

中图法分类号: TP3 文献标识码: A 文章编号: 1006-8961(2026)05-1545-12

论文引用格式: Zhang W D, Gao X Y, Zhou L, Lu H X and Zhao W Y. 2026. PrioLLIE: latent space decomposition guided by illumination-prior constraints for low-light image enhancement. Journal of Image and Graphics, 31(5):1545-1556(张卫东, 高兴运, 周玲, 路皓翔, 赵文义. 2026. 先验照明约束的潜在空间分解方法用于低光照图像增强. 中国图象图形学报, 31(5):1545-1556)[DOI:10.11834/jig.250484]

先验照明约束的潜在空间分解方法用于 低光照图像增强

张卫东^{1,2}, 高兴运¹, 周玲^{1,3}, 路皓翔⁴, 赵文义^{5*}

1. 河南科技学院信息工程学院, 新乡 453003; 2. 郑州大学电气与信息工程学院, 郑州 450001;
3. 上海大学机电工程与自动化学院, 上海 200444; 4. 桂林电子科技大学计算机与信息安全学院, 桂林 541004;
5. 北京邮电大学人工智能学院, 北京 100876

摘要: **目的** 现有低光照图像增强方法大多直接学习从低光图像到增强图像的端到端映射, 因缺乏对照明与反射分量的有效先验约束, 难以在复杂低光条件下准确区分两类分量, 易导致暗区域噪声放大、色彩偏移等问题。为此, 提出一种照明先验约束的潜在空间分解方法 (prior-illumination-based latent space decomposition for low-light image enhancement, PrioLLIE), 以实现更稳定、更有效的光照建模。**方法** 首先, 构建了空间先验融合模块, 结合 RGB (red, green, blue) 空间的色彩信息与 HSV (hue, saturation, value) 空间亮度通道, 提取并融合多源光照先验以形成鲁棒的照明引导特征。随后, 设计了潜在向量提取模块, 将输入映射至潜在特征空间, 对光照分量进行解耦建模, 并在生成过程中注入先验特征以增强光照估计的可控性与稳定性。最后, 提出一种 Retinex 驱动的跨空间分解模块, 在潜在空间中实现照明分量的精准分解, 并在 RGB 空间对反射分量建模, 实现内容与光照的互补表达, 提高分解与重建的协同性。**结果** 将本文方法与 SCLM (single convolutional layer model) 等 10 种方法在 3 个基准低光照数据集上进行定性和定量评估。在相近参数量下, 本文方法在峰值信噪比 (peak signal-to-noise ratio, PSNR) 上比 StableLLVE (learning temporal consistency) 提高了 2.40 dB, 在 LOL (low-light dataset) 数据集的结构相似性 (structural similarity index measure, SSIM)、学习式感知图像块相似度 (learned perceptual image patch similarity) 和色差 (DeltaE) 上均优于其他算法。**结论** PrioLLIE 通过引入照明先验并结合潜在空间解耦建模, 有效缓解了传统端到端方法在复杂低光场景中存在的光照估计偏差与细节恢复不足等问题。该方法具有良好的普适性和泛化性, 具有较好的潜在应用价值。

关键词: 低光照图像增强; 反射分量; 照明分量; 先验约束; 潜在特征

PrioLLIE: latent space decomposition guided by illumination-prior constraints for low-light image enhancement

Zhang Weidong^{1,2}, Gao Xingyun¹, Zhou Ling^{1,3}, Lu Haoxiang⁴, Zhao Wenyi^{5*}

1. School of Information Engineering, Henan Institute of Science and Technology, Xinxing 453003, China;
2. School of Electrical and Information Engineering, Zhengzhou University, Zhengzhou 450001, China;
3. School of Mechatronic Engineering and Automation, Shanghai University, Shanghai 200444, China;

收稿日期: 2025-10-13; 修回日期: 2025-12-05; 预印本日期: 2025-12-12

* 通信作者: 赵文义 zwy@bupt.edu.cn

基金项目: 国家自然科学基金项目 (62403066); 中国博士后科学基金面上项目 (2024M750747); 河南省高等学校青年骨干教师培养计划项目 (2025GGJS099); 河南省高等教育教学改革研究与实践项目 (研究生教育类) (2025SJGLX208Y)

Supported by: National Natural Science Foundation of China (62403066); General Program of China Postdoctoral Science Foundation (2024M750747); Young Backbone Teachers Training Program of Henan Provincial Colleges and Universities (2025GGJS099)

4. School of Computer and Information Security, Guilin University of Electronic Technology, Guilin 541004, China;

5. School of Artificial Intelligence, Beijing University of Posts and Telecommunications, Beijing 100876, China

Abstract: Objective Most existing low-light image enhancement methods, as a core branch of computer vision, primarily rely on deep learning frameworks, such as convolutional neural networks, vision transformers, or their hybrid architectures, to directly learn end-to-end mapping from raw low-light images (often suffering from low signal-to-noise ratio (SNR), uneven brightness distribution, and color information loss) to visually enhanced counterparts. This data-driven paradigm has gained widespread adoption because of its simplicity in network design and remarkable performance on large-scale labeled datasets. However, a critical limitation persists: these methods lack explicit illumination prior constraints tailored for illumination-reflection separation, a fundamental principle derived from Retinex theory that distinguishes between illumination components (responsible for global brightness distribution and environmental light effects) and reflection components (possessing object-specific attributes, such as intrinsic color, texture details, and structural information). Without such constraints, deep networks often fail to disentangle the two components during the enhancement process. For instance, when brightening dark regions to improve visibility, the model may mistakenly amplify inherent noise (e. g., sensor noise in low-light photography or compression artifacts) alongside proper signals, resulting in a grainy or noisy enhanced image. Similarly, the confusion between color information (part of the reflection component) and brightness fluctuations (part of the illumination component) frequently leads to color distortion. Common issues include an unnatural bluish tint in night scenes or an oversaturated warm tone in indoor low-light environments. Moreover, in pursuit of overall brightness balance, the network may over-smooth high-frequency texture details (e. g., fine lines in text, subtle patterns on fabrics, or edge contours of small objects), rendering the enhanced image visually blurry and lacking in clarity. These shortcomings become even increasingly pronounced in complex low-light scenarios that are close to real-world applications. For example, in scenes with local extreme darkness, such as shadowed areas under streetlights at night or dimly lit corners in indoor spaces, pure data-driven models tend to apply excessive brightness gains to dark pixels; such application of excessive brightness gains amplifies noise and causes local overexposure in adjacent regions with normal brightness. In cases involving color deviation (e. g., low-light images captured with incorrect white balance settings or under colored ambient-light-like neon signs), the model, without prior guidance on natural color distribution, may fail to correct the color shift and instead reinforce the distorted color palette. In addition, the poor generalization ability of these models poses a serious challenge: trained predominantly on specific low-light datasets (e. g., only outdoor night scenes or controlled indoor low-light environments), they struggle to adapt to unseen scenarios, such as low-light conditions in tunnels, rainy nights with light scattering, or backlit scenes with strong brightness contrast. This lack of adaptability makes it highly challenging to achieve balanced optimization across multiple key performance metrics, including brightness uniformity, noise suppression, detail preservation, and color fidelity. Simultaneously, it hinders the practical deployment of these methods in real-world systems, such as surveillance cameras, mobile phone photography, or autonomous driving vision modules. To address this problem, this study proposes a latent space decomposition method constrained by illumination priors; the method is referred to as prior-illumination-based latent space decomposition for low-light image enhancement (PrioLLIE). **Method** Specifically, we design a spatial prior fusion module, which combines the color information of RGB space and the brightness characteristics of the V channel in HSV space. This module extracts and fuses prior information to construct a robust illumination prior. Subsequently, we propose a latent vector extraction module that maps the image to the latent feature space for decoupled modeling of illumination components, with prior features being incorporated during the generation process. Then, we present a Retinex-driven cross-space decomposition module that accurately decomposes illumination components in the latent space while modeling reflection components in RGB space, thereby realizing complementary enhancement of content and illumination modeling. **Result** Qualitative and quantitative experiments on supervised datasets (i. e., low-light dataset (LOL) and single image contrast enhancer (SICE)) and an unsupervised dataset (i. e., different images collected from multiple cameras (DICM)) demonstrate that PrioLLIE achieves superior visual performance in terms of color restoration and contrast enhancement. It yields excellent quantitative results across the three datasets, particularly on SICE. PrioLLIE exhibits high performance in various metrics, including peak SNR, structural similarity index mea-

