

基于迁移学习的卷积神经网络植物叶片图像识别方法

郑一力 张 露

(北京林业大学工学院, 北京 100083)

摘要: 为了提高植物叶片图像的识别准确率,考虑到植物叶片数据库属于小样本数据库,提出了一种基于迁移学习的卷积神经网络植物叶片图像识别方法。首先对植物叶片图像进行预处理,通过对原图的随机水平、垂直翻转、随机缩放操作,扩充植物叶片图像数据集,对扩充后的叶片图像数据集样本进行去均值操作,并以4:1的比例划分为训练集和测试集;然后将训练好的模型(AlexNet、InceptionV3)在植物叶片图像数据集上进行迁移训练,保留预训练模型所有卷积层的参数,只替换最后一层全连接层,使其能够适应植物叶片图像的识别;最后将本文方法与支持向量机(SVM)方法、深度信念网络(DBN)方法、卷积神经网络(CNN)方法在ICL数据库进行对比实验。实验使用Tensorflow训练网络模型,实验结果由TensorBoard可视化得到的数据绘制而成。结果表明,利用AlexNet、InceptionV3预训练模型得到的测试集准确率分别为95.31%、95.40%,有效提高了识别准确率。

关键词: 叶片识别; 卷积神经网络; 迁移学习

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 1000-1298(2018)S0-0354-06

Plant Leaf Image Recognition Method Based on Transfer Learning with Convolutional Neural Networks

ZHENG Yili ZHANG Lu

(School of Technology, Beijing Forestry University, Beijing 100083, China)

Abstract: The identification of plant species plays an important role in the research and development of botany. In order to improve the recognition accuracy of plant leaf images, taking into account the plant leaf database as a small sample database, a convolutional neural network plant leaf image recognition method based on transfer learning was proposed. Firstly, the plant leaf image was preprocessed, and the plant leaf image data set was expanded by random horizontal, vertical flipping, and random scaling of the original image. The expanded plant leaf image data set samples were de-averaged and divided into 4:1 proportions as training set and test set. Then, the pre-trained models (AlexNet and InceptionV3) on the large-scale datasets were loaded to the plant leaf image data set. The parameters of all convolution layers of the pre-training models were retained, but the last layer was completely replaced to adapt the task of plant leaf image recognition. Finally, the proposed methods were compared with the support vector machine (SVM) method, the deep belief nets (DBN) method and the convolutional neural network (CNN) method from training time and the accuracy of test set in the ICL database. Tensorflow was used to train the network model in the experiment, and the model was visualized by the Tensorboard. The results showed that the accuracy rate of test set obtained with AlexNet and InceptionV3 pre-training models were 95.31% and 95.40%, respectively, which were better than those with SVM method, DBN method and CNN method. The training time of AlexNet and InceptionV3 pre-training model were 26 220 s and 3 984 s, respectively. The InceptionV3 pre-training model was superior to the AlexNet pre-training model in terms of test set accuracy and training time.

Key words: leaf recognition; convolutional neural network; transfer learning

收稿日期: 2018-07-15 修回日期: 2018-08-25

基金项目: 中央高校基本科研业务费专项资金项目(2015ZCQ-GX-04)、国家自然科学基金项目(31670719)和北京市科技计划项目(Z161100000916012)

