

基于生成对抗网络的文物图像修复与评价

张馨瀚, 孙刘杰, 王文举, 李佳昕, 刘丽

(上海理工大学, 上海 200093)

摘要: **目的** 为了有效解决文物图像的不易保存和物理方法修复困难等问题, 提出一种基于生成对抗网络的图像修复算法。**方法** 文中算法主要分为2个阶段, 第1阶段通过Canny边缘检测器提取图像已知部分的边缘信息, 利用1个生成器和1个鉴别器修复图像缺失边缘。第2阶段将第1阶段生成的边缘作为先验信息, 通过1个生成器和2个鉴别器修复图像缺失部分。2个鉴别器由整体鉴别器和局部鉴别器组成, 整体鉴别器用来评估修复后的图像整体连贯性, 局部鉴别器用来查看待修复区域为中心的小区域局部一致性。**结果** 与传统算法对比, 文中算法在提高生成图片纹理质量的基础上保证了全局语义结构一致性, 在客观指标(峰值信噪比和结构相似性)上, 较其他方法有更好的效果。**结论** 文中算法可以有效修复文物图像的缺损部分, 尤其是结构复杂的大范围缺失, 取得了良好的视觉效果, 表明该算法有良好的修复性能。

关键词: 文物图像; 生成对抗网络; 修复; 评价

中图分类号: TP751.1 **文献标识码:** A **文章编号:** 1001-3563(2020)17-0237-07

DOI: 10.19554/j.cnki.1001-3563.2020.17.033

Repair and Evaluation of Cultural Relic Images Based on Generative Adversarial Network

ZHANG Qing-han, SUN Liu-jie, WANG Wen-ju, LI Jia-xin, LIU Li

(University of Shanghai for Science and Technology, Shanghai 200093, China)

ABSTRACT: The work aims to propose an image repair algorithm based on generative adversarial network, so as to effectively solve the difficulties in preserving cultural relic images and repairing them in physical method. The proposed algorithm was mainly divided into two stages. In the first stage, the edge information of the known part of the image was extracted by Canny edge detector, and a generator and a discriminator were used to repair the missing edges of the image. In the second stage, the edges generated in the first stage were taken as prior information, and the missing part of the image was repaired by one generator and two discriminators. The two discriminators consisted of a global discriminator and a local discriminator. The global discriminator was used to evaluate the overall coherence of the repaired image. The local discriminator was used to check the local consistency of a small area centered on the area to be repaired. Compared with the traditional algorithm, the proposed algorithm ensured the consistency of the global semantic structure by improving the quality of the generated image texture. In terms of objective indicators (peak signal-to-noise ratio and structural similarity), the results of the proposed algorithm were better than those of other methods. The algorithm proposed herein can

收稿日期: 2019-12-13

基金项目: 上海市科学技术委员会科研计划(18060502500)

作者简介: 张馨瀚(1996—), 男, 上海理工大学硕士生, 主攻数字图文信息处理。

通信作者: 王文举(1979—), 男, 博士, 上海理工大学讲师, 主要研究方向为多媒体与虚拟仿真技术、图形图像处理技术。

effectively repair the defective parts of cultural relic images, especially large-scale missing complex structures, and has achieved good visual effects, indicating that the algorithm has good repair performance.

KEY WORDS: cultural relic image; generative adversarial network; repair; evaluation

文物图像作为我国五千年文明的重要载体,其中包含大量的历史、文化、人文宝贵信息^[1]。由于自然风化以及人为破坏等原因使得文物图像保存难度较大,运用传统的物理修复方法不仅会对文物造成二次损伤,而且需要耗费大量的人力和物力^[2],运用数字图像修复技术能有效避免这些问题。图像修复技术的出现对于文物图像修复、保护、展示和相应文化传播都有着非凡意义。

传统图像修复方法大致可以分为以下2类。

1) 基于纹理合成的修复方法,将待修复区域周围的图像作为样本,从中提取特征并选取匹配的纹理,将其合成到待修复区域内^[3-4]。通过这种方法能有效修复纹理细节,但是对图像缺失区域中有意义的结构无法修复。

