

模糊感知引导的渐进图像去模糊^{*}

胡 波, 田榕澳, 郑 佳, 龚兵兵, 高新波

(重庆邮电大学 计算机科学与技术学院, 重庆 400065)

通信作者: 高新波, E-mail: gaoxb@cqupt.edu.cn



摘 要: 图像去模糊因其在安防监控、医学影像处理、遥感图像处理等领域的广泛应用而备受关注。尽管基于端到端的方法已经取得了巨大的进步,但单一的 U-Net 网络也难以处理复杂的运动模糊,而基于辅助任务的恢复方式往往存在参数量大的问题。此外,绝大多数方法均无法实现对不同图像模糊位置和模糊程度的精确识别,而模糊感知往往是决定模型恢复性能的关键因素之一。受此启发,提出一种模糊感知引导的渐进图像去模糊算法 (progressive image deblurring guided by blur perception, PDBP-Net)。该算法的主要思想是利用辅助任务来生成模糊感知特征图从而引导算法实现更精细的恢复。首先,高频差异与图像残差生成子网络 (high frequency difference and image residual generative subnetwork, HDIRG-net) 采用辅助学习的方式同时生成高频差异特征图和残差图;然后,将两者输入高频差异引导的模糊感知模块 (blur perception module guided by high-frequency differences, BPGHD) 深入融合并提取模糊信息,从而生成模糊感知特征图。此外,为了缓解单网络对复杂场景难恢复的问题,该模块利用残差图和模糊图生成初步恢复图;最后,模糊感知指导的细节恢复子网络 (blur perception guided detail restoration subnetwork, BPGDR-net) 在模糊感知特征图的指导下对初步恢复图进行有针对性的再优化,从而生成最终的恢复图。提出的去模糊模型在多个基准数据集上进行了广泛的评估,并且与最先进的去模糊方法相比,具有显著的优势。特别地,在 GoPro 数据集上,峰值信噪比 (PSNR) 和结构相似性 (SSIM) 值达到了 33.85 dB 和 0.967,其中 PSNR 指标高于第 2 名 0.39 dB。大量实验结果表明,PDBP-Net 优于最先进的辅助学习方法,并显著提升了图像去模糊的性能,印证了所提方法的有效性。

关键词: 图像去模糊; 辅助学习; 高频差异; 模糊感知

中图法分类号: TP391

中文引用格式: 胡波, 田榕澳, 郑佳, 龚兵兵, 高新波. 模糊感知引导的渐进图像去模糊. 软件学报, 2026, 37(5): 2309–2324. <http://www.jos.org.cn/1000-9825/7494.htm>

英文引用格式: Hu B, Tian RA, Zheng J, Gong BB, Gao XB. Progressive Image Deblurring Guided by Blur Perception. Ruan Jian Xue Bao/Journal of Software, 2026, 37(5): 2309–2324 (in Chinese). <http://www.jos.org.cn/1000-9825/7494.htm>

Progressive Image Deblurring Guided by Blur Perception

HU Bo, TIAN Rong-Ao, ZHENG Jia, GONG Bing-Bing, GAO Xin-Bo

(School of Computer Science and Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: Image deblurring has attracted much attention due to its wide applications in fields such as security surveillance, medical image processing, and remote sensing image processing. Although end-to-end methods have made significant progress, a single U-Net network struggles to handle complex motion blur, while restoration approaches based on auxiliary tasks often suffer from large parameter sizes. In addition, the vast majority of methods fail to accurately identify the locations and degrees of blur in different images, while blur perception is often one of the key factors determining the restoration performance of models. Inspired by this, this study proposes a progressive

^{*} 基金项目: 国家自然科学基金 (62101084); 重庆自然科学基金 (CSTB2023NSCQ-BHX0187, CSTB2023NSCQ-LZX0085); 重庆市教委科学技术研究项目 (KJQN202200638); 重庆市博士后研究项目 (2022CQBSHTB2052)

收稿时间: 2024-10-18; 修改时间: 2025-03-18; 采用时间: 2025-06-16; jos 在线出版时间: 2025-12-03

CNKI 网络首发时间: 2025-12-04

image deblurring algorithm guided by blur perception (PDBP-Net). The main idea of the algorithm is to utilize auxiliary tasks to generate blur perception feature maps, thus guiding the algorithm to achieve more refined restoration. First, the high-frequency difference and image residual generative subnetwork (HDIRG-net) employs auxiliary learning to simultaneously generate high-frequency difference feature maps and residual maps. These are then fed into the blur perception module guided by high-frequency differences (BPGHD) for deep fusion and extraction of blur-related information, resulting in the generation of blur perception feature maps. Moreover, to alleviate the limitations of a single network in restoring complex scenes, this module uses the residual maps and blur maps to generate preliminary restored images. Finally, the blur perception-guided detail restoration subnetwork (BPGDR-net) conducts targeted re-optimization of the preliminary restored images under the guidance of the blur perception feature maps, thus generating the final restored images. The proposed deblurring model is extensively evaluated on multiple benchmark datasets and achieves significant improvements over state-of-the-art deblurring methods. Specifically, on the GoPro dataset, the peak signal-to-noise ratio (PSNR) and structural similarity index (SSIM) reach 33.85 dB and 0.967, respectively, with the PSNR being 0.39 dB higher than that of the second-best method. Extensive experimental results demonstrate that PDBP-Net outperforms state-of-the-art auxiliary learning-based methods and significantly enhances image deblurring performance, confirming the effectiveness of the proposed method.

Key words: image deblurring; assisted learning; high frequency difference; blur perception

随着信息化时代的迅猛发展,生活中涌现出海量的图片,然而,这些图片的质量却不可避免地呈现出参差不齐的状况。例如,在拍摄过程中,相机抖动或者拍摄物体处于运动状态等情况,通常会使图像变得模糊。为提升模糊图像质量,学界涌现出许多去模糊算法。在盲运动去模糊领域,这些算法可以被分为两类:传统的方法和基于深度学习的方法。前者主要基于正则化技术、稀疏图像先验、hyper-Laplacian 先验等先验^[1-3]知识进行模型构建,并取得了一定进展,但此类方法对真实场景中的复杂模糊缺乏建模能力。当模糊核具有空间变化特性或与训练假设存在域差异时,基于固定先验的估计方法容易偏离真实退化过程,最终限制去模糊算法的实际性能。随着卷积神经网络(convolutional neural network, CNN)的出现,基于深度学习的方法摆脱了先前手工估计模糊核的方式,模糊核可由卷积自主学习而得^[4-10]。相较于以往的方法,利用 CNN 学习得到的模糊核所恢复的效果更为优异。然而,这些方法仍然具有操作复杂性,即使估计出正确的模糊核,仍需使用该估计核进行反卷积以恢复图像。此外,如果先验设计复杂,则去模糊模型的计算与求解会变得更加困难。与模糊核估计方法不同,端到端的去模糊方法^[11-16]无需估计模糊核,从而避免了因估计不准而导致的去模糊误差。

尽管端到端的网络架构在数据集上表现良好,但它们未能准确识别模糊位置和程度,而这些信息往往是恢复图像细节的关键因素之一。运动模糊的位置和程度往往十分复杂并难以预估。如图 1 所示,在同一张图像中,不同区域(如 A 和 B)出现了不同的模糊效果。当行人 A 向左走时,产生的模糊效果与行人 B 向右走时产生的运动模糊方向不同,即同一张图像的不同位置可能会有不同方向的模糊效果。此外,即使在同一区域(如图 1 中的 A 位置),也存在不同程度的模糊。例如, A 位置行人的手臂靠近肩膀部分的模糊程度较小,而远离肩膀部分的模糊程度较大。因此,尽管模糊方向大致相似,但在相同的模糊区域,模糊程度可能不同。为了去除图像中大部分的模糊,基于单一框架的模型往往未对不同程度的模糊进行针对性的处理,使得恢复图像的纹理和边缘过于平滑,从而导致此类模型在高频信息恢复方面表现欠佳。为解决这一问题, Liu 等人^[17]设计了高频信息聚合模块和高频信息注意模块,通过有监督的高频信息重建任务指导高频注意模块的恢复,但是两种模块设计复杂只注重多尺度的相关性,忽视了初步恢复图和低频特征图的关联,不能从整体的角度利用生成的高频信息进一步恢复清晰图像。Ji 等人^[18]和 Tsai 等人^[19]采用横向和纵向的学习方式,逐块进行模糊位置识别,以大致获取模糊位置并学习不同的模糊方式,然而这种方法计算量大,并且模型监督不足,位置识别不够精确。Jiang 等人^[20]利用 CNN 提取局部信息,Transformer 提取全局信息,该方法在一定程度上能够较为准确地识别图像中不同位置的模糊程度差异,然而,对于同一位置不同程度的模糊,其学习能力存在一定局限性。

