

基于图网络的改进卷积单幅图像去雨算法

周进祥¹, 李志伟^{1,2*}, 邱火旺¹, 任远红², 周武能²

¹上海工程技术大学电子电气工程学院, 上海 201406;

²东华大学信息科学与技术学院, 上海 201620

摘要 图像去雨指通过去除图像中的雨痕来重构出高清背景图像的过程。目前最广泛应用于图像去雨任务的是深度卷积神经网络。卷积操作的核心是参数共享,这大大减少了计算量并提升了算法的泛化能力,然而这也导致卷积操作无法有效考虑到局部之间的联系和较远的像素点对所操作区域的影响,出现图像去雨中的过平滑现象。结合图网络的思想 and 机制,提出一个改进卷积方式。首先将所有像素点视为一个图节点,计算相邻像素点之间的相似度,根据设定的阈值判断有无边联系,完成图结构构建后,所得到的邻接矩阵与相似度矩阵会在卷积操作时对卷积核参数进行调整,充分考虑像素点之间的联系与提取拓扑信息。在图像去雨领域若干公开数据集上对多个最新算法进行对比,实验结果显示所提改进卷积的有效性,可以在不增加许多计算资源的前提下有效提升算法的性能。

关键词 图像去雨; 深度卷积神经网络; 图网络; 图节点; 改进卷积

中图分类号 TN911.73

文献标志码 A

DOI: 10.3788/LOP213091

Improved Convolutional Rain Removal Algorithm for Single Image Based on Graph Network

Zhou Jinxiang¹, Li Zhiwei^{1,2*}, Qiu Huowang¹, Ren Yuanhong², Zhou Wuneng²

¹College of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201406, China;

²College of Information Science and Technology, Donghua University, Shanghai 201620, China

Abstract Image deraining is the process of reconstructing a high-definition background image by removing rain marks. The deep convolutional neural network is now the most widely used to eliminate rain streaks. The core of the convolution operation is parameters globally sharing, which remarkably reduces the amount of calculation and improves the generalization ability of the algorithm. However, this also makes the convolution operation unable to effectively consider the connections between local parts and the influence of the distant pixels on the operated region. This will result in an over-smoothing phenomenon in single image deraining. Inspired by the great success that graph network has achieved in recent years, we hope to improve the convolution method by combining the kernel idea of graph network. First, all pixels are treated as graph nodes, the similarity between neighboring pixels is estimated, and the threshold value determines whether or not an edge connection exists. After the graph structure construction is completed, the obtained adjacent matrix and the similarity matrix will be used during the convolution operation, the parameters of the convolution kernel are adjusted, and the connection between the pixels and the extraction of topological information are fully considered. The intensive comparison experiments of several states-of-the-arts on several benchmark datasets show the effectiveness of the proposed enhanced convolution, which can effectively promote the performance of various latest algorithms without increasing a lot of computing resources.

Key words image rain removal; deep convolutional neural network; graph network; graph node; improved convolution

1 引言

近年来,深度学习^[1]在图像去雨领域取得巨大成

功并受到广大学者的关注,其中应用最广泛的技术莫过于由LeCun等^[2]提出的卷积神经网络(CNN)。从最初的用于手写字体分类的LeNet^[3],到用于图像分类的

收稿日期: 2021-11-29; 修回日期: 2021-12-16; 录用日期: 2022-01-05; 网络首发日期: 2022-01-15

基金项目: 国家自然科学基金(61705127)

通信作者: *zhiwei.li@sues.edu.cn

由 Srivastava 等^[4]提出的 AlexNet,再到 He 等^[5]提出的深度残差卷积神经网络,随后,深度卷积神经网络被广泛用于人脸识别^[6]、无人驾驶^[7]、目标检测^[8]、图像增强^[9]、自然语言处理^[10]等诸多上层应用。卷积神经网络深受广大研究人员的青睐。

卷积操作的最大特点是参数共享,同一数据的不同位置以及不同数据均共享相同的卷积核参数,这大大减少了所需的计算量,降低了网络模型的复杂度,并且可以比较好地提取出数据的特征用于后续操作。此外,卷积神经网络还可以直接接受图像作为网络的输入,这有效避免了传统机器学习算法需要对图像进行复杂的预处理和数据重构的过程,简易高效。然而,卷积神经网络的参数共享机制虽然可以大大减少计算量,但这也导致了数据间关系的缺失。如对图像进行卷积的过程中,卷积操作仅考虑卷积核感受野范围内的数据,没有考虑较远的像素点对目前操作区域的影响,同时由于参数共享机制的设定,不同区域共享相同的参数导致区域本身的拓扑信息容易丢失。

