

计算机科学

Computer Science

ISSN 1002-137X, CN 50-1075/TP

《计算机科学》网络首发论文

题目： 基于深度邻近连接网络的单幅图像去雨方法
作者： 傅雪阳, 孙琦, 黄悦, 丁兴号
收稿日期： 2019-01-28
网络首发日期： 2019-10-29
引用格式： 傅雪阳, 孙琦, 黄悦, 丁兴号. 基于深度邻近连接网络的单幅图像去雨方法. 计算机科学. <http://kns.cnki.net/kcms/detail/50.1075.TP.20191029.1327.040.html>



网络首发：在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

出版确认：纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。

基于深度邻近连接网络的单幅图像去雨方法



傅雪阳 孙琦 黄悦 丁兴号

厦门大学信息科学与技术学院福建厦门 361005

(fxy@stu.xmu.edu.cn)

摘要雨天环境下的雨线导致图像内容被遮挡,严重影响人眼的视觉效果和后续系统的处理性能。目前主流的深度学习方法为了提升处理性能,均以复杂的网络结构和较大的参数量为代价,导致相关方法难以服务于实际应用。为此,文中提出一种新的深度邻近连接网络结构。它通过关注深度网络中所学特征图之间的关系,采用融合操作将邻近特征图进行连接,以获得更加丰富和有效的特征表示。实验数据表明,文中方法在三个公开合成数据集及真实有雨图像上的主客观处理效果、模型参数量和运行时间等相关性能参数都有所提升。在合成数据集Rain100H上的平均结构相似性(SSIM)值达到0.84,在合成数据集Rain100L和Rain1200上的平均SSIM值分别达到0.96和0.91。在真实有雨图像上,文中方法在有效去除前景雨线的同时,能够保护更多的背景图像信息,从而获得更好的主观视觉效果。相比于同时期的深度学习方法JORDER,文中方法在保证相近的处理效果的前提下,模型参数量和CPU运行时间分别降低了一个和两个数量级。实验数据充分说明,通过将网络中邻近特征图进行融合,能够获取更加有效的特征表示。因此,虽然文中方法仅使用较少的模型参数和简洁的神经网络结构,却依旧能够实现较好的图像去雨效果,解决了现有方法模型参数量较大和网络结构较为复杂的问题。同时,文中网络结构设计方案也能够为相关基于深度学习的图像复原任务提供参考和借鉴。

关键词: 图像去雨; 深度学习; 卷积神经网络; 特征融合

中图法分类号 TP391.41 DOI 10.11896/jsjkk.190100228

Method for Single Image De-raining Based on Deep Adjacently Connected Networks

FU Xueyang, SUN Qi, HUANG Yue and DING Xinghao

School of Information Science and Technology, Xiamen University, Xiamen, Fujian 361005, China

Abstract Rain streaks result in the occlusion of image content, which seriously affects the human visual effect and the performance of subsequent systems. Existing deep learning-based methods improve de-raining performance at the expense of complex network structure and parameter burden, which makes these methods difficult for serving practical applications. In this work, a deep adjacently connected networks is proposed for single image de-raining. By focusing on the relationship between the learned feature maps, a fusion operation is designed to connect the adjacent features to obtain rich and effective representation. Experiments, which conducted on three

到稿日期: 2019-01-28 返修日期: 2019-04-22

基金项目: 国家自然科学基金(61571382, 81671766, 61571005, 81671674, 61671309, U1605252)

This work was supported by the National Natural Science Foundation of China (Grant No.61571382, Grant No.81671766, Grant No.61571005, Grant No.81671674, Grant No.61671309, Grant No.U1605252).

通信作者: 丁兴号 (dxh@xmu.edu.cn)

public synthetic datasets and real-world rainy images, show that the proposed method improves de-raining performance on both subjective and objective evaluations. The average structural similarity (SSIM) on the synthetic dataset Rain100H is 0.84, and the average SSIM values on the synthetic dataset Rain100L and Rain1200 are 0.96 and 0.91, respectively. When testing on real-world rainy images, the proposed method can effectively remove the foreground rain streaks while protecting background image information to obtain better visual quality. Compared with JORDER, the proposed method achieves comparable de-raining results while can reduce the model parameters and CPU runtime by one and two orders of magnitude, respectively. The experimental data demonstrates that fusing adjacent features in the deep network can generate more effective representation. Therefore, although the proposed method contains relative few parameters and simple neural network structure, it can still achieve better image de-raining performance and solve the problems of parameter burden and complex network structure in existing methods. Moreover, the network structure design scheme in this paper can also provide reference values for relative image restoration tasks based on deep learning.

