

低秩与字典表达分解的浓雾霾场景图像去雾算法

黄文君, 李杰, 齐春
(西安交通大学电子与信息学部, 710049, 西安)

摘要: 针对现有图像去雾算法对浓雾霾场景图像去雾效果不理想的问题,提出了一种低秩与字典表达分解的浓雾霾场景图像去雾算法。首先,根据大气散射物理模型与浓雾霾场景图像中“雾”的全局低秩特性,将退化图像看作低秩“雾”图与相对低秩无雾清晰图像的叠加;其次,将“雾”图表示为字典矩阵与表达矩阵的乘积,从而通过低秩与字典表达分解模型分解出“雾”图;再次,利用双三次插值将分解得到的局部“雾”图推广到全局;最后通过减去“雾”图恢复出无雾的清晰图像。实验结果表明:与现有主流图像去雾算法相比,该算法对浓雾霾场景图像的去雾效果更优,对 194 幅真实浓雾霾场景图像去雾后,图像平均可见边缘比到达了 21.315,平均可见边缘质量因子达到了 4.540,图像细节信息得到了较好的恢复。

关键词: 图像去雾;大气散射物理模型;低秩分解;稀疏表示;双三次插值
中图分类号: TP391 **文献标志码:** A

DOI: 10.7652/xjtuxb202004015 **文章编号:** 0253-987X(2020)04-0118-08



A Defogging Algorithm for Dense Fog Images via Low-Rank and Dictionary Expression Decomposition

HUANG Wenjun, LI Jie, QI Chun
(Faculty of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: A defogging algorithm for dense fog images based on low-rank and dictionary expression decomposition is proposed to improve the problem that the existing image defogging algorithm is not ideal for image defogging of haze scene. Based on the atmospheric scattering physical model and the global low-rank characteristics of “fog” in the haze scene image, the degraded image is assumed as a composition of a low-rank “fog” image and an original clear image. Then the “fog” image is expressed as a product of a dictionary matrix and a sparse matrix, so that the “fog” image can be decomposed through the low-rank and dictionary expression decomposition model. The decomposed local “fog” image is extended to a global level by combining the bicubic interpolation. The clear image is finally recovered by subtracting the “fog” image. Experimental results and comparisons with existing mainstream image defogging algorithms on 194 real dense fog images show that the proposed algorithm has better image defogging performance for dense fog scenes. The ratio of average visible edges of images reaches 21.315, the quality factor of average visible edges reaches 4.540, and the details of the images are recovered well.

Keywords: image defogging; atmospheric scattering physical model; low-rank decomposition; sparse representation; bicubic interpolation

雾、霾等天气环境下拍摄的图像对比度较低,图像细节模糊不清,使得主观感受和视觉效果变差,对后续的图像处理,如分析、理解、检测、跟踪、识别等造成困难^[1-2]。因此,图像去雾研究具有十分重要的意义和广阔的应用前景。利用图像去雾算法对降质图像进行处理,可以恢复“雾”图中被覆盖的细节纹理与偏移的色彩,从而提高图像质量。

近年来,图像去雾技术已经成为计算光学、图像处理等领域的研究热点,引起了众多学者的广泛讨论与研究。图像去雾方法主要可以分为基于图像增强的方法和基于图像复原的方法。基于图像增强的方法针对图像对比度较低、纹理信息不明显的特征,通过对图像的视觉效果进行增强以达到去雾的效果,并不考虑雾天图像质量退化的过程与原理。比较常用的图像增强算法包括直方图均衡、对数变换、幂律变换、锐化、小波变换、Retinex等^[3-6],虽然去雾后的图像得到增强,对比度得到改善,但去雾后的恢复图像会出现前景信息去雾过度,背景信息模糊不清的情况,会丢失一些图像的细节信息。基于图像复原的去雾算法是利用雾天图像降质的大气散射物理模型进行反演推算得到无雾清晰图像,能够最大程度的保留图像细节信息并得到自然真实的恢复图像。常用的基于图像复原的去雾方法通常分为以下4种:基于深度信息已知的图像复原方法、基于偏微分方程的图像复原方法、基于先验知识的图像复原方法以及基于学习的图像复原方法。基于先验知识和基于学习的图像复原算法是目前的主流去雾方向。例如 Tan 等通过对大量清晰图像和雾天图像的观察发现雾天图像的对比度一定小于对应的清晰图像,通过这个先验条件提出了最大化图像局部对比度的去雾算法^[7]。该方法去雾后能够得到较高的图像对比度,但恢复后的图像存在对比度过高导致的颜色失真,物体边缘在景深变化时有光晕现象。Fattal 等通过数理统计方法得到图像去雾的先验知识,该先验知识为物体表面的光照与图像局部的透射率是不相关的^[8]。该方法通过在马尔科夫条件随机场的框架下实现图像去雾恢复,但是该方法也存在一定局限性,在浓雾场景下图像可能会丢失大量的细节信息,不能取得较好的去雾效果。He 等在2009年提出了暗通道先验去雾算法,通过对大量户外无雾图像的观察发现暗通道先验知识,暗通道先验知识为在清晰的无雾图像中除去天空区域和非高亮区域,至少在 R、G、B(3个通道中)的其中一个通道的像素值趋近于零^[9],通过结合先验知识和大气