在图像去雨任务中,大量的雨痕与背景成分交错融合,难以区分。卷积神经网络提取雨痕信息时很容易错误地将背景信息一并提取出并去除,此现象也被称为过平滑现象,是计算机视觉领域一个常见但十分棘手的问题。值得一提的是,虽然生成对抗网络(GAN)^[11]可以重构出较为逼真的去雨图像,但通过计算评价指标发现,其性能甚至不如基于 CNN 的重构方式,因此可以推断 GAN 重构的许多细节纹理是虚假不真实的。此外,基于卷积神经网络的算法,如 DNN^[12]及 PReNet^[13]等经典前沿去雨算法,很难处理有雨图像中包含复杂拓扑信息的局部区域,例如草丛、毛发、建筑纹理等区域的雨痕难以有效去除或去除雨痕的同时也破坏了原有的局部图像。且其他基于卷积的图像处理算法^[14-16]也同样存在该过平滑问题。综上所述,基于卷积神经网络的方式仍然面临无法有效提取拓扑信息,即缺乏对局部关系的考虑的问题。

受近年来图神经网络^[17]取得巨大成功的启发,众多学者将图网络引入图像处理领域。Valsesia 等^[18]提出基于图网络的图像去噪网络,通过图网络充分提取图像像素点之间的联系,来达到更好的去噪声效果。Zhou 等^[19]提出了一个交叉尺度图网络,用于图像增强领域的超分辨率任务,通过图网络提取不同尺度的信息来交叉生成更高质量的超分辨率图像。本文希望结合图卷积的思想对目前的传统卷积方式进行改进,设计一个针对图像去雨任务的改进卷积方法。图网络非常擅于处理非欧氏数据,具有对拓扑结构信息非常强大的提取能力,可以有效地减缓过平滑问题。所提方法将输入图像的每一个像素点视为一个图节点,像素点的像素值视为图节点的初始特征向量;接着根据相邻节点对的处理特征向量计算相似度,若相似度高于设定的阈值,则视此两节点存在联系,即有边相连;最

后在卷积过程中,计算得到的相似度矩阵与确定有边关系的邻接矩阵会一同对卷积核参数进行调整,由此来充分考虑图像中的拓扑结构信息。

2 图神经网络

图神经网络首次由 Scarselli 等^[17]提出,经过十余年的发展,如今已经在深度学习舞台上大放异彩。

2.1 图网络相关定义

通常将一个简单无向图定义为 $G=(V, \mathbf{E})$,其中, $V=\{v_1, v_2, \dots, v_N\}$ 表示该图中的 N 条边所组成的无向边集合, $\mathbf{E}=\{\epsilon_1, \epsilon_2, \dots, \epsilon_M\}$ 表示该图中的 M 个节点所组成的点集合。一般使用 $\mathbf{A}=(a_{ij})_{N \times N}$ 来表示图 G 的邻接矩阵, a_{ij} 表示节点 v_i 与节点 v_j 的边权大小,若节点 v_i 与节点 v_j 不相连,则 $a_{ij}=0$ 。此外,对角度矩阵 $\mathbf{D}=\text{diag}\{d_1, d_2, \dots, d_N\}$ 表示每一个节点的度,即每一个节点所连边的数量。最后, $\mathbf{X}=\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}^T \in \mathbb{R}^{N \times C}$ 表示所有节点的初始特征向量矩阵,其中 $\mathbf{x}_i \in \mathbb{R}^C$ 表示节点 v_i 的初始特征向量。

根据 Kipf 等^[20]所著,定义 $\mathbf{L}=\mathbf{D}-\mathbf{A}$ 来表示图 G 的拉普拉斯矩阵,接着经过正交化操作,定义 $\mathbf{L}_{\text{sym}}=\mathbf{I}-\mathbf{D}^{-\frac{1}{2}}\mathbf{A}\mathbf{D}^{-\frac{1}{2}}$ 。对于每个图节点,不仅需要考虑其相互连接节点的信息,还需考虑自身节点的信息,一般对所有图 G 的节点增加一个自环,则调整后的邻接矩阵为 $\tilde{\mathbf{A}}=\mathbf{A}+\mathbf{I}$,调整后的对角度矩阵为 $\tilde{\mathbf{D}}=\mathbf{D}+\mathbf{I}$ 。

2.2 图卷积

受 Defferrard 等^[21]在卷积神经网络上所做部分工作的启发, Kipf 等^[20]提出了一个一阶近似的 ChebNet^[21],并称其为图卷积神经网络(GCN)。值得一提的是, Kipf 等将 ChebNet 中的卷积感受野大小限制为 1,即只考虑一阶邻居节点,并且限制了参数量来避免过拟合情况。此外, Kipf 等还将图拉普拉斯矩阵 \mathbf{L} 的最大特征值近似为 2,并且提出一个二次正交化策略来防止梯度消失或梯度爆炸问题。

综上,根据 Kipf 等的工作,一个一层的图卷积操作可以定义为

$$\mathbf{H}^{(k+1)}=\sigma(\mathbf{D}^{-\frac{1}{2}}\mathbf{A}\mathbf{D}^{-\frac{1}{2}}\mathbf{H}^{(k)}\mathbf{W}^{(k)}), \quad (1)$$

