

密集连接的生成对抗网络图像超分辨率重建

李斌^{1*}, 马璐²

¹宿州职业技术学院基础教学部, 安徽 宿州 234099;

²宿州职业技术学院计算机信息系, 安徽 宿州 234099

摘要 针对图像超分辨率重建过程中出现的边缘细节模糊、图像特征丢失的问题, 提出基于密集连接的生成对抗网络图像超分辨率重建算法。该算法由生成网络和判别网络组成, 在生成网络结构中, 将原始低分辨率图像作为网络的输入, 为了实现特征的充分利用, 采用密集连接方式将浅层网络的特征输送到深层网络结构的每一层, 有效避免图像特征的丢失。并在末端进行亚像素卷积, 对图像进行反卷积操作, 完成图像最终的超分辨率重建, 大大减少了训练耗时。在判别网络结构中, 采用 6 个卷积模块和一个全连接层对真伪图像进行甄别, 采用对抗博弈的思想, 提升重建图像的质量。实验结果表明, 本文算法在视觉效果评估、峰值信噪比值、结构相似性值以及耗时等多方面指标上都有了很大的改善, 恢复出较为丰富的图像细节信息, 取得了较好的视觉效果和综合特性。

关键词 图像处理; 超分辨率技术; 密集连接; 生成对抗网络

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP57.221011

Super-Resolution Reconstruction of Densely Connected Generative Adversarial Network Images

Li Bin^{1*}, Ma Lu²

¹Department of Basic Teaching, Suzhou Vocational and Technical College, Suzhou, Anhui 234099, China;

²Department of Computer Information, Suzhou Vocational and Technical College, Suzhou, Anhui 234099, China

Abstract Aiming at the problems of blurred edge details and loss of image features in the process of image super-resolution reconstruction, a super-resolution reconstruction algorithm based on dense connection generative adversarial network is proposed. This algorithm consists of a generative network and a discriminative network. In the generative network structure, the original low-resolution image is used as the input of the network. In order to make full use of the features, the features of the shallow network are transferred to each layer of the deep network structure using dense connection, so as to effectively avoid the loss of image features. Sub-pixel convolution is performed at the end, and the image is deconvolved to complete the final super-resolution reconstruction of the image, which greatly reduces the training time. In the discriminative network structure, 6 convolutional modules and a fully connected layer are used to identify true and false images, and the idea of adversarial games is used to improve the quality of reconstructed images. Experimental results show that the proposed algorithm has greatly improved the visual effect assessment, peak signal to noise ratio value, structural similarity value, time-consuming, and indicators. It has restored richer image detail information and achieved better visual effects and comprehensive characteristic.

Key words image processing; super-resolution technology; dense connection; generative adversarial network

OCIS codes 100.2960; 100.3010

1 引言

图像的超分辨率重建是利用一组低分辨率

(LR)图像(或运动序列)来产生单幅纹理细节清晰, 视觉效果较好的高分辨率(HR)图像^[1]。恢复出的 HR 图像视觉效果清晰, 方便了人们快速精准地获

收稿日期: 2020-02-14; 修回日期: 2020-03-18; 录用日期: 2020-03-26

基金项目: 安徽省高等学校省级质量工程: 计算机类专业数学教学创新团队(2019cxtd041)

* E-mail: 747952996@qq.com

取信息,比如医疗影像、城市安防、卫星遥感等领域,图像是不可或缺的,正因为此技术具有实用价值,所以成为计算机领域研究的热点。

目前,图像的超分辨率重建技术主要分为基于插值^[2]、基于重建^[3]、基于学习^[4]三大类,基于插值的方法是利用自身的相似性,采用近邻插值或双三次插值方法得到高频图像,但这种方法效果不理想。基于重建的方法是给目标函数增加约束项,求取最优解,这种方法也具有局限性。机器学习发展迅速,基于学习的图像超分辨率重建方法取得了突出的成就,其主要学习 LR 图像和 HR 图像之间的映射关系,建立映射模型,利用学习到的先验知识恢复出高分辨率图像。其中,最经典的是 Yang 等^[5]2010 年提出的基于稀疏编码的图像重建方法,将高/低分辨率图像进行分块,然后学习 LR 图像块与 HR 图像块之间的稀疏系数,最后利用 LR 图像稀疏系数与 HR 字典相乘得到重建的高分辨率图像。在 2013 年,Timofte 等^[6-7]在此基础上进一步研究,提出了锚定邻域回归的方法,改进了字典训练的方式,利用 K 奇异值分解(K-SVD)训练字典,采用最小二乘法获取高/低分辨率图像的映射模型。

