



计算机科学

COMPUTER SCIENCE

基于特征感知的数字壁画复原方法

徐辉, 康金梦, 张加万

引用本文

徐辉, 康金梦, 张加万. 基于特征感知的数字壁画复原方法[J]. 计算机科学, 2022, 49(6): 217-223.

XU Hui, KANG Jin-meng, ZHANG Jia-wan. Digital Mural Inpainting Method Based on Feature Perception[J].

Computer Science, 2022, 49(6): 217-223.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于时频域生成对抗网络的语音增强算法](#)

Speech Enhancement Based on Time-Frequency Domain GAN

计算机科学, 2022, 49(6): 187-192. <https://doi.org/10.11896/jsjcx.210500114>

[基于生成对抗网络的 5G 网络流量预测方法](#)

Traffic Prediction Method for 5G Network Based on Generative Adversarial Network

计算机科学, 2022, 49(4): 321-328. <https://doi.org/10.11896/jsjcx.210300240>

[基于生成对抗网络去影像的多基频估计算法](#)

Multiple Fundamental Frequency Estimation Algorithm Based on Generative Adversarial Networks for Image Removal

计算机科学, 2022, 49(3): 179-184. <https://doi.org/10.11896/jsjcx.201200081>

[基于改进 CycleGAN 的人脸性别伪造图像生成模型](#)

Generation Model of Gender-forged Face Image Based on Improved CycleGAN

计算机科学, 2022, 49(2): 31-39. <https://doi.org/10.11896/jsjcx.210600012>

[基于深度生成模型的人脸编辑研究进展](#)

Research Progress of Face Editing Based on Deep Generative Model

计算机科学, 2022, 49(2): 51-61. <https://doi.org/10.11896/jsjcx.210400108>

基于特征感知的数字壁画复原方法

徐辉^{1,2} 康金梦¹ 张加万¹

1 天津大学软件学院 天津 300072

2 河南科技学院文化遗产数字传承研究中心 河南 新乡 453000

(huixu@tju.edu.cn)

摘要 敦煌壁画存在多种病害造成的不规则破损区域,运用数字修复的方式对其进行恢复,既不会对原始壁画造成损坏,又可以获得较好的修补效果。由于壁画修补问题中缺失的区域较大,不能用局部非语义的修补方法来实现。针对敦煌壁画缺损区域的修复问题,设计了基于生成对抗网络的图像修补方法,使用语义上合理的内容来渲染缺失区域的像素,实现非接触性壁画场景重建,从而提升壁画虚拟修复准确度。该算法在生成对抗神经网络的基础上引入感知损失函数,在生成模型中添加3层扩张卷积层来收集破损区域的图像特征,利用感知损失提升模型对高频纹理细节的修复能力,运用扩展卷积提取范围特征激励生成模型生成较高质量的图像结果。在敦煌壁画数据集上将所提方法与3种优秀方法进行了比较,修复结果显示所提算法在测试数据集上的PSNR评分提高了1.79%,SSIM评分提高了7.7%。所提修复模型提升了破损壁画的修复精度,使修复结果更加准确。

关键词: 生成对抗网络;壁画修复;感知损失;扩张卷积

中图法分类号 TP181

Digital Mural Inpainting Method Based on Feature Perception

XU Hui^{1,2}, KANG Jin-meng¹ and ZHANG Jia-wan¹

1 School of Computer Software, Tianjin University, Tianjin 300072, China

2 Digitization Technology Research Center for Cultural Heritage Conservation and Promotion, Henan Institute of Science and Technology, Xinxiang, Henan 453000, China

Abstract There are irregular damaged areas caused by various diseases of grottoes in Dunhuang murals, digital restoration is used to restore the image of the Dunhuang grotto murals, which will not cause damage to the original murals, but also get a better repair effect. Because of the large missing area in the mural mending, it cannot be realized by local non-semantic repair methods. Aiming at the restoration of the defective area of Dunhuang grotto murals, this paper designs an image repair method based on the generation of confrontation network, and uses semantically reasonable content to render the pixels in the missing area to realize the reconstruction of non-contact mural scenes, improve the efficiency of mural virtual restoration and the accuracy of restoration. The algorithm introduces a perceptual-loss function on the basis of generating an adversarial neural network, adds a three-layer convolutional layer to the generation model to collect image features of damaged areas, uses the perceptual loss to improve the model's ability to repair high-frequency texture details, and uses extended convolution to extract range features, so as to stimulate the generative model to generate higher quality image results. Compared with three excellent methods on the Dunhuang grotto mural data set, and the repair results show that the PSNR score of the proposed algorithm on the test data set increases by 1.79%, and the SSIM score increases by 7.7%. The proposed repair model improves the repair accuracy of damaged murals and makes the repair results more accurate.

Keywords Generative adversarial networks, Mural inpainting, Perceptual loss, Expansion convolution

1 引言

在文物保护领域,一些珍贵的壁画受环境(如温度、湿度等)的影响,外表出现了一定程度的风化、脱皮、起甲问题。敦煌莫高窟壁画作为世界文化遗产,由于长年累月的风化与

病害,存在一定程度的破损与残缺。其按破损的程度可分为变色破损、褪色破损和脱落破损。变色破损,即壁画在光和其他因素的长期作用下,原始颜色演变成了其他颜色;褪色破损,即壁画原始颜色颗粒脱落或掺杂了粉尘,颜色逐渐变淡;脱落破损,即壁画局部区域的颜料层完全脱落,露出了墙壁的

到稿日期:2021-05-14 返修日期:2021-07-20

基金项目:国家重点研发计划(2019YFC1521200)

This work was supported by the National Key R&D Program of China(2019YFC1521200).

