

光电工程

Opto-Electronic Engineering

中文核心期刊 中国科技核心期刊
Scopus CSCD

基于双路引导更新的光场图像超分网络

黄莉, 吕天琪, 武迎春, 陈佳妮

引用本文:

黄莉, 吕天琪, 武迎春, 等. 基于双路引导更新的光场图像超分网络[J]. *光电工程*, 2024, 51(12): 240222.

Huang L, Lv T Q, Wu Y C, et al. Two-way guided updating network for light field image super-resolution[J]. *Opto-Electron Eng*, 2024, 51(12): 240222.

<https://doi.org/10.12086/oe.2024.240222>

收稿日期: 2024-09-18; 修改日期: 2024-11-23; 录用日期: 2024-12-03

相关论文

角度差异强化的光场图像超分网络

吕天琪, 武迎春, 赵贤凌

光电工程 2023, 50(2): 220185 doi: 10.12086/oe.2023.220185

联合空角信息的无参考光场图像质量评价

王斌, 白永强, 朱仲杰, 郁梅, 蒋刚毅

光电工程 2024, 51(9): 240139 doi: 10.12086/oe.2024.240139

LF-UMTI: 基于多尺度空角交互的无监督多曝光光场图像融合

李玉龙, 陈晔曜, 崔跃利, 郁梅

光电工程 2024, 51(6): 240093 doi: 10.12086/oe.2024.240093

更多相关论文见光电期刊集群网站 



<http://cn.ojournal.org/oe>



 OE_Journal




Website



DOI: 10.12086/oe.2024.240222

CSTR: 32245.14.oe.2024.240222

基于双路引导更新的光场图像超分网络

黄莉¹, 吕天琪^{1,2}, 武迎春^{1*}, 陈佳妮¹¹太原科技大学电子信息工程学院, 山西 太原 030024;²河北工程技术学院网络与通信学院, 河北 石家庄 050091

摘要: 基于双平面模型的四维光场表示形式, 光场相机以牺牲图像空间分辨率为代价, 实现了三维场景空间信息和角度信息的同步记录。为了提高光场图像的空间分辨率, 本文搭建了基于双路引导更新机制的光场图像超分辨率重建网络。网络前端以不同形式的图像阵列为输入, 构建残差串并联卷积实现了空间、角度信息解耦合。针对解耦合后的空间、角度信息, 设计了双路引导更新模块, 采用逐级增强、融合、再增强的方式, 完成空间信息与角度信息的交互引导迭代更新。最后将逐级更新后的角度信息送入简化后的残差特征蒸馏模块, 实现数据重建。对比实验表明, 所提网络在有效控制复杂度的基础上, 获得了更好的超分性能。

关键词: 光场超分辨率重建; 空间特征; 角度特征; 双路引导更新; 残差特征蒸馏

中图分类号: TP391.4

文献标志码: A

黄莉, 吕天琪, 武迎春, 等. 基于双路引导更新的光场图像超分网络[J]. 光电工程, 2024, 51(12): 240222

Huang L, Lv T Q, Wu Y C, et al. Two-way guided updating network for light field image super-resolution[J]. *Opto-Electron Eng*, 2024, 51(12): 240222

Two-way guided updating network for light field image super-resolution

Huang Li¹, Lv Tianqi^{1,2}, Wu Yingchun^{1*}, Chen Jiani¹¹School of Electronic and Information Engineering, Taiyuan University of Science and Technology, Taiyuan, Shanxi 030024, China;²School of Network and Communication, Hebei University of Engineering Science, Shijiazhuang, Hebei 050091, China

Abstract: Based on the four-dimensional representation of the two-plane model, the light field camera captures spatial and angular information of the three-dimensional scene simultaneously at the expense of image spatial resolution. To improve the spatial resolution of light field images, a two-way guided updating network for light field image super-resolution is built in this work. In the front of the network, different forms of image arrays are used as inputs, and the residual series and parallel convolution are constructed to realize the decoupling of spatial and angular information. Aiming at the decoupled spatial information and angular information, a two-way guide updating module is designed, which adopts step-by-step enhancement, fusion, and re-enhancement methods to complete the interactive guidance iterative update of spatial and angular information. Finally, the step-by-step updated

收稿日期: 2024-09-18; 修回日期: 2024-11-23; 录用日期: 2024-12-03

基金项目: 国家自然科学基金青年科学基金项目 (61601318); 山西省专利转化计划项目 (202405009); 山西省自然科学研究面上项目 (202103021224278, 202103021224272)

*通信作者: 武迎春, yingchunwu3030@foxmail.com。

版权所有©2024 中国科学院光电技术研究所

angular information is sent to the simplified residual feature distillation module to realize data reconstruction. Many experimental results have confirmed that our proposed method achieves state-of-the-art performance while effectively controlling complexity.

Keywords: light field image super-resolution; spatial feature; angular feature; two-way guided updating; residual feature distillation

1 引言

基于光场双平面表示模型, 光场相机可以同步记录空间光线的位置信息与方向信息。光场相机捕获的光场原图经四维 (four-dimensional, 4D) 数据解码, 可得到子孔径图像阵列^[1]、多聚焦图像^[2]、宏像素图像阵列^[3], 这些图像在后期场景深度图估计^[4-6]、三维 (three-dimensional, 3D) 重建^[7-8]、目标检测^[9-11] 等任务中具有显著优势。受传感器单元加工工艺的限制, 光场相机在记录角度信息时以牺牲空间分辨率为代价, 为了提高光场图像的空间分辨率, 研究 4D 光场超分辨率重构 (超分) 技术具有重要意义^[12-22]。与传统二维 (two-dimensional, 2D) 图像实现空间信息超分相比, 光场超分需要同时考虑空间信息和角度信息^[12]。而 4D 光场包含的角度信息与空间信息存在高度耦合, 角度信息反映了不同子孔径图像之间的视差^[13], 空间信息包含每个子孔径图像的自身结构及纹理特征^[14]。因此, 近年来众多学者从光场空间、角度信息解耦出发, 设计了各类先进的深度学习网络, 从不同角度挖掘空间、角度信息完成光场超分^[19-22]。

侧重于角度信息的挖掘, 张硕等人^[15]将残差结构用于光场空间超分, 提出了残差光场超分 (residual networks for light field image super-resolution, ResLF) 网络, 该网络以水平、垂直和对角方向上堆叠的子孔径图像阵列为输入, 通过学习不同方向上子孔径图像阵列内在结构信息来实现高频信息的有效补充。Jin 等人^[16]提出了结合几何嵌入与结构一致性的光场超分 (light field spatial super-resolution via deep combinatorial geometry embedding and structural consistency regularization, LF-ATO) 网络, 该网络采用“两步走”策略, 首先利用多对一框架探索子孔径图像间的信息, 再通过结构一致性正则化模块探索空间、角度间相关性。王应谦等人^[13]将可变形卷积应用于光场, 提出了可变形卷积光场超分 (light field image super-resolution using deformable convolution, LF-DFnet) 网络, 处理光场图像超分中存在的视差问题。吕天琪等人^[17]提出

了角度差异强化的光场图像超分网络 (light field image super-resolution network based on angular difference enhancement, LF-ADNet), 该网络在 LF-DFnet 的基础上侧重于视图自身特征的学习。陈家豪等人^[18]提出了结合深度特征的光场图像超分网络 (light-field image super-resolution with depth feature by multiple-decouple and fusion module, LF-MDFnet), 该网络设计了多重解耦与融合模块来隐式地处理不同视图间的差异。

