

# 基于弹性动量深度学习神经网络的果体病理图像识别\*

谭文学<sup>1,2</sup> 赵春江<sup>3</sup> 吴华瑞<sup>3</sup> 高荣华<sup>3</sup>

(1. 北京工业大学计算机学院, 北京 100124; 2. 湖南文理学院计算机科学与技术学院, 常德 415000;

3. 北京农业信息技术研究中心, 北京 100097)

**摘要:** 为了实时预警果蔬病害和辅助诊断果蔬疾病, 实现无人值守的病虫害智能监控, 设计了深度学习神经网络的果蔬果体病理图像识别方法, 基于对网络误差的传播分析, 提出弹性动量的参数学习方法, 以苹果为例进行果体病理图像的识别试验。结果表明, 该方法召回率为 98.4%; 同其他同源更新机制相比, 弹性动量方案能显著改善学习网络的果蔬病害识别准确率; 其收敛曲线平滑, 5 h 时耗能实现收敛, 对不同数据集也有良好泛化性能。

**关键词:** 果蔬病害 病理图像 深度学习神经网络 弹性动量 图像识别

**中图分类号:** TP183; TP391.41 **文献标识码:** A **文章编号:** 1000-1298(2015)01-0020-06

## A Deep Learning Network for Recognizing Fruit Pathologic Images Based on Flexible Momentum

Tan Wenxue<sup>1,2</sup> Zhao Chunjiang<sup>3</sup> Wu Huarui<sup>3</sup> Gao Ronghua<sup>3</sup>

(1. College of Computer Science, Beijing University of Technology, Beijing 100124, China

2. College of Computer Science and Technology, Hunan University of Arts and Science, Changde 415000, China

3. Beijing Research Center for Information Technology in Agriculture, Beijing 100097, China)

**Abstract:** Agricultural internet of things (IOT) and sensor technology has been widely used in the informationalized and mechanized orchard. The research aimed at both constructing an automatic-assistant diagnosis and a real-time alerting for plant disease and insect pest. The purpose also covered to realize an unmanned pest-disease monitoring and to release some human interaction in making a diagnosis. A method for pathologic image recognition-diagnosis based on deep learning neural network was designed and an innovative method for updating free parameters of the network was proposed on the basis of analyzing the error propagation of the network, so-called the gradient descent with flexible momentum. Then, computer recognizing pathologic images of fruit sphere was researched into systematically, where the apple was selected as a subject. Experiment result revealed the method manifested a recall rate at 98.4%. And in parallel with several well-known updating schemes based momentum, the proposal was able to obviously improve the accuracy of learning network with a flatter converging curve, at a cost of short converging time. The test upon the several popular benchmark datasets also demonstrated it could perform an effective recognition on the image pattern.

**Key words:** Plant disease and insect pest Pathological image Deep learning network Flexile momentum Image recognition

### 引言

我国水果蔬菜种植居世界首位, 但传统的栽培

管理技术依赖于农户的经验累积<sup>[1]</sup>, 准确性低, 效率不高。伴随着信息技术在农业领域的推广, 栽培管理专家系统得以广泛应用, 大大提高了农业生产

能力和科技水平<sup>[2]</sup>。然而,在云计算、物联网和大数据普及的 IT 环境下,其“短板”日益明显。对于面向知识的专家诊断系统,提取及表达疾病特征主要依赖自然人专家完成<sup>[3]</sup>,表达的规范化程度和精度常受人为因素影响,诊断准确率低。种植基地的传感网和其他信息化设备的部署大大便利了实时信息采集和传输,但基于结构化知识的传统生产管理系统无法及时响应图片、视频等实时数据,无法保障决策诊断在时间、空间上的一致性。

近年来,病理图像模式特征的自动提取及实时识别在农业信息化领域的应用已经成为一个新的研究热点。在无人值守的种植环境下,对布控点的果体生长进行监视,定时采集生理形态图像,运用机器学习技术对异常样本模式自动识别和预警。利用“电子眼”的方法实现植物病害信息的早期诊断及识别,对于果蔬的疾病治疗和植保植检都有着重要意义。

