

李艳玲,张博翔,李飞涛,等.基于改进CycleGAN的小样本玉米病害图像扩充方法[J].华中农业大学学报,2025,44(5):198-207.
DOI:10.13300/j.cnki.hnlkxb.2025.05.020

基于改进 CycleGAN 的小样本玉米病害图像扩充方法

李艳玲¹,张博翔¹,李飞涛¹,Bacao Fernando²,司海平¹,陈丽娜³

1.河南农业大学信息与管理科学学院,郑州 450002; 2.新里斯本大学信息管理学院,里斯本 1070-312;
3.商丘师范学院计算机与信息技术学院,商丘 476000

摘要 针对玉米病害图像识别任务存在数据集获取困难、样本不足及不同类别病害样本不均衡等问题,设计一种基于改进CycleGAN(cycle-consistent adversarial networks)的图像数据增强方法。首先,使用较小感受野的卷积核优化CycleGAN网络结构,生成高质量样本图像,减少过拟合现象发生;其次,将SE(squeeze-excitation)注意力机制嵌入到生成器的残差模块中,增强CycleGAN对病害特征的提取能力,使网络更准确地捕捉小目标病害或域间差异不明显的特征。结果显示,改进后的CycleGAN相较于原始CycleGAN、DCGAN、DCGAN+和WGAN算法,生成病害图像的FID分数分别降低了43.33、32.67、24.24和19.72,GAN-train与GAN-test相较于原始CycleGAN提升了3.13、4.25百分点;采用改进的CycleGAN图像扩充方法构建玉米病害数据集,基于该数据集的玉米叶片病害识别模型准确率在3种网络架构上均得到有效提升:AlexNet提升3.90个百分点,VGGNet提升4.41个百分点,ResNet提升3.44个百分点,在ResNet网络架构上与传统数据增强算法相比病害识别率提升5.79个百分点。结果表明,改进的CycleGAN网络有效解决了玉米病害图像数据集匮乏的问题。

关键词 数据增强;玉米叶片病害;残差模块;循环一致性生成对抗网络

中图分类号 S513; TP391.1 **文献标识码** A **文章编号** 1000-2421(2025)05-0198-10

农业是国民经济的基础产业,而玉米作为全球重要的粮食作物之一^[1-2],其种植面积广泛,产量巨大。然而,玉米在生长过程中易受到多种病害的侵袭,如玉米大斑病、普通锈病、灰斑病等^[3]。这些病害不仅影响玉米的产量,还可能导致品质下降,给农民带来巨大的经济损失。因此,及时、准确地识别玉米病害,对于采取有效的防治措施、保障粮食安全具有至关重要的意义^[4-5]。

在深度学习技术迅猛发展的当下,大量研究聚焦于提升玉米叶片病害识别的精准度,相继提出了诸多微调后的深度学习模型^[6],涵盖AlexNet^[7]、MobileNet^[8]、VGGNet^[9]、GoogLeNet^[10]、DenseNet^[11]以及ResNet^[12]等。虽然现有的深度学习模型在实际应用场景中具备各自独特优势,然而在某些情形下,依然暴露出一定局限性。这些局限性主要体现在以下几个方面:一是训练模型对训练图像需求量极大,但往往训练图像较为匮乏^[13];二是从野外采集

的植物病害数据集普遍存在数据不平衡问题,并且极易受到环境条件变化的显著影响^[14]。在数据集不够充足的情况下开展模型训练,极有可能导致深度学习模型产生偏差^[15]。所以,为防止模型因数据样本量过少而出现问题,运用平衡的数据集进行训练至关重要。就目前而言,对数据集实施数据扩充是实现数据集平衡最为行之有效的办法^[16]。

在农业领域,随着生成对抗网络(generative adversarial network, GAN)的出现,越来越多的研究人员针对此类数据扩充方法展开了研究与讨论。Stephen等^[17]提出一种基于IBS-DGAN(improved backtracking search algorithm optimized deep generative adversarial network)的水稻病害预测算法,有效解决了预测过程中出现的不稳定和过拟合问题。王志强等^[18]采用WGAN(wasserstein generative adversarial networks)和MCA-MobileNet(multi-scale feature fusion and coordinate attention MobileNet)实现10类番

收稿日期:2025-03-22

基金项目:河南省科技攻关项目(252102520037);河南省重点研发专项(251111211300,231111110100,231111211300);河南省杰出外籍科学家工作室项目(GZS2024006);河南省教育厅高等学校重点项目(25A520044)

