

基于增强多尺度特征网络的图像去模糊

虞志军, 王国栋*, 张镠月

青岛大学计算机科学技术学院, 山东 青岛 266071

摘要 现有的多尺度多阶段图像去模糊方法存在多尺度图像特征提取利用不充分和阶段加深导致特征信息丢失的问题。针对上述问题,提出了一种基于增强多尺度特征网络的图像去模糊方法。首先,提出一个多尺度残差特征提取模块,在两个分支中使用不同大小的卷积核扩大感受野,充分提取不同分辨率大小图像的特征信息。其次,提出跨阶段注意力模块,过滤和传递图像的关键特征。最后,设计类似于跳跃连接的跨阶段特征融合模块,弥补特征损失,同时融合来自不同大小输入图像的特征信息,丰富空间特征信息,以更好地处理纹理细节。在 GoPro 和 HIDE 数据集上的实验结果表明,所提方法能够很好地重建图像。

关键词 图像去模糊; 多尺度特征; 跨阶段注意力机制; 跨阶段特征融合

中图分类号 TP751.1 **文献标志码** A

DOI: 10.3788/LOP202259.2215007

Image Deblurring Based on Enhanced Multiscale Feature Network

Yu Zhijun, Wang Guodong*, Zhang Xinyue

College of Computer Science & Technology, Qingdao University, Qingdao 266071, Shandong, China

Abstract Recently, multiscale and multistage image deblurring methods have encountered issues such as insufficient multiscale image feature extraction and loss of feature information due to stage deepening. To address the above problems, an image deblurring method based on an enhanced multiscale feature network is proposed in this paper. First, a multiscale residual feature extraction module is proposed, and convolution kernels with various sizes are used in the two branches to expand the receptive field and fully extract the feature information of images with various resolution sizes. Second, a cross-stage attention module is proposed to filter and transfer the key features of the image. Finally, a cross-stage feature fusion module, similar to a jump connection, is designed to compensate for feature loss and fuse feature information from input images with various sizes, to enrich spatial feature information, and to improve texture processing. Experimental results on the GoPro and HIDE datasets show that the proposed method can successfully reconstruct the image.

Key words image deblurring; multi-scale feature; cross-stage attention mechanism; cross-stage feature fusion

1 引言

图像作为人类获取信息的主要来源,模糊的图像会增加获取信息的难度,降低获取信息的准确性,因此需要采取某些手段对模糊图像进行处理。近几十年来,图像去模糊在计算机视觉和图像处理领域得到了更多的关注,在 Fergus 等^[1]和 Shan 等^[2]的开创性工作之后,为了适应不同的应用场景,追求更高的恢复质量,更多优秀去模糊算法相继被提出。传统的去模糊算法包括基于变分和差分的方法^[3]、基于稀疏图像先验的方法^[4-7]、基于梯度先验的方法^[8-9]及基于已知模糊

核的方法^[10]等,这些方法需要先验条件才能重建清晰图像,应用场景有限且恢复图像不够清晰,无法满足实际应用需求。

近年来,随着深度学习在研究和应用上取得的进展,卷积神经网络(CNN)被广泛应用在图像去模糊领域^[11-24],在网络模型确定的情况下,训练时只需要将模糊的图像作为输入,将真实的清晰图像作为期望输出,训练过程中将自动学习模糊核用于图像重建。Nah 等^[25]通过端到端的网络直接恢复清晰图像,但该网络只对少数模糊类处理效果较好。为了处理更多类型的模糊,Zhang 等^[26]在端到端的基础上引入残差结构并

收稿日期: 2021-08-27; 修回日期: 2021-09-20; 录用日期: 2021-10-13

基金项目: 山东省自然科学基金(ZR2019MF050)、山东省高等学校优秀青年创新团队支持计划(2020KJN011)

通信作者: *doctorwgd@gmail.com

加深网络深度;Zamir 等^[27]通过注意力机制过滤特征信息,使网络更加关注有利于重建清晰图像的特征;此外,Kupyn 等^[28-29]提出通过学习提取输入图像特征,直接生成清晰图像的生成对抗网络(GAN);祁清等^[30]在生成对抗网络中加入图像边缘判别机制,该机制对去除大幅度模糊图像和运动模糊效果明显,证明边缘判别机制在图像边缘恢复中的重要作用;宋昊泽等^[31]在 GAN 基础上,将自编码部分修改为密集网络结构,通过多尺度的池化和上采样扩大感受野,提升算法的图像去模糊能力。

