

DOI: 10.13652/j.spjx.1003.5788.2024.60140

基于近红外光谱和 PCA-DBN-SVM 的猪肉种类识别

许新华¹ 杨礼波² 司夏萌³(1. 郑州西亚斯学院, 河南 郑州 451150; 2. 华北水利水电大学, 河南 郑州 450046;
3. 北京信息科技大学, 北京 102206)

摘要: [目的] 提高猪肉的分类精度, 建立基于近红外光谱和 PCA-DBN-SVM 的猪肉种类识别模型。[方法] 结合猪肉的近红外光谱特征信息, 利用 PCA 进行降维和特征提取, 并采用 DBN-SVM 进行分类识别, 构建一个融合近红外光谱信息特征和 PCA-DBN-SVM 模型的猪肉种类识别方法。[结果] 与 KNN 模型、RF 模型、ELM 模型以及 DBN 组合模型相比, PCA-DBN-SVM 模型的猪肉种类分类精度最高, 为 99.91%。[结论] PCA-DBN-SVM 模型具有更高的分类精度。

关键词: 支持向量机; 主成分分析; 近红外光谱; 深度置信网络

Pork species identification based on near-infrared spectroscopy and PCA-DBN-SVM

XU Xinhua¹ YANG Libo² SI Xiameng³(1. Zhengzhou Sias University, Zhengzhou, Henan 451150, China;
2. North China University of Water Resources and Electric Power, Zhengzhou, Henan 450046, China;
3. Beijing Information Science and Technology University, Beijing 102206, China)

Abstract: [Objective] To improve the classification accuracy of pork species by building an identification model based on near-infrared spectroscopy and PCA-DBN-SVM. [Methods] Combining the near-infrared spectroscopy characteristics of pork, principal component analysis (PCA) is used for dimensionality reduction and feature extraction, and DBN-SVM is then applied for classification and recognition to construct a pork species identification method that integrates near-infrared spectroscopy characteristics with PCA-DBN-SVM model. [Results] Compared with the KNN model, RF model, ELM, and DBN combination model, the PCA-DBN-SVM model has the highest classification accuracy of pork species, which reaches 99.91%. [Conclusion] The PCA-DBN-SVM model exhibits superior classification accuracy.

Keywords: support vector machine; principal component analysis; near-infrared spectroscopy; deep belief network

随着消费者对食品质量与安全性的需求日益增长, 特别是在肉类产品领域, 猪肉作为消费量巨大的肉类之一, 其品质鉴定与种类区分显得尤为关键。猪肉品质受多种因素影响, 包括遗传、环境、体外处理及品种差异, 可能导致出现如黑干肉 (dark firm and dry, DFD) 和白肌肉 (pale soft and exudative, PSE) 等不良类型。传统上, 正常

肉 (reddish pink firm and non-exudative, RFN)、DFD 肉与 PSE 肉的鉴别依赖于感官评估与化学分析, 但这些方法不仅耗时且主观性强, 且可能破坏样品。近年来, 光谱技术的进步, 特别是近红外光谱技术的引入, 为肉类品质检测与分类开辟了新途径。已有学者尝试将图像颜色特征^[1]、支持向量机 (support vector machine, SVM)^[2]、逐步回归

基金项目: 河南省科技攻关项目 (编号: 242102210021); 河南省高等学校重点科研项目 (编号: 24B510016)

通信作者: 许新华 (1986—), 女, 郑州西亚斯学院讲师, 硕士。E-mail: bbbff34@yeah.net

收稿日期: 2024-10-17 改回日期: 2025-02-21

引用格式: 许新华, 杨礼波, 司夏萌. 基于近红外光谱和 PCA-DBN-SVM 的猪肉种类识别[J]. 食品与机械, 2025, 41(3): 50-56.

Citation: XU Xinhua, YANG Libo, SI Xiameng. Pork species identification based on near-infrared spectroscopy and PCA-DBN-SVM[J]. Food & Machinery, 2025, 41(3): 50-56.

