

DOI: 10.19650/j.cnki.cjsi.J2412658

基于全局语义学习和显著目标感知的 激光干扰图像修复*

开志强^{1,2}, 苗锡奎³, 马天磊^{1,2}, 冯斌⁴, 艾彬⁵

(1. 郑州大学电气与信息工程学院 郑州 450001; 2. 智能农业动力装备全国重点实验室 洛阳 471032;

3. 中国人民解放军 63891 部队 洛阳 471000; 4. 西北工业大学自动化学院 西安 710072;

5. 郑州畅想高科股份有限公司 郑州 450066)

摘要: 光电成像侦察装备在受到激光干扰时, 成像中会出现干扰光斑。激光干扰光斑会显著降低图像质量并遮挡目标关键信息, 严重影响检测与跟踪系统的性能。针对典型目标场景下的激光干扰图像, 构建了一种基于全局语义学习和显著目标感知的修复网络, 旨在推理出语义合理和目标完整的图像内容。提出了一种门控语义学习机制, 首先通过上下文注意力机制建立干扰区域和已知区域之间的远距离信息相关性并推理干扰区域内容; 然后利用多尺度特征聚合模块在不同感受野上细化推理区域的内容, 实现在干扰区域重建丰富的语义信息; 最后通过门控机制自适应融合已知区域和重建区域特征, 提高修复图像的全局语义一致性。同时, 设计了显著目标一致性损失, 利用基于显著目标掩码的梯度惩罚方法, 从形状和纹理两个方面指导修复网络感知显著目标, 提高修复目标的轮廓清晰度和纹理连贯性。在飞机、桥梁、道路等典型目标场景下的实验结果表明, 提出的网络在生成视觉真实且目标完整的内容方面优于其他方法, 并在面对复杂干扰光斑时, 具有很好的泛化性能。

关键词: 图像修复; 激光干扰; 生成对抗网络; 注意力机制; 显著目标

中图分类号: TH39 **文献标识码:** A **国家标准学科分类代码:** 510.4

Laser jamming image inpainting based on global semantic learning and salient target awareness

Kai Zhiqiang^{1,2}, Miao Xikui³, Ma Tianlei^{1,2}, Feng Bin⁴, Ai Bin⁵

(1. School of Electrical and Information Engineering, Zhengzhou University, Zhengzhou 450001, China; 2. State Key Laboratory of

Intelligent Agricultural Power Equipment, Luoyang 471032, China; 3. Unit 63891 of PLA, Luoyang 471000, China;

4. School of Automation, Northwestern Polytechnical University, Xi'an 710072, China; 5. Zhengzhou Think Freely

Hi-Tech Co., Ltd, Zhengzhou 450066, China)

Abstract: In the context of laser interference in electro-optical imaging reconnaissance equipment, interference spots often appear in the imagery. These laser jamming spots significantly degrade image quality and obscure target information, severely impacting detection and tracking systems' performance. For addressing laser jamming images in typical target scenarios, an inpainting network is developed based on global semantic learning and salient object awareness. A gated semantic learning mechanism is specifically proposed. Initially, a contextual attention mechanism is employed to establish long-range correlations between the interfered and known regions, enabling the inference of content in the interfered regions. Then, a multi-scale feature aggregation module refines the inferred content across different receptive fields, reconstructing rich semantic information in the interfered areas. Finally, a gating mechanism adaptively fuses features from the known and reconstructed regions, enhancing the global semantic consistency of the restored image. Additionally, a salient target consistency loss is designed to guide the inpainting network in perceiving salient targets, improving the sharpness of object contours and texture coherence using a gradient penalty method based on the salient target mask. Experimental results in typical target scenarios such as aircraft, bridges, and roads demonstrate that the proposed network outperforms other methods in generating visually realistic and

收稿日期: 2024-03-25 Received Date: 2024-03-25

* 基金项目: 国家自然科学基金(62373330)、河南省重点研发专项(241111110500)、中原科技创新青年拔尖人才项目和河南省本科高校青年骨干教师培养计划(2023GGJS005)项目资助

complete content, with good generalization performance in dealing with complex interference spots.

Keywords: image inpainting; laser jamming; generative adversarial network; attention mechanism; salient target

0 引言

光电成像侦察装备能够实时获取并记录战场信息,获取最新的战争情报并对态势进行精准判断。然而,光电成像设备在受到激光干扰或损伤后,在图像中会出现饱和和区域无法对部分场景成像。激光干扰光斑对图像关键信息的遮挡,尤其是对显著目标的遮挡,会掩盖图像关键特征,严重影响检测与跟踪系统的性能^[1]。因此,恢复被光斑遮挡的目标特征已成为迫切需求。

迄今为止,有许多研究致力于激光干扰光斑的仿真以及激光干扰图像的效果评估。杨希伟等^[2]在建立形心式自适应跟踪模型的基础上,利用激光干扰光电导引头输出图像的特点,建立了亮斑与亮带干扰模型;袁航等^[3]对激光干扰的饱和串扰效应进行机理分析,建立了饱和串扰效应模型;钮赛赛等^[4]分析了不同波长激光在大气传输中的影响规律以及不同发散角随距离变化的辐照变化规律,建立了高置信度的激光干扰耀斑模型;张阳等^[5]利用一致相邻度熵权的综合赋权方法,建立了光学成像卫星激光干扰效果综合评估模型;孙可等^[6]提出目标区域局部特征和图像质量相结合的激光干扰效果评估算法。这些工作能够有效促进激光干扰图像的评估,同时为激光干扰图像数据库的建立奠定了可行性。

图像修复旨在用语义上合理且视觉上真实的内容填充缺失区域。图像修复的难点是需要保持修复区域与已知区域之间的协调性和语义一致性。近年来,卷积神经网络(convolution neural network, CNN)^[7]因其强大的拟合能力在自然图像任务中大放异彩;生成对抗网络(generative adversarial network, GAN)^[8]利用生成器和鉴别器之间的协同训练,以拟合原始样本分布。基于深度学习的图像修复算法通常采用 CNN 构建生成器和鉴别器,利用 GAN 的思想进行训练,约束生成器生成逼真的修复图像,已被广泛应用于人脸编辑、物体移除、遥感图像信息重建和文化遗产保护等领域。激光干扰图像的一个显著特点是图像局部质量的下降,考虑到局部场景内容与其周围场景内容存在相关性,因此设计基于深度学习的图像修复方法对激光干扰图像的缺失区域进行修复和还原在技术上可行。

