

基于双生成器生成对抗网络的壁画图像 虚拟修复方法^{*}

杨卓林¹ 曹建芳² 张英俊¹ 彭存赫¹

(1. 太原科技大学计算机科学与技术学院 太原 030024; 2. 忻州师范学院计算机系 忻州 034000)

摘要:针对现有的基于生成对抗网络的壁画修复方法,其生成样本缺乏多样性,容易造成大规模特征丢失等问题。提出一种基于双生成器生成对抗网络(BGGAN)的壁画图像虚拟修复方法。首先,从两个随机方向进行样本生成,保证了生成样本的多样性。其次,对 Dilate U-Net Kares 生成器模型,改进下采样阶段的膨胀卷积扩张率,取消池化操作。最后,设计损失函数,将均方误差(MSE)损失与对抗损失相结合,通过 λ_G 约束生成样本的特征梯度。在所收集壁画数据集上进行修复测试,测试结果与多种图像修复方法对比。结果表明,所提算法获得的图像修复结果细节更清晰。修复后图像的峰值信噪比(PSNR)相较对比模型平均提高了约 1.12 dB,结构相似度(SSIM)平均提高了约 0.047。

关键词:图像处理;壁画虚拟修复;生成对抗网络;U-Net

中图分类号: O436 文献标识码:A 国家标准学科分类代码: 520.6040

The mural image virtual restoration method based on bi-generator generative adversarial network

Yang Zhuolin¹ Cao Jianfang² Zhang Yingjun¹ Peng Cunhe¹

(1. College of Computer Science and Technology, Taiyuan University of Science and Technology, Taiyuan 030024, China;

2. Department of Computer Science and Technology, Xinzhou Normal University, Xinzhou 034000, China)

Abstract: Aiming at the existing fresco restoration methods based on generative adversarial networks, their generated samples lack diversity and are prone to large-scale feature loss and other problems. A virtual restoration method for fresco images based on bi-generator generative adversarial network (BGGAN) is proposed. Firstly, sample generation from two random directions ensures the diversity of generated samples. Secondly, for the Dilate U-Net Kares generator model, the inflated convolutional expansion rate in the downsampling stage is improved and the pooling operation is eliminated. Finally, the loss function is designed to combine the MSE loss with the adversarial loss, and the feature gradient of the generated samples is constrained by λ_G . Restoration tests are performed on the collected mural dataset, and the test results are compared with multiple image restoration methods. The results show that the image restoration results obtained by the proposed algorithm have clearer details. The peak signal-to-noise ratio (PSNR) of the restored image is improved by about 1.12 dB on average compared to the comparison model, and the structural similarity (SSIM) is improved by about 0.047 on average.

Keywords: image processing; virtual restoration of murals; generative adversarial network; U-Net

0 引言

壁画是一门古老而又常新的艺术,但由于年代久远,

很多壁画都受到如裂纹,脱落,褪色,霉变等不同程度的破损^[1]。壁画修复技术最初的修复方法修复过程耗时、费力、需求高精确度的手工技巧,容易对壁画造成二次伤

收稿日期:2024-03-12

* 基金项目:国家自然科学基金面上项目(62372397)、教育部人文社会科学研究项目(规划基金项目)(21YJAZH002)、山西省自然基金面上项目(202203021221222)、山西省文物局 2024 年度文物科研课题(2024KT23)项目资助

害^[2]。近年来,随着信息技术和数字图像处理的快速发展,壁画虚拟修复技术迎来了蓬勃发展的机遇。

图像虚拟修复方法包括传统方法与基于深度学习的方法。传统图像虚拟修复技术通常计算速度较快,对于较小规模的图像修复任务,处理速度可以得到保证。李丽等^[3]使用偏微分方程(PDF)对图像进行降噪修复,运用小波数值方法降低偏微分方程组规模,有效减少了壁画图像中的噪声点。刘义成^[4]针对云南壁画特点,在 criminisi 算法的基础上进行改进,提升了壁画修复效果。焦丽娟等^[5]针对 criminisi 算法在进行壁画图像修复时易出现错误填充的问题,提出优先修复信息丰富块区域的概念,平滑了修复区域边界。但传统方法需要大量的样本数据,难以进行高度受损的图像或复杂背景图片的修复,而基于深度学习的图像修复方法利用深度神经网络,学习图像的统计规律,通过预测和重建缺失或损坏的图像区域来进行图像修复。Pathak 等^[6]在传统自编码器的基础上,提出了上下文编码器,以周围环境为条件,生成任意图像区域。但修复的图像存在质量下降和失真的问题。Goodfellow 等^[7]提出了生成对抗网络(generative adversarial networks, GAN)模型。该模型通过生成器和鉴别器,以竞争的方式进行联合训练。Mirza 等^[8]提出在传统 GAN 基础上,利用一些真实样本所包含的额外信息来增强不同类别物体的修复效果。Donahue 等^[9]提出双向生成对抗网络模型(bi-directional generative adversarial networks, BiGAN)增加了从数据空间到特征空间的生成器(Encoder, E),从而无监督的利用 E 来提取数据特征,但模型容易产生模式崩溃且训练不稳定。高闻需等^[10]将辅助分类器生成对抗网络(auxiliary classifier GAN, ACGAN)结构与具有梯度惩罚的 wasserstein 生成对抗网络(wasserstein generative adversarial nets-gradient penalty, WGAN-GP)损失函数优势结合起来进行数据增强,显著提高了模型对陌生数据的识别能力。Yang 等^[11]提出了多尺度的神经网络 patch 合成方法,使用内容与纹理双生成网络生成图像,但由于使用的是近似最近的邻域搜索算法,并没有捕捉到图像的语言或全局结构。Demir 等^[12]将 Patch GAN 判别器和传统 GAN 的全局判别器结合起来,在保证全局一致性的同时关注到局部的细节纹理信息。Zeng 等^[13]提出了一种基于深度生成模型的金字塔上下文图像编码网络(PEN-Net),保证了修复中图像的视觉和语义的一致性。陈永等^[14]在 PEN-Net 的基础上进行改进,采用自注意力机制及特征融合编码器构建多尺度特征生成器,有效提升了对壁画图像的修复效果。Yu 等^[15]提出了一种语境注意力层来从距离较远的区域提取近似待修复区域的特征,但修复图像通常会产生扭曲的结构或模糊的纹理。Xiangli 等^[16]提出真实性生成对抗网络(realness generative adversarial network, RealnessGAN)多判别器模型,将真实性分布引入到 GAN 的训练中以对抗模式崩溃。Cao 等^[17]在双判别

