

基于高阶残差和参数共享反馈卷积神经网络的农作物病害识别

曾伟辉^{1,2}, 李 森¹, 李 增², 熊 焰²

(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, 安徽合肥 230027)

摘 要: 当前, 大部分农作物病害图像识别方法主要关注于精度而忽略了鲁棒性. 在面向实际环境时, 由于噪声干扰和环境因素影响导致识别精度不高. 为此提出了一种高阶残差和参数共享反馈的卷积神经网络模型以应用于实际环境农作物病害识别. 其中, 高阶残差子网络为病害表观提供丰富细致的特征表达, 以提高模型识别精度; 参数共享反馈子网络用来进一步抑制原深层特征中的背景噪声, 以提高模型的鲁棒性. 实验结果表明, 当面向实际环境农作物病害识别时, 本文方法在识别精度和鲁棒性上均优于其他方法.

关键词: 高阶残差; 参数共享反馈; 鲁棒性; 农作物病害识别

中图分类号: TP391.41

文献标识码: A

文章编号: 0372-2112 (2019)09-1979-08

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2019.09.023

High-Order Residual and Parameter-Sharing Feedback Convolutional Neural Network for Crop Disease Recognition

ZENG Wei-hui^{1,2}, LI Miao¹, LI Zeng², XIONG Yan²

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

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

Abstract: Most of current crop-disease recognition approaches mainly focus on improving the recognition accuracy on public datasets, while ignoring the recognition robustness. When dealing with real-world recognition problem, the actual recognition accuracy of those approach are often unsatisfactory because of noise interference and environmental influence. To address these issues, we propose a high-order residual and parameter-sharing feedback convolutional neural network (HORPSF) for crop-disease recognition. The high-order residual subnetwork is helpful for improving the recognition accuracy of crop disease. The parameter-sharing feedback subnetwork can effectively depress the background noises and enhance the robustness of the model. Extensive experiment results demonstrate that the proposed HORPSF approach significantly outperforms other competing methods in terms of recognition accuracy and robustness, especially demonstrating superior performance when dealing with the real-world examples of crop-disease recognition.

Key words: high-order residual (HOR); parameter-sharing feedback (PSF); robustness; crop disease recognition

1 引言

农作物病害识别是农作物病害防治的基础, 也是农作物产量和品质的重要保障. 传统农业农作物病害诊断主要依靠人眼判别. 然而由于农民缺乏专业知识, 农业专家又无法全方位、全天候在田间服务, 以致错失最佳防治时机. 近年来, 随着图像处理、模式识别、计算机视觉等技术在各个领域的快速发展, 利用计算机自

动识别和诊断农作物病害为以上问题提供了行之有效的解决方案.

农作物在感染病害后叶片上常出现一定形式的病斑, 这些病斑在颜色、纹理、形状等方面呈多样化、复杂化的特点, 如图1所示. 因此, 在农业领域常通过处理叶部病害图像来对农作物病害进行自动识别和诊断.

基于传统的图像处理方法的农作物病害识别相比于近年来兴起的基于深度神经网络的方法在识别精度



图1 本文构建的数据集AES-CD9214图片展示

和鲁棒性上都无法比拟. 当前基于神经网络的方法大多是在公开数据集 PlantVillage^[1] 或者简单背景图像上训练学习, 获取模型以实现农作物病害图像识别. 然而, 该类方法存在以下问题: 公开数据集 PlantVillage 背景简单, 农作物病害特征多样, 由于获取标注图像需要专家参与, 经常会导致类别不均衡, 直接将在 PlantVillage 上训练的模型迁移并不能得到很好的效果. 基于简单背景图像的病害识别方法在识别实际环境下农作物病害图像时, 需要抗击各种各样的噪声干扰因素, 实际的识别精度会大大降低, 无法满足识别准确率需求.

针对农作物病害图像识别具有背景复杂、干扰多、病害特征多样等特点, 本文兼顾模型的识别精度和鲁棒性, 提出了一种简单的高阶残差和参数共享反馈的卷积神经网络模型. 本文工作的主要贡献有以下几点:

(1) 提出了一种简单的高阶残差和参数共享反馈的卷积神经网络模型 (High-Order Residual and Parameter-Sharing Feedback Convolutional Neural Network, HORPSF) 以应用于农作物病害识别, 该网络包含高阶残差和参数共享反馈两个子网络, 分别用于提高网络的识别精度和鲁棒性.

