

基于图像边缘判别机制的盲图像去模糊方法

祁清^{1,2*}, 郭继昌², 陈善继¹

¹青海民族大学物理与电子信息工程学院, 青海 西宁 810007;

²天津大学电气自动化与信息工程学院, 天津 300072

摘要 图像拍摄过程中会不可避免地产生由相机抖动或物体运动引发的图像模糊问题。针对该问题,提出了一种基于图像边缘判别机制的盲图像去模糊方法,以恢复图像并使之具有清晰的边缘。首先,提出一个 PNet 子网,将模糊图像作为输入并利用数据驱动的方式进行判别学习,直到网络收敛。将模糊图像再次输入到训练收敛的 PNet 子网的生成器中,可得到去模糊图像,并将此图像记作边缘弱化图像。其次,提出一个 DNet 子网,将模糊图像和边缘弱化图像输入到 DNet 子网中进行训练,得到的训练收敛的 DNet 生成器即为图像去模糊模型。此外,提出边缘重建函数和图像语义内容损失函数用于约束图像的边缘和语义信息。最后,提出图像边缘判别的目标损失函数,使得 DNet 子网的判别器在完成生成图像与标签图像真假判别的同时,还完成对边缘弱化图像和标签图像的进一步判别,因此图像边缘信息的判别学习得到了强化。实验结果表明,所提方法能够有效地恢复大幅度模糊图像和运动引起的模糊图像,这证明了边缘判别机制对图像边缘恢复的重要作用。

关键词 图像处理; 图像去模糊; 生成对抗网络; 深度神经网络; 深度学习

中图分类号 TP751.1

文献标志码 A

doi: 10.3788/LOP57.241022

Blind Image Deblurring Based on Image Edge Determination Mechanism

Qi Qing^{1,2*}, Guo Jichang², Chen Shanji¹

¹School of Physics and Electronic Information Engineering, Qinghai Nationalities University, Xining, Qinghai 810007, China;

²School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China

Abstract In the process of image acquisition, the image blurring problem is always inevitably caused by camera shaking or object movement. In order to solve this problem, a blind image deblurring method based on image edge determination mechanism is proposed to restore images with sharp edges. First, a PNet subnet is proposed to set blurry images as inputs, and determination learning is carried out by using a data driven method until the network is converged. The blurring image is input again to the generator of training converge in the PNet subnet, which can obtain deblurring images and the deblurring images are noted as edge-weakened images. Second, a DNet subnet is proposed, both blurry images and edge-weakened images are served as inputs for training, and the DNet generator of training convergence is image deblurring model. In addition, the edge reconstruction function and image semantic content loss function are proposed to constrain the image edge and semantic information. Finally, an object loss function for image edge determination is proposed to make the DNet subnet generator complete the true-false determination of generated images and labeled images and finish the further determination of edge-weakened images and labeled images. Therefore, the determination learning of image edge information is enhanced. Experimental results show that the proposed method can restore large-scale blurring images and blurring images caused by movement, which proves the important role of edge determination mechanism in the image edge restoring.

Key words image processing; image deblurring; generative adversarial network; deep neural network; deep learning

OCIS codes 100.1455; 100.3190; 100.2000

收稿日期: 2020-06-01; 修回日期: 2020-06-17; 录用日期: 2020-06-28

基金项目: 青海民族大学新一代无线通信关键技术研究及原型开发科研创新团队

*E-mail: qiqing@tju.edu.cn

1 引言

图像一直是人类获取客观世界信息的主要来源。然而,图像拍摄过程中会不可避免地产生由相机抖动或物体运动引起的图像模糊问题。模糊的图像失去了清晰的边缘和丰富的纹理信息,这使得人们很难从中获取清晰的内容和确切的信息。盲图像去模糊是在模糊核未知的情况下,仅从已有的模糊退化图像中估计出潜在的清晰图像的一种方法。

由于图像去模糊具有高度不适定的性质,因此需要额外的先验信息正则图像恢复的过程。近年来图像去模糊方法可以概括为以下两类:基于图像先验的传统的图像去模糊方法和基于深度学习的图像去模糊方法。基于图像先验的传统的图像去模糊方法^[1-5]主要从图像中手动提取先验或统计信息,并以此作为正则项建立图像去模糊优化方程。然后,通过迭代估计模糊核并采用非盲去卷积算法得到恢复后的图像。由于传统去模糊方法仅在有限的图像上提取先验信息,因此这类方法只在特定模糊图像上具有较好的去模糊效果,而对于其他的模糊图像,算法鲁棒性较差。此外,迭代求解优化方程需要耗费大量的时间,因而这类方法并不能很好地满足算法的实时性要求。目前,深度学习在计算机视觉领域被广泛应用,并获得令人信服的结果^[6-10]。Gong等^[11-12]提出的方法首先利用卷积神经网络(CNN)估计模糊核,然后利用非盲解卷积方法获取去模糊图像。虽然这两种方法在一定程度上将传统方法和卷积神经网络的优势进行了结合,但是模糊核估计带来的偏差会为后续的非盲解卷积操作带来错误的引导,这导致恢复的图像产生伪影。Nah等^[13]构建了一个120层的多尺度卷积神经网络,并以扩大网络感受野的方式解决了图像去模糊问题。然而,巨大的参数会引起网络难以收敛的问题。此外,生成对抗网络(GAN)^[14]自被提出以来,就被应用于图像处理领域。Kupyn等^[15]提出了基于GAN的图像去模糊算法,利用条件生成对抗网络和感知损失函数实现了图像的恢复。Kupyn等^[16]提出了以特征金字塔为核心模块的网络,并根据算法实时性和性能需求分别搭建了不同的网络。Madam等^[17]提出了一种基于GAN的面向特定类型图像的去模糊算法。为了缓解同时训练两个GAN的困难,Madam提出一个基于非监督GAN和卷积神经网络的图像去模糊算法,然而这类方法并不能很好地恢复图像的细节信息。虽然基于GAN的图像去模