器的基础上引入扩张卷积增加卷积核感受野,同时采用残差模块,避免梯度消失问题,该算法在缺失面积大的壁画图像中的修复效果良好。胡雅妮等^[18]在壁画图像修复中使用双判别器概念,结合 U-Net 生成网络结构与跳跃连接,提升了修复较大区域受损壁画图像的整体一致性。谢巧雪等^[19]在残差策略基础上融合了结构相似性损失对生成对抗网络进行约束,在视网膜 OCT 图像去噪方面取得较大成果。张双等^[20]提出改进的双阶段生成对抗网络用于壁画修复,设计特征优化融合策略与残差模块,有效缓解了修复结果产生的伪影现象。

针对现有的修复方法存在生成样本质量不高,缺乏多样性,修复结果容易产生模糊与伪影的问题,本文提出双生成器的生成对抗网络模型(bi-generator generative adversarial network, BGGAN),结合技术创新和艺术保护的需求,提高修复效果和效率。

1 基于双生成器生成对抗网络的壁画图像虚拟修复算法

1.1 GAN 模型

GAN 是一种无监督学习方法,由两个相互竞争的神经网络生成器(generator, G)和判别器(discriminator, D)组成,结构如图 1 所示。生成器输入的是随机噪声 Z(在图像修复过程中输入的是受损图像),在生成器 G 中经过一系列的神经网络层来生成样本,目标是生成尽可能真实的样本,判别器以生成器生成样本和原始图像作为输入,目标是区分真实样本与生成样本,通过一系列的神经网络层对生成样本进行二分类判别,判断生成样本为真或假,然后通过损失函数来循环训练生成器与判别器,更新其中的参数,最终得到理想的生成图像。

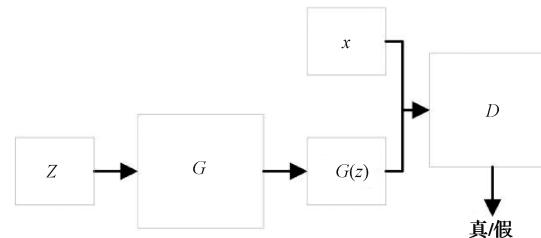


图 1 生成对抗网络结构

Fig. 1 Generative adversarial networks structure

生成对抗网络总损失函数如式(1)所示,其中, $D(x)$ 为判别器对真实样本 x 的输出, $G(z)$ 为生成器的生成样本, $D(G(z))$ 为判别器对生成样本 $G(z)$ 的输出, $P_{\text{data}}(x)$ 为真实数据分布函数, $P_z(x)$ 为噪声数据分布函数。其中生成器的目标是为了让判别器判断生成样本为真,因而生成器目标函数如式(2)所示,是在固定判别器的基础上进行推导得出。判别器的目标为做出尽可能正确的判断,因而判别器损失函数如式(3)所示,同样需要固定生成器。

$$\min_G \max_D V(D, G) = E_{x \sim P_{data}(x)} [\log_2(D(x))] + E_{z \sim P_z(z)} [\log_2(1 - D(G(z)))] \quad (1)$$

$$\min_G E_{z \sim P_z(z)} [\log_2(1 - D(G(z)))] \quad (2)$$

$$\max_D E_{x \sim P_{data}(x)} [\log_2 D(x)] + E_{z \sim P_z(z)} [\log_2(1 - D(G(z)))] \quad (3)$$

1.2 BGGAN 模型

为增加生成样本的多样性,缩短训练时间,解决壁画图像大规模破损区域修复时易产生的模糊、伪影等问题,本文提出 BGGAN 模型用于壁画图像修复,BGGAN 以 GAN 为基础,在其生成器模型与损失函数的基础上进行改进:增加生成器模型数量;用改进的 Dilate U-Net Kares 生成器模型替换原始 U-Net 生成器模型;损失函数选择均方误差(MSE)损失函数与对抗损失函数相结合。该模型

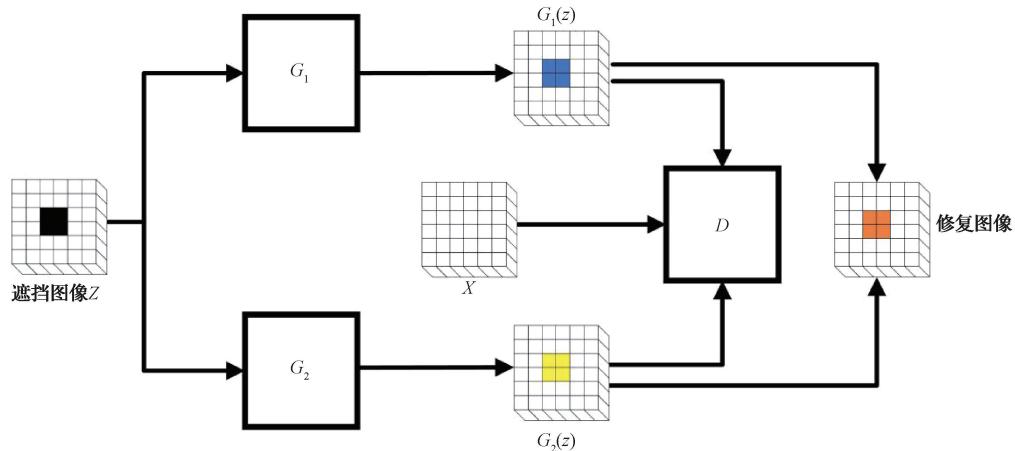


图 2 双生成器生成对抗网络结构

Fig. 2 Bi-generator generative adversarial networks structure

1)生成器网络结构

面对背景与特征都较为复杂,且特征关联性较强的壁画图像,特征提取较为困难,而 U-Net 网络由于跳跃连接对于多尺度,远距离的特征的提取效果较佳。因而,本文生成器模型选择在 Dilated U-Net Keras 模型基础上进行改进:下采样过程中的膨胀卷积部分,使用扩张率逐渐增大的膨胀卷积($dilation=2, 4, 8, 16$)代替之前的固定为 3 的膨胀卷积;在进行下采样时,使用卷积核为 3,步幅为 2 的卷积替换最大池化层减少特征丢失。

