

doi:10.3969/j.issn.1001-4616.2025.05.013

双条件扩散概率模型驱动的低光照图像增强方法

朱文佳^{1,3}, 伊君², 杨正阳³, 陈凤欣³, 余焯³

(1.安徽百诚慧通科技股份有限公司,安徽合肥 230001)
(2.黄冈师范学院计算机与人工智能学院,湖北黄冈 438000)
(3.合肥工业大学计算机与信息学院,安徽合肥 230601)

[摘要] 针对当前低光照图像增强算法生成图像存在色彩恢复不足、噪声和模糊现象等问题,提出一种双条件扩散概率模型驱动的低光照图像增强方法(low-light image enhancement method with dual conditional diffusion probabilistic model, LLDiffusion)。该方法以低光照图像和直方图均衡化图像作为扩散概率模型中反向过程的条件输入,以便充分利用低光照图像内的有效信息。同时,引入双条件噪声预测器,利用其多尺度特征提取模块和时间残差融合模块,获得更具真实性的生成图像,提高图像生成质量。在现有基准数据集 LOL 和 VE-LOL 上对所提方法进行测试,实验结果表明,LLDiffusion 在 P_{SNR} 、 S_{SIM} 、 F_{ID} 指标上均取得良好的效果,基于此方法增强的图像具有更好的曝光控制、更少的噪声和伪影。

[关键词] 扩散概率模型,低光照图像增强,虚拟环境构建,生成模型

[中图分类号] TP391.41 [文献标志码] A [文章编号] 1001-4616(2025)05-0114-07

A Low-Light Image Enhancement Method with Dual Conditional Diffusion Probabilistic Models

Zhu Wenjia^{1,3}, Yi Jun², Yang Zhengyang³, Chen Fengxin³, Yu Ye³

(1.Anhui Baichenghuitong Technology Co.,Ltd., Hefei 230001, China)
(2.School of Computer Science and Artificial Intelligence, Huanggang Normal University, Huanggang 438000, China)
(3.School of Computer and Information, Hefei University of Technology, Hefei 230601, China)

Abstract: To address the issues of inadequate color restoration, noise, and blurriness in images generated by current low-light image enhancement algorithms, a dual conditional diffusion probabilistic model-driven method for low-light image enhancement (LLDiffusion) is proposed. LLDiffusion takes low-light images and histogram equalized images as conditional inputs in the reverse process of diffusion probabilistic model, fully leveraging the valid information within the low-light image. Additionally, a dual conditional noise predictor is introduced, which includes multi-scale feature extraction module and a temporal residual fusion module to produce more realistic generated images, thereby improving the overall image quality. LLDiffusion was tested on benchmark datasets, LOL and VE-LOL. The experimental results demonstrate that the LLDiffusion achieves best performance in terms of F_{ID} , P_{SNR} and S_{SIM} . The enhanced images based on our method exhibit better exposure control, less noise, and fewer artifacts.

Key words: diffusion probabilistic model, low-light image enhancement, construction of virtual environments, generative model

受拍摄条件影响,低光照图像通常会出现严重的噪声和低对比度问题,导致细节损失和颜色失真,从而降低了图像质量。低光照图像增强旨在提升低光照图像的质量,有利于后续目标检测与识别、图像分割等计算机视觉任务,也因在视频监控、机器人视觉、元宇宙虚拟环境构建中的广泛应用而受到关注。

传统低光照图像增强方法对低光照图像的成像原理做出先验假设,并依靠该假设调整图像像素分布进而增强图像,主要包括基于直方图均衡化和基于 Retinex 理论的方法两类。传统方法受先验假设限制,

收稿日期:2024-12-10.

基金项目:安徽省自然科学基金项目(2308085MF216).

通讯作者:伊君,博士,讲师,研究方向:计算机视觉、多媒体技术与三维重建. E-mail:junyi@hgnu.edu.cn

不能依据现实世界的不同光照场景进行自适应增强,导致增强图像中出现噪声增大、亮度不均衡的现象. 基于深度学习的低光照图像增强方法^[1-4]利用神经网络拟合低光照图像到正常光照图像的非线性映射,通过直接学习低光照图像到正常光照图像的端到端映射,或通过图像解耦得到光照图和反射图等方式来获得增强图像. 然而,这些方法大多采用 L1(平均绝对误差)或 L2(均方误差)损失重建图像,其增强图像可能会丢失高频细节并呈现模糊.