近年来的去模糊 SOTA (state-of-the-art) 方法更注重网络结构创新,将去模糊的问题分为更小的子问题,通过对子问题进行求解得到最终解。Ren 等^[32]将去模糊任务分为多个阶段,以由“粗”到“精”的方式逐步恢复清晰图像,证明将具有挑战性的去模糊任务划分为多个子任务的策略是有效的。Zhang 等^[26]将网络分为四个阶段,通过残差连接将四个网络结构相同的子网络结合,但是每个阶段采用相同的网络结构,得到次优的结果。Tao 等^[33]在多阶段网络的基础上提出多尺度递归方案,该方案将向下采样得到的分辨率更小的图像作为输入,通过由残差块组成的编码器-解码器结构,能很好地恢复清晰图像。Zamir 等^[27]通过多尺度补丁模型,利用不同尺度上的去模糊线索,将残差特征线索传递到下一阶段,同时利用跨阶段特征融合和监督注意力模块加强特征处理,实现了目前最好的图像去模糊效果。当前基于卷积神经网络的多阶段方法也存在局限性:首先,每个阶段输入图像的分辨率大小不一致,上述方法未充分利用不同分辨率大小图像中所包含的空间信息;其次,缺少有效的特征融合策略,图像特征信息在传输到下一阶段过程中许多关键特征丢失;最后,需要采取监督和引导机制,连接所有阶段共同发挥作用,提升网络整体性能。

针对上述问题,本文提出基于增强多尺度特征网络的图像去模糊方法。所提方法的主要贡献为:1)提出增强的多尺度残差特征提取模块,该模块两个支路使用不同大小的卷积核,通过不同的感受野,能够更好地提取图像中的不同尺度特征信息;2)设计跨阶段注意力模块和跨阶段特征融合模块,结合前后两个阶段的多尺度残差特征,弥补特征在不同阶段间传输的损失,丰富空间特征信息,同时引导后一阶段的特征信息处理;3)设计新的能量损失函数计算方式,根据每个阶段对恢复清晰图像的贡献,决定其在总损失函数中的占比,该方式能够有效地提升模型训练效果。在两个公共数据集上的实验结果表明,所提方法恢复的图像更加清晰,细节部分处理得更好。

2 所提方法内容

所提方法的网络模型如图 1 所示,包含用于提取多尺度图像特征的多尺度残差特征提取模块(EMSR)、过滤重要特征信息的跨阶段注意力模块(CSA)、弥补和丰富特征空间信息的跨阶段特征融合模块(CFF)、用于重建清晰图像由编码器(Encoder)和解码器(Decoder)组成的重建模块。其中虚线表示跨阶段注意力模块。

将去模糊问题分为三个阶段逐步求解。对于输入的模糊图像 B ,将其划分为更小分辨率的块,阶段三输入的图像大小为原图像的 1/4、阶段二为 1/2、阶段一输入为原图大小。经过特征提取、特征融合及编码器-解码器后,每个阶段都会得到重建的清晰图像,最终以阶段一的重建图像 R_1 作为输出的清晰图像,即

$$R_i = \text{Cat} [R_{ij}], R_{ij} = \text{Predict} (B_{ij}), i = 1, 2, 3, j = 1, 2, \dots, 2^{i-1}, \quad (1)$$

式中: B_{ij} 为第 i 阶段第 j 块的输入模糊图像; R_i 为恢复图像。

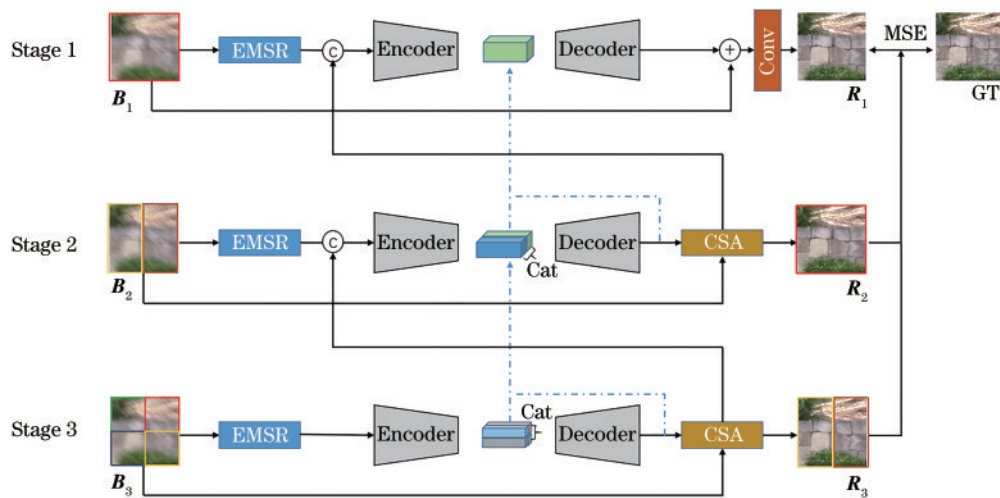


图 1 基于增强多尺度特征网络的图像去模糊方法

Fig. 1 Illustration of proposed image deblurring method based on enhanced multi-scale feature network

