

基于IB-UNet的零参考低照度图像增强方法

何天歌

兰州交通大学光电技术与智能控制教育部重点实验室, 甘肃 兰州

收稿日期: 2024年6月27日; 录用日期: 2024年7月24日; 发布日期: 2024年7月31日

摘要

在图像增强领域, 成对数据的过分依赖可能导致模型过度拟合, 影响其泛化能力。为了解决这一问题, 本文提出了一种无监督学习方法, 该方法受到Zero-DCE网络架构的启发, 采用了基于IB-UNet的零参考图像增强方法。该方法直接学习图像的深层特征, 提高了图像特征纹理的提取效率, 从而在不依赖成对参考数据的情况下, 有效提升低照度图像的增强质量。通过客观指标评估, 结合不同模型的对比试验与消融实验, 客观验证了所提出模型的优势, 展示了其在图像增强任务中的潜力和实用性。

关键词

无监督学习, 图像增强, 低照度图像

A Zero Reference Low Illumination Image Enhancement Method Based on IB-UNet

Tiange He

Key Laboratory of Opt-Electronic Technology and Intelligent Control of Ministry of Education, Lanzhou Jiaotong University, Lanzhou Gansu

Received: Jun. 27th, 2024; accepted: Jul. 24th, 2024; published: Jul. 31st, 2024

Abstract

In the field of image enhancement, an over-reliance on paired data can lead to overfitting of the model, which affects its generalization ability. To address this issue, this paper proposes an unsupervised learning method inspired by the Zero-DCE network architecture, which employs a zero-reference image enhancement method based on IB-UNet. This method directly learns the deep features of the image, improving the efficiency of extracting image feature textures, thereby effectively enhancing the quality of low-illumination images without relying on paired reference data. Through objective metrics evaluation, combined with comparative experiments of different mod-

els and ablation experiments, the advantages of the proposed model are objectively verified, demonstrating its potential and practicality in the task of image enhancement.

Keywords

Unsupervised Learning, Image Enhancement, Low-Illumination Images

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

在低光照条件下拍摄的图像往往会遇到细节模糊和对比度不足等问题，这些问题严重影响了图像的质量和信含量。Lv 等人[1]提出了一个多分支增强网络(MBLLEN)，它通过将网络架构划分为三个关键组成部分，即特征提取、增强和融合模块来实现高效的图像增强，特征提取模块负责从输入的图像中提取低频和高频特征，并将它们分别送入增强模块进行处理。随后，融合模块将经过增强的多尺度特征进行有效整合。Zero-DCE [2]通过一组非参考损失函数实现零次学习，其与需要高计算资源的图像重建方法不同，图像与曲线间的映射关系仅仅需轻量级的网络实现，加速了它推演的效率。Zhang 等人提出的 ExCNet [3]是首个基于无监督 CNN 的逆光图像恢复方法，利用 CNN 结构学习图像与最佳“S 曲线”参数之间的映射关系，用来直接调整基础图形层，作者以基于块的能量最简化问题定义损失函数，该方法在处理视频流时表现较好性能。RRDNet 是三支 CNN 网络，不需要先验或预学习，其权重是通过特别的损失函数反复最小化零样本方法来更新的[4]，这样的损失函数是为了评估测试图像的当前分解并导出噪声估计而设计的，能够实现全面真实且令人愉悦的视觉质量，达到鲁棒的校正效果。MZSL 利用多模态数据和先验知识来增强模型对未见类别的识别力，设计了有效的多模态特征融合机制[5]、选择了合适的先验知识表示并优化以处理多模态数据的异质性模型，为以后的发展提供新思考。Ren 等人提出零样本视觉语义分割，它通过利用少量或没有标记样本的情况来提高模型对未见类别的识别能力[6]，从而扩展了视觉语义分割技术的应用范围，拓宽了低照度图像增强的视野。