在此基础上,基于生成模型的方法尝试学习正常光照图像的条件分布来重建图像,保持图像细节与真实性. 本课题组^[5]采用基于生成对抗网络(generative adversarial networks, GAN)的方法,通过对抗性学习获取正常光照图像分布. 但由于 GAN 方法本身的特性,网络存在训练不稳定和模式崩溃的问题. Wang 等^[6]引入正则化流技术,通过可逆网络提取图像的局部像素相关性和全局图像特性. 虽然基于正则化流的方法比基于 GAN 的方法更加稳定,但其对模型卷积核的设计要求高,计算时需要大量的参数,并且存在高维空间解释性差的问题.

扩散概率模型学习由于噪声引起信息衰减,然后使用学习到的模式来生成图像,有效避免了上述 GAN 和正则化流存在的问题,且扩散概率模型已被应用于图像超分辨率和去雾等领域,取得很好的效果. 最近,扩散概率模型在低光照图像增强领域也得到应用. 如, Yi 等^[7]将 Retinex 理论与扩散概率模型结合,将图像解耦得到光照图和反射图,分别借助扩散概率模型建模增强,修复了图像退化后丢失的细节; Shang 等^[8]将图像分割为多个尺度,并结合图像的频域和空间域特征训练扩散概率模型,减少图像增强后出现的伪影现象. 然而现有方法对条件信息的利用不足,且噪声预测能力有限.

针对上述不足,提出一种双条件扩散概率模型驱动的低光照图像增强方法(low-light image enhancement method with dual conditional diffusion probabilistic model, LLDiffusion),通过双路径条件输入与多层次特征融合实现图像细节的重建.

1 LLDiffusion 方法

1.1 方法概述

在总时间步长为 T 的扩散概率模型基础上, LLDiffusion 对正常光照图像的复杂分布进行建模,如图 1 所示. 首先,利用正向过程将正常光照图像 x_0^{high} 映射为潜在变量 x_T^{high} . 其中, $x_T^{\text{high}} \sim N(0, I)$. 在反向过程中,引入双条件噪声预测器(dual conditional noise predictor, DCNP), 将其将潜在变量 x_t^{high} 、低光照图像 x^{low} 、直方图均衡化图像 x^{he} 和时间步长 t 作为输入来预测噪声. 其反向过程的条件分布可以表示为

$$q_{\theta}(x_{0:T}^{\text{high}} | x^{\text{low}}, x^{\text{he}}) = q(x_T^{\text{high}}) \prod_{t=1}^T q_{\theta}(x_{t-1}^{\text{high}} | x_t^{\text{high}}, x^{\text{low}}, x^{\text{he}}), \quad (1)$$

