

基于高光谱成像技术结合堆栈自动编码器-极限学习机方法的苹果硬度检测

饶利波¹, 庞涛¹, 纪然仕¹, 陈晓燕^{2,3*}, 张洁²

¹四川农业大学机电学院, 四川 雅安 625014;

²四川农业大学信息工程学院, 四川 雅安 625014;

³四川农业大学农业信息工程四川省重点实验室, 四川 雅安 625014

摘要 将堆栈自动编码器(SAE)与极限学习机(ELM)联合,建立了深度神经网络预测模型(SAE-ELM)。利用苹果高光谱图像提取出的光谱数据,对深度神经网络的权值和阈值进行了初始化和微调。与传统 ELM 模型预测结果相比,SAE-ELM 的预测集决定系数和残留预测偏差分别从 0.7345 和 1.968 提升至 0.7703 和 2.116,预测集方均根误差从 1.6297 降至 1.2837。研究结果表明:深度学习网络 SAE-ELM 模型的预测性能优于传统的 ELM 模型,将其用于预测苹果硬度是可行的。

关键词 光谱学; 高光谱成像技术; 硬度; 堆栈自动编码器; 极限学习机; 无损检测

中图分类号 O433.4

文献标识码 A

doi: 10.3788/LOP56.113001

Firmness Detection for Apples Based on Hyperspectral Imaging Technology Combined with Stack Autoencoder-Extreme Learning Machine Method

Rao Libo¹, Pang Tao¹, Ji Ranshi¹, Chen Xiaoyan^{2,3*}, Zhang Jie²

¹College of Mechanical and Electrical Engineering, Sichuan Agricultural University, Yaan, Sichuan 625014, China;

²College of Information Engineering, Sichuan Agricultural University, Yaan, Sichuan 625014, China;

³Sichuan Provincial Key Laboratory of Agricultural Information Engineering, Sichuan Agricultural University, Yaan, Sichuan 625014, China

Abstract Based on a stack autoencoder (SAE) combined with an extreme learning machine (ELM), we built a deep neural-network prediction model, SAE-ELM. We initialized and fine-tuned the weights and thresholds of the deep neural networks using the spectral data extracted from the hyperspectral images of apples. Compared with the results of the traditional ELM model, the SAE-ELM determination coefficient of the prediction set increases from 0.7345 to 0.7703, the SAE-ELM residual prediction bias increases from 1.968 to 2.116, and the square root error of the prediction set decreases from 1.6297 to 1.2837. These research results show that the performance of the SAE-ELM model is superior to that of the traditional ELM model, and it is feasible for the proposed model to predict apple firmness.

Key words spectroscopy; hyperspectral imaging techniques; firmness; stack autoencoder; extreme learning machine; nondestructive testing

OCIS codes 300.6170; 300.6340; 300.6550

1 引言

硬度是影响苹果口感与判断苹果成熟度的重要

质量参数之一。传统的硬度检测方法费时费力且具有破坏性,无法满足行业生产对硬度检测提出的快速无损的需求。

收稿日期: 2018-12-17; 修回日期: 2018-12-20; 录用日期: 2019-01-02

基金项目: 四川省教育厅自然科学基金项目(17ZB0333)

