

文章编号 1004-924X(2021)11-2692-11

物理成像模型的分解合成循环细化去雾网络

冯燕茹¹, 王一斌^{2*}

(1. 防灾科技学院 信息工程学院, 河北 三河 065201;
2. 四川师范大学 工学院, 四川 成都 610068)

摘要:为了充分挖掘雾天成像时的先验信息和物理参数间的约束关系,提高去雾算法的精度,本文提出了嵌入物理成像模型的分解合成循环细化网络以实现图像去雾。不同于已有的去雾算法,它包含透射率估计分支和清晰图像估计分支,且两分支均使用嵌入循环单元的多尺度金字塔编码解码网络框架来实现,具有能加强循环间信息交流、充分利用多尺度上下文特征的优点。考虑到透射率与场景深度和雾气浓度有关,可将透射率视为雾浓度先验,引导清晰图像估计分支循环细化去雾结果;而清晰图像中包含场景的深度信息,可将其视为深度先验,引导透射率估计分支预测及循环细化透射率。每次循环时,两分支估计的透射率和清晰图像进一步合成雾图,循环作为网络的输入,以确保透射率和清晰图像的估计结果满足物理成像模型的约束。实验结果表明算法在合成雾图及真实图像上均能取得较好的去雾效果,在视觉评价和客观评价方面均优于现有的去雾算法,单张雾图的处理时间仅为 0.037 s,能有效用于图像去雾的工程实践中。

关键词: 图像去雾;透射率估计;循环细化网络;分解合成;物理成像模型

中图分类号: TP391.41 **文献标识码:** A **doi:** 10.37188/OPE.20212911.2692

Dehazing using a decomposition-composition and recurrent refinement network based on the physical imaging model

FENG Yan-ru¹, WANG Yi-bin^{2*}

(1. School of Information Engineering, Institute of Disaster Prevention, Sanhe 065201, China;
2. School of Engineering, Sichuan Normal University, Chengdu 610068, China)

* Corresponding author, E-mail: yibeen.wong@gmail.com

Abstract: To explore the dehazing priors and constraints among the physical parameters during imaging under haze conditions and improve dehazing accuracy, we propose a decomposition - composition and recurrent refinement network based on the physical imaging model for image dehazing. Unlike existing dehazing methods, it contains a transmission prediction branch and a clear image prediction branch. Both branches are built based on the multi-scale pyramid encoder - decoder network with a recurrent unit that can utilize multiscale contextual features and has more complete information exchange. Considering the transmission map is related to the scene depth and haze concentration, the transmission map can be regarded as a haze concentration prior and guide the clear image prediction branch to estimate and refine the dehazing result recurrently. Similarly, the clear image that contains the scene depth information is regarded

收稿日期:2021-05-21;修订日期:2021-06-28.

基金项目:廊坊市科技局科学研究与发展计划自筹经费项目(No. 2021011046);中央高校基本科研业务费专项资金创新团队资助计划项目(No. ZY20180125)

as a depth prior and guides the transmission map prediction branch to predict and refine the transmission map. Then, the predicted transmission map and clear image are further synthesized as the haze image that serves as the input of the network in each recurrent step, enabling the predicted transmission map and clear image to meet the constraints of the physical imaging model. The experimental results demonstrate that our method not only achieves a good dehazing effect on both synthetic and real images, but also outperforms existing methods in terms of quality and quantity. The average processing time for a single hazy image is 0.037 s, indicating that it has potential application value in the engineering practice of image dehazing.

Key words: image dehazing; transmission map estimation; recurrent refinement network; decomposition-composition; physical imaging model

1 引 言

雾天条件下拍摄的户外图像,受大气中悬浮气溶胶等颗粒对光线的散射和吸收作用影响,会出现对比度低,色彩饱和度差,细节丢失等图像降质问题,为后续计算机视觉任务,如遥感监测、交通监控、目标跟踪与识别等,带来了不利的影响。因此,如何消除雾气造成的影响,复原清晰的无雾图像具有实际应用价值和研究意义^[1]。

目前,单幅图像去雾的算法可分为两类:基于先验的图像去雾算法和基于神经网络的去雾算法。基于先验的去雾算法以大气散射物理成像模型为理论依据,通过先验信息来估计模型中的透射率及大气光,最终获取清晰图像。例如,He 等人提出的暗通道先验 Dark Channel Prior (DCP)表明,户外图像中非天空区域的局部邻域内总有像素的某个颜色通道具有较低的像素值^[2]。Fattal 等人发现透射率与场景反射不相关,并由此构建求解透射率的约束方程^[3]。Meng 等人提出了基于边缘及纹理约束先验 Boundary Constraint and Contextual Regularization (BCCR)的去雾算法^[4]。Yoon 等人发现了光的波长与成像时场景目标的颜色相关,提出了基于波长自适应先验 Wavelength-adaptive Prior (WAP)的图像去雾算法^[5]。然而,依据观察或信息统计获得的先验信息无法泛化到所有的雾天场景,算法的鲁棒性较差,去雾精度不高。例如,DCP 无法描述雾图中白色的前景目标,导致估计的透射率精度较低,去雾结果存在色差。

