

文章编号:1001-9014(2018)04-0427-06

DOI:10.11972/j.issn.1001-9014.2018.04.009

基于生成对抗网络的单帧红外图像超分辨算法

邵保泰^{1,2,3}, 汤心溢^{1,3}, 金璐^{1,2,3}, 李争^{1,3*}

(1. 中国科学院上海技术物理研究所, 上海 200083;

2. 中国科学院大学, 北京 100049;

3. 中国科学院红外探测与成像技术重点实验室, 上海 200083)

摘要:高分辨率红外图像的获取受到了硬件性能的限制,利用信号处理的方法实现红外图像的超分辨率重建可以有效地提高红外图像的分辨率。将基于深度学习的超分辨率方法应用于红外图像,实现了单帧红外图像的超分辨率重建,获得了更好的评价结果。通过引入对抗训练的思想,以及添加基于判别网络的损失函数分量,提高了放大倍数的同时,获得更好的高频细节恢复,图像边缘锐化,避免了超分辨率红外图像过于模糊。

关键词:红外图像;超分辨率重建;深度学习;生成对抗网络

中图分类号:TP391.41 **文献标识码:**A

Single frame infrared image super-resolution algorithm based on generative adversarial nets

SHAO Bao-Tai^{1,2,3}, TANG Xin-Yi^{1,3}, JIN Lu^{1,2,3}, LI Zheng^{1,3*}

(1. Shanghai Institute of Technical Physics, Chinese Academy of Sciences, Shanghai 200083, China;

2. University of Chinese Academy of Sciences, Beijing 100049, China;

3. CAS Key Laboratory of Infrared System Detection and Imaging Technology,
Shanghai Institute of Technical Physics, Shanghai 200083, China)

Abstract: Image processing makes super-resolution infrared image reconstruction effectively improve infrared images resolution, which breaks through hardware performance limits. Based on deep learning, super-resolution method is applied to infrared image, which enables the super-resolution reconstruction of single-frame infrared image. Thus, better evaluation results are acquired. Derived from adversarial thoughts, adding a loss function based on discriminant network can improve magnification, which can access to better high-frequency details of the restoration and can sharpen image edge and avoid blurred super-resolution infrared images.

Key words: infrared image, super resolution, deep learning, GAN

PACS: 42.30.Va, 42.30.Wb, 07.05.Pj

引言

红外图像是探测器接收物体反射或自身发射的红外线而形成的图像,由于它的获取不受外部光线的影响,且温度灵敏度高、探测距离远,因此在监控、遥感等领域有着广泛的应用。但因为红外成像系统

的探测器阵列数目有限且探测单元尺寸受限,红外图像在实际应用中会受到分辨率低的制约,提高红外图像分辨率在遥感、目标检测识别等领域有着迫切的应用需求。

提高红外图像的分辨率有两种途径,第一种是通过提高红外探测器的制作工艺来提高红外成像系

收稿日期:2017-12-12,修回日期:2018-01-31

Received date: 2017-12-12, revised date: 2018-01-31

基金项目:国家十三五国防预研项目(Jzx2016-0404/Y72-2),上海市现场物证重点实验室基金资助项目(2017xcwzk08)

Foundation items: Supported by the National 13th Five Year Defense Prereseach Foundation (Jzx2016-0404/Y72-2), Shanghai Key Laboratory of Criminal Scene Evidence Funded Foundation (2017xcwzk08)

作者简介(Biography):邵保泰(1993-),男,山东莘县人,博士研究生,主要研究方向是图像处理与机器学习。E-mail:shaobaotai@sina.com

* 通讯作者(Corresponding author): E-mail:lizheng_sitp@163.com

统的硬件性能,达到提高红外图像空间分辨率的目的.这种方式需要投入巨大的人力和财力,并且短期内难以实现.第二种方法则是用信号处理或图像处理的方法,运用合适的算法从低分辨率观测图像中重建出高分辨率图像,即图像超分辨率重建(Super Resolution, SR).

