

# 通过色彩校正矩阵学习实现低光图像恢复



Muhammad Tahir Rasheed, 石大明\*

深圳大学计算机科学与软件工程学院, 广东深圳 518060

**摘要:** 在弱光下捕获的图像不仅可见度低, 而且质量差, 可能会显著降低多媒体和计算机视觉任务的性能。目前大量技术已经被提出以增强低光图像。大多数低光技术使用 sRGB 数据集, 但是在极低光图像增强方面表现不佳。一些技术使用原始数据进行极低光增强, 但输出图像会遇到色彩校正和细节损失的问题。为了解决色彩校正的问题, 本文中提出了一种新的基于双 MultiResUnet 的网络。在所提出的方法中, 原始数据和 sRGB 数据用作输入, 而 sRGB 图像是使用传统方法从原始数据生成的。双卷积神经网络的第一个分支从原始数据中学习结构细节, 另一个分支从 sRGB 数据中学习空间变化的颜色变换矩阵以进行颜色校正。通过将学到的颜色变换矩阵应用于第一个分支产生的结构信息来产生最终结果。实验结果表明, 所提出的方法表现更好, 并且很好地调整了极低光图像的颜色信息。

**关键词:** 图像处理; 图像增强; 图像去噪; 图像恢复; 图像色彩分析

**DOI:** [10.57237/j.cst.2023.03.003](https://doi.org/10.57237/j.cst.2023.03.003)

## Towards Low-light Image Restoration via Color Correction Matrix Learning

Muhammad Tahir Rasheed, Daming Shi\*

College of Computer Science and Software Engineering, Shenzhen University, Shenzhen 518060, China

**Abstract:** Images captured in low-light not only suffer from low visibility but also result in poor quality, which may significantly degrade the performance of multimedia and computer vision tasks. A large number of techniques have been proposed to enhance the low-light images. The majority of the low-light techniques use sRGB datasets and do not perform well in extreme low-light image enhancement. A few techniques use the raw data for extreme low-light enhancement but the output images suffer color correction and details loss. In this paper, to address this color correction problem a new dual MultiResUnet based network is proposed. In the proposed approach, raw and sRGB data is used as input, whereas sRGB images are generated from raw data by using the traditional pipeline. One branch of the dual CNN learns the structural details from raw data and the other branch learns a spatially variant color transformation matrix from sRGB data for color correction. The final result is produced by applying the learned color transformation matrix to the

基金项目: 中国科技部 (MOST) 新一代人工智能 2030 重大计划 (项目编号: 2018AAA0102200);  
国家自然科学基金重大项目 (项目编号: 61827814, U22A2097);  
深圳市科创委 (SZSTI) 项目 (项目编号: JCYJ20190808153619413).

\*通信作者: 石大明, dshi@szu.edu.cn

收稿日期: 2023-07-17; 接受日期: 2023-09-05; 在线出版日期: 2023-09-08

<http://www.computscitech.com>

structural information produced by the first branch. The experimental results demonstrate that the proposed approach performs better and achieved well-adjusted color information for extremely low-light images.

**Keywords:** Image Processing; Image Enhancement; Image Denoising; Image Restoration; Image Color Analysis

## 1 引言

弱光是我们生活中不可或缺的一部分。我们不能否认这样一个事实: 夜间光线量减少并显着影响人类的视觉能力。在弱光下执行任务不仅对人类来说是困难的, 而且对计算机视觉应用来说也是一个挑战。大多数情况下, 诸如目标检测[1]、目标跟踪和监控[2]等计算机视觉任务处理高质量图像, 但它们的性能在极低光照条件下显著不足。由于光子计数和噪声较低, 极低光成像是一项不适当且具有挑战性的任务。值得注意的是, 每张图像中都存在噪点, 但在极弱光图像的情况下, 噪点变得更具挑战性。然而, 低光增强是很困难的, 因为它的影响深入到图像的特征[3]。

在文献中, 一些经典的[4-9]和基于深度学习的技术[10-16]已被提出来增强低光图像。经典技术可分为直方图均衡 (HE) [7, 5, 4]、Gamma 校正[6, 8, 17]和 Retinex 理论[18-20]为基础的方法。然而, 基于低光深度学习的方法可以分为配对[21]、不配对[22, 23]、自监督[24]和基于零样本学习[25, 15, 26]的技术。然而, 几种基于经典的方法的主要普遍缺点包括缺乏去噪能力、曝光不足、过度增强以及出现奇怪的图案。例如, 基于 HE 的方法只是简单地重新排列像素以均衡直方图, 而伽玛校正对每个像素执行非线性函数。总之, HE 和 Gamma 校正都会单独处理每个像素。因此, 单独处理每个像素而不利用它们与邻域的关系有时会过度增强噪声系数。基于 Retinex 理论的方法将图像分解为照明和反射部分并对其进行增强。而将图像分解为照明度和反射率是一个非常不适当的问题。

洛尔等人[28]是第一个使用基于堆叠稀疏的自动编码器方法 (称为 LLNet) 进行联合增强和降噪的人。随后, 提出了全球照明感知和细节保留网络 (GLADnet) [14]、多分支低光增强网络 MBLLEN [14]、低光卷积神经网络 (LLCNN) [29]以及其他几种基于学习的网络用于弱光增强。但他们中的大多数使用 sRGB 空间的合成数据, 而不是极端低光, 他们的重点是相当低光的图像。在极低光成像中使用 sRGB 空间的问题是细节丢失。因为与原始图像相比, sRGB 图像的信息

相对较少, 因此它们会遇到此问题 (细节丢失)。陈等人[27]是第一个引入真实原始图像 (在黑暗中看到) 数据集的人, 并提出了一种使用 U-net [30]的新通道来增强极低光照下的原始图像。引入原始图像数据集进行极低光增强的目的是: 原始图像是 16 位的并且具有更多信息。与直接增强 RGB 空间中的图像相比, 以原始形式增强极低光图像可以产生更好的结果。虽然黑暗中看到的数据集的结果很有希望, 但颜色调整不理想, 如图 1 所示。RAW 图像具有更多的亮度和结构细节, 但缺乏颜色信息[31]。

本文提出了极端情况下的色彩校正解决方案。提出了低光增强并确定了 Unet 的问题。用于色彩校正的新双 MultiResUnet 通道如图 3 所示。提出的通道由两个并行 MultiResUnet 组成。第一个分支将原始数据作为输入, 其中包含更多结构细节, 但缺少颜色细节。为了获得颜色细节, sRGB 图像被用作该模型第二个分支的输入来学习颜色变换矩阵。由于相机对原始图像执行非线性变换以生成 sRGB 图像。第二个分支将学习非线性变换矩阵。该矩阵将用于恢复颜色信息。用作所提出的网络的第二个分支的输入的 sRGB 图像是使用传统通道生成的。

