

基于 CycleGAN-IA 方法和 M-ConvNext 网络的苹果叶片病害图像识别

李云红 张蕾涛 李丽敏 苏雪平 谢蓉蓉 史含驰

(西安工程大学电子信息学院, 西安 710048)

摘要: 针对苹果叶片病害图像识别存在数据集获取困难、样本不足、识别准确率低等问题, 提出基于多尺度特征提取的病害识别网络 (Multi-scale feature extraction ConvNext, M-ConvNext) 模型。采用一种结合改进的循环一致性生成对抗网络与仿射变换的数据增强方法 (Improved CycleGAN and affine transformation, CycleGAN-IA), 首先, 使用较小感受野的卷积核和残差注意力模块优化 CycleGAN 网络结构, 使用二值交叉熵损失函数代替 CycleGAN 网络的均方差损失函数, 以此生成高质量样本图像, 提高样本特征复杂度; 然后, 对生成图像进行仿射变换, 提高数据样本的空间复杂度, 该方法解决了数据样本不足的问题, 用于辅助后续病害识别模型。其次, 构建 M-ConvNext 网络, 该网络设计 G-RFB 模块获取并融合各个尺度的特征信息, GELU 激活函数增强网络的特征表达能力, 提高苹果叶片病害图像识别准确率。最后, 实验结果表明, CycleGAN-IA 数据增强方法可以对数据集起到良好的扩充作用, 在常用网络上验证, 增强后的数据集可以有效提高苹果叶片病害图像识别准确率; 通过消融实验可得, M-ConvNext 识别准确率可达 99.18%, 较原 ConvNext 网络准确率提高 0.41 个百分点, 较 ResNet50、MobileNetV3 和 EfficientNetV2 网络分别提高 3.78、7.35、4.07 个百分点, 为后续农作物病害识别提供了新思路。

关键词: 苹果叶片; 病害识别; 生成式对抗网络; 数据增强; 多尺度特征提取

中图分类号: S432.9*7

文献标识码: A

文章编号: 1000-1298(2024)04-0204-09

OSID:



Image Recognition of Apple Leaf Disease Based on CycleGAN-IA Method and M-ConvNext Network

LI Yunhong ZHANG Leitao LI Limin SU Xueping XIE Rongrong SHI Hanchi

(School of Electronics and Information, Xi'an Polytechnic University, Xi'an 710048, China)

Abstract: Aiming at the problems of difficult dataset acquisition, insufficient samples, and low recognition accuracy in apple leaf disease image recognition, a disease recognition network based on multi-scale feature extraction ConvNext (M-ConvNext) model was proposed. A data enhancement method combining improved CycleGAN and affine transformation (CycleGAN-IA) was used. Firstly, the CycleGAN network structure was optimized by using a convolutional kernel with a smaller sensory field and a residual attention module, and a binary cross-entropy loss function instead of the mean-variance loss function of CycleGAN network, in order to generate high-quality sample images and improve the complexity of sample features; then affine transformation was applied to the generated images to improve the spatial complexity of the data samples, which solved the problem of insufficient data samples, and was used to assist the subsequent disease recognition model. Secondly, the M-ConvNext network was constructed, which was designed with the G-RFB module to acquire and fuse the feature information of each scale, and the GELU activation function enhanced the feature expression ability of the network to improve the accuracy of apple leaf disease image recognition. Finally, the experimental results showed that the CycleGAN-IA data enhancement method can play a good role in expanding the dataset, and it was verified on the commonly used network that the enhanced dataset can effectively improve the accuracy of apple leaf disease image recognition; through the ablation and comparison experiments, the recognition

收稿日期: 2023-09-13 修回日期: 2023-10-10

基金项目: 国家自然科学基金项目(62203344)、陕西省科技厅自然科学基金基础研究重点项目(2022JZ-35)和国家级大学生创新创业计划项目(202210709012)

作者简介: 李云红(1974—), 女, 教授, 博士, 主要从事红外热像测温技术、图像处理和人工智能等研究, E-mail: hitliyunhong@163.com

accuracy of M - ConvNex can be up to 99.18%, which was 0.41 percentage points more than the original ConvNext network, and 3.78 percentage points, 7.35 percentage points, 4.07 percentage points higher than that of ResNet50, MobileNetV3, and EfficientNetV2 networks, respectively, which provided an idea and laid a foundation for the subsequent recognition of crop diseases.

Key words: apple leaf; disease identification; generative adversarial networks; data enhancement; multi-scale feature extraction

0 引言

苹果营养价值丰富、经济效益高,但苹果在生长过程中易受环境与虫害威胁,导致产量和质量不佳,造成严重的经济损失^[1-2]。因此,对苹果病害进行早期防治与干预,保证苹果产业的可持续发展,是亟待解决的问题^[3]。

长期以来,我国一直采用传统方法来识别农作物病害,农业工作者采用肉眼观察,通过经验判断病害,或者采集样本在实验室识别病害等,这些方式耗时耗力,且受到人力、物力、财力等限制,导致不能大规模应用于农业生产。因此,国家大力提倡智慧农业,使用人工智能方法解决农业问题。目前,深度学习快速发展,使用 AlexNet^[4]、VGG^[5]、GoogLeNet^[6]、ResNet^[7]、DenseNet^[8]、MobileNetV1/V2^[9-10]、ShufftNetV1/V2^[11-12] 和 EfficientNetV1/V2^[13-14] 等卷积神经网络进行病害识别效果较为显著。不少研究者根据实际问题,将上述网络进行优化改进应用于农业领域。陈伟文等^[15]提出 AlexNet - Improved 模型,该方法在 AlexNet 模型基础上引入数据增强与随机失活函数,选择 PlantVillage 数据集中番茄图像做验证,识别准确率可达 95.8%。姜红花等^[16]提出 ResNet18 - CBAM - RC1 网络模型,该模型使用混合注意力分支与随机裁剪分支来优化网络,在苹果数据集上识别准确率达到 98.25%。CHEN 等^[17]提出 Mobile - DANet 模型,该模型以 DenseNet 网络为基础模型,采用深度可分离卷积作为卷积核,并嵌入注意力模块,用该模型识别玉米病害准确率可达 95.86%。以上方法使用了注意力机制来提取特征病害,虽然起到了一定效果,但只局限于单一尺度的特征,因此,研究人员设计各种多尺度特征提取模块来改善农作物病害的识别效果^[18-19]。王泽钧等^[20]提出 LMA - CNNs 模型,该模型的特点在于深度可分离卷积基础上设计残差注意力和多尺度特征提取模块,并使用 59 类公开农作物病害图像测试,准确率可达 88.08%。通过不断研究发现,多尺度特征提取可以显著提高识别效果。

农作物病害图像获取困难,数据样本较少,而深度学习模型需要大量数据支撑,因此对数据进行扩充成为难题。仿射变换是传统数据增强中的典型方

法,他通过对图像进行翻转、平移、随机裁剪等方法对图像进行变换,可以有效扩充数据量,增加数据的空间复杂度。随着生成对抗网络 (Generative adversarial network, GAN) 的兴起,给数据增强带来了新的可能,研究人员尝试使用 GAN 网络生成“以假乱真”的图像,达到扩充图像的目的^[21-22]。在农业领域,王志强等^[23]使用 WGAN 进行番茄病害图像生成,并用 MCA - MobileNet 网络识别病害,通过实验证明了用 GAN 网络做数据增强时,在增加样本数量的基础上还可以提高模型分类准确率。安鑫宇^[24]、CHEN 等^[25]提出使用 DCGAN 进行数据增强,罗东升^[26]提出基于改进 ACGAN 的数据增强方法。生成对抗网络越来越多的应用于图像增强,对于扩充样本量与增加样本丰富度起到巨大作用。

以上方法虽然在一定程度上提高了农作物病害的识别效果,但对解决复杂环境下苹果叶片病害图像识别依旧存在样本数据不足、识别准确率不高等问题,因此,本文提出基于 CycleGAN - IA 方法和 M - ConvNext 网络的苹果叶片病害图像识别方法。采用 CycleGAN - IA 数据增强方法进行图像扩充,生成兼具特征与空间丰富度的样本图像,为后续分类模型提供数据支持,有效增强其鲁棒性;构建 M - ConvNext 网络模型进行病害识别,在 ConvNext 网络的基础上设计 G - RFB 多尺度特征提取模块,对病害特征进行提取,减少背景干扰,以提高模型对苹果叶片病害的识别准确率。


1 CycleGAN - IA 数据增强方法

针对复杂环境下苹果叶片病害数据集样本数量少的问题,提出 CycleGAN - IA 数据增强方法,运用改进后的循环一致性生成对抗网络 (CycleGAN) 生成丰富的苹果叶片病害图像,再将这些图像进行仿射变换提高其空间复杂度,最终构建本研究数据集。

1.1 实验数据集

目前常用的农作物病害数据集大多为实验室环境下采集的,数据集背景单一、复杂度低,无法应用于大田环境下,因此,本研究所用数据集均为复杂环境下的苹果叶片病害图像。该数据集由常见的 3 种苹果叶片病害 (黑腐病、锈病、疮痂病) 和健康叶片图像构成,典型数据样本见图 1。其中,健康图像

1 285 幅,黑腐病图像 888 幅,锈病图像 547 幅,疮痂病图像 944 幅,图像来源于 Kaggle 官方网站(<https://www.kaggle.com/>)。



1.2 改进的 CycleGAN 数据增强方法

首先使用改进的 CycleGAN 网络进行数据增强,该网络通过生成器与判别器对抗训练,学习苹果叶片病害数据集的病害特征、叶片特征及复杂背景,并以此生成复杂背景下的苹果叶片病害图像。该网络结构与原始 CycleGAN 网络类似,由 2 个循环网络构成,以健康图像与黑腐病图像的训练过程为例,该网络将 A 域图像(健康图像)映射到 B 域图像(黑腐病图像),B 域图像又通过生成器还原回 A 域,以此循环,加以判别器的辅助作用,使网络完成 A 域到 B 域的转换。B 域转换为




图 2 改进的 CycleGAN 网络生成器结构图
Fig. 2 Structural diagram of improved CycleGAN network generator

改进的 CycleGAN 网络的生成器类似编解码结构,将 A(健康)、B(某种病害)域图像输入,经过编码器结构后,进入转换层,然后将转换后的特征解码,输出生成 B 域图像。在转换层结构中,原 CycleGAN 网络通过堆叠 9 个残差结构块实现,但对病斑位置特征提取能力有限,导致病斑无法生成在叶片上。因此,提出将挤压-激励注意力机制(Squeeze-Excitation, SE)插入到残差块中,防止因卷积操作造成的位置特征信息丢失。SE-ResnetBlock 模块的结构如图 3 所示,图中红色虚框部分为 SE 模块。SE 模块将残差模块的输出作为输入进行挤压(Squeeze)操作,压缩展平为全局特征,通过激励(Excitation)机制将通道信息按照相关性赋予不同权重,激励后的特征与残差输出相乘,达到赋予注意力的目的,最后与上层输入相加输出,构成

A 域图像流程与上述一致。

原 CycleGAN 网络在生成苹果叶片病害图像时,存在病斑生成位置不定、病斑生成效果不佳、网络训练不稳定等问题,因此,设计改进的 CycleGAN 网络,该网络作出以下改进:①使用小感受野卷积核,增加网络深度。②设计残差注意力网络,生成细节信息。③使用二值交叉熵与 Sigmoid 激活函数结合的损失函数,提高网络稳定性。

1.2.1 网络结构优化

改进的 CycleGAN 网络在生成器中全部使用 3×3 卷积核进行运算,取消了原 CycleGAN 网络中的 7×7 卷积核。图 2 为改进的 CycleGAN 网络生成器结构图。小尺寸卷积核感受野较小,对图像细节信息更为敏感,可以生成目标较小的苹果叶片病斑,再通过堆叠小尺寸卷积核,达到与大尺寸卷积核扫描范围的一致性。在参数量方面,同一层网络, 7×7 的卷积核参数量高达 $7 \times 7 \times N$, 3 个 3×3 的卷积核参数量只需 $3 \times 3 \times 3 \times N$, 只有 7×7 卷积核参数量的 55%, 其中 N 表示输出通道数。在网络深度方面,使用 3 个小卷积核代替大卷积核,可以加深网络,提高特征提取能力,减少过拟合现象发生。

SE-ResnetBlock 模块。残差注意力模块结合短路连接和注意力机制的思想,在不丢失原有特征信息的前提下,融合各通道间的关系,增加了对微小病斑特征的注意力,提高了病害图像生成效果。

1.2.2 损失函数优化

原 CycleGAN 网络的损失函数由 3 部分组成,分别为:生成对抗损失 L_{GAN} 、循环一致性损失 L_{cyc} 和本体一致性损失 $L_{identity}$ 。总的损失函数计算式为

$$L(G, F, D_X, D_Y) = L_{GAN}(G, D_Y, X, Y) + L_{GAN}(F, D_X, X, Y) + \alpha L_{cyc}(G, F) + \beta L_{identity}(G, F) \tag{1}$$

式中 G, F ——生成器损失
 D_Y, D_X ——与 G, F 对应的判别器损失
 α ——循环一致性损失的权重系数
 β ——本体一致性损失的权重系数




图 3 SE - ResnetBlock 模块结构图

Fig. 3 Structure diagram of SE - ResnetBlock module

循环一致性损失函数是 CycleGAN 的特点,循环过程为 $A \rightarrow B \xrightarrow{\text{还原}} A' \approx A$,该损失函数用于计算 A' 与 A 相似性。本体一致性损失则希望在 A 域图像生成 B 域图像时,若输入为 B 域图像,则不做任何处理直接输出。CycleGAN 网络的优化目标可表示为

$$G^*, F^* = \arg \min_{G, F} \max_{D_X, D_Y} L(G, F, D_X, D_Y) \quad (2)$$

其中, G^* 、 F^* 分别表示优化后生成器和判别器损失。从优化目标不难看出,循环一致性生成对抗网络与其他生成对抗网络一样,都是通过训练最小化生成器损失值,最大化判别器损失值,以此对抗生成“以假乱真”的图像。

原 CycleGAN 网络的 L_{GAN} 采用均方误差 (Mean square error, MSE) 进行计算, L_{cyc} 与 L_{identity} 采用 L1 损失函数进行计算。原网络中的 MSE 损失 (平方差运算) 会显著提高大于 1 的误差,使得模型收敛困难。因此,改进的 CycleGAN 网络提出二值交叉熵 (Binary cross entropy, BCE) 与 Sigmoid 激活函数结合的损失函数作为网络的 L_{GAN} 损失,其公式为

$$L_{\text{BCE}} = \frac{1}{N} \sum_i L_i = \frac{1}{N} \sum_i \{ -[y_i \ln p_i + (1 - y_i) \ln (1 - p_i)] \} \quad (3)$$

式中 L_{BCE} ——总损失值
 L_i ——样本 i 的损失值
 y_i ——样本 i 的标签
 p_i ——经过 Sigmoid 后样本 i 预测为正类的概率

此时损失函数梯度更新与预测值和真值之差呈正相关,有效降低了异常值对模型收敛的影响,提高了损失值变化的稳定性。

1.3 仿射变换数据增强方法

将改进的 CycleGAN 网络生成的数据集与原数

据集组合成 I - Apple。I - Apple 是具有丰富特征的苹果叶片病害图像,为了进一步扩充数据集,对 I - Apple 进行仿射变换,使用水平翻转、随机旋转 (旋转角为 $0^\circ \sim 20^\circ$)、亮度增强 3 种变换方式,将变换后的数据集作为苹果叶片病害分类的研究对象,命名为 IA - Apple。使用仿射变换做数据增强,使 IA - Apple 数据集成为兼具特征与空间复杂度的苹果叶片病害图像,为后续病害识别奠定了基础。

2 M - ConvNext 网络改进

针对复杂背景下的苹果叶片病害数据集背景杂乱、病斑尺寸不一,导致识别准确率低的问题,设计多尺度特征提取模块,改进 M - ConvNext 网络,提高病害识别的准确率。

2.1 G - RFB 多尺度特征提取模块

常见的卷积神经网络每层卷积核大小都是一样的,也就是每层在提取特征时感受野相同,提取的范围相对局限。因此,提出一种多尺度特征提取方法,用不同大小的卷积核提取不同尺度的特征信息,将各个尺度的信息进行融合,得到新的特征图。新的特征图可以照顾到苹果叶片不同尺寸的病斑以及背景干扰。RFB 借鉴了 Inception 结构和 ASPP 结构,在多分支卷积的基础上采用空洞卷积的方法,实现不同位置不同感受野的特征提取。本研究对 RFB 结构进行改进,设计了多尺度特征提取模块 G - RFB,网络结构如图 4 所示。




图 4 G - RFB 特征提取模块结构图

Fig. 4 Structure diagram of G - RFB feature extraction module

上一层特征输入 G - RFB 模块后,分别通过 3 个不同尺度的并联分支,这 3 个分支分别采用感受野不同的卷积核与不同膨胀率的空洞卷积,实现多个尺度的特征提取,大尺度分支提取全局信息,小尺度分支关注细节信息。3 个分支特征提取完后进行特征拼接,并使用 1×1 的卷积核连接。

为保证原有特征不被丢失,借鉴了残差网络的思想,将输入特征图与多尺度并行特征融合,使用 GELU 激活并输出。GELU 是一种基于高斯误差函数的激活函数,该函数提高了 G-RFB 特征提取模块的非线性表达能力,防止了训练过程中产生的神经元死亡问题,有助于提高训练过程的收敛速度和性能。

2.2 M-ConvNext 网络结构

M-ConvNext 网络的搭建以 ConvNext 为基础,加入 G-RFB 多尺度特征提取模块,并将提取后的

特征继续在 ConvNext 网络中识别验证。M-ConvNext 网络中,所有的激活函数均使用 GELU,归一化层也从原来的 Batch Normalization 改为 Layer Normalization。图 5 为 M-ConvNext 网络结构图。首先输入尺寸为 $224 \times 224 \times 3$ 的苹果叶片病害图像,经过一个 4×4 卷积扩充数据维度,再经过 G-RFB 模块提取多尺度特征,减小苹果叶片图像背景的影响,然后经过多层 ConvNext Block 模块优化特征,最后通过全局平均池化和 Linear 层对 4 类苹果叶片图像分类。




图 5 M-ConvNext 网络结构图
Fig. 5 M-ConvNext network architecture diagram

3 实验结果与分析

3.1 实验环境及配置

实验均在 Linux 平台下运行,使用 Python 语言,调用 Pytorch 库进行网络搭建、调试、训练与测试。服务器配置为: 24 vCPU AMD EPYC 7642 48-Core Processor CPU 和 RTX 3090(24 GB)GPU。

3.2 评价指标

本研究使用峰值信噪比 (Peak signal to noise ratio, PSNR)、结构相似度 (Structural similarity, SSIM)、FID 分数 (Frechet inception distance score, FID)、准确率作为数据增强方法的评价指标;使用准确率、召回率、F1 值作为分类网络模型的评价指标。

3.3 数据增强实验

为解决复杂环境下苹果叶片病害数据集较少,数据类间差距大的问题,提出了 CycleGAN-IA 数据增强方法。首先通过改进的 CycleGAN 生成 I-Apple 数据集,和其他生成对抗网络不同的是,改进的 CycleGAN 网络训练时数据分为 4 类,分别为 A 域训练集和测试集,B 域训练集和测试集,其中训练集与验证集比例设置为 10:1,epoch 设置为 200,batch_size 设为 2,初始学习率设为 0.002,采用 Adamu 优化算法,训练时输入图像尺寸为 256 像素 $\times$ 256 像素。改进的 CycleGAN 网络是一对一互相生成的对抗网络,因此,实验分为 3 组进行,分别为 A1 域 (健康叶片) 和 B1 域 (黑腐病)、

A2 域 (健康叶片) 和 B2 域 (锈病)、A3 域 (健康叶片) 和 B3 域 (疮痂病),每组实验设置完全相同。

以 A1 域 (健康叶片) 和 B1 域 (黑腐病) 为例,改进的 CycleGAN 网络与原 CycleGAN 网络的生成效果图如图 6 所示。图中第 1 列为 A1 域 (健康叶片),第 2 列为原 CycleGAN 网络生成图像,第 3 列为在原 CycleGAN 上改进小卷积核、增加网络深度的生成图像,第 4 列为在第 3 列 (CycleGAN-1) 的基础上使用 SE-ResnetBlock 的生成图像,第 5 列为在第 4 列 (CycleGAN-2) 的基础上改进损失函数的生成图像,也就是改进的 CycleGAN 网络生成图像,第 6 列为 B1 域 (黑腐病) 图像。在生成过程中,目标是将健康叶片生成黑腐病叶片 (将 A1 域图像生成 B1 域图像),从图中可以看出,用原 CycleGAN 网络生成时,存在生成不了病斑、病斑位置出错的问题;改进为 CycleGAN-1 网络后,生成位置依旧会错位,且生成病斑质量较差;改进为 CycleGAN-2 网络后,位置上的问题基本解决,但还存在病斑不明显的问题;改进的 CycleGAN 网络生成效果最好,解决了上述网络存在的问题,并与真实 B1 域图像对比,可以看出生成后的图像可以达到目标效果。

为评估改进后的 CycleGAN 网络生成的样本图像质量,设计对比实验,如表 1 所示。

从表 1 可得,改进的 CycleGAN 网络生成的健康叶片 PSNR 提高 0.06 dB,SSIM 不变,FID 降低 5;生成的黑腐病叶片 PSNR 提高 0.04 dB,SSIM 提高




图 6 改进的 CycleGAN 网络生成效果图

Fig. 6 Generation effect of improved CycleGAN network

表 1 改进前后的 PSNR、SSIM 及 FID 对比
Tab. 1 Comparison of PSNR, SSIM and FID values before and after improvement

病害类型	网络模型	PSNR/dB	SSIM	FID
健康叶片	CycleGAN	11. 47	0. 41	52. 82
	改进的 CycleGAN	11. 53	0. 41	47. 82
黑腐病	CycleGAN	11. 82	0. 35	47. 62
	改进的 CycleGAN	11. 86	0. 37	32. 22
锈病	CycleGAN	11. 58	0. 39	46. 72
	改进的 CycleGAN	11. 65	0. 40	38. 02
疮痂病	CycleGAN	11. 85	0. 41	40. 54
	改进的 CycleGAN	11. 92	0. 44	31. 36

0. 02, FID 降低 15. 4; 生成的锈病叶片 PSNR 提高 0. 07 dB, SSIM 提高 0. 01, FID 降低 8. 7; 生成的疮痂病叶片 PSNR 提高 0. 07 dB, SSIM 提高 0. 03, FID 降低 9. 18。由此可见, 改进后的 CycleGAN 网络生成的样本图像多样性更高、细节更逼真、与真实图像的相似性也更高。

对苹果叶片病害数据集中的每类图像都使用改进的 CycleGAN 网络进行数据增强, 增强后得到 I - Apple 数据集, 再将 I - Apple 进行仿射变换, 变换后的数据集 IA - Apple 作为本实验的研究对象。表 2 为数据增强前后各类苹果叶片图像数量。

表 2 数据增强前后图像数量
Tab. 2 Number of images before and after data enhancement

病害类型	Apple	I - Apple	IA - Apple
健康叶片	1 285	1 542	6 168
黑腐病	888	1 821	7 284
锈病	547	1 069	4 276
疮痂病	944	1 596	6 384
总数	3 664	6 028	24 112

为验证 CycleGAN - IA 数据增强方法对苹果

叶片病害图像的识别效果, 设置对比实验, 使用分类网络 ResNet50、InceptionV3、DenseNet121、MobileNetV3、EfficientNetV2 和 ConvNext 进行验证, 实验结果见表 3。

表 3 不同数据增强方法的苹果病害识别分类准确率
Tab. 3 Effects of different data enhancement methods on classification accuracy of apple disease recognition %

网络模型	Apple	I - Apple	IA - Apple
ResNet50	84. 62	94. 23	95. 40
InceptionV3	80. 49	93. 96	97. 09
DenseNet121	85. 16	95. 32	95. 94
MobileNetV3	76. 37	87. 64	91. 83
EfficientNetV2	79. 40	95. 11	95. 88
ConvNext	74. 45	88. 68	98. 77

从整体来看, 用通过改进的 CycleGAN 网络加强的数据集进行分类训练, 准确率较原始数据集有初步提升, 而经过 CycleGAN - IA 数据增强后, 准确率继续提升。纵向来看, 对原始 Apple 数据集来说, ConvNext 网络分类准确率最低, 为 74. 45%, DenseNet121 网络准确率最高, 为 85. 16%; 对 I - Apple 数据集来说, MobileNetV3 网络准确率最低, 为 87. 64%, DenseNet121 网络准确率最高, 为 95. 32%; 对 IA - Apple 数据集来说, MobileNetV3 网络分类准确率最低, 为 91. 83%, ConvNext 网络准确率最高, 达到 98. 77%, InceptionV3 网络次之。横向对比得出, CycleGAN - IA 数据增强方法能够有效提高苹果叶片病害图像识别的准确率, 且具有普适性; 通过纵向对比, 可以看出网络深度与多尺度特征提取对网络分类有明显提升效果。选择准确率最高的 IA - Apple 数据集与 ConvNext 网络作为后续分类的数据集和基础网络。

3.4 消融实验

为证明 M-ConvNext 网络对苹果叶片病害图像识别的分类效果,设置 3 组实验,其中,数据集统一使用 IA-Apple,训练次数为 40,验证集统一使用真实环境下且未经过数据增强的苹果叶片图像,结果见表 4。

表 4 消融实验结果

Tab.4 Results of ablation experiments %				
网络模型	改进方式	准确率	F1 值	召回率
ConvNext		98.77	98.01	98.20
ConvNext1	+ RFB	98.90	98.17	98.35
M-ConvNext	+ G-RFB	99.18	98.91	99.08

从表 4 可得,M-ConvNext 网络较原网络准确率提高 0.41 个百分点,F1 值提高 0.9 个百分点,召回率提高 0.88 个百分点。相比于原网络,增加多尺度特征提取模块 RFB 使得分类准确率达到 98.90%,验证了多尺度特征提取可以优化模型的识别效果,在此基础上进行改进,使用 G-RFB 模块作为多尺度特征提取模块,准确率可达 99.18%,证明了 GELU 激活函数对 RFB 模块有进一步的优化作用。

图 7 为改进前后网络的混淆矩阵,从图中可以看出,M-ConvNext 网络绝大多数样本的分类结果集中在混淆矩阵的对角线上,在黑腐病和锈病的识别上存在些许误差,但总体来说,较改进前的网络识别效果更好。

采用类激活可视化算法来验证 M-ConvNext 网络与原 ConvNext 网络的识别效果,图 8 为改进前后网络对不同类别病害图像的识别热力图,观察可得,原 ConvNext 网络在识别 3 类病害时存在识别分散、受背景干扰的问题,M-ConvNext 网络解决了这些问题,能够更好地定位到病斑位置,从而改善病害识别效果。

3.5 与其他网络对比实验

为进一步验证 M-ConvNext 网络对苹果叶片病害的识别效果,在相同的实验环境,相同的数据集 IA-Apple,相同的 epoch、batch size 下,设计对比实验:将 M-ConvNext 网络与 ResNet50、InceptionV3、DenseNet121、MobileNetV3、EfficientNetV2 和 ConvNext 网络进行对比。其验证集准确率曲线如图 9 所示。

从图 9 中可以看出,M-ConvNext 网络模型在训练 20 轮时基本达到稳定,曲线平稳上升,未出现过拟合现象,且准确率最高。相比于其他网络模型,该模型识别效果更好,稳定性更强,同时也证明了采




图 7 改进前后网络混淆矩阵

Fig.7 Confusion matrix of network before and after improvement




图 8 改进前后网络识别热力图

Fig.8 Recognition heat map of network before and after improvement




图 9 不同模型在验证集上的准确率曲线

Fig.9 Accuracy curves of different models on validation set

用多尺度特征提取后会对苹果叶片病害图像识别效果有不错的提升作用。将上述 7 个网络模型在相同的测试集上测试,其准确率、F1 值和召回率见表 5。

表 5 不同模型在测试集上的对比

Tab.5 Comparison of different models on test set

网络模型	准确率	F1 值	召回率
ResNet50	95.40	93.17	93.70
InceptionV3	97.09	95.49	95.81
DenseNet121	95.94	94.04	94.43
MobileNetV3	91.83	88.41	89.33
EfficientNetV2	95.11	92.78	93.18
ConvNext	98.77	98.01	98.20
M-ConvNext	99.18	98.91	99.08

由表 5 可知,M-ConvNext 网络模型的 3 个评价指标都高于主流模型,准确率比 ResNet50、InceptionV3、DenseNet121、MobileNetV3、EfficientNetV2 和 ConvNext 分别提高 3.78、2.09、3.24、7.35、4.07、0.41 个百分点,F1 值分别提高 5.74、3.42、4.87、10.5、6.13、0.9 个百分点,召回率分别提高 5.38、3.27、4.65、9.75、5.9、0.88 个百分点。由此可得,在苹果叶片病害图像识别研究中,M-ConvNext 网络比其他 6 种基础网络效果更好,识别准确率更高,并且在进行多尺度特征提取之后,可以提高原网络提取、区分更多的病害特征的能力,使网络更适合该研究。

4 结论

(1)针对真实环境下苹果叶片病害图像识别中存在数据集获取困难、样本不足、识别准确率低等问题,提出了基于 CycleGAN-IA 方法和 M-ConvNext 网络的苹果叶片病害图像识别方法。

(2)提出 CycleGAN-IA 数据增强方法。使用改进后的 CycleGAN 网络进行样本特征复杂度的扩充,用仿射变换方法进行样本空间复杂度的扩充,解决了原始样本不足的问题,并设置 6 组对比实验证明了该数据增强方法可以有效提高模型识别准确率,增强模型鲁棒性,且具有普适性。

(3)提出基于 M-ConvNext 网络的苹果叶片病害图像识别方法。将 G-RFB 模块加入到 ConvNext 网络中,得到的 M-ConvNext 网络能够提取各个尺度的病害特征,避免背景干扰,提高识别准确率。消融实验结果表明,M-ConvNext 网络在苹果叶片病害图像识别过程中准确率最高,可达 99.18%,较 ConvNext 网络提高 0.41 个百分点,较 ResNet50、MobileNetV3 和 EfficientNetV2 网络分别提高 3.78、7.35、4.07 个百分点。

(4)提出的基于 CycleGAN-IA 方法和 M-ConvNext 网络的苹果叶片病害图像识别方法,在数据层面,能够有效扩充数据集,在分类层面,可以提取多尺度的病害特征,且通过实验验证了对苹果叶片病害图像的识别效果,为后续研究提供了数据支持和改进思路,具有一定理论和实际意义。

参 考 文 献

[1] 孟子恒,朱海燕,刘学忠. 农业产业集聚对农业经济增长的影响研究——基于苹果产业的实证分析[J]. 中国农业资源与区划,2022,43(2):231-239.
MENG Ziheng, ZHU Haiyan, LIU Xuezhong. Research on the impact of agricultural industry agglomeration on agricultural economic growth—an empirical analysis based on apple industry[J]. China Agricultural Resources and Zoning, 2022, 43(2): 231-239. (in Chinese)

[2] 常倩,李瑾. 2000 年以来中国苹果产业发展趋势分析[J]. 北方园艺,2021(3):155-160.
CHANG Qian, LI Jin. Analysis of the development trend of China's apple industry since 2000[J]. Northern Horticulture, 2021(3):155-160. (in Chinese)

[3] 王树桐,王亚南,曹克强. 近年我国重要苹果病害发生概况及研究进展[J]. 植物保护,2018,44(5):13-25,50.
WANG Shutong, WANG Ya'nan, CAO Keqiang. Overview of the occurrence of important apple diseases in China in recent years and research progress[J]. Plant Protection, 2018, 44(5):13-25,50. (in Chinese)

[4] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, 25: 1097-1105.

[5] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv Preprint, arXiv: 1409.1556, 2014.

[6] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2014: 1-9.

[7] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016:770-778.

[8] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4700-4708.

[9] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [J]. arXiv Preprint, arXiv:1704.04861, 2017.

[10] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2:inverted residuals and linear bottlenecks[C]//31st IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018:4510 – 4520.

[11] ZHANG X, ZHOU X Y, LIN M X, et al. ShuffleNet:an extremely efficient convolutional neural network for mobile devices [C]//31st IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018:6848 – 6856.

[12] MA N N, ZHANG X Y, ZHENG H T, et al. ShuffleNetV2: practical guidelines for efficient CNN architecture design[C]// 15th European Conference on Computer Vision (ECCV), 2018: 122 – 138.

[13] TAN M, LE Q. EfficientNet: rethinking model scaling for convolutional neural networks[C]// International Conference on Machine Learning. Proceedings of Machine Learning Research, 2019: 6105 – 6114.

[14] TAN M, LE Q. EfficientNetV2: smaller models and faster training[C]// International Conference on Machine Learning. PMLR, 2021:10096 – 10106.

[15] 陈伟文, 邝祝芳, 王忠伟. 基于卷积神经网络的种苗病害识别方法[J]. 中南林业科技大学学报, 2022, 42(7): 35 – 43.
CHEN Weiwen, KUANG Zhufang, WANG Zhongwei. Method of seed disease recognition based on convolutional neural network [J]. Journal of Central South Forestry University of Science and Technology, 2022, 42(7): 35 – 43. (in Chinese)

[16] 姜红花, 杨祥海, 丁睿柔, 等. 基于改进 ResNet18 的苹果叶部病害多分类算法研究[J]. 农业机械学报, 2023, 54(4): 295 – 303.
JIANG Honghua, YANG Xianghai, DING Ruiou, et al. Identification of apple leaf diseases based on improved ResNet18[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(4): 295 – 303. (in Chinese)

[17] CHEN J D, WANG W H, ZHANG D F, et al. Attention embedded lightweight network for maize disease recognition[J]. Plant Pathology, 2021, 70(3): 630 – 642.

[18] 黄林生, 罗耀武, 杨小冬, 等. 基于注意力机制和多尺度残差网络的农作物病害识别[J]. 农业机械学报, 2021, 52(10): 264 – 271.
HUANG Linsheng, LUO Yaowu, YANG Xiaodong, et al. Crop disease recognition based on attention mechanism and multi-scale residual network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(10): 264 – 271. (in Chinese)

[19] 杜甜甜, 南新元, 黄家兴, 等. 改进 RegNet 识别多种农作物病害受害程度[J]. 农业工程学报, 2022, 38(15): 150 – 158.
DU Tiantian, NAN Xinyuan, HUANG Jiaying, et al. Identifying the damage degree of various crop diseases using an improved RegNet[J]. Transactions of the CSAE, 2022, 38(15): 150 – 158. (in Chinese)

[20] 王泽钧, 马凤英, 张瑜, 等. 基于注意力机制和多尺度轻量型网络的农作物病害识别[J]. 农业工程学报, 2022, 38(增刊): 176 – 183.
WANG Zejun, MA Fengying, ZHANG Yu, et al. Crop disease recognition using attention mechanism and multi-scale lightweight network[J]. Transactions of the CSAE, 2022, 38(Supp.): 176 – 183. (in Chinese)

[21] XIAO Deqin, ZENG Ruilin, LIU Youfu, et al. Citrus greening disease recognition algorithm based on classification network using TRL – GAN[J]. Computers and Electronics in Agriculture, 2022, 200: 107206.

[22] 李云红, 段姣姣, 苏雪平, 等. 基于改进生成对抗网络的书法字生成算法[J]. 浙江大学学报(工学版), 2023, 57(7): 1326 – 1334, 1459.
LI Yunhong, DUAN Jiaojiao, SU Xueping, et al. Calligraphy generation algorithm based on improved generative adversarial network[J]. Journal of Zhejiang University (Engineering Edition), 2023, 57(7): 1326 – 1334, 1459. (in Chinese)

[23] 王志强, 于雪莹, 杨晓婧, 等. 基于 WGAN 和 MCA – MobileNet 的番茄叶片病害识别[J]. 农业机械学报, 2023, 54(5): 244 – 252.
WANG Zhiqiang, YU Xueying, YANG Xiaojing, et al. Tomato leaf diseases recognition based on WGAN and MCA – MobileNet[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(5): 244 – 252. (in Chinese)

[24] 安鑫宇. 基于生成式对抗网络和注意力机制的苹果叶片病害识别研究[D]. 泰安: 山东农业大学, 2022.
AN Xinyu. Research on apple leaf disease recognition based on adversarial network and attention mechanism[D]. Taian: Shandong Agricultural University, 2022. (in Chinese)

[25] CHEN Y, WU Q. Grape leaf disease identification with sparse data via generative adversarial networks and convolutional neural networks[J]. Precision Agriculture, 2023, 24(1): 235 – 253.

[26] 罗东升. 用于叶片病害识别的数据增强方法的研究[D]. 太原: 太原理工大学, 2022.
LUO Dongsheng. Research on data enhancement method for leaf disease recognition[D]. Taiyuan: Taiyuan University of Technology, 2022. (in Chinese)