sure, learned perceptual image patch similarity, and DeltaE, further verifying the advanced capability of the proposed method. **Conclusion** Through the design concept of combining prior knowledge with data-driven learning, PrioLLIE overcomes the limitations of pure data-driven methods. It provides a technical approach for low-light image enhancement that balances physical rationality and visual quality. Furthermore, it offers a reference for integrating prior constraints and latent space modeling into other image degradation restoration tasks. Future research can further expand the types of priors (e. g., texture and noise priors) and explore the lightweight deployment of the model in real-time low-light video enhancement scenarios.

Key words: low-light image enhancement; reflection component; illumination component; prior constraint; latent feature

0 引言

低光照图像由于拍摄条件受限(如夜间、阴天或室内弱光环境),常面临噪声、对比度降低和运动模糊等不同程度的退化问题(Yu等,2025;张航和颜佳,2024),这些退化问题严重制约了图像的后续分析和实际应用。因此,越来越多的研究者关注于低光照图像的增强研究。当前,低光照图像增强技术主要分为传统方法(Zhang等,2022a,b,c)和深度学习方

法(Gao等,2025;孙婉倩等,2025)。
传统方法依赖于物理模型或图像统计特性,通过反演退化过程或调整像素值提升图像的颜色、亮度与对比度。在具体研究中,Guo等人(2017)提出的Retinex优化算法LIME(low-light image enhancement via illumination map estimation)、Huang和Chen(2014)设计的自适应Gamma对比度增强算法,以及Fu等人(2016)开发的自适应直方图算法,均是该领域内兼具代表性与影响力的经典方案。然而,这类方法在复杂场景下难以自适应地校正光照不均和抑制噪声等问题。不同于传统方法,深度学习方法能够学习大规模数据中的鲁棒特征(Guo等,2020;马龙等,2022),建立低质量图像与高质量图像的非线性映射关系,从而避免了照明估计不准、伪影生成及噪声放大等问题。如Lyu等人(2018)提出基于卷积神经网络(convolutional neural network,CNN)的多分支低光增强网络(multi-branch low-light enhancement network,MBLLEN),Ignatov等人(2017)和Chen等人(2018)提出的生成对抗网络(generative adversarial network,GAN)等是基于深度学习的经典方法。然而,大多数方法依赖地面真实图像或配对正常光图像(Hao等,2020)。而在实际应用中,真实的配对参考图像往往难以获取,且适用场景有限。此外,也有部分方法忽略了图像内容及退化机理等物理属性,

导致在恢复图像自然外观方面存在局限(Li等,2016,2021)。

为应对上述问题,本文在无配对低光图像的基础上引入Retinex分解,一种照明先验约束的潜在空间分解方法(prior-illumination-based latent space decomposition for low-light image enhancement,PrioLLIE)。首先,为了充分学习图像中的有效信息,本文在RGB和HSV空间中分别提取图像的特征先验,并将其融合到照明图的分解过程中,以校正颜色与亮度。其次,为减轻噪声与无关细节的干扰,在潜在空间中对照明分量进行分解,使关注点不仅局限于亮度调节,同时能够更好地适应不同的光照条件。图1展示了该方法的实验结果,它能够观察到本文方法对于多种退化的低光照图像都具有良好的增强性能。本文的主要贡献总结如下:1)提出了一个颜色先验预测模块(color prior prediction module, CPPM),融合RGB(red, green, blue)空间的颜色信息与HSV(hue, saturation, value)空间的亮度通道信息作为照明先验,用于增强低光照图像的光照约束,从而引导后续照明分量的稳定分解;2)提出了一个潜在空间映射模块(latent space mapping module, LSPM),将输入图像映射到潜在空间来提取照明信息,并将照明先验嵌入映射过程以获取更具判别性的特征表示;3)提出了一个Retinex照明和反射分解模块(illumination and reflection decomposition module, IRDM),




图1 PrioLLIE在不同光照条件下的增强效果
Fig. 1 Enhancement effects of PrioLLIE under different illumination conditions

分别获取低光和潜在特征为输入,从潜在特征和输入图像中分解出照明和反射分量,避免冗余的特征摄入所造成的资源浪费和过度增强。

1 相关工作

低光图像增强在计算机视觉领域具有重要的应用,其方法主要分为传统方法和深度学习方法(Guo等,2017)。

1.1 传统方法

传统的低光照图像增强方法依赖于物理模型或图像统计特性等提升图像的视觉质量(张卫东等,2025)。直方图均衡化通过全局调整灰度分布来提升对比度。Han等人(2011)在三维彩色空间中利用累计分布函数生成均匀直方图以增强亮度,但这类方法往往容易导致过增强,从而引入噪声或伪影。近年来,Retinex理论(Guo等,2017)受到广泛关注。该理论将图像分解为照明分量与反射分量,并通过均衡照明分量实现图像增强。在此基础上,Fu等人(2016)引入加权变分优化与先验约束,并采用交替最小化策略,有效抑制噪声。Li等人(2018)提出一种针对亮度和反射率的正则化项,并用Retinex估计图像噪声图。然而,Retinex模型假设照明在全局范围内平滑,这一前提在复杂或非均匀光照场景中往往不成立,因此单纯依赖Retinex难以获得鲁棒且自然的增强效果。

1.2 基于深度学习方法

深度学习方法得益于强有力的建模能力为低光照图像增强任务提供了新的解决思路(Li等,2022)。其中监督学习方法通过成对数据直接学习低光照图像到正常图像的映射。例如,Xiao等人(2025)在标准光照条件下训练语义先验预测器,自适应学习高质量图像中的语义先验特征。Wang等人(2019)提出吸收光散射模型(absorption-light scattering model, ALSM),结合最小通道约束与超像素分割,并引入反向大气光和均值-一标准差机制,实现低光照图像的细节恢复与自动调整。然而,监督学习对成对数据的高度依赖增加了实际应用难度。为减少标注数据需求,无监督学习方法受到广泛关注。与监督学习依赖“输入-输出”对不同,无监督学习仅以原始数据作为输入,目标是揭示数据的内在组织方式。Zhu等人(2025)提出光调节网络 Ghillie(ghost imag-

ing in the dark),通过光调制网络估计光分布,并利用鬼成像算法重构照度图像。Wu等人(2025)设计端到端网络 SIRNet(simplified inverse rendering model),借助具有隐式正则化的反向渲染模型纠正不均匀光照。Lyu和Hou(2024)提出深度补偿展开网络 DCUNet(deep compensation unfolding network),通过中间增强结果估计光照图,并在展开过程中生成新的增强结果,实现数据驱动的逆成像优化。但无监督学习这种“自主发现”缺乏明确的监督信号(如标签)引导,导致结果往往具有随机性和不确定性,难以精准契合人类预设的任务目标。所以,有规律的引导性增强在无监督学习中有望指导图像更好地恢复。

