

DOI: 10.13652/j.issn.1003-5788.2021.01.025

基于 PCA-SVM 的红枣缺陷识别方法

Recognition method of jujube defects based on PCA-SVM

楚松峰 赵凤霞 方双 吴振华

CHU Song-feng ZHAO Feng-xia FANG Shuang WU Zhen-hua

(郑州大学机械与动力工程学院, 河南 郑州 450001)

(School of Mechanical and Power Engineering, Zhengzhou University, Zhengzhou, Henan 450001, China)

摘要:以干制红枣的黑斑、破头以及分类难度较高的干条 3 种病害图像作为研究对象,分别采用颜色矩和灰度共生矩阵提取颜色、纹理特征中的 14 维特征向量,然后采用主成分分析法对特征向量进行优化,得到 4 个主因素特征向量作为支持向量机输入。采用交叉算法确定最优支持向量机惩罚参数 c 和核函数参数 g 对支持向量机多分类模型进行训练,利用训练后的模型对红枣进行多分类试验。结果证明,该方法能够对红枣黑斑、破头和干条 3 种缺陷果进行快速准确的识别,识别率分别为 93.3%, 100.0% 和 96.6%, 总识别率可达 97.2%, 且分类效率高。

关键词:红枣缺陷识别;主成分分析法;支持向量机

Abstract: In this study, three kinds of disease images of jujubes, black spots, broken heads and dry strips with high classification difficulty were used as research materials. The color moment and gray level co-occurrence matrix were used to extract 14-dimensional eigenvectors of the color and texture features of jujube, and the principal component analysis method was used to optimize the features. Four principal factors of eigenvectors were obtained and then used as the input of support vector machine. The crossover algorithm was used to determine the optimal support vector machine penalty parameter c and kernel function parameter g , which was used as the parameter of the support vector machine multi-classification model to train the model. Using the trained model to perform multi-classification experiments on the jujube, the results proved that the three kinds of defects of jujube could recognized quickly and accurately, with the recognition rate at 93.3%, 100.0% and 96.6%, respectively. The classification accuracy of this model for jujube defects could reach 97.2%, with high efficiency.

Keywords: jujube defect recognition; principal component analysis; support vector machine

基金项目:国家重点研发计划项目(编号:2017YFF0206501-01)

作者简介:楚松峰,男,郑州大学在读硕士研究生。

通信作者:赵凤霞(1971—),女,郑州大学教授,博士。

E-mail: zfxmail@163.com

收稿日期:2020-07-28

红枣受到外部自然环境和采收运输的影响,表面会受到一定程度的损伤,产生黑斑、干条、破头等缺陷,这些缺陷影响着红枣的品质和等级。因而,红枣缺陷检测是红枣深加工过程中的一个重要环节。随着种植面积和产量的提升,单纯依靠传统的人工分级,工作量大、产能低、成本高,已经不能满足实际生产的需要。

近年来国内外许多学者针对红枣缺陷检测进行了相应研究,且取得了一定的进展。赵杰文等^[1]以河北金丝小枣为研究对象,利用红枣色调 H 的均值和方差特征,通过支持向量机对红枣油头、浆头和霉烂枣进行分类。由于提取的特征较少,只对霉烂果进行了分类,无法对干条、鸟啄等缺陷进行分类,分选的种类不足以满足实际生产需要。曾宛俊等^[2]对裂纹枣进行了分类,通过帧间路径搜索的方法获得图像中单个枣的位置坐标并构建数据集,再通过集成卷积神经网络的方式,构建多个卷积神经网络分别进行分类,最终根据分类结果选择最优解。海潮等^[3]根据红枣及其表面缺陷特征,提出在颜色空间中采用 BLOB 分析算法实现图像的分割及红枣缺陷的识别。该方法对干条缺陷识别率较低且速度较慢。

