

面向农作物病害识别的高阶残差卷积神经网络研究

曾伟辉^{1,2}, 李 森¹, 张 健¹, 黄小平^{1,2}, 王敬贤^{1,2}, 袁 媛¹

(1. 中国科学院合肥智能机械研究所, 安徽合肥 230031; 2. 中国科学技术大学信息学院, 安徽合肥 230027)

摘要: 当前研究农作物病害的准确识别工作中, 针对简单背景的农作物病害图像识别取得了巨大成功, 但当面向包含有各种噪声和复杂背景真实场景的农作物病害图像识别问题时, 难以满足识别准确率的要求, 为此提出了一种新的面向农作物病害识别应用的高阶残差卷积神经网络方法, 以实现农作物病害的准确、抗干扰的识别. 实验结果表明, 该方法具有高准确率、强鲁棒性和良好的抗干扰能力, 能较好地满足农作物病害识别的实际应用需求.

关键词: 农作物病害识别; 高阶残差; 鲁棒性; 卷积神经网络

中图分类号: TP391 **文献标识码:** A doi: 10.3969/j.issn.0253-2778.2019.10.002

引用格式: 曾伟辉, 李森, 张健, 等. 面向农作物病害识别的高阶残差卷积神经网络研究[J]. 中国科学技术大学学报, 2019, 49(10): 781-790.

ZENG Weihui, LI Miao, ZHANG Jian, et al. Research on high-order residual convolution neural network for crop disease recognition application[J]. Journal of University of Science and Technology of China, 2019, 49(10): 781-790.

Research on high-order residual convolution neural network for crop disease recognition application

ZENG Weihui^{1,2}, LI Miao¹, ZHANG Jian¹, HUANG Xiaoping^{1,2}, WANG Jingxian^{1,2}, YUAN Yuan¹

(1. Institute of Intelligent Machines, Chinese Academy of Sciences, Hefei 230031, China;

2. School of Information Science, University of Science and Technology of China, Hefei 230027, China)

Abstract: Current research works focusing on the image recognition of crop disease in simple background have achieved great success. However, when handling the problem of crop disease recognition with various noise and complex backgrounds, it is difficult to meet the requirement of recognition accuracy. To address these issues, a new high-order residual convolution neural network for crop disease recognition is proposed, which can realize crop disease recognition that is both accurate and anti-interference. Extensive experimental results demonstrate that the proposed method has high accuracy, strong robustness as well as good anti-interference ability, and can better meet the practical application requirements for crop disease recognition.

Key words: crop disease recognition; high-order residual(HOR); robustness; convolutional neural network (CNN)

收稿日期: 2018-06-30; 修回日期: 2018-09-28

基金项目: 十三五中科院信息化专项(XXH13505-03-104.)资助.

作者简介: 曾伟辉(通讯作者), 女, 1982年生, 博士生/副研究员. 研究方向: 农业信息化. E-mail: zengwhyu@163.com

0 引言

农作物病害的准确识别对于提高农产品产量和保障食品安全具有重要意义. 传统农业生产中, 农民凭经验来对农作物病害进行识别诊断, 无法保障诊断的正确率和可靠性. 由于农业专家无法实时在田间地头进行实地指导, 因此借助信息技术对农作物病害进行准确的识别就变得极其重要. 大部分农作物病害发生时会在作物叶片部位出现病斑, 具有不同的颜色、形状和纹理特征. 由于农作物致病的病原体不同, 造成了各种病害主要危害部位的表现不同, 这也使得我们可以将农作物病害的诊断转化为对农作物叶部图像的分类识别问题. 准确地对农作物病叶图像进行分类识别, 确诊病害类别, 是目前农业生产生活中亟待解决的问题.

基于图像处理技术的农作物病害识别常分为背景分割、病斑分割、特征提取和分类识别等步骤. 国内外研究表明此类方法已取得了较好的识别效果, 但面向农作物病害识别实际应用时, 其存在一定的局限性: 大量的图像预处理工作耗时耗力; 基于人工设计的特征忽视了病害图像中的全局以及上下文信息, 容易导致语义鸿沟问题. 这些局限性直接导致该方法无法满足实际场景复杂背景和噪声条件下农作物病害识别的准确率方面的需求.

深度学习模型可以自动从像素级原始数据到抽象的语义概念逐层提取信息, 这使得它在提取图像的全局特征和上下文信息方面具有优势, 能够为农作物病害识别提供新思路. 目前运用深度学习技术解决农作物病害识别问题的研究工作大部分都是基于简单背景的农作物病害识别. 当面向实际场景复杂背景和噪声条件下的农作物病害识别时, 识别准确率往往会大大降低, 无法满足实际应用需求.

面向真实场景复杂背景, 包含多种噪声条件下的农作物实际病害识别需求, 本文提出了一种高阶残差卷积神经网络方法, 用来实现农作物病害的准确识别. 同时, 为了验证方法的有效性, 我们建立了一个包含复杂背景, 不同分辨率、角度、光照等真实场景的农作物病害叶片数据集 AES-CD9214. 该数据集可以为农业领域农作物病害识别研究提供新的图像资源, 促进本领域进一步研究发展. 本文的主要贡献有以下两点:

(I) 提出一种面向农作物病害识别应用的高阶残差卷积神经网络模型, 用以对农作物病害进行准

确识别, 同时该模型还具有高鲁棒性和强抗干扰能力.

(II) 构建了一个真实场景下的复杂背景农作物病害叶片图像集 AES-CD9214. 该图像集中包含复杂背景, 不同分辨率、角度、光照等真实场景的农作物病害叶片图像. 这为农业领域研究农作物病害识别提供了重要的图像资源, 同时也可用于验证系统面向实际应用的识别准确率和鲁棒性.

