

引用格式: FENG Wei, ZHAO Xiao-dong, WU Gui-ming, *et al.* Computational Ghost Imaging Method Based on Convolutional Neural Network[J]. *Acta Photonica Sinica*, 2020, **49**(6):0610002

冯维, 赵晓冬, 吴贵铭, 等. 基于卷积神经网络的计算鬼成像方法研究[J]. *光子学报*, 2020, **49**(6):0610002

基于卷积神经网络的计算鬼成像方法研究

冯维^{1,2}, 赵晓冬¹, 吴贵铭¹, 叶忠辉¹, 赵大兴¹

(1 湖北工业大学 机械工程学院, 武汉 430068)

(2 现代制造质量工程湖北省重点实验室, 武汉 430068)

摘要:针对低采样下重构图像的成像质量和成像速度问题,提出一种基于卷积神经网络的计算鬼成像方法.首先,利用关联计算方法重建的一组训练集图像和相应的无损图像训练一个卷积神经网络;然后,将通过关联计算重建的测试集图像作为卷积神经网络的输入层,使其能够学习传感模型并最终能够预测出相应的图像;最后,将经卷积神经网络还原的图像分别与计算鬼成像和结合压缩感知算法重建的图像进行详细的对比实验分析.实验结果表明:本文方法在 0.08 采样率下能高质量地还原出被测物体的像,且成像质量均高于其他方法;同时,在不牺牲图像质量的条件下,执行程序所需的单张图像重建耗时约 0.06 s,极大地提高了图像重建的速度.分别通过数值模拟和光学实验,验证了本方法的有效性,对工程应用具有重要意义.

关键词:光学信息处理;计算鬼成像;卷积神经网络;数字微镜器件;散斑图

中图分类号:O438

文献标识码:A

doi:10.3788/gzxb20204906.0610002

Computational Ghost Imaging Method Based on Convolutional Neural Network

FENG Wei^{1,2}, ZHAO Xiao-dong¹, WU Gui-ming¹, YE Zhong-hui¹, ZHAO Da-xing¹

(1 School of Mechanical Engineering, Hubei University of Technology, Wuhan 430068, China)

(2 Hubei Key Laboratory of Modern Manufacturing Quality Engineering, Wuhan 430068, China)

Abstract: A computational ghost imaging method based on convolutional neural network is proposed to solve the imaging quality and the speed of reconstructed images under low sampling condition. Firstly, a convolutional neural network is trained by using a set of training images which are reconstructed by the correlation calculation method and corresponding lossless images. Then, the test set images reconstructed by the correlation calculation are used as the input layer of the convolutional neural network to learn the sensing model and predict the corresponding images. Finally, the images reconstructed by the convolutional neural network are compared with the images reconstructed by computational ghost imaging and compressed sensing algorithm, respectively. The experimental results show that the proposed method can restore the measured object with high quality when the sampling rate is 0.08, and the image quality is higher than other methods. Meanwhile, it takes about 0.06 s without sacrificing image quality when the method is used to reconstruct the single image, which greatly improves the speed of image reconstruction. The effectiveness of our method is also verified by numerical simulation and optical experiments, which is of great significance for engineering applications.

基金项目:国家自然科学基金(Nos. 51805153, 51675166),精密测试技术及仪器国家重点实验室开放基金(No. pilab1801),湖北工业大学高层次人才科研启动基金(No. BSQD2019005)

第一作者:冯维(1988—),男,副教授,博士,主要研究方向为计算成像与精密测量、深度学习. Email: david2018@hbut.edu.cn

通讯作者:赵大兴(1962—),男,教授,博士,主要研究方向为深度学习、机器视觉检测与质量评价. Email: zdx007@126.com

收稿日期:2019-12-16; **录用日期:**2020-03-02

<http://www.photon.ac.cn>

Key words: Optical information processing; Computational ghost imaging; Convolutional neural networks; Digital micromirror device; Speckle patterns

OCIS Codes: 100.3010; 110.1758; 110.3010; 200.4260

0 引言

计算鬼成像(Computational Ghost Imaging, CGI),作为一种单像素成像方法,近年来广泛受到人们的关注.早在 2008 年,SHAPIRO J H 等学者在理论上提出了计算鬼成像,取代了分束器分出的参考光路,根据空间光调制器(Spatial Light Modulator, SLM)特性,将其应用到关联成像^[1].次年, BROMBERG Y 完成了单路计算式鬼成像实验^[2].计算式关联成像主要使用 SLM 或数字投影仪(Digital Light Processing, DLP)或数字微镜器件(Digital Micromirror Device, DMD)对光源进行调制,投射不同的随机散斑图到被测表面,利用桶探测器记录相应的光场信息,并通过关联计算恢复出待测表面的空间信息.相比传统鬼成像,单臂式计算鬼成像具有灵活的光路设计和较高的峰值信噪比(Peak Signal to Noise Ratio, PSNR),正被用于低光照和恶劣环境下的水下成像^[3]、X 射线成像^[4]和透过散射介质成像^[5]等领域,并涌现出相关应用,如单像素相机^[6]、三维重建^[7-9]等,具有更加广阔的应用前景.

然而,需要大量的测量数据是阻碍其实际应用的主要问题之一.自压缩感知(Compressed Sensing, CS)理论^[10,11]提出后,通过利用大多数自然物体的稀疏性以减少重构所需的采样次数,突破了奈奎斯特采样定理的限制,实现压缩鬼成像^[12-16].但是这些方法仍需要很大的计算量,随着高分辨率图像的增加,重构时间成指数上升,导致实际应用可能性低.