低照度图像增强技术作为图像处理领域的关键分支，旨在通过提升图像的亮度和降低噪声来增强对比度和丰富图像信息。由于 Zero-DCE 模型[1]导致网络在泛化方面的表现不尽人意，无法有效提取图像的细和边缘信息。因此为了获取到更多的细和边缘信息，本文提出了基于 IB-UNet 的零参考低照度图像增强方法，IB-UNet 是在 U-Net [7]网络的颈部使用 Inception 模块来进行多尺度语义信息的融合，提取深层细和特征，最后将获取拟合的曲线特征参数图来迭代的进行图像增强。并以客观指标来评估模型对低照度图像的增强质量、结合不同模型对比试验与消融实验客观验证本模型的优势。

2. 特征提取模块

IB-UNet 模型是基于经典的 U-Net 架构，在网络的瓶颈位置引入了 Inception 模块，这一设计扩展了网络的感受野，使得模型能够捕获更广泛的上下文信息和全局特征，其架构如图 1 所示。

Inception 模块通过并行应用不同尺寸的卷积核以及最大池化操作，从而在不显著增加参数数量的前提下，提取多尺度特征，其核心思想是在网络的同一层中并行应用不同尺寸的卷积核，从而能够同时捕捉到图像的局部细和和全局上下文信息，它允许模型在不同层次上学习到丰富的特征表示，提高了网络

的性能和泛化能力。如图 2。




Figure 1. IB UNet Module

图 1. IB-UNet 模块




Figure 2. Inception Module

图 2. Inception 模块

3. 循环图像增强模块

循环图像增强网络通过迭代的方式逐步调整图像的亮度，每一轮迭代都会根据前一轮的结果和特定的增强系数来优化图像，通过其自适应的迭代机制，能够在缺乏标准参考图像的条件下，有效地提高效率。

这种增强系数是一个动态映射参数，允许网络对每个像素进行精确的调整。其工作原理可表达为：

$$E_n(x) = E_{n-1}(x) + \lambda_n(x) E_{n-1}(x) (1 - E_{n-1}(x)) \quad (1)$$

其中, $\lambda_n(x)$ 作为映射参数矩阵, 决定了如何根据前一轮的输出 $E_{n-1}(x)$ 动态调整当前轮的增强效果。门控因子 $1-E_{n-1}(x)$ 则保证了处理过程不过度增强, 保持了图像增强的均衡性。

本文模型如图 3 所示, 该网络使用 U-Net 结构作为主体来改善 Zero-DCE 中局部特征提取的能力不足的问题, 同时 IB-UNet 网络在 U-Net 的瓶颈处使用了 Inception 模块来获取到多尺度的深层语义信息, 扩大感受野, 捕获更广泛的上下文信息, 有助于模型在面对多样化的训练数据时, 能够提高其泛化能力。最后估计出图像的高阶特征曲线, 然后通过循环增强模块对图像进行迭代性低照度增强。




Figure 3. Zero Reference Network Architecture Based on IB-UNet

图 3. 基于 IB-UNet 的零参考网络架构

4. 损失函数

本文方法通过空间一致性损失、曝光控制损失、颜色恒常损失和照明平滑损失, 它们共同作用于训练过程中, 以确保输出图像的视觉自然性。

1) 空间一致性损失 $\mathcal{L}_{spa}$:

$$\mathcal{L}_{spa} = \frac{1}{K} \sum_{i=1}^K \sum_{j \in \Omega(i)} \left| (Y_i - Y_j) - (I_i - I_j) \right| \quad (2)$$

其中, K 代表局部区域数目, $\Omega(i)$ 是区域 i 各方向的邻域, I 与 Y 分别代表处理前、后图像局部的强度平均值。

2) 曝光控制损失 $\mathcal{L}_{exp}$:

$$\mathcal{L}_{exp} = \frac{1}{M} \sum_{k=1}^M |Y_k - E| \quad (3)$$

其中, M 为未重叠局部数, E 表示 RGB 图像空间恢复水平。

3) 颜色恒常损失 $\mathcal{L}_{col}$:

$$\mathcal{L}_{col} = \sum_{(p,q) \in \epsilon} (J_p - J_q)^2 \quad (4)$$

其中, J_p 代表输出图像 p 通道的平均强度, ϵ 代表通道集合。

4) 照明平滑损失 $\mathcal{L}_{tvA}$:

$$\mathcal{L}_{tvA} = \frac{1}{N} \sum_{n=1}^N \sum_{c \in \xi} (|\nabla_x A_c^n| + |\nabla_y A_c^n|)^2, \xi = \{R, G, B\} \quad (5)$$

