

文章编号: 1674-8085(2019)02-0031-08

基于深度卷积神经网络的水稻病害图像识别研究

谭云兰^{1,2}, 欧阳春娟^{1,2}, 李龙¹, 廖婷¹, *汤鹏杰³

(1. 井冈山大学电子与信息工程学院, 江西, 吉安 343009; 2. 井冈山大学流域生态与地理环境监测国家测绘地理信息局重点实验室, 江西, 吉安 343009; 3. 井冈山大学数理学院, 江西, 吉安 343009)

摘 要: 水稻病害类型多, 采集过来的图像病斑交界特征复杂多变。即便同类别水稻病害在不同的生长时期, 发生在叶片、茎秆、穗部等部位呈现的病斑特征也不一样, 而且不同类型病害也存在相似病斑, 这些都给水稻病害图像的精准识别带来了相当大的困难。采用深度卷积神经网络模型, 使用数据集扩增技术, 运用 fine-tune 方法对网络进行调参及构建, 将自然场景下采集的常见 8 类水稻病害图像输入网络模型中进行训练和测试, 在有限的图像数量下取得较高的识别精度, 其中纹枯病的准确率为 93%。不同于其他方法仅聚焦在水稻叶部或稻穗部, 本文识别的图像是多株水稻的场景, 可为水稻病害远程自动诊断提供关键技术支持。

关键词: 图像识别; 卷积神经网络; 水稻病害; GoogLeNet

中图分类号: TP391

文献标识码: A

DOI:10.3969/j.issn.1674-8085.2019.02.007

IMAGE RECOGNITION OF RICE DISEASES BASED ON DEEP CONVOLUTIONAL NEURAL NETWORK

TAN Yun-lan^{1,2}, OUYANG Chun-juan^{1,2}, LI Long¹, LIAO Ting¹, *TANG Peng-jie³

(1. School of Electronic Information and Engineering, Jinggangshan University, Ji'an, Jiangxi 343009, China; 2. Key laboratory of watershed ecology and geographical environment monitoring, National Administration of Surveying, Mapping and Geoinformation, Ji'an, Jiangxi 343009, China; 3. School of Mathematical and Physical Science, Jinggangshan University, Ji'an, Jiangxi 343009, China)

Abstract: There are many types of rice diseases, and the corresponding disease spot features of the collected images are complex and illegible. The reason is that the characteristics of the lesions occurring in leaves, stems, panicles and other parts are different at different growth stages of the same kind of rice diseases, while there are similar lesions in different types of diseases, which bring great difficulties to the accurate recognition of rice disease images. The purpose of this paper is to recognize the typical rice disease. Based on the deep learning technique, the recognition method for eight rice diseases is put forward. Firstly, the rice disease database of 1260 images is established. Secondly, based on the Caffe deep learning platform, the deep convolution neural network model is constructed through fine-tuning. Finally, eight kinds of common rice diseases images by data augmentation, which are collected in natural scenes, are input into the network model for training and testing. The experimental results show that the proposed method can effectively identify main rice diseases. The recognition

收稿日期: 2018-09-10; 修改日期: 2018-12-03

基金项目: 国家自然科学基金项目(61462046), 流域生态与地理环境监测国家测绘地理信息局重点实验室招标项目(WE2016015), 江西省教育厅科学技术研究项目(GJJ160750, GJJ170632, GJJ170643), 江西省高校人文社会科学重点研究基地招标项目(JD17082), 井冈山大学博士科研启动项目(JZB1807)

作者简介: 谭云兰(1972-), 女, 江西新干人, 副教授, 博士, CCF 会员, 主要从事虚拟现实、图像处理等方面的研究(E-mail: tanyunlan@163.com); 欧阳春娟(1974-), 女, 江西吉安人, 副教授, 博士, 主要从事信息隐藏、智能优化及图像处理等方面的研究(E-mail: oycj001@163.com); 李 龙(1998-), 男, 江西赣州人, 井冈山大学电子与信息工程学院 2016 级计算机专业本科生(E-mail: imcoding@foxmail.com); 廖 婷(1998-), 女, 江西赣州人, 井冈山大学电子与信息工程学院 2016 级网络工程专业本科生(E-mail: 2632922126@qq.com); *汤鹏杰(1983-), 男, 河南郸城人, 讲师, 在读博士生, 主要从事计算机视觉、深度学习等方面的研究(E-mail: 5tangpengjie@tongji.edu.cn).

accuracy of rice sheath blight is 93% under limited images. Unlike other methods which focus only on rice leaves or panicles, the proposed method in this paper can recognized the multi-plant rice scene image. The proposed method can offer a technical support for remote automatic diagnosis of rice diseases.