支持向量机(Support Vector Machine, SVM)在模式识别中有许多优势^[4],针对红枣缺陷类别较多,多种多分类思想能够对红枣所有缺陷进行同时分类。缺陷类别多也决定了必须采集较多特征来反映红枣的整个表面信息,如何准确选择区分度较高的输入特征是 SVM 研究运用中的一个重点。主成分分析法^[5](Principle Component Analysis, PCA)能够对提取的多维特征进行降维,找出描述原始目标对象的特征。基于以上分析,试验拟从实际工况下采集测试集,建立 PCA-SVM 的红枣缺陷检测模型,对红枣图像进行缺陷识别,能够在实际应用中保证高识别率的同时提高红枣缺陷识别效率,满足产能需求。

1 材料与试验平台

1.1 试验材料

新疆若羌干制红枣:以红枣表面是否存在黑斑、破头和干条缺陷进行筛选作为研究对象。

1.2 试验平台

红枣缺陷自动检测系统实验台如图 1 所示,包括输送装置和图像采集装置,其中图像采集装置由 MER-503-36U3C 型工业相机、日本 Computer 公司 M0814-MP 型工业镜头、LED 条形光源等组成。调节光圈大小为 2.0,快门速度设定为 0.1 s,一次采集多个红枣进行处理。图 2 为采集的一个样本图像,该图像中包括了无缺陷枣和黑斑、破头、干条 3 类缺陷枣。得到图像后,首先需要进行背景去除,从图像中提取出单个枣,然后对单个枣进行特征提取、优化及分类识别。

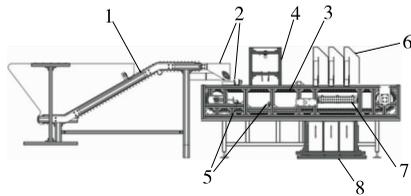
2 红枣表面特征的提取及优化

2.1 特征提取

图像特征提取是数字图像处理的关键步骤之一,关系到分类器的效率与准确度^[6]。常见的特征以属性不同分为形状特征、颜色特征和纹理特征,并称为图像的三大底层特征^[7]。

通过分析红枣各类缺陷图像可知,形状特征对于红枣分类识别意义并不大,而具有平移、旋转不变性的颜色特征和描述了图像中灰度排列规则,能够体现图像灰度变化的纹理特征来表示红枣表面信息较为理想。

基于颜色矩提取红枣图像 RGB 3 个颜色通道下的均值、方差颜色特征分量,共 3×2 个特征分量;基于灰度共生矩阵(Gray Level Co-occurrence Matrix, GLCM)计算色调 *H*、饱和度 *S* 下的能量、对比度、相关性和熵纹理特征分量,共 2×4 个特征分量。即提取的特征分量总计为 14 个。



1. 上料机构 2. 下料及排序机构 3. 鼓型输送轴 4. 上检测机构 5. 下检测机构 6. 分类箱 7. 喷吹机构 8. 收集箱

图 1 红枣缺陷自动检测系统试验台

Figure 1 Jujube automatic defect detection system test bench

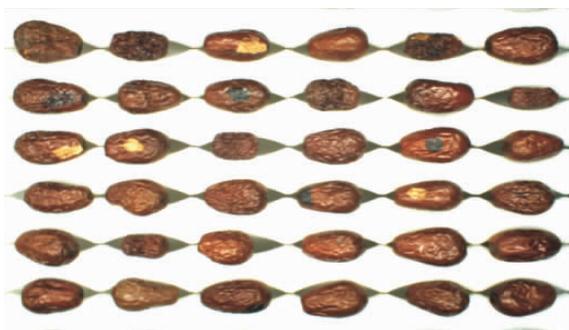


图 2 红枣图像样本

Figure 2 Jujube image samples

颜色矩是一种能够有效表示图像颜色分布的颜色特征^[8]。包括一阶矩(均值 μ_i)、二阶矩(方差 σ_i)和三阶矩(偏斜度 s_i),其数学定义:

$$\mu_i = \frac{1}{N} \sum_{j=1}^N P_{ij}, \quad (1)$$

$$\sigma_i = \left[\frac{1}{N} \sum_{j=1}^N (P_{ij} - \mu_i)^2 \right]^{\frac{1}{2}}, \quad (2)$$

$$s_i = \left[\frac{1}{N} \sum_{j=1}^N (P_{ij} - \mu_i)^3 \right]^{\frac{1}{3}}, \quad (3)$$