随着成像数据量的急剧增长和计算能力的不断提高,通过深度学习从数据中学习先验知识,并利用一个神经网络拟合输入输出数据对,从而建立输入到输出的映射关系,因此可有效恢复被测物成像效果^[17-22].2017 年, SINHA A 等^[18]首次证实深度学习(Deep Neural Networks, DNN)通过训练后可解决端到端逆向的计算成像问题,并实验建立和测试了一个无透镜成像系统,实现了物体的相位恢复. LYU M 等^[19]提出了基于深度学习的计算鬼成像,通过 DNN 对低采样率的输入数据进行训练,获取低采样率下的重构图像.但该方法在学习过程中将图像转换为向量的形式实现全连接,计算量庞大,针对复杂图像并不能较好地提取图像底层信息,且训练数据集难以获取. SHIMOBABA T 等^[20]使用 Caltech-256 数据集,挑选出不同分辨率的普通图像选择差分计算鬼成像(Differential Computational Ghost Imaging, DCGI)进行重构,再运用 DNN 预测低噪声图像,成像速度虽有所提升,但成像质量不佳. HE Y 等^[21]运用卷积神经网络(Convolutional Neural Networks, CNN),但该方法样本较为单一,模型泛化能力较差,针对多样性物体预测效果波动较大. WANG F^[22]等提出通过仿真数据集训练神经网络,运用恢复实验数据的方法应用于透过散射介质成像.鬼成像的重建质量可能从根本上受到采样效率的制约^[23,24],即表示在单位采样周期内获取对象信息的程度. LYU M 等^[19]通过实验证明在欠采样条件下,运用压缩感知算法图像的信噪比并不理想,但通过神经网络的方式可以在相同采样情况下提高图像信噪比.综上所述,目前计算关联成像方法主要是高采样率下提升整幅图像的信噪比,但在极小采样率 β (如 $0 \leq \beta \leq 0.3$)条件下,成像效果仍不理想.

鉴于此,本文借助神经网络的特征自提取优势,提出一种基于卷积神经网络的计算鬼成像方法(Computational Ghost Imaging Based on CNN, CNN-CGI),通过设计和构建卷积神经网络模型,可有效解决低采样率下重构图像的成像质量和成像速度问题,深入推进鬼成像技术在实际场景中的应用.首先,利用关联计算方法重建的训练集图像和相应的无损图像训练一个卷积神经网络;然后,将通过关联计算重建的测试集图像作为卷积神经网络的输入层,使其能够学习传感模型,并使其最终能够预测出相应的图像;最后,通过理论分析和实验,充分验证了本方法能够在不同数据集低采样的情况下,图像的重建质量和重建速度大大提升.

1 算法及架构设计

1.1 计算鬼成像原理

计算鬼成像^[5]原理示意图如图 1,利用 DLP 调制光场^[25],其核心元件为 DMD.由 Matlab 中 randn()函数可生成 N 个符合正态分布的随机二值矩阵,将其按照预先设定的周期顺序加载到 DMD 上.当二值随机散斑图某点取值为 1 时,对应的微镜处于“打开”状态;当二值随机散斑图某点取值为 0 时,对应的微镜处于“关

闭”状态,这相当于对光源进行了 N 次空间强度分布调制,且每次调制后的光强分布可由对应的二值随机矩阵 $I_i(x, y)$ ($1 \leq i \leq N$) 表示.假设反射或透射光信号通过桶探测器采集总光强的值为 S_i ,此处可用 CMOS 相机代替桶探测器收集透射物体光强,其单幅图像的光场强度依据面积分作为单像素桶探测器的总光强响应值.

$$\mathbf{G}_{\text{CGI}}(x, y) = \frac{1}{N} \sum_{i=1}^N (S_i - \langle S_i \rangle) I_i(x, y) = \langle S_i I_i(x, y) \rangle - \langle S_i \rangle \langle I_i(x, y) \rangle \quad (1)$$

$$S_i = \int I_i(x, y) T(x, y) dx dy \quad (2)$$

式中, $\langle \rangle$ 表示对 N 次测量结果的系综平均, $T(x, y)$ 为物体的透射率函数.经过 N 次采样后,理想情况下可由式(1)、(2)的关联计算算法对物体信息进行重建 $\mathbf{G}_{\text{CGI}}(x, y)$ 图像.




图1 原理示意图
Fig.1 Principle schematic

1.2 卷积神经网络算法设计

在本方案中,设计卷积神经网络算法以提升低采样下 CGI 重构图像的质量和速度.算法的整体流程如图2,其过程表述为

Step1: 模拟现实中的大量不确定性数据,随机选取具有多样性数据集 \mathbf{A} 中的训练集图片 m 张,测试集图片 n 张,根据经验将分辨率均进行放大,放大特征信息;

Step2: 将数据集 \mathbf{A} 中的图片当作被测物体,通过 DLP 对包含物体信息的光场进行二值随机矩阵 $I(x, y)$ 的调制,并利用桶探测器探测透过物体的总光强 S_i 数据,最后运用关联计算式(1)直接进行图像重构,构成新的图像数据集 \mathbf{A}' ;

Step3: 将重构后的新数据集 \mathbf{A}' 和对应原数据集 \mathbf{A} 通过滑窗法以增加样本量,如在水平和竖直方向上滑移、角度旋转,得到增强后的数据集分别对应 $\tilde{\mathbf{A}}'$ 和 $\tilde{\mathbf{A}}$;

