



基于生成式对抗网络的道路交通模糊图像增强

曹锦纲, 李金华, 郑顾平

引用本文:

曹锦纲, 李金华, 郑顾平. 基于生成式对抗网络的道路交通模糊图像增强[J]. 智能系统学报, 2020, 15(3): 491–498.

CAO Jin' gang, LI Jinhua, ZHENG Guping. Enhancement of blurred road-traffic images based on generative adversarial network[J]. *CAAI Transactions on Intelligent Systems*, 2020, 15(3): 491–498.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.201903041>

您可能感兴趣的其他文章

基于小样本学习的LCD产品缺陷自动检测方法

An automatic small sample learning-based detection method for LCD product defects

智能系统学报. 2020, 15(3): 560–567 <https://dx.doi.org/10.11992/tis.201904020>

深度学习的双人交互行为识别与预测算法研究

Human interaction recognition and prediction algorithm based on deep learning

智能系统学报. 2020, 15(3): 484–490 <https://dx.doi.org/10.11992/tis.201812029>

生成对抗网络辅助学习的舰船目标精细识别

Fine-grained inshore ship recognition assisted by deep-learning generative adversarial networks

智能系统学报. 2020, 15(2): 296–301 <https://dx.doi.org/10.11992/tis.201901004>

基于生成对抗网络的机载遥感图像超分辨率重建

Super-resolution reconstruction of airborne remote sensing images based on the generative adversarial networks

智能系统学报. 2020, 15(1): 74–83 <https://dx.doi.org/10.11992/tis.202002002>

隐式特征和循环神经网络的多声部音乐生成系统

A polyphony music generation system based on latent features and a recurrent neural network

智能系统学报. 2019, 14(1): 158–164 <https://dx.doi.org/10.11992/tis.201804009>

基于PCNN的图像椒盐噪声滤除方法

Filtering image impulse noise by using a PCNN image noise reduction technique

智能系统学报. 2017, 12(2): 272–278 <https://dx.doi.org/10.11992/tis.201605027>



关注微信公众号，获取更多资讯信息

DOI: 10.11992/tis.201903041

基于生成式对抗网络的道路交通模糊图像增强

曹锦纲, 李金华, 郑顾平

(华北电力大学 控制与计算机工程学院, 河北 保定 071003)

摘要: 为了提高道路交通模糊图像增强的质量, 进一步促进道路管理, 针对道路交通场景下的运动模糊图像增强问题, 提出了一种基于生成式对抗网络的多尺度多路径学习的模型。首先, 选用具有多尺度卷积核的神经网络, 对输入的图像进行更细致地特征值提取; 其次, 将局部残差学习和全局残差学习相结合, 采用多路径多权重共享的递归学习, 并利用判别网络和生成网络间的对抗训练优化网络参数; 最后, 实现端到端直接生成图像。实验结果表明: 提出的模型可以有效地增强道路交通场景下的运动模糊图像, 生成的图像细节更加丰富, 具有较好的图像视觉效果。

关键词: 图像增强; 道路交通; 运动模糊; 多尺度; 多权重; 残差网络; 神经网络; 生成式对抗网络

中图分类号: TP391 **文献标志码:** A **文章编号:** 1673-4785(2020)03-0491-08

中文引用格式: 曹锦纲, 李金华, 郑顾平. 基于生成式对抗网络的道路交通模糊图像增强 [J]. 智能系统学报, 2020, 15(3): 491-498.

英文引用格式: CAO Jin' gang, LI Jinhua, ZHENG Guping. Enhancement of blurred road-traffic images based on generative adversarial network[J]. CAAI transactions on intelligent systems, 2020, 15(3): 491-498.

Enhancement of blurred road-traffic images based on generative adversarial network

CAO Jin' gang, LI Jinhua, ZHENG Guping

(School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China)

Abstract: To improve the quality of blurred road-traffic images and facilitate road traffic management, we propose a multi-scale multi-path learning model based on a generative adversarial network, which solves the problem of enhancing motion-blur images in road traffic scenarios. First, the model selects a neural network with a multi-scale convolution kernel to extract the eigenvalues of the input image in more detail. Then, by combining local and global residual learning techniques and applying recursive learning with multi-path and multi-weight sharing, the model performs adversarial training between discriminant and generating networks to optimize the network parameters. Lastly, an image is generated directly end to end. The experimental results show that the proposed model can effectively enhance motion-blur images in road traffic scenarios, and the details of the generated image are richer and have better visual effects.

