

DOI:10.19651/j.cnki.emt.2209861

基于 DeblurGAN 的运动模糊图像盲复原算法研究 *

孙晶晶¹ 张艳艳² 高超¹ 胡佳琦³ 程菲¹(1. 安徽信息工程学院计算机与软件工程学院 芜湖 241000; 2. 南京信息工程大学电子与信息工程学院 南京 210044;
3. 中央财经大学信息学院 北京 100098)

摘要: DeblurGAN 方法利用条件生成对抗网络解决了端到端的图像去模糊问题,但存在图像边缘细节恢复不足以以及鲁棒性不高的问题,针对此问题,提出一种基于 DeblurGAN 的运动模糊图像盲复原方法。在生成网络中,采用多尺度卷积核神经网络提取特征,并使用级联空洞卷积扩大神经元的感受野;采用自适应归一化方法代替原来生成器中使用的实例归一化方法。其次,引入了梯度图像 L1 损失,结合对抗损失和感知损失,将其作为图像去模糊的正则约束,使得生成图像的边缘特征更加清晰。实验结果表明,提出方法复原的图像峰值信噪比数值较 DeblurGAN 算法高出 5.4%,结构相似性指标高出 1%;在主观上清晰化效果较好,且消除了网格效应。

关键词: 运动模糊;生成对抗网络;级联空洞卷积;多尺度特征提取;自适应归一化

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 520.6040

Research on blind restoration algorithm of motion blur image based on DeblurGAN

Sun Jingjing¹ Zhang Yanyan² Gao Chao¹ Hu Jiaqi³ Cheng Fei¹

(1. School of Computer and Software Engineering, Anhui Institute of Information Engineering, Wuhu 241000, China;

2. Department of Electronic and Information Engineering, Nanjing University of Information Science & Technology, Nanjing 210044, China; 3. School of Information, Central University of Finance and Economics, Beijing 100098, China)

Abstract: The DeblurGAN method uses Conditional Generative Adversarial Networks (cGANs) to solve the end-to-end image deblurring problem, but there are problems of insufficient image edge detail recovery and low robustness. Aiming at this problem, a blind restoration method of motion blurred images based on DeblurGAN is proposed. In the generative network, a multi-scale convolution kernel neural network is used to extract features, and cascaded atrous convolution is used to expand the receptive field of neurons; an adaptive normalization method is used to replace the instance normalization method used in the original generator. Second, the gradient image L1 loss is introduced, combined with adversarial loss and perceptual loss, as a regular constraint for image deblurring, making the edge features of the generated image clearer. The experimental results show that the peak signal-to-noise ratio of the image restored by the proposed method is 5.4% higher than that of the DeblurGAN algorithm, and the structural similarity index is 1% higher; the subjective clearing effect is better, and the grid effect is eliminated.

Keywords: motion blur; generative adversarial network; hybrid dilated convolution; multi-scale feature extraction; switchable normalization

0 引言

在物体成像过程中,由于相对运动、相机对焦、大气湍流等影响,导致图像出现模糊。图像去模糊是实现目标检测和识别等高级视觉任务的基础步骤,是图像处理和计算

机视觉领域的研究热点。图像模糊复原的方法一般是基于模糊退化模型,其定义为:

$$I_{blur} = K * I_{clear} + N \quad (1)$$

式中: I_{blur} 是模糊图像, K 为模糊核或点扩散函数, I_{clear} 为清晰图像,* 为卷积算子, N 是加性噪声。去模糊问题根

收稿日期:2022-05-06

* 基金项目:安徽省自然科学基金(2008085MF201)、科技部科技创新 2030“新一代人工智能”重大项目(2020AAA0103601)、安徽高校自然科学研究一般项目、安徽信息工程学院青年科研基金(22QNJJJK001)项目资助

据模糊核是否已知可以分为非盲去模糊和盲去模糊两类。如果模糊核是已知的,那么它是一个非盲的去模糊问题,可以采用经典的 Lucy-Richardson 滤波算法和 wiener 滤波算法进行反卷积,得到清晰的图像。然而,现实生活中遇到的模糊图像具有未知的模糊核,且模糊核复杂多样难以估计,这使得盲去模糊问题更加困难。

随着对深度学习研究的不断深入,基于卷积神经网络(CNN)去模糊的方法^[1-6]逐渐取代了基于先验的方法^[7-8]。Chakrabarti^[2]使用 CNN 来估计运动模糊内核,再使用非盲去模糊算法去模糊,虽然提高了模糊核估计的精度,但估计过程时间过长。2014 年,生成对抗网络(generative adversarial networks, GAN)^[9]被提出,由于其模型的简单性和生成效果的优势,GANs 被广泛用于图像翻译^[10]、图像超分辨率重建^[11]和语义分割^[12]等领域并取得了良好的效果,随后 GANs 也开始在去模糊领域得到应用。Nah^[13]将多尺度 CNN 和 GAN 相结合应用于动态场景,取得了较好的去模糊效果,然而该算法复杂度高效率低,模型的生成需要很长时间。Ramakrishnan 等^[14]提出了一种基于 GAN 架构的新型深度滤波器,该滤波器集成了 DenseNet 架构和全局跳跃连接,以解决三维空间中摄像机和对象之间的相对运动在整个图像上引起空间变化的模糊效应的问题,在保持去模糊效果的同时,提高了网络的效率,但生成的图像的清晰度与 Nah 的方法相当。2018 年, Orest Kupyn^[15]结合条件生成对抗网络(cGAN)^[16]和基于恢复图像内容的感知损失^[17],构造了 DeblurGAN,其网络结构简单,模型处理速度快,在结构相似性(SSIM)^[18]和视觉质量方面取得了最优异的去模糊成果,但美中不足的是 DeblurGAN 处理后的图像存在边缘模糊和较为严重的网格现象。

