

边缘和颜色信息引导下的高分辨率低光图像增强算法

张玲, 李振宇

引用本文

张玲, 李振宇. [边缘和颜色信息引导下的高分辨率低光图像增强算法](#)[J]. 计算机科学, 2025, 52(6): 297-305.

ZHANG Ling, LI Zhenyu. [Edge and Color Information Guided High-resolution Low-light Image Enhancement Algorithm](#) [J]. Computer Science, 2025, 52(6): 297-305.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于多任务联合学习的弱光场景人脸检测算法](#)

Face Detection Algorithm Based on Multi-task Joint Learning in Weak Light Scenes

计算机科学, 2025, 52(2): 191-201. <https://doi.org/10.11896/jsjcx.231100166>

[基于多尺度与双注意力网络的城市边缘区不透水面变化检测](#)

Impervious Surface Change Detection in Urban Fringe Areas Based on Multi-scale and Dual-attention Network

计算机科学, 2024, 51(11A): 231200064-8. <https://doi.org/10.11896/jsjcx.231200064>

[基于联合增强图像对的红外可见光深度展开图像融合网络](#)

Infrared and Visible Deep Unfolding Image Fusion Network Based on Joint Enhancement ImagePairs

计算机科学, 2024, 51(10): 311-319. <https://doi.org/10.11896/jsjcx.230800069>

[基于YOLOv5s和双稳随机共振的夜间车辆检测算法](#)

Night Vehicle Detection Algorithm Based on YOLOv5s and Bistable Stochastic Resonance

计算机科学, 2024, 51(9): 173-181. <https://doi.org/10.11896/jsjcx.230600056>

[基于改进图像增强及CNN的复杂环境车牌识别算法](#)

Complex Environment License Plate Recognition Algorithm Based on Improved Image Enhancement and CNN

计算机科学, 2024, 51(6A): 220200162-7. <https://doi.org/10.11896/jsjcx.220200162>

边缘和颜色信息引导下的高分辨率低光图像增强算法

张玲^{1,2} 李振宇¹

1 武汉科技大学计算机科学与技术学院 武汉 430065

2 智能信息处理与实时工业系统湖北省重点实验室(武汉科技大学) 武汉 430065

摘要 设备捕捉高分辨率图像的能力对图像处理提出了新的挑战,现有的低光图像增强算法多是针对低分辨率图像设计的,在处理高分辨率图像时,存在细节不清晰、颜色失真等问题。利用图像自身包含的纹理信息和颜色信息,提出了一种边缘和颜色信息引导的高分辨率低光照图像增强算法。为改善卷积神经网络局部特征学习的局限性,引入了边缘解码器,有助于捕获图像中远距离的关键信息,提高对边界语义信息的编码。此外,为处理高分辨率图像,在上下文注意力块中引入了稀疏注意力机制,集中关注图像中的重要信息,以有效减少噪声干扰。另一方面,颜色解码器有效利用了低光图像自身的色度线索,提升了颜色信息恢复的准确性。

关键词: 高分辨率; 图像增强; 低光照

中图分类号 TP301

Edge and Color Information Guided High-resolution Low-light Image Enhancement Algorithm

ZHANG Ling^{1,2} and LI Zhenyu¹

1 School of Computer Science and Technology, Wuhan University of Science and Technology, Wuhan 430065, China

2 Hubei Provincial Key Laboratory of Intelligent Information Processing and Real-time Industrial Systems, Wuhan University of Science and Technology, Wuhan 430065, China

Abstract The ability of the device to capture high-resolution images poses a new challenge to image processing, and most of the existing low-light image enhancement algorithms are designed for low-resolution images, and there are problems such as unclear details and color distortion when dealing with high-resolution images. Using the texture information and color information contained in the image itself, an edge and color information guided high-resolution low-light image enhancement algorithm is proposed. To improve the limitation of local feature learning of convolutional neural network, an edge decoder is introduced, which helps to capture the key information in the image at a long distance and improves the encoding of semantic information at the boundary. In addition, in order to deal with high-resolution images, a sparse attention mechanism is introduced in the context attention blocks, which focuses on the important information in the image and effectively reduces noise interference. On the other hand, the color decoder effectively utilizes the chromaticity cues of the low-light image itself to improve the accuracy of color information recovery.

Keywords High resolution, Image enhancement, Low light

1 引言

由于受到不可避免的复杂环境以及环境的不可控制性的影响,如照明不足或曝光时间有限,因此通常会获取到一些低光图像。这种低质量的低光图像影响了人们的视觉体验和高质量拍照体验,也给高级的计算机视觉任务带来了负担。尤其是在语义分割、目标识别和智能驾驶等领域,低质量的低光图像给数据分析带来了很大的限制性,降低了后续算法的准确性和精度。因此,对低光图像进行增强,恢复图像中的亮度

和对比度,得到更为准确和清晰的图像,是计算机视觉中的一项重要且必要的任务^[1-2]。

随着高分辨率图像获取设备的广泛应用,人们获取的图像分辨率也在逐步提高。高分辨率低光图像带来更高像素的同时,也包含了更多的细节信息。现有的低光增强方法大多只能处理低分辨率图像,在处理高分辨率图像时性能不佳,通常存在细节不清晰、颜色失真等问题,而高分辨率低光图像在其他视觉工作中应用广泛。

目前低光图像增强方法大体上分为传统方法和基于深度

到稿日期:2024-02-29 返修日期:2024-06-25

基金项目:国家自然科学基金(61902286);湖北省自然科学基金(2023AFB615)

This work was supported by the National Natural Science Foundation of China(61902286) and Hubei Provincial Natural Science Foundation(2023AFB615).

