

基于卷积神经网络的典型农作物叶病害识别算法

doi:10.3969/j.issn.1674-7100.2018.06.011

丁瑞 周平

浙江理工大学

信息学院

浙江 杭州 310018

摘要: 目前, 典型的一些农作物叶病害诊断主要依靠人工, 但该方式耗时费力。针对大豆、棉花、水稻、小麦和玉米 5 类典型农作物的常见叶病害诊断问题, 提出了一种基于卷积神经网络的典型农作物叶病害识别方法。从 Plantvillage 数据库以及其他网站收集典型农作物的叶病害图像, 并对这些图像进行预处理, 构建了含 12 836 张的数据集。参照 AlexNet 框架, 构建 8 层卷积神经网络, 采用迁移学习训练网络, 最后通过测试集验证网络的识别准确率和损失值。分析不同的卷积神经网络的性能, 实验结果表明: 本算法对典型农作物的叶病害有良好的识别效果; 迁移学习模式下, 学习率为 0.001 时本算法在训练集的识别准确率约为 99.47%, 在测试集的识别准确率约为 96.18%。

关键词: 卷积神经网络; 农作物; 叶病害识别; AlexNet; 迁移学习

中图分类号: TP183; S43

文献标志码: A

文章编号: 1674-7100(2018)06-0074-07

0 引言

农作物一旦遭遇病虫害, 将会影响其生长以及产量和质量, 严重时甚至会给农业生产带来巨大的经济损失^[1]。因而如何在第一时间准确、快捷、高效地对农作物病虫害进行诊断, 以采取有效防治措施显得尤为重要。

近些年来, 卷积神经网络 (convolutional neural network, CNN) 在图像分类和识别中取得了显著的研究成果^[2]。因此, 国内外专家学者也将卷积神经网络应用于农作物的病害诊断中。A. Krizhevsky 等^[3]将 CNN 应用于水稻病害分类中, 先用实验稻田中捕获的 500 张水稻病害图像构建数据集, 再利用 AlexNet 网络构建水稻病害分类器的 CNN 架构, 实验结果表明: 深度 CNN 优于传统的机器学习算法, 识别准确率在 90% 以上。A. Vedaldi 等^[4]提出了一

种基于 CNN 的黄瓜病害分类器, 数据集除健康类别外还包含了 7 种不同类型的病害, CNN 网络由 4 个卷积层组成, 交替使用最大池化层和局部响应归一化函数, 4 倍交叉验证情景测试结果表明, 该算法的识别准确率为 82.3%。张航等^[5]提出了基于卷积神经网络的小麦病害识别方法, 先利用中值滤波法、直方图阈值法等对图像进行预处理, 再构建一个 5 层的卷积神经网络, 并利用随机梯度下降法进行学习过程控制, 实验结果表明, 该算法的综合识别准确率在 99% 以上。李艳^[6]提出基于 Fisher 准则的深度卷积神经网络算法, 在网络反向传播权值的调整过程中通过 Fisher 准则的约束条件使权值迅速接近有利于分类的最佳值, 实验结果表明, 该算法的识别准确率达 87.04%。刘阔宇等^[7]采用多角度建议区域 Faster-RCNN 准确定位图像中的葡萄叶片, 以去除背景因素对病害区域的干扰, 降低识别错误率。以上文

收稿日期: 2018-10-08

作者简介: 丁瑞 (1993-), 男, 江苏盐城人, 浙江理工大学硕士生, 主要研究方向为智能信息处理,

E-mail: 1527505787@qq.com

通信作者: 周平 (1960-), 男, 浙江杭州人, 浙江理工大学教授, 主要从事计算机视觉方面的教学与研究,

E-mail: 1500064071@qq.com

献都是对传统卷积神经网络的改进, 以实现农作物叶病害的识别。虽然学者们取得了不错的研究成果, 但是他们都只是针对一种叶病害进行识别。

综上所述, 本课题组针对大豆、棉花、水稻、小麦、玉米 5 种典型的农作物叶病害诊断问题, 提出了基于卷积神经网络的典型农作物叶病害识别方法, 以期农作物病害识别提供参考。