过去十几年,神经网络学习在图像模式识别和降维领域得到了成功应用<sup>[4-5]</sup>。模式识别关键步骤是特征提取,对识别精度有直接影响。由于感知数据的多样性和丰富性,仅仅依赖自然人领域专家围绕某个问题手工确立一套特征提取的通用方法已不现实。深度神经网络嵌入卷积和采样操作,自动提取模式的基元视觉特征,满足了复杂多变环境下感知图像的特征提取需求。

本文采用深度学习网络,基于卷积和采样元件的反向误差传播剖析,提出弹性动量参数学习机制,研究果体病理图像自动识别预警模型。

## 1 学习网络设计

观察发现,果体病理图像几何特征比较明显。同类疾病,在致病环境相差不大的情况下,病果图像往往表现出共性,这为通过视觉观察诊断果体病害提供了便利。例如:轮纹病病果都有同心圆纹路;黑星病病果常有星状分布的染病孔状区域,其他疾病病斑纹路也表现不同程度的相似之处。

实现无人值守的病害机器自动识别,首先应使机器具备自动提取病理图像几何特征的能力。图像传感器采集过程中不可避免会产生图像的平移、旋转和扭曲,该机器特征提取必须具备对上述干扰的良好免疫力。其次,病理图像中的非特征信息无助于机器的学习目标,必须予以过滤,反之,它将增加网络复杂度,使网络不可收敛。

考虑到上述需求,网络引入卷积和采样部件。卷积实现病理图像的几何特征提取需求;采样满足特征提取过程的去冗余需求。通过多级“卷积-采样”网络提取病害的图像特征。

### 1.1 网络结构和参数

学习网络中,同列的元件或者节点集合称之为“层”。连接一个节点的输出(该节点称为连接的前驱)和另外节点的输入(称为连接的后继)的权或者卷积算子称之为“连接”。信息单向地从前驱向后流向后继。层间联系通过连接来桥接,相邻连接通过层来分隔,多层依次连接构成学习网络。存储连接参数的数据结构定义在其后继层。

图 1 所示为果体图像识别的深度学习网络。层类型有 2 种,某层前驱连接为卷积算子则该层为卷积层;前驱连接为采样算子则为采样层。“全连接”是一个高斯连接,本质上就是纯感知元层。

### 1.2 网络模型分析

如图 2 所示,一批病害特征图构成一个帧序列,用立方体表示。“C”标注的带对角线的矩形表示卷积型全连接,连接表示后继和前驱之间的卷积算子关系。两端用“o”表示层的输入和输出;中间为 $f(\cdot)$ 的方框表示激励函数,其组合体表示神经元件,同行元件构成层。“S”标注的双垂直线的矩形表示卷积直通连接,算子为常量,直连输出同样数量的帧序列。考虑到稀疏网络结构的信息亏损,放弃了 LeNet-5<sup>[6]</sup>的稀疏卷积连接结构,采用了全连接结构。以此类推,最后提取到 192 个特征值,以“from 1 to 192”的矩形表示,并作为经典神经网络的输入。随后,中间无字母标注的对角线矩形,表示全连接,经




