



中国科技期刊卓越行动计划项目入选期刊

控制与决策

CONTROL AND DECISION



基于深度学习的恶劣战场环境图像恢复方法

孙传猛, 陈嘉欣, 裴东兴, 马铁华, 祖静, 任一峰

引用本文:

孙传猛, 陈嘉欣, 裴东兴, 马铁华, 祖静, 任一峰. 基于深度学习的恶劣战场环境图像恢复方法[J]. *控制与决策*, 2024, 39(4): 1297–1304.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.1684>

您可能感兴趣的其他文章

Articles you may be interested in

[基于双边分解与 \$L_1\$ 暗通道的战场图像增强算法](#)

A battlefield image enhancement algorithm based on bilateral decomposition and L_1 dark channel prior
控制与决策. 2021, 36(5): 1165–1172 <https://doi.org/10.13195/j.kzyjc.2019.1213>

[基于MobileNet的多目标跟踪深度学习算法](#)

Deep learning algorithm based on MobileNet for multi-target tracking
控制与决策. 2021, 36(8): 1991–1996 <https://doi.org/10.13195/j.kzyjc.2019.1424>

[复杂背景下全景视频运动小目标检测算法](#)

Panoramic video motion small target detection algorithm in complex background
控制与决策. 2021, 36(1): 249–256 <https://doi.org/10.13195/j.kzyjc.2019.0686>

[非局部低秩正则化视频压缩感知重构](#)

Compressive video sensing reconstruction via nonlocal low-rank regularization
控制与决策. 2021, 36(11): 2743–2750 <https://doi.org/10.13195/j.kzyjc.2020.0310>

[一种基于稀疏系数匹配学习的图像去雾算法](#)

An image dehazing method based on learning framework with sparse coefficient matching
控制与决策. 2020, 35(11): 2797–2802 <https://doi.org/10.13195/j.kzyjc.2018.1764>

基于深度学习的恶劣战场环境图像恢复方法

孙传猛^{1,2†}, 陈嘉欣^{1,2}, 裴东兴^{1,2}, 马铁华^{1,2}, 祖静¹, 任一峰²

(1. 中北大学 省部共建动态测试技术国家重点实验室, 太原 030051;

2. 中北大学 电气与控制工程学院, 太原 030051)

摘要: 为实现恶劣战场环境下降质图像的有效恢复、降低环境因素对战场态势感知的干扰, 构建一种全新的、端到端的图像恢复方法——门控采样网络 (GSNet)。该网络以编码块-解码块为基本架构, 以 CNNs 与门控卷积为编码与解码机制, 以压缩和激励网络为编码块与解码块的连接机制, 以高阶信息重要程度的重标定区分目标与背景特征, 以通道粒度因子压缩方法为轻量化策略, 实现对战场所处恶劣环境图像的快速恢复。相关实验结果表明, GSNet 模型可使 PSNR 达到 19.35 dB, 并且 SSIM 达到 0.724, 无论是客观指标评价还是主观视觉效果, 性能均优于对比的主流图像恢复算法; 轻量级 GSNet 模型在较小提升 PSNR、SSIM 等指标的情况下, 其参数量、FLOPs 以及单张图像处理时间分别降低 56.6%、54.6% 和 55.56%。

关键词: 图像恢复; 恶劣战场环境; 深度学习; 门控卷积; 压缩和激励网络; 轻量化

中图分类号: TP183

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.1684

引用格式: 孙传猛, 陈嘉欣, 裴东兴, 等. 基于深度学习的恶劣战场环境图像恢复方法[J]. 控制与决策, 2024, 39(4): 1297-1304.

A deep learning based approach for image recovery in harsh battlefield environments

SUN Chuan-meng^{1,2†}, CHEN Jia-xin^{1,2}, PEI Dong-xing^{1,2}, MA Tie-hua^{1,2}, ZU Jing¹, REN Yi-feng²

(1. State key Laboratory of Dynamic Measurement Technology, North University of China, Taiyuan 030051, China;

2. School of Electrical and Control Engineering, North University of China, Taiyuan 030051, China)

Abstract: To achieve effective recovery of degraded images from harsh battlefield environments and reduce the interference of environmental factors on battlefield situational awareness, a new and end-to-end image recovery method, gated sampling network (GSNet), is constructed. The network adopts encoding block-decoding block as the basic architecture, CNNs and gated convolution as the encoding and decoding mechanism, compression and excitation network as the connection mechanism between encoding and decoding blocks, rescaling of higher-order information importance to distinguish targets and background features, and the channel granularity factor compression method as the light-weighting strategy to achieve rapid recovery of battlefield degraded environment images. The relevant experimental results show that the GSNet model can achieve a PSNR of 19.35 dB and an SSIM of 0.724, which are better than the compared mainstream image recovery algorithms in both objective metrics evaluation and subjective visual performance. The lightweight GSNet model reduces the number of parameters, FLOPs, and single image processing time by 56.6%, 54.6%, and 55.56%, respectively, with smaller improvements in PSNR and SSIM.

Keywords: image recovery; harsh battlefield environments; deep learning; gated convolution; compression and excitation networks; light-weighting

0 引言

近年来, 高精度卫星、无人机等用于侦察的先进设备普及运用深刻地改变了战场环境, 如何高效利用战场图像迅速区分、定位敌我目标已成为当前军事科学研究领域的研究前沿^[1]。然而, 实际的战场环境

日趋复杂恶劣, 雾、霾等不良天气以及战场扬尘、硝烟、烟幕伪装等均会不同程度地使获取到的战场图像出现退化降质现象, 对战场态势感知造成严重干扰。因此, 深入研究恶劣战场环境图像恢复技术, 消除雾、霾等环境因素对图像质量的影响, 对后续军事目

收稿日期: 2022-09-23; 录用日期: 2023-01-20.

