

并行生成卷积网络图像修复算法*

李海燕¹, 晁艳静¹, 李海江², 郭磊¹, 李红松¹

(1. 云南大学 信息学院, 云南 昆明 650504; 2. 云南交通投资建设集团有限公司(云南交投), 云南 昆明 650228)

摘要:为解决修复纹理精细、背景复杂图像中大面积不连续语义缺失时存在的边缘伪影和语义不连续的缺陷,提出一种并行生成卷积的残差连接图像修复算法。将残缺图像输入一个两列平行卷积的结构修复网络得到两个具有不同感受野大小的图像分量,通过共享解码合并两个图像分量并计算输出的L2损失优化网络。将结构修复网络的输出送入包含残差连接与注意力机制的细节修复网络,融合上下文信息,改善修复细节能力。使用全局与局部鉴别器和预训练视觉几何组网络计算损失,对修复网络进行整体判别优化,增强修复结果的整体与局部一致性。在国际公认数据库上验证提出算法的性能,实验结果表明:提出算法可以有效修复复杂背景且包含精细纹理的大面积不规则缺失区域,提升图像细节、语义和结构的真实性与完整性,其峰值信噪比和结构相似度优于经典的对比算法。

关键词:图像修复;并行生成卷积;残差连接;注意力机制;门控卷积

中图分类号:TP391.4 文献标志码:A 开放科学(资源服务)标识码(OSID):

文章编号:1001-2486(2023)03-127-09



听语音
与作者互动
聊科研

Algorithm on image restoration of parallel generation convolution network

LI Haiyan¹, CHAO Yanjing¹, LI Haijiang², GUO Lei¹, LI Hongsong¹

(1. School of Information Science and Engineering, Yunnan University, Kunming 650504, China;

2. Yunnan Communications Investment and Construction Group Co., Ltd., Kunming 650228, China)

Abstract: In order to solve the defects of edge artifacts and semantic discontinuity when inpainting large and irregular distortions in an image with fine texture and complex background, a residual connection image restoration algorithm based on parallel generation convolution was proposed. The damaged image was inputted into a two-column parallel convolutional structure inpainting network to obtain two image components with different sizes of reception fields. The two image components were combined by the shared decoding and the L2 loss of the output was calculated to optimize the network. The output of the coarse network was sent into the fine inpainting network which contained the residual connection and the attention mechanism to fuse context information and improve the ability of repairing fine details. The global and local discriminators and visual geometry group net were used to calculate the loss and to optimize the overall discrimination network and enhance the global and local consistency of the inpainting result. The performance of the proposed algorithm was validated on internationally recognized databases, and experimental results show that the proposed algorithm can effectively repair large and irregular missing areas under complex background and fine texture, improve the authenticity and integrity of image details, semantics and structure. Its peak signal-to-noise ratio and structural similarity are superior to the state-of-the-art.

Keywords: image inpainting; parallel generation convolution; residual connection; attention mechanism; gated convolution

图像修复用相似像素填充图像中缺失区域,生成内容合理的图像。现有的图像修复方法主要有两类:传统的修复算法和基于神经网络的修复算法。

基于扩散的方法^[1-6]是经典的传统修复算法,这类方法将已知的相似像素传播到缺失区域,仅能修复小面积缺失。Bertalmio等^[5]提出同时

填充纹理和结构的修复算法,将图像表达为两个函数之和再分别重构每个函数,能修复细小划痕,但是当缺失面积大时,此方法只能修复缺失区域边缘,无法修复其内部。Criminisi等^[6]提出一种基于块的纹理合成算法,首先计算填充区域的优先权,然后传播纹理及结构信息并更新置信度完成修复。由于缺乏对图像的高级理解,该方法通

* 收稿日期:2021-06-29

基金项目:国家自然科学基金资助项目(62066046,81771928);云南省基础研究计划重点资助项目(202101AS070031)

作者简介:李海燕(1976—),女,云南昆明人,教授,博士,博士生导师,E-mail:leehy@ynu.edu.cn;

郭磊(通信作者),男,云南昆明人,高级实验师,硕士,E-mail:guolei@ynu.edu.cn

常无法生成语义合理的结果和已知图像中不存在的结构,当缺失内容包含丰富纹理时,生成细节的能力不足。

为了克服传统修复算法的局限性,近年来学者们提出了许多基于深度学习的修复方法^[7-17]。Xie 等^[7]提出结合稀疏编码和神经网络的修复算法,该方法只能用于灰度图的小区域修复。Iizuka 等^[8]提出兼顾全局和局部一致性的全卷积修复网络,改善了图像的细节,可修复含多个小区域缺失的图像,但很难修复大面积语义缺失。为更好修复大面积缺失,两阶段修复模型逐渐兴起。Yu 等^[9]提出在细修复网络中嵌入上下文注意模块,增加生成内容与周围颜色和纹理的一致性判别,该方法可以修复大面积语义缺失,但图像包含复杂背景时,难以修复纹理细节。Nazeri 等^[10]提出结合边缘结构与对抗网络的两阶段修复模型,先训练出可能的边缘图,然后将其作为先验条件生成内部纹理。此方法可以产生较好的纹理细节,但是当图像存在大面积语义缺失时,修复的结构不合理。Xiong 等^[11]提出前景感知修复算法,以两阶段对抗模型为基础,预测前景轮廓作为修复先验,虽然能完成大孔洞修复,但较难生成精细的纹理细节,且修复结果包含模糊结构或错误纹理。文献^[12]提出基于混合空洞卷积网络的两阶段多鉴别器修复算法,使用平行路径网络提高修复精度,并用多个鉴别器增强图像的全局结构,但修复大面积且包含多处不连续缺失时,会出现纹理细节模糊。Peng 等^[13]提出第一阶段学习结构特征分布,为缺失图像生成多样性结构的两阶段修复算法,提高了生成图像的视觉质量,修复的结构一致性较好,但无法生成精细的细节纹理。此外,单阶段修复模型也有许多改进,Wang 等^[14]提出多列卷积的修复算法,修复大面积与多个不连续缺失时的整体效果较好,但修复边缘细节能力不足。Xie 等^[15]改进了多列卷积,有效去除修复模糊,但修复大面积缺失时得到的结构不连续。Zheng 等^[16]提出连接平行路径的方法,一条路径获得缺失图像的部分先验分布,另一条路径利用分布重建图像,但是该方法在修复多处不连续缺失时,会出现结构扭曲及伪影。Liu 等^[17]提出空间概率多样性归一化和感知多样性损失,在缺失区域生成逼真的视觉效果,但存在修复纹理细节不足的缺陷。