2.1 增强的多尺度残差特征提取模块

Zhang 等^[26]和 Zamir 等^[27]使用不同分辨率的图像作为输入,通过卷积核大小固定的简单残差块和密集连接的方式提取特征,该方法对图像的空间特征信息利用不足。Li 等^[34]在残差结构基础上提出多尺度残差块,该方法可以自适应地检测不同尺度上的图像特征,同时不同尺度特征信息之间能够共享和复用,提高特征提取的效率,减少网络的参数量。但 Li 等^[34]的方法通过叠加多个多尺度残差块提升特征提取能力,随着网络加深,浅层特征会逐渐丢失。

为了解决特征提取不充分和特征丢失的问题,提出如图 2 所示的增强的多尺度特征提取模块。其中多尺度残差块(MSRB)包含一个双通道特征提取器,卷积层利用不同大小的卷积核扩大感受野,两个通道

间通过残差方式连接,共享不同尺度的图像特征信息,最后通过 1×1 的卷积层融合两个通道的特征,操作为

$$C_1 = \beta_3(M_{n-1}), T_1 = \beta_5(M_{n-1}), \quad (2)$$

$$C_2 = \beta_5(\text{Cat}[C_1, T_1]), T_2 = \beta_3(\text{Cat}[T_1, C_1]), \quad (3)$$

$$M_n = \beta_1(\text{Cat}[C_2, T_2]) + M_{n-1}, \quad (4)$$

式中: β_c 表示卷积层和激活层, c 表示在该层中使用的卷积核的大小; M_n 表示第 n 个多尺度残差块的输入; $\text{Cat}[\cdot]$ 表示拼接操作。设 M 表示多尺度残差块的特征图的数量,经过式(2)中的卷积和 ReLU 操作后生成 M 个特征图,共享两个通道的特征,后经过式(3)操作生成 $2M$ 个特征图,所有特征图连接后,如式(4),使用 1×1 卷积层进行特征融合得到 M 个特征图。




图 2 增强的多尺度残差特征提取模块

Fig. 2 Enhanced multi-scale residual feature extracted module

特征提取模块通过使用多个多尺度残差块堆叠来增强特征提取能力,并通过残差连接方式融合所有多尺度残差块的输出特征,弥补网络加深带来的特征损失,加快网络收敛。令 F_c 为卷积层输出,则增强的多尺度特征提取模块的操作描述为

$$F_{out} = \text{Cat}[F_c + M_1 + \dots + M_n]. \quad (5)$$

2.2 特征融合与重建

重建模块如图 3(a)所示,由与 U-Net 结构^[35]类似的编码器-解码器组成。编码器的作用是对输入的图像特征进行下采样,将高维空间特征投影至低维空间,达到减少参数量和优化图像特征的目的;解码器对压缩后的特征进行重建,并还原至输出大小。编码器通过跳跃连接与解码器连接,提升对图像局部和纹理细

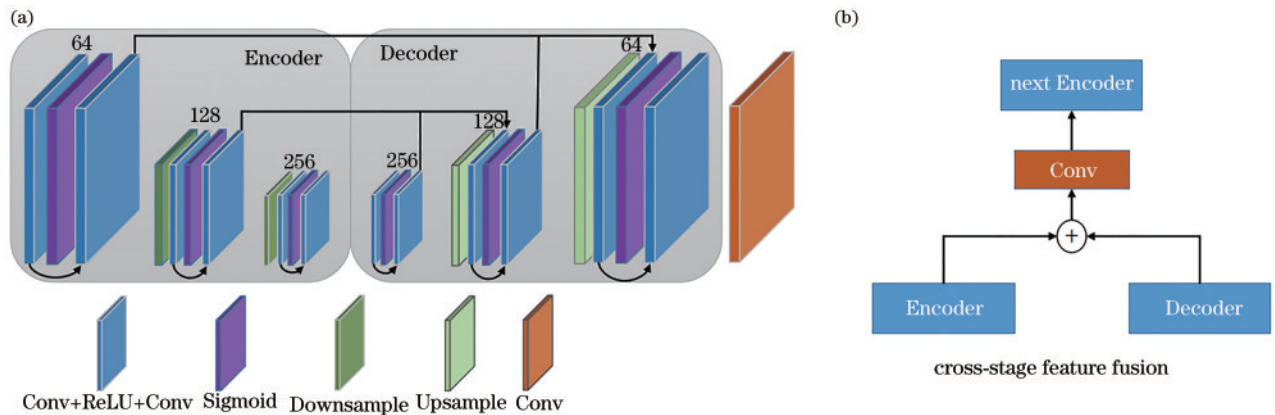


图 3 重建模块以及跨阶段特征融合模块。(a)重建模块;(b)跨阶段特征融合模块

Fig. 3 Illustration of the reconstruction module and the cross-stage feature fusion module. (a) Reconstruction module; (b) cross-stage feature fusion module

