

# 基于梯度引导偏振度估算的图像去雾

徐万春<sup>1</sup>, 张焱<sup>1\*</sup>, 张景华<sup>2</sup>, 凌峰<sup>1</sup>, 李顺<sup>3</sup>

(1. 国防科技大学电子科学学院 ATR 全国重点实验室, 湖南长沙 410073; 2. 军事科学院, 北京 100091;  
3. 国防科技大学电子科学学院, 湖南长沙 410073)

**摘要:** 雾或霾天气下, 大气粒子对光的散射作用造成光学图像细节弱化, 严重影响了后续的图像分析与处理任务. 现有去雾算法存在去雾后图像信息丢失、产生模糊、天空区域过增强等问题. 本文从偏振视角与暗通道先验理论出发, 提出了一种基于直接透射光梯度特征引导的目标偏振度估算算法, 用于图像去雾. 通过偏振图像获取场景与大气的偏振信息; 再以暗通道先验算法估计的直接透射光强的梯度特征为引导, 估算目标偏振度; 将估算的目标偏振度转为大气光强, 经过原理性约束与引导滤波, 得到优化的大气光强, 进一步求解去雾图像与优化的目标偏振度. 定性实验表明: 本文算法去雾后, 图像具有良好的平滑度, 且克服了现有去雾算法存在的可见性弱、去雾残留、天空区域过增强等问题; 定量实验表明: 本文算法既不会造成图像信息丢失, 也不会产生过多的噪声或模糊. 综合对比9种具有代表性的去雾算法, 本文算法具有良好的细节恢复能力、图像熵提升能力以及色调还原能力.

**关键词:** 图像处理; 图像去雾; 偏振图像; 暗通道先验; 偏振度估算

**基金项目:** 国家自然科学基金(No.62075239)

**中图分类号:** TP391.41; O436.3

**文献标识码:** A

**文章编号:** 0372-2112(2024)06-2011-14

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20231010

## Image Dehazing Based on Gradient Guided Polarization Degree Estimation

XU Wan-chun<sup>1</sup>, ZHANG Yan<sup>1\*</sup>, ZHANG Jing-hua<sup>2</sup>, LING Feng<sup>1</sup>, LI Shun<sup>3</sup>

(1. National Key Laboratory of Science and Technology on Automatic Target Recognition, College of Electronic Science and Technology, National University of Defense Technology, Changsha, Hunan 410073, China;  
2. Academy of Military Science, Beijing 100091, China;  
3. College of Electronic Science and Technology, National University of Defense Technology, Changsha, Hunan 410073, China)

**Abstract:** In foggy or hazy weather, the scattering of light by atmospheric particles weakens the details of optical images, which affects the subsequent image analysis and processing tasks seriously. The existing dehazing algorithms have problems such as the loss of image information, blurring and excessive enhancement of the sky after dehazing. Starting from the perspective of polarization and dark channel prior theory, this article proposes a target polarization degree estimation algorithm using the gradient feature of the direct transmission light intensity as guidance for image dehazing. The polarization information of scene and atmosphere are obtained from polarized images. Then, guided by the gradient feature of the direct transmission light intensity which is estimated by dark channel prior algorithm, the target polarization degree is estimated. The estimated target polarization degree is converted into atmospheric light intensity, and the optimized atmospheric light intensity is obtained after theoretical constraint and guided filtering atmospheric light intensity, then the optimized target polarization degree and image after dehazing are solved. Qualitative experiments show that the image dehazed by the proposed algorithm has good smoothness and overcomes the problems of existing dehazing algorithms, such as low visibility, dehazing residue and excessive enhancement of the sky. Quantitative experiments show that the proposed algorithm neither causes the loss of image information, nor generates excessive noise or blurs. The comparison with nine representative dehazing algorithms shows that our proposed algorithm has good ability of restoring details, improving image entropy, and enhancing the degree of tonal restoration.

Key words: image processing; image dehazing; polarization images; dark channel prior; polarization degree estimation  
Foundation Item(s): National Natural Science Foundation of China (No.62075239)

## 1 引言

雾或霾天气下,大气中的高浓度微小粒子会对光产生散射作用,散射的光线与目标本身反射的光线混合,造成民用监控与军事探测等专业成像设备采集的图像清晰度与对比度严重下降,对后续的目标检测、跟踪等任务造成严重影响.含雾图像的去雾处理可有效提升图像清晰度,进一步提升后续图像分析处理任务的性能.因此,图像去雾在民用与军事领域具有重要的研究意义.

近年来,涌现了众多的图像去雾算法.从去雾算法的原理出发,可具体分为三类:基于非物理模型、基于物理模型和基于深度学习的去雾算法<sup>[1]</sup>.

### 1.1 基于非物理模型的去雾算法

基于非物理模型的去雾算法,主要利用图像本身的数学特征或统计特性增强图像细节,本质是图像增强技术.具体包括直方图均衡化<sup>[2]</sup>、Retinex算法<sup>[3]</sup>、小波变换<sup>[4]</sup>等.直方图均衡化<sup>[2]</sup>利用非线性变换拉伸灰度直方图,增加图像对比度,进而实现去雾.此方法原理简单,可以实现一定程度的去雾,但容易引入额外的噪声且鲁棒性差.Retinex算法认为物体的色彩不受光照非均匀的影响,具有一致性.Retinex算法的发展较为完善,从单尺度Retinex算法到多尺度Retinex算法<sup>[5]</sup>,再引入色彩恢复因子得到色彩恢复的多尺度Retinex算法<sup>[6]</sup>.小波变换<sup>[4]</sup>具有多分辨率特点,由于雾霾主要影响图像低频部分,算法通过抑制低频亮度,增强高频亮度,实现去雾.以上算法的本质都是经过一定的统计与变换将细节特征进行放大,都属于图像增强手段<sup>[1]</sup>.

### 1.2 基于物理模型的去雾算法

基于物理模型的去雾算法,主要以大气物理退化模型为基础,通过结合不同的先验信息估算模型参数,进一步求解去雾图像.Schechner等<sup>[7]</sup>最先提出较为成熟的偏振去雾算法,但对浓雾图像的处理效果较差.Fattal等<sup>[8]</sup>利用阴影与透射率局部不相关假设求解透射率,但由于该方法固有的统计特性弱点,对浓雾图像的去雾效果不好<sup>[9]</sup>.Tan<sup>[10]</sup>认为无雾图像的对比度高于含雾图像,通过最大化对比度实现去雾.2009年,He等<sup>[11]</sup>通过分析大量的户外无雾图像,提出暗通道先验,进一步提出暗通道先验去雾算法,是目前最稳定的去雾算法<sup>[1]</sup>.该算法去雾效果明显,但存在颜色失真,常伴有一定的分块与纹理效应<sup>[12]</sup>.后续基于物理模型的去雾算法多以暗通道先验为基础,结合各种先验信息构建约束函数求解模型参数,实现去雾.如,Tarel等<sup>[13]</sup>使用

暗通道局部均值与标准差表示大气光强,通过中值滤波估计大气厚度,基于大气物理退化模型实现去雾.暗通道先验去雾算法虽能取得较好的去雾效果,但参数设置存在局限性,导致去雾鲁棒性不强<sup>[9]</sup>.此外,使用暗通道先验去雾时,大多数散射模型的去雾方法在处理天空区域时都会产生过增强现象<sup>[9]</sup>.

除暗通道先验算法外,还有颜色衰减先验去雾算法、基于偏振的图像去雾算法等.其中,颜色衰减先验去雾算法复原的清晰图像色彩自然,但在景深处容易出现雾残留等问题<sup>[1]</sup>.偏振去雾算法需要估计未知大气条件标定信息,估计成本过大、过程繁琐,导致实际运用难度较大<sup>[1]</sup>.如,Fang等<sup>[14]</sup>基于直接透射光强与透射率局部不相关的假设,估算目标偏振度,进一步求解去雾图像,但该算法假设易受图像噪声影响,导致偏振度出现较大偏差,去雾图像出现大面积失真.孟宇飞等<sup>[15]</sup>提出四分暗通道均值比较法,用于估计模型参数,进而实现双角度偏振图像去雾,此算法虽然可以减小场景中白色高亮物体的影响,确保所选区域位于天空,但易受图像过曝或噪声影响,鲁棒性较差.

### 1.3 基于深度学习的去雾算法

基于深度学习的去雾算法,主要从去雾数据集集中学习如何从含雾图像恢复出清晰图像.常见的公开去雾数据集有I-HAZE<sup>[16]</sup>、O-HAZE<sup>[17]</sup>、RESIDE<sup>[18]</sup>、NH-HAZE<sup>[19]</sup>和BeDDE<sup>[20]</sup>等,但以上数据集均未含有偏振数据.