* E-mail: xycheng123@hotmail.com

高光谱成像技术现已广泛应用于各种农产品的内外品质检测领域:魏文松等^[1]利用高光谱系统对猪肉中挥发性盐基氮(TVB-N)含量进行检测,所得预测集相关系数和预测集方均根误差(R_{RMSEP})分别为0.9040和 3.81×10^{-5} ;Lu^[2]基于高光谱散射成像技术使用主成分分析(PCA)和反向传播(BP)神经网络建立“Golden Delicious”苹果硬度预测模型,所得预测集决定系数 R_p^2 和 R_{RMSEP} 分别为0.74和6.20;Zhu等^[3]利用高光谱结合一种新的半监督亲和力传播算法和偏最小二乘(PLS)回归对“Golden Delicious”苹果进行硬度检测,模型预测集相关系数 R 为0.862, R_{RMSEP} 为6.1 N;李瑞等^[4]建立基于高光谱图像的蓝莓糖度和硬度无损测量方法,糖度和硬度的验证集相关系数分别为0.774和0.871。相较于近红外光谱分析技术,高光谱成像技术能同时提供光谱信息和图像信息,而高光谱图像上的像素级信息还可为建立模型提供大量的无标签数据,但巨大的数据量也会给预测模型增加计算负担。传统的简化模型方法是用竞争自适应重加权采样(CARS)^[5-6]、连续投影法(SPA)^[7]和遗传算法(GA)^[8-9]等特征变量筛选算法在全光谱中选择具有代表性的关键变量用于构建模型。深度神经网络在大规模数据处理方面具有显著优势,可利用堆栈自动编码器(SAE)学习深度特征并耦合,如softmax分类器和前向神经网络(FNN)回归模型等已应用于数字识别和回归预测等领域^[10-11]。相较于变量筛选算法,深度神经网络更容易捕捉到数据中的非线性信息,进而有效提升模型的预测精度。本文结合SAE^[12-13]和极限学习机(ELM)^[14]的优点,提出了SAE-ELM深度神经网络预测模型,并对该模型用于苹果硬度预测的可行性进行了探索。

2 材料与方法

2.1 样品准备

在雅安市雨城区水果市场采购126个体积大小相近的烟台红苹果,将苹果安全无损伤地运回实验室,洗净,贴好标签。在获取苹果的高光谱图像前,将苹果静置于实验室24 h。静置期间实验室温度处于 $(20 \pm 2)^\circ\text{C}$,以消除温度对吸光度的影响。

2.2 高光谱图像采集

由GaiaSorter高光谱分选仪(北京卓立汉光仪器有限公司)采集样品的高光谱图像。

如图1所示,该成像系统主要包括一台像素分辨率达 $1344 \text{ pixel} \times 1024 \text{ pixel}$ 的CCD相机、4个功率为200 W的溴钨灯光源、一个电动平移台和一台电脑。本实验所用成像仪光谱范围为 $387 \sim 1034 \text{ nm}$,采样间隔为2.8 nm,共计256个波段。采集时,电动平移台的移动速度为0.5 cm/s,相机镜头与样品表面距离255 mm,曝光时间为11 ms。为了消除环境因素和系统配置的影响,需要对采集的苹果原始高光谱图像进行黑白校正,校正公式为

$$R = \frac{R_{\text{raw}} - R_{\text{dark}}}{R_{\text{white}} - R_{\text{dark}}} \times 100\%, \quad (1)$$

式中: R 为校正后图像; R_{raw} 为原始高光谱图像; R_{white} 和 R_{dark} 分别为标准全白图像(反射率100%)和标准全黑图像(反射率0)。




图1 高光谱成像系统结构图

Fig. 1 Structural diagram of hyperspectral imaging system

2.3 光谱数据提取与预处理

由于SAE需要大量的无标签数据进行预训练,所以在获得苹果的高光谱图像之后,先在每张校正图像上的苹果区域内随机提取1000个像素点的光谱数据组成一个 126000×256 的大数据集矩阵。然后,在苹果邻近赤道部位手动选定一个 $60 \text{ pixel} \times 60 \text{ pixel}$ 的图形感兴趣区域(ROIs),提取该区域内所有像素点的平均光谱数据。以上操作均在软件ENVI5.1(美国ITT公司)上完成。

图2是苹果高光谱图像上单个像素点的原始光谱,由图可知,光谱的 $387 \sim 400 \text{ nm}$ 和 $1000 \sim 1034 \text{ nm}$ 两部分存在明显噪声,故截取每个样品 $400 \sim 1000 \text{ nm}$ 范围的光谱用于进一步分析,其中波段共计237个。样品的平均光谱在作进一步数据分析前先利用直接信号校正(DOSC)方法进行预处理,像素点原始光谱数据不作预处理。

