

DOI:10.19651/j.cnki.emt.2108177

基于双重控制网络的图像去模糊方法^{*}

李佳¹ 李晨² 郭业才¹

(1.南京信息工程大学电子与信息工程学院 南京 210000; 2.无锡学院电子信息工程学院 无锡 214000)

摘要:传统的图像复原问题主要采用分治法,即将图像复原问题分为不同的子问题,通过对子问题处理得到最优解。由于不同处理环节之间的衔接和损失问题,子问题的最优解并不能得到全局最优解。针对此问题,提出一种端到端的双重控制网络,采用控制模块通过参数分别控制退化分支和处理分支。该网络通过特殊的编解码器结构处理特征问题—在固定尺度因子子网下,采用循环跳跃连接结构消除卷积层的堆叠块,增强输出端的特征显示。实验证明,提出方法与对比方法复原的图像峰值信噪比(PSNR)数值在30以上,结构相似度(SSIM)指标在0.90以上,且有效地改善了视觉效果。

关键词:图像复原;端到端;编解码器;双重控制;循环跳跃连接

中图分类号:TP391.9 文献标识码:A 国家标准学科分类代码:520.6040

Dual control network for image deblurring

Li Jia¹ Li Chen² Guo Yecai¹

(1. School of Electronics and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210000, China;

2. School of Electronics and Information Engineering, Wuxi University, Wuxi 214000, China)

Abstract: The traditional image restoration problem mainly adopts the divide-and-conquer method, image restoration problem is divided into different sub-problems, and the optimal solution is obtained by processing the sub-problems. Due to the connection and loss between different processing links, the optimal solution of the sub-problem cannot be the global optimal solution. To solve this problem, an end-to-end dual control network is proposed, which uses a control module to control the degenerate branch and the processing branch through parameters. The network uses a special encode-decode structure to deal with the feature problem under the fixed scale factor subnet, the loop skip connection structure is used to eliminate the stacking blocks of the convolutional layer and enhance the feature display at the output end. Experiments show that the peak signal-to-noise ratio (PSNR) value of the image restored by the proposed method and the comparison method is above 30, and the structural similarity index measure (SSIM) is above 0.90, which effectively improves the visual effect.

Keywords: image restoration; end-to-end; encode-decode; dual control; loop skip connection

0 引言

单幅图像去模糊属于图像复原的一种,但与图像复原的本质—病态的退化问题有一定的区别。图像去模糊需要对图像模糊核进行估计,准确地估计是清晰复原的保证。真实的模糊图像由相机抖动、物体运动等原因造成,称为运动模糊。大气环境造成的模糊,如雨、雾等已经被单独研究,形成图像去雨^[1]、去雾^[2]等研究热点。对于单幅图像去模糊而言,运动模糊是主要研究方向。

单幅图像去模糊问题主要研究的是造成图像模糊的模

糊核估计。不同的模糊核对图像造成的模糊不同,准确估计模糊核可以复原出清晰的图像。根据模糊核是否已知可以分为盲去模糊和非盲去模糊。模糊核已知,称为非盲去模糊,常用基于先验和正则化的方法对已知的模糊核进行反卷积操作得到清晰图像,如逆滤波、维纳滤波等经典的图像复原算法,此类算法能够还原大多数清晰图像,但对于边缘^[3]细节复原质量不尽人意。模糊核未知,称为盲去模糊,常用基于深度学习的方法对未知的模糊核估计得到清晰图像。基于先验知识^[4]的方法,如 Pan 等^[5]提出的基于正则化先验图像去模糊算法,通过检测到图像边缘模糊进行估

收稿日期:2021-10-24

*基金项目:国家自然科学基金(61673222)、2020-2021年度南京信息工程大学无锡校区研究生实践创新项目(WXCX202012)资助

计并去除的方式复原清晰图像。Chakrabarti^[6]在 Pan 的基础上提出傅里叶反卷积进行全局模糊核估计,使得单幅图像复原更为清晰。基于深度学习的方法用于单幅图像去模糊在近年来广为流行。Sun 等^[7]使用分类卷积神经网络(convolutional neural networks, CNN)预测局部块的模糊方向和强度,从稀疏模糊核中,利用马尔可夫随机场(Markov random field, MRF)得到一个稠密的运动场。最终清晰图像由非盲解模糊方法生成。Gong 等^[8]利用全卷积网络从模糊图像中估计出密集的非均匀运动流,仍然使用非盲解模糊的方法生成清晰图像。Nah 等^[9]提出一种多尺度去模糊 CNN,以端到端方式分阶段逐步恢复清晰图像。Zamir 等^[10]提出多阶段渐进图像复原方法,将整个复原过程分解为更易于管理的步骤。Tao 等^[11]提出将管道建模为具有共享参数的尺度-循环结构。Gao 等^[12]提出以端到端网络在动态模糊场景下实行去模糊。