图 1 果体病害识别的卷积网络

Fig. 1 Convolution neural network for apple lesion image recognition

由激励函数,输出 20 个病类表决值,最大表决值的元件标签为输出。

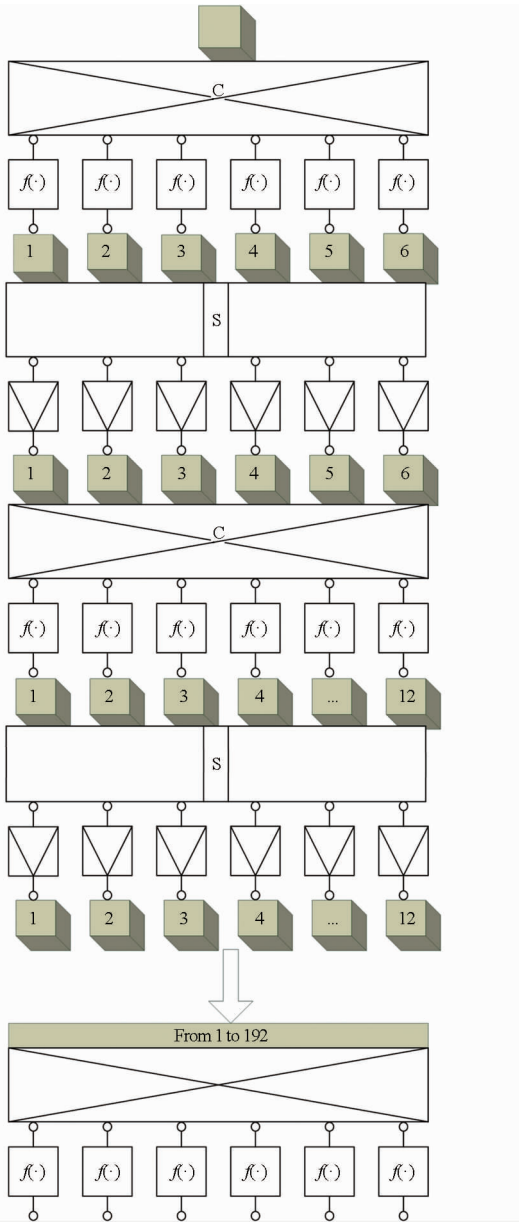


图2 病害 CNN 网络的逻辑结构

Fig.2 Logic structure of a CNN for apple lesion image recognition

网络训练参数由连接参数和层参数构成,与采用层数相同的标准神经网络相比,卷积网络大大简化了学习任务。

## 2 弹性动量学习

### 2.1 学习网络的误差传递

该网络是一个层层级联结构,输出误差向各级元件的扩散通过梯度下降来完成。

令  $E_d(\cdot)$  为损失函数,取误差平方和,“ $\cdot$ ”表示待学习自由参数。 $i_{netj}$  为激励元件  $j$  的输入, $E_d(\cdot)$  对于  $i_{netj}$  递减最快的比率  $\delta_j$  表示为

$$\delta_j = -\frac{\partial E_d}{\partial i_{netj}} \quad (1)$$

则元件  $j$  第  $i$  个入权的调整量  $\Delta w_{ji}$  的计算公式为

$$\Delta w_{ji} = \eta \delta_j x_{ji} \quad (2)$$

式中  $x_{ji}$ ——该权的输入  $\eta$ ——学习速率

(1) 误差在卷积层的传递。假设当前层  $l$  是卷积层,按图 1,则  $l$  之后的连接是采样连接。沿着连接前进,特征图的分辨率缩小到  $1/s$ ;沿着连接后退,则要放大到  $s$  倍。利用  $\text{expand}$  函数将  $l+1$  层的  $j$  个特征图的误差矩阵的每个元素扩展为  $s \times s$  的微格矩阵,得到了分辨率变为  $s$  倍的特征图误差。令层  $l$  的激励函数为  $f(\mathbf{x})$ ,由  $f(\mathbf{x})$  在层  $l$  的  $j$  个特征图  $\mathbf{O}_{f_{\text{map}-j}}^l$  处的导数和  $l+1$  层的  $s$  倍的特征图误差得到  $l$  层的特征图误差  $\Delta \mathbf{O}_{f_{\text{map}-j}}^l$ ,表示为

$$\Delta \mathbf{O}_{f_{\text{map}-j}}^l = f(\mathbf{x})' |_{\mathbf{x}=\mathbf{O}_{f_{\text{map}-j}}^l} \cdot \text{expand}(\Delta \mathbf{O}_{f_{\text{map}-j}}^{l+1}, [s \ s]) \quad (3)$$