基于深度学习的图像修复方法按照网络结构可以分为基于 CNN、基于 Transformer 和基于扩散概率模型 3 类。Pathak 等^[9]提出了第 1 个基于 CNN 的修复模型——上下文编码器,通过特征学习,根据上下文内容对缺失区域进行语义修复;陈哲等^[10]提出了一种基于梯度先验的水

下图像恢复方法,能够有效抑制水下图像噪声并提高清晰度;陶镛泽等^[11]利用长短期记忆网络对原子力显微镜扫描图像进行复原,大大提高了测量准确度;马敏等^[12]提出了一种多尺度自适应特征聚合网络以重建电容层析成像图像,能够极大地减少伪影现象;Wang 等^[13]利用动态选择机制避免缺失区域中无用信息的干扰,并将可变形卷积与区域机制结合,使网络灵活地从不同位置学习信息;Zhu 等^[14]提出掩码感知网络,可以有效学习编码阶段缺失区域的多尺度信息,并引入了多种损失以提高修复效果;Wu 等^[15]利用局部二元模型学习为修复网络引入结构先验信息,并设计了多级损失以提高训练过程的稳定性;Zhang 等^[16]首次将图像修复用于由于传感器故障和天气恶劣导致的遥感图像信息缺失问题,提出了一个统一的多源数据框架,以提高修复的准确性和一致性;Du 等^[17]提出一种由粗到细的修复网络,并结合双层空间注意力机制解决大面阵 CCD 拼接和硬件损坏导致的遥感影像信息缺失问题;Shao 等^[18]提出了一种基于 GAN 的统一框架,能够利用单源输入解决各种遥感图像信息缺失问题;Zuo 等^[19]首次将对比学习引入图像修复任务,并利用分割混淆对抗训练方法提高修复图像的全局一致性;Xiang 等^[20]提出了一种使用双重一致性注意力的结构感知多视角图像修复方法,能够减轻修复图像的边界伪影;Liu 等^[21]提出了 SynerFill,可以同时修复 RGB 图像和深度图像。基于 CNN 的方法具有强大的局部信息处理能力,但全局信息处理能力不足。近年来,因其强大的处理全局信息和长距离依赖的能力,基于 Transformer 的方法展现了优异的性能。Wan 等^[22]提出了第 1 个基于 Transformer 的图像修复方法,首先利用 Transformer 生成多元相关结构和粗糙纹理,然后利用 CNN 生成局部细节,提高图像的保真度;Yu 等^[23]设计了双向自回归 Transformer 学习回归分布,同时结合 Bert (bidirectional encoder representations from transformers) 等语言模型对缺失区域的上下文进行双向建模,以生成多样化的修复图像并提高修复性能;Huang 等^[24]提出了 Spa-former,在保留 Transformer 的远程建模能力的同时,减轻计算负担。除此之外,基于扩散概率模型的方法因其强大的图像生成能力大放异彩。Song 等^[25]提出一种基于分数的随机微分方程进行图像生成,通过缓慢添加噪声将复杂的数据分布平滑地转化为已知的先验分布,然后利用随机微分方程的逆过程缓慢去除噪声,将先验分布转化为已知分布;Lugmayr 等^[26]利用扩散概率模型作为生成先验,然后在反向扩散迭代过程对已知区域进行采样调节生成过程,大大提高了模型的修复质量和对掩

码的泛化能力;Corneanu 等^[27]利用提出的传播模块在潜在空间执行前向-后向融合步骤,以生成高质量的修复图像。

基于深度学习的图像修复算法取得了显著进展,然而,仍存在一些挑战。基于 CNN 和 Transformer 的方法虽然可以进行语义修复,但是由于缺乏足够的约束,这些方法有时会出现明显的伪影,例如棋盘状纹理和不正确的语义。基于扩散概率模型的新兴方法能够生成高质量的图像,但是这种方法目前修复过程缓慢,不适用于实时修复场景。为了满足检测与识别系统的实时性和准确性要求,激光干扰图像修复模型需要在快速推理的同时,保持修复图像的全局语义合理性以及修复目标的局部纹理连贯性。因此,本文基于 CNN 设计了具有多级门控注意力机制的生成器网络,利用 CNN 的局部特征提取能力和门控语义学习机制的全局语义学习能力,在快速推理的同时提高修复图像的全局语义合理性;利用分割一切网络(segment anything model, SAM)^[28]构建了局部鉴别器网络,通过结合显著目标一致性损失指导修复网络生成更加精细的局部细节,提高修复目标的局部纹理连贯性。

本文采用具有跳跃连接的编码器-解码器结构作为生成器,并将普通卷积替换为门控卷积,以更有效地提取次光斑区域特征。此外,为了提升修复图像的全局语义一致性,提出门控语义学习机制并将其嵌入到生成器中,以适应不同尺寸的激光干扰光斑,同时在不同尺度上关注远距离信息并重建具有全局结构的语义对象。为了保持显著目标完整性,通过 SAM 得到显著目标掩码,建立了局部鉴别器并提出了显著目标一致性损失函数,对修复图像中显著目标区域的纹理连贯性和轮廓清晰度施加约束。

本文设计了具有全局和局部鉴别器的端到端图像修复网络,以对不同典型目标场景下的激光干扰图像进行修复。提出了门控语义学习机制,在多个尺度上捕获丰富的上下文信息并进行特征集成,以学习图像全局语义信息,提高修复图像的全局语义一致性。提出了显著目标一致性损失函数,利用基于显著目标掩码的梯度惩罚方法,约束修复网络以隐式地方式感知显著目标,提高修复目标的轮廓清晰度和纹理连贯性。

1 激光干扰图像修复算法设计

1.1 激光光斑生成器

利用文献[4]的激光干扰耀斑模型模拟不同干扰激光功率密度下的激光干扰光斑图像如图 1 所示。其中,入射光强高于探测器饱和阈值的区域为饱和区域,灰度值为 255;仍存在原始图像一部分特征的区域为次光斑

区域,灰度值在 0~255。将激光干扰光斑图像归一化得到软掩码 M 。本文将软掩码 M 注入到感兴趣的原始图像区域,以模拟激光干扰图像:

$$I_m = I_{gt} \odot (1 - M) \quad (1)$$

式中: I_m 代表模拟激光干扰图像; I_{gt} 代表原始图像; $\odot$ 代表逐元素乘积; M 代表软掩码。




图 1 不同功率下的真实与模拟激光干扰光斑

Fig. 1 Real-world and simulated laser jamming spots under different power levels

通过使用软掩码生成器,可以将不同尺寸的激光干扰光斑注入到图像的随机位置,从而模拟不同入射功率和不同入射位置的激光干扰光电成像系统后的激光干扰图像。

1.2 图像修复网络整体框架

如图 2 所示,图像修复网络由 2 个部分组成,生成器 G 和鉴别器 D 。在训练阶段,生成器 G 基于已知区域信息,推理出激光干扰图像中的缺失区域,并生成修复图像。鉴别器 D 评估修复图像是否与真实图像相似。生成器和鉴别器之间通过交替训练的方式进行参数优化,以不断提高生成器的修复能力,使修复图像更加真实和自然。生成器和鉴别器的交替优化过程如图 3 所示。在测试阶段,仅使用生成器 G ,这使得本文网络为端到端网络。

