Application Research of Electronic Nose Technology Based on Collaborative Dimensionality Reduction Strategy*

WANG Chao[1], *WANG Xuan*[2], *XIA Zhiping*[3]

(1. *Henan Polytechnic Institute, Faculty of Electronic Information Engineering, Nanyang He'nan* 473009, *China*;
2. *Henan Polytechnic Institute, Faculty of Mechanical Engineering, Nanyang He'nan* 473009, *China*;
3. *School of Mechanical Engineering, Jiujiang Vocational and Technical College, Jiujiang Jiangxi* 332007, *China*)

Abstract: A collaborative dimensionality reduction strategy was proposed to optimize feature dimensions and improve the classification accuracy of electronic nose(e-nose). The collaborative dimensionality reduction strategy combined the advantages of the unsupervised and supervised dimensionality reduction. Firstly, the maximum value, steady-state average value, integral value and wavelet energy value of the e-nose detection data were extracted. Secondly, the kernel entropy component analysis(KECA) was introduced to perform the preliminary dimensionality reduction on the fusion feature, and the linear discriminant analysis(LDA) was used to perform the dimensionality reduction again to obtain the final comprehensive feature. Finally, based on the Support Vector Machine(SVM), Probabilistic Neural Network(PNN), Random Forest(RF) to classify the comprehensive features. The results shown that the KECA-LDA-SVM achieved the highest classification performance of 96%, indicating that the collaborative dimensionality reduction strategy can effectively improve the detection performance of the e-nose.

Key words: electronic nose detection; collaborative strategy; kernel entropy component analysis; linear discriminant analysis; support vector machine

EEACC: 7230 **doi**: 10.3969/j.issn.1004-1699.2020.09.023

基于协同降维策略的电子鼻技术应用研究*

王 超[1], 王 璇[2], 夏志平[3]*

(1.河南工业职业技术学院电子信息工程学院, 河南 南阳 473000; 2.河南工业职业技术学院机械工程学院, 河南 南阳 473000;
3.九江职业技术学院机械工程学院, 江西 九江 332007)

摘 要: 本文提出了一种协同降维策略来优化特征维度进而提升电子鼻分类精度, 该协同降维策略结合了无监督和有监督降维的优点实现原始特征的有效降维, 并利用该策略实现不同品牌白酒的智能辨识。首先, 提取电子鼻检测数据的最大值、稳态均值、积分值以及小波能量值作为特征值。其次, 将无监督降维方式的核熵成分分析(KECA)引入对融合特征进行初步降维, 再利用有监督降维方式的线性判别分析(LDA)进行再次降维得到最终的综合特征。最后, 基于支持向量机(SVM)、概率神经网络(PNN)、随机森林(RF)对综合特征进行分类识别。结果表明, KECA-LDA-SVM 获得了最高的分类性能达 96%, 说明该协同降维策略可以有效提升电子鼻的检测性能。

关键词: 电子鼻检测; 协同策略; 核熵成分分析; 线性判别分析; 支持向量机

中图分类号: TH89 **文献标识码**: A **文章编号**: 1004-1699(2020)09-1372-07

专注于电子鼻检测数据的特征挖掘与模式识别是提升其检测性能的主要方式[1]。作为一种机器感测技术, 电子鼻模仿人类的嗅觉感应机制, 以实现对样品交叉信息的全面采集[2-4]。因此, 其测量数据包含大量冗余和非线性信息。有效的特征挖掘技术是提高检测性能的关键问题之一。一方面, 为了描述检测样本的总体属性, 每个特征之间必须有很小的相关性, 这将减少冗余特征并避免维度爆炸。

项目来源: 2019 年河南省科技攻关项目(192102210165)
收稿日期: 2020-05-29 **修改日期**: 2020-07-09

另一方面,不同的检测对象之间的数据特征应存在明显的信息差异,这将有助于提高决策的准确性。因此,本文提出一种协同降维框架来对电子鼻的原始检测数据进行特征挖掘,进而提升其检测性能,并应用于白酒气味信息辨识。

