

DOI: 10.19650/j.cnki.cjsi.J2412494

# 基于视觉的夜间细颗粒物浓度估计\*

翔云<sup>1,2</sup>, 张凯华<sup>1,2</sup>, 陈作辉<sup>1</sup>, 宣琦<sup>1,2</sup>

(1. 浙江工业大学网络空间安全研究院 杭州 310023; 2. 滨江区浙工大人工智能创新研究院 杭州 310052)

**摘要:** 基于视觉的细颗粒物浓度( $PM_{2.5}$ )估计技术依据成像时悬浮细颗粒物对光线散射和吸收的整体影响来评估其浓度。这类技术具备良好的普适性,可实时检测广阔区域。已有研究依赖大气光均匀且充足的日间场景,无法适用于缺乏大气光且光照不均匀的夜间场景。本文提出首个基于视觉的夜间 $PM_{2.5}$ 浓度估计方法,通过图像处理捕获人造光源在不同散射方向的光强分布,并以此特征拟合浓度值。该方法创新地将人造光源及周边光晕区域视为夜晚雾霾信息的主要来源。由于夜间自然光照强度相对人造光源较低,其主导的区域往往趋于漆黑,导致日间雾霾信息的主要来源(自然光照下像素颜色随着景深增加而逐渐接近“大气光/天空”颜色)在夜间的作用相比光源处要小很多。该方法明显优于日间 $PM_{2.5}$ 估计方法,平均误差(MAE)为 $6.187 \mu\text{g}/\text{m}^3$ ,决定系数( $R^2$ )为0.857,对比最新的端到端的神经网络方法在MAE和 $R^2$ 上分别有20.69%、13.36%的相对提升。

**关键词:** 空气质量估计; 计算机视觉; 细颗粒物; 光晕; 夜间图像

中图分类号: TH89 TP75 文献标识码: A 国家标准学科分类代码: 520.20

## Vision-based night-time fine particulate matter concentration estimation

Xiang Yun<sup>1,2</sup>, Zhang Kaihua<sup>1,2</sup>, Chen Zuohui<sup>1</sup>, Xuan Qi<sup>1,2</sup>

(1. Institute of Cyberspace Security, Zhejiang University of Technology, Hangzhou 310023, China;

2. Binjiang Institute of Artificial Intelligence, ZJVT, Hangzhou 310056, China)

**Abstract:** The technique for estimating the concentration of fine particulate matter ( $PM_{2.5}$ ) based on visual cues relies on assessing its concentration by considering the overall effect of suspended fine particles on light scattering and absorption during imaging. These technologies demonstrate robust generalizability and real-time detection capabilities across large-scale areas. Existing studies depend on daytime scenes with uniform and sufficient atmospheric light, limiting their applicability to nighttime scenario with insufficient atmospheric light and uneven illumination. This paper introduces the pioneering vision-based nighttime estimation method of fine particulate matter concentration, which captures the intensity distribution of an artificial light source in various scattering directions through image processing, and utilizes the feature to correlate with fine particulate matter concentration. The proposed method innovatively leverages the artificial light source and its surrounding glowing area as the main source of nighttime haze information. Since areas dominated by natural lighting typically appear black at night, the conventional basis for daytime haze estimation (i.e., pixel value approaching the color of “atmospheric-light/sky” as the depth of field increases), is barely useful at night. This method outperforms existing daytime haze estimation methods, achieving a mean absolute error (MAE) of  $6.187 \mu\text{g}/\text{m}^3$  and a correlation coefficient ( $R^2$ ) of 0.857. Compared to the popular end-to-end neural network method, it shows a relative improvement of 20.69% in MAE and 13.36% in  $R^2$ .

**Keywords:** air quality estimation; computer vision; fine particulate matter; glow; nighttime image

## 0 引言

细颗粒物(2.5-micrometer particulate matter,  $PM_{2.5}$ )

是大气环境监测的主要检测指标之一,由直径小于 $2.5 \mu\text{m}$ 的各种颗粒物组成,能作为重金属、细菌、病毒等有害物质的载体<sup>[1]</sup>,侵入人体诱发疾病。研究证明长期暴露在 $PM_{2.5}$ 污染环境中会提高呼吸系统疾病和心血管

疾病的死亡率和发病率,2017年中国因 $PM_{2.5}$ 空气污染的死亡人数近100万,随着我国人口结构的变化 $PM_{2.5}$ 已成为国民预期寿命的主要威胁之一<sup>[2-4]</sup>。

长期以来,研究人员依赖基于称重、微振荡天平法或 $\beta$ 射线法的实验室结果来测量 $PM_{2.5}$ 浓度<sup>[5]</sup>。尽管此类方法是准确的,但其覆盖范围有限且建设和维护成本高昂。基于光散射传感器的空气质量传感器有类似的局限性<sup>[6-7]</sup>。基于卫星遥感的方案根据夜间灯光、热通道、气象地形等数据提升空间分辨率,但在照明不佳的郊区表现不佳且面临成本和实时性问题<sup>[8-9]</sup>。相比之下,相机因其经济性和普适性被广泛部署在各种户外环境中,在道路监测、安防监控、环境监测等领域<sup>[10]</sup>发挥作用。由于大气污染物造成的光线散射和吸收会影响拍摄的图像质量,这些差异可被应用到污染物监测任务中。已有多项基于视觉的日间空气质量估计技术,它们利用空间对比度、暗通道、语义色差等变化来评估目标环境中的污染物浓度,相比空气监测站具有更高的空间分辨率。