Key words: Image de-raining, Deep learning, Convolutional neural networks, Feature fusion

1 引言

雨天是一种最为常见的恶劣自然天气,当在雨天进行拍摄任务时,雨线会对场景中的内容进行遮挡和干扰,从而使拍摄到的图像质量严重下降,直接导致主观视觉效果变差,并降低后续计算机视觉系统的性能,对无人驾驶、道路监控等实际应用产生极大的影响。因此,如何改善有雨图像的清晰化问题受到国内外科研工作者的广泛关注。然而,单幅图像中并不具有视频信号中丰富的时空相关性,不能利用这些时空特征,这进一步增加了单幅有雨图像清晰化的难度。因此,对单幅图像去雨问题的研究具有十分重要的意义,不仅如此其相关研究成果也可扩展到视频信号地处理中。

目前,单幅图像去雨的方法可大致分为两类,基于模型驱动和基于数据驱动。其中,基于模型驱动的方法侧重于挖掘和利用图像的先验知识,并将其用到解决反问题时的约束和建模中去,再通过设计优化算法求解模型,获得无雨图像;而基于数据驱动的方法,主要是以深度学习为代表,通过构建神经网络,并采用仿真数据和反向传播算法对神经网络进行监督训练,让网络从数据中自行学习有雨图像

到无雨图像的映射关系。

具体来说,基于模型驱动的方法更倾向于将雨线当作一种具有明显几何形状的高频噪声,并通过图像分解或雨线识别等方法将雨线去除。由于雨线在图像中属于高频分量,因此Kang等^[1]首先用低通滤波器将有雨图像分解为高频和低频部分,再利用稀疏先验对高频部分进行字典学习,基于雨线的HOG特征可得到无雨高频图像,最后将其与低频部分重新相加以获得无雨图像。之后,Huang等^[2]也用了相似的图像分解和优化策略来恢复有雨图像和高斯噪声图像。而Chen等^[3]发现雨线在图像的不同区域中都是相似的,并利用这种相似性提出了基于低秩先验模型来建模雨线的时空关联性,进而求解出无雨图像。Wang等^[4]则采用了一种分级处理的策略,利用字典学习、图像滤波和图像增强等多种方法,对有雨图像的高频部分进行多级操作实现去雨。2015年,Luo等^[5]提出了一种辨别性稀疏编码,通过学习一个具有内在排斥性的字典,将雨线和干净图像进行分离。之后,Li等^[6]假设雨线和无雨图的分布相互独立,利用高斯混合模型分别学习雨线图和无雨图先验信息,再通过求解最

大后验概率来获得无雨图像。与上述方法不同, Zhu等^[7]根据图像块中的局部梯度统计信息, 定义了三种新的先验信息作为目标函数中的正则化项, 通过交替优化算法求解模型, 最终得到去雨后的图像。Chang等^[8]则利用了雨线在变换域内具有低秩性的先验信息进行去雨。而Gu等^[9]同时使用了稀疏表示中的分析与合成, 结合卷积稀疏编码来分离图像的结构和细节, 最终达到去雨的目的。