生成器 G 有 2 个输入:激光干扰图像 I_m 和软掩码 M 。生成器采用具有跳跃连接的编码器-解码器结构。编码器和解码器由一个普通卷积层和一些级联的步长为 2 的门控卷积层组成。编码器将激光干扰图像下采样至高维语义空间;解码器将高维特征上采样为修复图像 I_{pred} 。此外,两个空间分辨率分别为 32×32 和 64×64 的门控语义学习机制被嵌入到解码器中,以关注远距离信息并重建具有全局结构的语义对象。

鉴别器 D 包含全局鉴别器和局部鉴别器,输入分别是修复图像 I_{pred} 和显著目标图像 $\hat{I}_t$ 。其中显著目标图像




图 2 图像修复网络结构

Fig. 2 The network structure of image inpainting




图 3 生成器和鉴别器的训练过程

Fig. 3 The training process of generator and discriminator

$\hat{I}_t$ 由 SAM 生成的显著目标掩码 M_t 和修复图像 I_{pred} 逐元素相乘得到:

$$\hat{I}_t = I_{pred} \odot S(I_{gt}) \quad (2)$$

式中: $\odot$ 代表逐元素乘积; $S(\cdot)$ 代表 SAM 网络。

全局鉴别器和局部鉴别器分别关注图像的全局结构和显著目标的完整性,以优化对抗损失 $\mathcal{L}_{adv}$ 。此外,本文还采用了常用的感知损失 $\mathcal{L}_{perc}$ 、重构损失 $\mathcal{L}_{rec}$ 和设计的显著目标一致性损失 $\mathcal{L}_{shape}$ 和 $\mathcal{L}_{texture}$ 进行联合训练,分别指导全局语义级别和局部纹理级别的一致性关系学习,迫使生成器产生视觉真实、目标完整的修复图像。

1.3 门控语义学习机制

为了更好地学习全局语义信息,本文提出了门控语义学习机制,并将其部署在解码器中分辨率为 32×32 和 64×64 的位置。这是因为高级特征图中含有丰富的语义信息,而低级特征图主要包含边缘、颜色和纹理等基本视

觉特征。门控语义学习机制利用高级特征图作为输入,能够捕获未知区域和已知区域之间的语义相关性,通过在多个尺度对语义信息编码并利用门控机制融合原始与重建特征,以生成全局语义一致的修复图像。通过在解码器的低维特征空间对纹理、边缘等图像特征进行进一步细化,促使修复图像中清晰边界和连贯纹理的生成。门控语义学习机制由像素级上下文注意力机制、多尺度特征聚合模块和门控机制组成。

1) 像素级上下文注意力机制

如图 4 所示,本文采用 Deepfill-v2^[29] 中提出的上下文注意力模块捕获缺失区域和已知区域之间的语义相关性并用于缺失区域的重建。不同的是,对于背景特征,本文提取像素级的 1×1 补丁以更好的学习缺失区域边缘特征。




图 4 像素级上下文注意力机制

Fig. 4 Pixel-wise contextual attention mechanism

对于输入特征图 F_{in} ,从背景中提取 1×1 像素级补

丁,计算背景特征与前景特征的余弦相似度:

$$S_{i,j} = \left\langle \frac{f_i}{\|f_i\|}, \frac{b_j}{\|b_j\|} \right\rangle \quad (3)$$

式中: f_i 和 b_j 分别表示前景和背景特征图的第 i 个和第 j 个补丁; $S_{i,j}$ 表示前景和背景对应补丁的余弦相似度。

为了反映前景特征补丁对背景特征补丁的关注程度,在通道维度上使用 softmax 函数进行归一化,以得到每个补丁的注意力分数:

$$\tilde{S}_{i,j} = \frac{\exp(S_{i,j})}{\sum_{j=1}^N \exp(S_{i,j})} \quad (4)$$

式中: $\tilde{S}_{i,j}$ 表示归一化后的注意力分数; N 代表通道维度上补丁的总数。

为了保持前景特征和背景特征的一致性,使用大小为 k 的滑动窗口进行注意力传播:

$$\hat{S}_{i,j} = \sum_{n \in [-k, \dots, k]} \tilde{S}_{i+n, j+n} \quad (5)$$

式中: $\hat{S}_{i,j}$ 表示最终注意力图。

根据注意力图,利用背景补丁重建特征图:

$$\tilde{f}_i = \sum_{j=1}^N f_j \cdot \hat{S}_{i,j} \quad (6)$$

式中: $\tilde{f}_i$ 是重建特征图 F_{rec} 的第 i 个补丁; N 代表通道维度上补丁的总数。

2) 多尺度特征聚合模块

为了保持图像全局语义一致性,本文设计了多尺度特征聚合模块,在多个尺度上编码丰富的语义特征,如图5所示。




图5 多尺度特征聚合模块

Fig. 5 Multi-scale feature aggregation module

首先将像素级上下文注意力模块得到的重建特征图 F_{rec} 输入到卷积层和 softmax 层,得到像素级权重图:

$$W = \text{softmax}(\text{Conv}(F_{rec})) \quad (7)$$

然后,在通道维度上将 W 分解为 3 个不同的权重图,以分别关注不同尺度上的语义特征:

$$W^1, W^3, W^5 = \text{Slice}(W) \quad (8)$$

式中: W 表示像素级权重图; W^i 表示不同维度的权重图, $i \in \{1, 3, 5\}$; Slice 代表在通道维度分解特征图。

卷积核的尺寸影响着感受野的大小,通过具有不同卷积核尺寸的卷积层提取多尺度语义特征:

$$F_{rec}^k = \text{Conv}_k(F_{rec}) \quad (9)$$

式中: $\text{Conv}_k(\cdot)$ 表示卷积核尺寸为 k 的卷积层, $k \in \{1, 3, 5\}$ 表示不同尺度的重建特征图。

最后,将多尺度语义特征和权重图加权融合后,得到聚合特征:

$$F_{agg} = (F_{rec}^1 \odot W^1) \oplus (F_{rec}^3 \odot W^3) \oplus (F_{rec}^5 \odot W^5) \quad (10)$$

