doi:10.6041/j.issn.1000-1298.2014.07.042

基于高光谱图像及 ELM 的生菜叶片氮素水平定性分析*

孙　俊[1]　卫爱国[1]　毛罕平[2]　武小红[1]　张晓东[2]　高洪燕[2]

(1. 江苏大学电气信息工程学院, 镇江 212013; 2. 江苏大学江苏省现代农业装备与技术重点实验室, 镇江 212013)

摘要: 基于高光谱图像技术与极限学习机 (Extreme learning machine,ELM)模式识别方法构建一套生菜叶片氮素水平鉴别模型。利用 3 种不同氮浓度的营养液无土栽培各氮素水平生菜,在莲座期采集每类氮素水平生菜叶片各 84 片,利用高光谱图像采集系统采集生菜叶片高光谱图像,并在每个高光谱图像上选取叶片 4 个不同位置的 60 × 60 像素的感兴趣区域(ROI),求取感兴趣区域光谱数据平均值作为叶片样本的原始光谱,利用标准正态变量校正对原始光谱进行预处理,采用主成分分析法对光谱进行降维。采用 ELM 对训练样本进行建模,并与传统的 BP 及 SVM 算法模型进行对比。从实验结果可以看出,ELM 模型训练时间和分类正确率分别为 0.623 04 s 和 100%,在训练时间相当的情况下,ELM 分类正确率高于 SVM 模型,在分类正确率相当的情况下,ELM 模型的训练时间比 BP 模型要短。研究结果表明,基于高光谱图像技术及 ELM 可以构建生菜叶片氮素水平分类模型。

关键词: 生菜叶片　高光谱图像　极限学习机　氮素

中图分类号: TP73　　**文献标识码**: A　　**文章编号**: 1000-1298(2014)07-0272-06

引言

氮素是生菜必需的营养元素之一,若生菜缺氮将导致光合作用能力差、产量与品质降低;若施氮肥过多,不但造成营养成分利用率下降,而且会造成环境污染,因此生菜生长过程中氮素丰缺鉴别对合理施肥具有重要指导意义。目前,国内外作物的缺素诊断方法分为有损诊断和无损诊断两类。有损诊断主要是传统破坏性氮素化学分析[1],无损诊断技术主要有数字图像处理技术和光谱信息技术。文献[2-7]中,数字图像处理技术信息诊断波段来源较少,光谱技术信息来自点信息,它们都存在信息来源单一、不够全面的缺点。另外,多数相关文献只是对作物缺素进行判断,并没有涉及元素过量的判断研究。

高光谱图像包含面层次的光谱信息与丰富波段的图像信息,信息来源较全面,越来越多的学者将其应用于农作物无损检测中[8],但目前利用高光谱图像技术对生菜氮素水平定性分析研究却鲜见报道。本文利用高光谱图像技术和模式识别算法相结合构造生菜氮素水平丰缺(缺氮、正常和过氮)诊断分类器。传统的分类识别算法有 BP 神经网络、SVM 等,它们存在训练速度慢、无法达到全局最小、训练过程中需要不断调整网络的权值和阈值等缺点。极限学习机(Extreme learning machine,ELM)[9]算法随机产生输入层与隐含层间的连接值及隐含层神经元的阈值,在训练过程中无需调整,只需设置隐含层神经元的个数,便可获得唯一的最优解,与传统的训练方法相比,该方法具有学习速度快、泛化性能好等优点。本文分别利用 ELM、BP、SVM 算法建立生菜氮素丰缺定性分析模型,试图寻找最优的建模方法。

1　材料与方法

1.1　样本准备

1.1.1　样本培育

研究样本培育品种为意大利全年耐抽苔抗热生菜,其全生育期 50 d,实验在江苏大学现代农业装备与技术省部共建重点 Venlo 型温室中进行。为了获取不同含氮水平的生菜叶片,本研究以珍珠岩为基质的无土栽培技术对样本进行培育,根据日本山崎营养液配方配制营养液[10]。从移栽开始,分别按标准营养液配方氮元素投入量的 50% ~150% 处理实验样本,其他营养元素按正常量投入,按 3 个氮素水平处理:第 1 组在标准配方的基础上,在不影响其它营养素的情况下,将氮元素配为标准配方的 50%;第 2 组按照标准配方配置营养液;第 3 组在标准配