Zhang等<sup>[11]</sup>描述了一种利用图块颜色的散射和吸收特征来同时估计多种污染物的方法。Su等<sup>[12]</sup>设计了一个端到端的卷积神经网络(convolutional neural networks, CNN)来估计多个大气环境参数。Wang等<sup>[13]</sup>结合RGB帧和相应的语义分割视频帧,开发了一种双通道空气质量测量方法。Wang等<sup>[14]</sup>基于多模态实现图像特征融合,通过测量雾霾图像与其去雾图像之间熵、颜色和深度信息的差异以表示 $PM_{2.5}$ 引起的结构损失、颜色损失和深度损失实现浓度估计。但上述方法包含两个共同前提要素,充足且均匀的大气光和场景中可反演的景深变化,因此并不适用于夜间污染估算。

在弱光环境下,由于大气光的减少导致能见度显著下降,大多数的场景细节是难以被观测的。同时,夜间环境更容易收到系统噪声影响<sup>[15]</sup>。日间算法在经典雾图成像模型的基础上分析直射光、大气光、透射率、场景深度和大气污染物浓度之间的关系,即污染物浓度和场景深度影响透射率进而改变相机捕获的直射光与大气光的比例,使得远景变得模糊并趋于大气光的颜色。因此这些技术并不适用于夜间场景。

另一方面,图像去雾和基于视觉的空气质量估计技术密切相关,都是关于处理图像中的雾霾效应。图像去雾旨在消除雾霾影响并提高图像质量,而后者则量化雾霾影响的程度。He等<sup>[16]</sup>提出使用暗通道先验和全局大气光来估计雾霾图像中的透射率。尽管暗通道被广泛用于日间空气质量估计<sup>[17-18]</sup>,但由于暗通道先验是建立在日间图像集上的统计经验,因而此类方法不适用于夜间。日间暗通道中的低强度归因于可见因素,例如彩色物体、黑暗表面或阴影,而在夜间低照

明度下大片区域趋于漆黑,此时不可见因素是暗通道中的低强度的主要原因。Li等<sup>[19]</sup>根据平滑先验将辉光图与夜间图像分开,然而这种方法生成的辉光图中容易出现噪声和色偏问题从而降低准确性。本文在实验部分比较了所提的辉光特征与其他特征图(暗通道、亮度、饱和度)。

受夜间去雾工作的启发,本文提出一种通过光晕<sup>[20]</sup>,即光源(一般是人造光源)周围的辉光,来估计夜间 $PM_{2.5}$ 浓度的方法。稠密人口地区夜间照明的普及使得光晕在夜间图像中很常见,同时这些地区的 $PM_{2.5}$ 污染也影响较多的人口。光晕是光源辐射受附近细微粒子影响在一次或多次散射后造成的,视觉上形成为光源为起点向外辐射的光亮区域。(散射)颗粒浓度与光晕图像相关,因此可用于估计 $PM_{2.5}$ 浓度。此外光晕的成像效果与光源照度、相对位姿、相机的固有属性(曝光量、分辨率、光学倍率、焦距、信号采集等)也是相关的。不失一般性,本文讨论固定场景下从单张智能摄像机捕获的点光源图像中推断环境 $PM_{2.5}$ 浓度,在此设计下影响成像的两大隐变量分别是大气 $PM_{2.5}$ 浓度和相机自适应的曝光量。由于夜间成像的复杂性,原始图像往往包含冗余信息(背景颜色和纹理、前景阻挡等)和噪声,获取有效的光晕特征并估计 $PM_{2.5}$ 浓度的步骤为:1)定位光源的位置;2)异常值检测;3)特征提取,并建立特征空间;4)使用贝叶斯岭回归器拟合浓度。

## 1 基本原理

基于光的散射原理,当光照射空气中的细颗粒物时发生散射。散射光的偏离方向和强度与细颗粒物浓度是相关的。基于激光散射的 $PM_{2.5}$ 传感器可以通过光度计检测特定方向上散射光脉冲信号的数量和强弱,并使用算法转换为所需的 $PM_{2.5}$ 浓度计量单位<sup>[21]</sup>。

基于相同的原理,基于光晕的夜间 $PM_{2.5}$ 估计方法通过相机捕获人造光源的散射光强实现 $PM_{2.5}$ 估计。其中人造光源和相机的作用分别类似于传感器中的激光光源和光度计。两者的区别在于:1)不同于激光,人造光源一般是非定向的,因此需要考虑真实场景中反射光引入的干扰。2)相机能同时检测不同偏离方向上的散射光强并展示为图像。

所提估计方法如图1所示,首先通过计算光源中心作为极坐标原点将图像分割为扇环块;之后剔除图块内的异常像素值并计算剩余像素值的统计量作为指定散射方向的光强特征,不同散射方向的光强特征拼接为光源光晕的特征向量,最后使用贝叶斯岭回归器将特征向量映射为 $PM_{2.5}$ 估计值。

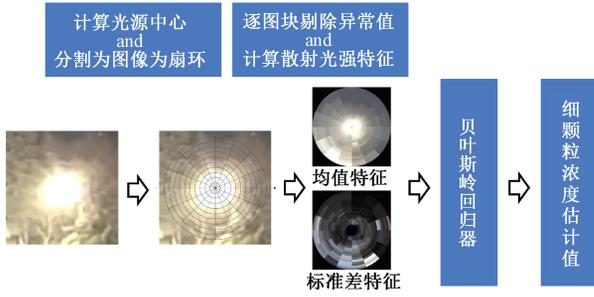


图1 基于视觉的细颗粒物浓度估计方法框架  
Fig.1 Framework of vision-based fine particulate matter concentration estimation method