作者简介: 郑一力(1981—),男,副教授,主要从事林业生态监测和林业工程装备研究,E-mail: zhengyili@bjfu.edu.cn

0 引言

植物种类识别对植物学研究具有重要意义和作用^[1]。由于植物叶片包含大量种属信息,且叶片采集方便,使其成为识别植物最直接、有效的方法。传统的叶片识别方法主要是根据植物形态进行人工鉴定,工作量大、效率较低,且识别结果存在主观性。目前,已经有很多较为有效的植物识别方法。INGROUILLE 等^[2]采用 27 种叶片形状特征,使用主成分分析方法对橡树进行分类。刘念等^[3]用局部二值模式(Local binary mode, LBP)、灰度共生矩阵、Gabor 滤波后的纹理特征与 Hu 不变矩、傅里叶算子等轮廓特征相结合,并利用深度信念网络(Deep belief nets, DBN)作为分类器,获得了较高的识别结果。郑一力等^[4]将叶片几何特征、Hu 不变矩特征、灰度共生矩阵特征、分形维数等多种特征相结合,并用支持向量机(Support vector machine, SVM)分类器进行识别,得到了较高的识别率。付波等^[5]将 LBP 特征与叶片形状特征进行结合,并利用 k 近邻法实现叶片的分类与识别。当 AlexNet 模型^[6]在 ImageNet^[7]的大规模图像分类竞赛(ILSVRC)中取得了巨大成功,GoogLeNet^[8]、VGGNet^[9]、ResNet^[10]等深度卷积神经网络模型不断涌现,越来越多的学者将这些模型用于具体的图像识别任务中。JEON 等^[11]使用卷积神经网络(Convolutional neural network, CNN)模型自动提取特征对植物叶片进行分类识别。张帅等^[12]利用一个 8 层卷积神经网络深度学习系统,在 PI@ antNet 叶片库和自扩展的叶片库中对叶片图像进行训练和识别,其利用 CNN + SVM 和 CNN + SoftMax 分类器识别方法对叶片图像进行识别,识别率分别为 91.11% 和 90.9%。

CNN 模型的训练需要数百万个参数,因此 CNN 训练时需要使用大量的标记样本。只有在网络结构比较复杂、训练样本数足够多的情况下,CNN 才能表现出较优异的性能^[13]。当训练样本缺失时,则容易出现过拟合和陷入局部最优解等现象^[6]。而迁移学习就是针对这个问题提出的,迁移学习的加入很好地解决了训练样本缺失带来的上述问题,在图像识别领域得到广泛应用。

本文提出一种基于迁移学习的卷积神经网络植物叶片图像识别方法。该方法直接使用预训练好的 AlexNet、InceptionV3 模型进行叶片特征提取,然后将提取到的特征向量放入分类器中进行训练,从而得出识别结果。

1 理论基础

1.1 卷积神经网络

卷积神经网络是一种深度学习模型,其结构如图 1 所示。




图 1 卷积神经网络结构

Fig. 1 Architecture of convolutional neural network

卷积层通过卷积运算提取图像的局部特征,上一层的特征图经过卷积核处理后,再通过激励函数便可以得到新一层的特征图。卷积层的工作过程^[14]为

$$x_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} k_{ij}^l + b_j^l\right) \tag{1}$$

式中 x_j^l ——第 l 层的第 j 个神经元的输出
 x_i^{l-1} ——第 $l-1$ 层的第 i 个神经元的输出
 M_j ——输入特征映射集合 l ——层序号
 k_{ij}^l ——卷积核 b_j^l ——偏置项
 $f(\cdot)$ ——非线性激活函数

非线性激活函数通常采用修正线性单元(Rectified linear units, RELU)函数,RELU 函数的表达式为

$$f(x) = \begin{cases} 0 & (x < 0) \\ x & (x \geq 0) \end{cases} \tag{2}$$

池化层通常在卷积层之后,它可以对特征图像进行降维,同时保持特征数据的局部不变性^[15]。一般有两种池化方式:最大值池化和平均值池化,池化过程表示为

$$x_j^l = f_{down}(x_i^{l-1}) \tag{3}$$

式中 $f_{down}(\cdot)$ ——下采样函数

经过多个卷积层和池化层的交替连接之后是全连接层,全连接层对提取的特征进一步降维,将特征输入到 SoftMax 分类器中进行分类。

卷积神经网络的训练目标是通过随机梯度下降法(Stochastic gradient descent, SGD),使得损失函数达到最小。损失函数计算公式为

$$L(W, b) = - \sum_{i=1}^N \sum_{j=1}^c I\{\hat{y}_i = j\} \lg p_i^j \tag{4}$$

式中 W ——权重 b ——偏置项
 $\hat{y}_i$ ——第 i 个训练样本的期望值
 j ——训练样本的类别
 I ——指示函数,当 $\hat{y}_i = j$ 时 I 为 1,否则 I 为 0
 p_i^j ——第 i 个训练样本第 j 个类别的预测概率