糊算法得到了一定的发展,但这类方法更强调生成器(G)网络的设计,而忽略了对判别器(D)的研究。

根据现有的图像去模糊方法存在的问题,本文引入了一种基于图像边缘判别机制的图像去模糊算法。提出一个图像预处理子网PNet,将模糊图像输送到网络中并以端对端的方式进行训练,直到网络收敛。将训练使用的模糊图像再次输送到训练收敛的PNet子网生成器中,即可得到去模糊图像并将其记作边缘弱化图像。提出一个图像去模糊子网DNet,将模糊图像和边缘弱化图像传入到DNet子网中进行训练,最终得到的训练收敛的DNet生成器就是图像去模糊模型。实验结果表明,所提方法能够有效地恢复相机抖动和物体运动引起的模糊,这证明了边缘判别机制对图像边缘恢复的重要作用。

2 本文方法

2.1 图像边缘判别机制

通常,图像边缘是否清晰是人们评判图像质量的标准之一。在传统图像去模糊方法中,图像边缘作为一种先验信息被直接或间接地作为正则项以限制图像的恢复。在基于GAN的图像去模糊算法中,以往的方法更侧重于对生成器结构和目标损失函数对的设计,而判别器只用于表征输出图像接近于真实图像(清晰图像)的程度。通过实验观察发现,显著的边缘是清晰图像的一个重要特征,但这些边缘在整个图像中的占比通常很小。因此,在标准判别目标损失函数的约束下,不具备显著边缘的生成图像很可能会干扰判别器,使其进行错误的判断。为了解决先前图像去模糊方法的弊端,本文提出了基于图像边缘的判别学习机制。具体来说,为了更好地揭示图像去模糊问题的时变性,首先提出一个边缘弱化图像生成网络PNet,将模糊图像 $P_{data}(b) = \{b_i | i = 1, \dots, M\} \subset B$ (其中 b 为模糊图像, b_i 为第 i 个模糊图像, B 表示模糊图像域, M 为训练集中模糊图像的个数)作为输入并利用端对端的方式进行训练,直到收敛;将训练使用的模糊图像输入到训练收敛的PNet子网中,即可得到边缘弱化图像 $P_{data}(e) = \{e_i | i = 1, \dots, N\} \subset E$, e_i 为第 i 个边缘弱化图像, E 为边缘弱化的图像域, N 为与标签图像对应的边缘弱化图像的个数。如图1所示,由数据驱动方式训练得到的边缘弱化图像能够揭示图像模糊问题的本质,图中由锯齿的线条构成的矩形代表模糊图像中的清晰区域,由实线构成的矩形代表模糊图像中的模糊区域。其次,提出一个图像去模

糊网络 DNet, 将模糊图像和边缘弱化图像输入到 DNet 子网中进行训练。在 DNet 的训练过程中, 引入边缘弱化图像能够增强判别器对图像边缘判别学习的灵敏度。因此, 判别器不仅要生成图像与清

晰图像进行判别, 还需要将标签图像与对应的边缘弱化图像进行二次判别。最终得到的训练收敛的 DNet 生成器就是图像去模糊模型。所提出的网络结构如图 2 所示。




图 1 模糊图像、清晰图像以及边缘弱化图像。(a)模糊图像;(b)清晰图像;(c)由 PNet 学习得到的边缘弱化图像

Fig. 1 Blurry image, clean image, and edge-weakened image. (a) Blurry image; (b) clean image; (c) edge-weakened image learned by PNet

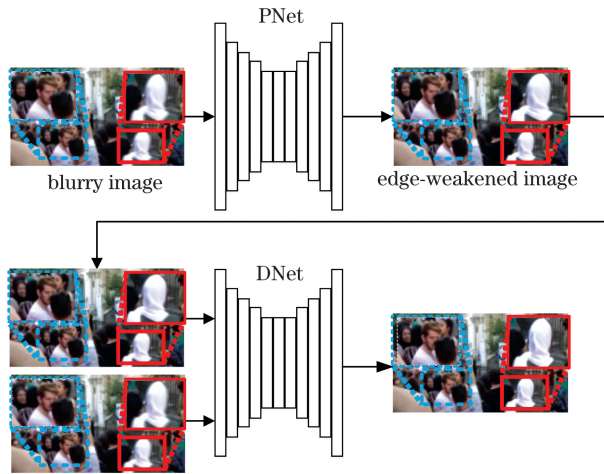


图 2 所提出的网络结构

Fig. 2 Structure of proposed network

2.2 生成对抗网络结构

1) PNet 子网

生成器。PNet 子网借鉴 UNet^[18] 网络的结构, 结构图如图 3 所示, 图中 k 为模糊核, n 为特征通道数, s 为步长, Conv 为卷积, Ins. Norm 为 Instance Normalization。PNet 子网的输入是模糊图像, 网络包括编码器和解码器两个部分, 编码器的主要作用是对模糊图像进行空间压缩和编码, 解码器的主要作用是构建图像内容和域的特征。此外, 在对应尺度的上采样层和下采样层之间建立跳变连接, 将编