散射物理模型反演得到较为优越的去雾效果。基于深度神经网络的图像去雾方法如 Ren 等提出的基于多尺度特征提取的卷积神经网络去雾算法^[10]及 Cai 等提出的一种端到端的卷积神经网络去雾算法^[11],均能取得较好的去雾效果,但是由于需要大量的训练数据进行训练,人工成本较高。然而,在浓雾场景下,目前还没有较为理想的去雾方法,现有方法的去雾效果还有提升的空间。

为了解决浓雾场景下的图像去雾问题,恢复出较多的图像细节和自然的视觉效果,对浓雾图像的降质特点进行分析,发现浓雾场景下拍摄的图像亮度较高,细节丢失严重,远处白茫茫的一片,“雾”图具有低秩特性。对此,本文提出了一种基于低秩与字典表达分解的图像去雾算法,通过低秩与字典表达分解得出低秩的“雾”图,结合双三次插值^[12]将局部的“雾”推广到全局,然后减去“雾”图恢复出无雾清晰图像。实验结果证明,本文算法可以在浓雾场景下取得较好的去雾效果。

1 算法基础

1.1 大气散射物理模型

在1976年,McCartney 基于米氏散射理论第一次提出了大气散射物理模型^[13],大气散射物理模型由两部分组成,主要是大气光成像模型和入射光衰减模型。在入射光衰减模型^[14]中,用于成像的目标反射光被大气散射吸收衰减导致图像亮度和对比度下降,使得图像边缘细节和物体纹理劣化。在大气光成像模型^[14]中,天空光、太阳光会被大气中的粒子散射传输到相机,可以把它理解为“雾”的组成部分,它的作用好比在物体上加盖了一层面纱,使得图像模糊。对于一幅清晰的图像,入射光衰减模型在成像模型中占有很大的比例,但是随着雾浓度的增加,入射光衰减模型的比例将减小,大气光成像模型的比例将增大,因此图像的能见度会下降。可以认为大气光成像模型是造成雾天图像降质的主要原因。Nayar 和 Narasimhan 认为散射系数与可见光的波长无关,该理论假设环境中的悬浮粒子的密度与属性等是均匀的,是同质的大气介质,并且只发生单散射^[15]。经过 Nayar 和 Narasimhan 与何恺明等人的优化,大气散射物理模型为

$$I(x) = J(x)t(x) + A_{\infty}(1 - t(x)) \quad (1)$$

式中: $I(x)$ 是待去雾的雾天图像; $J(x)$ 是需要恢复的清晰图像; $t(x)$ 是透射率; A_{∞} 是对应于无穷远距离的大气光值。

1.2 矩阵低秩分解理论

现实中很多数据都具有很高的维度,为了降低数据的维度和规模,研究者认为现实中的数据,一般都具有低秩的特性。如果 $\mathbf{X}$ 是一个 m 行 n 列的数值矩阵, $\text{rank}(\mathbf{X})$ 是 $\mathbf{X}$ 的秩,假如 $\text{rank}(\mathbf{X})$ 远小于 m 和 n ,则称 $\mathbf{X}$ 是低秩矩阵。低秩矩阵每行或每列都可以用其它的行或列线性表出,而实际的大规模矩阵,往往可以看成是一个低秩矩阵与一个稀疏矩阵相加的结果,矩阵的低秩稀疏分解模型如图 1 所示。




