组合,它们将被视为 ELM 模型的最优参数,从而有效提高模型的预测或分类性能。

$$\min f(W_i, b_i) = \sqrt{\frac{1}{n} \sum_{i=1}^n [x(i) - x_p(i)]^2}$$

$$\text{s.t. } W_i \in [W_{i\min}, W_{i\max}]$$

$$b_i \in [b_{i\min}, b_{i\max}], \quad (14)$$

式中:

n ——训练样本总数;

$x(i)$ ——第 i 个样本的实际值;

$x_p(i)$ ——第 i 个样本的预测值;

$[W_{i\min}, W_{i\max}], [b_{i\min}, b_{i\max}]$ ——输入权重 W 与隐含层偏置 b 的优化区间。

1.3.3 算法步骤 为了达到对葡萄酒品质的准确评估,利用红外光谱分析技术进行葡萄酒品质的 WOA-ELM 评价方法,其算法流程如图 2 所示。

Step1:初始化 WOA 参数。设定当前重复次数 t ,最大重复次数 T_{\max} 和对数螺旋线形常数 b 的确定方法。对鲸鱼群体的位置进行随机初始化, $X_i (i = 1, 2, \dots, n)$ 。




图 2 葡萄酒品质评价流程图
Figure 2 Flow chart of wine quality evaluation

Step2:数据划分为训练集和测试集。针对训练集,按照式(14),计算每一群鲸鱼的适合度,并找到目前种群中性能最好的那一群,将其保存下来。

Step3:如果 $t \leq M$,则更新 a, A, C, l 和 p 。

Step4:在 $p < 0.5$ 的情况下,若 $|A| < 1$,则按照式(5)对目前种群的空间位置进行修正。另外,从目前种群中任意选取一只鲸鱼的方位 X_{rand} 。另一方面,在 $p > 0.5$ 的情况下,按照式(6)来更新空间位置。

Step5:修正鲸鱼群体的搜寻空间。

Step6:计算每个鲸鱼个体的适应度,找出当前最佳个体并保存。然后,判断算法是否达到终止条件。如果未达到终止条件(即当前迭代次数未达到最大迭代次数),将重复之前的更新和计算步骤;否则,进入下一步 Step7。

Step7:输出最佳鲸鱼个体的适合度和相应的空间位置。此位置对应 ELM 模型的最佳参量。使用最优化的 ELM 模型参数来评估测试集,从而完成葡萄酒品质评价。

2 结果与分析

2.1 评价指标

为实现葡萄酒的品质评价,首先需要根据理化指标,将葡萄酒品质分为一般、良好和优 3 个品质等级。文中

葡萄酒的评价指标共选择 12 个理化指标, 分别为非挥发性酸、挥发性酸、柠檬酸、残糖、氯化物、游离二氧化硫、二氧化硫总量、密度、pH 值、硫酸盐、酒精度和葡萄酒质量级别, 具体如表 1 所示。评价指标确定之后, 对葡萄酒样本进行品质划分, 划分为一般、良好和优 3 个品质等级。后续将葡萄酒光谱特征作为自变量, 葡萄酒品质等级作为因变量, 建立葡萄酒品质评价模型。12 个特征属性归一化处理之后的统计箱型图如图 3 所示。

2.2 试验仪器

试验仪器采用美国 Thermo Fisher Scientific 公司的 Antaris II 型近红外检测仪, 其是一款高性能的分析仪器, 适用于多种样品检测与分析, 其中集成了多种检测模块, 包括透射、反射、漫透射以及漫反射等, 使得仪器能够适应不同样品特性和检测需求。Antaris II 型的近红外检测仪的光谱范围为 4 000~10 000 cm, 分辨率为 8 cm, 扫描次数为 64 次。选择张裕葡萄酒为研究对象, 运用 Antaris II 型的近红外检测仪共得到 1 110 组样本数据。