基于先验和正则化的方法用于单幅图像去模糊效率低下;基于深度学习的方法有足够的效率但没有基于先验和正则化方法的灵活性。本文提出一种基于端到端深度学习的双重控制网络(dual control network, DCNet),在增加去模糊有效性同时增加网络的灵活性,并且改善经典的滤波方法复原图像质量问题。网络的退化分支(degradation branch, DB)采用传统傅里叶变换和傅里叶反变换方法求解得到退化图像,增加网络的灵活性。处理分支(handle branch, HB)由残差 U 形网(residual U-network, ResUNet)构成。ResUNet 将残差块(ResBlock)^[13]与 UNet^[14]结合组成,ResUNet 能够快速处理大容量残差块,通过单模型可以处理不同的模糊核因子,明显减少了参数量,由此增加网络有效性。为合成相应测试模糊图像,应提供各种各样的模糊核因子和噪声水平,但会导致复杂的退化过程,因此采用和文献[15]同样具有代表性、多样性的 12 个不同的模糊核因子,控制模块将这些模糊核因子作为参数控制退化分支合成测试图像。结果表明,提出的网络去模糊性能优异,视觉质量较好。

现存学习单个深度模型进行图像去模糊的研究较少,本文在此基础上做出相应的研究。

1 双重控制网络用于图像复原

1.1 退化模型

在真实数据集难以获取的情况下,大多数的数据集采用退化方法来形成训练数据,一般模糊图像的数学模型表示为:

$$y = x \otimes k + n \quad (1)$$

其中, \otimes 表示卷积符号, k 表示模糊核, n 表示噪声。模糊图像等于输入图像与模糊核卷积,再与噪声干扰的和。

但一些特定环境下,如水下^[16]、雨天等,采用特殊的方法合成多样的数据集。在图像复原之超分辨率任务和图像去模糊任务中,双线性插值(bilinear interpolation)、双三次

插值(bicubic interpolation)退化方法应用广泛。

Zhang 等^[17]提出的剩余通道注意网络(residual channel attention networks, RCAN)和 Lim^[18]提出的增强深度超分(enhanced deep super-resolution, EDSR)所用的训练集都采用双三次插值退化方法获得。双三次插值方法通过插值方法将原来的 $m \times n$ 大小的图像 A 缩放为 $M \times N$ 大小的图像 B 。它所需要的权重用如下 Bicubic 基函数计算得出:

$$W(x) = \begin{cases} (a+2)|x|^2 + 1, & |x| \leq 1 \\ a|x|^3 - 5a|x|^2 + 8a|x| - 4a, & 1 < |x| < 2 \\ 0, & \text{其他} \end{cases} \quad (2)$$

其中, a 取 -0.5 , x 为 Bicubic 基函数中的参数,当求得 x 时,即得到原始图像中像素点 P 周围的 16 个像素点所对应的权重。

图像 B 中的对应点 (i, j) 的像素值为:

$$B(x, y) = \sum_{p \in S_{x,y}} w_p \times A(x, y) \quad (3)$$

其中, $S_{x,y}$ 表示原始图像中某个像素点周围的像素点的集合,最终权重为分量权重的乘积 $w_p = W(1+x) \times W(1+y)$, $A(x, y)$ 表示对应像素点 A 中的坐标。

对于单幅图像去模糊任务,合成图像数据集的获取主要来自不同模糊核的算法生成,即通过式(1)实现。文献[15]和[19]提出的方法都采用模糊核生成退化图像。此种退化方法得到的退化图像在进行复原时有更高的峰值信噪比(peak signal-to-noise ratio, PSNR)和结构相似性(structural similarity index measure, SSIM)数值以及更优的感知质量。如图 1 所示,使用不同的模糊核生成的退化图像。为了简化复杂的评估过程,选取代表性广泛的 12 种模糊核,包括 4 个不同宽度的(0.7、1.2、1.6、2.0)各向同性高斯核,4 个各向异性^[20-21]的高斯内核,4 个特定模糊核。这些模糊核组成模糊空间,以此来评估网络性能具有代表性。

