

深度卷积先验引导的鲁棒图像层分离方法及其应用

姜智颖 刘日升

(大连理工大学-立命馆大学国际信息与软件学院 辽宁 大连 116621)

(辽宁省泛在网络与服务软件重点实验室 辽宁 大连 116621)

摘要 图像层分离是根据任务需要将观测图像分解成两个独立且具有实际意义的组成成分。图像恢复领域中的很多问题在本质上都可以被理解为两个不同层的分离,如自然图像去雨、本质图像分解、反射层去除等。因此,做好图像层分解工作对解决这些问题有极大的推动作用。由于这个问题的求解具有病态性,已有的方法大多都是通过设计一个复杂的模型先验来约束所需要的两层。然而,复杂的先验会导致目标函数难以被优化求解,算法的有效性也不能很好地发挥出来。更重要的是,这些方法只能针对其中某一个特定的任务,不能迁移到其他应用上,泛化能力不强。为了弥补上述不足,文中提出了一个自适应的灵活优化框架,将深度网络整合到图像层分离迭代过程中。近年来,深度学习在特征提取上的优势逐步体现,在低级图像处理领域也越来越多地被采用。因此,该算法使用深度结构替代传统模型先验来刻画不同层的特征,同时,为了减少网络对训练数据的依赖并提升算法的有效性,将深度信息与传统优化框架相结合。具体来讲,首先基于 MAP(最大后验概率)建立能量函数。然后使用 ADMM(交替方向乘子法)将该模型分解成 3 个子问题。前两个子问题用来估计分离的两层,其中鉴于卷积操作在特征刻画上的优势,使用其作为隐式先验刻画问题属性;最后一个子问题通过优化的手段得到最终的精确结果。通过深度卷积先验引导优化迭代,既保持了深度结构对特征的刻画优势,又保留了传统模型优化的稳定性。最后,将所提方法应用到多种图像恢复问题上,包括自然图像去雨和反射层去除。与同类方法的定性定量比较表明,所提方法在可视效果和数值结果上均表现出了极大的优势,证明了该方法具有强大的泛化能力和有效性。

关键词 层分离,反射层去除,自然图像去雨,残差网络,最大后验概率估计

中图分类号 TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2019.03.017

Deep Convolutional Prior Guided Robust Image Separation Method and Its Applications

JIANG Zhi-ying LIU Ri-sheng

(Dalian University of Technology-Ritsumeikan University International School of Information

Science & Engineering, Dalian, Liaoning 116621, China)

(Key Laboratory for Ubiquitous Network and Service Software of Liaoning Province, Dalian, Liaoning 116621, China)

Abstract Single image layer separation aims to divide the observed image into two independent and practical components based on the requirement of tasks. Many tasks in computer vision can be understood as the separation of two different layers essentially, such as single image rain streak removal, intrinsic image decomposition and reflection removal. Therefore, an excellent image layer decomposition method would promote the solution of these problems greatly. Since there is only one known variable, two variables need to be recovered. This problem is fundamentally ill-posed. Most existing approaches tend to design complex priors according to the different characteristics between the two separated layers. However, loss function with complex prior regularization is hard to be optimized. Performance is also compromised by the fixed iteration schemes and less data fitting ability. More importantly, these conventional prior based methods can only be applied to one specific task as they are weak in generalization. To partially mitigate the limitations mentioned above, this paper developed a flexible optimization technique to incorporate deep architectures into optimization iterations for adaptive image layer separation. As we all know, the convolutional neural network is a network structure composed of convolutions and other non-linear operations. The convolution operation uses different convolution kernels to extract different features for a given image, so the convolution kernel has very strong capabilities for feature extraction. Recently, the advantages of deep learning in feature extraction have been gradually reflected and are increasingly

到稿日期:2018-07-22 返修日期:2018-09-25 本文受国家自然科学基金(61672125,61733002,61572096,61432003,61632019)资助。

