



基于多路特征渐进融合和注意力机制的轻量级图像超分辨率重建

刘玉铠, 周登文

引用本文:

刘玉铠, 周登文. 基于多路特征渐进融合和注意力机制的轻量级图像超分辨率重建[J]. 智能系统学报, 2024, 19(4): 863–873.

LIU Yukai, ZHOU Dengwen. Lightweight super-resolution reconstruction via progressive multi-path feature fusion and attention mechanism[J]. *CAAI Transactions on Intelligent Systems*, 2024, 19(4): 863–873.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202209045>

您可能感兴趣的其他文章

用于关系抽取的注意力图长短时记忆神经网络

Attention graph long short-term memory neural network for relation extraction

智能系统学报. 2021, 16(3): 518–527 <https://dx.doi.org/10.11992/tis.202008036>

基于注意力机制的显著性目标检测方法

Salient object detection method based on the attention mechanism

智能系统学报. 2020, 15(5): 956–963 <https://dx.doi.org/10.11992/tis.201903001>

基于注意力融合的图像描述生成方法

An image caption generation method based on attention fusion

智能系统学报. 2020, 15(4): 740–749 <https://dx.doi.org/10.11992/tis.201910039>

基于小样本学习的LCD产品缺陷自动检测方法

An automatic small sample learning-based detection method for LCD product defects

智能系统学报. 2020, 15(3): 560–567 <https://dx.doi.org/10.11992/tis.201904020>

层次化双注意力神经网络模型的情感分析研究

Hierarchical double-attention neural networks for sentiment classification

智能系统学报. 2020, 15(3): 460–467 <https://dx.doi.org/10.11992/tis.201812017>

基于生成对抗网络的机载遥感图像超分辨率重建

Super-resolution reconstruction of airborne remote sensing images based on the generative adversarial networks

智能系统学报. 2020, 15(1): 74–83 <https://dx.doi.org/10.11992/tis.202002002>

DOI: 10.11992/tis.202209045

网络出版地址: <https://link.cnki.net/urlid/23.1538.tp.20240313.1551.007>

基于多路特征渐进融合和注意力机制的轻量级 图像超分辨率重建

刘玉铠, 周登文

(华北电力大学 控制与计算机工程学院, 北京 102206)

摘要: 为进一步探索在计算和存储资源受限设备上应用超分辨率方法的可能性, 本研究聚焦于深度卷积神经网络技术在单图像超分辨率中的应用, 特别是如何在显著增加网络规模的情况下, 提升网络的性能。本文提出一种新的基于多路特征渐进融合和注意力机制的轻量级单图像超分辨率方法 (multi-path feature fusion and attention mechanism, MPFFA)。MPFFA 包括一个多路特征渐进融合块 (multi-path feature progressive fusion, FPF), 可以通过前面的特征, 多路渐进地引导和校准后面特征的学习; 还包括一个多路特征注意力机制 (multi-path feature attention mechanism, FAM), 通过加权拼接多路特征通道, 可以提高特征信息的利用率和特征表达能力。实验结果表明: MPFFA 显著优于当前其他代表性的方法, 在模型复杂度和性能间达到了更好的平衡。本文提出的模型能够更好地应用于计算和资源受限的设备上。

关键词: 图像超分辨率; 卷积神经网络; 特征融合; 注意力机制; 深度学习; 图像还原; 峰值信噪比; 结构相似度
中图分类号: TP391 **文献标志码:** A **文章编号:** 1673-4785(2024)04-0863-11

中文引用格式: 刘玉铠, 周登文. 基于多路特征渐进融合和注意力机制的轻量级图像超分辨率重建 [J]. 智能系统学报, 2024, 19(4): 863-873.

英文引用格式: LIU Yukai, ZHOU Dengwen. Lightweight super-resolution reconstruction via progressive multi-path feature fusion and attention mechanism[J]. CAAI transactions on intelligent systems, 2024, 19(4): 863-873.

Lightweight super-resolution reconstruction via progressive multi-path feature fusion and attention mechanism

LIU Yukai, ZHOU Dengwen

(School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China)

Abstract: In order to further explore the possibility of applying super-resolution methods on computing and storage resource-constrained devices, this study focuses on the application of deep convolutional neural network technology in single-image super-resolution, especially how to improve the performance of the network without significantly increasing the network size. In this paper, a novel lightweight single image super resolution (SISR) method via progressive multi-path feature fusion and attention mechanism (MPFFA) is proposed. MPFFA includes a multi-path FPF module, which can progressively guide and calibrate the learning of the following features through multiple paths. MPFFA also includes a multi-path feature attention mechanism (FAM), which can improve the utilization rate of feature information and the ability of feature expression by splicing multi-path features with weights. The experimental result shows that MPFFA significantly outperforms other representative methods, thus achieves a better balance between model complexity and performance. The proposed model can be better applied to computing and resource-constrained devices.

Keywords: image super-resolution; convolutional neural network; feature fusion; attention mechanism; deep learning; image restoration; peak signal-to noise ratio; structural similarity

收稿日期: 2022-09-23. 网络出版日期: 2024-04-02.

通信作者: 周登文. E-mail: zdw@ncepu.edu.cn.单图像超分辨率 (single image super-resolution, SISR)^[1] 旨在从给定的低分辨率 (low-resolution,

LR) 图像恢复对应的高分辨率 (high-resolution, HR) 图像, 已经被广泛用于遥感成像、视频监控和医学成像等计算机视觉领域。然而, SISR 是一个经典的病态问题, 因为一个 LR 图像可以对应多个 HR 图像。

图像超分辨率 (super-resolution, SR) 技术的研究有很长的历史^[1], 当前, 基于深度卷积神经网络^[2] (convolutional neural network, CNN) 的技术主导了 SISR 技术的研究。直接端到端地学习 LR 和 HR 图像之间的映射函数, 并革新了 SISR 的性能。但是, 基于 CNNs 的 SISR 方法严重依赖于网络的规模, 即网络中参数量、深度 (层数) 和宽度 (通道数) 等。要改进 SISR 的性能, 往往需要规模更大的网络, 例如: Lim 等^[3] 提出的用于单幅图像超分辨率的增强型深度残差网络 (enhanced deep residual networks for single image super-resolution, EDSR) 方法, 有 65 个卷积层, 参数量达到了 43×10^6 ; Zhang 等^[4] 提出的非常深的残差通道注意力网络 (very deep residual channel attention networks, RCAN) 卷积层数超过了 800 层, 参数量约为 16×10^6 ; EDSR 和 RCAN 等方法虽然有很好的性能, 但是需要较高的计算和存储能力, 难以在资源受限的设备上应用。因此, 设计轻量级网络 (计算和存储需求较低), 对于当前的 SISR 方法研究是有必要的。但是如何在深度卷积神经网络 CNN 模型复杂度和 SISR 的性能之间建立更好的平衡, 是一个具有挑战的问题。

