

多尺度卷积神经网络的噪声模糊图像盲复原

刘鹏飞^{1,2,3,4}, 赵怀慈^{1,2,4}, 曹飞道^{1,2,3,4}

- (1. 中国科学院沈阳自动化研究所, 辽宁 沈阳 110016; 2. 中国科学院机器人与智能制造创新研究院, 辽宁 沈阳 110169; 3. 中国科学院大学, 北京 100049; 4. 中国科学院光电信息处理重点实验室, 辽宁 沈阳 110016)

摘要: 图像盲复原是从一幅观测的模糊图像恢复出模糊核和清晰图像, 传统盲去卷积算法采用简化模型估计模糊核, 导致预测模糊核与真实值误差较大, 最终复原结果不理想。针对此问题提出一种基于改进残差模块的多尺度卷积神经网络模型, 采用端到端模式, 无需估计模糊核。提出了一种基于限制网络输入的改进 Wasserstein GAN (WGAN), 增加了一层输入限制层, 能够限定参数初始值, 提高了网络收敛速度。设计了多重损失函数, 融合了基于多尺度网络的感知损失和基于条件式生成对抗网络的对抗损失。实验结果表明: 所提方法在定量和定性评价指标上优于已有的代表性方法, 并且运行速度比相近算法快了 4 倍。

关键词: 多尺度卷积神经网络; 多重损失函数; 生成式对抗网络; 噪声模糊图像

中图分类号: TP391 **文献标志码:** A **DOI:** 10.3788/IRLA201948.0426001

Blind deblurring of noisy and blurry images of multi-scale convolutional neural network

Liu Pengfei^{1,2,3,4}, Zhao Huaici^{1,2,4}, Cao Feidao^{1,2,3,4}

- (1. Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China;
2. Institutes for Robotics and Intelligent Manufacturing, Chinese Academy of Sciences, Shenyang 110169, China;
3. University of Chinese Academy of Sciences, Beijing 100049, China;
4. Key Laboratory of Optical-electronics Information Processing, Chinese Academy of Sciences, Shenyang 110016, China)

Abstract: The purpose of image blind deconvolution is to estimate the unknown blur kernel from an observed blurred image and recover the original sharp image. Conventional methods used simple models to estimate blur kernel, meaning mistakes were inevitable between estimated blur kernel and the real one. It would cause the final deblurred image unpredictable. A multi-scale convolutional neural network was presented based on the novel residual network. And it restored sharp images in an end-to-end manner without estimating blur kernel. Domain constraint layer was designed to the WGAN, it could restrict parameters initial values and accelerate convergence. A total loss function was designed including perception loss which was based on the multi-scale network and adversarial loss which was

收稿日期: 2018-11-15; 修订日期: 2018-12-25

基金项目: 装备预研领域基金(61400010102)

作者简介: 刘鹏飞(1988-), 男, 博士生, 主要从事图像复原、深度学习方面的研究。Email: liupengfei@sia.cn

导师简介: 赵怀慈(1974-), 男, 研究员, 博士生导师, 主要从事图像处理、复杂系统建模与仿真技术, 指挥、控制、通信与信息处理技术方面的研究。Email: hczhao@sia.cn

based on conditional GAN. Extensive experiments show the superiority of the proposed method over other representative methods in terms of quality and quantity. The method is 4 times faster than the similar methods.

Key words: multi-scale convolution neural network; multiple loss function; generative adversarial networks; noisy and blurry image

0 引言

图像盲复原是图像处理和计算机视觉领域的一个最基本的研究问题。因其涉及问题表述、正则化和数值优化等诸多难点和挑战而一直被广泛关注。受成像设备与图像获取条件等因素影响,图像模糊问题广泛存在。

模糊核通常具有非一致性,求出每个像素的模糊核是一个严重病态问题,部分算法通过简化模糊核模型^[1-3]近似计算。Zhou等^[1]提出一种基于边际似然估计的图像盲去卷积方法,Whyte等^[2]模拟相机曝光时的3D运动,使用最大后验方法估计模糊核,Sun等^[3]提出一种在交替最大后验估计框架下利用低秩先验约束复原方法,Kim等^[4]提出一种变分L1模型,能够同时估计物体运动光流场和模糊核。以上几种基于概率统计的方法,模糊核的估计过程很难从理论上给出严谨的分析和阐释。