图 1 矩阵低秩稀疏分解图

矩阵的低秩分解公式为

$$\mathbf{D} = \mathbf{L} + \mathbf{S} \tag{2}$$

式中: $\mathbf{D}$ 是已知的原始矩阵; $\mathbf{L}$ 与 $\mathbf{S}$ 都是未知的变量矩阵,需要通过矩阵分解求得低秩矩阵和稀疏矩阵。为了解决上述问题,文献[16]提出一种经典的鲁棒主成分分析方法(RPCA),可以很好地解决低秩稀疏分解问题。RPCA 问题可以抽象为对于观测矩阵 $\mathbf{D}$,且 $\mathbf{D} = \mathbf{L} + \mathbf{S}$,其中 $\mathbf{L}$ 、 $\mathbf{S}$ 均是未知的,但已知 $\mathbf{L}$ 为低秩矩阵, $\mathbf{S}$ 为稀疏矩阵,要求通过矩阵分解恢复出 $\mathbf{L}$,因此目标表达式如下

$$\left. \begin{aligned} \min_{\mathbf{L}, \mathbf{S}} \text{rank}(\mathbf{L}) + \lambda \|\mathbf{S}\|_0 \\ \text{s. t. } \mathbf{D} = \mathbf{L} + \mathbf{S} \end{aligned} \right\} \tag{3}$$

该问题是一个 NP hard 问题,目前没有有效的解决方式,需要对上式进行松弛处理,使其变为一个凸问题^[16]。松弛后的目标表达式如下

$$\left. \begin{aligned} \min_{\mathbf{L}, \mathbf{S}} \|\mathbf{L}\|_* + \lambda \|\mathbf{S}\|_1 \\ \text{s. t. } \mathbf{D} = \mathbf{L} + \mathbf{S} \end{aligned} \right\} \tag{4}$$

式中: $\|\cdot\|_*$ 为矩阵的核范数,即为矩阵奇异值的和值,用于约束矩阵的低秩特性; $\|\cdot\|_1$ 为矩阵的 l_1

范数,即矩阵中各元素绝对值的和值,用于约束矩阵的稀疏特性。利用增广拉格朗日乘子算法进行优化求解可以分解得出低秩部分矩阵和稀疏部分矩阵。本文在矩阵低秩分解模型上提出改进使得矩阵分解模型适用于图像去雾问题。

2 低秩与字典表达算法基础


2.1 低秩与字典表达分解算法

在浓雾场景下,原始有雾图像可以分为“雾”图像和无雾图像的叠加,其中“雾”图像是具有低秩特性的。同样可以参照大气散射物理模型进行分析,“雾”图像主要对应于物理模型中的大气光成像模型部分即大气光散射造成的杂散光,由于透射率具有局部一致性即透射率在较小的范围内具有恒定的值,并且在雾较大时普遍具有较小的值,因此大气光散射形成的杂散光项具有低秩特性,在视觉上形成了“雾”。无雾图像对应于物理模型中的入射光衰减模型部分,由于现实生活中的清晰图像或者其经过一定变换后的清晰图像是具有相对低秩特性的,并且透过率的局部一致性与其在浓雾场景下整体较低的值区间使得入射光衰减模型部分相对低秩。因此可以通过表达出“雾”图来恢复无雾图像。浓雾场景下低秩与字典表达分解示意图如图 2 所示。

为了能够利用鲁棒主成分分析(RPCA)低秩稀疏分解模型进行去雾,本文对原始模型进行了修改,将低秩部分用字典学习进行表示,主要用于描述图像中的浓“雾”部分,而将 RPCA 中的稀疏部分看成无雾场景下的清晰图像矩阵,将其特性改为相对低秩,所构建模型如下

$$\mathbf{X} = \mathbf{AZ} + \mathbf{E} \tag{5}$$

式中: $\mathbf{X} \in \mathbf{R}^{m \times n}$ 为雾天场景下得到的原始有雾图像矩阵; $\mathbf{A} \in \mathbf{R}^{m \times r}$ 为字典矩阵; $\mathbf{Z} \in \mathbf{R}^{r \times n}$ 为表达矩阵,通过字典学习将“浓雾”表示出来; $\mathbf{AZ}$ 为分解出的具有低秩特性的矩阵; $\mathbf{E}$ 为无雾场景下的清晰图像矩阵,