Keywords: enhancement; road traffic; motion blur; multi-scale; multi-weight; residual network; neural network; generated adversarial network

随着科技的飞速发展, 当今社会已迎来新的智能时代, 智能交通系统为智能城市的发展创造了重要条件, 智能交通系统的道路交通信息来源于拍摄设备上传的道路交通图片。由于拍摄设备

抖动或是车辆在行驶的过程中采集到的图像会有不同程度的运动模糊, 这给道路管理带来了极大的不便。同时, 在自动驾驶中, 控制中心是根据车载摄像头拍摄到的道路交通图像来规划行驶路线, 以减轻驾驶员的操作疲劳程度。由于道路中的物体运动, 会造成所拍摄到的图像模糊。将增强的图像应用在自动驾驶感知模块, 可以增

收稿日期: 2019-03-29.

基金项目: 中央高校基本科研业务费专项资金资助项目 (2018MS072).

通信作者: 李金华. E-mail: 1844623784@qq.com.

强自动驾驶的容错力。因此,研究道路交通运动模糊图像的增强对智能城市的进步与发展有着重要的现实意义。

运动模糊图像 I_b 通常可以理解为清晰图像 I_s 和某个模糊核 K 的卷积加上噪声 N 作用的结果^[1], 用数学模型可以表达为 $I_b = I_s \times K + N$ 。对于由于物体运动或摄像设备抖动拍摄出来的运动模糊图片, 去除这类图片的模糊的目标: 一方面是恢复物体原有的边缘结构; 另一方面是增强图像的细节, 使图片具有较好的图像视觉效果。根据模糊核是否已知, 图像去模糊研究可以分为两种, 即盲去模糊和非盲去模糊。盲去模糊是利用模糊图像估计出模糊核, 同时估计出清晰图像, 非盲去模糊是在能获知模糊核的情况下使用^[1]。传统去模糊方法是以图像成像过程的物理模型为基础, 应用各种约束来模拟模糊特征, 利用基于内部图像特定的补丁重现先验^[2]、稀疏梯度先验^[3-4]、空间先验^[5]、最大后验^[6]等其他不同的自然图像先验信息^[7-9]对解空间进行正则化, 利用数学方法, 如概率论、最优化方法等, 通过数学建模来实现图像去模糊。传统方法涉及启发式参数调整和复杂计算, 而且真实情况下的模糊要比建模复杂得多, 因而基于神经网络学习的去模糊方法被提出。早期的方法^[10-12]是通过网络训练学到的参数替换传统框架中的一些步骤, 文献[10]使用深层分层结构, 采用包含了特定图像的反卷积计算来去除图像模糊; 文献[11]使用卷积神经网络(CNN)预测运动模糊的概率分布, 并使用马尔科夫随机场来推断密集非均匀运动模糊场, 将图像先验与非均匀去模糊模型相结合以去图像模糊; 文献[12]采用一种多尺度交错的收缩场级联模型, 其中包含一系列高阶滤波器, 以促进模糊内核和潜像的联合恢复, 但该模型运动离焦模糊处理效果不是很好。模糊图像增强一直以来都是计算机视觉领域内的重要研究课题, 在深度学习大热的背景下, 深度学习模型被应用到计算机视觉与图像处理当中, 使用可训练网络端到端来实现模糊图像增强。文献[13]利用多尺度卷积神经网络(CNN)将模糊图像逐步恢复高分辨率的潜像, 直到达到图像较好的分辨率; 文献[14]使用基于条件生成对抗网络^[15]和多分量损失函数的方法, 进行对抗网络训练, 端到端直接生成清晰图片。

目前针对道路交通场景下的运动模糊图像增强的深度学习研究较少, 而道路交通运动模糊图像的增强有重要价值。为提高道路交通模糊图像

增强的质量, 本文提出了一种基于生成式对抗网络的多尺度提取图像特征值多路径学习的模型。模型通过多尺度卷积核神经网络来进行特征值提取, 采用多路径模式下的局部残差学习与全局残差学习相结合, 进行多权重的递归学习, 判别网络和生成网络间的对抗训练, 最后利用生成网络生成清晰图像。

