

DOI: 10.13382/j.jemi.B2407892

基于跳跃连接神经网络的无监督弱光图像增强算法*

刘 洋¹ 刘思瑞¹ 徐晓森² 王竹筠¹

(1. 沈阳航空航天大学 沈阳 110136; 2. 火箭军某军事代表室 北京 100039)

摘要:针对 Zero-DCE 网络存在细节丢失和不同亮度区域处理结果出现差异等问题,设计了一种基于增强深度曲线估计网络(EnDCE-Net)的无监督弱光图像增强算法。通过探索弱光图像与未配对的正常光照图像之间的潜在映射关系,实现了对低光照场景下图像质量的显著改善。首先,提出新的特征提取网络,该网络整合了多个跳跃连接与卷积层,实现低层与高层特征的有效融合,从而学习到弱光图像中的关键特征,增强网络对弱光图像的学习能力。其次,设计一组联合的无参考损失函数,强调优化过程中与亮度相关的特性,从而更有利于图像增强模型的参数更新,提高图像增强的质量和效果。为了验证所提出算法的有效性,在5个公开数据集上进行了对比实验,与次优算法 Zero-DCE 相比,有参考数据集 SICE 上的峰值信噪比(PSNR)和结构相似性(SSIM)分别提升了9.4%、21%。无参考数据集 LIME、DICM、MEF、NPE 上 NIQE 分别达到了4.04、3.04、3.35、3.83。实验结果表明,所提出算法表现出色,增强后的图像色彩自然,亮度均衡且细节清晰。无论是主观视觉评价还是客观定量指标,均显著优于对比算法,充分体现了在图像增强效果上的卓越性和先进性。

关键词: 弱光图像增强;深度曲线估计;无参考损失函数;多层卷积神经网络;无监督学习

中图分类号: TP391;TN919.5 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Low-light image enhancement algorithm of multi-layer neural network based on hopping connection

Liu Yang¹ Liu Sirui¹ Xu Xiaomiao² Wang Zhujun¹

(1. Shenyang Aerospace University, Shenyang 110136, China; 2. Rocket Force Military Representative Office, Beijing 100039, China)

Abstract: To address issues such as detail loss and inconsistent results across different brightness regions in the Zero-DCE network, an unsupervised low-light image enhancement algorithm based on the enhanced depth curve estimation network (EnDCE-Net) is proposed. This algorithm explores the potential mapping relationship between low-light images and unpaired normal-light images to achieve significant improvements in image quality under low-light conditions. First, a novel feature extraction network is introduced, which integrates multiple skip connections and convolutional layers, allowing for the effective fusion of low-level and high-level features. This enables the network to learn the key features of low-light images and enhances its ability to process them. Second, a set of joint no-reference loss functions is designed, emphasizing brightness-related features during the optimization process, which facilitates more efficient parameter updates and enhances the overall quality and effectiveness of the image enhancement. To evaluate the effectiveness of the proposed algorithm, comparative experiments were conducted on five publicly available datasets. Compared to the suboptimal algorithm Zero-DCE, the PSNR and SSIM on the reference dataset SICE were improved by 9.4% and 21%, respectively. On the no-reference datasets LIME, DICM, MEF, and NPE, the NIQE scores reached 4.04, 3.04, 3.35, and 3.83, respectively. The experimental results demonstrate that the proposed algorithm outperforms others, producing enhanced images with natural colors, balanced brightness, and clear details. Both subjective visual assessments and objective quantitative metrics show significant improvements over the competing algorithms, highlighting the excellence and advancement of the proposed method in image enhancement.

Keywords: low-light image enhancement; deep curve estimation; no reference loss function; multi-layer convolutional neural networks; unsupervised learning

收稿日期:2024-10-16 Received Date: 2024-10-16

* 基金项目:国家自然科学基金(62003224)、辽宁省教育厅项目(JYT2020042)资助

0 引言

在多种基于图像数据的实际场景中,如视频监控、智能交通、目标检测等领域,不可避免地会遇到大量弱光环境下的图像。在获取这些图像过程中,由于光线较弱或光照不均匀等问题,导致图像重要信息被隐藏或模糊,表现为细节不清晰、对比度降低、噪声增加以及色彩失真等。这种弱光图像的可视性差和图像中信息内容有限,可视性差影响观看者的体验,信息内容有限导致传达信息错误,依赖特征提取的视觉算法很难提取出足够的特征信息^[1-2]。因此,这些问题严重影响了图像的视觉质量和后续处理的效果。

