

## 生成对抗映射网络下的图像多层感知去雾算法

李 策<sup>1,2)</sup>, 赵新宇<sup>1)</sup>, 肖利梅<sup>1)</sup>, 杜少毅<sup>2)</sup>

<sup>1)</sup>(兰州理工大学电气工程与信息工程学院 兰州 730050)

<sup>2)</sup>(西安交通大学电子与信息工程学院 西安 710049)  
(xjtulice@gmail.com)

**摘要:** 雾霾常会影响获取图像的质量, 单幅图像去雾是一个具有挑战性的不适宜问题. 针对传统的去雾方法存在去雾结果颜色失真、适用范围局限等问题, 提出一种基于深度网络的去雾算法——生成对抗映射网络的多层感知去雾算法. 在训练阶段中, 利用生成对抗映射网络里判别网络与生成网络间对抗式训练机制, 保证生成网络中参数的最优解; 在测试还原过程中, 先提取有雾图像中雾气相关特征, 并利用训练得到的生成网络对提取特征进行多层感知映射, 进而得到反映雾气深度信息的透视力, 最终运用得到的透视力实现了图像去雾. 实验结果表明, 与同类算法相比, 该算法能较好地还原出场景中目标的真实色彩, 并抑制部分噪声, 去雾效果明显.

**关键词:** 生成对抗映射网络; 多层感知; 雾气相关特征  
**中图分类号:** TP391.41

## Generative Adversarial Mapping Nets with Multi-layer Perception for Image Dehazing

Li Ce<sup>1,2)</sup>, Zhao Xinyu<sup>1)</sup>, Xiao Limei<sup>1)</sup>, and Du Shaoyi<sup>2)</sup>

<sup>1)</sup>(College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050)

<sup>2)</sup>(The School of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049)

**Abstract:** Haze has an impact on the quality of the image. Single image dehazing is a challenging ill-posed problem. The traditional dehazing methods have some problems, such as color distortion and limited application scope. To overcome these problems, we propose a generative adversarial mapping nets(GAMN) algorithm for image dehazing. In the training, an adversarial learning mechanism between the generative networks and the discriminative networks was used to obtain the optimal solution of parameters. In the testing, the trained generative networks can translate the haze related features to the medium transmission by multilayer Perception, the medium transmission is related to the depth and help to complete dehazing. Experimental results show that the proposed algorithm is closer to the real color compared with the state-of-the-art method. It can restrain noise and dehaze clearly.

**Key words:** generative adversarial mapping nets; multi-level perception; the haze related features

在自然场景中, 由于水气或空气中悬浮颗粒的存在, 造成雾或霾的出现, 导致图像采集过程中图像对比度降低、场景中部分细节丢失与颜色的偏

移, 使得图像中特征信息发生丢失与改变, 直接降低与限制了基于图像特征进行识别、分割和检测等算法的效果. 因此, 对有雾图像进行去雾处理, 在

收稿日期: 2016-12-19; 修回日期: 2017-03-13. 基金项目: 国家自然科学基金(61365003); 甘肃省基础研究创新群体项目(1506RJIA031); 中国博士后科学基金(2014M550494). 李 策(1974—), 男, 博士, 教授, 博士生导师, CCF 会员, 主要研究方向为计算机视觉、机器学习、智能机器人; 赵新宇(1990—), 男, 硕士研究生, CCF 学生会员, 主要研究方向为计算机视觉; 肖利梅(1978—), 女, 硕士, 高级工程师, 主要研究方向为计算机视觉、图像增强; 杜少毅(1980—), 男, 博士, 副教授, 博士生导师, 主要研究方向为计算机视觉、图像处理.