2) 基于源图像集合的补丁填充方法^[5],从相同图像或图像集合的相似区域,复制信息来填充缺失区域,以最大化补丁的相似性。问题在于,当图像和图像的集合与待修复区域相似性较低时,修复结果较差。

深度学习是目前的研究热点,广泛应用于图像处理领域。卷积神经网络^[6]在图像风格转换^[7]中的研究表明,一个良好的网络模型可以学习到更高层的语义信息(图像内容复杂背景下的内在联系,缺失对象与已知区域的结构一致性问题)^[8]。生成对抗网络^[9]通过对抗训练可以使生成图像更加真实。基于此研究背景,提出一个图像修复的深度学习方法-上下文编码器^[10],但是此对抗生成网络仅对修复区域内的图像判断真伪,使得修复区域与已知区域不能保证一致,最终产生模糊图像。基于语境注意的图像修复方法^[11]能改善图像修复结果。在修复信息复杂图像时,修复后图像与原已知部分存在语义鸿沟,虽然在局部上能有效保证修复区域与已知区域一致,但是整体修复更趋向于生成语义不连贯的图像。

文物图像对中国文化传承和研究具有重要意义,为了更好地修复文物图像,文中在上下文编码器^[10]的基础上提出一种基于生成对抗网络的图像修复方法,主要改进是在第2个生成对抗网络中添加1个局部鉴别器构成双鉴别器,重新构建损失函数,提高生成图像质量。文中算法实现是先通过1个生成器和1个鉴别器组成生成对抗网络来生成图像边缘部分。再将生成边缘部分作为先验信息与待修复图像一同输入到第2个生成对抗网络中,生成图像缺失部分。

1 理论基础

1.1 生成对抗网络

生成对抗网络来源于博弈论中的“零和博弈”,可看作2个博弈者,一个是生成器,另一个是鉴别器^[12-13]。生成器的工作是将1个输入的噪音 Z 或先验数据生成虚假图像。鉴别器的工作则是判断生成虚假图像的真伪,它的输入是一副图像 X ,输出数值代表 X 为真实图像的概率,若为1,则为真实图片,若为0,则为虚假图片。在训练过程中,生成器生成与真实图片相近的图片,使鉴别器识别生成图片为真实图片。相对的,鉴别器辨认生成图片为虚假图片。生成器和鉴别器构成一个动态博弈过程,最终达到纳什平衡。生成对抗网络流程见图1。




图1 生成对抗网络流程

Fig.1 Generative adversarial network flowchart

1.2 生成对抗网络的损失函数

生成对抗网络的总损失函数为:

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

式中: x 为真实图片, x 符合样本数据分布 $P_{\text{data}}(x)$; z 为噪声,通过 z 生成的图片符合数据分布 $P_z(z)$; $G(z)$ 指生成模型生成的虚假图片,而 $D(x)$ 和 $D(G(z))$ 为判断模型,判别图片真伪。式(1)中总损失函数实际是一个最优化问题,其包含2个优化过程。第1个过程是优化判别模型:

$$\max_D V(D, G) = E_{x \sim P_{\text{data}}(x)} [\log(D(x))] + E_{z \sim P_z(z)} [\log(1 - D(G(z)))] \quad (2)$$

式中： $D(x)$ 是判别模型的输出结果，是在区间(0,1)内的实数值，由 2 项组成，第 1 项为 $E_{x \sim P_{\text{data}}(x)}[\log(D(x))]$ ，目的是将真实图片 x 输入鉴别器中，并且输出的实数值要大；第 2 项为 $E_{z \sim P_z(z)}[\log(1 - D(G(z)))]$ ，将生成模型生成的虚假照片作为鉴别器的输入，鉴别器输出值要小，使第 2 项的输出值大。式(1)中第 2 个过程是优化生成模型：

$$\min_G V(D, G) = E_{z \sim P_z(z)}[\log(1 - D(G(z)))] \quad (3)$$

在优化生成模型时与真实图片无关，将生成模型所生成的虚假图片 $G(z)$ 输入到鉴别器，若鉴别器输出值较大，则虚假图片接近真实图片。将式(2)和式(3)结合即为生成对抗模型的总损失函数，见式(1)。