Key words: image recognition; convolutional neural network; rice pests images; GoogLeNet

0 引言

水稻是大田农作物,具有种植面积广、病害疫情早期发现难的特点,对水稻病害的自动化远程诊断就显得十分必要,而自动准确地识别出不同水稻病害类别图像是十分关键的技术。目前在水稻病害识别方面,大部分研究都聚焦在单株水稻病害的叶片或者株穗部位,有采用基于贝叶斯分类器、SVM分类器等传统方法的,也有采用深度学习模型进行水稻病害图像的分类研究。刘涛等人^[1]聚焦水稻叶部位置的15种主要病害,对采集过来的图像进行病斑分割,手工提取特征,再输入二分类SVM分类器,采用一对一的投票策略实现水稻病害图像的多分类问题。但这种方式需要设计 $105(k*(k-1)/2)$ 个SVM,因此总训练时间和测试时间相对较长,速度较慢。杨昕薇等人^[2]采用贝叶斯分类器开展了水稻病害稻瘟病、纹枯病和白叶枯病进行识别与分类,也仅仅是聚焦于水稻单株的叶片部位,对于其他叶部病害及相似病斑未进行区分。刘成^[3]采用机器学习的方法开展水稻病害识别算法的研究,该研究只是针对水稻病害稻曲病的染病和无病两种状态的图像进行了分类识别。黄双萍等人^[4]采用深度学习模型对高光谱穗株图像识别,研究的是水稻抽穗时期的病害。该研究对象仅限于单穗株的枝梗、穗主轴和穗颈基部等局部位置,对采集过来的高光谱图像还要去复杂背景,识别的内容也仅仅是染病和不染病的二分类,不能识别出具体的水稻病害类型。

对于自然场景下采集过来的水稻病害图像,更

多是多株水稻的场景,场景中包括了水稻叶部、茎秆、穗部等部位,水稻病害类型多,病斑交界特征复杂多变,即便是水稻专家进行人工识别也容易误判,原因是同类别水稻病害在不同的生长时期,发生在叶片、茎秆、穗部等部位呈现的病斑特征也不一样,而且不同类型病害也存在相似病斑,这些都给水稻病害图像的精准识别带来了巨大的困难。水稻病害图像中不同病害类型的病斑特征相似度高,区分难度大,传统方法识别图像存在特征变换层次不够、抽象及表达能力不强、识别精度低等问题。本文采用深度卷积神经网络模型,使用数据集扩增(Data augmentation)技术,运用fine-tune方法对网络进行调参及构建,将自然场景下的8类水稻病害图像输入网络模型中进行训练,取得较好的识别精度。

1 水稻病害图像库构建

1.1 常见8类水稻病害特征

从幼苗到抽穗时期,水稻病害发病部位发生在叶片、茎秆、穗部,在不同的生长时期,发病部位不同,呈现的病斑特征也不一样,因此水稻病害类型较多。本论文根据水稻病害防治图谱^[5],选出稻瘟病、纹枯病、胡麻叶斑病、小球菌核病、恶苗病、霜霉病、稻曲病和叶鞘腐败病等8类常见的水稻病害的特征描述作为研究对象,构建水稻病害特征库,其特征如表1所示,这些特征描述可为深度学习网络模型对水稻病害图像识别的准确度提供主观判别的视觉依据。