(2) 为了进一步验证本文提出的 HORPSF 方法性能, 本文创建了一个的新数据集 AES-CD9214, 此数据集是在自然环境下采集, 包含了复杂背景、不同尺寸、拍摄角度、光照等因素的图片, 更加符合实际应用场景, 可以为实际环境农作物病害识别研究提供宝贵的数据资源.

(3) 大量实验结果表明, 本文提出的 HORPSF 方法具有识别精度高、鲁棒性强、抗干扰能力强等优点. 与其他方法对比, 在参数量更少的情况下, 本文 HORPSF 方法在公开数据集上测试表现优异. 此外, 当在 AES-CD9214 数据集上测试, 并给测试图片添加多种噪声干扰后, 本文方法表现出更高的识别精度和鲁棒性.

2 相关工作

在农作物生长过程中, 由于植物病原体多种多样, 会随着环境变化不断发展使得农作物受到浸染, 从而

发生各种病害, 最终影响农作物的产量和品质. 准确、鲁棒、抗干扰的识别农作物叶部病害是农作物安全生产的前提和重要保障, 也是目前农业生产生活中亟待解决的问题.

农作物病害图像识别是综合利用图像处理、植物病理学、模式识别等技术手段来分析病害图像信息, 得到病害的特征表示和分类模型, 从而达到准确地识别出病害类别的目的. 根据当前病害图像识别基本思想, 可以将识别方法分为以下两类.

2.1 基于传统图像处理方法的农作物病害图像识别

基于传统图像处理方法的农作物病害图像识别通常首先提取农作物叶片病斑的一些手工设计的特征, 再依据这些特征, 选择合适的分类器对病害图像进行分类. Omrani E 等^[2] 比较了 SVM 和 ANN 识别苹果三种病害的效果, 得出 SVM 识别效果更好. 王志彬等^[3] 利用动态集成的 10 个 BP 神经网络分类器实现了黄瓜三种病害和正常叶片的有效分类. 马浚诚等^[4] 构建了基于径向基核函数的 SVM 分类器以实现温室黄瓜霜霉病的识别与诊断. 詹曙等^[5] 提出了一种基于 Gabor 特征和字典学习的高斯混合稀疏表示图像识别算法, 提高识别的鲁棒性.

以上文献所述的基于图像处理的方法, 取得了一定的成果, 但是存在以下局限性: 前期预处理复杂, 耗时耗力; 手工设计的特征, 无法客观完整的描述病害图像信息, 容易导致语义鸿沟问题.

2.2 基于深度神经网络的农作物病害识别

基于深度神经网络的农作物病害图像识别通常采用卷积神经网络对输入图像提取特征, 直接输出该图像的类别概率, 是一种端到端的图像识别方法. Mohanty SP 等^[6] 使用 GoogLeNet^[7] 和 AlexNet^[8] 分类 PlantVillage 数据集中 14 种作物共 26 种简单背景病害图像, 得出 GoogLeNet 平均分类效果比 AlexNet 略好的结论. Nachti-gall LG 等^[9] 使用 AlexNet 模型对 6 种苹果病害图像进行识别, 准确率超过专家. Fuentes A 等^[10] 为检测番茄病虫害, 分别将 R-CNN^[11]、R-FCN^[12]、SSD^[13] 与 VGG-Net^[14] 和 ResNet^[15] 相结合, 以寻找适合的深度学习架构. 孙俊等^[16] 采用一种批归一化与全局池化相结合的卷积神经网络识别模型, 对 PlantVillage 中 26 种病害进行识别. 张航等^[17] 利用一个五层网络模型对背景较为简单的小麦六种病害进行识别. 柯圣财等^[18] 引入一个包含 5 个卷积层、3 个采样层和 1 个全连接层的卷积神经网络提取图像深层特征, 以增强图像特征区分性能和表达能力.

以上文献方法大多针对的是 PlantVillage 或者简单背景的图像识别, 当面向实际环境下带有复杂背景和噪声干扰的识别时, 由于复杂背景噪声干扰, 识别

准确率往往会大大降低. 因此如何提高实际环境农作物病害图像识别的精度、鲁棒性和抗干扰能力成为农作物病害识别研究的关键.

3 本文方法

本文旨在构建一个简单准确、抗干扰能力强、鲁棒性好的深度卷积神经网络以实现农作物病害图像高精度识别. 本节将首先介绍本文的高阶残差和参数共享反馈的卷积神经网络(HORPSF)的整体结构图; 然后, 分别介绍高阶残差子网络和参数共享反馈子网络; 最后, 介绍 HORPSF 方法的网络参数、采用的损失函数以

及实现细节.