1.3 感知损失

生成对抗网络损失函数有效提高了修复缺失区域的纹理质量，但生成对抗网络对于结构信息的学习能力较差。在最初的图像修复方法中以 MSE 像素损失和生成对抗损失作为约束对网络进行训练，虽然结果有所优化，但是这样的约束无法确定高维纹理细节间的差距，使生成图像模糊^[14]。感知损失函数^[15]使用真实图片卷积得到的特征与生成图片卷积得到的特征作比较，使得修复的内容和全局结构更接近，这种方法比 MSE 像素损失函数更适合用来衡量图像之间的相似程度^[16]。感知损失函数由 2 部分组成，第 1 部分为特征重建损失，能有效学习高维特征信息，可定义为：

$$L_{\text{perc}} = \frac{1}{N_i} \|\phi_i(y_1) - \phi_i(y)\|_2^2 \quad (4)$$

式中： N_i 为第 i 层激活层的元素数量，通常给定 $C_i \times H_i \times W_i$ 的特征图，其中的元素共同构成 N_i ； ϕ_i 为预训练网络第 i 层的激活层； y 相当于输入图像； y_1 相当于网络生成图像。第 2 部分为风格损失，能有效提高修复区域的纹理质量，可定义为：

$$L_{\text{style}} = \|G_j^\phi(\hat{y}) - G_j^\phi(y)\|_F^2 \quad (5)$$

式中： F 为 Frobenius 范数； G_j^ϕ 为预训练网络 ϕ_i 构建的格拉姆矩阵； ϕ_i 为预训练网络第 i 层的激活层，其构建方式为：

$$G_j^\phi(x)_{c,c_1} = \frac{1}{C_j H_j W_j} \sum_{h=1}^{H_j} \sum_{w=1}^{W_j} \phi_j(x)_{h,w,c} \phi_j(x)_{h,w,c_1} \quad (6)$$

式中： $\phi_j(x)$ 为网络第 j 层，输入是 x ； $\phi_j(x)$ 理解成一个 C_j 维度的特征，每个特征的尺寸是 $H_j \times W_j$ ，则式(6)左边 $G_j^\phi(x)$ 与 C_j 维的非中心的协方差成比例，将每个网格位置当作一个独立样本。

2 算法实现过程

文中算法由 2 个阶段串联而成，2 个阶段共同完成图像的修复。第 1 阶段称为边缘生成网络，用于生成边缘图。第 2 阶段称为图像修复网络，用于生成修复图片，这 2 个阶段都应用了生成对抗网络。相较于传统的算法，文中算法额外添加了边缘生成网络，此网络生成的边缘图能有效提高图像修复的质量。

边缘生成网络由一个生成器网络 G_1 和一个鉴别器网络 D_1 组成。首先利用 canny 边缘检测算法提取图像边缘信息。将需要修复的图像的灰度图和 canny 边缘检测器提取的图像边缘信息输入生成网络 G_1 中，生成缺失部分的边缘线条。鉴别器网络 D_1 用来判断生成线条的真伪，即生成线条与原图线条的吻合程度。

图像修复网络由一个生成器网络 G_2 和 2 个鉴别器网络 D_2 、 D_3 组成。将边缘生成网络所生成的边缘图和需要修复的原图像一同输入图像生成网络的生成器 G_2 中，生成器 G_2 用来对图像缺少的部分进行补全，最终生成修复图片。鉴别器网络 D_2 和 D_3 用来判断修复后图片的真伪。

相比于传统的“生成对抗网络”算法，文中在图像修复网络中应用 2 个鉴别器 D_2 和 D_3 。鉴别器 D_2 为整体图像鉴别器，整体图像鉴别器主要评估修复后图像的整体连贯性。鉴别器 D_3 为部分图像鉴别器，部分图像鉴别器查看以完成区域为中心的小区域来确保所生成补丁的局部一致性。通过重新构建合理的损失函数，使得 2 个鉴别器能够确保生成的图片在总体以及细节上与真实图像相似度较高。算法流程见图 2，图 2 中上半部分为边缘生成网络，下半部分为图像修复网络，2 个部分串联构成了文中算法。




