

doi:10.6041/j.issn.1000-1298.2024.11.005

基于超分辨率生成对抗网络的玉米病害分类识别方法

马铁民 曲 浩 高 雅 王 雪

(黑龙江八一农垦大学信息与电气工程学院, 大庆 163319)

摘要: 深度学习在玉米病害识别领域应用广泛并取得了较好的效果,但存在低分辨率条件下训练效果差的问题,本文提出一种基于超分辨率生成对抗网络的玉米病害分类识别模型。为了实现低分辨率玉米病斑图像到高分辨率图像的恢复,提出基于双注意力机制的增强型超分辨率生成对抗网络模型,该模型生成的高分辨率重建图像与其他超分辨率图像重建模型相比,峰值信噪比(Peak signal-to-noise ratio, PSNR)和结构相似性指数(Structural similarity index measure, SSIM)平均提升2.1 dB和0.049;与4种不同的分类网络的结合,准确率均高于低分辨率图像,平均提升28.1个百分点。在模型对比及消融可视化实验中,模型识别玉米病斑准确率平均超出其它模型1.3个百分点,精确率达到97.8%。实验结果表明,双注意力机制的加入和损失函数的改变增加了模型对高频特征的恢复能力和稳健性,提高了玉米叶片病斑分类识别率,可为农作物定点监测或无人机田间监测中低分辨率叶片病害图像的精准识别提供参考。

关键词: 玉米叶片; 病害识别; 超分辨率图像重建; 生成对抗网络

中图分类号: TP391.4

文献标识码: A

文章编号: 1000-1298(2024)11-0049-08

OSID:



Maize Disease Classification and Recognition Method Based on Super-resolution Generative Adversarial Networks

MA Tiemin QU Hao GAO Ya WANG Xue

(College of Information Technology, Heilongjiang Bayi Agricultural University, Daqing 163319, China)

Abstract: Maize is one of the most important food crops in China. Leaf diseases of maize can seriously damage its yield, so the correct identification of disease is of great significance. However, the efficiency of traditional manual identification of leaf diseases is low. The resolution of disease images collected from agricultural fixed points or drone monitoring is low, and the key features are not significant, which cannot meet the image resolution requirements of classification and recognition models. The training effect is poor, making it difficult to accurately identify leaf diseases. To this end, a maize disease classification and recognition model based on an improved super-resolution generative adversarial network (SRGR) was designed. The images of maize leaf disease were divided into four types: large spot, rust, gray spot, and healthy leaves. The data set was divided into low resolution (LR) and high resolution (HR) images that corresponded one-to-one. In order to realize the restoration of low-resolution maize spot images to high-resolution images, this model proposed an improved strategy for the enhanced super-resolution generative adversarial networks (ESRGAN) model based on dual attention mechanism. LR images were input into the high-frequency feature reconstruction network, and channel attention (CA) mechanism after each residual dense block (RRDB) was added to extract deep detailed features of the image, making the model highly targeted in reconstructing high-frequency details and reducing the possibility of pseudo texture phenomenon. The generation network was divided into encoding and decoding parts, and the spatial attention mechanism was introduced into U-shaped dense block with skip layers to maximize the retention of maize disease effective features in the middle and low levels of the LR image of maize lesions. The probability value of high-frequency features in the input feature map was calculated to determine the position of reconstructed lesion features in the image. The WGAN-GP loss function was used to train the

收稿日期: 2024-07-26 修回日期: 2024-08-21

基金项目: 国家自然科学基金项目(52275246)、黑龙江八一农垦大学三横三纵支持计划项目(ZRCPY202018)和黑龙江八一农垦大学人才引进科研启动项目(XDB202115)

作者简介: 马铁民(1980—),男,讲师,博士,主要从事机器学习、推荐系统和图像处理研究,E-mail:mtm_120@sina.com

network to solve the problem of vanishing generator gradients, enhancing the stability of the network. The regenerated lesion images were input into the discriminant network, and images that met HR image standards were input into the ResNet34 classification model to achieve accurate classification and identification of maize leaf lesions, and images that did not meet the standards were returned to the generation network for retraining. The experimental results showed that the addition of the dual attention mechanism and the change of the loss function increased the model's ability to recover high-frequency features and robustness. Compared with other super-resolution image reconstruction algorithms, the high-resolution reconstructed images generated based on the SRGR model improved peak signal-to-noise ratio (PSNR) and structural similarity index measure (SSIM) values, with an average increase of 2.1 dB and 0.049, which was a significant improvement. Four different classification networks were selected for image classification and recognition, and the recognition accuracy of reconstructed images was improved by an average of 28.1 percentage points compared with that of LR images. Among them, the ResNet34 classification model had the highest accuracy compared with AlexNet, VggNet, and GoogleNet models. In the attention module ablation experiment, compared with the other three models, SRGR accuracy in identifying maize lesions exceeded other models by an average of 1.3 percentage points, with an accuracy rate of 97.8%. In the visualization of the recognition results, the heat map of the lesions identified by the SRGR model had the darkest color and the highest recognition degree. In summary, the research result can serve as a reference for accurate identification of low-resolution leaf disease images in crop leaf spot monitoring or drone field monitoring.