近几年,Dong 等^[8-9]将卷积神经网络应用于超分辨率重建问题中,提出一种基于卷积神经网络的图像重建算法,构建了一种高效的端到端的映射模型,整个网络分为特征提取、非线性映射和重建三个过程,取得了一定的效果。Wang 等^[10]采用神经网络与稀疏编码相结合的方式重建。Shi 等^[11]利用 LR 特征提取特征映射并引入了一个有效的亚像素卷积层,学习一组尺度扩展滤波器,将最终的 LR 特征映射放大成 HR 特征。随后,浅层网络不能满足需求,Kim 等^[12-13]于 2016 年提出更深层次的卷积神经网络解决图像超分辨率问题,该方法将网络加深至 20 层,扩大了感受野,同时利用残差学习,有效提高了网络训练速度,后期进一步改进,采用递归监督策略,充分利用参数共享,降低参数数量。

随着机器学习迅猛发展,由生成模型 G 和判别模型 D 组成的生成对抗网络(GANs)成为众多学者研究的热点^[14],其原理是判别模型 D 监督判别生成模型 G 所生成的数据,二者进行博弈训练,不断竞争,达到以假乱真的效果。受 GAN 网络的启发,2017 年,Ledig 等^[15]将 GAN 网络运用到图像超分辨率重建中,主要解决当放大倍数升级时,精细准确地重建退化图像,网络模型中采用对抗性损失和内容损失作为新的感知损失函数,达到相对

精准的恢复效果。2019 年,文献[16]提出一种三维视频图像的生成对抗网络的重建算法,利用低分辨率彩色图像和低分辨率深度图像的相互信息,使它们在相同场景中的几何结构相似性彼此增强。杨晓莉等^[17]提出基于生成对抗网络的多模态图像融合算法,实现了多模态图端到端的自适应融合。

以上算法虽然取得一定的效果,但文献[8-9]算法在图像的重建细节方面还有待完善,文献[12-13]方法训练层数过多,导致参数数量较大,并且这些算法均是在输入网络之前就对 LR 图像进行放大处理,增加了训练耗时,在深层卷积过程中对图像块的边缘信息损失较大。针对以上缺陷,本文提出一种基于密集连接的生成对抗网络图像超分辨率重建算法。第一,在生成网络结构中:1)采用密集连接代替链式堆叠网络结构,将前面浅层网络的特征输送到网络结构的后端,将层与层互连即可最大程度实现特征的充分利用,避免图像特征的丢失,进而优化重建细节信息,采用 3 个密集连接模块,减少了卷积层数,降低了参数数量;2)在卷积过程中采用卷积核大小为 1×1 的卷积层进行填充,灵活的升维和降维,达到不改变特征块大小的目的,保留更有效的边缘信息;3)本文的最初输入是原始低分辨率图像,在网络的末端进行图像的反卷积操作,即图像的上采样处理,完成最终的图像重建,大大降低了训练耗时。第二,在判别网络结构中:采用 6 个卷积模块和 1 个全连接层对真伪图像进行甄别,与生成网络进行博弈抗衡,提升了重建图像的质量,改变了以上算法直接计算损失函数,获取了最优参数的做法。综上所述,本文研究方法在医疗卫生、军事、交通等领域具有深远的实际应用意义。

2 本文方法

2.1 总体架构

GAN 最早由 Goodfellow 等^[14]提出,利用零和博弈思想,估计目标分布,找到最小最大平衡点。在生成对抗网络模型中,生成模型 G 通过输入随机噪声生成输出,判别模型 D 将 G 的输出作为自身的输入并且与真实数据做对比,判定输入数据真伪,从而不断地调整参数,整个过程如图 1 所示。

用方程式表示为

$$\min_G \max_D V(D, G) = E_{x \sim p_{\text{Data}(x)}} \{ \lg [D(x)] \} + E_{z \sim p_{z(z)}} \{ \lg [1 - D(G(z))] \}, \quad (1)$$

式中: z 表示随机噪声; x 表示样本数据; $p_{\text{Data}(x)}$ 表示样本数据的分布概率; $p_{z(z)}$ 表示随机噪声的分布




图 1 GANs 结构示意图

Fig. 1 Structure diagram of GANs

概率; $V(D, G)$ 表示值函数; $E_{x \sim p_{\text{Data}(x)}}$ 和 $E_{z \sim p_z(z)}$ 分别表示样本数据和生成数据的期望。