退化分支如式(4)所示, D_k 表示输出退化图像, k 代表模糊核因子, s 代表尺度,本文是在单一尺度下,所以令 s 为 1。退化分支的实质是利用傅里叶变换和傅里叶反变换求闭式解,即所得结果与退化图像相似。此外,只有 k 作为分支的输入,所以该分支可视为无参数可训练模块。

$$D_k = D(k, s) \quad (4)$$

1.2 网络结构

如图 2 所示,本网络由堆叠编解码器结构、控制模块以及数据模块—退化分支和处理分支组成。堆叠编解码器结构通过深层次的学习图像特征,能够更好的特征提取。为消除转置卷积带来多阶剩余块,提出循环跳跃连接(loop skip connection)。控制模块通过参数模糊核因子 k 控制退化分支和处理分支的输出。退化分支输出处理分支需要处理的对象,处理分支输出处理后的图像特征。为增强特征




图1 12种模糊核因子生成的不同模糊图像




图2 DCNet网络结构

表示能力,残差网络需要控制模块输入各种各样的模糊核因子。整个网络的工作流程:输入单幅退化图像经由堆叠编码器特征提取与转换,在模糊核的参与下,处理分支对特征处理,最终由解码器反卷积复原出清晰图像。

1.3 控制模块

控制模块通过参数控制退化分支和处理分支的输出,如式(5)所示,使用模糊核 k 决定 D, H 的输出。退化分支通过控制模块将不同的模糊核 k 与清晰图像合成输出退化图像;在信号处理中,普通信号加上一定的噪声以便于增强信号特征。在处理分支中,控制模块对待处理图像加上特定模糊核因子,增强图像特征表示。

$$[D, H] = C(k) \quad (5)$$

控制模块由 3 个全连接层组成,前两层使用 ReLU 激活函数,最后一层使用 softplus 激活函数。第 1 层作为输入层,最后一层作为输出层,每层通道数设为 64。

1.4 处理分支

处理分支目的是获得清晰特征图,本文借鉴文献[9],将残差模块结合 U-Net,形成 ResUNet 模块。U-Net 是图像处理中常用的网络结构,残差模块主要加速训练和处理大容量的剩余块。如式(6)所示,将模糊图像 D_k 和 k 作为输入,输出 H_k 清晰特征。ResUNet 能够通过单个模型处理不同的模糊核图像,从而减少参数数量。

$$H_k = H(D_k, k) \quad (6)$$

ResUNet 设置为 4 层,每层通道数为 64, 128, 256,

512。包含上采样和下采样部分,上采样包括上卷积、像素筛选和转置卷积;下采样包括平均池化、最大池化和步长卷积。为了让网络能够更好的自适应学习特征图,上采样操作和下采样操作分别采用转置卷积和步长卷积。一个 ResUNet 由 2 个 3×3 卷积层组成,并且在层与层之间使用 ReLU 激活函数,同时在输入加上跳跃连接。

1.5 循环跳跃连接

为了解决梯度消失问题和增强网络性能,跳跃连接近年来在神经网络中应用广泛^[22]。残差网络和残差块应用的是跨两层或两层以上的跳跃连接,将输入加到输出中,极大地克服了梯度消失问题。如图 3 所示,编解码器包括 3 个阶段,分别为特征提取、非线性变换和特征重构。编解码器结构一共包括 24 层。在编码部分,分成 3 个阶段。每个阶段由 $[32, 64, 128]$ 尺度的卷积层组成,每层之间使用 ReLU 激活函数。由于去模糊网络采用转置模块会导致多阶剩余学习块,提出循环跳跃连接消除多阶剩余学习块。循环跳跃连接指的是在非线性阶段采用正向和反向跳跃连接构成循环结构,通过正向跳跃连接将每个编码尺度子网特征输入对应的解码尺度子网,并在 D. stage1 特征重构块之前,将特征返回给输入强化学习。受文献[12]方法的启发,在解码部分,采用反卷积操作,使用和编码部分同样的结构。循环跳跃连接使反向传播更加灵活,跨越多个卷积层,从而实现特征从底层到顶层更好的映射。与文献[12]相比,此结构更适合该网络,循环学习特征为特征重构阶段节省了成本。结果表明,通过加强学习后图像细节特征恢复的更为清晰。