李艳玲,E-mail:lyl_lingling@163.com

通信作者:司海平,E-mail:pingsss@126.com;陈丽娜,E-mail:dxn1126@163.com

茄叶片病害识别,有效改善了番茄病害样本不足导致的识别率较低的问题。曾明昭等^[19]提出了一种可以通过CycleGAN生成更多葡萄病害图像的方法,有效地提升了小样本葡萄病害的识别准确率。Chen等^[20]提出使用DCGAN进行葡萄叶病害数据增强和识别,提高了模型的泛化能力和识别准确率。满超等^[21]设计了IAR-GAN用于增强小样本黄瓜叶片病害图像,为复杂环境下小样本的作物叶部病害的准确识别提供新思路。上述研究均采用了基于生成对抗网络(GAN)的数据增强方法来扩充病害图像数据集,以缓解农业病害识别中样本不足的问题。生成对抗网络在图像增强领域的应用愈发广泛,对扩大样本规模和提升样本丰富度起到了重要作用^[22-24]。

虽然基于生成对抗网络(GAN)的相关技术在图像生成领域展现出了一定应用潜力,但在生成高质量图像方面,其能力仍存在欠缺,面临着诸多问题^[25]。以普通的CycleGAN模型为例,当其应用于玉米叶片病害图像生成时,由于原始模型感受野过大、网络深度过浅、提取病害特征能力不足,并在图像生成时有时会省略病斑的生成,导致生成的玉米病害图像往往存在清晰度欠佳、病害特征模糊不突出、真实感不足以及图像间相似度偏高等问题^[26]。

针对上述问题,本研究在基础CycleGAN模型的

框架下提出了一种改进方法,该方法旨在通过小样本病害数据训练生成高质量病害图像,从而降低玉米病害图像的采集成本。具体思路如下:(1)在基础CycleGAN网络的编码层与解码层的初始卷积块中,将原先 7×7 像素大小的卷积核优化为 3×3 像素大小的卷积核,实现网络深度的增加以及明显病害特征的提取,使得采集到的病害图像更真实。(2)在基础CycleGAN网络的转换层中,将挤压-激励注意力机制(squeeze-excitation, SE)嵌入到原有残差块内,使其构成SE-ResnetBlock模块,该模块可使算法更聚焦于叶片病斑位置,提高生成器生成图像的病害真实性。

1 材料与方法

1.1 试验数据集

在本研究中,试验数据集是由常见的3种玉米叶片病害图像(玉米大斑病、玉米普通锈病、玉米灰斑病)以及健康叶片图像共同组成的。典型的数据样本情况如图1所示。健康叶片的图像一共有510幅,玉米大斑病的图像数量为554幅,玉米普通锈病的图像有578幅,玉米灰斑病的图像则是511幅。这些图像均来自Kaggle官方网站(<https://www.kaggle.com/>),具体情况如图1所示。




图1 玉米叶片病害图像

Fig. 1 Image of maize leaf diseases

1.2 循环对抗网络

CycleGAN是一种无需依赖成对数据即可训练的非对称图像迁移网络,具有强大的泛化能力,能够通过捕捉不同图像域的特征映射关系实现多样化图像转换;在农业病害数据增强领域,只要提供足够多样化的玉米叶片病害图像,该网络就能生成符合目标域特征的新样本,从而有效扩充病害数据集并缓解样本不足导致的模型识别性能瓶颈,因此可作为玉米叶片病害数据集扩充的高效方法。

CycleGAN的损失函数主要涵盖对抗性损失、循环一致性损失以及身份损失3个部分^[27]。对抗性损失函数结构 L_{GAN} 如下:

$$L_{GAN}(G, D_T, S, T) = E_{t \sim P_{data}(t)}(\log D_T(t)) + E_{s \sim P_{data}(s)}(\log(1 - D_T(G(s)))) \quad (1)$$

$$L_{GAN}(F, D_S, T, S) = E_{s \sim P_{data}(s)}(\log D_T(s)) + E_{t \sim P_{data}(t)}(\log(1 - D_S(F(t)))) \quad (2)$$

式(1)~(2)中, L_{GAN} 为对抗性损失函数, E 为数学期望。 S 为源域, s 为源域(健康)中的图像, T 为目标(病害)域, t 为目标域(病害)中的图像, F 为目标域(病害)到源域(健康)的生成器, G 为源域(健康)到目标域(病害)的生成器, D_S 为源域(健康)判别器, D_T 为目标域(病害)判别器。

单独使用对抗性损失函数时,存在“模式崩溃”问题,无法保证生成器将输入准确映射到期望输出,

会导致生成图像丢失大量源域的图像信息,具体到试验中为损失函数无法收敛,结束试验后得到的图像为乱码或是无法进行后续试验的图像。因此,需要加入循环一致性损失函数对其进行约束,防止模式崩塌,梯度异常,并提高转换图像的准确性。循环一致性函数 L_{cyc} 结构如下:

$$L_{\text{cyc}}(G, F) = E_{s \sim P_{\text{data}}(s)} \left(\| F(G(s)) - s \|_1 \right) + E_{t \sim P_{\text{data}}(t)} \left(\| G(F(t)) - t \|_1 \right) \quad (3)$$

