

基于多尺度渐进融合网络的图像超分辨重建

崔琛¹, 黄辉^{2*}, 张凯兵¹

(1. 西安工程大学 电子信息学院, 陕西 西安 710048; 2. 广西科技师范学院 职业技术教育学院, 广西 来宾 546100)

摘要: 深度卷积网络是一种有效的图像超分辨率(super-resolution, SR)重建技术。然而, 大多数已有多深度学习超分辨率方法没有充分利用输入图像中存在的不同尺度之间的相似性结构, 导致获得的超分辨率图像在视觉质量上仍然存在一定的差距。为解决上述问题, 提出一种多尺度渐进融合网络的图像超分辨率重建方法。该方法使用高斯核对输入图像生成不同尺度的高斯金字塔图像, 将高斯金字塔图像输入到粗融合模块中进行深度特征提取与融合, 将粗融合模块得到的结果输入到细融合模块中获取更加精细的图像特征, 最后将粗融合模块得到的粗特征和细融合模块得到的细特征进行融合, 从而恢复出高分辨率图像。实验结果表明, 该方法不仅计算效率高, 而且相比于其他深度学习方法, 重建出的高分辨率图像在主观和客观质量评价两个方面均取得更好的评价性能。

关键词: 图像超分辨率; 多尺度学习; 卷积神经网络; 特征融合

中图分类号: TP391 **文献标志码:** A **文章编号:** 2095-4824(2021)06-0050-06

图像超分辨率是一种利用同一场景下获得的一幅或多幅低分辨率(low-resolution, LR)图像重建出一幅高分辨率(high-resolution, HR)图像的图像恢复技术^[1]。一般而言, 目前主流的超分辨率算法主要分为四种类型: 基于插值的方法^[2-4]、基于重构的方法^[5-8]、基于传统的实例学习的方法^[9-12]和基于深度学习的方法^[13-15]。

基于插值的方法主要是利用特定的基函数或插值核估计高分辨率图像中的未知像素。尽管这类方法简单、高效, 但它们难以恢复低分辨率图像中丢失的高频细节, 导致重建的图像视觉效果模糊, 通常情况下难以满足实际应用要求。基于重构的方法通过求解图像生成的逆问题实现高分辨率图像的估计, 但该方法重建图像的质量很大程度上依赖于应用的先验知识。因此, 学习并利用有效而全面的图像先验知识进行正则化求解, 是成功解决该问题的关键。基于传统实例学习的图

像超分辨率方法主要借助于机器学习技术, 从给定的大量实例图像对中学习低分辨与高分辨图像块之间映射关系, 实现低分辨图像到高分辨图像的变换。虽然基于传统实例学习的方法能有效恢复低分辨图像中丢失的高频细节, 但是该类方法对数据集的依赖性较强, 当输入图像与训练数据集中的图像在结构上差异较大时, 重建出的超分辨率图像并不能达到令人满意的效果。

近年来, 随着深度卷积神经网络在计算机视觉中的成功应用, 基于深度学习的超分辨率方法得到了人们广泛的关注, 出现了很多有效的深度学习超分辨率重建算法。Dong 等^[5]首次应用卷积神经网络模型建立低分辨与高分辨图像间的非线性映射关系, 提出了卷积神经网络的超分辨率方法(super-resolution convolutional neural network, SRCNN)。该方法首先利用卷积层对低分辨图像进行特征提取, 然后利用获得的映射特征重建出

收稿日期: 2021-09-05

基金项目: 国家自然科学基金(61971339, 61471161); 陕西省自然科学基础研究计划重点项目(2018JZ6002); 西安工程大学博士启动基金(BS1616)

