arXiv:2304.02978v2 [cs.CV] 4 Aug 2023

使用相对损失函数简化低照度图像增强网络

Yu Zhang[1], Xiaoguang Di[1*],Junde 吴[2], YueWang[1], YongLi[1], RaoFu[3], Yanwu Xu[2], Guohui Yang[1] 和 Chunhui Wang[1*]

[1*]哈尔滨工业大学，中国哈尔滨，150001。[2]华南理工大学，中国广州，510000。[3]Mind VogueLab，中国北京，100000。

*通讯作者。电子邮箱：dixiaoguang@hit.edu.cn；wang2352@hit.edu.cn；贡献作者：zhangyuhit2@hit.edu.cn；jundewu@ieee.org；seraph@hit.edu.cn；522384058@qq.com；1098712828@qq.com；ywxu@ieee.org；gh.yang@hit.edu.cn；

摘要

图像增强是一种常见技术，用于缓解低光照图像中噪声严重、亮度低、对比度低和色彩偏差等问题。然而，对于低照度图像增强任务而言，不可能提供一张理想的高光照图像作为参考，这使得其学习过程比其他图像处理任务更加困难。因此，尽管已有多种低照度图像增强方法被提出，但其中大多数要么过于复杂，要么无法充分解决低光照图像中的所有问题。本文为简化低照度图像增强的学习过程，提出了FLW-Net（快速轻量级网络）和两个相对损失函数。具体而言，我们首先指出了该任务面临的挑战：需要较大的感受野来获取全局对比度，且缺乏绝对参考，这限制了网络结构的简化。随后，我们提出了一种高效的全局特征信息提取组件，以及两个基于相对信息的损失函数，以应对这些挑战。最后，我们进行了对比实验，以验证所提方法的有效性。结果表明，所提方法能够显著降低监督式低照度图像增强网络的复杂度，同时提升处理效果。代码见 https://github.com/hitzhangyu/FLW-Net。

关键词： 低光照图像、图像增强、轻量级网络、相对损失。

1 引言

在黑暗环境中拍摄或曝光不足的图像通常会成为低光照图像，存在对比度低、亮度低、噪声严重和色彩偏差等问题，导致图像中的部分信息不可见。

为了提高这些图像的质量，近年来提出了大量低照度图像增强方法（C.Guo etal.，2020； Y. Jiang etal.， 2021； X. Liu, Xie, Zhao,Wang,& Meng, 2023； Ma,Ma, Liu, Fan,&Luo，2022；Y.Zhang, Guo, Ma,Liu, & Zhang， 2021）。尽管这些方法已展现出良好的前景

尽管如此，无论是否基于学习，这些方法在处理速度与效果之间仍存在权衡。

虽然非基于学习的低照度图像增强方法能够显著提升图像对比度和亮度（X. Guo、Li 和 Ling，2016；Kimmel、Elad、Shaked、Keshet 和 Sobel，2003；Lee、Lee 和 Kim，2013；Yu 和 Zhu，2019），但后续单独进行的去噪步骤（Dabov、Foi、Katkovnik 和 Egiazarian，2007）或基于变分法的联合迭代去噪过程（M. Li、Liu、Yang、Sun 和 Guo，2018）可能非常耗时。这一局限使得这些方法中的大多数不适用于实时低照度图像增强应用。

基于学习的低照度图像增强方法可分为两大类：基于监督学习的方法和基于无监督学习的方法。通常，基于无监督学习的方法较为轻量，并且对各种环境具有更强的鲁棒性（C. Guo 等，2020；C. Li、Guo 和 Loy，2021；Ma 等，2022）。然而，这类方法往往缺乏灵敏的颜色校正和去噪方法，因而限制了其提升后续高级任务准确性的能力（Y. Zhang、Di、Zhang、Ji 和 Wang，2022）。相比之下，基于监督学习的方法旨在应对各种低照度图像退化问题，并能显著提升图像质量（N. Jiang、Lin、Zhang、Zheng 和 Zhao，2023；K. Zhang、Yuan、Li、Gao 和 Li，2023；Zhou、Shi 和 Ren，2023）。然而，这些方法中的大多数需要复杂的网络结构，导致处理时间较长。

设计一种能够同时增强对比度并去除噪声的轻量级网络是一项具有挑战性的任务。网络简化受到两个主要难题的制约。首先，图像的对比度调整应同时考虑局部和全局信息。这需要较大的感受野来捕捉全局对比度，从而增加网络的复杂度。其次，在低照度图像增强中，不存在绝对的参考，这意味着网络在去噪过程中必须为相同的输入像素或图像块学习不确定的输出值（我们可以将其称为一**对多问题**）。与无监督学习方法相比，这使得基于监督学习的方法更难学习，因为大多数无监督基于学习的方法都有一致的假设——关于输出值的信息，例如平均亮度值接近固定值（C.Li 等，2021）。

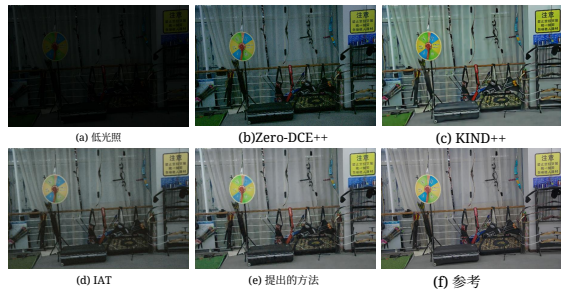


图1 与一些最先进方法的视觉比较。(a)原始输入低光照图像。(b) 至 (e) 是由 Zero-DCE生成的增强图像++ (C. Li 等，2021), KIND++ (Y. Zhang、Guo 等，2021) 以及本文提出的方法。(f) 参考图像。可以看出，我们提出的方法生成的增强图像 (e) 的颜色与参考图像 (f) 最为接近。

在本文中，为应对这些挑战，我们提出了一种解决方案：引入一种称为 FLW-Net 的快速轻量级图像增强网络，以及两个针对低照度图像增强任务、基于相对信息特别设计的损失函数。我们可以将基于相对信息的损失简称为相对损失；当参考图像与输出图像在某些特征上相似时，相对损失即可达到极值，而不要求二者完全相同。图 1 中展示了增强一幅包含色彩偏差的低光照图像的示例。可以看出，所提出方法生成的增强图像的色彩与参考图像最为接近。

具体而言，在网络结构设计方面，我们提出了一个简单的全局特征提取（GFE）组件，该组件可以从图像的直方图中提取全局信息，并通过高阶曲线调整方法生成全局亮度调整提C. Guo et al.,2020议。在损失函数方面，我们提出了两个基于相对信息的损失函数，以缓解低照度图像增强任务中的一对多问题。

我们的贡献可总结如下：

• 为提高计算效率并通过减少参数获取全局信息，我们提出了全局特征提取（GFE）组件，其参数量仅为 1.4K。与大多数使用大感受野或 Transformer 结构提取全局信息的现有方法不同，GFE 从仅包含少量区间的直方图中提取信息。这不仅提高了效率，也使其更容易与用于控制全局增强程度的超参数集成。

•为了解决多个潜在参考图像造成的学习困难，我们提出了两种新颖的损失函数（$L_{brightness}$ 和 $L_{structure}$），它们基于相对信息。不同于旨在使增强图像与参考图像完全匹配的传统 L_1 或 L_2 损失，我们提出的损失函数利用余弦相似度，从而允许输出图像与参考图像之间存在亮度差异。这样，网络就能更加专注于颜色、结构和噪声去除。当所提出的损失函数与其他监督方法结合使用时，可以用更少的参数实现更好的定量指标（例如，与 KIND（Y. Zhang、Zhang 和 Guo，2019）结合时，仅使用原始 KIND 网络约 5% 的参数）。

•通过 GFE 和提出的两个损失函数，我们构建了一个快速轻量的低照度图像增强网络，命名为 FLW-Net。与最先进水平的方法相比，该网络在保持更快处理速度的同时，实现了相当甚至更好的性能。这表明，所提出的方法有望降低低照度图像增强网络的复杂度。

2 相关工作

2.1 低照度图像增强

非学习型低照度图像增强方法主要包括直方图均衡化、伽马校正、基于去雾的方法（Dong 等，2011）或 Retinex 模型（王 S.、Zheng、Hu 和 Li，2013），以及基于这些方法的其他改进方法（Celik 和 Tjahjadi，2011；G. Fu、Duan 和 Xiao，2019；X. Guo 等，2016；Kumar 和 Bhandari，2022；Park、Yu、Moon、Ko 和 Paik，2017）。尽管这些方法能显著提升图像的亮度和对比度，但去除噪声和恢复色彩仍然颇具挑战。

近年来，用于增强低光照图像的基于学习的方法取得了令人瞩目的成果，包括监督方法（Xu、Chen、Xu、Jin 和 Zhu，2022；Y. Zhang 等，2022；Y. Zhang、Guo 等，2021；Y. Zhang 等，2019）以及无监督方法（C. Guo 等，2020；Y. Jiang 等，2021；X. Liu、Ma、Ma 和 Wang，2023；Ma 等，2022；Xiong、Liu、Shen、Fang 和 Luo，2020；Y. Zhang、Di 等，2021）。然而，与其他图像处理或计算机视觉任务不同，低照度图像增强任务通常缺乏真实值或绝对标签。对于同一场景，可能存在多张低光照和高光照图像，因此很难确定哪张参考图像最合适。即使经过专家校正，选择理想的参考图像仍可能颇具挑战（Y. Zhang 等，2022；Y. Zhang、Guo 等，2021）。

