

基于多层次特征融合的图像超分辨率重建

李金新¹ 黄志勇¹ 李文斌¹ 周登文¹

摘要 深度卷积神经网络显著改进了单图像超分辨率的性能。更深的网络往往能获得更好的性能。但是，加深网络会导致参数量急剧增加，限制了它在资源受限设备上的应用，比如智能手机。提出了一个融合多层次特征的轻量级单图像超分辨率网络，主要构件是双层嵌套残差块。为了更好地提取特征，减少参数量，每个残差块采用对称结构：先两次扩张，然后两次压缩通道数。在残差块中，通过添加自相关权重单元，加权融合不同通道的特征信息。实验证明，该方法显著优于当前同类方法。

关键词 残差学习，层次特征信息，超分辨率，卷积神经网络

引用格式 李金新, 黄志勇, 李文斌, 周登文. 基于多层次特征融合的图像超分辨率重建. 自动化学报, 2023, 49(1): 161–171

DOI 10.16383/j.aas.c200585

Image Super-resolution Based on Multi-hierarchical Features Fusion Network

LI Jin-Xin¹ HUANG Zhi-Yong¹ LI Wen-Bin¹ ZHOU Deng-Wen¹

Abstract Single image super-resolution based on deep convolutional neural network has made notable achievements. Deeper networks tend to get better performance. However, deepening the network will result in a sharp increase in the number of parameters, which limits its application in resource-constrained devices, such as mobile devices. In this paper, we propose a lightweight multi-hierarchical feature fusion network for single image super-resolution, whose main building blocks are the dual nested residual blocks. In order to better extract features and reduce the number of parameters as much as possible, the dual residual block uses an excite-and-squeeze structure. To better transfer feature information, we add auto-correlation weigh units to the dual nested residual block, which can weigh each channel according to the image feature information. Extensive experiments show that our method is significantly better than the existing methods.

Key words Residual learning, hierarchical features, super-resolution, convolutional neural network

Citation Li Jin-Xin, Huang Zhi-Yong, Li Wen-Bin, Zhou Deng-Wen. Image super-resolution based on multi-hierarchical features fusion network. *Acta Automatica Sinica*, 2023, 49(1): 161–171

单图像超分辨率 (Single image super-resolution, SISR) 技术旨在将一幅低分辨率 (Low-resolution, LR) 图像重建其对应的高分辨率 (High-resolution, HR) 图像。SISR 被广泛应用于医学成像^[1]、遥感^[2] 和安防^[3] 等领域。超分辨率重建是一个病态的逆问题：一个 LR 图像可与多个 (High-resolution, HR) 图像对应，恢复细节逼真、丰富的 HR 图像非常困难。超分辨率成像是计算机视觉领域的热点问题之一，深度学习技术已主导了当前 SISR 方法的研究^[4–13]。

基于深度学习的 SISR 方法直接端到端地学习 LR 图像与 HR 图像之间的映射关系。Dong 等^[7] 第一个提出基于卷积神经网络^[14] 的 SISR 方法，称为

收稿日期 2020-07-24 录用日期 2020-12-14
Manuscript received July 24, 2020; accepted December 14, 2020

本文责任编辑 杨健
Recommended by Associate Editor YANG Jian
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

SRCNN。SRCNN 仅使用了三个卷积层，以端到端的形式直接学习 LR 和 HR 图像间的非线性映射。Kim 等^[15] 基于残差学习^[16]，提出网络更深的 SISR 方法 (Very deep convolutional networks for super-resolution, VDSR)，改进了性能。为了能够增加网络深度，又限制网络参数的增加，Kim 等^[8] 采用共享参数的递归结构，提出了 Deeply-recursive convolutional Network (DRCN) 方法。Tai 等^[9] 提出的 Deep recursive residual network (DRRN)，同时利用了局部残差结构、全局残差结构和递归结构。残差单元之间参数共享，改进了 VDSR 和 DRCN 的性能。Li 等^[17] 提出的 Super-resolution feedback network (SRFBN-S) 方法，使用循环神经网络结构，共享隐藏层参数，降低参数量的同时提升了重建图像质量。Hui 等^[18] 提出 Information multi-distillation network (IMDN) 方法，在残差块内逐步提取特征信息，利用通道注意力机制进行特征选择，进一步提高了重建图像质量。Ahn 等^[10] 提出了基于

级联残差网络的 SISR 方法 (Cascading residual network, CARN), 结合级联结构与残差学习, 取得了更好的参数量和性能之间的平衡. Zhu 等^[19] 提出 Compact back-projection network (CBPN) 方法, 通过级联上/下采样层, 在 LR 和 HR 空间中提取特征信息, 增强了重建能力. Li 等^[11] 提出的 Multi-scale residual network (MSRN) 方法, 残差块内运用不同感受野的卷积层, 提取不同尺度的特征信息, 进一步改进了性能. Lai 等^[20] 提出了拉普拉斯金字塔网络结构的 SISR 方法 (Laplacian pyramid super-resolution network, LapSRN), 逐步上采样与预测残差, 可同时完成多个尺寸的 HR 图像重建.

以上方法使用了轻量级网络, 但网络深度和参数量是影响 SISR 性能的重要因素^[12]. Lim 等^[12] 提出了一个重量级的 Enhanced deep super-resolution network (EDSR) 方法, 去除了规范化层, 叠加残差块, 超过 65 个卷积层, 获得了 2017 年超分辨率比赛冠军^[21]. Zhang 等^[13] 提出的 Residual dense network (RDN) 方法, 结合残差结构和稠密结构, 并充分利用 LR 图像的层次特征信息, 能够恢复出高质量的 HR 图像. Liu 等^[22] 提出 Residual feature aggregation net work (RFANet) 方法, 在残差块中使用感受野更大, 参数量更小的空间注意力模块, 筛选特征信息, 并将每个残差块的残差支路提取的特征进行融合, 提高了图像重建质量. EDSR、RDN 和 RFANet 等方法是当前有代表性的重量级网络 SISR 方法, 性能好, 参数量也都较大 (分别为 43 MB、22 MB 和 11 MB).

在资源受限的情况下, 重量级 SISR 模型难以满足应用需求, 本文考虑轻量级 SISR 模型, 提供潜在的解决方法.

本文提出一个新的、轻量级多层次特征融合网络的 SISR 方法 (Multi-hierarchical features fusion network, MHFN). 当放大因子为 4 倍时, MHFN 参数量仅为 1.47 MB, 是当前尖端方法 EDSR 的 1/29, RDN 的 1/14, RFANet 的 1/7. 对比同类轻量级 SISR 模型, 本文的 MHFN 方法, 在性能和模型规模上取得了更好的平衡. 以最有代表性的 MSRN 方法为例, 本文的 MHFN 参数减少了 3/4, 在测试集上 2 倍、3 倍和 4 倍放大, 客观性能相当, 而 8 倍放大, 一致优于 MSRN 方法. 对于 4 倍和 8 倍放大, 主观性能也一致优于 MSRN 方法. 实验结果表明, MHFN 方法重建条纹的能力显著优于其他轻量级方法, 对于 8 倍大尺度放大因子, 重建图像结果优势更明显. 本文贡献包括: 1) 提出了一种对称结构的双层嵌套残差块 (Dual residual block, DRB). 残差块内先两次扩张, 然后两次压缩特征通

道, 并使用两层残差连接以有效地提取特征信息; 2) 提出了一种自相关权重单元 (Autocorrelation weight unit, ACW). ACW 可根据特征信息计算权值, 自适应地加权不同的特征通道, 以有效地传递特征信息; 3) 设计了一种浅层特征映射单元 (Shallow feature mapping unit, SFMU). SFMU 通过每条支路上的不同感受野的卷积层, 提取不同层次的浅层特征信息; 4) 设计了一种多路重建单元 (Multi-path reconstruction unit, MPRU). MPRU 可获取多条支路的特征信息, 以充分地利用不同层次的特征信息重建图像不同方面.

