

DOI:10.19651/j.cnki.emt.2518537

DynaKPM:鲁棒盲超分辨率重建的动态核先验调制网络<sup>\*</sup>吴运嘉<sup>1,2</sup> 曹颖<sup>1,2</sup> 邓泽宇<sup>1,2</sup> 王丽会<sup>1,2</sup>

(1.贵州省先进医学成像与智能计算全省重点实验室 贵阳 550025; 2.贵州大学计算机科学与技术学院 贵阳 550025)

**摘要:**针对盲超分辨率重建中核估计偏差与非盲方法先验失配的关键难题,本研究提出基于退化核解耦评估的动态先验调制新范式。通过建立退化核窗宽-幅度的解耦评估机制,揭示核窗宽估计误差对非盲重建网络的泛化性能具有决定性影响。基于此,本工作创新性构建双阶段优化框架:在核估计阶段引入损失函数松弛约束策略,通过避免过多损失函数影响核窗宽的精确估计,增强估计核与非盲先验的兼容性;同时设计动态核先验调制网络,采用双路径特征协同优化机制,其中锐化特征模块通过高频梯度强化提取图像锐化先验,模糊衰减特征模块通过均值滤波抑制噪声干扰,并提取具有区域退化差异的模糊衰减先验特征,二者通过先验调制层生成退化调制向量,实现核特征空间的动态校准。实验验证表明,动态核先验调制网络在Set5数据集 $2\times$ 高斯模糊场景下PSNR提升1.92 dB,BSD100数据集 $4\times$ 强噪声场景下提升0.61 dB,显著优于现有最优方法。该方法有效解决了复合退化场景下的核先验失配问题,为实际复杂退化场景下的盲超分重建提供了创新性解决方案。

**关键词:**盲超分辨率重建;退化先验;模糊核估计;特征协同优化

**中图分类号:** TN911.73 **文献标识码:** A **国家标准学科分类代码:** 520.6040

## DynaKPM: Dynamic kernel prior modulation network for robust blind super-resolution reconstruction

Wu Yunjia<sup>1,2</sup> Cao Ying<sup>1,2</sup> Deng Zeyu<sup>1,2</sup> Wang Lihui<sup>1,2</sup>

(1. Key Laboratory of Advanced Medical Imaging and Intelligent Computing of Guizhou Provenc, Guiyang 550025, China;

2. School of Computer Science and Technology, Guizhou University, Guiyang 550025, China)

**Abstract:** This study proposes a new paradigm of dynamic prior modulation based on degradation kernel decoupling evaluation to address the key challenges of kernel estimation bias and non blind method prior mismatch in blind super resolution reconstruction. By establishing a decoupling evaluation mechanism for degraded kernel window width amplitude, it is revealed that the estimation error of kernel window width has a decisive impact on the generalization performance of non blind reconstruction networks. Based on this, this work innovatively constructs a two-stage optimization framework: introducing a loss function relaxation constraint strategy in the kernel estimation stage, enhancing the compatibility between the estimation kernel and non blind priors by avoiding excessive loss functions affecting the accurate estimation of kernel window width; simultaneously design a dynamic kernel prior modulation network, adopting a dual path feature collaborative optimization mechanism. The sharpening feature module extracts image sharpening prior through high-frequency gradient enhancement, while the fuzzy attenuation feature module suppresses noise interference through mean filtering and extracts fuzzy attenuation prior features with regional degradation differences. The two generate degradation modulation vectors through prior modulation layers to achieve dynamic calibration of the kernel feature space. Experimental verification shows that dynamic kernel prior modulation network improves PSNR by 1.92 dB in Set5 dataset with  $2\times$  Gaussian blur scenes and 0.61 dB in BSD100 dataset with  $4\times$  strong noise scenes, significantly better than existing optimal methods. This method effectively solves the problem of kernel prior mismatch in complex degraded scenarios, providing an innovative solution for blind super-resolution reconstruction in actual complex degraded scenarios.

**Keywords:** blind super-resolution reconstruction; degradation prior; blur kernel estimation; feature collaborative optimization

## 0 引言

图像超分辨率重建的核心挑战在于从低分辨率输入中

恢复高保真细节<sup>[1-3]</sup>,这一过程在真实场景中往往受到复杂退化模式的严重制约<sup>[4-5]</sup>。以往深度学习的方法<sup>[6]</sup>,依赖固定退化先验假设<sup>[7-8]</sup>,在复杂退化<sup>[9-10]</sup>下其重建性能呈现显

收稿日期:2025-04-08

\* 基金项目:贵州省科技计划项目(黔科合支撑[2023]一般446)、国家自然科学基金(62161004)项目资助

著退化。为了解决这一问题,盲超分辨率重建技术应运而生,其主要思想是对图像退化进行建模估计<sup>[11-13]</sup>,在未知模糊核、噪声等退化场景下,实现了更高精度重建。

早期盲图像超分辨率研究主要依托传统方法<sup>[14-16]</sup>展开探索。如 Michaeli 等<sup>[17]</sup>基于统计先验理论,提出利用图像统计特性估计退化过程的方法,通过设计模糊核估计策略有效提升了先验知识利用效率。Wang 等<sup>[18]</sup>基于局部相似性思想,采用图像块匹配策略,挖掘图像的局部结构信息以提高重建质量。Chan 等<sup>[19]</sup>提出总变分正则化方法实现图像盲去卷积,通过约束图像梯度信息在去模糊和细节恢复方面表现优异。尽管这些传统方法具有严谨的理论体系,但由于特征表达能力有限,在复合退化场景下仍存在泛化能力不足的问题。

深度学习的兴起为退化学习提供了新的技术路径<sup>[20]</sup>。其中基于显式退化核估计技术通过构建可解释的退化参数空间,不仅突破了对固定退化假设的依赖,而且显式指导机制显著增强了重建网络的泛化能力。如 Bell-kligler 等<sup>[21]</sup>基于模糊核跨尺度相似性思想构建生成对抗网络(generative adversarial network, GAN),通过生成对抗框架模拟下采样过程实现模糊核估计,在真实图像重建质量上取得突破,但当图像严重退化时,跨尺度相似性遭到破坏导致核估计不准确。而 Gu 等<sup>[22]</sup>设计包含预测器和校正器的网络架构,通过迭代优化逐步修正模糊核估计以恢复高质量图像。

随着核生成精度的提升,研究者将盲核估计与超分重建方法结合<sup>[23-25]</sup>,形成了核估计结合非盲重建的两阶段范式。如 Shocher 等<sup>[26]</sup>基于内容跨尺度相似性,提出特定于图像的小型卷积神经网络(convolution neural network, CNN),在测试阶段可以借助模糊核适应不同退化,在非理想成像条件下表现出色,但简单网络结构难以应对复杂退化。而 Zhang 等<sup>[27]</sup>提出的 USRNet 基于退化展开思想,通过数据模块、先验模块和超参数模块的协同优化成为盲核估计的主流重建框架,但其依赖于模糊核先验的精确建模。为了更精确估计模糊核,Liang 等<sup>[28]</sup>提出 Flow-DIP,基于流思想建立核空间与潜在空间的可逆映射,以此优化核估计,从而提高了在 USRNet 上重建性能,但其仍受限于高斯退化假设。Lee 等<sup>[29]</sup>采用元学习框架构建自适应迁移的核估计器,显著增强复合退化场景下核估计泛化能力,但其在内容跨尺度重现较差的图像上表现仍待提升。而 Xia 等<sup>[30]</sup>提出 MLMC,将马尔可夫链蒙特卡罗核估计与元学习相结合,构建即插即用核生成范式,有效提升了未知场景的适应能力。

尽管现有方法通过融合核估计与非盲重建技术显著提升了超分辨率性能,但其核心局限性在于估计核与真实退化核的显著偏差,导致难以满足非盲方法对鲁棒先验的需求。这一偏差在噪声与模糊共存的复合退化场景下尤为突出,引发严重的核先验失配问题,进而导致重建质量急剧下

降。本文针对上述问题提出两方面创新性贡献:第一,提出基于模糊核窗宽-幅度解耦的评估策略,通过定量实验揭示核窗宽误差对非盲重建网络泛化能力的决定性影响,为优化核估计提供了理论依据,基于此提出松弛约束的核估计优化策略,通过弱化损失函数的整体约束优先保障核窗宽精度;第二,设计动态核先验调制网络(dynamic kernel prior modulation, DynaKPM),其双路径特征协同机制通过锐化特征模块提取图像锐化先验,同时,模糊衰减特征模块通过均值滤波抑制噪声干扰,并提取具有区域退化差异的模糊衰减先验特征,然后结合先验调制层(prior modulation, PM)实现退化特征与核特征的动态校准,以提高核估计精度。实验表明,相比于最优对比方法, DynaKPM 在 Set5 数据集  $2\times$  高斯模糊场景下峰值信噪比(peak signal-to-noise, PSNR)提升 1.92 dB,在 BSD100 数据集  $4\times$  强噪声场景下提升 0.61 dB,验证了其在复杂退化场景下的有效性与鲁棒性。

### 1 DynaKPM 结构和原理

针对盲超分辨率重建中核估计偏差与非盲先验失配的核心挑战,本文在 MLMC<sup>[30]</sup>框架基础上,提出的动态核先验调制网络 DynaKPM,采用如图 1 所示的双阶段优化框架,其核心结构由以下组件构建:首先,基于模糊核窗宽-幅度解耦分析结论,在盲核估计阶段通过松弛损失函数约束,仅采用最小化低分辨率图像的重建误差来优化核估计器参数来提高核窗宽估计精度。同时在 MLMC 核估计器上,创新的提出利用双分支从低分辨率图像中提取退化先验辅助模糊核估计。具体而言,为了避免从单一低分辨率图像中提取的退化先验偏离真实退化先验,首先提出数据增强(degradation extension, DE)扩展层,增加低分辨率图像的多样性。随后,设计锐化先验层(sharpening prior, SP)以及模糊衰减先验层(blurring attenuation prior, BAP)利用差分算法提取图像的锐化特征与模糊衰减特征,将两类特征分别输入到先验调制层,得到核特征的调制参数,基于该调制参数动态估计退化核。最后将优化后的模糊核作为先