侧重于空间、角度联合特征的挖掘, Yeung 等人^[12]提出了空间、角度信息可分离的光场超分 (light field super-resolution using deep efficient spatial-angular separable convolution, LFSSR) 网络, 通过交替使用空间、角度卷积来提取光场空间、角度的联合特征, 在提高运算速度的同时提升了网络的性能。梁政宇等人^[19]提出了角度分辨率可变的光场超分 (angular-flexible network for light field image super-resolution, LF-AFnet) 网络, 通过将空间、角度特征提取器直接作用于子孔径图像阵列使得特征提取器具有角度灵活性, 实现了任意角度分辨率光场图像的超分。陆耀等人^[20]提出了细节保留 transformer 的光场超分 (detail-preserving transformer for light field image super-resolution, DPT) 网络, 该网络基于 transformer 将光场超分视为一个序列到序列的任务, 并通过空间角度局部增强的自关注层在每个序列内建立远程几何相关性, 从而很好地保留每个子孔径图像的局部细节特征。

与前两类算法相比, 分别提取空间、角度再进行多次交互^[21-23]是一种更为通用的深度学习网络框架。王应谦等人^[21]提出了空间、角度交互光场超分 (spatial-angular interaction for light field image super-resolution, LF-Internet) 网络, 该网络以宏像素图像为输入, 利用空洞率不同的空洞卷积来提取 4D 光场的空间特征与角度特征, 再将其反复交互融合得到高分辨率光场图像。岳焕景等人^[22]提出了视图内与视图间信息交互的光场图像超分 (intra-inter view interaction network for light field image super-resolution, LF-IlNet)

网络。该网络利用交互的机制, 挖掘了视图内与视图间的相关性, 并保持光场的视差结构。以这类网络框架为基础, 受引导滤波思想的启发^[24-25], 本文提出空间、角度信息双向引导更新网络 (two-way guided updating network for light field image super-resolution, LF-TGUnet)。本文的主要贡献总结如下:

1) 网络前端采用双支路结构, 每一支路利用空洞空间金字塔和残差思想, 基于串并联卷积块有效提取光场的空间特征和角度特征, 且每一幅子孔径的空间信息独立提取。

2) 设计了双向引导更新模块, 完成空间信息与角度信息的迭代更新, 信息更新过程中, 所有子孔径图像间的相关性被强化学习, 光场的视差结构也被更好的保留。

3) 在数据重构部分, 采用简化后的残差特征蒸馏模块, 降低网络复杂度的同时具有较好的性能。

2 双路引导更新网络

光场用 4D 张量 $L \in \mathbb{R}^{U \times V \times S \times T}$ 表示, 其中 $U \times V$ 代表 4D 光场的角度分辨率, $S \times T$ 代表光场的空间分辨

率。一般情况下, 光场超分网络以子孔径图像阵列和宏像素图像为输入^[12-22]。考虑到光场相机以牺牲空间分辨率为代价, 捕获了空间场景的角度信息。为了提高光场相机的空间分辨率, 本文提出一个基于双路引导更新的光场超分网络。

网络的整体结构如图 1(a) 所示, 网络以子孔径图像阵列为输入, 该阵列由 $U \times V$ 个子孔径图像组成。网络的整体构架可划分为空间信息与角度信息解耦合、空间、角度特征引导更新和数据重构三部分。在空间信息和角度信息解耦合过程中, 本文设计了空间特征提取 (spatial feature extraction, SE) 模块和角度特征提取 (angular feature extraction, AE) 模块, 分别用于提取每一个子孔径图像的固有特征和 4D 光场的整体视差结构。空间、角度特征引导更新部分由 K 个双向引导更新 (two-way guided updating, TGU) 模块级联组成, 在这部分所有子孔径图像间的相关性被充分提取, 用于进一步增强挖掘每个子孔径图像的固有特征与 4D 光场的整体视差结构。数据重构部分由融合模块和上采样模块构成, 它们逐步从网络中解码有效信息, 进而重构高分辨率子孔径图像阵列。

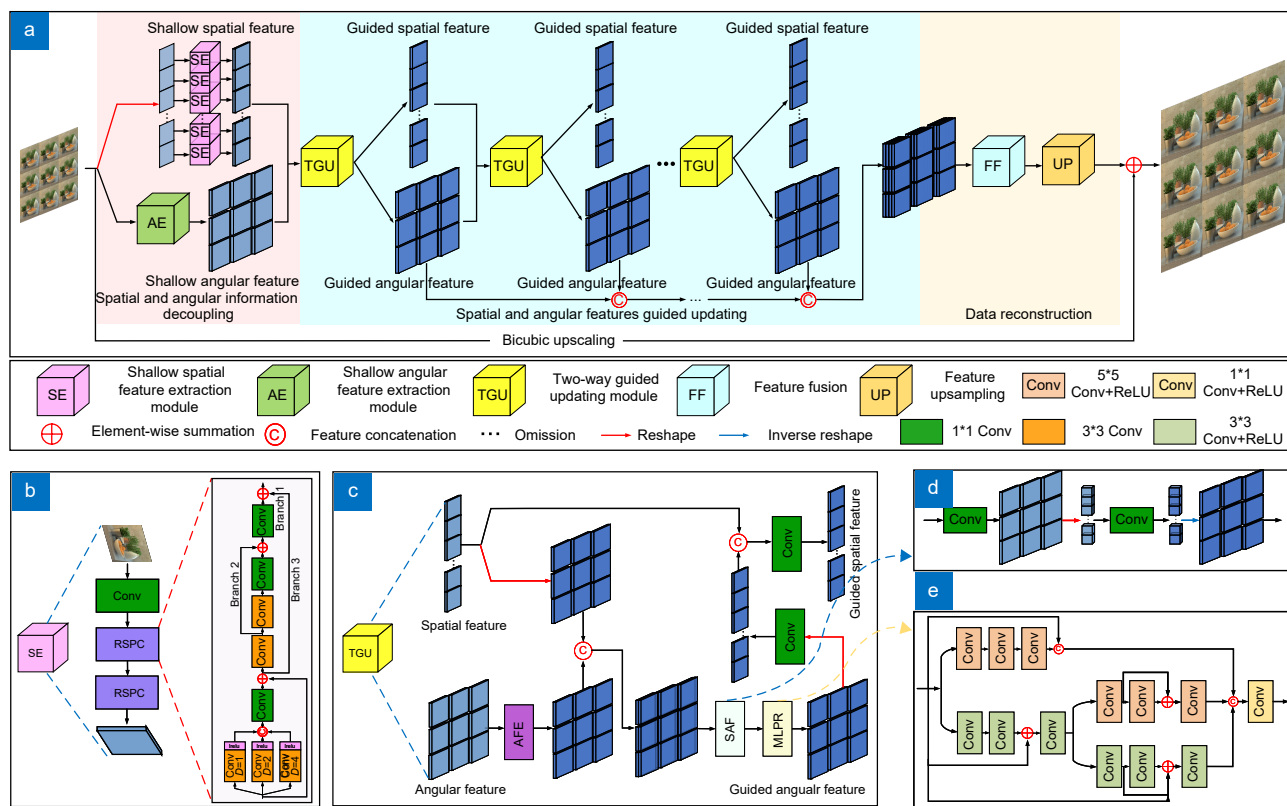


图 1 LF-TGUnet 结构图。(a) 整体网络结构图; (b) SE 模块; (c) TGU 模块; (d) SAF 模块; (e) MLPR 模块

Fig. 1 An overview of our diagram. (a) Overall network architecture diagram; (b) SE module; (c) TGU module; (d) SAF module; (e) MLPR module