随着深度学习的快速发展,基于神经网络的图像去雾算法广受关注。例如,Zhang 等人提出了金字塔稠密连接网络 Densely Connected Pyra-

mid Dehazing Network (DCPDN),联合估计透射率,大气光及清晰图像^[6]。Yin 等人进一步将金字塔模块与编码解码网络相结合,提出了 Residual Dense Pyramid Network (RDPN),它能从雾图中捕捉有效的上下文信息,以直接估计清晰图像^[7]。受此启发,Chen 等人提出了 Gated Context Aggregation Network (GCAN),进一步利用门限融合机制自适应融合多层次的上下文特征来实现去雾^[8]。随着研究的深入,Shao^[9]和 Yin^[10]等人提出了基于先验信息的图像去雾网络。具体来说,Shao 等人提出 Domain Adaptation Dehazing Network (DADN),它利用领域自适应知识获得合成雾图与真实雾图间的分布差异,引导网络去雾^[9]。而 Yin 等人提出的 Attentive U-Recurrent Network (AURN),将循环网络生成的透射率图视为先验信息,引导后续的编码解码网络实现去雾^[10]。虽然此网络具有较好的去雾效果,但仍存在以下问题:①网络仅考虑了透射率对清晰图像估计时的单向辅助作用,而未考虑清晰图像对透射率估计的辅助作用,从而忽略了透射率与清晰图像间的依赖关系;②网络未充分利用透射率与清晰图像间存在的物理约束,降低了去雾的精度;③多尺度上下文信息未充分利用,约束网络表现力和性能。

针对上述问题,本文提出了嵌入大气散射物理成像模型的分解合成循环细化网络,该模型由两个并行的多尺度金字塔编码解码网络分支作为结构框架,并将 Long Short-Term Memory (LSTM)^[11]循环单元和多尺度金字塔模块嵌入到两个网络分支中。为探索透射率与清晰图像间的依赖关系,充分利用两者满足的物理约束,该模型分别用两个网络分支估计透射率和清晰

图像,并将输出的透射率,清晰图像依据大气散射物理成像模型合成雾图,连同估计的透射率和清晰图像循环作为网络模型的输入。使得清晰图估计分支能在透射率和合成雾图的引导下循环细化清晰图像,同时透射率估计分支在清晰图像和合成雾图的辅助下循环细化透射率。其间,为了充分利用多尺度上下文信息,在两个多尺度金字塔编码解码网络的瓶颈处分别插入 LSTM 循环单元,增强循环间的信息交互。另一方面,网络最后的多尺度金字塔模块,能有效地利用多尺度上下文信息预测结果。实验证明,算法在合成雾图及真实图像上均能取得较好的去雾效果,在视觉评价和客观评价方面优于现有的去雾算法。

2 大气散射物理成像模型

依据 1976 年 McCartney 提出的大气散射物理成像模型,雾天拍摄的降质图像可描述为:

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

其中: (x, y) 为像素的坐标位置索引; I 为雾天图像; A 为大气光; J 为清晰图像; t 为透射率,它与场景的深度和雾的浓度分布有关,可表示为:

$$t(x, y) = e^{-\beta d(x, y)}, \quad (2)$$

其中: $d(x, y)$ 表示场景的深度, β 为散射系数。 t 值越小,雾浓度越大; t 值越大,雾浓度越小。

由此可知, t 和 J 不但满足公式(1)的约束关系,且 t 中包含的雾浓度信息可作为清晰图像 J 估计的先验信息,而清晰图像 J 中包含的深度信息亦可作为透射率 t 估计的先验信息。受此启发,本文提出嵌入物理成像模型的分解合成循环细化去雾网络。

3 嵌入物理成像模型的分解合成循环细化网络

3.1 算法原理

算法原理如图 1 所示,从中可见,本文所提的去雾算法为分解合成的循环结构。在循环开始时,首先输入初始雾图,并利用网络模型中的透射率估计分支和清晰图估计分支分别从初始雾

图中估计出透射率和去雾后的清晰图像,以实现分解操作;随后依据大气散射物理成像模型(公式(1))将估计的透射率和清晰图像合成雾图,以实现合成操作;最后,合成的雾图级联本次循环时估计的透射率和清晰图像一起作为下次循环时网络的输入。循环执行上述过程,直到循环数达到预先设置的最大循环数时停止。此时,清晰图估计分支输出的去雾结果,即为算法最终的结果。

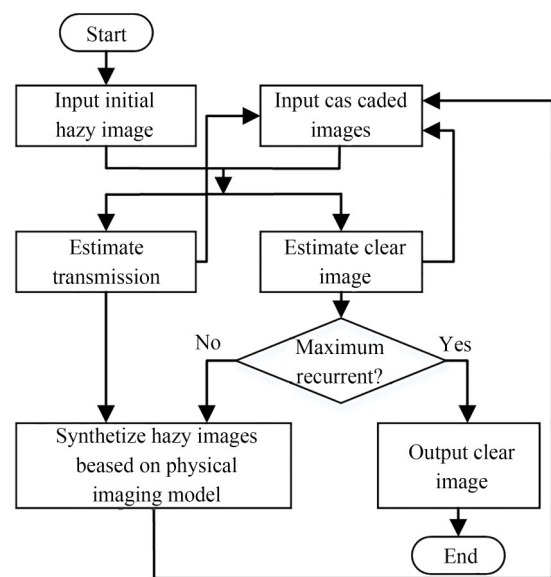


图 1 嵌入物理成像模型的分解合成循环网络模型流程图

Fig. 1 Flowchart of decomposition-composition and recurrent refinement network based on the physical imaging model

具体来说,本文所提的分解合成循环细化网络结构如图 2 所示,主要包括两个结构相同的多尺度金字塔编码解码网络分支,即透射率估计分支和清晰图像估计分支,分别预测并循环细化透射率和清晰图像。在网络循环的过程中,模型将上次循环时估计的透射率,清晰图像以及合成的雾图共同作为模型下次循环的输入,此操作不但能使上次循环时估计的透射率和清晰图像分别作为本次循环时,清晰图像估计分支和清晰图像估计分支的引导信息,还能将两分支估计结果合成的雾图,循环作为网络的输入,以达到充分利用两者间物理约束,实现去雾的目的。相关的函数表示如下:

