

基于压缩感知理论的苹果病害识别方法*

霍迎秋^{1,2} 唐晶磊² 尹秀珍² 方勇²

(1. 西北农林科技大学机械与电子工程学院, 陕西杨凌 712100; 2. 西北农林科技大学信息工程学院, 陕西杨凌 712100)

摘要: 为实现自然场景下低分辨率苹果果实病害的智能识别,提出了一种基于压缩感知理论的苹果病害识别方法。以轮纹病、炭疽病和新轮纹病3种常见的苹果果实病害为研究对象,提取病斑的8个纹理特征参数组成训练特征矩阵。利用压缩感知理论,求解待测样本特征向量在特征矩阵上的稀疏表示系数向量,通过对系数向量的分析实现待测样本的分类。设计灰度关联分析和支持向量机识别模型与本文方法进行识别效果对比,平均正确识别率分别为86.67%、90%和90%。实验结果表明,基于压缩感知理论的识别方法能够对苹果病害进行有效识别。

关键词: 苹果病害 压缩感知 特征矩阵 稀疏表示 支持向量机

中图分类号: TP391.41; S436.611.1 **文献标识码:** A **文章编号:** 1000-1298(2013)10-0227-06

Apple Disease Recognition Based on Compressive Sensing

Huo Yingqiu^{1,2} Tang Jinglei² Yin Xiuzhen² Fang Yong²

(1. College of Mechanical and Electronic Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China

2. College of Information Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract: To intelligently recognize apple fruit diseases from low-resolution images taken in natural environment, a method based on compressive sensing was proposed. Three kinds of apple fruit diseases (apple ring rot, apple anthracnose and new apple ring rot) were investigated. Eight texture feature values were extracted to construct the training eigenmatrix. Then compressive sensing was used to approximate the sparse coefficient vector which was the sparse representation of the sample eigenvector on the training eigenmatrix. Thus the test sample was classified by analyzing the coefficients vector. Both the gray relation analysis and the support vector machine recognition models were constructed to compare with the proposed method. The recognition rates of three models were 86.67%, 90% and 90%, respectively. The experimental results showed that the recognition method based on compressive sensing could effectively recognize these three kinds of apple fruit diseases.

Key words: Apple disease Compressive sensing Eigenmatrix Sparse representation Support vector machine

引言

陕西是中国苹果生产大省,种植面积占全国的20%左右,但是苹果病害每年都给果农造成巨大损失。目前病害主要依靠人工方法识别,对果农和专家的依赖性高,主观性强,而苹果病害病斑症状复杂,特征不够明显,往往难以对病害作出科学、准确

的识别。

基于图像分析进行病害检测是一种有效方法,但研究对象一般为黄瓜、西红柿、玉米、水稻等叶部常见病害图像的识别^[1~3]。从2008年开始,国内外学者才开展基于图像分析的苹果病害识别的研究工作^[4~8]。

本文利用压缩感知理论,借鉴人脸识别的经验,

收稿日期: 2012-10-25 修回日期: 2013-03-01

* 国家自然科学基金资助项目(61271280,61001100)和陕西省自然科学基金资助项目(2010K06-15)

作者简介: 霍迎秋,博士生,实验师,主要从事分布式编码和压缩感知研究,E-mail: fallying@nwsuaf.edu.cn

通讯作者: 方勇,教授,博士生导师,主要从事分布式编码和压缩感知研究,E-mail: fangyong@nwsuaf.edu.cn

探讨基于压缩感知理论的苹果果实病害识别方法,并设计基于灰度关联分析和支持向量机的分类识别模型,对比所提出的方法和现有方法的识别效果,探讨压缩感知理论在农业病害识别领域中的应用方法。