姜智颖(1995-),女,硕士生,主要研究方向为图像处理,E-mail:zyjiang@mail.dlut.edu.cn;刘日升(1984-),男,博士,副教授,CCF会员,主要研究方向为机器学习、优化方法、计算机视觉和多媒体技术,E-mail:rsliu@dlut.edu.cn(通信作者)。

used in the low-level image processing. Therefore, the proposed method uses deep convolutional prior instead of traditional model prior to characterize different layers. At the same time, in order to reduce the network's dependence on training data and improve the effectiveness of the algorithm on different tasks, deep information is combined with traditional optimization framework. Specifically, energy function using MAP (Maximum A Posteriori) is built and then the model is transferred to three subproblems based on ADMM (Alternating Direction Method of Multipliers). The first two subproblems are to estimate two approximate separated layers, and the other subproblem is to solve the final result. In other words, deep convolutional networks are used to guide the process of model optimization. In this way, the proposed method not only retains the advantage of feature extraction in deep structure, but also maintains the stability of traditional model optimization and improves the effectiveness of networks. Finally, this method is applied to a variety of image restoration tasks, including single image rain streak removal and reflection removal. By comparing this method with several tasks-specific methods including conventional model methods and deep learning methods respectively, this method shows great advantages in both visual effects and numerical results. It reveals that this method has a strong generalization in multi-tasks and outperforms other methods in each task.

Keywords Layer separation, Reflection removal, Rain streak removal, Residual network, Maximum a posteriori estimate

1 引言

计算机视觉领域中的很多问题都可以被抽象理解为由两个独立成分组成,如自然图像去雨、本质图像分解、反射去除、卡通纹理分解等。通过对观测图像加一些特征约束,可以得到这两个独立的具有实际意义的成分。在自然图像去雨中,观测到的雨图可以被理解为自然背景层和雨层的组合,雨线的存在会导致背景模糊、重要信息被遮挡,从而造成图像质量下降。而交通监控、自动驾驶等应用的准确性保障条件之一就是输入数据准确且清晰。因此,去除观测图像中的可视雨线,恢复出干净的背景,具有重要作用。当透过一面类似玻璃等透明介质拍摄图片时,图像往往会受到相机侧面物体反射的干扰,因此将得到的图像视为背景层和反射干扰层的组合。反射层的存在不仅会降低图像质量,而且会使很多计算机视觉任务(如分割、分类、识别等)失效。因此,消除反射干扰,还原图像真实场景,对于计算机进一步处理和利用图像信息是十分关键的。下面简单介绍图像层分离以及基于图像层分离的应用。

1.1 相关工作

1.1.1 图像层分离

目前,能普遍应用的图像层分离方法还比较少,大多是针对目标层设计不同的模型先验。Gu等人^[1]通过学习一个ASR字典和SSR字典来分别表示稀疏和不稀疏的两层,并且对于不同的应用,需要重新进行字典学习。字典学习比较复杂,而且对于不存在稀疏性差别的层分离问题,这种方法并不适用。Liang等人^[2]提出对所需分离的两层的梯度分别施加L0和L1范数约束,这与Gu等人^[1]的方法有相似之处,都是对稀疏性的应用;同时,该方法的提出主要是针对色调映射的,在其他应用上的表现还有待测评。

1.1.2 图像去雨

目前解决图像去雨问题的方法主要分为两大类:基于模型先验的方法和基于深度学习的方法。

基于模型先验的传统方法注重于利用传统模型来分别刻

画背景层和雨层两部分,由于雨的特殊性,对于雨层的先验往往设计得比较复杂。最早研究图像去雨的是Kang等人^[3],他们提出采用字典学习的方法来刻画高频层中的雨线。Huang等人^[4]在此基础上结合了图像内容信息,雨的位置可以被自动地识别出来。但是基于字典学习的方法会导致结果模糊,图像恢复效果不是很好。Luo等人^[5]采用判别稀疏编码来区别雨层和背景,但是该方法对雨线的刻画并不充分,结果中仍保留着大量的可视雨线。Li等人^[6]将高斯模型与块学习的思想相结合,针对每幅雨图,学习该图像的雨线分布,再在图像中用该模型刻画雨层,同时使用高斯混合模型刻画背景层。该方法是目前已有的基于模型的方法中效果最好的,但是其估计得到的背景仍存在细节缺失,导致图像不清晰。