多路径学习是一种流行的 SISR 网络架构^[5]。例如: Zhao 等^[6] 提出了一种非常轻量级的 SISR 网络, 称为像素注意力网络 (pixel attention network, PAN), 该网络仅有 272×10^3 , 却取得了较好的性能。PAN 的 SC-PA (self-calibrated block with pixel attention) 块包含 2 个分支: 一个分支包含像素注意力 (pixel attention, PA), 该分支主要用于提取更高层的特征信息; 另一个分支使用标准的卷积层, 保持原始的特征信息。2 个分支的输出最后进行通道拼接 (concatenation)。Wang 等^[7] 的研究表明: 前面层的特征 (即辅助特征) 有助于当前层特征的学习; Zhao 等^[8] 的研究表明: 采用加权的通道拼接, 更符合人脑神经元的行为, 可以提高特征的表达能力。本文主要受 Zhao 等^[6]、Wang 等^[7] 和 Zhao 等^[8] 的工作启发, 提出了一个基于多路特征渐进融合和注意力机制的轻量级 SISR 网络 (multi-path feature fusion and attention mechanism network, MPFFA)。其特点在于: 类似于 Zhao 等^[6] 提出的 PAN, 核心构件采用了多分支结构 (3 个分

支), 受 Wang 等^[7] 辅助特征学习的启发, 渐进地进行特征提取和融合, 使用前一个分支的特征引导和校准当前分支的特征学习, 并根据 Zhao 等^[8] 加权拼接的研究结果, 提出了一个多路注意力机制, 最优加权各个分支的特征通道, 再进行拼接。MPFFA 网络主干的核心构件是多路特征提取块 (multi-path feature extraction, MPFE)。MPFE 包括多路特征渐进融合块 (multi-path feature progressive fusion, FPF) 和多路特征注意力机制 (multi-path feature attention mechanism, FAM) 2 个子块。FPF 通过前面的特征, 多路渐进地引导后面特征的提取, 逐像素预测特征的重要性; FAM 则通过通道注意力, 加权各路特征通道后, 再进行拼接。通过比较其他先进的 SISR 方法的 4 倍 SR 模型在 Urban100 数据集上的参数量和平均计算峰值信噪比 (peak signal to noise ratio, PSNR) 结果可以看出, 本文提出的模型无论是主观视觉效果, 还是客观度量, 本文提出的 MPFFA 方法, 显著优于当前其他类似的轻量级方法, 把模型复杂度和性能之间的平衡, 提升到一个新的水平。

1 单图像超分辨网络的相关工作

1.1 轻量级 SISR 方法

Dong 等^[2] 第 1 个提出了基于 CNN 的 SISR 方法 (super-resolution using convolutional neural network, SRCNN)。之后, 出现了大量基于 CNN 的 SISR 方法^[9]。但是, 基于 CNN 的 SISR 模型严重依赖于网络规模。通常, 网络规模越大, 表达能力越强, 性能也越好, 然而, 更大的网络往往会急剧增加参数量和计算量, 这也限制了它们在计算和存储资源受限的设备上的使用。为了解决这一问题, 出现了大量基于 CNN 的轻量级 SISR 方法。递归是一种流行的轻量级 SISR 网络结构^[10-12]。递归的结构, 虽然可以减少参数量, 但是不能减少计算量。为了进一步解决这一问题, 1×1 卷积^[5-6, 13-14]、分组卷积^[15]、深度可分离卷积^[15] 和自校准卷积^[6] 等也在轻量级 SISR 网络架构中广泛使用。如图 1 所示, 本文采用了多路径学习和多路注意力机制, 设计了一种轻量的构建块, 减少了参数量和计算量, 提高了 SISR 性能和计算效率。

1.2 多路径学习

多路径学习是 CNN 架构的一个重要形式, 残差连接^[16] 和稠密连接^[17] 可能是 SISR 网络架构中最常见的多路径学习。残差连接和稠密连接能够增强特征信息的传播, 但是也会造成大量的特征

信息冗余。如何改进多路径学习,提高特征信息的利用率和表达能力,持续受到研究人员的重视^[13]。




图1 各个先进SISR方法的参数数量和平均PSNR结果
Fig.1 Average PSNRs and numbers of parameters for each state of the art SISR method

Wang等^[7]提出的注意力辅助特征块 A^2F (attentive auxiliary features), 包含2个主要分支: 一个分支与前面模块的输出特征进行通道拼接和压缩, 再使用通道注意力机制, 学习各个通道的重要性; 另一个分支执行卷积运算。Zhao等^[6]提出

的PAN, 基本组成块是自校准块SC-PA。SC-PA块包含2个分支: 一个分支使用PA, 用于提取更高层的特征信息; 另一个分支使用标准的卷积层, 保持原始的特征信息。受到PAN和 A^2F 的启发, 本文采用了3条支路, 并且可以通过前面的特征, 多路渐进地引导后面特征的提取。

1.3 注意力机制

注意力机制^[15]通常是指人类的视觉系统, 能够自动地聚焦于显著的区域。卷积神经网络架构中的注意力机制与其类似, 是指能够聚焦于输入的特定部分, 提高特征的利用率和表达能力^[4,18]。Zhang等^[19]提出的一个多上下文注意力块 (multi-context attentive block, MCAB), 还可以同时关注通道维度和空间维度之间的依赖关系。本文提出的多路特征注意力机制, 通过加权拼接多路通道特征, 进一步增强特征表达能力。