收稿日期: 2013-09-18　修回日期: 2013-10-10

* 国家自然科学基金资助项目(31101082、61075036)、江苏高校优势学科建设工程资助项目 PAPD(苏政办发 2011 6 号)和农业部农业信息技术重点实验室开放课题资助项目(2013007)

作者简介: 孙俊,副教授,博士,主要从事计算机技术在农业工程中应用研究,E-mail: sun2000jun@ujs.edu.cn

方的基础上，在不影响其它营养素的情况下，将氮元素配为标准溶液的 150%；每个氮素水平栽培 84 株。

1.1.2 高光谱图像采集

以生菜莲座期为例，每盆中种植一株生菜，采集生菜叶片时分别采集每一株生菜同一层级的老叶 1 片，每类氮素水平采集 84 片叶子，3 类共计 252 片，然后及时送至室内采集叶片高光谱图像。

实验所用的高光谱图像采集系统如图 1 所示，由可见-近红外相机（ImSpector V10E 型，Spectral Imaging Ltd.，Oulu，芬兰）、两个 150 W 的卤素灯、一个直流可调节光源（2900 - ER + 9596 - E 型，Illumination，美国）、位移台（MTS120 型，北京）和计算机等部件组成。为采集到图像的尺寸和分辨率不失真的高光谱图像，首先将生菜叶片平铺在位移台的白纸上，其次将相机曝光时间设定为 20 ms，位移台的运行速度为 1.25 mm/s，再次关闭相机快门，用摄像头的盖子完全遮住摄像头的镜头进行图像采集得到全黑的标定图像 D，扫描标准白板得到全白的标定图像 W，完成高光谱图像的黑白标定，使采集得到的初始图像 R_0 变成校准图像 R，即

$$R = \frac{R_0 - D}{W - D} \tag{1}$$

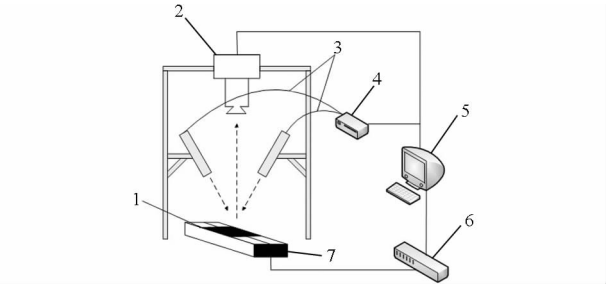

图 1　高光谱图像采集系统

Fig. 1　Hyperspectral imaging acquisition system

1. 样本　2. 可见-近红外相机　3. 光纤　4. 直流可调节光源
5. 计算机　6. 控制器　7. 位移台

最后用 SpectralCube（Spectral Imaging Ltd.，Finland）软件平台对样本进行逐一高光谱图像采集。

1.2 建模方法

1.2.1 SVM 算法

支持向量机（Support vector machine，SVM）是由 Vapnik 首先提出的[11]，其原理是基于统计学习理论采用结构风险最小化准则，在最小化样本点误差的同时最小化结构风险，提高了模型的泛化能力，且没有数据维数的限制。在进行线性分类时，将分类面取在两类样本距离较大处，进行非线性分类时通过高维空间变换，将非线性分类变成高维空间的线性分类问题。

1.2.2 BP 神经网络

BP 神经网络[12]是一种多层前馈神经网络，BP 的网络拓扑由输入层、隐含层和输出层组成。该网络的主要思想是信号的前向传递，误差反向传播。在前向传递中输入信号从输入层经隐含层逐层处理，直至输出层。每一层的神经元状态只影响下一层神经元状态。如果输出层得不到期望的输出，则转入反向传播，根据预测误差调整网络权值和阈值，从而使 BP 神经网络输出不断逼近期望输出。

1.2.3 ELM 算法

极限学习机（Extreme learning machine，ELM）[9]是 Huang 针对单隐层前馈神经网络（SLFN）提出的新算法。

含有 L 个隐含层节点的 SLFN 的输出表达式为

$$f_L(\boldsymbol{x}) = \sum_{i=1}^{L} \boldsymbol{\beta}_i \boldsymbol{G}(a_i, b_i, \boldsymbol{x}) \tag{2}$$