表 1 水稻病害特征描述
Table 1 The features description about 8 kinds of rice diseases

序号	病虫害图像类型	病斑特征描述
1	稻曲病	该病只发生于穗部，受害谷粒呈近球形淡黄色块状物，造成谷粒发病形成稻曲。
2	稻瘟病	主要为害叶片、茎秆、穗部。因为害时期、部位不同分为苗瘟、叶瘟、节瘟、穗颈瘟、谷粒瘟。病苗基部灰黑，开始在叶上产生暗绿色小斑，渐扩大为梭菜斑，上部变褐，卷缩而死。
3	恶苗病	节间明显伸长，节部常有弯曲露于叶鞘外，下部茎节逆生多数不定须根，分蘖少或不分蘖。剥开叶鞘，茎秆上有暗褐条斑，剖开病茎可见白色蛛丝状菌丝，以后植株逐渐枯死。
4	胡麻叶斑病	叶鞘上染病，病斑初椭圆形，暗褐色，边缘淡褐色，水渍状，后变为中心灰褐色的不规则大斑。穗颈和枝梗发病，受害部暗褐色，造成穗枯。谷粒染病早期受害的谷粒灰黑色扩至全粒造成秕谷，后期受害病斑小，边缘不明显。
5	霜霉病	叶片上发病初生黄白小斑点，后形成表面不规则条纹，斑驳花叶。病株心叶淡黄，卷曲，不易抽出，下部老叶渐枯死，根系发育不良，植株矮缩。
6	纹枯病	病斑最初在近水面的叶鞘上出现，初为椭圆形，水渍状，后呈灰绿色或淡褐色逐渐向植株上部扩展，病斑常相互合并为不规则形状，病斑边缘灰褐色，中央灰白色。
7	小球菌核病	小球菌核病和小黑菌核病症状相似，侵害稻株下部叶鞘和茎秆，初在近水面叶鞘生上褐色小斑，后扩展为黑色纵向坏死线及黑色大斑，上生稀薄浅灰色霉层，病鞘内常有菌丝块。
8	叶鞘腐败病	孕穗至抽穗期染病，剑叶叶鞘先发病且受害严重，在叶鞘或叶上的静脉上，主针大小为深棕色点，上下形成菱形深棕色斑点，边缘浅棕色。

1.2 水稻病斑图像数据库构建

深度学习网络模型模仿人脑从低级到高级抽象图像特征的前提是基于大规模图像集，由于没有现成的水稻病害图像库可用使用，因此需要自建病斑图像库用于DCNN（Deep Convolutional Neural Network）模型识别图像。本论文根据水稻病害图谱分类，编写爬虫软件在百度、Google、360等权

威图库中按照常见的水稻病害类别下载稻瘟病、纹枯病、胡麻叶斑病、小球菌核病、恶苗病、霜霉病、稻曲病、叶鞘腐败病等8种常见的水稻病害病斑图像。经过数据清洗，得到有效图像共计1262张，构建了水稻病斑图像数据库，各类病斑图像数量分布如表2所示。

表 2 各类水稻病害图像分布
Table 2 Image numbers of 8 kinds of rice disease

病害类别	稻曲病	稻瘟病	纹枯病	胡麻叶斑病	小球菌核病	恶苗病	霜霉病	叶鞘腐败病
数量（张）	174	152	127	141	132	283	113	140

2 水稻病害图像识别模型构建与分析

2.1 水稻病害图像识别模型结构




图1 水稻病害识别深度学习识别流程

Fig.1 The process for rice disease recognition based on deep learning model

图1的网络模型是由24层卷积层,多个Inception结构串联和2个辅助损失层构成图像美学质量评估分类器^[6]。为了便于统一网络模型的输入,首先从水稻病害图像库中取出样本图像,运用线性插值方法将图像缩小到256×256大小。受Lu Xin^[7]所提出的多图像块可以提高图像识别精度思想的启发,使用了多裁剪图像块,按照224×224大小截取图像中左上角、右上角、左下角、右下角和中间部分图像块,然后将截取后的图像块进行水平翻转,总共有10张子图像块输入到卷积网络模型的第一卷积层,达到数据集扩增效果。第一卷积层使用的卷积核大小为7×7,步长为2,一共设置了64个卷积核,生成64幅特征图;第一卷积层之后连接的是最大池化层(max-pooling),在卷积层输出基础上用64个大小为3×3的滤波核来降低学习特征的维数,并使池化后的特征表达具有一定的平移不变性,在平均意义上,与mean-pooling近似,在局部意义上,则服从max-pooling的准则。pooling的结果是使得特征减少,参数减少,pooling目的是为了保持某种不变性(旋转、平移、伸缩等);在进行ReLU非线性激活之后,接下来是归一化层Local Response Normalization(LRN),归一化处理是为了提高模型的泛化能力;之后的第二、第三卷积层直接相连,