通信作者:张加万(jwzhang@tju.edu.cn)

色彩。从保护文物的角度出发, 直接对原始文物进行修补存在着较大的风险, 一旦操作不当将会加重其损坏的程度, 造成不可挽回的后果, 而数字修补方法避免了这一问题的发生。鉴于文物保护的历史影响, 文物数字修补方法研究成为了文物修复领域的研究重点^[1-3]。

针对不同的破损情况, 目前主要的文物图像修复技术包括: 用于修复脱落破损的图像修补 (Inpainting/Completion) 技术和用于色彩老化或褪色的颜色复原 (Color Rejuvenation) 技术。Bertalmio 等^[4]首次提出数字图像修复这一概念, 通过图像等照度线扩散理论, 即 BSCB 高阶偏微分方程 (Partial Differential Equation, PDE), 实现信息传输机制的污损区域修补; Bertalmio 于 2006 年又提出了依赖于待修补图像的几何信息的三阶最优 PDE 方法^[5]。Chan 等将图像的几何特征曲率引入扩散方程, 提出了 CDD (Curvature Driven Diffusions, CDD) 模型^[6], 将图像去噪模型推广到图像修复领域。Chan 等^[7]提出了最优化图像小波域变换域修复算法, 该算法通过增减辅助变量的值, 将方程中的单变量函数转变为双变量函数, 改善了修复效率。这些基于图像结构的修复方法由偏微分方程和变分法通过变分原理相互推导得到, 其主要思想是艺术家用画笔修复油画时先从无损区的最外边缘处着手, 通过观察污损油画的边缘区域颜色信息进行小尺度修复上色。针对壁画大面积纹理缺失或较大面积破损的补全, 一般采用基于纹理的合成方法。利用纹理映射机制, 通过对像素模块进行分析实现空间位置上的匹配。Drori 等于 2003 年利用自相似原理提出了一种基于碎片的图像补全算法^[8], 通过选择优先权较高的图像块, 实现基于块的纹理合成方法来填充待补全区域。Criminisi 等^[9]采用全局搜索的方式来寻找原始的匹配像素块。Xu 等^[10]提出了补丁优先级措施来填充缺失区域中的结构补丁。Wang 等利用图像分解技术改进 Criminisi 算法进行敦煌壁画修复^[11]。Jiao 等通过引入分散度概念减少了 Criminisi 算法在修复五台山壁画过程中的错误填充问题^[12]。纹理合成的方法虽然在修复大尺度缺损方面表现优秀, 但在保留边缘结构方面还存在瓶颈。

近年来, 随着机器学习的不断推广, 基于学习的图像修复研究取得了巨大成功^[13]。早期基于卷积神经网络的修复局限于小范围修复任务^[14-16], 由于存在瓶颈层 (Bottleneck Layer), 生成的修复结果缺乏精细的纹理细节。生成对抗网络 (Generative Adversarial Network, GAN) 的引入提高了生成结果的清晰度。Pathak 等^[17]提出了一种编码器-解码器网络来预测图像缺失部分的信息, 通过采用对抗损失函数来提升修复图像的视觉质量。Li 等^[18]引入了额外的损失函数来提高修复图片的质量。Iizuka 等^[19-20]依靠 DCGAN^[21]进行对抗监督, 减少了修复过程中的合成与约束环节。针对古建筑文物的修复任务, Zou 等^[22]提出了一种基于自动深度学习的古建筑缺陷模式分割、修复和分类方法。敦煌壁画作为世界非物质文化遗产, 久经历史风霜, 破损类型复杂多样, 即便是单幅壁画也存在多种破损类型, 如果针对不同的破损类型设计特定的算法, 过程十分繁复, 计算量巨大。GAN 方法不但避免了复杂的生成数据的表达式, 还能捕捉更好的特征属性。利用 GAN 进行虚拟修复研究, 无论是对颜色复原、小尺度

缺损还是大块纹理丢失, 都只需把目前保存得比较好的壁画作为真实源数据, 所有类别的破损均可运用生成模型来修复, 过程简单、高效。同时, 由于壁画存在题材内容不同、主观意向性强、线条变化丰富等特点, 在没有先验知识或类比图像时, 根据壁画缺失区域的周边区域, 生成模型便可生成多种新情形。本文创建了可用于训练卷积神经网络的敦煌壁画的数据集, 为敦煌壁画的修复奠定了数据基础; 设计改进了基于生成对抗网络的数字图像修复模型, 通过改进生成对抗网络的结构与损失函数使 GAN 网络对敦煌数据训练收敛, 同时新增感知损失函数以提高破损壁画的修复效果。通过与现有修复方法进行对比发现, 本文算法的修复效果较为突出, 不但能够深入挖掘壁画的艺术特征, 还能依据修补过程获得新的经验知识, 从而使壁画达到语义层面及场景层面的补全, 提升壁画结构一致性。