基金项目: 国家重点研发计划青年科学家项目(2022YFC2905700); 国家重点研发计划项目(2022YFB3205800); 山西省高等学校科技创新项目(2020L0294); 山西省基础研究计划面上项目(202203021221106).

†通讯作者. E-mail: sun_c_m@163.com.

标识定位、实时跟踪、军事预警等战场态势感知技术具有重要理论意义和应用价值。

主流观点认为光在雾、霾等介质中传播时,因粒子的散射和吸收作用使得图像传感器采集的图像信息退化降质。基于这一认识,恶劣环境下的图像恢复技术包括基于图像增强的图像恢复方法、基于图像复原的图像恢复方法和基于深度学习的图像恢复方法3大类:

1) 基于图像增强的图像恢复方法旨在通过去除图像噪声提高图像对比度,从而恢复出清晰图像,代表性方法有直方图均衡化(HLE)^[2]、Retinex算法^[3]、小波变换算法^[4]、同态滤波算法^[5]等。该类方法没有考虑图像降质的实际物理过程,仅仅增强了图像的视觉效果,在图像恢复过程中可能存在色彩失真、曝光过度、细节损失等现象。

2) 基于图像复原的图像恢复方法从大量降质和清晰图像的对比信息中总结先验信息,通过逆运算得到清晰的图像,代表性算法包括暗通道先验(dark channel prior, DCP)方法^[6]及其改进^[7-9]、最大对比度(maximum contrast, MC)方法^[10]、颜色衰减先验(color attenuation prior, CAP)方法^[11]、色度不一致方法^[12]等。该类方法效果普遍好于基于图像增强的方法,但严重依赖先验知识,一旦先验知识失效则效果不佳。

3) 基于深度学习的图像恢复方法利用卷积神经网络(CNNs)强大的高层语义表示能力实现图像恢复,一种思路是利用CNN对大气退化模型的参数进行估计,另一种思路是端到端方法,即直接输入降质图像输出清晰图像。典型的方法包括DehazeNet^[13]、MSCNN^[14]、AOD-Net^[15]、GFN^[16]、GCANet^[17]、FFANet^[18]、HardGAN^[19]、MSBDN-DFE^[20]、多向导双边学习的去雾框架(后文简记为Zheng)^[21]等,目前最新的图像恢复方法倾向于端到端方法。

具体到战场图像的恢复技术研究,相关报道较少。张林蔚^[22]提出一种自适应调节算子军事图像恢复算法,该方法属于基于图像增强的方法,存在对分辨率敏感等问题;秦朝轩等^[23]提出一种通过结合 L_1 暗通道先验与双边分解的针对战场图像的增强算法,属于基于图像复原的方法。

综上所述,目前针对恶劣战场环境图像恢复技术还存在如下问题:1) 端到端的深度学习图像恢复方法是当前研究主流,展现了强大的性能,但针对恶劣战场环境图像的研究与应用鲜有报道;2) 已有的端到端图像恢复方法没有区分背景像素与目标像素的重要程度,而在战场环境图像恢复任务中,模糊目

标的恢复相比背景信息的恢复更加重要;3) 已有的端到端图像恢复方法,存在模型规模大、参数量多、每秒浮点计算量(FLOPs)大、运行时间长等问题,而且实时性差、不利于边缘端移植。鉴于此,本文针对恶劣战场环境图像特点,以编码块-解码块为基本架构,以CNNs与门控卷积(gated convolution)为编码与解码机制,以压缩和激励网络(squeeze-and-excitation networks, SENet)为编码块与解码块的连接机制,以高阶信息重要程度的重标定区分目标与背景特征,进而构建一种全新的、端到端的图像恢复方法——门控采样网络(gated sample network, GSNet),并采用通道粒度因子压缩方法对其轻量化,以期实现对战场恶劣环境图像的快速恢复。

1 相关工作

1.1 战场恶劣环境降质图像分析

在现代战场上,无论是处于雾、霾等不良天气,还是战场扬尘、硝烟、烟幕伪装等恶劣战况环境,均会导致大气中水分子或微小颗粒浓度急剧上升。此时,目标物体反射光与水分子或微小颗粒发生碰撞,会产生散射和吸收效应,导致图像出现退化降质^[24]。恶劣战场环境成像系统的成像过程如图1所示,成像设备采集到的光线主要包括经大气介质衰减后的目标物体反射光线和经微小粒子散射的光源入射光线。其中,目标物体反射光经大气中微小粒子的吸收和散射,能量产生衰减,在图像上表现为亮度降低、对比度下降;光源经微小粒子散射作用形成散射光,往往导致成像模糊、色彩不自然。恶劣战场环境下图像降质与常规雾、霾天气下的图像降质机理一致,均是大气中水分子或微小颗粒散射光线造成的,不同在于,恶劣战场环境下水分子或微小颗粒浓度更大或变化更为剧烈。典型的恶劣战场环境降质图像如图2所示。上述降质过程^[25-27]可以近似表达为

$$I(x, \lambda) = e^{-\beta(\lambda)d(x)} R(x, \lambda) + L_{\infty}(1 - e^{-\beta(\lambda)d(x)}). \quad (1)$$