3.1 网络整体结构图

本文提出的 HORPSF 方法实现农作物病害的准确识别, 兼顾识别的抗干扰能力和精确度. HORPSF 方法的网络整体结构如图 2 所示, 对于待分类病害图像, 本文通过 1 个卷积层、4 个残差模块、1 个参数共享反馈子网络、1 个全局平均池化层和 1 个 Softmax 层来直接输出该图像的分类概率, 以实现病害类别识别. 图 2 中绿色模块代表残差子网络(其结构如图 3), 黄色模块代表参数共享反馈子网络(结构如图 4).




图2 本文提出的HORPSF网络整体框架图




图3 残差子网络结构图

在图 2 中, 为了有效利用不同层的特征, 本方法中连接了前三个残差模块的输出. 因为在实验中我们发现, 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), 提高模型的识别准确率, 同时还可以间接提高网络的鲁棒性. 本文中将这种级联操作命名为高阶残差模块(High-Order Residual, HOR), 残差模块的结构如图 3 所示. 此外, 为了对图像特征进行精细过滤以提高其抗干扰能力, 本文在高阶残差子网络中间插入了一个参数共享反馈子网络, 其结构如图 4 所示.

3.2 高阶残差子网络

2015 年, 残差网络^[15]在 ILSVRC 上取得了很好的成绩. 残差网络不仅能加速网络拟合, 提高识别精度, 同时具有一定的抗干扰能力. 在此之前, 残差网络的作用在农作物病害识别中并没有引起足够的重视和研究. 实验过程中, 我们发现, 高阶残差网络对于深度网




图4 参数共享反馈子网络结构图

络模型的识别精度的提高具有很好的效果. 因此, 我们在网络结构中加入了高阶残差子网络.

本文提出的 HORPSF 网络中 HOR 结构如图 2 所示, 残差子网络结构如图 3 所示. 从图 3 可以看到, 本文的残差子网络中包含 3 个卷积层, 分别记为 CONV1、CONV2、CONV3. 当输入经过 CONV1、CONV2、CONV3 后的输出分别为 X_1 、 X_2 、 X_3 , 其详细参数在图 3 中已列出. 在图 3 中, 可以看到, X_1 和 X_3 的通道数相同, 可以直接级联起来, 黄色和操作符号表示对 X_1 和 X_3 做加法操作, X_1 和 X_3 之和作为整个残差子网络的总输出. 我们的残差子网络借助残差学习的思想, 卷积层学习残差函数 $F(x)$.

$$\text{假设 } H(x) = F(x) + X_1 = X_3 + X_1,$$

$$\text{则 } F(x) = H(x) - X_1 = X_3.$$

残差子网络通过对残差函数学习来获取图像中更突出的微小信息. 残差子网络实现了将经过 CONV1 卷积提取到的低层特征和经过 CONV1、CONV2、CONV3 三层

卷积获取到的高级细节特征同时传递到下面的网络结构中,继续进行更精细的特征提取.

综上所述,本文的 HOR 是将前三个残差子网络的输出级联,这样可以综合利用卷积神经网络中底层特征的细节描述和高层特征的抽象表达,为病害表现提供丰富细致的特征表达,从而有效提高模型的识别精度.为了验证 HOR 的作用,我们在公开数据集 PlantVillage 子集以及本文新创建的数据集 AES-CD9214 上进行实验,结果如表 1 所示.

表 1 卷积神经网络(CNN)引入和不引入 HOR 分类精度对比结果

数据集/方法	CNN without HOR	CNN with HOR
PlantVillage	0.8859	0.9179
AES-CD9214	0.8829	0.9014

从表 1 可以看到,加入 HOR 之后,在 PlantVillage 子集上识别精度由 0.8859 提升到 0.9179,而在 AES-CD9214 数据集上识别精度由 0.8829 提升到 0.9014.由此可见,引入 HOR 可以有效的提高识别准确率,这对于农作物病害识别具有重要意义.

3.3 参数共享反馈子网络

为了对实际环境下采集到的可能包含各种噪声因素的图像具有高识别精度和抗干扰能力,在本文的 HORPSF 方法中定义了一个新的参数共享反馈子网络(Parameter-Sharing Feedback, PSF),其结构如图 4 所示. PSF 是将卷积层重新加载,加载之后进行两次卷积,再将卷积结果返回到前面的浅层,重复加载之后作为输出传递到后面的网络层模型中.其中涉及到的卷积层为 3×3 的卷积核,步长为 1.我们可以从图 4 中看到 PSF 的整个流程.