随着深度学习已逐渐被应用到各种不同的任务和领域中^[5-6],近年来出现了一些基于卷积神经网络的复原方法,Schuler等^[7]使用卷积神经网络估计模糊核,对于均匀模糊核估计准确,但无法估计非均匀模糊核,Nah等^[8]使用多重卷积神经网络直接复原图像,但存在模型复杂、网络收敛速度慢等问题。

估计模糊核再恢复清晰图像这类算法存在很多问题,首先,在多数领域中应用而言,图像获取是瞬间发生,无法重现当时的拍摄条件,模糊核是未知的;其次,模糊核受相机抖动、物体瞬时移动等多种因素影响,简单模糊核模型无法精确描述以上场景;最后,实际图像获取过程中,尤其是在低光照条件下,成像需要较长的曝光时间,会导致模糊图像中含有噪声或出现饱和情况,传统方法复原以后会出现大量的伪影。综上,以模糊核估计为核心的传统方法计算的模糊核误差较大,导致最终复原结果不理想。

文中提出一种端到端深度学习模型。首先,提出了一种基于改进残差网络的多尺度卷积神经网络模型,输入模糊图像,输出即为清晰图像,避免了由模糊核估计错误导致的影响。其次,建立了基于VGG19的图像感知模型,同时结合了金字塔多尺度结构,提取图像不同层级的特征^[9],同时涵盖了图像边缘^[10-11]、颜色等低粒度特征以及物体、类别等高级特征,总损失函数融合了感知损失和基于条件式生成对抗网络的对抗损失。最后,文中设计了一个稀疏自动编码器,对输入图像范围加以约束,有助于生成更逼真的图像,并且提高网络收敛速度。实验表明:与代表性方法相比,所提出方法在定量和定性评价指标上具有更好的图像复原性能,网络参数比参考文献[8]少了大约3倍,复原速度提高了4倍。

1 方法

图像盲复原目标是从单幅模糊图像 B (没有任何先验信息)恢复出清晰图像 S 。首先,训练一个已改进残差网络为基本模块的多尺度神经网络模型作为生成器,每一个尺度都有对应的清晰图像输出;然后提出了多尺度内容损失和对抗损失,通过VGG19网络计算不同层级的内容损失。最后,设计了一个稀疏自动编码器,使输入更接近真实图像值,提升网络收敛速度。

1.1 生成器网络结构

图像模糊形成过程^[1-3,7]通常表示为:

$$B=K*S+n \quad (1)$$

式中: B 为观测到的噪声模糊图像; S 为原始清晰图像; K 为模糊核(也称点扩散函数),是一个大型稀疏矩阵,矩阵中的每一行代表一个局部模糊核,作用在清晰图像 S 上产生一个模糊像素; n 为图像噪声;*为卷积符号。采用盲复原方法同时估计清晰图像 S 和模糊核 K 。

残差网络^[12]包括一个卷积层,实例化层和 Rectified Linear Unit(ReLU)激活函数。残差网络结构能够获取图像深层特征,结构如图 1 所示,图 1(a)是参考文献[12]的结构,BN 代表实例标准化 Batch Normalization。图 1(b)是改进的网络并标注了具体网络参数,包含两个步幅卷积模块,步幅为 1/2。在每个残差网络模块第一个卷积层后,添加概率为 50% 的 dropout,防止过拟合,笔者发现去掉最后的 ReLU,有利于提高最终复原效果。

为了得到图像不同层次特征,模型采用由粗到精的多层高斯金字塔结构,一共分三层,分别是粗粒度层、中间层和精细层。每一层都有相应图像块作为下一层网络输入,经过实验验证每层堆叠 13 个残差模块效果最佳。笔者训练了多个尺度 $K=1, 2, 3, 4, 5$,发现当 $K=2$ 或 3 时,复原效果最好。取 1 时,恢复图像有较多人工波纹,取 4 或 5 时,训练收敛速度慢,网络难以收敛。输入、输出高斯金字塔图像块分辨率分别是 $256 \text{ pixel} \times 256 \text{ pixel}$, $128 \text{ pixel} \times 128 \text{ pixel}$, $64 \text{ pixel} \times 64 \text{ pixel}$,尺度之间比例为 1/2,所有卷积核尺寸为 3×3 ,Batch size=1。多尺度卷积模型如图 2 所示。输出采用 tanh 函数,实验表明:使用 tanh 函数与

