

# 基于改进残差网络的园林害虫图像识别

陈娟<sup>1</sup> 陈良勇<sup>1</sup> 王生生<sup>1</sup> 赵慧颖<sup>1</sup> 温长吉<sup>2</sup>

(1. 吉林大学计算机科学与技术学院, 长春 130012; 2. 吉林农业大学信息技术学院, 长春 130118)

**摘要:** 针对北方园林害虫识别问题, 提出了一种基于改进残差网络的害虫图像识别方法。首先, 采用富边缘检测算法, 将中值滤波、Sobel 算子和 Canny 算子相结合, 对害虫图像进行边缘检测; 然后, 改进残差网络中的残差块, 通过添加卷积层和增加通道数提取更多的害虫图像特征, 并将贝叶斯方法运用于改进后的网络中, 优化超参数; 最后, 将预处理的害虫图像输入神经网络中, 利用分块共轭算法优化网络权重。对 38 种北方园林害虫进行了识别, 试验结果表明, 在相同数据集下, 与 3 种传统害虫识别方法相比, 本文方法的平均识别准确率平均提高 9.6 个百分点, 加权平均分数分别提高 16.3、10.8、4.5 个百分点。

**关键词:** 图像识别; 害虫控制; 残差网络; 贝叶斯方法

中图分类号: TP391.41; S126 文献标识码: A 文章编号: 1000-1298(2019)05-0187-09

## Pest Image Recognition of Garden Based on Improved Residual Network

CHEN Juan<sup>1</sup> CHEN Liangyong<sup>1</sup> WANG Shengsheng<sup>1</sup> ZHAO Huiying<sup>1</sup> WEN Changji<sup>2</sup>

(1. College of Computer Science and Technology, Jilin University, Changchun 130012, China

2. College of Information and Technology, Jilin Agricultural University, Changchun 130118, China)

**Abstract:** Plant pest and disease is one of the three major natural disasters. Pest identification tends to consume a lot of labor, and it is difficult for naked eyes to quickly and accurately identify pest species. However, there still exist some drawbacks in the traditional deep learning algorithms for pest recognition, such as gradient explosion or gradient disappearance in deep neural networks, degradation and overfitting caused by limited sample size. In order to address these problems and improve the accuracy of pest recognition, a pest image recognition method based on improved residual network was proposed. Firstly, the pest images in the data set were converted to grayscale before edge detection was performed on them by using Rich-edge. To obtain a fine-lined pest image, the Rich-edge was combined with median filtering, Sobel operator and Canny operator to detect the edges of the pest images. Among them, the median filter effectively eliminated the salt and pepper noise, the Sobel operator accurately detected the position information, and the Canny operator detected the weak edge. The images after edge detection were quantized to be 224 pixel × 224 pixel for training and classification. Then the obtained pest image set was used to train the deep neural network, which was a variant of standard residual network with additional convolution layers and channels for extracting more image features. And the dropout layer was added to each residual block of the network to prevent overfitting when it was trained on a relatively small data set. Besides, the regularization hyper parameters of the network were designed to be optimized by Bayesian method which adaptively adjusted the size of the hyper parameters with the adjustment of weights during network training. The weights of the proposed network were optimized through the Block-cg algorithm. In the optimization algorithm, the block diagonal was used to approximate the curvature matrix, which improved the convergence of the Hessian matrix; and independent conjugate gradient update was conducted for each sub-block, which divided the whole issue into certain number of sub-problems and reduced the complexity of local search. Eventually the values of the weights were not updated until an ideal pest classification accuracy rate was obtained. To verify the validity and robustness

收稿日期: 2018-11-02 修回日期: 2018-11-26

基金项目: 吉林省科技发展计划项目(20180101334JC, 20190302117GX, 20160520099JH) 和吉林省发展改革委创新能力建设(高技术产业部分)项目(2019C053-3)

作者简介: 陈娟(1980—), 女, 副教授, 主要从事人工智能和农业信息化研究, E-mail: chenjuan@jlu.edu.cn

通信作者: 王生生(1974—), 男, 教授, 博士生导师, 主要从事机器视觉与农业信息化研究, E-mail: wss@jlu.edu.cn

of the proposed method, an image data set of 38 common garden pests in north of China was collected and experiments were carried out on this data set. Experimental results empirically demonstrated that compared with the three traditional pest recognition methods for the same data set, the proposed method could make the recognition accuracy increase by 9.6 percentage points on average and the weighted average score increase by 16.3 percentage points, 10.8 percentage points and 4.5 percentage points, respectively.

**Key words:** image recognition; pest control; residual network; Bayesian method

## 0 引言

园林害虫是制约森林城市建设的主要因素之一。在生长发育过程中,园林树木受到各种虫害的侵袭,导致树木生长不良、出芽凋萎、腐烂等现象,甚至引起整株死亡。这不仅影响了园林植物的正常生长和观赏、绿化价值,而且造成了很大的经济损失。目前,园林害虫的种类区分及数量统计工作主要依靠人工进行,劳动强度大,工作效率低。因此,使用人工智能和机器视觉技术实现对害虫图像的自动化识别具有重要意义。