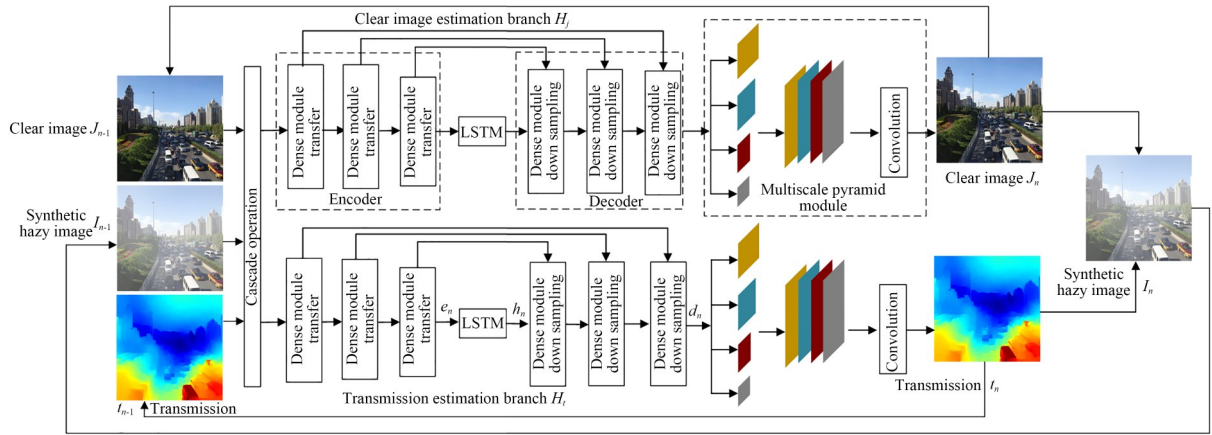


图 2 嵌入物理成像模型的分解合成循环细化网络结构

Fig. 2 The architecture of decomposition-composition and recurrent refinement network based on physical imaging model

$$t_n = H_t([t_{n-1}, J_{n-1}, I_{n-1}]), \quad (3)$$

$$J_n = H_j([t_{n-1}, J_{n-1}, I_{n-1}]), \quad (4)$$

$$I_n = J_n t_n + A(1 - t_n), \quad (5)$$

其中: n 为循环次数; $t_{n-1}, J_{n-1}, I_{n-1}$ 分别为第 $n-1$ 次循环时网络输出的透射率,清晰图像以及合成的雾图; t_n, J_n, I_n 分别为第 n 次循环时获得透射率,清晰图像以及合成的雾图。 $[\cdot]$ 为级联操作。 H_t 及 H_j 分别为透射率估计分支函数及清晰图像估计分支函数。

如图 1 所示, $n-1$ 次循环时网络的输出 t_{n-1}, J_{n-1} ,级联雾图 I_{n-1} ,作为本次循环网络的输入,并由公式(3)的 H_t 和公式(4)的 H_j 分别预测第 n 次循环时的 t_n 和 J_n ,以实现分解操作。随后公式(5)依据大气散射物理成像模型(公式(1))将网络分支预计的 t_n 和 J_n 合成雾图 I_n ,并进一步级联 t_n 和 J_n 作为 $n+1$ 次循环时网络的输入,以实现合成操作。

3.2 多尺度金字塔编码解码的网络分支

网络中透射率估计分支及清晰图像估计分支均具有相同的循环网络结构,即多尺度金字塔的编码解码网络。它在编码解码网络中添加了 LSTM 循环单元及多尺度金字塔模块,以便加强循环间的信息交互,充分利用多尺度上下文信息。以透射率估计分支 H_t 为例,各组件的描述如下:

(1) 编码器

从输入 $t_{n-1}, J_{n-1}, I_{n-1}$ 提取特征。它包含 1 个卷积池化层,3 个稠密模块。考虑到卷积池化层组合被广泛用于图像分类,以实现空间维度减

少,感受野增大,我们在网络的初始阶段设计了 1 个核为 3×3 ,步长为 2 的卷积层;以及 1 个核为 5×5 ,步长为 2 的最大池化层。随后,为了最大化信息流,确保网络的快速收敛,卷积池化层输出的信息进入 dense-net121 网络^[6]所提供的 3 个稠密模块。这里每个稠密模块的最后均包含一个转换层,以提供下采样操作。故编码器输出的特征大小为输入图像大小的 $1/32$ 。相关函数:

$$e_n = H_e(H_e(H_e(H_{cp}([t_{n-1}, J_{n-1}, I_{n-1}]))))), \quad (6)$$

其中: H_{cp} 为卷积池化层函数, H_e 为编码器中加转换层的稠密模块函数, e_n 为第 n 次循环编码器输出。

(2) LSTM 循环单元

基于编码解码的循环网络,仅利用网络的输出作为输入来实现循环,忽略了循环时中间层信息的交互。为解决该问题,我们在编码器与解码器的中间嵌入卷积 LSTM 循环单元,以便将本次循环时中间层捕获的信息用于下次循环。

$$h_n = H_{lstm}(e_n), \quad (7)$$

其中: H_{lstm} 为卷积 LSTM 循环单元的函数, h_n 为当前第 n 次循环时卷积 LSTM 循环单元的输出。更多卷积 LSTM 循环单元细节详见 3.3 节。