其中, N 代表迭代次数, ∇ 代表梯度操作。

5. 实验结果对比

本文以 LOL 数据集[8]为训练集, 其含有 1000 张两两成对的低光与正常光图像, 为衡量本章模型的增强效率, 进而验证本文方法的适行度, 选取主流的 2 个经典方法与 2 个无监督学习的方法与本章方法作比较, 选取的对比实验方法的详细介绍如表 1 所示。

Table 1. Comparative experimental methods

表 1. 对比实验方法

方法	模型类型	模型简介
LIME [9]	传统算法模型	基于视觉恒常性理论的总变分模型
MSR [10]	传统算法模型	基于视觉恒常性理论的多尺度颜色恢复模型
SCI [11]	无监督模型	基于零参考的自校准照明图像恢复模型
Zero-DCE	无监督模型	基于深度拟合图像特征曲线的细节恢复模型

与传统处理方法的颜色剧烈失真现象相比, 本章处理结果颜色流畅度与自然度均有极大提升, 与无监督方法暗区细节呈现差, 中亮区伪影较多和亮区过曝光并导致边缘流失, 本方法在细节处理、边缘检测和颜色恢复方面表现良好, 处理后的图像在细节呈现、调和曝光与突出边缘等方面取得高质量表现。如下图 4 所示。



Figure 4. Comparison experiment diagram

图 4. 对比实验图

为验证本章提出的网络的性能，通过对比各种模型在相同数据集上提升效果的差异，在 LOL 数据集上的结果对比如表 2 所示。本章方法在参考指标 PSNR、SSIM 上都有一定的提升，对于非参考指标 NIQE 上实现了一个最优的效果，但在 LOE 上没有明显的优势，整体上性能有一定的提升。

Table 2. LLIE performance of different models on the LOL dataset
表 2. 不同模型在 LOL 数据集上的 LLIE 效果

Methods	PSNR	SSIM	LOE	NIQE
LIME	16.758	0.563	817.1	9.130
MSR	13.172	0.476	2589.2	8.123
Zero-DCE	17.842	0.835	579.2	4.203
SCI	21.482	0.871	276.3	3.661
Ours	21.811	0.882	512.3	3.671

为进一步客观验证本章方法的可行性，基于 LOL 数据集进行可行性验证，验证过程包含 4 个消融模型：分别代表在本章方法上取消各改进操作后的模型，并将基准模型作为参照，验证两处改进共同作用的有效性。其中 Without IB-UNet 表示消除特征提取模块 IB-UNet 结构后的模型（本章基准模型）；Without Inception 表示消除 IB-UNet 结构中 Inception 模块后的模型；Ours 代表对改进后的本章方法。消融结果如表 3 所示。

Table 3. Comparison of ablation models in the LOL dataset
表 3. 消融模型在 LOL 数据集效果对比

Methods	PSNR	SSIM	LOE	NIQE
Without IB-UNet	18.371	0.852	564.1	4.031
Without Inception	19.568	0.849	535.4	3.949
Without All	17.842	0.835	579.2	4.203
Ours	21.811	0.882	512.3	3.671

由于本章模型在 4 项指标所表述的性能数据上均有不错的改善，证实了 IB-UNet 结构与图像深度特征曲线的结合合理有效，进而客观验证了在它们共同作用下本章模型的性能得到提升，证实本章方法的合理性和可行性。