近年来,研究者提出了许多害虫识别系统<sup>[1-11]</sup>。如基于视觉词袋框架<sup>[12]</sup>(Bag of words, BoW), VENUGOBAN 等<sup>[13]</sup>将方向梯度直方图<sup>[14]</sup>(Histograms of oriented gradients, HOG)与加速鲁棒特征<sup>[15]</sup>(Speeded up robust features)相结合,对稻田害虫图像进行分类。XIE 等<sup>[16]</sup>使用稀疏编码的空间金字塔模型识别农田害虫图像。与早期支持向量机和神经网络方法相比,带有背景的害虫图像识别精度已经得到了提高。为了进一步提高识别能力,XIE 等<sup>[17]</sup>提出了基于多任务稀疏表示和多核学习的害虫识别方法。孙俊等<sup>[18]</sup>提出了一种批归一化与全局池化相结合的新型神经网络模型植物害虫识别方法。刘德营等<sup>[19]</sup>采集田间自然状态下的白背飞虱图像,提出了一种基于卷积神经网络的白背飞虱识别方法,并进行了应用研究。HAFIZ 等<sup>[20]</sup>基于贝叶斯网络提出了一种害虫彩色图像识别方法。杨国国等<sup>[21]</sup>基于图像显著性分析和 Grubcut 算法<sup>[22]</sup>对复杂背景下的害虫目标进行定位,通过 AlexNet 卷积神经网络架构,实现了对茶园主要害虫的表达和分类。肖志云等<sup>[23]</sup>提出了一种基于小波域的马铃薯典型虫害特征提取与识别方法。基于支持向量机与区域生长结合算法,潘春华等<sup>[24]</sup>设计了黄曲条跳甲、烟粉虱、小菜蛾、蓟马这 4 类蔬菜害虫分类识别的检测算法。

北方园林面积大,害虫蔓延速度快,对植物生长发育危害极大,给园林虫害防治工作带来巨大难度。以佳木斯市双拥公园为例,仅乔木、灌木、草坪和花坛 4 种生态环境下的园林害虫就多达 26 种<sup>[25]</sup>。此

外,北方园林害虫种类多,且外形相似度很高,也给自动识别带来一定难度。在收集到的北方园林害虫数据集上可测试多种现有害虫识别方法,但随着网络结构的加深,这些方法容易导致梯度消失,或者梯度爆炸或退化现象,以及出现样本数量有限造成的过拟合等问题。为解决上述方法存在的问题,本文提出一种基于改进残差网络的害虫图像识别方法。

## 1 材料与方法

### 1.1 试验材料

试验选取北方园林常见害虫作为测试对象,针对大黑鳃金龟、杨叶甲、大青叶蝉、红天蛾、春尺蠖、榆黄叶甲、桃蚜等 38 类园林害虫收集图像进行识别。获取害虫图像的途径有两个:在自然光环境下,利用单反数码相机或智能手机实地拍摄,以植株、土壤、天空等自然环境为背景收集净月潭国家森林公园的园林害虫图像;从 Google、Naver 和 FreshEye 等搜索引擎上收集害虫图像。在植保专家的指导下,为获取的害虫图像标记类别,建立样本库。部分害虫样本图像如图 1 所示。样本库中每类害虫样本图像的数量在 200~300 之间,其中包括不同角度、姿态和自然环境下的原始图像。由于同一害虫在不同虫龄阶段的形态差异较大,试验将每一类害虫标记为幼虫和成虫两个子类别。

### 1.2 害虫图像识别方法

基于改进残差网络的害虫图像识别方法的流程图如图 2 所示。首先,使用富边缘检测算法(Rich-edge)对害虫图像进行边缘检测,得到轮廓精细的害虫图像。然后将得到的害虫图像集用来训练改进的残差神经网络,通过分块共轭算法(Block-cg)优化网络权重,更新超参数的值,直至达到理想的害虫分类准确率。

#### 1.2.1 图像数据集的预处理

在采集到的害虫原始图像中,为了能够更加精确地将害虫图像与背景分离,得到害虫图像的完整轮廓和更加丰富的细节信息,本文使用 Rich-edge 算法对害虫图像进行边缘检测。Rich-edge 将中值滤波、Sobel 算子和 Canny 算子三者相结合对害虫图像进行边缘检测。使用中值滤波对输入的图像进行去



图1 部分园林害虫样本图像

Fig. 1 Sample images for 24 insect species from garden

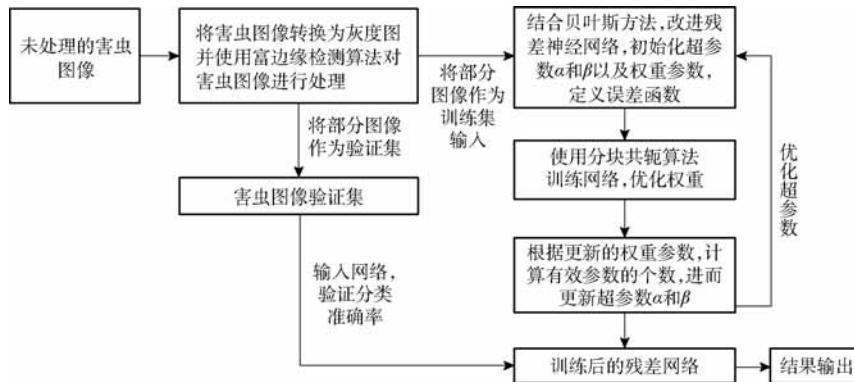


图2 基于改进残差网络的害虫图像识别流程图

Fig. 2 Flow chart of pest recognition based on improved residual network

除噪声处理, 中值滤波器能够有效地消除椒盐噪声, 并且能够很好地保留害虫图像的边缘细节。将 Sobel 算子和 Canny 算子的优点相结合, Sobel 算子可以检测到准确的位置信息, Canny 算子能够检测到弱边缘, 将二者相结合, 可使得到的害虫图像有更加完整的轮廓和丰富的细节信息, 提高了边缘检测的准确性。富边缘检测算法流程图如图 3 所示。