单帧图像超分辨率重建是利用信号处理或图像处理的方法,从一幅低分辨率(Low-resolution, LR)图像重建出高分辨率(High-resolution, HR)图像的技术.在可见光图像领域,随着深度学习的广泛应用,利用多层神经网络实现图像的超分辨率重建得到了较好的效果.Chao Dong 等在参考文献[1]中提出利用卷积神经网络(CNN)实现可见光图像的超分辨率重建,他们通过大量的数据训练学习低分辨率图像和高分辨率图像的映射关系.这种方法首先用 bicubic 方法对低分辨率图像预处理,将放大后的图像作为神经网络的输入,经过三层的卷积神经网络得到最后的结果.在此基础上,通过网络优化提升超分辨率性能,如参考文献[2]所见,利用感知损失(perceptual loss)取代最小均方误差(mean-square error, MSE),利用学习到的 upscale 取代 bicubic 插值,得到了更好的结果.在这之后研究者又相继提出 DRCN^[3],ESPCN^[4]等更多层次的网络结构追求更好的结果.在红外图像领域,研究者多利用稀疏编码方法^[5-6]实现超分辨率重建.这种方法利用图像的稀疏性,建立稀疏模型,通过对高分辨率图像字典和低分辨率图像字典及其映射关系的学习实现超分辨率重建.这种方法的关键问题是字典的学习,但一个字典很难捕获红外图像中的所有不同结构,字典的不完备限制了超分辨算法效果.

为了提高红外图像超分辨率重建能力,本文尝试把深度学习方法引入红外领域.利用自建数据集和 CVC-09/14: FIR Sequence Pedestrian Dataset^[8],将在可见光图像超分辨率重建问题上取得良好效果的对抗生成网络(SRGAN)应用于红外图像,并针对红外图像的特点减少数据通道,简化了模型的结构,利用卷积神经网络作为生成网络,实现超分辨率.通过生成网络和判别网络对抗训练的方式提升网络效果,得到超分辨率网络实现对单帧红外图像的超分辨率重建.与以往算法相比,本文算法提升了超分辨率图像效果,获得了更大的放大倍数,同时可以生成图像中的细节,得到更好的视觉效果.

1 生成对抗网络

生成对抗网络(Generative Adversarial Nets,

GAN)是一种概率生成模型,最早在 2014 年由 Ian Goodfellow^[10]引入深度学习领域.普通的 GAN 模型包括了一个生成模型 G 和一个判别模型 D .生成模型 G 进行概率分布的逆变换采样,捕捉样本数据 x 的分布 P_g ,用服从某一分布(均匀分布,高斯分布等)的噪声 z 生成一个类似真实训练数据的样本 $G(z, \theta_g)$,追求效果是越像真实样本越好;判别模型 $D(x, \theta_d)$ 是一个二分类器, $D(x)$ 表示 x 来自于真实数据的概率,如果样本来自于真实的训练数据 x , $D(x)$ 输出大概率,否则输出小概率.生成对抗网络的训练过程本质上是训练 D 来最大化判别正确率,同时训练 G 来最小化 $\log(1 - D(G(z)))$,即 D 和 G 的训练是关于值函数 $V(G, D)$ 的极小极大的博弈问题:

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

换言之, D 和 $z \sim p_z(z)$ G 的理想训练结果应使得 GAN 模型能够产生“以假乱真”的数据样本.在超分辨率重建问题上,基于生成对抗网络的模型同样由生成网络 G 和判别网络 D 组成,结构如图 1 所示.生成器的输入为低分辨率图像 I^{LR} ,输出为高分辨率重建图像 I^{SR} .判别模型的输入为原始高分辨率图像 I^{HR} 和高分辨率重建图像 I^{SR} ,输出则为对输入图像的来源判断.对二者的训练是求解式(2)的极小极大问题:

$$\min_G \max_D E_{I^{\text{HR}} \sim P_{\text{data}}(I^{\text{HR}})} [\log D(I^{\text{HR}})] + E_{I^{\text{LR}} \sim P_G(I^{\text{LR}})} [\log(1 - D(G(I^{\text{LR}}))] \quad . \quad (2)$$

式(2)的意义是训练一个生成模型 G 和一个判别模型 D ,判别模型 D 是为了分辨出超分辨率图像和真实高清图像,而生成模型 G 的目的则是不断产生尽可能接近真实高清图像的超分辨率图像,直到产生的超分辨率图像能够欺骗判别模型 D ,使 D 无法分辨出图像的真实来源.这种通过对抗训练的方法和普通的基于学习的超分辨率重建方法不同,普通的基于学习的超分辨率重建方法追求最小化均方误差,本文算法在此基础上添加了基于判别网络的损失函数分量,改进为基于视觉的损失函数.