式中:

μ_i ——灰度均值;

σ_i ——灰度方差;

s_i ——灰度偏斜度;

N——像素个数;

P_{ij} ——第 *i* 个颜色通道中第 *j* 个像素的值。

GLCM 算法由 Haralick 等提出来描述物品的纹理状况,反映的是图像灰度关于方向、相邻间隔、变化幅度的综合信息^[9]。常用的有以下 4 个纹理特征:

(1) 能量:矩阵各元素的平方和。反映了图像灰度分布均匀程度和纹理粗细程度。

$$f_1 = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P^2(i, j), \quad (4)$$

式中:

f_1 ——能量;

L——灰度级数。

(2) 对比度:矩阵主对角线附近的惯性矩。反映了图像的清晰度和纹理沟纹的深浅。

$$f_2 = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} (i-j)^2 \left[\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P(i, j) \right], \quad (5)$$

式中:

f_2 ——对比度。

(3) 熵:体现了图像纹理的随机性。

$$f_3 = - \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P(i, j) \lg P(i, j), \quad (6)$$

式中:

f_3 ——熵。

(4) 相关性:反映了图像局部灰度相关性。

$$f_4 = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} \frac{P(i, j)}{1 + (i-j)^2}, \quad (7)$$

式中:

f_4 ——相关性;

$P(i, j)$ ——灰度共生矩阵的第 *i* 行、第 *j* 列的元素。

2.2 特征优化

在提取红枣特征时,尽可能多地提取了不同空间下的颜色和纹理特征,以期提高分类器的识别率,但这些特征会存在一定的信息交叉,同时特征数量过多,加重分类器设计时的复杂性,影响分类器的性能。

采用 PCA 算法对提取的 14 维颜色和纹理特征进行优化降维^[10],选取能够有效描述原始目标对象的特征,在保证高识别率的前提下,提高缺陷识别效率。具体过程:

(1) 初始指标数据的标准化:采集样本,构造样本阵,对样本阵元进行标准化变换:

$$Z = \frac{X_{ij} - \bar{X}_j}{S_j}, \quad (8)$$

式中:

$$\bar{X}_j = \frac{1}{n} \sum_{i=1}^n X_{ij};$$

$$S_j^2 = \frac{1}{n-1} \sum_{i=1}^n (X_{ij} - \bar{X}_j)^2;$$

Z ——标准化矩阵;

n ——样本个数;

X_{ij} ——第 i 个样本的第 j 维特征。

得到标准化矩阵 Z 。

(2) 对 Z 求相关系数矩阵:

$$R = \frac{Z^T Z}{n-1}, \quad (9)$$

式中:

R ——相关系数矩阵。

(3) 解样本相关矩阵 R 的特征方程 $|R - \lambda I_p| = 0$ 得 p 个特征根,确定主成分。

$$\text{按 } \frac{\sum_{j=1}^m \lambda_j}{\sum_{j=1}^p \lambda_j} > 0.9 \text{ 确定 } m \text{ 值,使特征信息的利用率达}$$

90%以上,对每个 λ_j ,解方程组 $Rb = \lambda_j b$ 得单位特征向量 b_j^0 。

(4) 将指标变量转换为主成分。

$$U_j = Z^T b_j^0, \quad (10)$$

式中:

U_j ——第 j 主成分。

(5) 对主成分进行综合评价:对 m 个主成分进行加权求和,即得最终评价值,从预选特征中求得主成分作为新的特征代入算法,用于模型的训练及分类。

3 基于 SVM 的缺陷识别

以支持向量机作为分类模型,将优化降维后的特征作为支持向量机输入特征。高斯核函数是一种对应非线性映射的核函数,可以处理非线性可分问题,因此采用高斯核函数、最优核函数参数 g 以及惩罚系数 c 对模型进行训练,用训练后的模型对红枣进行缺陷识别,提高缺陷识别准确率。

3.1 支持向量机

SVM 是一类按监督学习方式对数据进行二元分类的广义线性分类器^[11]。以学习样本求解的最大边距超平面为决策边界,得到以下优化目标:

$$\begin{cases} \min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i \\ \text{s.t. } g_i(\omega, b) = 1 - y_i(\omega^T x_i + b) - \xi_i \leq 0 \\ \xi_i \geq 0, i = 1, 2, \dots, n \end{cases}, \quad (11)$$