1 本文方法

目前, 大多数 SISR 模型利用残差结构^[12, 23]. 残差块结构一般是卷积层-激活层-卷积层 (Conv-ReLU-Conv)¹. 这类模型的一个问题是: 模型性能严重依赖于网络规模 (可训练的网络层数和通道数), 如何减小网络规模, 又提高或不降低模型性能, 是极具挑战性的问题. 本文设计了轻量级的多层次特征融合网络, 特征通道先扩张后压缩的双层嵌套残差块, 可以显著降低参数量, 自相关权重单元自适应融合特征信息, 也改进了特征利用效果. 本文的 MHFN 网络结构如图 1(a) 所示, 主要包含浅层特征提取单元 (Shallow feature extraction unit, SFEU)、浅层特征映射单元 (Shallow feature mapping unit, SFMU)、深层特征映射单元 (Deep feature mapping unit, DFMU) 和多路重建单元 (Multi-path reconstruction unit, MPRU) 四个部分.

令 I_{LR} 与 I_{SR} 为输入与输出图像. 浅层特征提取单元 (SFEU) 仅包含一个 3×3 卷积层, 实现浅层特征信息提取和特征维度转换的功能:

$$F_0 = H_{SFEU}(I_{LR}) \quad (1)$$

式中, H_{SFEU} 是浅层特征提取单元, 将输入图像 I_{LR} 生成符合浅层/深层特征映射单元维度要求的浅层特征信息 F_0 . 浅层特征映射单元 (SFEU) 从 F_0 中进一步提取浅层特征信息, 并将浅层特征信息传递到多路重建单元 (MPRU):

$$(F_{S1}, F_{S2}, F_{S3}) = H_{SFMU}(F_0) \quad (2)$$

式中, (F_{S1}, F_{S2}, F_{S3}) 是浅层特征映射单元 H_{SFMU} 提取的浅层特征信息. 深层特征映射单元 (DFMU) 也从 F_0 提取深层特征信息:

$$(F_{D1}, F_{D2}, F_{D3}) = H_{DFMU}(F_0) \quad (3)$$

式中, (F_{D1}, F_{D2}, F_{D3}) 是深层特征映射单元 H_{DFMU}

¹ 该结构是将特征信息 x 经过卷积处理再激活操作, 随后再次卷积处理得到 \hat{x} , 结构最终输出为 $x + \hat{x}$.

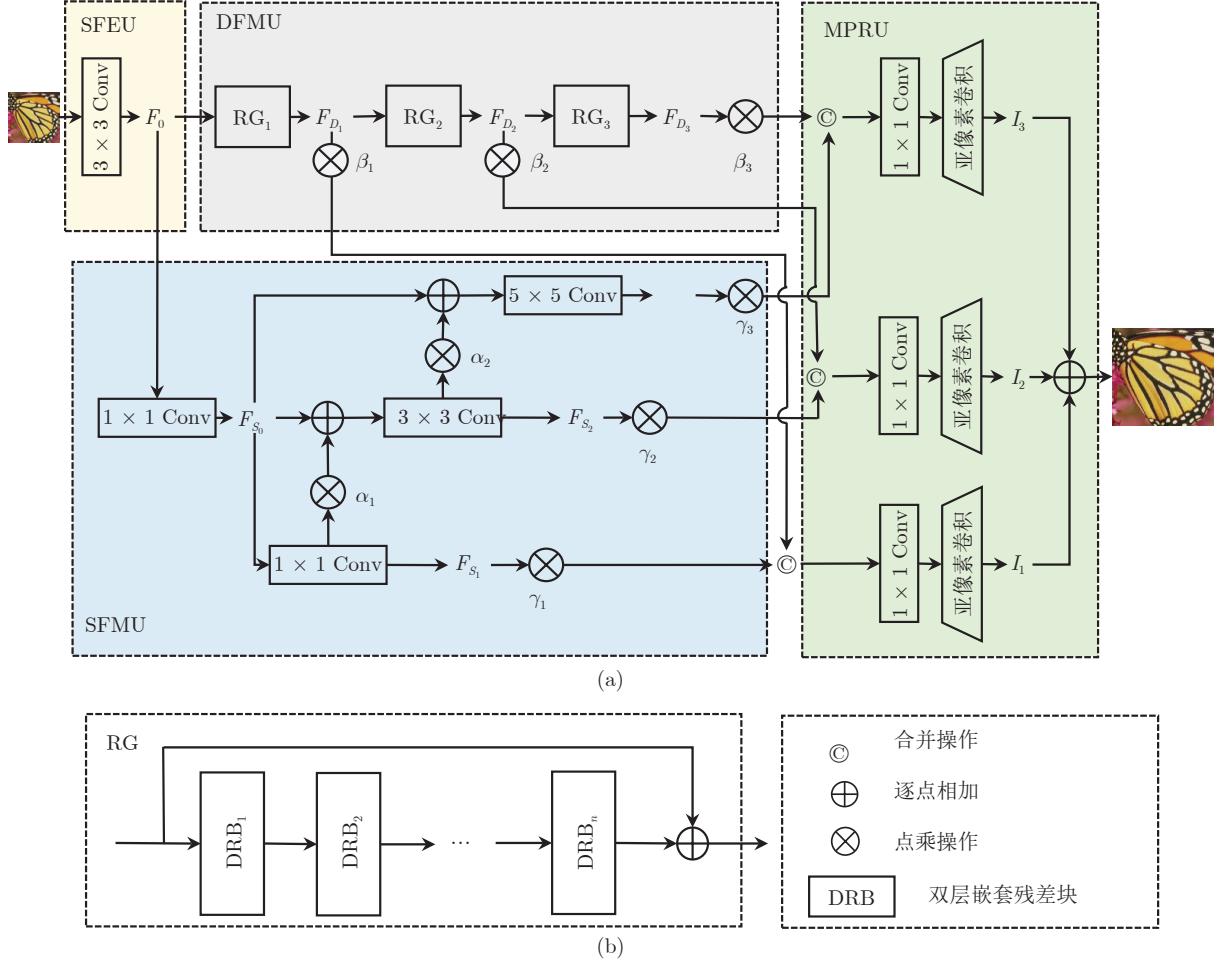


图 1 本文多层次特征融合网络结构与残差组结构 ((a) 多层次特征融合网络结构图; (b) 残差组结构图)

Fig. 1 Our multi-hierarchical feature fusion network structure and the residual group structure ((a) The architecture of multi hierarchical feature fusion network; (b) The structure of residual group)

生成的深层特征信息, 随后多路重建单元接受浅层特征信息与深层特征信息重建最终结果 I_{SR} :

$$I_{SR} = H_{MPRU}(F_{S_1}, F_{S_2}, F_{S_3}, F_{D_1}, F_{D_2}, F_{D_3}) \quad (4)$$

式中, H_{MPRU} 是多路重建单元, 利用所有特征信息重建图像, 生成最终结果 I_{SR} .