综上所述,现有算法在修复背景和纹理精细且存在多处不连续缺失区域时,会出现结构不一致、无法生成合理的纹理细节(包含边缘伪影或

细节模糊)等问题。针对这些不足,本文提出基于并行生成卷积的残差连接图像修复算法,有效修复大面积且包含多处不连续的缺失区域。提出算法的主要创新点在于:①提出基于多尺度卷积、残差连接与注意力机制的两阶段修复网络架构,使用两列卷积平行生成模型修复缺失区域的合理结构,并行捕获多尺度细节信息,增加修复结果的结构相似性。②提出残差连接与注意力机制融合方法,提高结构和内容的精度,生成精细纹理。③使用光谱归一化马尔可夫鉴别器 SN-PatchGAN 和预训练视觉几何组 (visual geometry group, VGG) 网络提取特征并计算损失,对细节网络的输出进行判别优化,增强修复结果的整体与局部一致性,改善修复质量。

1 算法整体框架

本文提出一种融合多尺度卷积、残差连接与注意力机制的两阶段图像修复算法,算法整体框架如图 1 所示。

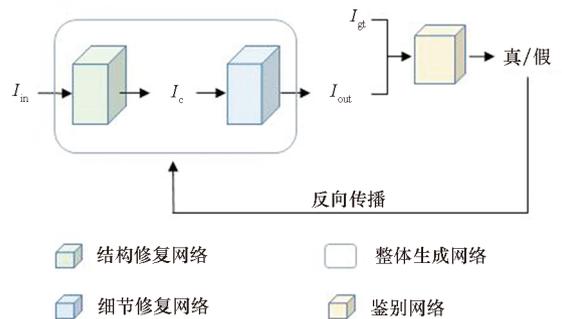


图 1 提出网络的整体算法结构

Fig. 1 Overall network structure of the proposed algorithm

I_{in} 、 I_c 、 I_{out} 和 I_{gt} 分别为有破损的输入图像、结构修复网络的输出、整体生成网络的输出和真实图像。待修复图像经过生成网络输出后与真实图像一起送入鉴别网络进行对抗鉴别,鉴别器计算鉴别损失后反馈优化生成网络。与现有两阶段修复网络相比,提出修复网络的创新点在于:结构修复网络使用并行生成卷积,并引入门控卷积和膨胀因子,使用结构重建损失优化结构修复网络。在细节修复网络中引入跳跃残差连接和注意力机制,并设计其融合机制,生成清晰纹理。

1.1 结构修复网络

为避免现有两阶段修复网络中生成图像结构扭曲的不足,提出使用并行卷积网络进行合理的结构修复,它包括两个并行的编-解码器分支以及一个共享的解码模块,分别用于从含掩码 M 的

输入中提取不同尺度的特征和将深层特征转换到自然空间。两个并行分支使用不同卷积核大小对图像进行编解码,感受不同尺度的信息和空间分辨率。为了扩大信息感受野,提出算法使用空洞卷积^[12]代替普通卷积。结构修复网络如图2所示,编解码器均包括9个门控卷积层、4个扩张卷积层和2个反卷积层,使用两层门控卷积作为共享解码模块进行信息融合。将缺失图像输入并行网络,使用xavier初始训练^[18]。最后的卷积层使用Tanh激活函数外,其他层使用 $\alpha = 0.2$ 的

LeakyReLU激活函数,采用组归一化^[19]方式。共享解码后得到结构修复结果。若并行网络分支表示为 f_i ,共享解码模块表示为 F ,则结构修复网络输出结果 I_c 的计算如下:

$$I_c = F\left(\sum_{i=1}^2 f_i(I_{in})\right) \quad (1)$$

其中, $I_{in} = I_{gt} \odot (1 - M)$ 。为保证生成结构的合理性,使用结构重建损失训练网络,损失函数表示为:

$$L_c = \|(I_c - I_{gt}) \odot M\|_1 \quad (2)$$

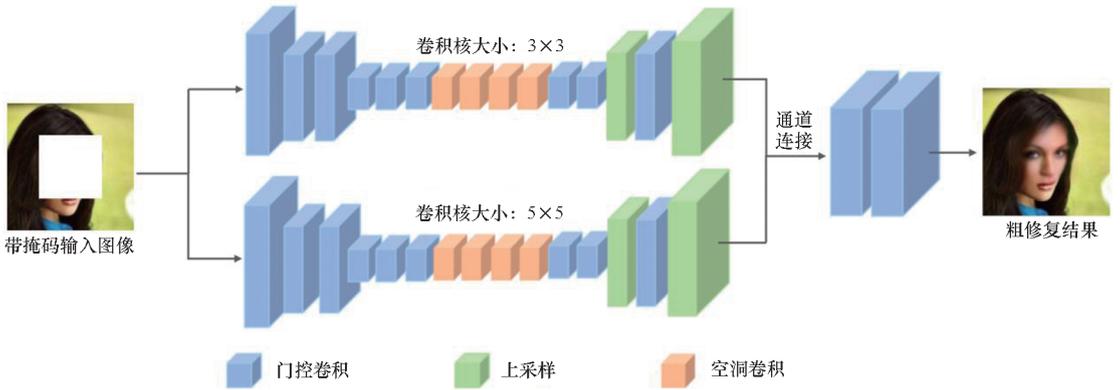


图2 结构修复网络模型结构

Fig. 2 Structure repair network model structure diagram

提出的结构修复网络优于现有的编解码结构。常用的编-解码器将图像转换为具有相同大小信息感受野的公共特征空间,忽略了各类特征的级别差异。提出的并行卷积网络生成的图像包含不同尺度的结构信息,在解码阶段相互补充,引入门控卷积扩大图像信息捕获范围,加入组归一化使训练过程不受batchsize的影响,加入结构重建损失,提高生成图像的结构相似性。