ReLU 函数相比,数据集收敛速度更快,并且得到的图像更加清晰。

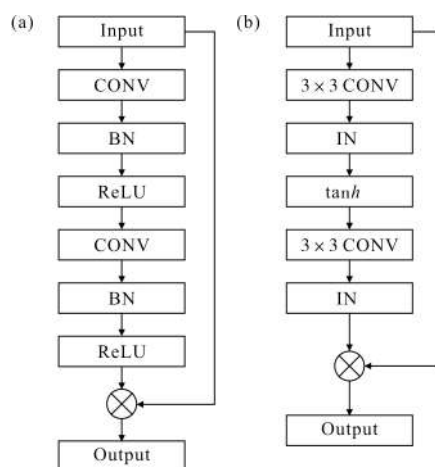


图 1 (a)原版残差网络结构;(b)改进残差网络结构
Fig.1 (a) Original residual network architecture;
(b) Modified residual network architecture

图 2 中, B_k 、 L_k 、 S_k 分别代表模糊图像、网络生成图像、真实清晰图像,下标 k 表示在高斯金字塔的第 k 层,下采样步幅为 1/2,除第三层以外,每层输入都是模糊图像和上一层输出清晰图像经上采样以后两

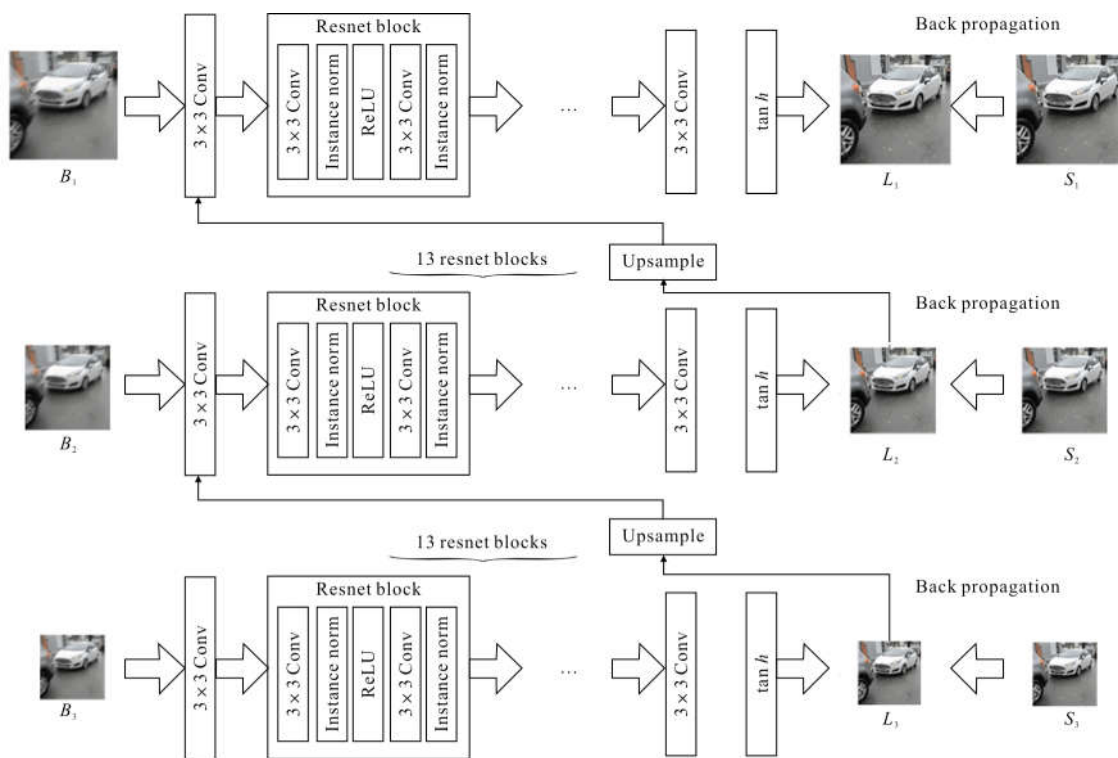


图 2 多尺度卷积神经网络结构
Fig.2 Multi-scale network architecture

者的结合。

多尺度结构中第一层图像分辨率为 64 pixel×64 pixel, 在经过第一个 3 pixel×3 pixel 卷积层以后, 将图像转换成 64 个特征映射, 随后紧邻 13 个残差网络, 最后输出这一层级的清晰图像。整个多尺度学习模型一共有 84 个卷积层, 保证网络能充分学习到图像特征。

1.2 改进 WGAN 结构

如果将模糊图像直接输入到生成网络中, 网络收敛速度慢, 并且容易陷入局部最优点。WGAN 采样值为整幅图像, 包含了部分高频噪声, 损失函数初

值很大, 模型训练困难, 并且 WGAN 有参数夹断层, 不利于判别器学习。文中设计了输入限制生成对抗网络 ILWGAN (Input Limited Wasserstein GAN), 引入输入限制层, 取代 WGAN 的参数夹断层, 可以减少生成样本与真实样本的距离, 提供更广泛的网络参数, 加快网络收敛速度。

生成器接收经过编码器处理过的图像作为输入, 生成清晰图像。在网络训练时, 生成器产生的清晰图像与原始清晰图像同时输入到判别器中, 通过多重损失函数判断二者的距离, 总损失函数包括多尺度内容损失和对抗损失。ILWGAN 网络结构如图 3 所示。




图 3 改进 Wasserstein GAN 网络结构

Fig.3 ILWGAN network architecture

1.3 损失函数设计

总损失函数结合了多尺度内容损失和对抗损失, 最后的损失函数表达式为:

$$L_{\text{total}} = L_{\text{GAN}} + \lambda L_{\text{CONT}} \quad (2)$$