1 图像获取与特征提取

1.1 图像获取

随着手机照相功能的普及,果农用自己的手机将苹果病害部位拍摄下来、用彩信方式发送变得极为简单。本研究采用华为 T5211 型手机,在陕西省杨凌区五泉镇农户果园中,在 10:00 ~11:00 自然光照条件下,顺光或侧顺光拍摄获取苹果果实病害图像,图像宽度为 320 像素、高度为 240 像素。为了便于后续处理,病害果实若被其他物体遮掩,不利于拍摄,则采用用手将病果托住的方法获取图像。在 10 个果园中共采集到 143 幅病害图像,经专家鉴定,其中 121 幅图像可辨别病害种类,共计 5 种:轮纹病、炭疽病、腐烂病、斑点病和新轮纹病等。腐烂病和斑点病样本数太少无法进行实验测试,舍弃。选择病斑特征典型、区分度高的图像,共计 78 幅,包含 3 类病害:轮纹病、炭疽病和新轮纹病,每类病害各 26 幅。其染病程度均为中等或稍重。

1.2 图像预处理

图像质量直接影响分割及特征提取。在图像采集过程中,由于受到采集设备、环境等影响,图像存在分辨率低、背景复杂、病斑边缘模糊等特点。为了有效去除噪声,较好地保留图像的细节、并突出边缘信息,在实验对比的基础上,首先选用自适应直方图均衡化方法,扩展图像灰度范围,对图像进行对比度增强,然后选用彩色图像中值滤波方法,即在图像的 R、G、B 通道上分别应用中值滤波方法滤波后,再进行通道融合,得到滤波后的彩色图像,较好地抑制了图像的噪声,保留了图像的边缘信息。

1.3 图像分割

图像分割是图像分析与模式识别中一个重要的环节,病斑分割的好坏直接影响后续特征提取与识别。由于本文研究对象是自然环境下拍摄的果实病害图像,背景十分复杂,分辨率低,模糊不清晰,要想直接使用机器准确地提取病斑区域十分困难。因此,采用改进的水平集彩色图像分割方法,即基于区域和边缘的变分水平集彩色图像分割方法^[9-10]。该方法充分利用了目标图像的区域信息和边缘信息,并用欧氏距离代替了灰度加权值,使得彩色图像的颜色空间信息得到充分利用,获得了更加精确的颜色边缘。同时,还考虑了各个彩色通道之间存在

的关系,尽可能地减少了各个通道中由于形状信息不同造成的失真,提高了分割的准确率,达到了将原始图像中病斑直接分割出来的目的。3 种病害原图与病斑提取结果如图 1、2 所示。




图 1 3 种病害原图

Fig. 1 Original image of three kinds of diseases

(a) 轮纹病 (b) 炭疽病 (c) 新轮纹病




图 2 3 种病害病斑分割结果

Fig. 2 Segmentation results of three kinds of diseases

(a) 轮纹病 (b) 炭疽病 (c) 新轮纹病

1.4 病斑特征提取

为分析和识别病斑图像,必须对病斑的特征进行分析。分类器的设计和性能在很大程度上依赖于特征的选择和提取,也即依赖于用来代表图像信息的特征向量。为了取得较好的病斑分类识别结果,本文提取病斑的 H、S、V 通道上的 1 阶矩和 2 阶矩特征作为颜色特征;采用基于统计方法的灰度共生矩阵法,在实验的基础上选取参数 $d = 1, \theta = 0^\circ、45^\circ、90^\circ、135^\circ$,灰度级为 16,提取能量、熵、惯性矩、相关性的均值和标准差等 8 个参数作为纹理特征^[11-12];提取 7 个 Hu 不变矩描述病害的形状特征。经分析并对不同病斑进行反复实验测试,结果表明不同病斑之间的颜色特征和形状特征区分不明显,而纹理特征区分明显,因此,舍弃颜色特征和形状特征,将纹理特征作为病害识别的有效分类特征。病斑纹理特征计算式为

能量

$$R_{ASM} = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} p^2(i,j) \tag{1}$$

式中 L ——图像的灰度级
 $p(i,j)$ ——2 个像素灰度级同时发生的概率
 i,j ——2 个不同元素的灰度

当 $p(i,j)$ 中有少数值大时,能量也大。它表明特定的像素对较多时,一致性较好,反映了图像灰度分布均匀程度和纹理粗细程度。

熵

$$R_{ENT} = - \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} p(i,j) \lg p(i,j) \tag{2}$$

当 $p(i, j)$ 的值分布越均匀, 则熵的值越大, 它描述了纹理均衡的逆性质。

惯性矩

$$R_{\text{CON}} = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} (i-j)^2 p(i, j) \quad (3)$$