因此，大多数用于低光照图像增强的监督方法，往往会因存在多个潜在参考图像而面临挑战。为解决这一问题，主要有两类方法。第一类是设计复杂的网络，例如当前达到最先进水平的方法 MAXIM（Tu etal.，2022）。虽然这些方法能够取得令人期待的视觉效果，但在低光照图像增强任务中往往耗时较长。

第二类方法是在训练过程中引入超参数，将输入与输出联系起来（Chen, Chen, Xu,& Koltun，2018；Q.Fu, Di, & Zhang，2020）、使用简化 Retinex 模型（Wei, Wang, Yang, & Liu，2018），或同时采用两者（Y.Zhang et al.，2019）。例如，Chen 等人（2018）将参考图像与输入图像的曝光时间比作为超参数，以实现去噪和色彩恢复。Q. Fu 等人（2020）进一步提出了一个子网络，用于自动选择超参数。Wei 等人（2018）将简化 Retinex 模型融入网络。然而，简化 Retinex 模型假设所有三个颜色通道具有相同的照明图像，这与现实不符（Y. Zhang etal.，2022），导致去噪效果不理想。

为解决这一问题，Y. Zhang 等人（2019）和Y. Zhang、Guo 等人（2021）引入了超参数和简化的 Retinex 模型

进入网络，并设计了一个独立的恢复- 模块，用于去除噪声并校正反射图像中的颜色。然而，需要注意的是，同时引入Retinex 模型和超参数，可能仍会偏离真实的成像过程。因此，尽管这些方法采用了较不复杂的网络结构，但其运行时间可能无法满足实际应用的要求。

低照度图像增强的无监督方法通常假设输出满足某些约束，使其在未见场景中更加轻量且稳定。例如，C. Guo 等人(2020) 使用均值假设（例如，假设图像的平均亮度介于 0.4 和 0.6 之间）以及一些专门设计的损失函数来约束输出。Xiong 等人(2020) 将简化 Retinex 模型中照明图像的初始值设定为每个像素中 R、G、B 的最大值。Y. Jiang 等人(2021) 提出通过 GAN 框架从正常光照图像中学习输出约束。Ma 等人(2022) 提出约束训练期间不同阶段输出的相似性。尽管这些无监督方法中的大多数能够满足实时性要求，但由于缺乏充分的噪声和颜色约束，准确去除噪声并恢复色彩仍然是一项挑战。

通过比较监督方法和无监督方法可以发现，如果我们的目标不是让增强结果与参考图像完全相同，而是着重于从参考图像中学习颜色、结构和噪声去除，那么在图像增强过程中，可以利用简单的网络有效去除噪声并恢复颜色。此时，需要解决的问题是如何设计不受亮度差异影响的评估指标或损失函数。

2.2 图像润饰

图像修饰方法侧重于亮度不当、对比度差、色彩偏差等问题，与图像增强任务类似（Y. Wang, Li, 等，2022）。然而，这些方法大多未考虑噪声问题。因此，基本的修饰操作可以作用于单个像素，使其极其快速且轻量（He、Liu、Qiao 和 Dong，2020；Y. Liu 等，2022；Y. Wang、Li 等，2022；Zeng、Cai、Li、Cao 和 Zhang，2020）。例如，He 等（2020）和Y. Liu 等（2022）提出了条件序列修饰网络（CSRNet），仅包含 37K个可训练参数。Y. Wang、Li 等（2022）提出了可训练的神经颜色算子，其方法仅包含 28K个参数。在图像修饰中成功应用简单网络，也证明了使用简单网络执行图像增强任务的可行性。

3 方法

图2 展示了 FLW-Net 的架构，该网络由两个主要模块组成：全局特征提取（GFE）组件和局部增强网络（LEN）组件。GFE 组件以低光照图像的 V通道和期望的平均亮度为输入，通过高阶曲线调整方法生成全局亮度调整方案。随后，将该方案拼接后馈入 LEN。LEN 组件以低光照图像和全局亮度调整方案为输入，并通过一些精心设计的损失函数增强图像。该组件由若干卷积层构成，其局部感受野用于捕获局部信息并生成高频细节。

所提出的方法除了常用的 L_1 和结构相似性指数外，还包括多个损失函数。颜色损失记为 L_{color}，用于衡量增强图像与参考图像之间的颜色相似度。亮度损失记为 $L_{brightness}$，用于衡量增强图像与参考图像之间亮度顺序的差异。最后，结构损失记为 $L_{structure}$，旨在促使增强图像具有与参考图像相似的梯度顺序。我们将这些损失称为相对损失。

与 L_1 和结构相似性指数损失不同，前者只有在输出与参考完全相等时才达到极值，而相对损失在输出与参考共享某些特征时即可达到极值。所有这些损失函数，包括 L_1 和结构相似性指数损失，都会组合起来，构成用于训练 FLW-Net 的总损失函数。据我们所知，$L_{brightness}$ 和 $L_{structure}$ 是首次提出的。

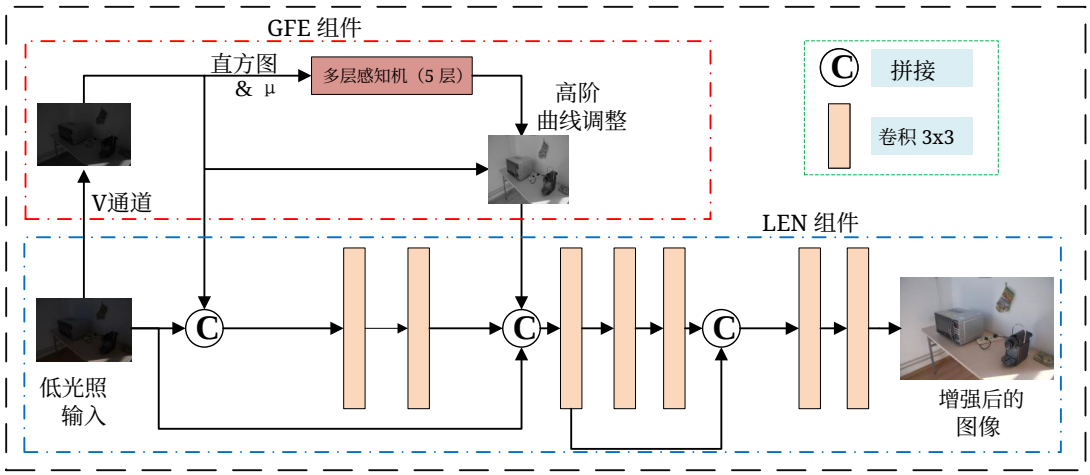


图 2 所提出方法的详细结构。

本文在这一低照度图像增强任务中。

3.1 全局特征提取组件

无需强调全局信息提取在低照度图像增强中的重要性，因为已有大量文献对此进行了讨论（Cui 等人，2022）。然而，挑战在于如何高效提取全局信息，并将其整合到增强网络中。

Y. Zhang等人(2022)已证明，HSV色彩空间中的V通道足以表示输入的低光照图像的亮度。同时，C. Guo等人(2020)提出迭代应用公式(1)来调整输入的低光照图像。

$$\mathbf{I_{k+1}} = \mathbf{I_k} + \alpha_k \mathbf{I_k}(1 - \mathbf{I_k}) \tag{1}$$

其中 k 表示迭代次数（例如，$\mathbf{I_0}$ 表示输入低光照图像）。

受这两项工作的启发，我们提出从低光照图像的 V 通道直方图中提取全局信息，并将其表示为高阶曲线系数，记为 $\alpha_{0,\ 1,\ \ldots t}$。具体而言，

$$\{\alpha_{0,1,\ldots t}\} = G(H(\mathbf{I^v})) \tag{2}$$

其中$\mathbf{I^v}$ 表示 HSV 色彩空间中低光照图像 $\mathbf{I}$ 的 V 通道，$H(\mathbf{I^v})$ 表示获取图像 $\mathbf{I^v}$直方图的操作，而 $G(\cdot)$ 表示全局特征提取（GFE）组件，该组件采用五层多层感知机实现，仅含 1.4K 个参数。与 C. Guo 等人 (2020) 提出的方法相比，我们方法中的 GFE 组件从 V 通道直方图而非像素级提取全局信息，效率更高。具体而言，随着图像尺寸增大，GFE 组件的计算成本不会显著增加。此外，GFE 组件的输出并非最终增强结果，因此还可以进一步进行去噪和色彩恢复。与Y. Zhang 等人 (2022) 提出的方法相比，我们的方法无需与其他图像对比度增强方法结合，借助式（9）和式（11）中提出的损失函数即可实现端到端训练。

如前所述，目前没有明确的标准来定义某个增强结果是否达到最优。同样，我们也不能声称，在特定数据集上训练的固定参数网络的处理结果是最优的。在这种情况下，为图像增强引入可调参数是一种合理的解决方案，正如先前工作所采用的（X.Liu、Xie 等，2023；Y. Wang、Wan 等，2022；Y. Zhang、Guo 等，

2021）。此外，如果参数与参考图像相关，我们可以允许网络学习相对确定的映射操作，从而简化网络在训练阶段的训练难度。

GFE 组件可以轻松修改，以纳入其他超参数。本文将期望的平均亮度值 μ用作超参数。在训练过程中，μ 计算为参考图像 V通道的平均值。与先前采用参考图像与输入图像之间的曝光时间差（Chenetal.，2018）以及参考图像和输入图像的照明图像之间的亮度比（Y. Zhanget al.，2019）等参数的研究相比，μ 更加直观，并且与直方图信息高度相关。此外，在测试过程中，我们可以轻松地将 μ 固定为一个常数值，这与一些无监督研究中的做法相同（C.Guo et al.，2020）。因此，修改后的 GFE 组件可表示为：

$$\{\alpha_{0,1,\ldots t}\} = G(H(\mathbf{I^v}), \mu) \tag{3}$$

然后，我们可以迭代地调整低光照图像的 V 通道，以获得全局亮度调整提议，如下所示：

$$\mathbf{I^v_{k+1}} = \mathbf{I^v_k} + \alpha_k \mathbf{I^v_k}(1 - \mathbf{I^v_k}) \tag{4}$$