计算机视觉与人工智能等领域具有重要的研究价值。

早期的图像去雾算法中,大多是基于同一场景下,通过多幅图像获取雾气场景的深度信息. Narasimhan 等<sup>[1]</sup>提出结合场景多个角度进行深度信息的提取,利用二值散射模型提取不同天气条件下彩色图像场景深度信息,但此种方法只适用于雾气较薄的环境. Schechner 等<sup>[2]</sup>提出了大气光中不同散射光具有偏振特性的假设,通过不同方向上的偏振光恢复场景深度信息. Kopf 等<sup>[3]</sup>利用已知的 3D 模型获取场景深度信息,进而复原雾气图像. 利用多幅图像协同去雾的算法借助相同场景下不同天气状况的多幅图像进行去雾,由于其很难满足对相同场景下在不同环境的图像采集,故此类算法在应用中有诸多限制. 因雾天场景中的图像颜色退化程度与其深度信息相关,所以另一些学者提出利用图像增强的方法进行单幅图像去雾. 例如, Jobson 等<sup>[4]</sup>提出利用 Retinex 图像增强算法进行去雾处理; Tan 等<sup>[5]</sup>提出了利用图像局部对比度最大化的去雾方法,其在对雾气较浓区域取得较好的去雾效果,但使得去雾后的整体图像颜色过饱和. 此外, Fattal 等<sup>[6]</sup>基于光线传播与场景中阴影区域局部不相关的假设,估算出场景中的反照率. He 等<sup>[7]</sup>提出一种基于暗通道去雾的方法,为有雾图像引入了暗通道先验特性. 后续在此基础上又提出了一些改进的去雾方法<sup>[8-9]</sup>,但由于透视率与大气光值估计偏高,导致该算法无法对天空、白色建筑等高亮区域存在的场景进行有效的去雾. Meng 等<sup>[10]</sup>提出了有雾图像物理模型的几何约束,并引入区域间的相关约束信息,预估出图像中的透视率完成去雾. 由于算法中所提约束模型无法准确地描述有雾图像中物理量间的相关性,所以无法得到准确透视率. 针对此问题, Tang 等<sup>[11]</sup>提出了结合有雾图像中的多种特征,通过随机森林进行训练,以便得到最优的透视率. Cai 等<sup>[12]</sup>提出了利用卷积神经网络训练的方法寻找最优透视率方法,并且收到比较好的实验效果. 由于大气光散射模型只考虑单一光源模型,在实际场景中,往往存在多光源情况,基于此, Li 等<sup>[13-14]</sup>又提出了夜间多光源去雾模型.

尽管去雾算法得到了迅速发展,但由于有雾图像中先验信息不足,图像去雾本质上是一个欠约束问题,致使目前已有算法都无法取得令人满意的效果,去雾结果也存在颜色偏移与所提先验信息制约算法适用范围等问题. 为了得到更能反

映真实场景信息的透视率,并且降低对有雾图像中先验信息的依赖,本文提出了一种基于生成对抗映射网络(generative adversarial mapping nets, GAMN)的图像去雾算法,运用 GAMN 网络建立有雾图像中相关特征到透视率间的映射关系,从而获得了更加有效的去雾效果.

## 1 模型与雾气相关特征描述

### 1.1 大气光散射模型

雾气场景中,由于大气颗粒对光线的散射,造成场景中目标表面的反射光散射损失,使其光强降低,且随传播距离呈指数衰减,同时在反射光传播过程中,附加了环境中大气光源,并随着传播距离的增加而改变光强,如图 1 所示. 根据上述大气光散射理论,在计算机视觉与图形学中,形成了广泛使用的大气光散射模型

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

其中,  $I$  表示采集到的有雾图像,  $J$  是去雾后的场景图像,  $t$  为光线传播介质的透视率,  $A$  表示大气光值,  $x$  为图像中的像素点. 在场景中大气颗粒分布均匀且同质的前提下,透视率  $t = e^{-\beta d(x)}$  描述透视率随光线传播距离呈指数衰减;  $\beta$  为大气散射系数;  $d$  为场景与相机间的距离.




图 1 大气光散射模型

在光线传播过程中,由于光线传输过程中存在损失,所以在 RGB 空间中的三通道中,预估透视率满足  $0 \leq \tilde{t} \leq 1$ , 并且  $\tilde{t}$  为 RGB 空间中的透视率. 在预估透视率中,由于透视率相关约束或先验信息不足,导致透视率估计存在偏差. 假设在同一场景中,相同光照下有雾图像与无雾图像都存在的情况下,则有

$$t_{\text{dist}}(x) = \frac{\|A - I^c(x)\|}{\|A - J^c(x)\|};$$

其中,  $t_{\text{dist}}$  为预估得到的最优透视率, 且满足  $0 \leq t_{\text{dist}}(x) \leq 1$ ;  $c$  为 RGB 中通道标号. 在有限的条件下求解透视率, 传统的方法都无法准确界定. 为解决此类不适宜问题, 本文利用机器学习的方法, 在有雾图像中引入去雾规则, 构建无监督学习网络, 完成有雾图像到透视率的映射, 最终实现了有雾图像的去雾还原.