白酒和威士忌、伏特加和白兰地等蒸馏酒一样享有盛誉,是我国国民的主要饮品之一,它主要以高粱、玉米、小麦等粮食为主要原料之后进行发酵、蒸馏、勾兑制成[5]。饮用白酒已经成为中华民族的一种文化,少量饮用可以有效预防心血管病、消除疲劳和紧张、开胃消食、驱除寒冷、舒筋活血等[6]。不同的制作工艺和酿造过程所生产的白酒质量也不同,常见的过程检测方式主要集中在理化检测,如气相色谱[7]、液相色谱[8]等理化分析技术,这种方式耗时长、检测成品较高。人工感官评价可以根据专业人员的经验进行质量监控,但是该方法的重现性差、主观性强,也不符合智能化检测技术的基本要求[9]。电子鼻作为一种先进传感技术,它可获取待检测样本的综合气味信息,它是白酒品质的一种外在表现,气味由 300 余种化学成分构成,基于电子鼻白酒检测方法的研究尚在验证阶段,即研究其可行性,普遍的检测精度不高。

限制白酒检测精度的主要因素是没有有效挖掘影响其气味信息的主要特征。因此,必须选择有效的特征处理方法以减小特征之间的相关性。国内外目前主要利用 Filter 和 Wrapper 方法来提取关键特征。前者是在提取初步特征之后,分析各个特征对决策性能的影响,删除对决策信息影响较小的特征,以减少计算时间并提高准确性。后者是在提取初步特征之后将其转化为几个综合变量来共同表征原始属性,但目前研究人员大多考虑单降维方法的使用,例如主成分分析(PCA)[10],核主成分分析(KPCA)[11],线性判别分析(LDA)[12]等,这些降维方法在一定程度上去除了冗余信息,但如果特征维度较高,各特征之间的非线性关系较强,则降维效果不明显,不能有效的提升电子鼻的检测精度。因此,本文以 Wrapper 思想对初步提取的电子鼻特征进行数据降维,结合无监督降维和有监督降维的优势,提出协同降维策略来实现白酒气味信息辨识。无监督的降维方法将原始特征简化为多个综合特征,使其线性独立并保留内部信息,但是,它没有考虑类别之间的关系,并且当数据结构复杂时,降维效果并不明显。有监督的降维将类内距离最小化,并将类间距离最大化,它可以尽可能地区分特征,并考虑类别之间的相互作用,但是,如果输入的维数太大,则会增加降维的难度和计算成本。具体的实验流程、特征提取、特征降维以及决策过程在文中进行讨论。

1　材料与方法

1.1　实验材料

本文的实验材料为五种不同品牌的白酒,其酒精度、香型、原材料、产地信息如表 1 所示。

表 1　五种不同品牌白酒信息

品牌	酒精度(%vol)	香型	原材料	产地
泸州老窖	52	浓香型	水、高粱	四川泸州
牛栏山	56	浓香型	水、高粱、大麦、小麦	北京
衡水老白干	52	浓香型	水、高粱、小麦	河北衡水
习酒	52	浓香型	水、高粱、小麦	贵州遵义
五粮醇	50	浓香型	水、高粱、大麦、小麦、玉米	四川宜宾

1.2　电子鼻及实验

商用化的 PEN3 型电子鼻被应用于白酒气味信息的获取。其主要构件为内置的 10 个金属氧化物传感器,该传感器阵列可实现待测气体的交叉敏感信息检测。表 2 显示了 10 个传感器的名称、检测物质以及检测限。传感器的响应输出值为传感器接触待测气体的电导(G)与经过活性炭过滤的洁净空气的电导(G_0)的比值,记为(G/G_0)。在传感器的交叉敏感作用下,获取了待测样本的综合检测信息。

表 2　传感器参数信息

序号	传感器名称	敏感物质	检测限/10^{-6}
1	W1C	芳香成分	10
2	W5S	碳氢化合物	1
3	W3C	氨水,芳香成分	10
4	W6S	对氢气有选择性	100
5	W5C	烷烃、芳香成分	1
6	W1S	甲烷	100
7	W1W	硫化成分	1
8	W2S	乙醇	100
9	W2W	芳香成分,有机硫化物	1
10	W3S	烷烃	10

在电子鼻的实验过程中,环境温度为(23±0.5)℃,相对湿度为(45±2)RH,实验步骤如下:①对白酒进行稀释,将每种白酒的酒精度用纯净的蒸馏水稀释到 2%;②取稀释后白酒 5 mL 置于 50 mL 的样品瓶中静止 5 min,使得样品瓶顶空空气饱满待检测;③在每次检测开始前,用经过活性炭过滤的洁净空气清洗传感器气室 60 s,清洗过程中的空气流速为 300 mL/min;④基于动态顶空取样法在气

