

文章编号 1004-924X(2018)04-0951-11

超低照度下微光图像的深度学习 卷积自编码网络复原

刘 超*, 张晓晖

(海军工程大学 兵器工程系, 湖北 武汉 430033)

摘要: 微光/红外图像彩色融合是目前国内外夜视技术的重要发展方向, 在超低照度下(环境照度小于 2×10^{-3} lux), 由于成像器件限制, 微光图像具有低信噪比、低对比度等特点, 导致目标难以辨识, 成为制约彩色夜视技术的关键。为了提高目标的探测和识别率, 提出了一种基于卷积自编码网络的微光图像复原方法, 利用卷积自编码网络从微光图像训练集中学习超低照度下微光图像特征, 实现去噪和对比度增强。实验结果表明, 本文提出的方法得到的峰值信噪比(Peak Signal to Noise Ratio, PSNR)较经典的 BM3D 算法平均提高 1.67 dB, 结构相似度(Structural Similarity Index, SSIM)的值平均提高 0.063, 均方根对比度的值(Root Mean Square Contrast, RMSC)平均提高 0.19。对微光图像复原具有很好的效果, 能够有效地提高信噪比和对比度水平。

关键词: 微光图像; 图像复原; 卷积神经网络; 图像去噪; 子像素卷积

中图分类号: TN223 **文献标识码:** A **doi:** 10.3788/OPE.20182604.0951

Deep convolutional autoencoder networks approach to low-light level image restoration under extreme low-light illumination

LIU Chao*, ZHANG Xiao-hui

(Department of Weaponry Engineering, Naval University of Engineering, Wuhan 430033, China)

* Corresponding author, E-mail: generaladolph@163.com

Abstract: LLL (Low-Light Level) / infrared image color fusion is an important development direction of night vision technology in the world. Under extreme low light level (environment illumination less than), LLL image has low signal to noise ratio and low contrast features, and the target is difficult to identify as imaging device limitations, which has been a key constraint to color night vision technology. In order to improve target detection and recognition rate, LLL image restoration method based on the deep convolutional autoencoder network was proposed, which learning LLL image characteristics from the LLL image training set by using the convolutional autoencoder, and implementing de-noising and contrast enhancement. The experiment results show that, compared with the classical BM3D algorithm, the proposed method improves the peak signal to noise ratio (PSNR) with value of 1.67 dB and reduces the RMSE with value of 0.098, improves the structural similarity (SSIM) with the value of 0.063 and improves the root mean square contrast (RMSC) with value of 0.91. It has a very good

收稿日期: 2017-08-18; 修订日期: 2017-09-26.

基金项目: 军内重点科研项目 (No. 427210843)

effect on the restoration of low light level images, and improves the signal-to-noise ratio and contrast level effectively.

Key words: Low-Light-Level image (LLL); image restoration; convolutional neural network; image de-noise; sub-pixel convolution

1 引言

微光成像技术是研究在夜天光或者光照情况比较差的情况下,利用光电转换技术实现对微弱目标信息的增强,是拓展人类夜间视觉感知的主要技术之一,是实现微光/红外彩色融合技术的关键,在军用和民用领域得到了广泛应用。但在超低照度下(环境照度小于 2×10^{-3} lux),微光图像具有低信噪比、低对比度和低分辨等特点,且图像整体灰度值较低,导致目标难以辨识,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^[1-3]。

目前,学者们利用图像处理技术改善微光图像质量取得了一定成果,针对微光图像低信噪比、低对比度等特点,研究主要集中在去噪和对比度增强两个方面。提出的方法有小波变换滤波法、时空域联合滤波法以及一些经典的图像去噪方法(主要假设噪声服从高斯分布、泊松分布等)^[4-5]。2010年,陈立等人提出了一种众值帧积分法进行微光图像离子噪声抑制,从时空域角度进行了噪声处理。但由于超低照度下的微光图像对比度比较低,且具有复杂的噪声特性(包含各种类型的噪声如高斯噪声、泊松噪声、离子噪声等),噪声模型难以精确建立,因此传统方法很难取得令人满意的效果。

