

# 基于电子鼻多传感器融合的茶叶存储时间识别

薛大为, 杨春兰

(蚌埠学院电子与电气工程学院, 安徽 蚌埠 233030)

**摘要:** 借助电子鼻检测存储 60、120、180、240、300、360 d 的黄山毛峰茶香气信息, 根据电子鼻各传感器响应曲线变化特点, 选取出一组能够表征不同香气信息的基本特征变量, 分别采用主成分回归(PCR)、偏最小二乘回归(PLS)和 BP 神经网络(BPNN)方法, 建立茶叶存储时间的预测模型。测试样本集对 3 种预测模型的检验结果表明: PCR、PLS、BPNN 模型的预测标准误差分别为 10.05、6.04、3.21 d; 最大预测相对误差分别为 11.03%、7.02%、5.89%; 平均预测相对误差分别为 6.73%、4.74%、3.62%; 预测值与实际值之间的决定系数  $R^2$  分别为 0.862、0.896、0.987。3 种模型都能较好地对茶叶存储时间进行预测, 相比较而言, BPNN 模型性能最优, PLS 模型性能优于 PCR 模型。

**关键词:** 电子鼻; 茶叶存储时间; 多传感器融合; 主成分回归; 偏最小二乘回归; BP 神经网络

中图分类号: TP274; TP212 文献标志码: A 文章编号: 1007-1032(2019)02-0218-07

## Recognition method for storage time of tea based on multi-sensor fusion of the electronic nose

XUE Dawei, YANG Chunlan

(School of Electronics and Electrical Engineering, Bengbu University, Bengbu, Anhui 233030, China)

**Abstract:** A recognition methods for storage time of tea was set up based on the Huangshanmaofeng tea under storage time of 60, 120, 180, 240, 300 and 360 d detected by electronic nose. According to response curves of electronic nose, a set of essential characteristic variables were selected. On the basis of these variables, principle component regression(PCR), partial least squares regression(PLS) and back propagation neural network(BPNN) was applied to build the prediction model for storage time of tea, respectively. Three prediction models were validated by test sample set. The results indicated that standard error of prediction of PCR, PLS and BPNN models were 10.05, 6.04 and 3.21 d, respectively; the maximum relative error 11.03%, 7.02% and 5.89%, respectively; the mean relative error 6.73%, 4.74%, and 3.62%, respectively; determination coefficient between predicted value and real value 0.862, 0.896 and 0.987, respectively. All of the models could predict storage time of tea well. BPNN was the model with the best performance and PLS is better than PCR.

**Keywords:** electronic nose; storage time of tea; multi-sensor fusion; principle component regression; partial least squares regression; back propagation neural network

非发酵茶类随着存储时间的增长, 化学成分会发生复杂的变化, 茶叶香气逐渐减弱, 品质越来越差, 直至失去饮用价值。感官审评和理化指标测定是茶叶品质鉴别常用的 2 种方法<sup>[1]</sup>。感官审评易受外界及自身因素的干扰, 评定结果存在一定程度的不确定性; 理化指标测定操作程序复杂、繁琐, 耗时

较长。茶叶香气与茶叶品质密切关联, 是评定茶叶品质的重要依据。已有研究表明, 茶叶香气是由几百种挥发性物质共同作用形成的综合状态的体现<sup>[2]</sup>, 依靠单个或少量传感器难以对其进行有效识别。