将彩色的害虫图像转换为灰度图像, 减小背景对图像的影响。使用 Rich-edge 算法对害虫灰度图进行边缘检测。将数据集进行图像的尺度归一化处理, 统一处理为 224 像素  $\times$  224 像素的图像。预留出已知样本  $\{X_i, Y_i\}$  来计算概率分布。具体步骤为:

(1) 对害虫的彩色图像进行灰度处理, 使用公式  $G_r = 0.299R + 0.587G + 0.114B$  来计算灰度值, 把 RGB 图像转换为灰度图, 其中  $R, G, B$  分别表示

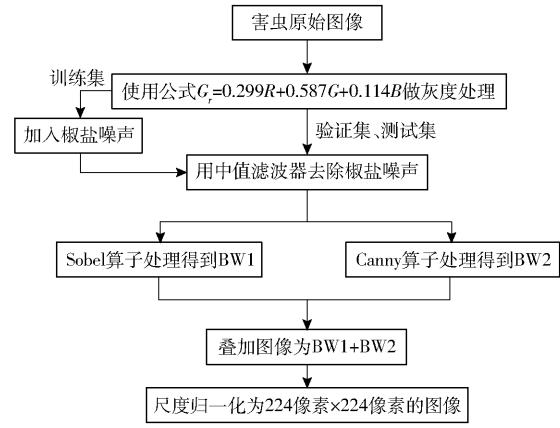


图3 富边缘检测算法流程图

Fig. 3 Flow chart of Rich-edge algorithm

彩色图像红、绿、蓝 3 个颜色通道数值。

(2) 向训练集图像  $f_1(x, y)$  中随机添加椒盐噪声, 模拟图像在传输、处理等过程中的噪声干扰, 增强算法的可靠性。

(3) 使用中值滤波器去除害虫灰度图的椒盐噪

声, 使用滑动窗口方式检测图像, 得到输出图像  $f_2(x, y)$ 。

(4) 使用 Sobel 算子对害虫图像  $f_2(x, y)$  进行边缘检测, 得到输出 BW1。

(5) 使用 Canny 算子对害虫图像  $f_2(x, y)$  进行边缘检测, 得到输出 BW2。

(6) 将 Sobel 算子和 Canny 算子检测到的害虫边缘图像 BW1、BW2 进行叠加。

(7) 将 Rich-edge 得到的害虫边缘图像统一处理为 224 像素  $\times$  224 像素的图像。

## 1.2.2 改进残差网络的结构与学习算法

改进的残差神经网络模型是对传统残差网络<sup>[26]</sup> (Residual network, ResNet) 中的每个残差块的结构进行改变, 通过添加卷积层和增加通道数来提取更多的害虫图像特征, 并将贝叶斯方法运用于改进后的网络中。初始化超参数和网络权重, 最小化总误差, 优化网络权重, 进而优化超参数, 重复该过程直到网络收敛。

ResNet 通过增加网络的深度来提高网络的性能。通过在输入和输出之前添加一个恒等映射可以有效地解决网络训练过程中出现的梯度消失问题, 从而通过增加网络深度来提高效果。

残差学习算法的目标函数  $H$  分为两部分, 定义为

$$H(x) = F(x) + x \quad (1)$$

式中  $x$ ——网络输入

$F$ ——网络学习的残差函数

当下层误差变大时, 网络会自动将  $F(x)$  逼近 0。

根据残差学习算法, ResNet 网络的残差块输出为

$$y = F(x, W_1, W_2, \dots, W_i, \dots, W_n) + x \quad (2)$$

式中  $W_i$ ——残差块中第  $i$  个卷积层权重

为了统一输入和输出的维数, 在维度不匹配的线性映射中, 需要对输入  $x$  做一个线性变换  $W_s$ , 这时残差网络的输出公式为

$$y = F(x, W_1, W_2, \dots, W_i, \dots, W_n) + W_s x \quad (3)$$

式中  $W_s$ ——线性映射

对传统的 ResNet 网络中的残差块结构进行修改, 每个残差块包含 2 个卷积层, 每个卷积层使用尺寸为  $3 \times 3$  的卷积核来增加网络宽度, 在两个卷积层之间加入 Dropout 层, 结构如图 4 所示。

当残差块中包含 2 个卷积层时, 其学习公式为

$$F(x) = W_2 \sigma(W_1 x) \quad (4)$$

式中  $\sigma$ ——ReLU 映射

式(4)为了简洁省略了偏置。

将预处理中得到的害虫边缘图像输入到构建的

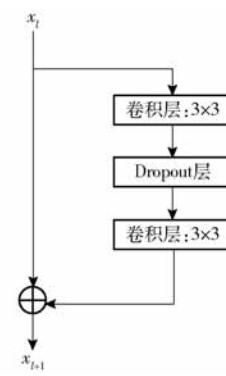


图 4 改进残差网络的残差块结构

Fig. 4 Residual block of improved residual network

改进残差网络中。利用贝叶斯原理对残差神经网络的权重参数进行初始化, 在这里假定该网络的参数  $W$  (权值和阈值等) 符合高斯分布。根据网络的输出结构, 得到网络的总误差函数。