整个网络的训练过程是首先固定生成器,去训练判别器,使其能够区分出数据真伪,然后再固定判别器,训练生成器,使其能够产生可以欺骗判别

器的输出,在这样的循环重复过程中,将网络不断优化。

2.2 构建生成网络模型

本文的生成网络模型结构如图 2 所示,主要分为特征提取、非线性映射和重建三个过程。

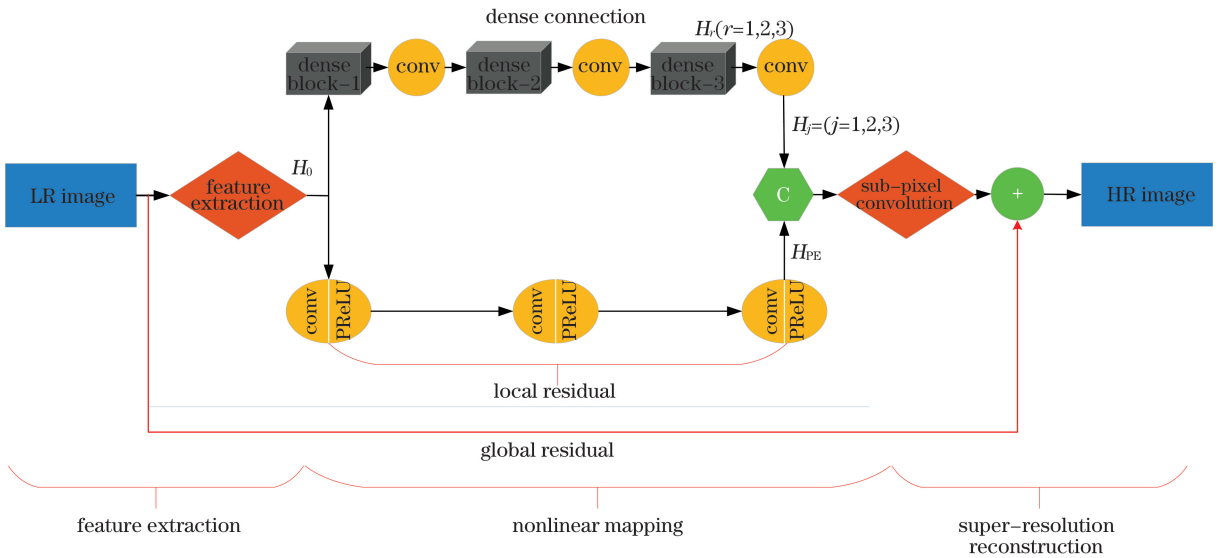


图 2 生成网络结构图

Fig. 2 Generate network structure diagram

1)特征提取。将原始的 LR 图像作为输入,采用单层卷积网络自适应地捕获图像特征,避免人工设计特征出现的特征不均匀、丢失等问题。假设提取出的浅层特征用 H_0 表示,具体操作表示为

$$H_0 = F(I_{LR}) = \varphi(0, W * I_{LR} + B), \quad (2)$$

式中: I_{LR} 表示输入的原始 LR 图像; $F(\cdot)$ 表示特征提取函数; $*$ 表示卷积操作; W 表示滤波器; B 表示偏置;本文中采用大小为 3×3 的卷积核,滤波器数量为 64; $\varphi(\cdot)$ 表示激活函数,由于 PReLU 比 ReLU 具有更好的修正性,故采用 PReLU 作为本文的激活函数。

2)非线性映射。主要分为两个子网络,一是由密集连接块和自适应特征选择层组成,主要解决随网络层数加深造成的图像特征丢失或不充分利用

问题。因为在深层网络中,要想联合所有层的特征十分困难。如果使用密集块的方式,将层与层进行互连就能最大程度上实现对特征的充分利用,在特征复用的基础上产生新的特征,进而丰富图像的特征,增强网络的表达能力。

本文设计的密集连接块如图 3 所示,包含 3 个权重层,1 个通道融合层,采用密集网络^[18]的连接方式。使得特征和梯度的传递更加有效,减少了梯度损失,相当于一种隐形的深度监督,有助于训练更深的网络。

假设输入特征为 H , 则第 i 个卷积层的输出特征 x_i 表示为

$$x_i = C_{3,32}([H, x_1, \dots, x_{i-1}]), \quad (3)$$

式中: $C_{3,32}$ 表示卷积层的卷积核大小为 3×3 , 数量

为 32; $[\cdot]$ 表示将各个卷积层特征按通道进行融合, 在特征复用的基础上探索新的图像特征, 即图中“C”标识的过程。本文密集块采用 3 个权重层, 所以最终的密集连接层输出特征 H_d 可表示为

$$H_d = [x_1, x_2, x_3]。 \quad (4)$$

采用的局部残差跳跃连接与 ResNet 稍有不同, 加入了卷积核大小为 1×1 的卷积层, 防止网络梯度消失, 则一个密集连接块的输出特征用 H_r 表示为

$$H_r = C_{1,128}(H) + H_d, \quad (5)$$

式中: $C_{1,128}$ 表示卷积层的卷积核大小为 1×1 , 数量为 128。




图 3 密集连接块结构图

Fig. 3 Structure of densely connected blocks

在每个密集连接块的后面紧跟的是特征选择层, 通过自适应学习选择有效的图像特征, 避免密集连接产生的特征冗余问题。对于输入特征 H_r , 其输出特征 H_j 可表示为

$$H_j = C_{1,32}(H_r), \quad (6)$$

式中: H_j 表示第 j 个密集块后特征选择层的输出, 本文中 $j = 1, 2, 3$; $C_{1,32}$ 表示卷积层的卷积核大小为 1×1 , 数量为 32。