本文的主要发现是:

1. 建议使用 MultiResUnet 通道在极低光增强的情况下进行色彩校正。
2. 所提出的通道能够通过将原始数据和 sRGB 图像作为输入来分别获取结构细节并学习颜色变换矩阵, 从而改进极低光图像的颜色校正, 然后使用非线性变换矩阵来改进极低光图像的颜色校正。恢复颜色信息。
3. 经过实验和定量验证, 与其他最先进的方法相比, 所提出的 MultiResUnet 通道在选定的测试数据集上显示出改进的性能。

本文的其余部分组织如下: 在第二节中, 我们简要回顾了低光增强、去噪和去马赛克的文献工作。第 3 节详细描述了所提出的双 CNN 模型。在第 4 节中, 我

们对所提出的方法的结果与最先进的技术进行了定性和定量的比较。最后，第五节总结了结论。

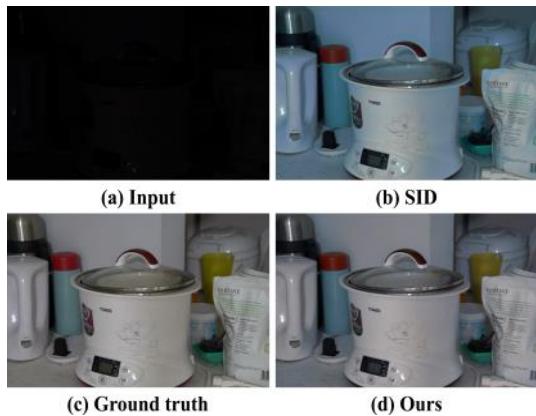


图 1 显示了极弱光方法 SID [27] 和所提出方法的输出。图 1(a) 是相机生成的输入图像, 图 1(c) 表示地面实况图像。图 1(b) 表示 SID 方法产生的结果, 该方法带有颜色细节的损失。图 1(d) 表示由所提出的方法生成的图像, 该方法纠正了颜色损失细节的损失。通过数字缩放可以更好地查看结果

## 2 文献综述

本节介绍包括经典和最先进的微光图像增强方法的文献工作。所有提出的方法在研究界都很有趣并且很有帮助, 但它们有一些局限性, 如下所述。

**经典的低光图像增强:** 直方图均衡[5]被认为是最早、最简单的低光增强方法之一。它根据概率分布平衡整个图像的直方图。平衡整个直方图会引入错误轮廓、伪影以及过度增强某些区域。后来, 引入了基于 HE 的方法的不同改进版本, 例如动态直方图均衡 (DHE)[4]、对比度受限自适应直方图均衡 (CLAHE) [30] 和亮度保持动态直方图均衡 (BDHHE) [32]。这些方法的主要缺点是缺乏去噪能力。然而, 现在已经提出了不同的图像增强方法。伽玛校正[6]等非线性方法也被用来抑制亮区并增强暗区。基于伽玛校正的方法的缺点是它们单独对每个像素执行操作而不考虑邻近像素, 因此输出图像与真实图像不一致。在[9]中, Tanka 等人引入了基于梯度的增强方法。但在该方法中, 必须手动调整增强参数。基于 Retinex 理论[18]的模型也被广泛用于低光增强。根据 Retinex 理论, 每幅图像可以分解为光照度和反射率[30], 可以用方程 1 表示如下:

$$S(x, y) = R(x, y) \circ I(x, y) \quad (1)$$

其中,  $S$  表示源图像,  $R$  和  $I$  分别表示反射率和光照度, 运算 $\circ$ 符表示逐元素相乘。

反射率部分被认为是固有属性并且保持不变。后来, Retinex 理论被用于单尺度 Retinex (SSR) [18] 和多尺度 Retinex (MSR) [25], 将低光图像分解为光照度和反射率, 而反射率部分用作最终的增强图像。然而, 通过去除照明, 图像的细节得到增强, 但破坏了图像的自然度。此外, 王等人[14]提出了非均匀照明图像的算法, 以保持自然度, 同时增强细节和感知质量。郭等人设计了一种名为低光光照图估计 (LIME) 的方法[33], 首先估计每个像素的光照, 然后对其施加先验结构并将其用作最终的光照图。其他基于 Retinex 理论的方法包括使用同时光照度和反射率估计进行图像增强的概率方法 (PM-SIRE) [2]、内-外先验 (JieP) [34] 以及同时光照度和反射率估计的加权变分模型 (WV-SRIE) [35]。总之, 将图像正确分解为光照度和反射率本身就是一个具有挑战性的部分。且大多数技术需要手动微调参数。

**最先进的低光图像增强:** 最近, 深度学习已广泛用于图像增强。基于深度学习的方法, 如双边学习[36]、Retinex-Net [37]、MBLLEN [13]、LightenNet [21] 和 EnlightenGAN [22], 优于传统方法。另一种方法[38-40]提出图像增强, 假设图像是由一些专业摄影师拍摄的, 这通常不适用于日常生活。王等人[31]在网络中提出了一种中间照明方法来增强曝光不足的图像。郭等人[25]提出了一种零参考深度曲线估计 (DCE-Net) 网络来估计一组光增强曲线, 并迭代地将这些曲线应用于 RGB 通道以获得增强图像。

在[41]中, 作者使用深度半监督递归带网络 (DRBN) 来增强低光图像的感知质量。赵等人[15]受到深度图像先验 (DIP) 思想的启发, 提出了名为 RetinexDIP 的零参考框架。在 RetinexDIP 中, 他们以生成方式执行 Retinex 分解。RetinexDIP 同时根据随机噪声作为输入生成反射率和光照图, 并增强所获得的光照图。所提出的模型在各种场景上都能很好地推广, 但需要数百次迭代才能生成光照图, 需要花费大量时间才能产生优化结果。王等人[16]使用几个闪电反投影 (LBP) 块提出了用于低光增强的深度闪电 (DLN) 网络。此外, 为了融合来自多个反投影块的局部和全局特征图, 提出了特征聚合 (FA) 块。

此外, 徐等人[42]利用低频噪声比高频噪声更容易去除的事实, 提出了一种基于频率的分解和增强模型。将图像分解为低频和高频部分, 在低频部分恢复目标, 然后在恢复的目标的基础上增强高频细节。总之, 大

多数网络使用 sRGB 数据集进行低光图像增强。在极端低光条件下, 由于光子计数低, 像素值非常小, 并且噪声变得很大。有趣的是, RGB 图像的信息量比 RAW 文件少。然而, 极端低光增强本身是一个不适用问题, 增强 RGB 图像可能无法恢复隐藏的细节。RAW 文件具有更多的结构细节, 这就是为什么我们的网络使用 RAW 文件来恢复结构细节以进行低光增强。