多传感器融合技术<sup>[3-4]</sup>是近年来兴起的一门新技术, 它通过多个传感器来获取客观对象的信息, 再利

用数据融合方法对信息进行处理,进而形成判别或决策结果。多传感器融合技术克服了单个传感器的局限性,获取的信息更为全面,得到的结果也更加准确。

电子鼻是多传感器融合技术的典型代表,主要由包括多个传感器的传感器阵列及相应的模式识别方法构成,是一种仿人类嗅觉功能的仪器。目前,电子鼻已经在肉类<sup>[5-10]</sup>、乳制品<sup>[11-16]</sup>、水果<sup>[17-22]</sup>等食品工业领域得到广泛应用。于慧春等<sup>[23]</sup>利用电子鼻对 5 个等级龙井茶的茶叶、茶水、叶底进行检测,采用线性判别和 BP 神经网络方法,实现了对不同等级茶叶的分类判别。陈哲等<sup>[24]</sup>利用电子鼻对 3 种等级的碧螺春茶的茶水、叶底进行检测,并将获取的特征信息进行综合,采用 K 邻近和 BP 神经网络方法对茶叶等级进行识别,结果 BP 神经网络识别正确率达到 100%。张红梅等<sup>[25-26]</sup>利用电子鼻对 3 个等级信阳毛尖茶进行检测,采用多元线性回归、主成分回归、二次多项式回归方法,建立了茶叶中咖啡碱及茶多酚含量的预测模型。BHATTACHARYA 等<sup>[27]</sup>利用电子鼻监测红茶发酵过程中产生的挥发性物质,进而确定最佳发酵时间。YANG 等<sup>[28]</sup>利用电子鼻对 7 种日本绿茶进行检测,采用主成分分析和聚类分析方法,实现了对不同浓缩香豆素含量绿茶的识别。这一系列研究主要集中于对不同等级茶叶的识别或茶叶中某种成分含量的预测。

笔者尝试以中国十大名茶之一的安徽黄山毛峰茶为研究对象,用电子鼻对已存储 60、120、180、240、300、360 d 的干茶进行检测,获取茶叶香气的特征信息;分别采用主成分回归(PCR)、偏最小二乘回归(PLS)、BP 神经网络(BPNN)方法,建立茶叶存储时间的预测模型,并对 3 种预测模型性能进行对比分析,以寻求茶叶存储时间的最佳识别方法。

## 1 材料与方法

### 1.1 材料与仪器

茶叶样本为从安徽黄山当地茶厂订购的黄山毛峰明前茶,每 50 g 茶样用锡纸袋密封、独立包装并加入干燥剂,置于 5 °C 冰箱中存储。

电子鼻为德国 Airsense 的 PEN3 便携式电子鼻。电子鼻主要由传感器阵列、数据采集及处理软件、采集及清洗装置、吸附与解吸附装置等组成,其中,传感器阵列包括 10 个半导体金属氧化物传感器:W1C、W5S、W3C、W6S、W5C、W1S、W1W、W2S、W2W 和 W3S,分别以 S1~S10 表示。传感

器响应值为  $G/G_0$ ,  $G$  为传感器在挥发性气体中的电导率,  $G_0$  为传感器在纯净空气中的电导率。

### 1.2 方法

从 2016 年 5 月 1 日开始,使用电子鼻每 60 d 检测 1 次茶样,至 2017 年 4 月 25 日结束。不同存储时间的茶叶分别准备 15 个重复样本,每个重复样本 5 g,放入 250 mL 烧杯中,用双层塑料保鲜膜密封,26 °C 条件下静置 60 min 后,进行电子鼻检测。电子鼻采样频率为 1 次/s,每次检测采样时间为 60 s,清洗时间为 2 min。共获取 90 组样本数据,其中 60 组(每一存储时间 10 组)作为训练样本集,30 组(每一存储时间 5 组)作为测试样本集。

### 1.3 数据处理

电子鼻各传感器对同一香气存在交叉敏感性且响应存在差异,首先根据不同存储时间茶样响应曲线变化特点,选取 1 组能够较好反映响应曲线特征的变量,即基本特征变量。为尽量不丢失原始数据中蕴含的信息,通常选取较多的基本特征变量,这些变量之间往往会存在一些信息重叠或多重相关性。如果直接以这些基本特征变量作为自变量,采用多元线性回归(MLR)方法建立茶叶存储时间的预测模型,预测精度会较低。

为了更好地抑制由于特征变量间的相关性带来的预测偏差,提高预测精度,分别采用主成分回归(PCR)、偏最小二乘回归(PLS)和神经网络(BPNN)模式识别方法,建立茶叶存储时间的预测模型。利用训练样本集和测试样本集对模型进行检验,通过模型的预测标准误差(SEP)、最大预测相对误差( $RE_{max}$ )、平均预测相对误差( $RE_{mean}$ )、预测值与实际值之间的决定系数( $R^2$ )对模型性能进行评价。