表 1 葡萄酒评价指标

Table 1 Wine evaluation index

变量	单位	取值范围
非挥发性酸	g/dm ³	4.6~15.9
挥发性酸	g/dm ³	0.12~1.58
柠檬酸	g/dm ³	0~1
残糖	g/dm ³	0.9~15.5
氯化物	g/dm ³	0.01~0.61
游离二氧化硫	g/dm ³	1~72
总二氧化硫	g/dm ³	6~289
密度	g/cm ³	0.990~1.004
pH		2.74~4.01
硫酸盐	g/dm ³	0.33~2.00
酒精含量	%	8.4~14.9
质量级别		3~8




图 3 特征箱型图

Figure 3 Feature box diagram

2.3 数据预处理

数据预处理方法主要有: 一阶导数预处理、二阶导数预处理、标准正态转换预处理、多变量散射修正预处理等方面的研究^[13-14]。经过对比, 这些不同预处理方法的建模效果如表 1 所示。图 4 展示了葡萄酒原始近红外光谱图像的形态。从表 2 可以看出, 多元散射校正(MSC)的预处理结果表现最为出色。经过 MSC 预处理后的葡萄酒原始近红外光谱如图 5 所示, 其效果明显优于其他预处理方法。

采用均方根差 E_{RMSE} 与相关系数 R 对葡萄酒质量评估模型进行评价^[15-16]。

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

$$R = \frac{\sum_{k=1}^n x_k p_k}{\sqrt{\sum_{k=1}^n x_k^2} \sqrt{\sum_{k=1}^n p_k^2}}, \quad (16)$$

表 2 不同预处理建模效果对比

Table 2 Comparison of modeling effects of different pretreatment

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 葡萄酒原始光谱

Figure 4 Original spectrum of wine




图 5 MSC 预处理结果

Figure 5 MSC pretreatment result chart

式中:

x_k 、 p_k ——葡萄酒质量的真实数值与第 k 样品的预测;
 n ——样本的总数量。

均方根误差 (E_{RMSE}) 是用来评估葡萄酒品质评价模型离散程度的重要指标。 E_{RMSE} 反映了预测值与实际值之间的偏差大小,数值越小,说明模型的预测结果与实际值越接近,模型的离散程度越低。另一个重要指标是 R 值,它描述了葡萄酒品质评价与实际值之间的关联程度。 R 值越接近于 1,意味着预测值与实际值之间的关联度越高,模型的预测效果也就越理想。

通过综合考虑 E_{RMSE} 和 R 值两个指标,可以全面评

价葡萄酒品质预测模型的性能,从而选择出最佳的模型进行实际应用。

2.4 特征波长筛选

介于葡萄酒的光谱信息维数高、结构复杂,在建立葡萄酒品质评价模型之前,首先对光谱数据进行了降维处理。为了找到最佳的降维方法,对比了多种特征波长筛选技术,包括全波段分析、偏最小二乘法、连续投影法以及自适应重加权采样法等^[11,17-18]。通过对比这些方法的效果,在此基础上,建立了一套适用于葡萄酒光谱数据的特征波段筛选方法。在对特征波长进行筛选之后,比较了两种算法对模型的影响,如图 6 所示。




图 6 特征波长筛选后建模效果图

Figure 6 Modeling effects diagram after feature wavelength screening

经过图 6 中特征波长筛选后的建模效果对比结果显示,利用自适应重加权采样法波长筛选法建立的模型表现最为出色。其相关系数高达 0.936 8,同时均方根误差仅为 1.287,这一效果不仅超过了使用全波段数据进行建模的效果,也优于采用偏最小二乘法和连续投影法筛选波长后所建立的模型。因此,采用自适应重加权采样法作为筛选葡萄酒光谱特征波长的最佳方法。

2.5 结果比较

为了验证 WOA-ELM 在葡萄酒品质评价中的有效性和可靠性,将其与 GA-ELM、PSO-ELM 以及传统的 ELM 进行了对比。在参数设置方面,采用了以下设定:

- (1) 对于 WOA 算法,设定种群规模为 10,最大迭代次数为 100。
- (2) 设置最大迭代次数为 100,群体大小为 10,变异几率为 0.1,交叉几率为 0.7。
- (3) 在 PSO 中,将学习系数 c_1 、 c_2 分别设为 2、最大迭代次数为 100、群体大小为 10、惯性权重为 0.8。
- (4) 在 ELM 中,输入层的神经元数目为 2 740,隐含层的神经元数目为 10,而输出层的神经元数目为 1。