2.4 苹果硬度值测定

在采集完苹果高光谱图像后,使用GY-4水果硬度测试仪(浙江杭州拓普仪器有限公司)测定苹果硬度。在苹果赤道区域附近削去大约 2 cm^2 的果




图2 像素点原始光谱图

Fig. 2 Original spectrum of pixel points




图3 基础 ELM 网络结构

Fig. 3 Basic network structure of ELM

皮,将去果皮区域置于直径为 3.5 mm 的探针下方,使探针透射入果肉组织 10 mm,记录以牛顿(N)为表达单位的测试仪示数。对同一苹果的不同区域重复以上操作 3 次,取平均值作为该样本的实际测量值。

3 数据分析方法原理

3.1 ELM

ELM 是一种学习速度快且拥有良好泛化性能的单隐含层前向神经网络(SLFNs)。如图 3 所示, $[x_1, x_2, \dots, x_n]$ 是输入变量数, n 是输入变量数序号, $[y_1, y_2, \dots, y_m]$ 是输出变量数, m 是输出节点序号, $[o_1, o_2, \dots, o_L]$ 是隐含层神经元数, L 是隐含层节点序号, w_{ij} 和 β_{jk} 分别是输入权值和输出权值。与传统的训练算法不同,ELM 在激活函数无限可微的前提下,可以随机设置输入权值和隐含层阈值,并通过解方程得到连接隐含层与输出层的权值^[15]。ELM 的输出数学模型表示为

$$f(x_j) = \sum_{i=1}^L \beta_i g_i(w_i x_j + b_i), j = 1, 2, \dots, N, \quad (2)$$

式中: x_j 为 j 个样本的输入变量; w_i 为连接隐含层节点和输入层节点的权值向量; β_i 为连接隐含层和输出层的权值向量; $g(\cdot)$ 为激活函数(本实验选择 sigmoid 函数作为激活函数); b_i 为隐含层节点的阈值矩阵; l 为隐含层节点个数; i 为隐含层节点序号; N 为样本个数。当 $l=N$ 时,激活函数则以 0 误差逼近这 N 个训练样本,可表示为

$$\|H\beta - T\| = 0, \quad (3)$$

式中: $H = [g_1, g_2, \dots, g_N]$ 为隐含层的输出矩阵; T 为浓度矩阵。当 $l < N$ 时,矩阵 H 是非方的不可逆矩阵, $H\beta = T$ 不存在。因此,输出权值则以 Moore-Penrose 广义逆 H^+ 代替,可表示为

$$\hat{\beta} = H^+ T. \quad (4)$$

3.2 SAE-ELM

基础自动编码器是一个包含输入层 x 、隐含层 y 和输出层 z 的前向型神经网络。通常将输入数据 $x \in \mathbf{R}^d$ (维度为 d 维)通过非线性激活函数映射到隐含层 $y \in \mathbf{R}^p$ (维度为 p 维)的阶段称为编码,将隐含层输出 $y \in \mathbf{R}^p$ 映射至输出层 $z \in \mathbf{R}^d$ 阶段称之为解码^[16]。这两步可用公式表示为

$$y = g(wx + b), \quad (5)$$

$$z = g(w^T y + b), \quad (6)$$

式中: w^T 为 w 的转置。

从图 4(a)可知,输出 z 的维度与输入 x 相等,因此输出 z 可视为对输入 x 的重构。本文的优化目标就是使输入与输出之间的重构误差最小,重构误差可表示为

$$\arg \min_{w, w^T, b} \|x - z\|^2. \quad (7)$$

当自动编码器以极小误差重构输出 z 时,说明隐含层 y 包含了输入数据 x 的绝大部分信息,是输入数据在维度 p 上的最佳代表。

SAE 将多个自动编码器堆叠在一起,采用贪婪逐层训练方法以无监督的方式对每个自动编码器进行单独训练,以解决传统多层神经网络训练的梯度弥散问题。在第一个自动编码器训练好后,将其隐含层的输出作为下一个自动编码器的输入,并以此类推训练整个深度神经网络,此阶段称为无监督预训练。

