

基于GAN的视景图像超分辨率重建方法研究

雷华成¹, 刘伟¹, 张云水¹, 陈贤龙², 黄胜²

¹珠海翔翼航空技术有限公司, 广东 珠海

²重庆邮电大学通信与信息工程学院, 重庆

收稿日期: 2022年11月15日; 录用日期: 2022年12月15日; 发布日期: 2022年12月22日

摘要

飞行模拟器是一种用于复现飞行器及空中环境并能够进行模拟飞行操作的装置, 在基于飞行模拟器系统进行日常飞行模拟训练时, 视景系统所呈现出来的图像质量的好坏将直接影响最终的训练效果。图像超分辨率重建是一种能提升图像质量的有效手段。结合生成对抗网络(GAN)在视觉效果上有着很好的优越性, 提出一种基于GAN的视景图像超分辨率重建方法, 以提高飞行模拟视景图像显示效果。整个网络由生成器和鉴别器构成, 其中生成器由浅层特征提取部分、深层特征提取部分和图像重建三个部分组成, 鉴别器采用相对鉴别的思想实现对真伪图像的鉴别。在不同测试集上的实验结果表明, 该方法不仅在视觉效果上优于RDN、DRFN等网络, 同时, 在客观评价指标上也优于它们。

关键词

视景系统, 生成对抗网络, 视景图像, 超分辨率重建

Research on Super Resolution Reconstruction Method of Visual Image Based on GAN

Huacheng Lei¹, Wei Liu¹, Yunshui Zhang¹, Xianlong Chen², Sheng Huang²

¹Zhuhai Xiangyi Aviation Technology Company Limited, Zhuhai Guangdong

²School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing

Received: Nov. 15th, 2022; accepted: Dec. 15th, 2022; published: Dec. 22nd, 2022

Abstract

Flight simulator is a kind of simulation device which can reproduce aircraft and air environment

文章引用: 雷华成, 刘伟, 张云水, 陈贤龙, 黄胜. 基于 GAN 的视景图像超分辨率重建方法研究[J]. 计算机科学与应用, 2022, 12(12): 2804-2812. DOI: 10.12677/csa.2022.1212285

and simulate flight operation. In the daily flight simulation training based on flight simulator system, the quality of the image presented by the visual system will directly affect the final training effect. Image super-resolution reconstruction is an effective method to improve image quality. Combined with the advantages of Generative Adversarial network (GAN) in visual effects, a super resolution reconstruction method of visual image based on GAN is proposed to improve the visual image display effect of flight simulation. The entire network is composed of generator and discriminator, of which the generator is composed of three parts: shallow feature extraction part, deep feature extraction part and image reconstruction, and the discriminator adopts the idea of relative discrimination to achieve the identification of true and false images. Experimental results on different test sets show that the proposed method is not only superior to RDN, DRFN and other networks in terms of visual effects, but also better than them in objective evaluation indicators.

Keywords

Visual System, Generative Adversarial Network, Visual Image, Super Resolution Reconstruction

Copyright © 2022 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

飞行模拟器是一种可以在地面模仿飞机的飞行状态、条件和环境的特殊装置，其可以通过相应的技术手段逼真的再现飞机的飞行特征。飞行模拟器的关键主要是依赖于视景系统对外部环境的模拟，飞行员有 70% 以上的信息来自于视觉，而外部环境的模拟主要是以视景图像的方式进行呈现，这就造成了飞行模拟器对图像的质量提出了更高的要求，更真实的、分辨率高的、质量更好的图像对飞行训练有着更有效的作用[1]。通过对模拟器的改进，如：增加光学设备和投影设备等组件，虽然能增强图像的分辨率，改善图像的质量，但这并不是一个最优的解决方案，因为合理的成本和模拟器的大小也是需要考虑的[2]。为解决这个问题，本文使用一种叫做超分辨率重建的方法，用于从低分辨率图像中恢复出高分辨率图像，恢复后的图像拥有更高的图像质量和更好的视觉效果。使用超分辨率技术克服原始分辨率的限制，是一个极具挑战性的过程[3]。