近年来,基于深度学习的图像复原研究得到了广泛关注。2008年,Vincent提出了去噪自编码(De-noising Autoencoder, DA)概念^[6];2012年,Xie等人将去噪自编码应用到图像去噪和图像修复领域^[7];Burger等人利用栈式去噪自编码(Stacked De-noising Autoencoder, SDA)研究多层感知器的编码和解码过程实现噪声图像到清晰图像地重构^[8];2013年,Agostinelli等人提出了一种自适应多列自编码结构,通过训练包含各种噪声类型的训练集来提高模型去噪的鲁棒性^[9];2014年,吴洋威等人用ReLU函数代替Sigmoid函数作为深度神经网络隐藏层的激活函数,用来

提高去噪网络地训练速度^[10];2015年,Kin等人利用深度自编码器网络提取低照度图像特征来实现自适应变亮和去噪,其低照度退化图像主要通过非线性暗化和添加高斯噪声的方法来模拟^[11];2015年,Dong等人提出了一种去噪卷积神经网络,用来去除图像压缩引起的噪声,首次将卷积神经网络引入到图像去噪领域^[12];2016年,Mao等人提出了一种非常深的卷积自编码网络,用来进行去噪和超分辨率重构研究^[13]。但上述方法,主要针对可见光图像,且退化图像一般通过人为添加噪声进行模拟,并不能反映真实图像地退化特性,因此不能够直接应用于超低照度下微光图像复原。

一般来说,基于深度神经网络的图像复原方法是纯数据驱动,即直接从数据中学习复原参数,且不用对噪声分布做出假设。因此本文结合超低照度下微光图像退化特征设计了一种微光图像复原网络结构,并利用课题组研制的微光/红外融合观察仪的微光观察模式采集了大量自然场景中退化前和退化后数据,将同一目标的高照度下图像(环境照度为 5×10^{-2} lx)和超低照度下图像(环境照度为 5×10^{-4} lx)作为一组训练样本对。然后通过随机梯度下降法学习网络模型参数,实验结果表明训练好的模型能够很好地复原超低照度下的微光测试集图像,提高微光图像信噪比和对比度水平,并且在英伟达 GTX850 GPU 上处理 720×576 大小的图像只需要不到 1 s 时间,下一步可通过模型压缩进一步提升运算效率。

2 超低照度下微光图像复原模型设计

2.1 问题描述

微光成像系统是一个复杂的光电、电光转换过程,成像过程中包含各种各样的退化,在高照度下,采用三代像增强管成像技术可以达到较好的信噪比和对比度,但随着环境照度地降低,微光图像受到探测器工艺、非线性、环境照度、噪声等多种因素影响,对比度和亮度不断下降,噪声急剧增加,导致成像质量快速下降,目标难以辨识,因此

需要将超低照度下微光图像复原到高照度下微光图像的信噪比和对比度水平^[14]。

设 $y \in \mathbf{R}^N$ 表示高照度下微光图像 ($5 \times 10^{-2} \text{lx}$), $x \in \mathbf{R}^N$ 表示超低照度下微光图像 ($5 \times 10^{-4} \text{lx}$), 可以将微光图像退化过程表示为:

$$x = My, \quad (1)$$

其中 $M \in \mathbf{R}^{N \times N}$ 是引起微光图像退化的高维、非线性矩阵。因此超低照度下图像复原问题可以转化:

$$N = \arg \min_N E \| Nx - y \|_2^2, \quad (2)$$

其中: $\arg \min$ 表示使目标函数取最小值的变量, E 表示求期望, 从上式可以看到, 本文的目的是寻找一个高维矩阵 N 可以很好地近似 M^{-1} , 实现超

低照度下微光图像复原。

2.2 网络结构设计

目前学者们开发了各种典型的深度神经网络结构, 如 AlexNet、ResNet、VGGNet、GoogleNet 和 SqueezeNet 等, 但大都基于图像分类和目标检测研究, 并不能直接应用于超低照度下微光图像复原。针对微光图像复原需要去除高斯、泊松、离子等多种类型噪声、提高对比度和保留图像细节这一特点, 本文受自编码网络、残差网络和反卷积网络启发, 设计了一种包含并行卷积、跳跃结构和子像素卷积层的卷积自编码深度神经网络(简称为 Skip Sub-pixel IRCNN), 如图 1 所示。