早期有两种较为经典的基于深度学习的去雾范式:第一种是利用深度学习估计大气物理模型参数,进而实现去雾,如:Cai等<sup>[21]</sup>基于先验,提出一种名为DehazeNet的端对端模型,输入含雾图像,输出透射图,代入大气物理退化模型实现图像去雾.图像去雾后细节明显,但景深变化处的去雾效果不好,低亮度区域易丢失图像信息,且算法参数较多,效率较低.此后,以DehazeNet为代表的基于物理模型参数估计的深度学习去雾算法迅速发展,如:王高峰等<sup>[22]</sup>在透射率估计部分引入深度可分离卷积层,提出了改进DehazeNet模型.麻文刚等<sup>[9]</sup>提出一种景深引导网络(Depth Guided Network, DGN)与环境光优化的图像去雾算法.第二种是在像素域直接建立含雾图像和清晰图像的映射,进而实现去雾,如:Qin等<sup>[23]</sup>提出一种端到端的特征融合注意力网络(Feature Fusion Attention Network, FFA-Net).Chen等<sup>[24]</sup>提出一种基于生成对抗网络(Generative Adversarial Network, GAN)的端到端模型(Gated Context Aggregation Network, GCANet),利用平滑卷积取代了扩

展卷积. 此模型不依赖先验信息, 但对数据集要求较高, 且应用场景受限. 肖进胜等<sup>[25]</sup>基于 GAN 设计了漏斗型的生成器, 实现从含雾图像到无雾图像的转换.

近年, 也涌现了很多新的去雾范式. Li 等<sup>[26]</sup>提出一种有效的半监督学习范式用于单幅图像去雾. Shao 等<sup>[27]</sup>为解决在合成图像上训练的模型不能很好推广到真实图像去雾的问题, 提出一种域适应范式. Zhao 等<sup>[28]</sup>将去雾任务分为可见度恢复与真实度增强, 提出基于两阶段去雾策略的弱监督去雾模型 (Refinement Dehazing Network, RefinedNet). Wu 等<sup>[29]</sup>提出一种新的真实图像去雾范式: 一方面重新考虑真实雾天图像的退化过程, 提出一种不同退化类型的现象学 pipeline; 另一方面结合强大的高质量码本先验提出真实图像去雾模型 (Real Image Dehazing network via high-quality Codebook Priors, RIDCP). Li 等<sup>[30]</sup>为解决单幅图像去雾中同场景无雾图像难以获取与数据采集成本高的问题, 受层解纠缠启发, 提出第一个用于单幅图像去雾的无监督的、未训练的神经网络 (You Only Look Yourself, YOLY).

绝大部分深度学习去雾算法的训练需要大量的低质量-高质量图像样本对, 实际中成对样本难以获得, 低质量图像常基于物理模型对高质量图像降质得到, 这种人为仿真难以很好地模拟图像真实降质, 因此训练出的模型泛化性能差, 处理真实图像时, 往往会失效<sup>[31]</sup>. 而且大多数的深度学习算法要求固定的分辨率输入, 导致很难迅速用于不同分辨率的图像去雾.

#### 1.4 本文去雾算法

针对大多数暗通道先验去雾算法对天空区域的过增强、偏振去雾算法易受图像噪声影响, 以及大多数深

度学习去雾算法泛化性差、难以快速用于不同分辨率图像的问题, 本文提出一种基于梯度引导偏振度估算的图像去雾算法. 首先, 从采集的偏振图像中提取场景偏振信息与大气偏振信息. 然后, 假设图像小区域内场景光强、大气光强不变, 以暗通道先验算法<sup>[11]</sup>估计的直接透射光强的梯度特征为引导, 估算目标偏振度. 最后, 将估算的目标偏振度转为大气光强, 通过原理性约束与引导滤波, 求解去雾图像与优化的目标偏振度. 相较于暗通道先验算法, 本文算法有效解决了天空区域过增强. 相较于其他偏振去雾算法, 本文算法不易受图像过曝或噪声影响. 相较于深度学习去雾算法, 本文算法不需要训练, 具有普遍适用性, 且不会造成图像信息丢失或产生模糊. 实验结果表明, 本文算法具有良好的去雾效果, 且去雾图像具有良好的细节信息、图像熵、色调还原程度与无参考图像质量评价.

## 2 算法原理与模型构建

### 2.1 大气物理退化模型

大气物理退化模型假设大气是均匀的, 并将成像设备接收的总光强 (场景光强)  $I$  分为直接透射光强  $D$  与大气光强  $A$ , 如图 1 所示, 使用公式表示为

$$I = D + A \quad (1)$$

其中, 直接透射光强  $D$  是目标反射光强  $J$  经大气衰减后, 成像设备接收的部分, 使用公式表示为

$$D = J \exp(-\beta d) = Jt \quad (2)$$

其中,  $\beta$  是大气衰减系数,  $d$  是目标到成像设备的传输距离,  $t$  是透射率.

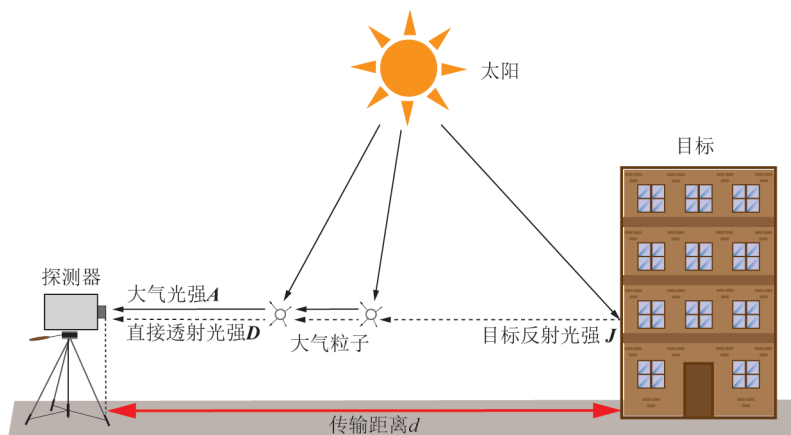


图 1 大气物理退化模型

大气光强  $A$  由大气自身辐射、大气粒子散射太阳光与环境光构成, 使用公式表示为

$$A = A_{\infty} [1 - \exp(-\beta d)] = A_{\infty} (1 - t) \quad (3)$$

其中,  $A_{\infty}$  是无穷远处大气光强, 通常视为全局参量<sup>[7]</sup>.

去雾算法的本质是去除大气光强  $A$ , 并对目标反射光强  $J$  受到的衰减进行补偿, 即  $J$  是理想情况下的去雾图像. 结合式 (1)~(3), 可得去雾图像:

$$J = \frac{I - A}{1 - A/A_{\infty}} \quad (4)$$

由式(4)可知,实现去雾需求解  $A$  与  $A_\infty$ .

相关理论与实验结果均表明大气光强  $A$  与目标反射光强  $J$  为偏振光<sup>[14]</sup>. 将场景、大气、目标偏振特征与大气物理退化模型结合,得到大气物理退化模型的偏振表示:

$$\rho I = \rho_A A + \rho_D D \quad (5)$$

其中,  $\rho$ 、 $\rho_A$  与  $\rho_D$  依次是场景、大气与目标偏振度. 进一步推导,得到直接透射光强  $D$  与大气光强  $A$  的偏振表示:

$$D = \frac{I(\rho_A - \rho)}{\rho_A - \rho_D} \quad (6)$$

$$A = \frac{I(\rho - \rho_D)}{\rho_A - \rho_D} \quad (7)$$

其中,式(7)将大气光强  $A$  表示为  $\rho$ 、 $\rho_A$  与  $\rho_D$  的函数,则

去雾需求解的参量可分解为  $\rho$ 、 $\rho_A$ 、 $\rho_D$  与  $A_\infty$ .

## 2.2 基于目标偏振度估算的去雾算法

基于上述分析,本节具体阐述  $\rho$ 、 $\rho_A$ 、 $\rho_D$ 、 $A_\infty$  的求解与去雾实现. 基本思想是利用偏振图像求解场景光强  $I$ 、场景偏振度  $\rho$  与场景偏振角  $\alpha$ , 在天空区域估计大气偏振度  $\rho_A$ , 利用暗通道先验算法<sup>[11]</sup> 估计无穷远处大气光强  $A_\infty$  与直接透射光强  $D_{\text{dark}}$ . 由于目标区域的场景光强同时包含了直接透射光强与大气光强,难以直接估算目标偏振度  $\rho_D$ , 因此考虑反映目标偏振特性的直接透射光强,将式(6)看作目标偏振度的函数  $D(\rho_D)$ , 以直接透射光强  $D_{\text{dark}}$  的梯度特征为引导,估算目标偏振度. 再通过一系列转换、约束和滤波优化,最终求得去雾图像与优化的目标偏振度. 图2为所提算法的流程图,图中序号为具体的实现步骤.