最近的图像去雨研究大多是基于深度学习进行的。Fu等人^[7]基于高频和低频层的区别,针对高频层设计了一个去雨的网络。后来他们^[8]又对网络的结构进行进一步改进,对深度残差网络的学习形式进行了简化,提出了深度细节网络,以解决图像去雨问题。Yang等人^[9]利用多任务网络结构同时学习雨线分布、雨的形态以及背景。该网络能够同时检测和去除雨线,并针对不同强度的雨进行不同程度的去除操作。实验表明:虽然基于深度学习的方法比传统模型方法更为有效,图像恢复得更好,但是该类方法具有数据依赖性,需要大量且丰富的训练数据才能得到有较好泛化能力的网络。然而在千变万化的真实环境中,该方法对复杂场景的恢复效果不尽如人意。

1.1.3 反射层分离

由于反射图像与背景图像十分相似,图像去反射十分困难。Li等人^[10]对反射层加了一个光滑的梯度约束,在背景层加了一个稀疏的梯度约束,通过这两个先验项来区别背景图像和反射图像。Shih等人^[11]使用双脉冲卷积核对反射进行建模,并自动估计反射分量的分离和衰减。Springer等人^[12]使用拉普拉斯数据项和梯度的0范数进行建模,通过半二次优化能量函数得到背景层和反射层。上述方法虽然有一定的

效果,但是当应用在复杂的真实场景下时,不能很好地区别背景和反射干扰层,恢复效果并不理想。

1.2 本文贡献

本文提出了一个可以应用于多种层分解任务的灵活优化框架。利用卷积神经网络的深度结构来刻画不同层的特征,同时为了弥补深度学习的数据依赖,提高网络的有效性,将深度卷积先验与模型优化相结合,使用深度先验替代传统模型先验,既保留了算法的泛化能力,又提升了网络方法对复杂场景处理的有效性。将本文的方法应用到自然图像去雨和反射层去除等情况下,实验结果表明:本文方法无论是在定量的数值化比较,还是在定性的可视化效果比较上,均优于已有的同类方法,从而证明了其泛化能力和有效性。

2 深度卷积先验引导的鲁棒图像层分离方法

2.1 深度结构刻画特征

传统的图像层分解方法需要根据目标层之间的特征差别,针对不同层设计复杂的先验,因此这些方法只能解决某一类特定的任务。而本文的目标是希望得到一种可适性更强、应用范围更广的方法。显然,传统建模的方式不能满足我们的要求。

卷积神经网络是一种由卷积、池化、激活等非线性操作构成的网络结构。其中,卷积操作是对一个给定图像使用不同的卷积核提取不同的特征,因此卷积核对于特征的提取有非常强的能力。受 Zhang 等人^[13]在图像去噪、去模糊和超分辨率等问题上操作的启发,我们提出使用一个深度卷积网络来从训练数据中学习刻画层的特征。然而,由于网络的数据依赖性以及真实场景的复杂性,虽然该网络可以应用到多种图像恢复任务中,但是其针对每一项应用的效果都不太令人满意,并不能与特定任务的传统方法相媲美。因此,单纯依靠深度学习来解决这个问题存在一定的难度。为了弥补这些不足,我们考虑将深度结构与传统模型优化相融合,尝试将两种不同方法的优势进行结合,通过深度结构引导模型优化,在提升算法泛化能力的同时兼顾算法在不同应用上效果的优越性。

2.2 基于优化的图像建模

针对层分解问题的特点,将观测图像视为具有独立意义的两个层的组合,因此本文使用如下线性组合表示该模型:

$$O = B + R \quad (1)$$

其中, $O \in \mathbb{R}^{M \times N}$ 表示输入的观测图像, $B \in \mathbb{R}^{M \times N}$, $R \in \mathbb{R}^{M \times N}$ 表示我们希望分离得到的两层。由于已知变量只有一个观测图像,因此这个问题的求解是病态的。在图像恢复问题中,对于病态问题的求解,基于概率的建模手段十分常用。本文基于最大后验概率(MAP),充分考虑所要恢复的两层的特征,最大化两层的联合概率,即:

$$p(B, R | O) \propto p(O | B, R) \cdot p(B) \cdot p(R) \quad (2)$$

则可以将层分解问题转化为求解如下最小化问题:

$$\min_{B, R} \|O - B - R\|_F^2 + \Phi(B) + \Psi(R) \quad (3)$$

其中, $\|\cdot\|_F^2$ 表示 Forbenius 范数,第一项 $\|O - B - R\|_F^2$ 是数据项,用来维持恢复图像层和观测图像之间的稳定性;