作者简介: 崔琛(1994-), 男, 河南安阳人, 西安工程大学电子信息学院硕士研究生。

黄辉(1976-), 男, 湖北孝感人, 广西科技师范学院职业技术教育学院副教授, 硕士, 本文通信作者。

需要的高分辨图像。之后 Dong 等^[7]对 SRCNN 进行了改进,在低分辨率空间进行图像特征的提取和非线性映射,最后使用反卷积实现图像超分辨重建。受大规模图像识别深度卷积神经网络的启发,Kim 等^[8]提出了一种基于深度卷积神经网络的精确图像超分辨率(very deep convolutional neural networks, VDSR)重建方法。为扩大超分辨网络的感受野,该方法使用了更深的残差网络结构,其性能较基于 SRCNN 的超分辨方法具有明显的优势。为缓解过深的网络结构而导致网络在训练过程中出现梯度消失或梯度爆炸问题,He 等^[9]提出了一种深度残差网络(residual network, ResNet)的图像识别方法,该方法通过设计残差连接网络结构,能在网络层数较深的情况下仍能获得较好的训练效果。受该思想的启发,Lim 等^[10]将残差网络结构引入到超分辨率重建网络中,提出了一种增强深度残差网络的超分辨方法(en-hanced deep residual network based super-resolution, EDSR),该方法通过去掉归一化层,使用更深更广的网络结构实现对 SR 网络的增强。Zhang 等^[11]使用密集残差块和所有卷积层的层次特征,提出了基于残差密集网络(residual dense network, RDN)的超分辨网络模型。他们利用残差中的残差结构和通道注意机制构建了一个残差通道注意力网络(residual channel attention network, RCAN),该方法能有效缓解深层网络的训练难度,提高了超分辨网络的重建能力。尽管上述网络模型在解决超分辨率问题中取得了较好的效果,但他们都忽略了如何利用低分辨图像中多尺度相似性信息来进一步提高超分辨率重建的性能。由于自然图像在同一尺度和不同尺度之间均存在相似性结构,相同尺度的自相似性有助于提高超分辨率估计的鲁棒性,而不同尺度的相似性有助于恢复图像中更精细的纹理结构信息。

最近研究者除了研究超分辨网络的结构外,还提出了许多针对超分辨率重建的特征提取模块块,具有代表性的有残差块^[11]、密集块^[13]和 Inception 块^[14]。Li 等^[15]引入 Inception 块来提取低分辨图像的多尺度特征。Kim 等^[16]提出了一种增强的残差块,从而减轻网络训练的难度。Li 等^[17]提出了一种带有门控选择机制的残差块,可以自适应地学习高频信息而过滤低频信息。Wang 等^[18]提出了多记忆残差块,将长短时记忆嵌入到该模块中,有效地学习了连续低分辨图像

帧之间的相关性。Tong 等^[19]引入了密集块,提出了一种将低维特征和高维特征有效相结合的方法,从而提升重建性能。Zhang 等^[11]提出了一种残差密集块,该模块结合残差块和密级连接块的优点,充分利用了低分辨图像的所有分层特征。不过,残差块和密集块都只使用单一大小的卷积核,不仅很难检测到不同尺度的图像特征,而且增加了计算复杂度。为了解决上述方法中存在的不足,Li 等^[20]将大小不同的卷积核加入到残差块中,并提出了多尺度残差块(multi-scale residual block, MSRB),并且在不同尺度特征之间使用跳连接实现特征的共享和重用。尽管基于 MSRB 的方法能检测到不同尺度的图像特征,但该方法应用大尺寸卷积核会导致网络计算复杂性的显著增加,而且该模型没有充分利用浅层和深层局部图像特征,导致该方法仍存在一定的局限性。

鉴于上述分析,本文将研究如何充分利用不同尺度的浅层和深层局部图像特征来解决上述方法存在的不足,以提高基于深度学习超分辨率网络的重建性能。为了充分利用低分辨图像中多尺度图像特征之间的互补性,本文提出了一种基于多尺度渐进融合网络(multi-scale progressive fusion network, MSPFN)的图像超分辨率方法。该方法首先利用高斯核对 LR 图像依次进行下采样,生成高斯金字塔序列图像。然后,设计一种粗融合模块(coarse-fusion module, CFM)实现多尺度图像特征的提取和融合,之后利用细融合模块(fine-fusion module, FFM)进一步对 CFM 中特征进行整合,并且在 FFM 模块中引入通道注意力机制选择性地学习不同尺度的特征,以有效地减少特征冗余。利用多个 FFM 模块以级联形式构建渐进多尺度融合网络,最后通过重建模块(reconstruction module, RM)对来自 CFM 模块和 FFM 模块的特征进行融合,以生成高质量的超分辨图像。提出的基于 MSPFN 的网络结构图如图 1 所示。