## 2 算法设计

### 2.1 光晕强度与颗粒物浓度的关联性分析

如图2所示,Narasimhan等<sup>[20]</sup>在球协函数的基础上构建大气点散射函数,将暗室环境中的光晕图像建模为光源与二维卷积的输出:

$$G(T, \mu) = \sum_{m=0}^{\infty} (g_m(T) + g_{m+1}(T)) L_m(\mu) \quad (1)$$

其中,  $G$  是光源图像, 光学厚度  $T = \sigma R$ , 其中  $R$  是辐射深度,  $\sigma$  是大气消光系数, 表示在单位大气体积内由于散射而造成的通量损失的比例。散射方向的余弦值  $\mu = \cos\theta = \cos(\arctan r/d)$ ,  $\theta$  是散射方向,  $d$  是焦距,  $r$  是像素位置相对直射点的偏移距离。  $L_m$  是  $m$  阶勒让德多项式,  $g_m$  是给定的系数数列:

$$g_m(T) = I_0 e^{h(m,q,T)}$$

$$h(m,q,T) = -\frac{2m+1}{m}(1-q^{m-1})T - \log T^{m+1} \quad (2)$$

式中:  $q = 0.75$  为雾霾介质下相函数的前向散射参数。

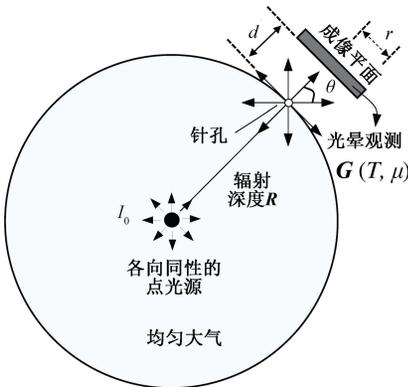


图2 均匀介质中点光源的光晕成像模型  
Fig.2 Glow imaging model of point light source in homogeneous medium

假设光源强度(流明)为  $I_0$ , 式(1)可简化为:

$$G(T, \mu) = \sum_{m=1}^{\infty} g_m(T) (L_{m-1}(\mu) + L_m(\mu)) = I_0 \cdot A_T \cdot e^{-f(T, \mu)} \quad (3)$$

其中,  $A_T$  是  $\mu = 1$  时的初值,  $f(T, \mu)$  是满足式(3)的函数。

由于相机与光源的相对位置是固定的,即辐射深度  $R$  被视为常量,已有研究证明大气消光系数  $\sigma$  与  $PM_{2.5}$  浓度呈现较好的线性关系<sup>[22]</sup>,因此光学厚度  $T$  与  $PM_{2.5}$  浓度是线性关系。由式(3)可知,散射方向  $\theta$  处相机捕获的光晕强度与光学厚度 ( $PM_{2.5}$  浓度) 相关,公式图像如图3所示。归一化后不同光学厚度 ( $PM_{2.5}$  浓度) 下光晕强度的随散射方向的变化规律如图3(a)所示,在相同散射方向上  $PM_{2.5}$  浓度、光学厚度、光晕强度是正相关的。低污染浓度环境中散射光强较为集中,而污染浓度较高时散射光强较为分散。

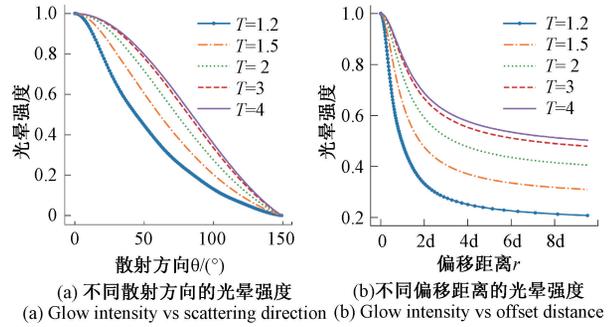


图3 不同光学厚度 ( $PM_{2.5}$ ) 下的光晕强度衰减

Fig.3 Glow intensity attenuation with different optical thicknesses ( $PM_{2.5}$ )

如图3(b)所示,经过变量代换后光晕强度与偏移距离近似于指数关系,不同光学厚度 ( $PM_{2.5}$  浓度) 下呈现分层结构,本文称该现象为指数衰减先验。后续数据分析验证这一先验(见3.2节),在低污染物浓度中光晕强度的衰减速度明显快于高污染物浓度环境,并按  $PM_{2.5}$  浓度存在明显的分层现象。

### 2.2 特征提取和回归估计

真实夜间图像常包含物体的色彩、边缘等多种干扰信息,受此影响光晕的模式通常是不明显的。此类干扰可以归结为结构型和异常值两类,前者指物体边缘、纹理信息,比如树叶;后者则是镜面反射或前景物体的阻挡影响,呈现为亮斑或暗斑。从图像中提取有效特征是优化模型性能的关键,本节通过定位光源、异常值检测和建立特征空间实现该过程。

#### 1) 定位光源

户外图像常包含多个可见光源,但有限的光源照度和/或较远的光传输距离会降低光晕特征的可视性,

因此适用的光源个数是有限的。这类光源需具备较强的照度、适中的物距,并且所处区域尽可能远离干扰因素(其他固定/移动光源、可见的背景)。如图4所示,光源明显优于其他光源,被选取作为本文研究对象。对于存在多个适用光源的场景可采用集成方法将所提模型作为基学习器,对每个光源独立并行地建立估计模型,随后结合(比如加权平均)多个结果得到最后的估计值。

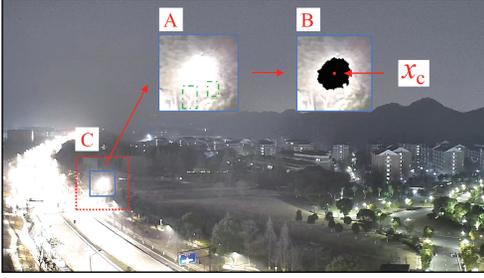


图4 目标光源( $PM_{2.5}$  为  $49.5 \mu g/m^3$ )

Fig. 4 Target light source( $PM_{2.5}$  is  $49.5 \mu g/m^3$ )

