

# 基于自适应级联的注意力网络的超分辨率重建

陈一鸣<sup>1</sup> 周登文<sup>1</sup>

**摘要** 深度卷积神经网络显著提升了单图像超分辨率的性能. 通常, 网络越深, 性能越好. 然而加深网络往往会急剧增加参数数量和计算负荷, 限制了在资源受限的移动设备上的应用. 提出一个基于轻量级自适应级联的注意力网络的单图像超分辨率方法. 特别地提出了局部像素级注意力模块, 给输入特征的每一个特征通道上的像素点都赋以不同的权值, 从而为重建高质量图像选取更精确的高频信息. 此外, 设计了自适应的级联残差连接, 可以自适应地结合网络产生的层次特征, 能够更好地进行特征重用. 最后, 为了充分利用网络产生的信息, 提出了多尺度全局自适应重建模块. 多尺度全局自适应重建模块使用不同大小的卷积核处理网络在不同深度处产生的信息, 提高了重建质量. 与当前最好的类似方法相比, 该方法的参数量更小, 客观和主观度量显著更好.

**关键词** 超分辨率, 轻量级, 注意力机制, 多尺度重建, 自适应参数

**引用格式** 陈一鸣, 周登文. 基于自适应级联的注意力网络的超分辨率重建. 自动化学报, 2022, 48(8): 1950–1960

**DOI** 10.16383/j.aas.c200035

## Adaptive Attention Network for Image Super-resolution

CHEN Yi-Ming<sup>1</sup> ZHOU Deng-Wen<sup>1</sup>

**Abstract** Deep convolutional neural networks have significantly improved the performance of single image super-resolution. Generally, the deeper the network, the better the performance. However, deepening network often increases the number of parameters and computational cost, which limits its application on resource constrained mobile devices. In this paper, we propose a single image super-resolution method based on a lightweight adaptive cascading attention network. In particular, we propose a local pixel-wise attention block, which assigns different weights to pixels on each channel, so as to select high-frequency information for reconstructing high quality image more accurately. In addition, we design an adaptive cascading residual connection, which can adaptively combine hierarchical features and is propitious to reuse feature. Finally, in order to make full use of all hierarchical features, we propose a multi-scale global adaptive reconstruction block. Multi-scale global adaptive reconstruction block uses convolution kernels of different sizes to process different hierarchical features, hence can reconstruct high-resolution image more effectively. Compared with other state-of-the-art methods, our method has fewer parameters and achieves superior performance.

**Key words** Super-resolution, lightweight, attention mechanism, multi-scale reconstruction, adaptive parameter

**Citation** Chen Yi-Ming, Zhou Deng-Wen. Adaptive attention network for image super-resolution. *Acta Automatica Sinica*, 2022, 48(8): 1950–1960

单图像超分辨率 (Single image super-resolution, SISR)<sup>[1]</sup> 技术是一个经典的计算机视觉任务, 旨在从一个低分辨率 (Low-resolution, LR) 图像生成对应的高分辨率 (High-resolution, HR) 图像, 在医学成像、监控和遥感等领域有十分广泛的应用. SISR 是一个病态的逆问题, 要重建逼真的 HR 图像非常困难, 因为一个 LR 图像可与多个 HR 图像对应, 需要假定的先验知识, 正则化原 HR 图像解<sup>[2]</sup>.

近年来, 深度学习<sup>[3]</sup> 技术显著改进了 SISR 性

能, 并主导了当前 SISR 技术的研究. Dong 等<sup>[4]</sup> 提出了第 1 个基于卷积神经网络的 SISR 算法称为超分辨率卷积神经网络 (Super-resolution convolutional neural network, SRCNN). SRCNN 只有 3 个卷积层, 感受野较小. 之后的 SISR 方法的一个趋势是: 逐步加深网络, 从而获得更强的 LR-HR 映射能力, 同时拥有更大的感受野, 能够融入更多的背景信息, 改进了 SISR 性能<sup>[5]</sup>. 然而加深网络也会带来一些问题: 更大的网络 (更深或更宽), 会有更多的参数, 需要更大的内存和更强的计算力, 这阻碍了在资源受限的设备, 如移动设备上的实际应用. 当前已有一些引人注意的基于轻量级网络的 SISR 方法被提出. Kim 等<sup>[6]</sup> 提出的深度递归卷积网络 (Deeply-recursive convolutional network, DRCN)

收稿日期 2020-01-16 录用日期 2020-06-28

Manuscript received January 16, 2020; accepted June 28, 2020  
本文责任编辑 胡清华

Recommended by Associate Editor HU Qing-Hua

1. 华北电力大学控制与计算机工程学院 北京 102206

1. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206

方法, 使用深度递归的方法, 在卷积层之间共享参数, 在加深网络的同时, 尽可能不增加网络参数量. Tai 等<sup>[7]</sup>提出的深度递归残差网络 (Deep recursive residual network, DRRN), 也使用了深度递归的方法. 与 DRCN 的区别在于 DRRN 在残差块之间共享参数, 不仅显著地减少了参数量, 而且性能也显著更好. Tai 等<sup>[8]</sup>也提出了深度持续记忆网络 (Deep persistent memory network, MemNet) 方法, 使用记忆模块, 并多次递归, 既能控制参数量, 也能更好地利用多层特征信息. Ahn 等<sup>[9]</sup>提出的级联残差网络 (Cascading residual network, CARN) 方法, 使用级联残差的形式, 重用不同层次的信息. Li 等<sup>[5]</sup>提出的轻量级超分辨率反馈网络 (Light-weight super-resolution feedback network, SRFBN-S) 方法, 使用循环神经网络结构, 共享隐藏层的参数, 并多次利用各个隐藏层的输出, 从而改进了网络性能.

本文提出了一个新的轻量级 SISR 模型, 称为自适应级联的注意力网络 (Adaptive cascading attention network, ACAN). 与当前类似的尖端 SISR 方法相比, ACAN 有更好的性能和参数量平衡. 的主要贡献包括: 1) 提出了自适应级联的残差 (Adaptive cascading residual, ACR) 连接. 残差块之间的连接权重, 是在训练中学习的, 能够自适应结合不同层次的特征信息, 以利于特征重用. 2) 提出了局部像素级注意力 (Local pixel-wise attention, LPA) 模块. 其对输入特征的每一个特征通道的空间位置赋予不同的权重, 以关注更重要的特征信息, 更好地重建高频信息. 3) 提出了多尺度全局自适应重建 (Multi-scale global adaptive reconstruction, MGAR) 模块, 不同尺寸的卷积核处理不同层次的特征信息, 并自适应地组合处理结果, 以产生更好的重建图像.