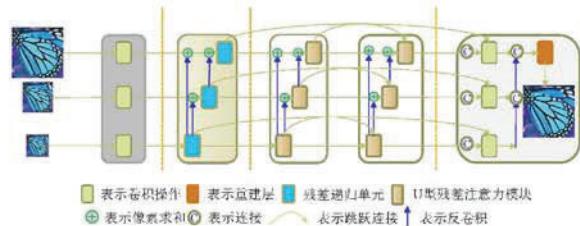


图 1 基于 MSPFN 的网络结构图

1 多尺度渐进融合超分辨网络

1.1 多尺度粗特征提取与融合

首先对输入图像使用高斯核生成不同尺度的高斯金字塔图像。将金字塔图像作为输入，并通过多个并行的卷积层提取浅层特征。在粗融合模块中，将不同尺度的浅层特征输入到几个并行的残差递归单元 (residual recurrent units, RRUs) 中，实现多尺度图像深度特征的提取。残差递归单元如图 2 所示。设计粗融合模块的作用包括三个方面：1) 引入 Conv-LSTM 来模拟空间维度上的纹理信息，并采用递归计算和残差学习来获取互补的图像信息。2) 对于多尺度图像来说，不同尺寸的图像能够提供不同的感受，使得网络在浅层结构上能捕获到更多的图像内容和细节。3) 有利于提取多尺度图像特征，实现更加鲁棒的超分辨率重建。

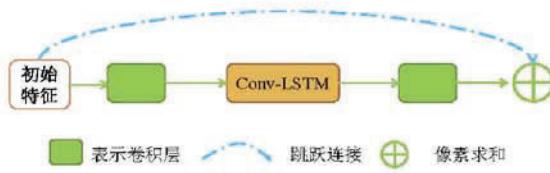


图 2 残差递归单元

1.2 多尺度细特征提取融合

为了获得更加精细的图像特征，将 CFM 模块输出的结果输入到 FFM 模块中。为了便于观察，将 CFM 模块设计成与 FFM 模块具有相似的多尺度结构，如图 2 所示。与 CFM 模块不同，在 FFM 模块中加入了通道注意力机制，增强了网络对重要特征的学习能力，从而为每个通道分配不同的权重，让网络更多地关注重要的图像特征抑制不重要的特征。最后，为了避免信息丢失，利用反卷积来提升分辨率，从而构成 U 型残差注意力模块 (U-shaped residual attention block, URAB)。URAB 结构如图 3 所示，URAB 由多个通道注意力单元组成，利用短跳跃连接学习同一尺度下的相似信息，而且在级联的细融合模块中利用长跳跃连接，不仅实现不同尺度下的图像信息融合，而且有利于反向传播。

1.3 损失函数

对图像超分辨率重建模型中，损失函数用来计算真实的高分辨图像与超分辨率图像之间的误差，以指导模型的优化。早期研究人员采用像素上

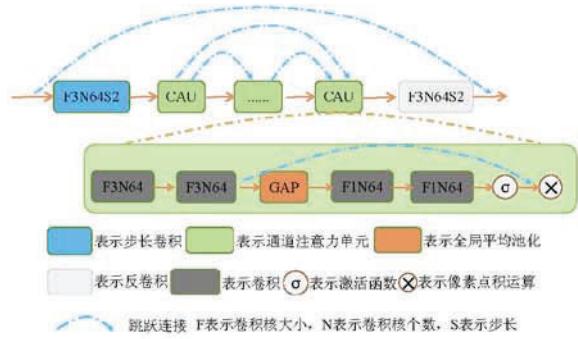


图 3 URAB 结构图

的 L_2 范数作为损失函数，尽管该损失函数能获得较高的峰值信噪比 (peak signal-to-noise ratio, PSNR) 和相似结构 (structural similarity, SSIM)，但主观视觉效果并没有提升。因此，该方法容易导致图像细节的模糊，产生过度平滑的视觉效果。为了避免上述问题，本文以 Charbonnier 损失函数为指导提出一种新的损失函数，表示为：

