

多局部残差连接注意网络的图像去模糊

陈清江 王巧莹

Image deblurring based on multiple local residual connection attention network

CHEN Qingjiang, WANG Qiaoying

引用本文:

陈清江, 王巧莹. 多局部残差连接注意网络的图像去模糊[J]. 应用光学, 2023, 44(2): 337–344. DOI: 10.5768/JAO202344.0202006

CHEN Qingjiang, WANG Qiaoying. Image deblurring based on multiple local residual connection attention network[J]. Journal of Applied Optics, 2023, 44(2): 337–344. DOI: 10.5768/JAO202344.0202006

在线阅读 View online: <https://doi.org/10.5768/JAO202344.0202006>

您可能感兴趣的其他文章

Articles you may be interested in

基于注意力残差编解码网络的动态场景图像去模糊

Image deblurring of dynamic scene based on attention residual CODEC network

应用光学. 2021, 42(4): 685–690 <https://doi.org/10.5768/JAO202142.0402008>

基于注意力机制与图卷积神经网络的单目红外图像深度估计

Depth estimation of monocular infrared images based on attention mechanism and graph convolutional neural network

应用光学. 2021, 42(1): 49–56 <https://doi.org/10.5768/JAO202142.0102001>

基于卷积神经网络的蛋胚活性精准检测方法研究

Research on accurate detection method of egg embryo activity based on convolutional neural network

应用光学. 2021, 42(2): 268–275 <https://doi.org/10.5768/JAO202142.0202003>

基于时空双流卷积神经网络的红外行为识别

Infrared behavior recognition based on spatio-temporal two-stream convolutional neural networks

应用光学. 2018, 39(5): 743–750 <https://doi.org/10.5768/JAO201839.0506002>

基于小波变换与卷积神经网络的图像去噪算法

Image denoising algorithm based on wavelet transform and convolutional neural network

应用光学. 2020, 41(2): 288–295 <https://doi.org/10.5768/JAO202041.0202001>

基于全卷积神经网络的图像去雾算法

Image defogging algorithm combined with full convolution neural network

应用光学. 2019, 40(4): 596–602 <https://doi.org/10.5768/JAO201940.0402003>



关注微信公众号，获得更多资讯信息

文章编号: 1002-2082 (2023) 02-0337-08

多局部残差连接注意网络的图像去模糊

陈清江, 王巧莹

(西安建筑科技大学 理学院, 陕西 西安 710055)

摘要: 针对现有的基于卷积神经网络的图像去模糊算法存在图像纹理细节恢复不清晰的问题, 提出了一种基于多局部残差连接注意网络的图像去模糊算法。首先, 采用一个卷积层进行浅层特征提取; 其次, 设计了一种新的基于残差连接和并行注意机制的多局部残差连接注意模块, 用于消除图像模糊并提取上下文信息; 再次, 采用一个基于扩张卷积的成对连接模块进行细节恢复; 最后, 利用一个卷积层重建清晰图像。实验结果表明: 在 GoPro 数据集上的 PSNR (peak signal to noise ratio) 和 SSIM (structure similarity) 分别为 31.83 dB、0.9275, 在定性和定量两方面都表明所提方法能够有效地恢复模糊图像的纹理细节, 网络性能优于对比方法。

关键词: 卷积神经网络; 注意机制; 局部残差连接; 扩张卷积

中图分类号: TN911.73; TP391

文献标志码: A

DOI: 10.5768/JAO202344.0202006

Image deblurring based on multiple local residual connection attention network

CHEN Qingjiang, WANG Qiaoying

(College of Science, Xi'an University of Architecture and Technology, Xi'an 710055, China)

Abstract: Aiming at the problem that existing image deblurring algorithms based on convolutional neural network are not clear in the restoration of image texture details, an image deblurring algorithm based on multiple local residual connection attention network was proposed. Firstly, a convolutional layer was used to extract the shallow features. Secondly, a new multiple local residual connection attention module based on residual connection and parallel attentional mechanism was designed to eliminate the image blur and extract the context information. Moreover, a pairwise connection module based on dilated convolution was adopted to restore details. Finally, a convolutional layer was used to reconstruct the clear images. The experimental results show that the peak signal to noise ratio (PSNR) and structure similarity (SSIM) on GoPro data set are 31.83 dB and 0.927 5, respectively. Both qualitative and quantitative results show that the proposed method can effectively restore the texture details of blurred images, and the network performance is better than that of the comparison method.