**图像去噪和去马赛克:** 任何相机传感器的输出都会受到不同类型的噪声的污染[43]。去噪和去马赛克是所有相机流程的基础。许多去马赛克技术在没有噪声的情况下提供了令人印象深刻的结果, 并且没有解决传感器噪声的问题。单独应用去噪和去马赛克并不是最优的[43]。如果首先对马赛克数据进行去噪, 那么利用跨颜色相关性就会变得更加困难[44], 类似地, 如果将去马赛克应用于嘈杂的 RAW 数据, 噪声就会相互关联, 并且在以后变得更难以去除[30]。最近, 联合去马赛克和去噪 (JDD) 方法已被用于传统方法[45, 46, 3]和深度学习方法[47, 48]以避免误差积累。基于深度学习的方法已经超越了传统的最先进的传统技术。加尔比等人[36]利用 JDD 深度学习的优势来训练数百万张图像并实现最先进的性能。

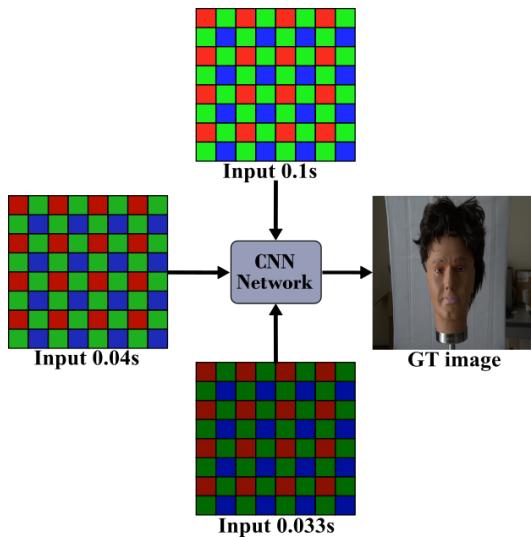


图 2 在不同曝光时间 (即 0.1 秒、0.04 秒和 0.033 秒) 拍摄的多个输入图像的映射被映射到单个地面实况图像 x100

此外, 埃雷特等人[43]使用特定 RAW 图像的突发, 无需地面实况图像即可微调 JDD 的自监督网络。刘等人[1]提出了密度图引导来帮助自引导网络 (SGNet) 处理各种频率以进行去马赛克和去噪。上述技术要么适用于合成拜耳图像, 要么适用于在良好照明条件下收集的真实数据, 而不是适用于在极低照明条件下收集

的图像。陈等人[27]引入了基于真实极低光 RAW 图像的暗视 (SID) 数据集, 并使用 U-net 进行快速图像增强。输出图像会出现细节丢失、HDR 色调映射和色彩校正问题。

### 3 提出的模型

在本节中, 我们提出了一种新的基于双 MultiResUnet 的通道来恢复极低光图像的隐藏细节和色彩校正。

通常, 图像处理通道对原始传感器数据应用一系列算法, 例如去马赛克、去噪、锐化、色彩校正、色调映射等, 以在 sRGB 空间中生成图像。利用原始传感器数据来学习使用深度神经网络的图像处理任务仅对恢复图像细节是有利的。原始传感器数据缺乏色彩校正和色调映射细节[49]。在[27]中, 陈等人。结果表明, 由于转换过程中细节丢失, 极低光图像增强的原始数据比 sRGB 空间中的数据表现更好。SID 的输出结果很有希望, 但存在色彩校正和色调映射的问题。为了解决极低光图像增强中的色彩校正问题, 基于[49], 我们提出了一种双分支 CNN 方法, 将原始数据和 sRGB 数据都视为输入, 如图 3 所示。

图 3 有两个部分/分支, 网络的第一个分支用于从原始传感器数据恢复所有 3 个颜色通道的图像线性结构, 第二个分支用于从 sRGB 数据。然后, 将变换矩阵应用于第一个分支的输出以恢复像素的颜色细节。经过探索, 我们重点关注两个 CNN 网络, 即 U-net [50] 和 MultiResUnet [51]。值得注意的是, Unet 因其内存需求低、收敛速度快、性能好而闻名。跳跃连接使得训练更容易, 但是通过跳跃连接将编码器的低级特征与解码器的高级特征合并可能会导致差异。为了避免这种差异, MultiResUnet 是首选, 并且被认为相对更有效。在 MultiResUnet 中, 低级编码器特征通过多个 resnet 模块与高层特征合并。

在本研究中, 考虑使用索尼 SID 数据集[27]进行网络训练。SID 数据集由 x100、x250 和 x300 输入原始图像组成, 对应于单个地面实况图像, 如图 2 所示。减去原始数据中的黑电平, 然后将其打包到 r 通道中, 如稍后的 SID [27]中所示。, 通过乘以放大因子  $\gamma$  进行放大, 并馈送到模型的图像结构恢复分支。对于色彩校正分支, 使用图像处理库 libraw 将原始数据处理到 sRGB 空间。该模型的图像恢复和色彩校正分支解释如下。

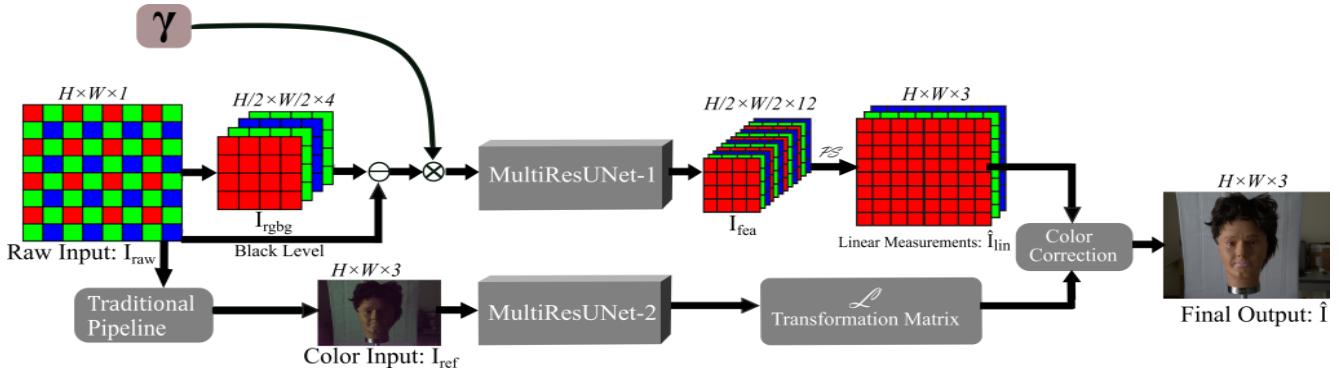


图 3 所述通道概述。在第一个分支中，原始输入  $I_{raw}$  被传递到网络以估计 3 通道  $I_{lin}$  的线性测量。第二个分支根据  $\mathbf{L}$  估计像素级颜色校正变换矩阵  $I_{lin}$ ，以产生最终的增强图像  $\hat{I}$