## 1.2 雾气相关特征

### 1.2.1 色调差异度

对于雾气场景图像, Ancuti 等<sup>[15]</sup> 提出了图像中无雾区域的色调与其半反转色调存在差异, 即色调差去雾算法. 半反转图像定义为

$$I_{\text{si}}^c(x) = \max[I^c(x), 1 - I^c(x)];$$

其中,  $c \in \{r, g, b\}$ . 色调差特征表示为

$$\Delta H(I) = |H_{\text{si}} - H|;$$

其中,  $H_{\text{si}}$  与  $H$  分别表示半反转色调与原色调, 并对  $\Delta H(I)$  进行归一化, 把  $[0^\circ, 360^\circ]$  化归到  $[0, 1]$ . 通过色调差特征的引入, 可以有效地划分出有雾区域与无雾区域, 并可以较好保持图像中的细节信息.

### 1.2.2 局部最大饱和度

雾气场景中, 存在雾气对反射光线的遮挡, 使得图像中色彩的饱和度下降, 所以在雾气图像中存在饱和度降低特性. 通过对图像饱和度的调节, 可实现图像中雾气的粗去除. 根据上述特性, Tang 等<sup>[11]</sup> 提出了有雾图像中局部最大饱和度特征, 即假设图像中局部饱和度一致, 局部最大饱和度特征为

$$S_r(I) = \max_{y \in \Omega(x)} \left( 1 - \frac{3 \max_{c \in \{r, g, b\}} I^c(x)}{I^r(x) + I^g(x) + I^b(x)} \right);$$

其中,  $\Omega(*)$  是  $r \times r$  的局部区域;  $y$  是区域  $\Omega(*)$  内像素值. 同时, 选取多种尺度最大饱和度特性作为输入.

### 1.2.3 局部最大矢量对比度

有雾图像中, 雾气的存在降低了图像对比度, 造成图像细节信息的丢失, Tan 等<sup>[5]</sup> 为提高图像的可视性, 提出了局部最大化对比度的去雾方法. 但在局部最大化对比度过程中, 由于无法准确反映出局部对比度变化方向, 会造成局部区域内无变化区域受变化区域影响. 如图 2 所示, 在提取局部区域中, 区域 1 中没有对比度变化, 而区域 2 中存在对比度变化, 在局部区域内, 若按局部最大对比度选取特征, 区域 1 受到区域 2 影响. 故针对有雾

图像, 为解决局部最大对比度特征存在的不足, 本文提出了局部最大矢量对比度特征, 在局部最大对比度特征基础上, 加入对比度方向信息, 以解决局部对比度提取中过度估计的问题, 进而保留了更多细节信息. 各通道内对比度定义为

$$C(I^c(x)) = \sqrt{\frac{1}{|\Omega_s(x)|} \sum_{z \in \Omega_s(x)} \|I^c(x) - I^c(z)\|^2};$$

其中,  $c \in \{r, g, b\}$ ;  $|\Omega_s(x)|$  为  $s \times s$  区域内的像素点个数;  $\Omega_s(x)$  为  $s \times s$  的局部区域; 本文中, 设  $s = 3$ . 在局部区域内, 为反映出对比度方向差异, 在  $s \times s$  区域内, 梯度变化最大处定义为对比度主方向. 如图 3 所示, 在  $3 \times 3$  局部区域中, 定义对比度主方向为梯度变化最大方向, 并对像素点 8 邻域进行编码, 其中主方向为 1, 其余方向量为 0, 且 8 邻域内方向信息编码值为唯一确定, 记为  $D_s(I^c(x))$ . 图 3 中, 对比度方向量为“11001000”.




图 2 局部对比度变化图




图 3 局部对比度方向信息图

在局部区域内, 对于区域内方向一致的对比度, 选取对比度最大值作为该方向上局部区域对比度, 故定义局部最大矢量对比度为

$$CV(I^c(x)) = \begin{cases} \sum_{x, y \in \Omega_r, x \neq y} \left[ \max_{z \in \{x, y\}} C(I^c(z)) \times 256 + D_s(I^c(x)) \right] \times 0.0039, & D_s(I^c(x)) \& D_s(I^c(y)) \neq 0 \\ \sum_{x, y \in \Omega_r, x \neq y} \left[ C(I^c(x)) \times 256 + D_s(I^c(x)) \right] \times 0.0039, & D_s(I^c(x)) \& D_s(I^c(y)) = 0 \end{cases}$$

其中, “&” 为按位“与”运算. 有雾图像中由于雾气与矢量对比度具有负相关性, 因此令其为训练

输入特征,并用多尺度局部最大矢量对比度降低场景对特征提取的影响.