码器中学习的低维度特征与解码后的特征进行关联, 以指引图像局部和细节的恢复, 这对于图像结构和细节的学习十分关键。编码器部分包括一个卷积层, 其将特征的维度映射到 64×64 ; 3 个下采样层用于下采样并编码图像, 每一个下采样层后面分别添加如图 4 所示的 3 个稠密残差块, 此时图像分辨率由 $256 \text{ pixel} \times 256 \text{ pixel}$ 递减至 $64 \text{ pixel} \times 64 \text{ pixel}$ 。对应地, 解码器包括 3 个上采样层, 用于上采样并解码图像, 每一个上采样层前面分别添加 3 个如图 4 所示的稠密残差块, 此时图像分辨率由 $64 \text{ pixel} \times 64 \text{ pixel}$ 递增至 $256 \text{ pixel} \times 256 \text{ pixel}$ 。最终, 利用一个卷积核是 7×7 的卷积层和一个 Tanh 激活函数, 即可得到生成图像。PNet 子网经训练收敛后, 将训练使用的模糊图像再次传送到收敛的 PNet 的生成器中, 即可得到去模糊后的图像, 并记作 e'_i 。与模糊图像相比, 去模糊图像 e'_i 得到了恢复; 但与标签图像相比, 图像的边缘信息并不足够显著。因此, 本文将 e_i 记作边缘弱化图像, 其目的是在网络判别学习中提升判别器对图像边缘信息学习的灵敏度。

判别器。为了对标签图像与边缘弱化图像进行判别, 这里采用如图 5 所示的 PatchGAN^[19] 作为判别器的网络结构。该判别器包括一个卷积层和三个下采样卷积层, 其目的是降低输入图像的分辨率和编码重要的局部特征用于特征分类。经过三个下采

样卷积层的特征维度由 $256 \text{ pixel} \times 256 \text{ pixel}$ 递减至 $32 \text{ pixel} \times 32 \text{ pixel}$ 。最终,采用一个被 Sigmoid 函数激活的卷积层得到分类响应。每个卷积层后面都添加了 Instance Normalization(样本标准化)层^[20]

和 Leaky ReLU 激活函数^[21],并且所有卷积层的卷积核大小为 4×4 。在网络训练阶段,生成网络和判别网路之间不断竞争学习,直至网络达到收敛。




图 3 用于图像去模糊的 DNet 子网生成器结构图

Fig. 3 Diagram of DNet subnet generator for image deblurring




图 4 稠密残差块

Fig. 4 Dense residual block




图 5 用于图像去模糊的 PNet 子网判别器(PatchGAN)结构图

Fig. 5 Diagram of PNet subnet discriminator (PatchGAN) for image deblurring

2)DNet 子网

生成器。DNet 子网生成器的结构如图 3 所示,具体细节不再赘述。DNet 子网生成器的作用是完成图像的二次去模糊任务,需要说明的是输入 DNet 子网的图像包括模糊图像和边缘弱化图像。

判别器。DNet 子网采用如图 5 所示的 PatchGAN 作为 DNet 网络判别器的结构, $P_{\text{data}}(s)$ 为标签图像样本分布, $P_{\text{data}}(e)$ 为边缘弱化图像分布, $G(b)$ 为生成的图。需要说明的是,DNet 子网

的判别器不仅需要对生成图像和标签图像进行判别,还需要对标签图像和边缘弱化图像进行判别。因此,DNet 的判别器能够对图像的边缘信息进行判别学习,从而驱使 DNet 的生成器生成边缘显著的去模糊图像。

2.3 目标损失函数

2.3.1 PNet 子网的目标损失函数

为了优化 PNet 子网的训练,分别添加图像语义内容的目标损失函数 L_{content} 以及判别目标损失函数 L_{adv}

对 G 与 D 加以约束。PNet 子网的目标损失函数为

$$L = \beta L_{\text{content}} + \alpha L_{\text{adv}}, \quad (1)$$

式中: β 和 α 分别是 L_{content} 和 L_{adv} 的权重系数。根据实验过程经验地确定 L_{adv} 的权重系数 $\alpha = 1$; 依据文献[15], L_{content} 的权重系数设置为 $\beta = 10$ 。下面对各约束项进行详细介绍。

$$L_{\text{content}} [s, G_{\theta G}(b)] = \frac{1}{WH} \sum_{x=1}^W \sum_{y=1}^H \|\varphi_{i,j}(s)_{x,y} - \varphi_{i,j}[G_{\theta G}(b)]_{x,y}\|_2, \quad (2)$$

式中: $G_{\theta G}(b)$ 为生成图像; θ 为生成网络的参数; x 为图像的水平坐标; y 为图像的垂直坐标; W 和 H 分别为输入图像的宽度和高度; $\varphi_{i,j}(s)_{x,y}$ 为清晰图像的语义特征, i 表示第 i 个池化层, j 表示第 j 个卷积层; $\varphi_{i,j}[G_{\theta G}(b)]_{x,y}$ 为生成图像的语义特征。本文采用预训练好的 VGG19 模型^[22] 的“Conv3-3”层中的特征图来计算语义内容的目标

1) 图像语义内容的目标损失函数

图像去模糊的目的在于标签图像和去模糊图像保持相同的语义内容, 因此引入图像语义内容的目标损失函数 L_{content} , 以约束去模糊图像和标签图像的高维特征相似性, 从而使图像更符合人眼视觉特性。图像语义内容的目标损失函数的数学表达式为

