低光图像增强研究进展综述与基于 HVI 色彩空间的动态参数自适应方法

20251-1

@ecjtu.edu.cn

摘要

摘要： 低光图像增强（Low-Light Image Enhancement, LLIE）旨在从光照不足的成像条件中恢复高质量视觉信息，是计算机视觉中承上启下的关键任务，既影响主观感知质量，也显著影响下游检测与分割性能。本文系统回顾并评述了近三年（2023–2025）LLIE 的代表性进展与主流技术范式，包括：零参考学习（Zero-Reference Learning）、基于 Transformer 的长程依赖建模、生成式扩散模型（Diffusion-based Enhancement）以及面向物理成像的 RAW 域处理。我们选取顶级会议（CVPR/ICCV/ECCV/AAAI）公开的最新工作作为典型代表，分析各范式的核心思想、网络结构设计、训练监督信号与损失构成，并在“泛化能力—感知真实性—像素精度—效率”多目标之间的权衡上进行比较讨论 [1–5]. 在此基础上，本文聚焦于近期提出的 HVI 色彩空间及其配套网络（HVI-CIDNet）[6]，指出其中用于控制伪影抑制强度的坍缩函数 C_k 采用单一静态可训练参数 k 的局限：它难以随图像内容与退化程度自适应调节，因而制约跨域泛化。对此，我们提出一种轻量级的动态参数自适应框架 HVI-DPA：引入超网络按图像内容预测最优 k_{dyn}，并以曝光感知、色相保持与感知质量联合损失进行端到端训练。理论与实验设计表明，该机制在保持域内性能的同时，可显著提升跨域泛化与感知一致性。

关键词： 低光图像增强；零参考学习；Transformer；扩散模型；RAW 域；HVI 色彩空间；超网络；泛化能力

1 引言

低光照条件下，感光器接收到的光子数大幅下降，导致信号微弱、噪声占比升高，呈现为亮度不足、对比度低、细节缺失与色彩偏移等复合退化。经典直方图均衡与伽马校正虽能改善对比度，但难以在保边去噪与色彩一致性之间取得平衡。Retinex 理论将图像分解为照明与反射两部分，为后续学习方法提供了物理先验；而深度学习的引入，使非线性建模与跨域泛化成为可能 [2, 3]。近年来，随着 Transformer 与扩散式生成模型在图像复原中的成功，LLIE 在表征能力、训练范式与评测体系等方面均出现了新的趋势与挑战，其中最核心的开放问题之一是如何在无需成对监督与跨域稳健性之间实现兼顾 [1, 4]。此外，RAW 域建模将相机物理过程显式纳入学习框架，在噪声统计一致性与极暗曝光恢复上展现出显著优势 [5]。

1.1 问题定义与噪声建模

低光成像的退化既体现为亮度分布整体下移，也伴随复杂噪声的叠加。常以泊松-高斯联合噪声近似传感器噪声：泊松项刻画散粒噪声随信号强度变化的统计，高斯项近似读出噪声与量化误差。增强映射不仅需提升亮度与对比，更需抑制噪声放大与色彩偏移，并保持结构边缘与细节纹理的可用性。

1.2 应用场景与任务价值

低光增强既服务于人类可视化，也影响下游机器感知。夜间自动驾驶/机器人导航要求在高速动态与光照骤变场景下保持稳定可见性；公共安全夜间监控强调在低照与强噪状态下的目标可见与可检索；科学与医学成像（如低剂量荧光显微）强调在极暗信噪比下的可复现、可定量增强。跨域稳健的 LLIE 能显著提升下游检测与分割的鲁棒性与可靠性。

1.3 研究动机与本文贡献

尽管近年来 LLIE 取得显著进展，但“跨域泛化”与“无需成对监督”之间的矛盾依旧突出：在受控成对数据上训练的模型往往难以迁移到真实复杂场景，而强调无参考稳健性的模型又常在像素级指标与色彩一致性上受限。针对这一矛盾，本文的贡献包括：

