

❖ 特约专栏 ❖

生成式对抗神经网络的多帧红外图像超分辨率重建

李方彪^{1,2}, 何 昕¹, 魏仲慧¹, 何家维¹, 何丁龙¹

(1. 中国科学院长春光学精密机械与物理研究所, 吉林 长春 130033;

2. 中国科学院大学, 北京 100049)

摘 要: 生成式对抗神经网络在约束图像生成表现出了巨大潜力, 使得其适合运用于图像超分辨率重建。但是使用生成式对抗神经网络重建后的超分辨率图像存在过度平滑, 缺少高频细节信息的缺点。针对单帧图像超分辨率重建方法不能有效利用图像序列间的时间-空间相关性的问题, 提出了一种基于生成式对抗神经网络的多帧红外图像超分辨率重建方法(M-GANs)。首先, 对低分辨率图像序列进行运动补偿; 其次, 使用权值表示卷积层对运动补偿后的图像序列进行权值转换计算; 最后, 将其输入生成式对抗重建网络, 输出重建后的高分辨率图像。实验结果表明: 文中方法在主观及客观评价中均优于当前代表性的超分辨率重建方法。

关键词: 超分辨率重建; 深度学习; 生成式对抗神经网络; 红外成像

中图分类号: TP391 **文献标志码:** A **DOI:** 10.3788/IRLA201847.0203003

Multiframe infrared image super-resolution reconstruction using generative adversarial networks

Li Fangbiao^{1,2}, He Xin¹, Wei Zhonghui¹, He Jiawei¹, He Dinglong¹

(1. Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, China;

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

Abstract: Generative adversarial networks had shown promising potential in conditional image generation. It seemed that the GANs were particularly suitable for use in image super-resolution reconstruction. However, there was a shortcoming of excessive smoothness and lack of high frequency detail information for the reconstructed SR images by using GANs. Aiming at resolving the problem that the method of single image super-resolution reconstruction ignored the spatio-temporal relationship between image frames, a method of multiframe infrared image super-resolution reconstruction based on generative adversarial networks (M-GANs) was proposed in this paper. Firstly, motion compensation was proposed for registration low resolution image frames; Secondly, a weight representation convolutional layer was performed to calculate the weight transfer; Finally, the generative adversarial network was used to reconstruct the high resolution image. Experimental results demonstrate that the proposed method surpass current state-of-the-art performance of both subjective and objective evaluation.

Key words: super-resolution reconstruction; deep learning; generative adversarial networks; infrared imaging

收稿日期: 2017-08-05; 修订日期: 2017-10-09

基金项目: 国家自然科学基金(61405191)

作者简介: 李方彪(1990-), 男, 博士生, 主要从事数字图像处理及超分辨率图像重建方面的研究。Email: lifangbiao1215@163.com

导师简介: 何昕(1966-), 男, 研究员, 博士生导师, 主要从事图像处理、光电测量等方面的研究。Email: hexin6627@sohu.com

0 引言

图像超分辨率重建技术是指由单帧或者多帧低分辨率图像通过信号处理等方式重建获取高分辨率图像的方法。相较于减小像素尺寸及增大芯片尺寸等通过改变硬件设施来提高图像分辨率的方法,超分辨率重建技术属于软件方法,具有范围广、成本低的优势^[1],被广泛应用于视频监控^[2]、显微成像^[3-4]、医学图像处理^[5]及遥感成像^[6-7]等领域。

1984 年, Tsai 和 Huang 首次在频域中完成了基于低分辨率图像序列的图像超分辨率重建, 获取了分辨率更高的图像。至此, 图像超分辨率重建技术受到了研究者的广泛关注, 随着对图像超分辨率重建技术的深入研究, 大量的超分辨率重建方法相继被提出。目前, 超分辨率重建技术的研究重点主要集中在于空域, 重建算法可分为三大类: (1) 基于插值^[8-9]; (2) 基于重建^[10-12]; (3) 基于学习^[13-16]。