图像超分辨率重建方法除传统方法[4]外，在深度学习领域主要分为：PSNR 导向和感知驱动导向[5]。PSNR 导向主要是指通过对 CNN 网络进行优化，如：SRCNN [6]、EDSR [7]、RDN [8]、MSFRN [9]和 RFN [10]等。这些方法虽然在 PSNR 上取得了卓越的性能，但图像的视觉效果较差，易出现伪影，时间开销也较大。感知驱动是指以生成质量较好的图像为目标，如：SRGAN [11]、LPIPS [12]、ESRGAN [13]、SPSR [5]、和 F_ESRGAN [14]等，然而这些网络最终生成的图像虽有着很好的视觉效果，但在 PSNR 上的值并不高。为此，本文结合 PSNR 导向所体现出的特点以及视景图像在视觉效果上的高要求，提出一个基于 GAN 的视景图像超分辨率重建网络，其主要贡献点包括：

- 1) 提出了一种基于 GAN 的视景图像超分辨率重建模型，通过全局和局部的特征融合，并结合对抗思想中的相对鉴别理论，该模型不仅能充分利用图像的特征信息，提高图像的最终重建能力，更能结合人类的感光视觉的特性，生成效果较好的图像。
- 2) 设计了一种深层特征提取模块，在残差块内引入注意力机制，并通过使用低维度的方式，引入较少的计算量，从而提升整体性能。
- 3) 设计了一种层次特征融合模块，在 1×1 卷积后，对特征进行分割，接着使用一个高维度的注意

力机制进行特征的提取,使得网络能恢复出更清晰的高频细节。

2. 基于 GAN 的网络模型

2.1. 网络结构

本文结合了对抗网络的思想,提出了一种基于 GAN 的视景图像超分辨率重建方法 GAN-RDCN,其网络整体结构如图 1 所示,整个网络由两个部分构成:生成器 Generator 和鉴别器 Discriminator,其中,生成器由 3 个部分构成:浅层特征提取部分、深层特征提取部分和图像重建部分。浅层特征提取部分由一个 3×3 的卷积组成,实现对输入图像的浅层特征提取。深层特征提取部分是由多个深层特征提取模块 RDCA 和层次特征融合模块 HSCA 组成,实现对输入图像特征的充分提取和复用。图像重建部分主要由亚像素卷积层实现图像的放大。




Figure 1. Overall network structure

图 1. 网络整体结构图

为了使最终得到的图像能更接近真实图像,拥有更好的视觉效果,本文采用了 GAN 网络中鉴别器的真伪鉴别方法,将生成器生成的图片与原始地面图像送入鉴别器进行真伪方面的鉴别,通过一种判断其是真是假的方式来得到本文最终所需要的超分辨率图像[13]。

2.2. 特征提取模块

网络结构中的深层特征提取模块是整个网络中最重要的特征提取部分,如何有效的提取原始输入图像的特征,直接关系到最终的图像重建效果。为此,为了能更有效的提取输入图像的特征并对图像信息进行有效的复用,本文借鉴了 Gu 等人所提出的 RFCB 模块[10],RFCB 是一个残差分形卷积模块,是一个非常优秀的特征提取模块,但其内部并没有对特征信息进行充分的复用。为此,本文对其子模块 RU 进行改进,提出了一个增强型的 RDCA 模块,相比于原有的 RFCB 模块,RDCA 模块考虑了通道间不同特征信息的比重,做到了对信息的复用,并在不增加大量参数量的情况下,对网络的整体性能进行了相应的提升。

特征提取模块结构如图 2 所示,模块中的 RB 表示的是本文在原有的 RFCB 模块中的 RU 基础上进行改进后提出的一个新的子模块 RB。单个 RB 模块的结构如图 3 所示。

RB 模块是一个由残差学习和通道注意力机制相结合所构成的特征提取模块,RB 模块一开始是用两个 3×3 的卷积和一个 Relu 激活函数,接着用一个 1×1 的卷积对所传入的特征进行降维,降维后的信息将以较少的参数量传入通道注意力机制,并实现相应性能的提升。

最后, 将 RB 模块中第一个 1×1 卷积的输出和经 Sigmoid 函数进行相乘得到相应的特征信息, 再使用一个 1×1 卷积将特征信息的维度升为一开始输入的特征信息的维度, 将升维后的信息与一开始输入的信息进行相加得到 RB 模块最终输出的信息。




