

引用格式: WANG Yibin, ZHENG Jia, YIN Shibai. Image Dehazing Method Using Channel Attention Network and Fuzzy Partition Entropy with Graph Cut[J]. Acta Photonica Sinica, 2021, 50(3):0310002

王一斌, 郑佳, 尹诗白. 通道注意网络和模糊划分熵图割的图像去雾[J]. 光子学报, 2021, 50(3):0310002

## 通道注意网络和模糊划分熵图割的图像去雾

王一斌<sup>1</sup>, 郑佳<sup>1</sup>, 尹诗白<sup>2</sup>

(1 四川师范大学 工学院, 成都 610068)

(2 西南财经大学 经济信息工程学院, 成都 611130)

**摘 要:** 针对雾图成像时变化的场景光及去雾过程中不同雾相关信息在处理上的差异性, 提出了通道注意网络和模糊划分熵图割的单幅图像去雾算法。以考虑变化场景光的大气散射物理成像模型为基础, 首先使用通道注意的编码解码网络来估计透射率, 并在编码器最后及解码器起始处添加通道注意模块, 以便为编码器提取的不同雾相关特征图分配不同的权重, 准确地计算透射率; 然后利用所提出的模糊划分熵图割算法将透射率划分为不同场景光覆盖下的近景、中景、远景, 此分割策略将考虑空间相关性的图割算法与模糊划分熵的阈值分割算法相结合, 解决了单一阈值分割算法产生的区域误分问题; 最后估计场景光和大气光, 得到去雾图像。实验结果表明, 算法在合成雾图及真实雾图上均有较好的去雾效果。与已有的去雾算法相比, 本文算法在峰值信噪比及结构相似性上均有提升, 单张图像的平均处理时间为 3.9 s。

**关键词:** 图像去雾; 卷积神经网络; 通道注意机制; 图割; 变化场景光

中图分类号: 520.6040

文献标识码: A

doi: 10.3788/gzxb20215003.0310002

### Image Dehazing Method Using Channel Attention Network and Fuzzy Partition Entropy with Graph Cut

WANG Yibin<sup>1</sup>, ZHENG Jia<sup>1</sup>, YIN Shibai<sup>2</sup>

(1 School of Engineering, Sichuan Normal University, Chengdu 610068, China)

(2 Department of Economic Information Engineering, Southwest University of Finance and Economics, Chengdu 611130, China)

**Abstract:** Aiming at the varying scene light in imaging process and difference between the haze relevant features in image dehazing, a channel attention network and fuzzy partition entropy with graph cut for single image dehazing based on the improved atmospheric scattering model with varying scene light is proposed. Firstly, the encoder-decoder network with channel attention mechanism is utilized to estimate transmission map. Then the proposed channel attention module is applied in the end of encoder and the beginning of the decoder for assigning different weights to different haze relevant feature maps and obtaining accurate transmission map. Then, the fuzzy partition entropy combined with graph cut is used to segment the transmission map into distant scene, middle scene and close scene covered with varying scene light. This scheme combines spatial correlation and fuzzy partition entropy, solving misclassified problem introduced by the threshold-based segmentation. Finally, a clear image is obtained with the predicted transmission map, estimated scene light and atmospheric light. Extensive experiments demonstrate that this method achieves promising effective on synthetic images and real images. Comparing with exiting methods, our

基金项目: 国家自然科学基金青年科学基金(No.61502396), 四川省教育厅一般项目(No.18ZB0484)

第一作者(通讯作者): 王一斌(1982—), 男, 讲师, 博士, 主要研究方向为图像处理、模式识别、数据挖掘。Email: yibeen.wong@gmail.com

收稿日期: 2020-08-31; 录用日期: 2020-12-14

<http://www.photon.ac.cn>

method improves dehazing results in both peak signal to noise ratio and structural similarity. The average running time for handling single hazy image is 3.9 s.

**Key words:** Image dehazing; Convolutional neural network; Channel attention mechanism; Graph cut; Varying scene light

**OCIS Codes:** 100.2000; 100.3020; 100.4996

## 0 引言

雾霾环境下,受大气中悬浮水滴和气溶胶散射作用的影响,捕获的图像出现对比度低、色调偏移等质量退化问题,影响户外视觉系统功能的发挥<sup>[1]</sup>。因此,雾天图像清晰化处理对户外视觉系统具有重要意义<sup>[2]</sup>。

目前存在的去雾方法多以大气散射物理成像模型为基础,通过计算模型中的透射率和大气光来得到无雾图像。考虑到场景中不同目标所处的空间位置不同,受周围环境光的影响也不同,JU M等<sup>[3]</sup>提出了考虑变化场景光的改进大气散射成像模型(Improved Atmospheric Scattering Model, IASM)。本文以此改进模型为基础,求解透射率,场景光及清晰图像。