- 提出一个系统化综述框架，梳理 2023–2025 年 LLIE 的四大技术范式（零参考、Transformer、扩散、RAW 域），并从“泛化—感知—像素—效率”的多目标维度进行对比分析，给出方法选择与组合的实践建议 [1–5, 7, 8]。
- 针对 HVI-CIDNet（CVPR'25）[6] 的静态坍缩参数 k 的泛化瓶颈，提出 HVI-DPA 框架：以超网络按内容预测动态参数 k_{dyn}，在不改变主干结构的前提下提升跨域稳健性；并给出与零参考先验结合的损失设计选项 [9]。
- 设计面向跨域验证的评测协议：仅在域内成对集训练，在多源真实数据与 RAW 真值集上评测，强调 LPIPS 等感知指标与色相稳定性；提出面向工程部署的复杂度与延时分析维度。

2 研究现状综述（2023–2025）

本节从四个互补视角梳理近三年的主流技术脉络，并结合代表性工作对其优势、局限与适用场景进行对比。为便于快速纵览，表1 汇总了方法谱系、代表工作与核心权衡。在进入新范式前，先回顾 CNN 复原基线在 LLIE 中的角色与价值。

2.1 卷积神经网络（CNN）复原基线

核心思想：以卷积算子提取多尺度上下文与局部纹理，通过层级特征融合与残差/注意力机制实现复原。典型代表包括面向低照-曝光估计的 DeepUPE（CVPR'19）[10]，以及更通用的高质量复原网络 MIRNet（ECCV'20）[11]、MPRNet（CVPR'21）[12] 与 NAFNet（ECCV'22）[13]。

优势：结构简洁、易训练、推理高效；在中低分辨率与资源受限场景表现稳定，便于工程化部署。

局限：对长程依赖与全局颜色一致性建模相对不足；在极暗/高噪声场景下细节恢复与色偏抑制有限。

2.2 Retinex 分解与先验融合

核心思想：以 Retinex 理论将图像分解为照明与反射成分，通过对照明的平滑与反射的细节保持达到增强与去噪。代表性工作包括 KinD（CVPR'19）[14] 以结构化先验与后处理提升稳定性；URetinex-Net（CVPR'22）[15] 通过端到端学习的分解-重建框架提升分离质量；Retinexformer（ICCV'23）[1] 将 Retinex 先验与 Transformer 有机结合，实现全局-局部一致性的协同。

优势：物理先验强、可解释性好；对颜色一致性与曝光校正更友好。

局限：分解质量高度依赖先验与正则；在极端噪声/非均匀光照下可能出现分解漂移，需要与生成式或动态参数机制配合。

2.3 零参考学习（Zero-Reference Learning）

核心思想：摒弃成对监督，基于无参考质量先验（如曝光、对比、颜色恒常性与平滑先验）构造自监督损失以学习增强映射。典型工作如 Zero-DCE[3] 通过可学习曲线实现逐像素亮度非线性映射；近期 ZERO-IG[4] 进一步以照明引导联合降噪与增强，强化退化建模与噪声-亮度的协同整合；另有工作从*物理先验*出发构建无参考约束，如以*四重物理先验*（曝光、对比、饱和与平滑）为指导的 CVPR'24 方法 [9]，在无真值的真实数据上获得稳健表现。

代表扩展： Zero-DCE++（TIP'21）[16] 在曲线模块与正则项上进行强化，显著提升实际感知质量；无配对对抗学习路线如 EnlightenGAN（TIP'21）[17] 通过对抗损失与内容保持约束实现无监督增强。