(a)浓雾图像 (b)低秩“雾”图 (c)无雾图像

图 2 浓雾场景下低秩与字典表达分解示意图

具有相对低秩的特性。令具有低秩特性的浓“雾”项 $AZ=L$, $L=[l_1, l_2, \dots, l_n]$, 其中的每一列向量即每一个原子可以用字典 $A=[a_1, a_2, \dots, a_n]$ 中原子的线性组合来表示, 用于表示的表达矩阵为 $Z=[z_1, z_2, \dots, z_n]$, 其中 z_i 是 l_i 的表达系数, 通常要求字典是过完备的^[17]。本文直接利用原始数据矩阵 X 作为字典矩阵 A , 这是实际计算中常用的一种方式。从图2可以看出, 在浓雾场景下图片被白茫茫的“雾”所覆盖, 存在大范围的亮白区域, 因此可以通过表达出“浓雾”, 分解出无雾清晰图像 E 。 XZ 是用来表示“浓雾”的矩阵项, “浓雾”具有低秩特性, 所以“浓雾”用字典表示时, 表达矩阵 Z 是十分稀疏的, 但稀疏表达仅仅提取图像的局部结构, 而不能提取全局结构, 因此对局部结构变化敏感, 容易在表达“浓雾”时受到局部非“雾”结构的干扰, 所以在对表达矩阵 Z 约束稀疏以达到 XZ 项低秩的同时, 约束 Z 低秩以捕获全局结构, 实现对于“浓雾”项估计的稳健性。因为在日常生活中的清晰自然图像总是由一些相似的局部结构组成, 因此对 E 进行相对低秩约束, 改造后的目标表达式如下

$$\left. \begin{aligned} & \arg \min_{Z, E} \text{rank}(Z) + \lambda \|Z\|_0 + \beta \text{rank}(E) \\ & \text{s. t. } X = XZ + E \end{aligned} \right\} \quad (6)$$

式中: $\text{rank}(\cdot)$ 和 $\|\cdot\|_0$ 分别为求取矩阵的秩和矩阵的 l_0 范数, 通过最小化矩阵的秩来约束矩阵 Z 、 E 的低秩特性, 最小化矩阵的 l_0 范数来约束矩阵 Z 的稀疏特性; λ 和 β 是平衡参数用来平衡调节矩阵稀疏性与低秩性的程度。因为求解 l_0 是一个 NP Hard 问题, 所以对式(6)进行松弛处理, 将式(6)转化为凸优化问题, 转化后的结果如下

$$\left. \begin{aligned} & \arg \min_{Z, E} \|Z\|_* + \lambda \|Z\|_1 + \beta \|E\|_* \\ & \text{s. t. } X = XZ + E \end{aligned} \right\} \quad (7)$$

首先在式(7)中引入一个辅助变量 W , 以使目标函数可分离, 得到如下目标函数

$$\left. \begin{aligned} & \arg \min_{Z, W, E} \|Z\|_* + \lambda \|Z\|_1 + \beta \|E\|_* \\ & \text{s. t. } X = XZ + E, Z = W \end{aligned} \right\} \quad (8)$$

该目标表达式的增广拉格朗日^[18]形式为

$$\begin{aligned} L = & \|Z\|_* + \lambda \|W\|_1 + \beta \|E\|_* + \\ & \langle Y_1, X - XZ - E \rangle + \langle Y_2, Z - W \rangle + \\ & \frac{\mu}{2} (\|X - XZ - E\|_F^2 + \|Z - W\|_F^2) \end{aligned} \quad (9)$$