透射率的估计算法可分基于先验的算法和基于深度学习的算法。基于先验的算法利用图像统计特性来估计透射率,如HE K等<sup>[4]</sup>提出的暗通道先验(Dark Channel Prior, DCP),它表明图像局部区域内总有一个颜色通道的某个像素灰度值趋于零。BERMAN D等<sup>[5]</sup>提出的非局部先验,它利用场景中颜色相近的目标其灰度值在RGB空间中呈一维线状分布的规律来估计透射率。然而,基于观察统计得到的先验知识无法适用于所有的雾天场景,算法鲁棒性较差,透射率值存在误差。

不同于基于先验的透射率估计算法,深度学习能从众多雾图样本数据中学习雾相关的信息,建立原始图像与透射率之间的映射关系,具有较好的鲁棒性。如CAI B等<sup>[6]</sup>提出的DehazeNet,它利用神经网络从雾图中直接估计透射率,并同时依据远景区域透射率值偏低的特性来获取大气光,从而得到去雾图像。ZHANG H等<sup>[7]</sup>提出的(Densely Connected Pyramid Dehazing Network, DCPDN)联合学习大气光、透射率和去雾结果。然而网络估计透射率的过程中没有考虑不同信息的特征图在处理上的差异,限制了网络的性能。为此,本文将通道注意机制引入到透射率估计网络中,使网络关注重要的通道特征图,高效准确地估计透射率。

另一方面,为获得变化的场景光,基于图像分割的去雾算法被广泛采用。JU M等<sup>[3]</sup>依据雾图中雾气的浓度信息将图像划分为不同的区域,并根据各区域入射光灰度值来计算场景光,各区域的最大对比度来计算透射率,最后利用全变分引导模型来消除透射率图中的边界效应,得出清晰图像。GAO Y等<sup>[8]</sup>提出了多区域融合策略(Multi-Region Fusion Method, MRFM),它将雾图分割为天空区域及非天空区域,并利用各向异性扩散模型来融合并优化天空区域及非天空区域的透射率值,获得去雾图像。YOON I等<sup>[9]</sup>提出了(Wavelength-Adaptive Dehazing, WAD)算法,它将雾气浓度与光的波长和物体的颜色关联起来,按场景中物体的颜色将雾图划分为远景、中景、近景,由此得到各个区域的透射率和场景光。但上述方法在实施图像分割获得场景光的过程中,没有考虑场景的空间相关性,易将白色的前景目标误分为远景的浓雾区域。为此,本文提出了模糊划分熵图割算法来划分场景光区域,将考虑空间相关性的图割算法融入到模糊划分熵中,解决了不同区域因像素值相近而产生的误分问题。

本文算法以考虑变化场景光的改进大气散射成像模型为基础,利用通道注意的神经网络预测透射率,使用模糊划分熵图割算法划分不同场景光区域,以计算场景光及大气光,得到去雾图像。算法有以下优点:1)提出了通道注意机制的透射率估计网络,它将通道注意机制引入到编码解码网络中,使其关注重要的通道特征图,提高透射率估计的准确度。2)充分考虑场景的空间相关性,利用模糊划分熵图割算法将透射率图划分为近景、中景和远景三个区域,以此获取准确的大气光和场景光。

## 1 大气散射物理成像模型

常用大气散射物理成像模型可表示为

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

式中,  $(x, y)$  为像素的坐标位置索引;  $I$  为雾天图像;  $t$  为透射率;  $J$  为清晰图像;  $A$  为大气光。

由式(1)可知雾图成像均来自大气光,然而实际成像过程中,受景物的遮挡,不同物体的反射率和吸收率差异的影响,成像时实际上是受大气光及场景光的共同影响,成像过程仅考虑大气光并不准确。因此,

$$I(x, y) = R(i)\rho(x, y)t(x, y) + A[1 - t(x, y)] \quad (2)$$

式中, $J(x, y)$ 表示为 $R(i)\rho(x, y)$ , $R(i)$ 为图像中第 $i$ 处的场景光强,它受场景的位置信息影响, $\rho(x, y)$ 为清晰图像在坐标 $(x, y)$ 处的像素值。这里 $(x, y) \in E(i)$ , $E(i)$ 为场景 $i$ 中所有像素集合。 $t(x, y)$ 表示成像点 $(x, y)$ 在大气中的透射率,其值在透射过程中受大气散射系数和景深影响,以指数量级衰减,可表示为

$$t(x, y) = e^{-\beta d(x, y)} \quad (3)$$

式中, $d(x, y)$ 为成像点 $(x, y)$ 的成像距离, $\beta$ 为散射系数。从式(2)可知,准确估计 $R, A, t$ 即可得 $\rho$ 。