Step4: 将增强后的 $\tilde{\mathbf{A}}'$ 和 $\tilde{\mathbf{A}}$ 训练集输入到一个端到端的卷积神经网络,通过向前卷积运算和图像变换函数运算得到实际输出结果,再通过反向传播阶段,计算实际输出与理想输出间的误差 $\Delta \tilde{\mathbf{A}}$; 利用实际输出结果与原数据集 $\tilde{\mathbf{A}}$ 中对应的原图,即相应标签的图像数据,通过反向传播算法传递误差以减小误差,同时更新相邻两层每两个神经元之间的连接权因子,得到一个端到端的 CNN 模型;

Step5: 利用训练完成的模型对数据集 $\tilde{\mathbf{A}}$ 中部分测试集(甚至是损坏的部分测试集)输入端到端的卷积神经网络进行预测,模型输出即为预测后的 CGI 图像 \mathbf{B} .

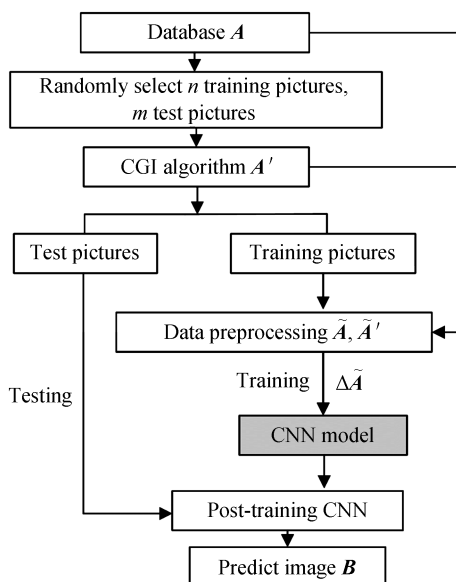


图2 算法流程
Fig.2 Flow chart of algorithm

1.3 卷积神经网络的架构设计

在去噪卷积神经网络^[26]基础上进一步优化为图像恢复模型,可获得基于卷积神经网络的 CGI 框架中 CNN model.网络模型的架构如图 3 所示,主要由输入、特征提取、非线性映射、重建和输出 5 个部分组成.

1)数据输入.通过上述 Step1~3 步骤,将网络中输入和输出调整为滑窗法设置的尺寸,在有限的数据集能够扩展数据集,选取 \tilde{A} 和 \tilde{A} 中对应块作为训练样本,增加网络的泛化能力.

2)特征提取.特征提取部分主要是对特征图像进行卷积运算,并通过修正线性单元(Rectified Linear Unit, ReLU)提取不同局部特征.

3)非线性映射.非线性映射由卷积层、批量归一化(Batch Normalization, BN)层和修正线性单元(Rectified Linear Unit, ReLU)激励层组成.通过改变减小网络中间数据分布和训练过程中反向传递误差,不断更新每一层神经元的权重和偏置,实现对神经网络参数训练的影响,从而加速训练过程,提高去噪和泛化能力.

4)重建与输出.只用一个卷积层便能实现图像重建,输出的是重建后高质量的图像.

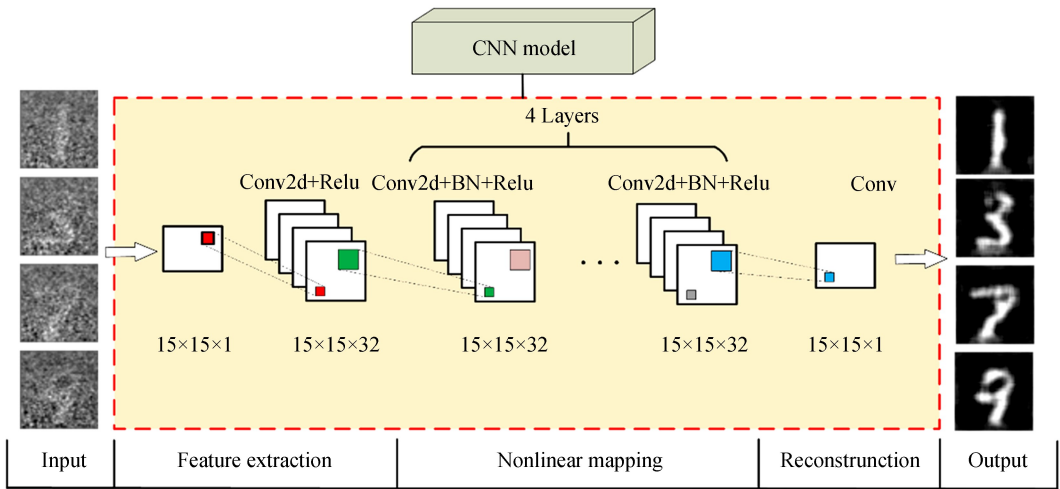


图 3 卷积神经网络架构模型

Fig.3 Convolutional neural network model

通过多次实验验证,本文所设计网络的架构参数如下:特征提取层采用卷积核尺寸为 3×3 ,卷积核数量为 32,步长为 1;非线性映射层采用卷积核尺寸为 3×3 ,卷积核数量为 32,步长为 1,同时使每一层的输出都规范化到均值为 0,方差为 1,且激活函数均选择 ReLU;重建层卷积核尺寸为 3×3 ,卷积核数量为 1,步长为 1;上述网络层均需要在卷积后对图像边缘进行零填充,通过这种方式使图像的输出与输入分辨率相同.

