

基于色彩聚类的图像修复^①

冯莹莹¹, 邱宇², 张登银¹

¹(南京邮电大学 物联网学院, 南京 210003)

²(南京邮电大学 通信与信息工程学院, 南京 210003)

通信作者: 张登银, E-mail: zhangdy@njupt.edu.cn



摘要: 现有图像修复方式普遍存在结构错乱和修复区域边缘模糊的问题, 这是由于修复过程中已知区域的结构信息未能得到充分利用, 针对这一问题, 本文提出了一种具有编解码结构的基于色彩聚类的图像修复算法, 算法采用渐进式图像修复网络结构, 将图像经过色彩聚类的结果作为输入, 聚类算法处理后的图像更好保留了输入图像的结构特征, 因此在后续图像纹理恢复过程中结构信息可以得到充分利用; 同时, 为进一步减少网络的计算开销, 引入交叉注意力机制, 从水平和垂直两个维度建模图像全局依赖性. 实验结果表明, 本文提出的图像修复算法可以有效缓解图像修复区域边缘模糊的现象, 与几种主流图像修复算法相比, 我们提出的图像修复算法可以在缺失区域较大的情况下产生更加真实的输出结果.

关键词: 图像修复; 色彩聚类; 交叉注意力机制; 渐进式修复

引用格式: 冯莹莹, 邱宇, 张登银. 基于色彩聚类的图像修复. 计算机系统应用, 2023, 32(11): 240-246. <http://www.c-s-a.org.cn/1003-3254/9284.html>

Image Restoration Based on Color Clustering

FENG Ying-Ying¹, QIU Yu², ZHANG Deng-Yin¹

¹(School of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

²(School of Communication and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: Existing image restoration methods generally suffer from structural misalignment and blurred edges of the restored area, which is due to the under-utilization of structural information in known areas during image restoration. To this end, a color clustering-based image restoration algorithm with an encoder-decoder structure is proposed in this study. The algorithm uses a progressive image restoration network structure, taking the results of the images after color clustering as input, and the images processed by the clustering algorithm better preserve the structural information. Therefore, the structural information can be fully utilized in the subsequent image texture restoration process. Meanwhile, to further reduce the computational overhead of the network, a cross-attention mechanism is introduced to model the global dependence of images from both horizontal and vertical dimensions. The experimental results show that the image restoration algorithm proposed in this study can effectively alleviate the blurring of the edges in the restored areas, and compared with several mainstream image restoration algorithms, the proposed image restoration algorithm can produce more realistic output results in the case of large missing areas.

Key words: image restoration; color clustering; cross-attention mechanism; progressive recovery

图像作为一种直观易懂的信息载体, 已经成为人们交流的重要形式之一. 然而, 图像在采集、保存以及

传递过程中易受环境、设备和技术影响^[1], 容易出现信息缺失的现象. 图像修复是指给定一张部分像素缺

① 基金项目: 国家自然科学基金 (61872423)

收稿时间: 2023-04-06; 修改时间: 2023-05-17; 采用时间: 2023-05-25; csa 在线出版时间: 2023-08-09

CNKI 网络首发时间: 2023-08-10

失的图像,根据图像中的已知信息对缺失的区域进行像素级填充,从而使填充后的图像达到人类视觉满意的效果.图像修复作为计算机视觉领域一项基本内容,也是许多图像处理任务的重要组成部分,研究图像修复的技术并将其应用到实际生活中具有重要意义.

传统的图像修复算法主要分为基于扩散和基于块匹配两类,通常是根据图像样本相似性或者结构纹理方面的信息,推理缺失区域,传统方法对图像纹理和分辨率具有较高的鲁棒性,但是计算代价非常昂贵,并且它无法有效提取并利用图像的语义信息,往往不适用于具有复杂结构或缺失区域占比较大的图像.基于深度学习的图像修复方式通过训练深度神经网络,挖掘图像深层语义特征,弥补了传统图像修复技术的不足.

