

基于改进 CycleGAN 的低光域图像增强模型

刘尚东, 吴健, 徐鹤, 季一木

1. 南京邮电大学计算机学院、软件学院、网络空间安全学院, 南京 210023;
2. 江苏省高性能计算与智能处理工程研究中心, 南京 210023

摘要: 传统的循环生成对抗网络 (Cycle Generative Adversarial Network, CycleGAN) 作为一种无需成对数据集的图像风格迁移模型, 在低光域图像增强任务中, 存在生成图像细节丢失、色彩失真以及复杂场景下适应性较差等问题。基于此, 本文提出了一种改进型的 CycleGAN 模型, 旨在提升低光域图像增强效果。首先, 在生成器设计上, 通过在上采样阶段集成二阶段色彩校正模块, 旨在缓解低照度环境下色彩失真和质量退化的问题。其次将通道-空间混合注意力机制嵌入跳跃连接层, 旨在实现特征融合过程中关键信息的自适应增强。然后在判别器设计上, 采用全局-局部判别模式, 使其兼顾全局信息与局部细节的判别能力。最后在损失函数设计上, 在对抗损失的基础上引入感知风格损失和内容损失, 进一步提升生成图像的结构保真度和视觉自然性。通过与多种具有代表性的图像增强模型的主客观实验评估对比, 实验结果表明, 该模型对低光域图像有较好的增强效果, 能够有效增强图像的整体亮度以及局部细节, 同时不会出现色彩失真, 提高了生成图像的质量。

关键词 循环生成对抗网络; 图像增强; 色彩校正; 通道-空间注意力; 卷积神经网络

中图分类号 TP391

A Low-Light Domain Image Enhancement Model Based on Improved CycleGAN

LIU Shangdong, WU Jian, XU He, JI Yimu

1. School of Computer Science, Nanjing University of Posts and Telecommunications, Nanjing 210023;
2. Jiangsu HPC and Intelligent Processing Engineer Research Center, Nanjing 210023

Abstract: The conventional Cycle Generative Adversarial Network (Cycle Generative Adversarial Network, CycleGAN), as an image style transfer model that does not require paired datasets, in the task of low-light domain image enhancement, there are problems such as the loss of details in the generated images, color distortion, and poor adaptability in complex scenarios. Based on this, this paper proposes an improved CycleGAN model which aims to enhance the effect of low - light image enhancement. First, in the design of the generator, a two - stage color correction module is integrated during the upsampling phase to alleviate the problems of color distortion and quality degradation in low - light environments. Second, the channel - spatial hybrid attention mechanism is embedded in the skip connection layer to achieve the adaptive strengthening of key information during the feature fusion process. Then, in the design of the discriminator, a global - local discrimination mode is adopted, enabling it to take into account the discrimination ability of both global information and local details. Finally, in the design of the loss function, perceptual style loss and content loss are introduced on the basis of adversarial loss to further improve the structural fidelity and visual naturalness of the generated images. Through the subjective and objective experimental evaluations and comparison with various representative image enhancement models, the experimental results show that this model has a good enhancement effect on low - light images. It can effectively enhance the overall brightness and local details of the images without causing color distortion, thus it improves the quality of the generated images.

Key words Cycle Generative Adversarial Network; Image Enhancement; Color Correction; Channel-Spatial Attention; Convolutional Neural Network

引言

在数字化浪潮的推动下，图像处理技术持续演进。作为提升视觉信息可用性的关键技术，图像增强被广泛应用于视频监控、自动驾驶、医疗成像等实际场景，旨在提升图像质量，增强下游视觉任务的鲁棒性与准确性。尽管计算机视觉技术已取得显著进展，但低光域环境下的图像质量增强依然是一个极具挑战性的领域^[1]。在低光域环境下，图像常常出现亮度不足、对比度降低、细节模糊及色彩失真的问题，这不仅削弱了视觉感知，也影响了后续任务如目标检测、识别与跟踪的精度。相较于一般图像增强任务，低光域图像增强面临着更加复杂的挑战：在细节层面，图像中有价值的纹理信息常常被噪声掩盖，如何在提升亮度的同时实现细节保真成为难点；在色彩层面，不同光照条件下图像色彩分布存在显著差异，若增强策略处理不当，容易引发色彩偏移或失真，影响增强图像的真实感与自然性。近年来，深度学习技术的快速发展为图像增强带来了新的解决思路^[2]。基于深度卷积神经网络的方法能够通过从海量数据中学习图像的潜在特征，以实现复杂场景的自适应优化。

卷积神经网络（Convolutional Neural Networks, CNN）凭借它自身层次化特征提取的机制，在图像增强领域展现出独特优势。通过多层卷积层与非线性激活函数的组合，CNN 能够有效建模图像的空间相关性，逐层解耦光照衰减、噪声干扰与真实场景间的复杂耦合关系。基于 CNN 的 U-Net 的编码器解码器结构，通过跳跃连接实现多尺度特征融合，有效提升了低光图像的细节恢复能力。然而，标准 CNN 框架在应对极端光照条件下的梯度消失、局部对比度失衡等挑战时仍存在局限。

生成对抗网络（Generative Adversarial Network, GAN）作为一种基于对抗学习的生成式模型^[3]，相较于传统卷积神经网络，在图像增强任务中，其具备更强的图像生成能力，能够学习更复杂的映射关系，从而提升增强结果的真实感和自然度。其中，CycleGAN（Cycle Generative Adversarial Network, CycleGAN）作为一种无需成对训练样本的图像到图像的转换模型^[4]，为解决图像增强问题提供了新的思路。然而，其在应用于低光域图像增强和图像去雾时，仍存在一些不足之处，如生成图像的细节丢失、色彩失真以及对复杂场景的适应性较差等，限制了其在实际场景中的广泛应用。

为解决上述问题，本文提出了一种基于混合注意力的 CycleGAN 低光域图像增强模型。本文的主要研究工作如下：

1) 本文对以 U-Net 结构为生成器的网络模型做出两点改进。首先是在上采样阶段集成二阶段色彩校正模块（Two-Stage Chromatic Correction Module, TCCM），旨在缓解低照度环境导致的色彩失真与质量退化问题。其次，在跳跃连接层加入通道-空间混合注意力模块（Channel-Spatial Hybrid Attention, CSHA），实现特征融合过程中关键信息的自适应增强。

2) 在判别器网络模型上，针对原 CycleGAN 只采用了局部判别机制，对全局光照感知不足。本文采用全局-局部的判别模式，使得判别器同时兼顾全局信息与局部细节的判别能力，以提升生成图像的质量。

3) 在损失函数方面，在对抗损失基础上引入感知风格损失函数和内容损失函数，以增强生成图像的结构保真度与视觉自然性。

本文将针对所提出的改进模型进行全方位阐述，并通过具体实验验证其有效性。

1 相关工作

低光域图像增强方法可根据其实现原理大致分为三类：基于直方图的方法、基于 Retinex 理论的方法^[5]和基于深度学习的方法。基于直方图的方法是通过调整图像的亮度分布，来改善视觉效果。虽然其能够快速实现亮度分布的调整，但常常会出现增强过度 and 细节丢失的问题。基于 Retinex 理论的方法，通过分离光照与反射分量来恢复图像亮度^[6]。然而，其容易产生色彩失真和边缘伪影，而且在极低信噪比条件下，可能出现纹理细节过于平滑与噪声放大共存的悖论。

