

孙云云, 江朝晖, 董伟, 等. 基于卷积神经网络和小样本的茶树病害图像识别[J]. 江苏农业学报, 2019, 35(1): 48-55.  
doi: 10.3969/j.issn.1000-4440.2019.01.007

# 基于卷积神经网络和小样本的茶树病害图像识别

孙云云<sup>1</sup>, 江朝晖<sup>1</sup>, 董伟<sup>2</sup>, 张立平<sup>2</sup>, 饶元<sup>1</sup>, 李绍稳<sup>1</sup>

(1. 安徽农业大学信息与计算机学院, 安徽 合肥 230036; 2. 安徽省农业科学院农业经济与信息研究所, 安徽 合肥 230036)

**摘要:** 以常见且特征相似的茶轮斑病、炭疽病和云纹叶枯病为对象, 研究在小样本情况下利用卷积神经网络进行病害图像识别问题。运用 7 种模式的预处理方法对茶树叶部病害图像样本进行处理, 并采用 AlexNet 经典网络模型进行学习实验, 比较、分析其训练及识别效果。结果显示, 模式 7 训练模型精度为 93.3%, 平均测试准确率为 90%, 且对茶轮斑病、炭疽病和云纹叶枯病的正确区分率分别为 85%、90% 和 85%, 在预测值和真实值一致性方面优于其他预处理方法。在小样本情况下, 该预处理方法可有效区分、识别 3 种易混病害, 且识别精度高, 性能好。

**关键词:** 茶叶病害; 图像识别; 卷积神经网络; 小样本

**中图分类号:** S126 **文献标识码:** A **文章编号:** 1000-4440(2019)01-0048-08

## Image recognition of tea plant disease based on convolutional neural network and small samples

SUN Yun-yun<sup>1</sup>, JIANG Zhao-hui<sup>1</sup>, DONG Wei<sup>2</sup>, ZHNAG Li-ping<sup>2</sup>, RAO Yuan<sup>1</sup>, LI Shao-wen<sup>1</sup>

(1. School of Information and Computer Science, Anhui Agricultural University, Hefei 230036, China; 2. Institute of Agricultural Economics and Information, Anhui Academy of Agricultural Sciences, Hefei 230036, China)

**Abstract:** Three kinds of common and similar tea diseases including pestalotiopsis theae, tea anthracnose and tea brown blight have been identified by the convolutional neural network(CNN) under the condition of small samples. Seven preprocessing modes were designed and used to process original tea plant leaf disease images automatically. The classic AlexNet network model was used to carry out the learning experiment, and the training and recognition effect was compared and analyzed. The result showed that the accuracy of training model under mode 7 was 93.3%, and the average test accuracy was 90%. And the correct recognition rates of the three diseases (pestalotiopsis theae, tea anthracnose and tea brown blight) were 85%, 90% and 85%, respectively, which were superior to the conventional pretreatment methods in terms of consistency between the predicted value and the true value. In the case of small samples, the proposed pretreatment method can effectively distinguish and identify three kinds of similar diseases, and has high recognition accuracy and good performance.

**Key words:** tea plant leaf disease; image recognition; convolutional neural network; small samples

收稿日期: 2018-06-08

基金项目: 农业部农业物联网技术集成与应用重点实验室开放基金项目(2016KL01); 国际先进农业科技计划的引进与创新项目(No.2016-X34); 安徽农业大学 2018 年度研究生创新基金项目(2018yjs-63)

作者简介: 孙云云(1992-), 女, 安徽界首人, 硕士研究生, 研究方向为作物信息处理, (E-mail) sunyunyun0910@sina.com

通讯作者: 江朝晖, (E-mail) jiangzh@ahau.edu.cn

茶树是重要的经济作物, 茶树病害发生严重<sup>[1-2]</sup>。常见的茶树病害有 40 多种, 以叶部病害居多<sup>[3]</sup>。利用机器视觉技术对植物病害进行自动检测和诊断是未来的发展方向<sup>[4-5]</sup>。由于卷积神经网络(CNN)等深度学习方法是由数据本身来驱动及其表达关系的自我学习<sup>[6]</sup>, 因而成为机器视觉的主流算法。Mohanty 等训练深度神经网络, 对 14