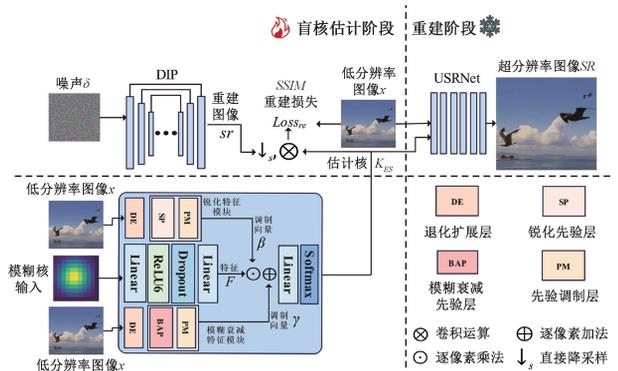


图 1 DynaKPM 架构

Fig. 1 DynaKPM architecture

验输入冻结参数的 USRNet,通过退化展开策略实现端到端重建。下面将对各个部分进行详细解释。

### 1.1 基于模糊核信号窗宽和幅度的解耦分析

现有两阶段盲超分方法虽通过核估计与非盲重建的结合取得显著进展,但其性能仍受限于关键理论空白,即表征模糊作用范围的模糊核窗宽与反映能量分布强度的幅度,对以核作为条件输入的非盲重建的差异化影响机制尚未明确,制约了其重建性能的进一步突破。为此,本研究提出基于信号维度解耦的定量评估框架,其核心实验设计如下:以标准高斯模糊核  $\mathbf{K}_0$  为基准对象,通过分层剥离与噪声注入两种独立扰动模式,分别构建窗宽缩减核集合与幅度扰动核集合。具体地,设  $\mathbf{K}_0$  大小为  $11 \times 11$ ,核的窗宽缩减通过十次迭代逐步将核最外围  $i$  层信号置零。对应操作如式(1)所示。

$$\mathbf{K}_i = \mathbf{K}_0 \odot \mathbf{Mask}_i, i = 0, 1, 2, \dots, 9 \quad (1)$$

其中,  $\mathbf{Mask}_i$  为第  $i$  次循环的外围  $i$  层置零的掩模矩

阵。另外,核的幅度扰动通过式(2)的 10 次噪声注入实现。

$$\mathbf{K}_i = \mathbf{K}_0 + \boldsymbol{\eta}_i, i = 0, 1, 2, \dots, 9 \quad (2)$$

其中,  $\boldsymbol{\eta}_i$  是在第  $i$  次循环中添加的高斯噪声。

基于上述解耦评估框架,本文对主流非盲重建网络 USRNet 在不同核先验条件下的性能展开系统性验证。如图 2(a)所示,其横轴为式(1)的 10 次采样索引。当核窗宽逐级缩减,USRNet 的 PSNR 指标呈现断崖式下降;而在图 2(b)所示的幅度扰动场景下,USRNet 的 PSNR 波动范围并不大,这验证了窗宽参数对重建性能的主导性作用。如图 2(c)~(e)所示,进一步扩展至 ZSSR<sup>[23]</sup>、DPSR<sup>[26]</sup> 等主流方法,3 种方法在高斯核与运动核场景下均呈现相似规律。这一跨方法一致性不仅证实窗宽敏感性是盲超分领域的共性挑战,更从实验角度验证了本文解耦策略的理论普适性,即精确的核窗宽估计是提升非盲方法鲁棒性的关键先决条件。

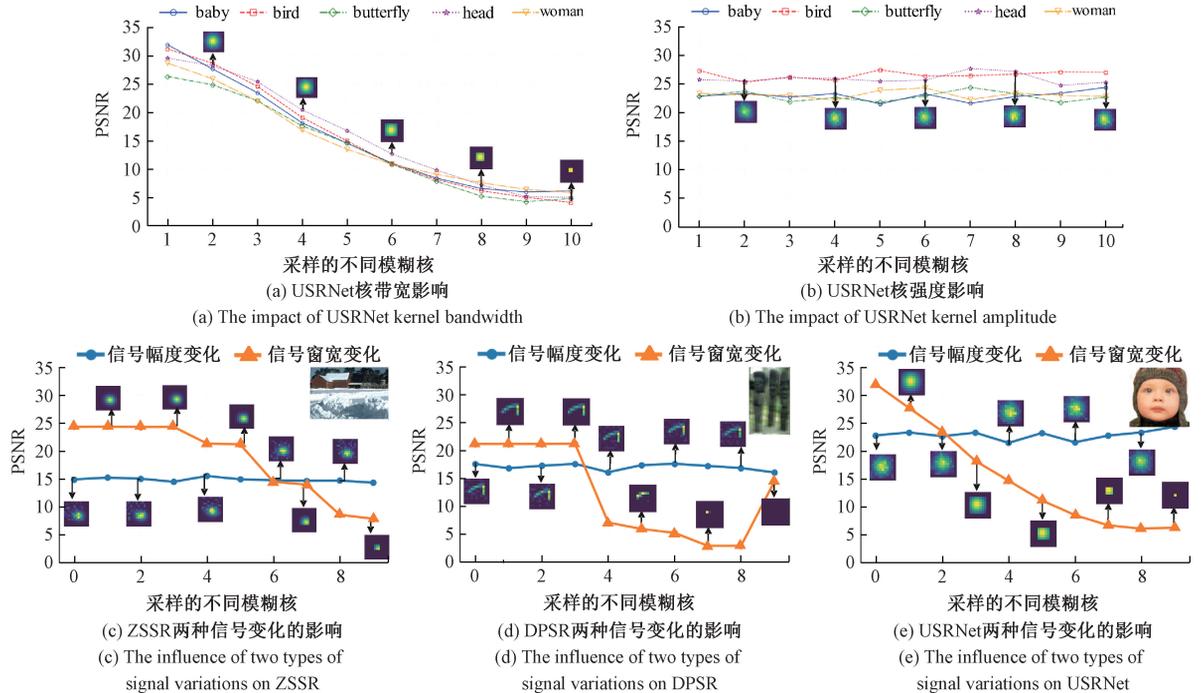


图 2 模糊核信号窗宽和幅度解耦分析

Fig. 2 Decoupling analysis of blur kernel signal window width and amplitude

基于上述分析,本文提出窗宽优先的核估计优化策略:在两阶段框架中,盲核估计阶段需优先保障生成核的窗宽参数与非盲方法的先验需求匹配。然而,以往方法过度依赖正则化损失约束核分布,导致估计过程偏向于整体信号拟合,而非关键的窗宽特性。为此,本文在核优化中仅采用 SSIM 的基础重建损失作为约束,其核心流程如图 1 所示:首先,通过深度图像先验网络 DIP<sup>[31]</sup> 从噪声图像  $\delta$  中重建高质量初始估计  $sr$ ,经降采样后与当前估计核  $K_{ES}$  进行卷积退化模拟;随后,计算模拟退化图像与真实低分辨率图像  $x$  的 SSIM 损失,通过迭代优化核参数与 DIP 网络参数,迫使核估计器聚焦于窗宽特征的精确匹配。具体

如式(3)所示。

$$Loss_{re} = SSIM((K_{ES} \otimes sr) \downarrow_s, x) \quad (3)$$

为避免核估计优化过程中因约束松弛导致的训练不稳定性,在优化核估计器与 DIP 之前,将核估计器按照 MLMC 的方式,基于随机高斯核分布空间生成仿真核数据集,对核估计器进行参数预训练,赋予模型初始退化空间建模能力。通过上述机制,即使仅采用单一重建损失约束,仍能保障优化过程的收敛性。待联合优化完成后,冻结核估计器与 DIP 网络参数,将优化后的模糊核作为先验输入预训练的 USRNet 框架,通过式(4)的退化展开机制实现端到端重建,最终输出超分辨率结果。

$$SR = U(K_{ES}, x) \quad (4)$$

其中,  $U$  为 USRNet 网络。

### 1.2 退化先验提取动机

仅依赖基础重建损失约束核估计过程可能导致模糊核特征趋于高混乱度的非结构化特征,从而引入显著的估计偏差。为应对这一问题,需通过先验引导机制抑制核特征空间的随机性,例如引入退化调制向量约束分布形态,以降低不确定性对估计精度的负面影响。从信息论视角来说,模糊核直接优化过程中,假设核特征为  $f_k$ , 其信息熵表示为  $H(f_k)$ , 当引入退化先验  $\mathbf{D}$  后,核特征的条件熵变为  $H(f_k | \mathbf{D})$ , 两者的互信息可表述为:  $I(f_k; \mathbf{D}) = H(f_k) - H(f_k | \mathbf{D})$ , 互信息的非负性使得退化先验  $\mathbf{D}$  必然包含关于  $f_k$  的有效信息,这意味着在  $\mathbf{D}$  的辅助下,  $f_k$  的熵不确定性能够降低,从而有效缓解神经网络因缺少先验知识导致优化不足的问题<sup>[32]</sup>。为确保互信息非负,退化先验需与真实退化过程相关,根据图像退化模型:

$$y = (K \otimes x) \downarrow_s + n \quad (5)$$

其中,  $x$  为 LR 图像,  $\downarrow_s$  为降采样  $s$  倍,  $K$  为模糊核,  $n$  为高斯噪声。当忽略模糊核  $K$  作用时,退化模型简化为:

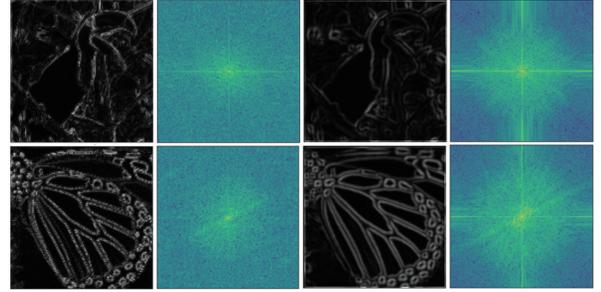
$$y_{simple} = x \downarrow_s + n \quad (6)$$

基于式(5)和(6),可以得到退化残差(degradation residual, DR)先验:

$$dr = |y - y_{simple}| \quad (7)$$

其中,  $dr$  表示退化残差 DR,可量化模糊核图像降质的显著区域,如图3所示第3列图像,模糊核的退化效应

主要集中于高频纹理区域。然而,在无监督训练条件下,由于缺乏真实高分辨率图像参考,无法直接获取精确的 DR 信息。



(a) 退化残差及其傅里叶信号 (b) 纹理退化先验及其傅里叶信号  
(a) Degradation residuals and their Fourier signals (b) Texture degradation prior and its Fourier signals

图3 不同退化先验像素信号与傅里叶空间信号对比

Fig.3 Comparison between different degraded prior pixel signals and Fourier signals

为此,本文提出从低分辨率图像中提取与 DR 特征相似的高频纹理作为退化先验,该先验分别通过锐化特征模块和模糊衰减特征模块提取,并利用先验调制退化核估计,下面将详细介绍先验调制退化核的具体结构。

### 1.3 基于先验的退化核调制模块

如图4所示,基于先验的退化核调制模块主要包含退化扩展层、锐化先验层、模糊衰减先验层以及先验调制层,下面分别对各层的具体结构进行详细阐述。

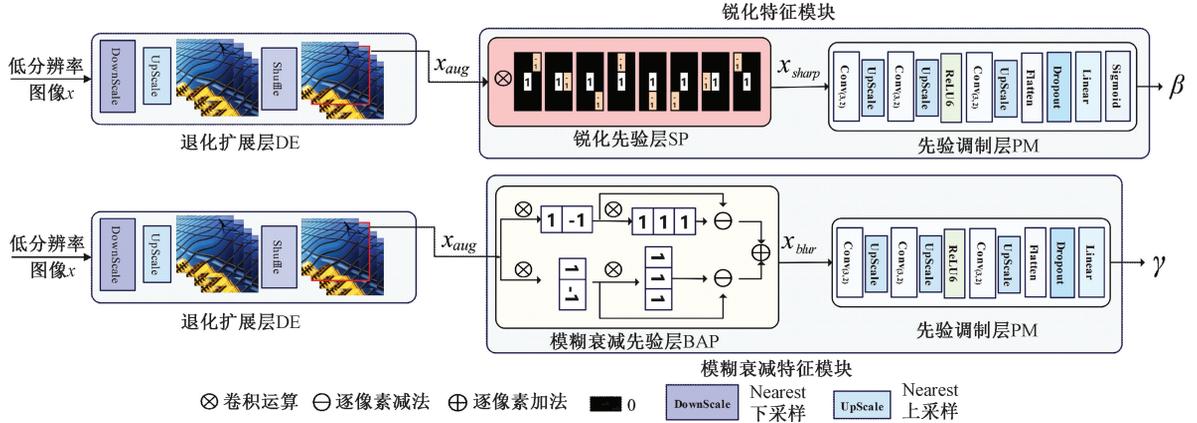


图4 基于先验的退化核调制模块组成

Fig.4 Composition of kernel modulation module based on priors

#### 1) 退化扩展层

为提取与退化残差 DR 相似的特征,本文设计的锐化特征模块与模糊衰减模块需从低质量图像中挖掘有效的退化先验。然而,低质量图像的静态特性易导致网络过拟合无关特征。为此,本文引入如图4中的退化扩展层 DE,其核心功能是通过动态尺度扰动增强退化模式的多样性。具体而言,假设低质量图像为  $x$ , 通过式(8)对  $x$  进行动态变换:

$$x_{aug} = Shuffle(\uparrow_s(\downarrow_s(x))) \quad (8)$$

其中,  $\downarrow_s$  表示缩放因子为  $s$  的插值下采样操作,  $\uparrow_s$  为对应的上采样操作,  $s \sim U(0, 1, 1)$  为均匀分布的随机缩放系数,而  $Shuffle$  函数表示随机采样任意尺度的增强图像。如图4的退化扩展层 DE 所示,该策略通过随机缩放系数  $s$  动态调节图像  $x$  的细节密度,即下采样过程压缩图像内容空间分布,上采样过程引入插值误差,二者协同作用形成退化模式扰动。DE 层通过模拟不同压缩程度的

退化变化,有效提高退化先验的多样性。

### 2) 锐化先验层

DR 表明退化集中在图像边缘纹理信息上,因此为了提取低质量图像的退化先验,本文提出如图 4 的锐化先验层 SP,其通过边缘检测算子<sup>[33-34]</sup>构建。具体实现如式(9)所示。

$$x_{sharp}(i, j) = \max_{\substack{(\delta_i, \delta_j) \in \{-1, 0, 1\}^2 \\ (\delta_i, \delta_j) \neq (0, 0)}} ([x_{aug} \otimes \mathbf{k}_{\delta_i, \delta_j}](i, j)) \quad (9)$$

其中,  $\mathbf{k}_{\delta_i, \delta_j}$  为  $3 \times 3$  卷积,以中心位置坐标为原点,  $(\delta_i, \delta_j)$  表示中心的 8 个邻域位置坐标,且  $\mathbf{k}_{\delta_i, \delta_j}$  中只有  $(\delta_i, \delta_j)$  位置为 -1,中心位置为 1,其余位置为 0。将  $x$  与 8 个邻域的  $\mathbf{k}_{\delta_i, \delta_j}$  卷积,等价于图像中任意像素  $x_{aug}(i, j)$ ,计算其 8 个邻域像素与它的差值,最后 max 运算取  $(i, j)$  所有邻域差值的最大值作为图像锐化先验  $x_{sharp}$  在  $(i, j)$  位置的值得。

### 3) 模糊衰减先验层

此外,图像不同区域的纹理信息受噪声干扰程度存在差异,即噪声强的区域退化表征弱,噪声弱的区域退化表征强,这一特性同样能反馈近似 DR 的纹理信息,为避免噪声过度影响退化先验的提取,因此本文设计如图 4 中的 BAP 模块,首先同样经过 DE 模块扩展图像的退化多样性,然后对输入图像  $x_{aug}$  与均值算子  $\mathbf{H}_d$  ( $d \in \{h, v\}$ ) 卷积 ( $d$  分别表示水平方向  $h$  和垂直方向  $v$ ) 得到平滑图像,随后将平滑图像与差分算子  $\mathbf{\Delta}_d$  ( $d \in \{h, v\}$ ) 卷积,提取平滑纹理细节,同时对原始图像  $x_{aug}$  进行相同的差分滤波,提取非平滑纹理细节。如式(10)所示。

$$x_{blur} = \sum_{d \in \{h, v\}} \max(|x_{aug} \otimes \mathbf{\Delta}_d| - |x_{aug} \otimes \mathbf{H}_d \otimes \mathbf{\Delta}_d|, 0) \quad (10)$$

将两个方向上的非平滑纹理与平滑纹理相减,得到水平和垂直方向的模糊衰减分量。最终将两个方向的非负分量相加,得到完整的模糊衰减先验  $x_{blur}$ 。模糊衰减先验通过结合均值滤波减少噪声的干扰,从而提取有效纹理信息。

综上,  $x_{sharp}$  与  $x_{blur}$  组成了本文提出的退化先验(如图 3 第 3 列所示,其由  $x_{sharp}$  与  $x_{blur}$  叠加显示),为方便后续称呼,本文将  $x_{sharp}$  与  $x_{blur}$  的搭配称为纹理退化先验(texture degradation, TD)。

### 4) 先验调制层

为将退化先验有效融入核估计过程,本文设计如图 4 所示的先验调制层 PM,其核心功能是将双路径提取的特征转换为可驱动核校准的退化感知向量。具体流程如下:输入图像依次通过退化扩展层 DE,锐化先验层 SP 以及模糊衰减先验层 BAP,分别提取两种先验构成退化先验集合  $\psi = \{x_{sharp}, x_{blur}\}$ ,PM 模块对两类特征执行分路径处理。首先,  $x_{sharp}$  通过由  $3 \times 3$  卷积核(Kernel Size = 3, Stride = 2)的 Conv<sub>(3,2)</sub>,上采样为 Nearest 插值 UpScale 层、ReLU 非线性激活构成的特征变换模块后,经 Flatten 层展平,通过 Dropout 层<sup>[35]</sup>,最终由线性层 Linear 生成锐化先验特

