

文章编号 1004-924X(2025)07-1114-16

LightDiffu-DCE: 基于光照强度扩散的 低光照图像增强

闫光辉, 吴佰靖*, 马 龙

(兰州交通大学 电子与信息工程学院, 甘肃 兰州 730070)

摘要: 针对低光照图像中不同光源的光照强度分布不均, 在图像增强时造成轮廓特征丢失及效果不自然的问题, 提出一种基于光照强度扩散的低光照图像增强方法(Light Diffusion based Zero-DCE Image Enhancement Algorithm, LightDiffu-DCE)。为增强模型的泛化能力, 提出了基于光源光照强度建模的扩散模型, 以生成不同光照强度的训练数据集。设计了边缘特征融合的深度曲线估计网络, 能够提取更丰富的低光照图像的多尺度轮廓和细节特征, 提升对光照强度估计的准确性。为恢复出光照更加自然的图像, 融合大气光估计来计算不同图像区域的光照强度, 实现了对光增强曲线和光增强系数的动态微调。在无参考数据集 ExDark 和有参考数据集 LOL 上, 使用 6 种评价指标进行实验分析。实验结果表明, 相较于基准方法, LightDiffu-DCE 在 ExDark 上的无参考评价指标 NIQE, PIQE 和 RISQ 上分别提升了约 8.35%, 6.20% 和 21.83%, 在 LOL 数据集上的有参考评价指标 PSNR, SSIM 和 RMSE 提升了约 12.12%, 4.76% 和 49.89%。该方法可以有效增强低光照图像, 且恢复出的低光照图像轮廓更加清晰, 色彩鲜明且效果更自然。

关键词: 计算机视觉; 扩散模型; 低光照增强; 边缘特征; 深度曲线估计网络

中图分类号: TP394.1 **文献标识码:** A

doi: 10.37188/OPE.20253307.1114

CSTR: 32169.14.OPE.20253307.1114

LightDiffu DCE: low light image enhancement based on light intensity diffusion

YAN Guanghui, WU Baijing*, MA Long

(School of Electronics & Information Engineering, Lanzhou Jiaotong University,
Lanzhou 730070, China)

* Corresponding author, E-mail: 1420716156@qq.com

Abstract: A Light Diffusion-based Zero-Reference Deep Curve Estimation algorithm (LightDiffu-DCE) is proposed to address the uneven distribution of light intensity from multiple sources in low-light images, which often results in the loss of image contour features and unnatural enhancement effects. To improve the model's generalization capability, a diffusion model grounded in light intensity modeling of light sources is employed to generate training datasets with varied illumination levels. Subsequently, a depth profile estimation network incorporating edge feature fusion is designed to extract richer multi-scale contour and detail features, thereby enhancing the accuracy of light intensity estimation. Furthermore, atmospheric

收稿日期: 2024-10-22; 修订日期: 2025-01-04.

基金项目: 国家自然科学基金资助项目 (No. 62062049, No. 62366028); 中央引导地方科技发展资金资助项目 (No. 22ZY1QA005); 兰州交通大学重点研发项目 (No. ZDYF2304)

light estimation is integrated to calculate the illumination of different image regions, enabling dynamic fine-tuning of enhancement curves and coefficients for more natural lighting recovery. Experimental evaluations on the challenging ExDark (non-contrast) and LOL (contrast) datasets, utilizing six rigorous metrics, demonstrate the superiority of LightDiffu-DCE. Specifically, on the ExDark dataset, improvements of approximately 8.35%, 6.20%, and 21.83% are achieved in the no-reference metrics NIQE, PIQE, and RISQ, respectively; on the LOL dataset, gains of approximately 12.12%, 4.76%, and 49.89% are observed in the reference-based metrics PSNR, SSIM, and RMSE. These results substantiate that LightDiffu-DCE effectively enhances low-light images, restoring clarity, vividness, and naturalness.

Key words: computer vision; diffusion model; low light intensity enhancement; edge features; depth curve estimation network

1 引言

在数字成像领域,低光照环境下的图像获取一直是一个具有挑战性的难题。随着智能手机、安防监控、医学成像,以及夜间摄影等应用的广泛普及,对高质量低光照图像的需求日益增长。然而,低光照条件下拍摄图像伴随着噪声增加、细节丢失、纹理模糊、亮度对比度较低等问题,严重限制了图像的视觉质量和后续处理(如低光照目标检测、低光照目标分类等)的性能。因此,通过设计低光照图像增强模型,在提升整体图像对比度的同时,恢复低光照图像的纹理和细节信息,能够有效提升图像的整体质量^[1]。

低光照图像增强算法经历了从传统处理方法到深度学习技术的发展。在早期,研究人员主要依赖空域和频域处理的低光照图像增强方法^[2-4],如直方图均衡化、伽马变换、Retinex、小波变换、暗通道先验算法等。这些传统方法通过对图像的像素值或变换域中的系数进行直接操作来提升图像的亮度和对比度。然而,这些方法对噪声的抑制能力有限,在增强图像的同时放大了噪声,造成细节丢失和色彩失真等问题,难以满足复杂场景下对高质量增强图像的需求^[5]。

随着深度学习技术在计算机视觉领域的广泛应用,基于深度学习的低光照图像增强算法通过构建深度神经网络模型,利用大规模数据集进行训练,能够学习低光照与正常光照图像之间复杂的映射关系,捕捉图像中的光照变化规律和细节特征,从而在增强图像亮度和对比度的同时,有效抑制噪声并恢复出更加自然的增强图像^[6-7]。

基于深度学习的低光照图像增强算法从实现方式上分为基于有监督和无监督两种。有监督的方法需要事先搜集配对的低光照和正常光照的图像,以此来建立正常图像与低光照图像的映射关系^[8]。低光照图像增强(Low-Light image enhancement Network, LLNet)^[9]使用叠加稀疏去噪自动编码器的一种变体来同时提亮和去噪。Lv等^[10]提出了一种端到端多分支增强网络(Multi-Branch Low-Light Enhancement Network, MBLLEN),通过多层特征提取和多分支特征融合网络设计,在提升亮度、对比度保持自然色彩的同时,抑制了低光照图像中的噪声干扰。RetinexNet^[11]基于Retinex理论,通过深度卷积网络估计光照和反射率,并对光照分量进行补偿,从而提升图像的细节信息。然而,RetinexNet的分解光照模型过于单一,增强后的图像容易出现噪声放大和色差问题。Zhu等^[12]提出了一种边缘增强多曝光融合网络(Edge Enhanced Multi-Exposure Fusion Network, EEMEFN),利用多曝光融合网络(Multi-Exposure Fusion, MEF)和边缘增强(Edge Enhancement, EE)两阶段的增强策略,使图像中的目标边缘更加清晰、锐利,提升了图像的整体清晰度。此外,还可以通过引入高斯金字塔网络^[13]、残差网络^[14]和拉普拉斯变换^[15]来增强低光照图像。上述方法通过端到端的网络学习集成特征表示,获得了良好的性能,但在现实低光环境中泛化性能受限,且在大多数场景中无法获取成对数据,因此,有监督方法在这些场景中的局限性较大^[16]。