总体而言,现有的低光照图像增强方法虽然在一定程度上改善了图像质量,但仍存在增强效果有限、颜色偏差以及细节丢失等问题。为进一步提升图像质量,本文结合物理先验与深度学习潜在特征信息,对低光图像的结构、纹理和光照进行了更精细的增强处理。

2 本文方法

图2展示了PrioLLIE的流程图。该网络主要由色彩通道先验预测模块、潜在向量提取模块以及照明与反射分量分解模块构成。具体而言,首先在RGB与HSV空间中提取图像的特征先验;随后对输入图像进行编码,将其映射至潜在空间,以强化高层结构特征并抑制冗余噪声,同时将先验约束引入编码过程,使高层特征更加突出。接着,将输入图像与潜在特征一同输入分解网络,解耦得到照明分量与反射分量。最后,将反射分量的解码回图像空间,并与照明分量融合,生成高质量的增强图像。

2.1 颜色先验预测模块

在缺乏监督信息或真实标注的场景下,先验信息中蕴含的统计规律(如自然图像的纹理分布、颜色相关性)或物理知识(如光照传播模型、色彩空间特性),往往成为引导模型学习与推理的关键支撑。这类先验能够在一定程度上弥补数据量不足、标注质量低等问题,为复杂退化环境(如低光、雾天、噪声干扰)下的图像增强任务提供有效约束。尤其在低光图像增强中,由于暗部细节淹没、色彩信息失真,单纯依赖数据驱动模型易出现“亮度过度提升但色

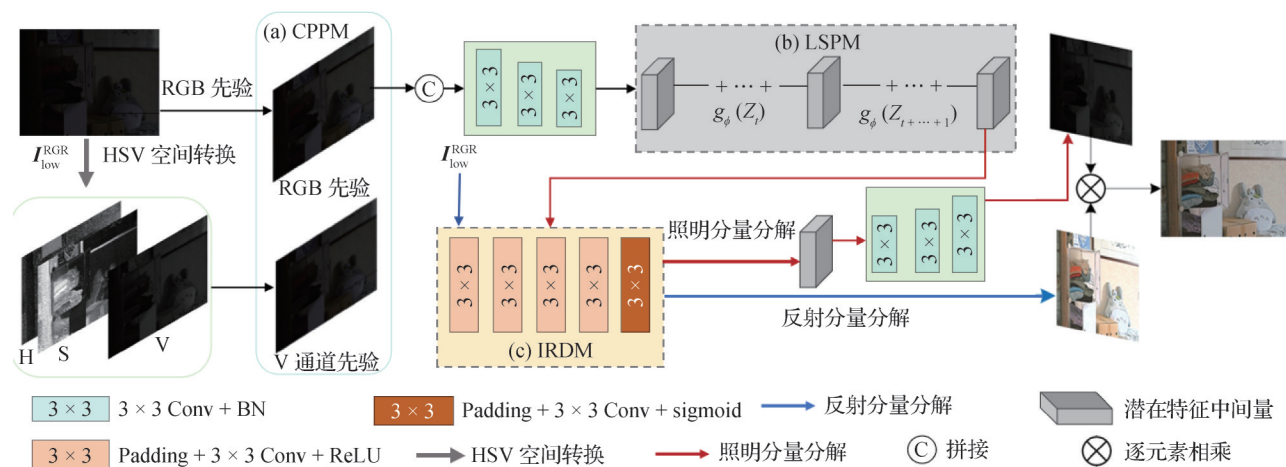


图2 PrioLLIE流程图

Fig. 2 Flowchart of PrioLLIE

彩偏移”、“暗部噪点放大”等问题,而合理的先验设计可精准规避这类缺陷。

基于自然图像的颜色分布特性(例如:自然场景中RGB三通道的像素值存在一定相关性,且HSV空间中亮度(V)与色相(H)、饱和度(S)的耦合性更低,更符合人眼对亮度与色彩的感知逻辑),本文设计了一种针对性的颜色先验预测模块。该模块并非直接使用原始图像的颜色信息,而是通过建模自然图像在不同光照条件下的潜在颜色分布规律(如低光环境下RGB通道的灰度值整体偏低但相对比例保持稳定,HSV空间中V通道的分布呈左偏特征),结合动态预测机制生成适配当前低光图像的颜色先验,进而有效提升网络在色彩偏差纠正(如低光导致的“偏蓝”、“偏灰”)与色彩失真修复(如暗部色彩信息丢失)方面的自适应能力。即使面对不同程度的低光退化(如弱光、极暗、局部光照不均),模型也能依据预测的颜色先验,动态调整色彩恢复策略,避免“一刀切”式增强导致的色彩不自然。

具体而言,该颜色先验在引导后续图像分解网络用于分离低光图像中的照明分量与反射分量时表现出明显优势,其实现流程如下:任意给出一幅低光图像 $I \in \mathbf{R}^{H \times W \times 3}$,先将该图像从RGB颜色空间转换至HSV颜色空间,得到对应的HSV三通道图像 $I_{HSV} = (I_H, I_S, I_V)$,并对原始RGB图像计算其灰度通道,确保灰度值能准确反映RGB空间的综合亮度信息。接着取HSV空间中的V通道 I_V 与RGB空间得到灰度通道均归一化至 $[0, 1]$ 范围以消除尺度差异,再通过“动态加权求和”进行融合。首先,根据人眼

视觉特性,生成亮度自适应分量 Y 和融合亮度基准 V_{fuse} 。具体为

$$\begin{aligned} H, S, V &= f_{HSV}^{RGB}(I) \\ Y &= aI_R + bI_G + cI_B \\ V_{fuse} &= \frac{mV_{hsv, norm}}{mV_{hsv, norm} + \sigma_Y} \cdot V_{hsv, norm} + \left(1 - \frac{mV_{hsv, norm}}{mV_{hsv, norm} + m_Y}\right) \cdot Y \end{aligned} \quad (1)$$

式中, H, S, V 分别表示色相、饱和度和亮度通道,通过 $f_{HSV}^{RGB}(\cdot)$ 将RGB空间映射到HSV空间。 a, b 和 c 分别表示归一化得到的自适应系数,可以表示为 $w_i = \frac{L_i}{\sum_{i=R, G, B} L_i}$,其中 $i \in R, G, B$ 。先计算图像的全局亮度均值,将像素值处于均值之上/下的区域定义为亮/暗区。 I_R, I_G 和 I_B 分别表示RGB中的三通道。 $mV_{hsv, norm}$ 是归一化HSV-V通道的标准差, m_Y 是RGB亮度分量 Y 的标准差。以 V_{fuse} 的全局均值为亮度指导,构建像素级自适应调整系数(暗区增益放大、亮区增益抑制),对RGB三通道进行协同缩放。具体为

$$\begin{aligned} V_{target} &= \min(\text{mean}(V_{fuse}) + \Delta V, 1.0) \\ n(i, j) &= \text{Clip}\left(\frac{V_{target}}{V_{fuse}(i, j) + p}, 0.5, 2.0\right) \end{aligned} \quad (2)$$