通信作者:张玲(zhling@wust.edu.cn)

学习的方法。传统的低光图像增强算法,如直方图均衡法^[3]、 γ 校正法^[4]及基于 Retinex 理论分解的方法^[5]等,是对图像的对比度、亮度和噪声进行调整,虽然一定程度改善了图像质量,但是对于图像的细节和不同场景的图像缺乏关注,进而产生图像失真和过度增强等现象。最近,深度学习也被广泛应用于低光图像增强^[6-11]。例如,LLNet^[12]采用了叠加稀疏去噪自动编码器的变体对低光图像进行增亮和去噪,但该方法在处理真实数据时会出现曝光不足的问题;Jiang 等推出了用于低光增强的 EnlightenGAN^[13]和 Zero-DCE^[14];Zhu 等^[15]提出了 RRDNet,用于曝光不足图像的修复;Cotogni 等^[16]提出了一种引导搜索策略来优化图像的增强过程;Zhang 等^[17]提出了一种跨尺度框架,减少了数据非线性映射过程中引入的噪声。近年来很多学者将 Transformer 嵌入到低光增强网络中,但是其对数据的要求过高,导致模型参数过大,如 LLFormer^[18]。此外,扩散模型也被引入低光增强领域,虽然在低光图像增强领域取得了不错的结果,但是其消耗的时间成本不可被忽略^[19-21]。

尽管低光图像增强已经取得实质性进展,但这些方法大多是针对低分辨率图像,在高分辨率低光图像上表现不佳,主要原因是高分辨率图像包含更多的图像细节和更加丰富的颜色信息,对于细节特征的捕获和颜色的恢复有更高的要求^[22-25]。这些方法在处理高分辨率低光图像时,通常会先降低图像的分辨率,这样容易造成细节丢失和颜色失真的问题。目前有一些高分辨率图像增强的算法被提出,如 LLFormer^[18],虽然这些方法在高分辨率低光图像增强上取得了一定的进展,但是因为缺乏全局上下文信息,不能让网络更好地理解场景的全局光照分布,导致在处理光照不均匀图像时会出现曝光的问题。

相比于低分辨率图像,高分辨率图像包含更多的像素和细节信息。例如,高分辨率图像的边缘会更加清晰和明显,可以更好地帮助识别物体的轮廓和形状;并且高分辨率图像保留了更多的颜色信息,可以提供更多关于物体表面特征和材质的线索,有助于更准确地理解物体的属性和环境。由此,边缘和颜色信息对于图像增强任务有着重要的作用。

综上所述,本文利用图像本身保留的边缘纹理和颜色信息作为引导,提出了一种新的高分辨率低光图像增强方法。该方法首先构建了一个共享编码器,使得网络更全面地理解图像中的语义信息,实现边缘和颜色的协同理解。接着分别使用边缘解码器和颜色解码器重建清晰的图像边缘信息和颜色信息,并利用获得的边缘信息和颜色信息生成最终的增强结果。为了解决高分辨率图像处理时细节信息量过于庞大的问题,边缘解码器引入了上下文注意力块,让模型更高效地捕获关键内容。颜色解码器利用低光图像本身所包含的色度信息提供线索,帮助网络恢复适当的颜色,同时解决了高分辨率图像处理过程中出现的颜色超出其边界的问题。实验结果表明,提出的方法优于现有的方法,并且能够取得不错的高分辨率低光图像增强结果。

本文的主要贡献如下:

1)构建了一个共享编码器,更全面地理解低光图像中的纹理和颜色信息,提高了网络在多任务处理中的性能和效率;

2)为了获得图像中长距离上下文信息,边缘解码器引入了一个基于稀疏注意力机制的上下文注意力块,通过关注重要内容解决了高分辨率图像处理时细节信息量过于庞大的问题;

3)构建的颜色解码器利用门控卷积有效嵌入图像的色度信息,帮助模型学习到图像中的真实颜色分布,进行色彩校正,使得恢复图像的色彩更加自然和准确。

2 相关工作

2.1 低分辨率低光图像增强算法

1)传统方法。一种典型的传统方法是利用直方图均衡法恢复照明^[26],通过寻找变换函数,使强度直方图具有均匀性,从而提高图像的对比度。此外,基于直方图均衡的方法可以分为全局直方图均衡^[27]、局部直方图均衡^[28]、自适应直方图均衡^[29]、限制对比度自适应直方图均衡^[30]等。虽然这些方法可以增强图像,但由于灰度合并,它们可能会丢失一些细节信息。另一种典型的传统方法是利用 Retinex 理论^[31],它恢复一个照明映射来增强图像。Dong 等^[32]使用去雾方法来实现照明增强。Wang 等^[33]提出了一种双对数变换和光通滤波器来实现图像细节和照度的平衡。

2)深度学习方法。许多基于学习的方法已经被提出来进行低光图像增强。LLNet^[12]使用了叠加稀疏去噪自动编码器^[34]的一种变体来同时提亮和去噪低光图像。Lv 等^[35]提出了一种端到端多分支增强网络(MBLEEN)。Ren 等^[36]设计了一个更复杂的端到端网络,其中包括一个用于图像内容增强的编码器-解码器网络和一个用于图像边缘增强的递归神经网络。与 Ren 等^[36]类似,Zhu 等^[37]提出了一种称为 EE-MEFN 的方法。此外,还有学者引入了金字塔网络(LP-Net)^[38]、残差网络^[39]和拉普拉斯金字塔^[40]来解决这一问题,这些方法可以通过共同的端到端网络结构学习集成特征表示。虽然上述方法可以获得良好的性能,但由于使用了合成的训练数据,它们在现实的低光环境中表现出了较差的泛化性。为了解决这个问题,一些工作试图综合更真实的训练数据或获得真实世界的训练数据,如 LOL^[41]。Wang 等^[42]提出了一种新型的流正则化模型 LLFlow,利用正则化流约束有助于调整图像亮度,同时抑制图像伪影。最近,一些研究试图使用级联融合网络搜寻适合低光增强的网络结构,但由于他们使用 Retinex 理论知识作为先验知识,尽管能在图像增强方面取得比较好的结果,但是容易在最后的增强结果上引入噪声,如 SCI-Net^[43]。同时,扩散模型也应用在低光增强领域之中,如 ExposureDiffusion^[44]。多模态的无监督生成对抗网络解决了训练数据不足的问题,但是对于具有庞大细节信息的高分辨率图像,其不能提供准确的物体的轮廓和边界信息,使增强结果存在细节不清晰、颜色失真的问题,如 NeR-CoGAN^[45]。然而,这些深度学习方法都是在低分辨率低光图像数据集上进行设计的,由于没有考虑高分辨率图像中更丰富和具体的细节信息和颜色信息,这些方法应用到高分辨率图像中容易产生细节不清晰、颜色失真等问题,因为高分辨率图像中的更多细节可能需要更加复杂的模型和更丰富的特征表示。

2.2 高分辨率低光图像增强算法

目前有一些高分辨率图像增强的算法被提出,如 LL-Former^[18]。现有的高分辨率低光图像增强算法在考虑高分辨率图像时没有参考其上下文信息,在多样化的场景下不能全面地考量图像的细节,导致图像细节丢失和伪影的产生。