损失函数。

2) 判别目标损失函数

PNet 子网判别器需要完成对生成图像 $G_{\theta G}(b)$ 和真实图像 s_i 真假的判别。由于 GAN 在训练时存在难以收敛的问题, 因此采用 WGAN-GP^[23] 架构作为本文判别器的优化器。PNet 子网的判别目标损失函数表示为

$$L_{\text{adv}} = E_{s_i \sim P_{\text{data}}(s)} [D(s_i)] - E_{b_i \sim P_{\text{data}}(b)} \{D[G(b_i)]\} - \lambda E_{\hat{x} \sim P_{\hat{x}}} \{[\|\nabla_{\hat{x}} D(\hat{x})\|_2 - 1]^2\}, \quad (3)$$

式中: $E_{s_i \sim P_{\text{data}}(s)} [D(s_i)]$ 为判别器 D 判别真实图像 s_i 为真的期望值; $E_{b_i \sim P_{\text{data}}(b)} \{D[G(b_i)]\}$ 为判别器 D 判别生成图像 $G(b_i)$ 为假的期望值; $\lambda E_{\hat{x} \sim P_{\hat{x}}} \{[\|\nabla_{\hat{x}} D(\hat{x})\|_2 - 1]^2\}$ 为梯度惩罚项, λ 为系数项, \hat{x} 为在真实图像 s_i 和生成数据 $G(b_i)$ 之间随机取值的连线上进行均匀采样得到的样本; $P_{\hat{x}}$ 为均匀采样得到的样本分布; $\nabla_{\hat{x}}$ 为均匀采样得到的样本的梯度。

2.3.2 DNet 子网的目标损失函数

在图像恢复过程中, 为了进一步提升 G 与 D 对图像边缘学习的灵敏度, 添加图像语义内容的目标损失函数 L_{content} 、图像边缘重建目标损失函数 L_{edge} 以及图像边缘判别目标损失函数 L_{adv} 对 G 与 D 加以约束, 使得重构得到的生成图像具有清晰的边缘。DNet 子网的目标损失函数为

$$L = \beta L_{\text{content}} + \lambda L_{\text{edge}} + \alpha L_{\text{adv}}. \quad (4)$$

依据实验过程经验地确定 L_{edge} 和 L_{adv} 的权重系数为 $\lambda = 12$ 和 $\alpha = 1$; 依据文献[15], L_{content} 的权重系数设置为 $\beta = 10$ 。下面对各约束项进行详细介绍。

1) 图像语义内容的目标损失函数

DNet 子网采用约束 PNet 生成器的图像语义内容的目标损失函数, 对标签图像和生成图像的语义信息的一致性进行约束, 具体公式不再赘述。

2) 图像边缘重建的目标损失函数

边缘是衡量图像是否清晰的定性指标之一, 在 G 中添加图像边缘重建的目标损失函数 L_{edge} , 以对图像的边缘重建加以约束。在设计 L_{edge} 时, 选择 Canny 边缘检测算子^[24] 提取生成图像的边缘和标签图像的边缘, 并通过求解一范数 L_1 对生成图像和清晰图像在边缘一致性上的差距 $L_{\text{content}} [s, G_{\theta G}(b)]$ 加以约束, 即

$$L_{\text{content}} [s, G_{\theta G}(b)] = \frac{1}{WH} \sum_{x=1}^W \sum_{y=1}^H \|C_{\text{canny}}(s)_{x,y} - C_{\text{canny}}[G_{\theta G}(b)]_{x,y}\|_1, \quad (5)$$

式中: $C_{\text{canny}}[G_{\theta G}(b)]_{x,y}$ 表示生成图像的边缘信息; $C_{\text{canny}}(s)_{x,y}$ 表示清晰图像的边缘信息。

3) 图像边缘判别目标损失函数

与以往采用标准判别目标损失函数对生成图像

进行判别的判别器不同, 本文设计的判别器需要完成两次判别任务, 即完成对生成图像 $G_{\theta G}(b)$ 和真实图像 s_i 的判别与对边缘弱化图像 e_i 和真实图像 s_i 的判别。由于 GAN 在训练时存在难以收敛的问题,

因此采用 WGAN-GP 架构作为本文的判别器的优化器。图像边缘判别目标损失函数的数学表达式为

$$L_{\text{adv}}(G, D) = E_{s_i \sim P_{\text{data}}(s)} [D(s_i)] - E_{b_i \sim P_{\text{data}}(b)} \{D[G(b_i)]\} + \lambda E_{\hat{x}_1 \sim P_{\hat{x}_1}} \{[\|\nabla_{\hat{x}_1} D(\hat{x}_1)\|_2 - 1]^2\} - E_{e_i \sim P_{\text{data}}(e)} [D(e_i)] + \lambda E_{\hat{x}_2 \sim P_{\hat{x}_2}} \{[\|\nabla_{\hat{x}_2} D(\hat{x}_2)\|_2 - 1]^2\}, \quad (6)$$

式中: $E_{e_i \sim P_{\text{data}}(e)} [D(e_i)]$ 为判别器 D 判别边缘弱化图像 e_i 为假的期望值; $\lambda E_{\hat{x}_1 \sim P_{\hat{x}_1}} \{[\|\nabla_{\hat{x}_1} D(\hat{x}_1)\|_2 - 1]^2\}$ 为梯度惩罚项; \hat{x}_1 表示在真实图像 s_i 和生成数据 $G(b_i)$ 之间随机取值的连线上进行均匀采样得到的样本; $P_{\hat{x}_1}$ 为 \hat{x}_1 的数据分布; \hat{x}_2 表示在真实图像 s_i 和边缘弱化图像 e_i 之间随机取值的连线上进行均匀采样得到的样本; $P_{\hat{x}_2}$ 为 \hat{x}_2 的数据分布。