Key words: maize leaf; disease identification; super-resolution image reconstruction; generative adversarial network

0 引言

玉米叶片病害一直是困扰种植管理者的主要问题之一^[1]。在玉米叶片病害的影响下,玉米产量会损失40%以上^[2]。然而在大田管理中,人工鉴别玉米叶片病害,效率较低,难以及时发现病害。

近年来,深度学习技术在图像识别与分析及相关领域都有了巨大的突破,新模型、新算法层出不穷,展现出了强大的学习能力和信息处理能力^[3-7]。这些方法被广泛应用到玉米叶片病害分类等农业应用中^[8-11]。深度学习技术可以通过对大量图像的自主学习训练进行病斑精准分类,提高效率、降低人力资源投入,但其准确率依赖于图像清晰、细节完整、像素密度高的高分辨率图像(High resolution, HR),在实际农业定点监测或无人机监测应用中,由于获取的是全景图像,截取后的叶片图像模糊、质量差、关键特征不显著,这些低分辨率图像(Low resolution, LR)输入分类模型后识别性能较低,难以快速而准确地诊断出叶片病害。为了增强分类模型的适应性,越来越多的研究将超分辨率图像重建技术与分类模型相结合。YAMAMOTO等^[12]首先使用图像重建算法将低分辨率图像转换为高分辨率图像用于作物病害识别,该算法应用超分辨率卷积神经网络(Super-resolution convolutional neural network, SRCNN)恢复了番茄叶片图像细节,增强了病害识别效果。CAP等^[13]使用SRCNN和GAN生成用于检测黄瓜病害的HR图像,同样提高了分类性能。

MAQSOOD等^[14]使用超分辨率生成对抗网络(Super-resolution generative adversarial network, SRGAN)与CNN模型相结合的方法用于小麦黄锈病图像的分类识别,重建图像的整体识别准确率为83%,超出基于低分辨率的下采样图像的识别准确率8个百分点。WEN等^[15]使用增强超分辨率生成对抗网络(Enhanced super-resolution generative adversarial networks, ESRGAN)以Plant Village数据集中提取的番茄病害图像重建为基础,在10级分类中的准确率为90.78%,优于LR图像18个百分点,比原始HR图像高4个百分点左右。ZHANG等^[16]将Real-ESRGAN用于水稻病害分类模型中,结果比ResNet18的准确率提高3.08%,比VGG11的准确率提高3.55%。以上研究能够说明,基于生成对抗网络及其改进网络的重建图像能够在一定程度降低LR图像对分类模型的影响,从而提高模型分类性能。但是,上述重建模型均存在重建后图像部分细节流失的问题,导致重建图像与真实图像存在一定的误差差。

注意力机制通过对不同特征赋予不同权重来增强模型的特征提取能力,有效保留图像重要细节信息,进而提高分类的效率和准确性^[17-19]。SONG等^[20]提出基于注意力生成对抗网络Attention-GAN和少样本学习的高精度检测方法,引入的注意力机制使模型能够更多地关注图像的重要部分,模型的准确率、召回率和平均精度分别达到97%、92%和95%,均优于其他基线模型。翟雪东

等^[21]在判别网络中引入通道注意力(Efficient channel attention, ECA)模块,增强了网络对不同通道特征的感知能力,提高了生成网络的泛化能力。ZHOU 等^[22]提出了基于少量数据集的辅助分类器 small-ACGAN 模型来扩展可用数据,该模型在辅助分类器 ACGAN 的生成器模块中加入轻量级的坐标注意来提高图像质量,实验表明,该方法能极大地提高分类器在双倍数据集上的识别准确率,为有效提高植物病害识别精度提供了一种新的数据集扩展方法。CHEN 等^[23]提出了基于重建的单图像生成网络 ReSinGN,该网络通过使用自动编码器替换 SinGAN 中的 GAN,并在自动编码器中加入注意力模块(Convolutional block attention module, CBAM),更准确地捕获图像中的重要特征和结构信息,该模型在训练速度和生成图像方面均优于原模型。这些研究表明,在生成网络中加入注意力机制能有效保留更多细节并更加关注叶片图像中的病害区域。

因此,为了提高低分辨率图像条件下玉米叶片病害分类模型的训练效果,以 ESRGAN 和 ResNet34 为基础模型,提出一种基于双注意力机制改进网络的图像重建方法,并构建玉米叶片病害识别模型(Super-resolution generative adversarial networks ResNet34, SRGR)。为获得高频图像的细节特征,建立高频特征重建网络,利用特征通道之间的相互依赖性计算病斑图像高频细节特征;为保留更多图像底层纹理的有效特征,结合含跳层的 U 形密集块提出一种基于空间注意力机制的高频特征选择方法;为增强网络的稳定性,模型使用 WGAN-GP 损失函数训练网络;最后结合 ResNet34 分类模型,实现玉米病害的精准分类识别。通过与其他超分辨率图像重建模型比较以及消融实验验证模型的图像重建及分类效果。

1 实验数据

1.1 数据来源

玉米叶片病害图像分别来自于公开数据集和自采数据集。公开数据集包含 1 145 幅玉米大斑病图像、1 306 幅玉米锈病图像、574 幅玉米灰斑病图像和 1 162 幅玉米健康叶片图像,图像分辨率为 550 像素×550 像素或以上。自采数据集来源于黑龙江八一农垦大学大庆实验田,采集时通过调整设备分辨率,获取一一对应的 LR 和 HR 叶片图像 80 幅,用作测试集,为减少模型训练时间,其中 HR 图像调整尺寸为 256 像素×256 像素,LR 图像调整尺寸为 64 像素×64 像素。

1.2 数据降质处理

由于训练超分辨率图像重建模型时,需要成对的 LR 和 HR 图像。实验中将公开数据集中的 HR 图像通过高斯模糊、双三次插值下采样和 JPEG 压缩、添加高斯噪声等方法进行降质,调整尺寸到 64 像素×64 像素,用来模拟真实场景下形成的 LR 图像,如图 1 所示。实验中形成 1 600 对 LR 和 HR 图像,按比例 3:1:1 划分训练集、验证集和测试集。