## 2 结果与分析

### 2.1 茶样香气的基本特征变量

基于电子鼻各传感器响应在 50 s 后基本趋于稳态,将采样时间设定为 60 s。图 1 为电子鼻传感器阵列对不同存储时间黄山毛峰茶叶香气具有代表性的响应曲线。可以看出,各传感器对同一香气都有响应,但有所不同,具有交叉敏感性。为了更好地反映香气的特征信息,对茶样香气传感器响应曲线变化趋势及其特点进行分析,发现各传感器在第

30 s 时的响应值、响应最大值、响应稳态值(取第 60 s 时的响应值)、采样时间内的响应平均值的变化较为显著,故选取这些值作为基本特征变量。由于电子鼻包含 10 个传感器,则由基本特征变量组成一 40 维基本特征向量,  $X=(x_1, x_2, \dots, x_{40})$ 。

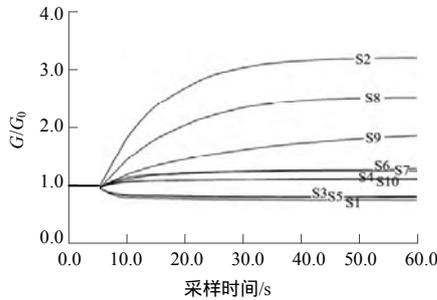


图 1 不同存贮时间茶叶电子鼻典型响应曲线

Fig.1 Representative response curve of electronic nose under different storage time

其中:  $x_1, x_2, \dots, x_{10}$  分别为 S1~S10 第 30 s 时的响应值;  $x_{11}, x_{12}, \dots, x_{20}$  分别为 S1~S10 响应最大值;  $x_{21}, x_{22}, \dots, x_{30}$  分别为 S1~S10 响应稳态值;  $x_{31}, x_{32}, \dots, x_{40}$  分别为 S1~S10 在 60 s 内响应平均值。

2.2 基本特征变量的相关性

由于基本特征向量维数较高,这些变量包含的信息可能会存在冗余。为了更好地利用这些特征变量,对基本特征变量进行相关性分析,相关系数采用 Pearson 相关,显著水平  $\alpha$  取 0.05,双尾显著性检验。相关性分析发现,多个基本特征变量之间存在较大的相关性,最大相关系数达到 0.931(表 1),说明基本特征变量之间存在多重相关性(共线性)。

表 1 部分基本特征变量的相关系数

Table 1 Correlation coefficient of partial characteristic variables

变量	相关系数									
	$x_1$	$x_2$	$x_{11}$	$x_{12}$	$x_{19}$	$x_{22}$	$x_{28}$	$x_{29}$	$x_{32}$	$x_{38}$
$x_1$	1.000									
$x_2$	-0.513	1.000								
$x_{11}$	0.732	-0.578	1.000							
$x_{12}$	-0.546	0.853	-0.327	1.000						
$x_{19}$	-0.247	0.775	-0.403	0.864	1.000					
$x_{22}$	-0.465	0.794	-0.547	0.882	0.633	1.000				
$x_{28}$	-0.351	0.418	-0.329	0.642	0.484	0.649	1.000			
$x_{29}$	-0.475	0.658	-0.551	0.810	0.863	0.727	0.805	1.000		
$x_{32}$	-0.514	0.852	-0.331	0.931	0.608	0.890	0.241	0.537	1.000	
$x_{38}$	-0.462	0.159	-0.379	0.593	0.550	0.623	0.874	0.488	0.665	1.000

2.3 茶叶存储时间的预测模型

由于基本特征变量之间存在多重相关性,如果直接用这些基本特征变量来建立茶叶存储时间的 MLR 模型,会给回归系数估计值带来很大偏差,降低预测精度。为提高模型的预测精度,先采用 PCR 方法和 PLS 方法建立茶叶存储时间预测模型,再以性能较优者与 BP 神经网络结合,建立 BPNN 预测模型,以寻求最佳的茶叶存储时间识别模型。

2.3.1 PCR 预测模型

由于基本特征向量为 40 维,则训练样本数据可构成 1 个 60×40 的基本特征变量矩阵。对基本特征变量矩阵进行主成分分析(PCA),前 5 个主成分的特征值都大于 1,累计贡献率为 96.78%(大于