### 3.1 图像结构估计网络

图 3 展示了整个方案的流程。在图 3 中，第一个分支代表图像结构恢复网络。拜耳阵列  $I_{raw}$  以与 [4] 中提到的相同方式打包成四个通道，即 R; G; B; G。然后，从相机封装的四通道 ( $I_{rgbg}$ ) 中减去黑电平，将其乘以输入与地面实况图像之间的曝光差之比（用  $\gamma$  表示），然后将其馈送到 MultiResUnet-1 [51]。MultiResUnet 的输出是 12 个特征通道，这些通道由子像素 [52] 层重新排列，以恢复 3 通道  $\hat{I}_{lin} \in \mathbb{R}^{H \times W \times 3}$  的线性测量。结构学习可以用等式 2 解释如下：

$$I_{fea} = V_{net1}(\gamma * (I_{rgbg} - BL)) \quad (2)$$

其中  $I_{rgbg}$  是传统通道从原始图像 ( $I_{raw}$ ) 生成的 sRGB 图像， $\mathbf{L}$  是颜色校正矩阵。但是如何得到这个颜色校正矩阵  $\mathbf{L}$  呢？获取此矩阵信息很棘手，因为它是相机内部设置的一部分。其中  $BL$  是黑电平， $I_{rgbg}$  被打包成  $I_{raw}$  到 R、G、B、G 通道， $V_{net1}$  表示 MultiResUnet-1 网络。 $V_{net1}$  学习线性结构并输出特征通道（即  $I_{fea}$ ）。 $I_{fea}$  具有学习到的结构细节，这些特征图将通过子像素层重新排列以获得 RGB 通道的结构信息。重排过程可以表示如下：

$$I_{lin} = PS(I_{fea}) \quad (3)$$

其中  $PS$  是周期性改组算子 [39]。 $PS$  将  $I_{fea}$ （即  $H/2 \times W/2 \times 12$ ）的元素重新排列成  $H \times W \times 3$  的形状。 $\hat{I}_{lin} \in \mathbb{R}^{H \times W \times 3}$  是具有详细结构信息的输出图像，而颜

色信息缺失。颜色信息学习和恢复将在接下来的小节中解释。

### 3.2 色彩校正恢复工具

使用原始数据进行极低光增强可以很好地恢复结构和精细细节，但输出图像会丢失颜色信息。在传统的通道中，原始图像通过矩阵乘法运算转换为 sRGB，可以用下面的公式 4 表示，

$$I_{rgb} = \mathbf{L} \cdot I_{raw} \quad (4)$$

受 [51] 的启发，我们在通道中引入了色彩校正的概念，以提高相机传感器输出（即  $I_{raw}$ ）产生的增强图像的色彩质量。在建议的通道中如图所示。第二个分支用于颜色校正矩阵估计。为了学习这个矩阵 ( $\mathbf{L}$ )，我们首先将原始输入  $I_{raw}$  图像转换为 RGB 图像，并将其输入到所提出的网络的第二个分支来学习这个矩阵。学习过程可以用方程 5 表示如下：

$$\mathbf{L} = V_{net2}(I_{ref}) \quad (5)$$

其中  $\mathbf{L} \in \mathbb{R}^{H \times W \times 9}$  是由网络  $V_{net2}$  的第二个分支估计的学习颜色校正矩阵， $I_{ref} \in \mathbb{R}^{H \times W \times 3}$  是馈送到网络的第二个分支的低光 RGB 图像。

然后将颜色校正矩阵应用于第一分支的预测线性输出  $\hat{I}_{lin}$  以产生最终的增强图像  $\hat{I}$ 。整个网络的输出是通过在  $I_{ref} \in \mathbb{R}^{H \times W \times 3}$  上应用  $\mathbf{L}$  产生的，可以用公式 6 表示如下：

$$\hat{I}[i, j] = \mathbf{L}(I_{ref})[i, j]\hat{I}_{lin}[i, j] \quad (6)$$

其中  $\mathbf{L}(I_{ref})[i,j] \in \mathbb{R}^{3 \times 3}$  是像素  $[i,j]$  处 RGB 向量的空间变化变换矩阵。我们使用具有平均池化层的 MultiResUnet-2 [21] 来直接估计每个像素的  $3 \times 3$  权重。

## 4 实验结果与讨论

在本节中，详细描述了我们提出的通道的实验性能，并衡量了所提出的通道与其他方法相比如何显示出显着的性能。特别地，SID-Sony 测试数据集用于实验结果评估。峰值信噪比(PSNR)和结构相似性(SSIM) [53]指标用于定量比较。此外，本节还提供了实验设置详细信息和结果讨论。

### 4.1 实施和训练细节

我们在 Tensorflow 框架中实现了该模型，并在四个 NVIDIA TITAN Xp GPU 上进行了训练。该网络使用损失函数和具有学习率的 Adam 优化器从头开始训练。在训练期间，原始数据（四个通道的包）作为输入传递到网络和 sRGB 短曝光图像以及 sRGB 空间中相应的地面实况（长曝光）图像。使用 libraw（图像处理库）将短曝光图像和长曝光图像覆盖在 sRGB 空间中。放大率的使用与 SID [27] 中提到的完全相同。此外，我们在每次迭代期间随机裁剪  $512 \times 512$  的补丁。这些补丁被随机翻转和旋转以进行数据增强。将网络训练 6000 个 epoch 需要 8 天。

MultiResUNet 中删除了批量归一化层，斜率为 0.2 的 LeakyReLU 用作除最后一层之外所有层的激活函数，MultiResUNet 使用 =1.67 以保持参数与 U-net 中提到的相同。

表 1 SID [27] 数据集子集的 PSNR 和 SSIM 比较

Method	Subset	PSNR↑	SSIM↑
SID	x100	29.68	0.085
	x250	27.95	0.799
	x300	28.97	0.758
Ours	x100	30.08	0.816
	x250	28.47	0.799
	x300	28.17	0.744

### 4.2 视觉比较

我们首先在 SID-Sony 测试数据集上将我们提出的模型与最先进的方法进行直观比较。测试数据集具有三个难度级别 x100、x250 和 x300。图 2 显示了这三种不同曝光输入图像及其曝光时间与地面实况的映射。

而 x250 和 x300 被认为相对更具挑战性。x100、x250 和 x300 的结果分别如图 4、5 和 6 所示。从这些图中可以看出，所提出的双 MultiResUnet 不仅成功地恢复结构细节，而且还产生了良好调整的颜色信息。另一方面，直方图均衡同时过度增强了图像和噪声。它不仅无法正确恢复颜色信息，也无法恢复结构信息。而且，HE 的结果看起来不自然。MSRCR [20] 是一个多尺度 Retinex。