在获得全局亮度调整方案后，它将与 LEN 的中间层进行拼接，并输入 LEN 以进行进一步增强。整个 FLW-Net 采用端到端方式训练，这意味着所有组件都经过联合训练，以优化网络的整体性能。

3.2 基于相对信息的损失函数

让我们将 $\{\mathbf{I},\mathbf{Y}\}$ 视为一对低光照/高光照图像。通常，我们使用大量成对图像来训练增强网络 E，并希望它能很好地拟合以下公式（5）：

$$\mathbf{Y_{(i,j)}} = E(\mathbf{I_{(i,j)}}) \tag{5}$$

其中 $(i,\ j)$ 表示一个像素的坐标。为实现这一点，已经提出了各种损失函数用于训练增强网络 E，采用成对的低光照/高光照图像，包括常用的 L_1、L_2 和结构相似性指数损失等。然而，由于一对多问题，这些损失函-数对于图像增强可能不如其在其他低层次图像处理任务（如图像去噪、图像去模糊和图像去雾）中的效果好。换言之，这些损失函- 数更适合学习输入与绝对参考图像之间的映射关系。

如前所述，先前的研究提出了建立增强模型输入与输出之间一对一关系的策略（其中一张输入低光照图像对应一张确定的参考图像）。然而，这些工作所采用的Retinex 模型和额外参数无法将一对多问题转化为真正的一对一问题。在实践中，即使为每个像素添加一个超参数，也无法保证令人满意的色彩恢复效果（Y. Zhanget al.，2022）。因此，大多数先前的工作通常需要复杂的网络或单独的去噪模块，例如 SID（Chen et al.，2018）、RetinexNet（Wei et al.，2018）、KIND（Y. Zhang etal.，2019）、KIND++ （Y. Zhang, Guo, et al.，2021）。

由于缺乏绝对监督信息，一种直观的方法是在损失函数中使用相对信息，从而减少对绝对参考图像存在性的假设。以往的无监督方法提出了一些有用的损失函数，例如空间一致性损失（C. Guo 等人，2020）、归一化梯度误差（Y. Zhang、Di 等人，2021）以及感知损失（Y. Jiang 等人，2021）。然而，由于约束较弱，这些方法大多无法在监督方法中取得令人瞩目的结果。

本文提出使用基于相对信息的相对损失函数，以降低网络的学习难度。

首先，对于一个像素，我们希望其颜色信息比亮度更符合参考图像。为此，我们需要提取图像的颜色信息，这可以通过多种颜色空间实现，例如 HSV（色调、饱和度、明度）或 HSI（色调、饱和度、强度）颜色空间。本文选择使用 HSV 颜色空间。它

已证明，当两个像素满足以下方程时，它们具有相同的色调和饱和度（Y. Zhang 等人，2022）：

$$E(\mathbf{I}_{(\mathbf{i},\mathbf{j})}) = \lambda \mathbf{Y}_{(\mathbf{i},\mathbf{j})} \tag{6}$$

其中，λ 表示任意非零正数。需要注意的是，$E(\mathbf{I}_{(\mathbf{i},\mathbf{j})})$ 和 $\mathbf{Y}_{(\mathbf{i},\mathbf{j})}$ 均表示三维向量。因此，我们可以采用余弦相似度来衡量两个像素之间色调和饱和度的差异。据此，颜色损失函数可设计如下：

$$L_{color} = 1 - \sum_{i=1,j=1}^{m,n} < E(\mathbf{I}_{(\mathbf{i},\mathbf{j})}), \mathbf{Y}_{(\mathbf{i},\mathbf{j})} > \tag{7}$$

其中 $< \cdot, \cdot >$ 表示两个向量的余弦相似度。通过最小化该损失函数，可以促使网络匹配输出图像与参考图像之间的色调和饱和度信息。该损失函数也已用于许多其他图像增强（刘 C.、吴和 Wang，2022；K. Zhang 等，2023）和计算颜色恒常性研究（Barnard、Cardei 和 Funt，2002；Gijsenij、Gevers 和 van de Weijer，2011）。

其次，就亮度而言，增强后的图像应与参考图像具有相同的明度顺序（王 S. 等，2013），这意味着参考图像中较亮的图像在增强后的图像中也应较亮。王 S. 等（2013）提出了用于评估明度顺序误差的指标 LOE（明度顺序误差）。然而，将 LOE 直接纳入损失函数并非易事，因为难以在反向传播过程中计算相应的梯度。本文提出以下公式来对增强图像与参考图像之间的亮度关系进行建模。

$$b(E(\mathbf{I}_{(\mathbf{i},\mathbf{j})})) = \beta b(\mathbf{Y}_{(\mathbf{i},\mathbf{j})}) + \gamma \tag{8}$$

其中，$b(\cdot)$表示以像素 $E(\mathbf{I}_{(\mathbf{i},\mathbf{j})})$和$\mathbf{Y}_{(\mathbf{i},\mathbf{j})}$为中心的图像块，$\beta$ 和 γ 可以表示彩色图像中的三维向量或灰度图像中的标量。对于不同的图像块，β 和γ可以不同。这对于处理亮度不均匀的图像很有用，因为图像的不同区域具有不同的增强程度。这可以是可以看到，在此模型中，增强图像在每个图像块中的明度顺序都与参考图像相同。此外，该模型比 LOE 指标更严谨，因为它的要求不止是亮度顺序。具体而言，它要求增强图像是无噪声参考图像的线性变换，从而显著抑制噪声。于是，我们可以将损失函数设计如下：

$$\begin{aligned} L_{brightness} = 1 - \sum_{c\in R,G,B} \sum_{i=1,j=1}^{m,n} \\ < b(E(\mathbf{I}^{\mathbf{c}}_{(\mathbf{i},\mathbf{j})})) - min(b(E(\mathbf{I}^{\mathbf{c}}_{(\mathbf{i},\mathbf{j})}))), \\ b(\mathbf{Y}^{\mathbf{c}}_{(\mathbf{i},\mathbf{j})}) - min(b(\mathbf{Y}^{\mathbf{c}}_{(\mathbf{i},\mathbf{j})})) > \end{aligned} \tag{9}$$

其中 c表示不同的颜色通道，减去最小值的目的是消除常数的影响γ。以下实验结果表明，$L_{brightness}$ 可以提升与噪声抑制相关的峰值信噪比指标（见第 4.3节、表 4和图 9）。

第三，对于结构信息，通常用梯度信息来表示。我们可以采用与公式（8）类似的模型。区别在于用梯度替换亮度值。然后，我们可以得到以下公式（10）。

$$b(\nabla E(\mathbf{I}_{(\mathbf{i},\mathbf{j})})) = \eta b(\nabla \mathbf{Y}_{(\mathbf{i},\mathbf{j})}) + \epsilon \tag{10}$$

因此，结构损失函数可表示如下：

$$\begin{aligned} L_{structure} = 1 - \sum_{c\in R,G,B} \sum_{i=1,j=1}^{m,n} \\ < b(\nabla E(\mathbf{I}^{\mathbf{c}}_{(\mathbf{i},\mathbf{j})})) - min(b(\nabla E(\mathbf{I}^{\mathbf{c}}_{(\mathbf{i},\mathbf{j})}))), \\ b(\nabla \mathbf{Y}^{\mathbf{c}}_{(\mathbf{i},\mathbf{j})}) - min(b(\nabla \mathbf{Y}^{\mathbf{c}}_{(\mathbf{i},\mathbf{j})})) > \end{aligned} \tag{11}$$

如果去掉 ϵ 公式（10）中的这一部分，公式（10）就会变成公式（8）的导数。此时，$L_{brightness}$ 和 $L_{structure}$ 本质上表示的是同一事物。然而，在公式（ ϵ 10）中引入这一项后，便可使图像块内的亮度发生非线性变化。这更贴近现实中的成像过程，并能减轻增强过程中亮度线性变化导致的饱和及欠饱和现象。因此，$L_{structure}$ 在保留图像

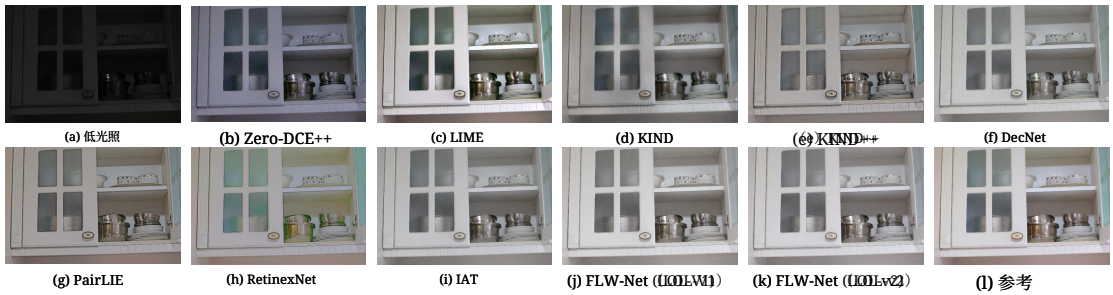


图3 在 LOL-V1 数据集上的视觉对比结果。对比方法包括 Zero-DCE++、LIME、KIND、KIND++、DecNet、PairLIE、RetienxNet、IAT，以及在 LOL-V1 和 LOL-V2 数据集上训练的所提出的 FLW-Net。（在高分辨率显示器上放大查看效果最佳。）