2 壁画数字修补模型

在当前的人工智能热潮下, 生成式对抗网络^[23]的提出满足了许多领域的研究需求, 各种有效的模型相继出现以适应不同的任务场景^[24-26]。GAN 的核心思想来源于二人零和博弈论, 一方是生成模型 (G), 另一方是判别模型 (D), 两个网络彼此博弈, 通过输入一个训练样本集合, 生成样本概率分布的表征。GAN 网络利用深度卷积网络进行大规模数据的训练, 能够预测缺失区域的图像信息, 可以产生语义上较为相似的修复结果。通过实验可观测到, 上下文编码器的网络在训练过程中的 JS 散度超过恒定值, 导致生成模型的梯度丢失, 无法继续训练网络, 判别模型无法指导生成模型继续优化, 造成上下文编码器的网络在敦煌数据中无法收敛, 训练未能有效提取到敦煌数据特征。

本文提出的壁画修补模型在 GAN 生成模型的基础上增加了 3 层扩张卷积层, 以提升捕获上下文信息的能力, 生成对抗网络搭建过程中采用 WGAN 损失来提升模型的稳定性, 同时构建感知损失捕获纹理高频细节, 细化壁画纹理细节。如图 1 所示, 壁画修复的网络模型由两部分组成: 修复模型和判别模型。修复模型与判别模型是两个完全独立的模型, 通过在训练时的交替迭代训练来交替优化两个模型, 直至生成器和判别器收敛。网络的输入为成对存在的原图和遮罩图像, 将两张图像进行像素之间的点乘运算, 得到的一张带白色遮罩块的图像即为网络的输入图像, 网络的输出为修复后的图像。




图 1 壁画修补模型的框架结构

Fig. 1 Frame structure of mural repair model

2.1 修复模型

修复模型由编码器-扩张卷积-解码器 3 部分组成。网络

的前6层是卷积层,输出高频细节丰富的特征图。经过编码器提取特征的特征图在经过低维度的瓶颈层时,将特征图重构为场景的压缩特征图,由于压缩过程中丢失了部分特征,因此不能学习图像语义特征的分布。为了捕获更多的图像特征,修复模型中间3层采用扩张卷积层作为中间过渡层,以收集更多的破损区域周围的信息。扩张卷积输出通道数不变,在不增加计算数量的基础上增大了卷积核的感受野,提取到了更多的细节信息,从而保证了图像的分辨率,提升了语义修复的准确性。最后的6层是解码层,通过上采样将特征图逐渐恢复到输入图像的大小。批标准化保证每层神经网络在训练过程中的输入分布是一致的,避免网络收敛速度慢。本文采用了LReLU激活函数。修复模型层结构如图2所示。

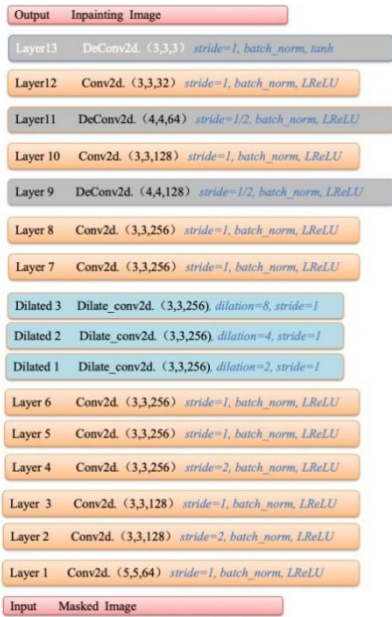


图2 修复模型结构

Fig. 2 Structure of repair model

2.1.1 扩张卷积

为提升图像特征感知能力,网络的生成器将编码器-解码器的全连接层替换为扩张卷积层,以提取更大范围的图像特征。扩张卷积增大了感受野,在图像修复任务中,感受野的大小影响着图像修复结果的质量。由于卷积核包含空洞,在进行卷积操作时会减小图像尺寸并增大感受野,使用参数“扩张率”来定义卷积和数据各值之间的间距。扩张率变大,感受野随之变大,从而提升网络输出的结果。提升感受野的同时,参数量保持不变。感受野的表达式如式(1)所示:

$$RF_i = RF_{i-1} + (k-1) \times \prod_{j=1}^{i-1} s_j \quad (1)$$

其中, RF_{i-1} 表示上一层的感受野, k 表示卷积核的大小, s_i 表示第*i*层的步长。

2.1.2 扩张率

由于扩张卷积之间有0填充的间隔区,因此并不是所有的输入都得到了全部计算。当相邻扩张卷积层使用相同的扩张率时,特征图体现出一种卷积中心点不连续的现象。如图3(a)所示,图中3个扩张率 $Dilation\ rate = 2$ 的卷积层经过连续卷积之后,卷积计算中心出现了一种格子状的不连续现象。颜色的深度表示计算的次数,颜色越深表示计算的次数越多。

为此,本文采用了一种不连续“锯齿状”组合形式的扩张率进行卷积核计算,避免了卷积中心分布出现遗漏的现象,如图3(b)所示。本文采用的3个扩张卷积的扩张率分别为 $Dilation\ rate = (2, 4, 8)$ 。