基于数据驱动的方法是指在获得大量数据的基础上经过训练和拟合形成端到端的单幅图像去雨模型。自2012年Hinton等^[10]使用基于深度学习的方法获得ImageNet分类比赛的冠军起, 深度学习便一步一步成为了目前计算机视觉领域中最主流的方法。然而, 使用深度学习来解决单幅图像去雨问题则是近几年才出现。2013年, Eigen等^[11]提出了一个三层的卷积神经网络结构, 用来去除粘附在玻璃上的雨滴及泥点。然而, 这一方法所针对的是静态的雨滴和泥点, 而非动态的雨线。2017年, Fu等^[12]提出了DerainNet网络结构, 将领域知识引入到深度学习框架中, 考虑到图像中的雨线属于高频分量这一先验知识, 先通过图像的高低频分解对问题进行简化, 再用三层的卷积神经网络对图像分解的高频部分进行去雨处理, 之后将去雨处理后的高频部分与低频部分相加实现最终的图像去雨。此外, Fu等^[13]又将领域知识与深度残差网络结构结合, 提出了深度细节网络来进一步提升去雨效果。同年, Yang等^[14]提出了一个多目标学习的深度神经网络框架, 并使用了一个二值化的位置图来判断该像素位置是否存在雨线, 同时, 作者还设计了一个深度循环网络可以自动检测出雨线区域, 并对这些区域进行雨线去除。随后,

Pan等^[15]提出了一种可分离出图像中结构和纹理的双重网络结构, 且该网络可以用于去雨、超分辨率和去雾等多种图像处理任务。同年, Zhang等^[16]提出了一种多分支密集连接的去雨网络, 该网络采用了一个分类器来判别有雨图像的类型, 再根据分类结果产生雨线密度图来辅助和提升最终的去雨结果。

由于神经网络不仅能构建复杂的非线性函数, 且具有较大的模型容量, 所以基于数据驱动的图像处理方法效果会明显优于前文中基于模型驱动的图像处理方法。然而, 目前基于深度学习的方法大多通过设计复杂的网络结构或增加网络参数量等牺牲计算时间和计算资源的方式来提升深度模型的建模能力。因此, 基于深度学习的处理方法难以在硬件上很好地实现。出于对无人驾驶等实际应用的考虑, 本文受到神经网络中特征信息地融合利用地启发, 提出了邻近连接网络结构。通过对网络中邻近的特征图进行简单地融合操作, 能够生成更加丰富和有效的特征表示。在实验部分, 本文分别使用仿真有雨图像和真实场景下拍摄的有雨图像进行验证, 证明了该网络对于极端密集的雨线情况依旧能够很好地去除。与当前主流的单幅图像去雨算法相比, 本文所提出的网络在具有最少的网络参数量的前提下, 仍能保证主客观去雨效果。

2 基于深度邻近连接结构的单幅图像去雨网络

本文采用线性模型^[1,3]对单幅有雨图像进行建模

$$Y = X + R(1)$$

式中, Y 表示有雨图像, X 表示无雨图像, R 表示包含有雨线的残差图像。由于目前基于深度学习的单幅图像去雨方法均是通过设计不同的网络结构, 再使用监督学习的方式, 将人工

生成的有雨图像 Y 和对应无雨图像 X 作为训练数据, 利用反向传播算法更新网络参数, 使网络自行学习出从有雨图像到无雨图像。可以看出, 此类方法的核心在于如何设计深度神经网络结构, 以获取更加有效的特征表示。本文提

出一种新的邻近连接网络结构, 其整体结构如图1所示。这一结构使得网络即便在参数量较少的情况下, 依旧可以有效表示有雨图像的特征, 进而获得更好的去雨效果。

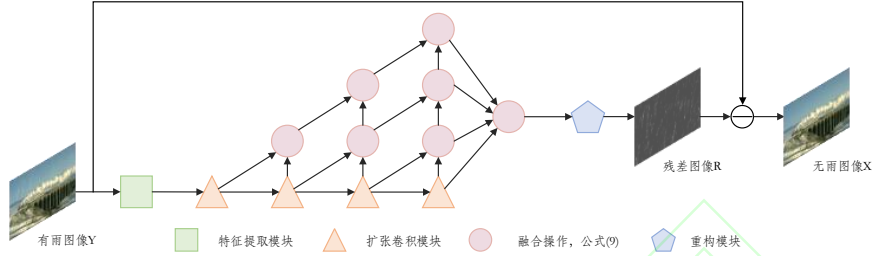


图1 本文所提深度邻近连接网络的整体结构示意图

Fig. 1 The overall structure of the proposed deep adjacently connected network

2.1 网络模块

本文所提出的网络包含三个基本模块, 即特征提取模块、扩张卷积模块和重构模块。特征提取模块的作用是提取有雨图像的基本特征, 这一模块可以表示为

$$F_1 = h(W_1 * Y + B_1) \quad (2)$$

式中, W_1 为第1层网络的卷积核, B_1 为对应的偏置向量, $*$ 表示二维图像的卷积操作, $h(\cdot)$ 为非线性激活函数, F_1 表示经过卷积和非线性操作后得到的特征图。