基于插值的图像超分辨率重建技术由于方法简单、重建速度快的优势最早被提出, 但其重建效果欠佳, 重建精度不高。随后, 人们提出了基于概率论的信息处理方法, 并扩展出了大量的基于重建的重建方法, 通过不断迭代将低分辨率图像逼近于高分辨率图像, 该方法获取的高分辨率图像精度较高。

随着深度学习方法在计算机视觉领域中表现出的巨大潜力, 以深度学习为基础的超分辨率重建技术受到了研究者们越来越多的关注。Dong^[17]等人提出了一种端到端的图像超分辨率重建方法 (Super-Resolution Convolutional Neural Network, SRCNN), 通过训练包括三个卷积层的网络完成了对单帧低分辨率图像的超分辨率重建。在 Dong 等人的研究基础上, Kappeler^[18]等人通过增加运动补偿等方式将网络扩展为多帧输入, 并完成了视频序列图像的超分辨率重建。Shi 和 Caballero^[19]等人通过增加亚像素卷积层减少了低分辨率图像上采样的过程, 增加了图像超分辨率重建的效率。接下来, 他们通过增加空间-时间网络及运动补偿将 ESPCN (Efficient Sub-pixel Convolutional Neural) 扩展为针对视频图像的实时超分辨率重建网络 (Video Efficient Sub-pixel Convolutional Neural, VESPCN)^[20]。Ledig^[21]等人将生成式对抗网络用于超分辨率重建问题, 通过改进代价函数, 使其重建网络适用于放大倍数较大的情况,

且重建后高分辨率图像的视觉效果非常真实。虽然人们提出了很多基于深度学习的超分辨率重建方法, 但其研究的对象主要还是基于单帧图像的超分辨率重建技术, 而基于多帧图像的超分辨率重建方法较少。

文中提出了一种基于生成式对抗神经网络的多帧红外图像超分辨率重建方法, 通过增加图像之间的空间-时间信息及运动补偿, 将多帧红外低分辨率图像输入生成式对抗神经网络, 从而获取具有高分辨率的红外图像。实验结果表明, 文中方法能有效完成多帧红外图像的超分辨率重建, 与对比方法相比较, 由于增加了图像间信息, 其重建后的高分辨率图像视觉效果真实, 性能评价指标高。

1 重建网络结构

基于学习的超分辨率重建方法能有效引入外部训练样本的细节信息, 提高图像分辨率。生成式对抗神经网络通过生成器生成高分辨率图像后, 经判别器判别, 使得重建后高分辨率图像的视觉效果真实自然, 但其质量评价标准不高。文中方法将生成式对抗神经网络扩展至多帧图像超分辨率重建, 有效利用低分辨率图像序列之间的空间-时间相关性, 使得重建后的高分辨率图像不仅视觉效果真实, 且具有较高的图像质量评价指标。

图 1 为多帧红外图像超分辨率重建过程的流程图, 低分辨率图像序列经过图像配准及运动补偿 (MC) 后形成一组排列图像, 在生成式对抗网络前增




图 1 多帧重建网络工作流程图

Fig.1 Flowchart of multiframe reconstruction network

加权值表示的卷积层, 对低分辨率图像序列进行加权值计算, 将序列图像表示为单幅低分辨率图像形式,

以此作为生成式对抗网络的输入信息,经训练后的超分辨率重建网络获取具有更高分辨率的红外图像,完成红外图像的超分辨率重建。图 1 所示的是输入为九帧低分辨率图像,经过超分辨率重建后形成一帧放大倍数为 3×3 的高分辨率图像。

2 超分辨率重建方法

如第 1 章所述,文中所提出的多帧红外图像超分辨率方法主要可分运动补偿、权值计算及图像超分辨率重建。运动补偿对低分辨率图像序列进行配准;权值计算可融合低分辨率图像序列之间的不同信息,充分利用图像序列之间的空间-时间相关性;超分辨率重建网络引入外部学习信息,增强重建图像的视觉真实性。