SAE 预训练所用数据是无标签的像素点光谱数据,本身并不具备分类或回归的功能;因此,在预训练完成后,将 SAE 的解码部分去除,并将编码部分与 ELM 耦合成一个具有回归功能的深度网络结构 SAE-ELM。如图 4(b)所示,将 SAE 中最后一层和倒数第二层的自动编码器的隐含层分别作为 ELM 的隐含层和输入层,图中 W 为编码器输




图4 基础自动编码器和 SAE-ELM 的网络结构。(a)基础自动编码器;(b) SAE-ELM

Fig. 4 Network structures of basic auto-encoder and SAE-ELM. (a) Basic auto-encoder; (b) SAE-ELM

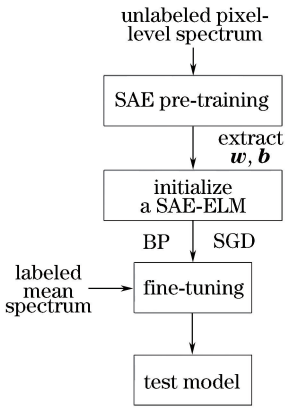


图5 SAE-ELM 训练流程图

Fig. 5 Flow chart of training in SAE-ELM

入权值, K 为 SAE 编码部分最后一层节点数, 同时也是 ELM 的隐含层节点数。对于节点数 K 的设置, 以 1 为步长, 依次选取范围在 15~22 之间的 8 个数作为节点数对模型进行测试, 在后续将其表示为 SAE-ELM(15), ..., SAE-ELM(22)。将预训练获得的权值和阈值作为 SAE-ELM 的初始参数, 其中以最后一层编码器的输入权值 W_i 和阈值替代 ELM 随机生成的输入权值和阈值, 但 ELM 的输出权值仍由解方程得到。然后, 将带有标签的训练集的平均光谱数据作为 SAE-ELM 的输入, 通过 BP 和小批量随机梯度下降(SGD)方法对整个网络的参数进行微调。SAE-ELM 训练流程如图 5 所示。损失函数表达式为

$$L = \frac{1}{2a} \sum_{i=1}^a (Y_i - \hat{Y}_i)^2, \quad (8)$$

式中: a 为训练样本数; Y_i 为苹果硬度实际测量值; \hat{Y}_i 为与之对应的预测值。利用 Matlab R2016b 平台实现整个 SAE-ELM 算法的编程, 其中 SAE 网络框架部分借助工具箱 DeepLearnToolbox(<https://github.com/rasmusbergpalm/DeepLearnToolbox>)

搭建。

3.3 模型评价

模型评价指数由训练集决定系数 R_C^2 、预测集决定系数 R_P^2 、训练集方均根误差 R_{RMSEC} 、预测集方均根误差 R_{RMSEP} , 以及预测集标准偏差 R_{SD} 与 R_{RMSEP} 的比值 R_{RPD} 组成。通常预测性能优异的模型, 其 R_C^2 和 R_P^2 值较高, R_{RMSEC} 和 R_{RMSEP} 的值较低。 R_C^2 和 R_{RMSEC} 代表模型对训练集数据的拟合能力, 而 R_P^2 、 R_{RMSEP} , 以及预测集 R_{RPD} 表示模型的泛化能力。因此评价模型预测能力时, 以 R_P^2 、 R_{RMSEP} 和预测集 R_{RPD} 为主要参考指标。当 $1.5 < R_{RPD} < 2.0$ 时, 说明该模型勉强具备预测能力, 但精度不高; 当 R_{RPD} 的值在 2.0~2.5 之间时, 说明该模型可以用于近似预测^[17]。评价指数公式为

$$R_C^2 = 1 - \frac{\sum_{i=1}^{n_t} (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^{n_t} (Y_i - Y_{\text{mean}})^2}, \quad (9)$$

$$R_P^2 = 1 - \frac{\sum_{i=1}^{n_p} (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^{n_p} (Y_i - Y_{\text{mean}})^2}, \quad (10)$$

