

基于穿插特征更新的光场图像超分网络

陈佳妮, 武迎春*, 吕天琪, 刘 丽, 赵贤凌

(太原科技大学电子信息工程学院, 山西太原 030024)

摘 要: 针对光场图像空间分辨率低的问题, 本文搭建了基于穿插特征更新的光场图像超分网络, 获得更高质量的光场子孔径图像阵列. 网络的浅层特征提取部分采用 3 分支结构, 设计了并行残差块从不同形式的光场数据中提取空间特征和角度特征. 深层特征提取采用穿插特征更新结构, 设计了特征对齐交互模块、自注意力特征交互模块和空间特征增强模块, 实现了空间特征与角度特征逐级融合更新. 数据重构部分通过交替使用多尺度残差块和通道注意力块将逐级更新后的空间信息融合, 最终经数据上采样得到超分图像. 所提网络在充分挖掘、补充空间、角度特征的基础上, 采用逐级融合、更新、增强机制, 实现不同层次空间信息的收集, 获得更好的超分效果. 对比实验验证了所提网络的优越性, 在 5 组公开光场数据集上, 本文搭建的网络在 4 倍超分任务下平均峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR) 值达到 32.31 dB, 较现有网络表现出更好的超分性能.

关键词: 4D 光场; 超分辨率重建; 穿插特征更新; 特征对齐交互; 自注意力特征交互

基金项目: 国家自然科学基金 (No.61601318); 山西省自然科学基金 (No.202103021224278); 山西省回国留学人员科研项目 (No.2020-128)

中图分类号: TP391.4

文献标识码: A

文章编号: 0372-2112(2024)12-4113-12

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20240253

Cross Feature Updating-Based Network for Light Field Image Super Resolution

CHEN Jia-ni, WU Ying-chun*, LÜ Tian-qi, LIU Li, ZHAO Xian-ling

(School of Electronic and Information Engineering, Taiyuan University of Science and Technology, Taiyuan, Shanxi 030024, China)

Abstract: Addressing the issue of low spatial resolution in light field image, cross feature updating-based network for light field image super resolution is built in this paper to generate a higher quality array of light field sub-aperture images. In this work, a 3-branch structure is adopted for shallow feature extraction. In order to extract spatial and angular features from different forms of light field data, parallel residual block is designed. A cross feature update structure is used for extract deep features, and feature alignment interaction module, self-attention feature interaction module, and spatial feature enhancement module are designed to achieve step-by-step fusion and updating of spatial and angular features. In the data reconstruction part, the updated spatial information is fused by using multi-scale residual block and channel attention block alternately and finally super-resolution images are obtained through data upsampling. On the basis of fully exploring and supplementing spatial and angular features, the proposed network adopts a step-by-step fusion, update, and enhancement mechanism to gather spatial information at different levels, leading to superior super-resolution results. Comparative experiments demonstrate the effectiveness of the proposed method, with the network achieving an average peak signal-to-noise ratio (PSNR) value of 32.31 dB for 4× tasks on 5 public light field datasets, surpassing the performance of existing networks.

Key words: 4D light field; super-resolution reconstruction; cross feature updating; feature alignment interaction; self-attention feature interaction

Foundation Item(s): National Natural Science Foundation of China (No.61601318); Natural Science Foundation of Shanxi Province (No.202103021224278); Research Project Supported by Shanxi Scholarship Council of China (No.2020-128)

1 引言

基于光场双平面表示理论模型^[1],光场相机可以通过单次曝光同时记录空间光线的位置信息和方向信息.将光线位置信息和方向信息解码为场景空间信息和角度信息后,得到4D光场.4D光场是实现数字重聚焦^[2,3]、多视点图像获取^[4]、全聚焦图像融合^[5]、深度估计^[6-8]的基础.由于空间光线方向信息的捕获以牺牲部分位置信息的捕获为代价,导致获取的光场图像的空间分辨率较低,阻碍其在下游视觉任务中的应用.因此,研究光场超分辨率重构技术具有重要意义.

将4D光场转化为多个2D图像,利用传统图像超分网络^[9-12]即可对每个2D图像进行超分.然而,传统单图像超分网络仅利用了光场的空间信息,未充分考虑多个2D图像之间的相关性——即角度相关性,造成超分后图像质量较低.为解决这个问题,一些学者将4D光场图像表示为携带空间信息和角度信息的子孔径图像(Sub-Aperture Image, SAI)阵列、宏像素图像(Macro-Pixel Image, MacPI)和极平面图像(Epipolar Plane Image, EPI)作为输入,从不同角度设计了性能优越的网络,充分挖掘光场空间和角度信息完成光场超分,进而提高光场图像的质量.

以SAI阵列为输入,Yoon等人^[13]首次将卷积神经网络应用于光场,设计了空间、角度分步超分网络实现光场超分.Yeung等人^[14]提出空间、角度信息可分离的光场超分(Light Field Spatial Super-Resolution using deep efficient spatial-angular separable convolution, LFSSR)网络,该方法使用交替的空间-角度可分离卷积来提取光场的4D信息,在子孔径模式和宏像素模式之间交替卷积重塑光场.Wang等人^[15]提出可变形卷积光场图像超分(Light Field image super-resolution using DeFormable convolution, LF-DFnet)网络,设计了角度可变形对齐模块,将角度信息编码到每个视图的特征中,处理了光场图像超分中存在的视差问题.Wang等人^[16]将Transformer引入光场超分,提出细节保留光场超分(Detail-Preserving Transformer for light field image super-resolution, DPT)网络,该网络利用3个Transformer来建立不同子孔径图像之间的非局部关系,使用梯度信息引导序列学习,很好地保留光场图像的细节纹理信息.Liu等人^[17]提出视图间和视图内的特征交互光场超分(Intra-Inter view interaction network for Light Field image super-resolution, LF-IInet)网络,该网络将子孔径图像的视图内和视图间特征进行交互,达到保留光场视差结构的目的.

以MacPI为输入,Wang等人^[18]提出空间、角度信息交互光场超分(spatial-angular Interaction for Light Field image super-resolution, LF-Internet)网络,该网络将光场4D信息解耦为空间信息和角度信息,将空间信息和角

度信息反复交互融合得到高分辨率的光场图像.之后,他们又提出解耦光场超分(Disentangling light fields for Spatia Super-Resolution, DistgSSR)网络^[19],通过设计特定的空间特征提取器和角度特征提取器来解耦光场结构,再通过空间、角度特征融合实现光场超分.

以EPI为输入,Zhang等人^[20]提出残差光场超分(Residual networks for Light Field image super-resolution, ResLF)网络,该方法将不同角度堆叠的子孔径图像作为网络输入,通过学习子孔径阵列水平、垂直和对角方向上的视差信息来建模空间-角度相关性来实现光场超分.由于ResLF仅使用部分子孔径图像来超分中心视图,导致被丢弃子孔径图像的角度信息未被充分利用.随后,Zhang等人^[21]再次提出基于多极几何的端到端光场超分网络(end-to-end Light Field spatial super-resolution network using Multiple Epipolar Geometry, LF-MEGnet),该方法将子孔径图像阵列按方向分成多个图像堆叠,通过学习图像间的亚像素信息来恢复空间中潜在的纹理信息,实现光场超分.

从以上文献分析可以看出,无论以何种形式的图像作为网络输入,有效提取空间信息和角度信息,合理建模空间信息与角度信息的相关性来实现信息融合都是提高网络超分性能的关键.基于此,本文在实现空间信息和角度信息的解耦时,将子孔径图像分3支路送入网络,通过并行残差块分别提取包含角度信息的子孔径阵列特征和包含空间信息的单个子孔径图像特征,并利用中心孔径图像特征补充子孔径阵列特征,强化角度差异,实现角度信息的充分挖掘.在实现空间信息和角度信息融合时,采用了双支路穿插特征更新机制,通过特征穿插交互结构更好地实现空间、角度信息的更新.针对更新后的空间特征设计了空间特征增强模块,增加后期馈入重构模块空间特征的丰富性.本文的主要贡献如下:

(1)设计了基于穿插特征更新的光场图像超分网络(Cross Feature Updating-based network for Light Field image super resolution, LF-CFUnet),实现更高的超分性能.