式中:

n ——样本个数;

i ——样本索引;

x_i ——训练样本;

y_i ——样本类别, $y_i \in \{-1, 1\}$;

ω, b ——主问题参数;

C ——惩罚因子;

ξ_i ——松弛变量。

针对目标求解最优化问题,构造拉格朗日函数:

$$\begin{cases} L(\omega, b, \xi, \lambda, \mu) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i + \\ \sum_{i=1}^n \lambda_i [1 - \xi_i - y_i(\omega^T x_i + b)] - \sum_{i=1}^n \mu_i \xi_i \\ \text{s.t. } \lambda_i \geq 0, \mu_i \geq 0 \end{cases}, \quad (12)$$

式中:

λ_i, μ_i ——拉格朗日乘子。

分别对主问题参数求偏导,得:

$$\begin{cases} \omega = \sum_{i=1}^n \lambda_i y_i x_i \\ 0 = \sum_{i=1}^n \lambda_i y_i \\ C = \lambda_i + \mu_i \end{cases}. \quad (13)$$

将式(13)代入拉格朗日函数[式(12)]中,得到:

$$\begin{cases} \max_{\lambda} \left[\sum_{i=1}^n \lambda_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j y_i y_j (x_i \cdot x_j) \right] \\ \text{s.t. } \sum_{i=1}^n \lambda_i y_i = 0, \lambda_i \geq 0, C - \lambda_i - \mu_i = 0 \end{cases}. \quad (14)$$

得到决策函数为:

$$f(x) = \text{sign} \left\{ \left[\sum_{i=1}^n \sum_{j=1}^n \lambda_i y_i (x_i \cdot x_j) \right] + b \right\}. \quad (15)$$

对于样本点线性不可分的情况,需要将二维线性不可分样本映射到高维空间中^[12]。映射高维空间后维度增加,加重计算的复杂度,因而引入核函数,在原始样本映射之前计算其内积。选取高斯核函数作为 SVM 核函数进行训练识别,其计算公式:

$$K(x_i, x_j) = \exp\left(-\frac{\|x_j - x_i\|}{2\beta^2}\right), \quad (16)$$

式中:

$\|x_j - x_i\|$ ——向量间的距离;

β ——给常数。

3.2 多类分类思想

红枣缺陷识别,需要对其黑斑、破头、干条以及正常

枣同时分类,涵盖类别较多,因而需要构造多分类 SVM,对 4 类枣进行准确高效的划分。多分类 SVM 是在二分类模型的基础上推广到 M 类的分类思想^[13]。针对红枣缺陷类别较多,选用一对一法^[14]进行多分类模型的构造。具体步骤:

对于给定含 N 个样本、 M 个类的训练集 X 。通过找到决策函数 $y = f(x)$,用于预测测试样本的类别。对于第 i 类和第 j 类数据,训练一个二分类 SVM 求解二次规划问题:

$$\begin{cases} \min \frac{1}{2} \|\omega^{ij}\|^2 + C \sum_t \xi_t^{ij} \\ \text{s.t. } (\omega^{ij})^T \Phi(X) + b^{ij} \geq 1 - \xi_t^{ij}, \text{ if } y_t = i, \\ (\omega^{ij})^T \Phi(X) + b^{ij} \leq -1 + \xi_t^{ij}, \text{ if } y_t = j \\ \xi_t^{ij} \geq 0, t = 1, 2, \dots, K \end{cases} \quad (17)$$

式中:

K —— i 类和 j 类样本数之和;

t —— i 类和 j 类并集中样本的索引;

y_t ——样本类别, $y_t \in \{i, j\}$;

ω^{ij} 、 b^{ij} ——主问题参数;

C ——惩罚因子;

ξ_t^{ij} ——松弛变量;

