

基于 NGDR 和 Logistic 模型的高速公路图像 雾浓度检测算法*

温立民¹, 杨睿¹, 聂磊¹, 吴锋²

1. 长安大学电子与控制工程学院, 陕西 西安 710064
2. 汉滨区农村公路养护中心, 陕西 安康 725000

摘要: 提出了基于 Logistic 函数拟合 S 型散点图的雾浓度评定算法。首先, 提取 LIVE 标准图集归一化灰度差-比散点图先验; 基于散点曲线与视场雾浓度的一一对应关系, 引入 Logistic 函数并推导出适合回归分析的模型。其次, 采用迭代搜索法确定纵向高斯分布的最佳回代样本点, 以提高检测精度。最后, 建立参数估计 $(\hat{\beta}, \hat{\gamma})$ 的查找表, 采用计算相关系数和遍历搜索查找的方法实现雾浓度等级评定。同场景不同浓度图像样本 1 的测试表明, 真实图像的 PM2.5 与查找表 PM2.5 的相关系数达 0.99, 检测误差小于 2.9%; 近似场景不同浓度高速公路图像样本 2 的测试表明, 真实图像 PM2.5 与查找表 PM2.5 值的相关系数达 0.98, 检测误差小于 1.8; 执行效率对比测试表明, 本文算法对于 300 kB 样本图像的处理时间为 19.8 s, 低于同精度数据驱动的深度视觉算法; 检测精度对比测试表明, 本文算法优于其它典型算法。

关键词: 高速公路; 图像; 雾浓度检测; NGDR; Logistic 模型; 回归分析; 查找表

中图分类号: TP391.9 **文献标志码:** A **文章编号:** 2097-0137 (2025) 03-0119-10

Detection algorithm for highway image fog concentration based on NGDR and Logistic model

WEN Limin¹, YANG Rui¹, NIE Lei¹, WU Feng²

1. School of Electronics and Control Engineering, Chang'an University, Xi'an 710064, China

2. Rural Road Maintenance Center of Hanbin District, Ankang 725000, China

Abstract: A fog concentration evaluation algorithm based on logistic function fitting S-type scatter plot was proposed. Firstly, a scatter-plot prior of normalized gray difference-ratio (NGDR) from the standard LIVE image set was extracted, and Logistic functions was introduced to derive a regression analysis model based on the one-to-one correspondence between the scatter curve and the fog concentration. Secondly, the iterative search method was used to determine the optimal sample points of longitudinal Gaussian distribution to improve the detection accuracy. Finally, a lookup table for parameter estimation $(\hat{\beta}, \hat{\gamma})$ was established, and both calculating the correlation coefficient and traversal search were used to evaluate concentration grade. The test of image samples with different concentrations in the same scene 1 shows that the correlation coefficient between PM2.5 in the real image and PM2.5 in the lookup table was 0.99, and the detection error was less than 2.9%. The test

* 收稿日期: 2024-11-26 录用日期: 2024-12-19 网络首发日期: 2025-01-24

基金项目: 陕西省交通厅重点项目(20-38T); 西安市未央区科技计划(202121)

作者简介: 温立民(1976年生), 男; 研究方向: 图像处理与机器视觉;

E-mail: lmwen@chd.edu.cn

全文阅读



ZR20240336

results of highway image sample 2 with different concentrations in the approximate scene show that the correlation coefficient is 0.98, and the detection error is less than 1.8. The comparative test of execution efficiency shows that the processing time of the proposed algorithm for 300 kB sample images is 19.8 s, which is lower than that of the data-driven depth vision algorithm with the same precision. The comparative test of detection accuracy shows that the proposed algorithm is better than other typical algorithms.

Key words: highway; image; fog concentration detection; NGDR; Logistic model; regression analysis; lookup table

根据公安部道路交通事故统计报告,我国年均高速公路阻断事件中,由雾霾引起事故占比高达 25%,甚至有的年份超过 30%(中国气象局, 2020)。我国是多雾国家,特别是在我国南部地区,雾发生的比例更大,因此必须采取有效的雾浓度检测和预报措施。当前用于雾浓度检测的方法主要有卫星遥感、激光雷达和地面检测等。卫星遥感方法只适合高空云雾,对于近地表和地表的雾浓度检测效果不够理想;激光雷达法技术难度高,导致应用范围受限;地面监测法虽可以实现高精度检测,但该方法只适用于定点检测且检测区域有限,不适合高速公路场景雾浓度检测(Mittal et al., 2012)。

对于高速公路场景,如何主动、实时的检测视场雾浓度是需要解决的问题。机器视觉技术的发展为解决这一问题提供了一种可行的低成本方案。Jiang et al.(2020)研制了公路行车辅助系统 ADASs 实现车载雾浓度等级评定,但其主要针对的是如何提高视场的能见度,检测雾浓度只是作为一个辅助功能。温立民等(2017)在自然统计特性基础上采用对比度、信息熵建立多维向量,通过求解空间马氏距离的方法映射视场雾浓度,虽取得了较好的效果,但算法过于复杂。Gallen et al.(2015)通过引入 NBGM 算法将公路监控数据与传感数据融合,经过数据重组与重排实现公路场景雾浓度检测,但因其只能做定点检测,所以适用性较窄。随着神经网络技术的发展,有学者将深度学习技术应用于视场雾浓度检测。Xiao et al.(2023)通过多尺度融合提取图像帧的深度时间序列特征,但因景深测量的复杂性导致效果不佳。Yang et al.(2023)采用视觉融合的深度神经网络构建级联网络架构,实现交通场景雾浓度等级评定,虽取得了较高的评定精度,但该类方法执行效率