其中 $\boldsymbol{x} \in \mathbf{R}^n$，$a_i \in \mathbf{R}^n$，$\boldsymbol{\beta}_i \in \mathbf{R}^m$，$a_i$ 是输入层到第 i 个节点的连接权值，b_i 表示第 i 个隐含层节点的阈值，$\boldsymbol{\beta}_i = (\beta_{i1}, \beta_{i2}, \cdots, \beta_{im})^{\mathrm{T}}$ 为隐含层第 i 个节点到输出层的连接权值，$\boldsymbol{G}(a_i, b_i, \boldsymbol{x})$ 表示第 i 个隐含层节点与输入 $\boldsymbol{x}$ 的关系，假设激励函数为 $\boldsymbol{g}(\boldsymbol{x})$，则有

$$\boldsymbol{G}(a_i, b_i, \boldsymbol{x}) = \boldsymbol{g}(a_i \boldsymbol{x} + b_i) \quad (b \in \mathbf{R}) \tag{3}$$

给定任意 N 个样本 $(x_i, t_i) \in \mathbf{R}^n \times \mathbf{R}^m$，其中 $x_i \in \mathbf{R}^n$ 为输入，$t_i \in \mathbf{R}^m$ 为输出，如果含有 L 个隐含节点的 SLFN 以任意小误差来逼近这 N 个样本，则存在 $\boldsymbol{\beta}_i$、a_i、b_i，使

$$f_L(x_j) = \sum_{i=1}^{L} \boldsymbol{\beta}_i \boldsymbol{G}(a_i, b_i, x_j) = \boldsymbol{t}_j \quad (j = 1, \cdots, N) \tag{4}$$

式(4)可以简化为

$$\boldsymbol{H}\boldsymbol{\beta} = \boldsymbol{T} \tag{5}$$

其中

$$\boldsymbol{H}(a_1, \cdots, a_N, b_1, \cdots, b_N, x_1, \cdots, x_N) = \begin{bmatrix} G(a_1, b_1, x_1) & \cdots & G(a_N, b_N, x_1) \\ \vdots & \cdots & \vdots \\ G(a_1, b_1, x_N) & \cdots & G(a_N, b_N, x_N) \end{bmatrix}_{N \times N} \tag{6}$$

$$\boldsymbol{\beta} = \begin{bmatrix} \boldsymbol{\beta}_1^{\mathrm{T}} \\ \vdots \\ \boldsymbol{\beta}_N^{\mathrm{T}} \end{bmatrix}_{N \times m} \qquad \boldsymbol{T} = \begin{bmatrix} \boldsymbol{t}_1^{\mathrm{T}} \\ \vdots \\ \boldsymbol{t}_N^{\mathrm{T}} \end{bmatrix}_{N \times m}$$

式中　$\boldsymbol{H}$——隐藏层输出矩阵

$\boldsymbol{\beta}$ 可以通过求解以下方程组的最小二乘解获得

$$\min_{\boldsymbol{\beta}} \| \boldsymbol{H}\boldsymbol{\beta} - \boldsymbol{T} \| \tag{7}$$

其解为

$$\hat{\boldsymbol{\beta}} = \boldsymbol{H}^{+} \boldsymbol{T} \tag{8}$$

其中 $\boldsymbol{H}^{+}$ 是隐含层输出矩阵 $\boldsymbol{H}$ Moore - Penrose 广义逆。因此，ELM 分类器的决策函数[13]可以构造的

形式为

$$f_N(\boldsymbol{x}) = \mathrm{sign}\left(\sum_{i=1}^{m} \boldsymbol{\beta}_i h_{ix}\right) = \mathrm{sign}(h(\boldsymbol{x})\boldsymbol{\beta}) \quad (9)$$

1.3 计算机软硬件平台

研究是在计算机 CPUi3 - 2330/2.20 GHz/2 GB 硬件环境和 Windows 7 操作系统下,利用 ENVI 4.5 和 Matlab 7.11(2009a)进行光谱的采集和生菜叶片氮素水平丰缺鉴别模型的建立。