近年来，随着深度学习技术的持续发展，低光域图像增强领域也取得了显著进展。基于深度学习的方法在低光域图像增强、图像去噪以及图像去雾等图像增强任务中展现出了优越的性能^[7]，其中以卷积神经网络为核心架构的深度学习模型得到了广泛应用。早期的基于深度学习的低光图像增强方法大多采用监督式学习，需要成对的低光图像和正常光照图像作为训练数据。例如，LLNet^[8]采用了一种基于深度自编码器的网络结构，通过学习低光图像与正常光照图像之间的映射关系来实现增强效果。LLFLOW^[9]则通过建模正常曝光图像上的像素分布，提取图像的局部像素相关性和全局图像特性，从而提高整体图像的质量。

为了解决监督式学习方法对成对数据的依赖,无监督学习方法近年来逐渐备受关注.其中,CycleGAN 作为一种无监督的生成对抗网络,被广泛应用于低光图像增强任务.它通过引入循环一致性损失,确保了低光域和正常光域之间转换过程中保持的内容一致性.然而,CycleGAN 在增强图像的结构细节恢复方面存在不足.

针对传统 CycleGAN 的不足,学者们提出了一系列改进方法.Cycle-Retinex^[10]结合了 Retinex 理论和 CycleGAN 模型,将低光图像增强任务分解为照度图增强和反射图复原两个子任务,从而在增强光照的同时更好地恢复图像的结构细节.Cycle-Interactive GAN^[11]通过引入弱光引导变换,在增强 GAN 和退化 GAN 之间传递图像特征,实现了低光图像与正常光图像之间的光照分布和细节信号的有效传递.其特征随机扰动模块能够合成真实感噪声,进一步提高了增强图像的质量.CycleGAN-Turbo^[12]将 CycleGAN 与扩散模型结合,通过将标准潜在扩散模型的各个模块合并为一个端到端生成网络,提高了模型在非成对图像转换任务中的效率和性能.有学者通过在生成器中加入自注意力模块^[13],模型能够更好地捕捉图像中的全局依赖关系,从而在生成图像时保留更多的细节和结构信息.也有学者从多尺度特征融合的角度改进,通过通过在生成器中引入多尺度特征提取模块^[14],模型能够同时处理图像的全局特征和局部细节,从而提高生成图像的质量.

2 提出的模型架构

针对传统循环生成对抗网络在低光域图像增强中可能出现细节丢失及色彩失真等问题,本文提出了一种基于混合注意力的 CycleGAN 低光域图像增强模型.该模型通过以 U-Net 网络^[15]为生成器网络,并结合注意力机制和色彩校正模块,旨在提高生成器对低光域图像光线增强和色彩增强的效果;同时判别器采用全局-局部的判别机制,使其兼顾全局信息和局部细节的判断能力.最后通过引入感知风格损失和内容损失两种损失函数,进一步提升生成图像的结构保真度和视觉自然性.




图 1 循环生成对抗网络架构图

Fig.1 Architecture Diagram of Cycle Generative Adversarial Network

2.1 U-Net 网络的生成器

CycleGAN 默认采用残差神经网络（Residual Neural Network, ResNet）^[16]作为生成器网络,尽管其在常规图像风格迁移中展现出出色性能,但在低光域图像增强任务中,其架构特性会导致出现多个维度的性能瓶颈.首先是在细节表征方面存在局限,由于 ResNet 残差块的设计,主要依赖残差块进行逐层特征提取,其卷积操作具有局部感受野特性,在低光场景中其逐层卷积的局部感受野难以有效捕获昏暗区域的纹理特征.其次是色彩保真度的缺失,受限于批归一化层的全局统计特性,ResNet 网络在极端低光条件下容易产生通道间色彩失真.最后是全局感知能力不足,ResNet 架构缺乏跨区域照度相关性建模,导致生成图像出现局部过曝或欠增强的情况.

相较之下,U-Net 架构凭借其编码器-解码器对称结构与逐层跳跃连接机制,能够有效保留图像的局部细节并提升对全局特征的捕捉能力.本文提出的改进的 U-Net 网络架构,采用了传统的编码器-解码器结构^[17],在

跳跃连接层加入了混合注意力模块,使得生成器能够自适应地调整图像不同区域和通道的注意力分布,从而强化亮度、纹理与结构等关键信息的恢复.其次,在上采样阶段设计并加入了二阶段色彩校正模块,旨在优化图像的光照与色彩平衡,以进一步提升成像质量.

网络整体采用左右对称的编码器-解码器结构,编码器由四个下采样阶段组成,解码器由四个上采样阶段组成.每个下采样阶段由 3×3 卷积、LeakyReLU 激活函数以及最大池化层组成. 3×3 卷积层有效地提取局部特征,LeakyReLU 激活函数引入非线性特征以增强模型表达能力,最大池化层负责降低空间维度并保留关键特征.每个上采样阶段则通过转置卷积、 3×3 卷积和 LeakyReLU 激活函数等操作完成图像细节恢复.转置卷积主要负责恢复图像的空间分辨率, 3×3 卷积负责融合跳跃连接后的特征信息,并进一步细化特征图,增强分割精度和细节表现.而 LeakyReLU 则用于防止特征过平滑现象,使恢复后的图像细节更加丰富且自然.




图 2 U-Net 结构生成器网络架构图

Fig.2 Network Architecture Diagram of the Generator with U-Net Structure

1) 混合注意力模块

在低光域的图像中,图像的光照分布通常呈现显著的空间异质性,且信息密度呈现非均匀特性,即视觉核心信息往往集中于局部区域,而其他区域则可能被噪声或无效像素占据主导地位.若模型对图像不同区域的显著性差异缺乏判别能力,极易导致关键细节重建不完整或噪声伪影被不当强化.本文在生成器网络的跳跃连接层中加入以通道注意力^[18]与空间注意力^[19]为基础的混合注意力机制(Channel-Spatial Hybrid Attention, CSHA).

通道注意力模块由平均池化、 1×1 卷积操作以及 LeakyReLU 和 Sigmoid 激活函数组合来组成,通道注意力模块结构如图 3 所示.平均池化能够捕捉全局特征,对于通道注意力来说,其可以让模块从全局视角评估各通道的权重,从而使得模型能够更加有效地关注到整个图像的全局信息. 1×1 卷积不但减小了特征图的维度,还增强了模型的表达能力.结合 LeakyReLU 和 Sigmoid 激活函数,模块能够引入非线性变换,通道注意力的权重计算可以表示为:

$$M_c(F) = \sigma \left(W_1 \cdot \delta(W_0 \cdot AvgPool(F)) \right) \quad (1)$$

其中, W_0 和 W_1 表示是 1×1 卷积的权重矩阵, δ 表示是 LeakyReLU 激活函数, σ 表示是 Sigmoid 激活函数, F 表示是输入特征图.




