

图文信息技术

基于生成对抗网络的压缩感知图像重构方法

简献忠¹, 张雨墨¹, 王如志²

(1.上海理工大学, 上海 200093; 2.北京工业大学, 北京 100124)

摘要: **目的** 为了解决传统压缩感知图像重构方法存在的重构时间长、重构图像质量不高等问题, 提出一种基于生成对抗网络的压缩感知图像重构方法。**方法** 基于生成对抗网络思想设计一种由具有稀疏采样功能的鉴别器和具有图像重构功能的生成器组成的深度学习网络模型, 利用对抗损失和重构损失 2 个部分组成的新的损失函数对网络参数进行优化, 完成图像压缩重构过程。**结果** 实验表明, 文中方法在 12.5% 的低采样率下重构时间为 0.009 s, 相较于常用的 OMP 算法、CoSaMP 算法、SP 算法和 IRLS 算法, 其峰值信噪比 (PSNR) 提高了 10~12 dB。**结论** 文中设计的方法应用于图像重构时重构时间短, 在低采样率下仍能获得高质量的重构效果。

关键词: 压缩感知; 生成对抗网络; 图像重构; 深度学习

中图分类号: TP391 **文献标识码:** A **文章编号:** 1001-3563(2020)11-0239-07

DOI: 10.19554/j.cnki.1001-3563.2020.11.035

Compressed Sensing Image Reconstruction Method Based on Generative Adversarial Network

JIAN Xian-zhong¹, ZHANG Yu-mo¹, WANG Ru-zhi²

(1.University of Shanghai for Science and Technology, Shanghai 200093, China;

2.Beijing University of Technology, Beijing 100124, China)

ABSTRACT: The work aims to propose a reconstruction method of compressed sensing image based on generative adversarial network, in order to solve the problems of long reconstruction time and low quality of reconstructed image by traditional compressed sensing image reconstruction method. Based on the idea of generative adversarial network, a deep learning network model composed of discriminator with sparse sampling function and generator with image reconstruction function was designed. The new loss function composed of adversarial loss and reconstruction loss was used to optimize the network parameters and complete the process of image compression and reconstruction. Experiments showed that the reconstruction time required by the proposed method was 0.009 s at a low sampling rate of 12.5%, and the Peak Signal to Noise Ratio (PSNR) was 10-12 dB higher than that of the commonly used OMP algorithm, CoSaMP algorithm, SP algorithm and IRLS algorithm. When applied to image reconstruction, the proposed method require less reconstruction time and can still achieve a high-quality reconstruction effect at a low sampling rate.

KEY WORDS: compressed sensing; generative adversarial network; image reconstruction; deep learning

随着近年来机器视觉的发展,大量图像数据的存储和传输带来了不小的问题。传统的奈奎斯特采样理论要求采样率要高于原信号最高频率的 2 倍以上,然

后对所获数据采用压缩、编码方式进行传输处理,这样做会带来很大程度的资源浪费。压缩感知 (CS) 理论可以突破奈奎斯特理论的限制,用较低的采样速

收稿日期: 2019-10-30

基金项目: 国家自然科学基金 (11774017)

作者简介: 简献忠 (1969—), 男, 博士, 上海理工大学教授, 主要研究方向为图像处理、嵌入式系统、电力系统优化。

率对信号进行采样,同时重建算法可以从较少的压缩测量值中重建原始信号,压缩感知理论的出现不仅降低了对信号采集设备的要求,同时也节省了大量的信道资源和储存空间。目前,基于压缩感知理论的图像重建技术已经被应用到雷达成像、医学图像、遥感图像等领域^[1]。

压缩感知技术由 3 步组成:信号的稀疏表示、观测矩阵的设计和信号的重构算法,其中重构算法是压缩感知技术的核心。传统的压缩感知图像重构方法研究也多是 对重构算法进行改进,最先使用的是匹配追踪(MP)算法;在 MP 算法的基础上使用最小二乘法更新原子集合,提出了正交匹配追踪(OMP)算法;引入回溯思想后,将当前支撑集与前一次支撑集合并选出最优解,提出了压缩采样匹配追踪(CoSaMP)算法等。国内的研究多是对上述经典算法进行改进,杜秀丽等^[2]提出了一种基于行间支撑集相似度的压缩采样匹配追踪算法(SSLCoSaMP);李琪等^[3]提出了一种基于阈值控制的稀疏度自适应匹配追踪(T-SAMP)算法;赵辉等^[4]设计了一种基于图像非局部低秩(NLR)和加权全变分(WTV)的图像重构算法。由于传统算法中的稀疏表示、观测矩阵和重构算法均需人为设计构造,无法完全捕获信号中的有用信息,导致生成的图像质量较差;重构算法均通过迭代运算,图像重构时间较长,无法满足实时性要求。