3 分析与讨论

3.1 数据准备及参数设置

3.1.1 数据准备

基于 GOPRO 数据集^[13] 的图像模糊过程模拟了真实的相机成像过程,这与以往的通过假设特定模糊核并合成得到模糊图像的方法有着本质上的区别,因而 GOPRO 数据集被广泛用于图像去模糊方法的评价。GOPRO 数据集包括 3214 对清晰和模糊的图像,将其分为互不重叠的训练集(2103 对图像)和测试集(1111 对图像)。将 GOPRO 训练集作为输入,并采用如图 3 和图 5 所示的网络结构对 PNet 进行训练,直到网络收敛。将 GOPRO 训练集再次输入到训练收敛的 PNet 子网的生成器中,即可得到边缘弱化图像 $e_i \in P_{\text{data}}(e)$; 其次,将 GOPRO 训练集和边缘弱化图像 $e_i \in P_{\text{data}}(e)$ 作为输入,并采用如图 3 和图 5 所示的网络结构对 DNet 进行训练,直到网络收敛。最终得到的训练收敛的 DNet 生成器就是图像去模糊模型。本文

采用 GOPRO 测试集、Köhler 数据集^[25] 以及 Lai 等^[26] 提出的真实模糊图像数据集作为本文方法的测试集。

3.1.2 参数设置

本文提出的网络模型是在实验环境为 Ubuntu14.04 操作系统中以 Python 编程语言为接口的 Pytorch 深度学习框架上搭建的。本文提出的网络模型在包含 1 块 Intel(R) Core(TM) i7 CPU (16 GB RAM) 3.60 GHz 的 CPU 和 1 块 NVIDIA GeForce GTX 1080Ti GPU 的台式计算机上运行。其中 batch size(批量训练图像的个数)是 1, G 和 D 的学习率是 0.0001, 训练的总迭代次数为 150。网络使用的优化器是 Adam optimizer^[27], 其动量和权重衰减参数分别是 $\beta_1 = 0.5$ 和 $\beta_2 = 0.999$ 。

3.2 实验与分析

本文对 GOPRO 测试集中的模糊图像进行了去模糊处理,对恢复结果采用了定性评价和定量评价。其中,定量评价指标包括图像峰值信噪比(PSNR)和图像结构相似度(SSIM)^[28]。

3.2.1 合成模糊图像在数据集上的比较实验

将本文提出的方法与文献[11]、文献[13]、文献[15]、文献[16]中的方法在 GOPRO 和 Köhler 数据集上进行了比较,并利用定量评估指标 PSNR 和 SSIM 进行评价。表 1 列出了本文方法和上述对比方法在 GOPRO 数据集和 Köhler 数据集上测试得到的 PSNR 和 SSIM 的平均值,本文的方法在 PSNR 与 SSIM 上均获得了较大的提升。

表 1 本文方法和对比方法在 GOPRO 和 Köhler 数据集上的定量评价结果

Table 1 Quantitative evaluation results of proposed method and compared methods on GOPRO and Köhler datasets

Method	GOPRO		Köhler	
	PSNR	SSIM	PSNR	SSIM
Method in Ref. [11]	27.2778	0.8187	21.2371	0.6490
Method in Ref. [13]	28.3225	0.8588	21.2335	0.6525
Method in Ref. [15]	25.2363	0.7773	20.8507	0.6340
Method in Ref. [16]	27.8086	0.8564	19.0843	0.5838
Ours	29.2278	0.8779	21.2987	0.6544

图 6 和图 7 分别给出了几个在 GOPRO 测试数据集和 Köhler 数据集上的去模糊结果。由图 6(f) 可知,本文提出的模型能够解决由相机运动和物体运动引起的模糊问题。由于文献[11]的方法试图采用 CNNs 来估计模糊核,然而模糊核估计带来的偏差却对图像的非盲解卷积带来影响,从而产生了如图 6(b)所示的去模糊图像。即使 Nah 等^[13]提出了一个 120 层的基于 CNN 的多尺度图像去模糊方法,但是如图 6(c)所示,此方法仍然无法应对极度

模糊的情况。Kupyn 等^[15]构建了一个基于残差块的生成对抗网络,并采用语义目标损失函数对网络进行优化训练。然而,该网络仅对图像的语义信息进行约束不能很好地恢复图像的边缘信息。作为生成对抗网络的进阶版,DeblurGAN-v2 具有一定的去模糊性能,但由图 6(e)可知,基于 DeblurGAN-v2 得到的图像中具有显著结构的区域仍然存在模糊。本文提出的基于边缘判别机制的生成对抗网络方法具有良好的去模糊性能和良好的视觉效果。