图 2 算法流程
Fig.2 Algorithm flow

2.1 边缘生成网络

首先输入一张完整图片 I ，对其进行预处理，通过遮掩部分图像生成缺失图片，缺失图片由 I_{gt} 表示。同时，缺失图片边缘图由 C_{gt} 表示，缺失图片灰度图由 I_g 表示。将缺失图片边缘图和灰度图输入生成器 G_1 ， G_1 生成缺失部分的边缘图 C_{pred} ：

$$C_{pred} = G_1(I_g, C_{gt}) \quad (7)$$

式中： C_{pred} 为鉴别器 D_1 的输入，该鉴别器判断边缘图 C_{pred} 真伪。边缘生成网络的训练目标包含对抗损失和特征重建损失，总损失式定义为：

$$\min_{G_1} \max_{D_1} L_{G_1} = \min_{G_1} (\alpha_{adv,1} \max_{D_1} (L_{adv,1}) + \alpha_{FM} L_{FM}) \quad (8)$$

式中： $\alpha_{adv,1}$ 和 α_{FM} 为正则化参数。其中，对抗损失表示为：

$$L_{adv,1} = E_{(C_{gt}, I_g)} [\log D_1(C_{gt}, I_g)] + E_{I_g} \log[1 - D_1(C_{pred}, I_g)] \quad (9)$$

特征重建损失表示为：

$$L_{FM} = E \left[\sum_{i=1}^F \frac{1}{N_i} \|D_1^i(C_{gt}) - D_1^i(C_{pred})\|_1 \right] \quad (10)$$

式中： F 为鉴别器的最终卷积层； N_i 为第 i 个激活层中的元素数； D_1^i 为鉴别器 D_1 第 i 层的权重矩阵。选取 $\alpha_{adv,1}=1$ ， $\alpha_{FM}=10$ 。生成器 G_1 由下采样 2 次的编码器、8 个尺寸相同的残差块和转置卷积上采样 2 次的解码器组成。鉴别器 D_1 是进行 5 层卷积后，使用折页损失函数计算图像真伪概率。

2.2 图像修复网络

将不完整图片 I_{gt} 和边缘图 C 作为图像修复网络的输入，边缘图 C 由实际边缘图和边缘生成网络生成的边缘图组成，其定义为：

$$C = C_{gt} + C_{pred} \quad (11)$$

图像修复网络返回颜色图像 I_{pred} ，填写缺失区域，其分辨率与输入图像相同，最终生成修复图片 I_{pred} ，其定义为：

$$I_{pred} = G_2(I_{gt}, C) \quad (12)$$

图像修复网络的整体图像鉴别器 D_2 对抗损失的定义与边缘生成网络的鉴别器 D_1 类似，表示为：

$$L_{adv,2} = E_{(I_{gt}, C)} [\log D_2(I_{gt}, C)] + E_C \log[1 - D_2(I_{pred}, C)] \quad (13)$$

对部分图像鉴别器 D_3 输入裁剪图片 I_{cq} ，定义为：

$$I_{cq} = Crop(I_{gt}, h) \quad (14)$$

得到裁切后的边缘图 C_{cq} 和图片预测图 $I_{pred, cq}$ ：

$$C_{cq} = Crop(C, h) \quad (15)$$

$$I_{pred, cq} = Crop(I_{pred}, h) \quad (16)$$

式中： h 为裁切的尺寸大小，部分图像鉴别器 D_3 的对抗损失见式 (17)。

$$L_{adv,3} = E_{(I_{cq}, C)} [\log D_2(I_{cq}, C_{cq})] + E_C \log[1 - D_2(I_{pred, cq}, C_{cq})] \quad (17)$$

图像修复网络的特征重建损失表示为：

$$L_{perc} = E \left[\sum_i \frac{1}{N_i} \|\phi_i(I_{gt}) - \phi_i(I_{pred})\|_1 \right] \quad (18)$$

式中： ϕ_i 为预训练网络的第 i 层的激活层。 ϕ_i 对应 VGG-19 网络在 ImageNet 上预训练的 relu1, relu2, relu3 层的激活层。即样式损失见式 (19)。

$$L_{style} = E_j \left[\|G_j^\phi(I_{pred}) - G_j^\phi(I_{gt})\|_1 \right] \quad (19)$$

