

基于卷积神经网络和迁移学习的水稻害虫识别

杨红云^{1*}, 肖小梅¹, 黄琼², 郑国梁¹, 易文龙¹

¹江西农业大学软件学院, 江西 南昌 330045;

²江西农业大学计算机与信息工程学院, 江西 南昌 330045

摘要 为了实现水稻害虫的快速、准确识别, 提出了一种基于迁移学习和卷积神经网络相结合的水稻害虫识别方法。首先对水稻害虫图像进行平移、翻转、旋转、缩放等预处理, 并按照害虫特征由人工分为稻纵卷叶螟、稻飞虱、二化螟、三化螟、稻蝗、稻象甲等 6 个类别。然后基于迁移学习方法, 将 VGG16 模型在图像数据集 ImageNet 上训练得到的权重参数迁移到水稻害虫的识别当中, 将 VGG16 的卷积层和池化层作为特征提取层, 同时将顶层重新设计为全局平均池化层和一个 softmax 输出层, 训练时冻结部分卷积层。实验结果表明: 所提模型的平均测试准确率为 99.05%, 训练时间约为原有模型的 1/2, 模型大小仅为 74.2 MB; 在稻蝗、稻飞虱、稻象甲、二化螟、稻纵卷叶螟、三化螟等 6 类害虫的 F1 值分别为 0.98、0.99、0.99、0.99、1.00、0.99。所提方法识别效率高, 识别效果好, 可移植性强, 可为农作物的害虫高效快速诊断提供参考。

关键词 机器视觉; 水稻害虫; 迁移学习; VGG16

中图分类号 TP391.4; S431.9

文献标志码 A

DOI: 10.3788/LOP202259.1615004

Rice Pest Identification Based on Convolutional Neural Network and Transfer Learning

Yang Hongyun^{1*}, Xiao Xiaomei¹, Huang Qiong², Zheng Guoliang¹, Yi Wenlong¹

¹School of Software, Jiangxi Agricultural University, Nanchang 330045, Jiangxi, China;

²School of Computer and Information Engineering, Jiangxi Agricultural University, Nanchang 330045, Jiangxi, China

Abstract In order to realize rapid and accurate identification of rice pests, a rice pest identification method based on transfer learning and convolutional neural network was proposed in this paper. First, the images of rice pests were preprocessed. Pre-processing methods include translation, inversion, rotation, and scaling. According to the characteristics of the pests, the images were divided into six categories, namely, rice leaf roller, rice planthopper, rice plant thopper, rice leaf roller, rice plant thopper, rice plant thopper, rice locust, and rice weevil. Then, based on the transfer learning method, the weight parameters trained by the VGG16 model on the image data set ImageNet were transferred to the recognition of rice pests. The convolution layer and the pooling layer of VGG16 were used as the feature extraction layer. Meanwhile, the top layer was redesigned as the global average pooling layer and a softmax output layer. Part of the convolutional layer is frozen during training. The experimental results show that the average test accuracy of this model is 99.05%, the training time is about 1/2 of the original model, and the model size is only 74.2 MB. The F1 values of six insect pests, namely, rice grasshopper, rice planthopper, rice weevil, striped rice borer, the rice leaf roller, and yellow rice borer, were 0.898, 0.99, 0.99, 0.99, 1.00, 0.99, respectively. The experimental results show that this method has high identification efficiency, good identification effect and strong portability, which can provide a reference for the efficient and rapid diagnosis of crop pests.

Key words machine vision; rice pest; transfer learning; VGG16

1 引言

中国是个农业大国, 水稻是我国重要的粮食作物

之一^[1]。近年来, 虽然水稻的种植水平不断提高, 但水稻病虫害的发生频率也越来越高, 导致水稻大量减产。当前水稻病虫害的检测主要依靠人工识别, 但是害虫

收稿日期: 2021-07-29; 修回日期: 2021-09-09; 录用日期: 2021-09-24

基金项目: 国家自然科学基金 (62162030, 61562039, 61762048)

