

doi:10.6041/j.issn.1000-1298.2015.11.034

油桃外部缺陷的高光谱成像检测*

黄锋华^{1,2} 张淑娟² 杨一² 满尊² 张学豪² 吴玉香³

(1. 山西农业大学信息科学与工程学院, 太谷 030801; 2. 山西农业大学工学院, 太谷 030801

3. 山西农业大学农学院, 太谷 030801)

摘要: 采用高光谱(420~1 000 nm)成像技术对“中油9号”油桃的4种外部缺陷(裂纹果、锈病果、异形果和暗伤果)进行检测判别。对400个样本(4种外部缺陷样本和完好样本)运用偏最小二乘回归(PLSR)从全波段中分别提取了10条特征波长,分别为497、534、657、677、696、709、745、823、868、943 nm。缺陷样本的高光谱图像经过主成分分析后,对876 nm下的单波段图像通过掩膜、Sobel算子处理,并对主成分图像经过区域生长算法实现缺陷样本的缺陷区域分割。对光谱数据进行主成分分析得到前10个主成分值,并对图像数据采用灰度共生矩阵(GLCM)提取得到6项图像纹理指标(均值、对比度、相关性、能量、同质性、熵值)。将主成分值和纹理值融合建立极限学习机(ELM)模型对油桃外部缺陷进行检测判别。结果表明,该模型对缺陷样本的判别正确率为91.67%,完好样本的正确率为100%。

关键词: 油桃 外部缺陷 高光谱成像 无损检测 极限学习机

中图分类号: S123; S665 **文献标识码:** A **文章编号:** 1000-1298(2015)11-0252-08

Application of Hyperspectral Imaging for Detection of Defective Features in Nectarine Fruit

Huang Fenghua^{1,2} Zhang Shujuan² Yang Yi² Man Zun² Zhang Xuehao² Wu Yuxiang³

(1. College of Information Science and Engineering, Shanxi Agricultural University, Taigu 030801, China

2. College of Engineering, Shanxi Agricultural University, Taigu 030801, China

3. College of Agronomy, Shanxi Agricultural University, Taigu 030801, China)

Abstract: Hyperspectral imaging, an emerging analytical technology for quality and safety inspections of agricultural and sideline products, combines the advantages of digital image or computer vision with spectroscopy technology in the whole system. Hyperspectral imaging can simultaneously acquire both spatial and spectral information, which deliver chemical, structural and functional information from the samples. In this work, hyperspectral imaging technology was applied to determine a classifier that can be used for nondestructive deflection of the defective features in “No. 9 of Zhongyou” nectarine fruit. There were 400 samples from a nectarine planting garden in the Wan'an Village in Yuncheng City of Shanxi Province, China, including: crack(50), peel spots(50), malformation(50), hidden damage(50) and normal(200) samples. Hyperspectral imaging technology covered the range of 420~1 000 nm was employed to detect defects (crack, peel spots, malformation and hidden damage) of nectarine fruit. 400 RGB images were acquired through a total of 400 samples, which included four types of defective features and sound samples. After acquiring hyperspectral images of nectarine fruits, the spectral data were extracted from region of interest (ROI). Using Kennard - Stone algorithm, all kinds of samples were randomly divided into training set (280) and testing set (120). First of all, based on the calculation of

收稿日期: 2015-04-13 修回日期: 2015-05-15

* 国家自然科学基金资助项目(31271973, 31171599)和山西省自然科学基金资助项目(2012011030-3)

作者简介: 黄锋华, 讲师, 博士生, 主要从事农产品无损检测研究, E-mail: fhhuangsxau@163.com

通讯作者: 张淑娟, 教授, 博士生导师, 主要从事农产品无损检测研究, E-mail: zsujuan1@163.com

partial least squares regression (PLSR), 10 wavelengths at 497 nm, 534 nm, 657 nm, 677 nm, 696 nm, 709 nm, 745 nm, 823 nm, 868 nm and 943 nm were selected as the optimal sensitive wavelengths (SWs), respectively. Subsequently, the image of the 876 nm wavelength was named as the feature image, then principal component analysis (PCA), mask process, “Sobel” edge detector and “region grow” algorithm were carried out among defective and normal nectarines to extract the defective region. Moreover, ten principal components (PCs) were selected based on PCA, and seven textural feature variables (mean, contrast, correlation, energy, homogeneity and entropy) were extracted by using gray level co-occurrence matrix (GLCM), respectively. Finally, the ability of hyperspectral imaging technique was tested by using the extreme learning machine (ELM) models. The ELM classification model was built based on the combination of PCs and textural features. The results show the correct discrimination accuracy of defective samples was 91.67%, and the correct discrimination accuracy of normal samples was 100%. The research revealed that the hyperspectral imaging technique is a promising tool for detecting defective features in nectarine, which could provide a theoretical reference and basis for designing classification system of fruits in further work.