由于雨线可以看作是具有明显线条性的几何形状, 且单条雨线会在固定方向上覆盖较多的像素, 因此为了更好地捕获雨线特征, 需要增加卷积核的大小以扩大感受野。然而, 增加卷积核大小的同时, 也会极大地增加网络参数量, 导致模型的存储负担增大, 消耗更多的计算资源, 使其难以在一般的硬件上应用。

近年来提出的扩张卷积 (dilated convolution) [17]在标准的卷积核里注入零值的空洞, 由此可以在保持参数数量不变的情况下增大感受野。本文受此启发, 提出扩张卷积模块, 以获取更加有效的有雨图像特征。图2给出了扩张卷积模块的结构示意图。从图2可

以观察到, 这一模块包含三种不同扩张率 (dilation rate) 的卷积操作

$$f_{l1} = h(W_{DR=1} * F_{l-1} + B_{l1}) \quad (3)$$

$$f_{l2} = h(W_{DR=2} * f_{l1} + B_{l2}) \quad (4)$$

$$f_{l3} = h(W_{DR=4} * f_{l2} + B_{l3}) \quad (5)$$

式中, DR 为扩张率, 本文在同一个扩张卷积模块内采用了三种不同的扩张率, 即 DR 分别为1、2和4。为了更加有效地进行特征表示, 每一个扩张卷积模块的输出为

$$F_l = h(W_{fuse} * \text{concat}(F_{l-1}, f_{l1}, f_{l2}, f_{l3})) \quad (6)$$

式中, $\text{concat}(\cdot)$ 为特征图的拼接操作, l 为当前的模块层数, W_{fuse} 为 1×1 大小的卷积核, 用以有效融合已拼接的特征图, 最终获得新的特征表示。因为这一操作的目的是对特征图进行加权融合, 所以没有引入偏置向量。从图2左侧示意图可以观察到, 每一个扩张卷积模块的输出都是由当前模块内的所有特征图共同决定的, 这就保证了该模块可以输出更加丰富的特征。同时, 从图2右侧示意图可以观察到, 扩张卷积是在卷积核相邻点之间插入 $(DR-1)$ 个0, 可以在不增加网络参数数量的前提下, 扩大卷积核的尺寸。将扩张卷积核和图像进行卷积操作,

便有了更大的感受野范围,进而能够捕获更有效的有雨图像特征。

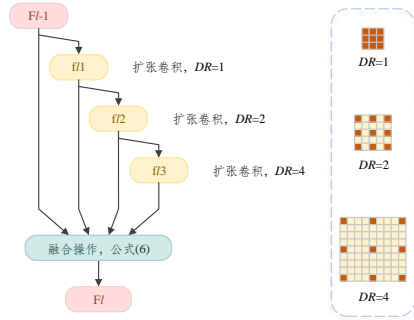


图2 扩张卷积模块及不同扩张率的卷积操作的具体结构,其中浅色像素的值为0。

Fig. 2 Detailed structures of dilated convolution module and dilated rates, shallow pixel values equal 0.