非线性映射的第二条子网络是由卷积核大小为 1×1 , 数量为 64 的 3 个卷积层构成的跳层连接, 是一个局部残差过程, 浅层特征对重建效果的影响也十分明显, 因为高/低分辨率图像很多时候的差别很小, 采用这样的卷积操作, 更好地保留了大部分的低频特征, 避免受到邻域像素的干扰, 能更好地与重建出的高频特征进行融合。假设用 F_{PE} 表示该条子网络上的所有操作, 对于初始特征 H_0 , 则其最终输出的浅层特征 H_{PE} 为

$$H_{PE} = F_{PE}(H_0)。 \quad (7)$$

非线性映射部分的整体输出为

$$H_{fu} = F_{fu}(H_{PE} + H_j), \quad (8)$$

式中: H_{fu} 表示浅层特征和重建的高频细节融合后的输出特征; F_{fu} 表示融合函数。

3) 重建过程。采用亚像素卷积完成图像的重建, 将特征图的每个像素进行重新排列, 对应地生

成高分辨率图像的子区域, 这种在网络的末尾对图像进行上采样操作, 很大程度上减少了参数数量, 降低了训练耗时。若用 $F_{sub}(\cdot)$ 表示亚像素卷积过程, 则最终输出的重建图像 I_{SR} 可表示为

$$I_{SR} = F_{sub}(H_{fu}) + I_{LR}。 \quad (9)$$

2.3 构建判别网络模型

通常情况下, 生成网络输出重建出的 HR 图像后, 就会直接计算损失函数, 通过反向传播法更新网络参数值, 以获取最优参数值, 这种方法对于纹理细节不多的图像是能够满足需求的, 但是对于纹理较为丰富的退化图像, 其恢复效果一般, 所以本文训练出了对应的判别网络模型, 对真实的图像和生成的图像进行区分, 让生成网络和判别网络进行博弈, 在训练过程中不断提升二者的能力, 最终生成高质量的重建图像。

本文设计的判别网络模型由 6 个卷积模块组成, 如图 4 所示, 除了第一个卷积模块不包含批量归一化(BN)层, 剩余的每个模块均包含 3×3 的卷积层、BN 层和 PReLU 激活函数层。BN 层防止网络训练过程中梯度消失, 从而增强网络的稳定性; PReLU 激活函数层增强了网络的非线性, 丰富了图像特征, 其中系数 $\alpha = 0.2$ 。每个模块的特征图数量以成倍的方式逐渐递增, 与此同时, 采用微步幅卷积^[19]减小特征图尺寸, 避免了传统的池化操作引起的局部特征丢失问题。最后是一个全连接层, 将卷积层提取的特征进行组合分类, 本文引入 EM (Earth-Mover) 距离, 去掉了最后的 sigmoid 层, 将二分类问题转变成回归问题, 使网络模型更精确。

3 实验与分析

3.1 数据集处理

本文训练集包含 91 张文献[5]的训练图像和 200 幅伯克利分割数据集(BSD)训练图^[20], 其中 BSD 训练图包含了边缘信息丰富的图片, 能够增强训练效果。选取 Set5、Set14、B100 和 Urban100^[21]作为测试集, 其中, Set5、Set14 测试集是最经典最具代表性的图片, 分别是 5 张和 10 张, 包含人物、动物。增加 B100 和 Urban100 这两个测试集是因为其中包含了更多纹理复杂、边缘细节敏锐的图片, 将 4 种测试集全部进行测试, 让检测结果更具有代表性, 更能突出本文算法的有效性。为了进一步扩充训练集的数量, 借鉴文献[22]的策略, 对训练集图像进行 90° 、 180° 、 270° 旋转后再进行水平翻转操作, 使每一个训练集图像都有 8 个不同的版本, 大大




图4 判别网络模型

Fig. 4 Discriminant network model

扩充了训练集数量。

3.2 训练参数设置

因为人眼对亮度通道比较敏感,所以本文只对Y通道进行重建,Cb、Cr通道采用插值进行放大,训练集中包含了2倍、3倍、4倍图像块,所以对不同尺度的超分辨率重建仅需要训练单一网络结构。为了减小训练复杂度、节约时间,将图像块裁剪为 27×27 ,步长设为14,学习率设为 10^{-3} 。当损失函数最小化时,学习率变为 10^{-4} 。采用PReLU作为激活函数,系数 $\alpha = 0.2$,判别网络模型由6个卷积模块组成,网络中滤波器大小为 3×3 ,具体数量在生成网络结构和判别网络结构中已经标出。为了在卷积过程中不改变图像块尺寸的大小,进行 1×1 填充,以确保保留图像块的边缘信息。