个作物品种 26 种病害的检测精度达 99.35%<sup>[7]</sup>。杨晋丹等采用卷积神经网络对草莓叶部白粉病进行识别获得成功<sup>[8]</sup>。Cruz 等开发了一种基于视觉的深度学习技术,并检测 *Xylella fastidiosa* 感染的橄榄叶片焦枯叶<sup>[9]</sup>。Amara 等采用深度学习方法实现了自动化的香蕉病害叶片分类<sup>[10]</sup>。深度学习模型训练时一般需要大量高质量的病害样本集作为网络模型输入数据,例如张善文等<sup>[11]</sup>的一种基于卷积神经网络的黄瓜病害识别方法中图像数据集多达 15 500 多幅。Brahimi 等收集了 14 828 张图像对番茄叶片病害进行识别<sup>[12]</sup>。但在实际应用中,往往存在样本采集少,图像质量低等问题,难以获得良好的识别效果<sup>[13]</sup>。因此,需要改进模型结构或参数,或者对原始样本进行加工和预处理。例如孙俊等<sup>[14]</sup>、Srdjan 等<sup>[15]</sup>分别设计了多种改进模型,对作物病害进行识别,获得了较高的识别准确率和较强的鲁棒性。吴翔<sup>[16]</sup>采用 Grabcut 分割方法对图像集进行预处理,提高了识别精度和识别速率。Lai 等<sup>[17]</sup>、Yi 等<sup>[18]</sup>采用基于 Laplacian 的超分辨率网络对图像集进行预处理,在低分辨率图像集下获得较好的识别效果。

本研究以常见且特征相似的茶轮斑病、茶炭疽病和茶云纹叶枯病为对象,研究 CNN 在小样本下的识别问题。设计、运用多种预处理方法对茶树叶部病害图像样本进行处理,采用适合病虫害识别的 AlexNet 经典网络模型进行学习实验。通过比较、分析模型的训练及识别效果,获得有效的图像预处理方法,以期提高小样本 CNN 病害识别的准确度。

## 1 材料与方法

### 1.1 材料

图像数据来源于安徽省农业科学院农业经济与信息研究所,实地拍摄。具体拍摄方式为:用单反数码相机在自然光和闪光灯补光 2 种光线环境下,以茶树叶片、土壤、天空等自然环境为背景,在田间直接采集病害图像;再利用图像处理软件对采集到的图像进行元数据标引、裁切、人工分类等预处理。经专业技术人员对比确认,最终筛选出茶树病害叶片样本图片 430 个,其中,茶轮斑病图片 94 个,茶炭疽病图片 252 个,茶云纹叶枯病图片 84 个。数据集分布情况见表 1。典型病害图像如图 1 所示,大小按

比例归一化为 300×200 像素。由表 1 和图 1 可知,病害图像具有数量少、背景复杂和目标区域占比少等特点。

表 1 茶树病害图像数据集分布表

Table 1 Distribution of disease image data sets of tea plant

病害种类	训练集 图片数	测试集 图片数	验证集 图片数	总数
茶轮斑病	67	7	20	94
茶炭疽病	209	23	20	252
茶云纹叶枯病	58	6	20	84



茶轮斑病 茶炭疽病 茶云纹叶枯病

图 1 3 种茶树叶部病害的典型图像

Fig.1 The typical images of three kinds of tea leaf diseases

### 1.2 图像预处理方法设计

以 AlexNet 为训练模型在相同参数设置下对同一数据集数据进行试验。在相同参数设置和同一数据集下,训练集图像的尺寸和质量是影响模型训练效率的关键因素。因此,为提高训练图像病害有效信息占比和提高模型训练效率,设计了 7 种预处理算法模式(表 2)进行卷积神经网络模型训练,包含文献[19]和[16]预处理方法在内的 8 种预处理方法。

