

基于渐进式边缘感知交互的多退化暗光图像增强

李悦洲¹, 牛玉贞^{1*}, 李富晟¹, 柯 道¹, 施逸青²

(1. 福州大学计算机与大数据学院, 福建福州 350108; 2. 福建师范大学光电与信息工程学院, 福建福州 350117)

摘 要: 暗光场景下拍摄的图像容易受暗光、噪声、模糊等多种退化因素的影响, 导致其内容可视度低且视觉观感较差. 多退化的暗光图像对现有图像增强方法提出了挑战: 一方面, 暗光图像增强或去模糊等方法不能涵盖所有的退化类型, 而组合使用已有方法的效果受到计算开销增加与误差累积的限制; 另一方面, 已有多退化暗光图像增强方法采用了先提升亮度再去模糊的策略, 这种顺序处理方式会增加特征线索丢失的风险, 不利于细节复原. 为应对上述挑战, 本文提出渐进式边缘感知交互增强网络 (Progressive Edge-aware Interactive Enhancement Network, PEIE-Net), 以逐步增强的方式减少图像增强过程中特征细节的丢失. 具体来说, 该网络由图像增强分支与边缘预测分支组成. 在图像增强分支的每个增强阶段中, 设计自注意力调制预测模块提取全局信息, 用于对通道调制模块和多尺度复原模块进行自适应调制. 在边缘预测分支中, 设计空频域特征变换模块提取边缘感知信息, 既用于预测高质量图像的边缘, 又与图像增强分支的特征进行融合, 以此模拟人类视觉系统在不同感知之间的交互. 此外, 本文还提出了场景亮度估计损失对多个渐进式增强阶段进行协调. 在合成与真实数据集上的实验验证了本文方法在增强暗光、噪声、模糊退化图像方面的有效性与先进性, 并可用于暗光图像增强与超分辨率任务.

关键词: 图像增强; 多退化图像; 暗光增强; 去模糊; 特征调制

基金项目: 国家自然科学基金 (No. U21A20472, No. 62072110, No. 61972097); 福建省科技重大专项 (No. 2021HZ022007); 福建省自然科学基金 (No. 2023J01067, No. 2020J01494); 福建省科技厅高校产学研合作项目 (No. 2021H6022)

中图分类号: TP391

文献标识码: A

文章编号: 0372-2112(2025)03-0926-15

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20240375

Progressive Edge-Aware Interactive Network for Multi-Degraded Low-Light Image Enhancement

LI Yue-zhou¹, NIU Yu-zhen^{1*}, LI Fu-sheng¹, KE Xiao¹, SHI Yi-qing²

(1. College of Computer and Data Science, Fuzhou University, Fuzhou, Fujian 350108, China;

2. College of Photonic and Electronic Engineering, Fujian Normal University, Fuzhou, Fujian 350117, China)

Abstract: Images captured in low-light scenes are susceptible to multiple degradations such as darkness, noise, and blur, resulting in poor visibility and visual perception. Multi-degraded low-light image enhancement poses challenges to existing image enhancement methods as follows: on the one hand, low-light image enhancement or deblurring methods cannot handle all three types of degradation, and the effect of the combination strategy is limited by the increased computational cost and error accumulation. On the other hand, the existing multi-degraded low-light image enhancement method adopts the strategy of enhancing brightness first and then removing blur, and this sequential processing manner increases the risk of losing feature cues and is not conducive to detail recovery. To cope with the above challenges, this paper proposes the progressive edge-aware interactive enhancement network (PEIE-Net), which reduces the loss of feature details by designing a step-by-step enhancement process. Specifically, our network consists of an image enhancement branch and an edge information prediction branch. In each enhancement stage of the image enhancement branch, a self-attention modulation prediction module is designed to extract the global information, which is used for adaptive modulation in the channel modulation module and multi-scale restoration module. In the edge information prediction branch, the spatial-frequency domain feature transformation module is developed to extract the edge perceptual information. The edge perceptual information is used to

predict the edges of high-quality images while also fused with the image enhancement features, simulating the interaction between different perceptions within the human visual system. In addition, we propose scene brightness estimation loss to coordinate the multiple progressive enhancement stages. Experiments on synthetic and real datasets demonstrate the effectiveness and sophistication of our method for enhancing low-light, noisy, and blur-degraded images, and can be used for low-light image enhancement and super-resolution tasks.

Key words: image enhancement; multi-degraded image; low-light enhancement; deblurring; feature modulation

Foundation Item(s): National Natural Science Foundation of China (No.U21A20472, No.62072110, No.61972097); Major Science and Technology Projects in Fujian Province (No.2021HZ022007); Natural Science Foundation of Fujian Province (No.2023J01067, No.2020J01494); Fujian Provincial Department of Science and Technology University Industry University Cooperation Project (No.2021H6022)

1 引言

在暗光条件下获取高质量图像对于智能终端、交通监控^[1]、遥感^[2]、无人驾驶等多个领域的全天候应用有重要意义,因而受到了计算摄影与图像处理领域研究人员的广泛关注.暗光图像的可视度不佳,且信噪比低,因此已有研究大多关注于暗光与噪声造成的图像退化,旨在改善黑暗图像的可视度.对于暗光图像增强方法来说,早期方法着重于亮度提升与颜色校正,此类方法主要基于伽马校正、直方图均衡化、Retinex理论,能够扩大图像的动态范围,改善对比度.但这些方法主要依赖手工设计的映射函数、光照图运算或经验化的参数设置^[3],其泛化能力较弱.近年来,暗光图像增强方法受益于深度学习数据驱动的特性,通过结合增强曲线^[4]、流正则化^[5]、神经架构搜索^[6]、对抗生成学习^[7]等技术,进一步提升了暗光场景图像的增强效果.

真实世界中暗光场景图像的退化可能更为复杂.除上述研究关注的暗光与噪声问题外,暗光图像中还可能合并运动模糊退化.具体来说,在光照不良条件下,相机/物体运动会导致图像出现运动模糊区域,损害场景中的语义信息和视觉观感.然而在已有研究中,图像去模糊方法主要局限于正常光照的场景^[8],针对暗光场景去模糊的研究仍然较少.综上所述,有必要针对暗光、噪声、运动模糊同时存在的多退化暗光图像的增强方法进行研究.对于多退化的暗光图像增强任务来说,组合已有暗光图像增强方法与去模糊方法并不能构建有效的解决方案.一方面,直接应用现有方法不仅会面临昼夜域之间的数据分布差异,还会增加误差累积的可能性.如图1(b)所示,顺序使用现有的暗光图像增强方法^[9]与去模糊方法^[10],可以一定程度上提升图像亮度,却无法有效去除模糊.另一方面,联合训练这两种模型使得参数量与计算代价线性增加,且两类任务方法设计上的内在差异也限制了组合后的效率,进而影响增强结果的视觉观感.图1(c)展示了使用LOL-Blur^[8]数据集联合训练暗光图像增强方法与去模糊方法处理真实场景图像的结果,该图像的亮度与颜色观

感得到一定改善,但是纹理模糊仍然严重.

面向多退化的暗光图像增强的现有方法中,暗光增强与去模糊网络(Low-light Enhancement and Deblurring Network, LEDNet)^[8]方法采用U型结构,由编码器与解码器分别实施暗光增强和去模糊处理.然而,这种先增强亮度再去模糊的方式限制了模型处理细节的能力,即亮度增强过程中可能抹除了去模糊所需要的特征线索,导致图像结果的细节和纹理的清晰度仍然欠佳,如图1(d)所示.联合低光照增强与去模糊的模糊感知结构先验(Ambiguity-aware Structural Priors for joint Low-light Enhancement and Deblurring, ASP-LED)^[11]针对全局线索感知设计SNR Transformer以关注图像的亮度和对比度,并设计边缘预测和低频信息预测分支,利用统计特征协同恢复清晰的纹理和结构.基于向量量化码本的更清晰夜间图像恢复(clearer Night Image Restoration with Vector-Quantized Codebook, VQCNIR)^[12]引入高质量码本先验用于指导图像增亮,并设计可变形双向交叉注意力模块,用于对图像的结构和纹理进行复原.这些方法大多针对暗光和模糊这两种图像退化问题进行了专门化设计,以确保模型能够同时关注暗光和模糊问题,但忽略了不同视觉感知之间的相关性.

本文认为,对于多退化的暗光图像增强,需要考虑不同视觉感知的特点及其相关性.一方面,提升暗光图像亮度与颜色需要基于准确的纹理、边缘等信息,这意味着需要抑制和削弱来自噪声和模糊的影响.另一方面,由于暗光条件下纹理和边缘感知大大降低,复原清晰的纹理和边缘需要依赖增亮后场景中的线索.因此,两类感知对于图像增强的作用是相互促进、相辅相成的.本文针对多退化的暗光图像增强设计了渐进式处理过程,以逐步增强的方式减少图像增强过程中特征细节的丢失,并使不同的感知特征交互融合,以此获得高质量的增强结果.具体来说,在每个增强阶段中,利用全局信息对亮度增强与细节复原过程进行自适应调制.同时,在图像增强过程中提取边缘感知特征,再将其传递回图像增强过程以实现感知交互.