## 2 通道注意的透射率估计网络

基于通道注意的透射率估计网络结构如图1,包括浅层特征提取、编码器、解码器和映射层。




图1 基于通道注意机制的深度学习模型  
Fig.1 Channel attention deep network model

浅层特征提取:提取如边缘、纹理、轮廓等浅层特征图有利于后续深层特征图的挖掘。利用核大小为 $3 \times 3$ ,步长为1的卷积层(Convolution, Conv)、批处理层(Normalization, BN)、激活层(Rectified Linear Unit, ReLU)以及池化层(Pooling)构成浅层特征提取模块

$$F_s = H_{SF}(I) \quad (4)$$

式中, $I$ 为输入的雾图; $H_{SF}$ 为浅层特征提取算子的函数; $F_s$ 为 $H_{SF}$ 的输出,同时也是编码器输入。

编码器:使用卷积残差模块(Convolutional Residual Block, CRB)及通道注意模块(Channel attention Block, CAB)进行构建。其中,CRB是在浅层特征提取模块的基础上引入了残差连接(如图1)。此外,在编码器最后添加CAB,为CRB提取的特征图分配不同的通道特征图权重,使网络更关注与透射率估计任务相关的重要信息,如浓雾信息。故编码器的函数可定义为

$$F_d = H_{EN}(F_s) = H_{CAB} \left\{ H_{CRB,d} \left\{ \dots [H_{CRB,1}(F_s)] \dots \right\} \right\} \quad (5)$$

式中, $H_{EN}(\cdot)$ 表示编码器函数; $H_{CRB,d}$ 表示第 $d$ 个卷积残差模块函数; $H_{CAB}$ 表示通道注意模块函数; $F_d$ 是编码器的输出。

解码器:为了重构透射率,使用反卷积模块(Deconvolution Block, DEB)对 $F_d$ 进行对称的上采样操作。如图1所示,在解码器的第一步仍使用CAB为 $F_d$ 分配合适的权重,随后使用结合了(Deconvolution, Deconv), (Batch Normalization, BN) 和(Rectified Linear Unit, ReLU)以及残差连接的DEB模块逐步实施上采样操作

$$F_b = H_{DE}(F_d) = H_{DEB,b} \left\{ \dots H_{DEB,2} \left\{ H_{DEB,1} [H_{CAB}(F_d)] \right\} \right\} \quad (6)$$

式中, $F_b$ 为解码器的输出; $H_{DE}(\cdot)$ 为解码器函数; $H_{DEB,b}$ 代表第 $b$ 个反卷积模块函数。

映射层:在网络的最后使用一个卷积层将特征图映射为透射率图,映射层的函数可表示为

$$t = H_{MAP}(F_b) \quad (7)$$

式中, $H_{MAP}(\cdot)$ 为映射层函数(Mapping), $t$ 为映射层输出,也为网络估计的透射率图。

受文献[7]中组合损失函数启发,基于通道注意的透射率估计网络使用损失函数 $L$ 搜索模型的最优参数

$$L = L_2 + \lambda L_g + \beta L_f \quad (8)$$

式中, $\lambda$ 和 $\beta$ 分别是 $L_g, L_f$ 的权重系数,默认设置为1。 $L_2$ 的表达式为

$$L_2 = \frac{1}{N} \sum_{i=1}^N \|H_{\text{CAN}}(I^i) - t^i\|_2 \quad (9)$$

式中,  $\{I^i, t^i\}_{i=1}^N$  代表  $N$  对雾图和对应的真实透射率。  $H_{\text{CAN}}$  表示通道注意网络的函数,  $H_{\text{CAN}}(I^i)$  为输入第  $i$  张雾图时通道注意网络估计的透射率。  $L_g$  的表达式为

$$L_g = \frac{1}{N} \left\{ \sum_{i=1}^N \|G_v[H_{\text{CAN}}(I^i)] - G_v(t^i)\|_2 + \sum_{i=1}^N \|G_h[H_{\text{CAN}}(I^i)] - G_h(t^i)\|_2 \right\} \quad (10)$$

式中,  $G_v$  和  $G_h$  分别为计算图像垂直方向和水平方向梯度的操作算子。

$L_f$  的表达式为

$$L_f = \frac{1}{N} \left\{ \sum_{i=1}^N \|F_{v1}[H_{\text{CAN}}(I^i)] - F_{v1}(t^i)\|_2 + \sum_{i=1}^N \|F_{v2}[H_{\text{CAN}}(I^i)] - F_{v2}(t^i)\|_2 \right\} \quad (11)$$