$\Phi(X)$ ——输入空间到特征空间的非线性映射。

然后求解式(17)的对偶问题。

共需训练 $C_M^2 = \frac{1}{2}M(M-1)$ 个二分类 SVMs。得

到第 i 类和第 j 类间二分类 SVM 的决策函数:

$$y_{\text{new}}^{ij} = \text{sign}[(\omega^{ij})^T \Phi(X) + b^{ij}] = \text{sign}\left[\sum \lambda_t^{ij} y_t K(x_t, x_{\text{new}}) + b^{ij}\right], \quad (18)$$

式中:

x_t ——训练样本;

x_{new} ——待预测样本;

$K(x_t, x_{\text{new}})$ ——核函数。

式(18)用于判断数据是属于 i 类还是 j 类。

对于新数据,采用投票策略进行分类,每个二分类 SVM 都会对测试样本进行预测,通过预测的结果对所属类别进行投票,票数最多的类别即对测试样本的决策。

3.3 交叉算法寻优

将原始样本分为 n 份,依次取每一份作为测试样本,剩余 $n-1$ 份样本作为训练样本训练分类器对测试样本进行分类,一次循环后,对于某一组给定的参数对 (c, g) ,共得到 n 个识别率,求取 n 个识别率的平均值,作为该参数对应的性能指标,当遍历了所有可能的参数对后,比较相邻参数对的性能指标,由此得到最优惩罚系数 c 和核函数参数 g ,作为 SVM 的参数。

4 试验结果和分析

构造支持向量机分类器,首先需要提取训练集的特

征,作为支持向量机的输入对模型进行训练。以黑斑、破头、干条和无缺陷枣 4 类干制红枣作为试验对象,每类采集 15 个作为训练集样本。图 3 为无缺陷红枣训练集样本图像。

特征提取前,对图像进行预处理,去除输送带背景,并分离出每个红枣。首先将训练集样本图像转换至 HSV 颜色空间,得到图像的 S 分量图像(如图 4 所示);对 S 分量图像运用直方图进行阈值分割,将背景区域与红枣区域分割开,然后进行腐蚀、膨胀、填充和形态转化等处理,消除背景干扰;最后进行连通域分析和特征提取,得到去除输送带背景的红枣区域图像,如图 5 所示。

分离得到每个红枣区域后,对红枣进行特征提取。按 2.1 所述,分别基于颜色矩和灰度共生矩阵提取 RGB 3 个颜色通道下的均值、方差共 6 个颜色特征分量;色调 H 、饱和度 S 下的能量、对比度、相关性和熵共 8 个纹理特征分量,总计 14 个特征。

为了在 14 个原始特征集中初步确定能够保持样本分类能力的特征子集,对训练集样本分别提取 4 类红枣在每一维特征下的特征值,得到每个特征下每一类红枣的特征值范围,并进行排列,结果如图 6 所示。在同一特征下,假设 A 类枣的特征值范围和其他类枣的特征值范围没有重叠,说明该特征对于 A 类枣具有较好的区分度,将其选为支持向量机的输入特征。由图 6 可知:图像 R 通道下的均值和方差特征,色度 H 分量下的能量、熵和



图 3 无缺陷红枣训练集样本图像

Figure 3 Sample image of the defect-free jujube training set

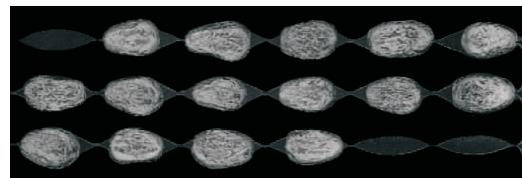


图 4 HSV 空间内的 S 分量图像

Figure 4 S-component image in HSV space

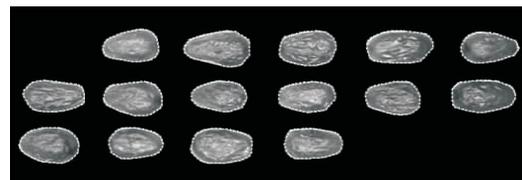


图 5 去除背景后的红枣区域图像

Figure 5 The complete jujube region image without background

对比度特征;饱和度 S 分量下的能量、相关性和对比度特征,共有 8 个特征组成了最优特征子集 X 。

运用 SPSS 软件对红枣特征子集 X 进行 PCA 分析,计算结果如图 7 所示。由图 7 可以看出, $P=4$ 时,特征值对应的累计贡献率已达 93.26%,能够代表原始数据具有的信息。因此,取前 4 个主成分组成向量 Y 作为红枣图像的特征向量代替原特征向量 X ,作为支持向量机的输入特征。