式中: λ 为权重常数, 取 100。

多尺度内容损失。多尺度模型训练是约束不完全问题, 没有解析解。传统方法直接对输出图像和参考图像做像素级比较, 内存消耗大, 并且对噪声敏感。文中提出感知损失方法, 计算生成图像与目标图像特征映射的不同, 表达式为:

$$L_{\text{CONT}} = \sum_{k=1}^K \sum_{x=1}^{W_{ij}} \sum_{y=1}^{H_{ij}} \frac{1}{2c_k W_{ij} H_{ij}} (\phi_{ij}(L^k)_{x,y} - \phi_{ij}(S^k)_{x,y})^2 \quad (3)$$

式中: $\phi_{i,j}$ 为在 VGG19 网络中第 j 个卷积层之后、第 i 个池化层之前获得的特征映射; $W_{i,j}$ 和 $H_{i,j}$ 为特征映射的维度; k 是 高斯金字塔层数, 这里取 [1, 3]; L^k 和 S^k 分别为在第 k 层级中多尺度模型输出和真实的参考图像, 每一层损失函数由通道数 c_k 做归一化处理。

使用 VGG19 图像感知模型, 在图像集 ImageNet 中训练 VGG19 网络, 并结合多尺度模型, 提取图像不同特征, 计算每一层级的内容损失。

对抗损失。对抗式网络常用来生成高逼真的清晰图像^[13], WGAN (Wasserstein GAN) 模型使用 Wasserstein-1 距离 $W(q, p)$ 去估计 Jensen-Shannon 散度。评价函数为:

$$\min_G \max_{D \in R} E_{S \sim P_{\text{sharp}}(S)} [D(S)] - E_{S \sim P_{\text{blurry}}(B)} [D(G(B))] \quad (4)$$

式中: R 为一阶李普希兹函数; P_{sharp} 为真实清晰图像数据分布; P_{blurry} 为深度学习模型分布; G 为生成器, 尽力减小对抗损失; D 为判别器, 尽力增大对抗损失。

WGAN 模型有收敛速度慢、内存利用率低、梯度消失等问题, 解决办法是增加梯度惩罚项 Gradient Penalty (GP), 会对李普希兹函数有限制作用, 并且几乎不用调节超参, 梯度惩罚项为:

$$\lambda E_{S \sim P_{\text{blurry}}(B)} [(\|\nabla_B D(B)\|_{2-1})^2] \quad (5)$$