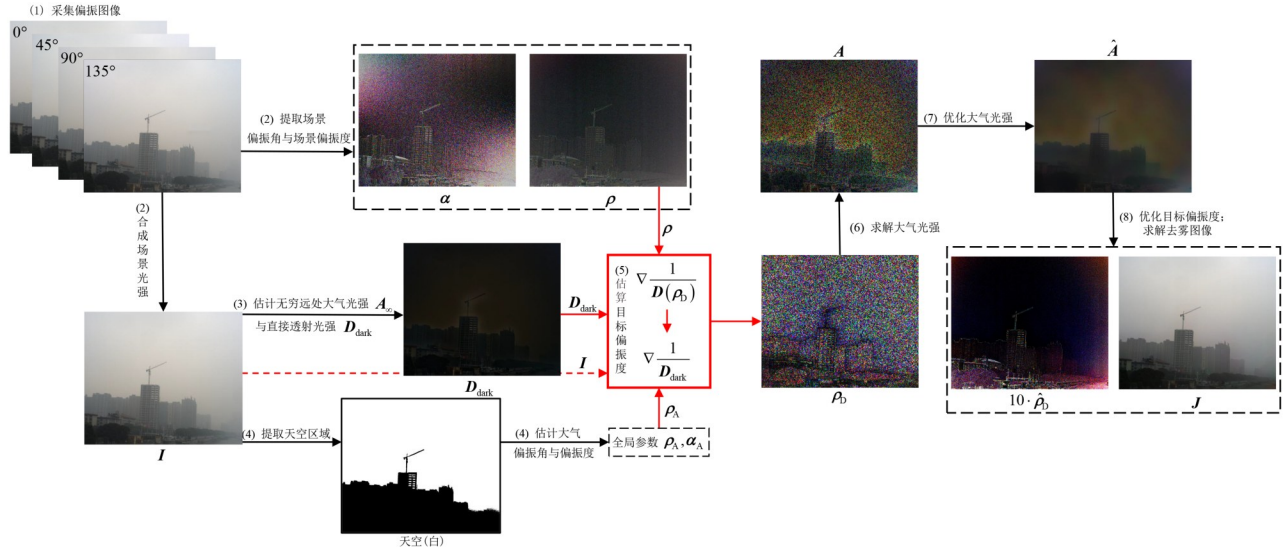


图2 算法流程

第(1)步、第(2)步:采集偏振图像后提取场景光强  $I$ 、场景偏振度  $\rho$  与场景偏振角  $\alpha$ . 采集起偏方向为  $0^\circ$ 、 $45^\circ$ 、 $90^\circ$ 、 $135^\circ$  的偏振图像,分别记作  $I_{0^\circ}$ 、 $I_{45^\circ}$ 、 $I_{90^\circ}$  与  $I_{135^\circ}$ , 可求得斯托克斯矢量:

$$\begin{cases} S_0 = I_{0^\circ} + I_{90^\circ} \\ S_1 = I_{0^\circ} - I_{90^\circ} \\ S_2 = I_{45^\circ} - I_{135^\circ} \end{cases} \quad (8)$$

其中,  $S_0$  是场景光强;  $S_1$  是水平方向与垂直方向的偏振光强差;  $S_2$  是  $45^\circ$  与  $135^\circ$  方向的偏振光强差. 由式(8)求解  $I$ 、 $\rho$  与  $\alpha$ :

$$I = S_0 = I_{0^\circ} + I_{90^\circ} \quad (9)$$

$$\rho = \frac{\sqrt{S_1^2 + S_2^2}}{S_0} \quad (10)$$

$$\alpha = \frac{1}{2} \arctan \left( \frac{S_2}{S_1} \right) \quad (11)$$

第(3)步:基于场景光强  $I$ , 利用暗通道先验算法<sup>[11]</sup> 估计无穷远处大气光强  $A_\infty$  与直接透射光强  $D_{\text{dark}}$ . 含雾图像中天空区域的光强非常接近  $A_\infty$ , 因此暗通道图像中天空区域的强度明显大于目标区域,选取暗通道图像中强度最大的0.1% 像素,以其在  $I$  中的均值估计  $A_\infty$ . 进一步估计直接透射光强  $D_{\text{dark}}$ , 详细推导见附录A.

第(4)步:基于场景光强  $I$ , 分割天空区域以估计大气偏振度  $\rho_A$  与大气偏振角  $\alpha_A$ . 大气物理退化模型假设大气均匀,理论上天空区域各像素的偏振信息一致,即  $\rho_A$  与  $\alpha_A$  是全局参量. 基于天空像素的偏振统计特性估计  $\rho_A$  与  $\alpha_A$ :

(1)分割天空区域是为了获取足够多的天空像素,

因此对分割边缘的准确性要求不高. 采用自动阈值分割与手动分割结合的方式, 在不含目标像素的前提下获取足够多的天空像素;

(2) 采集偏振图像时, 成像设备的响应单元存在偏差, 这使得偏振图像含有一定的系统噪声. 由于  $S_0$  是  $I_{0^\circ}$  与  $I_{90^\circ}$  之和、 $S_1$  是  $I_{0^\circ}$  与  $I_{90^\circ}$  之差、 $S_2$  是  $I_{45^\circ}$  与  $I_{135^\circ}$  之差, 可认为  $S_1$  与  $S_2$  中的系统噪声小于  $S_0$ . 式(11)中,  $\alpha$  的求解只受  $S_1$  与  $S_2$  中噪声的影响, 而式(10)中,  $\rho$  的求解还会受  $S_0$  中噪声的影响. 为抑制系统噪声对估计的影响: 首先由式(11)求解天空像素的偏振角, 以出现频次最高的偏振角为  $\alpha_A$ ; 其次, 选取偏振角为  $\alpha_A$  的天空像素, 以其偏振度最大值为  $\rho_A$ .

第(5)步: 基于上述步骤得到的  $I$ 、 $\rho$ 、 $\rho_A$  与  $D_{\text{dark}}$  估算目标偏振度. 基于场景光强  $I$  与大气光强  $A$  在均匀区域内缓慢变化的性质, 假设小区域内场景光强与大气光强不变, 该假设仅在少数边缘变化剧烈的情况下有效性较弱. 综合考虑  $I$  与  $A$  不变的假设与估算精度, 选择  $5 \times 5$  像素的小区域用于目标偏振度估算. 由式(6)可以发现, 直接透射光强  $D$  在场景光强  $I$ 、场景偏振度  $\rho$  与大气偏振度  $\rho_A$  已知的条件下, 是以目标偏振度  $\rho_D$  为自变量的函数  $D(\rho_D)$ . 以  $D(\rho_D)$  与  $D_{\text{dark}}$  的梯度特征差异构造代价函数, 通过优化代价函数估算  $\rho_D$ , 求解过程参照文献[32], 详细推导见附录B.

第(6)步: 将场景光强  $I$ 、场景偏振度  $\rho$ 、大气偏振度  $\rho_A$  与目标偏振度  $\rho_D$  代入式(7), 求解大气光强  $A$ .

第(7)步: 由于  $A$  是  $I$  的组成部分, 对  $A$  进行  $0 < A \leq I$  约束, 再以  $I$  为引导图像, 对  $A$  进行引导滤波<sup>[33]</sup>, 得到优化的大气光强  $\hat{A}$ .

第(8)步: 将  $A_\infty$  与  $\hat{A}$  代入式(4), 求解目标反射光强  $J$ . 同时可将式(7)变形, 代入  $\hat{A}$ , 得到优化的目标偏振度  $\hat{\rho}_D = \frac{\rho I - \rho_A \hat{A}}{I - \hat{A}}$ .

由大气物理退化模型可知, 求解目标反射光强  $J$  意味着图像去雾的实现.

### 3 实验结果与分析

本文利用分焦平面偏振探测器<sup>[34]</sup>获取 16 组城市背景下的  $0^\circ$ 、 $45^\circ$ 、 $90^\circ$ 、 $135^\circ$  四通道偏振图像, 各通道图像的分辨率为  $1\ 224 \times 1\ 024$ . 为验证本文算法的去雾效果, 选取场景含雾明显且具有大量建筑的 5 组偏振图像作为实验数据, 从主观评价与客观评价两个角度对比本文算法与其他去雾算法. 本文实验在 Win11 操作系统下进行, 处理器型号为 12th Gen Intel(R) Core(TM) i9-12900H, RAM 为 16 GB, 显卡为 NVIDIA GeForce RTX 3060 Laptop. 深度学习框架为 Pytorch1.10.1, 并行计算框架为 CUDA11.6, GPU 加速库为 CUDNN8.6.0, 实验平

台为 Pycharm, Python 版本为 3.9.16. 本文算法参数如下: 暗通道区域大小为  $15 \times 15$ ; 引导滤波<sup>[33]</sup>参数设为:  $r=81$ ,  $\epsilon=10^{-3}$ ; 估算目标偏振度的参数设为: 小区域尺寸为  $5 \times 5$ , 正则化参数  $\epsilon=10^{-4}$ .

#### 3.1 主观评价

主观评价基于人的视觉感受对图像质量进行评价, 可直观反映人的主观感受, 是最为准确、可靠的质量评价方法<sup>[31]</sup>. 为验证本文算法的去雾有效性, 将本文算法与四类去雾算法进行比较: 基于物理模型的非偏振去雾算法(文献[11]与文献[13])、基于物理模型的偏振去雾算法(文献[14]与文献[15])、基于深度学习的经典去雾算法(DehazeNet<sup>[21]</sup>与 FFA-Net<sup>[23]</sup>)和新去雾范式(RefineDNet<sup>[28]</sup>、RIDCP<sup>[29]</sup>与 YOLY<sup>[30]</sup>). 其中, 文献[14]、文献[15]属于偏振去雾算法, YOLY<sup>[30]</sup>属于深度学习无监督去雾算法, 可重点与本文算法进行对比.