3 高分辨率低光增强模型

本文提出了一个新的高分辨率低光图像增强模型,利用图像自身所包含的纹理信息和颜色信息恢复图像中的光照及对比度,为低光图像重建一张新的正常光照图像。

3.1 模型整体架构

低光图像中的语义信息主要包括边缘纹理和颜色信息,这些特征有助于更好地理解和学习图像的语义信息。因此,本文从边缘和颜色两个方向分别进行信息恢复,为模型提供更为丰富的背景知识,从而更准确地理解和处理图像,帮助网络更好地完成图像增强任务。其中,边缘特征能够更准确地捕捉物体边界和结构信息,而颜色特征可

以提供物体的表面特征和颜色分布,有助于提高模型对图像整体色彩的还原和保真度。通过将这两种信息结合起来,神经网络能够更准确地理解图像中的语义信息。

本文提出的模型旨在处理低光图像。如图 1 所示,首先构建一个共享编码器对输入的低光图像进行特征提取,然后利用一个边缘解码器和一个颜色解码器对提取的特征进行解码,从而获得清晰的图像边缘信息和颜色信息。为了更好地利用图像中的有效信息,颜色解码器将低光图像的 HSV 颜色图作为辅助信息,帮助网络更好地恢复图像的颜色。此外,本文方法使用 canny 边缘检测算法提取了低光图像的边缘图,将边缘图和低光图像进行分块,并将获得的图像块作为边缘解码器的输入,帮助边缘解码器生成一张清晰的图像边缘图。由于恢复的边缘结果图和颜色结果图涉及到两个不同域的信息,为了确保来自不同任务的信息能够得到有效的协同表达,模型利用两个特征融合块对颜色信息和边缘进行整合,生成最终的高质量图像增强结果。

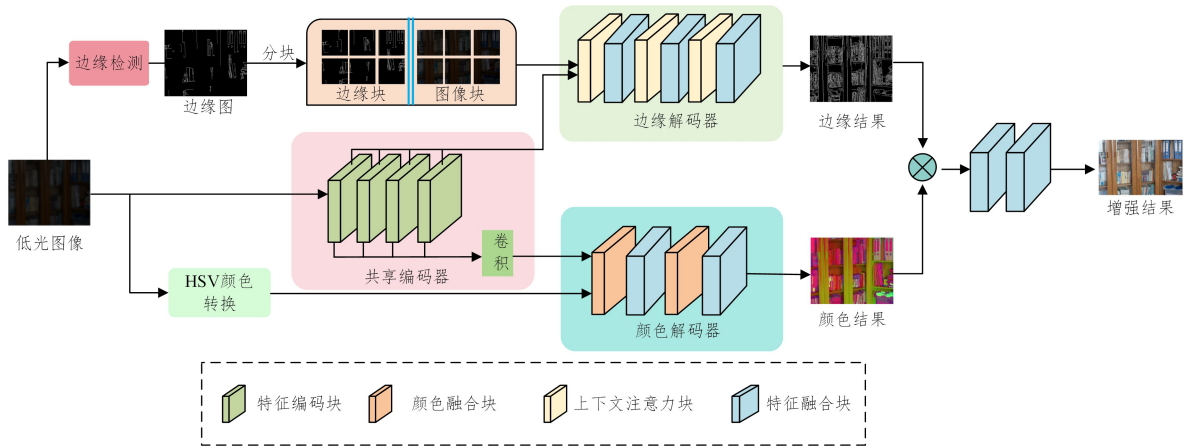


图 1 网络的整体结构模型

Fig. 1 Overall structure of network

3.2 共享编码器

在多任务学习中,网络被设计为能够共享一些层次的特征表示,以便同时学习多个相关的任务。这种共享的架构有助于提高模型的性能,特别是当多个任务之间存在相关性时。受此启发,低光图像中的语义信息主要包括边缘纹理和颜色信息,这是两个存在关联性的任务。其中,边缘结构对于低光照图像的恢复至关重要,因为它能够指导网络在何处应用相应的颜色。为了更有效地处理这两个任务,本文构建了一个共享编码器,其能够同时进行边缘特征和颜色特征的提取。

共享编码器实现了边缘信息和颜色信息的交流,使得网络能够更全面地理解低光图像中的语义信息及内容结构特征,实现边缘和颜色的协同恢复,帮助提高网络对于低光图像的恢复能力。

共享编码器包含 4 个特征编码块。4 个特征编码块获取的特征整合后一起输入到边缘解码器中,而颜色解码器仅使用了前 3 个特征编码块的特征,并经过一个 3×3 的卷积和 ReLU 激活函数之后再作为其输入。这种特征使用方式使得边缘解码器和颜色解码器能够在特定的层次上获取最具信息量的特征,专注于适当的特征提取,提高了网络在多任务处理中的性能和效率。特征编码块的结构如图 2 所示,输入的特

征首先经过两层 3×3 卷积和一个 ReLU 激活函数,获得的特征分别进行 1×1 卷积与 3×3 卷积,将两个卷积的结果相乘以获得全局的特征图;然后使用 1×1 的卷积调整特征图的通道数,使其与输入的特征图通道数对应;最后进行逐元素相加,让特征图中带上全局的信息。




图 2 特征编码块的结构

Fig. 2 Structure of feature coding blocks

3.3 边缘解码器

现有的高分辨率低光照图像增强网络模型并没有考虑到图像本身包含的长距离上下文信息,而由于光照不均匀,部分反射材质在图像的局部会出现过度曝光和失真,造成局部特征失真。由于边缘特征通常具有较高的信息密度,代表了图像中物体的边界和轮廓信息,因此,利用边缘特征来获取上下文注意力可以更有效地聚焦于图像中的关键区域,避免被无

关信息干扰。基于此,本文在边缘解码器中引入上下文注意力块,提升模型对高分辨率图像复杂结构的理解。如图 1 所示,边缘解码器由 4 个上下文注意力块组成。为了防止在进行针对高分辨率图像的庞大数据计算时出现梯度爆炸的问题,在每个上下文注意力块之后添加了一个具有残差结构的特征融合块。