1.2.4 暗通道

暗通道是指在非天空无雾区域,像素点对应的 RGB 三通道中,至少存在一个通道具有低亮度值<sup>[7]</sup>,可表示为  $D_r(x) = \min_{y \in \Omega_r(x)} \left( \min_{c \in \{r,g,b\}} (I^c(x)) \right)$ ; 其中,  $\Omega_r$  表示  $r \times r$  的局部区域. 区域半径  $r$  反映了加入先验信息的强弱,较大的  $r$  会造成去雾过程中的过度还原,故运用多尺度暗通道特性作为输入,以降低加入先验强度不合适问题.

1.2.5 光辉特性

Narasimhan 等<sup>[1]</sup>最早提出了夜间多光源模型,并将其运用到有雾图像的去雾还原.在此基础上, Li 等<sup>[13]</sup>提出了长尾理论来降低雾气图像中光源出现的光辉特性.但是,在真实有雾图像中,场景中出现的“长尾”现象不仅存在光源处,同时也发生在雾气存在的所有场景里.有雾图像中均满足长尾理论<sup>[13]</sup>,所以定义图像中光辉特性层  $A^\infty$  满足

$$\min_x E(J^*) = \min_x \sum_x \left( \sum_{i=1}^2 \rho(J^*(x) \otimes f_i) + \lambda (A^\infty \otimes f_3)^2 \right),$$

$$\text{s.t. } 0 \leq J^*(x) \leq I(x),$$

$$\sum_x J_r^*(x) = \sum_x J_g^*(x) = \sum_x J_b^*(x).$$

其中,  $A^\infty = I(x) - J^*(x)$  表示光辉特性层,即场景中非大气光光线与目标间相互干扰的散射光线,且  $J^*(x) = J(x)t(x) + \alpha_0 A(1-t(x))$ ;  $J_r^*(x)$ ,  $J_g^*(x)$ ,  $J_b^*(x)$  分别表示  $J^*(x)$  在 RGB 三通道内对应值,  $\otimes$  为卷积运算;  $f_1 = [-1 \ 1]$ ,  $f_2 = [-1 \ 1]^T$ ,  $f_3 = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$  分别表示水平方向微分滤波器、垂直方向微分滤波器与拉普拉斯滤波器,且  $\rho(s) = \min(s^2, \tau)$ ;  $\tau$  为输入图像梯度下限值.

2 去雾生成对抗映射网络

在去雾还原过程中,如图 4 所示,首先对透视率进行预估,然后结合大气光散射模型进行去雾还原.为估计出最优透视率,构建雾气相关特征到透视率间的映射网络——GAMN. 本文方法 GAMN 是基于深度学习中生成对抗网络(generative adversarial

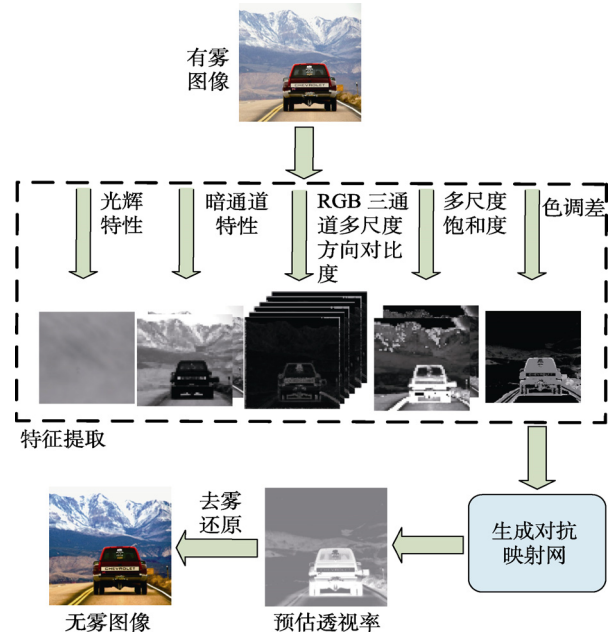


图 4 有雾图像去雾还原

nets, GAN)构建的映射网络, GAN 是由 Goodfellow 等<sup>[16]</sup>首次提出,并在后续得到广泛研究<sup>[17-18]</sup>.