$$L_d = \sqrt{(\hat{I} - I)^2 + \epsilon} \quad (1)$$

式中： I 表示 HR 图像， \hat{I} 表示重建图像， ϵ 为正则系数设为 10^{-3} 。

为了进一步改善高频细节的真实性，使用另外一种边缘损失函数来防止出现图像过度平滑的效果。边缘损失函数表示为：

$$L_{edge} = \sqrt{(\text{Lap}(I) - \text{Lap}(\hat{I}))^2 + \epsilon^2} \quad (2)$$

式中： $\text{Lap}(I)$ 和 $\text{Lap}(\hat{I})$ 分别表示 HR 图像和重建图像通过 Laplacian 算子提取出的边缘图像特征。联合上述两种损失，训练网络时的总损失函数表示为：

$$L = L_d + \lambda \times L_{edge} \quad (3)$$

式中： λ 为权重参数，本文实验中设置为 0.05。

2 实验结果与分析

2.1 数据集

本文提出的 MSPFN 模型在 DIV2K^[21] 数据集进行训练。该数据集包含 800 幅训练图像、100 幅验证图像和 100 幅测试图像。本文选择 800 幅图像进行训练，选择 5 幅图像进行验证。测试集选用 Set5, Set10, Set14 和 Urban100，它们分别包含 5, 14, 100, 100 幅图像。这些数据集中包含图像内容丰富，能充分评估超分辨率重建算法的有效性。

2.2 参数设置

为了验证本文所提出算法的有效性，首先建立一个基准模型。在本文的基准中，金字塔图像

的级别设置为 3, 即原始比例、 $1/2$ 比例和 $1/4$ 比例。在 CFM 中, 每个循环 Conv-LSTM 的滤波器数量分别设置为 32、64 和 128, FFM(M) 和 CAU(N) 的深度分别设置为 10 和 3。利用 Adam 优化器每批次处理 16 幅图像, 初始学习率设为 2×10^{-4} , 每 20000 步减小为原来的 $1/2$, 直到 1×10^{-6} , 将上述参数设置迭代 30 次进行训练网络。本文实验均在英伟达 2080Ti GPU 和 Ubuntu 18.04 系统中进行训练和测试。

2.3 消融实验

1) 基本模块验证。本文使用的基准模型中 $M = 10, N = 3$, 分别设计 3 个比较模型来分析基本模块 CFM、FFM 和多尺度金字塔框架对超分辨率性能的影响。其中 Model1 是仅具有原始输入的单尺度框架, Model2 代表从 MSPFN 去除所有 CFM 模块的网络模型, 而 Model3 表示从 MSPFN 中去除所有 FFM 模块的网络模型。表 1

表 2 不同 M 和 N 的比较结果

评价指标	MSPFN M5 N3	MSPFN M8 N3	MSPFN M10 N1	MSPFN	MSPFN M10 N5
PSNR	33.42	33.51	33.28	33.88	33.93
SSIM	0.909	0.912	0.878	0.919	0.925

由表 2 可知, 随着 M 和 N 的增加, 超分辨率重建图像的质量也随之提升。但需要注意的是, 随着 M 和 N 的增加, 超分辨率网络模型的参数量会增加, 导致算法的计算效率变低。为平衡重建质量和计算效率, 本文设置 $M = 10, N = 3$ 。