之间没有池化层和归一化层。其中第二卷积层使用了64个卷积核,大小为1×1,步长为1。第三卷积层使用了192个卷积核,大小为3×3,步长为1;接下来在归一化层和池化层之后,设计了9个Inception模块,这些模块能够增加网络的宽度,也能降低feature map的厚度;网络的层数更深,更易出现梯度消失问题。为了解决梯度消失问题,模型在不同深度处增加了两个辅助性的classifiers来保证梯度回传消失;在Inception模块操作之后,经过平均池化,降低特征维度。最后是一个1024个神经元的全连接层和一个8输出的softmax函数。softmax函数产生8个水稻病害类别的概率值(0~1),本文使用Top-1错误率,即将网络输出8个概率值中最高值映射为1,表示网络将测试图像识别为该类别,其余7个概率值映射为0,表示该测试图像不属于这些类别。最终测试值和真值(Ground-truth)进行比较,可判别网络图像识别是否准确。

2.2 网络模型反馈传播学习机制

DCNN的梯度反向传播过程中,第 l 层的梯度定义如式(1)所示:

$$\begin{cases} y_l = \omega_l x_l + b_l \\ x_l = f(y_{l-1}) \\ \Delta y_l = f'(y_l) \Delta x_{l+1} \end{cases} \quad (1)$$

其中 ω_l 第 l 层的滤波权值参数, b_l 是 l 层的偏置, y_l 是第 l 层输出特征图像, $f(\cdot)$ 是激活函数, f' 是 f 的梯度。权值 ω_l 和偏置 b_l 的更新如式(2)、式(3)所示:

$$\begin{cases} \mu_l^{i+1} = \alpha \cdot \mu_l^i - \lambda \cdot \eta \cdot \omega_l^i - \eta \cdot \left[\frac{\partial L}{\partial \omega_l} \right]_{D_i} \\ \omega_l^{i+1} = \omega_l^i + \mu_l^{i+1} \end{cases} \quad (2)$$

$$\begin{cases} \mu_l^{i+1} = \alpha \cdot \mu_l^i - \lambda \cdot \eta \cdot \omega_l^i - \eta \cdot \left[\frac{\partial L}{\partial b_l} \right]_{D_i} \\ b_l^{i+1} = b_l^i + \mu_l^{i+1} \end{cases} \quad (3)$$

其中 μ 为动量变量, α 是动量因子, λ 是权重延时weight decay, η 为学习率。 $\left[\frac{\partial L}{\partial \omega_l} \right]_{D_i}$ 是目标函数 L 对 ω 在第 i 次迭代下批量样本 D_i 的平均梯度。在目标函数最小值附近的时候,由于曲率较小,梯度的变化会变得很小,特别是在深度网络中,最后一层的梯度经过反向传播算法传递到前面几层时梯度会变得非常小,导致随机梯度下降法收敛得很慢。梯

度下降是更新整体样本,随机梯度下降是更新一个样本,而批量随机梯度下降法(MSGD-stochastic gradient method with mini-batches),则是介于两者之间,更新一部分样本。为了加快算法的收敛过程,使得随机梯度下降跳出局部最优,对于目标函数 $L(w)$,采用上述Momentum动量方法。本实验中,我们发现权重延时weight decay较小时能够减少模型训练错误,因此设置 $\alpha=0.9$, $\lambda=0.0005$, 样本批量batch size=16。