基于 MSRCR 的颜色恢复方法，完全无法恢复图像的颜色和对比度，输出看起来像灰度图像。CLAHE 和 BIMEF 的结果对于 x100 和 x300 来说较暗，而它们在一定程度上增强了 x250 图像。但在 x250 图像上的结果中可以观察到绿色。噪声、颜色信息丢失是最常见的因素。缺乏抑制噪声的能力是在大多数经典方法中可以观察到的最常见因素。

LIME 是另一种基于 Retinex 理论的方法，它估计用于增强的照明图以产生最终结果。然而，LIME 的结果并不理想，但与 NPE、CLAHE、BIMEF 和 MSRCR 相比还是好得多。此外，LIME 方法产生的结果更清晰且噪声更少。LIME 无法正确渲染颜色信息，无法完全恢复隐藏的细节。PM-SIRE [2] 使用概率方法同时估计照度和反射率，而 NPE [19] 使用亮通滤波器将图像分解为反射率和照度，以在细节和自然度之间取得平衡，从而实现图像增强。虽然这两种方法都会增强图像和噪声，但无法正确恢复颜色。KinD [54] 将图像分解为光照和反射率两部分，CNN 用于增强照明部分以进行光调整，反射率部分用于退化去除。由于严重的噪点和极低的光照，KinD 在 x250 上的结果比在 x100 和 x300 上的结果要好得多。它无法正确分解图像。基于 CNN 的方法，即 DPED [38] 被训练以将低质量图像改善为高质量的图像，但无法消除噪声。

其中 See-in-the-Dark (SID) [27] 是在 SID 原始数据集上训练的基于 Unet 的网络。它成功地抑制了噪声并产生了有希望的结果。结构细节比基于 RGB 的方法好得多。该方法的输出图像存在不正确的颜色和 HDR 色调映射，如图 4(k)、5(k) 和 6(k) 中的红色框中所示。相比之下，我们的方法不仅增强了图像细节，而且还消除了噪声并正确估计了颜色，因此所提出的方法产生的结果与其他方法相比是显著的。

### 4.3 定量比较

在本节中，提供了定量分析，以将我们的模型与

最先进的增强方法进行比较。为了比较，使用了峰值信噪比（PSNR）和结构相似性（SSIM）[53]两种指标。我们计算了 RGB 空间中所有三个通道的 PSRN 和

SSIM。这两个指标的值越高，表明性能越好。从表二中可以看出，我们的方法优于传统方法和最先进的方法，并表现出出色的性能。

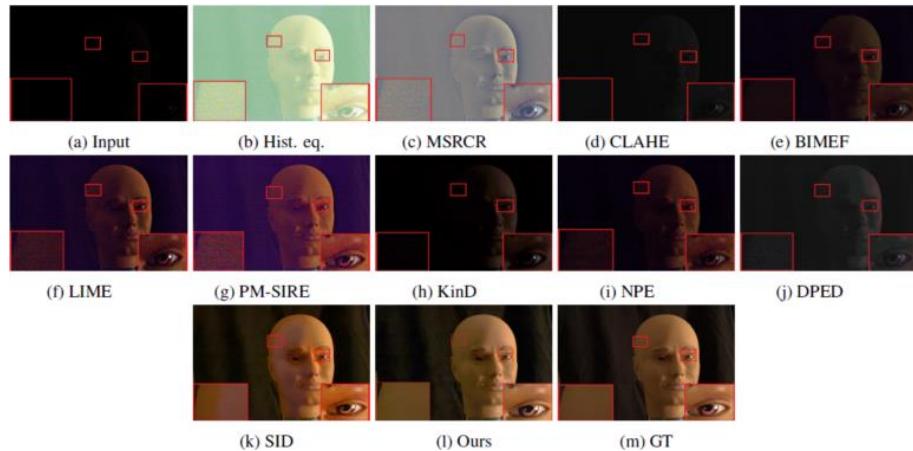


图 4 SID 数据集 (Sonyx100 子集) 图像上最先进方法的视觉结果。红框显示了该区域的近距离观察，其中大多数方法都失败了。放大进行详细比较。而“GT”代表地面实况图像