2.1 运动补偿

图 2 所示为输入两帧低分辨率图像时的运动补偿过程,首先对两帧图像进行运动估计,以第一帧图像为基准,利用运动估计参数对第二帧图像进行运




图 2 运动补偿示意图

Fig.2 Schematic diagram of motion compensation

动转换,完成图像间的运动补偿。运动补偿网络的训练过程即对运动估计参数 θ_i 的最优化过程,运动空间变换可表示为:

$$I'_{t+k} = T_{\theta_i}(I_{t+k}) \quad (1)$$

式中: I'_{t+k} 为 I_{t+k} 经运动变换 $T_{\theta_i}(I_{t+k})$ 后的低分辨率图像; $T(\cdot)$ 为六参数仿射变换模型。文中运动补偿网络的损失函数使用正则化方法表示,则最优化运动估计参数过程为:

$$\theta_i^* = \operatorname{argmin}_{\theta_i} \|I_t - I'_{t+k}\|_2^2 + \lambda \|Q I'_{t+k}\|_2^2 \quad (2)$$

式中: θ_i^* 为运动参数的最优化估计; λ 为正则化参数; Q 为拉普拉斯算子。将公式(2)右边对运动参数 θ_i^* 微分,并令其结果为 0,采用最速梯度下降法对其迭代求解,从而获取最优运动参数 θ_i^* 。

2.2 超分辨率重建网络

超分辨率重建网络主要由权值表示卷积层和生成式对抗重建网络组成,其示意图如图 3 所示。低分辨率图像序列经过运动补偿后输入重建网络,经过权值表示层时对低分辨率图像序列进行权值表示,由对抗式生成网络的生成器生成超分辨率图像,然后由判别器对生成的超分辨率图像进行判别,判断所生成的图像是否真实,最后输出重建后的高分辨率图像,完成多帧图像的超分辨率重建。




图 3 超分辨率重建网络示意图

Fig.3 Schematic diagram of super-resolution reconstruction network

2.2.1 权值表示

多帧图像超分辨率重建技术能有效利用图像序列之间的空间-时间相关性,通过融合图像序列之间的不同信息,从而提高图像分辨率。如图 3 所示,为了充分利用低分辨率图像序列之间的不同信息,文中在生成式对抗神经网络之前增加了权值表示卷积层,对输入的多帧低分辨率图像进行权值计算,其形式可表示为:

$$X(m, n) = \sum_{k=0}^{K-1} \omega_k(m, n) I_{t+k}(m, n) \quad (3)$$

式中: $\omega_k(m, n)$ 为低分辨率图像序列的每一块图像块所对应权值,输入低分辨率图像序列总数为 K 。 m, n 表示图像块所对应的序列号 ($m \in 0, \dots, M-1$; $n \in 0, \dots, N-1$),当低分辨率图像大小为 W, H 时,则低分辨率图像块对应大小为 $W/M, H/N$ 。

2.2.2 生成式对抗网络

生成式对抗网络由 Goodfellow^[22]等人首先提出,主要由生成器 G 和判别器 D 组成,通常将其表示为最小-最大问题,其数学表达式可表示为:

$$\min_G \max_D E_{x \sim P_r} [\log(D(x))] + E_{\tilde{x} \sim P_g} [\log(1 - D(\tilde{x}))] \quad (4)$$

式中: P_r 表示真实的数据类; P_g 为生成的数据类。将生成式对抗网络应用到超分辨率重建问题,其表达式可表示为:

$$\min_{\theta_g} \max_{\theta_d} E_{I^{LR} \sim P_{r_g}(I^{LR})} [\log(D_{\theta_d}(I^{LR}))] + E_{I^{LR} \sim P_g(I^{LR})} [\log(1 - D_{\theta_d}(I^{LR}))] \quad (5)$$