法^[3]、典型判别分析^[4]及前向神经网络^[5]等方法应用于猪肉分类,但各方法在不同类别间的区分效果存在差异,且多依赖于单一指标或人工判断,存在局限性。近红外光谱技术通过结合光谱与成像技术,能够在非破坏性条件下获取丰富的光谱与空间信息,适用于肉类品质的无损检测。然而,该技术产生的大量数据伴随信息冗余与噪声,对数据处理与分析构成挑战。尽管许多研究已经利用光谱分析技术成功实现了猪肉品质的快速检测,但這些方法往往受限于样本数量、特征提取能力以及模型泛化性能等方面的不足^[6-7]。特别是,一些传统机器学习模型在处理高维光谱数据时容易陷入过拟合,而深度学习模型则可能因参数过多而导致训练困难。研究拟提出一种基于主成分分析(principle components analysis, PCA)、深度信念网络(deep belief network, DBN)和SVM的集成模型(PCA-DBN-SVM),以期提高猪肉种类识别的准确性,为猪肉品质评估提供新的技术途径。

1 猪肉近红外光谱采集系统

采集系统主要用于生鲜猪肉近红外光谱数据的收集,对象选定为排酸24 h后的左胴体眼肌部位。所有样本均被精确切割至40 mm厚,去除结缔组织与脂肪后制成25 mm厚的标准品,确保数据采集的一致性,共获得129个有效样本。图1为近红外光谱数据采集系统,该系统包括稳定光源、遮光暗箱、AvaSpec-USB近红外光谱仪、计算机、支撑平板、光纤组件和探头以及AvaSoft7.4光谱采集软件。光谱仪检测波长覆盖350~1 150 nm,分辨率达0.6 nm。光源稳定发射,样品反射光由光纤探头捕捉并传输至光谱仪分析,高效获取猪肉近红外光谱信息。




图1 数据采集系统图

Figure 1 Data acquisition system

2 研究方法

2.1 主成分分析

PCA作为一种有效的数据降维技术^[8-9],能够精准提炼猪肉近红外光谱数据的关键特征,剔除冗余,以最少的信息集精准映射原始数据核心,加速数据挖掘进程。研

究运用PCA方法,筛选出猪肉光谱数据的核心波段。

2.2 深度置信网络

DBN是一种新型深度学习网络,由多层受限玻尔兹曼机(restricted boltzman machine, RBM)堆叠组成。其架构如图2所示。首先,通过可见层 v_1 与隐层 h_1 组成RBM₁,随后以可见层 v_2 与隐层 h_2 构建RBM₂,依此类推至RBM₃,最后一层为BP层,负责网络的精细调整。在此结构中,可见层负责接收输入数据,而隐层则用于特征提取^[10-11]。

可见层:接收输入数据,这些数据通常是原始数据或经过预处理的特征数据。可见层中的神经元数量对应于输入数据的特征数量。

隐层(第1层、第2层、...、第N层):提取输入数据的特征,并通过逐层传递的方式逐步抽象出更高层次的特征。每一层隐层都试图捕捉到输入数据中的不同特征模式。

分类器层(如SVM层、BP网络层等):基于从隐层提取的特征进行分类或预测。分类器层可以是任何适合的分类型算法,如支持向量机(SVM)、BP神经网络等。




图2 DBN网络结构

Figure 2 DBN network architecture

对于DBN中,任意给定的可见层(v)与隐层(h)的状态组合,针对所有二值变量 i (属于可见层 v)和 j (属于隐层 h),其能量函数定义为:

$$E(v, h | \theta) = - \sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m v_i w_{ij} h_j, \quad (1)$$

式中:

θ ——待求参数, $\theta = \{w, a, b\}$;

a, b ——可见层和隐层的偏置项;

w ——可见层与隐层的权重。

在训练过程中,若存在 K 个训练样本,通过最大化对数似然函数 $L(\theta)$ 来求解参数 θ 。

$$\theta^* = \arg_{\theta} \max L(\theta) = \arg_{\theta} \max \sum_{k=1}^K \ln p(v^k | \theta) \quad (2)$$

当参数 θ 与其他相关参数得以确定后,针对任意状态组合 (v, h) , 其联合概率分布为^[12]:

$$p(v, h | \theta) = \frac{e^{-E(v, h | \theta)}}{Z(\theta)} \quad (3)$$

式中:

$$Z(\theta) = \sum_v \sum_h e^{-E(v, h | \theta)} \text{——归一化因子。}$$

在给定可见层 v 的状态后,隐层单元 j 的激活概率 $p(h_j = 1 | v, \theta)$ 为:

$$p(h_j = 1 | v, \theta) = \text{sigmoid}(b_j + \sum_{i=1}^n v_i w_{ij}) \quad (4)$$

相应地,当隐层 h 的状态已知时,可见层单元 i 的激活概率 $p(v_i = 1 | h, \theta)$ 为:

$$p(v_i = 1 | h, \theta) = \text{sigmoid}(a_i + \sum_{j=1}^m h_j w_{ij}) \quad (5)$$