(2) 误差在采样层的传递。采样层本身不含自由参数,但是,特征图误差的向后传送必须穿透它。假定当前层  $l$  是采样层,则  $l$  之后的连接是卷积连接。对于层  $l$  的节点  $i$  有  $n_{\text{outmap}}$  个卷积连接回退,故误差为  $n_{\text{outmap}}$  个分量求和。 $\text{size}$  为返回矩阵维度向量的函数,则向前卷积是“valid”卷积,其得到维度缩小为  $\text{size}(\mathbf{O}^l) - (\text{size}(\mathbf{K}) - 1)$  的矩阵  $\mathbf{O}^{l+1}$ ;向后卷积则必须为“full”卷积,得到维度放大到  $\text{size}(\mathbf{O}^{l+1}) + \text{size}(\mathbf{K}) - 1$  的矩阵  $\mathbf{O}^l$ ,同时,用  $\text{inv}$  操作将卷积核翻转,层  $l$  的  $i$  个特征图误差矩阵  $\Delta \mathbf{O}_{f_{\text{map}-i}}^l$  执行  $n$  维卷积操作 ( $\text{convn}$  表示) 得到,即

$$\Delta \mathbf{O}_{f_{\text{map}-i}}^l = \sum_{j=1}^{n_{\text{outmap}}} \text{convn}(\Delta \mathbf{O}_{f_{\text{map}-j}}^{l+1}, \text{inv}(\mathbf{K}_{ij}^{l+1}), \text{'full'}) \quad (4)$$

### 2.2 弹性动量学习

通过误差向后传播过程,各层  $l$  的节点  $i$  依次获得了特征图误差  $\Delta \mathbf{O}_{f_{\text{map}-i}}^l$ ,从  $l=2$  到  $l=n$  向前选择卷积层学习可得到卷积算子的误差。由式 (4) 可知:翻转的卷积核和矩阵误差作“full”卷积得到输出误差;反之,翻转的矩阵  $\text{inv}(\mathbf{O}_{f_{\text{map}-i}}^{l-1})$  和输出误差“valid”卷积  $\Delta \mathbf{O}_{f_{\text{map}-j}}^l$  就得到核误差  $\Delta \mathbf{K}_{ij}^l$

$$\Delta \mathbf{K}_{ij}^l = \text{convn}(\text{invn}(\mathbf{O}_{f_{\text{map}-i}}^{l-1}), \Delta \mathbf{O}_{f_{\text{map}-j}}^l, \text{'valid'}) \quad (5)$$

如此,通过一次回退和一次向前,得到全连接层的权值误差和各个卷积层的核误差。从  $l=2$  到  $l=n$  向前选择卷积层的卷积核应用误差可得学习后的卷积算子。忽略层标号,令第  $n-1$  次调整前的卷积核为  $\mathbf{K}_{ij}^{(n-1)}$  和调整后的为  $\mathbf{K}_{ij}^{(n)}$ ,则有

$$\mathbf{K}_{ij}^{(n)} = \mathbf{K}_{ij}^{(n-1)} - \Delta \mathbf{K}_{ij} \quad (6)$$

为了改善算法收敛性,文献[7]提出采用动量方法可以加快收敛。当 $\alpha$ 初始化某个常数 $\alpha_0$ 时,在学习过程中,根据算法的设置参数,如 $s$ 和训练样本的批容量大小 $n_{\text{batch}}$ 调整 $\alpha$ ,称为自适应动量梯度下降(traingdx)<sup>[8]</sup>。此法相比动量方法更加灵活。但是,仍未体现调整方向、当前量和动量项的关系,并未有意识地将参数学习向改进收敛性和学习性能的方向指引<sup>[9-10]</sup>

$$\Delta K_{ij}^{(n)} = \text{convn}(\cdot) + \alpha \Delta K_{ij}^{(n-1)} \quad (7)$$

$$\alpha = f(\alpha_0, n_{\text{batch}}, s) \quad (8)$$

该方法没有考虑到动量项和误差符号不一致性。但实际中,其方向是否改变,或者是否保持和上次同样动量,与当前误差都有关系。因而,提出下面的方法。

被调整项统一用 $\tau_{ji}$ 表示,sign函数返回当前误差 $\partial\tau_{ji}$ 和上次调整量 $\Delta\tau_{ji}(n-1)$ 乘积的符号,使动量项和误差项在方向动态上一致;其值取上次调整量和其误差量之和当中的比例,这种机制定义为弹性动量梯度下降(Train by gradient descent with flexible momentum, traingdfm),表示为

$$\alpha = \text{sign}(\partial\tau_{ji} \cdot \Delta\tau_{ji}(n-1)) \left| \frac{\Delta\tau_{ji}(n-1)}{\Delta\tau_{ji}(n-1) + \partial\tau_{ji}} \right| \quad (9)$$

$$\Delta\tau_{ji}(n) = \partial\tau_{ji} + \alpha \Delta\tau_{ji}(n-1) \quad (10)$$