惯性矩可理解为图像的清晰度。粗纹理图像, 由于矩阵的数值集中在主对角线附近, 相应的对比度较小; 反之, 则较大。

相关性

$$R_{\text{COR}} = \frac{\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} ij p(i, j) - \mu_1 \mu_2}{\delta_1 \delta_2} \quad (4)$$

其中

$$\mu_1 = \sum_{i=0}^{L-1} i \sum_{j=0}^{L-1} p(i, j) \quad (5)$$

$$\mu_2 = \sum_{j=0}^{L-1} j \sum_{i=0}^{L-1} p(i, j) \quad (6)$$

$$\delta_1 = \sqrt{\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} p(i, j) (i - \mu_1)^2} \quad (7)$$

$$\delta_2 = \sqrt{\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} p(i, j) (j - \mu_2)^2} \quad (8)$$

相关性描述了矩阵中行或列元素之间的相似程度。

从轮纹病、炭疽病和新轮纹病 3 种病害中各随机抽取 6 幅病斑图像, 根据上述步骤计算纹理特征, 组成特征向量 $\mathbf{v} = [v_1, v_2, \dots, v_m]^T$ ($m = 1, 2, \dots, 8$), 分别绘制能量、熵、惯性矩和相关性等 4 个特征的均值和标准差的柱状图, 如图 3 所示。病斑纹理特征区分明显, 能够作为病害识别的有效分类特征。

1.5 病害分类识别

1.5.1 压缩感知理论

假定 $\mathbf{x} \in \mathbb{R}^n$ 是稀疏信号, $\mathbf{u}$ 是其在某种正交变换基 $\{\Psi_i\}$ ($i \in \{1, 2, \dots, n\}$) 下的相关系数, 即稀疏




图 3 纹理特征区分示意图

Fig. 3 Schematic diagram of texture features

向量,则 $\mathbf{x} = \Psi \mathbf{u}$,其中正交变换基 Ψ 是 $n \times n$ 的矩阵。如果 n 个元素中只有 k 个不为零,则 $\mathbf{x}$ 是关于 Ψ 的 k 阶稀疏信号。可以用一个与变换基不相关的矩阵 Φ 对信号 $\mathbf{x}$ 进行线性测量,得到 m 维的观测值向量 $\mathbf{y} = \Phi \mathbf{x}$ 或 $\mathbf{y} = \Phi \Psi \mathbf{u}$,式中 $\Phi \in \mathbb{R}^{n \times n}$ 为观测矩阵, $\mathbf{y} \in \mathbb{R}^m$ 为观测向量,其中 $m < n$ 。显然方程为欠定方程,无法从 $\mathbf{y}$ 求解出信号 $\mathbf{x}$ 。根据压缩感知理论可以通过求解最优 l_0 范数来解决这个问题^[13~15],即

$$\min \|\mathbf{u}\|_0 \quad \text{依赖于} \quad \mathbf{y} = \Phi \Psi \mathbf{u}$$

但是,上式求解是个 NP 难题,很难求解。压缩感知理论认为,如果满足 $m > ck$,其中 $c > 1$,则上式可以转换为求解最优 l_1 范数来解决,即

$$\min \|\mathbf{u}\|_1 \quad \text{依赖于} \quad \mathbf{y} = \Phi \Psi \mathbf{u}$$

通过线性编程来对上式求解,最小测量值依赖于 k 、 n 和集合 $\{\varphi_i\} \{\psi_i\}$ 之间的非相关度,然后通过最小测量值恢复信号 $\mathbf{x}$ 的 k 个非零相关系数^[16]。

1.5.2 基于压缩感知理论的病害识别

模式识别的基本问题是用 k 个不同类别的训练样本决定一个新的测试样本的类归属。本文提取苹果病斑特征向量 $\mathbf{v}_i = [v_{1i}, v_{2i}, \dots, v_{mi}]^T \in \mathbb{R}^m$,作为每个病斑类的特征集的一列。组成类特征矩阵 $\mathbf{A}$,即

$$\mathbf{A} = [\mathbf{v}_1 \quad \mathbf{v}_2 \quad \dots \quad \mathbf{v}_n] \in \mathbb{R}^{m \times n} \quad (9)$$