不同于上述方法,本文提出了模糊感知引导的渐进图像去模糊方法(progressive image deblurring guided by blur perception, PDBP-Net),该方法的核心思想是首先生成残差图和低频差异特征图,然后在此基础上生成模糊感知特征图和初步恢复图,最后在模糊感知特征图的指导下对初步恢复图进行再优化,从而生成高质量的恢复图。具体地,该方法大致分为 3 个步骤:首先,本文设计了高频差异与图像残差生成子网络(high-frequency differences and image residual generative, HDIRG-net),该网络采用辅助学习的方式同时生成高频差异特征图和残差图;然后,本文

设计了高频差异引导的模糊感知模块(blur perception module guided by high-frequency differences, BPGHD)用于融合上层子网络的两个输出,同时生成模糊感知特征图来指导下层子网络的细节恢复;最后,本文设计的模糊感知指导的细节恢复子网络(blur perception guided detail restoration, BPGDR-net)利用融合后的模糊感知信息对初步恢复图进行精细化恢复,得到高质量的去模糊图像。在3个基准数据集的量化结果表明,所提的PDBP-Net方法取得了当前最优的性能表现。




图1 GoPro数据集^[21]中的模糊图像

本文的主要贡献可总结为以下3点。

- (1) 提出基于辅助学习的高频差异与图像残差生成子网络,该子网络通过辅助学习方式重建潜在的高频差异信息并生成残差图。
- (2) 提出跨层连接的高频差异引导的模糊感知模块,不仅融合了上层子网络生成的高频差异特征图和残差图并加以约束,而且为下层的恢复子网络提供精确的模糊感知指导。
- (3) 大量实验表明,本文方法在不同类型数据集上都具有出色的模糊感知和图像恢复能力,并显著提高了真实场景中的去模糊性能。

1 图像去模糊相关工作

目前端到端的方法按照网络任务可以分为两大类:单任务方法和辅助学习方法。下面将详细综述这两类方法。

● 单任务方法。近年来,众多单任务图像去模糊网络架构相继涌现,其核心优势在于能够直接生成清晰图像,省去了复杂的中间处理步骤,实现了简单高效的去模糊效果。此类方法进一步可以细分为3类:基于U-Net网络的方法,多尺度分块的网络架构和基于GAN网络的方法。Gao等人^[22]提出了一种从粗到细的图像去模糊网络,该模型的不同子网络之间可以有选择性参数共享和跳跃连接。该方法设计了参数选择共享方案,从而优化了传统参数独立和共享方案的局限性。Purohit等人^[23]则从注意力机制入手,设计了融合通道注意力和空间注意力的卷积块。他们的编码器-解码器主干采用可变形模块(dense deformable module, DDM)和自注意力(self-attention, SA)模块,在不显著增加计算成本的前提下提升了去模糊性能。Cho等人^[24]则提出了一种多尺度的U-Net网络,即MIMO-UNet。该网络在单层编码器-解码器架构上实现了多尺度的输入输出,并通过巧妙设计的多尺度交互连接增强了网络的特征提取能力。Li等人^[25]在此基础上进一步探索,设计了局部学习策略,专注于图像局部模糊的恢复,并提出了数据集的生成方法。Zhang等人^[26]则从频域角度出发,提出了一种基于频域的对比学习方法。该方法通过对模糊图像的高频区域进行对比学习监督,结合编码器、解码器与清晰图像的对比,实现了高效的去模糊效果。Chen等人^[27]对U-Net网络中的残差块进行了简化,以简洁的基线模块构建出性能出色的去模糊网络。近年来,Transformer在图像领域因其能够提取全局相关信息的优势而受到广泛关注,但由于计算量大、对设备要求高,其在图像去模糊领域的应用一直受到限制。为了解决这一难题,Zamir等人^[28]提出了Restormer模型,该模型通过计算特征深度域中的缩放点积注意力来降低计算成本。Pan等人^[29]基于NAFNet^[27]框架进行改进,通过Transformer提取频域特征,从而达到了优秀的恢复效果。此类基于U-Net网络的方法(如图2(a)所示)无需输出中间特征,但框架简单仅对内部残差结构进行了创新。Nah等人^[21]提出一种多尺度卷积神经网络,通过金字塔结构从粗到细逐级恢复图像。在不同分辨率层级上分别提取特征,并通过跨尺度连接融合低层细节与高层语义信息。Tao等人^[30]设计一

种尺度循环网络, 通过递归处理多尺度图像, 从低分辨率到高分辨率逐步重建清晰图像, 并在不同尺度间共享权重, 利用跨尺度信息传递提升模型恢复能力. Wan 等人^[31]提出一种基于通道注意力机制的动态场景盲去模糊方法, 网络通过自适应通道注意力模块动态调整不同特征通道的权重, 增强对模糊区域的特征敏感性. 上述多尺度分块的网络架构 (如图 2(b) 所示) 在中间层多次生成初步恢复图, 虽然分阶段的方式可以拆分解决模糊空间变化性和复杂性, 但不能精准地找寻模糊关键位置. Kupyn 等人^[32]提出了 DeblurGAN 来对不同的模糊源进行建模, 其中采用具有编码器解码器架构的 CNN 作为生成器, 并采用基于卷积块的分层器作为判别器. DeblurGAN-v2^[33]将双尺度判别器和特征金字塔网络合并到 GAN 中, 以实现更好的去模糊结果. 上述基于 GAN 网络的方法 (如图 2(c) 所示) 在模型训练阶段增加了判别器, 可以对生成的清晰图像进行判别, 帮助模型监督图像恢复, 然而基于 GAN 网络的模型训练困难, 不易收敛. 尽管单任务方法因其结构简单、参数量小且无需生成中间结果而受到青睐, 但它难以针对性学习模糊位置和模糊程度, 同时难以引入其他任务来辅助网络进行优化. 因此, 在追求更高去模糊效果的过程中, 如何平衡方法的复杂性和性能, 仍是图像去模糊领域面临的重要挑战.




图 2 单任务学习中的主流模型框架

● 辅助学习方法. 辅助学习是一种强大的深度学习策略, 它允许模型同时处理多个相关任务. 通过共享模型参数和特征提取器, 这类方法不仅减少了所需的模型数量和计算复杂度, 还提高了模型的效率和泛化性能, 有效避免了过拟合问题. 在图像恢复领域, 引入相关任务进行辅助学习有助于图像的细节恢复. 现有的辅助学习方法可以分为 3 类: 基于 U-Net 的多输出方法、基于先验特征指导的恢复方法和基于循环的生成网络. Chi 等人^[34]结合了辅助学习和元学习, 实现了清晰图像和模糊图像的同步生成. 该网络的设计使得两种图像的生成过程在参数上实现了共享, 同时在测试阶段仍能针对不同图像特征进行学习. 此类基于 U-Net 的多输出方法 (如图 3(a) 所示) 在单任务 U-Net 网络的基础上额外生成了模糊图像, 帮助模型进行监督和测试, 然而由于网络架构相对简单, 在共享参数的情况下同时生成清晰图像和模糊图像是非常困难的, 这导致其在进行图像去模糊时性能受限. 文献 [17,35] 首先设计一个子网络, 通过模糊图像生成对应的先验信息, 然后利用先验信息辅助第 2 个子网络恢复模糊图像. 上述基于先验特征指导的辅助学习网络 (如图 3(b) 所示) 通过生成的先验特征图针对性拆解图像恢复步骤, 同时提取图像恢复所需的关键特征信息, 然而这一设计并未实现两个子网络的参数共享, 导致先验信息与恢复图像的关联不够紧密, 同时计算量和参数量成倍增加导致模型训练困难. Zhao 等人^[36]通过引入多个注意力机制, 自适应地关注图像中的运动模糊区域, 从而显著提升了去模糊效果. 他们进一步利用对比引导技术, 通过对比生成的清晰和模糊图像与真实清晰图像, 有效指导生成器的训练过程. Zhao 等人^[37]利用清晰图像和模糊图像在频域分布上的不一致性, 将图像同时清晰化和模糊化, 实现了轻量级的无监督学习去模糊模型. Li 等人^[38]则从另一个角度入手, 他们认为模糊图像是清晰图像与模糊空间纠缠的结果. 他们设计的模糊空间解缠网络能够分离出模糊图像中的模糊空