2 仿真实验结果与对比分析

2.1 实验步骤

仿真实验时,根据 1.2 节设计的卷积神经网络算法,首先分别随机选取 MNIST 手写数字数据集^[27] A 中的一组(该数据集中包含 2 000 个训练集和 10 个测试集)和 EMNIST 手写英文数据集中的一组(此数据集中包含 2 600 个训练集和 260 个测试集)来训练网络,将其图片为 28 pixel \times 28 pixel 统一调整为 50 pixel \times 50 pixel,并将其均通过 CGI 算法构成新的图像数据集 A' .随后,将重构后的新数据集 A' 和对应原数据集 A 一一对应,并通过滑窗法,设置窗口的尺寸为 15,滑窗间隔为 5,对图像进行平移和旋转操作,即可将训练的两个数据集分别扩展到 1 140 000 和 1 482 000,最终增强后的数据集分别对应 \tilde{A} 和 \tilde{A} .通过对有限的数据集进行预处理操作,能有效扩展数据集,增加了数据集的多样性,可为后续的网络训练奠定良好的基础.

训练过程中,两次仿真实验均训练 20 个周期,对应的每个周期分别训练 8 906 和 11 578 个批次,每个批次各含有 128 张小尺寸图像.采用损失函数设为均方误差(Mean Square Error, MSE)作为反向传播阶段的衡量参数,权重和偏置则是通过自适应矩估计(Adaptive Moment Estimation, Adam)优化算法得到更新,加速训练的收敛过程,同时将学习率调整为 0.000 1.训练结束后,输入测试集, CNN 就可以重构出目标图像 B .

2.2 实验结果分析

在本文中,全采样率定义为 $2500(50 \times 50)$ 次检测.相应地,0.1 的采样率代表 250 次检测,低采样率范围为 $0 \leq \beta \leq 0.3$.实验中,分别在低采样率 β 为 0.04、0.1、0.2 的情况下通过 CGI、CSCGI、CNN-CGI 算法重构的图像,仿真实验结果如图 4.图 4(a)、(e)为测试目标原图像,图 4(b)~(d)、(f)~(h)中 CGI 所在列为不同采样率运用关联计算式(1)直接进行重构而成图像 A' ,同时作为 CNN 网络训练输入图像;对比实验输出结果如图 4(b)~(d)、(f)~(h)中的 CGI、CSCGI 和 CNN-CGI 所示.

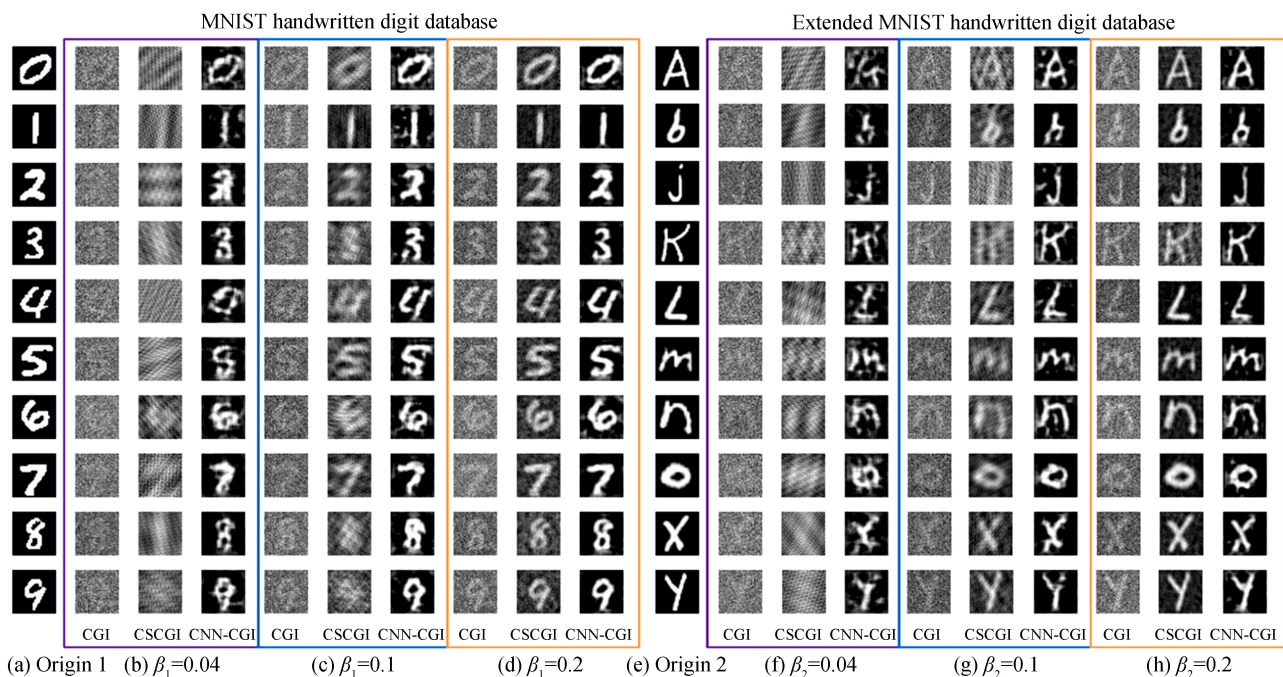


图 4 不同方法的数值仿真结果对比

Fig.4 Comparison of numerical simulation results of different methods

仿真实验结果表明:随着采样率 β 增高,CSCGI 和 CNN-CGI 成像效果越好,但在较低采样率时,CNN-CGI 成像质量明显优于 CSCGI 成像质量.当 $\beta=0.1$ 时,CGI 和 CSCGI 是很难清晰地分辨图像,这是由于采用压缩感知算法在低采样下对重构图像影响较大,易造成区域模糊,重建效果差.但通过 CNN 进行图像预测,CNN-CGI 算法处理后的输出图像的对比度和边缘信息显著增强,且 PSNR 和结构相似性 (Structural Similarity Index, SSIM) 大大提升,背景散斑也能够有效滤除.