$\Phi(B)$ 和 $\Psi(R)$ 是先验项,用来约束提取不同层的结果。解决这种优化问题的传统思想是将难于直接求解的问题转化成多个易于求解的子问题。这里采用交替方向乘子算法(ADMM)^[14]将该问题分解成3个子问题:

$$P^{(k+1)} = \arg \min_P \Phi(P) + \frac{\rho_B}{2} \|P - \tilde{P}^{(k)}\|_F^2 \quad (4)$$

$$Q^{(k+1)} = \arg \min_Q \Psi(Q) + \frac{\rho_R}{2} \|Q - \tilde{Q}^{(k)}\|_F^2 \quad (5)$$

$$B^{(k+1)}, R^{(k+1)} = \arg \min_{B, R} \|O - B - R\|_F^2 + \frac{\rho_B}{2} \|B - \tilde{B}^{(k)}\|_F^2 + \frac{\rho_R}{2} \|R - \tilde{R}^{(k)}\|_F^2 \quad (6)$$

式(4)和式(5)分别表示在先验约束下得到的两个近似目标层;式(6)中 $\tilde{B}^{(k)} = P^{(k-1)} - \bar{S}^{(k-1)}$, $\tilde{R}^{(k)} = Q^{(k-1)} - \bar{T}^{(k-1)}$,其中 $\bar{S}^{(k-1)}$ 和 $\bar{T}^{(k-1)}$ 是拉格朗日乘子。通过固定式(4)和式(5)的结果,使用 L-BFGS^[15]算法得到最终分离的两层结果。

2.3 引入深度卷积先验的可学习模型优化策略

上节已经提出了完整的优化框架,但是对 P, Q 两个重要子问题的求解才是关系到分离结果好坏的关键一步,因为用来提取各层特征的是式(4)和式(5)中的先验约束,只有把特征表示得准确、清晰,才能得到相对好的结果。2.1节讨论了深度学习有很强的特征提取能力,它通过学习大量的训练数据得到网络中的各个参数,这些参数就是用来提取特征的卷积核等。这里提出使用一个深度卷积网络来学习目标层的特征,也就是不像传统模型方法那样构造显式的模型先验,而是将深度卷积神经网络作为隐式先验,并且把这个隐式先验引入到模型的迭代优化过程中,通过深度卷积先验来引导迭代优化。因此,迭代过程中的式(4)和式(5)可以被表示成:

$$P^{(k+1)} = \mathcal{Q}(\tilde{P}^{(k)}; \Theta_P) \quad (7)$$

$$Q^{(k+1)} = \mathcal{F}(\tilde{Q}^{(k)}; \Theta_Q) \quad (8)$$

其中, Θ_P, Θ_Q 是分别针对不同层特征的参数, \mathcal{Q}, \mathcal{F} 表示网络的处理操作。为了得到效果最好的网络,我们测试了不同的网络结构,包括加深网络结构、更改每个功能块的操作组合等。最终在兼顾网络效果和代价两方面的情况下,我们确定了一个18层的深度卷积神经网络,该网络包括1个由卷积和 ReLU (Rectified Linear Unit) 操作构成的初始块,5个由卷积操作、BN (Batch Normalization)、ReLU 组成的中间模块,以及只有卷积操作的结束模块。图1展示了网络的详细结构。

在网络的训练中,损失函数采用欧几里得损失 (Euclidean Loss),即:

$$\mathcal{L}(\Theta) = \frac{1}{2N} \sum_{i=1}^N \|u_i - u_{gt}\|_F^2 \quad (9)$$

其中, N 表示训练对的数量, u_i 表示网络输出的结果图像, u_{gt} 是与之相对的输入图像。损失函数的值越小,表示模型对数据的拟合程度越高,越能更好地刻画图像特征。以图像去雨为例,雨层先验(\mathcal{F})是用来刻画雨层的特征。我们依据问题模型合成了一系列的训练数据。为了使该网络能适用于真实场景,该组训练数据从 BSDS^[16]数据库中取材,囊括了多种风