式中, V_{target} 表示目标亮度, ΔV 为亮度增益, $n(i, j)$ 表示像素级自适应调整系数, $\text{Clip}(\cdot)$ 表示裁剪函数,用于限制系数范围,防止过曝/过暗, $p = 10^{-8}$ 避免除零,得到自适应调整系数后进行RGB通道优化计算。具体为

$$R/G/B_{out} = \begin{cases} R/G/B_{in} \cdot n(i, j) & |r_{temp} - r_{ori}| \leq 0.1 \\ f_i(i, j) & |r_{temp} - r_{ori}| > 0.1 \end{cases} \quad (3)$$

式中, $R/G/B_{out}$ 表示优化后的三通道, $R/G/B_{in}$ 表示归一化的原始 RGB 通道, r_{ori} 表示原始色彩比, r_{temp} 表示调整后的色彩比。 $f_i(i, j)$ 为第 i 通道的像素级色彩比偏差校正, 偏差超过 0.1 时启用修正值。最后将优化后的 RGB 三通道与亮度 V 通道进行融合, 得到先验 P , 具体为

$$P = Cat(R_{out}, G_{out}, B_{out}, V_{in}) \in \mathbf{R}^{4 \times H \times W} \quad (4)$$

式中, $Cat(\cdot)$ 表示特征拼接操作, V_{in} 表示归一化的 HSV-V 通道。该先验既保留了 HSV-V 通道“纯净亮度”的优势, 又融入了 RGB 灰度通道的“色彩—亮度关联信息”, 为后续分解网络精准分离照明与反射分量、避免色彩失真提供了可靠约束。

2.2 潜在空间映射模块

深度学习的核心在于通过多层非线性变换, 从海量原始数据中自动学习具有判别性的特征, 并将高维、冗余的数据信息转化为更简洁、更本质的表示形式。而在这一过程中, 将数据从原始分布空间映射到更利于特征提取的目标分布空间, 例如将低光图像的暗部信息冗余、噪声密集分布, 映射到亮度均衡、细节清晰的目标分布, 能够显著降低特征学习的难度, 让模型更高效地聚焦于数据的核心规律。

为进一步获得精准、鲁棒的特征表示, 研究者通常引入潜在空间(latent space)(Zheng 等, 2021)作为特征学习的核心载体: 潜在空间是一个抽象的低维特征空间, 其每个维度对应数据的一种潜在语义或结构属性(如图像的亮度强度、色彩饱和度、纹理复杂度), 相较于高维原始像素空间, 潜在空间能更直观地刻画数据的本质特征, 且有效避免原始空间中像素间的冗余关联与噪声干扰。潜在空间映射常见的方法是利用自动编码器, 通过“编码—解码”机制实现像素空间与潜在空间的双向映射, 其核心思想是基于确定性映射。在编码阶段, 编码器通过卷积、激活函数等操作, 将输入图像 I 映射为低维潜在特征 $z \in \mathbf{R}^d (d \leq HWC)$, 该过程定义为

$$z = f_{\theta}(x) = \sigma(W_n \cdot \sigma(W_{n-1} \cdots \sigma(W_1 x + b_1) + \cdots + b_{n-1}) + b_n) \quad (5)$$

式中, f_{θ} 是编码器函数(参数为 $\theta =$

$\{W_1, \dots, W_n, b_1, \dots, b_n\}$), W_i, b_i 分别是卷积/全连接层的权重和偏置。 $\sigma(\cdot)$ 是激活函数, 引入非线性映射能力。在解码阶段, 解码器通过反卷积、上采样等操作, 将潜在特征 z 重构为增强图像 \hat{x} 的表达为

$$\hat{x} = g_{\phi}(z) = \sigma'(V_m \cdot \sigma'(V_{m-1} \cdots \sigma'(V_1 z + c_1) + \cdots + c_{m-1}) + c_m) \quad (6)$$

式中, g_{ϕ} 是解码器函数(参数为 $\phi = \{V_1, \dots, V_m, c_1, \dots, c_m\}$), V 为解码器的权重矩阵, c_i 为偏置向量, $\sigma'(\cdot)$ 为激活函数。然而, 仅依赖潜在空间的直接映射难以充分刻画复杂退化条件下的图像特性, 尤其是在低照度与颜色失真场景中。基于此, 本文在潜在空间建模的基础上引入先验知识约束, 设计了先验引导的潜在空间映射模块(LSPM), 通过二者协同作用实现更稳健的特征表达与增强效果。为了压缩数据, 本文将输入图像 I 通过编码器 E 映射到潜在空间特征 Z , 并引入先验 P , 首先, 将输入图像 I 与先验 P 在分解的输入阶段融合, 即

$$F_1 = ReLU(Conv_3(Cat(I, P)) + g_1) \quad (7)$$

式中, F_1 表示融合了先验信息的输出结果, $ReLU(\cdot)$ 表示 $ReLU$ (rectified linear unit)激活函数, $Conv_3(\cdot)$ 表示 3×3 卷积, $Cat(\cdot)$ 表示拼接, g_1, g_2, g_3 是偏置项。 F_1 同时包含图像的原始视觉信息和照明先验(如亮度基准、色彩比值), 为后续映射奠定基础。接着将 P 映射到与 F_1 同尺度并进行深度交互。具体为

$$F_2 = ReLU(Conv_3(F_1 \odot P) + g_2) \quad (8)$$

式中, \odot 表示逐元素相乘, 强化先验与图像特征的局部关联。最后, 融合全局 + 局部 + 先验特征得到高维特征图 Z_{input} 。具体为

$$Z_{input} = Conv_3(F_2) + g_3 \quad (9)$$

生成的 Z_{input} 直接进行潜在空间分解, 该表达为

$$Z = E(Z_{input}) = \sigma(W_n \cdot \sigma(W_{n-1} \cdots \sigma(W_1(Z_{input}) + b_1) + \cdots + b_{n-1}) + b_n) \quad (10)$$

结合输入图像和融合先验, 潜在特征 Z 不仅剔除了原始图像的冗余信息与噪声, 还蕴含了图像的本质结构与语义属性, 为后续的解码重构或特征优化奠定基础。

2.3 照明和反射分量分解模块

根据 Retinex 理论, 照明分量刻画图像的光照条件与分布, 反射分量则反映物体的固有颜色和纹理。传统 Retinex 分解方法(如基于变分模型、高斯滤波的方法)多在像素空间直接进行分解, 受限于单一空间的特征表达能力, 在复杂退化场景(如低光叠加噪声、局部过曝、色彩失真)中, 难以实现照明分量 L 与反射分量 R 的彻底解耦, 易出现两类关键问题: 一是照明分量混入纹理细节; 二是反射分量受亮度干扰。为此, 本文突破传统像素空间单一分解的局限, 提出“潜在空间—像素空间联合分解”策略。将潜在空间的低维特征与输入图像联合分解, 在不同特征域分别估计照明与反射分量, 从而在保证照明分布平滑性的同时, 有效保留反射分量中的细节和颜色信息。