式中: $\odot$ 代表逐元素乘积; $\oplus$ 代表逐元素相加; F_{agg} 代表多尺度聚合模块输出的多尺度聚合特征。

3) 门控机制

现有的注意力方法简单的将输入特征与注意力特征进行合并,而没有考虑特征合并过程需要以自适应的方式进行,即原始特征和注意力特征对于不同的图像应该赋予不同的权重。本文利用门控机制有选择地增强原始特征细节并抑制其他区域,以获得全局语义一致的特征,如图6所示。




图6 门控语义学习机制

Fig. 6 Gate semantic learning mechanism

将原始特征 F_{in} 输入到卷积核尺寸为 1×1 的卷积层中,然后通过一个 sigmoid 层获得空间门控图,通过空间门控图重建加权原始特征:

$$F_g = F_{in} \odot \sigma(\text{Conv}(F_{in})) \quad (11)$$

式中: $\odot$ 代表逐元素乘积; $\sigma(\cdot)$ 代表 sigmoid 函数。

在获得细化的原始特征后,将其与经过 PCA 和 MFA 的多尺度特征聚合特征 F_{agg} 连接在一起,然后通过一个卷积层得到和原始特征图同尺寸的门控注意力特征图 F_{out} :

$$F_{out} = \text{Conv}(F_g \parallel F_{agg}) \quad (12)$$

式中: $\parallel$ 代表在通道维度合并特征图。

1.4 损失函数设计

由于激光干扰通常出现在目标区域,以干扰后续目标检测系统的识别性能,因此,保持修复图像中显著目标的完整性对激光干扰图像修复至关重要。本文利用基于显著目标掩码的梯度惩罚方法,提出了显著目标一致性损失函数。如图7所示,显著目标一致性损失包含形状一致性损失和纹理一致性损失,从显著目

标的形状和纹理两个方面,以隐式的方式实现显著目标感知和关键信息学习。显著目标掩码可以为显著目标信息的重构提供空间指导,以指导网络更好地重建

显著目标;特定的损失函数被用来引导特征的提取和重建,确保在修复图像中,显著目标的形状和纹理与原始图像保持一致。




图 7 显著目标一致性损失函数

Fig. 7 Salient object coherent loss function

形式上, I_{gt} 表示原始图像, I_{pred} 表示修复图像, 通过 SAM^[28] 获得显著目标掩码 $M_t = S(I_{gt})$, 并得到原始图像显著目标 $I_t = I_{gt} \odot M_t$, 修复图像显著目标 $\hat{I}_t = I_{pred} \odot M_t$, 通过梯度操作得到显著目标轮廓 $M_s = \nabla M_t$, 原始图像边缘图 $I_{grad} = \nabla I_{gt}$, 修复图像边缘图 $\hat{I}_{grad} = \nabla I_{pred} \odot M_t$.

1) 重构损失

重构损失关注全局图像一致性, 计算 I_{pred} 与 I_{gt} 的 ℓ_1 距离。

$$\mathcal{L}_{rec} = \mathbb{E}[\|I_{gt} - I_{pred}\|_1] \quad (13)$$

式中: $\mathbb{E}$ 代表期望值运算符, 下同。

2) 形状一致性损失

为了限制 I_{pred} 与 I_{gt} 具有相同的军事目标轮廓, 本文提出形状一致性损失, 计算 I_{pred} 与 I_{gt} 显著目标轮廓的 ℓ_1 距离。

$$\mathcal{L}_{shape} = \mathbb{E}[\|M_s \odot (I_{grad} - \hat{I}_{grad})\|_1] \quad (14)$$

3) 纹理一致性损失

引入纹理一致性损失增强对网络的约束, 限制 I_{pred} 与 I_{gt} 的显著目标区域具有相同的像素分布, 以指导生成器的优化。

$$\mathcal{L}_{texture} = \mathbb{E}[\|M_s \odot (I_{gt} - I_{pred})\|_1] \quad (15)$$

此外, 本文还采用图像修复领域常用的感知损失^[30] $\mathcal{L}_{perc}$ 和对抗损失 $\mathcal{L}_{adv}$ 进行联合训练, 以呈现视觉真实和语义合理的结果。最终的联合损失如下:

$$\mathcal{L} = \lambda_1 \mathcal{L}_{rec} + \lambda_2 \mathcal{L}_{shape} + \lambda_3 \mathcal{L}_{texture} + \lambda_4 \mathcal{L}_{perc} + \lambda_5 \mathcal{L}_{adv} \quad (16)$$

式中: $\lambda_1 \sim \lambda_5$ 为超参数。

2 实验验证

2.1 数据集

本文的修复框架需要一个包含大量典型目标图片的训练数据集, 但是目前没有已公开的针对典型目标(例如, 飞机、桥梁、公路等)的图像修复数据集。因此选择收集已公开的遥感数据集的典型目标图片, 并构建新的数据集作为替代方案。

本文收集了来自 UC Merced Land Use Dataset^[31]、WHU-RS19^[32]、SIRI-WHU^[33]、PatternNet^[34]、AID^[35]、NWPU-RESISC45^[36]和RSI-CB256^[37]遥感数据集的关于机场、机场跑道、飞机、桥梁以及其他军事目标的图片构建了一个新的数据集, 命名为 LJA (laser jamming of airplane) 和 LJABR (laser jamming of airport runway, bridge and road)。由于飞机图像数目较少, 将 HRPlanes 数据集^[38]图片中含有飞机目标的区域裁剪为 256×256 大小, 作为额外的飞机数据集图片。

最终, LJA 数据集包含了 8 846 张不同种类的飞机图像, LJABR 包含了 4 659 张桥梁图像; 1 792 张机场和机场跑道图像; 5 467 张公路、骨干道路等图像。按照 8:2 的比例将数据集分为训练集和测试集, 数据集分布情况如表 1 所示。

表 1 军事目标图像数据集分布情况

Table 1 The distribution of military image dataset		
数据集	训练集	测试集
LJA	7 331	1 515
LJABR	9 534	2 385

2.2 实验设置与基准

使用构建的 LJA 和 LJABR 数据集对本文模型进行实验和评估。对于模型训练,随机采样 8 张图像及对应的显著目标掩码,并在每个小批量中随机创建相应的干扰光斑掩码,干扰光斑的饱和区域半径为 30 pixels ~ 50 pixels,所有的图片和掩码均为 256×256 大小。使用 Adam 优化器, momentum 选择 $\beta_1 = 0.5$ 和 $\beta = 0.99$, 学习率设置为 0.002, 训练 150 个 epoch。模型训练和测试使用的环境参数如表 2 所示。