本文引入 PSF 的目的是希望通过将网络中深层卷积层的特征反馈至浅层卷积层,对网络特征进行再一次的精细过滤调整,使得原深层特征中的背景噪声进一步被抑制,有效提高模型的鲁棒性.为了验证 PSF 的作用,我们同样在 PlantVillage^[1] 子集上以及 AES-CD9214 上进行实验,结果如表 2 所示.

表 2 卷积神经网络(CNN)引入和不引入 PSF 识别准确率对比结果

数据集/方法	CNN without PSF	CNN with PSF
PlantVillage	0.8859	0.9093
AES-CD9214	0.8829	0.8856

由表 2 可以看到,加入 PSF 之后,识别准确率在 PlantVillage 子集上由 0.8859 提升到 0.9093,而在 AES-CD9214 上由 0.8829 提升到 0.8856.由此表明,引入 PSF 可以在一定程度上提高识别准确率.值得注意的是,引入 PSF 的最大意义在于提高模型抗干扰能力,在实验部分将详细阐述.

3.4 网络参数与损失函数

本文 HORPSF 是一个简单准确,具有高鲁棒性的卷积神经网络.表 3 中列出了本文方法中采用的主要参数.其中, HOR 的参数详见图 3, PSF 参数详见图 4.从表 3 中可以看到,为了减少网络参数的数量,我们只使用 1×1 和 3×3 两种类型的核,这也有助于避免因为图像集过小而产生过拟合.

表 3 本文提出的 HORPSF 网络参数详情

层名	输出尺寸 ($h/w/c$)	滤波器尺寸 ($h \times w$)/stride
卷积层	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	-
反馈模块	32/32/64	-
残差模块 4	16/16/128	-
全局平均池化层	1×128	-
Softmax 层	1×6	-

本文方法中目标函数使用 Softmax,其公式如式(1).其中, $(\mathbf{X}_1, y_1), (\mathbf{X}_2, y_2) \cdots (\mathbf{X}_L, y_L)$ 是训练集, $\mathbf{X}_l$ 是第 l 个训练样本, $y_l \in 1, 2, 3, \dots, K$ 是 $\mathbf{X}_l$ 对应的标签; θ_k^T, θ_p^T 分别表示 θ_k, θ_p 的转置; L 和 K 分别表示训练样本数和类别数; $q(\cdot)$ 是引导函数.

$$J(\theta) = -\frac{1}{L} \left[\sum_{l=1}^L \sum_{k=1}^K q(y_l = k) \log \frac{e^{\theta_k^T \mathbf{X}_l}}{\sum_{p=1}^K e^{\theta_p^T \mathbf{X}_l}} \right] \quad (1)$$

3.5 方法实现细节

我们在三个数据集: MalayaKew 叶片集^[19]子集 MK-D2, PlantVillage^[1]子集和 AES-CD9214 上对 HORPSF 方法进行验证.在 NVIDIA GPU 1080i 的机器上,训练 100 个 epoch 大约需要 20 分钟.通常,经过 50 次迭代训练之后, HORPSF 便能够输出令人满意的精度.本文利用 Adam 最优优化算法对式(1)的损失函数进行优化,初始学习率为 2×10^{-3} .批处理大小设置为 120.在测试阶段,为了证明所提出的 HORPSF 网络的抗干扰能力,我们将不同等级的高斯和椒盐噪声加入到测试图像中,以测试网络的识别精度,评估网络的鲁棒性.

4 实验结果

4.1 数据集介绍

本文使用的实验数据集有三种: MalayaKew 叶片数据集子集 MK-D2、PlantVillage^[1]子集和 AES-CD9214. MalayaKew 数据集^[19]是从英国克佑的皇家植物园收集的叶片图像集,包括 MK-D1 和 MK-D2 两个子集. MK-D1 是整叶图像集. MK-D2 是将 MK-D1 中的整叶进行局部裁剪并经过多角度旋转扩充而成的局部叶片图集,包括 44 类图像,训练集和测试集中每类分别为 788 张

和 200 张图片. PlantVillage 数据集是一个包含有多种植物健康和病害图像的数据集,其中包含有 38 类,五万多张农作物病害和健康图像,并且每类图像数量不均衡. 本文选取 PlantVillage 中番茄的健康和 5 种病害图像共 10,478 张作为其子集,具体类别和数量如表 4 所列. MK-D2 和 PlantVillage 都是目前研究中广泛使用的作物病害图像集,具有简单背景,可以用来与现有方法进行识别对比实验,以验证本文方法的识别精度.