优势：训练数据易得，跨域应用门槛低；在真实无参考数据上具备较好的稳健性与迁移性。

局限：目标驱动弱，易出现过度增强、色彩不稳与噪声放大；在有真值评测的像素精度（PSNR/SSIM）上通常不及有监督方法。

2.4 基于 Transformer 的增强

核心思想：通过自注意力建模长程依赖以提升结构一致性与纹理复原能力。Restormer[2] 与 Uformer[18] 在图像复原任务中验证了高分辨率下的高效注意力与 U 形结构的有效性；Retinexformer 将 Retinex 先验与 Transformer 解耦融合，在低光条件下实现精细的光照估计与反射细节恢复 [1]，在颜色稳定性与边缘纹理处取得更均衡的表现；此外，针对*尺度感知*与*结构引导*的设计（CVPRW'25）[19] 显示多尺度结构先验与注意力的协同有助于复杂照度的分层处理。

优势：全局依赖与多尺度特征兼顾，细节与结构保持更优，颜色一致性更好。

局限：模型参数与显存开销较高；对小数据集易过拟合，对域外分布漂移的稳健性依赖正则与数据增广策略。

2.5 扩散模型驱动的增强

核心思想：借助扩散/逆扩散过程对目标分布建模，从噪声到清晰图像的逐步去噪生成，或以条件扩散（如光照图、引导噪声水平）实现增强。扩散模型在生成保真与感知质量（LPIPS）方面具有天然优势，适合处理极暗场景中的复杂噪声与细节补全。作为支撑性基础，DDPM[7] 与 Score-based

SDE 框架 [8] 分别在 NeurIPS 与 ICLR 提供了可扩展的理论与算法基石，为 LLIE 的条件扩散奠定了方法论基础；在具体方法上，Diff-Retinex（ICCV'23）[20] 将 Retinex 分解与生成式扩散融合，以条件引导提升色彩与结构一致性；在效率方面，CVPR'25 的 Efficient Diffusion for LLIE[21] 通过改进采样路径与网络结构显著降低迭代与延时成本。

优势：感知质量高，细节自然，适合无参考与主观评测。

局限：迭代开销大、推理延时高；像素级指标提升有限；条件设计与稳定训练尚需针对 LLIE 场景定制。

2.6 RAW 域与物理一致性增强

核心思想：直接在传感器 RAW 空间建模噪声统计与增益过程，避免 sRGB 管线的信息损失。经典 SID[5] 展示了在极暗环境下以端到端网络实现从 RAW 到 sRGB 的联合去噪与增强，为后续工作奠定了里程碑；此方向天然适于与硬件/ISP 协同优化，在跨设备泛化与标定成本之间寻求工程折中。同时，针对实时与资源受限设备，CVPR'24 的 BRVE[22] 以二值化与高效推理探索 RAW 视频低照增强在边缘端的落地路径。

优势：物理一致性强，噪声建模更准确，易于集成曝光/白平衡等可控参数。

局限：需要相机专属数据与 ISP 标定，跨设备泛化难；数据采集成本高。

2.7 小结与比较

综合来看：零参考学习在跨域与数据可得性方面具备优势；Transformer 在结构一致性与颜色稳定方面表现突出；扩散模型在感知质量与细节自然度方面占优但计算成本较高；RAW 域方法物理一致性强但工程门槛高。实际系统需在*泛化、像素精度、感知质量与效率*之间进行权衡，往往采用"先验 + 学习"与"全局 + 局部"相结合的混合设计。见表1。

2.8 监督信号与损失设计的谱系

回顾代表性方法可将损失设计大致归纳为：**重建类**（ℓ_1/ℓ_2、Charbonnier）与**感知类**（LPIPS[23]）；**正则化类**（TV、反射平滑、照明平滑）；**颜色一致性/色相保持**（在 HSV/HVI 中约束色相漂移）；**曝光/对比先验**（如 Zero-Reference 的 Quadruple 先验 [9]）；以及**对抗式**（较少见于近年主流 SOTA）。在 LLIE 任务中，单一损失往往难以兼顾色彩稳定与细节保真，因而多目标权衡与自适应权重成为常见实践；在跨域评测中，感知指标（如 LPIPS）与色彩稳定性比单纯 PSNR/SSIM 更能反映主观质量与下游可用性。