1 相关工作

农作物病害识别由于直接面向农民实际应用需求, 其测试图像具有复杂的背景, 并带有各种噪声, 包括不同分辨率、角度、光照等. 这些特点给农作物病害图像识别实际应用带来了挑战. 当前, 研究工作主要可以分为基于图像处理技术的农作物病害识别和基于深度学习技术的农作物病害图像识别两类.

1.1 基于图像处理技术的农作物病害识别

基于图像处理技术的农作物病害识别一般是先对图像进行预处理, 分割背景和叶片病斑, 接着人为设计病斑特征并提取, 最后选择合适的分类器对提取到的病斑特征进行分类, 以达到识别的目的. 该方法可以分为背景分割、病斑分割、特征提取和分类识别 4 个步骤.

刁智华等^[1]针对小麦病斑分割不准确、噪声大以及病斑边缘不清晰等问题, 提出一种基于改进的模糊边缘检测的图像阈值分割算法. 相比传统固定阈值分割算法提高了 8.35%. 秦立峰等^[2]提出基于词袋特征 PCA(principal component analysis)多子空间自适应融合的黄瓜病害识别方法. 该方法在两个主成分子空间融合分类的平均准确率为 90.38%. 魏丽冉等^[3]针对植物叶片的 4 种病害和健康叶片, 提出了基于核函数支持向量机的多分类检测方法, 对 4 种病害的识别率最高达到 89.5%. 肖志云等^[4]提出了一种马铃薯典型病害图像的自适应特征融合与快速识别方法. 同时验证了在 SVM 识别模型下, 自适应特征融合方法有效保证识别精度和速度. 张经纬等^[5]提出了基于随机森林算法的黄瓜种子腔图像分割方法. 与 K -均值聚类算法、支持向量机(support vector machine, SVM)算法相比, 随机森林分割算法正确识别率高, 分割质量优. 许良凤等^[7]针对单分类器识别的局限性和玉米叶部病害的复杂性, 提出了一种基于自适应加权的多分类器融合的玉米叶部病害识别方法. Zhang 等^[8]提出了

一种基于超像素、 K -均值和方向梯度直方图金字塔 (PHOG) 算法融合策略的物联网植物病害叶片分割与识别方法. Kamal 等^[9] 使用支持向量机对棕榈油树病害叶斑进行分类.

上述研究表明, 基于图像处理技术的农作物病害识别方法虽然目前已取得了不错的成果, 但存在以下局限性: ①大量的背景分割、病斑分割等前处理工作耗时耗力 ②人为设计的有限特征提取忽视了病害图像中的全局以及上下文信息, 难以完整的描述病害类别间的差异, 容易导致图像语义鸿沟问题. 这两点局限性使得基于图像处理技术的识别方法很难满足实际场景中复杂背景和噪声条件下农作物病害识别的准确率方面的实际应用需求.

1.2 基于深度学习技术的农作物病害图像识别

深度学习模型可以自动从像素级原始数据到抽象的语义概念逐层提取信息, 这使得它在提取图像的全局特征和上下文信息方面具有优势, 并成功地在很多复杂的、具有内在表现特征的学习方面^[10-11].

目前, 在基于深度学习的农作物病害识别已经开展了大量的研究工作. 张善文等^[12] 提出一种基于环境信息和改进的深度置信网络的冬枣病虫害预测模型. 黄双萍等^[13] 提出了一种基于深度卷积神经网络 GoogleNet^[14] 模型的水稻穗瘟病检测方法, 该方法利用 Inception 基本模块重复堆叠构建主体网络, 实现了穗瘟病害预测建模, 最高准确率达到 92.0%.

Nachtigall 等^[15] 使用 AlexNet^[16] 模型对 6 种共两千多幅的苹果病害图像进行识别, 其识别准确率超过了专家人工识别的准确率. Lee 等^[17] 利用卷积神经网络直接从输入数据的原始表示中学习有用的叶片特征, 证明使用深度学习的混合局部-全局特征学习方法可以提高识别性能. Jeon 等^[18] 提出了一种利用深度卷积神经网络方法对植物叶片进行分类, 并利用 GoogleNet 调整了网络深度, 建立了两种模型. Sladojevic 等^[19] 利用深度卷积网络, 构建了一种基于叶片图像分类的植物病害识别模型, 该模型能够从健康叶片中识别出 13 种不同类型的植物病害. Durmu 等^[20] 使用 AlexNet 和 SqueezeNet^[21] 模型对 PlantVillage^[22] 中西红柿病害图像进行分类识别, 结果发现, AlexNet 模型的识别准确率比 SqueezeNet 模型的稍高, 但模型大小和所用时间也相对翻番.

上述研究表明, 基于深度学习技术的农作物病害识别可以获取农作物病害的全局特征和上下文信息, 能够较快地解决农作物病害识别问题. 但是, 目前研究工作基本上处理的都是公开数据集 PlantVillage 或者简单背景的病害图像, 对于真实场景的包含复杂背景和噪声, 不同分辨率、角度和光照环境等的农作物病害图像, 其识别准确率会大大降低, 从而导致无法准确识别.

综上所述, 在面向真实场景复杂背景, 包含各种噪声, 不同分辨率、角度和光照的农作物病害识别时, 目前的两种技术都不能很好地兼顾了识别准确率和鲁棒性的需求, 因此如何提高农作物病害图像识别的准确率和抗干扰能力成为农作物病害识别应用研究的关键.