近年来深度学习技术获得了迅速的发展,尤其是生成对抗网络(generative adversarial network, GAN)的出现,因其具有强大的特征提取和拟合估计能力,该网络一经提出就成为热点研究方向,其在图像处理领域获得了大量应用,如:图像合成^[5]、图像超分辨率^[6]、图像转换^[7]等。生成对抗网络尚未应用在压缩感知图像重构领域,于是文中提出一种基于生成对抗网络的压缩感知图像重构方法用来解决传统图像压缩重构中存在的问题。利用生成对抗网络对图像特征提取和拟合估计的能力,设计一种由具有稀疏采样功能的鉴别器和具有图像重构功能的生成器组成的深度学习网络模型,免去人为设计采样矩阵和重构算法带来的信息丢失问题,从而提升图像重构质量,减少图像重构时间,并且训练后的生成器和鉴别器可在不同设备上单独使用,满足压缩感知所需的图像采集设备与图像恢复设备间压缩数据传输的应用场景,使压缩感知重构图像的实时实现成为可能。

1 理论基础

1.1 压缩感知理论

Donoho 等^[8-10]于 2006 年提出压缩感知(CS)理论,理论指出,假设一个 N 维信号 $x \in R^N$ 是可压缩

的,则其在标准正交基 $\Psi \in R^{N \times N}$ 下可稀疏表示为:

$$x = \Psi\theta \tag{1}$$

式中: θ 为信号 x 在变换域 Ψ 下的稀疏表示,且仅有 $K \ll N$ 个非零元素。如果给出 $M \times N$ 测量矩阵 Φ ($M < N$),则对信号 x 进行投影观测:

$$y = \Phi x \tag{2}$$

式中: y 为 $M \times 1$ 维观测向量。由式(1—2)可知,投影观测过程可表示为:

$$y = \Phi x = \Phi\Psi\theta = A\theta \tag{3}$$

式中: A 为观测矩阵,且感知矩阵 A 要满足受限等距性准则(RIP)^[11]。最后对于信号重构的问题,通过分析可知,如果可得到信号的稀疏表示 θ ,就可以恢复原始信号 x ,因此信号重构问题简化为在观测矩阵 A 和测量向量 y 已知的条件下,求方程组 $y=A\theta$ 最稀疏解的问题:

$$\min \theta_0, \text{条件} y = A\theta \tag{4}$$

信号重构问题转化为求解式(4)^[12],压缩感知理论的实现方式见图 1。

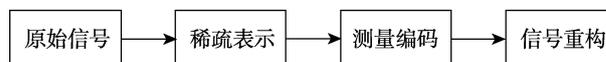


图 1 压缩感知理论框架

Fig.1 Theoretical framework of compressed sensing

1.2 生成对抗网络

生成对抗网络(GAN)是由 Goodfellow^[13]提出的一种强大的深度学习方法,GAN 受博弈论中零和博弈的启发,GAN 中的 2 个网络之间不断进行竞争、优化,从而达到一个纳什均衡(Nash equilibrium)状态。GAN 通常由 2 个网络构成,一个被称为生成器(G),另一个被称为鉴别器(D)。其中生成器(G)用随机噪声作为输入并生成样本数据,并将生成的样本数据提供给鉴别器(D);鉴别器(D)用真实数据或生成器(G)生成的样本数据为输入,并对输入的数据是真实数据还是样本数据进行判断^[14]。鉴别器(D)将判断结果反馈给这 2 个网络,各自改进网络参数,提高生成能力和判断能力。经过不断训练优化,最终达到纳什均衡状态,生成器(G)生成的数据和真实数据十分接近,鉴别器(D)判断不出生成数据和真实数据间的差别。

2 算法设计

2.1 网络结构设计

文中受到生成对抗网络思想的启发,并结合压缩感知理论,利用生成对抗网络强大的特征提取能力和拟合估计能力,创新性地 将生成对抗网络中的鉴别器(D)作为一个编码器(encoder)用于提取图像中的