征。而  $x_{blur}$  经过 Sigmoid 函数归一化,生成空间自适应的权重掩膜,用于抑制核特征中的噪声敏感信号。

通过 PM 模块  $P$ ,两类先验被转化为如式(11)的退化调制向量。

$$\{\gamma, \beta\} = p(\psi_k), k = 1, 2 \quad (11)$$

两个调制向量通过如式(12)的线性层  $l$  与模糊核特征  $F$  融合后,输出校准后的退化感知模糊核,从而降低核分布的不确定性,提高核估计精度。

$$K_{ES} = l(F \odot \beta + \gamma) \quad (12)$$

## 2 实验结果与分析

### 2.1 数据集和实验设置

实验在 Set5<sup>[36]</sup>、Set14<sup>[37]</sup>、BSD100<sup>[38]</sup>、Urban100<sup>[39]</sup> 四个标准数据集和真实场景数据集 RealSR<sup>[40]</sup> 上展开,为增加数据集的退化类别,本文构建高斯模糊和运动模糊核,统一模糊核尺寸 $[4s+3, 4s+3]$ ,高斯核信号窗宽范围为 $[2.5s, 3.5s]$ ,运动模糊核则按照固定长度通过随机生成的方向来模拟不同强度的运动,随后合成低分辨率缩放倍数  $s$  为 2 和 4 的 LR 图像,最后在由高斯模糊核或者运动模糊核得到的低分辨率图像上,施加了包括 0.0%、3.9% 以及 7.8% 的高斯噪声。

此外,采用如下 3 个指标定量评估重建图像 SR 与高分辨率图像的相似度。

1) PSNR 主要用来衡量图像的峰值信噪比,其值越大,代表图像质量越好。对于尺寸为  $h \times w$  的参考图和重建图像,其数学定义为:

$$PSNR = 10 \lg \left( \frac{MAX_x^2}{\frac{1}{hw} \sum_{i=1}^h \sum_{j=1}^w [y(i, j) - x(i, j)]^2} \right) \quad (13)$$

其中,  $MAX_x^2$  是图像  $x$  最大像素值。

2) 结构相似性(structural similarity index measure, SSIM)<sup>[41]</sup>反映了两幅图像的相似程度,其值越接近 1,代表图像质量越好,其数学定义为:

$$SSIM(x, y) = \left( \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \right) \times \left( \frac{2\sigma_{xy} + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \right) \quad (14)$$

其中,  $\mu_x$  和  $\mu_y$  分别是图像  $x$  和  $y$  的平均亮度,  $\sigma_x^2$  和  $\sigma_y^2$  分别是图像  $x$  和  $y$  的灰度方差,  $\sigma_{xy}$  是图像  $x$  和  $y$  的协方差,表示结构相似性,  $C_1, C_2$  为稳定常数。

3) 学习感知图像块相似度(learned perceptual image patch similarity, LPIPS)<sup>[42]</sup>是一种基于深度学习的图像相似性度量方法,它使用预训练的卷积神经网络来提取图像特征,并计算特征之间的距离。其值越小,代表图像视觉质量越好。其具体定义为:

$$LPIPS(x, y) = \sum_l \frac{1}{h \times w} \sum_{h, w} \| \omega_l \odot (f_l(x)_{h, w} - f_l(y)_{h, w}) \|_2^2 \quad (15)$$

其中,  $f_l(x)_{h,w}$  表示神经网络第  $l$  层特征,  $w_l$  为可学习权重。

实验对比的深度学习方法均采用盲核估计范式, 其中 Flow-DIP 基于流学习模糊核分布, 并假设潜在空间分布为高斯分布, 通过可逆映射将潜在分布转化为高斯核分布从而得到预训练的核估计器。推理阶段, 固定核估计器参数, 通过优化潜在变量搜索合适模糊核进行退化估计。BSRDM<sup>[43]</sup> 在噪声建模方面, 将图片分割成多个小块, 假设每个小块的噪声分布不同, 从而更精准地模拟真实噪声。在核建模方面, 基于各向异性高斯核的协方差矩阵, BSRDM 能够生成具有明确形式的模糊核。MLMC 利用蒙特卡洛模拟在随机高斯分布上采样学习模糊核的先验, 同时, 结合元学习策略, 交替优化核生成器和基于 DIP 的图像恢复网络的参数, 通过最小化低分辨率图像重建误差来提高核估计的准确性和稳定性。

在方法参数配置方面, 本文严格遵循 BSRDM 的原始

最佳参数配置。Flow-DIP 与 MLMC 分别采用其最佳性能配置 Flow-DIP+USRNet 和 MLMC+USRNet 的两阶段盲超分框架, 后续实验简称为 Flow-DIP、MLMC。为确保公平对比各方法对分布外退化的泛化能力, 特别将 MLMC 在马尔可夫链蒙特卡罗核估计中, 预训练的高斯核窗范围调整为  $[0.175s, 2.5s]$ , 以确保预训练阶段未接触测试集的退化分布, 其余超参数保持原最佳配置。DynaKPM 沿用 MLMC 的预训练策略, 故采用相同预训练配置。所有对比方法均采用单张低分辨率图像训练模式。USRNet 统一使用 Tiny 预训练权重, 其余参数不变, 实验中仅模糊核先验作为可变参数。

### 2.2 与各个最新方法比较

#### 1) 随机高斯模糊数据的超分辨率重建结果

表 1 展示了不同方法在随机高斯模糊条件下的  $2\times$  和  $4\times$  超分辨率重建性能对比, 评估指标包括 PSNR、SSIM 和 LPIPS 的平均值, 其中加粗为最优, 下划线为次优。

表 1 不同方法在高斯模糊退化场景中不同噪声下的定量比较

Table 1 Quantitative comparison of different methods under Gaussian degradation scenario with different noise levels

图像噪声强度	方法(倍数)	Set5			Set14			BSD100			Urban100		
		PSNR	SSIM	LPIPS									
0.0%	Flow-DIP(2×)	26.55	0.815 3	0.293 3	24.09	0.696 2	0.381 4	24.48	0.672 8	0.482 3	21.30	0.648 1	0.398 4
	BSRDM(2×)	24.91	0.779 8	0.328 8	23.42	0.665 5	0.440 6	23.83	0.639 2	0.541 1	20.74	0.610 4	0.471 2
	MLMC(2×)	<u>26.99</u>	0.796 8	0.320 5	<u>24.27</u>	0.695 9	0.396 1	<u>24.78</u>	<u>0.674 8</u>	0.494 0	<u>21.37</u>	0.640 8	0.430 6
	DynaKPM(2×)	<b>28.91</b>	<b>0.835 6</b>	<b>0.228 8</b>	<b>25.59</b>	<b>0.711 4</b>	<b>0.364 6</b>	<b>25.54</b>	<b>0.678 5</b>	<b>0.469 0</b>	<b>22.32</b>	<b>0.675 5</b>	<b>0.360 5</b>
	Flow-DIP(4×)	23.02	0.620 6	0.481 4	22.66	0.604 4	<u>0.514 5</u>	23.40	0.582 1	<u>0.620 2</u>	19.92	<u>0.529 3</u>	<u>0.570 3</u>
	BSRDM(4×)	21.89	0.626 9	0.443 2	21.31	0.565 2	0.547 0	22.02	0.543 2	0.655 7	18.90	0.482 0	0.605 8
	MLMC(4×)	<u>24.07</u>	<u>0.672 0</u>	<u>0.423 6</u>	<u>22.97</u>	<u>0.608 7</u>	0.520 6	<u>23.63</u>	<u>0.586 7</u>	0.622 6	<u>20.04</u>	0.528 3	0.578 7
	DynaKPM(4×)	<b>24.69</b>	<b>0.699 5</b>	<b>0.388 6</b>	<b>23.74</b>	<b>0.624 8</b>	<b>0.462 5</b>	<b>23.99</b>	<b>0.594 0</b>	<b>0.575 3</b>	<b>20.50</b>	<b>0.552 3</b>	<b>0.498 4</b>
3.9%	Flow-DIP(2×)	17.51	0.320 6	0.674 6	17.11	0.257 3	0.750 2	19.44	0.318 1	0.742 0	15.39	0.253 8	0.779 3
	BSRDM(2×)	24.80	0.746 4	<u>0.326 7</u>	<u>23.31</u>	0.651 8	0.445 3	<u>23.69</u>	<u>0.621 7</u>	<u>0.552 7</u>	<u>20.73</u>	<u>0.595 2</u>	<u>0.478 4</u>
	MLMC(2×)	<b>26.34</b>	<b>0.767 2</b>	0.329 5	21.75	0.426 6	0.561 1	22.14	0.417 2	0.652 5	19.28	0.395 3	0.617 0
	DynaKPM(2×)	<u>26.19</u>	<u>0.766 7</u>	<b>0.303 8</b>	<b>24.62</b>	<b>0.671 6</b>	<b>0.413 5</b>	<b>24.41</b>	<b>0.629 9</b>	<b>0.530 4</b>	<b>21.28</b>	<b>0.611 0</b>	<b>0.443 9</b>
	Flow-DIP(4×)	22.57	0.572 1	0.500 2	21.61	<u>0.490 3</u>	0.618 6	22.58	0.493 1	0.697 4	<u>19.29</u>	0.437 7	0.679 6
	BSRDM(4×)	21.43	0.608 1	<u>0.459 0</u>	21.16	0.535 1	<u>0.574 5</u>	21.92	<u>0.520 9</u>	<u>0.676 6</u>	18.86	<u>0.467 6</u>	0.607 8
	MLMC(4×)	<u>23.27</u>	<u>0.644 3</u>	0.469 3	<u>21.68</u>	0.487 9	0.641 7	<u>22.60</u>	0.489 0	0.716 5	17.86	0.432 1	<u>0.538 9</u>
	DynaKPM(4×)	<b>23.73</b>	<b>0.673 8</b>	<b>0.419 0</b>	<b>22.07</b>	<b>0.549 0</b>	<b>0.548 3</b>	<b>22.90</b>	<b>0.538 3</b>	<b>0.648 6</b>	<b>19.60</b>	<b>0.490 2</b>	<b>0.586 0</b>
7.8%	Flow-DIP(2×)	18.20	0.278 1	0.717 4	18.29	0.264 2	0.718 2	19.72	0.301 8	0.748 2	16.43	0.257 2	0.770 4
	BSRDM(2×)	24.26	<u>0.706 0</u>	0.341 4	<u>23.18</u>	<b>0.629 7</b>	<u>0.474 0</u>	<u>23.53</u>	<u>0.598 3</u>	<u>0.587 2</u>	<u>20.56</u>	<u>0.567 0</u>	<u>0.516 6</u>
	MLMC(2×)	<b>25.22</b>	0.697 4	<b>0.329 7</b>	20.63	0.349 0	0.622 4	20.95	0.337 9	0.710 7	18.43	0.329 5	0.685 4
	DynaKPM(2×)	<u>24.81</u>	<b>0.714 6</b>	<u>0.340 4</u>	<b>23.40</b>	<u>0.626 7</u>	<b>0.445 6</b>	<b>23.80</b>	<b>0.597 5</b>	<b>0.533 9</b>	<b>20.64</b>	<b>0.565 0</b>	<b>0.478 0</b>
	Flow-DIP(4×)	21.44	0.491 3	0.561 5	20.65	0.397 7	0.686 1	21.71	0.416 2	0.755 6	<u>18.78</u>	0.383 9	0.725 5
	BSRDM(4×)	21.58	0.580 1	0.466 7	<u>20.92</u>	<u>0.503 6</u>	<u>0.578 7</u>	<u>21.82</u>	<u>0.502 5</u>	<u>0.672 7</u>	18.70	<u>0.446 1</u>	<u>0.619 7</u>
	MLMC(4×)	<u>22.76</u>	<u>0.615 0</u>	<u>0.447 8</u>	20.41	0.375 4	0.734 2	21.54	0.395 7	0.789 5	18.71	0.373 4	0.752 4
	DynaKPM(4×)	<b>22.82</b>	<b>0.635 0</b>	<b>0.439 6</b>	<b>21.54</b>	<b>0.519 0</b>	<b>0.549 6</b>	<b>22.43</b>	<b>0.515 1</b>	<b>0.658 5</b>	<b>19.24</b>	<b>0.460 3</b>	<b>0.607 9</b>