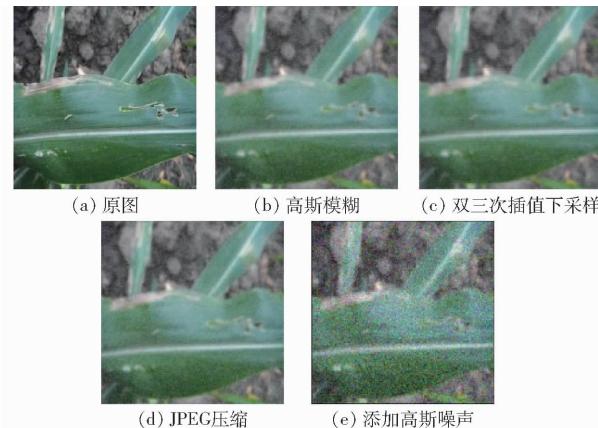


图 1 图像降质效果

Fig. 1 Image degradation effects

2 基于超分辨率重建的玉米病害分类识别模型

为了解决实时采集农业病害图像分辨率较低,无法满足分类识别模型要求的问题,设计了基于改进的超分辨率生成对抗网络的玉米病害分类识别模型(SRGR),整体结构如图 2 所示,主体结构由图像重建网络和分类网络 2 部分构成。

在图像重建网络中,为了保证图像重建的效果,采用 ESRGAN 作为 SRGR 的主干网络。输入的玉米病害 LR 图像,会同时经过高频特征重建网络和生成网络,生成的 HR 图像通过判别网络评估重建的超分辨率特性。

为了恢复图像中的高频细节特征,高频特征重建网络首先使用卷积层提取 LR 图像浅层特征;同时为了提取深层特征,在每个残差密集块(Residual-in-Residual dense block, RRDB)后引入一个通道注意力机制(Channel attention, CA),以特征通道之间的依赖关系为权重,通过该权重赋予每个 RRDB 模块提取的高频图像细节特征权重^[24]。利用通道之间的相互依赖性提取图像的高频细节特征,使模型在重建高频细节上具备较强的针对性,降低产生伪纹理现象的可能性。为了准确定位病斑的重建位置,生成网络中将空间注意力机制(Spatial attention, SA)引入含跳层的 U 形密集块(Dense Block)网络

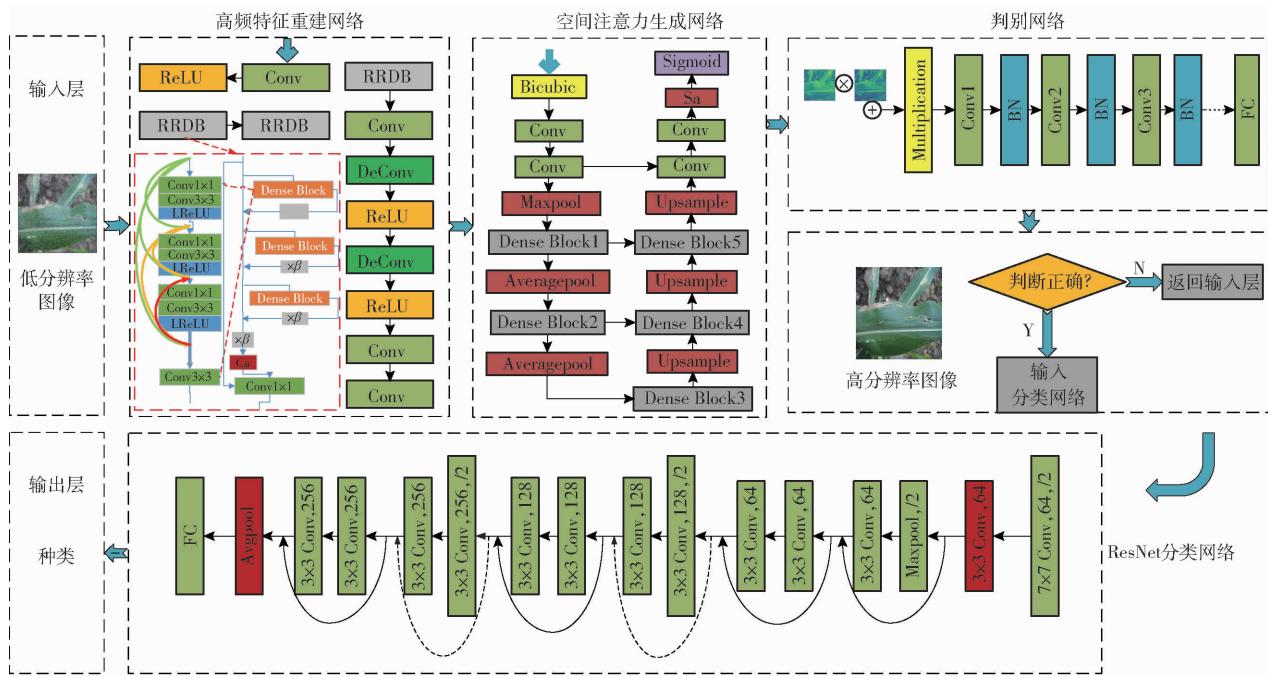


图2 SRGR模型结构图

Fig. 2 Model structure diagram of SRGR

结构中,增强病斑高频特征区域^[25]。空间注意力生成网络分为编码和解码两部分,首先对玉米病斑 LR 图像进行双三次下采样处理。在左侧编码器中,保留输入图像的底层结构和边缘信息完整性,用 2 个卷积层提取浅层特征,最大池化层降低特征数据的维度,最后使用 Dense Block 和平均池化层提取深层特征。在右侧解码器中,利用反卷积层组成的上采样模块和 Dense Block 对提取的特征进行上采样,不同的 Dense Block 通过跳层连接,融合对应部分的浅层特征,使得玉米病斑 LR 图像的底层信息最大限度保留下来。接下来,通过 2 个卷积层结合空间注意力机制将上采样后的特征图调整到与网络输入前相同尺寸,再使用 Sigmoid 函数计算输入特征图中高频特征的概率值,确定图像重建病斑特征位置。

将玉米病斑 LR 图像经过 2 个网络所获得的特征图相乘并添加经过双三次下采样的原始 LR 图像后就会得到重建的超分辨率图像。将重建的玉米病斑图像输入到判别网络中,用多个卷积层进行深层下采样,判断生成网络输出结构是否符合 HR 图像,不符合的图像返回生成网络重新训练,符合的玉米图像输入到 ResNet 分类网络中。