1 叶病害图像数据集

Plantvillage 工程^[8]是一个面向所有用户开放的免费数据库, 该数据库有很多不同种类的农作物病害图像。因此, 本课题组构建的农作物叶病害图像数据集中大部分图像来自 Plantvillage 数据库, 一部分来自中国农业病虫网以及其它网站。本数据集共有农作物叶病害图像 12 836 张, 10 269 张图像作为训练集, 2 567 张图像作为测试集, 图像尺寸均为 224 × 224。本数据库按照农作物所属种类(大豆、棉花、水稻、小麦和玉米)和病害种类进行了归类, 每类有 5 种常见的叶病害, 总共 25 种叶病害, 如图 1 所示。



注: 标号 1~5 依次为大豆根腐病、大豆褐斑病、大豆霜霉病、大豆炭疽病、大豆锈病; 6~10 依次为棉花褐斑病、棉花黄萎病、棉花茎枯病、棉铃黑果病、棉铃疫病; 11~15 依次为水稻白叶枯病、水稻稻曲病、水稻稻瘟病、水稻胡麻斑病、水稻纹枯病; 16~20 依次为小麦白粉病、小麦赤霉病、小麦全蚀病、小麦条锈病、小麦纹枯病; 21~25 依次为玉米大斑病、玉米黑粉病、玉米茎腐病、玉米纹枯病、玉米锈病。

图 1 25 种叶病害图像

Fig. 1 Leaf image of 25 diseases

2 图像预处理

自然条件下拍摄的农作物叶病害图像容易受光照、背景、角度、距离等多个因素的影响, 导致图像质量不佳, 这对识别病害类型造成了一定的干扰。因此, 本课题组在训练神经网络之前先对图像进行预处理, 这样既可以减少模型训练的参数, 使得模型能够更快收敛, 又能提高病害的识别准确率。

当图像中存在无效背景如天空、土壤、水、泥土或者手指等, 通过人工裁剪, 去除大量的无效背景, 提取以叶病害病斑为主的区域。接下来, 图像预处理的主要工作是图像的尺寸重定义、图像的灰度化、图像降噪、图像分割和数据增强^[9]。1) 原有的图像尺寸有所差异, 在 800 × 500 左右。图像像素过多, 会包含大量的冗余信息, 这增加了计算量, 所以通过 MATLAB 软件中 Reshape 函数将所有图像尺寸进行归一化处理, 最后图像尺寸为 224 × 224 (见图 2a)。2) 图像的灰度化是把图像从原始的彩色图像转换为灰度图像, 即将图像从三维降为一维, 以加快训练模型的收敛, 减少计算量 (见图 2b)。3) 为了减少图像中的噪声, 使用中值滤波^[10]对图像进行降噪处理, 即将图像中某点的灰度值用该点邻域的像素值的中值进行替换。中值滤波作为图像增强的一种手段, 可以较好地改善图像质量 (见图 2c)。4) 图像分割采用大津阈值法以分离图像的前景和背景。大津阈值法也称最大类间方差法, 是由日本学者大津在 1979 年提出的一种基于概率统计学原理的自适应阈值算法^[11]。其原理是用一个阈值将图像分为两类, 一类中图像的像素点的灰度值均小于阈值, 另一类中图像的像素点的灰度值均大于或者等于阈值。如果某阈值使得这两个类中像素点的灰度值的方差最大, 则该阈值就是最佳阈值。因为目标与背景类间方差反映了两个区块的差异程度, 所以最大类间方差可以使两个区块错分概率最小, 从而保证目标与背景最大程度上的分离 (见图 2e)。5) 数据增强采用随机翻转、旋转图像, 改变图像亮度等方法, 以扩充图像数量, 提高训练模型准确率的同时避免过拟合现象的发生^[12]。



a) 原图

b) 灰度化

c) 中值滤波

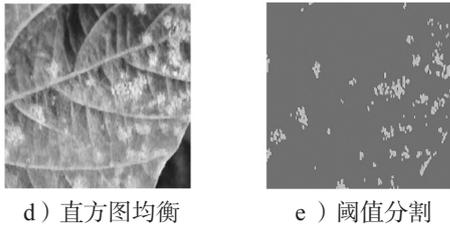


图2 图像预处理示意图

Fig. 2 Image preprocessing schematic

3 叶病害识别模型

由于 AlexNet、GoogLeNet、VGGNet 等经典神经网络能在大型数据集上学习图像特征，因而在图像分类识别大赛中均取得了非常优异的成绩^[13]。考虑本数据集规模较小，本课题组拟采用迁移学习，利用 J. Yosinski 等^[14]在 ImageNet 数据集上预训练的 AlexNet 神经网络对农作物叶病害图像数据集进行学习，训练 AlexNet 神经网络的最后几层，而其他层直接使用预训练的网络参数，即得农作物叶病害的识别网络模型。相较于训练神经网络所有层的参数，参数精调可以加速网络收敛。