基于深度学习的图像修复方式按照网络结构层次分为单阶段和多阶段图像修复.单阶段图像修复算法通常利用编解码或者 U-Net 结构,在多个损失函数联合约束下,直接恢复缺失图像.典型算法如 Pathak 等人提出的上下文编码器 CE^[2],Liu 等人提出的基于特征均衡的互编解码网络 MED^[3].多阶段图像修复算法按照技术路线大致分为两类,第 1 类以第 1 阶段重构的信息作为先验指导后续纹理合成任务,如 Liao 等人^[4]采用多尺度联合优化,首先对语义和纹理的联合先验进行建模.第 2 类采用由粗到细渐进恢复图像缺失区域的方式,如 Yang 等人^[5]提出的多尺度神经网络合成,首先将 512×512 大小的测试图像以步长为 2 进行两次下采样,创建 3 层金字塔结构图像作为输入,然后执行由粗到细的图像修复.Zamir 等人^[6]将输入图像分为不重叠的块,第 1 阶段分为 4 块,第 2 阶段分为 2 块,为保留更多的空间细节,最后一阶段在原始图像上进行操作.Lamba 等人^[7]将原图分辨率分别降为 1/32, 1/8 以及 1/2 再通过级联操作依次恢复.

考虑到渐进式图像修复算法在下采样过程中会丢失大量信息,且相较于图像色彩的细微差异,人们往往对图像整体结构一致性更为敏感,故本文提出一种新的基于色彩聚类的图像修复算法.这与 Wang 等人^[8]为解决图像修复过程中可能会出现色彩渗透问题,提出的将图像修复工作分为外部结构重建以及内部色彩引导修复两个阶段想法相类似.Wang 等人在结构重建阶段将三通道彩色图片转化为单通道黑白图片,接着在单色空间中重建缺失的结构和细节,色彩引导阶段利用渐进学习策略实现内部颜色传播与恢复.本文

同样采用了色彩量化情形下的结构重建思想,不同的是,本文用 K-means 聚类算法对图像色彩进行处理,处理后的图像保留了一定量级(≥ 2)的色彩信息和更加完整的结构信息;并且为满足细粒度图像恢复质量需求,采用渐进式图像恢复结构,将 K-means 聚类处理后的生成图像作为输入,结合 K 值较小的图像恢复结果,由粗到细来恢复色彩损失,优化修复结果.主流图像修复方式常采用上下文注意力机制提取远距离图像信息,这会带来大量的计算开销.为降低计算成本,本文在最后一层修复网络中引入交叉注意力机制,从水平和垂直两个维度建模全局依赖性,增强逐像素表征能力.同时,为修复任意位置、任意形状缺失的图像,采用门控卷积在每个空间位置为每个通道提供可学习的动态特征选择机制.

我们在 Paris StreetView 和 Places2 数据集上进行了大量实验以评估模型性能,结果表明,我们提出的图像修复方法与经典修复方式 EC^[9]、MED^[3]、CA^[10]、GC^[11]相比,修复图片更加清晰,边缘伪影明显减少,且峰值信噪比 (peak signal to noise ratio, PSNR) 与结构相似度 (structural similarity, SSIM) 均有提升.相较于其他方法,本文主要解决了如下两个方面的问题.

(1) 提出了一种基于色彩聚类的图像修复算法,该算法将对全分辨率图像进行色彩聚类处理的结果作为输入,为后续修复任务保留了更多的结构和色彩细节,也为渐进式图像修复网络的输入提供了新的思路.

(2) 引入交叉注意力机制,从水平和垂直两个维度建模全局依赖性,增强逐像素表征能力,可以有效减少网络参数,降低计算开销.

1 相关工作

1.1 基于深度学习的图像修复算法

基于深度学习的图像修复算法利用卷积神经网络提取图像的语义信息,填充图像的缺失区域.然而,这些方式生成的图像通常会存在边缘伪影以及与已知区域结构纹理信息不一致的现象.为此,Iizuka 等人^[12]引入全局和局部上下文鉴别器,分别从整体和局部确保生成图像的上下文一致,Yu 等人^[11]提出门控卷积,与用户输入兼容,根据当前位置是否被遮挡自动学习掩码,同时融合上下文注意力机制,优化已知区域与未知区域之间的纹理相似性.Liu 等人^[3]提出交互编解码网络,由图像浅层特征提取纹理信息,深层特征提取结构

信息, 并采用双边传播激活函数均衡图像结构和纹理特征, 有效去除了缺失区域周围的模糊和伪影. Zeng 等人^[13]在 U-Net 架构中引入了多尺度编码器, 使用注意力转移网络由深到浅逐层修复. Wang 等人^[14]在 U-Net 编码器中采用分层金字塔卷积和动态归一化机制获取不同感受野的图像特征图, 解码器部分使用金字塔注意力机制以学习更加精细的特征信息. Li 等人^[15]设计了一个即插即用的循环特征推理模块, 利用部分卷积多次循环由外向内逐步完善修复图像.