其中: $I(x, \lambda)$ 为降质图像; $R(x, \lambda)$ 为需恢复的未降质图像; x 为图像中像素点的标记位置; λ 为光的波长; L_{∞} 为无穷远处的大气光值; $e^{-\beta(\lambda)d(x)}$ 为大气散射模型中的介质透射率, β 为散射系数。式(1)为Jaffe-McGlamey提出的经典成像模型(IFM),是对图像真实退化过程的某种理想简化。

根据上述分析,恶劣战场环境降质图像降质过程是从“清晰(未降质)域”到“降质域”的映射(函数)。因此,根据通用近似定理^[28-29],可以构建端到端




图1 恶劣战场环境成像系统成像过程



图2 典型的恶劣战场环境降质图像

的神经网络去无限逼近“恶劣战场环境降质图像降质过程”。所谓“端到端学习”，是指在深度学习过程中不进行分模块或分阶段训练，直接优化任务的总体目标。在端到端学习中，一般不需要明确地给出不同模块或阶段的功能，中间过程不需要人为干预；端到端学习的训练数据为“输入-输出”对的形式，无需提供其他额外信息^[30]。

观察图2可知，在微小颗粒浓度较大时，图像降质的同时还存在大量噪声，这对战场图像恢复处理的影响不容忽视。此外，在战场环境下，图像处理任务往往对战场目标更为敏感，对模糊目标的恢复相比背景信息的恢复更加重要，这有利于引导图像恢复网络模型的设计。

1.2 门控采样网络

1.2.1 主体结构

图像恢复技术的本质是寻求降质图像 $I(x, \lambda)$ 与

未降质图像 $R(x, \lambda)$ 之间的映射关系 $f(\cdot)$ ，有

$$R(x, \lambda) = f(I(x, \lambda)). \tag{2}$$

端对端的深度学习图像恢复方法通过构建深度神经网络模型以一定的精度近似连续非线性映射关系 $f(\cdot)$ (即通用近似定理^[28-29])，而近似精度取决于构建的深度神经网络性能。显然，端对端的深度学习图像恢复方法跳脱已有降质过程模型的约束，不受假设模型偏离实际成像过程的影响，不受参数估计可能的误差相互放大的影响，不依赖先验知识，具有良好的适应性和更广泛的应用范围。

如前述分析，恶劣战场环境下图像降质过程更为复杂，利用端对端进行恶劣战场环境图像恢复必须解决好如下问题：1) 如何解决底层特征(降质图像)、高层语义信息和底层特征(未降质图像)之间的“语义鸿沟”；2) 如何分割有效像素与无效像素，并消除噪声的影响；3) 如何利用战场目标的敏感性，优化网络性能。

基于上述考虑，本文构建一种全新的端到端的图像恢复方法，称为门控采样网络 (gated sample network, GSNet)。该网络由编码块与解码块两部分构成，其结构如图3所示。其中：1) 编码块通过卷积模块、门控卷积模块和下采样模块实现从底层到高层特征的逐层抽象；2) 解码块通过卷积模块、门控卷积模块和上采样模块实现从高层到底层特征的逐层还原；3) 编码块与解码块通过压缩和激励网络模块连接，赋予各高阶信息通道不同重要程度；4) 门控卷积模块区分有效像素与无效像素，并消除噪声影响。