间, 并利用这些生成的模糊空间与其他清晰图像生成新的模糊图像. 这种辅助学习方法有助于更好地去除图像模糊并生成逼真的模糊图像. 然而, 这种方法通常使用两个不同的网络分别处理清晰图像和模糊图像的生成, 导致模型参数无法充分共享. 这些基于循环的生成网络框架 (如图 3(c) 所示) 可以将清晰图像生成模糊图像、模糊图像恢复成清晰图像, 同时训练两个生成网络相互监督学习, 然而, 此类方法训练量大, 难以精确地生成所需图像. 综上所述, 辅助学习为图像恢复任务引入了其他相关任务, 有助于模型进行针对性的学习, 从而提高收敛速度和泛化能力. 然而, 其复杂的框架往往导致参数量增加, 且如果未能有效分步骤学习每个任务, 反而不利于模型的收敛, 引发欠拟合问题, 从而阻碍模型求得最优解. 为了解决这一问题, 本文提出了一种不同的辅助学习方法, 如图 3(d) 所示. 该方法的核心在于通过辅助学习任务, 在共享参数的基础上同时生成高频特征和初步恢复图. 这两个任务相互借鉴, 共同帮助图像去模糊. 此外, 本文方法中分步骤的学习方式不仅减轻了模型的训练负担, 还有效防止了因任务过重导致的模型不收敛问题.




图 3 辅助学习中的主流模型框架

2 方法

本文采用辅助学习的方式来帮助网络感知图像的模糊位置和模糊程度, 进而指导模型进行精细化的去模糊. 该方法分为 4 个部分: 高频差异与图像残差生成子网络、高频差异引导的模糊感知模块、模糊感知指导的细节恢复子网络和损失函数. 首先, 本文生成高频特征与残差图; 接下来, 将生成的高频差异特征图和残差图输入高频差异引导的模糊感知模块, 生成模糊感知特征图. 与此同时, 利用模糊图和残差图生成初步恢复图; 最后, 将模糊感知特征图与初步恢复图一并输入模糊感知指导的细节恢复子网络对图像进行更为精准的细节恢复, 从而得到高质量的恢复图像. 本文提出的网络框架如后文图 4 所示, 下面详细介绍各个模块.

2.1 高频差异与图像残差生成 (HDIRG) 子网络

频域处理在图像去模糊领域取得了显著进展, 有研究表明, 模糊图像和清晰图像之间的差异主要体现在频率上^[21,26,29]. 具体而言, 图像的低频部分和高频部分表现出截然不同的特性, 清晰图像的高频分量总是能够捕捉到比模糊图像更为清晰的纹理和细节, 而清晰图像和模糊图像的低频分量则表现出很高的相似性. 如图 5 所示, (a) 为模糊图像, (b) 为模糊图像提取的高频特征, (c) 为清晰图像, (d) 为清晰图像提取的高频特征, (e) 为两个高频特征之差. 从图 5 中可以看出, 模糊图像和清晰图像在高频特征中具有较大差异. 基于此, Liu 等人^[17]和 Fu 等人^[35]在各自的研究中采用了不共享参数的双网络策略, 分别用于生成高频特征和恢复清晰图像. 上述方法虽然有效, 但步骤繁琐, 且由于模型参数不共享, 导致了较大的参数量, 进而增加了计算难度. 与之不同, 本文提出的高频差异与图像残

差生成子网络,旨在同时生成残差图和高频差异特征图,这一策略不仅显著减少了模型参数量和复杂度,而且两个任务相辅相成,实现了更好的效果.




图4 整体网络架构




图5 高频差异对比图

如图4所示, HDIRG子网络中的编码器-解码器通过堆叠多个编码层和解码层来提取图像特征. 首先, 对输入的模糊图像 $I_b \in \mathbb{R}^{H \times W \times 3}$ 提取浅层特征 $F_q \in \mathbb{R}^{H \times W \times C}$, 公式如下:

$$F_q = FE(I_b) \quad (1)$$

其中, $H \times W$ 代表特征大小, C 表示特征维度, 浅层特征提取层 $FE(\cdot)$ 包含一个 5×5 卷积网络和一个残差块. 随后, 将 F_q 输入至编码器.

编码器部分由4个相同的编码层堆叠而成, 用来捕获多尺度特征. 每个编码层之间进行下采样操作, 将提取的图像特征映射为原本空间大小的一半, 并将其通道增加一倍. 上述编码过程可用如下公式表示:

$$F_e = E(F_q) \quad (2)$$

其中, $E(\cdot)$ 表示编码器, F_e 表示编码器提取的特征.

为了逐步恢复高分辨率的特征表示, 在解码器部分使用与编码器对应的特征提取模块. 每个尺度的解码层之间进行上采样操作, 将图像特征的尺寸大小增加一倍, 通道数量减半. 上述解码过程可用如下公式表示:

$$F_d = D(F_e) \quad (3)$$

其中, $D(\cdot)$ 表示解码器, F_d 表示解码器的输出特征.

最后, 将解码器最终生成的图像特征输入到重构层, 生成最终的高频差异特征图和残差图. 重构层包括 1 个 5×5 卷积网络和 3 个残差块, 它将图像特征维度映射为 6 通道, 取前 3 个通道为残差图, 后 3 个通道为高频差异特征图, 其过程可用公式表示如下:

$$F_r, F_h = RE(F_d) \quad (4)$$

其中, $RE(\cdot)$ 表示重构层, $F_r \in \mathbb{R}^{H \times W \times 3}$ 为生成的残差图, $F_h \in \mathbb{R}^{H \times W \times 3}$ 为生成的高频差异特征图.

上述编码层和解码层都由 4 个如图 6 所示的残差块组成^[27], 其中 SG (simple gate) 为门控线性单元 (gated linear unit, GLU) 的变体, 用于增强模型表现的激活函数. 通过引入门控机制, 使得模型能够选择性地通过信息, 从而提高模型的表达能力和性能, SG 在此基础上简化了操作, 提高模型计算效率. SCA (simplified channel attention) 为通道注意力, 它首先将空间信息压缩到通道中, 然后应用多层感知来计算通道注意力, 并将其用于加权特征图, 高效地捕获全局信息. 这些组件共同协作, 提升了网络的特征提取和表示能力.




图 6 残差块结构

2.2 高频差异引导的模糊感知模块 (BPGHD)

将生成的高频差异特征图直接送入 BPGDR 子网络进行指导去模糊是不合理的^[17,39], 原因如下: 高频差异特征图的模糊感知能力不强, 不能有效地指导后续精细化细节的恢复. 因此, 本文设计了 BPGHD 模块 (如图 7 所示), 它将生成的高频差异特征图和残差图进行深度融合, 生成模糊感知特征图用于指导后续细节恢复. 同时, 该模块还利用模糊图和残差图生成了初步恢复图, 为后续精细化恢复奠定基础.




图 7 高频差异引导的模糊感知模块 BPGHD

具体地, BPGHD 模块将高频差异特征图 F_h 乘以残差图 F_r 生成注意力图 F_a , 此过程可以表示为:

$$F_a = F_h \times F_r \quad (5)$$

然后, 将注意力图 F_a 和生成的高频差异特征图 F_h 分别进行 3×3 卷积用来提取具有融合特性的信息, 残差图 F_r 进行频域注意力操作用于关注具有高频信息的图像特征 F_l . 随后, 将注意力图送入激活函数后分别与生成的高频差异特征图

F_h 和图像特征 F_l 相乘, 自适应提取模糊位置和模糊程度, 最后将融合信息相加, 通过 3×3 卷积进行通道变换得到模糊感知特征图 $F_g \in \mathbb{R}^{H \times W \times 1}$. 上述模块的操作过程可用如下公式表示:

$$F_g = \text{cat}\{C(\mathcal{F}(F_r) \times S(C(F_a)) + C(F_h) \times S(C(F_a))), F_r\} \quad (6)$$

其中, $C(\cdot)$ 表示卷积操作, $\mathcal{F}(\cdot)$ 表示高频注意力操作, $\text{cat}\{\cdot, \cdot\}$ 表示两个特征按通道进行叠加, $S(\cdot)$ 表示激活函数.