AlexNet 神经网络主要由输入层、卷积层、池化层、全连接层和输出层等组成^[15]。本网络包含 1 个输入层、5 个卷积层、3 个池化层、2 个全连接层以及 1 个输出层（见图 3）。卷积层中，卷积核对输入图像进行卷积运算，得到特征图。5 个卷积层和全连接层之后有激活层，激活函数为 ReLU 函数。卷积核公式为

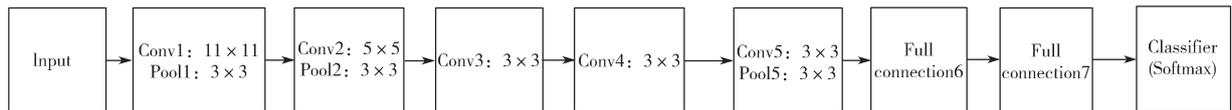


图3 卷积神经网络结构图

Fig. 3 Structural diagram of convolutional neural network

本网络的具体设计如下：

1) 输入层。输入图像的尺寸为 224×224 。

2) 第 1 层。a. 卷积层的核为 11×11 ，步长为 4，卷积核个数为 64，特征图的尺寸为 55×55 ，特征图共有 64 个。b. 池化层的核为 3×3 ，步长为 2，特征图的尺寸为 27×27 ，特征图共有 64 个。

3) 第 2 层。a. 卷积层的核为 5×5 ，步长为 1，每个像素层的四周均填充两个 0，卷积核个数为 256，特征图的尺寸为 27×27 ，特征图共有 256 个。b. 池化层的核为 3×3 ，步长为 2，特征图的尺寸为

$$x_j^l = f \left(\sum_{x_i^{l-1} \in M_{l-1}} x_i^{l-1} \right) \times k_{ij}^l + b_j^l, \quad (1)$$

式中： x_j^l 为第 l 层的第 j 个特征图；

$f(\cdot)$ 为 ReLU 激活函数；

M_{l-1} 为第 $l-1$ 层特征图的集合；

x_i^{l-1} 为第 $l-1$ 层的第 i 个特征图；

k_{ij}^l 为 x_j^l 的第 i 个卷积核；

b_j^l 为第 l 层的第 j 个特征图的偏置^[15]。

池化层为降采样操作，采用最大值池化，即计算滤波器的最大值，得到新特征图。最大值池化公式为

$$x_j^l = \text{down}(x_j^{l-1}), \quad (2)$$

式中 $\text{down}(\cdot)$ 为池化函数。

全连接层采用 Dropout 方法以减少过拟合，丢弃率设为 0.5。由于病害识别属于互斥分类，因而输出层采用 Softmax 分类器。本研究中样本共有 25 类，因此归一化后得到长度为 25 的向量。分类训练采用随机梯度下降法（stochastic gradient descent, SGD）使交叉熵损失最小，即

$$J(\theta) = -\frac{1}{N} \left[\sum_{p=1}^N \sum_{q=1}^M t_{pq} \log \frac{e^{\theta_q^T x_p}}{\sum_{n=1}^M e^{\theta_n^T x_p}} \right]. \quad (3)$$

式中： t_{pq} 为第 p 个样本属于 q 类时，其值等于 1；

θ_q^T 为 T 种类型中 q 类的模型参数；

$\frac{1}{\sum_{n=1}^M e^{\theta_n^T x_p}}$ 为输出概率值归一化处理。

13×13 ，特征图共有 256 个。

4) 第 3 层。卷积层的核为 3×3 ，步长为 1，每个像素层的四周均填充 1 个 0，特征图的尺寸为 13×13 ，特征图共有 256 个。

5) 第 4 层。第 4 层同第 3 层设置一样。

6) 第 5 层。a. 卷积层的核为 3×3 ，每个像素层的四周均填充两个 0，步长为 1，特征图的尺寸为 13×13 ，特征图共有 256 个。b. 池化层的核为 3×3 ，步长为 2，特征图的尺寸为 6×6 ，特征图共有 256 个。

7) 第6层。全连接层的输入数据尺寸为 $6 \times 6 \times 256$, 共有 4 096 个卷积核对输入数据进行运算, 并通过 4 096 个神经元输出运算结果, 最后通过 Relu 激活函数以及 Dropout 操作输出本层最终结果。