在学习率策略中,本文选择多项式曲线下降方法,公式如式(4)所示:

$$\eta_t = LR(t) = base_lr \times (1 - \frac{t}{T})^{power} \quad (4)$$

其中 $base_lr = 0.0$, $power = 0.5$, t 是当前迭代次数, T 是最大迭代次数。

2.3 防止过拟合技术

深度CNN网络模型参数众多,其拟合函数具有高度的非凸性,随着模型训练的进行,模型的复杂度会增加,此时模型在训练数据集上的训练误差会逐渐减小,当模型的复杂度达到一定程度时,测试集上的误差反而随着模型的复杂度增加而增大。也就是网络模型在训练的时候误差很小,但在测试的时候误差很大,这就是过拟合现象,这种模型泛化能力不强。为了提高深度网络的泛化能力,本文引入数据集扩增(Data augmentation)、Dropout、正则化(Regularization)等技术。数据扩增技术,就是对图像样本 X_i ,它被剪切成 K 个图像块,构成一个图像块数据袋 $Xp_i = \{Xp_{ij}\}_{j \in [1,K]}$, $K=10$,这样每张图像共得到40个图像块,整个训练集扩增为原来的40倍。在训练阶段的全连接层引入Dropout技术,Dropout技术的主要思想是指在网络的全连接层,每次深度网络前向传播过程中以一定比例随机地将一些隐藏节点置0,这些节点在本次迭代中不工作,在反向传播时也不去更新这部分节点的权值。在下次迭代中再按相同比例随机设置一些节点不工作,误差反向传播时也不更新。通过设定一个参数来保证每次迭代中不工作节点的比例,这个参数就是Dropout率。这个Dropout技术从生物角度解释,网络类似性别在生物进化中所扮演的角色,物种为了适应不断变化的环境从而出现了性别的差异^[8]。另

外一种防止模型过拟合,提高模型泛化能力的技术就是即在对模型的目标函数(objective function)或代价函数(cost function)加上正则项。正则项是为了降低模型的复杂度,从而避免模型区分过拟合训练数据,包括噪声与异常点(outliers)。从另一个角度上来讲,正则化即是假设模型参数服从先验概率,即为模型参数添加先验,只是不同的正则化方式的先验分布是不一样的。这样就规定了参数的分布,使得模型的复杂度降低,这样模型对于噪声与异常点的抗干扰性的能力增强,从而提高模型的泛化能力。

3 实验设计方案与结果分析

3.1 水稻病害图像识别实验设置

在深度学习模型的选择上,对于LeNet^[9], AlexNet^[10]等卷积层次较浅层的深度学习网络模型,我们在前期选择过这些模型做过实验,但识别精度只有40%多,识别效果不好,因此来进一步实验。对于VGGNet超深度网络模型,拥有19层卷积层的VGG19模型^[11]的神经元个数为14860K,参数规模为144M,而GoogLeNet模型的神经元个数为5500K(是VGG19的37%),参数规模为6.8M(是VGG19的4.7%),可以看出,深度GoogLeNet模型的连接数远少于VGG19,因此我们选择GoogLeNet模型作为水稻病害图像的识别器。为了减少构建DCNN网络模型的时间,我们使用预训练模型GoogLeNet_place205_train_iter_2400000.caffemodel,也就是这个预训练GoogLeNet网络模型在其它任务数据集完成训练和测试,网络模型之间的连接权重是已经得到较好的初始化。在训练过程中,为了得到较好的分类精度,采用fine-tune方法微调和优化深度学习的参数,使用随机梯度下降的方式更新网络参数,Batch_Size设置为16,学习率初始设置为0.01,学习动量为0.9。为了降低过拟合overfitting,权重衰减weight decay值为0.0005,在全连接层dropout设置为0.5或0.6。实验环境为2块型号为GTXTitan-X的GPU,操作系统为Ubuntu 14.04,以及Caffe平台,工具软件为Matlab 2013a, GPU并行计算带OpenCV3.0的C++。



3.2 实验测试结果分析

3.2.1 水稻病斑图像深度特征提取

为了观察深度网络对水稻病斑特征的提取，我们提取了DCNN网络8类图像的卷积层第一层的特征图，如表3所示。从表3中可以看出，对于稻曲病、恶苗病、胡麻叶斑病、纹枯病等水稻病害图像，由于这些病害病斑交界特征明显，因此抽取的显著特

征提取还是比较准确。表1中各类水稻病害特征描述为深度学习网络模型特征提取提供了主观判别的视觉依据。相比之下，对稻瘟病、霜霉病、叶鞘腐病、小球菌核病等病斑特征的提取，还不够精确，原因是这些水稻病害的病斑边界分布不明显。