式中, n 在这里特指类内训练样本数。假设每个类的训练样本足够多,则类特征矩阵 $\mathbf{A}$ 可以作为病斑类的特征子空间,一个同类的测试样本特征向量 $\mathbf{y}$ 可由特征矩阵中的基向量(列向量)稀疏表示为

$$\mathbf{y} = a_1 \mathbf{v}_1 + a_2 \mathbf{v}_2 + \dots + a_n \mathbf{v}_n \quad (10)$$

式中, $\mathbf{a}$ 为系数向量,其元素不全为零。如果特征矩阵 $\mathbf{A}$ 为所有病斑类训练样本的特征向量组成。则任一个测试样本特征向量 $\mathbf{y}$ 可稀疏表示为

$$\mathbf{y} = a_1 \mathbf{v}_1 + a_2 \mathbf{v}_2 + \dots + a_n \mathbf{v}_n + a_{n+1} \mathbf{v}_{n+1} + \dots + a_{2n} \mathbf{v}_{2n} + \dots + a_{nk} \mathbf{v}_{nk} \quad (11)$$

$\mathbf{a} = [a_1, a_2, \dots, a_{nk}]^T \in \mathbb{R}^{nk}$ 为系数向量,其中除了与第 j 类相关的元素外($j = 1, 2, \dots, k$),其他都为零。改写式(11)为矩阵相乘形式为

$$\mathbf{y} = \begin{bmatrix} v_{11} & v_{12} & \dots & v_{1nk} \\ v_{21} & v_{22} & \dots & v_{2nk} \\ \vdots & & \ddots & \\ v_{m1} & v_{m2} & \dots & v_{mnk} \end{bmatrix} \begin{bmatrix} 0 \\ \vdots \\ a_{(j-1)n+1} \\ \vdots \\ a_{jn} \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (12)$$

将式(12)简化为

$$\mathbf{y} = \mathbf{A} \mathbf{u} \quad (13)$$

根据以上分析,将所有训练样本特征向量组成特征矩阵 $\mathbf{A} \in \mathbb{R}^{m \times nk}$,任意待识别样本特征向量为 $\mathbf{y} \in \mathbb{R}^m$,应存在稀疏系数向量 $\mathbf{u} \in \mathbb{R}^{nk}$ 满足式(13)。只需求解式(13)表示的线性方程组,求得 $\mathbf{u}$,对向量 $\mathbf{u}$ 中非零元素进行分析,即可求得待识别样本 $\mathbf{y}$ 的类归属。

但是,由于特征矩阵 $\mathbf{A} \in \mathbb{R}^{m \times nk}$, $m < nk$,方程个数小于未知数个数,线性方程组为欠定方程组,无法直接求解。根据压缩感知理论可知,可通过求解 l_1 范数的最小化问题^[16],得到 $\mathbf{u}$ 的近似解 $\hat{\mathbf{u}}$,即

$$\min \|\mathbf{u}\|_1 \quad \text{依赖于} \quad \mathbf{y} = \mathbf{A} \mathbf{u}$$

经过实验分析发现,近似解 $\hat{\mathbf{u}}$ 并非如式(12)中系数向量 $\mathbf{a}$ 所示,为一稀疏向量。如图4所示,除了与第 j 类($j = 1, 2, \dots, k$)相关的元素为非零值外,也有很多其他非零元素。因此设计分类方法

$$\hat{\mathbf{y}} = [\mathbf{A}_1 \quad \mathbf{A}_2 \quad \dots \quad \mathbf{A}_k] [\boldsymbol{\beta}_1 \quad \boldsymbol{\beta}_2 \quad \dots \quad \boldsymbol{\beta}_k]^T \quad (14)$$

或 $\hat{\mathbf{y}} = [\mathbf{A}_1 \boldsymbol{\beta}_1 \quad \mathbf{A}_2 \boldsymbol{\beta}_2 \quad \dots \quad \mathbf{A}_k \boldsymbol{\beta}_k]$ (15)

式中 $\mathbf{A}_k$ ——第 k 类训练样本特征向量组成的子矩阵
 $\boldsymbol{\beta}_k$ ——近似解 $\hat{\mathbf{u}}$ 中与第 k 类相关的系数组成的子向量