将预处理中得到的害虫图像的训练集记为  $D = \{x_k, y_k\}, k = 1, 2, \dots, K, K$  为害虫图像样本总数。 $\alpha$  和  $\beta$  是改进残差网络的两个超参数, 在训练之前将  $\alpha$  和  $\beta$  进行初始化, 通过迭代优化超参数, 提高网络学习的性能和效果。网络结构记为  $A$ , 在  $A$  和  $W$  确定的情况下可以根据输入向量  $x$  得到网络的输出  $y$ , 将训练集的误差函数定义为

$$E_D(D|W, A) = \sum_k \frac{1}{2} (y(x_k, W, A) - y_k)^2 \quad (5)$$

并且在该函数后添加正则化项  $E_W(W|A) = \sum_i \frac{1}{2} w_i^2$  来防止过拟合,  $w_i$  为网络  $A$  的权重参数, 总误差函数定义为

$$M(W) = \alpha E_W(W|A) + \beta E_D(D|W, A) \quad (6)$$

在给定观察数据后, 通过已有的参数可以得到网络参数的后验概率为

$$P(W|D; \alpha, \beta, A) = \frac{\frac{1}{Z_W(\alpha)} \frac{1}{Z_D(\beta)} \exp(-M(W))}{P(D|\alpha, \beta, M)} \quad (7)$$

$$\text{其中 } Z_W(\alpha) = \left(\frac{2\pi}{\alpha}\right)^{\frac{m}{2}} \quad Z_D(\beta) = \left(\frac{2\pi}{\beta}\right)^{\frac{K}{2}}$$

式中  $P(D|\alpha, \beta, M)$ ——超参数  $\alpha$  和  $\beta$  的显著度

$Z_W, Z_D$ ——归一化系数

$m$ ——该网络中所有权重参数的个数

归一化系数和  $W$  无关, 因此网络参数  $W$  的优化可转换为最小化网络总误差  $M(W)$ 。

## 1.2.3 基于分块共轭算法的网络优化

分块共轭算法 (Block-cg) 使用块对角线来近似曲率矩阵, 提高了 Hessian 矩阵的收敛性, 并且对每个子块进行独立的共轭梯度更新, 将子问题分离开

处理,降低了局部搜索的复杂性。对比梯度下降、牛顿法以及共轭梯度等经典算法,Block-cg 算法具有计算效率高、计算复杂性小等优势,并且具有更好的收敛性和泛化能力。

本文使用 Block-cg 算法优化网络,更新网络的权重参数,减小误差函数,主要步骤如下:

(1) 参数变量定义:害虫图像的训练数据集记为  $D_T = \{(x_i, y_i)\}, i=1, 2, \dots, T$ , 改进残差网络的输出函数为  $z_i = f(x_i, w)$ , 损失函数定义为  $\lambda(z_i, y_i)$ , 其他超参数的定义如下:算法调用的最大循环次数为  $l$ , 最大的共轭梯度迭代次数为  $C_g$ , 停止计算共轭梯度的准则为  $cg\_stop$ , 学习速率为  $\eta$ 。并且定义两个害虫图像数据集,随机选取数据集  $D_g \subset D_T$  用来计算梯度  $g = (g_{(1)}; g_{(2)}; \dots; g_{(B)})$ , 害虫图像数据集  $D_c \subset D_g$ , 该数据集用来计算曲率向量。

(2) 曲率矩阵的近似矩阵  $G$  的计算和分块。根据随机选取的害虫图像数据集  $D_c$ , 通过 Gauss - Newton 方法计算矩阵  $G$  作为曲率矩阵的近似

$$G = \frac{1}{|D_c|} \sum_{(x, y) \in D_c} 2\beta J^T J + 2\alpha I \quad (8)$$

式中  $J$ —网络输出对于权重参数导数的 Jacobian 矩阵

$I$ —单位矩阵

将矩阵  $G$  分成  $B \times B$  的子块,  $G_{(b)}$  表示矩阵  $G$  的第  $b$  个对角块。

(3) 将网络的权重参数分成  $B$  个子块,  $W = (w_{(1)}, w_{(2)}, \dots, w_{(b)}, \dots, w_{(B)})$ 。将梯度也分成子块, 即  $\nabla \lambda(W) = (\nabla_{(1)} \lambda, \nabla_{(2)} \lambda, \dots, \nabla_{(b)} \lambda, \dots, \nabla_{(B)} \lambda)$ , 其中向量  $\nabla_{(b)} \lambda$  仅包含了参数子块  $w_{(b)}$  的梯度。通过对角块划分的方式,可以利用对每个块的计算来求解子问题。

(4) 随机选取小批量数据集  $D_g$  来计算梯度  $g$ , 以及小批量数据集  $D_c$  计算曲率向量。对每个子对角块进行共轭梯度迭代计算,当满足终止标准  $cg\_stop$  或者达到最大迭代次数  $C_g$  时,终止迭代过程。每个子块的网络权重参数优化过程可以并行进行,具体如下

$$\left\{ \begin{array}{l} \underset{\Delta w_{(1)}}{\text{argmin}} \Delta w_{(1)}^T \nabla_{(1)} \lambda + \frac{1}{2} \Delta w_{(1)}^T G_{(1)} \Delta w_{(1)} \\ \underset{\Delta w_{(2)}}{\text{argmin}} \Delta w_{(2)}^T \nabla_{(2)} \lambda + \frac{1}{2} \Delta w_{(2)}^T G_{(2)} \Delta w_{(2)} \\ \vdots \\ \underset{\Delta w_{(B)}}{\text{argmin}} \Delta w_{(B)}^T \nabla_{(B)} \lambda + \frac{1}{2} \Delta w_{(B)}^T G_{(B)} \Delta w_{(B)} \end{array} \right. \quad (9)$$