Key words: convolutional neural network; attention mechanism; local residual connection; dilated convolution

引言

图像作为一种日常生活中必不可少的信息传递载体, 其在科研、医学研究、刑侦等许多领域都有广泛应用^[1-2]; 然而, 由于相机抖动、物体运动或失焦等诸多原因, 都易造成图像模糊, 严重阻碍了研究者们获取有效信息。因此, 图像去模糊研究

在科研、实际应用等方面都具有不可估量的重大价值。

传统的图像去模糊方法^[3-4]通常对估计图像和模糊核施加各种约束, 以解决高度非凸优化问题。早期的模糊核估计方法^[5-6]结合了传统的正则化和图像先验来估计模糊核, 然后通过迭代方案

收稿日期: 2022-05-07; 修回日期: 2022-08-07

基金项目: 国家自然科学基金 (61902304); 陕西省自然科学基金基础研究计划 (2021JQ-495); 陕西省自然科学基金 (2019JQ-755)

作者简介: 陈清江 (1966—), 男, 博士, 教授, 主要从事小波分析、图像处理与信号处理研究。E-mail: chen66xauat@126.com

通信作者: 王巧莹 (1998—), 女, 硕士研究生, 主要从事小波分析、图像处理与信号处理研究。E-mail: 3459551981@qq.com

逐步恢复清晰的图像,例如暗通道先验^[5]、全变差正则化^[6]等。由于人工先验设计的局限性,上述方法无法克服自然运动图像的复杂模糊限制和不确定性。此外,传统的去模糊过程涉及复杂的模糊核估计过程,耗时较长。无论是基于常规正则化的模糊核估计还是基于卷积神经网络的模糊核估计,模糊核估计的假设往往会阻碍自然图像的去模糊性能。

近年来,深度学习被广泛应用于计算机视觉领域,在图像复原方面取得了较多成果^[7-10],卷积神经网络作为深度学习的杰出代表,极大地减少了训练参数,降低了训练难度。为了学习自然模糊图像的非线性特征,自适应地重建清晰图像,卷积神经网络逐渐被应用于图像盲去模糊^[11-14],无需估计模糊核,提升了图像的去模糊性能。Sun等^[15]提出了端到端的无核去模糊方法,通过卷积神经网络去除非均匀运动模糊;Nah等^[16]提出了一种基于深度学习的图像去模糊方法,将传统的图像恢复多尺度恢复策略与卷积神经网络相结合,以提高网络的去模糊性能;Tao等^[17]提出了一种尺度递归网络,通过金字塔形式逐层复原图像,在不同尺度上共享其参数,以减小模型的大小并稳定训练过程;Zhang等^[18]提出了一种基于空间金字塔的深度分层多补丁网络,通过从细到粗的层次处理模糊图像;Xu等^[19]提出了一种基于注意机制的深度卷积神经网络用于图像盲去模糊,但复原图像的纹理细节出现部分丢失。上述方法大多在处理不同空间和通道的特征信息时并未加以区分,造成了去模糊效果不佳、细节丢失等问题。

针对上述方法复原的图像仍然存在纹理细节不清晰的问题,本文提出了一种基于多局部残差连接注意网络的图像去模糊算法。设计了一个多局部残差连接注意模块,用于消除模糊和提取上

下文信息,该模块中引入了新的残差模块与并行注意模块,使得网络可以更加灵活地处理不同类型信息,有助于消除模糊并提取特征信息,同时,采用多个局部残差连接,可以将浅层信息传到深层,减少信息丢失。通过一个基于扩张卷积^[20]的成对连接模块,提取更多细节特征,恢复图像纹理细节。将多局部残差连接注意模块与成对连接模块串连起来,在运动模糊数据集 GoPro 上进行训练与测试,可以得到纹理清晰的高质量图像。运动模糊在日常生活中较为常见,并且其为不适定问题,导致去模糊难度较大,故本文采用运动模糊数据集 GoPro 进行训练与测试。