Key words: Nectarine Defective feature Hyperspectral imaging Nondestructive detection Extreme learning machine

引言

油桃既是营养丰富的水果,又是天然的保健品,以其果皮光滑无毛、色泽艳丽、风味浓甜,深受人们的喜爱^[1]。油桃果实在生长过程中及收获前,常出现裂纹、锈病、异形、暗伤等多种类型的外部缺陷,而这些缺陷的存在严重影响了油桃的产量和品质。

目前,针对油桃的检测主要以人工分拣为主,通过人工对外部缺陷损伤果等进行分拣,然后再用现有的分级设备进行大小分级,进而分装出售。由于人工分拣的效率较低,分拣精度也较低,对诸如暗伤果的分拣难度也较大。高光谱成像技术是一种光谱和图像的融合技术,具有分辨率高、波段多等特点,近年来在水果外部缺陷检测方面应用广泛^[2-5]。本文使用高光谱技术实现对油桃外部缺陷果实的检测,用以解决当下使用人工进行油桃分选效率低的弊端。

本文选取“中油 9 号”油桃作为研究对象,运用高光谱成像系统采集裂纹果、锈病果、异形果、暗伤果以及完好果实的图像信息,运用图像处理技术实

现对油桃外部缺陷区域分割,同时采用光谱主成分数值及图像特征纹理指标值对缺陷果和完好果进行判别分类。从光谱和图像分析 2 方面对油桃外部缺陷样本进行快速、准确识别,为油桃外部缺陷的在线判别研究提供理论依据。

1 实验材料与方法

1.1 样本采集

“中油 9 号”油桃样品采购于山西省运城市万安村。为保证研究的可靠性,采摘时以形状相近、大小(单果质量 100 ~ 105 g)均匀和缺陷类型(完好和 4 种缺陷类型)齐全为原则。共选取 400 个样品,包含裂纹果样本 50 个、锈病果样本 50 个、异形果样本 50 个、暗伤果样本 50 个和完好样本 200 个。图 1 为外部缺陷和完好油桃的样本图。

裂纹果是在果实将近成熟时遇水,果面纵向或横向开裂,果肉外露,随之裂果腐烂变酸,不堪食用,见图 1b。锈病果是一种真菌性病害,当果皮表面受到外界摩擦或刺伤时果面出现一层锈斑,影响外观;随着病原的侵染果实开始失水皱缩,出现大量落果

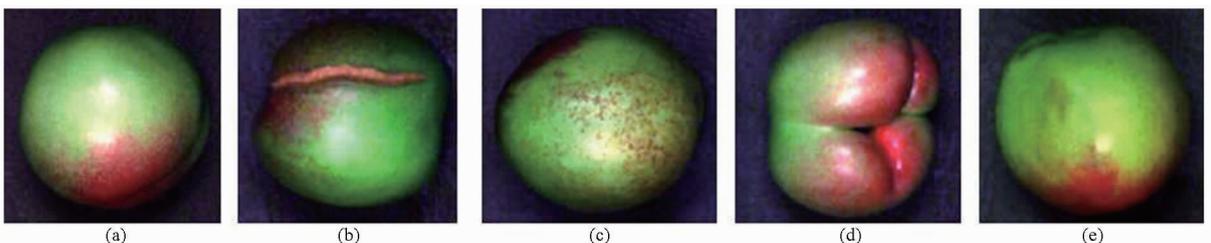


图 1 油桃完好及缺陷典型样本图

Fig. 1 Typical samples of normal and defective nectarine

(a) 完好果 (b) 裂纹果 (c) 锈病果 (d) 异形果 (e) 暗伤果

造成大面积减产或绝收,见图1c。异形果一般是在果树开花坐果的时候花的心室未联合好或几个心室联合在一起形成的,异形果对油桃的销量和价格会造成影响,见图1d。暗伤果,即果实受到损伤后果皮处有轻微凹陷,色泽几乎不变,肉眼难于觉察,无汁液外流,但易变质,且果实损坏部分易于感染其他果实,见图1e。

依据 Kennard - Stone 算法,对 5 类(裂纹果、锈病果、异形果、暗伤果、完好果)样本按照一定比例分为校正集 280 个和预测集 120 个。划分结果见表 1。

表 1 Kennard - Stone 算法划分样本结果

Tab.1 Results of sample sets selected by Kennard - Stone algorithm

样本类型	样本总数	校正集样本数	预测集样本数
裂纹果	50	35	15
果锈病果	50	35	15
异形果	50	35	15
暗伤果	50	35	15
完好果	200	140	60
共计	400	280	120

1.2 仪器设备

实验中使用的的高光谱成像系统由 2 个 150 W 的光纤卤素灯 (Illumination, USA)、ImSpector V10E 型光谱仪 (Specim Finland)、ImSpector V10E 型 CCD 探测器以及 C-mount 成像镜头 OLE23 型 (ImSpector V10E 系统)、电控移动平台 (IRCP0076 型)、计算机和暗箱等辅助设备构成。

图像采集过程中需要设置合理的曝光时间以及移动平台的移动速度,以免出现信息过度饱和与成像失真的现象^[6]。经多次实验最终确定曝光时间 $t = 0.13$ s,样本与镜头的距离 $h = 340$ mm,传送带移动速度 $v = 2.2$ mm/s。为了准确地收集到各个区域的光谱数据,在采集不同样本光谱时,分别将目标区域面向镜头。