为了评价葡萄酒品质评价的效果,选择准确率、敏感性和特异性作为评价指标。数据库中共采集到光谱数据 1 110 组,按照 70% : 30% 划分训练集和测试集,前

777 组数据作为训练集,剩余 333 组数据作为测试集。通过对比分析,葡萄酒品质评价结果如表 3 所示。

根据表 3,4 种方法在葡萄酒品质评价的结果比较可知:

WOA-ELM 的准确率最高,达到了 0.944 5,明显高于其他 3 种方法。GA-ELM 的准确率为 0.929 0,排在第

表 3 葡萄酒品质评价结果对比

Table 3 Comparison of wine quality evaluation results

方法	准确率	敏感性	特异性
WOA-ELM	0.944 5	0.958 9	0.963 4
GA-ELM	0.929 0	0.894 3	0.956 7
PSO-ELM	0.906 1	0.826 2	0.913 7
ELM	0.817 7	0.805 1	0.844 7

表 4 不同算法评价结果

Table 4 Evaluation results of different algorithms

方法	验证集				测试集				%
	准确率	精准率	召回率	F ₁ 分数	准确率	精准率	召回率	F ₁ 分数	
	ELM	82.86	84.06	88.31	89.63	82.78	84.56	86.39	
GA-ELM	89.75	88.64	89.67	89.88	93.63	88.64	89.62	89.67	
CARS+PSO-ELM	90.71	88.88	94.91	91.80	94.71	93.81	94.73	91.26	
CARS+GA-ELM	93.43	90.35	93.78	92.14	94.28	94.35	95.27	93.31	
CARS+WOA-ELM	97.02	93.50	96.91	94.05	96.69	96.42	96.76	94.47	

由表 4 可知,在验证集和测试集上,CARS + WOA-ELM 模型的准确率最高。

基于鲸鱼优化算法改进的极限学习机(WOA-ELM)在葡萄酒品质评价中表现出最高的准确率、敏感性和特异性,其性能远超极限学习机(GA-ELM)、粒子群优化(PSO-ELM)和经典极限学习机(ELM)。研究结果显示,利用智能算法对 ELM 的参数进行优选,尤其是使用鲸类算法,能够有效改善酒质量评估的精度。

3 结论

为提高葡萄酒品质评价的准确性,针对目前葡萄酒质量检测中存在的问题,采用红外光谱技术,结合鲸类算法,对极限学习机进行改进。考虑到极限学习机的预报效果很大程度上受到初值权重及门限选取的影响,采用鲸类算法对极限学习机的初值和权重进行精化,并以葡萄酒的红外吸收光谱为输入,以葡萄酒质量为输出,建立以红外光谱为基础的质量评估模型。

通过对比分析,研究表明,采用基于鲸鱼优化算法改进的极限学习机建立的葡萄酒质量评估模型,其预测准确性明显高于极限学习机、粒子群优化和经典极限学习机,展示了智能优化算法在提升机器学习模型性能方面

的巨大潜力。

二位,而 PSO-ELM 的准确率为 0.906 1,位于第三。传统的 ELM 方法准确率仅为 0.817 7,表现最差。

WOA-ELM 的敏感性为 0.958 9,是 4 种方法中最高的,说明其在识别高品质葡萄酒方面表现优异。GA-ELM 和 PSO-ELM 的敏感性相对较低,分别为 0.894 3 和 0.826 2。ELM 的敏感性最低(0.805 1)。

WOA-ELM 的特异性为 0.963 4,同样是最高的,表明其在识别低品质葡萄酒方面也有很好的表现。GA-ELM 的特异性为 0.956 7,紧随其后,而 PSO-ELM 的特异性为 0.913 7。ELM 的特异性极低,仅为 0.844 7,进一步证明了其整体性能不佳。

为进一步验证竞争性自适应重加权采样法 CARS+WOA-ELM 算法的效果,对比采用竞争性自适应重加权采样法 CARS 和不采用竞争性自适应重加权采样法 CARS 进行特征筛选的降维效果,对比结果如表 4 所示。