图1 网络结构

Fig. 1 Network structure

由于现有的图像复原网络采用级联结构, 随着层数的加深, 网络难以训练, 本文通过在网络中引入跳跃结构连接具有相同空间分辨率的卷积层和子像素卷积层, 能够加快网络训练速度, 防止网络陷入局部最优, 同时保证微光图像细节信息的有效传递。卷积层和子像素卷积层采用编码-解码模式进行连接, 卷积层主要用来进行特征提取和增强, 实现去噪和对比度提升, 网络中第 1、2、4、5 层为卷积层, 由于微光图像包含噪声特性复杂, 且图像尺度丰富, 因此第 1 卷积层采用包含不同滤波器大小的并行卷积结构, 可以密集地计算在多个空间尺度的输入图像特征, 主要作用是提取微光图像中不同尺度目标和不同类型噪声特征, 但是由于并行卷积会导致参数的大量增加, 因此在并行卷积后面连接 1×1 卷积进行维度压缩; 第 2 卷积层采用步长为 2 的滑动窗对上层的特征图进行下采样操作, 主要进行图像的高级特征提取、对比度拉伸和噪声抑制; 网络中的第 3 层为子像素卷积层, 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, 能够克服传统双线性插值和转置卷积引起的图像边缘模糊, 同时计

算量小, 因此本文利用子像素卷积层对上层降采样的特征图进行放大率为 2 的上采样, 保证网络输入和输出维度的一致性。第 4 卷积层对子像素卷积层和并行卷积层的输出特征图进行综合处理, 目的是进一步抑制噪声和提高对比度, 并进行图像重建和细节恢复; 第 5 卷积层主要功能是进行输出地转换, 对前一层输入进行线性组合。网络中还包括非线性激活层, 主要结合卷积层和子像素卷积层来逼近任意函数, 这里采用近似生物神经激活的 $\text{ReLU}(x) = \max(0, x)$ 函数。

本文设计的网络输入和输出具有相同的尺寸 $w \times h \times d$, 其中 w, h, d 分别为图像的宽度、高度和维度, 由于微光图像为灰度图像, 因此其维度 $d = 1$ 。设 $F_0(x) = x$ 表示输入, $F_l (0 < l \leq L)$ 表示卷积层和子像素卷积层, $\mathbf{W}_l, \mathbf{b}_l$ 分别表示卷积层或子像素卷积层的卷积核的权重和偏差, $*$ 表示卷积或子像素卷积操作, $\mathbf{W}_{11} = 3 \times 3 \times 128$, $\mathbf{W}_{12} = 5 \times 5 \times 128$ 和 $\mathbf{W}_{13} = 7 \times 7 \times 128$ 分别表示第一并行卷积层包含的 3 种不同尺度大小的卷积核, 网络第 1、2、3 层的输出可表示为:

$$F_1(x) = \frac{1}{3} \sum_{i=1}^3 \max(0, \mathbf{W}_{1,i} * F_0(x) + \mathbf{b}_{1,i}), \quad (3)$$

$$F_2(x) = \max(0, \mathbf{W}_2 * F_1(x) + \mathbf{b}_2), \quad (4)$$

$$F_3(x) = \max(0, \mathbf{W}_3 * F_2(x) + \mathbf{b}_3). \quad (5)$$

对于第 4 层,由于跳跃结构的引入,涉及到求和操作,其输出可表示为:

$$F_4(x) = \max(0, \mathbf{W}_4 * (F_2(x) + F_3(x)) + \mathbf{b}_4). \quad (6)$$

对于第 5 层,由于主要目的是进行输出地转换,仅对前一层进行线性组合,因此没有使用 ReLU 激活函数,其输出可表示为:

$$F_5(x) = \mathbf{W}_5 * F_4(x) + \mathbf{b}_5. \quad (7)$$

3 实验结果与分析

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地采集,本文通过在课题组研制的微光/红外融合观察仪的微光通道镜头前添加不同透过率的可见光和近红外波段中性密度衰减片来模拟不同照度效果,采集真实的不同照度下微光图像。

实验中,首先在不加衰减片的情况下进行微光图像采集,并用照度计测量环境照度为 m lx,然后通过添加不同透过率 α 的衰减片来模拟 $\alpha \times m$ lx 照度条件。通过对真实照度环境下和模拟照度环境下的微光图像进行观察和噪声特性分析,发现二者具有相同的退化特性,说明通过添加衰减片这种方式采集的退化图像和真实退化图像一致。