结构方面更为有效。实验结果也表明，它在提升结构相似性指数（SSIM）指标方面更有效（见第4.3节、表4和图9）。

总损失可表示如下：

$$L_{ALL} = L_1 + L_{SSIM} + L_{color} + L_{brightness} + L_{structure} \quad (12)$$

其中，L_{SSIM} 表示增强图像与参考图像之间的结构相似性指数损失。

4 实验

4.1 实现细节

该框架在英伟达 3090 Ti GPU 上使用 PyTorch 实现。训练时使用的批量大小为 171。我们使用 Adam优化器，以0.0001 的学习率训练网络。我们主要使用两个数据集进行训练和测试：LOL-V1数据集（Wei 等人，2018）和 LOL-V2数据集（Yang、Wang、Huang、Wang 和 Liu，2021）。LOL-V1数据集包含 500 对图像，其中15对用于测试。LOL-V2数据集包含 689 对用于训练的图像和 100 对用于测试的图像。我们还从网上收集了一些图像并将它们合并在一起，将其称为混合数据集。混合数据集包括 LOL-V1 的测试图像（15 张图像）、LIME（X. Guo 等人，2016）（10张图像）、MF（X. Fu 等人，2016）（10 张图像）和 VV[1]（23 张图像），其中大多数图像没有对应的参考图像。

我们使用四种指标进行定量比较：峰值信噪比、结构相似性指数、CIEDE2000（Luo、Cui 和 Rigg，2001；Sharma、吴和 Dalal，2005），以及自然图像质量评价器（Mittal、Soundararajan 和 Bovik，2012）。峰值信噪比和结构相似性指数是参考图像质量评估方法，分别用于表示增强图像与参考图像之间的噪声水平和结构相似度。CIEDE2000 是一种参考图像质量评估方法，用于准确测量颜色差异，由国际照明委员会（也称 Commission Internationale de l´Eclairage，CIE）发布。数值越低，表示颜色差异越小。自然图像质量评价器是一种非参考图像质量评估方法，用于评估图像的自然度，数值越低表示质量越好。为区分训练和测试过程中的 μ 数值，我们分别使用 μ_{train} 和 μ_{test} 来表示。

4.2 客观性能评估

在本节中，我们将我们的方法与几种最先进水平（SOTA）的低照度图像增强方法进行了比较，包括 LIME （X. Guo 等，2016）、 RetinexNet （Wei 等，2018）、Zerodce++（C. Li 等，2021）、KIND（Y. Zhang 等，2019）、KIND++（Y. Zhang、Guo 等，2021）、DecNet（X. Liu、Xie 等，2023）、PairLIE（Z. Fu 等，2023）和 IAT（Cui 等，2022）。其中，LIME 是一种非学习方法，ZeroDCE++无需任何参考图像即可训练。PairLIE 可以使用成对的低光照图像进行训练。其他方法均基于监督学习。其中，KIND（Y. Zhang 等，2019）、KIND++（Y. Zhang、Guo 等，2021）和 DecNet（X. Liu、Xie 等，2023）

[1]https://sites.google.com/site/vonikakis/datasets/challenging-dataset-for-enhancement

表 1 LOL（V1（Wei 等人，2018）和 V2（Yang 等人，2021））数据集及混合数据集的定量比较结果。混合数据集包含 LOL-V1 的测试图像（15 张）、LIME（X. Guo 等人，2016）（10 张）、MF（X. Fu 等人，2016）（10 张）和 VV（23 张）的测试图像，其中大多数图像没有对应的参考图像。需要注意的是，KIND 和 KIND 的测试时间++ 来自 KIND++（Y. Zhang、Guo 等人，2021）使用 Titan-X GPU 测得，而 RetinexNet 的测试时间不包括使用 BM3D（Dabov 等人，2007）进行去噪的运行时间。

方法	LOL-V1			LOL-V2			混合数据集（非配对）	效率	
	峰值信噪比↑	结构相似性指数↑	自然图像质量评价器↓	峰值信噪比↑	结构相似性指数↑	自然图像质量评价器↓	自然图像质量评价器↓	参数(M)↓	测试时间(s)↓
LIME(X. Guo 等人,2016)	17.22	0.50	5.32	15.77	0.46	5.37	4.57	-	0.190
RetinexNet(魏等, 2018)	17.86	0.78	6.37	17.37	0.76	9.09	5.68	0.4	0.019*
Zerodce++(C. Li 等人，2021)	15.35	0.57	7.86	18.49	0.58	8.05	4.53	**0.01**	**0.001**
KIND(Y. Zhang 等人，2019)	20.38	0.83	5.45	23.78	**0.88**	4.96	3.87	8.21	0.11*
KIND++(Y. Zhang、Guo 等人，2021)	21.80	**0.84**	5.17	22.21	0.84	4.89	3.74	8.28	0.12*
IAT(Cui 等人，2022)	23.38	0.81	**3.92**	23.50	0.82	4.29	4.71	0.09	0.004
DecNet(X. Liu、Xie 等人，2023)	22.49	0.82	4.51	22.56	0.84	4.83	4.26	1.83	0.353
PairLIE(Z. Fu 等人，2023)	18.47	0.75	4.25	19.88	0.78	4.34	3.90	0.33	0.057
FLW（使用 LOL V1 进行训练）	23.84	0.83	4.22	25.71	0.87	4.09	3.93	0.02	0.001
FLW（使用 LOL V2 进行训练）	**24.70**	**0.84**	4.11	**26.61**	**0.88**	**3.89**	**3.72**	0.02	**0.001**

在训练和测试期间都具有超参数。比较结果如表 1、2 和 3 以及图 3、 4、 5 和 6所示。在图 5 和 6中，超参数 μ 固定为 0.4。

在 LOL-V1 数据集上训练时，我们仅使用了 343 张图像，约为 LOL-V2 训练数据的一半。值得注意的是，这两个数据集均由同一团队制作，且 LOL-V2 包含了 LOL-V1 中的大部分数据。因此，我们可以评估训练数据量对网络的影响。

如表所示1，训练数据量对峰值信噪比的影响大于对结构相似性指数的影响。例如，在LOL-V1数据集上训练时，与LOL-V2 数据集相比，峰值信噪比降低了近 0.9 dB（峰值信噪比： $26.61 \rightarrow 25.71$）。然而，结构相似性指数仅下降了 0.01（结构相似性指数： $0.88 \rightarrow 0.87$）。此外，无论是在 LOL-V1 还是LOL-V2 数据集上训练，FLW-Net 在峰值信噪比方面都优于其他方法。在结构相似性指数方面，FLW-Net、KIND 和 KIND++取得了相似的结果。然而，FLW-Net 的参数更少（仅有 17K 个参数），并且在测试期间消耗的运行时间更少。需要注意的是，在 LOL-V2 和 LOL-V1 数据集上进行测试时，DecNet、KIND 和 KIND++的超参数均源自参考图像。

表 2 展示了各种方法在 LOL（V1（Wei 等人，2018）和 V2（Yang 等人，2021））数据集上的色彩比较结果。我们使用总色差 ΔE_{00} CIEDE2000来评估不同方法。可以看出，所提出的方法取得了比其他方法更低的 CIEDE2000（ΔE_{00}）值，

表 2 LOL（V1（Wei 等人，2018）和 V2（Yang 等人，2021）数据集上的颜色比较结果。

方法	CIEDE2000↓	
	LOL-V1	LOL-v2
LIME(X. Guo 等, 2016)	14.62	17.63
RetinexNet(魏等人, 2018)	13.76	18.07
Zerodce++(C. Li 等，2021)	19.28	14.27
KIND(Y. Zhang 等，2019)	9.68	6.74
KIND++(Y. Zhang、Guo 等，2021)	8.51	9.36
IAT(Cui 等，2022)	7.97	8.17
DecNet(X. Liu、Xie 等，2023)	8.93	8.87
PairLIE(Z. Fu 等，2023)	11.93	11.23
FLW（在 LOL V1 上训练）	7.74	6.64
FLW（在 LOL V2 上训练）	**7.23**	**6.06**

展示了我们所提出的方法在色彩恢复方面的有效性。

表3 在 LOL-v2（Yang 等人，2021））数据集上测试期间所有方法均采用固定参数的比较结果。（$\mu_{test} = 0.4$ 在我们的方法中采用）

方法↑	峰值信噪比↑	SSIM	自然图像质量评价器↓	CIEDE2000↓
KIND(Y. Zhang 等，2019)	20.59	0.82	4.86	9.3872
KIND++（Y. Zhang、Guo 等，2021）	17.66	0.77	4.73	13.89
DecNet(X. Liu、Xie 等，2023)	21.13	0.83	4.85	10.45
FLW（我们的方法）	**23.50**	**0.86**	**3.88**	**8.28**

在图 3 和4中，我们可以观察到，与参考图像相比，FLW-Net 增强的图像在亮度、对比度和色彩方面更加接近。LIME 和 RetinexNet 中使用的模型是简化 Retinex 模型。因此，增强图像的饱和度和色调与原始低光照图像相同，尤其是在图4中。尽管 KIND 和 KIND++引入了恢复网络来恢复反射图像的色彩并去除噪声，但结果仍不稳定。例如，在图4（e）中，KIND++ 增强的图像与参考图像相比仍存在色彩偏差。在