对于相机的视角可能存在的小幅偏移,指定光源图块后需先定位光源的图像位置。算法1基于图块(图4中图块A)中饱和区域(白色区域)的形态来实现像素级的光源定位。对于非饱和光源需对图块进行归一化操作以确保饱和区域的存在。本文实验中涉及的图像均包含饱和区域,因此并不需要归一化操作。笛卡尔坐标系下给定  $101 \times 101$  的灰度图块  $\mathbf{P}$ ,  $X$  是所有像素的坐标集。首先用饱和像素的坐标均值初始光源中心坐标  $\mathbf{x}_c$ , 设置代表光源区域的二值图  $\mathbf{M}$  初值为0并将  $\mathbf{M}(\mathbf{x}_c)$  标注为光源区域。 $A$  是由  $X$  中的坐标排序构成的有序数组,排序依据为坐标到中心的欧氏距离。按序遍历  $A$  中的元素,当坐标处像素饱和且欧氏距离( $E(\cdot)$ )和哈密顿距离( $H(\cdot)$ )满足条件时将其标注为光源。结束遍历后,标注为光源的坐标均值为新的中心坐标。重复迭代到  $\mathbf{x}_c$  的差值小于常量  $\varepsilon$ , 根据经验算法在3次迭代后收敛。

该策略是通过搜索能够覆盖大部分饱和区域的最大圆并将圆内饱和区域被视为光源区域(图4中图块B的黑色区域)。光源区域的形心被用作光源中心(图4中  $\mathbf{x}_c$  点),消除圆外因反光导致的条状区域的影响(图4中图块A内点划线框)。

## 2) 异常值检测

以光源为中心取出  $201 \times 201$  大小的图块并将其分割为若干等宽的圆环,内径  $r_1$ , 外径为  $r_2$  的圆环记为  $I_{r_1, r_2}$ 。由图3可知,同一圆环中像素点的偏移距离对应相近的散射方向,其光晕强度应趋于一致。

基于光源图像数据(见3.1节),如图5(a)~(f)所

## 算法1 定位光源

**Input:** 包含光源的图块  $\mathbf{P}$ ; 像素坐标集合  $X$

**Output:** 光源二值图  $\mathbf{M}$ ; 光源中心坐标  $\mathbf{x}_c$

```

1:  $\text{int } \mathbf{x}_c \leftarrow \text{Average}(X_1), X_1 \leftarrow \{\mathbf{x} | \mathbf{x} \in X, \mathbf{P}(\mathbf{x}) = 1\}$ 
2: repeat
3:    $\mathbf{M} \leftarrow O_{101 \times 101}, \mathbf{M}(\mathbf{x}_c) \leftarrow 1$ 
4:    $\mathbf{x}' \leftarrow \mathbf{x}_c$ ; 构建坐标数组  $A \quad \forall 1 \leq i \leq j \leq |A|, E(A_i, \mathbf{x}_c) \leq E(A_j, \mathbf{x}_c)$ 
5:   for ( $i \leftarrow 2; \mathbf{x} \leftarrow A(i); i \leq |A|; i++$ ) do
6:     if  $\{\hat{\mathbf{x}} | \mathbf{M}(\hat{\mathbf{x}}) = 1, H(\hat{\mathbf{x}}, \mathbf{x}) = 1, \hat{\mathbf{x}} \in A\} \neq \emptyset$  and  $\mathbf{P}(\mathbf{x}) = 1$  then
7:        $\mathbf{M}(\mathbf{x}) \leftarrow 1$ ; //识别为光源
8:     end if
9:     if  $i > 200$  and  $\sum_{j=i-199}^i \mathbf{M}(\mathbf{x}_j) < 20$  then
10:      break;
11:    end if
12:  end for
13:   $\mathbf{x}_c \leftarrow \text{Average}(X_M), X_M \leftarrow \{\mathbf{x} | \mathbf{x} \in X, \mathbf{M}(\mathbf{x}) = 1\}$ 
14: until  $E(\mathbf{x}', \mathbf{x}_c) < \varepsilon$ 
15: Return  $\mathbf{M}, \mathbf{x}_c$ 

```

示分别是圆环  $I_{30, 40} \sim I_{80, 90}$  内灰度图像素值的统计分布。随着半径增大,圆环内的像素峰值逐渐减小,该现象符合所提的衰减先验。但一方面,随着圆环半径的增加,较大的观测值占比随之增加(横坐标为1处的“尖峰”)。这类正偏异常值有下列原因:其他光源,白色背景或物体的镜面反射。另一方面,基于暗通道先验<sup>[16]</sup>,非白色背景或阴影会导致RGB图像中至少一个通道的观测值较小,导致灰度值分布中的负偏异常值。因此定义异常值剔除函数  $Ano(\cdot)$ : 给定像素值集合,基于箱线图方法仅保留箱体内的数据,即上四分位数和下四分位数之间50%的数据,其余数据被视为异常值。

原始图像、光晕图及其特征图<sup>[16,23]</sup>如图6(a)~(d)所示。为方便描述,以光源中心为原点建立极坐标系,  $(r_x, \theta_x)$  表示像素  $\mathbf{x}$  在极坐标中的映射。此时光晕图  $I_{rc}$  的定义如式(4)所示:

$$I_{rc}(\mathbf{x}) = \text{Rand}(Ano(Ann^c(\mathbf{x})))$$

$$\text{s. t. } Ann^c(\mathbf{x}) = \{I^c(\mathbf{x}') | |r_x - r_{x'}| \leq w/2\} \quad (4)$$

其中,  $\text{Rand}(\cdot)$  是随机采样函数,  $Ano(\cdot)$  是异常值剔除函数,  $c \in \{r, g, b\}$  是图像通道,  $w$  是圆环宽度。视觉上,重构后的图像较好地消除了复杂环境对光晕的影响,在光晕图和暗通道、亮度通道两种特征图上呈现以光源为中心向往辐射衰减的趋势。