1.1 浅层特征映射单元 (SFMU)

当前 SISR 模型通常使用 1 或 2 个卷积层提取浅层特征, 本文的 SFMU 使用了不同感受野的卷积核, 分层次提取浅层特征信息, 实现多尺度、多层次浅层特征信息的获取。丰富的浅层特征信息, 可以帮助重建单元重建更高质量的 SR 图像。

SFMU 首先通过 1×1 卷积层对输入信息进行维度转换, 以降低后续操作的参数量。然后, 使用三种不同感受野的卷积层, 实现多尺度浅层特征信息提取。将三个卷积层分为三条支路, 逐步加权叠加

浅层特征信息。实现多尺度、多层次浅层特征信息的提取。

浅层特征映射单元三条支路分别提取不同层次的浅层特征信息 ($F_{S_1}, F_{S_2}, F_{S_3}$)。

$$F_{S_0} = H_T(F_0) \quad (5)$$

$$F_{S_1} = H_{C_1}(F_{S_0}) \quad (6)$$

$$F_{S_2} = H_{C_2}(F_{S_0} + \alpha_1 F_{S_1}) \quad (7)$$

$$F_{S_3} = H_{C_3}(F_{S_0} + \alpha_2 F_{S_1}) \quad (8)$$

式中, H_T 是用于调整特征信息通道数目的 1×1 卷积层, $H_{C_1}, H_{C_2}, H_{C_3}$ 是每一个支路上卷积层, α_1, α_2 是可学习的自适应权重。

1.2 深层特征映射单元 (DFMU)

为了获取深层次特征信息, 本文设计了 DFMU, 如图 1(a) 所示。DFMU 包含 3 个残差组 (Residual group, RG), 每个 RG 又包含多个 DRB。简单地堆

叠残差块, 不利于特征信息的传递. 本文在每个 RG 中添加局部跳跃连接, 促进特征信息的有效传递. 并且通过 RG 获取深层次特征信息:

$$F_{D_i} = H_{RG_i}(F_{D_{i-1}}) \quad (9)$$

第 i 个残差组 H_{RG_i} 将第 $(i-1)$ 个残差组生成的层次特征信息 $F_{D_{i-1}}$ 作为输入, 生成层次特征信息 F_{D_i} .

1.2.1 双层嵌套残差块 (DRB)

在 SISR 模型中, 常用的残差结构如图 2(a) 所示, 每个卷积层具有相同的通道数目. 这个结构的一个主要问题是: 增加特征通道数目, 会导致参数量快速增加. 本文提出了如图 2(b) 所示的 DRB, 由内单元 (Inner unit, IU) 和外单元 (External unit, EU) 嵌套组成, 并且使用先扩张后压缩的策略^[24]. 该策略可以降低通道数目, 进而减少参数量. EU 第 1 个卷积层提取特征信息同时, 扩张特征通道, 以获取更丰富的图像特征信息. 第 2 个卷积层压缩特征通道, 筛选特征信息, 促使有效特征信息传递. 本文在 EU 内部增加了包含 2 个 1×1 卷积的 IU, 增加通道数目, 不会造成参数量的急剧增加.

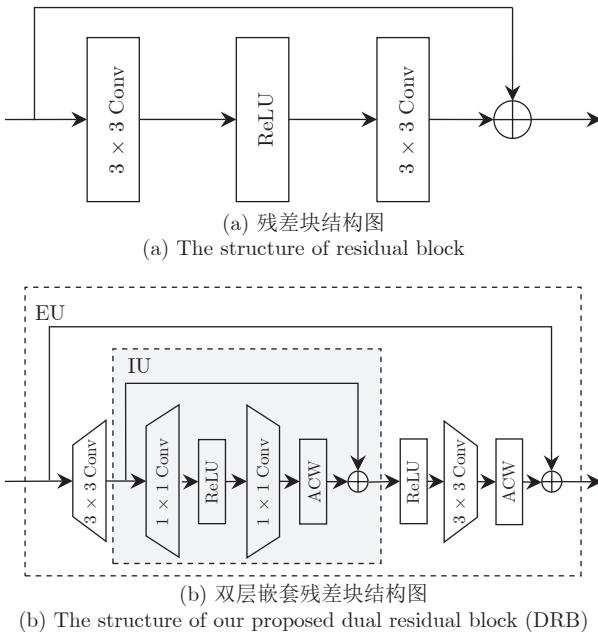


图 2 不同的残差块结构图

Fig.2 The structure of different residual block

假设第 i 个 DRB 输入输出特征信息分别为 F_{i-1} 和 F_i .

$$F_i = F_{ACW}(W_{EU_2}\sigma(H_{IU}(W_{EU_1}F_{i-1}))) + F_{i-1} \quad (10)$$

EU 两个卷积层的核尺寸均为 3×3 , 权重分别

为 W_{EU_1} 与 W_{EU_2} (忽略了偏置项). H_{IU} 是内单元操作, $\sigma(\cdot)$ 是 ReLU 激活函数, F_{ACW} 是自相关权重单元. 权重为 W_{EU_1} 的第一个卷积层将 F_{i-1} 处理生成特征信息 F_{input} , 输入到内单元处理. 内单元处理后生成特征信息 F_{output} , 通过卷积层、自相关权重单元和跳跃连接处理后, EU 的输出结果即为第 i 个 DRB 提取的特征信息 F_i .

IU 采用了 Conv-ReLU-Conv 结构, 并加入跳跃连接.

$$F_{output} = F_{ACW}(W_{IU_2}\sigma(W_{IU_1}F_{input})) + F_{input} \quad (11)$$

式中, W_{IU_1} 与 W_{IU_2} 分别是内单元的两个卷积层权重 (忽略了偏置项), $\sigma(\cdot)$ 是 ReLU 激活函数. 内单元的输入来自外单元第一个卷积层的输出 F_{input} , 通过卷积层、自相关权重单元和跳跃连接处理后, 提取的特征信息为 F_{output} .

1.2.2 自相关权重单元 (ACW)

基于深度残差结构的 SISR 模型, 仍然存在梯度消失或爆炸问题, 为了稳定训练, 通常引入一个残差尺度参数^[25]. 这个超参数通常经验设置, 难以优化. 本文的 ACW 可学习最优的残差尺度参数.

如图 3 所示. ACW 由全局平均池化层和 Sigmoid 激活函数两部分组成, 没有附加的参数. 全局平均池化层将所有输入特征信息编码为初始化权重, 随后利用 Sigmoid 激活函数将其调整至 $[0, 1]$. 由于特征信息之间存在差异, 生成不同的权重, 增强了对重建图像有效的特征信息.

令 $X = [x_1, x_2, \dots, x_C]$ 为输入特征信息, 尺寸为 $H \times W \times C$. 初始化权值 $Z = [z_1, z_2, \dots, z_C]$ 是通过全局平均池化层 H_{GAP} 对输入特征信息 X 进行计算得出. 第 c 个输入特征信息的初始权值为:

$$z_c = H_{GAP}(x_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j) \quad (12)$$

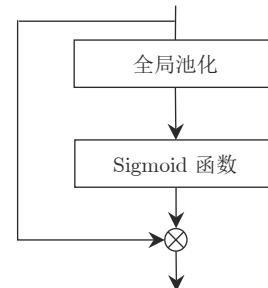


图 3 自相关权重单元结构图

Fig.3 The structure of autocorrelation weight unit

使用 Sigmoid 激活函数 $f(\cdot)$ 调整初始化权值 Z , 生成最终的权重参数 W :

$$W = f(Z) \quad (13)$$

对输入特征信息进行加权处理:

$$\hat{X} = X \cdot W \quad (14)$$

式中, \hat{X} 是自相关权重单元处理后的输出.

