

基于自监督域自适应网络的苹果叶部病害识别*

程超¹, 吕佳^{1,2}, 范亚洲¹

(1. 重庆师范大学 计算机与信息科学学院; 2. 重庆市数字农业服务工程技术研究中心, 重庆 401331)

摘要:为解决现实农业生产环境中的苹果叶部病害识别较为困难的问题,提出一种基于自监督域自适应网络的识别模型。该模型首先引入域自适应的方法,通过苹果叶部图片源域与目标域数据集的联合训练,减少源域到目标域的域偏差,增强预训练的模型在目标域上的泛化能力;其次添加自监督模块并引入一种对比损失,使模型在特征空间上学习到病变区域更为细致的表征信息,从而有效增强对相似症状的辨别能力,提高模型的分类性能。模型在具有复杂背景的公共苹果数据集上进行实验,结果表明所提模型对各类病害的平均识别准确率为 91.31%,实现了较高的分类准确度。所提模型与其他流行的卷积神经网络方法相比,实验结果有一定的提升,验证了提出的模型在实际生产环境中对苹果叶部病害识别上的有效性。

关键词:苹果叶部病害识别;域自适应;自监督;对比损失

中图分类号:TP391.4

文献标志码:A

文章编号:1672-6693(2024)03-0089-11

据 2024 年病虫害发生趋势预报,中国病虫害累计发生面积约 1.553 亿 hm^2 次^[1]。中国作为农业大国,农作物的病虫害防治一直都是重要工作之一。作为重要的水果作物,苹果一旦感染病虫害,就必须及时加以识别和治疗,才能防止病虫害蔓延造成经济损失。叶部病害是苹果树生长过程中最常见的问题之一。苹果叶部病害会导致苹果树的叶片变黄、干枯掉落,进而影响果实的生长和品质,严重时甚至会导致果树死亡。因此,快速、准确地识别苹果叶部病害,对于保障苹果生产的质量和数量,具有非常重要的意义。

近些年来,卷积神经网络(convolutional neural networks, CNN)正迅速成为农业生产中进行苹果叶部病害识别的首选方法^[2]。Li 等人^[3]提出了一种使用名为 RegNet 的轻量级卷积神经网络对苹果叶病进行识别和分类的新方法,这一方法在识别不同类型的苹果叶病方面实现了很高的准确性,在测试集上实现了 99.23% 的总体准确率,优于其他预先训练的模型。Chao 等人^[4]为了提高对苹果叶部病害早期诊断的检测精度,提出了一种基于深度卷积神经网络的模型,该模型结合了 DenseNet 和 Xception,使用全局平均池替代全连接层,利用卷积神经网络提取特征,然后利用支持向量机对苹果叶片病害进行分类,在数据集上的总体准确率为 98.82%,实现了很好的识别效果。Yu 等人^[5]基于残差网络 ResNet50 提出了一种(multi-step optimization ResNet, MSO-ResNet)苹果叶病识别模型。该模型通过分解卷积核、更新身份映射方法、减少残差模块的数量和替换批量归一化层来提高模型的识别精度和速度,并减少模型参数的数量。Bedi 等人^[6]为了减少模型的训练参数提出了一种基于卷积自动编码器(convolutional auto encoder, CAE)网络和卷积神经网络的混合模型用于苹果叶部病害的识别,该混合模型仅使用了 9 914 个训练参数,在 PlantVillage 数据集上实现了 98.38% 的测试准确率。李大湘等人^[7]针对苹果叶部病害图像类间差异小、类内差异大的特点,设计了一种基于全局与局部特征交互的耦合特征提取方法。该方法包括全局和局部特征提取分支以及多头交叉注意力特征耦合模块。实验结果表明,该方法识别准确率可达到 98.23%,较单纯的局部或全局特征提取分支提高了 3.39% 和 4.61%。Wang 等人^[8]提出了一种改进的基于 YoloV5s 的苹果叶病识别模型 GSE_YoloV5s,该模型通过 GhostBottleneck 模块用于取代原来的 CSPBottleneck 模块并且添加通道注意力模块 SE,有效地解决了 YoloV5s 模型的高存储和计算资源消耗问题。实验结果表明,与 YoloV5s 模型相比,改进的 GSE_YoloV5s 模型可以减少 40% 的参数数量和计算工作量,平均

* 收稿日期:2023-04-20 修回日期:2024-03-08 网络出版时间:2024-06-07T15:35

资助项目:重庆市高校创新研究群体(No. CXQT20015)

第一作者简介:程超,男,研究方向为农业图像处理,E-mail:edison_chengc@163.com;通信作者:吕佳,女,教授,博士,博士生导师,E-mail:lvjia@cqnu.edu.cn

网络出版地址:https://link.cnki.net/urlid/50.1165.N.20240607.1501.016

精度达到 83.4%,可以有效地检测苹果叶片病害。虽然上述研究都取得了对苹果叶部病害较高的识别准确率,但所研究的病害图片背景大多相对简单,且为实验室受控环境下采集;而实际农业生产环境中采集的图片易受光照、天气、拍摄角度等因素的影响,图片之间存在较大差异,这使得模型不能很好地应用到真实生产环境中。同时对于叶片相似症状病变区域而言,由于叶片颜色、形状和纹理基本一致,导致病变区域相似程度大幅增加,需要模型实现更加细致的病害类别间差异化判别特征提取和表示。

因此,本文提出了一种基于自监督域自适应网络的苹果叶部病害识别模型(self-supervised domain adaptive network, SSDANet),该模型通过引入动态域自适应的方法实现对苹果叶部病害图片的识别分类,同时添加自监督模块并引入对比损失,使模型更好的关注作物病变区域的特征信息,实现更高的分类准确度。

1 本文方法

1.1 自监督域自适应模型结构

在实际的农业生产环境中,由于获取的苹果叶部病害图片的拍摄环境易受视角、背景、光照和天气等因素的影响,且图片中包含的病害叶片外观和位置等也存在差异,使得源域和目标域之间的数据差异较大,源域训练的模型不能很好地应用到目标域。而深度域自适应^[9-12]方法可以通过在源域和目标域之间引入域适应层,减少两域的域偏差,提高源域训练的模型对目标域的分类性能。同时由于苹果叶片颜色、形状和纹理基本一致,这导致部分叶片病变区域相似度大幅增加,从而需要模型能够有效识别出相似病害叶片。自监督方法可以通过预先构造辅助任务的方式来进行损失计算,脱离标签学习叶片潜在空间的语义信息,这种细粒度信息能够增强模型对相似病害的鉴别能力。本文的自监督域自适应模型结构如图 1 所示。模型在域自适应方法上引入自监督模块,其中域自适应方法以预训练的 ResNet50 作为特征提取器,主要功能是负责对输入图片的特征信息进行提取,最后通过主分类器得到每一类的类别概率,并对对比标签信息计算交叉熵损失,自监督模块作为多任务之一被引入。




图 1 模型结构

Fig. 1 Model structure

图 1 中: x_s 、 x_t 分别表示源域和目标域的输入数据; y_s 表示源域的标签; x_t 作为自监督模块的输入,在经过特征变换后得到 x_i ; x_j 是同一批次中输入的其他图片。值得注意的是,对于 x_t 而言, x_i 被定义为它的正样本数据,而 x_j 被定义为它的负样本数据。自监督模块通过不断拉近输入数据和它的正样本的距离,推开与它的负样本之间的距离来达到样本自身细粒度特征学习的能力。模型在训练开始前,标记的源域图片和未标记的目标域图片一起被输入模型。其中,在每轮训练开始时,源域中有标记数据被送入域自适应模块,通过分类预测和标签值计算损失。与此同时,目标域中的无标签数据被送入自监督模块,通过特征变换操作得到正样本,并将除它之外的其他样本视为负样本进行损失计算。模型在特征学习过程中,依赖于域自适应模块的同时,还考虑到了自监督模块提供的细粒度语义信息。最后,在反向传播过程中联合多任务损失多次迭代训练优化参数。

1.2 自监督模块

自监督学习(self-supervised learning, SSL)基本上分为 2 种学习范式:对比学习和生成性学习。对比学习

通过学习对 2 个事物的相似或不同进行编码来构建表征^[13-14]。生成式学习通过自动编码器等模型生成不同的上下文信息,并允许网络学习其中的关联^[15-16]。目前,对比学习在表征学习^[17]方面取得了很好的成绩。受此启发,为了使自监督模块更有目的地学习关于叶部病变区域细粒度的信息,引入了一种 InfoNce 损失^[18],使得模块能够更好地学习到图片位于潜在空间的特征信息。自监督模块如图 2 所示。




图 2 自监督模块

Fig. 2 Self-supervised model diagram

由图 2 可以看出,在任务开始时给定一个未标记的图片,用作自监督模块的输入,然后通过特征转换将它旋转 90°后得到新的图片 x_i 。并将 x_i 和同一批次中的其他图片 x_j 一起送入特征提取器(预训练好的 Resnet50),通过特征提取器将输入数据映射到新的向量空间。在新的向量空间中,相同颜色的特征向量被定义为互为正样本,不同颜色的特征向量被定义为互为负样本。通过 InfoNCE 损失迫使互为正例样本的向量彼此靠近,互为负例样本的向量彼此远离。值得注意的是,这种策略的损失计算完全脱离了标签的约束,在训练过程中样本自身存在的潜在特征能够被模块提取,从而使得整个分类模型能够有效学习到特征的细粒度信息。

1.3 损失函数

本文提出的 SSDANet 模型损失函数由 2 部分组成:域自适应方法的损失和自监督模块的损失。对于域自适应方法,网络的交叉熵损失为:

$$l = l_m(D_s, y_s) + \lambda l_d(D_s, D_t), \quad (1)$$

其中: $l_m(D_s, y_s)$ 为主分类模型在源域的损失, $l_d(D_s, D_t)$ 为网络的动态自适应损失, λ 为权衡参数。

利用对比损失对自监督模块进行约束,对比损失 l_s 采用 InfoNCE 损失,损失定义为:

$$l_s = -\log \frac{\exp(\text{sim}(h_i, h_j))}{\sum_{k=1}^{n-1} \exp(\text{sim}(h_i, h_k))}, \quad (2)$$

其中: $k \neq i$, n 为 1 个批次样本数量, k 为这个批次中判定为负样本的数量, $\text{sim}(\cdot, \cdot)$ 为余弦相似度计算公式。

最后,本文提出模型的总体损失为:

$$l_{\text{total}} = l + l_s. \quad (3)$$

2 实验结果与分析

2.1 实验数据集

为了验证模型对在实际生产环境下采集的数据集的有效性,本文采用 kaggle 举办的 2021 年苹果叶部病理学挑战赛数据集作为实验数据,网址为(<https://www.kaggle.com/c/plant-pathology-2021-fgvc8>),该数据集是在真实农业生产环境中使用数码单反相机和智能手机在各种光照、角度、表面和噪音条件下拍摄的苹果数据集,包含 12 个不同类别(按“病害-程度”分),共 18 632 幅。图 3 为包含数据集中所有 12 类叶部病害的部分图片。

对数据集进行整理时发现其中出现了样本数量不足、类别不平衡等问题,当样本分布失衡时,模型可能会出现过拟合等问题,并且可能难以提取某些类别的特征,因此需要进行预处理操作。使用图片变换来增加数据集中的图像数量,从而构建更多自然条件下的病害识别场景,进而增强模型的鲁棒性。数据增强操作包括以下 4 种:




图 3 包含数据集中所有 12 类叶部病害的部分图片

Fig. 3 All types and partial leaf images in the dataset

- 1) 图像旋转:对所有图片进行 90° 、 180° 和 270° 旋转,模拟拍摄设备的不同拍摄角度;
- 2) 图像翻转:对所有图片沿着水平方向翻转,模拟拍摄设备不同拍摄角度;

3) 随机亮度增强和减弱:对所有图片进行随机亮度增强或者减弱,模拟真实田间环境下苹果叶片在不同的光照情况下的场景;

4) 随机噪声:对所有图片加入随机噪声,模拟真实田间环境下苹果叶片在夜间和恶劣天气等条件下含噪的情况。

通过查看数据集,发现数据集中图片尺寸大小不一致,图片宽度和高度不统一。这样的图片无法输入到深度学习网络模型中进行训练,因为本文采用的基础模型为 ResNet50,该模型的要求输入图片尺寸为 224×224 ,因此需要对该苹果数据集图片尺寸进行预处理操作。本文采用将图像数据压缩为 224 像素 $\times$ 224 像素的方法,这样的方法既可以满足 ResNet50 模型对输入图片对尺寸大小的要求,同时又能最大限度的保留图片的主要信息。苹果叶部病害图片调整前后的图像如下图 4 所示。




图 4 图片调整前后对比

Fig. 4 Comparison before and after image adjustment

图 5 为数据集中应用上述 4 种数据增强操作的部分叶部图片。最终,利用数据增强技术,扩充后的数据集的大小为 23 325 幅图片。




图 5 数据增强操作后的部分图片

Fig. 5 Partial images after data augmentation operation

2.2 评价指标

在苹果叶部病害识别分类中,苹果叶片的病害被分类为真阳性(TP)、假阳性(FP)、假阴性(FN)和真阴性(TN),并与相应的真标签进行比较。然后,通过准确率(accuracy, x_{acc})、查准率(precision, P)、查全率(recall, R)、 $F1$ 值($F1$ -score, $F1$)和混淆矩阵来评估模型的性能。各指标定义如表 1 所示。

表 1 评价指标
Tab. 1 Evaluation index

指标	定义	指标	定义
x_{acc}	TP、TN 总和与 TP、TN、FN、FP 总和之比	R	TP 与 TP、FN 总和之比
P	TP 与 TP、FP 总和之比	$F1$	2 倍 TP 与 2 倍 TP、FP、FN 总和之比

混淆矩阵可以直观地体现模型在各个类别上的分类情况;准确率反映了分类模型预测正确的样本数占总样本数的比例;查准率反映了在所有被分类模型预测为正类的样本中,实际为正类的样本数比例;查全率反映了在所有实际为正类的样本中,被分类模型正确预测为正类的样本数比例; $F1$ 值综合了查准率和查全率,是准确率和查全率之间的调和平均值。它们的取值范围都为 $[0,1]$,取值越大表示分类模型性能越好。

2.3 实验环境及参数设置

针对苹果叶部病害数据,将本文提出的模型与以下模型进行比较:

- 1) AlexNet^[19]:首次在 CNN 中成功应用了 ReLU、Dropout 和 LRN 等,获得了 ImageNet 2012 图像识别挑战赛冠军;
- 2) VGG-16^[20]:VGGNet 由 AlexNet 发展而来的,VGG16 包含了 16 个隐藏层(由 13 个卷积层和 3 个全连接层构成);
- 3) GoogLeNet^[21]:提出了名为 Inception 的模块化结构来保持神经网络结构稀疏性的同时充分利用密集矩阵的高计算性能,获得了 ImageNet 2014 图像识别挑战赛冠军;
- 4) ResNet50^[22]:ResNet 网络模型中提出了残差块的结构以此缓解在深度神经网络中增加深度带来的梯度消失问题,在 ImageNet 2015 的图像分类比赛中获得了冠军,Resnet50 网络中包含 49 个卷积层、1 个全连接层;
- 5) DenseNet121^[23]:DenseNet121 是 DenseNet(dense convolutional network)系列模型中的一种,DenseNet 在网络中引入密集连接(dense connection),DenseNet121 总共包含 121 层,其中有 4 个密集块,每个密集块包含不同数量的卷积层和过渡层,以及 1 个全局平均池化层和 1 个全连接层;
- 6) EfficientNet B0^[24]:EfficientNet B0 是 EfficientNet 系列中的一种模型,EfficientNet B0 的网络结构使用了一种名为“复合缩放”(compound scaling)的方法,通过同时扩大网络深度、宽度和分辨率,在保持计算资源不变的情况下提高网络的性能;
- 7) RegNetY_400MF^[25]:RegNetY_400MF 是 RegNet(Regularized neural networks)系列中的一种模型,RegNetY_400MF 的网络结构基于网络深度和宽度的缩放规律进行设计,拥有 400 万个模型参数;
- 8) SSDANet-SSL:本文提出的 SSDANet 方法不考虑自监督模块。

本实验的 SSDANet 模型采用 ImageNet 上预先训练的 ResNet50 作为基准网络,将 ResNet50 模型网络结构中全连接层的输出设置为本文数据集的病害类别种类数,本实验设置为 12。源域数据有标签,目标域数据为无标签。同时本实验中涉及到深度迁移学习的模型 AlexNet、VGG16、GoogLeNet、ResNet50、DenseNet121、EfficientNet B0 和 RegNetY_400MF 均为已经在 ImageNet 上预训练好的模型,并针对本文实验采用微调策略。随机选取增强后数据集的 70%作为训练集,20%作验证集,剩下的 10%作为测试集。由于采用了预训练,模型收敛很快,所以每个模型共迭代 50 次,批次大小设置为 32。模型采用随机梯度下降优化算法(Stochastic gradient descent,SGD)进行优化,权衡参数 λ 设置为 0.3,初始学习率设置为 0.01,每次迭代学习率减小为原来的 10%,正则化系数设置为 0.000 5。实验用的环境配置如表 2 所示。

2.4 实验结果及分析

在设置相同的实验环境和模型参数的条件下,用本文提出的 SSDANet 模型以及上述识别模型分别在数据增强后的数据集上进行实验。SSDANet 模型在数据集验证集上的识别准确率见表 3。

从表 3 结果中可以看出,本文提出的模型具有较高的准确率。在使用了数据增强的数据集识别准确率达到

了 91.31%,相比原始数据集准确率提高了 0.6%。这说明数据增强技术起到了一定的作用,增加了网络提取的特征,提高了模型对苹果叶部病害的识别准确率。

表 2 实验环境

配置单元	型号
CPU	Intel Xeon E-2 186 M @ 2.90 GHz 六核
显卡	NVIDIA Quadro P5200(16 GB/惠普)
内存	海力士 DDR4 2 666 MHz(64 GB)
硬盘	三星 MZVLB2T0HMLB-000H1(2 TB)
操作系统	Windows 10 64 位
编程语言	Python 3.6.5
CUDA	11.1

表 3 验证集分类准确率

数据集	图片数量/幅	x_{acc}
原始数据集	18 632	90.71%
增强数据集	23 325	91.31%

2.4.1 消融实验

在基准网络模型 ResNet50 上引入域自适应方法和自监督模块,在使用数据增强后的数据集进行实验,验证所提出 SSDANet 模型的性能。消融实验结果如表 4 所示。

表 4 消融实验结果

算法	评价指标			
	P	R	$F1$	x_{acc}
Resnet50	79.87%	73.52%	75.64%	86.98%
SSDANet-SSL	84.01%	84.08%	82.75%	90.94%
SSDANet	84.83%	84.39%	83.36%	91.31%

根据表 4 显示的实验结果,SSDANet 模型在数据集获得了最高的准确率。在 ResNet50 模型基础上引入域自适应方法后,实验结果对比 ResNet50 模型,识别准确率提升了 3.96%。在域自适应方法上引入自监督模块后,对比 ResNet50 模型,识别准确率提升了 4.33%;对比 SSDANet-SSL 模型,识别准确率提升了 0.37%。各模型在数据集上的具体学习情况如图 6 所示。




图 6 各模型准确率曲线

Fig.6 Accuracy curve of each model

根据图 6 可以看出,由于采用 ImageNet 上预训练的 ResNet50 作为基准网络,3 个模型收敛得都很快,在第 1 个 epoch 都达到了 75%以上的识别准确率。SSDANet 模型和 SSDANet-SSL 模型收敛曲线稳定性都好于基准网络 ResNet50,这表明域自适应方法在数据集上有较强的适应性,域自适应方法能提高分类模型在目标域上的泛化性,同时加入的自监督模块对病害识别准确率的提升也有一定帮助。通过上述分析,可以看出提出的 SSDANet 模型的性能优于 ResNet50 模型和 SSDANet-SSL 模型,SSDANet 模型可以对叶部病害实现较高的分类准确率。

为了进一步证明 SSDANet 模型的有效性,下面将从查准率、查全率和 $F1$ 值来说明 SSDANet 模型在性能上的优势。实验结果中,查准率分别提升了 0.82%,查全率分别提升了 0.31%, $F1$ 值分别提升了 0.61%。在这 3 项指标上,SSDANet 模型对比 ResNet50 模型和 SSDANet-SSL 模型,在数据集上都表现最佳,实现了最优的分类性能。

通过分析发现,SSDANet 模型对比基准网络模型 ResNet50 各项性能提升明显,对比 SSDANet-SSL 模型各项性能也有一定提升,这表明域自适应网络可以实现很好的分类性能,同时加入的自监督模块能够提升对于叶部病害的识别分类性能。通过消融实验验证了 SSDANet 模型识别叶部病害的有效性。

2.4.2 算法性能对比

为进一步验证本文提出的 SSDANet 模型的有效性,将所提出的模型的性能与较为经典的卷积神经网络模型进行了比较。所提出的模型和 AlexNet、VGG16、GoogLeNet、DenseNet121、EfficientNet B0 和 RegNetY_400MF 这 6 种模型验证在数据集上的性能如表 5 所示。

表 5 各模型性能
Tab. 5 Performance of each model

算法	评价指标			
	P	R	$F1$	x_{acc}
AlexNet	71.02%	63.89%	66.23%	76.69%
GoogLeNet	74.55%	68.52%	70.74%	79.89%
VGG16	75.69%	76.04%	72.79%	81.06%
DenseNet121	78.23%	78.02%	76.61%	87.85%
EfficientNet B0	79.54%	78.44%	77.64%	89.27%
RegNetY_400MF	76.64%	76.98%	74.98%	86.26%
SSDANet	84.83%	84.39%	83.36%	91.31%

各模型在数据集上的具体学习情况如图 7 所示。

从表 5 和图 7 可知,与上述几种卷积神经网络模型对比,SSDANet 模型在数据集上实现了最优的分类性能。在实验结果中,对比识别准确率最高的 EfficientNet B0、DenseNet121 和 RegNetY_400MF 这 3 个模型,识别准确率分别提升了 2.04%、3.46%和 5.05%。在查准率、查全率和 $F1$ 值这 3 项指标上,所提出的 SSDANet 模型的分值同样都高于其他算法,对比 3 个模型中整体性能最好的 EfficientNet B0 模型,查准率、查全率和 $F1$ 值分别提升了 5.29%、5.95%和 5.72%,效果明显。通过对比实验,可以看出 SSDANet 模型对真实农业生产环境中的数据实现了较好的分类效果,进一步验证了本文提出的 SSDANet 模型的性能。

SSDANet 模型在数据集上的混淆矩阵如图 8 所示。混淆矩阵图中,横轴表示真实标签类别,纵轴表示预测标签类别。图像右侧的蓝黑色条形图表示不同数值,混淆矩阵中的不同颜色也表示不同数值,均为颜色越深数值越大。根据图 8 可以看出,从第 0 类到第 11 类,对这些类别中的部分样本识别错误的主要原因是模型无法对症状相近的病害进行准确判断,比如混合病害与严重程度病害之间、同种病害的一般程度和严重程度以及相似病害之间。例如,在对第 0 类混合病害识别过程中,图片数量一共有 320 张,但识别错误的有 108 张,根据这 108 张数据分析得到大部分的识别错误类别为第 10 类蛙眼叶斑病(严重)和第 11 类蛙眼叶斑病(严重)。通过对数据集中这 3 种病害图片观察,发现它们的病变区域都为棕褐色的圆斑点,病害之间相似度极大,从而使得模型在识别过程中出现了识别错误的情况。数据集中的这 3 种病害部分图片如图 9 所示。




图7 各模型准确率曲线图

Fig. 7 Accuracy curve of each model




图8 SSDANet 模型在数据集上的混淆矩阵

Fig. 8 Confusion matrix of SSDANet model on data set



a 混合病害



b 蛙眼叶斑病(严重)



c 蛙眼叶斑病(严重)

图9 数据集中识别错误的部分图片

Fig. 9 Partial images with incorrect recognition in the dataset

综合以上分析可以看出,病害识别错误的原因主要是各病害类别之间相似度太大。模型无法对症状相近的病害进行准确判断,造成部分图片分类错误。但从整个数据集来看,引入域自适应方法后可以有效改善图片差异太大造成识别困难的问题,此外加入自监督模块后,通过自监督任务的设置,可以提高模型在细粒度识别方面的性能。

3 结束语

本文提出一种基于自监督域自适应网络的苹果叶部病害识别模型来解决真实农业生产环境中苹果叶部病害识别困难的问题,该模型通过在域自适应方法的基础上添加自监督模块来实现病害的有效识别,具有较高的稳定性,为复杂背景下苹果叶部病害的准确识别和防治提供了一种技术手段。未来将会研究在不同的基础网络上加入自监督域自适应方法的效果。此外,对于其他真实农业生产环境下的农作物叶部病害数据集的研究也会考虑在内,同时改进现有算法,提高模型在此类问题上的泛化能力。

参考文献:

- [1] 刘杰,曾娟,黄冲,等. 2024 年全国农作物重大病虫害发生趋势预报[J]. 中国植保导刊, 2024, 44(1): 37-40.
LIU J, ZENG J, HUANG C, et al. Forecast of the occurrence trend of major crop diseases and insect pests in China in 2024[J]. China Plant Protection, 2024, 44(1): 37-40.
- [2] KAMILARIS A, PRENAFETA-BOLDÚ F X. Deep learning in agriculture: a survey[J]. Computers and Electronics in

- Agriculture, 2018, 147: 70-90.
- [3] LI L L, ZHANG S J, WANG B. Apple leaf disease identification with a small and imbalanced dataset based on lightweight convolutional networks[J]. *Sensors*, 2022, 22(1): 173.
- [4] CHAO X F, SUN G Y, ZHAO H K, et al. Identification of apple tree leaf diseases based on deep learning models[J]. *Symmetry*, 2020, 12(7): 1065.
- [5] YU H L, CHENG X H, CHEN C C, et al. Apple leaf disease recognition method with improved residual network[J]. *Multimedia Tools and Applications*, 2022, 81(6): 7759-7782.
- [6] BEDI P, PUSHKAR G. Plant disease detection using hybrid model based on convolutional autoencoder and convolutional neural network[J]. *Artificial Intelligence in Agriculture*, 2021, 5: 90-101.
- [7] 李大湘, 曾小通, 刘颖. 耦合全局与局部特征的苹果叶部病害识别模型[J]. *农业工程学报*, 2022, 38(16): 207-214.
LI D X, ZENG X T, LIU Y. Apple leaf disease identification model by coupling global and patch features[J]. *Chinese Journal of Agricultural Engineering*, 2022, 38(16): 207-214.
- [8] WANG Y L, SUN F G, WANG Z J, et al. Apple leaf disease identification method based on improved yoloV5[C]//ABOUL E H. *Proceedings of the 8th International Conference on Signal and Information Processing*. Singapore: Springer, 2022: 1246-1252.
- [9] WANG J D, FENG W J, CHEN Y Q, et al. Visual domain adaptation with manifold embedded distribution alignment[C]//SU S B. *Proceedings of the 26th ACM International Conference on Multimedia*. Seoul: ACM, 2018: 402-410.
- [10] ZHAO T Y, SHEN Z C, ZOU H, et al. Unsupervised adversarial domain adaptation based on interpolation image for fish detection in aquaculture[J]. *Computers and Electronics in Agriculture*, 2022, 198: 107004.
- [11] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. *Communications of the ACM*, 2020, 63(11): 139-144.
- [12] NGUYEN P, TRUONG T D, HUANG M, et al. Self-supervised domain adaptation in crowd counting[C]//GIUSEPPE V. *2022 IEEE International Conference on Image Processing*. Piscataway: IEEE, 2022: 2786-2790.
- [13] CIGA O, XU T, MARTEL A L. Self-supervised contrastive learning for digital histopathology[J]. *Machine Learning with Applications*, 2022, 7: 100198.
- [14] LIU X, ZHANG F J, HOU Z Y, et al. Self-supervised learning: generative or contrastive[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2021, 35(1): 857-876.
- [15] MASCOLINI A, CARDAMONE D, PONZIO F, et al. Exploiting generative self-supervised learning for the assessment of biological images with lack of annotations[J]. *BMC Bioinformatics*, 2022, 23(1): 1-17.
- [16] WANG J D, CHEN Y Q, FENG W J, et al. Transfer learning with dynamic distribution adaptation[J]. *ACM Transactions on Intelligent Systems and Technology*, 2020, 11(1): 1-25.
- [17] GRILL J B, STRUB F, ALTCHÉ F, et al. Bootstrap your own latent—a new approach to self-supervised learning[J]. *Advances in Neural Information Processing Systems*, 2020, 33: 21271-21284.
- [18] CHEN T, KORNBLITH S, NOROUZI M, et al. A simple framework for contrastive learning of visual representations[C]//DAUME H C. *The 37th International Conference on Machine Learning*. Virtual: ACM, 2020: 1597-1607.
- [19] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks[C]//ALBRECHT S. *Proceedings of the 25th International Conference on Neural Information Processing Systems*. Nevada: Curran Associates, 2012: 1079-1105.
- [20] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. *Computer Science*, 2014, 1556(6): 1-14.
- [21] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]//ERIC M. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE, 2015: 1-9.
- [22] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//OLGA R. *2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE, 2016: 770-778.
- [23] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//ERIC M. *Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE, 2017: 4700-4708.
- [24] TAN M, LE Q V. EfficientNet: Rethinking model scaling for convolutional neural networks[C]//KAMALIKA C. *Proceedings of the 36th International Conference on Machine Learning*. Long Beach: PMLR, 2019: 6105-6114.
- [25] RADOSAVOVIC I, KOSARAJU R P, GIRSHICK R, et al. Designing network design spaces[C]//TERRY B. *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE, 2020: 10425-10433.

Apple Leaf Diseases Recognition Based on Deep Learning

CHENG Chao¹, LÜ Jia^{1, 2}, FAN Yazhou¹

(1. College of Computer and Information Sciences, Chongqing Normal University;

2. Chongqing Digital Agriculture Service Engineering Technology Research Center, Chongqing 401331, China)

Abstract: Aiming at the difficulty of apple leaf disease recognition under actual agricultural production environments, a recognition model is proposed based on self-supervised domain adaptive network. This model first introduces the dynamic domain adaptive method. Through the joint training of crop leaf image source domain and target domain data set, the domain deviation from the source domain to the target domain is reduced, and the generalization ability of the pre-trained model in the target domain is enhanced. Secondly, a self-supervised module is added and a contrast loss is introduced to make the model learn more detailed representation information of the lesion area in the feature space, so as to effectively enhance the ability to distinguish similar symptoms and improve the classification performance of the model. The model was tested on a public apple dataset with complex backgrounds, and the experiment showed that the average recognition accuracy of this model for various diseases reached 91.31%, achieving high classification accuracy. Compared with other popular convolutional neural network methods, the experimental results of this model have shown some improvement, verifying the effectiveness of the proposed model in identifying apple leaf diseases in actual production environments.

Keywords: apple leaf disease recognition; domain adaptive; self-supervised; contrast loss

(责任编辑 黄 颖)