针对 DeblurGAN 方法在图像边缘细节恢复的不足以及鲁棒性不高的问题,提出一种基于 DeblurGAN 改进的图像去模糊网络结构。本文在生成网络中采用多尺度卷积核神经网络来进行特征提取以获得更丰富的特征信息;同时使用级联空洞卷积扩大神经元的感受野获得更大范围的图像信息;采用自适应配归一化方法代替原来生成器中使用的实例归一化方法,为网络中的每一个归一化层确定合适的归一化操作。其次,引入了梯度图像 L1 损失,结合对抗损失和感知损失,将其作为图像去模糊的正则约束。最后,在经典的 GOPRO 数据集上进行训练得到去模糊的模型,实验结果表明,此模型在复原效果上有一定的收益。

1 相关理论

2014 年, Ian Goodfellow 等在文献[9]中引入了生成式对抗网络模型,该模型建立了两个具有竞争力的网络:生成器网络 G 和鉴别器网络 D。生成器 G 通过学习训练集中真实数据的概率分布 P_r ,将输入的噪声 z 转化为可以以假乱真的图像 $G(z)$;判别器 D 判断输入的图像为真实图像的概率,其目标是将生成器生成的图像与真实图像尽可能地

区分开,生成器与判别器进行对抗训练相互进行参数优化,提高各自的生成和判别能力,最终使通过生成器生成的图像可以达到与真实图像十分相近。这种对抗学习的思想可以表示为:

$$\min_{G} \max_{D} E_{x \sim P_r} [\log(D(x))] + E_{\tilde{x} \sim P_G} [\log(1 - D(\tilde{x}))] \quad (2)$$

其中, P_r 表示真实数据的分布, P_G 为生成数据 $\tilde{x} = G(z)$ 的分布, 即是由生成器 G 从简单的噪声分布 P_z 中随机抽取样本 z 生成的, $D(x)$ 表示鉴别器认为真实图像为真的概率, $D(\tilde{x})$ 表示鉴别器认为生成的图像是否真实的概率。

然而, GANs 模型的训练会出现如模式崩溃、训练不稳定、梯度消失等问题^[19]。这些问题的出现是由最初 GANs 使用 JS 距离来度量两个分布之间的差异。JS 距离是常数 \ln , 其中两个分布没有完全重叠, 导致 JS 散度的性质突变。因此, Arjovsky 等^[20]提出了 Wasserstein GAN (WGAN), 它使用推土机(Earth-Mover, EM)距离来替代 JS 距离。WGAN 可以用式(3)来表示:

$$\min_{G} \max_{D} E_{x \sim P_r} [D(x)] - E_{\tilde{x} \sim P_G} [D(\tilde{x})] \quad (3)$$

Gulrajani 等^[21]提出在式(3)的函数中增加一个梯度惩罚项,以实现对多种 WGAN 体系结构的稳定训练:

$$\lambda E_{\tilde{x} \sim P_{\text{penalty}}} [(\| \nabla_{\tilde{x}} D(\tilde{x}) \| - 1)^2] \quad (4)$$

其中, P_{penalty} 为 P_r 和 P_G 之间的罚值分布, $\tilde{x} \sim P_{\text{penalty}}$ 为从 P_{penalty} 中抽样一个点 \tilde{x} 。 $\nabla_{\tilde{x}} D(\tilde{x})$ 是输入 \tilde{x} 到输出 $D(\tilde{x})$ 之间的梯度。

Isola 等提出了条件 GAN(cGAN),即 pix2pix, 它从观测图像 x 和随机噪声向量 z 中学习一个映射函数,输出图像 y ,即

$$\begin{aligned} & \min_{G} \max_{D} E_{x \sim P_r} [\log(D(x | y))] + \\ & E_{\tilde{x} \sim P_G} [\log(1 - D(\tilde{x} | y))] \end{aligned} \quad (5)$$

2 基于 DeblurGAN 去模糊算法的改进

由于 GAN 生成的图像更加符合人类感知,研究者们在 GAN 的技术上提出了许多优秀的网络模型应用于图像修复等领域,DeblurGAN 模型采用基于感知损失约束的生成对抗网络进行去模糊,是当前深度学习领域里处理图像去模糊最为优秀的方法之一,针对该算法存在图像边缘细节恢复的不足以及严重的网格现象,本文对其网络模型进行改进,用以恢复图像并使之具有清晰的边缘,整体网络架构如图 1 所示。

