

DOI:10.19651/j.cnki.cmt.2107332

基于自编码神经网络的鬼成像优化方法^{*}

张思卿 杨风暴 王肖霞

(中北大学 信息与通信工程学院 太原 030051)

摘要: 针对鬼成像重构效果差所导致目标信息难以有效凸显的问题,结合自编码神经网络降噪优势,提出了一种鬼成像优化方法。该方法以手写数字数据集为样本,在对探测数据进行二阶关联获得初始鬼像的基础上,构建了一个降噪网络模型。该网络模型采用 Leaky ReLU 线性激活函数来解决网络的过饱和和单元死亡的问题,并通过 10 000 个测试样本集验证了所提网络模型的有效性。通过对不同采样率下优化前后鬼像的质量进行了对比分析,分析结果表明,优化后综合不同采样率下鬼像的峰值信噪比 CGI、DGI、CSGI 分别平均提高 87.02%/93.99%、81.97%/85.90%、27.22%/18.16%;对比度较 CGI、DGI、CSGI 分别平均提高 479.03%/363.79%、380.42%/272.91%、38.76%/31.05%。

关键词: 鬼成像;自编码神经网络;采样率;峰值信噪比;重构

中图分类号: O431.2 **文献标识码:** A **国家标准学科分类代码:** 110.3010

Ghost imaging optimization method based on autoencoder neural networker

Zhang Siqing Yang Fengbao Wang Xiaoxia

(School of Information and Communication Engineering, North University of China, Taiyuan 030051, China)

Abstract: Aiming at the problem that the target information is difficult to effectively highlight due to the poor reconstruction effect of ghost imaging, combined with the advantages of autoencoder neural network in noise reduction, a ghost imaging optimization method is proposed. In this method, a handwritten digital data set is used as a sample, and a noise reduction network model is designed based on the second-order correlation of the detection data to obtain the initial ghost image. The network model uses the Leaky ReLU linear activation function to solve the problem of network oversaturation and cell death, and the effectiveness of the proposed network model is verified through 10 000 testing sample sets. By comparing the quality of ghost images before and after optimization at different sampling rates, the analysis results show that the peak signal-to-noise ratio of ghost images after optimization is increased by 87.02%/93.99%, 81.97%/85.90%, 27.22%/18.16%, respectively. At the same time, the contrast is increased by 479.03%/363.79%, 380.42%/272.91%, 38.76%/31.05%, respectively, compared with CGI, DGI, and CSGI respectively.

Keywords: ghost imaging; autoencoder neural network; sampling rate; peak signal-to-noise ratio; reconstitution

0 引言

不同于传统光学成像,鬼成像可在不直视目标物体的情况下实现对目标的反直觉间接成像^[1],具有不受探测空间限制、可突破阵列式探测器响应极限等独特优势^[2]。然而,鬼成像探测过程中由于散斑场的随机性使得待测目标有效信息被分散隐藏在大量的探测数据中,导致待测目标有用信息极易被大量噪声所淹没^[3],极大制约了探测系统

对目标的有效提取与识别。为此,相关研究人员提出了各种鬼像质量优化方法^[4],如文献[5]提出了差分鬼成像(differential ghost imaging, DGI),该方法通过去除一个近似的噪声项来达到降低鬼像噪声的作用,但噪声项由透过待测目标的差分物体信息来确定导致鬼像重构效果提升有限;文献[6]在伪逆关联成像的基础上通过迭代的方式,提出了一种伪逆迭代重构方法,从而使得噪声消除量在差分鬼成像基础上有了进一步提高,但迭代次数的不足严重制

收稿日期:2021-07-20

^{*} 基金项目:内燃机可靠性国家重点实验室开放基金(skler-202011)、山西省应用基础研究计划青年科技研究基金(201901D211233)、山西省回国留学人员科研项目(2021-110)资助

约着鬼像重构质量;Katz 等^[7]将压缩感知理论引入鬼成像提出了压缩鬼成像,该方法利用物体稀疏特性在大量的时间下获得了较低噪声的重构鬼像;随后俞文凯在压缩感知鬼成像的基础上,通过自适应确定小波变换后初始鬼像的大系数区域来进行更高分辨率扫描及成像,提出了一种自适应压缩鬼成像^[8]。该类方法在全采样时能够很好地重构待测物体,但压缩算法复杂性会使得成像时间增加,且大场景高分辨率也会导致需求的测量数据呈指数式增长^[9]。