8) 第7层。第6层的 4 096 个数据和第7层全连接层的 4 096 个神经元全连接, 之后的运算原理同第6层。

9) 输出层。第7层的 4 096 个数据与 Softmax 分类器的 25 个神经元进行全连接, 输出分类结果。

4 实验结果与分析

TensorFlow 是由谷歌大脑团队开发的采用数据流图、用于数值计算的开源软件库。TensorFlow 架构非常灵活, 可以在多个平台(如 CPU、GPU)进行计算, 并且支持不同的操作系统, 可移植性较强。因此, 本课题组选择在 TensorFlow 中进行卷积神经网络的训练与测试。实验的硬件环境为: 处理器是 Intel Core i7, 内存是 8 GB DDR4, GPU 是 NVIDIA GTX1080 (显存是 6 GB)。实验的软件环境为: 操作系统是 Windows 10 64 位, Python 3.5, TensorFlow-GPU 1.8.0, CUDA 9.0, cuDNN 7.0。训练集和测试集的样本数比值为 8:2, 每个批次测试和训练的样本数都为 64, 最大迭代次数为 1 000。

本课题组进行了 3 组实验: 第 1 组实验, 分析不同数量的卷积层对 AlexNet 神经网络性能的影响; 第 2 组实验, 迁移学习下, 比较本文算法、GoogLeNet^[16]、VGGNet^[17] 以及 SqueezeNet^[18] 的性能; 第 3 组实验, 分析在学习方式(全新学习、迁移学习)、正则项系数(0、0.001)、初始学习率(0.001、0.005)的不同组合下本文算法、GoogLeNet、VGGNet 以及 SqueezeNet 的性能。

TensorBoard 是 TensorFlow 的官方可视化工具, 可以记录与显示多种数据形式, 如标量、图片、音频、计算图、数据分布、直方图、嵌入向量等。识别准确率和损失值都属于标量。具体的可视化过程如下:

a) 建立一个图(graph), 以便后续从图中获取信息;

b) 确定图中哪些节点放置 summary operations 以记录信息, 使用 tf.summary.scalar 记录标量, 使用 tf.summary.image 记录图像数据, 使用 tf.summary.histogram 记录数据直方图等;

c) 网络运行后, 可能有很多的 summary 节点,

因而使用 tf.summary.merge_all 将所有 summary 节点合并成一个节点, 并运行该节点, 得到之前设置的 summary data。

d) 使用 tf.summary.FileWriter 将运行后输出的数据保存到本地磁盘;

e) 运行整个程序, 并在命令行输入运行指令 TensorBoard, 之后通过浏览器查看可视化结果。

1) 第 1 组实验

本课题组将输入层、全连接层、输出层的设置保持不变, 通过改变卷积层的数量得到不同的 AlexNet 神经网络。卷积层的数量分别设定为 1, 2, 3, 4, 5, 6 时, 相应的 AlexNet 神经网络总层数为 5, 6, 7, 8, 9, 10。不同层数的 AlexNet 神经网络性能的实验结果如图 4 所示。

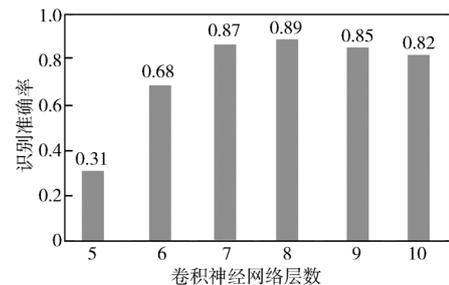


图 4 不同层数的网络性能对比
Fig. 4 Comparison of network performance at different layers

由图 4 可知: 网络总层数为 8 时, 识别准确率最高, 网络性能最好; 当网络中只包含 1 个或 2 个卷积层(即网络总层数分别为 5 和 6)时, 网络层数太少, 训练不够充分, 因而识别准确率比较低; 当网络中卷积层太多(即网络总层数分别为 9 和 10)时, 网络识别性能并没有显著提高, 反而出现了一定程度的下降, 原因在于过度训练容易发生拟合现象, 另外过多的参数增加了计算量, 不利于网络收敛。因此, 网络层数只有处于一个合理的区间内, AlexNet 神经网络的性能才能达到最佳。