1 生成式对抗网络

生成式对抗网络(generative adversarial network, GAN)是由Goodfellow等^[16]于2014年设计的一种生成式模型, 其核心思想是二人零和博弈, 生成式对抗网络模型是由一个生成网络 G 和一个判别网络 D 组成。生成网络 G 通过不断学习真实数据的概率分布, 利用学习到的分布模型生成新的数据。判别网络 D 的作用是将真实数据与生成网络 G 生成的数据区别开。判别网络能使生成网络在没有较多的图像先验知识的情况下仍然可以很好地去学习真实数据, 生成网络与判别网络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, 最终使通过生成网络生成的数据可以与真实数据十分相近。生成式对抗网络原始模型框架如图1所示。




图1 GAN结构

Fig. 1 GAN structure

随机噪声向量 Z 输入生成网络 G , 输出 $G(z)$, 当输入判别网络 D 的数据为真实数据 x 时, D 输出 1, 当输入判别网络 D 的数据为 $G(z)$ 时, D 输出 0。生成网络和判别网络利用损失函数进行对抗训练, 网络对抗训练的的目的是使 $G(z)$ 接近真实数据分布 P_{data} 。经过不断对抗训练且迭代优化, 当 D 最终无法判别数据来源时, 认为生成网络已学到真实数据分布。

生成网络 G 的损失函数为

$$\min_G (D, G) = E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (1)$$

判别网络 D 的损失函数为

$$\max_D V(D, G) = E_{x \sim p_{\text{data}}(x)} [\log(D(x))] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (2)$$

模型的总体损失函数为

$$\min_G \max_D V(D, G) = E_{x \sim p_{\text{data}}(x)} [\log(D(x))] J + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (3)$$

式中: E 代表分布函数的期望; P_{data} 代表的是真实数据分布; P_z 代表的是噪声分布。

在最开始的生成式对抗网络研究中, 输入的是随机噪声, 经生成网络映射成图像, 随着生成式对抗网络的发展, 后来越来越多的研究采用图像^[13-14,17-18]或者视频^[19-20]输入代替噪声输入, 这使得生成网络的生成质量和效率得到了进一步提升。

2 基于生成式对抗网络的多尺度多路径模型

2.1 网络结构设计

本文提出的模型整体框架图如图2所示。为了更好地提取出图像数据信息, 本文在设计生成网络中, 主要有2个创新点: 1) 采用多尺度卷积核神经网络进行特征值提取; 2) 使多路径模式的局部残差学习与全局残差学习相结合, 进行多权重的递归学习。利用多尺度卷积核提取特征值的本质是使用不同尺寸的卷积核对图像进行卷积操

作, 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。多路径模式下的局部与全局学习相结合, 采用多权重的递归学习, 实现各卷积层的参数共享, 深浅层特征融合, 采用残差学习, 提高了网络的性能。这些都有利于使模糊增强图像更加清晰和细节更加丰富。本文生成网络框架如图3所示。




