

基于深度强化学习的图像去模糊方法

王晓红¹, 曾静¹, 麻祥才², 刘芳¹

(1.上海理工大学, 上海 200093; 2.上海出版印刷高等专科学校, 上海 200093)

摘要: 目的 为了有效地去除多种图像模糊, 提高图像质量, 提出基于深度强化学习的图像去模糊方法。方法 选用 GoPro 与 DIV2K 这 2 个数据集进行实验, 以峰值信噪比 (PSNR) 和结构相似性 (SSIM) 为客观评价指标。通过卷积神经网络获得模糊图像的高维特征, 利用深度强化学习结合多种 CNN 去模糊工具建立去模糊框架, 将峰值信噪比 (PSNR) 作为训练奖励评价函数, 来选择最优修复策略, 逐步对模糊图像进行修复。结果 通过训练与测试, 与现有的主流算法相比, 文中方法有着更好的主观视觉效果, 且 PSNR 值与 SSIM 值都有更好的表现。结论 实验结果表明, 文中方法能有效地解决图像的高斯模糊和运动模糊等问题, 并取得了良好的视觉效果, 在图像去模糊领域具有一定的参考价值。

关键词: 去模糊; 残差学习; 深度强化学习

中图分类号: TS801.3 **文献标识码:** A **文章编号:** 1001-3563(2020)15-0245-08

DOI: 10.19554/j.cnki.1001-3563.2020.15.037

Image Deblurring Method Based on Deep Reinforcement Learning

WANG Xiao-hong¹, ZENG Jing¹, MA Xiang-cai², LIU Fang¹

(1.University of Shanghai for Science and Technology, Shanghai 200093, China;

2.Shanghai Publishing and Printing College, Shanghai 200093, China)

ABSTRACT: The paper aims to propose an image deblurring method based on deep reinforcement learning to effectively remove multiple image blurs and improve image quality. GoPro and DIV2K datasets were used for experiments. The peak signal-to-noise ratio (PSNR) and structural similarity index (SSIM) were used as objective evaluation indicators. The high-dimensional feature of fuzzy image was obtained by convolutional neural network. The deblurring framework was established by deep reinforcement learning combined with a variety of CNN deblurring tools. The peak signal-to-noise ratio (PSNR) was used as the training reward evaluation function to select the optimal restoration strategy and gradually restore the fuzzy image. Through training and testing, compared with the existing mainstream algorithm, the method presented in this paper had a better subjective visual effect; and the PSNR value and SSIM value had better performance. The experimental results show that the method in this paper can effectively solve the problem of Gaussian blur and motion blur of image, and obtain good visual effects. It has certain reference value in image deblurring.

KEY WORDS: deblurring; residual learning; deep reinforcement learning

收稿日期: 2019-11-20

基金项目: 上海市出版印刷高等专科学校柔板印刷绿色制版与标准化实验室资助项目 (ZBKT201809); 上海市教育发展基金会和上海市教育委员会“晨光计划” (18CGB09)

作者简介: 王晓红 (1971—), 女, 上海理工大学教授, 主要研究方向为数字图像信息处理与色彩再现理论。

数字图像在采集、传输过程中由于受到光学、大气、人为、技术等因素,造成图像不可避免地出现失真、退化等现象,从而影响到对图像的视觉感受以及对图像细节的捕捉。图像模糊是图像失真中常见的问题,因此图像去模糊也成了图像增强领域中不可缺少的一步。

图像模糊可分为很多种类,常见的有运动模糊、焦散模糊、高斯模糊等。传统方法中对图像模糊失真一般使用如下数学模型来表示图像模糊的过程:

$$I_B = K * I_S \quad (1)$$

式中: I_B 为模糊图像; I_S 为潜在的、未知的清晰图像; K 为一个由多个局部模糊核构成的矩阵,称为扩散函数(又称模糊函数),它与 I_S 卷积产生模糊图像; $*$ 为卷积符号。图像去模糊问题就可以表示为求解其扩散函数的问题,再通过扩散函数与模糊图像反卷积获得修复图像。