2) 第 2 组实验

本课题组通过迁移学习比较不同卷积神经网络的性能。在 TensorFlow-GPU 模式下完成导入包、定义超参数、读取数据、构建神经网络层、创建损失函数、训练网络模型等操作之后, 利用 TensorBoard 生成损失值和识别准确率的曲线图。在 TensorFlow 中, 交叉熵损失函数用 tf.nn.softmax_cross_entropy_with_

logits 计算, 求其均值, 即为损失值。

迁移学习下, 本文算法、GoogLeNet、VGGNet 以及 SqueezeNet 的损失值和识别准确率的曲线图分别见图 5, 6。

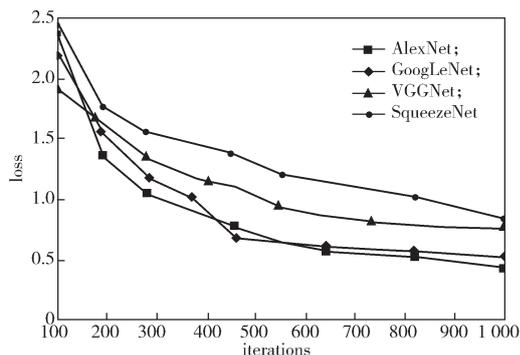


图 5 损失函数变化曲线

Fig. 5 Loss function curve

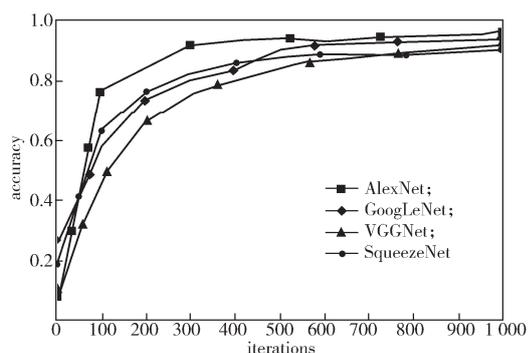


图 6 识别准确率曲线

Fig. 6 Recognition accuracy curve

由图 4~5 可知: 迁移学习下, 4 种卷积神经网络的识别准确率均在 90% 以上; 本文算法的识别准确率达到 95% 左右, 损失值也是最小的。可见, 本文算法取得了较好的识别效果。

3) 第 3 组实验

全新学习是指没有采用其他卷积神经网络已经训练好的权重和参数, 而是采用先随机初始化网络所有层的权重和参数, 然后利用训练集对网络从头开始训练的方法。在学习方式(全新学习、迁移学习)、正则项系数(0、0.001)、初始学习率(0.001、0.005)的不同组合下, 本课题组对本文算法进行了 8 组对比实验^[19], 实验结果见表 1。实验时, 迭代次数为 1000。

由表 1 可知: 迁移学习下, 本文算法的识别病害准确率和损失值都明显优于全新学习下的。正则项系

数对本文算法的性能影响比较小。全新学习下, 学习率为 0.005 的网络比学习率为 0.001 的好; 而在迁移学习下, 正好相反, 学习率为 0.001 的网络表现更为出色。其原因是全新学习下, 网络的权重和参数没有得到充分训练, 较大的学习率使网络更快地向最优解接近; 而迁移学习下, 网络前几层的权重和参数已经接近最优解, 较大的学习率使网络容易错过最优解而发生振荡, 从而导致损失值增大。可见, 迁移学习下, 学习率为 0.001 时本文算法的性能最好, 测试集的识别准确率约为 96.18%。

表 1 网络训练与测试时的损失值和准确率

Table 1 Loss and accuracy in network training and testing

序号	学习 方式	正则项 系数	学习 率	损失值		准确率 / %	
				训练集	测试集	训练集	测试集
1	全新 学习	0	0.001	0.742 6	1.462 9	74.57	53.61
2			0.005	0.465 8	1.147 2	87.25	57.82
3	迁移 学习	0.001	0.001	0.786 3	1.058 1	75.16	52.97
4			0.005	0.725 9	1.012 4	79.13	58.24
5	迁移 学习	0.001	0.001	0.011 6	0.186 3	99.36	95.09
6			0.005	0.001 8	0.241 8	99.82	94.27
7			0.001	0.012 4	0.336 9	99.47	96.18
8			0.005	0.003 9	0.471 2	99.84	94.25