图2 本文提出模型的整体框架

Fig. 2 Overall framework of the proposed model

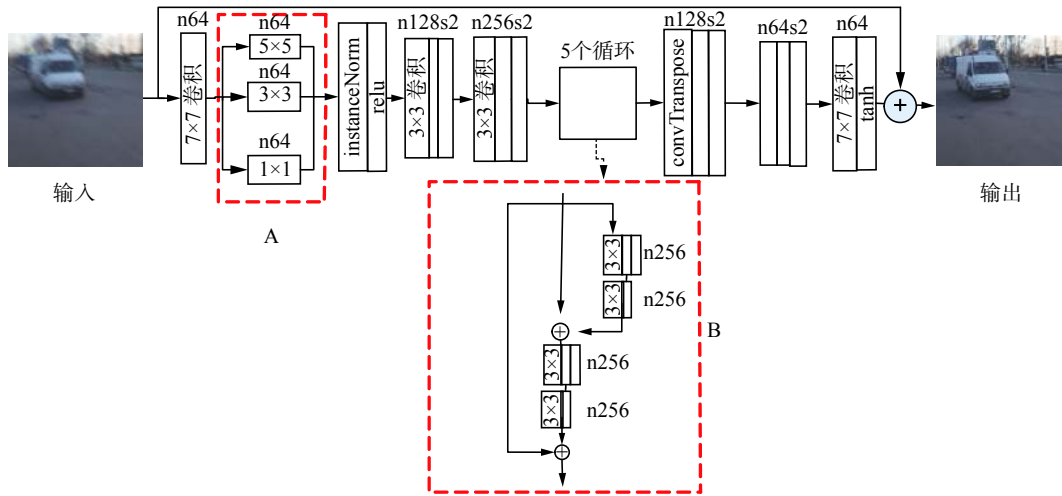


图3 本文提出的生成网络框架

Fig. 3 Diagram of the framework of the generated network

图3中: A部分为多尺度神经网络; B部分为1个多路径模式下的学习; instanceNorm和convTranspose分别代表归一化和反卷积层; n为通道数; s为步长; tanh和relu是激活函数。本文提出的生成网络框架图包含一个卷积核尺寸为 $7 \times 7 \times 64$ 的卷积, 步长为1, 多尺度卷积的卷积核尺寸分别为 $5 \times 5 \times 64$ 、 $3 \times 3 \times 64$ 、 $1 \times 1 \times 64$, 步长为1, 卷积融合后进行instanceNorm和relu处理, 之后进行卷积核尺寸为 $3 \times 3 \times 128$ 、 $3 \times 3 \times 256$ 的卷积处理, 步长为2, 每步卷积跟随instanceNorm和relu处理, 随后进入步长为1、卷积核为 $3 \times 3 \times 256$ 的多路径模式的局部残差学习与全局残差学习, 每步卷

积跟随instanceNorm和relu处理, 经过循环学习5次后, 进行两次步长为2、卷积核为 $3 \times 3 \times 128$ 和 $3 \times 3 \times 64$ 的反卷积操作, 每步反卷积跟随instanceNorm和relu处理, 最后进行一次卷积核为 $7 \times 7 \times 64$ 的卷积和tanh操作。

为充分考虑到像素间的联系, 选用了Path-cGAN^[21]作为判别网络, 其每次只输入 $N \times N$ 个像素点, 然后让判别器对这 $N \times N$ 个像素点判断其是否为真, 采用类似CNN滑窗的方法得到每个 $N \times N$ 框的判别器输出值, 将这些输出值进行平均得到最后判别器的输出结果。本文采用的判别网络框架结构如图4所示。




图 4 判别网络框架

Fig. 4 Framework of the discriminant network

sigmoid 是激活函数。生成网络生成的清晰图像和原清晰图像输入判别网络, 先进行步长为 2、卷积核为 $4 \times 4 \times 64$ 的卷积, 跟随 relu 处理, 之后依次经过步长为 2、卷积核为 $4 \times 4 \times 128$ 、 $4 \times 4 \times 256$ 、 $4 \times 4 \times 384$ 的卷积, 再进行一个步长为 1、卷积核为 $4 \times 4 \times 384$ 的卷积, 每步卷积跟随 instanceNorm 和 relu 处理, 接着经过步长为 1、卷积核为 $4 \times 4 \times 1$ 的一次卷积, 经 flatten、全连接 1、tanh、全连接 2、sigmoid 操作后产生 0~1 之间的值。

2.2 损失函数

本文的损失函数由两部分构成, 即对抗网络损失 L_{adv} 和感知损失 L_c 。

为使训练过程更好地收敛, 采用的是 WGAN-GP^[17] 中的对抗网络损失, 对每个样本独立地施加梯度惩罚, 损失函数为

$$L_{adv} = E_{z \sim p_z(z)} D(G(z)) - E_{x \sim p_{data}(x)} D(x) + \lambda E_{\theta \sim p_\theta} [(\|\nabla_\theta D(\theta)\|_2 - 1)^2] \quad (4)$$

式中: θ 为在 z 和 x 之间随机插值取样; λ 取值为 10。

采用感知损失^[18] 来帮助恢复图像内容, 感知损失是基于生成和目标图像特征映射的差异。它定义为

$$L_c = \frac{1}{W_{i,j} H_{i,j}} \sum_{x=1}^{W_{i,j}} \sum_{y=1}^{H_{i,j}} (\varphi_{i,j}(I_S)_{x,y} - \varphi_{i,j}(G(I_B))_{x,y})^2 \quad (5)$$

先使用 ImageNet 进行预训练 VGG19, 其中 $\varphi_{i,j}$ 是在 VGG19 网络中第 i 个最大池化层之前的第 j 个卷积 (激活之后) 获得的特征图, $W_{i,j}$ 和 $H_{i,j}$ 是特征值, I_B 是模糊图像, I_S 是清晰图像。