2 高光谱数据分析方法

本研究中的数据处理和分析由 ENVI 4.7 (ITT Visual Information Solutions, Boulder, 美国), Matlab R2010b (The MathWorks, Natick, 美国), The Unscrambler X10.1 (CAMO AS, Oslo, 挪威), Origin 8.5 (Origin Lab, 美国) 等软件来实现。图 2 为本研究基本流程图。

2.1 黑白校正

为了消除光强变化和镜头中暗流对成像的影响以及计算扫描物体的相对反射光谱值,要在光谱采

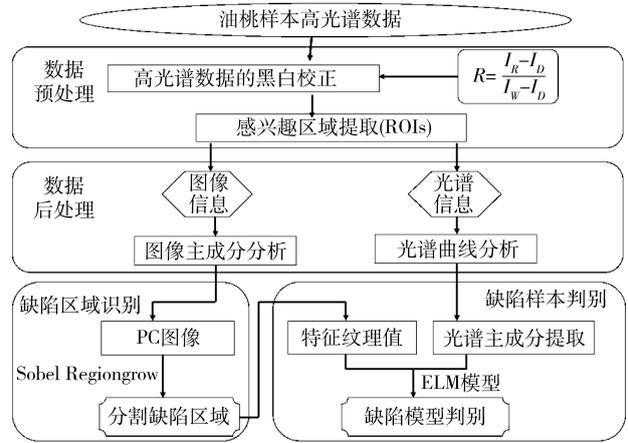


图 2 油桃表面缺陷判别流程图

Fig.2 Schematic diagram of current study

集前进行黑板校正^[7]。计算公式为

$$R = \frac{I_R - I_D}{I_W - I_D} \quad (1)$$

式中 R ——校正后图像

I_R ——原始图像

I_D ——黑板校正图像

I_W ——白板校正图像

2.2 特征主成分提取

主成分分析 (Principal component analysis, PCA) 就是一种去除波段之间多余信息、将多波段信息压缩到比原波段更有效的少数几个转换波段的方法。该方法不仅可以避免信息间的互相重叠,而且通过数据简化,可提取最具代表性的变量子集,且变量之间互不相关^[8]。因此,本研究采用 PCA 对可见/近红外 (420 ~ 1 000 nm) 范围内的油桃光谱及图像数据进行降维处理,获得主成分 (Principal components, PC) 光谱数据及图像数据。根据主成分的贡献率,确定用于后续研究的光谱及图像数据。

2.3 特征纹理指标提取

纹理作为一种区域特征,是对于图像各像元之间空间分布的一种描述,它能更好地兼顾图像宏观性质与细微结构,因此,本研究采用纹理特征来描述外部缺陷油桃与完好油桃之间的差异。灰度共生矩阵 (Gray level co-occurrence matrix, GLCM) 是关于图像亮度变化的二阶特征统计^[9]。GLCM 是从图像灰度为 i 的像元 (i, j) 出发,统计与其距离为 d 、灰度为 j 的像元 ($x + a, y + b$) 同时出现的频度 $P(i, j, d, \theta)$, 数学表达为

$$P(i, j, d, \theta) = \{ (x, y), (x + a, y + b) \mid f(x, y) = i; f(x + a, y + b) = j \} \quad (2)$$

其中, θ 为 GLCM 的生成方向,一般常用 0° 、 45° 、

90°、135°这4个方向,在本文中使用0°方向上的位置。本研究对灰度共生矩阵产生的6个纹理参数,即均值(Mean)、对比度(Contrast)、相关性(Correlation)、能量(Energy)、同质性(Homogeneity)、熵(Entropy),分别对0°方向上的纹理特征进行对比,参数具体计算公式见文献[10]。

2.4 检测模型

极限学习机(Extreme learning machine, ELM)是由单隐层前馈神经网络(SLFN)发展起来的一种神经网络算法。根据Huang等^[11]研究结果,在SLFN中,当隐含层神经元的激活函数 $g(x)$ (常用的激活函数有sigmoid、sin和hardlim等)无限可微时,对任意的输入层与隐含层之间的连接权值 ω 和隐含层的偏置 b ,只要隐含层神经元个数 K 小于等于训练集样本数 Q ,SLFN网络的训练误差都可逼近一个任意小的数 ε ($\varepsilon > 0$,且 $K = Q$ 时,误差为零)。传统SLFN网络(如BP神经网络算法)存在训练速度慢、陷入局部而非全局最小、学习率选择敏感等问题。而ELM算法只需要设置隐含层的神经元个数,即可得到唯一的最优解, ω 和 b 等参数随机产生且保持不变。ELM以其快速的学习能力、良好的泛化性、简单的参数设置等优点,广泛应用于各个领域^[12-13]。

3 结果与讨论

3.1 油桃表面缺陷的平均光谱曲线分析

感兴趣区域(Region of interest, ROI)即图像中最能引起用户兴趣,最能表现图像内容的区域,如能提取出这些区域将会大大提高图像处理和效率的效率和准确度^[14]。本研究中,实验样本“中油9号”油桃样本为近圆形且表面光滑,光照在整个果实表面呈现中间亮边缘暗的分布。为了使光照不均信息对光谱强度影响最低^[15],在使用ENVI 4.7软件感兴趣区域函数的手动提取时,应避免反光过强的区域。4种外部缺陷样本(裂纹果、锈病果、异形果、暗伤果)选取缺陷区域周围30像素×30像素作为感兴趣区域,完好样本选取完好区域周围30像素×30像素作为感兴趣区域,由此得到4种外部缺陷样本以及完好果样本的光谱数据,然后求取各自的平均光谱,并将含有大量噪声的波段去除,只保留420~1000 nm波段对应的吸收光谱(图3)进行后续研究。