(3) 解码器

为将特征重构为与输入图像大小一致的透射率,我们堆叠 5 个稠密模块^[6]来构成解码器。与编码器对应,每个稠密模块最后都添加一个上采样操作,以逐步增大空间维度。相关函数如下:

$$d_n = H_d \left(H_d \left(H_d \left(H_d \left(H_d (h_n) \right) \right) \right) \right), \quad (8)$$

其中： H_d 为解码器中添加了上采样操作的稠密模块函数， d_n 为当前第 n 次循环时解码器的输出。

(4)多尺度金字塔模块

虽然嵌入 LSTM 循环单元的编码解码网络能充分利用网络的中间信息,强化循环操作间的信息交互,但忽略了雾天场景在不同尺度下的全局信息。受全局上下文信息在目标分类及图像分割任务中应用的启发^[12-14],在编码解码网络的最后插入多尺度金字塔模块,估计最终结果。这里,本文不但利用大的池化尺度来捕捉全局上下文信息,还利用小的池化尺度来获取体现场景结构的局部信息。

函数如下:

$$t_n = H_r (H_{p_1}(d_n \uparrow), H_{p_2}(d_n \uparrow), H_{p_3}(d_n \uparrow), H_{p_4}(d_n \uparrow)), \quad (9)$$

其中： $H_{p_1}, H_{p_2}, H_{p_3}, H_{p_4}$ 为池化层函数,分别提取池化大小为 $1/32, 1/16, 1/8, 1/4$ 特征； \uparrow 为上采样操作,它将池化后的特征上采样为与输入图像大小相同的特征； H_r 为映射层,它采用核为 3×3 ,步长为1的卷积层将级联的多尺度特征映射为透射率 t_n 。

3.3 卷积 LSTM 循环单元

受文献^[10]启发,编码器及解码器中间层提取的特征,包含与视觉任务相关的丰富信息,在此处添加 LSTM 循环单元,可最大程度捕获当前循

环时,与任务相关的重要信息,用于下次循环。这里采用卷积 LSTM 实现该操作,它具有参数少,实现简单的优点。其结构如图3所示,包含输入门 P ,输入门控制单元 G ,输出门控制单元 O 和记忆单元 C ,遗忘门控制单元 R 。输入门 P 和输入门控制单元 G 共同控制进入记忆单元 C 的信息;遗忘门控制单元 R 控制记忆单元 C 中的信息被保留或被删除;输出门控制单元 O 控制从卷积 LSTM 中输出信息。其中 P, G, O, R 各包含2个卷积层,且2个卷积层的输入分别为编码器的输出 e_n (见公式(6))以及第 $n-1$ 次循环时 H_{lstm} 的隐藏状态 h_{n-1} ,而 LSTM 的输出为当前第 n 次循环时隐藏状态 h_n (见公式(7))。相同的 LSTM 循环单元同样嵌入到清晰图像估计分支 H_d 中。

从图4可见,在实现的过程中,对于透射率估计分支和清晰图像估计分支而言,第 $n-1$ 次循环时 LSTM 输出的 h_{n-1} 将作为第 n 次循环

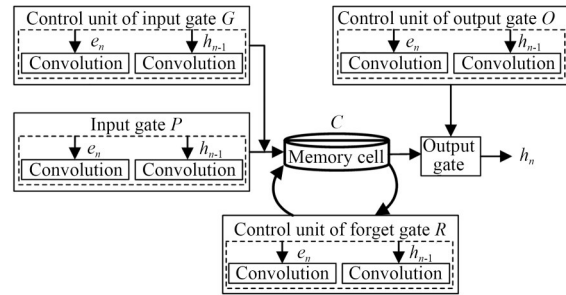


图3 LSTM 循环单元结构示意图

Fig. 3 The architecture of LSTM recurrent unit

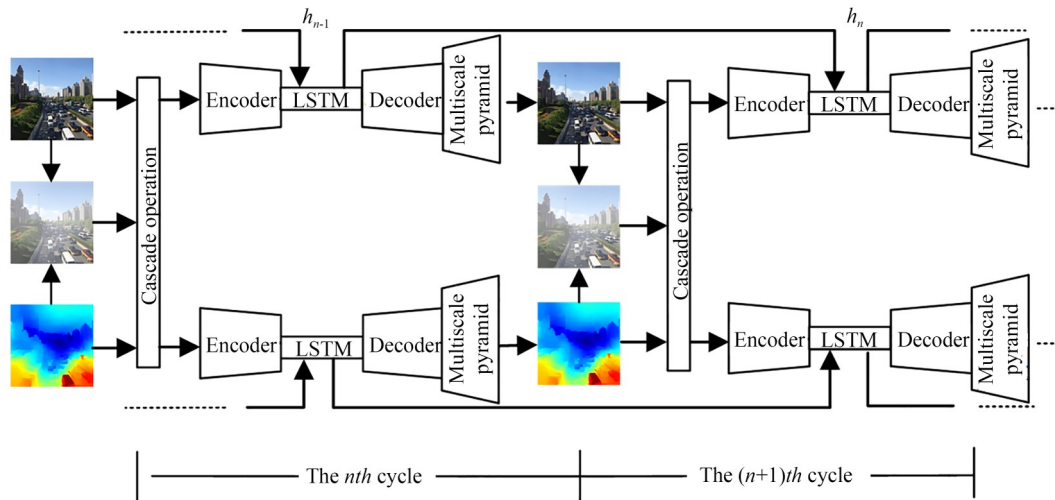


图4 LSTM 单元的工作机制

Fig. 4 The work mechanism of LSTM units

时 LSTM 输入,从而加强了循环时的信息交互,充分利用了编码解码中间层捕获的丰富信息。

4 损失函数

考虑到分解合成循环细化网络在实施过程中,涉及到透射率和清晰图像的分解合成操作,因此损失函数包括两部分:透射率和清晰图像估计的损失函数和合成雾图的损失函数。假设 t_n^i 和 T_t^i , $i=1,2,\dots,m$ 分别为一组 H_t 估计的透射率和真实透射率,其中 t_n^i 为第 n 次循环时 H_t 估计的透射率。故 H_t 对应的损失函数 L_t 表示为:

$$L_t = \frac{1}{m} \sum_{i=0}^m \sum_{n=0}^k \|t_n^i - T_t^i\|_2, \quad (10)$$

其中: k 为分解合成循环细化网络的最大循环次数, $\|\cdot\|_2$ 为 2 范数操作。

假设 J_n^i 和 J_t^i , $i=1,2,\dots,m$ 分别为一组 H_j 估计的清晰图像和真实无雾图,其中 J_n^i 为第 n 次循环时 H_j 估计的清晰图像。 H_j 对应的损失函数为 L_j 可表示为:

$$L_j = \frac{1}{m} \sum_{i=0}^m \sum_{n=0}^k \|J_n^i - J_t^i\|_2. \quad (11)$$

假设 I^i 和 I_n^i , $i=1,2,\dots,m$ 分别为一组输入的初始雾图和合成雾图,则合成操作对应的损失函数 L_h 为:

$$L_h = \frac{1}{m} \sum_{i=0}^m \sum_{n=0}^k \|I_n^i - I^i\|_2, \quad (12)$$

其中, I_n^i 为第 n 次循环时公式(5)合成的雾图,且合成时公式(5)中大气光 A 为训练集中合成初始雾图 I^i 时的大气光。综上,网络的损失函数 L 可表示为:

$$L = L_t + L_j + L_h. \quad (13)$$

5 实验结果与分析

5.1 数据集及实施细节

考虑到本网络的训练集需包含雾图,真实透射率,清晰图像,故利用 RESIDE^[15] 和 data-DCPDN 数据集^[6]来创建本文的训练集及测试集。从 data-DCPDN 选取 4 000 对室内雾图,透射率和清晰图像,这里雾图和透射率图利用公式(1)和公

式(2)合成,且合成参数设置 $A \in \{0.5, 1.0\}$, $\beta \in \{0.4, 1.6\}$ 同文献[6]中参数设置。进一步从 RESIDE 中选择 4000 对不同雾浓度的室外图像对,利用公式(1)和公式(2)合成雾图和透射率图时,合成参数 $A \in \{0.8, 0.85, 0.9, 1.0\}$, $\beta \in \{0.04, 0.06, 0.08, 0.1, 0.12, 0.16, 0.2\}$ 取值同文献[15]。故本文的训练集共包含 8000 对室内室外图像。同理,从 RESIDE^[15] 和 data-DCPDN^[6] 额外选取 400 张室外图像对和 400 张室内图像对,组成包含 800 对图像的测试集 Test O。最后,选取包含不同雾浓度的 500 张室内图像及 500 张室外图像的公共测试集 SOTS 来进一步测试算法性能。

算法在 NVIDIA RTX 2080 Ti GPU 的 PC 机上,通过搭建 Pytorch 深度学习的网络框架实现。网络最大循环次数 $n=3$ 。初始 J_0 设为输入雾图 I ,初始 t_0 设为初值为 0.5 的透射率图。优化算法选用改进的梯度下降法 Adaptive Moment Estimation (Adam) 算法来更新网络模型的参数,其更新的操作如下所示:

$$m_k = \beta_1 m_{k-1} + (1 - \beta_1) g_k, v_k = \beta_2 v_{k-1} + (1 - \beta_2) g_k^2, \quad (14)$$

$$\hat{m}_k = \frac{m_k}{1 - \beta_1^k}, \hat{v}_k = \frac{v_k}{1 - \beta_2^k}, \quad (15)$$

$$\theta_{k+1} = \theta_k - \frac{\eta}{\sqrt{\hat{v}_k} + \epsilon} \hat{m}_k, \quad (16)$$

其中: k 为时间步, g_k 为时间步为 k 时的梯度, m_k 和 v_k 分别为 k 时梯度的一阶矩(梯度均值)和二阶矩(方差), m_{k-1} 和 v_{k-1} 分别为 $k-1$ 时梯度的一阶矩和二阶矩估计, β_1 和 β_2 分别为一阶矩和二阶矩的指数衰减率, θ_k 和 θ_{k+1} 分别为时间步为 k 和 $k+1$ 时的参数, η 为学习率, ϵ 为维持数值稳定性而添加的常数, \hat{m}_k 和 \hat{v}_k 分别为 m_k 和 v_k 的偏差修正。

从公式(14)至公式(16)可见,利用 Adam 来更新网络权重时,首先利用公式(14)对梯度 g_k 和梯度平方 g_k^2 进行滑动平均,使得 m_k 和 v_k 的每次更新都与历史值相关。随后,利用公式(15)对 m_k 和 v_k 进行偏差修正。最后,Adam 算法利用学习率 η 及修正的 \hat{m}_k 和 \hat{v}_k 对模型中的参数 θ_k 进行更新,获取 θ_{k+1} 。同其他去雾网络^[6-7,10],本文也选用 Adam 算法的默认参数 $\beta_1=0.9$, $\beta_2=0.999$, $\epsilon=10^{-8}$ 来设置实施优化。