相比有监督方法,无监督方法不需要图像配

对,极大降低了数据制作的要求,提高了模型的计算效率。无监督方法从实现方式上分为基于生成对抗网络(Generative Adversarial Networks, GAN)和基于深度卷积的方法。GAN的方法由生成器和判别器两部分组成,生成器的目的是将低光照图像转换为正常光照图像,判别器则是区分生成的图像是真实的正常光照图像还是由生成器生成的图像^[17]。在训练过程中,生成器和判别器通过相互对抗、不断优化,最终生成高质量的增强图像。文献[18]提出了CycleGAN(Cycle-Consistent GAN)方法,该方法在图像转换方面表现出色,但在低光照增强方面,增强的图像细节和纹理特征模糊,出现颜色偏差和失真等现象。为解决上述问题,文献[19]引入层分解和光效应抑制网络对编码器进行重构训练,但该方法的增强效果不稳定且模型泛化能力欠佳。文献[20]提出的 EnlightenGAN (Enhancing Low-Light GAN)引入了全局-局部判别器,在泛化性方面较传统的GAN有了很大提升,但 EnlightenGAN在处理复杂纹理和结构的图像时,由于画面中存在闪光灯、多个光源等过曝光或欠曝光图像,无法准确还原出自然效果更好的图像。

GAN的方法需要设计复杂的生成器和判别器,且对超参数敏感,存在一定的局限性。相较于GAN的方法,基于深度卷积的方法在一些特定场景中更容易训练,对超参数的敏感性也较低,因此逐渐成为低光照图像增强的主流。Li等^[21]提出了一种用于提高低光照图像质量的渐进式递归图像增强网络(Progressive Recursive Image Enhancement Network, PRIEN),该网络设计了一个递归单元用于处理输入图像,并结合双重注意力模块进行全局和局部特征的提取,但该方法处理的图像易出现过曝光现象。Zhou等^[22]提出了一种轻量化低光照图像增强网络(SurroundNet),该网络包含多个自适应Retinex块(Adaptive Retinex Blocks, ARBlock)和一个低曝光去噪器(Low Exposure Denoiser, LED),用于解决模型复杂性和图像增强性能间的矛盾问题。该方法仅用较少的参数就实现了高性能的低光照图像增强,但颜色信息计算存在偏差,导致增强后的图像出现颜色失真现象。Li等^[23]提出了一种轻量级的亮度感知金字塔网络(Lumi-

nance-aware Pyramid Network, LPNet),该网络通过结合多尺度对比度特征块(Multi Scale Contrast Feature Block, MSCFB)和亮度感知机制,由粗到细重建出高质量增强图像,解决了过曝光的问题,但易造成图像边缘细节信息丢失的问题。Guo等^[24]提出了一种无参考深度曲线估计(Zero-Reference Deep Curve Estimation, Zero-DCE),利用轻量化的深度网络(Deep Curve Estimation, DCENet)来动态增强低光照图像,不需要成对的数据集;但该方法并没有考虑噪声的影响,且未突出图像轮廓特征和细节信息,会影响后续任务的性能。Li等^[25]提出了Zero-DCE的加速和轻量化网络Zero-DCE++,该模型具有较快的计算速度,同时保持Zero-DCE的增强性能。SCI(Self-Calibrated Illumination)^[26]使用级联融合网络搜寻适合低光增强的网络结构,该方法以Retinex理论作为先验知识,易在增强图像中放大噪声。

综上所述,低光照图像增强虽取得了一定进展,但仍面临诸多挑战。为了提升模型在不同低光照场景中的泛化能力,在增强图像整体亮度的同时增强低光照条件下几乎不可见的细节轮廓信息,并动态控制亮度强度,使增强后的图像不会出现色彩丢失等,本文提出一种基于光照强度扩散模型的低光照图像增强方法(Light Diffusion based Zero-DCE Image Enhancement Algorithm, LightDiffu-DCE),从低光照增强的实际需求出发,在训练阶段为增加模型的泛化能力,根据低光照图像不同光源造成的光照强度不同的特点,设计了基于光源光照强度建模的PM模型(Light source Illumination intensity Probabilistic Models, LIPM)来生成不同光照强度的训练数据集,使模型获得更多的低光照和正常光照图像之间的非线性映射关系。其次,引入离散小波变换,设计并行边缘特征融合的深度曲线估计网络(Deep Curve Estimation Network of Wavelet Transform Convolution Network, WTDCNet),来提取低光照图像的细节和轮廓特征,并使用注意力机制来加权融合细节和轮廓特征。最后,为避免增强后的图像出现过曝光现象,提出融合大气光估计的光增强曲线(Light Enhancement curve, LE-curve),对光增强

曲线和光增强系数进行微调,恢复出更接近正常光照的增强图像。LightDiffu-DCE增强了低光照图像,并细化了图像的整体轮廓信息。经LIPM扩散训练,模型在不同低光照场景下的泛化能力得到显著提高。

2 原理

本文构建的LightDiffu-DCE总体框架如图1所示。首先,使用大气光估算出不同低光照图像的大气光照强度,并构建基于光源光照强度的扩散模型,根据不同光照强度来生成训练样本,以

提升模型在不同低光照图像增强场景中的泛化能力。然后,引入离散小波变换,设计WTDCNet,提取到更丰富的纹理和细节特征,并使用迭代注意力特征融合机制(Iterative Attention Feature Fusion, iAFF)^[27]由WTCNet和DCENet并行网络提取到的不同尺度特征,提升后续光增强曲线的估计准确性,恢复出更接近真实场景的低光照增强图像。最后,在光增强曲线LE-curve估计低光照增强曲线时引入大气光估计,对光增强曲线和光增强系数进行修正微调,避免过曝光现象,突出增强图像的细节和纹理特征。




图1 LightDiffu-DCE网络结构

Fig. 1 Architecture of LightDiffu-DCE network

2.1 基于LIPM的不同光照强度扩散图像生成

为提升模型的增强效果和泛化能力,本文提出基于光源光照强度建模的扩散模型LIPM来生成训练数据集,模拟不同光照强度下的图像,以获得更加多样的低光照图像和正常光照图像的映射关系。

