

# 超低照度下微光图像增强神经网络损失函数设计分析\*

刘超<sup>1,2</sup>, 张晓晖<sup>1</sup>, 胡清平<sup>1</sup>

(1. 海军工程大学 兵器工程学院, 湖北 武汉 430033; 2. 军事科学院 系统工程研究院, 北京 100044)

**摘要:**超低照度下(环境照度小于 $2 \times 10^{-3}$  lux)微光图像具有低信噪比、低对比度等特点,使目标难以辨识,严重影响观察效果。为了提高超低照度下微光图像质量,设计了一种用于微光图像增强的卷积自编码深度神经网络,并针对传统的均方误差损失函数不符合人类视觉感知特性等问题,结合现有的全参考图像质量评价指标,研究了包括感知损失在内的几种损失函数,并提出了一种新的可微分损失函数。实验结果表明,在网络结构不发生改变的情况下,所提损失函数具有更好的性能,在提高微光图像信噪比和对比度的同时,能够有效地增强图像内部细节信息。

**关键词:**微光图像;图像增强;卷积神经网络;损失函数

中图分类号:TN223 文献标志码:A 文章编号:1001-2486(2018)04-067-07

## Design and analysis of loss functions of low-light level image enhancement neural networks under extreme low-light illumination

LIU Chao<sup>1,2</sup>, ZHANG Xiaohui<sup>1</sup>, HU Qingping<sup>1</sup>

(1. College of Weaponry Engineering, Naval University of Engineering, Wuhan 430033, China;

2. System Engineering Research Institute, Academy of Military Science, Beijing 100044, China)

**Abstract:** Under the extreme LLL (low light level) conditions (environment illumination less than  $2 \times 10^{-3}$  lux), the LLL image has the characteristics of low signal-to-noise ratio and low contrast, so that the target is difficult to be identified, thus seriously affecting the observation effect. In order to improve the LLL image quality, a convolutional autoencoder deep neural network for image enhancement was designed. In view of the fact that the traditional mean square error loss function cannot meet the human visual perception characteristics, several loss functions including perceptual loss were studied and a novel, differentiable loss function was proposed in combination with the existing full reference image quality evaluation index. Experimental results show that the proposed loss function can improve the detail information of the image while improving the signal-to-noise ratio and contrast ratio of the low-light level image when the network structure does not change.

**Key words:** low-light level image; image enhancement; convolutional neural network; loss function

微光成像技术是彩色夜视技术的重要组成部分,目前在军用和民用领域得到了广泛的应用,但是受微光成像原理和器件水平的限制,微光夜视仪在超低照度下所形成的微光图像(环境照度小于 $2 \times 10^{-3}$  lux,如图1所示)因为动态范围小、包含各种随机噪声而具有低信噪比、低对比度等特点,使目标难以辨识,这样的微光图像与红外图像进行融合必然会影响到最终所形成的彩色融合图像的质量,因此提高超低照度下微光图像质量是一个亟待解决的问题<sup>[1-2]</sup>。目前大多数微光图像增强处理的方法都集中在降噪和提高对比度方面,且提高对比度方面已经出现了比较经典的方法(直方图均衡、图像强度的统计分布变换)。

传统的图像降噪算法通常假设噪声特性是已

知的(高斯噪声、泊松噪声或高斯泊松噪声),在噪声不是很严重的情况下能够取得比较好的效果。然而在高噪声或者噪声特性比较复杂的情况下,由于对比度和信噪比较低,图片内部可利用的信息比较少,降噪性能会迅速下降。对于微光成像系统,不仅噪声特性是先验未知的,且在超低照度下,入射光子数不断减少,噪声非常严重,对比度和信噪比也比较低,图片内部可利用的信息也比较少。传统一流的图像降噪方法退化相当严重,很难取得令人满意的效果。近年来,深度学习方法在机器视觉领域取得了巨大成功,基于深度学习的图像增强研究也得到了广泛关注,相对于传统的图像降噪方法,基于深度学习的图像降噪能够充分利用先验数据集内部的有效信息,通过