针对多退化的暗光图像增强,首先,本文提出渐进



图1 采用不同方法进行多退化暗光图像增强的结果对比

式边缘感知交互增强网络(Progressive Edge-aware Interactive Enhancement Network, PEIE-Net). 具体来说, 该网络由图像增强分支与边缘预测分支组成. 其中, 图像增强分支的每个增强阶段包含自注意力调制预测模块(Self-attention Modulation Prediction Module, SMPM)、通道调制模块(Channel Modulation Module, CMM)和多尺度复原模块(Multi-Scale Restoration Module, MSRM). 其次, 设计场景亮度估计损失协调各个增强阶段的亮度调制. 为提升增强结果图像的细节表现, 本文构建了边缘预测分支, 该分支中的空频域特征变换模块(Spatial-frequency Feature Transformation Module, SFTM)输出的特征用于预测高质量图像的边缘信息. 最后, 边缘预测分支与图像增强分支进行特征交互, 以此模拟不同感知之间的关联. 为了验证本文方法的表现, 我们采用包含暗光、噪声、模糊退化的数据集 LOL-Blur 和 Real-LOL-Blur^[8], 与现有的先进图像处理方法进行了定性与定量实验对比. 此外, 本文还在真实低光照图像超分辨率(Real Low-Light Image Super-Resolution, RELISUR)^[13]数据集上探讨了所提出方法同时处理暗光增强与超分辨率任务的表现.

综上所述, 本文的主要贡献如下:

(1) 提出了一种新颖的渐进式边缘感知交互增强网络用于多退化暗光图像的增强, 该网络由图像增强分支与边缘预测分支组成, 其中两分支之间的特征交互用于模拟不同感知之间的关联;

(2) 提出全局调制预测模块、通道调制模块、多尺度复原模块用于增强过程, 以自注意力方式对亮度增强与细节复原过程进行全局调制, 还提出场景亮度估计损失协调各个增强阶段的亮度调制;

(3) 提出空频域特征变换模块预测高质量图像的边缘信息, 其中边缘预测过程由各个阶段的输出共同参与, 能够引导该模块学习边缘感知的特征;

(4) 在 LOL-Blur 和 Real-LOL-Blur 数据集上的定量和定性实验表明, 本文方法增强包含暗光、噪声、模糊的多退化暗光图像的表现优于现有的图像增强方法, 同时 RELISUR 数据集上的实验表明, 本文方法可用于暗光图像增强与超分辨率任务.

2 相关工作

图像增强与复原是图像处理领域的经典任务, 具

有极其广泛的应用场景. 近期, 随着自动驾驶、全天候监控、人工智能图像分析等领域的发展, 研究人员开始聚焦于暗光/夜间场景下的图像处理任务. 然而, 由于多退化暗光图像增强是包含多种图像退化的综合任务, 其现有研究仍处于初步阶段. 本章中从三个方面概述与本文研究内容相关的工作, 即暗光图像增强、图像去模糊、多退化图像增强.

2.1 暗光图像增强

随着深度学习的发展, 基于深度学习技术的暗光图像增强方法被陆续提出. 其中一类方法将 Retinex 理论和深度学习结合起来, 比如文献[14]通过将暗光图像分解为反射和照明分量来实现增强. 受此工作启发, 文献[15]提出了 KinD 网络, 包含分解、反射图恢复和光照增强三个子网络, 并设计了损失函数以约束照明分量和反射分量的生成. 文献[16]提出单阶段的 Retinexformer, 向反射图与照明图中引入扰动项模拟图像退化. 第二类方法将暗光图像增强任务视为图像转换问题, 直接学习暗光图像到正常光照图像的映射. 例如, 文献[17]在特征和图像空间中利用拉普拉斯金字塔恢复全局光照和局部细节. 文献[18]引入了信噪比解决多变的光照和噪声问题. 然而, 真实拍摄的暗光图像的照度水平差异大, 容易耦合多种退化类型, 从而限制上述两类方法的泛化能力. 总的来说, 暗光图像增强方法主要关注于亮度、颜色的增强与噪声的抑制和去除, 对于多退化暗光图像中的模糊问题缺乏有效的策略.

2.2 图像去模糊

近年来, 对于退化图像增强的研究一直是图像处理的热课题, 例如图像去模糊等应用场景较广的问题. 在拍摄过程中, 成像过程往往受到相机/物体运动的影响, 而获得运动模糊的图像. 因此文献[10]提出多输入多输出 U 型网络(Multi-Input Multi-Output U-Net, MIMO-UNet), 引入非对称特征融合的编解码器逐步恢复清晰图像, 以低计算复杂度处理多尺度模糊. 文献[19]提出幽灵去模糊生成对抗网络(Ghost Deblur Generative Adversarial Network, GhostDeblurGAN), 引入幽灵网络(GhostNet)设计轻量级去模糊网络, 适用于实时图像去模糊. 文献[20]提出 SharpFormer, 该方法引入了全局-局部特征的动态卷积块以自适应处理非均匀模糊. 文献[21]提出结合深度网络与正则化模型对清

晰图像与模糊核联合建模,交替并迭代估计清晰图像与模糊核。然而,当前图像去模糊方法主要面向正常光照的数据场景(即正常光照条件场景的图像),忽略了夜间暗光条件/场景,特别是多退化暗光图像增强面临的低亮度和颜色退化问题。

2.3 多退化图像增强

在实际场景中,由于多重退化的影响,所获取的图像可能存在多种失真问题,如噪声、模糊、马赛克和低分辨率等。为了解决这些多退化问题,现有方法提出了不同的图像增强方案。文献[22]提出了一种用于联合去马赛克、去噪和超分辨率的端到端解决方案,通过颜色提取、特征提取和重建模块实现。文献[23]将单帧运动模糊图像的超分辨率问题分解为运动去模糊和多帧超分辨率两个子问题,利用多帧超分辨率方法提升性能。文献[24]通过对比学习提取退化特征,解决空间目标图像的超分辨率和去模糊问题,而文献[25]使用辅助网络帮助理解全局散焦模糊分布,并联合进行散焦去模糊与超分辨率。

特别地,针对暗光场景,文献[26]提出了暗光超分辨率(Low-light Super-Resolution, LSR)网络,利用反投影算法学习低分辨率空间中亮特征和暗特征间的相互依赖关系。文献[27]提出了循环条件渐进生成对抗网络(Recurrent Conditional Progressive Generative Adversarial Network, Re-CPGAN)网络,结合递归复制粘贴和照明补偿的方式进行暗光图像的超分辨率处理。文献[8]通过端到端网络 LEDNet 解决联合暗光增强和去模糊问题。文献[12]引入高质量码本(Codebook)先验,将光照先验与退化的图像相匹配,以进行结构和细节恢复。文献[28]通过估计边缘和高频映射来设计结构先验以此引导去模糊的过程。文献[29]设计了傅里叶先验引导的零参考 Diffusion 模型,该模型对反向扩散过程的采样结果在傅里叶域中进行分解,并利用生成先验的幅度(Amplitude)将增强后的亮度与自然图像的分布对齐。

面向多种退化类型的图像增强方法在真实世界中具有更广泛的使用场景,而针对多退化暗光图像增强的研究仍处于初步阶段,特别是在模型的泛化能力、增强结果图像观感等方面,需要研究更高效、轻量的增强方法。

3 本文方法

多重感知对视觉观感的作用特性不同且互相关联,如暗光条件下难以感知图像内容,此时亮度和颜色成为影响整体观感的主要因素,而亮度提升一定程度后人眼对于边缘纹理等信息的感知加强,此时更加关注场景中的语义信息(如人脸、车牌、文字等),若语义纹理出现模糊、噪声则会较大程度地影响观感^[30]。因此,增强多退化的暗光图像需要考虑增强过程中不同

感知之间的关联性。本文提出渐进式边缘感知交互增强网络,将图像增强设计为渐进式过程,即通过多个增强阶段逐渐提升图像质量,这使得模型可以更加灵活地应对光照条件、模糊程度不同的场景,从而避免过度增强,同时提高模块复用效率。

图2展示了本文提出的渐进式边缘感知交互增强网络的框架,该网络由图像增强分支与边缘预测分支组成。其中,图像增强分支由多个增强阶段构成,每个阶段由自注意力调制增强网络块实施自适应图像增强,该部分详细设计将在3.1节中介绍。在边缘预测分支中,空频域特征变换模块提取边缘感知特征,使之与图像增强分支交互,该部分详细设计将在3.2节中介绍。最后,本文提出场景亮度估计损失协调各个阶段的亮度增强,以及边缘预测损失对特征学习进行约束。训练本文方法的损失函数将在3.3节中介绍。

3.1 自注意力调制增强

真实场景中所拍摄的多退化暗光图像复杂多样,不仅场景内容多变,而且在光照水平和模糊程度上也有较大差别,这要求图像增强方法能够尽可能地应对更多类型的场景,并且避免过度处理造成的过曝、伪影等问题。因此,本文在构建渐进式图像增强过程的基础上,设计了自注意力调制的自适应增强,以此提高模型应对多种复杂情况的能力。具体来说,提出的自注意力调制增强网络块中,输入特征一方面经过自注意力调制预测模块处理,获得全局通道调制值与全局模式调制核。另一方面,通道调制模块对输入特征进行通道变换与数值缩放,并由全局通道调制值进行整体缩放。而后,多尺度复原模块进一步地对特征进行聚合与复原,并由全局模式调制核进行全局变换。下文将详细介绍各个模块。