调整壁画图片为 128×128 大小的图像,随机生成 24~48 pixels 的矩形缺失区域并标记为 1,其余位置为 0,将原始壁画图像的每个像素与对应掩膜的像素进行按元素的加法,从而使掩膜与原始壁画图像融合,生成随机缺损壁画图像。在生成器中,首先,生成网络输入 128×128 的缺损壁画图像,膨胀卷积与进行特征提取的 3×3 卷积并行操作,通过将并行结果进行跳跃连接融合来保证在特征提取的过程中兼顾整体相关联性。然后,用步长为 2 的 3×3 卷积代替最大池化操作进行下采样,避免因池化操

在进行样本生成时,能够有效提高生成样本的多样性,防止梯度崩溃^[21]。

BGGAN 模型结构如图 2 所示。其中, Z 为被随机掩码遮挡的图像, $G_1(z)$ 、 $G_2(z)$ 分别为两个生成器 G_1 和 G_2 的生成样本, D 为判别器模型。首先,输入带有随机大规模掩膜的壁画图像 Z ,经过双生成器 G_1 、 G_2 分别产生 $G_1(z)$ 和 $G_2(z)$ 两个生成样本。之后,将生成样本分别与原图送入判别器 D ,产生整体评估分数判断生成样本真/假,将结果反馈回生成器与判别器,并根据 MSE 损失函数和对抗损失函数,对双生成器和判别器模型中参数进行循环更新,同时通过约束项 λ_G 引导 $G_1(z)$ 和 $G_2(z)$ 向训练样本进行收缩。最后,将两个生成样本进行融合,从而完成模型训练。

作造成的特征丢失现象,上述操作循环 4 次完成下采样,过程中使用的膨胀卷积扩张率分别为 2、4、8、16。其次,使用步长为 2 的 2×2 卷积进行上采样操作,以此收集更细节的局部信息,并将每一层上采样的结果与下采样中跳跃连接后的结果整合起来再次进行跳跃连接。最终通过 3×3 的卷积操作恢复到原来的通道数。

在进行的每个卷积操作后,通过一个 BN 层来抑制梯度消失问题,除最后一层卷积操作使用 Tanh 作为激活函数外,其余 BN 层后的激活函数均使用 ReLU 激活函数。改进的 Dilated U-Net Keras 网络结构如图 3 所示。

2)判别器网络结构

本文在判别器上选择全局与局部相结合的双判别器模型,将原始图片 x 与一个修复图片放入全局判别器,逐步经过卷积与全连接操作,生成一个全局评估分数。缺损原始区域与生成样本的修复区域放入局部判别器,生成一个局部评估分数。以此对修复图像的局部相似以及整体一致性做出判断,从而进行反馈调整。双判别器中全局判别器比局部判别器多一层卷积层,其余均相同。所有卷积

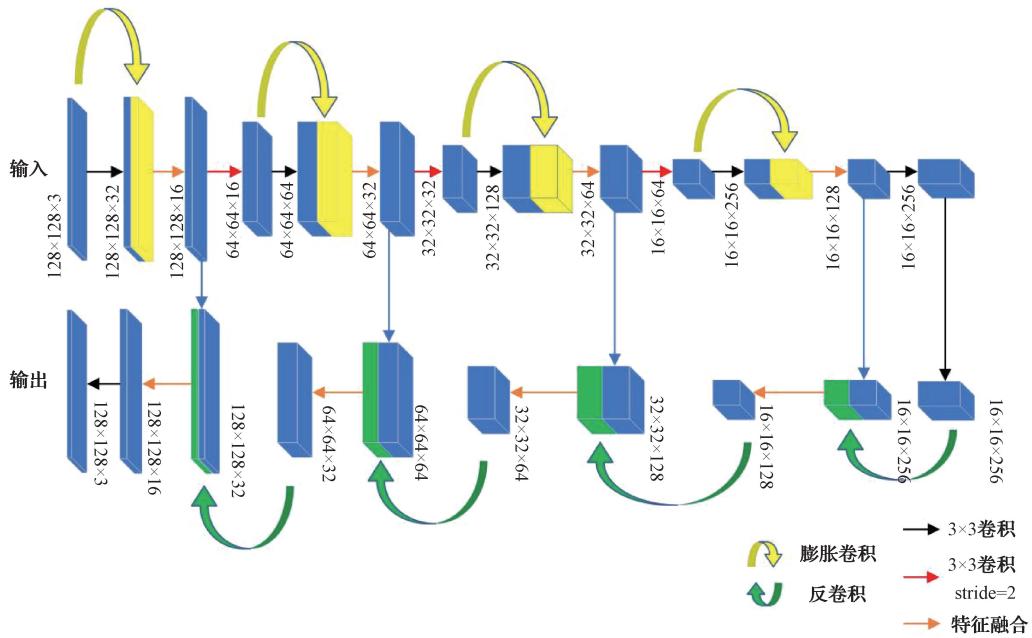


图3 生成器网络结构

Fig. 3 Generative network structure

均使用步长为 2 的 5×5 大小的卷积核。除全局与局部判别器最后一层全连接层外,其余卷积层均通过一个 BN 层来抑制梯度消失问题,激活函数均使用 ReLU 激活函数。

判别器网络模型如图 4 所示,可以看到生成器 $G_1(z)$ 的生成样本与原始图片输入双判别器后,全局判别器与局部

判别器生成全局与局部评估分数的过程。生成器 G_2 通过判别器进行训练的过程与其相同,但两个生成器是分别进行训练的。在每一组的训练过程中通过约束项约束两个生成器生成样本的梯度,从而在特征方向上更好的调整两个生成器的生成结果。