式中: $\mathbf{H}^{(k)}=\{\mathbf{h}_1^{(k)}, \mathbf{h}_2^{(k)}, \dots, \mathbf{h}_N^{(k)}\}^T$ 表示所有节点在第 k 层的特征表示矩阵,并规定 $\mathbf{H}^{(0)}=\mathbf{X}$,即第 0 层的特征表示为初始特征向量矩阵; $\mathbf{W}^{(k)}$ 是第 k 层的可学习参数矩阵; σ 指激活函数,一般为 ReLU 激活函数。显然,每次进行图卷积操作,节点的特征向量会更新为自身与一阶邻居节点的特征向量聚合的向量。通过堆叠多个图卷积层,每个节点可以吸纳更高阶邻居节点的信息。

3 所提改进算法内容

主要介绍如何将一张图像构建为图结构,如何将

图卷积的思想与机制融入到传统的卷积操作中。原始图像输入后,先根据卷积核尺寸进行展开操作,再对其进行相似度计算,获得相似度矩阵;根据节点间的相似度是否达到阈值来判断是否有边关系;而后构建图结构,对获得的邻接矩阵与相似度矩阵进行矩阵点乘运

算;对卷积核进行一维展开,与先前邻接矩阵与相似度矩阵进行矩阵点乘运算后所获取的矩阵进行矩阵乘法,获取卷积后的特征表示矩阵,通过折叠操作获得输出的特征表示矩阵。所提改进算法的整体流程如图 1 所示。

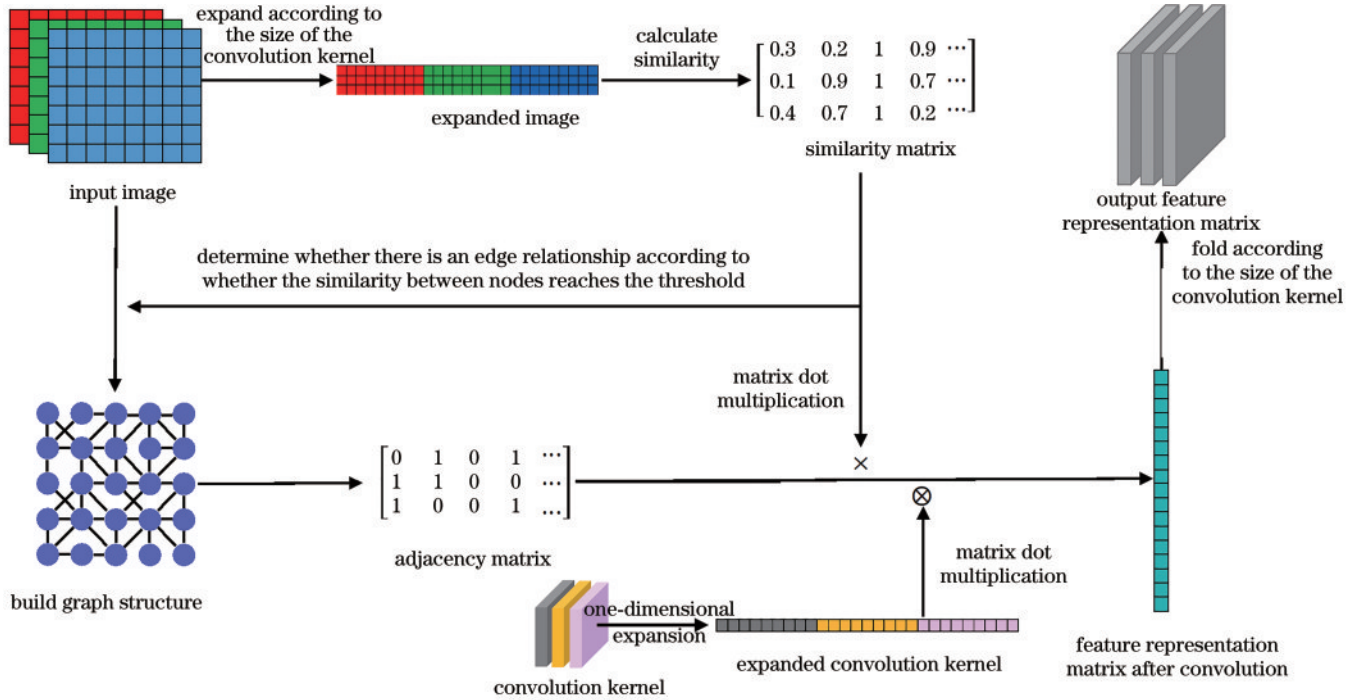


图 1 所提算法的流程

Fig. 1 Flowchart of the proposed algorithm

3.1 图结构的构建

图卷积的基本思想是利用图中的边信息对节点信息进行聚合,进而产生新的节点表示。这样使得具有潜在联系或者行为相似的节点集趋于一致,可以与其他不相似的节点区分开。因此首先需要确定节点之间的边关系并构建图结构。