本文在 5×10^{-2} lx 条件下采集微光图像,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 2.5×10^{-2} lx、 5×10^{-3} lx、 5×10^{-4} lx、 2.5×10^{-4} lx、 5×10^{-5} lx 的照度条件,采集的图像如图 2 所示,可以看到在照度下,微光图像成像质量较好,基本没有噪声,随着环境照度的降低,图像质量越来越差。本文训练集采用质量较好的退化前图像(5×10^{-2} lx 照度下)和真实的退化后图像(5×10^{-4} lx 照度下)。

虽然 5×10^{-2} lx 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




(a) 5×10^{-2} lx(b) 2.5×10^{-2} lx(c) 5×10^{-3} lx(d) 5×10^{-4} lx(e) 2.5×10^{-4} lx(f) 5×10^{-5} lx

图 2 通过添加衰减片得到的不同环境照度下微光图像
Fig. 2 LLL image under different environmental illumination obtained by the addition of attenuator



(a) 高照度

(b) 预处理

(c) 低照度

(a) High illumination (b) Preprocessing (c) Low illumination

图 3 高照度图像预处理前后对比

Fig. 3 Comparison of original high illumination image and after preprocessing

比,其对比度水平依旧很低,因此需要对该照度图像进行对比度拉伸操作,进一步提高训练集图像质量,同时由于高照度图像(5×10^{-2} lx 照度下)和低照度图像(5×10^{-4} lx 照度下)亮度差异比较大,网络容易仅学习亮度的变化关系,而忽略对比度和噪声的学习,因此需要对高照度图像进行亮度降低预处理,确保其亮度和低照度图像亮度处

于一个水平上。最终对训练集的高照度图像进行了对比度拉伸和亮度降低操作,图3为其中一张训练集的处理效果。

3.2 训练测试

设 $D=(\mathbf{x}^i, \mathbf{y}^i)$ 为包含 N 个训练样本对的数据集, $\mathbf{y}^i \in \mathbf{R}^N$ 表示 2×10^{-5} lx 照度下微光图像块, $\mathbf{x}^i \in \mathbf{R}^N$ 表示 5×10^{-4} lx 照度下微光图像块。通过最小化均方差来估计参数 $\theta=(\mathbf{W}_l, \mathbf{b}_l)$, 目标函数为:

$$J(\theta) = \frac{1}{N} \sum_{i=1}^N \|F(\mathbf{x}^i; \theta) - \mathbf{y}^i\|, \quad (8)$$

其中,数据集 D 是来自于训练集(5×10^{-2} lx 和 5×10^{-4} lx 照度下的微光图像对)的 64×64 图像块对。本文采用随机梯度下降法求解损失函数,每一步的更新为:

$$\theta^{t+1} \leftarrow \theta^t - \eta_t (F(\mathbf{x}^i) - \mathbf{y}^i)^T \frac{\partial}{\partial \theta} F(\mathbf{x}^i), \quad (9)$$

其中 $\eta_t = 0.001 / (1 + 5t \times 10^{-7})$ 为可变学习率,随着训练次数的增加不断衰减,初始学习率为 0.001,卷积层和反卷积层的滤波器尺寸除第 1 层外均设置为 3×3 ,权重采用 Xavier 初始化,偏差统一初始化为 0,训练周期设置为 80,批处理大小为 32。然后采用 Tensorflow 开源架构在 GTX850 GPU 上训练本文提出的网络结构。最后采用峰值信噪比(PSNR)、结构相似度(SSIM)和均方根对比度(RMSC)来评估模型的复原效果,峰值信噪比是基于对应像素点间的误差,即基于误差敏感的图像质量评价,主要用来衡量模型的去噪表现。设原始和复原后信号为 x 和 y , 峰值信噪比表达式为:

$$\text{PSNR} = 10 \lg \left(\frac{255^2}{\sum_{i=1}^H \sum_{j=1}^W (x(i, j) - y(i, j))^2 / H \times W} \right), \quad (10)$$

其中: H, W 分别为图像的高度和宽度, $x(i, j)$ 是退化图像中第 (i, j) 像素的强度值, $y(i, j)$ 是复原后图像中第 (i, j) 像素的强度值。

SSIM 用来估计图像亮度,对比度和结构变化等 3 个量的复合效果,主要用来比较图像的一致性和准确性,其表达式为:

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

$$l(x, y) = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1}, \quad (12)$$

$$c(x, y) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2}, \quad (13)$$

$$s(x, y) = \frac{2\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3}, \quad (14)$$