1.2 残差连接与注意力机制融合网络

提出的细节修复网络与现有两阶段修复算法的不同之处在于:引入残差连接,将低层次信息通

过编解码之间的长跳跃连接向解码层传递,在解码层之前引入自注意力机制^[20],提取图像深层语义信息,设计残差连接与注意力机制融合模块,将图像低层次信息与深层语义信息结合,促进上下文信息交互,将融合结果输入生成器经上采样操作后,修复缺失内容的精细细节。细节修复网络如图3所示。

生成器的基本架构是上下文编解码器,共包括11个门控卷积层、4个扩张卷积层和2个反卷积层,最后一层卷积使用Tanh激活函数,其余卷积层均使用LeakyReLU激活函数。自注意力机制

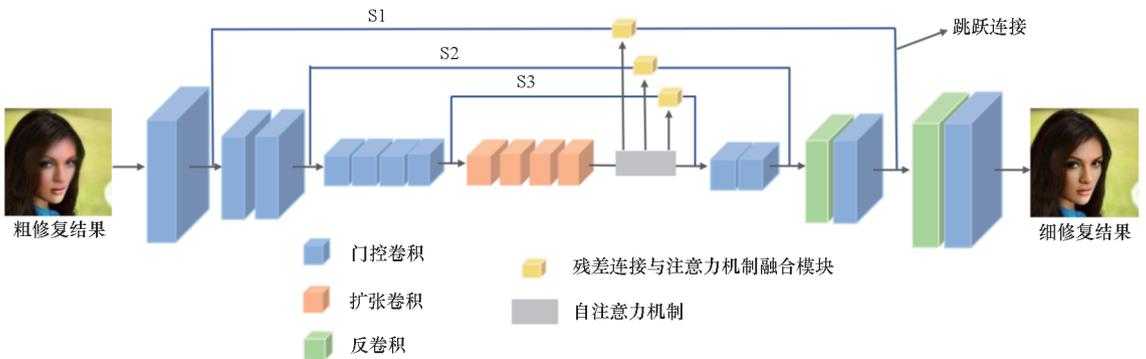


图3 细节修复网络

Fig. 3 Fine repair network

计算像素点间的相关性,提取图像细节特征。设输入特征为 \mathbf{x} , 从中提取低维特征向量 \mathbf{K} 、 \mathbf{Q} 、 \mathbf{V} , 计算输入向量的注意力分值:

$$\mathbf{x}_{i,j} = \frac{\exp((\mathbf{w}^Q \mathbf{x})^T (\mathbf{w}^K \mathbf{x})_i)}{\sum_{i=1}^N \exp((\mathbf{w}^Q \mathbf{x})^T (\mathbf{w}^K \mathbf{x})_i)} \quad (3)$$

加权得到所有注意力分数:

$$\mathbf{A}_{i,j} = \sum_{j=1}^N \mathbf{x}_{i,j} (\mathbf{w}^V \mathbf{x})_j \quad (4)$$

其中, \mathbf{w}^K 、 \mathbf{w}^Q 、 \mathbf{w}^V 中表示随机初始化权重矩阵。

计算出注意力分数后,提出算法使用残差连接融合上下文信息,并融入注意力分数加权的高级特征信息填充低级特征图 \mathbf{S}_i ($i = \{1, 2, 3\}$) 中的对应像素,恢复缺失内容的清晰细节。设计残差连接与注意力机制的融合方法如下:

将低级特征图 \mathbf{S} 分为 N 小块,获得每一小块的注意力分数为:

$$\mathbf{S}_{i,j} = \frac{e^{A_{i,j}}}{\sum_{i=1}^N e^{A_{i,j}}} \quad (5)$$

使用注意力分数加权得到的信息块 \mathbf{R}_j 填充低级特征图 \mathbf{S} 中的缺失区域:

$$\mathbf{R}_j = \sum_{i=1}^N \mathbf{S}_{i,j} \mathbf{R}_i \quad (6)$$

式中, \mathbf{R} 是残差图像, \mathbf{R}_i 是从掩码外提取的第 i 个色块。将填充后的低级特征图与图像深层信息一起输入生成器的上采样模糊图像中,获得清晰的纹理细节。

1.3 鉴别器与损失函数

为更好地优化整体网络,增强图像修复结果的整体与局部一致性,提出以 SN-PatchGAN 鉴别器为全局与局部鉴别器计算对抗损失。全局鉴别器关注整体的特征差异,局部鉴别器关注缺失区域的局部像素信息,再使用 VGG19 网络计算特征块的 VGG 损失,并引入置信驱动的重建损失优化整体网络,获得更连续的图像特征。SN-PatchGAN 鉴别器和 VGG19 网络模型如图 4 所示。