### 3 果体病理图像获取及处理

#### 3.1 方向干扰病理图像

果园中,图像感知设备安装在一系列指定的网点,它和监视范围内果体的相对位置、果体当前生长点的空间位置密切相关<sup>[11-12]</sup>。以重力方向为参考,感知图像和标准图像呈现某个夹角 $\phi$ ,多个设备同时能监视某果体则得到多张不同 $\phi$ 的图像,同一对象,识别系统感知得到不同的图像模式。理论上, $\phi$ 是连续的。为了建立识别系统对 $\phi$ 的适应性,在标准图像加入8个角度旋转得到干扰后的病理图像。

#### 3.2 亮度干扰病理图像

通常情况下,果园光照环境比较复杂,太阳周期性运动、云层随机变化、阴晴雨露天气、成像方向的背光程度等因素均影响图像的曝光和白平衡<sup>[13]</sup>。为了模拟不同光照环境下的图像,在数据集加入4级亮度干扰,参数区间分别为 $[0.2 \ 0.4]$ 、 $[0.4 \ 0.6]$ 、 $[0.6 \ 0.8]$ 和默认值。

结合光照和方向干扰,1个标准的原始样本就得到若干个干扰后的样本,它们分别模拟不同角度和背光场景下对同一种病变果体的成像。以模拟干扰的图像为样本训练网络<sup>[14]</sup>。

## 4 试验结果分析和讨论

在北京市大兴区圣泽林梨合作社果园,收集了黑星病、轮纹病、黑腐病等20种常发于苹果果体外表的病理图像,得到苹果病害图像的基准数据集。网络的训练算法基于Matlab实现。以识别召回率、收敛性、准确性、有效性泛化等为指标进行对比试验。

#### 4.1 混淆矩阵和召回率

分类精度可用混淆矩阵 $C[i, j]$ (Confusion matrix)表示,它表示被划分为类 $i$ 而实测为类 $j$ 的样本数量,在测试样本总量所占的百分比。

召回率为评价分类器性能的指标,集合 $S$ 的 $n$ 个 $A$ 类样本构成子集 $S_T$ ,当使用某分类器对测试集合 $S$ 进行测试,归类为 $A$ 类的样本构成子集 $S_O$ ,记 $S_O = S_T \cap S_O$ , $S_O$ 的元素数 $m$ 和 $n$ 的比率为分类器对 $A$ 的召回率。

选择黑星病、锈果病等4类疾病的病理图像数据子集,对网络进行训练。用500个样本测试所得模型,得到混淆矩阵如图3所示。网格(1,1)显示,120个输出为类1(锈果病)且目标类也是为类1的样本,在样本总量中占24%。网格(1,3)显示4个输出为类1的样本实际属类3(花脸病),占0.8%。网格(5,1)表示,120个类1目标全部被识别,其召回率为100%。类3的仅召回了112个,召回率为94.9%。总体而言,召回率为98.4%。对于病理图像数据,该方法召回率高,效果较好。

实际类别	1	120 24.0%	0 0.0%	4 0.8%	0 0.0%	96.8% 3.2%
	2	0 0.0%	133 26.6%	0 0.0%	1 0.2%	99.3% 0.7%
	3	0 0.0%	0 0.0%	112 22.4%	1 0.2%	99.1% 0.9%
	4	0 0.0%	0 0.0%	2 0.4%	127 25.4%	98.4% 1.6%
	5	100% 0.0%	100% 0.0%	94.9% 5.1%	98.4% 1.6%	98.4% 1.6%
		1	2	3	4	目标类别