1 图像去模糊网络

1.1 整体网络结构

为了进一步提高模糊图像的复原质量,设计了一种多局部残差连接注意的图像去模糊网络。网络中设计了一个多局部残差连接注意模块 (multiple local residual connection attention module, MLRA), 该模块由新的残差模块 (residual module, RM)、结合空间注意机制和通道注意机制的并行注意模块 (parallel attention module, PAM)、多个局部残差连接 (multiple local residual connections, MLRC) 3 部分组成,用于消除图像模糊并提取上下文信息,残差模块与并行注意模块的引入,使得网络在处理不同类型信息时更加灵活,有助于消除模糊并提取上下文信息,进一步,引入多个局部残差连接,可以加大信息的流通,增强当前特征信息。为了使得复原图像包含更多纹理细节,提出了一个基于扩张卷积的成对连接模块恢复图像细节,整体网络结构如图1所示。首先,通过一个卷积核为 $3 \times 3 \times 64$ 的卷积层进行浅层特征提取;其次,通过两个




图1 整体网络结构

Fig. 1 Overall network structure

串联的多局部残差连接模块消除模糊, 并提取上下文信息, MLRA 的详细结构如图 2 所示; 再次, 采用一个成对连接模块 (paired connection module, PCM)

提取更多特征信息, 有助于恢复图像纹理细节, 如图 1 虚线框内所示; 最后, 通过一个卷积核为 $3 \times 3 \times 3$ 的卷积层重建清晰图像。




图 2 多局部残差连接注意模块

Fig. 2 Multiple local residual connection attention module

1.2 多局部残差连接注意模块

由于在执行图像去模糊任务时, 感受野越大越好, 而残差网络可以在训练更深网络的同时, 又可以保留良好的信息, 因此, 设计了一个新的结合扩张卷积的残差模块 (RM), 有助于消除模糊并保留特征信息。考虑到图像模糊分布的不均匀性, 不同空间和通道包含的权重信息不同, 提出了一个并行注意模块 (PAM), 该模块将空间注意机制与通道注意机制并行起来, 使得网络在处理不同类型的信息时更加灵活, 关注更有效的信息。多个局部残差连接可以实现特征的重复利用, 充分利用浅层特征信息。将残差模块与并行注意模块成对串连起来, 同时加入多个局部残差连接 (MLRC), 组合成了多局部残差连接注意模块 (MLRA), 用于消除模糊并提取上下文信息。MLRA 的具体细节如图 2 所示。

1) 残差模块 (RM) 为了更好地去除图像模糊, 感受野越大越好, 扩张卷积可以迅速增大感受野, 而不会改变卷积核的大小, 从而避免了增大计算量、信息丢失等问题, 而残差网络又可以在训练更深网络的同时保留良好的信息, 因此设计了一

个新的基于扩张卷积的残差模块, 有助于消除模糊并保留特征信息, 该模块的具体参数如表 1 所示。

表 1 残差模块参数配置表

Table 1 Parameters configuration of residual module

层	卷积核	通道数	步长	扩张因子
Conv1	3×3	64	1	1
Conv2	3×3	64	1	2
Conv3	3×3	64	1	3

2) 并行注意模块 (PAM) 注意机制作为人类感知系统的一个重要属性, 可以认为是引导个体的视线聚焦于输入场景中最重要、信息量最大的部分, 而不是一次性处理整个场景。近年来, 注意机制已经被用于深度学习去处理计算机视觉问题, 取得了较好的成果^[21-24], 但结合注意机制的去模糊方法是非常有限的。本文将空间注意机制与通道注意机制并行连接起来, 最后通过像素点相加融合特征, 加深图像特征信息。并行注意模块的引入使得网络可以更加灵活地处理不同类型的信息, 该模块分为 3 个分支, 第 1 个分支包含空间

注意机制,第2个分支保留原来的特征,第3个分支包含通道注意机制,特征经过3个平行分支后,分别将第1个分支与第2个分支、第3个分支与第2个分支的输出特征图进行像素点相乘后得到2个输出,最后将这2个输出通过像素点相加进行特征融合,如图2所示。并行注意模块中所用卷积层的卷积核均为 $3 \times 3 \times 64$,步长为1。

① 空间注意机制 不是图像中所有的区域对任务的贡献都是同样重要的,只有任务相关的区域才是需要关心的,比如分类任务的主体,空间注意机制就是寻找网络中最重要的部位进行处理。如图2的PAM模块的上半部分所示,空间注意机制包括3个卷积层和1个激活层(sigmoid)。