本文根据 ADMM 算法^[19]求解目标表达式, 其中的未知量为 Z 、 W 、 E 通过交替迭代进行优化求解, 优化求解结果为

$$\left. \begin{aligned} Z_{k+1} = & \arg \min \|Z\|_* + \\ & \langle \nabla zq(Z_k, W_k, E_k, Y_{1,k}, Y_{2,k}, \mu_k), Z - Z_k \rangle + \\ & (\eta_1 \mu_k / 2) \|Z - Z_k\|_F^2 = \Theta((\eta_1 \mu_k)^{-1})(Z_k + \\ & X^T(X - XZ - E_k + Y_{1,k} / \mu_k) - \\ & (Z_k - W_k + Y_{2,k} / \mu_k) / \eta_1) \\ E_{k+1} = & \arg \min \beta \|E\|_* + (\mu_k / 2) \|X - XZ_{k+1} - \\ & E + Y_{1,k} / \mu_k\|_F^2 = \Theta(\eta_1 \mu_k^{-1})(X - XZ_{k+1} + \\ & Y_{1,k} / \mu_k) \\ W_{k+1} = & \arg \min \lambda \|W\|_1 + (\mu_k / 2) \|Z_{k+1} - \\ & W + Y_{2,k} / \mu_k\|_F^2 = S(\lambda \mu_k^{-1})(Z_{k+1} + Y_{2,k} / \mu_k) \end{aligned} \right\} \quad (10)$$

式中: Θ 是奇异值分解算子; S 是收缩算子^[20]。因此, 算法步骤如下。

步骤1 输入: 观察矩阵 $X \in \mathbf{R}^{m \times n}$, 平衡参数 λ, β 。

步骤2 参数初始化: $Z_0 = W_0 = E_0 = Y_{1,0} = Y_{2,0} = 0$, $\mu_0 = 10^{-6}$, $\mu_{\max} = 10^{10}$, $\rho = 1.1$, $\epsilon_1 = 10^{-6}$, $\epsilon_2 = 10^{-2}$, $\eta_1 = \|X\|_2^2, k=0$ 。

步骤3 循环迭代: 当 $\|X - XZ_k - E_k\|_F / \|X\|_F \geq \epsilon_1$ 或 $\mu_k * \max(\sqrt{\eta_1} \|Z_k - Z_{k-1}\|_F, \|W_k - W_{k-1}\|_F, \|E_k - E_{k-1}\|_F) / \|X\|_F \geq \epsilon_2$ 时, 执行以下步骤:

(1)按式(10)交替迭代更新 Z 、 W 、 E ;

(2)更新拉格朗日乘子

$$Y_{1,k+1} = Y_{1,k} + \mu_k (X - XZ_{k+1} - E_{k+1})$$

$$Y_{2,k+1} = Y_{2,k} + \mu_k (X - XZ_{k+1} - E_{k+1})$$

(3)更新参数 $\mu_{k+1} = \min(\mu_{\max}, \rho \mu_k)$;

(4)更新 $k \leftarrow k+1$;

(5)输出 (Z_k, W_k, E_k) 。

通过将优化求解得到的表达矩阵 Z 与字典矩阵 X 相乘可以得到低秩矩阵 XZ 。 XZ 捕获了全局“雾”的特性, 矩阵 E 即为分解出的无雾场景下的清晰图像。


由图2的实验结果可以看出, 本文算法在浓雾场景下能够取得较好的去雾效果, 去雾后的图像能够获得较清晰的细节信息, 但也存在一些局限性, 例如在图2中出现了白色的条纹, 这主要是因为局部结构信息对“雾”的估计造成了干扰, 导致该方法对于参数的调节要求较高。因此, 根据浓雾场景下图像的降质特点, 利用低秩与字典表达分解与双三次插值相结合的方法实现对全局“雾”图的估计以完成浓雾场景下的去雾。

2.2 算法流程

利用低秩与字典表达分解, 对于浓雾图像能够

取得较好的去雾恢复效果,但是仍然存在一些待改进的地方,由于低秩与字典表达分解算法的计算需要捕捉图像的全局特性,由前面的分析可知,在浓雾场景下,全局的图像降质情况与局部的图像降质情况基本一致,因此可以通过将局部的“雾”推广到全局的“雾”。这样既可以加快处理速度也避免了参数调节寻优带来的困难。本节通过使用双三次插值来实现将局部的“雾”推广到全局。

本节将雾图均匀地分为 3×3 共 9 个图像块,对每一个图像块进行低秩与字典表达分解,通过利用矩阵分解得到的表达矩阵 Z 恢复出低秩矩阵 XZ ,对这 9 块低秩图像块分别求取其矩阵的秩,选择出秩最低的低秩矩阵块,将该矩阵块通过双三次插值到整幅图像大小,即可以得到浓雾场景下全局“雾”的特性,从在雾天场景下拍摄的原始雾图中减去覆盖在上面的“雾”,即得到了无雾场景下的清晰图像,揭开了掩盖在清晰图像上的那层“面纱”。结合双三次插值后的效果对比图如图 3 所示。算法流程图如图 4 所示。