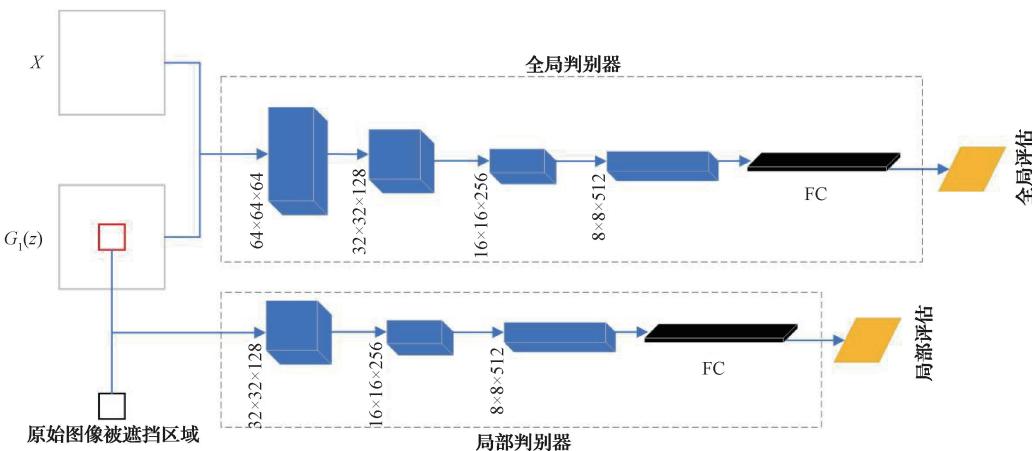


图4 判别器网络结构

Fig. 4 Discriminant network structure

3) 损失函数设计

本文损失函数使用 MSE 损失函数与对抗损失函数相结合。通过 MSE 损失保持图像的结构信息,通过对抗损失提高生成图像的真实性。首先,设置前 80 个 epoch 作为预训练,在预训练阶段,输入被遮挡图像,两个生成器分别生成样本,MSE 函数通过真实图像与生成样本对应区

域平均插值设置。MSE 公式如下:

$$L_{mse} = \frac{1}{M} \sum_{m=1}^M (P_{data}(x) - P_z(x))^2 \quad (4)$$

式中: M 为训练壁画图像数据集; $P_{data}(x)$ 为输入的壁画图像; $P_z(x)$ 壁画图像经过生成器后的生成样本。

预训练阶段之后,使用 MSE 损失函数与对抗损失函

数结合循环训练生成器与判别器,对抗损失函数包括真实样本损失和生成样本损失,公式如下:

$$L_{radv} = -\frac{1}{M} \sum_{i=1}^M \sum_{j=1}^2 (y_i \log_2 r_{i,j} + (1-y_i) \log_2 (1-r_{i,j})) \quad (5)$$

$$L_{fadv} = -\frac{1}{M} \sum_{i=1}^M \sum_{j=1}^2 (y_i \log_2 f_{i,j} + (1-y_i) \log_2 (1-f_{i,j})) \quad (6)$$

式中: L_{radv} 与 L_{fadv} 分别为真实样本与生成样本的对抗损失; y_i 为训练样本的真实标签; $r_{i,j}$ 为模型判断样本属于真实样本的概率; $f_{i,j}$ 为模型判断样本属于生成样本的概率($j=1,2$,分别代表两个生成器)。

因此,本文双判别器中一个的损失函数为:

$$L_{jd} = (L_{radv} + L_{fadv}) \times \alpha \quad (7)$$

式中: L_{jd} 为第 j 个生成器生成样本在判别器的损失函数, α 为一个超参数,用于调节损失的比例。

因为最终的修复目标唯一,从而通过 λ_G 约束项对两个生成器生成样本进行约束,在保证生成样本多样性的同时,提高修复质量,并且加快训练速度。公式如下:

$$L_b = \lambda_G \|G_1(z) + G_2(z)\| \quad (8)$$

式中: $G_1(z), G_2(z)$ 分别为两个生成器的生成样本。

由于本文使用的是 BGGAN 模型,结合双判别器模型,所以本文联合损失函数为:

$$L = \frac{1}{2} \sum_{j=1}^2 (\lambda_1 L_{jmse} + \lambda_2 L_{jgd} + \lambda_3 L_{jld}) + L_b \quad (9)$$

式中: L_{jmse} 为第 j 个生成器生成样本的 MSE 损失; L_{gd} 为全局判别网络的损失函数; L_{ld} 为局部判别网络的损失函数; λ_i 为相应的权重($i=1,2,3$)

2 实验对比与结果分析

2.1 实验环境与数据集

为了验证本文双生成器网络模型在对大规模破损壁画图像修复的效果,本文所有实验在配备为 NVIDIA GTX 1650 的 Win11(64)平台上,基于 Anaconda 以及 PyCharm 的开发环境,运用 Python3.8 编程语言,结合深度学习开源框架 Tensorflow-GPU 1.15.5 上进行,实验使用 Adam 优化算法,Batch-size 为 16,Learning rate 为 0.002。

本文数据集收集了 650 张五台山壁画图像与 230 张敦煌壁画,并通过图像随机旋转、裁剪、镜像翻转、对比度等数据增强算法对数据集扩充至 10 560 幅图片,其中随机取 5% 图像作为测试集,其余作为训练集用于训练模型,并在之后的实验中使用的训练与测试图像集不会改变。

2.2 本文模型对比实验分析

为验证本文算法、BGGAN 模型以及本文改进的 Dilate U-Net Kares 生成器网络模型的优越性,设计 4 组对比试验,其中第 1、第 2 组实验为本文模型与所选文献模型的对比实验,第 3、第 4 组实验为针对本文模型的消融实

验。实验分别选择中心固定掩码与不规则掩码, λ_G 约束项均设置为 0.1。

第 1 组将本文算法与文献[11,13,18]进行对比,通过设置中心固定,大小为 28×28 的掩码,对 5 幅破损壁画图像修复结果进行对比分析。第 2 组模拟真实壁画图像破损情况,通过设置 5 组不规则掩码,与第 1 组实验的对比模型相同,进行实验分析。第 3 组针对生成器模型,在 BGGAN 模型基础上,选择 MSFP、U-Net、Dilate U-Net Kares 与本文模型进行比较。第 4 组针对 BGGAN 模型在训练速度,训练效果上的提升,设置中心固定,大小为 34×34 的掩码,通过对比 Dilate U-Net Kares 和 BGGAN+Dilate U-Net Kares 训练结果。客观评价指标均采用峰值信噪比(peak signal-to noise ratio,PSNR)与结构相似性(structural similarity,SSIM)两种评价指标进行对比分析,在数据上体现本文模型的优越性。