重复执行该过程  $l$  次,求得最终的网络权重参数更新值  $\Delta w$ 。求得每个子块的  $\Delta w \leftarrow (\Delta w_{(1)}; \Delta w_{(2)}; \dots; \Delta w_{(B)})$ , 将所有子块更新整合到一起,求得更新

的权重参数  $w \leftarrow w + \eta \Delta w$ 。

(5) 定义网络中有效权重参数的个数为

$$\gamma = m - 2\alpha \text{tr}(\mathbf{H}^{-1}) \quad (10)$$

其中  $\alpha = \frac{\gamma}{2E_w(W)} \quad (\gamma \in [0, m])$

式中  $H$ —网络输出的 Hessian 矩阵  
 $\beta$  定义如下

$$\beta = \frac{T - \gamma}{2E_b(W)} \quad (11)$$

每次更新权重参数后更新  $\alpha$  和  $\beta$  的值,并且使用更新后的  $\alpha$  和  $\beta$  重新计算误差函数。

(6) 重复执行上述过程。使用 Block-cg 算法最小化损失函数,从而更新网络权重参数,计算有效参数的个数  $\gamma$ , 利用更新后的权重参数更新超参数  $\alpha$  和  $\beta$ , 最终得到优化后的网络权重参数。

## 2 结果及分析

### 2.1 图像测试样本及参数设置

试验使用的 9 072 幅害虫图像全部来源于所建立的样本库。首先使用 Python 脚本语句对原始图像进行随机旋转角度、随机缩放原图、镜像等操作扩充样本数量至原来的 3 倍,然后分别从各类别中随机抽取 60% 图像样本构建训练集,20% 作为验证集,剩余 20% 作为测试集。测试样本具体信息及识别结果如表 1 所示。试验中,改进残差网络的深度为 28 层,超参数  $\alpha$  和  $\beta$  分别初始化为 0 和 1,学习速率  $\eta$  为 0.001; 使用 Block-cg 算法训练网络时,每个批次训练 64 幅图像,最大迭代次数为 2 000 次。

### 2.2 算法的有效性分析

为了验证本文方法的有效性,在本文数据集上,分别采用本文方法、贝叶斯神经网络方法<sup>[27]</sup> (Bayesian neural network)、卷积神经网络方法<sup>[28]</sup> (Convolutional neural network)、支持向量机<sup>[2]</sup> (Support vector machine, SVM) 进行害虫识别准确率比较。试验选取害虫图像的颜色直方图构造 SVM 的训练特征样本,核函数为高斯核函数。表 1 给出了不同方法下的 38 种害虫识别准确率。由表 1 可知,支持向量机方法下的害虫识别准确率较低;而卷积神经网络在小数据集上容易发生过拟合现象,因此在该方法下的害虫识别准确率也不高;文献[27]所提的贝叶斯神经网络方法与本文方法较为接近,但仍然低于本文方法的平均识别准确率。与上述 3 种方法相比,本文方法的平均识别准确率平均提高了 9.6 个百分点。

### 2.3 算法的鲁棒性分析

为了进一步验证本文所提方法的鲁棒性,针对

表1 38种害虫测试样本细节和不同方法下的害虫识别准确率

Tab.1 Details of 38 analyzed insect species and pest recognition rate by different methods

害虫样本序号	害虫名称	虫态	测试样本数量	害虫识别准确率/%		
				支持向量机	卷积神经网络	贝叶斯神经网络
1	大黑鳃金龟	成虫	85	79.0	82.3	86.0
		幼虫	62	75.3	76.8	89.3
2	铜绿丽金龟	成虫	57	78.8	82.2	84.4
		幼虫	64	75.4	79.8	85.0
3	杨叶甲	成虫	73	79.2	75.9	88.9
		幼虫	78	74.8	80.1	88.7
4	榆紫叶甲	成虫	72	75.3	82.5	87.6
		幼虫	86	78.0	76.4	88.4
5	柳蓝叶甲	成虫	83	76.1	78.3	85.6
		幼虫	51	78.2	81.9	86.9
6	二十八星瓢虫	成虫	73	79.1	76.5	86.1
		幼虫	68	78.2	79.5	89.9
7	光肩星天牛	成虫	67	76.4	81.7	84.7
		幼虫	72	78.6	78.3	87.4
8	大青叶蝉	成虫	80	75.2	81.4	87.9
		幼虫	84	78.9	76.5	84.1
9	榆三节叶蜂	成虫	76	76.8	82.7	87.0
		幼虫	87	77.6	82.2	86.5
10	烟角树蜂	成虫	131	78.5	84.3	87.8
11	杏毛球坚蚧	成虫	79	74.1	79.5	90.1
		幼虫	70	78.4	87.0	86.3
12	柳黑毛蚜	成虫	124	78.4	79.4	86.3
13	非洲蝼蛄	成虫	67	77.8	85.1	89.4
		幼虫	57	78.7	84.7	86.5
14	红天蛾	成虫	79	74.5	80.2	85.8
		幼虫	74	79.2	83.5	89.1
15	柳裳夜蛾	成虫	87	78.6	80.1	85.9
		幼虫	68	79.2	82.8	89.3
16	黄刺蛾	成虫	62	77.0	83.3	84.6
		幼虫	65	77.3	78.6	83.7
17	落叶松毛虫	成虫	75	79.8	79.5	84.3
		幼虫	78	75.2	80.7	86.7
18	天幕毛虫	成虫	59	75.9	78.3	84.8
		幼虫	72	76.8	84.6	88.3
19	折带黄毒蛾	成虫	65	78.0	75.9	86.7
		幼虫	56	79.5	81.1	87.1
20	舞毒蛾	成虫	81	76.1	83.5	88.2
		幼虫	72	75.3	76.9	84.7
21	春尺蠖	成虫	84	79.5	84.5	91.7
		幼虫	79	74.8	77.9	85.8
22	绢粉蝶	成虫	50	78.6	80.7	89.5
		幼虫	69	79.9	76.6	87.1
23	菜粉蝶	成虫	65	74.7	75.4	86.3
		幼虫	62	75.8	81.3	87.7
24	尖钩粉蝶	成虫	123	78.1	84.7	88.1
25	榆黄叶甲	成虫	51	75.3	79.1	86.2
		幼虫	54	76.0	85.5	85.8
26	中华萝卜肖叶甲	成虫	139	76.9	82.7	89.4
27	桃红颈天牛	成虫	51	79.0	83.2	87.5
		幼虫	90	75.6	79.9	85.0