重要特征作为稀疏采样过程，并使用生成器 (G) 作为一个解码器 (decoder) 对压缩过的信号进行拟合估计生成图像作为重构过程。

文中设计的网络结构使用带步长的卷积层或反卷积层替代常用的卷积层和池化层的组合来进行下采样和上采样过程，在鉴别器中通过多个卷积层进行卷积操作可以将图像中的特征逐步提取出来，这与压缩感知理论中的稀疏采样过程极为相似；同时在生成器中通过反卷积操作将压缩过的信号生成图像，这一过程即完成了对图像的重构。并且文中使用的生成对抗网络由一个卷积网络和一个反卷积网络组成，在完成模型训练后即可将模型拆分为稀疏采样模块和图像重构模块，将其分别部署在图像采集设备和图像恢复设备中，满足实际工程需要。

文中网络结构的可视化模型见图 2，由卷积层 (Conv)、反卷积层 (Deconv)、批量规范化层 (BN) 和全连接层 (FC) 构成。其中 x 是输入鉴别器 (D) 的原始图像， $D'(x)$ 是经过鉴别器 (D) 稀疏采样后的信号， z 是输入生成器 (G) 的随机噪声，经过 Deconv

5 生成的图像即为重构图像。通过调整网络结构中的参数，进而改变经稀疏采样后的信号 $D'(x)$ 的大小，即可改变压缩比。网络结构中的鉴别器与生成器在实际应用时可分别在图像采集设备和图像恢复设备中使用，可实现图像数据压缩传输，降低设备功耗。

在鉴别器中输入图像大小为 100×100 像素，通道数为 3。每层的构成如下：卷积 (Conv 1) 使用 256 个 3×3 滤波器，步长为 2；卷积 (Conv 2) 使用 128 个 5×5 滤波器，步长为 2；卷积 (Conv 3) 使用 64 个 3×3 滤波器，步长为 2；卷积 (Conv 4) 使用 32 个 5×5 滤波器，步长为 2；然后对卷积 (Conv 4) 输出的数据整形，将其变形为 1×8192 大小的一维数组，即为经过稀疏采样后的信号 $D'(x)$ ；最后再对进行全连接操作。

在生成器中输入的是信号 $D'(x)$ 或随机噪声，先对其进行整形操作方便后续卷积运算，其整形为 $16 \times 16 \times 32$ 的数组，其后每层构成如下：反卷积 (Deconv 1) 使用 32 个 3×3 滤波器，步长为 2；反卷积 (Deconv 2) 使用 64 个 5×5 滤波器，步长为 2；反