(1) 自注意力调制预测模块

图像的整体观感会明显影响人的主观视觉感受^[31],如场景中的亮度、饱和度、结构一致性不佳时,图像会出现明显失真。因此,增强多退化暗光图像有必要对图像的整体观感进行自适应的调整。受到基于卷积核预测机制^[32-34]的启发,本文引入“预测-调制”机制,即将卷积核(调制核)预测作为网络学习的目标之一,以此构建元学习(Meta-Learning)过程^[33],能够提升模型处理复杂问题的灵活性。同时,考虑到图像内在的关联性有益于高保真的场景复原,本文设计自注意力调制预测模块预测全局通道调制值与全局模式调制核,用于对亮度和纹理模式进行全局调整。以第 i 个($i \in \{1, 2, \dots, n\}$)增强阶段为例,自注意力调制预测模块的输入特征 $f_{in} \in \mathbb{R}^{C \times H \times W}$ 经过 3×3 卷积残差块进行块编码得到 $f_e \in \mathbb{R}^{C \times H \times W}$,而后通过自注意力机制处理特征,过程如下:

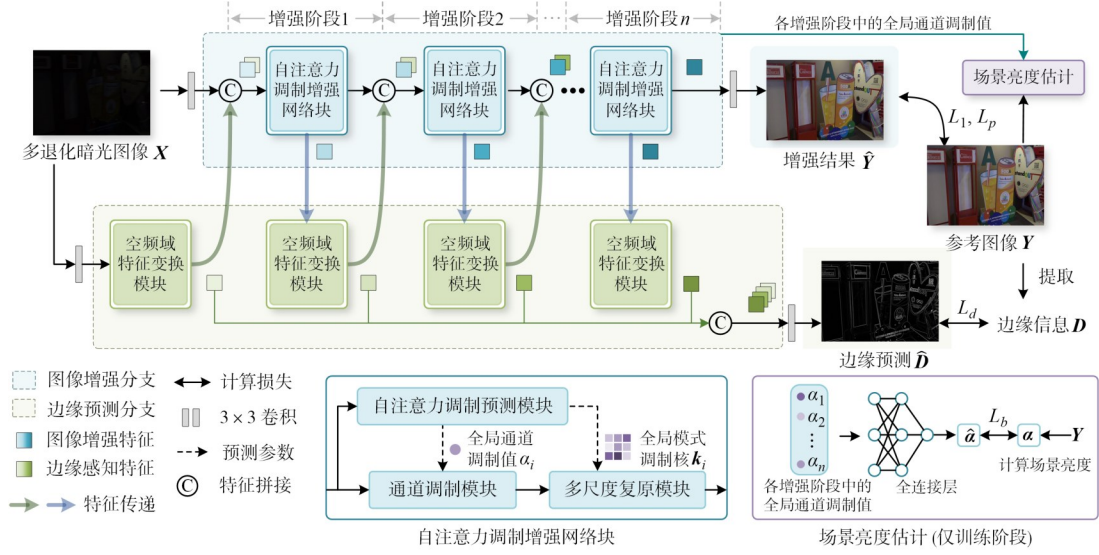


图2 本文提出的渐进式边缘感知交互增强网络的框架图

$$\mathbf{K} = T(\text{Linear}_k(\mathbf{f}_e)) \quad (1)$$

$$\mathbf{V} = T(\text{Linear}_v(\mathbf{f}_e)) \quad (2)$$

$$\mathbf{f}_{\text{att}} = \text{FFN}(\text{Linear}_{\text{att}}(T(\mathbf{Q}\mathbf{K}^T\mathbf{V}))) \quad (3)$$

其中, $\text{Linear}_v(\cdot)$ 、 $\text{Linear}_k(\cdot)$ 分别对特征进行线性映射; $\mathbf{Q} \in \mathbb{R}^{10 \times C}$ 初始化为单位矩阵; 维度变换 $T(\cdot)$ 使得 $\mathbf{K} \in \mathbb{R}^{H \times W \times C}$ 与 $\mathbf{V} \in \mathbb{R}^{H \times W \times C}$ 可用于矩阵乘法运算, 并调整自注意力运算后的特征维度为 $C \times 10$; 而后 $\text{Linear}_{\text{att}}(\cdot)$ 对特征进行降维至 1×10 ; FFN 为前馈网络^[35], 由层归一化、全连接层、GELU 激活函数与全连接层依次堆叠, 且输入和输出间使用残差连接. 利用 $\mathbf{f}_{\text{att}} \in \mathbb{R}^{1 \times 10}$ 获得当前阶段的全局通道调制值 α_i 与全局模式调制核 \mathbf{k}_i 如下:

$$\alpha_i = \mathbf{f}_{\text{att}}[1] \quad (4)$$

$$\mathbf{k}_i = T(\mathbf{f}_{\text{att}}[2:10]) \quad (5)$$

其中, α_i 截取自 \mathbf{f}_{att} 的第 1 个元素; \mathbf{k}_i 截取自 \mathbf{f}_{att} 的第 2~10 个元素; $T(\cdot)$ 将特征维度的空间维度变换为 3×3 , 使得 \mathbf{k}_i 可以作为卷积核使用.

本文设计的自注意力调制预测模块具有如下特性: 第一, 本文设计的全局通道调制值本质上是预测特征的数值缩放, 而全局模式调制核的作用方式与通道可分离卷积类似^[36], 能够用于特征空间模式的变换; 第二, 区别于 LEDNet^[8] 中先增强亮度, 再利用自适应卷积对特征处理的方式, 本文的图像增强分支采用渐进式增强设计, 对于每个网络阶段都进行通道调制与模式调制过程, 能够使模型灵活地应对光照条件、模糊程度不同的场景; 第三, 本文方法与大多预测卷积/调制核的机制不同, 已有方法^[33,34,37] 使用全卷积网络预测卷积/调制核, 而本文提出使用自注意力机制预测作为预测子网络, 能够有效发挥自注意力机制对长距离关系的

捕捉能力.

(2) 通道调制模块

多退化暗光图像中的黑暗区域对应的像素数值很低, 一些方法^[25,35] 将亮度提升过程转换为数值/函数映射运算, 具备较好的可解释性. 受到这一启发, 本文提出构建通道调制的方式以快速实现亮度提升和颜色变换. 具体来说, 通道调制模块可以实现对特征通道的数值缩放与偏置调节. 如图 3 所示, 通道调制模块的输入特征 $\mathbf{f}_{\text{in}} \in \mathbb{R}^{C \times H \times W}$ 首先经过通道升维, 扩充特征空间的编码模式得到特征 $\mathbf{f} \in \mathbb{R}^{4C \times H \times W}$, 而后进行可学习通道调制. 对于 \mathbf{f} 中的第 $v \in [1, 2, \dots, 4C]$ 个通道特征 $f_{[v]}$, 首先经由可学习的通道权重 $\mathbf{W} \in \mathbb{R}^{4C \times 1 \times 1}$ 中对应通道的 $w_{[v]}$ 进行缩放, 再由通道偏置 $\mathbf{B} \in \mathbb{R}^{4C \times 1 \times 1}$ 中对应通道的 $b_{[v]}$ 进行调节, 得到该通道输出 $f'_{[v]}$, 将全部输出通道特征记为 \mathbf{f}' . 再由自注意力调制预测模块所预测的通道调制值 α_i 进行全局调制, 并将通道降维至初始输入的维度, 得到输出特征 $\mathbf{f}_{\text{ch}} \in \mathbb{R}^{C \times H \times W}$. 上述过程可以形式化表示为

$$\mathbf{f}_{\text{ch}} = \text{Conv}_{1 \times 1}(\text{Conv}_{1 \times 1}(\mathbf{f}_{\text{in}}) \otimes \mathbf{W} \oplus \mathbf{B}) \otimes \alpha_i \quad (6)$$

其中, $\text{Conv}_{1 \times 1}(\cdot)$ 为 1×1 的卷积; \otimes 为特征相乘运算; \oplus 为特征相加运算.

本文构建的通道调制模块有如下两个特性: 其一, 特征的代数运算可以模拟对于图像的亮度、色调、饱和




图3 通道调制模块

度的调整. 本文方法结合 CNN 通道对于特征的分布式表示特性^[38], 基于通道的调制可以在高维空间中更精细地完成上述调整. 其二, 本文设计的全局通道调制是动态进行的, 这意味着对于不同的输入可以进行自适应的调制, 有利于提升对多样光照场景的处理能力.

(3) 多尺度复原模块

基于多尺度的特征处理能够有效地扩大特征的感受野, 有助于捕获场景中不同大小的物体, 因而在图像增强与复原任务中被广泛使用. 同时, 图像特征在缩小后能够削弱模糊、噪声等退化对视觉感知的影响, 有助于模型输出高质量的增强结果. 因此本文提出多尺度复原模块.