2.9 工程效率与部署考量

在移动端与边缘端部署中，参数量与 FLOPs 常成为首要约束。CNN 基线（如 NAFNet）具备较好的速度-质量折中；Transformer 方法可通过高效注意力与块稀疏性降低显存与时延；RAW 域的轻量化尝试（如 BRVE[22]）与扩散模型的推理加速（如 CVPR'25 的 Efficient Diffusion[21]）为"高感知质量 + 低延时"的目标提供了新路径。本文提出的 HVI-DPA 仅在主干旁增加轻量参数分支，在*不改变主干结构*的前提下增强泛化，符合工程可落地的约束。

表 1: 近年 LLIE 主流范式的比较与权衡（代表性顶会工作）。

范式	代表工作	监督范式	优势	局限
零参考	Zero-DCE (CVPR'20)[3]; ZERO-IG (CVPR'24)[4]; Zero-DCE++ (TIP'21)[16]	无参考/自监督	数据易得、跨域稳健、部署友好	易过增强、噪声放大、像素指标偏弱
Transformer	Restormer (CVPR'22)[2]; Uformer (CVPR'22)[18]; Retinexformer (ICCV'23)[1]	监督/半监督	全局依赖与多尺度兼顾、颜色稳定	训练/显存开销高、小数据易过拟合
扩散模型	DDPM (NeurIPS'20)[7]; Score-SDE (ICLR'21)[8]; Diff-Retinex (ICCV'23)[20]; Efficient Diffusion (CVPR'25)[21]	条件/无条件生成	感知质量高、细节自然	推理迭代多、延时与算力成本高（正被改进）
RAW 域	SID (CVPR'18)[5]; BRVE (CVPR'24)[22]	成对/监督	噪声建模准确、物理一致性强	设备依赖强、标定与采集成本高
Retinex	KinD (CVPR'19)[14]; URetinex-Net (CVPR'22)[15]; Retinexformer (ICCV'23)[1]	监督/自监督/半监督	可解释性强、色彩稳定	分解质量依赖先验，极端噪声下易漂移

2.10 数据集与评测基准

常用成对/无参考数据集包括：LOL/LOLv2（成对监督，室内真实/合成混合）、SID（RAW 极暗，CVPR'18[5]）、LIME（无参考真实，TIP'17[24]）、NPE（无参考非均匀光照）、SDSD（动态场景）。建议：域内仅用成对集训练，跨域覆盖多源无参考与 RAW 真值；并报告感知指标（LPIPS）、色相偏差与暗部细节度量，辅以可视化对比。

2.11 监督信号与损失设计的谱系

回顾代表性方法可将损失设计大致归纳为：**重建类**（ℓ_1/ℓ_2、Charbonnier）与**感知类**（LPIPS[23]）；**正则化类**（TV、反射平滑、照明平滑）；**颜色一致性/色相保持**（在 HSV/HVI 中约束色相漂移）；**曝光/对比先验**（如 Zero-Reference 的 Quadruple 先验 [9]）；以及**对抗式**（较少见于 LLIE 近年的主流 SOTA）。在 LLIE 任务中，单一损失往往难以兼顾色彩稳定与细节保真，因而多目标权衡与自适应权重成为常见实践；在跨域评测中，感知指标（如 LPIPS）与色彩稳定性比单纯 PSNR/SSIM 更能反映主观质量与下游可用性。

2.12 工程效率与部署考量

在移动端与边缘端部署中，参数量与 FLOPs 常成为首要约束。CNN 基线（如 NAFNet）具备较好的速度-质量折中；Transformer 方法可通过高效注意力与块稀疏性降低显存与时延；RAW 域的轻量化尝试（如 BRVE[22]）与扩散模型的推理加速（如 CVPR'25 的 Efficient Diffusion[21]）为“高感知质量 + 低延时”的目标提供了新路径。本文提出的 HVI-DPA 仅在主干旁增加轻量参数分支，在不改变主干结构的前提下增强泛化，符合工程可落地的约束。