1.3 多路重建单元 (MPRU)

当前的 SISR 模型网络末端, 大多采用转置卷积或亚像素的卷积进行上采样. 与转置卷积相比, 亚像素的卷积重建的图像质量更好^[26], 但需要配合使用多个 3×3 卷积层^[11-13], 放大因子增加, 参数量会显著增加. 为了在不降低图像重建质量的同时减少参数量, 设计了 MPRU. 见图 1(a), MPRU 有三条重建支路, 每条重建支路由 1 个 1×1 卷积层与 1 个亚像素卷积层组成. 每条支路重建结果与 HR 图像尺寸相同, 最终的 SR 图像是三条支路重建结果的和. MPRU 使用 1×1 卷积层, 可极大地减少参数, 放大因子增加, 也不会显著提高参数量. 同时, MPRU 获取各支路的特征信息, 也可以改进重建效果.

下面将计算 MPRU 参数量并与 EDSR²方法的重建单元参数量作对比分析. 假设两者用于重建的特征信息通道均为 C , 图像放大因子为 S , 重建后图像为 3 通道. 经 1×1 卷积层处理后的特征信息通道数目为 $S \times S \times 3$. 亚像素卷积层没有参数量, 不参与计算. MPRU 的重建支路参数为 $3 \times ((1 \times 1 \times C + 1) \times S \times S \times 3)$.

EDSR 重建单元在放大因子 $S = [2, 3]$ 时, 包含 2 个 3×3 卷积层和 1 个亚像素卷积层. 第 1 个卷积层将输入的特征信息通道由 C 扩张至 $S \times S \times C$, 再经过亚像素卷积层将特征信息高度与宽度扩张为原来的 S 倍, 通道压缩为 C , 再经过另一个卷积层将通道压缩至 3, 生成最终结果. 参数量为 $((3 \times 3 \times C + 1) \times S \times S \times C + (3 \times 3 \times C + 1) \times 3)$. 在放大因子 $S = 4$ 时包含 3 个卷积层和 2 个亚像素卷积层. 同理于上述过程, 先将图像放大 2 倍, 再放大 2 倍. 其参数量为 $(2 \times ((3 \times 3 \times C + 1) \times 2 \times 2 \times C) + (3 \times 3 \times C + 1) \times 3)$.

当 $S = [2, 3]$ 时, MPRU 参数量与 EDSR 重建单元参数量之比为:

$$\begin{aligned} & 3 \times ((1 \times 1 \times C + 1) \times S \times S \times 3) / \\ & ((3 \times 3 \times C + 1) \times S \times S \times C + \\ & (3 \times 3 \times C + 1) \times 3) \end{aligned} \quad (15)$$

当 $S = 4$ 时, MPRU 参数量与 EDSR 重建单元参数量之比为:

$$\begin{aligned} & 3 \times ((1 \times 1 \times C + 1) \times S \times S \times 3) / \\ & (2 \times ((3 \times 3 \times C + 1) \times 2 \times 2 \times C) + \\ & (3 \times 3 \times C + 1) \times 3) \end{aligned} \quad (16)$$

在本文模型中, 重建的特征信息通道为 48, 即 $C = 48$. 由式 (15) 和式 (16) 可知, 放大因子 $S = 2, 3$ 时, EDSR 重建单元参数量是 MPRU 参数量的 47 倍, 而 $S = 4$ 时, EDSR 重建单元参数量是 MPRU 参数量的 23 倍.

$F_S = [F_{S_1}, F_{S_2}, F_{S_3}]$ 为浅层特征映射单元提取的浅层特征信息, $F_D = [F_{D_1}, F_{D_2}, F_{D_3}]$ 为深层特征映射单元提取的层次特征信息, 多路重建单元中第 i 条支路生成:

$$I_i = H_{UP_i}(H_{conv_i}([\gamma_i F_{S_i}, \beta_i F_{D_i}])) \quad (17)$$

H_{UP_i} 与 H_{conv_i} 分别表示第 i 条支路的亚像素卷积层与 1×1 卷积层, γ_i 与 β_i 分别是 F_{S_i} 与 F_{D_i} 的自适应权重. I_i 是第 i 条支路重建的图像. $[\cdot]$ 是对 F_{S_i} 与 F_{D_i} 进行合并操作. 本文的多路重建单元有 3 条支路, 所以 $i = [1, 2, 3]$.

$$I_{SR} = I_1 + I_2 + I_3 \quad (18)$$

式中, 多路重建单元将所有支路生成的图像 (I_1, I_2, I_3) 相加, 生成最终的结果 I_{SR} .

2 实验细节

2.1 实验设置

本文使用 DIV2K^[21] 数据集中第 1 ~ 800 个图像作为训练数据集, 并对训练集进行 90° 旋转和随机的水平翻转, 进行数据增强. 训练中每个批次处理 16 个尺寸为 48×48 像素的图像块, 使用 $\beta_1 = 0.9, \beta_2 = 0.999, \epsilon = 10^{-8}$ 的 ADAM 优化器^[27]. 本文在训练模型中使用权值归一化处理^[28], 初始学习率设置为 10^{-3} , 共训练 1000 个迭代周期, 并且每 200 个迭代周期学习率衰减为原先的一半. 使用 L_1 损失函数. 为了验证本文方法性能, 使用 Set5^[29] 标准测试数据集以及 DIV2K 数据集中第 801 ~ 810 张高质量图像 (标记为 DIV2K-10) 进行对比实验, Set14^[30]、B100^[31]、Urban100^[32] 和 Manga109^[33] 共 4 个标准测试数据集进行测试, 并使用平均峰值信噪比 (Peak signal-to-noise ratio, PSNR)^[34] 与结构相似性 (Structural similarity index, SSIM)^[34] 指标评价实验结果. 模型使用 PyTorch 实现, 并在 NVIDIA GeForce RTX 2080Ti GPU 上训练.

² <https://github.com/thstkdgus35/EDSR-PyTorch>

2.2 实验分析

2.2.1 残差组实验分析

本文提出模型包含 3 个残差组, 并且每组内包含相同数目的双层嵌套残差块。为了验证残差组内不同数目的双层嵌套残差块对模型的影响, 本文在 Set5 标准测试数据集以及 DIV2K-10 数据集上进行 4 倍超分辨率实验, 对组内数目分别为 5、6、7 的残差组作对比实验。如表 1 所示, 组内数目为 6 时性能最佳。对比组内数目为 5 时, 虽然参数量提高 0.24 MB, 但是 PSNR 指标分别在 Set5 与 DIV2K-10 数据集上提高 0.03 dB 和 0.04 dB, 而当组内数目为 7 时, PSNR 指标提升不明显, 参数量却提高 0.24 MB。本文模型残差块个数为 6, 是一个合理的选择。

表 1 Set5 和 DIV2K-10 数据集上, 放大 4 倍, 运行 200 个迭代周期, 残差组中不同双层嵌套残差块数
模型的平均 PSNR 及参数量

Table 1 Average PSNRs and number of parameter with different numbers of DRBs in the residual group with a factor of $\times 4$ on Set5 and DIV2K-10 datasets under 200 epochs

数目	参数量 (MB)	Set5 (%)	DIV2K-10 (%)
5	1.23	32.23	29.51
6	1.47	32.26	29.55
7	1.71	32.25	29.55

2.2.2 SFMU 单元实验分析

为了验证浅层特征映射单元不同支路上卷积核大小, 以及未使用浅层特征映射单元等情形对模型的影响, 本文在 Set5 标准测试数据集与 DIV2K-10 数据集上, 进行 4 倍超分辨率对比实验。如表 2 所示, 未使用浅层特征映射单元导致模型无法使用浅层特征信息, 致使重建效果较差。而当每条支路使用相同大小的卷积核, 且卷积核大小不断增加时, 重建效果提升, 然而参数量也随之增加。当支路卷积核均为 1 时, PSNR 指标低于未使用浅层特征映射单元的模型, 这是由于提取的特征信息较少, 存在冗余信息, 导致效果较差。本文发现当三条支路卷积核分别设置 1、3、5 时效果最佳。这是由于每一条支路可以提取不同层次的浅层特征信息, 可以有效地与深层层次特征信息进行组合使用。因而本文使用支路卷积核大小分别为 1、3、5 的浅层特征映射单元。