对于一张输入的 RGB 彩色图像,将每个像素点视为一个图节点,注意到每个像素点的值为一个三维的 RGB 数值向量,则使用每个像素点的初始 RGB 数值向量作为该图节点的初始特征向量。接着,根据每个节点的初始特征向量值计算出每个像素点和 8 个一阶邻居像素点的相似度,公式为

$$s_{ij} = e^{-\frac{\|n_i - n_j\|^2}{\beta}}, \quad (2)$$

式中: s_{ij} 指节点 i 与节点 j 的相似度; n_i 与 n_j 分别表示节点 i 与节点 j 的初始特征向量; β 为一个可训练参数,初值设为 1,在神经网络的训练过程中与网络的其他参数如卷积核参数一同训练,进行更新。若两个节点像素值完全相同,则相似度为 1。值得一提的是,由于神经网络训练在 GPU 上并行计算的需求,一般在卷积操作的底层运算中,运算单元会根据卷积核尺寸将输入的高维张量展开为二维矩阵,因此本文的操作也均是

在高维张量展开后进行的。

得到每个节点与一阶邻居节点的相似度后,根据设定的阈值判断两点之间是否存在边关系。设定阈值为 0.3,若节点 i 与节点 j 的相似度大于 0.3,则这两节点存在边关系相连,且边权即为相似度。阈值的设定很大程度上取决于所使用的数据集,在所使用的数据集上,当阈值小于 0.3 时,几乎所有节点都相连,而当大于 0.3 时,则在所构建局部图中当确定节点之间的边关系和边权后,图结构便构建完成,即可以得到邻接矩阵 A 。

3.2 根据卷积核的特征图张开方式

由于深度学习有在 GPU 上并行计算的需求,因此所提改进方法也需要在 GPU 上进行并行计算。因此改进操作将在卷积操作的内部进行,其中十分关键的是根据卷积核尺寸将特征图展开的步骤。一次普通的卷积操作包括展开操作、矩阵乘法、折叠操作。折叠操作可以视为展开操作的逆过程,因此主要介绍卷积核的展开操作。

如图 2 所示,特征张量在卷积过程的起始时会根据卷积核尺寸展开为二维的矩阵。对于一个尺寸为 $C \times H \times W$ 的特征张量,若与尺寸为 $C \times N \times M$ 的卷积核进行卷积操作,假设卷积核移动步长为 1 且卷积

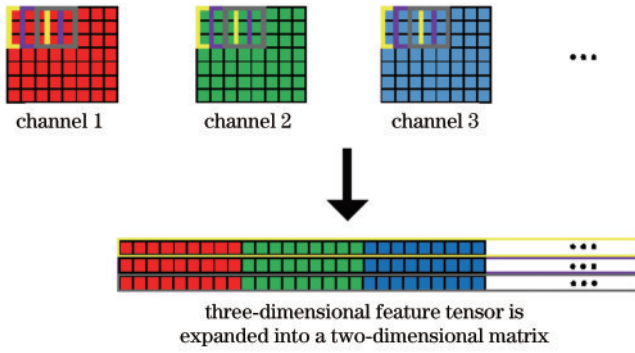


图 2 卷积核展开过程示意图

过程中无填充操作,则可得到一个尺寸为 $(H - N + 1)(W - M + 1) \times CNM$ 的二维展开矩阵。例如,对于一个 $(3, 48, 48)$ 的特征张量,与一个 $3 \times 3 \times 3$ 的卷积核进行卷积的过程中,特征张量会展开为一个尺寸为 2116×27 的二维矩阵。

3.3 调整后的卷积方式

传统的卷积方式中,对于一个输入的张量 T ,首先根据卷积核尺寸将其展开为二维矩阵,计为 T_{unfold} 。接着将卷积核 ω 展开为一维向量,记为 ω_{unfold} ,则卷积过程可以表示为

$$\omega \star T = \text{fold}(\omega_{\text{unfold}} \times T_{\text{unfold}}), \quad (3)$$

式中: \star 表示传统的卷积过程; \times 表示矩阵乘法; $\text{fold}(\cdot)$ 表示根据卷积核尺寸将已展开的矩阵折叠回原始尺寸的操作,是 $\text{unfold}(\cdot)$ 操作的逆过程。

改进的卷积过程中,将计算得到的相似度矩阵、邻接矩阵一并考虑入卷积过程。改进后的公式为

$$\omega \star T = \text{fold}(\omega_{\text{unfold}} \times T_{\text{unfold}} \cdot S \cdot A), \quad (4)$$

式中: \cdot 表示矩阵之间的点乘操作; S 为相似度矩阵; A 为邻接矩阵。此过程作为卷积的一个调整方法,结合图网络的思想来考虑像素点之间的关系,随着此卷积操作的堆叠,可以考虑到较远处像素点对目前区域的影响。

综上所述,所提改进卷积算法借鉴和结合了图卷积的过程,充分考虑图像像素点间的关系,从而可以有效提取图像中包含复杂拓扑信息的区域特征,进而提升去雨网络的性能,达到更好的去雨效果。此外,所提改进卷积的一大亮点为,可以在不明显增加计算资源的情况下对去雨算法进行有效提升。