2 高阶残差卷积神经网络方法

本节将详细介绍本文提出的高阶残差卷积神经网络 (HOResNet) 方法. 首先, 我们介绍 HOResNet 方法的网络整体架构. 然后, 详细介绍 HOResNet 中的残差模块. 接着, 从残差模块中间卷积层存在的必要性以及卷积层层数的选择两方面对 HOResNet 方法的网络结构进行探讨. 最后, 介绍每一层中的网络参数以及本文方法的实现细节.

2.1 网络整体架构

面向农作物病害识别实际应用, 我们引入了一个高阶残差卷积神经网络 HOResNet, 该网络整体架构如图 1 所示. 图 1 中, 当输入一张待识别的农作物病害图像时, 首先经过一层卷积层对其进行低层特征提取; 其次经过 3 个残差模块级联进一步的提取更多特征; 再使用 4 层卷积层和一个残差模块提取图像的高层特征; 最后经过一个全局平均池化层和一个 Softmax 层后直接输出该图像所属的病害类别概率, 从而实现对该图像的分类识别. HOResNet 方法共包括 5 层卷积层、4 个残差模块、一个全局平均池化层和一个 Softmax 层.

2.2 高阶残差模块

2015 年, 微软亚洲研究院视觉计算组在 2015 ImageNet^[23] 计算机识别挑战赛中凭借残差网络^[24], 以绝对优势获得图像分类、图像定位以及图像检测等 3 个主要项目的冠军. 这使得研究者开始关注残差网络. 目前在农作物病害识别研究工作中, 研究人员对残差模块的重要作用还未能重视和应用.

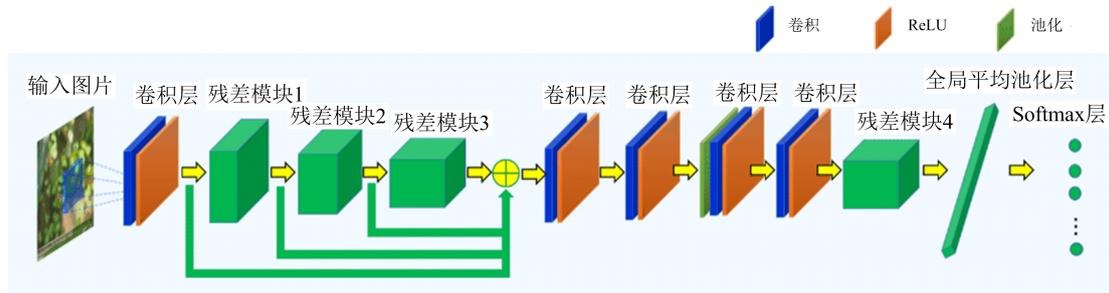


图 1 高阶残差卷积神经网络 HOResNet 整体架构

Fig. 1 Overall architecture of high-order residual convolutional neural network (HOResNet)

为了有效地利用不同层的特征,我们定义了一个高阶残差模块,其结构如图 2 所示.图 2 中,圆圈是和操作层,表示将多个输入做和运算之后传送到下一层.我们将经过第一层卷积层的输出与经过前 3 个残差模块后的输出一起连接.实验中,我们发现这种级联操作可以为后面的网络层提供更丰富的特征(包含低层和高级特征),同时还可以提高网络的鲁棒性,增强其抗干扰能力.我们把这种级联操作定义为高阶残差模块(HOR).

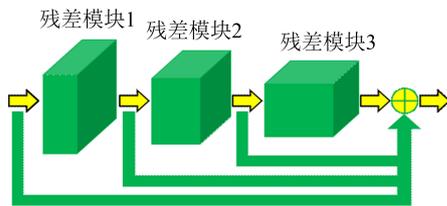


图 2 高阶残差模块结构图

Fig. 2 Structural diagram of high-order residual modules(HOR)

高阶残差网络中的残差模块结构如图 3 所示.残差模块包含 3 个卷积层,其输出分别为 X_1 、 X_2 和 X_3 . X_1 和 X_3 的通道数相同,可以直接将 X_1 和 X_3 级联起来, X_1 和 X_3 之和作为整个残差子网络的总输出.

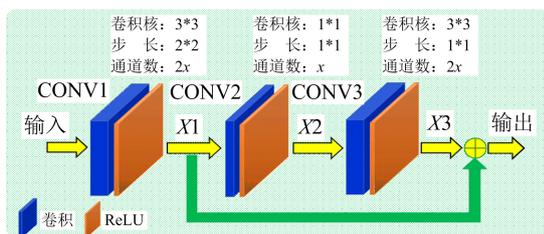


图 3 残差模块结构图

Fig. 3 Structural diagram of residual modules

我们在 PlantVillage 子集以及本文新创建的数据集 AES-CD9214 上分别进行实验,以验证高阶残差模块的作用,实验结果如表 1 所示.从表 1 可以看到,当引入高阶残差模块时,在两个数据集上识别准

确率分别获得了 3.61%、2.10% 的提升.由此验证了引入高阶残差模块可以有效地提高识别准确率,这在面向农作物病害识别实际应用中具有非常重要的意义.

表 1 卷积神经网络(CNN)引入和不引入高阶残差模块测试的识别准确率对比结果

Tab. 1 Comparison of recognition accuracy with and without high-order residual module introduced by convolutional neural network (CNN)

数据集	方法	
	CNN	CNN + HOR(提升率)
PlantVillage	0.885 9	0.917 9(3.61%)
AES-CD9214	0.882 9	0.901 4(2.10%)

2.3 网络结构探讨

在设计 HOResNet 方法网络系统架构时,我们进行了一系列的实验来验证 HOResNet 方法架构的合理性.下面将从残差模块中卷积层存在的必要性和添加卷积层层数的选择两个方面来讨论架构的确定依据.