传统图像去模糊通常基于特征量来进行处理,一般使用 Lucy-Richardson 算法、维纳滤波算法、逆滤波算法^[1]等方法将模糊图像与所估计的模糊函数进行反卷积获得清晰图像。传统方法对模糊函数的估计不准确,导致图像去模糊效果不理想。

近年来,众多学者利用深度学习的方法对单一图像模糊进行修复。如 Sun 等^[2]使用卷积神经网络(Convolutional Neural Network)预测出非均匀运动图像模糊核集,再根据预测的模糊核重建图像; Nah 等^[3]提出使用多尺度卷积神经网络直接对图像进行端对端的训练,以达到去运动模糊的目的; Kup 等^[4]则利用条件生成对抗网络(GAN)对运动模糊图像进行训练,采用端对端的方式直接生成清晰图像。这些研究都是针对单图像模糊的问题,其模型应用范围有一定的局限性。

在解决多种图像模糊等失真的问题上, Gao 等^[9]提出一种按需学习算法,利用深度卷积网络同时处理图像模糊及其他失真。Zhang 等^[10]提出一种残差非局部注意力的方法对多种图像模糊等失真进行处理,并取得了较好的效果。2016 年 Google 研究团队将深度学习与强化学习联合,提出深度强化学习^[11]方法。Yu 等^[12]将深度强化学习应用到图像处理领域。此类处理方法需要考虑各种因素,导致处理结果精度不高,故文中提出利用深度强化学习的方法,对高斯模糊图像和运动模糊图像进行修复。通过训练智能体 Agent 选择不同的去模糊工

具作用于模糊图像,并利用一个联合的机制同时对去模糊工具进行训练,以达到图像去模糊的目的。

1 基本理论

1.1 CNN 残差网络

传统的卷积神经网络在学习和训练的过程中,整个网络通过向前传播的方式进行特征提取,然后整个网络会通过反向传播进行网络结构中权值的修改与调整。随着网络的加深,传统的 CNN 网络在信息传递时会出现信息丢失及损耗的问题,而残差网络则利用残差块进行跳跃连接的方式,直接将输入信息传到输出,解决了随网络加深梯度消失的问题^[13]。其网络框架见图 1。

残差框架结构中的非线性层拟合残差见式(2)。

$$\zeta(x) = H(x) - x \quad (2)$$

式中: $H(x)$ 为模糊图像; $\zeta(x)$ 为修复后的图像; x 为残差网络训练得到的模糊失真。由于模糊图像在残差网络中通过对其特征量进行提取和处理,相比于 $H(x)$ 会减少很多特征,更容易找到最优结果,同时网络训练时间也会相应地减少,性能也会相应地提高。对于多种图像模糊而言,单个 CNN 残差网络不能对其进行多线程处理,为了解决单一网络的不足,故将 CNN 残差学习作为修复工具与强化学习结合,以弥补其缺陷。

1.2 强化学习

强化学习是一个用于强化训练智能体 Agent 进行决策以最大限度增加累计回报的工具,通常使用马尔可夫决策^[14]过程(Markov Decision Process,简称 MDP)来描述。它是由智能体(Agent)、环境(Environment)、动作(Action)、状态(State)和奖励(Reward)组成。其在图像去模糊中可表述为,智能体为了完成图像去模糊的任务,在动作和环境的交互作用下,模糊图像在环境中会产生新的状态,同时环境会给出一个奖励,使智能体决策做出下一个动作。如此循环,智能体与环境进行不断地交互,从而产生大量数据,并利用数据进一步改善自身的行为,经过数次迭代学习后,使智能体最终完成相应去模糊任务,并得到最优策略。其框架见图 2。