4 实验结果与分析

将图像去雨的一些经典算法和最新算法中的卷积替换为所提改进卷积操作,对 DDN^[12]、PReNet^[13]、BRN^[22]、多尺度非局部(multi-scale non-local)方法进行对比^[23]。对比内容包括性能、计算时间、显存大小等。

对比实验中涉及的所有参数设置保持一致,如学习率、卷积核尺寸、批次数量等。所有实验将在一台配有若干 2080Ti GPU 的计算机上运行,编程语言均为

Python,深度学习框架为 PyTorch。

4.1 视觉效果对比

使用大量雨图来验证所提改进措施,选取图 3(a) 草丛、图 3(b) 刺猬、图 3(c) 建筑 3 张背景包含丰富拓扑结构信息的雨图对改进前后的算法进行对比。从视觉对比图中可以直观看出: DDN 算法在改进前后都无法有效去除雨痕,也大量破坏了背景;多尺度非局部方法基本达到去雨目的,但是在图 3(a) 的草丛附近、图 3(b) 的刺猬毛发附近、图 3(c) 的全图都存在较为明显的雨痕,且部分背景成分明显被破坏,使用所提改进卷积算法后,去雨效果得到了较为明显的提升,且背景被破坏区域明显减少; PReNet 和 BRN 取得了很好的去雨效果,但在纹理结构明显的区域存在过平滑现象,如在图 3(a) 的右上角背景草丛、图 3(b) 的刺猬头部毛发、图 3(c) 的建筑顶部网状结构区域均存在一定程度的过平滑现象,改进后的 PReNet+ 和 BRN+ 能明显减缓过平滑现象。这说明所提改进卷积可以充分提取图像局部的拓扑信息,尽可能地保留背景的纹理结构,减缓在去雨过程中造成背景被充分破坏的过平滑现象,从而提升图像重构质量。

4.2 客观指标评价

图像去雨任务旨在去除图像中的雨痕层,从而得到清晰的背景层。由于雨痕与背景成分复杂地融合在一起,因此去除雨痕的同时非常容易将背景成分破坏,造成重构图像质量低下。本实验将 4 个最新算法中的卷积替换为所提改进卷积,分别记作 DDN+、PReNet+、BRN+、多尺度非局部+。采用 4 个公开标准数据集, Rain100L^[24]、Rain100H^[24]、RainLight^[25]、RainHeavy^[25]。其中 Rain100L 包括 200 对训练集与 100 对测试集,其余 3 个数据集均包括 1800 对训练集与 200 对测试集。评价指标为峰值信噪比 (PSNR)^[26-27] 和结构相似性 (SSIM)^[28]。PSNR 是一种全参考的图像质量评价指标,用于评估两幅图像在像素上的差异,数值越大,恢复出的图像质量越好,失真越小。自然图像具有极高的结构性,表现为图像的像素间存在着很强的相关性,尤其是在空间相似的情况下。这些相关性在视觉场景中携带着关于物体结构的重要信息,所以通过探测结构信息改变多少来感知图像失真程度的近似信息,对应的衡量指标即为 SSIM。

使用所提改进卷积方式后,改进后的算法在 4 个数据集上分别进行训练与测试,并统计 PSNR 和 SSIM 值,对比结果如表 1 所示。可以看出:各改进算法对应的 PSNR、SSIM 指标都得到一定程度的提升,从而可以有效去除图像中雨痕层的同时,尽可能地保留原有图像背景成分,通过充分利用图像局部的拓扑信息减缓过平滑问题。