随着机器学习的发展,机器学习通过对大型数据集中的弱光图像和正常图像进行学习,来获得其之间的映射关系,从而实现弱光增强。LLNet^[3]是第1个基于深度学习的弱光图像增强方法,此方法使用了将正常光照下图像进行合成从而获得正常光和弱光图像对。基于Retinex原理,RUAS^[4]开发了一种模型来分析弱光图像中固有的曝光不足的模式。Hai等^[5]将光照图作为先验信息引入降噪网络,并利用频率信息补充细节重建,从而实现了更高视觉质量的增强效果。虽然这些方法获得良好的效果,但是其中许多方法严重依赖于弱光和正常光照的图像对,这在现实场景中价格昂贵且不易获得。同时,也存在过拟合、模型的泛化能力差等问题。

与上述方法不同,众多学者采用无监督的深度学习方法增强图像,来消除对配对数据的依赖。程宇等^[6]提出了一种将传统方法和卷积神经网络(convolutional neural networks, CNN)相结合,通过将弱光图像经传统方法增强后的结果与原始图像整合,并输入到CNN中,实现了从弱光图像到正常光照图像的端到端映射。Jiang等^[7]采用无监督弱光和正常光图像配对训练对抗生成网络(GAN)网络,获得生成的增强图像,从一定程度上解决了配对数据集制作成本高昂的问题,但是处理高分辨率样本时容易出现棋盘效应。Guo等^[8]提出了一种基于亮度曲线估计的零参考深度曲线估计(zero-reference deep curve estimation, Zero-DCE)网络,用于弱光图像增强。该方法有效解决了传统CNN依赖大量配对数据以及GAN需要对非配对数据进行精细筛选的问题。Zero-DCE通过设计多个损失函数,旨在解决不同因素对图像亮度的影响,从而提升整体图像质量。该方法具有体积小、处理效率高和输出质量优的特点。然而,由于其结构简单且采用分区域计算方式,导致增强过程中可能出现细节丢失以及不同亮度区域处理效果不一致的问题,从而影响图像的整体质量。

本文方法通过研究弱光图像的深度曲线映射关系,

实现了对弱光图像的高质量增强,从而提升了整体视觉效果。即弱光图像经过特征提取模块获得多幅经过重组的特征图,最后通过迭代计算,获得理想的增强图像。为了准确提取图像的细节特征,本文设计了一种多层CNN结构EnDCE-Net;为了提高模型对图像亮度的约束能力,设计了一组无考损失函数对图像增强质量和效果进行评估,避免出现细节丢失出现色偏及引入噪声等情况;针对弱光图像增强中常见的曝光不足问题,在测试阶段引入了可选的线性增强模块。该模块可根据需要对图像进行亮度提升,从而改善整体视觉效果。

1 总体网络设计

本文聚焦于弱光图像恢复领域,基于弱光图像恢复与深度曲线估计之间存在的映射联系,创新性地构建了一种基于深度曲线估计的图像增强网络模型。该模型主要涵盖特征提取模块、迭代增强模块以及具备选择性的线性增强模块。

在实际运行过程中,首先由特征提取模块对输入的弱光图像展开处理,进而生成与之对应的参数图。然后,迭代增强模块会依据这些参数图,针对输入图像的RGB 3个通道同步开展映射操作与迭代计算,最终成功输出增强后的图像。而在测试环节,可依据实际的可视化效果,灵活决定是否启用线性增强模块对已增强图像实施二次处理,以此进一步优化图像质量。整体网络框架结构如图1所示。




图1 网络整体框架

Fig. 1 The overall framework of the network

1.1 特征提取网络设计

浅层卷积层提取的特征与输入层较为接近,包含更多的像素级信息,例如颜色、纹理和边缘等细粒度特征。浅层网络较小的感受野和较小的感受野重叠区域,使得它在处理输入数据时,能够更细致地对每个局部区域进行分析和处理。为了更好的对输入图像进行特征提取,本文设计EnDCE-Net网络。该网络包含8层CNN结构,

并通过不同层的网络进行拼接和跳跃连接,获得不同尺度的信息,前 7 层均采用 32 个大小为 3×3 的卷积核和 Relu 激活函数,最后一层采用 24 个大小为 3×3 的卷积核和 Tanh 激活函数。