在分类网络中,采用 ResNet 为主干网络,为了提高分类的准确率,设置多层卷积网络,并在每 2 层卷积层中加入跳跃连接,使得每层的输入包含上一层的输出和图像特征,网络层数越深,提取玉米病斑图像的特征与信息越多,最后用全连接层输出结果,得到输入图像的病斑分类识别结果。

2.1 基于双注意力机制的超分辨率重建改进网络构建

为了使重建图像具有和 HR 图像一致的纹理细节,提出基于 SA 生成网络的“定位”和基于 CA 的高频特征重建网络的“重建”改进策略。LR 病斑图像会经过图像高频特征重建网络,基于 CA 的 RRDB 模块会根据学习到的空间关系和重要性进行病斑特征计算。通过双三次上采样模块对输出的病斑图像进行上采样,以进一步提高分辨率,得到重建病斑图像。

为了适应大尺寸图像的精确判别,在判别器网络中,将生成器重建的图像和 HR 图像输入到全域卷积判别器中,以计算判别损失。并使用 Adam 优化器来优化更新网络参数,根据判别器对图像的判别结果,进一步优化生成损失,以提高生成器的性能。为了改善模型稳定性,解决生成器梯度消失问题,采用 WGAN-GP 损失训练模型^[26]。

改进网络的算法构建描述如下:

(1) 初始化参数。设 n 为当前迭代次数, N 为完全迭代次数, p 为已完成批次数, P 为总批次数, Batch-size(i), 设置权重系数 $\alpha = 0.005$, $\beta = 0.01$, $\gamma = 0.5$ 。

(2) 从训练集中取出 i 个样本构成 LR 病斑图像样本集合 $\{x_1, x_2, \dots, x_i\}$, 分别输入到生成器的特征重建网络和注意力生成网络。

(3) 通过特征重建网络计算特征重建网络的重建特征 F_i 。

(4) 通过注意力生成网络计算其高频特征概率 P_i 。

(5) 通过插值函数 $\text{Bicubic}(x_i)$ 将输入样本进行双三次下采样提取特征, 并计算生成器输出的重建图像数据集 $\{G(x_1), G(x_2), \dots, G(x_i)\}$, 其中 $G(x_i) = F_i P_i + \text{Bicubic}(x_i)$ 。

(6) 根据 WGAN-GP 得到判别损失 L_D 。

(7) 使用 Adam 优化器更新 WGAN-GP 判别网络参数 $\omega_1: \nabla_{\omega_1} \gamma L_D$, ∇ 表示梯度运算。

(8) 从训练集样本中再次输入数据 $\{x_1, x_2, \dots, x_i\}$ 到生成器, 得到重建图像 $\{G'(x_1), G'(x_2), \dots, G'(x_i)\}$ 。

(9) 根据判别器的判别结果得到 WGAN-GP 生成损失 L_G 、内容损失 L_{content} 和感知损失 $L_{\text{perceptual}}$ 。

(10) 使用 Adam 优化器更新生成网络的参数 ω_2 , 优化器可表示为 $\nabla_{\omega_2} (\alpha L_{\text{content}} + L_{\text{perceptual}} + \beta L_G)$ 。

(11) 完成病斑图像的超分辨率重建。

2.2 基于 CA 的特征计算

在玉米叶片病害识别中, 病害图像中的病斑部分是关注的重点, 通道注意力机制(CA)可以根据全局信息计算通道特征权重, 增大关键通道特征权重, 减小无效或弱效果的通道特征权重, 使模型训练时权重大的通道更容易被关注^[27]。为了使重建图像中病斑部分具有和 HR 图像一致的纹理细节, 在高频特征重建网络中进行基于 CA 的特征计算。在高频特征重建网络的 RRDB 结构中加入 CA, 输入的 LR 病斑图像会首先基于 RRDB 模块提取病斑特征并生成一个初步的高分辨率估计。生成模块会根据 CA 注意力学习到的空间关系和重要性, 生成注意力图, 两者加权聚合, 引导生成器在重建过程中关注权重较大的区域。

基于 CA 的特征计算描述如下:

(1) 定义网络输入 LR 图像为 y_i 。

(2) 使用一个卷积层提取浅层特征 F_0 。

(3) 通过 n 个 RRDB 模块从 F_0 提取深层特征 F_1 , 表示为

$$F_1 = H_{\text{conv}}(H_{n, \text{RRDB}}(F_0) + F_0) \quad (1)$$

式中 $H_{\text{conv}}()$ —— 卷积操作函数

$H_{n, \text{RRDB}}()$ —— 通过 n 个 RRDB 模块提取深层特征

(4) 通过 CA 计算通道权重 $M_c(F_1)$, 将其与原 F_1 加权相乘, 得到加权通道特征图 F'_1 。 $M_c(F_1)$ 的计算式为

$$M_c(F_1) = \sigma(W_1(W_0(F_{1\text{avg}}^c)) + W_1(W_0(F_{1\text{max}}^c))) \quad (2)$$

式中 $F_{1\text{avg}}^c$ —— 通道维度上全局平均池化特征

$F_{1\text{max}}^c$ —— 通道维度上最大池化特征

$W_1(\cdot), W_0(\cdot)$ —— 多层感知机操作函数

$\sigma(\cdot)$ —— Sigmoid 激活函数

(5) 使用亚像素卷积层放大 F'_1 得到 F_2 , 表示为 $F_2 = H_{\text{UP}}(F'_1)$, 其中 $H_{\text{UP}}(\cdot)$ 为亚像素卷积函数。

(6) 通过 2 个卷积层得到重建特征 F_i , 表示为 $F_i = H_{\text{conv}}(H_{\text{conv}}(F_2)) = (F_i^{(1)}, F_i^{(2)}, F_i^{(3)})$ 。