此外, 为了约束残差图的生成与后续精细化细节的恢复, 本文将模糊图与残差图相加以生成初步恢复图, 此过程可以表示为:

$$I = I_b + F_r \quad (7)$$

2.3 模糊感知指导的细节恢复 (BPGDR) 子网络

BPGDR 子网络利用具有模糊信息的模糊感知特征图指导初步恢复图进行精细化恢复. 它与 HDIRG 子网络的编码器和解码器完全相同并且参数共享, 这一设计不仅使得已经学习到的去模糊参数能方便地应用于恢复子网络, 而且显著减少了模型的参数量和复杂度, 提升了运算效率.

首先, BPGDR 子网络对初步恢复图 I 和模糊感知特征图 F_g 进行 $\text{cat}\{\cdot, \cdot\}$ 操作得到通道为 4 的合成特征图. 然后, 为了方便后续主干网络的学习, 本文采用 3×3 的卷积操作对特征进行降维, 最终得到 3 通道的特征图 F_{sum} . 上述操作的公式表示如下:

$$F_{\text{sum}} = C(\text{cat}\{F_g, I\}) \quad (8)$$

随后, 将特征图 F_{sum} 送入 BPGDR 子网络的编码器与解码器. 不同于 HDIRG 子网络的多输出, 该层子网络的输出仅有最终恢复图, 这样可以让 BPGDR 子网络更加专注利用模糊感知特征图的指导信息去生成最终恢复图, 而非学习识别模糊区域, 该过程表示如下:

$$I_s = M(F_{\text{sum}}) \quad (9)$$

其中, $M(\cdot)$ 为 BPGDR 子网络, I_s 为最终恢复图.

2.4 损失函数

本文采用多损失联合方式来约束模型的学习, 下面介绍各个损失函数.

PSNR 损失: 为了控制图像的像素级精度, 本文将初步恢复图 I 和最终恢复图 I_s 都与清晰图 G 求 PSNR 损失, 公式如下:

$$L_{\text{PSNR}} = \mathcal{P}(G, I) + \mathcal{P}(G, I_s) \quad (10)$$

其中, $\mathcal{P}(\cdot, \cdot)$ 表示计算 PSNR 损失.

高频损失: 为了监督高频差异特征图的生成效果, 本文通过 Laplacian 算子提取清晰图 G 和模糊图 I_b 的高频信息, 两者做差得到了真实的高频差异特征图 G_h , 然后与生成的高频差异特征图 F_h 计算 L_h 损失:

$$L_h = \|G_h - F_h\|_1 \quad (11)$$

傅里叶损失: 对于最终恢复图 I_s , 本文不仅采用了 PSNR 损失, 还采用了傅里叶损失对其频域特征进行监督. 具体公式如下:

$$L_f = \|\mathcal{T}(G) - \mathcal{T}(I_s)\|_1 \quad (12)$$

其中, $\mathcal{T}(\cdot)$ 表示傅里叶变换.

综上, 本文的整体损失定义如下:

$$Loss = L_{\text{PSNR}} + \lambda_h L_h + \lambda_f L_f \quad (13)$$

其中, λ_h 和 λ_f 分别为高频损失和傅里叶损失权重, 参数设置为 $\lambda_h = 0.1$ 和 $\lambda_f = 0.1$.

3 实验

本文通过大量的实验来评估 PDBP-Net 的有效性. 首先, 介绍实验设置, 包括用于训练和验证的数据集、实现细节和评价指标; 然后, 通过客观指标来呈现本文方法的优越性; 接着, 通过主观实验展示本文算法对合成运动模

糊、真实运动模糊和失焦模糊等多种模糊类型的恢复效果;最后,通过消融实验验证 PDBP-Net 中每个组件的有效性.

3.1 实验设置

- 数据集: 为了全面验证 PDBP-Net 对各种场景下模糊图像的恢复效果,本文采用了多个公开的图像运动去模糊数据集.具体地: GoPro 数据集^[21]包含 3 214 个图像对,每对图像中包含一个模糊和一个清晰图像.该数据集划分 2 103 对图像为训练集、1 111 对图像为测试集. HIDE 数据集^[40]包含 8 422 个图像对,其中 6 397 对训练集和 2 025 对测试集,该数据集主要关注行人和街道场景中的运动模糊. REDS 数据集的测试集是非公开的,按照其他算法^[27]的测试方式,本文采用 REDS-val-300 中的 300 张图像作为测试集.
- 实现细节: 与之前的工作相同,本文模型仅在 GoPro 数据集上进行训练,之后在 GoPro、HIDE 和 REDS 数据集上进行测试.参考 NAFNet 网络的参数设置: 将 $\beta_1 = 0.9$ 、 $\beta_2 = 0.9$ 、 $\varepsilon = 0$ 的 Adam 优化器用于优化网络.本文模型总共训练 4×10^5 次迭代,初始学习率设置为 $1\text{E}-3$,通过余弦退火方案逐渐降低到 $1\text{E}-6$.训练的图像尺寸大小为 256×256 ,32 通道下的批量大小为 11,64 通道下的批量大小为 5.通过裁块方式进行训练并在全图像进行测试会导致性能下降,因此 PDBP-Net 在测试阶段加入 TLC 方法^[41]来解决此类问题.
- 评价指标: 本文采用峰值信噪比 (PSNR) 和结构相似度 (SSIM) 两个指标来衡量各个算法的恢复效果.

3.2 客观对比

为了验证 PDBP-Net 的优越性,本文在 3 个数据集上进行测试并与先进的方法进行定量比较.这些算法的所有定量数据都来自相应的文献.实验结果如表 1 和表 2 所示,Params 为网络的参数量,FLOPs 为网络的计算量.

表 1 在 GoPro 和 HIDE 数据集上的对比结果

Methods	GoPro		HIDE		Params (MB)	FLOPs (G)
	PSNR (dB)	SSIM	PSNR (dB)	SSIM		
Liu等人 (2021, TMM) ^[17]	31.90	0.951	29.47	0.934	25.7	—
Stripformer (2022, ECCV) ^[19]	33.08	0.962	31.03	0.940	20	170
CLG-INet (2023, ACM) ^[20]	33.43	0.962	31.49	0.944	24.7	86.8
MIMO-UNet (2021, ICCV) ^[24]	32.68	0.959	29.99	0.930	16.1	89.5
MSFS-Net (2023, TCSVT) ^[26]	33.46	0.964	31.30	0.943	21.6	—
Restormer (2022, CVPR) ^[28]	32.92	0.959	31.22	0.942	25.3	140
Chi等人 (2021, CVPR) ^[34]	32.50	0.958	30.55	0.935	—	—
EADNet (2022, IJON) ^[35]	31.02	0.912	—	—	8.99	—
HSDNet (2023, TIP) ^[38]	31.68	0.950	—	—	6	88
MPRNet (2021, CVPR) ^[39]	32.66	0.958	30.96	0.939	20.1	660.2
Whang等人 (2022, CVPR) ^[42]	31.66	0.948	29.77	0.922	26.0	—
BAGdeblur (2022, TNNLS) ^[43]	31.71	0.944	—	—	—	—
Pan等人 (2022, ICIJ) ^[44]	32.12	0.955	29.88	0.929	1.9	16.35
SharpFormer (2023, TIP) ^[45]	33.10	0.963	—	—	27.8	158.5
Mao等人 (2023, TCSVT) ^[46]	31.92	0.953	—	—	3.11	—
Zhao等人 (2023, TIM) ^[47]	32.73	0.959	31.05	0.940	16.5	—
HINet (2022, CVPR) ^[48]	33.08	0.962	30.66	0.936	22.3	85.6
FSNet (2024, TPAMI) ^[49]	33.29	0.963	31.05	0.941	13.28	111.14
RGE-Net (2024, TCSVT) ^[50]	32.60	0.958	30.39	0.933	2.58	33
Guo等人 (2025, EOC) ^[51]	31.87	0.952	29.38	0.922	—	—
Our_32	33.61	0.966	31.50	0.944	17.0	32
Our_64	33.85	0.967	31.55	0.946	67.9	126.4