表 2 实验环境参数

Table 2 Experimental environment parameters	
实验系统	Windows 10
CPU	3.00 GHz Intel(R) Xeon(R) Gold 6 248 R
GPU	NVIDIA Quadro RTX6000
内存	32 GB
开发环境	Python3.8
深度学习框架	Pytorch
CUDA 版本	10.2

对于式(16)定义的超参数,由于重构损失、感知损失和对抗损失为图像修复领域常用的损失函数,本文参考文献[39]方法将其对应的超参数凭经验设置为 $\lambda_1 = 20$ 、 $\lambda_4 = 10$ 和 $\lambda_5 = 1$ 。

对比实验的 5 种典型深度学习图像修复模型的缩写和简介如下,为了公平比较,使用相同的数据集和光斑并按照每项研究中的相同实验设置对这些模型重新训练。

1) **Pconv**^[40] 提出了部分卷积,以解决普通卷积将所有输入像素视为有效像素的问题。

2) **Deepfill-v2**^[29] 是一个由粗到细模型,利用可学习的动态特征选择机制改进部分卷积。

3) **MEDFE**^[41] 提出了互编码器-解码器对受损图像的结构和纹理进行联合修复。

4) **CTSDG**^[39] 以耦合的方式对结构约束的纹理和纹理引导的结构重建进行建模。

5) **CoordFill**^[42] 利用快速傅里叶卷积生成空间自适应参数,并作为多层感知机的参数和偏差以修复图像。

2.3 评估指标

本文使用 4 个指标来评估模型的性能,分别是:峰值信噪比(peak signal-to-noise ratio, PSNR)、结构相似度(structural similarity index measure, SSIM)^[43]、学习感知图像块相似性(learned perceptual image patch similarity, LPIPS)^[44]和弗雷切特起始距离(Frechet inception distance, FID)^[45]。PSNR 和 SSIM 广泛应用与图像处理领域,衡量像素级的图像保真度。由于它们假定像素独立,因此可能会对感知上不合理的结果标记有利的分数。而 FID 和 LPIPS 测量高级特征的图像保真度,更符合人类的视觉感知,也更适合测量模型对大区域受损图像的修复性能。

2.4 定量比较

在 LJA 和 LJABR 的测试集上进行定量比较,以评估本文方法的有效性。随机抽取一个激光干扰光斑图像作为掩码,掩码具有特定的光斑面积与图像面积百分比(例如,30%)。为了公平比较,对所有的对比方法使用相同的测试掩码。

定量比较结果通过对测试集中所有图片的评估结果取平均值得到,如表 3 和 4 所示。在光斑比例为 30% 和 40% 时,提出的模型在所有指标方面都优于对比方法,尤其是 FID。在光斑比例为 20% 时, LPIPS 和 FID 指标也取得了最优结果,而 PSNR 和 SSIM 与 CTSDG 非常相近。随着光斑比例增大,本文方法明显优于其他基准,在最具挑战的光斑比例为 40% 时, FID 指标相对于次优的 CTSDG 提高了 49.37%。FID 已被验证更接近人类感知。因此可以得出结论,本文方法在重建全局一致性的内容方面优于目前先进的深度学习修复模型。

表 3 在 LJA 数据集上的定量比较结果
Table 3 Quantitative results on LJA dataset

算法	光斑比例 ~ 20%				光斑比例 ~ 30%				光斑比例 ~ 40%			
	SSIM	PSNR	LPIPS	FID	SSIM	PSNR	LPIPS	FID	SSIM	PSNR	LPIPS	FID
PConv	0.954	28.70	0.357	16.17	0.922	25.42	0.519	30.69	0.890	24.09	0.701	45.21
Deepfill-v2	0.961	29.16	0.634	27.13	0.936	26.49	0.526	43.22	0.907	24.38	0.714	66.53
MEDFE	0.950	27.18	0.358	20.86	0.921	24.79	0.517	35.14	0.884	22.91	0.703	53.43
CTSDG	0.977	32.35	0.286	10.55	0.956	29.00	0.423	19.22	0.927	26.37	0.614	38.69
CoordFill	0.951	25.93	0.490	30.09	0.920	23.63	0.730	48.76	0.882	21.91	0.993	72.91
本文	0.976	32.13	0.278	7.55	0.956	29.01	0.409	12.17	0.930	26.50	0.566	19.59

表 4 在 LJABR 数据集上的定量比较结果
Table 4 Quantitative results on LJABR dataset

算法	光斑比例~20%				光斑比例~30%				光斑比例~40%			
	SSIM	PSNR	LPIPS	FID	SSIM	PSNR	LPIPS	FID	SSIM	PSNR	LPIPS	FID
PConv	0.953	32.77	0.312	8.80	0.925	30.38	0.450	13.85	0.893	28.54	0.613	20.97
Deepfill-v2	0.966	35.12	0.361	13.06	0.945	32.58	0.505	20.96	0.920	30.54	0.667	30.40
MEDFE	0.948	31.77	0.363	10.59	0.917	29.40	0.505	16.31	0.882	27.57	0.669	23.63
CTSDG	0.975	36.27	0.251	6.20	0.954	33.22	0.362	11.66	0.927	30.67	0.540	20.53
CoordFill	0.955	29.47	0.451	14.63	0.924	26.93	0.658	22.65	0.885	24.93	0.895	32.56
本文	0.976	35.82	0.256	4.76	0.958	33.40	0.354	7.14	0.933	31.12	0.489	11.49

2.5 定性比较

除了定量比较之外,本文还与上述的图像修复模型在 LJA 和 LJABR 测试集上进行定性比较,使用将激光光斑注入到目标区域的测试图像,以证明模型对显著目标修复的优越性。在 LJA 和 LJABR 数据集上训练的对应模型的修复结果分别如图 8、9 所示。结果表明,本文方法取得了视觉上最优的效果,保持了显著目标的完整性和与周围图像的一致性。PConv 和 MEDFE 往往生成扭曲的纹理;Deepfill-v2 修复结果存在明显的伪影;CTSDG 无法保持显著目标的完整性,

在目标边缘有明显的结构扭曲;CoordFill 倾向于生成背景纹理来填充缺失区域;利用门控语义学习机制和显著目标一致性损失,修复模型能够重建语义一致的全局结构且纹理连贯的显著目标区域,并在复杂的场景中产生清晰合理的纹理。例如,对于图 8 中飞机图像,生成了合理的飞机结构,并且保持了颜色一致性;对于图 9 中的桥梁和道路图像,即使是比较大的光斑区域,本文方法仍然重建了具有连贯纹理且清晰的内容,在显著目标边缘处没有明显的伪影,有利于跟踪系统的检测。