2 实验

2.1 数据集与评估标准

由于该模型是独立训练,本文选择使用代表多种模糊情况下的不同模糊核因子组成的模糊空间评估网络的性能。训练集选择具有代表性的公共数据集 GoPro,包含 2 103 对模糊清晰图像和 1 111 对评估图像。为了更好地




图3 编解码器结构

测试该方法的性能,从通用的 HIDE 数据集和 GoPro 评估图像中分别选取 65 张图像和 11 张不同场景的图像在不同模糊核下组成的退化图像作为测试集。两种数据集对于测试本文方法和对比其他方法提供充足的数据支撑。

在测试网络过程中,使用合成图像测试时,模糊图像直接处理得到复原图像。在使用真实图像测试时,因为图像边缘问题,需要对图像进行预处理。首先将真实模糊图像插值到标准化尺寸。其次,使用最适合人眼的宽度为 2.2 的高斯模糊核进行边缘处理。最后输出复原图像。

评估标准是定量结果和定性结果,其中定量结果采用通用的 PSNR 和 SSIM 作为评价标准,定性结果以主观视觉评价为标准。

PSNR 一般用于最大值信号和背景噪音之间的一个工程项目。为了衡量压缩后图像的品质,使用 PSNR 数值评价图像是否符合标准,单位为 dB,PSNR 值越大代表图像质量越好。其计算公式如下:

$$PSNR = 10 \times \lg \left(\frac{(2^n - 1)^2}{MSE} \right) \quad (7)$$

其中, n 为每个采样值的比特数, MSE 为均方误差。

SSIM 是衡量两张数位图像的相似程度,其功能与 PSNR 相同,SSIM 值越大代表两张图像相似度越高。其定义如下:

$$SSIM(x, y) = [l(x, y)]^\alpha [c(x, y)]^\beta [s(x, y)]^\gamma \quad (8)$$

$$\begin{cases} l(x, y) = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \\ c(x, y) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \\ s(x, y) = \frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3} \end{cases} \quad (9)$$

其中, x, y 为输入和输出图像; $l(x, y), c(x, y)$ 和 $s(x, y)$ 分别为比较亮度、对比度和结构; μ_x, μ_y 为 x, y 的均值; σ_x, σ_y 为 x, y 的方差; σ_{xy} 为协方差; C 为常数。

2.2 实验细节

训练过程中采用 Adam 优化器^[23], 学习率从 1×10^{-4} 开始, 每 100 000 次迭代衰减 0.5 倍, 最后以 6.25×10^{-6} 结束。整个训练过程设置为 2 000 个轮次, 清晰图像的每个块大小设置为 96×96 。硬件设备使用英特尔 i7 处理器, GPU 型号为 RTX3070-8G。

在测试过程,为了通过式(1)合成相应的测试数据集,需要提供模糊核和相应的噪声水平。评估图像时,提供模糊核宽度为 0.6~2.2 的高斯模糊,噪声水平取值为 0~20。本文对控制模块进行分析:当设置高斯模糊核宽度为 2.2 时,噪声水平取 0, 所获得复原图像锐化程度严重影响图像质量,逐渐提高噪声水平,所获得图像趋于平滑。当设置模糊核宽度为 0, 噪声取 20, 复原图像模糊严重。通过不断调试选取适当参数后,复原图像达到理想效果。以上分析表明,模糊核代表图像的锐化程度,噪声水平代表图像平滑程度。复原图像出现严重失真表明在评估过程中对图像预处理不符合训练模型的参数设置。调节预处理参数有助于提高复原图像的质量,同时证明控制模块存在的必要性。

2.3 损失函数

本文使用鲁棒性较好的 L1 损失函数用于训练,但会导致过平滑,丢失图像细节信息。为了解决此问题,引入感知损失(perceptual loss),增强图像的细节信息。总的损失函数 ℓ_{total} 表示为:

$$\ell_{total} = \sum_{k=1}^{12} |X_G - X_k| + \frac{\lambda}{H_k W_k} \| \Psi_k^{agg}(X_k) - \Psi_k^{agg}(X_G) \|_2^2 \quad (10)$$

其中,前半部分表示的是 L1 损失, X_G 是真值图像(ground truth), X_k 为不同模糊核下的预测图象;后半部分表示感知损失, Ψ_k^{agg} 表示某一层 VGG 的特征图, $H_k W_k$ 表示该层的特征图形状,设置权重 λ 为 1。