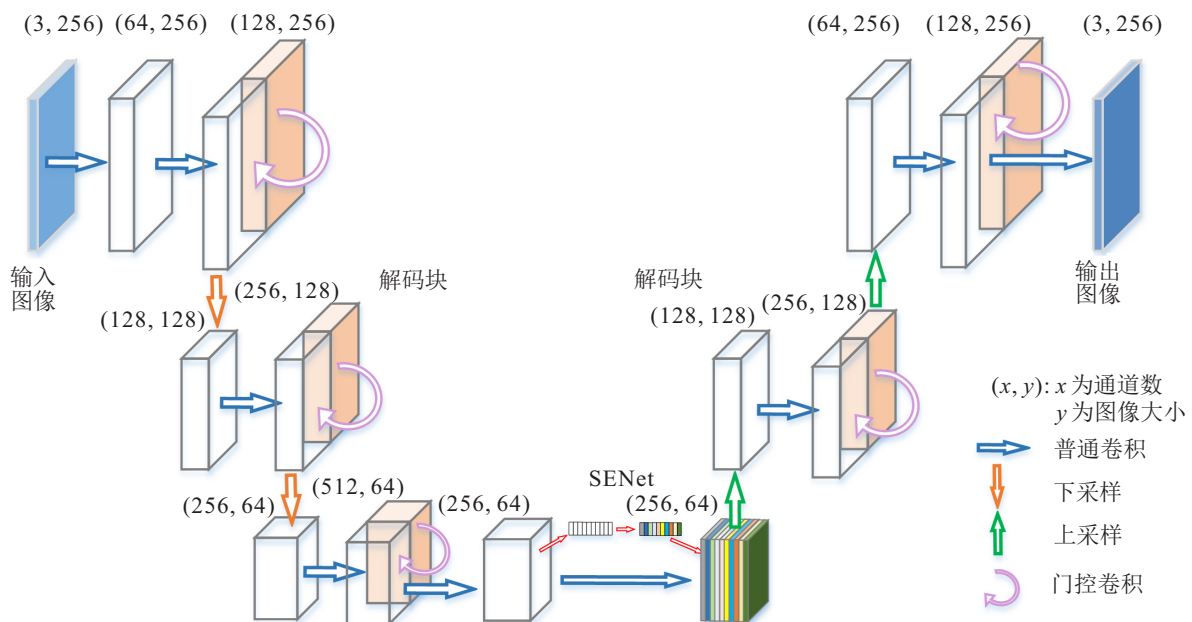


图3 门控采样网络结构

1.2.2 门控卷积模块

门控卷积模块结构如图4所示,其通道数比普通卷积多一倍,其中一半通道的卷积核进行特征提取,与普通卷积一致;另一半通道的卷积核进行软掩码的学习,并经过sigmoid激活函数将软掩码的值约束在[0,1]区间.而门控卷积的输出则为一半通道输出的特征映射与另一半通道输出软掩码的范德蒙德积.这样,门控卷积的作用过程可以表达为

$$\text{Feature} = \sum \sum W_f \cdot I, \quad (3)$$

$$\text{Gating} = \sum \sum W_g \cdot I, \quad (4)$$

$$\text{Output} = \Gamma(\text{Feature}) \odot \sigma(\text{Gating}). \quad (5)$$

其中:Feature为一半通道的特征映射,Gating为另一半通道学习到的软掩码, I 为网络输入数据; W_f 、 W_g 为卷积核, $\Gamma(\cdot)$ 为ReLU激活函数, $\sigma(\cdot)$ 为sigmoid激活函数, \odot 为范德蒙德积;Output为模块输出特征.




图4 门控卷积

对于恶劣战场环境图像恢复任务而言,目标的残留信息更加重要,背景残留信息次要,噪声等干扰信息最不重要,甚至起到负面效果.在门控采样网络编码和解码过程中,门控卷积通过自学习的软掩码机制突出了特征映射中的重要信息而削弱无效信息,从而实现有效像素与无效像素的区分.

1.2.3 压缩和激励网络模块(SENet)

压缩和激励网络模块鉴于不同通道重要性的不同,显式地构建通道间的相互依赖关系,自适应地重新校准通道特征响应,从而使用全局信息来选择性地突出有效信息特征并抑制无效特征. SENet包含两条分支,一条分支直连以传递特征映射,另一条分支经压缩与激励操作赋予特征映射各通道的重要程度,结构如图5所示.




图5 压缩和激励网络模块

假设输入的特征映射为 $I \in \mathbf{R}^{C \times H \times W}$,经压缩操作映射为一维向量 $z \in \mathbf{R}^{C \times 1 \times 1}$,有

$$z = \frac{1}{H \times M} \sum_{i=1}^H \sum_{j=1}^M I(i, j). \quad (6)$$

向量 z 继续经激励操作后即可得到各通道的重要程度信息,该信息以一维向量 $\tilde{z} \in \mathbf{R}^{C \times 1 \times 1}$ 表示为

$$\tilde{z} = \sigma(\text{FC}(\Gamma(\text{FC}(z))))), \quad (7)$$

其中 $\text{FC}(\cdot)$ 为全连接操作.

将向量 \tilde{z} 重新添加至直连的特征映射中,实现在通道维度上的特征重标定,标定输出数据 $s \in \mathbf{R}^{C \times H \times W}$,有

$$s = \tilde{z} \cdot I. \quad (8)$$

在GSNet模型中,经编码块逐层特征提取操作获得的高阶全局信息并不是全部有效,而无效信息传递到解码块中,经逐层卷积和上采样操作可能会放大无效信息的作用,这对恶劣战场环境图像恢复任务而言极为不利.利用SENet作为编码块、解码块的连接机制,起到了对无效信息的“过滤”作用,使传递到解码器的高阶全局信息为有效信息,且有效信息的重要程度有所区分,从而极大地提升了图像恢复的性能.

1.3 门控采样网络轻量化

在现代战争场景下,战场形势瞬息万变,对信息感知的实时性要求不断提高,给基于深度学习的信息感知技术带来较大挑战.一种行之有效的方法是对深度学习模型进行剪枝处理,形成轻量级网络.本文利用通道粒度因子实现对门控采样网络轻量化处理.

通常,一个卷积核只捕捉输入数据中的一种特定的局部特征,因此在卷积层中相同的或者相似的多个卷积核存在冗余,删除冗余通道是实现模型轻量化的有效手段.本文认为,在剪枝过程中必须保证通道权重和在各个尺度上具有均衡性,才能保持原网络的准确性和泛化性能.而在卷积层中,卷积核的矩阵元素之和决定了特征映射整体的明暗,控制了特征提取的尺度.因此,利用通道权重和将门控采样网络各层通道分为若干尺度,各尺度下通道提取的特征是相同或相似的,记为本质特征类,并在每个尺度下按相同的压缩率进行通道剪枝,使得原网络提取出的特征在各尺度下均得到有效保留,从而最大程度地维持原网络的准确性和泛化性能.设通道集合为 D ,任一通道为 d^i ,将 d^i 按下式构建的通道相似性评价函数 $S_{\text{index}}(\cdot)$ 划分为不同本质特征类:

$$S_{\text{index}}(d^i) =$$

$$\text{round}\left\{N\left[\frac{1}{1+\exp\left(-\frac{\Psi(d^i)}{\max(\Psi(D))}\right)}-\frac{1}{2}\right]\right\}, \quad (9)$$

其中: $\Psi(\cdot)$ 为对矩阵元素求和; $\text{round}(\cdot)$ 为四舍五入计算; N 为通道粒度因子, 起调节相似性粒度的作用, N 越大 D 集合划分的本征特征类越多, 判断相似的条件越严格.