如图 4 所示, 多尺度复原模块首先对输入特征在原尺寸、 $\times 2$ 倍缩小尺寸、 $\times 4$ 倍缩小尺寸上分别处理. 具体

来说, 对于每种尺寸特征的处理由 3 个残差单元进行, 而 $\times 4$ 与 $\times 2$ 倍缩小尺寸特征在前两个残差单元处理后, 均与更大尺寸 (即 $\times 2$ 倍缩小尺寸和原尺寸) 的特征通过融合单元进行融合. 其中, 残差单元由 4 个残差块施加跳跃连接组成, 残差块则由 3×3 卷积、LeakyReLU 激活函数、 3×3 卷积堆叠并施加跳跃连接组成. 而后, 经过所有残差单元处理后的 $\times 2$ 、 $\times 4$, 以及原尺寸特征与未经处理的特征进行拼接. 最后, 在全局调制单元中, 多尺度拼接特征经过 1×1 卷积处理得到多尺度融合特征, 同时自注意力调制预测模块所预测的全局模式调制核 k_i 经过 1×1 卷积升维, k_i 升维后以卷积核的方式作用于多尺度融合特征, 此处的计算方式为通道可分离卷积^[36].

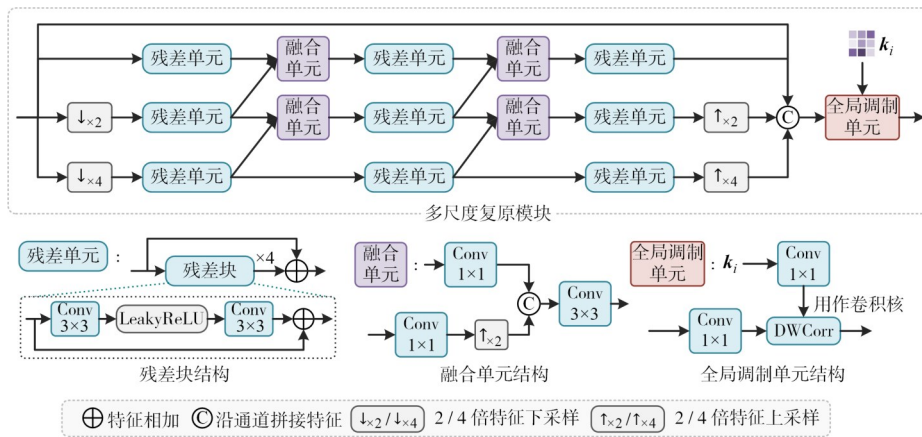


图 4 多尺度复原模块

3.2 边缘感知特征交互

多退化暗光图像中黑暗区域内的场景内容难以感知, 尤其是语义纹理等细节信息, 此时改善可视度的最直接方式是提升图像亮度与颜色. 然而, 对基于深度学习的暗光图像增强方法来说, 上述直接提升亮度与颜色的方式在应对多退化暗光图像时存在较大的限制. 具体来说, 深度模型在训练时对于低频信息 (表现为亮度、颜色等) 更为偏好^[39], 这意味着模型会更倾向于优先学习亮度增强与颜色校正, 使得模型求解陷入局部最优. 另外, 噪声通常会因亮度提升被放大, 同时去模糊的线索也可能被平滑. 为应对这些挑战, 本文在构建渐进式图像增强过程的基础上, 提出边缘感知特征交互, 使得模型在增强图像时能够复原清晰的边缘, 以输出更高质量的增强结果. 下文将详细介绍边缘感知特征提取与交互.

(1) 边缘感知特征提取

如图 2 所示, 本文方法基于输入图像以及每个增强阶段的图像增强特征提取边缘感知特征, 并提出空频域特征变换模块. 该模块的结构如图 5 所示, 其中包含

两个主要分支, 分别用于空间域特征变换和频域特征变换. 具体来说, 空间域特征变换分支对输入特征进行基于空间注意力的处理: 一方面由 3×3 卷积、LeakyReLU 激活函数、 3×3 卷积堆叠并施加跳跃连接组成的残差块直接变换特征; 另一方面首先由沿通道的最大池化 (MAX pooling, MAX) 和平均池化运算 (AVerage pooling, AVG) 捕获不同的特征, 再由 7×7 卷积、Sigmoid 激活函数计算注意力权重, 而后二者相乘得到空间注意力特征. 频域特征变换分支中, 首先由 1×1 卷积、LeakyReLU 激活函数处理输入特征, 而后在频域空间处理特征, 过程为: 快速傅里叶变换 (Fast Fourier Transform, FFT)、 1×1 卷积、LeakyReLU 激活函数、快速傅里叶逆变换 (Inverse Fast Fourier Transform, IFFT), 并且施加残差连接. 最后, 空间域特征变换分支与频域特征变换分支的结果沿着通道拼接, 经过 1×1 卷积降维后得到提取的边缘感知特征.

本文认为, 提取边缘感知特征的关键在于: 将特征提取的过程与场景的边缘描述建立关联. 因此, 本文设计边缘预测任务以获得边缘感知特征. 如图 2 所示, 空

频域特征变换模块基于输入图像以及每个增强阶段的图像增强特征分别提取边缘感知特征,并在网络的前馈计算过程中保留,然后在通道拼接后经由 3×3 卷积输出对高质量图像边缘的预测.通过这种方式,能够实现对边缘感知特征提取过程的间接约束,允许模型在高维空间中编码并存储对于细节复原有价值的特征线索.

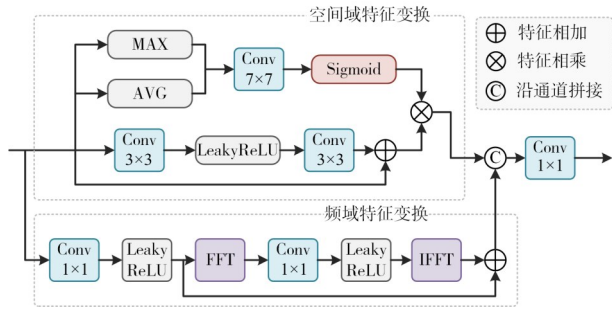


图5 空频域特征变换模块

(2) 边缘感知特征交互

图像边缘刻画了场景中的主要构成轮廓和纹理,是独立于亮度、颜色等信息的描述方式.增强图像时,提升亮度、颜色的感知能使得轮廓细节更明显,而复原清晰的轮廓反过来有助于增强正确的亮度与颜色,这启发本文提出基于边缘感知交互的图像增强方式.基于提出的渐进式图像增强,本方法设计了每个增强阶段特征与边缘感知特征的交互过程,以此模拟不同感知之间的关联.

如图2所示,首先,多退化暗光图像经过卷积编码的特征,与空频域特征变换模块输出的特征进行拼接后,作为第1个增强阶段的输入.其次,对于第 $i = \{1, 2, \dots, n-1\}$ 个增强阶段,图像增强分支的特征被用于提取边缘感知特征,同时边缘预测分支输出的边缘感知特征进一步融合至下一个阶段的图像增强特征流中,完成感知的双向交互.最后,对于第 n 个增强阶段,图像增强分支的输出经过 3×3 卷积变换得到增强结果,而边缘预测分支经由 3×3 卷积输出边缘预测结果.通过在渐进式增强过程中设计边缘感知特征交互,模型能够关注复原边缘信息的线索特征,进而有助于增强结果图像的细节表现.

3.3 损失函数

本节中将介绍训练渐进式边缘感知交互增强网络的损失函数.为使得多退化暗光图像增强的结果趋于正常光照下的高质量图像,计算网络输出的增强结果与参考图像之间的L1损失与感知损失,计算式为

$$L_r = \|\hat{Y} - Y\|_1 + \lambda_p \|\Phi(\hat{Y}) - \Phi(Y)\|_1 \quad (7)$$

其中, \hat{Y} 为网络输出的增强结果; Y 为参考图像; $\Phi(\cdot)$ 是VGG-19提取多尺度特征的运算;感知损失的权重值

$\lambda_p = 0.01$ 为经验设置,用于平衡损失数值.

在本方法中,每个增强阶段均会预测全局通道调制值,并对特征进行全局调制以动态调节亮度水平.进一步地,为协调各个增强阶段之间的全局通道调制,本文提出场景亮度估计.如图2所示,对于各增强阶段中全局通道调制值 $\{\alpha_1, \alpha_2, \dots, \alpha_n\}$,由全连接层输出场景亮度的估计值 $\hat{\alpha}$,并与场景亮度值 α 计算损失为

$$L_b = \|\hat{\alpha} - \alpha\|_1 \quad (8)$$

其中,场景亮度值 α 由参考图像变换至HSV色彩空间后,计算V(亮度)通道的均值得到.

用于3.2节中边缘预测任务的损失函数的计算式为

$$L_d = \|\hat{D} - D\|_2^2 \quad (9)$$

其中, \hat{D} 为网络输出的边缘预测结果; D 为参考图像经过Sobel算子^[40]所提取的边缘信息,二者计算平方损失以增强对细节损失的敏感程度.

综上,训练渐进式边缘感知交互增强网络的总损失函数可表示为

$$L_{\text{total}} = \lambda_r L_r + \lambda_b L_b + \lambda_d L_d \quad (10)$$

其中, $\lambda_r = 1$, $\lambda_b = 0.3$, $\lambda_d = 0.2$ 为用于平衡损失的超参数.