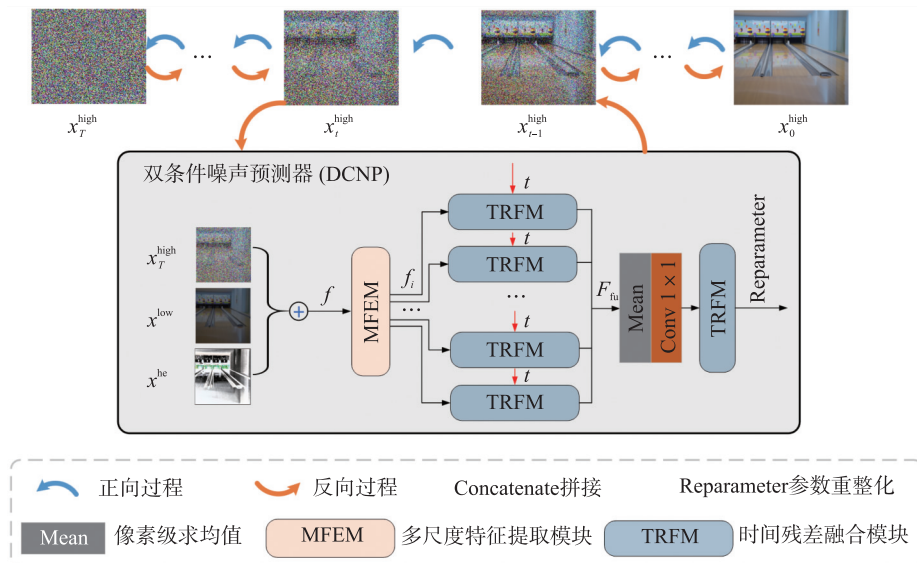


图 1 LLDiffusion 方法架构图

Fig. 1 Architecture of LLDiffusion method

$$q_{\theta}(x_{t-1}^{\text{high}} | x_t^{\text{high}}, x^{\text{low}}, x^{\text{he}}) = N(x_{t-1}; \mu_{\theta}(x_t^{\text{high}}, t, x^{\text{low}}, x^{\text{he}}), \sigma_{\theta}^2 I), \quad (2)$$

式中, $q(x_t) = N(0, I)$, N 表示高斯分布.

训练时将下式最小化, 即

$$L'_{\theta} = \|\varepsilon - \varepsilon'_{\theta}(\sqrt{\bar{\alpha}_t}x_0 + \sqrt{1-\bar{\alpha}_t}\varepsilon, t, x^{\text{low}}, x^{\text{he}})\|_2^2, \quad (3)$$

式中, $\varepsilon'_{\theta}(\cdot)$ 表示通过给定输入 x_0 和时间步长 t , 利用 DCNP 得到的估计值.

推理过程可以利用下式迭代获取 x_{t-1} . 即

$$x_{t-1}^{\text{high}} = \frac{1}{\sqrt{\alpha_t}t} \left(x_t^{\text{high}} - \frac{\beta_t}{\sqrt{1-\bar{\alpha}_t}} \varepsilon_{\theta}(x_t, \bar{\alpha}_t, x^{\text{low}}, x^{\text{he}}) \right) + \sigma_{\theta}^2 \varepsilon. \quad (4)$$

在训练阶段, 输入成对图像用于训练 T 时间步的 LLDiffusion, 然后随机初始化双条件噪声预测器, 通过从训练集采样训练图像、从标准高斯分布中采样 ε 和从均匀分布中抽样 $t, \varepsilon \sim N(0, I), t \sim \{1, \dots, T\}$, 利用公式(3)执行梯度下降算法来优化噪声预测器.

在推理阶段, 仅输入低光照图像, 加载训练好的双条件噪声预测器权重, 执行采样 $x_T \sim N(0, I)$, 然后从 $t=T$ 到 1 迭代计算: 采样 $\varepsilon \sim N(0, I)$, 利用公式(4)获得 x_{t-1}^{high} . 最终输出增强图像.

1.2 双条件噪声预测器

原始扩散模型采用传统 U-Net 结构, 且仅使用低光照图像作为反向过程的条件输入. 由于低光照图像的光源和噪声复杂性, 增强图像质量容易不稳定. 双条件噪声预测器 DCNP 的提出, 在一定程度上解决了上述问题, 提升了增强图像质量. DCNP 将低光照图像 x^{low} 、直方图均衡化图像 x^{he} 作为双条件输入模型, 与潜在变量 x_T^{high} 一起在通道维度上拼接, 生成拼接后的特征 f , 将其作为条件输入到 n 层多尺度特征提取模块(multi-scale feature extraction module, MFEM), 实验中 n 设置为 11. 直方图均衡化可以增强图像的对比度, 使图像中的细节更加明显. 直方图均衡化后的图像可以被视为一个具有光照不变性的图像. 由于同一场景的不同光照条件产生的低光照图像不同, 将直方图均衡化图像作为条件编码器输入的一部分, 可以使网络更好地利用低光照图像的内容特征.

经过 MFEM 模块输出 n 个尺度特征 $f_i (i \in \{1, 2, \dots, n\})$, 然后再分别经过时间残差融合模块(time residual fusion module, TRFM), 获得时间融合特征 F_{ffu} . 最后 F_{ffu} 经过像素级求均值、 1×1 卷积、TRFM 模块和参数重参数化获得 $t-1$ 时刻的潜在向量. 下面分别介绍多尺度特征提取模块 MFEM 和时间残差融合模块 TRFM.