由式(9)可知, 所有通道被分为 $N + 1$ 个类别, 根据每一类别中通道数目进行排序, 按照冗余程度顺序进行剪枝. 在剪枝过程中, 依次考察该类别中的各个通道, 每次考察时生成一个随机数 $r \in [0, 1]$, 若 r 小于提前设定的剪枝率阈值则删除该通道, 否则保留. 最终, 冗余的通道集合被随机稀疏, 实现门控采样网络轻量化.

2 实验结果及分析

2.1 实验方案

本文选用人工合成数据集 RESIDE SOTS 作为训练集, 选取其中对应的 3 000 组图像数据; 使用退化模型为自建的战场环境模拟数据集作为测试集, 包括 1 000 组相互对应的降质图像和清晰图像. 同时, 为测试 GSNet 对真实场景的泛化能力, 针对山西太原、河北石家庄、贵州德江等地采集的真实降质图像进行恢复实验.

主要硬件实验环境如下: Intel Xeon Gold 5218R GPU, 256 G 内存, NVIDIA Quadro RTX 6000 24 GB GPU. 软件环境如下: 操作系统为 64 位的 Window10, 开发环境为 PyCharm 2021. 在实验中, 所有超参数均使用相同设置: 使用 Adam 优化器, 设置初始学习率为 0.002, 共学习 20 个 epochs, 在第 15 个 epoch 时学习率衰减 0.1 倍. 使用 L_1 损失函数计算训练梯度. 网络输

入大小设置为 400×544 , batch_size 为 8.

2.2 实验方案

采用峰值信噪比 (PSNR, 单位 dB) 和结构相似性 (SSIM) 作为图像恢复的评价指标. PSNR 用于量化图像的重建质量, 计算过程如下:

$$\text{PSNR} = 20 \cdot \log_{10}\left(\frac{\text{Max}}{\sqrt{\text{Mse}}}\right). \quad (10)$$

其中: Max 为输入数据的最大值, Mse 为两幅同等大小图像之间的均方差.

SSIM 从亮度、对比度和结构 3 方面度量了图像之间的相似性. 设 μ 为图像均值, σ 为标准差, σ_{XY} 为图像 X 和 Y 的协方差, 则有

$$\text{SSIM}(X, Y) = \frac{(2\mu_X\mu_Y + C_1)(2\sigma_{XY} + C_2)}{(\mu_X^2 + \mu_Y^2 + C_1)(\sigma_X^2 + \sigma_Y^2 + C_2)}, \quad (11)$$

其中 C_1, C_2 为常数.

2.3 图像恢复实验结果分析

使用相同的数据集并设置相同超参数下训练相关深度学习模型, 在自建战场环境模拟数据集上进行测试. 将本文算法测试结果与主流图像恢复算法 DCP^[6]、AOD-Net^[15]、GCANet^[17]、FFANet^[18]、MSBDN-DFE^[20]、Zheng^[21] 进行对比, 部分测试结果如图 6 所示 (从左到右依次为清晰图像、模拟降质图像、DCP 恢复效果、AOD-Net 恢复效果、GCANet 恢复效果、FFANet 恢复效果、MSBDN-DFE 恢复效果、Zheng 恢复效果和本文所述 GSNet 恢复效果), 评价指标结果如表 1 所示. 其中, Base 为基准测试, 自建战场环境模拟数据集中降质图像的 PSNR 为 12.03 dB, SSIM 为 0.135. 由图 6 和表 1 可知, 所提出 GSNet 模型可使 PSNR 达到 19.35 dB, 相比主流方法达到最高, 并