通信作者: *nc_yhy@163.com

数量庞大,种类繁多。仅仅依靠少量的植物保护专家,无法及时有效地识别害虫^[2-3]。因此,农业领域迫切需要一种水稻害虫识别方法。

农业信息化的发展使得越来越多的机器学习方法运用到了农作物害虫识别领域当中,并且取得一定的成果。潘春华等^[4]通过支持向量机和区域生长算法对多种蔬菜害虫如条纹蚤、白蝇、小菜蛾、蓟马等进行识别,识别率高达93%以上;张亚军^[5]为了提高农业害虫的识别效率,提出了一种基于支持向量机改进的算法,该算法通过优化惩罚因子、Manhattan距离来确定核函数,并建立害虫图像特征模型对害虫图像进行多特征融合识别,改进后的算法对害虫的识别率高达95.67%;Kasinathan等^[6]采用基分类器和集成分类器等多种机器学习算法对昆虫数据集进行分类,并采用多数投票的方式对分类结果进行评价,结果表明,结合纹理、颜色、形状、histogram of oriented gradients(HOG)和GIST特征的集成分类器采用多数投票的方法可提高分类准确率。机器学习的方法虽然取得了较好的效果,但是该方法严重依赖于特征参数的准确提取,存在特征提取困难、抗干扰能力弱、普适性差等不足。

深度学习是机器学习的一个重要分支,与传统机器学习不同的是,深度学习由数据驱动自动提取抽象特征,减少了人工提取特征的不完备性,在分类识别领域受到众多学者青睐^[7-10]。刘文定等^[11]使用全卷积神经网络(FCN)识别航拍林区虫害图像,像素准确率达97.86%,为林业虫害的防治提供了参考。Grinblat等^[12]针对白豆、红豆和黄豆3个不同品种豆科植物的识别问题,提出了一种基于深度卷积神经网络的深度学习模型,该模型通过学习不同品种豆科植物的叶脉特征,实现了豆科植物的分类,且该模型可以大大提高豆科植物的识别准确率。Mohanty等^[13]在PlantVillage

的基础上,训练了一种识别14种作物的26种病害的深度卷积神经网络,其准确率高达99.35%,为作物诊断提供了一条清晰的道路。Cheng等^[14]为了识别复杂背景下的害虫图像,提出了一种基于深度残差学习的害虫识别方法,并使用该方法对10类复杂背景下的作物害虫进行了识别分类,其准确率高达98.67%。

神经网络的训练需要大量的数据和良好的计算资源支撑,且花费时间较长。而迁移学习^[15-18]可以在大型图像数据集上训练好的神经网络通过一定的方式,在小的目标数据集上经过小幅调整即可完成目标识别任务,能有效弥补数据量的不足,且缩短计算时间。本文对传统的卷积神经网络进行结构优化,并与迁移学习结合,实现水稻害虫的快速、准确识别。首先基于迁移学习方法,将VGG16模型在ImageNet数据集上训练得到的权重参数迁移到水稻害虫的识别当中;然后将VGG16的卷积层和池化层作为特征提取层,并重新设计顶层,提高模型的性能。相比于全新学习,迁移学习有利于提高模型性能,加快网络收敛。

2 材料与方法

2.1 图像采集

本实验组以6种不同的水稻害虫作为研究对象。因为水稻害虫图像数据难以获取,实地拍摄受害虫习性影响较大,所以本实验的数据集一部分来自于百度、谷歌等网络搜索引擎,一部分于2020年拍摄于自然环境,拍摄时以水稻叶片、白板等为背景,相机型号为佳能EOS60D,并进行正面和侧面的多角度拍摄。从网络中获取的图像有580幅,相机拍摄的图像有106幅,共获取样本图像686幅,包括122幅稻飞虱、127幅二化螟、106幅稻纵卷叶螟、112幅稻象甲、102幅三化螟、107幅稻蝗。图像样本示例如图1所示。

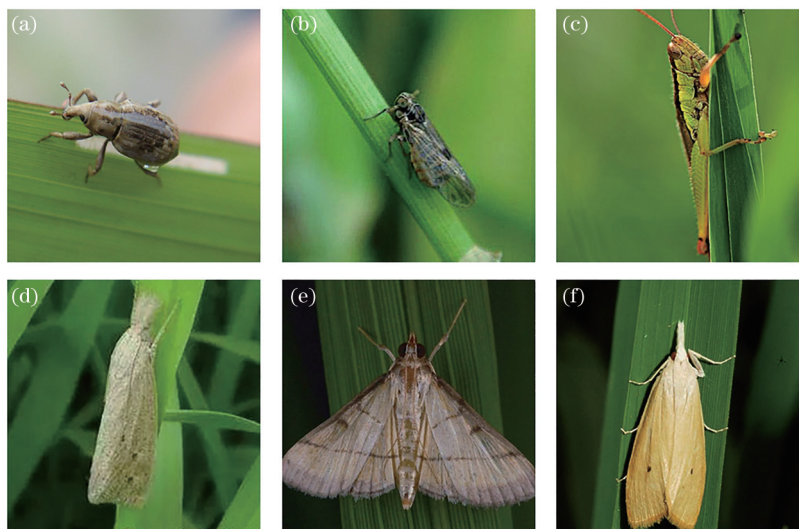


图1 水稻害虫样本示例。(a)稻象甲;(b)稻飞虱;(c)稻蝗;(d)二化螟;(e)稻纵卷叶螟;(f)三化螟

Fig. 1 Samples of rice pests. (a) Rice weevil; (b) rice planthopper; (c) rice grasshopper; (d) striped rice borer; (e) rice leaf roller; (f) yellow rice borer