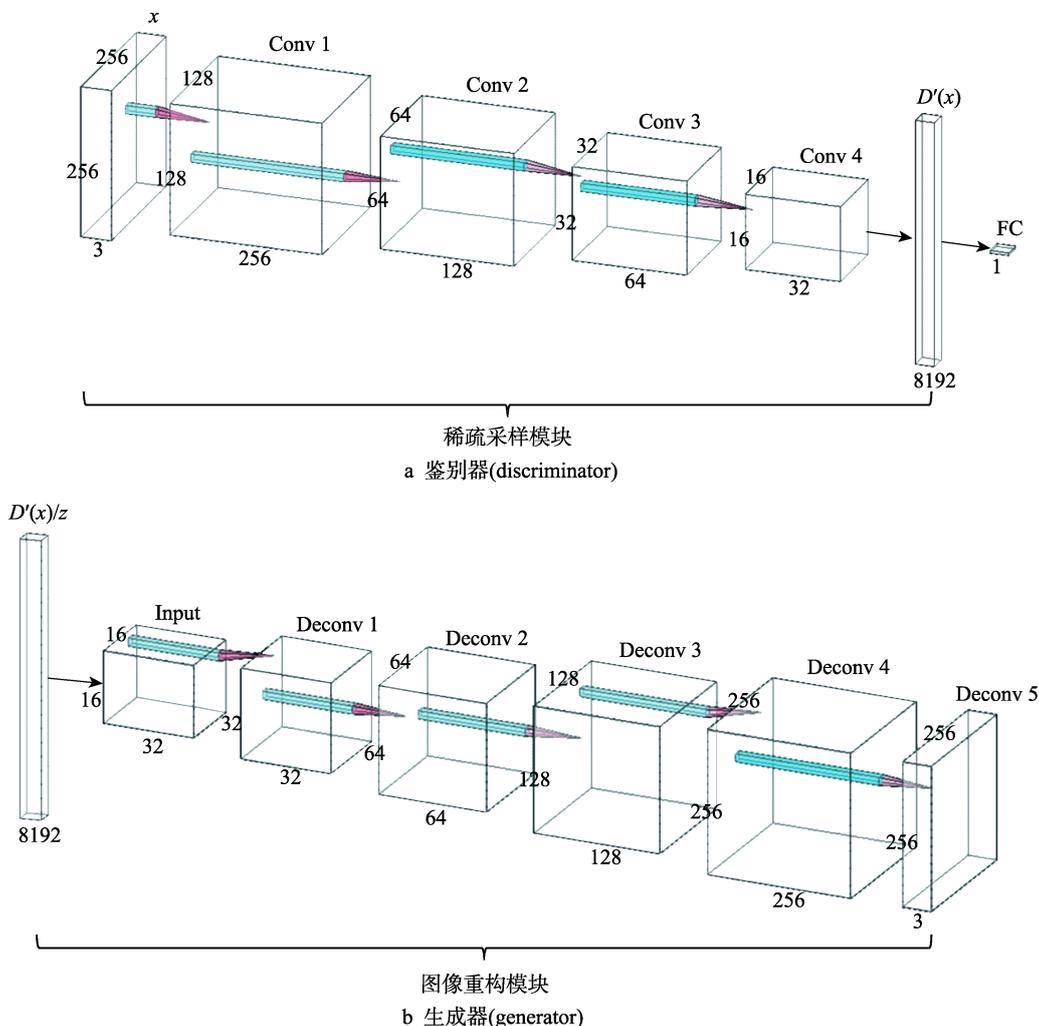


图 2 网络结构

Fig.2 Network structure

卷积 (Deconv 3) 使用 128 个 3×3 滤波器, 步长为 2; 反卷积 (Deconv 4) 使用 256 个 5×5 滤波器, 步长为 2; 反卷积 (Deconv 5) 使用 3 个 3×3 滤波器, 步长为 1, 其输出图像即为经过重构后的图像。

文中网络结构中鉴别器的激活函数均设置为 LeakyRelu, 生成器的激活函数均设置为 Relu, 并在鉴别器和生成器中加入批量规范化层 (BN), 使得每层的输入数据标准化, 用于缓解模型崩溃问题^[15]。同时在网络中交叉使用 5×5 和 3×3 这 2 种大小的滤波器, 目的是为了捕获更多的图像特征, 这样做可以分别获得图像中较为明显的特征和细节中的特征, 增强了模型的特征提取能力。具体结构参数见表 1 和表 2。

2.2 损失函数设计

在模型训练阶段, 需要构建损失函数用于评估网络输出结果与实际值的差异, 在训练过程中损失函数值会逐渐变小并趋于稳定, 当损失函数在 3 次迭代训练内不再变小, 即可认为模型训练完毕。文中使用的损失函数由对抗损失和重构损失等部分构成。对抗损失由生成器 (G) 损失函数 L_G 和鉴别器 (D) 损失函数 L_D 构成:

$$L_G = -E_{z \sim p_z} [\log(D(G(z)))] \quad (5)$$

$$L_D = -E_{x \sim p_x} [\log(D(x))] - E_{z \sim p_z} [\log(1 - D(G(z)))] \quad (6)$$

式中: z 为随机噪声; x 为输入的原始图像; $G(z)$ 为生成器根据随机噪声生成的图像; $D(G(z))$ 为鉴别器

对 $G(z)$ 的判别结果; $D(x)$ 为鉴别器对 x 的判别结果; $D'(x)$ 为经稀疏采样后的信号。

重构损失主要用来训练生成器对压缩后的信号进行重构的能力, 通过与输入图像不断对比, 提高重构图像质量, 增强训练稳定性:

$$L_R = E_{x \sim p_x} [\|G(D'(x)) - x\|_2^2] \quad (7)$$

式中: $G(D'(x))$ 为生成器根据稀疏采样后的信号生成的图像, 文中所用生成器 (G) 损失函数 L_{TG} 和鉴别器 (D) 损失函数 L_{TD} 为:

$$L_{TG} = L_G + \lambda L_R \quad (8)$$

$$L_{TD} = L_D + \lambda L_R \quad (9)$$

式中: 参数 $\lambda=5$ 。在图 3 的数据流程中直观地展示了损失函数的数据流向。

3 实验结果与分析

3.1 实验环境

文中实验基于 Windows 10 操作系统, 配置有 3.20 GHz 主频、16 GB 内存的 Intel i7-8700 CPU, 和 12 GB 显存的 NVIDIA GeForce GTX 1080Ti GPU, 使用开源的深度学习框架 TensorFlow。使用 Adam 优化器^[16]对损失函数进行优化, 动量参数 $\beta_1=0.9$, $\beta_2=0.99$, 学习率采用自适应学习率, 随着迭代次数的增加, 学习率逐渐减小。文中从 ImageNet 数据集中随机选取了 8000 张图片作为训练集, 并将图片缩放到 256×256