如表 1 所示, 由于 Flow-DIP 缺乏噪声建模机制, 并且在模糊核估计时, 仅在高斯分布空间采样, 导致难以适应

各种退化组合, 在  $2\times$  的 Set14 上的 PSNR 减小了 1.12 dB。BSRDM 虽然受益于噪声建模, 在 3.9% 以及 7.8% 的噪声

下优于 Flow-DIP,然而优化中对噪声建模与模糊核估计相互制约,在复杂退化下可能无法对未知模糊核进行精确建模。MLMC 方法在随机分布上采样训练核估计器学习先验,虽然提高了灵活性,然而该方法依赖在随机分布中进行采样学习模糊核先验,尤其在噪声干扰下,其学习的核先验可能难以捕捉未知退化的特性。

相比之下,DynaKPM 在多种复合退化条件下均取得最优性能。在  $2 \times$  无噪声条件下,DynaKPM 相较于 MLMC 在 Set5 数据集上的 PSNR 提升 1.92 dB。在  $4 \times$

强噪声场景下,DynaKPM 相较于 BSRDM 在 Set14 数据集上的 PSNR 提升 0.62 dB。在其余大多数数据集上,DynaKPM 同样展现出最优性能。图 5 所示可视化分析表明,得益于松弛优化策略,DynaKPM 估计的退化核虽未严格遵循高斯分布,但其核窗更接近真实值(ground truth, GT)。这一特性与 USRNet 核先验要求高度适配,验证了模糊核窗宽-幅度解耦策略的有效性。此外,DynaKPM 的核估计结果相较于其他方法与 GT 的匹配度更高,表明退化先验特征辅助优化机制显著提升了核估计精度。

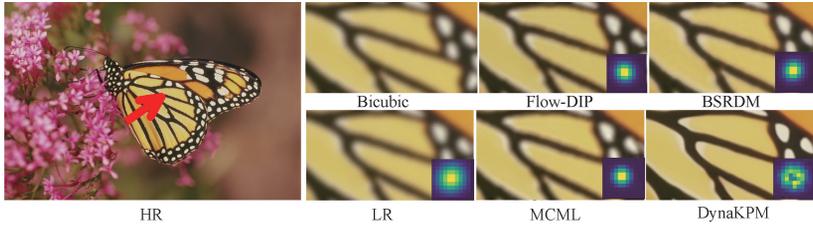


图 5 高斯模糊场景下各方法的重建可视化

Fig. 5 Visualization of reconstruction results obtained by different methods in Gaussian blurred scene

2) 运动模糊数据集的超分辨率重建结果

表 2 展示了不同方法在随机运动模糊条件下的  $2 \times$  和

$4 \times$  超分辨率重建性能对比。相较于高斯模糊退化,所有方法的性能指标均有不同程度下降,这表明复合退化会普

表 2 不同方法在运动模糊退化场景中不同噪声下的定量比较

Table 2 Quantitative comparison of different methods under blur degradation scenario with different noise levels

图像噪声强度	方法(倍数)	Set5			Set14			BSD100			Urban100		
		PSNR	SSIM	LPIPS									
0.0%	Flow-DIP( $2 \times$ )	21.41	0.619 5	0.214 9	20.58	0.518 2	0.286 2	20.17	0.485 4	<b>0.349 4</b>	17.87	0.485 7	<b>0.276 2</b>
	BSRDM( $2 \times$ )	23.22	0.722 7	0.255 8	<u>22.39</u>	<u>0.629 0</u>	0.351 4	<u>22.83</u>	<u>0.615 0</u>	0.446 7	<u>19.36</u>	<u>0.557 3</u>	0.378 5
	MLMC( $2 \times$ )	24.69	<u>0.739 2</u>	0.275 2	21.66	0.584 8	<b>0.281 9</b>	22.45	0.592 0	<u>0.351 9</u>	19.26	0.542 5	<u>0.282 1</u>
	DynaKPM( $2 \times$ )	<b>27.06</b>	<b>0.812 9</b>	<b>0.204 2</b>	<b>25.08</b>	<b>0.719 6</b>	0.313 1	<b>25.20</b>	<b>0.698 4</b>	0.392 7	<b>21.54</b>	<b>0.659 1</b>	0.300 8
	Flow-DIP( $4 \times$ )	20.72	0.575 3	0.370 8	20.25	<u>0.550 9</u>	0.425 4	<u>21.37</u>	<u>0.540 2</u>	<u>0.504 6</u>	<u>17.96</u>	<u>0.469 3</u>	0.451 5
	BSRDM( $4 \times$ )	19.17	0.566 3	<u>0.357 8</u>	19.61	0.536 8	0.450 7	20.61	0.526 6	0.517 7	17.33	0.449 6	0.466 9
3.9%	MLMC( $4 \times$ )	<b>20.83</b>	<b>0.584 6</b>	0.382 1	<b>20.35</b>	<b>0.555 9</b>	0.416 3	<b>21.43</b>	<b>0.545 6</b>	<b>0.494 1</b>	<b>17.99</b>	<b>0.477 3</b>	<u>0.435 2</u>
	DynaKPM( $4 \times$ )	<u>20.78</u>	<u>0.584 2</u>	<b>0.350 7</b>	<u>20.28</u>	0.546 4	<b>0.415 7</b>	21.27	0.529 8	0.510 5	17.77	0.454 9	<b>0.429 8</b>
	Flow-DIP( $2 \times$ )	20.47	0.534 3	0.404 9	19.46	0.362 9	0.470 9	20.01	0.367 5	0.524 2	17.61	0.359 9	0.457 1
	BSRDM( $2 \times$ )	22.99	0.705 1	<b>0.268 7</b>	<u>22.33</u>	<u>0.617 5</u>	<u>0.392 9</u>	<u>22.80</u>	<u>0.604 8</u>	<u>0.479 2</u>	<u>19.44</u>	<u>0.555 9</u>	<u>0.407 4</u>
	MLMC( $2 \times$ )	<u>24.73</u>	<u>0.735 9</u>	0.286 0	20.79	0.428 9	0.438 0	21.40	0.428 5	0.513 3	18.69	0.404 0	0.448 4
	DynaKPM( $2 \times$ )	<b>25.44</b>	<b>0.750 5</b>	<u>0.277 2</u>	<b>24.13</b>	<b>0.674 4</b>	<b>0.342 1</b>	<b>24.31</b>	<b>0.653 6</b>	<b>0.433 5</b>	<b>20.72</b>	<b>0.602 4</b>	<b>0.355 9</b>
7.8%	Flow-DIP( $4 \times$ )	20.00	0.449 0	0.453 9	20.13	0.526 2	0.463 7	21.14	0.496 5	0.585 1	<u>17.89</u>	<u>0.442 4</u>	0.512 6
	BSRDM( $4 \times$ )	19.01	0.543 9	<b>0.373 2</b>	19.56	0.520 8	0.477 0	20.52	<u>0.505 7</u>	<u>0.567 6</u>	17.26	0.435 4	<u>0.490 7</u>
	MLMC( $4 \times$ )	<u>20.71</u>	<u>0.573 1</u>	0.393 4	<u>20.17</u>	0.518 6	0.487 0	21.05	0.473 0	0.633 7	17.86	0.432 1	0.538 9
	DynaKPM( $4 \times$ )	<b>20.99</b>	<b>0.573 3</b>	<u>0.385 0</u>	<b>20.30</b>	<b>0.539 5</b>	<b>0.441 2</b>	<b>21.37</b>	<b>0.520 4</b>	<b>0.548 4</b>	<b>18.01</b>	<b>0.453 9</b>	<b>0.475 1</b>
	Flow-DIP( $2 \times$ )	20.31	0.433 1	0.502 3	19.10	0.331 3	0.547 0	19.80	0.316 5	0.614 1	17.71	0.325 0	0.542 1
	BSRDM( $2 \times$ )	23.15	0.685 7	<u>0.305 0</u>	<u>22.36</u>	<u>0.602 0</u>	<u>0.432 4</u>	<u>22.78</u>	<u>0.589 6</u>	<u>0.524 3</u>	<u>19.54</u>	<u>0.545 0</u>	<u>0.453 9</u>
7.8%	MLMC( $2 \times$ )	<u>24.61</u>	<u>0.707 3</u>	<b>0.287 7</b>	19.76	0.359 1	0.522 8	20.40	0.345 4	0.605 5	17.99	0.337 9	0.547 9
	DynaKPM( $2 \times$ )	<b>24.61</b>	<b>0.710 4</b>	0.305 8	<b>23.30</b>	<b>0.632 4</b>	<b>0.343 4</b>	<b>23.68</b>	<b>0.618 1</b>	<b>0.445 6</b>	<b>20.25</b>	<b>0.563 3</b>	<b>0.398 8</b>
	Flow-DIP( $4 \times$ )	19.69	0.427 7	0.508 9	<u>19.83</u>	0.479 6	0.530 6	<u>20.49</u>	0.411 4	0.685 8	<u>17.66</u>	0.390 1	0.594 8
	BSRDM( $4 \times$ )	18.95	0.514 8	0.417 3	19.55	<u>0.503 0</u>	<u>0.505 7</u>	20.48	<u>0.485 4</u>	<u>0.606 6</u>	17.25	<u>0.416 3</u>	<u>0.527 2</u>
	MLMC( $4 \times$ )	<b>20.45</b>	<u>0.547 5</u>	<u>0.397 1</u>	19.74	0.462 6	0.571 1	20.20	0.377 6	0.738 7	17.49	0.367 8	0.641 0
	DynaKPM( $4 \times$ )	<u>20.40</u>	<b>0.548 7</b>	<b>0.393 7</b>	<b>20.22</b>	<b>0.525 2</b>	<b>0.456 6</b>	<b>21.15</b>	<b>0.502 8</b>	<b>0.557 7</b>	<b>18.06</b>	<b>0.445 5</b>	<b>0.500 6</b>