1) 算法实验对比分析

为了验证本文算法对于大规模破损区域壁画图像的修复效果,在数据集中选取 5 幅壁画图像进行测试,添加中心固定,大小为 28×28 的掩码进行修复实验,实验结果如图 5 所示。从修复结果可以看出,文献[11]使用内容与纹理双生成网络生成图像,但由于使用的是近似最近的邻域搜索算法,难以捕捉到全局的语义信息,文献[11]对图像 3 的修复结果可以明显看出颜色产生了偏差,并且存在细节模糊的问题。文献[13]在 U-Net 基础上构建了 PEN-Net,通过对全分辨率输入的上下文语义进行编码,在边界效果上修复结果较好,但从图像 2 与图像 5 的修复结果不难看出,修复区域还是出现了伪影、线条修复模糊的现象。文献[18]通过双判别器结合 U-Net 生成网络结构与跳跃连接,提升了修复较大区域受损壁画图像的整体一致性,但观察文献[18]对图像 5 的修复可以看到当图片待修复区域线条较复杂时,仍会出现修复结果模糊的问题。与对比算法相比,本文算法在面对大规模破损区域时,修复结果在特征一致性,纹理细节,以及结构的整体性都有很好的效果,能基本还原出原始壁画图像,避免出现模糊、伪影的情况。算法的客观评价指标对比结果如表 1 所示,从而客观验证了本文算法在对大规模破损壁画进行修复的优越性。

2) 模拟真实破损情况实验分析

为验证本文算法在面对真实破损壁画图像时的修复能力,通过观察真实破损壁画情况,在本文壁画数据集中人为设置 5 组非矩形掩码模拟真实壁画破损,并对修复结果进行对比分析。实验结果如图 6 所示。

从修复结果可以看出,当掩码设置偏向不规则时,图像修复算法在整合大区域特征时容易将其进行泛化,从而影响对破损区域的修复,如文献[13]对图像 1 和文献[11]对图像 4 的修复。同时,原本在面对规则掩码时对破损边缘修复较为流畅的文献[18]算法,当面对不规则掩码时,破损区域边缘感更加明显(图像 4 和 3)。而本文算法在破

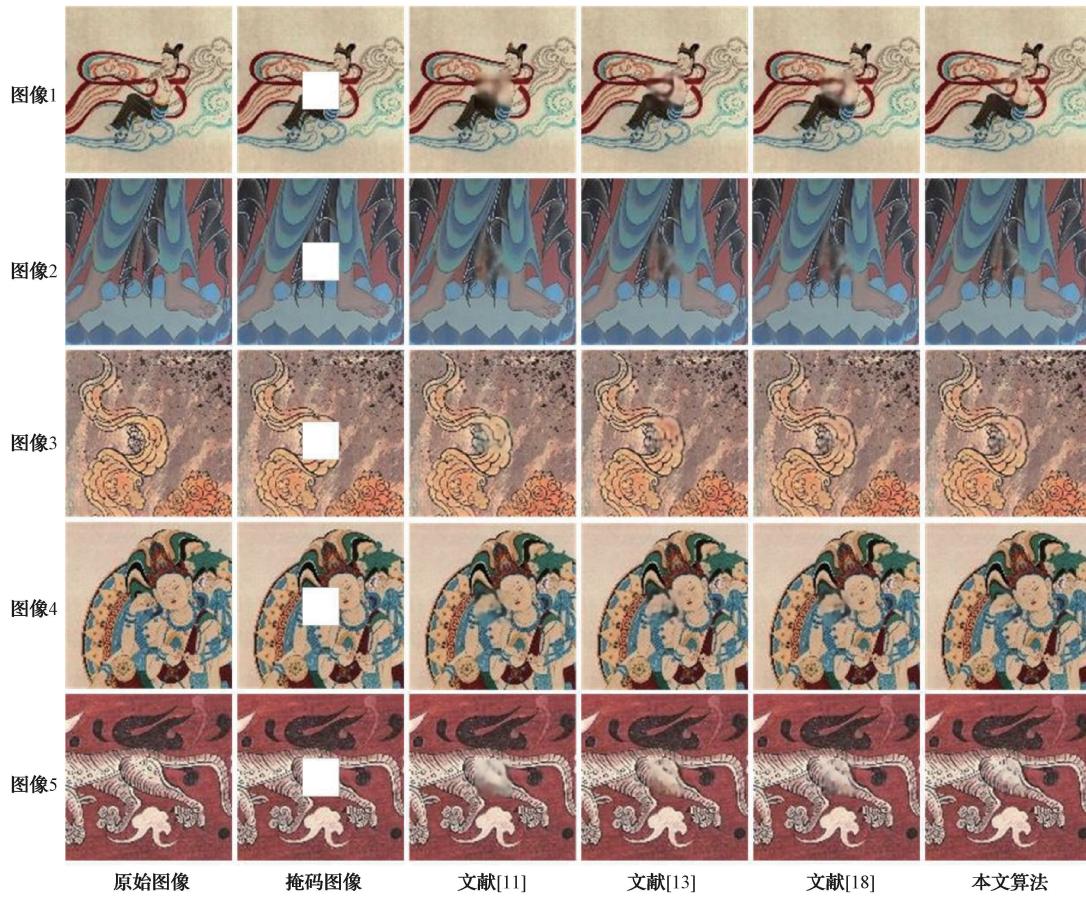


图 5 各算法对中心固定掩码缺损壁画图像的修复结果
Fig. 5 Restoration results of mural defect images by various algorithms

表 1 不同算法 PSNR 和 SSIM 对比

Table 1 Comparison of PSNR and SSIM for different algorithms

原始壁画 图像	文献[11]算法		文献[13]算法		文献[18]算法		本文算法	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM
1	29.64	0.864	30.47	0.891	29.52	0.838	31.49	0.945
2	30.40	0.873	30.45	0.879	30.67	0.884	31.11	0.938
3	30.55	0.858	30.23	0.822	30.30	0.908	30.64	0.916
4	28.35	0.821	29.19	0.838	30.25	0.910	31.15	0.940
5	27.32	0.766	28.34	0.836	29.26	0.897	31.24	0.936