低光照增强中的 Retinex 分解思想, 正是通过分离这两类信息, 实现对图像亮度的有效提升和细节的自然保留。Retinex 分解思想表达为

$$I = R \cdot L \quad (11)$$

式中, I 表示输入图像, R 表示反射分量(反映物体本身的颜色/纹理), L 表示照明分量(光照强弱分布)。本文将潜在特征 Z 和输入图像 I_{low} 送入一个由简单卷积组成的分解器(Fu 等, 2023), 分别解耦反射和照明分量, 照明和反射分量分解网络是具有独立参数的相同结构, 主体由 5 层 3×3 的卷积层构成, 其中反射分解网络的输入为不同尺度的卷积拼接得到的多尺度特征, 照明分解网络的输入为潜在特征 Z , 最后经过一个 5×5 卷积层得到两个分量。具体过程可表示为

$$\begin{aligned} \hat{R} = & \sigma(\text{Conv}_5(\text{Conv}_3(\text{Conv}_1(\text{Cat}(\text{Conv}_5(I_{\text{low}})\text{Conv}_3(I_{\text{low}})))))) \\ \hat{L} = & \sigma(\text{Conv}_5(\text{Conv}_3(\text{Conv}_3(Z)))) \end{aligned} \quad (12)$$

式中, \hat{R} 和 \hat{L} 分别表示反射和照明分量, $\text{Conv}_5(\cdot)$ 和 $\text{Conv}_3(\cdot)$ 分别表示卷积核为 5×5 和 3×3 的卷积。最后, 将 \hat{R} 和 \hat{L} 相乘得到增强图像 \hat{X} 定义为

$$\hat{X} = \hat{L} \cdot \hat{R} \quad (13)$$

这种先分解后重构的逻辑, 从物理层面保证了增强效果的合理性, 避免了直接对像素值调整导致的细节丢失或色彩失真问题。

2.4 损失函数

为更充分地发挥模型性能, 在训练过程中引入

了 3 类损失函数, 以共同提升模型的准确性与鲁棒性, 分别为均方误差损失、重建损失和光照约束损失。

2.4.1 均方误差损失

采用均方误差损失来约束网络输出(即注意力机制的结果)与输入图像之间的像素级一致性, 从而保证关键特征的准确保留。预测损失可表示为

$$L_p = \frac{1}{N} \|\text{im}_1^i - X_1^i\|^2 \quad (14)$$

式中, im_1 表示融合先验约束的输出图像, 其输入图像 X_1 进行像素级的对比, $i = 1, 2, \dots, N$, 表示输入图像的像素数。用均方误差(mean squared error, MSE)衡量预测的增强图像与参考图像之间的像素差异, 确保生成图像与目标一致。

2.4.2 重建损失

引入重建损失, 将光照分量与反射分量进行联合约束, 以确保分解结果的合理性, 并有效减轻伪影和噪声的影响。该损失可表示为

$$L_{\text{recon}} = \frac{1}{N} \sum_{i=1}^N \left(\left\| L_1^i \cdot R_1^i - X_1^i \right\|^2 + \left\| R_1^i - \frac{X_1^i}{L_1^i} \right\|^2 \right) \quad (15)$$

式中, $L_1 \cdot R_1$ 表示光照分量和反射分量的组合, 应该与参考图像一致。 X_1/L_1 表示由光照分量分解得到的理想反射分量, 与网络输出的反射分量对齐。

2.4.3 光照约束损失

为了保证光照分量与输入图像的亮度保持一致, 引入光照约束损失, 对光照信息约束。该损失函数可表示为

$$L_{\text{ill}} = \frac{1}{N} \sum_{i=1}^N \left\| L_1^i - C_{\text{max}^{(i)}} \right\|^2 + TV(L_1) \quad (16)$$

式中, $C_{\text{max}^{(i)}}$ 表示输入图像在每个像素的最大通道值, $TV(L_1)$ 表示总变分损失, 在这里本文引入它对光照分量进行细微修改, 平滑照明分量。

最终, 总损失由均方误差损失、重建损失、光照约束损失构成, 总损失表示为

$$L_{\text{total}} = W_p L_p + W_{\text{recon}} L_{\text{recon}} + W_{\text{ill}} L_{\text{ill}} \quad (17)$$

式中, W_p 、 W_{recon} 和 W_{ill} 分别为 3 个损失权重, 为了更好地训练模型, 分别设置为 20、1 和 1。

3 实验结果与分析

本节介绍实验使用的数据集及网络参数, 并讨

论 PrioLLIE 在 LOL、SICE 和 DICM 3 个标准数据集上的定性与定量结果。此外,消融实验验证 PrioLLIE 各个模块的有效性。

3.1 实验数据和细节

使用 SICE (single image contrast enhancer) 和 LOL (low-light dataset) 数据集对网络模型进行训练。在两个数据集中,本文随机挑选 350 个低光序列,每个序列包含 3~5 幅低光图像,总计约 1 000 幅图像。训练时的输入图像分辨率为 128×128 像素。此外,使用 LOL 数据集的标准测试集中的 15 幅低光图像,以及在 SICE 数据集中随机挑选的 50 组低光图像(共 150 幅)进行测试。在定量比较中,在 LOL 和 SICE 数据集上采用峰值信噪比(peak signal-to-noise ratio, PSNR)、结构相似性(structural similarity index measure, SSIM)、学习式感知图像块相似度(learned perceptual image patch similarity, LPIPS)和 DeltaE 指标评估方法性能。在 DICM (different images collected from multiple cameras) 数据集上采用(information entropy, IE)和 NIQE (natural image quality evaluator) 和 PI (perceptual index) 进行评估。PrioLLIE 的训练在 Windows 11 PC 上进行,使用 Intel (R) XEON (R) Gold 5218 CPU 和 NVIDIA GeForce RTX 3090 GPU,并基于 PyTorch 框架执行。训练过程中,学习率设置为 1×10^{-3} ,批次大小为 6,训练共进行 200 个阶段。

3.2 对比实验

将 PrioLLIE 与 10 种深度学习方法在 LOL、SICE 和 DICM 数据集进行定性定量比较。包括:SCLM (single convolutional layer model) (Zhang 等, 2024b)、

RUAS (Retinex-inspired unrolling with cooperative prior architecture search) (Liu 等, 2021a)、SCI (self-calibrator) (Ma 等, 2025)、CSPN (category-specific processing network) (Wu 等, 2024)、URetinex (Wu 等, 2022)、PairLIE (Fu 等, 2023)、StableLLVE (Zhang 等, 2021)、Zero-DCE (zero-reference deep curve estimation) (Guo 等, 2020)、Zero-DCE++ (Li 等, 2022) 和 RetinexNet (Chen 等, 2018)。

3.2.1 定性比较

图 3 展示了不同方法在各数据集上的视觉效果。LOL 数据集包含室内弱光、夜景等低光场景,对低光图像增强方法的性能提出了较高要求。本次测试选取了室内弱光条件下的图像。

如图 3 第 1 行所示,在 LOL 数据集上,SCLM 和 StableLLVE 过度曝光,导致细节丢失;RUAS 在增强过程中产生颜色偏差,且亮度提升不足,影响整体视觉效果;SCI、CSPN 和 Zero-DCE++ 虽然在细节保留方面表现较好,但在较暗区域的亮度增强仍不足,部分细节未能完全呈现;PairLIE 虽然亮度增强效果明显,但同时引入了较多噪声。