然后计算 $\mathbf{y}$ 与 $\hat{\mathbf{y}}_k$ 差的最小绝对值 $\min |\mathbf{y} - \hat{\mathbf{y}}_k|$ 或 $\min |\mathbf{y} - \mathbf{A}_k \boldsymbol{\beta}_k|$, k 即为所求,即 $\mathbf{y}$ 属于第 k 类病害。




图4 稀疏系数
Fig.4 Sparse coefficients

算法主要步骤如下:

- (1)构建训练样本特征矩阵 $\mathbf{A} \in \mathbb{R}^{m \times nk}$ 。
- (2)构建测试样本特征矩阵 $\mathbf{Y} \in \mathbb{R}^{m \times q}$, q 为待识别特征向量个数。
- (3)对每一个 $\mathbf{y}_i$ 求解 l_1 范数的最小化问题: $\hat{\mathbf{u}} = \min \|\mathbf{u}\|_1$, 依赖于 $\mathbf{y}_i = \mathbf{A} \mathbf{u}$ 。
- (4) $\boldsymbol{\beta} = \hat{\mathbf{u}}$ 。
- (5) $\min |\mathbf{y}_i - \mathbf{A}_k \boldsymbol{\beta}_k|$: 计算差的最小绝对值, k 为所属的类别。
- (6) $z_i = k$ 。

2 病害识别实验

为对比算法的分类识别效果,设计了3种分类

模型:灰度关联分析、支持向量机和基于压缩感知的分类模型。硬件环境为 Intel Corei3 CPU M380 @ 2.53 GHz,内存 2.00 GB;软件环境为 Lenovo Win 7 家庭普通版,Matlab R2010a。

以轮纹病、炭疽病和新轮纹病等 3 种发病率较高的苹果果实病害为研究对象,实验图片共 78 幅,每类病害各 26 幅。首先对获取的病斑图像进行预处理,然后采用改进的水平集彩色图像分割方法分割病斑,提取每幅病斑图像的 8 个纹理特征参数,建立特征库。抽取 48 幅病斑图像的特征作为训练样本,其中轮纹病、炭疽病和新轮纹病每类训练样本数为 16,对应每类剩余样本为 10,作为测试样本。

在基于支持向量机的分类识别测试中,分别采用线性核、多项式核和高斯径向基核(RBF)等 3 种不同的核函数训练分类器,以确定苹果果实病害识别的最优核函数。其中,多项式核的 q 值取 3;对于径向基核的参数 c 和 g ,根据训练、测试样本数,采用交叉验证的方法获取最优参数, $c=1.4142,g=2$ 。基于支持向量机的分类模型识别结果如表 1 所示。

表 1 基于支持向量机的分类模型识别结果
Tab.1 Recognition results of support vector machine

识别模型	正确识别率			平均正确识别率
	轮纹病	炭疽病	新轮纹病	
线性核	80	70	90	80
多项式核	80	100	90	90
RBF 核	80	100	90	90

由表 1 的实验结果可知,核函数为线性核函数时,平均正确识别率最低,为 80%;采用多项式核函数与径向基核函数平均正确识别率最高,均为

90%。因此,多项式核函数与径向基核函数的支持向量机分类方法效果最好。

3 种不同的分类模型识别结果如表 2 所示。

表 2 不同的分类模型识别结果
Tab.2 Recognition results of different

recognition model				%
识别模型	正确识别率			平均正确识别率
	轮纹病	炭疽病	新轮纹病	
灰度关联	80	90	90	86.67
支持向量机	80	100	90	90.00
压缩感知	80	90	100	90.00

由表 2 的实验结果可知,3 种分类模型中,灰度关联分析识别模型平均正确识别率最低,为 86.67%;基于支持向量机的分类模型与基于压缩感知的分类识别模型,平均正确识别率最高,达 90%,能够对病害进行有效分类。