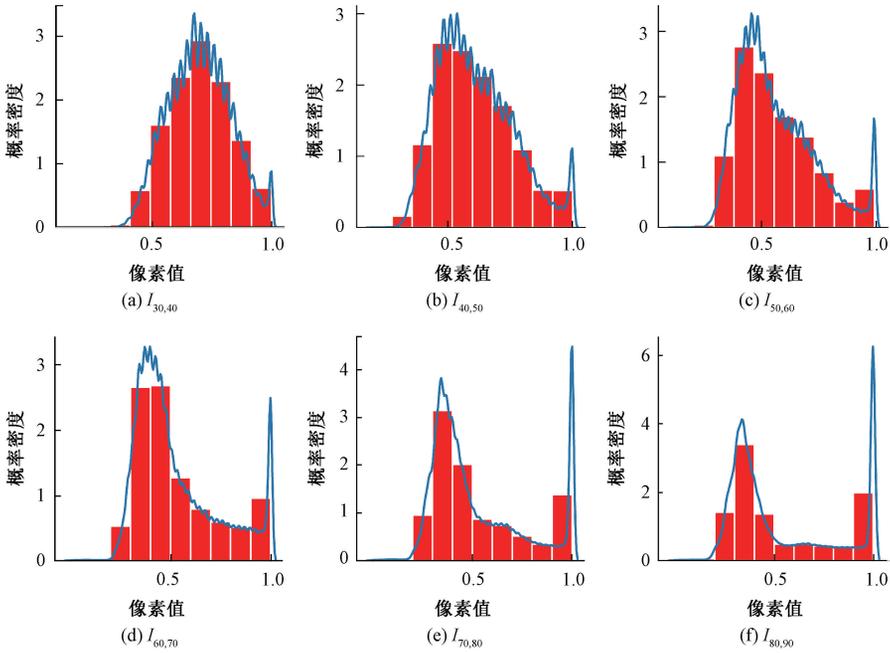


图 5 不同半径圆环内的像素值直方图和核密度估计曲线

Fig. 5 Pixel value histograms and kernel density estimation curves within rings of different radii

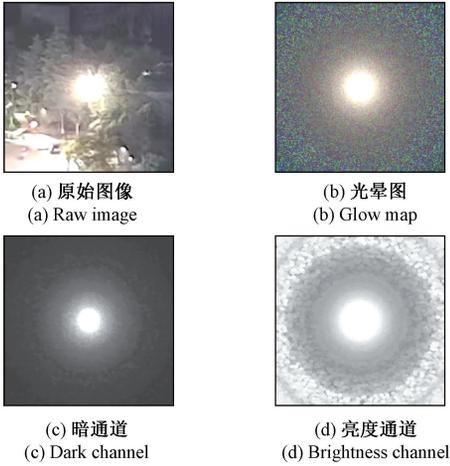


图 6 原始图像及其不同特征图

Fig. 6 Raw image and its different feature maps

3) 建立特征空间

由于同一扇环内的像素在空间上未必是相邻的, 照明和背景差异导致图 6(b) 中存在噪点。进一步地, 如图 7 所示, 将圆环等分为多个扇环使得块内像素在空间上是相邻的, 整体上看图像被极坐标网格分割为若干弧度为  $\phi$ , 宽度为  $w$  的扇环, 并基于每个扇环内的像素值逐通道地进行异常值检测。

扇环内的像素值应是一致的, 即服从一定的分布模式。受 VAE<sup>[24]</sup> 启发, 采用均值-标准差两个统计量构成散射光强的特征向量。具体而言, 图像被分割为  $20 \times 16 =$

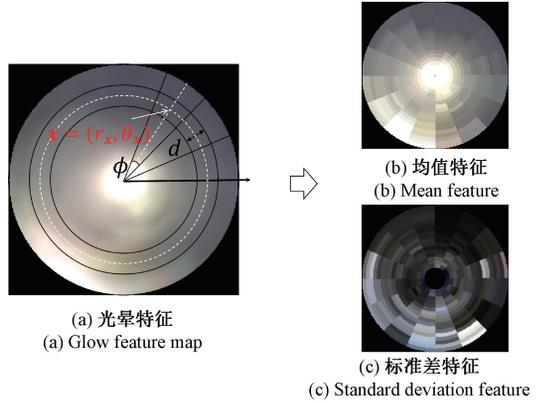


图 7 光晕特征可视化图

Fig. 7 Visualization of glow feature

320 个扇环, 按半径排序后每个扇环逐通道计算均值和标准差两种特征。单张图像被编码为均值特征向量和标准差特征向量(A-S 特征), 其长度均为 960, 拼接后作为样本的光晕特征向量。

视觉上, 剔除异常值后的光晕图像如图 7(a) 所示, 图中每个像素位置的光晕强度是为其为形心的扇环内的像素均值。光晕图的定义:

$$\begin{aligned}
 \mathbf{I}_{ave}(\mathbf{x}) &= Ave(Ano(AnnSec^c(\mathbf{x}))) \\
 \text{s. t. } AnnSec^c(\mathbf{x}) &= \left\{ \mathbf{I}(\mathbf{x}') \mid \begin{aligned} &|r_x - r_x'| \leq \frac{w}{2}, \\ &|\theta_x - \theta_x'| \leq \frac{\phi}{2} \end{aligned} \right\} \quad (5)
 \end{aligned}$$