2 结果分析和处理

2.1 样本训练集与测试集的建立

针对每个生菜叶片样本的高光谱图像,避开主叶脉在高光谱图像中选叶片左上、左下、右上、右下 4 个 60×60 像素点为感兴趣区域(ROI)的平均值作为样本的原始光谱,具体示意图如图 2 所示。本研究采集了 252 条光谱曲线数据(缺氮类、正常类和过氮类各 84 组),提取的光谱曲线原始数据为252×512 维。实验所有样本的原始高光谱图像光谱曲线如图 3 所示。采集的光谱范围为 390 ~ 1 050 nm,从图 3 可以看出在 410 nm 以下和 750 nm 以上光谱值存在一定的噪声,并且氮素的吸收光谱主要集中在 400 ~ 700 nm 范围内,因此截取 411 ~ 860 nm(光谱数据 252×353 维)范围内的平均光谱进行分析。

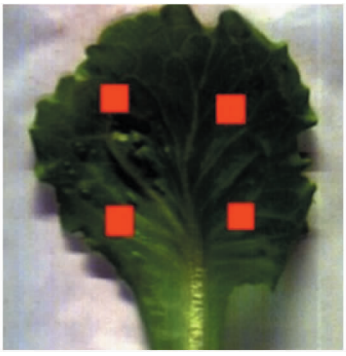

图 2 高光谱图像中的 4 个 60×60 像素点的 ROI

Fig. 2 Four different positions of 60×60 pixel as region of interest on hyperspectral imaging

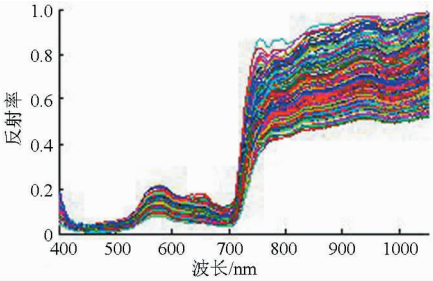

图 3 样本的高光谱图像原始光谱曲线

Fig. 3 Original spectra of samples' hyperspectral images

2.2 光谱预处理

采集到的生菜叶片光谱不仅反映生菜叶片氮素的丰缺情况,还受到背景噪声、样本的表面纹理等特定的物理因素的影响[14],因此在模型建立前需要对采集的样本的高光谱图像原始光谱进行预处理。采用标准正态变量校正(Standard normal variate correction, SNV)[15]对原始光谱进行预处理。SNV 变换公式为

$$x_{i,\mathrm{SNV}} = \frac{x_i - \bar{x}}{\sqrt{\sum_{i=1}^{n}(x_i - \bar{x})^2/n}} \quad (10)$$

式中,$x_{i,\mathrm{SNV}}$ 是第 i 条光谱经 SNV 变换后的光谱数据,$\bar{x}$ 是第 i 条光谱的 n 个光谱点的平均值。经 SNV 处理后的光谱曲线如图 4 所示。

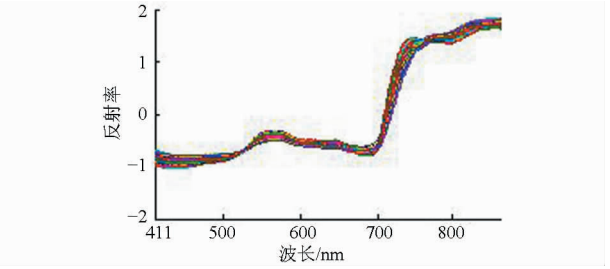

图 4 SNV 处理后的光谱曲线

Fig. 4 Spectra after preprocessed by SNV

高光谱图像的光谱数据量比较大,相邻的波段具有较强的相关性,使得高光谱图像的光谱数据中存在大量的冗余信息[16],因此有必要通过降维处理以寻找其特征光谱,这样不仅可以提高后期数据处理的速度,而且可以去除数据中的冗余信息。本文采用主成分分析(Principal component analysis, PCA)[17]进行特征提取,为了最大程度地保留原始光谱的所有信息,将文中的原始光谱(252×353 维)经 PCA 降维后变为 252×250 维。每个氮素水平的光谱数据各取一半分别作为训练样本数据和测试样本数据,即 126 个样本作为训练样本集,剩余的 126 个样本作为测试样本集。