将 ILWGAN 模型结合梯度惩罚项, 使用 ILWGAN-GP 作为评价函数, 计算公式为:

$$L_{\text{GAN}} = \sum_{k=1}^K -D_{\text{WGAN}}(G(I^k)) \quad (6)$$

式中: G 为对抗网络生成器, 即图 2 所示的多尺度卷积神经网络模型; k 为高斯金字塔层数, 这里取 3; I^k

为在第 k 层中多尺度模型的输入; D_{WGAN} 为判别器。

2 实验与结果分析

2.1 训练过程

使用 PyTorch 深度学习框架实现文中模型, CPU 配置为英特尔酷睿 i7-6700K, 显卡使用 NVIDIA GTX Titan-X GPU。训练集使用 GoPro 数据集^[12], RGB 三通道图像分别输入并把顺序打乱。在 3 214 对图像中, 2 103 对图像作为训练集, 其余图像作为测试集。由于模型是基于图像块训练, 并且模型是全卷积模型, 因此, 模型可以应用到图像中的任意尺寸。对判别器模型 D_{WGAN} 使用 5 次梯度下降法后, 对 G 启用一次梯度下降, 选用 ADAM 优化器。对于生成器和判别器, 初始学习率设为 10^{-4} , 在经过 130 个 epochs 以后, 学习率线性减少直至 0。采用 dropout 和实例标准化等优化方法。经过在验证集上验证, Batch size=1 时效果最好。

为了防止网络过拟合, 图像块随机在水平和垂直方向上旋转 90° , 增加训练集图像数量。为增强系统鲁棒性, 添加高斯随机噪声, 噪声从高斯分布 $N(0, (1/90)^2)$ 中采样, 剔除不在 $[0, 1]$ 范围内的噪声, 将噪声值减去 0.5, 得到以 0 为中心、 $[-0.5, 0.5]$ 范围的高斯噪声。

2.2 GoPro 数据集


GoPro 数据集^[8]包含 2103 对模糊和清晰图像对, 分辨率是 720 p, 涵盖了很多场景。测试集包含 1 103 对模糊/清晰图像对, 对文中方法与模糊核估计方法^[3]和端到端模型^[8]进行了比较, 表 1 为在客观度量指标以及运行时间上的结果, 所有算法都在单 GPU 环境下运行。从表 1 中可以得出, 在结构相似度(SSIM)和峰值信噪比(PSNR)方面, 文中方法最优, 当 $K=2$ 时, 在 PSNR 和 SSIM 指标上得到了最好效果, 当 $K=3$ 时, 系统运行最快。

表 1 GoPro 测试集中 1 000 张模糊图像评估结果, K 表示多尺度层级

Tab.1 Evaluation results of the 1 000 images in GoPro dataset, K denotes the multi-scale level

Metric	Ref.[3]	Ref.[8]	Proposed method		
			$K=1$	$K=2$	$K=3$
PSNR	24.64	29.23	29.56	33.14	32.25
SSIM	0.842	0.916	0.884	0.953	0.951
Time	20 min	4.33 s	3.81 s	1.20 s	0.94 s

去模糊效果如图 4 所示, 矩形框表示图像的局部区域, 图 4(a)~(e)分别为模糊图像、参考文献[3]中






图 4 GoPro 数据集结果

Fig.4 Results of GoPro dataset

方法处理后的图像、参考文献[8]中方法处理后的图像、文中所提方法处理后的图像、清晰图像。参考文献[3]在处理模糊边界时效果不理想,图 4(a)中,文中算法复原的树枝可以看清纹理,图 4(b)中,文中算法结果与清晰图像最为接近,另两种算法汽车拖尾现象较严重,图 4(c)中,只有文中算法能够看清车牌号码,另两种算法有较多的伪影。

2.3 Kohler 数据集

Kohler 数据集^[14]包括 4 张模糊图像,分别用 12 组不同的模糊核施加到图像中,是评价盲去模糊算法的基准数据集。Kohler 数据集通过分析真实的相机运动轨迹,借助机器平台记录相机 6 个自由度的运动轨迹。数据集的评价指标分别是 PSNR 和平均结构相似度 MSSIM。不同算法比较结果如表 2 所示,当 $K=3$ 时,PSNR 与 MSSIM 指标最高,复原效果最理想。