观察完好油桃样本的光谱曲线可知,样本在680 nm和980 nm处出现2处明显吸收峰,并在442、470、623、740、832 nm处出现小的吸收峰。其中,在442~680 nm波段内出现的吸收峰主要是由

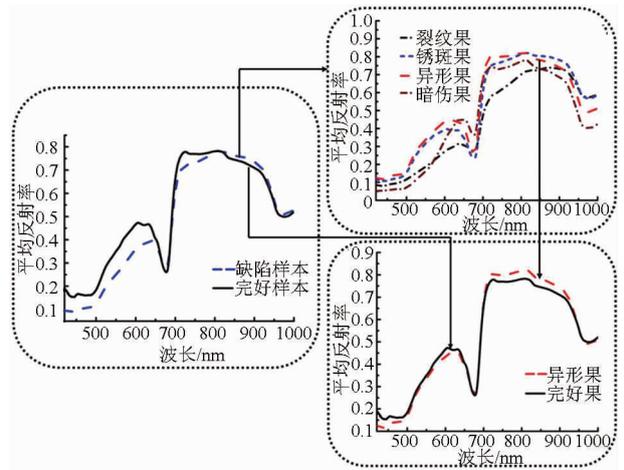


图3 油桃完好与缺陷样本的平均光谱曲线

Fig. 3 Average spectral curves of normal and defective nectarine samples

于油桃果实表皮及内部果肉细胞中叶绿素和类胡萝卜素对光谱的吸收作用引起的^[16];在740 nm和980 nm处的吸收峰主要由油桃内部水分的吸收引起的,这2个波段分别为水中O—H基团的组合频及二级倍频特征吸收峰^[17];832 nm处出现的吸收峰反映了油桃果实中糖分的含量。

Abbott等^[18]的研究表明,在缺陷样本的组织中其叶绿素含量小于正常果实组织中的含量。由图3缺陷与完好样本光谱图可知,在可见光区域(420~780 nm)两类样本的光谱曲线差异较大,且完好样本的反射率高于缺陷样本,这种差异可能是由于果肉细胞组织结构的不同造成的;而在近红外区域(780~1000 nm)两类样本的光谱曲线趋势一致,差异变小,且缺陷样本的反射率高于完好样本。这与Abbott等的研究结果相一致。

通过观察各类缺陷样本的光谱曲线可知,各类缺陷样本的光谱曲线差异较大且重叠交错现象较为严重,表明可以通过缺陷样本与完好样本的光谱变化达到缺陷识别的目的。比较完好果与异形果的光谱曲线,可以看出这两类样本的光谱曲线趋势高度一致,在700~900 nm波段存在的微弱差异主要是由于异形果采集到的ROI区域中含有果实腹缝区域造成的,因此可知,无法通过单纯的光谱分析实现对完好果和异形果的分类判别。

3.2 光谱主成分分析

对预测集120个油桃样本(外部缺陷60个、完好60个)的光谱数据进行主成分分析(PCA),得到缺陷和完好样本前3个主成分的散点分布如图4所示。

由图4可以看出,完好样本聚类效果好,只有少数几个样本发生偏离现象。由于缺陷样本是由4种

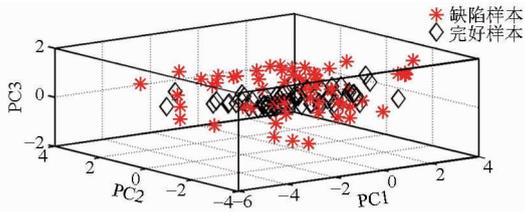


图4 前3个主成分的散点分布图

Fig. 4 Scatter plot of nectarine samples of the first three principal components

不同种类的外部缺陷类型(裂纹果、锈病果、异形果、暗伤果)构成,故较完好样本而言分类比较零

表2 前10个主成分的累计贡献率

Tab. 2 Accumulated credibility of the first 10 principal components

主成分	1	2	3	4	5	6	7	8	9	10
累计贡献率/%	79.59	95.87	98.28	99.14	99.66	99.79	99.82	99.87	99.89	99.91

3.3 缺陷区域分割

3.3.1 特征波长提取

偏最小二乘回归(Partial least squares regression, PLSR)法是基于PLS的算法原理,通过选取回归系数(Regression coefficient, RC)中的局部极值对最佳敏感波段进行选择^[19-20]。每个波长点所对应的回归系数的绝对值越大表明该波长对所建模型预测性能的影响也就越大。因此,本文根据波长所对应的回归系数的局部极值来提取特征波长,结果如图5所示。