格的自然背景;然后又从 Garg 等人^[17]关于仿真雨的研究中收集雨图资源,包括不同强度、不同方向、不同形状的雨线,按照雨图的生成模型,最终合成了训练数据集。在训练的过程中,首先将训练数据裁剪成大小为 40×40 的小块,然后通过旋转和翻转来增加小块的数量,从而增强网络的能力。而对于背景层先验⁽⁹⁾,其目的是刻画清晰的自然场景。Zhang 等人^[13]用于去噪的残差网络的目的也是刻画自然图像的分布,




图1 本文所用网络的结构

Fig. 1 Architecture of network used in this paper

3 实验结果

为了验证本文方法在有效性和泛化能力上的效果,我们将该方法应用到两个图像恢复问题上:自然图像去雨和反射层分离。针对每一个问题,分别在合成数据和真实数据上进行测试。为了更好地测评结果,针对合成数据,还使用结构相似性(SSIM)和峰值信噪比(PSNR)作为评价指标进行定量的比较,值越高表示恢复结果与真实场景(Ground Truth)越相近。

3.1 自然图像去雨

由于雨线的分布具有不确定性,很难被刻画,因此图像去雨是一个具有挑战性的任务,也吸引了越来越多的关注。将所提方法与近几年效果明显的方法进行对比,包括字典学习的方法(SR^[3])、判别稀疏编码的方法(DSC^[5])、基于高斯混合模型的方法(GMM^[6])和基于深度学习的两种方法(DerainNet^[7]和 DetailNet^[8])。由于图像去雨问题还没有标准数据库,因此我们合成了12张雨图用作测试集。图2展示的是各

因此我们采用该模型来提取自然背景。图像去反射等其他问题与图像去雨相似,反射层和背景层均使用网络来刻画特征,再通过网络的结果引导模型的优化,从而得到最终的结果。对于训练数据,我们仍在BSDS^[16]中随机选定两层的自然图像,对反射层的图像使用不同的模糊核进行卷积,得到相对模糊的反射层,然后依据生成模型合成得到仿真的反射图像。

种方法在合成数据上的可视化效果,不难发现SR^[3]方法由于是对高频层的直接处理,其结果很模糊,图像中的细节信息被丢失;DSC^[5]方法的去雨效果并不明显,仍然残留了大量的可视雨线;GMM^[6]方法具有一定的去雨效果,但是背景中的细节仍有一部分丢失。至此,我们验证了前面的结论:基于模型的传统方法对雨线的刻画有一定难度,并且会丢失背景信息;而基于深度学习的方法(DerainNet^[7]和 DetailNet^[8])的结果虽然对背景的保留很好,但是并不能完全达到去雨的效果,这是由于测试数据与该方法的训练数据差别比较大,这两种方法在该测试数据上并不能完全发挥它们的作用。观察图2最后一列,即本文方法的结果,不难发现,本文方法结合了传统迭代和数据驱动的优势,在去除雨线的同时最大程度地保留了背景图像的细节,并且除雨效果在这6种方法中也是最明显的。定量比较的结果如表1所列,我们将测试集上的结果取平均值,可以发现本文方法无论是在结构相似性(SSIM)还是在峰值信噪比(PSNR)上的结果都是最高的,这与可视化结果相一致。

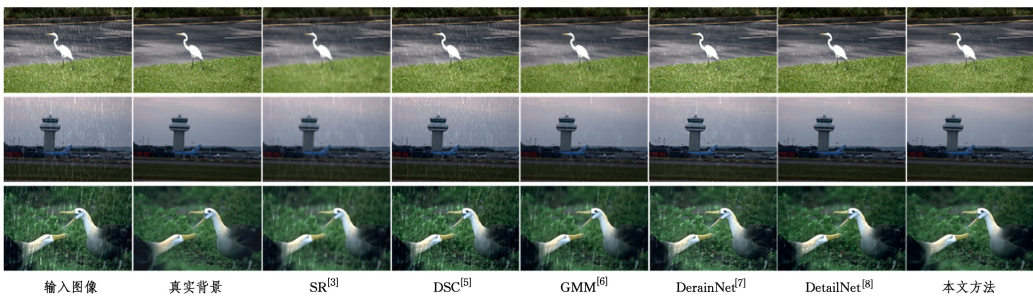


图2 多种图像去雨方法在合成数据上的可视化结果比较

Fig. 2 Comparison of visualization results of image rain removal methods on synthetic images