图3 混淆矩阵

Fig. 3 Confusion matrix

#### 4.2 收敛性能

针对卷积深度学习网络选择3个动量算法,观察训练目标损失函数值随迭代轮数的变化。如图4所示。不难看出相对于“traingdm”<sup>[9]</sup>(标准动量方法)的收敛点14和“traingdx”(自适应动量)的收敛



点 18,“traingdfm”方法的收敛点 7 收敛迭代轮数最少,耗费训练时间最短。从收敛的损失函数曲线的平滑性和波动性来看,本文方法具有竞争力。

### 4.3 准确率比较

为比较网络的准确率,进行 3 种不同方法下的 5 层深度的 LeNet(LeNet-5<sup>[6]</sup>)、增强的 4 层深度的 LeNet(Boosted-LeNet-4; B-LeNet-4<sup>[15]</sup>)和层数为 3 的标准神经网络(MNN)的对比试验。识别准确率如表 1 所示。可见,采用弹性动量机制(traingdfm)训练的网络同对应的用标准动量(traingdm)和自适应动量(traingdx)的训练模型相比,准确率都有不同程度的提高,提高幅度的平均值依次为 1.81%、2.10%和 5.51%,该方法是有有效的。




图 4 损失函数和收敛性

Fig.4 Loss function and convergence

表 1 算法识别准确率对比

Tab.1 Comparison of accuracy %

动量算法	LeNet-5	B-LeNet-4	MNN
标准动量	96.38	95.79	68.45
自适应动量	97.00	97.50	65.54
弹性动量	98.50	98.75	72.50

### 4.4 不同基准集上的泛化能力

为验证网络的泛化能力,用手写阿拉伯数字数据集<sup>[15]</sup>(MNIST-Zip-Digit)和人脸数据集(ORL-Face<sup>[16]</sup>)进行算法试验。网络的错误率和迭代时间的关系曲线如图 5 所示。




图 5 不同基准数据集上的学习性能

Fig.5 Learning performance upon different benchmark datasets

在手写阿拉伯数字数据集 MNIST-Zip-Digit 上,算法表现的错误最低,收敛时间最短,具备最佳的收敛速度和识别精度。而在 ORL-Face 人脸数据集上错误率高了许多。但错误率稳定在 25% 上下,其平均错误率为 9.37%,通过 5 h 的训练能较好地收敛,表明算法是有效的,性能尚待改进。和病理图像数据相比,手写阿拉伯数字图片模式简单,主要特征是线条和弯角;人脸图像复杂,有表情、覆盖物(眼镜)等,模式自身复杂程度影响着学习算法的精度和收敛<sup>[17]</sup>。

## 5 结论

(1)提出了基于弹性动量的参数学习方法,该方法应用于基于病理图像识别的苹果果体常见疾病诊断,召回率为 98.4%。

(2)运用该方法训练 3 个不同的学习网络 and 对应地用标准动量梯度方法及自适应动量方法训练的网络相比,准确率平均提高幅度分别为 1.81%、2.10%和 5.51%。

(3)手写阿拉伯数字数据集和人脸数据集的错误率试验结果证明,对于其他基准数据集的图像识别,该方法平均错误率为 9.37%,5 h 的样本训练能实现较好收敛,识别性能和泛化能力良好。

## 参 考 文 献

- Dutot M, Nelson L M, Tyson R C. Predicting the spread of postharvest disease in stored fruit, with application to apples[J]. Postharvest Biology and Technology, 2013, 85: 45-56.
- 赵朋,刘刚,李民赞,等. 基于 GIS 的苹果病虫害管理信息系统[J]. 农业工程学报, 2006, 22(12): 150-154. Zhao Peng, Liu Gang, Li Minzan, et al. Management information system for apple diseases and insect pests based on GIS[J]. Transactions of the CSAE, 2006, 22(12): 150-154. (in Chinese)
- 赵春江. 农业智能系统[M]. 北京:科学出版社, 2009.
- Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- 马晓丹,刘刚,周薇,等. 基于量子遗传模糊神经网络的苹果果实识别[J]. 农业机械学报, 2013, 44(12): 227-233.