(2)为了有效提取光场的空间与角度信息,将中心孔径图像、子孔径图像阵列、单个子孔径图像分3支路送入网络.在浅层特征提取部分,设计了并行残差模块(Parallel Residual Block, PRB),利用残差空洞空间金字塔池化(Residual Atrous Spatial Pyramid Pooling, ResASPP)和稠密残差块在捕获层次特征同时扩大感受野.

(3)在深层特征提取部分,采用穿插特征更新机制,设计了特征对齐交互模块(Feature Alignment Interaction Module, FAIM)和自注意力特征交互模块(Self-attention Feature Interaction Module, SFIM),分别进行空

间特征更新和角度特征更新. 为了充分挖掘视图内潜在的空间信息, 将更新后的空间特征送入空间特征增强模块 (Spatial Feature Enhancement Module, SFEM) 进行特征强化.

(4) 在重构部分, 交替使用多尺度残差 (Multi-Scale Residual, MSR) 块和通道注意力 (Channel Attention, CA) 块来融合不同层次的空间特征, 实现有效的数据重构.

2 穿插特征更新的光场图像超分网络搭建

将 4D 光场表示为 $L_{\text{Field}}(h, w, u, v) \in \mathbf{R}^{H \times W \times U \times V}$, 其中 $U \times V$ 表示 4D 光场的角度分辨率, $H \times W$ 表示 4D 光场的空间分辨率. 本文所设计的网络输入为低分辨率子孔径图像阵列 $L^{LR} \in \mathbf{R}^{H \times W \times U \times V}$, 每个阵列包含 $U \times V$ 张子孔径图像, 每个子孔径图像的分辨率为 $H \times W$. 经过网络, 最终输出为高分辨率子孔径图像阵列 $L^{HR} \in \mathbf{R}^{aH \times aW \times U \times V}$, a 表示为上采样因子.

网络的整体结构如图 1(a) 所示, 包括浅层特征提取、深层特征提取和数据重构 3 部分. 在浅层特征提取部分, 本文设计了 3 个支路, 通过并行残差块来获取中心孔径图像特征、不同子孔径图像间特征和单个子孔径图像特征, 使用中心孔径图像特征补充角度特征强化角度差异. 在深层特征提取部分, 设计了特征对齐交互模块和自注意力特征交互模块, 通过特征穿插交互更好地实现空间、角度信息的更新, 并将更新后的空间特征送入空间特征增强模块进行特征强化. 数据重构部分包括特征融合和特征上采样, 特征融合包括 6 组交替残差和通道注意力模块, 逐步解码出图像的有效信息, 通过上采样得到高分辨率的子孔径图像阵列.

2.1 浅层特征提取

由于不同子孔径图像存在视差, 其包含的空间信息有所不同, 充分利用单个子孔径图像内的信息和不同子孔径图像间的信息, 对 2 路信息交叉融合是提高超分性能的关键. 为了深入挖掘单个子孔径图像内的特征和子孔径图像间的特征差异, 本文的浅层特征提取部分由 3 个分支组成, 通过并行残差块 (PRB) 完成特征提取. 第 1 个分支在子孔径图像阵列中选择中心孔径图像 $I_c^{LR} \in \mathbf{R}^{1 \times H \times W}$, 通过 C-PRB 提取其特征 $F_c \in \mathbf{R}^{C \times H \times W}$, 因为中心孔径图像对应于每个微透镜成像区域的中心位置, 和其他图像具有更强的空间相关性, 提供更丰富的场景特征. 第 2 个分支是将子孔径图像阵列沿通道维度进行重排 $I^{LR} \in \mathbf{R}^{N \times H \times W}$ ($N = U \times V$), 挖掘多个子孔径图像之间的相关性, 通过 A-PRB 提取不同子孔径图像间差异特征 (角度特征) $A \in \mathbf{R}^{C \times H \times W}$. 第 3 个分支以子孔径图像阵列 $I_i^{LR} \in \mathbf{R}^{1 \times H \times W}$ ($i = 1, 2, \dots, N$) 为输入, 充分挖掘单个视图内的信息, 通过 S-PRB 提取单个视图内特征 (空间特征)

$S_i^0 \in \mathbf{R}^{C \times H \times W}$. A-PRB、C-PRB、S-PRB 等 3 个模块的操作与 PRB 相同, 区别在于输入、输出特征维度不同. PRB 的结构如图 1(b) 所示, 其包含 2 个分支, 上分支是残差空洞空间金字塔池化 (ResASPP), 包含膨胀率为 1、2、4 的 3 个 3×3 的空洞卷积, 可生成多尺度特征实现不同尺度特征的提取; 下分支是稠密残差块, 包含 3 个 3×3 和 2 个 1×1 的普通卷积, 在 3×3 卷积之后使用非线性激活函数 (Rectified Linear Unit, ReLU), 采用稠密连接的方式, 高效利用浅层特征信息的同时提高模型表达能力, 解决网络退化问题, 有效提高超分性能.

中心孔径图像位于子孔径图像阵列中心, 与阵列中其他图像的视差有对称规律, 故将中心孔径图像特征补充到角度特征中, 强化角度差异. 具体操作: 将第 1 个支路特征和第 2 个支路特征进行通道拼接, 通过卷积进行降维.

$$A_s^0 = H_{1 \times 1}([\mathbf{F}_c, \mathbf{A}]) \quad (1)$$

其中, $[\cdot]$ 表示通道拼接操作, $H_{1 \times 1}(\cdot)$ 表示 1×1 卷积操作压缩通道数, A_s^0 表示补充后的角度特征.

2.2 深层特征提取

深层特征提取主要实现空间特征和角度特征融合与更新, 本文采用双支路穿插特征更新机制, 设计了特征对齐交互模块 (FAIM) 和自注意力特征交互模块 (SFIM), 采用多个 FAIM、SFIM 进行空间特征和角度特征的融合更新. 由于本文的目标是空间信息超分, 对更新后的空间特征, 设计了空间特征增强模块 (SFEM), 增加了后期馈入重构模块空间特征的丰富性.

FAIM 首先采用 2 个 PRB 进一步挖掘空间特征, 然后将补充后的角度特征与每个子孔径图像特征对齐, 通过空间、角度特征相互穿插, 实现空间特征更新, FAIM 的结构如图 1(c) 所示. 设深层特征提取部分包含 M 个 FAIM, 第 1 个 FAIM 的输入为补充后的角度特征 A_s^0 和每个子孔径图像的空间特征 S_i^0 ($i = 1, 2, \dots, N$), 输出为更新后每个子孔径空间特征 S_i^1 . 第 m 个 FAIM 的输入为 A_s^{m-1} 和 S_E^{m-1} , 输出为 S_i^m :

$$S_i^m = H_{\text{FAIM}}^m(A_s^{m-1}, S_E^{m-1}) \quad (2)$$

其中, S_i^m 表示第 m 个 FAIM 更新后的空间特征, A_s^{m-1} 表示第 $m-1$ 个 SFIM 更新后的角度特征, $H_{\text{FAIM}}^m(\cdot)$ 表示第 m 个 FAIM 的操作.

SFIM 首先将更新后的空间特征重排, 重排后的空间特征经 1×1 卷积降通道后与补充的角度特征拼接实现空间、角度特征融合, 融合后的特征经过空间注意力和通道注意力 2 个并行自注意力模块进行有效特征提取, 提取后的特征再拼接得到更新后的角度特征, SFIM 的结构如图 1(d) 所示. 设深层特征提取部分包含 $M-1$ 个 SFIM, 第 1 个 SFIM 的输入为补充后的角度特征 A_s^0 和更新后的每个子孔径图像的空间特征 S_i^1 ($i = 1, 2, \dots, N$),

输出为更新后角度特征 A_s^1 . 第 m 个 SFIM 的输入为 A_s^{m-1} 和 S_i^m , 输出为 A_s^m :

$$A_s^m = H_{\text{SFIM}}^m(A_s^{m-1}, S_i^m) \quad (3)$$

其中, $H_{\text{SFIM}}^m(\cdot)$ 表示第 m 个 SFIM 的操作, A_s^m 表示第 m 个 SFIM 更新后的角度特征.