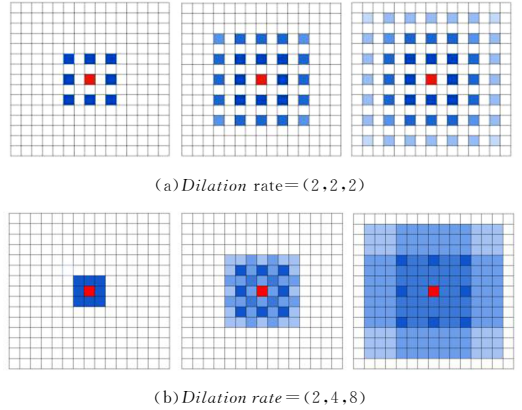


图3 扩张率卷积图示

Fig. 3 Diagram of expansion rate

2.2 判别模型

判别模型作为一个分类器,通过提取图像特征对图像进行判别分类。判别模型的输入为原始图像和修复后的图像,输出为隐藏层的激活值与真假判别的概率值。对于分类器而言,神经网络的隐藏层能够将图像从像素空间映射到高级特征空间,提供有意义的缺失区域的高级特征,进而优化模型性能。本文通过提取判别模型隐藏层上修复图片和真实图片的隐藏层的激活值并计算两者之间的差异,来激励生成模型生成高清的、细节更加丰富的修复效果图。壁画作为一种艺术表现形式,线描和程式化颜色表现出的结构特征明显。判别模型利用网络中的4层隐藏层提取原始图片与生成图片的高频特征损失信息,并将特征图的误差作为对抗感知损失,以最大程度地保留全局结构特征;通过感知损失对生成模型进行反馈训练,感知损失较大时表示生成模型在生成图片高频纹理信息上效果较差,此时生成模型将通过调整参数来进一步优化网络。

判别模型的网络结构与生成模型类似,由卷积层-标准化层-激活函数构成。卷积层的卷积核大小为 3×3 ,采用步长为1的卷积核来获取尽量多的特征,使用步长为2的卷积核来减小矩阵的尺寸,降低维度,从而代替池化层操作。判别模型的网络结构如图4所示。

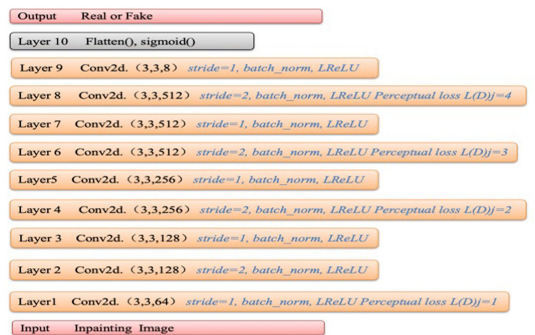


图4 判别模型的网络结构

Fig. 4 Network structure of discriminant model

2.3 修复框架

假设用 I_{gr} 表示原始状态下的图像, 训练过程中 I_m 为随机蒙版图像, 真实场景时 I_m 为指定破损壁画蒙版图像。对成对存在的原图 I_{gr} 和遮罩图像 I_m 进行像素之间的点乘运算, 得到的带蒙版的图像即为生成网络的输入图像, 网络的输出为修复后的图像。判别网络通过提取输入图片的特征, 并对特征进行分类, 指导生成网络修复图像。最终修复的图像用 I' 表示, 则 I_{gr} 与 I' 之间的关系式如式(2)所示:

$$I' = I_{gr} \otimes (1 - I_m) + G(I_{gr} \otimes (1 - I_m)) \otimes I_m \quad (2)$$

其中, \otimes 表示像素点乘, $I_{gr} \otimes (1 - I_m)$ 表示图片的完整区域, $G(I_{gr} \otimes (1 - I_m)) \otimes I_m$ 表示将经过修复模型的壁画修复区域; 将两部分按位融合, I' 为最终的修复完成的图片。

3 损失函数

3.1 WGAN 损失

破损壁画重建算法使用语义上合理的内容来渲染缺失区域的像素, 采用上下文编码器的形式来训练生成模型, 使其能够预测破损区域图像。由于原始 GAN 在训练过程中生成的数据分布与真实的数据分布不重合或部分重合, 因此 GAN 在训练过程中会出现梯度消失、生成模型无法继续优化、损失函数收敛缓慢等情况。

在生成模型与判别模型的两个分布没有重合的情形下, GAN 判别模型趋于最优, 生成模型的梯度将接近于 0, GAN 无法对生成模型进行指导。为了避免训练过程中出现模型崩溃或者判别模型在最优情况下无法继续指导生成模型优化的问题, 本文采用 Wasserstein^[27] 距离表示生成分布与真实分布之间的距离, 以此提高网络的稳定性。

通过将 Wasserstein 距离转换成网络模型的损失函数, 使得网络的损失函数可以生成平滑且有意义的梯度值。

$$L = E_{X \sim p_r} [f_w(x)] - E_{X \sim p_g} [f_w(x)] \quad (3)$$

其中, f_w 函数代表每次迭代更新判别模型后将其绝对值 ω 限制在固定常数 c 之内, 即 $\omega_i \in [-c, c]$ 。此时, L 会接近真实分布与生成分布之间的 Wasserstein 距离。Wasserstein 距离避免了生成模型梯度消失问题, 由 L 可分离出两个损失:

$$L_g = -E_{x \sim p_g} [f_w(x)] \quad (4)$$

$$L_d = -E_{x \sim p_r} [f_w(x)] + E_{x \sim p_g} [f_w(x)] \quad (5)$$

其中, 式(5)指导训练过程, 其数值越大, 表示生成模型的分布与真实分布的 Wasserstein 距离越小, GAN 的训练效果越好。

本文生成网络损失函数与判别网络损失函数分别如式(6)、式(7)所示:

$$L_{wgan}(G) = -E_{I_g} [D(I_g)] \quad (6)$$

$$L_{wgan}(D) = E_{I_g} [D(I_g)] - E_{I_{gr}} [D(I_{gr})] \quad (7)$$

其中, I_g 表示生成模型生成的图像, I_{gr} 表示原始图像。对于判别模型, 当输入是生成模型生成的图片时, 其期望输出值较小; 当输入是原始图片时, 其期望输出值较大。对于生成模型, 其输出的生成图片经过判别模型的输出数值越大越好。