5 结语

本课题组以水稻、小麦、玉米、棉花、大豆 5 种典型农作物的常见叶病害为研究对象, 参照 AlexNet 设计卷积神经网络, 再采用迁移学习训练本网络。实验结果表明: 迁移学习适用于数据集不大的卷积神经网络; 迁移学习模式下, 正则项系数对网络的影响较小, 学习率的设置不宜太大, 较小值更有助于网络求得最优解, 当学习率为 0.001 时, 本文算法的识别准确率在 95% 以上。本课题组在后续的研究中, 将增加复杂叶片(卷曲、残缺、枯萎等)和农作物病害种类的样本, 使本算法应用更加广泛。

参考文献:

- [1] 中国农业科学院植物保护研究所. 中国农作物病虫害(上册)[M]. 第 2 版. 北京: 中国农业出版社, 1995: 351-437.
Institute of Plant Protection. Chinese Crop Diseases and Pests (Volume 1)[M]. 2nd ed. Beijing: China Agricultural

- Press, 1995: 351-437.
- [2] 汤雪峰, 周平. 基于卷积神经网络的模糊车牌自动识别[J]. 包装学报, 2017, 9(5): 35-41.
TANG Xuefeng, ZHOU Ping. Automatic Fuzzy License Plate Recognition Based on CNN[J]. Packaging Journal, 2017, 9(5): 35-41.
- [3] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet Classification with Deep Convolutional Neural Networks[C]//Proceedings of the 25th International Conference on Neural Information Processing Systems. Lake Tahoe: ACM, 2012, 60(6): 1097-1105.
- [4] VEDALDI A, LENC K. MatConvNet: Convolutional Neural Networks for MATLAB[C]//Proceedings of the 23rd ACM International Conference. [S. l.]: ACM, 2015: 689-692.
- [5] 张航, 程清, 武英洁, 等. 一种基于卷积神经网络的小麦病害识别方法[J]. 山东农业科学, 2018, 50(3): 137-141.
ZHANG Hang, CHENG Qing, WU Yingjie, et al. A Method of Wheat Disease Identification Based on Convolutional Neural Network[J]. Shandong Agricultural Sciences, 2018, 50(3): 137-141.
- [6] 李艳. 基于改进CNN的马铃薯病害识别算法[J]. 信息通信, 2017, 30(6): 46-48.
LI Yan. Potato Disease Recognition Algorithms Based on Improved CNN[J]. Information and Communications, 2017, 30(6): 46-48.
- [7] 刘阔宇, 冯全, 杨森. 基于卷积神经网络的葡萄叶片病害检测方法[J]. 东北农业大学学报, 2018, 49(3): 73-83.
LIU Tianyu, FENG Quan, YANG Sen. Detection Graph Diseases Based on Convolution Neural Network[J]. Journal of Northeast Agricultural University, 2018, 49(3): 73-83.
- [8] SIMONYAN K, ZISSERMAN A. Very Deep Convolutional Networks for Large-Scale Image Recognition[J]. Computer Science, 2014, 1: 1-14.
- [9] 顾秀华, 王持, 周平. 基于图像识别的薄板自动计数算法[J]. 包装学报, 2017, 9(5): 56-61.
GU Xiuhua, WANG Chi, ZHOU Ping. Research on Automatic Counting of Sheet Number Based on Image Recognition[J]. Packaging Journal, 2017, 9(5): 56-61.
- [10] 程曦, 吴云志, 张友华, 等. 基于深度卷积神经网络的储粮害虫图像识别[J]. 中国农学通报, 2018, 34(1): 154-158.
CHENG Xi, WU Yunzhi, ZHANG Youhua, et al. Image Recognition of Stored Grain Pests: Based on Deep Convolutional Neural Network[J]. Chinese Agricultural Science Bulletin, 2018, 34(1): 154-158.
- [11] 杨晋丹, 杨涛, 苗腾, 等. 基于卷积神经网络的草莓叶部白粉病病害识别[J]. 江苏农业学报, 2018, 34(3): 527-532.
YANG Jindan, YANG Tao, MIAO Teng, et al. Recognition of Powdery Mildew Disease of Strawberry Leaves Based on Convolutional Neural Network[J]. Jiangsu Journal of Agricultural Sciences, 2018, 34(3): 527-532.
- [12] 马浚诚, 杜克明, 郑飞翔, 等. 基于卷积神经网络的温室黄瓜病害识别系统[J]. 农业工程学报, 2018, 34(12): 186-192.
MA Juncheng, DU Keming, ZHENG Feixiang, et al. Disease Recognition System for Greenhouse Cucumbers Based on Deep Convolutional Neural Network[J]. Transactions of the Chinese Society of Agricultural Engineering, 2018, 34(12): 186-192.
- [13] ZHANG S W, SHANG Y J, WANG L. Plant Disease Recognition Based on Plant Leaf Image[J]. Journal of Animal and Plant Sciences, 2015, 25(3): 42-45.
- [14] YOSINSKI J, CLUNE J, BENGIO Y, et al. How Transferable are Features in Deep Neural Networks[J]. Advances in Neural Information Processing Systems, 2014, 27: 3320-3328.
- [15] SLADOJEVIC S, ARSENOVIC M, ANDERLA A, et al. Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification[J]. Computational Intelligence and Neuroscience, 2016(6): 1-11.
- [16] BALLESTER P L, ARAUJO R M. On the Performance of GoogLeNet and AlexNet Applied to Sketches[C]//Proceedings of the 30th AAAI Conference on Artificial Intelligence. [S. l.]: ACM, 2016: 1124-1128.
- [17] WANG L M, GUO S, HUANG W L, et al. Places205-VGGNet Models for Scene Recognition[J]. Computer Science, 2015: 1-2.
- [18] SHAFIEE M J, LI F, CHWYL B, et al. SquishedNets: Squishing SqueezeNet Further for Edge Device Scenarios via Deep Evolutionary Synthesis[EB/OL]. [2018-03-02]. <https://arxiv.org/abs/1711.07459>.
- [19] 米硕, 孙瑞彬, 李欣, 等. 迁移学习在卷积神经网络中的应用[J]. 中国新通信, 2018(7): 121.
MI Shuo, SUN Ruibin, LI Xin, et al. Application of Transfer Learning in Convolutional Neural Networks[J]. China New Communications, 2018(7): 121.