多尺度特征提取模块通过不同形状的掩码, 捕获条件输入的局部特征. 同时采用不同大小的空洞值捕获多级感受野的特征. 如图 2 所示, 将拼接后的特征 f 输入进 1×1 卷积, 随后分别输入到具有 n 层结构的 A 和 B 分支. 如图 3 所示, A_i 和 $B_i (i \in \{1, 2, \dots, n\})$ 表示卷积核与掩码的乘积. $A_i = K_{1i} \odot M_{1i}, B_i = K_{2i} \odot M_{2i} (i \in \{1, 2, \dots, n\})$. 其中, K_{ji} 表示卷积核, $M_{ji} (j \in \{1, 2\}, i \in \{1, 2, \dots, n\})$ 是受空洞卷积启发设计的掩码, 掩码的形状如图 3 所示. 对 A 和 B 分支每一

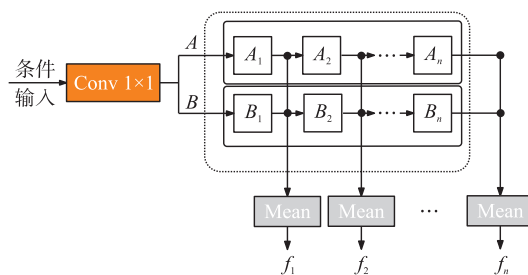


图 2 多尺度特征提取模块

Fig 2 Multi-scale feature extraction module




图 3 掩码示例

Fig. 3 Examples of mask

层的输出进行像素级求均值(图2)获得第 i 个尺度的特征 f_i .因此,经过多尺度特征提取模块可以获得 n 个尺度的特征.

时间残差融合模块的结构如图4所示.将时间步长 t 编码为 t_e ,从而将时间步长 t 转换为一个固定维度的向量,从而使双条件噪声预测器能够更好地学习每一个与时间步长相关的噪声.然后,利用线性层将时间步长编码 t_e 进行维度变换,并加入到两个 3×3 卷积层中间,形成一个分支.同时,增加一个 3×3 卷积层的分支,与上述分支构成残差结构.通过时间残差融合模块可以感知时间步长,以获得更准确的噪声预测结果.




图4 时间残差融合模块

Fig 4 Time residual fusion module

2 实验结果与分析

2.1 数据集与评价指标

实验采用LOL公开数据集^[2]和VE-LOL公开数据集^[7].LOL数据集于2018年被提出,是在真实场景中拍摄的第一个成对的弱光/正常光图像数据集,被广泛应用于低光照图像增强领域.它包含500对大小为 $400\text{ px}\times 600\text{ px}$ 的低/正常光图像,以RGB格式保存,其中15对图像用于测试.VE-LOL数据集于2021年被提出,包括成对的图像和带有标注的低光照非成对图像,具有多样化场景和内容.选取其成对图像中的配对数据,共100对大小为 $400\text{ px}\times 600\text{ px}$ 的低/正常光图像用于测试.

为验证方法性能,选用峰值信噪比(P_{SNR})、结构相似性度量(S_{SIM})和FID(F_{ID})^[9]作为评价指标.

2.2 实验环境与配置

实验的硬件环境为CPU: Intel Core i9-9900KF@3.6 GHz;内存:32 GB;显卡:Nvidia GeForce RTX 3090;显存:24 GB.

实验所有模型在Linux环境下基于开源框架Pytorch实现,CUDA版本为12.1.LLDiffusion在训练和测试时采用的图像大小为 $256\text{ px}\times 256\text{ px}$,扩散步数为2000,批次大小为2,使用Adam作为优化器,学习率为 5×10^{-4} ,没有设置权重衰减,在LOL数据集上模型进行了 3×10^6 次迭代训练,分别在LOL和VE-LOL数据集上做测试.

2.3 在LOL数据集上的实验

将LLDiffusion分别与LIME^[10]、Retinex-Net^[2]、EnlightenGAN^[4]、KinD^[3]、KinD++^[11]、DeepUPE^[12]、Zero-DCE^[13]、RUAS^[14]、LLFlow^[6]、Bread^[15]、SCI^[16]和LLFormer^[17]共12个不同的先进低光照图像增强方法进行比较,实验结果如表1所示.LLDiffusion在 F_{ID} 指标上取得了最佳效果,在 P_{SNR} 和 S_{SIM} 指标上取得了次优效果.

表1 在LOL数据集上实验的定量分析结果

Table 1 Quantitative analysis results of experiments conducted on the LOL dataset

Method	$P_{\text{SNR}}/\text{dB}\uparrow$	$S_{\text{SIM}}\uparrow$	$F_{\text{ID}}\downarrow$	Method	$P_{\text{SNR}}/\text{dB}\uparrow$	$S_{\text{SIM}}\uparrow$	$F_{\text{ID}}\downarrow$
LIME ^[10]	14.344	0.720	81.520	RUAS ^[14]	16.909	0.703	90.156
RetinexNet ^[2]	17.976	0.765	114.938	LLFlow ^[6]	24.202	0.913^a	58.221
EnlightenGAN ^[4]	19.931	0.826	72.732	Bread ^[15]	21.024	0.891	67.112
KinD ^[3]	19.976	0.866	62.643	SCI ^[16]	13.715	0.591	94.794
KinD++ ^[11]	18.045	0.805	98.222	LLFormer ^[17]	24.563^a	0.894	65.302
DeepUPE ^[12]	13.766	0.592	150.344	CDAN ^[18]	20.102	0.816	
Zero-DCE ^[13]	15.354	0.731	110.494	LLDiffusion(Ours)	24.203^b	0.899^b	57.660^a

注:上标a表示最优值,上标b表示次优值,下同.

从实验结果中抽取一组样本,其增强效果如图5所示.由图5(a)可知,LIME算法对噪声信息没有充分地处理,实验结果仍存在大量噪声.图5(b)、(d)和(e)的RetinexNet、KinD和KinD++算法都基于Retinex理论,通过校正光照图调整图像亮度.由于没有对色彩进行很好的约束,均出现不同程度的色偏和噪声.图5(c)和(h)的EnlightenGAN和RUAS算法对图像对比度提升不足.由于DeepUPE算法无法适应

极暗环境,因此图 5(f)上有明显的伪影. 图 5(g)的 Zero-DCE 采用零样本方法,在面对复杂图像时出现过度曝光的现象. 图 5(j)和(k)的 Bread 和 SCI 算法出现亮度增强不足的现象. 图 5(i)和(l)的 LLFlow 和 LLFormer 算法在图中红色矩形框区域的色彩恢复不足,而 LLDiffusion 方法能够更加均匀地增强光照、更好地减少噪声和降低色偏.




图 5 在 LOL 数据集上实验的结果

Fig. 5 Experimental results conducted on the LOL dataset

2.4 在 VE-LOL 数据集上的实验

采用 LOL 数据集上的训练权重对 VE-LOL 数据集中 100 个低光/正常光图像对进行测试,目的是通过对比实验结果,验证 LLDiffusion 的泛化性. 从实验结果中抽取一组样本,其增强效果如图 6 所示. 由图中



图 6 在 VE-LOL 数据集上实验的结果

Fig. 6 Experimental results conducted on the VE-LOL dataset

可见,图(a)、(j)和(k)的亮度增强不足;图(b)、(c)和(g)中出现过曝现象;图(d)和(e)中出现大量噪声;图(f)存在伪影;图(h)存在细节丢失问题;图(i)和(l)中含有少许噪声. 该实验的定量分析结果如表2所示. 其中,LLDiffusion算法在 P_{SNR} 和 F_{ID} 指标上效果为最优,在 S_{SIM} 指标上的表现为次优. 从上述实验结果可知,LLDiffusion算法具有较好的泛化性能.

