

引用格式: 苏志明, 王烈. 基于改进 Ghost 模块的快速去雾算法[J]. 微电子学与计算机, 2021, 38(6): 27-32. [SU Z M, WANG L. Fast defogging algorithm based on improved Ghost module[J]. Microelectronics & Computer, 2021, 38(6): 27-32]

基于改进 Ghost 模块的快速去雾算法

苏志明, 王 烈

(广西大学 计算机与电子信息学院, 广西 南宁 530004)

摘 要: 最近基于卷积神经网络的端到端学习算法在去雾方面取得了进展, 但这些算法大都使用过深过大的网络去拟合含雾图像数据, 从而导致去雾速度偏慢. 为解决此问题, 本文提出了一个用于单幅图像快速去雾的高效去雾模型. 该模型基于改进的 Ghost 模块构建轻量级神经网络; 将金字塔池化和注意力机制结合获取图像不同区域的上下文信息, 从而提高了网络获取含雾图像全局信息的能力. 该网络在 RESIDE 的室外数据集进行训练和测试. 实验结果表明: 相比较 DCP、MSCNN、AODNet 等先进算法, 所提出的方法具有令人满意的去雾质量和速度.

关键词: 快速去雾; 金字塔池化; 注意力机制

中图分类号: TP391.41

文献标识码: A

文章编号: 1000-7180(2021)06-0027-06

Fast defogging algorithm based on improved Ghost module

SU Zhi-ming, WANG Lie

(School of Computer and Electronic Information, Guangxi University, Nanning 530004, Guangxi China)

Abstract: Recently, end-to-end learning algorithms based on convolutional neural networks have made progress in defogging, but most of them use networks that are too deep and too large to fit foggy image data, resulting in slow defogging speed. To solve this problem, an efficient defogging model is proposed in this paper, which can be used to quickly defog a single image. The model is based on the improved GHOST module to build a lightweight neural network. Pyramid pooling and attention mechanism are combined to obtain the context information of different areas of the image, thus improving the network's ability to obtain the global information of foggy images. The network RESIDE in Donatella's outdoor data set for training and testing. Experimental results show that, compared with DCP, MSCNN, AODNet and other advanced algorithms, the proposed method has satisfactory defogging quality and speed.

Key words: fast defogging; pyramid pooling; attention mechanism

1 引言

在恶劣条件下, 户外图像的摄取易受到空气中的悬浮粒子(如雾霾等)的影响造成图像降质, 这是由于悬浮粒子会对光线产生散射, 使成像后图像的对比度降低、颜色偏灰白等^[1]. 为了美化图像的视觉效果以及方便后续计算机进行高级视觉任务, 如图像分类、目标检测等, 需要从含雾图像中恢复无雾的清晰图像.

基于手工提取特征恢复图像是传统去雾常用手

段. 各种基于先验理论去雾算法只有在特定约束条件下有效, 具有一定的应用局限性. 例如暗原色先验统计算法^[2] (Dark Channel prior, DCP) 应用于存在白色物体、天空区域的图像恢复会导致过度增强、光晕、色偏等.

近年来, 深度学习越来越多应用到计算机视觉任务: 去雾、去雨、去噪、图像增强等. Cai 等^[3] 提出了 Dehazenet 通过卷积神经网络预测出带雾图像的介质传输图. Ren 等^[4] 提出 MSCNN 通过多尺度卷积神经网络生成粗略场景透射率, 并采用多尺度融

合完成图像去雾. 以往常用的方法是分别估计介质传输图和大气光值, 这两者求解的结果是有误差的, 相结合误差更大. 因此, AODNet^[5]将大气散射模型中的介质传输图和大气光值统一到一个 K 参数估计, 改进了去雾的参数分别估计弊端, 提高了去雾鲁棒性. 现有的模型在一些昂贵的显卡如 RTX2080Ti、GTX1080Ti 上才能实现实时去雾, 处理成本偏高. FFA-Net^[6]提出基于注意力的特征融合深度残差网络取得目前最好去雾效果, 但是参数高达 400 多万, 网络复杂度高, 处理速度偏慢.

近年来, 深度学习为了适用于各种场合, 如手机终端、云服务器等, 不仅仅追求算法的高精度等指标, 更需要算法模型的快速运行. 例如近些年来 MobileNet^[7]提出深度可分离卷积, 极大减少了参数, 实现了速度跟精度的平衡, 再到 GhostNet^[8]提出 Ghost 模块将标准卷积融合线性特征消除了卷积中的冗余特征, 在精度和速度上优于 MobileNet 系列网络.