其中: α, β 和 γ 控制 SSIM 中的 3 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, μ_x 和 μ_y 表示原始和编码图像的平均值, σ_x 和 σ_y 是标准偏差, σ_{xy} 是两个图像的协方差。

RMS 对比度主要用来衡量复杂图像的对比度,其定义为像素强度的标准差,表达式为:

$$\text{RMS} = \sqrt{\frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W (y(i, j) - \bar{y})^2}, \quad (15)$$

其中: H, W 分别为图像的高度和宽度, $y(i, j)$ 是图像中第 (i, j) 像素的强度值, \bar{y} 是图像的平均强度,均方根对比度越大说明图像的对比度越好。

在进行测试的过程中,虽然设计的网络结构采用 64×64 大小的图像块对进行训练,但由于卷积神经网络的内在特性,可以处理任意大小的微光图像,即给定微光测试图像,可以简单的通过网络前向传播进行复原。

3.3 网络结构评估

主要对本文提出的跳跃结构和子像素卷积层的效果进行了实验分析。

3.3.1 跳跃结构作用评估

2.2 节提到跳跃结构主要有两个优势:(1)将图像的细节信息传递到网络的重构端;(2)能够有效防止梯度爆炸,加快收敛速度。本文对有无跳跃结构的两种网络进行了实验。包含跳跃结构的网络采用本文设计的 Skip Sub-pixel IRCNN,无跳跃结构的网络即将 Skip Sub-pixel IRCNN 结构中的跳跃连接去掉(简称 Sub-pixel IRCNN)。为了充分说明跳跃结构对细节的传递作用,将上述网络结构第 2 层卷积的滑动步长设置为 4,利用上文提出的超参数和训练集进行了实验,不同网络结构对测试集的图像复原结果如图 4 所示。

从图中可以看到,没有添加跳跃结构网络的复原效果比较平坦,对图像的细节刻画不够明显,跳跃结构的引入确保了图像细节的有效传递,通过对复原结果进行定量分析,可知复原图像的熵平均提高 0.03,均方根对比度平均提高 0.05。



(a)无跳跃结构连接
(a) No skip connection



(b)有跳跃结构连接
(b) Have skip connection

图 4 跳跃结构对复原效果的影响

Fig. 4 Influence of skip connection on restoration effect

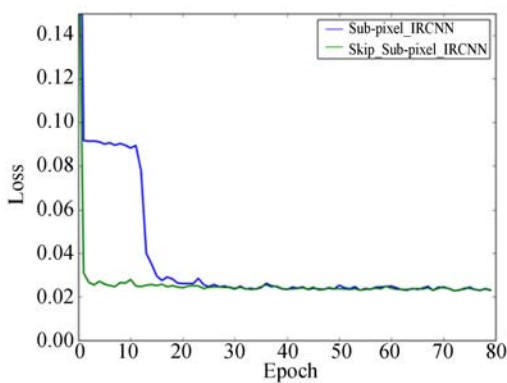


图 5 不同网络结构训练过程中的 loss 变化

Fig. 5 Change of loss in different network during training

图 5 为 Sub-pixel IRCNN 结构和 Skip Sub-pixel IRCNN 结构的训练 loss 随周期的变化曲线,可以明显地看到 Sub-pixel IRCNN 结构在前 16 周期内一直处于局部最优解,收敛速度较慢。


Skip Sub-pixel IRCNN 结构在第 3 个周期左右就达到了最优解,跳跃结构的引入加快了网络收敛速度,能够有效防止陷入局部最优解。

3.3.2 子像素卷积层作用评估

目前所有的图像复原任务中,关于特征图的上采样操作主要是传统的双线性插值或转置卷积两种方式。双线性插值作为一种传统的上采样方法,没有引入可以通过网络学习的滤波器,因此结果通常缺少细节信息;转置卷积虽然引入了可以学习的滤波器,但是在学习过程中需要补零操作,导致图像边缘存在失真;子像素卷积层作为一种新的上采样方式,通过利用维度信息来补偿图像空间分辨率损失,即通过在一般卷积层后面添加相位移层改变图像尺寸,能够克服补零操作带来的影响,同时减少了运算量。为了进一步说明本文提出子像素卷积的优势,分别对包含双线性插值层、转置卷积层和子像素卷积层的 3 种网络结构进行了实验,在实验中为了只观察不同上采样方式引起的差异,3 种网络结构都没有采用跳跃连接,包含子像素卷积层的网络采用 3.2.1 中设计的 Sub-pixel IRCNN 结构,包含双线性插值层和转置卷积层的网络分别将 Sub-pixel IRCNN 结构中的子像素卷积层替换为双线性插值层和转置卷积层。模型在测试集的复原结果如图 6 所示。表 1 给出了采用不同上采样操作复原结果的 PSNR 和 RMSC 指标,从中明显可以看到,包含子像素卷积层的网络结构,无论在对比度和去噪效果上都好于前两种方式。