② 通道注意机制 不同通道特征的重要程度不同,通道注意机制的本质在于建模了各个特征之间的重要性。如图2的PAM模块的下半部分所示,通道注意机制由一个平均池化层、一个卷积层和一个激活层组成。

并行注意模块的步骤通过公式表述如下:

$$A_S = \sigma(\text{Conv}(\delta(\text{Conv}(\delta(\text{Conv}(F))))) \quad (1)$$

$$A_C = \sigma(\text{Conv}(\text{AvgPool}(F))) \quad (2)$$

$$A_P = (A_S * F) + (A_C * F) \quad (3)$$

式中: F 为并行注意模块的输入特征图; σ 代表 Sigmoid 激活函数; δ 代表 ReLU 激活函数; Conv 代表卷积层; AvgPool 表示平均池化; A_S 为空间注意机制的输出; A_C 为通道注意机制的输出; A_P 为并行注意模块的最后输出。

3) 多局部残差连接 (MLRC) 随着网络深度的增加,可能会出现梯度消失和梯度爆炸问题,而残差连接有助于解决这两个问题,可以在训练更深网络的同时,又可以保证良好的信息。为了充分利用特征信息,同时引入了多个局部残差连接,如图2所示,将 RM 与 PAM 串联而成的多个成对操作的输入与输出均通过残差连接进行跨层相连。

1.3 成对连接模块

为了恢复更多图像细节信息,设计了一个基于卷积和扩张卷积的成对连接模块,用于提取更多图像纹理细节,该模块由2对成对操作组成,这2对成对操作具有相同的结构,皆由1个卷积层和1个扩张卷积层组成,如图3所示。输入特征首先通过两对成对操作,之后将第1个成对操作的结果和第2个成对操作的结果按照通道数叠加(Concat)的方式融合特征信息。由于经过通道叠加后,特征层通道数变多,故引入1个 1×1 的卷积用来实现

跨通道的交互和信息整合,并起到了降维的作用。参数配置如表2所示。




图3 成对连接模块

Fig. 3 Pairwise connection module

表2 成对连接模块参数配置表

Table 2 Parameters configuration of pairwise connection module

层	卷积核	通道数	步长	扩张因子
Conv1_1	3x3	64	1	1
Conv1_2	3x3	64	1	2
Conv2_1	3x3	64	1	1
Conv2_2	3x3	64	1	3
Conv3_1	1x1	64	1	1

1.4 损失函数

本文所用的总损失函数计算公式如式(4):

$$L_{\text{total}} = \lambda_A L_A + \lambda_S L_S \quad (4)$$

式中: L_A 为平均绝对误差损失 (mean absolute error, MAE); L_S 为结构损失 (structural loss, SL), 实验表明: λ_A 取 0.1、 λ_S 取 0.9 时效果最好, 故此处 λ_A 取 0.1, λ_S 取 0.9。

平均绝对误差 (MAE) 损失是目标值与预测值之差绝对值和的平均值, 其计算公式为

$$L_A = \frac{1}{N} \sum_{i=1}^N |I_i - \hat{I}_i| \quad (5)$$

式中: $I_i (i=1, 2, \dots, N)$ 为真实清晰图像; $\hat{I}_i$ 为所提方法输出的去模糊图像。

在网络中引入结构损失, 以便保留图像纹理细节, 减少图像模糊。其计算公式为

$$L_S = L_{\text{SSIM}} + L_{\text{MS-SSIM}} \quad (6)$$

其中 L_{SSIM} 可以表示为

$$L_{\text{SSIM}} = 1 - f_{\text{SSIM}}(P) \quad (7)$$

多尺度结构相似损失 (MS-SSIM) 是基于多层的 SSIM 损失函数, 考虑了分辨率, $L_{\text{MS-SSIM}}$ 可以表示为

$$L_{\text{MS-SSIM}} = 1 - f_{\text{MS-SSIM}}(P) \quad (8)$$

式中 P 为像素块的中间像素值。

2 实验结果与分析

2.1 实验配置及实验步骤

本文所做实验配置为: 计算机配置为 NVIDIA GeForce 2 060 GPU, 显存为 6 GB, 在 TensorFlow2.0 深度学习框架和 python3.7 环境下对模型进行训练与测试, 学习率与 batch size 分别设置为 0.000 1 和 1, 模型迭代 3 000 次, 为了优化损失函数, 使用了 Adam 优化器, 动量参数分别设置为 0.9 和 0.999。在 GoPro 数据集上进行训练和测试, 将原始图像大小裁剪为 256×256 像素输入模型。