4 实验与分析

4.1 实现细节

本文提出的渐进式边缘感知交互增强网络包含多个增强阶段,本实验设置增强阶段的数目为 $n=4$,此时模型的参数量为7.779 M.此网络使用包含暗光、噪声、运动模糊图像的合成数据集LOL-Blur^[8]进行训练,其中训练集包含10 200个图像对,训练用的图像块的大小为 256×256 .训练过程使用Adam优化器优化,并设置 $\beta_1 = 0.9$, $\beta_2 = 0.99$,学习率为 10^{-4} ,批次大小为4,训练迭代次数为 5×10^5 ,上述设置是遵循基于深度学习的图像增强方法所采用的一般经验数值.本文中的实验均在NVIDIA A40 GPU上进行.

4.2 对比实验

本文在具备暗光、噪声、运动模糊的数据集LOL-Blur与Real-LOL-Blur上进行测试,以验证本文方法的有效性.其中LOL-Blur的测试集包含1 800个成对图像,每个测试图像对中包含低质量图像,以及用于评估的高质量参考图像.

因此本文采用峰值信噪比(Peak Signal to Noise Ratio, PSNR)、结构相似度(Structural SIMilarity index, SSIM)和学习感知图像相似度(Learned Perceptual Image Patch Similarity, LPIPS)作为客观评价指标.此外,Real-LOL-Blur数据集包含1 354张夜间真实拍摄的非成对图像,因此本文采用自然图像质量评价(Natural Image Quality Evaluator, NIQE)、盲/无参考图像空间质

量评估(Blind/Referenceless Image Spatial Quality Evaluator, BRISQUE)和感知指标(Perceptual Index, PI)作为评价指标。

文献[8]已证明了使用现有方法顺序处理图像无法获得高质量增强结果,因此本文的对比实验重点探讨使用专门数据集 LOL-Blur 重新训练现有方法的有效性。本文对比的方法有,暗光图像增强方法:基于傅里叶的低照度增强(Fourier-based Low-Light Image Enhancement network, FourLLIE)^[41]、光照自适应的 Transformer (Illumination Adaptive Transformer, IAT)^[35]、LLFormer^[9];去模糊方法:多输入多输出(Multi-Input Multi-Output, MIMO)网络^[10]、SharpFormer^[20]、FFTformer^[42];端到端联合训练暗光图像增强方法与去模糊方法:联合训练 LLFormer 与 MIMO、联合训练 LLFormer 与 FFTformer;以及暗光模糊图像增强方法 LEDNet^[8]、VQC NIR^[12]。表 1 中

给出了所有对比方法在 LOL-Blur 与 Real-LOL-Blur 上的定量分析结果,以及各个方法模型的参数量,其中加粗代表最好性能,下划线代表第二名的性能。

由表 1 可知,重训练后的去模糊方法在 LOL-Blur 上相较于暗光增强方法可以取得更好的 SSIM 表现。同时,联合训练两类方法有助于提升 PSNR,但是可能降低 SSIM 和 LPIPS 指标的表现。在 Real-LOL-Blur 上, MIMO、FFTformer 等方法的增强结果的 BRISQUE 质量分数表现没有优于输入图像,同时联合训练的模型也难以取得更显著的优势,这说明了增强真实场景图像的困难。综合来看,SharpFormer 取得两项排名第二的性能指标,但是参数量高达 515.11 M, VQC NIR 与本文方法 PEIE-Net 在 LOL-Blur 与 Real-LOL-Blur 数据集的定量评估表现近似,但是本文方法的 7.78 M 参数量远小于 VQC NIR 的 47.85 M 参数量,充分说明了本文方法的有效性。

表 1 LOL-Blur 与 Real-LOL-Blur 数据集上的方法对比

方法	LOL-Blur 测试集			Real-LOL-Blur			模型参数/M
	PSNR ↑	SSIM ↑	LPIPS ↓	NIQE ↓	BRISQUE ↓	PI ↓	
输入图像	10.735	0.309	0.498	6.554	38.428	5.975	—
FourLLIE	19.808	0.699	0.439	5.484	35.815	5.749	0.18
IAT	21.404	0.728	0.424	5.711	26.105	5.462	0.09
LLFormer	24.549	0.798	0.354	6.107	39.803	5.998	24.55
MIMO	22.618	0.827	0.269	5.871	43.069	5.539	6.81
SharpFormer	23.997	<u>0.871</u>	0.233	<u>4.865</u>	37.330	4.645	515.11
FFTformer	24.381	0.867	0.238	5.173	41.129	4.991	16.56
LLFormer+MIMO	24.671	0.834	0.314	5.483	37.338	5.297	31.36
MIMO+LLFormer	24.986	0.840	0.302	5.424	35.863	5.159	31.36
LLFormer+FFTformer	24.998	0.854	<u>0.224</u>	6.501	48.924	5.567	41.11
FFTformer+LLFormer	25.376	0.861	<u>0.224</u>	6.153	50.104	5.638	41.11
LEDNet	25.740	0.850	0.224	5.337	46.022	4.881	7.41
VQC NIR	27.793	<u>0.875</u>	0.172	4.599	36.916	3.806	47.85
PEIE-Net(本文方法)	<u>26.766</u>	0.879	<u>0.184</u>	4.458	<u>33.376</u>	<u>4.067</u>	7.78

图 6 中展示了对比方法与本文方法对来自 LOL-Blur 数据集中图像的增强结果。可以观察到,FourLLIE 与 IAT 的增强结果的颜色欠佳且模糊仍然存在, MIMO 与 LLFormer 组合模型以及 LEDNet 的增强结果中的广告牌文字难以辨识。在 LLFormer 与 FFTformer 组合模型输出的增强结果中,图片左侧树木的亮度较低。本文方法的增强结果的亮度与颜色观感自然,纹理复原较为清晰,更接近参考图像。

图 7 中展示了对比方法与本文方法对来自 Real-LOL-Blur 的真实场景图像的增强结果。可以观察到, IAT 的处理结果出现了过度增强, MIMO 与 SharpFormer 在增强夜空时引入了亮度不一致的伪影, FFTformer 的结果整体更亮,但是去模糊效果不理想。在 LLFormer 和 FFTformer 的组合模型以及 LEDNet 输出的增强结果

中,左侧建筑物的可视度不佳。VQC NIR 方法的结果中,汽车灯仍然存在较为明显的模糊。本文方法能够有效提升场景亮度,同时复原出更清晰的纹理细节,所生成的增强结果具备较好的视觉观感。

4.3 消融实验

为验证所设计的各个模块的有效性,我们在 LOL-Blur 与 Real-LOL-Blur 上通过消去既定的模块、损失或网络结构的方式进行消融对比实验,以评估对应部分的作用。具体来说,首先对于(1)通道调制模块进行消融,其次对于(2)多尺度复原模块进行消融,接着对于(3)自注意力调制预测模块的必要性进行分析,再对本文提出的(4)边缘感知特征交互机制进行分析,进一步对于本文设计的(5)损失函数进行消融,最后讨论(6)增强阶段数目设置对性能的影响。



图6 合成数据集 LOL-Blur 上的方法对比



图7 真实数据集 Real-LOL-Blur 上的方法对比

(1) 通道调制模块

在表2中,实验(1)将整个通道调制模块从网络中去除,导致 LOL-Blur 数据集的 PSNR 指标大幅下降以及 Real-LOL-Blur 数据集 BRISQUE 表现的显著降低,实验(2)与实验(3)分别说明了本文通道调制模块中,权重项以及偏置项的预测在调节亮度的必要性。具体来说,去除式(6)中的权重项 W 使得 Real-LOL-Blur 数据集的 NIQE 与 PI 表现变差,而去掉式(6)中的偏置项 B 使得 LOL-Blur 数据集的 PSNR 与 SSIM 指标下降。

(2) 多尺度复原模块

在表3中,实验(1)将整个多尺度复原模块从网络中去除,对于所有的指标都有较大影响,这是由于多尺度复原模块提取了用于图像增强的基础特征,并且该模块的参数量占总模型比重较大,去除时影响模型的整体表现。实验(2)对于本文设计的融合单元进行了消融,证明了该单元的特征融合功能对高质量特征提取的必要性,尤其对 LOL-Blur 数据集中 PSNR、SSIM 指标有较大影响。

(3) 自注意力调制预测模块

在表4中,实验(1)与实验(2)分别取消了对全局通道调制与全局模式调制的预测过程,因此通道调制模块与多尺度复原模块中的全局调制过程也不会进行。而实验(3)则同时去除这两种调制机制,可以看出,在不使用本文所设计的全局通道调制与全局模式调制的情况下,合成数据集 LOL-Blur 与真实非成对数据集 Real-LOL-Blur 的指标都有较明显的下降,说明了自注意力调制预测模块在网络中的有效性。

(4) 边缘感知交互机制

由表5可知,实验(1)的网络不使用边缘感知特征交互,即仅依靠图像增强分支进行渐进式增强,其 PSNR、SSIM 值均有比较明显的降低;实验(2)设置为在边缘预测分支中不使用空频域特征变换模块提取特征,而使用等参数的普通卷积替代,此时模型的整体指标均出现下降,说明了本文的空频域特征变换模块对于边缘感知特征提取的效果更好。