2.2 图像数据预处理

本实验组搜集的水稻害虫数据集较少,水稻害虫识别模型难以了解数据集的真实分布,容易出现过拟合现象,因此要通过数据扩充方法来解决数据量少的问题,在深度学习中,数据增强是常用的数据扩充方法之一。本实验组使用平移变换(shift)、翻转变换(flip)、旋转(rotation)、尺度变化(scale)、噪声扰动(noise)及亮度调节(brightness)等6种数据增强方式对水稻害虫数据集进行扩充,将每种害虫图像扩充为原来的10倍,样本图像由原来的686幅增加到6860幅,详细情况如表1所示。此外,数据集有一部分来源于网络,扩增前后的图像尺寸参差不齐,为了满足VGG16网络的输入要求,将水稻害虫图像统一调整为 $224 \text{ pixel} \times 224 \text{ pixel}$,图像格式均为jpg。并将80%的图像作为训练数据集,剩下的20%作为测试数据集。

表1 水稻害虫数据集
Table 1 Rice pest dataset

Pest species	Number of images	
	Original	After data enhancement
Rice weevil	112	1120
Rice planthopper	122	1220
Rice grasshoppe	107	1070
Striped rice borer	127	1270
Rice leaf roller	106	1060
Yellow rice borer	102	1020

2.3 实验环境以及参数设置

水稻害虫识别模型的训练与测试均是在Windows 10 64 bit操作系统下完成的,CPU为Intel(R) Xeon(R) Silver 4112@ 2.6 GHZ 2.59 GHZ,内存为16 GB,GPU采用NVIDIAQuadro P4000,容量为8 GB。软件环境配置为keras 2.1.2、CUDAToolkit 9.0、CUDNN7.1、Python3.6.6。

综合考虑实验设备的性能和训练效果,将批量大小(batch size)设置为32,即每次训练与测试都是32张图像。迭代次数(epoch)设置为200,采用随机梯度下降优化算法(SGD)优化模型,将初始学习率设置为0.01,且学习率随着训练轮次变化,每轮次衰减0.00005,动量参数(momentum)设置为0.9。

3 水稻害虫图像识别模型构建

3.1 卷积神经网络

卷积神经网络(CNN)是深度学习中的一种多层次网络模型,在图像识别领域使用广泛。卷积神经网络的结构如图2所示。卷积神经网络包括大量的参数和超参数,如偏差、权值、网络层数、神经元个数、卷积核大小、学习率、步幅等。卷积神经网络主要由两部




图2 卷积神经网络结构

Fig. 2 Structure of convolutional neural network

部分组成,即特征提取器和分类器。特征提取器通常由若干个卷积层和一个最大池化层组成。分类器通常是一个全连接的softmax层。常用的卷积神经网络有LeNet^[19]、Alexnet^[20]、VGG^[21-22]和GoogleNet^[23]等。一般而言,为了获取更好的性能,训练卷积神经网络需要大量的数据和训练时间。

3.2 迁移学习

传统的深度学习方法试图从一开始学习每一项任务。然而,在一些情况下,人们可以运用先前学到的知识解决新问题,这种知识的迁移即迁移学习^[24-25]。在图像分类领域,迁移学习是一种利用在特定数据集上训练过的模型的技术和方法,将该模型再次用于解决其他分类问题,以其作为起点,进行参数的更新和修改,使其与目标的数据集相适应。常用的迁移方法有两种,一种是特征迁移^[26-27],去除预训练网络的最后一层,将其之前的激活值(视为特征向量)送入分类器进行分类训练;另一种是参数迁移^[28],将源域训练得到的参数迁移到目标领域,并微调网络、精调网络参数以适应新的数据集。本实验组将基于参数的迁移学习方式与深度学习结合起来构建适合水稻病虫害识别的最优模型。参数迁移与全新学习的不同之处在于,参数迁移冻结部分网络层的权值参数从源域迁移得到,未冻结部分随机初始化,全新学习则随机初始化所有网络层的参数,并用数据集对网络模型从头开始训练。因此,相比于全新学习,迁移学习可以加快网络收敛速度。