图 3 通道注意力模块结构图

Fig.3 Structure diagram of the channel attention module

空间注意力模块由 1×1 卷积操作以及 ReLU 和 Sigmoid 两种激活函数组成, 空间注意力模块结构如图 4 所示. ReLU 用于引入非线性特性, 帮助网络学习到更加复杂的空间模式, Sigmoid 函数的输出可以很好地控制每个空间区域的贡献度, 通过对这些权重进行加权, 使得模型能够聚焦在更为关键的空间区域, 提高特征表示的质量和任务性能. 空间权重计算可表示为:

$$M_s(F) = \sigma(W_2 \cdot \delta(W_1 \cdot F)) \quad (2)$$

其中, W_1 和 W_2 表示是 1×1 卷积的权重矩阵, δ 表示是 ReLU 激活函数, σ 表示是 Sigmoid 激活函数, F 表示是输入特征图.




图 4 空间注意力模块结构图

Fig.4 Structure diagram of the spatial attention module

CSHA 模块采用串联结构设计. 具体而言, 输入特征图首先经过通道注意力模块, 以学习不同通道在整体特征中的重要性, 从而突出对全局语义更敏感的通道特征. 随后, 增强后的特征图会进入空间注意力模块, 以引导模型关注图像中更关键的空间区域. 采用这种先通道后空间的组合方式, 模型可以同时提升对通道信息和空间区域的感知能力, 使生成器在低光图像增强任务中更有效地捕捉细节.

2) 二阶段色彩校正模块

本文设计了一个二阶段色彩校正模块 (Two-Stage Chromatic Correction Module, TCCM) 并应用在生成器的上采样阶段, 如图 5 所示. 该模块首先通过色彩空间变换对图像进行初步调整, 独立地优化亮度、色调和饱和度, 以增强低光图像的色彩表现; 随后, 利用色彩校正矩阵对 RGB 通道进行线性变换, 进一步恢复和增强色彩信息, 确保图像色彩的自然性与平衡. TCCM 能够提升生成器网络生成图像的视觉效果, 使生成的低光图像更加真实自然.

具体而言, 一阶段将上采样后的图像从 RGB 色彩空间转换到 HSV 色彩空间^[20,21]. 通过计算 RGB 通道的最大值与最小值差异来确定色调, 结合归一化操作计算饱和度, 并提取最大值作为明度, 以实现图像颜色信息的有效分离. HSV 色彩空间由色调、饱和度以及明度组成. 其中, 明度通道用于表示图像亮度, 饱和度通道反映颜色鲜艳程度, 色调通道则表示颜色种类^[22]. 在低光增强任务中, 明度通道的分离允许单独调整亮度信息, 而饱和度通道的动态增强能够有效恢复低光区域的色彩鲜艳度. 完成色彩空间的调整后, 图像的色彩信息得到了明显改善. 具体而言, 明度通道采用对比度拉伸与归一化方法, 优化整体亮度; 饱和度通道通过线性增强与动态范围限制, 实现颜色饱和度的动态增强; 色调通道则保持相对稳定, 通过动态平滑的方式实现色彩校正. 完成各通道的独立调整后, 图像再从 HSV 色彩空间转换回 RGB 空间, 作为二阶段色彩校正矩阵的输入.




图 5 二阶段色彩校正模块流程图

Fig.5 Flowchart of the two-stage color correction module

二阶段应用色彩变换矩阵对图像进行全局色彩校正^[23], 采样设计了一个色彩校正矩阵, 用于对图像的色彩通道进行线性变换, 调整其对比度和饱和度, 色彩校正矩阵的基本形式如下:

$$\begin{bmatrix} R' \\ G' \\ B' \end{bmatrix} = \begin{bmatrix} M_{11} & M_{12} & M_{13} \\ M_{21} & M_{22} & M_{23} \\ M_{31} & M_{32} & M_{33} \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (3)$$

$$\begin{cases} R' = M_{11} \times R + M_{12} \times G + M_{13} \times B \\ G' = M_{21} \times R + M_{22} \times G + M_{23} \times B \\ B' = M_{31} \times R + M_{32} \times G + M_{33} \times B \end{cases} \quad (4)$$

$$\sum_{i=1}^3 M_{ij} = 1 \quad | \quad j = 1, 2, 3 \quad (5)$$

其中, $\begin{bmatrix} R' \\ G' \\ B' \end{bmatrix}$ 表示校正后的图像的 RGB 值, 矩阵 M 是色彩校正矩阵系数, 负责控制各通道之间的线性变换

关系, $\begin{bmatrix} R \\ G \\ B \end{bmatrix}$ 是输入图像的 RGB 值.

2.2 全局-局部判别器

判别器网络的作用是评估生成图像与真实图像之间的差异程度, 从而为生成器提供优化方向. 在传统 CycleGAN 架构中, 判别器采用的是基于 PatchGAN 结构的局部的判别方式. 与传统判别器不同的是, PatchGAN 先将图像分割成多个局部区域, 然后对每个区域独立地进行真实性判别. 这种判别设计模式, 虽然在一定程度上能够提高判别速度和效率. 但在低光域场景下, 由于图像亮度较低、细节信息模糊且常存在阴影, 局部判别器很难对这些区域进行准确判断. 局部判别器侧重于对图像中各个小块区域的细节特征进行判别, 但对于低光场景中的全局结构、亮度变化以及整体一致性, 往往缺乏足够的敏感性. 这使得生成的图像在这些区域可能出现缺乏连贯性以及局部细节表现不自然的情况.

因此, 本文采用全局-局部判别机制^[24-25], 在对抗网络中引入了全局判别器和局部判别器的结合, 以同时兼顾全局信息与局部细节的判别能力.

全局判别器采用 6 层 4×4 的卷积网络, 步长为 2. 其中第一层由卷积操作和 LeakyReLU 激活函数组成, 中间三层由卷积操作、批量归一化(Batch Normalization)以及 LeakyReLU 激活函数组成, 批量归一化层的引入则有助于稳定训练过程, 减少内部协变量偏移, 提高模型的收敛速度和泛化能力, 最后一层只包含卷积操作. 该结构的设计使得判别器能够逐步提取图像中的高级特征, 同时保留一定的空间信息. 输入为整张图像, 经过卷积操作后, 输出一个 4×4 的 Patch, 每个小块用于进行真假判别. 每个小块的真假判别结果通过计算其概率, 最终将所有小块的概率值求和并取平均, 作为整个图像的最终判别结果. 这种结构使得全局判别器能够有效评估图像的全局一致性和亮度分布.




图 6 全局判别器网络架构图

Fig.6 Network Architecture Diagram of the Global Discriminator

局部判别器由 4 个卷积层组成, 每层的卷积层由卷积操作和 LeakyReLU 激活函数组成, 大小都为 4×4 , 步长为 2. 不同于全局判别器, 局部判别器不对整个图像进行评估, 而是从生成器输出的图像及真实图像中随机裁剪出小区域进行局部判别操作. 这些小区域的大小为 4×4 的 Patch, 通过多层卷积操作, 判别器逐步提取图

像的局部细节特征. 每个小块的真假判别结果通过计算其为真的概率值, 最终所有小块的概率值进行求和并取平均值, 作为整个局部区域的判别结果输出.