训练模型的步骤如下:

- 1) 获取模糊图像数据集 GoPro;
- 2) 对获取到的模糊图像数据集进行预处理, 将其裁剪成大小相同的图像;
- 3) 将预处理后的图像输入搭建好的多局部残差连接注意网络中进行训练, 在训练过程中, 使用平均绝对误差损失与结构损失的加权和作为损失函数来反向调参, 当损失值稳定在足够小的值时, 停止训练;
- 4) 随机选取若干幅测试图像, 将其输入到训练好的卷积神经网络模型中, 输出得到清晰的预测图像。使用峰值信噪比、结构相似度、模型大小和网络模型运行时间进行评估。

2.2 实验评估指标及实验结果对比

为了验证所提方法的有效性, 将所提方法的实验结果与 Sun 等^[15]、Nah 等^[16]、Tao 等^[17]、Zhang 等^[18]、Xu 等^[19]5 种方法进行对比, 选取的评价指标有峰

值信噪比 (PSNR)、结构相似度 (SSIM)、模型尺寸 (Size) 和运行时间 (Runtime)。

峰值信噪比 (PSNR) 是一种评价图像的客观标准, 为了衡量经过处理后的图像品质, 通常会参考 PSNR 值来衡量某个程序的处理是否令人满意。PSNR 可以表示为

$$f_{\text{PSNR}}(I, \hat{I}) = 20 \log \frac{255q}{\|I - \hat{I}\|_2} \quad (9)$$

式中: I 和 $\hat{I}$ 分别表示原始的清晰图像和去模糊后的图像; q 表示 I 的总像素数。

结构相似度 (SSIM) 是一种衡量两幅图像相似度的指标, 是结构相似性理论的实现, 结构相似度指数从图像组成的角度将结构信息定义为独立于亮度、对比度的, 反映场景中物体结构的属性。SSIM 可以表示为

$$f_{\text{SSIM}}(I, \hat{I}) = \frac{(2\mu_I\mu_{\hat{I}} + C_1)(2\sigma_{I\hat{I}} + C_2)}{(\mu_I^2 + \mu_{\hat{I}}^2 + C_1)(\sigma_I^2 + \sigma_{\hat{I}}^2 + C_2)} \quad (10)$$

式中: μ_I 和 $\mu_{\hat{I}}$ 分别表示图像 I 和 $\hat{I}$ 的均值; σ_I 和 $\sigma_{\hat{I}}$ 分别表示图像 I 和 $\hat{I}$ 的标准差; $\sigma_{I\hat{I}}$ 是 I 和 $\hat{I}$ 的协方差; C_1 和 C_2 是两个常数。

为了更加清楚地展现本文复原图像和其他对比方法复原图像之间的区别, 利用 Visio 软件对测试图像的部分差距明显区域用红色矩形框进行了手动标注, 并将标注区域裁剪后适当放大以便用于视觉评估。可视化对比示例图如图 4 所示, 不同的去模糊算法在 GoPro 数据集上的评价指标结果对比如表 3 所示。




图 4 不同方法的可视化对比

Fig. 4 Visual comparison of different methods

由表 3 可以看出本文方法得到的 PSNR 值最高, 虽然 SSIM 值与最高指标相差 0.02, 但本文提出的网络模型达到最小, 运行时间最短。图 4 展示

了所提方法与对比方法生成的可视化效果对比示例图。不同空间和通道的特征信息具有不同的权重, 有些是高频信息, 有些是低频信息, 在处理不

同类型的信息时需要加以区分, Sun 等^[15]、Nah 等^[16]、Tao 等^[17]、Zhang 等^[18]方法在处理图像模糊时并未加以区分, 导致了复原图像细节丢失, 不能有效地去除模糊, Xu 等^[19]方法的去模糊效果与 Sun 等^[15]、Nah 等^[16]、Tao 等^[17]、Zhang 等^[18]相比有所提升, 但该方法生成的图像中仍然存在模糊, 没有达到更好的图像去模糊效果。本文方法恢复的图像中包含丰富的纹理细节, 图像去模糊性能较好。