85%)(表 2),能较好地概括基本特征变量矩阵包含的信息;因此,取前 5 个主成分建立茶叶存储时间的 PCR 预测模型。

表 2 基本特征变量矩阵前 5 个主成分的特征值及贡献率  
Table 2 The eigenvalues and contribution rate of the first five principal components of the basic characteristic value matrix

主成分	特征值	贡献率/%	累计贡献率/%
$P_1$	48.75	52.32	52.32
$P_2$	26.82	28.78	81.10
$P_3$	9.63	10.34	91.44
$P_4$	3.01	3.23	94.67
$P_5$	1.98	2.12	96.79

分别用训练样本集和测试样本集对 PCR 预测模型进行检验。PCR 模型的预测值与实际值如图 2

所示。对于训练样本集，PCR 预测模型的  $SEP$ 、 $RE_{max}$ 、 $RE_{mean}$ 、 $R^2$  分别为 9.48 d、10.97%、6.57%、0.873；对于测试样本集，PCR 预测模型的  $SEP$ 、

$RE_{max}$ 、 $RE_{mean}$ 、 $R^2$  分别为 10.05 d、11.03%、6.73%、0.862。

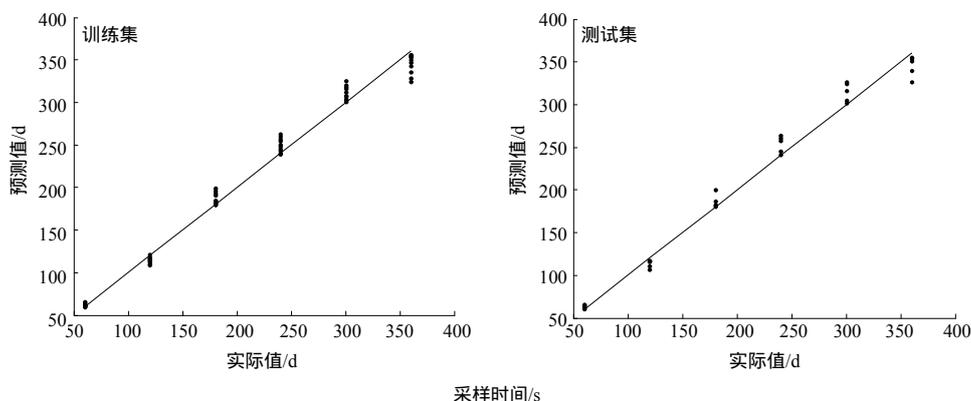


图 2 PCR 模型的预测值与实际值

Fig.2 Predicted values from PCR and real values

2.3.2 PLS 预测模型

PCR 方法可以消除基本特征变量间存在的多重相关性问题，但主成分只是根据基本特征变量矩阵(自变量)得到的，并没有考虑基本特征变量与茶叶存储时间(因变量)之间的关系，因而有必要进一步对训练样本集构成的  $60 \times 40$  基本特征变量矩阵及其对应的  $60 \times 1$  茶叶存储时间矩阵进行 PLS 分析，并通过交叉有效性进行检验，设定限定值 0.05。根据检验结果，当取前 4 个成分时模型便可达到设定的检验目标，因此利用前 4 个成分来建立 PLS 回归模型。前 4 个成分对变量的解释能力如表 3 所示。结果表明，前 4 个成分共解释了基本特征变量矩阵(自变量)90.36%的信息，对基本特征变量具有较好的概括性。同时，前 4 个成分共解释了茶叶存储时间矩阵(因变量)88.76%的信息，对茶叶存储时间的解释能力也较强。

表 3 前 4 个成分对变量的解释能力

Table 3 Explanatory ability for the variables of the first four components

成分	自变量	自变量	因变量	因变量
	解释率	累计解释率	解释率	累计解释率
$t_1$	51.97	51.97	68.65	68.65
$t_2$	20.21	72.18	12.64	81.29
$t_3$	16.83	89.01	5.24	86.53
$t_4$	1.35	90.36	2.23	88.76

分别用训练样本集和测试样本集对 PLS 预测模型进行检验。PLS 模型的预测值与实际值如图 3 所示。对于训练样本集，PLS 预测模型的  $SEP$ 、 $RE_{max}$ 、 $RE_{mean}$ 、 $R^2$  分别为 5.37 d、6.96%、4.58%、0.904；对于测试样本集，PLS 预测模型的  $SEP$ 、 $RE_{max}$ 、 $RE_{mean}$ 、 $R^2$  分别为 6.04 d、7.02%、4.74%、0.896。与 PCR 预测模型相比，PLS 预测模型的性能更好。