\* 收稿日期:2017-06-20

基金项目:国家部委基金资助项目(427210843)

作者简介:刘超(1989—),男,陕西周至人,博士研究生,E-mail:generaladolph@163.com;

张晓晖(通信作者),女,教授,博士,博士生导师,E-mail:1547300454@qq.com

学习自然图像的统计特性,借助外部信息来为降噪过程服务,能够有效地增强噪声特性比较复杂、噪声强度比较高的微光图像,而且深度神经网络在对微光图像降噪的同时还可以从训练数据中学习目标图像的对比度。




图 1  $1 \times 10^{-3}$  lux 照度条件下的微光图像

Fig. 1 LLL image under  $1 \times 10^{-3}$  lux illumination conditions

目前,已经有学者将深度学习技术用于可见光图像降噪,并取得了一系列引人注目的成果,但学者们将主要研究方向都放在了网络结构的设计上,而忽视了损失函数的设计。虽然设计了各种各样的可见光图像降噪网络结构,但大都采用均方误差 (Mean Square Error, MSE) 作为损失函数<sup>[3-9]</sup>,仅有少量学者将感知损失函数引入到图像合成和彩色图像复原领域中<sup>[10-11]</sup>。

本文利用深度学习技术,对超低照度下微光图像进行了增强研究,设计了一种用于微光图像增强的卷积自编码深度神经网络,并在此基础上对微光增强网络的损失函数进行了重点研究,结合现有的全参考图像质量评价指标,有针对性地选择了均方根误差 (Root Mean Square Error, RMSE)、平均绝对误差 (Mean Absolute Error, MAE) 和结构相似度 (Structural SIMilarity, SSIM) 三种图像评价指标作为损失函数<sup>[12]</sup>,比较了 MSE 损失函数和这几种损失函数对微光增强影响,最后提出了一种新的损失函数,结果表明,该损失函数对超低照度下微光图像的增强效果优于前面提到的三种指标。

### 1 网络结构

目前出现了大量不同类型的网络结构,但大

都基于图像分类和目标检测研究,虽然能够很好地提取目标的特征,但对超低照度条件下微光图像增强并不适用。针对微光图像增强需要去除各种类型噪声、提高对比度和保留细节信息这一特点,设计了一种包含并行卷积、跳跃结构和子像素卷积的卷积自编码深度神经网络(简称为 Skip Sub-pixel IRCNN),网络结构如图 2 所示。其中并行卷积包含不同尺度的滤波器,主要作用是处理微光图像中不同尺度目标和不同类型噪声;跳跃结构连接对应的卷积层和子像素卷积层,主要作用是确保图像细节信息能够有效地传递到深层网络,并加快网络的训练速度;子像素卷积是一种可以自主学习滤波器参数的反卷积网络结构,主要进行特征图的上采样操作,保证网络输入和输出图像维度的一致性。

### 2 损失函数

#### 2.1 损失函数要求

深度神经网络作为一种数据表达方法,理论上可以逼近任何函数,其训练的本质是通过一种学习算法找到合适的权重和偏置,确保网络的输出  $\mathbf{a}(p)$  为能够拟合所有的训练输入  $\mathbf{x}(p)$ ,一般通过损失函数来量化这一目标。

MSE 损失函数由于其数学形式的方便,在机器学习领域得到了广泛应用,其表达如式(1)所示。

$$C(\mathbf{P}) = \frac{1}{2N} \sum_{p \in \mathbf{P}} \|\mathbf{a}(p) - \mathbf{y}(p)\|^2 \quad (1)$$

其中,  $p$  为像素,  $\mathbf{P}$  表示整个图像块,  $\mathbf{a}(p)$  为网络输入  $\mathbf{x}(p)$  时的激活输出,  $\mathbf{y}(p)$  为网络的真实参考输出。