利用 PCA 对训练集样本特征矩阵降维处理后,得到了 4 个主成分,将其转化为 PC4 数组矩阵,归一化处理后作为支持向量机的输入。支持向量机内核选用高斯核函数,分类方法选用一对一法,惩罚参数 $c=0.05$,核函数参数 $g=0.05$ 作为支持向量机模型参数对测试集进行识别。

测试集:无缺陷枣 90 个,黑斑、破头和干条枣各 30 个,共 180 个测试样本混合后,放置于试验台中,在同一环境下采集 5 幅图像,每幅图像包含 36 个枣,得到的测试结果见表 1。图 8 为对一幅红枣图像样本缺陷识别的结果。

由表 1 可以看出,运用 PCA 对提取到的红枣表面特征进行优化处理,将降维后的特征矩阵应用到支持向量机分类器的训练中,通过调整支持向量机各项参数,能够得到综合识别率为 97.2% 的分类结果。其中,破头枣和干条枣的识别率较高,可以达到 100.0% 和 96.6%。与文献[3]提出的采用 BLOB 分析算法进行红枣缺陷识别得

表 1 $PC=4$ 的 SVM 模型测试集识别结果

Table 1 $PC=4$ SVM model test set recognition result

红枣类型	待识别样本数	正确识别数	识别率/%
破头	30	30	100.0
黑斑	30	28	93.3
干条	30	29	96.6
无缺陷枣	90	88	97.7
总计	180	175	97.2

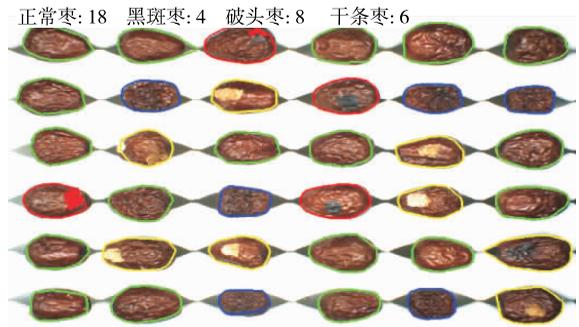


图 8 缺陷识别结果图

Figure 8 Defect recognition result image

到的破头枣准确率 98.3%、黑斑枣准确率 92.5% 相比,文中提出的方法缺陷识别准确度高,同时对目前现有文献鲜有研究的红枣干条缺陷进行了研究。

在缺陷识别效率方面,采用 PCA 进行了特征降维处理,减轻了分类器的计算复杂度,缩短了缺陷识别时间,平均一个枣识别用时 15 ms(运行环境是 Intel 酷睿 i5 8G 处理器的计算机硬件平台)。

由表 1 可知,该模型对黑斑枣的识别率只有 93.3%,其主要原因是由光照导致处于边缘部位的红枣颜色较深,黑斑枣表面的黑色病害区域不明显,从而产生一定的误差,后续将从光源的布置等方面对其采集装置进行改进。

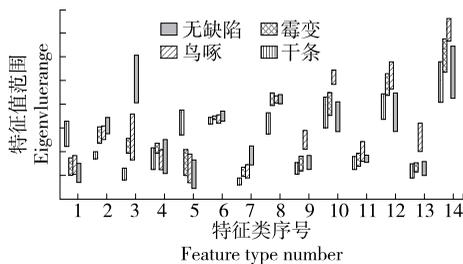
5 结束语

为了提高红枣缺陷识别的准确率和效率,提出了一种基于 PCA 与 SVM 的红枣缺陷分类方法,利用 PCA 来对多维特征矩阵进行优化降维以获取低维特征矩阵。然后将降维后的优化特征矩阵应用于 SVM 分类器来实现对红枣 4 类缺陷的分类训练。结果表明,通过运用 PCA 对 SVM 输入特征进行优化处理,能够在保证红枣缺陷识别准确率高的同时,提高模型识别效率。但模型对黑斑枣的识别率较低,后续将针对黑斑缺陷对图像采集装置和算法模型进行优化改进。

参考文献

[1] 赵杰文,刘少鹏,邹小波,等.基于支持向量机的缺陷红枣机器视觉识别[J].农业机械学报,2008(3):113-115,147.