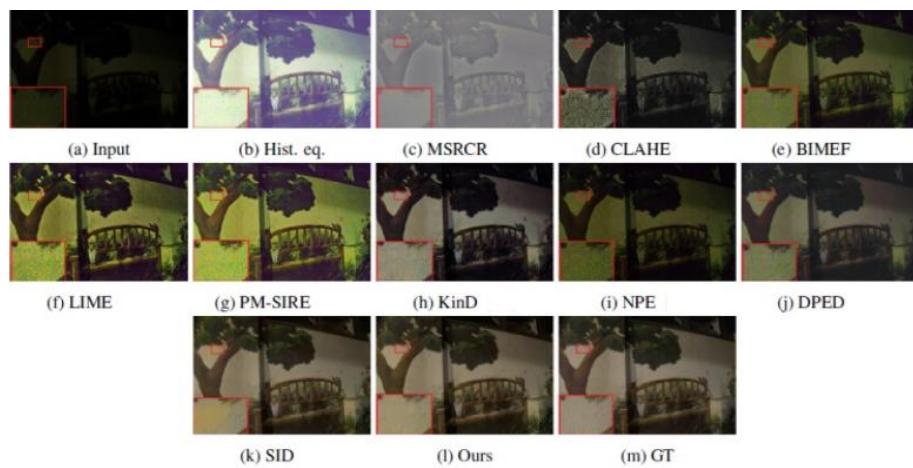


图 5 SID 数据集 (Sonyx250 子集) 图像上最先进方法的视觉结果。红色框代表了该区域的近距离观察，大多数方法都失败了

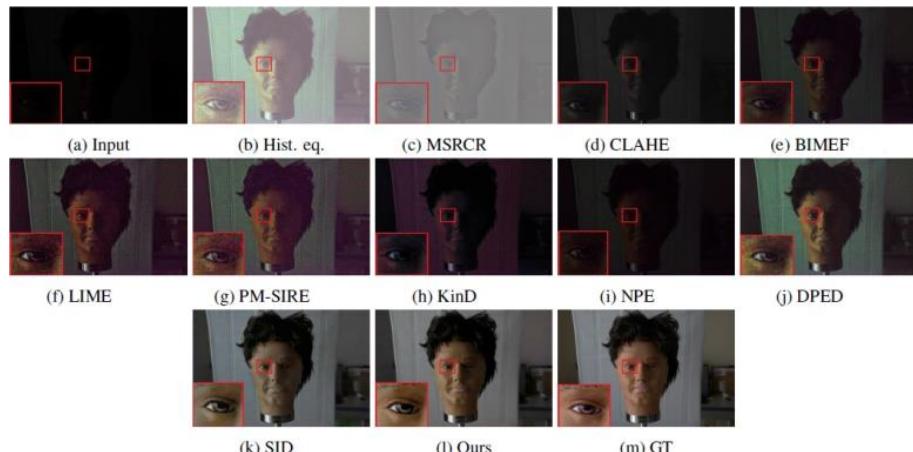


图 6 SID 数据集 (Sonyx300 子集) 图像上最先进方法的视觉结果。红色框代表了该区域的近距离观察，大多数方法都失败了

此外,我们的方法与 SID [27]进行了比较,实验结果表明我们的方法表现得相当好。还分别计算测试数据集的 x100、x250 和 x300 子集的 PSNR 和 SSIM,如表 2 所示。此外,从表 2 中可以看出,与 SID 相比,x100 和 x250 子集上的 PSRN 和 SSIM 的值更高。据观察,在 x300 子集中,图像非常暗并且丢失细节。然而,x300 子集的结果并没有改善,因为颜色矩阵无法从中学习。图 7 和图 8 表示子集 x100、x250 和 x300 上不同方法的 PSNR 和 SSIM。可以看出,由于严重的噪声、细节和颜色信息的丢失,大多数方法在 x300 子集中无

法表现得更好。这表明在丢失细节和极端低光照条件的情况下,这些方法不是合适的选择。该网络的另一个具有挑战性的部分是将具有不同曝光度的 3 个图像映射到单个地面实况图像。尽管图像乘以曝光时间比率,但曝光时间仍然与图像的亮度不成线性正比。当网络尝试将 x100 图像映射到真实情况时,x250 和 x300 的结果映射就变得具有挑战性。所有这三个图像之间都具有非线性关系,如图 2 所示。子集(即 x100、x250 和 x300)的 PSNR 和 SSIM 可以在图 7 和 8 中看到。

表 2 在 SID 数据集上与最先进的增强方法进行定量比较。最佳性能以粗体标记。表中的值是 SID 测试数据集上的平均 PSNR/SSIM

Input	Method	PSNR↑	SSIM↑
sRGB	Hist. Eq.	6.07	0.099
	MSRCR [20]	9.671	0.133
	CLAHE [7]	13.85	0.358
	BIMEF [55]	13.89	0.121
	LIME [33]	13.29	0.073
	PM-SIRE [2]	13.06	0.0583
	KinD [54]	13.94	0.199
	NPE [19]	13.96	0.188
	DPED [38]	15.69	0.474
	SID [27]	17.40	0.554
RAW	SID [27]	28.88	0.787
	Ours	28.92	0.789

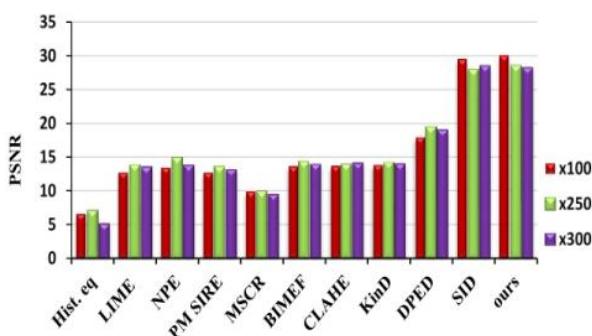


图 7 SonySID 测试数据集的 x100、x250 和 x300 子集的平均 PSNR

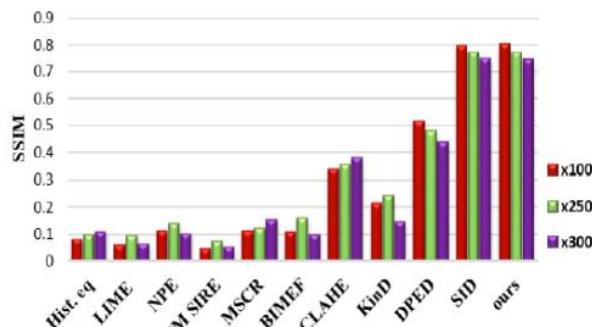


图 8 SonySID 测试数据集的 x100、x250 和 x300 子集上的平均 SSIM

## 5 结论

在本文中,我们提出了一种使用原始数据和 sRGB 数据进行极低光图像增强的双卷积神经网络通道。在所提出的流程中,引入了一个新概念来提高极低光增强下图像的色彩质量。所提出的方法基于端到端训练。据观察,极低光图像的传统方法存在严重的噪声和色偏问题。另一方面,与在 sRGB 数据集上训练的模型相比,在原始数据上训练的模型表现更好。值得注意的是,原始数据存在一些局限性,例如色彩校正问题。为了解决这个问题,我们要考虑到这一点。实验结果表明,我们的网络增强的结果噪声低、对比度好、颜色调整良好。此外,与传统和先进方法相比,所提出的方法在 PSNR 和 SSIM 两个评价指标方面显示出优越性。尽管双卷积神经网络通道能产生较好的结果,但大量参数增加了处理时间。未来我们将进一步优化网络并探索其在去模糊和去噪方面的应用。另一个未来的方向是探索在不同曝光时间拍摄的图像之间的关系,并利用该关系将多个不同曝光图像映射到单个地面实况图像。