从式(1)中可以看到损失函数  $C(\mathbf{P})$  是非负的,此外,损失函数  $C(\mathbf{P})$  的值相当小,精确地说,对于所有的网络输入  $\mathbf{x}(p)$ ,激活输出  $\mathbf{a}(p)$  接近于真实参考输出  $\mathbf{y}(p)$ ,即最小化损失函数,使  $C(\mathbf{P}) \approx 0$ 。一般采用梯度下降学习技术来解决损失函数的最小化问题,同时也要求损失函数具备




图 2 网络结构

Fig. 2 Network structure

可导性质。对于 MSE 损失函数,由于  $\partial C(\mathbf{P})/\partial q = 0, \forall q \neq p$ , 则图像块对每一个激活的导数为:

$$\partial C(\mathbf{P})/\partial(p) = \frac{1}{N}[\mathbf{a}(p) - \mathbf{y}(p)] \quad (2)$$

MSE 损失函数的目标形式包含平方项,梯度容易计算,并且具有很好的收敛特性。然而对于微光图像增强问题,MSE 损失函数存在一定限制,首先 MSE 损失函数具有对离群值进行大量加权的缺点,由于对每一项都进行了平方,且对大的误差比对小的误差惩罚得多一些,因此对离子噪声存在过度抑制问题;其次 MSE 损失函数假设噪声服从高斯分布,但对于微光图像,噪声特性复杂,不仅仅包含高斯噪声;最后 MSE 损失函数基于原始误差度量的方式,没有考虑人眼视觉特性,并不能引起人眼视觉感受质量的提高。

由于深度神经网络训练的本质是找到能够最小化损失函数  $C(\mathbf{P})$  的权重和偏置,因此不同形式的损失函数能够引导网络向不同方向学习,对最终的增强图像质量影响很大。全参考图像质量评价指标主要通过标准参考图像来对目标图像质量进行评价,因此可作为深度神经网络的损失函数。为了满足网络的反向传播要求,选择了平滑、可导的几种指标作为微光图像增强网络的损失函数,主要包含基于原始误差度量和基于人眼视觉系统(Human Visual System, HVS)启发度量的两种评价方式指标,其中 MSE、RMSE 和 MAE 指标属于基于原始误差的度量方式;SSIM 指标属于基于 HVS 启发的度量方式。

## 2.2 MAE 损失函数

MAE 损失函数属于原始误差度量方式,由于没有平方项,不会过度惩罚大的误差项,且每个像素误差对 MAE 损失的影响与误差的绝对值成正比,因此其与 MSE 损失函数有不同的收敛特性,其损失函数为:

$$C(\mathbf{P}) = \frac{1}{N} \sum_{p \in \mathbf{P}} |\mathbf{a}(p) - \mathbf{y}(p)| \quad (3)$$

其中,  $p$  为像素,  $\mathbf{P}$  表示整个图像块,  $\mathbf{a}(p)$  为网络输入  $\mathbf{x}(p)$  时的激活输出,  $\mathbf{y}(p)$  为网络的真实参考输出,由于  $\partial C(\mathbf{P})/\partial q = 0, \forall q \neq p$ , 则图像块对每一个激活的导数如式(4)所示,其中  $\text{sgn}$  为符号函数。

$$\partial C(\mathbf{P})/\partial(p) = \text{sgn}[\mathbf{a}(p) - \mathbf{y}(p)] \quad (4)$$

从图 5 可知,MAE 损失函数在目标轮廓的对比度、均匀区域的平滑效果方面优于 MSE 损失函数,且不会对大的离子噪声进行过度惩罚,从而导

致亮度很高的离子噪声变为黑色的椒盐噪声。

## 2.3 RMSE 损失函数

由于 MSE 损失函数强烈地惩罚大错误,因此对异常值非常敏感,为了避免这种情况,可以尝试使用平方根版本,即 RMSE 损失函数,属于原始误差度量方式,其表达如式(5)所示。

$$C(\mathbf{P}) = \frac{1}{\sqrt{N}} \sqrt{\sum_{p \in \mathbf{P}} \|\mathbf{a}(p) - \mathbf{y}(p)\|^2} \quad (5)$$

