

# 采用两阶段混合策略实现的低照度图像增强算法

徐少平, 陈孝国, 李 芬, 林珍玉, 陈晓军

(南昌大学信息工程学院, 江西南昌 330031)

**摘 要:** 在深入分析现有各主流低照度图像增强(Low Light Image Enhancement, LLIE)算法的基础上, 提出了一种采用两阶段混合策略实现的低照度图像增强(Hybrid LLIE, HLLIE)算法. 具体地, 在第一阶段, 对于给定的低照度图像, 利用互补效果较好的 Fu 和 Ying 两个主流 LLIE 算法分别对其进行增强预处理, 所得到的两张增强后图像称为初步增强图像; 在第二阶段, 将所得到的两张初步增强图像输入到预先训练好的多通道浅层卷积神经网络(Multi-channel Shallow Convolution Neural Network, MSCNN)模型中, 由 MSCNN 模型将两张初步增强图像优化组合为一张具有更高图像质量的最终增强图像. 实验结果表明: 与各主流 LLIE 算法相比, 所提出的 HLLIE 算法在各个客观图像质量评价指标上有显著优势, 人工主观评价亦能证实这一点.

**关键词:** 低照度图像增强; 两阶段混合策略; 初步增强图像; 多通道浅层卷积神经网络; 组合

**中图分类号:** TP391.41      **文献标识码:** A      **文章编号:** 0372-2112(2021)11-2166-05

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20201018

## A Low-Light Image Enhancement Algorithm Using Two-Stage Hybrid Strategy

XU Shao-ping, CHEN Xiao-guo, LI Fen, LIN Zhen-yu, CHEN Xiao-jun

(School of Information Engineering, Nanchang University, Nanchang, Jiangxi 330031, China)

**Abstract:** After carefully analyzing the characteristics of existing low light image enhancement (LLIE) algorithms, we proposed a hybrid LLIE (HLLIE) algorithm with two-stage hybrid strategy. Specifically, in the first stage, for a given low-light image, we chose the complementary LLIE algorithms, i.e., Fu and Ying, to enhance the low-light image, respectively. In the second stage, the two preliminary enhanced images were used as the inputs of the multi-channel shallow convolution neural network (MSCNN), and then the pre-trained MSCNN conducted optimal combination of the two preliminary enhanced images to achieve further enhancement regarding the image quality. The experimental results show that, compared with the state-of-the-art LLIE algorithms, the HLLIE algorithm has obvious advantages in terms of the objective image quality metrics on the low-light images, and the subjective evaluation also can confirm this.

**Key words:** low-light image enhancement; two-stage hybrid strategy; initial enhanced image; multi-channel shallow convolution neural network; combination

### 1 引言

在微光、夜间、背光等照明条件下, 各种成像设备所获取的图像在内容的对比度、可分辨程度上通常都比较差, 不经妥善处理将严重影响后续图像处理任务的顺利执行. 为此, 研究者们提出了大量的低照度图像增强(Low Light Image Enhancement, LLIE)算法来提高低照度图像的图像质量<sup>[1-4]</sup>. 根据具体所采用的实现策略, 主流的 LLIE 算法可以大致分为基于直方图均衡化

(Histogram Equalization, HE)<sup>[5]</sup>、基于 Retinex 模型<sup>[6]</sup>、基于图像融合<sup>[7]</sup>、基于深度学习<sup>[8]</sup>等几类. 其中, 后三者近年来受研究者关注度最高, 是主流的实现策略. 一般地, 基于 Retinex 模型的 LLIE 算法所获得的增强图像, 整体上比较符合人类视觉感知特点, 但是由于照射分量和反射分量的分离操作还不能达到理想意义上的完全分离, 故这类算法对图像中某些局部纹理细节的处理并不是很好, 容易导致模糊的现象<sup>[9]</sup>. 近年来, 研究者开始采用多曝光图像融合(Multi-exposure Image Fu-

sion, MEF)策略实现了一类 LLIE 算法. 基于融合策略实现的 LLIE 算法虽在视觉上对图像细节的增强效果比较好,但对增强过程中所引入的噪声和颜色失真的处理能力不强<sup>[7]</sup>. 随着神经网络在图像处理领域的广泛应用,基于深度学习的 LLIE 算法成为研究者关注的热点. 该类方法所实现的 LLIE 算法能充分利用自然图像中所蕴含的先验知识对低照度图像进行增强. 一般来说,基于机器学习实现的 LLIE 算法充分利用深度神经网络模型强大的非线性映射能力,能将输入的低照度图像映射为视觉上令人满意的输出图像<sup>[8]</sup>. 然而,这些模型易受数据依赖问题的困扰<sup>[10]</sup>,当低照度图像明显异于训练模型所使用的图像集时,增强效果将受到显著影响.