2.3.1 残差模块中间卷积层存在的必要性验证

为了测试网络模型中带卷积层和不带卷积层对识别过程中鲁棒性的影响,我们在真实场景农作物病害数据集 AES-CD9214 测试集上分别添加了不同等级的噪声进行了两种网络模型的识别准确率对比实验,实验结果如图 4 所示.

从图 4 可以看出,当在测试集中添加不同等级的高斯噪声,以及同时添加高斯和椒盐噪声时,带卷积层的网络模型识别准确率明显高于不带卷积层的网络模型的识别准确率.这是因为高阶残差模块中间的卷积层能进一步提取病害图像更多的有效特征,能对高斯噪声起到很好的过滤作用,从而能够抗击其干扰.

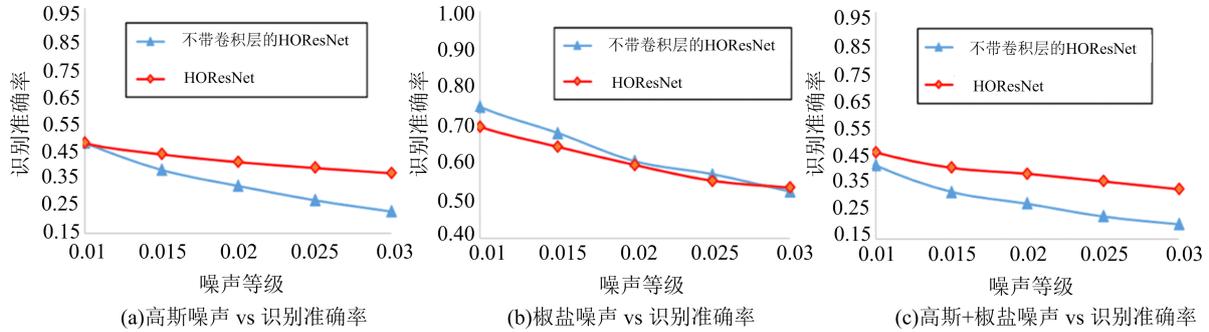


图 4 在 AES-CD9214 数据集上带卷积层和不带卷积层的识别准确率对比结果曲线图

Fig. 4 Comparison results of HOResNet with and without convolutional layers on AES-CD9214 dataset

当添加椒盐噪声时,相比不带卷积层的网络模型,带卷积层的 HOResNet 对添加了椒盐噪声的测试集的识别准确率不高,但是两者整体差别不大.综合分析实验结果,我们选择了带卷积层的网络模型来应对噪声干扰问题,提高网络的鲁棒性,使其具有更强的抗干扰能力,以适应实际应用中的识别需求.

2.3.2 卷积层层数选择

为了进一步确定 HOResNet 方法中残差模块 3 和残差模块 4 之间卷积层的层数,我们针对相应的网络结构进行了层数对比实验,对比结果如表 2 所示.

表 2 在 AES-CD9214 数据集上的网络深度识别精度的影响

Tab. 2 The effect of network depth for recognition accuracy on AES-CD9214 dataset

卷积层数量	3	4	5	6
识别精度	0.836 7	0.870 6	0.871 7	0.871 1

从表 2 可以看到,随着卷积层数量增加,识别准确率随之增加.这是因为随着卷积层层数的增加,提取的图像特征会更多,识别准确率就会提高.不足之处在于,卷积层层数增加会使得运算参数随之增加,运算量也会相应地增加,从而会使得模型训练困难.另外,参数量大,将需要更多的训练数据来进行训练,否则容易导致过拟合;因此综合考虑识别准确率和网络参数量两方面因素,为了实现简单准确的识别需求,我们选择在残差模块 3 和 4 中间插入 4 层卷积层,即 HOResNet 整体模型架构确定为包含 5 层卷积层的结构.

2.4 参数详情及方法实现细节

2.4.1 参数详情

本文 HOResNet 方法模型是一个简单的卷积神经网络,其详细参数如表 3 所示.表 3 中残差模块

的参数细节见图 3.为了减少网络的参数量,在 HOResNet 中,我们只使用 1×1 和 3×3 两种卷积核,这样有助于避免过拟合.本文选用更深的网络设计策略来设计通道的每一层,在每一层上均使用小通道来避免由于训练样本数不足而导致的过拟合问题.

表 3 HOResNet 方法的参数详情

Tab. 3 Parameter details of the proposed HOResNet.

层名	输出尺寸 (h/w/c)	滤波器尺寸 (h × w) /步长	池化尺寸 (h × w) /步长
卷积层 1	256/256/8	$3 \times 3/1$	—
残差模块 1	128/128/16	—	—
残差模块 2	64/64/32	—	—
残差模块 3	32/32/64	—	—
卷积层 2	32/32/64	$3 \times 3/1$	—
卷积层 3	32/32/64	$3 \times 3/1$	—
最大池化层	16/16/64	—	$2 \times 2/2$
卷积层 4	16/16/128	$3 \times 3/1$	—
卷积层 5	16/16/64	$1 \times 1/1$	—
残差模块 4	8/8/192	—	—
全局平均池化层	1×192	—	—
Softmax	1×6	—	—

2.4.2 方法实现

我们在 PlantVillage 子集和 AES-CD9214 上分别对本文 HOResNet 方法进行验证.在 NVIDIA GPU 1080i 的机器上,模型训练 100 个 epoch 大约需要 20 min.通常,在经过 50 次迭代之后, HOResNet 网络便能够输出令人满意的识别准确率.本文使用 Softmax 作为目标函数,其计算公式为

$$S(\theta) = -\frac{1}{L} \left[\sum_{l=1}^L \sum_{m=1}^M h(y_l = m) \log \frac{e^{\theta_m^T X_l}}{\sum_{q=1}^M e^{\theta_q^T X_l}} \right] \quad (1)$$

式中, $(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)$, 是训练集, x_l 是第 l 个训练样本, $y_l \in 1, 2, 3, \dots, M$, 是相应的标签. L 和 M 分别表示训练样本数和类别数; $h(\cdot)$ 是引导函数.