节的恢复效果,同时加速网络收敛并减少梯度消失和梯度爆炸的风险。

编码器与解码器包含由卷积层、激活层和卷积层组成的残差块,每一个尺度包含两个通过残差连接的不同残差块,残差块之间使用一个 Sigmoid 层过滤特征,使网络更关注对恢复清晰图像有利的特征信息。与 U-Net 在上下采样时对特征图的大小进行缩放,增减特征通道数相同,所提方法在进行上下采样时,对图像大小进行缩放的同时增减特征通道数。如图 3(a) 所示,输入编码器的特征通道数为 64,经过两次卷积核大小为 3、步长为 2 的卷积后,图像缩小至原来的 1/4,通道数增加至 256,解码器中的操作则与编码器的操作相反,最后使用 1×1 卷积整合细化特征。

现有的去模糊工作^[26,30,33,35]证明了编码器-解码器结构在上下文信息提取上的重要作用,但不利于图像空间特征信息的传递。因此本文提出一种跨阶段的特征融合方法,如图 3(b) 所示,能够将编码器-解码器中的空间特征信息更好地传递到后续阶段,提升恢复图像的质量。

跨阶段特征融合模块中,来自编码器和解码器的

特征进行像素级的相加,由 1×1 卷积层对特征进行细化,再传输到下一阶段编码器,按照对应的采样尺度进行特征融合,这样有利于减少上下采样导致的信息丢失,同时融合不同尺度图像的特征,能丰富下一阶段的空间特征信息,保留更多的图像细节特征。

2.3 跨阶段注意力模块

图像分类^[36]等任务中常使用注意力机制过滤特征,让网络更加关注图像的细节信息。受到 Purohit 等^[37]及 Suin 等^[38]的启发,所提方法在每两个阶段之间通过跨阶段注意力模块监督模型学习,使网络关注有利于重建清晰图像的特性信息。跨阶段注意力模块如图 4 所示,首先将模糊图像与自重建模块的特征相加,得到 R_i (R_i 是第 i 阶段恢复的清晰图像);然后通过 1×1 的卷积和 Sigmoid 函数生成注意力特征图;最后对特征图与来自解码器的特征进行点乘,经过 1×1 的卷积对特征进行细化,过滤掉弱图像特征,留下重要特征传输至下一阶段。跨阶段注意力模块的优点为:首先每个阶段都生成清晰图像,通过与真实清晰图像的对比反馈,监督引导网络的训练;其次注意力模块能够过滤掉无用特征,留下重要特征,使恢复图像的局部和细节更加清晰。




图 4 跨阶段注意力模块

Fig. 4 Cross-stage attention architecture

2.4 损失函数

所提方法使用恢复的清晰图像与真实的清晰图像的均方误差作为损失函数,损失函数定义为

$$L = \frac{1}{n} \sum_{j=1}^n \sum_{i=1}^3 \lambda_i \|R_i - R_{GT}\|^2, \quad (6)$$

式中: R_{GT} 为真实的清晰图像; λ_i 为第 i 阶段的损失占比。深度学习中的模型蒸馏方法表明:使用训练好的大模型引导小模型进行训练能够提升小模型的最终效果。根据模型蒸馏的思想,实验中阶段一到阶段三的 λ 值分别设置为 0.7, 0.2, 0.1。训练过程中,前两个阶段将引导最后阶段的特征学习,但不起决定作用。消融实验结果表明,该能量损失函数对网络训练效果有较大提升。

3 实验结果与分析

实验的环境为 Linux 操作系统,深度学习框架为 pytorch,使用 cuda10.1 和 cudnn 加速实验,显卡为 NVIDIA Tesla V100。

3.1 数据集及网络参数设置

所提方法在 GoPro 数据集^[25]上训练,在 GoPro 和 HIDE 数据集^[39]上进行评估。GoPro 数据集由 3214 对模糊图像和清晰图像对组成,这些图像来自于 720×1280 分辨率视频序列,其中 2103 对图像作为训练集,1111 对图像作为测试集。训练所提基于多尺度增强特征网络的去模糊方法时,将 GoPro 训练集图像随机裁剪为 256×256 像素大小,并随机旋转 90° 、 180° 和 270° 对数据进行增广后作为网络训练时的输入;测试时使用 720×1280 分辨率的图像作为输入。根据网络结构分析实验结果,增强的多尺度残差特征提取模块中,多尺度残差块的数量为 4 且通道数为 64 时,网络模型去模糊效果最佳。训练时输入图像批处理大小为 8,使用 Adam 优化器^[40],其参数设置分别为 $\beta_1' = 0.9$ 和 $\beta_2' = 0.999$ 。共进行 1.5×10^5 次迭代,初始学习率为 1×10^{-4} ,每经过 2.5×10^4 次,迭代学习率衰减为原来的 1/2。

为了测试所提去模糊方法的泛化能力,实验中将 GoPro 数据集上训练得到的模型直接在 HIDE 测试集

上进行测试。HIDE 数据集共包含 8422 对模糊图像和清晰图像对,使用其中 2025 对图像作为测试集。

3.2 实验结果评价

对 GoPro 测试集进行去模糊处理,并使用峰值信噪比 (PSNR) 和结构相似度 (SSIM)^[26] 两个客观指标定量评价去模糊效果。PSNR 值越高,表示恢复出来的图像越清晰,越接近真实的图像;SSIM 值越接近 1,表明恢复的清晰图像和真实的清晰图像的结构相似度越高。