2.1 生成对抗映射网络 GAMN

GAMN 算法是一种训练生成模型架构,通过对输入特征多层网络感知映射得到生成透视率. GAMN 由 2 部分组成:生成网络  $G(*)$  与判别网络  $D(*)$ . 生成网络  $G(*)$  主要学习构建有雾图像相关特征到透视率间的映射网络,得到生成透视率,并通过判别网络对生成透视率与最优透视率进行判别区分.  $G(*)$  与  $D(*)$  满足

$$\min_G \max_D T(D, G) = E_{t_{\text{dist}} \sim p_{\text{data}}(t_{\text{dist}})} [\log D(t_{\text{dist}})] + E_{\tilde{t} \sim p_t(\tilde{t})} [\log(1 - D(G(F)))]$$

其中,  $t_{\text{dist}}$  为从训练样本中获取的最优透视率,其作为判别过程中的判别透视率,且从样本中得到的判别透视率  $t_{\text{dist}}$  满足分布  $p_{\text{data}}$ ;  $\tilde{t}$  为  $G(*)$  得到的生成透视率,服从分布  $p_t$ .  $F$  为输入特征,即从有雾图像样本中提取的训练特征. 对于网络  $D(*)$ ,其功能是最大限度地区分出判别透视率与生成透视率;而对于网络  $G(*)$ ,则最小化  $(1 - D(G(F)))$ ,令  $D(*)$  无法正确判别生成透视率,以此形成整体网络对抗式训练,提高整体网络鲁棒性,减少预估结果偏离真实情形的程度.

2.1.1 判别网络

判别网络主要是对输入的透视率进行判别分类,

得到正确的判别概率. 由于透视率与图像深度信息存在一定相关性, 且深度信息在实际场景中是一种渐变信息, 所以真实场景中的透视率存在一定变化规则. 而对于生成透视率, 因其构造中存在偏差, 使得生成后的结果不能满足真实场景下的变化规则, 无法准确地反映出雾气场景光线传输状态. 针对于此, 可通过卷积神经网络对透视率进行特征提取, 得到表征透视率变化规则的特征, 并用此特征作为透视率判别标准, 判别出 2 种透视率的判别概率, 如图 5 所示. 在对卷积层进行训练中, 训练的精度受到初始参数影响, 参数更新与每层输入节点梯度变化有关, 容易使训练后得到饱和的非线性模型. 为降低输入与初始化对参数更新的影响, 提高训练学习速度, 在判别网络中引入批标准化层<sup>[19]</sup>, 并且批标准化层包括归一化与激活函数 ReLU. 随后利用卷积网络对输入信息进行多层感知, 逐层提取透视率中雾气相关特征, 并进行高阶特征全连接判别出 2 种透视率.

2.1.2 生成网络

图 6 所示为生成网络结构图. 雾气场景中透视率与有雾图像饱和度、色调差、矢量对比度、暗通道以及光辉特性等特征有关, 故可利用卷积网络对上述特征逐层抽象化, 结合 ReLU 对多种透视率相关信息进行融合与特征提取, 得到雾气场景中透视率相关抽象特征. 由于提取的高度抽象特征

具有表征透视率的特性, 包含了透视率信息, 故对其进行映射还原即可获得所需透视率. 利用步幅卷积网络<sup>[20]</sup>对抽象特征进行感知分解, 并通过 Sigmoid 激活函数映射将得到场景中透视率. 为解决网络训练初始化与损失函数下降梯度过小的影响, 在生成网络中加入批标准化层. 为使得得到透如视率信息更可靠地反映场景实际情况, 在生成网络中加入空间池化层, 对得到的粗透视率信息进行特征提取与稀疏处理, 以保证生成网络最终得到最优透视率.