图 7 局部判别器网络架构图

Fig.7 Network Architecture Diagram of the Local Discriminator

2.3 损失函数

在本文所改进的网络模型中, 使用三个彼此独立的损失项, 分别是对抗损失 L_{ad} 、感知风格损失 L_{sty} 与内容损失 L_{con} . 模型的训练过程依据这三个损失函数进行优化, 最终的模型目标函数定义如下:

$$L = \lambda_{ad}L_{ad} + \lambda_{sty}L_{sty} + \lambda_{con}L_{con} \quad (6)$$

1) 对抗损失

对抗损失能够推动生成器生成与真实数据分布高度一致的样本, 在生成器与判别器不断进行动态博弈的过程中, 生成器持续优化自身的生成策略, 进而让生成的图像在视觉效果上与真实图像几乎无法区分. 本模型对抗损失 L_{ad} 采用最小二乘损失函数. 此外, 对抗损失由全局损失 L_{global} 和局部损失 L_{local} 两部分组成. 生成器的全局损失函数和全局判别器的损失函数分别为:

$$L_G^{global} = E_{x \sim P(x)} [(D^{global}(G(x)) - 1)]^2 \quad (7)$$

$$L_D^{global} = E_{y \sim P(y)} [(D^{global}(x) - 1)]^2 + E_{x \sim P(x)} [D^{global}(G(y))]^2 \quad (8)$$

其中, x 表示低光域图像, y 表示正常光亮的图像, L_G^{global} 是生成器全局对抗损失, L_D^{global} 是全局判别器对抗损失, G 是生成器, D^{global} 是全局判别器, E 是数学期望, $P(x)$ 和 $P(y)$ 分别表示源低光域图像数据集和目标正常光亮图像数据集. 生成器 G 的局部损失函数和局部判别器的损失函数分别为:

$$L_G^{local} = E_{y \sim P(y)} [(D^{local}(G(y)) - 1)]^2 \quad (9)$$

$$L_D^{local} = E_{x \sim P(x)} [(D^{local}(y) - 1)]^2 + E_{y \sim P(y)} [D^{local}(G(x))]^2 \quad (10)$$

其中, x 是来自低光域的真实图像, y 是来自正常光亮的真实图像, D^{local} 是局部判别器, E 是数学期望, L_G^{local} 是生成器局部对抗损失, L_D^{local} 是局部判别器对抗损失.

2) 感知风格损失

感知风格损失通过衡量生成图像与目标图像在不同层次特征上的相似度来优化模型, 侧重于纹理和颜色的分布. 它通过计算特定卷积层的特征图差异, 确保生成图像保留目标图像的风格特征, 避免纹理和色彩信息丢失.^[26] 在 CycleGAN 中引入感知风格损失, 可帮助生成器在图像转换时更好地保留目标图像的纹理和风格, 提升生成图像的质量和视觉效果. 本文采用预训练的 VGG16 网络提取特征映射, 以捕捉图像的语义信息, 具体定义如下:

$$L_{sty} = E \left[\sum_l \|\phi_l(\hat{I}) - \phi_l(I)\|_1 \right] \quad (11)$$

其中, $\hat{I}$ 表示生成器所生成的图像, I 表示真实图像, $\phi_l(\hat{I})$ 表示从生成图像中所提取的第 l 层特征图, $\phi_l(I)$ 表示从真实图像中提取的第 l 层特征图, $\|\cdot\|_1$ 表示衡量特征图之间差异的 L_1 范数, E 表示数学期望.

3) 内容损失

与传统的像素级损失相比,内容损失能够有效减少生成过程中的模糊与失真,捕捉细腻的细节和真实结构,从而提升视觉效果和感知质量.对于 CycleGAN 来说,引入内容损失能够确保生成图像在结构和内容上与目标图像高度一致,从而生成更逼真、更细腻的图像^[27].此外,内容损失还能够避免单纯依赖对抗损失产生的伪影和不必要的噪声,进一步确保生成图像的质量和一致性,其定义如下所示:

$$L_{con}(G,Y) = \frac{1}{N} \sum_{i=1}^N \|\phi_i(G(X) - \phi_i(Y))\|^2 \quad (12)$$

其中, L_{con} 是内容损失, Y 是目标图像, ϕ_i 是预训练的卷积神经网络中的第 i 层特征映射, N 表示特征图数量, $\|\cdot\|^2$ 表示特征差异的平方和.

3 实验与分析

3.1 实验数据集

本文数据集由 LOL、LIME 和 EnlightenGAN 实验数据集组成. LOL 数据集由成对的低光和正常光图像组成,而 LIME 和 EnlightenGAN 数据集包含非配对图像.考虑到 LOL 数据集数据量较少且均为成对数据,为进一步验证模型在非配对图像增强任务中的表现,本文实验在以 LOL、LIME 及 EnlightenGAN 实验数据集组成的数据集下进行实验分析.其中,正常光图像共 500 张,低光图像共 1500 张.

3.2 实验环境

本文实验基于深度学习框架 Pytorch1.13 版本进行模型构建,所使用的 GPU 是 NVIDIA GeForce GTX 4090.图片批处理数量设置为 4,学习率为 0.0002 的 Adam 优化器,训练轮数为 300,并在最后 50 个训练批次中,学习率以线性衰减的方式逐步降至 0.

3.3 对比方法

为验证本文所提出的基于混合注意力的 CycleGAN 模型的性能表现,将其与其他四种具有代表性的低光域图像增强模型在相同数据集和实验环境下进行定量实验和定性实验,以对比它们在图像质量、细节恢复及色彩校正等方面的性能优劣.对比方法包括基于无参考学习的 Zero-DCE 模型^[28]、基于生成对抗网络的 EnlightenGAN^[29]、以 ResNet 网络为生成器的原 CycleGAN 模型和基于深度学习的 KinD 模型^[30]以及基于流式建模的 LLFlow 模型.

3.4 损失函数权重分析

为验证损失函数各项权重配置对模型性能的影响,本节设计了五组具有代表性的损失项加权组合,并通过客观指标对生成效果进行定量评估,以分析不同损失配置下模型表现的差异. Gatys 等人^[31]关于图像风格迁移的研究指出,内容损失与风格损失之间的权重比例调节显著影响生成图像中内容保真度与风格一致性之间的平衡效果.受其研究成果的启发,本节进行五组超参数组合,对不同权重配置下模型生成图像的客观指标进行对比分析,以确定最优参数设定.分别是三项损失均衡化、非均衡化、单项损失主导的组合策略.权重数值的选取均控制在 1 至 3 之间,一方面避免数值差距过大引发训练不稳定,另一方面便于对各项损失的贡献进行清晰对比.具体的组合策略与性能指标如表 1 所示.组合 1 作为基准配置,三类损失权重相等,旨在观察模型在均衡化约束下的性能表现;组合 2 和组合 3 在三项损失权重均不相等的前提下,分别提升内容损失和感知风格损失的权重,旨在分析在非均衡约束下,内容信息与纹理风格对图像增强性能的不同影响.通过二者的对比,可揭示不同类型损失对感知质量与结构保真之间的权衡关系;组合 4 提升对抗损失比重,验证生成器在更强对抗驱动下的性能表现;组合 5 在保持对抗与风格感知损失等权重的同时,适度提高内容损失的权重,旨在探索三类损失在真实性、细节纹理与结构还原之间的协同效果.由表可见,当三者权重一致时,整体性能平稳但无突出优势;当感知风格损失权重偏高,PSNR、SSIM 及 NIQE 指标均有所下降,表明图像纹理增强虽有所提升,但整体图像质量受到影响;当内容损失函数权重偏高时,NIQE 指标提升明显;当对抗损失权重提升时,图像所有指标相较于组合 1 均有所提升,说明增强对抗性有助于提升图像的整体质量;综合三项指标表现,组合 5 可以在三个损失函数之间取得更好的平衡,本文最终采用该组参数作为损失函数的配置方案.