续表 1

害虫样本序号	害虫名称	虫态	测试样本数量	害虫识别准确率/%			
				支持向量机	卷积神经网络	贝叶斯神经网络	本文方法
28	梨网蝽	成虫	141	77.3	80.3	87.6	92.3
29	绿盲蝽	成虫	84	74.7	81.2	89.7	88.5
		幼虫	77	79.2	82.3	88.5	92.6
30	草履蚧	成虫	137	77.4	80.8	87.7	93.5
31	桃蚜	成虫	88	75.6	81.6	87.5	90.3
		幼虫	60	78.7	77.3	89.6	88.7
32	杨二尾舟蛾	成虫	85	80.6	84.4	87.2	89.8
		幼虫	62	79.3	81.6	89.7	94.0
33	苜蓿夜蛾	成虫	84	77.2	85.0	87.9	93.6
		幼虫	70	76.7	79.8	88.3	91.1
34	苹果巢蛾	成虫	80	74.9	81.6	88.4	93.3
		幼虫	54	78.3	84.2	91.2	90.9
35	国槐尺蛾	成虫	85	77.4	82.2	85.4	91.9
		幼虫	73	79.7	78.9	84.8	93.7
36	金凤蝶	成虫	55	80.4	79.0	84.1	93.6
		幼虫	65	77.9	79.9	88.8	92.0
37	白钩蛱蝶	成虫	73	79.4	76.1	85.2	91.5
		幼虫	55	78.7	85.3	83.6	84.7
38	白矩朱蛱蝶	成虫	112	77.1	83.3	88.5	89.6
平均识别准确率/%				77.4	80.9	87.2	91.4

上述 4 种害虫识别方法,结合每个类别查准率  $p_i$ ,再计算其查全率  $r_i$  以及查全率与查准率的加权平均分数  $F_i$ ,最后取平均值  $F_a$  作为模型评价标准,对比结果如表 2 所示。

$$F_i = 2 \frac{p_i r_i}{p_i + r_i} \quad (12)$$

$$F_a = \frac{\sum_{i=1}^{n_c} F_i}{n_c} \quad (13)$$

$$\text{其中 } p_i = \frac{n_{ii}}{n_c} \times 100\% \quad r_i = \frac{n_{ii}}{\sum_{j=1}^{n_c} n_{ji}} \times 100\%$$

式中  $n_c$ —样本类别总数,取 38

$i$ —类别标签(1~38)

$n_{ii}$ —类别  $i$  预测为第  $i$  类的样本数

$n_{ji}$ —类别  $j$  预测为第  $i$  类的样本数

$n_{ij}$ —类别  $i$  预测为第  $j$  类的样本数

表 2 不同害虫识别方法的鲁棒性对比结果

Tab. 2 Robustness comparison of different pest identification methods

识别方法	平均查全率	加权平均分数
支持向量机	73.3	75.2
卷积神经网络	81.6	80.7
贝叶斯神经网络	87.7	87.0
本文方法	91.9	91.5

由表 2 可知,本文所提害虫识别方法在平均查全率和加权平均分数这两项指标上均获得了更好的

表现。与其他 3 种害虫识别方法相比,本文方法加权平均分数分别提高 16.3、10.8、4.5 个百分点,具有更强的鲁棒性。

## 2.4 北方园林害虫识别系统

基于本文方法,设计了对 38 种北方园林害虫识别的手机 APP 系统,如图 5 所示。该 APP 能够部分代替植保专家对园林害虫进行有效地自动化识别,以便及时做好防治工作。首先,利用智能手机在自然光环境下直接拍摄园林中的害虫生态图像。通过手机 APP 将待识别害虫图像读入自动识别系统,最