(7) 输出 F_i 。

2.3 基于 SA 的高频特征概率计算

准确定位玉米病斑特征的位置能够增加重建玉米病斑特征时的准确性。空间注意力机制(SA)通过计算特征图中不同特征的权重, 提取特征图像中的重要信息空间, 进而确定图像中需要重新生成的高频病斑特征位置。该算法属于高频特征的概率方法, 能够快速标识出图像底层特征位置和恢复特征图尺寸, 有效保留图像底层纹理特征, 确定待增强图像高频特征, 实现图像高频细节的恢复。

基于 SA 的高频特征概率计算描述如下:

(1) 定义网络输入 LR 图像为 y_i 。

(2) 对 y_i 进行双三次下采样处理。

(3) 通过注意力生成网络从处理后的 y_i 提取深层特征。

(4) 计算基于 SA 提取深层特征空间权重 $M_s(F_1)$, 将其与原 F_1 加权相乘, 得到加权空间特征图 H'_{SA} 。 $M_s(F_1)$ 计算式为

$$M_s(F_1) = \sigma(f^{7 \times 7}[F_{1\text{avg}}^s; F_{1\text{max}}^s]) \quad (3)$$

式中 $F_{1\text{avg}}^s$ —— 空间维度上全局平均池化特征

$F_{1\text{max}}^s$ —— 空间维度上最大池化特征

$f^{7 \times 7}$ —— 7×7 卷积核降维

(5) 计算提取特征属于高频特征的概率 P_i ,

$$P_i = H'_{SA}(\text{Bicubic}(x_i))$$

(6) 输出 P_i 。

3 实验结果与分析

模型实验与分析基于深度学习框架 Pytorch

1.7.1 和 Python 3.7 完成。网络训练使用 Adam 优化器, Batch-size 为 16, 初始学习率为 0.0001, 迭代次数为 300, 输入的玉米病斑 LR 图像尺寸为 64 像素 \times 64 像素, 输出的重建 HR 图像尺寸为 256 像素 \times 256 像素。

3.1 模型重建效果

为了验证 SRGR 模型的图像重建网络性能, 采用 PSNR 和 SSIM 这 2 个指标来衡量图像的质量。在相同实验条件下, 选择 SRGAN 等 6 种超分辨率重建模型, 实现 3 种不同病斑及健康叶片图像的重建,

重建图像方法平均 PSNR 和 SSIM 对比如图 3 所示。

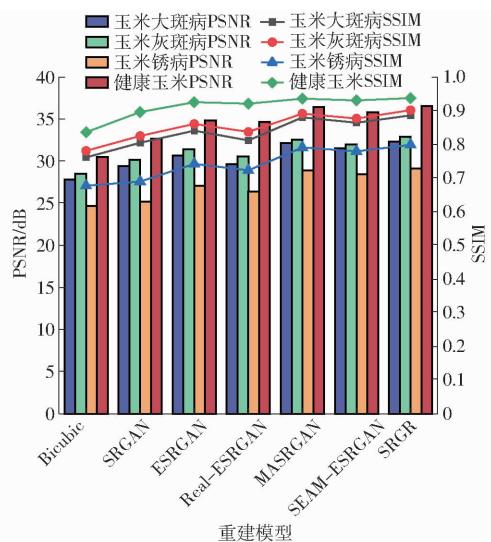


图 3 不同图像重建模型的平均 PSNR/SSIM 对比

Fig. 3 Comparison of average PSNR/SSIM for different image reconstruction models

通过图 3 可以看出, SRGR 模型重建不同病斑图像的指标值均高于其他图像重建模型, 表明与其他模型相比 SRGR 模型能更有效地保证图像质量。与传统的图像重建模型 Bicubic 相比, SRGR 模型的 PSNR 和 SSIM 有明显提升, 平均提高 4.85 dB 和 0.117。与其他基于 GAN 的深度学习模型相比, SRGR 模型的 PSNR 和 SSIM 较 SRGAN 和 Real - ESRGAN 模型也有所提升, 平均提升 2.9 dB 和 0.067。与仅基于通道注意力机制的 SEAM - ESRGAN 模型相比, SRGR 模型的重建玉米病害图像的 PSNR 和 SSIM 平均提高 0.79 dB 和 0.018 2, 比 ESRGAN 模型平均提高 1.72 dB 和 0.038 8。说明, 注意力机制对重建图像质量有较大提升, 并且双注意力机制与单通道注意力机制相比, 提升效果更明显。与 CHEN 等^[28]提出的基于双重注意力机制重建的病害识别模型 MASRGAN 相比, PSNR 和 SSIM 平均提高 0.24 dB 和 0.007。总的来说, SRGR 模型相比于其它 6 种主流图像重建模型的 PSNR 和 SSIM 平均提高 2.1 dB 和 0.049。实验结果表明, SRGR 算法生成的重建图像能够保留更多细节, 更能贴近原始 HR 图像, 可以为低分辨率条件下玉米病害分类识别模型性能提供保证。

3.2 模型分类效果

为了验证 SRGR 模型在分类模型中的应用效果, 分别输入该模型重建的玉米病害图像和低分辨率图像到 AlexNet、VggNet、GoogleNet 和 ResNet34 模型中进行训练, 迭代次数为 50^[29-32], 模型准确度对比如图 4 所示。