2.3 定性模型建立及结果分析

2.3.1 SVM 模型

Huang 把 SVM 看成了神经网络[9],该思想把神经网络的输入层到最后一层隐含层的部分或者 SVM 核函数映射的部分都看成了从输入空间到一个新的空间的转换。在构建 SVM 网络模型时在保证模型其他参数不变情况下,要考虑核函数对模型的影响,本文采用默认的 RBF 核函数。实验运行时间为 0.530 59 s,分类正确率为 55.556%。SVM 模型测试分类图如图 5 所示。

2.3.2 BP 神经网络模型

BP 神经网络隐含层节点数对 BP 神经网络训练精度有较大的影响,节点数太少,网络不能很好学

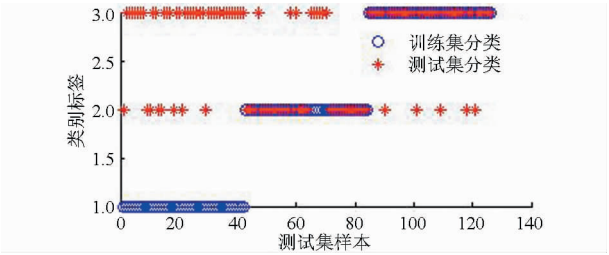

图 5　SVM 模型测试分类图

Fig. 5　Classification of test's figures by SVM model

习，需要增加训练次数，训练精度也受到影响，节点太多，训练时间增加，网络容易出现过拟合。BP 最佳隐含层节点数选择可参考公式 $L < \sqrt{m+n} + \alpha$，式中 n 为输入层节点数，L 为隐含层节点数，m 为输出层节点数，α 为 0 ~ 10 之间的常数。本研究输入层节点为 250，输出层为 3，通过计算 BP 隐含层节点数为 0 ~ 20。为了构建分类器的最优分类正确率，不同的隐含层节点数逐一实验，最终确定隐含层节点数为 5（如图 6 所示），误差指数设置为 0.001，训练步长为 0.05，训练次数为 5 000。本实验运行时间为 7.031 1 s，由于 BP 网络分类输出结果为非整数结果，因此程序中进行了四舍五入处理，分类正确率 99.206 3%。

BP 模型测试分类图如图 7 所示。

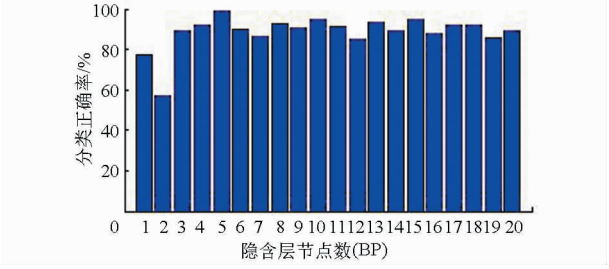

图 6　BP 模型隐含层各节点分类正确率

Fig. 6　Classification accuracy of BP model's nodes in the hidden layer

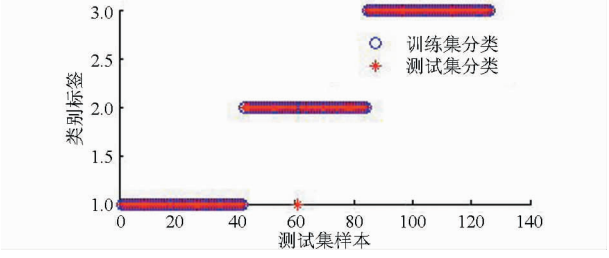

图 7　BP 模型测试分类图

Fig. 7　Classification of test's figures by BP model

2.3.3　ELM 网络模型

ELM 算法在建立模型之前只要确定网络激励函数和隐含层节点数就可以了，选用 Sigmoidal 函数作为 ELM 网络的激励函数。为了与 BP 神经网络进行对比，ELM 的隐含层节点数也选用 0 ~ 20，并在其中根据分类正确率情况选择最佳隐含层节点，隐含层节点数为 0 ~ 20 的模型的分类情况如图 8 所示。故本文设定隐含层节点数为 17。实验运行时间为 0.623 04 s，分类正确率为 100%。ELM 模型测试分类图如图 9 所示。