3 实验结果

3.1 合成图像的去模糊

在评估网络性能方面选取 Gao 等^[12]、Nah 等^[9]、Tao 等^[11]

的网络进行对比,这些网络都是基于端到端训练的深度学习网络。

从定量评价标准出发,表 1 和 2 分别为 PSNR、SSIM 的对比结果。表中的数据表明(本文结果加粗表示),与对比方法相比,在 K1 模糊核下,本方法低于其他方法,在其他模糊核下本文方法在 PSNR 和 SSIM 指标上具有更


高更稳定的数值。从定性角度出发,随机选取 3 个不同模糊核与其他方法进行对比,如图 4 所示,本文方法在视觉质量上表现最好。结果表明,在模糊核未知的情况下,虽然以 GoPro 数据集作为训练,但在 HIDE 测试集中表现出很好的复原能力,说明此方法在其他模糊情况下也同样适应。

表 1 不同的模糊核与其他方法的 PSNR 对比

方法	模糊核											
	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12
Gao 等 ^[12] (HIDE)	33.26	28.69	26.80	25.66	27.12	26.79	27.05	25.24	20.40	19.52	21.01	22.56
Gao 等 ^[12] (GoPro)	34.26	29.95	28.14	27.10	29.07	28.88	28.85	26.64	20.94	20.16	21.55	23.36
Nah 等 ^[9] (HIDE)	34.92	30.04	27.89	26.44	26.55	26.27	26.42	25.36	20.19	19.99	20.70	22.21
Nah 等 ^[9] (GoPro)	37.51	32.71	30.21	28.41	28.39	28.23	28.30	27.01	20.57	20.44	21.22	23.17
Tao 等 ^[11] (HIDE)	34.02	29.27	27.39	26.02	26.75	26.55	26.75	25.27	20.27	19.64	20.92	22.67
Tao 等 ^[11] (GoPro)	35.89	31.21	29.20	27.78	28.55	28.48	28.63	26.93	20.90	20.21	21.71	23.66
DCNet(HIDE)	31.85	31.52	31.26	30.92	30.55	30.47	30.62	30.29	31.04	31.11	31.04	30.60
DCNet(GoPro)	35.33	34.93	34.59	34.13	33.85	33.52	33.70	33.29	34.34	34.47	34.37	34.27

表 2 不同的模糊核与其他方法的 SSIM 对比

方法	模糊核											
	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12
Gao 等 ^[12] (HIDE)	0.964	0.894	0.839	0.792	0.832	0.823	0.827	0.761	0.545	0.532	0.604	0.615
Gao 等 ^[12] (GoPro)	0.970	0.918	0.871	0.832	0.875	0.869	0.891	0.803	0.567	0.546	0.614	0.648
Nah 等 ^[9] (HIDE)	0.973	0.913	0.858	0.816	0.817	0.806	0.810	0.761	0.535	0.556	0.572	0.622
Nah 等 ^[9] (GoPro)	0.983	0.944	0.900	0.855	0.860	0.855	0.856	0.809	0.545	0.562	0.591	0.650
Tao 等 ^[11] (HIDE)	0.967	0.899	0.846	0.796	0.820	0.811	0.820	0.760	0.531	0.539	0.605	0.624
Tao 等 ^[11] (GoPro)	0.978	0.930	0.886	0.843	0.861	0.858	0.861	0.808	0.557	0.548	0.630	0.659
DCNet(HIDE)	0.933	0.928	0.924	0.919	0.913	0.911	0.913	0.906	0.919	0.920	0.920	0.908
DCNet(GoPro)	0.960	0.957	0.953	0.948	0.945	0.940	0.942	0.936	0.952	0.953	0.952	0.948






图4 两种测试集上不同方法的去模糊对比

3.2 真实图像的去模糊

在经过上文所述对图像进行预处理之后,本网络用于真实模糊图像去模糊效果如图5所示,从结果图中看出,Gao等^[12]和Tao等^[11]方法对真实模糊图像具有相同的效果。

Nah等^[9]方法锐化程度更深,但图像细节损失较多。本文方法对细节的边缘处理更好。整体来看,DCNet视觉效果最好。由此可知,该方法在真实图像去模糊上有较好的复原性能。