图 8 在 LJA 数据集上的定性评估结果
Fig. 8 Qualitative results on LJA dataset




图 9 在 LJAIR 数据集上的定性评估结果

Fig. 9 Qualitative results on LJAIR dataset

2.6 泛化实验

由于真实场景的激光干扰光斑是多样化的,为了评估模型对训练阶段未见过的光斑的泛化性能,本文使用文献[1]的 3 种不同的真实光斑进行了定性实验,如

图 10 所示。本文方法对真实光斑的泛化性能最好,生成了颜色和轮廓更真实的飞机目标。CTSDG 在面对多样化的真实光斑时表现不佳,修复图像中存在明显的光斑伪影,并且没有生成合理的飞机轮廓;CoordFill 在面对




图 10 在真实光斑上的定性结果

Fig. 10 Qualitative results on real-world laser spots

多样化的光斑时,能够恢复真实的背景区域,且在光斑边缘处没有产生显著的伪影。但是,当光斑覆盖目标较大区域时,CoordFill 通过会生成语义混乱的修复目标,在飞机区域产生了背景纹理;而本文的方法即使在多样化且复杂的光斑情况下,仍然能够恢复纹理和轮廓更加合理的飞机目标,仅在光斑轮廓区域产生了部分伪影。

2.7 消融实验

为了评估设计的显著目标一致性损失函数对网络性能的影响,本文对式 (16) 的超参数进行消融研究。所有实验均在光斑比例为 30% 的 LJA 数据集上进行。实验结果如表 5 所示,显著目标一致性损失的引入显著提高了修复性能。其中形状一致性损失能够有效提高修复图像的结构相似度,而纹理一致性损失能够提高图像质量,但

是过高的 λ_3 值会导致修复图像在特征层面相似度下降。因此,本文选取超参数的值为 $\lambda_2=0.1, \lambda_3=5$ 。

为了验证关键组件对本文模型的贡献,本文训练了一系列变体模型:1) w/o GSLM,其中门控语义学习机制从网络的解码器中删除;2) w/o $\mathcal{L}_{pere}$ 、w/o $\mathcal{L}_{shape}$ 和 w/o $\mathcal{L}_{texture}$,它们分别从整体损失中去除了感知损失、形状一致性损失和纹理一致性损失。本文在所有实验设置下保留基于生成对抗模型的图像修复网络的必备损失重构损失 $\mathcal{L}_{rec}$ 和对抗损失 $\mathcal{L}_{adv}$ 。本文在 LJA 数据集上训练上述变体模型。

变体模型和完整模型之间的定量与定性比较结果如表 6 和图 11 所示。结果表明,所有变体模型的性能均次于完整模型。当失去感知损失的指导(w/o $\mathcal{L}_{perc}$)时,修复的图像在视觉上是不真实的,这是由于重构损失往往会使生成的像素趋于平均值,修复图像区域出现模糊;对于没有形状一致性损失(w/o $\mathcal{L}_{shape}$)的情况,修复的区域有着比较连贯的纹理,但是当光斑遮挡大面积飞机目标时,模型很难推理出完整的飞机区域;当缺失纹理一致性损失(w/o $\mathcal{L}_{texture}$)时,修复的目标区域存在明显的视觉伪影,纹理看起来不真实;对于缺少门控语义学习机制(w/o $\mathcal{L}_{GSLM}$)的情况,修复的目标出现了明显的语义混乱,例如将飞机目标重建为地面或者出现明显的色彩差异;而完整模型既生成了轮廓清晰、纹理合理的飞机目标又能推理出缺失区域正确的颜色,实现了全局语义一致和局部纹理连贯的修复。

表 5 式 (16) 中超参数 λ_2 和 λ_3 的消融实验
Table 5 Ablation studies of the hyperparameter λ_2 and λ_3 in equation (16)

λ_2	λ_3	SSIM	PSNR	LPIPS	FID
0	0	0.921	26.79	0.517	17.07
0.01	0	0.943	27.32	0.464	15.44
0.01	1	0.953	28.63	0.418	13.98
0.1	5	0.956	29.01	0.409	12.17
0.1	10	0.954	28.74	0.426	14.69

表 6 本文模型重要组件和损失函数的消融实验

Table 6 Ablation studies on critical architecture components and loss functions of our model

变体模型	CLSM	$\mathcal{L}_{pere}$	$\mathcal{L}_{shape}$	$\mathcal{L}_{texture}$	SSIM	PSNR	LPIPS	FID
w/o GSLM		✓	✓	✓	0.953	28.53	0.427	14.37
w/o $\mathcal{L}_{pere}$	✓		✓	✓	0.943	27.74	0.473	16.62
w/o $\mathcal{L}_{shape}$	✓	✓		✓	0.952	28.67	0.414	12.55
w/o $\mathcal{L}_{texture}$	✓	✓	✓		0.949	28.15	0.441	14.33
Full	✓	✓	✓	✓	0.956	29.01	0.409	12.17




图 11 消融实验
Fig. 11 Ablation study

2.8 模型评估

本文还从参数数量、和单张图像推理的 GPU 内存占用和推理时间来评估各个模型的计算复杂度,结果如表 7 所示。Repaint 基于扩散概率模型,参数量最多,推理时间过长,不满足激光干扰图像修复任务的实时性要求。Deepfillv2 模型具有最小的参数量和 GPU 占用,但是其使用了两阶段模型,增加了推理时间。CTSDG 模型 GPU 占用最高,因为其在低维特征空间进行了大量注意力计算。本文模型使用显著目标一致性损失训练网络,在推理阶段仅使用生成器,因此推理速度更快,在参数量和 GPU 占用方面也取得了很好的平衡。

表 7 模型计算复杂度数据

Table 7 Model computational complexity statistics			
模型	#参数量/ $\times 10^6$	GPU 占用/GB	推理时间/s
PConv	25.78	2.1	0.072 4
Deepfillv2	4.05	1.0	0.069 1
MEDEF	130.32	4.3	0.163 1
CTSDG	52.14	5.8	0.364 8
CoordFill	34.40	1.3	0.096 9
Repaint *	552.81	4.0	337.819 0
本文	57.58	1.8	0.036 8

注: * 代表扩散模型

3 结 论

提出了一种基于全局语义学习和显著目标感知的端到端激光干扰图像修复网络,用于在典型目标场景下重建激光干扰图像的受损区域。提出了门控语义学习机制,以学习远距离信息特征并编码丰富的语义信息,从而提高图像的全局语义一致性;设计了显著目标一致性损失,以确保修复图像中显著目标的轮廓完整性和纹理连贯性。为了评估方法的有效性,构建了典型目标数据集,并进行了广泛的评估。实验结果表明,本文模型对修复具有不同半径和位置的光斑的激光干扰图像具有广泛适用性,并在生成视觉真实和目标完整的修复图像方面优于现有的深度学习方法。在未来的工作中,将改进激光干扰图像的仿真,以模拟更真实的激光干扰效果,并进一步优化模型,以提升对复杂目标场景的修复性能。

参考文献

[1] REN L J. Research on laser interference effect analysis and evaluation technology of photoelectric imaging

system[D]. Wuhan: Huazhong University of Science & Technology, 2019.