### 1.3 卷积神经网络(CNN)模型

卷积神经网络包含多层卷积和池化层,用于逐层提取图片深层特征,在图像识别领域应用效果较好<sup>[20-21]</sup>。将预处理后的样本集图像输入 CNN 模型进行训练,生成 3 种易混病害识别模型。训练中采用擅长于图像识别的 AlexNet 经典网络模型<sup>[22]</sup>,模型结构见图 2。以尺寸为 50×50 的图像为例,模型包含 5 个卷积层(Conv1~Conv5)、3 个池化层(Pooling1~Pooling3)、2 个全连接层(Fc6、Fc7)以及 1 个分类层。其中,滤波器的大小为 11×11×3,卷积层 1 的卷积核数目为 96,卷积层 2 和 5 的卷积核数目均为 256,卷积层 3 和 4 的卷积核数目均为 384,2 个全连接层的神经元数量均为 4 096,分类层的输出类别数目即为最终的类别数。

表 2 7 种茶树叶片病害图像预处理模式

Table 2 Seven preprocessing modes of leaf disease images of tea plant

预处理方法	模式 1	模式 2	模式 3	模式 4	模式 5	模式 6	模式 7
平均像素填充较短边 <sup>[16]</sup>	√						
SLIC_SVM 去除背景 <sup>[17]</sup>				√	√	√	√
白色填充背景 <sup>[13]</sup>			√				
k-means 提取病斑					√	√	√
形态学处理						√	√
最小N×N 区域提取		√		√	√	√	√
归一化						√	
插值重建							√

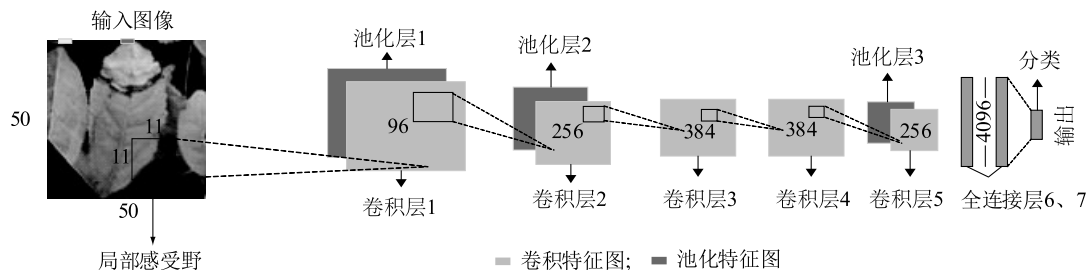


图 2 AlexNet 模型结构

Fig.2 The architecture of AlexNet model

#### 1.4 图像预处理

对样本集图像分别按照表 2 中设计的预处理方法自动生成 7 种新的样本集图像。其中 k-means 提取病斑、最小N×N 区域提取和插值重建方法是本研究改进后的预处理方法。归一化处理是针对尺寸不一致的样本图像进行的尺寸强制性统一化处理。SLIC\_SVM 算法是本团队设计的一种针对茶树叶部病害的复杂背景去除方法,在训练集样本中应用良好<sup>[19,23]</sup>。模式 1 和模式 4 的预处理方法分别对应文献[16]中的平均像素填充较短边并缩放为统一尺寸的方法和文献[13]中采用的迭代切割方法去除复杂背景并以白色填充背景实现目标提取。形态学处理是指图像处理中的像素点乘、填充和腐蚀等基础运算。

**1.4.1 改进 k-means 病斑提取** 病害样本中叶部病斑颜色特征差异最为显著,因此采用 k-means 方法在  $L^*$ 、 $a^*$ 、 $b^*$  颜色空间进行颜色聚类以提取出病斑<sup>[24]</sup>。该方法采用欧式距离计算像素点间距离,进行区域聚类,聚类完成后,病斑和叶片可以得到有效分离。但在区域图像选择方面,往往需要人工进行