表2 在VE-LOL数据集上实验的定量分析结果

Table 2 Quantitative analysis results of experiments conducted on the VE-LOL dataset

Method	$P_{\text{SNR}}/\text{dB} \uparrow$	$S_{\text{SIM}} \uparrow$	$F_{\text{ID}} \downarrow$	Method	$P_{\text{SNR}}/\text{dB} \uparrow$	$S_{\text{SIM}} \uparrow$	$F_{\text{ID}} \downarrow$
LIME ^[10]	17.696	0.738	72.729	RUAS ^[14]	15.717	0.682	84.654
RetinexNet ^[2]	18.076	0.760	131.287	LLFlow ^[6]	27.571	0.955^a	40.737
EnlightenGAN ^[4]	19.483	0.834	65.553	Bread ^[15]	24.338	0.929	59.383
KinD ^[3]	21.170	0.893	51.398	SCI ^[16]	16.728	0.589	88.632
KinD++ ^[11]	13.187	0.325	240.373	LLFormer ^[17]	29.662	0.937	49.480
DeepUPE ^[12]	16.289	0.706	111.236	LLDiffusion (Ours)	29.718^a	0.950^b	37.522^a
Zero-DCE ^[13]	13.457	0.659	107.917				

2.5 消融实验

为验证LLDiffusion的有效性,进行了消融实验,实验设置如下.

噪声预测器采用传统U-Net:(1)仅使用低光照图像作为条件输入;(2)使用低光照图像和直方图均衡化图像作为条件输入,噪声预测器采用双条件噪声预测器;(3)仅使用低光照图像作为条件输入;(4)使用低光照图像和直方图均衡化图像作为条件输入.

在LOL数据集上对以上4种设置基于 P_{SNR} 、 S_{SIM} 和 F_{ID} 指标进行分析. 如表3所示,当采用双条件噪声预测器并使用低光照图像和直方图均衡化图像作为条件输入时, P_{SNR} 、 S_{SIM} 和 F_{ID} 指标取得最优值.

2.6 算法复杂度分析

表4对比了不同低光照增强模型需要学习的参数数量(N_{Params})和浮点运算次数(n_{FLOPs}). 实验结果表明,所提方法在参数量与计算量之间实现了更优的平衡. 与基于GAN的EnlightenGAN相比,参数量减少21.4%,计算量降低36.9%;与基于Transformer的LLFormer相比,参数量减少8.3%,计算量减少26.8%. 实验结果验证了双条件噪声预测器设计的有效性,即通过引入直方图均衡化图像的条件先验信息,减少了冗余特征计算,从而在保证生成质量的同时降低了计算复杂度.

表3 双条件噪声预测器的消融实验结果

Table 3 Ablation study results of DCNP

	x^{low}	x^{he}	$P_{\text{SNR}}/\text{dB} \uparrow$	$S_{\text{SIM}} \uparrow$	$F_{\text{ID}} \downarrow$
U-Net	✓		20.334	0.810	82.669
	✓	✓	22.236	0.829	70.614
DCNP	✓		22.107	0.858	65.789
	✓	✓	24.277^a	0.899^a	57.660^a

表4 模型复杂度对比

Table 4 Comparison of model complexity

方法	$N_{\text{Params}} \times 10^6$ 个	$n_{\text{FLOPs}} \times 10^9$ 个
DiffLL ^[19]	20.742	29.740
CLE Diffusion ^[20]	3.210	14.500
LLFormer ^[17]	4.800	18.300
EnlightenGAN ^[4]	5.600	21.300
LLDiffusion (Ours)	4.400	13.400

2.7 超参数分析

对超参数 T 的取值进行分析. 如图7所示,当 $T=2000$ 时, P_{SNR} 与 S_{SIM} 指标达到边际效益转折点($P_{\text{SNR}}=24.20$ dB, $S_{\text{SIM}}=0.899$),进一步增大 T 至2500步时,性能增益不足0.01 dB且计算成本显著增加. 因此,选择 $T=2000$ 作为最优步长,在质量与效率间实现平衡.