最后一层重构模块的作用是融合网络所抽取的特征,以恢复出彩色的无雨图像。文献[13]已证明,相比于直接学习图像间的映射关系,学习残差部分能够降低问题难度,提高训练的收敛速度。因此,本文同样基于残差学习来构建最后一层的融合模块,其相关表达式为

$$\hat{R} = W_L * F_{L-1} + B_L(7)$$

$$\hat{X} = Y - \hat{R}(8)$$

式中, \hat{R} 和 \hat{X} 分别为网络输出的残差图像和去雨图像, L 为网络的总层数。

2.2 邻近连接操作

目前主流的网络训练方式是反向传播算法,通过对损失函数求导,将梯度反向传播回每一层网络以更新参数。然而,反向传播算法所遵循的是链式求导法则,随着网络深度地增加,传递到浅层网络的梯度值会因连续的乘法操作而减小,导致浅层网络参数无法得到有效更新,出现梯度消失现象。在2016年CVPR的最佳论文中, He等^[18]通过引入跨层连接操作设计了一种残差模块,有效地缓解了梯度消失的问题,实现对深层网络进行训练。之后在2017年CVPR的最佳论文中, Huang等^[19]在残

差网络的基础上,又提出了密集连接网络结构,即网络中每一层输入的特征图都是由前面所有层输出的特征图融合获得。这一结构同样可以缓解梯度消失问题,并在此基础上加强了各层信息地传递,最终获得更加有效的特征。基于上述这两类网络结构,近年来也涌现出许多单幅图像去雨的相关论文^[13-16],均取得了不错的效果。

受到上述残差网络和密集连接网络地启发,本文提出了一种新的网络结构——邻近连接网络结构。如图1所示,邻近连接网络结构是对网络中相邻模块的输出进行层级地融合,具体的融合操作与式(6)相似

$$x_{fuse} = h(W_{fuse} * \text{concat}(x_1, x_2))(9)$$

式中, x_1 和 x_2 表示相邻模块的特征图, x_{fuse} 为融合后的特征图。

图3中给出了残差网络、密集连接网络及本文所提网络的结构对比图。从图中可以观察到,同残差网络相比,本文方法可以更加充分地连接网络中不同层的特征图,使得信息间地传递和交互更加频繁。




图3 三种不同网络的结构示意图比较

Fig. 3 Comparisons on different network architectures

同密集连接网络相比,本文方法采取了相对稀疏的连接方法,有效降低了内存占用量。不仅如此,本文所提出的网络结构也能够有效地缓解梯度弥散问题。另一方面,与残差网络和密集连接网络直接融合浅层特征图的操作

不同的是, 本文所提出的网络采取了逐层处理的结构来实现特征图之间的融合, 使得网络在前向过程中, 对于信息地处理更加精细。为了充分利用每一层的信息, 本文通过融合网络各层级方向上的所有特征图, 来获得网络中的最后一组特征图 F_{L-1} , 并将此特征图作为公式(7)的输入, 最终获得网络预测的输入有雨图像的残差部分。

2.3 损失函数

由于本文所提方法属于监督学习范畴, 在训练过程中, 需使用损失函数为网络提供监督信息来更新网络参数。目前大多数基于深度学习的图像去雨方法^[13-16]均使用均方误差 (Mean Squared Error, MSE) 作为损失函数。MSE会对较大误差的区域给予较大的权重, 如图像中的平滑区域。而相对于这些区域, 高频纹理和细节属于小误差区域, MSE无法对这些区域进行有效地惩罚。因此, 使用MSE作为损失函数会使最终得到的去雨图像变得模糊。基于上述分析, 本文采用平均绝对误差 (Mean Absolute Error, MAE), 即网络的输出与真实无雨图像之间的误差的 l_1 范数作为损失函数

$$L(\theta) = \frac{1}{N} \sum_{n=1}^N \|\hat{X} - X\|_1 \quad (10)$$

式中, N 为训练样本的数量, \hat{X} 是网络输出的去雨图像, X 是真实的无雨图像。同MSE相比, MAE在保证惩罚平滑区域的同时, 能够相对地增大图像中高频部分的惩罚权重, 有利于保护和恢复图像中的高频信息。

3 实验结果与分析

实验环境为Intel i7 CPU, 64位的windows 10, 使用英伟达的GTX1080Ti型号的GPU对网络训练并行加速, 所使用的编程语言为Python, 并采用谷歌公司开发的TensorFlow深度学习工具箱进行网络的搭建。