挑选确定病斑图像,不利于算法的广泛应用。本研究对该方法进行改进,实现快速、自动地获得目标区域图像。主要原理是根据  $L^*$ 、 $a^*$ 、 $b^*$  颜色空间下对叶片和病害区域进行聚类,即对 2 个像素值区间的颜色进行聚类,从而导致 2 个区域质心分布的差异。根据差异,从分割的图像中通过公式(1)自动提取出病斑区域(图 3-b)。

$$k = \arg \min_i \sum_{i=1}^2 (x_i + y_i) \quad (1)$$

式中, $k$  是最终聚类块的像素序列号, $i$  是质心编号, $(x_i, y_i)$  是质心的坐标。

茶轮斑病、炭疽病和云纹叶枯病等病害发生时,叶片上往往会存在多个小区域病斑,这些病斑特征相同,分布具有随机性。若将单叶片中多个病斑区域全部提取作为训练集,会降低有效区域占比,不利于病斑的精确识别。因此,采用形态学处理方法提取出主病斑区域(图 3c)。

**1.4.2 最小N×N 病斑提取** 基于 CNN 对病斑图像进行特征提取和识别中,首先需要将病斑图像归一化为N×N 的待训练样本<sup>[25]</sup>。采用直接归一化或短边填充等方法,往往会造成冗余信息多,不利于有限





图3 k-means 方法提取叶片病斑

Fig.3 Leaf spot extracted by k-means

样本空间下 CNN 病斑特征的自主学习。结合最小外接矩形方法,提出一种适合于 CNN 模型样本训练的最小 $N \times N$ 病斑提取方法。

首先采用旋转卡壳法求解出病斑的最小外接矩形<sup>[26]</sup>(图 4a),接着对算法进行改进,得到最小 $N \times N$

病斑图像。最小 $N \times N$ 病斑提取步骤为:首先,对倾斜病斑图像进行旋转,用公式(2)计算倾斜角度 $\alpha$ ,使图像处于水平状态,接着将图像转化为二值图像,通过中心点的方法获得最小方形区域,最后通过将主病斑区域二值图像和原始图像进行点乘运算并裁剪获得最小 $N \times N$ 待训练病斑区域。假设中心点的坐标为 $C$ ,旋转后最小外接矩形中的最大边长为 $d_{\max}$ ,用公式(3)计算 $C$ 点坐标 $(x_c, y_c)$ ,用公式(4)计算 $d_{\max}$ 。通过公式(5)计算得到最小外接方形区域的4个顶点 $r_1, r_2, r_3, r_4$ (图 4b)。上述操作完成后,即可提取得到图 4c 所示的最小 $N \times N$ 病斑区域。

图4 最小 $N \times N$ 病斑提取Fig.4 The extraction of minimum  $N \times N$  lesion area

$$\alpha = \arctan \left[ \frac{x_i - \min(x_j)}{\min(y_i) - y_j} \right] \times \frac{180}{\pi} \quad (2)$$

$$\begin{cases} x_c = \frac{x_n - x_1}{2} + x_1 \\ y_c = \frac{y_n - y_1}{2} + y_1 \end{cases} \quad (3)$$

$$d_{\max} = [(x_n - x_1), (y_n - y_1)] \quad (4)$$

$$\begin{cases} r_1 = (x_c - \frac{d_{\max}}{2}, y_c - \frac{d_{\max}}{2}) \\ r_2 = (x_c + \frac{d_{\max}}{2}, y_c - \frac{d_{\max}}{2}) \\ r_3 = (x_c - \frac{d_{\max}}{2}, y_c + \frac{d_{\max}}{2}) \\ r_4 = (x_c + \frac{d_{\max}}{2}, y_c + \frac{d_{\max}}{2}) \end{cases} \quad (5)$$

1.4.3 超分辨率病斑重建将最小 $N \times N$ 主病斑区域从图像集样本叶片中提取完成后,会产生若干个大

小不一的方形病斑图像,显然不能直接作为 CNN 训练图像集,但若将病斑图像尺寸直接归一化,会造成图像分辨率下降,不利于 CNN 特征提取。因此,采用超分辨率重建的方法获得较高质量的训练集病斑图像<sup>[18]</sup>。