C ——训练样本类别数

N ——训练样本总数

SGD 权重迭代表式为

$$W_i \leftarrow W_i - \eta \frac{\partial L(W, b)}{\partial W_i}$$
$$b_i \leftarrow b_i - \eta \frac{\partial L(W, b)}{\partial b_i}$$

式中 η ——学习率,用于控制反向传播的强度

1.2 迁移学习

迁移学习是运用已存有的知识对不同但相关领域问题进行求解的一种机器学习方法,其目标是完成知识在相关领域之间的迁移。对于卷积神经网络而言,迁移学习就是要把在特定数据集上训练得到的“知识”成功运用到新的领域之中^[15]。

DONAHUE 等^[16] 利用在 ImageNet 数据集上训练好的深度 CNN 模型,提取通用视觉特征,并且利用这个特征在场景识别、鸟类识别等新的任务上取得了很好的分类效果。

2 基于迁移学习的植物叶片图像识别

2.1 模型架构

本文使用的预训练模型是 AlexNet 和 InceptionV3^[17],以 InceptionV3 模型为例进行说明。首先保留训练好的 InceptionV3 模型中所有卷积层的参数,只替换最后一层全连接层。在全连接层之前的网络层称为瓶颈层。即将植物叶片图像输入网络,最后在瓶颈层生成一个 2 048 维度的特征向量,将这个特征保存在 txt 文件中,再用这个特征来训练 SoftMax 分类器。InceptionV3 模型架构如图 2 所示。




图2 InceptionV3 模型架构

Fig.2 Architecture of InceptionV3

2.2 SoftMax 分类器

SoftMax 分类器是 Logistic 回归模型在多分类问题上的扩展,在多分类问题中,类标签 y 可以取 r 个不同的值,对于训练集 $\{(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})\}$,类标签为 $y^{(n)} \in \{1, 2, \dots, r\}$ 。对于给定的输入 $x^{(n)}$,用假设函数 $h_{\lambda}(x^{(n)})$ 针对每一个类 k 估算出概率 $p(y^{(n)} = k | x^{(n)})$, $k = 1, 2, \dots, r$ 。 $h_{\lambda}(x^{(n)})$ 是一个和为 0 的 r 行列向量,每一行表示每

种分类结果出现的概率。假设函数 $h_{\lambda}(x^{(n)})$ ^[18] 的公式为

$$h_{\lambda}(x^{(n)}) = \begin{bmatrix} p(y^{(n)} = 1 | x^{(n)}) & \lambda \\ p(y^{(n)} = 2 | x^{(n)}) & \lambda \\ \vdots & \vdots \\ p(y^{(n)} = r | x^{(n)}) & \lambda \end{bmatrix} = \frac{1}{\sum_{k=1}^r e^{\lambda_k^T x^{(n)}}} \begin{bmatrix} e^{\lambda_1^T x^{(n)}} \\ e^{\lambda_2^T x^{(n)}} \\ \vdots \\ e^{\lambda_r^T x^{(n)}} \end{bmatrix} \tag{5}$$

式中 $\lambda_1, \lambda_2, \dots, \lambda_r$ ——模型参数

将 $x^{(n)}$ 分为第 k 类的概率记为

$$p(y^{(n)} = k | x^{(n)}; \lambda) = \frac{e^{\lambda_k^T x^{(n)}}}{\sum_{k=1}^r e^{\lambda_k^T x^{(n)}}} \tag{6}$$