## 参考文献

- [1] MT. Rasheed, G. Guo, D. Shi, H. Khan, and Q. C, "An Empirical Study on Retinex Methods for Low-Light Image Enhancement," *Remote Sensing*, vol. 14, no. 18, 2022, doi: 10.3390/rs14184608.
- [2] X. Fu, Y. Liao, D. Zeng, Y. Huang, X. P. Zhang, and X. Ding, "A Probabilistic Method for Image Enhancement with Simultaneous Illumination and Reflectance Estimation," *IEEE Trans. Image Process.*, vol. 24, no. 12, pp. 4965–4977, 2015, doi: 10.1109/TIP.2015.2474701.
- [3] MT. Rasheed, D. Shi, and H. Khan, "A comprehensive experiment-based review of low-light image enhancement methods and benchmarking low-light image quality assessment," *Signal Processing*, vol. 204, 2023, doi: 10.1016/j.sigpro.2022.108821.
- [4] H. Ibrahim and N. S. P. Kong, "Brightness preserving dynamic histogram equalization for image contrast enhancement," *IEEE Trans. Consum. Electron.*, vol. 53, no. 4, pp. 1752–1758, 2007, doi: 10.1109/TCE.2007.4429280.
- [5] H. D. Cheng and X. J. Shi, "A simple and effective histogram equalization approach to image enhancement," *Digit. Signal Process. A Rev. J.*, vol. 14, no. 2, pp. 158–170, 2004, doi: 10.1016/j.dsp.2003.07.002.
- [6] G. Xu, J. Su, H. Pan, Z. Zhang, and H. Gong, "An image enhancement method based on gamma correction," *Isc. 2009 - 2009 Int. Symp. Comput. Intell. Des.*, vol. 1, pp. 60–63, 2009, doi: 10.1109/ISCID.2009.22.
- [7] J. S. Yoo, J. H. Choi, K. S. Choi, D. Y. Lee, H. Y. Kim, and J. O. Kim, "Fast search of a similar patch for self-similarity based image super resolution," *IEICE Trans. Inf. Syst.*, vol. E99D, no. 8, pp. 2194–2198, 2016, doi: 10.1587/transinf.2016EDL8049.
- [8] S. Rahman, M. M. Rahman, M. Abdullah-Al-Wadud, G. D. Al-Quaderi, and M. Shoyaib, "An adaptive gamma correction for image enhancement," *Eurasip J. Image Video Process.*, vol. 2016, no. 1, pp. 1–13, 2016, doi: 10.1186/s13640-016-0138-1.
- [9] M. Tanaka, "Gradient-Based Low-Light Image Enhancement," pp. 11–12.
- [10] M. Afifi, K. G. Derpanis, B. Ommer, and M. S. Brown, "Learning Multi-Scale Photo Exposure Correction," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 9153–9163, 2021, doi: 10.1109/CVPR46437.2021.00904.
- [11] K. Lu, "TBEFN : A Two-Branch Exposure-Fusion Network for Low-Light Image Enhancement," *vol. 23*, pp. 4093–4105, 2021.
- [12] Y. Wang, R. Wan, W. Yang, H. Li, L.-P. Chau, and A. C. Kot, "Low-Light Image Enhancement with Normalizing Flow," 2021, [Online]. Available: <http://arxiv.org/abs/2109.05923>.
- [13] F. Lv, F. Lu, J. Wu, and C. Lim, "MBLLEN: Low-light image/video enhancement using CNNs," *Br. Mach. Vis. Conf. 2018, BMVC 2018*, no. May, 2019.
- [14] W. Wang, C. Wei, W. Yang, and J. Liu, "GLADNet: Low-light enhancement network with global awareness," *Proc. - 13th IEEE Int. Conf. Autom. Face Gesture Recognition, FG 2018*, pp. 751–755, 2018, doi: 10.1109/FG.2018.00118.
- [15] Z. Zhao, B. Xiong, L. Wang, Q. Ou, L. Yu, and F. Kuang, "RetinexDIP: A Unified Deep Framework for Low-Light Image Enhancement," *IEEE Trans. Circuits Syst. Video Technol.*, vol. 32, no. 3, pp. 1076–1088, 2022, doi: 10.1109/TCSVT.2021.3073371.
- [16] L. W. Wang, Z. S. Liu, W. C. Siu, and D. P. K. Lun, "Lightening Network for Low-Light Image Enhancement," *IEEE Trans. Image Process.*, vol. 29, pp. 7984–7996, 2020, doi: 10.1109/TIP.2020.3008396.
- [17] S. C. Huang, F. C. Cheng, and Y. S. Chiu, "Efficient contrast enhancement using adaptive gamma correction with weighting distribution," *IEEE Trans. Image Process.*, vol. 22, no. 3, pp. 1032–1041, 2013, doi: 10.1109/TIP.2012.2226047.
- [18] D. J. Jobson, Z. Rahman, and G. A. Woodell, "Properties and Performance of a Center / Surround Retinex," *vol. 6*, no. 3, pp. 451–462, 1997.
- [19] S. Wang, J. Zheng, H. M. Hu, and B. Li, "Naturalness preserved enhancement algorithm for non-uniform illumination images," *IEEE Trans. Image Process.*, vol. 22, no. 9, pp. 3538–3548, 2013, doi: 10.1109/TIP.2013.2261309.
- [20] D. J. Jobson, Z. U. Rahman, and G. A. Woodell, "A multiscale retinex for bridging the gap between color images and the human observation of scenes," *IEEE Trans. Image Process.*, vol. 6, no. 7, pp. 965–976, 1997, doi: 10.1109/83.597272.
- [21] C. Li, J. Guo, F. Porikli, and Y. Pang, "LightenNet: A Convolutional Neural Network for weakly illuminated image enhancement," *Pattern Recognit. Lett.*, vol. 104, pp. 15–22, 2018, doi: 10.1016/j.patrec.2018.01.010.
- [22] Y. Jiang et al., "EnlightenGAN: Deep Light Enhancement without Paired Supervision," *IEEE Trans. Image Process.*, vol. 30, pp. 2340–2349, 2021, doi: 10.1109/TIP.2021.3051462.
- [23] Y. S. Chen, Y. C. Wang, M. H. Kao, and Y. Y. Chuang, "Deep Photo Enhancer: Unpaired Learning for Image Enhancement from Photographs with GANs," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 6306–6314, 2018, doi: 10.1109/CVPR.2018.00660.