SICE 数据集通过多曝光拍摄获取图像,每组图像可反映场景在不同亮度下的表现。本文选取光照相对均匀的图像,对各方法的增强效果进行测试。如图 3 第 2 行所示,在 SICE 数据集上,SCLM 和 StableLLVE 出现过度曝光,细节难以呈现。SCI、CSPN 和 Zero-DCE 在亮度增强方面不足,且存在较明显的颜色偏差,整体视觉效果不理想。PairLIE 虽然整体增强效果较好,但部分区域出现过度增强,细节恢复不足。

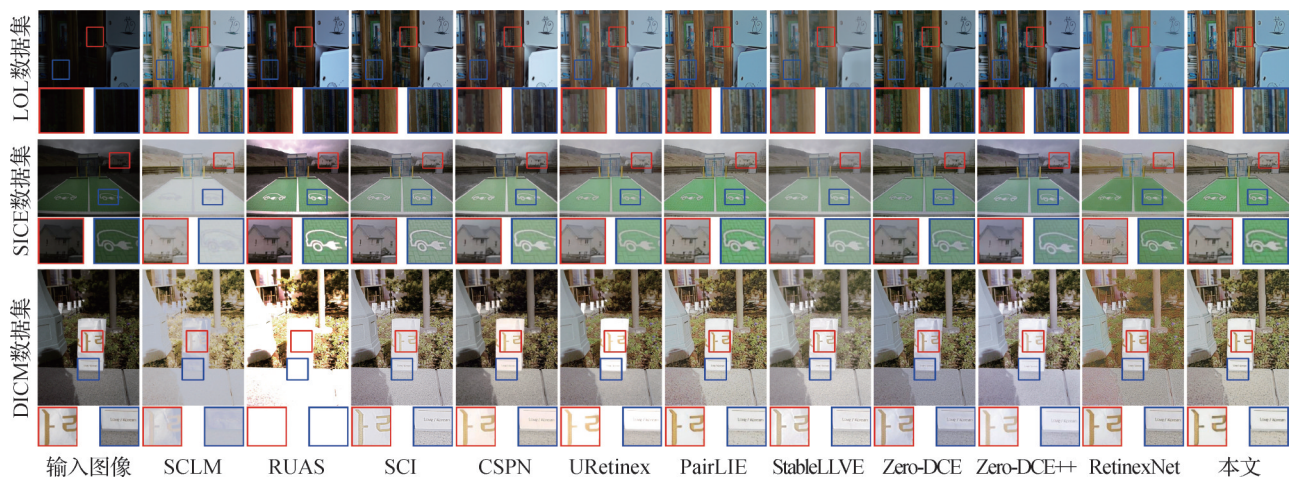


图3 不同方法在不同数据集上的定性测试

Fig. 3 Qualitative tests of different methods on different datasets

DICM数据集常用于无参考评估,便于测试增强方法在低光和阴影区域的表现。如图3第3行所示,在DICM数据集上,SCLM和RUAS由于过度曝光导致细节丢失。SCI和StableLLVE在颜色校正方面表现不佳。CSPN和PairLIE则存在细节模糊的问题。相比之下,PrioLLIE在不同场景下均表现出色,能够有效恢复颜色并增强细节。

图4展示了不同极端环境下各方法的增强效果对比,部分对比方法未能有效还原图像的亮度水平与真实色彩,存在亮度失衡或色彩失真问题。实验结果表明,所提PrioLLIE方法能够自适应不同环境

的退化特性,在极端场景下仍保持稳定的增强性能,充分体现了其优异的鲁棒性。

3.2.2 定量比较

表1给出了PrioLLIE在LOL、SICE和DICM数据集上的定量结果,并与10种方法进行了对比,PrioLLIE在3个数据集上几乎均取得最优表现,尤其在SICE数据集上,其在PSNR、SSIM、LPIPS和DeltaE 4个指标上均达最佳。这表明结合物理先验与多维特征协同有助于提升图像质量,验证了PrioLLIE在低光照图像增强中的性能。表2给出了每种方法的参数信息。




图4 不同方法在极端环境下的性能对比

Fig. 4 Performance comparison of different methods under extreme environments

表1 在LOL、SICE和DICM数据集的定量比较

Table 1 Quantitative comparison on the LOL, SICE, and DICM datasets

| 方法 | LOL | | | | SICE | | | | DICM | | |
|--------------|-----------------|----------------|----------------|----------------|-----------------|----------------|----------------|----------------|--------------|--------------|-------------|
| | PSNR/dB ↑ | SSIM ↑ | LPIPS ↓ | DeltaE ↓ | PSNR/dB ↑ | SSIM ↑ | LPIPS ↓ | DeltaE ↓ | IE ↑ | NIQE ↓ | PI ↓ |
| SCLM | 18.807 6 | 0.630 3 | 0.333 2 | 17.223 9 | 18.486 4 | 0.771 4 | 0.312 5 | 13.809 8 | 6.394 | 3.760 | 6.17 |
| RUAS | 16.401 2 | 0.500 9 | 0.270 1 | 19.638 5 | 12.987 9 | 0.670 3 | 0.535 0 | 25.605 2 | 5.270 | 4.783 | 7.19 |
| SCI | 13.806 3 | 0.526 1 | 0.358 4 | 26.221 9 | 17.597 6 | 0.783 8 | 0.485 6 | 16.151 0 | 6.764 | 4.111 | 5.85 |
| CSPN | 19.607 2 | <u>0.755 8</u> | 0.216 8 | <u>9.101 0</u> | 18.612 0 | 0.821 7 | 0.234 6 | 13.724 8 | 7.168 | 3.879 | 5.49 |
| URetinex | 19.841 9 | 0.825 9 | 0.128 1 | 13.943 7 | 21.651 9 | <u>0.844 4</u> | 0.465 3 | 9.687 4 | 7.002 | 4.023 | 5.52 |
| PairLIE | 19.510 6 | 0.736 4 | 0.248 0 | 9.560 0 | 21.333 2 | 0.843 1 | <u>0.227 2</u> | <u>9.407 4</u> | 6.964 | 4.048 | <u>5.31</u> |
| StableLLVE | 17.363 8 | 0.739 8 | 0.283 9 | 17.928 4 | 19.643 4 | 0.789 4 | 0.272 4 | 12.366 9 | 6.878 | 3.963 | 6.76 |
| Zero-DCE | 14.860 7 | 0.558 8 | 0.335 2 | 22.213 7 | 18.691 8 | 0.810 5 | 0.265 4 | 14.120 0 | 7.030 | <u>3.546</u> | 5.95 |
| Zero-DCE++ | 14.681 9 | 0.472 0 | 0.329 2 | 24.416 0 | 16.092 0 | 0.511 4 | 0.339 3 | 19.850 6 | 7.190 | 3.570 | 5.60 |
| RetinexNet | 17.557 7 | 0.719 1 | 0.000 4 | 16.415 3 | 19.896 7 | 0.786 2 | 0.273 3 | 10.643 1 | 6.941 | 4.136 | 6.98 |
| PrioLLIE(本文) | <u>19.771 4</u> | 0.745 5 | 0.202 1 | 9.021 7 | <u>21.489 5</u> | 0.848 0 | 0.212 1 | 9.007 9 | <u>7.178</u> | 3.491 | 5.27 |

注:加粗、下划线字体表示各列最优、次优结果,↑表示向上取最优,↓表示向下取最优。

3.3 消融实验

本文使用不同的实验设置在SICE数据集上进行消融实验,以验证每个模块的作用。本文在原始的方法上进行了几种变换:1)无颜色先验预测模块

(-w/o CPPM);2)无潜在空间映射模块(-w/o LSPM);3)无照明和反射分解模块(-w/o IRDM);4)全模型(PrioLLIE)。如图5所示,去掉CPPM(-w/o CPPM)会导致细节过度锐化,难以还原真实颜色;去掉LSPM