2.1.1 扩散模型

扩散模型的目的是学习一条马尔可夫链,将高斯噪声的分布逐渐转化为训练数据。它是一种基于概率论的生成模型,广泛应用于数据生成

任务,如图像、视频和音频的合成。扩散模型通过模拟一个从数据分布到简单噪声分布的逐渐“扩散”过程,并学习逆过程来从噪声中重构出高质量的数据样本。

扩散模型的核心思想有正向和反向扩散两个过程。正向扩散定义了一个由数据分布逐步转化为高斯噪声分布的过程,通过正向学习数据从纯净迈向噪声分布的过程,模型能深刻理解并捕捉到数据的内在映射关系。反向扩散与正向扩散形成对偶,它基于前一步的输出调整来逐步

减少噪声,同时保留并增强主要特征^[28-30]。正向加噪过程表示为:

$$q(x_t|x_{t-1})=N(x_t; \sqrt{\eta_t} x_{t-1}, (1-\eta_t)H), \quad (1)$$

其中: x_t 为 t 步长时间上的输入图像数据, $t-1$ 为上一时间步的输入图像数据, η_t 为一个随时间递减的系数,控制噪声的增量, $N(x, \omega, \sigma^2 H)$ 表示均值为 ω ,协方差矩阵为 $\sigma^2 H$ 的高斯分布, $\sqrt{\eta_t} x_{t-1}$ 是对上一时间步输入图像数据的缩放, $(1-\eta_t)H$ 为噪声方差, H 为单位矩阵,表示噪声在各个维度上是相互独立的。

式(1)表明,在时间步长 t 的控制下,新扩散(加噪)的数据 x_t 是通过从 x_{t-1} 按照 $x_{t-1}\sqrt{\eta_t}$ 进行缩放并加入一个方差为 $(1-\eta_t)$ 的高斯噪声计算,随着时间步长 t 的增加,产生的噪声干扰越来越大,当到最大时间步长 T 时,几乎完全变成噪声。

反向扩散与正向扩散过程相反,从纯噪声或高度噪声化的数据中逐步恢复出原始数据样本,在图像增强任务中,反向扩散过程通过逐步去除噪声,最终生成清晰的图像。反向扩散过程从正向扩散后的数据出发,通过一系列反向扩散操作逐步去除噪声,恢复出原始的数据样本。这个过程表示为:

$$p(x_{t-1}|x_t)=N(x_{t-1}; \mu(x_t, t), \sum(x_t, t)), \quad (2)$$

其中: μ 和 $\sum()$ 表示神经网络预测的均值和方差,通过当前的噪声图像 x_t 和时间步长 t 计算。反向扩散通常采用迭代的方式进行,每一步基于当前的噪声图像和预测的噪声来更新图像,反向扩散过程能够学习并模拟反向扩散的复杂非线性映射。因此,训练扩散模型的目标是通过最小化损失函数,尽量降低扩散模型中的逆向误差。

2.1.2 非线性扩散PM算法

PM模型是一种基于偏微分方程的图像增强技术,其基本思想是通过模拟图像中的扩散过程来实现去噪效果,同时尽可能保持图像的边缘信息^[31]。在二维图像中,该模型根据图像中的梯度信息对像素值进行非线性扩散,以达到去噪的目的,具有保留图像前景、平滑背景内容的优点。PM将梯度的模值信息融合到传输系数中,得到:

$$\begin{cases} \frac{\partial I(x, y, t)}{\partial t} = \text{div}[g(|\nabla I|)\nabla I], \\ I(x, y, 0) = I_0(x, y) \end{cases}, \quad (3)$$

其中: I 为图像的像素值在空间位置 (x, y) 和时间 t 的函数, ∇I 为图像 I 的梯度, $\frac{\partial I}{\partial t}$ 表示图像像素值随时间的变化率, $|\nabla I|$ 表示在空间位置上的模值: $|\nabla I(x, y)| = \sqrt{(I_x^2 + I_y^2)}$;div是散度算子,用于计算向量场的散度; g 为扩散系数,决定不同梯度值下的扩散速率; k 为梯度阈值,可以控制 g 的扩散速率。

常见的PM扩散系数表达式为:

$$g(|\nabla I|) = \frac{1}{1 + (\frac{|\nabla I|}{k})^2}. \quad (4)$$

非线性扩散概率模型在低光照图像增强领域,通过迭代学习不同光照强度的数据产生的正向和逆向扩散过程,进行逐步去噪,实现了较高质量的图像增强。该方法不仅可以生成多样化的训练样本,增强模型的泛化能力,还能在逆向过程中灵活调整扩散系数,以适应不同曝光度的图像,有效保留了图像的细节信息。

2.1.3 基于光照强度建模的LIPM模型

为提升模型在不同低光照场景中的泛化能力,根据低光照图像的不同光照强度值,来建立不同光照强度的训练数据。低光照图像受不均匀光照的影响,设计光源光照强度来补偿由于外部条件变化(如时间或天气变化)引起的光照变化。

LIPM根据经典大气散射模型,图像像素强度 $I(x, y)$ 可用低光照图像场景中的真实光照强度来表示:

$$I(x, y) = J(x, y)o(x, y) + A(1 - o(x, y)), \quad (5)$$

其中: $I(x, y)$ 为图像像素在 (x, y) 位置的光照强度, $J(x, y)$ 是实际场景的亮度(无大气散射的影响), A 是大气光强度。在计算过程中,通常取图像中最亮区域(如光源)的颜色。 $o(x, y)$ 为透射率,表示场景中的光线在到达观察者之前未被散射的比例。 A 和 $o(x, y)$ 由暗通道去雾算法计算得到^[32]。

在低光照场景中,图像亮度受光源的影响。因此,如果场景中有一个或多个光源,将每个光

源视为在其位置产生一定强度的光,光源在图像中的位置为 (x_0, y_0) ,对周围区域的影响用高斯表达,即:

$$S(x, y, I) = A \exp\left(-\frac{(x - x_0)^2 + (y - y_0)^2}{2\sigma^2}\right), \quad (6)$$

其中 σ 为控制光源影响的范围。在LIPM中,将式(3)修改为:

$$\begin{cases} \frac{\partial I(x, y, t)}{\partial t} = \text{div}[D(I(x, y, t)\nabla I)] + S(x, y, t), \\ I(x, y, 0) = I_0(x, y) \end{cases} \quad (7)$$