2 本文方法

本文提出的基于多路特征渐进融合和注意力机制的轻量级SISR网络 (MPFFA) 架构, 参见图2(a)。

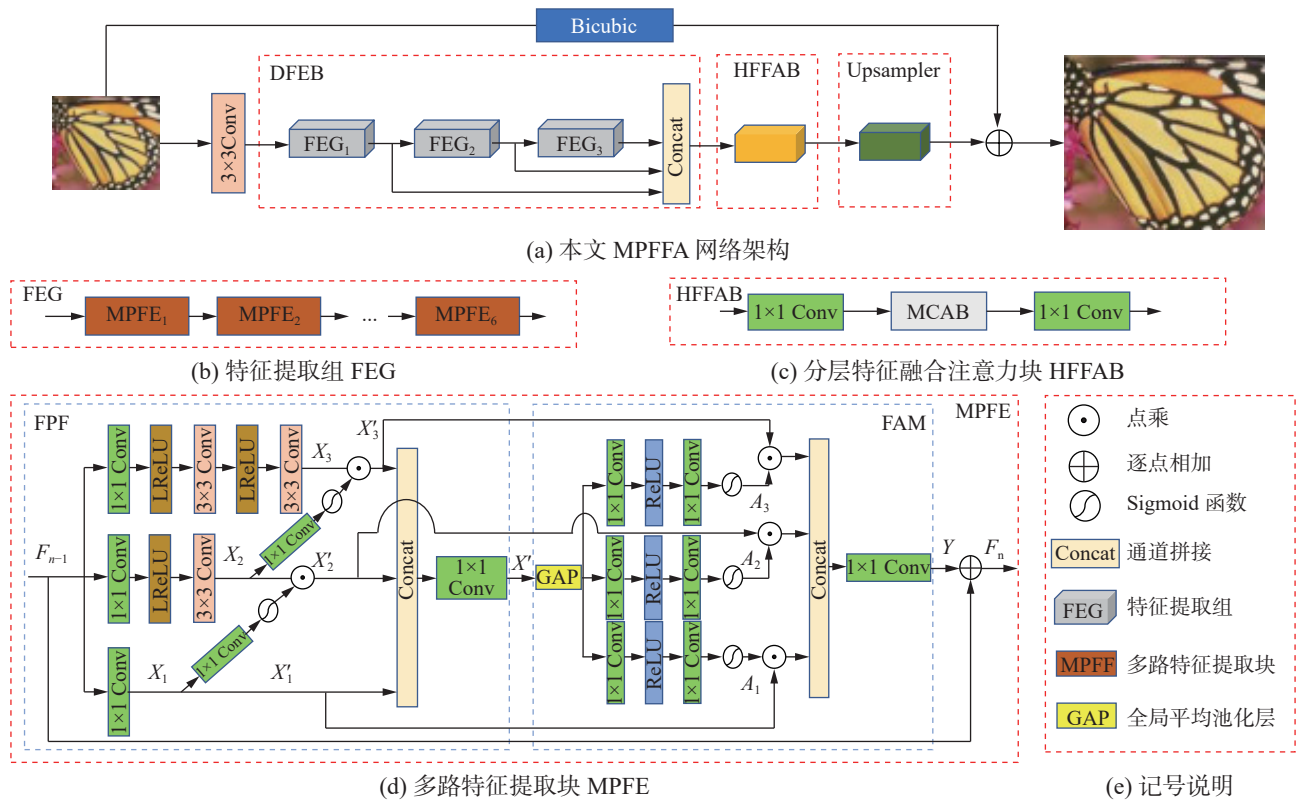


图2 本文模型架构

Fig.2 Model architecture of this paper

MPFFA 主要包括一个 3×3 的卷积层、一个深层特征提取块 (deep feature extraction block, DFEB)、一个分层特征融合注意力块 (hierarchical

feature fusion attention block, HFFAB) 和一个上采样块 (Upsampler) 4个部分。 3×3 的卷积层用于提取浅层特征, Upsampler 使用了 PAN^[6]的上采样

块。HFFAB 主要使用了用于单张图像超分辨率的两阶段注意力网络 (two-stage attentive network for single image super-resolution, TSAN)^[19] 中的多上下文注意力块 MCAB。为了减小计算量, 对输入到 MCAB 的特征通道, 用 1×1 的卷积进行了 4 倍的压缩和融合; 对 MCAB 的输出特征通道, 再用 1×1 的卷积进行了 4 倍的扩张。本文工作主要是 DFEB, 包括 3 个特征提取组 (feature extraction group, FEG)。每个 FEG 包含 6 个多路特征提取块 (MPFE), 参见图 2(b)。FEG 提取的分层特征进行拼接, 并经 HFFAB 注意力块进行融合, 以更高效地聚焦和利用信息丰富的上下文特征。组成 FEG 的 MPFE 是本文模型的核心构件。每个 MPFE 包括一个多路特征渐进融合块 (FPF) 和一个多路特征注意力机制 (FAM), 参见图 2(d)。FPF 和 FAM 的详细介绍, 参见下文 2.1 和 2.2 节。MPFFA 架构也包含一个全局残差连接, LR 图像通过双三次插值放大到目标 SR 图像的大小。下面详细介绍 MPFFA 的各个部分。

假定输入的 LR 图像为 I_{LR} , I_{LR} 首先通过一个 3×3 的卷积层提取浅层特征。

$$F_0 = \text{Conv}_{3 \times 3}(I_{LR})$$

式中: $\text{Conv}_{3 \times 3}(\cdot)$ 为 3×3 的卷积, F_0 为其输出的特征信息。 F_0 再输入到 DFEB, 进行深层特征提取。DFEB 包含 3 个 FEG, 每个 FEG 又包含 6 个 MPFE。所以, F_0 共经过 18 个 MPFE, 每个 MPFE 的输出可以表示为

$$F_n = H_n(F_{n-1}), n = 1, 2, \dots, 18 \quad (1)$$

式中: $H_n(\cdot)$ 为第 n 个 MPFE 函数, F_n 为其输出特征信息。每个 FEG 的输出分别为 F_6 、 F_{12} 和 F_{18} , 进行通道拼接:

$$F_{M0} = [F_6, F_{12}, F_{18}]$$

式中: $[\cdot]$ 为特征通道拼接, F_{M0} 为拼接后的特征, 也是 DFEB 块的输出特征, 再输入到 HFFAB:

$$F_M = H_{\text{HFFAB}}(F_{M0}) \quad (2)$$

式中: $H_{\text{HFFAB}}(\cdot)$ 为 HFFAB 函数; F_M 为其输出的特征信息, F_M 再输入上采样块。

$$I_{SR} = H_{\text{Up}}(F_M) + H_{\text{Bic}}(I_{LR})$$

式中: $H_{\text{Up}}(\cdot)$ 为上采样块 Upsampler 函数; $H_{\text{Bic}}(\cdot)$ 为传统的双三次插值函数, 叠加到残差 $H_{\text{Up}}(\cdot)$ 的输出, 得到最终输出的目标 SR 图像 I_{SR} 。当前 SISR 方法的上采样块, 大多数采用亚像素的卷积^[3]或转置的卷积^[9], 本文使用了 PAN^[6] 的上采样块。

2.1 多路特征渐进融合块 (FPF)

FPF 主要是受 Zhao 等^[6] 和 Wang 等^[7] 工作的

启发, 进行多路 (本文使用 3 路) 渐进特征提取和融合, 并用前面的特征引导和校准后面的特征学习。第 1 条支路仅包含 1 个 1×1 的卷积层; 第 2 条支路包含了 1 个 1×1 的卷积层和 1 个 3×3 的卷积层, 2 个卷积层之间包含 1 个 LReLU^[15] 非线性激活函数, 第 1 条支路的特征通过 1×1 的卷积和 Sigmoid 函数, 引导和校准该支路特征; 第 3 条支路包含 1 个 1×1 的卷积层和 2 个 3×3 的卷积层, 2 个卷积层之间包含 1 个 LReLU 非线性激活函数, 第 2 条支路的特征再通过 1×1 的卷积和 Sigmoid 函数, 引导和校准该支路特征。考虑到 F_{n-1} 和 F_n 分别是第 n 个 MPFE 的输入和输出, 参见式 (1)。3 条支路校准前的特征输出分别为 (忽略了 LReLU 非线性激活函数)

$$X_1 = \text{Conv}_{1 \times 1}(F_{n-1})$$

$$X_2 = \text{Conv}_{3 \times 3}(\text{Conv}_{1 \times 1}(F_{n-1}))$$

$$X_3 = \text{Conv}_{3 \times 3}(\text{Conv}_{3 \times 3}(\text{Conv}_{1 \times 1}(F_{n-1})))$$

式中: $\text{Conv}_{1 \times 1}(\cdot)$ 为 1×1 的卷积, $\text{Conv}_{3 \times 3}(\cdot)$ 为 3×3 的卷积, 3 条支路校准后的特征输出分别为

$$X'_1 = X_1$$

$$X'_2 = X_2 \odot (\sigma(\text{Conv}_{1 \times 1}(X_1)))$$

$$X'_3 = X_3 \odot (\sigma(\text{Conv}_{1 \times 1}(X_2)))$$

式中: $\sigma(\cdot)$ 为 Sigmoid 函数, \odot 为对应元素相乘。然后, 3 条支路校准后的输出特征通道进行拼接, 并用 1×1 的卷积进行通道压缩和融合。

$$X' = \text{Conv}_{1 \times 1}([X'_1, X'_2, X'_3])$$

式中: $\text{Conv}_{1 \times 1}(\cdot)$ 为 1×1 的卷积, $[\cdot]$ 为特征通道拼接。

2.2 多路特征注意力机制 (FAM)

FAM 主要是受 Zhao 等^[8] 工作的启发, 加权的特征通道拼接, 可以提高特征的表达能力。本文算法采用注意力机制, 可以最优加权特征通道, 并进行拼接。第 n 个 FPF 块的输出特征 X' , 通过全局平均池化 (global average pooling, GAP) 生成初始权重向量。然后, 各个支路通过 2 个 1×1 的卷积 (2 个 1×1 的卷积之间包含 1 个 ReLU^[15] 非线性激活函数) 进行通道的压缩和扩张, 再通过 1 个 Sigmoid 函数生成各个支路特征通道的权重向量。