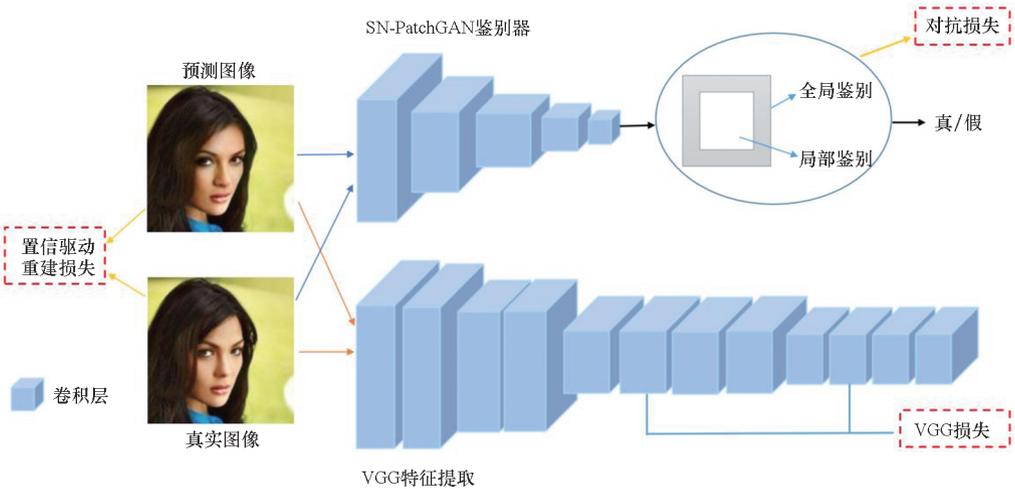


图 4 鉴别器模型结构

Fig. 4 Discriminator model structure diagram

SN-PatchGAN 鉴别器使用全卷积网络,输出图像大小为 $h \times w \times c$ (h 、 w 、 c 分别代表高度、宽度和通道数),堆叠 5 个步长卷积,内核大小为 5,步幅为 2。VGG 特征提取块为预先训练的 VGG19 网络。

1.4 置信驱动重建损失

引入置信驱动的重建损失,使靠近填充边界的未知像素比远离填充边界的未知像素受到更大的约束。设已知像素的置信度为 1,将未知像素的置信度设为与边界的距离相关。为了将已知像素的置信度传播到未知像素,使用大小为 $64 \times$

64 、标准偏差为 40 的高斯滤波器 g 创建损失权重掩码 M_w 。

$$M_w^i = (g * (1 - M + M_w^{i-1})) \odot M \quad (7)$$

其中, $M_w^0 = 0$,重复式(7)生成损失权重掩码 M_w 。最终的重建损失为:

$$L_c = \|(Y - G([X, M]; \theta)) \odot M_w\|_1 \quad (8)$$

其中, θ 是可学习的参数, $G([X, M]; \theta)$ 表示生成模型 G 的输出, Y 为真实图像。

1.5 对抗损失

使用改进的 Wasserstein GAN^[21]、全局与局部鉴别器计算对抗损失,提高生成图像的视觉质量。

对抗损失定义为:

$$L_{\text{adv}} = -E_{X \sim P_X} [D(G(X; \theta))] + \lambda_{\text{gp}} E_{\hat{X} \sim P_{\hat{X}}} [(\|\nabla_{\hat{X}} D(\hat{X}) \odot M_w\|_2 - 1)^2] \quad (9)$$

其中: $\hat{X} = tG([X, M]; \theta) + (1-t)Y$, $t \in [0, 1]$; D 代表鉴别器函数; λ_{gp} 设置为 10。

1.6 VGG 损失

采用相对距离度量局部特征与目标特征之间的相似度。

$$R(v, s) = \exp\left[\left(\frac{\mu(v, s)}{\max_{r \in \rho_v(Y^L)} \mu(v, r) + \varepsilon}\right) / h\right] \quad (10)$$

其中: v, s 分别是生成图像和真实图像从 VGG 第 L 特征层中提取的神经补丁; $R(v, s)$ 表示 v 与 s 的相对相似度; $\mu(v, s)$ 表示 v 与 s 之间的余弦相似度; Y^L 表示预训练 VGG 第 L 特征层生成的特征; $r \in \rho_v(Y^L)$ 表示 r 属于 Y^L (不包括 v); ε, h 是两个正常数。

预测图像与真实图像之间的 VGG 损失定义为:

$$L_v(L) = -\log\left(\frac{1}{z} \sum_{s \in Y^L} \max_{r \in \rho_v(Y^L)} \frac{R(v, s)}{\sum_{r \in \rho_v(Y^L)} R(v, r)}\right) \quad (11)$$

其中, z 表示归一化因子。根据 VGG19 的多个特征层计算最终的 VGG 损失:

$$L_{\text{vgg}} = L_{M, \text{conv4}_2} + \sum_{l=2}^3 L_{M, \text{convl}_2} \quad (12)$$

其中, conv4_2 描述图像语义结构, conv2_2 和 conv3_2 描述图像纹理。最小化 VGG 损失, 使预测图像最接近真实图像。

综上, 整个模型损失函数为:

$$L = L_c + \lambda_{\text{vgg}} L_{\text{vgg}} + \lambda_{\text{adv}} L_{\text{adv}} \quad (13)$$

其中, λ_{adv} 和 λ_{vgg} 是用于平衡不同损失项的参数。

1.7 算法实现流程

所提算法实现步骤如算法 1 所示。

算法 1 并行卷积算法实现流程

Alg. 1 Algorithm implementation flow of parallel convolution

设置训练数据集: 调整数据集图像与掩码大小为 256×256

设置训练初始参数: 重建损失参数 $\lambda_{\text{rec}} = 1.4$, 算法更新梯度初始参数 $\lambda_{\text{ae}} = 1.2$, 马尔可夫鉴别器初始参数 $\lambda_{\text{mf}} = 0.05$, $\lambda_{\text{gp}} = 10$, $\lambda_{\text{adv}} = 0.001$, 算法学习率 $lr = 0.0005$, $\text{batchsize} = 4$, $\text{epoch} = 40$, $D_iters = 5$ (鉴别器最大迭代次数)