把 $p(y^{(n)} = k | x^{(n)}; \lambda)$ 取最大值时对应的类别 k 作为当前样本的分类结果,并与样本本身的真实标签做对比,若一致,则分类正确,否则分类错误。

3 实验设计与结果分析

本实验运行环境是 Anaconda3 中的 Jupyter notebook,使用开源深度学习框架 Tensorflow 作为开发环境,本文实验结果中的 Loss 曲线、准确率曲线均是由 TensorBoard^[19] 可视化得到的数据绘制而成,以此来分析卷积神经网络的收敛情况。

3.1 实验数据与预处理

本文使用的叶片图像来自 ICL 数据库^[20],该数据库是由中国科学院合肥机械研究所智能计算实验室建立。ICL 数据库包含 220 种植物叶片样本,每种样本最少 26 个,最多 1 078 个。该数据库中的叶片图像是尺寸约为 200 像素 $\times$ 500 像素,且图像背景均为单一的扫描图像。实验选用样本数量大于 50 的 42 种植物,共计 4 771 幅叶片图像。数据库中的叶片图像如图 3 所示。

为了在一定程度上减少过拟合,使用 python 脚本语句对叶片图像进行随机水平、垂直翻转、随机缩放操作来扩充数据集,最终扩充的数据集样本总数为 14 313,然后再将数据集以 4:1 的比例划分为训练集和测试集。图像尺寸统一修改为 224 像素 $\times$ 224 像素和 299 像素 $\times$ 299 像素,分别用于 AlexNet 和 InceptionV3 模型。如图 4 为选取的一幅图像经过预处理后得到的一系列图像。

在使用卷积神经网络对图像进行处理前,对样本进行去均值操作^[14],公式为

$$x' = x - \mu \tag{7}$$

式中 x' ——去均值后的样本 x ——样本

μ ——训练集上样本均值

3.2 实验设置

利用在 ImageNet 上训练完成的 AlexNet 模型的




图 3 ICL 数据库

Fig. 3 ICL leaf image dataset




图 4 预处理后得到的一系列图像

Fig. 4 A series of images obtained after preprocessing

权值和偏差来进行模型初始化,将模型的全连接层替换成 SoftMax 分类器,最后用修改后的模型对植物叶片图像数据集进行训练。其中模型学习率为 0.001,迭代次数为 100 次,批尺寸 (Batch_size) 为 64,随机失活 (Dropout) 为 0.5。为了方便描述该方法记为 Fine_Alex。

利用在 ImageNet 上已经训练好的 InceptionV3 模型来训练植物叶片图像集进而获得其特征向量,然后将特征向量输入到 SoftMax 分类器中获得分类

结果。其中,模型的学习率为 0.01,迭代次数为 4 000。为了方便描述该方法记为 Fine_IncepV3。

3.3 实验结果与分析

图 5 为 Fine_Alex 方法在训练集和测试集上的准确率及 Loss 值随迭代次数变化曲线。从图 5a 可以看到,训练集在迭代 20 次时准确率快速上升达到 100%,而测试集的准确率波动较大。从图 5b 可以看到,训练集和测试集二者之间的 Loss 值存在一定间隙且在迭代 20 次时,训练集 Loss 值已经接近于 0,而测试集的 Loss 值在 0.2 左右,存在过拟合现象。

Fine_IncepV3 方法在训练集和测试集上的准确率及 Loss 值随迭代次数变化曲线如图 6 所示。可以看出它们在测试集和训练集上走势基本一致,在迭代 4 000 次时准确率和 Loss 值基本稳定,模型没有发生过拟合。