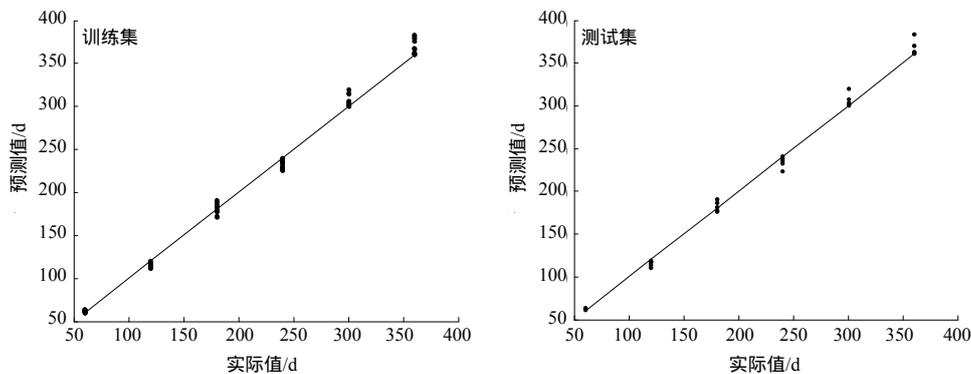


图 3 PLS 模型的预测值与实际值

Fig.3 Predicted values from PLS and real values

### 2.3.3 BPNN 预测模型

PCR 方法和 PLS 方法建立的预测模型,是利用线性回归方程来近似逼近电子鼻传感器响应与茶叶存储时间之间的非线性映射关系,虽然都有较好的预测效果,但仍然存在一定的误差。鉴于 PLS 模型的预测效果优于 PCR 模型,选择 PLS 模型中提取的前 4 个成分作为 BPNN 的输入。

BPNN 采用只含有单个隐含层的 3 层网络结构。输入层和输出层节点数分别由输入变量数和输出变量数决定。BPNN 输入量为 PLS 提取的 4 个成分,输入层节点数为 4 个;输出量为茶叶存储时间,输出层节点数为 1 个。根据输入层与输出层节点数及设计经验可估计出隐含层节点的大致范围为 3~13 个<sup>[29]</sup>,再逐一进行试验比较,以网络训练误差和网络对测试集样本预测值与实际值间的决定系数对性能进行综合评价。隐含层传递函数采用 tansig 函数,输出层传递函数采用 purelin 函数,网络学习采用 L-M 算法,目标误差采用均方差,设定值为 10,最大迭代次数取 5 000。不同隐含层节点数 BPNN 的训练结果如表 4 所示。

当隐含层节点数取 10、11 和 13 时,训练误差较小,都达到了设定的目标要求,模型预测的茶叶存储时间与茶叶实际存储时间之间的决定系数分别为 0.975、0.987 和 0.893。当隐含层节点数为 13

表 4 不同隐含层节点数网络训练结果

Table 4 Training results of BPNN with different node numbers in hidden layer

隐含层节点	训练误差	决定系数 $R^2$	迭代次数
3	12.874	0.835	103
4	11.735	0.852	210
5	10.682	0.861	542
6	10.455	0.902	1 231
7	10.643	0.883	2 005
8	10.317	0.910	2 243
9	10.176	0.872	3 624
10	9.098	0.975	1 852
11	10.002	0.986	1 767
12	10.219	0.943	3 004
13	10.001	0.893	4 216

时,模型对于测试集的决定系数较小,存在过拟合现象,泛化能力较差;当隐含层节点数为 11 时,虽然比取 10 时训练误差稍大,但模型对测试集的决定系数较高,泛化能力较强。综合考虑,确定隐含层节点为 11。BPNN 预测模型的最佳网络结构为 4-11-1。BPNN 模型的预测值与实际值如图 4 所示。对于训练样本集, BPNN 预测模型的  $SEP$ 、 $RE_{max}$ 、 $RE_{mean}$ 、 $R^2$  分别为 3.17 d、5.68%、3.45%、0.985;对于测试样本集, BPNN 预测模型的  $SEP$ 、 $RE_{max}$ 、 $RE_{mean}$ 、 $R^2$  分别为 3.21 d、5.89%、3.62%、0.987。与 PCR、PLS 预测模型相比, BPNN 预测模型的性能更优。