模型的总体损失函数为

$$L_{loss} = L_{adv} + \beta L_c \quad (6)$$

3 实验结果与分析

3.1 数据集

现有公开的道路交通模糊图像数据库较少, 为了更好地训练本文的模型, 我们从网络图像库、GoPro 数据集搜集了 3000 对图像组成了数据

集, 每一对图像包含一张模糊图和与之对应的清晰图像。所有数据集图像都是道路交通场景下的图像, 图像中包含道路、行人、车辆等, 其中的 2000 对模糊清晰图像对作为模型的训练集, 剩下的 1000 对作为测试集。在输入神经网络模型之前, 将图像对的分辨率大小设置为 256×256 。

3.2 质量评价

图像的质量评价方法主要分为两种: 一种是主观评价, 另一种是客观评价。主观评价依靠的是观察者的视觉效果来反映图像的质量, 客观评价是通过数学模型定性地评价图像质量。本文采用的是客观评价中常用的 2 种图像质量评价方法, 即峰值信噪比 (PSNR) 和结构相似度 (SSIM), 实验结果数据取的是全部测试图像的平均值。峰值信噪比是通过计算对应像素点间的误差来判断图像质量的好坏, 其值越高表示失真越小, 说明图像与原图越接近。结构相似度是将感知误差的度量转移到对感知结构失真的度量, 其值越大越好。

3.3 网络训练

本文的模型是建立在 pycharm 平台上, 采用深度学习 Keras 框架实现, 选用自适应矩估计 (ADAM) 算法来优化损失函数。通过训练数据不断更新神经网络权重, 经过多次训练调优, 学习率 α 定为 0.0001, $\beta_1=0$, $\beta_2=0.9$ 。采用道路交通模糊图像作为直接输入, 每 50 对图像为一次训练, 设置的最大迭代次数为 1000, 实验步骤如下:

1) 先固定生成网络 G , 不使生成网络 G 的参数更新, 使用原清晰图像训练判别网络 D , 5 次迭代训练保存 1 次参数。

2) 用生成网络 G 生成的清晰图像, 使用生成得到的清晰图像训练判别网络 D , 5 次迭代训练保存 1 次参数。

3) 固定判别网络 D , 不使判别网络 D 的参数更新, 使用损失训练生成网络 G , 5 次迭代训练保存 1 次参数。

4) 重复 1)~3), 直到生成网络 G 可以生成判别网络 D 分辨不出的图像。

为证明本文提出的多尺度多路径模型的优越性, 设置了 3 个对照模型, 命名为模型 b、模型 c 和模型 d, 模型主要区别在图 3 生成网络的 A 和 B 两部分, A 部分网络分为多尺度和非多尺度卷积, B 部分网络分为多路径和链模式学习, 用“√”表示模型中含此部分, 模型分类如表 1 所示。

表 1 模型分类
Table 1 Model classification

多尺度卷积	非多尺度卷积	多路径模式	链模式	算法模型
√		√		提出模型
	√		√	模型b
	√	√		模型c
√			√	模型d

模型 b 与本文提出的网络模型的不同点是: 模型 b 的 A 部分网络结构使用卷积核为 5×5 、 3×3 、 1×1 的卷积依次卷积, B 部分网络结构采用链模式的局部残差学习, 具体模型结构如图 5 所示。




图 5 模型 b 生成网络框架
Fig. 5 Framework of model b generation network

模型 c 与本文提出的网络模型的不同点是: 模型 c 的 A 部分网络结构使用卷积核为 5×5 、 3×3 、 1×1 的卷积依次卷积, B 部分网络结构采用多路径模式的局部残差学习与全局残差学习相结合, 进行多权重的递归学习, 具体不同点的模型结构如图 6 所示。

模型 d 与本文提出的网络模型的不同点是: 模型 d 的 A 部分网络结构使用卷积核为 5×5 、 3×3 、 1×1 的多尺度卷积, B 部分网络结构采用链模式的局部残差学习, 具体不同点的模型结构如图 7 所示。




图 6 模型 c 生成网络框架
Fig. 6 Framework of model c generation network




图 7 模型 d 生成网络框架
Fig. 7 Framework of model d generation network

3.4 结果讨论

首先使用本文自建的数据集分别对本文提出的模型、模型 b、模型 c、模型 d 进行了对照实验, 实验结果如表 2 所示, 图 8 是选取了测试集中的 4 幅图像的实验效果图。

表 2 图像质量评价结果
Table 2 Results of image quality evaluations

模型	PSNR/dB	SSIM
本文算法	27.27	0.899 1
模型b	25.39	0.725 3
模型c	26.62	0.748 3
模型d	25.45	0.730 4