2.1 生成器网络

生成网络作用在于去除退化图像的运动模糊,生成还原图像。本文主要致力于 GAN 生成器的设计,提出以下 3 个创新点:

- 1) 采用多尺度卷积核神经网络来进行特征提取以获得

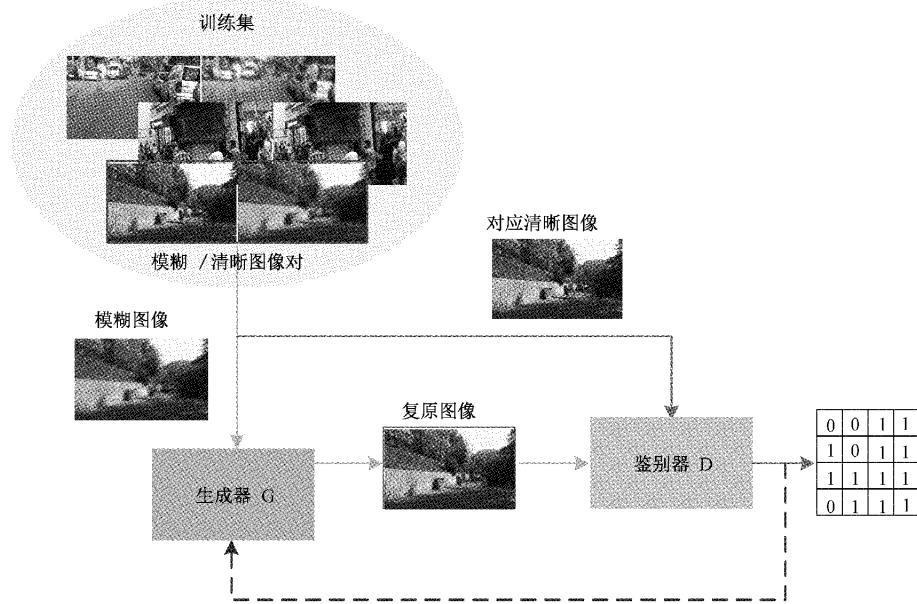


图 1 本文模型整体框架图

更丰富的特征信息；

2) 使用级联空洞卷积来加大感受野, 同时消除网格效应;

3) 采用自适应归一化方法代替原来生成器中使用的实例归一化方法, 为网络中的每一个归一化层确定合适的归一化操作。

在生成器的网络结构设计上采用的是深度残差网络(ResNet)结构^[22], 改进后的生成器网络如图 2 所示。输入图像为三通道大小为 256×256 的 RGB 图像, 首先经过多尺度特征提取模块(multi-scale feature module, MFM)(如图 3(a)所示)进行卷积, 将提取出的图像特征利用 Concat 方式进行融合, 减少训练参数的数量。为了加快训练速度以及提升模型的精度, 对卷积之后的数据进行一次自适应

归一化(switchable normalization, SN)和 Relu 激活函数操作。接着经过两个结构相同的下采样模块后进行一次级联空洞卷积(hybrid dilated convolution, HDC)(如图 3(b)所示), 再经过九个 ResBlock 块(如图 3(c)所示)操作, 数据经过该层的处理后, 对其进行比例为 0.5 的 Dropout 操作, 即随机断开 50% 的神经元连接, 防止训练过程中可能出现的过拟合现象。随后通过两次上采样, 其目的主要是将卷积后的小尺寸高维度特征图恢复到原始的尺寸。转置卷积操作之后, 对输出数据做一次卷积核数量为 3、卷积核大小为 7×7 、步长为 1 的二维卷积以及 Tanh 激活函数操作。最后将从该层输出的数据与原始数据融合到一起, 即是生成器网络模块生成的样本数据, 也就是去模糊之后的清晰图像。

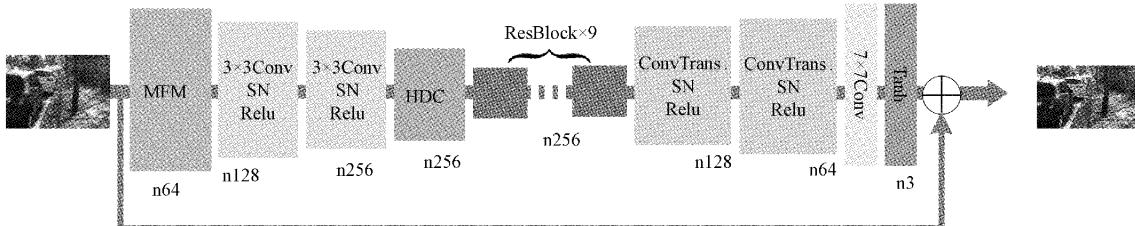


图 2 生成器网络结构

1) 多尺度特征提取

为了更好的提取浅层特征, 本文使用多尺度卷积核代替传统的单一卷积核模式, 从而获得图像在不同尺度下采集到的不同类型的特征信息, 因而能提取到更加丰富和细腻的特征信息。由于图像的模糊程度会随着尺度的降低而降低, 故可以用不同尺度的特征来处理不同程度的模糊, 因为输入的模糊图像上各处模糊程度可能是相同的,