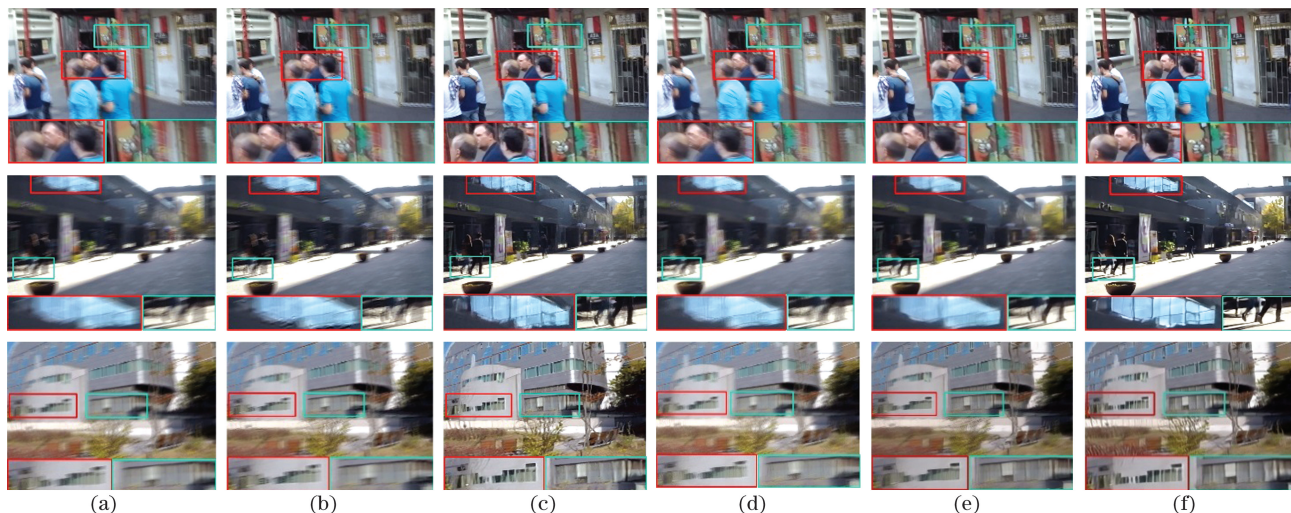


图 6 对比算法在 GOPRO 测试集上的去模糊结果。(a)模糊图像;(b)文献[11]方法;(c)文献[13]方法;(d)文献[15]方法;(e)文献[16]方法;(f)本文方法

Fig. 6 Results of image deblurring of compared methods on test dataset of GOPRO. (a) Blurry images; (b) method in Ref. [11]; (c) method in Ref. [13]; (d) method in Ref. [15]; (e) method in Ref. [16]; (f) ours




图 7 对比算法在 Köhler 数据集上的去模糊结果。(a)模糊图像;(b)文献[11]方法;(c)文献[13]方法;(d)文献[15]方法;(e)文献[16]方法;(f)本文方法

Fig. 7 Results of image deblurring of compared methods on dataset of Köhler. (a) Blurry images; (b) method in Ref. [11]; (c) method in Ref. [13]; (d) method in Ref. [15]; (e) method in Ref. [16]; (f) ours

3.2.2 真实模糊图像数据集上的比较实验

为进一步验证本文方法的有效性,将本文提出的方法与文献[11]、文献[13]、文献[15]、文献[16]中的方法在Lai等提出的真实数据集上进行了比较。图8给出了几个在真实数据集上的去模糊结果。与在合成模糊图像上处理得到的结果一致,如图8(b)所示,文献[11]中的方法并不具有良好的图像去模糊性能,尽管该文献中提出了两阶段(估计模糊核与非盲去卷积)的图像去模糊方

法。如图8(e)所示,文献[16]中方法的结果在视觉效果上有所改善,但在图像结构区域仍存在模糊。与文献[11]、文献[15]和文献[16]中的方法相比,文献[13]中的方法恢复的图像具有显著的边缘,然而该方法在人脸图像的恢复方面存在结构变形的现象。如图8(f)所示,由于本文引入了边缘判别机制,网络在训练的过程中更加关注图像边缘的学习,因而恢复后的图像具有清晰显著的边缘。

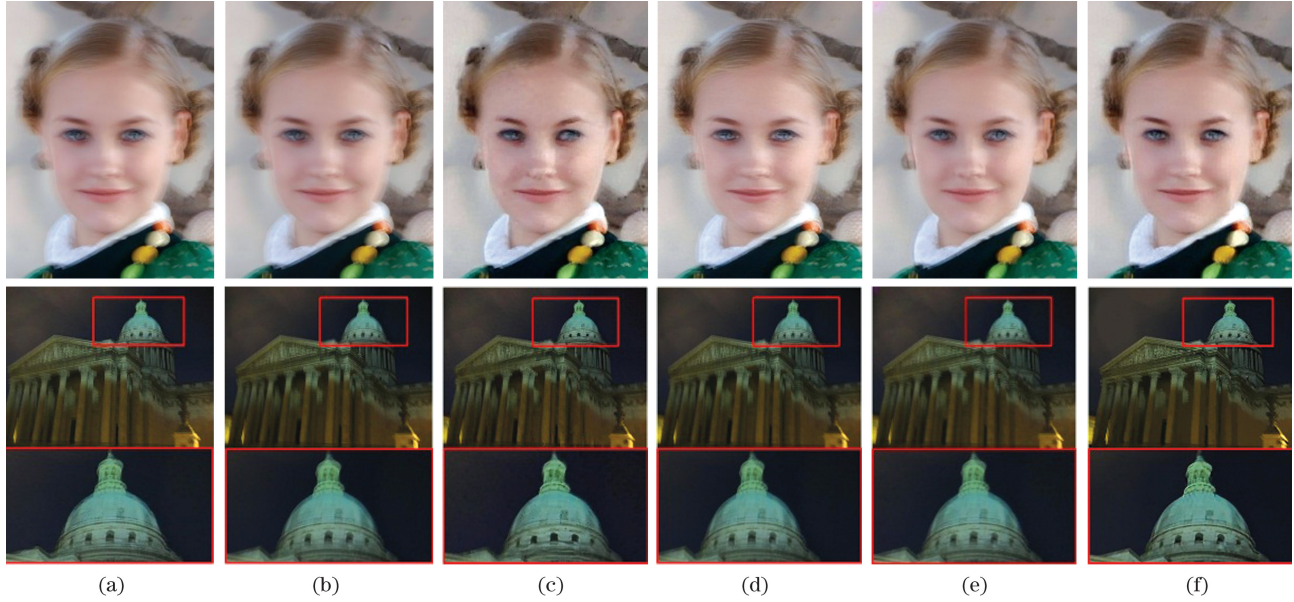


图8 对比算法对真实模糊图像的去模糊效果对比。(a)模糊图像;(b)文献[11]方法;(c)文献[13]方法;(d)文献[15]方法;(e)文献[16]方法;(f)本文方法