通过 Gibbs 采样重复, RBM 参数的更新规则为:

$$\begin{aligned} \Delta w_{ij} &= \epsilon (\langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{recon}}) \\ \Delta a_i &= \epsilon (\langle v_i \rangle_{\text{data}} - \langle v_i \rangle_{\text{recon}}) \\ \Delta b_j &= \epsilon (\langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{recon}}) \end{aligned} \quad (6)$$

式中:

ϵ ——RBM 学习速率;

$\langle \cdot \rangle_{\text{data}}, \langle \cdot \rangle_{\text{recon}}$ ——输入和重构后的数据的数学期望。

2.3 支持向量机

假设训练样本 $(\mathbf{x}_i, \mathbf{y}_i)$, 其中 $\mathbf{x}_i$ 为输入向量, $\mathbf{y}_i$ 为输出向量, 引入松弛变量 ξ_i , $\hat{\xi}_i$ 之后, SVM 数学模型的表达式为^[13]:

$$\begin{aligned} \min & \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^m (\xi_i + \hat{\xi}_i) \\ \text{s.t.} & \begin{cases} f(x_i) - \mathbf{y}_i \leq \epsilon + \xi_i \\ \mathbf{y}_i - f(x_i) \leq \epsilon + \hat{\xi}_i \\ \xi_i \geq 0, \hat{\xi}_i \geq 0, i = 1, 2, \dots, m \end{cases} \end{aligned} \quad (7)$$

式中:

$\epsilon, C, \mathbf{w}$ ——不敏感损失系数、惩罚参数和权向量。

引入核函数 $K(x_i, x_j)$ 和 Lagrange 乘子, SVM 模型转化成为:

$$\begin{aligned} \max_{\hat{\alpha}, \hat{\alpha}} & \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) \mathbf{y}_i - \sum_{j=1}^m (\hat{\alpha}_j + \alpha_j) \epsilon - \\ & \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m (\hat{\alpha}_i - \alpha_i) (\hat{\alpha}_j - \alpha_j) K(x_i, x_j), \end{aligned} \quad (8)$$

式中:

$\hat{\alpha}_i, \hat{\alpha}_i, \hat{\alpha}_j, \hat{\alpha}_j$ ——Lagrange 乘子。

核函数采用 RBF 核函数:

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2g^2}\right) \quad (9)$$

式中:

g ——核参数。

求解式(8), SVM 分类模型的数学表达式为^[14]:

$$f(x, \hat{\alpha}_i, \alpha_i) = \text{sgn}\left\{\sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) K(x_i, x_j) + b\right\} \quad (10)$$

式中:

b ——偏置。

为了确定 C 和 g 的最佳取值, 采用了交叉验证和网格搜索的方法。通过遍历一系列可能的 C 和 g 值, 并计算每个组合下的交叉验证准确率, 选择了准确率最高的 C 和 g 值作为模型的参数。这种方法确保了 SVM 模型在给定数据集上的最优性能。

3 基于 PCA-DBN-SVM 猪肉种类识别模型

在研究方法上, 采用了机器学习算法对猪肉种类进行识别。尽管在样本选择上尽量做到了随机性和代表性, 但由于样本数量有限, 可能无法全面覆盖所有可能的猪肉种类和饲养环境。因此, 在未来的研究中, 计划增加样本数量, 并尽量涵盖更多不同品种、饲养环境和生长阶段的猪肉, 以提高模型的普适性和可信度。PCA-DBN-SVM 猪肉种类识别模型的主要思想: 利用近红外光谱技术结合 PCA-DBN-SVM 模型, 实现了猪肉种类的快速准确识别。通过采集不同种类猪肉的近红外光谱数据, 结合 PCA 进行数据降维, 利用 DBN 进行特征提取, 最后通过 SVM 进行分类。PCA-DBN-SVM 猪肉种类识别流程如图 3 所示。

基于 PCA-DBN-SVM 的猪肉种类识别流程:

(1) 加载猪肉样本的近红外光谱图像数据, 执行去噪声步骤并对其进行标准化预处理。

(2) 采用主成分分析(PCA)技术对标准化后的近红外光谱数据进行特征波段的提取与筛选。

(3) 猪肉的类别编码, 文中分为 3 类, 分别编码成 $[0 \ 0 \ 1]$, $[0 \ 1 \ 0]$ 和 $[1 \ 0 \ 0]$ 。

(4) 将猪肉近红外光谱数据分为训练样本和测试样本, 将训练样本的猪肉近红外光谱的特征向量作为 DBN-SVM 的输入, 训练样本的猪肉类别作为 DBN-SVM 的输