表 2 在 REDS 数据集上的对比结果

指标	NAFNet ^[27]	MPRNet ^[39]	HINet ^[48]	MAXIM ^[52]	Our_32	Our_64
PSNR (dB)	29.09	28.79	28.83	28.93	29.08	29.27
SSIM	0.867	0.811	0.862	0.865	0.867	0.870

从表 1 中的实验数据可以看到本文模型在上述两个数据集中取得了卓越的性能表现. 在 32 通道设定下, 本文方法的性能已超越当前大部分去模糊算法. 该模型不仅在性能上得到了大幅提升, 同时还在参数量和计算量之间实现了良好的平衡. 为了进一步探索 PDBP-Net 性能极限, 本文同时训练了更大的 64 通道模型, 其性能表现超越了比较的其他方法. 具体地, 在 GoPro 数据集和 HIDE 测试集上的 PSNR 分别为 33.85 dB 和 31.55 dB, 排名第 1. 这表明了 PDBP-Net 具有很好的泛化性能, 能够应对不同模糊场景带来的挑战. 与其他辅助学习算法^[34,35,38]相比, 本文方法展现出了明显的优势, 这是由于 PDBP-Net 将辅助学习方法与渐进图像去模糊方法相结合, 正确感知图像模糊区域与程度, 从而精细化指导了高频特征重建. 与基于 Transformer 的方法^[49-51]相比, 本文方法用较小的算力取得了更优的性能. 此外, 这 3 种方法的局部建模能力不强, 难以感知图像中的模糊程度, 从而限制了模型的恢复能力.

如表 2 所示, 本文模型在 REDS 数据集上仍然表现良好, 即使在 32 通道的模型上已经得到了与 NAFNet 相当的结果. 64 通道的模型取得了第一的性能, PSNR 和 SSIM 分别达到了 29.27 dB 和 0.870. 综上所述, 本文提出的 PDBP-Net 模型在图像去运动模糊领域展现出了卓越的性能表现和泛化能力.

3.3 主观对比

除了客观评价之外, 本节还在合成模糊去除、真实模糊去除和失焦模糊去除等方面进行了主观对比, 以直观呈现 PDBP-Net 的恢复效果.

3.3.1 合成模糊去除效果

为了直观呈现本文方法在合成模糊去除方面的优越性, 本文在 GoPro 数据集和 HIDE 数据集上进行了可视化比较, 实验结果如图 8 所示.




图 8 合成模糊去除结果 PSNR 对比

由图 8 可知, 本文方法不仅取得了最优的 PSNR 值, 还在细节恢复方面取得较好效果. 具体地: 首先, PDBP-Net 在 GoPro 数据集上的去模糊效果 (图 8 第 1 行) 更好, 特别是在车轮边缘轮廓的恢复上, PDBP-Net 展现出了更精细的细节处理能力. 其次, 在第 2 行 HIDE 数据集的测试结果中, 其他模型对于相机抖动造成的背景模糊和人物车辆移动造成对象模糊恢复时会产生一定的伪影, 这影响了图像质量的直观感受. 相比之下, 本文模型对两种运动模糊都可以有效恢复. 特别是在处理背景中的玻璃条纹模糊和刻画运动中的人物面部时, PDBP-Net 展现出了更强的恢复能力. 在第 3 行中, 我们可以注意到 PDBP-Net 在处理路标、文字以及人物背影等细节丰富的区域时, 恢复效果同样出色. 与其他方法相比, PDBP-Net 没有产生不可控的退化现象, 保持了图像的原始结构和纹理信息.

3.3.2 真实模糊去除效果

为了验证模型在真实场景中的恢复性能, 除了在数据集上进行对比实验外, 本文还在相机拍摄的真实模糊场景中进行对比实验, 实验结果如图 9 所示. 通过对比真实场景下的恢复效果, 可以看到 PDBP-Net 在图像去运动模糊领域具有强大的泛化性能, 本文模型无论是在纹理细节的恢复上, 还是在色彩和形状的保持上, 恢复效果都更贴合人眼视觉感知. 具体地: 首先, PDBP-Net 对于文字恢复不会产生严重的边缘伪影 (图 9 中第 1 行和第 2 行), 线条恢复也更生动, 其他模型在恢复文字、物体等纹理细节时缺乏模糊程度的指导, 往往表现不佳. 其次, 对于区域特征变化幅度小的图像 (图 9 中第 3 行), PDBP-Net 也能够发现细小的模糊差异, 避免破坏原本图像中的非模糊位置, 使得图像中线条恢复效果更流畅, 同时防止了过度恢复图像造成物体轮廓不清晰等问题. 其他模型由于缺乏模糊感知的设计学习, 有的模型无法正常恢复清晰图像、有的模型则边缘恢复过度平滑, 甚至导致了物体色彩和形状的失真形变, 严重影响了图像的视觉质量.



图 9 真实模糊去除结果对比

3.3.3 失焦模糊去除效果

为了验证本文模型跨模糊类型的性能表现, 本节在 DPDD 数据集^[53]上进行了失焦模糊的去除实验, 实验结果如图 10 所示. 本文算法通过引入辅助学习方法重建了退化的高频细节, 在未引入任何失焦先验知识的情况下, 仍有较强的恢复能力, 验证了本文方法的泛化性能. 具体地: 首先, 在文本复原任务中 (图 10 第 1 行), 本文模型在有效保

持清晰区域完整性的同时还能精准定位模糊区域并重建文字边缘结构, 其 PSNR 指标较模糊图像提升了 2.93 dB. 其次, 在人像恢复方面 (图 10 第 2 行), 由于模糊感知模块的指导, 本文模型成功解耦了散焦噪声与人脸特征, 避免了常规方法中出现的五官畸变问题. 最后, 对于复杂物体场景 (图 10 第 3 行) 的海报复原, PDBP-Net 在细节保留、色彩还原和边缘锐化等方面都表现出了更好的性能.

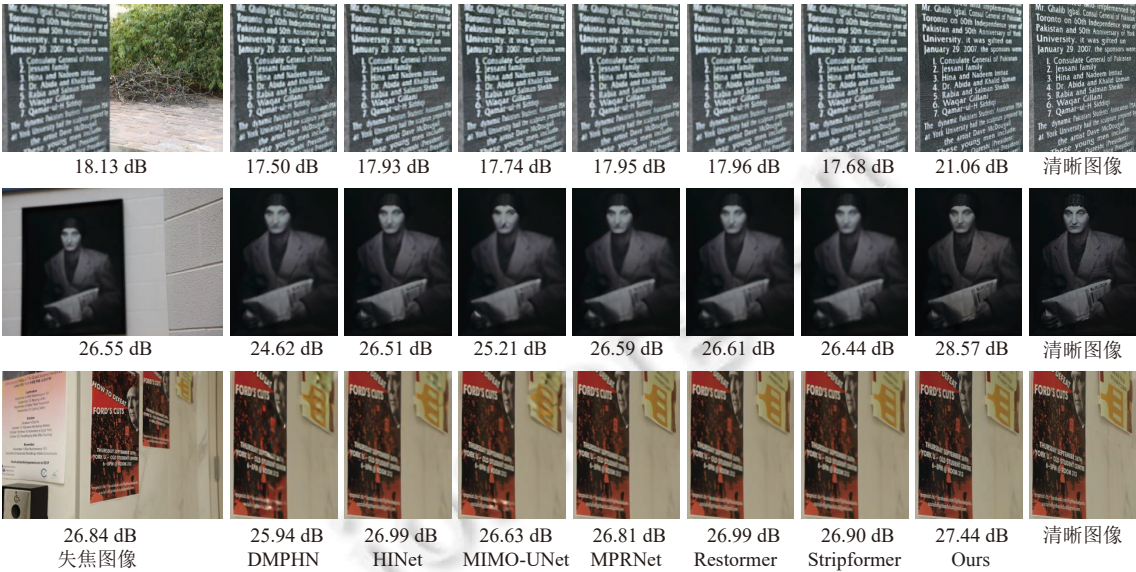


图 10 失焦去模糊 PSNR 结果对比

3.4 消融实验

本节通过多组实验来评估 PDBP-Net 中组件的有效性. 具体地, 本节验证了辅助学习、高频差异引导的模糊感知模块 (BPGHD) 和傅里叶损失的有效性. 本节的消融实验在 GoPro 数据集上进行, 实验结果如表 3 所示.