此外,统计了算法改进前后计算单张去雨图像的时间与训练网络所需要的显存大小,对比结果如表 2 所示。

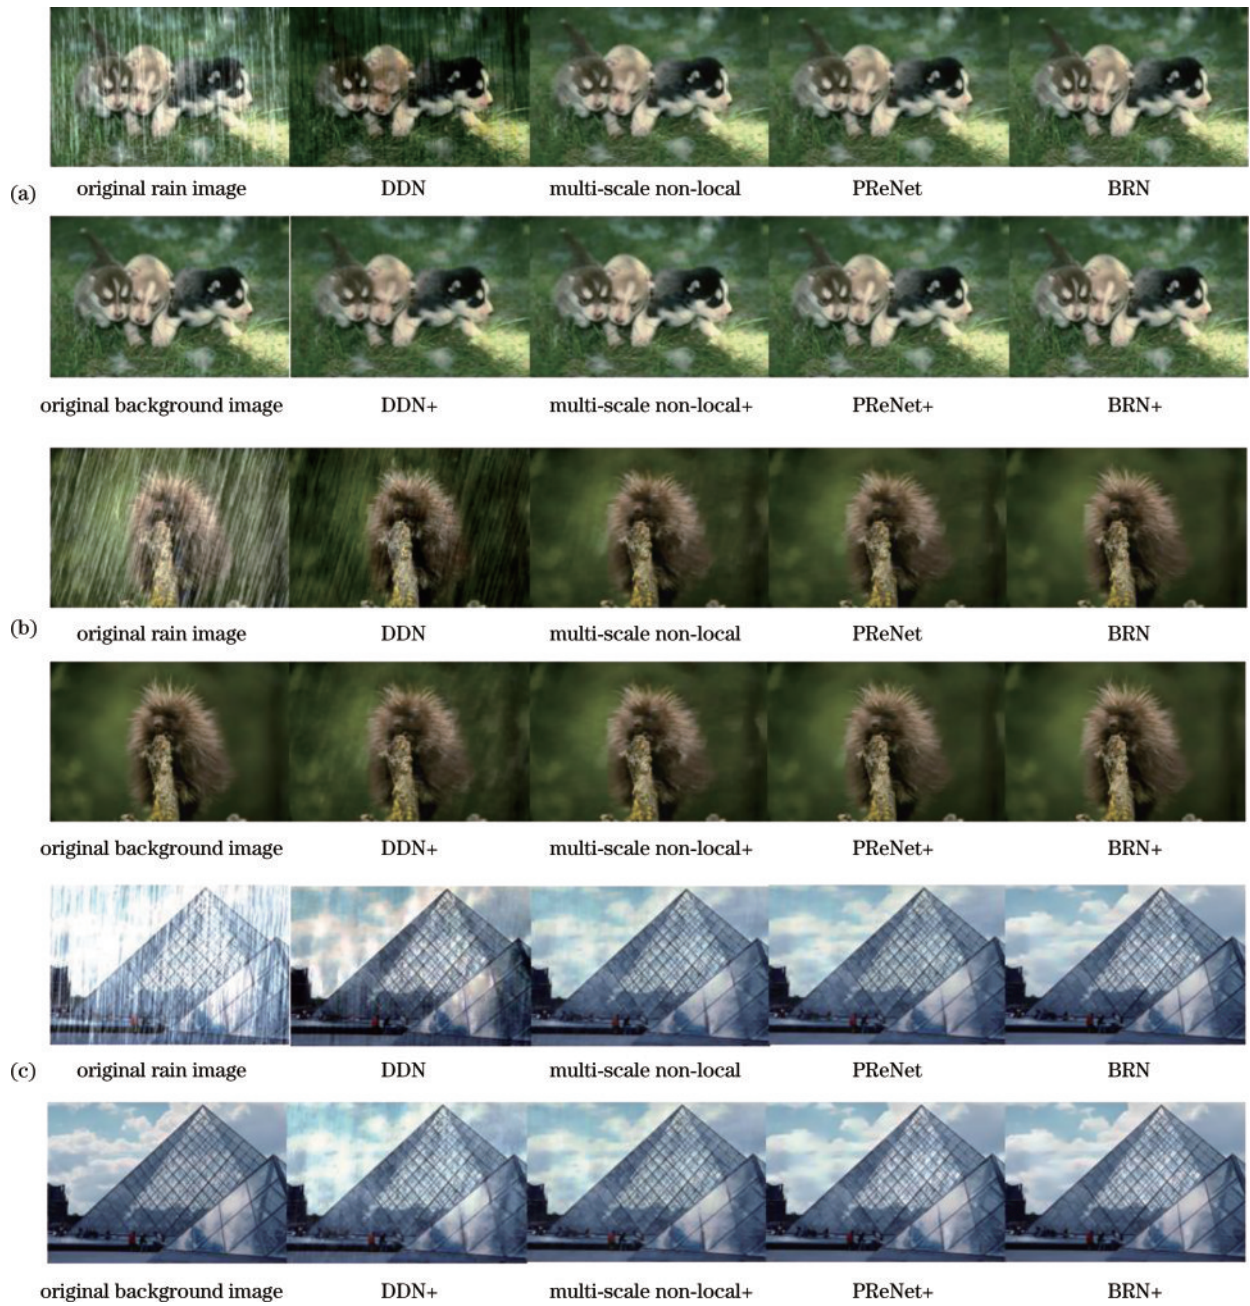


图 3 若干最新算法改进前后的视觉对比

Fig. 3 Visual comparison of several latest algorithms before and after improvement

表 1 若干最新算法在 4 个公开测试数据集上的性能对比结果

Table 1 Performance comparison results of several latest algorithms on four public test datasets

Algorithm	PSNR/SSIM			
	Rain100L	Rain100H	RainLight	RainHeavy
DDN	32.16/0.936	21.92/0.764	31.66/0.922	22.03/0.777
DDN+	33.45/0.944	24.02/0.816	32.91/0.937	24.22/0.825
PReNet	37.48/0.979	29.45/0.905	37.93/0.983	29.36/0.903
PReNet+	39.21/0.991	30.55/0.921	39.60/0.993	30.41/0.919
Multi-scale non-local	36.01/0.965	28.63/0.884	36.39/0.968	28.47/0.883
Multi-scale non-local+	37.88/0.984	29.98/0.916	37.93/0.982	29.77/0.914
BRN	38.16/0.982	30.47/0.918	38.86/0.986	30.27/0.917
BRN+	39.55/0.993	31.29/0.934	40.08/0.996	31.11/0.925