遍影响模型重建性能。其中 Flow-DIP 在高斯分布空间搜索模糊核, BSRDM 由于利用各向异性高斯核的协方差矩阵估计模糊核。而 MLMC 依赖在随机高斯分布中进行采样来学习模糊核先验。这 3 个方法在一定的假设空间估计模糊核, 虽然能够生成合理的核, 但在处理如运动模糊核以及复杂噪声混合条件下, 可能无法完全捕捉复杂模糊核的真实特性, 导致核估计精度受限。例如在  $2\times$  无噪声的 BSD100 上, DynaKPM 的 PSNR 相比次优方法高达 2.37 dB。

虽然在无噪声条件下, MLMC 等方法在  $4\times$  缩放因子的 BSD100 及 Urban100 数据集上展现出与 DynaKPM 相近的性能指标。然而随着退化过程引入噪声干扰时,

DynaKPM 表现出显著性能优势, 其泛化能力随退化复杂度增加而显著增强。例如在  $2\times$  缩放因子的中等噪声水平条件下, DynaKPM 在 Set14 数据集上的 PSNR 指标较最优方法 BSRDM 提升 1.8 dB, 在强噪声水平条件下, DynaKPM 在 BSD100 数据集上的 PSNR 指标较最优对比方法 BSRDM 提升 0.9 dB。值得注意的是, DynaKPM 相较于其他方法获得更优的重建质量, 这归因于其退化先验引导生成的鲁棒核先验与非盲方法的高度适配性。如图 6 所示的可视化分析表明, DynaKPM 估计的退化核在信号窗宽上与真实值 GT 的偏差显著减小, 这验证了退化先验特征对噪声干扰的抑制能力, 以及其对 USRNet 核先验窗宽参数的精准匹配机制。

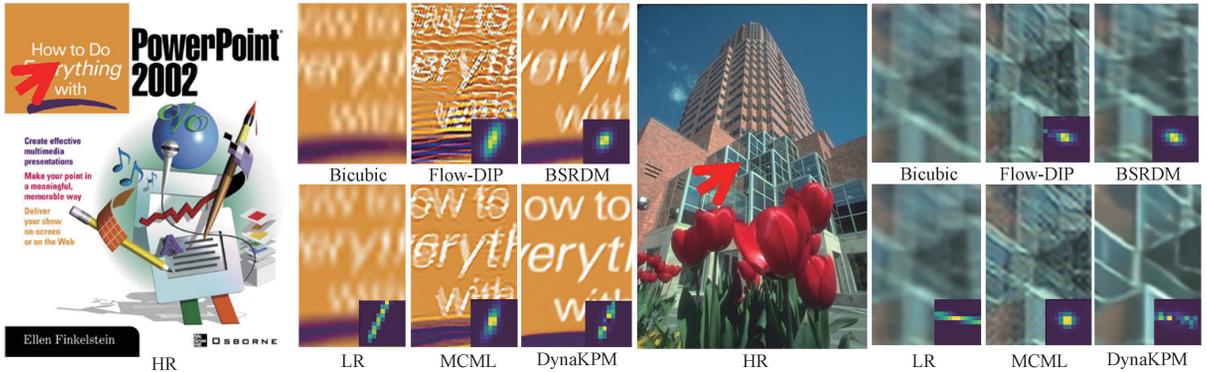


图 6 运动模糊场景下各方法重建可视化

Fig. 6 Visualization of reconstruction results obtained by different methods in motion blurred scenes

### 3) 真实图像的超分辨率重建结果

为验证 DynaKPM 在未知场景下的泛化性能, 本文在 RealSR 真实退化数据集上开展  $2\times$  超分辨率重建实验。如表 3 所示, DynaKPM 以 26.58 dB 的 PSNR 指标优于现有方法。尽管其 LPIPS 为 0.173 0 指标未达最优, 但图 7 所示风车图像的重建分析表明, 该现象源于 USRNet 的重建特性, 即当模糊核窗宽接近真实退化信号窗宽时, 网络倾向于生成清晰度更高且纹理平滑的图像。

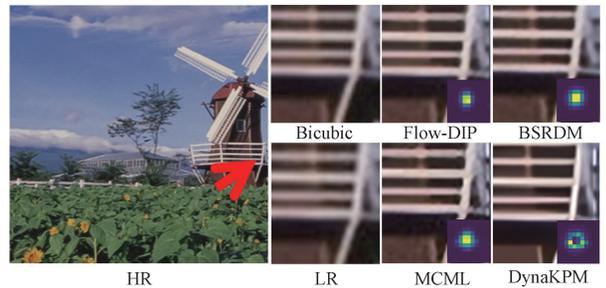


图 7 真实场景 Canon\_028(RealSR) 的重建可视化

Fig. 7 Reconstruction visualization for real scene data Canon\_028 (RealSR)

表 3 不同方法在真实退化场景下的性能评估

Table 3 Performance evaluation of different methods in real degradation scenarios

倍数	方法	PSNR	SSIM	LPIPS
$2\times$	Flow-DIP	25.59	0.815 5	0.157 8
$2\times$	BSRDM	<u>26.44</u>	<u>0.824 1</u>	<b>0.151 3</b>
$2\times$	MLMC	25.74	0.812 2	<u>0.154 7</u>
$2\times$	DynaKPM	<b>26.58</b>	<b>0.840 9</b>	0.173 0

图 7 的对比结果显示, DynaKPM 重建图像的边缘细节恢复效果更优。值得注意的是, DynaKPM 生成的模糊核虽未严格遵循高斯分布, 却实现了最清晰的视觉重建效果, 表明其能够准确估计符合真实退化规律的模糊核参数, 进一步验证了该方法在未知场景下的鲁棒超分辨率重建能力。

### 2.3 消融实验

由于 DynaKPM 目的是通过退化先验辅助模糊核估计, 因此本节着重讨论调制模糊核过程中重要组成部分的作用。首先本文对退化扩展层 DE 进行了消融, 从而验证退化多样性扩展对图 4 中退化特征  $\beta, \gamma$  辅助模糊核估计的影响。然后验证锐化特征模块以及模糊衰减特征模块对模糊核特征调制的作用。最后接着讨论将组成  $\beta, \gamma$  的退化先验替换为真实图像根据式 (7) 计算得到的退化残差, 来验证本文提出的方法在无监督下的普适性。

#### 1) 退化扩展层 DE 的消融实验

表 1、2 的实验结果表明, DynaKPM 在多种复合退化

场景中展现出优异的泛化能力,这得益于退化扩展层 DE 的关键设计。为验证 DE 层的有效性,本文在  $4\times$  缩放因子下的 Set5 数据集上开展消融实验,分别针对高斯模糊与运动模糊退化场景进行对比分析。如表 4 所示,在无噪声与强噪声两种水平的高斯退化场景中,未使用 DE 层的性能与使用 DE 层相近。而在同样噪声水平的运动模糊场景中,去除 DE 层导致 PSNR 指标下降 0.21 与 0.22 dB。

表 4 DE 层的消融结果  
Table 4 Ablation results of DE layer

图像噪声强度	模糊核	方法	PSNR	SSIM	LIPIS
0.0%	高斯	DE	24.69	0.699 5	0.388 6
	高斯	无 DE	<b>24.72</b>	<b>0.699 5</b>	<b>0.386 6</b>
	运动	DE	<b>20.78</b>	<b>0.584 2</b>	0.350 7
	运动	无 DE	20.57	0.573 1	<b>0.345 0</b>
7.8%	高斯	DE	<b>22.82</b>	<b>0.635 0</b>	0.439 6
	高斯	无 DE	22.82	0.633 8	<b>0.437 9</b>
	运动	DE	<b>20.40</b>	<b>0.548 7</b>	<b>0.393 7</b>
	运动	无 DE	20.18	0.543 9	0.398 1