所以提取不同尺度的特征是很重要的, 本文提出了多尺度卷积模块的结构如图 3(a)所示, 模糊图像先经过一个卷积核尺寸为 $7 \times 7 \times 64$, 步长为 1 的卷积, 再经 MFM 模块处理, 其中三个尺度的卷积核尺寸分别为 $1 \times 1 \times 64$ 、 $3 \times 3 \times 64$ 、 $5 \times 5 \times 64$, 步长均为 1, 通过 concat 方式将提取到的特征进行融合。

2) 级联空洞卷积

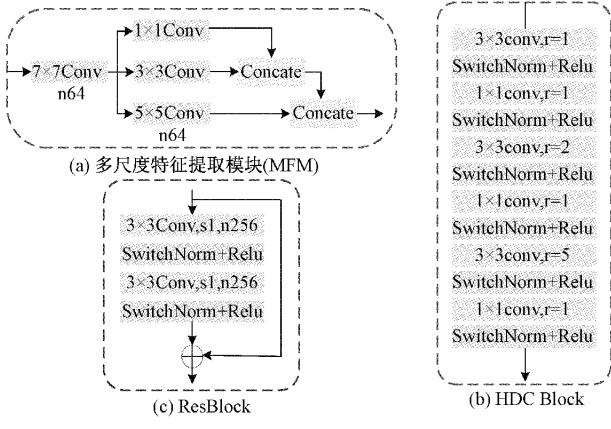


图 3 生成器中的模块

为了捕获更大范围的图像信息通常会使用空洞卷积, 但空洞卷积的卷积核是不连续、稀疏的, 会导致输出的图像存在网格效应。假设连续采用扩张率为 2 的空洞卷积进行卷积运算, 从图 4(a)中可以看出, 因为浅层特征图中卷积核的空洞, 致使高层卷积核在进行卷积的时候出现更多的空洞, 导致图像信息之间的相关性降低。为了解决空洞卷积带来的网格效应, Wang 等人^[23]提出采用一个 HDC 块来扩大输出神经元的感受野, 它由 3 个扩张率不断增加的连续空洞卷积层组成, 分别具有 1、2 和 3 的扩张率, 如图 4(b)所示。本文在图像经过生成器网络中两个下采样模块后, 加入一个扩张率分别为 1、2 和 5 的 HDC 块, 如图 4(c)所示。每次扩张卷积后添加一个 1×1 的卷积以减少卷积核参数, 简化模型, 图 3(b)描绘了所提出的模型中

的 HDC 块的细节。

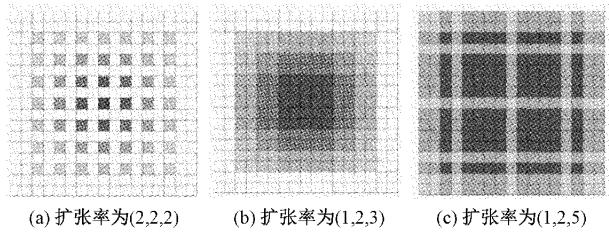


图 4 级联空洞卷积

3) 自适应归一化

归一化虽然有加快模型收敛速度和缓解深层网络中存在的梯度弥散问题的作用, 但 DeblurGAN 是通过手动设计和繁琐大量的实验验证来选择某种归一化方式, 原则上在神经网络不同位置和深度的归一化层应该选择不同的归一化操作, 并没有一个通用的归一化方法能够解决所有应用问题。故本文采用自适配归一化方法^[24], SN 能自适应不同的任务为每一个归一化层确定合适的归一化操作, 拓展了单个结构使用同一种归一化的方式。图 5 直观的展示了 SN 的基本原理, 假设输入数据是一张具有 4 个维度(N, C, H, W)的特征图, 其中 N, C, H, W 分别代表样本数目、通道数目、通道的高和宽。SN 中每个样本每个通道($H \times W$)的均值和方差, 由批量归一化 (batch normalization, BN)、实例归一化 (instance normalization, IN)、层归一化 (layer normalization, LN)3 种不同统计方法计算得到的均值和方差共同决定。

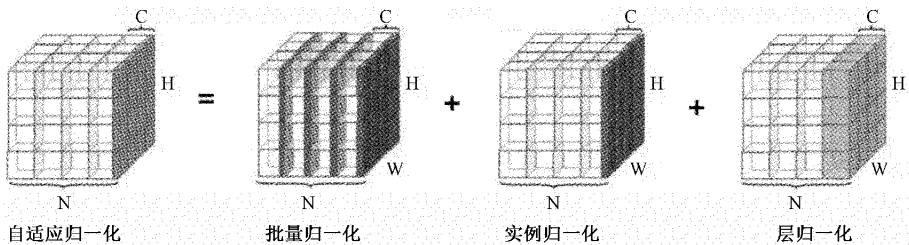


图 5 自适应归一化图形解释

利用 SN 对 h_{ncij} 进行归一化操作, 并输出归一化后的像素值 \hat{h}_{ncij} 。SN 的计算公式如下:

$$\hat{h}_{ncij} = \gamma \frac{h_{ncij} - \sum_{k \in \Omega} \omega_k \mu_k}{\sqrt{\sum_{k \in \Omega} \omega'_k \sigma_k^2 + \epsilon}} + \beta \quad (6)$$