本文中,建立的网络模型可以生成具有高分辨率的看似自然采集的图像.因为生成网络可以生成高频细节,所以结果更接近自然图像.该方法采用多层次卷积网络作为超分辨率重建的生成器,同时利用对抗生成网络的概念设计一个新的基于视觉的损失函数.第 2 节介绍算法原理,第 3 节介绍实验和超分辨率图像质量评价.

2 算法原理

在单帧红外图像超分辨率问题中,目标是由低分辨率输入图像 I^{LR} 估计一个高分辨率的超分辨率图像 I^{SR} . 这里 I^{LR} 是由与其对应的高分辨率图像 I^{HR} 以 r 倍的下采样因子下采样获得的, 高分辨率图像只在训练中使用。训练的最终目标是获得生成模型 G , 为此训练一个前向传播的多层卷积神经网络 G_{θ_G} 作为生成模型, 其中 $\theta_G = \{\mathbf{W}_{1:L}; b_{1:L}\}$ 是 G_{θ_G} 的参数, 表示一个 L 层深度卷积网络的权重和偏置项。参数 θ_G 通过训练过程中对损失函数 l^{SR} 的优化获得, 而在训练过程中, 对图像 $I_n^{HR}, n=1, \dots, N$ 和 $I_n^{LR}, n=1, \dots, N$ 的训练, 实际上是解决下式:

$$\hat{\theta}_G = \arg \min_{\theta_G} \frac{1}{N} \sum_{n=1}^N l^{SR}(G_{\theta_G}(I_n^{LR}), I_n^{HR}) \quad . \quad (3)$$

2.1 网络结构

将卷积神经网络作为生成模型, 改进生成对抗网络, 利用基于视觉的损失函数指导训练。该网络利用生成对抗网络的框架结构, 如图 1 所示。

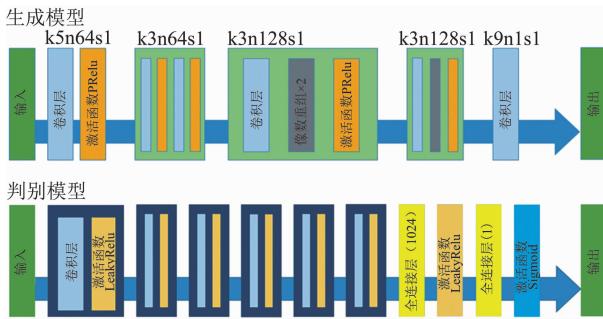


图1 生成网络和判别网络结构图, k 为卷积核尺寸, n 为卷积核数量, s 为步长

Fig. 1 Architecture of the generator and discriminator network with corresponding kernel size (k), number of feature maps (n) and stride (s) indicated for each convolutional layer

设计的生成模型由 3 层卷积层和两层亚像素卷积层(sub-pixel convolutional layer)构成。生成模型的输入为低分辨率图像 I^{LR} , 它可以完成以下操作:

1) 小块映射和表示: 该操作可以从低分辨率图像 I^{LR} 提取小块, 并将每个小块表示为高维向量, 这些向量包括一组数量和向量维度相等的特征。选择通过一组卷积核对图像进行卷积, 然后以 PReLU 作为激活函数, 即:

$$F_1(I^{LR}) = \max(0, \mathbf{W}_1 * I^{LR} + b_1) + \alpha_1 * \min(0, \mathbf{W}_1 * I^{LR} + b_1) \quad . \quad (4)$$