最后,在前两个函数的基础上加入身份损失函数,可以对输入和循环生成的图像进行色彩、纹理等方面的约束。身份损失函数 L_{ID} 如下:


$$L_{\text{ID}} = E_{s \sim P_{\text{data}}(s)} \left(\| (G(s) - s) \|_2 \right) + E_{t \sim P_{\text{data}}(t)} \left(\| (\hat{G}(t) - t) \|_2 \right) \quad (4)$$

1.3 改进的 CycleGAN 数据增强方法

由图 2 可知,改进的 CycleGAN 网络由 2 个生

成器与 2 个判别器共同构成,能够实现源域图像(健康图像)和目标域图像(病害图像)之间的非对称转换。其中 X 和 Y 表示真实的玉米健康叶片和病害叶片 2 种不同类型的图像域, x 和 y 分别表示真实健康叶片和真实病害叶片中的图像; G 和 F 表示真实健康叶片图像域 X 和真实病害叶片图像域 Y 相互转换过程所需的生成器; D_X 和 D_Y 是对应的判别器。

从域 X 到域 Y 的转换过程可以描述为: X 域中的真实图像 x 通过生成器 G 转化得到具有 Y (病害)风格的生成图像 $G(x)$ (本研究生成的目标病害图像), 将生成图像 $G(x)$ 输入到生成器 F 得到重建图像 $F[G(x)]$ 。接着将生成病害图像 $G(x)$ 与真实病害图像 y 送入判别器 D_Y 以判断真假, D_Y 旨在区分生成样本 $G(x)$ 和真实样本 y , D_Y 通过计算得到 y 和 $G(x)$ 属于 Y 域的概率 $D_Y(y)$ 和 $D_Y[G(x)]$ 。



红色虚线部分为改进部分。The red dotted area represents the improved part.

图 2 改进的 CycleGAN 网络结构

Fig. 2 Structure of improved cyclegan network

在改进的 CycleGAN 网络中进行数据增强,首先将相同像素大小的真实图像与病害图像输入到编码层进行下采样操作;之后进入转换层进行图像特征的提取与转换;最后进入解码层进行上采样操作。在此过程中,以健康图像与玉米大斑病图像的训练为例,生成器与判别器进行对抗训练,学习到玉米大斑病的病害特征后,在健康图像上与病害特征进行

结合,最后生成全新的玉米叶片病害图像。

普通 CycleGAN 模型生成的玉米叶片病害图像通常存在模糊、病害特征不明显、真实性差以及图像相似度高等问题。鉴于此,需要对 CycleGAN 网络进行改进设计。具体的改进措施如下:(1)在基础 CycleGAN 网络的转换层中,将挤压-激励注意力机制嵌入到原有残差块内,使其构成 SE-ResnetBlock 模

块;(2)在基础 CycleGAN 网络的编码层与解码层的初始卷积块中,将原先 7×7 像素大小的卷积核优化为 3×3 像素大小的卷积核。

1)嵌入注意力机制。原始 CycleGAN 网络的生成器采用编码器-解码器结构,用于将 B 域(健康)图像转换为 A 域(病害)图像。在转换层结构中,原 CycleGAN 网络通过堆叠 9 个残差结构块实现图像转换,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^[28]插入到转换层中的原始残差块中,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,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 SE-ResnetBlock 模块。残差注意力模块结合了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,融合了各通道间的关系,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。

2)生成器网络结构优化。对 CycleGAN 网络生成器进行结构优化,将原来网络生成器中卷积块的 7×7 卷积核全部替换为 3×3 卷积核。图 4 为改进的 CycleGAN 网络生成器结构图(红色虚线部分为改进部分)。小尺寸的卷积核感受野较小,对图像的细节信息更为敏感,可以生成目标较小的玉米叶片病斑,再通过堆叠小尺寸卷积核,达到与大尺寸




图 3 SE-ResnetBlock 模块结构

Fig. 3 Structure of SE-ResnetBlock module

卷积核扫描范围的一致。在参数量方面,通过将多个 3×3 卷积核进行堆叠,其扫描范围可与 7×7 卷积核的扫描范围相媲美,且 7×7 卷积核的参数量为 $7 \times 7 \times N$ (N 为输出通道数),而 3 个 3×3 卷积核的参数量为 $3 \times 3 \times 3 \times N$,相当于原先参数量的一半。在网络深度方面,用 3 个小卷积核取代大卷积核,可使网络深度增加,提高特征提取能力,降低过拟合风险。