1.2 注意力机制

在图像修复任务中引入注意力机制可以使图像信息得到充分利用, 注意力机制在背景区域中搜索可能的纹理信息, 替换生成的部分, 从而生成纹理一致的结果. 如 Yu 等人^[10]为利用图像远距离已经区域信息, 提出上下文注意力机制, 通过卷积计算前景与背景区域的余弦相似性, 接着在相似性图上作通道维度的, 选取值最大的背景块进行反卷积. Shin 等人^[16]基于两向量

之间角度的考虑, 提出使用欧式距离代替余弦相似性得分. Liu 等人^[17]认为生成图像块之间的相似性同样重要, 提出利用图像已知区域与未知区域之间的相似性保证图像的全局语义一致性, 利用未知区域内部相邻块之间的相似性进行迭代优化保证图像局部特征一致性.

2 基于 K-means 聚类的图像修复算法

本文所提出的图像修复算法网络结构如图 1 所示, 由色彩聚类图像生成、图像结构分层重建以及光谱归一化马尔可夫鉴别器 3 部分组成, 首先, 为降低计算成本, 选用 K-means 算法对图像进行聚类处理, 处理后图像的结构信息可以得到更好的保留. 在图像结构分层重建中引入交叉注意力机制和门控卷积, 前者有利于减少网络的参数量, 降低计算成本, 后者用于处理任意位置形状的缺失区域图像修复. 鉴别器模块采用结合 SN-GAN 和 PatchGAN 的光谱归一化马尔可夫鉴别器 SN-PatchGAN^[11], 以提高训练的稳定性.

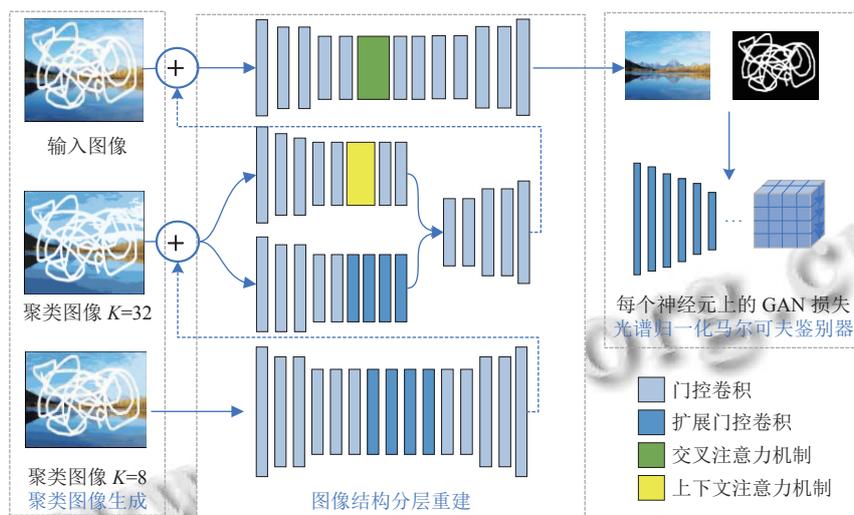


图 1 网络结构模型图

2.1 K-means 聚类图像生成

图像可以看作是若干像素点的集合, 对图像进行聚类就是将构成图像的像素点进行分组, 一个聚类就是一组像素点的集合, 聚类的最终目标是使同一集合中的元素具有较高的相似度, 不同集合间差别尽可能大. 给定一张图像, 根据 K-means 算法^[18], 首先随机初始化 K 个不同颜色分量作为聚类中心, 将图像中的每个像素根据颜色距离最短的原则分配到相应的簇, 颜色距离公式如 (1) 所示:

$$Distance = \sqrt{(R-R')^2 + ((G-G')^2 + ((B-B')^2)} \quad (1)$$

其中, (R', G', B') 为聚类中心的像素值, (R, G, B) 为图像中除聚类中心外其余任一点的像素值.

当所有像素对象划分完成后, 重新计算每个簇的颜色分量的均值, 将均值作为新的聚类中心重新划分簇, 算法运行停止准则为中心点颜色分量不再发生变化.