2) 其中, \mathbf{W}_1, b_1 分别表示卷积核和偏差, \mathbf{W}_1 大

小为 $1 * k_1 * k_1 * n_1$, k_1 为卷积核的空间尺寸, n_1 为卷积核数量。 α_1 为激活函数 PReLU 中的可学习参数。

3) 非线性映射: 该操作可以将每个高维向量非线性映射到另一高维向量。每个映射向量为高分辨率图像小块的表示, 我们采用两个卷积网络层实现非线性映射:

$$\begin{aligned} F_2(I^{LR}) &= \max(0, \mathbf{W}_2 * F_1(I^{LR}) + b_2) + \\ &\quad \alpha_2 * \min(0, \mathbf{W}_2 * F_1(I^{LR}) + b_2) \\ F_3(I^{LR}) &= \max(0, \mathbf{W}_3 * F_2(I^{LR}) + b_3) + \\ &\quad \alpha_3 * \min(0, \mathbf{W}_3 * F_2(I^{LR}) + b_3) \end{aligned} \quad . \quad (5)$$

4) 重建: 该操作聚集高分辨率小块并产生高分辨率图像 I^{SR} , I^{SR} 预期与 I^{HR} 相似。我们利用两个亚像素卷积层对图像进行 4 倍放大。

为了区分真实的 HR 图像和生成的 SR 样本, 参考文献[7]设计了如图所示的判别模型。判别模型作为一个二分类器, 是为了解决式(2)中的最大值问题, 选择通过 6 个卷积层提取图像特征, 最后将提取到的 512 维特征利用两个全连接层和 sigmoid 激活函数获得样本分类的概率。

2.2 损失函数

损失函数的定义对于生成对抗网络的表现性能是极其重要的, 如式(6)所见, 生成模型的训练过程就是对损失函数的优化过程。传统方法中应用最广泛的是基于 MSE 的损失函数, 它反映原图像和超分辨率图像之间的均方误差, 均方误差越小, 表示超分辨率图像越接近原图像, 反之超分辨率图像与原图像的相似度越低。该损失函数可以定义为:

$$l_{MSE}^{SR} = \frac{1}{r^2 w h} \sum_{x=1}^{rw} \sum_{y=1}^{rh} (I_{x,y}^{HR} - G(I_{x,y}^{LR}))^2 \quad . \quad (6)$$

传统方法往往能够获得更好的峰值信噪比(Peak Signal to Noise Ratio, PSNR), 但是结果会因为缺乏高频细节而过于平滑, 得不到很好的视觉效果。在此基础上, 引入一个新的基于视觉特性损失函数^[7], 它包括基于 MSE 的损失和基于判别网络的损失两个分量:

$$l^{SR} = l_{MSE}^{SR} + 10^{-3} l_{gen}^{SR} \quad , \quad (7)$$

式中, l_{gen}^{SR} 定义为 $\sum_{n=1}^N -\log D(G(I^{LR}))$, 其中 $D(G(I^{LR}))$ 表示生成的超分辨率图像来自于真实数据的概率, $D(G(I^{LR}))$ 越大, l_{gen}^{SR} 也就越小, 生成的超分辨率图像也就更接近真实图像的视觉效果。通过引入基于判别网络的损失分量, 生成模型将更容易产生能够

“欺骗”判别模型的图像数据,这样以来,生成的图像数据也就更接近真实图像,具有更好的视觉效果.

3 实验

3.1 数据

目前,可供选择的公开的红外图像数据集较少,本文选择了自建红外数据集,以及 CVC-09/14 数据集中的红外部分. 其中自建红外数据集采集于“初航”制冷型红外相机,所有的数据集都是街景红外图像,包含行人、汽车、交通标识和建筑等. 其中,选取 CVC-09 数据集中 6 000 张红外图像作为训练集的高分辨率图像,对高分辨率图像下采样得到训练集的低分辨率图像,下采样因子为 4. 同时,选取 CVC-14 数据集和自建数据集的部分红外图像下采样得到测试集,下采样因子也为 4. 使用了 PSNR 和 SSIM 两种评价算法对超分辨率图像进行评价,同时使用 bicubic, SRSC, SRCNN 网络得到的超分辨率图像作为结果对比,其中, SRCNN 网络为本文描述的生成模型,但在训练过程中未使用对抗网络提高效果,即损失函数仅为 l_{MSE}^{SR} .