表 2 若干最新算法改进前后时间与显存对比结果

Table 2 Comparison results of computing time and GPU memory of several latest algorithms before and after improvement

Algorithm	Computing Time /s	GPU memory /MB
DDN	0.014	1242
DDN+	0.016	1305
PReNet	0.058	1897
PReNet+	0.062	1994
Multi-scale non-local	0.104	4957
Multi-scale non-local+	0.111	5135
BRN	0.089	2587
BRN+	0.099	2643

表 1 结果说明,改进后的先进算法相比较于改进前拥有更强大的去雨能力,结合图 3 的直观对比可以看出,主要因为改进后的算法在去除纹理细节区域的雨痕时可以取得更好的效果。表 2 结果说明,所提改进卷积方式可以在没有明显增加计算时间与训练所需的显存情况下,有效地提升网络的去雨性能。

4.3 图像去雾

图像去雾与图像去雨任务类似,为去除有雾图像中的雾霾,从而重构出一张清晰的背景图像。根据经典的去雾模型^[29],该任务可以描述为

$$\mathbf{I}(x) = \mathbf{J}(x)\mathbf{t}(x) + \mathbf{A}[\mathbf{1} - \mathbf{t}(x)], \quad (5)$$

式中: \mathbf{I} 为观测到的雾图; \mathbf{J} 为清晰的背景原图; \mathbf{t} 为转移矩阵; \mathbf{A} 为大气光参数。构建的去雾网络需要估计 \mathbf{t} 与 \mathbf{A} 两个参数来重构出清晰的背景原图。根据 Li 等^[30]提出的改进模型,上述模型可以简化为

$$\begin{cases} \mathbf{J}(x) = \mathbf{K}(x)\mathbf{I}(x) - \mathbf{K}(x)\mathbf{b} \\ \mathbf{K}(x) = \frac{1}{\mathbf{t}(x)}[\mathbf{I}(x) - \mathbf{A}] + \mathbf{A} - \mathbf{b} \end{cases}, \quad (6)$$

式中: \mathbf{K} 为包含待估计参数 \mathbf{t} 与 \mathbf{A} 的混合参数; \mathbf{b} 为偏差,根据 Li 等^[30]的设计, $|\mathbf{b}|=1$ 。根据此模型,则网络仅需估计一个混合参数 \mathbf{K} 。

为了验证所提改进卷积方法不仅适用于图像去雨任务,还可以应用于图像增强领域的其他任务,选取图像去雾中的一个经典方法 AODNet^[30]进行测试。与前文相同,改进后的 AODNet 记作 AODNet+。性能的对比仍选用 PSNR 与 SSIM 指标,采用的评价数据集为 Li 等^[30]提供的 Test A 测试数据集,结果如表 3 和表 4 所示。该对比结果说明:所提改进卷积算法不仅适用于图像去雨问题,且适用于图像去雾等相似任务上,同样可以在不增加很多计算资源的前提下提升算法性能。

表 3 AODNet 改进前后的性能对比

Table 3 Comparison results of performance of AODNet

Parameter	AODNet	AODNet+
PSNR	19.6954	20.1430
SSIM	0.8478	0.8539

表 4 AODNet 改进前后的时间和显存对比

Table 4 Comparison results of computing time and GPU memory of AODNet before and after improvement

Parameter	AODNet	AODNet+
Time /s	0.0087	0.0095
GPU memory /MB	587	614

5 结 论

提出了一个结合图卷积思想与机制的针对图像去雨的改进卷积操作。通过计算图像局部相似度来构建图结构,可以在卷积过程中对卷积核参数进行局部调整,充分考虑局部拓扑信息以及较远的像素点的影响。且所提改进卷积方法并没有增加很多的计算资源,仅略高于传统的卷积。在图像去雨、图像去雾这些任务上,所提改进卷积方法在替换了经典算法中的传统卷积后,可以明显提升算法性能。

参 考 文 献

- [1] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [2] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [3] Deng J, Dong W, Socher R, et al. ImageNet: a large-scale hierarchical image database[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition, June 20-25, 2009, Miami, FL, USA. New York: IEEE Press, 2009: 248-255.
- [4] Srivastava N, Hinton G E, Krizhevsky A, et al. Dropout: a simple way to prevent neural networks from overfitting[J]. Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [5] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [6] 常亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络[J]. 自动化学报, 2016, 42(9): 1300-1312. Chang L, Deng X M, Zhou M Q, et al. Convolutional neural networks in image understanding[J]. Acta Automatica Sinica, 2016, 42(9): 1300-1312.
- [7] 王科俊, 赵彦东, 邢向磊. 深度学习在无人驾驶汽车领域应用的研究进展[J]. 智能系统学报, 2018, 13(1): 55-69. Wang K J, Zhao Y D, Xing X L. Deep learning in driverless vehicles[J]. CAAI Transactions on Intelligent Systems, 2018, 13(1): 55-69.