## 1 相关工作

### 1.1 注意力机制

注意力机制在计算机视觉领域中已经引起了越来越多的关注<sup>[10-12]</sup>. 在图像分类问题中, Wang 等<sup>[11]</sup>设计了软掩模支路, 同时探索特征在空间维度和通道维度上的关系. Hu 等<sup>[12]</sup>提出了轻量级的挤压和激励 (Squeeze-and-excitation, SE) 模块, 在网络训练过程中探索特征通道之间的内在联系. 在图像理解问题中, Li 等<sup>[13]</sup>提出了引导的注意推理网络, 网络预测结果能够聚焦于感兴趣的区域. Liu 等<sup>[14]</sup>首次将注意力机制引入到 SISR 中, 提出了全局的

注意力产生网络, 能够定位输出特征的高频信息, 以改进 SISR 性能. Zhang 等<sup>[15]</sup>提出的残差通道注意力网络方法, 使用通道注意力机制, 能够选择携带信息丰富的特征通道. 本文主要受 Wang 等<sup>[11]</sup>和 Liu 等<sup>[14]</sup>的启发, 提出了局部像素级注意力模块. 在像素级别上定位高频信息丰富的区域, 以更好地利用特征.

### 1.2 上采样层

上采样层是 SISR 重建中很重要的一个组成部分. 早期基于深度学习的 SISR 方法<sup>[4, 8, 16]</sup>, 一般先将 LR 图像, 用双三次插值到目标 HR 图像的尺寸, 再输入到网络模型. 这有助于减轻学习难度, 但大大增加了网络的计算量与参数量<sup>[17]</sup>. 目前常用的重建方法是直接输入原始的 LR 图像<sup>[18-19]</sup>, 再将网络模型的输出上采样得到重建的 HR 图像. 文献 [18] 和文献 [20] 使用转置的卷积作为上采样层, 文献 [15] 和文献 [19] 使用亚像素卷积进行上采样. 这些单尺度上采样能缓解预上采样的弊端, 但是, 其同样存在难以充分利用网络模型产生的丰富的特征信息的问题. 本文提出了一种多尺度全局自适应的上采样方式: 针对不同的层次特征使用不同尺寸的卷积核, 多尺度地利用网络模型产生的特征信息, 并能够根据自适应参数, 自适应选择不同层次特征的结合方式, 以改进超分辨率的重建效果.

## 2 方法

本文 ACAN 网络模型主要包括: 浅层特征提取模块 (Shallow features extract block, SFEB)、非线性映射模块 (Non-linear mapping block, NLMB)、多尺度全局自适应重建模块和全局残差连接, 如图 1 所示. SFEB 是一个  $3 \times 3$  卷积层, 提取输入 LR 图像的浅层特征, 并将提取的特征输入到 NLMB 模块. 本文使用的所有大小的卷积层的尾部都伴随着激活层, 并且使用 PReLU 作为所有激活层的激活函数, 后文不再详细说明. 受 SRFBN<sup>[5]</sup> 的启发, 本文在 NLMB 中采用类似结构, 并在层次特征提取模块 (Hierarchical features extract block, HFEB) 之间参数共享, 以减少参数量. NLMB 是 HFEB 的多次递归, 在 SFEB 的基础上进一步进行深层特征的提取. HFEB 由 2 个  $3 \times 3$  的卷积层和一个提取及掩模 (Extract-and-mask, EM) 模块组成. 由于本文设计的 ACR 连接, 第 1 个 HFEB 的输入仅为 SFEB 的输出, 之后递归的每一次, HFEB 的输入都包含两个部分: 1) 上一层 HFEB 的输出; 2) 前面所有 HFEB 的输出与对应的自适应参数相

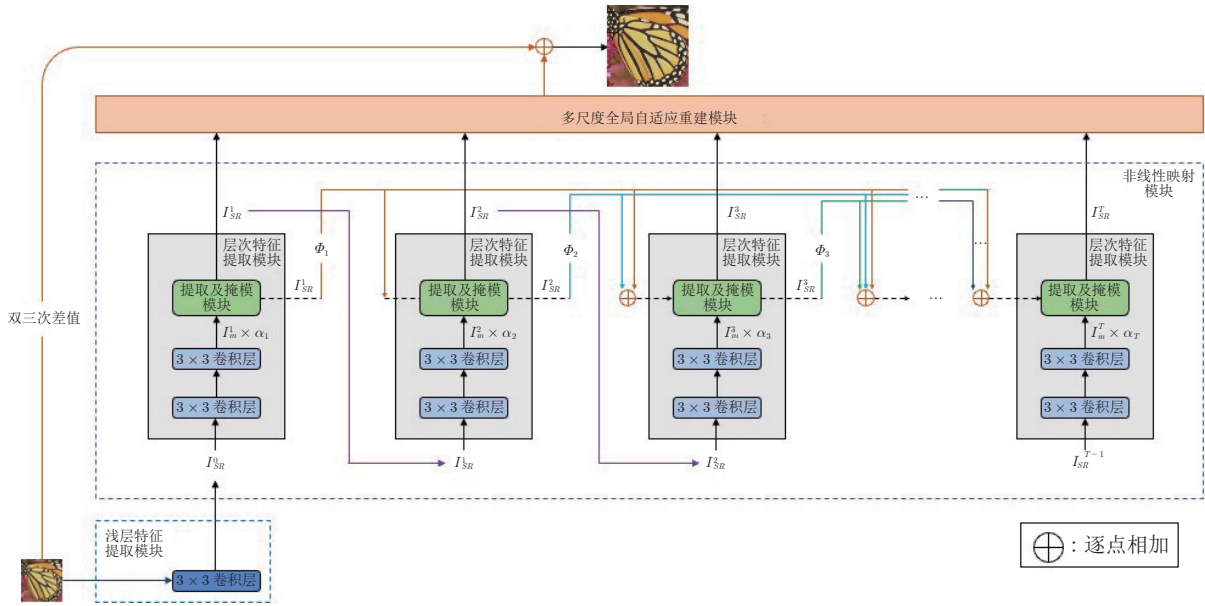


图 1 自适应级联的注意力网络架构 (ACAN)

Fig.1 Adaptive cascading attention network architecture (ACAN)

乘后的和, 并直接输入到当前 HFEB 的 EM 模块中. MGAR 模块则接收 NLMB 所有输出重建残差图像; 最后, 全局残差连接产生双三次插值的 LR 图像, 与残差图像相加之后即为重建的 HR 图像. 由于文献 [21] 已经指出 L2 函数作为损失函数所谓缺点, 所以本文使用 L1 损失函数, 如下式所示:

$$Loss(\hat{I}, I) = \|\hat{I} - I\|_1 \quad (1)$$

式中,  $\hat{I}$  和  $I$  分别代表模型产生的 HR 图像和真实的 HR 图像.