3.2 重建损失

距离损失函数用来训练生成模型, 使其具有预测破损区域图像的能力。 L_1 是对像素进行差异计算, 通过绝对值来避免正值与负值相互抵消的问题。 L_2 距离为二阶范数, 可放大

较小误差与较大误差之间的距离, 具有更大的惩罚力度, 且对较小误差更为容忍。因此本文使用 L_2 损失即欧氏距离作为损失函数, 重建损失函数如式(8)所示:

$$L_{recon}(I_{gr}) = \| I_m \otimes (I_{gr} - G((1 - I_m) \otimes I_{gr})) \|_2^2 \quad (8)$$

其中, I_{gr} 表示原始图像, I_m 表示遮罩图像, I_g 表示修复模型生成的图像, \otimes 表示像素点乘, $I_m \otimes (I_{gr} - G((1 - I_m) \otimes I_{gr}))$ 表示生成图像与原始图像在生成区域的像素间差异。重建损失函数 L_{recon} 对最终判别模型的输出结果进行判断, 激励生成模型预测对象的轮廓。由于计算像素之间的距离惩罚模型会丢失图像高频信息, 导致图像模糊, 因此需要进一步提高模型感知图像细节的能力。

3.3 感知损失

WGAN 损失与 L_2 损失具备了预测图像破损区域的能力, 但是在生成细节纹理方面表现不佳, 修复后的像素块仍旧模糊不清, 不能很好地还原敦煌壁画的原貌。为了提升生成模型的性能和提高其修复高频纹理特征的能力, 加强修复图像的真实感, 本文添加了感知损失函数来捕获图像的高频纹理信息, 通过衡量生成模型的输出图片与真实图片在高级特征上的相似程度来促使生成模型进一步优化, 激励生成模型生成较高质量的图像结果。当感知损失较大时, 表示生成模型在生成高频纹理信息上效果较差。感知损失通过计算判别网络隐藏层之间的特征差异, 来衡量生成图像与真实图像的高级特征之间的区别。通过感知损失对生成模型进行反馈训练, 提取判别模型中隐藏层上修复图像和真实图像的隐藏层的激活值, 调整生成模型参数来进一步优化网络, 计算两者之间的差异来激励生成模型生成高清的、细节更加丰富的修复效果图。感知损失为:

$$L_{perc}(G) = \sum_{j=1} \lambda^j \| D^j(I_{gr}) - D^j(I_g) \| \quad (9)$$

$$L_{perc}(D) = \max(0, m - \sum_{j=1} \lambda^j \| D^j(I_{gr}) - D^j(I_g) \|) \quad (10)$$

其中, $L_{perc}(G)$ 为生成模型的感知损失函数, $L_{perc}(D)$ 为训练判别模型隐藏层的感知损失函数。通过激励 $L_{perc}(G)$ 感知损失函数趋于最小化来不断优化生成模型, 使其生成的图片的高频特征近似于真实图片的高频特征。 $D^j(\cdot)$ 表示判别模型第 j 层隐藏层的特征值, λ^j 表示第 j 层隐藏层的权重, m 表示判别网络的感知对抗损失的阈值。对于判别模型而言, 在第 j 层隐藏层上通过计算生成模型生成图片与真实图片特征图的差异, 来约束生成模型对图像高频信息的捕获。 $L_{perc}(G) < m$ 时(根据特征图大小, 本文实验中 m 取 3), 即表示生成模型生成高频纹理信息的能力不足, 生成模型会根据判别模型的指导进一步优化模型, 进而不断提高生成模型生成高频纹理细节的能力, 获得高精度的图片。

本文的联合损失函数为:

$$L(G) = L_{recon} + L_{wgan}(G) + L_{perc}(G) \quad (11)$$

$$L(D) = L_{wgan}(D) + L_{perc}(D) \quad (12)$$

4 实验与结果分析

4.1 数据集及数据预处理

壁画作为艺术文物, 具有特殊的艺术属性, 数据集具有收集难度大、数量少的特点, 因此利用数据增广扩大数据集、提高模型性能变得非常重要。数据增广使训练的数据集比实际

数据集多出了一定数量的新样本,减少了过拟合问题。如图5所示,实验采用了在原始图像(见图5(a))的基础上向左旋转 90° (见图5(b))、右旋转 90° (见图5(c))、任意位置截取(见图5(d))、任意位置截取并反转(见图5(e))以及图像加噪声(见图5(f))等数据增广方法。敦煌壁画有其独特的风格,其局部纹理细节丰富,样本的增广不是为了简单地增加样本数量,而是再现小样本量无法完全覆盖的真实样本,进而扩大样本多样性,提升模型性能。