3.3 实验分析

为了更有效地证明本文算法的效果,与文献[23]、文献[5]、文献[7]、文献[8]、文献[13]、文献[16]等6种主流算法做对比,其中,文献[23]算法是传统的超分辨率重建技术,即双三次插值算法,但插值方法只是将原始像素点进行简单组合,并不能增加图像的细节信息。文献[5]提出的是一种稀疏编码算法,邻域嵌入的图像块的提取和聚合放在预处理和后处理阶段分别进行。文献[7]提出基于锚定邻域回归(ANR)的图像重建算法,学习稀疏字典和固定在字典原子上的锚定回归量。文献[8]算法是一种三层的超分辨率卷积神经网络(SRCNN),直接学习低分辨率图像和高分辨率图像之间的端到端映射关系。文献[13]是在文献[8]基础上的改进,采取深度卷积网络,参数数量也增加了很多。文献[16]提出一种基于生成对抗网络的重建方法,利用低分辨率彩色图像和低分辨率深度图像的相互信息,使它们在相同场景中的几何结构相似性可以彼此增强。而本文算法采用了最前沿的生成对抗网络训练网络,在重建细节上更突出,并结合密

集连接技术和亚像素卷积,在参数数量和时间上具有突出优势,取得了比其他算法更突出的效果。下面分别从视觉效果、客观数据、参数数量、边缘信息保留度和运行时间等5个方面做出对比分析。

1) 视觉效果对比

由于篇幅原因,选取其中的4幅图作为展示,突出人眼视觉效果。图5~8分别为不同算法在放大3倍时的重建效果,对于butterfly图像来说,本文算法重建出的翅膀脉络更为清晰、真实,而其他算法的效果不够锐利,边缘不够清晰,损失的纹理细节较多。对于lenna图,帽子的边缘进行了放大,可以看出,其他几种算法都有锯齿现象,而本文算法能够做到较为光滑,与原图更为接近。对于253027斑马和barbara图亦是如此,可以看出本文算法的优越性和有效性。

2) 峰值信噪比(PSNR)和结构相似性(SSIM)对比

为了更为客观地分析效果,将本文算法的PSNR值和SSIM值与主流的经典算法相对比,如




图5 butterfly重建效果展示。(a)原图;(b)文献[23]方法;(c)文献[5]方法;(d)文献[7]方法;(e)文献[8]方法;(f)文献[13]方法;(g)文献[16]方法;(h)本文方法

Fig. 5 Comparison of butterfly reconstruction effect. (a) Original image; (b) method in Ref. [23]; (c) method in Ref. [5]; (d) method in Ref. [7]; (e) method in Ref. [8]; (f) method in Ref. [13]; (g) method in Ref. [16]; (h) proposed method




图6 lenna重建效果展示。(a)原图;(b)文献[23]方法;(c)文献[5]方法;(d)文献[7]方法;(e)文献[8]方法;(f)文献[13]方法;(g)文献[16]方法;(h)本文方法

Fig. 6 Comparison of lenna reconstruction effect. (a) Original image; (b) method in Ref. [23]; (c) method in Ref. [5]; (d) method in Ref. [7]; (e) method in Ref. [8]; (f) method in Ref. [13]; (g) method in Ref. [16]; (h) proposed method




图7 253027重建效果展示。(a)原图;(b)文献[23]方法;(c)文献[5]方法;(d)文献[7]方法;(e)文献[8]方法;(f)文献[13]方法;(g)文献[16]方法;(h)本文方法

Fig. 7 Comparison of 253027 reconstruction effect. (a) Original image; (b) method in Ref. [23]; (c) method in Ref. [5]; (d) method in Ref. [7]; (e) method in Ref. [8]; (f) method in Ref. [13]; (g) method in Ref. [16]; (h) proposed method

表1 本文算法与主流算法在4种测试集上的PSNR值比较

Table 1 Comparison of PSNR between proposed algorithm and mainstream algorithm on four test sets unit: dB