表 3 水稻病害图像原图及第一层卷积层提取的特征图
Table 3 The original image of rice disease and the feature map extracted from the first convolution layer

类别	第 1 类稻曲病	第 2 类稻瘟病	第 3 类恶苗病	第 4 类胡麻叶斑病
水稻病害 原图				
卷积层特 征图				
类别	第 5 类霜霉病	第 6 类纹枯病	第 7 类小球菌核病	第 8 类叶鞘腐败病
水稻病害 原图				
卷积层特 征图				

3.2.2 不同的实验方案测试

1) 实验方案一的测试及结果

为了测试GoogLeNet深度学习网络模型对水稻病害图像的识别精度，先随机从8个不同水稻病害图像类别中选出887张图像进行实验，其中720张用于训练，167张用于测试，GoogLeNet模型最终迭代

6000次收敛。为了验证所选用的深度卷积神经网络模型能取得更好的水稻病害图像识别性能，选择了ResNet-152深度模型^[12]，用与GoogLeNet模型相同的图像数进行训练和测试，模型迭代5900次收敛。实验结果如表4所示。

表 4 训练数=720，测试数=167 时的识别精度
Table 4 Recognition accuracy when training number = 720 and test number = 167

序号	病虫害类型	训练数	测试数	GoogLeNet 模型 准确率	ResNet 模型 准确率
1	稻曲病	84	21	0.84	0.74
2	稻瘟病	90	20	0.70	0.69
3	恶苗病	72	18	0.67	0.55
4	胡麻叶斑病	90	21	0.71	0.66
5	霜霉病	75	18	0.39	0.32
6	纹枯病	153	30	0.81	0.72
7	小球菌核病	81	19	0.44	0.38
8	叶鞘腐败病	75	20	0.63	0.54

2) 实验方案二的测试及结果

为了测试在模型中增加图像后对识别精度的影响，本次实验选择水稻病害图像库所有1262张图像用于实验，其中1039张图像用于训练网络，223

张图像用于测试。最终迭代次数：GoogLeNet网络模型迭代11000次，ResNet网络模型迭代10000次。实验结果如表5所示。

表 5 训练数=1039，测试数=223 时的识别精度
Table 5 Recognition accuracy when training number = 1039 and test number = 223

序号	病虫害类型	训练数	测试数	准确率 Google	准确率 ResNet
1	稻曲病	144	30	0.85	0.80
2	稻瘟病	126	26	0.65	0.54
3	恶苗病	103	24	0.83	0.83
4	胡麻叶斑病	117	24	0.83	0.83
5	霜霉病	108	24	0.54	0.58
6	纹枯病	243	40	0.93	0.80
7	小球菌核病	90	23	0.70	0.74
8	叶鞘腐败病	108	32	0.60	0.59

3.2.3 结果分析

从表4和表5中可以看出，图像的数量会影响深度学习网络模型的识别精度，当用887张水稻病害图像用于网络训练和测试时，GoogLeNet网络模型的平均精度为65%，ResNet为58%；当水稻病害图像增加到1262张用于网络训练和测试时，GoogLeNet深度网络模型的平均准确率达到74%，ResNet为71%。

从表5可以看出，GoogLeNet深度网络模型在8类水稻病害图像中，识别精度最高的是纹枯病图像类，精度为93%。由于纹枯病的病斑边缘灰褐色、中央灰白色，整体为椭圆形、水渍状，这种病斑特征成像时不容易被遮挡，植株整体成像后病斑明

显，因此识别率很高。精度比较高还有85%的稻曲病，由于该病只发生在穗部，病斑特征为受害谷粒呈近球形淡黄色后者黑色块状物，特征也非常明显。此外还有83%的恶苗病和胡麻叶斑病两种类别，恶苗病的病斑特征是节间明显伸长，节部常有弯曲露于叶鞘外，下部茎节逆生多数不定须根，胡麻叶斑病类型的叶面上病斑呈椭圆形麻点型，而这些特征也容易被深度学习网络抽取和识别。表5中识别精度最低的是霜霉病，识别精度只为54%。由于该病的病株初期的叶片生出黄白小斑点，后期病株心叶淡黄卷曲，下部老叶渐枯死，根系发育不良，植株矮缩，因此从图像的角度来看植株的这些病斑特征不明显，深度学习网络也难以抽取有效的特