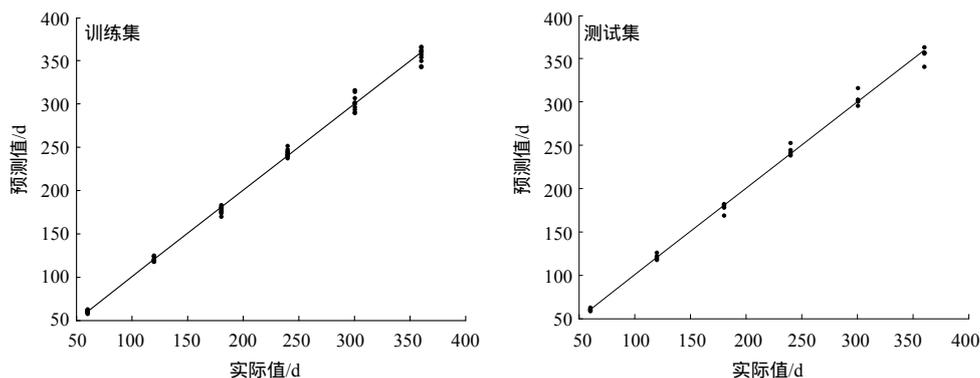


图 4 BPNN 模型的预测值与实际值

Fig.4 Predicted values from BPNN and real values

## 2.4 PCR、PLS 和 BPNN 预测模型比较

依据电子鼻传感器阵列对不同存储时间茶叶的响应,提取出基本特征变量,以此为基础分别采用 PCR、PLS 和 BPNN 方法建立茶叶存储时间的 3 种预测模型,并利用  $SEP$ 、 $RE_{max}$ 、 $RE_{mean}$ 、 $R^2$  作为

指标对 3 种预测模型性能进行评价。3 种预测模型对测试样本集性能的比较如表 5 所示。3 种预测模型对测试样本集中 6 种存储时间茶叶的平均预测值如表 6 所示。

表 5 3 种预测模型的性能

模型	SEP/d	RE <sub>max</sub> /%	RE <sub>mean</sub> /%	R <sup>2</sup>
PCR	10.05	11.03	6.73	0.862
PLS	6.04	7.02	4.74	0.896
BPNN	3.21	5.89	3.62	0.987

表 6 3 种预测模型的平均预测值

模型	平均预测值/d					
	60	120	180	240	300	360
PCR	63.60	113.58	186.7	253.86	314.90	345.64
PLS	63.00	115.92	182.70	234.66	307.30	368.44
BPNN	60.80	121.42	178.20	243.72	303.52	355.40

3 种模型都能较好地测试样本集茶叶存储时间进行预测。BPNN 模型具有最小的 SEP、RE<sub>max</sub>、RE<sub>mean</sub> 和最大的 R<sup>2</sup>, 平均预测值与实际值最为接近, 预测效果最好, 表明相对于 PCR 与 PLS 线性识别方法, 非线性识别方法 BPNN 能够更好地描述电子鼻传感器响应与茶叶存储时间之间复杂的非线性映射关系。PLS 预测模型性能优于 PCR 预测模型, 表明 PCR 方法仅从自变量矩阵出发提取的前 5 个主成分虽然可以较好地解释自变量, 但对因变量的解释能力不够。3 种模型中, BPNN 为茶叶存储时间最佳预测模型。

### 3 结论

利用电子鼻对存储 60、120、180、240、300、360 d 的黄山毛峰干茶进行检测, 依据电子鼻传感器阵列获取的茶叶香气信息, 提取了基本特征变量, 分别采用 PCR、PLS 和 BPNN 方法, 对多传感器信息进行融合, 建立了茶叶存储时间预测模型。以最大预测相对误差 RE<sub>max</sub>、平均预测相对误差 RE<sub>mean</sub>、预测值与实际值之间的决定系数 R<sup>2</sup> 作为评价指标, 对 3 种预测模型预测效果进行比较分析, 结果表明, 3 种模型都能对茶叶存储时间进行较好的预测, 采用非线性 BPNN 预测模型具有最小的 SEP、RE<sub>max</sub>、RE<sub>mean</sub> 和最大的 R<sup>2</sup>, 性能最优。