在目前所提出的各类主流 LLIE 算法中,仅依靠单一策略实现的增强算法无法保证其能达到最佳的增强效果,或多或少存在着不足. 为此,本文提出了一种新的采用两阶段混合策略实现的低照度图像增强(Hybrid LLIE, HLLIE)算法. 该算法利用多通道浅层卷积神经网络(Multi-channel Shallow Convolutional Neural

Network, MSCNN)接收 Fu<sup>[6]</sup>和 Ying<sup>[9]</sup> 2 个互补性较好的主流 LLIE 算法处理给定低照度图像所获得的初步增强图像,充分利用卷积神经网络强大的非线性映射能力将两张互补的初步增强图像组合成为图像质量更高的最终增强图像.

## 2 HLLIE 算法

### 2.1 改进方法与实现框架

如图 1 所示,所提出的 HLLIE 算法执行流程可以分为两个阶段:预处理阶段和组合阶段. 其中,预处理阶段首先使用  $n$  个具有互补性的低照度图像增强算法(作为增强器)分别对给定的低照度图像进行增强得到  $n$  张初步增强图像(实际仅使用 Fu<sup>[6]</sup>和 Ying<sup>[9]</sup>算法生成 2 张初步降噪图像). 在组合阶段使用的 MSCNN 网络结构采用了深度卷积网络中常采用的 Conv+BN+ReLU 网络结构<sup>[11]</sup>,将预先得到的  $n$  张初步增强图像同时输入到 MSCNN 网络中得到残差图像(利用残差学习技术),将输入的  $n$  张初步增强图像的均值  $\bar{L}$  加上残差图像  $R(\bar{L})$  即可获得最终的增强图像  $\hat{x}$ .