3 实验平台测试及结果分析

3.1 实验平台搭建

为了验证本文提出方法的实际可行性,根据图 1 搭建的实验装置如图 5 所示.本成像系统主要由数字光处理器 DLP4500、衰减片、被测物、光学镜头、CMOS 相机、服务器组成,将它们放在同一主光轴上.服务器的配置为:处理器为 Inter(R) Xeon(R) CPU E5-2640 v4;运行内存:64 GB;操作系统为:Win7,64 位;GPU 型号:NVIDIA GeForce GTX2080Ti.算法程序是使用 Python 3.5 编写,采用基于 TensorFlow 的 Keras 框架实现 CNN 模型.




图 5 实验装置

Fig.5 Experimental setup

3.2 实验步骤

实验中,仍采用仿真实验中的测试图像,通过 DLP4500 依次投射 $50 \text{ pixel} \times 50 \text{ pixel}$ 的散斑图,先后通过衰减片和被测物后,并用 CMOS 相机代替桶探测器收集透过物体总光强值^[2,21].考虑到理论仿真散斑与实际散斑存在差别^[28],由 CMOS 相机采集到的散斑场代替仿真散斑场,仿真散斑和实际散斑图分别如图 6(a)和(b)所示,将实际散斑图代入关联计算式(1)直接进行测试目标重构,构成新的图像测试集.将该测试集作为所设计卷积神经网络的输入,通过仿真数据集 A' 训练神经网络,输出的则是重建后高质量的图像 B .




图 6 仿真散斑与实际散斑

Fig.6 Simulated speckle and actual speckle

3.3 成像质量分析

利用 CMOS 相机测量次数分别为 200 次和 400 次,根据图 5 实验装置所做的光学验证实验效果如图 7 所示,分别在低采样率 β 为 0.08、0.16 的情况下通过 CGI、CSCGI、CNN-CGI 算法重构的图像.图 7(a)、(d)为测试目标原图像,图 7(b)~(c)、(e)~(f)中 CGI 所在列为不同采样率下的测试输入图像,对比实验输出结果如图 7(b)~(c)、(e)~(f)中的 CSCGI 和 CNN-CGI 所示.实物实验结果表明:由于 DLP4500 投影散斑在采集时受周围环境的影响,导致通过 CGI 重建的图像,上半部分较为模糊,效果较差;但采用 CSCGI、CNN-CGI 算法都不易受周围环境的影响,并且通过 CNN-CGI 能够更加真实地还原出图像的物体信息和背景信息.因此,通过本文方法可以在较低的采样率的情况下,可以将其运用在低光照和恶劣环境下.