5.2 模型结构及参数分析

为了选取最优的网络循环参数 n , 我们分别设置 $n=1, 2, 3, 4, 5$ 。其中 $n=1$ 时, 网络无循环, 此时清晰图像估计分支 H_i 获得的结果即为最终结果。不同参数设置下的模型在 SOTS 测试集上测得的量化结果如表 1 所示。可见随着 n 值的增加, 模型的性能逐渐提高, 但当 $n \geq 3$ 时, 模型的性能逐减稳定。为平衡模型的去雾精度及计算成本, 本文设置网络参数 $n=3$ 。在此基础上, 进一步验证分解合成结构及多尺度金字塔模块的有效性。首先, 我们从模型中移除透射率估计分支 H_i , 仅留下清晰图像估计分支 H_j , 故网络的分解合成结构去除, 第 n 次循环时公式 (4) 中 H_i 的输入更新为 J_{n-1} , 对应的变异模型为 w/oH_i 。随后, 我们从初始模型的 H_i 和 H_j 中移除多尺度金字塔模块, 使得公式 (8) 的输出 d_n 直接进入映射层 H_r , 对应的变异模型为 w/op 。 w/oH_i 和 w/op 在 SOTS 测试集上测得的量化结果如表 1 所示, 可见 w/oH_i 和 w/op 的 SSIM 值和 PSNR 值均低于初始的网络模型 ($n=3$), 证明分解合成结构及多尺度金字塔模块能帮助网络性能提升。

表 1 不同参数设置及网络结构的 SSIM 和 PSNR 值

Tab. 1 Different parameters setting and network architecture in terms of SSIM and PSNR

	$n=1$	$n=2$	$n=3$	$n=4$	$n=5$	w/oH_i	w/op
PSNR	29.98	30.55	31.22	31.23	31.24	29.78	30.59
SSIM	0.960	0.968	0.976	0.976	0.976	0.958	0.974

5.3 透射率结果对比

综上所述, 在分解合成循环细化网络中, 透射率估计分支与清晰图像估计分支相互辅助和相互约束, 共同生成高精度的透射率图和清晰图像。为验证透射率估计分支的有效性, 选取 DCP^[2], BCCR^[4], WAP^[5], DCPDN^[6] 算法的透射率估计结果, 与本算法透射率估计结果相对比。不同算法在测试集 Test O 和 SOTS 的平均 SSIM 值如表 2 所示, 从中可见本文算法在所有数据集上均具有最高的 SSIM 值, 透射率估计的准确度较高。

5.4 合成图像去雾结果对比

为验证算法有效性, 本小节选取 DADN^[9], DCPDN^[6], GCAN^[8], DNPAB^[10], RDPN^[7] 算法与

表 2 不同算法的透射率 SSIM 值

Tab. 2 Transmission map by different algorithms in terms of SSIM

	DCP ^[2]	BCCR ^[4]	WAP ^[5]	DCPDN ^[6]	Ours
Test O	0.866	0.841	0.886	0.961	0.972
SOTS	0.844	0.830	0.867	0.956	0.973

所提算法的去雾结果进行对比。从 Test O 中选取的 3 幅室内和室外雾图, 各算法的视觉对比结果如图 5 所示。图 5(b)~5(f) 为对比算法的去雾结果, 图 5(g) 为本文算法结果, 图 5(h) 为真实清晰图像。为了更好地观察去雾效果, 图 5 第三行及第五行分别为图 5 第二行及第四行对应图片的局部放大图。从中可见, GCAN 算法, RDPN 算法和 DNPAB 算法虽能去除雾气, 但去雾结果仍有明显的颜色偏移。如第一行图 5(d) 的窗帘颜色过白, 图 5(e) 的窗帘呈现蓝绿色, 图 5(f) 的窗帘存在明显的黑影。此外, 第五行的图 5(d) 和图 5(f) 存在颜色过暗或过亮的问题。DCPDN 算法结果则存在色彩对比度过大的问题, 如图 5(c) 第一行的窗帘顶部为粉红色, 图 5(c) 第二行和第四行的天空出现了失真的亮白色。DADN 算法结果存在明显的雾残余, 如图 5(b) 的第一行和第三行的柜子和人群处的残余雾。相比而言, 本文算法能彻底除雾, 其去雾结果 (如图 5(g)) 与真实结果 (如图 5(h)) 最接近, 视觉效果最好。图 5 下方标出的 PSNR/SSIM 值以及表 3 列出的各算法在 Test O 及 SOTS 上的平均量化结果表明, 本文算法在所有数据集上均具有最高的 PSNR 和 SSIM 值。以 SOTS 数据集上测得的 PSNR 为例, 本文算法较次优的 DADN 算法至少提高了 12%。

5.5 真实图像去雾结果对比

真实图像的去雾结果如图 6 所示。为了更好的观察细节及色调信息, 第二行和第四行分别展示了第一行, 第三行图像中的局部细节。从中可见 DADN^[9], GCAN^[8], DNPAB^[10] 和 RDPN^[7] 的去雾结果均存在不同程度的雾残余, 如图 6(b)、6(d)、6(e) 和图 6(f) 中第二行的树林因雾残余而导致绿色树林的鲜艳度不高, 此外第四行的楼房墙壁处也有明显的雾气。DCPDN 算法^[6] 结果存在对比度大, 局部区域颜色偏亮的问题, 如图 6(c) 第一行天空颜色明显失真。本算法结果 (见图 6(g)) 清晰度和颜色保真度最高。




图 5 合成图去雾结果对比 (PSNR/SSIM 值标于图像下方, 最优结果加黑)

Fig. 5 The comparison of dehazing results on synthetic images (The PSNR/SSIM values are marked under each image with best results in bold)