式中,  $F_{v1}$  和  $F_{v2}$  为 VGG-16 网络中的第一层和第二层的函数。

在神经网络中引入通道注意机制, 能给当前任务相关的重要特征图分配较高权重, 从而达到将有限的信息处理资源合理分配给重要特征图的目的。 本文在编码器和解码器的中间添加通道注意模块(Channel Attention Block, CAB), 以提高网络的性能, 模块结构如图 2(a), 包括稠密连接、通道注意和残差学习。

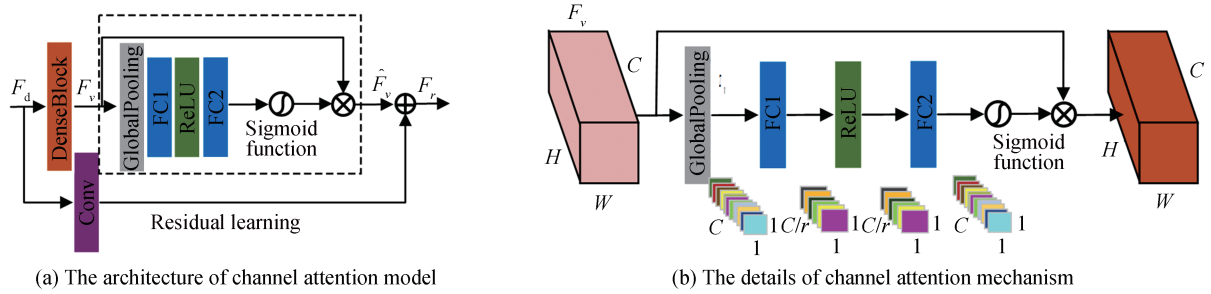


图2 通道注意模块

Fig2 The channel attention model

稠密连接: 选用文献[7]中的稠密模块 Dense Block 作为稠密连接层, 以解码器的 CAB 为例, 其输出为

$$F_v = H_{\text{DB}}(F_d) \quad (12)$$

式中,  $H_{\text{DB}}$  为稠密连接层对应的函数,  $F_v$  为稠密连接层最后的输出。

假设稠密连接最后一个卷积层, 包含  $C$  个滤波核  $[t_1, \dots, t_c, \dots, t_C]$ , 它将输入此层的特征图  $F_d' \in \mathbb{R}^{H' \times W' \times C'}$  ( $H'$ 、 $W'$  和  $C'$  分别表示  $F_d'$  特征图的长、宽和通道数) 映射成  $F_v \in \mathbb{R}^{H \times W \times C}$ ,  $F_v = [F_v^1, L, F_v^c, L, F_v^C]$  ( $H$ 、 $W$  和  $C$  分别表示  $F_v$  特征图的长、宽和通道数), 则上述过程可以表示为

$$F_v^c = t_c * F_d' = \sum_{s=1}^{c'} t_c^s * F_d'^s \quad (13)$$

式中,  $*$  为卷积操作,  $t_c = [t_c^1, t_c^2, \dots, t_c^{c'}]$ ,  $F_d' = [F_d'^1, F_d'^2, L, F_d'^{c'}]$ ,  $t_c^s * F_d'^s$  代表  $t_c^s$  滤波核作用于  $F_d'$  在第  $s$  通道下的特征图  $F_d'^s$ 。由式(13)可见,  $F_v$  为所有通道的卷积操作结果之和。因此不同通道下特征图的相互关系未能充分挖掘, 作用于局部感受野的卷积操作使得特征图所含信息具有局部性。为了探索不同通道下特征图之间相互关系, 增强网络对重要特征图(如包含浓雾信息)的敏感性, 采用通道注意层来解决此问题。

通道注意: 采用全局池化层(Global Pooling, GP)将特征图  $F_v \in \mathbb{R}^{H \times W \times C}$  的全局空间信息压缩到一个通道描述器里。如图 2(b), 利用 GP 将  $F_v$  转化为  $1 \times 1 \times C$  的通道全局统计量  $z_v$  为

$$z_v^c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F_v^c(x, y) \quad (14)$$

式中,  $F_v^c(x, y)$  为特征  $F_v$  在  $c$  通道上坐标为  $(x, y)$  的值。  $z_v^c$  为  $F_v$  经过 GP 后  $z_v$  在第  $c$  通道上的统计量。

从压缩操作中获取集成信息  $z_v$  后, 选用 Sigmoid 函数来探索不同通道特征图的依赖关系是

$$\alpha = \sigma\{FC_2 \delta[FC_1(z_v)]\} \quad (15)$$

式中,  $\sigma(\cdot)$  表示 Sigmoid 函数,  $\delta(\cdot)$  表示 ReLU 激活函数。为了简化网络参数, 并学习不同通道的非线性交互