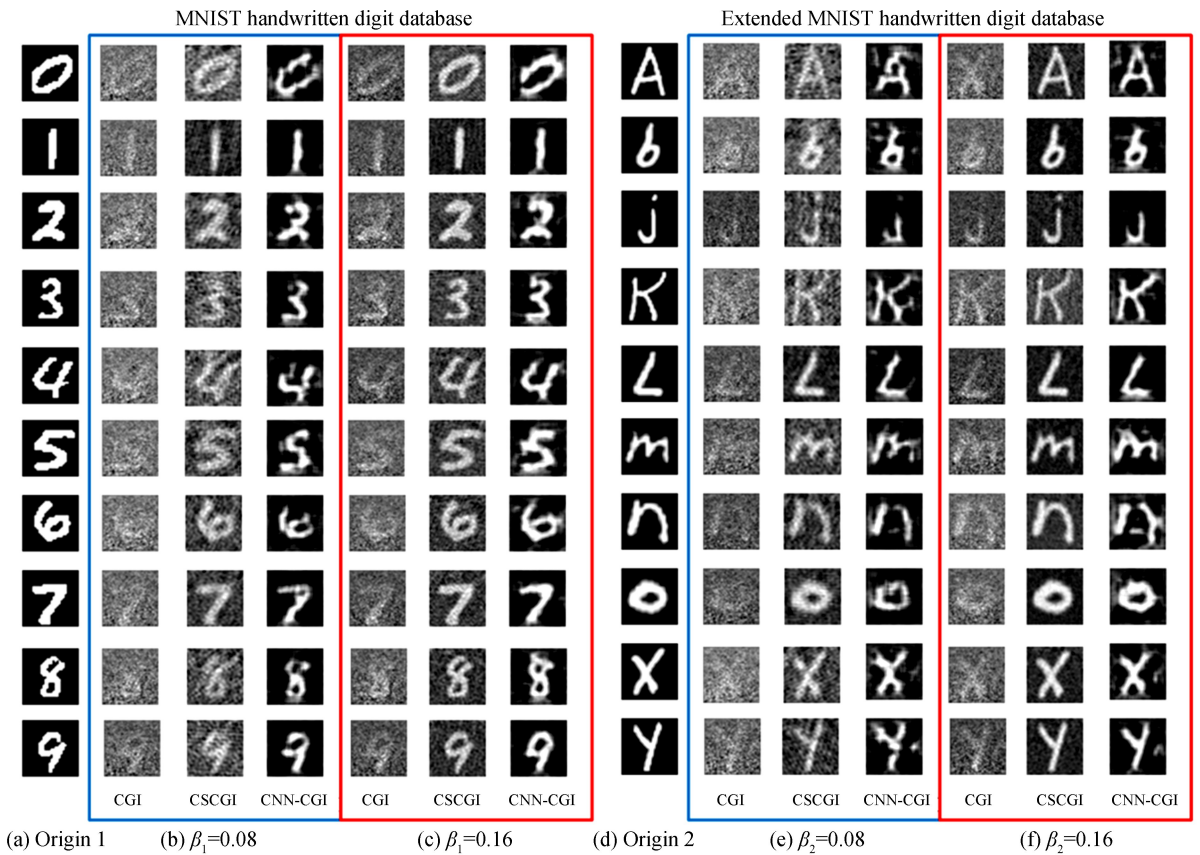


图 7 不同方法的实验实际效果对比

Fig.7 Comparison of experimental actual effects of different methods

在物理实验中,数字场景的稀疏性较低.为进一步客观评价本文方法的优越性,利用 PSNR 和 SSIM 来衡量对比 CGI、CSCGI 和 CNN-CGI 三种成像方法的图像质量.通常,PSNR 和 SSIM 越大,图像重构效果越好.为此,本文绘制了不同采样次数情况下,三种成像方法所对应的 PSNR 和 SSIM 关系曲线,如图 8 所示.实验数据结果表明:CNN-CGI 的 PSNR 和 SSIM 值明显高于其他方法,并且能够在低采样下能够还原出更好