3.3 模型构建

由于VGG16网络架构易于实现,本实验组选用VGG16模型进行迁移学习。VGG16是一种经典的卷积神经网络模型,在图像分类领域运用广泛^[29-31]。该模型共16层,包括13个卷积层(convolutional layer),5个池化层(pooling layer)以及3个全连接层(fully connected layer),模型结构如图3所示。VGG16是由 3×3 的滤波器组合堆叠而成的,可提取图像包含的细小特征。

ImageNet是优秀的图像分类资源,拥有320万幅图像,在目标检测和图像分类领域运用广泛^[32-33]。本实验组将VGG16在ImageNet上训练得到的参数迁移到水稻害虫识别模型中,可以完成水稻害虫的小数据集分类任务。本实验组保留VGG16模块1~模块5的结构,并对全连接层模块进行重新设计。经多次实验验证,最终将顶层设计为一个全局平均池化层和一个

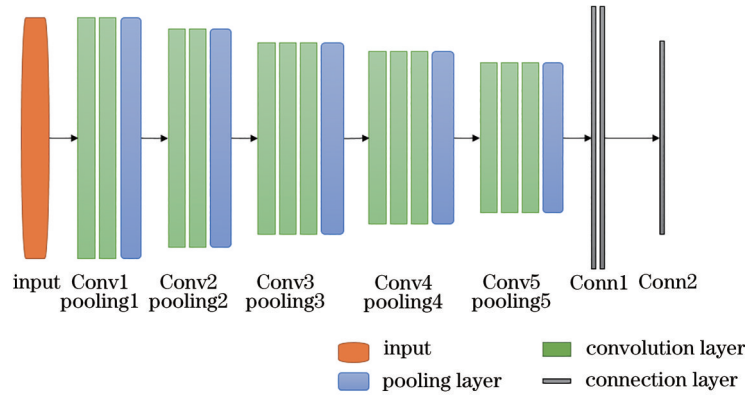


图 3 VGG16 卷积神经网络模型

Fig. 3 VGG16 convolutional neural network model

神经元个数为 6 的全连接层,并且冻结部分卷积层,全连接层经过 softmax 函数后,被映射成 (0, 1) 之间的分

布,得到水稻害虫预测类别,改进后的模型记为 VGG16_N,其流程图如图 4 所示。

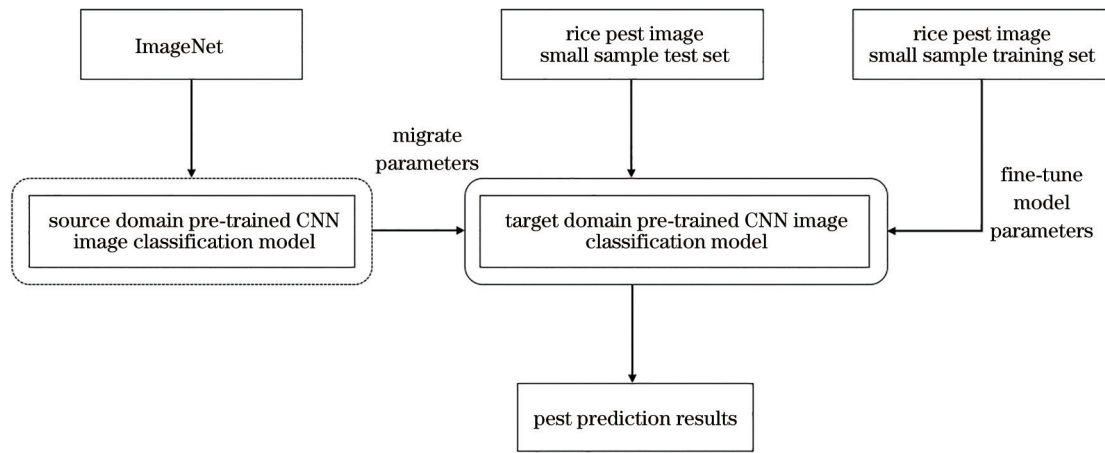


图 4 基于 CNN 和参数迁移相结合的水稻害虫算法流程图

Fig. 4 Flow chart of rice pest algorithm based on CNN and parameter migration

该算法主要流程如下:

1) 图像预处理。将采集到的水稻害虫图像进行平移、翻转、旋转、缩放等预处理,实现害虫数据集的扩增。并将水稻害虫图像统一调整为 224 pixel × 224 pixel。

2) 输入水稻害虫图像样本。随机从水稻害虫图像数据集中抽取 6 种稻水稻害虫图片的 80% 作为训练样本输入。

3) 构建水稻害虫识别模型。基于预训练 VGG16 模型的整体构架,用带有 6 个神经元的 softmax 分类器替换原有的 softmax 分类层,并将其余全连接层替换为全局平均池化层。