体流速为 300 mL/min 条件下通入白酒气体检测时间为 80 s,采样频率为 1 Hz,图 1 为电子鼻检测信号输出图。

重复上述实验步骤②~步骤④,为了不失一般性,每种品牌的白酒准备 30 个平行样本,最终获得 150 组实验数据。

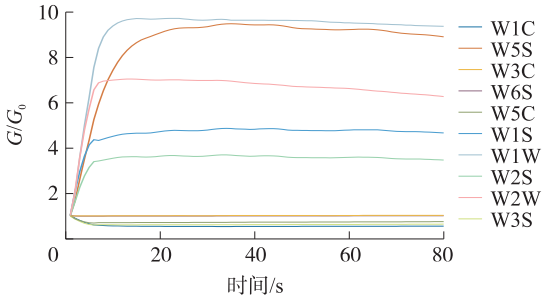

图 1 电子鼻响应输出图

1.3 协同降维策略

无监督降维可以迅速将高位数据转换至低维空间,并使得各个维度之间相互独立[13-14]。但它没有考虑类别之间的数据差异,往往降维效果不明显。有监督降维充分考虑了类别间的差异性,但数据过高造成的维度灾难会使得降维过程难以获得最佳的投影方向[15]。因此,本文将无监督和有监督降维方式相结合,形成协同降维策略。首先利用无监督降维将高维数据向低维空间转换,在利用有监督降维实现类内差异最小,类间差异最大。

核熵成分分析(KECA)为一种无监督的降维技术,它区别于 PCA 按照特征值的大小来保留有效信息,而引入了瑞利熵的概念,利用特征熵值的大小来决定新的特征空间结构,该方法可以有效的减少信息损失,充分利各个特征之间的作用关系,进而实现无监督数据降维[16-17]。KECA 的数学原理如下:

输入向量可以表示为:$\boldsymbol{D}=[x_1,\cdots,x_N]$,$x_k\in\boldsymbol{R}^d$。瑞利熵可以用式(1)进行表示,

$$I(p)=-\log\int p^2(x)\,\mathrm{d}x \tag{1}$$

式中:$p(x)$ 为原始数据的概率密度函数,由于对数函数的单调性,瑞利熵可以定量地估计为

$$Q(p)=\int p^2(x)\,\mathrm{d}x \tag{2}$$

为了估计 $Q(p)$,KECA 引入了 Parzen 窗口密度估计器

$$\hat{p}(x)=\frac{1}{N}\sum_{x_k\in\boldsymbol{D}}k_\tau(x,x_k) \tag{3}$$

式中:$k_\tau(x,x_k)$ 以 x_k 为中心,τ 控制 Parzen 窗口功能的宽度。因此,$M(p)$ 可以表示为

$$\hat{M}(p)=\frac{1}{N}\sum_k\hat{p}(x_k)=\frac{1}{N}\sum_k\frac{1}{N}\sum_k k_\tau(x_k,x_{k'})=\frac{1}{N^2}\boldsymbol{L}^{\mathrm{T}}\boldsymbol{K}\boldsymbol{L} \tag{4}$$

式中:$\boldsymbol{K}=k_\tau(x_k,x_{k'})$,$\boldsymbol{L}$ 是一个长度为 N 的单位向量。对核矩阵 $\boldsymbol{K}$ 进行特征分解如下

$$\boldsymbol{K}=\boldsymbol{E}\boldsymbol{D}\boldsymbol{E}^{\mathrm{T}} \tag{5}$$

式中:$\boldsymbol{D}$ 为对角矩阵,$\boldsymbol{E}$ 的每个特征向量对应着特征值 $\lambda_1,\cdots,\lambda_N$,进而式(5)可以表示为

$$\hat{M}(p)=\frac{1}{N^2}\sum_{i=1}^{N}(\sqrt{\lambda_i}\boldsymbol{e}_i^{\mathrm{T}}\boldsymbol{L})^2 \tag{6}$$