2.1 空间信息与角度信息解耦合

由于空间信息与角度信息存在高度耦合, 在光场超分过程中先有效分离这些信息, 再进行特征分析与综合可有效提升网络性能, 因此在网络前端设计 1 个有效的特征提取模块来分离空间、角度信息至关重要。受文献 [13,22] 的启发, 不同膨胀率的空洞卷积并行使用 (即 Aspp 结构) 可以在稠密像素采样率下获得更大感受野。本文借鉴 Aspp 结构的思路, 并结合残差的优势, 设计了 1 个残差串并联卷积 (residual serial-parallel convolution, RSPC) 块, 用于空间信息与角度信息解耦合过程中不同层次的特征提取。RSPC 的细节如图 1(b) 所示。与文献 [13,22] 不同, 本文没有直接使用残差空洞空间金字塔池化+残差块 (ResAspp+ResBlock) 结构, 而是在 RSPC 中并联使用 3 个空洞率不同的空洞卷积, 用稠密采样率实现不同层次特征的挖掘, 同时级联了 3 个不同尺寸的普通卷积, 用于强化特征挖掘。为了防止网络退化, 引入了残差结构, 将不同深度的特征进行拼接。

在采用 SE 模块进行光场空间特征提取时, 每一幅子孔径图像先经过 1×1 卷积进行特征化, 然后馈入 2 个级联的 RSPC 块挖掘空间特征, 其设计的思想是交替使用不同卷积块的串并联结构与残差结构, 实现稠密采样率下强化特征挖掘。在角度特征提取时, AE 模块的结构与 SE 相同, 但 AE 的输入为子孔径图像阵列, 用于学习不同子孔径图像的差异信息。该差异也就是光场的整体视差结构, 它体现了光场固有的角度信息。

2.2 空间、角度特征引导更新

本文所提 LF-TGUnet 的交互机制借鉴了引导滤波图像融合的思想^[24-25], 将初始角度特征类比为被融合图像的基础层, 逐级更新后的角度特征类比为图像不同层次的细节层, 初始空间特征类比为图像基础层的权重, 逐级更新后的空间特征类比为图像各细节层的权重, 基础层与不同细节层加权平均得到最终融合信息。空间引导角度特征更新时, 将经增强模块的角度特征与重排后的空间特征对齐, 经空间、角度洗牌后, 再送入多层感知残差模块, 将空间信息融入角度特征。角度引导空间特征更新时, 将更新后的角度特征重排与空间信息对齐, 经卷积操作后, 将角度信息融入空间特征。具体操作如下:

设 SE 模块获取的空间特征为 SF_i^0 , 其中 $i \in 0, 1, 2, \dots, UV$, 一共有 $U \times V$ 个空间特征, AE 模块

获得的角度特征由 AF^0 表示。 AF^0 经角度特征增强 (angular feature enhancement, AFE) 模块后得到增强后的角度特征 AF_e^0 :

$$AF_e^0 = f_{SRconv}(f_{PRconv}(AF^0))_{\times 2}, \quad (1)$$

其中: f_{SRconv} 表示串联卷积的操作, f_{PRconv} 表示并联卷积的操作。

AFE 的结构与 RSPC 的结构类似, 其中并联卷积残差结构相同, 串联卷积残差结构的深度是 RSPC 模块的 2 倍。 $U \times V$ 个空间特征 SF_i^0 经阵列排列后, 得到阵列化特征 $SF_{U \times V}^0$, 其尺寸与增强后的角度特征相同。 $SF_{U \times V}^0$ 与增强后的角度特征 AF_e^0 进行通道拼接后, 送入空间角度特征融合 (spatial and angular feature fusion, SAF) 模块和多层感知残差 (multi-level perception residual, MLPR) 模块进行特征学习, 得到更新后的角度特征:

$$AF^1 = f_{MLPR}(f_{SAF}([SF_{U \times V}^0, AF_e^0])), \quad (2)$$

其中: $[\]$ 表示通道拼接, $f_{SAF}(\cdot)$ 和 $f_{MLPR}(\cdot)$ 分别表示 SAF 块和 MLPR 块的操作。 SAF 块和 MLPR 块的具体结构如图 1(d, e) 所示, SAF 块先对拼接后的特征使用 1×1 的卷积降低通道数, 然后通过反阵列排列、 1×1 卷积和阵列排列将角度特征和空间特征深度融合。 MLPR 块包含 2 条支路, 第 1 条支路先通过 3 个级联 3×3 卷积提取初级特征, 再通过 2 路不同尺度的并联卷积提取多尺度特征, 第 2 条支路级联 3 个 5×5 卷积提取初级特征, 将第 1 支路特征、第 2 支路特征和输入特征通道拼接再通过 1×1 卷积进一步生成多尺度特征, 实现多层次特征提取。

更新后的角度特征 AF^1 经反阵列排列后, 得到 $U \times V$ 个特征 AF_i^1 , AF_i^1 经 1×1 卷积特征提取后与 $U \times V$ 个原始空间 SF_i^0 特征进行拼接, 降维后得到更新后的空间特征 SF_i^1 。

$$SF_i^1 = f_{conv}([f_{conv}(AF_i^1), SF_i^0]), \quad (3)$$

其中: f_{conv} 表示 1×1 卷积的操作。

以上操作可看作一个输入为 SF_i^0, AF^0 , 输出为 SF_i^1, AF^1 的双输入双输出模块, 本文将其称之为双向引导更新 (TGU) 模块, 两路特征 (空间特征和角度特征) 经 K 个 TGU 引导更新后, 更新的特征可表示为

$$(SF_i^k, AF^k) = f_{TGU}(SF_i^{k-1}, AF^{k-1}), \quad k \in 0, 1, 2, \dots, K, \quad (4)$$

其中: $f_{TGU}(\cdot)$ 表示 TGU 块的操作, 其具体结构如图 1(c) 所示。

2.3 数据重构

数据重构一般由特征融合 (feature fusion, FF) 和特征上采样 (feature upsampling, UP) 两部分组成, 它们逐步将网络提取的有效信息解码成最终的高分辨率图像, 如文献 [22] 采用残差块+通道注意力结构。受文献 [13, 17] 的启发, 将蒸馏思想应用于数据重构可有效提升网络的性能。因此本文在特征融合部分, 设计了简化版的残差特征蒸馏 (simplified residual feature distillation, SRFD) 模块来融合 K 个 TGU 模块生成的层次特征。SRFD 模块的细节如图 2(a) 所示。SRFD 先通过卷积、激活操作对输入层次特征进行初步学习, 再将特征分 2 支路: 第 1 支路送入残差块进行特征保留, 将保留特征馈送到下一层的残差块和 1×1 卷积块进行新的特征保留和蒸馏操作, 第 2 支路送入 1×1 卷积块进行特征蒸馏, 最后将各级蒸馏特征沿通道维度拼接送入通道注意力模块, 实现有效信息的解码。残差块包含卷积、激活操作, 并使用残差连接将不同深度的特征进行拼接, 防止网络退化。考虑到网络的复杂度, SRFD 使用简单通道注意力模块替换残差特征蒸馏 (residual feature distillation, RFD) [26] 模块中的对比度感知通道注意力模块, 在提升网络性能的同时降低了网络的复杂度。RFD 模块的细节如图 2(b) 所示。

本文的上采样部分以融合后的特征为输入, 通过 2 个 1×1 卷积和像素洗牌操作 [17-22] 来提升光场图像的空间分辨率。融合数据先经过 1×1 卷积将特征沿通道维度进行扩展, 然后经过像素洗牌操作生成高分辨