图3是不同算法在五种场景下的去雾结果. 每一行是一种场景的含雾图像与不同算法的去雾结果, 从上到下依次记为场景一到场景五, 并使用方框将变化明显的区域标出. 从图3可以看出, 文献[11]的算法具有明显的去雾效果, 但去雾后图像整体变暗, 颜色失真严重, 天空区域出现过增强与颜色失真现象, 且天空过曝区域与非过曝区域差异明显(图3场景三、五中红框区域). 文献[13]的算法具有非常直观的去雾效果, 但去雾后图像粗糙, 且天空区域出现颜色失真, 同时存在过增强现象, 产生不必要的纹理(图3场景三中黄色框域). 文献[14]的算法使图像出现大面积颜色失真, 严重影响了图像的可见性. 文献[15]的算法去雾后, 图像出现大量噪点与色偏, 场景三、五中由于四分暗通道均值比较法选择的区域位于偏振信息丢失的曝光区域, 导致估计的大气偏振度为0, 使得恢复的图像数值趋于无穷, 完全丧失可见性. DehazeNet去雾效果良好, 但去雾后图像整体偏暗, 部分区域由于过暗而丧失可见性(图3场景三、四、五中黄框区域), 无法辨别区域内的物体. FFA-Net去雾效果差, 存在去雾残留, 产生不规则模糊, 严重影响图像结构. RefineDNet去雾效果良好, 但天空与建筑的交界区域存在明显的光晕与波纹状斑块. RIDCP去雾效果略弱于文献[13]的算法, 虽然去雾后所有场景的天空区域一致偏黄, 但建筑色彩更加逼真, 图像更光滑. YOLY去雾后图像整体偏暗, 部分区域由于过暗而丧失可见性, 但优于DehazeNet; 天空区域不均匀, 且天空过曝区域与非过曝区域差异明显(图3场景三中红色区域). 本文算法虽存在少量与文献[15]的算法类似的色偏, 但色偏程度明显更低, 整幅图像平滑无噪点, 所有场景均可实现正常去雾, 且去雾效果良好.

本文算法去雾后天空区域均匀平滑,克服了文献[11]与文献[13]的算法去雾后天空区域过增强的问题;克服了文献[14]的算法在目标偏振度估算时易受图像噪声干扰、文献[15]的算法在过曝条件下易失效的问题,且大大

减小了色偏程度与噪点;克服了DehazeNet与FFA-Net丧失可见性、去雾残留或产生模糊的问题;没有出现RefineDNet导致的波纹状斑块,也没有像RIDCP一样令天空区域一致偏黄,以及YOLY中的可见性丧失问题。




图3 不同算法在五种场景下的去雾结果

### 3.2 客观评价

客观评价基于数学模型对图像质量进行评价。相较于主观评价,客观评价具有可重复、不受主观因素影响等特点。本文通过图像信息与灰度分布、边缘细节恢复与定量分析,客观评价不同算法的去雾效果。

#### 3.2.1 图像信息与灰度分布情况

将含雾图像与不同算法的去雾结果转为灰度图像,统计去雾前后的灰度直方图,进而分析不同算法对图像信息与灰度分布的影响。

图4是不同算法去雾前后的灰度图像。从图4可以看出,文献[11]的算法去雾后,图像明显整体变暗,且天空区域存在过增强现象。文献[13]的算法去雾后,图像结构变得突出,但整幅图像变得粗糙。文献[14]的算法去雾后,图像信息受到严重破坏,无法用于后续的分析与处理。文献[15]的算法去雾后,场景一、二与四的图像中出现大量噪点,图像信息受到严重破坏,场景三、五的图像信息完全丢失。DehazeNet去雾后,图像整体变暗,部分区域灰度过低,图像信息丢失。FFA-Net去雾后,出现具有一定结构的模糊,遮盖了图像原有的信息。RefineDNet去雾后图像变暗,且天空与建筑的交界附近出现大量波纹状斑块,引入额外的干扰信息。RIDCP去雾后图像变亮,图像结构变得突出。YOLY去雾后,图像整体变暗,部分区域灰度过低,图像信息丢失。本文算法去雾后,图像也会略微变暗,但图像整体平滑且没有造成图像信息的遮盖、丢失或引入干扰信息。

图5是不同算法去雾前后的灰度直方图。每一行

为一种场景,每行的四幅图依次对比了含雾图像、本文算法的灰度直方图和基于物理模型的非偏振去雾算法(文献[11]与文献[13])、基于物理模型的偏振去雾算法(文献[14]与文献[15])、基于深度学习的经典去雾算法(DehazeNet<sup>[21]</sup>与FFA-Net<sup>[23]</sup>)以及新去雾范式(RefineDNet<sup>[28]</sup>、RIDCP<sup>[29]</sup>与YOLY<sup>[30]</sup>)。其中,由于文献[15]的算法使场景三、五的图像信息完全丢失,场景三、五中与基于物理模型的偏振去雾算法对比时,仅与文献[14]的算法进行对比。从图5可以看出,文献[11]的算法去雾后灰度集中分布在低灰度区域,破坏了去雾前的灰度分布。文献[13]的算法去雾后基本保持去雾前的灰度分布。文献[14]的算法去雾后大量像素的灰度为零,严重破坏了去雾前的灰度分布。文献[15]的算法去雾后,灰度直方图峰值位于两侧,这是图中大量噪点造成的。DehazeNet去雾后大致保持去雾前的灰度分布,但部分像素的灰度变为零,意味着部分图像信息完全丢失了。FFA-Net去雾后基本保持去雾前的灰度分布。RefineDNet去雾后大致保持去雾前的灰度分布,但整体偏低。RIDCP去雾后大致保持与去雾前相似的灰度分布,整体灰度分布比其他算法更高,且在场景一、二与四中出现了原始含雾图像未曾出现的更高灰度,这是RIDCP带来良好视觉感受的原因之一。YOLY去雾前后的灰度分布差异较大,且部分像素的灰度为零,即部分图像信息完全丢失了。本文算法去雾后基本保持去雾前的灰度分布,但略微偏低。




图4 不同算法去雾前后的灰度图像

### 3.2.2 边缘细节恢复情况

为直观分析不同算法的边缘细节恢复情况,利用sobel算子计算含雾图像与不同算法去雾结果的梯度图像.为方便观察,本文近似认为梯度大于1为强边缘,小于1为弱边缘,通过将梯度clip至 $[0,1]$ 区间(大于1的梯度置为1)以关注强边缘数量与弱边缘强度.使用颜色框标记变化明显的区域,并将放大后的结果置于梯度图像下方.

图6~8分别是场景三、场景四与场景五去雾前后的梯度图像.图6选取了近处墙体(绿色)和建筑表面(红色)两个区域进行放大.从图6可以看出,文献[11]的算法去雾后,天空曝光区域与非曝光区域的交界处出现大量噪点.文献[13]的算法去雾后,图像的边缘细节明显增强,但天空非曝光区域出现大量噪点.文献[14]的算法去雾后,图像的边缘细节遭到严重破坏.文献[15]的算法去雾后,边缘细节完全丢失. DehazeNet去雾后,近处墙体丢失细节信息. FFA-Net去雾后,远处建筑受模糊影响,难以分辨原有的结构,边缘细节遭到破坏. RefineDNet去雾后,边缘细节得到增强,但天空曝光区域与非曝光区域的交界处出现大量噪点. RIDCP去雾后,图像边缘细节明显增强,但建筑表面存在过增强现象. YOLY去雾后,天空曝光区域与非曝光区域的交界处出现大量噪点,且近处墙体丢失细节信息. 本文算法去雾后,不仅天空区域没有噪点,而且近处墙体与建筑表面也没有丢失细节信息或受模糊影响.