图5 真实模糊图像对比

4 结论

针对传统基于逆滤波或维纳滤波图像去模糊算法的图像质量不足以及分治法引起的衔接问题,提出双重控制网络的方法。网络的控制模块通过参数控制处理分支和退化分支,减少网络计算成本;同时为增加图像上下文的特征映射,采用堆叠的编解码器结构,在编解码器结构之间提出循环跳跃连接。最后使用代表大多数模糊情况的不同模糊核生成的退化图像来评估网络性能。实验结果表明,DCNet在PSNR和SSIM数值上都有提升,对真实图像去模糊有较好的视觉效果。同时提出的模型具有传统去模糊方法的灵活性同时也具有基于深度学习方法的有效性。本方法对于其他图像复原任务有一定的参考价

值。研究过程发现,本模型对于图像超分辨率任务有一定效果,而单幅图像复原多任务成为目前的研究趋势,接下来通过改进模型,使模型能够处理多任务图像复原成为后续的研究方向。

参考文献

- [1] LI P, TIAN J, TANG Y, et al. Model-based deep network for single image deraining[J]. IEEE Access, 2020, 8(1): 14036-14047.
- [2] ZHANG Y, GAO K, WANG J, et al. Single-image dehazing using extreme reflectance channel prior [J]. IEEE Access, 2021, 9(6): 87826-87838.
- [3] 陆盈. 基于区间值直觉模糊集的图像边缘检测算法[J]. 电子测量与仪器学报, 2018, 32(12): 99-107.

- [4] BAHAT Y, EFRAT N, IRANI M. Non-uniform blind deblurring by reblurring[C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 3286-3294.
- [5] PAN J, SUN D, PFISTER H, et al. Blind image deblurring using dark channel prior[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1628-1636.
- [6] CHAKRABARTI A. A neural approach to blind motion deblurring [C]. European Conference on Computer Vision, Springer, Cham, 2016: 221-235.
- [7] 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, 2015: 769-777.
- [8] 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 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2319-2328.
- [9] NAH S, HYUN K T, MU L K. Deep multi-scale convolutional neural network for dynamic scene deblurring[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 3883-3891.
- [10] 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), Nashville, TN, USA, 2021: 14816-14826.
- [11] TAO X, GAO H, SHEN X, et al. Scale-recurrent network for deep image deblurring[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8174-8182.
- [12] GAO H, TAO X, SHEN X, et al. Dynamic scene deblurring with parameter selective sharing and nested skip connections[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 3848-3856.
- [13] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [14] WENG W, ZHU X. INet: Convolutional networks for biomedical image segmentation [J]. IEEE Access, 2021, 9(1): 16591-16603.
- [15] ZHANG K, GOOL L V, TIMOFTE R. Deep unfolding network for image super-resolution[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 3217-3226.
- [16] LIU X D, CHEN B M. An approach to synthesize diverse underwater image dataset[J]. Instrumentation, 2019,6(3):67-75.
- [17] ZHANG Y, LI K, LI K, et al. Image super-resolution using very deep residual channel attention networks[C]. Proceedings of the European Conference on Computer Vision(ECCV), 2018: 286-301.
- [18] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2017: 136-144.
- [19] ZHANG K, ZUO W, ZHANG L. Deep plug-and-play super-resolution for arbitrary blur kernels [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 1671-1681.
- [20] ZHANG K, ZUO W, ZHANG L. Learning a single convolutional super-resolution network for multiple degradations[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 3262-3271.
- [21] 刘俊,吕芳,薛海鹏.结合高斯核与各向异性邻域抑制的模糊聚类图像分割[J].电子测量技术,2020,43(3): 132-138.
- [22] MAO X, SHEN C, YANG Y B. Image restoration using very deep convolutional encoder-decoder networks with symmetric skip connections [J]. Advances in Neural Information Processing Systems, 2016, 29(3): 2802-2810.
- [23] KINGMA D P, BA J. Adam: A method for stochastic optimization[J]. ArXiv E-prints, 2014, DOI:10.18550/arXiv.1412.6980.

作者简介

李佳(通信作者),硕士研究生,主要研究方向为深度学习、图像处理。

E-mail:1402106144@qq.com

李晨,博士,讲师,硕士研究生导师,主要研究方向为深度学习、图像处理。

E-mail:1075826261@qq.com

郭业才,博士,教授,博士生导师,主要研究方向为通信信号处理、水声信号处理和图像处理。

E-mail:guo-yecai@163.com