红色和蓝色分别表示重建图像和低分辨率图像

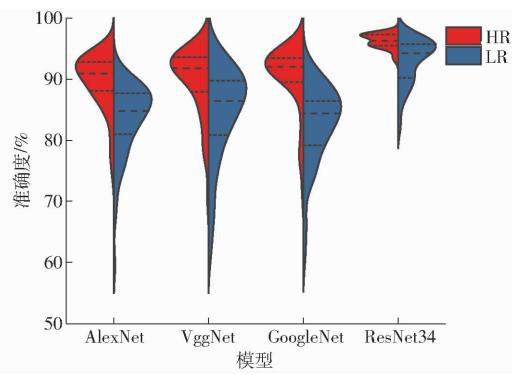


图 4 不同模型验证集的准确度分布情况

Fig. 4 Accuracy distribution of validation sets in different models

的模型识别效果。可以明显看出, 对于不同的分类模型, 红色区域集中部分的准确度均明显高于蓝色部分, 并且红色区域的中位线部分相比蓝色区域也均有所提高, 红色区域的最低点相较于蓝色区域的最低点, 提升 15 个百分点左右, 4 种模型平均识别准确度提高超过 5 个百分点, 使用重建图像的不同分类模型整体训练过程的准确度分布相对于低分辨率图像训练的分类模型均有明显提升。结果表明, 在训练分类模型前, 使用 SRGR 模型重建图像可以减弱低分辨率图像带来的影响, 提高模型识别能力。在 4 种模型中, ResNet 34 的准确度最高。

不同分类模型训练中验证集的损失值变化趋势如图 5 所示。可以看出, 重建的高分辨率图像和低

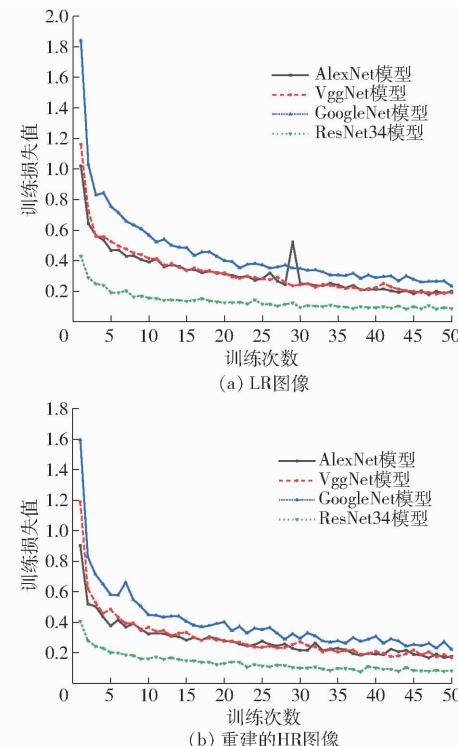


图 5 不同模型验证集损失值变化曲线

Fig. 5 Change curves of loss value for different model validation sets

分辨率图像模型训练中损失值均呈下降趋势, 最终都在一定范围内振荡并达到稳定。但是, 使用 LR 图像的分类模型损失值曲线持续较长的振荡, 在训练的第 30 个训练次数仍有很大的波动。使用重建 HR 图像的分类模型损失值更快速地趋于稳定, 从第 25 次训练就开始逐渐收敛。表明, 基于改进的超分辨率重建图像网络的分类模型 SRGR 训练过程更加稳定, 图像重建可有效提高分类模型的训练效果和稳定性。

3.3 模型注意力模块消融实验

为了进一步说明双注意力机制在 SRGR 模型中的作用, 分别使用去掉双注意力模块、仅去掉通道注意力模块和仅去掉空间注意力模块的 SRGR 模型和完整 SRGR 模型重建玉米病斑 LR 图像, 算法重建出的玉米病斑 HR 图像尺寸为 256 像素 \times 256 像素, 模型准确率、召回率、精确度如表 1 所示。

表 1 SRGR 模型的注意力模块消融性能指标

Tab. 1 Performance comparison of attention mechanism ablation in SRGR model %

模型	准确率	召回率	精确度
SRGR - CA - SA	95.6	95.2	95.3
SRGR - CA	96.9	96.5	96.7
SRGR - SA	97.0	96.8	96.9
SRGR	97.8	97.3	97.7

注:“-”的含义为去除。

由表 1 可以看出, 相比于去掉 CA 和 SA 的 SRGR 模型, 单注意力模型在分类准确率、召回率、精确度评价指标上均有所提升, 说明注意力机制在 SRGR 模型中发挥了提高病斑特征提取和定位的作用, 更有助于模型保留更多病斑细节。并且完整 SRGR 的 3 项指标均达到 97% 以上, 与单注意力机制 SRGR 相比, 准确率分别提升 0.9、0.8 个百分点, 精确度提升 1.0、0.8 个百分点, 召回率分别提升 0.8、0.5 个百分点, 说明双注意力机制对于玉米病害分类模型性能提升更加显著, 在实际应用中, 能够有效解决玉米病害分类模型训练中原始图像分辨率低或原始高分辨率样本不足的问题。

3.4 模型病斑识别可视化

深度学习分类网络模型凭借关键特征识别病斑, 为了进一步验证 SRGR 模型可行性, 通过热力图直观体现病斑的识别效果, 如图 6 所示, 热力图下面的值分别表示对应的准确率、召回率和精确度。

热力图中颜色区域部分即为识别出的病斑部分, 由浅入深表示病斑的识别程度, 颜色越深病斑识别度越高。可以看出, 图 6 中在输入未经重建网络的 LR 图像到分类网络时, 病斑几乎未被识