表 1 损失函数权重组合实验评价指标结果对比表

Table 1 Comparison Table of Evaluation Metric Results for Loss Function Weight Combination Experiments

编号	λ_{ad}	λ_{sty}	λ_{con}	PSNR	SSIM	NIQE
1	1	1	1	21.45	0.744	4.35
2	1	2	3	22.05	0.756	4.04
3	1	3	2	21.02	0.728	4.81
4	2	1	1	21.87	0.739	4.09
5	2	2	3	22.31	0.761	3.92

3.5 主观定性实验

本文将数据集图像是否存在低光与正常光的配对关系，将数据划分为配对数据集和非配对数据集两部分。其中，配对数据集主要来源于 LOL 数据集，而非配对数据集则选自 EnlightenGAN 实验数据集。基于实验结果，本文从各测试数据集中各随机抽取四幅图像，对生成效果进行了对比分析，其对比结果如图 8 和图 9 所示。

图 8 展示了在不同场景下的室内环境下，本文改进模型与原 CycleGAN、EnlightenGAN、Zero-DCE、KinD 以及 LLFlow 五种模型在配对数据集上的对比实验结果。从图中可以看出，虽然原 CycleGAN 通过对抗训练实现了域间映射^[32]，但生成图像的效果较为不稳定，且亮度增强效果不足。此外，生成图像还存在局部失真和细节模糊的问题。例如，在第一幅纸巾物品生成图中，整体亮度偏低，未达到预期效果；而在第三幅颜料板生成图中，上部区域出现了明显的局部色彩失真现象。

EnlightenGAN 通过全局光照感知模块提升整体亮度，其亮度增强效果优于 CycleGAN，但其生成的图像普遍存在对比度低以及色彩不够生动的问题。Zero-DCE 通过可微曲线估计实现无监督光照调整^[33]，但实验结果显示，其在局部区域的细节恢复表现欠佳，在局部细节的呈现上存在不足。例如在第一张纸巾物品的生成效果图中，纸巾区域有模糊感，边缘和细节不够清晰，没有很好地还原其轮廓和质感，局部清晰度有待提升。

KinD 在光照增强上通过光照-反射分解提升可解释性^[34]，然而，实验结果显示，其在分解过程中引入的先验约束可能导致对比度过高。无论是光线恢复程度还是局部细节表现，效果都是不错的。但是，由于对比度过高，图像中的明暗差异过于显著，导致生成的图片缺乏柔和感，存在阴影丢失等问题，影响了图像的视觉舒适度和自然度。

LLFlow 相较于上述四种模型，在整体亮度提升以及色彩自然性方面表现最为出色。但是部分区域存在过度平滑的问题，导致局部区域存在模糊感，降低了图像局部细节的清晰度。综合分析，与上述五种模型相比，本文所改进的模型在图像生成方面展现出了明显优势。其生成图像整体上亮度均衡、对比度适宜，而且不存在细节丢失和局部色彩失真的情况，在整体视觉效果上，生成的图像观感更为柔和。

图 9 展示了在接近黑夜的极低光环境下，五种模型对室外场景的增强效果对比，实验数据选自 EnlightenGAN 的非配对数据集。由图可见，原 CycleGAN 生成的图像整体清晰度不足且局部区域存在模糊化的问题。例如结果图中的城堡塔楼存在丢失棱角特征的情况的棱角特征同时色彩还原存在系统性偏差。

相比之下，EnlightenGAN 在全局亮度提升方面表现较好，但在第三张风景图的天空与云层交界处出现了轻微的色调失真的情况，色彩一致性有所降低。Zero-DCE 在几张效果图上亮度和对比度提升效果较好，图像整体较为明亮，但在色彩方面部分区域可能存在轻微的过度增强。KinD 在细节保留上表现较好，建筑表面的纹理清晰度优于上述模型，但其整体对比度偏高，图像整体色彩过于厚重，视觉效果缺少柔和感。LLFlow 整体表现较优，亮度提升自然，色彩协调，但部分区域边缘过渡略显生硬，影响了图像的整体自然感。相比之下，本文所改进的模型在室外自然场景下亮度均衡且色彩柔和，还原了真实环境的细腻质感，整体增强性能优于上述模型。

综合以上分析，CycleGAN 性能表现最差，其生成结果极不稳定，图像常常出现亮度不足和局部失真的情况。EnlightenGAN 虽然在整体亮度提高方面表现较优，但对比度和色彩生动性仍需改进。Zero-DCE 在局部细节恢复上存在不足。KinD 则因对比度过高及视觉效果生硬而影响了图像的自然感。LLFlow 在亮度增强与色彩协

调性方面表现较优,但是在局部细节的清晰度上存在不足. 相比之下, 本文的改进模型在在亮度均衡性、细节完整性与色彩保真度各方面表现均衡, 展现了最为自然、清晰的图像增强效果.