2.4 对比实验

为了验证本文所提出方法的有效性, 将本文方法与 7 种主流超分辨率方法进行比较, 包括 A+^[22], SelfExSR^[23], SRCNN^[5], FSRCNN^[7], VDSR^[8], DRCN^[24] 和 MSRN^[20]。图 4~图 6 从视觉质量上分别展示 8 种算法对不同测试图像进行超分辨率的视觉效果, 并对比了 4 倍放大下各算法对 Urban 数据集中的 3 幅图像(包括 img005、img061 和 img074)中特定区域的重建效果。从图 4~图 6 中的对比结果可以看出, 本文所提出的算法重建出的效果最接近与原始图像。其中, A+ 和 SelfExSR 算法重建的图像视觉效果最差, 出现了明显的模糊, 且纹理细节缺失严重。SRCNN 和 FSRCNN 相对与 A+ 和 SelfExSR 性能有所提高, 但是重建出来的边缘和纹理细节比较模糊, 不能满足实际需求。VDSR, DRCN 和 MSRN 相较于其他算法性能有明显的提升, 但在纹理细节丰富的区域出现明显的扭曲失真。综合上述结果,

是 Set14 数据集在 $\times 2$ 倍放大情况下不同模型的重建结果。由表 1 可知, 本文提出的 MSPFN 相对于其他三种模型具有明显的优势, 而且发现 FFM 模块对超分辨率重建结果的影响显著高于 CFM 模块和单尺度框架。

表 1 基本模块验证结果

评价指标	Model1	Model2	Model3	MSPFN
PSNR	32.92	33.60	30.28	33.88
SSIM	0.909	0.914	0.885	0.919

2) M 和 N 参数分析。为了验证 FFM 的深度(M)和 CAU(N)的数量对超分辨率性能的影响, 相对于基准模型($M=10, N=3$)设计出 4 个比较模型, 4 个模型分别为 MSPFN M5 N3, MSPFN M8 N3, MSPFN M10 N1, MSPFN M10 N5。表 2 列出了 Set14 数据集在 $\times 2$ 倍情况下在不同模型的重建结果。