3 结束语

研究了苹果病害的特征、病斑分割方法和特征提取方法,借鉴人脸识别的研究思路,分析了压缩感知理论应用于分类识别的理论基础,提出了一种基于压缩感知理论的苹果病害识别模型。为进行分类识别效果的对比,设计了灰度关联分析和支持向量机识别模型。实验结果表明,在训练样本不多的情况下,基于压缩感知的识别模型能够对苹果病斑进行有效分类。因每类的训练样本只有 16 个,特征矩阵很小,可能会影响待识别样本在特征矩阵上的稀疏表示,即影响病害识别效果,如果训练样本足够多时,能否进一步提高识别模型的识别率,有待进一步进行实验验证。

参 考 文 献

1 任宪忠,马小愚. 农产品粒形识别研究进展及其在工程中应用现状[J]. 农业工程学报,2004,20(3): 276 ~ 280.
Ren Xianzhong, Ma Xiaoyu. Research advances of agricultural product grain shape identification and current situation of its application in the engineering field[J]. Transactions of the Chinese Society of Agricultural Engineering, 2004, 20(3):276 ~ 280. (in Chinese)

2 陈建,陈晓,李伟,等. 基于近红外光谱技术和人工神经网络的玉米品种鉴别方法研究[J]. 光谱学与光谱分析,2008,28(8):1 806 ~ 1 809.
Chen Jian, Chen Xiao, Li Wei, et al. Study on discrimination of corn seed based on near infrared spectra and artificial neural network model[J]. Spectroscopy and Spectral Analysis, 2008, 28(8): 1 806 ~ 1 809. (in Chinese)

3 周子立,张瑜,何勇,等. 基于近红外光谱技术的大米品种快速鉴别方法[J]. 农业工程学报,2009,25(8): 131 ~ 135.
Zhou Zili, Zhang Yu, He Yong, et al. Method for rapid discrimination of varieties of rice using visible NIR spectroscopy[J]. Transactions of the Chinese Society of Agricultural Engineering, 2009, 25(8):131 ~ 135. (in Chinese)

4 李宗儒,何东健. 基于手机拍摄图像分析的苹果病害识别技术研究[J]. 计算机工程与设计, 2010,31(13):3 051 ~ 3 053.
Li Zongru, He Dongjian. Research on identify technologies of apple's disease based on mobile photograph image analysis[J]. Computer Engineering and Design, 2010, 31(13): 3 051 ~ 3 053. (in Chinese)

5 樊景超. 苹果果实病害近红外光谱信息获取与识别模型研究[D]. 北京:中国农业科学院,2011.

6 Donoho D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4): 1 289 ~ 1 306.

7 Donoho D, Tsaig Y. Extensions of compressed sensing[J]. Signal Processing, 2006, 86(3): 533 ~ 548.

- 8 Wright J, Yang A, Ganesh A, et al. Robust face recognition via sparse representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210 ~ 227.
 - 9 石娜. 基于 snake 和水平集的图像分割方法的研究及应用[D]. 长春: 吉林大学, 2011.
 - 10 Li Chunming, Xu Chenyang, Gui Changfeng, et al. Level set evolution without reinitialization: a new variational formulation[J]. IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), 2005, 1: 430 ~ 436.
 - 11 田有文. 基于纹理特征和支持向量机的葡萄病害的识别[J]. 仪器仪表学报, 2005, 26(8): 1 486 ~ 1 488.
Tian Youwen. A method of recognizing grape disease based on texture feature and support vector machine[J]. Chinese Journal of Scientific Instrument, 2005, 26(8): 1 486 ~ 1 488. (in Chinese)
 - 12 王惠明, 史萍. 图像纹理特征的提取方法[J]. 中国传媒大学学报, 2006, 13(1): 49 ~ 52.
Wang Huiming, Shi Ping. Methods to extract images texture features[J]. Journal of Communication University of China Science and Technology, 2006, 13(1): 49 ~ 52. (in Chinese)
 - 13 Rauhut H, Schnass K, Vandergheynst P. Compressed sensing and redundant dictionaries[J]. IEEE Transactions on Information Theory, 2008, 54(5): 2 210 ~ 2 219.
 - 14 Candes E, Romberg J, Tao T. Robust uncertainty principles: exact signal reconstruction from highly incomplete frequency information [J]. IEEE Transactions on Information Theory, 2006, 52(4): 489 ~ 509.
 - 15 Bruckstein A, Donoho D, Elad M. From sparse solutions of systems of equations to sparse modeling of signals and images[J]. SIAM Review, 2009, 51(1): 34 ~ 81.
 - 16 Donoho D. For most large underdetermined systems of linear equations the minimal l_1 -norm solution is also the sparsest solution [J]. Communications on Pure and Applied Mathematics, 2006, 59(6): 797 ~ 829.
-