本文的优化算法选择的是 Adam 最优化算法, 使用 Adam 对公式(1)的损失函数进行优化. 训练中初始学习率设定为 2×10^{-3} , 批处理大小设置为 120.

3 实验

3.1 AES-CD9214 数据集

数据集 AES-CD9214 是本研究团队在自然环境下使用 Canon EOS 6D 数码相机拍摄采集的农作物病害图像. 我们拍摄了两种真实环境下的病害图像: 大田种植环境下水稻的 3 种病害图像和大棚种植环境下黄瓜的 3 种病害图像. 采集到包含不同分辨率、角度、姿势、背景及光照等不同场景的 6 种原始病害图像合计 2 240 张.

我们在这些原始图像的基础上, 通过边角裁剪以扩充数据集, 并剔除重复和未含病斑的图像, 最终形成 9 214 张规格为 256×256 的图像集, 即 AES-CD9 214 数据集. AES-CD9214 数据集集中的图像带有各种噪声和环境因素, 如不同分辨率、角度、光照等, 其图像样例如图 5 所示. 图 6 展示的是公开数据集 PlantVillage 中的图像样例.



图 5 数据集 AES-CD9214 中的图例

Fig. 5 Visual examples of AES-CD9214 dataset

从图 5 可以看到, AES-CD9214 数据集中图像带有复杂的背景, 且包含光照等噪声干扰. 从图 6 易见, 公开数据集 PlantVillage 中的图片都是完整的叶片, 病斑明显, 易于区分. 相比于实际环境的 AES-CD9214, PlantVillage 中的图片更容易识别.



图 6 公开数据集 PlantVillage 中的图片展示

Fig. 6 Visual examples of the open datasets: PlantVillage

另外, AES-CD9214 的类别数目很不均衡, 其类别名及其数量如表 4 所示. 由于类别不均衡, 识别过程中需要克服某些类别训练不充分导致的训练偏差, 因此从复杂的背景噪声干扰和类别不均衡两方面可以确定, AES-CD9214 数据集对图像识别方法具有挑战性.

表 4 AES-CD9214 数据集中
各类别名称以及对应的图像数量

Tab. 4 The disease name and number of corresponding images on AES-CD9214 dataset

病害名称	稻纹枯病	稻瘟病	稻胡麻斑病	黄瓜白粉病	黄瓜霜霉病	黄瓜靶斑病
图像数量	3 559	2 741	795	763	780	576

在实际应用中, 由于训练集的标注图像需要专家参与, 病害发生种类不一, 会使得拍摄的图像数量不均衡, 带标注的训练集图像数量有限. 本文的 AES-CD9214 能够真实反映实际环境下农作物病害图像识别的数据资源现状, 这为农业领域研究农作物病害识别提供了重要的图像资源. 同时, AES-CD9214 数据集也足以用来验证本文方法对于实际环境病害识别的准确率和鲁棒性.

3.2 对比实验

为了验证本文方法的识别准确率, 与文献[20]中的方法进行公平对比, 本文选择了文献[20]中相同的数据集与其进行识别准确率的对比实验. 实验数据集选取 PlantVillage 中 10 种番茄叶片图像集共 18 160 张图片, 随机选取每类图片的 80% 作为训练集, 20% 作为测试集来进行实验.

本文 HOREsNet 在 PlantVillage 中 10 种番茄叶片图像集上测试的结果如表 5 所示. 表 5 列出了 HOREsNet 方法、文献[20]中的 AlexNet 方法以及 SqueezeNet 三种方法测试获得的识别准确率、识别

时间和对应的网络参数量。

表 5 在 PlantVillage10 种番茄叶片图像集上的对比结果

Tab. 5 Comparison of 10 tomato leaf images set on PlantVillage

方法	识别准确率	参数量	识别时间
AlexNet	0.956 5	227.6 MB	~0.15 s
SqueezeNet	0.943	2.9 MB	~0.05s
HOResNet	0.964 4	0.4 MB	~0.11 s

由表 5 可以看到,相比于 AlexNet 和 SqueezeNet 方法:①从识别准确率来看,HOResNet 方法在相同的数据集上的识别准确率最高,比 AlexNet 方法识别准确率高出 0.81%,比 SqueezeNet 方法识别准确率高出 2.11%。②从参数量上来比较,HOResNet 方法参数量远远少于 AlexNet 方法与 SqueezeNet 方法,仅为 AlexNet 方法参数量 0.176%,为 SqueezeNet 方法参数量的 13.79%。③从识别时间来比较,HOResNet 方法识别一张图片的时间为 0.11s,介于 AlexNet 方法和 SqueezeNet 方法之间,3 种方法识别时间都在可接受范围内。

综上所述,本文提出的 HOResNet 方法在相同的数据集上的测试结果与 AlexNet 及 SqueezeNet 方法相比,识别准确率更高,参数量少,识别时间相对也比较快,可以实现快速、高精度识别的目标。此外,HOResNet 方法还具有模型小的特点。