如图 2 所示,本文在前向传递的 CNN 结构中加入了跳跃连接,将低层网络的输入连接到高层网络的输入,以允许信息在不同层之间进行传递。其中,将 C_1 层特征与 C_6 特征和 C_7 特征拼接在一起;将 C_2 层特征与 C_5 层特征拼接在一起;将 C_3 层特征与 C_4 层特征拼接在一起。这种方法有助于增强网络的特征提取性能,保证网络获得更多的细节信息,并提高训练速度。




图 2 EnDCE-Net 网络结构

Fig. 2 Network structure of EnDCE-Net

1.2 LE 迭代

弱光图像通过 EnDCE-Net 提取特征后,送入 LE 迭代过程实现图像增强。在弱光图像增强的任务中,图像增强算法里的曲线调节方法发挥着关键作用。其中,自适应曲线参数唯一的依赖因素便是输入图像。然而,面对那些极具挑战性的弱光图像时,想要获得最佳的增强效果,所需的最优曲线通常阶数较高。针对这一难题,Zero-DCE 提出了一种创新性的解决方案,即借助低阶曲线的反复运算来等效替代高阶曲线,以此达成弱光图像增强的过程。在具体的研究实践里,每一个操作步骤都选用二阶光线增强曲线,以此作为实现图像增强的关键方法。该曲线的公式化表达如式(1)所示。

$$LE(I(x); A(x)) = I(x) + A(x)I(x)(1 - I(x)) \quad (1)$$

式中: I 表示输入的低照度图像; x 表示像素坐标; $A(x)$ 表示与图像大小一致的特征参数; $LE(x)$ 表示在输入图像像素坐标 x 处输出的增强后图像。

通过多次迭代应用上述曲线逐步逼近更高阶的增强曲线对低照度图像进行增强。在第 n 步 ($n \geq 1$) 中,获得的增强曲线如式(2)所示。

$$LE_n = LE_{n-1}(x) + A_n(x)LE_{n-1}(x)(1 - LE_{n-1}(x)) \quad (2)$$

1.3 损失函数

本文采用无监督训练方式,通过设计一组零参考损失函数,实现了不依赖配对数据和标签的无监督学习。这些损失函数在评估图像增强效果时,主要通过剖析图

像像素的空间差异,以及探究原图像和增强后图像之间的内在关联来进行。零参考损失函数包括空间一致性损失、曝光控制损失、颜色恒常损失、照度平滑损失和通道一致性损失 5 部分,每部分均为可微函数,确保网络能够通过反向传播进行梯度更新。

1) 空间一致性损失 L_{spa}

为了提升增强图像的视觉效果,确保其与原始图像在结构和空间排列上保持一致,采取了以下策略。首先,将图像分割成众多 4×4 的像素块,这些像素块作为图像分析的基本单元。接着,运用精心设计的空间一致性损失,该损失的核心作用是保留原始图像与增强图像相邻区域之间的差异。在模型优化过程中,这一损失函数发挥着关键指导作用,它促使模型在增强图像时,最大程度地保留原始图像的结构和空间排列,从而有效促进增强图像的空间一致性,呈现出视觉效果更佳的增强图像。空间一致性损失 L_{spa} 计算过程如式(3)所示。

$$L_{spa} = \frac{1}{K} \sum_{i=1}^K \sum_{j \in \Omega(i)} (|Y_i - Y_j| - |I_i - I_j|)^2 \quad (3)$$

式中: K 所代表的是窗口的数量; $\Omega(i)$ 指的是以 i 为中心,涵盖上、下、左、右 4 个方向的范围; Y_i 与 Y_j 分别代表增强之后图像窗口区域的像素均值; I_i 和 I_j 则分别代表原始图像窗口区域的像素均值。