图像修复网络的整体损失函数为：

$$L_{G_2} = \alpha(\alpha_{adv,2} L_{adv,2} + \alpha_{adv,3} L_{adv,3}) + \alpha_p L_{perc} + \alpha_s L_{style} \quad (20)$$

生成器 G_2 和边缘修复阶段的生成器 G_1 相同，由下采样 2 次的编码器经过 8 个尺寸相同的残差块最后由转置卷积上采样 2 次的解码器组成。鉴别器 D_2 和鉴别器 D_3 进行 5 层卷积后，没有制作额外的全连接层将全局和局部鉴别器的输出耦合在一起，而是分别使用折页损失函数作为损失函数得出图片鉴别的真伪概率，设置参数 $\alpha_{adv,2}=0.8$ ， $\alpha_{adv,3}=0.2$ ，使对抗损失函数的值在合理范围中。裁切图片尺寸 h 为 128×128 ，式中 $\alpha=0.1$ ， $\alpha_p=0.1$ ， $\alpha_s=250$ 。

2.3 网络参数和数据集的选择

文中实验硬件环境是 Dell 台式电脑，主要配置为 NVIDIA Quard T4000 GPU 和 8 GB 显存，操作系统为 Windows 10 系统 (64) 位，仿真实验平台为 Pytorch1.1。使用批量大小为 4 的 256×256 的图像进行训练。选取 places2 的子数据集 places365 中的 30 万张图像作为训练样本。模型选择 Adam 优化器优化，学习率大小为 0.0001，在网络总计迭代 30 万次停止训练。

3 实验及结果分析

为了验证文中算法的有效性，选择来自文献[17]的算法 GLCIC 和文献[11]的算法 CA 同文中算法进行对比实验，此 2 种算法同属于“生成对抗网络”。选取《雅典文学》中的 2 张局部图，图像尺寸为 256×256 。如图 3a 中的 2 幅原图所示，图像本身完整，并不存在自身缺失。首先，对图像进行预处理，通过生成随机掩码对原图进行标记处理，制作标记图片。然后用 GLCIC 算法、CA 算法和文中算法对标记图片进行处理，并通过主观和客观的角度对处理结果进行评价。主观评测邀请 10 名评估者对实验结果进行评测，评估者视力正常，且有一定的图像识别的知识。要求评估者从主观角度对比评估 3 个算法的优劣。

图 3 中 GLCIC 算法处理结果表明，第 1 幅图的腿和手部、第 2 幅图的衣服上修复结果中出现了明显错误的内容填充。这是由于 GLCIC 算法采用不恰当的损失函数造成的。对此，GLCIC 算法额外使用泊松图像融合的后处理方法进行解决。这样的改进依




图 3 自身完整图像的不同算法处理结果
Fig.3 Different algorithm processing results of its own complete image

然无法保证修复结果不出现错误，由图 3 可见通过 GLCIC 算法处理的 2 幅图都出现了模糊伪影。相比于 GLCIC 算法，CA 算法采用一个后续改进网络来重新定义原始网络的预测值，保证了修复图像的语义连贯性，但是受限于网络本身的学习能力较差，修复结果的纹理质量并没有太大的提升。通过 CA 算法处理的 2 幅图都出现了虚影。文中算法处理后的 2 幅图片与原图具有良好的视觉一致性，纹理修复质量较高。对于自身完整图像的不同算法处理结果客观质量评价结果见表 1。

表 1 自身完整图像的不同算法处理结果
Tab.1 Different algorithm processing results of its own complete image

算法	第 1 幅图		第 2 幅图	
	峰值信噪比	结构相似性	峰值信噪比	结构相似性
GLCIC 算法	24.5262	0.9024	19.6702	0.8037
CA 算法	24.4656	0.8956	20.6706	0.8623
文中算法	30.0395	0.9716	28.1373	0.9571

由表 1 可以看出，GLCIC 算法和 CA 算法都有一定的修复效果，与 GLCIC 算法和 CA 算法相比，文中算法修复结果较好。文中算法峰值信噪比最高，说明修复图像清晰度高、质量好、失真小。结构相似性有所提升，说明了文中算法修复结果与原图最接近，修复结果较好。