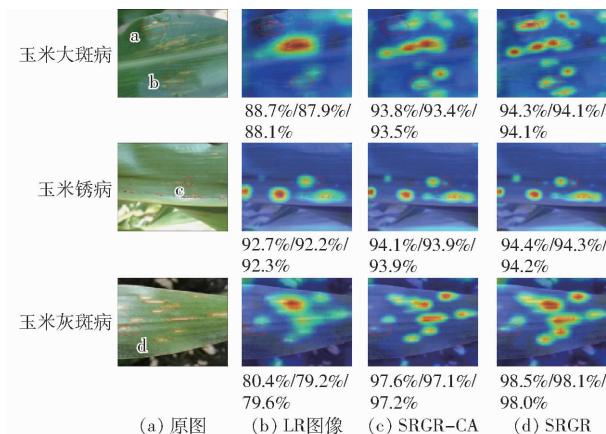


图 6 病斑识别结果可视化图

Fig. 6 Visualization of lesion recognition results

别, 热力图显示颜色很浅, 识别准确率分别仅为 88.7%、92.7% 和 80.4%; 可能是由于特征病斑小或受到病斑位置、光线、叶片纹理等环境特征的影响, LR 图像的病斑分类效果不理想。当输入经过仅有空间注意力机制的 SRGR-CA 模型的重建图像到分类网络时, 图中的病斑能够被识别, 但是热力图颜色标识较浅, 识别程度较差, 3 种病斑识别准确率仅提升 5.1、1.4、17.2 个百分点。当输入经过完整 SRGR 模型的重建图像到分类网络中识别病斑时, 这些区域的热力图颜色标识明显加深, 几乎与原始图像中的病斑细节完全重叠, 病斑识别程度进一步增强, 3 种病斑识别准确率比输入 LR 图像时提升 5.6、1.7、18.1 个百分点。进一步从可视化角度验证了基于双注意力机制的 ESRGAN 改进策略对分类模型性能提升明显, 更能够加强网络对病斑关键特征信息的注意, SRGR 玉米叶片病斑分类识别方法确实可有效提高玉米病斑识别准确性和精确性。

4 结论

(1) 提出了一种基于双注意力机制的超分辨率生成对抗网络改进策略, 基于 CA 的特征计算协助网络实现了在重建过程中更关注病斑区域, 基于 SA 的病斑提取高频特征概率计算能够协助网络快速标识出图像底层特征位置和恢复特征图尺寸。通过图像重建效果分析证明, 基于改进的超分辨率生成对抗网络生成的重建图像能够有效保留图像底层纹理特征, 实现图像高频细节的恢复。通过消融实验证明双注意力机制能够提高病斑特征的提取和定位精确度。

(2) 提出了一种基于改进的超分辨率生成对抗网络的玉米病害分类识别模型 SRGR。实验结果表明, SRGR 模型玉米病斑识别准确率平均超出其他

模型1.3个百分点,达到97.8%。

(3)通过对玉米叶片病斑图像的分类识别的可视化,直观验证了SRGR分类模型能够增强网络对玉米病斑特征的注意,分类效果更加精确,有效改善

玉米病害分类模型训练中原始图像分辨率低或原始高分辨率样本不足的问题,可以为农作物定点监测或无人机农作物田间监测中的叶片病害识别提供一种可参考的方法。

参 考 文 献

- [1] 樊湘鹏,周建平,许燕,等. 基于改进卷积神经网络的复杂背景下玉米病害识别[J]. 农业机械学报,2021,52(3):210–217.
FAN Xiangpeng, ZHOU Jianping, XU Yan, et al. Corn disease recognition under complicated background based on improved convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(3): 210 – 217. (in Chinese)
- [2] 马先红,李峰,宋荣琦. 玉米的品质特性及综合利用研究进展[J]. 粮食与油脂,2019,32(1):1–3.
MA Xianhong, LI Feng, SONG Rongqi. Research on quality characteristics and comprehensive utilization of maize[J]. Cereals & Oils, 2019, 32(1): 1 – 3. (in Chinese)
- [3] 贾兆红,张袁源,王海涛,等. 基于Res2Net和双线性注意力的番茄病害时期识别方法[J]. 农业机械学报,2022,53(7):259–266.
JIA Zhaohong, ZHANG Yuanyuan, WANG Haitao, et al. Identification method of tomato disease period based on Res2Net and bilinear attention mechanism[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53 (7): 259 – 266. (in Chinese)
- [4] 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 Ruirou, 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)
- [5] 孙艳歌,吴飞,姚建峰,等. 多尺度自注意力特征融合的茶叶病害检测方法[J]. 农业机械学报,2023,54(12):308–315.
SUN Yan'ge, WU Fei, YAO Jianfeng, et al. Tea disease detection method with multi-scale self-attention feature fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(12): 308 – 315. (in Chinese)
- [6] 陶兆胜,宫保国,李庆萍,等. 基于残差网络和特征融合的小麦图像修复模型[J]. 农业机械学报,2023,54(3):318–327.
TAO Zhaosheng, GONG Baoguo, LI Qingping, et al. Wheat image inpainting based on residual networks and feature fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(3): 318 – 327. (in Chinese)
- [7] 于明,李若曦,阎刚,等. 基于颜色掩膜网络和自注意力机制的叶片病害识别方法[J]. 农业机械学报,2022,53(8):337–344.
YU Ming, LI Ruoxi, YAN Gang, et al. Crop diseases recognition method via fusion color mask and self-attention mechanism [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(8): 337 – 344. (in Chinese)
- [8] SHARMA V, TRIPATHI A K, DAGA P, et al. ClGanNet: a novel method for maize leaf disease identification using ClGan and deep CNN[J]. Signal Processing: Image Communication, 2024, 120: 117074.
- [9] JESIE R S, GODWIN PREMI M S, JARIN T. Comparative analysis of paddy leaf diseases sensing with a hybrid convolutional neural network model[J]. Measurement: Sensors, 2024, 31: 100966.
- [10] QI J, LIU X, LIU K, et al. An improved YOLO v5 model based on visual attention mechanism: application to recognition of tomato virus disease[J]. Computers and Electronics in Agriculture, 2022, 194: 106780.
- [11] SALIH T A, ALI A J, AHMED M N. Deep learning convolution neural network to detect and classify tomato plant leaf diseases[J]. Open Access Library Journal, 2020, 7(5): 1 – 12.
- [12] YAMAMOTO K, TOGAMI T, YAMAGUCHI N. Super-resolution of plant disease images for the acceleration of image-based phenotyping and vigor diagnosis in agriculture[J]. Sensors, 2017, 17(11): 2557.
- [13] CAP Q H, TANI H, UGA H, et al. Super-resolution for practical automated plant disease diagnosis system[C]//2019 53rd Annual Conference on Information Sciences and Systems. IEEE, 2019:1 – 6.
- [14] MAQSOOD M H, MUMTAZ R, HAQ I U, et al. Super resolution generative adversarial network (SRGANs) for wheat stripe rust classification[J]. Sensors, 2021, 21(23): 7903.
- [15] WEN J, SHI Y, ZHOU X, et al. Crop disease classification on inadequate low-resolution target images[J]. Sensors, 2020, 20(16): 4601.
- [16] ZHANG Z, GAO Q, LIU L, et al. A high-quality rice leaf disease image data augmentation method based on a dual GAN[J]. IEEE Access, 2023, 11: 21176 – 21191.
- [17] 贾璐,叶中华. 基于注意力机制和特征融合的葡萄病害识别模型[J]. 农业机械学报,2023,54(7):223–233.
JIA Lu, YE Zhonghua. Grape disease recognition model based on attention mechanism and feature fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(7): 223 – 233. (in Chinese)
- [18] CAO Y, ZHAO Z, HUANG Y, et al. Case instance segmentation of small farmland based on Mask R – CNN of feature pyramid network with double attention mechanism in high resolution satellite images[J]. Computers and Electronics in Agriculture, 2023, 212: 108073.
- [19] ZHANG W, MA H, LI X, et al. Imperfect wheat grain recognition combined with an attention mechanism and residual network [J]. Applied Sciences, 2021, 11(11): 5139.