2) 曝光控制损失 L_{exp}

用于衡量局部区域亮通道均值 Y_i 与曝光水平 E 之间的差距,控制图像的曝光水平。根据先验知识,在对增强后的图像进行处理时,将其亮通道数值限定于特定区间,能够对图像的曝光程度进行有效调控。大量实验结果表明,在多数场景下,将 E 值设定为 0.6,能够让图像达到较为理想的曝光效果,无论色彩还原度还是细节清晰度,都有较好的呈现。曝光控制损失函数为:

$$L_{exp} = \frac{1}{M} \sum_{i=1}^M |Y_i - E| \quad (4)$$

式中: M 表示大小为 16×16 且不重叠的图像数量; Y_i 表示增强后图像中窗口内的亮度平均值。

3) 颜色恒常损失 L_{col}

依据 Gray-World 颜色恒常性假设理论,在自然环境下,一幅完整图像在各个通道中的颜色均值呈现出灰色特征。基于此原理,研究采用了颜色恒常损失函数 L_{col} 。由于在增强图像时,光照条件的调整、像素值的变换等操作可能会引入潜在的颜色偏差,导致增强后的图像颜色与原始图像相比出现失真。而 L_{col} 函数的主要作用,就是针对这些潜在的颜色偏差进行修正,同时对图像不同通道间的相互关系进行精准调控。它通过对图像内各个像素点的颜色数据进行深度分析与计算,能够敏锐地识别出因拍摄环境、光照条件等因素导致的颜色偏离现象,并运用特定算法对其进行纠正,从而使图像的色彩分布

趋向于真实场景中的表现。颜色恒常损失函数为:

$$L_{col} = \sum_{\forall (p,q) \in \varepsilon} (O^p - O^q)^2, \varepsilon = \{(R,G), (R,B), (G,B)\} \quad (5)$$

式中: J 表示图像增强后通道中平均强度值, 其反映了图像整体的明亮程度以及色彩的强度分布情况; (p, q) 表示通道对。

4) 照度平滑损失 L_{twA}

为防止相邻像素的亮度产生急剧变化, 运用照度平滑损失函数对曲线的参数映射 A 加以调控, 进而实现图像照度的平滑效果。照度平滑损失函数为:

$$L_{twA} = \frac{1}{N} \sum_{n=1}^N \sum_{c \in \delta} (|\nabla x A_n^c| + |\nabla y A_n^c|), \delta = \{R, G, B\} \quad (6)$$

式中: N 为迭代次数; ∇x 和 ∇y 分别为水平和垂直梯度值。

5) 通道一致性损失函数 L_{dv}

在增强过程中 3 个通道有可能出现噪声和无效特征, 这些情况会导致增强后图像与原图像在通道差值之间不致性, 增强效果变差。为了解决这个问题, 采用了通道一致性损失函数, L_{dv} 通道一致性误差如式(7)所示。

$$D_{kl}(P \parallel Q) = \sum_{x \in X} P(x) \log \frac{P(x)}{Q(x)}$$

$$L_{dv} = D_{kl}[R - B \parallel R' - B'] + D_{kl}[R - G \parallel R' - G'] + D_{kl}[G - B \parallel G' - B'] \quad (7)$$

式中: R, G, B 表示原始图像的颜色通道; R', G', B' 表示增强图像的颜色通道。当 P 与 Q 的值相近时 D_{kl} 趋近于 0, 即增强前后的通道间差值相近时 D_{kl} 趋近于 0。

6) 总损失 L_{total}

综上所述, 总损失为:

$$L_{total} = W_{spa} L_{spa} + W_{exp} L_{exp} + W_{col} L_{col} + W_{twA} L_{twA} + W_{dv} L_{dv} \quad (8)$$

式中: $W_{spa}, W_{exp}, W_{col}, W_{twA}, W_{dv}$ 均为可调节权重。

1.4 线性增强

输入图像通过特征提取和迭代过程实现了弱光图像增强。但是由于损失函数限制, 针对极暗光条件下, 有时会出现亮度不足的情况, 为了解决这个问题, 本文提出一种高效且计算成本低廉的亮度调节策略实现进一步图像提亮。不同于动态范围广泛的随机调整方法, 本文采用了一个亮度增强因子 f , 以实现图像整体亮度的线性增强 T 。其增强过程如式(9)所示。

$$P' = T(p; f)$$

$$P' = \min(\max(\lfloor \frac{p}{255} \times f \times 255 \rfloor, 0), 255) \quad (9)$$

式中: p 和 p' 表示增强前后的像素值; $\lfloor \cdot \rfloor$ 表示向下取整。

2 实验与结果分析

2.1 实验设置

本文模型基于 Pytorch v2.0.1 框架进行实现, 该框架运行于 CUDA v11.8 和 CUDNN v8.9.2 环境下。硬件设备选用 NVIDIA GTX 3070 GPU, 卷积的初始参数设定为 0.0 和 0.02。在训练过程中, 采用 Adam 优化算法, 权重衰减设置为 1×10^{-3} , batch size 设定为 16。为了确定各项损失函数的最佳权重, 进行了大量实验数据的对比分析, 结果表明, 当 $W_{spa}, W_{exp}, W_{col}, W_{twA}, W_{dv}, f$ 分别设置为 2、20、10、200、3、1.3 图像增强效果最优。