1. **while** 迭代次数 $< \text{epoch}$ **then**
2. **if** 鉴别器迭代次数 $< D_iters$ **then**
3. 使用 Adam 优化^[22] 鉴别网络
4. 使用 Adam 优化生成网络
5. 使用式(9)更新鉴别网络参数
6. 使用式(13)更新生成网络参数
7. **else**
8. 使用 Adam 优化生成网络
9. 使用式(13)更新生成网络参数
10. **end if**
11. **end while**

2 实验及结果分析

使用 PyTorch3.7.0 的 GPU 实现网络框架, 使用 Adam^[22] 优化器优化算法。

2.1 数据集与掩码选择

在 CelebA、Paris Street 与 Place2 三个公开数据集上对提出算法进行性能评估。在 CelebA、Place2 公开数据集中选择 20 000 幅和 1 000 幅图像作为训练集和测试集, 在 Paris Street 中选择 14 900 幅和 100 幅图像作为训练集和测试集。使用规则掩码与多个随机不规则掩码, 在同样的训练与测试条件下, 将提出算法与多元图像完成 (pluralistic image completion, PIC) 算法^[16]、可学习双向注意力图 (learnable bidirectional attention maps, LBAM) 算法^[15] 和生成多列卷积神经网络 (generative multi-column convolutional neural networks, GMCNN) 算法^[14] 的修复结果进行对比。

2.2 生成图像结果对比

图 5 是对 Paris Street 数据集叠加规则掩码后各算法修复效果对比。上图缺失区域只包含线条等简单纹理, PIC 算法可以修复出大致的图像结构, 但出现线条扭曲; LBAM 算法只修复出离缺失区域边缘较近的图像结构; GMCNN 算法修复的结果结构较好, 线条较平整, 但颜色变化较大; 提出算法可修复出笔直且合理的线条结构。

图 5 中图的缺失区域为简单结构 (柱子) 与复杂纹理 (窗户) 的结合, PIC 算法对窗户的复杂纹理修复效果不佳, 生成的纹理细节模糊; LBAM 算法不能合理修复缺失区域的中心部分, 无法保证结构的连续性; GMCNN 算法可以修复出图像大致的结构和纹理, 但中间部分有错误的窗户形状存在; 相比较而言, 提出算法修复的结构合理且纹理清晰。

图 5 下图的缺失区域包含复杂纹理和深色背

景, PIC 算法无法很好地修复深色背景边缘, 生成混乱的结构; LBAM 算法在深浅色背景连接处生成的内容模糊; GMCNN 算法不能正确判断深色

区域的合理内容, 生成的结构相似性较差; 相比较而言, 提出算法的修复结果语义更连续, 结构更合理。

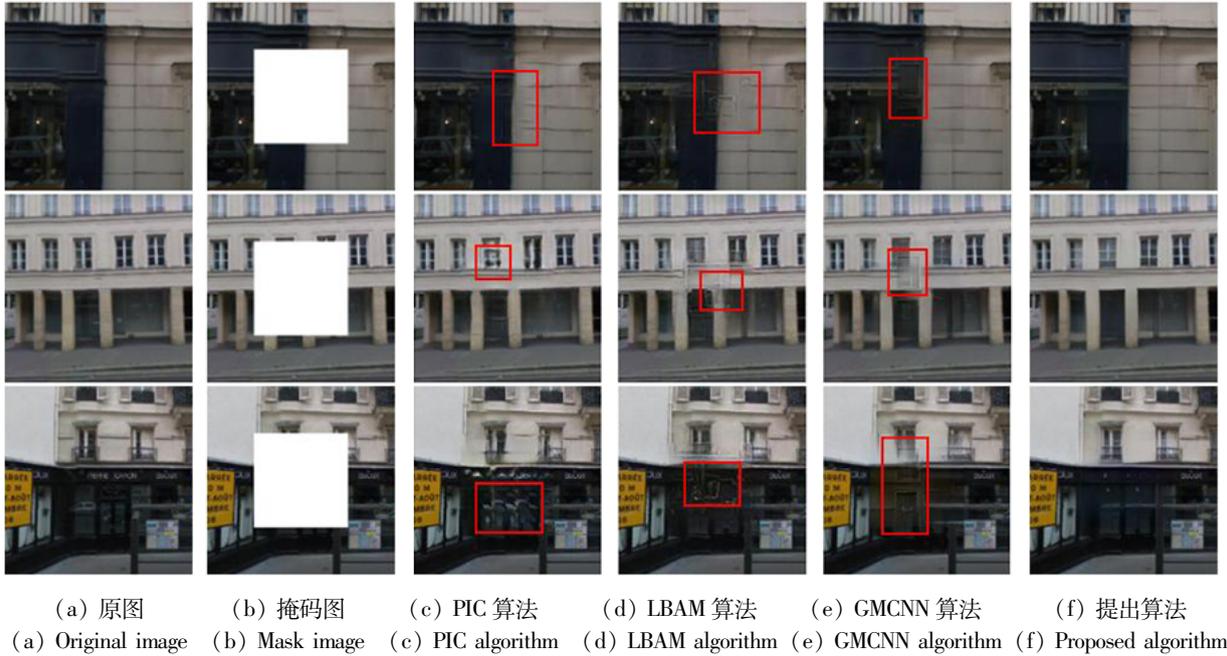


图 5 Paris Street 规则掩码修复效果对比

Fig. 5 Paris Street rule mask repair effect comparison

图 6 是对 Place2 数据集叠加规则掩码后各模型修复效果对比。上图缺失区域颜色单一且结构较简单, PIC 算法可以修复出大致的结构, 但出现大片颜色伪影; LBAM 算法修复的山峰与天空连接处模糊, 存在边缘伪影; GMCNN 算法在山尖处出现结构断裂现象; 提出算法修复的结构较连续。

图 6 中图缺失区域包含丰富的颜色信息, PIC 算法不能修复出缺失区域的合理内容; LBAM 算法修复的结构较合理但细节不清晰; GMCNN 算法修复结果中包含明显的掩码痕迹, 生成区域颜色较深; 提出算法修复的结果合理且与周围区域相似性较高。