2.2.3 DRB 对比实验分析

相比于流行的残差块结构, 如图 2(a) 所示, 本

表 2 Set5 与 DIV2K-10 数据集上, 放大 4 倍, 运行 200 迭代周期, 浅层特征映射单元支路不同卷积核设置的平均 PSNR

Table 2 Average PSNRs of the models with different convolutional kernel settings for SFMU branches for $\times 4$ on Set5 and DIV2K-10 datasets under 200 epochs

卷积核设置	Set5 (%)	DIV2K-10 (%)
—	32.22	29.52
1 1 1	32.18	29.50
3 3 3	32.24	29.53
5 5 5	32.25	29.53
1 3 5	32.26	29.55

文的 DRB 在性能和参数量上均有优势。本文在 Set5 与 DIV2K-10 数据集上进行 4 倍超分辨率对比实验。本文构建了两个测试模型, 分别称为模型 I 和模型 II。模型 I 是 EDSR 架构, 但是, 卷积层输入输出通道数从 256 缩减为 64, 残差块数从 32 缩减为 18。模型 II 是把模型 I 中残差块替换为 DRB。在 DRB 扩张阶段, EU 输入输出特征通道数分别设置为 32 与 64, IU 输入输出特征通道数分别设置为 64 与 128; 在压缩阶段, EU 输入输出特征通道数分别设置为 64 与 32, IU 输入输出特征通道数分别设置为 128 与 64。模型 I 和模型 II 中其他参数都是相同的: 残差尺度参数为 0.1, 运行 200 个迭代周期。结果如表 3 所示, 在 Set5 与 DIV2K-10 数据集上, 模型 II 的 PSNR 分别高于模型 I 0.01 dB 和 0.05 dB, 而本文的 DRB 比 ERSR 残差块的参数量少 20.3 KB。

表 3 Set5 与 DIV2K-10 数据集上, 放大 4 倍, 运行 200 个迭代周期, 不同模型的平均 PSNR

Table 3 Average PSNRs of different models for $\times 4$ super-resolution on Set5 and DIV2K-10 datasets under 200 epochs

测试模型	残差块参数量 (KB)	Set5 (%)	DIV2K-10 (%)
模型 I	73.8	32.11	29.42
模型 II	53.5	32.12	29.47

2.2.4 ACW 对比实验分析

为了验证 ACW 的有效性, 考虑第 2.2.3 节中模型 I 包含和不包含 ACW 两种情形, 结果如表 4 所示。使用 ACW 后, Set5 与 DIV2K-10 数据集上 PSNR 分别提高 0.02 dB 和 0.03 dB。实验结果表明, ACW 自动学习最优的残差尺度参数是有效的。

2.2.5 MPRU 对比实验分析

为了验证本文的 MPRU 重建性能, 本文把第

表 4 Set5 和 DIV2K-10 数据集上, 放大 4 倍, 运行 200 个迭代周期, 包含/不包含 ACW 模型的平均 PSNR

Table 4 Average PSNRs of the models with/without the ACW for $\times 4$ super-resolution on the Set5 and DIV2K-10 datasets under 200 epochs

模型	Set5 (%)	DIV2K-10 (%)
不包含 ACW	32.11	29.42
包含 ACW	32.13	29.45

2.2.3 节模型 I 中的 EDSR 重建单元替换为 MPRU 后, 与模型 I 进行比较, 两个模型的结果分别对应于表 5 中 EDSR 重建单元和 MPRU. MPRU 参数量仅为 9.36 KB, 大约只有 EDSR 重建单元参数量的 $1/32$ (297.16 KB). 在 Set5 与 DIV2K-10 数据集上, 本文 MPRU 使 PSNR 分别提高了 0.02 dB 和 0.05 dB.

2.3 模型分析

本文提出的模型在 Set14、B100、Urban100 和

表 5 Set5 和 DIV2K-10 数据集上, 放大 4 倍, 运行 200 个迭代周期, 不同重建单元模型的平均 PSNR

Table 5 Average PSNRs of the models with different reconstruction modules for $\times 4$ super-resolution on Set5 and DIV2K-10 datasets under 200 epochs

重建单元	参数量 (KB)	Set5 (%)	DIV2K-10 (%)
EDSR 重建单元	297.16	32.11	29.42
MPRU	9.36	32.13	29.47

Manga109 标准测试集验证 2 倍、3 倍、4 倍和 8 倍超分辨率性能. 并与轻量级的 SRCNN^[7]、FSRCNN^[35]、VDSR^[15]、DRCN^[8]、DRRN^[9]、LapSRN^[20]、CARN^[10]、SRFBN-S^[17]、IMDN^[18]、CBPN^[19]、MSRN^[11]、MemNet^[36] 和 SRMDNF^[37] 进行性能对比.

1) 客观指标如表 6 所示, 最好的结果与次好结果分别以粗体和下划线形式标出. 在 Set14 数据集上, 放大因子为 2 倍时, 本文的 MHFN 模型比 CARN 模型 PSNR 高出 0.27 dB, 在其他放大因子的情况下类似, 并且 MHFN 模型参数量比 CARN 更少

表 6 各个 SISR 方法的平均 PSNR 和 SSIM
Table 6 The average PSNRs/SSIMs of different SISR methods

放大倍数	模型	参数量 (KB)	Set14	B100	Urban100	Manga109
			PSNR (%) / SSIM (%)			
$\times 2$	SRCNN	57	32.42 / 0.9063	31.36 / 0.8879	29.50 / 0.8946	35.74 / 0.9661
	FSRCNN	12	32.63 / 0.9088	31.53 / 0.8920	29.88 / 0.9020	36.67 / 0.9694
	VDSR	665	33.03 / 0.9124	31.90 / 0.8960	30.76 / 0.9140	37.22 / 0.9729
	DRCN	1774	33.04 / 0.9118	31.85 / 0.8942	30.75 / 0.9133	37.63 / 0.9723
	LapSRN	813	33.08 / 0.9130	31.80 / 0.8950	30.41 / 0.9100	37.27 / 0.9740
	DRRN	297	33.23 / 0.9136	32.05 / 0.8973	31.23 / 0.9188	37.92 / 0.9760
	MemNet	677	33.28 / 0.9142	32.08 / 0.8978	31.31 / 0.9195	37.72 / 0.9740
	SRMDNF	1513	33.32 / 0.9150	32.05 / 0.8980	31.33 / 0.9200	38.07 / 0.9761
	CARN	1592	33.52 / 0.9166	32.09 / 0.8978	31.92 / 0.9256	38.36 / 0.9765
	MSRN	5930	<u>33.70 / 0.9186</u>	32.23 / 0.9002	<u>32.29 / 0.9303</u>	<u>38.69 / 0.9772</u>
$\times 3$	SRFBN-S	282	33.35 / 0.9156	32.00 / 0.8970	31.41 / 0.9207	38.06 / 0.9757
	CBPN	1036	33.60 / 0.9171	32.17 / 0.8989	32.14 / 0.9279	—
	IMDN	694	33.63 / 0.9177	32.19 / 0.8996	32.17 / 0.9283	38.88 / 0.9774
	本文 MHFN	1463	33.79 / 0.9196	<u>32.20 / 0.8998</u>	<u>32.40 / 0.9301</u>	<u>38.88 / 0.9774</u>
	SRCNN	57	29.28 / 0.8209	28.41 / 0.7863	26.24 / 0.7989	30.59 / 0.9107
	FSRCNN	12	29.43 / 0.8242	28.53 / 0.7910	26.43 / 0.8080	30.98 / 0.9212
	VDSR	665	29.77 / 0.8314	28.82 / 0.7976	27.14 / 0.8279	32.01 / 0.9310
	DRCN	1774	29.76 / 0.8311	28.80 / 0.7963	27.15 / 0.8276	32.31 / 0.9328
	DRRN	297	29.96 / 0.8349	28.95 / 0.8004	27.53 / 0.8378	32.74 / 0.9390
	MemNet	677	30.00 / 0.8350	28.96 / 0.8001	27.56 / 0.8376	32.51 / 0.9369
$\times 4$	SRMDNF	1530	30.04 / 0.8370	28.97 / 0.8030	27.57 / 0.8400	33.00 / 0.9403
	CARN	1592	30.29 / 0.8407	29.06 / 0.8034	27.38 / 0.8404	33.50 / 0.9440
	MSRN	6114	30.41 / 0.8437	<u>29.15 / 0.8064</u>	<u>28.33 / 0.8561</u>	<u>33.67 / 0.9456</u>
	SRFBN-S	376	30.10 / 0.8372	28.96 / 0.8010	27.66 / 0.8415	33.02 / 0.9404