2.2 数据集

实验采用了 5 个公开数据集用于验证算法的有效性和先进性, 其中, SICE^[9] 数据集用于算法训练, LIME^[10]、DICM^[11]、NPE^[12]、MEF^[13] 和 SICE 用于算法测试。为了确保实验的公平性, 采用与其他研究中相同的实验数据量, 参数如表 1 所示。

表 1 训练与测试数据集参数

名称	训练图像数量	测试图像数量
SICE	2 002	23
LIME	--	10
DICM	--	64
NPE	--	84
MEF	--	17

SICE 数据集由弱光图像及其多个曝光图像组成, 包括 Part1 和 Part2 两部分, 图像分辨率在 $3\ 000 \times 2\ 000 \sim 6\ 000 \times 4\ 000$, 并且以 RGB 格式存储。实验中, 将所用训练图像尺寸统一设置为 512×512 。为了充分发挥模型的动态范围调节能力, 在模型训练过程中采取了独特的策略。将弱光和过曝光的图像进行混合, 弱光图像存在细节难以辨认、整体偏暗的问题, 而过曝光图像则表现为亮度过高、部分细节丢失。将这两种极端情况的图像混合后加入其中, 即采用 Part1 子集中 2 002 幅具有不同曝光水平的图像进行训练, Part2 子集中 228 幅图像的不同曝光程度中随机选择 23 幅弱光图像用于测试。

为了验证模型的泛化能力, 采用 LIME、DICM、NPE、MEF 4 个自然弱光无参考数据集进行测试。这些数据集中不仅包含室内外环境中的自然风光, 还包括人物日常以及建筑等丰富的内容场景。不仅包含弱光图像还包含弱光程度不同的图像, 从而能够充分验证本文方法的有效性和普遍适用性。

2.3 评价指标

为了更客观地评估不同算法的图像增强效果, 本文

引入了经典的图像评价方法对实验结果进行对比分析。所采用的 3 种评价方法可分为两类。有参考的图像评价指标,峰值信噪比(peak signal-to-noise ratio,PSNR)、结构相似性(structural similarity,SSIM);无参考图像评价指标,自然图像质量评估(natural image quality evaluator,NIQE)^[14]。

1)有参考图像评价指标

(1)PSNR

峰值信噪比是一种常用的图像评价指标,主要用于计算两幅图像之间的可视化误差,例如评估原始图像与处理后图像之间的视觉差异,它对图像的噪声和失真情况更为敏感,PSNR 值越高,代表图像质量越好。峰值信噪比的计算公式如式(10)所示。

$$\text{PSNR} = 10 \times \lg\left(\frac{255 \times 255}{\frac{1}{N} \sum_{i=1}^n \sqrt{y_i - \hat{y}_i}}\right) \quad (10)$$

式中: N 表示图像像素的个数; y_i 表示原始图像; $\hat{y}_i$ 表示处理后图像。

(2)SSIM

结构相似性是衡量两张图像相似度的指标。其值的范围为 $[0,1]$,值越大代表两张图像越相似。其计算公式如式(11)所示。

$$\text{SSIM}(a,b) = [l(a,b)]^\alpha [c(a,b)]^\beta [s(a,b)]^\gamma \quad (11)$$

式中: a,b 分别为两幅图像; l,c,s 分别为图像亮度、对比度和结构评价。

$$\begin{aligned} l(a,b) &= \frac{2\eta_a\eta_b + c_1}{\eta_a^2 + \eta_b^2 + c_1} \\ c(a,b) &= \frac{2\mu_{ab} + c_2}{\mu_a^2 + \mu_b^2 + c_2} \\ s(a,b) &= \frac{\mu_{ab} + c_3}{\mu_a\mu_b + c_3} \end{aligned} \quad (12)$$

式中: η 表示图像均值; μ 表示图像标注差; μ_{ab} 表示两幅图像的协方差; c_1,c_2,c_3 分别取 6.502 5、58.522 5、29.261 25。