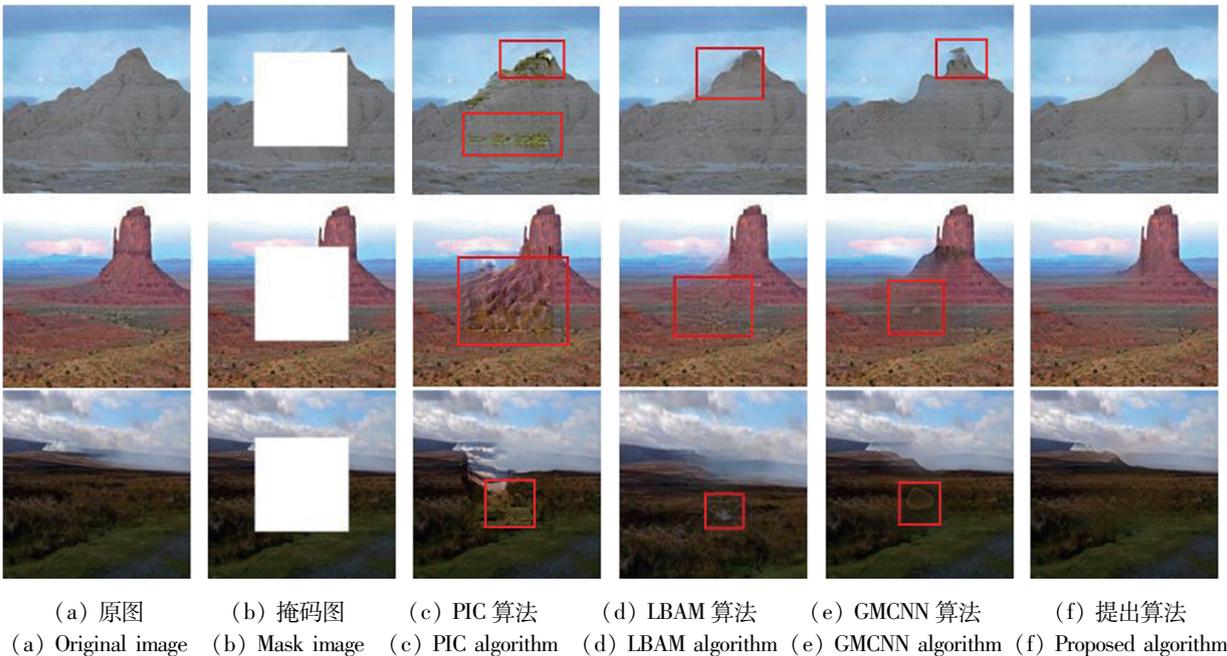


图 6 Place2 规则掩码修复效果对比

Fig. 6 Place2 rule mask repair effect comparison

图6下图的缺失区域包含复杂纹理,PIC算法的修复结果连续性差且纹理不清晰;LBAM算法修复的结构较好,纹理较清晰但出现块状斑点;GMCNN算法修复的结果包含明显的水滴伪影;相比较而言,提出算法可得到较合理的细节内容。

图7是对CelebA数据集叠加规则掩码的修复效果对比。上图掩码覆盖了头发与额头边缘,PIC算法不能合理区分额头与头发像素,修复效果较差;LBAM算法生成的头发结构较连续,但脸部结构扭曲;GMCNN算法生成的结构较完整,但有明显的掩码痕迹;提出算法可以生成合理的结

构与纹理。

图7中图的掩码几乎覆盖了人脸的所有五官。PIC算法修复的嘴巴结构混乱;LBAM算法修复的眼睛有重叠现象;GMCNN算法修复的脸部线条不连续;提出算法得到的结果与原图相似度较高。

图7下图中,PIC算法生成的内容不清晰,有大量的颜色不一致现象,视觉效果较差;LBAM算法生成的结果存在明显扭曲,难以修复五官细节;GMCNN算法修复的颧骨相似性较差;相比较而言,提出算法修复的结构完整,有较好的视觉特征。