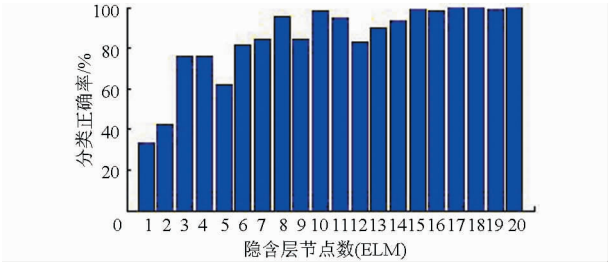

图 8　ELM 模型隐含层各节点分类正确率

Fig. 8　Classification accuracy of ELM model's nodes in the hidden layer

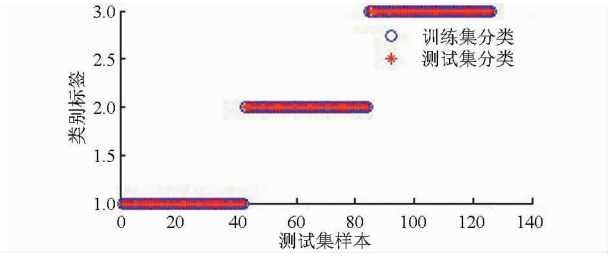

图 9　ELM 模型测试分类图

Fig. 9　Classification of test's figure by ELM model

2.3.4　结果讨论

实验具体的分类结果如表 1 所示。从表 1 可以看出 SVM 分类模型在训练时间上与 ELM 模型相当，但分类正确率较低。BP 网络模型与 ELM 网络模型在模式分类效果相当的情况下，BP 网络模型的拓扑结构明显比 ELM 的拓扑结构要简单。在训练时间上，ELM 网络模型的训练时间比 BP 网络模型短，这主要是因为 ELM 算法在训练过程中不需要调整输入层的连接权值和隐含层的神经元阈值，只需确定好一个无限可微的函数作为隐含层激励函数和隐含层节点数，这样可有效节省大量训练时间，而 BP 网络各个参数的最终确定，需要在每一次的训练过程中不断迭代更新，以期寻求最佳网络参数。因此，总体衡量分类正确率与训练时间 2 个因素，ELM 模型的泛化能力要优于 SVM 模型和 BP 网络模型。

表 1　3 种模型分类结果

Tab. 1　Classification results of the three model

模型	隐含层节点数	运行时间/s	分类正确率/%
SVM		0.530 59	55.556
BP	5	7.031 1	99.206 3
ELM	17	0.623 04	100

3　结束语

利用高光谱图像采集系统对不同氮素水平的生

菜叶片进行图像采集,提取了生菜叶片高光谱图像的4个感兴趣区域光谱平均数据作为原始的光谱曲线,经过光谱预处理(SNV)对原始光谱数据进行预处理,利用主成分分析(PCA)对光谱进行特征提取,确定ELM网络模型的激励函数和最佳分类正确率隐含层节点数,构造生菜氮素丰缺判断分类器,并与传统的BP网络模型和SVM模型进行比较。设定BP和ELM模型确定隐含层节点数为5和17时,SVM、BP和ELM模型训练时间分别为0.530 59 s、7.031 10 s、0.623 04 s,分类正确率分别为55.556%、99.206 3%、100%。综合考虑实验结果表明,ELM网络模型优于BP网络模型和SVM模型。利用高光谱图像技术和ELM构建分类模型定性分析生菜氮素水平丰缺状况(缺氮、正常、过氮)的思路是可行的,研究结果能为生菜生长过程中适时合理施加氮肥提供参考。

参 考 文 献

1 叶新新,常江,刘春盛. 油菜叶片氮吸收量与其产量预测关系的研究[J]. 安徽农业大学学报,2009,36(1):144-148.