Figure 2. Feature extraction module RDCA

图 2. 特征提取模块 RDCA




Figure 3. RB module

图 3. RB 模块

2.3. 层次特征融合模块

图像超分辨率重建中, 分层特征信息的充分利用可以进一步提升网络整体结构的性能, 如何使用层次间的特征信息对最终的重建有着很重要的影响。目前, 已有的图像超分辨率重建中对层次特征进行处理的, 使用最多的是仅使用一个 1×1 的卷积对分层特征进行压缩, 这种方法并不能提取有效的特征, 也不利于最终的图像重建。为此, 本文设计了一个层次特征融合模块用于对层次间的特征信息进行处理, 模块结构如下图 4 所示。




Figure 4. Hierarchical feature fusion module

图 4. 层次特征融合模块

层次特征融合模块主要是对级联后的信息进行处理, 首先使用一个 1×1 的卷积对信息进行维度变换。

接着,采用类似于坐标轴上的 X 轴和 Y 轴的方向对升维后的特征信息进行分割,得到类似于矩阵中的行矩阵和列矩阵所表示的特征信息,对分割后的信息分别进行平均池化和标准差的计算,得到相应的特征信息。接着将这两个级联后的特征信息通过混洗机制进行混洗,以使通道间的信息联系更加紧密,对混洗后的信息使用两个 1×1 的卷积和分割操作来对不同通道间的特征进行处理。其中,第一个 1×1 的卷积将特征维度变为原来的 $1/r$ (r 表示维度压缩比例, $r = 16$),经 Relu 激活函数进行激活操作后,将信息以 X 轴和 Y 轴的形式进行分割,对分割后的信息分别使用一个 1×1 卷积将特征信息的维度进行复原。然后,使用 Sigmoid 函数对特征信息进行重新表示。

最后,将重新表示后的特征信息与第一次分割之前的特征信息进行依次相乘后得到包含重要特征的信息。接着,通过一个 1×1 的卷积对其进行降维,得到最终所需输出的信息。

2.4. 损失函数

神经网络的训练离不开损失函数,合适的损失函数可以使网络得到更好的训练和更好的网络性能。本文所提出的重建方法是基于 GAN 的思想进行设计的,整个网络涉及的损失函数有对抗性损失和生成器损失。

对抗性损失采用 ESRGAN 中所提出的方法[13],分为鉴别器和生成器两个部分,生成器的对抗性损失与鉴别器的对抗性损失呈对称形式。

生成器损失由感知损失、生成器的对抗性损失和 L_1 损失函数构成,感知损失是采用 L_{LPIPS} 损失函数[12]用于定义图像的感知相似度。则,整个生成器的损失函数由式(1)表述:

$$L_G = L_{LPIPS} + \lambda L_G^r + \mu L_1 \quad (1)$$

其中, λ 和 μ 是平衡不同损失项的系数。 L_{LPIPS} 损失函数是一个在视觉相似判断上更接近人类感知,是一个真正意义上的以符合人类判断的方式对图像的相似度进行衡量的“感知距离”损失函数。

3. 实验结果和分析

3.1. 实验设置

3.1.1. 数据集

虽然视景系统中的视景图像所包含的范围一般是 180° 的半全景图像,但通过扁平化以及切割等技术处理,半全景图像则近似等于一个或多个平常的二维平面图。

因此,在实验中,本文采用了 DIV2K [15]和 Flickr2K [16]作为整个网络的训练集,总共有 3650 张图像,其中 3000 张图像为训练集,325 张图像为验证集,另外 325 张为测试集。在评估验证方面,采用标准的测试集: Set5 [17], Set14 [18], BSD100 [19]和 Urban100 [20]。为了便于与其它方法进行比较,本文采用的评价指标为:峰值信噪比 PSNR 和结构相似度 SSIM [21],评价指标均在 YCbCr 颜色空间中的 Y 通道上进行计算。

3.1.2. 实验细节

为了扩充训练集,本文对整合后的训练图像进行 90° 、 180° 、 270° 的旋转和水平翻转,并采用双三次下采样的方法来获得低分辨率和高分辨率图像对。网络初始学习率设置为 5×10^{-5} ,优化器采用 Adam,并设置 $\beta_1 = 0.9$, $\beta_2 = 0.999$, $\varepsilon = 10^{-8}$ 。训练时先对网络中的生成器进行训练,每轮训练迭代 1000 次,每次迭代中采用 16 个 48×48 的图像块作为输入,每经过 200 轮学习率减半,总共训练 1000 轮。在生成器训练完成后,对鉴别器进行训练,每轮训练迭代 500 次,每次迭代中采用 16 个 48×48 的图像对作为输入,总共训练 500 轮。整个实验采用 pytorch 框架进行搭建。