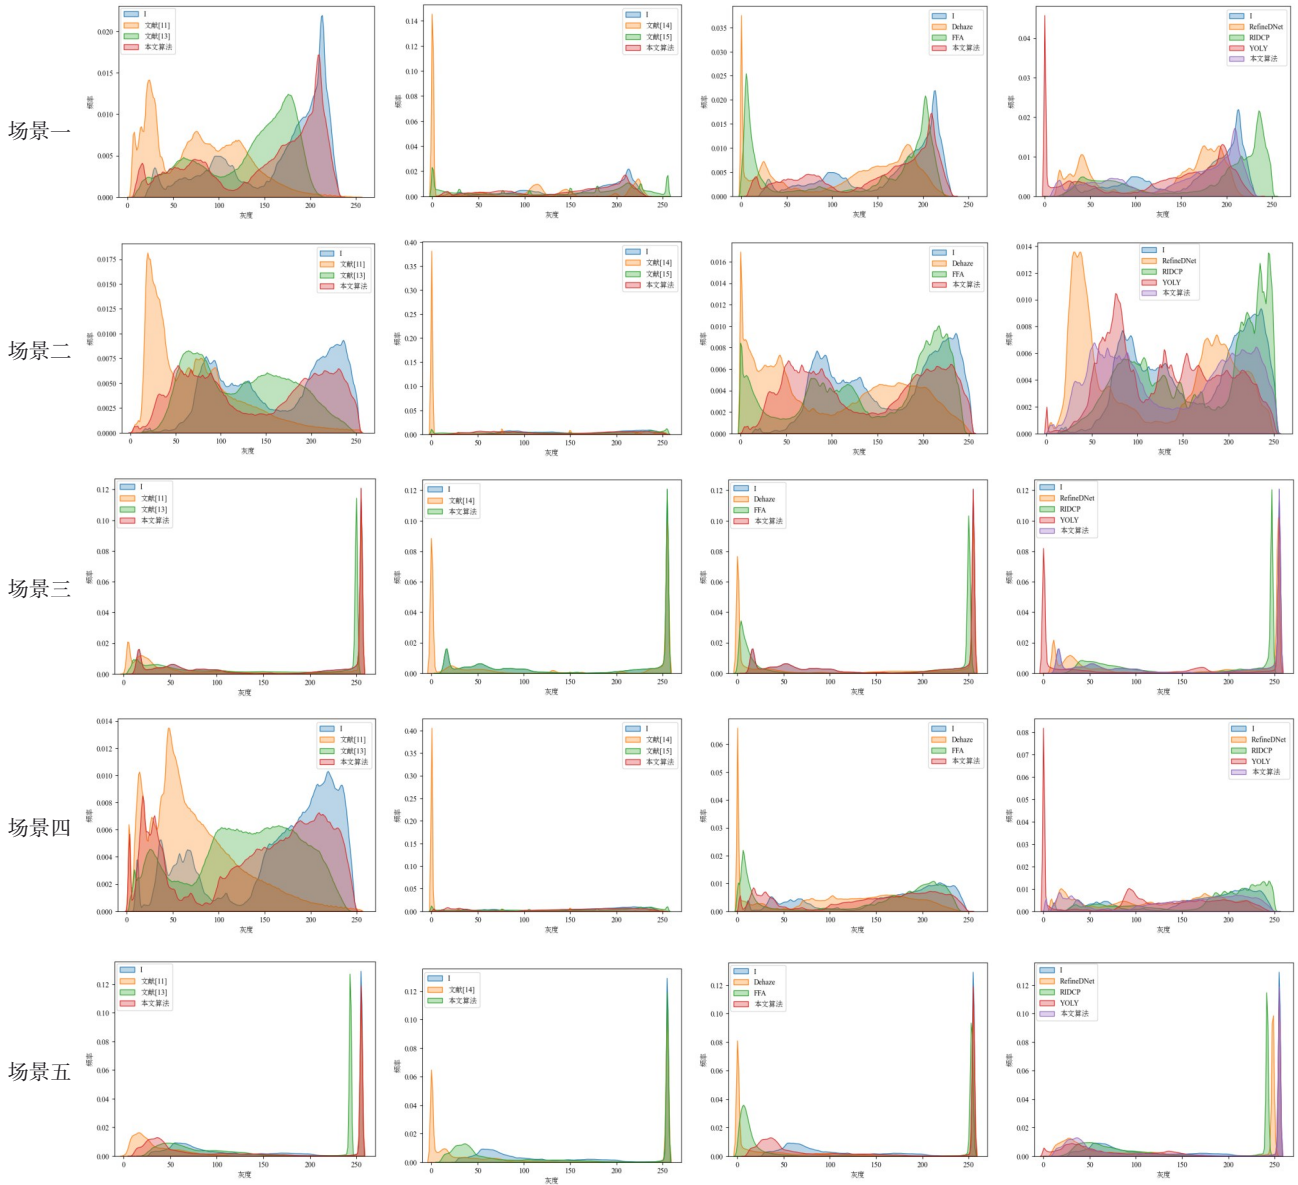
为与图6互补,图7选取了天空与建筑交界(红色)和另一建筑(绿色)两个区域进行放大.从图7可以看出,文献[11]的算法去雾后,图像边缘的细节得到一定增强,但天空区域出现大量噪点.文献[13]的算法去雾后,图像的边缘细节得到明显增强,但天空区域出现更

多的噪点.文献[14]的算法去雾后,图像的边缘细节遭到严重破坏.文献[15]的算法去雾后,大量的噪点将图像原有的边缘细节淹没. DehazeNet去雾后,建筑窗内的边缘细节丢失. FFA-Net去雾后,天空与建筑的交界处出现不规则模糊,建筑边缘受模糊影响变得扭曲. RefineDNet去雾后,建筑的边缘细节得到增强,但天空与建筑的交界处出现密集纹理. RIDCP去雾后,图像的边缘细节得到较为明显的增强,但存在一定程度的过增强(绿框中的建筑屋檐). YOLY去雾后,天空区域变得略微粗糙,建筑的部分边缘细节丢失. 本文算法去雾后,天空区域无噪点,且边缘细节并未出现丢失、扭曲或过增强现象.

图8选取了树木(红色)与建筑(绿色)两个区域进行放大.从图8可以看出,文献[11]的算法去雾后,图像的边缘细节得到一定的增强,但天空非曝光区域出现大量噪点.文献[13]的算法去雾后,图像的边缘细节得到明显增强,天空非曝光区域也出现大量噪点.文献[14]的算法去雾后,图像的结构信息遭到严重破坏.文献[15]的算法去雾后,边缘细节完全丢失. DehazeNet去雾后,对建筑区域有一定的增强,但树木区域丢失细节信息. FFA-Net去雾后,建筑区域出现不规则模糊,对原有细节信息造成扭曲. RefineDNet去雾后,图像的边缘细节得到一定的增强. RIDCP去雾后,图像的边缘细节得到明显增强,但存在过增强现象(绿框区域). 本文算法去雾后,图像的边缘细节得到增强,细节信息并未丢失、扭曲或出现过增强现象.

### 3.2.3 定量分析

计算不同场景下含雾图像与不同算法去雾结果的图像熵、结构相似度<sup>[35]</sup>、色调还原程度<sup>[35]</sup>与无参考图像质量评价指标(Blind/Referenceless Image Spatial Quality Evaluator, BRISQUE)<sup>[36]</sup>. 图像熵是图像特征



基于物理模型的非偏振去雾算法    基于物理模型的偏振去雾算法    基于深度学习的经典去雾算法    基于深度学习的新去雾范式

图5 不同算法去雾前后的灰度直方图

的一种统计形式,反映了图像中平均信息量的多少<sup>[37]</sup>.

图像熵越大,图像包含的信息越多. 图像熵的表达式如下:

$$H = - \sum_{i=0}^{255} p_i \cdot \log(p_i) \quad (12)$$

其中,  $p_i$  表示图像中灰度为  $i$  的像素占比.

结构相似度反映了两幅图像的结构相似程度. 结构相似度越大,表明去雾图像的结构失真越小. 场景中物体的结构独立于照度,因此结构相似度比较的是反射图像  $R_1$  与  $R_2$  的结构信息<sup>[35]</sup>. 结构相似度的表达式如下:

$$S(R_1, R_2) = \frac{\sigma_{12}}{\sigma_1 \sigma_2} \quad (13)$$

其中,  $\sigma_{12} = \frac{1}{N+1} \sum_{i=1}^N (R_1(i) - u_1)(R_2(i) - u_2)$ ,  $N$  为像素数,

$u_1, u_2$  是  $R_1, R_2$  的均值,  $\sigma_1, \sigma_2$  是  $R_1, R_2$  的标准差.

色调还原程度利用直方图相似性度量去雾图像的色调偏移程度<sup>[35]</sup>. 去雾前后的直方图相似性越高,色调还原程度越高. 色调还原程度的表达式如下:

$$d_{\text{correl}}(h, h^*) = \frac{\sum_{i=0}^{255} (h_i^* - \bar{h}^*)(h_i - \bar{h})}{\sqrt{\sum_{i=0}^{255} (h_i^* - \bar{h}^*)^2 \sum_{i=0}^{255} (h_i - \bar{h})^2}} \quad (14)$$