(a)未结合插值分解效果图 (b)结合插值分解效果图
图 3 双三次插值效果对比图

实验设置低秩与字典表达分解的参数为 $\lambda=1$, $\beta=1$ 。此处需要说明的是, λ 和 β 是两个权系数,表示两个分量在模型中所起作用的平衡因子, λ 和 β 都




图 4 算法流程图

设为 1,表示低秩与字典表达都按原始状态,两者平等对待。在实验中,浓雾图像按照 R、G、B 3 个通道分别进行处理,去雾后再合成为彩色图像。实验结果如图 5~图 9 所示,为了验证本文所提算法的有效性,通过对浓雾场景下的户外图像进行去雾测试,并分别使用暗通道先验算法^[9]、深度学习 DehazeNet 算法^[11]及非局部雾线算法^[21]进行实验测试,与本文算法的实验结果进行对比。

从图 5~图 9 可以看出:在对浓雾图像的去雾恢复中,本文所提算法的图像对比度有显著提升,可见细节纹理和色彩的恢复,景深场景感知的增强等方面均优于其他算法;图 5 在图像细节信息被严重掩盖的情况下恢复出最多的图像纹理信息,且相较于其他算法色彩信息恢复的更好;图 6 不仅恢复出较多的纹理细节信息,还避免了其他算法中色偏的出现,场景景深感知复原较好;图 7 中的细节信息遮盖严重,本文算法恢复出的图像细节最多,其中房屋,



(a)原图 (b)暗通道先验 (c)DehazeNet (d)非局部雾线 (e)本文算法
图 5 消防员场景浓雾图像去雾效果



(a)原图 (b)暗通道先验 (c)DehazeNet (d)非局部雾线 (e)本文算法
图 6 摩天轮场景浓雾图像去雾效果



图 7 城市街道场景浓雾图像去雾效果



图 8 公园小桥场景浓雾图像去雾效果



图 9 十字路口场景浓雾图像去雾效果

树木纹理恢复的较好;图 8 人物细节恢复细腻,本文所提算法避免了其他经典算法在场景深度出现剧烈变化时会产生光晕的缺陷;图 9 相较于其他算法恢复后图像亮度较低的问题,本文算法得到的结果不仅图像亮度较高,而且色彩恢复真实自然,图像细节信息恢复效果良好。

本文还使用基于客观的图像去雾算法评价标准来量化评估算法的去雾效果。本文的浓雾图像集均为从网络上选取的真实场景下的浓雾图片,其中包括浓雾交通图,浓雾风景图等共 194 张,真实图像更加能够验证本文算法的有效性。主要从新增可见边缘比(e),可见边缘的恢复质量($\bar{r}$)与去雾恢复后图像的过饱和程度(σ)这 3 个方面进行分析^[22]。 e 值越大,新增可见边缘越多, $\bar{r}$ 值越大新增可见边缘质量越高, σ 越小,过饱和程度越小,图像恢复效果越好。基于客观的评价标准进一步验证了本文算法的有效性,实验结果如表 1 所示。

在算法处理时间方面,本文对 3 种典型场景不同分辨率浓雾图像的去雾处理时间进行了对比。

对比实验运行环境为: Intel(R) Core(TM) i7-4790 CPU @3.60 GHz,无 GPU,8 GB 内存, Windows 7_64 bit 操作系统, Matlab R2014a。对比实验结果如表 2 所示。由表 2 可以看出,结合双三次

插值之后算法运行速度得到了很大的提升,图像的分辨率越大,速度提升效果越明显。这主要是因为低秩与字典的表达分解涉及矩阵运算,运算时间和图像的分辨率成正相关,使用分块操作,矩阵计算的运算量减少,运行时间缩短。

表 1 去雾算法基于可见边缘评价标准对比

去雾算法	e	$\bar{r}$	$\sigma/\%$
暗通道先验	14.095	4.021	7.142×10^{-4}
DehazeNet	1.459	1.556	0.000
非局部雾线	8.898	3.521	0.057
本文算法	21.315	4.540	0.415