表 4 PlantVillage^[1]子集各类别名称以及对应的图像数量

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-二斑蜘蛛螨	番茄靶斑病
图像数量	2127	1591	1909	1771	1676	1404

数据集 AES-CD9214 是基于本研究团队在自然环境下使用 Canon EOS 6D 数码相机拍摄到的黄瓜和水稻两种作物共 6 种病害的 2,240 张原始图像,通过对原始图像进行边角裁剪扩充,剔除重复和未含有病斑的图像,最终形成尺寸为 256 * 256 的 9,214 张图像集即 AES-CD9214 图集. 该图集中图像包含各种噪声和环境因素如角度、光照等,其样例如图 1 所示. AES-CD9214 数据集中的类别数目不均衡,其类别名及其数量如表 5 所示. AES-CD9214 数据集对于识别方法具有挑战性,因为需要克服类别不均衡带来的某些类别训练不充分导致训练偏差的问题. 实际应用中,由于训练集的标注图像需要专家参与识别,病害发生种类也各不相同,会使得拍摄到的图像数量不均衡,带标注的图像集数量有限. 所以我们的 AES-CD9214 能够真实反应实际环境下农作物病害图像识别时的数据资源现状,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.

表 5 本文采集的 AES-CD9214 数据集中各类别名称以及对应的图像数量

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	3559	2741	795	763	780	576

实验中,我们将 PlantVillage 子集和 AES-CD9214 数据集中的图像按类别随机划分 20% 作为测试集,80% 作为训练集.

4.2 对比方法介绍

本文实验验证包括两种:(1)在 MK-D2 上,本文 HORPSF 方法与现有方法对比以验证识别准确率.(2)在 PlantVillage 子集及 AES-CD9214 数据集上,从精度和鲁棒性两方面对本文 HORPSF 方法进行详细的实验验证.

在 MK-D2 上实验中的对比方法包括文献[20]中的 LeafSnap SVM(RBF)方法、LeafSnap NN 方法;文献[21]中的 HCF SVM(RBF)方法、HCF-ScaleRobust SVM(RBF)方法、Combine 线性 SVM 方法;文献[22]中的 SIFT 线性 SVM 方法等.

文献[20]中 SVM(RBF)方法是使用径向基核函数的 SVM 分类器对叶片 gist 特征分类. 其中 SVM 分类器采用 libsvm^[23]来实现的. LeafSnap NN 方法是使用神经网络对 gist 特征进行分类识别. HCF SVM(RBF)分类器是使用 SVM(RBF)对文献[21]中表 1 中的手工设计的特征进行分类. HCF-ScaleRobust SVM(RBF)方法是对 HCF 特征中去除掉叶轮廓长度、面积和骨架长度之外的特征进行提取,并使用 SVM(RBF)分类器分类. Combine 线性 SVM 方法中的特征包括卷积神经网络 ConvNet^[24]提取的特征和 HCF-ScaleRobust 方法提取的特征. 其中 ConvNet 包括 5 个卷积层、3 个最大池化层和 2 个全连接层. HCF-ScaleRobust 提取的是在文献[21]表 1 中的手工设计的特征. 对两种方法提取到的特征使用 SVM 分类. SIFT 线性 SVM^[22]方法是通过提取 SIFT 特征,使用基于稀疏编码的线性空间金字塔匹配 SPM 核的简单线性 SVM 分类方法进行分类识别.

在对本文方法的详细讨论验证部分,本文采用了 CNN、PSF、HOR 和 HORPSF 四种方法进行对比实验. 其中 CNN 方法是过去除本文 HORPSF 模型结构中的高阶残差和参数共享反馈模块后得到的通用卷积神经网络,即无反馈无残差的卷积神经网络,包括 16 层卷积层、1 个最大池化层、1 个全局平均池化层和一个 softmax 层;PSF 方法指在 CNN 基础上添加参数共享反馈模块的方法;HOR 方法指在 CNN 基础上添加了高阶残差模块的方法.

4.3 与现有方法对比

为了验证本文 HORPSF 方法的精度,本文首先在 MK-D2 数据集上与现有方法进行识别准确率对比,实验对比结果如表 6 所示.