关系,采用 $FC_1$ 和 $FC_2$ 两个全连接层(Full Connection, FC)函数的门限机制来实现,其对应的参数分别为 $W_1 \in \mathbb{R}^{C \times C/r}$ 和 $W_2 \in \mathbb{R}^{C/r \times C}$ , $r$ 为特征通道数缩减率。最后通过Sigmoid函数得到输出 $\alpha$ 。

利用 $\alpha$ 对 $F_v$ 进行逐通道加权

$$\hat{F}_v^c = F_v^c \cdot \alpha^c \quad (16)$$

式中, $F_v^c$ 和 $\alpha^c$ 分别为 $c$ 通道下的特征 $F_v$ 及 $c$ 通道下的通道统计量 $\alpha$ , $\hat{F}_v^c$ 为 $F_v^c$ 重新分配权重后的特征图。由此可见,通道注意机制可看成为一个通道层面上的自注意函数,它在不局限于卷积滤波器所响应的局部感受野域的情况下,自动探索各通道特征图的相互关系,为不同通道特征图分配不同的权重。

残差学习:考虑到 $F_d$ 经过稠密连接及通道注意后得到的特征 $\hat{F}_v$ 的通道数与 $F_d$ 并不相同,为此,利用卷积层(Convolution, Conv)调整 $F_d$ 的通道数,使残差学习能顺利进行

$$F_r = \hat{F}_v + H_{CO}(F_d) \quad (17)$$

式中, $H_{CO}$ 为卷积函数, $F_r$ 为CAB的输出。

### 3 场景光估计及图像去雾

如式(2)所示,不同区域的场景光因从对应的场景区域 $E$ 中估计获取,因此准确划分场景光区域尤为重要。采用模糊划分熵图割算法将透射率划分为近景、中景和远景,该方法在阈值分割算法中融入考虑空间相关性的图割算法,不但避免了区域误分,还便于准确估计场景光和大气光。

采用模糊3-划分熵算法来搜索划分近景 $E_b$ 、中景 $E_m$ 和远景 $E_d$ 像素集合的最佳阈值<sup>[10,11]</sup>。即使用S函数及其反函数 $Z = 1 - S$ 定义集合<sup>[11]</sup> $E_m$ 、 $E_b$ 、 $E_d$ 的隶属度函数 $M_d$ 、 $M_m$ 、 $M_b$ ,则各集合的模糊划分概率为

$$\begin{cases} P_b = \sum_{k=0}^{255} h(k) M_b \\ P_m = \sum_{k=0}^{255} h(k) M_m \\ P_d = \sum_{k=0}^{255} h(k) M_d \end{cases} \quad (18)$$

式中, $h(\cdot)$ 为透射率直方图,统计透射率中任一灰度 $k$ 出现概率。 $P_b$ 、 $P_m$ 、 $P_d$ 为 $E_b$ 、 $E_m$ 和 $E_d$ 的集合划分概率。

透射率图的模糊3-划分熵模型如式(19)所示,利用基于递推策略的穷举法<sup>[11]</sup>可快速搜索使模糊熵最大时刻划分 $E_d$ 、 $E_m$ 、 $E_b$ 集合的阈值

$$H = -P_d \log(P_d) - P_m \log(P_m) - P_b \log(P_b) \quad (19)$$

直接使用最大模糊熵确定的阈值来划分,并未考虑像素的空间相关性,易发生因不同区域的透射率值相近而产生的区域误分。为此,将考虑空间相关性的图割算法<sup>[11]</sup>融入到模糊划分熵中,提出模糊划分熵图割算法。图割的能量函数 $E$ 表示为

$$E = \lambda D(l_p) + Q(l_p, l_q) \quad (20)$$

式中, $p$ 和 $q$ 为相邻像素; $l_p$ 和 $l_q$ 为标号,其值可为远景“d”,中景“m”,近景“b”三种; $D(l_p)$ 为数据项,表示透射率中像素被分为标记 $l_p$ 的代价; $Q(l_p, l_q)$ 为平滑项,表示 $p$ 和 $q$ 标记为 $l_p, l_q$ 的代价; $\lambda$ 是数据项与平滑项的平衡因子,默认为1。对于 $D(l_p)$ ,利用式(19)最大值时的集合划分概率来设计

$$\begin{cases} D(l_p = "b") = -\log(P_b) \\ D(l_p = "m") = -\log(P_m) \\ D(l_p = "d") = -\log(P_d) \end{cases} \quad (21)$$

平滑项则参考文献[12],定义为

$$Q(l_p, l_q) = \exp\left(-\frac{(k_p - k_q)^2}{2\phi^2}\right) \times \frac{1}{\text{dist}(p, q)} \quad (22)$$