超分辨率重建(Super-resolution image reconstruction)的概念最早由 Harris 于 1964 年提出,是一种针对低分辨率图像提出的一种分辨率恢复方法,在图像处理领域应用广泛<sup>[27-28]</sup>。插值是图像超分辨率重建的一个关键步骤,广泛采用的有最邻近插值法、双线性插值法、双三次插值法<sup>[29]</sup>。对比 3 种插值算法超分辨率重建样本集图像的效果,并计算峰值信噪比(PSNR)、均方误差(MSE)、结构相似性(SSIM)3 个指标值进行评价。由图 5 和表 3 可知,双三次插值法的放大效果最好,可用于 CNN 模型训练样本集图像超分辨率重建。






图 5 不同插值算法的超分辨率图像重建效果

Fig.5 Super-resolution image reconstruction effects of different interpolation algorithm

表 3 3 种插值算法的效果指标值

Table 3 Performance indicators of three kinds of interpolation methods

指标	最邻近插值法	双线性插值法	双三次插值法
峰值信噪比 (PSNR)	22.495 9	22.348 1	22.505 6
均方误差 (MSE)	366.011 6	476.723 9	365.187 5
均方误差 (MSE)	0.965 8	0.850 7	0.972 9

## 2 结果与分析

试验平台环境搭建参数见表 4。AlexNet 模型参数设置为:网络初始权重提取自标准差为 0.01、均值为 0 的高斯分布;训练阶段采用动量项为 0.9 的异步随机梯度下降,并设置权重参数的初始学习率为 0.01。试验采用交叉验证的方式,按照 9:1 比例随机分配训练集与测试集,且以表 2 中设计的预处理方法产生的图像样本集分别进行卷积神经网络 AlexNet 识别模型训练(图 6)。试验中每个模型迭代次数为 8 000。在输入卷积神经网络前,模式 1 定位图像被随机裁剪为 280×280 dpi,模式 2、3 和 4 定位图像被随机裁剪为 80×80 dpi,其他 3 种模式的定位图像被裁剪为 40×40 dpi,裁剪完成后作镜像翻转以扩增数据集。

表 4 试验平台搭建

Table 4 Construction of the test platform

硬件	软件
CPU: Intel Xeon E3-1230	Windows10
RAM: 12GB DDR3	CUDA8.0+CUDDNN5.0+VS2013
GPU: NVIDIA GTX1060 (6GB)	Caffe+Matlab2017b

7 种模式下模型训练的精度 (Accuracy) 和损失函数 (Loss) 曲线见图 7。对 7 种预处理模式分别训

练 10 次,得到表 5 所示结果。7 种预处理模式下,随着迭代次数的不断增加,训练精度都在不断增加,直至趋于稳定。其中,模式 7 的训练精度达到 0.933,明显优于其他 6 种模式,Loss 收敛速度也较快,因此训练结果可靠。由表 5 可见,模式 7 的平均测试准确率为 90%,明显优于其他 6 种模式,且标准差也最小。7 种模式的训练结果表明:在训练精度曲线中,训练精度大小顺序为模式 7>模式 4>模式 1>模式 2>模式 6>模式 3>模式 5;在 loss 曲线图中,除了模式 5 和模式 6 存在跳跃点以外,其他几个模式曲线收敛速度都较快,可信度都比较高。7 种模式的平均准确率大小顺序为模式 7>模式 1>模式 2>模式 3>模式 4>模式 6>模式 5;在运行时间上,模式 1 时间长达 3 264 s,而其他几种模式都在 10 min 左右,相差较大的主要原因是模式 1 中图像尺寸较大。模式 7 中由于采用图像重建提高样本质量,因而运行时间相对于其他 5 种模式也增加了约 100 s,但相对于常规 CNN 模型训练耗时较少。因此模式 7 (主要作用是去除背景提取病斑,形态学处理,最小  $N \times N$  区域提取和超分辨率重建) 在训练精度和平均测试准确率及模型训练耗时方面优势明显。