特征融合块的网络结构如图 3 所示,首先对输入特征进行 1 次 1×1 卷积调整并输入特征的通道数,再进行 3 次 3×3 卷积操作,并且每个卷积后使用 ReLU 函数作为激活函数,最后使用一个 1×1 卷积调整特征通道数,得到特征 D_1 。同时,再次对输入特征进行一次 1×1 卷积操作来获取全局特征,并与特征 D_1 进行逐元素相乘,得到调合特征 D_2 。为了构成残差结构,防止网络训练过程中的梯度爆炸,将 D_2 与输入特征进行相加,生成最终的特征融合块结果。




图 3 特征融合块的结构

Fig. 3 Structure of feature fusion blocks

Transformer 模型可以通过计算图像中所有相关的信息来捕捉高分辨率图像中的长距离依赖关系,这在众多高级和低级计算机视觉任务中得到了充分验证。但是这种直接获取的全局注意力图容易被不相干的信息干扰,尤其是对于噪声污染严重的低光图像,导致拟合了不需要的信息,产生错误的推理结果。考虑到高分辨率图像包含了丰富的信息,为了排除干扰信息,本文提出了基于稀疏注意力的上下文注意力块,让模型关注主要图像内容,更高效地捕获关键信息。

上下文注意力块包括两部分,如图 4 所示。首先,将输入图像和检测的边缘图分解为大小为 $q \times q$ 的图像块,并将其输入到稀疏注意力机制中计算全局注意力分布,获得注意力权重 Attention。实验中根据经验将 q 设置为 3。另一方面,共享编码器的结果经过一次 1×1 卷积进行维度的变换,并利用 3×3 卷积捕捉更大范围的特征和一个 ReLU 激活函数进行非线性映射,这样有助于捕获数据中的复杂模式。最后通过一个 1×1 的卷积调整大小,并将获得的结果 F_{in} 与注意力权重 Attention 进行逐元素相乘,得到边缘增强结果,再利用一个残差结构防止训练过程中的梯度爆炸。




图 4 上下文注意力块的结构

Fig. 4 Structure of context attention blocks

为了更有效地理解图像内容,本文使用稀疏注意力来提取图像的注意力信息,具体包括全局注意力机制、梯度注意力机制和扩张滑动窗口注意力机制,如图 5 所示。通过稀疏注意力的热力图了解 3 种注意力机制的关注内容,如图 6 所示。与自注意力不同的是,自注意力允许每个位置关注到其他位

置的信息,而全局注意力专注于整个低光图像的信息。本文采用全连接层等方法来获取全局信息,最终应用 Softmax 函数来获得全局注意力分布 $Attention_{global}$ 。这种方法的目的是强调整个图像中的全局特征,以便网络更全面地理解低光条件下的图像内容。全局注意力表示为:

$$Attention_{global} = S(FC(F_{input}, F_{edge}))$$

其中, S 表示 Softmax 函数, FC 表示全连接层, F_{input} 表示输入图像的特征图, F_{edge} 表示输入图像的边缘图。

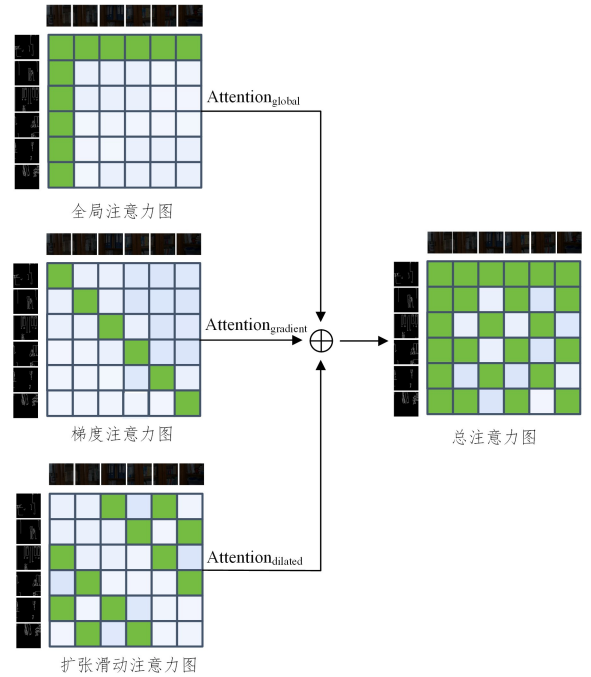


图 5 稀疏注意力的计算图

Fig. 5 Computational maps for sparse attention

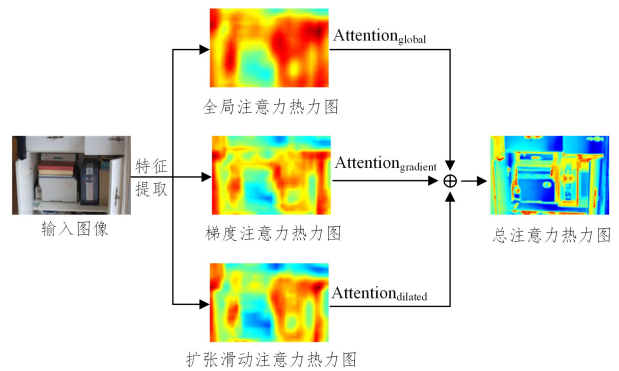


图 6 稀疏注意力的热力图

Fig. 6 Heat maps for sparse attention

在图像处理领域,边缘通常表现为图像强度的显著变化,梯度则用于量化图像中像素强度的变化程度。由于边缘具有明显的梯度变化,因此关注梯度变化可以有效捕捉图像中的边缘信息。然而,在低光图像中,由于局部亮度的不一致性,边缘特征变得不够显著。为了优化低光图像的梯度特征,以增强网络对边缘特征的学习能力,通过学习的方式对低光图像的梯度特征进行了优化。乘法运算在图像处理中主要用于实现图像的掩膜处理,即屏蔽或加强图像中的特定部分。本文使用图像的乘法运算来精细调节梯度特征,以便更有效地突显低光图像中的边缘信息。这一策略旨在提升网络对于低

光条件下边缘特征的表示和理解能力。梯度注意力表示为:

$$Attention_{\text{gradient}} = GN \left(\frac{\partial(F_{\text{input}} * F_{\text{edge}})}{\partial F_{\text{input}}} \right)$$

其中, GN 表示梯度归一化(Gradient Normalization)操作, $*$ 表示像素点乘, F_{input} 表示输入图像的特征图, F_{edge} 表示输入图像的边缘图。