由于  $\partial C(\mathbf{P})/\partial q = 0, \forall q \neq p$ , 则图像块对每一个激活的导数为:

$$\partial C(\mathbf{P})/\partial(p) = \frac{2[\mathbf{a}(p) - \mathbf{y}(p)]}{2\sqrt{N} \sum_{p \in \mathbf{P}} \|\mathbf{a}(p) - \mathbf{y}(p)\|^2} \quad (6)$$

RMSE 损失函数对异常值的敏感性和 MAE 损失函数相当,但相对于 MAE 损失函数, RMSE 避免使用绝对值,从图 5 中可以看到在对比度提升、均匀区域平滑方面和 MAE 损失函数一致,但在对离子噪声抑制方面优于 MAE 损失函数。

## 2.4 SSIM 损失函数

尽管基于原始误差度量的损失函数计算简单方便,但由于其与人眼视觉主观感受不相关,因此需要考虑人眼视觉特性,选择新的基于人眼视觉系统启发度量的评价指标作为损失函数。研究发现,人眼视觉系统适合从图像中提取结构信息,而图像质量的退化主要由于图像中结构化信息的丢失,因此构思测量结构失真的质量度量与人眼感知的图像具有良好的相关性。在这里我们选择误差函数满足感知特性的结构相似度,结构相似度被表示为:

$$SSIM(\mathbf{a}, \mathbf{y}) = [l(\mathbf{a}, \mathbf{y})]^\alpha [c(\mathbf{a}, \mathbf{y})]^\beta [s(\mathbf{a}, \mathbf{y})]^\gamma \quad (7)$$

$$l(\mathbf{a}, \mathbf{y}) = \frac{2\bar{a} \cdot \bar{y} + C_1}{\bar{a}^2 + \bar{y}^2 + C_1} \quad (8)$$

$$c(\mathbf{a}, \mathbf{y}) = \frac{2\sigma_a \sigma_y + C_2}{\sigma_a^2 + \sigma_y^2 + C_2} \quad (9)$$

$$s(\mathbf{a}, \mathbf{y}) = \frac{2\sigma_{ay} + C_3}{\sigma_a \sigma_y + C_3} \quad (10)$$

其中:  $\alpha, \beta$  和  $\gamma$  控制 SSIM 中三个项中的每一项的相对重要性;  $l, c, s$  分别是亮度、对比度和结构分量;  $\bar{a}$  和  $\bar{y}$  表示原始和编码图像的平均值;  $\sigma_a$  和  $\sigma_y$  是标准偏差;  $\sigma_{ay}$  是两个图像的协方差。如果  $\alpha = \beta = \gamma, C_3 = C_2/2$ , 则结构相似度如式(1)所示。

$$\begin{aligned} SSIM(\mathbf{a}, \mathbf{y}) &= \frac{2\bar{a} \cdot \bar{y} + C_1}{\bar{a}^2 + \bar{y}^2 + C_1} \cdot \frac{2\sigma_{ay} + C_2}{\sigma_a^2 + \sigma_y^2 + C_2} \\ &= l(p) \cdot cs(p) \end{aligned} \quad (11)$$