(下转第 198 页)



1、2、3、4 分别表示色度 H 分量下的对比度、熵、能量和相关性; 5、6、7、8 分别表示饱和度 S 分量下的对比度、熵、能量和相关性; 9、10、11、12、13、14 分别表示 RGB 三通道的方差和均值

图 6 4 类红枣不同特征的对比如

Figure 6 Comparison chart of different characteristics of four types of red dates

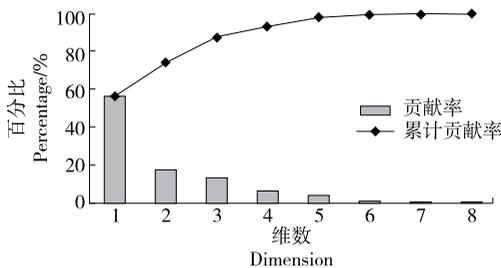


图 7 贡献率与累计贡献率图

Figure 7 Contribution rate and cumulative contribution rate graph

- [11] 吕倩, 邓泽新, 吴颖, 等. 婴幼儿营养米粉加工过程中营养素损耗研究[J]. 粮食与饲料工业, 2018(8): 7-9, 17.
- [12] 包清彬. 日本大米食味理化测定[J]. 食品科技, 2006(2): 83-86.
- [13] 李少寅, 舒在习. 米汤碘蓝值测定条件的探讨[J]. 粮食与饲料工业, 2014(4): 5-7.
- [14] 江帆. RVA 仪分析不同添加物对大米粉糊化特性的影响[J]. 食品研究与开发, 2013, 34(8): 74-77.
- [15] 郎凯红. 大米凝胶特性的评价与检测[D]. 郑州: 河南工业大学, 2012: 16-18.
- [16] 夏凡, 董月, 朱蕾, 等. 大米理化性质与其食用品质相关性研究[J]. 粮食科技与经济, 2018, 43(5): 100-107.
- [17] 吴伟, 李彤, 蔡勇建, 等. 三种稻米在贮藏过程中蒸煮特性变化的比较[J]. 食品与机械, 2014, 30(3): 122-126.
- [18] TRAN T U, SUZUKI K, OKADOME H, et al. Detection of changes in taste of japonica and indica brown and milled rice during storage using physicochemical analyses and a taste sensing system[J]. Journal of Agricultural and Chemistry, 2005, 53(4): 1108-1118.
- [19] 周显青, 祝方清, 张玉荣, 等. 不同储藏年限稻谷的蒸煮特性及其米饭的食味和质构特性分析[J]. 河南工业大学学报(自然科学版), 2020, 41(1): 96-103.
- [20] 程威威, 吴跃, 周婷, 等. 发芽糙米蒸煮食用品质相关性研究[J]. 粮食与油脂, 2014, 27(3): 39-44.
- [21] LELOUP V M, COLONNA P, BUELON A. Influence of amylose-amylopectin ratio on gel properties[J]. J Cereal Science, 1991, 13: 1-13.
- [22] 李安平, 蒋雅茜, 周玉杰, 等. 米糠膳食纤维对大米淀粉糊化特性的影响[J]. 江西农业大学学报, 2015, 37(4): 725-732.
- [23] KONG Xiang-li, ZHU Ping, SUI Zhong-quan, et al. Physicochemical properties of starches from diverse rice cultivars varying in apparent amylase content and gelatinisation temperature combinations[J]. Food Chemistry, 2015, 172: 433-440.
- [24] TONG Chuan, CHEN Ya-ling, TANG Fu-fu, et al. Genetic diversity of amylase content and RVA pasting parameters in 20 rice accessions grown in Hainan, China[J]. Food Chemistry, 2014, 161: 239-245.
- [25] JANG E H, LEE S J, HONG J Y, et al. Correlation between physicochemical properties of japonica and indica rice starches[J]. LWT-Food Science and Technology, 2016, 66(3): 530-537.
- [26] 赵思明, 熊善柏, 俞兰苓. 稻米淀粉糊老化动力学研究[J]. 农业工程学报, 2003, 19(1): 37-39.
- [27] 廖卢艳, 吴卫国. 不同淀粉糊化及凝胶特性与粉条品质的关系[J]. 农业工程学报, 2014, 30(15): 332-338.
- [28] ISONO H, OHTSUBO K, IWASAKI T, et al. Eating quality of domestic and foreign rices of various varieties and characteristics[J]. Journal of the Japanese Society of Food Science and Technology-Nippon Shokuhin Kogyo Gakkaishi, 1994, 41: 485-492.
- [29] 陈新峰, 徐龙, 钱锋, 等. 基于快速黏度分析仪评价婴幼儿营养米粉品质[J]. 浙江农业科学, 2016, 57(8): 1260-1263.
- [30] 王鹏跃, 路兴花, 庞林江. 影响米饭质构特性和感官的关键理化因素分析[J]. 食品工业科技, 2016, 37(2): 119-124.
- [31] 詹耀. 超高压处理对糙米物性品质的影响研究[D]. 杭州: 浙江大学, 2014: 20-27.
- [32] 李苏红, 宋媛媛, 董墨思, 等. 大米理化特性与食味品质的相关性分析[J]. 食品研究与开发, 2017, 38(23): 26-31.