对所提方法和文献[10]、文献[26]、文献[27]、文

献[29]、文献[33]、文献[38]提出的方法进行比较。为了比较结果的公平性,使用作者提供的官方实现代码,在 GoPro 训练集上重新训练,然后使用 PSNR 和 SSIM 进行定量评价。表 1 展示了不同方法在 GoPro 测试集和 HIDE 测试集上测试得到的 PSNR 及 SSIM 平均值,与目前最好的去模糊方法文献[27]中的方法相比,所提方法在 GoPro 数据集上测试的 PSNR 值取得了 0.21 dB 的提升。

图 5 展示了所提方法与其他方法在 GoPro 数据集上的部分去模糊结果。与文献[26]和文献[27]中的方

表 1 不同方法在 GoPro 数据集和 HIDE 数据集上的去模糊结果

Table 1 Deblurring results of different methods on GoPro dataset and HIDE dataset

Method	Conference	GoPro		HIDE	
		PSNR /dB	SSIM	PSNR /dB	SSIM
Method in Ref. [10]	CVPR2014	23.54	0.822		
Method in Ref. [26]	CVPR2019	31.20	0.940	29.09	0.924
Method in Ref. [27]	CVPR2021	32.66	0.959	30.96	0.939
Method in Ref. [29]	ICCV2019	29.55	0.934	26.16	0.875
Method in Ref. [33]	CVPR2018	30.26	0.934	28.36	0.915
Method in Ref. [38]	CVPR2020	29.98	0.930	29.98	0.930
Proposed method		32.87	0.967	31.03	0.942