式中: I^{HR} 表示高分辨率图像; I^{LR} 表示低分辨率图像; θ_G 为生成器参数; θ_D 为判别器参数。重建网络的损失函数由均方误差表示, 则生成器网络损失函数为:

$$\hat{\theta}_G = \operatorname{argmin}_{\theta_G} \frac{1}{N} \sum_{n=1}^N \|G_{\theta_G}(I_n^{HR}, \theta_G) - I_n^{HR}\|_2^2 \quad (6)$$

与 Christian^[21]等人类似, 文中使用的判别器网络损失函数包括三个部分: 均方损失 l_{MSE}^{SR} 、对抗损失 l_{Gen}^{SR} 及规则项 l_{TV}^{SR} 。其表达式为:

$$l^{SR} = l_{MSE}^{SR} + 10^{-3} l_{Gen}^{SR} + 10^{-6} l_{TV}^{SR} \quad (7)$$

其中

$$l_{MSE}^{SR} = \frac{1}{r^2 WH} \sum_{x=1}^{rW} \sum_{y=1}^{rH} (I_{x,y}^{HR} - G_{\theta_G}(I^{LR})_{x,y})^2 \quad (8)$$

$$l_{Gen}^{SR} = \sum_{n=1}^N -\log G_{\theta_D}(G_{\theta_G}(I^{LR})) \quad (9)$$

$$l_{TV}^{SR} = \frac{1}{r^2 WH} \sum_{x=1}^{rW} \sum_{y=1}^{rH} \|\nabla G_{\theta_G}(I^{LR})_{x,y}\| \quad (10)$$

3 实验结果及分析

文中进行的超分辨率重建实验所使用的低分辨率图像序列数量为九帧, 即超分辨率重建实验分辨率的放大倍数为 3×3 。为了验证文中提出方法的有效性, 将文中方法(M-GANs)与不同的重建方法进行对比: 双三次插值(Bicubic)、凸集投影法(Projections Onto Convex Sets, POCS)、卷积网络超分辨率重建法(Video Super-Resolution network, VSRnet)和单帧生成式对抗网络重建法(Generative Adversarial Networks, GANs)。对比算法中, Bicubic 算法为超分辨率重建方法中典型的基于插值的方法; POCS 为典型基于重建的超分辨率重建算法; 而 VSRnet 与 GANs 为基于学习的图像超分辨率重建方法, 其中 VSRnet 为多帧重建方法, GANs 为单帧重建方法。

实验数据集: 文中使用的训练数据集主要来源于 <http://decsai.ugr.es/cvg/dbimagenes/>。其中包括 266 幅图像, 将每张在 X 轴与 Y 轴方向分别进行 1 个像素与 2 个像素的位移, 如此可得到九帧具有相对位移的图像, 对其进行 X 轴与 Y 轴方向上的 3 倍下采样, 可获得具有亚像素位移的九帧低分辨率图像。实验测试数据集主要由实际拍摄图像构成。

网络训练: 超分辨率重建网络输入为图像块数据, 文中使用的图像块大小为 36×36 。初始学习率设为 10^{-4} , 并且随着每 10 000 次迭代后, 学习率下降

5%。为了平衡网络的收敛性及训练时间, 将超分辨率重建的最大迭代次数设置为 10^6 。运动补偿网络的损失函数使用公式(2), 计算当前帧与参考帧之间的光流场差对当前帧进行运动补偿, 主要过程与参考文献[20]类似。对于 GAN 的训练, 文中使用的方法与参考文献[21]相同。