第 2.1 ~ 2.3 节详细介绍 HFEB、EM 模块和 MGAR 模块.

### 2.1 层次特征提取模块 (HFEB)

HFEB 的重要特征是: 每个 HFEB 的输入来源不同. 由于信息在流动过程中会不断损耗, 因此希望使用跳跃连接解决这个问题. 为了有效地进行特征重用, 同时考虑参数数量的问题, 最终搭建了自适应级联残差 (ACR) 连接, 如图 1 所示. ACR 连接结构上类似于级联连接, 但本质上仍为残差连接, 并通过自适应参数控制信息流动. 由图 1 可知, 由于 ACR 连接, 除第 1 个 HFEB 的输入只接收 SFEB 的输出外, 之后的每个 HFEB 的输入都包括两个部分: 1) 上一层 HFEB 的输出; 2) 前面所有 HFEB 的输出与对应的自适应参数相乘后的和.

在第  $t$  个 HFEB 中, 第 1 部分输入 (即第  $t-1$  个 HFEB 的输出), 先经过两个  $3 \times 3$  的卷积层, 然后将输出乘上对应的自适应参数, 并与第 2 部分输

入相加, 再输入到其中的 EM 模块进行高频信息的定位与提取. 第  $t$  个 HFEB 的表达式如下:

$$I_{SR}^t = f_{HFEB}(I_{inter\_in}^t, I_{SR}^{t-1}) \quad (2)$$

式中,  $f_{HFEB}$  表示 HFEB,  $I_{SR}^{t-1}$  和  $I_{inter\_in}^t$  分别为第  $t$  个 HFEB 的第 1 部分输入和第 2 部分输入,  $I_{SR}^t$  为第  $t$  个 HFEB 的输出.

### 2.2 提取及掩模 (EM) 模块

在每个 HFEB 中, 使用 EM 模块选择和提取高频特征信息. EM 模块主要由特征预处理单元、特征提取模块和局部像素级注意力模块 3 个部分组成, 如图 2 所示.




图 2 提取及掩膜模块

Fig.2 The extract and mask block

如前所述, 第  $t$  个 EM 模块的输入来自两部分: 1) 当前 HFEB 中, 经过两个  $3 \times 3$  卷积层的输出  $I_{in}^t$ , 乘上对应的自适应参数  $\alpha_t$  后的积; 2) 前面所有 HFEB 的输出与对应的自适应参数相乘后的和  $I_{inter\_in}^t$ . 二者之和为当前 EM 模块的输入. EM 模块的输入可表示如下:

$$I_{inter\_in}^t = \sum_{i=1}^{t-1} \Phi_i^{t-i} \times I_{SR}^i \quad (3)$$

$$I_{sum\_in}^t = I_{inter\_in}^t + \alpha_t \times I_{in}^t \quad (4)$$

式中,  $I_{sum\_in}^t$  是第  $t$  个 EM 模块最终的输入,  $I_{SR}^i$  是第  $i$  个 EM 模块输出, 同时也是第  $i$  个 HFEB 的输出,  $\Phi_i^{t-i}$  是第  $i$  个 HFEB 输出输入到第  $t$  个 EM 模块时, 对应的自适应参数.

为了缓解梯度消失的问题, 在 EM 模块外增加了局部残差连接. 第  $t$  个 HFEB 中 EM 模块的输出可表示如下:

$$I_{SR}^t = f_{EM}(I_{sum\_in}^t) + I_{sum\_in}^t \quad (5)$$

下面详细介绍 EM 模块的各个组成部分.

### 2.2.1 特征预处理单元

为了初步选择信息更丰富的特征, 先在 EM 模块中, 使用类似于 Hu 等<sup>[12]</sup> 提出的 SE 模块, 进行通道级的特征选择. 为了加权各个特征通道, 将 SE 模块中的 Sigmoid 门函数替换成 Softmax 门函数. 同时为了减少因 Softmax 门函数引起的信息损失, 增加了局部残差连接. 修改的 SE 模块, 可表示如下:

$$I_{SE*} = f_{SE*}(I_{sum\_in}) + I_{sum\_in} \quad (6)$$

式中,  $f_{SE*}$  表示修改后的 SE 模块,  $I_{sum\_in}$  和  $I_{SE*}$  是 EM 模块的输入和输出.

### 2.2.2 特征提取模块

修改后的 SE 模块的输出  $I_{SE*}$ , 输入至特征提取模块, 进行高频信息的提取, 如图 3 所示.

Haris 等<sup>[22]</sup> 已经证明了使用递归的上下采样进行特征提取的有效性. 因此, 也使用这种采样方式进行特征提取. 输入特征  $I_{SE*}$ , 先通过  $4 \times 4$  的转置卷积层上采样得到  $I_{up}^0$ , 然后, 经过  $6 \times 6$  的卷积层下采样得到  $I_{down}^0$ , 如下所示:

$$I_{up}^0 = f_{\uparrow}(I_{SE*}) \quad (7)$$

$$I_{down}^0 = f_{\downarrow}(I_{up}^0) \quad (8)$$

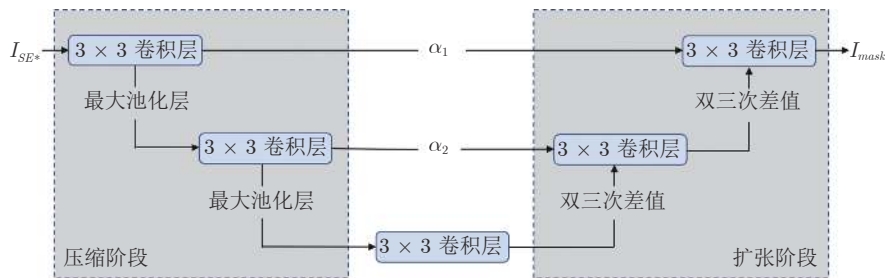


图 4 局部像素级注意力模块

Fig.4 Local pixel-wise attention block




图 3 特征提取模块

Fig.3 Feature extracting block

然后使用局部残差连接将  $I_{down}^0$  与输入  $I_{SE*}$  相减, 再使用转置卷积层上采样得到  $I_{up}^1$ . 最后, 再次通过局部残差连接, 将  $I_{up}^0$  与  $I_{up}^1$  相加, 经卷积层下采样, 得到输出  $I_{out}$ :

$$I_{up}^1 = f_{\uparrow}(I_{down}^0 - I_{SE*}) \quad (9)$$

$$I_{out} = f_{\downarrow}(I_{up}^1 + I_{up}^0) \quad (10)$$

特征提取模块中, 使用的两次转置卷积和两次卷积, 都使用了参数共享. 特征提取模块  $f_{up\_down}$  可表示如下:

$$I_{out} = f_{up\_down}(I_{SE*}) \quad (11)$$

### 2.2.3 局部像素级注意 (LPA) 模块

由于通道注意力机制只按通道携带的信息量多少进行选择, 对于高频信息的定位可能不够准确. 受 Wang 等<sup>[11]</sup> 和 Liu 等<sup>[14]</sup> 的启发, 提出局部像素级注意 (LPA) 模块, 进行像素级的高频信息定位. LPA 模块如图 4 所示, 为了减小参数量, 各卷积层的参数都是共享的.