在扩张窗口注意力机制中,通过设计扩张模式,能够更有效地捕捉图像中的远程关系。然而,扩张注意力也可能导致连接模式中出现间隙或扩张,因为在注意力模式中一些标记可能被跳过。这些被忽略的标记在其他注意力机制中可能得到关注并被记录下来。因此,在扩张滑动窗口注意力机制中,本文根据经验选择了扩张率为 2 的感受野,以在更大范围内有效地捕捉图像中的关联关系,同时避免过度的间隙和扩张现象。这种选择旨在平衡扩张的范围和保持对关键信息的准确关注。扩张窗口注意力表示为:

$$Attention_{\text{dilated}} = S \left(\frac{\mathbf{W}_Q (\mathbf{W}_K)^T}{\sqrt{d_k}} \right) \mathbf{W}_V$$

本文对共享编码器推理结果进行一次全连接,获得的结果记为 $\mathbf{W}_Q, \mathbf{W}_K, \mathbf{W}_V$ 。 S 是 Softmax 函数,用于归一化 \mathbf{W}_Q 和 \mathbf{W}_K 转置相乘之后的结果, d_k 是 $\mathbf{W}_Q, \mathbf{W}_K, \mathbf{W}_V$ 的维度。

因此,本文计算的注意力权重可表示为:

$$Attention = (1 - \alpha - \beta) Attention_{\text{global}} + \alpha Attention_{\text{gradient}} + \beta Attention_{\text{dilated}}$$

其中, α 和 β 是根据实验调整的超参数,根据经验设置为 0.32 和 0.4。

3.4 颜色解码器

在低光图像中仍然存在大量的颜色信息,可以为网络提供线索恢复图像的正常颜色信息。颜色解码器使用门控卷积嵌入低光图像的颜色信息,为模型提供额外的颜色特征,帮助模型学习到图像中的真实颜色分布,进行色彩校正,使生成的色彩更加自然和准确。颜色解码器包含两个颜色融合模块,与边缘解码器相同,为了防止梯度爆炸等问题,在每个颜色融合模块后面添加了特征融合块。

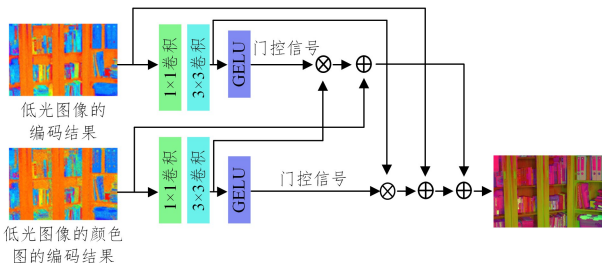


图7 颜色融合块的结构

Fig. 7 Structure of color fusion blocks

低光图像中不仅存在不少颜色信息,还包含许多无用信息,为了获得更有效的颜色信息,颜色融合模块使用 GELU 和输入特征进行元素相乘过滤掉无用的信息,并通过双重门控机制融合相关有用信息,帮助网络生成更有效的颜色图。如图 7 所示,对从共享编码器中提取的特征以及 HSV 颜色图特征分别进行两次卷积,用于丰富局部特征,并使用 GELU 激活函数,然后把两个结果作为门控信号,进行联合控制特征的融合。

3.5 网络损失函数

为了获得稳定的参数,设计网络模型的损失函数包含 3 部分,重建损失、边缘损失和颜色损失。

重建损失是为了考量网络的重建正常光图像的能力,采用均方误差(Mean Square Error, MSE)损失,定义为:

$$L_{\text{recons}} = \frac{1}{N} \sum_{i=1}^N (I_{\text{enhance}} - I_{\text{gt}})^2$$

其中, N 为图像个数, I_{enhance} 为网络增强结果, I_{gt} 为真实正常光照图像。

边缘损失主要用来优化边缘解码器,本文利用 Canny 算法对正常光照图像进行处理,获取正常光照下的边缘图来约束边缘解码器的推理能力。边缘损失函数的定义为:

$$L_{\text{edge}} = \frac{1}{N} \sum_{i=1}^N (I_{\text{enhance}} - \text{Canny}(I_{\text{gt}}))^2$$

其中, N 为图像个数, I_{enhance} 为网络增强结果, I_{gt} 为真实正常光照图像, $\text{Canny}(\cdot)$ 表示 Canny 边缘检测函数。

颜色损失的目的是为了使增强的目标颜色更加符合人眼对颜色的感知。在计算颜色损失时引入颜色感知权重,在 LAB 颜色空间上计算颜色损失,其中 L 表示亮度, a 表示绿-红轴, b 表示蓝-黄轴。对于颜色感知损失,在 a 和 b 通道上引入权重 w_a 和 w_b ,颜色损失的定义为:

$$L_{\text{color}} = \frac{1}{N} \sum_{i=1}^N (w_a * (a_{\text{enhance}} - a_{\text{gt}})^2 + w_b * (b_{\text{enhance}} - b_{\text{gt}})^2)$$

其中, a_{enhance} 为网络增强图像在 LAB 颜色空间上 a 通道的通道值, b_{enhance} 为网络增强图像在 LAB 颜色空间上 b 通道的通道值, a_{gt} 为真实正常光照图像在 LAB 颜色空间上 a 通道的通道值, b_{gt} 为网络增强图像在 LAB 颜色空间上 b 通道的通道值。

最终,图像增强网络的整体损失如下:

$$L = L_{\text{recons}} + \lambda_{\text{edge}} L_{\text{edge}} + \lambda_{\text{color}} L_{\text{color}}$$

其中, λ_{edge} 和 λ_{color} 是用来平衡的超参数。

4 实验与结果

4.1 数据集

本文使用来自 GLAD 数据集的 4500 对低光和正常亮度图像进行训练,并使用剩余的 523 对图像进行测试。此外,还在 UHD-LOL4K, MIT-Adobe FiveK 和 SID 数据集上进行了测试。在 UHD-LOL4K 数据集上选择了 2100 对低光图像进行测试。MIT-Adobe FiveK 测试数据集包含 500 对图像。对于 SID 数据集,选择了索尼相机拍摄的图像进行评估,并选择 1196 对图像进行测试。