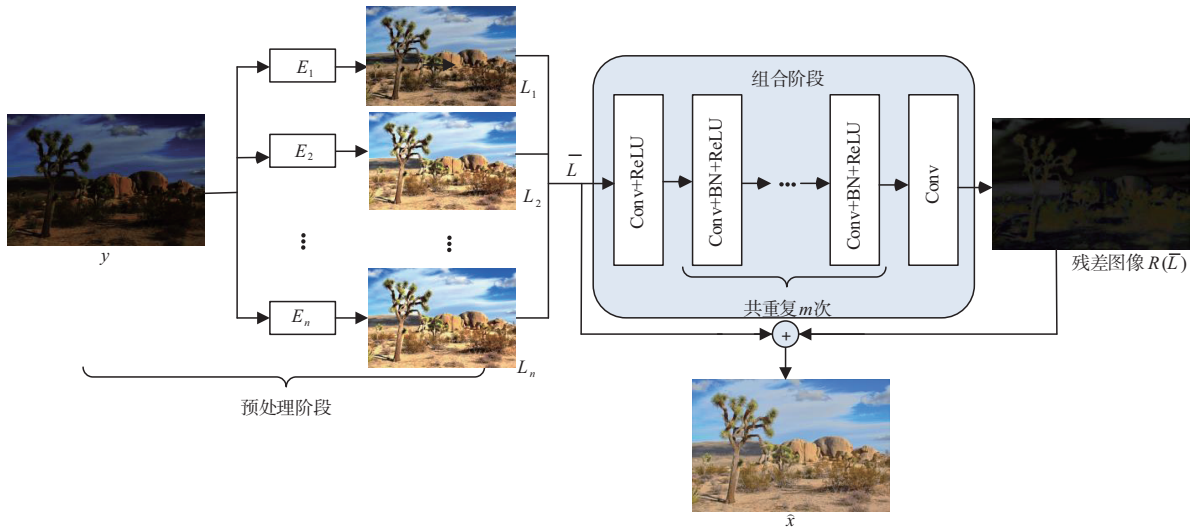


图 1 两阶段 HLLIE 算法的执行流程

具体地,第一层(Conv+ReLU)使用 64 个大小为  $3 \times 3 \times n$  的滤波器主要作用在于接受  $n$  张初步增强图像,并对输入图像执行局部加权组合. 线性修正单元(Rectified Linear Units, ReLU)作为非线性激活函数,共输出 64 个特征映射图. 中间若干层使用多个(Conv+BN+ReLU)重复结构,仍然使用 64 个大小为  $3 \times 3$  的滤波器,并在卷积和非线性激活的基础上增加了批归一化(Batch Normalization, BN)操作. 最后一层(Conv)只用了 1 个通道的卷积层输出残差图像,利用残差图像与输入图像的均值图像即可重构增强后的图像.

### 2.2 混合策略优势

HLLIE 算法充分利用了非数据驱动和数据驱动两大类 LLIE 算法的各自优势. 其中,非数据驱动的非 Fu 和 Ying 算法受图像内容的限制少,且所获得增强图像在图像质量上具有很好的互补性,相对于低照度图像来说图像质量已经大幅度得到改善,可以确保第二阶段组合器的性能受数据依赖缺陷的制约大幅度减弱;另外一方面,一旦组合器训练完成,图像融合过程能充分利用训练所获得的先验知识,无需手工计算融合权重,能自动为输入的图像设置融合权重以获得最佳的增强图像.

### 3 具体实现

#### 3.1 模型训练

形式化地,对于给定的一张低照度图像 $y$ ,HLLIE算法首先使用 $n$ 个低照度图像增强器 $E_1, E_2, \dots, E_n$ 分别对输入的低照度图像进行初步增强,得到 $n$ 张初步增强图像 $L_1, L_2, \dots, L_n$ ;其次,将所得到的初步增强图像 $L_1, L_2, \dots, L_n$ 同时输入MSCNN网络中进行自动组合完成图像质量再次增强.MSCNN网络利用了残差学习(Residual Learning)技术,对所得的初步增强图像求均值得到均值图像 $\bar{L}$ 并将其作为MSCNN网络的输入,并利用该网络输出均值图像的残差图像 $R(\bar{L})$ ,通过将均值图像 $\bar{L}$ 与残差图像 $R(\bar{L})$ 相加即可得到一张最终的增强图像 $\hat{x}$ .为训练所提出的MSCNN模型,从文献[12]中所提出的数据库中随机选取200张图像作为训练集 $Y = \{y_1, y_2, \dots, y_{200}\}$ ,用于训练的每张图像都有与之对应的原始无失真标签(Label)图像.首先,利用 $n$ 个低照度图像增强器分别对训练集中的低照度图像进行初步增强,得到 $n$ 张增强后图像 $(L_1^1, L_1^2, \dots, L_1^{200}), (L_2^1, L_2^2, \dots, L_2^{200}), \dots, (L_n^1, L_n^2, \dots, L_n^{200})$ ;再将所得的 $n$ 张增强图像的均值图像和相应的残差图像组成的训练对 $\{(\bar{L}_i, R(\bar{L}_i))\}_{i=1}^n$ 输入MSCNN网络模型中进行训练.其中, $\bar{L}_i$ 为 $n$ 个初步增强图像的均值图像作为网络的输入,而均值图像 $\bar{L}_i$ 与对应Label图像之间的残差图像 $R(\bar{L}_i)$ 作为网络的输出.需要说明的是:具体实现时, $n$ 值实际取值为2,HLLIE算法仅利用Fu和Ying算法作为增强器,MSCNN网络为双通道结构.

#### 3.2 组合模式分析

理论上讲,任意多种LLIE算法均可以用于预处理阶段,但其实它们之间的搭配组合模式对第二阶段

的影响会有较大区别,它们之间的互补性存在一定的差别.实验数据表明:2个以上的LLIE算法对增强效果的提升幅度并不是很大(限于篇幅,文中未提供相应的实验数据),本文仅考虑两种主流LLIE算法.为了确定各种LLIE算法之间的最佳的两两组合模式,分别使用HVS<sup>[13]</sup>、Ying<sup>[7]</sup>、Fu<sup>[6]</sup>、LIME<sup>[9]</sup>、Li<sup>[14]</sup>和Fu2016<sup>[15]</sup>这6个具有代表性的非数据驱动的LLIE算法进行两两组合测试,其所有可能的组合方式如表1所示.