3.2 训练细节和参数

训练过程是在一块 NVIDIA GTX 960 GPU 上完成的. 对于生成网络,设置 (k_1, n_1) 为 $(5, 64)$, (k_2, n_2) 和 (k_3, n_3) 为 $(3, 64)$, 如图 1 所示. 训练前,先对输入图像进行归一化处理,将输入图像像素的灰度取值范围线性映射到 $[0, 1]$. 在训练过程中,为了避免直接训练 SRGAN 容易陷入局部最优解,首先训练 SRCNN 网络,在训练时,随机选取 16 幅 $96 * 96$ 的高清子图像作为小批次进行训练. 因为采取了完全卷积的方式,所以此网络可以应用于任意大小的图像. 优化过程中选取 $\beta_1 = 0.9$ 的 Adam 算法^[9], 学习速率为 10^{-4} , 迭代次数为 100 000, 训练过程损失函数变化曲线如图 4(a)所示. 在训练 SRGAN 网络时,我们利用训练好的 SRCNN 网络作为初始化的生成模型,对生成模型和判别模型进行交替训练,学习速率为 10^{-5} , 迭代次数为 2 000 000, 训练过程损失函数变化曲线如图 4(b)、(c)、(d)所示,其中(b)为判别网络损失函数变化曲线,(c)为生成网络基于 MSE 的损失函数分量变化曲线,(d)为生成网络基于判别网络的损失函数分量变化曲线. 测试过程中不再使用批处理方式,这样确保输出结果仅仅取决于输入图像的大小.

3.3 质量评价

超分辨率图像质量是判别超分辨率重建算法性能

的重要指标. 超分辨率图像质量的评价方法可以分为主观评价方法和客观评价方法. 主观评价方法指通过实验人员的主观感受来评价图像质量; 客观评价方法则是设计算法模型, 依据量化指标衡量图像质量. 本文选取了两种常用的全参考图像质量评价算法来对红外超分辨率图像进行计算.

峰值信噪比(PSNR)是一种基于对应像素点间的误差的图像客观评价指标. MSE 越小, PSNR 越大, 表示图像越接近于对比图像.

结构相似性(structural similarity, SSIM)分别从亮度、对比度、结构三个方面度量图像的相似性. SSIM 取值范围为 $[0, 1]$, 值越大, 表示图像越接近于对比图像.

3.4 结果讨论

随机选取 CVC-14 中的 9 张图像和自建数据集中的 7 张图像, 利用 3.3 节质量评价算法验证超分辨率重建算法性能. 评价结果如表 1 所示. 可以看到相比于 bic 和 SRSC, SRGAN 与 SRCNN 效果有了显著的提高. 但在 PSNR 这一项评价标准上, SRGAN 的表现不如 SRCNN, 这是因为两者选用了相同的网络结构, SRCNN 的损失函数为 l_{MSE}^{SR} , 追求超分辨率图像可以得到最小的 MSE 值, 但 SRGAN 引入了基于判别网络的损失函数 l_{gem}^{SR} , 其中 l_{MSE}^{SR} 和 l_{gem}^{SR} 分量的比例为 $1:10^{-3}$. 而 PSNR 值是和 MSE 值相关的, MSE 越小, PSNR 越大, 所以 SRCNN 方法可以获得更好的 PSNR 值.

表 1 超分辨率结果列表

Table 1 List of SR results

		bic	SRSC	SRCNN	SRGAN
CVC-14	PSNR	22.42	21.76	26.92	26.15
	SSIM	0.86	0.83	0.88	0.89
	PSNR	27.72	27.16	30.66	30.38
	SSIM	0.85	0.82	0.86	0.88

超分辨率重建结果如图 2 所示, 使用 SRGAN 方法得到的超分辨率图像整体感受最接近于原图, 从细节上观察图中近处的标识牌、灯杆、路沿、树木和远处的建筑、路灯等, 本文算法得到了几种方法中最好的重建效果. 更显著的图像细节可以观察图 3, 对于车辆边缘, bicubic 方法得到的结果最为模糊, 而 SRGAN 方法得到的结果最为锐利. 观察 SRCNN 和 SRGAN 两种算法的超分辨率图像发现, 使用 SRCNN 方法得到的图像稍显平滑, 但 PSNR 值最高, 使用 SRGAN 得到的图像在高频细节还原上更加逼真, 但 PSNR 值略小. 这是因为 PSNR 值是一种对误差敏感

的图像质量评价算法,并没考虑到人眼的视觉特性,因此其结果会出现与人眼观察不一致的情况。由于人眼视觉对边缘信息的敏感性,所以 SRGAN 的结果在主观评价上更好。

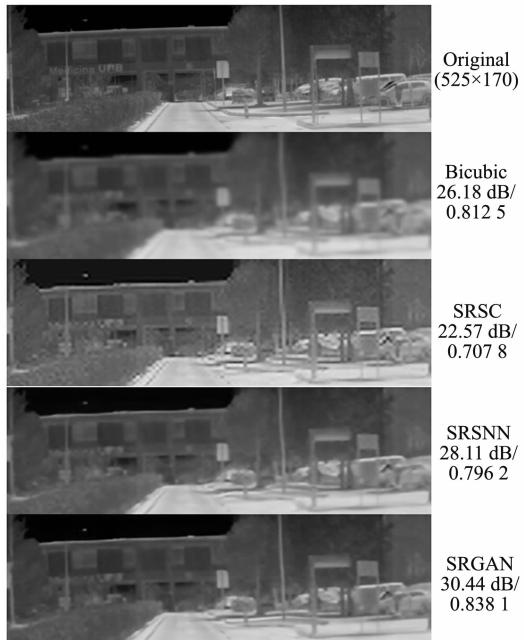


图2 单帧红外图像超分辨率重建结果图

Fig. 2 Super resolution results from single frame infrared image

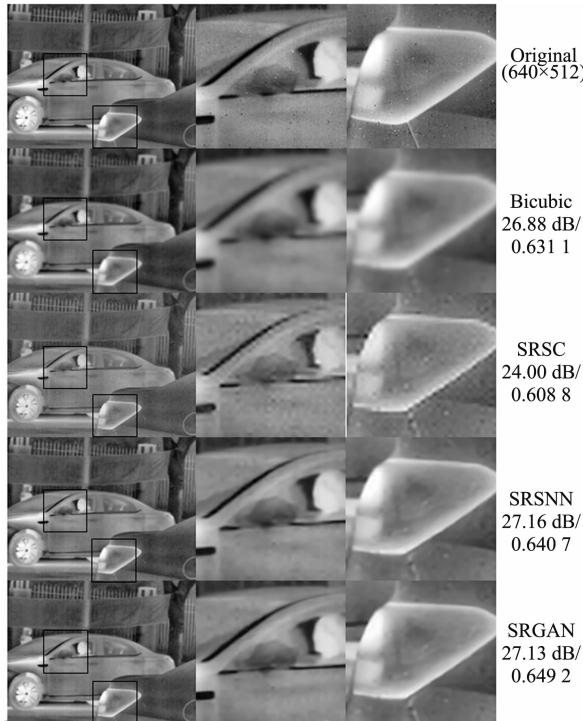


图3 原始高清图像和 Bicubic, SRSC, SRCNN 和 SRGAN 方法重建结果及细节图

Fig. 3 Bicubic, SRSC, SRCNN and SRGAN reconstruction results and the corresponding reference HR image. (4×upscale)