2.2 网络训练

在训练 GAMN 中, 需要有雾图像与对应场景中的无雾图像, 但在应用过程中很难获得有雾图像相同场景与光照下的无雾图像. 为得到合适的训练样本, 假设图像中透视率满足: (1) 样本中图像场景的透视率是相对独立的, 不同图像中所具有的传播透视率是不同的; (2) 在图像中, 局部透视率是恒定的. 基于上述假设, 利用大气光散射模型  $\hat{I}(x) = J(x)\hat{t}(x) + A(1-\hat{t}(x))$  进行雾化处理. 对于给定无雾图像  $J(x)$ , 随机给定透视率  $\hat{t}$ , 且满足  $\hat{t} \in (0,1)$ . 为了减少学习中不确定因素, 本文构造样本使用的大气光值设定为  $A=1$ . 训练样本是从网络上选取多种场景图像, 用于降低背景对网络训练中影响.




图 5 判别网络结构图




图 6 生成网络结构图

在本文训练模型中,运用多层感知器构建生成网络.为确保生成网络得到最优透视率,利用判别网络对生成网络进行反向调节.生成对抗网络通过随机梯度下降法(stochastic gradient descent, SGD),结合给定数据标签进行网络参数优化,最终训练得到最优网络参数.

### 3 去雾还原

在大气光散射模型中,一般假设为均匀大气光,本文选用三通道内像素最大值作为全局大气光值.

根据 GAMN 模型预估出有雾图像中透视率,并结合全局大气光值,按照式(1)得到去雾后图像.本文去雾方法基于大气光散射模型,利用生成网络得到有雾图像中最优透视率,以降低以往预估透视率过高问题;通过样本的多样性与输入特征的多尺度变换,降低了图像背景对训练的影响.

### 4 实验与结果分析

为了验证本文去雾算法的有效性,将实验结果与其他算法<sup>[7,10,12]</sup>的实验进行主客观结果对比,由于本文仅在 CPU 模式训练测试, GPU 模式下将可进一步提升算法运行时间.本文算法所用训练

样本是从网上获取 5 000 幅  $256 \times 256$  无雾图像.对每一幅无雾图像,随机生成透视率  $t \in (0,1)$ ,并且大气光值设定为  $A=1$ ,由式(1)产生相应的 5 000 幅有雾图像.在训练映射网络中,进行 5 000 次迭代,学习率从 0.005 下降到  $2.96E-5$ .预估还原中,为避免透视率过低造成的还原图像像素值过高,设定透视率下限值为 0.003.同时,本实验依赖于 Torch7,运行环境为 64 位 Ubuntu,计算机配置为 CPU Inter(R) Core(TM) i7-4170 M 2.5 GHz,内存 16 GB.

#### 4.1 预估透视率对比实验

图 7 所示为分别运用与其他算法<sup>[7,10,12]</sup>对图 7a 中样本进行透视率预估,并与给定透视率进行对比.图 7a 分别为无雾图像、合成有雾图像、给定透视率样本;图 7b~7e 中,红点为给定透视率分布,其余点分别为文献<sup>[7,10,12]</sup>与本文预估透视率分布.从图 7 可以看出,文献<sup>[7,10]</sup>算法预估透视率都与给定透视率偏差较大,且预估结果整体分布低于给定透视率,文献<sup>[12]</sup>算法得到的透视率分布与给定透视率分布接近,但仍存在较大偏差,而本文算法得到的透视率分布与给定值更加接近.因而,本文算法具有更好的预估效果,更贴近真实场景透视率.