3.1 参数设置和网络训练

本文网络中所有融合模块的卷积核大小均为 1×1 , 其余卷积核大小为 3×3 。网络中每一个隐层均包含16个卷积核, 所有的卷积操作的步长都为1, 同时进行一个像素地扩展, 这样可以保证图像的尺寸不变。使用均值为0, 标准差为0.001的高斯分布对网络中的卷积核进行初始化, 偏置初始化均为0。本文网络共采用了4个扩张卷积模块, 且本文采用Leaky ReLU函数作为对非线性激活单元的选择, 这一分段函数对所有负值赋予一个取值为0.2的非零斜率, 其表达式为

$$\text{LReLU}(x) = \begin{cases} x, & \text{if } x > 0 \\ 0.2x, & \text{if } x < 0 \end{cases} \quad (11)$$


本文采用Adam算法^[20]对网络进行优化, 并采用批处理的方式输入训练数据, 每批数据中的图像块个数均为10个, 学习率固定为 10^{-4} , 经过30万次迭代后停止训练。

3.2 仿真数据实验

本文在3个公开的仿真数据集上进行训练和测试, 分别为Yang等^[14]所使用的Rain100L和Rain100H数据集, 以及Zhang等^[16]所使用的Rain1200数据集。这三个数据集包含不同类型的仿真雨天数据, 且分别都有训练集和测试集。其中, 前两个数据集各自包含100张测试图像, Rain1200包含1200张测试图像。

为了验证本文算法的性能, 分别将其与两种模型驱动的方法及两种数据驱动的方法进行比较, 分别为: 基于层先验的方法^[6] (简称LP)、基于卷积稀疏编码的方法^[9] (简称CSC)、基于深度细节网络的方法^[13] (简称DDN) 及基于多目标联合学习的方法^[14] (简称JORDER)。为公平比较, 所有对比算法的程序均为作者提供的源代码, 同时采用对应论文中提供的最优参数, 并用本文算法所使用的训练集对基于深度学习的网络重新进行了训练。

图4分别给出了上述包括本文算法在内的上述五种算法的主观实验结果。其中, 图4(a)为有雨图像, 图4(b)、图4(c)分别为LP算法^[6]和CSC算法^[9]的去雨结果, 从图中结果可以观察到, 由于人工设计的局限性, 仅靠人工挖掘出较为简单的图像特征无法有效地分辨出雨线和物体边缘之间的差异, 因此, 基于模型驱动的LP^[6]和CSC^[9]的方法会残留明显的雨线痕迹。同时, 这两类方法的模型容量较小, 不足以应对更加密集复杂的大雨图像。而基于深度学习的DDN算法^[13]和JORDER算法^[14]具有较大的模型容量和非线性函数映射能力, 能更好地去除不同类型的雨线。图4(d)、图4(e)分别为DDN算法^[13]和JORDER算法^[14]在仿真数据上的去雨结果, 其主观视觉效果明显优于LP算法^[6]和CSC算法^[9]的去雨结果。但是由于这两种方法均使用MSE作为损失函数, 导致图像中平滑区域的惩罚力度较大, 而忽略高频细节部分, 因此在处理大雨图像时, 会产生明显的处理痕迹。反观本文提出算法的去雨结果, 因采用了MAE作为损失函数, 而在有效去除雨线的同时, 能够更好地保护边缘, 进而获得更好的视觉效果, 如图4(f)所示。



(a) (b) (c) (d) (e) (f)

图4不同的去雨方法在仿真数据集上的主观效果比较。从上至下依次为: Rain100L, Rain100H和Rain1200数据集。

Fig. 4 Visual comparisons on synthesized datasets.

除了对比各算法的主观效果外, 本文还采用了SSIM^[21]和PSNR^[22]对上述方法进行客观评价。其中, SSIM用来衡量两幅图像的结构和细节相似度, 当两幅图像的内容和结构完全相等时, SSIM的值等于1。PSNR则是对图像整体的相似度进行度量, 更加侧重于评价图像颜色和平滑区域的失真程度, 其值越大, 就表示测试图像与参考图像的全局信息越相近。表1给出了上述五种算法的SSIM、PSNR以及模型参数数量的统计实验数据。由表可知, 同其他四种方法相比, 本文所提出的网络在三种数据集上均取得了较好的指标。值得注意的是, 本文所提出的邻近连接网络在保证相近处理结果的前提下, 网络参数量依旧比JORDER^[14]的网络参数低了一个数量级。这充分说明了本文所提网络结构的有效性, 在具有较少参数的情况下, 依旧能够挖掘出有雨图像的有效特征, 并且获得不错的去雨效果。