3.2. 超参数实验

本节主要是对网络中的特征提取模块 RDCA 的模块数进行实验, 整个实验所反映出的性能是在 Set5 测试集上 $\times 4$ 因子情况下进行完成。当模块数为 2 时, PSNR 的值为 32.19 dB, 依次增加模块数, 网络性能得到了相应的提升, 当模块数为 8 时, PSNR 最高, 性能最好, 当模块数持续增加时, 网络性能开始下降, 性能变差。原因是特征模块 RDCA 中的特征提取和复用的能力达到了饱和, 继续增加模块数不仅不能提高网络性能, 还会使训练变得困难。

3.3. 消融实验

本节主要是对网络中特征提取模块和层次特征融合模块中所采用的注意力机制进行实验, 以验证模型中采用的注意力机制的作用, 整个实验是在 Set5 测试集, $\times 4$ 放大因子的情况下进行。

在网络中, 于 RB 模块和层次特征融合模块内同时引入注意力机制, PSNR 值增加了 0.09 dB。而在 RB 模块和层次特征融合模块内分别单独引入注意力机制时, PSNR 值分别增加 0.03 dB 和 0.06 dB。因此, 在 RB 模块和层次特征融合模块内引入注意力机制对网络模型的性能有着很好的提升, 尤其是在层次特征融合模块内引入注意力机制对网络性能的提升更加明显, 这表明, 层次间的特征信息的利用程度对最终的重建效果有着很重要的影响。

3.4. 客观结果比较

表 1 和表 2 分别显示了本文所提超分辨率方法与现有的先进超分辨率方法 EDSR [7], MSRN [22], MDCN [23], RDN [9], DRFN [10]在 $\times 2$ 和 $\times 4$ 这 2 种不同放大倍数时进行定量比较的结果(表中数据所表示的是 PSNR/SSIM), 两张表中每一行的数据分别表示的是: 算法, EDSR, MSRN, MDCN, RDN, DRFN, GAN-RDCN, GAN-RDCN(+).

Table 1. Performance of each module on different test sets with $\times 2$ factor

表 1. 在 $\times 2$ 因子情况下各模型在不同测试集上的性能

Set5	Set14	BSD100	Urban100
38.11/0.9602	33.92/0.9195	32.32/0.9013	32.93/0.9351
38.07/0.9608	33.68/0.9184	32.22/0.9002	32.32/0.9304
38.19/0.9612	33.86/0.9202	32.32/0.9014	32.92/0.9355
38.24/0.9614	34.01/0.9212	32.34/0.9017	32.89/0.9353
38.24/0.9614	34.16/0.9228	32.39/0.9025	33.13/0.9374
38.27/0.9617	34.19/0.9232	32.39/0.9023	33.22/0.9378
38.33/0.9619	34.26/0.9235	32.42/0.9026	33.41/0.9389

Table 2. Performance of each module on different test sets with $\times 4$ factor

表 2. 在 $\times 4$ 因子情况下各模型在不同测试集上的性能

Set5	Set14	BSD100	Urban100
32.46/0.8968	28.80/0.7876	27.71/0.7420	26.64/0.8033
32.07/0.8903	28.60/0.7751	27.52/0.7273	26.04/0.7896
32.48/0.8985	28.83/0.7879	27.74/0.7423	26.69/0.8049
32.47/0.8990	28.81/0.7871	27.72/0.7419	26.61/0.8028

Continued

32.55/0.8995	28.86/0.7880	27.79/0.7435	26.82/0.8074
32.58/0.9362	28.85/0.7880	27.79/0.7445	26.84/0.8075
32.67/0.9396	28.99/0.7916	28.86/0.7450	27.02/0.8110

从表 1 和表 2 可知, 本文所提出的 GAN-RDCN 网络在测试集上的定性效果很多要高于其他方法, 特别是在 Set5 和 Urban100 测试集上, 不管是在哪一个放大因子下, 本文所提出的方法均要优于其他方法。尤其是 Urban100 是由包含很多细节和纹理的建筑图像, 这表明本文所提出的图像重建方法在图像细节和纹理的恢复上有着很好的性能。