表 2 通道调制模块消融实验结果

实验	消融设置	LOL-Blur 测试集			Real-LOL-Blur		
		PSNR \uparrow	SSIM \uparrow	LPIPS \downarrow	NIQE \downarrow	BRISQUE \downarrow	PI \downarrow
实验(1)	不使用通道调制模块	26.060	0.870	0.196	4.714	37.607	4.259
实验(2)	去除式(6)中的 W	26.397	0.877	0.185	4.661	33.915	4.254
实验(3)	去除式(6)中的 B	26.545	0.874	0.187	4.565	33.898	4.124
本文方法		26.766	0.879	0.184	4.458	33.376	4.067

表 3 多尺度复原模块消融实验结果

实验	消融设置	LOL-Blur 测试集			Real-LOL-Blur		
		PSNR \uparrow	SSIM \uparrow	LPIPS \downarrow	NIQE \downarrow	BRISQUE \downarrow	PI \downarrow
实验(1)	不使用多尺度复原模块	24.819	0.830	0.258	5.529	43.635	5.048
实验(2)	去除融合单元	25.955	0.869	0.194	4.823	37.649	4.442
本文方法		26.766	0.879	0.184	4.458	33.376	4.067

表 4 自注意力调制预测模块消融实验结果

实验	消融设置	LOL-Blur 测试集			Real-LOL-Blur		
		PSNR \uparrow	SSIM \uparrow	LPIPS \downarrow	NIQE \downarrow	BRISQUE \downarrow	PI \downarrow
实验(1)	不使用全局通道调制 α_i	26.229	0.872	0.189	4.611	34.990	4.238
实验(2)	不使用全局模式调制 k_i	26.553	0.871	0.192	4.630	33.853	4.237
实验(3)	不使用全局通道调制 α_i 与全局模式调制 k_i	25.643	0.870	0.202	4.574	33.773	4.311
本文方法		26.766	0.879	0.184	4.458	33.376	4.067

表 5 边缘感知交互机制消融实验结果

实验	消融设置	LOL-Blur 测试集			Real-LOL-Blur		
		PSNR \uparrow	SSIM \uparrow	LPIPS \downarrow	NIQE \downarrow	BRISQUE \downarrow	PI \downarrow
实验(1)	不使用边缘感知特征交互	25.955	0.865	0.198	5.019	40.384	4.550
实验(2)	不使用空频域特征变换模块	26.121	0.869	0.194	4.780	33.737	4.020
本文方法		26.766	0.879	0.184	4.458	33.376	4.067

针对本文提出的渐进式边缘感知交互增强网络,我们进一步地对网络的中间特征进行可视化分析.如图 8 所示,图 8(a)是输入的多退化暗光图像,图 8(b)为参考图像,图 8(c)为不使用边缘感知交互(即表 5 中实验(1))的增强结果,图 8(d)为本文方法的增强结果,图 8(e)与图 8(f)为图像增强分支各个增强阶段的输出特征,黑色框中为其局部放大区域.可以观察到,在使用多个相同增强阶段的渐进式增强设计方式下,无论是否使用了边缘感知特征交互,其特征的纹理模式都呈现逐渐精细化的趋势,说明图像增强以渐进方式进行.

这种渐进式增强设计能够有效提高模块的复用效率,同时为图像增强模型的细节与纹理复原过程提供了良好的可解释性^[43-45].其次,相较于不使用边缘感知特征交互的网络(图 8(e)),本文方法的输出特征(图 8(f))更加关注于边缘纹理,这种更精细化的特征编码使增强结果中细节复原的效果更好,进一步证明了提出的边缘感知特征交互的有效性.此外,针对本文方法中的空频域特征变换模块,本文将使用该模块时和使用等量卷积替代该模块时(即表 5 中实验(2))的增强结果与

边缘预测结果进行对比.如图 9 所示,图 9(a)是输入的多退化暗光图像,图 9(e)是利用 Sobel 算子^[40]提取多退化暗光图像的边缘信息,图 9(b)与图 9(c)为参考图像及 Sobel 算子^[40]提取的参考图像边缘信息,图 9(c)与图 9(g)是使用等量卷积替代空频域特征变换模块后(即表 5 中实验(2))的模型得到的增强结果及其边缘信息的预测结果,图 9(d)与图 9(h)是使用本文空频域特征变换模块的增强结果及其边缘信息的预测结果.可以看出,本文方法能够预测更高质量的边缘信息,增强结果中的细节表现也相应更好,如放大区域中第二行的字母“A”“N”“G”更为接近参考图像.

(5) 损失函数

在表 6 中,实验(1)与实验(2)验证了本文提出的场景亮度估计损失与边缘预测损失的作用.其中场景亮度估计损失的作用在于协调各个增强阶段之间的亮度提升程度,去除该损失函数时,对于亮度调节能力的影响较为明显,即 LOL-Blur 数据集的 PSNR 指标受到较为显著的影响.另一方面,本文边缘预测损失旨在提升模型对于边缘纹理等细节特征的代表能力,去除该损失

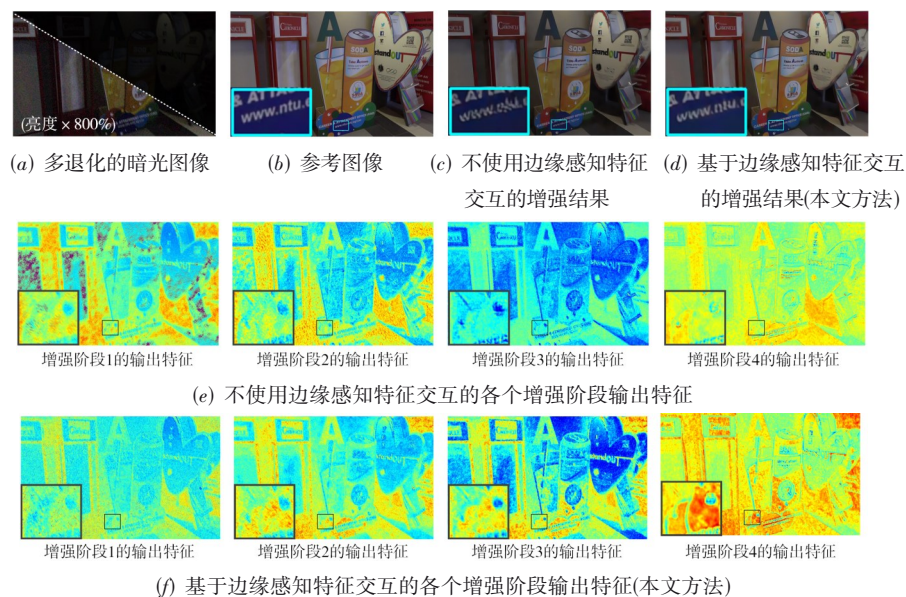


图8 增强阶段特征可视化与结果对比

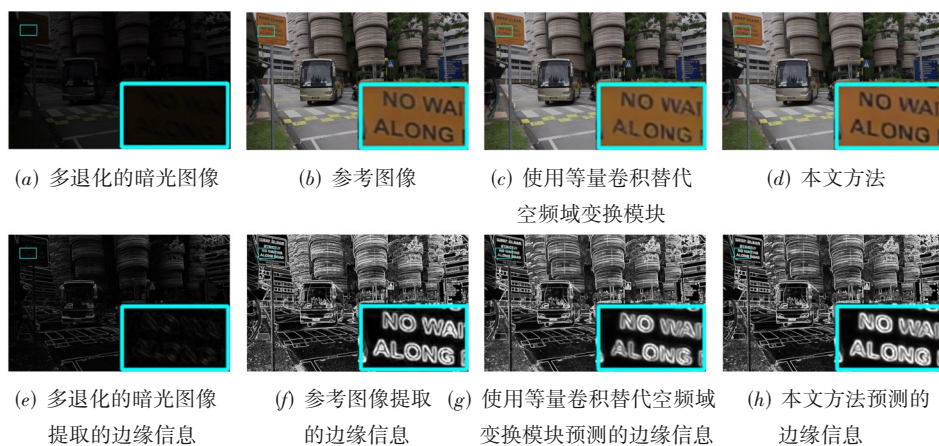


图9 空频域特征变换模块的消融可视化

表6 损失函数消融实验结果

实验	消融设置	LOL-Blur 测试集			Real-LOL-Blur		
		PSNR \uparrow	SSIM \uparrow	LPIPS \downarrow	NIQE \downarrow	BRISQUE \downarrow	PI \downarrow
实验(1)	不使用场景亮度估计损失 L_b	26.321	0.876	0.191	4.488	34.553	4.116
实验(2)	不使用边缘预测损失 L_d	26.182	0.871	0.189	4.701	35.936	4.309
	本文方法	26.766	0.879	0.184	4.458	33.376	4.067

对 LOL-Blur 数据集的 SSIM 指标以及 Real-LOL-Blur 数据集的 NIQE 指标影响较大。

(6) 增强阶段数目设置

本文采用多阶段的渐进式图像增强设计,其中增强阶段的数量是可设置的超参数。图 10 中展示了在设置不同增强阶段数量的情况下,模型大小与模型 PSNR 和 SSIM 指标的关系。其中图 10(a)表明本文方法在设置增强阶段数量为 4 时已经达到了较高 PSNR 水平,而更多的增强阶段带来的 PSNR 提升较小。图 10(b)表明在设