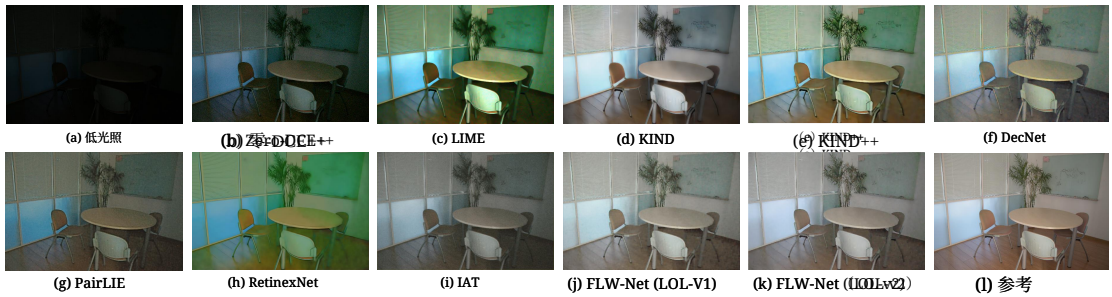


图 4 LOL-V2 数据集上的视觉对比结果。对比方法包括在 LOL-V1 和 LOL-V2 数据集上训练的 Zero-DCE++、LIME、KIND、KIND++、DecNet、PairLIE、RetienxNet、IAT 和所提出的 FLW-Net。（建议在高分辨率显示屏上放大查看，以获得最佳效果。）

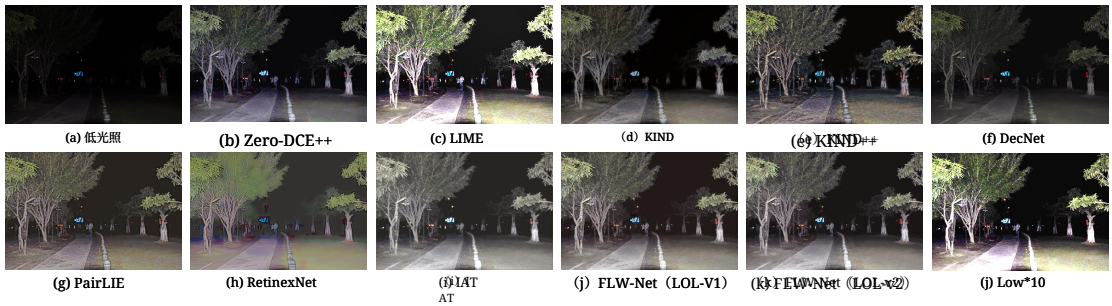


图 5 MF 数据集上的视觉比较结果（X. Fu 等人，2016）。比较方法包括 Zero-DCE++、LIME、KIND、KIND++、DecNet、PairLIE、RetienxNet、IAT，以及在 LOL-V1 和 LOL-V2 数据集上训练的所提出的 FLW-Net。（建议在高分辨率显示器上放大查看。）

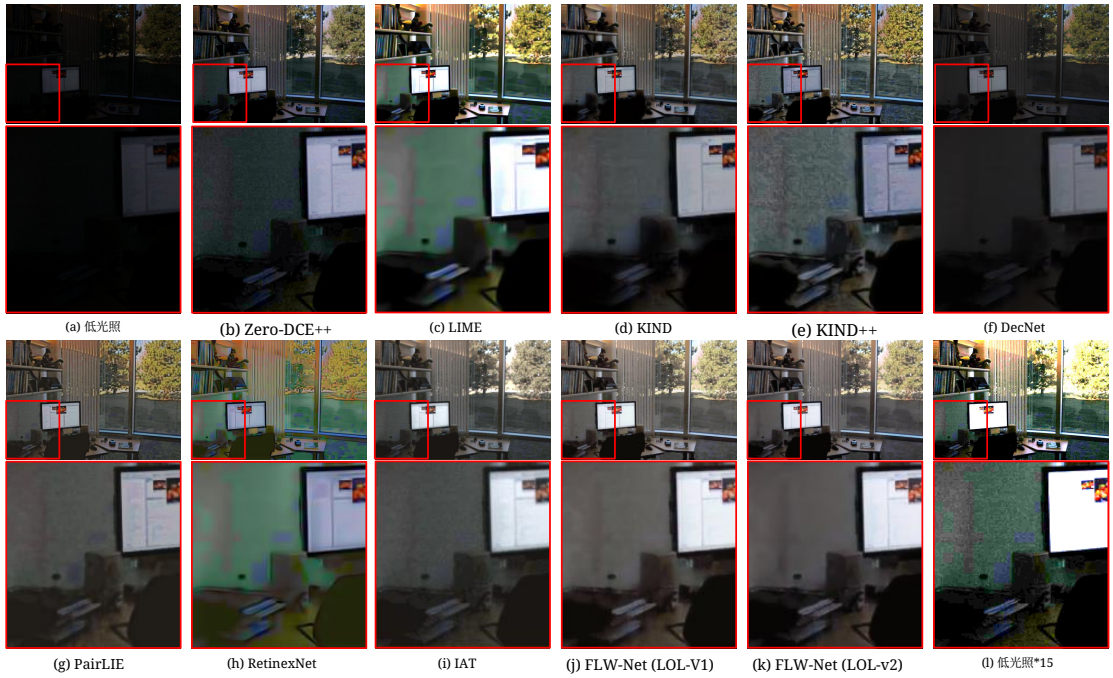


图 6 互联网图像上的视觉比较结果。比较方法包括在 LOL-V1 和 LOL-v2数据集上训练的Zero-DCE++、LIME、KIND、KIND++、DecNet、PairLIE、RetienxNet、IAT以及所提出的 FLW-Net。（在高分辨率显示器上放大查看效果更佳。）

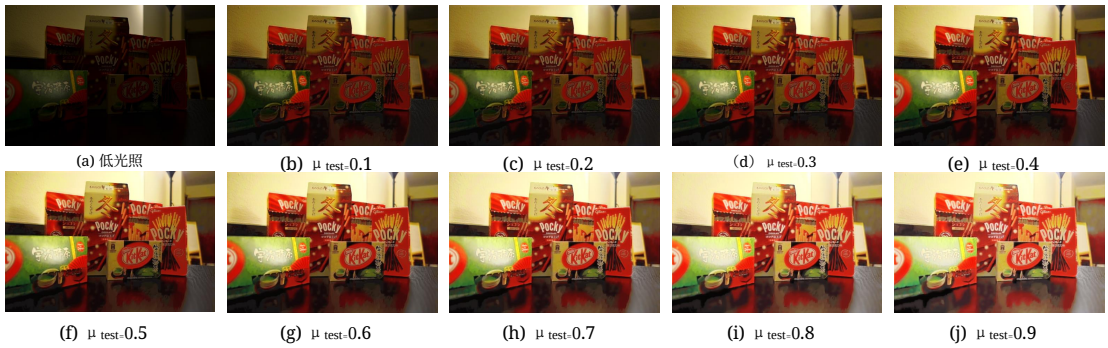


图7 在MF数据集上将 μ_{test} 值从0.1以0.1的步长改为0.9时的视觉对比结果。（在高分辨率显示器上放大查看效果最佳。）

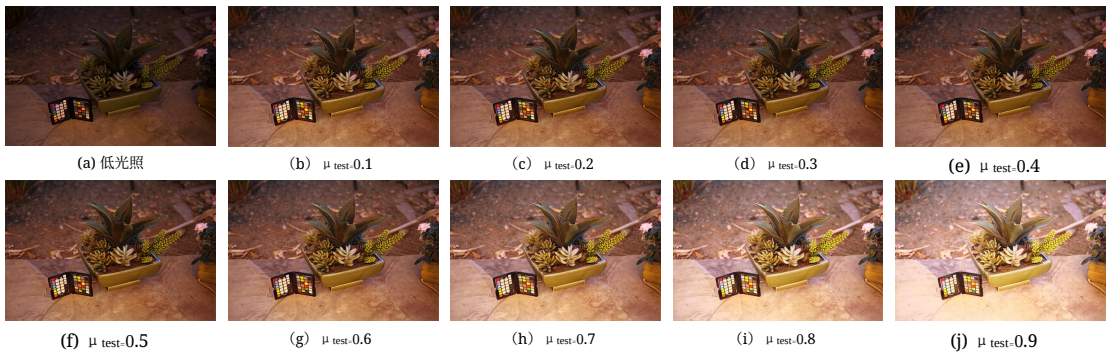


图 8 将 μ_{test} 值从 0.1 调整至 0.9，步长为 0.1 时，在 LIME 数据集上的视觉对比结果。（建议在高分辨率显示器上放大查看。）

图 5（d）中，KIND 将小光源视为噪声并将其去除。

测试时，μ_{test} 的值可以从参考图像中获得，例如（Y. Zhang 等人，2019）、（X. Liu、Xie 等人，2023）以及（Y. Zhang、Guo 等人，2021）。然而，在实际应用中，μ_{test} 的值通常由用户或机器确定，以动态调整增强结果，而非依赖参考图像。因此，仔细考虑 μ_{test} 取值的影响十分重要。为此，我们还展示了测试时 μ_{test} 取不同常数值时获得的结果。

表3 展示了与其他同样引入超参数的方法的定量比较结果。可以看出，所提出的方法使用更少的参数和更简单的网络结构，便能取得优于其他方法的性能。图5和6 展示了与其他方法的视觉效果比较结果。可以看出，所提出的方法能够在保留结构信息的同时有效去除噪声。