图 4 改进的 CycleGAN 网络生成器结构

Fig. 4 Structure of improved CycleGAN network generator

1.4 试验环境及配置

试验环境配置如下:操作系统为64位版Windows10,使用python语言,版本为3.7.0,深度学习框架采用Pytorch,在该环境下进行网络的搭建、数据集的训练与测试。中央处理器为Intel i5-12400F,图形处理器为NVIDIA RTX 3060 Ti显卡,显存容量为8 GB。

1.5 试验设置

试验设置组包括玉米大斑病、玉米普通锈病和玉米灰斑病3组病害。训练集与验证集比例设置为10:1,优化算法采用Adam,生成器和判别器的学习率设定为0.0002,批处理大小为32,生成图像规格为256像素×256像素,并经过300个epoch的迭代训练后,终止训练。对比试验是在AlexNet、VGGNet和ResNet 3种识别网络上进行识别准确率对比,迭代次数为100次。每组试验设置完全相同。

1.6 评价指标

在评估GAN系列模型生成的图像时,通常主要关注以下几个方面:真实性、多样性以及结构一致性。真实性指的是生成的图像是否符合人类对现实世界的认知与期望,从而使观察者确信其为真实存在的图像^[29]。多样性则体现在GAN系列模型能否生成具有各异特征的样本。至于结构一致性,它关乎生成的图像在多大程度上保持了其局部和整体结构的稳定性,这些因素共同构成了对GAN系列模型生成图像质量的评价。

因此,本研究选择GAN-train、GAN-test、FID作为衡量GAN生成图像性能的指标。其中GAN-train是指利用GAN生成的图像对分类器进行训练,然后在真实图像上进行测试(相当于召回率)。而GAN-test则是以真实图像为训练样本,对分类器进行训练,之后在生成的图像上进行测试,从而实现对GAN模型生成图像质量的评估(相当于精确率)。通过这2种指标,可以判断GAN生成的图像是否具备多样性和真实性,为GAN的改进和优化提供有力支持,以便更好地应用于实际场景中。GAN评估的原理如图5所示。

FID(feature inception distance,公式中记作 F_{ID})评价指标通过Inception网络分别提取生成图像和真实图像的特征向量,并计算两者在特征空间中分布差异的统计距离^[30]。FID分数越低,表明生成图像在视觉真实性和数据多样性方面越接近真实数据分布。FID计算公式为:

$$F_{ID}(x, g) = \|\mu_x - \mu_g\|^2 + t_r(C_x + C_g - 2\sqrt{C_x C_g}) \quad (5)$$




图5 GAN评价指标处理流程

Fig. 5 GAN evaluation index processing process

式(5)中, x 为真实样本数据分布, g 为生成样本数据分布, μ 、 C 为提取特征后特征向量的均值和协方差, t_r 为矩阵的迹。

2 结果与分析

2.1 生成图像展示

玉米叶片病害生成图像对比图如图6所示。图示中的第1列为由原始CycleGAN生成的3种不同病害的病斑图像,第2列为CycleGAN-1生成的病害图像(CycleGAN-1即只在生成器中将卷积核的大小改为 3×3),第3列为改进的CycleGAN网络(I-CycleGAN)生成的病害图像,第4列为各个病害的真实图像。由图6可知,原始CycleGAN网络生成的图像在真实性和清晰度方面存在不足,病害特征不够明显,并且有时无法完整地生成图像;当网络改进为CycleGAN-1后,虽然相较于原始CycleGAN的生成图像有所提升,但图像仍然存在一定程度的模糊,且生成病斑质量较差。本研究提出的I-CycleGAN网络更加清晰,接近于真实病斑图像。

2.2 对比试验

为了精准评估改进的I-CycleGAN网络模型在玉米病害叶片图像生成方面的性能表现,本研究以基础CycleGAN网络模型为基准模型,引入DCGAN、DCGAN+^[31]与WGAN,并将改进的I-CycleGAN网络模型一并纳入对比分析体系。为构建全面且严谨的试验体系,本研究首先对这3种病害图像进行扩充,整合到原始数据集中共同构成训练集。其次,在预先训练的3种不同的识别网络上进行了试验和测试;最后,将各对比网络生成的病害叶片图像,分别输入至AlexNet、VGGNet以及ResNet这3种在图像识别领域广泛应用且具有不同网络深度与结构