- Ma Xiaodan, Liu Gang, Zhou Wei, et al. Apple recognition based on fuzzy neural network and quantum genetic algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2013,44(12):227-233. (in Chinese)
- 6 赵志宏, 杨绍普. 基于卷积神经网络 LeNet-5 的车牌字符识别研究[J]. 系统仿真学报, 2010, 22(3): 638-641.  
Zhao Zhihong, Yang Shaopu. License plate character recognition based on convolutional neural network LeNet-5[J]. Journal of System Simulation, 2010, 22(3): 638-641. (in Chinese)
- 7 Mitchell T M, 曾华军, 张银奎. 机器学习[M]. 北京: 机械工业出版社, 2003.
- 8 Agrawal S S, Yadava V. Modeling and prediction of material removal rate and surface roughness in surface-electrical discharge diamond grinding process [J]. Materials and Manufacturing Processes, 2013, 28(4): 381-389.
- 9 Pandey S, Hindoliya D A. Artificial neural networks for predicting indoor temperature using roof passive cooling techniques in buildings in different climatic conditions[J]. Applied Soft Computing Journal, 2012, 12(3): 1214-1226.
- 10 Liao Z, Wang B, Xia X, et al. Environmental emergency decision support system based on artificial neural network[J]. Safety Science, 2012, 50(1): 150-163.
- 11 乔闹生, 张奋. 基于点结构光系统双摄像机立体视觉测量方法[J]. 湖南文理学院学报: 自然科学版, 2014, 26(2): 22-25.  
Qiao Naosheng, Zhang Fen. A measurement method of double cameras solid vision based on dot structure light system[J]. Journal of Hunan University of Arts and Science: Natural Science Edition, 2014, 26(2): 22-25. (in Chinese)
- 12 王文山, 柳平增, 臧官胜, 等. 基于物联网的果园环境信息监测系统的设计[J]. 山东农业大学学报: 自然科学版, 2012, 43(2): 239-243.  
Wang Wenshan, Liu Pingzeng, Zang Guansheng, et al. Design of environment information monitoring system for orchard based on the internet of things[J]. Journal of Shandong Agricultural University: Natural Science, 2012, 43(2): 239-243. (in Chinese)
- 13 曹杨, 李有志. 探讨不同因素对白背飞虱在稻苗间传播南方水稻黑条矮缩病毒效率的影响[J]. 湖南文理学院学报: 自然科学版, 2014, 26(1): 30-37.  
Cao Yang, Li Youzhi. Effect of various kinds of factors on the transmission efficiency of southern rice blacked planthopper among rice plants[J]. Journal of Hunan University of Arts and Science: Natural Science Edition, 2014, 26(1): 30-37. (in Chinese)
- 14 曹斌芳, 彭光含, 彭元杰, 等. 一种分层阈值优化的语音感知小波去噪方法[J]. 湖南文理学院学报: 自然科学版, 2014, 26(2): 35-39.  
Cao Binfang, Peng Guanghan, Peng Yuanjie, et al. Speech de-noising algorithm of perception wavelet transform based on hierarchical threshold optimization[J]. Journal of Hunan University of Arts and Science: Natural Science Edition, 2014, 26(2): 35-39. (in Chinese)
- 15 Al-Jawfi R. Handwriting arabic character recognition LeNet using neural network[J]. International Arab Journal of Information Technology, 2009, 6(3): 304-309.
- 16 Kadappa V, Negi A. Computational and space complexity analysis of SubXPCA[J]. Pattern Recognition, 2013, 46(8): 2169-2174.
- 17 王文初, 郭玉凤. 基于主成分回归分析的环境因素与学生身高关系的研究[J]. 湖南文理学院学报, 2013, 25(2): 78-83.  
Wang Wenchu, Guo Yufeng. A study on the relationship of environmental factors and the height of students based on principal component regression[J]. Journal of Hunan University of Arts and Science, 2013, 25(2): 78-83. (in Chinese)