表 6 MK-D2 数据集上不同分类方法识别精度对比结果

方法	识别准确率	输入图片尺寸	网络层数	参数量
HORPSF	0.932	168 * 168	23	14,489,612
Combine SVM(线性) ^[21]	0.951	256 * 256	5	31,723,392
HCF ^[21]	0.716	256 * 256	—	—
HCF-ScaleRobust ^[21]	0.665	256 * 256	—	—
LeafSnap SVM(RBF) ^[20]	0.420	256 * 256	—	—
LeafSnap NN ^[20]	0.589	256 * 256	—	—
SIFT SVM(线性) ^[22]	0.588	256 * 256	—	—

从表 6 可以看出,本文的 HORPSF 方法明显优于除 Combine 线性 SVM 方法以外的其他方法. 虽然 Combine 线性 SVM 方法识别精度比本文方法略高(高 1.99%),但是它采用了一个复杂的网络且包含大量的特征提取、降维等预处理操作,方法复杂,预处理耗时耗力,参数量大,模型训练难度大. 而本文方法只采用了简单的网络实现了端到端的识别,卷积层尺寸小,参数量少,这样有效降低了模型训练的难度. 本文采用 168 * 168 规格图片作

为输入图片以进一步减少网络运算参数,总参数数量为 14,489,612,仅为 Combine 线性 SVM 方法中 ConvNet^[24] 参数数量的 45.675%。另外,在实际环境农作物病害识别时,由于标注图像集数量有限,参数量少可以更好缓解训练数据不足引起的过拟合问题。在下一节将进一步验证本文方法更适用于实际应用,能够实现类别不平衡的农作物病害图像的简单准确鲁棒的识别。

4.4 本文方法的详细讨论

4.4.1 无噪声干扰时的识别精确度对比

在不加噪声时,我们在 PlantVillage^[1] 子集和 AES-CD9214 上对识别准确率进行测试,对比结果如表 7 所示。

表 7 PlantVillage 子集和 AES-CD9214 上识别准确率对比结果

数据集/方法	CNN	PSF	HOR	HORPSF
AES-CD9214	0.8829	0.9014	0.8856	0.9257
PlantVillage	0.8859	0.9093	0.9179	0.9675

从表 7 中,可以看到,在 PlantVillage 子集上,当采用通用卷积网络 CNN 时,识别准确率为 0.8859;当分别加入参数共享反馈模块 (PSF)、高阶残差模块 (HOR) 时,准确率分别提升到 0.9093、0.9179。相比 CNN、PSF 以及 HOR 方法,本文的 HORPSF 方法达到了最高的识别准确率 0.9675。在更加符合实际环境的 AES-CD9214 数据集上,我们观察到了相似的实验结

果, HORPSF 方法获得了最高识别准确率 0.9257。这充分说明了当结合高阶残差和参数共享反馈模块时可带来更高的识别精度,这对于农作物病害识别以及其他领域的识别问题都具有重要的启发意义和参考价值。

4.4.2 添加不同噪声时的识别鲁棒性对比

为了验证本文提出的 HORPSF 方法的鲁棒性,我们在 PlantVillage 子集和 AES-CD9214 数据集的测试集中分别添加 0.005 至 0.03 等级的高斯噪声、椒盐噪声、同时添加高斯和椒盐噪声等,以测试本文方法在加入不同等级噪声干扰时的识别准确率,从而评估模型的鲁棒性。本实验测试集添加的噪声等级间隔为 0.005。

4.4.2.1 数据集 PlantVillage 上的测试

图 5 展示了 PlantVillage 子集上识别准确率对比结果。在图 5 中,横坐标表示添加的噪声等级,纵坐标是测试获得的识别准确率。从图 5 中可明显的看到,红色曲线(对应 HORPSF 方法)的识别准确率均高于其他方法;当添加噪声后,识别准确率会降低,这是因为添加噪声会影响网络模型对图像病斑有效特征的提取,进而影响模型准确识别。同样道理,识别准确率会随着噪声等级的增加而降低。因为随着等级增加,可供提取的病斑区域有效像素数量会逐渐减少,导致模型难以获得准确的预测类别。