其中,  $AnnSec(\cdot)$  是以  $\mathbf{x}$  为形心, 弧度为  $\phi$ , 宽度为  $w$  的扇环块内  $c$  通道的像素值集合,  $Ano(\cdot)$  是异常值剔除函数,  $Ave(\cdot)$  是均值函数。对应均值向量和归一化后的标准差向量的可视化图像如图 7(b)、(c) 所示, 图块颜色分别逐通道对应所处环扇内像素的均值和归一化后的标准差, 共同表征不同散射方向的光晕强度特征。

对于非点光源本方法依旧适用。以锥形光源为例, 沿不同射线方向和偏移距离同样可将图像分割为扇环块从而计算光晕特征。本质上仅需单个扇区的光晕图像便可实现特征提取, 因此光源形状并不限制方法的应用。

#### 4) 回归模型

简单地, 本文采用贝叶斯岭回归模型将特征向量映射为  $PM_{2.5}$  浓度的估计值。在线性模型的基础上, 岭回归模型将权值的 L2 范数作为正则项, 形式上如下:

$$\arg \min_{\omega} \|\mathbf{X}\omega - \mathbf{y}\|_2^2 + \alpha \|\omega\|_2^2 \quad (6)$$

其中,  $\omega$  表示模型参数,  $\mathbf{X}$  和  $\mathbf{y}$  分别是特征向量和真实值,  $\alpha > 0$  是正则项的收缩因子, 值越大则参数对模型共线性的鲁棒性越强。结合贝叶斯理论, 等价于求出  $\omega$  在高斯先验下且均值为 0, 精度为  $\lambda^{-1}$  的最大后验估计:

$$\arg \min_{\omega} P(\mathbf{y} | \mathbf{X}, \omega, \alpha) \quad (7)$$

$$\text{s.t. } P(\omega | \lambda) \sim \mathcal{N}(\omega | 0, \lambda^{-1} \mathbf{I}_p)$$

其中,  $\alpha$  被视为需从数据中估计的随机变量,  $\mathcal{N}(\cdot)$  表示高斯分布,  $\mathbf{I}_p$  表示  $p$  维单位矩阵。本文基于 scikit-learn 函数库 (版本 0.24.1) 实现算法, 在模型拟合过程中, 通过最大化对数边际似然估计正则化参数  $\alpha$  和  $\lambda$  [25]。模型的估计结果如式 (8) 所示。

$$\hat{y} = \begin{cases} \omega \cdot x, & \omega \cdot x > 0 \\ 0, & \text{其他} \end{cases} \quad (8)$$

### 3 数据与实验与结果分析

鉴于这是第 1 项基于光晕的夜间空气污染估计的工作, 评估该算法需要新的数据集。本节介绍数据的采集、分析和对比实验, 对比实验中将多种日间雾霾估计方法和经典网络作为基线方法。

#### 3.1 数据采集与分析

除了  $PM_{2.5}$  浓度外, 夜间相机成像受多种要素 (相机与光源的相对位姿、光源强度、相机焦距、曝光量等) 影响。通过控制变量, 设备被部署在浙江省杭州市西湖区 ( $120^{\circ}03'21.372''E, 30^{\circ}14'08.083''N$ ), 对图 4 所示的固定场景进行监测, 相机的相对高度为 33 m, 俯角为  $5^{\circ}$ 。假设目标光源的强度是稳定的, 因此影响光晕成像的主要因素有  $PM_{2.5}$  浓度和智能相机的曝光调节。同时, 如图 8 所示, 一个便携式传感器平台被开发来收集并存储环境数据。平台包括 Nova 颗粒物传感器模块、温度和湿度传

感器以及 Arduino UNO 控制器, 以锂电池供电每秒记录一次数据。采集时间为 2022 年 11 月 ~ 2023 年 03 月, 多数情况下  $PM_{2.5}$  浓度值较小。考虑到标签平衡和天气原因, 多数低浓度环境下的数据并未被保留。实验数据集包含源于 4 个月份的 2 426 张图像和对应的环境数据, 对应的监测时长约 200 h。



图 8 数据采集平台

Fig. 8 Data collection platform

#### 3.2 特征分析

如图 9 所示,  $PM_{2.5}$  浓度与图像像素值之间存在关联性。过原点  $-45^{\circ}$  方向直线上原图的灰度图像素值与浓度之间的关系如图 9(a) 所示, 随着  $|r|$  增大, 光晕强度的衰减满足指数衰减先验。由于衰减主要发生在 100 像素偏移距离内, 本文光源图块的边长被设为 201 (如图 4 中 C 处点线框所示)。  $r = -100$  处 (负数表示反方向) 像素值与浓度的关系如图 9(b) 所示。当浓度低  $50 \mu\text{g}/\text{m}^3$  时, 像素值相对浓度的平均依赖性约  $0.0035 \mu\text{g}/\text{m}^3$ 。黑色部分数据不满足该趋势, 这是由于高  $PM_{2.5}$  浓度导致全局亮度的增加, 智能摄像机为此自动降低曝光。

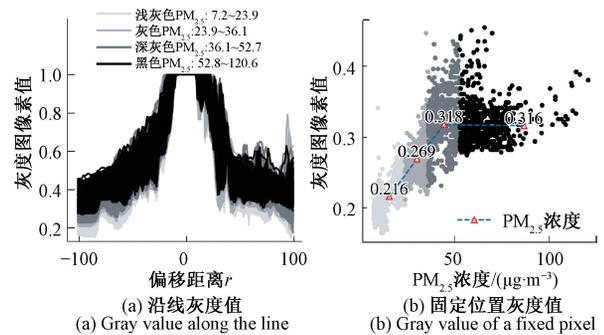


图 9 光晕衰减特性

Fig. 9 Glow attenuation characteristics

图 10 展示了曝光量与  $PM_{2.5}$  分布之间的关联。如图 10(a) 所示, 纵轴用算法 1 中二值图 M 面积 (饱和区域的像素个数) 代表相机的曝光水平, 在高  $PM_{2.5}$  浓度条件下 (大于  $50 \mu\text{g}/\text{m}^3$ ) 相机曝光是受限的。