质量评价: 峰值信噪比 (Peak Signal to Noise Ratio, PSNR) 通常用来评价图像间的灰度相似性, 而结构相似性指数 (Structure Similarity Image Measure, SSIM) 通常用来评价图像间的结构相似性。因此, 文中同时选用 PSNR 及 SSIM 对实验结果进行评价, 其表达式如下:

$$PSNR = 10 \log_{10} \frac{255^2 \times W \times H}{\sum_{i=1}^W \sum_{j=1}^H [x(i,j) - \tilde{x}(i,j)]^2} \quad (11)$$

$$SSIM = \frac{(2\mu_x\mu_x + C_1)(2\sigma_{xx} + C_2)}{(\mu_x + \mu_x + C_1)(\sigma_x^2 + \sigma_x^2 + C_2)} \quad (12)$$

图 4 为文中方法 M-GANs 与传统 GANs 在不同迭代次数下重建高分辨率图像的 PSNR, 曲线图中的 PSNR 为网络训练图像集 266 帧图像的平均值。由图可知, 文中方法与传统 GANs 重建的高分辨率图像随着迭代次数的提高, 图像质量评价指标不断提高, 增加程度不断减小, 直到重建图像趋于平稳的质量效果, 即图像重建效果随着迭代次数不断增加而趋于收敛。




图 4 不同迭代次数重建图像的 PSNR

Fig.4 PSNR of reconstructed images in different iteration

表 1 表示放大倍数为 3 时, 文中方法与三种对比方法对部分测试红外图像的 PSNR 质量评价, 表 2 表示文中方法与三种对比方法对部分测试红外图像的 SSIM 质量评价。如表 1 及表 2 所示, 对比 4 种不同超分辨率重建方法所重建的高分辨率图像, 文中方法 PSNR 和 SSIM 评价价值均为最优值, 即 GANs 能利用多帧低分辨率图像有效重建出高分辨率图像, 且重建效果优于当前代表性方法。

表 1 测试图像的 PSNR 评价结果(单位: dB)

Tab.1 Evaluation results of PSNR on the test images (Unit: dB)

Images	Bicubic	POCS	VSRnet	GANs	M-GANs
Robot	29.189	33.218	34.095	28.872	35.286
Hollow	21.565	24.352	25.370	21.359	25.508
Pot-plant	31.089	34.725	36.597	30.674	37.211
Woman	31.954	37.860	39.354	31.869	40.137
Tele-pole	34.821	39.673	40.947	35.161	41.394

表 2 测试图像的 SSIM 评价结果

Tab.2 Evaluation results of SSIM on the test images

Images	Bicubic	POCS	VSRnet	GANs	M-GANs
Robot	0.961 2	0.974 7	0.976 8	0.973 3	0.982 2
Hollow	0.558 7	0.678 0	0.748 3	0.593 1	0.757 0
Pot-plant	0.928 1	0.950 2	0.962 4	0.944 7	0.966 2
Woman	0.923 9	0.952 6	0.961 9	0.931 2	0.966 8
Tele-pole	0.950 3	0.971 4	0.977 3	0.963 4	0.979 1

同时, 经过对比 3 种不同类型的超分辨率重建方法可发现, 相较于基于插值及基于重建的方法, 基于学习的多帧超分辨率图像重建方法(VSRnet 和 GANs)所重建的高分辨率图像, 在 PSNR 和 SSIM 质量评价上都具有优势。这是因为深度学习对于外部样本具有很好的学习能力, 充分融合了学习样本的有效信息。

图 5~9 为部分测试红外图像使用不同超分辨率重建方法获取的高分辨率红外图像。在所选取的 5 组实验中, 图 5(a)~9(a)为原始高分辨率红外图像, 对图 5(a)~9(a)中图像进行整像素位移后对其下采样, 可获得具有亚像素位移的低分辨率图像序列, 文中实验所采用的重建倍数为 3×3, 即原始高分辨率图像在水平及垂直方向分别进行 1 个像素和 2 个像素位移, 再对高分辨率图像序列进行 3 倍下采样, 从而获取九帧具有亚像素位移的低分辨率红外图像。