表 1 鉴别器结构参数

Tab.1 Structural parameters of discriminator

层 (Layer Type)	核尺寸 (Kernel)	步长 (Stride)	尺寸 (Dimensions)	通道 (Channels)
Input	—	—	256×256	3
Conv 1	3×3	2×2	128×128	256
Conv 2	5×5	2×2	64×64	128
Conv 3	3×3	2×2	32×32	64
Conv 4	5×5	2×2	16×16	32
FC	—	—	1×1	1

表 2 生成器结构参数

Tab.2 Structural parameters of generator

层 (Layer Type)	核尺寸 (Kernel)	步长 (Stride)	尺寸 (Dimensions)	通道 (Channels)
Input	—	—	16×16	32
Deconv 1	3×3	2×2	32×32	32
Deconv 2	5×5	2×2	64×64	64
Deconv 3	3×3	2×2	128×128	128
Deconv 4	5×5	2×2	256×256	256
Deconv 5	3×3	1×1	256×256	3

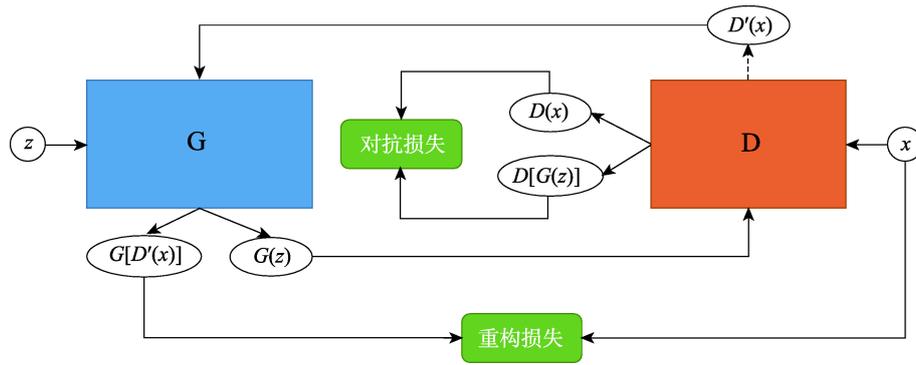


图 3 数据流程
Fig.3 Data flow

像素大小，从训练集中随机选择 64 幅图像作为一个批次，对网络模型进行 400 000 次迭代训练。

3.2 评价指标

为了客观评价各种图像重构算法的效果，文中选取峰值信噪比 (PSNR) 和均方根误差 (RMSE) 作为评价指标。峰值信噪比 (PSNR) 是信号的最大输出功率与噪声的输出功率的比值，其单位为分贝 (dB)。PSNR 越大，则重构失真度越小，其定义为：

$$PSNR = 10 \lg \frac{255^2}{\frac{1}{N} \sum_{j=1}^N [x(j) - x(\hat{j})]^2} \quad (10)$$

均方根误差 (RMSE) 是用来衡量观测值与真实值之间的差距，RMSE 越小，说明重构图像与原图像越接近，其定义为：

$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N [x(j) - x(\hat{j})]^2} \quad (11)$$

3.3 实验结果

为了对文中提出的基于生成对抗网络的压缩感知图像重构方法进行验证，并与目前常用的压缩感知图像重构方法进行对比，重构方法包括：基于离散小波变换 (DWT) 的 OMP 算法^[17]、CoSaMP 算法^[18]、SP 算法^[19]和 IRLS 算法^[20]。文中进行了 2 种情况下的仿真实验：不同采样率下使用相同图像 (Lena)；相同采样率 (12.5%) 下使用不同图像。

5 种不同算法的重构效果见图 4 和图 5，记录图 3 和图 4 中的 RMSE、PSNR 和重构时间见表 3 和表 4。

由图 4—5 和表 3—4 可知，OMP、CoSaMP、SP 和 IRLS 算法在低采样率下无法有效重构图像，随着采样率的提升重构效果逐渐变好，但与原图像相比图像质量仍然不高。文中提出方法无论在低采样率还是高采样率下均取得了较好的重构效果，尤其在 12.5% 的低采样率下仍能得到高质量的重构图像，相较于传统方法