[2] 杨希伟, 童忠诚, 汪亚夫, 等. 激光干扰光电成像导引头的建模与仿真[J]. 红外与激光工程, 2011, 40(7): 1243-1248.

YANG X W, TONG ZH CH, WANG Y F, et al. Modeling and simulation of laser jamming for electro-optical imaging guided seeker[J]. Infrared and Laser Engineering, 2011, 40(7): 1243-1248.

[3] 袁航, 王晓蕊, 李丹翠, 等. 激光辐照 TDI-CCD 相机饱和串扰效应及侧斑建模仿真分析[J]. 光子学报, 2017, 46(12): 21-30.

YUAN H, WANG X R, LI D C, et al. Modeling and simulation analysis for crosstalk effects and secondary spots of laser irradiation on TDI-CCD camera[J]. Acta Photonica Sinica, 2017, 46(12): 21-30.

[4] 钮赛赛, 印剑飞, 曹卫卫, 等. 红外成像系统激光干扰耀斑仿真建模[J]. 红外与激光工程, 2017, 46(S1): 19-23.

NIU S S, YIN J F, CAO W W, et al. Simulation modeling of laser jamming spot in infrared imaging system[J]. Infrared and Laser Engineering, 2017, 46(S1): 19-23.

[5] 张阳, 刘湘伟, 郝成民. 基于图像特征相关度的激光干扰卫星效果评估[J]. 激光与红外, 2017, 47(3): 352-356.

ZHANG Y, LIU X W, HAO CH M. Effect evaluation of laser jammed satellite based on correlation degree of image feature[J]. Laser & Infrared, 2017, 47(3): 352-356.

[6] 孙可, 叶庆, 孙晓泉. 目标区域局部特征和局部图像质量相结合的激光干扰效果评估[J]. 国防科技大学学报, 2020, 42(1): 24-30.

SUN K, YE Q, SUN X Q. Laser dazzling effect assessment based on local features and image quality in target region[J]. Journal of National University of Defense Technology, 2020, 42(1): 24-30.

[7] LECUN Y, BOSER B, DENKER J S, et al. Back-propagation applied to handwritten zip code recognition[J]. Neural Computation, 1989, 1(4): 541-551.

[8] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]. Proceedings of the 27th International Conference on Neural Information

- Processing Systems, 2014, 2: 2672-2680.
- [9] PATHAK D, KRAHENBUHL P, DONAHUE J, et al. Context encoders: Feature learning by inpainting [C]. Proceedings of the 29th IEEE Conference on Computer Vision and Pattern Recognition, 2016: 2536-2544.
- [10] 陈哲, 周旭, 沈洁, 等. 基于梯度先验的水下图像恢复[J]. 仪器仪表学报, 2022, 43(8): 39-46.
CHEN ZH, ZHOU X, SHEN J, et al. Underwater image restoration based on gradient prior[J]. Chinese Journal of Scientific Instrument, 2022, 43(8): 39-46.
- [11] 陶镛泽, 胡佳成, 施玉书, 等. 基于 LSTM 的矩形纳米光栅 AFM 图像复原方法[J]. 仪器仪表学报, 2021, 42(7): 50-57.
TAO Y Z, HU J CH, SHI Y SH, et al. AFM image restoration method of rectangular nano grating based on LSTM [J]. Chinese Journal of Scientific Instrument, 2021, 42(7): 50-57.
- [12] 马敏, 梁雅蓉. 基于多尺度自适应特征聚合网络的 ECT 图像重建[J]. 仪器仪表学报, 2023, 44(6): 264-272.
MA M, LIANG Y R. ECT image reconstruction based on multi-scale adaptive feature aggregation network [J]. Chinese Journal of Scientific Instrument, 2023, 44(6): 264-272.
- [13] WANG N, ZHANG Y P, ZHANG L F. Dynamic selection network for image inpainting [J]. IEEE Transactions on Image Processing, 2021, 30: 1784-1798.
- [14] ZHU M Y, HE D L, LI X, et al. Image inpainting by end-to-end cascaded refinement with mask awareness[J]. IEEE Transactions on Image Processing, 2021, 30: 4855-4866.
- [15] WU H W, ZHOU J T, LI Y M. Deep generative model for image inpainting with local binary pattern learning and spatial attention[J]. IEEE Transactions on Multimedia, 2022, 24: 4016-4027.
- [16] ZHANG Q, YUAN Q Q, ZENG CH, et al. Missing data reconstruction in remote sensing image with a unified spatial-temporal-spectral deep convolutional neural network [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(8): 4274-4288.
- [17] DU Y, HE J, HUANG Q, et al. A coarse-to-fine deep generative model with spatial semantic attention for high-resolution remote sensing image inpainting [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60(1): 1-13.
- [18] SHAO M, WANG CH, ZUO W M, et al. Efficient pyramidal GAN for versatile missing data reconstruction in remote sensing images [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-14.
- [19] ZUO ZH W, ZHAO L, LI AI L, et al. Generative image inpainting with segmentation confusion adversarial training and contrastive learning[C]. Proceedings of the 37th AAAI Conference on Artificial Intelligence, 2023, 3(2): 3888-3896.
- [20] XIANG H, MIN W, HAN Q, et al. Structure-aware multi-view image inpainting using dual consistency attention[J]. Information Fusion, 2024, 104: 102174.
- [21] LIU K H, ZHANG Y Q, XIE Y T, et al. SynerFill: A synergistic RGB-D image inpainting network via fast fourier convolutions[J]. IEEE Transactions on Intelligent Vehicles, 2024, 9(1): 69-78.
- [22] WAN Z Y, ZHANG J B, CHEN D D, et al. High-fidelity pluralistic image completion with transformers[C]. Proceedings of the 2021 IEEE/CVF International Conference on Computer Vision, 2021: 4692-4701.
- [23] YU Y CH, ZHAN F N, WU R L, et al. Diverse image inpainting with bidirectional and autoregressive transformers [C]. Proceedings of the 29th ACM International Conference on Multimedia, 2021: 69-78.
- [24] HUANG W, DENG Y, HUI S, et al. Sparse self-attention transformer for image inpainting [J]. Pattern Recognition, 2024, 145: 109897.
- [25] SONG Y, SOHL-DICKSTEIN J, KINGMA D P, et al. Score-based generative modeling through stochastic differential equations [J]. ArXiv preprint arXiv: 2011.13456, 2020.
- [26] LUGMAYR A, DANELLJAN M, ROMERO A, et al. Repaint: Inpainting using denoising diffusion probabilistic models [C]. Proceedings of the 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 11461-11471.
- [27] CORNEANU C, GADDE R, MARTINEZ A M. LatentPaint: Image inpainting in latent space with diffusion models [C]. Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision,