令单个像素误差函数为  $\varepsilon(p) = 1 - SSIM(p)$ , 则损失函数可以被定义为:

$$C(\mathbf{P}) = \frac{1}{N} \sum_{p \in \mathbf{P}} 1 - SSIM(p) \quad (12)$$

$SSIM(p)$  的计算需要观察像素  $p$  的邻域。这意味着  $C(\mathbf{P})$  及其导数不能在  $\mathbf{P}$  的一些边界区域中计算, 但这些边界区域对整体的影响并不重要, 为了计算  $p$  邻域的结构相似度, 需要给  $p$  设定一定大小的邻域  $G$ 。然后计算图像块  $p$  对其中任何其他像素  $q$  的导数:

$$\begin{aligned} \frac{\partial C(\mathbf{P})}{\partial \mathbf{x}(q)} &= -\frac{1}{N} \sum_{p \in \mathbf{P}} \frac{\partial}{\partial \mathbf{x}(q)} SSIM(p) \\ &= -\frac{1}{N} \sum_{p \in \mathbf{P}} \left[ \frac{\partial l(p)}{\partial \mathbf{x}(q)} cs(p) + l(p) \frac{\partial cs(p)}{\partial \mathbf{x}(q)} \right] \end{aligned} \quad (13)$$

$$\frac{\partial l(p)}{\partial \mathbf{a}(q)} = 2G \left( \frac{\bar{y} - \bar{a} \cdot l(p)}{\bar{a}^2 + \bar{y}^2 + C_1} \right) \quad (14)$$

$$\frac{\partial cs(p)}{\partial \mathbf{a}(q)} = \frac{2G[(\mathbf{y}(q) - \bar{y}) - cs(p) \cdot (\mathbf{a}(q) - \bar{a})]}{\sigma_a^2 + \sigma_y^2 + C_2} \quad (15)$$

SSIM 损失函数能够很好地恢复图像的结构和局部细节, 但是 SSIM 损失函数在提高对比度方面的效果弱于 MAE 和 RMSE 损失函数。

## 2.5 MAE + SSIM 损失函数

由前面分析可知, SSIM 损失函数由于引入结构约束, 在保持图像高频细节和图像内容方面优于其他损失函数, MAE 和 RMSE 损失函数对所有误差采用相等的权重而不去考虑图像的局部结构, 能够有效平滑图像均匀区域和提高轮廓对比度, 但由于 RMSE 求导计算比较复杂, 因此结合 SSIM 和 MAE 两种误差函数的优势, 本文提出了下面的损失函数。

$$C(\mathbf{P}) = \alpha C^{SSIM}(\mathbf{P}) + (1 - \alpha) C^{L1}(\mathbf{P}) \quad (16)$$

其中,  $\alpha$  是权重超参数, 主要用来平衡 MAE 损失函数和 SSIM 损失函数对最终误差的贡献, 因为该超参数改变了损失函数的误差值, 不能够采用传统的通过观察损失函数误差的方式进行设置。本文采用 SSIM 和峰值信噪比 (Peak Signal to Noise Ratio, PSNR) 两种评估指标进行  $\alpha$  超参数的设置, 由于 SSIM 的提升更加符合人眼的视觉感受, 因此将 SSIM 设置为优化指标, PSNR 设置为满足指标, 这里 PSNR 的阈值设置为采用 SSIM 损失函数时获得的峰值信噪比  $T = 21.23$  dB, 不同  $\alpha$  值的测试结果如表 1 所示。

表 1 不同  $\alpha$  值的量化指标

Tab. 1 Quantitative indicators of different $\alpha$ values					
$\alpha$	0.1	0.3	0.5	0.7	0.9
PSNR	21.21	21.03	20.76	22.25	21.983
SSIM	0.771 0	0.755 1	0.745 3	0.760 2	0.756 3