6. 结论

本文以 Zero-DCE 模型为基准，对特征提取模块中特征提取不足的问题，使用 IB-UNet 来进行特征的深度提取，同时通过 Inception 模块来进行多尺度特征的提取，以达到优化特征提取网络，获取良好的高阶特征曲线。针对日常生活中低照度图像缺乏参考图像的缺点，使用无监督方法，突破参考图像的约束，有效推进 LLIE 发展进程，提高社会生活质量。针对 Zero-DCE 中处理中的缺陷，如光照不均匀、特征提取不充分、颜色失真等问题，提出了基于 IB-UNet 的零参考图像增强网络法，并通过实验进行了验证，从客观评价指标和主要视觉效果上对模型进行了评估，证实了本章方法的可行性和有效性。

综上所述，本研究提出的图像增强方法在特征细节呈现和颜色优化方面取得了显著进展。通过结合先进的深度学习技术和创新的网络架构，能够有效提升低质量图像的信息提取效率，为智能科技应用的

发展提供了强有力的支持。

参考文献

- [1] Lv, F., Lu, F., Wu, J., *et al.* (2018) MBLLEN: Low-Light Image/Video Enhancement Using CNNs. *BMVC*, **220**, 4.
- [2] Guo, C., Li, C., Guo, J., Loy, C.C., Hou, J., Kwong, S., *et al.* (2020) Zero-Reference Deep Curve Estimation for Low-Light Image Enhancement. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, 13-19 June 2020, 1777-1786. <https://doi.org/10.1109/cvpr42600.2020.00185>
- [3] Zhang, L., Zhang, L., Liu, X., Shen, Y., Zhang, S. and Zhao, S. (2019) Zero-shot Restoration of Back-Lit Images Using Deep Internal Learning. *Proceedings of the 27th ACM International Conference on Multimedia*, Nice France, 21-25 October 2019, 1623-1631. <https://doi.org/10.1145/3343031.3351069>
- [4] Zhu, A., Zhang, L., Shen, Y., Ma, Y., Zhao, S. and Zhou, Y. (2020) Zero-Shot Restoration of Underexposed Images via Robust Retinex Decomposition. 2020 *IEEE International Conference on Multimedia and Expo (ICME)*, London, 6-10 July 2020, 1-6. <https://doi.org/10.1109/icme46284.2020.9102962>
- [5] Cao, W., Wu, Y., Sun, Y., Zhang, H., Ren, J., Gu, D., *et al.* (2023) A Review on Multimodal Zero-Shot Learning. *WIREs Data Mining and Knowledge Discovery*, **13**, e1488. <https://doi.org/10.1002/widm.1488>
- [6] Ren, W., Tang, Y., Sun, Q., Zhao, C. and Han, Q. (2024) Visual Semantic Segmentation Based on Few/Zero-Shot Learning: An Overview. *IEEE/CAA Journal of Automatica Sinica*, **11**, 1106-1126. <https://doi.org/10.1109/jas.2023.123207>
- [7] Ronneberger, O., Fischer, P. and Brox, T. (2015) U-Net: Convolutional Networks for Biomedical Image Segmentation. *Lecture Notes in Computer Science*, **9351**, 234-241. https://doi.org/10.1007/978-3-319-24574-4_28
- [8] Wei, C., Wang, W., Yang, W., *et al.* (2018) Deep Retinex Decomposition for Low-Light Enhancement. arXiv: 1808.04560.
- [9] Guo, X., Li, Y. and Ling, H. (2017) LIME: Low-Light Image Enhancement via Illumination Map Estimation. *IEEE Transactions on Image Processing*, **26**, 982-993. <https://doi.org/10.1109/tip.2016.2639450>
- [10] Shen, L., Yue, Z., Feng, F., *et al.* (2017) MSR-Net: Low-Light Image Enhancement Using Deep Convolutional Network. arXiv: 1711.02488.
- [11] Ma, L., Ma, T., Liu, R., Fan, X. and Luo, Z. (2022). Toward Fast, Flexible, and Robust Low-Light Image Enhancement. 2022 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, New Orleans, 18-24 June 2022, 5627-5636. <https://doi.org/10.1109/cvpr52688.2022.00555>