分别以模式 7、模式 1 (文献[19]) 和模式 3 (文献[16]) 的预处理方法对验证集图像进行最终模型识别效果验证。结果表明,Mode1 中 70% 的轮斑病图像被正确识别为轮斑病,75% 的炭疽病图像被正确识别为炭疽病,75% 的云纹叶枯病图像被正确识别为云纹叶枯病;Mode3 中 25% 的轮斑病图像被正确识别为轮斑病,85% 的炭疽病图像被正确识别为炭疽病,10% 的云纹叶枯病图像被正确识别为云纹叶枯病;Mode7 中 85% 的轮斑病图像被正确识别为轮斑病,90% 的炭疽病图像被正确识别为炭疽病,85% 的云纹叶枯病图像被正确识别为云纹叶枯病。图 8 为本研究设计的模式 7 下预处理方法识别 3 种病害的性能评估 ROC 曲线,可以看出,模式 7 对 3 种病害的识别精度高、性能好。

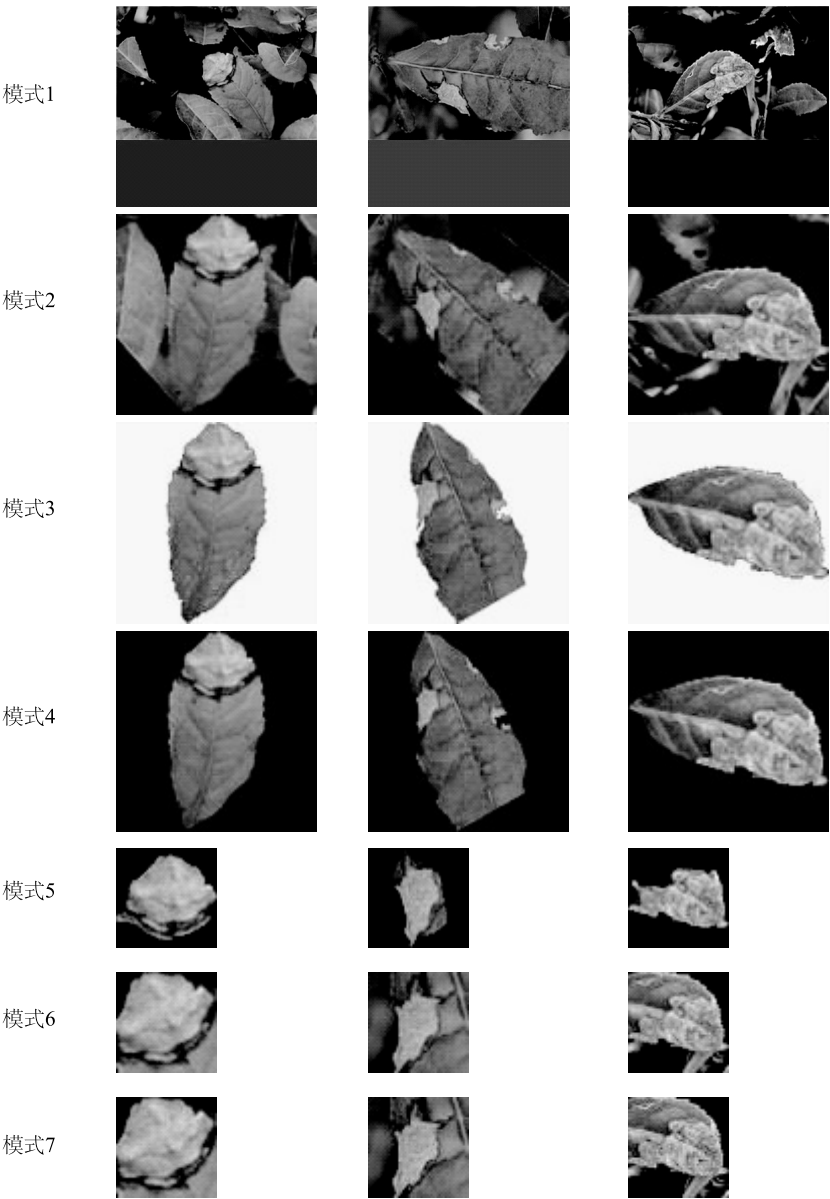


图6 训练集样本预处理结果  
Fig.6 The preprocessing results of training set sample

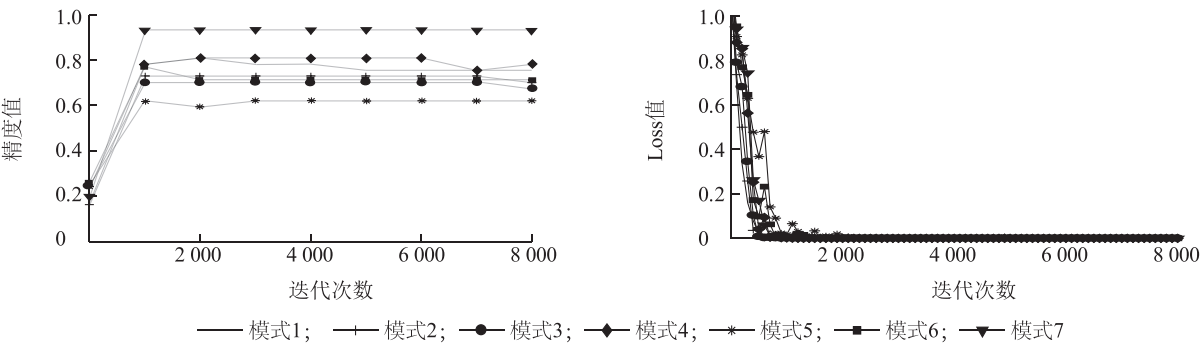


图7 7种预处理模式的训练精度和损失函数(Loos)曲线  
Fig.7 Training curves of accuracy and loss function of seven preprocessing modes


表 5 不同预处理模式的训练结果对比

Table 5 Comparison of training results of different preprocessing modes

算法	运行时间 (s)	尺寸 (像素)	平均测试 准确度
模式 1	3 264	300×300	0.784±0.047
模式 2	635	100×100	0.735±0.033
模式 3	634	100×100	0.730±0.042
模式 4	637	100×100	0.678±0.027
模式 5	657	50×50	0.608±0.026
模式 6	543	50×50	0.674±0.034
模式 7	725	50×50	0.900±0.027

### 3 结 论

针对茶树病害自动图像检测的需求和训练样本小影响深度学习模型性能的难题,研究了通过对样本进行预处理从而提高训练效果的可行性。设计和运用 7 种不同模式进行卷积神经网络病害识别,用结构和参数相同的 AlexNet 模型训练,分析、比较训练及实测效果。试验结果显示,模式 7 识别精度达 93.3%,平均测试准确率为 90%,识别效果最好。试验中,茶轮斑病、茶炭疽病和茶云纹叶枯病 3 种病害的样本图片数量分别为 94、252 和 84,属于典型的小样本。本研究设计的模式 7 预处理方法,能够提高小样本卷积神经网络病害识别准确度且性能好,本研究方法能够准确地识别、区分茶轮斑病、炭疽病和云纹叶枯病。