其中 $D(I)$ 是光照强度依赖的扩散系数:

$$D(|\nabla I|) = \frac{o(x, y)^\gamma}{1 + \left(\frac{|\nabla I|}{k}\right)^2}, \quad (8)$$

式中: γ 为透射率调整系数,取值为 $[0-1]$ 。为自适应确定梯度阈值 k ,有:

$$u = w_0 u_0 + w_1 u_1, \quad (10)$$

$$k = w_0 (u_0 - u)^2 + w_1 (u_1 - u)^2, \quad (11)$$

其中: w_0 为前景像素比例, w_1 为背景像素比例, u_0 为前景梯度均值, u_1 为背景梯度均值, u 为自适应梯度均值。

2.2 边缘特征融合的深度曲线估计网络

如图2所示,WTDCNet由DCENet和WTCNet组成,DCENet使用具有对称连接的6个卷积核大小为 3×3 ,步长为1的CNN组成,并使用ReLU激活函数和跳跃连接的方式,实现不同卷积层提取特征的拼接融合,提取到更加丰富的特征。

为增强低光照图像的轮廓特征并细化其纹

理细节,受WTCConv^[33]启发设计了WTCNet。该网络首先使用一层 3×3 Conv卷积来整合纹理和细节特征,然后使用三层WTCConv实现由浅到深的纹理和轮廓特征提取,进而计算出更准确的光增强曲线。本文引入iAFF注意力将不同特征进行深度融合,在实现特征互补的同时,提取到更多的轮廓特征和纹理特征,使得增强后的低光照图像纹理更加清晰,细节更加精细。

在WTCNet中,WTCConv首先将输入特征经过第一层db1小波变换,将输入特征分解为一个低频分量LL和三个高频分量(HL, HH, LH)。然后,将低频分量使用第二层db1小波变换,完成低频分量的特征提取;三个高频分量经过卷积特征提取后,再重新调整尺度,将特征提取后的高频分量与低频分量进行小波逆变换。最后,将小波变换后的特征与输入特征经卷积跳跃连接和融合,实现不同尺度的特征融合。这样的网络设计,不仅充分利用了小波变换多尺度特征信息的分解和融合,突出了整个图像的边缘轮廓特征,而且在计算量消耗极少的情况下,最大限度提升了网络的感受野和特征提取能力。

为了更好地融合DCENet和WTCNet网络不同层次的特征,采用“加权”和“门控”融合的思想,引入iAFF注意力机制来实现两个网络不同层次的特征互补融合,iAFF结构如图3所示。首先,将两个输入特征通过MS-CAM(Multi-scale Channel Attention Module)计算各自的权重,然后对两个输入特征进行加权融合,再将融合后的特征经过第二层MS-CAM模块,计算出第二层特征图的注意力权重。经过多次迭代融合后,最终得到不同尺度的融合特征图。该注意力可以有效整合不同尺度的语义特征,融合后的特征更加丰富。





图2 WTDCNet结构

Fig. 2 Structure of WTDCNet



(a) iAFF

(b) MS-CAM

图3 iAFF注意力和MS-CAM的结构

Fig. 3 Structures of iAFF attention and MS-CAM

在 iAFF 中,输出特征为:

$$Z = F_{\text{MS-CAM}}(I_1 + I_2) \odot I_1 + (1 - F_{\text{MS-CAM}}(I_1 + I_2)) \odot I_2, \quad (12)$$

其中: Z 为经过 iAFF 模块的输出特征, I_1 和 I_2 为两个维度相同的输入特征, $F_{\text{MS-CAM}}$ 为通过 MS-CAM 模块计算各个输入特征的权重。从式(12)可以看出,iAFF 注意力通过计算两个输入特征的融合权重,实现了特征的加权融合。

2.3 融合大气光估计的光增强曲线

Zero-DCE 使用 LE-curve 来动态调整低光照增强的强度,低光照增强通过二次曲线自适应调整。整个过程描述为:

$$LE(I(x, y), \alpha) = I(x, y) + \alpha(I(x, y)(1 - I(x, y))), \quad (13)$$

其中: $LE()$ 为增强后的像素点, α 为可训练曲线参数,它可以调整光增强曲线的大小并控制曝光水平, $\alpha \in [-1, 1]$ 。此外,LE-curve 还设计了三通道光增强曲线求解和高阶迭代的曲线求解方法,使得 Zero-DCE 算法能够更好地保留固有色,降低过饱和度的风险。高阶增强曲线求解为:

$$LE_n(I(x, y), \alpha_n) = LE_{n-1}(I(x, y)) + \alpha_n \cdot I(x, y) \cdot LE_{n-1}(I(x, y))(1 - LE_{n-1}(I(x, y))), \quad (14)$$

其中: n 为模型的迭代训练次数, $LE_n(I(x, y); \alpha)$ 为给定输入 $I(x, y)$ 的增强图像, α 为训练曲线参数。

然而,在一些有光源的场景中,低光照还受不同光源光照强度的影响,其光照强度不均匀,导致增强后的低光照图像不自然,某些区域出现过曝光现象。因此,在求解 LE-curve 曲线时,加入大气光强 A 对曲线进行修正,降低过曝光的风险,实现更加真实的低光照图像恢复。融合大气光估计后的光增强曲线描述为:

$$LE_n(I(x, y), \alpha_n, \beta_n) = LE_{n-1}(I(x, y)) + \alpha_n I(x, y)_{n-1} (1 - LE_{n-1}(I(x, y))) + \beta_n (A_n - LE_n(I(x, y))), \quad (15)$$

其中: β 为大气光估计的影响强度参数, A 为通过暗通道去雾算法计算的大气光估计值。

2.4 训练损失函数设计

损失函数选择从增强图像的边缘轮廓连贯性、是否出现过曝光现象、颜色是否偏差和增强图像是否平滑四个角度来综合衡量,选择空间一致性损失、曝光控制损失、色彩恒定损失和光照

平滑度损失来训练模型,以控制模型的增强效果。将训练损失 L_{total} 设置为:

$$L_{\text{total}} = L_{\text{SCloss}} + L_{\text{ECloss}} + L_{\text{CCloss}} + L_{\text{ISloss}}. \quad (16)$$

空间一致性损失可以指导网络在进行低光照图像增强时关注到目标的轮廓信息和背景的连贯性,使得增强效果更连续。曝光控制损失能够在网络训练时控制低光照图像的曝光水平,避免过曝光和欠曝光现象。色彩恒定损失通过控制增强图像的颜色色彩水平,准确估计 LE-curve,避免出现颜色色彩失真或偏差的问题。光照平滑度损失能够控制低光照图像整体的增强程度,平滑整个增强图相邻区域的相关性,去除增强图的伪影和伪迹。上述损失的具体计算过程如下:

$$L_{\text{SCloss}} = \frac{1}{H} \sum_{i=1}^H \sum_{j \in \Omega(i)} (|Y_i - Y_j| - |I_i - I_j|)^2, \quad (17)$$