表 6 各个 SISR 方法的平均 PSNR 和 SSIM (续表)

Table 6 The average PSNRs/SSIMs of different SISR methods (continued table)

放大倍数	模型	参数量 (KB)	Set14	B100	Urban100	Manga109
			PSNR (%) / SSIM (%)			
$\times 3$	IMDN	703	30.32 / 0.8417	29.09 / 0.8046	28.17 / 0.8519	33.61 / 0.9445
	本文 MHFN	1465	30.40 / 0.8428	29.13 / 0.8056	28.35 / 0.8557	33.85 / 0.9460
	SRCNN	57	27.49 / 0.7503	26.90 / 0.7101	24.52 / 0.7221	27.66 / 0.8505
	FSRCNN	12	27.59 / 0.7535	26.98 / 0.7150	24.62 / 0.7280	27.90 / 0.8517
	VDSR	665	28.01 / 0.7674	27.29 / 0.7251	25.18 / 0.7524	28.83 / 0.8809
	DRCN	1774	28.02 / 0.7670	27.23 / 0.7233	25.14 / 0.7510	28.98 / 0.8816
	LapSRN	813	28.19 / 0.7720	27.32 / 0.7280	25.21 / 0.7560	29.09 / 0.8845
	DRRN	297	28.21 / 0.7720	27.38 / 0.7284	25.44 / 0.7638	29.46 / 0.8960
	MemNet	677	28.26 / 0.7723	27.40 / 0.7281	25.50 / 0.7630	29.42 / 0.8942
	SRMDNF	1555	28.35 / 0.7770	27.49 / 0.7340	25.68 / 0.7730	30.09 / 0.9024
$\times 4$	CARN	1592	28.60 / 0.7806	27.58 / 0.7349	26.07 / 0.7837	30.47 / 0.9084
	MSRN	6078	28.63 / 0.7836	27.61 / 0.7380	26.22 / 0.7911	30.57 / 0.9103
	SRFBN-S	483	28.45 / 0.7779	27.44 / 0.7313	25.71 / 0.7719	29.91 / 0.9008
	CBPN	1197	28.63 / 0.7813	27.58 / 0.7356	26.14 / 0.7869	—
	IMDN	715	28.58 / 0.7811	27.56 / 0.7353	26.04 / 0.7838	30.45 / 0.9075
	本文 MHFN	1468	28.66 / 0.7830	27.61 / 0.7371	26.27 / 0.7909	30.74 / 0.9114
	SRCNN	57	23.86 / 0.5443	24.14 / 0.5043	21.29 / 0.5133	22.46 / 0.6606
	FSRCNN	12	23.94 / 0.5482	24.21 / 0.5112	21.32 / 0.5090	22.39 / 0.6357
$\times 8$	VDSR	655	23.20 / 0.5110	24.34 / 0.5169	21.48 / 0.5289	22.73 / 0.6688
	DRCN	1774	24.25 / 0.5510	24.49 / 0.5168	21.71 / 0.5289	23.20 / 0.6686
	LapSRN	813	24.45 / 0.5792	24.54 / 0.5293	21.81 / 0.5555	23.39 / 0.7068
	MSRN	6226	24.88 / 0.5961	24.70 / 0.5410	22.37 / 0.5977	24.28 / 0.7517
	本文 MHFN	1490	25.02 / 0.6426	24.80 / 0.5968	22.46 / 0.6170	24.60 / 0.7811

(大约减少了 120 KB). 在所有测试数据集上, 放大因子为 4 倍时, MHFN 模型比 CBPN 模型和 IMDN 模型 PSNR 平均高出 0.06 dB 与 0.16 dB. 虽然在部分数据集上, MSRN 性能略好, 但本文的 MHFN 综合性能更好, MSRN 的 4 倍模型参数量是本文 MHFN 的 4 倍.

2) 主观视觉如图 4 所示, 本文对比 Urban100 标准测试数据集中 img012、img024 与 img046 图像以及 Manga109 标准测试数据集中的 Highschool-Kimengumi_vol20 (HK_vol20) 图像. 在图像 img012 中, IMDN 与 MSRN 重建结果与原图像条纹方向相反, 本文的模型正确重建了条纹的方向, 可能是浅层特征提取单元获取了更丰富的浅层特征信息, 帮助重建单元重建出更精确的结果. 在 img046 图像中, Bicubic 插值、SRCNN 模型和 VDSR 模型重建图像非常模糊, LapSRN 模型、CARN 模型、SRFBN-S 模型、IMDN 模型与 MSRN 模型重建结果严重失真, 本文结果显著更好. 类似地, 在 img024 图像中, 本文模型与其他方法均存在恢复的

条纹数目与原图像不一致的问题. 其他方法均严重模糊和失真, 本文的重建结果也显著更好. 在 HK_-vol20 图像中, 其他方法眼睛部位重建模糊和走样, 本文重建结果显著优于其他方法, 是清晰可视的.

如图 5 所示, 当放大因子为 8 倍时, 本文的模型重建效果显著优于其他模型. 在 img092 图像中, LapSRN 模型与 MSRN 模型重建图像条纹方向与原图像相反, 本文的重建结果很接近于原图像. 在 ppt3 图像中, 本文重建结果比其他模型显著更清晰. 对于规则形状和结构的重建, 本文模型性能提升显著. 如何进一步提高不规则形状和结构的重建质量, 是本文未来的研究工作.