表1 本文方法与其他方法的定量结果(PSNR,SSIM)比较

Table 1 Comparison of quantitative results (PSNR,SSIM) about our method and state-of-the-art methods

算法	SR ^[3]	DSC ^[5]	GMM ^[6]	DerainNet ^[7]	DetailNet ^[8]	本文方法
PSNR	26.12	27.24	27.28	26.35	29.43	29.54
SSIM	0.76	0.81	0.85	0.86	0.89	0.93

为了更全面地评价本文方法,在真实图像上进行对比实验,结果如图3所示。通过观察发现,本文方法的除雨效果最好,选框标注了比较明显的效果对比;SR^[3]和GMM^[6]方法仍然存在模糊背景的情况,这与在合成数据上的效果类似。综合背景细节保留和除雨效果可知,本文方法相比其他5种方法表现最好,从而证明了其在图像去雨应用上的有效性。

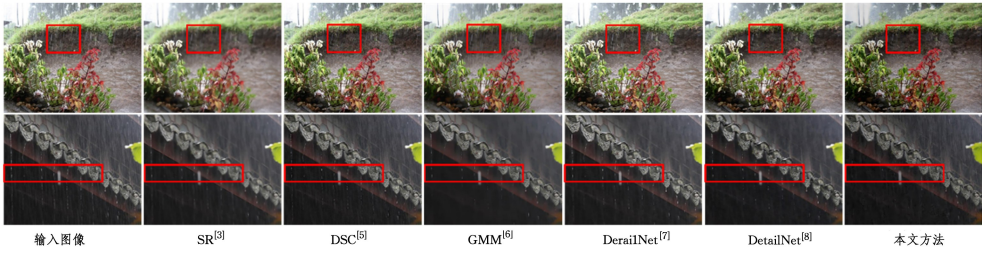


图 3 多种图像去雨方法在真实数据上的可视化结果比较

Fig. 3 Comparison of results of image rain removal methods on real world images

3.2 反射层分离

为了测试本文方法应用在反射层分离上的效果,将其与几个较新的方法进行对比,包括基于 SIFT-flow 的方法(ARR^[18])、标注引导的方法(GA^[12])以及一个基于相关平滑的方法(RS^[10])。图 4 展示的是各种方法在合成数据上的可视效果。可以发现,ARR^[18]方法在去反射层的效果上并不是很明显;并且为了防止恢复出的图像过暗,该方法在最后进行

了颜色校正,但是从结果上看,该操作并没有得到很好的结果,反而产生了色差。RS^[10]方法的恢复效果也不是很好,仅除掉了部分反射图像。GA^[12]方法不仅没有去掉反射图像,而且破坏了原本的背景图像,丢失了很多信息。相比之下,本文方法不仅去除反射干扰的效果是最明显的,而且对原始背景的影响最小,几乎没有产生色差和丢失信息的情况。与之对应的定量结果如表 2 所列。




图 4 多种图像去反射方法在合成数据上的可视结果对比

Fig. 4 Comparison of reflection removal results on synthetic images

表 2 多种去反射方法在样图上的定量结果(PSNR,SSIM)比较
Table 2 Comparison of quantitative results (PSNR,SSIM) of our method and state-of-the-art methods

	ARR ^[18]		RS ^[10]		GA ^[12]		本文方法	
	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR
图 1	0.32	16.58	0.71	16.40	0.70	12.27	0.82	22.61
图 2	0.76	21.12	0.87	14.55	0.88	20.11	0.90	23.63
图 3	0.43	14.91	0.63	15.67	0.34	4.33	0.66	17.83

由表 2 可知,本文方法无论是在结构相似性(SSIM)还是

峰值信噪比(PSNR)上的结果都是最高的,与其他方法相比有很大的优势,具有有效性和优越性。

图 5 展示的是在真实图像上去反射的效果比较,观察选框里的内容可以明显发现本文方法在去除反射层的同时极大程度地还原了背景图像。而在其他对比方法中,ARR^[18]去反射效果不明显,RS^[10]对真实场景的还原度不高,GA^[12]将部分真实背景也当作反射干扰去除了。合成数据和真实图像上的表现,均证明了本文方法在图像去反射应用上的有效性。