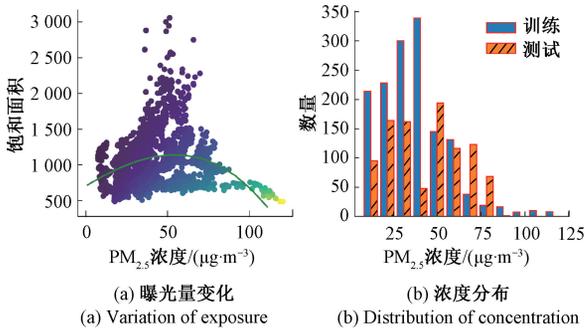


图 10 PM<sub>2.5</sub> 分布与相机曝光量的关系

Fig. 10 The relationship between PM<sub>2.5</sub> distribution and camera exposure

进一步分析所提光晕特征与 PM<sub>2.5</sub> 浓度之间的相关性, 为将高维数据与低维数据进行比较, 采用主成分分析方法实现特征降维。如图 11 所示, 降维后所有样本特征向量的第一主成分与 PM<sub>2.5</sub> 浓度之间线性相关, 相关系数为 0.465。

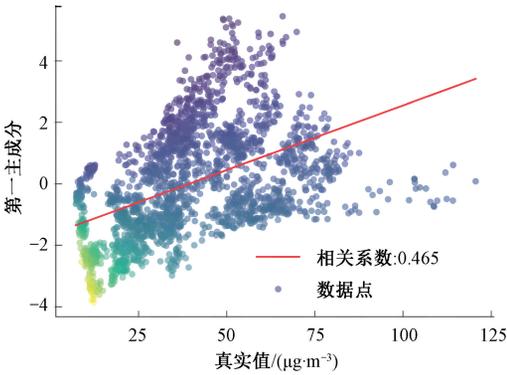


图 11 第一主成分与 PM<sub>2.5</sub> 浓度之间的相关性

Fig. 11 Correlation between the first principal component and PM<sub>2.5</sub> concentration

### 3.3 估计精度分析

如图 10(b) 所示, 按照时间顺序数据集以 3:2 比例被划分为训练集和测试集。实验采用平均误差 (MAE) 和决定系数 ( $R^2$ ) 作为评价指标:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (9)$$

$$R^2 = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (10)$$

其中,  $N$  是样本总数,  $\hat{y}_i$  是第  $i$  个样本的估计值,  $y_i$  为真实值,  $\bar{y} = \sum_i (y_i / N)$ 。

由于端到端的神经网络方法在计算机视觉等领域大获成功。本文将所提方法与经典的 ResNet<sup>[26]</sup> 系列模型和基于视觉的日间雾霾估计方法<sup>[23,27-29]</sup> 进行对比, 后者

使用缩放后的全景图像作为输入。深度学习算法基于 PyTorch (版本 2.0.1, CUDA 11.8) 开发, 批处理大小为 128, 损失函数为均方误差。使用 Adam 优化器, 学习率初始值为 0.005, 衰减比例为 0.98, 并在 GeForce RTX 3070 GPU 上迭代 400 次。

如表 1 所示, 本文所提方法的精度明显优于第 2 名 (Utomo/ResNet34), 在 MAE 和  $R^2$  指标上分别有 1.614  $\mu\text{g}/\text{m}^3$  和 0.101 的绝对提升。这类基于卷积算子的网络通过学习目标对象的一般性特征来完成分类等任务, 由于单层感受域的局限性通常依赖增加模型深度来捕获全局信息以提升模型性能。但随着模型参数数量和深度的增加其学习难度也随之上升, 模型容易陷入局部最优而在无法得到性能提升 (ResNet50 比 ResNet34 差), 因此需要更大规模的数据。

表 1 不同方法估计精度对比表

Table 1 Comparison of estimation accuracy of different methods

方法	MAE/ $(\mu\text{g} \cdot \text{m}^{-3})$	$R^2$
本文方法	<b>6.187</b>	<b>0.857</b>
特征生成+CNN	7.685	0.734
Pre-trained PE-MobileNetV2 <sup>[27]</sup>	17.85	0.001 7
Re-trained PE-MobileNetV2 <sup>[27]</sup>	10.261	26.622
Utomo <sup>[28]</sup>	<b>7.801</b>	0.712
Liaw <sup>[29]</sup>	11.061	0.457
ImaSensingNet <sup>[23]</sup>	8.073	0.752
ResNet18	10.117	0.577
ResNet34	7.94	<b>0.756</b>
ResNet50	10.772	0.507

与日间估计方法相比, 在 Fang 等<sup>[27]</sup> 提供的预训练模型上, 夜间数据的糟糕测试结果 ( $R^2 = 0.001 7$ ) 说明基于视觉进行 PM<sub>2.5</sub> 估计存在日夜差异, 已有的日间模型并不能直接适用于夜间场景。几乎所有基于视觉的方法都通过设计有效特征来提高准确率。大多数日间的方法侧重于图像结构损失、色度和场景深度估计等因素。然而, 对于夜间场景, 可见性更为重要。因此, 研究应该专注于可见的对象, 如光晕。Utomo 等<sup>[28]</sup> 通过实验证明天空区域是模型决策中最有影响力像素的来源。对于夜间场景, 图像中天空区域是低照度且容易受到噪声影响, 所以已有基于视觉的日间方法并不能直接适用于夜间场景。

值得一提的是, 基于 VAE<sup>[24]</sup> 中生成模型的思想, 在 2.2 节中每一样本被编码为特征分布向量, 本文设计了由 3 个一维卷积层连接 2 个全连接层组成的简单回归网络, 以特征分布的随机采样作为输入, 样本的真实值作为