图 8 的核估计可视化结果表明,未采用 DE 层时,估计核的形态分布相较于使用 DE 层时显著偏离真实标签。这证明 DE 层通过尺度扰动增强退化模式的多样性,有效提升了核估计模块对复合退化的表征能力。

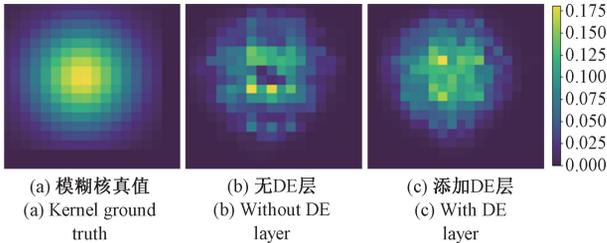


图 8 DE 层消融的退化核估计可视化

Fig. 8 Visualization of degradation kernels estimated with different DE layer ablations

2) 锐化特征/模糊衰减特征模块的消融实验

由于 DynaKPM 中的双分支学习到的退化先验特对提升 DynaKPM 在复合退化场景下的泛化能力具有关键作用。因此本文在含两种噪声水平的  $2\times$  与  $4\times$  缩放高斯模糊退化的 Set5 数据集上设计消融实验,量化结果如表 5 所示。其中,  $\beta, \gamma$  分别表示图 4 中的锐化特征/模糊衰减特征模块提取的退化特征,  $F \odot \beta$  表示只使用锐化特征模块调制模糊核特征,  $F + \gamma$  表示只使用模糊衰减特征模块,  $F \odot \beta + \gamma$  表示本文提出的完整 DynaKPM 方法,最后 No Prior 表示两个分支都不使用。

实验表明,在  $2\times$  缩放下,单独融合  $\beta$  特征的模型 PSNR 优于单独融合  $\gamma$  特征;而在  $4\times$  缩放下,单独融合  $\gamma$

表 5 锐化/模糊衰减特征层消融结果

Table 5 Ablation results for SP and BAP layers

图像噪声强度	倍数	方法	PSNR	SSIM	LIPIS
0.0%	$2\times$	No Prior	28.32	0.824 7	0.251 4
	$2\times$	$F \odot \beta$	<u>28.80</u>	<u>0.832 4</u>	0.233 2
	$2\times$	$F + \gamma$	28.45	0.827 3	0.247 1
	$2\times$	$F \odot \beta + \gamma$	<b>28.91</b>	<b>0.835 6</b>	<b>0.228 8</b>
	$4\times$	No Prior	<u>24.71</u>	<u>0.698 4</u>	<b>0.384 6</b>
	$4\times$	$F \odot \beta$	24.47	0.688 5	0.400 9
	$4\times$	$F + \gamma$	24.44	0.689 4	0.399 4
	$4\times$	$F \odot \beta + \gamma$	<b>24.69</b>	<b>0.699 5</b>	<u>0.388 6</u>
3.9%	$2\times$	No Prior	25.80	0.753 8	0.332 5
	$2\times$	$F \odot \beta$	<u>26.05</u>	<u>0.764 9</u>	<u>0.311 1</u>
	$2\times$	$F + \gamma$	25.90	0.757 7	0.324 0
	$2\times$	$F \odot \beta + \gamma$	<b>26.19</b>	<b>0.766 7</b>	<b>0.303 8</b>
	$4\times$	No Prior	23.49	0.661 0	0.436 9
	$4\times$	$F \odot \beta$	23.36	0.661 2	0.432 3
	$4\times$	$F + \gamma$	<u>23.58</u>	<u>0.666 0</u>	<u>0.430 3</u>
	$4\times$	$F \odot \beta + \gamma$	<b>23.73</b>	<b>0.673 8</b>	<b>0.419 0</b>

特征则展现出相对优势。这一结果证明不同退化先验特征协同方式在不同缩放退化场景中具有互补性。进一步分析显示,在无噪声条件下,同时融合  $\gamma, \beta$  特征的模型较单一特征的最优 PSNR 分别在  $2\times$  和  $4\times$  提升 0.46 dB 和 0.25 dB,表明双分支协同机制能够突破单路径优化的性能上限。该结论从实验角度验证了构建双模块的必要性,为框架设计提供了坚实的实证支撑。

3) 纹理退化先验 TD 与真实退化残差 DR 的对比

为验证本文在 1.5 节提出由锐化先验层与模糊衰减先验层所提取的纹理退化先验 TD 对核估计的作用,如表 6 所示,本文在 Set5 数据集上构建高斯模糊与运动模糊两种退化场景,对比分析两类优化策略:TD 与 DR 策略。其中,TD 表示本文提出的 DynaKPM 采用图 4 中的 SP/BAP 层提取的退化先验辅助模糊核估计,DR 表示 DynaKPM 双分支均采用由式(7)计算得到的真实退化残差 DR 先验辅助模糊核估计。

表 6 展示了无噪声条件下  $2\times$  与  $4\times$  超分辨率重建的量化评估结果。在  $2\times$  缩放因子下,TD 展现出显著优势,在高斯模糊场景下,其 PSNR 较 DR 分别提升 0.25 dB,验证 TD 先验对核估计精度的增强效果,这在四倍超分条件下也展现出了相同的表现。特别地,在  $2\times$  运动模糊场景中,DR 的 PSNR 较 TD 提升 0.64 dB,表明 DR 作为真实退化先验具有更强的表征能力。然而,由于 DR 在无监督条件下无法获取,TD 策略通过从低质量图像中提取代理特征,在保证可比性能的同时具有更强的实际适用性。

此外,利用退化先验辅助模糊核估计,可以有效降低

表6 与真实退化残差辅助模糊核估计对比

Table 6 Comparison with the results obtained by the kernel estimation aided with real degradation residual

模糊核	倍数	方法	PSNR	SSIM	LIPIPS
高斯	2×	TD	<b>28.91</b>	<b>0.835 6</b>	<b>0.228 8</b>
	2×	DR	28.76	0.832 4	0.235 8
	4×	TD	24.69	<b>0.699 5</b>	0.388 6
	4×	DR	24.69	0.698 2	0.391 5
运动	2×	TD	27.06	0.812 9	0.204 2
	2×	DR	<b>27.70</b>	<b>0.823 8</b>	<b>0.202 6</b>
	4×	TD	<b>20.78</b>	<b>0.584 2</b>	0.350 7
	4×	DR	20.53	0.575 2	<b>0.333 6</b>

其特征的不确定性,因此局部训练周期内的特征会变得更加相似。

对此,本文利用标准化欧氏距离  $Dist(x, y)$  计算模糊核特征间的相似度,以衡量加入退化先验后降低模糊核优化中核特征的不确定性程度。具体标准化欧氏距离为:

$$Dist(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2 / V_i} \quad (16)$$

其中,  $x_i$  与  $y_i$  都代表核估计器输出的模糊核  $K_{ES}$  在第  $i$  维的值,  $V_i$  代表  $x_i$  与  $y_i$  在第  $i$  维特征的标准差。图9展示了2×缩放因子下各策略在200训练周期内的特征标准化欧氏距离热力图,该热力图用于量化盲核估计训练过程中特征的相似度变化,颜色越深,值越小,表示特征相似度越高,颜色越浅,值越大,则表明相似度越低。对比实验

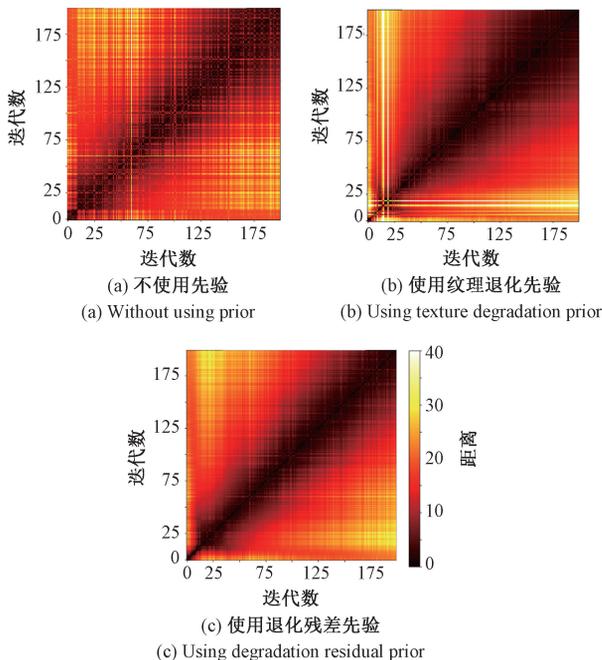


图9 不同退化先验下模糊核特征相似性变化热力图

Fig. 9 Heat map showing the variations of kernel feature similarity with epochs obtained with different degradation priors

表明,采用纹理退化先验 TD 或退化残差 DR 策略时,在迭代次数 Epoch>100 后的训练收敛阶段,模糊核特征空间的局部相似度趋于饱和状态,而不适用先验的 No Prior 策略下,特征差异在训练后期仍保持较高水平,如图9所示表现为更多黄色区域。这一现象验证了退化先验特征对模糊核特征空间不确定性的抑制作用。通过引入先验信息,核估计过程的随机性显著降低,优化轨迹更加稳定。