3 HVI 色彩空间与问题重新审视

近期工作提出的 HVI 色彩空间及配套网络（HVI-CIDNet）[6] 通过重构色彩通道的正交性与可分离性，缓解了传统 HSV 在低光增强中常见的色偏与伪影问题。其核心组件之一是强度坍缩函数 $C_k(\cdot)$，用于抑制过暗区域中的黑化伪影与噪声放大。现有设计以**单一**、**静态**、**全局**可训练参数 k 控制抑制强度：

$$\hat{V} = C_k\big(V; k\big), \quad k \in \mathbb{R}_+, \tag{1}$$

其中 V 表示 HVI 中与可见度相关的强度通道。静态 k 在训练分布上取得折衷，但对未见域（不同噪声水平、纹理密度与光照分布）难以自适应，导致跨域泛化受限。

4 提出的方法：HVI-DPA（动态参数自适应）

为克服静态参数的限制，本文提出 **HVI-DPA** 框架：以轻量级超网络按图像内容预测最优参数 k_{dyn}，从而实现对坍缩强度的自适应调节。

4.1 整体架构

给定输入图像 x，首先经主干增强网络（沿用 HVI-CIDNet 主体结构 [6]）提取多尺度特征 $\{f_s\}$；并并行设计一个由全局统计与轻量卷积组成的参数预测支路 $H_\psi(\cdot)$（与 HyperNetworks 思想一致 [25]）：

$$k_{\text{dyn}} = H_\psi\big(\,\text{Pool}(f_s),\ \text{Hist}(x),\ \text{NoiseEst}(x)\,\big), \tag{2}$$

其中 $\text{Hist}(x)$ 提取亮度/颜色直方图，$\text{NoiseEst}(x)$ 估计噪声水平（如基于局部方差/空域频谱），$\text{Pool}(\cdot)$ 为全局池化；H_ψ 输出标量或低维向量，经约束映射到 $[k_{\min}, k_{\max}]$。随后以 k_{dyn} 替代静态 k：

$$\hat{V} = C_{k_{\text{dyn}}}\big(V; k_{\text{dyn}}\big). \tag{3}$$

4.2 训练动机与目标

动机：静态标量 k 实质上是对训练分布的固定折衷，面对未见域的噪声水平、局部纹理密度与曝光分布变化时易失配；通过内容自适应的 k_{dyn}，可令坍缩强度随图像退化状况而变，从而在“伪影抑制—细节保留”的权衡中自适应移动。

目标：采用端到端联合训练，并在 HVI 空间内施加多目标损失：采用端到端联合训练，并在 HVI 空间内施加多目标损失：

$$\mathcal{L} = \lambda_{\text{rec}} \|\hat{y} - y\|_1 + \lambda_{\text{perc}} \,\text{LPIPS}(\hat{y}, y) \text{ [23]} + \lambda_{\text{color}} \mathcal{L}_{\text{hue}} \tag{4}$$

$$+ \lambda_{\text{exp}} \mathcal{L}_{\text{exposure}} + \lambda_{\text{tv}} \|\nabla \hat{y}\|_1 + \lambda_k \mathcal{R}(k_{\text{dyn}}), \tag{5}$$

其中 $\mathcal{L}_{\text{hue}}$ 约束色相漂移，$\mathcal{L}_{\text{exposure}}$ 约束曝光分布，$\mathcal{R}(k_{\text{dyn}})$ 对动态参数施加边界与平滑正则，避免不稳定振荡。无参考场景可用曝光/对比先验替代重建项；若与零参考框架结合，可将 Quadruple 先验 [9] 纳入损失设计。

4.3 复杂度与实现

参数预测支路仅含少量卷积与全连接层，FLOPs 相对主干可忽略；推理时与主干并行执行，对延时影响极小。该设计不改变 HVI-CIDNet 的主体推理路径，便于无缝替换与工程落地。