表 3 PDBP-Net 在 GoPro 数据集上的消融实验

实验编号	双层网络	辅助学习任务	BPGHD	傅里叶损失	PSNR (dB)	SSIM
a	×	×	×	×	32.85	0.960
b	×	√	×	×	33.24	0.963
c	√	√	×	×	33.38	0.964
d	√	√	√	×	33.58	0.965
e	√	√	√	√	33.61	0.966

3.4.1 辅助学习的有效性

为了验证辅助学习的有效性, 本文将通道为 32 的单层 NAFNet 网络作为模型的基线网络 (实验 a), 这意味着基线网络中不会生成高频差异特征, 模型只是从图像中提取空间特征. 然后, 本文在单层网络中加入辅助学习任务 (实验 b), 同时生成高频差异特征图和残差图. 正如预想的一样, 辅助学习方式可以有效提高模型的恢复能力. 相比于基线网络, 加入辅助学习方法的模型 PSNR 提升了 0.39 dB. 性能的提升是因为两个任务相辅相成, 从而能够生成更符合人类视觉感知的去模糊图. 由此可见, 高频差异信息对于恢复边缘轮廓十分关键, 从而印证了辅助学习的有效性.

3.4.2 BPGHD 模块的有效性

为了验证 BPGHD 模块的有效性, 本文在实验 b 的基础上加入了一个基线网络 (实验 c), 该基线网络的输入为实验 b 中的两个输出: 初步恢复图和高频差异特征图. 然后, 在 HDIRG-net 和 BPGDR-net 之间加入 BPGHD 模块 (实验 d). 通过对比实验 c 和实验 d 的结果可以看到, 加入 BPGHD 模块后 PSNR 的指标提升了 0.2 dB. 这是由于

BPGHD 模块可以有效融合上层子网络的两个输出,同时生成模糊感知特征图精确指导下层子网络的恢复.因此,上述实验验证了 BPGHD 模块的有效性.

3.4.3 傅里叶损失的有效性

为了验证傅里叶损失的有效性,本文在实验 d 的基础上加入了傅里叶损失做监督(实验 e).结果表明,加入傅里叶损失的方法的性能得到了进一步的提升.这是由于傅里叶损失可以弥补 BPGDR-net 不能进行高频特征监督的缺陷.因此,上述实验验证了傅里叶损失的有效性.

4 结 论

本文提出了模糊感知引导的渐进图像去模糊框架,该框架旨在通过子网络和模块之间的相互配合实现对模糊图像的精准恢复.首先,为了有效地学习清晰图像和模糊图像之间的高频差异特征,本文提出了高频差异与图像残差生成子网络,该子网络能够同时生成高频差异特征图和初步恢复图,为后续的去模糊处理提供了重要的先验信息.其次,为了融合高频差异特征图和残差图,本文设计了高频差异引导的模糊感知模块.该模块能够有效地利用高频差异信息,使得网络更加关注模糊位置和程度,从而生成了具有模糊感知的特征图.最后,在细节恢复阶段,提出了模糊感知指导的细节恢复子网络.该子网络在模糊感知特征的指导下,对图像进行精细化的去模糊处理,以恢复高质量的清晰图像.通过有机结合上述子网络和模块,本文方法能够实现对模糊图像的全面、精准恢复.为了验证该方法的优越性,我们进行了广泛的定量和定性评估.实验结果表明,与最先进的方法相比,本文方法取得了最优的去模糊效果.综上所述,所提方法能够提升图像去模糊处理的性能,具有较好的实用性,为图像去模糊领域的研究提供了不同的思路和方法.

在未来的研究工作中,我们将深入探讨频域中不同频段的特征对图像去模糊的影响机制.此外,轻量化的图像去模糊方法也是一个值得探索的研究方向.

References

- [1] Chan TF, Wong CK. Total variation blind deconvolution. *IEEE Trans. on Image Processing*, 1998, 7(3): 370–375. [doi: 10.1109/83.661187]
- [2] Levin A, Weiss Y, Durand F, Freeman WT. Understanding and evaluating blind deconvolution algorithms. In: *Proc. of the 2009 IEEE Conf. on Computer Vision and Pattern Recognition*. Miami: IEEE, 2009. 1964–1971. [doi: 10.1109/CVPR.2009.5206815]
- [3] Krishnan D, Fergus R. Fast image deconvolution using hyper-Laplacian priors. In: *Proc. of the 23rd Int'l Conf. on Neural Information Processing Systems*. Vancouver: Curran Associates Inc., 2009. 1033–1041. [doi: 10.5555/2984093.2984210]
- [4] Tang S, Wan SD, Yang SL, Xie XZ, Xia M, Zhang X. Spatial-scale-information method for motion blur kernel estimation. *Ruan Jian Xue Bao/Journal of Software*, 2019, 30(12): 3876–3891 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/5587.htm> [doi: 10.13328/j.cnki.jos.005587]
- [5] Jiang XL, Wang L, Luo XY, Wang SC, Luo SW. Forward-motion blurring kernel based on generalized motion blurring model. *Ruan Jian Xue Bao/Journal of Software*, 2016, 27(8): 2135–2146 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/4864.htm> [doi: 10.13328/j.cnki.jos.004864]
- [6] Li GP, Lu Y, Wang ZJ, Wu ZW, Wang SZ. Blurred image blind super-resolution network via kernel estimation. *Acta Automatica Sinica*, 2023, 49(10): 2109–2121 (in Chinese with English abstract). [doi: 10.16383/j.aas.c200987]
- [7] Wen F, Ying RD, Liu YP, Liu PL, Truong TK. A simple local minimal intensity prior and an improved algorithm for blind image deblurring. *IEEE Trans. on Circuits and Systems for Video Technology*, 2020, 31(8): 2923–2937. [doi: 10.1109/TCSVT.2020.3034137]
- [8] Bai YC, Jia HZ, Jiang M, Liu XM, Xie XD, Gao W. Single-image blind deblurring using multi-scale latent structure prior. *IEEE Trans. on Circuits and Systems for Video Technology*, 2019, 30(7): 2033–2045. [doi: 10.1109/TCSVT.2019.2919159]
- [9] Mao XT, Liu YM, Liu FZ, Li QL, Shen W, Wang Y. Intriguing findings of frequency selection for image deblurring. In: *Proc. of the 37th AAAI Conf. on Artificial Intelligence*. Washington: AAAI, 2023. 1905–1913. [doi: 10.1609/aaai.v37i2.25281]
- [10] Fang ZX, Wu FF, Dong WS, Li X, Wu JJ, Shi GM. Self-supervised non-uniform kernel estimation with flow-based motion prior for blind image deblurring. In: *Proc. of the 2023 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*. Vancouver: IEEE, 2023. 18105–18114. [doi: 10.1109/CVPR52729.2023.01736]
- [11] Ren DD, Li JB. Methods of image restoration and object detection in low-light environment. *Ruan Jian Xue Bao/Journal of Software*,