在压缩阶段, 使用了 2 个连续的  $3 \times 3$  卷积层-最大池化操作. 最大池化下采样有助于扩大感受野和定位高频特征信息区域. 压缩阶段可表示如下:

$$I_{exp} = f_{\downarrow}(W_0 \times f_{\downarrow}(W_0 \times I_{SE*})) \quad (12)$$

$I_{SE*}$  和  $I_{exp}$  分别是 LPA 模块的输入特征和压缩阶段的输出特征.  $W_0$  是卷积层的参数 (省略偏差以简化符号),  $f_{\downarrow}$  表示最大池化的下采样.

在扩张阶段, 设置与压缩阶段对称的 2 个连续的上采样- $3 \times 3$  卷积层, 并使用双三次插值作为上采样方式. 考虑到下采样会造成部分信息丢失, 在

扩张阶段和压缩阶段的对应位置处建立了跳跃连接, 并且引入了可学习的自适应参数  $\alpha$ , 调节从压缩阶段连接到扩张阶段的特征信息. 扩张阶段如下所示:

$$I_{mask} = W_0 \times f_{\uparrow}(W_0 \times f_{\uparrow}(I_{ext} + \alpha_2 \times I_2) + \alpha_1 \times I_1) \quad (13)$$

式中,  $I_{ext}$  和  $I_{mask}$  分别是扩张阶段的输入 (即压缩阶段的输出  $I_{exp}$  再经过  $3 \times 3$  的卷积层之后的输出) 和扩张阶段的输出,  $I_{mask}$  同时也是 LPA 模块的输出.  $I_1$  和  $I_2$  分别是压缩阶段第 1 次和第 2 次卷积层的输出,  $\alpha_1$  和  $\alpha_2$  是自适应参数.  $f_{\uparrow}$  是双三次插值上采样.

### 2.3 多尺度全局自适应重建 (MGAR) 模块

文献 [4-9] 大多是单尺度的重建, 受 MSRN<sup>[21]</sup> 的启发, 提出了多尺度重建的 MGAR 模块, 可以利用 NLMB 中提取的层次特征, 进一步改进 SISR 重建性能. MGAR 模块与 MSRN 中 MSRB 的区别在于: MGAR 模块是一个 SISR 重建模块, 多尺度利用之前的层次特征, 重建残差图像; MSRB 是一个特征提取模块, 仅处理前一个 MSRB 输出的特征.

MGAR 模块如图 5 所示. 由于 NLMB 中低层 HFEB 的感受野较小, 故在 MGAR 模块中使用较大的卷积核与之对应, 然后, 逐渐减少卷积核的大小. 考虑到参数量的约束, 选取最大的卷积核尺寸为 9, 最小的卷积核尺寸为 3. 假定 NLMB 中有  $T$  个 HFEB, 第  $t$  ( $1 \leq T \leq 8$ ) 个 HFEB 的输出  $I_{SR}^t$  在 MGAR 模块中对应的卷积核的尺寸计算为:

$$S_t = \left\lfloor \frac{(T-t) \bmod 8}{2} \right\rfloor \times 2 + 3 \quad (14)$$

当  $T > 8$  时, 由于此时网络已经有足够的深度,

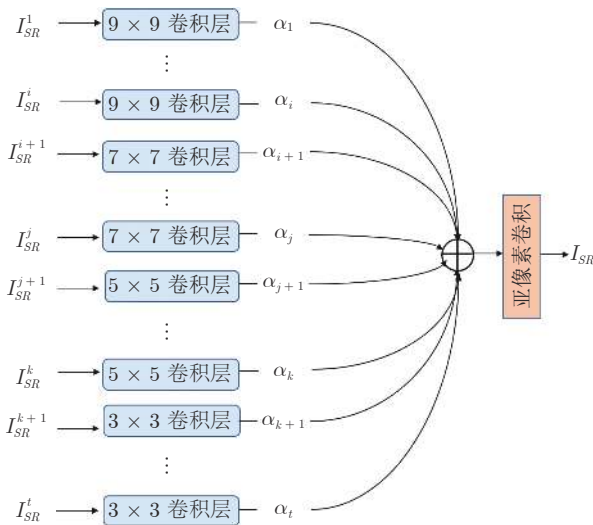


图 5 多尺度全局自适应重建模块

Fig. 5 Multi-scale global adaptive reconstruction block

所以设置 MGAR 模块中前 8 层的卷积核大小与  $T = 8$  时相同, 之后的卷积核大小均设置为 3.

MGAR 模块的每一个输入, 与对应卷积核卷积后, 再与一个可学习的自适应参数相乘, 作为当前支路的输出. 各个分支的和, 经过亚像素卷积<sup>[19]</sup>上采样之后, 作为 MGAR 模块的最终输出. 对输入的 LR 图像进行双三次上采样后, 与 MGAR 模块的输出求和, 得到重构的 HR 图像, 用公式表示如下:

$$I_{SR} = f_{MGAR}(I_{SR}^1, I_{SR}^2, \dots, I_{SR}^t) + f_{up}(I_{LR}) \quad (15)$$

式中,  $I_{SR}$  是输出的 HR 图像,  $I_{LR}$  是输入的 LR 图像,  $f_{MGAR}$  和  $f_{up}$  分别表示 MGAR 模块和双三次插值的上采样.

## 3 实验细节

### 3.1 设置

本文实验保持与之前的研究文献设置相同. 训练图像: DIV2k 数据集<sup>[23]</sup> 中 800 张高质量图像; 测试图像: 共同使用的 Set5<sup>[24]</sup>, Set14<sup>[25]</sup>, Urban100<sup>[26]</sup>, B100<sup>[27]</sup> 和 Manga109<sup>[28]</sup> 测试集; 验证图像: DIV2k 数据集中第 801 ~ 810 张高质量图像; 训练图像增扩: 进行 90、180、270 度旋转、水平翻转和随机裁剪. 训练阶段: 在 RGB 颜色空间上进行训练, 并且使用梯度裁剪策略稳定训练过程. 测试阶段: 所有彩色图像均转换到 YCrCb 颜色空间, 在亮度通道 Y 上进行测试. 每一个最小批训练输入: 16 个  $48 \times 48$  的图像. 使用 Adam 优化器<sup>[29]</sup> 训练网络, 其中设置  $\beta_1 = 0.9$ ,  $\beta_2 = 0.999$ ,  $\epsilon = 10^{-8}$ . 初始学习率  $e = 10^{-4}$ , 每经过 200 个回合, 学习率  $e$  衰减一半. 使用 NVIDIA GeForce RTX 2080Ti GPU (11GB 内存) 和 PyTorch 框架构建网络.