表 2 Kohler 标准数据集评估结果, K 表示多尺度层级
Tab.2 Evaluation results of the images in Kohler dataset, K denotes the multi-scale level

Metric	Ref.[3]	Ref.[8]	Proposed method		
			$K=1$	$K=2$	$K=3$
PSNR	25.22	26.02	25.63	25.97	26.13
MSSIM	0.773	0.811	0.798	0.802	0.815

Kohler 数据集复原结果如图 5 所示,矩形框范围表示恢复的图像部分细节,图像右边两幅叠加图像是对矩形范围内的局部特写,图 5(a)~(d)分别为模糊图像、采用参考文献[8]中的方法处理后的图像、采用文中方法处理后的图像、清晰图像。文中方法在上方时钟图中可见清晰的指针纹理,下方旗帜图中可见清晰的旗帜细节,其他算法看不清图像细节。




图 5 Kohler 数据集结果

Fig.5 Results of Kohler dataset

2.4 Lai 数据集

Lai 数据集^[15]是由清晰图像与模糊核卷积,并加入噪声形成的,整体结构较复杂,对于盲去模糊算法要求更高。Lai 数据集包含 26 张清晰图像,对每张图像分别施加 4 种不同的均匀模糊核和 4 种不同的非均匀模糊核,分别产生 104 张均匀模糊图像和 104 张非均匀模糊图像,共 208 张模糊数据集。不同算法定量比较结果如表 3 所示,从表 3 可以得出文中算法具有更高的 PSNR 和 SSIM 值,且运行时间最少。

复原结果如图 6 所示,经过文中方法处理后,图 6(a)~(e)分别为模糊图像、采用参考文献[3]中的

方法处理后的图像、采用参考文献[8]中的方法处理后的图像、采用文中方法处理后的图像、清晰图像。

表 3 Lai 测试集中 208 张模糊图像评估结果, K 表示多尺度层级

Tab.3 Evaluation results of the 208 images in Lai dataset, K denotes the scale level

Metric	Ref.[3]	Ref.[8]	Proposed method		
			$K=1$	$K=2$	$K=3$
PSNR	18.902	21.998	22.483	24.834	22.596
SSIM	0.525	0.669	0.684	0.695	0.725
Time	4 min	1.25 s	1.26 s	0.98 s	1.22 s