为了进一步验证文算法效果。随机选取《雅典文学》不同位置，尺寸大小为 256×256 的局部图共计 10 张进行对比实验，对 GLCIC 算法、CA 算法和文中算法处理后的图像进行客观质量评价。峰值信噪比值为 0~100，结构相似性的值为 0~1，2 幅图像越相似，峰值信噪比和结构相似性值越大^[18]。峰值信噪比数据见图 4，结构相似性数据见图 5。通过图 4 和图 5 的实验数据对比可以看出，文中算法相对于传统

算法，修复图像质量有所提升，修复结果较好。




图 4 不同算法处理结果的峰值信噪比
Fig.4 Peak signal-to-noise ratio of processing results of different algorithms




图 5 不同算法处理结果结构相似性
Fig.5 Structural similarity of processing results of different algorithms

为了验证文中算法可以应用于实际中的文物图像修复，选取来自敦煌莫高窟的壁画且本身有部分缺失的图片，见图 6a，图像尺寸为 256×256。




图 6 自身缺失图像的不同算法处理结果
Fig.6 Processing results of different algorithms for self-missing images

图 6 中 2 张原图由于自然风化以及人为破坏等原因,第 1 幅图片出现裂痕、模糊,而第 2 幅图像出现裂痕和大量内容缺失。首先对 2 幅图片进行预处理,对第 1 幅图中的裂痕和模糊部分,第 2 幅图中大面积缺失用掩码进行标记,制作相应的标记图片,然后用 GLCIC 算法、CA 算法和文中算法对标记图片进行处理。对于自身缺失图像的不同算法处理结果客观质量评价结果见表 2。

表 2 自身缺失图像的不同算法处理结果
Tab.2 Processing results of different algorithms for self-missing images

算法	第 1 幅图		第 2 幅图	
	峰值信噪比	结构相似性	峰值信噪比	结构相似性
GLCIC 算法	26.4730	0.9570	22.3093	0.9167
CA 算法	29.7448	0.9713	23.4498	0.9217
文中算法	30.8356	0.9742	25.6583	0.9470

由图 6 中 GLCIC 算法、CA 算法和文中算法的处理结果可以看出,对于裂痕和模糊部分 GLCIC 算法修复的纹理有较多不合理的地方。这是由于待修复区域前景和背景重叠且界限不明显, GLCIC 算法无法合理分离待修复区别的前景和背景界限,这造成网络填充得不准确。对于第 2 幅图中的大面积缺失, GLCIC 算法能保证修复图像的部分语义完整性,但图中莲花部分依然出现不合理的填充和颜色差异,而 CA 算法网络学习能力较为一般,修复结果的纹理质量不佳,处理第 1 幅图中裂痕和模糊虽然没有出现明显错误,但是生成结果中存在结构不连贯性。对于大面积缺失部分,CA 算法相较于 GLCIC 算法能保证修复结果有一定的语义连贯性和较小的颜色差异,却仍然生成了部分边界伪影。GLCIC 算法和 CA 算法都是将卷积神经网络训练为一种端到端的映射函数,这种

映射函数可以将损坏的图像修复为完整的图像。这 2 种基于生成对抗网络的修复方法过度依赖已知区域的像素值和待修复区域内的替代值,这会导致修复结果产生不正确的虚影和模糊。文中所使用的边缘生成网络能通过生成边缘图,将待修复区域的高频和低频信息进行有效的分离,解决了模糊和虚影。由图 6 可见,文中算法对于裂痕和模糊处理的效果较好,不仅使修复后纹理细节的更为逼真,而且保证了修复图像的语义连贯性。对于第 2 幅图中大面积缺失,文中算法使修复结果的整体语义更为合理。与传统算法相比,文中算法在实际的文物图像中具有良好的修复效果。由表 2 可以看出,文中算法峰值信噪比和结构相似性都取得了最高值,说明文中算法的修复效果更好。

4 结语

为了解决文物图像的不易保存和物理方法修复困难等问题,在生成对抗网络的基础上提出了一种改进算法——基于生成对抗网络的图像修复算法。此算法首先利用 1 个生成器和 1 个鉴别器先修复图像缺失的边缘部分,然后通过 1 个生成器和 2 个鉴别器修复图像缺失部分的所有信息。算法实验结果表明,文中算法在峰值信噪比和结构相似性等指标上都有所提高。文中算法在图像修复中有较好的适用性,对于图像去噪和图像风格转化也有一定的参考意义。