可以看到, 当  $\alpha = 0.7$  时峰值信噪比满足最低阈值限制, 并且取得了最优的结构相似度。

## 3 实验

### 3.1 训练集建立

由于真实场景环境照度变化不可控, 难以进行大量数据集的采集, 本文通过在添加不同透过率的衰减片来模拟不同照度效果。

本文采集了  $5 \times 10^{-2}$  lux 条件下的微光图像, 然后依次添加透过率分别为 50%、10%、1%、0.5%、0.1% 的衰减片, 分别模拟  $2.5 \times 10^{-2}$  lux、 $5 \times 10^{-3}$  lux、 $5 \times 10^{-4}$  lux、 $2.5 \times 10^{-4}$  lux、 $5 \times 10^{-5}$  lux 的照度条件, 采集的图像如图 3 所示, 可以看到在  $5 \times 10^{-2}$  lux 照度下, 微光图像成像质量较好, 对比度和信噪比都比较高, 随着环境照度的降




(a)  $5 \times 10^{-2}$  lux

(b)  $2.5 \times 10^{-2}$  lux



(c)  $5 \times 10^{-3}$  lux

(d)  $5 \times 10^{-4}$  lux




(e)  $2.5 \times 10^{-4}$  lux

(f)  $5 \times 10^{-5}$  lux

图 3 通过添加衰减片得到的不同环境照度下的微光图像  
Fig. 3 Low light level image under different environmental illumination obtained by the addition of attenuator

低,图像质量越来越差,图像亮度、对比度、信噪比不断下降。本文训练集采用高照度下的退化前图像( $5 \times 10^{-2}$  lux 照度下)和真实的退化后图像( $5 \times 10^{-4}$  lux 照度下)。

虽然  $5 \times 10^{-2}$  lux 照度下的微光图像有较好的对比度,但由于成像机理的限制,同可见光图像相比,其对比度水平依旧很低。因此需要对该照度图像进行预处理操作,进一步提高训练集图像质量;同时由于高照度图像( $5 \times 10^{-2}$  lux 照度下)和低照度图像( $5 \times 10^{-4}$  lux 照度下)亮度信息不一致,因此需要通过亮度处理,确保其亮度和低照度图像亮度处于一个水平上,便于指导网络更好地训练。图4为训练集中一对典型照片的处理效果。



(a) 高照度 (b) 预处理 (c) 低照度  
(a) High illumination (b) Preprocessing (c) Low illumination

图4 高照度图像预处理前后对比

Fig. 4 Comparison of original high illumination image and after preprocessing

### 3.2 训练细节

训练样本:首先从建立的30对微光复原数据集中随机抽取15 000对图像块( $\mathbf{x}^i, \mathbf{y}^i$ ),其中 $\mathbf{y}^i$ 表示 $2 \times 10^{-5}$  lux 照度下的微光图像块, $\mathbf{x}^i$ 表示 $5 \times 10^{-4}$  lux 照度下的微光图像块。并从中随机提取1000对作为验证集,其余作为训练集。

训练参数:优化算法采用学习率可以自适应优化的Adam算法,初始学习率 $lr = 0.001$ ;权重初始化采用xavier初始化方法<sup>[13]</sup>;激活函数采用ReLU函数;Batchsize设置为100;周期数设置为60。

训练环境:训练过程均采用Keras库实现,训练平台采用CPU为intel i7 4710MQ, GPU为nvidia gtx 860,内存为16 G的笔记本。

训练方式:将处理好的训练样本作为网络的输入和输出;然后利用反向传播算法不断进行参数的更新,直至损失函数不再降低,可认为网络模型已经训练成功;最后利用训练好的模型对测试集数据进行测试。

### 3.3 实验结果

采用前面分析的不同损失函数和所设计的网

络结构分别在所提供的硬件环境中进行训练,并将测试结果与传统经典3维块匹配滤波(Block-Matching and 3D filtering, BM3D)去噪算法<sup>[14]</sup>进行了比较。图5为4幅典型测试图像的处理结果,每个场景子图中从左至右、从上至下依次为:目标图像、超低照度下图像、BM3D方法效果、MSE损失函数效果、RMSE损失函数效果、MAE损失函数效果、SSIM损失函数效果和MAE + SSIM损失函数效果。