4.3 消融研究

我们在 LOL-V2 数据集上进行了两项消融研究，以展示所提出方法中各个组成部分的有效性。为进行定量比较，我们采用峰值信噪比、结构相似性指数和 CIEDE2000 作为评估指标。

各损失函数的贡献： 在这项消融研究中，我们使用采用L_1 和结构相似性指数损失训练的完整网络作为基线模型。随后，我们将相对损失函数纳入网络的损失函数中，并重新训练网络，以检验它们对模型性能的影响。此外，我们还仅使用相对损失函数训练网络，以评估其有效性。

表 4 不同训练损失的影响。在测试期间，输入 μ_{test} 值可以是常数（例如，$\mu_{test} = 0.4$），也可以通过参考值获得（例如，μ_{test} 等于参考图像 V通道的均值）。

损失函数				$\mu_{test} = 0.4$			μ_{test} 来自参考		
L_1+结构相似性指数	L_{color}	$L_{brightness}$	$L_{structure}$	峰值信噪比↑	结构相似性指数↑	CIEDE2000↓	峰值信噪比↑	结构相似性指数↑	CIEDE2000↓
✓				22.62	0.84	8.67	26.26	0.87	6.20
	✓	✓	✓	20.54	0.83	10.60	21.22	0.84	9.85
✓	✓			22.88	0.85	8.37	26.49	0.87	5.92
✓		✓		**23.72**	0.85	**7.90**	**26.80**	0.87	5.86
✓			✓	23.28	**0.86**	8.14	26.75	**0.88**	**5.84**
✓	✓	✓	✓	23.50	**0.86**	8.28	26.61	**0.88**	6.06

在表 4中可以观察到，当μ_{test} 取自参考图像时，将每个相对损失加入基线模型都会使峰值信噪比或结构相似性指数略有提升。然而，当 μ_{test} 对所有测试图像均取常数值时，$L_{brightness}$ 和 $L_{structure}$ 在峰值信噪比和结构相似性指数方面均表现出显著提升。这表明，所提出的两个损失函数能够帮助网络更好地学习噪声去除和结构保持，从而增强网络的稳定性。在这两个损失函数中，$L_{brightness}$ 在峰值信噪比方面的提升更为明显，这与其去噪能力有关；而 $L_{structure}$ 在结构相似性指数方面的提升更为明显，这与其保留结构信息的能力有关。另一方面，使用 L_{color} 时，峰值信噪比和结构相似性指数的提升相对较小。这可能是因为 L_{color} 仅考虑单个像素的信息，而噪声去除和结构信息的保留需要引入周围像素的信息。

此外，如表4所示，三种基于相对信息的损失函数均能提升色彩恢复性能。其中，本文提出的 $L_{brightness}$ 和$L_{structure}$ 的色彩恢复性能优于常用的 L_{color}。然而，同时使用全部三种损失函数时，CIEDE2000指标的性能并未达到最佳。这可能是因为三种损失函数所用模型的假设之间存在冲突。峰值信噪比指标也反映出同样的问题。仅在损失函数中添加 $L_{brightness}$ 时，峰值信噪比可达到23。72和26。80，而同时添加全部三种损失函数时，峰值信噪比只能达到23

。50和26。61。

图 7 和 8 展示了不同 μ_{test}值对增强结果的影响。可以看出，随着 μ_{test} 值的变化，增强图像的亮度也会相应变化。这表明使用参数 μ_{test} 控制增强结果的策略是可行的。亮度

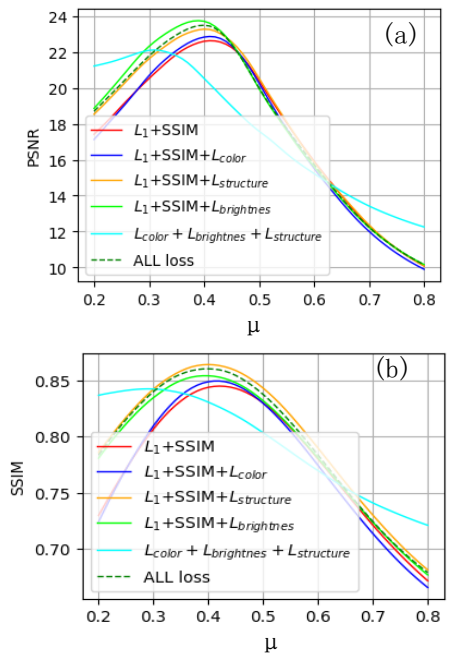


图9 改变 μ_{test} 值时，不同损失函数对峰值信噪比和结构相似性指数的影响。(a) 不同 μ_{test} 值对应的峰值信噪比。(b) 不同 μ_{test} 值对应的结构相似性指数。ALL loss表示以相同权重添加所有损失函数（公式（12））。

差异会对峰值信噪比和结构相似性指数值产生显著影响。图 9 展示了不同 μ_{test} 值和损失函数下结构相似性指数与峰值信噪比值的变化。可以看出，当网络训练不使用 L_1 和结构相似性指数损失时，其结构相似性指数和峰值信噪比方面的表现都更加稳定。如果训练损失包括 L_1和结构相似性指数损失，则当 μ_{test} 接近 0.4 时，结构相似性指数和峰值信噪比均达到最高值。

表 5 基于相对信息的 GFE 组件和损失函数的影响。在训练期间，输入 μ_{train} 值可以是常数（例如， $\mu_{train} = 0.4$），也可以通过参考获得（例如，本表中的 μ_{train} 等于参考图像 V通道的均值）。在测试期间，本表中所有图像的输入 μ_{test} 值均为常数（ $\mu_{test} = 0.4$）。相对损失表示 $L_{color} + L_{brightness} + L_{structure}$

损失函数		GFE	$\mu_{test} = 0.4$		LOL-v2	
L_1+结构相似性指数	相对损失	组件	$\mu_{train} = 0.4$	μ_{train} 来自参考	峰值信噪比↑	结构相似性指数↑
✓					18.32	0.80
✓	✓				19.05	0.82
✓		✓	✓		20.59	0.83
✓		✓		✓	22.62	0.84
✓	✓	✓		✓	**23.50**	**0.86**

这是因为，LOL-V2数据集中人为选取的参考图像，其V通道的均值为0.41。V通道均值高于0.5的图像非常少，这导致当 μ_{test} 的值更高时，结构相似性指数和峰值信噪比会显著下降。

此外，在图 9(b) 中，我们可以看到，使用 L_1、结构相似性指数和 $L_{structure}$损失训练的网络取得了最高的结构相似性指数。在图 9(a) 中，使用 L_1、结构相似性指数和 $L_{brightness}$训练的网络取得了最高的峰值信噪比。这证明了 $L_{structure}$ 和 $L_{brightness}$ 分别在改善结构恢复和亮度恢复方面的有效性。

GFE组件的贡献： 在这项消融研究中，使用 L_1 和结构相似性指数损失训练且不包含 GFE 组件的网络被视为基线模型。随后，对添加GFE 组件以及本文提出的损失函数的效果进行了比较和研究。结果如表5所示。需要注意的是，在该表的测试过程中，输入 μ_{test} 值对于所有图像都是恒定的。

表 5 表明，当我们将其他提出的损失函数或 GFE 组件添加到基线模型中时，峰值信噪比和结构相似性指数值均有所提升。这有力地证明了GFE组件以及采用相对信息设计的损失函数的有效性。GFE 组件能够捕获全局亮度信息，并以较少的参数将其整合到增强过程中，使峰值信噪比显著提升 2.27 dB，结构相似性指数提升 0.03（峰值信噪比：18.32 $\rightarrow$ 20.59，结构相似性指数：0.80 $\rightarrow$ 0.83），即使在测试和训练期间固定 μ_{test} 和 μ_{train} 值也是如此。

此外，我们观察到，当根据参考图像计算 μ_{train} 值时在训练过程中，峰值信噪比和结构相似性指数值的提升更加显著（例如，峰值信噪比：18.32 $\rightarrow$ 22.63，结构相似性指数： 0.80 $\rightarrow$ 0.84）。这一发现凸显了在低照度图像增强中，学习如何去除噪声并保留结构信息时所面临的一对多问题挑战。因此，GFE 组件是一种简单高效的输入图像与输出图像连接方法，可通过促进学习过程大幅改善增强结果。

4.4 与其他网络结合

所提出的 $L_{brightness}$ 和 $L_{structure}$ 损失函数也可以与其他有监督的图像增强方法相结合，以更少的运算或参数提升其性能。例如，在基于Retinex的低光照图像增强方法中，采用 BM3D 或额外的子网络对反射图像进行去噪，例如 RetinexNet (Wei 等人，2018)、KIND (Y.Zhang 等人，2019) 和 KIND++(C. Li 等人，2021))。然而，如果将所提出的两个相对损失函数加入网络的训练中，则无需额外部分即可提升其性能。表6、7 和图 10、11展示了将 $L_{brightness}$ 和$L_{structure}$ 与 RetinexNet 和 KIND 相结合的示例。

在原论文中，RetinexNet 使用 LOL-V1 数据集进行训练（Wei 等人，2018），并使用 BM3D 对反射图像进行去噪。通过将提出的两个相对损失函数加入 RetinexNet 的训练中，该网络取得了优于原始 RetinexNet 以及结合 BM3D 的 RetinexNet 的峰值信噪比、结构相似性指数和 CIEDE2000 分数，如表 6 所示。此外，如图 10所示，RetinexNet配合 $L_{brightness}$ 和 $L_{structure}$损失函数可以显著降低增强图像中的噪声（图 10（b）和（d））。相比