3 结束语

本文提出一种轻量级的多层次特征融合网络 (MHFN), 用于重建高质量的超分辨率图像. 本文设计了双层嵌套残差块 (DRB) 用于提取图像特征信息, 其特征通道数目先扩张后压缩, 并且使用不同

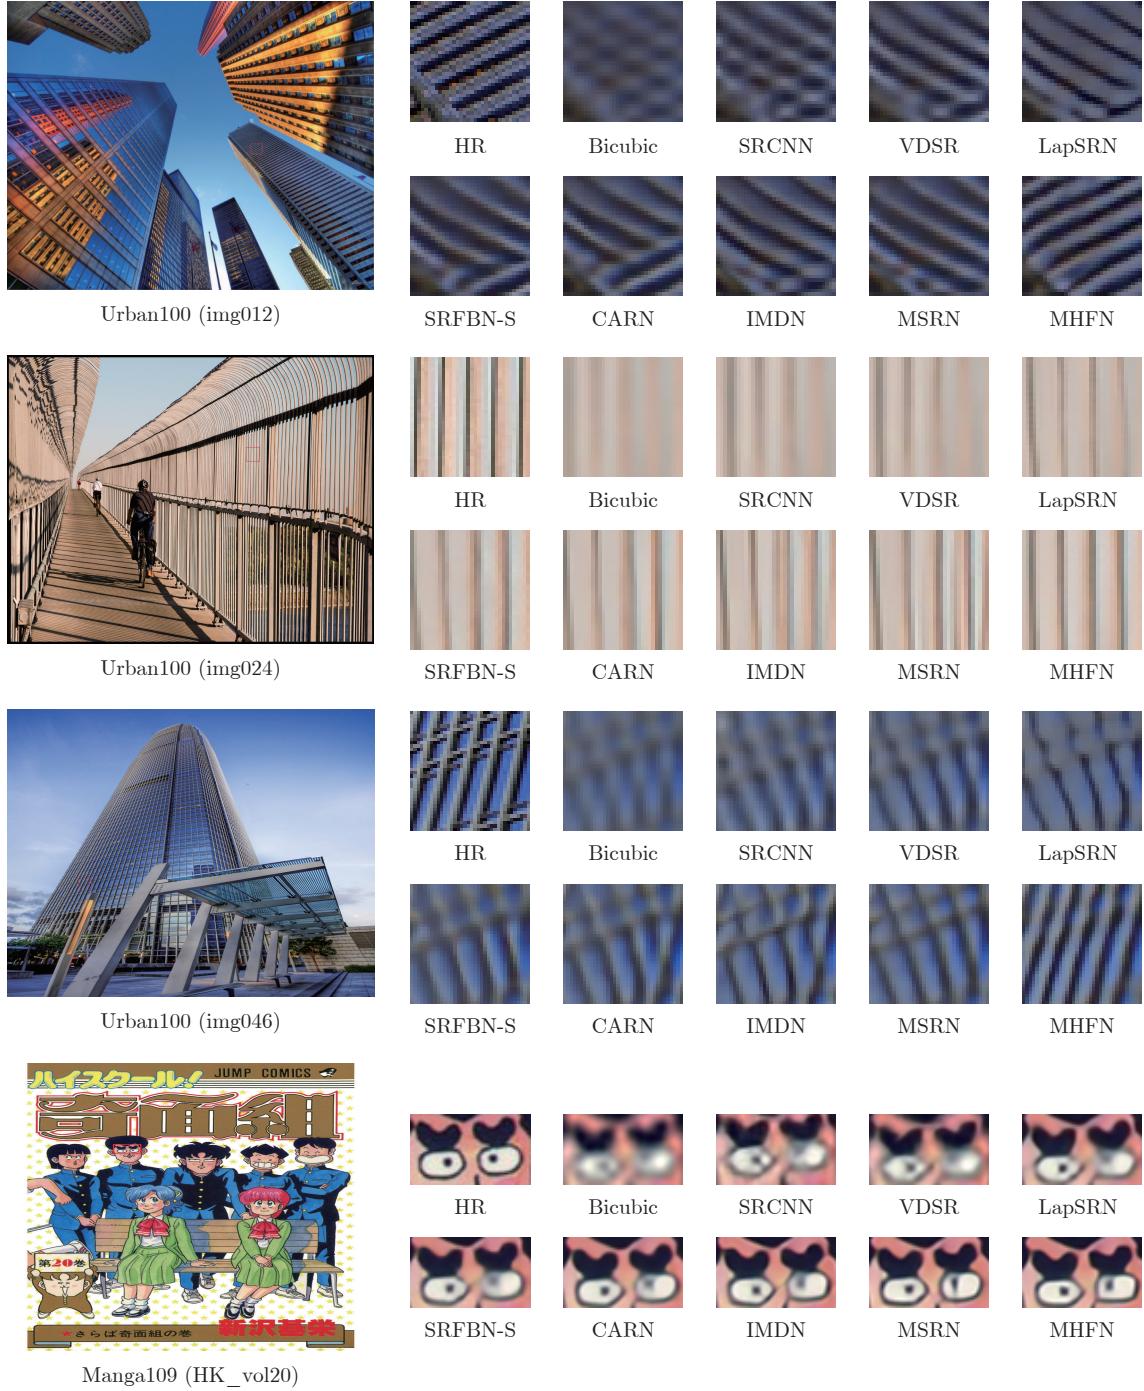


图 4 标准测试集放大 4 倍视觉效果比较

Fig.4 Visual qualitative comparison of $\times 4$ super-resolution on the standard test datasets

感受野的卷积层，降低参数量。为了使双层嵌套残差块有效传递特征信息，本文设计了自相关权重单元(ACW)，通过计算特征信息生成权重信息，再利用权重信息对特征信息进行加权处理，保证高权重的特征信息被有效传递。本文将双层嵌套残差块组成残差组，用于提取深层的层次特征信息，并构建浅层特征映射单元(SFMU) 提取多尺度、多层次的

浅层特征信息。多路重建单元(MPRU) 将深层的层次特征信息与浅层特征信息融合重建为高质量超分辨率图像。实验结果表明，上述模块设计有助于重建高质量图像，并且本文的模型可以有效增强图像条纹，重建高质量超分辨图像。与其他轻量级模型相比，本文模型在性能与模型规模方面上获得了更好的平衡。

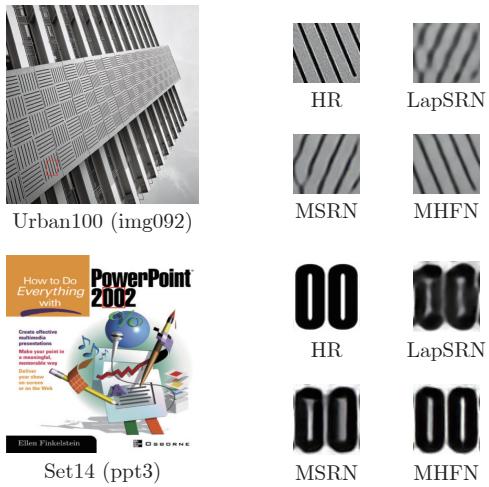


图5 标准测试集下放大8倍视觉效果比较

Fig.5 Visual qualitative comparison of $\times 8$ super-resolution on the standard test datasets