可以明显看出 λ_i 和 $\boldsymbol{e}_i$ 共同对瑞利熵进行了估计。它综合了特征值和特征向量的作用关系寻找到降维数据的最佳投影方向。

LDA 是一种有监督的降维方法,它明确了各个样本的所属类别,它对降维后的数据要求其类内方法最小,类间方差最大[18]。LDA 通过转换向量 w 寻找最佳的投影方向,进而使得类内方差与类间方差比例最大化,该比例如式(7):

$$J=\frac{\boldsymbol{w}^{\mathrm{T}}\boldsymbol{S}_b\boldsymbol{w}}{\boldsymbol{w}^{\mathrm{T}}\boldsymbol{S}_w\boldsymbol{w}} \tag{7}$$

式中:$\boldsymbol{S}_b$ 为类内离散矩阵,$\boldsymbol{S}_w$ 为类间离散矩阵,最佳投影方向可以转换为以下特征求解问题,

$$\boldsymbol{S}_b\boldsymbol{w}=\lambda\boldsymbol{S}_w\boldsymbol{w} \tag{8}$$

因此,式(7)的最优解问题,可以转化为

$$\max\frac{\mathrm{tr}(\boldsymbol{w}^{\mathrm{T}}\boldsymbol{S}_b\boldsymbol{w})}{\mathrm{tr}(\boldsymbol{w}^{\mathrm{T}}\boldsymbol{S}_w\boldsymbol{w})} \tag{9}$$

代入式(8),可得

$$\max\lambda_i \tag{10}$$

因此,最佳投影方向,即最终确定的维度由累计特征贡献率决定。

1.4 模式识别方法

本文引入支持向量机(SVM)、概率神经网络(PNN)和随机森林(RF)实现不同特征集合下的分类决策,来证明特征降维策略的有效性和普适性。SVM 基于结构风险最小化理论,在处理非线性,高维,小样本数据集是具有非常好的分类性能[19-20],本文以 RBF 为核函数,基于网格式搜索在(2^{-10},2^{10})范围内对影响 SVM 分类性能的两个重要参数(惩罚因子 c、核函数函数 g)进行寻优,当训练集在 5 倍交叉验证下获得最高分类准确率时完成参数寻优,进而实现白酒样本决策。PNN 是一种前馈神经网络,它具有学习简单、训练速度快、容错性好的优点,它基于贝叶斯最小风险准则实现样本决策[21-22]。RF 成功的实现了引导策略和随机子空间

方法的结合,其训练决策树的速度远快于一般的人工神经网络,同时,它具有泛化性能好,分类精度高的优点[23-24],本文选择的分类决策树颗数为 500。

2　结果和讨论

2.1　数据可视化

图 2 为在电子鼻检测过程中五种不同白酒的第 60 s的响应雷达图,W1C-W3S 为 10 个不同的传感器,中轴为响应输出,即电导率值的大小。可以看出,气味信息的整体响应趋势类似,泸州老窖和牛栏山,衡水老白干、习酒和五粮醇之间的响应相似度较高。在各传感器下,W5S、W1W、W2W 以及 W1S 的响应值较大,这可能成为对白酒进行辨识的主要特征。但是,各个传感器之间的作用关系是非常复杂的,不能通过响应信息的大小来决定特征对决策的贡献。同时,过少的特征容易导致模型过拟合,过多的特征会增加分类器的决策难度。因此,应对多特征进行综合分析,寻求能表征原始特征的综合变量,在不丢失各特征的决策贡献情况下,实现分类器的高性能辨识。