率的重构特征, 最后经过 1×1 卷积压缩特征通道数, 得到高分辨率光场图像。

3 实验

3.1 视觉效果对比

实验所采用的数据集 [27-31] 以及处理细节与文献 [19-22] 相同。实验前期将图像的 RGB 通道转化为 YCbCr 通道, Y 通道使用本文所提网络进行超分, CbCr 通道用双三次插值进行超分, 三通道合成后生成最终超分图像 [19-22]。本文所提模型在 PyTorch 框架中实现, 采用 NVIDIA RTX 2080 TI GPU 进行训练, 训练过程中批尺寸设置为 8, 初始学习率设置为 2×10^{-4} , 每 15 个周期学习率降低一半。训练在 50 个周期后停止, 使用 ADAM 算法优化网络。

为了从视觉上直观看出本文所提的 LF-TGUnet 的优越性, 选取 2 种单图像超分算法 (EDSR [32]、RCAN [33]) 和 6 种光场图像超分算法 (ResLF [15]、LFSSR [12]、LF-Internet [21]、LF-DFnet [13]、LF-Ilnet [22] 和 DPT [20]) 与本文算法进行对比。不同算法的超分视觉效果如图 3、图 4 所示。为了增强对比效果, 将基础的双三次插值 (bicubic) 算法得到的超分图像、标准的高分辨率图像 (ground truth, GT) 也列入对比图。

图 3 显示了 HCInew [28] 数据集中, “Origima” 与 “Bicycle” 场景的 2 倍超分视觉效果对比。在 “Origima” 场景中, 对桶的局部进行了放大 (矩形框所框区域), 所提算法在椭圆框所框区域可以较清楚的恢复桶状物体的散乱圆点, 且产生伪影较少。在 “Bicycle” 场景

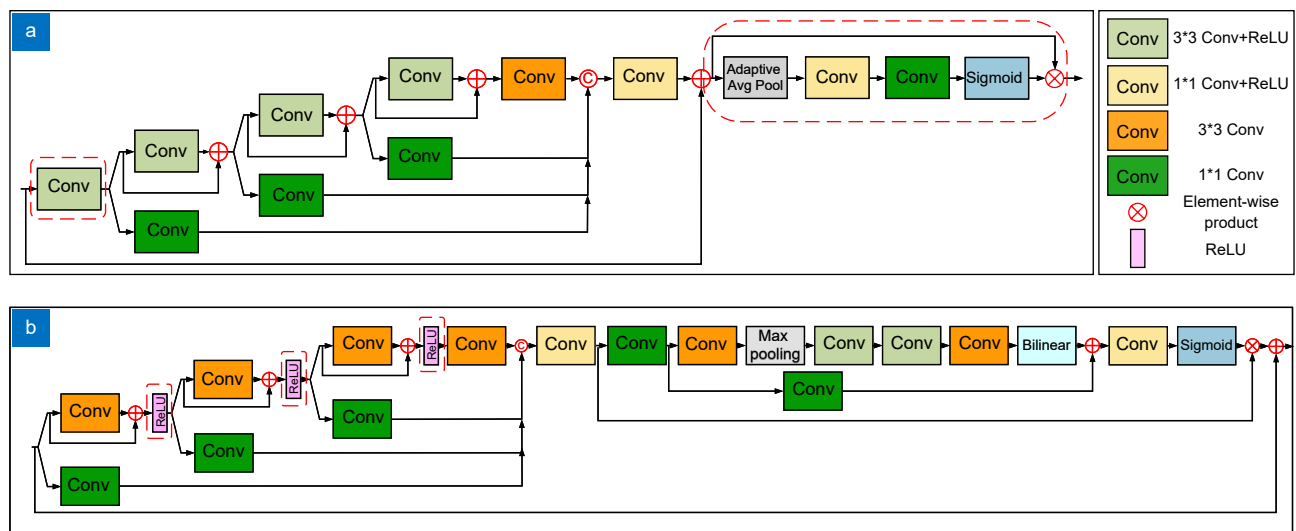


图 2 SRFD 与 FRD 对比。(a) SRFD 模块; (b) RFD 模块
Fig. 2 Comparison between SRFD and FRD. (a) SRFD module; (b) RFD module

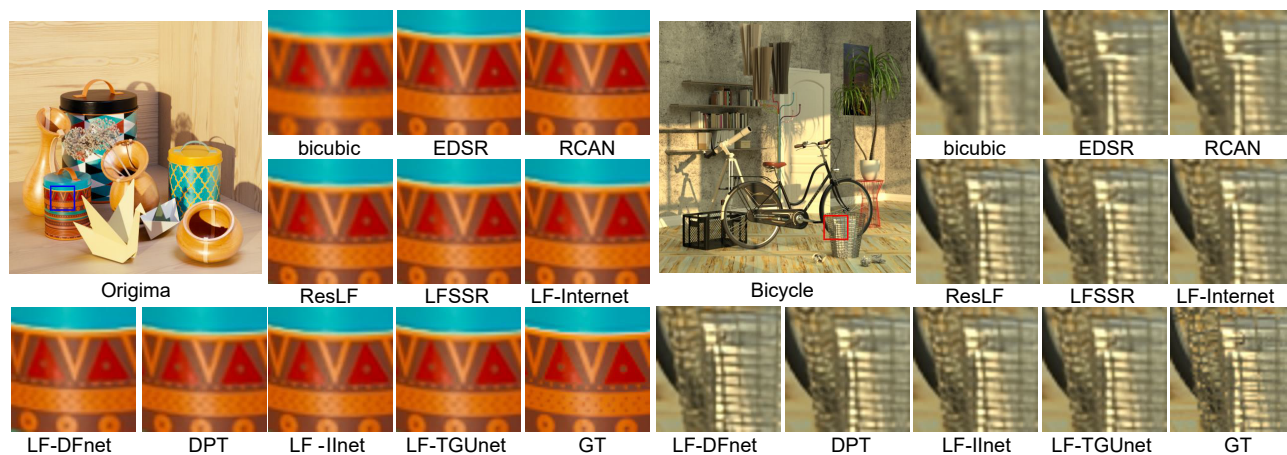


图3 “Origima”与“Bicycle”场景的2倍超分的视觉效果对比

Fig. 3 Visual results of the “Origima” and “Bicycle” scene with 2×SR

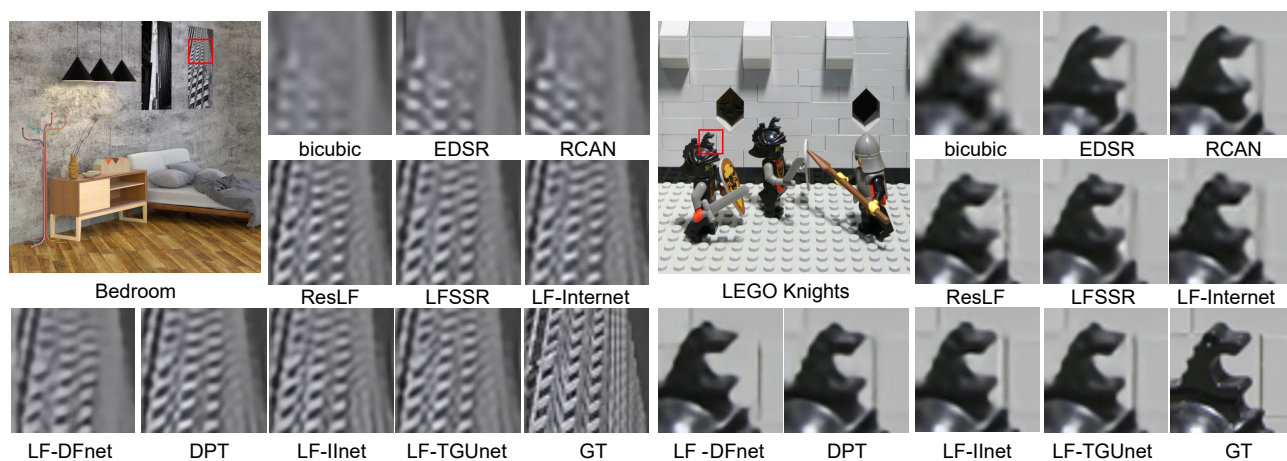


图4 “Bedroom”与“LEGO Knights”场景的4倍超分的视觉效果对比

Fig. 4 Visual results of the “Bedroom” and “LEGO Knights” scene with 4×SR

中, 对垃圾桶的局部区域进行了放大(矩形框所框区域), 所提算法在椭圆框所框区域恢复出来的网状结构较为清晰, 与标准高分辨率图像更为接近。证明了本文所提算法在进行光场2倍超分时表现出较好的效果。