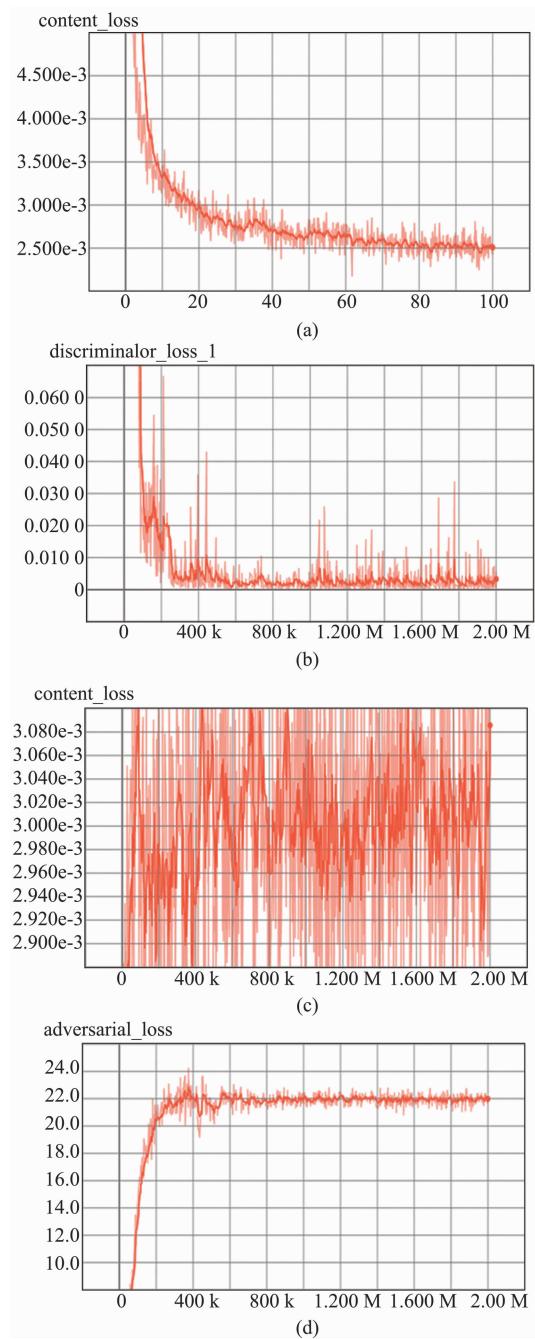


图4 (a) SRCNN 训练情况,(b)、(c)、(d) SRGAN 训练情况

Fig. 4 (a) Loss function of SRCNN,(b)、(c)、(d) loss function of SRGAN

4 结论

将深度学习方法应用于红外图像的超分辨率问题,学习了低分辨率图像到高分辨率图像的映射。同时引入对抗训练的思想,通过判别网络和生成网络对抗训练的方式提高了超分辨网络对图像细节的恢复能力,实现了大倍数的图像放大,并获得了更好的

结果。然而相比于可见光图像，红外图像的数据集较少，可供训练的图像数据不够丰富，红外成像质量较低等问题仍然制约了超分辨网络性能的进一步提高。除此之外，网络结构、训练方式的调整也会影响网络的超分辨能力，通过调整和优化网络结构和训练方式，单帧红外图像的超分辨能力仍有较大的提升空间。

References

- [1] Dong C, Chen C L, He K, et al. Learning a deep convolutional network for image super-resolution [J]. *European Conference on Computer Vision*, 2014, **8692**:184–199.
- [2] Dong C, Chen C L, He K, et al. Image super-resolution using deep convolutional networks[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2016, **38**(2):295.
- [3] Kim J, Lee J K, Lee K M. Deeply-recursive convolutional network for image super-resolution[C] *Computer Vision and Pattern Recognition. IEEE*, 2016:1637–1645.
- [4] Shi W, Caballero J, Huszar F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C] *Computer Vision and Pattern Recognition. IEEE*, 2016:1637–1645.
- [5] Deng Cheng-Zhi, Tian Wei, Wang Sheng-Qian, et al. Super-resolution reconstruction of approximate sparsity regularized infrared image[J]. *Opt. Precision Eng.* (邓承志, 田伟, 汪胜前, 等. 近似稀疏正则化的红外图像超分辨率重建. 光学精密工程), 2014, **22**(6):1648–1654.
- [6] Deng C Z, Tian W, Chen P, et al. Infrared image super-resolution via locality-constrained group sparse model[J]. *Acta Phys Sin* (邓承志, 田伟, 陈盼, 等. 基于局部约束群稀疏的红外图像超分辨率重建. 物理学报), 2014, **63**(4):144–151.
- [7] Ledig C, Theis L, Huszar F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]. *Computer Vision and Pattern Recognition. IEEE*, 2016: 4681–4690.
- [8] Socarras Y, Ramos S, Vazquez D, et al. Adapting pedestrian Detection from synthetic to far infrared images[C]. In *ICCV-Workshop on Visual Domain Adaptation and Dataset Bias*. Sydney, Australia, 2013.
- [9] Kingma D P, Ba J. Adam: A method for stochastic optimization[J]. *Computer Science*, 2014.
- [10] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. *Advances in Neural Information Processing Systems*, 2014, **3**:2672–2680.