各种方法在 ICL 数据库上的对比实验结果如




图 5 AlexNet 模型准确率与 Loss 值曲线

Fig. 5 Accuracy and loss function curves of AlexNet model




图 6 InceptionV3 模型准确率与 Loss 值曲线

Fig. 6 Accuracy and loss function curves of InceptionV3 model

表 1 所示,其中 CNN 方法是通过直接随机初始化 AlexNet 模型的各层权值参数和偏置来提取植物叶片图像数据集的特征,然后使用 SoftMax 分类器进行分类,参数设置和 Fine_Alex 方法一致。其中时间是指训练和测试全部完成时所用的时间。

表 1 各种方法实验结果对比
Tab.1 Comparison results of different methods

方法	训练时间/s	准确率/%
SVM ^[4]	23. 10	89. 97
DBN ^[3]	5 045	93. 94
CNN	55 070	41. 90
Fine_Alex	26 220	95. 31
Fine_IncepV3	3 984	95. 40

从表 1 中可以看出,SVM 在时间上有较大优势,但是准确率偏低,这是由于 SVM 方法提取的多特征主要依靠人工提取,需要有足够的经验;DBN 方法相对于 SVM 方法在准确率上有明显提升,主要是因为使用了分类模型更加复杂的 DBN 分类器,但由于 DBN 方法提取的特征也是通过人工提取,所以对数据的依赖性仍较高,需要大量的数据来训练模型。

深度模型需要大量的训练数据才能获得较为理想的实验效果,本文实验中的数据集属于小数据集,因此 CNN 方法的准确率还是很低,而且 CNN 方法

是从头开始训练模型,比较费时;Fine_Alex 方法在时间和准确率上都优于 CNN 方法,说明先在大数据集上进行模型训练,再将训练好的模型微调到特定领域,会比重头开始训练节约大量时间,而且能够达到更好的准确率,也就是说在小样本数据集中利用迁移学习的方法是可行的;Fine_IncepV3 方法比 Fine_Alex 方法所用时间少,而且测试集准确率更高一些,这是因为 InceptionV3 模型比 AlexNet 模型层数更深,其模型收敛能力更好。

4 结束语

提出了一种基于迁移学习的卷积神经网络植物叶片图像识别方法。利用预训练 AlexNet、InceptionV3 模型在植物叶片图像数据集上进行迁移训练,实验结果显示二者在测试集上的准确率分别为 95. 31% 和 95. 40%,由于 InceptionV3 模型层数更深,其模型可以更快收敛,而且其训练集与测试集之间不存在过拟合现象。将直接随机初始化 AlexNet 模型的各层权值参数和偏置来提取植物叶片图像数据集特征的 CNN 方法与本文 Fine_Alex 方法进行对比,结果表明,在大数据集上进行模型训练,再将训练好的模型微调到特定领域,不仅可以节约大量时间,而且识别效果较好。

参 考 文 献

1 侯国祥,翁章卓,李洪斌,等. 基于图像处理的树叶面积测量系统[J]. 武汉植物学研究, 2005,23(4): 369-372.
HOU Guoxiang, WENG Zhanghuo, LI Hongbin, et al. An image processing based system for leaf area measurement[J]. Journal of Wuhan Botanical Research, 2005, 23(4): 369-372. (in Chinese)

2 INGROUILLE J M, LAIRD M S. A quantitative approach to oak variability in some north London woodlands[J]. The London Naturalist, 1986, 65: 35-46.

3 刘念,阚江明. 基于多特征融合和深度信念网络的植物叶片识别[J]. 北京林业大学学报, 2016, 38(3): 110-119.
LIU Nian, KAN Jiangming. Plant leaf identification based on the multi-feature fusion and deep belief networks method[J]. Journal of Beijing Forestry University, 2016, 38(3): 110-119. (in Chinese)

4 郑一力,钟刚亮,王强,等. 基于多特征降维的植物叶片识别方法[J/OL]. 农业机械学报, 2017, 48(3):30-37. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20170304&flag=1. DOI:10. 6041/j. issn. 1000-1298. 2017. 03. 004.
ZHENG Yili, ZHONG Gangliang, WANG Qiang, et al. Method of leaf identification based on multi-feature dimension reduction [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(3): 30-37. (in Chinese)