的巨大潜力。

近红外光谱的预处理方法和特征选择方法有很多种,该研究只考察了几种预处理方式和特征选择方法,后续将研究多种组合方法对比不同方法的效果;此外,将尝试运用深度学习方法,比如深度卷积神经网络、长短记忆网络等来提高模型的评价精度,增加模型的适应性和可靠性。

参考文献

- [1] 赵杰文,张海东,刘木华. 利用近红外漫反射光谱技术进行葡萄酒糖度无损检测的研究[J]. 农业工程学报, 2005, 21(3): 162-165.
ZHAO J W, ZHANG H D, LIU M H. 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.
- [2] 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葡萄酒糖度模型的优化[J]. 食品安全质量检测学报, 2019 (14): 4 608-4 612.
LI S Z, TONG H X, YUAN L M, 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.
- [3] 刘燕德, 周延睿. 基于 GA-LSSVM 的葡萄酒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 Y D, ZHOU Y R. 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.
- [4] 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葡萄酒糖度[J]. *分析测试学报*, 2010, 29(12): 1 173-1 177.
- XIA A L, ZHOU X Q, YE H J, 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.
- [5] 王浩云, 李晓凡, 李亦白, 等. 基于高光谱图像和 3D-CNN 的葡萄酒多品质参数无损检测[J]. *南京农业大学学报*, 2020, 43(1): 178-185.
- WANG H Y, LI X F, LI Y B, et al. Research on non-destructive detection of apple multi-quality parameters based on hyperspectral imaging technology and 3D-CNN [J]. *Journal of Nanjing Agricultural University*, 2020, 43(1): 178-185.
- [6] 郭志明, 赵春江, 黄文倩, 等. 葡萄酒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 Z M, ZHAO C J, HUANG W Q, 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] 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 X F, DAI L K, HUANG C W. 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.
- [8] NICOLA B M, THERON K I, LAMMERTYN J. Kernel PLS regression on wavelet transformed NIR spectra for prediction of sugar content of apple[J]. *Chemometrics & Intelligent Laboratory Systems*, 2007, 85(2): 243-252.
- [9] SAYED G I, DARWISH A, HAWOANIEN A E. A new chaotic multi-verse optimization algorithm for solving engineering optimization problems[J]. *Journal of Experimental & Theoretical Artificial Intelligence*, 2018, 42(3): 1-25.
- [10] IBRAHIM A, AHMED A, HUSSEIN S, et al. Fish image segmentation usingsalpswarm algorithm [C]// *International Conference on Advanced Machine Learning Technologies & Applications*. [S.l.]: Springer, Cham, 2018: 42-51.
- [11] ZHAO J, OU Y 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.
- [12] 乔正明, 詹成. 基于近红外光谱和 SSA-ELM 的苹果糖度预测[J]. *食品与机械*, 2021, 37(9): 121-126.
- QIAO Z M, ZHAN C. Prediction of apple sugar content based on near-infrared spectroscopy of SSA-ELM[J]. *Food & Machinery*, 2021, 37(9): 121-126.
- [13] NICOLA B M, THERON K I, LAMMERTYN J. Kernel PLS regression on wavelet transformed NIR spectra for prediction of sugar content of apple[J]. *Chemometrics & Intelligent Laboratory Systems*, 2007, 85(2): 243-252.
- [14] WEI X, JIE S W, CHENG X, et al. Extreme learning machine soft-sensor model with different activation functions on grinding process optimized by improved black hole algorithm [J]. *IEEE Access*, 2020(8): 25 084-25 110.
- [15] ZHANG H D, LI G R, LI R C, et al. Determination of tea polyphenols content in puerh tea using near-infrared spectroscopy combined with extreme learning machine and GA-PLS algorithm [J]. *Laser & Optoelectronics Progress*, 2013, 50(4): 180-186.
- [16] 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 K X, CAO P F. 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.
- [17] BAO Y F, WANG X F, LIU G L, et al. NIR detection of alcohol content based on GA-PLS[J]. *Applied Mechanics and Materials*, 2012, 128/129: 200-204.
- [18] 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 Y F, GAO Z B. Study on double adaptive AIS-PSO based model for gas concentration soft-sensing[J]. *Computer Simulation*, 2020, 37(1): 338-342.