表1 两种增强算法组合模式列表

组合模式		组合模式	
Case1	Fu+LIME	Case2	Fu2016+LIME
Case3	Fu+Fu2016	Case4	Fu+Li
Case5	Li+LIME	Case6	Fu2016+Li
Case7	Li+Ying	Case8	Li+HVS
Case9	Fu+HVS	Case10	Fu+Ying
Case11	Fu2016+HVS	Case12	LIME+HVS
Case13	Fu2016+Ying	Case14	HVS+Ying
Case15	LIME+Ying	-	-

为了测试主流LLIE算法最佳的组合模式,从文献[12]中所提的图像集中随机选取90张低照度图像(与训练阶段所使用的图像不重叠)进行了测试.由于这些用于测试的低照度图像都有与其对应的Label图像,故可以使用IW-PSNR(Information Content Weighted Peak Signal to Noise Ratio)<sup>[16]</sup>和IW-SSIM(Information Content Weighted Structural Similarity)<sup>[16]</sup>2个有参考的图像质量评价指标衡量各种组合模式的增强效果.IW-PSNR和IW-SSIM指标值其值越大,表明图像增强的效果越好.从表2中可知:Case10所代表的Fu和Ying算法组合模式在IW-PSNR和IW-SSIM指标上表现最佳,因此本文选用Fu和Ying算法作为MSCNN模型的预处理增强算法.

表2 各种算法组合在90张低照度图像上所获评价指标值的平均值

评价指标	组合模式							
	Case1	Case2	Case3	Case4	Case5	Case6	Case7	Case8
IW-PSNR	23.6894	22.0059	21.3225	22.5234	22.3017	21.5752	22.5093	21.6897
IW-SSIM	0.9417	0.9156	0.9123	0.9294	0.9215	0.9181	0.9354	0.9135
	Case9	Case10	Case11	Case12	Case13	Case14	Case15	-
IW-PSNR	22.6713	<b>24.3390</b>	23.0180	22.2188	21.9148	23.4783	21.7534	-
IW-SSIM	0.9298	<b>0.9510</b>	0.9368	0.9183	0.9219	0.9441	0.9203	-

#### 3.3 MSCNN网络层数选择

如表3所示,通过对比有参考图像评价指标IW-PSNR值可以看出,随着Conv+BN+ReLU层数的增加,HLLIE算法的图像增强效果仅在Conv+BN+ReLU网络层数重复次数为15时有小幅度提升,与重复次数为1时相比仅提高了0.18dB.而由表4中对应的执行时间可知,在核心网络层重复次数分别为15和1时,其平

均执行时间相差一倍.故综合考虑模型的执行效率和增强性能,将Conv+BN+ReLU网络层重复次数设置为1.

## 4 实验与分析

#### 4.1 测试环境

为了验证所提出的HLLIE增强算法对低照度图像

表 3 不同 MSCNN 网络模型在 90 张低照度图像上的 IW-PSNR 均值 (单位: dB)

评价指标	Conv+BN+ReLU 网络层重复的次数						
	1	3	5	7	9	12	15
IW-PSNR	22.89	21.28	21.50	21.48	22.27	22.43	23.07

表 4 在不同网络层数下的 MSCNN 网络模型在 90 张低照度图像上的平均执行时间 (单位: s)

评价指标	Conv+BN+ReLU 网络层重复的次数						
	1	3	5	7	9	12	15
IW-PSNR	0.09	0.12	0.14	0.12	0.13	0.15	0.18

的增强效果,从文献[14, 17, 18]中收集了 50 张低照度图像组成无参考(无 Label 图像)图像集. 另外,从文献[12]所使用的图像集中随机选取了 90 张低照度图像作

为有参考图像集,该测试集中图像均含有对应的 Label 图像作为参考图像. 所有实验均在统一环境下(Intel(R) Core(TM) i7-3770 CPU @ 3.40GHz 16GB RAM)完成的.