损边缘部分仍然能够达到很好的衔接,并且不会影响到修复图像的质量,同时在主观视觉上优于其他对比算法。表2为本文算法与对比算法在不规则掩码实验中的PSNR与SSIM对比结果,可以较为直观地看出,本文算法的修复结果在PSNR与SSIM上均高于对比算法。

3)生成器模型实验对比分析

为验证改进的Dilate U-Net Kares生成器模型在BG-GAN模型中的优越性,设计对比试验,分别选择MSFP、U-Net、Dilate U-Net Kares与改进的Dilate U-Net Kares生成器模型进行壁画修复对比试验,掩码选择 50×50 大

小,实验结果如图7所示。

从修复结果可以看出,MSFP在特征较为简单的壁画图片中修复结果较好,但当特征变复杂时,出现了明显的线条丢失的现象。传统U-Net模型由于缺乏引导远距离特征的膨胀卷积,容易出现大规模特征丢失现象,从而造成修复结果模糊,出现了伪影。原始Dilate U-Net Kares修复结果较为良好,但在待修复区域特征较为复杂时,仍会出现小区域的线条模糊现象。与其他模型相比,本文改进的Dilate U-Net Kares生成器网络模型的修复结果结构较为完善,线条清晰,在面对大规模破缺区域时,仍能表现

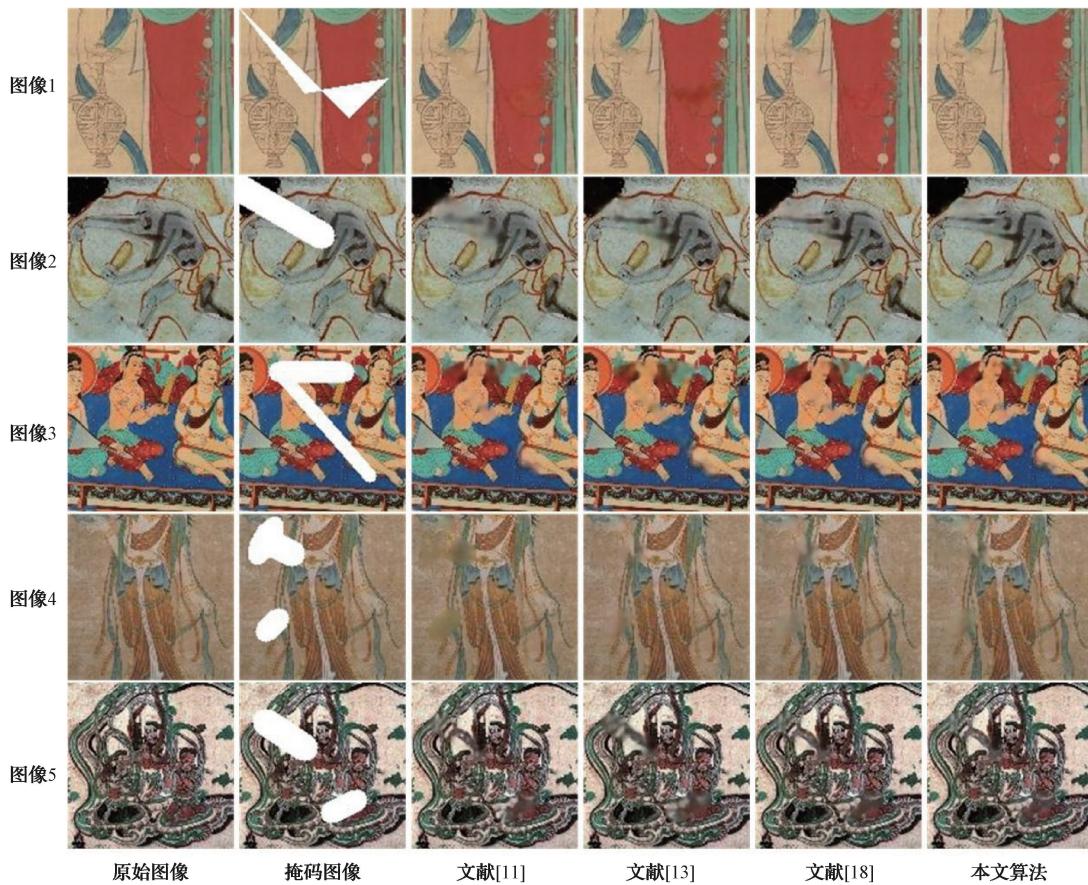


图 6 各算法对随机缺损壁画图像的修复结果

Fig. 6 Restoration results of various algorithms for randomly damaged mural images

表 2 不同算法 PSNR 和 SSIM 对比

Table 2 Comparison of PSNR and SSIM for different algorithms

原始壁画 图像	文献[11]算法		文献[13]算法		文献[18]算法		本文算法	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM
1	29.84	0.906	29.51	0.895	30.77	0.914	31.56	0.927
2	29.33	0.891	30.13	0.916	30.10	0.916	30.82	0.924
3	28.59	0.877	28.17	0.826	30.12	0.904	30.21	0.936
4	29.09	0.872	30.65	0.912	30.35	0.903	30.94	0.933
5	29.38	0.889	28.68	0.824	29.63	0.901	29.83	0.909

出较其他模型更好的修复能力。算法的客观评价指标对比结果如表 3 所示。

4) 针对 BGGAN 模型的实验对比分析

在保证其他条件基本相同的情况下,损失函数使用 MSE 与对抗损失相结合,判别器均使用本文双判别器模型,对比 Dilate U-Net Kares 生成器模型与 BGGAN 模型,分别在 200、400、600、800 epoch 下对壁画图像的修复效果,修复结果如图 8 所示,其对应 SSIM 与 PSNR 数据分别如表 4 所示。

从实验结果可以看出,本文 BGGAN + Dilate U-Net Kares 模型在 400 epoch 时就表现出明显的修复优势,在 600 epoch 时就已经训练完毕,而缺乏 BGGAN 模型,在 800 epoch 左右训练完毕,因而本文 BGGAN 模型可以极大的减小训练时间。并且在修复结果上,对比原始壁画图像,本文模型线条清晰,除部分地方有细微伪影,颜色修复不准确外,与原始壁画图像达到了极高的相似性,缺乏了 BGGAN 模型,在修复结果上仍能观察到大范围的模糊,与原始壁画背景不匹配的问题。