(上接第 160 页)

- [2] 曾宛俊, 吴俊杭, 马本学, 等. 基于帧间路径搜索和 E-CNN 的红枣定位与缺陷检测[J]. 农业机械学报, 2019, 50(2): 307-314.
- [3] 海潮, 赵凤霞, 孙烁. 基于 Blob 分析的红枣表面缺陷在线检测技术[J]. 食品与机械, 2018, 34(1): 126-129.
- [4] 王春普, 文怀兴, 王俊杰. 基于机器视觉的大枣表面缺陷检测[J]. 食品与机械, 2019, 35(7): 168-171.
- [5] 范雪莉, 冯海泓, 原猛. 基于互信息的主成分分析特征选择算法[J]. 控制与决策, 2013, 28(6): 915-919.
- [6] 夏永泉, 李耀斌, 李晨. 基于图像处理技术的小麦叶部病害识别研究[J]. 科技通报, 2016, 32(4): 92-95.
- [7] 韩丁, 武佩, 张强, 等. 基于颜色矩的典型草原牧草特征提取与图像识别[J]. 农业工程学报, 2016, 32(23): 168-175.
- [8] STRICKER A M A, ORENGO M. Similarity of color images[J]. Proceedings of SPIE-the International Society for Optical Engineering, 1970, 2420: 381-392.
- [9] TAN Jia-xing, GAO Yong-feng, LIANG Zheng-rong, et al. 3D-GLCM CNN: A 3-dimensional gray-level co-occurrence matrix-based CNN model for polyp classification via CT colonography[J]. IEEE Transactions on Medical Imaging, 2020, 39(6): 2013-2024.
- [10] 李康顺, 李凯, 张文生. 一种基于改进 BP 神经网络的 PCA 人脸识别算法[J]. 计算机应用与软件, 2014, 31(1): 158-161.
- [11] XU Li-xiang, WANG Xiao-feng, BAI Lu, et al. Probabilistic SVM classifier ensemble selection based on GMD H-type neural network[J]. Pattern Recognition, 2020, 106: 107373.
- [12] 唐发明, 王仲东, 陈绵云. 支持向量机多类分类算法研究[J]. 控制与决策, 2005(7): 746-749, 754.
- [13] HSU Chih-wei, LIN Chih-jen. A comparison of methods for multiclass support vector machines[J]. IEEE Transactions on Neural Networks, 2002, 13(2): 415-425.
- [14] TOMAR D, AGARWAL S. A comparison on multiclass classification methods based on least squares twin support vector machine[J]. Knowledge Based Systems, 2015, 81: 131-147.