其中, $n \in [1, N], c \in [1, C], i \in [1, H], j \in [1, W]$ 。主要的区别在于 SN 的均值和方差, 不像 IN 只是在一个通道中计算的, 也不像 LN 只是在一个层中计算, 而是在一个集合 Ω 中选择合适的归一化方法来加权平均的, 其中 $\Omega = \{IN, BN, LN\}$ 。 ω_k 和 ω'_k 分别为均值和方差的权重系数。在 SN 中, 均值的权重系数 ω_k 计算如下:

$$\omega_k = \frac{e^{\lambda_z}}{\sum_{z \in \Omega} \{in, ln, bn\} e^{\lambda_z}}, k \in \{in, ln, bn\} \quad (7)$$

2.2 鉴别器网络

鉴别器网络采用经典的马尔科夫鉴别器 (PatchGAN)^[16], 完全由卷积层组成, 优点在于其输出是一个 $N \times N$ 矩阵, 矩阵中的每个元素表示对应图像 patch 是真实的还是人为生成的概率, 将矩阵中元素的平均值作为鉴别器的最终输出。将式(3)中的 Wasserstein GAN 和式(4)中的梯度惩罚引入来训练网络。由于鉴别器网络较浅, 能记忆较容易的分类任务, 故除最后一层外, 所有卷积层均叠加归一化层, 且斜率为 -0.2 的 LeakyReLU^[25], 如图 6 所示。

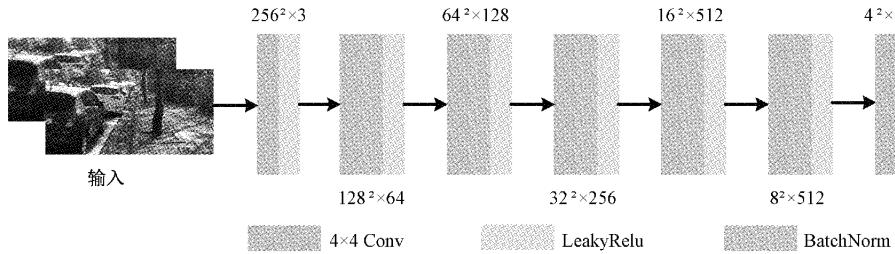


图6 鉴别器网络结构

2.3 损失函数设计

损失函数的主要作用是计算模型预测值与真实值之间的偏差程度,偏差值与模型精度成正比,损失函数的值越小表明网络模型的实际效果就越好。将损失函数作为网络反向传播过程中各层参数更新的依据,网络模型的优化实际上就是最小化损失函数的过程,故损失函数的选择和设计是至关重要的。本文的模型是以自我监督的方式训练出来的。在生成器训练过程中,提出一种新的联合损失函数,在对抗损失和感知损失的基础上,引入梯度损失共同参与模型的训练,如式(8)所示。

$$L = L_{\text{WGAN-GP}} + \lambda \cdot L_{\text{percept}} + \gamma \cdot L_{\text{grad}} \quad (8)$$

其中, λ 和 γ 分别表示感知损失和梯度损失占的权重,本文训练过程中, λ 设置为 0.05, γ 设置为 0.0001。

1) 对抗损失

由于 GAN 网络在训练时存在模型崩塌、梯度消失等问题,对抗损失采用 WGAN-GP 损失,该损失函数对于生成网络 G 的训练更加鲁棒,计算方法如式(9)所示,其中 I_{blur} 为模糊图像:

$$L_{\text{WGAN-GP}} = \sum_{n=1}^N -D_{\theta_D}(G_{\theta_D}(I_{\text{blur}})) \quad (9)$$

2) 感知损失

为了生成具有清晰结构的去模糊图像,本文用内容损失来评估生成的清晰图像和实际清晰图像之间的差距,两个常用的选择是 L1/MAE 损失, L2/MSE 损失。本文将感知损失作为内容损失,感知损失是基于预先训练好的 VGG-Net,本质上是一种 L2 损失,可表示为:

$$L_X = \frac{1}{W_{i,j}H_{i,j}} \sum_{x=1}^{W_{i,j}} \sum_{y=1}^{H_{i,j}} (\varphi_{i,j}(I_{\text{clear}})_{x,y} - (G_{\theta_G}(I_{\text{blur}}))_{x,y})^2 \quad (10)$$