图6 I-CycleGAN 网络生成对比图

Fig. 6 Comparison chart of improved CycleGAN network generation

特性的识别网络中,通过严格计算病害识别准确率,实现对不同生成网络性能的量化对比分析。具体试验结果如表1所示。

表1 5种网络模型的3种识别网络准确率对比

Table 1 Comparison of accuracy of three recognition networks among five network models

模型 Models	AlexNet	VGGNet	ResNet	%
CycleGAN	91.30	92.16	93.71	
DCGAN	92.42	93.02	93.94	
DCGAN+	94.24	95.43	96.08	
WGAN	94.58	95.80	96.67	
I-CycleGAN	95.20	96.57	97.15	

由表1可知,本研究提出的I-CycleGAN网络模型相较于原始CycleGAN网络模型,在AlexNet、VGGNet和ResNet上识别准确率分别提升3.90、4.41、3.44个百分点,在病害识别准确率上实现显著提升,表明改进后的网络模型在生成病害图像时,能够有效捕捉病害特征,生成的图像具有更高的真实性与多样性,进而有力验证了该算法在玉米病害叶片图像生成任务中的有效性与优越性。

为进一步从多维度评估生成图像质量,从各类病害生成图像中随机选取500张样本,精确计算其GAN-train、GAN-test和FID分数。由表2可知,I-CycleGAN网络模型中GAN-train和GAN-test相比原始CycleGAN网络模型分别提升至81.25%和68.75%,表明该模型生成的图像在真实性与多样性方面表现更为出色。同时,相较于其他4种模型的FID分数,I-CycleGAN网络模型FID分数分别下降了43.33、32.67、24.24和19.72,表明利用改进的I-


CycleGAN网络模型生成图像的病害特征分布与真实图像的病害特征分布更为接近,且生成图像的多样性也得到进一步增强。

表2 3个评价指标下5种网络模型的对比

Table 2 Comparison of five network models under three evaluation indicators

模型 Models	GAN-train/%	GAN-test/%	FID score
CycleGAN	78.12	64.50	108.29
DCGAN	78.42	65.89	97.63
DCGAN+	79.15	66.87	89.20
WGAN	79.64	67.21	84.68
I-CycleGAN	81.25	68.75	64.96

由图7可知,3种识别网络下改进的I-CycleGAN模型识别准确率均显著高于其他4种模型。在AlexNet识别网络上,改进后的I-CycleGAN网络模型最高识别准确率达到95.20%,相较于CycleGAN、DCGAN、DCGAN+和WGAN模型,分别提升了3.90、2.78、0.96和0.62个百分点;在VGGNet识别网络中,改进后的I-CycleGAN网络模型最高识别准确率为96.57%,较其他4种模型分别高出4.41、3.55、1.14、0.77个百分点;在ResNet识别网络上,改进后的I-CycleGAN网络模型最高识别准确率为97.15%,相比其他4种网络模型分别提升了3.44、3.21、1.07、0.48个百分点。此外,改进后的I-CycleGAN网络模型收敛速度最快,且收敛趋势更易稳定。以上结果表明,相较于CycleGAN、DCGAN、DCGAN+和WGAN这些常用网络模型,改进的I-CycleGAN网络模型能够生成更为真实且多样性更高的玉米叶片病害图像。



A: AlexNet 识别准确率 AlexNet recognition accuracy; B: VGGNet 识别准确率 VGGNet recognition accuracy; C: ResNet 识别准确率 ResNet recognition accuracy.

图7 3种识别网络下的识别准确率统计结果

Fig. 7 Statistical results of recognition accuracy under three recognition networks

2.3 与传统数据增强算法比较

为验证本研究改进的数据增强算法与传统数据增强算法对病害识别准确率的影响,以原始500张病害图像为基准进行训练,在此基础上进行3组对比试验,第一组为仅采用原始病害图像进行训练,第二组为通过传统数据增强方法增强的数据结合原始数据集进行训练,第三组为改进的I-CycleGAN数据增强算法生成的数据结合原始数据集进行训练(选用ResNet识别网络进行测试)。由表3可知,本研究改进的数据增强算法优于传统数据增强方法,在病害识别准确率上达到97.03%,高于其他2组试验结果。究其原因,传统增强方法只是对原始图像进行基本的旋转平移等操作,并没有实质性的特征变换,还是原来的语义信息。而改进的I-CycleGAN数据增强算法生成的图像产生了新的样本特征,不仅扩充了数据集的数量,同时增加了数据集的多样性。因此,本研究改进的算法适用于小样本数据的增强以及数据匮乏的问题,有效地解决了因数据不足导致的过拟合问题。

2.4 消融实验

为了验证改进后的I-CycleGAN网络模型的有效性,在CycleGAN网络模型的基础上应用不同的优化策略进行训练,以生成相应的玉米病害叶片图像扩充数据集,并采用GAN-train、GAN-test和FID作