不高,同时对硬件依赖度较大。

针对高速公路场景雾浓度检测算法效率低、精度差的问题,本文采用散点回归分析方法实现高速公路视场雾浓度评定。通过实验提取图像雾浓度散点归一化灰度差-比(NGDR, normalized gray difference-ratio)先验规律,采用迭代搜索法计算高斯函数最大概率密度点以确定最佳回代样本,引入改进的 Logistic 函数拟合散点 S 型曲线,推导出适合于散点求解的 Logistic 参数估计方程,并采用查找表和计算相关系数的方法实现了雾浓度等级评定。

1 NGDR 散点先验原理

1.1 标准图像集获取

本文所需要的雾浓度图像,需要满足各种条件,如样本容量、场景、浓度、光照、视场介质等(Sheng et al., 2021; Pal et al., 2023),这些条件会给目标获取带来巨大的障碍,而满足这些条件的图像样本从标准图像集中可轻松获得。当前在图像处理领域较为通用的标准图像库有 O_HAZE、FRIDA 和 LIVE(Rajevenceltha et al., 2024; Wu et al., 2024),其中 LIVE 库拥有门类齐全的图像资源,特别是各种有雾和无雾图像;不仅如此,该图像集的采集条件齐全,其中传播介质包括匀质介质、非匀质介质,光照条件包括各向同性和各向异性,适合各种图像处理和机器视觉应用,具有广泛的权威性,可以满足本文对图像样本的需求。

1.2 NGDR 散点先验

为了获得散点先验首先从标准 LIVE 图像库中选取背景相同或相近的测试图像样本组成标准图像集,图像集包括 1 600 幅无雾图像和 1 600 幅有雾图像,将无雾和有雾图像样本分别按光照和雾

同异性分为4组(每组400个图像样本), 图1为样本示例。4组示例样本的上排为有雾图像, 下排为无雾图像, 并且图1(a)~(d)按有雾图像浓度(PM2.5)逐渐升高顺序排列。

实验中以灰度级为x轴, 以每组图像NGDR值为y轴做散点图, 如图1(e)~(h)所示, 本文定义归一化灰度差-比为 $R_{NGDR} = \frac{I_{fog} - I_{free}}{I_{free} - A}$, I_{free} 为无雾图像灰度, I_{fog} 为有雾图像灰度, A 为天空光灰度。经实验发现, 每组样本的 R_{NGDR} 整体成S形状分布, 且在远景处 R_{NGDR} 趋近于常数, 在近景区域趋近于0, 在远景和近景区域间存在线性段; 在线性段与远景区间存在上凸形态, 在近景区与线性段间存在下凹形态, 中间线性区的倾角会随着雾浓度的

增加而增加。

此外, 实验还表明S型散点分布为一条具有一定宽度粗线条的轨迹, 如图2(b)所示上下边界间为散点分布区域, NGDR散点值在曲线中分布的概率密度不同。考察某一灰度纵向断面概率密度如图2(b), 整体上散点呈现高斯分布, 即在中间区域位置散点分布比较集中, 向两边散点分布越来越稀疏。如前所述, S型散点曲线的线性区倾角会随着视场雾浓度的增大而增大, 并且S型曲线的线性区斜率与标准图集PM2.5近似存在一一对应关系。由此可知, 如果能确定S型曲线的形状或线性区倾角斜率, 则可反向推演出标准图集PM2.5进而映射视场雾浓度, 因此本文拟通过回归分析拟合出S型散点曲线以确定视场雾浓度。

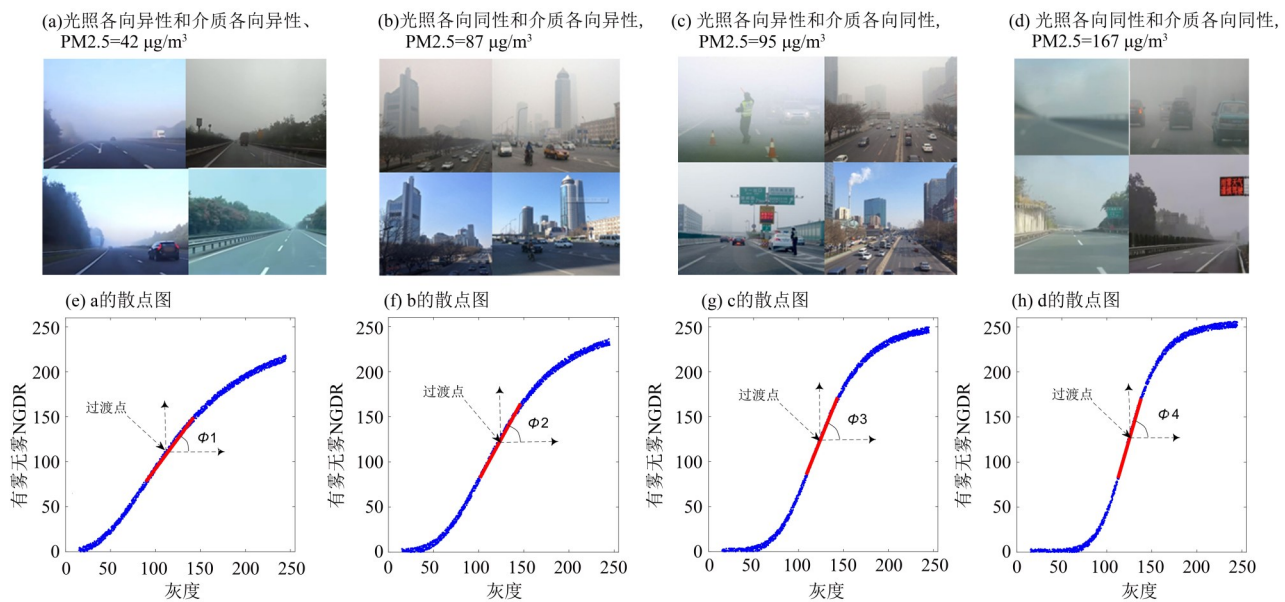


图1 NGDR散点图先验

Fig. 1 Scatter prior of the NGDR

然而, S型散点图是粗线条轨迹, 表明进行回归分析时同一灰度级的回代样本点不是唯一的, 且同一浓度下拟合出的S型曲线也不唯一, 致使检测结果产生较大的误差。因此, 为避免类似的拟合多态性, 需要在众多曲线中确定一条最佳的拟合曲线以获得最佳的检测结果。

由于散点轨迹纵向断面上服从高斯分布, 可以散点的概率分布为切入点, 采用迭代搜索法定位最高概率密度以确定最佳回代样本点, 同时引入Logistic(LGC)模型估计参数(β, γ)以确定S型

曲线, 并制作标准样本集(β, γ)查找表; 通过计算真实视场图像的参数估计($\hat{\beta}', \hat{\gamma}'$)与标准样本集参数轨迹($\hat{\beta}, \hat{\gamma}$)间的相关系数确定雾浓度等级。

1.3 散点样本容量确定

散点样本的容量大小将直接影响最终的检测精度。根据蒙特卡洛回归分析与样本容量关系原理可知, 对于服从正态分布的样本, 样本容量需要满足 $n \geq 3k$, n 为样本容量, k 为待确定因素个数(周佳, 2018; Jad et al., 2022)。本文需确定的因素为2个, 即每个灰度阶至少需6个样本, 则至

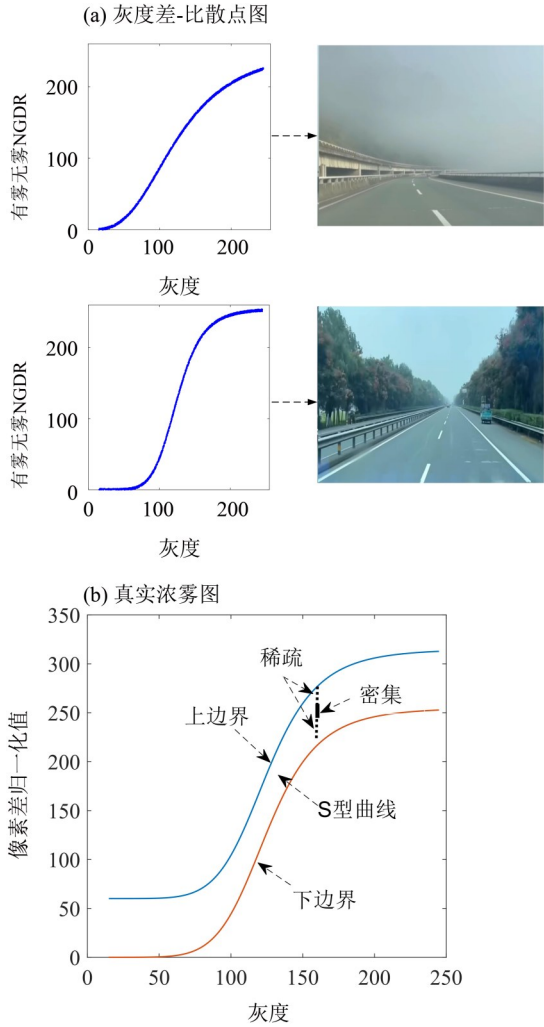


图2 归一化灰度差-比散点图先验
Fig. 2 Scatter prior of the NGDR

少需要有雾和无雾图像样本各 1 536 个方可保证检测精度, 本文取有雾和无雾图像样本各 1 600 个。

1.4 NGDR 先验证明

1.2 节中 NGDR 为从统计实验中获得的散点先验规律, 并不具有一般性。为保证该先验规律具有一般性, 需要对该先验从理论上加以证明。本文从视场中光传播的散射模型入手, 验证散点先验规律(Guy et al., 2023; 张琪东等, 2024)。在图像去雾领域占有重要地位的大气散射模型为

$$I(x, \lambda) = I_0(x, \lambda)e^{-k\beta(x, \lambda)d(x)} + A_\infty(\lambda)(1 - e^{-k\beta(x, \lambda)d(x)}), \quad (1)$$

式中 k 为常数; $I(x, \lambda)$ 为采集设备采集的有雾图像; $I_0(x, \lambda)$ 为同场景下的无雾图像; λ 为入射光线的波长; $\beta(x, \lambda)$ 为传播介质的衰减系数; $d(x)$ 为视场景深函数; $A_\infty(\lambda)$ 为天空光图像, 在真实的采集图像 $I(x, \lambda)$ 中理想的天空光图像不易获得, 实际

使用时通常用像素最大值或高 10% 的像素均值代替。对式(1)进行整理, 得

$$\frac{|I(x, \lambda) - I_0(x, \lambda)|}{|I_0(x, \lambda) - A_\infty(\lambda)|} = e^{k\beta(x, \lambda)d(x)} - 1, \quad (2)$$