#### 参考文献:

[1] 薛大为, 孔慧芳, 杨春兰. 主成分分析与神经网络结合的黄山毛峰茶品质检测[J]. 计算机与应用化学, 2014, 31(5): 578-582.  
 [2] 杨春兰, 薛大为, 鲍俊宏. 黄山毛峰茶贮藏时间电子

鼻检测方法研究[J]. 浙江农业学报, 2016, 28(4): 676-681.

- [3] 周波, 钱堃, 马旭东, 等. 基于集员估计的室内移动机器人多传感器融合定位[J]. 控制理论与应用, 2017, 34(4): 541-550.  
 [4] 徐礼胜, 靳雁冰, 王琦文, 等. 多传感器融合的穿戴式心率监测系统[J]. 哈尔滨工业大学学报, 2015, 47(5): 97-103.  
 [5] 蒙万隆, 郑丽敏, 杨璐, 等. 电子鼻技术对猪肉挥发性盐基氮的预测研究[J]. 食品工业科技, 2018, 39(7): 243-248.  
 [6] 张娟, 张申, 张力, 等. 电子鼻结合统计学分析对牛肉中猪肉掺假的识别[J]. 食品科学, 2018, 39(4): 296-300.  
 [7] SOARES S, AMARAL J S, MBPPO et al. A SYBR green real-time PCR assay to detect and quantify pork meat in processed poultry meat products[J]. Meat Science, 2013, 94(1): 115-120.  
 [8] HADDI Z, BARBRI N E, TAHRI K, et al. Instrumental assessment of red meat origins and their storage time using electronic sensing systems[J]. Analytical Methods, 2015, 7(12): 5193-5203.  
 [9] NURJULIANA M, CHE M Y, MAT H D, et al. Rapid identification of pork for halal authentication using the electronic nose and gas chromatography mass spectrometer with headspace analyzer [J]. Meat Science, 2011, 88(4): 638-644.  
 [10] 洪雪珍, 韦真博, 海铮, 等. 基于电子鼻和神经网络的牛肉新鲜度的检测[J]. 现代食品科技, 2014, 30(4): 279-285.  
 [11] 贾茹, 张娟, 王佳奕, 等. 电子鼻结合化学计量法对羊奶中蛋白质掺假的识别[J]. 食品科学, 2017, 38(8): 308-312.  
 [12] CUI S, WANG J, YANG L, et al. Qualitative and quantitative analysis on aroma characteristics of ginseng at different ages using E-nose and GC-MS combined with chemometrics[J]. Journal of Pharmaceutical and Biomedical Analysis, 2015, 102: 64-77.  
 [13] SINGH H, RAJ V B, KUMAR J, et al. Metal oxide SAW E-nose employing PCA and ANN for the identification of binary mixture of DMMP and methanol[J]. Sensors and Actuators B: Chemical, 2014, 200: 147-156.  
 [14] 贾茹, 刘占东, 马利杰, 等. 电子鼻对山羊奶中致瘤游离脂肪酸的识别研究[J]. 中国乳品工业, 2015, 43(3): 18-21.  
 [15] BOUGRINI M, TAHRI K, HADDI Z, et al. Aging time and brand determination of pasteurized milk using a multisensor E-nose combined with a voltammetric E-tongue[J]. Materials Science and Engineering: C, 2014, 45: 348-358.  
 [16] 马利杰, 贾茹, 杨春杰, 等. 基于电子鼻技术对羊奶