置增强阶段数量为 5 时可以取得更好的 SSIM 表现,而增强阶段数量为 6 时则 SSIM 略有下降,这是因为更深的网络对于图像纹理细节的丢失风险相对更高。

4.4 暗光图像增强与超分辨率

受到相机传感器或光学变焦的限制,暗光场景下拍摄的图像还可能同时受到低分辨率的影响。同时进行暗光图像增强与超分辨率是获得夜间高质量图像的重要方式,因而逐渐受到图像增强领域研究者的关注。本文提出的基于渐进式边缘感知交互的增强网络能够提升暗光图

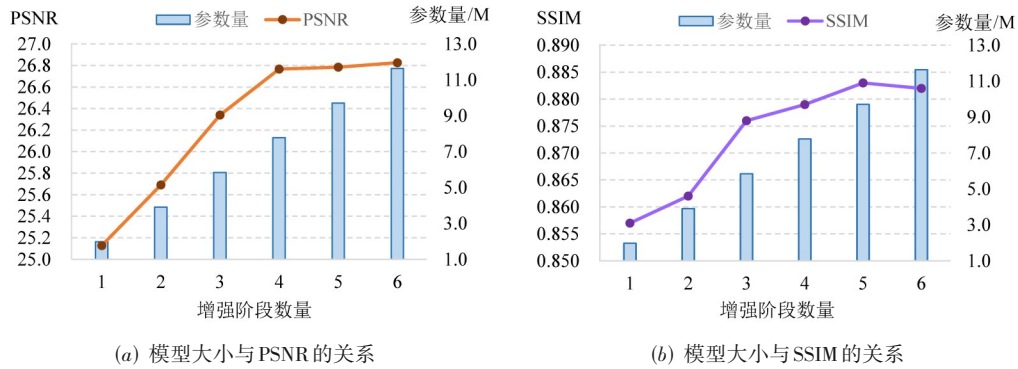


图 10 增强阶段数量设置分析

像的内容可可见度,并具备边缘细节复原能力,因此也可以用于进行暗光图像增强与超分辨率任务. 本文使用真实数据集 RELISUR^[13]进行训练并测试所提出方法在暗光图像增强与超分辨率任务上的表现. 此外,为了匹配超分辨率任务对于图像尺寸提升的需求,我们将本文方法与上采样模块^[46]进行结合并训练,训练的超参数设置仍然使用 4.1 节中的值,未进行额外的调参与设置.

遵循暗光图像增强与超分辨率研究^[47-50]中的典型设置,我们将低照度增强方法 IAT^[35]、LLFormer^[9]拼接上采样模块^[46]并进行重新训练,也引入超分辨率方法混合注意力 Transformer (Hybrid Attention Transformer, HAT)^[51]、SMFANet (Self-Modulation Feature Aggregation Network)^[52]、SRformer^[53]以及 Restormer^[54]在 RELISUR 上进行重新训练与测试,以此探究利用已有方法解决多重退化的效果.

本文对比了近几年提出的暗光图像增强与超分辨率任务的专用方法: LUCN^[47]、DiD^[48]、CollaBA^[49]和 LoLiSRFlow^[50],这些方法均是专门为联合暗光图像增强与超分辨率任务设计的,并同样在 RELISUR 上进行训练与测试的. 实验结果如表 7 所示,在 PSNR、SSIM、LPIPS 指标评估下,第一/第二名表现使用加粗/下划线标记. 可以看出,本文方法取得了最优的 SSIM 指标,以及次优的 PSNR 指标,这说明本文方法能够应对真实暗光场景下多种退化问题,并且对于暗光图像增强与超分辨任务具备良好的泛化能力.

图 11 中展示了本文方法应用于暗光图像增强与超分辨率任务数据集 RELISUR 的增强结果,其右侧为各个方法的局部放大区域. 可以看出,低分辨率暗光图像经过增强后,大多数方法都能有效提升亮度并改善颜色. 然而在细节方面,本文方法对纹理重建的表现更好,说明了本文提出的基于渐进式边缘感知交互的增强网络具有增强暗光场景亮度与颜色、改善细节感知的能力,可用于暗光增强与超分辨率任务.

5 结论

针对多退化的暗光图像增强,本文提出渐进式边缘感知交互增强网络,由图像增强分支与边缘预测分支组

表 7 暗光图像增强与超分辨率任务对比

方法	RELLISUR 测试集(×4)		
	PSNR ↑	SSIM ↑	LPIPS ↓
输入图像+上采样	8.292	0.143	0.836
IAT	15.870	0.679	0.763
LLFormer	19.471	0.752	0.632
HAT	18.103	0.741	0.625
SMFANet	19.743	0.758	0.550
SRFormer	18.252	0.746	0.595
Restormer	20.919	0.755	0.503
LUCN	19.824	0.652	0.708
DiD	21.036	0.726	0.371
CollaBA	20.423	0.734	0.371
LoLiSRFlow	21.580	<u>0.742</u>	—
本文方法	<u>21.144</u>	0.767	0.451



图 11 RELISUR 数据集的结果对比

成. 在图像增强分支中,设计自注意力调制预测模块,对通道调制模块和多尺度复原模块进行自适应调制. 在边

缘预测分支中,设计空频域特征变换模块提取边缘感知信息,使之与图像增强分支特征融合,以模拟不同感知之间的交互. 在 LOL-Blur 与 Real-LOL-Blur 上的实验表明:本文方法处理多退化暗光图像的有效性与先进性,并可用于暗光增强与超分辨率任务. 在今后的工作中,将尝试使用对抗学习等无监督训练策略,减少对成对训练数据集的需求,进一步提升网络的泛化能力.

参考文献

- [1] 江泽涛, 施道权, 雷晓春, 等. 一种基于 Night-YOLOX 的低照度目标检测方法[J]. 电子学报, 2023, 51(10): 2821-2830. JIANG Z T, SHI D Q, LEI X C, et al. A low-illumination object detection method based on Night-YOLOX[J]. Acta Electronica Sinica, 2023, 51(10): 2821-2830. (in Chinese)
- [2] LI Y Z, NIU Y Z, XU R, et al. Zero-referenced enlightening and restoration for UAV nighttime vision[J]. IEEE Geoscience and Remote Sensing Letters, 2024, 21: 8002105.
- [3] 牛玉贞, 林晓锋, 许煌标, 等. 基于 Transformer 的多尺度优化低照度图像增强网络[J]. 模式识别与人工智能, 2023, 36(6): 511-529. NIU Y Z, LIN X F, XU H B, et al. Transformer-based multi-scale optimization network for low-light image enhancement[J]. Pattern Recognition and Artificial Intelligence, 2023, 36(6): 511-529. (in Chinese)
- [4] WANG W J, XU Z B, HUANG H F, et al. Self-aligned concave curve: Illumination enhancement for unsupervised adaptation[C]// Proceedings of the 30th ACM International Conference on Multimedia. New York: ACM, 2022: 2617-2626.
- [5] WANG Y F, WAN R J, YANG W H, et al. Low-light image enhancement with normalizing flow[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36(3): 2604-2612.
- [6] LIU R S, MA L, MA T Y, et al. Learning with nested scene modeling and cooperative architecture search for low-light vision[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(5): 5953-5969.
- [7] 江泽涛, 钱艺, 伍旭, 等. 一种基于 ARD-GAN 的低照度图像增强方法[J]. 电子学报, 2021, 49(11): 2160-2165. JIANG Z T, QIAN Y, WU X, et al. Low-light image enhancement method based on ARD-GAN[J]. Acta Electronica Sinica, 2021, 49(11): 2160-2165. (in Chinese)
- [8] ZHOU S C, LI C Y, CHANGE LOY C. LEDNet: Joint low-light enhancement and deblurring in the dark[M]// Computer Vision-ECCV 2022. Cham: Springer Nature Switzerland, 2022: 573-589.
- [9] WANG T, ZHANG K H, SHEN T R, et al. Ultra-high-definition low-light image enhancement: A benchmark and transformer-based method[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2023, 37(3): 2654-2662.
- [10] CHO S J, JI S W, HONG J P, et al. Rethinking coarse-to-fine approach in single image deblurring[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2021: 4621-4630.
- [11] YE J, LIU Y, YU C J, et al. ASP-LED: Learning ambiguity-aware structural priors for joint low-light enhancement and deblurring[C]//2024 IEEE International Conference on Robotics and Automation (ICRA). Piscataway: IEEE, 2024: 12389-12396.
- [12] ZOU W B, GAO H X, YE T, et al. VQCNIR: Clearer night image restoration with vector-quantized codebook[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2024, 38(7): 7873-7881.
- [13] AAKERBERG A, NASROLLAHI K, MOESLUND T B. RELISUR: A real low-light image super-resolution dataset[C]// In Advances in Neural Information Processing Systems 35 (NeurIPS 2021). Schloss Dagstuhl: DBLP, 2021: 5234969.
- [14] WEI C, WANG W, YANG W, et al. Deep retinex decomposition for low-light enhancement[C]//Proceedings of the Conference on British Machine Vision Conference. Newcastle: BMVC, 2018: 1-12.
- [15] ZHANG Y H, ZHANG J W, GUO X J. Kindling the darkness: A practical low-light image enhancer[C]//Proceedings of the 27th ACM International Conference on Multimedia. New York: ACM, 2019: 1632-1640.
- [16] CAI Y H, BIAN H, LIN J, et al. Retinexformer: One-stage retinex-based transformer for low-light image enhancement[C]// 2023 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2023: 12470-12479.
- [17] LIM S, KIM W. DSLR: Deep stacked Laplacian restorer for low-light image enhancement[J]. IEEE Transactions on Multimedia, 2020, 23: 4272-4284.
- [18] XU X G, WANG R X, FU C W, et al. SNR-aware low-light image enhancement[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2022: 17693-17703.
- [19] LIU Y B, HARIDEVAN A, SCHOFIELD H, et al. Application of ghost-DeblurGAN to fiducial marker detection[C]//2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Piscataway: IEEE, 2022: 6827-6832.
- [20] YAN Q S, GONG D, WANG P, et al. SharpFormer: Learning local feature preserving global representations for image deblurring[J]. IEEE Transactions on Image Processing, 2023, 32: 2857-2866.
- [21] 白勇强, 禹晶, 李一稔, 等. 基于深度先验的盲图像去模糊算法[J]. 电子学报, 2023, 51(4): 1050-1067. BAI Y Q, YU J, LI Y N, et al. Deep prior-based blind image deblurring[J]. Acta Electronica Sinica, 2023, 51(4): 1050-1067. (in Chinese)