4) 参数的迁移和微调。使用参数迁移方式初始化改进后的网络模型,训练时冻结池化层和部分卷积层,同时手动设置学习率,动量因子及 batchsize 等训练参数,并计算损失函数的值,通过损失值的反向传播机制,指导部分卷积层和 softmax 分类层相关参数的优化更新。

5) 模型测试。从水稻害虫数据集中抽取余下

20% 水稻害虫图片作为测试样本对模型进行测试,以验证模型的精确度。

4 实验结果与分析

4.1 不同改进方案的对比

迁移学习有冻结全部卷积层和微调部分网络层两种方式:冻结全部卷积层指只允许模型的顶层参与训练,卷积层全部不参与;微调部分网络层则允许模型的部分卷积层和顶层同时参与训练,部分卷积层指的是靠近顶层的几个卷积层。本实验组在冻结全部卷积层的情况下,设计了 5 种顶层方案用于迁移学习的有效性分析:1) 一个含有 64 个神经元的 dense 层和一个 softmax 输出层;2) 一个含有 512 个神经元的 dense 层和一个 softmax 输出层;3) 一个含有 1024 个神经元 dense 层和一个 softmax 输出层;4) VGG16 的原有顶层结构;5) 全局平均池化层和一个 softmax 输出层。实验结果如表 2 所示。

从表 2 可以看出,不同的顶层设计会影响模型性

表 2 不同顶层设计方案实验对比

Table 2 Experimental comparison of different top-level design schemes

Experiment number	Accuracy / %	Loss	Time / s	Model size / MB
1	84.70	0.689	9439.03	68.4
2	96.43	0.098	9650	154
3	96.94	0.090	9742	252
4	97.15	0.098	10524	968
5	91.84	0.330	9244	56.2

能,模型的识别准确率随着全连接层的个数增加而有所提升。损失值描述的是预测值和真实值之间的偏离程度,损失值越小,代表模型的鲁棒性能越好,实验 2 和实验 3 的损失值相差不大,均维持在较低水平。表 2 中记录的时间是模型迭代 200 次所花费的时间,从表 2 也可以看出,模型的训练时间也会随着神经元个数的增加而延长,模型大小也会随着神经元个数的增加而增大,而模型的大小会影响模型的可移植性,模型越

表 3 是否冻结全部卷积层对实验的影响

Table 3 Influence of freezing all convolutional layers on experiment

Model	Whether to unfreeze convolution layer	Accuracy / %	Loss	Time / s	Model size / MB
VGG16_M	No	96.43	0.098	9650	154
	Yes	98.98	0.042	10015	172
VGG16_N	No	91.84	0.330	9244	56.2
	Yes	99.05	0.025	9661	74.2

由表 2 可知:解冻部分卷积层可以提升模型的识别准确率,降低损失值,但是也会增加模型的训练时间和模型大小;解冻部分卷积层后的 VGG16_N 表现优异,在识别准确率和损失值,可移植性方面的表现均优于 VGG16_M,训练时间相差不大。因此,将迁移学习与 VGG16_N 结合,并解冻部分卷积层为本次实验的最终改进方案。

4.3 改进方案与原有方法的比较

在水稻害虫数据集上验证迁移学习与 VGG16_N

小,可移植性越强。全局平均池化层的引入可以大幅缩短训练时间,并且减小模型大小,增强模型可移植性能,但是由于在模型训练过程中,全局平均池化层的参数不参与更新,导致模型训练不足,会出现一定的欠拟合现象。综合分析,在冻结卷积层的情况下,一个 softmax 输出层和一个神经元个数为 512 的 dense 层的顶层设计可以获得较为理想的效果,此改进模型记为 VGG16_M。

4.2 是否冻结全部卷积层对实验的影响

微调部分网络指允许部分卷积层与顶层一起参与训练。在 VGG16_M 的基础上解冻部分卷积层,对其进一步探究。由于在冻结全部卷积层的情况下,引入全局平均池化可以大幅度缩短模型训练时间并减小模型大小,但是存在训练不足的情况。因此,本实验组在这种顶层设计的基础上解冻部分卷积层,并观察实验结果。将这种顶层设计为一个全局平均池化层和一个 softmax 层的模型记为 VGG16_N,对 VGG16_M 和 VGG16_N 解冻部分卷积层的实验结果如表 3 所示。