图5 壁画图像数据增广

Fig. 5 Mural image data augmentation

使用增广后的40000张壁画图像作为训练数据,另外选取100张完好壁画图像与若干张遮罩图作为测试数据。本文采用文献[11]中提到的数据集作为遮罩数据集,该数据集中遮罩图片的面积大小不一,可使训练得到的模型适应各种输入大小的修复图片,符合破损壁画修复的要求。所有输入数据均为 128×128 大小。图6为部分训练数据示例、部分遮罩图片示意样式,以及经过遮罩处理的训练图像输入示意样式。




图6 实验数据图示

Fig. 6 Representation of experimental data

实验采用改进的各向异性扩散图像中的去噪方法^[28]对图像进行预处理。经过去噪处理的壁画图像质量有了较大的提升,为图像修复工作奠定了良好的基础。图7为壁画去噪前和去噪后的对比图。




图7 图像预处理(去噪)示意

Fig. 7 Schematic diagram of image preprocessing(denoising)

4.2 网络稳定性

实验硬件环境为 Nvidia Titan X GPU,16GB内存。软件环境为 Ubuntu16.04, Anaconda3, Tensorflow-gpu 1.5.0, CUDA8.0, cuDNN6.0。在训练集与遮罩数据集中抽取小批量 m 个样本进行训练,并构造带有遮罩的输入图像。经过遮罩的待修复图像输入生成网络后,将得到的生成图 I_g 与原始图像一起输入到判别模型中,计算判别模型的损失函数 $L(D)$,根据判别模型输出的结果值反向修改生成模型和判别模型的网络参数,通过不断迭代执行,使得网络最终收敛,完成修复。优化迭代算法采用 Adam 算法,图像的批处理参数 $batch_size$ 设置为 64,迭代次数设置为 64000,学习率设置为 0.0002,通过对数据及输入样本的不断学习训练,生成高质量的壁画图像。如图8所示,由于原始 GAN 训练不稳定,基于上下文编码器的网络在敦煌数据集上无法收敛,如图8(a)所示。从本文方法损失函数曲线(见图8(b))可以看出,改进的网络是收敛的。随着训练次数的不断增加, L_2 损失函数不断减小,如图8(c)所示,生成模型生成的图片质量越来越好,因此,生成模型呈逐渐递减的趋势,从而验证了本文提出的网络结构的稳定性。

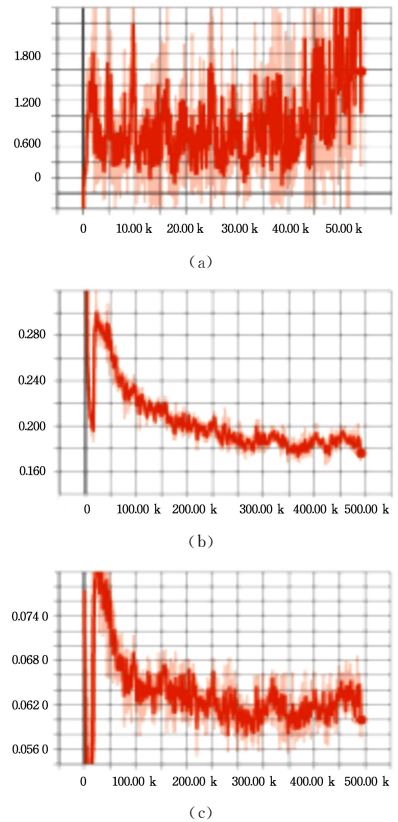


图8 损失函数曲线

Fig. 8 Loss function curve

4.3 实验结果

通过与文献[12,19-20]中的3种优秀方法进行对比,来验证所提方法的修复效果。在对比实验中,文献[12]中改进的 Criminisi 方法的实验环境为 Win7, MATLABR2013。文献[19]中基于全局和局部的图像修复方法的实验环境为 Ubuntu16, Tensorflow1.5.0, CUDA8.0, cuDNN6.0。文献[20]中 Shift-Net 的修复方法的实验环境为 Ubuntu16,

Pytorch, CUDA8.0, cuDNN6.0。其中 Tensorflow 与 Pytorch 环境通过 Anaconda3 的虚拟环境搭建,是两个独立的虚拟环境,避免了两种不同测试框架的软件版本及依赖库对结果的影响。

测试数据包含两类图像,一类为对自然状态下破损的壁画进行修复,如图 9(a)–图 9(c)所示;另一类为对人为破坏的壁画进行修复,如图 9(d)–图 9(f)所示。测试图像包含风景壁画和人物壁画。风景壁画纹理较为简单,人眼视觉感知对其修复结果容错较高。人物类壁画与风景壁画不同,画面内容线条较多,根据主观经验,人眼感知对修复后的壁画容错较低,故其修复要求较高。如图 9 所示,文献[12]根据优先级复制图像中的像素块来进行“粘贴式”修复,这种方式在修复大面积缺损图像时容易产生错误堆积现象,造成纹理错位,同时不能较好地预测破损处的颜色信息,导致出现修复颜色与周围完整区域颜色不一致的现象,修复效果达不到语义级别。文献[19]和文献[20]在修复大面积缺损图像时,对于结构感较强的图像,修复结果缺失高频纹理信息和细节,修复效果模糊。本文方法能够预测出破损处的纹理信息,有效地修复细节纹理,并且边缘处平滑,颜色过渡自然顺畅,与原图更为接近。从视觉感知层面上看,本文方法修复结果优于其他 3 种测试方法。