图 5 PlantVillage 子集测试集上添加不同等级和不同种类噪声的识别准确率测试结果

从图 5(a) 可看到,当添加 0.005 等级的高斯噪声时,四种方法识别准确率均会有不同程度的衰减:除 HORPSF 方法外, HOR 方法识别准确率衰减最小,从 0.9179 下降到 0.6520,即衰减了 29.11%;而 HORPSF 方法只衰减了 15.39%。当添加其他等级的噪声时,同样可以看到 HORPSF 方法识别准确率衰减最慢。由此可见, HORPSF 方法对于高斯噪声的抗干扰能力相比 CNN、PSF 和 HOR 方法更强。从添加椒盐噪声、同时添加高斯噪声和椒盐噪声测试的结果同样可以得出类似的结论。由此可得,在对 PlantVillage 子集测试集中添加不同等级的噪声时,本文的 HORPSF 均具有高准确率和强鲁棒性。

4.4.2.2 数据集 AES-CD9214 上的测试

在 AES-CD9214 的测试集中添加不同等级噪声后的识别准确率测试结果如图 6 所示。

在图 6 中,显而易见,整体上, HORPSF 在加入不同等级的高斯、椒盐、高斯和椒盐噪声时,其识别准确率相比其他方法都是最高的。从图中曲线的变化趋势可以看出,对应本文 HORPSF 方法识别准确率的红色曲线在加入不同等级噪声干扰时,其变化最缓慢,说明其衰减最慢,对噪声的抗干扰能力最强。这是因为 HORPSF 中引入的高阶残差子网络为病害表现提供丰富细致的特征表达,有效提高模型的病害识别精度;参数共享反馈子网络使得原深层特征中的背景噪声进一步被抑制,能有效提高模型的鲁棒性。本文的 HORPSF 方法中两者同时发挥作用,使得 HORPSF 方法在面向实际环境农作物病害图像识别时,具有高精度、强鲁棒性和良好的实际应用性能。




图6 在挑战性数据集AES-CD9214测试集上添加不同等级和不同种类噪声的识别准确率测试结果

5 总结

为了提高农作物病害识别的准确率和鲁棒性,本文引入了一种高阶残差和参数共享反馈的卷积神经网络(HORPSF)。同时,为了验证本文方法,本文分别在公开数据集 MK-D2 和自然环境下的农作物病害数据集 AES-CD9214 上进行了相应的实验。经过大量的实验验证,本文的 HORPSF 方法在相同的测试数据集上具有更高的精度和鲁棒性,具有很强的抗干扰能力,能获得很好的识别效果。下一步,我们将考虑在网络模型中加入更多的残差网络模块和反馈模块,扩充训练数据,进一步优化模型结构,提高网络识别精度和鲁棒性。

参考文献

- [1] 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.
- [2] Omrani E, Khoshnevisan B, Shamshirband S, et al. Potential of radial basis function-based support vector regression for apple disease detection[J]. Measurement, 2014, 55(1): 512–519.
- [3] 王志彬, 王开义, 王书锋, 等. 基于动态集成的黄瓜叶部病害识别方法[J]. 农业机械学报, 2017, 48(9): 46–52. Wang Zhibin, Wang Kaiyi, Wang Shufeng, et al. Recognition method of cucumber leaf diseases with dynamic ensemble learning[J]. Chinese Society for Agricultural Machinery, 2017, 48(9): 46–52. (in Chinese)
- [4] 马浚诚, 温皓杰, 李鑫星, 等. 基于图像处理的温室黄瓜霜霉病诊断系统[J]. 农业机械学报, 2017, 48(2): 195–202. Ma Juncheng, Wen Haojie, Li Xinxing, et al. Downy mildew diagnosis system for greenhouse cucumbers based on image processing[J]. Chinese Society for Agricultural Machinery, 2017, 48(2): 195–202. (in Chinese)
- [5] 詹曙, 王俊, 杨福猛, 等. 基于 Gabor 特征和字典学习的高斯混合稀疏表示图像识别[J]. 电子学报, 2015, 43(03): 523–528. Zhan Shu, Wang Jun, Yang Fumeng, et al. Gaussian mixture sparse representation for image recognition based on gabor features and dictionary learning[J]. Acta Electronica Sinica, 2015, 43(03): 523–528. (in Chinese)
- [6] Mohanty S P, Hughes D P, Salathe M, et al. Using deep learning for image-based plant disease detection[J]. Frontiers in Plant Science, 2016, 7(1): 1–7.
- [7] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions[A]. IEEE Conference on Computer Vision and Pattern Recognition[C]. Boston: IEEE, 2015. 1–9.
- [8] Krizhevsky A, Sutskever I, Hinton G E, et al. ImageNet classification with deep convolutional neural networks[A]. NIPS12 Proceedings of the 25th International Conference on Neural Information Processing Systems[C]. Lake Tahoe, Nevada: IEEE, 2012. 1097–1105.
- [9] Nachtigall L G, Araujo R M, Nachtigall G R, et al. Classification of apple tree disorders using convolutional neural networks[A]. 28th IEEE International Conference on Tools with Artificial Intelligence[C]. San Jose, CA, USA: IEEE, 2016. 472–476.
- [10] Fuentes A, Yoon S, Kim S C, et al. A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition[J]. Sensors, 2017, 17(9): 1–21.
- [11] Ren S, He K, Girshick R B, et al. Faster R-CNN: towards real-time object detection with region proposal networks[A]. Neural Information Processing Systems[C]. Montréal, Canada: IEEE, 2015. 91–99.
- [12] Dai J, Li Y, He K, et al. R-FCN: object detection via region-based fully convolutional networks[A]. NIPS'16 Proceedings of the 29th International Conference on Neural Information Processing Systems[C]. Barcelona: IEEE, 2016. 379–387.
- [13] Liu W, Anguelov D, Erhan D, et al. SSD: single shot multibox detector[A]. European Conference on Computer Vision[C]. Amsterdam: Springer, 2016. 21–37.
- [14] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[A]. International Conference on Learning Representations[C]. San Diego:

- IEEE, 2015. 1 – 14.
- [15] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. Las Vegas, Nevada: IEEE, 2016. 770 – 778.
- [16] 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 Chinese Society of Agricultural Engineering, 2017, 33 (19): 209 – 215. (in Chinese)
- [17] 张航, 程清, 武英洁, 等. 一种基于卷积神经网络的小麦病害识别方法 [J]. 山东农业科学, 2018, 50 (3): 137 – 141.
- Zhang Hang, Cheng Qing, Wu Yingjie, et al. A method of wheat disease identification based on convolutional neural network [J]. Shandong Agricultural Sciences, 2018, 50 (3): 137 – 141. (in Chinese)
- [18] 柯圣财, 赵永威, 李弼程, 等. 基于卷积神经网络和监督核哈希的图像检索方法 [J]. 电子学报, 2017, 45 (01): 157 – 163.
- Ke Shengcai, Zhao Yongwei, Li Bicheng, et al. Image retrieval based on convolutional neural network and kernel-based supervised hashing [J]. Acta Electronica Sinica, 2017, 45 (01): 157 – 163. (in Chinese)
- [19] 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, 71 (1): 1 – 13.
- [20] Kumar N, Belhumeur P N, Biswas A, et al. Leafsnap: a computer vision system for automatic plant species identification [A]. European Conference on Computer Vision [C]. Firenze, Italy: Springer, 2012. 502 – 516.
- [21] Hall D, Mccool C, Dayoub F, et al. Evaluation of features for leaf classification in challenging conditions [A]. IEEE Workshop on Applications of Computer Vision [C]. Waikoloa Beach, Hawaii: IEEE, 2015. 797 – 804.
- [22] Yang J, Yu K, Gong Y, et al. Linear spatial pyramid matching using sparse coding for image classification [A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. Miami, Florida: IEEE, 2009. 1794 – 1801.
- [23] Chang C, Lin C. LIBSVM: a library for support vector machines [J]. ACM Transactions on Intelligent Systems and Technology, 2011, 2 (3): 1 – 27.
- [24] Douze M, Jegou H, Sandhawalia H, et al. Evaluation of GIST descriptors for web-scale image search [A]. Proceeding of the ACM International Conference on Image and Video Retrieval [C]. Santorini Island, Greece: ACM, 2009. 1 – 19.

作者简介



曾伟辉 女, 1982 年生于陕西咸阳. 中国科学院合肥智能机械研究所副研究员, 博士研究生. 研究方向为计算机视觉与农业信息处理.
E-mail: whzeng@iim.ac.cn



李森 女, 1955 年生于安徽庐江. 中国科学院合肥智能机械研究所研究员, 博士生导师. 研究方向为人工智能和农业知识工程.
E-mail: mli@iim.ac.cn



李增 男, 1989 年生于河南商丘. 中国科学技术大学博士研究生. 研究方向为数据挖掘、数据管理和信息安全.
E-mail: lizeng@mail.ustc.edu.cn



熊焰 (通信作者) 男, 1960 年出生于安徽合肥. 中国科学技术大学计算机学院教授, 博士生导师. 研究方向为分布式处理、移动计算、计算机网络和信息安全.
E-mail: yxiong@ustc.edu.cn