A、B、C 分别为轮斑病、炭疽病、云纹叶枯病 ROC 曲线。

图 8 模式 7 的识别性能评估曲线

Fig.8 Identification performance evaluation curve of mode 7

### 参考文献:

- [1] 刘 威,袁 丁,郭桂义,等. 茶树炭疽病病原鉴定[J]. 南方农业学报, 2017, 48(3): 448-453.
- [2] 王国君,陈利军,熊建伟,等. 对茶树炭疽病病菌具拮抗作用根际促生细菌的分离、筛选及鉴定[J]. 江苏农业科学, 2017, 45(11): 76-78.
- [3] 张 强,杨云祥,唐方圆,等. 茶树主要病害及防治措施研究[J]. 中国农业信息, 2015(12): 80-81.
- [4] 赖军臣,李少昆,明 博,等. 作物病害机器视觉诊断研究进展[J]. 中国农业科学, 2009, 42(4): 1215-1221.
- [5] 赵建敏,薛晓波,李 琦. 基于机器视觉的马铃薯病害识别系统[J]. 江苏农业科学, 2017, 45(2): 198-202.
- [6] 李彦冬,郝宗波,雷 航. 卷积神经网络研究综述[J]. 计算机应用, 2016, 36(9): 2508-2515.
- [7] MOHANTY S P, HUGHES D P, SALATHÉ M. Using deep learning for image-based plant disease detection [J]. Frontiers in Plant Science, 2016, 22(7): 1-10.
- [8] 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.
- [9] CRUZ A C, LUVISI A, BELLIS L D, et al. Vision-based plant disease detection system using transfer and deep learning [C]. Spokane, Washington: American Society of Agricultural and Biological Engineers, 2017: 1-9.
- [10] AMARA J, BOUAZIZ B, ALGERGAWY A, et al. A deep learning-based approach for banana leaf diseases classification [C]. B. Mitschang, Bonn: Lecture Notes in Informatics, 2017: 79-88.
- [11] 张善文,谢泽奇,张晴晴. 卷积神经网络在黄瓜叶部病害识别中的应用[J]. 江苏农业学报, 2018, 34(1): 56-61.
- [12] BRAHIMI M, BOUKHALFA K, MOUSSAOUI A. Deep learning