SFEM 将更新后的空间特征先通过 3 个级联卷积生成初级特征, 再通过 3 路并联的不同尺度卷积进一步提取多尺度特征, 实现特征强化. 为了防止网络退化, 级联

结构和并联结构中用到了跳跃连接和残差连接, SFEM 的结构如图 1(f) 所示. 设深层特征提取部分包含 M 个 SFEM, 第 1 个 SFEM 的输入为更新后空间特征 S_i^1 ($i=1, 2, \dots, N$), 输出为强化后每个子孔径空间特征 S_E^1 . 第 m 个 SFEM 的输入为 S_i^m , 输出为 S_E^m :

$$S_E^m = H_{\text{SFEM}}^m(S_i^m) \quad (4)$$

其中, $H_{\text{SFEM}}^m(\cdot)$ 表示第 m 个 SFEM 的操作, S_E^m 表示通过第 m 个 SFEM 强化后的空间特征.

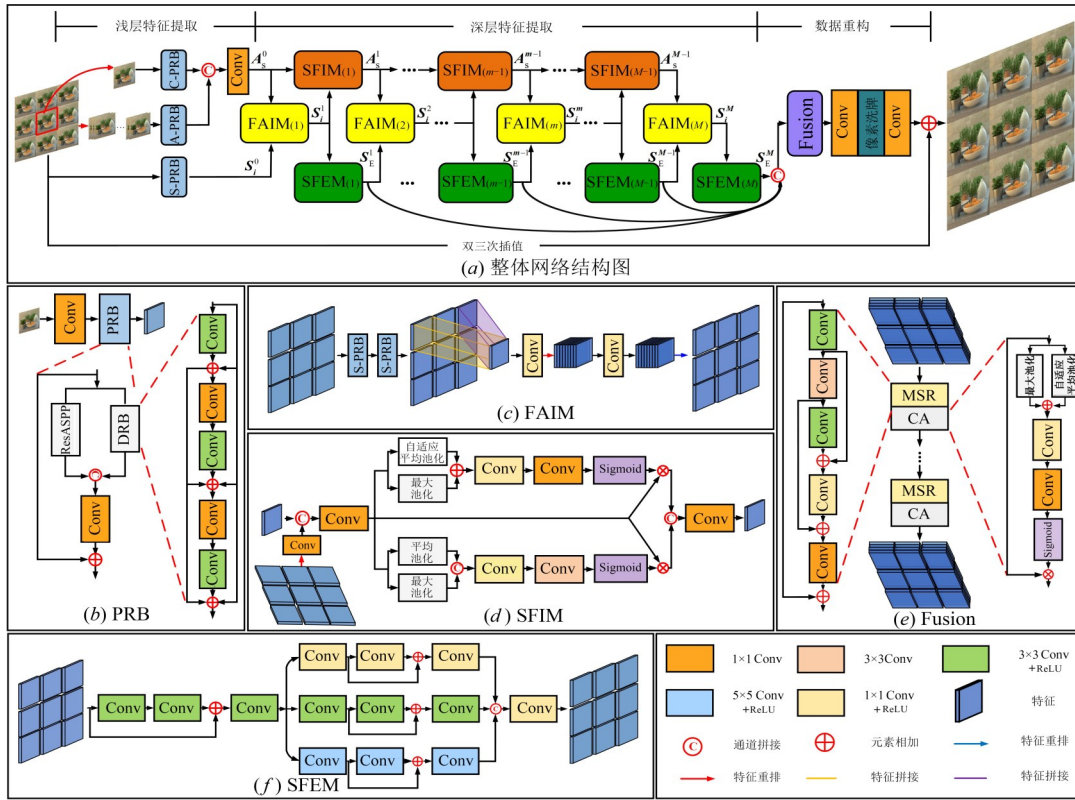


图1 所提算法结构图

2.3 数据重构

数据重构一般包括特征融合和特征上采样 2 部分, 它们的目的是将网络提取的有效信息解码为高分辨率的光场图像. 为了充分利用深层特征提取部分得到的多层次信息, 本文特征融合模块交替使用 6 组多尺度残差块 (MSR) 和通道注意力块 (CA), 进一步提高超分性能.

特征融合模块具体细节如图 1(e) 所示, 将 4 个 SFEM 生成的特征沿通道维度拼接送入 MSR 来融合浅层特征和深层特征, 避免信息丢失. MSR 以残差的形式构建, 包含 3 个 3x3 的普通卷积和 2 个 1x1 的普通卷积, 采用跳跃连接的方式, 直接将浅层信息向后传递, 可以很好地将浅层特征和深层特征融合, 解决网络退化的问题. 由于不同通道的特征对网络的贡献不同, 使用通道注意力模块学习每个通道的重要性, 为通道产

生其对应的权重. 在通道注意力模块中, 使用自适应平均池化和最大池化, 将它们并行连接来压缩空间信息, 然后使用 1x1 卷积压缩通道数, 在 Relu 激活函数之后, 再使用 1x1 卷积来扩展通道数, 通过升维和降维将通道间相互作用关系纳入特征中, 最后采用 Sigmoid 函数来生成通道注意力权重. 将该融合过程简单表示如下:

$$S_{\text{Fusion}} = H_{\text{Fusion}}([S_E^1, S_E^2, \dots, S_E^m, \dots, S_E^{M-1}, S_E^M]) \quad (5)$$

其中, S_{Fusion} 表示融合后的空间特征, $H_{\text{Fusion}}(\cdot)$ 表示融合操作.

上采样模块包含 1x1 卷积和像素洗牌的操作, 旨在将融合特征升维, 得到最终的高分辨率光场图像. 融合特征先经过 1x1 卷积将特征通道数从 C 扩展到 a^2C , 再经过像素洗牌操作, 将特征从通道维度映射到空间维度, 生成分辨率为 $aS \times aT$ 、通道数为 C 的重构特征. 最

后,通过 1×1 卷积将特征通道数从 C 压缩到1,生成高分辨率的光场子孔径图像阵列。

3 实验结果与分析

3.1 数据集与程序执行细节

本文使用2个合成数据集(HCInew^[22]和HCIold^[23])和3个真实场景数据集(EPFL^[24]、INRIA^[25]和STFgantry^[26])验证所提方法的有效性,各数据集中训练集和测试集的场景数如表1所示,训练集和测试集中的所有光场图像的角分辨率为 9×9 。在训练阶段,将输入的光场图像裁剪成大小为 64×64 的块,通过下采样生成低分辨率光场补丁。为了训练稳定性,本文将批尺寸(batchsize)设置为8,初始学习率设置为 2×10^{-4} ,训练周期(epoch)设置为50,每15个周期学习率降低1/2。在NVIDIA RTX 3090 GPU上,使用Pytorch框架对网络进行训练和测试,L1损失函数进行约束,ADAM算法进行优化。

表1 实验采用的5个公共光场数据集

数据集	训练	测试
HCInew ^[22]	70	10
HCIold ^[23]	20	4
EPFL ^[24]	10	2
INRIA ^[25]	35	5
STFgantry ^[26]	9	2
合计	144	23

为了降低计算复杂度,本文将输入图像的RGB通道转化为YCbCr通道,仅超分Y通道,CbCr通道采用双3次插值进行上采样。使用PSNR和结构相似性值(Structural SIMilarity, SSIM)作为评价指标,在每个子孔径图像的Y通道上,计算超分后图像与标准高分辨率图像的PSNR和SSIM值,以评估网络的性能。

3.2 整体网络超分性能评价

3.2.1 视觉效果对比

为了直观验证本文所提网络的性能,将本文算法与2种基于深度学习的单图像超分算法和8种基于深度学习的光场图像超分辨率重构算法进行对比。在不同超分任务下,分别在测试数据集中选择2个场景作为展示。不同算法的视觉效果对比如图2和图3所示。