图 6 场景三不同算法去雾前后的梯度图像

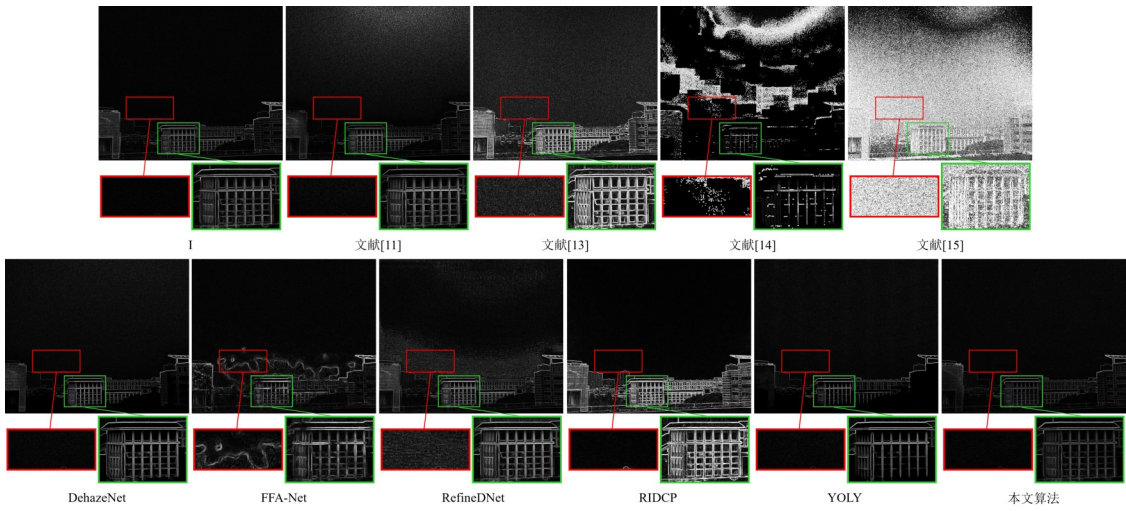


图 7 场景四不同算法去雾前后的梯度图像

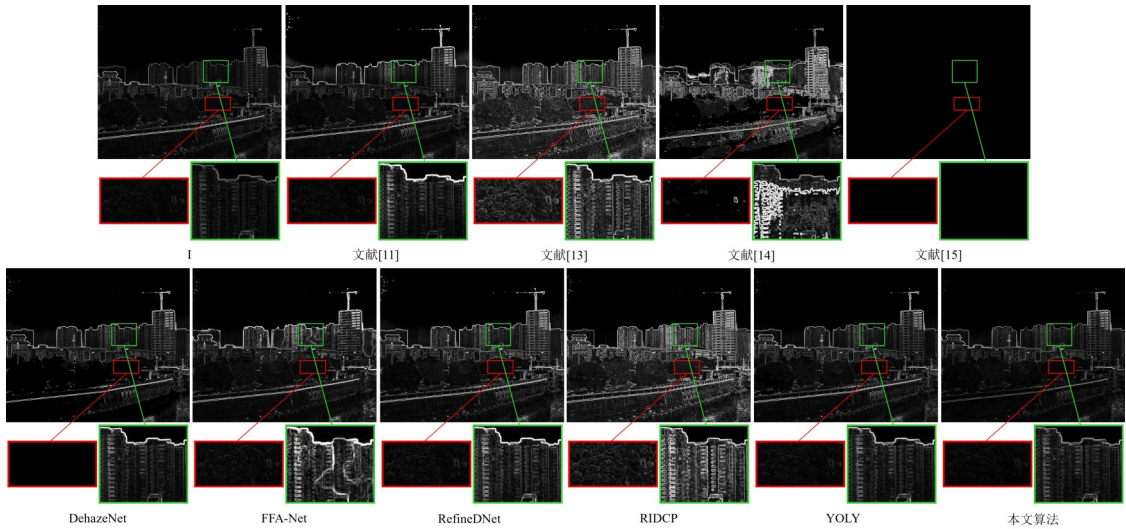


图 8 场景五不同算法去雾前后的梯度图像

其中,  $h$  与  $h^*$  为直方图;  $\bar{h}$ 、 $\bar{h}^*$  是  $h$ 、 $h^*$  的均值。

无参考质量评价指标 BRISQUE 利用自然图像统计特性并结合机器学习量化图像失真。从图像中提取 (Mean Subtracted Contrast Normalized, MSCN) 系数, 将其拟合为非对称广义高斯分布, 提取分布的特征, 输入训练好的支持向量机 (Support Vector Machine, SVM) 中进行回归, 最终得到代表图像质量的分数 (0~100)。其中, 0 表示最佳, 100 表示最差。本文仅将 0~100 之间的分数视为有效。

表 1 是不同算法去雾前后的客观指标, 使用红、蓝

色表示当前场景下某一指标的最优、次优值, 用“—”表示无意义数值。从表 1 可以看出, 在图像熵对比中, 不同场景下文献 [11]、文献 [13] 与本文算法均对图像熵有提升作用, 本文算法在五个场景下均能达到最优或次优, 其中场景一、二、四中本文算法最优, 场景三、五中文献 [11] 的算法最优, 而文献 [14] 的算法、FFA-Net、RefineDNet 与 YOLY 均低于含雾图像, 文献 [15] 的算法在场景三、五中为 0, DehazeNet 仅在场景一、二、四中有提升作用, RIDCP 仅在场景三、五中有提升作用。

表 1 不同算法去雾前后的客观指标

场景	方法	图像熵	结构相似度	色调还原程度				BRISQUE
				R 通道	G 通道	B 通道	平均	
场景一	I	17.051 59	1	1	1	1	1	17.086 61
	文献[11]	20.257 33	0.803 71	-0.369 63	-0.343 63	-0.329 26	-0.347 51	-15.812 81
	文献[13]	20.242 77	0.883 25	0.060 59	0.040 21	0.041 64	0.047 48	2.221 37
	文献[14]	10.931 74	0.653 50	-0.040 86	0.058 66	-0.014 62	0.001 06	76.201 84
	文献[15]	17.198 92	0.815 17	0.041 03	-0.003 59	-0.002 15	0.011 76	72.564 33
	DehazeNet	19.077 56	0.894 38	0.052 75	0.009 49	0.061 00	0.041 08	0.218 93
	FFA-Net	14.744 86	0.820 17	0.442 74	0.356 69	0.253 85	0.351 09	18.434 27
	RefineDNet	15.068 83	0.885 59	0.209 18	0.247 59	0.179 24	0.212 00	7.185 73
	RIDCP	15.621 64	0.893 60	0.003 63	0.231 20	0.424 90	0.219 91	14.704 28
	YOLY	14.922 25	0.901 45	0.162 50	0.158 85	0.087 31	0.136 22	15.443 05
本文算法	20.257 39	0.905 19	0.773 08	0.780 01	0.751 68	0.768 26	11.858 58	
场景二	I	17.527 56	1	1	1	1	1	9.064 15
	文献[11]	20.255 05	0.783 20	-0.412 02	-0.358 16	-0.437 38	-0.402 52	-13.036 44
	文献[13]	20.249 49	0.821 73	-0.098 16	0.111 16	0.202 45	0.071 81	1.640 81
	文献[14]	2.998 25	0.484 31	-0.071 10	-0.074 00	-0.072 89	-0.072 66	153.719 42
	文献[15]	19.057 76	0.799 92	-0.045 04	-0.048 74	-0.051 53	-0.048 44	68.559 27
	DehazeNet	19.908 12	0.835 24	-0.298 56	-0.428 71	-0.464 75	-0.397 34	-4.733 22
	FFA-Net	15.222 70	0.735 58	0.486 26	0.464 90	0.358 75	0.436 63	17.359 56
	RefineDNet	15.608 80	0.822 97	-0.274 71	-0.244 61	-0.352 44	-0.290 59	4.012 88
	RIDCP	15.777 53	0.815 21	0.494 64	0.715 24	0.726 49	0.645 46	12.990 91
	YOLY	16.113 67	0.798 27	0.205 62	0.274 09	0.316 34	0.265 35	10.983 58
本文算法	20.257 38	0.800 37	0.561 24	0.343 19	0.339 66	0.414 70	6.820 01	
场景三	I	11.557 78	1	1	1	1	1	43.048 03
	文献[11]	15.137 73	0.761 38	0.980 80	0.981 71	0.980 59	0.981 03	30.835 14
	文献[13]	13.839 75	0.788 47	0.005 93	0.002 62	-0.000 15	0.002 80	20.346 86
	文献[14]	6.963 66	0.743 37	0.547 46	0.728 29	0.614 16	0.629 97	60.432 80
	文献[15]	0	—	—	—	—	—	—
	DehazeNet	9.451 61	0.802 31	0.771 12	0.786 45	0.772 26	0.776 61	48.883 00
	FFA-Net	10.372 00	0.798 74	0.000 93	0.000 20	-0.000 58	0.000 18	39.490 91
	RefineDNet	10.901 38	0.805 70	0.005 94	0.036 70	0.043 00	0.028 55	27.441 10
	RIDCP	12.032 79	0.810 27	0.012 98	-0.001 18	-0.011 79	0.000 00	29.978 21
	YOLY	7.786 40	0.787 05	0.768 90	0.776 92	0.773 68	0.773 17	46.123 23
本文算法	14.049 44	0.812 41	0.986 27	0.986 58	0.983 57	0.985 47	40.786 80	

续表

场景	方法	图像熵	结构相似度	色调还原程度				BRISQUE
				R 通道	G 通道	B 通道	平均	
场景四	I	17.268 38	1	1	1	1	1	9.578 31
	文献[11]	20.256 57	0.680 53	-0.396 54	-0.380 14	-0.318 70	-0.365 12	-15.596 01
	文献[13]	20.234 38	0.756 40	-0.026 12	-0.023 08	-0.159 07	-0.069 42	0.744 81
	文献[14]	2.663 86	0.345 68	-0.065 24	-0.066 36	-0.072 17	-0.067 93	159.428 89
	文献[15]	18.655 91	0.718 65	-0.006 42	-0.041 12	-0.032 48	-0.026 68	72.892 21
	DehazeNet	17.992 07	0.781 16	-0.068 68	-0.084 85	-0.074 19	-0.075 91	-4.558 41
	FFA-Net	14.746 44	0.755 45	0.391 78	0.363 69	0.262 28	0.339 25	20.238 46
	RefineDNet	15.847 46	0.772 28	0.097 58	0.151 24	0.047 57	0.098 80	-0.509 09
	RIDCP	15.399 69	0.784 19	0.503 89	0.673 19	0.716 99	0.631 35	15.775 57
	YOLY	14.054 41	0.777 83	-0.037 56	-0.042 21	-0.055 09	-0.044 95	12.490 42
本文算法	20.257 39	0.793 67	0.540 25	0.453 03	0.516 32	0.503 20	5.582 21	
场景五	I	11.897 42	1	1	1	1	1	36.617 37
	文献[11]	15.494 51	0.839 08	0.977 25	0.976 61	0.972 70	0.975 52	34.701 84
	文献[13]	13.589 37	0.857 77	-0.007 22	-0.005 61	-0.006 59	-0.006 47	13.572 45
	文献[14]	9.069 73	0.843 47	0.832 65	0.640 85	0.659 83	0.711 11	47.509 70
	文献[15]	0	—	—	—	—	—	—
	DehazeNet	8.838 72	0.866 70	0.779 01	0.780 56	0.749 76	0.769 78	48.317 57
	FFA-Net	10.544 20	0.815 97	0.018 90	0.000 15	0.054 86	0.024 64	34.302 43
	RefineDNet	11.634 03	0.871 79	-0.017 47	-0.015 58	-0.022 35	-0.018 47	33.987 00
	RIDCP	12.330 41	0.855 04	-0.004 08	-0.005 00	-0.007 96	-0.005 68	23.177 43
	YOLY	10.826 99	0.886 59	0.989 26	0.989 22	0.987 64	0.988 71	37.251 65
本文算法	13.852 73	0.879 46	0.987 50	0.985 20	0.983 80	0.985 50	35.623 23	