- 2019, 30(S1): 94–104 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/19010.htm>
- [12] Zhang XF, Li JJ. Single image de-raining using a recurrent dual-attention-residual ensemble network. *Ruan Jian Xue Bao/Journal of Software*, 2021, 32(10): 3283–3292 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6018.htm> [doi: 10.13328/j.cnki.jos.006018]
- [13] Chen JB, Xiong BS, Kuang F, Zhang ZZ. Motion deblurring based on deep feature fusion attention and double-scale. *Journal of Image and Graphics*, 2023, 28(12): 3731–3743 (in Chinese with English abstract). [doi: 10.11834/jig.220931]
- [14] Wu D, Zhao HT, Zheng SB. Motion deblurring method based on DenseNets. *Journal of Image and Graphics*, 2020, 25(5): 890–899 (in Chinese with English abstract). [doi: 10.11834/jig.190400]
- [15] Jin Y, Huang MJ, Jiang ZW. Image deblurring based on aggregate residual adversary networks. *Journal of Computer-aided Design & Computer Graphics*, 2022, 34(1): 84–93 (in Chinese with English abstract). [doi: 10.3724/SP.J.1089.2022.18839]
- [16] Tang S, Wan SD, Xie XZ, Yang SL, Huang R, Gu J, Zheng WP. Multi-scale image blind deblurring network for dynamic scenes. *Ruan Jian Xue Bao/Journal of Software*, 2022, 33(9): 3498–3511 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6297.htm> [doi: 10.13328/j.cnki.jos.006297]
- [17] Liu Y, Fang FM, Wang TT, Li JC, Sheng Y, Zhang GX. Multi-scale grid network for image deblurring with high-frequency guidance. *IEEE Trans. on Multimedia*, 2022, 24: 2890–2901. [doi: 10.1109/TMM.2021.3090206]
- [18] Ji SW, Lee J, Kim SW, Hong JP, Baek SJ, Jung SW, Ko SJ. XYDeblur: Divide and conquer for single image deblurring. In: *Proc. of the 2022 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*. New Orleans: IEEE, 2022. 17400–17409. [doi: 10.1109/CVPR52688.2022.01690]
- [19] Tsai FJ, Peng YT, Lin YY, Tsai CC, Lin CW. Stripformer: Strip Transformer for fast image deblurring. In: *Proc. of the 17th European Conf. on Computer Vision*. Tel Aviv: Springer, 2022. 146–162. [doi: 10.1007/978-3-031-19800-7_9]
- [20] Jiang YQ, Zhang CN, Jin S, Liu J, Wang JP. CLG-INet: Coupled local-global interactive network for image restoration. In: *Proc. of the 31st ACM Int'l Conf. on Multimedia*. Ottawa: ACM, 2023. 7580–7589. [doi: 10.1145/3581783.3612251]
- [21] Nah S, Hyun Kim T, Mu Lee K. Deep multi-scale convolutional neural network for dynamic scene deblurring. In: *Proc. of the 2017 IEEE Conf. on Computer Vision and Pattern Recognition*. Honolulu: IEEE, 2017. 257–265. [doi: 10.1109/CVPR.2017.35]
- [22] Gao HY, Tao X, Shen XY, Jia JY. Dynamic scene deblurring with parameter selective sharing and nested skip connections. In: *Proc. of the 2019 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*. Long Beach: IEEE, 2019. 3843–3851. [doi: 10.1109/CVPR.2019.00397]
- [23] Purohit K, Rajagopalan AN. Region-adaptive dense network for efficient motion deblurring. In: *Proc. of the 34th AAAI Conf. on Artificial Intelligence*. New York: AAAI, 2020. 11882–11889. [doi: 10.1609/aaai.v34i07.6862]
- [24] Cho SJ, Ji SW, Hong JP, Jung SW, Ko SJ. Rethinking coarse-to-fine approach in single image deblurring. In: *Proc. of the 2021 IEEE/CVF Int'l Conf. on Computer Vision*. Montreal: IEEE, 2021. 4621–4630. [doi: 10.1109/ICCV48922.2021.00460]
- [25] Li HY, Zhang ZR, Jiang TT, Luo P, Feng HJ, Xu ZH. Real-world deep local motion deblurring. In: *Proc. of the 37th AAAI Conf. on Artificial Intelligence*. Washington: AAAI, 2023. 1314–1322. [doi: 10.1609/aaai.v37i1.25215]
- [26] Zhang YN, Li Q, Qi M, Liu D, Kong J, Wang JZ. Multi-scale frequency separation network for image deblurring. *IEEE Trans. on Circuits and Systems for Video Technology*, 2023, 33(10): 5525–5537. [doi: 10.1109/TCSVT.2023.3259393]
- [27] Chen LY, Chu XJ, Zhang XY, Sun J. Simple baselines for image restoration. In: *Proc. of the 17th European Conf. on Computer Vision*. Tel Aviv: Springer, 2022. 17–33. [doi: 10.1007/978-3-031-20071-7_2]
- [28] Zamir SW, Arora A, Khan S, Hayat M, Khan FS, Yang MH. Restormer: Efficient Transformer for high-resolution image restoration. In: *Proc. of the 2022 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*. New Orleans: IEEE, 2022. 5718–5729. [doi: 10.1109/CVPR52688.2022.00564]
- [29] Kong LS, Dong JX, Ge JJ, Li MQ, Pan JS. Efficient frequency domain-based Transformers for high-quality image deblurring. In: *Proc. of the 2023 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*. Vancouver: IEEE, 2023. 5886–5895. [doi: 10.1109/CVPR52729.2023.00570]
- [30] Tao X, Gao HY, Shen XY, Wang J, Jia JY. Scale-recurrent network for deep image deblurring. In: *Proc. of the 2018 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018. 8174–8182. [doi: 10.1109/CVPR.2018.00853]
- [31] Wan SD, Tang S, Xie XZ, Gu J, Huang R, Ma B, Luo L. Deep convolutional-neural-network-based channel attention for single image dynamic scene blind deblurring. *IEEE Trans. on Circuits and Systems for Video Technology*, 2021, 31(8): 2994–3009. [doi: 10.1109/TCSVT.2020.3035664]
- [32] Kupyn O, Budzan V, Mykhailych M, Mishkin D, Matas J. DeblurGAN: Blind motion deblurring using conditional adversarial networks. In: *Proc. of the 2018 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018. 8183–8192. [doi: 10.1109/CVPR.2018.00853]