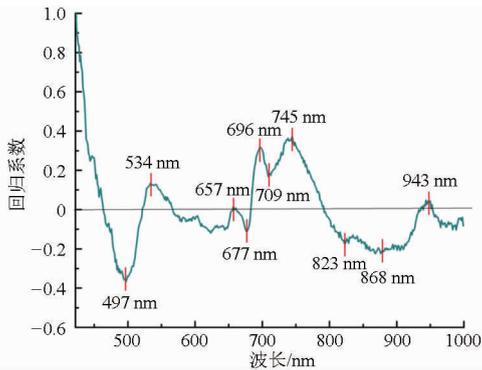


图5 PLSR模型的回归系数

Fig. 5 Regression coefficients of PLSR model

如图5所示,本研究通过PLSR的RC选取了497、534、657、677、696、709、745、823、868、943 nm共10个特征波长。

3.3.2 图像主成分分析

对10条特征波长下的缺陷样本的图像分别进行主成分分析,得到相应主成分图像(PC图像)。图6表示对高光谱图像进行主成分分析后得到的油桃外部缺陷样本的前6个PC图像。各小图从左到右依次为原图像、PC1、PC2、PC3、PC4、PC5、PC6图像。从图6可以看出,不同缺陷类型油桃的前4个主成分

散,且由于异形果光谱趋势与完好果接近,因此与完好样本重合不易区分。提取的前10个主成分对原始光谱数据的累计贡献率见表2。

由表2可知,前5个主成分累计贡献率已达到99.66%,表示前5个主成分能够解释原始光谱量99.66%的信息,但因4种缺陷样本和完好油桃样本的光谱重叠部分较多,若选取的主成分相对过少,会造成有效信息的丢失,影响模型的判别效果。因此选取前10个主成分建立判别模型,以保证模型具有较好的判别性能。

图像基本保留了绝大部分的信息,PC5、PC6图像噪声干扰严重。以裂纹果为例,比较前4幅PC图像可知:PC1包含的原始数据的信息最多,但这些信息中绝大部分为外表皮轮廓信息,而相比较PC4图像中的裂纹信息十分显著,其裂纹部分与原图像最为相似,更适合用于对裂纹区域的分割。而锈病果样本的PC图像中,PC2中外表皮轮廓最为清晰,PC3中锈斑区域最为明显,可用来进行缺陷分割。异形果样本中PC1中外表皮轮廓清晰,由于异形果样本的外表皮轮廓与完好果样本差异很大,且无明显缺陷区域,故提取外表皮轮廓就可实现异形果样本的缺陷分割。暗伤样本的PC5图像中暗伤区域非常明显,故选定PC5图像对样本中暗伤部分进行分割。

3.3.3 区域分割算法

使用提取得到的PC图像并结合图像处理技术分别对裂纹果、锈病果、异形果及暗伤果的缺陷区域进行分割,如图7所示。以裂纹果为例,裂纹PC4图像的裂纹区域最为明显。观察图3的平均光谱图可以发现,完好油桃的平均光谱图在876 nm处出现了最高的反射率,因此选用这个波长的样本灰度图进行掩膜处理^[21]。运用Sobel算子^[22]对掩膜图像的边缘进行识别,得到样本边缘图像。对PC4图像采用区域生长Regiongrow^[23]提取得到样本裂纹区域图像。将边缘图和裂纹区域图做加法运算得到最终的裂纹样本识别图像。由于异形果与完好果的主要差异体现在外表皮轮廓上,故对该类型的缺陷样本可通过对完好果外表皮轮廓的比较实现图像缺陷的分割。