- for tomato diseases: classification and dymptoms visualization[J]. Applied Artificial Intelligence, 2017, 31 (4):299-315.
- [13] LIU S, DENG W. Very deep convolutional neural network based image classification using small training sample size [C]. Kuala Lumpur, Malaysia: Asian Conference on Pattern Recognition (ACPR), 2016:730-734.
- [14] 孙 俊,谭文军,毛罕平,等. 基于改进卷积神经网络的多种植物叶片病害识别[J]. 农业工程学报, 2017, 33(19):209-215.
- [15] SRDJAN S, MARKO A, ANDRAS A, et al. Deep neural networks based recognition of plant diseases by leaf image classification[J]. Computational Intelligence and Neuroscience, 2016, 2016(6):1-11.
- [16] 吴 翔. 基于机器视觉的害虫识别方法研究[D]. 杭州:浙江大学, 2016.
- [17] LAI W S, HUANG J B, AHUJA N, et al. Fast and accurate image super-resolution with deep laplacian pyramid networks [J] Computer Vision and Pattern Recognition, 2017, 99:1-14.
- [18] YI Y, XI C, DI Z, et al. Deep recursive super resolution network with laplacian pyramid for better agricultural pest surveillance and detection [J]. Computers & Electronics in Agriculture, 2018, 150:26-32.
- [19] 杨国国,鲍一丹,刘子毅. 基于图像显著性分析与卷积神经网络的茶园害虫定位与识别[J]. 农业工程学报, 2017, 33(6):156-162.
- [20] WU Z, HU Z, FAN Q. Superpixel-Based unsupervised change detection using multi-dimensional change vector analysis and svm-based classification [J]. Photogrammetry, Remote Sensing and Spatial Information Sciences, 2012, 1(7):257-262.
- [21] HOOCHANG S, ROTH H R, GAO M, et al. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning[J]. IEEE Transactions on Medical Imaging, 2016, 35(5):1285.
- [22] ZHAO B, WANG M, LIU M. An energy-efficient coarse grained spatial architecture for convolutional neural networks AlexNet[J]. Ieice Electronics Express, 2017, 14(15):1-12.
- [23] TANG J L, WANG D, ZHANG Z G, et al. Weed identification based on K-means feature learning combined with convolutional neural network [J]. Computers & Electronics in Agriculture, 2017, 135:63-70.
- [24] TANG J L, WANG D, ZHANG Z G, et al. Weed identification based on K-means feature learning combined with convolutional neural network [J]. Computers & Electronics in Agriculture, 2017, 135:63-70.
- [25] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [C]. Long Beach, CA, USA: International Conference on Neural Information Processing Systems, MIT Press, 2012:1097-1105.
- [26] 卢 蓉,范 勇,陈念年,等. 一种提取目标图像最小外接矩形的快速算法[J]. 计算机工程, 2010, 36(21):178-180.
- [27] HARRIS J L. Diffraction and resolving power [J]. J Opt Soc Am, 1964, 54(7):931-933.
- [28] ANBARJAFARI G, DEMIREL H. Image super resolution based on interpolation of wavelet domain high frequency subbands and the spatial domain input image[J]. ETRI Journal, 2010, 32(3):390-394.
- [29] 王会鹏,周利莉,张 杰. 一种基于区域的双三次图像插值算法[J]. 计算机工程, 2010, 36(19):216-218.

(责任编辑:张震林)