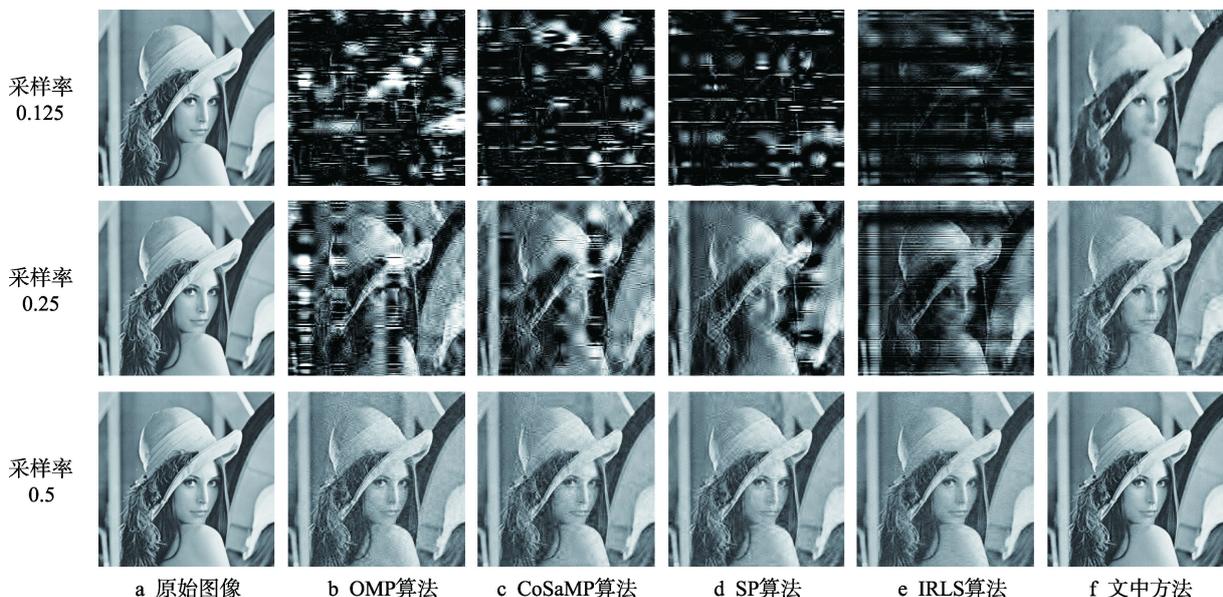


图 4 不同采样率下重构效果

Fig.4 Reconstruction effect under different sampling rates

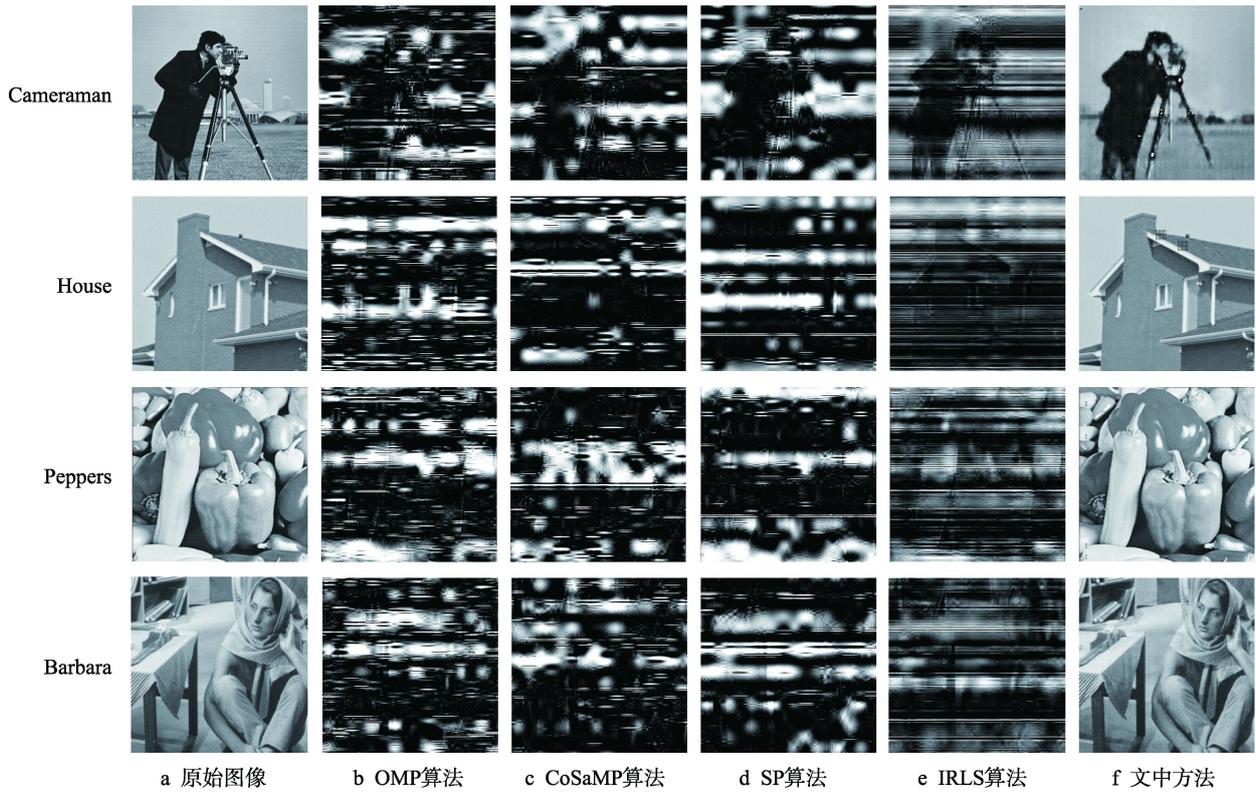


图5 不同图像下重构效果
Fig.5 Reconstruction effect under different images

表3 5种算法在相同图像(Lena),不同采样率下的RMSE和PSNR
Tab.3 RMSE and PSNR of five algorithms under the same image but different sampling rates

重构方法	$M/N=0.125$			$M/N=0.25$			$M/N=0.5$		
	RMSE	PSNR/dB	时间/s	RMSE	PSNR/dB	时间/s	RMSE	PSNR/dB	时间/s
OMP	127.835	5.998	0.770	70.589	11.156	1.039	11.719	26.752	2.123
CoSaMP	124.615	6.219	0.950	42.664	15.529	1.502	11.604	26.838	3.804
SP	119.163	6.608	0.907	37.047	16.756	1.287	10.887	27.393	2.669
IRLS	97.241	8.374	0.956	50.093	14.135	2.098	9.255	28.804	7.915
文中	28.808	18.9404	0.009	8.996	28.146	0.011	3.938	39.358	0.013

表4 5种算法在不同图像,相同采样率($M/N=0.125$)下的RMSE和PSNR
Tab.4 RMSE and PSNR of five algorithms under the different images but the same sampling rate