3.5. 主观视觉比较

为了验证本文所提的方法在视觉效果上的优越性, 本文从飞行模拟器的视景系统中选取了 2 张不同视角的图像用于视觉效果比较, 整个实验基于×4 放大因子的情况下进行完成。由图 5 和图 6 可知本文所提出的方法在纹理细节的恢复上有着很好的效果, 细节特征更加丰富, 适用于视景图像的超分辨率重建, 如: 将图 5 进行放大后可以发现, 在 114 下面的字体, 相比于其他方法, 本文所提出的方法来得更加清晰, 将图 6 进行放大后可以发现, 本文所提出的方法所对应的图像中白色部分包含实际跑道中出现的黑色痕迹。




Figure 5. Visual image—landing dock
图 5. 视景图像——降落停靠




Figure 6. Visual image—runway turn
图 6. 视景图像——跑道转弯

3.6. 参数比较

表 3 显示了不同模型和参数性能的比较,所有参与比较的模型是在 Set5 测试集,×4 放大因子的情况下进行计算所得出的参数量和性能的关系。

Table 3. The relationship between the performance of each model and the number of parameters in the case of ×4 factor
表 3. 在×4 因子情况下各模型的性能和参数量的关系

模型	PSNR(dB)	参数量(M)
EDSR	32.46	43.89
MSRN	32.07	6.08
MDCN	32.48	13.71
RDN	32.47	22.27
DRFN	32.55	15.00
GAN-RDCN	32.58	13.31
GAN-RDCN(+)	32.67	13.31

由表 3 可知,本文所提出的 GAN-RDCN 模型在测试集上的效果是最好的,但参数只有 EDSR 模型的 1/3,这充分说明了本文所提模型的优越性。

4. 结束语

本文提出了一种基于 GAN 的飞行模拟器中的视景图像超分辨率重建方法,整个网络由生成器和鉴别器两个部分进行组成,生成器中采用不同维度的通道注意力机制,进行深层特征的提取以及层次间的特征融合,提升了网络对特征信息的复用以及细节纹理的恢复能力。在不同测试集上的实验结果表明,本文提出的方法与其它方法相比,本文在视觉效果上优于其他方法,在定性指标上也有着不弱于其他方法的性能,能有效地提高重建图像的质量,尤其是在视景图像上。未来将对网络的整体结构进行进一步优化,以提升其整体性能。

基金项目

飞行模拟训练设备视景投影系统升级研发项目(KC22201)。

参考文献

- [1] 赵国昌, 周文藻. 飞行模拟器逼真度评估方法研究进展[J]. 机床与液压, 2020, 48(23): 176-183.
- [2] Almalioglu, Y., Ozyoruk, K.B., Gokce, A., et al. (2020) EndoL2H: Deep Super-Resolution for Capsule Endoscopy. *IEEE Transactions on Medical Imaging*, **39**, 4297-4309. <https://doi.org/10.1109/TMI.2020.3016744>
- [3] Wang, Z., Chen, J. and Hoi, S.C.H. (2020) Deep Learning for Image Super-Resolution: A Survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **43**, 3365-3387. <https://doi.org/10.1109/TPAMI.2020.2982166>
- [4] 苟东强. 基于深度学习的图像超分辨率重构技术[J]. 信息记录材料, 2022, 23(8): 100-103.
- [5] Ma, C., Rao, Y., Cheng, Y., et al. (2020) Structure-Preserving Super Resolution with Gradient Guidance. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Seattle, 13-19 June 2020, 7769-7778. <https://doi.org/10.1109/CVPR42600.2020.00779>
- [6] Dong, C., Loy, C.C., He, K., et al. (2015) Image Super-Resolution Using Deep Convolutional Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **38**, 295-307. <https://doi.org/10.1109/TPAMI.2015.2439281>
- [7] Lim, B., Son, S., Kim, H., et al. (2017) Enhanced Deep Residual Networks for Single Image Super-Resolution. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, Honolulu, 21-26 July 2017,