考虑到人们对细微颜色差异并不敏感和推理速度的要求以及计算可行性, 我们跳过会带来大量计算开

销和延迟的较低尺度, 仅在 $K=8$ 、 $K=32$ 以及原输入图像上进行操作. 如图 2 所示, 聚类生成图像更为完整保留了图像的结构信息, 作为分层修复网络的输入, 更有利于后续的修复任务进行.

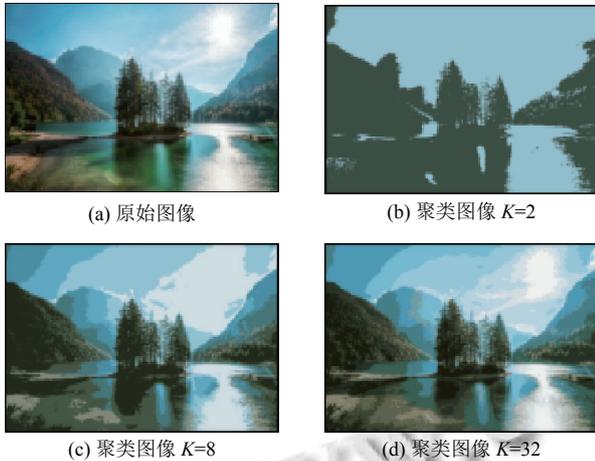


图 2 聚类图像生成示例

2.2 图像结构分层重建

相较于图像细微颜色的差异, 人们观察图像时更加注重整体结构的观感. 为使生成图像结构合理以及保持上下文语义的一致性, 我们采用图像结构分层重建逐层细化修复结果. 网络采用编解码结构, 首先, 以 $K=8$ 时的聚类图像作为编码器输入, 并且在编解码结构中引入扩展卷积, 其在标准卷积的基础上引入了扩展率的参数, 如图 3 所示图 3(a) 为普通卷积, 图 3(b) 为扩展卷积, 扩展率为 2. 即扩展卷积通过向卷积核各参数之间引入间隔, 可以在保持网络参数数量不变的前提下增加卷积核的感受野, 使得卷积核的输出能够包含较大范围的信息, 再由解码器恢复出粗略修复结果. 将第一层粗略恢复的图像生成部分与 $K=32$ 时的聚类图像结合, 作为第 2 层的输入, 第 2 层采用融合上下文注意力机制和扩展卷积两条路径的编解码结构进行图像修复, 再将修复的结果送入原始输入图像中进行更细粒度的修复.

考虑到上下文注意力机制的计算复杂度, 为降低计算成本, 在最后一层修复网络中引入可以简化计算的交叉注意力机制^[19], 同时, 为修复任意位置、任意形状缺失的图像, 采用门控卷积^[11]代替普通卷积.

2.2.1 交叉注意力机制

交叉注意力机制从水平和垂直两个维度建模图像全局依赖, 增强逐像素表征能力. 模型结构如图 4 所示. 交叉注意力模块首先使用两个带有 1×1 滤波器的卷积层对输入局部特征图 $F \in \mathbb{R}^{(C \times W \times H)}$ 进行卷积, 生成两个

特征图 F_1 和 F_2 , 接着, 对 F_1 和 F_2 进行仿射变换, 再送入 Softmax 层生成注意力图 $A \in \mathbb{R}^{(W \times H+1) \times (W \times H)}$, 利用另一个带有 1×1 滤波器的卷积层, 进行自适应特征融合, 其中, C 、 W 、 H 分别为特征图的通道数、宽度和高度.