其中: H 为局部区域的数量, $\Omega(i)$ 为以区域 i 为中心的四个相邻区域(上、下、左、右), Y 和 I 分别表示为增强图像和低光照图像中局部区域的平均强度。

$$L_{\text{ECloss}} = \frac{1}{M} \sum_{m=1}^M |Y_m - E|, \quad (18)$$

其中: M 为尺寸为 16×16 的非重叠局部区域的数量, Y 为增强图像中的局部区域平均强度。

$$L_{\text{CCloss}} = \sum_{\forall (p, q) \in \epsilon} (J^p - J^q)^2, \quad \epsilon \in \{(R, G), (R, B), (G, B)\}, \quad (19)$$

其中: J 为增强图像中通道的平均强度,两个通道分别为 (p, q) 。

$$L_{\text{ISloss}} = \frac{1}{N} \sum_{n=1}^N \sum_{c \in \epsilon} (|\nabla_x A_n^c| + |\nabla_y A_n^c|)^2, \quad \epsilon = \{R, G, B\}, \quad (20)$$

其中: N 为迭代次数, ∇_x 和 ∇_y 分别是水平和垂直方向的梯度值。

3 实验及结果分析

3.1 数据集和实验参数设置

为验证本文方法对低光照图像的增强效果,选择无对比的低光照公开数据集 ExDark^[34]和有对比低光照公开数据集 LOL^[35]进行实验。ExDark 数据集是一个用于目标检测和图像增强的

数据集,数据采集环境为低光照和黄昏,包含10种不同光照条件下的7363张图像,标注12个类别,分别为自行车(Bicycle)、船(Boat)、瓶子(Bottle)、公交车(Bus)、汽车(Car)、猫(Cat)、椅子(Chair)、杯子(Cup)、狗(Dog)、摩托车(Motorbike)、人(People)和桌子(Table)。LOL数据集是专门用于评估低光照条件下图像增强算法性能的数据集,包含787对低光照与正常光照条件下的图像对,这些图像覆盖了室内和室外环境、自然风景和人物肖像等场景和对象。该数据集通过在同一场景下拍摄低光照和对应的正常光照图像对,为算法提供真实的测试环境。

实验采用深度学习框架Pytorch 1.12.1, Python3.7.6, CUDA10.0, 硬件为Intel(R) Xeon(R) CPU E5-2678 v3, GPU为NVIDIA GeForce RTX 3060进行单卡训练。在训练过程中,学习率设置为0.0001, epoch为100, batch size为8。在两个数据集的训练过程中,按照8:2的比例来划分训练集和测试集,使用无参考图的方式对LightDiffu-DCE进行网络训练,不引入预训练权重,对网络进行重新训练,以达到最优效果。

3.2 评价指标

本文选择两个低光照公开数据集ExDark和LOL,在ExDark数据集上使用无参考评价指标,从增强图像的总体质量(自然程度)、噪声干扰程度和图像的亮度及对比度3方面来评价增强图像,选择NIQE(Naturalness Image Quality Evaluator), PIQE (Perception based Image Quality Evaluator)和RISQ(Referenceless Image Spatial Quality Evaluator)为该数据集的评价指标。在LOL数据集上使用有参考的评价指标,从增强图像的噪声干扰信噪比、正常光照图与增强图之间的视觉结构相似度、正常光照图与增强图之间的

误差以及自然度和亮度顺序上的一致性4方面来评价增强图像,选择峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)、结构一致性参数(Structural Similarity Index Measurement, SSIM),均方根误差(Root Mean Squared Error, RMSE)和NIQE来评价各个算法在LOL数据集上的表现。其中,PSNR用于衡量经过低光照增强后的图像与正常光照图之间的质量差异,其值越高,表示增强后的图像失真越小,质量越高;SSIM用于评估经过低光照增强后的图像与正常光照图间的视觉相似度,其值越接近1,越能够更全面地反映图像之间的相似程度;RMSE衡量模型经过低光照增强后的图像与正常光照图之间的误差,其值越低,误差越小;NIQE反映图像的自然保持能力,值越小说明增强的图像具有更好的亮度顺序,效果更自然;PIQE利用图像的块状结构和噪声特征来计算图像的质量分数,从对比度敏感度、亮度适应、颜色视觉等方面进行综合评估,其值越低表示图像质量越高;RISQ使用支持向量机来学习图像质量与图像特征之间的映射关系,能够反映图像局部区域的对比度变化,且可以计算增强后的图像是否失真,其值越低表示图像质量越高。

3.3 改进策略的消融实验

在两个公开数据集上分别进行消融实验,以验证本文所提不同改进策略的有效性和合理性。实验中,基准算法为ZERO-DCE,使用LIPM扩散数据生成方法记为M1,边缘特征融合的深度曲线估计网络记为M2,融合大气光估计的光增强曲线方法记为M3。在Exdark数据集上的消融实验结果如图4和表1所示,在LOL数据集上的消融实验结果如图5和表2所示。




图4 在Exdark数据集上的可视化消融实验

Fig. 4 Visualization ablation experiments on Exdark dataset




图 5 在 LOL 数据集上的可视化消融实验

Fig. 5 Visualization ablation experiment on LOL dataset

表 1 在 Exdark 数据集上的消融实验

Tab. 1 Ablation experiments on Exdark dataset

M1	M2	M3	NIQE ↓	PIQE ↓	RISQ ↓
			10.54	12.59	11.91
✓			9.91	12.07	10.14
✓	✓		9.75	11.94	9.76
✓	✓	✓	9.66	11.81	9.31

表 2 在 LOL 数据集上的消融实验

Tab. 2 Ablation experiments on LOL dataset

M1	M2	M3	PSNR ↑	SSIM ↑	RMSE ↓
			17.57	0.63	2165.03
✓			18.49	0.67	1876.41
✓	✓		19.52	0.68	1319.17
✓	✓	✓	19.70	0.69	1084.89

由表 1 和图 4 可知,优化改进策略具有一定的合理性和优越性,其 LIPM 扩散数据生成方法生成的不同光照强度下的训练数据,增加了模型的泛化和增强能力;使用边缘特征融合的深度曲线估计网络提取到更多纹理细节特征,使得增强后的图像轮廓纹理更加细腻;融合大气光估计的光增强曲线方法将高曝光图像进行微调,增强后的图像更接近正常光照下的图像。