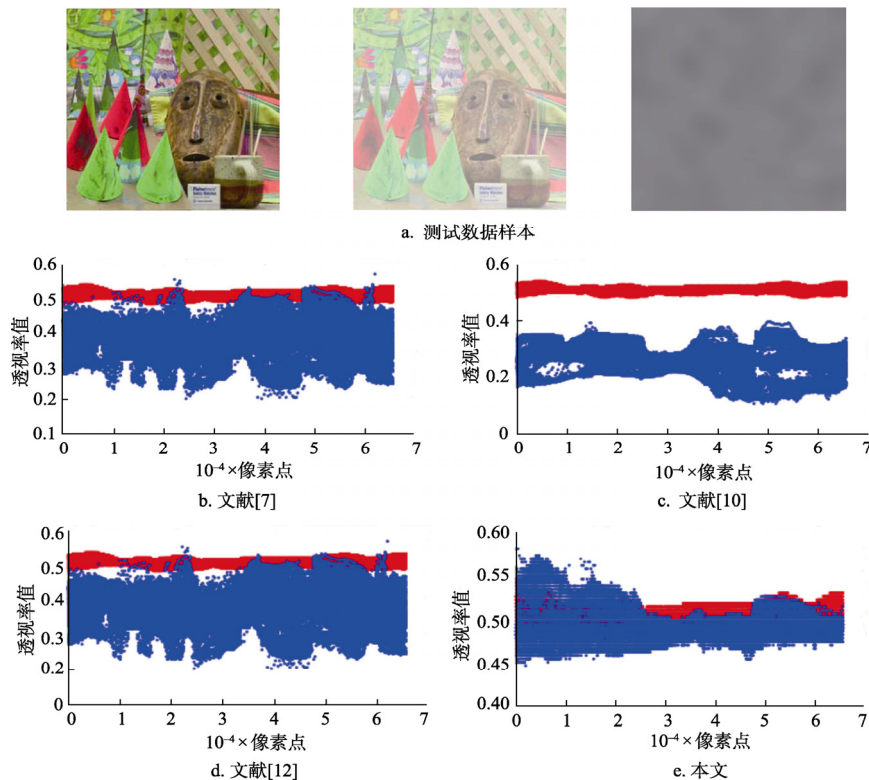


图 7 不同算法对单幅图像预估透视率对比图

### 4.2 合成图像对比实验

为进一步说明本文算法的去雾有效性, 将其与其他去雾算法<sup>[7,10,12]</sup>进行去雾实验比较, 如图 8 所示. 可以看出, 所有的去雾算法对有雾图像去雾后的结果图都存在一定的颜色过饱和, 并且从结果中可以看到, 文献[7]算法对于背景简单的显著性目标容易产生光晕, 颜色饱和度还原过高; 而文献[10]算法在处理有雾图像中, 容易导致颜色偏移, 造成图像失真严重; 文献[12]算法的算法在去雾过程中, 可以较好地保持原图像特性, 但对于具有多种颜色显著区域的场景, 其去雾还原结果存在较大偏差. 通过实验结果可以看出, 本文算法在保持图像原有属性基础上具有较好还原效果, 并在多种场景中都有表现较好的去雾还原效果, 可以准确地保持场景中的色调与饱和度. 为客观验证本文算法在去雾还原后可以保持较好的场景属性,

表 1 所示为本文算法与同类去雾算法在训练样本中的平均均方误差(mean square error, MSE)、结构相似度(structural similarity, SSIM)以及峰值信噪比(peak signal to noise ratio, PSNR). 可以看出, 本文算法较对比算法具有更小的 MSE、更高的 SSIM 和 PSNR, 说明其去雾还原后的结果具有更小的失真程度, 可更有效地保持场景原有结构, 且有效地降低算法引入噪声. 由于本文算法是基于雾气图像多特征得到透视率, 融合雾气图像中的多种信息, 降低预估透视率对单一先验信息的依赖, 减少偏差信息权重, 得到更真实还原结果. 同时, 本文的对抗式映射训练框架有效地减少了样本扰动与随机干扰对结果的影响, 故本文算法具有更好的鲁棒性. 实验结果表明, 去雾后的结果可以更加完整地保持同场景下原光照的情形, 并且在多种场景中表现较好结果.



图 8 合成雾气图像实验结果对比

表 1 不同算法对训练样本平均客观指标对比

指标	文献[7]	文献[10]	文献[12]	本文
MSE	1.532 8	1.750 9	1.051 2	<b>0.245 9</b>
SSIM	0.915 6	0.879 4	0.943 5	<b>0.991 2</b>
PSNR	20.784 2	19.200 5	24.432 0	<b>36.486 8</b>

### 4.3 真实图像对比实验

图 9 所示为对真实有雾图像的去雾效果图. 由于目前已有去雾算法对室外场景的去雾都有一定的效果, 但对于场景中存在白色或灰色的区域仍存在挑战, 所以本文选取具有天空和白色建筑的



图 9 真实有雾图像去雾结果对比

场景图像进行对比。从实验结果中可以看到，本文实验结果在上述场景中仍具有较好的去雾效果，通过 GAMN 从雾气图像中多种特征得到透视率，抽象提取了多种特征中与透视率相关信息，抑制了无用信息与噪声对预估透视率的影响，较为真实地映射出透视率信息，所得结果较同类去雾算法也具有较高的鲁棒性与泛化性。