式中, $k_p$ 及 $k_q$ 为相邻像素 $p$ 和 $q$ 的灰度级; $\phi$ 为相邻像素间的方差; $\text{dist}(p, q)$ 为像素 $p$ 和 $q$ 的欧氏距离。当图割模型构建好后,使用 $\alpha - \beta$ 交换算法<sup>[12]</sup>来求解图割模型,从而获得 $E_d$ 、 $E_m$ 、 $E_b$ 集合的最优划分。

从已划分的 $E_d$ 、 $E_m$ 、 $E_b$ 像素集合中选取在初始雾图中亮度值最高的前1%像素,并将其亮度均值作为各

集合区域的场景光,得到初略估计的场景光 $R$ 。但上述方法估计的场景光 $R$ 存在明显的边界效应,与真实情况不符,为了逼近真实结果,采用正则优化算法细化场景光

$$R' = \operatorname{argmin} \left\{ \|R - R'\|_2^2 + \theta_1 \|\nabla(R') - \nabla(G)\|_2^2 \right\} \quad (23)$$

式中, $\theta_1$ 为正则化参数,默认设置为0.4; $G$ 为雾图的亮度分量; $\nabla$ 为梯度算子。式(23)的第一项能确保优化的场景光 $R'$ 逼近模糊划分熵图割的分割结果,而第二项约束 $R'$ 的边缘特征,使其与 $G$ 保持一致。采用文献[13]的迭代寻优策略可获得优化后的场景光 $R'$ 。

已知大气光强 $A$ ,场景光 $R'$ ,透射率 $t$ ,可通过式(2)求得清晰图像 $\rho$ 。为了避免因 $t$ 太小而导致分母无穷大,设置 $t$ 的下限 $t_0$ ,清晰图像可由式(24)计算得到

$$\rho = \frac{I - A[1 - \max(t, t_0)]}{R' \max(t, t_0)} \quad (24)$$

## 4 实验与结果分析

### 4.1 实验数据及网络参数

从文献[14]提供的训练集中,随机选取2 000对室内合成雾图,清晰图像及透射率图,其中合成雾图的大气光 $A \in \{0.5, 1\}$ ,散射系数 $\beta \in \{0.4, 1.6\}$ 。从RESIDE中随机选取2 000对室外合成雾图,清晰图像及透射率,合成雾图的大气光 $A \in \{0.8, 0.85, 0.9\}$ ,散射系数 $\beta \in \{0.06, 0.08, 0.1, 0.12, 0.16, 0.2\}$ 。因此,训练集共包含4 000对图像。同理,创建包含200张室内图像对和200张室外图像对的测试集。

通道注意的透射率估计网络包含3个CRB,2个CAB和3个DEB。每个CAB中的稠密连接层均选用6层卷积的稠密模块Dense Block<sup>[7]</sup>实现。网络中所有卷积层的核大小均为 $3 \times 3$ ,步长均为1,反卷积层的核大小为 $3 \times 3$ ,步长均为2。训练过程选用 $\beta_1 = 0.5, \beta_2 = 0.999$ 及 $\epsilon = 10^{-8}$ 的ADMA优化算法。初始学习率及批量大小分别设为0.002和2。模型在NVIDIA RTX 2080Ti GPU的Pytorch框架下训练800 000次迭代。

### 4.2 透射率估计网络有效性测试

本小节对透射率估计网络的有效性进行测试。首先验证编码器中CRB个数及解码器中DEB个数对网络性能的影响。设计了4个变化的模型C\_D\_2, C\_D\_3, C\_D\_4, C\_D\_5,他们分别代表编码器和解码器中各包含2个CRB和2个DEB,3个CRB和3个DEB,4个CRB和4个DEB,5个CRB和5个DEB。在测试集上获取的量化结果如表1所示,从中可见随着CRB和DEB数量的增加,透射率的SSIM值逐渐提高,但当CRB和DEB数量均为4和5时,SSIM提升幅度较小。为平衡精度和计算效率,本网络选择C\_D\_3的设置。在此基础上,改变网络中CAB的个数来验证CAB的有效性。变化模型CAB\_0, CAB\_1, CAB\_2, CAB\_3分别表示在透射率估计网络中编码器的最后一层和解码器的起始层插入0个,1个,2个,3个CAB模块。从表1可见, CAB\_2的SSIM值最高,较去CAB\_0提高了约0.02。随着CAB模块数的增加,透射率的SSIM值下降。可见,过多的CAB模块并不会提高网络的性能。故网络选择CAB\_2的设置。

表1 不同透射率估计网络的SSIM值

Table 1 SSIM results obtained by different variant models of transmission map predicted network

Model	C_D_2	C_D_3	C_D_4	C_D_5	CAB_0	CAB_1	CAB_2	CAB_3
Transmission	0.958 6	0.969 7	0.969 8	0.969 8	0.950 3	0.960 1	0.969 7	0.950 3

### 4.3 合成图像测试

在合成数据集上,选取MRFM算法<sup>[8]</sup>,Dehazenet算法<sup>[7]</sup>,WAD算法<sup>[9]</sup>,IASM算法<sup>[3]</sup>与本文算法结果相对比,并用结构相似性(Structural Similarity, SSIM)和峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)对各算法结果进行量化评估。如表2,本文算法不但预测透射率的平均SSIM值优于其余算法,去雾结果的平均PSNR值和SSIM值也优于比较的算法。Dehazenet算法虽较MRFM算法,IASM算法,WAD算法有更好的鲁棒性,但在预测透射率时,同等处理所有特征图,限制了网络性能,透射率预测精度低于本文结果。在预测去雾结果时,Dehazenet算法仅考虑了均匀分布的大气光,未考虑变化场景光,去雾结果不理想。WAD算法及IASM算法采用基于阈值的分割策略获取变化的场景光,但未考虑空间的相关性,易将前景中白色目标

误分为远景的浓雾区域。本文算法能准确估计场景光,去雾结果具有最高的 PSNR 及 SSIM。此外,各算法的视觉去雾结果如图 3。MFRM 算法的去雾结果(图 3(b))颜色过暗,有明显的颜色偏移问题。WAD 算法结果(图 3(d))的亮度较高,天空出现失真的亮白色。Dehazenet 算法结果(图 3(c))较好地保存了原始图 3(a)中的色调,但图 3(c)的广场区域仍存在雾残余。IASM 算法结果(图 3(e))的天空区域则存在颜色不均匀的色块。本文算法不但能彻底去雾,还能最大限度地保持图像色彩,结果图 3(f)与真实图 3(g)最接近。

表 2 不同算法透射率的 SSIM 值及去雾结果的 PSNR 值及 SSIM 值对比

Table 2 SSIM results for the transmission maps and SSIM/PSNR results for clear images by different methods

		MRFM	Dehazenet	WAD	IASM	Ours
Transmission	SSIM	0.886 7	0.911 4	0.893 4	0.896 3	0.969 7
	SSIM	0.835 6	0.862 4	0.901 2	0.861 7	0.950 6
Dehazed image	PSNR	18.76	22.39	21.41	19.52	28.52



图 3 合成图像的去雾结果

Fig.3 Dehazing results of synthetic images

#### 4.4 真实图像测试

在真实图像上测试算法性能,选用了包含 45 张室外图像的 O-Haze 数据集,包含 35 张室内图像的 I-Haze 数据集。其中,O-Haze 和 I-Haze 数据集是在室内及室外场景下利用专业烟雾机生成雾气获得,故数据集中的每张雾图均有对应的无雾参考图。可选用能见度指数(Visibility Index, VI)和真实性指数(Realness Index, RI)测试去雾算法的去雾效果。能见度指数利用去雾的图像及其无雾参考图的视觉相似性来评估去雾效果,而真实性指数则利用去雾图像与其无雾参考图在预先定义特征空间的相似性来评估去雾效果。VI 和 RI 的值越高,则去雾效果越好,值越低去雾效果越差。表 3 列出了各算法在 O-Haze 和 I-Haze 数据集上的 VI 和 RI 值,本文算法具有最高的 VI 和 RI 值,去雾效果最优。图 4 展示了视觉效果。MFRM 算法及 IASM 算法的去雾结果(图 4(b)及图 4(e))颜色偏暗。WAD 算法的去雾结果(图 4(d))对比度过强。Dehazenet 算法结果图 4(c)的远景区域有明显的雾残余。本算法结果图 4(f)能较好去除雾气,并有效保存图像原有的色

表 3 不同算法在 O-Haze 和 I-Haze 数据集上的平均 VI 及 RI 结果对比

Table 3 VI and RI results obtained by different methods on O-Haze and I-Haze datasets

		MRFM	Dehazenet	WAD	IASM	Ours
O-Haze	VI	0.811 0	0.842 1	0.866 5	0.834 1	0.902 1
	RI	0.900 4	0.912 7	0.922 5	0.910 6	0.941 7
I-Haze	VI	0.876 6	0.892 5	0.906 4	0.887 6	0.938 8
	RI	0.902 7	0.914 5	0.911 7	0.910 1	0.946 0