可以看出本文所提出的算法恢复出来的图像纹理细节最清晰, 视觉效果最好。

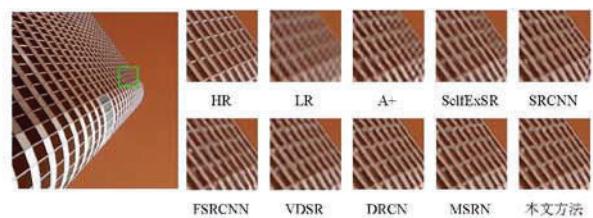


图 4 img005 放大 4 倍时 SR 结果对比

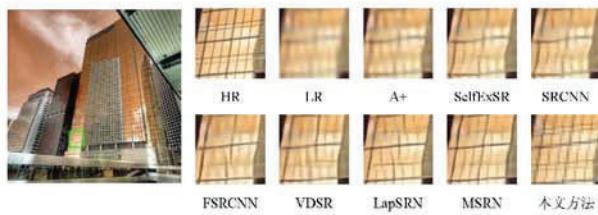


图 5 img061 放大 4 倍时 SR 结果对比

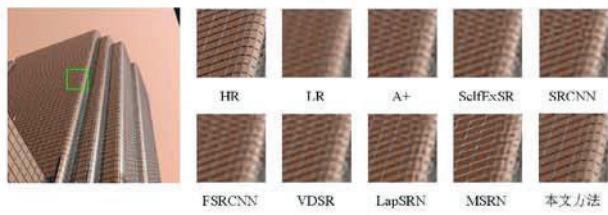


图 6 img074 放大 4 倍时 SR 结果对比

表 3 展示不同方法在 Set5、Set14、Urban100

和 BSD100 4 个测试数据集上的 3 种放大倍数情况下的平均 PSNR 值和 SSIM 值。

表 3 不同尺度图像超分辨重建结果

算法	尺度	Set5	Set14	Urban100	BSD100
		PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
A + ^[22]	2	36.60/0.9542	32.42/0.9059	29.25/0.8955	31.24/0.8870
SelfExSR ^[23]	2	36.60/0.9537	32.46/0.9051	29.55/0.8983	31.20/0.8863
SRCNN ^[5]	2	36.71/0.9536	32.32/0.9052	29.54/0.8962	31.36/0.8880
FSRCNN ^[7]	2	37.06/0.9554	32.76/0.9078	29.88/0.9024	31.53/0.8912
VDSR ^[8]	2	37.53/0.9583	33.05/0.9107	30.79/0.9157	31.92/0.8965
DRCN ^[24]	2	37.62/0.9581	33.08/0.9109	30.41/0.9112	31.80/0.8949
MSRN ^[20]	2	38.08/0.9605	33.74/0.9170	32.22/0.9326	32.23/0.9002
本文算法	2	38.15/0.9610	33.88/0.9195	32.29/0.9010	32.29/0.9010
A + ^[22]	3	32.63/0.9085	29.25/0.8194	26.05/0.8019	28.31/0.7828
SelfExSR ^[24]	3	32.66/0.9089	29.34/0.8222	26.45/0.8124	28.30/0.7839
SRCNN ^[5]	3	32.47/0.9067	29.23/0.8201	26.25/0.8028	28.31/0.7832
FSRCNN ^[7]	3	33.20/0.9149	29.54/0.8277	26.48/0.8175	28.55/0.7945
VDSR ^[8]	3	33.68/0.9201	29.86/0.8312	27.15/0.8315	28.83/0.7966
DRCN ^[24]	3	33.82/0.9207	29.89/0.8317	27.07/0.8298	28.82/0.7950
MSRN ^[20]	3	34.48/0.9262	30.34/0.8395	28.08/0.8554	29.08/0.8041
本文算法	3	34.65/0.9292	30.53/0.8463	28.15/0.8619	29.23/0.8086
A + ^[22]	4	30.33/0.8565	27.44/0.7450	24.34/0.7211	26.83/0.6999
SelfExSR ^[24]	4	30.34/0.8593	27.55/0.7511	24.83/0.7403	26.84/0.7032
SRCNN ^[5]	4	30.50/0.8573	27.62/0.7453	24.53/0.7236	26.91/0.6994
FSRCNN ^[7]	4	30.73/0.8601	27.71/0.7488	24.62/0.7272	26.98/0.7029
VDSR ^[8]	4	31.36/0.8796	28.11/0.7624	25.18/0.7543	27.29/0.7167
DRCN ^[23]	4	31.56/0.8810	28.19/0.7635	25.21/0.7564	27.32/0.7162
MSRN ^[20]	4	32.27/0.8903	28.60/0.7751	26.04/0.7896	27.52/0.7273
本文算法	4	31.67/0.8945	28.59/0.7803	26.10/0.7848	27.53/0.7346

由表 3 中的结果可知, 本文提出的 MSPFN 方法在不同数据集进行放大 2 倍和 3 倍时, 无论是 PSNR 还是 SSIM 的结果均优于其他 7 种算法。尽管在放大 4 倍时在个别数据集上的性能指标略低于 MSRN 算法, 但综合所有数据集上的性能指标, 本文所提出的方法具有最好的重建性能。

3 结论

本文提出了一种基于多尺度渐进融合的超分辨率网络模型, 该模型首先将生成的多尺度高斯金字塔图像输入到 CFM 对多尺度的图像进行特征提取并融合。然后利用 FFM 进一步对 CFM 中的特征进行整合, 并且在 FFM 模块中引入通道注意力机制。通道注意力机制不仅可以选择性地学习不同尺度的特征, 而且可以有效地减少特征冗余。此外多个 FFM 以级联形式形成渐进的多尺度融合。最后通过 RM 模块将来自 CFM 模块和 FFM 模块中的特征进行有效融合, 从而重建出高质量的超分辨率图像。与其他七种主流的超分辨率算