标签,实现样本数据增强的同时通过减少数据大小节约计算和存储成本。结果显示该方法(特征生成+CNN)获得接近深层网络(ResNet34)的表现,证明了所提光晕特征与 $\text{PM}_{2.5}$ 浓度是关联的,且所提特征获得近似深层网络的特征提取效果。

### 3.4 误差分析

为分析测试样本估计值与真实值之间的误差,以 $10 \mu\text{g}/\text{m}^3$ 为单位区间长度,不同区间内估计值的误差棒如图12所示。图中 $35 \sim 45 \mu\text{g}/\text{m}^3$ 之间的样本的误差较大,这是由于该区间训练与测试样本分布差异较大(如图10(b)所示),进一步收集数据有助于提升模型精度。

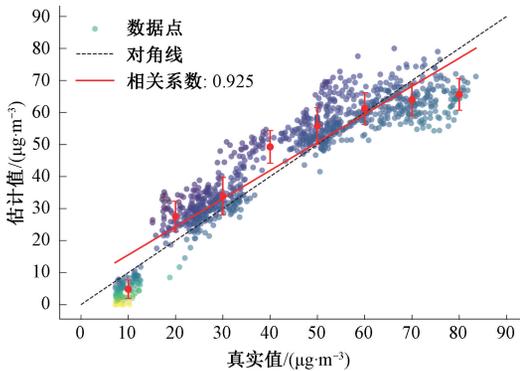


图12 测试样本的估计值与真实值相关性分析

Fig. 12 Correlation analysis between estimated value and true value of test samples

随着 $\text{PM}_{2.5}$ 浓度逐渐增大,如图10(a)所示,智能相机降低曝光时间以避免大片区域过度饱和。此时捕获的散射光强度减小导致高污染物浓度样本的估计值整体偏小。因此控制相机曝光量为常量或将其视为模型参数可进一步提升模型的估计精度。

### 3.5 消融分析

为获得有效的光源特征,本文提出的方法包含极坐标网格图像分割,异常值检测(A)和计算均值-标准差特征向量(A-S特征,B)。消融实验的基线是相同分割下原图图块的像素均值作为特征向量的模型表现。

为验证异常值检测的作用,使用经过异常值检测后的像素均值构成的特征向量作为模型输入(即仅使用均值特征向量)。如表2所示,此时的MAE为 $6.702 \mu\text{g}/\text{m}^3$ ,略差与最优结果。因此基于指数衰减先验的异常值检测是有效的,通过排除图块中偏大/小值还原了无外部干扰(背景、反光等)下的光晕真实强度,并在本文方法中起主要作用。

为验证A-S特征的作用,将不经过异常值监测条件下图像的均值-标准差特征向量作为模型的输入。此时的MAE为 $8.488 \mu\text{g}/\text{m}^3$ ,低于基线。这是因为不经过异

表2 消融分析

Table 2 Ablation analysis

方法	MAE/ $(\mu\text{g}\cdot\text{m}^{-3})$	$R^2$
本文方法(A+B)	6.187	0.857
原图(基线)	8.081	0.763
异常值检测(A)	6.702	0.841
A-S特征(B)	8.488	0.715
暗通道	7.92	0.757
亮度	9.891	0.633
饱和度	9.332	0.665

常值剔除时,扇环块内可能包含的干扰信息使得均值和标准差无法表征图块位置的散射光强度分布。相比基线中仅使用均值特征,额外的标准差特征本质上是一种无效特征。

同时,为比较不同特征与 $\text{PM}_{2.5}$ 的相关性差异,所提特征与日间雾霾估计方法中常用的特征(暗通道、亮度、饱和度)进行比较<sup>[23]</sup>,使用特征图的均值特征向量作为岭回归器的输入。除了暗通道的表现略优于基线外,其他特征的表现均低于基线,这是因为日间理论建立在观测景深变化与图像模糊程度的基础上,在因低照度可见性受限的夜间场景中作用有限。

## 4 结论

本文介绍了基于光源光晕的夜间 $\text{PM}_{2.5}$ 浓度估计技术。实验结果表明,与端到端的经典神经网络方法相比,所提基于光晕特征的方法在MAE和 $R^2$ 指标上分别有20.69%、13.36%的相对提升,明显优于最新的基于视觉的日间雾霾估计方法。基于指数衰减先验的异常值检测和均值-标准差特征能够较好地提取和表征光晕强度,实验中获得了近似深层网络(ResNet34)的抽象特征提取效果。

在部署期间,由于杭州地区的污染处于相对较低水平,大多数 $\text{PM}_{2.5}$ 值低于 $80 \mu\text{g}/\text{m}^3$ 。此外,降水天气有时会阻碍数据收集。本方法主要在夜间有效,并且依赖场景中包含可见的人造光源,并未考虑自然光源下(基于月晕)的表现,因此在阳光主导场景的黎明或黄昏时段可能不起作用。相机的曝光水平会影响图像质量,因此采用可编程的摄像头对其控制可提升模型的精度。未来的工作包括融合其他参数,如湿度、温度等气象因素和相机曝光时间等设备因素,以提高浓度估计的精度。此外,收集更多样化和更大规模的夜间图像数据集可以进一步提高方法的准确率。

## 参考文献

- [1] 王光奇, 王玲玲, 马双良, 等. 2022北京冬奥会管控下新乡市农村地区PM<sub>2.5</sub>中重金属及生态风险变化特征[J]. 环境科学学报, 2024, 44(1): 47-61.  
WANG G Q, WANG L L, MA SH L, et al. Changes in PM<sub>2.5</sub> heavy metals and their ecological risks in rural areas of Xinxiang City under the control of 2022 Beijing Winter Olympic Games [J]. