

# 基于自适应SLIC的遥感影像去雾算法

余航, 李晨阳, 刘志恒, 周绥平, 郭玉茹

西安电子科技大学 空间科学与技术学院, 西安 710126

**摘要:** 遥感影像由于雾霾的原因导致清晰度下降, 增添了遥感影像目标检测和地物分割任务的困难。本文提出一种基于自适应SLIC的遥感影像去雾算法, 首先, 针对有雾遥感影像出现局部区域高亮问题, 使用改进的Retinex算法, 对输入遥感影像进行对比度增强, 保留图像细节, 以减少伪影现象, 扩展图像的对比度动态范围, 准确估计遥感影像大气强度值; 其次, 提出了一种自适应SLIC算法, 解决超像素数目参数设定的困难, 对输入遥感影像进行超像素分割, 避免局部对比度强烈区域对固定窗口的影响, 从而获得更加精确的透射率估计; 最后, 基于暗通道先验原理和大气散射模型恢复出无雾遥感影像。本文使用所提算法和DCP、DOC、EVP和CHAL的4种算法进行对比, 分别在公开数据集Inria Aerial Image Dataset和RICE Image Dataset进行去雾效果比较。主观上, 所提算法处理后的遥感影像颜色更真实、去雾更彻底、地物更清晰, 能更好的保留影像细节信息; 客观上, 所提算法处理后的图像信息熵平均值为7.56, 峰值信噪比平均值为22.05, 结构相似性平均值为0.87, 均高于其他4种算法。本文所提出的去雾算法模型, 综合了图像增强与恢复的优点, 使得去雾后的遥感影像更加自然真实, 更好的恢复出遥感影像细节信息。

**关键词:** 遥感图像去雾, 自适应SLIC, 暗通道先验, Retinex, 超像素分割

**中图分类号:** TP751.1/P2

**引用格式:** 余航, 李晨阳, 刘志恒, 周绥平, 郭玉茹. 2024. 基于自适应SLIC的遥感影像去雾算法. 遥感学报, 28(12): 3158-3172

Yu H, Li C Y, Liu Z H, Zhou S P and Guo Y R. 2024. Remote sensing image dehazing algorithm based on adaptive SLIC. National Remote Sensing Bulletin, 28(12): 3158-3172 [DOI:10.11834/jrs.20242532]

## 1 引言

遥感RS (Remote Sensing) 影像被广泛地应用于军事 (Hudson和Hudson, 1975; 张朝阳等, 2008; Stevens, 1988; Qin等, 2021)、测绘 (Wang等, 2020; Liu等, 2022)、土地利用和农作物产量调查 (Mancini和Pirotti, 2021) 等。自然图像和遥感影像中的云雾是由相同或相似的物理原理引起的, 但由于成像传感器的距离不同, 遥感影像往往具有不同的场景深度估计 (Zhu等, 2021a)。由于雾霾或薄云的存在, 从远距离拍摄的RS影像通常质量差, 影响实际应用。对遥感影像进行云雾去除处理, 不仅可以提高目标的识别检测率, 而且可以提高遥感影像信息的解读率 (姜侯等, 2016; 孙航等, 2023)。因此, 去除云雾是后续RS图像处理和析的前提且具有挑战性。

目前, 遥感影像去雾方法主要有基于学习的方法、基于图像增强的方法、基于物理模型的方法。随着机器视觉技术的发展, 基于学习的遥感影像去雾方法近年来也取得了很大的发展。Jiang等 (2021) 提出一种基于编码器—解码器的遥感影像去雾方法, 利用小波变换提取图像低频信息, 解决了遥感影像雾霾分布不均匀问题。Zhu等 (2021a) 提出一种基于双自注意力提升残余倍频程卷积 (DOC) 的遥感影像去雾网络, 既可恢复遥感影像高频分量的细节, 又可恢复低频分量的结构信息, 从而提高遥感影像的整体质量。Liu等 (2022) 提出了一种门控背景聚合的遥感影像去雾网络, 能够直接学习输入图像和相应的无雾图像之间的映射关系, 不依赖于传统的大气散射模型。基于深度学习的图像去雾方法通常表现良好, 但其由于模型参数量较大, 且依赖标签遥感影像的质量, 学习遥感影

收稿日期: 2022-10-13; 预印本: 2023-04-20

基金项目: 中央高校基本科研业务费专项资金 (编号: JB211312, XJS221307); 陕西省自然科学基金 (编号: 2023-JC-QN-0299)

第一作者简介: 余航, 研究方向为合成孔径雷达图像理解与解译、模式识别和计算机视觉。E-mail: yuhang9551@163.com

通信作者简介: 李晨阳, 研究方向为计算机视觉、图像处理、去雾算法和机器学习。E-mail: chenyangli@stu.xidian.edu.cn

像特征需要耗费大量时间, 花费成本大。

基于图像增强的方法实质上是提高遥感影像的对比度实现去雾效果, 该类方法主要以 Retinex 算法 (Tang 等, 2021)、同态滤波算法 (Wu 和 Tan, 2020)、小波算法为 (Kumar 和 Naganaik, 2023) 和图像融合算法 (Huang 等, 2021) 为代表。该类方法能有效地提高图像清晰度, 但没有全面深入的考虑雾天遥感影像退化机理, 不能适应不同场景下的遥感影像, 且常常会丢失图像信息从而导致图像失真。

近年来, 基于物理模型的去雾算法取得了重大进展。这些算法通过分析图像退化的原因来建立数学模型, 并通过辅助或先验信息恢复遥感影像。Nayar 和 Narasimhan (1999) 以雾度天气图像成像过程进行模拟建模, 提出大气散射模型 (如式 (1)), 其物理意义在于: 利用局部最小值滤波, 对天空区域外大气光值  $A^c$  和透射率  $T(x)$  进行计算, 基于式 (1) 进而得到无雾的真实图像; He 等 (2009) 基于大气散射模型进而提出了基于暗通道先验原理 DCP (Dark Channel Prior) 的去雾方法, 表示为

$$I^c(x) = J^c(x)T(x) + A^c(1 - T(x)) \quad (1)$$

$$J^{\text{dark}} = \min_{y \in \Omega(x)} \left( \min_{c \in r, g, b} \frac{J^c(y)}{A^c} \right) \rightarrow 0 \quad (2)$$

式中,  $c$  为 RGB 通道,  $I^c(x)$  表示获取的有雾图像,  $J^c(x)$  表示原始的真实图像,  $A^c$  表示大气光强,  $T(x)$  为透射率,  $y$  为区域  $\Omega(x)$  中的像素,  $J^{\text{dark}}$  为暗通道图像。

DCP 易受到白色场景和天空区域等明亮区域的影响, 导致复原遥感影像残留雾气 (如图 1 中红色矩形框区域所示)。基于此, 国内外许多学者将大气散射模型和 DCP 引入遥感影像去雾研究中, 提出了许多改进方法。Jiao 等 (2012) 基于暗通道先验原理和大气散射模型, 使用低通高斯滤波器来细化透射率, 但是当遥感影像中具有稠密的雾时, 去雾后的遥感影像会出现色彩失真和细节信息丢失。Xie 等 (2018) 基于暗通道与无雾霾遥感图像饱和度的关系, 提出了暗通道饱和先验原理, 通过先验估计最优透射率实现去雾。该方法对非均匀雾气的遥感影像去雾效果较好, 而对于均匀雾气遥感影像去雾效果差。张峥等 (2019) 提出一种基于最小二乘的透射率优化方法, 通过计算先验可信度权重加权融合颜色线和暗通道先验估

计, 以获得更为准确的透射率分布。该方法通过在优化方程中加入梯度正则化约束, 避免了 halo 效应, 但是该方法需要手动设置相对长度阈值和调节指数, 导致去雾后的遥感影像可能出现局部残留雾的情况。Bi 等 (2022) 提出一种基于低秩稀疏先验 (LSP) 的单遥感影像去雾算法, 根据大气散射模型, 将有雾遥感影像的暗通道分解为两部分: 直接衰减的暗通道和低秩的大气面纱, 但当遥感影像中包含白色场景时, 该方法去雾后遥感影像出现颜色失真现象。




图 1 暗通道先验原理

Fig. 1 DCP

基于深度学习的遥感影像去雾方法, 由于模型参数量较大, 且依赖遥感影像数据量, 耗费时间多; 基于图像增强的遥感影像去雾方法没有充分考虑雾天遥感影像退化机理, 难以适应不同的场景下的遥感影像, 易丢失图像信息导致图像失真; 基于物理模型的遥感影像去雾方法, 在细化透射率时需要手动设置参数, 同时由于没有完整提升遥感影像的对比度, 导致去雾后的影像整体颜色偏暗, 局部区域残留雾气。针对上述问题, 基于图像增强和物理模型两类遥感影像去雾算法的优势, 对有雾遥感影像退化的原因进行分析, 提出一种基于自适应 SLIC 的遥感影像去雾算法。主要包括: (1) 针对有雾遥感影像出现局部区域高亮, 及大气强度值计算出现偏差问题, 提出改进的 Retinex 算法 iRetinex (improved Retinex), 对

有雾遥感影像进行整体对比度增强, 扩展影像的对比度动态范围, 提高遥感影像大气强度值准确率; (2) 为避免局部对比度强烈区域对固定窗口的影响, 提出一种基于自适应SLIC算法aSLIC (adaptive SLIC), 解决SLIC算法中超像素数目参数设定的困难, 对增强后的遥感影像进行超像素分割, 计算每个超像素块区域的透射率, 从而获得更加精确的透射率; (3) 最后基于暗通道先验原理和大气散射模型恢复出无雾遥感影像。所提出的方法无需手动设置参数, 可以实现对遥感影像的自适应去雾。

## 2 研究方法

有雾遥感影像可能存在局部对比度强烈区域, 导致大气强度值和透射率计算出现偏差; 同时现有

基于滑动窗口计算透射率的方法需要手动设置参数, 导致其难以自适应于不同的场景下的遥感影像。

为解决上述问题, 提高遥感影像去雾的质量, 基于图像增强和物理模型的遥感影像去雾方法, 提出一种基于自适应SLIC的遥感影像去雾算法。算法流程如图2所示, 首先, 提出一种改进的Retinex算法, 用于对输入有雾遥感影像进行整体对比度增强, 得到增强图像 $I^R$ , 避免局部区域高亮对大气强度值的影响; 提出aSLIC算法, 解决传统SLIC算法超像素数目设定困难, 基于aSLIC算法对增强图像 $I^R$ 进行超像素分割, 得到分割图像 $I_{aSLIC}^c$ , 分别计算每个超像素块区域的透射率, 避免局部对比度强烈区域的影响, 获得更加精确的透射率; 最后基于暗通道先验原理计算遥感影像的大气强度值 $A_R^c$ 和透射率 $T_{aSLIC}$ , 结合大气散射模型实现去雾。

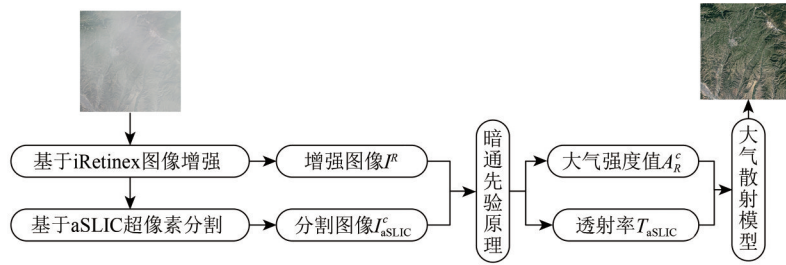


图2 算法流程图

Fig. 2 Algorithm flowchart

### 2.1 基于iRetinex增强的大气光值估计

Rahman等(1996)首先提出了Retinex算法理论, 可以在动态范围压缩、边缘增强和颜色恒常化3个方面取得平衡, 从而能够对多个不同种类的图像实现自适应的增强, 原理如下:

$$\begin{aligned} I(x,y) &= L(x,y) \cdot R(x,y) \\ L(x,y) &= I(x,y) \otimes G(x,y) \end{aligned} \quad (3)$$

式中,  $I(x,y)$ 表示一幅图像,  $L(x,y)$ 表示为照度分量,  $R(x,y)$ 为反射分量,  $\otimes$ 为卷积运算,  $G(x,y)$ 为高斯函数。反射分量 $R(x,y)$ 可以表示为

$$\log(R(x,y)) = \log(I(x,y)) - \log(I(x,y) \otimes G(x,y)) \quad (4)$$

针对遥感影像去雾实验发现 (如图3 (b) (e) 所示), 传统的基于高斯函数的Retinex图像增强算法, 不同于传统的线性、非线性方法, 只能增强图像某一种特征, 容易导致颜色失真现象, 细节信息丢失。

为解决该问题, 使用引导函数 $H(x,y)$ 替代Retinex

算法中的高斯函数 $G(x,y)$ , 提出了改进的Retinex算法 (improved Retinex)。引导函数是边缘保留函数, 通过引入边缘保留函数, 来解决图像伪像和局部区域过暗的问题。引导函数 $H(x,y)$ 的定义为

$$H(x,y) = \frac{1}{|\omega|} \sum_{\varepsilon_x, \varepsilon_y \in \omega(x,y)} (a(\varepsilon_x, \varepsilon_y) I(x,y) + b(\varepsilon_x, \varepsilon_y)) \quad (5)$$

式中,  $(\varepsilon_x, \varepsilon_y)$ 表示像素坐标,  $\omega(x,y)$ 表示以 $(x,y)$ 为中心, 半径为 $w$ 的矩形窗口,  $|\omega|$ 是 $\omega(x,y)$ 的像素数目,  $a(\varepsilon_x, \varepsilon_y)$ 和 $b(\varepsilon_x, \varepsilon_y)$ 表示线性系数。引导函数在图像边缘附近具有更好的性能, 可更好地保留图像细节信息。

如图3所示, 图3 (b) 为基于高斯函数的Retinex增强处理效果, 图3 (c) 为基于引导函数的Retinex增强处理效果。对比发现, 图3 (b) 中尽管对比度有所改善, 但是整体增强不均匀, 存在色彩不真实现象, 而图3 (c) 处理后的遥感影像更加均匀、真实、细节明显, 可以提高大气强度估计的准确性。



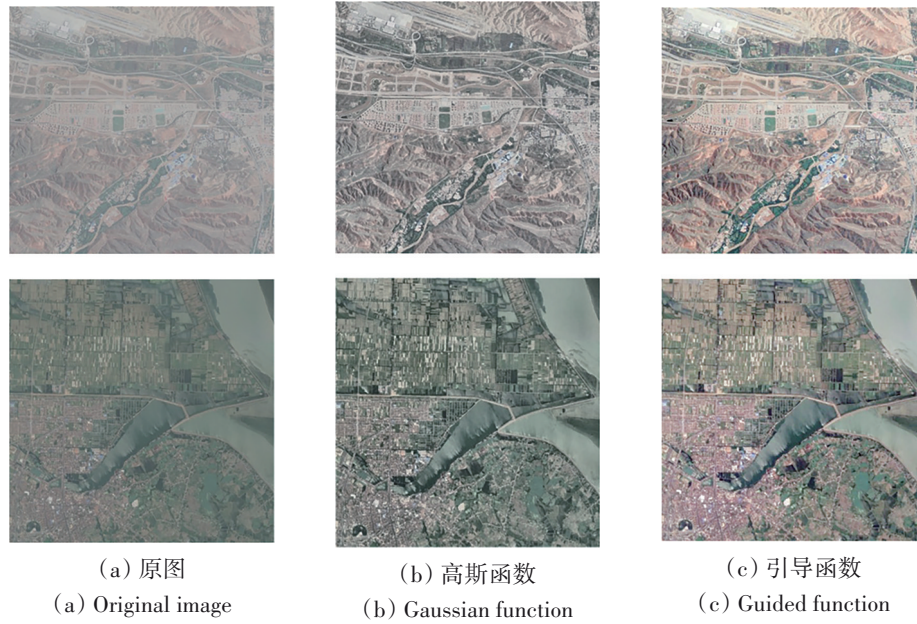


图3 图像增强对比

Fig. 3 Image enhancement comparison

基于 iRetinex 算法处理后的遥感影像, 根据式 (2), 可以得到准确的大气强度值  $A_R^c$ :

$$A_R^c = \left\{ \frac{A_{\text{sum}}^c(x)}{n} \right\} \quad (6)$$

式中,  $c \in \{r, g, b\}$ ,  $n$  为把图像的像素点按亮度由高至低排序, 选取前 0.1% 像素点的数量;  $A_{\text{sum}}^c(x)$  表示为  $n$  个像素点各个颜色通道的灰度值之和, 即:

$$A_{\text{sum}}^c(x) = A^c(x_1) + A^c(x_2) + \dots + A^c(x_n) \quad (7)$$

式中,  $A^c(x_n)$  为 R、G 和 B 颜色通道的第  $n$  个像素点的大气强度值。

## 2.2 基于 aSLIC 算法的透射率估计

由于大气光在遥感影像上是不均匀的, 传统 DCP 方法采用固定的滑动窗来估计透射率, 当窗口位于对比强烈变化的区域时, 估计透射率则会出现偏差, 在细节恢复上是不正确的。采用超像素来估计透射率, 通过合并同质区域, 将像素级图像预处理为块图像, 从而获得少数区域和有效的空间位置信息, 可有效降低后处理难度, 提高算法鲁棒性 (Wu 等, 2019)。

简单线性聚类算法 SLIC (Simple Linear Iterative Clustering) 是一种生成超像素的常用方法, 具有运算速度快、边缘拟合准确的特点 (Zhang 等, 2020)。SLIC 中只有一个参数需要设置, 即超像素个数  $K$ , 其决定了每个超像素所含像素的平均数目, 如果  $K$  值设置过大, 则超像素太小, 无法实现目标的准

确分割; 设置过小, 超像素太大, 可能会产生错分的超像素。超像素个数  $K$  的设定关系着图像分割的准确性, 往往难以设定。提出了一种自适应的 SLIC 算法 aSLIC (adaptive SLIC), 该算法可根据图像所表达内容信息的不同, 自主调整超像素块的数目, 具有更强的适应性和准确性, 从而可以提高图像透射率估计的准确性。

假设输入一幅有  $N$  个像素点的图像  $I$ , 将其由 RGB 颜色空间转化为 CIELab 颜色空间, 均匀分布  $K$  个种子点。对于每一个搜索到的所有像素点, 使之和距离最近的种子点聚为一类, 距离计算公式为

$$\begin{aligned} d_c &= \sqrt{(l_j - l_i)^2 + (a_j - a_i)^2 + (b_j - b_i)^2} \\ d_s &= \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2} \\ D(i, k) &= d_c + \frac{m}{S} d_s \end{aligned} \quad (8)$$

式中,  $d_c$  代表像素间的颜色距离,  $c \in l, a, b$ ,  $d_s$  代表像素间的空间距离,  $D(i, k)$  代表像素点  $i$  与种子点  $k$  之间的距离,  $m$  为权重系数, 取值范围为 (1, 40)。其中  $K$  为 SLIC 算法的关键参数, 按照如下方式产生:

(1) 针对亮度分量  $L$  的直方图, 计算其所含波峰的个数  $N_w$ :

$$N_w = \sum_{i \in [0, 255]} w_i, w_i = \begin{cases} 1, & l_i > l_{i-1}, l_i > l_{i+1} \\ 0, & \text{其他} \end{cases} \quad (9)$$

式中, 当  $L$  的直方图第  $i$  个位置的亮度值  $l_i$  均高于其



相邻两个亮度值时,  $w_i = 1$ ; 否则,  $w_i = 0$ ,  $i \in [0, 100]$ 。

(2) 经过对大量图像观察分析发现: 若一种颜色仅分布在一个超像素内, 则亮度  $L$  分量直方图波峰数目  $N_w$  等于超像素的数目  $K$ ; 若一种颜色分布在多个超像素内, 则亮度  $L$  分量直方图波峰数目  $N_w$  比超像素数目  $K$  少。为弥补同一颜色分布在多个超像素的情况, 设置比例系数  $n_1$ , 通过对大量遥感影像进行实验, 计算超像素分割后影像的边界召回率, 确定比例系数  $n_1$  的最佳值。其中边界召回率 BR (Boundary Recall) 的定义为: 超像素边缘像素与其对应实际边缘像素的距离小于 2 的像素数目, 在所有真实边缘像素数目中所占的比例, 值越大所取得的分割精度更高 (Goh 等, 2021)。初始超像素个数 (种子点数) 可表示为

$$K = n_1 N_w \quad (10)$$

(3) 在图像的  $3 \times 3$  邻域内, 对种子点和周围所有像素点的梯度值进行计算, 并将种子点移动至该邻域内梯度最小的位置, 以此更新种子点。计算像素点与种子点的距离进行迭代优化。如果迭代达到最小误差精度或迭代次数, 则停止迭代, 即

$$\|D(i, k)_o - D(i, k)_{o+1}\| < \varepsilon \quad (11)$$

式中,  $o$  为迭代次数,  $\varepsilon$  为误差精度。

(4) 为了增强连通性, 最后对所有超像素进行遍历, 将孤立像素点和尺寸过小的超像素块, 与其相邻的超像素块进行合并。aSLIC 算法步骤为

步骤 1 自适应初始化种子点: 根据图像亮度

$L$  分量直方图波峰的个数, 自动确定超像素分割数目  $K$ ;

步骤 2 更新种子点: 在  $3 \times 3$  邻域内, 计算种子点和周围所有像素点的梯度值, 并将种子点移动至该邻域内梯度最小的位置;

步骤 3 距离度量: 分别计算所有像素点和该种子点的距离;

步骤 4 迭代优化: 根据距离度量结果, 像素点与其距离最小的种子点的类别保持一致。不断重复步骤 2、步骤 3, 如果达到最小误差精度或迭代次数, 则停止迭代;

步骤 5 增强连通性: 采用从左到右, 从上到下的方式遍历图像中的超像素, 将筛选出来的孤立像素点和尺寸过小的超像素块与其相邻的大超像素块合并。

如图 4 所示, 不同图像  $L$  颜色分量直方图的波峰数目是不同的, 如图 4(b) 中直方图的波峰个数  $N_w$  分别为 64 和 72。依据式 (10), 当  $n_1=10$  可以确定超像素数目分别为 640 和 720。使用传统的 SLIC 算法对图 4(a) 分别进行分割, 分割后的图像分别对应图 4(c); 使用 aSLIC 算法对图像图 4(a) 分别进行分割, 分割后的图像分别对应图中的图 4(d)。可以看到, 图 4(d) 中的超像素大小均匀, 每个超像素内部像素保持一致, 超像素边界与图像真实目标边缘一致性很好。与传统的 SLIC 算法手动调节  $K$  值相比, aSLIC 算法具有更高的自适应性和分割准确性。

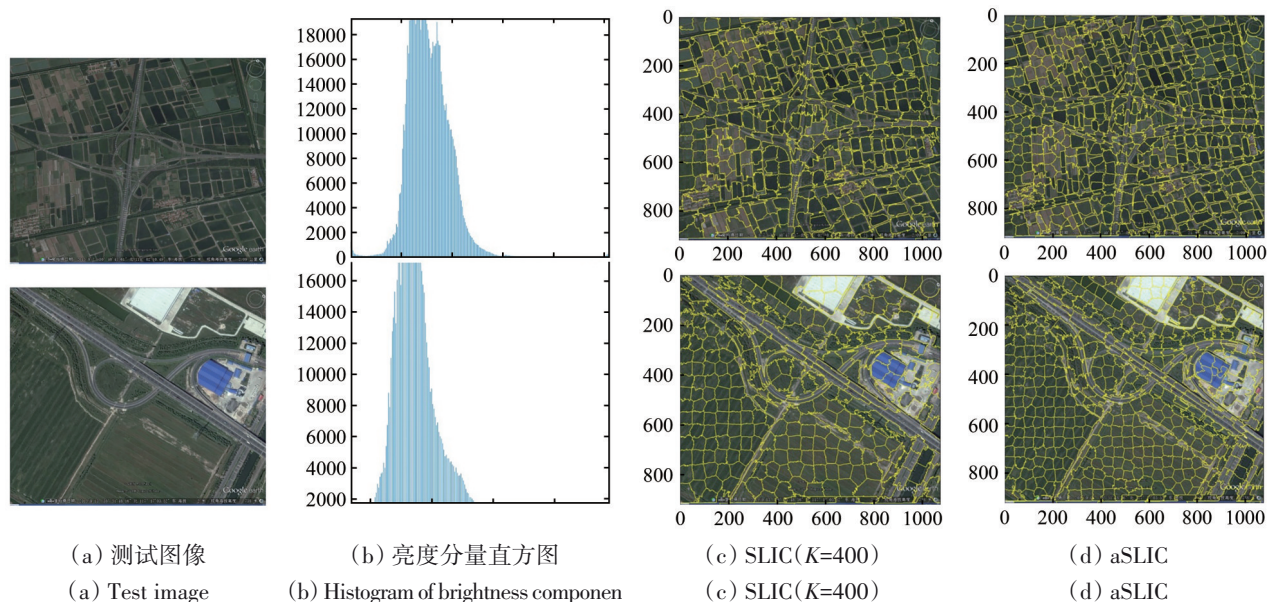


图 4 aSLIC 算法分割效果图

Fig. 4 aSLIC algorithm segmentation

基于 aSLIC 算法处理后的遥感影像, 根据公式 (1) — (2) 来估计每一个超像素块的透射率  $T_{\text{aSLIC}}(x)$ :

$$T_{\text{aSLIC}}(x) = 1 - \omega \min_{y_{\text{aSLIC}} \in \Omega_{\text{aSLIC}}(x)} \left( \min_{c \in r, g, b} \frac{I_{\text{aSLIC}}^c(y)}{A_R^c} \right) \quad (12)$$

式中,  $I_{\text{aSLIC}}^c(y)$  是使用自适应 SLIC 算法处理后的图像,  $\Omega_{\text{aSLIC}}(x)$  为边长为  $S \times S$  的窗口,  $y_{\text{aSLIC}}$  为窗口  $\Omega_{\text{aSLIC}}(x)$  中的像素,  $\omega$  为雾度系数, 防止过度去雾造成图像失真。

### 2.3 有雾遥感影像恢复

根据 2.1 估计的大气光  $A_R^c$  和 2.2 计算的  $T_{\text{aSLIC}}(x)$ , 基于式 (1) 对无雾遥感影像  $J^c(x)$  进行恢复。将  $A_R^c$  和  $T_{\text{aSLIC}}(x)$  代入式 (1), 则去雾后的遥感影像  $J^c(x)$  可表示为

$$J^c(x) = A_R^c + \frac{I^c(x) - A_R^c}{T_{\text{aSLIC}}(x)} \quad (13)$$

为了保留遥感影像的细节信息, 将引导函数引入 Retinex 算法。首先对输入遥感影像进行对比度增强, 提升遥感影像对比度动态范围。同时由于遥感影像大气光是不均匀的, 传统固定窗口在估计透射率时估计不准确, 导致复原后的遥感影像局部出现光晕色差现象。因此, 提出了自适应 SLIC 算法, 通过滑动窗口对局部超像素来准确估计透射率。

联合式 (1) 中进行无雾影像恢复, 具体步骤为

步骤1 输入遥感雾图  $I^c(x)$ , 基于改进的 Retinex 增强处理, 输出图像  $I^R(x)$ ;

步骤2 输入图像  $I^R(x)$ , 基于自适应 SLIC 算法处理, 输出图像  $I_{\text{aSLIC}}^c(x)$ ;

步骤3 输入图像  $I^R(x)$ , 借助暗通道先验原理, 输出大气强度值  $A_R^c$ ;

步骤4 输入图像  $I_{\text{aSLIC}}^c(x)$ , 借助暗通道先验原理, 输出透射率  $T_{\text{aSLIC}}(x)$ ;

步骤5 输入  $I_{\text{aSLIC}}^c(x)$  和  $A_R^c$ , 借助大气散射模型, 输出真实图像  $J^c(x)$ 。

## 3 实验结果与分析

实验硬件环境为: Intel (R) Core (TM) i5-10400F 2.9 GHz CPU, 内存 16 GB; 软件环境为: Win11, Visual Studio 2017, 视觉处理库版本为 OpenCV 4.1.0。实验分为 4 部分: (1) 参数设置实验、(2) 对大气光值估计准确性的测试实验、(3) 对透射率估计准确性的测试实验和 (4) 所提出算法的整体实验。为了验证所提方法的有效性, 将所提算法和 DCP (He 等, 2009)、DOC (Zhu 等, 2021a)、EVP (Han 等, 2022) 和 CHAL (Nie 等, 2022) 等 4 种算法进行对比, 对比算法具体介绍如表 1 所示。

表 1 对比算法分析

Table 1 Comparison algorithm analysis

算法	内容	优缺点
DCP 算法 (He 等, 2009)	提出暗通道先验基本原理, 认为无雾图像在除天空局域区域外, 某些像素在对应的颜色通道中, 至少在一个通道中的像素强度值较低, 其值近似接近于零。假设大气光为已知量, 对图像进行透射率估计, 从而实现图像的去雾。	首次提出暗通道先验原理, 实现快速去雾; 但去雾后的图像颜色偏暗, 对于由天空区域的图像, 去雾效果差。
DOC 算法 (Zhu 等, 2021a)	提出一种基于大气光估计的遥感影像去雾方法, 首先, 通过建立原始图像和场景深度之间的关系, 使用可微分函数训练线性场景深度模型的参数, 用于生成遥感影像的场景深度图, 进而获得影像的大气光估计值。然后, 在估计的大气光的基础上, 获得相应的透射图。最后, 基于大气散射模型实现遥感影像的去雾。	利用遥感影像的场景深度图估计大气光和透射率, 提高了大气光和透射率估计的准确率; 但算法复杂度高, 单幅遥感影像处理时间较长。
EVP 算法 (Han 等, 2022)	提出一种基于局部块最小值先验 (MinVP) 和局部块最大值先验 (MaxVP) 遥感影像去雾方法。MinVP 能够解决去雾过程中出现过饱和、过曝和光晕等情况; MaxVP 用于对影像进行简单增强, 在去雾同时实现影像的增强。	提出 MainVP 和 MaxVP, 替代了暗通道先验和亮通道先验, 实现遥感影像的快速去雾; 但去雾后的影像对比度依然较低。
CHAL 算法 (Nie 等, 2022)	提出一种基于对比的雾感知动态遥感影像去雾方法。首先使用对比聚类方法已无监督方式学习一组真实世界雾霾遥感影像的雾特征; 然后参数生成器生成雾感知参数, 动态构建去雾模型; 最后通过模型训练学习实现遥感影像的去雾。	构建动态学习雾度感知参数模型, 通过对模型进行训练, 实现遥感影像的去雾。但该方法前期需要训练学习大量数据的雾度参数特征, 消耗大量时间。

### 3.1 参数设置

所提方法只含有 1 个参数需要设置: 即自适应

SLIC 算法中比例系数  $n_1$ 。为确定其值, 并测试其鲁棒性, 设计本节实验。具体的:



在去雾数据集 RSOD-Dataset (Long 等, 2017) 中选取 8 幅遥感影像, 将  $n_1$  的值分别取为 4、6、8、10、12、14, 然后对 8 幅遥感影像使用 aSLIC 算法进行超像素分割, 并计算边界召回率。

图 5 (a)–(h) 为选取的 8 幅遥感影像, 各幅图像的  $L$  分量直方图和分割结果图; 如

图 5 所示, 8 幅遥感影像亮度分量  $L$  直方图的波峰个数  $N_w$  分别为 58、62、65、70、71、72、73 和 76; 图 6 为图 5 各幅遥感影像的边界召回率折线图。如图 6 所示, 当  $n_1$  的值取 10 时, 8 幅遥感影像分割后的边界召回率都能达到最大值, 因此, 将  $n_1$  取为 10。

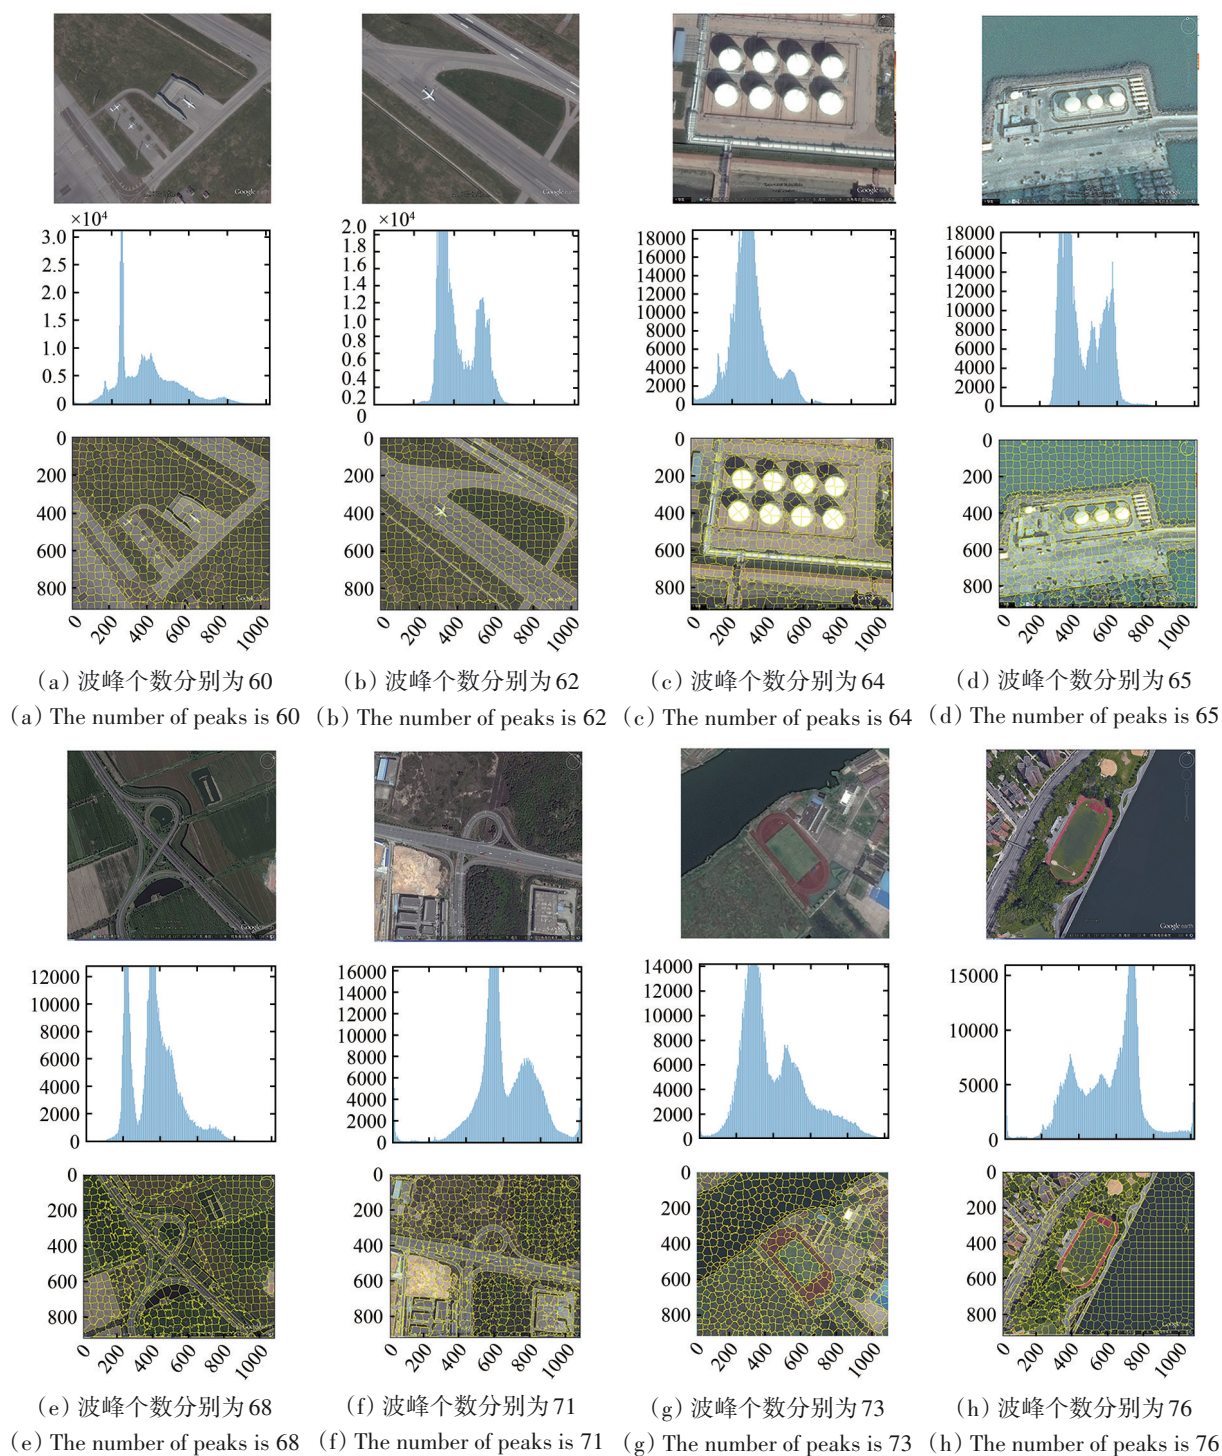


图 5 O-HAZE 中 8 幅图像及其  $L$  颜色分量的直方图

Fig. 5 Histograms of eight images and their color components in O-HAZE






图6 边界召回率折线图

Fig. 6 Boundary recall line chart

## 3.2 主观评价

### 3.2.1 对大气光值估计准确性的测试

为检验 iRetinex 算法对遥感影像去雾效果的影响，进行对比试验。

首先对原始影像采用 iRetinex 算法进行增强，根据 He 等的算法 (DCP) 可以得到准确的大气光值，进而根据式 (1) 实现去雾。将所提出算法与 DCP 算法进行比较，如图 7 所示。

如图 7 (b) 所示，采用暗通道先验原理去雾时，能较好地去除雾气，但是恢复后的影像颜色暗淡。如图 7 (c) 所示，采用基于引导函数的 Retinex 图像增强算法去雾时，能很好的去除影像的雾气，同时处理后的影像对比度显著增高，细节信息增多。由此可见，当采用基于引导函数的 Retinex 算法后，遥感影像大气光值的估计更加准确。

### 3.2.2 对透射率估计准确性的测试

为了检验 aSLIC 算法的去雾效果，进行对比实验。首先对遥感影像采用 aSLIC 算法进行超像素分割，根据式 (10) 得到准确的透射率值，最后根据 He 等 (2009) 的算法 (DCP) 实现去雾。将所提出算法与 DCP 算法的去雾效果进行比较，如图 8 所示。



(a) 雾图  
(a) Haze image

(b) 基于暗通道先验原理  
(b) Based on dark channel prior principle

(c) 基于 iRetinex 图像增强算法  
(c) Based on iRetinex image enhancement algorithm

图7 去雾结果对比图

Fig. 7 Comparison of dehazing results

如图 8 (b) 所示，由于 DCP 采用的是固定窗口计算影像的透射率，导致恢复后的遥感影像出现较多的残留的雾，如图 8 (b) 所示，恢复后的

影像质量较差。如图 8 (c) 所示，基于自适应 SLIC 算法去雾时，采用的是超像素，在每个超像素内分别计算透射率，处理后的影像颜色更真实。

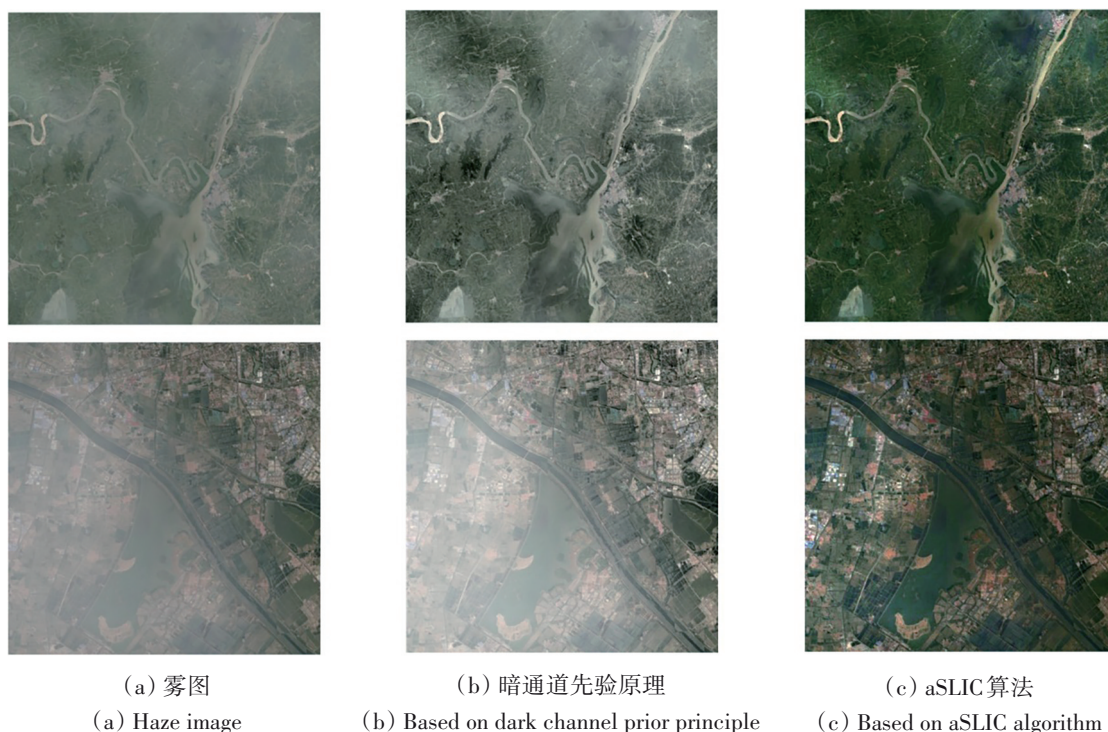


图8 去雾结果对比图

Fig. 8 Comparison of dehazing results

### 3.2.3 去雾实验对比

图9为不同算法的去雾结果对比图。选用的遥感影像来自于数据集RICE Datasets (Lin等, 2019), 该数据集包含了不同场景的清晰标签遥感影像和有雾遥感影像, 在此数据集中随机选取5幅有雾遥感影像进行试验。

对比发现, 整体上, DCP、DOC、EVP和CHAL的去雾算法能一定程度上降低雾气对影像质量的影响, 但在细节上, 不同算法会引起不一样的视觉感知效果, 比如在景深突变处的有残留的雾、去雾之后出现影像整体颜色偏暗等。具体地, 图9(c)和图9(e)方法对去除薄雾有较好效果, 然而对浓雾影像的恢复效果有限, 同时去雾后的影像颜色整体偏暗。图9(d)能较好地恢复出影像的细节信息, 但去雾不彻底, 影像局部区域仍有残留雾气。图9(f)方法去雾彻底, 但去雾影像出现了颜色偏差现象, 如图9中第5幅图所示。相对而言, 图9(g)方法恢复效果相对较好, 颜色更真实。它不仅很好的恢复出真实影像, 还提高了影像的对比度和饱和度。与图9(c)~(f)等算法相比, 所提出的方法(图9(g))在景深突变处消除了残雾, 抑制了颜色失真现象, 同时保留了影像细节信息。

为了进一步证明所提出算法的有效性, 在公开数据集 Inria Aerial Image Dataset (Maggiori等, 2017) 中随机选取其中的4幅用于实验, 如图10所示。对比发现, DOC算法和CHAL算法的结果主观上要优于EVP算法的结果, 颜色上更加的真实。EVP和DCP算法能很好的恢复出遥感影像的真实颜色, 但影像偏暗、对比度低, 丢失细节信息。所提出的算法能够有效的去除遥感影像中的雾气, 很好的恢复出遥感影像的真实颜色, 可以有效避免遥感影像出现颜色失真现象, 同时保留了遥感影像细节信息。

### 3.3 客观评价

为了定量评估所提出的去雾模型的性能, 使用3个图像性能评价指标: 图像熵 (Entropy,  $H$ )、峰值信噪比PSNR (Peak Signal to Noise Ratio) 和结构相似性SSIM (Structural Similarity)。研究表明,  $H$ 值越大, 图像中信息量越大, 说明图像灰度分布的聚集特征; PSNR值与图像的失真程度呈负相关, 即数值越大, 说明其图像质量越好; SSIM基于感知模型, 从亮度、对比度、结构3个方面对图像相似性进行评价, 数值越大, 图像质量越好。遥感影像去雾后效果的判断方法是具有较高的 $H$ 值、PSNR值和SSIM值。



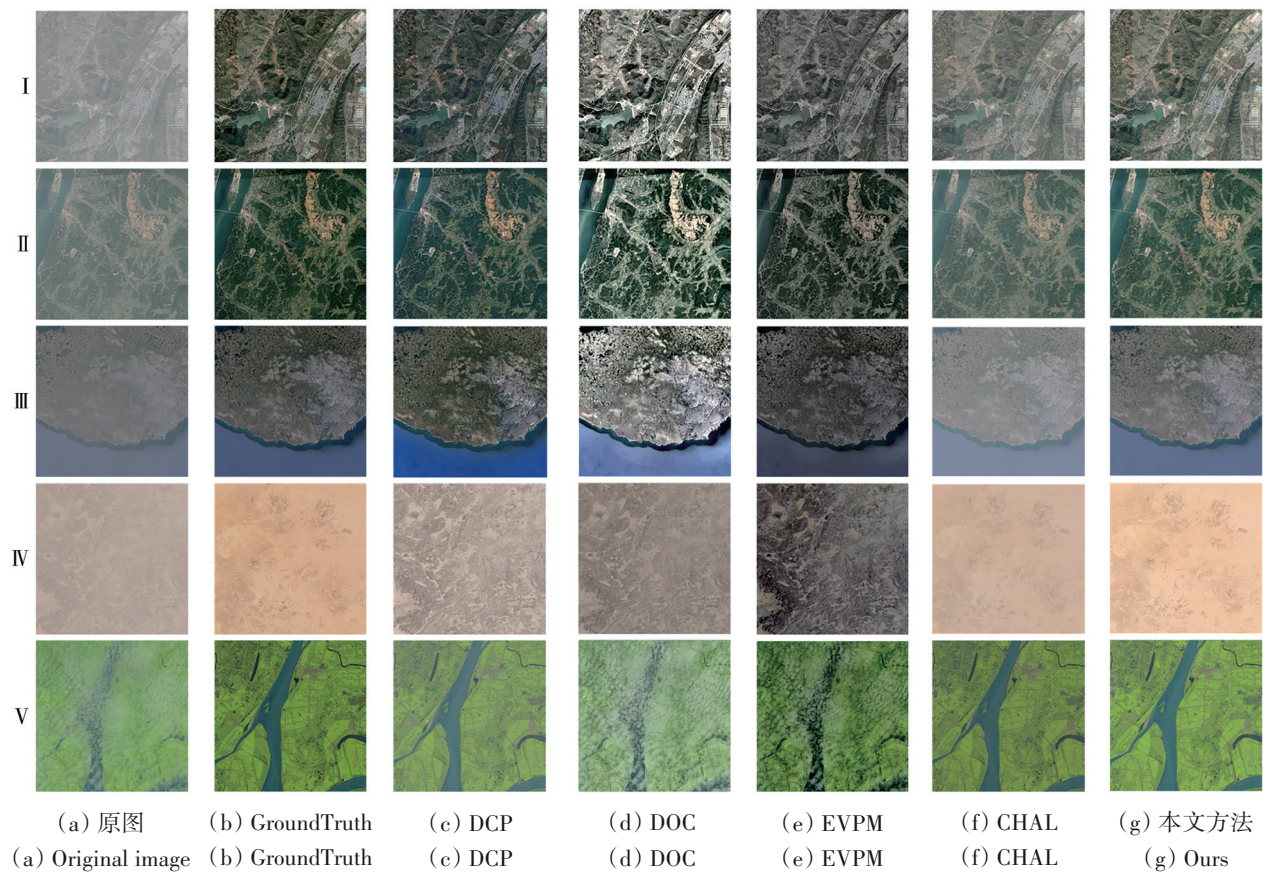


图9 去雾效果对比

Fig. 9 Dehaze effect comparison

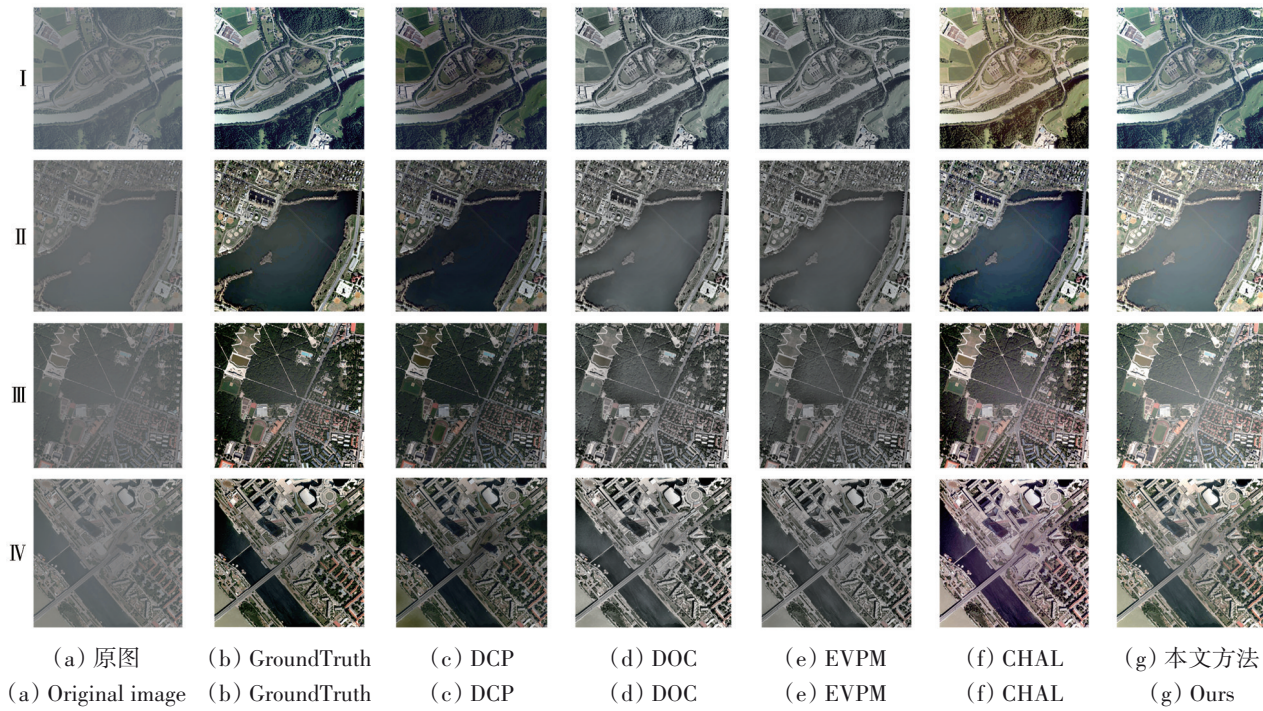


图10 去雾效果对比

Fig. 10 Dehaze effect comparison



基于上述3个指标，分别使用图9、图10中5种算法计算表2去雾后遥感影像的质量评价指标的变化，绘制表2和表3各指标折线图，如图11和图12所示。

(表2，表3)。为了更直观地表达不同算法质量评

表2 RICE Datasets 图像指标对比  
Table 2 Image metrics comparison for RICE Datasets

算法	图像 I			图像 II			图像 III			图像 IV			图像 V		
	H/bit	PSNR/dB	SSIM	H/bit	PSNR/dB	SSIM	H/bit	PSNR/dB	SSIM	H/bit	PSNR/dB	SSIM	H/bit	PSNR/dB	SSIM
DCP	6.21	15.52	0.65	5.91	23.96	0.85	6.44	21.67	0.76	7.71	19.24	0.75	5.11	8.91	0.45
DOC	6.41	18.27	0.74	6.39	25.81	0.89	6.88	23.85	0.84	7.98	21.06	0.81	5.98	11.29	0.64
EVPM	6.14	17.68	0.72	6.05	24.66	0.86	6.73	23.36	0.82	7.83	19.92	0.78	5.64	11.03	0.59
CHAL	7.29	19.54	0.83	7.67	26.29	0.93	7.51	24.05	0.88	8.07	25.38	0.84	6.79	13.67	0.79
本文算法	7.41	20.21	0.85	7.82	26.32	0.93	7.53	24.12	0.9	8.12	25.95	0.85	6.93	13.69	0.83

表3 Inria Aerial Image Dataset 图像指标对比  
Table 3 Image metrics comparison for Inria Aerial Image Dataset

算法	图像 I			图像 II			图像 III			图像 IV		
	H/bit	PSNR/dB	SSIM	H/bit	PSNR/dB	SSIM	H/bit	PSNR/dB	SSIM	H/bit	PSNR/dB	SSIM
DCP	6.35	16.23	0.45	6.12	22.31	0.73	6.43	20.46	0.68	7.19	18.57	0.72
DOC	8.32	18.34	0.75	7.93	26.75	0.85	7.57	26.04	0.79	8.23	23.92	0.79
EVPM	7.98	18.02	0.68	7.64	25.90	0.81	7.50	24.83	0.78	7.92	22.61	0.72
CHAL	9.19	20.99	0.84	8.58	28.84	0.91	8.49	27.04	0.89	8.53	25.13	0.85
本文算法	9.23	21.32	0.88	8.62	29.13	0.91	8.57	27.10	0.91	8.57	25.56	0.87




图11 表4评价结果折线图  
Fig. 11 Evaluation results broken line Table 4




图12 表5评价结果折线图  
Fig. 12 Evaluation results broken line Table 5

如表 2 所示, 对于 RICE Datasets, 相比于 DCP、DOC 和 EVPM 算法, CHAL 算法能够取得较高的 H 值和 PSNR 值, 表明该算法去雾后的遥感影像失真程度更小, 遥感影像信息量更丰富。相对于 DPC 和 EVPM 算法, DOC 算法有较高的 SSIM 值, 说明该算法去雾后的遥感影像更接近于真实影像。可以看出, 提出的算法具有比其他算法更高的 H 值、PSNR 值和 SSIM 值。较高的 SSIM 值表明, 提出的算法去雾后的遥感影像与 GroundTruth 遥感影像具有更高的相似性, 去雾后的遥感影像更接近真实场景; 较高的 H 值和 PSNR 值表明提出的算法去雾后的遥感影像信息量更丰富, 失真程度最小; 总体表明提出的算法去雾后的遥感影像质量更好, 颜色更真实, 遥感影像细节信息更丰富。

图 11 中各子图的横坐标表示各种去雾算法, 纵坐标表示图像性能指标值, 各子图中的曲线分别代表图 9 中的 5 幅遥感影像。由图 11 可以看出, DCP 算法和 EVPM 算法曲线具有较大的波动性, 表明遥感影像的场景信息会影响去雾后影像的质量, 表明这两种算法的鲁棒性较差; 相比于 DCP、DOC 和 EVPM 算法, CHAL 算法曲线波动性小, 稳定性更高, 具有更高的鲁棒性。相对而言, 对于任何一幅遥感影像, 所提出的算法都能取得最高的 H 值、PSNR 值和 SSIM 值, 表明所提出算法具有更高的稳定性、优越性和更强的鲁棒性。

如表 5 所示, 对于 Inria Aerial Image Dataset, 相比于 DCP、DOC 和 EVPM 算法, 由于 CHAL 算法构建雾度感知参数模型, 并进行深度学习训练, 因此, CHAL 算法能够取得较高的 H 值、PSNR 值和 SSIM 值, 表明 CHAL 算法去雾后的遥感影像失真程度更小, 影像信息量相对更丰富, 但 CHAL 算法在模型训练过程中消耗的时间更多; DCP 算法效果最差, 具有最低的 H 值、PSNR 值和 SSIM 值, 这与图 10 主观视觉上相一致; DOC 算法和 EVPM 算法在 3 个图像性能指标相接近, 表明这两种算法的去雾效果相似, 但视觉上 EVPM 算法去雾后的遥感影像对比度较低。可以看出, 提出的算法具有比其他算法更高的 H 值、PSNR 值和 SSIM 值; 相对于 DCP 算法, 所提出的算法分别在 H、PSNR 和 SSIM 平均提升 2.22、6.38 和 0.25; 相对于 CHAL 算法, 所提出的算法分别在 H、PSNR 和 SSIM 平均提升 0.05、0.28 和 0.02, 表明所提出的算法去雾后的遥感影像质量更好, 影像失真更小, 遥感影像细节信息更

丰富。

图 12 中各子图的横坐标表示各种去雾算法, 纵坐标表示图像性能指标值, 各子图中的曲线分别代表图 10 中的 4 幅遥感影像。由图 11 可以看出, DCP、DOC 和 EVPM 算法曲线具有较大的波动性, 表明对于包含更多细节场景遥感影像中, 该方法的去雾效果更差, 鲁棒性更低; 相比于 DOC 和 EVPM 算法, CHAL 算法曲线波动性小, 稳定性更高, 去雾效果更好。相对而言, 对于任何一幅遥感影像, 所提出的算法都能取得最高的 H 值、PSNR 值和 SSIM 值, 且曲线的波动性最小, 表明所提出方法具有更高的稳定性和更强的鲁棒性。

为更加说明所提算法的优越性以及普适性, 在 RICE Datasets 和 Inria Aerial Image Dataset 两个数据集中, 选取 100 幅遥感影像进行对比实验, 分别计算去雾后遥感影像的 H、PSNR 和 SSIM 指标的平均值。该 100 幅遥感影像包含不同的场景, 以及不同的雾浓度分布, 实验结果如表 4 所示。

表 4 100 幅遥感影像去雾指标平均值  
Table 4 Average of 100 remote sensing image dehazing metrics

方法	H/bit	PSNR/dB	SSIM
DCP	6.13	15.82	0.52
DOC	7.98	18.83	0.77
EVPM	7.78	18.05	0.73
CHAL	8.39	19.98	0.80
本文算法	8.43	20.07	0.81

由表 4 可以看出, 对于遥感影像去雾, 相比于 DCP、DOC 和 EVPM 算法, CHAL 算法去雾后的遥感影像质量更高, 该方法通过学习影像雾度特征, 建立雾度参数模型, 实现遥感影像的去雾。DCP 算法去雾后的遥感影像质量最差, 这是因为 DCP 算法在计算图像透射率时基于固定的窗口, 导致透射率计算不准确, 去雾后的遥感影像整体偏暗, 遥感影像细节信息丢失。DOC 算法能很好的恢复遥感影像的颜色, 但去雾后的影像中仍残留雾气。EVPM 算法能很好的去除雾气, 但去雾后的影像对比度较低。相对而言, 所提出的算法在 H、PSNR 和 SSIM 3 个指标上均能取得最大值, 说明所提出的算法去雾后的遥感影像质量更高, 遥感影像的细节信息更多, 能够恢复遥感影像的真实场景, 视觉上效果更佳。

表5为同一实验平台下,各去雾算法对图9中的5幅尺寸为 $512 \times 512$ 的遥感影像进行去雾的运行时间对比。结果表明,对于同一幅遥感影像,DOC算法效率最低,处理一幅遥感影像,用时最多为0.54 s;CHAL算法效率高于所提出的算法的效率,但其在前期对网络模型进行训练学习时,会消耗较多的时间,以及对硬件要求较高。因此,所提出的算法在实际应用中有更高的效率,以及更低的成本。

表5 各算法运行时间对比

Table 5 Comparison of the running time of each algorithm

方法	图像 I	图像 II	图像 III	图像 IV	图像 V
DCP	0.39	0.41	0.40	0.43	0.37
DOC	0.51	0.54	0.54	0.53	0.49
EVPM	0.35	0.36	0.38	0.33	0.31
CHAL	0.17	0.24	0.25	0.24	0.14
本文	0.19	0.29	0.27	0.25	0.17

## 4 结 论

针对遥感影像由于雾霾的原因导致清晰度下降,影响遥感影像目标检测和地物分割任务的问题,提出一种基于自适应SLIC的遥感影像去雾算法。针对有雾遥感影像出现局部区域高亮,大气强度值计算出现偏差问题,提出改进的Retinex算法,对有雾遥感影像进行整体增强的同时扩展对比度动态范围,提高遥感影像大气强度值准确率;为解决传统暗通道先验原理基于固定窗口计算透射率问题,提出一种基于自适应SLIC算法,解决SLIC算法中超像素数目参数难以设定的问题,对增强后的遥感影像进行超像素分割,计算每个超像素块区域的透射率,避免局部对比度强烈区域对固定窗口的影响,从而获得更加精确的透射率;基于暗通道先验原理和大气散射模型恢复出无雾遥感影像。主观和客观实验表明,所提出的遥感影像去雾算法能够有效增强影像的对比度,恢复和保留遥感影像中的局部细节信息,并且该算法无需手动设置参数,避免了人为因素的影响导致复原的影像出现局部区域残留雾气,提高了算法的处理效率。

未来,将致力于去除高分辨率遥感影像中稠密团雾或云的研究,提升算法的性能。

## 参考文献(References)

Bi G L, Si G L, Zhao Y C, Qi B and Lv H Y. 2022. Haze removal for a single remote sensing image using low-rank and sparse prior. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5615513 [DOI: 10.1109/TGRS.2021.3135975]

Goh K L, Ng G W, Hamzah M and Chai S S. 2021. Sizes of superpixels and their effect on interactive segmentation//*Proceedings of 2021 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAET)*. Kota Kinabalu: IEEE: 1-5 [DOI: 10.1109/IICAET51634.2021.9573623]

Han J, Zhang S L, Fan N X and Ye Z. 2022. Local patchwise minimal and maximal values prior for single optical remote sensing image dehazing. *Information Sciences*, 606: 173-193 [DOI: 10.1016/j.ins.2022.05.033]

He K M, Sun J and Tang X O. 2009. Single image haze removal using dark channel prior//*Proceedings of 2009 IEEE Conference on Computer Vision and Pattern Recognition*. Miami: IEEE: 20-25 [DOI: 10.1109/CVPR.2009.5206515]

Huang Y R, Liu Y K, Liu H S, Shui Y Y, Zhao G W, Chu J H, Situ G H, Li Z B, Zhou J Y and Liang H W. 2021. Multi-view optical image fusion and reconstruction for defogging without a prior in-plane. *Photonics*, 8(10): 454 [DOI: 10.3390/photonics8100454]

Hudson R D and Hudson J W. 1975. The military applications of remote sensing by infrared. *Proceedings of the IEEE*, 63(1): 104-128 [DOI: 10.1109/PROC.1975.9711]

Jiang B, Chen G T, Wang J S, Ma H, Wang L, Wang Y X and Chen X X. 2021. Deep dehazing network for remote sensing image with non-uniform haze. *Remote Sensing*, 13(21): 4443 [DOI: 10.3390/rs13214443]

Jiang H, Lyu N and Yao L. HOT-transform based method to remove haze or thin cloud for Landsat 8 OLI satellite data. *Journal of Remote Sensing (in Chinese)*, 2016, 20(4): 620-631 (姜侯, 吕宁, 姚凌. 改进HOT法的Landsat 8 OLI遥感影像雾霾及薄云去除[J]. 遥感学报, 2016, 20(4): 620-631)

Jiao L, Shi Z W and Tang W. 2012. Fast haze removal for a single remote sensing image using dark channel prior//*Proceedings of 2012 International Conference on Computer Vision in Remote Sensing*. Xiamen: IEEE: 132-135 [DOI: 10.1109/CVRS.2012.6421247]

Kumar R P and Naganaik M. 2023. OptiMD-3D DCNN: a framework for restoring the haze-free images by image dehazing techniques using heuristic approach of adaptive lifting wavelet transform. *Cybernetics and Systems* [DOI: 10.1080/01969722.2023.2176624]

Lin D Y, Xu G L, Wang X K, Wang Y, Sun X and Fu K. 2019. A remote sensing image dataset for cloud removal. *arXiv*: 1901.00600 [DOI: 10.48550/arXiv.1901.00600]

Liu S C, Shi H J and Guo Z. 2022. Research on defog algorithm of single remote sensing image based on deep learning//*Proceedings of the 3rd International Conference on Computer Information and Big Data Applications*. Wuhan: IEEE: 1-5

Long Y, Gong Y P, Xiao Z F and Liu Q. 2017. Accurate object localiza-



- tion in remote sensing images based on convolutional neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, 55(5): 2486-2498 [DOI: 10.1109/TGRS.2016.2645610]
- Maggiori E, Tarabalka Y, Charpiat G and Alliez P. 2017. Can semantic labeling methods generalize to any city? The Inria aerial image labeling benchmark//*Proceedings of the 2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. Fort Worth: IEEE: 3226-3229 [DOI: 10.1109/IGARSS.2017.8127684]
- Mancini F and Pirotti F. 2021. Innovations in photogrammetry and remote sensing: modern sensors, new processing strategies and frontiers in applications. *Sensors*, 21(7): 2420 [DOI: 10.3390/s21072420]
- Nayar S K and Narasimhan S G. 1999. Vision in bad weather//*Proceedings of the Seventh IEEE International Conference on Computer Vision*. Kerkyra: IEEE: 820-827 [DOI: 10.1109/ICCV.1999.790306]
- Nie J T, Wei W, Zhang L, Yuan J L, Wang Z B and Li H. 2022. Contrastive haze-aware learning for dynamic remote sensing image dehazing. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5634311 [DOI: 10.1109/TGRS.2022.3220940]
- Qin P, Cai Y L, Liu J, Fan P R and Sun M H. 2021. Multilayer feature extraction network for military ship detection from high-resolution optical remote sensing images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 11058-11069 [DOI: 10.1109/JSTARS.2021.3123080]
- Rahman Z, Jobson D J and Woodell G A. 1996. Multi-scale retinex for color image enhancement//*Proceedings of the 3rd IEEE International Conference on Image Processing*. Lausanne: IEEE: 1003-1006 [DOI: 10.1109/ICIP.1996.560995]
- Stevens M M. 1988. *Application of Remote Sensing to the Assessment of Surface Characteristics of Selected Mojave Desert Playas for Military Purposes*. Rolla: University of Missouri-Rolla
- Sun H, Fang S L, Dan Z P, Ren D, Yu M and Sun S F. 2023. A two-branch remote sensing image dehazing network based on hierarchical feature interaction and enhanced receptive field. *National Remote Sensing Bulletin*, 27(12): 2831-2846 (孙航, 方帅领, 但志平, 任东, 余梅, 孙水发. 2023. 层级特征交互与增强感受野双分支遥感图像去雾网络. *遥感学报*, 27(12): 2831-2846) [DOI: 10.11834/jrs.20232333]
- Tang Q F, Yang J, He X J, Jia W J, Zhang Q N and Liu H B. 2021. Nighttime image dehazing based on Retinex and dark channel prior using Taylor series expansion. *Computer Vision and Image Understanding*, 202: 103086 [DOI: 10.1016/j.cviu.2020.103086]
- Wang F Y, Zhou K, Wang M C and Wang Q. 2020. The impact analysis of land features to JL1-3B nighttime light data at parcel level: illustrated by the case of Changchun, China. *Sensors*, 20(18): 5447 [DOI: 10.3390/s20185447]
- Wu H and Tan Z W. 2020. An image dehazing algorithm based on single-scale retinex and homomorphic filtering//Liang Q L, Wang W, Liu X, Na Z Y, Jia M, Zhang B J, eds. *Communications, Signal Processing, and Systems: Proceedings of the 8th International Conference on Communications, Signal Processing, and Systems*. Singapore: Springer: 1482-1493 [DOI: 10.1007/978-981-13-9409-6\_178]
- Wu Y P, Zhao Z, Wu W G, Lin Y S and Wang M Y. 2019. Automatic glioma segmentation based on adaptive superpixel. *BMC Medical Imaging*, 19(1): 73 [DOI: 10.1186/s12880-019-0369-6]
- Xie F Y, Chen J J, Pan X X and Jiang Z G. 2018. Adaptive haze removal for single remote sensing image. *IEEE Access*, 6: 67982-67991 [DOI: 10.1109/ACCESS.2018.2879893]
- Zhang C Y, Cheng H F, Chen Z H and Zheng W W. 2008. The development of hyperspectral remote sensing and its threatening to military equipments. *Electro-Optic Technology Application*, 23(1): 10-12 (张朝阳, 程海峰, 陈朝辉, 郑文伟. 2008. 高光谱遥感的发展及其对军事装备的威胁. *光电技术应用*, 23(1): 10-12) [DOI: 10.3969/j.issn.1673-1255.2008.01.003]
- Zhang Y X, Liu K, Dong Y N, Wu K and Hu X Y. 2020. Semisupervised classification based on SLIC segmentation for hyperspectral image. *IEEE Geoscience and Remote Sensing Letters*, 17(8): 1440-1444 [DOI: 10.1109/LGRS.2019.2945546]
- Zhang Z, Li Q, Xu Z H, Feng H J and Chen Y T. 2019. Color-line and dark channel based dehazing for remote sensing images. *Optics and Precision Engineering*, 27(1): 181-190 (张峥, 李奇, 徐之海, 冯华君, 陈跃庭. 2019. 结合颜色线和暗通道的遥感图像去雾. *光学精密工程*, 27(1): 181-190) [DOI: 10.3788/OPE.20192701.0181]
- Zhu Z Q, Luo Y Q, Qi G Q, Meng J, Li Y and Mazur N. 2021a. Remote sensing image defogging networks based on dual self-attention boost residual octave convolution. *Remote Sensing*, 13(16): 3104 [DOI: 10.3390/rs13163104]
- Zhu Z Q, Luo Y Q, Wei H Y, Li Y, Qi G Q, Mazur N, Li Y Y and Li P L. 2021b. Atmospheric light estimation based remote sensing image dehazing. *Remote Sensing*, 13(13): 2432 [DOI: 10.3390/rs13132432]

## Remote sensing image dehazing algorithm based on adaptive SLIC

YU Hang, LI Chenyang, LIU Zhiheng, ZHOU Suiping, GUO Yuru

*School of Aerospace Science and Technology, Xidian University, Xi'an 710126, China*

**Abstract:** Objective Remote sensing images have degraded clarity because of haze, which makes remote sensing image target detection, feature segmentation, and remote sensing image information interpretation difficult. Remote sensing image defogging based on deep learning is time consuming because of the large number of model parameters and the dependence on the amount of remote sensing image

data. Remote sensing image dehazing based on image enhancement does not fully consider the degradation mechanism of remote sensing images in hazy conditions, and as a result, remote sensing images cannot be used for different scenes and easily lose their image information, leading to image distortion. Remote sensing image dehazing based on physical models requires manual parameter setting during transmittance refinement. At the same time, because the contrast of remote sensing images is not completely enhanced, the overall color of dehazed images is dark, and fog remains in local areas. Method In this study, a remote sensing image dehazing method based on image enhancement and physical modeling is proposed to solve the abovementioned problems and improve the quality of remote sensing image dehazing. An adaptive Simple Linear Iterative Clustering (SLIC)-based remote sensing image dehazing algorithm is proposed. First, for the problem of local area highlighting in hazy remote sensing images and the atmospheric intensity value calculation bias problem, an improved Retinex algorithm is used to contrast-enhance the input remote sensing images. The objective is to preserve image details, reduce artifacts, extend the dynamic range of image contrast, and accurately estimate the atmospheric intensity value of remote sensing images. Second, an adaptive SLIC algorithm is proposed to solve the difficulty of setting the number of superpixels and performing superpixel segmentation on the input remote sensing image to avoid the influence of the local contrast intensity region on the fixed window and obtain an accurate transmittance estimation. Last, a haze-free remote sensing image is recovered based on the dark channel a priori principle and atmospheric scattering model. The proposed method can achieve adaptive dehazing of remote sensing images without manual parameter setting. Results The proposed algorithm is compared with the four algorithms of He et al., Zhu et al., Han et al., and Nie et al., and the dehazing effects are compared using the publicly available datasets Inria Aerial Image Dataset and RICE Image Dataset. Subjectively, the remote sensing images processed by the proposed algorithm have a more realistic color, more complete dehazing, clearer features, and better retention of image detail information compared with the images processed by the other algorithms. Objectively, the mean value of image information entropy, the peak signal-to-noise ratio, and the structural similarity of the proposed algorithm are 7.56, 22.05, and 0.87, respectively, which are higher than the values for the four other algorithms. Conclusion The proposed dehazing algorithm model integrates the advantages of image enhancement and recovery, thus making the dehazed remote sensing images natural and realistic. It also effectively recovers remote sensing image detail information.

**Key words:** remote sensing image dehazing, adaptive SLIC, dark channel a priori, Retinex, superpixel segmentation

**Supported by** Fundamental Research Funds for the Central Universities (No. JB211312, XJS221307); Natural Science Basic Research Program of Shaanxi (No. 2023-JC-QN-0299)