图3 PCA-DBN-SVM猪肉种类识别流程图

Figure 3 Flow of PCA-DBN-SVM for pork species identification

出,建立 DBN-SVM 模型。

(5) 针对猪肉近红外光谱的测试样本,运用 DBN-SVM 猪肉种类识别模型进行猪肉种类识别。

4 结果与分析

4.1 预处理

PSE、RFN、DFD 3 类猪肉样本的原始光谱曲线、变量标准化与归一化处理后的光谱曲线以及 3 类肉品的平均漫反射光谱曲线分别如图 4~图 6 所示。预先将 129 个猪肉样本分为 PSE、RFN、DFD 3 类,分别为 39、39、51 个样本。随机排列所有试验样本并按照 2:1 的比例划分为训练集与测试集。其中,训练集包含 PSE 26 个、RFN 34 个、DFD 26 个样本;而测试集则包括 PSE 13 个、RFN 17 个、DFD 13 个样本。在试验设计方面,采用了更为稳健的方法来评估模型性能。除了按照 2:1 的比例随机划分训练集和测试集外,还进行了多次重复试验,并采用了交叉验证等更稳健的方法来减少因样本划分带来的随机性误差。通过多次试验验证,确认了所提出的 2:1 划分比例在模型评估中的有效性,确保了试验结果的稳定性和可靠性。

4.2 PCA 特征选择

猪肉近红外光谱数据经 PCA 处理后,依据特定的筛选标准确定了具有代表性的特征波长,如图 7 所示,分别位于 371、388、425、456、473、562、578、607、696、764、772、813、927 nm 处。这些波长的选择基于它们在 PCA 处理中




图4 原始光谱图

Figure 4 Original spectra




图5 标准化的光谱图

Figure 5 Standardized spectra

对数据变异性的高贡献度,即它们能够在降维后的主成分空间中有效地保留原始光谱数据的大部分信息。筛选标准综合考虑了波长对应的载荷系数大小、对猪肉成分




图6 平均反射光谱曲线

Figure 6 Average reflection spectrum curves




图7 PCA特征提取结果图

Figure 7 PCA characteristics extraction

预测的潜在贡献以及避免信息冗余的原则,从而确保了所选特征波长能够高效地用于后续的建模与分析工作。

4.3 结果分析

PCA-SVM、DBN-SVM 和 PCA-DBN-SVM 3 种方法的识别准确率如表 1 所示。由表 1 可知,PCA-DBN-SVM 识别准确率最高,达到 95.52%,较 PCA-SVM 和 DBN-SVM 分别提高了 4.48% 和 2.98%。灵敏度和特效度分别衡量分类算法对正例和负例的识别能力,3 种算法的灵敏度和特效度对比结果如图 8~图 9 所示。

表1 识别准确率对比

Table 1 Recognition accuracy comparison

方法	准确率/%
PCA-SVM	91.04
DBN-SVM	92.54
PCA-DBN-SVM	95.52

由图 8 和图 9 可知,PCA-DBN-SVM 在灵敏度和特效度指标上,优于 PCA-SVM 和 DBN-SVM,尤其在 PSE 类别上灵敏度最高。PCA-SVM、DBN-SVM 和 PCA-DBN-SVM 3 种算法在 PSE 类别上灵敏度普遍高于 RFN 和 DFD




图8 灵敏度对比图

Figure 8 Sensitivity comparison




图9 特效度对比图

Figure 9 Specificity comparison

类别,说明 PSE 类别与 RFN 和 DFD 类别区分度大,不容易与其他类别混淆。3 种算法在 RFN 类别上的灵敏度较低,说明 RFN 类别容易与 PSE 类别和 DFD 类别混淆。由图 9 可知,DFD 类别的特效度明显高于 PSE 类别和 RFN 类别,说明 PSE 和 RFN 类别识别效果好,不容易将 PSE 类别和 RFN 类别划分为 RFN 类别。PSE 类别与 RFN 和 DFD 类别在光谱特征上存在显著差异,可能是由于它们在不同生长环境和饲养条件下形成的肉质特性所致。而 RFN 类别容易混淆的原因可能在于其光谱特征与其他两类存在一定的重叠区域,这提示在未来的研究中需要进一步优化特征提取方法以提高分类精度。对于 DFD 类别特效度高的现象,推测这可能与该类猪肉在光谱上具有的独特吸收峰或反射特性有关。这些分析不仅增强了研究的逻辑性和连贯性,还为后续研究提供了有益的启示。