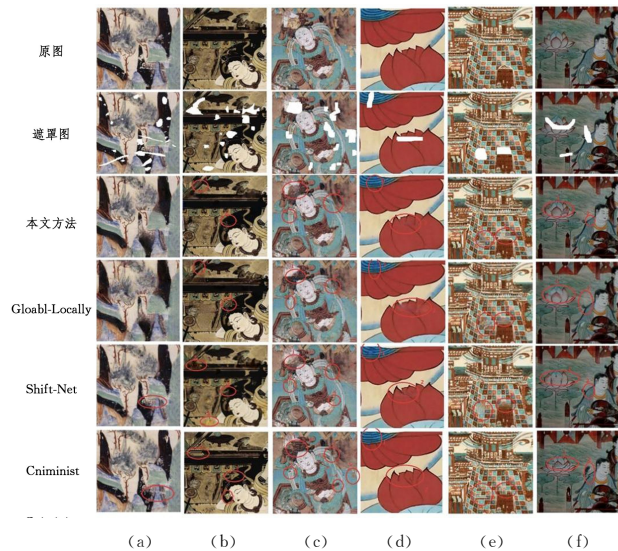


图 9 修复效果对比

Fig. 9 Comparison of repair effect

为了使评价更为客观,实验使用峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)作为评价指标对壁画修复质量进行评价,PSNR 的值越高,表示图像失真程度越小。同时使用结构相似性指标(Structural SIMilarity, SSIM)对修复后的壁画与自然状态下的壁画进行相似度评分,SSIM 评分越高表明两张图像越相似,修复的效果越好。实验结果如表 1 和表 2 所列。

表 1 不同算法 PSNR 的比较

Table 1 Comparison of PSNR of different algorithms

算法	a	b	c	d	e	f
算法 1 ^[19]	20.10	16.79	16.16	17.93	19.45	13.77
算法 2 ^[20]	17.52	16.18	16.15	16.94	19.56	13.23
算法 3 ^[12]	19.87	16.28	17.43	16.87	19.73	13.17
本文算法	20.24	17.92	19.63	18.20	20.13	15.26

表 2 不同算法 SSIM 的比较

Table 2 Comparison of SSIM of different algorithms

算法	a	b	c	d	e	f
算法 1 ^[19]	0.773	0.665	0.657	0.809	0.731	0.827
算法 2 ^[20]	0.543	0.605	0.636	0.823	0.736	0.752
算法 3 ^[12]	0.771	0.637	0.622	0.825	0.521	0.734
本文算法	0.777	0.665	0.677	0.831	0.736	0.875

从表 1 和表 2 可以看出,无论是自然破损壁画还是人为破损图像,本文算法的客观量化评分皆表现最优,修复效果最好。与文献[19]相比,单张图像的 PSNR 得分平均提高了 7.45%,SSIM 平均提高了 2.13%,其中,纹理较为丰富的人物壁画的 PSNR 评分提高了 12.99%,SSIM 评分提高了 3.85%。与文献[20]相比,单张 PSNR 评分平均提高了 12.24%,SSIM 评分平均提高了 12.79%,其中,人物壁画的 PSNR 评分提高了 15.85%,SSIM 评分提高了 10.9%。与文献[12]相比,单张 PSNR 评分平均提高了 8.38%,SSIM 评分平均提高了 12.53%,其中,人物壁画的 PSNR 评分提高了 12.85%,SSIM 评分提高了 10.81%。

此外,还利用不同算法对 100 张图片进行了测试并对整体质量进行了评价,结果如表 3 所列。

表 3 不同算法对 100 张图片的测试评分比较

Table 3 Test score comparison of 100 images with different algorithms

指标	PSNR	SSIM
算法 1 ^[19]	18.92	0.896
算法 2 ^[20]	18.07	0.732
算法 3 ^[12]	16.48	0.875
本文算法	19.26	0.965


可以看出,与文献[19]的方法相比,本文方法的 PSNR 得分提高了 1.79%,SSIM 得分提高了 7.7%;与文献[20]相比,PSNR 得分提高了 6.59%,SSIM 得分提高了 31.83%;与文献[12]相比,PSNR 得分提高了 16.87%,SSIM 得分提高了 10.29%。

综上所述,本文算法提高了壁画修复结果的准确度,修复后的壁画质量有一定的提升,修复结构的准确性表现最优,最大程度地还原了破损壁画的结构和纹理。

结束语 针对敦煌壁画数字保护过程中出现的问题,本文深入挖掘壁画艺术特征信息,构建了针对敦煌壁画的修复模型。为了避免训练过程中出现模型崩溃或者判别模型在最优情况下无法继续指导生成模型优化的问题,模型采用 Wasserstein 距离来提高网络的稳定性,同时将扩张卷积层作为中间过渡层,以收集更多的破损区域周围的信息。模型设计感知损失以捕获纹理高频细节,细化壁画高频纹理细节。实验结果显示,本文的修复结果优于现有方法,修复结果较其他方法更加准确,精度更高,效果更好。所提算法提高了敦煌壁画修复结果的准确度,无论是对墙皮脱落导致破损的壁画,还是对细小裂纹破损的壁画,都能进行有效的修复,具有一定的实际应用价值。针对敦煌壁画的高度密集个性化纹理图像修复研究,还需要继续完善网络结构,通过添加辅助条件的方式进一步指导网络的修复过程。