图2显示了2倍超分任务下HCInew^[22]数据集中,“Origima”与“Herbs”场景的视觉效果对比。通过对比发现,在边缘部分和纹理较密集部分,本文算法处理得更好。在“Origima”场景中,对绿色矩形框所框区域进行放大,可以看出,本文算法在椭圆框所框区域较清晰地恢复桶状物体的水平条纹,产生伪影较少。在“Herbs”场景中,对红色矩形框所框区域进行放大,可以看出,本文算法在椭圆框所框区域恢复出来的植物结构较清

晰,而LF-Internet、DPT存在明显的伪影和模糊现象。在进行光场2倍超分任务时,本文算法恢复的图像质量更高。

图3显示了4倍超分任务下EPFL^[24]数据集中“ISO_Chart”场景与HCInew^[22]数据集中“Bedroom”场景的视觉效果对比。通过仔细对比发现,在复杂纹理和细节方面,本文算法获得更好的视觉效果。在“ISO_Chart”场景中,对红色矩形框所框区域进行放大,可以看出,本文算法在椭圆框所框区域恢复出的线条更为清晰,且数字“2”最为清晰。LF-DFnet和LF-ILnet恢复结果存在明显伪纹理,且数字“2”较模糊。在“Bedroom”场景中,对红色矩形框所框区域进行放大,可以看出,本文算法在椭圆框所框区域较真实值最为接近。证明了本文算法在进行光场4倍超分时表现出较好的超分效果。

从图2和图3可看出,基于深度学习的光场超分算法恢复出的图像的质量明显优于基于深度学习的单图像超分算法和传统的双3次插值算法恢复出的图像的质量。由于基于深度学习的单图像超分算法的输入为单张子孔径图像,且该算法仅利用空间信息,忽略了角度信息,导致超分图像质量不高。基于深度学习的光场超分算法的输入为子孔径图像阵列,且该算法利用空间信息的同时,引入相邻子孔径图像之间的学习-角度信息,使得超分图像的质量有所提升。本文算法在实现空间信息和角度信息融合时,设计了双支路特征融合结构,通过特征穿插交互充分利用4D光场空间-角度信息的相关性,进一步提高超分效果。

3.2.2 整体性能定量评价

为了评估本文算法的性能,将本文算法与其他算法进行了比较,实验结果如表2所示。表2列出了不同算法在5个公共光场数据集测试集上PSNR和SSIM值的比较结果,同时提供5个数据集平均PSNR和SSIM值的比较结果。蓝色加粗字体表示每列的最优值,黑色加粗字体表示每列的次优值,加下划线字体表示本文算法。从表2可以看出,在2倍超分任务下,本文算法在HCInew和STFgantry数据集上性能最佳,且整体平均性能表现较好。在4倍超分任务下,本文算法的PSNR和SSIM值在5个光场数据集上均获得最大值,且整体平均性能表现最好。从表中可以看出,在4倍超分任务下,本文算法的PSNR和SSIM值相比于文献[17]分别提高了0.23 dB和0.002 1。该实验进一步验证了算法的优越性。

3.2.3 超分后子孔径图像的PSNR值分布

光场空间超分的目的是超分光场子孔径图像阵列中所有角度的图像,为此,本文研究了不同算法在不同角度下的超分性能。分别从表1列出的5个数据集中的

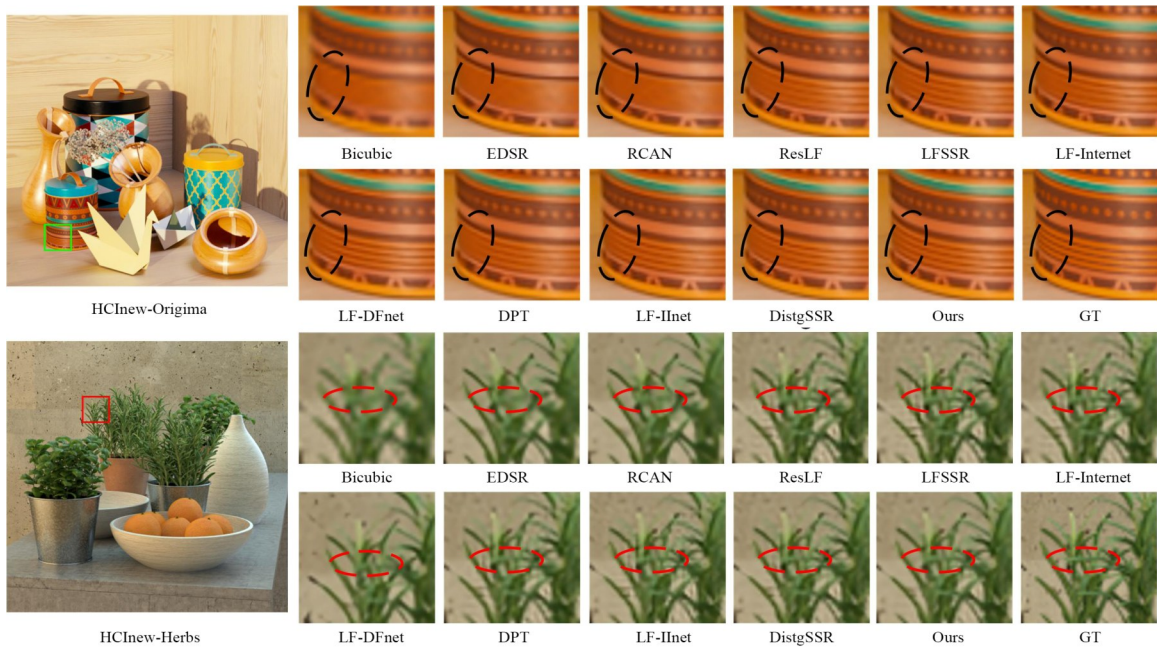


图2 “Origima”与“Herbs”场景的2倍超分的视觉效果对比

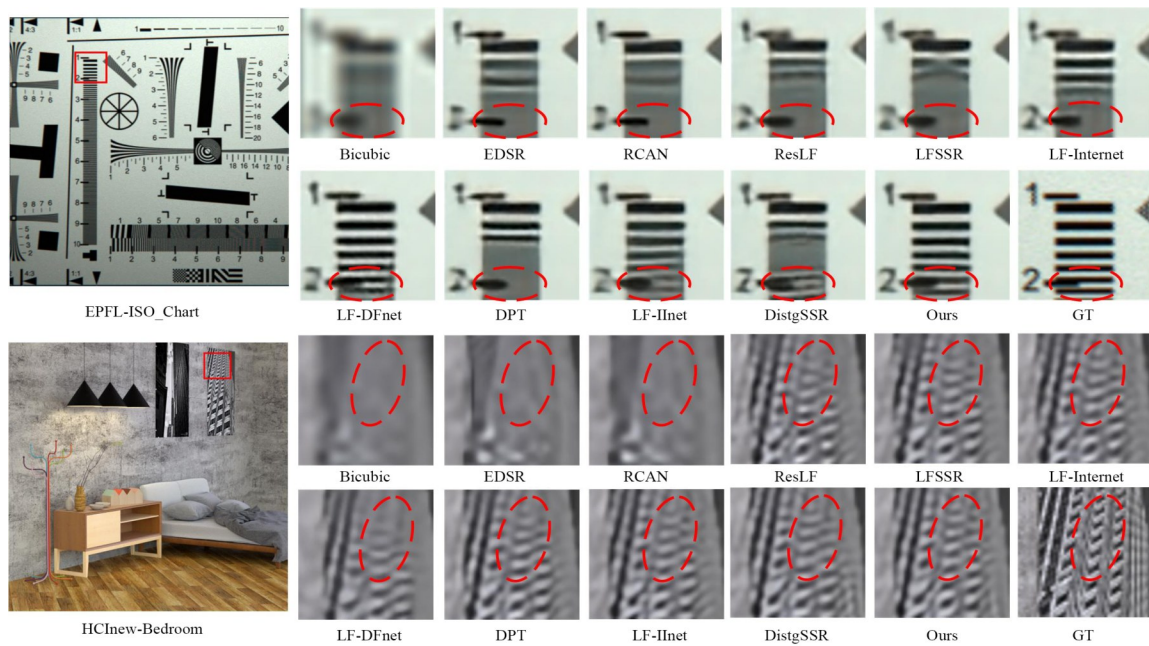


图3 “ISO_Chart”与“Bedroom”场景的4倍超分的视觉效果对比

测试集里选择1个场景,计算每个子孔径图像的PSNR值.实验过程中,使用子孔径图像阵列中心 5×5 个图像进行4倍超分,对实验结果可视化并计算每个子孔径图像的PSNR值,不同算法在不同角度下的超分效果如图4所示.由图4可知,本文算法获得了最好的超分效果.