3.4 特征纹理指标值分析

使用ENVI软件提取样本图像中的感兴趣区

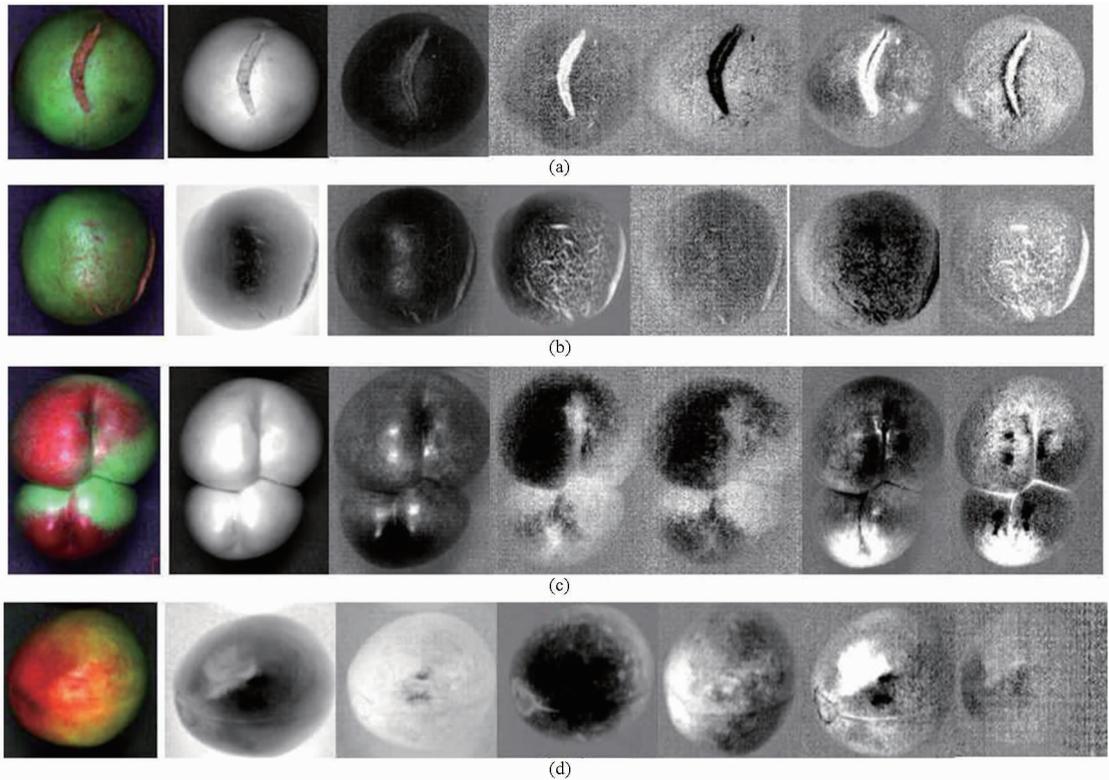


图 6 油桃缺陷样本前 6 个主成分的灰度图

Fig. 6 Samples of defective features before the first six principal components gray scale

(a) 裂纹果 (b) 锈病果 (c) 异形果 (d) 暗伤果

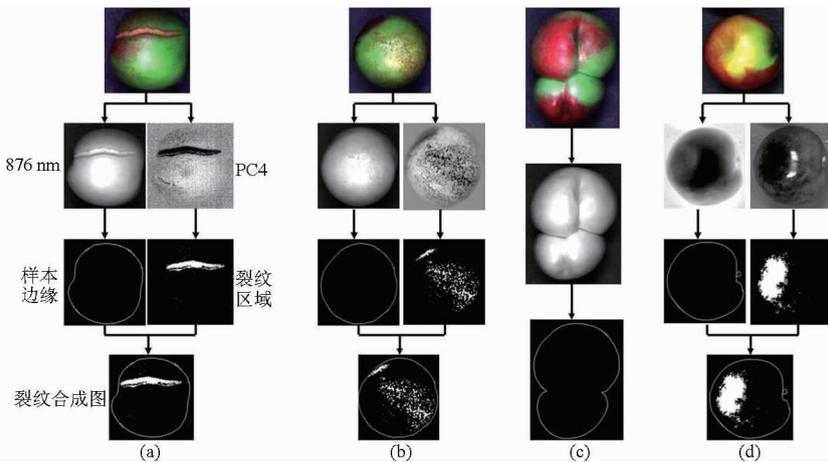


图 7 缺陷样本检测算法关键步骤流程图

Fig. 7 Flow chart of key steps involved in sample of defective feature algorithm

(a) 裂纹果 (b) 锈病果 (c) 异形果 (d) 暗伤果

域,其中对于外部缺陷油桃样本根据上述提取得到的缺陷区域,提取缺陷位置周围图像 50 像素 × 50 像素的感兴趣区域,对于完好油桃样本则提取果实中间部分 50 像素 × 50 像素大小的感兴趣区域图像。然后选取均值、对比度、相关性、能量、同质性和熵作为本研究的纹理特征指标对感兴趣区域图像进行纹理特征分析。

均值表示窗口内的平均灰度;对比度表示区域内灰度级的差异,图像的局部变化越大,其值越高;相关性是影响灰度线性相关的度量;区域内像素值

越相似,则能量越大,同质性也越高;熵代表影像的无序程度,当影像特征为完全随机性纹理时,达到最大值。选取预测集 120 个样本感兴趣区域的纹理特征计算值绘制得到图 8。其中前 60 个样本为完好果纹理特征数据,后 60 个为缺陷果纹理特征数据。

由图 8a 可知,缺陷油桃的均值分布在 0.03 ~ 0.13,完好油桃的纹理均值分布在 0.02 ~ 0.065,缺陷样本与完好样本的均值有部分重叠,但缺陷油桃的均值普遍高于完好油桃,且分布范围更广。由图 8b 可知,完好样本的平均对比度约为 0.37,而缺

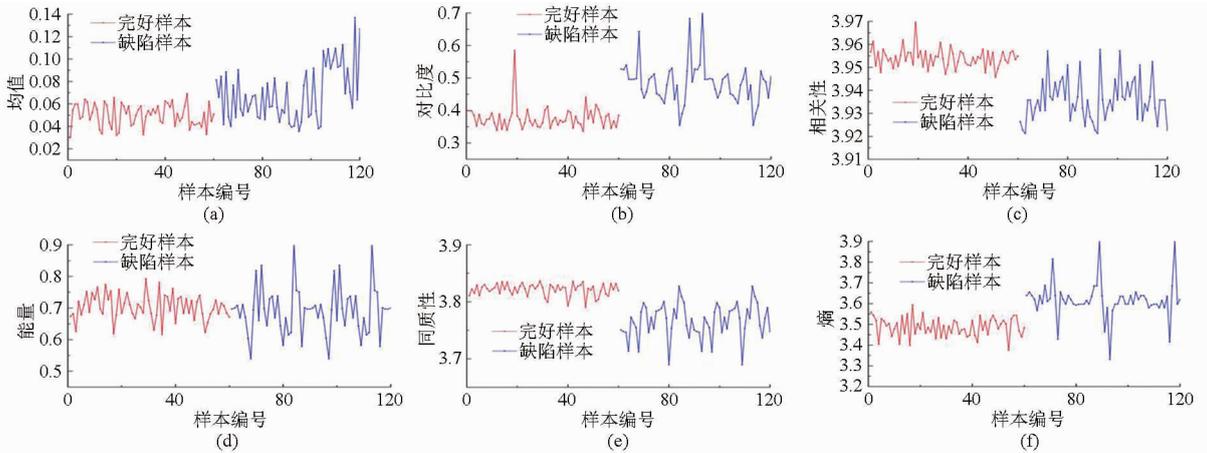


图8 共生矩阵纹理特征值

Fig. 8 Co-occurrence matrix eigenvalues

(a) 均值 (b) 对比度 (c) 相关性 (d) 能量 (e) 同质性 (f) 熵

陷样本的对比度明显高于完好样本,约为 0.45。由图 8c、8e 可知,缺陷样本的相关性、同质性均比完好样本的相关性、同质性低。由图 8d 可知,缺陷样本与完好样本的能量重叠现象较为严重,但缺陷样本的能量分布较广,主要集中在 0.54 ~ 0.89,而完好样本的能量集中在 0.62 ~ 0.79。由图 8f 可知,完好样本的平均熵约为 0.48,而缺陷样本的熵明显高于完好样本且数值波动较大,约为 0.62。

3.5 ELM 模型检测分析

表 3 为预测集样本 ELM 模型的判别结果,其中判别正确的样本集中在表 3 的对角线上,而误判样本分散在非对角线位置上,同时同一列样本的数量和即为该类样本的预测集样本总数。

表 3 预测集样本 ELM 模型的判别结果

Tab. 3 Results of classification ELM model for classifying nectarine samples in prediction set

类别	裂纹果	锈病果	异形果	暗伤果	完好果
裂纹果	15	0	0	0	0
锈病果	0	14	0	1	0
异形果	0	0	11	0	0
暗伤果	0	1	0	13	0
完好果	0	0	4	1	60
正确率/%	100	93.33	73.33	86.67	100

由表 3 可知,1 个锈病果被误判为暗伤果,1 个暗伤果被误判为锈病果。可见,锈病果与暗伤果有相似的缺陷特征,虽易造成两类样本间的误判,但均未被误判为完好样本,因此对整体缺陷样本的判别正确率无直接影响。此外,4 个异形果、1 个暗伤果未被检出均被误判为完好果样本,导致缺陷样本的正确率为 91.67% (55/60)。完好样本全部被检出,

正确率达到 100%,因此,预测集样本的整体判别正确率达到 95.83% (115/120)。研究表明,使用光谱主成分和图像纹理指标建立的 ELM 判别模型能很好地实现油桃缺陷样本和完好样本的分类。

4 结论

(1) 外部缺陷样本与完好样本的光谱曲线在可见光区域(420 ~ 780 nm)两类样本的光谱曲线差异较大,完好样本的反射率高于缺陷样本。各类缺陷样本的光谱曲线差异较大且重叠交错现象较为严重,其中完好果与异形果的光谱曲线走势高度一致,因此无法通过单纯的光谱分析研究实现对完好果和异形果的分类判别研究。

(2) 对 10 条特征波长下的缺陷样本图像进行主成分分析得到相应 PC 图像。对 876 nm 下的单波长图像通过掩膜、Sobel 算子处理得到缺陷样本的边缘图像,同时选定缺陷样本的高光谱图像中最适用于分割的 PC 图像,并对该 PC 图像经过区域生长算法后能有效实现缺陷区域的分割。

(3) 对油桃外部缺陷进行检测的结果表明,使用光谱主成分数值与图像特征纹理指标融合建立的 ELM 模型能很好地实现油桃外部缺陷的检测判别,其中缺陷样本的正确率为 91.67%,完好样本的正确率为 100%,该模型的综合判别正确率为 95.83%。

(4) 本研究表明,通过光谱主成分数值和图像纹理指标值进行数据融合建立的 ELM 模型可以达到对“中油 9 号”油桃样本进行快速判别的目的,为研究开发油桃在线检测设备提供了理论支持和依据。