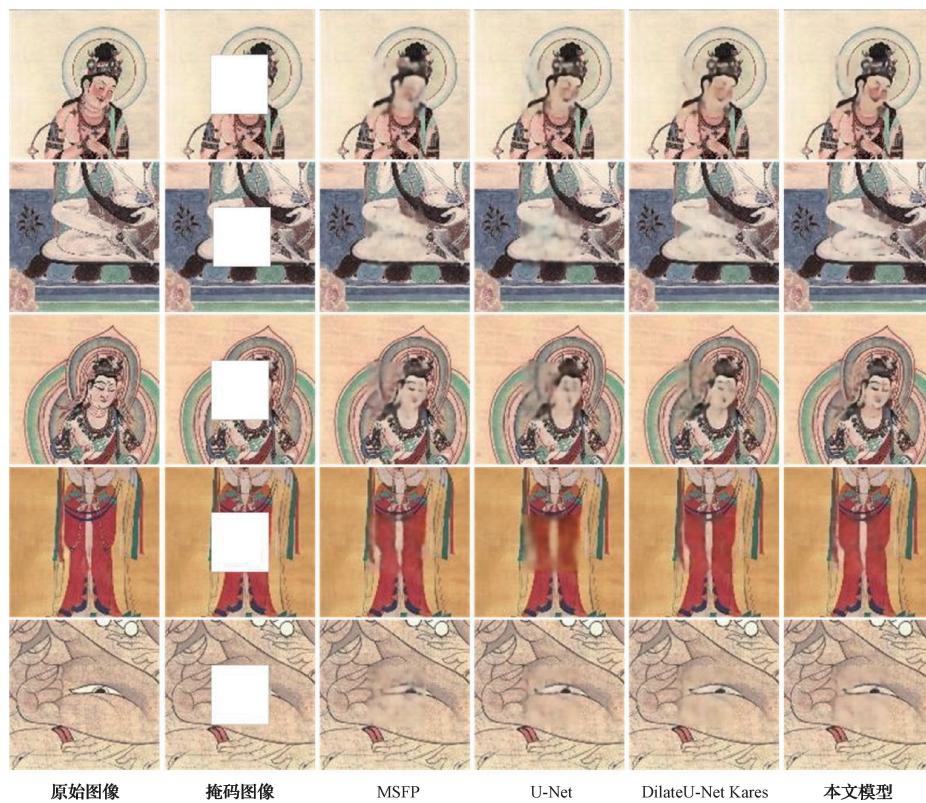


图 7 各生成器模型壁画缺损图像修复结果

Fig. 7 Restoration results of mural defective images by various generator models

表 3 不同生成器模型 PSNR 和 SSIM 对比

Table 3 Comparison of PSNR and SSIM for different generator models

生成器 模型	MSFP		U-Net		Dilate U-Net Kares		本文模型	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM
1	26.70	0.740	26.88	0.742	26.97	0.747	29.19	0.829
2	27.33	0.781	26.71	0.761	28.42	0.831	30.18	0.858
3	27.05	0.794	26.17	0.729	27.21	0.793	28.40	0.796
4	29.21	0.907	26.34	0.735	29.55	0.895	30.07	0.918
5	26.94	0.728	27.31	0.852	27.83	0.881	28.89	0.894

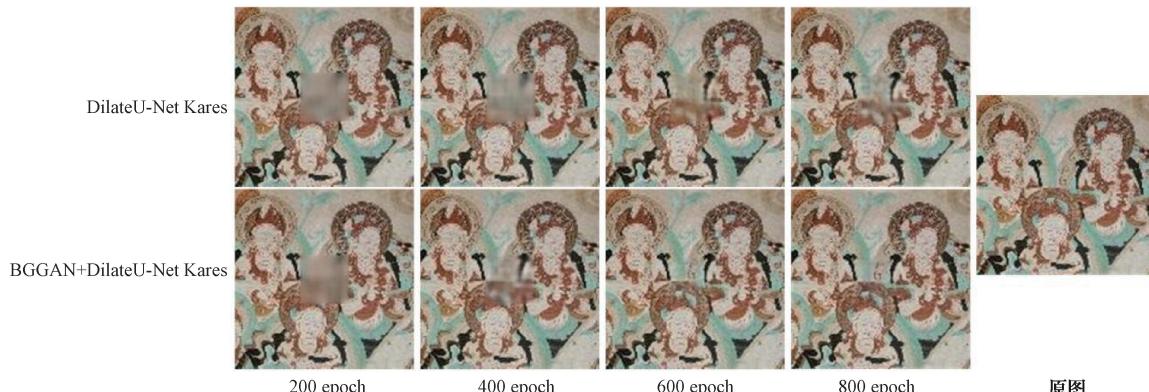


图 8 Dilate U-Net Kares 与 BGGAN+Dilate U-Net Kares 在不同 epoch 下对同一壁画图像的修复结果

Fig. 8 Restoration results of Dilate U-Net Kares and BGGAN+Dilate U-Net Kares on the same mural image at different epochs

表4 不同 epoch 阶段修复图像 SSIM 与 PSNR 对比
Table 4 Comparison of SSIM and PSNR for image restoration at different epochs

评价指标	200 epoch		400 epoch		600 epoch		800 epoch	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM
1	21.33	0.719	22.82	0.742	26.78	0.824	29.02	0.815
2	21.61	0.726	26.56	0.804	30.37	0.936	30.40	0.929

3 结 论

本文提出了一种双生成器生成对抗网络的网络模型用于大规模破损壁画图像修复,生成器模型均使用改进的 Dilate U-Net Kares 特征提取网络模块,重点在于解决 GAN 中生成样本缺乏多样性,训练速度较慢,在进行大规模破损壁画图像修复时修复结果模糊,细节不清晰的问题。在 GAN 中增加生成器模型的数量,使用改进 Dilate U-Net Kares 生成器模型,通过逐步增加膨胀卷积扩张率来减小远距离特征丢失,取消池化操作来减小特征提取时造成的大规模特征丢失。将所提算法与其他提取图片特征较好算法进行比较,实验结果表明,本文模型在大规模破损壁画图像修复结果中,特征一致性更强,纹理细节更清晰,结构的整体性也更完整,客观评价指标(PSNR、SSIM)相比于对比算法也都有所提高。但本文所提方法在面对大规模破损壁画时,修复结果仍会出现部分特征丢失,修复背景与原始图片存在差异的情况。针对这些问题,后续研究将进一步提高模型在复杂场景条件下的特征提取能力,并尝试使用不同的鉴别器网络模型,进一步优化本文算法。