因此, 本文结合 AODNet 的去雾思想, 基于大气散射模型和改进的 Ghost 模块, 结合特征注意力金字塔池化模块^[9], 提高全局信息处理能力, 最终实现快速去雾.

2 去雾方法

2.1 改进的 Ghost 模块

Chost 模块如图 1 所示, 当 Φ 为 1 时, 分两步求得与普通卷积数量一致的特征图.

(1) 少量卷积. 如若正常使用 64 个卷积核, 这里就用 32 个卷积核, 从而减少一半的计算量.

(2) 廉价操作. 如图 1 中的 Φ 表示, 是深度卷积 (卷积核 $3 \times 3, 5 \times 5$ 等), 数量为正常使用的一半即 32.




图 1 Ghost 模块

本文 Ghost 模块 Φ 取值为 1 即固定一个 1×1 卷积 (记为 $k \times k$) 和一个 3×3 深度卷积 (可取 $3 \times 3, 5 \times 5, 7 \times 7$ 等, 记为 $d \times d$) 提取特征, 可以看做并行

式深度可分离卷积. 按照 GhostNet 中的理论, 计算量为

$$0.5 \cdot n \cdot h \cdot w \cdot c \cdot k \cdot k + 0.5 \cdot n \cdot h \cdot w \cdot d \cdot d \quad (1)$$

式中, n, c 分别为输出输入通道数; h, w 分别为输入图像高和宽.

深度可分离卷积的 1×1 卷积和深度卷积是串行式, 计算量为

$$n \cdot h \cdot w \cdot d \cdot d + n \cdot h \cdot w \cdot c \cdot k \cdot k \quad (2)$$

可得到两者的比值为 $1/2$, 即计算量是深度可分离卷积的一半. 由此可见, 该模块可以用于设计轻量级卷积神经网络, 更适合实时性高的应用场景.

为了改进网络去雾性能, 我们将 Ghost 模块做出改进如图 2 所示.




图 2 改进的 Ghost 模块

去除深度卷积后的非线性激活可保护提取特征不受破坏, 提升网络的性能^[10]. 但深度卷积后稀疏化操作增强网络特征表达能力, 因此保留 IN (Instance Normalization). 这是因为去雾网络输入分辨率高, 受 GPU 内存限制 batch size 通常取值为个位数, 而 BN (Batch Normalization) 沿着 batch 维度进行归一化, 其受限于 batch size; 当 batch size 很小时, BN 会得到不准确的统计估计, 这会导致模型误差明显增加, 从而影响去雾质量和去雾图像的视觉效果. 而且 IN 更注重像素级任务如图像风格迁移等. 本文的端到端图像去雾也是像素级生成任务, 需要考虑每个像素的重要性. 综上所述, 在小批量输入训练模型时, 理论上 IN 更适合图像去雾任务.

2.2 AODNet 去雾思想

雾霾的形成可用大气散射模型解释

$$I(x) = J(x)t(x) + A(1 - t(x)) \quad (3)$$

式中, x 为图像像素; $I(x)$ 为含雾图像; $J(x)$ 表示无雾图像; $t(x)$ 为介质传输图; A 是指全局大气光值. $t(x)$ 的表达式为

$$t(x) = e^{-\beta(\gamma)d(x)} \quad (4)$$

式中, β 是大气散射因子; γ 是反射光弧长; $d(x)$ 为场景深度, 即场景对象和成像设备的距离.

若不加约束条件,该方程有无数解. AODnet 巧妙地将大气光值和介质传输图统一到一个方程

$$J(x) = K(x)I(x) - K(x) + b \quad (5)$$




图3 快速去雾算法网络结构




图4 结合特征注意力的金字塔池化模块

$$\text{其中 } K(x) = \frac{\frac{1}{t}(I(x) - A) + A - b}{I(x) - 1} \quad (6)$$

式中, b 默认取值为 1, 本文尝试将 b 取其他值, 但去雾后图像客观评价指标峰值信噪比 (peak signal to noise ratio, PSNR) 和结构相似性 (structural similarity, SSIM) 均不如取 1 时高。

2.3 网络结构

本文提出的快速去雾算法网络结构如图 3 所示. 在 $k \times k \times N$ 中, k 为 Ghost 模块中深度卷积的滤波器大小, N 为滤波器个数. 经不同尺度 Ghost 模块得到的特征图输入结合注意力机制的金字塔池化模块, 如图 3 所示. 本文通过不同层级的池化聚合上下文信息, 如图 4 所示. 平均池化卷积核大小分别为 $4 \times 4, 8 \times 8, 16 \times 16, 32 \times 32$. 为了保证全局特征的权重, 若金字塔有 N 个层级, 池化后经 1×1 卷积将每级的通道数降低为原来的 $1/N$. 然后将每级的特征图经双线性插值上采样得到池化前大小相同的特征图. 金字塔池化后获得空间信息, 但缺乏通道间某种联系, 经通道注意力获取通道权重, 与经金字塔池化的特征图相乘, 得到通道注意力的全局信息. 而经金字塔池化降低层级信息会损失细节信息, 因此在未池化前引入 1×1 空间注意力机制, 和通道注意

力机制相融合, 在参数量极少的情况下, 提高了网络去雾能力. 最后经带填充的 3×3 池化进行滤波得到精细的 K 图. 最后通过式 (5) 恢复无雾图像.