表2 不同方法的模型参数量、计算量和推理时间对比

Table 2 Comparison of model parameters, computational complexity, and inference latency across different methods

| 方法 | Params/M | FLOPs/G | 时间/s |
|--------------|-------------|-------------|-------------|
| SCLM | 0.01 | 0.01 | 7.46 |
| RUAS | 0.01 | 0.28 | 23.81 |
| SCI | 0.01 | 0.03 | 23.19 |
| CSPN | 0.41 | 1.24 | 20.10 |
| URetinex | 0.01 | 227.73 | 48.05 |
| PairLIE | 0.34 | 5.59 | 10.49 |
| StableLLVE | 4.32 | 40.29 | 0.06 |
| Zero-DCE | 0.08 | 5.19 | 3.25 |
| Zero-DCE++ | 0.01 | 2.64 | 4.17 |
| RetinexNet | 0.83 | 136.01 | 40.14 |
| PrioLLIE(本文) | 3.93 | 45.53 | 13.55 |

注:加粗字体表示各列最优结果。



图5 不同消融设置下的消融实验视觉效果对比

Fig. 5 Visual effect comparison of ablation experiments under different ablation settings

(-w/o LSPM)虽然在整体视觉较好,但产生了非均匀色彩;去掉 IRDM(-w/o IRDM)未能有效提升亮度。相比之下,PrioLLIE 不仅提升了亮度,还能保持真实色彩,更符合人眼视觉感受。

表3为在SICE数据集上的消融实验定量分析。表3中,在SICE数据集上的定量评估显示,PrioLLIE

表3 在SICE数据集的消融实验定量分析

Table 3 Quantitative analysis of ablation experiments on the SICE dataset

| 方法 | PSNR/dB ↑ | SSIM ↑ | LPIPS ↓ | DeltaE ↓ |
|--------------|-----------------|----------------|----------------|----------------|
| -w/o CPPM | 21.324 2 | 0.834 9 | 0.220 8 | 9.752 0 |
| -w/o LSPM | 21.219 6 | 0.833 1 | 0.227 4 | 9.766 6 |
| -w/o IRDM | 19.578 5 | 0.653 2 | 0.365 5 | 14.172 1 |
| PrioLLIE(本文) | 21.489 5 | 0.848 0 | 0.212 1 | 9.007 9 |

注:加粗字体表示各列最优结果,↑表示向上取最优,↓表示向下取最优。

在PSNR、SSIM、LPIPS和DeltaE上均取得最佳得分,有效验证了PrioLLIE的性能和各模块的关键作用,进一步表明了各个模块对全模型PrioLLIE都具有积极作用。

4 结论

本文提出了一种基于照明先验的低光照图像特征分解网络。该网络在RGB和HSV空间中提取照明先验信息,并将其引入到潜在空间映射过程,有效缓解了仅依赖像素域特征时易出现的模糊与不稳定问题。在潜在空间中,该网络能够对照明分量分解,更好地反映场景的整体亮度分布。通过重分解与融合,PrioLLIE不仅实现了亮度增强和细节恢复,还在抑制噪声与颜色失真方面表现出良好效果。在定性定量对比分析中,本文方法在多个数据集上能够取得较好的视觉效果和测量指标。尽管PrioLLIE方法具有良好视觉效果,但在LOL数据集的量化指标略显不足,其原因可能是训练阶段的数据不足,未来将增加样本的多样性和丰富性,并关注网络结构的轻量化设计,在保证增强效果的同时提升模型在复杂场景下的泛化能力。

参考文献(References)

- Chen Y S, Wang Y C, Kao M H and Chuang Y Y. 2018. Deep photo enhancer: unpaired learning for image enhancement from photographs with GANs//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Salt Lake, USA: IEEE: 6306-6314 [DOI: 10.1109/CVPR.2018.00660]
- Fu X Y, Zeng D L, Huang Y, Zhang X P and Ding X H. 2016. A weighted variational model for simultaneous reflectance and illumination estimation//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). LasVegas, USA: IEEE: 2782-2790 [DOI: 10.1109/CVPR.2016.304]
- Fu Z Q, Yang Y, Tu X T, Huang Y, Ding X H and Ma K K. 2023. Learning a simple low-light image enhancer from paired low-light instances//Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE: 22252-22261 [DOI: 10.1109/CVPR52729.2023.02131]
- Gao X Y, Zhang W B, Zhuang P X, Zhao W Y and Zhang W D. 2025. RDANet: Retinex decomposition attention network for low-light image enhancement. Pattern Recognition Letters, 197: 175-181 [DOI: 10.1016/j.patrec.2025.07.026]
- Guo C L, Li C Y, Guo J C, Loy C C, Hou J H, Kwong S, et al. 2020.