表1 不同去雨方法的SSIM和PSNR评估

Table 1 Comparisons on SSIM and PSNR

数据集	指标/理想值	LP ^[6]	CSC ^[9]	DDN ^[13]	JORDER ^[14]	本文
Rain100L	SSIM / 1.00	0.86	0.9	0.95	0.97	0.96
	PSNR / +∞	28.65	29.89	34.61	36.63	34.31
Rain100H	SSIM / 1.00	0.43	0.51	0.81	0.84	0.84
	PSNR / +∞	15.05	15.23	26.88	26.54	26.84
Rain1200	SSIM / 1.00	0.82	0.82	0.89	0.89	0.91
	PSNR / +∞	22.46	25.16	30.95	29.75	32.34
参数量		-	-	56,175	369,792	36,915

表2给出了上述五种算法在100幅大小为

750×750像素的图像上的平均运行时间, 对于

LP^[6]和CSC^[9]算法的作者所提供的是Matlab源码,因此没有进行GPU的比较。对于深度神经网络而言,一旦训练完成,在测试阶段仅需要执行前向操作,大部分的计算时间都消耗在卷积操作上,因此相比于基于优化迭代的LP^[6]和CSC^[9]算法,以及基于循环网络的JORDER^[14]算法,DDN^[13]和本文网络在CPU的计算速度上会有极大的优势。同时,由于图像的卷积操作十分适合并行计算编程,所以可用GPU等硬件进行加速,进一步加快计算时间。

表2不同去雨方法在运行时间上的对比(单位:秒)

	LP ^[6]	CSC ^[9]	DDN ^[13]	JORDE R ^[14]	本文
CPU	2.37×10 ³	1.67×10 ²	2.51	3.12×10 ²	2.13
GPU	-	-	0.21	0.23	0.19

3.3 真实数据实验

为了验证本文所提网络在真实场景数据上的有效性,用本文算法与其他4种算法在真实的有雨图像上进行对比,结果如图5所示。其中,图5(a)为有雨图像,图5(b)-图5(f)分别为LP算法^[6]、CSC算法^[9]、DDN算法^[13]、JORDER算法^[14]及本文提出算法的去雨结果。通过图5发现,本文算法在真实图像上能够有效去除雨线,同时最大化保留背景图像的信息,而两种基于模型驱动的方法则会在去除雨线的同时导致物体细节模糊。相比之下本文算法的泛化能力更强,对不同程度的雨线均能达到不错的去除效果。




图5不同的去雨方法在真实数据上的主观效果比较。

Fig. 5 Visual comparisons on real-world data.

结束语

针对单幅图像去雨问题,本文提出了一种新型的基于深度邻近连接网络。该网络结构通过融合相邻特征图,来获取更加有效的特征表示;构造扩展卷积模块,能够在不增加网络参数数量的前提下,有效增加网络的感受野大小。实验结果表明,本文所提网络不仅在相关主客观指标上,均能够达到与同时期的方法相近的结果,而且参数量明显少于其他基于数据驱动的方法,具有服务于实际应用的潜力。未来工作将通过引入领域知识等策略进一步提升处理效率;考虑将雨和雾联合去除,并借鉴本文思路进行求解。