为了更好的对比不同方法的重建效果, 选择局部具有边缘细节的图像进行放大显示, 选择区域为矩形框标记区域(大小为 30×30), 放大效果图显示在图像右下角。对比实验图 5~9 中不同方法的重建




图 5 “机器人”图像使用不同超分辨率重建方法的重建结果及质量评价(PSNR 和 SSIM), 尺度因子为 3, 图像大小为 480 pixel×480 pixel

Fig.5 Reconstructed result and quality evaluation (PSNR and SSIM) of "Robot" image by different super-resolution reconstruction approaches, upscaling factor is 3, image size is 480 pixel×480 pixel




图 6 “山川”图像使用不同超分辨率重建方法的重建结果及质量评价(PSNR 和 SSIM),尺度因子为 3,图像大小为 420 pixel×420 pixel
 Fig.6 Reconstructed result and quality evaluation (PSNR and SSIM) of "Cordillera" image by different super-resolution reconstruction approaches, upscaling factor is 3, image size is 420 pixel×420 pixel




图 7 “盆栽”图像使用不同超分辨率重建方法的重建结果及质量评价(PSNR 和 SSIM),尺度因子为 3,图像大小为 750 pixel×561 pixel
 Fig.7 Reconstructed result and quality evaluation (PSNR and SSIM) of "Potted plant" image by different super-resolution reconstruction approaches, upscaling factor is 3, image size is 750 pixel×561 pixel



图 8 “女人”图像使用不同超分辨率重建方法的重建结果及质量评价 (PSNR 和 SSIM), 尺度因子为 3, 图像大小为 399 pixel×279 pixel

Fig.8 Reconstructed result and quality evaluation (PSNR and SSIM) of "Woman" image by different super-resolution reconstruction approaches, upscaling factor is 3, image size is 399 pixel×279 pixel




图 9 “电线杆”图像使用不同超分辨率重建方法的重建结果及质量评价 (PSNR 和 SSIM), 尺度因子为 3, 图像大小为 630 pixel×510 pixel

Fig.9 Reconstructed result and quality evaluation (PSNR and SSIM) of "Telegraph pole" image by different super-resolution reconstruction approaches, upscaling factor is 3, image size is 630 pixel×510 pixel

效果可知, 基于插值的方法重建后的高分辨率图像边缘较模糊, 图像细节显示不清晰; 基于重建的 POCS 方法重建后图像相较于插值法图像更清晰, 边缘更尖锐; 基于学习的方法重建后的图像效果最佳, 由于 VSRnet 重建方法引入了图像序列之间的空间-时间相关性, 其重建后的高分辨率图像较单帧 GANS 重建法重建的图像具有更高的质量评价指

数。相较而言, 使用文中方法获取的高分辨率图像不仅具有最高的质量评价指数, 且具有清晰分明的图像边缘及丰富的细节信息, 视觉效果真实。

4 结 论

文中提出了一种使用生成式对抗神经网络的多帧红外图像超分辨率重建方法。通过对低分辨率图

像序列进行运动补偿及权值表示,从而引入图像序列之间的时间-空间相关性。再将运动补偿后的低分辨率图像序列作为生成式对抗重建网络的输入,通过训练后的重建网络完成对低分辨率图像序列的超分辨率重建,获得具有高度真实视觉效果的高分辨率图像。为了说明所提超分辨率重建方法的重建效果,文中将所提算法与不同超分辨率重建方法在主观评价与客观评价(峰值信噪比及结构相似性指数质量评价)进行对比实验,实验结果说明文中方法重建后的图像不仅具有边缘锐度更高,视觉效果更清晰自然的主观效果,同时客观评价上也具有最高的质量评价价值。

参考文献:

[1] Chandra M S, Rajan K, Srinivasan R. Locally adaptive regularization for robust multiframe super resolution reconstruction [J]. *Advances in Computer Science, Eng & Appl*, 2012, AISC166: 223-234.