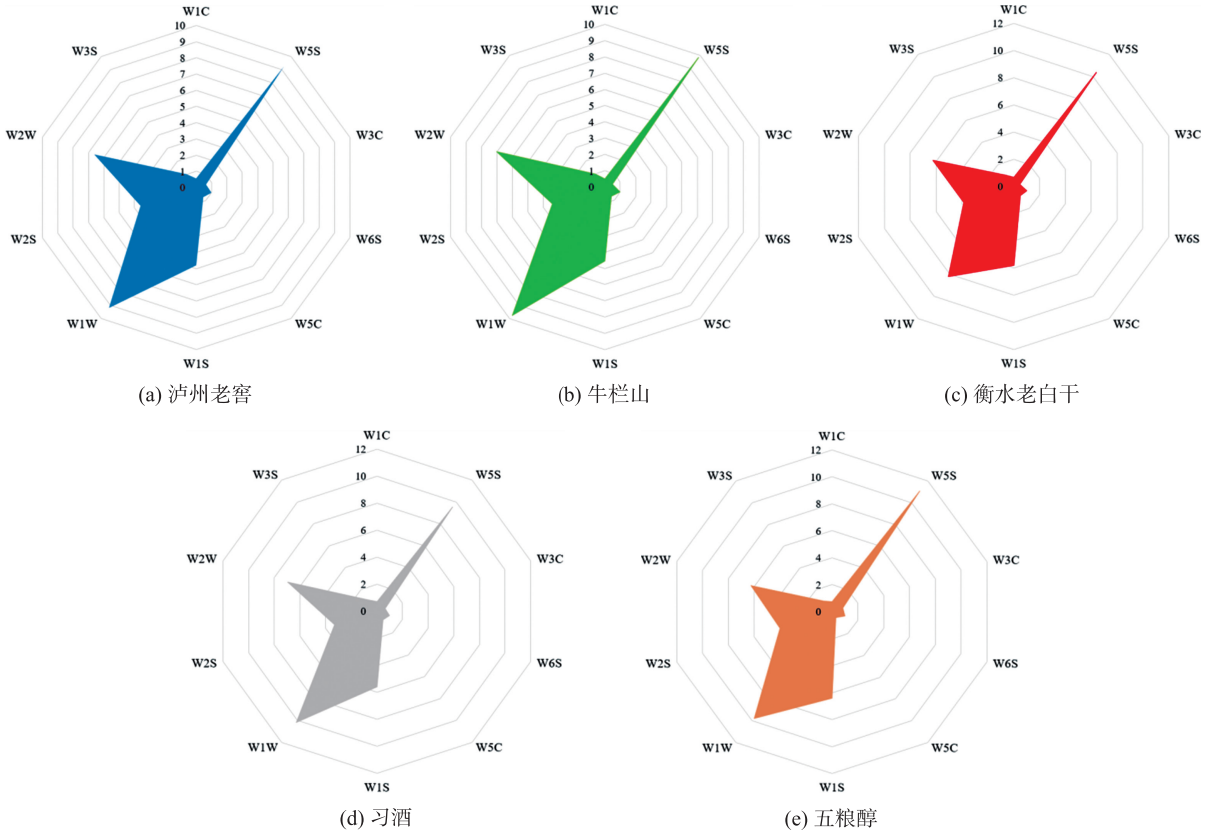

(a) 泸州老窖　(b) 牛栏山　(c) 衡水老白干

(d) 习酒　(e) 五粮醇

图 2　不同白酒的响应雷达图

2.2　协同降维可视化

电子鼻传感器的原始检测数据包含着大量的冗余信息,因此,需要将原始数据进行特征提取。时域和时频域特征可以从不同的数学角度对原始检测信号进行整体表征,因此,本文提取的每个传感器的时域特征为:60 s~80 s 的稳态均值、0~80 s 的最大值、0~80 s 的曲线积分值,时频域特征为 db1 为基函数的小波变换 3 层分解的能量平均值,并基于这四个特征构成了原始融合特征集。为了消除不同量纲以及不同数量级的影响,本文将提取的特征进行归一化处理,归一化区间为(0,1)。

首先,本文利用 KECA 方法对原始融合特征进行降维,当累计熵值贡献率达到 95%确定最终的降维个数。图 3(a)为基于 KECA 的降维结果,横坐标为第一个熵成分,纵坐标为第二个熵成分,两个熵成分的累计贡献率为 79.62%。可以看出,泸州老窖、衡水老白干以及习酒有相对明显的聚类,但是牛栏山和五粮醇的聚类效果不明显。同时,各个类别之间的类内距离较大,类间距离较小,这不利于分类器的决策。最终,确定达熵值贡献率 95%的前 13 个主成分作为 KECA 的降维特征集。

然后,基于协同降维过程,对于无监督降维得到的 13 个 KECA 特征集在进行 LDA 的有监督降维,它将无监督降维和有监督降维相结合。图 3(b)为 KECA-LDA 的最终降维结果,在经过 KECA-LDA 降维后的前两个特征累计贡献率为 88.68%,相比较于