模型相结合的有效性,并与原有方法(模型 VGG16,采用全新学习方式)进行比较。原有方法与改进方案在水稻害虫数据集上的识别效果分别如图 5、图 6 所示。从图中可以看出,基于全新学习的传统 VGG16 的 accuracy 曲线和 loss 曲线大约在迭代 50 次左右开始收敛,但是曲线出现了局部突变现象,说明模型不稳定。收敛后的 validation accuracy 曲线与 validation loss 曲线都与对应的训练曲线维持着较大的距离,说明基于全新学习的传统 VGG16 模型在水稻害虫数据集上拟合




图 5 基于全新学习的 VGG16 的识别效果。(a) Accuracy 曲线;(b) loss 曲线

Fig. 5 Recognition effect based on the newly learned VGG16. (a) Accuracy curve;(b) loss curve




图 6 迁移学习与 VGG16_N 相结合的识别效果。(a) Accuracy 曲线; (b) loss 曲线

Fig. 6 Recognition effect of the combination of transfer learning and VGG16_N. (a) Accuracy curve; (b) loss curve

得不是很好,出现了欠拟合现象。迁移学习与 VGG16_N 相结合的 accuracy 曲线与 loss 曲线大约在迭代 20 次左右就开始收敛,明显快于原有模型,收敛后的 validation accuracy 曲线与 validation loss 曲线与对应的训练曲线接近,说明模型很好地拟合了水稻害虫数据集。从图中也可以看出,在训练后期引入迁移学习的 VGG16_N 的 accuracy 曲线与 loss 曲线相比于原有模型,震荡幅度更小,模型更加稳定。

改进方案(迁移学习与 VGG16_N 相结合,并解冻部分卷积层)与传统的 VGG16(全新学习方式)在准确率、损失值,训练时间、模型大小方面的具体数值对比如表 4 所示。从表中可以看出,相比原有方法,改进方案显著改善了网络性能,在水稻害虫数据集上的准确率提高了 12.53 个百分点,损失值降低了 0.91,训练时间缩短了一半以上,模型大小仅为 74.2 MB,远小于原有方法。

表 4 改进方案与原有模型的对比

Table 4 Comparison between improved scheme and original model

Model	Learning method	Accuracy / %	Loss	Time / s	Model size / MB
VGG16	New learning	86.52	0.93	20204	1000
VGG16_N	Transfer learning	99.05	0.02	9661	74.2

为了对最终改进方案在各类害虫的识别效果进一步探究,将改进方案(迁移学习与 VGG16_N 相结合,并解冻部分卷积层)经过 200 次迭代训练的模型进行测试,得到的各类害虫的查准率(Precision)、查全率(Recall)和 F1 得分如表 5 所示。从表中可以看出,按 F1 得分,模型分类性能最好的是稻纵卷叶螟,最差的是稻蝗。

表 5 所提模型的性能对比

Table 5 Classification performance of proposed model

Pest species	Precision	Recall	F1
Rice grasshopper	0.98	0.99	0.98
Rice planthopper	0.99	0.99	0.99
Rice weevil	0.99	0.99	0.99
Striped rice borer	0.99	0.99	0.99
The rice leaf roller	1.00	1.00	1.00
Yellow rice borer	1.00	0.99	0.99

4.4 不同网络模型的性能对比

为了进一步验证改进方案的有效性,将改进方案与其他模型进行了对比,实验结果如表 6 所示。

由表 6 可知,不同的卷积神经网络模型在识别准确率、损失值、时间、模型大小方面存在较大差异。引入迁移学习的模型 VGG16_N 在害虫识别准确率、损

失值、模型大小等方面均优于基于全新学习的 Alexnet、Resnet34、Resnet50 等传统模型。

表 6 不同网络模型的性能对比

Table 6 Performance comparison of different network models

Model	Learning method	Accuracy / %	Loss	Time / s	Model size / MB
Alexnet	New learning	94.20	0.3089	5109	444
Resnet34	New learning	98.25	0.0719	15128	173
Resnet50	New learning	96.79	0.1911	398270	349
VGG16_N	Transfer learning	99.05	0.0247	9661	74.2

5 结 论

针对传统识别方法存在的识别效果差、效率低等问题。本实验组引入迁移学习,并对模型的顶层重新设计,对比不同的顶层设计方案以及训练时是否冻结全部卷积层的识别效果,得到如下结论。1)在冻结全部卷积层的情况下,引入迁移学习的模型识别效果与不同结构的顶层有关,随着神经元个数的增加,模型的识别准确得到提高,损失值下降。但是模型大小也会随着神经元个数的增加而变大,导致可移植性降低。2)解冻部分卷积层可以解决顶层神经元过少导致训练不足的问题,在解冻部分卷积层的情况下,一个全局平均池化层和一个神经元个数为 6 的 softmax 输出层的顶层设计可以获得较为理想的效果,在水稻害虫数据集上的平均识别准确率达 99.05%,模型大小仅为 74.2 MB,具有较好的可移植性,且相对于原有模型耗时更少。3)相比于全新学习,迁移学习可以利用在大型数据上学习到的知识,加快模型收敛,提高模型的识别准确率,节约模型训练时间。