从图 8 中可以看到本文算法模型处理后的图像更加细腻, 边缘的细节较清晰。由表 2 的图像质量评价结果的数据可以看出, 本文算法模型的

峰值信噪比 (PSNR) 是 27.27, 结构相似度 (SSIM) 是 0.899 1, PSNR 和 SSIM 皆高于模型 b、模型 c 和模型 d 的峰值信噪比和结构相似度, 证明了本文提出网络结构的有效性。

为说明本文提出模型的优越性, 我们对 Sun 等^[11]及 Kupyin 等^[14]提出的模型进行了对比实验, 使用上述本文自建的数据集, 实验结果如表 3 所示, 图 9 是选取了测试集中 4 幅图像的实验效果图。

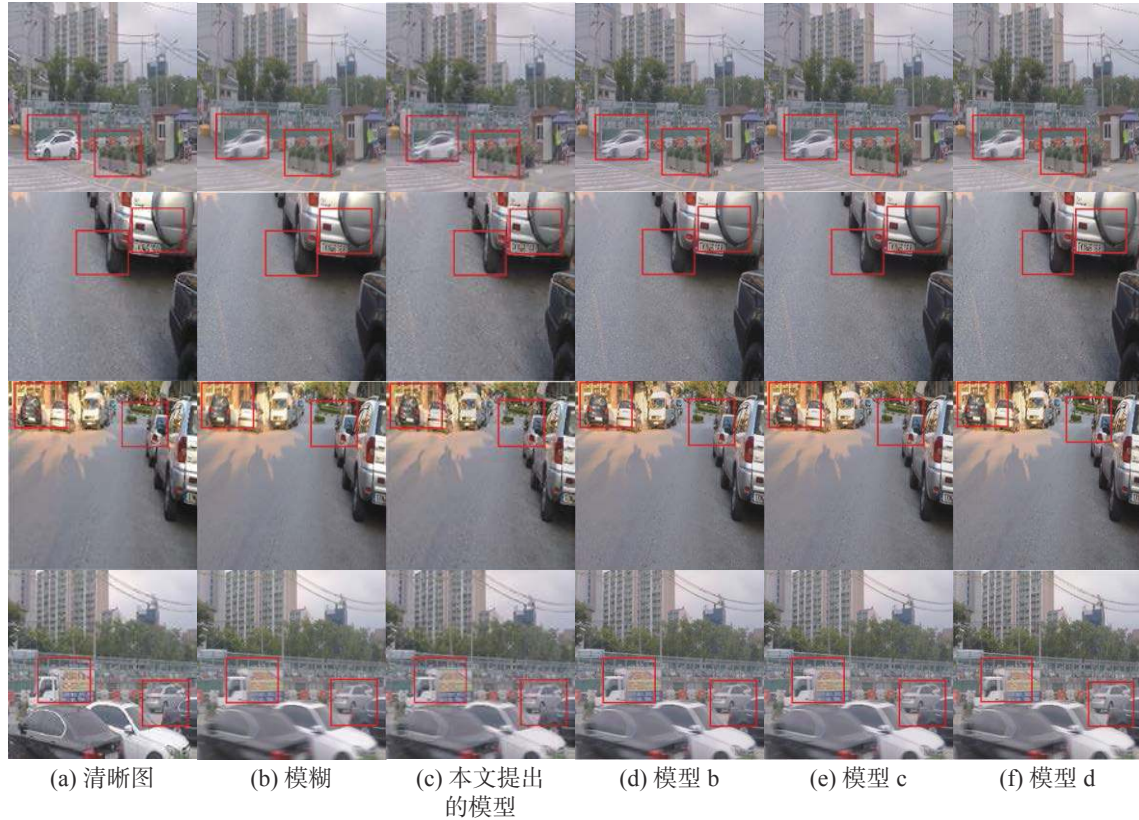


图 8 实验结果对比图

Fig. 8 Comparison of experimental results

表 3 图像质量评价结果

Table 3 Results of image quality evaluations

模型	PSNR/dB	SSIM
本文算法模型	27.27	0.899 1
Sun ^[11]	24.81	0.812 5
Kupyin ^[14]	26.31	0.850 3