3) 梯度图像 L1 损失

清晰图像具有显著的边缘特征,而模糊图像的边缘特征比较杂乱,本文引入了梯度图像的 L1 距离,将其作为图像去模糊的正则约束,与上述两种损失共同参与模型的训练,有助于获得具有清晰边缘特征的生成图像。本文用 sobel 梯度算子计算图像的梯度,如式(11)所示,图像梯度计算如式(12)所示:

$$d_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \times I, d_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \times I$$

$$\nabla I = |d_x| + |d_y| \quad (11)$$

$$\text{式中: } d_x \text{ 和 } d_y \text{ 分别表示原图像在水平方向和垂直方向的梯度图像。} \quad (12)$$

梯度图像 L1 损失的计算如下:

$$L_{\text{grad}} = \frac{1}{HW} \|\nabla I_{\text{clear}} - \nabla I_{\text{gen}}\| \quad (13)$$

∇I_{clear} 和 ∇I_{gen} 分别表示生成图像的梯度和对应的原清晰图像的梯度; H 和 W 表示梯度图像的尺寸。

3 实验结果及分析

3.1 实验环境配置和数据集预处理

本文实验采用 Nah 等^[13]公开的 GoPro 数据集进行网络训练和验证,该数据集是目前规模最大、分辨率最高的图像去模糊领域的公开数据集,包含来自多个街景的人工模糊图像。该数据集由模糊-清晰图像对组成,包括 2 103 个训练集图像和 1 111 个测试集图像。图像分辨率为 720 pixel,由于 GOPRO 数据集图像都是尺寸为 1 280×720 的高质量图像,训练时需要将输入图像尺寸缩小到 640×360,模型训练输入是在此尺寸上随机裁剪到生成器要求的 256×256 大小。

实验环境配置具体如表 1 所示,另外采用自适应矩估计(Adam)算法来优化损失函数,设置动量为 0.5,通过训练数据不断更新神经网络权重,经过多次调优,训练周期预设为 300,模型的前 150 个周期初始学习率设置为 0.0001,而后学习率线性衰减为 0,为了获得更好的图片复原效果, batchsize 大小设置为 2。

表 1 实验环境配置

编写语言	Python
编辑器	Pycharm
深度学习框架	Keras+TensorFlow
CPU	Intel Xeon E5 V3 2600, 16 线程
显卡	NVIDIA GeForce GTX1080Ti GPU
操作系统	Ubuntu 16.04
镜像	AI cuda10 pytorch1.4 tf1.14

3.2 消融实验

为了进一步研究本文方法的优越性,在 GoPro 数据集

上进行了消融实验,以此分析本文提出的多尺度特征提取模块(MFM)、级联空洞卷积模块(HDC)以及自适应归一化(SN)方法对运动模糊图像清晰化结果的必要性和有效性。

首先对 HDC 模块中不同扩张率进行了探讨和分析,将扩张率分别为(1,2,1)、(1,2,3)和(1,2,5)的 HDC 模块加入到 DeblurGAN 模型中进行训练,其他参数及训练步

骤均保持一致,对训练后的模型进行测试,实验结果如图 7 所示,实验结果的定量分析结果如表 2 所列。观察图 7 及表 2 中的数据可以发现,随着第三层空洞卷积的扩张率的增加,运动模糊图像逐渐清晰化,且空洞效应渐渐消失;到达一定界限后,扩张率继续加大清晰化后的图像质量反而没有得到提升,故本文选择扩张率分别为 1,2 和 5 的 HDC 模块进行实验。



图 7 不同扩张率去模糊实验结果

表 2 HDC 中不同扩张率定量分析结果

HDC	PSNR/dB	SSIM
—	28.70	0.927
(1,2,1)	29.13	0.928
(1,2,3)	29.47	0.930
(1,2,5)	29.65	0.935
(1,2,7)	29.10	0.929

在消融实验中,选择不同的模块或其组合利用控制变量的方式进行对比实验,图 8 展示了消融研究的定性对比结果,定量结果对比如表 3 所列。从表中数据可以看出,与 DeblurGAN 模型相比,每个模块的增加都会使模型在 PSNR 和 SSIM 上有小幅度的提升,尤其添加 HDC 模块后 PSNR 和 SSIM 值上升显著。此消融实验充分证明了采用 MFM 模块、HDC 模块以及 SN 方法均可以有效改善 DeblurGAN 模型对运动模糊图像清晰化后图像的质量。

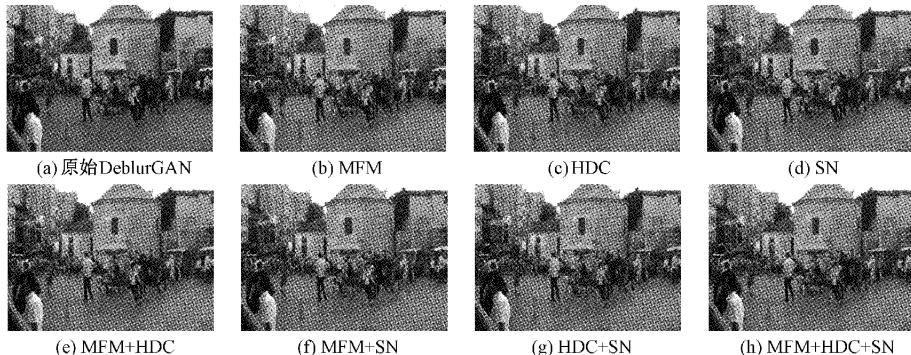


图 8 不同模块组合去模糊实验结果

表 3 GoPro 上的消融实验结果对比

DeblurGAN	MFM	HDC	SN	PSNR/dB	SSIM
✓	—	—	—	28.70	0.927
✓	✓	—	—	29.23	0.931
✓	—	✓	—	29.65	0.935
✓	—	—	✓	29.15	0.930
✓	✓	✓	—	30.51	0.939
✓	✓	—	✓	30.10	0.931
✓	—	✓	✓	30.25	0.936
✓	✓	✓	✓	31.83	0.941