3.3 抗干扰能力测试与对比分析

为了评估本文 HOResNet 网络的鲁棒性,在每个实验数据集中,我们均采用将每类的 80%作为训练集,20%作为测试集。我们将不同等级的噪声加入测试图像集,给出识别准确率的对比结果。

我们选取了 PlantVillage 数据集子集和 AES-CD9214 数据集对本文 HOResNet 方法的抗干扰能力进行测试。其中 PlantVillage 子集包括番茄的 6 种病害,其种类名称和数量如表 6 所示。

表 6 PlantVillage 子集各类别名称以及对应的图像数量

Tab. 6 The disease name and number of corresponding images in PlantVillage subset

图像类别	番茄细菌性斑疹病	健康番茄	番茄晚疫病	番茄斑枯病	番茄叶螨-二斑蜘蛛	番茄靶斑病
图像数量	2 127	1 591	1 909	1 771	1 676	1 404

在以上两种数据集上,本文采用卷积神经网络

CNN、带反馈的卷积神经网络 FB 以及本文的 HOResNet 三种方法进行抗干扰能力的对比实验。其中 CNN 方法是通过去除 HOResNet 模型结构中的残差模块后得到的通用卷积神经网络方法;FB 方法指的是在 CNN 基础上增加了反馈模块的方法。

表 7(a)、(b)、(c)依次列出了在 PlantVillage 子集测试集中加入不同等级噪声时,识别准确率的实验对比结果。

表 7 在 PlantVillage 子集测试集中加入不同等级噪声时,识别准确率的对比结果

Tab. 7 Comparison of recognition accuracy with different levels of noise added to the PlantVillage test subset

(a)高斯噪声 VS 识别准确率

方法	噪声等级			
	0.005	0.01	0.015	0.02
CNN	0.566 1	0.370 9	0.293 6	0.277 8
FB	0.652 0	0.398 1	0.307 9	0.279 7
HOResNet	0.640 1	0.510 3	0.361 3	0.282 1

(b)椒盐噪声 VS 识别准确率

方法	噪声等级			
	0.005	0.01	0.015	0.02
CNN	0.756 6	0.601 0	0.524 1	0.469 7
FB	0.890 7	0.830 1	0.701 7	0.580 9
HOResNet	0.882 6	0.764 2	0.647 7	0.603 8

(c)高斯+椒盐噪声 VS 识别准确率

方法	噪声等级			
	0.005	0.01	0.015	0.02
CNN	0.469 2	0.320 8	0.289 7	0.281 1
FB	0.548 0	0.339 9	0.283 5	0.253 0
HOResNet	0.594 7	0.401 0	0.279 7	0.236 3

表 7(a)、(b)、(c)中对应的最高的识别准确率用加粗字体表示。统计可得,HOResNet 方法的识别准确率取到了 6 次最高值,FB 方法取得 4 次最高值,而 CNN 方法仅取得 2 次最高值。由此可见,在 PlantVillage 子集上,对于噪声的抗干扰能力,本文的 HOResNet 方法最强,其次是 FB 方法,最差的是 CNN 方法。特别注意的是,HOResNet 方法面向的是复杂背景含有噪声的图像识别应用,对不带任何背景的 PlantVillage 子集中图片的识别,虽然

HOResNet 方法表现不差,但其优势并不能特别体现出来.

当在 AES-CD9214 测试集中加入不同等级噪声时,识别准确率的对比结果如表 8 和图 7 所示.

表 8 在 AES-CD9214 测试集中加入不同等级噪声时,识别准确率的对比结果

Tab. 8 Comparison of recognition accuracy with different levels of noise added to the AES-CD9214 test set

方法	噪声等级			
	0.005	0.01	0.015	0.02
CNN	0.598 9	0.483 5	0.415 7	0.368 6
FB	0.432 5	0.335 0	0.283 5	0.247 7
HOResNet	0.578 9	0.486 7	0.445 5	0.416 8

方法	噪声等级			
	0.005	0.01	0.015	0.02
CNN	0.773 4	0.694 9	0.636 9	0.590 8
FB	0.776 2	0.643 9	0.539 3	0.461 2
HOResNet	0.782 1	0.694 3	0.641 2	0.593 0

方法	噪声等级			
	0.005	0.01	0.015	0.02
CNN	0.555 6	0.436 9	0.364 8	0.321 4
FB	0.398 4	0.301 9	0.253 7	0.219 0
HOResNet	0.557 7	0.463 4	0.407 6	0.385 9

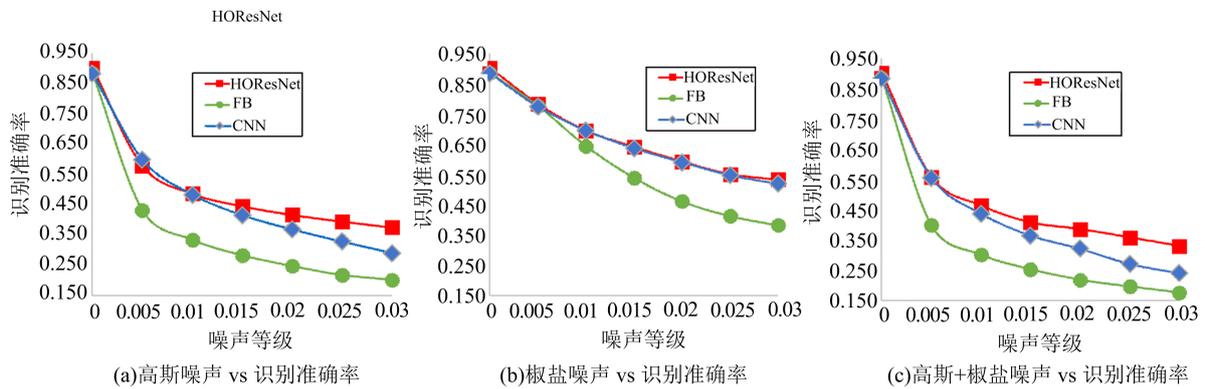


图 7 在 AES-CD9214 测试集加入不同等级噪声时,CNN、FB、HOResNet 三种方法识别准确率对比结果

Fig. 7 Comparison of recognition accuracy of CNN, FB and HOResNet when different levels of noise added to AES-CD9214 test set