2)无参考图像评价指标

NIQE 是衡量图像失真和噪声高低程度的一种评价指标,通过一个自然场景统计模型获得质量特征,采用多元高斯模型进行建模后,计算两者多元高斯分布之间的距离,如式(13)所示。数值越小代表图像增强的效果越好。

$$D(\mathbf{v}_1,\mathbf{v}_2,\mathbf{\Sigma}_1,\mathbf{\Sigma}_2) = \sqrt{((\mathbf{v}_1 - \mathbf{v}_2)^\text{T}(\mathbf{\Sigma}_1 - \mathbf{\Sigma}_2)^{-1}(\mathbf{v}_1 - \mathbf{v}_2))} \quad (13)$$

式中: $\mathbf{v}_1$ 表示自然图像 MVG 均值; $\mathbf{v}_2$ 表示 MVG 均值; $\mathbf{\Sigma}_1$ 表示自然图像方差矩阵; $\mathbf{\Sigma}_2$ 表示测试图像方差矩阵。

本文为了验证算法效果,并与其他算法进行对比,数据集与采用评价指标如表 2 所示。

表 2 数据集在 3 种评价指标的应用

Table 2 Application of datasets in three evaluation indicators

评价指标	SICE	LIME	DICM	MEF	NPE
SSIM	√	--	--	--	--
PSNR	√	--	--	--	--
NIQE	--	√	√	√	√

2.4 实验分析

1)定量比较

为了精准评估本文提出的基于跳跃连接神经网络的无监督弱光图像增强算法的实际效能,在实验过程中,采用了结构相似性、峰值信噪比和自然图像质量评价指标,对图像增强后的结果进行多维分析与对比。实验数据及对比结果如表 3 和 4 所示。

表 3 在 SICE 数据集上不同方法的有参考图像质量评价结果

Table 3 The results of image quality evaluation of different methods on the SICE dataset are available

方法	PSNR	SSIM
EnlightenGAN ^[15]	16.21	0.59
RetinexNet ^[16]	15.99	0.53
Zero-DCE	16.57	0.59
Zero-DCE Tiny ^[17]	16.50	0.61
Zero-DCE++ ^[18]	16.42	0.58
本文	18.13	0.74

表 4 LIME、DICM、NPE、MEF 数据集上不同方法的 NIQE 结果

Table 4 NIQE results of different methods on LIME, DICM, NPE, MEF datasets

方法	LIME	DICM	MEF	NPE
RetinexNet	6.53	4.76	4.69	4.69
ZeroDCE	5.07	3.89	4.03	4.03
ElighenGAN	4.54	4.06	3.95	4.45
RUAS	5.39	4.43	5.45	7.09
SCI ^[19]	4.08	4.13	3.60	4.52
文献[20]	4.66	3.87	3.84	4.13
本文	4.04	3.04	3.35	3.83

比较实验结果可知,本文提出的基于跳跃连接多层神经网络的弱光图像增强算法,在图像增强领域展现出卓越性能,各项指标全面超越其他方法。在量化指标方面,该算法能显著提升图像质量。本文方法实现了更高的 PSNR,表示图像信号的噪声干扰更少;SSIM 更大,反映出图像的结构信息保留得更为完整 NIQE 更小,体现出图像质量更接近自然状态。

2) 定性比较

将本文提出的基于增强深度曲线估计网络 EnDCE-Net 的无监督弱光图像增强算法与具有代表性的低照度图像增强算法进行了比较,这些算法包括基于生成对抗网络的 EnlightenGAN, 基于人眼视觉原理的 RetinexNet 方法,以及基于 CNN 增强的 Zero-DCE 和文献[20]算法。结果对比如图 3 所示。




图 3 不同方法对比结果
Fig. 3 Result of image comparison

从对比结果可以看出,本文算法增强后的图像能够在对图像增强的同时更好的保留图像细节,Zero-DCE 算法在提亮后对图像的曝光效果不足;文献[20]算法和 RetinexNet 算法对图像进行增强后存在对比度不足,并且 RetinexNet 算法增强后的图像存在伪彩色的情况;EnlightenGAN 算法存在伪彩色严重的情况。综上所述,本文算法对弱光图像以及极弱光图像细节的保留和曝光恢复程度方面表现较好,具有更好的视觉效果。