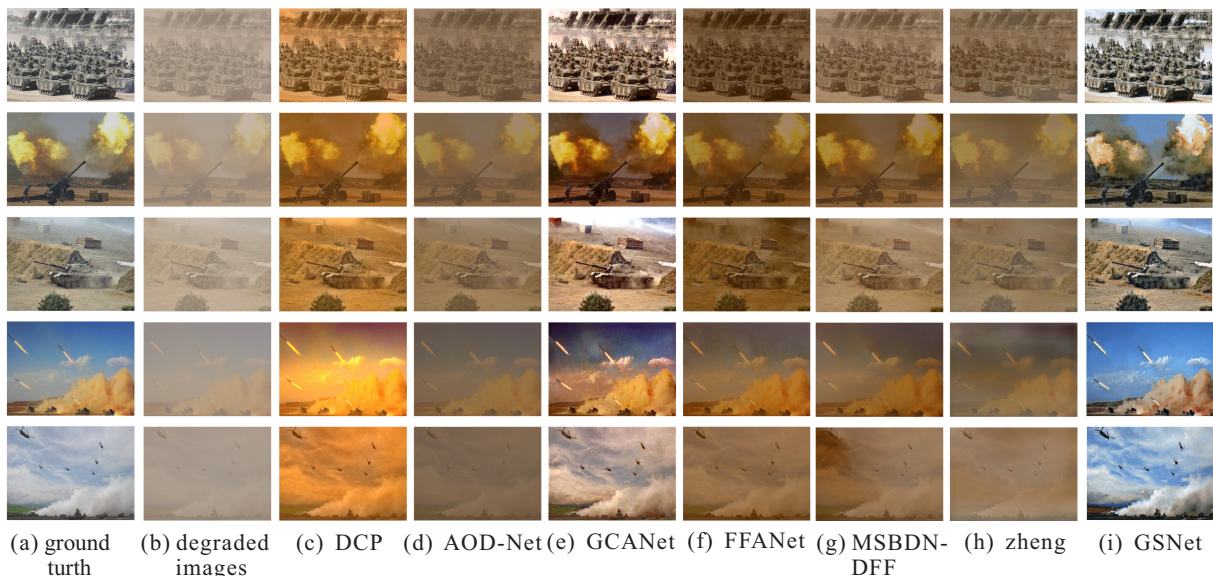


图 6 GSNet 模型部分测试结果

表1 战场环境降质图像恢复客观评价

方法	PSNR/dB	SSIM
Base	12.03	0.135
DCP	12.04	0.541
AOD-Net	8.562	0.488
GCANet	17.10	0.785
FFANet	16.64	0.754
MSBDN-DFF	12.32	0.677
Zheng	11.52	0.527
GSNet	19.35	0.724

且SSIM达到0.724,无论是客观指标评价还是主观视觉效果,性能均优于对比的图像恢复算法。

针对山西太原、河北石家庄、贵州德江等地采集的真实降质图像进行恢复实验效果如图7所示(从左到右依次为真实降质图像、DCP恢复效果、AOD-Net恢复效果、GCANet恢复效果、FFANet恢复效果、MSBDN-DFF恢复效果、Zheng恢复效果和本文GSNet恢复效果)。从主观视觉效果看,所提出的GSNet性能显著优于上述对比的图像恢复算法,而真实场景下的图像恢复效果充分表明了GSNet的泛化性能。

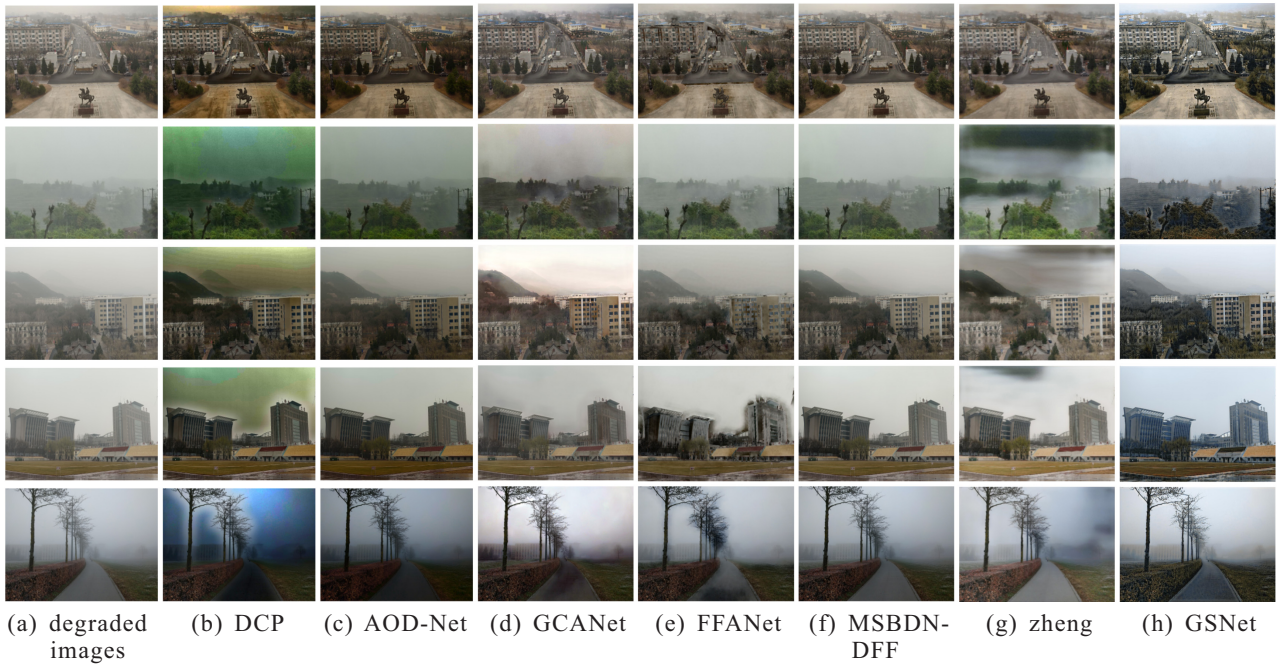


图7 真实降质图像恢复实验效果

2.4 轻量化实验结果分析

在GSNet中,利用通道粒度因子对卷积、门控卷积进行通道剪枝.实验中,设置通道粒度因子 N 为13,并逐层设置压缩率.将所有卷积层的部分通道进行剪枝后,对模型重新进行微调以恢复其精度,微调所需训练epochs为10.

轻量化GSNet与原GSNet模型性能对比如表2所示,针对降质图像的恢复效果如图8和图9所示.