重构方法	Cameraman			House			Peppers			Barbara		
	RMSE	PSNR	时间/s	RMSE	PSNR	时间/s	RMSE	PSNR	时间/s	RMSE	PSNR	时间/s
OMP	151.695	4.511	0.788	162.536	3.912	0.797	161.903	3.946	1.072	142.162	5.075	0.801
CoSaMP	131.991	5.719	0.958	154.564	4.349	0.939	149.214	4.655	1.503	125.301	6.172	0.934
SP	116.929	6.772	0.992	137.698	5.352	0.941	140.765	5.160	0.939	119.404	6.590	1.154
IRLS	82.613	9.789	0.996	109.620	7.333	1.019	112.395	7.116	1.264	99.283	8.193	1.172
文中	18.581	22.749	0.01	16.327	22.106	0.009	19.948	20.202	0.009	20.927	19.249	0.009

PSNR提高了10~12 dB,展现出极高的应用价值。

4 结语

文中提出的基于生成对抗网络的压缩感知图像

重构方法,首次使用鉴别器(D)对图像进行压缩采样、生成器(G)对图像进行重构,同时设计了由对抗损失和重构损失共同组成的损失函数用于提高重构图像质量。通过实验验证了文中方法在12.5%的低采样率下可以得到高质量的重构图像,解决了传统压

缩感知图像重构算法计算时间长、重构效果不佳的问题。所用模型在完成训练后，首先保存模型的网络参数，然后将稀疏采样模块和图像重构模块所对应的网络参数分别进行交叉编译，即编译 TensorFlow 底层的 C++ 库、再用 C++ 接口调用 API。将交叉编译好的稀疏采样模块部署在嵌入式设备、图像重构模块部署在上位机中，稀疏采样模块压缩后的数据通过总线传输到上位机中，在上位机中进行图像重构过程可满足实际工程需要，为图像压缩重构与深度学习的结合提供了一种新的方法。