图4显示了HCInew^[28]数据集的“Bedroom”场景与STFgantry^[31]数据集的“LEGO Knights”场景的4倍超分视觉效果对比。在“Bedroom”场景中, 对壁画的局部进行了放大(矩形框所框区域), 所提算法在椭圆框所框区域恢复出的黑白网格更为清晰, 与标准高分辨率图像最为接近。在“LEGO Knights”场景中, 对小人的头盔进行了放大(矩形框所框区域), 所提算法在椭圆框所框区域较好的恢复出头盔顶部的波浪形结构, 且伪影较少, 与标准高分辨率图像最为接近。证明了本文所提算法在进行光场4倍超分时表现出较好

的效果。

从总体上看, 双三次插值的效果最差, 原因在于双三次是最基础的传统算法。EDSR^[32]、RCAN^[33]算法获得的图像丢失了图像细节, 原因在于单图像超分只利用了光场的空间信息。ResLF^[15]、LFSSR^[12]和LF-DFnet^[13]算法在利用了空间信息的同时, 增加了角度信息利用, 使得超分效果有所提高。LF-Internet^[21]、LF-Ilnet^[22]采用了交互的框架, 进一步提升了网络性能。DPT^[20]引入了可以更好保留细节的transformer结构, 得到的超分图像质量更好。本文所提LF-TGUnet充分挖掘光场空间、角度特征, 采用双向引导结构不断更新特征, 获得了与标准图像最为接近的高分辨率图像。

3.2 整体性能定量评价

为了更为直观看出本文所提的LF-TGUnet超分

性能, 分别计算了不同超分任务下本文算法与对比算法得到超分图像在 5 个公共光场数据集上的 PSNR 值和 SSIM 值。不同超分任务下, 不同算法得到超分图像的 PSNR 值和 SSIM 值如表 1 所示。在表 1 中, 蓝色加粗数字和黑色加粗数字分别表示当前列的最优值和次优值, 加下划线的数字表示本文算法。从表 1 可以看出, 在 2 倍超分的性能上, 本文所提 LF-TGUnet 与 LF-Ilnet^[22]、LF-ADEnet^[17] 的整体性能相当, 并超越了其它算法。在 4 倍超分性能上, 本文所提 LF-TGUnet 在 HCInew^[28]、INRIA^[30]、STFgantry^[31] 数据集上性能优于先进的 LF-Ilnet, 且整体平均性能表现为最好。该实验进一步验证了本文所提 LF-TGUnet 超分性能的优越性。

3.3 超分后子孔径图像的 PSNR 值分布

光场超分网络以子孔径图像阵列为输入, 最后输

出超分后的子孔径图像阵列。为了定性评价各超分算法对不同视角子孔径图像的超分均衡性, 在 5 个公共光场数据集中, 分别选取一个测试场景, 对光场进行 2 倍超分后, 计算每一幅子孔径图像的 PSNR 值。实验过程中光场的角度分辨率为 5×5, 即每个场景包含 5×5 个子孔径图像, 根据 PSNR 值的大小对其进行可视化后并根据每个场景平均 PSNR 值绘制了柱状图, 不同算法在不同视角下的超分效果如图 5 所示。从图 5 可以看出, 本文所提 LF-TGUnet 在整体上获得了最佳的超分效果, 且超分性能在不同视角之间进行了很好的平衡。

3.4 算法复杂度对比

经过定量分析和主观视觉效果对比后, 进一步分析了本文所提 LF-TGUnet 的复杂度。在不同超分任务下, 将 LF-TGUnet 的参数量 (#Params)、浮点运算

表 1 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

Table 1 PSNR/SSIM values by different methods for 2×SR and 4×SR

Method	Scale	Dataset					Average
		EPFL	HCInew	HCold	INRIA	STFgantry	
bicubic	2×	29.74/0.9376	31.89/0.9356	37.69/0.9785	31.33/0.9577	31.06/0.9498	32.34/0.9518
EDSR ^[32]	2×	33.09/0.9631	34.83/0.9594	41.01/0.9875	34.97/0.9765	36.29/0.9819	36.04/0.9728
RCAN ^[33]	2×	33.16/0.9635	34.98/0.9602	41.05/0.9875	35.01/0.9769	36.33/0.9825	36.11/0.9741
ResLF ^[15]	2×	32.75/0.9672	36.07/0.9715	42.61/0.9922	34.57/0.9784	36.89/0.9873	36.58/0.9793
LFSSR ^[12]	2×	33.69/0.9748	36.86/0.9753	43.75/0.9939	35.27/0.9834	38.07/0.9902	37.53/0.9835
LF-Internet ^[21]	2×	34.14/0.9761	37.28/0.9769	44.45/0.9945	35.80/0.9846	38.72/0.9916	38.08/0.9847
LF-DFnet ^[20]	2×	34.44/0.9766	37.44/0.9786	44.23/0.9943	36.36/0.9841	39.61/0.9935	38.42/0.9854
LF-Ilnet ^[22]	2×	34.68/0.9771	37.74/0.9789	44.84/0.9948	36.57/0.9853	39.86/0.9935	38.74/0.9859
DPT ^[20]	2×	34.48/0.9759	37.35/0.9770	44.31/0.9943	36.40/0.9843	39.52/0.9928	38.41/0.9849
LF-ADEnet ^[17]	2×	34.58/0.9772	37.92/0.9796	44.84/0.9948	36.59/0.9854	40.11/0.9939	38.81/0.9862
LF-MDFnet ^[18]	2×	34.62/0.9844	37.37/0.9772	44.06/0.9823	36.23/0.9791	39.42/0.9923	38.34/0.9831
LF-TGUnet	2×	34.67/0.9776	37.80/0.9791	44.78/0.9948	36.46/0.9857	39.95/0.9936	38.73/0.9862
bicubic	4×	25.14/0.8324	27.61/0.8517	32.42/0.9344	26.82/0.8867	25.93/0.8452	27.58/0.8661
EDSR ^[32]	4×	27.84/0.8858	29.60/0.8874	35.18/0.9538	29.66/0.9259	28.70/0.9075	30.20/0.9121
RCAN ^[33]	4×	27.88/0.8863	29.63/0.8880	35.20/0.9540	29.76/0.9273	28.90/0.9110	30.27/0.9133
ResLF ^[15]	4×	27.46/0.8899	29.92/0.9011	36.12/0.9651	29.64/0.9339	28.99/0.9214	30.43/0.9223
LFSSR ^[12]	4×	28.27/0.9080	30.72/0.9124	36.70/0.9690	30.31/0.9446	30.15/0.9385	31.23/0.9345
LF-Internet ^[21]	4×	28.67/0.9143	30.98/0.9165	37.11/0.9715	30.64/0.9486	30.53/0.9426	31.59/0.9387
LF-DFnet ^[13]	4×	28.77/0.9165	31.23/0.9196	37.32/0.9718	30.83/0.9503	31.15/0.9494	31.86/0.9415
LF-Ilnet ^[22]	4×	29.11/0.9194	31.36/0.9211	37.62/0.9737	31.08/0.9516	31.21/0.9495	32.08/0.9431
DPT ^[20]	4×	28.93/0.9167	31.19/0.9186	37.39/0.9720	30.96/0.9502	31.14/0.9487	31.92/0.9412
LF-ADEnet ^[17]	4×	28.81/0.9190	31.30/0.9206	37.39/0.9725	30.81/0.9513	31.15/0.9494	31.86/0.9429
LF-MDFnet ^[18]	4×	28.70/0.9049	31.41/0.9146	37.42/0.9856	30.86/0.9521	30.86/0.9365	31.85/0.9387
LF-TGUnet	4×	28.96/0.9189	31.42/0.9215	37.63/0.9734	31.28/0.9529	31.36/0.9511	32.13/0.9436