4.2 实验细节

本文利用 PyTorch 实现网络模型的整体框架,并在一张 RTX 3090 GPU 的 Linux 系统上进行了训练和测试。在模型的训练阶段,将所有的图像大小调整为 400×600 ,并且没有对输入图像做任何的增强操作。对于 LOL 数据集,训练 200 个 epoch。增强网络由 SGD 训练,动量设置为 0.9,编码器的初始学习率设置为 2×10^{-4} ,解码器学习率设置为 2×10^{-3} ,学习率通过 2 次多项式衰减降低。超参数 $w_a, w_b, \lambda_{\text{edge}}$ 和 λ_{color} 分别设置为 0.000007, 0.0000005, 0.00000005 和 0.000002。

4.3 定量分析

表 1 列出了在 GLAD, UHD-LOL4K, MIT-adobe 和 SID 数据集上本文模型和现有方法的定量结果比较。本文方法在 4 个数据集上都优于对比模型。评估指标为 PSNR 和 SSIM。

表 1 评估得分对比

Table 1 Comparison of evaluation scores

方法	GLAD		UHD-LOL4K		MIT-Adobe		SID	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
SCI-Net ^[43]	23.48	0.84	36.01	0.98	20.45	0.89	36.09	0.59
LLflow ^[42]	24.32	0.84	37.29	0.97	23.22	0.91	34.33	0.61
LLFormer ^[18]	24.09	0.82	37.33	0.98	25.75	0.92	35.25	0.62
ExposureDiffusion ^[44]	24.69	0.88	37.54	0.98	25.81	0.92	38.88	0.90
NeRCoGAN ^[45]	24.72	0.88	37.61	0.98	24.95	0.90	37.52	0.83
Ours	27.20	0.92	38.36	0.99	26.21	0.93	39.36	0.92

4.4 定性结果

本文在高分辨率低光图像上也进行了可视化,结果如图 8 所示,生成的结果细节非常充分和自然。同时可视化了部分对比模型的低光图像增强结果(包含现有效果最好的模型)。图 9 给出了定性比较的结果,虽然测试时不需要正常光照图像,但是为了更好地可视化比较,图中仍然显示了它们。SCI-Net^[43]使用 Retinex 理论^[5]作为先验知识消除噪声,但它们可能引入其他曝光因素,导致细节信息缺失的问题,如图 9(b)所示。LLflow^[42]的结果也可能出现颜色退化,在高分辨率图像中会出现一些伪影,如图 9(c)所示。LLFormer^[18]仅

学习图像的长距离相关性,导致高分辨率图像的上下文细节信息并不完善,增强的结果会出现亮度不均衡,如图 9(d)所示。ExposureDiffusion^[44]虽然在抑制噪声方面取得了不错的结果,但是在处理光照不均匀的低光图像时,仍然会出现曝光的问题,如图 9(e)所示。NeRCoGAN^[45]在多模态的生成对抗网络方面有较好的生成结果,但是由于在处理高分辨率图像时没有考虑高分辨率低光图像带来的庞大细节信息,在生成结果中容易出现伪影和亮度增强不佳的问题,如图 9(f)所示。本文方法能够生成令人满意的结果,如图 9(g)所示。

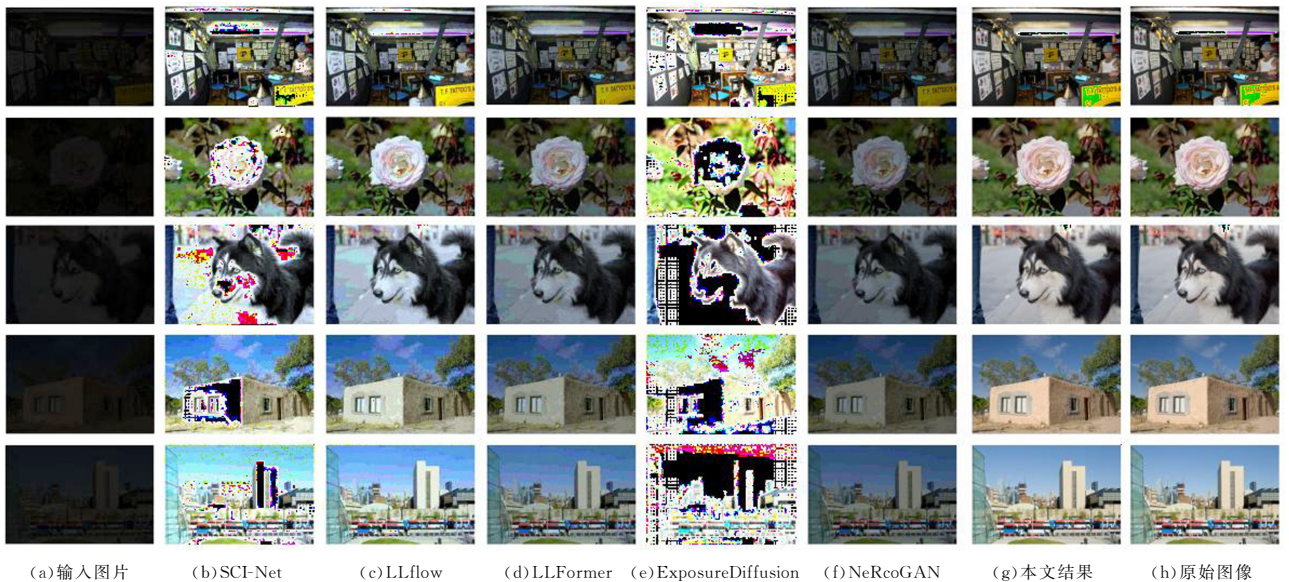


(a) 高分辨率低光图像

(b) 增强结果

图 8 高分辨率低光图像的增强结果

Fig. 8 Enhancement results of high-resolution low-light images



(a) 输入图片

(b) SCI-Net

(c) LLflow

(d) LLFormer

(e) ExposureDiffusion

(f) NeRCoGAN

(g) 本文结果

(h) 原始图像

图 9 对比实验的可视化结果

Fig. 9 Visualisation results of comparative experiments

4.5 消融实验

为了进一步评估模型中使用到的每个组件的性能, 通过从模型中删除不同的组件, 考虑了几种消融变体设置。

变体 1 低光图像增强网络中去掉全局注意力。

变体 2 低光图像增强网络中去掉梯度注意力。

变体 3 低光图像增强网络中去掉扩张窗口注意力。

变体 4 低光图像增强网络中去除边缘预测分支。

变体 5 低光图像增强网络中去除颜色预测分支。

我们在 GLAD 数据集上训练这 5 组消融设置, 并在 GLAD 和 UHD-LOL4K 数据集上评估了实验结果。从变体 1—变体 3 看出, 去除全局注意力后, 如图 10(b) 所示, 图像曝光程度加深, 说明了其对增强图像曝光水平的控制作用; 去除梯度注意力后, 如图 10(c) 所示, 图像边缘出现伪影和噪点, 说明了其对增强图像边缘信息稳定性的控制作用; 去除扩张窗口注意力后, 如图 10(d) 所示, 图像亮度增强变弱, 图像变暗, 同时出现了细节信息丢失的问题, 说明了其能够增强对图