- [25] MEHTA S, RASTEGARI M. MobileViT: light-weight, general-purpose, and mobile-friendly vision transformer [J]. arXiv Preprint, arXiv:2110.02178, 2021.
- [26] CHEN J, KAO S, HE H, et al. Run, don't walk: chasing higher FLOPS for faster neural networks[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 12021 – 12031.
- [27] DAI Y, GIESEKE F, OEHMCKE S, et al. Attentional feature fusion[C] // Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision, 2021: 3560 – 3569.
- [28] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6) : 84 – 90.
- [29] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770 – 778.
- [30] SANDLER M, HOWARD A, ZHU M, et al. Mobilenetv2: inverted residuals and linear bottlenecks[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510 – 4520.
- [31] MA N, ZHANG X, ZHENG H T, et al. Shufflenet v2: practical guidelines for efficient CNN architecture design [C] // Proceedings of the European Conference on Computer Vision (ECCV), 2018: 116 – 131.
- [32] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16×16 words: transformers for image recognition at scale[J]. arXiv Preprint, arXiv:2010.11929, 2020.
- [33] LIU Z, LIN Y, CAO Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[C] // Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 10012 – 10022.

(上接第 56 页)

- [20] SONG Y, ZHANG H, LI J, et al. High-accuracy maize disease detection based on attention generative adversarial network and few-shot learning[J]. Plants, 2023, 12(17) : 3105.
- [21] 翟雪东, 韩文霆, 马伟童, 等. 基于改进 AdvSemiSeg 的半监督遥感影像作物制图方法 [J]. 农业机械学报, 2024, 55(8) : 196 – 204.
Zhai Xuedong, Han Wenting, Ma Weitong, et al. Semi-supervised network for remote sensing crop mapping based on improved AdvSemiSeg[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(8) : 196 – 204. (in Chinese)
- [22] ZHOU H, FANG Z, WANG Y, et al. Image generation of tomato leaf disease identification based on small – ACGAN[J]. Computers, Materials & Continua, 2023, 76(1) : 175 – 194.
- [23] CHEN J, HU H, YANG J. Plant leaf disease recognition based on improved SinGAN and improved ResNet34[J]. Frontiers in Artificial Intelligence, 2024, 7: 1414274.
- [24] ZHANG Y, LI K, LI K, et al. Image super-resolution using very deep residual channel attention networks[C] // Proceedings of the European Conference on Computer Vision (ECCV) , 2018:286 – 301.
- [25] LIU Y, WANG Y, LI N, et al. An attention-based approach for single image super resolution[C] // 2018 24th International Conference on Pattern Recognition (ICPR). IEEE, 2018:2777 – 2784.
- [26] 周齐, 杨晓君, 林浩申, 等. 基于 WGAN – GP 的搜索式路径规划算法 [J]. 计算机应用研究, 2022, 39(12) : 3626 – 3630, 3638.
ZHOU Qi, YANG Xiaojun, LIN Haoshen, et al. Search-based path planning algorithm based on WGAN – GP[J]. Application Research of Computers, 2022, 39(12) : 3626 – 3630, 3638. (in Chinese)
- [27] WOO S H, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C] // Proceedings of the European Conference on Computer Vision (ECCV) , 2018:3 – 19.
- [28] CHEN Z, WANG J, JIA C, et al. Pathological image super-resolution using mix-attention generative adversarial network[J]. International Journal of Machine Learning and Cybernetics, 2024, 15(1) : 149 – 159.
- [29] LV M, ZHOU G, HE M, et al. Maize leaf disease identification based on feature enhancement and DMS-robust AlexNet[J]. IEEE Access, 2020, 8: 57952 – 57966.
- [30] SYARIEF M, SETIAWAN W. Convolutional neural network for maize leaf disease image classification [J]. Telkomnika (Telecommunication Computing Electronics and Control) , 2020, 18(3) : 1376 – 1381.
- [31] KRISHNAMOORTHI M, SANKAVI R, AISHWARYA V, et al. Maize leaf diseases identification using data augmentation and convolutional neural network[C] // 2021 2nd International Conference on Smart Electronics and Communication (ICOSEC). IEEE, 2021:1672 – 1677.
- [32] STEPHEN A, PUNITHA A, CHANDRASEKAR A. Designing self attention-based ResNet architecture for rice leaf disease classification[J]. Neural Computing and Applications, 2023, 35(9) : 6737 – 6751.