5 付波,杨章,赵熙临,等. 基于降维 LBP 与叶片形状特征的植物叶片识别方法[J]. 计算机工程与应用, 2018, 54(2): 173-176.
FU Bo, YANG Zhang, ZHAO Xilin, et al. Plant leaves recognition method based on dimension reduction local binary pattern and shape features of leaves[J]. Computer Engineering and Applications, 2018, 54(2): 173-176. (in Chinese)

6 KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [C] // Communications of the ACM, 2017,60(6): 84-90.

7 RUSSAKOVSKY O, DENG J, SU H, et al. ImageNet large scale visual recognition challenge [J]. International Journal of Computer Vision, 2015, 115(3): 211-252.

8 SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C] //2015 IEEE Conference on Computer Vision and Pattern Recognition , 2015.

9 SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C] //Computer Vision and Pattern Recognition, 2014.

10 HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C] //Proceedings of 29th IEEE Conference on Computer Vision and Pattern Recognition, 2016:770-778.

11 JEON W, RHEE S. Plant leaf recognition using a convolution neural network[J]. The International Journal of Fuzzy Logic and

- Intelligent Systems, 2017, 17(1): 26 – 34.
- 12 张帅, 淮永建. 基于分层卷积深度学习系统的植物叶片识别研究[J]. 北京林业大学学报, 2016, 38(9): 108 – 115.
ZHANG Shuai, HUAI Yongjian. Leaf image recognition based on layered convolutions neural network deep learning[J]. Journal of Beijing Forestry University, 2016, 38(9): 108 – 115. (in Chinese)
- 13 TIAN Lei, FAN Chunxiao, YUE Ming, et al. Stacked PCA Network (SPCANet): an effective deep learning for face recognition [C]//IEEE International Conference on Digital Signal Processing, 2015:1039 – 1043.
- 14 ZHONG Zhuoyao, JIN Lianwen, XIE Zecheng. High performance offline handwritten chinese character recognition using googlenet and directional feature maps[C]//13th International Conference on Document Analysis and Recognition (ICDAR), 2015:846 – 850.
- 15 李彦冬, 郝宗波, 航雷. 卷积神经网络研究综述[J]. 计算机应用, 2016, 36(9): 2508 – 2515.
LI Yandong, HAO Zongbo, HANG Lei. Survey of convolutional neural network[J]. Journal of Computer Application, 2016, 36(9): 2508 – 2515. (in Chinese)
- 16 DONAHUE J, JIA Y, VINYALS O, et al. DeCAF: a deep convolutional activation feature for generic visual recognition[C]//Proceedings of the 31st International Conference on Machine Learning, 2014:988 – 996.
- 17 SZEGEDY G, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]//Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016:2818 – 2826.
- 18 宋青松, 田正鑫, 孙文磊, 等. 用于孤立数字语音识别的一种组合降维方法[J]. 西安交通大学学报, 2016, 50(6): 42 – 46.
SONG Qingsong, TIAN Zhengxin, SUN Wenlei, et al. Combined dimension reduction method for isolated digital speech recognition[J]. Journal of Xian Jiaotong University, 2016, 50(6): 42 – 46. (in Chinese)
- 19 GIBSON E, LI Wenqi, SUDRE C, et al. NiftyNet: a deep-learning platform for medical imaging[J]. Computer Methods and Programs in Biomedicine, 2018, 158:113 – 122.
- 20 Intelligent Computing Laboratory of Chinese Academy of Sciences. Plant leaf database of intelligent computing laboratory of Chinese academy of sciences [EB/OL]. <http://www.intelengine.cn/dataset>.
-

(上接第 353 页)