- Zero-reference deep curve estimation for low-light image enhancement//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, USA: IEEE: 1777-1786 [DOI: 10.1109/CVPR42600.2020.00185]
- Guo X J, Li Y and Ling H B. 2017. LIME: low-light image enhancement via illumination map estimation. *IEEE Transactions on Image Processing*, 26(2): 982-993 [DOI: 10.1109/TIP.2016.2639450]
- Han J H, Yang S and Lee B U. 2011. A novel 3-D color histogram equalization method with uniform 1-D gray scale histogram. *IEEE Transactions on Image Processing*, 20(2): 506-512 [DOI: 10.1109/TIP.2010.2068555]
- Hao S J, Han X, Guo Y R, Xu X and Wang M. 2020. Low-light image enhancement with semi-decoupled decomposition. *IEEE Transactions on Multimedia*, 22(12): 3025-3038 [DOI: 10.1109/TMM.2020.2969790]
- Huang S C and Chen W C. 2014. A new hardware-efficient algorithm and reconfigurable architecture for image contrast enhancement. *IEEE Transactions on Image Processing*, 23(10): 4426-4437 [DOI: 10.1109/TIP.2014.2348869]
- Ignatov A, Kobyshev N, Timofte R and Vanhoey K. 2017. DSLR-quality photos on mobile devices with deep convolutional networks//Proceedings of 2017 IEEE International Conference on Computer Vision (ICCV). Venice, Italy: IEEE: 3297-3305 [DOI: 10.1109/ICCV.2017.355]
- Li C Y, Anwar S, Hou J H, Cong R M, Guo C L and Ren W Q. 2021. Underwater image enhancement via medium transmission-guided multi-color space embedding. *IEEE Transactions on Image Processing*, 30: 4985-5000 [DOI: 10.1109/TIP.2021.3076367]
- Li C Y, Guo J C, Cong R M, Pang Y W and Wang B. 2016. Underwater image enhancement by dehazing with minimum information loss and histogram distribution prior. *IEEE Transactions on Image Processing*, 25(12): 5664-5677 [DOI: 10.1109/TIP.2016.2612882]
- Li C Y, Guo C L and Loy C C. 2022. Learning to enhance low-light image via zero-reference deep curve estimation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(8): 4225-4238 [DOI: 10.1109/TPAMI.2021.3063604]
- Li M D, Liu J Y, Yang W H, Sun X Y and Guo Z M. 2018. Structure-revealing low-light image enhancement via robust Retinex model. *IEEE Transactions on Image Processing*, 27(6): 2828-2841 [DOI: 10.1109/TIP.2018.2810539]
- Liu R S, Ma L, Zhang J A, Fan X and Luo Z X. 2021a. Retinex-inspired unrolling with cooperative prior architecture search for low-light image enhancement//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE: 10556-10565 [DOI: 10.1109/CVPR46437.2021.01042]
- Lyu F F, Lu F, Wu J H and Lim C S. 2018. MBLLN: low-light image/video enhancement using CNNs//Proceedings of 2018 British Machine Vision Conference (BMVC). Northumbria, UK: [s.n.]: #4 [DOI: BMVC 2018: 220]
- Lyu X Q and Hou J H. 2024. Enhancing low-light light field images with a deep compensation unfolding network. *IEEE Transactions on Image Processing*, 33: 4131-4144 [DOI: 10.1109/TIP.2024.3420797]
- Ma L, Ma T Y and Liu R S. 2022. The review of low-light image enhancement. *Journal of Image and Graphics*, 27(5): 1392-1409 (马龙, 马腾宇, 刘日升. 2022. 低光照图像增强算法综述. *中国图象图形学报*, 27(5): 1392-1409 [DOI: 10.11834/jig.210852])
- Ma L, Ma T Y, Xu C P, Liu J Y, Fan X, Luo Z X, et al. 2025. Learning with self-calibrator for fast and robust low-light image enhancement. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 47(10): 9095-9112 [DOI: 10.1109/TPAMI.2025.3586712]
- Sun W Q, Peng C Y and Zhang X J. 2026. A low-light image enhancement network via fused multi-scale dilated convolutions and coordinate grouping. *Journal of Image and Graphics*, 31(2): 448-464. (孙婉倩, 彭春燕, 张效娟. 2025. 融合多重空洞卷积与坐标分组的暗光图像增强网络. *中国图象图形学报*, 31(2): 448-464 [DOI: 10.11834/jig.250177])
- Wang Y F, Liu H M and Fu Z W. 2019. Low-light image enhancement via the absorption light scattering model. *IEEE Transactions on Image Processing*, 28(11): 5679-5690 [DOI: 10.1109/TIP.2019.2922106]
- Wu H J, Wang C X, Tu L W, Patsch C and Jin Z. 2024. CSPN: a category-specific processing network for low-light image enhancement//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE: 5891-5900 [DOI: 10.1109/CVPR46437.2021.01042]
- Wu W H, Weng J, Zhang P P, Wang X, Yang W H and Jiang J M. 2022. URetinex-Net: Retinex-based deep unfolding network for low-light image enhancement. *IEEE Transactions on Circuits and Systems for Video Technology*, 35(10): 9608-9622 [DOI: 10.1109/CVPR52688.2022.00581]
- Wu W H, Pang J, Gao S B, Zhang P P, Chen Z and Qiu G P. 2025. Low-light image enhancement through learning a simplified inverse rendering model. *IEEE Transactions on Circuits and Systems for Video Technology*, 35(10): 9608-9622 [DOI: 10.1109/TCSVT.2025.3562423]
- Xiao Q Q, Jin H Y, Su H N and Yan R X. 2025. SELL: a method for low-light image enhancement by predicting semantic priors. *IEEE Signal Processing Letters*, 32: 1785-1789 [DOI: 10.1109/LSP.2025.3562822]
- Yu B Q, Zhou L, Yu W Q, Zhuang P X and Zhang W D. 2025. Underwater image color correction via global and local two-step optimization. *Pattern Recognition Letters*, 196: 38-44 [DOI: 10.1016/j.patrec.2025.05.007]
- Zhang F, Li Y, You S D and Fu Y. 2021. Learning temporal consistency for low light video enhancement from single images//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE: 4965-4974 [DOI: 10.1109/

- CVPR46437.2021.00493]
- Zhang H and Yan J. 2024. Low-light image enhancement guided by semantic segmentation and HSV color space. *Journal of Image and Graphics*, 29(4): 966-977 (张航, 颜佳. 2024. 语义分割和 HSV 色彩空间引导的低光照图像增强. *中国图象图形学报*, 29(4): 966-977) [DOI: 10.11834/jig.230182]
- Zhang W D, Dong L L and Xu W H. 2022a. Retinex-inspired color correction and detail preserved fusion for underwater image enhancement. *Computers and Electronics in Agriculture*, 192: #106585 [DOI: 10.1016/j.compag.2021.106585]
- Zhang W D, Wang Y D and Li C Y. 2022b. Underwater image enhancement by attenuated color channel correction and detail preserved contrast enhancement. *IEEE Journal of Oceanic Engineering*, 47(3): 718-735 [DOI: 10.1109/JOE.2022.3140563]
- Zhang W D, Wang Z, Hao Z B and Gao X Y. 2025. Marine species image enhancement method based on box-cox transform. *Journal of Naval Aviation University*, 40(4): 600-606, 640 (张卫东, 王中, 郝志斌, 高兴运. 2025. 基于 Box-Cox 变换的海洋物种图像增强方法. *海军航空大学学报*, 40(4): 600-606, 640) [DOI: 10.7682/j.issn.2097-1427.2025.04.010]
- Zhang W D, Zhou L, Zhuang P X, Li G H, Pan X P, Zhao W Y, et al. 2024a. Underwater image enhancement via weighted wavelet visual perception fusion. *IEEE Transactions on Circuits and Systems for Video Technology*, 34(4): 2469-2483 [DOI: 10.1109/TCSVT.2023.3299314]
- Zhang W D, Zhuang P X, Sun H H, Li G H, Kwong S and Li C Y. 2022c. Underwater image enhancement via minimal color loss and locally adaptive contrast enhancement. *IEEE Transactions on Image Processing*, 31: 3997-4010 [DOI: 10.1109/TIP.2022.3177129]
- Zhang Y T, Teng B X, Yang D Q, Chen Z Z, Ma H C, Li G, et al. 2024b. Learning a single convolutional layer model for low light image enhancement. *IEEE Transactions on Circuits and Systems for Video Technology*, 34(7): 5995-6008 [DOI: 10.1109/TCSVT.2023.3343696]
- Zheng M, Wang W and Li Q Y. 2021. Fine-grained image-text retrieval via discriminative latent space learning. *IEEE Signal Processing Letters*, 28: 643-647 [DOI: 10.1109/LSP.2021.3065595]
- Zhu Z J, Yang X G, Lu R T, Shen T, Zhang T and Wang S Y. 2025. Ghost imaging in the dark: a multi-illumination estimation network for low-light image enhancement. *IEEE Transactions on Circuits and Systems for Video Technology*, 35(2): 1576-1590 [DOI: 10.1109/TCSVT.2024.3472278]

作者简介

张卫东,男,副教授,硕士生导师,主要研究方向为图像增强和深度学习。E-mail: zwd_wd@163.com

赵文义,通信作者,男,副研究员,硕士生导师,主要研究方向为深度学习和视觉感知。E-mail: zwy@bupt.edu.cn

高兴运,男,硕士研究生,主要研究方向为计算机视觉与深度学习。E-mail: gaopingyun012024@163.com

周玲,女,讲师,主要研究方向为视觉图像处理。

E-mail: 1026160568@qq.com

路皓翔,男,博士后,硕士生导师,主要研究方向为深度学习和图像处理。E-mail: hxlu1005@163.com