- 2024; 4322-4331.
- [28] KIRILLOV A, MINTUN E, RAVI N, et al. Segment anything [C]. Proceedings of the 2023 IEEE/CVF International Conference on Computer Vision, 2023; 3922-4003.
- [29] YU J H, LIN ZH, YANG J M, et al. Free-form image inpainting with gated convolution[C]. Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision, 2019; 4470-4479.
- [30] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. ArXiv preprint arXiv: 1409.1556, 2014.
- [31] YANG Y, NEWSAM S. Bag-of-visual-words and spatial extensions for land-use classification[C]. Proceedings of the 18th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems, 2010; 270-279.
- [32] DAI D, YANG W. Satellite image classification via two-layer sparse coding with biased image representation[J]. IEEE Geoscience and Remote Sensing Letters, 2010, 8(1): 173-176.
- [33] ZHAO B, ZHONG Y F, XIA G S, et al. Dirichlet-derived multiple topic scene classification model for high spatial resolution remote sensing imagery [J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 54(4): 2108-2123.
- [34] ZHOU W X, NEWSAM S, LI C M, et al. PatternNet: A benchmark dataset for performance evaluation of remote sensing image retrieval [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2018, 145: 197-209.
- [35] XIA G S, HU J W, LU X Q, et al. AID: A benchmark data set for performance evaluation of aerial scene classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55: 3965-3981.
- [36] CHENG G, HAN J W, ZHOU P CH, et al. Multi-class geospatial object detection and geographic image classification based on collection of part detectors [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014, 98: 119-132.
- [37] LI H F, DOU X, TAO CH, et al. RSI-CB: A large-scale remote sensing image classification benchmark using crowdsourced data[J]. Sensors, 2020, 20(6): 1594-1613.
- [38] BAKIRMAN T, SERTEL E. A benchmark dataset for deep learning-based airplane detection: HRPlanes [J]. International Journal of Engineering and Geosciences, 2023, 8(3): 212-223.
- [39] GUO X F, YANG H Y, HUANG D. Image inpainting via conditional texture and structure dual generation[C]. Proceedings of the 2021 IEEE/CVF International Conference on Computer Vision, 2021; 14134-14143.
- [40] LIU G L, REDA F A, SHIH K J, et al. Image inpainting for irregular holes using partial convolutions[C]. Computer Vision-ECCV 2018, 2018; 85-100.
- [41] LIU H Y, JIANG B, SONG Y B, et al. Rethinking image inpainting via a mutual encoder-decoder with feature equalizations[C]. Part 2, 2020; 725-741.
- [42] LIU W H, CUN X D, PUN CH M, et al. CoordFill: Efficient high-resolution image inpainting via parameterized coordinate querying [C]. Proceedings of the 37th AAAI Conference on Artificial Intelligence, 2023, 2(1): 1746-1754.
- [43] WANG Z, SIMONCELLI E P, BOVIK A C. Multiscale structural similarity for image quality assessment [C]. Signals, Systems and Computers 2004, 2003; 1398-1402.
- [44] ZHANG R, ISOLA P, EFROS A A, et al. The unreasonable effectiveness of deep features as a perceptual metric [C]. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018; 586-595.
- [45] HEUSEL M, RAMSAUER H, UNTERTHINER T, et al. Gans trained by a two time-scale update rule converge to a local Nash equilibrium [J]. ArXiv preprint arXiv: 1706.08500, 2017.

作者简介



开志强, 2018 年于天津理工大学获得学士学位, 现为郑州大学硕士研究生, 主要研究方向为激光干扰图像修复。

E-mail: kzq@gs.zzu.edu.cn

Kai Zhiqiang received his B.Sc. degree from Tianjin University of Technology in 2018. He is currently a M.Sc. candidate at Zhengzhou University. His main research interest is laser jamming image inpainting.



苗锡奎, 2007 年于辽宁工程技术大学获得学士学位, 2010 年于辽宁工程技术大学获得硕士学位, 2013 年于中国科学院大学获得博士学位, 现为 63891 部队高级工程师, 主要研究方向为图像处理、目标检测与识别。

E-mail: miaoxikui@163.com

Miao Xikui received his B. Sc. degree and M. Sc. degree from Liaoning Technical University in 2007 and 2010, and Ph. D. degree from the University of Chinese Academy of Sciences in 2013, respectively. He is currently a senior engineer at army 63891. His main research interests include image processing and target detection and recognition.



马天磊 (通信作者), 2010 年于郑州大学获得学士学位, 2016 年于中国科学院大学获得博士学位, 现为郑州大学教授, 主要研究方向为红外弱小目标检测, 图像处理。

E-mail: tlma@zzu.edu.cn

Ma Tianlei (Corresponding author) received the B. Sc. degree from Zhengzhou University in 2010, and Ph. D. degree from the University of Chinese Academy of Sciences in 2016. He

is currently an professor at Zhengzhou University. His main research interests include infrared dim target detection and image processing.



冯斌, 2007 年于西安电子科技大学获得硕士学位, 2012 年于中国科学院大学获得博士学位, 现为西北工业大学副研究员, 主要研究方向为智能光电成像。

E-mail: fengbin@nwpu.edu.cn

Feng Bin received his M. Sc. degree from Xidian University of Technology in 2007, and Ph. D. degree from the University of Chinese Academy of Sciences in 2012. He is currently an associate researcher at Northwestern Polytechnical University. His main research interest is intelligent photoelectric imaging.



艾彬, 现为郑州畅想高科股份有限公司, 研发中心总工程师, 高级工程师, 主要研究方向轨道交通信息化。

E-mail: ibean@foxmail.com

Ai Bin is currently the chief engineer and senior engineer of the R&D center of Zhengzhou Think Freely Hi-Tech Co., Ltd., and his main research interest is rail transit informatization.