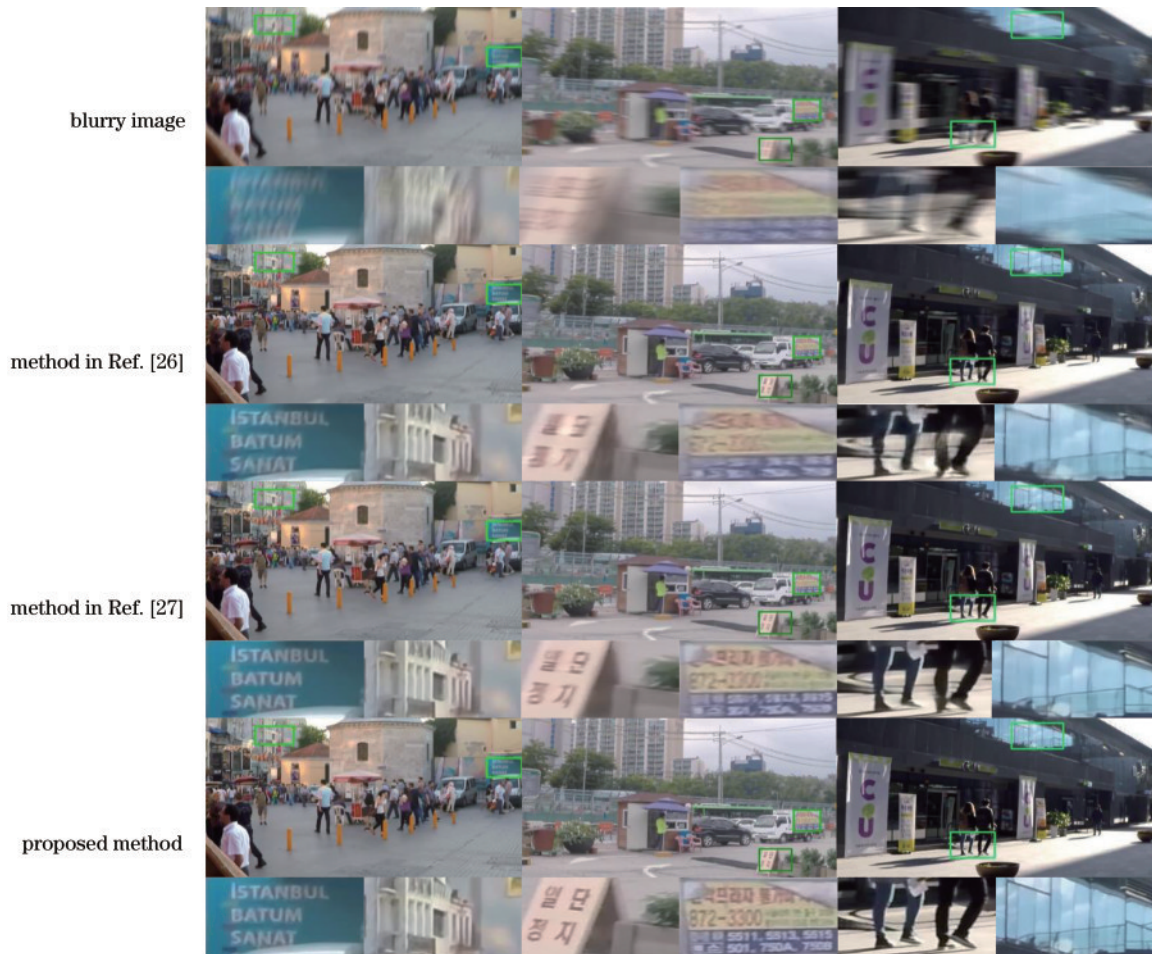


图 5 GoPro 数据集中去模糊结果可视化

Fig. 5 Visualization of deblurring results on the GoPro dataset

法相比,所提方法能够更好地解决各种运动引起的模糊问题,并且重建后的图像更加接近真实的清晰图像。文献[26]中的方法将去模糊任务分为四个阶段,每个阶段包含一个由密集残差块构成的编码器-解码器,上一阶段的输出作为下一阶段的输入,不同阶段之间缺少特征融合策略,导致许多图像局部信息和细节信息丢失,无法很好地恢复清晰图像。所提方法使用与文献[27]中的方法相同的多阶段式网络架构,每个阶段以不同分辨率大小的图像作为输入。然而文献[27]中的方法忽略了不同大小图像所包含的空间特征信息不同的内容,采用的特征提取方法提取特征不充分,导致最终恢复的图像在细节部分和图像局部

处理不足。

将在 GoPro 数据集上训练的模型直接应用在 HIDE 测试集上测试泛化能力。图 6 展示了 HIDE 测试集上部分图像的去模糊结果。同样地,将文献[26]和文献[27]中的方法应用在 HIDE 数据集上进行测试,并与所提方法的结果进行对比。从图 5 去模糊的结果可知,所提方法重建的清晰图像更加接近真实图像,与其他方法相比,所提方法在消除图像运动模糊的同时在图像局部和细节纹理上处理得更好,恢复的图像中运动物体的边缘更加清晰。泛化实验结果如图 6 所示,所提方法的泛化能力更强,具有很好的鲁棒性,证明所提方法的实用性。

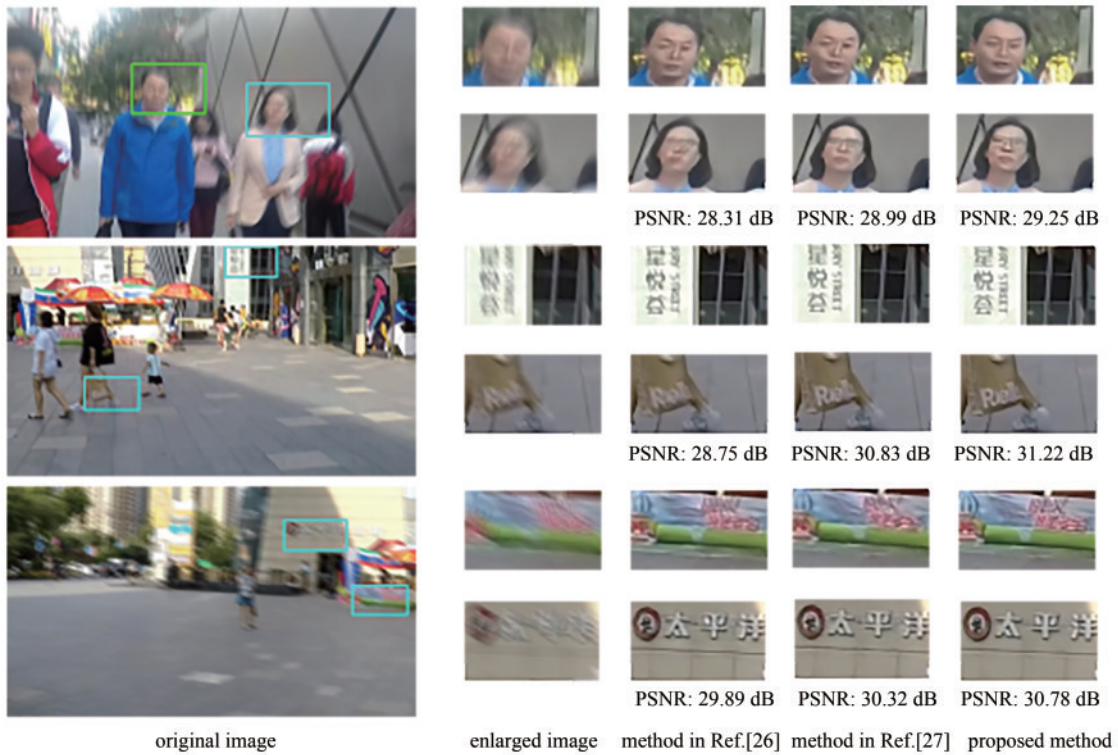


图 6 HIDE 数据集去模糊结果可视化

Fig. 6 Visualization of deblurring results on the HIDE dataset

3.3 网络结构分析实验

通过网络结构的消融实验,证明所提方法中增强多尺度特征提取模块、跨阶段特征融合模块(CSFF)及跨阶段注意力模块(CSA)的有效性,同时对提出的能量损失函数的作用进行验证。