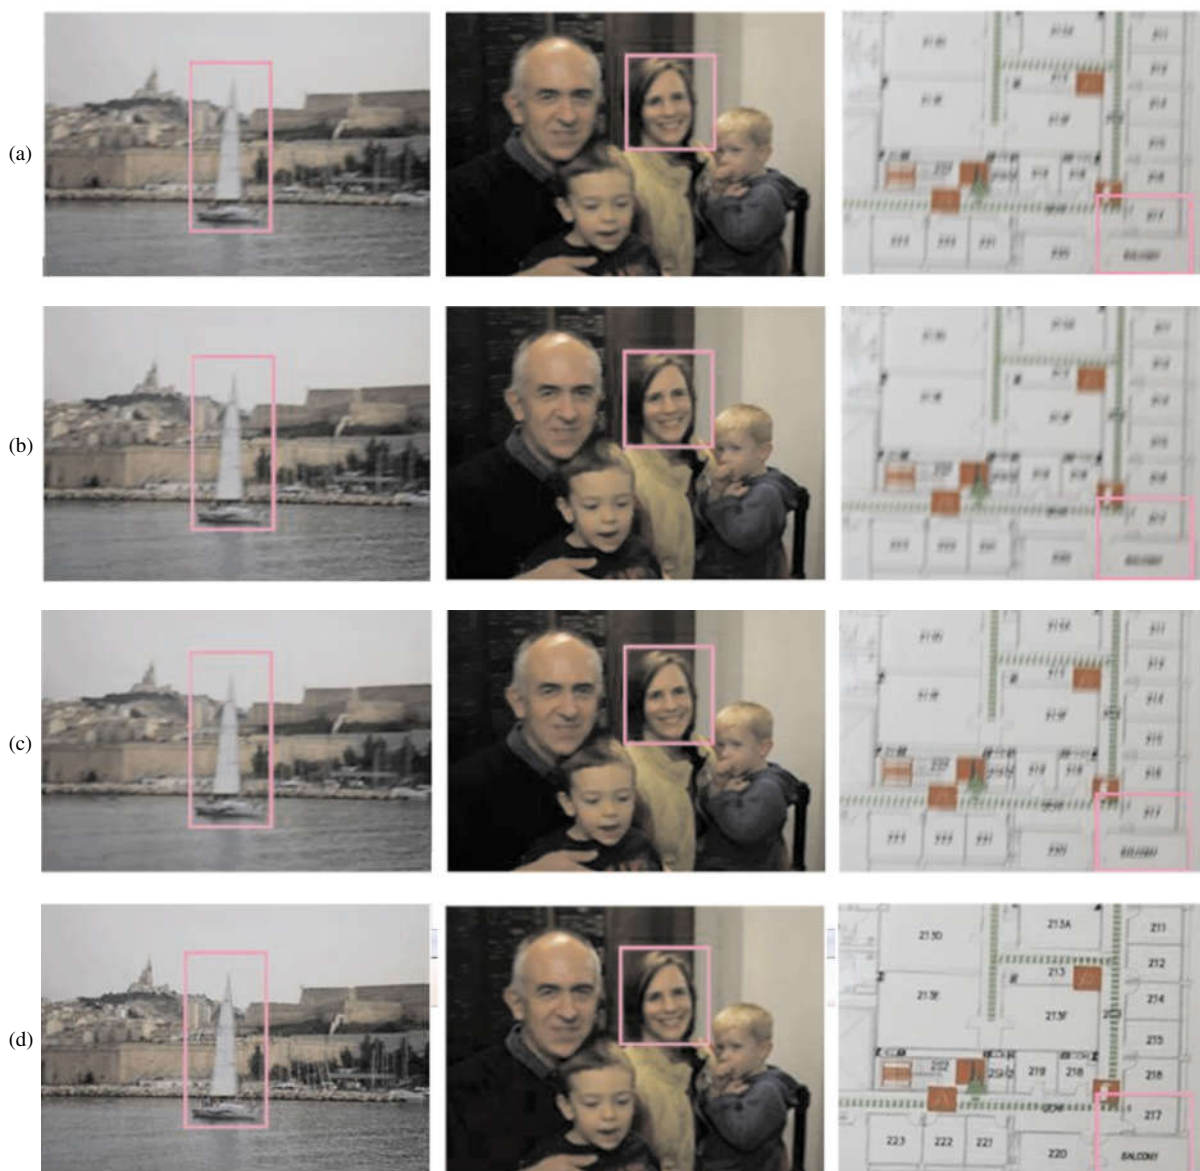




图 6 Lai 数据集结果

Fig.6 Results of Lai dataset

3 结论

针对单幅噪声模糊图像盲复原问题,文中提出了一种基于改进残差网络的多尺度卷积神经网络模型,采用端到端模式,输入单幅模糊图像,无需估计模糊核,直接输出清晰图像。模型训练通过金字塔不同层级,增大图像感受野,充分发掘图像不同特征,并设计多重损失函数,包括多重感知损失和对抗损失,给出了判别器的网络结构。提出了 ILWAN 网络,设计了自动稀疏编码器,将输入限制层取代 WGAN 中参数夹断层,通过控制输入范围,使判别器更快达到最优,加快了整个网络收敛速度。实验结果表明:文中方法具有较好的噪声模糊图像复原性能,其在评估盲复原算法的三个标准测试集中客观指标和主观评价优于代表性方法,网络参数比同类近似算法少了 3 倍,运行速度比同类近似算法快了 4 倍。

参考文献:

[1] Zhou Luoyu, Zhang Bao, Yang Yang. Estimation of parameter of defocused blurred image using Hough transform[J]. *Infrared and Laser Engineering*, 2012, 41(10): 2833–2837. (in Chinese)
周箩鱼, 张葆, 杨扬. 采用 Hough 变换的离焦模糊参数的估计[J]. *红外与激光工程*, 2012, 41(10): 2833–2837.