- [22] XING W Z, EGIAZARIAN K. End-to-end learning for joint image demosaicing, denoising and super-resolution[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2021: 3506-3515.
- [23] NIU W J, ZHANG K H, LUO W H, et al. Blind motion deblurring super-resolution: When dynamic spatio-temporal learning meets static image understanding[J]. *IEEE Transactions on Image Processing*, 2021, 30: 7101-7111.
- [24] YANG X, WANG X Q, WANG N N, et al. SRDN: A unified super-resolution and motion deblurring network for space image restoration[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60: 5614411.
- [25] WANG R, ZHANG C J, ZHENG X L, et al. Joint defocus deblurring and superresolution learning network for autonomous driving[J]. *IEEE Intelligent Transportation Systems Magazine*, 2024, 16(1): 104-115.
- [26] RASHEED M T, SHI D M. LSR: Lightening super-resolution deep network for low-light image enhancement[J]. *Neurocomputing*, 2022, 505: 263-275.
- [27] ZHANG Y, TSANG I W, LUO Y W, et al. Recursive copy and paste GAN: Face hallucination from shaded thumbnails[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(8): 4321-4338.
- [28] YE J, YANG L J, QIU C Z, et al. Joint low-light enhancement and deblurring with structural priors guidance[J]. *Expert Systems with Applications*, 2024, 249: 123722.
- [29] LV X Q, ZHANG S P, WANG C Y, et al. Fourier priors-guided diffusion for zero-shot joint low-light enhancement and deblurring[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2024: 25378-25388.
- [30] 牛玉贞, 陈铭铭, 李悦洲, 等. 基于任务解耦的低照度图像增强方法[J]. *电子学报*, 2024, 52(1): 34-45.
- NIU Y Z, CHEN M M, LI Y Z, et al. Task decoupling guided low-light image enhancement[J]. *Acta Electronica Sinica*, 2024, 52(1): 34-45. (in Chinese)
- [31] YI R, TIAN H Y, GU Z H, et al. Towards artistic image aesthetics assessment: A large-scale dataset and a new method[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2023: 22388-22397.
- [32] WANG L G, WANG Y Q, DONG X Y, et al. Unsupervised degradation representation learning for blind super-resolution[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2021: 10581-10590.
- [33] BERTINETTO L, HENRIQUES J F, VALMADRE J, et al. Learning feed-forward one-shot learners[EB/OL]. (2016-01-16)[2024-04-07]. <https://arxiv.org/abs/1606.05233v1>.
- [34] LI X J, HUANG L, WEI G Q, et al. Online parallel framework for real-time visual tracking[J]. *Engineering Applications of Artificial Intelligence*, 2021, 102: 104266.
- [35] CUI Z T, LI K C, GU L, et al. You only need 90K parameters to adapt light: A light weight transformer for image enhancement and exposure correction[EB/OL]. (2022-10-08)[2024-04-07]. <https://arxiv.org/abs/2205.14871v4>.
- [36] LI B, WU W, WANG Q, et al. SiamRPN++: Evolution of Siamese visual tracking with very deep networks[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2019: 4282-4291.
- [37] MILDENHALL B, BARRON J T, CHEN J W, et al. Burst denoising with kernel prediction networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 2502-2510.
- [38] WEI X S, LUO J H, WU J X, et al. Selective convolutional descriptor aggregation for fine-grained image retrieval[J]. *IEEE Transactions on Image Processing*, 2017, 26(6): 2868-2881.
- [39] WANG H H, WU X D, HUANG Z Y, et al. High-frequency component helps explain the generalization of convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2020: 8684-8694.
- [40] GONZALEZ R C, WINTZ P A. *Digital Image Processing*[M]. Mass.: Addison-Wesley Pub. Co., 1977.
- [41] WANG C X, WU H J, JIN Z. FourLLIE: Boosting low-light image enhancement by Fourier frequency information[C]//Proceedings of the 31st ACM International Conference on Multimedia. New York: ACM, 2023: 7459-7469.
- [42] KONG L S, DONG J X, GE J J, et al. Efficient frequency domain-based transformers for high-quality image deblurring[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2023: 5886-5895.
- [43] ZAMIR S W, ARORA A, KHAN S, et al. Multi-stage progressive image restoration[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2021: 14816-14826.
- [44] ZHANG Y, YANG Q X, CHANDLER D M, et al. Reference-based multi-stage progressive restoration for multi-degraded images[J]. *IEEE Transactions on Image Processing*, 2024, 33: 4982-4997.
- [45] WAN Y C, SHAO M W, CHENG Y S, et al. Progressive convolutional transformer for image restoration[J]. *Engineering Applications of Artificial Intelligence*, 2023, 125: 106755.
- [46] ZHANG Y L, LI K P, LI K, et al. Image super-resolution using very deep residual channel attention networks[M]//Computer Vision-ECCV 2018. Cham: Springer International Publishing, 2018: 294-310.
- [47] CHENG D Q, CHEN L L, LV C, et al. Light-guided and cross-fusion U-Net for anti-illumination image super-reso-

- lution[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2022, 32(12): 8436-8449.
- [48] GAO J X, YUE Z Y, LIU Y H, et al. Diving into darkness: A dual-modulated framework for high-fidelity super-resolution in ultra-dark environments[EB/OL]. (2023-09-11)[2024-04-07]. <https://arxiv.org/abs/2309.05267v1>.
- [49] GAO J, LIU Y, YUE Z, FAN X, et al. Collaborative brightening and amplification of low-light imagery via bi-level adversarial learning[EB/OL]. (2023-10-03)[2024-04-07]. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4617171.
- [50] YUE Z Y, GAO J X, XIE S H, et al. LoLiSRFlow: Joint single image low-light enhancement and super-resolution via cross-scale transformer-based conditional flow[EB/OL]. (2024-02-29)[2024-04-07]. <https://arxiv.org/abs/2402.18871v1>.
- [51] CHEN X Y, WANG X T, ZHOU J T, et al. Activating more pixels in image super-resolution transformer[C]//Proceedings of the Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2023: 22367-22377.
- [52] ZHENG M J, SUN L, DONG J X, et al. SMFANet: A lightweight self-modulation feature aggregation network for efficient image super-resolution[M]//Computer Vision-ECCV 2024. Cham: Springer Nature Switzerland, 2024: 359-375.
- [53] ZHOU Y P, LI Z, GUO C L, et al. SRFormer: Permuted self-attention for single image super-resolution[C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2023: 12734-12745.
- [54] ZAMIR S W, ARORA A, KHAN S, et al. Restormer: Efficient transformer for high-resolution image restoration[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2022: 5718-5729.

作者简介



李悦洲 男,1995年出生于河北省石家庄市.现为福州大学计算机与大数据学院博士研究生.主要研究方向为图像增强与复原、视觉目标跟踪.

E-mail: liyuezhou.cm@gmail.com




柯 逍 男,1983年出生于福建省福州市.现为福州大学教授、博士生导师.主要研究方向为计算机视觉、模式识别.

E-mail: kex@fzu.edu.cn



牛玉贞 女,1982年出生于山东省济南市.福州大学计算机与大数据学院教授、博士生导师.主要研究方向为计算机视觉.

E-mail: yuzhenniu@gmail.com



施逸青 女,1994年出生于福建省莆田市.现为福建师范大学光电与信息工程学院教师、硕士生导师.主要研究方向为计算机视觉、机器学习.

E-mail: 417shelly@gmail.com



李富晟 男,2001年出生于云南省姚安县.现为福州大学计算机与大数据学院硕士研究生,主要研究方向为计算机视觉.

E-mail: lifusheng.chn@gmail.com