表 8(a)、(b)、(c)对应的最高识别准确率用加粗字体表示,从实验结果可以看出, HOResNet 方法仅在添加 0.005 等级的高斯噪声和添加 0.01 等级的椒盐噪声时,识别准确率比 CNN 方法略低(分别低 0.02 和 0.0005)外,其余情况下的识别准确率均高于 CNN 方法和 FB 方法.从图 7 可以看到, HOResNet 方法(即图 7 中矩形标记的曲线)在数据集 AES-CD9214 上的识别准确率均高于其他对比方法;在添加不同等级的噪声干扰时, HOResNet 方法的识别准确率曲线整体下降最缓慢,表明了经噪声干扰后,其识别准确率衰减最缓慢,同样具有较其他两种方法更高的识别准确率,具有最好的鲁棒性和抗干扰能力.

由此可见,在 AES-CD9214 数据集上, HOResNet 方法对添加的高斯噪声和椒盐噪声的抗干扰能力比 CNN、FB 方法更强.这充分展示了

HOResNet 方法在处理自然环境下采集到的农作物病害图像识别问题时具有高识别准确率、强鲁棒性和很好的抗干扰能力,能够满足实际应用需求.

4 结论

面向农作物病害识别实际应用需求,我们引入了一种高阶残差卷积神经网络(HOResNet)以实现高识别准确率和强鲁棒性的识别农作物病害.为了更好地验证 HOResNet 的鲁棒性和抗干扰能力,我们新建了一个真实场景农作物病害图像数据集 AES-CD9214,为农作物病害识别研究提供了重要的图像资源,有助于整个农作物病害识别领域的研究.实验表明, HOResNet 方法在识别准确率方面优于在测试数据集上的其他方法.此外,当测试图像中添加不同级别的噪声干扰时, HOResNet 方法相比其他方法获得了更高的识别精度,尤其是在

AES-CD9214 数据集上, HOREsNet 方法具有高识别准确率、强鲁棒性和较好的抗干扰能力, 这充分说明了 HOREsNet 方法能够满足实际农作物病害识别应用需求. 未来的工作中, 我们考虑将高阶残差模块与其他模块更好地融合利用起来, 进一步提高网络的精度和鲁棒性.

参考文献(References)

- [1] 刁智华, 刁春迎, 袁万宾, 等. 基于改进型模糊边缘检测的小麦病斑阈值分割算法[J]. 农业工程学报, 2018, 34(10):147-152.
DIAO Zhihua, DIAO Chunying, YUAN Wanbin, et al. Segmentation algorithm with threshold for wheat lesion based on improved fuzzy edge detection [J]. Transactions of the Chinese Society of Agricultural Engineering, 2018, 34(10): 147-152.
- [2] 秦立峰, 何东健, 宋怀波. 词袋特征 PCA 多子空间自适应融合的黄瓜病害识别[J]. 农业工程学报, 2018, 34(08):200-205.
QIN Lifeng, HE Dongjian, SONG Huaibo. Bag of words feature multi-PCA subspace adaptive fusion for cucumber diseases identification [J]. Transactions of the Chinese Society of Agricultural Engineering, 2018, 34(8): 200-205.
- [3] 魏丽冉, 岳峻, 李振波, 等. 基于核函数支持向量机的植物叶部病害多分类检测方法[J]. 农业机械学报, 2017, 48(S1):166-171.
WEI Liran, YUE Jun, LI Zhenbo, et al. Multi-classification detection method of plant leaf disease based on kernel function SVM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48 (S1):166-171.
- [4] 肖志云, 刘洪. 马铃薯典型病害图像自适应特征融合与快速识别[J]. 农业机械学报, 2017, 48(12):26-32.
XIAO Zhiyun LIU Hong. Adaptive features fusion and fastrecognition of potato typical disease images [J]. Transactions of the Chinese Society for Agricultural Machinery. 2017, 48(12):26-32.
- [5] 张经纬, 贡亮, 黄亦翔, 等. 基于随机森林算法的黄瓜种子腔图像分割方法[J]. 农机化研究, 2017, 39(10): 163-168.
ZHANG Jingwei, GONG Liang, HUANG Yixiang, et al. Image segmentation of cucumber seed cavity based on the random forest algorithm [J]. Journal of Agricultural Mechanization Research, 2017, 39(10): 163-168.
- [6] 田凯, 张连宽, 熊美东, 等. 基于叶片病斑特征的茄子褐纹病识别方法[J]. 农业工程学报, 2016, 32(S1): 184-189.
TIAN Kai, ZHANG Liankuan, XIONG Meidong, et al. Recognition of phomopsis vexans in solanum melongena based on leaf disease spot features [J]. Transactions of the Chinese Society of Agricultural Engineering, 2016, 32(S1): 184-189.
- [7] 许良凤, 徐小兵, 胡敏, 等. 基于多分类器融合的玉米叶部病害识别[J]. 农业工程学报, 2015, 31(14): 194-201.
XU Liangfeng, XU Xiaobing, HU Min, et al. Corn leaf disease identification based on multiple classifiers fusion [J]. Transactions of the Chinese Society of Agricultural Engineering, 2015, 31(14): 194-201.
- [8] ZHANG S, WANG H, HUANG W, et al. Plant diseased leaf segmentation and recognition by fusion of superpixel, K-means and PHOG [J]. Optik, 2018: 866-872.
- [9] KAMAL M M, MASAZHAR A N, RAHMAN F D, et al. Classification of leaf disease from image processing technique [J]. Indonesian Journal of Electrical Engineering and Computer Science, 2018, 10 (1): 191-200.
- [10] WANG Y B, YOU Z H, LI X, et al. Predicting protein-protein interactions from protein sequences by a stacked sparse autoencoder deep neural network [J]. Molecular Biosystems, 2017, 13(7):1336-1344.
- [11] WANG L, YOU Z, CHEN X, et al. Computational methods for the prediction of drug-target interactions from drug fingerprints and protein sequences by stacked auto-encoder deep neural network [C]. International Symposium on Bioinformatics Research and Applications, 2017: 46-58.
- [12] 张善文, 张传雷, 丁军. 基于改进深度置信网络的大棚冬枣病虫害预测模型[J]. 农业工程学报, 2017, 33 (19):202-208.
ZHANG Shanwen, ZHANG Chuanlei, DING Jun. Disease and insect pest forecasting model of greenhouse winter jujube based on modified deep belief network [J]. Transactions of the Chinese Society of Agricultural Engineering, 2017, 33(19): 202-208.
- [13] 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.
HUANG Shuangping, SUN Chao, QI Long, et al. Rice panicle blast identification method based on deep convolution neural network [J]. Transactions of the Chinese Society of Agricultural Engineering, 2017, 33 (20): 169-176.
- [14] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [J]. Computer Vision and Pattern Recognition, 2015: 1-9.