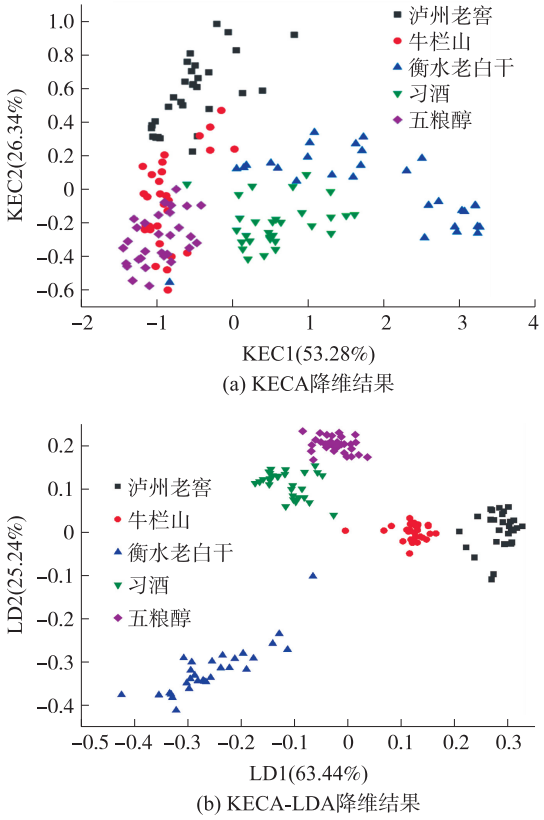

(a) KECA降维结果

(b) KECA-LDA降维结果

图 3 协同降维结果

KECA 的降维熵成分贡献率有明显提升。可以看出五种不同的白酒样本聚类效果明显,类内间距变小,类间间距增加,仅衡水老白干白酒的类间间距相对较大,但整体上仍取得了较好的降维效果。最终,取累计特征贡献率前 95%的 5 个主成分进行分类决策。

2.3 多模式识别结果

本文引入 SVM、RF、PNN 为多模式识别分类器,对不同特征集下的气味信息进行决策。同时,利用 Kennard-Stone(KS)方法对训练集和预测集进行划分,该方法可以使得训练集样本的广泛的分布,有助于加强模型的泛化能力[25]。基于 KS 方法,每类白酒数据选择 15 个样本作为训练集,剩余的 15 个样本作为测试集。因此,五类不同白酒样本,训练集和预测集各包含 75 个样本。表 3 为不同特征集的多模式识别分类结果。整体上,在不同的特征集,SVM 的分类准确率高于 RF,RF 高于 PNN。综合特征集 KECA-LDA 在不同识别算法下的准确率高于 KECA 特征集,KECA 特征集高于原始融合特征。而不同单特征集的分类准确率在 77.33%~88.00%之间。结果显示,基于 SVM 的分类器在 KECA-LDA 特征集下获得最高分类准确率为 96%。图 4 为基于 KECA-LDA 特征集的多模式分类输出图,可以看出 SVM 在不同类别下的错分个数较少。

表 3 不同特征集的多模式分类结果 单位:%

分类器	稳态均值	最大值	积分值	能量值	融合特征	KECA	KECA-LDA
SVM	82.67	80	84	80	88	92	96
RF	82.67	80	82.67	82.67	88	90.67	93.33
PNN	80	77.33	82.67	80	85.33	86.67	90.67