3 结论

针对弱光条件下的图像增强问题,提出一种基于扩散概率模型的LLDiffusion方法,将低光照图像和直方图均衡化图像共同作为逆扩散过程的条件输入,以




图7 总时间步长 T 对图像增强质量的影响分析
Fig. 7 Influence of diffusion step size (T) on image enhancement quality

充分利用图像的有效信息,同时,设计了一个双条件噪声预测器,能够更好地学习逆扩散过程的噪声分布.与现有的其他基于重建损失和生成模型的方法相比,LLDiffusion 在调节亮度、抑制噪声和伪影方面取得较好的结果.

[参考文献]

- [1] 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.
- [2] WEI C, WANG W J, YANG W H, et al. Deep retinex decomposition for low-light enhancement[C]//Proceedings of the British Machine Vision Conference. Newcastle: BMVA Press, 2018: 155–166.
- [3] ZHANG Y H, ZHANG J W, GUO X J. Kindling the darkness: a practical low-light image enhancer[C]//Proceedings of the ACM International Conference on Multimedia. Nice: Association for Computing Machinery, 2019: 1632–1640.
- [4] YU Y, CHEN F X, YU J, et al. LMT-GP: combined latent mean-teacher and gaussian process for semi-supervised low-light image enhancement[C]//European Conference on Computer Vision. Milan: Springer, 2024: 261–279.
- [5] 余焯, 陈维笑, 陈凤欣. 面向车型识别的夜间车辆图像增强网络 RIC-NVNet[J]. 中国图像图形学报, 2023, 28(7): 2054–2067.
- [6] WANG Y F, WAN R J, YANG W H, et al. Low-light image enhancement with normalizing flow[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Vancouver: AAAI Press, 2022: 2604–2612.
- [7] YI X P, XU H, ZHANG H, et al. Diff-retinex: rethinking low-light image enhancement with a generative diffusion model[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Paris: IEEE, 2023: 12302–12311.
- [8] SHANG K, SHAO M W, WANG C, et al. Multi-domain multi-scale diffusion model for low-light image enhancement[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Vancouver: AAAI Press, 2024, 38(5): 4722–4730.
- [9] 朱文佳, 张婷, 程秋花, 等. 考虑背景失真的无参考视频质量评价方法[J]. 南京师大学报(自然科学版), 2025, 48(3): 102–111.
- [10] GUO X J, LI Y, LING H B. LIME: low-light image enhancement via illumination map estimation[J]. IEEE transactions on image processing, 2017, 26(2): 982–993.
- [11] ZHANG Y H, GUO X J, MA J Y, et al. Beyond brightening low-light images[J]. International journal of computer vision, 2021, 129(4): 1013–1037.
- [12] WANG R, ZHANG Q, FU C W, et al. Underexposed photo enhancement using deep illumination estimation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 6842–6850.
- [13] GUO C L, LI C Y, GUO J C, et al. Zero-reference deep curve estimation for low-light image enhancement[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Virtual Event: IEEE, 2020: 1777–1786.
- [14] LIU R S, MA L, ZHANG J A, et al. Retinex-inspired unrolling with cooperative prior architecture search for low-light image enhancement[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Virtual Event: IEEE, 2021: 10556–10565.
- [15] HU Q, GUO X J. Low-light image enhancement via breaking down the darkness[J]. International journal of computer vision, 2022, 131(1): 48–66.
- [16] MA L, MA T Y, LIU R S, et al. Toward fast, flexible, and robust low-light image enhancement[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022: 5627–5636.
- [17] WANG T, ZHANG K H, SHEN T R, et al. Ultra-high-definition low-light image enhancement: a benchmark and transformer-based method[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Washington, D.C.: AAAI Press, 2023: 295.
- [18] SHAKIBANIA H, RAOUFI S, KHOTANLOU H. Cdan: convolutional dense attention-guided network for low-light image enhancement[J]. Digital signal processing, 2025, 156: 104802.
- [19] JIANG H, LUO A, FAN H Q, et al. Low-light image enhancement with wavelet-based diffusion models[J]. ACM transactions on graphics (TOG), 2023, 42(6): 1–14.
- [20] YIN Y Y, XU D, TAN C C, et al. Cle diffusion: controllable light enhancement diffusion model[C]//Proceedings of the 31st ACM International Conference on Multimedia. Ottawa: ACM, 2023: 8145–8156.

[责任编辑: 杜忆忱]