近年来,随着深度学习模型训练在目标提取与识别方面的优势^[10-12],部分学者尝试将深度学习引入到鬼成像优化中,通过网络训练方式来构建重建方法,从而达到提升鬼像质量的目的^[13]。例如:Lyu 等^[14]利用全连接神经网络构建了能够减少初始鬼像噪声的模型,提出了深度学习鬼成像(ghost imaging using deep learning, GIDL);Shimobaba 等^[15]在此基础上利用 U-Net 网络提出了深度学习计算鬼成像,该方法通过网络训练的方式对初始鬼像噪声的估计和模拟,构建了鬼像信噪比提升效果更好的网络模型;文献[16]将深度神经网络修改为卷积神经网络,通过网络参数调整来执行输入输出间完整映射,在降低少量测量数据的情况下依然获得了较好的重构结果。基于深度学习思想提出的上述方法虽在鬼成像质量提升方面有较大改善,然而在网络训练中仍然存在参数过多和模型泛化能力差和在采样率较低时重构效果不理想的问题。然而自编码神经网络作为一种有效特征提取的深度学习模型,不仅能够提取最具代表性的原始图像信息,而且能够以更精炼的数据和更高的准确性来保存前面一层的的信息,同时使用的转置卷积还可以很容易的重构出原始特征,从而为上述问题的解决提供了思路。

鉴于此,本文通过设计和构建适合鬼成像特性的自编码神经网络模型,提出了一种基于自编码神经网络的鬼成像优化方法,来解决低采样率下重构图像的成像质量问题。该方法首先将计算鬼成像重构结果作为训练集图像和测试集图像,然后通过网络构建及模型训练来获得待测目标的高质量重构图像,最后通过理论推导和实验分析,验证了所提方法在较低的采样率下可实现高质量的图像重构,同时成像时间大大降低,从而加快鬼成像的实用化进程。

1 自编码神经网络架构

自编码神经网络使用编码器和解码器的架构,通过无监督的方式学习和提取数据的重要基础特征,进而忽略额外噪声。编码器是将输入数据编码到潜在表示空间,而解码器依据该表示空间对原始数据进行重构。编码器和解码器使用的神经网络构建方式与普通的神经网络类似,均通过最小化输入和输出间差异来调整网络参数获得最终的神经网络模型,网络示意图如图 1 所示。

该网络中编码器由 3 个卷积层组成,而解码器由 3 个反卷积层构成,层与层之间添加 $\alpha=0.2$ 的 Leaky_ReLU 激




图 1 自编码神经网络架构模型

活函数。这里使用的 Leaky_ReLU 激活函数不仅可以解决 ReLU 函数坏死的问题,还可以在神经网络训练过程中修正数据分布,从而保留阈值的神经元信息以及加速网络的拟合速度。值得一提的是,解码器部分使用的与编码器相同激活函数,目的是在减少参数的同时来保证图像去噪的效果。

具体地,本文设计的 Encode 层使用了 10 个 3×3 大小的滤波器(filter),并且每一个卷积层均由标准偏差为 0.1 的随机正态值来初始化。同时,采用步长为 2 的卷积层在保留图像特征的基础上对图像进行降维。此外,Deconder 层也选用 10 个大小为 3×3 的滤波器(filter),并通过设计信息损失小和映射能力大的转置卷积对图像进行恢复。

2 鬼成像优化方法

自编码神经网络鬼成像优化方法整体流程如图 2 所示,主要包括数据选取、计算重构、模型训练和模型测试 4 个部分,具体如下。

1) 数据选取。选用公开手写数字数据集 MNIST 中包含 0~9 的手写数字作为原始数据集,且在输入网络之前要进行预处理将所有图片适当放大以获得新的数据集 A,从而来突出特征信息。在此基础上,将其随机分为 A_1 、 A_2 两组数据集。

2) 计算重构。将数据集中所有图片作为待测物体进行鬼成像实验,对探测数据运用如式(1)所示的计算鬼成像算法重构,获得训练集 A'_1 和测试集 A'_2 。

$$\hat{T}(x, y) = \frac{1}{M} \sum_{i=1}^M (B_i - \langle B \rangle) (I_i(x, y) - \langle I_i(x, y) \rangle) \quad (1)$$

式中: $I_i(x, y)$ 表示第 i 时刻下的光场分布,且 $i = 1, 2, \dots, M$; $B_i = \iint I_i(x, y) T(x, y) dx dy$ 表示第 i 时刻下的桶探测器接收值; $T(x, y)$ 和 $\hat{T}(x, y)$ 表示待测物体和最终重构出的物体鬼像。