图 5 北方园林害虫识别 APP 系统图

Fig. 5 Diagram of northern garden pest identification APP

后使用本文算法对测试样本进行自动识别,给出识别结果与对应的害虫防治方法。

### 3 结束语

针对现有害虫图像识别方法存在的问题,提出了一种基于改进残差网络的害虫图像识别方法。该方法使用富边缘检测算法对害虫图像进行边缘检

测,将得到的害虫图像集用来训练残差神经网络,并通过 Block-cg 算法优化网络权重,进而更新超参数的值,直至得到理想的害虫分类准确率。试验结果表明,与其他 3 种传统害虫识别方法相比,本文方法的平均识别准确率平均提高 9.6 个百分点,加权平均分数分别提高 16.3、10.8、4.5 个百分点,具有较高的识别准确率及较强的鲁棒性。

### 参 考 文 献

- [1] LARIOS N, DENG H, ZHANG W, et al. Automated insect identification through concatenated histograms of local appearance features: feature vector generation and region detection for deformable objects [J]. *Machine Vision and Applications*, 2008, 19(2):105–123.
- [2] 胡玉霞,张红涛. 基于模拟退火算法-支持向量机的储粮害虫识别分类[J]. *农业机械学报*,2008,39(9):108–111.  
HU Yuxia, ZHANG Hongtao. Recognition of the stored-grain pests based on simulated annealing algorithm and support vector machine[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2008, 39(9): 108 – 111. (in Chinese)
- [3] ZHAO J, LIU M, YAO M. Study on image recognition of insect pest of sugarcane cotton aphid based on rough set and fuzzy C-means clustering [C] // Third International Symposium on Intelligent Information Technology Application. IEEE Computer Society, 2009:553–555.
- [4] ZHU L Q, ZHEN Z. Auto-classification of insect images based on color histogram and GLCM [C] // Seventh International Conference on Fuzzy Systems and Knowledge Discovery. IEEE, 2010: 2589–2593.
- [5] HAN Antai, PENG Hui, LI Jianfeng, et al. Recognition of pests based on compressive sensing theory [C] // 2011 IEEE 3rd International Conference on Communication Software and Networks (ICCSN), 2011: 263–266.
- [6] WEN Chenglu, DANIEL G. Image-based orchard insect automated identification and classification method[J]. *Computers and Electronics in Agriculture*, 2012, 89(1): 110 – 115.
- [7] 张建华,祁力钧,冀荣华,等. 基于粗糙集和 BP 神经网络的棉花病害识别[J]. *农业工程学报*,2012,28(7):161–167.  
ZHANG Jianhua, QI Lijun, JI Ronghua, et al. Cotton diseases identification based on rough sets and BP neural network [J]. *Transactions of the CSAE*, 2012, 28(7): 161 – 167. (in Chinese)
- [8] 邹修国,丁为民,刘德营,等. 基于 4 种不变矩和 BP 神经网络的稻飞虱分类[J]. *农业工程学报*,2013,29(18): 171–178.  
ZOU Xiuguo, DING Weimin, LIU Deying, et al. Classification of rice planthopper based on invariant moments and BP neural network [J]. *Transactions of the CSAE*, 2013, 29(18): 171 – 178. (in Chinese)
- [9] FAITHPRAISE F, BIRCH P, YOUNG R, et al. Automatic plant pest detection and recognition using K-means clustering algorithm and correspondence filters[J]. *International Journal of Advanced Biotechnology & Research*, 2013, 4(2):189 – 199.
- [10] 贾建楠,吉海彦. 基于病斑形状和神经网络的黄瓜病害识别[J]. *农业工程学报*,2013,29(增刊1):115–121.  
JIA Jiannan, JI Haiyan. Recognition for cucumber disease based on leaf spot shape and neural network [J]. *Transactions of the CSAE*, 2013, 29(Supp. 1): 115 – 121. (in Chinese)
- [11] 李文勇,李明,陈梅香,等. 基于机器视觉的作物多姿态害虫特征提取与分类方法[J]. *农业工程学报*,2014,30(14): 154 – 162.  
LI Wenyong, LI Ming, CHEN Meixiang, et al. Feature extraction and classification method of multi-pose pests using machine vision[J]. *Transactions of the CSAE*, 2014, 30(14): 154 – 162. (in Chinese)
- [12] SIVIC J, ZISSERMAN A. Video google: a text retrieval approach to object matching in videos [C] // IEEE Computer Society. IEEE International Conference on Computer Vision, 2003: 1470 – 1477.
- [13] VENUGOBAN K, RAMANAN A. Image classification of paddy field insect pests using gradient-based features [J]. *International Journal of Machine Learning & Computing*, 2014, 4(1): 1 – 5.
- [14] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection [C] // IEEE Computer Society Conference on Computer Vision & Pattern Recognition. IEEE Computer Society, 2005:886 – 893.
- [15] BAY H, TUYTELAARS T, GOOL L V. SURF: speeded up robust features[C] // European Conference on Computer Vision. Springer-Verlag, 2006:404 – 417.
- [16] 谢成军,李瑞,董伟,等. 基于稀疏编码金字塔模型的农田害虫图像识别[J]. *农业工程学报*,2016,32(17):144–151.  
XIE Chengjun, LI Rui, DONG Wei, et al. Recognition for insects via spatial pyramid model using sparse coding [J]. *Transactions of the CSAE*, 2016, 32(17): 144 – 151. (in Chinese)
- [17] XIE C, ZHANG J, LI R, et al. Automatic classification for field crop insects via multiple-task sparse representation and multiple-kernel learning [J]. *Computers and Electronics in Agriculture*, 2015, 119:123 – 132.
- [18] 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.  
SUN Jun, TAN Wenjun, MAO Hanping, et al. Recognition of multiple plant leaf diseases based on improved convolutional neural network [J]. *Transactions of the CSAE*, 2017, 33(19): 209 – 215. (in Chinese)
- [19] 刘德营,王家亮,林相泽,等. 基于卷积神经网络的白背飞虱自动识别方法研究[J/OL]. *农业机械学报*,2018,49(5):