表 6 在 LOL-V1 数据集上，将 $L_{brightness}$ 和 $L_{structure}$ 与 RetinexNet 结合的影响。原论文（Wei 等人，2018）中，RetienxNet 使用 LOL-V1 数据集进行训练，作者使用 BM3D 对反射图像进行去噪。

原始损失函数	BM3D	$L_{brightness}$&$L_{structure}$	峰值信噪比↑	结构相似性指数↑	CIEDE2000↓
✓			16.79	0.42	15.89
✓	✓		17.86	0.78	13.76
✓		✓	**18.87**	**0.79**	**12.01**



(a) 低光照 (b) 不使用 BM3D 的 RetinexNet (c) RetinexNet 与 BM3D (d) RetinexNet 与我们的损失函数 (e) 参考

图10 将所提出的损失函数与 RetinexNet 结合后的视觉效果。(a) 输入的低光照图像。(b) 未使用 BM3D 的 RetinexNet 结果。(c) 使用 BM3D 的 RetinexNet 结果。(d) 未使用 BM3D、且训练损失函数中使用 $L_{brightness}$ 和 $L_{structure}$ 的 RetinexNet 结果。(e) 参考图像。在原论文中（Wei 等人，2018），RetinexNet 使用 LOL-V1 数据集进行训练，并使用 BM3D 对反射图像进行去噪。（建议在高分辨率显示器上放大查看。）

使用BM3D方法（图 10（c））， 提出的相对损失函数可以帮助保留更多细节并恢复色彩（图 10（d））。

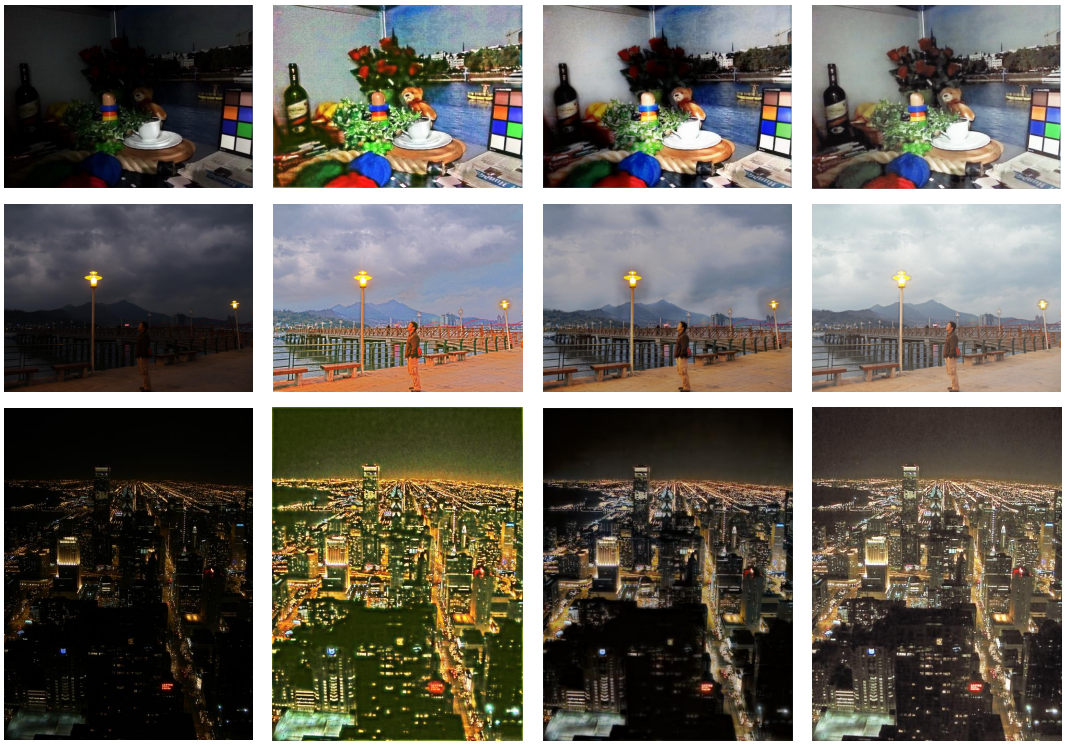
KIND 由三个子网络组成：DecomNet、RestorNet 和 AdjustNet。通过将所提出的相对损失函数加入 DecomNet 的训练中，DecomNet 取得了比完整 KIND 方法更好的结果，如表7所示。此时，参数数量可减少近 95%。图 11 展示了将相对损失函数与 KIND 的 DecomNet结合后得到的一些图像。可以看出，相对损失函数对降噪、颜色校正和细节保留均有积极影响。因此，使用这两个所提出的相对损失函数和更简单的网络结构，我们可以获得相当甚至更优的结果。

5 结论

在本文中，我们证明了通过使用高效的全局特征提取和采用所提出的相对损失函数，只需简单的网络结构，就能实现图像增强，效果可与当前最先进水平（SOTA）的方法相媲美，甚至更好，同时运行时间大幅缩短。此外，全局特征提取组件和损失函数还可以与其他低照度图像增强技术结合，以提升峰值信噪比（PSNR）和结构相似性指数（SSIM）等客观评价指标。实验结果表明，我们的方法在低照度图像增强方面具有效果和优势。然而，我们的方法仍存在一些局限性，例如最终增强结果取决于期望的亮度参数 μ_{test} ，且训练时需要配对数据。为解决第一个问题，可以自动选择参数，正如我们之前的工作所示（Q. Fu 等人，2020），也可以通过伽马校正或其他局部色调映射技术进一步调整增强图像的对比度（Zeng 等人，2020）。在未来的研究中，我们计划

表7 将 $L_{brightness}$ 和 $L_{structure}$ 与 KIND 结合在 LOL-V1 数据集上的影响。原论文（Y. Zhang 等人，2019）中，KIND 使用 LOL-V1 数据集进行训练。KIND 有三个子网络，分别是分解网络、恢复网络和光照调整网络。在本表中，它们分别简称为 DecomNet、RestorNet 和 AdjustNet。

DecomNet	RestorNet&AdjustNet	$L_{brightness}$&$L_{structure}$	峰值信噪比↑	结构相似性指数↑	CIEDE2000↓	参数(M)↓
✓			15.68	0.50	18.73	0.43
✓	✓		17.65	0.78	12.49	8.21
✓		✓	**18.94**	**0.80**	**11.93**	0.43



(a) 低光照　(b) KIND 的 DecomNet　(c) KIND　(d) DecomNet 与我们的损失函数

图1 11 将损失函数与 KIND 的 DecomNet 结合后的视觉效果。KIND 包含三个子网络，分别是分解网络、恢复网络和光照调整网络。在本表中，它们分别简称为 DecomNet、RestorNet 和 AdjustNet。(a) 输入的低光照图像。(b) KIND 中 DecomNet 的结果。(c) KIND。(d) 使用 $L_{brightness}$ 和 $L_{structure}$ 替换原始损失函数后的 KIND 中的 DecomNet。（建议在高分辨率显示屏上放大查看。）

提升所提方法的鲁棒性，并探索用于网络训练的无监督方法。

致谢。作者谨向国家自然科学基金（编号：62027283和61775048）、中国航空科学基金（编号：2022Z071077002）以及深圳市基础研究计划（编号：JCYJ20201091508080037）资助项目表示感谢。

声明

•作者声明，他们没有与本文内容相关的利益冲突。

•代码可在 https://github.com/hitzhangyu/FLW-Net获取

•论文中使用的数据来源于公开发表的论文或公开网站。不过，如有合理理由，也可以向通讯作者索取数据。

• Y.Zhang 设计了工作流程并撰写了稿件。J.Wu.、Y.Wang.、Y.Li. 和 R.Fu. 提供了一些想法，解决了工作中的一些问题，并为稿件撰稿。Y.Xu. 和 Y.Guo 提供了一些想法，并为稿件撰稿。X.Xiao 和 C.Wang. 监督了这项工作，并为稿件撰稿。

参考

Barnard, K., Cardei, V., Funt, B. (2002). 计算颜色恒常性算法的比较。I：使用合成数据的方法与实验。*IEEE*图像处理汇刊，*11*(9), 972-984.

https://doi.org/10.1109/TIP.2002 .802531

Celik, T., & Tjahjadi, T. (2011). 上下文与变分对比度增强。*IEEE*图像处理汇刊，*20*(12), 3431–3441.