2 贾良良,范明生,张福锁,等. 应用数码相机进行水稻氮营养诊断[J]. 光谱学与光谱分析,2009,29(8):2176-2179.
Jia Liangliang, Fan Mingsheng, Zhang Fusuo, et al. Nitrogen status diagnosis of rice by using a digital camera[J]. Spectroscopy and Spectral Analysis, 2009, 29(8): 2176-2179. (in Chinese)

3 石吉勇,邹小波,赵杰文,等. 近红外光谱技术快速无损诊断黄瓜植株氮、镁元素亏缺[J]. 农业工程学报,2011,27(8):283-287.
Shi Jiyong, Zou Xiaobo, Zhao Jiewen, et al. Rapid and non-destructive diagnostics of nitrogen and magnesium deficiencies in cucumber plants by near-infrared spectroscopy[J]. Transactions of Chinese Society of Agricultrual Engineering, 2011, 27(8): 283-287. (in Chinese)

4 徐贵力,毛罕平,李萍萍. 缺素叶片彩色图像颜色特征提取的研究[J]. 农业工程学报,2002,18(4):150-155.
Xu Guili, Mao Hanping, Li Pingping. Extracting color features of leaf color images[J]. Transactions of the Chinese Society of Agricultural Engineering, 2002, 18(4): 150-155. (in Chinese)

5 毛罕平,吴雪梅,李萍萍. 基于计算机视觉的番茄缺素神经网络识别[J]. 农业工程学报,2005,21(8):106-109.
Mao Hanping, Wu Xuemei, Li Pingping. Recognition of tomato nutrient deficiency using aritificial neural network based on computer vision[J]. Transactions of the Chinese Society of Agricultural Engineering, 2005, 21(8): 106-109. (in Chinese)

6 关海鸥,衣淑娟,焦峰,等. 农作物缺素症状诊断的正则化模糊神经网络模型[J]. 农业机械学报,2012,43(5):162-167,156.
Guan Haiou, Yi Shujuan, Jiao Feng, et al. Diagnosis model of crop nutrient deficiency symptoms based on regularized adaptive fuzzy neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2012, 43(5): 162-167, 156. (in Chinese)

7 Wiwart M, Fordonski G, Zuk-Golaszewska K, et al. Early diagnostics of macronutrient deficiencies in three legume species by color image analysis[J]. Computers and Electronics in Agriculture, 2009, 65(1): 125-132.

8 石吉勇,邹小波,赵杰文,等. 高光谱图像技术检测黄瓜叶片的叶绿素叶面分布[J]. 分析化学,2011,39(2):243-247.
Shi Jiyong, Zou Xiaobo, Zhao Jiewen, et al. Measurement of chlorophyll distribution in cucumber leaves based on hyper-spectral imaging technique[J]. Chinese Journal of Analytical Chemistry, 2011, 39(2): 243-247. (in Chinese)

9 Guangbin Huang, Dianhui Wang, Yuan Lan. Extreme learning machines: a survey[J]. International Journal of Machine Learning and Cybernetics, 2011, 2(2): 107-122.

10 曲明山,董海泉,邢文鑫,等. 调整山崎生菜营养液配方对生菜产量及品质的影响[J]. 河北农业科学,2012,16(8):31-35.

11 Suykens J A K, Lukas L, Vandewalle J. Sparse aparse approximation using least squares support vector machines[C]// Proceedings of the IEEE International Symposium on Circuits and Systems, 2000, 2: 757-760.

12 朱文学,孙淑红,陈鹏涛,等. 基于BP神经网络的牡丹花热风干燥含水率预测[J]. 农业机械学报,2011,42(8):128-130.
Zhu Wenxue, Sun Shuhong, Chen Pengtao, et al. Moisture content prediction modeling of hot-air drying for pressed peony based on BP neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2011, 42(8): 128-130. (in Chinese)

13 Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and application[J]. Neurocomputing, 2006, 70(1~3): 489-501.

14 Kamruzzaman M, ElMasry G, Sun D W, et al. Prediction of some quality attributes of lamb meat using near-infrared hyperspectral imaging and multivariate analysis[J]. Analytica Chimica Acta, 2012, 714: 57-67.