假定 FPF 块的特征拼接输出 $X' = [x_1, x_2, \dots, x_c, \dots, x_C] \in \mathbf{R}^{H \times W \times C}$, GAP 运算可表示为

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

式中: $H_{\text{GAP}}(\cdot)$ 为 GAP 函数, $\mathbf{Z} = [z_1, z_2, \dots, z_c, \dots, z_C] \in \mathbf{R}^C$, 3 个支路特征各个通道的权重可表示为 (忽略了 ReLU 非线性激活函数)

$$A_k = \sigma(\text{Conv}_{1 \times 1}(\text{Conv}_{1 \times 1}(Z))), k = 1, 2, 3$$

式中 $\text{Conv}_{1 \times 1}(\cdot)$ 为 1×1 的卷积。第 n 个 FAM 的残差输出 Y , 可表示为

$$Y = \text{Conv}_{1 \times 1}([A_1 \odot X'_1, A_2 \odot X'_2, A_3 \odot X'_3])$$

式中: $\text{Conv}_{1 \times 1}(\cdot)$ 为 1×1 的卷积, $X'_k (k = 1, 2, 3)$ 为第 n 个 FPF 块的 3 条支路输出的特征, $[\cdot]$ 为特征通道拼接, \odot 为权重向量元素与对应特征通道相乘。由于使用了残差连接, 第 n 个 FAM 的输出特征 F_n 需要再加上第 n 个 FPF 块的输入 F_{n-1} , 即

$$F_n = Y + F_{n-1}$$

2.3 分层特征融合注意力模块 (HFFAB)

MCAB^[19] 可聚焦信息丰富的上下文特征。HFFAB 只是在多上下文注意力块 (MCAB) 前后各增加一个 1×1 的卷积层。前一个 1×1 的卷积层压缩特征通道, 以减少计算量; 后一个 1×1 的卷积层再扩张特征通道。HFFAB 块的运算, 参见式 (2), 可进一步表示为

$$F_M = \text{Conv}_{1 \times 1}(H_{\text{MCAB}}(\text{Conv}_{1 \times 1}(F_{M0})))$$

3 训练 MPFFA 实验

3.1 实验设置

训练阶段, 本文采用流行的 DIV2K^[20] 数据集作为训练和验证数据集。前 800 张图像 (001~800) 用于训练, 10 张图像 (821~830) 用于验证, 标记为 DIV2K_val10。为了制作这些训练对, 首先从高质量的 HR 图像开始, 然后应用双三次插值法进行下采样, 以生成对应的 LR 图像。除了下采样, 为了提高模型的泛化能力, 还需要对训练数据集进行数据增强。这包括随机地对图像进行 90° 、 180° 、 270° 的随机旋转以及水平翻转以对图像进行数据增强。首先训练好的 $\times 2$ 模型, 然后通过预训练的 $\times 2$ 模型, 训练 $\times 3$ 和 $\times 4$ 的模型。测试中, 使用了 Set5、Set14、B100、Urban100 和 Manga109 共 5 个标准的测试数据集^[6]。为了公正地比较, 与之前的方法一样, 在 YCbCr 空间^[17]

的亮度 (Y) 通道上, PSNR 和结构相似性 (structural similarity index, SSIM)^[3] 度量。同时本文也计算了学习的感知图像块相似性 (learned perceptual image patch similarity, LPIPS)^[21] 度量。

模型训练中, 每批次随机选取 32 个长和宽均为 48 的图像块, 使用 Adam^[22] 优化器, $\beta_1 = 0.9$ 、 $\beta_2 = 0.999$ 和 $\varepsilon = 10^{-8}$ 。本文模型训练了 1200 个迭代周期, 初始学习率设置为 2×10^{-4} , 每 200 个迭代周期衰减一半。使用的损失函数是 L_1 , 通过 PyTorch^[22] 框架, 一个 NVIDIA 2080Ti GPU 实现模型, 并进行模型的训练和测试。

3.2 消融实验

为了验证 FPF、FAM 以及 HFFAB 的有效性, 进行了 4 组对比实验。第 1 个实验, 不包含 FAM 和 HFFAB, FPF 块仅包含 3 个主支路, 不包含前面的特征对后面的特征的校准, 即不包含 2 个支路之间的 1×1 的卷积和 Sigmoid 函数, 这个模型称为 MPFFA_0; 第 2 个实验, 在 MPFFA_0 基础上增加包含前面的特征对后面的特征的校准, 即完整包含 FPF, 仍不包含 FAM 和 HFFAB, 这个模型称为 MPFFA_1; 第 3 个实验, 是在 MPFFA_1 的基础上, 增加 HFFAB, 这个模型称为 MPFFA_2; 第 4 个实验, 是在 MPFFA_2 的基础上, 再增加 FAM, 即完整的 MPFFA 网络模型。4 个模型在 DIV2K_val10 验证集上, 3 倍 SR 的 PSNR, 参见表 1。同时也给出了各个模型的参数量和计算量 (即 GFLOPs^[15]) 和 LPIPS 度量^[21] 结果, 以供参考, 其中 LPIPS 值越小越好。可以看到: 模型 MPFFA_0 的 PSNR 仅 29.49 dB; 模型 MPFFA_1 的 PSNR 增加了 0.11 dB, 表明多路特征渐进融合, 前面特征辅助后面特征的学习, 是很有效的; 相较于模型 MPFFA_1, 模型 MPFFA_2 仅增加了 15×10^3 的参数量和 1.4 GFLOPs 的计算量, 使 PSNR 值增加了 0.03 dB。最终的模型 MPFFA 相较于模型 MPFFA_2, PSNR 又增加了 0.06 dB, 表明对各个支路特征通道进行加权拼接的 FAM 块, 是有效的。

表 1 网络架构不同变种在验证集 DIV2K_val10 上 3 倍 SR 的 PSNR、参数量、计算量和 LPIPS

Table 1 Average PSNRs, number of parameters, computational cost and LPIPSs for $\times 3$ SR on validation dataset DIV2K_val10 for different variants of network architecture

模型	FPF校准部分	FPF3个主分支	HFFAB	FAM	PSNR/dB	参数量/ 10^3	计算量/GFLOPs	LPIPS
MPFFA_0	×	√	×	×	29.49	443	59.4	0.1861
MPFFA_1	√	√	×	×	29.60	465	61.6	0.1836
MPFFA_2	√	√	√	×	29.63	480	63.0	0.1826
MPFFA	√	√	√	√	29.69	523	66.2	0.1813

3.3 特征提取组 (FEG) 实验

本文模型包含3个FEG, 每组内包含相同个数MPFE。MPFE的个数选择, 要综合考虑参数量、计算量以及每个FEG输出的不同深度特征拼接后对性能的影响。本文在DIV2K_val10验证集上, 进行了3组实验。每组实验中, 每个FEG中MPFE个数分别设置为5、6和7。表2给出了模型在DIV2K_val10上3倍SR实验, 每个FEG中不同MPFE个数对模型平均PSNR性能和参数数量的影响。