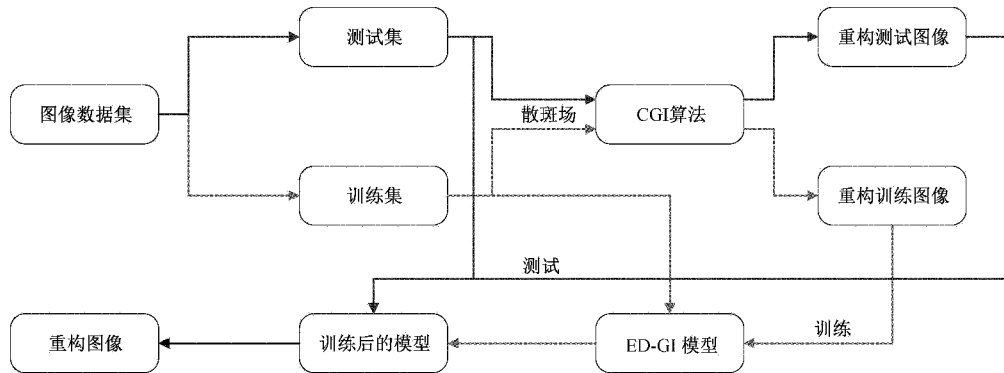


图 2 自编码神经网络鬼成像方法架构设计

3) 模型训练。将获得的训练集 A_1' 和原始数据集 A_1 输入到自编码神经网络, 在其训练过程中, 输出层会计算图像中噪声矩阵的估计值并利用损失函数计算损失值, 从而更新模型当中的参数以及相邻层间神经元的连接权因子, 从而获得最终的神经网络模型。

4) 模型测试。将测试集 A_2' 中的部分图像输入到最终的自编码神经网络模型中进行预测, 通过模型运算输出预测后的图像。

3 实验结果与对比分析

为了客观准确地说明所提方法的有效性和合理性, 引入峰值信噪比 (peak signal to noise ratio, PSNR) 和对比度 (visibility, V) 两个定量评价指标, 来对不同采样率下优化前后鬼像进行定量评价并对比说明所提方法的优势, 即:

$$P_{psnr} = 10 \lg \left(\frac{MAX_G^2}{MSE} \right) \quad (2)$$

$$V = \frac{G_{in} - G_{out}}{G_{in} + G_{out}} \quad (3)$$

式中: $MSE = \frac{1}{x \times y} \sum_{i=1}^x \sum_{j=1}^y [T'(x, y) - T(x, y)]^2$ 表示重构图像与原始图像的均方误差, x, y 为物体像素数, 是正整数; MAX_G^2 表示图像的最大灰度值; G_{in} 和 G_{out} 分别为重构鬼像中信息区域与背景区域的二阶关联函数值。

3.1 仿真实验结果与对比分析

仿真实验依据上一章算法整体架构来展开。首先, 从 MINIST 数据集中选取 19 947 张图片、10 000 张图片作为训练集和测试集; 然后, 将原始训练集和测试集通过 CGI 重构算法获得新的训练集和测试集; 随后, 将训练集和真实物体作为标签输入到自编码神经网络中进行训练。训练过程选择 Batch Size = 100 对模型进行训练。训练结束后, 随机选取测试集中部分图片输入到模型中即可获得重建图像。

图 3 和 4 分别展示了 0.1、0.3 采样率的 CGI、DGI、CSGI、ED-GI 的鬼成像算法重构结果。这里, 0.1、0.3 采样率为 $28 \times 28 \times 0.1$ 和 $28 \times 28 \times 0.3$, 即 196 次和 392 次采样。其中, 图 3(a) 和图 4(a) 表示测试物体原图像,