为评价指标。由表4可知,在对卷积核进行改进并增加网络深度之后,CycleGAN-1网络模型相较于原始CycleGAN网络模型,其GAN-train和GAN-test分别提升1.42、1.52个百分点,FID分数降低19.11。CycleGAN-2网络相比较原始CycleGAN网络模型,其中GAN-train和GAN-test分别提升1.56、2.20个百分点,FID分数降低23.05,说明这2种改进方法的有效

表3 不同增强算法对比结果

Table 3 Comparison results of different enhancement methods

算法 Algorithm	准确率/% Accuracy
无增强算法 No enhancement algorithm	89.85
传统数据增强算法 Traditional data augmentation algorithm	91.24
改进的循环对抗生成网络数据增强算法 I-CycleGAN augmentation algorithm	97.03

表4 本研究模型消融实验对比结果

Table 4 Comparison results of ablation tests on the model in this study

模型 Model	GAN-train/%	GAN-test/%	FID
CycleGAN	78.12	65.63	108.29
CycleGAN-1	79.54	67.14	89.18
CycleGAN-2	79.68	67.83	85.24
I-CycleGAN	81.25	68.75	64.96

性。将2种改进方法相结合,改进后的I-CycleGAN网络模型在GAN-train和GAN-test分别达到了81.25%和68.75%,同时FID分数降低至64.96,表明改进后的I-CycleGAN网络模型生成的图像更加真实,叶片病斑信息更加丰富,更能满足实际应用的需求。

3 讨 论

针对玉米病害图像识别领域中存在的数据集获取艰难、样本数量匮乏以及不同类别病害样本分布不均衡等问题,本研究基于原始CycleGAN网络模型框架,首先对生成器卷积块进行优化,将原有的 7×7 卷积核全部替换为 3×3 卷积核进行运算,降低了模型的参数量,提升了运算效率,加深了网络深度,使得生成的病害图像更加贴近真实情况;其次,在原有残差结构的基础上,将挤压-激励注意力机制融入到原有的残差块内,构建成SE-ResnetBlock模块,更加精准地聚焦于叶片病斑位置,增强了对病害特征的捕捉能力,从而显著提升了生成器生成病害图像的真实性。在对比试验中,改进后的I-CycleGAN网络模型展现出了卓越的性能优势。在3种病害网络识别中,其生成图像的准确率均达到最高水平。同时,GAN-train提升至81.25%,GAN-test提升至68.75%,而FID分数则下降至64.96,各项指标均优于对照模型。

综上所述,本研究通过两方面的关键改进显著提升了CycleGAN网络模型在玉米叶片病害图像增强中的性能:一是在转换层中嵌入挤压-激励注意力机制构建SE-ResnetBlock模块,二是在编码层与解码层的初始卷积块中将 7×7 卷积核优化为 3×3 卷积核。改进后的I-CycleGAN网络模型有效缓解了数据不足的问题,为玉米叶片病害图像的增强与识别提供了可靠的技术支持。虽然改进后的模型在生成图像质量上优于其他对比模型,但由于结构复杂度增加导致参数量上升,需要更多计算资源和更长的训练时间,这一不足有待未来进一步优化以提升模型的实用性和部署效率。