(a)采用双线性插值复原效果
(a) Restoration effect with bilinear interpolation



(b)采用转置卷积复原效果

(b) Restoration effect with transpose convolution



(c)采用子像素卷积复原效果

(c) Restoration effect with bilinear interpolation sub-pixel convolution

图 6 包含不同上采样模式网络结构的训练效果

Fig. 6 Training effect of network structure with different upsampling modes

表 1 采用不同上采样操作复原结果的 RMSC 和 PSNR


Tab. 1 RMSC and PSNR of restored image with different upsampling operations

评价指标	双线性插值层	转置卷积层	子像素卷积层
RMSC	8.38	8.73	8.99
PSNR	18.27	19.85	21.86

3.3.3 不同网络层作用评估


为了验证设计的网络不同层的作用,将图 6 中的包含汽车的图像输入到训练好的 Skip Sub-pixel IRCNN 网络,并提取了不同层的输出特征图,由于每层至少包含 128 个特征图,本文仅选取了具有代表性的 4 幅特征图,如图 7 所示。图 7 (a)为第 1 卷积层的部分特征图,可以看到并行卷积提取了噪声特征、汽车轮廓特征以及树林特征

等,说明该层能够有效提取微光图像中不同尺度的特征。图 7(b)为第 2 卷积层的特征图,可以看到该层特征图包含了比较高级的特征信息,并且噪声得到了一定抑制,说明该层能够实现对对比度拉伸和噪声抑制等功能。图 7(c)为子像素卷积层的特征图,由于其主要用来对上层降采样的特




(a)第 1 层输出典型特征图

(a) Output typical feature maps of first layer




(b)第 2 层输出典型特征图

(b) Output typical feature maps of second layer



(c)第 3 层输出典型特征图

(c) Output typical feature maps of third layer



(d)第 4 层输出典型特征图

(d) The output typical feature maps of fourth layer

图 7 不同卷积层的输出特征图

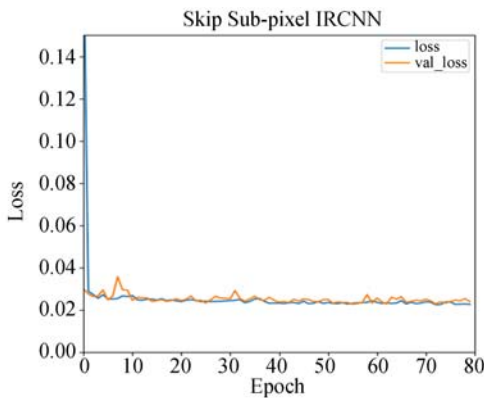
Fig. 7 Output feature maps of different convolution layer

特征图进行放大率为 2 的上采样,因此其特征图和第 2 卷积层特征图比较相近,但包含了更多的细节信息。图 7(d)为第四卷积层的特征图,可以看到几乎包含了整个图像的信息,并且噪声得到了进一步抑制,不同特征之间存在一定的亮度差异,说明该层可进一步抑制噪声和提高对比度。

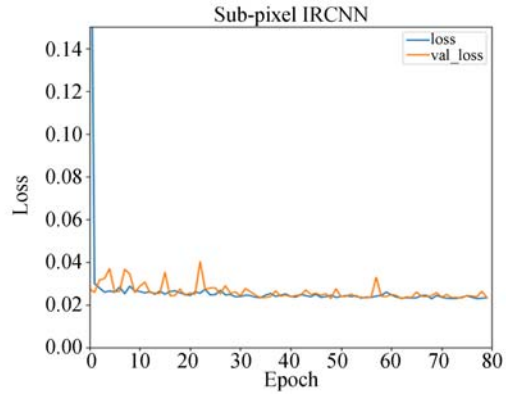
3.4 训练模型评估

本文利用 3.2 节设置的超参数对设计的 Skip Sub-pixel IRCNN 结构、Sub-pixel IRCNN 结构进行了训练,训练的收敛曲线如图 8 所示,可以看到,由于引入了 RELU 激活函数,网络都能够很快的收敛在 0.02 水平上,并且验证集误差和训练集误差几乎一致,没有发生过拟合。