4.4 模型对比

为验证 PCA-DBN-SVM 的效果,将其与 PCA-DBN-RF/DBN-RF^[15]、PCA-DBN-KNN/DBN-KNN^[16]、PCA-DBN-ELM/DBN-ELM^[17]进行对比,结果见表 2。

由表 2 可知,采用 PCA 进行数据预处理的 DBN 模型(即 PCA-DBN)在准确率上普遍高于直接采用 DBN 的模

表2 不同模型准确率对比

Table 2 Accuracy of different models				%
方法	SVM	RF	KNN	ELM
DBN	99.24	99.13	98.64	98.63
PCA-DBN	99.91	99.62	99.89	99.58

型。这一结果表明,PCA作为一种有效的降维技术,能够去除原始数据中的冗余信息,提高模型的泛化能力。同时,在PCA-DBN的基础上,采用SVM作为分类器的模型(即PCA-DBN-SVM)在准确率上进一步优化了RF、KNN和ELM等分类器,达到了99.91%的最高准确率。

在与其他模型的对比中,注意到SVM模型在结合PCA-DBN后展现出了显著的优势。SVM作为一种基于最大边距原理的分类器,在处理高维数据时具有出色的性能,而PCA-DBN则通过降维和特征提取为SVM提供了更加精炼和有效的输入特征。相比之下,RF、KNN和ELM等分类器虽然也在一定程度上受益于PCA-DBN的数据预处理,但在准确率上仍略逊于SVM。

RF(随机森林)作为一种集成学习方法,通过构建多个决策树并综合其预测结果来提高模型的稳定性和准确性。然而,在处理高维数据时,RF可能会受到特征冗余和计算复杂性的限制。KNN(K近邻)是一种基于实例的学习方法,其性能高度依赖于数据的局部结构和特征选择。在高维空间中,KNN可能会受到“维度灾难”的影响,导致预测准确性下降。ELM(极限学习机)是一种单隐层前馈神经网络,具有训练速度快、泛化能力强的特点。然而,ELM的性能对输入特征的选择依赖性较高。

通过全面的对比分析,进一步突出了PCA-DBN-SVM模型在猪肉品质检测中的独特优势,包括高准确率、强泛化性能以及良好的鲁棒性。这些优势使得PCA-DBN-SVM模型在肉类品质检测、食品安全监控等领域具有广阔的应用前景和重要的实践价值。未来,将继续探索和优化该模型,以进一步提高其在肉类品质检测中的准确性和可靠性。

5 结论

为提高猪肉种类识别的精度,提出一种基于近红外光谱和PCA-DBN-SVM的猪肉种类识别模型。首先,通过近红外光谱技术获取其光谱信息,利用主成分分析(PCA)进行光谱特征降维和特征提取;之后,运用深度信念网络(DBN)提取近红外光谱特征,采用支持向量机(SVM)进行分类识别。与PCA-DBN-RF/DBN-RF、PCA-

DBN-KNN/DBN-KNN 和 PCA-DBN-ELM/DBN-ELM 对比可知,采用PCA-DBN-SVM进行猪肉种类识别的准确率最高,达到99.91%。

基于当前129个有效样本的研究结果,发现机器学习算法在猪肉种类识别方面具有一定的潜力。然而,由于样本数量的限制和猪肉种类的多样性,所得模型的普适性和可信度仍有待进一步验证。在未来的研究中,将继续扩大样本数量,并探索更多可能影响猪肉种类识别的因素,以提高模型的准确性和可靠性。