参考文献：

- [1] RANI M, DHOK S B, DESHMUKH R B. A Systematic Review of Compressive Sensing: Concepts, Implementations and Applications[J]. IEEE Access, 2018, 6: 4875—4894.
- [2] 杜秀丽, 顾斌斌, 胡兴, 等. 用于图像重构的基于行间支撑集相似度的 CoSaMP 算法[J]. 计算机科学, 2018, 45(4): 306—311.
DU Xiu-li, GU Bin-bin, HU Xing, et al. Support Similarity between Lines Based CoSaMP Algorithm for Image Reconstruction[J]. Computer Science, 2018, 45(4): 306—311.
- [3] 李琪, 张欣, 张平康, 等. 阈值稀疏自适应匹配追踪图像重构算法[J]. 小型微型计算机系统, 2018, 39(11): 2528—2532.
LI Qi, ZHANG Xin, ZHANG Ping-kang, et al. Image Reconfiguration Algorithm Via Threshold Sparse Adaptive Matching Tracking[J]. Journal of Chinese Computer Systems, 2018, 39(11): 2528—2532.
- [4] 赵辉, 张静, 张乐, 等. 基于非局部低秩和加权全变分的图像压缩感知重构算法[J]. 电子与信息学报, 2019, 41(8): 2025—2032.
ZHAO Hui, ZHANG Jing, ZHANG Le, et al. Compressed Sensing Image Restoration Based on Non-local Low Rank and Weighted Total Variation[J]. Journal of Electronics & Information Technology, 2019, 41(8): 2025—2032.
- [5] LI Y, XIAO N, OUYANG W. Improved Boundary Equilibrium Generative Adversarial Networks[J]. IEEE Access, 2018, 6: 11342—11348.
- [6] LEDIG C, THEIS L, HUSZAR F, et al. Photo-Realistic Single Image Super-resolution Using a Generative Adversarial Network[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4681—4690.
- [7] ISOLA P, ZHU J Y, ZHOU T, et al. Image-to-Image Translation with Conditional Adversarial Networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1125—1134.
- [8] CANDES E J, ROMBERG J, TAO T. Robust Uncertainty Principles: Exact Signal Reconstruction from Highly Incomplete Frequency Information[J]. IEEE Transactions on Information Theory, 2006, 52(2): 489—509.
- [9] DONOHO D L. Compressed Sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289—1306.
- [10] CANDES E J, TAO T. Near-Optimal Signal Recovery from Random Projections: Universal Encoding Strategies? [J]. IEEE Transactions on Information Theory, 2006, 52(12): 5406—5425.
- [11] CANDES E, TAO T. Decoding by Linear Programming[J]. IEEE Transactions on Information Theory, 2005, 51(12): 4203—4215.
- [12] 李坤, 马彩文, 李艳, 等. 压缩感知重构算法综述[J]. 红外与激光工程, 2013, 42(S1): 225—232.
LI Shen, MA Cai-wen, LI Yan, et al. Survey on Reconstruction Algorithm Based on Compressive Sensing[J]. Infrared and Laser Engineering, 2013, 42(S1): 225—232.
- [13] GOODFELLOW I, POUGET A J, MIRZA M, et al. Generative Adversarial Nets[C]// Advances in Neural Information Processing Systems, 2014: 2672—2680.
- [14] WANG K, GOU C, DUAN Y, et al. Generative Adversarial Networks: Introduction and Outlook[J]. IEEE/CAA Journal of Automatica Sinica, 2017, 4(4): 588—598.
- [15] IOFFE S, SZEGEDY C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift[C]// International Conference on Machine Learning, 2015: 448—456.
- [16] KINGMA D P, BA J. Adam: A Method for Stochastic Optimization[C]// 3rd International Conference for Learning Representations (ICLR), 2015.
- [17] TROPP J A, GILBERT A C. Signal Recovery from Random Measurements via Orthogonal Matching Pursuit[J]. IEEE Transactions on Information Theory, 2007, 53(12): 4655—4666.
- [18] NEEDELL D, TROPP J A. CoSaMP: Iterative Signal Recovery from Incomplete and Inaccurate Samples[J]. Applied and Computational Harmonic Analysis, 2009, 26(3): 301—321.
- [19] DAI W, MILENKOVIC O. Subspace Pursuit for Compressive Sensing Signal Reconstruction[J]. IEEE Transactions on Information Theory, 2009, 55(5): 2230—2249.
- [20] CHARTRAND R, YIN W. Iteratively Reweighted Algorithms for Compressive Sensing[C]// 2008 IEEE International Conference on Acoustics, Speech and Signal Processing, 2008: 3869—3872.