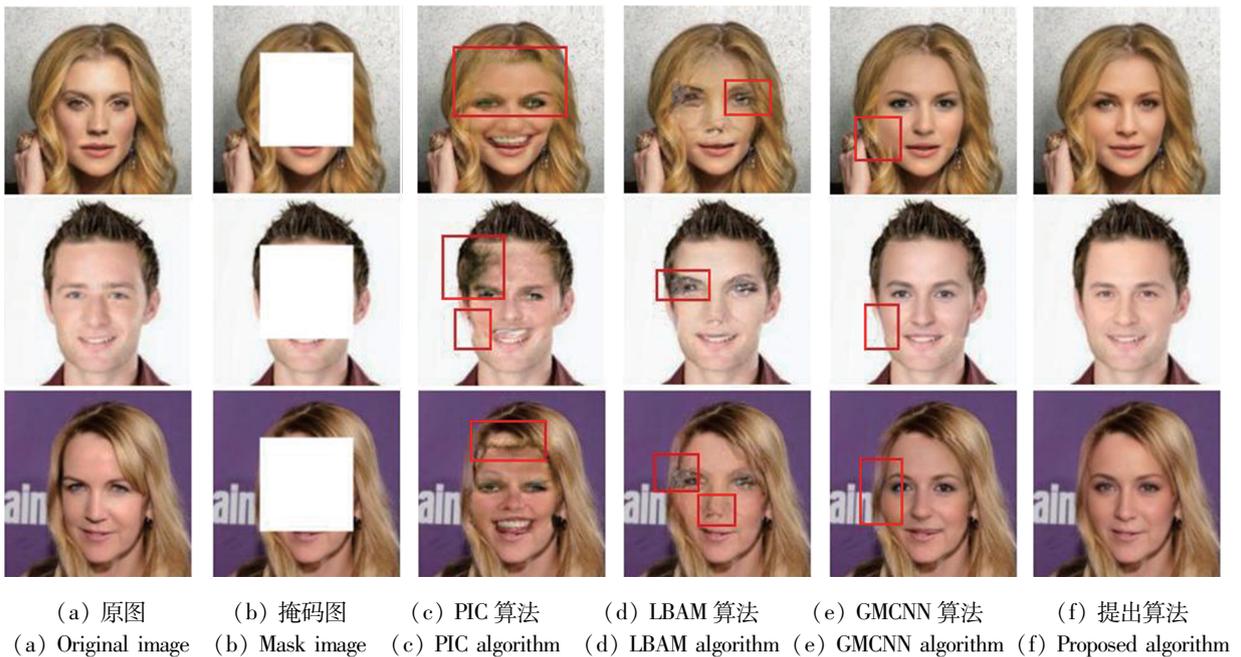


图7 CelebA 规则掩码修复效果对比

Fig.7 CelebA rule mask repair effect comparison

为验证提出算法对大面积不规则缺失修复的有效性,在Paris Street数据集上添加多个不规则掩码,将提出算法与多缺失修复算法GMCNN对比,如图8所示。上图中,在白色管道与深色墙沿边缘处,GMCNN算法未能正确修复出白色管道;相比较而言,提出算法能修复出清晰的白色管道,并在管道与深色墙沿连接处生成清晰的边缘细节。在窗户边沿处,GMCNN算法修复的部分线条结构扭曲,提出算法修复的结果结构清晰且与原图相似性较高。

图8中图中,GMCNN算法修复的窗框纹理模糊,且颜色较深,窗框与玻璃相接处的结构不够连续;提出算法可以正确区分窗框与玻璃,生成的

窗框内容清晰且结构连续。

图8下图中,缺失区域包含横条百叶窗的复杂纹理,GMCNN算法不能修复出百叶窗的复杂线条,但是提出算法可以修复出清晰的线条结构。在门与窗户的掩码处,GMCNN算法修复的门边缘细节较差,窗户的结构模糊;相对而言,提出算法修复的结构和纹理较清晰,有较好的语义连续性和合理性。

为客观评价提出算法,用峰值信噪比(peak signal to noise ratio, PSNR)、结构相似性(structural similarity, SSIM)和L2损失——均方误差(mean squared error, MSE)分别对三种数据集进行定量分析,其结果如表1~3所示。

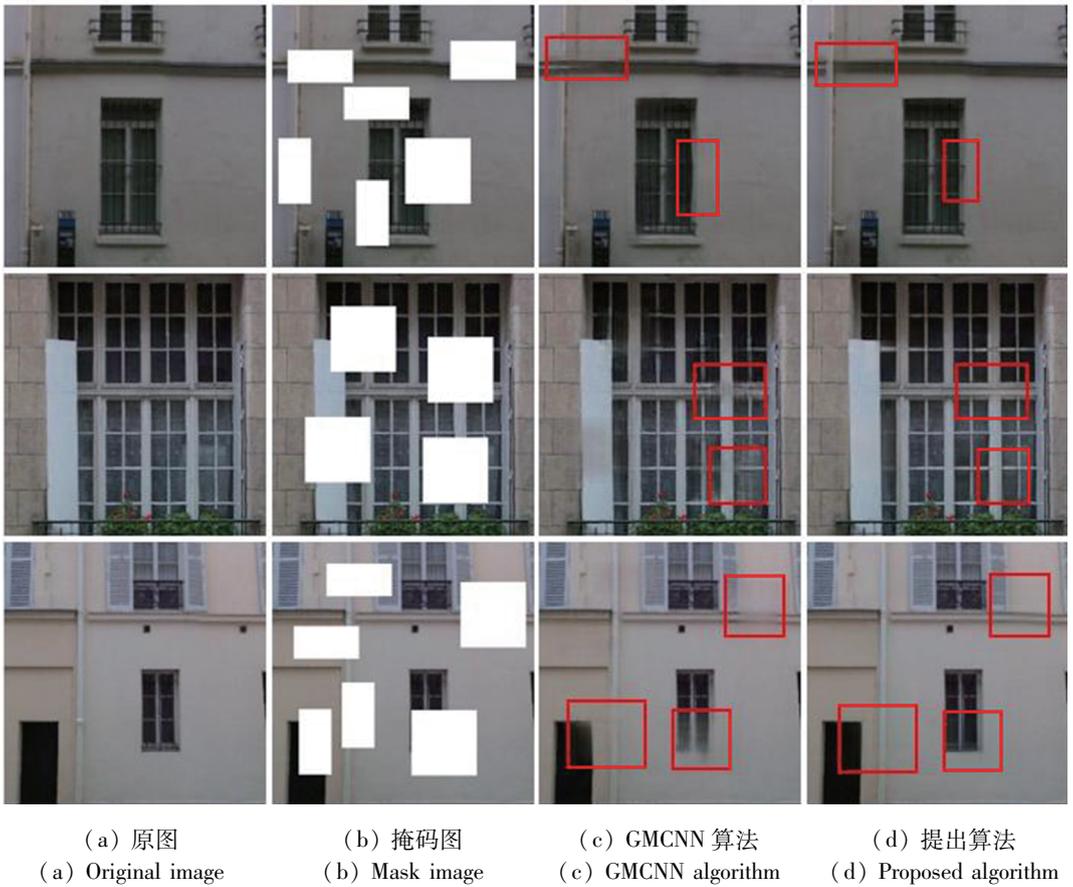


图 8 Paris Street 不规则掩码修复效果对比

Fig. 8 Paris Street irregular mask repair effect comparison

表 1 Paris Street 数据集定量分析

Tab. 1 Paris Street data set quantitative analysis

修复算法	Paris Street		
	PSNR/dB	SSIM	L2(MSE)
PIC ^[16]	28.35	0.79	33.48
LBAM ^[15]	28.46	0.84	30.98
GMCNN ^[14]	28.64	0.88	28.54
提出算法	28.82	0.91	23.72

表 2 Place2 数据集定量分析

Tab. 2 Place2 data set quantitative analysis

修复算法	Place2		
	PSNR/dB	SSIM	L2(MSE)
PIC ^[16]	23.83	0.75	33.82
LBAM ^[15]	23.88	0.77	31.49
GMCNN ^[14]	25.15	0.83	23.06
提出算法	33.23	0.89	20.92

表 3 CelebA 数据集定量分析

Tab. 3 CelebA data set quantitative analysis

修复算法	CelebA		
	PSNR/dB	SSIM	L2(MSE)
PIC ^[16]	21.35	0.76	30.95
LBAM ^[15]	22.69	0.82	32.88
GMCNN ^[14]	23.55	0.88	21.68
提出算法	27.25	0.92	19.37

3 结论

提出并行生成卷积的残差连接图像修复算法,基于结构和细节修复网络对缺失图像进行修复。结构修复网络包含两个并行生成器,可生成具有不同尺度特征的图像并经过共同解码模块合成图像分量,对合成图像使用 L2 损失优化结构修复网络,增加修复图像的结构相似性。细节修复网络是融合了残差连接与注意力机制的生成对抗网络模型,可获得精细的纹理细节。使用 SN-PatchGAN 全局与局部鉴别器对网络进行判别优

从表 1~3 的评价指标可以看出,提出算法的客观指标在三种数据集上都获得了最好的效果。

化,增强修复结果的整体与局部一致性。对算法进行定性比较和定量分析,结果表明:提出算法能有效修复大面积缺失图像,提升图像细节、语义和结构的真实性与完整性。

参考文献 (References)

- [1] BERTALMIO M, SAPIRO G, CASELLES V, et al. Image inpainting[C]//Proceedings of the 27th Annual Conference on Computer Graphics and Interactive Techniques, 2000: 417-424.
- [2] BALLESTER C, BERTALMIO M, CASELLES V, et al. Filling-in by joint interpolation of vector fields and gray levels[J]. IEEE Transactions on Image Processing, 2001, 10(8): 1200-1211.
- [3] SHEN J H, CHAN T F. Mathematical models for local nontexture inpaintings [J]. SIAM Journal on Applied Mathematics, 2002, 62(3): 1019-1043.
- [4] 张宗华, 彭翔, 胡小唐. 深度图像的纹理合成方法[J]. 天津大学学报(自然科学与工程技术版), 2001, 34(6): 733-737.
ZHANG Z H, PENG X, HU X T. Approach to merge texture of range images [J]. Journal of Tianjin University (Science and Technology), 2001, 34(6): 733-737. (in Chinese)
- [5] BERTALMIO M, VESE L, SAPIRO G, et al. Simultaneous structure and texture image inpainting [C]//Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2003.
- [6] CRIMINISI A, PEREZ P, TOYAMA K. Object removal by exemplar-based inpainting [C]//Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2003.
- [7] XIE J Y, XU L L, CHEN E H, et al. Image denoising and inpainting with deep neural networks[C]//Proceedings of the 25th International Conference on Neural Information Processing Systems, 2012: 341-349.
- [8] IIZUKA S, SIMO-SERRA E, ISHIKAWA H. Globally and locally consistent image completion[J]. ACM Transactions on Graphics, 2017, 36(4): 1-14.
- [9] YU J H, LIN Z, YANG J M, et al. Generative image inpainting with contextual attention [C]//Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 5505-5514.
- [10] NAZERI K, NG E, JOSEPH T, et al. EdgeConnect: generative image inpainting with adversarial edge learning[C]// Proceedings of International Conference on Computer Vision and Pattern Recognition, 2019.
- [11] XIONG W, YU J H, LIN Z, et al. Foreground-aware image inpainting [C]//Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 5833-5841.
- [12] 李海燕, 吴自莹, 郭磊, 等. 基于混合空洞卷积网络的多鉴别器图像修复[J]. 华中科技大学学报(自然科学版), 2021, 49(3): 40-45.
LI H Y, WU Z Y, GUO L, et al. Multi-discriminator image inpainting algorithm based on hybrid dilated convolution network [J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2021, 49(3): 40-45. (in Chinese)
- [13] PENG J L, LIU D, XU S C, et al. Generating diverse structure for image inpainting with hierarchical VQ-VAE [C]// Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021: 10770-10779.
- [14] WANG Y, TAO X, QI X J, et al. Image inpainting via generative multi-column convolutional neural networks [C]// Proceedings of International Conference on Computer Vision and Pattern Recognition, 2018.
- [15] XIE C H, LIU S H, LI C, et al. Image inpainting with learnable bidirectional attention maps [C]//Proceedings of IEEE/CVF International Conference on Computer Vision (ICCV), 2020: 8857-8866.
- [16] ZHENG C X, CHAM T J, CAI J F. Pluralistic image completion [C]//Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 1438-1447.
- [17] LIU H Y, WAN Z Y, HUANG W, et al. PD-GAN: probabilistic diverse GAN for image inpainting [C]// Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021: 9367-9376.
- [18] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks [J]. Journal of Machine Learning Research, 2010, 9: 249-256.
- [19] WU Y X, HE K M. Group normalization [J]. International Journal of Computer Vision, 2020, 128(3): 742-755.
- [20] ZHANG H, GOODFELLOW I, METAXAS D, et al. Self-attention generative adversarial networks [J]. Machine Learning, 2018.
- [21] WEI X, GONG B Q, LIU Z X, et al. Improving the improved training of Wasserstein GANs: a consistency term and its dual effect [C]//Proceedings of International Conference on Learning Representation (ICLR), 2018.
- [22] KINGMA D P, BA J. Adam: a method for stochastic optimization [C]//Proceedings of the 3rd International Conference for Learning Representations, 2015.