[2] Whyte O, Zisserman A, Ponce J. Non-uniform deblurring for shaken images [J]. *International Journal of Computer Vision*, 2012, 98(2): 168–186.

[3] Sun Shijie, Zhao Huaici, Li Bo, et al. Blind deconvolution for noisy and blurry images using low rank prior [J]. *Journal of Electronics & Information Technology*, 2017, 39(8): 1919–1926. (in Chinese)
孙士洁, 赵怀慈, 李波, 等. 利用低秩先验的噪声模糊图像

盲去卷积[J]. *电子与信息学报*, 2017, 39(8): 1919–1926.

[4] Kim T H, Lee K M. Segmentation-free dynamic scene deblurring [C]//*Computer Vision and Pattern Recognition*. IEEE, 2014: 2766–2773.

[5] Liu Tianci, Shi Zelin, Liu Yunpeng, et al. Geometry deep network image-set recognition method based on Grassmann manifolds [J]. *Infrared and Laser Engineering*, 2018, 47(7): 0703002. (in Chinese)
刘天赐, 史泽林, 刘云鹏, 等. 基于 Grassmann 流形几何深度网络的图像集识别方法 [J]. *红外与激光工程*, 2018, 47(7): 0703002.

[6] Zhang Lamei, Chen Zexi, Zou Bin. Fine classification of polarimetric SAR images based on 3D convolutional neural network [J]. *Infrared and Laser Engineering*, 2018, 47(7): 0703001. (in Chinese)
张腊梅, 陈泽茜, 邹斌. 基于 3D 卷积神经网络的 PolSAR 图像精细分类 [J]. *红外与激光工程*, 2018, 47(7): 0703001.

[7] Schuler C, Hirsch M, Harmeling S, et al. Learning to deblur [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2016, 38(7): 1439–1451.

[8] Nah S, Kim T H, Lee K M. Deep Multi-scale convolutional neural network for dynamic scene deblurring [JJ]. *IEEE Computer Vision and Pattern Recognition*, 2017, 35(1): 257–265.

[9] Feng Jun, Yan Yuyu, Zhao Yan, et al. A terracotta image partition matching method based on learned invariant feature transform [J]. *Optics and Precision Engineering*, 2018, 26(7): 1774–1783. (in Chinese)
冯筠, 延瑜瑜, 赵妍, 等. 基于学习不变特征变换的兵马俑图像分区匹配 [J]. *光学精密工程*, 2018, 26(7): 1774–1783.

[10] Ji Huizhong, Jia Dayu, Dong Enqing, et al. Non-rigid registrations based on image characteristics and optical flows [J]. *Optics and Precision Engineering*, 2017, 25

- (9): 2469–2482. (in Chinese)
纪慧中, 贾大宇, 董恩清, 等. 基于图像特征和光流场的非刚性图像配准[J]. 光学精密工程, 2017, 25(9): 2469–2482.
- [11] Han Guangliang. Alignment between different source images by high frequency vector matching [J]. *Chinese Optics*, 2011, 4(5): 468–473. (in Chinese)
韩广良. 高频信息矢量匹配实现异源图像配准[J]. 中国光学, 2011, 4(5): 468–473.
- [12] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [J]. *IEEE Computer Vision and Pattern Recognition*, 2016, 90(1): 770–778.
- [13] Yu Siqun, Han Zhi, Tang Yandong, et al. Texture synthesis method based on generative adversarial networks[J]. *Infrared and Laser Engineering*, 2018, 47(2): 0203005. (in Chinese)
余思泉, 韩志, 唐延东, 等. 基于对抗生成网络的纹理合成方法[J]. 红外与激光工程, 2018, 47(2): 0203005.
- [14] Köhler R, Hirsch M, Mohler B, et al. Recording and playback of camera shake: benchmarking blind deconvolution with a real-world database [C]// Conference on Computer Vision–ECCV 2012: 27–40.
- [15] Lai W S, Huang J B, Hu Z, et al. A comparative study for single image blind deblurring [C]//Computer Vision and Pattern Recognition, IEEE, 2016: 1701–1709.