次数 (FLOPs)、运行时间与其他算法进行了对比, 对比结果如表 2 所示。在表 2 中, 蓝色加粗数字和黑色加粗数字分别表示当前行的最优值和次优值, 加下划线的数字表示本文算法。从参数量来看, LF-TGUnet 的参数量较少, 与当前典型的超分网络参数量相当。从浮点运算次数和运行时间来看, LF-TGUnet 的计算复杂度与时间复杂度较高, 原因在于 LF-TGUnet 在空间、角度特征提取时、特征交互时, 较多使用了残差结构。与超分性能与复杂度均衡的 LF-IInet 相比, 本文所提算法的优点是参数量更小, 对设备内存有更低的要求; 超分性能更高, 得到的超分图像能满足更高的应用需求。不足在于, 本文所提算法 FLOPs 值较高、且运行时间较长, 降低了数据重建的实时性,

这一点我们将在后期研究中进一步提升。

3.5 消融实验

3.5.1 各模块有效性消融

为了验证本文所提 RSPC、TGU、MLPR、SRFD 模块的有效性, 进行了消融实验, 实验以 4 倍超分任务为例。由于 RSPC 设计的思想是交替使用不同卷积块的串并联结构与残差结构, 因此, 将 LF-TGUnet 中的 RSPC 用其 3 种变体: 没有并联卷积 (RSPC w/o parallel convolution)、没有串联卷积 (RSPC w/o series convolution)、没有残差结构 (RSPC w/o residual) 进行替代来证明 RSPC 结构设计的合理性。RSPC 的 3 种变体的结构如图 6(a, c) 所示, 对应网络性能如表 3 的 case 1~case 3 所示。在表 3 中, 蓝色加粗数字




图 5 2 倍超分任务下 5×5 子孔径图像 PSNR 值分布的可视化

Fig. 5 A visualization of PSNR distribution among different perspectives on 5×5 LFs for 2×SR

表 2 不同算法的参数量、每秒浮点运算次数与运行时间对比

Table 2 Comparisons of the number of parameters (#Params), FLOPs, and running time

Method	EDSR ^[32]	RCAN ^[33]	ResLF ^[15]	LFSSR ^[12]	LF-Internet ^[21]	LF-DFnet ^[13]	LF-IInet ^[22]	DPT ^[20]	LF-ADEnet ^[17]	LF-MDFnet ^[18]	LF-TGUnet
#Params/M	2× 38.62	15.31	6.35	0.81	4.80	3.94	4.84	3.73	12.74	5.37	<u>4.37</u>
	4× 38.89	15.36	6.79	1.61	5.23	3.99	4.89	3.78	12.80	5.42	<u>4.42</u>
FLOPs/G	2× 39.56×25	15.59×25	37.06	25.70	47.46	57.22	56.16	57.44	238.92	135.65	<u>78.84</u>
	4× 40.66×25	15.65×25	39.70	128.44	50.10	57.31	57.42	58.64	240.51	136.91	<u>80.11</u>
Running time	2×	0.44	13.10	2.95	0.21	1.45	1.73	0.55	7.56	4.85	<u>3.02</u>
/s	4×	0.29	3.54	0.95	0.16	0.47	0.55	0.21	2.06	1.75	<u>0.81</u>

和黑色加粗数字分别表示当前行的最优值和次优值, 加下划线的数字表示本文算法。TGU 结构的特点是双支路互相引导, 因此用基于空间信息收集的单支路 (half TGU) 结构替代, 证明双支路交互在特征挖掘中的有效性。单支路的 TGU 如图 6(d) 所示, 对应网络性能如表 3 的 case 4 所示。TGU 模块中 MLPR 的作用是提取不同层次的角度信息, 有效建模子孔径图像之间的相关性, 为了验证其有效性, 将 TGU 模块中 MLPR 块去掉 (TGU w/o MLPR), 用 3×3 卷积与 5×5 卷积级联替代, 对应网络性能如表 3 的 case 5 所示。最后, 将 SRFD 模块用 RFD (如图 2(b) 所示) 模块替代, 来验证 SRFD 模块的性能优势, 对应网络性能如表 3 的 case 6 所示。

通过分析表 3 可得, 本文所提算法框架在有效控制参数数量的同时, 获得了最高精度。空间信息与角度信息解耦合中 RSPC 块的串联、并联、残差结构均对

网络性能提升有贡献, 且残差结构的贡献最大。TGU 模块的双向引导结构对提升网络性能也有很大贡献。SRFD 模块与 FRD 模块相比, 很大程度降低了网络参数量, 网络性能并没有变差。

3.5.2 TGU 数量优化

为了验证本文所提网络 LF-TGUnet 中 TGU 模块的数量对网络性能的影响, 本文通过不断增加 TGU 的数量, 绘制了 PSNR、网络参数量随 TGU 个数增加的曲线图、SSIM、FLOPs 随 TGU 个数增加的曲线图, 如图 7 所示。从图 7(a) 的红色曲线可以看出, 随着 TGU 个数的增加, PSNR 值急剧增加, 但在 4 以后增加明显减缓。从蓝色曲线可以看出, 随着 TGU 个数的增加, 网络的参数量在 4 以前增加较为平缓, 但 4 以后急剧增加。说明网络选择 4 个 TGU 为最优选择。同时, 从图 7(b) 的绿色曲线可以看出, 随着 TGU 个数的增加, SSIM 值急剧增加, 但在 4 以后增




图 6 各个模块的变体。(a) RSPC 无并联卷积; (b) RSPC 无串联卷积; (c) RSPC 无残差结构; (d) 单支路 TGU

Fig. 6 Variations of each module. (a) RSPC w/o parallel convolution; (b) RSPC w/o series convolution; (c) RSPC w/o residual; (d) Half TGU