参考文献 References

- [1] ROUF SHAH T, PRASAD K, KUMAR P. Maize, a potential source of human nutrition and health: a review [J/OL]. Cogent food & agriculture, 2016, 2 (1) : 1166995 [2025-03-22]. <https://doi.org/10.1080/23311932.2016.1166995>.
- [2] ESMAEILINEZHAD A, ABBASI H. Physicochemical, thermal and microstructural properties of new developed bigels through Zein and Persian gum biopolymers [J]. Journal of food measurement and characterization, 2025, 19 (3) : 1693-1706.
- [3] KUSUMO B S, HERYANA A, MAHENDRA O, et al. Machine learning-based for automatic detection of corn-plant diseases using image processing [C]//2018 International Conference on Computer, Control, Informatics and its Applications (IC3INA). November 1-2, 2018, Tangerang, Indonesia. Tangerang: IEEE, 2018: 93-97.
- [4] ZHANG X H, QIAO Y, MENG F F, et al. Identification of maize leaf diseases using improved deep convolutional neural networks [J]. IEEE access, 2018, 6: 30370-30377.
- [5] SHARMA V, TRIPATHI A K, DAGA P, et al. ClGanNet: a novel method for maize leaf disease identification using ClGan and deep CNN [J/OL]. Signal processing: image communication, 2024, 120: 117074 [2025-03-22]. <https://doi.org/10.1016/j.image.2023.117074>.
- [6] CARRARO A, SAURIO G, MARINELLO F. Towards rigorous dataset quality standards for deep learning tasks in precision agriculture: a case study exploration [J/OL]. Smart agricultural technology, 2025, 10: 100721 [2025-03-22]. <https://doi.org/10.1016/j.atech.2024.100721>.
- [7] ALOM M Z, TAHA T M, YAKOPCIC C, et al. The history began from alexnet: a comprehensive survey on deep learning approaches [DB/OL]. arXiv, 2018: 1803.01164 [2025-03-22]. <https://doi.org/10.48550/arXiv.1803.01164>.
- [8] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: inverted residuals and linear bottlenecks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. June 18-23, 2018, Salt Lake City, USA. Salt Lake City: IEEE, 2018: 4510-4520.
- [9] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [DB/OL]. arXiv, 2014: 1409.1556 [2025-03-22]. <https://doi.org/10.48550/arXiv.1409.1556>.
- [10] AL-QIZWINI M, BARJASTEH I, AL-QASSAB H, et al. Deep learning algorithm for autonomous driving using GoogLeNet [C]//2017 IEEE Intelligent Vehicles Symposium (IV). June 11-14, 2017, Los Angeles, CA, USA. Los Angeles, IEEE, 2017: 89-96.
- [11] HUANG G, LIU S, VAN DER MAATEN L, et al. Densenet: An efficient densenet using learned group convolutions [DB/OL]. arXiv, 2018: 1711.09224 [2025-03-22]. <https://doi.org/10.48550/arXiv.1711.09224>.
- [12] 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). June 27-30, 2016, Las Vegas, NV, USA. Las Vegas: IEEE, 2016:

- 770-778.
- [13] BAO W X, HUANG X F, HU G S, et al. Identification of maize leaf diseases using improved convolutional neural network[J]. Transactions of the CSAE, 2021, 37(6): 160-167.
- [14] BANSAL S, KUMAR A. Automatic deep neural network hyper-parameter optimization for maize disease detection[J/OL]. IOP conference series: materials science and engineering, 2021, 1022 (1) : 012089 [2025-03-22]. <https://doi.org/10.1088/1757-899X/1022/1/012089>.
- [15] 马铁民,曲浩,高雅,等.基于超分辨率生成对抗网络的玉米病害分类识别方法[J].农业机械学报,2024,55(11):49-56. MA T M, QU H, GAO Y, et al. Maize disease classification and recognition method based on super-resolution generative adversarial networks[J]. Transactions of the CSAM, 2024, 55 (11):49-56 (in Chinese with English abstract).
- [16] 武芳,王芹,毛洪贵.小样本在线学习数据处理及学生成绩预测方法研究[J].医药高职教育与现代护理,2024,7(6):502-508. WU F, WANG Q, MAO H B. Research on small sample online learning data processing and student performance prediction methods[J]. Medical higher vocational education and modern nursing, 2024, 7(6) : 502-508 (in Chinese with English abstract)
- [17] STEPHEN A, PUNITHA A, CHANDRASEKAR A. Optimal deep generative adversarial network and convolutional neural network for rice leaf disease prediction[J]. The visual computer, 2024, 40(2):919-936.
- [18] 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 Z Q, YU X Y, YANG X J, et al. Tomato leaf diseases recognition based on WGAN and MCA-MobileNet[J]. Transactions of the CSAM, 2023, 54(5):244-252 (in Chinese with English abstract).
- [19] 曾明昭,高会议,万莉.基于生成对抗网络的葡萄叶片图像数据增强方法[J].仪表技术,2021(5) : 41-44. ZENG M Z, GAO H Y, WAN L. Data augmentation of grape leaf diseases based on generative adversarial network [J]. Instrumentation technology, 2021(5):41-44 (in Chinese with English abstract).
- [20] CHEN Y P, WU Q F. Grape leaf disease identification with sparse data via generative adversarial networks and convolutional neural networks[J]. Precision agriculture, 2023, 24(1) : 235-253.
- [21] 满超,饶元,张敬尧,等.基于改进Inception网络的复杂环境下小样本黄瓜叶片病害识别[J].华中农业大学学报,2023, 42(3) : 152-160. MAN C, RAO Y, ZHANG J Y, et al. Recognition of cucumber leaf disease with small samples in complex environment based on improved Inception network[J]. Journal of Huazhong Agricultural University, 2023, 42 (3) : 152-160 (in Chinese with English abstract).
- [22] 叶阳,沈冰雁,沈毓琦.基于生成对抗网络的抗阴影树木检测方法[J].农业工程学报,2021, 37 (10) : 118-126. YE Y, SHEN B Y, SHEN Y Q. Research on anti-shadow tree detection method based on generative adversarial network [J]. Transactions of the CSAE, 2021, 37 (10) : 118-126 (in Chinese with English abstract).
- [23] LIANG X D, HU Z T, ZHANG H, et al. Recurrent topic-transition GAN for visual paragraph generation[C]//2017 IEEE International Conference on Computer Vision (ICCV). October 22-29, 2017, Venice, Italy. Venice: IEEE, 2017: 3382-3391.
- [24] 韩翔,李玉强,高昂,等.基于改进生成对抗网络的甜樱桃数据增强方法[J].农业机械学报,2024,55(10):252-262. HAN X, LI Y Q, GAO A, et al. Data augmentation method for sweet cherries based on improved generative adversarial network[J]. Transactions of the CSAM, 2024, 55 (10) : 252-262 (in Chinese with English abstract).
- [25] XU B, ZHOU D, LI W J. Image enhancement algorithm based on GAN neural network [J]. IEEE access, 2022, 10: 36766-36777.
- [26] BERTOGLIO R, MAZZUCHELLI A, CATALANO N, et al. A comparative study of Fourier transform and CycleGAN as domain adaptation techniques for weed segmentation [J/OL]. Smart agricultural technology, 2023, 4:100188[2025-03-22].<https://doi.org/10.1016/j.atech.2023.100188>.
- [27] SANDFORT V, YAN K, PICKHARDT P J, et al. Data augmentation using generative adversarial networks (CycleGAN) to improve generalizability in CT segmentation tasks[J/OL]. Scientific reports, 2019, 9 (1) : 16884 [2025-03-22]. <https://doi.org/10.1038/s41598-019-52737-x>.
- [28] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. June 18-23, 2018, Salt Lake City, UT, USA. Salt Lake City: IEEE, 2018: 7132-7141.
- [29] GAN X Y, FERNANDEZ I C, GUO J, et al. When to use what: methods for weighting and aggregating sustainability indicators[J]. Ecological indicators, 2017, 81:491-502.
- [30] 代强,程曦,王永梅,等.基于轻量自动残差缩放网络的图像超分辨率重建[J].计算机应用,2020,40(5):1446-1452. DAI Q, CHENG X, WANG Y M, et al. Light-weight automatic residual scaling network for image super-resolution reconstruction [J]. Journal of computer applications, 2020, 40 (5) : 1446-1452.
- [31] WU Q F, CHEN Y P, MENG J. DCGAN-based data augmentation for tomato leaf disease identification [J]. IEEE access, 2020, 8:98716-98728.