式(2)等号左边即为 NGDR 函数, 右边等价于一个过原点的超越函数(或称类指数函数), 其形状与指数函数类似, 这就是散点图出现类线性的原因。与指数函数不同的是, 式(2)右边函数随着 x 的增大不是无限增大, 而是有界函数。由 Wu et al.(2024) 可知, $\beta(x, \lambda) = \frac{13}{d(x)} \cdot \left(\frac{\lambda}{550}\right)^{-q}$, 即衰减系数 β 是波长与景深的函数, 且

$$\lim_{x \rightarrow \infty} k\beta(x, \lambda)d(x) = k.$$

因此, 式(2)右边的 $e^{k\beta(x, \lambda)d(x)} - 1$ 为有界函数, 而归一化灰度差-比函数为 S 型函数。令

$$f(d(x)) = \frac{|I(x, \lambda) - I_0(x, \lambda)|}{|I_0(x, \lambda) - A_\infty(\lambda)|}.$$

$f(d(x))$ 为归一化像素灰度差-比函数。因为式(2)是个超越方程, 所以本文采用拟合分析的方法计算雾浓度, 即首先建立广义灰度散点图、并选取合适的参数点建立拟合函数。

2 基于 Logistic 模型的参数估计

2.1 基于 Logistic 统计拟合函数

为了有效的拟合散点轨迹, 本文引入 Logistic 模型拟合 NGDR 散点图, 并进一步估计视场雾浓度。Logistic 模型为

$$y = \frac{\alpha}{1 + e^{\beta - \gamma x}}, \quad (3)$$

其中 α, β, γ 为可调参数(王雪冬等, 2022; Wichitaksorn et al., 2023), 一组参数对应一个曲线形状。如果能够确定参数 α, β 和 γ , 则可确定曲线形状以及对应的视场雾浓度。将式(3)变形为

$$ye^{\beta} = (\alpha - y)e^{\gamma x}. \quad (4)$$

对式(4)两边取对数, 则

$$\ln y + \beta = \ln(\alpha - y) + \gamma x. \quad (5)$$

由式(3)可知, 参数 α 用于调整拟合曲线最大值, 对应散点图的远景区渐近线, 而在散点图中 S 型轨迹的上渐近线基本保持一定, 此时的 α 可取为常数, 因此式(5)中只需确定参数 β 和 γ 。为此对式(5)两边求集合, 有

$$\sum \ln y + \sum \beta = \sum \ln(\alpha - y) + \sum \gamma x. \quad (6)$$

式(6)即为采用回归分析拟合散点图的 Logistic 参数估计最终模型, α 为常数。但如果将样本值直接带入式(6)估计 (β, γ) , 计算量较大。为简化算法, 需做如下处理:

(1) 选取 N 个样本记为 $y_i, i \in [1, N]$, 其中 N 为自然数。将 N 个样本平均分成两组: 组 1 包括样本 $y_i, i \in [1, n]$; 组 2 包括样本 $y_i, i \in [n + 1, 2n]$; 其中 $n = N/2$ 。

(2) 将每组样本带入式(6), 令

$$\begin{cases} S_1 = \sum_{i=1}^n \ln y_i, \\ S_2 = \sum_{i=n+1}^{2n} \ln y_i, \end{cases}$$

则

$$\begin{cases} S_1 = \sum_{i=1}^n \ln(\alpha - y_i) + \gamma \sum_{i=1}^n x_i - n\beta, \\ S_2 = \sum_{i=n+1}^{2n} \ln(\alpha - y_i) + \gamma \sum_{i=n+1}^{2n} x_i - n\beta. \end{cases} \quad (7)$$

可解得

$$\gamma = \frac{\sum_{i=n+1}^{2n} \ln(\alpha - y_i) - \sum_{i=1}^n \ln(\alpha - y_i)}{\sum_{i=n+1}^{2n} x_i - \sum_{i=1}^n x_i}. \quad (8)$$

将 γ 带入式(7), 得

$$\beta = \left(S_1 - \ln(\alpha - y_i) - \sum_{i=1}^n \frac{x_i}{n} \right) \times \frac{(S_2 - S_1) - \left[\sum_{i=n+1}^{2n} \ln(\alpha - y_i) - \sum_{i=1}^n \ln(\alpha - y_i) \right]}{\sum_{i=n+1}^{2n} x_i - \sum_{i=1}^n x_i}. \quad (9)$$

式(8)和(9)为回归分析参数估计模型。将样本值带入式(8)后可估计参数 $\hat{\gamma}$, 当将样本值带入式(9)后, 可估计参数 $\hat{\beta}$ 。参数 $\hat{\beta}$ 和 $\hat{\gamma}$ 确定后, 对应的 S 型曲线也就得以确定。

2.2 基于高斯分布的最佳回代样本点搜索

最佳回代样本点应该在散点高斯分布最大概率密度处。本文采用迭代搜索法确定最大概率点。高斯分布概率密度函数为

$$P(R) = \frac{1}{\sqrt{2\pi} \sigma} \exp\left(-\frac{(R - \mu)^2}{2\sigma^2}\right), \quad (10)$$

式中 R 为归一化灰度差-比值; 纵向均值 $\mu = \sum R_i / m$, 纵向标准差 $\sigma = \sqrt{\sum (R_i - \mu)^2 / m}$, m 为各灰度级纵向断面散点个数。当均值和标准差确定后, 可采用迭代搜索法确定最大概率密度,

搜索流程如图 3 所示:




图3 迭代搜索最佳样本点

Fig. 3 Iteratively search for the best sample points

(1) 统计每个灰度级上的归一化灰度差-比 (NGDR) 值和散点个数 n , 计算均值 μ 和标准差 σ ;

(2) 将 μ, σ 和下边界归一化灰度差-比值代入公式(10), 计算概率密度初值 $P(R_0)$; 然后计算 $P(R_i) = P(R_0 + i\Delta R), i \in \{1, 2, \dots, m\}$;

(3) 比较 $P(R_i), P(R_{i+1})$ 的大小, 若 $P(R_{i+1}) > P(R_i)$ 则继续搜索; 若 $P(R_{i+1}) < P(R_i)$, 表明已搜索到最大值概率密度 P_{max} , 则 P_{max} 对应的 NGDR 值即为最佳回代样本点, 此时将最佳回代样本点带入式(8)、(9)即可实现参数 (β, γ) 的估计。

3 基于 Logistic 的雾浓度检测流程

如图 4 所示, 采用回归分析法, 估计参数 $(\hat{\beta}, \hat{\gamma})$ 的流程为:

(1) 在 LIVE 库中选择合适的样本组成标准图集, 以灰度级 $[1, 255]$ 为横轴, 以标准图集的 NGDR 值为纵轴绘制散点图, 统计每个灰度级上的散点个数和对应的 NGDR 值, 记 $R_{i,j} \in \{R_{i,1}, R_{i,2}, R_{i,3}, \dots, R_{i,n}\}$ 为第 i 灰度级的第 j 个 NGDR 值;

(2) 按迭代搜索算法确定各灰度级最大概率密度, 以确定每个灰度级上的最佳回代样本值, 将所有最佳回代样本值代入回归方程(8)和(9)估计参数 $\hat{\beta}, \hat{\gamma}$, 同时拟合 Logistic 曲线;

(3) 选取不同浓度的标准图集, 重复步骤(1)和(2), 拟合出不同雾浓度对应的 Logistic 曲线, 同时计算并记录每级浓度对应的参数估计值 $(\hat{\beta}, \hat{\gamma})$;

(4) 按步骤(1)~(3)所述方法将所有雾浓度的

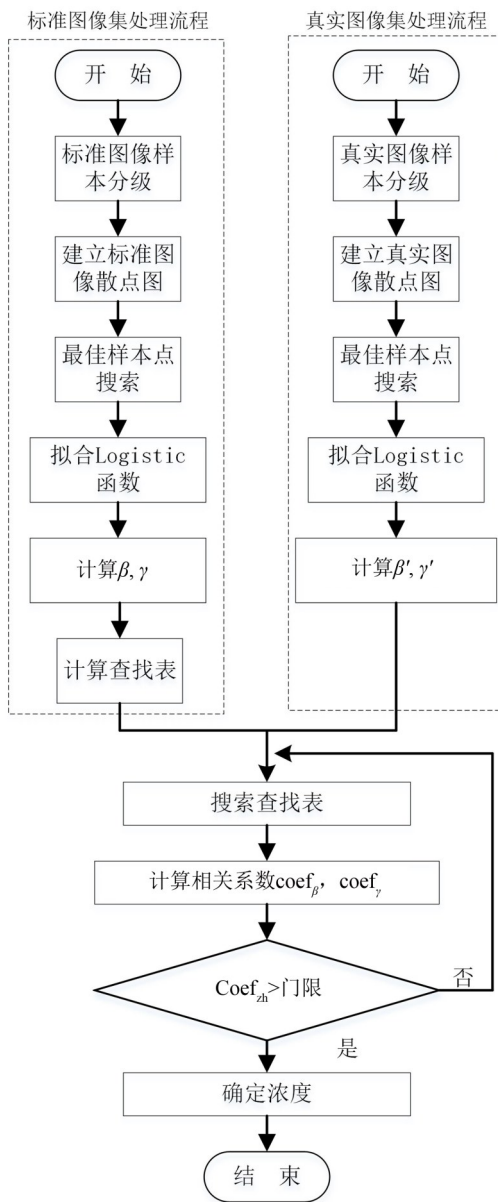


图4 参数估计流程

Fig. 4 Flow of parameter estimation

参数估计完毕后，以标准图像雾浓度由小到大的顺序排列相应的估计参数 $(\hat{\beta}, \hat{\gamma})$ ，并建立 $(\hat{\beta}, \hat{\gamma})$ 与 PM2.5 对应的查找表，如表 1 所示，表 1 只给出 $(\hat{\beta}, \hat{\gamma})$ 部分值。由于实验中测得 γ 的变化范围为 $[0.025, 0.09]$ ，意味着数值分辨率较低且图像对 γ 的变化较为敏感。为了提高分辨率，查找表中 γ 值是取倒数，则此时 γ 的取值范围变为 $[11, 40]$ 。

(5) 查找表建立后，可以将查找表作为标尺衡量真实图像雾浓度，步骤如下：

1. 参照步骤(1)建立真实图像(记为 I')的有雾和无雾 NGDR 散点图，如图 2(a)、(b)所示；
2. 采用回归分析法计算 I' 的 Logistic 模型函数，并计算相应的参数估计，记为 $(\hat{\beta}', \hat{\gamma}')$ ；
3. 计算标准图像集 $(\hat{\beta}, \hat{\gamma})$ 和真实图像集参数 $(\hat{\beta}', \hat{\gamma}')$ 的相关系数

$$\text{coef}_{\beta} = \frac{\text{cov}(\beta, \beta')}{\sqrt{D(\beta)} \sqrt{D(\beta)'}}$$

$$\text{coef}_{\gamma} = \frac{\text{cov}(\gamma, \gamma')}{\sqrt{D(\gamma)} \sqrt{D(\gamma)'}}$$

式中 coef_* 为 β 和 γ 标准图像集与真实图像集间的相关系数， $\text{cov}(*, *)$ 为二者间的协方差， $\sqrt{D(*)}$ 和 $\sqrt{D(*)'}$ 为各自的标准差；

4. 计算综合相关系数

$$\text{coef}_{th} = \omega_{\beta} \text{coef}_{\beta} + \omega_{\gamma} \text{coef}_{\gamma}$$

式中 ω_{β} 、 ω_{γ} 为权重系数。经实验测试，权重 $\omega_{\beta} = 0.23$ ， $\omega_{\gamma} = 0.77$ 为最佳；

5. 建立遍历搜索进程，搜索相关系数 coef_{th} 大于门限的 $(\hat{\beta}, \hat{\gamma})$ ；

6. 搜索查找表 1，确定当前雾浓度，即查表后的 PM2.5 (本文称为查表 PM2.5)。

表 1 (β, γ) 估计与浓度对应表

Table 1 Correspondence table of (β, γ) stimation and concentration

$(\hat{\beta}, \hat{\gamma})$	PM2.5	$(\hat{\beta}, \hat{\gamma})$	PM2.5	$(\hat{\beta}, \hat{\gamma})$	PM2.5	$(\hat{\beta}, \hat{\gamma})$	PM2.5	$(\hat{\beta}, \hat{\gamma})$	PM2.5	$(\hat{\beta}, \hat{\gamma})$	PM2.5
(1,35)	14	(2,25)	56	(4,37)	100	(5,35)	142	(6,35)	181	(7,21)	220
(1,23)	28	(3,35)	70	(4,27)	114	(5,25)	156	(6,25)	200	(8,30)	231
(2,30)	42	(3,24)	84	(4,20)	128	(5,19)	170	(7,30)	211	(8,14)	245

4 仿真实验

4.1 实验条件

本文实验仿真平台为：CPU 酷睿 i7，内存容量 32 GB，配有独立显卡和 GPU 加速卡(根据需要

有或无)；仿真软件为 matlab 2016。本文选取的测试图像样本为标准 LIVE 图像集和随机采集的有雾和无雾图像，图分辨率从 300×200 dpi 到 1024×768 dpi 不等。

4.2 相关性及精度测试

4.2.1 测试实例1 为验证算法的有效性, 需要进行相关性测试。在雾浓度评定中通常以PM2.5作为度量标准, 如果能证明本文算法与PM2.5存在相关性, 则表明本文算法也可以用于雾浓度的度量。用X表示本文算法样本向量值, 用Y表示PM2.5样本向量值, 则相关系数可按下式计算:

$$\rho_{XY} = \frac{E(XY) - E(X)E(Y)}{\sqrt{E(X^2) - E^2(X)} \sqrt{E(Y^2) - E^2(Y)}} \quad (11)$$

选用同场景不同浓度图像的样本进行测试, 选用该组图像的原因: 1)该组图像是同场景, 可以避免复杂背景带来的干扰; 2)该组图像是连续14天拍摄, 而且PM2.5值每个级别都有出现; 3)每幅图像对应的雾浓度(PM2.5真实值)都有预报记录, 为算法的相关性检测和精度测量提供了数据支持。测试时, 将14幅样本图像从左到右从上到下按浓度由小到大的顺序排列, 并编号1-14#。图像真实浓度见表2第2行和第7行, 采用本文算法估计的参数($\hat{\beta}$, $\hat{\gamma}$)如表2的3、8行所示, 查表PM2.5在表2的4、9行。以图像真实PM2.5数据为横坐标, 以查表PM2.5值为纵坐标, 所得曲线如图5所示。该曲线近似为直线, 将真实PM2.5与本文查表PM2.5值代入式(11), 计算得到的相关系数为0.99, 表明本文测量值与样本真实值高度相关且近似呈线性。




图5 样本1测试性能

Fig. 5 Test results of sample 1

为了验证算法的准确性, 需要进行精度误差测试, 计算公式为:

$$E_{err} = \frac{|\text{查表PM2.5} - \text{真实PM2.5}|}{\text{真实PM2.5}} \times 100\% \quad (12)$$

样本的误差如表2所示。误差曲线为图5中的洋红色曲线。由误差曲线可知, 测量误差随着视场雾浓度的增加而减小, 误差最大点在低浓度区为2.9%, 原因在于低浓度区PM2.5值较小, 而公式(12)中分母为真实PM2.5值, 导致同样的测量绝对误差值在低浓度区域相对误差较大。

表2 样本2测试数据

Table 2 Sample 2 test data

序号	1	2	3	4	5	6	7
PM2.5	34	48	70	85	101	116	132
($\hat{\beta}$, $\hat{\gamma}$)	(1,18)	(2,28)	(3,35)	(3,25)	(4,38)	(4,26)	(4,18)
查表PM2.5	33	49	72	84	102	114	130
误差/%	2.90	2.00	2.80	1.17	0.99	1.72	1.50
序号	8	9	10	11	12	13	14
PM2.5	151	165	180	201	216	244	258
($\hat{\beta}$, $\hat{\gamma}$)	(5,26)	(5,22)	(6,35)	(6,25)	(7,29)	(8,15)	(9,28)
查表PM2.5	154	163	179	200	214	243	256
误差/%	1.98	1.21	0.50	0.50	0.90	0.40	0.77

4.2.2 测试实例2 测试样本2由背景、光照、雾同异性相近的15幅高速公路图像组成, 15幅样本图像从左到右从上到下按视场浓度(PM2.5已知)增大的顺序排列, 测试结果如表3和图6所示。显

然, 对于背景、光照相近的高速公路样本图像, 测试值和样本真实值正相关或呈线性, 经计算相关系数为0.98; 洋红色的径型线为误差曲线。经测定, 样本2的误差同样是随着雾浓度的增加而减

表 3 样本 2 测试数据
Table 3 Sample 2 test data

序号	1	2	3	4	5	6	7	8
PM2.5	54	62	81	95	102	113	126	143
$(\hat{\beta}, \hat{\gamma})$	(1, 18)	(2, 28)	(3, 35)	(3, 25)	(4, 38)	(4, 26)	(4, 18)	(5, 34)
查表 PM2.5	55	63	80	94	101	115	124	142
误差/%	1.8	1.6	1.2	1.0	0.98	1.7	1.5	0.6
序号	9	10	11	12	13	14	15	
PM2.5	158	162	181	205	218	240	256	
$(\hat{\beta}, \hat{\gamma})$	(5, 26)	(5, 22)	(6, 35)	(6, 25)	(7, 29)	(8, 15)	(9, 28)	
查表 PM2.5	157	163	179	206	216	242	257	
误差/%	0.6	0.6	1.1	0.4	0.9	0.8	0.4	

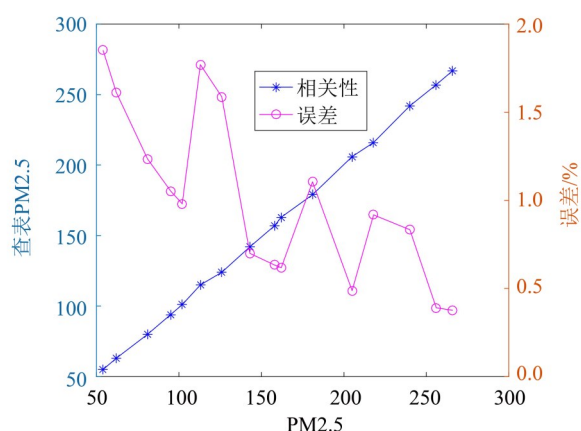


图 6 样本 2 的测试性能

Fig. 6 Test results of sample 2

小, 最大误差为 1.8%, 表明本文算法可以用于高速公路雾浓度检测。

4.3 横向对比测试

温立民等(2017)是通过建立空间向量组, 计算

有雾图像和无雾图像间的马氏距离实现视场雾浓度度量; Xiao et al.(2023)采用多尺度融合提取图像帧深度时间序列特征实现雾浓度等级评定; Yang et al.(2023)采用视觉融合的深度神经网络实现雾浓度检测。因每个文献侧重的角度不同, 衡量标准也不同, 为统一标准引入 MOS(mean opinion scores)值(温立民等, 2017)¹⁸⁹²⁻¹⁸⁹³, MOS 是一种通用的评定图像对比度的方法, 而图像对比度能用于映射视场雾浓度, 因此本文也采用 MOS 法作为对比度衡量指标。

选择不同路段、不同时刻、不同雾浓度图像, 组成如图 7 所示的测试样本, 同样将样本按浓度由小到大的顺序排列。以图像序号为横坐标、对比度为纵坐标, 绘制如图 8(a)所示的曲线, 蓝色正方形曲线为参考标准 MOS 测试结果, 红色的星花线为本文的测试结果, 紫色的径型线为 Yang et al.(2023)的测试结果, 绿色的上三角为 Xiao et al.



图 7 同场景不同雾图

Fig. 7 Fog image with same scene




图8 本文算法与经典文献结果对比

Fig. 8 The results of algorithm in this paper compared with the classic literature

(2023)测试结果, 黑色的点画线为温立民等(2017)的测试结果。因该成果采用的是通过计算图像样本对比度空间马氏距离的方式映射雾浓度, 在计算马氏距离时难以保证向量正交, 因此对比度计算值与本文及Xiao et al.(2023)、Yang et al.(2023)相比整体上相差较大; 温立民等(2017)属于数据驱动的深度学习方法, Xiao et al.(2023)测试目标是检测视场能见度, 同样需要将能见度指标转换为对比度指标进行比较。由图8(a)可知, Xiao et al.(2023)、Yang et al.(2023)的对比度与本文算法基本一致, 但Yang et al.(2023)与Xiao et al.(2023)的方法整体上波动较大。图8(b)中误差

$$E_D = \frac{|D_* - D_{MOS}|}{D_{MOS}} \times 100\%$$

D_* 为每种算法的对比度转化值, D_{MOS} 为MOS方法的检测值。由误差曲线可知, 温立民等(2017)整体上误差值较高; 本文与Yang et al.(2023)、Xiao et al.(2023)相比检测误差较低, 表明整体上本文的检测精度要优于其它几种算法。

参照唐晓庆等(2015)、Tannistha et al.(2023)给出的算法效率评定方法, 选取4组图像集为对象(每组图像集各100幅, 图像样本大小分别为1.4、40、200、300 kB)进行耗时测试, 各算法测试结果如图9所示。由图9可知, MOS方法作为参考基准执行效率最高; 本文与温立民等(2017)的算法时间复杂度处在一个数量级上, 但相比温立民等(2017)本文执行效率要更优; Xiao et al.(2023)和Yang et al.(2023)因采用神经网络算法, 无论是在硬件消耗还是时间消耗上都远高于本文和温立民等(2017)的算法, 且时间消耗随着测试样本大小




图9 算法时间测试

Fig. 9 Test time of algorithm

的增加迅速增加。当样本图像大小为300 kB时, Xiao et al.(2023)和Yang et al.(2023)所需时间分别约为1 200 s和1 500 s, 这是在增设GPU加速卡的情况下。本文在没有GPU卡的情况下, 对于300 kB的图像样本处理速度为19.8 s, 远低于Xiao et al.(2023)和Yang et al.(2023)的耗时, 表明本文算法更适合高速公路场景的雾浓度检测。

5 结论

本文在实验基础上提出基于标准图像集的PM2.5散点先验, 并将回归分析与散点图先验相结合, 通过引入Logistic函数拟合S型散点图; 采用迭代搜索法计算高斯函数最大概率密度以确定最佳回代样本点; 通过建立和搜索查找表的方法实

现雾浓度等级评定。经相关性、精度及实际样本的仿真测试,验证了本文算法执行效率更优。

但本文算法仍有需改进的地方,主要是:计算相关系数时权重系数 ω_β 、 ω_γ 是通过实验得到,还不能实现自适应确定;所建立的参数 (β, γ) 查找表具有离散特性,只能采用估值方法确定非表中

值的数据;搜索算法中,纵向断面服从高斯分布,这是从实验角度出发得出的结果,若偶尔出现不服从高斯分布的断面散点,则概率密度峰值可能多于一个,在此情况下检测结果将出现较大误差,因此需要做进一步的研究。

参考文献:

- 唐晓庆,范赐恩,刘鑫,2015. 基于边缘保持滤波的单幅图像快速去雾[J]. 西安交通大学学报,49(3):143-150.
- 王雪冬,张超彪,王翠,等,2022. 基于 Logistic 回归与随机森林的和龙市地质灾害易发性评价[J]. 吉林大学学报(地球科学版),52(6):1957-1970.
- 温立民,巨永锋,闫茂德,2017. 基于自然统计特征分布的交通图像雾浓度检测[J]. 电子学报,45(8):1888-1895.
- 张琪东,迟静,陈玉妍,等,2024. 基于雾浓度分类与暗-亮通道先验的多分支去雾网络[J]. 计算机研究与发展,61(3):762-779.
- 周佳,2018. 蒙特卡罗模拟在计量经济学中的应用——以样本容量对回归分析的影响为例[J]. 中国商论,22:161-163.
- 中国气象局,2020. 气象与交通专家解析如何科学防御减轻雾的影响[EB/OL]. https://www.cma.gov.cn/2011xzt/2012zhuant/20120102/2012010204/201110/t20111028_3093508.html.
- GALLEN R, CORD A, HAUTIERE N, et al, 2015. Nighttime visibility analysis and estimation method in the presence of dense fog [J]. IEEE Trans Intell Transp Syst, 16(1): 310-320.
- GUY H, BROOKS I M, TURNER D D, et al, 2023. Observations of fog-aerosol interactions over central Greenland [J]. JGR: Atmospheres, 128(13):1-24.
- JAD B, ERIC G, 2022. Factor and factor loading augmented estimators for panel regression with possibly non-strong factors [J]. J Bus Econ Stat, 41(1):270-281.
- JIANG Y, ZHANG N, LI A X, et al, 2020. Effects of weather on highway traffic capacity in China: Characteristics and causes of roadblocks due to fog events [J]. Pure Appl Geophys, 177(10):5027-5040.
- MITTAL A, MOORTHY A K, BOVIK A C, 2012. No-reference image quality assessment in the spatial domain [J]. IEEE Trans Image Process, 21: 4695.
- PAL T, HALDER M, BARUA S, et al, 2023. A deep learning model to detect foggy images for vision enhancement [J]. Imag Sci J, 71(6):484-498.
- RAJEVENCELTHA J, GAIDHANE V H, 2024. A no-reference image quality assessment model based on neighborhood component analysis and Gaussian process [J]. J Vis Commun Image Represent, 98:104041.
- SHENG D, DENG J, XIANG J W, 2021. Automatic smoke detection based on Slic-DbSCAN enhanced convolutional neural network [J]. IEEE Access, 9(19): 63933-63942.
- WICHITAKSORN N, KANG Y, ZHANG F, 2023. Random feature selection using random subspace logistic regression [J]. Expert Syst Appl, 217(5):119535.
- WU W, HUANG D, YAO Y, et al, 2024. Feature rectification and enhancement for no-reference image quality assessment [J]. J Visual Commun Image Represent, 98(9):104030.
- XIAO P, ZHANG Z, LUO X, et al, 2023. Highway visibility estimation in foggy weather via multi-scale fusion network [J]. Sensors, 23(24):9739.
- YANG W C, ZHAO Y T, LI Q, et al, 2023. Multi visual feature fusion based fog visibility estimation for expressway surveillance using deep learning network [J]. Expert Syst Appl, 234(9): 121151.

(责任编辑 王海蓉)