- 11 许林云, 张昊天, 张海锋, 等. 果园喷雾机自动对靶喷雾控制系统研制与试验[J]. 农业工程学报, 2014, 30(22): 1 – 9.
XU Linyun, ZHANG Haotian, ZHANG Haifeng, et al. Development and experiment of automatic target spray control system used in orchard sprayer[J]. Transactions of the CSAE, 2014, 30(22): 1 – 9. (in Chinese)
- 12 周良富, 薛新宇, 周立新, 等. 果园变量喷雾技术研究现状与前景分析[J]. 农业工程学报, 2017, 33(23): 80 – 92.
ZHOU Liangfu, XUE Xinyu, ZHOU Lixin, et al. Research situation and progress analysis on orchard variable rate spraying technology [J]. Transactions of the CSAE, 2017, 33(23): 80 – 92. (in Chinese)
- 13 ZAMAN Q U, SALYANI M. Effects of foliage density and ground speed on ultrasonic measurement of citrus tree volume[J]. Applied Engineering in Agriculture, 2014, 20(2): 173 – 178.
- 14 ESCOLÀ A, PLANAS S, ROSELL, et al. Performance of an ultrasonic ranging sensor in apple tree canopies [J]. Sensors, 2011, 11(3): 2459 – 2477.
- 15 翟长远, 赵春江, WANG Ning, 等. 果园风送喷雾精准控制方法研究进展[J]. 农业工程学报, 2018, 34(10): 1 – 15.
ZHAI Changyuan, ZHAO Chunjiang, WANG Ning, et al. Research progress on precision control methods of air-assisted spraying in orchards[J]. Transactions of the CSAE, 2018, 34(10): 1 – 15. (in Chinese)
- 16 RICARDO S, JORDI L, ALEXANDRE E, et al. Innovative LIDAR 3D dynamic measurement system to estimate fruit-tree leaf area [J]. Sensors, 2011, 11(3): 5769 – 5791.
- 17 SWALKLATE P, CROSS J, RICHARDSON G, et al. Comparison of different spray volume deposition mode using LIDAR measurements of apple orchards[J]. Biosyst. Eng., 2002, 82(3): 253 – 267.
- 18 李龙龙, 何雄奎, 宋坚利, 等. 基于变量喷雾的果园自动仿形喷雾机的设计与试验[J]. 农业工程学报, 2017, 33(1): 70 – 76.
LI Longlong, HE Xiongkui, SONG Jianli, et al. Design and experiment of automatic profiling orchard sprayer based on variable air volume and flow rate[J]. Transactions of the CSAE, 2017, 33(1): 70 – 76. (in Chinese)
- 19 刘慧, 李宁, 沈跃, 等. 融合激光三维探测与 IMU 姿态角实时矫正的喷雾靶标检测[J]. 农业工程学报, 2017, 33(15): 88 – 97.
LIU Hui, LI Ning, SHEN Yue, et al. Spray target detection based on laser scanning sensor and real-time correction of IMU attitude angle[J]. Transactions of the CSAE, 2017, 33(15): 88 – 97. (in Chinese)
- 20 吴腾, 胡良龙, 王公仆, 等. 步行式甘薯碎蔓还田机的设计与试验[J]. 农业工程学报, 2017, 33(16): 8 – 17.
WU Teng, HU Lianglong, WANG Gongpu, et al. Design and test of walking sweet potato (*Ipomoea batatas*) vines crushing and returning machine[J]. Transactions of the CSAE, 2017, 33(16): 8 – 17. (in Chinese)
- 21 程焱焱, 祁力钧, 吴亚奎, 等. 矮化密植果园摇摆变量喷雾机参数响应面法优化[J/OL]. 农业机械学报, 2017, 48(增刊): 22 – 29. http://www.j-csam.org/jcsam/ch/reader/abstract_view.aspx?file_no=2017s004&flag=1&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2017.S0.004.
- CHENG Zhenzhen, QI Lijun, WU Yalei, et al. Parameter optimization of swing variable sprayer of orchard based on RSM [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(Supp.): 22 – 29. (in Chinese)