3.2.4 算法复杂度对比

为进一步验证网络的性能,从参数量(#Params)、计算量(Floating Point of Operations, FLOPs)、运行时间3

个方面将本文算法和其他算法进行对比,结果如表3所示.

将本文算法的参数量、FLOPs值与各基于深度学习光场超分的算法进行对比,可以看出,本文算法参数量和FLOPs值稍大,原因在于,在网络的浅层特征提取部分,为了强化角度差异,本文算法在提取空间、角度特征的同时额外增加了1个支路,用来提取中心孔径图像特征;在深层特征提取部分,设计的FAIM在特征交互前增加了空间特征强化的过程,同时,在进行数据重构

表 2 2倍超分和4倍超分任务下不同算法得到超分图像的PSNR/SSIM值

方法	超分系数/倍	数据集					平均
		EPFL	HCInew	HCold	INRIA	STFgantry	PSNR/SSIM
Bicubic	2	29.74/0.937 6	31.89/0.935 6	37.69/0.978 5	31.33/0.957 7	31.06/0.949 8	32.34/0.951 8
EDSR ^[27]	2	33.09/0.963 1	34.83/0.959 4	41.01/0.987 5	34.97/0.976 5	36.29/0.981 9	36.04/0.972 8
RCAN ^[28]	2	33.16/0.963 5	34.98/0.960 2	41.05/0.987 5	35.01/0.976 9	36.33/0.982 5	36.11/0.974 1
ResLF ^[20]	2	32.75/0.967 2	36.07/0.971 5	42.61/0.992 2	34.57/0.978 4	36.89/0.987 3	36.58/0.979 3
LFSSR ^[14]	2	33.69/0.974 8	36.86/0.975 3	43.75/0.993 9	35.27/0.983 4	38.07/0.990 2	37.53/0.983 5
LF-Internet ^[18]	2	34.14/0.976 1	37.28/0.976 9	44.45/0.994 5	35.80/0.984 6	38.72/0.991 6	38.08/0.984 7
LF-DFnet ^[15]	2	34.44/0.976 6	37.44/0.978 6	44.23/0.994 3	36.36/0.984 1	39.61/0.993 5	38.42/0.985 4
DPT ^[16]	2	34.48/0.975 9	37.35/0.977 0	44.31/0.994 3	36.40/0.984 3	39.52/0.992 8	38.41/0.984 9
LF-Inet ^[17]	2	34.68/0.977 1	37.74/0.978 9	44.84/0.994 8	36.57/0.985 3	39.86/0.993 5	38.74/0.985 9
DistgSSR ^[19]	2	34.91/0.978 7	37.96/0.979 6	44.94/0.994 9	36.59/0.985 9	40.40/0.994 2	38.94/0.986 6
Ours	2	34.78/0.977 8	38.04/0.979 7	44.77/0.994 8	36.72/0.985 7	40.59/0.994 4	38.98/0.986 5
Bicubic	4	25.14/0.832 4	27.61/0.851 7	32.42/0.934 4	26.82/0.886 7	25.93/0.845 2	27.58/0.866 1
EDSR ^[27]	4	27.84/0.885 8	29.60/0.887 4	35.18/0.953 8	29.66/0.925 9	28.70/0.907 5	30.20/0.912 1
RCAN ^[28]	4	27.88/0.886 3	29.63/0.888 0	35.20/0.954 0	29.76/0.927 3	28.90/0.911 0	30.27/0.913 3
ResLF ^[20]	4	27.46/0.889 9	29.92/0.901 1	36.12/0.965 1	29.64/0.933 9	28.99/0.921 4	30.43/0.922 3
LFSSR ^[14]	4	28.27/0.908 0	30.72/0.912 4	36.70/0.969 0	30.31/0.944 6	30.15/0.938 5	31.23/0.934 5
LF-Internet ^[18]	4	28.67/0.914 3	30.98/0.916 5	37.11/0.971 5	30.64/0.948 6	30.53/0.942 6	31.59/0.938 7
LF-DFnet ^[15]	4	28.77/0.916 5	31.23/0.919 6	37.32/0.971 8	30.83/0.950 3	31.15/0.949 4	31.86/0.941 5
DPT ^[16]	4	28.93/0.916 7	31.19/0.918 6	37.39/0.972 0	30.96/0.950 2	31.14/0.948 7	31.92/0.941 2
LF-Inet ^[17]	4	29.11/0.919 4	31.36/0.921 1	37.62/0.973 7	31.08/0.951 6	31.21/0.949 5	32.08/0.943 1
DistgSSR ^[19]	4	28.99/0.919 5	31.38/0.921 7	37.56/0.973 2	30.99/0.951 9	31.65/0.953 5	32.11/0.944 0
本文算法	4	29.24/0.921 3	31.54/0.923 4	37.75/0.974 0	31.32/0.953 2	31.68/0.953 9	32.31/0.945 2

注:蓝色加粗字体表示每列的最优值,黑色加粗字体表示每列的次优值,加下划线字体表示本文算法。

前增加了SFEM进一步增强了网络特征挖掘能力;在数据重构部分,交替使用6组MSR块和CA块来融合不同层次的特征,最终造成整体参数量、FLOPs增加。从运行时间看,由于本文设计的FAIM和SFEM均使用并行结构,使网络的运算速度有所提高,最终,在使网络结构复杂度增加的情况下,未明显增加运行时间。因此,本文算法在合理控制复杂度的前提下,使PSNR和SSIM取得了最高值,实现了最佳的超分性能。

3.2.5 算法精度与复杂度整体评价

从算法精度和复杂度2个方面综合评价本文算法的性能,以PSNR值为横坐标,SSIM值为纵坐标分别绘制了2倍超分任务下和4倍超分任务下的气泡图,如图5和图6所示。其中,气泡的大小反映了算法的复杂度。从图5和图6可以看出,本文算法在合理控制气泡大小的情况下,取得了最佳超分效果。

3.3 消融实验

为了验证本文搭建的网络各部分的有效性与合理性,从3个角度进行了消融实验:(1)在保持网络模型大小差异不大的前提下,将本文设计的模块用其他模块替代;(2)在基准网络基础上,逐步增加本文设计的各个模块;(3)基于本文所提网络框架,不断改变FAIM和

MSR模块数量。所有实验均在4倍超分任务下进行,实验结果如表4~表7所示。

3.3.1 各模块被替代

首先,验证浅层特征提取中3支路结构与PRB的有效性。用双支路替代3支路结构,即去掉网络的C-PRB支路,仅使用L-PRB和A-PRB提取浅层特征。对比表4的第1行与最后1行,可见,基于浅层3支路结构的PSNR和SSIM值高于双支路结构,验证了中心孔径图像特征作为角度特征的补充特征有利于提高超分性能。用文献[15~17]使用的ResASPP+ResBlock模块替代PRB,为了保证替代前后参数量变化不大,采用了2组ResASPP+ResBlock,对比表4的第2行与最后1行,可见,使用PRB模块的网络的PSNR值比使用ResASPP+ResBlock模块的网络的PSNR值高0.05 dB,论证了PRB模块设计的有效性。