法的对比实验结果表明, 所提出的基于多尺度渐进融合网络的超分辨率方法能重建出主、客观质量评价方面更好的超分辨率图像。

[参考文献]

- [1] ZHANG L, WU X. An edge-guided image interpolation algorithm via directional filtering and data fusion[J]. IEEE Transactions on Image Processing, 2006, 15(8): 2226–2238.
- [2] KIM H, CHA Y, KIM S. Curvature interpolation method for image zooming[J]. IEEE Transactions on Image Processing, 2011, 20(7): 1895–1903.
- [3] DAI S, HAN M, XU W, et al. Soft edge smoothness prior for alpha channel super resolution[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR). 2007: 1–8.
- [4] 李云红, 王珍, 张凯兵, 等. 基于学习的图像超分辨率重建方法综述[J]. 计算机工程与应用, 2018, 54(15): 13–21.
- [5] DONG C, LHEN C L, HE K, et al. Learning a

- deep convolutional network for image super-resolution[C]// Proceedings of 2014 European Conference on Computer Vision, 2014:184 – 199.
- [6] HARIS M, SHAKHNAROVICH G, UKITA N. Deep back-projection networks for super-resolution [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018: 1664 – 1673.
- [7] DONG C , LOY C , HE K, et al. Image super-resolution using deep convolutional networks[J]. IEEE Trans Pattern Anal Mach Intell, 2016, 38 (2):295 – 307.
- [8] KIM J, KWON LEE J, MU LEE K. Accurate image super-resolution using very deep convolutional networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016: 1646 – 1654.
- [9] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 770 – 778.
- [10] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). 2017: 136 – 144.
- [11] ZHANG Y, TIAN Y, KONG Y, et al. Residual dense network for image super-resolution [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018: 2472 – 2481.
- [12] CLARK J, PALMER M, LAWRENCE P O. A transformation method for the reconstruction of functions from nonuniformly spaced samples[J]. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1985, 33(5): 1151 – 1165.
- [13] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR). 2015: 1 – 9.
- [14] HARIS M, WIDYANTO M R, Nobuhara H. Inception learning super-resolution [J]. Applied optics, 2017, 56(22): 6043 – 6048.
- [15] LI F, BAI H, ZHAO Y. FilterNet: Adaptive information filtering network for accurate and fast image super-resolution [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2019, 30(6): 1511 – 1523.
- [16] KIM J, LEE J K, LEE K M. Deeply-recursive convolutional network for image super-resolution [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016: 1637 – 1645.
- [17] LI F, BAI H, ZHAO Y. FilterNet: Adaptive information filtering network for accurate and fast image super-resolution[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2019, 30(6): 1511 – 1523.
- [18] WANG Z, YI P, JIANG K, et al. Multi-memory convolutional neural network for video super-resolution[J]. IEEE Transactions on Image Processing, 2018, 28(5): 2530 – 2544.
- [19] TONG T, LI G, LIU X, et al. Image super-resolution using dense skip connections[C]//Proceedings of the IEEE International Conference on Computer Vision(ICCV). 2017: 4799 – 4807.
- [20] LI J, FANG F, MEI K, et al. Multi-scale residual network for image super-resolution[C]//Proceedings of the European Conference on Computer Vision(ECCV). 2018: 517 – 532.
- [21] TIMOFTE R, AGUSTSSON E, VAN GOOL L, et al. Ntire 2017 challenge on single image super-resolution: Methods and results[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops(CVPRW). 2017: 114 – 125.
- [22] TIMOFTE R, DE SMET V, VAN GOOL L. A + : Adjusted anchored neighborhood regression for fast super-resolution [C]//Proceedings of the Asian Conference on Computer Vision (ACCV). 2014: 111 – 126.
- [23] HUANG J B, SINGH A, AHUJA N. Single image super-resolution from transformed self-exemplars[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR). 2015: 5197 – 5206.
- [24] KIM J, LEE J K, LEE K M. Deeply-recursive convolutional network for image super-resolution [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016: 1637 – 1645.