- 1109/CVPR.2018.00854]
- [33] Kupyn O, Martyniuk T, Wu JR, Wang ZY. DeblurGAN-v2: Deblurring (orders-of-magnitude) faster and better. In: Proc. of the 2019 IEEE/CVF Int'l Conf. on Computer Vision. Seoul: IEEE, 2019. 8877–8886. [doi: [10.1109/ICCV.2019.00897](https://doi.org/10.1109/ICCV.2019.00897)]
 - [34] Chi ZX, Wang Y, Yu YH, Tang J. Test-time fast adaptation for dynamic scene deblurring via meta-auxiliary learning. In: Proc. of the 2021 IEEE/CVF Conf. on Computer Vision and Pattern Recognition. Nashville: IEEE, 2021. 9133–9142. [doi: [10.1109/CVPR46437.2021.00902](https://doi.org/10.1109/CVPR46437.2021.00902)]
 - [35] Fu ZC, Zheng YB, Ma TL, Ye H, Yang J, He L. Edge-aware deep image deblurring. *Neurocomputing*, 2022, 502: 37–47. [doi: [10.1016/j.neucom.2022.06.051](https://doi.org/10.1016/j.neucom.2022.06.051)]
 - [36] Zhao BX, Li WH, Gong WG. Real-aware motion deblurring using multi-attention CycleGAN with contrastive guidance. *Digital Signal Processing*, 2023, 135: 103953. [doi: [10.1016/j.dsp.2023.103953](https://doi.org/10.1016/j.dsp.2023.103953)]
 - [37] Zhao SY, Zhang Z, Hong RC, Xu ML, Yang Y, Wang M. FCL-GAN: A lightweight and real-time baseline for unsupervised blind image deblurring. In: Proc. of the 30th ACM Int'l Conf. on Multimedia. Lisboa: ACM, 2022. 6220–6229. [doi: [10.1145/3503161.3548113](https://doi.org/10.1145/3503161.3548113)]
 - [38] Li ZY, Gao Z, Yi H, Fu Y, Chen BA. Image deblurring with image blurring. *IEEE Trans. on Image Processing*, 2023, 32: 5595–5609. [doi: [10.1109/TIP.2023.3321515](https://doi.org/10.1109/TIP.2023.3321515)]
 - [39] Zamir SW, Arora A, Khan S, Hayat M, Khan FS, Yang MH, Shao L. Multi-stage progressive image restoration. In: Proc. of the 2021 IEEE/CVF Conf. on Computer Vision and Pattern Recognition. Nashville: IEEE, 2021. 14816–14826. [doi: [10.1109/CVPR46437.2021.01458](https://doi.org/10.1109/CVPR46437.2021.01458)]
 - [40] Shen ZY, Wang WG, Lu XK, Shen JB, Ling HB, Xu TF, Shao L. Human-aware motion deblurring. In: Proc. of the 2019 IEEE/CVF Int'l Conf. on Computer Vision. Seoul: IEEE, 2019. 5571–5580. [doi: [10.1109/ICCV.2019.00567](https://doi.org/10.1109/ICCV.2019.00567)]
 - [41] Chu XJ, Chen LY, Chen CP, Lu X. Improving image restoration by revisiting global information aggregation. In: Proc. of the 17th European Conf. on Computer Vision. Tel Aviv: Springer, 2022. 53–71. [doi: [10.1007/978-3-031-20071-7_4](https://doi.org/10.1007/978-3-031-20071-7_4)]
 - [42] Whang J, Delbracio M, Talebi H, Saharia C, Dimakis AG, Milanfar P. Deblurring via stochastic refinement. In: Proc. of the 2022 IEEE/CVF Conf. on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022. 16272–16282. [doi: [10.1109/CVPR52688.2022.01581](https://doi.org/10.1109/CVPR52688.2022.01581)]
 - [43] Zhang J, Zhai WM. Blind attention geometric restraint neural network for single image dynamic/defocus deblurring. *IEEE Trans. on Neural Networks and Learning Systems*, 2023, 34(11): 8404–8417. [doi: [10.1109/TNNLS.2022.3151099](https://doi.org/10.1109/TNNLS.2022.3151099)]
 - [44] Lv JT, Pan JS. Lightweight deep deblurring model with discriminative multi-scale feature fusion. In: Proc. of the 2023 IEEE Int'l Conf. on Image Processing. Kuala Lumpur: IEEE, 2023. 3065–3069. [doi: [10.1109/ICIP49359.2023.10222723](https://doi.org/10.1109/ICIP49359.2023.10222723)]
 - [45] Yan QS, Gong D, Wang P, Zhang Z, Zhang YN, Shi JQ. SharpFormer: Learning local feature preserving global representations for image deblurring. *IEEE Trans. on Image Processing*, 2023, 32: 2857–2866. [doi: [10.1109/TIP.2023.3251029](https://doi.org/10.1109/TIP.2023.3251029)]
 - [46] Mao YX, Wan ZX, Dai YC, Yu X. Deep idempotent network for efficient single image blind deblurring. *IEEE Trans. on Circuits and Systems for Video Technology*, 2023, 33(1): 172–185. [doi: [10.1109/TCSVT.2022.3202361](https://doi.org/10.1109/TCSVT.2022.3202361)]
 - [47] Zhao Q, Yang H, Zhou DM, Cao JD. Rethinking image deblurring via CNN-Transformer multiscale hybrid architecture. *IEEE Trans. on Instrumentation and Measurement*, 2023, 72: 5002415. [doi: [10.1109/TIM.2022.3230482](https://doi.org/10.1109/TIM.2022.3230482)]
 - [48] Chen LY, Lu X, Zhang J, Chu XJ, Chen CP. HINet: Half instance normalization network for image restoration. In: Proc. of the 2021 IEEE/CVF Conf. on Computer Vision and Pattern Recognition. Nashville: IEEE, 2021. 182–192. [doi: [10.1109/CVPRW53098.2021.00027](https://doi.org/10.1109/CVPRW53098.2021.00027)]
 - [49] Cui YN, Ren WQ, Cao XC, Knoll A. Image restoration via frequency selection. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2024, 46(2): 1093–1108. [doi: [10.1109/TPAMI.2023.3330416](https://doi.org/10.1109/TPAMI.2023.3330416)]
 - [50] Chen J, Ye SL, Chen G, Atlaw MM, Lin L, Zhang YN. Lightweight image deblurring via recurrent gated attention and efficient decoupling. *IEEE Trans. on Circuits and Systems for Video Technology*, 2025, 35(2): 1814–1824. [doi: [10.1109/TCSVT.2024.3484392](https://doi.org/10.1109/TCSVT.2024.3484392)]
 - [51] Guo YC, Yang G, Mao XN. A multi-scale structure image deblurring method integrating Transformer. *Electronics Optics & Control*, 2025, 32(3): 62–68 (in Chinese with English abstract). [doi: [10.3969/j.issn.1671-637X.2025.03.010](https://doi.org/10.3969/j.issn.1671-637X.2025.03.010)]
 - [52] Tu ZZ, Talebi H, Zhang H, Yang F, Milanfar P, Bovik A, Li YX. MAXIM: Multi-axis MLP for image processing. In: Proc. of the 2022 IEEE/CVF Conf. on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022. 5759–5770. [doi: [10.1109/CVPR52688.2022.00568](https://doi.org/10.1109/CVPR52688.2022.00568)]
 - [53] Abuolaim A, Brown MS. Defocus deblurring using dual-pixel data. In: Proc. of the 16th European Conf. on Computer Vision. Glasgow: Springer, 2020. 111–126. [doi: [10.1007/978-3-030-58607-2_7](https://doi.org/10.1007/978-3-030-58607-2_7)]

附中文参考文献

- [4] 唐述, 万盛道, 杨书丽, 谢显中, 夏明, 张旭. 空间尺度信息的运动模糊核估计方法. 软件学报, 2019, 30(12): 3876–3891. <http://www.jos.org.cn/1000-9825/5587.htm> [doi: 10.13328/j.cnki.jos.005587]
- [5] 蒋欣兰, 王亮, 罗晓月, 王胜春, 罗四维. 基于广义运动模糊模型的前向运动模糊核. 软件学报, 2016, 27(8): 2135–2146. <http://www.jos.org.cn/1000-9825/4864.htm> [doi: 10.13328/j.cnki.jos.004864]
- [6] 李公平, 陆耀, 王子建, 吴紫薇, 汪顺舟. 基于模糊核估计的图像盲超分辨率神经网络. 自动化学报, 2023, 49(10): 2109–2121. [doi: 10.16383/j.aas.c200987]
- [11] 任东东, 李金宝. 低光照环境下的图像恢复与目标识别方法. 软件学报, 2019, 30(S1): 94–104. <http://www.jos.org.cn/1000-9825/19010.htm>
- [12] 张学锋, 李金晶. 基于双注意力残差循环单幅图像去雨集成网络. 软件学报, 2021, 32(10): 3283–3292. <http://www.jos.org.cn/1000-9825/6018.htm> [doi: 10.13328/j.cnki.jos.006018]
- [13] 陈加保, 熊邦书, 况发, 章照中. 深度特征融合注意力与双尺度的运动去模糊. 中国图象图形学报, 2023, 28(12): 3731–3743. [doi: 10.11834/jig.220931]
- [14] 吴迪, 赵洪田, 郑世宝. 密集连接卷积网络图像去模糊. 中国图象图形学报, 2020, 25(5): 890–899. [doi: 10.11834/jig.190400]
- [15] 金燕, 黄梦佳, 姜智伟. 基于聚集残差生成对抗网络的图像去模糊. 计算机辅助设计与图形学学报, 2022, 34(1): 84–93. [doi: 10.3724/SP.J.1089.2022.18839]
- [16] 唐述, 万盛道, 谢显中, 杨书丽, 黄容, 顾佳, 郑万鹏. 一种多尺度的图像动态场景盲去模糊网络. 软件学报, 2022, 33(9): 3498–3511. <http://www.jos.org.cn/1000-9825/6297.htm> [doi: 10.13328/j.cnki.jos.006297]
- [51] 郭业才, 阳刚, 毛湘南. 一种融合 Transformer 的多尺度结构图像去模糊方法. 电光与控制, 2025, 32(3): 62–68. [doi: 10.3969/j.issn.1671-637X.2025.03.010]

作者简介

胡波, 博士, 副教授, 博士生导师, 主要研究领域为图像质量评价视频画质提升与评价, 图像视频去模糊, 图像视频质量评价, 图像美学评价.

田镕澳, 硕士, 主要研究领域为图像去模糊.

郑佳, 硕士, 主要研究领域为图像质量评价.

龚兵兵, 硕士生, 主要研究领域为图像去模糊.

高新波, 博士, 教授, 博士生导师, CCF 会士, 主要研究领域为人工智能与知识发现, 模式识别, 图像处理.