其次,验证深层特征提取中FAIM、SFIM及SFEM的有效性。用IntraFUM^[17]替代FAIM,实验结果如表4第3行所示,与最后1行对比后可见,在特征交互前增加空间特征强化过程可有效提高网络超分性能。用无自注意力的SFIM替代SFIM,实验结果如表4第4行所示,与最后1行对比后可见,自注意力的引入有利于提高有效特征的




图4 4倍超分任务下5×5孔径图像PSNR值分布的可视化

表3 不同算法的复杂度对比

方法	2倍				4倍			
	#Params/M	FLOPs/G	运行时间/s	PSNR/SSIM	#Params/M	FLOPs/G	运行时间/s	PSNR/SSIM
EDSR ^[27]	38.62	39.56×25	0.44	36.04/0.972 8	38.89	40.66×25	0.29	30.20/0.912 1
RCAN ^[28]	15.3	15.59×25	13.10	36.11/0.974 1	15.36	15.65×25	3.54	30.27/0.913 3
ResLF ^[20]	6.35	37.06	2.95	36.58/0.979 3	6.79	39.70	0.95	30.43/0.922 3
LFSSR ^[14]	0.81	25.70	0.21	37.53/0.983 5	1.61	128.44	0.16	31.23/0.934 5
LF-Internet ^[18]	4.80	47.46	1.45	38.08/0.984 7	5.23	50.10	0.47	31.59/0.938 7
LF-DFnet ^[15]	3.94	57.22	1.73	38.42/0.985 4	3.99	57.31	0.55	31.86/0.941 5
DPT ^[16]	3.73	57.44	7.56	38.41/0.984 9	3.78	58.64	2.06	31.92/0.941 2
LF-IInet ^[17]	4.84	56.16	0.55	38.74/0.985 9	4.89	57.42	0.21	32.08/0.943 1
DistgSSR ^[19]	3.53	64.11	1.55	38.94/0.986 6	3.58	65.41	0.46	32.11/0.944 0
本文算法	6.19	105.11	3.50	38.98/0.986 5	6.23	106.38	1.28	32.31/0.945 2

注:蓝色加粗字体表示每列的最优值,黑色加粗字体表示每列的次优值,加下划线字体表示本文算法。

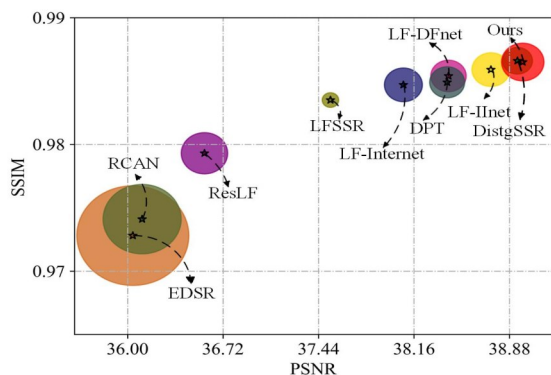


图5 2倍超分任务下不同算法的PSNR、SSIM值与参数量对比

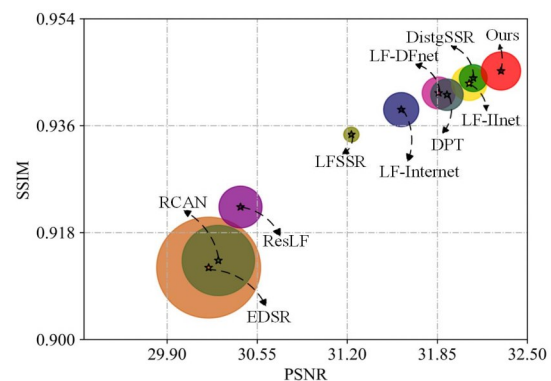


图6 4倍超分任务下不同算法的PSNR、SSIM值与参数量对比

提取.使用3DResASPP^[17,29]替代SFEM,实验结果如表4第5行所示,可见,采用SFEM的网络PSNR值略高.FAIM、SFIM及SFEM的有效性得以验证.

最后,验证重构部分MSR模块的有效性.使用ResBlock模块替代MSR模块,为保证参数量变化不大,使用8组ResBlock.对比表4的第6行与最后1行,可

见,使用 ResBlock 的网络的 PSNR、SSIM 值均低于使用 MSR 的网络,验证了 MSR 模块的有效性.

3.3.2 逐步增加各模块

根据现有光场图像超分领域的文献[15~19],搭建了基准网络,在基准方法基础上逐步增加本文设计的各网络模块,分析网络性能.基准网络的浅层特征提取部分使用 LF-DFnet^[15]和 LF-IIInet^[17]中的 ResASPP+ResBlock 结构;深层特征提取部分,级联 4 组空间特征更新模块(Spatial Feature Update Module, SFUM)和角度特征更新模块(Angular Feature Update Module, AFUM)来实现空间、角度信息的交互,其中 SFUM 将角度特征与每个视角下的空间特征通道拼接,再通过 2 个 1×1 卷积来实现空间特征更新,AFUM 将更新后的空间特征通过 Reshape 操作

与角度特征通道拼接来实现角度特征更新;数据重构部分,特征融合模块使用 LF-DFnet 中 IMDB 模块.基准网络的结构图如图 7 所示,对应性能如表 5 中方案 1 所示.

为验证 PRB 模块的有效性,将基准网络中浅层特征提取模块替换为 PRB 模块,对应的性能如表 5 中方案 2 所示.在此基础上,增加中心孔径图像特征提取的支路,对应的性能如表 5 中方案 3 所示.在深层特征提取部分依次增加 FAIM、SFIM 和 SFEM,对应的性能如表 5 中方案 4~方案 6 所示.在数据重构部分,使用所设计的 MSR+CA 模块替换基准方法中 IMDB 模块,对应的性能如表 5 中方案 7 所示.从表 5 中可以看出,逐步增加各个模块后,网络的性能也逐步提升,进一步验证了本文所提各模块的有效性.

表 4 网络各部分有效性验证

模型	#Params /M	FLOPs /G	数据集					平均
			EPFL	HCInew	HCIdld	INRIA	STFgantry	
双支路替代 3 支路	6.19	106.31	29.12/0.921 5	31.54/0.923 4	37.71/0.973 8	31.17/0.953 1	31.57/0.952 7	32.22/0.944 9
ResASPP+ResBlock 替代 PRB	6.40	107.37	29.27/0.921 9	31.50/0.923 3	37.70/0.973 9	31.28/0.953 2	31.57/0.953 1	32.26/0.945 1
IntraFUM 替代 FAIM	5.89	93.59	29.05/0.920 8	31.51/0.922 8	37.61/0.973 3	31.10/0.952 7	31.34/0.950 4	32.12/0.944 0
无自注意力 SFIM 替代 SFIM	6.23	106.37	29.22/0.921 5	31.50/0.922 7	37.70/0.973 8	31.29/0.953 1	31.53/0.952 7	32.25/0.944 8
3DResASPP 替代 SFEM	6.85	112.04	29.19/0.922 1	31.57/0.923 2	37.86/0.974 5	31.12/0.953 2	31.64/0.953 2	32.28/0.945 2
ResBlock 替代 MSR	6.34	108.90	29.05/0.921 3	31.49/0.922 9	37.63/0.973 5	31.06/0.953 0	31.46/0.952 6	32.14/0.944 7
本文算法	6.23	106.38	29.24/0.921 3	31.54/0.923 4	37.75/0.974 0	31.32/0.953 2	31.68/0.953 9	32.31/0.945 2

注:蓝色加粗字体表示每列的最优值,黑色加粗字体表示每列的次优值,加下划线字体表示本文算法.