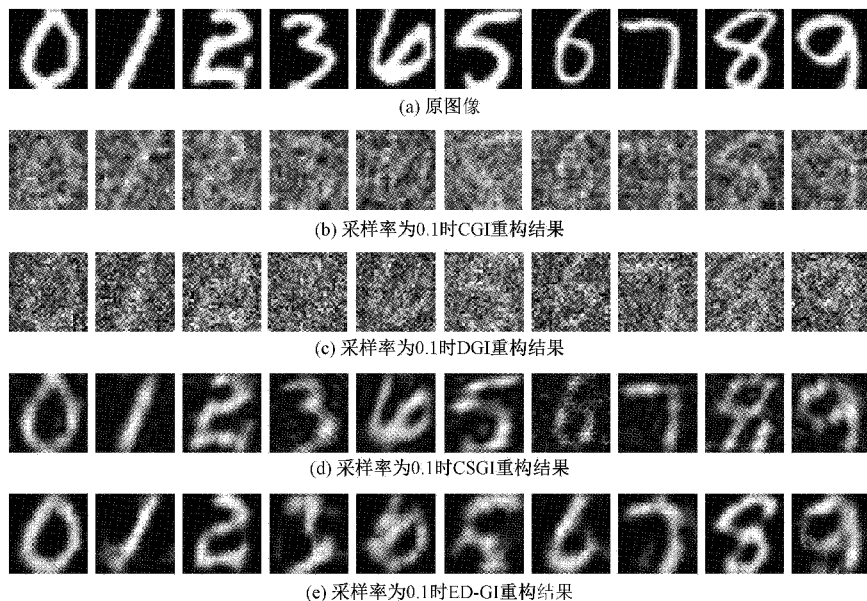


图 3 0.1 采样率下不同算法数值仿真结果对比




图 4 0.3 采样率下不同算法数值仿真结果对比

图 3(b)/图 4(b)、图 3(c)/图 4(c)分别表示 0.1/0.3 采样率下基于 CGI、DGI 算法重构结果,图 3(d)/图 4(d)分别表示 0.1/0.3 采样率下基于 CSGI 算法重构结果,同时图 3(e)/图 4(e)为图 3(b)/图 4(b)作为训练输入的 ED-GI 不同采样率重构结果。

观察图 3 和 4 重构结果可知两点。首先,同一采样率下,CGI、DGI 始终包含明显噪声,尤其在较低的采样率下目标信息基本被掩盖;而 CSGI 成像效果相对 CGI、DGI 有了极其明显地提升,同时对于信息基本被隐藏的 CGI 结果经过模型训练后,所得 ED-GI 重构结果明显最优。其次,随着采样率的上升,CGI、DGI、CSGI 和 ED-GI 的成像效果均有所上升,CGI、DGI 重构结果中目标已可基本可辨,CSGI 与 ED-GI 成像效果中背景噪声明显减少,且质量始终优于 CGI、DGI。

与此同时,为了定量分析所提方法在图像重构方面的有效性,利用式(2)、(3)所示的峰值信噪比公式和对比度

公式分别计算 CGI、DGI、CSGI、ED-GI 等算法在 0.1 和 0.3 采样率下对测试图片 0~9 所得重构图像的指标,并绘制如图 5、6 所示曲线。为了便于分析,本文计算了 10 张图片在 0.1 和 0.3 采样率下的平均峰值信噪比为 7.851 9/8.487 7、8.069 8/8.857 4、11.542 4/13.934 9、14.684 8/16.465 5,平均对比度为 0.110 5/0.116 0、0.130 9/0.183 0、0.322 6/0.459 1、0.620 1/0.678 9。此时,在 0.1 和 0.3 采样率下,ED-GI 算法的峰值信噪比相较于 CGI、DGI、CSGI 分别提升 87.02%/93.99%、81.97%/85.90%、27.22%/18.16%,对比度相较于 CGI、DGI、CSGI 分别提升 479.03%/363.79%、380.42%/272.91%、38.76%/31.05%;同时,相比于 0.1 采样率下重构图像,0.3 采样率时的 CGI、DGI、CSGI、ED-GI 等算法重构图像质量峰值信噪比指标分别提升 8.10%、9.76%、20.73%、12.13%,对比度指标分别提升 40.07%、41.16%、16.29%、9.98%。因此,定量分析结果与定性分析结果一致。