- [15] NACHTIGALL L G, ARAUJO R M, NACHTIGALL G R, et al. Classification of apple tree disorders using convolutional neural networks [C]. International Conference on Tools with Artificial Intelligence, 2016: 472-476.
- [16] KRIZHEVSKY A, SUTSKEVER I, HINTON G E, et al. ImageNet classification with deep convolutional neural networks [C]. Neural Information Processing Systems, 2012: 1097-1105.
- [17] LEE S H, CHAN C S, MAYO S J, et al. How deep learning extracts and learns leaf features for plant classification[J]. Pattern Recognition, 2017: 1-13.
- [18] JEON W, RHEE S. Plant leaf recognition using a convolution neural network [J]. The International Journal of Fuzzy Logic and Intelligent Systems, 2017, 17(1): 26-34.
- [19] 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.
- [20] DURMUS H, GUNES E O, KIRCI M, et al. Disease detection on the leaves of the tomato plants by using deep learning [C]. international conference on agro-geoinformatics, 2017: 1-5.
- [21] HU Jie, SHEN Li, SUN Gang. Squeeze-and-excitation networks [J]. 2017, arXiv Preprint, arXiv: 1709.01507.
- [22] DENG J, DONG W, SOCHER R, et al. ImageNet: a large-scale hierarchical image database[C]. Computer Vision and Pattern Recognition, 2009: 248-255.
- [23] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [J]. Computer Vision and Pattern Recognition, 2016: 770-778.
- [24] HUGHES D P, SALATHE M. An open access repository of images on plant health to enable the development of mobile disease diagnostics[J]. arXiv: Computers and Society, 2015.

(上接第 780 页)

- [17] MEYER C H, PAULY J M, MACOVSKIAND A, et al. Simultaneous spatial and spectral selective excitation[J]. Magnetic Resonance in Medicine, 1990, 15(2): 287-304.
- [18] ZHANG T M, WU R B, ZHANG F H, et al. Minimum-time selective control of homonuclear spins [J]. IEEE Transactions on Control Systems Technology, 2015, 23(5): 2018-2025.
- [19] KHANEJA N, BROCKETT R, GLASER S J. Time optimal control in spin systems[J]. Physical Review A, 2001, 63(3): 032308.
- [20] WERSCHNIK J, GROSS E K U. Quantum optimal control theory [J]. Journal of Physics B: Atomic, Molecular and Optical Physics, 2007, 40(18): R175.
- [21] BOOZER A D. Time-optimal synthesis of $su(2)$ transformations for a spin-1/2 system [J]. Physical Review A, 2012, 85(1): 012317.
- [22] BOSCAIN U, CHITOURN Y. Time-optimal synthesis for left-invariant control systems on $so(3)$ [J]. SIAM Journal on Control and Optimization, 2005, 44(1): 111-139.
- [23] BOSCAIN U, MASON P. Time minimal trajectories for a spin 1/2 particle in a magnetic field[J]. Journal of Mathematical Physics, 2006, 47(6): 062101.
- [24] CARLINI A, HOSOYA A, KOIKE T, et al. Time-optimal unitary operations [J]. Physical Review A, 2007, 75(4): 042308.
- [25] KHANEJA N, REISS T, KEHLET C, et al. Optimal control of coupled spin dynamics: Design of NMR pulse sequences by gradient ascent algorithms. Journal of Magnetic Resonance, 2005, 172(2): 296-305.
- [26] CHEN Q M, WU R B, ZHANG T M, et al. Near-time-optimal control for quantum systems[J]. Physical Review A, 2015, 92(6): 063415.
- [27] YANG F, CONG S, LONG R X, et al. Exploring the transition-probability-control landscape of open quantum systems: Application to a two-level case[J]. Physical Review A, 2013, 88(3): 033420.