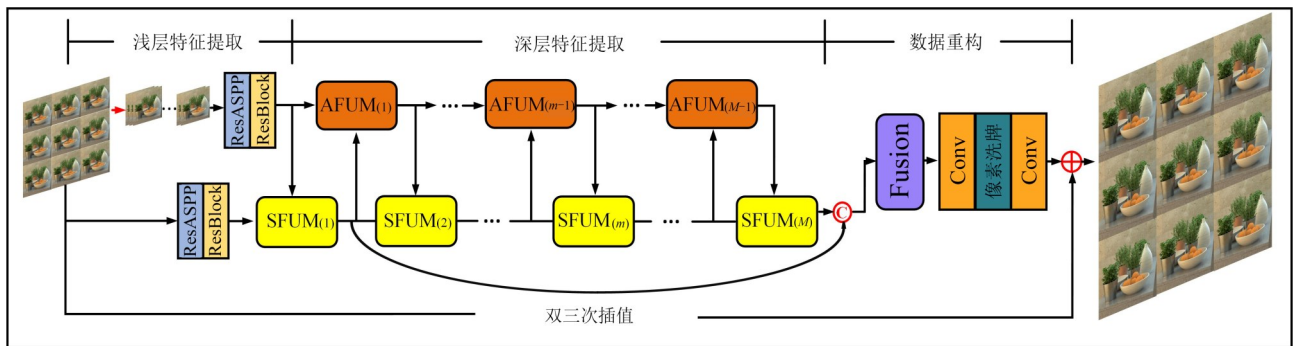


图 7 基准网络的结构图

3.3.3 FAIM 和 MSR 模块数量优化

为验证本文算法中 FAIM 和 MSR 模块数量对网络性能的影响,本文研究了 4 倍超分任务下不同 FAIM 和 MSR 数量对网络复杂度和性能的影响,如表 6 和表 7 所示.为了直观地看出网络精度、复杂度和 FAIM、MSR 数量之间的关系,绘制了 PSNR、网络参数量随 FAIM、MSR 数量增加的折线图和 SSIM、FLOPs 随 FAIM、MSR 数量增加的折线图,如图 8 和图 9 所示.从图 8 可以看出,随着 FAIM 个数增加,PSNR 和 SSIM 值急剧增加,但

在 4 以后基本保持不变,而 FLOPs 值和参数量一直呈上升趋势.从图 9 中可以看出,随着 MSR 个数的增加,PSNR 和 SSIM 值急剧增加,但在 6 以后增加明显减缓,而 FLOPs 值和参数量一直呈上升趋势.因此,为了平衡超分性能和计算复杂度,本文采用 4 个 FAIM 模块($M=4$)和 6 个 MSR 模块.

4 结论

本文提出了基于穿插特征更新的光场图像超分网

表 5 逐步增加各模块后算法性能比较实验

方案	浅层特征提取		深层特征提取			数据重构	#Params/M	FLOPs/G	平均
	PRB	3支路结构	FAIM	SFIM	SFEM	MSR+CA			PSNR/SSIM
方案1	—	—	—	—	—	—	4.45	47.96	31.93/0.941 7
方案2	√	—	—	—	—	—	4.46	48.53	32.01/0.942 5
方案3	√	√	—	—	—	—	4.50	48.60	32.02/0.942 8
方案4	√	√	√	—	—	—	4.85	61.39	32.12/0.943 9
方案5	√	√	√	√	—	—	4.86	61.39	32.17/0.944 3
方案6	√	√	√	√	√	—	5.02	75.65	32.21/0.944 1
方案7	√	√	√	√	√	√	6.23	106.38	32.31/0.945 2

注:蓝色加粗字体表示每列的最优值,黑色加粗字体表示每列的次优值,加下划线字体表示本文算法。

表 6 4倍超分任务下不同FAIM个数对网络性能及复杂度的影响

FAIM数量	#Params/M	FLOPs/G	数据集					平均
			EPFL	HCInew	HCold	INRIA	STFgantry	PSNR/SSIM
1	3.50	14.23	28.65/0.910 3	30.82/0.913 8	36.85/0.969 5	30.67/0.947 3	30.28/0.939 4	31.45/0.936 1
2	4.05	35.83	28.98/0.918 1	31.30/0.920 3	37.44/0.972 6	31.05/0.951 2	31.30/0.950 6	32.01/0.942 6
3	4.96	66.56	29.20/0.921 2	31.50/0.922 9	37.58/0.973 4	31.21/0.953 0	31.47/0.953 1	32.19/0.944 7
<u>4</u>	<u>6.23</u>	<u>106.38</u>	<u>29.24/0.921 3</u>	<u>31.54/0.923 4</u>	<u>37.75/0.974 0</u>	<u>31.32/0.953 2</u>	<u>31.68/0.953 9</u>	<u>32.31/0.945 2</u>
5	8.66	155.35	29.23/0.922 1	31.60/0.924 0	37.75/0.974 0	31.27/0.953 5	31.65/0.953 9	32.30/0.945 5
6	11.45	213.45	29.27/0.922 4	31.62/0.924 2	37.77/0.974 1	31.26/0.953 3	31.64/0.953 0	32.31/0.945 4

注:蓝色加粗字体表示每列的最优值,黑色加粗字体表示每列的次优值,加下划线字体表示本文算法。

表 7 4倍超分任务下不同MSR个数对网络性能及复杂度的影响

MSR数量	#Params/M	FLOPs/G	数据集					平均
			EPFL	HCInew	HCold	INRIA	STFgantry	PSNR/SSIM
2	4.32	57.72	29.04/0.919 9	31.36/0.921 4	37.60/0.973 3	30.99/0.951 9	31.25/0.950 9	32.05/0.943 5
4	5.28	82.05	29.23/0.920 8	31.46/0.922 1	37.69/0.973 8	31.20/0.952 4	31.43/0.951 1	32.20/0.944 0
<u>6</u>	<u>6.23</u>	<u>106.38</u>	<u>29.24/0.921 3</u>	<u>31.54/0.923 4</u>	<u>37.75/0.974 0</u>	<u>31.32/0.953 2</u>	<u>31.68/0.953 9</u>	<u>32.31/0.945 2</u>
8	7.19	130.71	29.26/0.922 1	31.54/0.923 5	37.86/0.974 4	31.32/0.953 5	31.63/0.953 1	32.32/0.945 3

注:蓝色加粗字体表示每列的最优值,黑色加粗字体表示每列的次优值,加下划线字体表示本文算法。

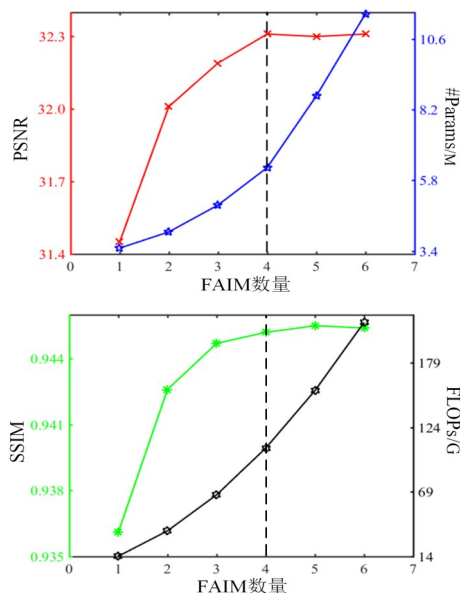


图 8 FAIM个数的最优选择

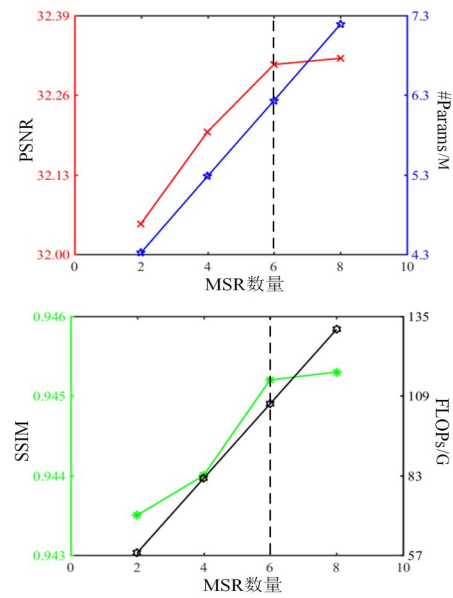


图 9 MSR个数的最优选择

络,旨在提高子孔径图像阵列的空间分辨率.网络浅层特征提取设计了3条支路,充分挖掘了空间特征和角度特征.深层特征提取部分采用穿插特征更新机制,设计了FAIM和SFIM来实现空间特征与角度特征的融合与更新.为了充分挖掘单个子孔径图像内潜在的空间信息,将更新后的空间特征再送入SFEM进行了特征强化.数据重构部分采用6组交替的MSR和CA来融合提取多层次信息.在5个公共光场数据集上,本文搭建的网络在4倍超分任务下的平均PSNR和SSIM值分别达到32.31 dB和0.945 2.本文所提网络在合理控制复杂度的前提下,较现有网络实现了更好的超分性能.对比实验验证了所提网络的优越性:与其他光场超分网络相比,本文所提网络在大视差数据集上表现最好,且在主观视觉上得到了最为清晰的高分辨率图像.通过消融实验,本文所提网络中各个模块的有效性得到了验证.