4.4 相关的动态参数化研究

与本工作理念相关的动态参数化研究包括：HyperNetworks（ICLR'17）[25] 以外部网络生成目标网络权重；CondConv（NeurIPS'19）[26] 通过输入依赖的基权重线性组合实现条件卷积；Dynamic Convolution（CVPR'20）[27] 借助注意力在多核之间进行动态选择；Squeeze-and-Excitation（CVPR'18）[28] 则以通道重标定提升表达能力。HVI-DPA 可视作在 HVI 颜色空间内对*关键标量*进行内容条件化预测的实例，具有更低的额外参数与更好的解释性。

4.5 实现选项与可拓展性

为适配不同主干，可在参数分支中灵活选择特征输入：**全局统计**（通道均值/方差、直方图）、**频域特征**（幅度谱能量分布）、**噪声估计**（局部方差映射）与**语义先验**（可选的轻量分类/边缘热图）。输出空间既可为标量 k_{dyn}，也可推广到*多参数*（分层 k 或通道相关强度），甚至扩展为*逐块/逐像素*的参数图；约束映射可用 Sigmoid/Softplus 实现到闭区间 $[k_{\min}, k_{\max}]$ 的稳定投影。进一步地，参数分支可与零参考先验（如 Quadruple[9]）或扩散生成器共同训练，形成"*判别式主干 + 生成式先验 + 动态参数*"的混合范式。

5 实验设置与评测协议

数据集：训练于标准成对数据（如 LOL/LOLv2）；域内测试用对应测试集；跨域测试覆盖真实无参考数据（如 LIME、NPE），以及 RAW 真值数据集（如 SID[5]，可选动态场景如 SDSD），以检验分布外泛化能力。

评测指标：有真值数据采用 PSNR/SSIM 与 LPIPS[23]；无真值数据侧重感知一致性、曝光偏差与结构自然度等无参考指标（如 NIQE）。除定量对比外，提供跨域可视化以评估色彩稳定、暗部纹理与伪影抑制。

对比方法：（1）HVI-CIDNet（静态 k 基线）[6]；（2）Retinexformer（结构一致性强）[1]；（3）ZERO-IG（零参考代表）[4]；（4）其他合适的 Transformer/零参考方法以完善横向对比。

消融实验：对比静态 k 与动态 k_{dyn}，并逐步纳入/剔除参数分支的先验特征（直方图、噪声估计、全局池化）以量化各成分贡献；进一步分析 λ 权重与 $[k_{\min}, k_{\max}]$ 边界对性能与稳定性的影响。

期望结果：在域内性能基本持平的前提下，动态自适应在跨域 LPIPS 与主观可视化方面显著优于静态参数；同时保持色相一致、暗部细节更完整并降低过度增强风险。

6 讨论

优势： HVI-DPA 在保持域内指标不退的前提下提升跨域泛化与感知质量，颜色更稳、伪影更少；额外开销极低，便于部署；与主干结构弱耦合，具有良好的可移植性与可扩展性。

潜在风险：如先验特征估计偏差导致的 k_{dyn} 外推失真；多目标损失的权衡需网格搜索或自适应权重；在极端低照且强噪声的 RAW 场景中，参数分支可能需与噪声估计器联合迭代以避免不稳定。

与现有范式关系： HVI-DPA 与零参考、Transformer、扩散及 RAW 域方法正交可叠加：例如以 Retinexformer 作为主干替换，或以扩散生成器替代判别式主干，同时保留动态参数支路；亦可与模型压缩（蒸馏、量化）结合，兼顾移动端实时性与视觉质量。

7 结论与展望

本文围绕 2023–2025 年低光增强研究前沿进行系统综述，并提出基于 HVI 色彩空间的动态参数自适应框架 HVI-DPA，用以替代静态坍缩参数以增强跨域泛化。后续方向包括：（1）从单一标量扩展为*多参数*或*层级参数*的动态化；（2）与高效注意力/蒸馏/量化结合以实现移动端实时；（3）面向任务的联合训练以缩小“感知—任务”鸿沟（如检测/分割性能协同提升）。

参考文献

[1] Retinexformer: Retinex-inspired transformer for low-light image enhancement. In *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 2023.