### 4.2 主观图像质量评价

如图 2 所示,House 图像不同区域的曝光程度差异比较大,部分区域(左半边)曝光度较差,而部分区域(右半边)曝光度尚可. 总体来说,HLLIE 算法从视觉上看亮度和对比度均较为适中,细节展示的非常好,整体视觉效果与 Label 图像最为接近,显著优于对比算法. 表明 MSCNN 网络充分利用了 Fu 和 Ying 算法所得到的两张初步增强图像中的互补性信息,在提高图像亮度的同时能很好地增强图像纹理细节. 另外,从 IW-PSNR 指标值也验证了 HLLIE 算法的增强效果是最好的.

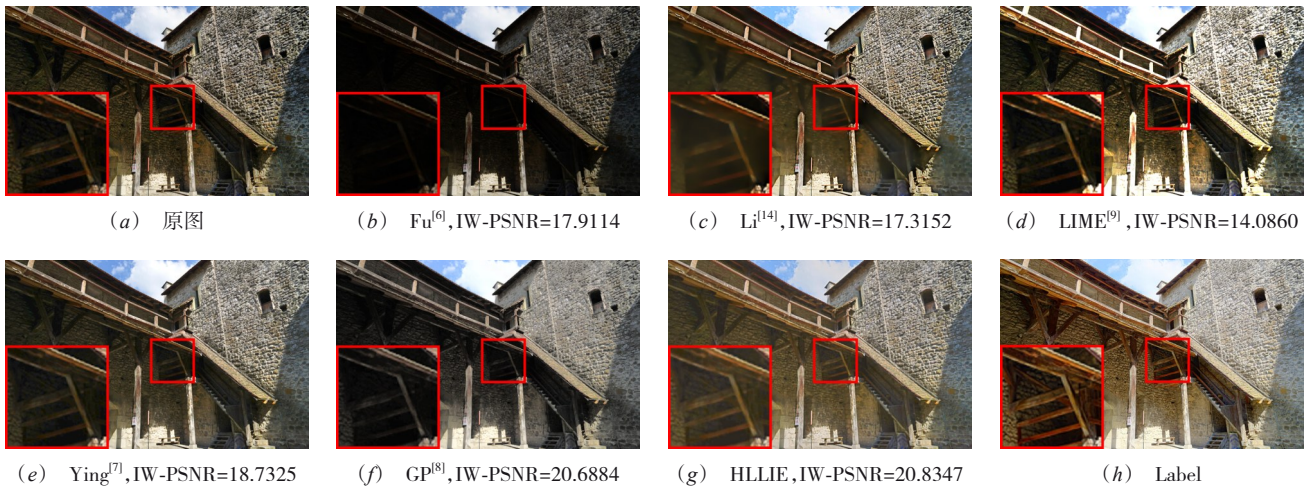


图 2 各个算法在 House 图像上的增强效果对比

### 4.3 算法整体性能评价

由表 5 可以看出:所提出的 HLLIE 算法的整体性能与上文在单个图像上所表现出的情况类似,其平均性能仍然是最佳的,显著优于各个对比算法.

表 5 各对比算法在 90 张低照度图像上客观评价指标的平均值

评价指标	对比算法					
	Fu <sup>[6]</sup>	Li <sup>[14]</sup>	LIME <sup>[9]</sup>	Ying <sup>[7]</sup>	GP <sup>[8]</sup>	HLLIE
IW-PSNR	19.8241	22.0265	15.3176	22.1174	19.7818	24.3390
IW-SSIM	0.9117	0.9316	0.8403	0.9433	0.9029	0.9510

## 5 总结

提出利用 MSCNN 网络接收主流 Fu 和 Ying 低照度增强算法生成的 2 张互补性较好的初步增强图像,并将它们最佳组合后作为最终的增强图像. 实验结果表明:相对于参与比较的各主流 LLIE 算法,HLLIE 算法对于

低照度图像具有更好的增强效果,对不同内容的场景也更为鲁棒.