表2 轻量化实验结果客观评价

指标	GSNet	轻量级GSNet
PSNR/dB	19.35	20.43
SSIM	0.724	0.752
参数量/MB	3.11	1.35
FLOPs/GB	35.46	16.09
处理时间/ms	0.153	0.068

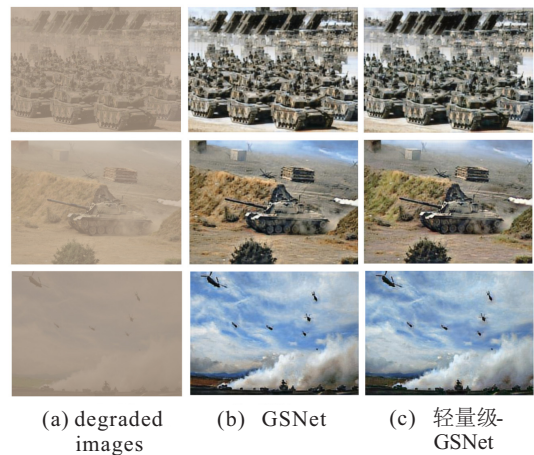


图8 轻量化实验模拟数据集测试效果

由表2可知:原GSNet模型中参数量为3.11M,其FLOPs为35.46G;实现通道剪枝后,所得轻量级GSNet的参数量为1.35M,FLOPs为16.09G,其PSNR为20.43dB,SSIM为0.752.相比原模型,轻量级模型

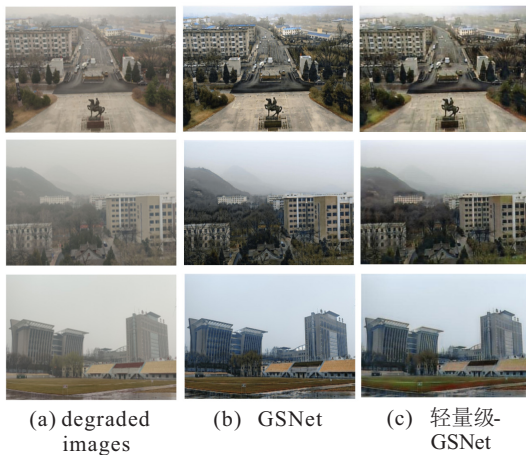


图9 轻量化实验真实图像测试效果

的参数数量、FLOPs 以及单张图像处理时间分别降低了 56.6%、54.6% 和 55.56%; 然而经过大量压缩后, 模型中的部分参数被移除, 使模型泛化能力得到提升, 其 PSNR 和 SSIM 评价指标分别增加了 1.08 和 0.28. 就图 8 所示的主观视觉效果而言, 轻量化 GSNNet 与原模型的恢复效果基本一致.

3 结论

本文对恶劣战场环境下降质图像的恢复进行研究, 提出了一种在采样过程中充分利用有效特征信息而逐渐抑制冗余、无用的信息通道和元素的端对端的图像恢复模型——门控采样网络. 结果表明:

1) 门控采样网络充分考虑了战场恶劣环境图像特征, 在编码和解码过程中使用门控卷积区分有效像素和噪声信息, 在编码连接解码部分使用 SENet 对高阶信息进行重标定, 加强有效高阶信息通道的信息传递.

2) 借助通道粒度因子对卷积层进行随机通道剪枝, 移除大量冗余通道得到轻量级网络, 并且维持模型性能.

3) 使用自建战场环境数据集进行测试, 在相同的实验设置下, GSNNet 相比主流算法得到了最高的 PSNR 值, 且轻量级-GSNNet 的参数数量和 FLOPs 也大幅减少; 在真实降质图像测试实验中, GSNNet 获得了最佳的主观视觉效果, 展现了卓越的泛化性能.

参考文献(References)

[1] 刘英. 基于卷积神经网络的陆战场目标分类算法研究[D]. 成都: 电子科技大学, 2020.
(Liu Y. Research on land battlefield target classification algorithm based on convolutional neural network[D]. Chengdu: University of Electronic Science and Technology of China, 2020.)

[2] 汪秦峰. 基于直方图均衡化和 Retinex 的图像去雾算

法研究[D]. 西安: 西北大学, 2016.

(Wang Q F. Research on image defogging algorithm based on histogram equalization and Retinex[D]. Xi'an: Northwest University, 2016.)

- [3] Zhou J, Zhang D, Zou P, et al. Retinex-based laplacian pyramid method for image defogging[J]. IEEE Access, 2019, 7: 122459-122472.
- [4] 何立风, 袁朴, 周广彬, 等. 基于图像特征量和小波变换的去雾算法[J]. 激光与光电子学进展, 2022, 59(2): 271-280.
(He L F, Yuan P, Zhou G B, et al. Defogging algorithm based on image features and wavelet transform[J]. Laser & Optoelectronics Progress, 2022, 59(2): 271-280.)
- [5] 周小军, 郭佳, 周承仙, 等. 基于改进同态滤波的遥感图像去云算法[J]. 无线电工程, 2015, 45(3): 14-18.
(Zhou X J, Guo J, Zhou C X, et al. An algorithm of cloud removal for remote sensing image based on improved homomorphic filtering[J]. Radio Engineering, 2015, 45(3): 14-18.)
- [6] He K, Sun J, Tang X. Single image haze removal using dark channel prior[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 33(12): 2341-2353.
- [7] Du H. Research on image de-disturbing algorithm based on dark channel prior and anisotropic Gaussian filtering[J]. Concurrency and Computation: Practice and Experience, 2018, 30(24): e4933.
- [8] Koley S, Sadhu A, Roy H, et al. Single image visibility restoration using dark channel prior and fuzzy logic[C]. The 2nd International Conference on Electronics, Materials Engineering & Nano-Technology. Kolkata, 2018: 1-7.
- [9] Zhu W W, Yang L, Zang X X. Application of dark channel prior principle to license plate detection in foggy weather[C]. IEEE 3rd Advanced Information Technology, Electronic and Automation Control Conference. Chongqing, 2018: 2591-2595.
- [10] Tan R T. Visibility in bad weather from a single image[C]. IEEE Conference on Computer Vision and Pattern Recognition. Anchorage, 2008: 1-8.
- [11] Zhu Q S, Mai J M, Shao L. A fast single image haze removal algorithm using color attenuation prior[J]. IEEE Transactions on Image Processing, 2015, 24(11): 3522-3533.
- [12] Ancuti C O, Ancuti C, Hermans C, et al. A fast semi-inverse approach to detect and remove the haze from a single image[J]. Asian Conference on Computer Vision. Queenstown, 2010: 501-514.
- [13] Cai B L, Xu X M, Jia K, et al. DehazeNet: An end-to-end system for single image haze removal[J].