### 3 结 论

本研究针对现有两阶段盲超分辨率方法在盲核估计阶段退化估计显著偏离真实退化等关键问题,首先,本文提出基于模糊核信号窗宽和幅度的解耦策略,揭示出核宽估计偏差对主流非盲重建网络的性能具有关键性影响。并据此在盲核估计阶段通过弱化损失函数对核估计的约束,优先提升核宽估计精度,从而有效增强整体重建效果。随后本文提出 DynaKPM,并设计由退化扩展层、锐化先验层、模糊衰减先验层以及先验调制层将图像退化先验与模糊核特征融合,有效降低了弱化核估计损失带来的核分布不确定性,从而提高了核估计精度。实验表明,DynaKPM 在 Gaussian 模糊、运动模糊及噪声复合退化场景下均实现了盲超分辨率重建性能的显著提升,具有广泛的应用价值。然而,实验结果也表明,在强噪声水平下 DynaKPM 仍然会面临泛化性能下降的问题,探索对噪声鲁棒性的策略仍然是未来研究重点,以进一步推动盲超分技术的实用化进程。

### 参考文献

- [1] DONG CH, LOY CH CH, HE K M, et al. Learning a deep convolutional network for image super-resolution [C]. European Conference on Computer Vision (ECCV), 2014:184-189.
- [2] 李轩, 刘小祎. 通道可分离残差网络的图像超分辨率重建[J]. 电子测量技术, 2023, 46(6):84-90.  
LI X, LIU X Y. Image super-resolution reconstruction based on channel-separable residual network [J]. Electronic Measurement Technology, 2023, 46(6): 84-90.
- [3] 莫恒辉, 魏霖静. 基于层次交互动态注意力与序列学习的图像超分辨率重建[J]. 国外电子测量技术, 2024, 43(6):76-86.  
MO H H, WEI L J. Image super-resolution reconstruction based on hierarchical interactive dynamic attention and sequence learning [J]. Foreign Electronic Measurement Technology, 2024, 43(6): 76-86.
- [4] 张博伟, 何彦霖, 王康, 等. 基于全方位深层加权轻量化网络的冠脉造影图像超分辨率重建方法[J]. 仪器仪表学报, 2024, 45(7):200-209.  
ZHANG B W, HE Y L, WANG K, et al. Super

- resolution reconstruction of coronary angiography images based on the omnidirectional deep weighted lightweight network[J]. *Chinese Journal of Scientific Instrument*, 2024, 45(7):200-209.
- [5] 刘兰兰, 万旭东, 汪志刚, 等. 基于超分辨率重建与多尺度特征融合的输电线路缺陷检测方法[J]. *电子测量与仪器学报*, 2023, 37(1):130-139.  
LIU L L, WAN X D, WANG ZH G, et al. Transmission line defect detection method based on super-resolution reconstruction and multi-scale feature fusion[J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(1):130-139.
- [6] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks[C]. *IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, 2016:1646-1654.
- [7] LYN J, YAN S. Non-local second-order attention network for single image super resolution[C]. *IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, 2019:11065-11074.
- [8] ZHANG Y L, LI K, LI K, et al. Image super-resolution using very deep residual channel attention networks [C]. *European Conference on Computer Vision(ECCV)*, 2018:294-310.
- [9] ZHANG K, LIANG J Y, VAN GOOL L, et al. Designing a practical degradation model for deep blind image super-resolution[C]. *IEEE/CVF International Conference on Computer Vision (ICCV)*, 2021: 4771-4780.
- [10] WANG X T, YU K, WU SH X, et al. Esrgan: Enhanced super resolution generative adversarial networks [C]. *European Conference on Computer Vision(ECCV)*, 2018:63-79.
- [11] XU Y S, TSENG S Y R, TSENG Y, et al. Unified dynamic convolutional network for super-resolution with variational degradations[C]. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2020:12493-12502.
- [12] YANG ZH X, XIA J Y, LI SH X, et al. A dynamic kernel prior model for unsupervised blind image super resolution[C]. *IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, 2024:26046-26056.
- [13] LIU AN R, LIU Y H, GU J J, et al. Blind image super-resolution: A survey and beyond [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(5):5461-5480.
- [14] BEGIN I, FERRIE F P. Blind super-resolution using a learning-based approach[C]. *International Conference on Pattern Recognition(ICPR)*, 2004:85-89.
- [15] 沈焕锋, 李平湘, 张良培. 一种自适应正则 MAP 超分辨率重建方法[J]. *武汉大学学报(信息科学版)*, 2006, 31(11):949-952.  
SHEN H F, LI P X, ZHANG L P. Adaptive regularized map super-resolution reconstruction method[J]. *Geomatics and Information Science of Wuhan University*, 2006, 31(11): 949-952.
- [16] YU H, YAP K H, LI CH, et al. A soft map framework for blind super-resolution image reconstruction [J]. *Image & Vision Computing*, 2009, 27(4):364-373.
- [17] MICHAELI T, IRANI M. Nonparametric blind super resolution [C]. *IEEE/CVF International Conference on Computer Vision(ICCV)*, 2013:945-952.
- [18] WANG Q, TANG X O, SHUM H. Patch based blind image super resolution[C]. *IEEE/CVF International Conference on Computer Vision(ICCV)*, 2005:709-716.
- [19] CHAN T F, WONG C K. Total variation blind deconvolution [J]. *IEEE Transactions on Image Processing*, 1998,7(3):370-375.
- [20] WANG L G, WANG Y Q, DONG X Y, et al. Unsupervised degradation representation learning for blind super-resolution [C]. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2021:10581-10590.
- [21] BELL-KLIGLER S, SHOCHER A, IRANI M. Blind super resolution kernel estimation using an internal-gan[C]. *Annual Conference on Neural Information Processing Systems(NeurIPS)*, 2019:284-293.
- [22] GU J J, LU H N, ZUO W M, et al. Blind super-resolution with iterative kernel correction[C]. *IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, 2019:1604-1613.
- [23] ZHANG K, ZUO W M, ZHANG L. Deep plug-and-play super-resolution for arbitrary blur kernels[C]. *IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, 2019:1657-1670.
- [24] SOH J W, CHO S, CHO N I. Meta-transfer learning for zero-shot super-resolution[C]. *IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, 2020:3513-3522.
- [25] YOO J S, KIM D W, LU Y C, et al. Rzsrr: Reference-based zero-shot super-resolution with depth guided self-exemplars [J]. *IEEE Transactions Multimedia*, 2023,25:5972-5983.
- [26] SHOCHER A, COHEN N, IRANI M. Zero-shot super-resolution using deep internal learning [C].

- IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2018:3118-3126.
- [27] ZHANG K, VAN GOOL L, TIMOFTE R. Deep unfolding network for image super-resolution [C]. IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2020:3214-3223.
- [28] LIANG J Y, ZHANG K, GU SH H, et al. Flow-based kernel prior with application to blind super-resolution[C]. IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2021:10601-10610.
- [29] LEE R, LI R, VENIERIS S I, et al. Meta-learned kernel for blind super-resolution kernel estimation[C]. IEEE/CVF Winter Conference on Applications of Computer Vision(WACV), 2024:1485-1494.
- [30] XIA J Y, YANG ZH X, LI SH X, et al. Blind super-resolution via meta-learning and markov chain monte carlo simulation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46 (12): 8139-8156.
- [31] ULYANOV D, VEDALDI A, LEMPITSKY V S. Deep image prior [J]. International Journal of Computer Vision, 2020,128(8): 9446-9454.
- [32] GAWLIKOWSKI J, TASSI C R N, ALI M, et al. A survey of uncertainty in deep neural networks [J]. Artificial Intelligence Review, 2023, 56 (S1): 1513-1589.
- [33] EMAD M, PEEMEN M, CORPORAAL H. Dualssr: Zero-shot dual learning for real-world super-resolution[C]. IEEE/CVF Winter Conference on Applications of Computer Vision(WACV), 2021:1629-1638.
- [34] SHI Z L, METTES P, MAJI S, et al. On measuring and controlling the spectral bias of the deep image prior[J]. International Journal of Computer Vision, 2022,130(4):885-908.
- [35] KONG X T, LIU X N, GU J J, et al. Reflash dropout in image super resolution [C]. IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2022:5992-6002.
- [36] BEVILACQUA M, ROUMY A, GUILLEMOT C, et al. Low complexity single image super-resolution based on nonnegative neighbor embedding [C]. British Machine Vision Conference(BMVC), 2012:1-10.
- [37] ZEYDE R, ELAD M, PROTTER M. On single image scale-up using sparse-representations [C]. International Conference on Curves and Surfaces (ICCS), 2010:711-730.
- [38] MARTIN D R, FOWLKES C C, TAL D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics [C]. IEEE/CVF International Conference on Computer Vision(ICCV), 2001:416-425.
- [39] HUANG J B, SINGH A, AHUJA N. Single image super-resolution from transformed self-exemplars[C]. IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2015:5197-5206.
- [40] CAI J R, ZENG H, YONG H W, et al. Toward real-world single image super-resolution: a new benchmark and a new model [C]. IEEE/CVF International Conference on Computer Vision (ICCV), 2019: 3086-3095.
- [41] WANG ZH, BOVIK A C, SHEIKH H R, et al. Image quality assessment: From error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004,13(4):600-612.
- [42] ZHANG R, ISOLA P, EFROS A A, et al. The unreasonable effectiveness of deep features as a perceptual metric[C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 586-595.
- [43] YUE Z SH, ZHAO Q, XIE J W, et al. Blind image super-resolution with elaborate degradation modeling on noise and kernel [C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2022:2118-2128.

## 作者简介

吴运嘉,硕士研究生,主要研究方向为计算机视觉、盲图像超分辨率重建。

E-mail:2815778319@qq.com

曹颖,博士,主要研究方向为计算机视觉、盲图像超分辨率重建。

E-mail: yshxdm@gmail.com

邓泽宇,博士,主要研究方向为计算机视觉、图像复原。

E-mail: dengzeyu1996@sina.com

王丽会(通信作者),教授,主要研究方向为深度学习、机器学习、医学成像、医学图像处理和计算机视觉。

E-mail: lhwang2@gzu.edu.cn