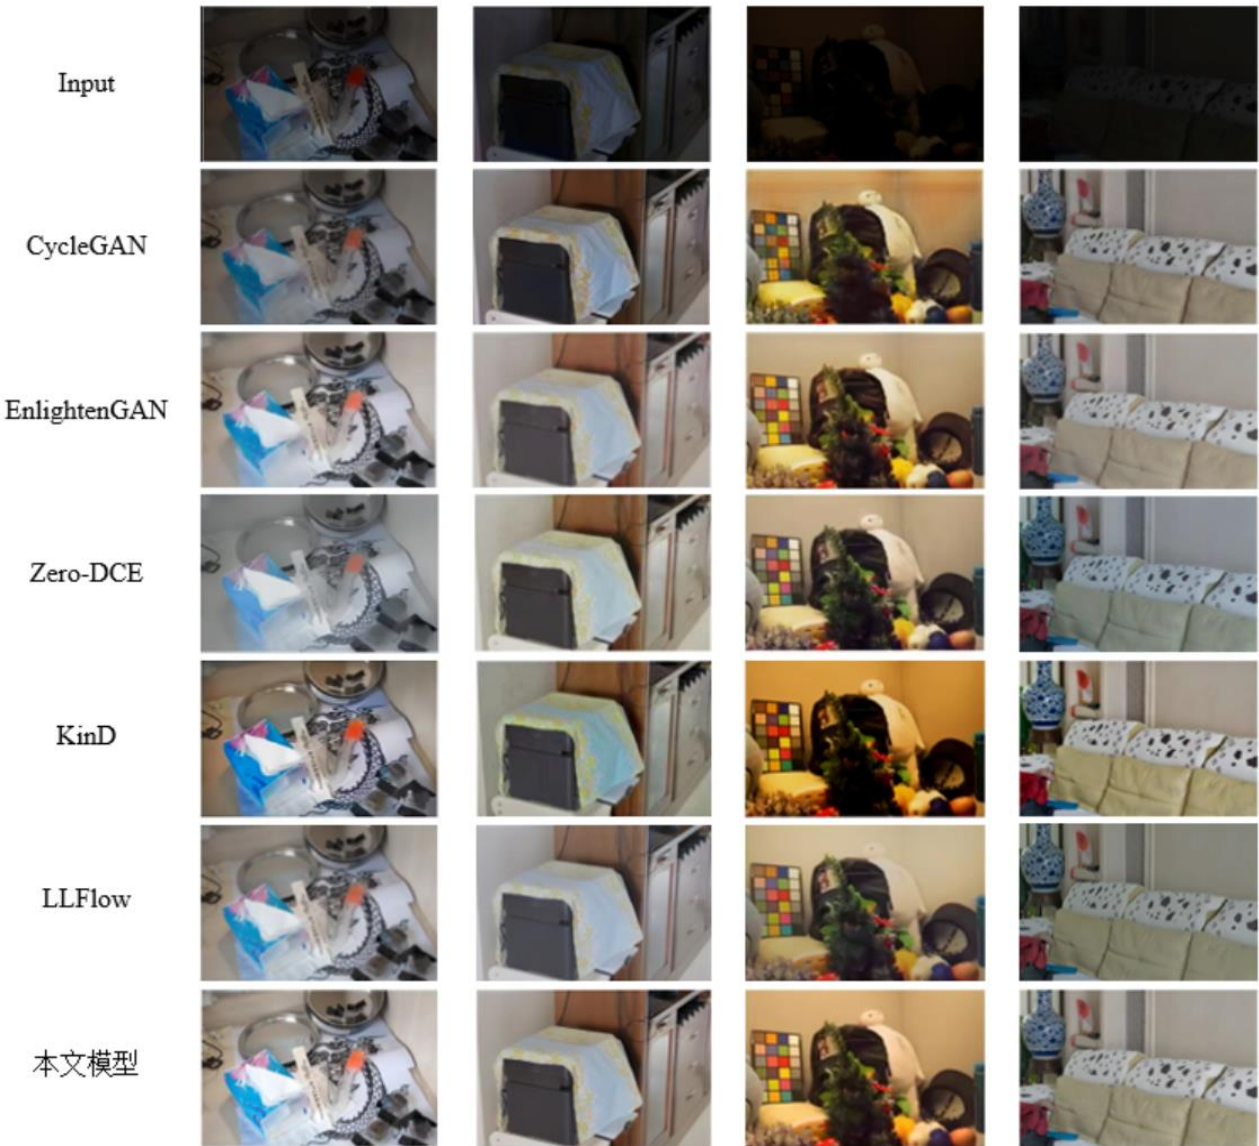


图 8 配对数据集低光域图像增强实验结果图

Fig.8 Experimental Result Diagram of Low-light Domain Image Enhancement for Paired Datasets




图 9 非配对数据集低光域图像增强实验结果图

Fig.9 Experimental Result Diagram of Low-light Domain Image Enhancement for Unpaired Datasets

3.6 客观定量实验

为进一步客观科学地评估上述模型的性能表现，在本文实验中，采用三种图像质量客观评价指标于本实验测试集上予以验证，分别是基于像素级误差分析的峰值信噪比 PSNR、引入人眼视觉感知特性的结构相似性指数 SSIM 以及无参考型自然图像质量评价器 NIQE。

PSNR 通过计算原始图像与处理图像的均方误差量化失真程度^[35]。该指标与图像质量呈正相关关系，其数值越高，表明图像质量越优。能够有效反映模型处理对图像保真度的影响。SSIM 从亮度、对比度以及结构信息三个维度构建多尺度评价模型^[36]，其指标值域为[0,1]，数值越接近 1，则表明处理图像在视觉感知层面与原始图像高度吻合。NIQE 则通过分析图像块的自然场景统计特征建立多维质量评估体系^[37]，特别适用于生成式图像的自然度与视觉舒适度评估。以下为实验结果，具体指标数据见表 2。需说明的是，表中数据均为多次实验所得的平均值，旨在确保数据的可靠性与稳定性，降低单次实验可能引发的误差及不确定性对结果的干扰。

表 2 定量实验评价指标结果对比表

Table 2 Comparison Table of the Results of Quantitative Experimental Evaluation Indicators

模型	配对测试集			非配对测试集		
	PSNR	SSIM	NIQE	PSNR	SSIM	NIQE
CycleGAN	18.76	0.592	6.13	17.14	0.565	6.68
EnlightenGAN	21.42	0.734	4.39	20.37	0.712	4.53
Zero-DCE	20.04	0.672	4.74	18.31	0.629	4.91
KinD	19.58	0.625	5.83	17.97	0.590	6.11
LLFlow	21.63	0.738	4.01	20.59	0.671	4.57
本文模型	22.31	0.761	3.92	21.03	0.694	4.25

由表 2 可见，本文的改进模型在客观评估指标 PSNR、SSIM 以及 NIQE 上，不论是配对数据集还是非配对数据集都优于原 CycleGAN 以及其他几种模型。具体的，在配对测试集方面 PSNR、SSIM 以及 NIQE 分别达到了 22.31、0.761、3.92，在非配对测试集方面 PSNR、SSIM 以及 NIQE 分别达到了 21.03、0.694、4.25，这表明本文所提出的 CycleGAN 低光域改进模型在生成图像的质量上优于其他模型。

3.7 注意力模块对比实验

为深入评估本文所提出的通道-空间混合注意力模块在低光图像增强任务中的优越性，本文在生成器的跳跃连接层分别引入不同类型的注意力模块进行对比实验。分别是单通道注意力模块^[18]（Squeeze-and-Excitation, SE）、采用局部一维卷积替代全连接结构以降低参数数量的轻量级单通道注意力模块^[38]（Efficient Channel Attention, ECA）以及基于卷积结构联合建模通道与空间特征的 CBAM 模块^[19]（Convolutional Block Attention Module）。其中，与 CBAM 相比，本文提出的 CHSA 模块在结构设计上更加轻量化。通道注意力部分仅使用全局平均池化与 1×1 卷积，并引入 LeakyReLU 激活函数以提升特征建模能力；空间注意力则通过 1×1 卷积结合 ReLU 与 Sigmoid 激活函数完成加权操作，有效避免大卷积核与池化拼接操作带来的冗余计算。

由表 3 可见，相较于其他注意力模块，CycleGAN 引用本文所改进的模块在 PSNR、SSIM 以及 NIQE 上都具有最好的数据表现。与仅关注通道信息的 SE 和 ECA 模块相比，CHSA 同时引入空间注意力机制，有助于模型在低光图像中更精准地定位关键区域，从而提升对局部细节的还原能力。而相较于 CBAM 模块，CHSA 采用轻量的结构设计，在降低模型计算的同时，也能够提升模型特征表达能力。因此，CHSA 模块能够更充分地挖掘图像的通道与空间特征，为低光图像增强任务提供更优的方案。

表 3 不同注意力模块实验评价指标结果对比表

Table 3 Comparison of Evaluation Metrics for Different Attention Modules

模块	PSNR	SSIM	NIQE
SE	18.73	0.615	5.82
ECA	19.02	0.632	5.75
CBAM	19.27	0.641	5.60
CHSA	19.35	0.663	5.38

3.8 图像增强时间分析

为评估所提出图像增强模型在实际应用场景中的可部署性，本文对不同模型在低光图像增强任务中的训练阶段与推理阶段的运行效率进行了对比分析。具体而言，训练时间衡量模型从初始化到收敛所需的总耗时，反映模型的训练复杂度；增强时间是模型在测试阶段对单张图像进行增强处理所需的平均时间，负责衡量模型的实时性。