### 参考文献

[1] Wang Y F, Liu H M, Fu Z W. Low-light image enhancement via the absorption light scattering model[J]. IEEE Transactions on Image Processing, 2019, 28(11): 5679 – 5690.  
 [2] Ren Y R, Ying Z Q, Li T H, et al. LECARM: Low-light image enhancement using camera response model[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2019, 29(4):968 – 981.  
 [3] Guo Y H, Ke X, Ma J, et al. A pipeline neural network for low-light image enhancement[J]. IEEE Access, 2019, 7: 13737 – 13744.

- [4] Park S, Yu S, Kim M, et al. Dual autoencoder network for Retinex-based low-light image enhancement[J]. IEEE Access, 2018, 6:22084 – 22093.
- [5] Cheng H D, Shi X J. A simple and effective histogram equalization approach to image enhancement[J]. Digital Signal Processing, 2004, 14(2):158 – 170.
- [6] Fu X Y, Zeng D L, Yue H, et al. A weighted variational model for simultaneous reflectance and illumination estimation[A]. 2016 IEEE Conference on Computer Vision and Pattern Recognition[C]. USA:IEEE, 2016. 2782 – 2790.
- [7] Ying Z Q, Ge L, Ren Y R, et al. A new image contrast enhancement algorithm using exposure fusion framework[A]. International Conference on Computer Analysis of Images and Patterns[C]. Sweden:Springer Verlag, 2017.36 – 46.
- [8] Loh Y P, Liang X F, Chan C S. Low-light image enhancement using Gaussian process for features retrieval[J]. Signal Processing: Image Communication, 2019, 74: 175 – 190.
- [9] Guo X J, Yu L, Ling H B. LIME: Low-light image enhancement via illumination map estimation[J]. IEEE Transactions on Image Processing, 2017, 26(2):982 – 993.
- [10] 徐少平,刘婷云,林珍玉,等.深度卷积神经网络降噪模型的技术瓶颈与研究展望[J].中国图象图形学报, 2019, 24(8):1207 – 1214.  
Xu S P, Liu T Y, Lin Z Y, et al. Main bottlenecks and research prospects of the deep convolutional neural network-based denoising model[J]. Journal of Image and Graphics, 2019, 24(8):1207 – 1214.(in Chinese)
- [11] Zhang K, Zuo W M, Chen Y J, et al. Beyond a Gaussian denoiser: Residual learning of deep CNN for image denoising[J]. IEEE Transactions on Image Processing, 2017, 26(7):3142 – 3155.
- [12] Cai J R, Gu S H, Zhang L. Learning a deep single image contrast enhancer from multi-exposure images[J]. IEEE Transactions on Image Processing, 2018, 27(4): 2049 – 2062.
- [13] Fu X Y, Liao Y H, Zeng D L, et al. A probabilistic method for image enhancement with simultaneous illumination and reflectance estimation[J]. IEEE Transactions on Image Processing, 2015, 24(12):4965 – 4977.
- [14] Li M D, Liu J Y, Yang W H, et al. Structure-revealing low-light image enhancement via robust Retinex model[J]. IEEE Transactions on Image Processing, 2018, 27(6):2828 – 2841.
- [15] Fu X Y, Zeng D L, Yue H, et al. A fusion-based enhancing method for weakly illuminated images[J]. Signal Processing, 2016, 129: 82 – 96.
- [16] Wang Z, Li Q. Information content weighting for perceptual image quality assessment[J]. IEEE Transactions on Image Processing, 2011, 20(5):1185 – 1198.
- [17] Ying Z Q, Ge L, Wen G. A bio-inspired multi-exposure fusion framework for low-light image enhancement[J]. Journal of Latex Class Files, 2015, 14(8):1 – 10.
- [18] Kai Z, Ma K D, Hassen R, et al. Perceptual evaluation of multi-exposure image fusion algorithms[A]. International Workshop on Quality of Multimedia Experience[C]. Singapore: IEEE, 2014. 7 – 12.

#### 作者简介



徐少平(通讯作者) 男,1976年5月出生于江西省九江市. 博士,南昌大学信息工程学院计算机科学与技术系教授,博士生导师. 主要研究方向为图形图像处理、机器视觉、虚拟手术仿真等.  
E-mail:xushaoping@ncu.edu.cn



陈孝国 男,1994年生,河南濮阳人. 现为南昌大学硕士研究生,主要研究方向为图像处理与计算机视觉.