图 1 残差网络

Fig.1 Residual network




图 2 强化学习框架

Fig.2 Reinforcement learning framework

强化学习应用于图像去模糊方法，是将图像提取出高维特征，并输入智能体进行训练，得到相应的修复动作，再利用与之对应的 CNN 残差网络进行图像去模糊修复。其中强化学习对应策略优化以获得最大化累计奖励，残差网络对应图像修复以获得去模糊图像，两者相互反馈从而得到最优的修复结果。

1.3 峰值信噪比 (PSNR) 损失函数

为了使智能体在接收到环境状态的反馈时做出合理的策略，需要给其一个客观的评判机制，使智能体得到正确的奖罚信号。利用峰值信噪比 (PSNR) 作为训练智能体 agent 评判标准项，使智能体 agent 给出最优的去模糊策略。峰值信噪比的定义式为：

$$P_{\text{PSNR}} = 10 \times \lg \left[\frac{(2^n - 1)^2}{L_{\text{MSE}}} \right] \quad (3)$$

式中： L_{MSE} 为原图像与模糊图像的均方根误差； n 为每个像素的比特数，一般取 8，即像素灰阶数为 256，2 个图像之间 PSNR 值越大，则越相似。为确保每一步动作后的图像质量都得到提高，文中将逐步奖励函数定义为：

$$R_t = P_{t+1} - P_t \quad (4)$$

式中： R_t 为在 t 时刻奖励损失函数； P_{t+1} 为图像

在 t 时刻动作结束时，与原始参考图像的 PSNR 值； P_t 为在 t 时刻与原始参考图像的 PSNR 值。为了最大限度地使奖励函数收敛到最大值，以达到最佳去模糊效果，文中将损失函数定义为：

$$L_{\text{PSNR}}(t) = \sum_{t=1}^T |P(t) - P_1| \quad (5)$$

式中： P_1 为初始模糊图像与原始参考图像的 PSNR 值，即求 L_{PSNR} 的最大值，使得函数收敛于某一数值，得到最优去模糊策略。

2 基于深度强化学习的图像去模糊方法

文中利用深度强化学习框架，针对图像高斯模糊与运动模糊，实现图像的去模糊。该网络分为 2 个部分：深度强化学习决策、CNN 残差修复工具，网络框架见图 3。

文中将深度强化学习与 CNN 残差网络相结合，在不断进行智能体 (Agent) 训练的过程中，寻找最佳去模糊策略。首先通过特征提取模块提取模糊图像特征量，其特征提取模块是由 4 个卷积层和上 1 个全连接层组成，输出一个维度为 32 的特征矩阵。然后将提取结果输送到智能体中进行训练决策，智能体从去模糊工具中决策使用相应的 CNN 残差网络作用于模糊图像，再将其结果输出到环境 (Environment) 判断图像修复结果，通过 PSNR 奖励损失函数给出当前奖赏值并累计记录，并反馈当前图像状态给智能体。通过反复循环迭代此训练过程，逐步对图像进行去模糊处理，直到使累积奖励值达到最大，输出最优修复结果。

2.1 深度强化学习决策

深度强化学习决策部分包含特征提取模块、智能体 (Agent)、动作 (Action)、奖励函数 (Reward)、




图 3 基于深度强化学习的图像去模糊框架

Fig.3 Image deblurring framework based on deep reinforcement learning

状态 (State) 和环境 (Environment)。

1) 特征提取模块。特征提取模块即非线性映射模块,一般由 4 个卷积层和 1 个全连接层组成,在智能体进行训练前,将当前图像进行预处理,提取出一个 32 维的特征矩阵,以更好地表示图像的特性,从而使智能体更好地理解图像进行训练。

2) 智能体 (Agent)。智能体通过接收特征提取模块所提取的图像高维特征做出决策,选择适当的 Action (即多种 CNN 残差网络) 作用于模糊图像,并将修复结果输出到环境 (Environment),同时产生一个奖罚信号反馈给智能体,智能体根据奖罚信号和环境当前的状态 (state) 选择下一个动作,以此反复迭代更新修复策略,使得累积奖赏 (Reward) 达到最大值。