(上接第 426 页)

- [4] Ackerson K, Musante C, Gambino J, et al. Characterization of "blinking pixels" in CMOS image sensors [J]. *Proc. IEEE/SEMI Adv. Semicond. Manuf. Conf.* 2008: 255–258.
- [5] LENG Han-Bing, GONG Zhen-Dong, XIE Qing-Sheng, et al. Adaptive blind pixel detection and compensation for IRFPA based on fuzzy median filter[J]. *Infrared and Laser Engineering*, (冷寒冰, 宫振东, 谢庆胜, 等. 基于模糊中值的IRFPA自适应盲元检测与补偿. 红外与激光工程) 2015, **44**(3):821–826.
- [6] LI Xue, SHAO Xiu-Mei, TANG Heng-Jing, et al. Inoperable pixels of 256×1 element linear InGaAs near-infrared focal plane arrays. [J]. *Journal of Infrared and Millimeter Waves*, (李雪, 邵秀梅, 唐恒敬, 等. 近红外 256×1 元 InGaAs 焦平面探测器无效像元研究. 红外与毫米波学报) 2011, **30**(5):409–411+438.
- [7] LI Ling-Xiao, FENG Hua-Jun, ZHAO Ju-Feng, et al. Adaptive and fast blind pixel correction of IRFPA. [J]. *Optics and Precision Engineering*. (李凌霄, 冯华君, 赵巨峰, 等. 红外焦平面阵列的盲元自适应快速校正. 光学精密工程) 2017, **25**(04):477–486.
- [8] CUI Kun, CHEN Fan-Sheng, SU Xiao-Feng, et al. A fast screening method of pixels with unstable response rate in IRFPA. [J]. *Infrared Technology*. (崔坤, 陈凡胜, 苏晓锋, 等. 红外焦平面探测器响应率不稳定像元快速筛选方法. 红外技术) 2017, **39**(02):130–135.
- [9] GUO Liang, LI Dong-Bing, YANG Wei, et al. Alternative method of linear TDI infrared detector blind pixel. [J]. *Laser and Infrared*. (郭亮, 李冬冰, 杨微, 等. 线列 TDI 型红外探测器组件坏元替代方法. 激光与红外) 2015, **45**(7):809–813.
- [10] ZHENG Wei. Research on image enhancement algorithm based on line array infrared detector. [J]. *Laser and Infrared*. (郑为. 基于线列红外探测器的图像增强算法研究. 激光与红外) 2015, **45**(01):84–87.
- [11] ZHOU Da-Biao, WANG De-Jiang, HUO Li-Jun, et al. Nonuniformity correction method based on gradient scenes. [J]. *Acta Optica Sinica*. (周达标, 王德江, 霍丽君, 等. 基于梯度场景的非均匀校正方法. 光学学报) 2017, **37**(05):346–355.
- [12] LENG Han-Bing, YI Bo, XIE Qing-Sheng, et al. Adaptive nonuniformity correction for infrared images based on temporal moment matching. [J]. *Acta Optica Sinica*. (冷寒冰, 易波, 谢庆胜, 等. 基于时域矩匹配的红外图像自适应非均匀性校正. 光学学报) 2015, **35**(04):123–128.
- [13] QIN Yan, DENG Ru-Ru, HE Ying-Qing, et al. Piecewise linear dynamic moment matching desriping. *Journal of Image and Graphics*. (秦雁, 邓孺孺, 何颖清, 等. 分段线性动态矩匹配条带去除. 中国图象图形学报) 2012, **17**(11):1444–1452.
- [14] Li Y, Zhang Y, Yu J G, et al. A novel spatio-temporal saliency approach for robust dim moving target detection from airborne infrared image sequences [J]. *Information Sciences*, 2016, **369**(C):548–563.
- [15] Samson V, Champagnat F, Giovannelli J F. Point target detection and subpixel position estimation in optical imagery. [J]. *Applied Optics*, 2004, **43**(2):257–63.
- [16] Novak L M, Halversen S D, Owirka G, et al. Effects of polarization and resolution on SAR ATR[J]. *IEEE Transactions on Aerospace & Electronic Systems*, 1997, **33**(1):102–116.