表 3 各模块的有效性验证

Table 3 Validity verification of each module

		Case 1	Case 2	Case 3	Case 4	Case 5	Case 6	Case 7 (LF-TGUnet)
Spatial and angular information decoupling	RPSC w/o parallel convolution	✓						
	RPSC w/o series convolution		✓					
	RPSC w/o residual			✓				
	RPSC				✓	✓	✓	✓
Spatial and angular features guided updating	half TGU				✓			
	TGU	✓	✓	✓		✓	✓	✓
	TGU w/o MLPR					✓		
	MLPR	✓	✓	✓	✓		✓	✓
Data reconstruction	RFD						✓	
	SRFD	✓	✓	✓	✓	✓		✓
#Params/M		4.30	4.34	4.42	4.46	4.41	5.70	4.42
Dataset	EPFL	28.83/0.9184	29.01/0.9196	25.26/0.8324	27.82/0.8856	28.87/0.9195	29.18/0.9175	28.96/0.9189
	HCInew	31.40/0.9214	31.40/0.9216	27.71/0.8517	29.64/0.8869	31.37/0.9212	31.23/0.9193	31.42/0.9215
	HCold	37.55/0.9730	37.57/0.9731	32.58/0.9344	35.12/0.9536	37.51/0.9732	37.30/0.9720	37.63/0.9734
	INRIA	30.89/0.9512	30.97/0.9516	26.95/0.8867	29.79/0.9264	31.02/0.9520	31.08/0.9505	31.28/0.9529
	STFgantry	31.35/0.9510	31.35/0.9511	26.09/0.8452	28.78/0.9091	31.29/0.9512	31.07/0.9486	31.36/0.9511
Average (PSNR/SSIM)		32.00/0.9430	32.06/0.9434	27.72/0.8701	30.23/0.9123	32.01/0.9434	31.97/0.9416	32.13/0.9436
Deviation		-0.13/-0.0006	-0.07/-0.0002	-4.41/-0.0735	-1.90/-0.0313	-0.12/-0.0002	-0.16/-0.0020	<u>0/0</u>




图 7 TGU 个数的最优选择。(a) PSNR、网络参数量随 TGU 个数增长的曲线;
(b) SSIM、FLOPs 随 TGU 个数增长的曲线

Fig. 7 Optimal selection of the number of TGUs. (a) PSNR and the number of parameters values increase with the number of TGUs;
(b) SSIM and FLOPs values increase with the number of TGUs

加明显减缓。从黑色曲线可以看出, 随着 TGU 个数的增加, FLOPs 值一直呈上升趋势, 进一步说明了网络采用 4 个 TGU 模块的合理性。

4 结论

为了提高光场图像的空间分辨率, 本文以光场子孔径图像阵列为输入, 设计了基于双路引导更新的光场超分网络。网络前端采用双支路残差串并联卷积结构实现了空间、角度信息的提取, 中间部分设计了双路引导更新模块, 通过空间、角度特征逐级强化、融合、再强化, 实现了空间信息与角度信息的迭代更新, 最后提出简化的残差特征蒸馏模块完成数据重建。视觉效果对比实验与定量评价结果验证了本文所提算法的优越性, 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 PSNR 值达到 32.13 dB, SSIM 值达到 0.9436, 较现有网络表现出更好的超分性能。消融实验验证了网络各模块的有效性与 TGU 个数设置的合理性。

参考文献

- [1] Van Duong V, Huu T N, Yim J, et al. Light field image super-resolution network via joint spatial-angular and epipolar information[J]. *IEEE Trans Comput Imaging*, 2023, **9**: 350–366.
- [2] Wang C C, Zang Y S, Zhou D M, et al. Robust multi-focus image fusion using focus property detection and deep image matting[J]. *Expert Syst Appl*, 2024, **237**: 121389.
- [3] Sakem A, Ibrahim H, Kang H S. Learning epipolar-spatial relationship for light field image super-resolution[C]// *Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, Vancouver, 2023: 1336–1345. <https://doi.org/10.1109/CVPRW59228.2023.00140>.
- [4] Cui Z L, Sheng H, Yang D, et al. Light field depth estimation for non-Lambertian objects via adaptive cross operator[J]. *IEEE Trans Circuits Syst Video Technol*, 2024, **34** (2): 1199–1211.
- [5] Chao W T, Wang X C, Wang Y Q, et al. Learning sub-pixel disparity distribution for light field depth estimation[J]. *IEEE Trans Comput Imaging*, 2023, **9**: 1126–1138.
- [6] Wang Y Q, Wang L G, Wu G C, et al. Disentangling light fields for super-resolution and disparity estimation[J]. *IEEE Trans Pattern Anal Mach Intell*, 2023, **45** (1): 425–443.
- [7] Ding Y Q, Chen Z, Ji Y, et al. Light field-based underwater 3D reconstruction via angular re-sampling[J]. *IEEE Trans Comput Imaging*, 2023, **9**: 881–893.
- [8] Zhang Z J, Wu Q Y, Deng Y F, et al. Structured light field 3-D imaging method based on Hough transform[J]. *Laser Technol*, 2023, **47** (4): 492–499. 张志俊, 吴庆阳, 邓亦锋, 等. 基于霍夫变换的结构光场 3 维成像方法[J]. *激光技术*, 2023, **47** (4): 492–499.
- [9] Gao W, Fan S L, Li G, et al. A thorough benchmark and a new model for light field saliency detection[J]. *IEEE Trans Pattern Anal Mach Intell*, 2023, **45** (7): 8003–8019.
- [10] Chen G, Fu H Z, Zhou T, et al. Fusion-embedding Siamese network for light field salient object detection[J]. *IEEE Trans Multimedia*, 2024, **26**: 984–994.
- [11] Chen Y L, Li G Y, An P, et al. Light field salient object detection with sparse views via complementary and discriminative interaction network[J]. *IEEE Trans Circuits Syst Video Technol*, 2024, **34** (2): 1070–1085.
- [12] 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 Trans Image Process*, 2019, **28** (5): 2319–2330.
- [13] Wang Y Q, Yang J G, Wang L G, et al. Light field image super-resolution using deformable convolution[J]. *IEEE Trans Image Process*, 2021, **30**: 1057–1071.
- [14] Yoon Y, Jeon H G, Yoo D, et al. Learning a deep convolutional network for light-field image super-resolution[C]// *Proceedings of 2015 IEEE International Conference on Computer Vision Workshop*, Santiago, 2015: 24–32. <https://doi.org/10.1109/ICCVW.2015.17>.
- [15] Zhang S, Lin Y F, Sheng H. Residual networks for light field image super-resolution[C]// *Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition*,