3) 动作 (Action)。用 A 表示动作空间,其含义为智能体所采取的一系列的可能动作,在每个状态 t ,选择合适的操作 A_t 并将其应用于当前的图像,执行 Action 达到最大化期望 Reward,所得的记忆存储器 Memory 就是一系列 Action 的集合。文中定义每个 Action 代表不同深度的 CNN 残差网络,见表 1,其包含了 8 个用于不同模糊图像且不同模糊程度的去模糊工具,每个工具都能完成指定的去模糊任务,即每一种工具只在特定的范围内作用于图像。表 1 中,每个工具都被分配用于不同程度的高斯模糊或运动模糊图像上,其中 3 层网络结构用于轻量级模糊图像处理,8 层网络结构用于严重的模糊图像处理。

表 1 CNN 残差去模糊网络工具
Tab.1 CNN residual deblurring network tool

模糊类型	模糊程度	网络深度
高斯模糊 σ	[0,1.25], [1.25,2.5]	3
	[2.5,3.75], [3.75,5]	8
运动模糊 L	[0,12.5], [12.5,25]	3
	[25,37.5], [37.5,50]	8

4) 奖励函数 (Reward)。在深度强化学习中,算法的学习目标是最大化所有步骤的累计奖励,因而奖励是驱动算法学习的关键。为确保图像质量在每一阶段都能得到提升,文中利用初始模糊图像的 PSNR 值与当前修复图像的 PSNR 值的差值累计作为奖励函数,见式 (5)。其损失函数结果最终收敛于某一数值,从而得到最优去模糊策略。

5) 环境状态 (Environment)。智能体 (Agent) 被置于某一环境 (Environment) 中,状态即在 t 时刻图像的去模糊情况。在任何时候,环境总是处于某种状态 (State),环境根据当前状态反馈奖赏值给智能体。智能体从反馈的奖赏值再做出可能的动作,使图像得到进一步的修复。智能体一旦选择并做了某一动

作,状态就随之改变。问题的解决需要执行一系列的动作,之后得到反馈,反馈以奖励的形式输出到智能体,通常只有在完整的动作序列执行完毕时才发生。

2.2 CNN 残差修复工具

CNN 残差修复工具是由一系列的 CNN 去模糊残差网络组成,其通过智能体的决策作用而分别作用于相应的模糊图像,并通过反复迭代的方式进行图像修复工作。深度强化学习通过训练智能体 Agent 来学习一项最优策略,选择合适的 CNN 残差网络对图像进行修复。文中利用多个 CNN 残差网络作为深度强化学习中的动作 (Action),并定义当前修复图像 PSNR 值与初始模糊图像 PSNR 值的差值作为损失函数,每个修复工具的梯度在每 1 次训练中进行累积,最后利用最大梯度更新相应的去模糊工具,经过多次迭代,最终得到一系列的去模糊工具。文中将多种 CNN 残差网络层数定义为 3 层或 8 层,在训练中与深度强化学习的决策进行相互反馈,对模糊图像进行去模糊处理。

3 实验结果与分析

3.1 数据集与评价指标

文中选用 GoPro 与 DIV2K 这 2 个数据集进行实验,GoPro 数据集包含 3214 对模糊图像与高质量图像,其中含有 2103 对训练图像,1111 对测试图像。DIV2K 数据集包含了 800 张高质量图像,文中的训练集分别由 GoPro 运动模糊训练图像与 DIV2K 数据集所生成高斯模糊图像组成。数据生成将图像裁剪成 63×63 的图像块,并通过旋转、缩小因子 2, 3, 4 等来增加数据量来训练,分别生成 252 929 张高斯模糊训练子图与 1 464 946 张运动模糊训练子图。测试集选用数字图像处理常用的 10 张图像和 Kodak24 数据集联合作为高斯模糊测试集,选用 GoPro 数据集中 1111 张测试图像作为运动模糊测试集。