参考文献

- [1] KANG L, LIN C, FU Y. Automatic Single-Image-Based Rain Streaks Removal via Image Decomposition[J]. IEEE Transactions on Image Processing, 2012, 21(4): 1742–1755.
- [2] HUANG D, KANG L, WANG Y, et al. Self-Learning Based Image Decomposition with Applications to Single Image Denoising[J]. IEEE Transactions on Multimedia, 2014, 16(1): 83–93.
- [3] CHEN Y, HSU C. A Generalized Low-Rank Appearance Model for Spatio-Temporally Correlated Rain Streaks[C]//IEEE International Conference on Computer Vision. Sydney, NSW, Australia, 2013, 1968–1975.
- [4] WANG Y, LIU S, CHEN C, et al. A Hierarchical Approach for Rain or Snow Removing in a Single Color Image[J]. IEEE Transactions on Image Processing, 2017, 26(8): 3936–3950.
- [5] LUO Y, XU Y, JI H. Removing Rain from a Single Image via Discriminative Sparse Coding[C]//IEEE International Conference on Computer Vision. Santiago, Chile, 2015, 3397–3405.
- [6] LI Y, TAN R, GUO X, et al. Rain Streak Removal Using Layer Priors[C]//IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA, 2016, 2736–2744.
- [7] ZHU L, FU C, LISCHINSKI D, et al. Joint Bi-layer Optimization for Single-image Rain Streak Removal[C]//IEEE International Conference on Computer Vision. Venice, Italy,

2017, 2545–2553.

[8] CHANG Y, YAN L, ZHONG S. Transformed Low-Rank Model for Line Pattern Noise Removal[C]//IEEE International Conference on Computer Vision. Venice, Italy, 2017, 1735–1743.

[9] GU S, MENG D, ZUO W, et al. Joint Convolutional Analysis and Synthesis Sparse Representation for Single Image Layer Separation[C]//IEEE International Conference on Computer Vision. Venice, Italy, 2017, 1717–1725.

[10] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks[C]//Conference and Workshop on Neural Information Processing Systems. Lake Tahoe, Nevada, 2012, 1097–1105.

[11] EIGEN D, KRISHNAN D, FERGUS R. Restoring an Image Taken through a Window Covered with Dirt or Rain[C]//IEEE International Conference on Computer Vision. Washington, DC, USA, 2013, 633–640.

[12] FU X, HUANG J, DING X, 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.

[13] FU X, HUANG J, ZENG D, et al. Removing rain from single images via a deep detail network[C]//IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA, 2017, 3855–3863.

[14] YANG W, TAN R, FENG J, et al. Deep Joint Rain Detection and Removal from a Single Image[C]//IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA, 2017, 1685–1694.

[15] PAN J, LIU S, ZHANG J, et al. Learning Dual Convolutional Neural Networks for Low-Level Vision[C]//IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, Utah, USA, 2018, 1–10.

[16] ZHANG H, PATEL V. Density-Aware Single Image De-raining using a Multi-stream Dense Network[C]//IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, Utah, USA, 2018, 1–10.

[17] YU F, KOLTUN V, FUNKHOUSER T. Dilated residual networks[C]//IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA, 2017, 636–644.

[18] HE K, ZHANG X, REN S, et al. Deep residual learning for image

recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, United States, 2016, 770–778.

[19] HUANG G, LIU Z, MAATEN L, et al. Densely connected convolutional networks[C]//IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA, 2017, 4700–4708.

[20] KINGMA D, BA J. Adam: A Method for Stochastic Optimization [C]//International Conference on Learning Representations. San Diego, CA, USA, 2015, 1–15.

[21] WANG Z, BOVIK A, SHEIKH H, et al. Image Quality Assessment: from Error Visibility to Structural Similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4):600–612.

[22] GONZALEZ R, WOODS R. Digital Image Processing[M], 2012.

傅雪阳, 出生于1988年, 男, 博士, CCF会员, 主要研究方向为图像处理 and 机器学习; 孙琦, 出生于1994年, 女, 硕士生, 主要研究方向为图像处理和深度学习; 黄悦, 出生于1983年, 女, 博士, 副教授, 主要研究方向为计算机视觉、深度学习、迁移学习等; 丁兴号, 出生于1976年, 男, 博士, 教授, CCF会员, 主要研究方向为计算机视觉、机器学习、大数据分析 and 处理、稀疏表示理论及人工智能等。



Xueyang Fu, born in Anhui, PhD, is Member of China Computer Federation (CCF).

His main research interests include image processing and machine learning.



Xinghao Ding, born in Anhui, PhD, Professor, PhD supervisor, is Member of China Computer Federation (CCF). His main research

interests include computer vision, machine learning, big data analysis and processing, sparse representation theory and artificial intelligence.