3.3 对比实验结果分析

图像去模糊效果评价指标可分为定量评价和定性评

价,定性评价是通过视觉识别进行评估比较,具有一定的主观性。为验证文中所提去模糊网络的有效性,分别用改进 DeblurGAN 方法和 DeblurGAN 去模糊方法对验证集进行处理,并将处理结果进行主观视觉比较。图 9 和图 10 展示了去模糊效果的对比图并将其中两处细节进行了放大,通过图 9 可以明显看出本文方法去模糊后图像纹理细节更加丰富,图像中远处的行人可以更清晰的辨识,有效地改善了边缘模糊问题;通过图 10 中墙面上的字母可以明显看出使用本文方法能够有效的消除 DeblurGAN 方法存在的网格效应问题。

定量评价是对图像的客观评价,本文采用峰值信噪比(PSNR)和结构相似指数测度(SSIM)两个客观指标来评价图像去模糊前后的质量。为了进一步验证本文去模糊

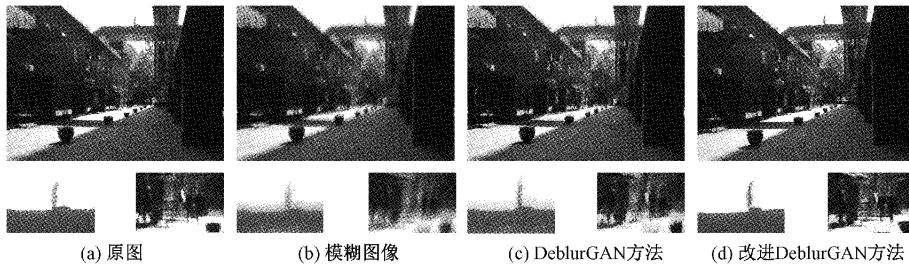


图9 在GOPRO数据集上的对比实验效果图

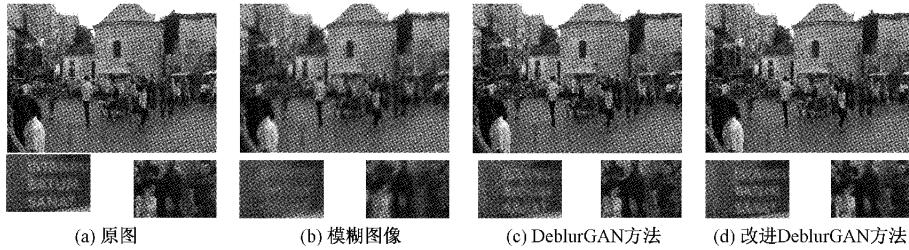


图10 在GOPRO数据集上的对比实验效果图

算法的性能,我们将其与 DeepDeblur^[15]方法、DeblurGAN^[15]方法、Sun^[26]的方法、SRN^[27]方法、及 DeblurGAN-v2^[28]方法进行对比,PSNR 和 SSIM 值如表 4 所示。结果如表 4 所示,从

表中可以看出本文算法 PSNR 和 SSIM 要高于其他先进的去模糊方法,说明本文方法去模糊后细节信息更加丰富,与原图更为接近,再一次证明了本文算法的优越性。

表4 在GoPro数据集上去模糊性能的定量比较

Method	Sun	DeepDeblur	DeblurGAN	DeblurGAN-v2	SRN	Ours
PSNR/dB	24.64	29.23	28.70	29.55	30.10	31.83
SSIM	0.842	0.916	0.927	0.934	0.932	0.941

4 结 论

本文在 DeblurGAN 方法的基础上对该方法进行了改进。通过对 DeblurGAN 模型生成器及损失函数的改进,更好地利用网络中的特征和图像信息,从而达到很好的去模糊效果。本文模型采用 GOPRO 数据集验证,使用 PSNR 和 SSIM 指标对图像重建的整体效果进行评价,实验结果表明,相比原有的一些经典算法本文方法能够有效地恢复出细节清晰的图像,具有更好的视觉效果。尽管本文算法取得了很好的去模糊效果,但网络模型的结构和参数还有调整的空间,在保证去模糊效果不受负面影响的同时降低复杂度,减少训练时间是未来仍需重点研究的方向。