消融实验中,使用 GoPro 数据集,将图像随机裁剪为 256×256 大小作为输入,分别测试在多尺度残差块(MSRB)数量为 4 的情况下,其他模块对网络性能产生的影响,以及增加多尺度残差块数量对去模糊性能的影响,实验结果如表 2 所示。多尺度残差块数量为 4 时,不使用跨阶段特征融合模块、跨阶段注意力模块及能量函数,网络的去模糊性能下降。去除跨阶段融合模块时,模型整体性能下降最大,证明所提方法中的跨阶段特征融合模块能够有效地保留上下文不同尺度的

表 2 消融实验结果

Table 2 Results of ablation experiment

Method	Number of MSRB	CSA	CSFF	Loss	PSNR / dB	SSIM
Base model	4	✓	✓	✓	32.87	0.967
EMF-block4	4	×	✓	✓	31.35	0.944
EMF-block4	4	✓	×	✓	30.50	0.931
EMF-block4	4	✓	✓	×	32.53	0.960
EMF-block6	6	✓	✓	✓	32.88	0.967
EMF-block8	8	✓	✓	✓	32.50	0.959

图像特征信息,弥补随阶段加深带来的特征损失。此外,在其他条件相同的情况下,使用 6 个多尺度残差块对模型去模糊效果提升非常小,反而增加网络的参数

量,延长网络运行时间;在使用 8 个多尺度残差块时,网络的性能反而下降,其原因是过多堆叠多尺度残差块加深了网络的深度,提取到的冗余特征较多,不利于后续对图像特征信息的处理,导致模型效果变差。

4 结 论

针对当前多阶段图像去模糊方法对不同尺度图像特征的提取利用不足和随阶段加深带来的特征丢失的问题,提出基于增强多尺度特征网络的图像去模糊方法。该方法利用多尺度特征提取模块充分提取不同尺度图像所包含的特征信息,同时使用跨阶段的注意力机制和特征融合方法,减少特征损失,丰富图像空间特性信息。针对多阶段式网络结构的训练,改进能量函数,提升了多阶段式网络结构的效果。实验结果表明,所提方法在重建清晰图像方面取得了更好的性能,下一步将继续优化方法,减少方法的运行时间,优化模型参数。

参 考 文 献

- [1] Fergus R, Singh B, Hertzmann A, et al. Removing camera shake from a single photograph[J]. *ACM Transactions on Graphics*, 2006: 787-794.
- [2] Shan Q, Jia J Y, Agarwala A. High-quality motion deblurring from a single image[J]. *ACM Transactions on Graphics*, 2008, 27(3): 1-10.
- [3] Chan T F, Wong C K. Total variation blind deconvolution[J]. *IEEE Transactions on Image Processing*, 1998, 7(3): 370-375.
- [4] Aharon M, Elad M, Bruckstein A. K-SVD: an algorithm for designing overcomplete dictionaries for sparse representation[J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4311-4322.
- [5] Luo Y, Xu Y, Ji H. Removing rain from a single image via discriminative sparse coding[C]//2015 IEEE International Conference on Computer Vision, December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 3397-3405.
- [6] Levin A, Weiss Y, Durand F, et al. Understanding and evaluating blind deconvolution algorithms[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition, June 20-25, 2009, Miami, FL, USA. New York: IEEE Press, 2009: 1964-1971.
- [7] Mairal J, Elad M, Sapiro G. Sparse representation for color image restoration[J]. *IEEE Transactions on Image Processing*, 2008, 17(1): 53-69.
- [8] Kim K I, Kwon Y. Single-image super-resolution using sparse regression and natural image prior[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 32(6): 1127-1133.
- [9] Xu L, Zheng S C, Jia J Y. Unnatural L0 sparse representation for natural image deblurring[C]//2013 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2013, Portland, OR, USA. New York: IEEE Press, 2013: 1107-1114.
- [10] Kim T H, Lee K M. Segmentation-free dynamic scene deblurring[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE Press, 2014: 2766-2773.
- [11] Wang Z, 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.
- [12] Rozumnyi D, Oswald M R, Ferrari V, et al. DeFMO: deblurring and shape recovery of fast moving objects[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 3455-3464.
- [13] Zhang K H, Luo W H, Zhong Y R, et al. Deblurring by realistic blurring[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 2734-2743.
- [14] Pan J S, Bai H R, Tang J H. Cascaded deep video deblurring using temporal sharpness prior[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 3040-3048.
- [15] Seets T, Ingle A, Laurenzis M, et al. Motion adaptive deblurring with single-photon cameras[C]//2021 IEEE Winter Conference on Applications of Computer Vision, January 3-8, 2021, Waikoloa, HI, USA. New York: IEEE Press, 2021: 1944-1953.
- [16] Jiang Z, Zhang Y, Zou D Q, et al. Learning event-based motion deblurring[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 3317-3326.
- [17] Brooks T, Mildenhall B, Xue T F, et al. Unprocessing images for learned raw denoising[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 11028-11037.
- [18] Yuan Y, Su W, Ma D D. Efficient dynamic scene deblurring using spatially variant deconvolution network with optical flow guided training[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 3552-3561.
- [19] Zhang Y L, Li K P, Li K, et al. Residual non-local attention networks for image restoration[EB/OL]. (2019-03-24)[2021-04-05]. <https://arxiv.org/abs/1903.10082>.
- [20] Dai T, Cai J R, Zhang Y B, et al. Second-order attention network for single image super-resolution[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 11057-11066.
- [21] Zamir S W, Arora A, Khan S, et al. CycleISP: real image restoration via improved data synthesis[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA,