图 5 多种图像去反射方法在真实图像上的可视结果对比

Fig. 5 Comparison of reflection removal results of image dereflection methods on real world images

结束语 本文提出了一个灵活自适应的层分解框架,该框架不同于传统模型的方法,使用深度卷积先验代替模型先

验;基于最大后验估计建立能量模型,将深度先验与优化算法相结合,通过深度卷积先验引导模型的优化迭代过程。本文

方法不仅克服了深度学习的数据依赖性,同时弥补了传统模型方法的单一任务适用性的不足,提高了算法的泛化能力。将本文方法应用到自然图像去雨和反射层分离两个任务上,综合其在真实数据和合成数据上的表现可知,本文方法均比同类特定任务的方法效果明显,显示出了较强的有效性和泛化能力。

未来我们会继续探索本文方法在其他应用上的表现和能力,以进一步扩大其适用范围。

参 考 文 献

- [1] GU S H, MENG D Y, ZUO W M, et al. Joint Convolutional Analysis and Synthesis Sparse Representation for Single Image Layer Separation[C]// Proceedings of the IEEE International Conference on Computer Vision. Venice, Italy, 2017: 1717-1725.
- [2] LIANG Z T, XU J, ZHANG D, et al. A Hybrid l1l0 Layer Decomposition Model for Tone Mapping[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA, 2018.
- [3] KANG L W, LIN C W, FU Y H. Automatic single-image-based rain streaks removal via image decomposition[J]. IEEE Transactions on Image Processing, 2012, 21(4): 1742-1755.
- [4] HUANG D A, KANG L W, YANG M C, et al. Context-Aware Single Image Rain Removal[C]// Proceedings of the IEEE International Conference on Multimedia and Expo. Melbourne, Australia, 2012: 164-169.
- [5] LUO Y, XU Y, JI H. Removing rain from a single image via discriminative sparse coding[C]// Proceedings of the IEEE International Conference on Computer Vision. Santiago, Chile, 2015: 3397-3405.
- [6] LI Y, TAN R T, GUO X J, et al. Rain streak removal using layer priors[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA, 2016: 2736-2744.
- [7] FU X Y, HUANG J B, DING X H, et al. Clearing the Skies: A deep network architecture for single-image rain removal[J]. IEEE Transactions on Image Processing, 2017, 26(6): 2944-2956.
- [8] FU X Y, HUANG J B, ZENG D L, et al. Removing Rain from Single Images via a Deep Detail Network[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, Hawaii, 2017: 3855-3863.
- [9] YANG W H, TAN R T, FENG J S, et al. DeepJoint Rain Detection and Removal from a Single Image[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, Hawaii, 2017: 1357-1366.
- [10] LI Y, BROWN M S. Single Image Layer Separation Using Relative Smoothness[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Columbus, USA, 2014: 2752-2759.
- [11] SHIH Y C, KRISHNAN D, DURAND F, et al. Reflection removal using ghosting cues[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Boston, USA, 2015: 3193-3201.
- [12] SPRINGER O, WEISS Y. Reflection separation using guided annotation[C]// Proceedings of the IEEE International Conference on Image Processing. Beijing, China, 2017: 1192-1196.
- [13] ZHANG K, ZUO W M, GU S H, et al. Learning deep CNN denoiser prior for image restoration[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, Hawaii, 2017.
- [14] BOYD S, PARIKH N, CHU E, et al. Distributed optimization and statistical learning via the alternating direction method of multipliers[J]. Foundations and Trends in Machine Learning, 2011, 3(1): 1-122.
- [15] ZHU C, BYRD R H, LU P, et al. Algorithm 778: L-BFGS-B: Fortran subroutines for large-scale bound-constrained optimization[J]. ACM Transactions on Mathematical Software, 1997, 23(4): 550-560.
- [16] MARTIN D, FOWLKES C, TAL D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics[C]// Proceedings of the IEEE International Conference on Computer Vision. Vancouver, Canada, 2001: 416-423.
- [17] GARG K, NAYAR S K. Photorealistic rendering of rain streaks[J]. ACM Transactions on Graphics, 2006, 25(3): 996-1002.
- [18] LI Y, BROWN M S. Exploiting reflection change for automatic reflection removal[C]// Proceedings of the IEEE International Conference on Computer Vision. Sydney, Australia, 2013: 2432-2439.