然后对两种网络在测试集合上的复原效果与 BM3D 去噪方法^[15]、BM3D+HE 方法(即采用 BM3D 去噪后再进行直方图均衡化)进行了比较,



(a) Skip Sub-pixel IRCNN




(b) Sub-pixel IRCNN

图 8 不同网络结构的收敛曲线

Fig. 8 Convergence curve of different network structures

图 9 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、BM3D+HE 方法效果、Sub-pixel IRCNN 方法效果和 Skip Sub-pixel IRCNN 方法效果。

从图 9 可以基于卷积神经网络的模型能够有效提高图像的对比度和亮度。同 BM3D 方法相比,本文提出的方法不仅抑制了成像过程中光电




(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 9 各种场景下不同模型的处理结果

Fig. 9 Results of different models

转换引起的高斯噪声和泊松噪声等,也抑制了器件工艺缺陷引起的大颗粒离子噪声,同时也提高了图像对比度和亮度。同 BM3D+HE 方法相比,本文提出的方法能够有效地控制图像亮度和离子噪声影响,确保图像不至于过饱和,符合人眼视觉效果。并且 Skip Sub-pixel IRCNN 方法由于引入了跳跃连接和子像素卷积层,其测试效果优于 Sub-pixel IRCNN 结构。然后比较了不同模型的时间复杂度(所有模型的运行时间通过 nvidia gtx 860 GPU 上的 python 进行测试),如表 2 所示,可以看到本文提出的模型具有更快的处理速度,处理大小的图像的测试时间仅需要 0.95 s,相对于 BM3D 方法提高了 6 倍。

表 2 不同模型的时间复杂度

Tab. 2 Time complexity of different models

评价指标	BM3D	BM3D+HE	Sub-pixel IRCNN	Skip Sub-pixel IRCNN
测试时间/s	6	6	0.9	0.95

最后对不同处理结果的峰值信噪比、结构相似度和均方根对比度进行了计算,结果如表 3、表 4 和表 5 所示,可以看到 Skip Sub-pixel IRCNN 方法得到了比较好的峰值信噪比、结构相似度和均方根对比度,说明相对于其他去噪或去噪后再对比度增强算法,该方法的复原效果能够在去噪、对比度提高、亮度提升 3 个环节进行有效地权衡,得到符合人眼感受的图像。

表 3 不同模型的 PSNR

Tab. 3 PSNR for different models

场景	BM3D	BM3D+HE	Sub-pixel IRCNN	Skip Sub-pixel IRCNN
1	25.13	9.83	18.90	20.09
2	23.02	10.24	24.50	25.45
3	19.78	10.82	21.93	20.46
4	20.26	10.27	17.98	20.65

表 4 不同模型的 SSIM

Tab. 4 SSIM for different models

场景	BM3D	BM3D+HE	Sub-pixel IRCNN	Skip Sub-pixel IRCNN
1	0.719 9	0.357 2	0.771 0	0.780 8
2	0.75	0.39	0.84	0.85
3	0.729 0	0.433	0.806 3	0.768 9
4	0.726 6	0.354 9	0.764 4	0.776 4

表 5 不同模型的 RMSC

Tab. 5 RMSC for different models

模型	BM3D	BM3D+HE	Sub-pixel IRCNN	Skip Sub-pixel IRCNN
1	8.63	10.89	8.76	8.75
2	8.20	10.78	8.02	8.60
3	9.62	10.83	9.76	9.95
4	8.42	10.81	8.08	8.68

4 结 论

本文通过借鉴自编码网络、残差网络设计思想,提出了基于卷积神经网络的微光图像复原方法,同时建立了超低照度下微光图像复原训练集。实验结果表明,利用自建数据集训练的模型能够有效的进行超低照度下微光图像的复原,并与传统的去噪方法进行了比较,本文提出的方法在提