Dataset	Scale	Method in Ref. [23]	Method in Ref. [5]	Method in Ref. [7]	Method in Ref. [8]	Method in Ref. [13]	Method in Ref. [16]	Proposed method
Set5	2	33.57		36.61	36.72	37.44	37.71	37.93
	3	30.42	31.39	31.99	32.85	33.45	33.90	34.11
	4	29.00		30.27	30.56	31.12	31.62	31.79
Set14	2	30.24		32.28	32.45	33.03	33.23	33.44
	3	27.55	28.31	29.13	29.30	29.77	29.92	30.08
	4	26.00		27.32	27.50	28.01	28.14	28.35
B100	2	29.49		30.97	31.45	31.57	31.90	32.13
	3	27.11	27.83	28.10	28.38	28.96	29.01	29.30
	4	25.88		26.79	26.96	27.22	27.38	27.57
Urban100	2	26.76		28.94	29.49	30.69	30.85	30.97
	3	24.59	25.35	26.01	26.33	27.23	27.44	27.58
	4	23.30		24.45	24.65	25.09	25.36	25.63



图8 barbara重建效果展示。(a)原图;(b)文献[23]方法;(c)文献[5]方法;(d)文献[7]方法;(e)文献[8]方法;(f)文献[13]方法;(g)文献[16]方法;(h)本文方法

Fig. 8 Comparison of barbara reconstruction effect. (a) Original image; (b) method in Ref. [23]; (c) method in Ref. [5]; (d) method in Ref. [7]; (e) method in Ref. [8]; (f) method in Ref. [13]; (g) method in Ref. [16]; (h) proposed method

表1和表2所示,对测试集 set5、set14、B100、Urban100 分别在 $\times 2$ 、 $\times 3$ 、 $\times 4$ 因子下进行展示对比。从表1可以看出,相比最原始的文献[23]算法,本文算法的PSNR值平均高出3.75 dB,相比文献[5]、文献[7]、文献[8]算法,约高出2.97 dB、2.10 dB、1.48 dB,与深层网络文献[13]算法相比,约高出0.27 dB,与生成对抗网络文献[16]算法相比,约高出0.2 dB。从表2可以看出,本文算法在SSIM值上更具有优越性,相比文献[23]、文献[5]、文献[7]、文献[8]、文献[13]、文献[16]算法,分别高出0.0784、0.0379、0.0253、0.0149、0.0028、0.0013。综上所述,大部分数据表明本文算法比其他算法更具优越性。

表2 本文算法与主流算法在4种测试集上的SSIM值比较

Table 2 Comparison of SSIM between proposed algorithm and mainstream algorithm on four test sets

Dataset	Scale	Method in Ref. [23]	Method in Ref. [5]	Method in Ref. [7]	Method in Ref. [8]	Method in Ref. [13]	Method in Ref. [16]	Proposed method
Set5	2	0.9293		0.9500	0.9539	0.9576	0.9577	0.9603
	3	0.8671	0.8819	0.9003	0.9088	0.9209	0.9228	0.9239
	4	0.8115		0.8622	0.8630	0.8839	0.8871	0.8877
Set14	2	0.8679		0.9070	0.9057	0.9130	0.9131	0.9143
	3	0.7738	0.7937	0.8177	0.8209	0.8325	0.8329	0.8326
	4	0.7026		0.7487	0.7521	0.7669	0.7678	0.7687
B100	2	0.8429		0.8854	0.8880	0.8955	0.8958	0.8993
	3	0.7383	0.7458	0.7844	0.7857	0.7968	0.7981	0.7994
	4	0.6680		0.7069	0.7100	0.7247	0.7266	0.7280
Urban100	2	0.8411		0.8922	0.8951	0.9135	0.9150	0.9164
	3	0.7338	0.7554	0.7908	0.7976	0.8266	0.8246	0.8299
	4	0.6567		0.7183	0.7233	0.7509	0.7537	0.7551

3) 参数数量对比

为了证明本文算法在网络的最后采用亚像素卷积操作能够减少参数数量,以测试集 set5 为例,在3倍放大因子下,将本文算法的参数数量分别与文献[5]、文献[7]、文献[8]、文献[13]、文献[16]等主流算法的参数数量进行了对比,如图9所示,横坐标表示参数数量,纵坐标表示PSNR值。深层网络文献[13]、文献[16]均是在网络输入之前对低分辨率图像进行放大处理,对比发现,本文算法的参数数量明显减少很多,虽然比浅层网络文献[5]、文献[7]、文献[8]算法的参数数量要多,但本文算法的PSNR值更高,重建效果更佳,所以综合来看,本文算法更具有研究价值。