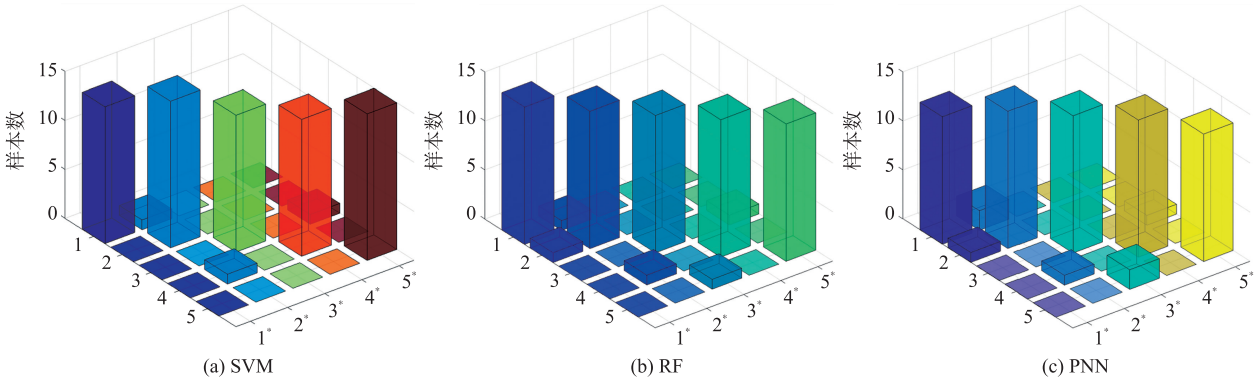

(a) SVM (b) RF (c) PNN

图 4 基于 KECA-LDA 特征集的多模式分类输出

在获得整体分类准确率的情况下,本文对各类内准确率进行对比分析。表 4~表 6 为 SVM、RF、PNN 在 KECA-LDA 特征集下的分类性能对比结果。SVM 共错分 3 个样本,其中泸州老窖被错分到牛栏山 1 个样本,衡水老白干被错分到五粮醇 1 个样本,习酒被错分到牛栏山 1 个样本。对比各类内准确率,相较与 RF、PNN,SVM 均取得了最好的分类效果,五种不同白酒的类内准确率分别为 93.33%、100%、93.33%、93.33%、100%。

表 4　基于 KECA-LDA 特征集的 SVM 分类性能

预测值	真实值						
	类别 1	类别 2	类别 3	类别 4	类别 5	类内准确率/%	平均准确率/%
类别 1 *	14	0	0	0	0	93.33	
类别 2 *	1	15	0	1	0	100	
类别 3 *	0	0	14	0	0	93.33	96
类别 4 *	0	0	0	14	0	93.33	
类别 5 *	0	0	1	0	15	100	

表 5　基于 KECA-LDA 特征集的 RF 分类性能

预测值	真实值						
	类别 1	类别 2	类别 3	类别 4	类别 5	类内准确率/%	平均准确率/%
类别 1 *	14	1	0	0	0	93.33	
类别 2 *	1	14	0	1	0	93.33	
类别 3 *	0	0	14	0	1	93.33	93.33
类别 4 *	0	0	0	14	0	93.33	
类别 5 *	0	0	1	0	14	93.33	

表 6　基于 KECA-LDA 特征集的 PNN 分类性能

预测值	真实值						
	类别 1	类别 2	类别 3	类别 4	类别 5	类内准确率/%	平均准确率/%
类别 1 *	13	1	0	0	0	86.67	
类别 2 *	2	14	0	1	0	93.33	
类别 3 *	0	0	14	0	2	93.33	90.67
类别 4 *	0	0	0	14	0	93.33	
类别 5 *	0	0	1	0	13	86.67	

3　结论

为了提升电子鼻的检测性能,本文提出了一种协同降维策略来对原始特征进行数据降维,进而降维分类器的决策难度。从 KECA 的无监督降维可视化图可以看出,不同白酒之间的类内间距较大,类间间距较小。在确定了 KECA 降维的特征个数后,基于 LDA 的有监督降维效果明显,有效减小了类内距离,增大了类间距离。从多模式识别结果可以看出,KECA-LDA-SVM 获得了最高的整体分类准确率 96%,高于 RF 的 93.33%,以及 PNN 的 90.67%。同时,各项类内准确率也达到了最高,有效提升了电子鼻的检测性能,也为白酒质量检测提供了一个有效的技术手段。

参考文献:

[1] Jia P,Meng F,Cao H,et al. Training Technique of Electronic Nose Using Labeled and Unlabeled Samples Based on Multi-Kernel LapsVM[J]. Sensors and Actuators B:Chemical,2019,294:98-105.

[2] Hu X,Lu L,Guo Z,et al. Volatile Compounds,Affecting Factors and Evaluation Methods for Rice Aroma:A Review[J]. Trends in Food Science & Technology,2020,97:136-146.

[3] 刘芳,杨康卓,张建敏,等. 基于电子鼻和气质联用技术的浓香型白酒分类[J]. 食品与发酵工业,2020,46(2):73-78.

[4] 庞林江,王俊,路兴花,等. 基于电子鼻技术的山核桃陈化指标预测模型研究[J]. 传感技术学报,2019,32(9):1303-1307.

[5] 卢君,唐平,山其木格,等. 不同封窖方式对酱香白酒基础酿造的影响[J]. 食品与发酵工业,2020,46(2):203-207.

[6] 邓依,齐慧,张文学. 白酒的生理功效及其评价方法浅析[J]. 酿酒,2009,36(1):15-17.

[7] 余建华,梁炽琼. 气相色谱-质谱法测定白酒中塑化剂残留前处理方法的优化[J]. 食品安全质量检测学报,2020,11(4):1247-1254.