征来区分出这类水稻病害。表5中识别精度为60%的叶鞘腐败病,之所以精度不高是因为这类病害图像特征是在叶鞘或叶上的静脉上,病斑点很细小,容易被正常植株遮挡。

另外一种深度网络模型ResNet-152识别精度与GoogLeNet深度网络在不同水稻病害类别识别上一致,但均整体要偏低一些。对于稻曲病、恶苗病、胡麻叶斑病、纹枯病等四类水稻病害图像识别上均高于80%,而稻瘟病、霜霉病、叶鞘腐败病等三类病害图像识别上均低于60%。在实验初期我们也挑选了深度较浅的网络模型Alex-Net,相比之下,GoogLeNet深度网络更适合做水稻病害多类别图像的识别。

由于我们在实验中使用的是Top-1错误率,这种错误率比起Top-5来说,更能衡量深度学习网络模型的图像识别精度。本实验中,Top-1错误率是指8个水稻病害图像识别的概率值输出中,即将网络输出的8个概率值中最高值映射为1,表示深度学习网络将输入图像识别为该类别,其余7个概率值映射为0,表示该输入图像不属于这些类别。而Top-5错误率是指如果概率前五中包含正确答案,即认为正确,因此我们认为Top-1错误率更严格。对于GoogLeNet深度网络模型,在病斑图像1200多张的情况下,也能自动区分出8类水稻病害图像。该类网络模型对于水稻病害边缘模糊的图像自动提取的特征更加抽象、语义及结构信息更加丰富,对图像具有更强的表达能力及识别性。

4 结论

对于超深度学习模型,本文使用的深度网络模型,由于已经在百万级大型图像数据集上进行了训练和测试,因而网络模型的参数和层次比较稳定,可以减少模型重新训练时间。将模型学习得到的图像分类的共性知识迁移到水稻病害图像识别中,采用不同数量的水稻病害图像进行组合实验,在有限的图像数据集下经过数据集扩增(Data augmentation)技术,运用fine-tune方法得到较高的水稻病害多类别的识别精度,避免了人工特征抽取的时间消耗,从而大大提高了在线计算效率,可为水稻病害远程自动诊断提供关键技术支持。由于水稻病害的大面

积患病的自然场景不易采集,也没有大规模现成的水稻病害图像数据库,本论文通过爬虫程序到百度、Google、360等权威图库爬取得到有效的图像只有1262张,对于超深度网络模型来说,这些数量还是不够,因而也影响了多类别的图像识别精度。今后将加强水稻病害图像的收集,改进深度学习模型的结构,提升水稻病害图像的识别精度。

参考文献:

- [1] 刘涛,仲晓春,孙成明,等. 基于计算机视觉的水稻叶部病害识别研究[J]. 中国农业科学,2014,47(4):664-674.
- [2] 杨昕薇,谭峰. 基于贝叶斯分类器的水稻病害识别处理的研究[J]. 黑龙江八一农垦大学学报,2012,24(3):64-67.
- [3] 刘成. 基于机器学习的水稻病害识别算法的研究[D]. 合肥:安徽大学,2018.
- [4] 黄双萍,孙超,齐龙,等. 基于深度卷积神经网络的水稻穗瘟病检测方法[J]. 农业工程学报,2017,33(20):169-176.
- [5] 孙恢鸿. 水稻病害防治图谱[M]. 南宁:广西科学技术出版社,2004.
- [6] Lin M, Chen Q, Yan S. Network in network[J]. arXiv preprint arXiv:1312.4400 [cs.NE],2013.
- [7] Lu X, Lin Z, Shen X, et al. Deep Multi-Patch Aggregation Network for Image Style, Aesthetics, and Quality Estimation[C]. Proceedings of the IEEE International Conference on Computer Vision. 2015: 990-998.
- [8] 杨强鹏. 深度学习算法研究[D]. 南京:南京大学,2015.
- [9] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [10] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[C]. Advances in neural information processing systems. 2012: 1097-1105.
- [11] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[C]. International Conference on Learning Representations (ICLR'15), 2015.
- [12] He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE Computer Society, 2016.