Improved CycleGAN-based method for augmenting images of few-shot maize diseases

LI Yanling¹, ZHANG Boxiang¹, LI Feitao¹, BACAO Fernando², SI Haiping¹, CHEN Lina³

1. College of Information and Management Sciences, Henan Agricultural University, Zhengzhou 450046, China;

2. NOVA Information Management School (NOVA IMS), Universidade Nova de Lisboa, Lisboa 1070-312, Portugal;

3. School of Computer and Information Technology, Shangqiu Normal University, Shangqiu 476000, China

Abstract An improved cycle-consistent adversarial networks (CycleGAN)-based method for augmenting data of maize leaf disease images was designed to solve the difficulties in obtaining image dataset of recognizing maize diseases, insufficient samples, and imbalanced samples across different categories of diseases. Convolutional kernels with smaller receptive fields were used to optimize the structure of the CycleGAN network and generate sample images with high-quality and reduce the occurrence of overfitting. The SE (squeeze-excitation) attention mechanism was embedded into the residual module of the generator to enhance the ability of CycleGAN to extract disease features and allow the network to more accurately capture diseases with small target or features with subtle inter-domain differences. The results showed that the improved CycleGAN reduced the frechet inception distance (FID) value of generated disease images by 43.33, 32.67, 24.24, and 19.72 compared with the original CycleGAN, DCGAN, DCGAN+, and WGAN algorithms. GAN-train and GAN-test increased by 3.13 and 4.25 percentage points compared to that in the original CycleGAN. The improved CycleGAN-based method for augmenting data was used to construct a dataset of maize diseases, and the accuracy of recognizing the maize leaf diseases based on this dataset was significantly improved on three network architectures. AlexNet, VGGNet, and ResNet increased by 3.90, 4.41, and 3.44 percentage points, respectively. Compared with traditional data augmentation algorithms, the disease recognition rate of ResNet network architecture increased by 5.79 percentage points. It is indicated that the improved CycleGAN network effectively solves the problem of insufficient image dataset of maize diseases.

Keywords data augmentation; maize leaf diseases; residual module; cycle-consistent adversarial networks (CycleGAN)

(责任编辑:葛晓霞)