参 考 文 献

- [1] CHEN Y, AI Y P, GUO H G. Inpainting algorithm for dunhuang mural based on improved curvature-driven diffusion model[J]. *Journal of Computer-Aided Design & Computer Graphics*, 2020, 32(5): 787-796.
- [2] ZHANG Z Y, SHUI W Y, ZHOU M Q, et al. Research on disease extraction and inpainting algorithm of digital grotto murals [J]. *Application Research of Computers*, 2021, 38(8): 1-5.
- [3] BELHI A, BOURAS A, AL-ALI A K, et al. A machine learning framework for enhancing digital experiences in cultural heritage [J/OL]. *Journal of Enterprise Mnformation Management*. <https://doi.org/10.1108/JEIM-02-2020-0059>.
- [4] BERTALMIO M, SAPIRO G, CASELLES V, et al. Image inpainting [C]//*Proceedings of International Conference on Computer Graphics and Interactive Techniques*. New Orleans, Louisiana, USA, 2000: 417-424.
- [5] BERTALMIO M. Strong-continuation, contrast-invariant inpainting with a third order optimal PDE[J]. *IEEE Transaction on Image Processing*, 2006, 15(7): 1934-1938.
- [6] CHAN T F, SHEN J H. Non-texture inpainting by curvature-driven diffusions (CDD) [J]. *Journal of Visual Communication and Image Representation*, 2001, 12(4): 436-449.
- [7] CHAN R H, WEN Y W, YIP A M. A fast optimization transfer algorithm for image inpainting in wavelet domains [J]. *IEEE Transactions on Image Processing*, 2009, 18(7): 1467-1476.
- [8] DRORI I, COHEN-OR D, YESHURUN H. Fragment-based image completion [C]//*ACM SIGGRAPH*. 2003: 303-312.
- [9] CRIMINISI A, PEREZ P, TOYAMA K. Region filling and object removal by exemplar-based image inpainting [J]. *IEEE Transactions On Image Processing*. 2004, 13(9): 25-29.
- [10] XU Z, SUN J. Image inpainting by patch propagation using patch sparsity [J]. *IEEE Transactions on Image Processing*, 2010, 19(5): 1153-1165.
- [11] YANG X P, WANG S W. Dunhuang mural inpainting in intricate disrepaired region based on improvement of priority algorithm [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2011, 23(2): 284-289.
- [12] 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.
- [13] ZHAO L L, SHEN L, HONG R C. Survey on image inpainting research progress [J]. *Computer Science*, 2021, 48(3): 14-26.
- [14] KÖHLER R, SCHULER C, SCHÖLKOPF B, et al. Mask-specific inpainting with deep neural networks [C]//*German Conference on Pattern Recognition*. Cham: Springer, 2014: 523-534.
- [15] XIE J, XU L, CHEN E. Image denoising and inpainting with deep neural networks [C]//*Advances in Neural Information Processing Systems*. 2012: 341-349.
- [16] REN J S J, XU L, YAN Q, et al. Shepard convolutional neural networks [C]//*Advances in Neural Information Processing Systems*. 2015: 901-909.
- [17] PATHAK D, KRAHENBUHL P, DONAHUE J, et al. Context encoders: Feature learning by inpainting [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016: 2536-2544.
- [18] LI Y, LIU S, YANG J, et al. Generative face completion [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017: 3911-3919.
- [19] IIZUKA S, SIMO-SERRA E, ISHIKAWA H. Globally and locally consistent image completion [J]. *ACM Transactions on Graphics*. 2017, 36(4): 1-14.
- [20] YAN Z, LIX, LI M, et al. Shift-net: Image inpainting via deep feature rearrangement [C]//*Proceedings of the European Conference on Computer Vision*. 2018: 1-17.
- [21] RADFORD A, METZ L, CHINTALA S. Unsupervised Representation Learning With Deep Convolutional Generative Adversarial Networks [EB/OL]. <http://arxiv.org/abs/1511.06434>.
- [22] ZOU Z, ZHAO P, ZHAO X F. Automatic segmentation, inpainting, and classification of defective patterns on ancient architecture using multiple deep learning algorithms [J/OL]. *Structural Contural & Health Monitoring*. <https://doi.org/10.1002/stc.2742>.
- [23] GOODFELLOW I, POUGET-ABADIE J, MIRZA M. Generative Adversarial Networks [DB/OL]. <http://arxiv.org/abs/1406.2661>.
- [24] MIRZA M, OSINDERO S. Conditional Generative Adversarial Nets [DB/OL]. <http://arxiv.org/abs/1411.1784>.
- [25] DENTON E, CHINTALA S, SZLAM A, et al. Deep Generative Image Models using a Laplacian Pyramid of Adversarial Networks [DB/OL]. <http://arxiv.org/abs/506.05751>.
- [26] LEI L, GUO D E, JIN F. Image Inpainting Algorithm Based on Conditional Generative Adversarial Network with Spectral Normalization [J]. *Computer Engineering*, 2021, 47(1): 230-238.
- [27] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein gan [J]. *arXiv*: 1701.07875, 2017.
- [28] CHEN Y, GAO Y. Image denoising via iterative diffusion methods combining two edge-indicators with adaptive thresholds [J]. *Multimedia Tools and Applications*, 2021, 80(10): 16027-16044.



XU Hui, born in 1986, Ph.D, is a member of China Computer Federation. Her main research interests include image synthesis and digital conservation of cultural heritage.



ZHANG Jia-wan, born in 1975, professor, Ph.D supervisor, is a member of China Computer Federation. His main research interests include image synthesis, visualization and visual analysis.