由表 2 和图 5 可知,LightDiffu-DCE 方法对低光照图像中的色彩恢复更加接近真实场景,且增强后的图像色彩未出现颜色失真现象。

综上,对比基准 ZERO-DCE 方法,LightDiffu-DCE 方法在两个公开数据集上具有一定优越性,在 Exdark 数据集上 NIQE,PIQE 和 RISQ 指标分别提高了 0.88,0.78 和 2.6,分别提升了约 8.35%,6.20% 和 21.83%。在 LOL 数据集上 PSNR,SSIM,RMSE 和 NIQE 分别提高了 2.13,

0.06,1 080.14 和 1.58,分别提升了约 12.12%,4.76%,49.89% 和 12.52%,增强效果明显。

3.4 在 ExDark 和 LOL 数据集上的对比实验

为进一步验证 LightDiffu-DCE 方法的有效性,在两个数据集上选择与现有经典低光照增强方法 (RetinexNet^[11], ZERO-DCE^[24], ZERO-DCE++^[25], NeRC^[36] 和 SCINet^[26]) 进行对比实验,结果如图 6、图 7 和表 3 所示。

图 6 是 Exdark 数据集上的可视化结果,第 1 列为整体亮度较低场景,第 2 列为有光源光照强度不均匀场景,第 3 列为光照不均匀场景、第 5 列为存在阴影场景,第 4 列为第 3 列和第 5 列的局部放大图,第 6 列为彩色细节恢复场景,第 7 列为第 6 列的局部细节放大图。在第 1 列整体亮度较低图像的增强结果中,RetinexNet 和 SCINet 增强的图像存在过曝光现象,ZERO-DCE, ZERO-DCE++, NeRC 和 Light Diffu-DCE 恢复出的图像未出现过曝光现象,且 LightDiffu-DCE 恢复出的低光照图像整体亮度和对比度较好,对阴影区域恢复效果最好,符合自然条件下拍摄图像的特点。在有光源光照强度不均匀图像中,ZERO-DCE, ZERO-DCE++, NeRC 和 SCINet 的方法增强后的图像存在较大区域的阴影且轮廓信息模糊,RetinexNet 的增强方法存在颜色色彩失真现象,LightDiffu-DCE 方法增强的图像对光源光照强度不均匀的细节处理更好,且恢复出的图像整体亮度细节较高。在光照不均匀场景中,SCINet 出现过曝光现象,RetinexNet 和 NeRC 出现较为明显的色彩颜色失真现象,ZERO-DCE, ZERO-DCE++ 和 Light Diffu-DCE 方法的恢复效果较好,但由局部放大图对比可以看出,LightDiffu-DCE 增强图中的“小狗”周围轮廓较为明显且颜色细节更接近真实场景。在阴影




图6 在Exdark数据集上的可视化结果

Fig. 6 Visualization results on Exdark dataset

场景中,RetinexNet和NeRCo同样出现较为明显的色彩颜色失真现象,本文方法的增强效果更好,在第4列局部放大图的对比中,本文方法在“沙发”底下的阴影面积更少且整体亮度更亮。在彩色细节图像中,RetinexNet存在颜色失真,ZERO-DCE,ZERO-DCE++,NeRCo,SCINet和LightDiffu-DCE方法的恢复效果良好。从第七列的两个局部放大图可以看出,LightDiffu-DCE对图像彩色颜色更加艳丽生动,细节纹理更

加清晰,与背景的边界区分更加明显。Exdark数据集上的可视化结果表明,LightDiffu-DCE方法增强后的低光照图像细节轮廓特征更加明显,整体亮度对比度较高,颜色色彩更加绚丽,图像的整体质量较高。

图7为不同算法在LOL数据集上的可视化结果,第1列图像为细节轮廓增强场景,第2列为第一列图像的局部放大图,第3列为颜色色彩恢复场景,第4列为颜色亮度对比度恢复场景,第5




图7 LOL数据集上的可视化结果

Fig. 7 Visualization results on LOL dataset

列为低对比度恢复场景,第6列为背景/远景细节恢复场景,第7列为第6列的局部放大图。在细节轮廓增强图中,RetinexNet存在颜色失真现象,NeRCO方法的亮度最高;但从第2列的局部放大图中可以看出,该方法造成细节和纹理特征的丢失,ZERO-DCE,ZERO-DCE++,SCI-Net和LightDiffu-DCE方法的恢复效果良好,其中LightDiffu-DCE方法增强后的图像整体亮度、细节和轮廓信息更为全面。在颜色色彩恢复场

景中,RetinexNet,ZERO-DCE,SCINet三种方法均存在颜色色彩失真的现象,NeRCO方法的亮度最高,但出现了过曝光现象,LightDiffu-DCE和ZERO-DCE++的恢复效果良好,且LightDiffu-DCE的增强图像与背景对比度更加明显,纹理和轮廓信息更加丰富。在颜色亮度对比度恢复场景中,RetinexNet出现过曝光现象,相较于其他方法,LightDiffu-DCE恢复出的图像色彩对比度更加艳丽,更加接近正常光照

条件下的图像,且整体亮度较高。在低对比度恢复场景中,SCINet,RetinexNet 和 ZERO-DCE 均出现过曝光,其细节信息较为模糊,较于 ZERO-DCE++ 和 NeRCo 方法增强后的图像,LightDiffu-DCE 增强后的图像细节恢复到位,对“洗衣液”细节和轮廓的恢复更加明显。在背景/远景细节恢复场景中,RetinexNet 方法出现

了色彩失真的现象,从第 7 列的局部放大图可以看出,LightDiffu-DCE 对远景区域的恢复结果中“塑料座椅”轮廓明显,图像的整体亮度更加准确,对远景目标和阴影细节的处理更加细腻。通过在两个公开数据集上的定性分析,证明了本文方法能够更好地增强不同场景下的低光照图像,性能更优。

表 3 不同算法在 ExDark 和 LOL 数据集上的对比实验结果
Tab. 3 Comparative experimental results of different algorithms on ExDark and LOL datasets

算 法	Exdark			LOL			
	NIQE	PIQE	RISQ	PSNR	SSIM	MSE	NIQE
RetinexNet	11.23	13.75	13.31	16.77	0.56	4 830.05	12.94
ZERO-DCE	10.54	12.59	11.91	17.57	0.63	2 165.03	12.62
ZERO-DCE++	10.17	12.46	11.20	18.02	0.64	1 847.43	12.45
NeRCo	9.41	11.98	10.63	18.28	0.66	1 608.50	12.07
SCINet	9.83	12.49	10.95	17.78	0.62	2 810.28	11.47
LightDiffu-DCE	9.66	11.81	9.31	19.70	0.69	1 084.89	11.04