15 郭婷婷,邬文锦,苏谦,等. 近红外玉米品种鉴别系统预处理和波长选择方法[J]. 农业机械学报,2009,40(增刊):87-91.
Guo Tingting, Wu Wenjin, Su Qian, et al. Effects of spectral pretreatment and wavelength selection on discrimination of maize seed varieties by NIR spectroscopy[J]. Transactions of the Chinese Society for Agricultural Machinery, 2009, 40(Suppl.): 87-91. (in Chinese)

16 De L M, Terouzi W, Kzaiber F, et al. Classification of moroccan olive cultivars by linear discriminant analysis applied to ATR-FTIR spectra of endocarps[J]. International Journal of Food Science and Technology, 2012, 47(6): 1286-1292.

17 武小红,唐凯,孙俊,等. 基于Adaboost-OLDA和近红外光谱的猪肉贮藏时间检测研究[J]. 光谱学与光谱分析,2012,32(12):3238-3241.
Wu Xiaohong, Tan Kai, Sun Jun, et al. Discrimination of pork storage time using near infrared spectroscopy and Adaboost-OLDA[J]. Spectroscopy and Spectral Analysis, 2012, 32(12): 3238-3241. (in Chinese)

Discrimination of Lettuce Leaves' Nitrogen Status Based on Hyperspectral Imaging Technology and ELM

Sun Jun[1]　Wei Aiguo[1]　Mao Hanping[2]　Wu Xiaohong[1]　Zhang Xiaodong[2]　Gao Hongyan[2]

(1. *School of Electrical and Information Engineering*, *Jiangsu University*, *Zhenjiang* 212013, *China*

2. *Jiangsu Provincial Key Laboratory of Modern Agricultural Equipment and Technology*, *Jiangsu University*, *Zhenjiang* 212013, *China*)

Abstract: Discrimination of crop's nitrogen level can contribute to reasonable and effective fertilization. Lettuces of various nitrogen levels were planted in three soilless nutrient solutions of different nitrogen concentrations. In the rosette stage, 84 lettuce leaves of each nitrogen level were collected and scanned by the hyperspectral imaging acquisition system. In every hyperspectral image of lettuce leaf, four different positions of 60 × 60 pixel were selected as regions of interest (ROI). The average spectral data of the ROI were used as the original spectra of the leaf samples. The original spectra were preprocessed by the standard normal variate correction (SNV), and their dimensionalities were reduced through principal component analysis (PCA). ELM algorithm was used to establish model for the training samples, and then was compared with BP algorithm model and SVM algorithm model. The results show that the running time of ELM model is 0.623 04 s and its classification accuracy rate is 100%. During the same running time, the classification accuracy rate of ELM model is higher than that of SVM model. At the same classification accuracy rate, the running time of ELM model is shorter than that of BP model.

Key words: Lettuce leaf　Hyperspectral imaging technology　Extreme learning machine　Nitrogen status

(上接第 230 页)

State-of-the-art and Developing Strategies of Agricultural Internet of Things

Ge Wenjie[1]　Zhao Chunjiang[2]

(1. *College of Engineering*, *Heilongjiang Bayi Agricultural University*, *Daqing* 163319, *China*

2. *Beijing Research Center for Information Technology in Agriculture*, *Beijing* 100097, *China*

3. *Key Laboratory of Information Technology in Agriculture*, *Ministry of Agriculture*, *Beijing* 100097, *China*)

Abstract: Agricultural internet of things (Ag-IoT) is the highly integrated and comprehensive application of the new generation of information technology in agricultural field. Ag-IoT is playing an important leading role in the agricultural informationization of China. It has changed the traditional agricultural production mode, and it is also promoting the transformation from the traditional agriculture to intelligent and precision agriculture. The concept of Ag-IoT and its technical system framework were firstly introduced. Then the research status and advances of sensing technologies, communicating technologies and key application technologies used in Ag-IoT were reviewed in detail. The challenges and problems existing in the development of Ag-IoT in China were further analyzed. Based on the analysis, countermeasures for the applications and development of Ag-IoT of China in many aspects were proposed, such as research priorities, development layout, advancing directions, application models and mechanisms for sustainable development.

Key words: Ag-IoT　Sensor　State-of-the-art　Strategy