3 实验

所提出的网络通过定性和定量分析进行了检验. 定量分析考虑了全参考图像质量评价指标 PSNR 和 SSIM, 其数值越大表示算法越好. PSNR 计算公式为

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} (I(x, y) - K(x, y))^2 \quad (7)$$

$$PSNR = 10 \cdot \log_{10} \left(\frac{MAX_I^2}{MSE} \right) \quad (8)$$

式中, m, n 为含雾图像 I 和去雾后图像 K 的高和宽, i, j 为图像像素值的横纵坐标. MAX_I 通常为 255.

SSIM 的计算公式为

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (9)$$

式中, μ_x, μ_y 分别为图像 x 和 y 的均值; σ_x, σ_y 分别为图像 x 和 y 的标准差; σ_x^2, σ_y^2 分别为图像 x 和 y 的方差. σ_{xy} 为图像 x 和 y 的协方差. $c_1 = (k_1 L)^2, c_2 = (k_2 L)^2$, 通常 $k_1 = 0.01, k_2 = 0.03, L = 255$.

此外, 我们将其与最先进的方法进行了比较, 包

括 DCP^[2], MSCNN^[4], Dehazenet^[3] 和 AODNet^[5].

3.1 训练数据集

本文的方法是基于数据驱动的. 雾霾、烟等恶劣天气通常发生在户外, 户外的图像包含的背景更丰富, 如天空、白云等, 去雾相对室内更有挑战性. 因此, 我们使用 RESIDE^[11] 室外合成数据集进行训练, 该数据集包含 72 135 个有雾图像和 2 061 个无雾图像, 其中每张无雾图像被合成为 35 个不同请在等级的有雾图像. 测试时使用 SOTS 室外数据集包含 500 张雾天图像, 取 500 幅图像的 PSNR 和 SSIM 的平均值做为最终结果.

3.2 训练细节

使用 Pytorch 开发模型, 系统为 Windows 10, 英特尔酷睿 i7-9750H CPU@2. 60 GHz, 内存为 24 GB, 显卡为 NVIDIA GTX1650. 使用 Adam 优化网络, β_1 和 β_2 值分别为 0. 9, 0. 99. 图像大小调整为 480×480 , batchsize 为 8, 学习初始效率为 0. 001, 八万步后衰减为 $1e-4$, 总共训练 10^5 步. 图像增强为随机旋转角度为 90, 180, 270. 通过数据增强扩充训练样本数, 提高模型的泛化能力和去雾能力. 损失函数为均方差损失函数. 计算公式为

$$L_{MSE}(I(x), O(x)) = \sum_{i=1}^a \| I(x) - O(x) \|^2 \quad (10)$$

式中, $I(x)$ 表示网络输出的预测结果; $O(x)$ 表示 Groundtruth; a 为输入数据个数.

客观评价指标 PSNR 和 SSIM 为 500 张 SOTS 室外图像的平均值.

4 实验和结果

4.1 模型选择

为了选取更佳的去雾模型, 我们进行了不基于先验理论的模型 $J_1 = I + R$ (其中 J 是清晰图像, I 是输入含雾图像, R 为神经网络最后输出的 3 通道特征图) 和基于大气退化模型两种模型, $J_2 = I \times R$, $J_3 = KI - K + 1$ 的去雾对比实验. 学习效率为 $1e-4$, 训练 15 万步. 三种模型均在无任何 BN 或 IN 等批归一化手段下实验.

表 1 不同模型实验对比

模型	PSNR	SSIM
$J_1 = I + R$	15. 93	0. 812 5
$J_2 = I \times R$	22. 01	0. 872 7
$J_3 = KI - K + 1$	23. 89	0. 932 9

由表 1 可知, J_3 去雾的 PSNR 和 SSIM 明显高于 J_1 和 J_2 , 这是因为不基于先验知识的模型去雾需

要更深的, 通道数更多的神经网络去拟合数据, 当网络拟合能力欠佳时并不能取得较好去雾效果. 而基于大气退化模型有大气模型的条件制约作为指导, 更容易恢复出质量较高的无雾图像(J_3 比 J_2 模型表达式更为准确).