表 3 不同算法的去雾结果

Tab. 3 Dehazing results by different algorithms

		DADN ^[9]	DCPDN ^[6]	GCAN ^[8]	DNPAB ^[10]	RDPN ^[7]	Ours
Test O	PSNR	25.04	28.67	24.10	28.81	28.94	30.23
	SSIM	0.9307	0.9428	0.9296	0.9610	0.9749	0.9759
SOTS	PSNR	27.76	17.89	26.28	27.36	23.24	31.22
	SSIM	0.9300	0.8312	0.9446	0.9490	0.9285	0.9761

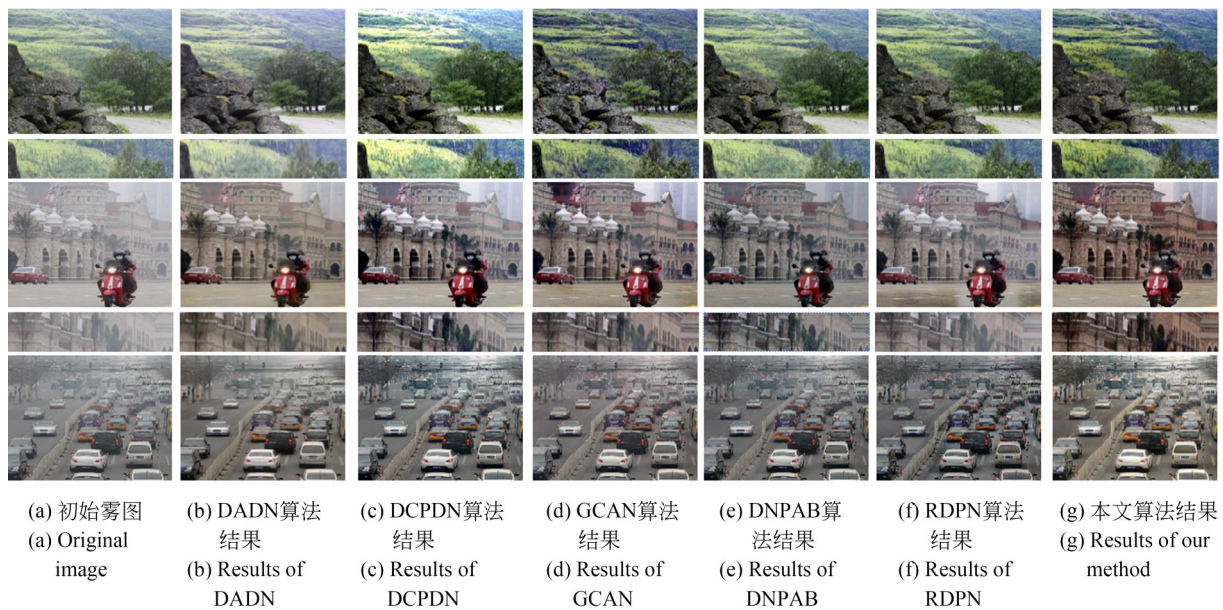


图 6 真实图去雾结果对比

Fig. 6 The comparison of dehazing results on synthetic images

为进一步验证本算法处理真实雾图的有效性,采用无参考的图像质量评估指标量化结果^[16],如图像对比度(CG)、视觉对比度(VCM)、信息熵(ENT)。CG体现了图像的色彩程度,VCM体现了图像的可视度,ENT体现了去雾图

像所包含的信息量。上述三个指标值越高,表明算法的去雾效果越好。表4为^[6-7]提供的30张富有挑战性的真实雾图去雾量化结果。由此可见,本文算法在三个指标上均具有较高的值,清晰度和对比度优于已有的算法。

表4 不同算法的去雾结果

Tab. 4 Dehazing results by different algorithms

	DADN ^[9]	DCPDN ^[6]	GCAN ^[8]	DNPAB ^[10]	RDPN ^[7]	Ours
CG	0.289	0.347	0.296	0.274	0.254	0.412
VCM	46.195	55.196	49.680	47.988	44.526	60.114
ENT	15.015	16.024	15.896	15.672	14.896	16.515

6 运行时间

由于本文所提的分解合成循环细化网络包含分解、合成、循环细化操作,因此算法的运行时间值得关注。本节比较本文算法与DCP^[2],DADN^[9],DCPDN^[6],GCAN^[8],DNPAB^[10]算法的平均运行时间。值得一提的是,DCP算法是传统去雾算法,算法运行平台为Matlab,其余算法为基于神经网络的去雾算法,算法运行平台为Pytorch。传统算法DCP可直接运行代码来实施去雾,而基于神经网络的去雾算法,如DADN,DCPDN,GCAN,DNPAB算法,需预先训练获得

去雾模型后,再进一步进行运行时间的对比。不同算法的单张图像平均运行时间如表5所示。从中可见,本算法的运行时间位于第二,明显优于DADN,DCPDN,DCPDN和DCP算法的运行时间。GCAN因采用单个编码解码网络及门限融合机制实施去雾,网络结构较轻,算法效率较高,运行时间最短。相比之下,本文算法采用两个金字塔多尺度编码解码网络分别估计透射率和清晰图像,较GCAN算法的运行时间仅相差0.026 s,但算法的精度值,如PSNR,较GCAN提高了近19%。故算法能更好地平衡运行时间和精度。

表5 不同算法的单张图像平均运行时间

Tab. 5 Average running time of different methods processing single image

Methods	DADN ^[9]	DCPDN ^[6]	GCAN ^[8]	DNPAB ^[10]	DCP ^[2]	Ours
Time/s	0.167	0.056	0.009	0.048	1.426	0.037