表2 不同MPFE个数对模型平均PSNR性能和参数数量的影响

Table 2 Average PSNRs and numbers of parameters for different number of MPFEs

MPFE/个	PSNR /dB	参数量/ 10^3
5	29.55	445
6	29.69	523
7	29.74	601

通过结果分析, 可以明显观察到随着MPFE个数的增加, 模型在3倍超分辨率任务上的性能得到了提升。这表明MPFE能够有效地丰富模型对图像的理解, 从而更好地重建高分辨率图像。然而, 需要注意的是, 随着MPFE个数的增加, 模型的参数量也相应增长。这可能会导致模型变得更加复杂, 需要更多的计算资源和存储空间。因此, 在实际应用中, 需要权衡性能提升和参数量增加之间的关系, 找到一个合理的平衡点, 以确保模型既有较好的性能, 又能保持较低的计算成本。相较于5个MPFE, 6个MPFE的PSNR增加了0.14 dB; 相较于7个MPFE, 6个MPFE的PSNR仅减少了0.05 dB; 7个MPFE的PSNR增幅显著减缓, 而参数数量的增加是一样的, 都是 78×10^3 。为了保持网络模型足够轻量, MPFE个数取6 (本文中的设置), 可能是一个合理的折中。

3.4 多路特征注意力机制 (FAM) 实验

3.4.1 多支路的效果

为了进一步洞察FAM中多支路的效果, 本文把FAM块改成了1条支路, 在DIV2K_val10验证集上进行实验。3倍SR的PSNR结果为29.56 dB, 这比FAM包含3条支路的MPFFA模型的PSNR低0.13 dB。一个有趣的结果是: FAM仅包含一条支路的模型, 比MPFFA中去掉FAM块的模型(MPFFA_2)的PSNR还要低0.07 dB。

3.4.2 参数共享的效果

参数共享, 可以减少参数量。如果FAM中各支路参数共享, 在验证集DIV2K_val10上, 3倍SR的PSNR结果为29.65 dB, 比MPFFA中各支路参数不共享的情形, PSNR低0.04 dB。

3.5 与先进方法比较

为了检验本文提出的MPFFA方法的有效性, 将其与其他前沿技术进行了客观指标的对比以及从主观视角出发的视觉效果评估的比较。其他代表性的方法包括SRCNN^[2]、FSRCNN^[9]、VDSR^[16]、DRCN^[10]、MemNet^[11]、IMDN^[13]、RFDN^[14]、PAN^[6]、A²F-M^[7]、AWSRN-M、LapSRN^[23]、DRRN^[24]、SRMDNF^[25]、CARN^[26]、LatticeNet^[27]、MAFFSRN-L^[28]、ACAN^[29]和LAPAR-A^[30]。在5个标准测试数据集上, 2、3和4倍SR的PSNR/SSIM、参数量和计算量(即GFLOPs^[15])结果如表3所示, 视觉效果如图3所示。除LatticeNet和PAN以外, 其他方法的PSNR/SSIM结果均来自作者的原论文。LatticeNet的结果, 源自运行文中提供的训练模型^[27]。由于PAN使用了DIV2K和Flickr2K^[6]2个训练数据集, 为了公平比较, 使用了文中提供的代码, 在DIV2K训练集上, 重新进行了训练, 所以, 测试结果与原论文上的结果略有不同。

表3 各种先进SISR方法的平均PSNR/SSIM、参数量和计算量结果

Table 3 Average PSNRs/SSIMs, number of parameters and computational cost of various state-of-the-art SISR methods

放大 倍数	模型	参数量/ 10^3	计算量/ GFLOPs	PSNR/SSIM				
				Set5	Set14	B100	Urban100	Manga109
×2	SRCNN	57	52.7	36.66/0.9524	32.42/0.9063	31.36/0.8879	29.50/0.8946	35.74/0.9661
	FSRCNN	12	6	37.00/0.9558	32.63/0.9088	31.53/0.8920	29.88/0.9020	36.67/0.9694
	VDSR	665	612.6	37.53/0.9587	33.03/0.9124	31.90/0.8960	30.76/0.9140	37.22/0.9729
	DRCN	1774	17974	37.63/0.9588	33.04/0.9118	31.85/0.8942	30.75/0.9133	37.63/0.9723
	LapSRN	813	29.9	37.52/0.9590	33.08/0.9130	31.80/0.8950	30.41/0.9100	37.27/0.9740
	DRRN	297	6796.9	37.74/0.9591	33.23/0.9136	32.05/0.8973	31.23/0.9188	37.92/0.9760
	MemNet	677	2662.4	37.78/0.9597	33.28/0.9142	32.08/0.8978	31.31/0.9195	37.72/0.9740
	SRMDNF	1513	347.7	37.79/0.9600	33.32/0.9150	32.05/0.8980	31.33/0.9200	38.07/0.9761

续表3

放大 倍数	模型	参数量/ 10 ³	计算量/ GFLOPs	PSNR/SSIM				
				Set5	Set14	B100	Urban100	Manga109
×2	CARN	1592	222.8	37.76/0.9590	33.52/0.9166	32.09/0.8978	31.92/0.9256	38.36/0.9765
	IMDN	694	158.8	38.00/0.9605	33.63/0.9177	32.19/0.8996	32.17/0.9283	38.88/ 0.9774
	LAPAR-A	548	171	38.01/0.9605	33.62/0.9183	32.19/0.8999	32.10/0.9283	38.67/0.9772
	RFDN	534	123.0	38.05/0.9606	33.68/0.9184	32.16/0.8994	32.12/0.9278	38.88/0.9773
	A ² F-M	999	224.2	38.04/0.9607	33.67/0.9184	32.18/0.8996	32.27/0.9294	38.87/ 0.9774
	ACAN	800	2108	38.10/0.9608	33.60/0.9177	32.21/0.9001	32.29/0.9297	38.81/0.9773
	LatticeNet	756	169.5	38.06/0.9607	33.70/0.9187	32.20/0.8999	32.25/0.9288	38.94/ 0.9774
	AWSRN-M	1063	244.1	38.04/0.9605	33.66/0.9181	32.21/0.9000	32.23/0.9294	38.66/0.9772
	PAN	261	70.5	37.99/0.9603	33.53/0.9174	32.14/0.8992	31.93/0.9263	38.37/0.9766
	MAFFSRN-L	790	154.4	38.07/0.9607	33.59/0.9177	32.23/0.9005	32.38/0.9308	—/—
	MPFFA (本文方法)	523	129.4	38.09/0.9607	33.70/0.9190	32.21/0.9000	32.34/0.9296	38.98/0.9767
×3	SRCNN	57	52.7	32.75/0.9090	29.28/0.8209	28.41/0.7863	26.24/0.7989	30.59/0.9107
	FSRCNN	12	4.6	33.16/0.9104	29.43/0.8242	28.53/0.7910	26.43/0.8080	30.98/0.9212
	VDSR	665	612.6	33.66/0.9213	29.77/0.8314	28.82/0.7976	27.14/0.8279	32.01/0.9310
	DRCN	1774	17974	33.82/0.9226	29.76/0.8311	28.80/0.7963	27.15/0.8276	32.31/0.9328
	DRRN	297	67969.0	34.03/0.9244	29.96/0.8349	28.95/0.8004	27.53/0.8378	32.74/0.9390
	MemNet	677	2662.4	34.09/0.9248	30.00/0.8350	28.96/0.8001	27.56/0.8376	32.51/0.9369
	SRMDNF	1530	156.3	34.12/0.9250	30.04/0.8370	28.97/0.8030	27.57/0.8400	33.00/0.9403
	CARN	1592	118.8	34.29/0.9255	30.29/0.8407	29.06/0.8034	27.38/0.8404	33.50/0.9440
	IMDN	703	71.5	34.36/0.9270	30.32/0.8417	29.09/0.8046	28.17/0.8519	33.61/0.9445
	LAPAR-A	594	114	34.36/0.9267	30.34/0.8421	29.11/0.8054	28.15/0.8523	33.51/0.9441
	RFDN	541	55.4	34.41/0.9273	30.34/0.8420	29.09/0.8050	28.21/0.8525	33.67/0.9449
	A2F-M	1003	100	34.50/0.9278	30.39/0.8427	29.11/0.8054	28.28/0.8546	33.66/0.9453
	ACAN	1115	1051.7	34.46/0.9277	30.39/ 0.8435	29.11/0.8055	28.28/0.8550	33.61/0.9447
	LatticeNet	765	76.3	34.40/0.9272	30.32/0.8416	29.10/0.8049	28.19/0.8513	33.63/0.9442
	AWSRN-M	1143	116.6	34.42/0.9275	30.32/0.8419	29.13/0.8059	28.26/0.8545	33.64/0.9450
	PAN	261	39.0	34.30/0.9266	30.30/0.8416	29.06/0.8042	28.02/0.8493	33.34/0.9435
	MAFFSRN-L	807	68.5	34.45/0.9277	30.40/0.8432	29.13/0.8061	28.26/ 0.8552	—/—
	MPFFA (本文方法)	523	66.2	34.51/0.9283	30.37/0.8424	29.13/0.8058	28.35/0.8550	33.85/0.9461
×4	SRCNN	57	52.7	30.48/0.8628	27.49/0.7503	26.90/0.7101	24.52/0.7221	27.66/0.8505
	FSRCNN	12	4.6	30.71/0.8657	27.59/0.7535	26.98/0.7150	24.62/0.7280	27.90/0.8517
	VDSR	665	612.6	31.35/0.8838	28.01/0.7674	27.29/0.7251	25.18/0.7524	28.83/0.8809
	DRCN	1774	17974	31.53/0.8854	28.02/0.7670	27.23/0.7233	25.14/0.7510	28.98/0.8816
	LapSRN	813	149.4	31.54/0.8850	28.19/0.7720	27.32/0.7280	25.21/0.7560	29.09/0.8845
	DRRN	1774	17974.3	31.53/0.8854	28.02/0.7670	27.23/0.7233	25.14/0.7510	28.98/0.8816
	MemNet	677	2662.4	31.74/0.8893	28.26/0.7723	27.40/0.7281	25.50/0.7630	29.42/0.8942
	SRMDNF	1555	89.3	31.96/0.8930	28.35/0.7770	27.49/0.7340	25.68/0.7730	30.09/0.9024
	CARN	1592	90.9	32.13/0.8937	28.60/0.7806	27.58/0.7349	26.07/0.7837	30.47/0.9084
	IMDN	715	40.9	32.21/0.8948	28.58/0.7811	27.56/0.7353	26.04/0.7838	30.45/0.9075
	LAPAR-A	659	94	32.15/0.8944	28.61/0.7818	27.61/0.7366	26.14/0.7871	30.42/0.9074
	RFDN	550	31.6	32.24/0.8952	28.61/0.7819	27.57/0.7360	26.11/0.7858	30.58/0.9089
	A ² F-M	1010	56.7	32.28/0.8955	28.62/0.7828	27.58/0.7364	26.17/0.7892	30.57/0.9100

续表 3

放大 倍数	模型	参数量/ 10^3	计算量/ GFLOPs	PSNR/SSIM				
				Set5	Set14	B100	Urban100	Manga109
×4	ACAN	1 556	616.5	32.24/0.895 5	28.62/0.782 4	27.59/0.736 6	26.17/0.789 1	30.53/0.908 6
	LatticeNet	777	43.6	32.18/0.894 3	28.61/0.781 2	27.57/0.735 5	26.14/0.784 4	30.54/0.907 5
	AWSRN-M	1 254	72	32.21/0.895 4	28.65/0.783 2	27.60/0.736 8	26.15/0.788 4	30.56/0.909 3
	PAN	272	28.2	32.06/0.893 9	28.56/0.781 3	27.55/0.735 2	26.01/0.783 0	30.33/0.906 9
	MAFFSRN-L	830	38.6	32.20/0.895 3	28.62/0.782 2	27.59/0.737 0	26.16/0.788 7	—/—
	MPFFA(本文方法)	534	43.0	32.36/0.896 8	28.69/0.783 5	27.61/0.737 2	26.29/0.790 2	30.71/0.911 5