图 5 0.1 和 0.3 采样率下不同算法重构结果峰值信噪比曲线

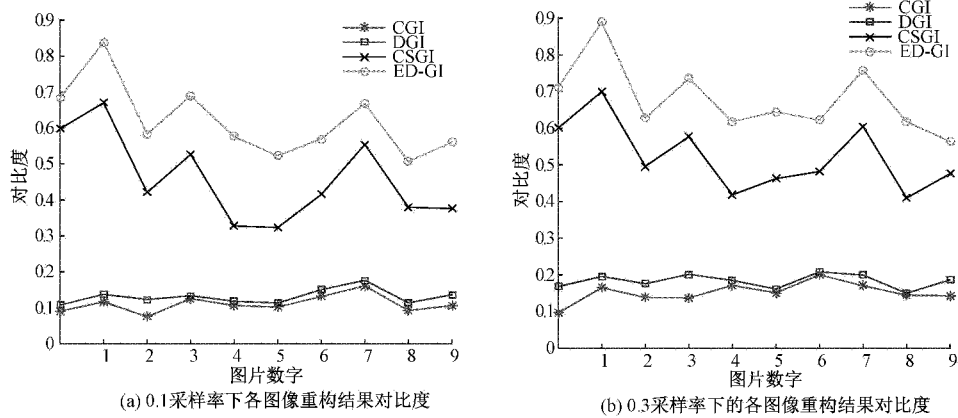


图 6 0.1 和 0.3 采样率下不同算法重构结果对比度曲线

3.2 实验平台测试及结果分析

为了验证本文所提方法应用于实际场景中的可行性,根据上节算法流程搭建了如图 7 所示的实验装置。成像系统主要由 532 nm 激光器、像元尺寸 $13.67 \mu\text{m}$ 且分辨率为 1027×768 的 DMD 设备、频带宽度 DC-11.0 MHz 的单像素探测器、光学镜头、CMOS 相机等组成,具体的摆放位置如图 7 所示。同时,所使用的计算机配置为 i5、Windows10、64 位,运行内存 4 GB,算法程序使用 Python3.5 编写,采用基于 TensorFlow2.3.0 的 Keras 框架实现自编码神经网络模型。

真实实验中,待测物体仍为上述测试图像。首先,激光照射到 DMD,经调制后产生 $112 \text{ pixel} \times 112 \text{ pixel}$ 的散斑图。这里散斑图扩大 4 倍的原因为 DMD 中像素设置为 4 点合并。然后经过自由传播照射到待测物体表面,透过物体的总光强由单像素探测器进行接收。考虑到理论仿真散斑与实际散斑存在差别,本文将 DMD 的调制光场当作实际散斑场,通过将得到的散斑场与单像素测得的总光强进行二阶关联运算,获得测试图像的重构鬼像,构成新的图像数据

集。最后,随机选取部分图像数据集输入到所设计的网络中,从而使得输出结果即为高质量的重构结果。




图 7 实验平台

经过真实实验验证,当设置采样率为 0.6 时,获得的 CGI、DGI、CSGI、ED-GI 重构结果如图 8 所示。其中,图 8(a)为包含数字 0~9 的原图像,图 8(b)~(e)为 CGI、

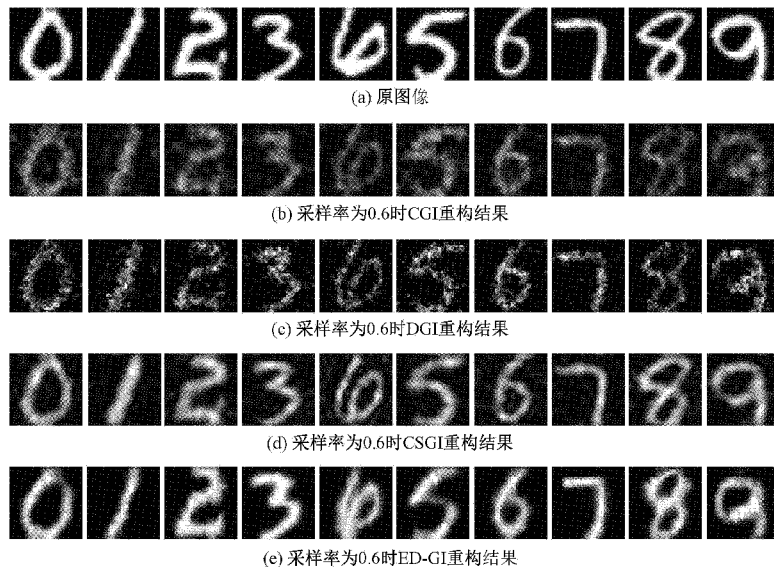


图 8 不同算法的实验实际效果对比

DGI、CSGI、ED-GI 对测试图像的重构结果。分析图 8 结果可知,ED-GI 所重构图像拥有更高视觉效果,且包含最少的噪声。此时,各重构算法对包含数字 0~9 的测试图像的峰值信噪比和对比度曲线如图 9 所示。