参考文献

- [1] 李佳,李晨,郭业才.基于双重控制网络的图像去模糊方法[J].电子测量技术,2022,45(6):136-142.
- [2] CHAKRABARTI A. A neural approach to blind motion deblurring [C]. European Conference on Computer Vision, Springer, Cham, 2016: 221-235.
- [3] NOROOZI M, CHANDRAMOULI P, FAVARO P. Motion deblurring in the wild[C]. German Conference on Pattern Recognition, 2017:65-77.
- [4] SON H, LEE S. Fast non-blind deconvolution via regularized residual networks with long/short skip-connections[C]. 2017 IEEE International Conference on Computational Photography (ICCP), IEEE, 2017: 1-10.
- [5] HRADIŠ M. Convolutional neural networks for direct text deblurring [C]. British Machine Vision Conference, 2015.
- [6] XU X, PAN J, ZHANG Y J, et al. Motion blur kernel estimation via deep learning [J]. IEEE Transactions on Image Processing, 2017, 27:194-205.
- [7] PAN J, ZHE H, SU Z, et al. Deblurring text images via ℓ_0 -regularized intensity and gradient prior[C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2014: 2901-2908.
- [8] KRISHNAN D, TAY T, FERGUS R. Blind deconvolution using a normalized sparsity measure[C]. Computer Vision & Pattern Recognition, IEEE, 2011:233-240.
- [9] GOODFELLOW I J, POUGET A J, MIRZA M, et al. Generative adversarial nets [C]. Neural

- Information Processing Systems. MIT Press, 2014.
- [10] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2223-2232.
- [11] LEDIG C, THEIS L, F HUSZAR, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4681-4690.
- [12] LUC P, COUPRIE C, CHINTALA S, et al. Semantic Segmentation using Adversarial Networks[J]. ArXiv Preprint, 2016, ArXiv:1611.08408.
- [13] NAH S, KIM T H, LEE K M. Deep multi-scale convolutional neural network for dynamic scene deblurring[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 3883-3891.
- [14] RAMAKRISHNAN S, PACHORI S, GANGOPADHYAY A, et al. Deep generative filter for motion deblurring[C]. Proceedings of the IEEE International Conference on Computer Vision Workshops, 2017: 2993-3000.
- [15] KUPYN O, BUDZAN V, MYKHAILYCH M, et al. DeblurGAN: Blind motion deblurring using conditional adversarial networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8183-8192.
- [16] ISOLA P, ZHU J Y, ZHOU T, et al. Image-to-image translation with conditional adversarial networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 5967-5976.
- [17] JOHNSON J, ALAHI A, FEI-FEI L. Perceptual losses for real-time style transfer and super-resolution [C]. European Conference on Computer Vision, Springer, Cham, 2016: 694-711.
- [18] TOUFIQUE Y, MOURSLI R, MASMOUDI L, et al. Ultrasound image enhancement using an adaptive anisotropic diffusion filter[C]. Middle East Conference on Biomedical Engineering, 2014: 1-4.
- [19] SALIMANS T, GOODFELLOW I, ZAREMBA W, et al. Improved techniques for training GANs[J]. Advances in Neural Information Processing Systems, 2016, 29, DOI: 10.48550/arXiv.1606.03498.
- [20] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein GAN[J]. Advances in Neural Information Processing Systems, 2017, DOI: 10.48550/arXiv.1701.07875.
- [21] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved Training of Wasserstein GANs [J]. Advances in Neural Information Processing Systems, 2017, 30, DOI: 10.48550/arXiv.1704.00028.
- [22] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[J]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016, DOI: 10.1109/cvpr.2016.90.
- [23] WANG P, CHEN P, YUAN Y, et al. Understanding convolution for semantic segmentation[C]. 2018 IEEE Winter Conference on Applications of Computer Vision (WACV), IEEE, 2018: 1451-1460.
- [24] LUO P, REN J, PENG Z, et al. Differentiable learning-to-normalize via switchable normalization [J]. ArXiv Preprint, 2018, ArXiv:1806.10779.
- [25] MAAS A L, HANNUN A Y, NG A Y. Rectifier nonlinearities improve neural network acoustic models[C]. Proc. ICML, 2013, 30(1): 3.
- [26] SUN J, CAO W, XU Z, et al. Learning a convolutional neural network for non-uniform motion blur removal[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 769-777.
- [27] TAO X, GAO H, WANG Y, et al. Scale-recurrent network for deep image deblurring[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8174-8182.
- [28] KUPYN O, MARTYNIUK T, WU J, et al. DeblurGAN-v2: Deblurring (orders-of-magnitude) faster and better[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 8878-8887.

作者简介

孙晶晶,硕士,助教,主要研究方向为图像处理。

E-mail:jjsun14@iflytek.com

张艳艳,博士,副教授,主要研究方向为信号与信息处理、多媒体技术等。

E-mail:002243@nuist.edu.cn

高超,硕士,副教授,主要研究方向为自然语言处理。

E-mail:chaogao@iflytek.com

胡佳琦,本科,主要研究方向为计算机视觉。

E-mail:1529607593@qq.com

程菲,博士,副教授,副研究员,主要研究方向为智能制造。

E-mail:feicheng6@iflytek.com