(a) 场景1复原效果

(a) Scene 1 restoration effect




(b) 场景2复原效果

(b) Scene 2 restoration effect



(c) 场景3复原效果

(c) Scene 3 restoration effect



(d) 场景4复原效果

(d) Scene 4 restoration effect

图5 各种场景下不同损失函数的处理结果

Fig. 5 Results of different loss function


通过人眼可以看到采用基于深度神经网络的

增强效果都好于传统的 BM3D 方法,且不同损失函数效果有所不同,总的来说采用传统的 MSE 损失函数获得的效果最差;MAE 和 RMSE 能够很好地提高对比度,且均匀区域平滑效果好;SSIM 能够很好地恢复图像的结构和局部细节;MAE + SSIM 能够很好地综合两者优势。


为了更好地展示不同方法的增强效果,对图 6 中用方框标记的区域(从左至右依次为区域 1 至区域 5)进行了复原并放大显示,结果如图 7 所示,可以看到,MSE 损失函数复原的效果相对于其他几种损失函数较差,如图 7(b)中树干轮廓




图 6 参考图像  
Fig. 6 Reference image




(a) 区域 1 复原效果  
(a) Zone 1 restoration effect




(b) 区域 2 复原效果  
(b) Zone 2 restoration effect



(c) 区域 3 复原效果  
(c) Zone 3 restoration effect



(d) 区域 4 复原效果  
(d) Zone 4 restoration effect



(e) 区域 5 复原效果  
(e) Zone 5 restoration effect

图 7 各种场景下不同损失函数的处理结果放大图  
Fig. 7 Enlarged drawing of different loss function results

区域的 MSE 损失函数复原效果的对比度比较差,且均匀区域不够平滑,图 7(c)中均匀区域的 MSE 损失函数复原效果对离子噪声进行了过度惩罚,将灰度值很高的离子噪声增强为灰度值很低的椒盐噪声;RMSE 和 MAE 损失函数的复原图像对比度比较好,且均匀区域比较平滑,但对图像的结构复原不够好;SSIM 损失函数由于引入了结构约束,且符合人眼视觉感受,因此复原结构能够很好地保留图像结构和内部细节信息,图 7(a)中汽车前盖饱和区域的 SSIM 损失函数复原效果使得细节信息得到了更好的保留,但是对比度提升效果不如 MAE 和 RMSE 损失函数;SSIM + MAE 损失函数能够综合 MAE 损失函数对离子噪声的抑制、对比度的提高和 SSIM 损失函数对结构细节保留的优势,从而产生了很好的结果。

最后对所有的结果进行了量化分析,采用结构相似度<sup>[15]</sup>、峰值信噪比<sup>[16]</sup>和具有感知特性的视觉信噪比<sup>[17]</sup>等指标对测试结果进行了量化。测试图像在这些指标上的平均值如表 2 所示。采用基于深度神经网络的微光图像增强方法在大部分指标上优于传统的 BM3D 算法,且采用 MAE + SSIM 损失函数的网络能够综合两种损失函数的指标优势,同时取得较好的峰值信噪比和结构相似度,且视觉信噪比指标最优,这说明相对于其他

损失函数,该损失函数能够在有效的综合降噪、提高对比度和保留图像细节的优势。

表2 不同测试数据集上不同图像质量度量的平均值

Tab.2 Average of different image quality measurements in different data sets

图像评价指标	噪声	BM3D	MSE	RMSE	MAE	SSIM	MAE + SSIM
SSIM	0.479 7	0.614 1	0.756 7	0.754 8	0.752 7	0.762 7	0.760 2
PSNR	15.06	18.18	21.64	21.15	21.23	22.19	22.25
VSNR	12.12	14.95	13.19	13.85	13.81	14.21	14.35

## 4 结论

本文主要进行了深度卷积自编码网络对超低照度下微光图像的增强研究,结合现有的全参考图像质量评价指标,研究了包括感知损失在内的几种损失函数对微光增强的影响,并提出了一种新的损失函数,实验结果表明,采用该损失函数训练的网络胜过其他网络,并且增强结果与现有的一流降噪方法相比,具有较好的增强效果。