4.2 定性和定量评价

如表 2 所示, 本文算法相比于 DCP、Dehazenet、MSCNN 和 AODNet 的客观评价指标更优异, 明显高于这些对比算法. DCP 算法为传统去雾方法, 存在传输图估计不准确的问题, 去雾效果一般, 去雾客观评价指标 PSNR 和 SSIM 分别为 19. 13, 0. 814 3. 而 Dehazenet 基于深度学习模型估计传输图, 但大气光值还是人为统计计算的, 同样存在估计偏差的问题, 但去雾质量比 DCP 算法有所提升, PSNR 约提升了 3. 3 dB. 本文算法比 AODNet 的 PSNR 和 SSIM 分别提升了 2. 4 dB, 0. 033. MSCNN 算法也是深度学习去雾, 去雾效果一般, 仍有改善空间. 而且 AODNet 网络模型大小为 18 KB, 而本文算法为 17 KB, 两者相差不大. 定性评价见图 5, 第一行为真实雾图去雾, 第二行为合成室外图像去雾. DCP 去雾算法对天空处理不够鲁棒, 存在色偏. Dehazenet 去雾结果比较好, 但色彩偏深偏暗(如图 5 第一行, 第 3 幅). MSCNN 去雾后的图像明显有较多雾(图 5 对应两幅图像). AODNet 算法去雾效果相对较好, 但颜色偏暗. 本文算法基于 AODNet 思想去雾, 和 AODNet 一样去雾不彻底, 仍有雾霾残留, 但亮度较 AODNet 好.

表 2 不同算法在 SOTS 数据集上的定量评估

去雾算法	PSNR	SSIM
DCP	19. 13	0. 814 3
Dehazenet	22. 46	0. 851 4
MSCNN	17. 48	0. 8105
AODNet	23. 38	0. 911 9
本文算法	25. 79	0. 944 9

4.3 去雾耗时

在本实验平台下, 统计了 30 幅 480×480 的真实雾图的平均处理耗时以及相应的方差, 如表 3 所示. 为了避免不必要的误差, 我们使用了官方开源代码和官方认可的开源代码进行对比测试. 本文算法去雾速度最快, 比 AODNet 快速去雾算法具有一点点处理速度优势, 优于 DCP、DCP(fast)、MSCNN 和 Dehazenet 算法. 除了 DCP 算法方差稍微大一点, 其他几种算法方差并不大, 去雾速度比较稳定.




图 5 不同图像去雾方法比较

表 3 不同算法耗时对比

算法	耗时(s)	方差	平台
DCP	12. 31	0. 020 63	Matlab
DCP(fast)	0. 73	0. 000 52	Matlab
MSCNN	0. 91	0. 000 40	Matlab
Dehazenet	1. 57	0. 000 38	Matlab
AODNet	0. 43	0. 000 52	Pytorch
本文算法	0. 38	0. 000 43	Pytorch

4. 4 消融实验

如表 4 所示,模型是未改进的 Ghost 模块搭建,使用 IN 改进 Ghost 模块获得了最高 PSNR 和 SSIM,说明深度卷积后直接线性输出有利于防止其提取的特征不受破坏,从而验证改进有效.

表 4 不同改进实验对比

	PSNR	SSIM	运行时间(s)
模型	24. 89	0. 929 1	0. 43
模型+IN	25. 79	0. 944 9	0. 38
模型+BN	24. 83	0. 940 1	0. 38

5 结束语

本文基于改进的 Ghost 模块和结合注意力机制的金字塔池化模块提出了一个新的卷积神经网络结构用于单幅图像快速去雾. 消融实验证明改进的 Ghost 模块有效地提升了去雾质量. 在 RESIDE 室外数据集实验证明,相比于所提到的其他算法,本文算法在定量定性和速度上均有优势. 特别地,在模型参数基本一致的情况下,本文算法相比于 AODNet,在运行速度上略优,而且在 PSNR 上约提升了 2. 4 dB.

参考文献:

[1] 吴迪,朱青松. 图像去雾的最新研究进展[J]. 自动化学报, 2015, 41(2): 221-239. DOI: 10. 16383/j. aas. 2015. c131137.

WU D, ZHU Q S. The latest research progress of image dehazing[J]. Acta Automatica Sinica, 2015, 41 (2): 221-239. DOI: 10. 16383/j. aas. 2015. c131137.