在 NLMB 中, 每个 HFEB 的第 1 个卷积层, 输出通道数为 128, 其余卷积层的输出通道数均为 64. ACR 连接中, 所有自适应参数的初始值为 0.2. 在 MGAR 模块中, 所有的自适应参数初始化为  $1/n$ ,  $n$  是 NLMB 中 HFEB 的个数, 并且每个卷积层的输入通道数为 64, 输出通道数为  $3 \times r \times r$ , 此处的  $r$  代表放大因子. 除网络模型深度对图像重建的对比实验外, 在其他所有实验中均设置  $n = 8$  个 HFEB. 使用测试图像进行客观定量比较, 使用验证图像选择模型参数及相关结构.

### 3.2 模型分析

#### 3.2.1 MGAR 模块中卷积核尺寸的选择

在 MGAR 模块中, 选择卷积核尺寸为 9、7、5、3 的排列顺序, 具体参见第 2.3 节. 下面分析不同排列顺序对重建结果的影响, MGAR 模块结构见图 5.

MGAR 模块的输入来自 NLMB 的 HFEB, 浅层 HFEB 的感受野较小, 使用较大的卷积核, 以提取更加全局的背景信息; 深层 HFEB 的感受野较大, 使用较小的卷积核, 防止提取不相关的背景信。在 MGAR 模块中, 每个卷积层的输出特征如图 6 所示。浅层 HFEB 输出的特征包含更多连续的高频信息, 深层 HFEB 输出的特征包含更多分散的高频信息。不同层次特征信息互补, 可以增强 HR 图像的重建效果。

下面设置 4 组对比实验, 进一步量化卷积核的排列顺序对重建结果的影响。4 组实验使用的卷积核尺寸分别是: 第 1 组为 9、7、5、3; 第 2 组为 3、5、7、9; 第 3 组均为 3; 第 4 组均为 9。实验结果如表 1 所示, 由于第 1 组实验合理设置了卷积核的尺寸, 因此获得最好的重建效果。

### 3.2.2 不同层次特征对重建结果的影响

为分析 NLMB 中不同层次特征对重建结果的影响, 依次移除 MGAR 模块中不同大小的卷积层, 计算重建 HR 图像的峰值信噪比 (Peak signal-to-noise ratio, PSNR)。计算结果如表 2 所示, 与越小卷积核对应的 HFEB 产生的层次特征对重建结果影响更大, 即更深层的 HFEB 产生的层次特征, 对重建结果的影响更大。

### 3.2.3 MGAR 模块的优势

下面分析 MGAR 模块相比于普通单尺度重建模块的优势。由于使用了类似深度反向投影网络 (Deep back-projection networks, DBPN)<sup>[22]</sup> 方法的

采样方式, 所以在 DBPN 上进行实验, 并且用 MGAR 模块替换原有的单尺度重建模块。在 DBPN 中设置  $T = 6$ , 假定原始 DBPN 方法称为 O-DBPN; 用 MGAR 模块替换后的 DBPN 方法称为 M-DBPN。重建结果如表 3 所示, 使用了 MGAR 模块的 DBPN 方法, 比原始 DBPN 方法的重建性能更好。

### 3.2.4 LPA 模块的设计考虑

LPA 模块中未包含 Sigmoid 门函数。为了解 Sigmoid 门函数的作用, 进行了 LPA 模块末尾包含和不包含 Sigmoid 门函数 2 种情形实验。实验结果如表 4 所示, 带有 Sigmoid 门函数的 LPA 模块性能要低一些。

LPA 模块另一个考虑的因素是: 压缩阶段和扩张阶段对应位置的跳跃连接方式, 具体参见第 2.2.3 节。本文设计了 3 个对比实验: 实验 1 是直接使用残差连接; 实验 2 是去掉残差连接; 实验 3 是带有自适应参数的残差连接。实验结果如表 5 所示, 实验 2 比实验 1 效果好一些, 实验 3 效果最好。说明直接引入压缩阶段的特征确实会影响 LPA 模块对高频信息的定位, 并且加入自适应参数能够很好地缓解这个问题。

### 3.2.5 LPA 模块对重建结果的影响

为验证 LPA 模块对重建效果的影响, 进行以下两种情形的对比试验: 在 HFEB 的 EM 模块中, 包含和不包含 LPA 模块。实验结果如表 6 所示, 可以看出有 LPA 模块效果更好。说明 LPA 模块确实对重建效果有帮助。




图 6 非线性映射模块中每个 HFEB 输出特征的可视化结果

Fig. 6 Visual results of each HFEB's output feature in non-linear mapping

表 1 不同卷积核的排列顺序对重建效果的影响  
Table 1 Effect of convolution kernels with different order on reconstruction performance

卷积组排列顺序	9753	3579	3333	9999
PSNR (dB)	35.569	35.514	35.530	35.523

表 2 不同层次特征对重建效果的影响  
Table 2 Impact of different hierarchical features on reconstruction performance

移除的卷积组大小	3	5	7	9
PSNR (dB)	35.496	35.517	35.541	35.556

表 3 原始 DBPN (O-DBPN) 和使用 MGAR 模块的 DBPN (M-DBPN) 的客观效果比较  
Table 3 Objective comparison between original DBPN (O-DBPN) and DBPN (M-DBPN) using MGAR module

使用不同重建模块的DBPN	PSNR (dB)
O-DBPN	35.343
M-DBPN	35.399

表 4 Sigmoid 门函数的有无对 LPA 模块性能的影响  
Table 4 Influence of Sigmoid gate function to LPA block

Sigmoid门函数	PSNR (dB)
有	35.569
无	35.497

表 5 不同残差的连接方式对重建效果的影响  
Table 5 Effect of different residual connection methods on reconstruction performance

不同种类的残差连接	PSNR (dB)
残差连接	35.515
无残差连接	35.521
带自适应参数的残差连接	35.569

表 6 使用和未使用 LPA 模块的客观效果比较  
Table 6 Comparison of objective effects of ACAN with and without LPA module

LPA模块	PSNR (dB)
使用	35.569
未使用	35.489

### 3.2.6 ACR 连接对重建结果的影响

ACR 连接参见图 1(a). 为了观察 ACR 连接的有效性, 分别在 NLMB 中使用 ACR 连接、残差连接和级联连接进行对比实验, 实验结果如表 7 所示.

从表 7 可以看出, 残差连接优于级联连接, ACR 连接效果最好. 由此可见, 使用自适应的级联残差

表 7 NLMB 使用 3 种不同连接方式对重建效果的影响  
Table 7 Impact of using three different connection methods on NLMB on reconstruction performance

使用的跳跃连接	PSNR (dB)
残差连接	35.542
级联连接	35.502
自适应级联残差连接	35.569

能更有利地进行特征重用, 改进了 SISR 的重建性能.

### 3.3 网络模型深度选择

为了探索 NLMB 中 HFEB 的个数 (表示为  $T$ ), 对于重建性能的影响. 设置了 4 组对比实验: 在放大因子为 2 的情况下,  $T = 1, 3, 6, 8$ , 对应的训练曲线及测试曲线如图 7 和图 8 所示. 可以看出, HFEB 的多次级联有利于提高重建效果.




图 7 包含不同个数的 HFEB 的 ACAN 在验证集上的性能比较

Fig. 7 Performance comparison of ACAN on validation set with different numbers of HFEB




图 8 包含不同个数的 HFEB 的 ACAN 在 Set5 测试集上的性能比较

Fig. 8 Performance comparison of ACAN on Set5 testing set with different number of HFEB

为了进一步精确  $T$  的选择, 在放大因子为 2 的情况下设置  $T = 6, 7, 8, 9$  进行对比实验. 由表 8 可以看出,  $T = 8$  是合理的选择.

### 3.4 与当前先进的方法比较

本文 ACAN 方法与高分辨率图像 (High resol-

表 8 不同网络模型深度对重建性能的影响  
Table 8 Impact of different network depths on reconstruction performance

$T$	6	7	8	9
PSNR (dB)	35.530	35.538	35.569	35.551

ation, HR)、双三次插值 (Bicubic interpolation, Bicubic)、SRCNN、LapSRN、SRFBN-S、CARN、FSRCNN、VDSR 和 SRMDNF 9 个方法进行主观

效果比较.

1) 客观定量结果. 本文 ACAN 方法与 SRCNN<sup>[4]</sup>、快速超分辨率卷积神经网络 (Fast super-resolution convolutional neural networks, FSR-CNN)<sup>[18]</sup>、极深卷积神经网络 (Very deep convolutional networks, VDSR)<sup>[16]</sup>、DRCN<sup>[6]</sup>、拉普拉斯金字塔超分辨率网络 (Laplacian pyramid super-resolution network, LapSRN)<sup>[30]</sup>、DRRN<sup>[7]</sup>、MemNet<sup>[8]</sup>、用于多重无噪衰减的超分辨率网络 (Super-resolu-

表 9 各种 SISR 方法的平均 PSNR 值与 SSIM 值  
Table 9 Average PSNR/SSIM of various SISR methods

放大倍数	模型	参数量	Set5	Set14	B100	Urban100	Manga109
			PSNR / SSIM	PSNR / SSIM	PSNR / SSIM	PSNR / SSIM	PSNR / SSIM
×2	SRCNN	57 K	36.66 / 0.9524	32.42 / 0.9063	31.36 / 0.8879	29.50 / 0.8946	35.74 / 0.9661
	FSRCNN	12 K	37.00 / 0.9558	32.63 / 0.9088	31.53 / 0.8920	29.88 / 0.9020	36.67 / 0.9694
	VDSR	665 K	37.53 / 0.9587	33.03 / 0.9124	31.90 / 0.8960	30.76 / 0.9140	37.22 / 0.9729
	DRCN	1774 K	37.63 / 0.9588	33.04 / 0.9118	31.85 / 0.8942	30.75 / 0.9133	37.63 / 0.9723
	LapSRN	813 K	37.52 / 0.9590	33.08 / 0.9130	31.80 / 0.8950	30.41 / 0.9100	37.27 / 0.9740
	DRRN	297 K	37.74 / 0.9591	33.23 / 0.9136	32.05 / 0.8973	31.23 / 0.9188	37.92 / 0.9760
	MemNet	677 K	37.78 / 0.9597	33.28 / 0.9142	32.08 / 0.8978	31.31 / 0.9195	37.72 / 0.9740
	SRMDNF	1513 K	37.79 / 0.9600	33.32 / 0.9150	32.05 / 0.8980	31.33 / 0.9200	38.07 / 0.9761
	CARN	1592 K	37.76 / 0.9590	33.52 / 0.9166	32.09 / 0.8978	31.92 / 0.9256	38.36 / 0.9765
	SRFBN-S	282K	37.78 / 0.9597	33.35 / 0.9156	32.00 / 0.8970	31.41 / 0.9207	38.06 / 0.9757
本文 ACAN	800 K	<u>38.10 / 0.9608</u>	<u>33.60 / 0.9177</u>	<u>32.21 / 0.9001</u>	<u>32.29 / 0.9297</u>	<u>38.81 / 0.9773</u>	
<b>本文 ACAN+</b>	<b>800 K</b>	<b>38.17 / 0.9611</b>	<b>33.69 / 0.9182</b>	<b>32.26 / 0.9006</b>	<b>32.47 / 0.9315</b>	<b>39.02 / 0.9778</b>	
×3	SRCNN	57 K	32.75 / 0.9090	29.28 / 0.8209	28.41 / 0.7863	26.24 / 0.7989	30.59 / 0.9107
	FSRCNN	12 K	33.16 / 0.9140	29.43 / 0.8242	28.53 / 0.7910	26.43 / 0.8080	30.98 / 0.9212
	VDSR	665 K	33.66 / 0.9213	29.77 / 0.8314	28.82 / 0.7976	27.14 / 0.8279	32.01 / 0.9310
	DRCN	1774 K	33.82 / 0.9226	29.76 / 0.8311	28.80 / 0.7963	27.15 / 0.8276	32.31 / 0.9328
	DRRN	297 K	34.03 / 0.9244	29.96 / 0.8349	28.95 / 0.8004	27.53 / 0.8378	32.74 / 0.9390
	MemNet	677 K	34.09 / 0.9248	30.00 / 0.8350	28.96 / 0.8001	27.56 / 0.8376	32.51 / 0.9369
	SRMDNF	1530 K	34.12 / 0.9250	30.04 / 0.8370	28.97 / 0.8030	27.57 / 0.8400	33.00 / 0.9403
	CARN	1592 K	34.29 / 0.9255	30.29 / 0.8407	29.06 / 0.8034	27.38 / 0.8404	33.50 / 0.9440
	SRFBN-S	376 K	34.20 / 0.9255	30.10 / 0.8372	28.96 / 0.8010	27.66 / 0.8415	33.02 / 0.9404
	本文 ACAN	1115 K	<u>34.46 / 0.9277</u>	<u>30.39 / 0.8435</u>	<u>29.11 / 0.8055</u>	<u>28.28 / 0.8550</u>	<u>33.61 / 0.9447</u>
<b>本文 ACAN+</b>	<b>1115 K</b>	<b>34.55 / 0.9283</b>	<b>30.46 / 0.8444</b>	<b>29.16 / 0.8065</b>	<b>28.45 / 0.8577</b>	<b>33.91 / 0.9464</b>	
×4	SRCNN	57 K	30.48/0.8628	27.49 / 0.7503	26.90 / 0.7101	24.52 / 0.7221	27.66 / 0.8505
	FSRCNN	12 K	30.71 / 0.8657	27.59 / 0.7535	26.98 / 0.7150	24.62 / 0.7280	27.90 / 0.8517
	VDSR	665 K	31.35 / 0.8838	28.01 / 0.7674	27.29 / 0.7251	25.18 / 0.7524	28.83 / 0.8809
	DRCN	1774 K	31.53 / 0.8854	28.02 / 0.7670	27.23 / 0.7233	25.14 / 0.7510	28.98 / 0.8816
	LapSRN	813 K	31.54 / 0.8850	28.19 / 0.7720	27.32 / 0.7280	25.21 / 0.7560	29.09 / 0.8845
	DRRN	297 K	31.68 / 0.8888	28.21 / 0.7720	27.38 / 0.7284	25.44 / 0.7638	29.46 / 0.8960
	MemNet	677 K	31.74 / 0.8893	28.26 / 0.7723	27.40 / 0.7281	25.50 / 0.7630	29.42 / 0.8942
	SRMDNF	1555 K	31.96 / 0.8930	28.35 / 0.7770	27.49 / 0.7340	25.68 / 0.7730	30.09 / 0.9024
	CARN	1592 K	32.13 / 0.8937	28.60 / 0.7806	27.58 / 0.7349	26.07 / 0.7837	30.47 / 0.9084
	SRFBN-S	483 K	31.98 / 0.8923	28.45 / 0.7779	27.44 / 0.7313	25.71 / 0.7719	29.91 / 0.9008
本文 ACAN	1556 K	<u>32.24 / 0.8955</u>	<u>28.62 / 0.7824</u>	<u>27.59 / 0.7366</u>	<u>26.17 / 0.7891</u>	<u>30.53 / 0.9086</u>	
<b>本文 ACAN+</b>	<b>1556 K</b>	<b>32.35 / 0.8969</b>	<b>28.68 / 0.7838</b>	<b>27.65 / 0.7379</b>	<b>26.31 / 0.7922</b>	<b>30.82 / 0.9117</b>	



tion network for multiple noise-free degradations, SRMDNF)<sup>[31]</sup>、CARN<sup>[9]</sup> 和 SRFBN-S<sup>[5]</sup>10 个当前类似的先进方法进行比较, 同时采用自组方法<sup>[32]</sup>, 进一步提高 ACAN 的性能 (称为 ACAN+). 采用共同的客观度量标准: 平均峰值信噪比 (PSNR) 和结构相似性 (Structural similarity index, SSIM)<sup>[33]</sup>, 计算结果如表 9 所示. 最好结果与次好结果分别用加粗和下划线标出. ACAN+ 的平均 PSNR 和 SSIM 度量显著优于其他方法, 包括之前最好的方法 CARN, 而在  $\times 2$  情况下参数量大约只有其一半. 即使未使用自组方法, 本文 ACAN 方法也优于其他所有的方法. 本文方法性能提升的原因主要有: ACR 连接、LPA 模块和 MGAR 模块发挥了作用. LPA 模块能够更加精准地选择高频特征信息, MGAR 模块能够充分利用多尺度的特征信息, ACR 连接更有效

地进行特征重用, 这些因素导致了本文 ACAN 方法性能的显著提高.

2) 主观效果比较: 如图 9 所示: 第 1 组图是 Urban 100 数据集中的 image 024 在  $\times 4$  下的比较结果; 第 2 组图是 Urban 100 数据集中的 image 061 在  $\times 4$  下的比较结果; 第 3 组图是 Urban 100 数据集中的 img 092 在  $\times 4$  下的比较结果. ACAN 方法显著优于其他方法. 以 Urban 100 中的 img 061 图像为例, 在放大因子为 4 的情况下, 对于图中玻璃上难以恢复的网格细节, SRFBN-S、CARN 和 SRMDNF 方法都遭遇了严重的失真, SRCNN 方法的重建图像遭遇到严重模糊. 而 ACAN 几乎完美地恢复了原 HR 图像中纹理和网格信息. 在放大因子为 4 的情况下, 另外两个图像的结果也与 img 061 图像的结果类似. 本文方法之所以能够




图 9 视觉比较结果

Fig.9 Visual comparison of images

更好地重建纹理和网格信息, 主要得益于 ACR 连接、LPA 模块和 MGAR 模块. ACR 连接能够有效地重用特征; LPA 模块能够准确定位特征中的高频信息; MGAR 模块能够利用多尺度层次特征. 因此, 能够更好地恢复规则的形状和结构<sup>[34]</sup>. 由于 Urban 100 数据集中, 包含较多建筑物的规则结构<sup>[22]</sup>, 本文方法性能提升显著. 如何进一步提升不规则的形状和结构重建效果, 仍是有待研究和解决的问题.

## 4 结束语

本文提出了一个新的轻量级单图像超分辨率方法, 使用自适应级联的注意力网络 (ACAN) 能够高质量重建超分辨率图像. 本文的局部像素级注意力 (LPA) 模块, 通过对输入特征进行像素级的高频信息定位, 加强了特征流动过程中对高频特征信息的选择能力; 本文的多尺度全局自适应重建 (MGAR) 模块, 使用不同尺寸的卷积核, 能够自适应地选择和组合多尺度的特征信息; 本文的自适应级联残差 (ACR) 连接, 能够自适应地组合不同层次特征. 充分的实验结果也验证了 ACAN 方法的良好性能.