表 3 不同方法的评价指标结果对比

Table 3 Comparison of evaluation index results of different methods

方法	Sun	Nah	Tao	Zhang	Xu	本文
PSRN/dB	24.64	29.08	30.26	31.20	31.23	31.83
SSIM	0.8429	0.9135	0.9342	0.9454	0.9455	0.9275
Size/MB	54.1	303.6	33.6	86.8	26.34	19.5
Runtime/s	12000	4300	1600	424	563	396

2.3 消融实验

为了验证所提网络结构的有效性, 增加了 5 种不同配置方案的消融实验, 均以本文提出的去模糊网络为基础网络, 分别为以下实验: 1) 去除并行注意模块 (PAM-); 2) 去除残差模块 (RM-); 3) 去除多个局部残差连接 (MLRC-); 4) 将本文设计的残差模块替换成经典残差块^[10](residual block, RB); 5) 去除成对连接模块 (PCM-)。不同配置方案的消融实验评价指标对比结果如表 4 所示, 可视化效果对比结果如图 5 所示。

表 4 不同配置算法在 GoPro 上的实验结果对比

Table 4 Comparison of experimental results of different configuration algorithms on data set GoPro

不同配置	PAM-	RM-	MLRC-	RB	PCM-	本文
PSNR/dB	28.86	29.38	29.56	29.73	29.76	31.83
SSIM	0.8932	0.9106	0.9131	0.9156	0.9147	0.9275




图 5 不同配置算法在数据集 GoPro 上的图片可视化对比

Fig. 5 Comparison of image visualization of different configuration algorithms on data set GoPro

由表 4 可知, 本文方法的评价指标 PSNR 和 SSIM 均高于其余 5 种消融实验的评价指标, 结合图 5 可以发现, 去除并行注意模块 (PAM-) 的网络图像复原效果最差, 图片中依然存在大量模糊, 因此, 并行注意模块在本文中是非常有效和必要的。去除残差模块 (RM-)、去除多个局部残差连接 (MLRC-) 和去除成对连接模块 (PCM-) 的网络图像复原效果有一定的提升, 但是图片中的一些纹理细节仍然不够清晰。将本文设计的残差模块替换成经典残差块 (RB) 的网络复原图像中依然存在较多伪影, 说明了本文设计的残差模块去模糊性能优于经典残差块。从表 4 和图 5 可以发现, 本文方法的图像去模糊效果较好, 证明了所提方法

的有效性。

3 结论

本文提出了一种多局部残差连接注意网络用于图像去模糊, 设计了基于残差连接和注意机制的多局部残差连接注意模块消除模糊并提取上下文信息及基于扩张卷积的成对连接模块恢复图像纹理细节。并行注意机制的引入, 使得网络在处理不同类型的信息时更加灵活, 同时, 采用多个局部残差连接, 可以在训练更深网络的同时, 又能保证良好的信息。实验结果表明, 所提方法在保持较高的 PSNR、SSIM 值的情况下, 同时拥有更小的模型尺寸, 并且运行时间最短, 能够有效恢复模糊图

像的纹理细节, 图像的整体复原效果较好。

参考文献:

- [1] KOUR A, YADA V K, MAHESHWARI V, et al. A review on image processing[J]. International Journal of Electronics Communication and Computer Engineering, 2013, 4(1): 270-275.
- [2] GONG D, YANG J, LIU L, et al. From motion blur to motion flow: a deep learning solution for removing heterogeneous motion blur[C]//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2017: 2319-2328.
- [3] PAN J, HU Z, SU Z, et al. Deblurring text images via L0-regularized intensity and gradient prior[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2014: 2901-2908.
- [4] LI L, PAN J, LAI W S, et al. Learning a discriminative prior for blind image deblurring[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2018: 6616-6625.
- [5] PAN J, SUN D, PFISTER H, et al. Deblurring images via dark channel prior[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 40(10): 2315-2328.
- [6] LI W, CHEN R, XU S, et al. Blind motion image deblurring using nonconvex higher-order total variation model[J]. Journal of Electronic Imaging, 2016, 25(5): 053033.
- [7] JIANG H, CHEN F, LIU X, et al. Thermal wave image deblurring based on depth residual network[J]. Infrared Physics and Technology, 2021, 117(7): 103847.
- [8] 陈清江, 李金阳, 胡倩楠. 基于并联残差网络的低照度图像增强算法[J]. 激光与光电子学进展, 2021, 58(14): 1410015.
CHEN Qingjiang, LI Jinyang, HU Qiannan. Low-illuminated image enhanced algorithm based on parallel residual network[J]. Laser & Optoelectronics Progress, 2021, 58(14): 1410015.
- [9] 杨书广. 基于深度反向投影的感知增强超分辨率重建模型[J]. 应用光学, 2021, 42(4): 691-716.
YANG Shuguang. Perception based on deep reverse projection enhanced the super-resolution reconstruction model[J]. Application optics, 2021, 42(4): 691-716.
- [10] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2016: 770-778.
- [11] 王晨卿, 荆涛, 刘云鹏, 等. 基于多尺度条件生成对抗网络的图像去模糊[J]. 计算机工程与设计, 2022, 43(4): 1074-1082.
WANG Chenqing, JING Tao, LIU Yunpeng, et al. Image deblur based on multi-scale conditional generative adversarial network[J]. Computer Engineering and Design, 2022, 43(4): 1074-1082.
- [12] 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[J]. 计算机辅助设计与图形学学报, 2022, 34(1): 84-93.
JIN Yan, HUANG Mengjia, JIANG Zhiwei. Image deblurring based on aggregation residuals generation adversarial network[J]. Journal of Computer-Aided Design & Computer Graphics, 2022, 34(1): 84-93.
- [13] 陈清江, 胡倩楠, 李金阳. 多尺度交替连接残差网络用于图像去模糊[J]. 光学精密工程, 2021, 29(7): 1686-1694.
CHEN Qingjiang, HU Qiannan, LI Jinyang. Multi-scale alternating residual networks are used for images to blur[J]. Optical precision engineering, 2021, 29(7): 1686-1694.
- [14] 杨爱萍, 李磊磊, 张兵, 等. 基于轻量化渐进式残差网络的图像快速去模糊[J]. 电子与信息学报, 2022, 44(5): 1674-1682.
YANG Aiping, LI Leilei, ZHANG Bing, et al. Fast image deblurring based on lightweight progressive residual network[J]. Journal of Electronics & Information technology, 2022, 44(5): 1674-1682.
- [15] SUN J, CAO W, XU Z, et al. Learning a convolutional neural network for non-uniform motion blur removal[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2015: 769-777.
- [16] NAH S, HYUN KIM T, MU LEE K. Deep multiscale convolutional neural network for dynamic scene deblurring[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2017: 3883-3891.
- [17] TAO X, GAO H, WANG Y, et al. Scale-recurrent network for deep image deblurring [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2018: 8174-8182.
- [18] ZHANG H, DAI Y, LI H, et al. Deep stacked hierarchical

- multi-patch network for image deblurring[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2019: 5978-5986.
- [19] XU Y, ZHU Y, QUAN Y, et al. Attentive deep network for blind motion deblurring on dynamic scenes[J]. Computer Vision and Image Understanding, 2021, 205(11): 103169.
- [20] YU F, KOLTUM V. Multi-scale context aggregation by dilated convolutions[J]. ArXiv Preprint ArXiv, 2015, 151: 07122.
- [21] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2018: 7132-7141.
- [22] 王建明, 黎向锋, 叶磊, 等. 基于信道注意结构的生成对抗网络医学图像去模糊[J]. 计算机科学, 2021: 101-106.
- WANG Jianming, LI Xiangfeng, YE Lei, et al. Medical image deblurring based on generative adversarial network based on channel attention structure[J]. Computer Science, 2021: 101-106.
- [23] 杨飞璠, 李晓光, 卓力. 基于注意力残差编解码网络的动态场景图像去模糊[J]. 应用光学, 2021, 42(4): 685-690.
- YANG Feifan, LI Xiaoguang, ZHUO Li. Dynamic scene image deblur based on attentional residual codec network[J]. Applied Optics, 2021, 42(4): 685-690.
- [24] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision (ECCV). Berlin, Heidelberg: Springer, 2018: 3-19.