像细节信息的恢复。通过表 2 可以看出, 移除任何一项都会使评价指标出现一定程度的下降, 同时使用全局注意力、梯度注意力和扩张窗口注意力可以在高分辨率低光图像上关注到更多的细节信息, 有助于网络获得更好的结果。图 10 中, 第 2, 4, 6 行的 b, c, d 3 列都是针对第 1, 3, 5 行中的低光照图像分别做出的全局注意力、梯度注意力和扩张窗口注意力的热力图结果, 从热力图中可以看出, 单独使用 3 种注意力的信息会比本文提出的做法更粗糙。如图 10 的第 2, 3, 4 行的第 e 列, 是针对第 1, 3, 5 行中的低光照图像使用本文提出的稀疏注意力做出的注意力热力图, 可以看出, 将 3 种注意力整合, 能够获得更加细致的注意力热力图, 进而表明网络能够更加关注图像的细节信息。图 10 的第 2, 3, 4 行的第 f 列, 是将正常光照图像放入网络, 使用本文的注意力获得的网络关注的热力图, 图 10 的第 2, 3, 4 行的第 e 列和第 f 列非常接近, 进一步说明了将 3 种注意力整合, 能够获得与正常光照图像注意力热力图一样的注意力热力图。




图 10 消融实验的可视化结果(I)

Fig. 10 Visualisation results of ablation experiments(I)

表 2 消融实验评估得分对比

Table 2 Comparison of evaluation scores in ablation experiments

方法	GLAD		UHD-LOL4K	
	PSNR	SSIM	PSNR	SSIM
变体 1	21.48	0.72	31.41	0.83
变体 2	20.25	0.69	29.57	0.80
变体 3	21.81	0.72	30.14	0.82
变体 4	22.52	0.79	28.04	0.79
变体 5	24.01	0.82	31.04	0.85
本文方法	27.20	0.92	38.36	0.99

从图 11 中变体 4 和变体 5 可以看出, 边缘预测分支和颜

色预测分支的设计可以提升高分辨率低光图像的增强效果, 从图 11(b) 中可以看出, 去掉了边缘预测分支后图像的曝光比较严重, 缺少边缘信息可能导致颜色在图像中扩散, 因为边缘预测有助于模型更好地地区分物体之间的边界, 说明边缘预测分支可以给网络提供更加清楚的边缘信息, 使网络对图像的细节信息有更强的感知能力。同时, 在图 11(c) 中, 因为去掉了颜色预测分支, 图像的整体恢复和亮度恢复比较模糊, 说明颜色预测分支可以很好地增强图像的整体亮度效果和准确的颜色, 使网络对图像的颜色信息有更强的感知。



图 11 消融实验的可视化结果(II)

Fig. 11 Visualisation results of ablation experiments(II)

结束语 本文利用图像自身所包含的纹理信息和颜色信息提出了一种边缘和颜色信息引导的高分辨率低光照图像增强网络,从边缘和颜色两个方面分别进行信息恢复,帮助网络更好地完成图像增强任务。提出的共享编码器实现了边缘信息和颜色信息的交流,使得网络能够更全面地理解低光图像中的语义信息。所提方法在边缘解码器中引入了基于稀疏注意力机制的上下文注意力块,有利于捕获长距离的关键信息,解决了高分辨率图像中信息量过大的问题。此外,颜色解码器利用门控卷积有效地嵌入了低光图像中所包含的色度信息,更好地帮助网络恢复低光图像的颜色。实验结果表明,提出的方法在高分辨率图像上取得了不错的恢复结果。

参考文献

- [1] WANG B, LIANG Y D, LIU Z, et al. Study on Unsupervised Image Dehazing and Low-light Image Enhancement Algorithms Based on Luminance Adjustment[J]. *Computer Science*, 2023, 50(1):123-130.
- [2] LI L, LIU X L, ZHAO Y, et al. Low Light Image Fusion Detection Method Based on Lego Filter and SSD[J]. *Computer Science*, 2021, 48(7):213-218.
- [3] PISANO E D, ZONG S, HEMMINGER B M, et al. Contrast limited adaptive histogram equalization image processing to improve the detection of simulated speculations in dense mammograms[J]. *Journal of Digital Imaging*, 1998, 11(4):193-200.
- [4] HOU L X, NIE F Y, WAN L Y. Multiscale adaptive Gamma correction for low-light image enhancement[J]. *Journal of Yunnan University(Natural Sciences Edition)*, 2023, 45(1):57-66.
- [5] LI M, LIU J, YANG W, et al. Structure-revealing low-light image enhancement via robust retinex model[J]. *IEEE Transactions on Image Processing*, 2018, 27(6):2828-2841.
- [6] WANG W, WEI C, YANG W, et al. Gladnet: Low-light enhancement network with global awareness[C] // 2018 13th IEEE International Conference on Automatic Face & Gesture Recognition(FG 2018). IEEE, 2018:751-755.
- [7] WANG R, XU X, FU C W, et al. Seeing dynamic scene in the dark: A high-quality video dataset with mechatronic alignment [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2021:9700-9709.
- [8] LIU R, MA L, ZHANG J, et al. Retinex-inspired unrolling with cooperative prior architecture search for low-light image enhancement[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021:10561-10570.
- [9] ZHAO Z, XIONG B, WANG L, et al. RetinexDIP: A unified deep framework for low-light image enhancement[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2021, 32(3):1076-1088.
- [10] LI J, FENG X, HUA Z. Low-light image enhancement via progressive-recursive network[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2021, 31(11):4227-4240.
- [11] WANG R, XU X, FU C W, et al. Seeing dynamic scene in the dark: A high-quality video dataset with mechatronic alignment [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2021:9700-9709.
- [12] LORE K G, AKINTAYO A, SARKAR S. LLNet: A deep autoencoder approach to natural low-light image enhancement[J]. *Pattern Recognition*, 2017, 61:650-662.
- [13] JIANG Y, GONG X, LIU D, et al. Enlightengan: Deep light enhancement without paired supervision[J]. *IEEE Transactions on Image Processing*, 2021, 30:2340-2349.
- [14] GUO C, LI C, GUO J, et al. Zero-reference deep curve estimation for low-light image enhancement[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020:1780-1789.
- [15] ZHU A, ZHANG L, SHEN Y, et al. Zero-shot restoration of underexposed images via robust retinex decomposition[C] // 2020 IEEE International Conference on Multimedia and Expo (ICME). IEEE, 2020:1-6.
- [16] COTOGNI M, CUSANO C. TreEnhance: A tree search method for low-light image enhancement[J]. *Pattern Recognition*, 2023, 136:109249.
- [17] ZHANG Y, LIU H, DING D. A cross-scale framework for low-light image enhancement using spatial-spectral information[J]. *Computers and Electrical Engineering*, 2023, 106:108608.