- [24] Y. Zhang, X. Di, B. Zhang, Q. Li, S. Yan, and C. Wang, "Self-supervised Low Light Image Enhancement and Denoising," 2021, [Online]. Available: <http://arxiv.org/abs/2103.00832>.
- [25] C. Guo et al., "Zero-reference deep curve estimation for low-light image enhancement," Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., pp. 1777–1786, 2020, doi: 10.1109/CVPR42600.2020.00185.
- [26] A. Zhu, L. Zhang, Y. Shen, Y. Ma, S. Zhao, and Y. Zhou, "ZERO-SHOT RESTORATION OF UNDEREXPOSED IMAGES VIA ROBUST RETINEX DECOMPOSITION School of Software Engineering, Tongji University, Shanghai, China School of Computer Information Engineering, Jiangxi Normal University, China Department of Computer and I," Icme, pp. 3–8, 2020.
- [27] C. Chen, Q. Chen, J. Xu, and V. Koltun, "Learning to See in the Dark," Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., pp. 3291–3300, 2018, doi: 10.1109/CVPR.2018.00347.
- [28] K. G. Lore, A. Akintayo, and S. Sarkar, "LLNet: A deep autoencoder approach to natural low-light image enhancement," Pattern Recognit., vol. 61, pp. 650–662, 2017, doi: 10.1016/j.patcog.2016.06.008.
- [29] L. Tao, C. Zhu, G. Xiang, Y. Li, H. Jia, and X. Xie, "LLCNN: A convolutional neural network for low-light image enhancement," 2017 IEEE Vis. Commun. Image Process. VCIP 2017, vol. 2018-January, no. 2013, pp. 1–4, 2018, doi: 10.1109/VCIP.2017.8305143.
- [30] S. H. Park, H. S. Kim, S. Lansel, M. Parmar, and B. A. Wandell, "A case for denoising before demosaicking color filter array data," Conf. Rec. - Asilomar Conf. Signals, Syst. Comput., no. 4, pp. 860–864, 2009, doi: 10.1109/ACSSC.2009.5469990.
- [31] R. Wang, Q. Zhang, C. W. Fu, X. Shen, W. S. Zheng, and J. Jia, "Underexposed photo enhancement using deep illumination estimation," Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., vol. 2019-June, pp. 6842–6850, 2019, doi: 10.1109/CVPR.2019.00701.
- [32] T. Huynh-The and T. Le-Tien, "Brightness preserving weighted dynamic range histogram equalization for image contrast enhancement," Int. Conf. Adv. Technol. Commun., vol. 53, no. 4, pp. 386–391, 2013, doi: 10.1109/ATC.2013.6698142.
- [33] X. Guo, Y. Li, and H. Ling, "LIME: Low-light Image Enhancement via," IEEE Trans. Comput. Imaging, vol. 26, no. 2, pp. 1–12, 2017.
- [34] B. Cai, X. Xu, K. Guo, K. Jia, B. Hu, and D. Tao, "A Joint Intrinsic-Extrinsic Prior Model for Retinex," Proc. IEEE Int. Conf. Comput. Vis., vol. 2017-October, pp. 4020–4029, 2017, doi: 10.1109/ICCV.2017.431.
- [35] X. Fu, D. Zeng, Y. Huang, X. P. Zhang, and X. Ding, "A Weighted Variational Model for Simultaneous Reflectance and Illumination Estimation," Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., vol. 2016-December, pp. 2782–2790, 2016, doi: 10.1109/CVPR.2016.304.
- [36] M. Gharbi, J. Chen, J. T. Barron, S. W. Hasinoff, and F. Durand, "Deep bilateral learning for real-time image enhancement," ACM Trans. Graph., vol. 36, no. 4, 2017, doi: 10.1145/3072959.3073592.
- [37] C. Wei, W. Wang, W. Yang, and J. Liu, "Deep retinex decomposition for low-light enhancement," Br. Mach. Vis. Conf. 2018, BMVC 2018, no. 61772043, 2019.
- [38] A. Ignatov, N. Kobyshev, R. Timofte, K. Vanhoey, and L. Van Gool, "DSLR-Quality Photos on Mobile Devices with Deep Convolutional Networks," Proc. IEEE Int. Conf. Comput. Vis., vol. 2017-October, pp. 3297–3305, 2017, doi: 10.1109/ICCV.2017.355.
- [39] J. Park, J. Y. Lee, D. Yoo, and I. S. Kweon, "Distort-and-Recover: Color Enhancement Using Deep Reinforcement Learning," Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., pp. 5928–5936, 2018, doi: 10.1109/CVPR.2018.00621.
- [40] X. Yang, K. Xu, Y. Song, Q. Zhang, X. Wei, and R. W. H. Lau, "Image Correction via Deep Reciprocating HDR Transformation," Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., pp. 1798–1807, 2018, doi: 10.1109/CVPR.2018.00193.
- [41] W. Yang, S. Wang, Y. Fang, Y. Wang, and J. Liu, "From fidelity to perceptual quality: A semi-supervised approach for low-light image enhancement," Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., pp. 3060–3069, 2020, doi: 10.1109/CVPR42600.2020.00313.
- [42] K. Xu, X. Yang, B. Yin, and R. W. H. Lau, "Learning to restore low-light images via decomposition-and-enhancement," Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., pp. 2278–2287, 2020, doi: 10.1109/CVPR42600.2020.00235.
- [43] T. Ehret, A. Davy, P. Arias, and G. Facciolo, "Joint demosaicking and denoising by fine-tuning of bursts of raw images," Proc. IEEE Int. Conf. Comput. Vis., vol. 2019-October, pp. 8867–8876, 2019, doi: 10.1109/ICCV.2019.00896.
- [44] K. Dabov, A. Foi, V. Katkovnik and K. Egiazarian, "Color Image Denoising via Sparse 3D Collaborative Filtering with Grouping Constraint in Luminance-Chrominance Space," 2007 IEEE International Conference on Image Processing, San Antonio, TX, USA, 2007, pp. I - 313-I - 316, doi: 10.1109/ICIP.2007.4378954.

- [45] L. Condat and S. Mosaddegh, "Joint demosaicking and denoising by total variation minimization," 2012 19th IEEE International Conference on Image Processing, Orlando, FL, USA, 2012, pp. 2781-2784, doi: 10.1109/ICIP.2012.6467476.
- [46] D. Khashabi, S. Nowozin, J. Jancsary, and A. W. Fitzgibbon, "Joint demosaicing and denoising via learned nonparametric random fields," *IEEE Trans. Image Process.*, vol. 23, no. 12, pp. 4968–4981, 2014, doi: 10.1109/TIP.2014.2359774.
- [47] F. Kokkinos and S. Lefkimmias, "Deep image demosaicking using a cascade of convolutional residual denoising networks," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 11218 LNCS, pp. 317–333, 2018, doi: 10.1007/978-3-030-01264-9\_19.
- [48] K. Hirakawa and T. W. Parks, "Joint demosaicing and denoising," *Proc. - Int. Conf. Image Process. ICIP*, vol. 3, no. 8, pp. 306–309, 2005, doi: 10.1109/ICIP.2005.1530390.
- [49] X. Xu, Y. Ma, and W. Sun, "Towards Real Scene Super-Resolution with Raw Images Supplementary Material," *Cvpr*, no. c, pp. 1723–1731, 2019.
- [50] N. Navab, J. Hornegger, W. M. Wells, and A. F. Frangi, "Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015: 18th International Conference Munich, Germany, October 5-9, 2015 proceedings, part III," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 9351, no. Cvd, pp. 12–20, 2015, doi: 10.1007/978-3-319-24574-4.
- [51] N. Ibtehaz and M. S. Rahman, "MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation," *Neural Networks*, vol. 121, pp. 74–87, 2020, doi: 10.1016/j.neunet.2019.08.025.
- [52] W. Shi et al., "Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-December, pp. 1874–1883, 2016, doi: 10.1109/CVPR.2016.207.
- [53] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, "Image quality assessment: From error visibility to structural similarity," *IEEE Trans. Image Process.*, vol. 13, no. 4, pp. 600–612, 2004, doi: 10.1109/TIP.2003.819861.
- [54] Y. Zhang, J. Zhang, and X. Guo, "Kindling the darkness: A practical low-light image enhancer," *MM 2019 - Proc. 27th ACM Int. Conf. Multimed.*, pp. 1632–1640, 2019, doi: 10.1145/3343031.3350926.
- [55] Z. Ying, G. Li, and W. Gao, "A Bio-Inspired Multi-Exposure Fusion Framework for Low-light Image Enhancement," vol. 14, no. 8, pp. 1–10, 2017, [Online]. Available: <http://arxiv.org/abs/1711.00591>.