- 51–56.
- LIU Deying, WANG Jialiang, LIN Xiangze, et al. Automatic identification method for *Sogatella furcifera* based on convolutional neural network [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(5): 51–56. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=20180506&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20180506&journal_id=jcsam). DOI: 10.6041/j.issn.1000-1298.2018.05.006. (in Chinese)
- [20] HAFIZ G, QAISAR A, FATIMA G. Insect classification using image processing and Bayesian network [J]. Journal of Entomology and Zoology Studies, 2017, 5(6): 1079–1082.
- [21] 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.
- YANG Guoguo, BAO Yidan, LIU Ziyi. Localization and recognition of pests in tea plantation based on image saliency analysis and convolutional neural network [J]. Transactions of the CSAE, 2017, 33(6): 156–162. (in Chinese)
- [22] ROTHER C, KOLMOGOROV V, BLAKE A. GrabCut: interactive foreground extraction using iterated graph cuts [J]. ACM Transactions on Graphics (TOG), 2004, 23(3): 309–314.
- [23] 肖志云, 刘洪. 小波域马铃薯典型虫害图像特征选择与识别 [J/OL]. 农业机械学报, 2017, 48(9): 24–31.
- XIAO Zhiyun, LIU Hong. Features selection and recognition of potato typical insect pest images in wavelet domain [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(9): 24–31. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=20170903&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20170903&journal_id=jcsam). DOI: 10.6041/j.issn.1000-1298.2017.09.003. (in Chinese)
- [24] 潘春华, 肖德琴, 林探宇, 等. 基于 SVM 和区域生长结合算法的南方主要蔬菜害虫分类识别 [J]. 农业工程学报, 2018, 34(8): 192–199.
- PAN Chunhua, XIAO Deqin, LIN Tanyu, et al. Classification and recognition for major vegetable pests in Southern China using SVM and region growing algorithm [J]. Transactions of the CSAE, 2018, 34(8): 192–199. (in Chinese)
- [25] 田晔, 秦运宏, 纪艳, 等. 佳木斯市双拥公园主要害虫种类及其综合防治 [J]. 生物灾害科学, 2017, 40(2): 108–111
- TIAN Ye, QIN Yunhong, JI Yan, et al. Main pests at Shuangyong Park in Jiamusi City and comprehensive prevention [J]. Biological Disaster Science, 2017, 40(2): 108–111 (in Chinese)
- [26] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770–778.
- [27] MACKAY D J C. A practical Bayesian framework for backpropagation networks [J]. Neural Computation, 2014, 4(3): 448–472.
- [28] 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 CSAE, 2018, 34(12): 186–192. (in Chinese)

(上接第 103 页)

- [22] MUNDO C, SOMMERFELD M, TROPEA C. Droplet-wall collisions: experimental studies of the deformation and breakup process [J]. International Journal of Multiphase Flow, 1995, 21(2): 151–173.
- [23] FORSTER W A, MERCER G. Process-driven models for spray droplet shatter, adhesion or bounce [C] // 9th International Symposium on Adjuvants for Agrochemicals, The Netherlands, 2010.
- [24] 张文君. 农药雾滴雾化与在玉米植株上的沉积特性研究 [D]. 北京: 中国农业大学, 2014.
- ZHANG Wenjun. The study of pesticide droplets atomization and deposit characteristics in corn leaves [D]. Beijing: China Agricultural University, 2014. (in Chinese)
- [25] 王双双. 雾化过程与棉花冠层结构对雾滴沉积的影响 [D]. 北京: 中国农业大学, 2015.
- WANG Shuangshuang. Studying the influence of spray atomization process and cotton canopy structure on the droplet deposition [D]. Beijing: China Agricultural University, 2015. (in Chinese)
- [26] DORR G J, FORSTER W A, MAYO L C, et al. Spray retention on whole plants: modelling, simulations and experiments [J]. Crop Protection, 2016, 88: 118–130.
- [27] 丁维龙, 金梦杰, 罗临风, 等. 基于虚拟模型的雾滴与叶片的交互行为分析 [J]. 农业工程学报, 2017, 33(14): 40–48.
- DING Weilong, JIN Mengjie, LUO Linfeng, et al. Behavior analysis of spray droplet interacting with plant leaves based on virtual model [J]. Transactions of the CSAE, 2017, 33(14): 40–48. (in Chinese)
- [28] MASSINON M, LEBEAU F. Review of physicochemical processes involved in agrochemical spray retention [J]. Biotechnologie Agronomie, Société et Environnement, 2013, 17(3): 494–504.
- [29] 黄晓敏, 冯花, 郭雅玲. 茶树叶片显微结构及扫描电镜研究进展 [J]. 福建茶叶, 2011, 33(5): 2–4.
- HUANG Xiaomin, FENG Hua, GUO Yaling. Advances in microstructure and scanning electron microscopy of tea leaves [J]. Tea in Fujian, 2011, 33(5): 2–4. (in Chinese)