参 考 文 献

- 1 杨静, 刘丽娟, 李想. 我国桃和油桃生产与进出口贸易现状及其展望[J]. 农业展望, 2011(3): 48 - 52.
- 2 王斌, 薛建新, 张淑娟. 基于高光谱成像技术的腐烂、病害梨枣检测[J]. 农业机械学报, 2013, 44(增刊 1): 205 - 209.
Wang Bin, Xue Jianxin, Zhang Shujuan. Detection of decay and disease pear jujube based on hyperspectral imaging technology [J]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(Supp. 1): 205 - 209. (in Chinese)
- 3 余克强, 赵艳茹, 李晓丽, 等. 基于高光谱成像技术的鲜枣裂纹的识别研究[J]. 光谱学与光谱分析, 2014, 34(2): 532 - 537.
Yu Keqiang, Zhao Yanru, Li Xiaoli, et al. Study on identification the crack feature of fresh jujube using hyperspectral imaging [J]. Spectroscopy and Spectral Analysis, 2014, 34(2): 532 - 537. (in Chinese)
- 4 Lee W H, Kim M S, Lee H, et al. Hyperspectral near-infrared imaging for the detection of physical damages of pear[J]. Journal of Food Engineering, 2014, 130: 1 - 7.
- 5 Lorente D, Aleixos N, Gomez-Sanchis J, et al. Recent advances and applications of hyperspectral imaging for fruit and vegetable quality assessment[J]. Food Bioprocess Technology, 2012, 5(4): 1121 - 1142.
- 6 张初, 刘飞, 孔汶汶, 等. 利用近红外高光谱图像技术快速鉴别西瓜种子品种[J]. 农业工程学报, 2013, 29(20): 270 - 277.
Zhang Chu, Liu Fei, Kong Wenwen, et al. Fast identification of watermelon seed variety using near infrared hyperspectral imaging technology[J]. Transactions of the CSAE, 2013, 29(20): 270 - 277. (in Chinese)
- 7 Baranowski P, Mazurek W, Wozniak J, et al. Detection of early bruises in apples using hyperspectral data and thermal imaging [J]. Journal of Food Engineering, 2012, 110(3): 345 - 355.
- 8 邓书斌. ENVI 遥感图像处理方法[M]. 北京: 科学出版社, 2010.
- 9 吴刚, 唐振民, 程勇, 等. 灰度共生矩阵纹理特征的运动目标跟踪方法[J]. 南京理工大学学报: 自然科学版, 2010, 34(4): 459 - 463.
Wu Gang, Tang Zhenmin, Cheng Yong, et al. Object tracking method based on gray level co-occurrence matrix texture characteristic[J]. Journal of Nanjing University of Science and Technology: Natural Science, 2010, 34(4): 459 - 463. (in Chinese)
- 10 章毓晋. 图像工程(中册)图像分析[M]. 2 版. 北京: 清华大学出版社, 2007.
- 11 Huang G, Zhu Q, Siew C. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1-3): 489 - 501.
- 12 孙俊, 卫爱国, 毛罕平, 等. 基于高光谱图像及 ELM 的生菜叶片氮素水平定性分析[J]. 农业机械学报, 2014, 45(7): 272 - 276.
Sun Jun, Wei Aiguo, Mao Hanping, et al. Discrimination of lettuce leaves' nitrogen status based on hyperspectral imaging technology and ELM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(7): 272 - 276. (in Chinese)
- 13 Cao J, Lin Z, Huang G, et al. Voting based extreme learning machine[J]. Information Sciences, 2012, 185(1): 66 - 77.
- 14 王艳娟, 陈晓红, 邹丽. 图像感兴趣区域自动提取算法[J]. 科学技术与工程, 2007, 12(7): 2867 - 2871.
Wang Yanjuan, Chen Xiaohong, Zou Li. Automatic extraction of regions of interest[J]. Science Technology and Engineering, 2007, 12(7): 2867 - 2871. (in Chinese)
- 15 黄文倩, 陈立平, 李江波, 等. 基于高光谱成像的苹果轻微损伤检测有效波长选取[J]. 农业工程学报, 2013, 29(1): 272 - 277.
Huang Wenqian, Chen Liping, Li Jiangbo, et al. Effective wavelengths determination for detection of slight bruises on apples based on hyperspectral imaging[J]. Transactions of the CSAE, 2013, 29(1): 272 - 277. (in Chinese)
- 16 Liu C, Liu W, Lu X, et al. Application of multispectral imaging to determine quality attributes and ripeness stage in strawberry fruit[J]. PLoS ONE, 2014, 9(2): e87818.
- 17 Rajkumar P, Wang N, Elmasry G, et al. Studies on banana fruit quality and maturity stages using hyperspectral imaging [J]. Journal of Food Engineering, 2012, 108(1): 194 - 200.
- 18 Abbott J A, Lu R, Upchurch B L, et al. Technologies for nondestructive quality evaluation of fruits and vegetables [J]. Horticultural Reviews, 1997, 20: 1 - 120.
- 19 ElMasry G, Sun D W, Allen P. Non-destructive determination of water-holding capacity in fresh beef by using NIR hyperspectral imaging[J]. Food Research International, 2011, 44(9): 2624 - 2633.
- 20 Wu D, Sun D W, He Y. Application of long-wave near infrared hyperspectral imaging for measurement of color distribution in salmon fillet [J]. Innovative Food Science & Emerging Technologies, 2012, 16: 361 - 372.
- 21 Baranowski P, Mazurek W, Pastuszka-Wozniak J. Supervised classification of bruised apples with respect to the time after bruising on the basis of hyperspectral imaging data[J]. Postharvest Biology and Technology, 2013, 86(1): 249 - 258.
- 22 袁春兰, 熊宗龙, 周雪花, 等. 基于 Sobel 算子数学图像的边缘检测[J]. 激光与红外, 2009, 39(1): 85 - 87.
Yuan Chunlan, Xiong Zonglong, Zhou Xuehua, et al. Study of infrared image edge detection based on Sobel operator[J]. Laser & Infrared, 2009, 39(1): 85 - 87. (in Chinese)
- 23 Yu K, Zhao Y, Liu Z, et al. Application of visible and near-infrared hyperspectral imaging for detection of defective features in Loquat [J]. Food and Bioprocess Technology, 2014, 7(11): 3077 - 3087.