表 2 本文算法对 3 种典型场景不同分辨率浓雾图像的去雾处理时间对比

图像	分辨率/像素	处理时间/s	
		不分块	3×3 分块
摩天轮	200×300	24.998 0	9.122 0
	405×630	203.443 0	34.616 0
公园小桥	200×300	24.467 0	8.674 0
	598×900	832.800 0	63.233 0
十字路口	200×300	25.988 0	10.010 0
	585×925	816.117 0	65.913 0

为了说明雾图低秩特性,对浓雾、薄雾和城市霾 3 种场景各 50 幅真实图像进行了雾霾图秩的计算。由于图像均为彩色,且分辨率各有不同,为进行比较,分别计算每幅图像 R、G、B 通道的秩,取最大值除以该图像的行、列像素数的最小值,得到归一化后的秩。比较发现:①雾和霾图均表现为低秩;②雾或

霾越浓,图像秩越低。进一步证实了本文所提算法约束条件的适用性和正确性。图 10 为 3 种场景中的 15 幅图,表 3 为图 10 对应的每幅图的秩计算结果对比。图 10a 为浓雾图像,图 10b 为薄雾图像,图 10c 图像中,c1 图的霾较其余图霾更浓,其计算出的秩也相对更低。



图 10 3 种场景选取的部分计算图像

表 3 3 种场景雾图的秩

图像 编号	雾图的秩			水平 像素数	竖直 像素数	归一化 的秩
	R 通道	G 通道	B 通道			
a1	26	25	24	1 126	736	0.035 3
a2	38	38	37	900	600	0.063 3
a3	68	68	68	800	600	0.113 3
a4	57	56	50	1 200	800	0.071 2
a5	22	22	22	700	400	0.055 0
b1	52	52	52	638	448	0.116 1
b2	53	53	53	630	460	0.115 2
b3	135	135	135	1 600	1 200	0.112 5
b4	66	66	66	575	750	0.114 8
b5	69	69	69	800	600	0.115 0
c1	8	7	7	940	608	0.013 2
c2	35	35	35	930	635	0.055 1
c3	40	40	40	512	345	0.115 9
c4	22	22	22	860	585	0.037 6
c5	70	70	70	980	611	0.114 6

3 结 论

(1)本文所提图像去雾算法可实现较为优异的

浓雾图像去雾效果,对于浓雾图像能够恢复出具有较多细节和自然色彩的无雾图像,在基于可见边缘评价方法中可见边缘比可达 21.315,可见边缘质量可达 4.540,图像饱和程度为 0.415%。

(2)本文算法相对于现有的深度学习算法,不需要在大量的浓雾数据集上进行训练学习,因此人工成本较低。

(3)本文算法根据浓雾具有的低秩特性,通过对“雾”进行字典表达,约束表达矩阵既低秩又稀疏,可以实现捕捉全局结构“雾”图的分离。

为使本文提出的算法达到实时性要求,将在后续的研究中改进矩阵计算方法,并使用并行计算提高运算速度。

参考文献:

[1] 禹晶,徐东彬,廖庆敏. 图像去雾技术研究进展 [J]. 中国图象图形学报, 2011, 16(9): 7-22.
YU Jing, XU Dongbin, LIAO Qingmin. Image defogging: a survey [J]. Journal of Image and Graphics, 2011, 16(9): 7-22.
[2] 代书博,徐伟,朴永杰,等. 基于暗原色先验的遥感