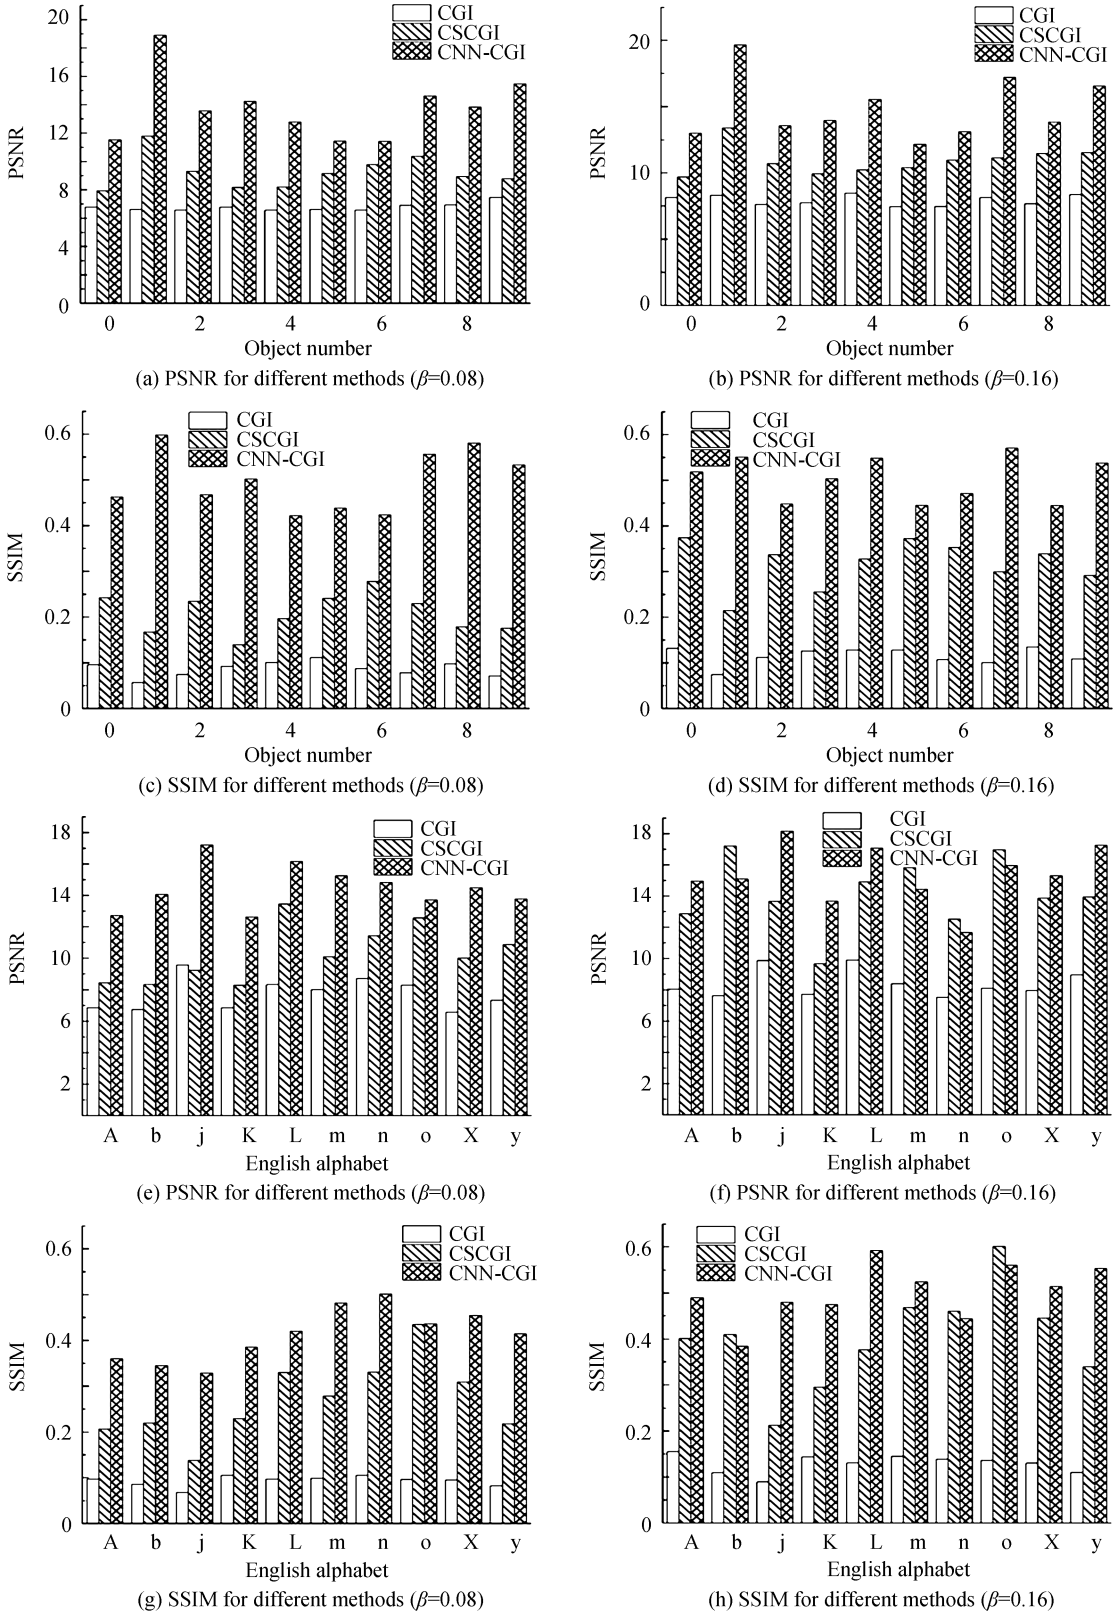


图 8 不同采样次数下 PSNR 和 SSIM

Fig.8 PSNR and SSIM at different sampling times

的图像;当在采样率不足(如 $\beta=0.08$)的情况下,CSCGI 结果的 PSNR 并不理想,部分图像存在失真,但通过 CNN-CGI 方法则可以有效避免.

3.4 实验成像速度分析

表 1 为单张测试图像在不同采样次数下各算法重建图像所需的平均运行时间.从中可知,在不同的低采样率下,采用 CNN-CGI 方法重构单张图像的时间已经缩短至 0.06 s 左右,远小于采用 CSCGI 方法重构单张图像的时间.因此,相比传统的计算鬼成像方法,本文设计的 CNN-CGI 算法,在保证重构图像质量的前提下,利用 GPU 多核并行运算的高效率,能同时极大地缩短神经网络的训练时间和目标物体重建时间,对工程应用具有重要意义.

表 1 单张测试图像在不同采样次数下各算法重建图像的平均运行时间(单位:秒)

Table 1 Average running time of each algorithm for a single test image at different sampling times (unit: s)

Sampling rates	Methods	CSCGI	CNN-CGI
	$\beta=0.08$		3.159 0
$\beta=0.16$		9.728 7	0.058 9

4 结论

本文提出一种基于卷积神经网络的计算鬼成像方法,能够充分挖掘图像内部特征,通过在去噪卷积神经网络算法的基础上进一步改进和优化,可有效解决低采样率下重构图像的成像质量和成像速度问题.本文方法与传统的 CGI、CSCGI 方法相比,在低采样率的情况下,可以更快地重建出目标图像,并且图像的 PSNR 和 SSIM 均有明显提升,背景散斑也能够有效滤除.最后,分别通过仿真实验和实际物理实验,进一步验证了本方法的有效可行性.本文方法为解决计算鬼成像速度问题提供了一个新的解决方案,有效推动了人工智能技术在计算鬼成像领域的应用.在后续的研究中,将进一步完善 CNN 的结构以提高模型的泛化能力.