## References

- Freeman W T, Pasztor E C, Carmichael O T. Learning lowlevel vision. *International Journal of Computer Vision*, 2000, **40**(1): 25–47
- Peyré G, Bougleux S, Cohen L. Non-local regularization of inverse problems. In: Proceedings of the European Conference on Computer Vision. Berlin, Germany: Springer, Heidelberg, 2008. 57–68
- LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015, **521**(7553): 436–444
- Dong C, Loy C C, He K, Tang X. Learning a deep convolutional network for image super-resolution. In: Proceedings of the European Conference on Computer Vision. Zurich, Switzerland: Springer, Cham, 2014. 184–199
- Li Z, Yang J, Liu Li Z, Yang J, Liu Z, Yang X, et al. Feedback network for image superresolution. In: Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE, 2019. 3867–3876
- Kim J, Kwon Lee J, Mu Lee K. Deeply-recursive convolutional network for image super-resolution. In: Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016. 1637–1645
- Tai Y, Yang J, Liu X. Image super-resolution via deep recursive residual network. In: Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE, 2017. 3147–3155
- Tai Y, Yang J, Liu X, Xu C. Memnet: A persistent memory network for image restoration. In: Proceedings of the 2017 IEEE International Conference on Computer Vision. Venice, Italy: IEEE, 2017. 4539–4547
- Ahn N, Kang B, Sohn K A. Fast, accurate, and lightweight super-resolution with cascading residual network. In: Proceedings of the European Conference on Computer Vision. Zurich, Switzerland: Springer, Cham, 2018. 252–268
- Cao C, Liu X, Yang Y, Yu Y, Wang J, Wang Z, et al. Look and think twice: Capturing top-down visual attention with feedback convolutional neural networks. In: Proceedings of the 2015 IEEE International Conference on Computer Vision. Santiago, Chile: IEEE, 2015. 2956–2964
- Wang F, Jiang M, Qian C, Yang S, Li C, Zhang H, et al. Residual attention network for image classification. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE, 2017. 3156–3164
- Hu J, Shen L, Sun G. Squeeze-and-excitation networks. In: Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE, 2018. 7132–7141
- Li K, Wu Z, Peng K C, Ernst J, Fu Y. Tell me where to look: Guided attention inference network. In: Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE, 2018. 9215–9223
- Liu Y, Wang Y, Li N, Cheng X, Zhang Y, Huang Y, et al. An attention-based approach for single image super resolution. In: Proceedings of the 2018 24th International Conference on Pattern Recognition. Beijing, China: IEEE, 2018. 2777–2784
- Zhang Y, Li K, Li K, Wang L, Zhong B, Fu Y. Image super-resolution using very deep residual channel attention networks. In: Proceedings of the European Conference on Computer Vision. Zurich, Switzerland: Springer, Cham, 2018. 286–301
- Kim J, Kwon Lee J, Mu Lee K. Accurate image superresolution using very deep convolutional networks. In: Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016. 1646–1654
- Wang Z, Chen J, Hoi S C H. Deep learning for image superresolution: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, **43**(10): 3365–3387
- Dong C, Loy C C, Tang X. Accelerating the super-resolution convolutional neural network. In: Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Zurich, Switzerland: Springer, Cham, 2016. 391–407
- Shi W, Caballero J, Huszár F, Totz J, Aitken A P, Bishop R, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network. In: Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016. 1874–1883
- Tong T, Li G, Liu X, Gao Q. Image super-resolution using dense skip connections. In: Proceedings of the 2017 IEEE International Conference on Computer Vision. Venice, Italy: IEEE, 2017. 4799–4807
- Li J, Fang F, Mei K, Zhang G. Multi-scale residual network for image super-resolution. In: Proceedings of the European Conference on Computer Vision. Zurich, Switzerland: Springer, Cham, 2018. 517–532
- Haris M, Shakhnarovich G, Ukita N. Deep back-projection networks for super-resolution. In: Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA, 2018. 1664–1673
- Agustsson E, Timofte R. Ntire 2017 challenge on single image super-resolution: Dataset and study. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. Honolulu, USA: IEEE, 2017. 126–135
- Bevilacqua M, Roumy A, Guillemot C, Albiro-Morel M L. Low-complexity single-image super-resolution based on nonnegative neighbor embedding. In: Proceedings of the 23rd British Machine Vision Conference. Guildford, UK: BMVA Press, 2012. (135): 1–10
- Zeyde R, Elad M, Protter M. On single image scale-up using sparse-representations. In: Proceedings of International Conference on Curves and Surfaces. Berlin, Germany: Springer, Heidelberg, 2010. 711–730
- Huang J B, Singh A, Ahuja N. Single image super-resolution from transformed self-exemplars. In: Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition.

- Boston, USA: IEEE, 2015. 5197–5206
- 27 Martin D, Fowlkes C, Tal D, Malik J. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics. In: Proceedings of the 2001 International Conference on Computer Vision. Vancouver, Canada: IEEE, 2015. 416–423
- 28 Matsui Y, Ito K, Aramaki Y, Fujimoto A, Ogawa T, Yamasaki T, et al. Sketch-based manga retrieval using manga109 dataset. *Multimedia Tools and Applications*, 2017, **76**(20): 21811–21838
- 29 Kingma D P, Ba J. Adam: A method for stochastic optimization. arXiv preprint, 2014, arXiv: 1412.6980
- 30 Lai W S, Huang J B, Ahuja N, Yang M H. Deep laplacian pyramid networks for fast and accurate super-resolution. In: Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE, 2017. 5835–5843
- 31 Zhang K, Zuo W, Zhang L. Learning a single convolutional super-resolution network for multiple degradations. In: Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE, 2018. 3262–3271
- 32 Timofte R, Rothe R, Van Gool L. Seven ways to improve example-based single image super resolution. In: Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016. 1865–1873
- 33 Wang Z, Bovik A C, Sheikh H R, Simoncelli E P. Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, 2004, **13**(4): 600–612
- 34 Wu H, Zou Z, Gui J, Zeng W J, Ye J, Zhang J, et al. Multi-grained attention networks for single image super-resolution. *IEEE Transactions on Circuits and Systems for Video Technology*, 2020, **31**(2): 512–522



**陈一鸣** 现为北京大学计算机学院硕士研究生. 主要研究方向为计算机视觉, 深度学习和生物计算.

E-mail: 88143221@163.com

**(CHEN Yi-Ming** Master student at the School of Computer Science, Peking University currently. His research interest covers computer vision, deep learning and biocomputing.)



**周登文** 华北电力大学控制与计算机工程学院教授. 主要研究方向为图像处理, 神经网络和深度学习在图像处理和计算机视觉中的应用和图像超分辨率技术. 本文通信作者.

E-mail: zdw@ncepu.edu.cn

**(ZHOU Deng-Wen** Professor at the School of Control and Computer Engineering, North China Electric Power University. His research interest covers image processing the applications, neural networks and deep learning in image processing and computer vision and image super-resolution technology. Corresponding author of this paper.)