Identification of Typical Crop Leaf Diseases Based on Convolutional Neural Network

DING Rui, ZHOU Ping

(School of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China)

Abstract: At present, the identification and diagnosis of some typical crop leaf diseases mainly rely on artificial method, which is time-consuming and laborious. Aimed at the diagnosis of common leaf diseases of five typical crops of soybean, cotton, rice, wheat and maize, a recognition method of typical leaf diseases of crops based on convolution neural network was proposed. Leaf disease images of typical crops were collected from the Plantvillage database and some other sites, and these images were pretreated to build a database of 12 836 sheets. Referring to AlexNet framework, an eight-layer convolutional neural network was constructed, and the transfer learning training network was adopted. Finally, the recognition accuracy and loss value of the network were verified by the test set. The performance of different convolutional neural networks was analyzed. The experimental results showed that the algorithm performed well in identifying typical crop leaf diseases. Under the transfer learning mode, with the learning rate of 0.001, the recognition accuracy of the algorithm in the training set was about 99.47%, and about 96.18% in the test set.

Keywords: convolutional neural network; crops; leaf disease identification; AlexNet; migration learning

.....
(上接第 66 页)

[14] 马冬菁. 城市生活垃圾处理产业化探讨 [J]. 湖南工业大学学报, 2011, 25(5): 62-65.
MA Dongjing. Discussion on Urban Domestic Wastes

Processing Industrialization[J]. Journal of Hunan University of Technology, 2011, 25(5): 62-65.

Economic Analysis of the Reverse Logistics Mode

ZHENG Xiangming, CHEN Yi

(School of Urban and Environmental Science, Hunan University of Technology, Zhuzhou Hunan 412007, China)

Abstract: With the rapid development in China's express delivery business, express garbage recycling has become the fastest growing industry of renewable resources recycling. There are three main models of express garbage recycling, including recycling by professional express packaging garbage recycling company, reverse logistics mode and public recycling mode. Among all these models, the reverse logistics is the most potential and inevitable main channel based on the analysis from economic view. At present, the reverse logistics mode shows the low garbage recovery rate, leading to the difficulty in achieving positive yield. Therefore, the following proposal was put forward as the express packaging garbage recycling should mainly be based on reverse logistics, supplemented by the other two methods. The public recycling mode should be adopted in rural areas, while the professional express packaging garbage recycling company mode should be adopted in first-tier cities with advanced economy. Meantime, the government should promote the development of the garbage recycling business from the aspects of policy, funding and publicity.

Keywords: express packaging recycling; reverse logistics; economic analysis