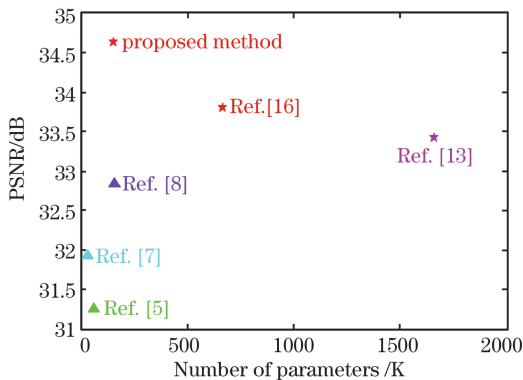



图9 参数数量对比

Fig. 9 Comparison of the number of parameters

4) 边缘信息对比

图像的边缘是图像属性区域和另一个属性区域的交接处,是区域属性发生突变的地方,包含着丰富的信息,并且不确定性最大,所以图像的边缘

在重建过程中至关重要。本文通过 1×1 卷积操作,使网络根据需要能够更灵活地控制数据的通道数,有效地实现升维和降维,提高了网络的非线性表达能力,更精准地恢复边缘信息。为了能够更清楚地分辨出使用 1×1 卷积操作前后的区别,采用sobel算子分别提取了使用 1×1 卷积操作前后的图像边缘信息进行对比,结果如图10所示。其中,图10(a)~(c)分别表示图像“lenna”、“butterfly”、“253027”使用 1×1 卷积操作后的图像边缘信息提取效果,而图10(d)~(f)分别表示与之对应的未进行 1×1 卷积操作的图像边缘信息提取效果。经对比可以看出,图10(a)~(c)中边缘连续性较好,在光线明暗的交界区域也能保持清晰的边缘,能够精确定位真实边缘,降低噪声引起的伪边缘。而图

图10 1×1 卷积操作前后的图像边缘信息提取对比。

(a)~(c)卷积操作后的图像;(d)~(f)对应的卷积操作前的图像

Fig. 10 Comparison of image edge extraction before and after convolution operation. (a)~(c) Images after convolution operation; (d)~(f) corresponding images before convolution operation

10(d)~(f)中存在边缘伪迹,边缘信息“肥胖”、不清晰,提供的基本信息有较大误差,在细微的背景边缘处会连成“片”状。所以 1×1 卷积能够更好地保留边缘信息,对重建效果有帮助。

5) 运行时间对比

除此之外,对不同算法的测试耗时进行统计对比,如表3所示。相比文献[5]、文献[6]、文献[8]算法,本文算法的耗时有了较为明显的改善;相比文

献[13]算法和文献[16]算法,本文算法的耗时约降低了0.11 s和0.2 s,虽然不是很大幅度的改善,但这是经历多次实验,在确保提高质量的情况下完成的最优的耗时结果。总体来看,本文算法在人类视觉效果评估、PSNR值、SSIM值、参数数量以及耗时等多方面指标上都有了很大的改善,包含了更多的边缘细节,丰富了图像信息,表现出了较好的鲁棒性和综合特性。

表3 本文算法与主流算法在4种测试集上的耗时对比表

Table 3 Comparison of time consumption between proposed algorithm and mainstream algorithms on four test sets

Dataset	Scale	Method in Ref. [23]	Method in Ref. [5]	Method in Ref. [7]	Method in Ref. [8]	Method in Ref. [13]	Method in Ref. [16]	Proposed method
Set5	2	—		0.58	2.19	0.13	0.21	0.11
	3	—	0.47	0.32	2.23	0.14	0.19	0.13
	4	—		0.24	2.19	0.12	0.22	0.12
Set14	2	—		0.84	4.32	0.25	0.27	0.22
	3	—	0.51	0.56	4.40	0.26	0.23	0.21
	4	—		0.38	4.39	0.25	0.21	0.20
B100	2	—		0.59	2.51	0.16	0.30	0.13
	3	—	0.52	0.33	2.58	0.21	0.27	0.17
	4	—		0.26	2.51	0.21	0.25	0.15
Urban100	2	—		2.96	22.12	0.98	1.01	0.91
	3	—	0.69	1.67	19.35	1.08	1.00	0.98
	4	—		1.21	18.46	1.06	1.03	1.02

4 结 论

本文提出一种基于密集连接的生成对抗网络图像超分辨率重建算法,采用生成网络和判别网络对抗博弈的训练思想,解决了目前算法存在的图像特征丢失、边缘细节信息恢复不完整的问题。其中,在生成网络结构中:1)采用密集连接,将前面浅层网络的特征输送到网络结构的后端,将层与层进行互连就能最大程度上实现对特征的充分利用,避免图像特征的丢失;2)在卷积过程中采用卷积核大小为 1×1 的卷积层进行填充,达到不改变特征块大小的目的,保留更有效的边缘信息;3)在网络中输入最初的低分辨率图像进行训练,而在输出的末端,采用亚像素卷积进行像素的重新排列,对图像进行放大倍数处理,完成最终的图像重建,这种将放大倍数放到最后操作的策略,会大大降低训练耗时。在判别网络结构中:采用6个卷积模块和1个全连接层对真伪图像进行甄别,与生成网络进行博弈抗衡,直到判别网络不能区分出真伪,进而输出最终的重建图像。实验结果表明,本文算法在视觉