- USA. New York: IEEE Press, 2020: 2693-2702.
- [22] 陈永, 郭红光, 艾亚鹏. 基于双域分解的多尺度深度学习单幅图像去雾[J]. 光学学报, 2020, 40(2): 0210003.
Chen Y, Guo H G, Ai Y P. Single image dehazing of multiscale deep-learning based on dual-domain decomposition[J]. Acta Optica Sinica, 2020, 40(2): 0210003.
- [23] 唐睢, 王凯强, 张维, 等. 一种基于深度学习的光学合成孔径成像系统图像复原方法[J]. 光学学报, 2020, 40(21): 2111001.
Tang J, Wang K Q, Zhang W, et al. Deep learning based image restoration method of optical synthetic aperture imaging system[J]. Acta Optica Sinica, 2020, 40(21): 2111001.
- [24] 胡芬, 林洋, 侯梦迪, 等. 基于深度学习的细胞骨架图像超分辨重建[J]. 光学学报, 2020, 40(24): 2410001.
Hu F, Lin Y, Hou M D, et al. Super-resolution reconstruction of cytoskeleton image based on deep learning[J]. Acta Optica Sinica, 2020, 40(24): 2410001.
- [25] Nah S, Kim T H, Lee K M. Deep multi-scale convolutional neural network for dynamic scene deblurring [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 257-265.
- [26] Zhang H G, Dai Y C, Li H D, et al. Deep stacked hierarchical multi-patch network for image deblurring [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 5971-5979.
- [27] Zamir S W, Arora A, Khan S, et al. Multi-stage progressive image restoration[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 14816-14826.
- [28] Kupyn O, Budzan V, Mykhailych M, et al. DeblurGAN: blind motion deblurring using conditional adversarial networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 8183-8192.
- [29] Kupyn O, Martyniuk T, Wu J R, et al. DeblurGAN-v2: deblurring (orders-of-magnitude) faster and better[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea (South). New York: IEEE Press, 2019: 8877-8886.
- [30] 祁清, 郭继昌, 陈善继. 基于图像边缘判别机制的盲图像去模糊方法[J]. 激光与光电子学进展, 2020, 57(24): 241022.
Qi Q, Guo J C, Chen S J. Blind image deblurring based on image edge determination mechanism[J]. Laser & Optoelectronics Progress, 2020, 57(24): 241022.
- [31] 宋昊泽, 吴小俊. 图像多尺度密集网络去模糊模型[J]. 激光与光电子学进展, 2019, 56(21): 211001.
Song H Z, Wu X J. Deblurring model of image multi-scale dense network[J]. Laser & Optoelectronics Progress, 2019, 56(21): 211001.
- [32] Ren D W, Zuo W M, Hu Q H, et al. Progressive image deraining networks: a better and simpler baseline[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 3932-3941.
- [33] Tao X, Gao H Y, Shen X Y, et al. Scale-recurrent network for deep image deblurring[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 8174-8182.
- [34] Li J, Fang F, Mei K, et al. Multi-scale residual network for image super-resolution[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer Vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11212: 517-532.
- [35] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science. Cham: Springer, 2015, 9351: 234-241.
- [36] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.
- [37] Purohit K, Rajagopalan A N. Region-adaptive dense network for efficient motion deblurring[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 11882-11889.
- [38] Suin M, Purohit K, Rajagopalan A N. Spatially-attentive patch-hierarchical network for adaptive motion deblurring [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 3603-3612.
- [39] Shen Z Y, Wang W G, Lu X K, et al. Human-aware motion deblurring[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea (South). New York: IEEE Press, 2019: 5571-5580.
- [40] Kingma D P, Ba J. Adam: a method for stochastic optimization[EB/OL]. (2014-12-22) [2021-04-05]. <https://arxiv.org/abs/1412.6980>.