参考文献

- [1] SHAPIRO J H. Computational ghost imaging[J]. *Physical Review A*, 2008, **78**(6): 061802.
- [2] BROMBERG Y, KATZ O, SILBERBERG Y. Ghost imaging with a single detector[J]. *Physical Review A*, 2009, **79**(5): 053840.
- [3] LE M, WANG G, ZHENG H, *et al.* Underwater computational ghost imaging[J]. *Optics Express*, 2017, **25**(19): 22859-22868.
- [4] YU H, LU R, HAN S, *et al.* Fourier-transform ghost imaging with hard x rays[J]. *Physical Review Letters*, 2016, **117**(11): 113901.
- [5] LIU Bao-lei, YANG Zhao-hua, QU Shao-fan, *et al.* Influence of turbid media at different locations in computational ghost imaging[J]. *Acta Optica Sinica*, 2016, **36**(10): 1026017.
刘保磊, 杨照华, 曲少凡, 等. 不同路径下散射介质对计算关联成像的影响[J]. *光学学报*, 2016, **36**(10): 1026017.
- [6] YUAN S, LIU X, ZHOU X, *et al.* Multiple-object ghost imaging with a single-pixel detector[J]. *Journal of Optics*, 2016, **45**(1): 92-98.
- [7] SUN B, EDGAR M P, BOWMAN R, *et al.* 3d computational imaging with single-pixel detectors[J]. *Science*, 2013, **340**(6134): 844-847.
- [8] JIANG H, ZHAI H, XU Y, *et al.* 3D shape measurement of translucent objects based on Fourier single-pixel imaging in projector-camera system[J]. *Optics Express*, 2019, **27**(23): 33564-33574.
- [9] SUN Ming-jie, ZHANG Jia-min. Single-pixel imaging and its application in three-dimensional reconstruction [J]. *Infrared and Laser Engineering*, 2019, **48**(6): 603003.
孙鸣捷, 张佳敏. 单像素成像及其在三维重建中的应用[J]. *红外与激光工程*, 2019, **48**(6): 603003.
- [10] DONOHO D L. Compressed sensing[J]. *IEEE Transactions on Information Theory*, 2006, **52**(4): 1289-1306.
- [11] CANDÈS 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.
- [12] KATE O, BROMBERG Y, SILBERBERG Y. Compressive ghost imaging[J]. *Applied Physics Letters*, 2009, **95**(13): 131110.
- [13] ABMANN M, BAYER M. Compressive adaptive computational ghost imaging[J]. *Scientific Reports*, 2013, **3**: 1545.
- [14] YU W K, LI M F, YAO X R, *et al.* Adaptive compressive ghost imaging based on wavelet trees and sparse representation[J]. *Optics Express*, 2014, **22**(6): 7133-7144.
- [15] LI Xin-yu, CAO Fei, ZHAO Sheng-mei. A compressive complex-valued ghost imaging theoretical scheme based on

- phase modulation[J]. *Acta Photonica Sinica*, 2014, **43**(S1): 111001.
- 李欣禹, 曹非, 赵生妹. 基于相位调制的复值物体压缩关联成像理论研究[J]. 光子学报, 2014, **43**(S1): 111001.
- [16] CHEN Yi, FAN Xiang, CHENG Yu-bao, *et al.* Intensity spread function analysis of single compressive sensing ghost imaging[J]. *Acta Photonica Sinica*, 2016, **45**(9): 911002.
- 陈熠, 樊祥, 程玉宝, 等. 单臂压缩感知鬼成像的光强扩散函数分析法[J]. 光子学报, 2016, **45**(9): 911002.
- [17] WANG Fei, WANG Hao, BIAN Yao-ming, *et al.* Applications of deep learning for computational imaging[J]. *Acta Optica Sinica*, 2020, **40**(1): 0111002.
- 王飞, 王昊, 卞耀明, 等. 深度学习在计算成像中的应用[J]. 光学学报, 2020, **40**(1): 0111002.
- [18] SINHA A, LEE J, LI S, *et al.* Lensless computational imaging through deep learning[J]. *Optica*, 2017, **4**(9): 1117-1125.
- [19] LYU M, WANG W, WANG H, *et al.* Deep-learning-based ghost imaging[J]. *Scientific Reports*, 2017, **7**(1): 17865.
- [20] SHIMOBABA T, ENDO Y, NISHITSUJI T, *et al.* Computational ghost imaging using deep learning[J]. *Optics Communications*, 2018, **413**: 147-151.
- [21] HE Y, WANG G, DONG G, *et al.* Ghost imaging based on deep learning[J]. *Scientific Reports*, 2018, **8**(1): 6469.
- [22] WANG F, WANG H, WANG H, *et al.* Learning from simulation: An end-to-end deep-learning approach for computational ghost imaging[J]. *Optics Express*, 2019, **27**(18): 25560-25572.
- [23] CHEN M, LI E, HAN S. Application of multi-correlation-scale measurement matrices in ghost imaging via sparsity constraints[J]. *Applied Optics*, 2014, **53**(13): 2924-2928.
- [24] KHAMOUSHIS M, NOSRATI Y, TAVASSOLI S H. Sinusoidal ghost imaging[J]. *Optics Letters*, 2015, **40**(15): 3452-3455.
- [25] LU Ming-hai, SHEN Xia, HAN Shen-shen. Ghost imaging via compressive sampling based on digital micromirror device[J]. *Acta Optica Sinica*, 2011, **31**(7): 0711002.
- 陆明海, 沈夏, 韩申生. 基于数字微镜器件的压缩感知关联成像研究[J]. 光学学报, 2011, **31**(7): 0711002.
- [26] ZHANG K, ZUO W, CHEN Y, *et al.* Beyond a gaussian denoiser: residual learning of deep CNN for image denoising [J]. *IEEE transaction on image processing*, 2017, **26**(7): 3142-3155.
- [27] DENG L. The MNIST database of handwritten digit images for machine learning research[J]. *IEEE Signal Processing Magazine*, 2012, **29**(6): 141-142.
- [28] GUO Shu-xu, ZHANG Chi, CAO Jun-sheng, *et al.* Object reconstruction by compressive sensing based normalized ghost imaging[J]. *Optics and Precision Engineering*, 2015, **23**(1): 288-294.
- 郭树旭, 张驰, 曹军胜, 等. 基于压缩感知归一化关联成像实现目标重构[J]. 光学精密工程, 2015, **23**(1): 288-294.