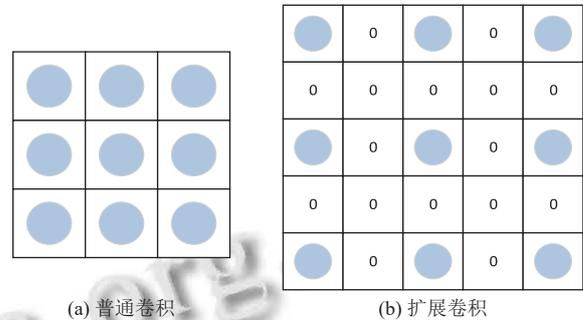


图 3 扩展卷积模块结构图

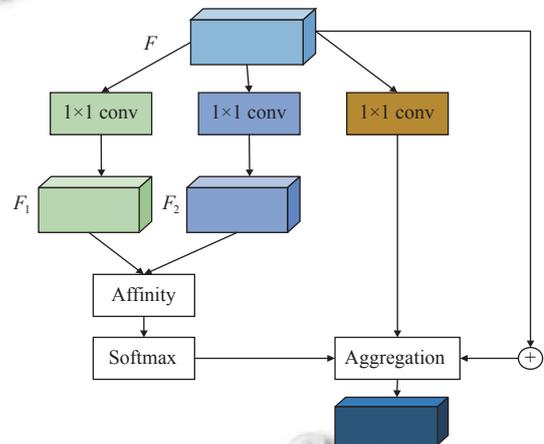


图 4 交叉注意力模块结构图

交叉注意力模块中单个像素与其非同行或同列的像素之间不存在联系, 为充分利用上下文信息, 采用双层交叉注意力模块, 在第 1 次注意力传播过程中, 像素点 A 的信息传递至其同行同列, B 点接收不到 A 的信息, 在第 2 次传播过程中, B 通过其所在行列与 A 所在行列的交叉点获取像素点 A 的信息, A 点注意力传播过程如图 5 所示, 所以通过双层交叉注意力模块的堆叠, 任意像素点能够收集图像中所有像素的上下文信息.

非局部注意力机制首先生成每个位置的注意力图, 并将输入特征图转化为每个位置注意力图的加权和, 需要 $O(N^2)$ 时间与空间复杂度, 其中 N 为输入特征的数量, 而交叉注意力模块与特征图中的每个位置只有稀疏的连接, 约为 \sqrt{N} , 因此时间和空间复杂度为 $O(N\sqrt{N})$, 在最后一层修复网络中, 使用双层交叉注意力机制代替传统的上下文注意力机制, 能够在保证图像修复质量的基础上有效减低网络参数量.

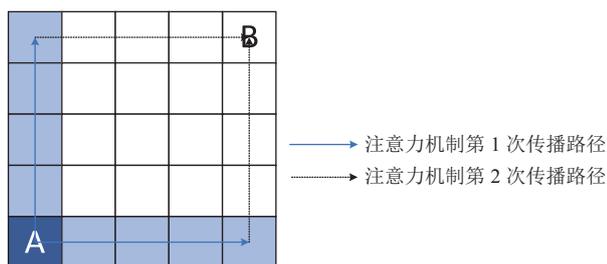


图5 双层交叉注意力模块示意图

2.2.2 门控卷积

普通卷积中将所有像素视作有效像素,采用同样处理方式,容易造成图像缺失区域边缘模糊,门控卷积采用动态特征选择机制,可以动态学习不同通道和空间特征,获取缺失区域与已知区域的关联特征,门控卷积 $O_{y,x}$ 由门控选择单元 $Gating_{y,x}$ 和特征选择单元 $Feature_{y,x}$ 进行像素级别的乘积.其公式如下:

$$Gating_{y,x} = \sum \sum W_g \cdot I \quad (2)$$

$$Feature_{y,x} = \sum \sum W_f \cdot I \quad (3)$$

$$O_{y,x} = \phi(Feature_{y,x}) \odot \sigma(Gating_{y,x}) \quad (4)$$

其中, I 表示输入特征. W_g 、 W_f 是两个不同的卷积滤波器,分别用于计算门控值和特征值. $\phi(\cdot)$ 是 $ReLU$ 激活函数, $\sigma(\cdot)$ 为Sigmoid函数,用于输出(0,1)范围内的门控值.门控卷积的引入不仅使网络能够根据背景、掩码、草图动态选择特征,还能考虑某些通道的语义信息,即使在网络较深的层次中,也能突出掩码区域,以生成更好的修复结果,有效减少修复区域边缘模糊的现象.

2.3 鉴别器模块

为提高训练的稳定性,鉴别器模块采用结合 SN-GAN 和 PatchGAN 的光谱归一化马尔可夫鉴别器 SN-PatchGAN^[11],SN-PatchGAN 由堆叠的卷积层构成.鉴别器的输入是图片和掩码,输出为 $h \times w \times c$ 的三维特征图.对输出特征图上的每个元素应用 GAN,因此输出特征图中神经元的感受野可以覆盖整个输入图像,无需全局鉴别器.

2.4 损失函数

为得到结构一致且视觉满意的图像修复结果,本文采用重构损失和 SN-PatchGAN 损失提高所有尺度下的像素重建精度,默认损失平衡超参数为 1:1.