- 粉中掺假牛奶粉的快速检测[J]. 中国乳品工业, 2014, 42(11): 47-50.
- [17] HUI G H, WU Y L, YE D D, et al. Fuji apple storage time predictive method using electronic nose[J]. Food Analytical Methods, 2013, 6(1): 82-88.
- [18] 张鹏, 李江阔, 陈绍慧. 基于电子鼻判别富士苹果货架期的研究[J]. 食品工业科技, 2015, 36(5): 272-276.
- [19] 宋小青, 任亚梅, 张艳宜, 等. 电子鼻对低温贮藏猕猴桃品质的预测[J]. 食品科学, 2014, 35(20): 230-235.
- [20] PATHANGE L P, MALLIKARJUNAN P, MARINI R P, et al. Non-destructive evaluation of apple maturity using an electronic nose system[J]. Journal of Food Engineering, 2006, 77(4): 1018-1023.
- [21] 李莹, 任亚梅, 张爽, 等. 基于电子鼻的苹果低温贮藏时间及品质预测[J]. 西北农林科技大学学报(自然科学版), 2015, 43(5): 183-191.
- [22] AYŞEGÜL U, RECEP Ö. Efficient android electronic nose design for recognition and perception of fruit odors using Kernel Extreme Learning Machines[J]. Chemometrics and Intelligent Laboratory Systems, 2017, 166: 69-80.
- [23] 于慧春, 王俊. 电子鼻技术在茶叶品质检测中的应用研究[J]. 传感技术学报, 2008, 21(5): 748-752.
- [24] 陈哲, 赵杰文. 基于电子鼻技术的碧螺春茶叶品质等级检测研究[J]. 农机化研究, 2012, 34(11): 133-137.
- [25] 张红梅, 田辉, 何玉静, 等. 茶叶中茶多酚含量电子鼻技术检测模型研究[J]. 河南农业大学学报, 2012, 46(3): 302-306.
- [26] 张红梅, 王俊, 余泳昌, 等. 基于电子鼻技术的信阳毛尖茶咖啡碱检测方法[J]. 传感技术学报, 2011, 24(8): 1223-1227.
- [27] BHATTACHARYA N, TUDU B, JANA A, et al. Preemptive identification of optimum fermentation time for black tea using electronic nose[J]. Sensors and Actuators B, 2008, 131: 110-116.
- [28] YANG Z Y, DONG F, KAZUO S, et al. Identification of coumarin enriched Japanese green teas and their particular flavor using electronic nose[J]. Journal of Food Engineering, 2009, 92: 312-316.
- [29] 严正红, 周俊, 毛家敏. 基于 GA-BP 神经网络的番茄应力松弛参数的估计[J]. 湖南农业大学学报(自然科学版), 2018, 44(5): 565-569.

责任编辑: 罗慧敏  
英文编辑: 吴志立

(上接第 217 页)

- [10] 鹿丽鹏, 王彬, 刘辉, 等. 基于图像灰度差分统计的雾霾污染等级检测方法[J]. 计算机工程, 2016, 42(1): 225-230.
- [11] 刘媛, 冯全. 葡萄病害的计算机识别方法[J]. 中国农机化学报, 2017, 38(4): 99-104.
- [12] 白文斌, 白帆, 贺文文, 等. 基于 SVM 的高粱叶片病斑图像自动分割提取方法研究[J]. 农学学报, 2014, 4(6): 101-106.
- [13] 黄曜, 许华虎, 欧阳杰臣, 等. 针对图像来源鉴别中支持向量机的研究[J]. 计算机技术与发展, 2016, 26(10): 1-5.
- [14] 徐洪平, 刘洋, 易航, 等. 运载火箭测发网络异常流量识别技术[J]. 清华大学学报(自然科学版), 2018, 58(1): 20-26, 34.
- [15] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273-297.
- [16] 刘向东, 朱美琳, 陈兆乾, 等. 支持向量机及其在模式识别中的应用[J]. 计算机科学, 2003, 30(6): 113-117.
- [17] 吴忠强, 康晓华, 于丹琦. 基于小波消噪和优化支持向量机的板形模式识别[J]. 中国机械工程, 2018, 29(1): 95-103.
- [18] EBERHART R C, SHI Y H. Particle swarm optimization: development, applications and resources[C]// Proceedings of the Congress on Evolutionary Computation. Piscataway: IEEE, 2001: 81-86.
- [19] 巩敦卫, 张勇, 张建化, 等. 新型粒子群优化算法[J]. 控制理论与应用, 2008, 25(1): 111-114, 119.
- [20] 冯远静, 俞立, 冯祖仁, 等. 采样粒子群优化模型及其动力学行为分析[J]. 控制理论与应用, 2009, 26(1): 28-34.

责任编辑: 罗慧敏  
英文编辑: 吴志立