参 考 文 献

- [1] 谢明. 浅析农业技术推广及水稻栽培技术的要点[J]. 现代农业研究, 2021, 27(3): 129-130.
Xie M. Brief analysis on the key points of agricultural technology extension and rice cultivation techniques[J]. Modern Agricultural Research, 2021, 27(3): 129-130.
- [2] 靳亚. 论北方地防治水稻病虫害[J]. 农民致富之友, 2019(5): 74.
Jin Y. On the control of rice diseases and insect pests in northern China[J]. Nongmin Zhifuzhiyou Yuekan, 2019 (5): 74.
- [3] 马鹏鹏, 周爱明, 姚青, 等. 图像特征和样本量对水稻害虫识别结果的影响[J]. 中国水稻科学, 2018, 32(4): 405-414.
Ma P P, Zhou A M, Yao Q, et al. Influence of image features and sample sizes on rice pest identification[J]. Chinese Journal of Rice Science, 2018, 32(4): 405-414.
- [4] 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(英文)[J]. 农业工程学报, 2018, 34(8): 192-199.
Pan C H, Xiao D Q, Lin T Y, et al. Classification and recognition for major vegetable pests in Southern China using SVM and region growing algorithm[J]. Transactions of the Chinese Society of Agricultural Engineering, 2018, 34(8): 192-199.
- [5] 张亚军. 基于改进支持向量机算法的农业害虫图像识别研究[J]. 中国农机化学报, 2021, 42(2): 146-152.
Zhang Y J. Image recognition of agricultural pest based on improved support vector machine[J]. Journal of Chinese Agricultural Mechanization, 2021, 42(2): 146-152.
- [6] Kasinathan T, Uyyala S R. Machine learning ensemble with image processing for pest identification and classification in field crops[J]. Neural Computing and Applications, 2021, 33(13): 7491-7504.
- [7] Dyrmann M, Karstoft H, Midtby H S. Plant species classification using deep convolutional neural network[J]. Biosystems Engineering, 2016, 151: 72-80.
- [8] 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 J, Tan W J, Mao H P, et al. Recognition of multiple plant leaf diseases based on improved convolutional neural network[J]. Transactions of the Chinese Society of Agricultural Engineering, 2017, 33 (19): 209-215.
- [9] 张祥东, 王腾军, 朱劭俊, 等. 基于扩张卷积注意力神经网络的高光谱图像分类[J]. 光学学报, 2021, 41(3): 0310001.
Zhang X D, Wang T J, Zhu S J, et al. Hyperspectral image classification based on dilated convolutional attention neural network[J]. Acta Optica Sinica, 2021, 41 (3): 0310001.
- [10] 邢永鑫, 吴碧巧, 吴松平, 等. 基于卷积神经网络和迁移学习的奶牛个体识别[J]. 激光与光电子学进展, 2021, 58(16): 1628002.
Xing Y X, Wu B Q, Wu S P, et al. Individual cow recognition based on convolution neural network and transfer learning[J]. Laser & Optoelectronics Progress, 2021, 58(16): 1628002.
- [11] 刘文定, 田洪宝, 谢将剑, 等. 基于全卷积神经网络的林区航拍图像虫害区域识别方法[J]. 农业机械学报, 2019, 50(3): 179-185.
Liu W D, Tian H B, Xie J J, et al. Identification methods for forest pest areas of UAV aerial photography based on fully convolutional networks[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50 (3): 179-185.
- [12] Grinblat G L, Uzal L C, Larese M G, et al. Deep learning for plant identification using vein morphological patterns[J]. Computers and Electronics in Agriculture, 2016, 127: 418-424.
- [13] Mohanty S P, Hughes D P, Salathé M. Using deep learning for image-based plant disease detection[J]. Frontiers in Plant Science, 2016, 7: 1419.
- [14] Cheng X, Zhang Y H, Chen Y Q, et al. Pest identification via deep residual learning in complex background[J]. Computers and Electronics in Agriculture, 2017, 141: 351-356.
- [15] Liu Y Z, Shi K M, Li Z X, et al. Transfer learning method for bearing fault diagnosis based on fully convolutional conditional Wasserstein adversarial Networks[J]. Measurement, 2021, 180: 109553.
- [16] Jiang Z C, Dong Z X, Jiang W P, et al. Recognition of rice leaf diseases and wheat leaf diseases based on multi-task deep transfer learning[J]. Computers and Electronics in Agriculture, 2021, 186: 106184.
- [17] Krishnamoorthy N, Prasad L V N, Kumar C S P, et al. Rice leaf diseases prediction using deep neural networks with transfer learning[J]. Environmental Research, 2021,