参考文献

- [1] 刘媛媛,彭彦昆,王文秀,等. 基于偏最小二乘投影的可见/近红外光谱猪肉综合品质分类[J]. 农业工程学报, 2014, 30(23): 306-313.
- [2] LIU Y Y, PENG Y K, WANG W X, et al. Classification of pork comprehensive quality based on partial least squares projection and Vis/NIR spectroscopy[J]. Transactions of the Chinese Society of Agricultural Engineering, 2014, 30(23): 306-313.
- [3] 贾渊,李振江,彭增起. 结合LLE流形学习和支持向量机的猪肉颜色分级[J]. 农业工程学报, 2012, 28(9): 147-152.
- [4] JIA Y, LI Z J, PENG Z Q. Pork color grading based on LLE manifold learning and support vector machine[J]. Transactions of the Chinese Society of Agricultural Engineering, 2012, 28(9): 147-152.
- [5] MONROY M, PRASHER S, NGADI M O, et al. Pork meat quality classification using Visible/Near-Infrared spectroscopic data[J]. Biosystems Engineering, 2010, 107(3): 271-276.
- [6] 付淑亚,谢安国,刘云宏. 二维相关红外光谱和高光谱成像技术检测黄精干燥过程中多糖的变化[J]. 食品与机械, 2024, 40(8): 33-39.
- [7] FU S Y, XIE A G, LIU Y H. Two - dimensional correlation infrared spectroscopy and hyperspectral imaging to detect the changes of polysaccharide during the drying process of Polygonatum sibiricum[J]. Food & Machinery, 2024, 40(8): 33-39.
- [8] RØDBOTTEN R, NILSEN B N, HILDRUM K I. Prediction of beef quality attributes from early post mortem near infrared reflectance spectra[J]. Food Chemistry, 2000, 69(4): 427-436.
- [9] 陈亦凡,李芸婧,彭苗苗,等. MIV波长优选改善VIS/NIR光谱TVB-N模型性能研究[J]. 光谱学与光谱分析, 2020, 40(5): 1413-1419.
- [10] CHENG Y F, LI Y J, PENG M M, et al. Improvements of VIS-NIR spectroscopy model in the prediction of TVB-N using MIV wavelength selection[J]. Spectroscopy and Spectral Analysis, 2020, 40(5): 1413-1419.
- [11] 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 CH 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] 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 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.
- [9] ZHAO J W, OUYANG Q, CHEN Q S, 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 and Technology International, 2013, 19(4): 305-314.
- [10] 徐瑞煜, 朱焯炜, 胡扬俊, 等. 三维荧光光谱结合 PCA-SVM 对几种浓香型白酒的鉴别[J]. 光谱学与光谱分析, 2016, 36(4): 1 021-1 026.
- XU R Y, ZHU Z W, HU Y J, et al. The discrimination of Chinese strong aroma type liquors with three-dimensional fluorescence spectroscopy combined with principal component analysis and support vector machine[J]. Spectroscopy and Spectral Analysis, 2016, 36(4): 1 021-1 026.
- [11] 陈淑一, 赵全明, 董大明. 对比主成分分析的近红外光谱测量及其在水果农药残留识别中的应用[J]. 光谱学与光谱分析, 2020, 40(3): 917-921.
- CHEN S Y, ZHAO Q M, DONG D M. Application of near infrared spectroscopy combined with comparative principal component analysis for pesticide residue detection in fruit[J]. Spectroscopy and Spectral Analysis, 2020, 40(3): 917-921.
- [12] DAMI S, YAHAGHIZADEH M. Predicting cardiovascular events with deep learning approach in the context of the internet of things[J]. Neural Computing and Applications, 2021, 33(13): 7 979-7 996.
- [13] KANG S, KYUNKIM S. Outlier behavior detection for indoor environment based on t-SNE clustering[J]. Computers, Materials & Continua, 2021, 68(3): 3 725-3 736.
- [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): 2 516-2 523.
- 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): 2 516-2 523.
- [15] 章恺, 朱丽芳, 李入林, 等. 基于改进 WOA-LSSVM 和高光谱的猕猴桃糖度无损检测[J]. 食品与机械, 2024, 40(5): 107-112, 226.
- ZHANG K, ZHU L F, LI R L, et al. Nondestructive detection of kiwifruit sugar content based on improved WOA-LSSVM and hyperspectral analysis[J]. Food & Machinery, 2024, 40(5): 107-112, 226.
- [16] 陈珏, 李佳琮, 刘翠玲, 等. 荧光光谱技术结合机器学习算法检测大白菜中吡虫啉含量[J]. 食品安全质量检测学报, 2023, 14(13): 134-140.
- CHEN J, LI J C, LIU C L, et al. Determination of imidacloprid in cabbage by fluorescence spectroscopy combined with machine learning algorithms[J]. Journal of Food Safety and Quality, 2023, 14(13): 134-140.
- [17] 程朋飞, 朱燕萍, 潘金燕, 等. 三维荧光光谱结合 IGOA-SVM 分类鉴别油类污染物[J]. 光谱学与光谱分析, 2024, 44(4): 1 031-1 038.
- CHENG P F, ZHU Y P, PAN J Y, et al. Classification of oil pollutants by three-dimensional fluorescence spectroscopy combined with IGOA-SVM[J]. Spectroscopy and Spectral Analysis, 2024, 44(4): 1 031-1 038.