- [8] 周姣, 辛云宏. 基于显著性与尺度空间的红外弱小目标检测[J]. 激光与红外, 2015, 45(4): 452-456.
Zhou J, Xin Y H. Infrared dim small target detection based on saliency and scale-space[J]. Laser & Infrared, 2015, 45(4): 452-456.
- [9] 江智呈, 李志伟, 陈晨, 等. 基于多尺度前馈结构的单幅图像去雨算法[J]. 激光与光电子学进展, 2022, 59(12): 1215001.
Jiang Z C, Li Z W, Chen C, et al. Multiscale feedforward structure-based single image rain removal algorithm[J]. Laser & Optoelectronics Progress, 2022, 59(12): 1215001.
- [10] 班玛宝, 才让加, 张瑞, 等. 融合双通道音节特征的藏文 La 格例句自动分类模型[J]. 北京大学学报(自然科学版), 2022, 58(1): 91-98.
Ban M B, Cai R J, Zhang R, et al. An automatic classification model of Tibetan La case example sentences with fusion dual-channel syllable features[J]. Acta Scientiarum Naturalium Universitatis Pekinensis, 2022, 58(1): 91-98.
- [11] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[EB/OL]. (2014-06-10) [2021-05-04]. <https://arxiv.org/abs/1406.2661>.
- [12] Cinbis R G, Verbeek J, Schmid C. Weakly supervised object localization with multi-fold multiple instance learning[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(1): 189-203.
- [13] Zhang S D, He F Z, Ren W Q. NLDN: Non-local dehazing network for dense haze removal[J]. Neurocomputing, 2020, 410: 363-373.
- [14] Park J, Brady D J, Zheng G A, et al. Review of bio-optical imaging systems with a high space-bandwidth product[J]. Advanced Photonics, 2021, 3(4): 044001.
- [15] Ding P P, Yao Y H, Qi D L, et al. Single-shot spectral-volumetric compressed ultrafast photography[J]. Advanced Photonics, 2021, 3(4): 045001.
- [16] Zeng X K, Zheng S Q, Cai Y, et al. High-spatial-resolution ultrafast framing imaging at 15 trillion frames per second by optical parametric amplification[J]. Advanced Photonics, 2020, 2(5): 056002.
- [17] Scarselli F, Gori M, Tsoi A C, et al. The graph neural network model[J]. IEEE Transactions on Neural Networks, 2009, 20(1): 61-80.
- [18] Valsesia D, Fracastoro G, Magli E. Deep graph-convolutional image denoising[J]. IEEE Transactions on Image Processing, 2020, 29: 8226-8237.
- [19] Zhou S C, Zhang J W, Zuo W M, et al. Cross-scale internal graph neural network for image super-resolution [EB/OL]. (2020-06-30) [2021-04-09]. <https://arxiv.org/abs/2006.16673>.
- [20] Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks[EB/OL]. (2016-09-09) [2021-05-04]. <https://arxiv.org/abs/1609.02907>.
- [21] Defferrard M, Bresson X, Vandergheynst P. Convolutional neural networks on graphs with fast localized spectral filtering[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems, December 5-10, 2016, Barcelona, Spain. New York: ACM Press, 2016: 3844-3852.
- [22] Ren D W, Shang W, Zhu P F, et al. Single image deraining using bilateral recurrent network[J]. IEEE Transactions on Image Processing, 2020, 29: 6852-6863.
- [23] Cai B L, Xu X M, Jia K, et al. DehazeNet: an end-to-end system for single image haze removal[J]. IEEE Transactions on Image Processing, 2016, 25(11): 5187-5198.
- [24] Yang W H, Tan R T, Feng J S, et al. Deep joint rain detection and removal from a single image[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 1685-1694.
- [25] Yang W H, Tan R T, Feng J S, et al. Joint rain detection and removal from a single image with contextualized deep networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(6): 1377-1393.
- [26] Hong T, Li Z P. Peak-to-average power ratio reduction for an artificial noise aided secure communication system [C]//2016 3rd International Conference on Information Science and Control Engineering (ICISCE), July 8-10, 2016, Beijing, China. New York: IEEE Press, 2016: 1370-1374.
- [27] Huynh T Q, Ghanbari M. The accuracy of PSNR in predicting video quality for different video scenes and frame rates[J]. Telecommunication Systems, 2012, 49(1): 35-48.
- [28] Wang Z, Bovik A C, Sheikh H R, et al. Image quality assessment: from error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612.
- [29] Hide R. Optics of the atmosphere: scattering by molecules and particles[J]. Physics Bulletin, 1977, 28(11): 521.
- [30] Li B Y, Peng X L, Wang Z Y, et al. AOD-net: all-in-one dehazing network[C]//2017 IEEE International Conference on Computer Vision, October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 4780-4788.