在结构相似度对比中,DehazeNet 仅在场景二中最高,RefineDNet 在场景二中次高,RIDCP 在场景三、四中次高,YOLY 在场景五中最高,在场景一中次高,而本文算法在场景一、三、四中最高,在场景五中次高。

在色调还原程度对比中,文献[11]的算法去雾后,图片明显变暗且直方图分布与含雾图像具有相反分布,因此色调还原程度为绝对值较大的负值。由于场景五过曝,文献[11]的算法基本保持了与含雾图像相同的分布,因此具有高的色调还原程度。文献[13]的算法与 DehazeNet 去雾后,图片偏暗且直方图分布基本与含雾图像相同,因此色调还原程度没有表现为绝对值较大的负值。FFA-Net 去雾后,在场景一、二、四中具有较高的色调还原程度。RefineDNet 的色调还原程度在不同场景下正负摇摆,并没有表现出较强的规律性。RIDCP 在场景二、四中最高或次高。YOLY 在场景五中最高。本文算法去雾后,普遍具有较高的色调还原程度,在场景一、三中最高,在场景四、五中次高。

在 BRISQUE 对比中,文献[13]的算法在所有场景中均为最优或次优,DehazeNet 在场景一中最优,RefineDNet 在场景二、三中次优,RIDCP 在场景五中次优,

本文算法在场景四中次优。本文算法虽然没达到多个场景中的最优或次优,但在所有场景中,均为有效值,且均优于含雾图像,此效果在对比的算法中仅文献[13]的算法可以达到,表明了本文算法的稳定性。

综上所述,图像熵、结构相似度、色调还原程度与 BRISQUE 均证明了本文算法去雾的有效性、优越性与稳定性。

#### 4 结论

本文提出了一种基于直接透射光强梯度特征引导的目标偏振度估算算法,实现了图像的偏振去雾。算法从偏振视角与暗通道先验理论出发,基于小区域内场景光强与大气光强不变的假设,以暗通道先验算法估计的直接透射光强梯度特征为引导,实现了目标偏振度的估算。进一步将目标偏振度转为大气光强,通过原理性约束与引导滤波,得到优化的大气光强,进一步求解去雾图像与优化的目标偏振度。实验结果表明,本文算法具有良好的去雾效果,图像整体平滑,不存在细节信息丢失、产生模糊等问题,且去雾图像具有较高的图像熵、结构相似度、色调还原程度以及良好的无参考质量评价。

## 参考文献

- [1] 郑凤仙, 王夏黎, 何丹丹, 等. 单幅图像去雾算法研究综述[J]. 计算机工程与应用, 2022, 58(3): 1-14.  
ZHENG F X, WANG X L, HE D D, et al. Survey of single image defogging algorithm[J]. Computer Engineering and Applications, 2022, 58(3): 1-14. (in Chinese)
- [2] LIU J, WANG X, CHEN M, et al. Thin cloud removal from single satellite images[J]. Optics Express, 2014, 22(1): 618-632.
- [3] RAJPUT G S, RAHMAN Z U. Hazard detection on runways using image processing techniques[C]//SPIE Defense and Security Symposium. Enhanced and Synthetic Vision 2008. Orlando: SPIE, 2008, 6957: 112-123.
- [4] RUSSO F. An image enhancement technique combining sharpening and noise reduction[J]. IEEE Transactions on Instrumentation and Measurement, 2002, 51(4): 824-828.
- [5] JOBSON D J, RAHMAN Z, WOODDELL G A. Properties and performance of a center/surround retinex[J]. IEEE Transactions on Image Processing, 1997, 6(3): 451-462.
- [6] JOBSON D J, RAHMAN Z, WOODDELL G A. A multi-scale retinex for bridging the gap between color images and the human observation of scenes[J]. IEEE Transactions on Image Processing, 1997, 6(7): 965-976.
- [7] SCHECHNER Y Y, NARASIMHAN S G, NAYAR S K. Instant dehazing of images using polarization[C]//Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR. Piscataway: IEEE, 2001: I(325-332).
- [8] FATTAL R. Single image dehazing[J]. ACM Transactions on Graphics, 2008, 27(3): 1-9.
- [9] 麻文刚, 张亚东, 郭进. 基于景深先验引导与环境光优化的图像去雾[J]. 电子学报, 2022, 50(7): 1708-1721.  
MA W G, ZHANG Y D, GUO J. Image dehazing based on priori guidance of depth of field and optimization of ambient light[J]. Acta Electronica Sinica, 2022, 50(7): 1708-1721. (in Chinese)
- [10] TAN R T. Visibility in bad weather from a single image[C]//2008 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2008: 1-8.
- [11] HE K M, SUN J, TANG X O. Single image haze removal using dark channel prior[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2009: 1956-1963.
- [12] 李加元, 胡庆武, 艾明耀, 等. 结合天空识别和暗通道原理的图像去雾[J]. 中国图象图形学报, 2015, 20(4): 514-519.  
LI J Y, HU Q W, AI M Y, et al. Image haze removal based on sky region detection and dark channel prior[J]. Journal of Image and Graphics, 2015, 20(4): 514-519. (in Chinese)
- [13] TAREL J P, HAUTIERE N. Fast visibility restoration from a single color or gray level image[C]//2009 IEEE 12th International Conference on Computer Vision. Piscataway: IEEE, 2009: 2201-2208.
- [14] FANG S, XIA X S, XING H, et al. Image dehazing using polarization effects of objects and airlight[J]. Optics Express, 2014, 22(16): 19523-19537.
- [15] 孟宇飞, 王晓玲, 刘畅, 等. 四分暗通道均值比较法的双角度偏振图像去雾[J]. 激光与光电子学进展, 2022, 59(4): 0411001.  
MENG Y F, WANG X L, LIU C, et al. Dehazing of dual angle polarization image based on mean comparison of quartering dark channels[J]. Laser & Optoelectronics Progress, 2022, 59(4): 0411001. (in Chinese)
- [16] ANCUTI C, ANCUTI C O, TIMOFTE R, et al. I-HAZE: A dehazing benchmark with real hazy and haze-free indoor images[C]//Advanced Concepts for Intelligent Vision Systems. Cham: Springer, 2018: 620-631.
- [17] ANCUTI C O, ANCUTI C, TIMOFTE R, et al. O-HAZE: A dehazing benchmark with real hazy and haze-free outdoor images[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Piscataway: IEEE, 2018: 867-8678.
- [18] 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.
- [19] ANCUTI C O, ANCUTI C, TIMOFTE R. NH-HAZE: An image dehazing benchmark with non-homogeneous hazy and haze-free images[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Piscataway: IEEE, 2020: 1798-1805.
- [20] ZHAO S Y, ZHANG L, HUANG S Y, et al. Dehazing evaluation: Real-world benchmark datasets, criteria, and baselines[J]. IEEE Transactions on Image Processing, 2020, 29: 6947-6962.
- [21] 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.
- [22] 王高峰, 张赛, 张亚南, 等. 基于改进 DehazeNet 的图像去雾方法[J]. 计算机系统应用, 2021, 30(5): 208-213.  
WANG G F, ZHANG S, ZHANG Y N, et al. Defogging method based on improved DehazeNet[J]. Computer Sys-