Fig. 8 Results of deblurring of compared methods for real blurred images. (a) Blurry images;(b) method in Ref. [11]; (c) method in Ref. [13];(d) method in Ref. [15];(e) method in Ref. [16];(f) ours

3.2.3 网络结构的分析实验

为进一步验证本文提出的网络结构的有效性,增加了网络结构的消融实验,包括以下两个实验:1)本文提出的网络结构除去PNet(w/o PNet);2)本文方法(包含PNet)。

本文采用相同的实验配置和参数设置完成上述两个实验,并进一步在GOPRO数据集上进行定量评价。表2给出了定量评价结果。由此可以推断出:当移除PNet子网时,去模糊图像的定量指标以及视觉效果的质量均有所下降。与之相比,本文方法得到的去模糊图像具有显著的边缘和良好的视觉效果,这证明了所提图像边缘判别机制的必要性和有效性。

表2 不同子网在GOPRO测试集上的定量评价结果

Table 2 Quantitative evaluation results on dataset of GOPRO with different subnetworks

Method	PSNR	SSIM
w/o PNet	28.8856	0.8687
Ours	29.2278	0.8779

3.2.4 目标损失函数的分析实验

为进一步验证本文提出的目标损失函数的有效性,增加了目标损失函数的消融实验,包括以下4个实验:1)本文提出的方法除去图像语义内容的目标损失函数 L_{content} (w/o content);2)本文方法除去图像边缘重建的目标损失函数 L_{edge} (w/o edge);3)本

文提出的方法除去图像边缘判别的目标损失函数 L_{adv} (w/o adv); 4) 本文方法。

本文采用相同的实验配置和参数设置完成上述



图9 不同子网在 GOPRO 测试集上的视觉效果。(a)模糊输入;(b) w/o content、(c) w/o edge、(d) w/o adv、(e) w/o PNet 和(f)本文方法的结果

Fig. 9 Visual results of subnetworks on GOPRO test set. (a) Blurry input; results of (b) w/o content, (c) w/o edge, (d) w/o adv, (e) w/o PNet, and (f) proposed method

1) 当移除 $L_{content}$ 时, 图像的定量指标急剧下降, 这说明 $L_{content}$ 能显著影响图像去模糊性能。

2) 当移除 L_{edge} 时, 定量指标锐减。如图 9(c) 所示, 去模糊后得到的图像无法恢复显著的边缘信息。实验表明, 本文提出的 L_{edge} 能够有效地恢复图像的边缘信息。

3) 当移除 L_{adv} 时, 定量指标和图像去模糊视觉效果图的质量均有所下降。

综上所述, 定量和定性评价结果都证明了本文提出的目标损失函数的有效性。

表3 不同的损失函数在 GOPRO 测试集上的定量评价结果

Table 3 Quantitative evaluation results on dataset of GOPRO for different loss functions

Method	PSNR	SSIM
w/o content	26.5778	0.8034
w/o edge	28.4260	0.8418
w/o adv	28.5863	0.8513
Ours	29.2278	0.8779

3.2.5 算法实时性的对比实验

为了证明本文方法的实时性, 增加算法复杂度和测试时间的对比实验。本文采用相同的实验设备(详见 3.1.1 节)在 GOPRO 数据集上完成测试时间的比较, 定量评价结果如表 4 所示。其中, FLOPs 表示算法的复杂度。虽然文献[11]中方法利用 CNN 估计模糊核, 但是他们采用非盲去卷积算法计算潜在图像, 因此需要耗费大量的时间, 不能很好地满足算法实时性的要求。文献[13]中方法受到“由粗糙到精细”的图像去模糊策略的启发, 提出了一个多尺度的 CNN 来解决图像去模糊问题。相比文献[11]中方法, 文献[13]中方法的测试时间要少得

4 个实验, 并进一步在 GOPRO 数据集上进行定量评价。表 3 和图 9 分别给出了定量评价结果和视觉结果。由此可以推断出:

多。由于网络多个尺度之间的参数是相互独立的, 因此文献[13]中方法具有较高的算法复杂度。文献[15]和文献[16]中分别提出一个包含残差块的 CNN 和一个特征金字塔网络用于图像恢复。本文方法提出的模型包含两个子网络, 与文献[15]中方法相比具有更高的复杂度, 但是本文方法取得了更好的图像去模糊性能。从算法的测试速度而言, 本文方法基本能满足算法的实时性。

表4 本文方法和对比方法在 GOPRO 测试集上的定量评价结果

Table 4 Quantitative evaluation results of proposed method and compared methods on dataset of GOPRO

Method	FLOPs / 10^9	Average time / s
Method in Ref. [11]	4.12	1300.0
Method in Ref. [13]	1760.04	8.1
Method in Ref. [15]	678.29	1.1
Method in Ref. [16]	411.34	0.7
Ours	628.03	1.3