参 考 文 献

- [1] 刘晓琴,侯妙乐,董友强,等.基于高光谱影像的瞿昙寺壁画颜料层脱落病害评估[J].地理信息世界,2019,26(5):22-26.
- LIU X Q, HOU M L, DONG Y Q, et al. Extraction and evaluation of the disease of the mural paint loss[J]. Geomatics World, 2019, 26(5):22-26.
- [2] 李宣妮.古壁画虚拟修复技术研究[D].西安:西安建筑科技大学,2015.
- LI X N. Research on virtual restoration of the ancient murals[D]. Xi'an: Xi'an University of Architecture and Technology, 2015.
- [3] 李丽,高若婉,梅树立,等.基于 Shannon-Cosine 小波精细积分法的壁画降噪修复方法[J].浙江大学学报(理学版),2019,46(3):279-287.
- LI L, GAO R W, MEI SH L, et al. Mural image denoising based on Shannon-Cosine wavelet precise integration method [J]. Journal of Zhejiang University (Science Edition), 2019,46(3):279-287.
- [4] 刘义成.基于改进 Criminisi 算法的云南壁画修复研究[D].昆明:云南大学,2017.
- LIU Y CH. The research of Yunnan murals restoration based on the improved Criminisi algorithm[D]. Kunming: Yunnan University, 2017.
- [5] 焦莉娟,王文剑,李秉婧,等.改进的块匹配五台山壁画修复算法[J].计算机辅助设计与图形学学报,2019,31(1):118-125.
- JIAO L J, WANG W J, LI B J, et al. Wutai Mountain mural inpainting based on improved block matching algorithm[J]. Journal of Computer-Aided Design & Computer Graphics, 2019, 31(1):118-125.
- [6] PATHAK D, KRÄHENBÜHL P, DONAHUE J, et al. Context encoders: Feature learning by inpainting[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 2536-2544.
- [7] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]. Proceedings of the International Conference on Neural Information Processing Systems, 2014: 2672-2680.
- [8] MIRZA M, OSINDERO S. Conditional generative adversarial nets [J]. ArXiv preprint arXiv: 1411.1784, 2014.
- [9] DONAHUE J, KRÄHENBÜHL P, DARRELL T. Adversarial feature learning[J]. ArXiv preprint, arXiv:1605.09782, 2016.
- [10] 高闻霈,杨波,闵琳孜.低分辨率红外感知系统的人体行为数据增强[J].仪器仪表学报,2023,44(1):163-171.
- GAO W P, YANG B, MIN L Z. Human behavior data augmentation for the low-resolution[J]. Chinese Journal of Scientific Instrument, 2023, 44(1):163-171.
- [11] YANG C, LU X, LIN Z L, et al. High-resolution image inpainting using multi-scale neural patch synthesis[C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 4076-4084.
- [12] DEMIR U, ÜNAL G B. Patch-based image inpainting with generative adversarial networks[J]. ArXiv preprint, arXiv:1803.07422, 2018.
- [13] ZENG Y, FU J, CHAO H, et al. Learning pyramid-context encoder network for high-quality image inpainting[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019:

- 1486-1494.
- [14] 陈永, 陈锦, 陶美风. 多尺度特征和注意力融合的生成对抗壁画修复[J]. 北京航空航天大学学报, 2023, 49(2):254-264.
CHEN Y, CHEN J, TAO M F. Mural inpainting with generative adversarial networks based on multi-scale feature and attention fusion[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(2):254-264.
- [15] YU J, LIN Z L, YANG J, et al. Generative image inpainting with contextual attention[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 5505-5514.
- [16] XIAGLI Y B, DENG Y B, DAI B, et al. Real or not real, that is the question[J]. ArXiv preprint arXiv: 2002.05512, 2020.
- [17] CAO J F, ZHANG Z B, ZHAO A D, et al. Ancient mural restoration based on a modified generative adversarial network [J]. Heritage Science, 2020, 8: 1-14.
- [18] 胡雅妮, 李光亚, 韩晓东, 等. 基于双判别生成对抗网络的壁画图像虚拟修复[J]. 国外电子测量技术, 2022, 41(6): 14-19.
HU Y N, LI G Y, HAN X D, et al. Virtual restoration of mural image based on bi-discriminator generative adversarial network[J]. Foreign Electronic Measurement Technology, 2022, 41(6): 14-19.
- [19] 谢巧雪, 马宗庆, 祝连庆, 等. 基于结构相似约束生成对抗网络的视网膜 OCT 图像去噪算法[J]. 电子测量与仪器学报, 2023, 37(3): 11-20.
XIE Q X, MA Z Q, ZHU L Q, et al. Retinal OCT image denoising based on structural similarity constrained generative adversarial network[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(3): 11-20.
- [20] 张双, 杨帆. 改进的双阶段生成对抗数字壁画修复算法[J]. 电子测量技术, 2023, 46(11): 123-129.
ZHANG SH, YANG F. Digital mural inpainting model based on improved two-stage generative adversarial network[J]. Electronic Measurement Technology, 2023, 46(11): 123-129.
- [21] 苟瑶, 李敏, 杜卫东, 等. 基于双向约束的生成对抗网络[J]. 软件学报, 2023, 34(9): 4195-4209.
GOU Y, LI M, DU W D, et al. Generative adversarial network based on bidirectional constraints[J]. Journal of Software, 2023, 34(9): 4195-4209.

作者简介

杨卓林,硕士研究生,主要研究方向为深度学习、图像处理等。

E-mail: yang2021090925@163.com

曹建芳(通信作者),博士,硕士生导师,主要研究方向为数字图像理解、大数据技术。

E-mail: kcxjdjl22@126.com