References

- 1 Shi W Z, Caballero J, Ledig C, Zhuang X H, Bai W J, Bhatia K, et al. Cardiac image super-resolution with global correspondence using multi-atlas PatchMatch. In: Proceedings of the 16th International Conference on Medical Image Computing and Computer-Assisted Intervention. Nagoya, Japan: 2013. 9–16
- 2 Luo Y M, Zhou L G, Wang S, Wang Z Y. Video satellite imagery super resolution via convolutional neural networks. *IEEE Geoscience and Remote Sensing Letters*, 2017, **14**(12): 2398–2402
- 3 Zou W W, Yuen P C. Very low resolution face recognition problem. *IEEE Transactions on Image Processing*, 2012, **21**(1): 327–340
- 4 Sun Xu, Li Xiao-Guang, Li Jia-Feng, Zhuo Li. Review on deep learning based image super-resolution restoration algorithms. *Acta Automatica Sinica*, 2017, **43**(5): 697–709
(孙旭, 李晓光, 李嘉峰, 卓力. 基于深度学习的图像超分辨率复原研究进展. 自动化学报, 2017, **43**(5): 697–709)
- 5 Zhou Deng-Wen, Zhao Li-Juan, Duan Ran, Chai Xiao-Liang. Image super-resolution based on recursive residual networks. *Acta Automatica Sinica*, 2019, **45**(6): 1157–1165
(周登文, 赵丽娟, 段然, 柴晓亮. 基于递归残差网络的图像超分辨率重建. 自动化学报, 2019, **45**(6): 1157–1165)
- 6 Zhang Yi-Feng, Liu Yuan, Jiang Cheng, Cheng Xu. A curriculum learning approach for single image super resolution. *Acta Automatica Sinica*, 2020, **46**(2): 274–282
(张毅峰, 刘袁, 蒋程, 程旭. 用于超分辨率重建的深度网络递进学习方法. 自动化学报, 2020, **46**(2): 274–282)
- 7 Dong C, Loy C C, He K M, Tang X O. Learning a deep convolutional network for image super-resolution. In: Proceedings of the 13th European Conference on Computer Vision. Zurich, Switzerland: 2014. 184–199
- 8 Kim J, Kwon Lee J, Mu Lee K. Deeply-recursive convolutional network for image super-resolution. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: 2016. 1637–1645
- 9 Tai Y, Yang J, Liu X M. Image super-resolution via deep recursive residual network. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: 2017. 2790–2798
- 10 Ahn N, Kang B, Sohn K A. Fast, accurate, and lightweight super-resolution with cascading residual network. In: Proceedings of the 15th European Conference on Computer Vision. Munich, Germany: 2018. 256–272
- 11 Li J C, Fang F M, Mei K F, Zhang G X. Multi-scale residual network for image super-resolution. In: Proceedings of the 15th European Conference on Computer Vision. Munich, Germany: 2018. 527–542
- 12 Lim B, Son S, Kim H, Nah S, Lee K M. Enhanced deep residual networks for single image super-resolution. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. Honolulu, USA: 2017. 1132–1140
- 13 Zhang Y L, Tian Y P, Kong Y, Zhong B N, Fu Y. Residual dense network for image super-resolution. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: 2018. 2472–2481
- 14 LeCun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 1998, **86**(11): 2278–2324
- 15 Kim J, Kwon Lee J, Mu Lee K. Accurate image super-resolution using very deep convolutional networks. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: 2016. 1646–1654
- 16 He K M, Zhang X Y, Ren S Q, Sun J. Deep residual learning for image recognition. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016. 770–778
- 17 Li Z, Yang J L, Liu Z, Yang X M, Jeon G, Wu W. Feedback network for image super-resolution. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: 2019. 3862–3871
- 18 Hui Z, Gao X B, Yang Y C, Wang X M. Lightweight image super-resolution with information multi-distillation network. In: Proceedings of the 27th ACM International Conference on Multimedia. Nice, France: 2019. 2024–2032
- 19 Zhu F Y, Zhao Q J. Efficient single image super-resolution via hybrid residual feature learning with compact back-projection network. In: Proceedings of the IEEE/CVF International Conference on Computer Vision Workshop. Seoul, South Korea: 2019. 2453–2460
- 20 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 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: 2017. 5835–5843
- 21 Timofte R, Agustsson E, van Gool L, Yang M H, Zhang L, Lim B, et al. NTIRE 2017 challenge on single image super-resolution: Methods and results. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. Honolulu, USA: 2017. 1110–1121
- 22 Liu J, Zhang W J, Tang Y T, Tang J, Wu G S. Residual feature aggregation network for image super-resolution. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: 2020. 2356–2365
- 23 Zhang Y L, Li K P, Li K, Wang L C, Zhong B N, Fu Y. Image super-resolution using very deep residual channel attention networks. In: Proceedings of the 15th European Conference on Computer Vision. Munich, Germany: 2018. 294–310
- 24 Sandler M, Howard A, Zhu M L, Zhmoginov A, Chen L C. MobileNetV2: Inverted residuals and linear bottlenecks. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: 2018. 4510–4520
- 25 Szegedy C, Ioffe S, Vanhoucke V, Alemi A A. Inception-v4, inception-ResNet and the impact of residual connections on learning. In: Proceedings of the 31st AAAI Conference on Artificial Intelligence. San Francisco, USA: 2017. 4278–4284
- 26 Wang Z H, Chen J, Hoi S C H. Deep learning for image super-resolution: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, **43**(10): 3365–3387
- 27 Kingma D P, Ba J. Adam: A method for stochastic optimization. In: Proceedings of the 3rd International Conference on Learning Representations. San Diego, USA, 2014.
- 28 Salimans T, Kingma D P. Weight normalization: A simple re-parameterization to accelerate training of deep neural networks. In: Proceedings of the 30th International Conference on Neural Information Processing Systems. Barcelona, Spain: 2016. 901–909

- 29 Bevilacqua M, Roumy A, Guillemot C, Alberi Morel M L. Low-complexity single-image super-resolution based on nonnegative neighbor embedding. In: Proceedings of the British Machine Vision Conference. Surrey, UK: 2012. 1–10
- 30 Zeyde R, Elad M, Protter M. On single image scale-up using sparse-representations. In: Proceedings of the 7th International Conference on Curves and Surfaces. Avignon, France: 2010. 711–730
- 31 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 8th International Conference on Computer Vision. Vancouver, Canada: 2001. 416–423
- 32 Huang J B, Singh A, Ahuja N. Single image super-resolution from transformed self-exemplars. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Boston, USA: 2015. 5197–5206
- 33 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
- 34 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
- 35 Dong C, Loy C C, Tang X O. Accelerating the super-resolution convolutional neural network. In: Proceedings of the 14th European Conference on Computer Vision. Amsterdam, Netherlands: 2016. 391–407
- 36 Tai Y, Yang J, Liu X M, Xu C Y. MemNet: A persistent memory network for image restoration. In: Proceedings of the IEEE International Conference on Computer Vision. Venice, Italy: 2017. 4539–4547
- 37 Zhang K, Zuo W M, Zhang L. Learning a single convolutional super-resolution network for multiple degradations. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: 2018. 3262–3271



李金新 华北电力大学控制与计算机工程学院硕士研究生。2018年获河北建筑工程学院学士学位。主要研究方向为计算机视觉和深度学习。

E-mail: 1182227091@ncepu.edu.cn
(LI Jin-Xin) Master student at the School of Control and Computer Engineering, North China Electric Power University. He received his bachelor degree from Hebei University

Engineering, North China Electric Power University. He received his bachelor degree from Hebei University

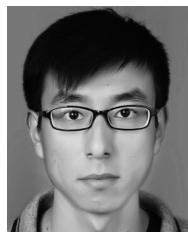
of Architecture in 2018. His research interest covers computer vision and deep learning.)



黄志勇 华北电力大学控制与计算机工程学院硕士研究生。2018年获华北电力大学学士学位。主要研究方向为计算机视觉和深度学习。

E-mail: 1182227193@ncepu.edu.cn

(HUANG Zhi-Yong) Master student at the School of Control and Computer Engineering, North China Electric Power University. He received his bachelor degree from North China Electric Power University in 2018. His research interest covers computer vision and deep learning.)



李文斌 华北电力大学控制与计算机工程学院硕士研究生。2017年获上海电力学院学士学位。主要研究方向为计算机视觉和深度学习。

E-mail: 1182227108@ncepu.edu.cn

(LI Wen-Bin) Master student at the School of Control and Computer Engineering, North China Electric Power University. He received his bachelor degree from Shanghai University of Electric Power in 2017. His research interest covers computer vision and deep learning.)



周登文 华北电力大学控制与计算机工程学院教授。主要研究方向为神经网络在图像处理中的应用。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 main research interest is applications of neural network in image processing. Corresponding author of this paper.)