- 136-144. <https://doi.org/10.1109/CVPRW.2017.151>
- [8] Zhang, Y., Tian, Y., Kong, Y., *et al.* (2018) Residual Dense Network for Image Super-Resolution. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 18-23 June 2018, 2472-2481. <https://doi.org/10.1109/CVPR.2018.00262>
 - [9] Feng, X., Li, X. and Li, J. (2021) Multi-Scale Fractal Residual Network for Image Super-Resolution. *Applied Intelligence*, **51**, 1845-1856. <https://doi.org/10.1007/s10489-020-01909-8>
 - [10] Gu, J., Qu, Z., Wang, X., *et al.* (2021) Residual Fractal Network for Single Image Super Resolution by Widening and Deepening. 2020 25th International Conference on Pattern Recognition (ICPR) IEEE, Milan, 10-15 January 2021, 1596-1603. <https://doi.org/10.1109/ICPR48806.2021.9412184>
 - [11] Ledig, C., Theis, L., Huszár, F., *et al.* (2017) Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, 21-26 July 2017, 4681-4690. <https://doi.org/10.1109/CVPR.2017.19>
 - [12] Zhang, R., Isola, P., Efros, A.A., *et al.* (2018) The Unreasonable Effectiveness of Deep Features as a Perceptual Metric. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 18-23 June 2018, 586-595. <https://doi.org/10.1109/CVPR.2018.00068>
 - [13] Wang, X., Yu, K., Wu, S., *et al.* (2018) ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks. *Proceedings of the European Conference on Computer Vision (ECCV) Workshops*, Munich, 8-14 September 2018, 63-79. https://doi.org/10.1007/978-3-030-11021-5_5
 - [14] Nambiar, A.M. and Mittal, A. (2022) A GAN-Based Super Resolution Model for Efficient Image Enhancement in Underwater Sonar Images. *OCEANS 2022*, Chennai, 21-24 February 2022, 1-8.
 - [15] Agustsson, E. and Timofte, R. (2017) NTIRE 2017 Challenge on Single Image Super-Resolution: Dataset and Study. *Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, Honolulu, 21-26 July 2017, 1122-1131. <https://doi.org/10.1109/CVPRW.2017.150>
 - [16] Timofte, R., Agustsson, E., Van Gool, L., *et al.* (2017) Ntire 2017 Challenge on Single Image Super-Resolution: Methods and Results. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, Honolulu, 21-26 July 2017, 114-125. <https://doi.org/10.1109/CVPRW.2017.149>
 - [17] Bevilacqua, M., Roumy, A., Guillemot, C., *et al.* (2012) Low-Complexity Single-Image Super-Resolution Based on Nonnegative Neighbor Embedding. In: *Low-Complexity Single-Image Super-Resolution Based on Nonnegative Neighbor Embedding*, British Machine Vision Association, Malvern, 1-10. <https://doi.org/10.5244/C.26.135>
 - [18] Zeyde, R., Elad, M. and Protter, M. (2010) On Single Image Scale-Up Using Sparse-Representations. In: *International Conference on Curves and Surfaces*, Springer, Berlin, 711-730. https://doi.org/10.1007/978-3-642-27413-8_47
 - [19] Martin, D., Fowlkes, C., Tal, D., *et al.* (2001) A Database of Human Segmented Natural Images and Its Application to Evaluating Segmentation Algorithms and Measuring Ecological Statistics. *Proceedings 8th IEEE International Conference on Computer Vision*, ICCV 2001, Vol. 2, 416-423. <https://doi.org/10.1109/ICCV.2001.937655>
 - [20] Huang, J.B., Singh, A. and Ahuja, N. (2015) Single Image Super-Resolution from Transformed Self-Exemplars. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Boston, 7-12 June 2015, 5197-5206. <https://doi.org/10.1109/CVPR.2015.7299156>
 - [21] Wang, Z., Bovik, A.C., Sheikh, H.R., *et al.* (2004) Image Quality Assessment: From Error Visibility to Structural Similarity. *IEEE Transactions on Image Processing*, **13**, 600-612. <https://doi.org/10.1109/TIP.2003.819861>
 - [22] Li, J., Fang, F., Mei, K., *et al.* (2018) Multi-Scale Residual Networ for Image Super-Resolution. *Proceedings of the European Conference on Computer Vision (ECCV)*, Munich, 8-14 September 2018, 517-532. https://doi.org/10.1007/978-3-030-01237-3_32
 - [23] Li, J., Fang, F., Li, J., *et al.* (2020) MDCN: Multi-Scale Dense Cross Network for Image Super-Resolution. *IEEE Transactions on Circuits and Systems for Video Technology*, **31**, 2547-2561. <https://doi.org/10.1109/TCSVT.2020.3027732>