为了证明本文方法的有效性,从 4 个数据集中随机选取 8 幅图像可视化结果如图 4 所示。

3) 消融实验

为了验证所提出的弱光图像增强算法中各个模块的有效性,进行了多项消融实验。

(1) 特征提取模块的效果

为了验证特征提取模块的必要性,特征提取模块与 Zero-DCE 中的 DCE-Net 对比结果如图 5 所示。

从图 5 可以看出,DCE-Net 虽然能较好地提取图像的特征,但是细节模糊,边缘特征不显著。本文提出 EnDCE-Net 网络增强了图像的特征,图像的底层特征和边缘信息显著,能够在弱光图像增强过程中更好地完成



图 4 本文算法的弱光图像增强结果
Fig. 4 The low-light image enhancement result of the algorithm in this paper




图 5 特征提取模块消融实验
Fig. 5 Ablation experiment of feature extraction module

特征提取任务。

(2) 各个损失函数的效果

本文对所设计的损失函数与 Zero-DCE 中的损失函数展开了对比分析,并借助 SSIM 和 PSNR 对图像增强效果进行验证。具体实验结果如表 5 和图 6 所示。

表 5 所提出损失函数与 Zero-DCE 损失函数在 SICE 数据集上对比结果

Table 5 Comparison results between the proposed loss function and the Zero-DCE loss function on SICE dataset		
方法	SSIM	PSNR
Zero-DCE	0. 59	16. 57
Zero-DCE+ L_{de}	0. 64	16. 92

与 Zero-DCE 的损失函数相比,本文提出的损失函数在 SSIM 和 PSNR 上分别提升了 0. 3% 和 0. 4%。此外,本文在训练过程中设置了不同的损失函数组合实验,以验证各损失函数的效果。具体实验结果如图 7 所示。




图 6 所提出损失函数与 Zero-DCE 损失函数的对比结果

Fig. 6 Comparison results between the proposed loss function and the Zero-DCE loss function




图 7 损失函数消融实验

Fig. 7 Ablation experiment of loss function

从图 7 可以看出,去除颜色一致性损失 L_{col} ,会导致

出现严重的颜色偏移;去除空间一致性损失 L_{spa} 会导致出现图像对比度降低;去除曝光控制损失 L_{exp} 会导致图像增强无效;去除光照平滑损失 L_{rvd} ,相邻区域间的相关性遭到破坏,进而在图像中产生明显伪影;去除通道一致性损失 L_{dv} 会导致图像在增强过程无法保证通道间一致性,与原图之间差异较大。

(3) 线性增强模块的效果

为了验证可选择的线性增强模块效果,对增强前后的图像进行分析,其结果如表 6 和图 8 所示。

表 6 线性增强模块在 SICE 数据集上消融实验结果

Table 6 Results of ablation experiments with the linear enhancement module on SICE dataset

方法	SSIM	PSNR
Zero-DCE	0. 59	16. 57
Zero-DCE+LTE	0. 64	16. 80
本文 (No-LTE)	0. 73	18. 02
本文	0. 74	18. 13

从表 6 和图 8 可以看出,经过线性增强模块处理后的图像亮度进一步提升,并且通过实验可知,线性增强模块对原始 Zero-DCE 模型的亮度增强不足情况也有改善效果。在实际应用中,由于算法特性,图像可能会出现一定程度的噪声情况。因此,本模块支持根据实际应用需求,灵活选择测试过程中是否添加。当实际应用中对主观可视化亮度要求较高时,采用线性增强模块;当实际应用中对图像质量效果要求较高时,选择不采用该模块,或不考虑算法体积时采用模型较大,使用效果更好的增强模块。




图 8 线性增强模块消融实验结果

Fig. 8 Results of ablation experiments with the linear enhancement module

3 结 论

针对 Zero-DCE 网络存在细节丢失和不同亮度区域处理结果出现差异等问题,提出了一种基于跳跃连接神经网络的无监督弱光图像增强算法。算法创新点包括特征提取模块,损失函数和线性增强模块。核心在于通过学习弱光图像与非配对的正常图像之间的映射关系,实现对弱光图像的有效增强。在实际操作中,算法并不依赖于弱光图像和正常图像的一一对应关系,而是从大量的弱光图像集合以及正常图像集合中,挖掘两者之间潜在的特征关联。实验结果表明,所提出的特征提取网络将输入图像特征更好的提取并保留,所设计的损失函数更好的控制了图像提亮后的色偏问题,线性增强模块使增强图像主观视觉效果更佳。总的来说,本文的研究工作针对实际应用场景中存在的弱光图像问题,提出了一种创新的增强解决方案,为图像分析和理解的后续任务提供有利支持。然而,在应对极弱光情况下的复杂背景图像时,无法全面有效地增强细节信息,增强效果存在一定的局限性。因此,未来的研究方向是利用多层卷积神经网络构建更加有效的细节特征提取与保留策略。