由表 4 可见，原 CycleGAN 模型训练与推理效率相对较低，而本文所提出的改进模型在引入混合注意力机制与二阶段色彩校正模块的基础上，参数量在增加的同时，模型整体结构也得到了优化。虽然训练时间有所增加，但其在推理阶段的增强时间有所下降。在保持图像增强效果的同时提升了运行效率，具备更强的实时处理能力。这主要得益于生成器结构由 ResNet 替换为具有紧凑信息流与多尺度特征融合能力的 U-Net 架构。相比 ResNet 中较深的残差堆叠，U-Net 的跳跃连接能够缩短信息传递路径，减少冗余计算，从而提高推理效率。此外，判别器仅在训练阶段参与优化，测试阶段不参与图像生成过程，因此全局-局部判别机制不会影响推理耗时。所以，尽管改进模型训练时间略有增加，但推理效率更高，能够在保持图像增强质量的同时满足更强的实时处理需求。

表 4 不同模型的图像增强处理时间效率对比表

Table 4 Comparison Table of Time Efficiency for Image Enhancement Processing of Different Models

模型	训练时间(h)	增强时间(s)
CycleGAN	14.6	0.62
EnlightenGAN	10.3	0.54
Zero-DCE	9.8	0.49
KinD	10.2	0.51
LLFlow	17.4	0.46
本文模型	15.9	0.45

3.9 消融实验

为了评估混合注意力模块、二阶段色彩校正模块、全局-局部判别机制以及感知风格损失和内容损失对本文改进模型的生成器性能影响，本节进行了消融实验。实验共分为七个部分，分别是：以 ResNet 作为生成器的原 CycleGAN 模型、在不引入其他模块的前提下，仅将生成器结构替换为 U-Net 的 CycleGAN 模型、仅去除跳跃连接层的混合注意力模块、仅去除上采样阶段的二阶段色彩校正模块、仅去除全局-局部判别机制，采用原 CycleGAN 的局部判别机制、仅去除感知风格损失和内容损失函数以及完整的改进模型。实验在相同条件下进行，以验证各模块对生成器性能的具体影响。

图 10 展示了不同实验组的对比结果。由图可见，原始 CycleGAN 的图像成像质量较低，局部区域存在模糊化现象，甚至出现少量像素点异常。而在将生成器替换为 U-Net 后，生成图像在局部色彩与整体清晰度方面存在部分改善。相比之下，加入二阶段色彩校正模块后，色彩和亮度明显提升；加入混合注意力模块的实验后，纹理细节更加清晰。进一步地，在引入全局-局部判别机制后，模型对图像整体结构和局部细节的判别能力有所提高，成像效果也更加自然，减少了因局部判别失效而导致的局部失真现象。在加入感知风格损失和内容损失后，图像存在局部纹理退化和模糊的现象。综合来看，以 U-Net 结构作为生成器并同时集成两个模块、判别器采用全局-局部判别机制并在损失函数中加入感知风格损失和内容损失的本文改进模型在色彩、亮度和纹理方面均表现最优，并且在整体一致性和细节还原能力上提升明显。

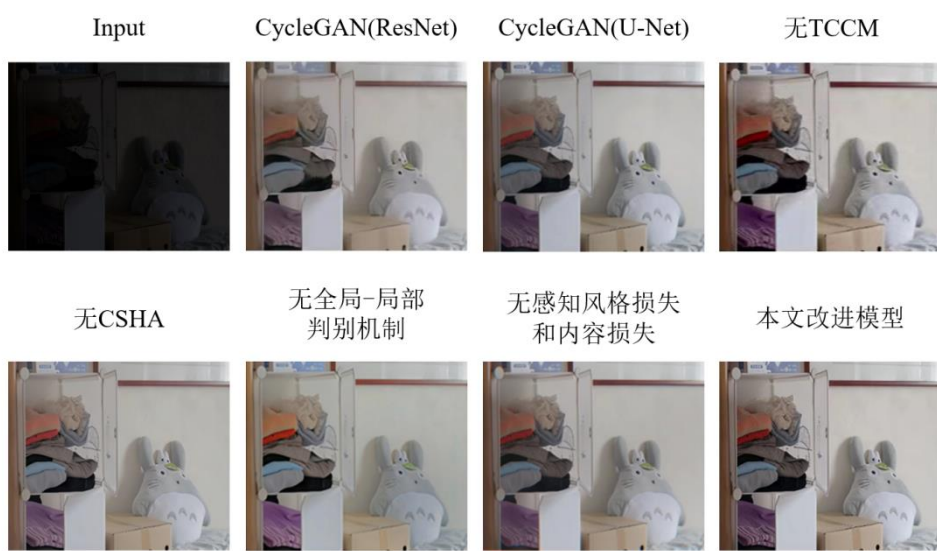


图 10 消融实验对比图

Fig.10 Ablation Study Comparison Chart

表 5 展示了三种评价指标的消融实验结果. 由表可见, 以 U-Net 作为生成器, 并在跳跃连接层加入混合注意力模块、在上采样阶段加入二阶段色彩校正模块, 同时结合全局-局部判别机制以及感知风格损失和内容损失, 都能在一定程度上提升图像质量. 综合分析, 当这些改进协同作用时, 图像质量的提升最为突出, 在色彩风格、亮度和细节纹理以及图像结构一致性等多个方面表现出明显的优化效果. 这表明, 它们的结合能够更全面地改善图像的整体质量.

表 5 消融实验评价指标结果对比表

Table 5 Comparison Table of the Results of Evaluation Indicators for the Ablation Experiment

模型	测试数据集		
	PSNR	SSIM	NIQE
CycleGAN(ResNet)	18.13	0.573	6.21
CycleGAN(U-Net)	18.45	0.594	6.06
无 TCCM	18.70	0.636	5.67
无 CSHA	19.87	0.658	5.05
无全局-局部判别机制	20.56	0.669	4.72
无感知风格损失和内容损失	20.92	0.681	4.55
本文改进模型	21.08	0.695	4.49

4 总结与展望

针对循环生成对抗网络在低光域图像增强中存在色彩失真与细节丢失问题, 本文提出了一种基于混合注意力的 CycleGAN 低光域图像增强模型. 结合通道-空间混合注意力机制、二阶段色彩校正模块以及全局-局部判别策略. 具体的, 首先在生成器的上采样阶段引入二阶段色彩校正模块, 并在跳跃连接层嵌入混合注意力模块, 以提升生成器的生成性能. 其次在判别器中引入全局-局部判别器, 以使判别器兼顾全局信息与局部细节的判别能力. 最后在损失函数中加入感知风格损失和内容损失, 以进一步提升生成图像的结构保真度和视觉自然性.