SN-PatchGAN 损失由生成器损失函数和鉴别器损失函数两部分组成,公式分别为:

$$L_G = -E_{z \sim P_z(z)} [D^{sn}(G(z))] \quad (5)$$

$$L_{D^{sn}} = E_{z \sim P_{data}(x)} [ReLU(1 - D^{sn}(x))] + E_{z \sim P_z(z)} [ReLU(1 + D^{sn}(G(z)))] \quad (6)$$

其中, G 是修复网络, L_G 表示生成器的损失函数, D^{sn} 表示光谱归一化鉴别器, $L_{D^{sn}}$ 表示鉴别器的损失函数, z 为输入图像.

重建损失函数要保证修复图像真实感和清晰度,对于像素级的重建过程,算法选用 L_1 重建损失函数:

$$L_1 = \|x - G(z)\|_1 \quad (7)$$

3 实验

3.1 实验设计

本文在巴黎街景和 Places2 数据集上展开实验,验证模型的性能,在巴黎街景数据集中随机抽取 500 幅图像作为测试集,其余为训练集,在 Places2 数据集中选取 6 种类型图片,再从中随机抽取 500 张作为测试集,其余为训练集.硬件配置环境为 Intel(R) Core(TM) i7-10875H CPU @ 2.30 GHz.我们使用 Adam 优化器对模型进行训练,设置 batch_size 为 4,初始阶段学习率设置为 1×10^{-4} ,最后使用 1×10^{-5} 进行微调.训练过程中所有图片和掩码均被调整至 256×256 大小,本文中所有实验结果都是由训练好的模型直接输出,没有任何后续处理.

3.2 对比模型

为验证图像恢复质量,本文将提出的 K-means 聚类的图像修复方式与图像修复的经典算法进行对比,通过定性和定量实验,验证本文所提出的模型的性能.

定性比较:图 6 分别展示了本文所提出方法与对比方法在 Paris StreetView 和 Places2 数据集中心区域缺失情形下的恢复效果.如图,在巴黎街道数据集上,EC^[9]、MED^[3] 恢复出的图像缺失区域有明显的伪影,存在修复区域边缘模糊问题,而本文所提出的方法能够有效推理出缺失区域的信息,恢复出与输入图像结构更为一致协调的结果.在 Places2 数据集上,本文提出的修复算法相比于 CA^[10]、GC^[11] 也能推理出与上下文更为一致的合理结构,测试效果如图 7 所示.

图 8 展示了本文所提出的方法与 EC 方法在 Paris StreetView 数据集上不同比例不规则缺失情形下的恢复效果.当缺失区域占比较小时,对比方法和本文提出的方法都能在复杂的场景中得出合理的恢复结果,而随着缺失区域占比逐渐增加,EC 恢复出来的图像恢复结果则更为模糊.在多数情况下,我们的方法可以恢复出更加合理准确的图像结构.

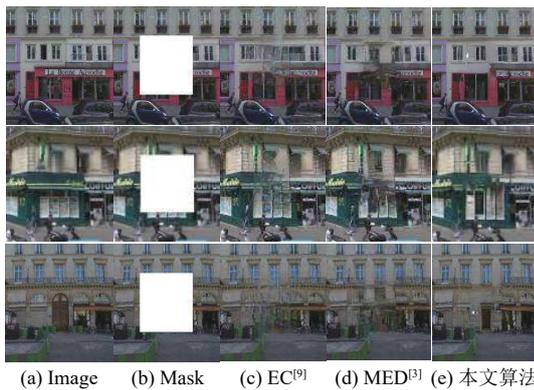


图6 Paris StreetView 掩码为中心为失时恢复效果对比

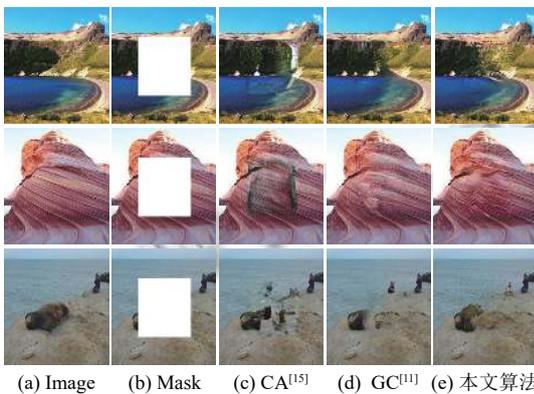


图7 Places2 图像使用中心缺失掩码恢复效果对比

定量比较: 为衡量图像修复质量, 我们采用 *SSIM*、*PSNR* 指标来客观展示对比各种模型性能. *SSIM* 用来反映生成图像与原始图像之间的结构相似性, *SSIM* 值越高表示越相似, *PSNR* 用来反映恢复图像质量的高低, 公式如下, *PSNR* 值越高表明恢复图像质量越高. 具体数值如表 1 所示.

$$PSNR = 20 \lg \left(\frac{(MAX_i)^2}{\sqrt{MSE}} \right) \quad (8)$$

其中, MAX_i 表示生成图像中像素信号的最大值, MSE 表示生成图像与原始图像的均方误差.

$$SSIM = \frac{(2\mu_x\mu_y + c_1)(2\delta_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\delta_x^2 + \delta_y^2 + c_2)} \quad (9)$$

其中, μ_x 、 μ_y 分别表示原始图像与生成图像的像素均值, δ_{xy} 表示协方差, c_1 、 c_2 均表示常量.

通过对本文提出的模型进行定性定量分析可以看出, 可以看出, 本文提出的方法可以恢复出更加合理一致的图像结构, 更适合用于复杂场景较大面积缺失图像恢复中.

3.3 消融实验

为验证本文所提出的基于 K-means 图像修复算法

的有效性, 在 Paris StreetView 数据集上展开了消融实验. 实验结果如图 9 所示, 其中, 图 9(a) 为原始输入图像, 图 9(b) 为采用单张原始图像作为输入生成图像, 图 9(c) 为去掉交叉注意力层所生成的图像.

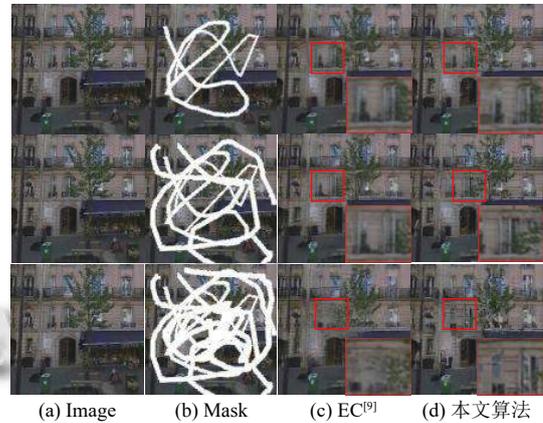


图8 使用不规则缺失掩码恢复效果对比

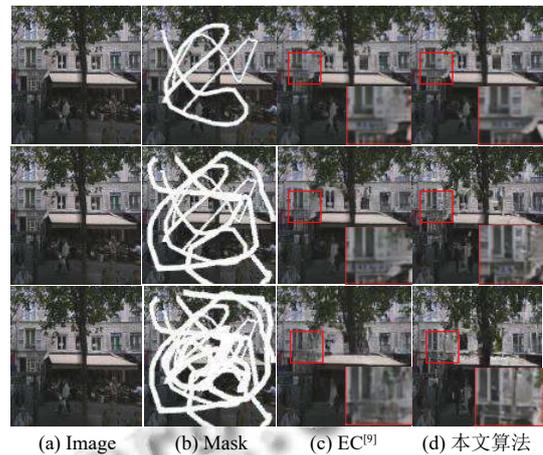


图9 消融实验对比图

表 1 巴黎街景数据集模型指标对比

指标	Mask (%)	CA ^[10]	EC ^[9]	MED ^[3]	本文算法
<i>SSIM</i>	10-20	90.50	93.80	92.50	93.87
	20-30	83.50	89.20	88.20	89.39
	30-40	76.60	84.20	81.90	84.97
	40-50	69.50	78.40	74.70	79.56
<i>PSNR</i> (dB)	10-20	26.09	31.23	27.42	30.65
	20-30	22.80	28.26	25.85	28.34
	30-40	20.74	26.05	23.27	26.18
	40-50	19.35	24.20	21.21	24.42

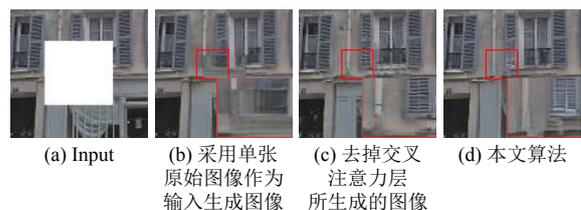


图9 消融实验对比图

通过对比可以看出,采用单张图片作为输入时,会明显出现图像结构模糊,而采用本文提出的基于色彩聚类的图像输入可以更好地保留图像的结构信息,生成更加自然的图像;并且添加了交叉注意力机制可以进一步减小无效特征信息对图像修复的干扰,保持缺失区域与周围像素的一致性.本文提出的基于色彩聚类的图像修复相较于采用单张图片作为输入,不添加交叉注意力机制的原始模型,PSNR和SSIM分别提升了5.31%和2.36%.