[8] 白丽真,刘洪银,刘伟,等. 超高效液相色谱法检测白酒中乳酸含量的方法及方法确认[J]. 酿酒科技,2020,1:75-77.

[9] Qiu S,Gao L,Wang J. Classification and Regression of ELM,LVQ And SVM for E-Nose Data of Strawberry Juice[J]. Journal of Food Engineering,2015,144:77-85.

[10] Gu S,Wang J,Wang Y. Early Discrimination and Growth Tracking of Aspergillus Spp. Contamination in Rice Kernels Using Electronic Nose[J]. Food Chemistry,2019,292:325-335.

[11] 朱培逸,顾晓云,杜洁,等. 基于 KPCA 和 SOM 网络的电子鼻大闸蟹新鲜度评价[J]. 食品工业,2017,38(2):200-203.

[12] Mahmodi K,Mostafaei M,Mirzaee-Ghaleh E. Detection and Classi-

fication of Diesel-Biodiesel Blends by LDA, QDA and SVM Approaches Using an Electronic Nose[J]. Fuel, 2019, 258: 116114.

[13] Buratti S, Malegori C, Benedetti S, et al. E-nose, E-Tongue And E-Eye for Edible Olive Oil Characterisation and Shelf Life Assessment: A Powerful Data Fusion Approach[J]. Talanta, 2018, 182: 131-141.

[14] Ouyang Q, Zhao J, Chen Q. Instrumental Intelligent Test of Food Sensory Quality as Mimic of Human Panel Test Combining Multiple Cross-Perception Sensors and Data Fusion[J]. Analytica Chimica Acta, 2014, 841: 68-76.

[15] Peng X, Zhang L, Tian F, et al. A Novel Sensor Feature Extraction Based on Kernel Entropy Component Analysis for Discrimination of Indoor Air Contaminants[J]. Sensors and Actuators A: Physical, 2015, 234: 143-149.

[16] Jenssen R. Kernel Entropy Component Analysis[J]. IEEE Trans Pattern Anal Mach Intell, 2010, 32(5): 847-860.

[17] Zhang Y, Duan L, Duan M. A New Feature Extraction Approach Using Improved Symbolic Aggregate Approximation for Machinery Intelligent Diagnosis[J]. Measurement, 2019, 133: 468-478.

[18] Yuan Y, Wang S, Wang J, et al. Rapid Detection of the Authenticity and Adulteration of Sesame Oil Using Excitation-Emission Matrix Fluorescence and Chemometric Methods[J]. Food Control, 2020, 112: 107145.

[19] Qiu S, Wang J, Tang C, et al. Comparison of ELM, RF, and SVM on E-Nose and E-Tongue to Trace the Quality Status of Mandarin (Citrus Unshiu Marc.)[J]. Journal of Food Engineering, 2015, 166: 193-203.

[20] Haifeng W, Qing H, Daqing W, et al. A CNN-SVM Combined Model for Pattern Recognition of Knee Motion Using Mechanomyography Signals[J]. Journal of Electromyography and Kinesiology, 2018, 42: 136-142.

[21] 吴垒, 于哲舟. 基于概率神经网络的在线分类器[J]. 计算机技术与发展, 2019, 29(12): 14-20.

[22] Wang, Xia X. A Hybrid KPCA-PNN Approach to Condenser Fault Diagnosis with a Particle Swarm Optimizer[J]. Advanced Materials Research, 2010, 108-111: 476-481.

[23] 王猛, 张新长, 王家耀, 等. 结合随机森林面向对象的森林资源分类[J]. 摄影测量学与遥感, 2020, 49(2): 235-244.

[24] Kopp M, Pevny T, Holena M. Anomaly Explanation with Random Forests[J]. Expert System with Applications, 2020, 149: 113187.

[25] Li Y, Zhang J, Li T, et al. Geographical Traceability of Wild Boletus Edulis Based on Data Fusion of FT-MIR and ICP-AES Coupled with Data Mining Methods(SVM)[J]. Spectrochim Acta A Mol Biomol Spectrosc, 2017, 177: 20-27.

王 超(1975—),男,副教授,黑龙江省林口县人,现为河南工业职业技术学院电子信息工程学院教师,研究方向为计算机应用技术及网络,577887317@qq.com;

夏志平(1988—),男,讲师,江西九江人,现为九江职业技术学院机械工程学院教师。研究方向为控制理论与控制工程、智能检测技术,824922601@qq.com。