- tems & Applications, 2021, 30(5): 208-213. (in Chinese)
- [23] 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.
- [24] 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). Piscataway: IEEE, 2019: 1375-1383.
- [25] 肖进胜, 申梦瑶, 雷俊锋, 等. 基于生成对抗网络的雾霾场景图像转换算法[J]. 计算机学报, 2020, 43(1): 165-176.
- XIAO J S, SHEN M Y, LEI J F, et al. Image conversion algorithm for haze scene based on generative adversarial networks[J]. Chinese Journal of Computers, 2020, 43(1): 165-176. (in Chinese)
- [26] LI L, DONG Y L, REN W Q, et al. Semi-supervised image dehazing[J]. IEEE Transactions on Image Processing, 2020, 29: 2766-2779.
- [27] 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). Piscataway: IEEE, 2020: 2805-2814.
- [28] ZHAO S Y, ZHANG L, SHEN Y, et al. RefinedNet: A weakly supervised refinement framework for single image dehazing[J]. IEEE Transactions on Image Processing, 2021, 30: 3391-3404.
- [29] WU R Q, DUAN Z P, GUO C L, et al. RIDCP: Revitalizing real image dehazing via high-quality codebook priors[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2023: 22282-22291.
- [30] LI B Y, GOU Y B, GU S H, et al. You only look yourself: Unsupervised and untrained single image dehazing neural network[J]. International Journal of Computer Vision, 2021, 129(5): 1754-1767.
- [31] 贾童瑶, 卓力, 李嘉锋, 等. 基于深度学习的单幅图像去雾研究进展[J]. 电子学报, 2023, 51(1): 231-245.
- JIA T Y, ZHUO L, LI J F, et al. Research advances on deep learning based single image dehazing[J]. Acta Electronica Sinica, 2023, 51(1): 231-245. (in Chinese)
- [32] JIN H H, QIAN L J, GAO J, et al. Polarimetric calculation method of global pixel for underwater image restoration[J]. IEEE Photonics Journal, 2021, 13(1): 6800315.
- [33] HE K M, SUN J, TANG X O. Guided image filtering[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(6): 1397-1409.
- [34] 赵峰, 程喜萌, 冯斌, 等. 分焦平面偏振图像插值算法的比较研究[J]. 激光与光电子学进展, 2020, 57(16): 161014.
- ZHAO F, CHENG X M, FENG B, et al. Comparison research of interpolation algorithms for division of focal plane polarization image[J]. Laser & Optoelectronics Progress, 2020, 57(16): 161014. (in Chinese)
- [35] 李大鹏, 禹晶, 肖创柏. 图像去雾的无参考客观质量评测方法[J]. 中国图象图形学报, 2011, 16(9): 1753-1757.
- LI D P, YU J, XIAO C B. No-reference quality assessment method for defogged images[J]. Journal of Image and Graphics, 2011, 16(9): 1753-1757. (in Chinese)
- [36] MITTAL A, MOORTHY A K, BOVIK A C. No-reference image quality assessment in the spatial domain[J]. IEEE Transactions on Image Processing, 2012, 21(12): 4695-4708.
- [37] 李金才, 马自辉, 彭宇行, 等. 基于图像熵的各向异性扩散相干斑噪声抑制[J]. 物理学报, 2013, 62(9): 582-591.
- LI J C, MA Z H, PENG Y X, et al. Speckle reduction by image entropy anisotropic diffusion[J]. Acta Physica Sinica, 2013, 62(9): 582-591. (in Chinese)

## 附录 A

将以  $\Omega$  为局部区域, 求取暗通道图像的方法用 DK 表示, 将暗通道先验算法<sup>[11]</sup>与大气物理退化模型结合, 可得:

$$\text{DK}\left(\frac{\mathbf{I}}{\mathbf{A}_\infty}\right) = t(x) \cdot \text{DK}\left(\frac{\mathbf{J}}{\mathbf{A}_\infty}\right) + 1 - t(x) \quad (\text{A-1})$$

其中,  $t(x)$  是以  $x$  为中心的局部区域  $\Omega(x)$  透射率. 由于目标反射光强  $\mathbf{J}$  本质是无雾图像, 目标区域有  $\text{DK}\left(\frac{\mathbf{J}}{\mathbf{A}_\infty}\right) \rightarrow 0$ , 代入式(A-1)可得

$$t(x) = 1 - \text{DK}\left(\frac{\mathbf{I}}{\mathbf{A}_\infty}\right) \quad (\text{A-2})$$

天空区域的场景光强非常接近  $\mathbf{A}_\infty$ , 又天空区域传输距离近似为  $\infty$ , 透射率近似为 0, 因此式(A-2)可同时涵盖目标区域与天空区域. 由式(A-2), 可得透射率的简单估计  $t_{\text{dark}}$ . 由于暗通道算法是基于区块的,  $t_{\text{dark}}$  存在明显的块效应. 为消除块效应, 以场景光强  $\mathbf{I}$  为引导图像, 对  $t_{\text{dark}}$  进行引导滤波<sup>[33]</sup>, 得到优化的透射率  $\hat{t}_{\text{dark}}$ . 进一步估计直接透射光  $\mathbf{D}_{\text{dark}}$ :

$$\mathbf{D}_{\text{dark}} = \mathbf{I} - \mathbf{A}_{\text{dark}} = \mathbf{I} - \mathbf{A}_\infty (1 - \hat{t}_{\text{dark}}) \quad (\text{A-3})$$

## 附录 B

由式(1)与式(5),可将目标偏振度表示如下:

$$\rho_D = \frac{I}{I-A} \rho - \frac{A}{I-A} \rho_A \quad (\text{B-1})$$

小区域内,场景光强  $I$  与大气光强  $A$  的变化是微弱的,即  $I$  与  $A$  是局部光滑的. 进一步假设在  $n \times n$  的小区域内,  $I$  与  $A$  不变. 设图像尺寸为  $M \times N$ ,  $\omega_k$  为  $n \times n$  的小窗口,则式(B-1)可表示为

$$\rho_D(i, j) = a_k \rho(i, j) + b_k \quad (\text{B-2})$$

其中,  $(i, j)$  表示窗口  $\omega_k$  中的像素,  $k \in M \times N$ .

为减小大气光强  $A$  对目标偏振度估算的影响,以式(6)中  $D(\rho_D)$  的梯度特征逼近  $D_{\text{dark}}$  的梯度特征,通过对小窗口内所有像素  $D(\rho_D)$  与  $D_{\text{dark}}$  的梯度特征差进行累计平方求和,在小窗口  $\omega_k$  中构建代价函数:

$$E(a_k, b_k) = \sum_{i, j \in \omega_k} \left[ \left( \nabla \frac{1}{D(\rho_D)} - \nabla \frac{1}{D_{\text{dark}}} \right)^2 + \varepsilon a_k^2 \right] \quad (\text{B-3})$$

其中,  $\varepsilon$  为趋于0的正则化参数,本文取  $\varepsilon = 10^{-4}$ ;  $\nabla$  为梯度算子:  $\nabla(\cdot) = \sqrt{G_x^2(\cdot) + G_y^2(\cdot)}$ , 其中  $G_x(\cdot)$  与  $G_y(\cdot)$  为 sobel算子的  $x$  方向与  $y$  方向梯度函数. 将式(6)、式(B-2)代入式(B-3),得

$$E(a_k, b_k) = \sum_{i, j \in \omega_k} \left[ \left( \nabla \frac{\rho_A - a_k \rho - b_k}{I(\rho_A - \rho)} - \nabla \frac{1}{D_{\text{dark}}} \right)^2 + \varepsilon a_k^2 \right] \quad (\text{B-4})$$

令  $G = \frac{1}{I(\rho_A - \rho)}$ ,  $H = \nabla \frac{1}{D_{\text{dark}}}$ , 则上式简化为

$$E(a_k, b_k) = \sum_{i, j \in \omega_k} \left[ \left( \nabla [G(\rho_A - a_k \rho - b_k)] - H \right)^2 + \varepsilon a_k^2 \right] \quad (\text{B-5})$$

进一步求得  $a_k$  与  $b_k$ :

$$a_k = \frac{\sum_{i, j \in \omega_k} \left\{ (H - s \cdot \nabla G) [m \cdot \nabla G - \nabla(G \cdot \rho)] \right\}}{\sum_{i, j \in \omega_k} [m \cdot \nabla G - \nabla(G \cdot \rho)]^2 + \varepsilon n^2} \quad (\text{B-6})$$


$$b_k = \rho_A - a_k m - s \quad (\text{B-7})$$

其中,  $m = \frac{\sum_{i, j \in \omega_k} [\nabla(G \cdot \rho) \nabla G]}{\sum_{i, j \in \omega_k} (\nabla G)^2}$ ,  $s = \frac{\sum_{i, j \in \omega_k} (H \cdot \nabla G)}{\sum_{i, j \in \omega_k} (\nabla G)^2}$ .

至此,可以估算目标偏振度为

$$\rho_D = \rho_A + a_k(\rho - m) - s \quad (\text{B-8})$$

## 作者简介




徐万春 男, 2000年出生, 山东临沂人. 国防科技大学电子科学学院博士研究生. 主要研究方向为光学目标识别.

E-mail: xuwanchun@nudt.edu.cn




张焱 女, 1975年出生, 山东济南人. 国防科技大学电子科学学院研究员、博士生导师. 主要研究方向为光学目标识别.

E-mail: atrthreefire@sina.com



张景华 男, 1994年出生, 河南夏邑人. 军事科学院助理研究员. 主要研究方向为目标特性分析、自动目标检测识别.

E-mail: 965477460@qq.com



凌峰 男, 1996年出生, 安徽马鞍山人. 国防科技大学电子科学学院博士研究生. 主要研究方向为光学目标识别.

E-mail: lingfeng@nudt.edu.cn



李顺 男, 1993年出生, 山东乳山人. 2018年获得国防科技大学工学硕士学位. 主要研究方向为雷达图像处理.

E-mail: 18844193650@163.com