4 结论

为解决现有图像修复方法容易引起的修复边缘模糊的问题,本文提出了一种基于色彩聚类的图像修复方式.首先采用K-means算法对图像进行聚类处理,为渐进式图像修复方式输入提供了新的思路,也可以保存更多的图像结构信息,同时为降低传统注意力机制的计算复杂度,引入了交叉注意力机制,从水平和垂直两个维度建模图像全局依赖性,有效减少了计算量.大量实验表明,对比经典主流的修复方式,我们提出的方法更有利于复杂场景的结构重建,能有效减少修复边缘模糊的现象.但是本文仅在注意力模块降低了计算量,如何从整个网络的角度减小参数量和计算量将是接下来主要的研究方向.

参考文献

- 1 陈东岳,朱晓明,马腾,等.双尺度顺序填充的深度图像修复.中国图象图形学报,2022,27(8):2344-2355.
- 2 Pathak D, Krähenbühl P, Donahue J, et al. Context encoders: Feature learning by inpainting. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016. 2536-2544.
- 3 Liu HY, Jiang B, Song YB, et al. Rethinking image inpainting via a mutual encoder-decoder with feature equalizations. Proceedings of the 16th European Conference on Computer Vision. Glasgow: Springer, 2020. 725-741.
- 4 Liao L, Xiao J, Wang Z, et al. Image inpainting guided by coherence priors of semantics and textures. Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE, 2021. 6535-6544.
- 5 Yang C, Lu X, Lin Z, et al. High-resolution image inpainting using multi-scale neural patch synthesis. Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017. 4076-4084.
- 6 Zamir SW, Arora A, Khan S, et al. Multi-stage progressive image restoration. Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE, 2021. 14816-14826.
- 7 Lamba M, Mitra K. Restoring extremely dark images in real time. Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE, 2021. 3486-3496.
- 8 Wang TF, Ouyang H, Chen QF. Image inpainting with external-internal learning and monochromic bottleneck. Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE, 2021. 5116-5125.
- 9 Nazeri K, Ng E, Joseph T, et al. EdgeConnect: Generative image inpainting with adversarial edge learning. arXiv: 1901.00212, 2019.
- 10 Yu JH, Lin Z, Yang JM, et al. Generative image inpainting with contextual attention. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 5505-5514.
- 11 Yu JH, Lin Z, Yang JM, et al. Free-form image inpainting with gated convolution. Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019. 4470-4479.
- 12 Iizuka S, Simo-Serra E, Ishikawa H. Globally and locally consistent image completion. ACM Transactions on Graphics, 2017, 36(4): 107.
- 13 Zeng YH, Fu JL, Chao HY, et al. Learning pyramid-context encoder network for high-quality image inpainting. Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019. 1486-1494.
- 14 Wang C, Shao MW, Meng DY, et al. Dual-pyramidal image inpainting with dynamic normalization. IEEE Transactions on Circuits and Systems for Video Technology, 2022, 32(9): 5975-5988. [doi: 10.1109/TCSVT.2022.3165587]
- 15 Li JY, Wang N, Zhang LF, et al. Recurrent feature reasoning for image inpainting. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020. 7757-7765.
- 16 Shin YG, Sagong MC, Yeo YJ, et al. Peps++: Fast and lightweight network for image inpainting. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(1): 252-265. [doi: 10.1109/TNNLS.2020.2978501]
- 17 Liu HY, Jiang B, Xiao Y, et al. Coherent semantic attention for image inpainting. Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019. 4169-4178.
- 18 任恒怡,贺松,陈文亮.一种改进的K-means聚类算法在图像分割中的应用.通信技术,2017,50(12):2704-2707.
- 19 Huang ZL, Wang XG, Huang LC, et al. CCNet: Criss-cross attention for semantic segmentation. Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019. 603-612.

(校对责编:牛欣悦)