参考文献


- [1] TAO M W, HADAP S, MALIK J, et al. Depth from combining defocus and correspondence using light-field cameras[C]//2013 IEEE International Conference on Computer Vision. Piscataway: IEEE, 2013: 673-680.
- [2] LIU M D, WU R F, LUO Z C, et al. Fast digital refocusing Fourier ptychographic microscopy method based on convolutional neural network[J]. Optics Express, 2024, 32(1): 339-354.
- [3] WANG Y Q, YANG J G, GUO Y L, et al. Selective light field refocusing for camera arrays using bokeh rendering and superresolution[J]. IEEE Signal Processing Letters, 2019, 26(1): 204-208.
- [4] WU G C, MASIA B, JARABO A, et al. Light field image processing: An overview[J]. IEEE Journal of Selected Topics in Signal Processing, 2017, 11(7): 926-954.
- [5] 武迎春, 王玉梅, 王安红, 等. 基于边缘增强引导滤波的光场全聚焦图像融合[J]. 电子与信息学报, 2020, 42(9): 2293-2301.
WU Y C, WANG Y M, WANG A H, et al. Light field all-in-focus image fusion based on edge enhanced guided filtering[J]. Journal of Electronics & Information Technology, 2020, 42(9): 2293-2301. (in Chinese)
- [6] TIAN C R, PAN W H, WANG Z M, et al. DPS-net: Deep polarimetric stereo depth estimation[C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2023: 3546-3556.
- [7] 刘玉轩, 张力, 艾海滨, 等. 光场相机三维重建研究进展与展望[J]. 电子学报, 2022, 50(7): 1774-1792.
- LIU Y X, ZHANG L, AI H B, et al. Progress and prospect of 3D reconstruction based on light field cameras[J]. Acta Electronica Sinica, 2022, 50(7): 1774-1792. (in Chinese)
- [8] 周晓清, 王翔, 郑锦, 等. 基于自适应空间稀疏化的高效多视图立体匹配[J]. 电子学报, 2023, 51(11): 3079-3091.
ZHOU X Q, WANG X, ZHENG J, et al. Adaptive spatial sparsification for efficient multi-view stereo matching[J]. Acta Electronica Sinica, 2023, 51(11): 3079-3091. (in Chinese)
- [9] LAN R S, SUN L, LIU Z B, et al. MADNet: A fast and lightweight network for single-image super resolution[J]. IEEE Transactions on Cybernetics, 2021, 51(3): 1443-1453.
- [10] CHEN H G, HE X H, QING L B, et al. Real-world single image super-resolution: A brief review[J]. Information Fusion, 2022, 79: 124-145.
- [11] CHEN Y T, LIU L W, PHONEVILAY V, et al. Image super-resolution reconstruction based on feature map attention mechanism[J]. Applied Intelligence, 2021, 51(7): 4367-4380.
- [12] CHEN Z, ZHANG Y L, GU J J, et al. Dual aggregation transformer for image super-resolution[C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2023: 12278-12287.
- [13] YOON Y, JEON H G, YOO D, et al. Light-field image super-resolution using convolutional neural network[J]. IEEE Signal Processing Letters, 2017, 24(6): 848-852.
- [14] YEUNG H W F, HOU J H, CHEN X M, et al. Light field spatial super-resolution using deep efficient spatial-angular separable convolution[J]. IEEE Transactions on Image Processing, 2018, 28(5): 2319-2330.
- [15] WANG Y Q, YANG J G, WANG L G, et al. Light field image super-resolution using deformable convolution[J]. IEEE Transactions on Image Processing, 2021, 30: 1057-1071.
- [16] WANG S Z, ZHOU T F, LU Y, et al. Detail-preserving transformer for light field image super-resolution[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36(3): 2522-2530.
- [17] LIU G S, YUE H J, WU J M, et al. Intra-inter view interaction network for light field image super-resolution[J]. IEEE Transactions on Multimedia, 2021, 25: 256-266.
- [18] WANG Y Q, WANG L G, YANG J G, et al. Spatial-angular interaction for light field image super-resolution [M]//Lecture Notes in Computer Science. Cham: Springer International Publishing, 2020: 290-308.

- [19] WANG Y Q, WANG L G, WU G C, et al. Disentangling light fields for super-resolution and disparity estimation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(1): 425-443.
- [20] ZHANG S, LIN Y F, SHENG H. Residual networks for light field image super-resolution[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2019: 11038-11047.
- [21] ZHANG S, CHANG S, LIN Y F. End-to-end light field spatial super-resolution network using multiple epipolar geometry[J]. IEEE Transactions on Image Processing, 2021, 30: 5956-5968.
- [22] HONAUER K, JOHANNSEN O, KONDERMANN D, et al. A dataset and evaluation methodology for depth estimation on 4D light fields[M]//Lecture Notes in Computer Science. Cham: Springer International Publishing, 2017: 19-34.
- [23] WANNER S, MEISTER S, GOLDLÜCKE B. Datasets and benchmarks for densely sampled 4D light fields[C]//International Symposium on Vision, Modeling, and Visualization. Switzerland: Computer Graphics Forum, 2013: 1-8.
- [24] RERÁBEK M, EBRAHIMI T. New light field image dataset[C]//8th International Conference on Quality of Multimedia Experience. Lisbon: Multimedia Signal Processing Laboratory Press 2016: 1-2.
- [25] LE PENDU M, JIANG X R, GUILLEMOT C. Light field inpainting propagation via low rank matrix completion[J]. IEEE Transactions on Image Processing, 2018, 27(4): 1981-1993.
- [26] VAISH V, ADAMS A. The (new) stanford light field archive[EB/OL]. (2008-06-07) [2023-12-20]. <http://light-field.stanford.edu/>.
- [27] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Piscataway: IEEE, 2017: 1132-1140.
- [28] ZHANG Y L, LI K P, LI K, et al. Image super-resolution using very deep residual channel attention networks[M]//Lecture Notes in Computer Science. Cham: Springer International Publishing, 2018: 294-310.
- [29] LIU G S, YUE H J, WU J M, et al. Efficient light field angular super-resolution with sub-aperture feature learning and macro-pixel upsampling[J]. IEEE Transactions on Multimedia, 2022, 25: 6588-6600.

作者简介



陈佳妮 女, 1999年8月出生, 山西运城人. 太原科技大学硕士研究生. 主要研究方向为光场信息的获取与处理.
E-mail: 1519374568@qq.com




武迎春 女, 1984年1月出生, 山西朔州人. 太原科技大学教授, 硕士生导师. 主要研究方向为3D数据获取与处理、光场信息获取与处理.
E-mail: yingchunwu3030@tyust.edu.cn



吕天琪 女, 1996年3月出生, 河北保定人. 太原科技大学硕士研究生. 主要研究方向为光场信息获取与处理.
E-mail: 2502632776@qq.com



刘丽 女, 1978年10月出生, 宁夏吴忠人. 太原科技大学副教授, 硕士生导师. 主要研究方向为多媒体数据安全、信息隐藏. 中国电子学会会员编号: E190161621M.
E-mail: liliu@tyust.edu.cn



赵贤凌 女, 1978年12月出生, 山西长治人. 太原科技大学副教授. 主要研究方向为3D数据获取与处理.
E-mail: zhaoxl@tyust.edu.cn