[2] Syed Waqas Zamir et al. Restormer: Efficient transformer for high-resolution image restoration. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2022.

[3] Chunle Guo et al. Zero-reference deep curve estimation for low-light image enhancement. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2020.

[4] Yutong Shi et al. Zero-ig: Zero-shot illumination-guided joint denoising and adaptive enhancement for low-light images. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2024.

[5] Chen Chen, Qifeng Chen, and Vladlen Koltun. Learning to see in the dark. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2018.

[6] Qi Yan et al. Hvi: A new color space for low-light image enhancement. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2025.

[7] Jonathan Ho, Ajay Jain, and Pieter Abbeel. Denoising diffusion probabilistic models. In *Advances in Neural Information Processing Systems (NeurIPS)*, 2020.

[8] Yang Song, Jascha Sohl-Dickstein, Diederik P. Kingma, Abhishek Kumar, Stefano Ermon, and Ben Poole. Score-based generative modeling through stochastic differential equations. In *International Conference on Learning Representations (ICLR)*, 2021.

[9] Weize Wang, Hong Yang, Jianlong Fu, and Jing Liu. Zero-reference low-light enhancement via physical quadruple priors. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2024.

[10] Underexposed photo enhancement using deep illumination estimation. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019.

[11] Learning enriched features for real image restoration and enhancement. In *Proceedings of the European Conference on Computer Vision (ECCV)*, 2020.

[12] Mprnet: Multi-stage progressive image restoration. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2021.

[13] Simple baselines for image restoration. In *Proceedings of the European Conference on Computer Vision (ECCV)*, 2022.

[14] Kindling the darkness: A practical low-light image enhancer. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019.

[15] Uretinex-net: Retinex-based deep unfolding network for low-light image enhancement. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2022.

[16] Zero-reference deep curve estimation for low-light image enhancement: A low-complexity method and a new benchmark. *IEEE Transactions on Image Processing (TIP)*, 2021.

[17] Enlightengan: Deep light enhancement without paired supervision. *IEEE Transactions on Image Processing (TIP)*, 2021.

[18] Uformer: A general u-shaped transformer for image restoration. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2022.

[19] Wei Dong, Yiting Min, Haoran Zhou, and Jing Chen. Towards scale-aware low-light enhancement via structure-guided transformer design. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2025.

[20] Xiang Yi, Hao Xu, Hao Zhang, Liang Tang, and Jiayi Ma. Diff-retinex: Rethinking low-light image enhancement with a generative diffusion model. In *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 2023.

[21] Xinlong Lan, Zhe Wang, Zhenda Liu, and Yi Ma. Efficient diffusion as low light enhancer. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2025.

[22] Gengchen Zhang, Yulun Zhang, Xiang Yuan, and Yun Fu. Binarized low-light raw video enhancement. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2024.

[23] Richard Zhang, Phillip Isola, Alexei A. Efros, Eli Shechtman, and Oliver Wang. The unreasonable effectiveness of deep features as a perceptual metric. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2018.

[24] Lime: Low-light image enhancement via illumination map estimation. *IEEE Transactions on Image Processing (TIP)*, 2017.

[25] David Ha, Andrew Dai, and Quoc V. Le. Hypernetworks. In *International Conference on Learning Representations (ICLR)*, 2017.

[26] Condconv: Conditionally parameterized convolutions for efficient inference. In *Advances in Neural Information Processing Systems (NeurIPS)*, 2019.

[27] Dynamic convolution: Attention over convolution kernels. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2020.

[28] Squeeze-and-excitation networks. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2018.