效果评估、PSNR值、SSIM值以及耗时等多方面指标上都有了很大的改善,包含了更多的边缘细节,丰富了图像信息,表现出了较好的鲁棒性和综合特性。

参 考 文 献

- [1] Shi Z T, Wang Z R, Wang R, et al. Single image super-resolution based on convolutional neural network [J]. Laser & Optoelectronics Progress, 2018, 55(12): 121001.
史紫腾, 王知人, 王瑞, 等. 基于卷积神经网络的单幅图像超分辨[J]. 激光与光电子学进展, 2018, 55(12): 121001.
- [2] Zhang L, Wu X L. An edge-guided image interpolation algorithm via directional filtering and data fusion [J]. IEEE Transactions on Image Processing, 2006, 15(8): 2226-2238.
- [3] Dai S Y, Han M, Xu W, et al. SoftCuts: a soft edge smoothness prior for color image super-resolution [J]. IEEE Transactions on Image Processing, 2009, 18(5): 969-981.
- [4] Hu S Y, Wang G D, Zhao Y, et al. Image super-

- resolution network based on dense connection and squeeze module [J]. *Laser & Optoelectronics Progress*, 2019, 56(20): 201005.
- 胡诗语, 王国栋, 赵毅, 等. 基于密集连接与激励模块的图像超分辨率网络[J]. *激光与光电子学进展*, 2019, 56(20): 201005.
- [5] Yang J C, Wright J, Huang T S, et al. Image super-resolution via sparse representation [J]. *IEEE Transactions on Image Processing*, 2010, 19(11): 2861-2873.
- [6] Timofte R, De V, Van L. Anchored neighborhood regression for fast example-based super-resolution [C]//2013 IEEE International Conference on Computer Vision, December 1-8, 2013, Sydney, NSW, Australia. New York: IEEE Press, 2013: 1920-1927.
- [7] Timofte R, de Smet V, van Gool L. A+: adjusted anchored neighborhood regression for fast super-resolution [M]//Computer Vision-ACCV 2014. Cham: Springer International Publishing, 2015: 111-126.
- [8] Dong C, Loy C C, He K M, et al. Learning a deep convolutional network for image super-resolution[J]. *Computer Vision-ECCV 2014*, 2014, 8692:184-199.
- [9] Dong C, Loy C C, He K M, et al. Image super-resolution using deep convolutional networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(2): 295-307.
- [10] Wang Z W, Liu D, Yang J C, et al. Deep networks for image super-resolution with sparse prior [C]//2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 370-378.
- [11] Shi W Z, Caballero J, Huszár F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 1874-1883.
- [12] Kim J, Lee J K, Lee K M. Accurate image super-resolution using very deep convolutional networks [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 1646-1654.
- [13] Kim J, Lee J K, Lee K M. Deeply-recursive convolutional network for image super-resolution [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 1637-1645.
- [14] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[EB/OL]. (2014-06-10) [2020-02-14]. <https://arxiv.org/abs/1406.2661>.
- [15] Ledig C, Theis L, Huszár F, et al. Photo-realistic single image super-resolution using a generative adversarial network [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 105-114.
- [16] Zhao L J, Bai H H, Liang J, et al. Simultaneous color-depth super-resolution with conditional generative adversarial networks [J]. *Pattern Recognition*, 2019, 88: 356-369.
- [17] Yang X L, Lin S Z, Lu X F, et al. Multimodal image fusion based on generative adversarial networks [J]. *Laser & Optoelectronics Progress*, 2019, 56(16): 161004.
- 杨晓莉, 蔺素珍, 禄晓飞, 等. 基于生成对抗网络的多模态图像融合[J]. *激光与光电子学进展*, 2019, 56(16): 161004.
- [18] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks [EB/OL]. (2018-01-28) [2020-02-14]. <https://arxiv.org/abs/1608.06993>.
- [19] Huang K B, Hu R M, Jiang J J, et al. Face image super-resolution through improved neighbor embedding [M]//Multimedia Modeling. Cham: Springer International Publishing, 2016: 409-420.
- [20] Martin D, Fowlkes C, Tal D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics [J]. *Proceedings Eighth IEEE International Conference on Computer Vision. ICCV 2001*, 2001, 2: 416-423.
- [21] Huang J B, Singh A, Ahuja N. Single image super-resolution from transformed self-exemplars [C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 5197-5206.
- [22] Tai Y, Yang J, Liu X M. Image super-resolution via deep recursive residual network [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2790-2798.
- [23] de Boor C. Bicubic spline interpolation[J]. *Journal of Mathematics & Physics*, 1962, 41(1):212-218.