$$R_{RMSEC} = \sqrt{\frac{1}{n_t} \sum_{i=1}^{n_t} (Y_i - \hat{Y}_i)^2}, \quad (11)$$

$$R_{RMSEP} = \sqrt{\frac{1}{n_p} \sum_{i=1}^{n_p} (Y_i - \hat{Y}_i)^2}, \quad (12)$$

$$R_{RPD} = \frac{R_{SD}}{R_{RMSEP}}, \quad (13)$$

式中: Y_i 为第 i 个苹果硬度测量值; \hat{Y}_i 为第 i 个苹果硬度预测值; Y_{mean} 为训练集和测试集苹果硬度测量值的平均值; n_t 和 n_p 分别为训练集和测试集的样本数量。

4 结果与讨论

4.1 苹果硬度测量值统计

将 126 个苹果由 Kennard-Stone 方法^[18]划分为训练集和预测集,训练集苹果硬度值的范围为 28.975~55.900,预测集硬度值的范围为 30.80~44.55。训练集硬度值范围囊括了预测集的硬度值范围,保证了训练模型所用信息的代表性。训练集与预测集的统计结果如表 1 所示。

表 1 训练集和预测集苹果硬度统计结果

Table 1 Statistics of apple firmness in calibration set and prediction set

Set	Number of samples	Min /N	Max /N	Mean /N	Bias
Total	126	28.975	55.900	36.438	4.147
Calibration	90	28.975	55.900	36.720	4.579
Prediction	36	30.800	44.500	35.733	2.717

表 2 ELM 模型和 SAE-ELM 模型苹果硬度的计算和预测结果

Table 2 Calibration and prediction results of apple firmness using ELM and SAE-ELM

Index	Index	Calibration		Prediction		
		R_C^2	R_{RMSEC}	R_P^2	R_{RMSEP}	R_{RPD}
ELM	Full spectral	0.8442	1.7998	0.7099	1.4427	1.883
ELM	Optimal spectral	0.8940	1.4445	0.7345	1.6297	1.968
SAE-ELM(15)	Full spectral	0.8347	1.8517	0.7335	1.3828	1.965
SAE-ELM(16)	Full spectral	0.8285	1.8860	0.6866	1.4994	1.812
SAE-ELM(17)	Full spectral	0.8075	1.9984	0.6252	1.6398	1.657
SAE-ELM (18)	Full spectral	0.8399	1.8222	0.7703	1.2837	2.116
SAE-ELM (19)	Full spectral	0.8633	1.6836	0.7097	1.4432	1.882
SAE-ELM (20)	Full spectral	0.8362	1.8431	0.6601	1.5618	1.740
SAE-ELM(21)	Full spectral	0.8674	1.6284	0.7440	1.3553	2.004
SAE-ELM(22)	Full spectral	0.8538	1.7412	0.7225	1.4111	1.925

使用规模为 90000×237 的训练集完成对 SAE 的逐层训练,训练次数为 100。以带标签的校正集样本的平均光谱数据作为输入对整个 SAE-ELM 网络进行微调,进一步优化网络的连接权值与阈值,微

4.2 ELM 模型结果

ELM 算法原理在 3.1 小节已讨论,除 SAE-ELM 回归模型外,本文也建立了基础的 ELM 回归模型,并比较分析了以全光谱和使用 CARS 方法选取的 15 个特征波段作为模型输入条件下的预测结果。如表 2 所示,全光谱的 ELM 模型计算结果为 $R_C^2=0.8442$, $R_{RMSEC}=1.7998$, $R_P^2=0.7099$, $R_{RMSEP}=1.4427$, $R_{RPD}=1.883$,说明该模型初步具备预测能力但并不理想。以特征波段为基础建立的预测模型结果为 $R_C^2=0.8940$, $R_{RMSEC}=1.4445$, $R_P^2=0.7345$, $R_{RMSEP}=1.6297$, $R_{RPD}=1.968$,与全光谱模型相比,预测精度和模型稳健性都有了一定的提升。