4 结束语

针对当前图像去模糊算法在图像边缘细节恢复方面的不足以及鲁棒性差的问题, 提出了基于边缘判别机制的图像去模糊方法。该算法充分利用了图像边缘先验, 不仅在图像的生成阶段引入边缘重建约束, 而且在图像判别阶段加入了边缘判别学习的约束。与近几年的图像去模糊算法相比, 该算法能更好地恢复图像的边缘等细节信息, 为图像去模糊算法在边缘恢复方面提供了新的思路。对实验结果的定性评价和定量评价都表明本文算法能有效地恢

复图像的边缘细节,恢复后的图像具有更良好的视觉效果。

参 考 文 献

- [1] Whyte O, Sivic J, Zisserman A, et al. Non-uniform deblurring for shaken images [J]. *International Journal of Computer Vision*, 2012, 98(2): 168-186.
- [2] Pan J S, Sun D Q, Pfister H, et al. Blind image deblurring using dark channel prior [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 1628-1636.
- [3] Krishnan D, Tay T, Fergus R, et al. Blind deconvolution using a normalized sparsity measure [C] // Proceedings of 2011 IEEE International Conference on Computer Vision and Pattern Recognition, June 20-25, Colorado Springs, Colorado, USA. New York: IEEE Press, 2011: 233-240.
- [4] Cho S, Lee S. Fast motion deblurring [J]. *ACM Transactions on Graphics*, 2009, 28(5): 145.
- [5] Ren W Q, Cao X C, Pan J S, et al. Image deblurring via enhanced low-rank prior [J]. *IEEE Transactions on Image Processing*, 2016, 25(7): 3426-3437.
- [6] Li C Y, Guo C L, Ren W Q, et al. An underwater image enhancement benchmark dataset and beyond [J]. *IEEE Transactions on Image Processing*, 2020, 29: 4376-4389.
- [7] Li C Y, Guo J C, Guo C L. Emerging from water: Underwater image color correction based on weakly supervised color transfer [J]. *IEEE Signal Processing Letters*, 2018, 25(3): 323-327.
- [8] Li C Y, Anwar S, Porikli F. Underwater scene prior inspired deep underwater image and video enhancement [J]. *Pattern Recognition*, 2020, 98: 107038.
- [9] Cai C D, Huo G Y, Zhou Y, et al. Underwater image restoration method based on scene depth estimation and white balance [J]. *Laser & Optoelectronics Progress*, 2019, 56(3): 031008.
蔡晨东, 霍冠英, 周妍, 等. 基于场景深度估计和白平衡的水下图像复原 [J]. *激光与光电子学进展*, 2019, 56(3): 031008.
- [10] Jin W P, Guo J C, Qi Q. Underwater image enhancement based on conditional generative adversarial network [J]. *Laser & Optoelectronics Progress*, 2020, 57(14): 141002.
- [11] Gong D, Yang J, Liu L Q, et al. From motion blur to motion flow: A deep learning solution for removing heterogeneous motion blur [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 3806-3815.
- [12] Sun J, Cao W, Xu Z, et al. Learning a convolutional neural network for non-uniform motion blur removal [C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 769-777.
- [13] Nah S, Kim T H, Lee K M. Deep multi-scale convolutional neural network for dynamic scene deblurring [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 257-265.
- [14] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets [C]//Advances in Neural Information Processing Systems, December 8-13, Montréal CANADA. New York: IEEE Press, 2014: 2672-2680.
- [15] Kupyn O, Budzan V, Mykhailych M, et al. DeblurGAN: blind motion deblurring using conditional adversarial networks [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 8183-8192.
- [16] Kupyn O, Martyniuk T, Wu J R, et al. DeblurGAN-v2: Deblurring (orders-of-magnitude) faster and better [C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea (South). New York: IEEE Press, 2019: 8877-8886.
- [17] Madam N T, Kumar S, Rajagopalan A N. Unsupervised class-specific deblurring [M] // Computer Vision-ECCV 2018. Cham: Springer International Publishing, 2018: 358-374.
- [18] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation [M] // Lecture Notes in Computer Science. Cham: Springer International Publishing, 2015: 234-241.

- [19] Isola P, Zhu J Y, Zhou T H, et al. Image-to-image translation with conditional adversarial networks [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 5967-5976.
- [20] Ulyanov D, Vedaldi A, Lempitsky V. Instance normalization: the missing ingredient for fast stylization [EB/OL]. (2019-09-03) [2020-06-01]. https://blog.csdn.net/qq_42192910/article/details/100528305.
- [21] Maas A L, Hannun A, Ng A. Rectifier nonlinearities improve neural network acoustic models [C] // Proceedings of 2013 International Conference on Machine Learning. June 16-21, Atlanta, USA. New York: IEEE Press, 2013.
- [22] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2015-04-10) [2020-06-01]. <https://arxiv.org/abs/1409.1556>.
- [23] Gulrajani I, Ahmed F, Arjovsky M, et al. Improved training of Wasserstein GANs [EB/OL]. (2017-12-25) [2020-06-01]. <https://arxiv.org/abs/1704.00028>.
- [24] Canny J. A computational approach to edge detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1986, PAMI-8(6): 679-698.
- [25] Köhler R, Hirsch M, Mohler B, et al. Recording and playback of camera shake: Benchmarking blind deconvolution with a real-world database [M] // Computer Vision-ECCV 2012. Berlin, Heidelberg: Springer, 2012: 27-40.
- [26] Lai W S, Huang J B, Hu Z, et al. A comparative study for single image blind deblurring [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 1701-1709.
- [27] Kingma D P, Ba J. Adam: A method for stochastic optimization [EB/OL]. (2017-06-30) [2020-06-01]. <https://arxiv.org/abs/1412.6980>.
- [28] 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.