- 198: 111275.
- [18] 雷相达, 王宏涛, 赵宗泽. 基于迁移学习的小样本机载激光雷达点云分类[J]. 中国激光, 2020, 47(11): 1110002.
- Lei X D, Wang H T, Zhao Z Z. Small sample airborne LiDAR point cloud classification based on transfer learning[J]. Chinese Journal of Lasers, 2020, 47(11): 1110002.
- [19] Wu Z L, Chen H, Lei Y K. Recognizing non-collaborative radio station communication behaviors using an ameliorated LeNet[J]. Sensors, 2020, 20(15): 4320.
- [20] He M, Zhao X D, Lu Y, et al. An improved AlexNet model for automated skeletal maturity assessment using hand X-ray images[J]. Future Generation Computer Systems, 2021, 121: 106-113.
- [21] Qiu J, Lu X L, Wang X X, et al. Research on rice disease identification model based on migration learning in VGG network[J]. IOP Conference Series: Earth and Environmental Science, 2021, 680(1): 012087.
- [22] 丁永军, 张晶晶, 李民赞. 基于卷积胶囊网络的百合病害识别研究[J]. 农业机械学报, 2020, 51(12): 246-251, 331.
- Ding Y J, Zhang J J, Li M Z. Disease detection of lily based on convolutional capsule network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(12): 246-251, 331.
- [23] Huang X H, Chen W H, Yang W D. Improved algorithm based on the deep integration of Googlenet and residual neural network[J]. Journal of Physics: Conference Series, 2021, 1757(1): 012069.
- [24] 朱劲松, 李欢, 王世芳. 基于卷积神经网络和迁移学习的钢桥病害识别[J]. 长安大学学报(自然科学版), 2021, 41(3): 52-63.
- Zhu J S, Li H, Wang S F. Defect recognition for steel bridge based on convolutional neural network and transfer learning[J]. Journal of Chang'an University (Natural Science Edition), 2021, 41(3): 52-63.
- [25] 郭心悦, 胡沁涵, 刘纯平, 等. 基于迁移学习和批归一化的菜肴图像识别方法[J]. 计算机应用与软件, 2021, 38(3): 124-133.
- Guo X Y, Hu Q H, Liu C P, et al. Food image recognition based on transfer learning and batch normalization[J]. Computer Applications and Software, 2021, 38(3): 124-133.
- [26] Jiang D, Xu R B, Xu X, et al. Multi-view feature transfer for click-through rate prediction[J]. Information Sciences, 2021, 546: 961-976.
- [27] Yao S Z, Tan J H, Chen Y, et al. A weighted feature transfer Gan for medical image synthesis[J]. Machine Vision and Applications, 2020, 32(1): 1-11.
- [28] 王姝, 关展旭, 王晶, 等. 基于迁移学习的贝叶斯网络参数学习方法[J]. 东北大学学报(自然科学版), 2021, 42(4): 509-515.
- Wang S, Guan Z X, Wang J, et al. Bayesian network parameter learning method based on transfer learning[J]. Journal of Northeastern University (Natural Science), 2021, 42(4): 509-515.
- [29] Pardede J, Sitohang B, Akbar S, et al. Implementation of transfer learning using VGG16 on fruit ripeness detection[J]. International Journal of Intelligent Systems and Applications, 2021, 13(2): 52-61.
- [30] Bi J. A flower classification study based on SVM and VGG16[J]. International Core Journal of Engineering, 2021, 7(2): 368-377.
- [31] 王浩雨. 基于改进 VGG16 神经网络的异常检测模型研究[J]. 现代计算机, 2020(30): 3-7, 15.
- Wang H Y. Research on anomaly detection model based on improved VGG16 neural network[J]. Modern Computer, 2020(30): 3-7, 15.
- [32] Moon J, Hossain M B, Chon K H. AR and ARMA model order selection for time-series modeling with ImageNet classification[J]. Signal Processing, 2021, 183: 108026.
- [33] Xiao Y D, Huang X Q, Liu K. Model transferability from ImageNet to lithography hotspot detection[J]. Journal of Electronic Testing, 2021, 37(1): 141-149.