参考文献:

- [1] 韩长明. 应用于古文物的数字图像修复方法研究[D]. 长春: 吉林大学, 2019: 1—2.
HAN Chang-ming. Research on Digital Image Restoration Methods Applied to Ancient Cultural Relics[D]. Changchun: Jilin University, 2019: 1—2.
- [2] 贾蕊, 王慧琴, 吴萌. 基于内容自适应的唐墓室壁画修

- 复算法[J]. 计算机工程与应用, 2015, 51(11): 179—181.
- JIA Rui, WANG Hui-qin, WU Meng. Content-adaptive Mural Restoration Algorithm of Tang Tomb[J]. Computer Engineering and Applications, 2015, 51(11): 179—181.
- [3] CRIMINISI A, PATRICK P, TOYAMA K. Object Removal by Exemplar-based Inpainting[C]// 2003 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR 2003), 2003: 721—728.
- [4] 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): 1200—1212.
- [5] HUANG J B, KANG S B, AHUJA N, et al. Image Completion Using Planar Structure Guidance[J]. ACM Transactions on Graphics, 2014, 33(4): 1—10.
- [6] ZHANG Q, ZHANG M, CHEN T, et al. Recent Advances in Convolutional Neural Network Acceleration[J]. Neurocomputing, 2019(323): 37—51.
- [7] GATYS L A, ECKER A S, BETHGE M. Image Style Transfer Using Convolutional Neural Networks[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 2414—2423.
- [8] 强振平, 何丽波, 陈旭, 等. 深度学习图像修复方法综述[J]. 中国图象图形学报, 2019, 24(3): 447—463.
- QIANG Zhen-ping, HE Li-bo, CHEN Xu, et al. Review of Deep Learning Image Repair Methods[J]. Journal of Image and Graphics, 2019, 24(3): 447—463.
- [9] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative Adversarial Nets[C]// International Conference on Neural Information Processing Systems, 2014: 2672—2680.
- [10] PATHAK D, KRAHENBUHL P, DONAHUE J, et al. Context Encoders: Feature Learning by Inpainting[J]. IEEE International Conference on Computer Vision (CVPR), 2016, 1(1): 2536—2544.
- [11] YU J, LIN Z, YANG J, et al. Generative Image Inpainting with Contextual Attention[J]. IEEE International Conference on Computer Vision (CVPR), 2018, 1(1): 5505—5514.
- [12] MIYATO T, KATAOKA T, KOYAMA M, et al. Spectral Normalization for Generative Adversarial Networks[J]. ICLR, 2018, 1(2): 1—14.
- [13] MAO X, LI Q, XIE H, et al. Least Squares Generative Adversarial Networks[J]. ICCV, 2017, 5(36): 2813—2821.
- [14] GATYS L A, ECKER A S, BETHGE M. Image Style Transfer Using Convolutional Neural Networks[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 2414—2423.
- [15] JOHNSON J, ALAHI A, FEI-FEI L. Perceptual Losses for Real-time Style Transfer and Super-resolution[J]. European Conference on Computer Vision(ECCV), 2016, 1(2): 694—711.
- [16] SAJJADI M S M, SCHOLKOPF B, HIRSCH M. EnhanceNet: Single Image Super-Resolution Through Automated Texture Synthesis[C]// 2017 IEEE International Conference on Computer Vision (ICCV), 2017: 4501—4510.
- [17] IIZUKA S, SIMO-SERRA E, ISHIKAWA H. Globally and Locally Consistent Image Completion[J]. ACM Transactions on Graphics, 2017, 36(4): 1—14.
- [18] 王晓红, 刘芳, 麻祥才. 基于深度残差学习的彩色图像去噪研究[J]. 包装工程, 2019, 40(17): 235—242.
- WANG Xiao-hong, LIU Fang, MA Xiang-cai. Research on Color Image Denoising Based on Deep Residual Learning[J]. Packaging Engineering, 2019, 40(17): 235—242.