图 9 真实实验重构图像峰值信噪比和对比度曲线

分析图 9 可知,除了极少数的图像峰值信噪比和对比度结果与 CSGI 接近外,ED-GI 算法对测试图像的峰值信噪比和对比度始终处于领先地位,该定量分析结果与定性分析一致。

同时,本文还记录了 10 张图片在不同采样率下运用各种重构算法在仿真实验中重建图像所需的平均运行时间,如表 1 所示。观察表 1 可知,CGI 与 DGI 时间相近,CSGI 由于重构算法复杂时间最长,可以看出本文方法时间远远小于 CSGI,极大的促进了鬼成像的实用化进程。

表 1 不同采样率下的各算法重构图像的平均时间 s

采样率	算法			
	CGI	DGI	CSGI	ED-GI
0.3	0.007 8	0.009 2	0.048 3	0.012 2
0.1	0.004 1	0.005 1	0.036 8	0.007 2

4 结 论

本文在计算鬼成像的基础上,利用深度学习自动提取图像目标信息特征的能力,提出了一种基于自编码神经网络

的鬼成像优化方法。该方法将手写数字数据集作为待测目标,利用损失函数回调以及模型训练,降低了计算鬼成像重构结果中的大量噪声,获得了高质量的重构图像。以 CGI、DGI、CSGI 在不同采样率下对目标的重构结果为对比实验,通过数值模拟与真实实验,结果表明:视觉上所提方法在不同采样率下的重构结果要优于 CGI、DGI、CSGI 重构结果;数值上本文方法在 0.1 和 0.3 采样率下的峰值信噪比和对比度较 CGI、DGI、CSGI 提高显著;此外,在时间效率方面,所提方法重构时间大大降低。实验结果与理论分析一致,表明所提方法在一定程度上有利于改善未知目标重构质量,从而有助于推动鬼成像的工业化进程。

参 考 文 献

- [1] BROMBERG Y, KATZ O, SILBERBERG Y. Ghost imaging with a single detector[J]. Physical Review A, 2009, 79(5):053840.
- [2] ZHAI X, CHENG Z, DONG, HU Y D, et al. Foveated ghost imaging based on deep learning[J]. Optics Communications, 2019, 448:69-75.
- [3] 周成,黄贺艳,刘兵,等.基于混合散斑图的压缩计算鬼成像方法研究[J].光学学报,2016,36(9):99-105.
- [4] SHAPIRO J H. Computational ghost imaging[J]. Physical Review A, 2008, 78(6):061802.
- [5] FERRI F, MAGATTI D, LUGIATO L A, et al. Differential ghost imaging [J]. Physical Review Letters, 2010, 104(25):253603.
- [6] 张红伟,郭树旭,张驰,等.关联成像目标重构的伪逆迭代降噪方法[J].光子学报,2017,46(2):88-95.
- [7] KATZ O, BROMBERG Y, SILBERBERG Y. Compressive ghost imaging [J]. Applied Physics Letters, 2009, 95(13):739.
- [8] 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): 7133-44.
- [9] 陶勇.面向大视场探测的计算鬼成像重构模型研究[D].太原:中北大学,2020.
- [10] 王陶然,王明泉,张俊生,等.基于 Mask R-CNN 的轮毂缺陷分割技术[J].国外电子测量技术,2021,40(2): 1-5.
- [11] 范新南,严炜,史朋飞,等.PCNN 简化模型结合快速自适应双边滤波的裂缝图像去噪算法[J].国外电子测量技术,2021,40(5):8-13.
- [12] 杨昆,杜瑀,钱武侠,等.基于多尺度上下文信息融合的条件生成对抗神经网络用于低剂量 PET 图像去噪[J].电子测量技术,2021,44(7):74-81.
- [13] RIZVI S, CAO J, ZHANG K Y, et al. DeepGhost: Real-time computational ghost imaging via deep

- learning[J]. Scientific Reports, 2020, 10(1):11400.
- [14] LYU M, WANG W, WANG H, et al. Deep-learning-based ghost imaging [J]. Scientific Reports, 2017, 8(1):6315.
- [15] SHIMOBABA T, ENDO Y, NISHITSUJI T, et al. Computational ghost imaging using deep learning[J]. Optics Communications, 2018, 413:147-151.
- [16] HE Y C, WANG G, DONG G X, et al. Ghost imaging based on deep learning[J]. Scientific Reports, 2018, 8(1):6469.

作者简介

张思卿, 硕士研究生, 主要研究方向为鬼成像及计算成像方面的研究。

E-mail:1029901058@qq.com