- [18] WANG T, ZHANG K, SHEN T, et al. Ultra-high-definition low-light image enhancement: A benchmark and transformer-based method[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2023, 37(3): 2654-2662.
- [19] TRIANTAFYLIDOU D, MORAN S, MCDONAGH S, et al. Low light video enhancement using synthetic data produced with an intermediate domain mapping[C]//Computer Vision—ECCV 2020: 16th European Conference, Glasgow, UK, Part XIII 16. Springer International Publishing, 2020: 103-119.
- [20] LU K, ZHANG L. TBEFN: A two-branch exposure-fusion network for low-light image enhancement[J]. IEEE Transactions on Multimedia, 2020, 23: 4093-4105.
- [21] WU W, WENG J, ZHANG P, et al. Uretinex-net: Retinex-based deep unfolding network for low-light image enhancement[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2022: 5901-5910.
- [22] WU J F, ZHAO X G, ZHOU Q, et al. Contrastive Learning for Low-light Image Enhancement [J]. Computer Science, 2023, 50(S1): 525-530.
- [23] ZHAO M H, WEN Y C, DU S L, et al. Low-light image enhancement algorithm based on illumination and scene texture attention map[J]. Journal of Image and Graphics, 2024, 29(4): 862-874.
- [24] HE L, YI Z H, XIE Y F, et al. Fast enhancement method for low light images guided by Retinex prior [J]. Acta Automatica Sinica, 2024, 50(5): 1-12.
- [25] JIANG Z T, QIN L L, Qin J Q, et al. Low-light image enhancement method based on MDARNet [J]. Journal of Software, 2021, 32(12): 3977-3991.
- [26] SENTHILKUMARAN N, THIMMIARAJA J. Histogram equalization for image enhancement using MRI brain images [C]//2014 World Congress on Computing and Communication Technologies. IEEE, 2014: 80-83.
- [27] YUN S H, KIM J H, KIM S. Image enhancement using a fusion framework of histogram equalization and Laplacian pyramid[J]. IEEE Transactions on Consumer Electronics, 2010, 56(4): 2763-2771.
- [28] SENTHILKUMARAN N, THIMMIARAJA J. Histogram equalization for image enhancement using MRI brain images [C]//2014 World Congress on Computing and Communication Technologies. IEEE, 2014: 80-83.
- [29] SURESHA M, RAGHUKUMAR D S, KUPPA S. Kumaraswamy distribution based bi-histogram equalization for enhancement of microscopic images [J]. International Journal of Image and Graphics, 2022, 22(1): 2250003.
- [30] SINGH P, MUKUNDAN R, DE RYKE R. Feature enhancement in medical ultrasound videos using contrast-limited adaptive histogram equalization[J]. Journal of Digital Imaging, 2020, 33: 273-285.
- [31] LAND E H. The retinex theory of color vision[J]. Scientific American, 1977, 237(6): 108-129.
- [32] DONG X, PANG Y, WEN J. Fast efficient algorithm for enhancement of low lighting video[C]//2011 IEEE International Conference on Multimedia and Expo. 2011.
- [33] WANG S, ZHENG J, HU H M, et al. Naturalness preserved enhancement algorithm for non-uniform illumination images[J]. IEEE Transactions on Image Processing, 2013, 22(9): 3538-3548.
- [34] JAIN V, SEUNG S. Natural image denoising with convolutional networks[C]//Proceedings of the 22nd International Conference on Neural Information Processing Systems. 2008: 769-776.
- [35] LV F, LU F, WU J, et al. MBLLEN: Low-Light Image/Video Enhancement Using CNNs[C]//BMVC. 2018.
- [36] REN W, LIU S, MA L, et al. Low-light image enhancement via a deep hybrid network[J]. IEEE Transactions on Image Processing, 2019, 28(9): 4364-4375.
- [37] ZHU M, PAN P, CHEN W, et al. Eemefn: Low-light image enhancement via edge-enhanced multi-exposure fusion network [C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2020, 34(7): 13106-13113.
- [38] LI J, LI J, FANG F, et al. Luminance-aware pyramid network for low-light image enhancement [J]. IEEE Transactions on Multimedia, 2020, 23: 3153-3165.
- [39] WANG L W, LIU Z S, SIU W C, et al. Lightening network for low-light image enhancement[J]. IEEE Transactions on Image Processing, 2020, 29: 7984-7996.
- [40] LIM S, KIM W. DSLR: Deep stacked Laplacian restorer for low-light image enhancement[J]. IEEE Transactions on Multimedia, 2020, 23: 4272-4284.
- [41] WEI C, WANG W, YANG W, et al. Deep retinex decomposition for low-light enhancement[J]. arXiv:1808.04560, 2018.
- [42] WANG Y, WAN R, YANG W, et al. Low-light image enhancement with normalizing flow[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2022, 36(3): 2604-2612.
- [43] MA L, MA T, LIU R, et al. Toward fast, flexible, and robust low-light image enhancement [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2022: 5637-5646.
- [44] WANG Y, YU Y, YANG W, et al. Exposediffusion: Learning to expose for low-light image enhancement[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. 2023: 12438-12448.
- [45] YANG S, DING M, WU Y, et al. Implicit neural representation for cooperative low-light image enhancement[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. 2023: 12918-12927.



ZHANG Ling, born in 1986, Ph.D, associate professor. Her main research interests include image and video editing, and computational photography.