- Long Beach, 2019: 11046–11055.
<https://doi.org/10.1109/CVPR.2019.01130>.
- [16] Jin J, Hou J H, Chen J, et al. Light field spatial super-resolution via deep combinatorial geometry embedding and structural consistency regularization[C]//*Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Seattle, 2020: 2260–2269.
<https://doi.org/10.1109/CVPR42600.2020.00233>.
- [17] Lv T Q, Wu Y C, Zhao X L. Light field image super-resolution network based on angular difference enhancement[J]. *Opto-Electron Eng*, 2023, 50 (2): 220185.
吕天琪, 武迎春, 赵贤凌. 角度差异强化的光场图像超分网络[J]. *光电工程*, 2023, 50 (2): 220185.
- [18] Chan K H, Im S K. Light-field image super-resolution with depth feature by multiple-decouple and fusion module[J]. *Electron Lett*, 2024, 60 (1): e13019.
- [19] Liang Z Y, Wang Y Q, Wang L G, et al. Angular - flexible network for light field image super - resolution[J]. *Electron Lett*, 2021, 57 (24): 921–924.
- [20] Wang S Z, Zhou T F, Lu Y, et al. Detail-preserving transformer for light field image super-resolution[C]//*Proceedings of the 36th AAAI Conference on Artificial Intelligence*, Vancouver, 2022: 2522–2530. <https://doi.org/10.1609/aaai.v36i3.20153>.
- [21] Wang Y Q, Wang L G, Yang J G, et al. Spatial-angular interaction for light field image super-resolution[C]//*Proceedings of the 16th European Conference on Computer Vision*, Glasgow, 2020: 290–308.
https://doi.org/10.1007/978-3-030-58592-1_18.
- [22] Liu G S, Yue H J, Wu J M, et al. Intra-inter view interaction network for light field image super-resolution[J]. *IEEE Trans Multimedia*, 2023, 25: 256–266.
- [23] Li Y L, Chen Y Y, Cui Y L, et al. LF-UMTI: unsupervised multi-exposure light field image fusion based on multi-scale spatial-angular interaction[J]. *Opto-Electron Eng*, 2024, 51 (6): 240093.
李玉龙, 陈晔曜, 崔跃利, 等. LF-UMTI: 基于多尺度空角交互的无监督多曝光光场图像融合[J]. *光电工程*, 2024, 51 (6): 240093.
- [24] 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]. *J Electron Inf Technol*, 2020, 42 (9): 2293–2301.
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.
- [25] Wu Y C, Wang Y M, Liang J, et al. Light field all-in-focus image fusion based on spatially-guided angular information[J]. *J Vis Commun Image Represent*, 2020, 72: 102878.
- [26] Liu J, Tang J, Wu G S. Residual feature distillation network for lightweight image super-resolution[C]//*Proceedings of 2020 European Conference on Computer Vision Workshops*, Glasgow, 2020: 41–55.
https://doi.org/10.1007/978-3-030-67070-2_2.
- [27] Rerabek M, Ebrahimi T. New light field image dataset[C]//*Proceedings of the 8th International Conference on Quality of Multimedia Experience*, Lisbon, 2016.
- [28] Honauer K, Johannsen O, Kondermann D, et al. A dataset and evaluation methodology for depth estimation on 4D light fields[C]//*Proceedings of the 13th Asian Conference on Computer Vision*, Taipei, China, 2017, 10113: 19–34.
https://doi.org/10.1007/978-3-319-54187-7_2.
- [29] Wanner S, Meister S, Goldluecke B. Datasets and benchmarks for densely sampled 4D light fields[C]//*Proceedings of the 18th International Workshop on Vision*, Lugano, 2013: 225–226.
- [30] Le Pendu M, Jiang X R, Guillemot C. Light field inpainting propagation via low rank matrix completion[J]. *IEEE Trans Image Process*, 2018, 27 (4): 1981–1993.
- [31] Vaish V, Adams A. The (new) Stanford light field archive[EB/OL]. [2024-3-15]. <http://lightfield.stanford.edu/>.
- [32] Lim B, Son S, Kim H, et al. Enhanced deep residual networks for single image super-resolution[C]//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops*, Honolulu, 2017: 136–144.
<https://doi.org/10.1109/CVPRW.2017.151>.
- [33] Zhang Y L, Li K P, Li K, et al. Image super-resolution using very deep residual channel attention networks[C]//*Proceedings of the 15th European Conference on Computer Vision*, Munich, 2018: 286–301. https://doi.org/10.1007/978-3-030-01234-2_18.

作者简介



黄莉 (1979-), 女, 讲师, 研究方向为 3D 数据获取与处理、光电检测、光场图像处理等。

E-mail: huangli@tyust.edu.cn



【通信作者】武迎春 (1984-), 女, 博士, 教授, 研究方向为 3D 数据获取与处理、光信息获取与处理。

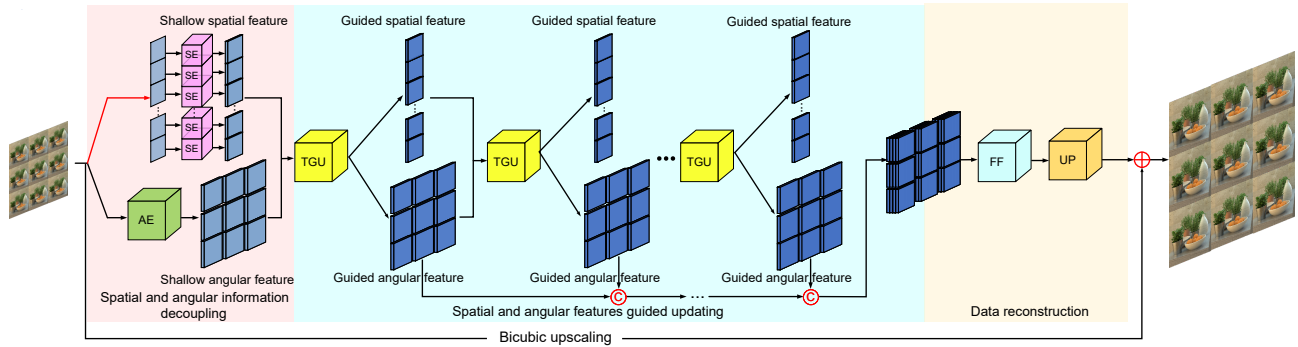
E-mail: yingchunwu3030@foxmail.com



扫描二维码, 获取PDF全文

Two-way guided updating network for light field image super-resolution

Huang Li¹, Lv Tianqi^{1,2}, Wu Yingchun^{1*}, Chen Jiani¹



Structure of LF-TGUnet

Overview: Based on the two-plane representation model, the light field camera captures both spatial and angular information of a three-dimensional scene, which causes the spatial resolution decline of the light field image. To improve the spatial resolution, a two-way guided updating super-resolution network is constructed in this work. In the shallow layers of the network, a double-branch structure is adopted. A series-parallel convolution (RSPC) block based on the atrous spatial pyramid is designed in each branch to decouple the spatial and angular information from different forms of image arrays. Then, based on the ideas of enhancement, fusion, and re-enhancement, a two-way guide updating (TGU) module is designed to complete the iterative update of the decoupled spatial and angular information. Finally, the updated angular information at different layers is fed into the simplified residual feature distillation (SRFD) module to realize data reconstruction and upsampling. Based on effectively controlling complexity, this network adopts a two-way guided updating mechanism to collect light field features of different levels, achieving better super-resolution results. The design concepts for each part of the network are as follows:

1) When decoupling spatial information and angular information, different forms of image arrays are used as inputs to extract the inherent features of each sub-aperture image and the overall parallax structure of the 4D light field through the RSPC block. The RSPC initially employs three atrous convolutions with varying atrous rates in parallel to achieve feature extraction at different levels. Subsequently, it cascades three convolutions of differing sizes to enhance feature extraction. Finally, a residual structure is introduced to mitigate network degradation.

2) In the middle part of the network, TGU module is repeatedly used to iteratively update the decoupled spatial information and angular information. The angular features are first enhanced by TGU module, then fuse with the spatial features and feed into a multi-level perception residual module to obtain the updated angular features. The updated angular features are integrated with the original spatial features, then channel reduction is performed to obtain the updated spatial features.

3) The SRFD module is presented to facilitate data reconstruction. In comparison to the residual feature distillation (RFD) network, SRFD uses channel attention to replace the CCA layer in the RFD, which results in fewer parameters and better performance.

Numerous experimental results on public light field datasets have confirmed that our proposed method achieves state-of-the-art performance both in qualitative analysis and quantitative evaluation.

Huang L, Lv T Q, Wu Y C, et al. Two-way guided updating network for light field image super-resolution[J]. *Opto-Electron Eng*, 2024, 51(12): 240222; DOI: 10.12086/oe.2024.240222

Foundation item: Project supported by the National Natural Science Foundation of China (61601318), the Patent Conversion Program of Shanxi Province (202405009), and the Fundamental Research Program of Shanxi Province (202103021224278, 202103021224272)

¹School of Electronic and Information Engineering, Taiyuan University of Science and Technology, Taiyuan, Shanxi 030024, China; ²School of Network and Communication, Hebei University of Engineering Science, Shijiazhuang, Hebei 050091, China

* E-mail: yingchunwu3030@foxmail.com