图 4 真实图像的去雾结果

Fig.4 Dehazing result of real image

彩,视觉效果最佳。

#### 4.5 运行时间

本文算法的运行时间由通道注意网络的透射率估计时间和场景光及大气光的计算时间组成。通道注意网络的编码器和解码器各含四个模块,网络层数少,框架简单,估计单张雾图的透射率仅需 0.2 s。另一方面在估计大气光及场景光时,采用了文献[11]的递推策略搜索最大模糊熵,单张图像的平均运行时间为 0.2 s,随后的  $\alpha - \beta$  交换算法求解图割模型耗时仅 3 s。最后利用梯度下降法求解正则优化模型耗时 0.5 s。如表 4,本文算法运行时间共为 3.9 s,优于 IASM 算法和 WAD 算法的运行时间,虽较 Dehazenet 算法及 MRFM 算法的运行时间更长,但从表 1~3 可知,本文算法的去雾效果明显优于 WAD 算法及 IASM 算法。

表 4 不同算法的运行时间对比  
Table 4 Comparison of running times obtained by different methods

	MRFM	Dehazenet	WAD	IASM	Ours
Time/s	2.5	1.78	4.3	4.5	3.9

## 5 结论

本文提出了基于通道注意网络和模糊熵图割的去雾算法。在利用编码解码网络估计透射率时,在编码器和解码器中间加入通道注意模块,为包含不同信息的特征图分配不同的权重,使网络对重要特征图(如包含浓雾信息的特征图)更敏感,为后续网络层提供更有效的信息。在估计场景光及大气光时,采用模糊熵图割算法将透射率划分为近景、中景和远景,并从各区域提取对应的场景光和大气光。该策略将考虑空间相关性的图割算法融入到模糊划分熵算法中,确保了透射率值相近的区域不会被误分。实验结果表明,引入通道注意机制的透射率估计网络能准确地估计透射率,在 400 张测试图像上估计透射率的平均结构相似性为 0.969 7,且进一步利用模糊划分熵图割算法获取大气光及场景光后,实施图像去雾的结果也优于已有去雾算法。由此可见,准确预测透射率并充分考虑变化场景光,能提高图像去雾的精度。然而,算法在估计变化场景光时使用的模糊划分熵图割和场景光迭代寻优算法降低了去雾的效率,单张图像的平均去雾时间为 3.9 s。后续将进一步优化场景光求解过程,提高效率,使其能应用到智能驾驶等工程实践中。

#### 参考文献

- [1] ZHANG S, HE F, REN W, et al. Joint learning of image detail and transmission map for single image dehazing[J]. The Visual Computer, 2020, 36(2): 305-316.
- [2] REN W, PAN J, ZHANG H, et al. Single image dehazing via multi-scale convolutional neural networks with holistic edges[J]. International Journal of Computer Vision, 2020, 128(1): 240-259.
- [3] JU M, ZHANG D, WANG X. Single image dehazing via an improved atmospheric scattering model[J]. The Visual Computer, 2017, 33(12): 1613-1625.
- [4] HE K, SUN J, TANG X. Single image haze removal using dark channel prior[J]. IEEE transactions on pattern analysis and machine intelligence, 2010, 33(12): 2341-2353.
- [5] BERMAN D, AVIDAN S. Non-local image dehazing[C]. Proceedings of the IEEE conference on computer vision and pattern recognition, 2016:1674-1682.
- [6] CAI B, XU X, 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.
- [7] ZHANG H, PATEL V M. Densely connected pyramid dehazing network[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 3194-3203.
- [8] GAO Y, LI Q, LI J. Single image dehazing via a dual-fusion method[J]. Image and Vision Computing, 2020, 94: 103868.
- [9] YOON I, JEONG S, JEONG J, et al. Wavelength-adaptive dehazing using histogram merging-based classification for UAV images[J]. Sensor, 2015, 15(3): 6633-6651.
- [10] YIN Shibai, WANG Yibin, DENG Zhen. Infrared image segmentation based on graph cut of fast recursive fuzzy 2-partition entropy[J]. Optics and Precision Engineering, 2016, 24(3): 668-680.
- [11] 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.
- [12] 尹诗白, 王一斌, 邓箴. 基于快速递推模糊 2-划分熵图割的红外图像分割[J]. 光学精密工程, 2016, 24(3): 668-680.
- [13] VEKSLER O. Efficient graph cut optimization for full CRFs with quantized edges[J]. IEEE transactions on pattern analysis and machine intelligence, 2019, 42(4): 1005-1012.
- [14] NAN D, BI D, MA S, et al. Single image dehazing method based on scene depth constraint[J]. Acta Electronica Sinica, 2015, 43(3): 500-504.
- [15] LI B, REN W, FU D, et al. Benchmarking single-image dehazing and beyond[J]. IEEE Transactions on Image Processing, 2018, 28(1): 492-505.

Foundation item: National Natural Science Foundation of China Youth Science Foundation (No.61502396), General project of Sichuan Education Department (No.18zb0484)