7 结 论

为充分挖掘去雾先验,探索透射率与清晰图像间的约束关系,提高去雾算法的精度,提出了嵌入物理成像模型的分解合成循环细化网络。此网络共包含两个结构相同的并行循环分支:透射率估计分支及清晰图像估计分支。前者估计透射率,后者估计清晰图像。每次循环时,两分支预测的透射率及清晰图像将共同作为网络的

输入,因此透射率估计分支能在包含深度信息的清晰图像引导下,估计和优化透射率;而清晰图像估计分支能在包含雾浓度信息的透射率引导下,估计和优化清晰图。此外,每次循环时两分支估计的结果,将通过大气散射物理成像模型合成的雾图并输入到网络中,以确保透射率估计分支和清晰图像估计分支的预测结果满足大气散射物理成像模型的约束关系。值得一提的是,为了提高各分支的预测精度,采用嵌入LSTM循环

单元的多尺度金字塔编码解码网络作为分支的框架,它不但能利用 LSTM 捕捉每次循环时与任务相关的丰富信息用于下次循环,还能利用多尺度金字塔模块挖掘上下文特征用于透射率估计和图像去雾。在合成图及真实图上的测试表明,

本文所提的嵌入物理成像模型的双向协助网络,能高效估计透射率和清晰图像,且去雾精度较已有去雾算法至少提高了 12%,单张雾图的平均处理时间仅为 0.037 s,可用于图像去雾的工程实践中。

参考文献:

- [1] 韩昊男,钱锋,吕建威,等.改进暗通道先验的航空图像去雾[J].光学精密工程,2020,28(6):1387-1394.
HAN H N, QIAN F, LÜ J W, *et al.* Aerial image dehazing using improved dark channel prior [J]. *Opt. Precision Eng.*, 2020, 28(6): 1387-1394. (in Chinese)
- [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.
- [3] FATTAL R. Dehazing using color-lines[J]. *ACM Transactions on Graphics*, 2014, 34(1): 1-14.
- [4] MENG G F, WANG Y, DUAN J Y, *et al.* Efficient image dehazing with boundary constraint and contextual regularization [C]. 2013 *IEEE International Conference on Computer Vision. December 1-8, 2013, Sydney, NSW, Australia. IEEE*, 2013: 617-624.
- [5] YOON I, JEONG S, JEONG J, *et al.* Wave-length-adaptive dehazing using histogram merging-based classification for UAV images [J]. *Sensors (Basel)*, 2015, 15(3): 6633-6651.
- [6] ZHANG H, PATEL V M. Densely connected pyramid dehazing network[C]. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition. June 18-23, 2018, Salt Lake City, UT, USA. IEEE*, 2018: 3194-3203.
- [7] YIN, WANG, YANG. A novel residual dense pyramid network for image dehazing [J]. *Entropy*, 2019, 21(11): 1123.
- [8] CHEN D D, HE M M, FAN Q N, *et al.* Gated context aggregation network for image dehazing and deraining [C]. 2019 *IEEE Winter Conference on Applications of Computer Vision (WACV). January 7-11, 2019, Waikoloa, HI, USA. IEEE*, 2019: 1375-1383.
- [9] SHAO Y J, LI L, REN W Q, *et al.* Domain adaptation for image dehazing [C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 13-19, 2020, Seattle, WA, USA. IEEE*, 2020: 2805-2814.
- [10] YIN S B, WANG Y B, YANG Y H. A novel image-dehazing network with a parallel attention block [J]. *Pattern Recognition*, 2020, 102: 107255.
- [11] 周自维,王朝阳,徐亮.基于融合门网络的图像理解算法设计与应用[J].光学精密工程,2021,29(4):906-915.
ZHOU Z W, WANG CH Y, XU L. Design and application of image captioning algorithm based on fusion gate neural network [J]. *Opt. Precision Eng.*, 2021, 29(4): 906-915. (in Chinese)
- [12] SANG H W, ZHOU Q H, ZHAO Y. PCANet: Pyramid convolutional attention network for semantic segmentation [J]. *Image and Vision Computing*, 2020, 103: 103997.
- [13] 徐胜军,欧阳朴衍,郭学源,等.多尺度特征融合空洞卷积 ResNet 遥感图像建筑物分割[J].光学精密工程,2020,28(7):1588-1599.
XU SH J, OUYANG P Y, GUO X Y, *et al.* Building segmentation in remote sensing image based on multiscale-feature fusion dilated convolution resnet [J]. *Opt. Precision Eng.*, 2020, 28(7): 1588-1599. (in Chinese)
- [14] 鞠默然,罗海波,刘广琦,等.采用空间注意力机制的红外弱小目标检测网络[J].光学精密工程,2021,29(4):843-853.
JU M R, LUO H B, LIU G Q, *et al.* Infrared dim and small target detection network based on spatial attention mechanism [J]. *Opt. Precision Eng.*, 2021, 29(4): 843-853. (in Chinese)
- [15] 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.
- [16] 姚婷婷,梁越,柳晓鸣,等.基于雾线先验的时空关联约束视频去雾算法[J].电子与信息学报,

2020, 42(11): 2796-2804.

YAO T T, LIANG Y, LIU X M, *et al.* Video dehazing algorithm via haze-line prior with spatio-

temporal correlation constraint[J]. *Journal of Electronics & Information Technology*, 2020, 42(11): 2796-2804. (in Chinese)

作者简介:



冯燕茹(1985—),女,山西长治人,硕士,讲师。2011年于太原理工大学获得硕士学位。主要从事模式识别,网络工程 and 信息安全方面的研究。E-mail: yrfeng2020@163.com

通讯作者:



王一斌(1982—),男,博士后,2015年于西北工业大学获得博士学位,主要从事模式识别和图像处理方面的研究。E-mail: yibei.wong@gmail.com