[2] HE K M, SUN J, TANG X O. Single image haze removal using dark channel prior[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33 (12): 2341-2353. DOI: 10. 1109/TPAMI. 2010. 168.

[3] 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. DOI: 10. 1109/TIP. 2016. 2598681.

[4] REN W Q, LIU S, ZHANG H, et al. Single image dehazing via multi-scale convolutional neural networks [C]//Proceedings of the14th European Conference European Conference on Computer Vision. Amsterdam: Springer, 2016: 154-169. DOI: 10. 1007/978-3-319-46475-6_10.

[5] LI B Y, PENG X L, WANG Z Y, et al. AOD-Net: all-in-one dehazing network[C]//Proceedings of the IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 4770-4778. DOI: 10. 1109/ICCV. 2017. 511.

[6] QIN X, WANG Z L, BAI Y C, et al. FFA-Net: Feature Fusion Attention Network for Single Image Dehazing[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34 (7): 11908-11915. DOI: 10. 1609/aaai. v34i07. 6865.

- [7] HOWARD A G, ZHU M L, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [J]. arXiv preprint arXiv: 1704.04861, 2017.
- [8] HAN K, WANG Y H, TIAN Q, et al. GhostNet: more features from cheap operations[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 1580-1589. DOI: 10.1109/CVPR42600.2020.00165.
- [9] ZHAO H S, SHI J P, QI X J, et al. Pyramid scene parsing network[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 2881-2890. DOI: 10.1109/CVPR.2017.660.
- [10] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]//Proceedings of the 2017 IEEEConference onComputer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 1800-1807. DOI: 10.1109/CVPR.2017.195.
- [11] LI B Y, REN W Q, FU D P, et al. Benchmarking single-image dehazing and beyond[J]. IEEE Transactions on Image Processing, 2019, 28(1): 492-505. DOI: 10.1109/TIP.2018.2867951.

作者简介:

苏志明 男,(1994-),硕士研究生.研究方向为深度学习、图像处理.

王 烈(通讯作者) 男,(1965-),教授,硕士研究生导师.研究方向为 FPGA 和深度学习、图像处理.

E-mail:lwang@gxu.edu.cn

(上接第 26 页)

- [11] ERICKSON A. Transaction-level friending: an open-source, standards-based library for connecting TLM models in SystemC and SystemVerilog[C]//Design and Verification Conference & Exhibition (DVCon). San Jose, CA: Accellera, 2013: 321-330.
- [12] 李璐,周春良,冯曦,等. 基于 DPI-C 接口的可扩展 SOC 验证平台[J]. 电子设计工程, 2018, 26(4): 136-140. DOI: 10.14022/j.cnki.dzsjgc.2018.04.029.
- LI L, ZHOU C L, FENG X, et al. An extensible SOC verification platform based on DPI-C interface [J]. Electronic Design Engineering, 2018, 26(4): 136-140. DOI: 10.14022/j.cnki.dzsjgc.2018.04.029.
- [13] 杨宇科,王保成. 基于 FPGA 和 EMIFA 的 SPI 控制器系统设计[J]. 计算机测量与控制, 2019, 27(5): 82-86. DOI: 10.16526/j.cnki.11-4762/tp.2019.05.019.
- YANG Y K, WANG B C. Design of a SPI controller system based on FPGA and EMIFA [J]. Computer Measurement & Control, 2019, 27(5): 82-86. DOI: 10.16526/j.cnki.11-4762/tp.2019.05.019.
- [14] 刘梦影,王芬芬. 基于 APB 总线的 SPI 接口设计与实现[J]. 电子与封装, 2018, 18(5): 28-32. DOI: 10.16257/j.cnki.1681-1070.2018.0054.
- LIU M Y, WANG F F. Design and implement of SPI based on APB[J]. Electronics & Packaging, 2018, 18(5): 28-32. DOI: 10.16257/j.cnki.1681-1070.2018.0054.
- [15] Accellera. Universal verification methodology (UVM) 1.2 user's guide[EB/OL]. (2015-10-08) [2020-10-17]. https://www.accellera.org/images/downloads/standards/uvm/uvm_users_guide_1.2.pdf.

作者简介:

任传宝 男,(1996-),硕士研究生.研究方向为数字集成电路验证技术.

崔建国 男,(1996-),硕士研究生.研究方向为硬件安全技术.

鲁迎春 男,(1979-),讲师,博士研究生.研究方向为可编程逻辑器件设计.

黄正峰 男,(1978-),博士,教授.研究方向为数字集成电路的硬件容错.

易茂祥(通讯作者) 男,(1964-),博士,教授.研究方向为集成电路测试与可靠性设计. E-mail: mxyi126@126.com.