为了验证网络的有效性,通过主观评价和客观评价 2 种方法对图像进行对比。客观评价方法采用峰值信噪比 (PSNR) 与结构相似度 (SSIM),PSNR 定义见式 (3),SSIM 定义见式 (6)。

$$S_{SSIM}(x, y) = \frac{(2\epsilon_x \epsilon_y + d_1)(2\sigma_{xy} + d_2)}{(\epsilon_x^2 + \epsilon_y^2 + d_1)(\sigma_x^2 + \sigma_y^2 + d_2)} \quad (6)$$

式中: x, y 为 2 幅图像; ϵ_x, ϵ_y 为均值; σ_x^2 和 σ_y^2 为方差; σ_{xy} 为 x 和 y 的协方差; $d_1 = (k_1 L)^2$, $d_2 = (k_2 L)^2$, L 为像素值的动态范围, $k_1 = 0.01$, $k_2 = 0.03$ 。SSIM 的值为 0 ~ 1 之间,SSIM 的值越大,则 2 幅图像越相似。

文中将高斯模糊通过添加随机级别到训练图像中,高斯模糊的标准差 σ 定义在区间 [0, 5] 内,步长为 0.5,在该区间中随机添加高斯模糊到图像,生成高斯模糊训练图。利用 GoPro 数据集作为运动模糊训练图像,将

训练图分别输入深度强化学习网络中进行训练。

3.2 训练参数

文中训练参数设置见表 2，训练中网络的输入为 63×63 的图像块。在 CNN 残差网络中，每个卷积层采用 128 个尺寸为 3×3 的滤波器，学习率为 0.001，动量参数为 0.9，通过随机初始化卷积权重来训练网络和正则化强度，即权重衰减为 0.0001。在深度强化学习的训练中，文中通过使用深度 Q-learning 进行训练，其奖励折扣因子为 0.99，选用 Adam^[15]优化器对回归目标进行优化训练，批量处理大小为 32，最大处理步长 $T_{\max}$ 设置为 2，重放储存器的大小选择为 5×10^5 ，更新频率 $C=2500$ ，使得目标网络每 2500 次复制迭代 1 次，学习率从 2.5×10^{-4} 到 2.5×10^{-5} ，直到 5×10^5 次迭代终止。

文中分别对高斯模糊与运动模糊图像进行了训练和测试，都在 TensorFlow 工具上进行，实验硬件设备为 Intel Core i3-4790k 4.0 GHz，NVIDIA Quard T4000 GPU。

3.3 实验结果与分析

3.3.1 基于高斯模糊图像质量分析与评价

为了验证算法的有效性与稳定性，文中选取了 2 个具有代表性的测试集进行测试，分别为数字图像处理常用的 10 张图像与 Kodak24 数据集中 24 张图像，常用数字图像处理数据集见图 4。

文中在不同的测试集上生成不同模糊程度的高斯模糊图像，并分别计算出在各个模糊等级下，模糊图像与修复图像的平均 PSNR 值与平均 SSIM 值，其结果见表 3—4。

表 3—4 分别展示了模糊原图与 Kodak24 数据集与常用图像集在经过文中算法去模糊处理后修复图像的平均 PSNR 值与 SSIM 值。从表 3—4 中的数据可以看出，文中算法对高斯模糊图像恢复性能高，有着良好的去模糊效果，其部分修复图像主观视觉效果见图 5。

表 2 参数设置
Tab.2 Parameter settings

区块名称	参数名称	参数
训练图像	图像块尺寸	63×63
	高斯模糊核区间	[0,5]
CNN 残差网络修复	每层卷积核数量	128
	卷积核尺寸	3×3
	动量参数	0.9
	学习率	0.001
	折扣因子	0.99
深度强化学习决策	批处理大小	32
	最大处理步长	2
	储存器大小	5×10^5
	更新频率	2500
	终止迭代次	5×10^5