(上接第 97 页)

- 7 姚立健, 丁为民, 赵三琴, 等. 基于 SOFM 神经网络的茄子图像分割方法[J]. 南京农业大学学报, 2008, 31(3): 140 ~ 144.
Yao Lijian, Ding Weimin, Zhao Sanqin, et al. Method of image segmentation for eggplant based on SOFM neural network[J]. Journal of Nanjing Agricultural University, 2008, 31(3): 140 ~ 144. (in Chinese)
 - 8 乔曦, 黄亦其. Matlab 在精密排种机监测装置中的应用研究[J]. 中国农机化, 2011(2): 108 ~ 110.
Qiao Xi, Huang Yiqi. The research of precise seed metering device based on Matlab [J]. Chinese Agricultural Mechanization, 2011(2): 108 ~ 110. (in Chinese)
 - 9 陆尚平, 文友先, 葛维, 等. 基于机器视觉的甘蔗茎节特征提取与识别[J]. 农业机械学报, 2010, 41(10): 190 ~ 194.
Lu Shangping, Wen Youxian, Ge Wei, et al. Recognition and features extraction of sugarcane nodes based on machine vision[J]. Transactions of the Chinese Society for Agricultural Machinery, 2010, 41(10): 190 ~ 194. (in Chinese)
 - 10 Moshashai K, Almasi M, Minaei S, et al. Identification of sugarcane nodes using image processing and machine vision technology [J]. International Journal of Agricultural Research, 2008, 3(5): 357 ~ 364.
 - 11 Sanet H. Connected component labeling using quadrees[J]. Journal of the ACM, 1981, 28(3): 487 ~ 501.
 - 12 朱景福. 图像处理中小边缘消除方法研究[J]. 黑龙江八一农垦大学学报, 2006, 18(3): 79 ~ 82.
Zhu Jingfu. Research on method of eliminating small edge in image processing[J]. Journal of Heilongjiang August First Land Reclamation University, 2006, 18(3): 79 ~ 82. (in Chinese)
 - 13 Galigekere R R, Holdsworth D W. Moment patterns 3n the radon space[J]. Optical Engineering, 2000, 39(4): 1 088 ~ 1 097.
-

(上接第 182 页)

- 15 Gurung A, van Ginkel S W, Kang W C, et al. Evaluation of marine biomass as a source of methane in batch tests: a lab-scale study [J]. Energy, 2012, 43(1): 396 ~ 401.
- 16 李秋敏, 杨斌, 张无敌, 等. 蔗糖发酵产氢与产甲烷能源转换效率的研究[J]. 云南师范大学学报, 2011, 31(增刊): 97 ~ 104.
Li Qiumin, Yang Bin, Zhang Wudi, et al. Study on the energy conversion efficiency of hydrogen and methane fermentation of saccharose [J]. Journal of Yunnan Normal University, 2011, 31(Supp.): 97 ~ 104. (in Chinese)
- 17 Guerrero L, Omil F, Mendez R, et al. Anaerobic hydrolysis and acidogenesis of wastewaters from food industries with high content of organic solids and protein [J]. Water Research, 1999, 33(15): 3 281 ~ 3 289.
- 18 Lier J B V, Grolle K C, Frijters C T, et al. Effects of acetate, propionate, and butyrate on the thermophilic anaerobic degradation of propionate by methanogenic sludge and defined cultures[J]. Applied and Environmental Microbiology, 1993, 59(4): 1 003 ~ 1 011.
- 19 Demirel B, Yenigün O. Two-phase anaerobic digestion processes: a review [J]. Journal of Chemical Technology and Biotechnology, 2002, 77(7): 743 ~ 755.
- 20 Wang Q, Kuninobub M, Ogawa H I, et al. Degradation of volatile fatty acids in highly efficient anaerobic digestion [J]. Biomass and Bioenergy, 1999, 16(6): 407 ~ 416.