## 参考文献 (References)

- [1] 曾桂林, 苏秉华, 牛丽红, 等. 基于神经网络的微光图像增强与复原[J]. 兵工学报, 2006(4): 652 - 654.  
ZENG Guilin, SU Binghua, NIU Lihong, et al. Neural network-based low-light-level image enhancement and reconstruction [J]. Acta Armamentarii, 2006(4): 652 - 654. (in Chinese)
- [2] 金伟其, 陶禹, 石峰, 等. 微光视频器件及其技术的进展[J]. 红外与激光工程, 2015(11): 3167 - 3176.  
JIN Weiqi, TAO Yu, SHI Feng, et al. Progress of low level light video technology [J]. Infrared and Laser Engineering, 2015(11): 3167 - 3176. (in Chinese)
- [3] Zhang K, Zuo W, Chen Y, 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.
- [4] Xie J X, Xu L L, Chen E H. Image denoising and inpainting with deep neural networks [C]// Proceedings of the 21st International Conference on Neural Information Processing Systems, 2012: 341 - 349.
- [5] Vincent P, Larochelle H, Lajoie I, et al. Stacked denoising autoencoders: learning useful representations in a deep network with a local denoising criterion [J]. Journal of Machine Learning Research, 2010, 11: 3371 - 3408.
- [6] Jain V, Seung H S. Natural image denoising with convolutional networks [C]//Proceedings of the 21st International Conference on Neural Information Processing Systems, 2009: 769 - 776.
- [7] Chen G, Srihari S N. Removing structural noise in handwriting images using deep learning [C]// Proceedings of the Indian Conference on Computer Vision Graphics and Image Processing, 2014: 28.
- [8] Burger H C, Schuler C J, Harmeling S. Image denoising: can plain neural networks compete with BM3D? [C]// Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2012: 2392 - 2399.
- [9] Agostinelli F, Anderson M R, Lee H. Adaptive multi-column deep neural networks with application to robust image denoising [C]//Proceedings of Advances in Neural Information Processing Systems, 2013: 1493 - 1501.
- [10] Snell J, Ridgeway K, Liao R J, et al. Learning to generate images with perceptual similarity metrics [J]. Computer Science, 2017: 1511.06409.
- [11] Zhao H, Gallo O, Frosio I, et al. Loss functions for image restoration with neural networks [J]. IEEE Transactions on Computational Imaging, 2017, 3(1): 47 - 57.
- [12] Lahoulou A, Bouridane A, Viennet E, et al. Full-reference image quality metrics performance evaluation over image quality databases [J]. Arabian Journal for Science and Engineering, 2013, 38(9): 2327 - 2356.
- [13] Glorot X, Bengio Y. Understanding the difficulty of training deep feedforward neural networks [C]// Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics, 2010: 249 - 256.
- [14] Dabov K, Foi A, Katkovnik V, et al. Image denoising by sparse 3-D transform-domain collaborative filtering [J]. IEEE Transactions on Image Processing, 2007, 16(8): 2080 - 2095.
- [15] Wang Z, Bovik A C, Sheikh H R, et al. Image quality assessment: from error visibility to structural similarity [J]. IEEE Transactions on Image Processing, 2004, 13(4): 600 - 612.
- [16] Wikipedia Corporation Peak signal-to-noise ratio [EB/OL]. (2017 - 2 - 07) [2017 - 06 - 20]. [https://en.wikipedia.org/wiki/Signal-to-noise\\_ratio](https://en.wikipedia.org/wiki/Signal-to-noise_ratio).
- [17] Chandler D M, Hemami S S. VSNR: a wavelet-based visual signal-to-noise ratio for natural images [J]. IEEE Transactions on Image Processing, 2007, 16(9): 2284 - 2298.