图 4 常用数字图像处理数据集
Fig.4 Commonly-used digital image processing dataset

表 3 Kodak24 数据集模糊图像与修复图像平均 PSNR 与 SSIM 值
Tab.3 Average PSNR and SSIM values of blurred and restored images in Kodak24 dataset

数据集	峰值信噪比(PSNR)		结构相似度(SSIM)	
	模糊图	修复图	模糊图	修复图
$\sigma=1$	28.5	32.2	0.904	0.954
$\sigma=3$	23.6	30.1	0.777	0.889
$\sigma=5$	22.6	27.2	0.744	0.853

表 4 常用图像集模糊图像与修复图像平均 PSNR 与 SSIM 值
Tab.4 Average PSNR and SSIM values of blurred and restored images in common-used datasets

数据集	峰值信噪比(PSNR)		结构相似度(SSIM)	
	模糊图	修复图	模糊图	修复图
$\sigma=1$	28.8	30.7	0.878	0.943
$\sigma=3$	24.5	28.8	0.813	0.859
$\sigma=5$	23.1	26.4	0.762	0.826




图 5 高斯模糊参数 $\sigma=5$ 的视觉对比效果
Fig.5 Visual contrast effect of Gaussian fuzzy parameter $\sigma=5$

为了更好地验证算法的有效性,文中将算法模型输出结果与 FISTA^[6]算法、FGSIA^[7]算法、SRCNN^[16]算法进行比较。由于上述 FISTA 算法、FGSIA 算法、SRCNN 算法只利用 PSNR 值来对图像进行评价,故文中在 Kodak24 数据集上以 24 张图像的 PSNR 平均值作为评价标准,结果见表 5。

表 5 Kodak24 数据集上 $\sigma=3$ 时不同算法平均 PSNR 对比

Tab.5 Comparison of the average PSNR of different algorithms with the algorithm of $\sigma=3$ on the Kodak24 dataset

算法	PSNR 值
FISTA	27.9
FGSIA	28.6
SRCNN	29.1
文中算法	30.1

由结果看以看出,文中算法在去高斯模糊方面具有良好的性能,与算法 FISTA, FGSIA, SRCNN 相比较也有明显的提高,结合图 5 和表 5 可知,文中算法在主观视觉与客观评价方面也有较好的提升。

3.3.2 基于运动模糊图像分析与评价

GoPro 数据集由训练集和测试集组成,共 3214 对运动模糊图像和高质量图像,其中训练集有 2103 对图像,测试有 1111 对图像,图像的分辨率均为 720 像素,包含来自各种场景的图像,在去运动模糊领域广泛应用。文中在测试集上对模型进行评估,并将结果与文献[3]、文献[4]中的方法进行对比,其主观视觉效果见图 6。

运动模糊原图见图 6a, Nah[3]处理结果见图 6b, Kup[4]处理结果见图 6c,文中处理结果见图 6d。图 6 结果表明,文中算法模型在图像去运动模糊方面有较好的效果。与文献[3—4]相比在细节方面有明显的提升。



图 6 运动模糊图像与各类算法对比
Fig.6 Comparison of motion blurred images and various algorithms

将文中算法分别与其他去模糊算法在量化指标上进行比较,以 GoPro 数据集中 1111 张测试图像的平均 PSNR 值与 SSIM 值作为参考对象,其结果见表 6。

表 6 在 GoPro 测试集中与各类算法平均 PSNR 值与 SSIM 值对比
Tab.6 Comparison of average PSNR and SSIM values in various GoPro test sets and algorithms

方法	PSNR 值	SSIM 值
文献[2]	24.6	0.842
文献[3]	28.3	0.916
文献[4]	28.7	0.958
文中算法	30.3	0.938

从表 6 可以看出,文中算法在去运动模糊中也有很好的表现效果,与其他算法对比其表现也更为突出,细节还原也有显著的提高,数据显示在 PSNR 量化指标上高于对比文献。由于文中方法应用于多种图像模糊,故 SSIM 值略低于文献[4],但文中算法综合性能更强,适用范围更广。