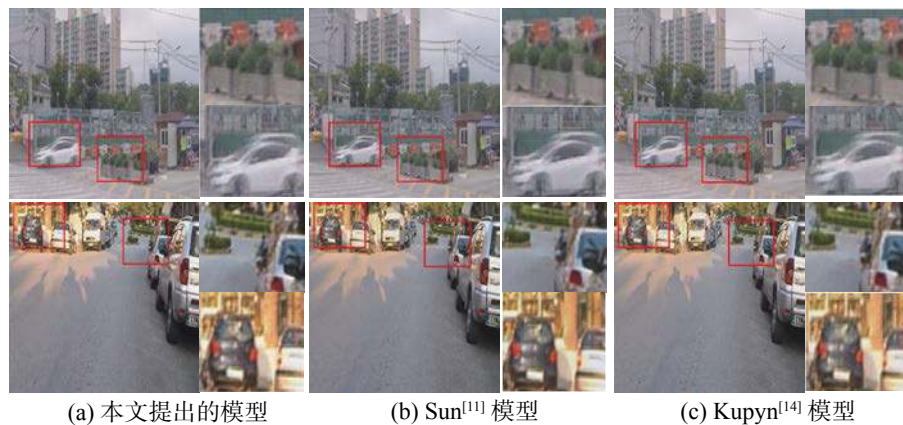


图 9 与其他模型对比结果

Fig. 9 Comparison with other models

从图9中可以看到, Sun等^[11]的方法在处理图像边缘模糊增强时,效果不是很好,细节不够丰富,文献[11]和文献[14]的方法都会出现失真,而经本文模型处理后的图像在主观的视觉感受方面取得了较好的效果。从表3中可以看到, Sun等^[11]提出的模型峰值信噪比为24.81, Kupyn等^[14]提出的模型峰值信噪比为26.31,而本文提出的模型的峰值信噪比达到了27.27,同时本文提出的模型的结构相似度达到了0.8991,皆高于另外两个模型的结构相似度。因此,本文算法模型无论是从峰值信噪比还是从结构相似度上来看都要优于其他的算法。

4 结束语

针对道路交通场景下的模糊图像,基于生成式对抗网络,本文提出了一个利用多尺度提取图像特征值多路径学习的模型,通过判别网络和生成网络间的对抗训练,端到端生成清晰图像。经过实验表明,生成图像的细节更加丰富,无论是主观还是客观,本文提出的模型针对道路交通场景下的模糊图像增强,都取得了较好的效果。虽然实验证明了该算法的优越性,但是生成图像与原始图像相比还存在差距,仍需要进一步优化网络结构和调整参数。

参考文献:

- [1] 陈春雷, 叶东毅, 陈昭炯. 多局部模糊核融合的图像盲去模糊算法[J]. *光子学报*, 2018, 47(10): 205–215.
CHEN Chunlei, YE Dongyi, CHEN Zhaojiong. Blind image deblurring via multi-local kernels' fusion[J]. *Acta photonica sinica*, 2018, 47(10): 205–215.
- [2] BAHAT Y, EFRAT N, IRANI M. Non-uniform blind deblurring by reblurring[C]//Proceedings of 2017 IEEE International Conference on Computer Vision. Venice, Italy, 2017: 3306–3314.
- [3] CHAN T F, WONG C K. Total variation blind deconvolution[J]. *IEEE transactions on image processing*, 1998, 7(3): 370–375.
- [4] CHO S, LEE S. Fast motion deblurring[J]. *ACM transactions on graphics*, 2009, 28(5): 1–8.
- [5] XU Li, JIA Jiaya. Two-phase kernel estimation for robust motion deblurring[C]//Proceedings of the 11th European Conference on Computer Vision. Crete, Greece, 2010: 157–170.
- [6] XU Li, ZHENG Shicheng, JIA Jiaya. Unnatural l0 sparse representation for natural image deblurring[C]//Proceedings of 2013 IEEE Conference on Computer Vision and Pattern Recognition. Portland, USA, 2013: 1107–1114.
- [7] GOLDSTEIN A, FATTAL R. Blur-kernel estimation from spectral irregularities[C]//Proceedings of the 12th European Conference on Computer Vision. Florence, Italy, 2012: 622–635.
- [8] PAN Jinshan, HU Zhe, SU Zhixun, et al. Deblurring text images via l0-regularized intensity and gradient prior[C]//Proceedings of 2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus, USA, 2014: 2901–2908.
- [9] PAN Jinshan, SUN Deqing, PFISTER H, et al. Blind image deblurring using dark channel prior[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA, 2016: 1628–1636.
- [10] SCHULER C J, HIRSCH M, HARMELING S, et al. Learning to deblur[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2016, 38(7): 1439–1451.
- [11] SUN Jian, CAO Wenfei, XU Zongben, et al. Learning a convolutional neural network for non-uniform motion blur removal[C]//Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston, USA, 2015: 769–777.
- [12] XIAO Lei, WANG Jue, HEIDRICH W, et al. Learning high-order filters for efficient blind deconvolution of document photographs[C]//Proceedings of the 14th European Conference on Computer Vision. Amsterdam, The Netherlands, 2016: 734–749.
- [13] NAH S, KIM T H, LEE K M. Deep multi-scale convolutional neural network for dynamic scene deblurring[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA, 2017: 257–265.
- [14] KUPYN O, BUDZAN V, MYKHAILYCH M, et al. DeblurGAN: blind motion deblurring using conditional adversarial networks[C]//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA, 2018: 8183–8192.
- [15] MIRZA M, OSINDERO S. Conditional generative adversarial nets[J/OL]. [2019-03-29]. <https://arxiv.org/abs/1411.1784>.
- [16] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems. Cambridge, USA, 2014: 2672–2680.
- [17] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved

training of Wasserstein GANs[C]//Proceedings of 31st Annual Conference on Neural Information Processing Systems. Long Beach, USA, 2017: 5769–5779.


- [18] JOHNSON J, ALAHI A, LI Feifei. Perceptual losses for real-time style transfer and super-resolution[C]//Proceedings of the 14th European Conference on Computer Vision. Amsterdam, The Netherlands, 2016: 694–711.

- [19] KIM T H, LEE K M, SCHÖLKOPF B, et al. Online video deblurring via dynamic temporal blending network[C]//Proceedings of 2017 IEEE International Conference on Computer Vision. Venice, Italy, 2017: 4058–4067.

- [20] SU Shuochen, DELBRACIO M, WANG Jue, et al. Deep video deblurring for hand-held cameras[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA, 2017: 237–246.

- [21] ISOLA P, ZHU Junyan, ZHOU Tinghui, et al. Image-to-image translation with conditional adversarial networks[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA, 2017: 5967–5976.

作者简介:



曹锦纲, 博士研究生, 主要研究方向为图像处理和模式识别。发表学术论文 10 余篇。



李金华, 硕士研究生, 主要研究方向为图像处理和人工智能。



郑顾平, 教授, 博士, 主要研究方向为图像处理、人工智能、大数据分析。发表学术论文 50 余篇。

新书介绍：联邦学习

在当前大数据驱动的社会环境下, 数据隐私安全成为了全民探讨的重要议题。信息技术的发展, 离不开由我们在智能终端(手机及其他设备等)上产生或推断出的个人数据, 如浏览习惯、点击频次等, 来推动个性化应用和服务的发展。尤其在 AI 领域, 这一情况更为明显, 依赖于持续的数据感知、收集, 并上传至服务端进行深度分析与训练, AI 才能迎来蓬勃发展。但底层未经审查、不透明的数据收集和聚合协议, 很可能造成严重的数据安全威胁和隐私风险。

要解决这样的困境, 仅仅靠传统的机器学习方法已经出现瓶颈。我们需要一个既满足隐私保护和数据安全, 又可实施的解决方案——联邦学习。联邦学习希望做到各个企业的自有数据不出本地, 而联邦系统可以通过加密机制下的参数交换方式, 即在不违反数据隐私法规情况下, 建立一个虚拟的共有模型。这个虚拟模型就好像大家把数据聚合在一起建立的最优模型一样。但是在建立虚拟模型的时候, 数据本身不移动, 也不泄露隐私和影响数据合规, 也就是“数据不动, 模型动”。这样, 建好的模型在各自的区域仅为本地的目标服务。在这样一个联邦机制下, 各个参与者的身份和地位相同, 而联邦系统帮助大家建立了“共同富裕”的策略, 也就是“风险不增, 效益增”。这就是为什么这个体系叫做“联邦学习”。

首部全面、系统论述联邦学习的中文著作《联邦学习》可以作为广大学习者入门和探究联邦学习的第一本书。本书由杨强教授及其团队撰写, 详细描述了联邦学习如何将分布式机器学习、密码学、基于金融规则的激励机制和博弈论结合起来, 以解决分散数据的使用问题。介绍不同种类的面向隐私保护的机器学习解决方案以及技术背景, 并描述一些典型的实际问题解决案例。