注: 加黑代表每列最优值, 下同。

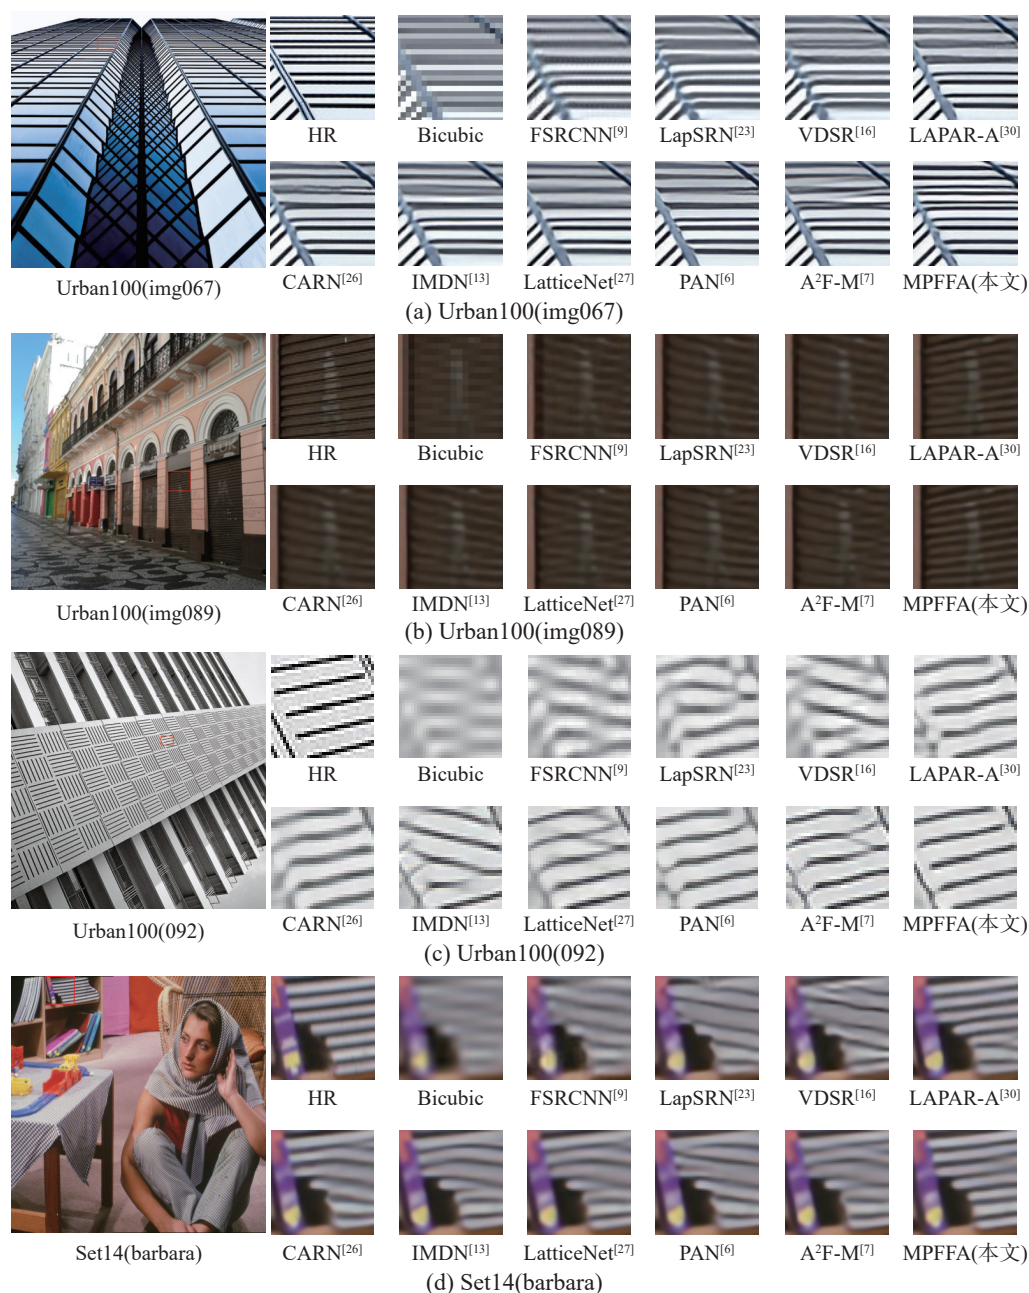


图 3 4 倍 SR 结果的视觉效果比较

Fig. 3 Visual comparison for ×4 SR

在 Set5、Urban100 和 Manga109 标准测试数据集上, 与其他 5 个代表方法 (CARN^[26]、IMDN^[13]、

LatticeNet^[27]、LAPAR-A^[30] 和 PAN^[6]) 4 倍 SR 的 LPIPS 结果如表 4 所示, 其值越小越好。

1) 定量客观比较。从表3可以看出,本文方法的PSNR/SSIM结果显著优于其他比较的方法。例如,LAPAR-A和RFDN方法比本文的MPFFA模型略大,但是,PSNR的结果一致优于这2个方法。 $\times 2$ 、 $\times 3$ 、 $\times 4$ 的PSNR在各个数据集上,超出LAPAR-A最大值分别为0.31、0.34和0.29 dB;超出RFDN最大值分别为0.22、0.18和0.18 dB。 A^2F -M方法的参数量大约是MPFFA参数量的2倍,但是,在Manga109数据集上 $\times 2$ 、 $\times 3$ 、 $\times 4$ 的PSNR结果比MPFFA的结果分别低0.11、0.19和0.14 dB。ACAN方法的 $\times 4$ 参数量大约是MPFFA参数量的3倍,在Manga109数据集上的PSNR结果,比MPFFA的结果低0.18 dB,而且计算量比MPFFA大约高出了26倍。从表4可以看出,本文方法的LPIPS结果也均优于其他比较的方法。

表4 不同SISR方法4倍SR的LPIPS值
Table 4 LPIPSs of $\times 4$ SR for different SISR methods

模型	参数量/ 10^3	计算量/ GFLOPs	Set5	Urban100	Manga109
CARN	1592	90.9	0.1761	0.2363	—
IMDN	715	40.9	0.1743	0.2350	0.1330
LatticeNet	777	43.6	0.1769	0.2423	0.1113
LAPAR-A	659	94.0	0.1759	0.2317	0.1101
PAN	272	28.2	0.1741	0.2348	0.1107
MPFFA	534	43.0	0.1727	0.2265	0.1071

2) 主观效果比较。图3给出了本文方法与其他先进方法在 $\times 4$ 时重建的SR图像结果。本文方法的结果比其他方法的结果更好,是显著可视

的。以Urban100数据集中图像img067为例,Bicubic、FSRCNN、CARN、LatticeNet和 A^2F -M等方法恢复的楼房条纹,均有不同程度的模糊和失真,甚至 A^2F -M方法恢复的条纹也发生了部分扭曲,本文方法恢复出的条纹很接近于原HR图像。Urban100数据集中图像img089,除LAPAR-A方法和本文网络模型之外,其他方法恢复的条纹基本上过度模糊失真和条纹方向错误。虽然LAPAR-A方法正确地恢复了条纹的方向,但是仍然有明显的模糊,本文方法的结果更加清晰,更接近于原HR图像。Urban100数据集中图像img092,除LAPAR-A、PAN方法和本文网络模型之外,其他方法恢复的条纹,基本上存在过度模糊失真和条纹方向错误的现象。虽然LAPAR-A、PAN正确地恢复了条纹方向,但是仍然有明显的模糊,本文方法的结果更加清晰,与原HR图像更加接近。而对于Set14数据集中的图像barbara,只有本文方法对纹理的重建方向正确,而且视觉效果更加清晰且不失真。

图4给出了本文方法与其他先进方法在 $\times 3$ 时重建的SR图像结果。本文方法的结果比其他方法的结果更好,是显著可视的。以Urban100数据集中图像img011为例,Bicubic、FSRCNN、CARN、LatticeNet和 A^2F -M等方法恢复的纹理均有不同程度的模糊和失真,本文方法的重建效果很接近于原HR图像。Urban100数据集中图像img024也类似,相较于其他几种方法,本文方法的重建效果比它们更接近于HR图像。

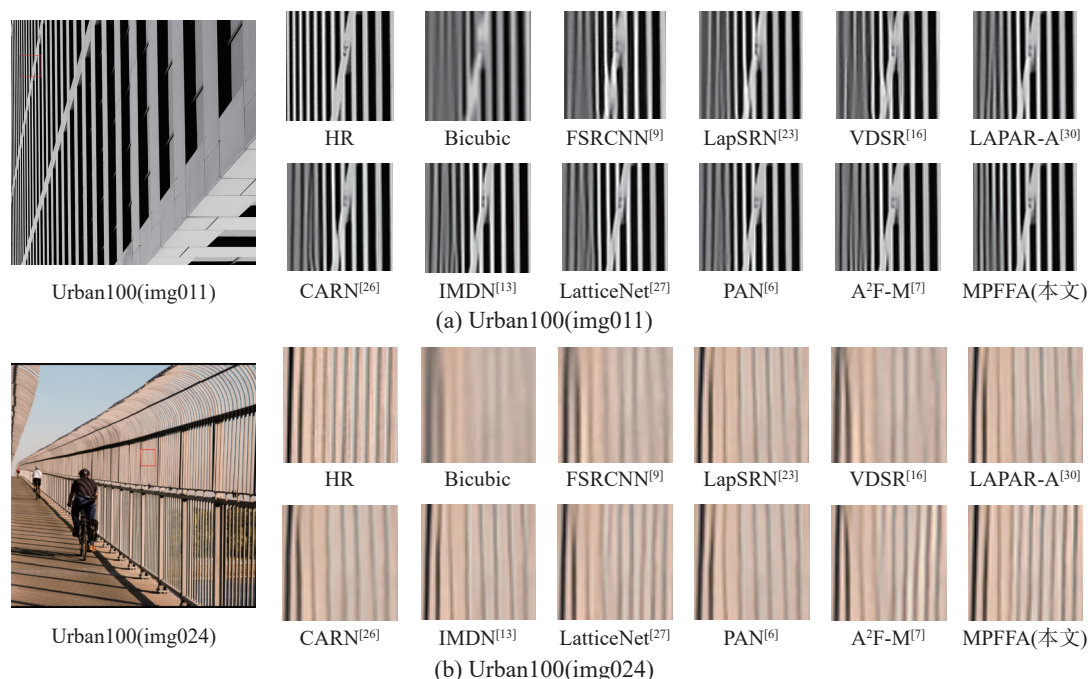


图4 3倍SR结果的视觉效果比较

Fig. 4 Visual comparison for $\times 3$ SR

4 结束语

本文提出了一个基于多路特征渐进融合和注意力机制的轻量级图像超分辨率网络。本文主要工作是提出了一个 FPF 和一个 FAM, FPF 和 FAM 块配对使用。FPF 可以利用前面的特征,多路渐进地引导和辅助后面特征的学习; FAM 则可以把多路特征通道,加权拼接,提高特征信息的利用率和表达能力。实验结果表明,本文方法是有效的,无论是客观度量还是主观度量都明显优于其他先进的方法,把轻量级 SISr 的复杂度和性能平衡提高到了一个新的水平。未来仍考虑进一步优化本文网络结构和损失函数,继续改进其性能。

参考文献:

- [1] PARK S C, PARK M K, KANG M G. Super-resolution image reconstruction: a technical overview[J]. *IEEE signal processing magazine*, 2003, 20(3): 21–36.
- [2] DONG Chao, LOY C C, HE Kaiming, et al. Image super-resolution using deep convolutional networks[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2015, 38(2): 295–307.
- [3] 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*. Hawaii: IEEE, 2017: 136–144.
- [4] ZHANG Yulun, LI Kunpeng, LI Kai, et al. Image super-resolution using very deep residual channel attention networks[C]//*Proceedings of the European Conference on Computer Vision*. Munich: ACM, 2018: 286–301.
- [5] HUI Zheng, WANG Xiumei, GAO Xinbo. Fast and accurate single image super-resolution via information distillation network[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018: 723–731.
- [6] ZHAO Hengyuan, KONG Xiangtao, HE Jingwen, et al. Efficient image super-resolution using pixel attention[C]//*European Conference on Computer Vision*. Glasgow: ACM, 2020: 56–72.
- [7] WANG Xuehui, WANG Qing, ZHAO Yuzhi, et al. Lightweight single-image super-resolution network with attentive auxiliary feature learning[C]//*Proceedings of the Asian Conference on Computer Vision*. Kyoto: AFCV, 2021: 268–285.
- [8] ZHAO Xiaole, LIAO Ying, HE Tian, et al. Fc²n: fully channel-concatenated network for single image super-resolution [EB/OL]. (2021–05–05)[2023–06–12]. <https://arxiv.org/pdf/1907.03221.pdf>.
- [9] DONG Chao, LOY C C, TANG Xiaoou. Accelerating the super-resolution convolutional neural network[C]//*European Conference on Computer Vision*. Amsterdam: ACM, 2016: 391–407.
- [10] 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*. Las Vegas: IEEE, 2016: 1637–1645.
- [11] TAI Ying, YANG Jian, LIU Xiaoming, et al. MemNet: a persistent memory network for image restoration[C]//*Proceedings of the IEEE International Conference on Computer Vision*. Venice: IEEE, 2017: 4539–4547.
- [12] 周登文, 赵丽娟. 基于递归残差网络的图像超分辨率重建[J]. *自动化学报*, 2019, 45(6): 1157–1165.
ZHOU Dengwen, ZHAO Lijuan. Image super-resolution based on recursive residual networks[J]. *Acta automatica sinica*, 2019, 45(6): 1157–1165.
- [13] HUI Zheng, GAO Xinbo, YANG Yuchu, et al. Lightweight image super-resolution with information multi-distillation network[C]//*Proceedings of the 27th ACM International Conference on Multimedia*. Nice: ACM, 2019: 2024–2032.
- [14] LIU Jie, TANG Jie, WU Gangshan. Residual feature distillation network for lightweight image super-resolution [C]//*European Conference on Computer Vision*. Glasgow: ACM, 2020: 41–55.
- [15] 周登文, 王婉君. 基于区域互补注意力和多维注意力的轻量级图像超分辨率网络 [J]. *模式识别与人工智能*, 2022, 35(7): 625–636.
ZHOU Dengwen, WANG Wanjun. Lightweight image super-resolution network based on regional complementary attention and multi-dimensional attention[J]. *Pattern recognition and artificial intelligence*, 2022, 35(7): 625–636.
- [16] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE, 2016: 1646–1654.
- [17] ZHANG Yulun, TIAN Yapeng, KONG Yu, et al. Residual dense network for image super-resolution[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018: 2472–2481.
- [18] WOO S, PARK J, LEE J Y, et al. Cbam: convolutional block attention module[C]//*Proceedings of the European Conference on Computer Vision*. Glasgow: ACM, 2018: 3–19.
- [19] ZHANG Jiqing, LONG Chengjiang, WANG Yuxin, et al.

- A two-stage attentive network for single image super-resolution[J]. IEEE transactions on circuits and systems for video technology, 2021, 32: 1020–1033.
- [20] TIMOFTE R, AGSTSSON 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. Hawaii: IEEE, 2017: 114–125.
- [21] ZHANG R, ISOLA P, EFROS A A, et al. The unreasonable effectiveness of deep features as a perceptual metric[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 586–595.
- [22] HUANG Zhiyong, LI Wenbin, LI Jinxin, et al. Dual-path attention network for single image super-resolution[J]. *Expert systems with applications*, 2021, 169: 114450.
- [23] LAI Weisheng, HUANG Jiabin, AHUJA N, et al. Deep laplacian pyramid networks for fast and accurate super-resolution[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Hawaii: IEEE, 2017: 624–632.
- [24] TAI Ying, YANG Jian, LIU Xiaoming. Image super-resolution via deep recursive residual network[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Hawaii: IEEE, 2017: 3147–3155.
- [25] ZHANG Kai, ZUO Wangmeng, ZHANG Lei. Learning a single convolutional super-resolution network for multiple degradations[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 3262–3271.
- [26] AHN N, KANG B, SOHN K A. Fast, accurate, and lightweight super-resolution with cascading residual network[C]//Proceedings of the European Conference on Computer Vision. Munich: ACM, 2018: 252–268.
- [27] LUO Xiaotong, XIE Yuan, ZHANG Yulun, et al. Latticenet: towards lightweight image super-resolution with lattice block[C]//Computer Vision–ECCV 2020: 16th European Conference. Glasgow: ACM, 2020: 272–289.
- [28] MUQEET A, HWANG J, YANG S, et al. Multi-attention based ultra lightweight image super-resolution[C]//European Conference on Computer Vision. Glasgow: ACM, 2020: 103–118.
- [29] ZHOU Dengwen, CHEN Yiming, LI Wenbin, et al. Image super-resolution based on adaptive cascading attention network[J]. *Expert systems with applications*, 2021, 186: 115815.
- [30] LI Wenbo, ZHOU Kun, QI Lu, et al. Lapar: linearly-assembled pixel-adaptive regression network for single image super-resolution and beyond[C]//Proceedings of the Advances in Neural Information Processing Systems. Chicago: NIPS, 2021: 20343–20355.

作者简介:



刘玉铠, 硕士, 主要研究方向为计算机视觉和深度学习。E-mail: liuyk@ncepu.edu.cn。



周登文, 教授, 主要研究方向为图像去噪、图像去马赛克、图像插值和图像超分辨率。发表学术论文 50 余篇。E-mail: zdw@ncepu.edu.cn。