4.3 SAE-ELM 模型结果

目前,人们仍然是凭经验对神经网络隐含层的节点数进行设置,并没有固定的选择方式。本实验 SAE 网络结构设置为 237-150-100-50-K-50-100-150-237。

调循环次数为 1000。结果如表 2 所示,与其他模型预测结果相比,SAE-ELM(18)模型获得了最大的 $R_P^2=0.7703$ 和 $R_{RPD}=2.116$,以及最小的 $R_{RMSEP}=1.2837$ 。校正集样本和预测集样本的预测值和实际




图 6 校正集样本和预测集样本的预测值和实际测量值的散点图。(a) SAE-ELM (18);(b) ELM

Fig. 6 Scatter plots of prediction and measurements for samples in calibration set and prediction set.

(a) SAE-ELM (18); (b) ELM

测量值之间的散点图如图 6 所示, 尽管基于特征波段的 ELM 模型和 SAE-ELM(18) 模型的校正集样本的预测值和实际测量值之间的拟合优度大致一样, 但 SAE-ELM(18) 模型的预测集样本分布在直线周围的散点更加紧密, 拟合优度更好。

5 结 论

利用高光谱成像技术所提供的光谱信息对苹果硬度进行无损检测, 并综合 SAE 和 ELM 的优点提出了 SAE-ELM 深度网络回归模型。根据模型评价, SAE-ELM(18) 模型所得 $R_p^2 = 0.7703$, $R_{RMSEP} = 1.2837$ 和 $R_{RPD} = 2.116$, 相较于以 CARS 算法筛选出的 15 个特征波段为基础的 ELM 模型, R_p^2 和 R_{RPD} 分别增长了 4.8% 和 7.5%, R_{RMSEP} 下降了 21.2%。结果表明 SAE-ELM(18) 模型的预测性能要优于传统的 ELM 模型, 在苹果硬度检测方面具有良好的可行性。但本工作仍存在不足之处, 在对模型损失函数进行优化的过程中, 梯度下降的学习率是设定的固定学习率, 存在局部收敛或收敛过慢的风险。下一步工作将探究学习率随着训练次数动态更新对模型性能的影响。

参 考 文 献

[1] Wei W S, Peng Y K, Zheng X C, *et al.* Rapid determination of content of total volatile basic nitrogen in pork based on multispectral detection system with optimal wavelength [J]. *Acta Optica Sinica*, 2017, 37(11): 1130003.

魏文松, 彭彦昆, 郑晓春, 等. 基于优选波长的多光谱检测系统快速检测猪肉中挥发性盐基氮的含量 [J]. *光学学报*, 2017, 37(11): 1130003.

[2] Lu R F. Nondestructive measurement of firmness and soluble solids content for apple fruit using hyperspectral scattering images [J]. *Sensing and Instrumentation for Food Quality and Safety*, 2007, 1(1): 19-27.

[3] Zhu Q B, Huang M, Zhao X, *et al.* Wavelength selection of hyperspectral scattering image using new semi-supervised affinity propagation for prediction of firmness and soluble solid content in apples [J]. *Food Analytical Methods*, 2013, 6(1): 334-342.

[4] Li R, Fu L S. Nondestructive measurement of firmness and sugar content of blueberries based on hyperspectral imaging [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2017, 33(z1): 362-366.

李瑞, 傅隆生. 基于高光谱图像的蓝莓糖度和硬度无损测量 [J]. *农业工程学报*, 2017, 33(z1): 362-366.

[5] Li H D, Liang Y Z, Xu Q S, *et al.* Key wavelengths screening using competitive adaptive reweighted sampling method for multivariate calibration [J]. *Analytica Chimica Acta*, 2009, 648(1): 77-84.

[6] Wang C P, Huang W Q, Fan S X, *et al.* Moisture content detection of maize kernels based on hyperspectral imaging technology and CARS [J]. *Laser & Optoelectronics Progress*, 2016, 53(12): 123001.