表 3 表明,相较于其他算法,本文算法在两个数据集上具有一定的优越性,在 Exdark 数据集上 PIQE 和 RISQ 指标最优,分别为 11.81 和 9.31,NIQE 指标排名第二;相较于基准 ZERO-DCE 方法,NIQE,PIQE 和 RISQ 指标分别提高了 0.88,0.78 和 2.6;在 LOL 数据集上 PSNR,SSIM,MSE 和 NIQE 指标最优,分别为 19.70,0.69,1 084.89 和 11.04。本文方法增强后的低光照图像在亮度顺序和整体自然度上更接近正常自然的图像,较好地平滑了低光照图像中的块状效应和噪声问题,从而提升了图像的整体质量,增强图像的整体色彩、亮度对比度和清晰度。

通过在两个公开数据集上的定性和定量的对比实验,证明了 LightDiffu-DCE 方法能够较好地完成低光照图像增强的任务,恢复出的低光照图像整体亮度对比度较高,细节和轮廓信息更加丰富。

3.5 LightDiffu-DCE 增强图对后续任务的实验分析

为验证本文所提方法对后续目标检测的有效性,在低光照目标检测 ExDark 数据集上进行实验,实验选择经典的目标检测算法 YOLOv7 和 RTDETR (Real time detection transformer),经过目标检测网络提取的特征热力图如图 8 所示。




图 8 LightDiffu-DCE 对目标检测的热力图结果

Fig. 8 Heatmap results of LightDiffu-DCE for object detection

从图 8 可以看出,LightDiffu-DCE 方法不仅能够增强图像的整体亮度,而且增强了图像中目

标的轮廓、纹理和颜色信息,使得目标检测网络能够提取到更加丰富的特征,进一步提升检测

精度。

目标检测结果如图 9 所示。从图 9 可以看出,使用 LightDiffu-DCE 方法对低光照图像进

行增强,能够提升后续低光照目标检测的精度,验证了本文方法具有一定的优越性和可靠性。




图 9 LightDiffu-DCE 对低光照目标检测的可视化结果

Fig. 9 Visualization results of LightDiffu-DCE for low light target detection

4 结 论

为了更好地提升低光照图像的亮度,同时精细保留自然色彩与光照分布的细节和轮廓信息,避免过曝光现象,本文提出一种低光照图像增强模型 LightDiffu-DCE。根据低光照不同光源的光照强度和特性设计了 LIPM,以生成不同光照强度的训练数据集,提升模型的泛化能

力。为恢复图像的整体轮廓和细节信息,设计了边缘特征融合的深度曲线估计网络,提取更丰富的低光照图像多尺度轮廓和细节特征,避免噪声放大的同时,提升后续光照强度估计的准确性。最后,融合大气光估计来微调图像,避免恢复出的图像出现过曝光现象,通过计算不同区域的光照强度,恢复出光照亮度更加自然的图像。采用 3 个有参考评价指标和 3 个无参

考评价指标,在无对比数据集 ExDark 和有对比数据集 LOL 上进行了消融实验和对比实验。消融实验证明了改进优化策略的有效性,相较于基准算法,LightDiffu-DCE 在 Exdark 数据集上的 NIQE,PIQE 和 RISQ 指标分别提升了 8.35%,6.20% 和 21.83%,在 LOL 数据集上的 PSNR,SSIM、RMSE 和 NIQE 分别提升了 12.12%,4.76%,49.89% 和 12.52%。对比实验结果表明,本文算法具有更好的增强效果,增

强后的图像质量较高,且轮廓纹理信息更加丰富,效果更加自然。未来,将在低光照增强时融合更多的多模态复杂特征,以获得质量更高的增强图像。

作者贡献声明:

闫光辉:论文构思,方法的提出;
吴佰靖:实验设计及数据的整理和分析;
马龙:论文的编辑与审核。

参考文献:

- [1] 彭大鑫,甄彤,李智慧. 低光照图像增强研究方法综述[J]. 计算机工程与应用, 2023, 59(18): 14-27.
PENG D X, ZHEN T, LI ZH H. Survey of research methods for low light image enhancement [J]. *Computer Engineering and Applications*, 2023, 59(18): 14-27. (in Chinese)
- [2] 袁炬,王笑雪,颜廷昊,等. 双路混合注意力的跨层次特征聚合图像增强[J]. 光学精密工程, 2024, 32(10): 1538-1551.
YUAN H, WANG X X, YAN T H, *et al.* Cross-level feature aggregation image enhancement with dual-path hybrid attention [J]. *Opt. Precision Eng.*, 2024, 32(10): 1538-1551. (in Chinese)
- [3] JIANG H, LUO A, FAN H Q, *et al.* Low-light image enhancement with wavelet-based diffusion models[J]. *ACM Transactions on Graphics*, 2023, 42(6): 1-14.
- [4] 常志文,王立忠,梁晋,等. 基于图像块分解融合的水下标定图像增强[J]. 中国光学(中英文), 2024, 17(4): 810-822.
CHANG ZH W, WANG L ZH, LIANG J, *et al.* Underwater calibration image enhancement based on image block decomposition and fusion[J]. *Chinese Optics*, 2024, 17(4): 810-822. (in Chinese)
- [5] AGNES P, AHMAD I, ALBERGO S, *et al.* Sensitivity projections for a dual-phase argon TPC optimized for light dark matter searches through the ionization channel[J]. *Physical Review D*, 2023, 107(11): 112006.
- [6] 田静. 基于特征加权融合的红外图像增强方法[J]. 激光杂志, 2024, 45(8): 155-158.
TIAN J. Infrared image enhancement method based on feature-weighted fusion [J]. *Laser Journal*, 2024, 45(8): 155-158. (in Chinese)
- [7] LI X F, WANG W W, FENG X C, *et al.* Deep parametric Retinex decomposition model for low-light image enhancement[J]. *Computer Vision and Image Understanding*, 2024, 241: 103948.
- [8] SINGH K, PARIHAR A S. Illumination estimation for nature preserving low-light image enhancement [J]. *The Visual Computer*, 2024, 40(1): 121-136.
- [9] LORE K G, AKINTAYO A, SARKAR S. LL-Net: a deep autoencoder approach to natural low-light image enhancement[J]. *Pattern Recognition*, 2017, 61: 650-662.
- [10] LV F, LU F, WU J, *et al.* MBLLEN: Low-light image/video enhancement using cnns [C]. BMVC, 2018, 220(1): 4.
- [11] WEI C, WANG W J, YANG W H, *et al.* Deep retinex decomposition for low-light enhancement [EB/OL]. 2018: 1808.04560. <https://arxiv.org/abs/1808.04560v1>.
- [12] ZHU M F, PAN P B, CHEN W, *et al.* EEME-FN: low-light image enhancement via edge-enhanced multi-exposure fusion network [J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(7): 13106-13113.
- [13] MA R J, ZHANG B, HU H F. Gaussian pyramid of conditional generative adversarial network for real-world noisy image denoising[J]. *Neural Processing Letters*, 2020, 51(3): 2669-2684.
- [14] HAI J, XUAN Z, YANG R, *et al.* R2RNet: low-light image enhancement via real-low to real-normal network [J]. *Journal of Visual Communication and Image Representation*, 2023, 90: 103712.
- [15] YIN X C, YU Z D, FEI Z T, *et al.* PE-YOLO: pyramid enhancement network for Dark object de-