- IEEE Transactions on Image Processing, 2016, 25(11): 5187-5198.
- [14] Ren W, Liu S, Zhang H, et al. Single image dehazing via multi-scale convolutional neural networks[C]. European Conference on Computer Vision. Springer, 2016: 154-169.
- [15] Li B Y, Peng X L, Wang Z Y, et al. AOD-net: All-in-one dehazing network[C]. IEEE International Conference on Computer Vision. Venice, 2017: 4780-4788.
- [16] Ren W, Ma L, Zhang J, et al. Gated fusion network for single image dehazing[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 3253-3261.
- [17] Chen D, He M, Fan Q, et al. Gated context aggregation network for image dehazing and deraining[C]. IEEE Winter Conference on Applications of Computer Vision. Piscataway: IEEE, 2019: 1375-1383.
- [18] Qin X, Wang Z L, Bai Y C, et al. FFA-net: Feature fusion attention network for single image dehazing[J/OL]. 2019, arXiv: 1911.07559.
- [19] Deng Q L, Huang Z L, Tsai C C, et al. HardGAN: A haze-aware representation distillation GAN for single image dehazing[C]. Computer Vision—ECCV 2020: 16th European Conference. Glasgow, 2020: 722-738.
- [20] Dong H, Pan J S, Xiang L, et al. Multi-scale boosted dehazing network with dense feature fusion[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, 2020: 2154-2164.
- [21] Zheng Z R, Ren W Q, Cao X C, et al. Ultra-high-definition image dehazing via multi-guided bilateral learning[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, 2021: 16180-16189.
- [22] 张林蔚. 军事图像复原系统的设计与实现[D]. 北京: 中国科学院大学, 2013.
(Zhang L W. Design and implementation of the restoration system to military images[D]. Beijing: University of the Chinese Academy of Sciences, 2013.)
- [23] 秦朝轩, 顾晓辉. 基于双边分解与 L_1 暗通道的战场图像增强算法[J]. 控制与决策, 2021, 36(5): 1165-1172.
(Qin C X, Gu X H. A battlefield image enhancement algorithm based on bilateral decomposition and L_1 dark channel prior[J]. Control and Decision, 2021, 36(5): 1165-1172.)
- [24] 段明珍. 雾霾气象条件下颗粒物质量浓度分布模型研究[J]. 环境科学与管理, 2022, 47(4): 78-82.
(Duan M Z. Distribution model of particulate matter concentration under haze meteorological conditions[J]. Environmental Science and Management, 2022, 47(4): 78-82.)
- [25] Li M D, Liu J Y, Yang W H, et al. Structure-revealing low-light image enhancement via robust retinex model[J]. IEEE Transactions on Image Processing, 2018, 27(6): 2828-2841.
- [26] Kopf J, Neubert B, Chen B, et al. Deepphoto: Model-based photograph enhancement and viewing[J]. ACM Transactions on Graphics, 2008, 27(5): 1-10.
- [27] Feldhake G. Estimating the attenuation due to combined atmospheric effects on modern earth-space paths[J]. IEEE Antennas and Propagation Magazine, 1997, 39(4): 26-34.
- [28] Cybenko G. Approximation by superpositions of a sigmoidal function[J]. Mathematics of Control, Signals and Systems, 1989, 2(4): 303-314.
- [29] Hornik K, Stinchcombe M, White H. Multilayer feedforward networks are universal approximators[J]. Neural Networks, 1989, 2(5): 359-366.
- [30] 邱锡鹏. 神经网络与深度学习[M]. 北京: 机械工业出版社, 2020.
(Qiu X P. Neural networks and deep learning[M]. Beijing: China Machine Press, 2020.)

作者简介

孙传猛(1988—), 男, 讲师, 博士, 从事深度学习、机器视觉等研究, E-mail: sun_c_m@163.com;

陈嘉欣(1998—), 男, 硕士生, 从事深度学习及模型轻量化的研究, E-mail: chenjiaxin_ty@163.com;

裴东兴(1970—), 男, 教授, 博士, 从事高压、高冲击、高温、高速、强电磁干扰等恶劣环境下各种瞬态过程的信息获取等研究, E-mail: 13935174305@163.com;

马铁华(1964—), 男, 教授, 博士, 从事动态测试与武器智能装备等研究, E-mail: matiehua@nuc.edu.cn;

祖静(1933—), 男, 教授, 博士, 从事动态测试与智能仪器等研究, E-mail: zujing@nuc.edu.cn;

任一峰(1967—), 男, 教授, 博士, 从事变频器的控制、光伏并网系统等研究, E-mail: renyifeng126@126.com.