[2] Xiao C, Yu J, Xue Y. A high-efficiency super-resolution reconstruction algorithm from image/video sequences [C]// Third International IEEE Conference on Signal-Image Technologies and Internet-Based System, 2008: 573-581.

[3] Luo W, Zhang Y, Feizi A, et al. Pixel super-resolution using wavelength scanning[J]. *Light: Science & Application*, 2016, 5(4): e16060.

[4] Zhaoghao K, Chen L, Yang X S, et al. Super-resolution dipole orientation mapping via polarization demodulation[J]. *Light: Science & Application*, 2016, 5(10): e16166.

[5] Ashikaga H, Estner H L, Herzka D A, et al. Quantitative assessment of single-image super-resolution in myocardial scar imaging [J]. *Medical Imaging and Diagnostic Radiology*, 2014, 2(1): 1-12.

[6] Lei Sen, Shi Zhenwei, Zou Zhengxia. Super-resolution for remote sensing images via local-global combined network[J]. *IEEE Geosciences and Remote Sensing Letters*, 2017, 14(8): 1243-1247.

[7] Pan Z, Yu J, Huang H, et al. Super-resolution based on compressive sensing and structural self-similarity for remote sensing images [J]. *IEEE Transactions Geosci and Remote Sensing Letters*, 2013, 51(9): 4864-4876.

[8] Zhou F, Yang W M, Liao Q M. Interpolation-based image super-resolution using multisurface fitting [J]. *IEEE Transactions on Image Processing*, 2012, 21(7): 3312-3318.

[9] Freedman G, Fattal R. Image and video upscaling from local self-examples[J]. *TOG*, 2011, 28(2): 1-11.

[10] Liu Xueting, Song Daojin, Dong Chuandai, et al. MAP-based image superresolution reconstructions [J]. *International Journal of Computer Science Engineering*, 2008, 2(1): dai: 10.1999/1307-6892/2034.

[11] Simon Baker, Takeo Kanad. Limits on super-resolution and how to break them [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, 24(9): 1167-1183.

[12] Marcia L S A, Neison D A. Mascarenhas, generalization of iterative restoration techniques for super-resolution [C]// SIBGRAPI Conference on Graphics, Patterns and Images, 2011: 258-265.

[13] Yang J C, Wright J, Huang T S, et al. Image super-resolution via sparse representation [J]. *IEEE Signal Processing Magazine*, 2010, 19(11): 2861-2873.

[14] Timofte R, Smet V D, Gool L V. Anchored neighborhood regression for fast example-based super-resolution[C]// IEEE International Conference on Computer Vision, 2013: 1920-1927.

[15] Wang Xinwei, Cao Yinan, Lu Dezhen, et al. Spatial difference shaping to improve range resolution in 3D super-resolution range-gated imaging [C]//2015 International Conference on Optical Instruments and Technology: Optoelectronic Imaging and Processing Technology, 2015, 9622: 1-8.

[16] Zhang Di, He Jiazhong. Hybrid sparse-representation-based approach to image super-resolution reconstruction[J]. *Journal of Electronic Imaging*, 2017, 26(2): 02308.

[17] Dong Chao, Chen Change Loy, He Kaiming, et al. Image super-resolution using deep convolutional networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(2): 295-307.

[18] Kappeler A, Yoo Seunghwan, Dai Qiqin, et al. Video super-resolution with convolutional neural networks [J]. *IEEE Transactions on Computational Imaging*, 2016, 2(2): 109-122.

[19] Shi Wenzhe, Caballero J, Huszar F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 1874-1883.

[20] Caballero J, Ledig C, Aitken A, et al. Real-time video super-resolution with spatio-temporal networks and motion compensation [C]//Computer Vision and Pattern Recognition, 2017, arXiv preprint arXiv: 1611. 05250v2.

[21] 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, 2016, arXiv preprint arXiv: 1609. 04802v1.

[22] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks [C]//Machine Learning, 2014, arXiv preprint arXiv: 1406. 2661v1.