王超鹏, 黄文倩, 樊书祥, 等. 基于高光谱成像技术与 CARS 算法的玉米种子含水率检测 [J]. *激光与光电子学进展*, 2016, 53(12): 123001.

[7] Zhang B H, Fan S X, Li J B, *et al.* Detection of early rottenness on apples by using hyperspectral imaging combined with spectral analysis and image processing [J]. *Food Analytical Methods*, 2015, 8(8): 2075-2086.

[8] Gao H Y, Mao H P, Zhang X D. Measurement of nitrogen content in lettuce canopy using spectroscopy combined with BiPLS-GA-SPA and ELM [J]. *Spectroscopy and Spectral Analysis*, 2016, 36(2): 491-495.

高洪燕, 毛罕平, 张晓东. 光谱技术结合 BiPLS-GA-SPA 和 ELM 算法的生菜冠层氮素含量检测研究 [J]. *光谱学与光谱分析*, 2016, 36(2): 491-495.

[9] Wang S T, Wang X L, Chen D Y, *et al.* Application of GA-BP neural network in detection of trace phosphate [J]. *Chinese Journal of Lasers*, 2015, 42(5): 0515001.

王书涛, 王兴龙, 陈东营, 等. GA-BP 神经网络在检测微量磷酸盐中的应用 [J]. *中国激光*, 2015, 42(5): 0515001.

[10] Lin S F, Sheng H X, Li Q W. Handwritten digital classification based on the stacked sparse autoencoders [J]. *Microprocessors*, 2015, 36(1): 47-51.

林少飞, 盛惠兴, 李庆武. 基于堆叠稀疏自动编码器的手写数字分类 [J]. *微处理机*, 2015, 36(1): 47-51.

[11] Yu X J, Lu H D, Wu D. Development of deep learning method for predicting firmness and soluble solid content of postharvest Korla fragrant pear using Vis/NIR hyperspectral reflectance imaging [J]. *Postharvest Biology and Technology*, 2018, 141: 39-49.

[12] Qu J L, Du C F, Di Y Z, *et al.* Research and

- prospect of deep auto-encoders [J]. *Computer and Modernization*, 2014(8): 128-134.
- 曲建岭, 杜辰飞, 邸亚洲, 等. 深度自动编码器的研究与展望[J]. *计算机与现代化*, 2014(8): 128-134.
- [13] Dai X A, Guo S H, Ren Y, *et al.* Hyperspectral remote sensing image classification using the stacked sparse autoencoder [J]. *Journal of University of Electronic Science and Technology of China*, 2016, 45(3): 382-386.
- 戴晓爱, 郭守恒, 任涓, 等. 基于堆栈式稀疏自编码器的高光谱影像分类[J]. *电子科技大学学报*, 2016, 45(3): 382-386.
- [14] Feng Y, Cui N B, Gong D Z, *et al.* Prediction model of reference crop evapotranspiration based on extreme learning machine [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2015(z1): 153-160.
- 冯禹, 崔宁博, 龚道枝, 等. 基于极限学习机的参考作物蒸散量预测模型[J]. *农业工程学报*, 2015(z1): 153-160.
- [15] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications [J]. *Neurocomputing*, 2006, 70(1/2/3): 489-501.
- [16] Vincent P, Larochelle H, Bengio Y, *et al.* Extracting and composing robust features with denoising autoencoders [C] // *Proceedings of the 25th International Conference on Machine Learning*, July 5-9 2008, Helsinki. New York: ACM, 2008: 1096-1103.
- [17] Suktanarak S, Teerachaichayut S. Non-destructive quality assessment of hens' eggs using hyperspectral images[J]. *Journal of Food Engineering*, 2017, 215: 97-103.
- [18] Chu X L. *Molecular spectroscopy analytical technology combined with chemometrics and its application*[M]. Beijing: Chemical Industry Press, 2011: 86-88.
- 褚小立. *化学计量学方法与分子光谱分析技术*[M]. 北京: 化学工业出版社, 2011: 86-88.