参考文献


- [1] WU C, SHAO S, TUNC C, et al. An explainable and efficient deep learning framework for video anomaly detection [J]. Cluster Computing, 2022, 25: 2715-2737.
- [2] 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.
- [3] 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.
- [4] 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.
- [5] HAI J, XUAN Z, YANG R, et al. R2RNet: Low-light image enhancement via real-low to real-normal network [J]. Journal of Visual Communication and Image Representation. 2023, 90: 103712.
- [6] 程宇, 邓德祥, 颜佳, 等. 基于卷积神经网络的弱光照图像增强算法 [J]. 计算机应用, 2019, 39(4): 1162-1169.
- CHEN Y, DENG D X, YAN J, et al. Low-light image enhancement algorithm based on convolutional neural networks [J]. Computer Applications, 2019, 39(4): 1162-1169.
- [7] 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.
- [8] 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.
- [9] CAI J, GU S, ZHANG L. Learning a deep single image contrast enhancer from multi-exposure images [J]. IEEE Transactions on Image Processing, 2018, 27(4): 2049-2062.
- [10] GUO X, LI Y, LING H. LIME: Low-light image enhancement via illumination map estimation [J]. IEEE Transactions on Image Processing, 2017, 26(2): 982-993.
- [11] LEE C, KIM C S. Contrast enhancement based on layered difference representation of 2D histograms [J]. IEEE Transactions on Image Processing, 2013, 22(12): 5372-5384.
- [12] 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.
- [13] MA K, ZENG K, WANG Z. Perceptual quality assessment for multi-exposure image fusion [J]. IEEE Transactions on Image Processing, 2015, 24(11): 3345-3356.
- [14] MITTAL A, SOUNDARARAJAN R, BOVIK A C. Making a “completely blind” image quality analyzer [J]. IEEE Signal Processing Letters, 2013, 20(3): 209-212.
- [15] GONG Y, LIAO P Y, ZHANG X, et al. Enlighten-GAN for super resolution reconstruction in mid-resolution remote sensing images [J]. Remote Sensing, 2021, 13(6): 1104.
- [16] WEI C, WANG W, YANG W, et al. Deep retinex decomposition for low-light enhancement [J]. ArXiv preprint arXiv:1808.04560, 2018.
- [17] MU W, LIU H, CHEN W, et al. A more effective Zero-DCE variant: Zero-DCE tiny [J]. Electronics, 2022, 11(17): 2750.
- [18] LI C, GUO C, LOY C C. Learning to enhance low-light image via zero-reference deep curve estimation [J]. IEEE Transactions on Pattern Analysis and Machine

Intelligence, 2021, 44(8): 4225-4238.

[19] 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.

[20] WU Y. Unsupervised low-light enhancement method based on attention mechanism [C]. 2023 IEEE International Conference on Image Processing and Computer Applications (ICIPCA), 2023.

作者简介



刘洋,2001 年于辽宁石油化工大学获得学士学位,2004 年于东北大学获得硕士学位,2014 年于南京航空航天大学获得博士学位,现为沈阳航空航天大学副教授,主要研究方向为深度学习与图像处理。
E-mail: yang97_net@ sau. edu. cn

Liu Yang received her B. Sc. degree from Liaoning Petrochemical University in 2001, M. Sc. degree from Northeastern University in 2004 and Ph. D. degree from Nanjing University of Aeronautics and Astronautics in 2014, respectively. Now she is an associate professor at Shenyang Aerospace University. Her main research interests include deep learning and image processing.



刘思瑞(通信作者),2022 年于沈阳航空航天大学获得学士学位,现为沈阳航空航天大学硕士研究生,主要研究方向为深度学习与图像处理、暗光图像增强。
E-mail: lsraizyy@ 163. com

Liu Sirui (Corresponding author) received his B. Sc. degree from Shenyang Aerospace University in 2022. Now he is a M. Sc. candidate at Shenyang Aerospace University. His main research interests include deep learning and image processing, low-light image enhancement.