Chen, C., Chen, Q., Xu, J., Koltun, V. (2018). 在黑暗中学习视觉。*IEEE* 计算机视觉与模式识别会议论文集（第 3291–3300 页）。

Cui,Z., Li, K., Gu, L., Su, S.,Gao, P.,Jiang,Z., ... Harada, T.(2022). 适应光照只需90k个参数：用于图像增强和曝光校正的轻量级Transformer。第*33*届英国机器视觉会议*2022*，*BMVC 2022*，英国伦敦，*2022*年*11*月*21*日至*24*日。BMVA出版社。检索自 https://bmvc2022.mpi-inf.mpg.de/0238.pdf

Dabov, K., Foi, A., Katkovnik,V.,Egiazarian, K. (2007). 基于稀疏三维变换域协同滤波的图像去噪。*IEEE*图像处理汇刊，*16*

(8)，2080–2095。

Dong, X., Wang, G., Pang, Y., Li,W., Wen, J., Meng, W., Lu, Y. (2011). 快速高效低照度视频增强算法。*2011* 年 *IEEE* 多媒体与博览会国际会议（第 1–6 页）。Fu, G., Duan, L., Xiao, C. (2019). 一种结合亮通道先验的单幅低照度图像增强混合 l2-lp 变分模型。*2019* 年 *IEEE* 国际图像处理会议（*ICIP*）（第 1925–1929 页）。

Fu, Q., Di, X., Zhang, Y.（2020）。学习一种用于极端低光照原始图像处理的自适应模型。*IET* 图像处理，*14*(14)，3433–3443。

Fu, X., Zeng, D., Huang, Y., Liao, Y., Ding, X., Paisley, J.（2016）。一种基于融合的弱光照图像增强方法。信号处理，*129*，82–96。

Fu, Z., Yang, Y., Tu, X., Huang, Y., Ding, X., Ma, K.-K.（2023）。从成对的低光照图像实例中学习一种简单的低光照图像增强器。*IEEE*计算机视觉与模式识别会议论文集（第22252–22261页）。

Gijsenij, A., Gevers, T., van de Weijer.（2011）。计算颜色恒常性：综述与实验。*IEEE*图像处理汇刊，*20*(9)，2475-2489。

https://doi.org/10.1109/TIP.2011 .2118224

Guo, C.,Li, C., Guo, J., Loy, C.C., Hou, J.,Kwong, S.,Cong, R. (2020).无参考深度曲线估计用于低照度图像增强。*IEEE/CVF*计算机视觉与模式识别会议论文集 (pp. 1780–1789)。

Guo, X., Li,Y.,Ling, H. (2016). LIME：通过照明图估计进行低照度图像增强。*IEEE*图像处理汇刊，*26*(2)，982–993。

He, J.、Liu, Y.、Qiao, Y.、Dong, C.（2020）。用于高效处理的条件序列调制

全局图像修饰。 欧洲计算机视觉会议 （第679–695页）。

Jiang, N., Lin, J., Zhang, T., Zheng, H., Zhao, T. (2023). 通过阶段变换器引导网络进行低照度图像增强。*IEEETransactions on Circuitsand Systems forVideo Technology*, 1-1.

https://doi.org/10.1109/TCSVT.2023 .3239511

Jiang, Y., Gong, X., Liu, D., Cheng, Y., Fang, C., Shen, X.,.. .Wang, Z.(2021). Enlighten- gan: 无需配对监督的深度光照增强。*IEEE*图像处理汇刊，*30*，2340–2349。Kimmel, R., Elad, M., Shaked, D., Keshet,R.,Sobel, I. (2003).Retinex的变分框架。国际计算机视觉期刊，*52*(1)，7–23。Kumar,R.,&Bhandari,A.K. (2022). 针对近乎不可见图像的模糊化对比度增强。*IEEE*视频技术电路与系统汇刊，*32*(5)，2802-2813。https://doi.org/10.1109/TCSVT.2021 .3098763 Lee, C., Lee,C., Kim, C.-S. (2013). 基于二维直方图分层差异表示的对比度增强。*IEEE*图像处理汇刊，*22*(12)，5372–5384。Li, C., Guo,C.,Loy, C.C. (2021). 通过零参考深度曲线估计学习低光照图像增强。*IEEE*模式分析与机器智能汇刊，*44*(8)，4225–4238。Li, M.,Liu, J.,Yang,W., Sun, X.,Guo,Z.(2018). 通过鲁棒Retinex模型实现揭示结构的低光照图像增强。*IEEE*图像处理汇刊，*27*(6), 2828–2841。Liu, C., Wu, F., Wang, X. (2022)。Efinet：通过增强-融合迭代网络实现低光照图像复原。*IEEE Transactions on Circuits and Systems for Video Technology*, *32*(12), 8486-8499。https://doi.org/10.1109/TCSVT.2022 .3195996 Liu, X., Ma, W., Ma, X., Wang, J. (2023)。Laenet：用于低照度图像增强的局部自适应嵌入网络。*PatternRecognition*，*133*，109039。https://doi.org/10.1016/j.patcog.2022 .109039 Liu, X., Xie, Q., Zhao, Q., Wang, H., Meng, D. (2023)。基于Retinex的算法展开与调整实现低照度图像增强。*IEEE Transactions onNeuralNetworks and Learning Systems*，1-14。https://doi.org/10.1109/TNNLS.2023 .3289626 Liu, Y., He, J., Chen, X., Zhang, Z., Zhao, H., Dong, C., Qiao, Y. (2022)。采用条件序列调制的超轻量级照片润饰网络。*IEEE Transactionson Multimedia*。Luo, M.R., Cui, G., Rigg, B. (2001)。CIEDE2000颜色差异公式的开发：CIEDE2000。*Color Research & Application: Endorsed by Inter-Society Color Council, The Colour Group (Great Britain), Canadian Society for Color, Color Science Association of Japan, Dutch Society for the Study of Color, The Swedish Colour Centre Foundation, Colour Society of Australia, Centre Fran.cais de la Couleur*，*26*(5), 340– 350。Ma, L., Ma, T., Liu, R., Fan, X., Luo, Z. (2022)。迈向快速、灵活且稳健的低照度图像增强。*Proceedingsof the*

IEEE/CVF 计算机视觉与模式识别会议 （第5637–5646页）。

Mittal,A., Soundararajan,R.,Bovik,A.C. (2012). 制作一种“完全盲”的图像质量分析器。*IEEE* 信号处理快报,*20*(3), 209–212。

Park, S.、Yu, S.、Moon, B.、Ko, S.、Paik, J.（2017）。基于变分优化 Retinex 模型的低照度图像增强。*IEEE* 消费电子学汇刊，*63*(2)，178–184。

Sharma,G.、吴、Dalal,E.N.（2005）。CIEDE2000色差公式：实现说明、补充测试数据与数学观察。《色彩研究与应用》：获跨社会色彩委员会、英国色彩学会、日本色彩科学协会、荷兰色彩研究学会、瑞典色彩中心基金会、澳大利亚色彩学会、法国色彩中心认可，*30*（1），21–30。

Tu,Z., Talebi, H., Zhang, H., Yang,F., Milanfar, P.,Bovik,A.,Li,Y. (2022). MAXIM：用于图像处理的多轴多层感知机。*IEEE/CVF*计算机视觉与模式识别会议论文集 （第5769–5780页）。

Wang, S., Zheng, J.,Hu, H.-M., Li, B. (2013). 保留自然度的非均匀照明图像增强算法. *IEEE*图像处理汇刊, *22*(9), 3538–3548.

Wang, Y., Li, X., Xu, K.,He, D., Zhang,Q.,Li,F.,Ding, E. (2022). 用于序列图像修饰的神经色彩算子。*arXiv* 预印本 *arXiv:2207.08080* 。

Wang, Y., Wan, R., Yang, W., Li, H., Chau, L.- P., Kot, A.（2022年6月）。低光照图像使用归一化流进行增强。 人工智能促进会（*AAAI*）会议论文集，*36*（3），2604-2612。

https://doi.org/10.1609/aaai.v36i3 .20162

Wei,C., Wang, W., Yang, W.,Liu, J. (2018). 用于低照度增强的深度 Retinex 分解。*arXiv* 预印本 *arXiv:1808.04560*。

Xiong,W., Liu, D.,Shen,X., Fang, C.,Luo, J. (2020). 采用解耦网络进行无监督真实场景低照度图像增强。*arXiv* 预印本 *arXiv:2005.02818*。

Xu, K., Chen, H., Xu, C., Jin, Y., Zhu, C. (2022). 用于低照度图像增强的结构-纹理感知网络。*IEEE*视频技术电路与系统汇刊，*32*(8), 4983-4996。

https://doi.org/10.1109/TCSVT.2022 .3141578

Yang, W., Wang, W., Huang, H., Wang, S., Liu, J. (2021). 用于鲁棒低照度图像增强的稀疏梯度正则化深度 Retinex 网络。*IEEE*图像处理汇刊，*30*，2072–2086。

Yu, S.-Y., & Zhu, H.（2019）。基于物理照明模型的低光照图像增强算法。*IEEE* 视频技术电路与系统汇刊，*29*(1)，28-37。

https://doi.org/10.1109/TCSVT.2017 .2763180

Zeng, H.,Cai, J., Li, L., Cao, Z., Zhang, L.（2020）。学习用于实时高性能照片增强的图像自适应 3D 查找表。*IEEE* 模式分析与机器智能汇刊。

Zhang, K., Yuan, C.,Li,J.,Gao, X., Li, M.（2023）。用于……的多分支渐进式网络。

低照度图像增强。*IEEE*图像处理汇刊，*32*，2295- 2308。https://doi.org/10.1109/TIP.2023 .3266171 Zhang, Y.,Di, X., Zhang,B.,Ji, R.,Wang,C. (2022)。低照度图像增强中优于参考：条件再增强网络。*IEEE*图像处理汇刊，*31*，759-772。https://doi.org/10.1109/TIP.2021 .3135473 Zhang, Y., Di, X., Zhang, B., Li, Q.,Yan,S., Wang, C. (2021)。自监督低光照图像增强与去噪。*arXiv*预印本 *arXiv:2103.00832*。Zhang, Y.,Guo, X.,Ma,J.,Liu,W., Zhang, J. (2021)。超越低光照图像提亮。国际计算机视觉杂志，*129*(4)，1013–1037。Zhang,Y., Zhang,J., Guo, X. (2019)。点亮黑暗：一种实用的低光照图像增强器。第*27*届*ACM*国际多媒体会议论文集 (第1632–1640页)。Zhou,Z.,Shi,Z., Ren, W. (2023)。低照度图像增强的线性对比度增强网络。*IEEE*仪器与测量汇刊，*72*，1-16。