高 6 倍测试速度的条件下,PSNR 平均提高 1.67 dB,SSIM 的值平均提高 0.063,RMSE 的值平均

提高 0.19。下一步还需优化网络参数、增加训练样本数量,提高模型的鲁棒性和适应性。

参考文献:

- [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, 27(4): 652-654.
ZENG G L, SU B H, NIU L H, *et al.*. Neural network-based low-light-level image enhancement and reconstruction[J]. *Acta Armamentarii*, 2006, 27(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, 44(11): 3167-3176.
JIN W Q, TAO Y, SHI F, *et al.*. Progress of low level light video technology[J]. *Infrared and Laser Engineering*, 2015, 44(11):3167-3176. (in Chinese)
- [3] 鲁佳颖, 谷小婧, 顾幸生. 面向微光/红外融合彩色夜视的场景解析方法[J]. 红外与激光工程, 2017, 46(8): 0804002.
LU J Y, GU X J, GU X SH. Scene parsing method toward low-light-level/infrared color night vision [J]. *Infrared and Laser Engineering*, 2017, 46(8): 0804002. (in Chinese)
- [4] ROUDOT P, KERVRANN C, BOULANGER J, *et al.*. Noise modeling for intensified camera in fluorescence imaging: Application to image denoising [C]. *Proceedings of 2013 IEEE 10th International Symposium on Biomedical Imaging (ISBI)*, IEEE, 2013:600-603.
- [5] QUAN J. *Image denoising of Gaussian and Poisson noise based on wavelet thresholding*[D]. Cincinnati: University of Cincinnati, 2013.
- [6] VINCENT P, LAROCHELLE H, BENGIO Y, *et al.*. Extracting and composing robust features with denoising autoencoders [C]. *Proceedings of the 25th International Conference on Machine Learning*, ACM, 2008: 1096-1103.
- [7] XIE J Y, XU L L, CHEN E H. Image denoising and inpainting with deep neural networks[C]. *Proceedings of the 25th International Conference on Neural Information Processing Systems*, ACM, 2012: 341-349.
- [8] BURGER H C, SCHULER C J, HARMELING S. Image denoising: Can plain neural networks compete with BM3D? [C]. *Proceedings of 2012 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, 2012: 2392-2399.
- [9] AGOSTINELLI F, ANDERSON M R, LEE H. Adaptive multi-column deep neural networks with application to robust image denoising[C]. *Advances in Neural Information Processing Systems*, NIPS, 2013: 1493-1501.
- [10] WU Y W, ZHAO H H, ZHANG L Q. Image denoising with rectified linear units[C]. *Proceedings of the 21st International Conference on Neural Information Processing*, Springer, 2014: 142-149.
- [11] LORE K G, AKINTAYO A, SARKAR S. LL-Net: A deep autoencoder approach to natural low-light image enhancement[J]. *Pattern Recognition*, 2017, 61: 650-662.
- [12] DONG CH, DENG Y B, LOY C C, *et al.*. Compression artifacts reduction by a deep convolutional network[C]. *Proceedings of 2015 IEEE International Conference on Computer Vision (ICCV)*, IEEE, 2015: 576-584.
- [13] MAO X J, SHEN CH H, YANG Y B. Image restoration using very deep convolutional encoder-decoder networks with symmetric skip connections [C]. *Advances in Neural Information Processing Systems*, NIPS, 2016.
- [14] 肖龙, 徐超, 刘广荣. 应用于可穿戴微光成像系统的嵌入式平台设计[J]. 红外与激光工程, 2016, 45(1): 0118006.
XIAO L, XU CH, LIU G R. Design of embedded platform applied in wearable low-light level ima-

ging system[J]. *Infrared and Laser Engineering*, 2016, 45(1): 0118006. (in Chinese)

[15] 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.

作者简介:



刘超(1989—),男,陕西周至人,博士研究生,2012年于西安理工大学获得学士学位,2014年于海军工程大学获得硕士学位,主要从事机器视觉及彩色夜视方面的研究。E-mail:generaladol-ph@163.com

导师简介:



张晓晖(1965—),女,湖北武汉人,博士,教授,博士生导师,1984年于华中工学院获得学士学位,1989年于海军工程大学获得硕士学位,2001年于华中理工大学获得博士学位,主要从事激光探测技术、光电成像、机器视觉方面的研究工作。E-mail: 1547300454@qq.com