- tection[C]. *Artificial Neural Networks and Machine Learning-ICANN 2023*. Cham: Springer Nature Switzerland, 2023: 163-174.
- [16] YIN J K, WANG Y, GUAN B W, *et al.* Unsupervised underwater image enhancement based on disentangled representations via double-order contrastive loss[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 3353371.
- [17] GAO Z, YANG J, ZHANG L, *et al.* TEGAN: transformer embedded generative adversarial network for underwater image enhancement[J]. *Cognitive Computation*, 2024, 16(1): 191-214.
- [18] ALMAHAIRI A, RAJESHWAR S, SORDONI A, *et al.*. Augmented cycleGAN: Learning many-to-many mappings from unpaired data[C]. *International conference on machine learning*. PMLR, 2018: 195-204.
- [19] JIN Y Y, YANG W H, TAN R T. Unsupervised night image enhancement: when layer decomposition meets light-effects suppression[C]. *Computer Vision-ECCV 2022*. Cham: Springer Nature Switzerland, 2022: 404-421.
- [20] JIANG Y F, GONG X Y, LIU D, *et al.* EnlightenGAN: deep light enhancement without paired supervision[J]. *IEEE Transactions on Image Processing*, 2021, 30: 2340-2349.
- [21] LI J J, FENG X M, HUA Z. Low-light image enhancement via progressive-recursive network[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2021, 31(11): 4227-4240.
- [22] ZHOU F, SUN X, DONG J Y, *et al.* SurroundNet: Towards effective low-light image enhancement[J]. *Pattern Recognition*, 2023, 141: 109602.
- [23] LI J Q, LI J C, FANG F M, *et al.* Luminance-aware pyramid network for low-light image enhancement[J]. *IEEE Transactions on Multimedia*, 2021, 23: 3153-3165.
- [24] GUO C L, LI C Y, GUO J C, *et al.* Zero-reference deep curve estimation for low-light image enhancement[C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 13-19, 2020. Seattle, WA, USA. IEEE, 2020: 1777-1786.
- [25] ZHANG Y H, LI Y J, LIN Q. Low-light enhancer for UAV night tracking based on zero-DCE++[J]. *Journal of Computer and Communications*, 2023, 11(4): 1-11.
- [26] MA L, MA T Y, LIU R S, *et al.* Toward fast, flexible, and robust low-light image enhancement[C]. 2022 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 18-24, 2022. OrleansNew, LA, USA. IEEE, 2022: 5627-5636.
- [27] DAI Y M, GIESEKE F, OEHMCKE S, *et al.* Attentional feature fusion[C]. 2021 *IEEE Winter Conference on Applications of Computer Vision (WACV)*. January 3-8, 2021. Waikoloa, HI, USA. IEEE, 2021: 3559-3568.
- [28] 张印辉, 庄宏, 何自芬, 等. 氨气泄漏混洗自注意力轻量化红外检测[J]. *中国光学(中英文)*, 2023, 16(3): 607-619.
- ZHANG Y H, ZHUANG H, HE Z F, *et al.* Lightweight infrared detection of ammonia leakage using shuffle and self-attention[J]. *Chinese Optics*, 2023, 16(3): 607-619. (in Chinese)
- [29] TIARIMTI-ALAOUI A, JOURHMANE M. Edge-preserving smoothing of Perona-Malik nonlinear diffusion in two-dimensions[J]. *International Journal of Nonlinear Analysis and Applications*, 2024: 2008-6822.
- [30] 朱凯, 李理, 张彤, 等. 视觉Transformer在低级视觉领域的研究综述[J]. *计算机工程与应用*, 2024, 60(4): 39-56.
- ZHU K, LI L, ZHANG T, *et al.* Survey of vision transformer in low-level computer vision[J]. *Computer Engineering and Applications*, 2024, 60(4): 39-56. (in Chinese)
- [31] YE Z, CHEN T X, WANG F, *et al.* P-mamba: marrying perona malik diffusion with mamba for efficient pediatric echocardiographic left ventricular segmentation [EB/OL]. 2024: 2402.08506. <https://arxiv.org/abs/2402.08506v3>.
- [32] WANG X D, CHEN X A, REN W H, *et al.* Compensation atmospheric scattering model and two-branch network for single image dehazing[J]. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2024, 8(4): 2880-2896.
- [33] FINDER S E, AMOYAL R, TREISTER E, *et al.* Wavelet convolutions for large receptive fields [EB/OL]. 2024: 2407.05848. <https://arxiv.org/abs/2407.05848v2>.
- [34] LOH Y P, CHAN C S. Getting to know low-light images with the Exclusively Dark dataset[J]. *Com-*

- puter Vision and Image Understanding*, 2019, 178: 30-42.
- [35] WU Y H, PAN C, WANG G Q, *et al.* Learning semantic-aware knowledge guidance for low-light image enhancement[C]. 2023 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 17-24, 2023. Vancouver, BC, Canada. IEEE, 2023: 1662-1671.
- [36] YANG S Z, DING M X, WU Y M, *et al.* Implicit neural representation for cooperative low-light image enhancement[C]. 2023 *IEEE/CVF International Conference on Computer Vision (ICCV)*. October 1-6, 2023. Paris, France. IEEE, 2023: 12872-12881.

作者简介:



闫光辉(1970—),男,河南睢县人,博士,教授,博士生导师,主要从事复杂网络分析以及人工智能等方面的研究。E-mail:yanghacademic@163.com

通讯作者:



吴佰靖(1997—),男,甘肃武威人,博士研究生,主要从事图像处理、深度学习的研究。E-mail:1420716156@qq.com