## 5 结 语

本文提出了一种基于机器学习的自适应单幅图像去雾算法，运用 GAMN，结合有雾图像中多种相关特征，通过对抗式训练方式，得到特征到透视率的最优映射网，继而得到最优透视率，最终还原出相应场景下的无雾图像。通过实验可以得出，本文算法还原后的结果可以更好地保持无雾情形下原场景信息，且具有较高的鲁棒性与自适应性。

## 参考文献(References):

- [1] Narasimhan S G, Nayar S K. Chromatic framework for vision in bad weather[C] //Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2000: 598-605
- [2] Schechner Y Y, Narasimhan S G, Nayar S K. Instant dehazing of images using polarization[C] //Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2001: 325-332
- [3] Kopf J, Neubert B, Chen B, *et al.* Deep photo: model-based photograph enhancement and viewing[J]. *ACM Transactions on Graphics*, 2008, 27(5): 116-126
- [4] Jobson D J, Rahman Z, Woodell G. A. A multiscale 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
- [5] Tan R T. Visibility in bad weather from a single image[C] //Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2008: 2347-2354
- [6] Fattal R. Single image dehazing[J]. *ACM Transactions on Graphics*, 2008, 27(3): Article No.72
- [7] 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
- [8] Huang Lihong. Adaptive defogging algorithm of single image in color space[J]. *Journal of Computer-Aided Design & Computer Graphics*, 2015, 27(8): 1506-1511(in Chinese)  
(黄黎红. 色彩空间中的单幅图像自适应去雾算法[J]. *计算机辅助设计与图形学学报*, 2015, 27(8): 1506-1511)
- [9] Xue Mogen, Zhou Pucheng, Zhang Hongkun. Single foggy image restoration using orientation extended fields of experts[J]. *Journal of Computer-Aided Design & Computer Graphics*, 2014, 26(5): 782-787(in Chinese)  
(薛模根, 周浦城, 张洪坤. 利用方向延伸专家场的单幅雾天图像复原[J]. *计算机辅助设计与图形学学报*, 2014, 26(5): 782-787)
- [10] Meng G F, Wang Y, Duan J Y, *et al.* Efficient image dehazing with boundary constraint and contextual regularization[C] //Proceedings of IEEE International Conference on Computer Vision. Los Alamitos: IEEE Computer Society Press, 2013: 617-624
- [11] Tang K T, Yang J C, Wang J. Investigating haze-relevant features in a learning framework for image dehazing[C] //Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press.



- 2014: 2995-3002
- [12] 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
- [13] Li Y, Tan R T, Brown M S. Nighttime haze removal with glow and multiple light colors[C] //Proceedings of IEEE International Conference on Computer Vision. Los Alamitos: IEEE Computer Society Press, 2015: 226-234
- [14] Li Y, Brown M S. Single image layer separation using relative smoothness[C] //Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2014: 2752-2759
- [15] Ancuti C O, Ancuti C, Hermans C, *et al.* A fast semi-inverse approach to detect and remove the haze from a single image[C] // Proceedings of the 10th Asian Conference on Computer Vision. Heidelberg: Springer, 2010: 501-514
- [16] Goodfellow I, Pougetabadi J, Mirza M, *et al.* Generative adversarial nets[C] //Proceedings of Advances in Neural Information Processing Systems. Cambridge: MIT Press, 2014: 2672- 2680
- [17] Denton E, Chintala S, Szlam A, *et al.* Deep generative image models using a laplacian pyramid of adversarial networks[C] //Proceedings of Advances in Neural Information Processing Systems. Cambridge: MIT Press, 2015: 1486-1494
- [18] Bowman S R, Vilnis L, Vinyals O, *et al.* Generating sentences from a continuous space[C] //Proceedings of the 20th SIGNLL Conference on Computational Natural Language Learning. Pennsylvania: Association for Computational Linguistics Press, 2016: 10-21
- [19] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C] //Proceedings of the 32nd International Conference on Machine Learning. Cambridge: Microtome Publishing Press, 2015: 448-456
- [20] Springenberg J T, Dosovitskiy A, Brox T, *et al.* Striving for simplicity: the all convolutional net[C] //Proceedings of the 3rd International Conference on Learning Representations. Los Alamitos: IEEE Computer Society Press, 2015: 1-14