- 图像去雾方法[J]. 光学学报, 2017, 37(3): 341-347.
- DAI Shubo, XU Wei, PIAO Yongjie, et al. Remote sensing image defogging based on dark channel prior [J]. Acta Optica Sinica, 2017, 37(3): 341-347.
- [3] 高原原, 胡海苗. 基于多子块协同单尺度 Retinex 的浓雾图像增强 [J]. 北京航空航天大学学报, 2019, 45(5): 101-108.
- GAO Yuanyuan, HU Haimiao. Foggy image enhancement based on multi-block coordinated single-scale Retinex [J]. Journal of Beijing University of Aeronautics and Astronautics, 2019, 45(5): 101-108.
- [4] 王萍, 张春, 罗颖昕. 一种雾天图像低对比度增强的快速算法 [J]. 计算机应用, 2006, 26(1): 152-153.
- WANG Ping, ZHANG Chun, LUO Yingxin. Fast algorithm to enhance contrast of fog-degraded images [J]. Journal of Computer Applications, 2006, 26(1): 152-153.
- [5] 祝培, 朱虹, 钱学明, 等. 一种有雾天气图像景物影像的清晰化方法 [J]. 中国图象图形学报, 2004, 9(1): 124-128.
- ZHU Pei, ZHU Hong, QIAN Xueming, et al. An image clearness method for fog [J]. Journal of Image and Graphics, 2004, 9(1): 124-128.
- [6] 詹翔, 周焰. 一种基于局部方差的雾天图像增强方法 [J]. 计算机应用, 2007, 27(2): 510-512.
- ZHAN Xiang, ZHOU Yan. Algorithm based on local variance to enhance contrast of fog-degraded image [J]. Journal of Computer Applications, 2007, 27(2): 510-512.
- [7] TAN R T. Visibility in bad weather from a single image [C]// 26th IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA; IEEE, 2008: 4587-4593.
- [8] FATTAL R. Single image dehazing [J]. ACM Transactions on Graphics, 2008, 27(3): 72.
- [9] HE K, SUN J, TANG X. Single image haze removal using dark channel prior [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2011, 33(12): 2341-2353.
- [10] REN W, LIU S, ZHANG H, et al. Single image dehazing via multi-scale convolutional neural networks [C]// 14th European Conference on Computer Vision. Berlin, Germany: Springer-Verlag, 2016: 154-169.
- [11] CAI B, XU X. Dehaze net: an end-to-end system for single image haze removal [J]. IEEE Transactions on Image Processing, 2016, 25(11): 5187-5198.
- [12] 张阿珍, 刘政林, 邹雪城, 等. 基于双3次插值算法的图像缩放引擎的设计 [J]. 微电子学与计算机, 2007, 24(1): 49-51.
- ZHANG A'zhen, LIU Zhenglin, ZOU Xuecheng, et al. Design of image scaling engine based bicubic interpolation algorithm [J]. Microelectronics & Computer, 2007, 24(1): 49-51.
- [13] MCCARTNEY E J. Optics of the atmosphere: scattering by molecules and particles [M]. New York, USA: John Wiley & Sons Inc., 1976: 23-32.
- [14] NAYAR S K, NARASIMHAN S G. Vision in bad weather [C]// Proceedings of the 1999 7th IEEE International Conference on Computer Vision. Piscataway, NJ, USA; IEEE, 1999: 820-827.
- [15] NARASIMHAN S G, NAYAR S K. Removing weather effects from monochrome images [C]// Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA; IEEE, 2001: II186-II193.
- [16] PARTRIDGE M, JABRI M. Robust principal component analysis [C]// Proceedings of the 10th IEEE Workshop on Neural Signal Processing. Piscataway, NJ, USA; IEEE, 2000: 289-298.
- [17] ZHUANG L, GAO H, LIN Z, et al. Non-negative low rank and sparse graph for semi-supervised learning [C]// 2012 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA; IEEE, 2012: 2328-2335.
- [18] ROCKAFELLAR R T. Augmented Lagrangians and applications of the proximal point algorithm in convex programming [J]. Mathematics of Operations Research, 1976, 1(2): 97-116.
- [19] BOYD S, PARIKH N, CHU E, et al. Distributed optimization and statistical learning via the alternating direction method of multipliers [J]. Foundations & Trends in Machine Learning, 2011, 3(1): 1-122.
- [20] DAUBECHIES I, DEFRISE M, DE MOL C. An iterative thresholding algorithm for linear inverse problems with a sparsity constraint [J]. Communications on Pure and Applied Mathematics, 2004, 57(11): 1413-1457.
- [21] BERMAN D, TREIBITZ T, AVIDAN S. Non-local image dehazing [C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA; IEEE, 2016: 1674-1682.
- [22] HAUTIERE N, TAREL J P, AUBERT D, et al. Blind contrast enhancement assessment by gradient ratioing at visible edges [J]. Image Analysis & Stereology, 2008, 27(2): 87-95.

(编辑 刘杨)