4 结语

文中提出利用一个深度强化学习框架结合多种

CNN 残差去模糊工具的图像去模糊方法,该框架有效地解决了多种图像模糊问题。与大多数现有的基于深度学习的方法不同,文中通过将深度强化学习中的决策能力与 CNN 残差网络中的修复功能结合,并利用 PSNR 作为奖励函数,逐步训练深度强化学习中的智能体 Agent,最大化累计奖励,最终得到去模糊图像。对比结果表明,无论是在主观视觉对比还是客观定量分析中,文中提出的方法都能得到在细节与纹理方面更好的修复效果,有效地实现对图像高斯模糊与运动模糊的增强。

参考文献:

[1] 杨东. 模糊降质图像恢复技术研究进展[J]. 计算机应用研究, 2016, 33(10): 2882—2888.
YANG Dong. Research Progress in Fuzzy Degradation Image Restoration Technology[J]. Application Research of Computers, 2016, 33(10): 2882—2888.

[2] SUN J, CAO W, XU Z, et al. Learning a Convolutional Neural Network for Non-uniform Motion Blur Removal[C]// IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2015: 769—777.

[3] NAH S, KIM T H, LEE K M. Deep Multi-scale Convolutional Neural Network for Dynamic Scene Deblurring[C]// IEEE Conference on Computer Vision and

- Pattern Recognition (CVPR), 2017: 3883—3891.
- [4] KUPYN O, BUDZAN V, MYKHAILYCH M, et al. DeblurGAN: Blind Motion Deblurring Using Conditional Adversarial Networks[C]// IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8183—8192.
- [5] SAKURIKAR P, MEHTA I, BALASUBRAMANIAN V N. RefocusGAN: Scene Refocusing Using a Single Image[C]// The European Conference on Computer Vision(ECCV), 2018: 497—512.
- [6] ALONSO J. Synthetically Reshaped Aperture for Postacquisition Three-dimensional Scene Refocusing from a Multi-focus Image Stack[C]// 3D Image Acquisition and Display, Technology, Perception and Applications, 2016: 25—28.
- [7] ZUO W, MENG D, ZHANG L, et al. A Generalized Iterated Shrinkage Algorithm for Nonconvex Sparse Coding[C]// IEEE International Conference on Computer Vision, 2013: 217—224.
- [8] ZUO W M, REN D W, ZHANG D, et al. Learning Iteration-wise Generalized Shrinkage-thresholding Operators for Blind Deconvolution[J]. IEEE Transactions on Image Processing, 2016, 25(4): 1751—1764.
- [9] RUOHAN G, KRISTEN G. On-demand Learning for Deep Image Restoration[C]// IEEE International Conference on Computer Vision(ICCV), 2017: 1086—1095.
- [10] ZHANG K, ZUO W, GU S, et al. Learning Deep CNN Denoiser Prior for Image Restoration[C]// IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2017: 3929—3938.
- [11] 刘全, 翟建伟, 章宗长, 等. 深度强化学习综述[J]. 计算机学报, 2018, 41(1): 3—29.
- LIU Quan, ZHAI Jian-wei, ZHANG Zong-chang, et al. Overview of Deep Reinforcement Learning[J]. Chinese Journal of Computers, 2018, 41(1): 3—29.
- [12] KE Y, CHAO D, LIANG L, et al. Crafting a Toolchain for Image Restoration by Deep Reinforcement Learning[C]// IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 2443—2452.
- [13] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition[C]// IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770—778.
- [14] ROTH S, BLACK M J. Fields of Experts[J]. International Journal of Computer Vision, 2009, 82(2): 205—229.
- [15] DIEDERIK P K, JIMMY B. Adam: A Method for Stochastic Optimization[C]// International Conference for Learning Representations (ICLR), 2015.
- [16] DONG C, LOY C, HE K, et al. Image Super-resolution Using Deep Convolutional Networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2): 295—307.