虽然当前改进模型在低光域图像生成质量上表现出色, 但仍存在两方面的提高空间. 首先, 模型整体计算度相对较高, 计算效率上有提高的空间. 因此, 未来研究可以考虑轻量化网络的方向, 以降低计算成本并提高模型的实用性. 其次, 当前模型场景泛化能力可进一步加强, 适用场景较为单一, 未来可以考虑融入跨任务学

习框架或模块，以提高模型的普适性。

参 考 文 献

- [1] Zhan J, Goh E.S., Sunar M.S. Low-Light Image Enhancement: A Comprehensive Review on Methods, Datasets and Evaluation Metrics[J]. Journal of King Saud University - Computer and Information Sciences, 2024, 36(10): 102234.
- [2] Tian Z, Qu P, Li J, et al. A Survey of Deep Learning-Based Low-Light Image Enhancement[J]. Sensors, 2023, 23(18): 7763.
- [3] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative Adversarial Networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [4] Zhu J Y, Park T, Isola P, et al. Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks[C]//Proceedings of the IEEE International Conference on Computer Vision. 2017: 2223-2232.
- [5] 谢凤英, 汤萌, 张蕊. 基于Retinex的图像增强方法综述[J]. 数据采集与处理, 2019, 34(1): 1-11.
- [6] 蒲恬, 张子夜, 彭真明. 保持自然度的非均匀光照图像增强的Retinex算法[J].数据采集与处理,2021, 36(1): 76-84.
- [7] Wang M, Li J, Zhang C. Low-Light Image Enhancement by Deep Learning Network for Improved Illumination Map[J]. Computer Vision and Image Understanding, 2023, 232: 103681.
- [8] 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.
- [9] 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.
- [10] Wu K, Huang J, Ma Y, et al. Cycle-Retinex: Unpaired Low-Light Image Enhancement Via Retinex-Inline CycleGAN[J]. IEEE Transactions on Multimedia, 2023, 26: 1213-1228.
- [11] Ni Z, Yang W, Wang H, et al. Cycle-Interactive Generative Adversarial Network for Robust Unsupervised Low-Light Enhancement[C]//Proceedings of the 30th ACM International Conference on Multimedia. 2022: 1484-1492.
- [12] Parmar G, Park T, Narasimhan S, et al. One-Step Image Translation with Text-to-Image Models[J]. Arxiv Preprint Arxiv:2403.12036, 2024.
- [13] Cheng X. Refining CycleGAN with Attention Mechanisms and Age-Aware Training for Realistic Deepfakes[J]. Heliyon, 2024, 10(16).
- [14] Shao X, Wei C, Shen Y, et al. Feature Enhancement Based on CycleGAN for Nighttime Vehicle Detection[J]. IEEE Access, 2020, 9: 849-859.
- [15] Jiangtao W, Ruhaiyem N I R, Panpan F. A Comprehensive Review of U-Net and Its Variants: Advances and Applications in Medical Image Segmentation[J]. ArXiv Preprint ArXiv:2502.06895, 2025.
- [16] Zhang K, Sun M, Han T X, et al. Residual networks of Residual Networks: Multilevel Residual Networks[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2017, 28(6): 1303-1314.
- [17] 王万良, 杨小涵, 赵燕伟, 等. 采用卷积自编码器网络的图像增强算法 [J]. 浙江大学学报 (工学版), 2019, 53(09): 1728-1740.
- [18] Hu J, Shen L, Sun G. Squeeze-and-Excitation Networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018: 7132-7141.
- [19] Woo S, Park J, Lee J Y, et al. Cbam: Convolutional Block Attention Module[C]//Proceedings of the European Conference on Computer Vision (ECCV). 2018: 3-19.
- [20] Bi Z, Cao P. Color Space Conversion Algorithm and Comparison Study[C]//Journal of Physics: Conference Series. IOP Publishing, 2021, 1976(1): 012008.
- [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] Zhang N, Han X, Liu C, et al. Joint Luminance Adjustment and Color Correction for Low-Light Image Enhancement Network[J]. Applied Sciences (2076-3417), 2024, 14(14).
 - [23] 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(07): 13106-13113.
 - [24] Huang Z, Zhang J, Zhang Y, et al. DU-GAN: Generative Adversarial Networks with Dual-Domain U-Net-Based Discriminators for Low-Dose CT Denoising[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 71: 1-12.
 - [25] Jaisurya R S, Mukherjee S. AGLC-GAN: Attention-Based Global-Local Cycle-Consistent Generative Adversarial Networks for Unpaired Single Image Dehazing[J]. Image and Vision Computing, 2023, 140: 104859.
 - [26] Johnson J, Alahi A, Fei-Fei L. Perceptual Losses for Real-Time Style Transfer and Super-Resolution[C]//Computer Vision – ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11-14, 2016, Proceedings, Part II 14. Springer International Publishing, 2016: 694-711.
 - [27] Mechrez R, Talmi I, Zelnik-Manor L. The Contextual Loss for Image Transformation with Non-Aligned Data[C]//Proceedings of the European Conference on Computer Vision (ECCV). 2018: 768-783.
 - [28] 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.
 - [29] 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.
 - [30] Zhang Y, Zhang J, Guo X. Kindling the darkness: A Practical Low-Light Image Enhancer[C]. Proceedings of the 27th ACM International Conference on Multimedia. 2019: 1632-1640.
 - [31] Gatys L A, Ecker A S, Bethge M. Image Style Transfer Using Convolutional Neural Networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016: 2414-2423.
 - [32] Son D M, Kwon H J, Lee S H. Enhanced Night-to-Day Image Conversion Using CycleGAN-Based Base-Detail Paired Training[J]. Mathematics, 2023, 11(14): 3102.
 - [33] Mi A, Luo W, Qiao Y, et al. Rethinking Zero-DCE for Low-Light Image Enhancement[J]. Neural Processing Letters, 2024, 56(2): 93.
 - [34] 彭大鑫,甄彤,李智慧.低光照图像增强研究方法综述[J].计算机工程与应用,2023,59(18):14-27.
 - [35] Mohammadi P, Ebrahimi-Moghadam A, Shirani S. Subjective and Objective Quality Assessment of Image: A Survey[J]. ArXiv Preprint ArXiv:1406.7799, 2014.
 - [36] Bakurov I, Buzzelli M, Schettini R, et al. Structural Similarity Index (SSIM) Revisited: A Data-Driven Approach[J]. Expert Systems with Applications, 2022, 189: 116087.
 - [37] Mittal A, Soundararajan R, Bovik A C. Making a “Completely Blind” Image Quality Analyzer[J]. IEEE Signal Processing Letters, 2012, 20(3): 209-212.
 - [38] Wang Q, Wu B, Zhu P, et al. ECA-Net: Efficient Channel Attention for Deep Convolutional Neural Networks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020: 11534-11542.



刘尚东(1979-), 男, 博士, 副教授. 研究方向: 人工智能、网络空间安全、大数据及云计算技术. Email: lsd@njupt.edu.cn



吴健(1998-), 男, 硕士研究生. 研究方向: 图像增强与去噪、深度学习. Email: 1222045829@njupt.edu.cn



徐鹤(1985-), 男, 博士, 教授, CCF 高级会员. 研究方向: 人工智能与大数据、物联网技术. Email: xuhe@njupt.edu.cn



季一木(1978-), 男, 博士, 教授, 博士生导师, CCF 会员. 研究方向: 高性能计算、大数据和人工智能. Email: jiym@njupt.edu.cn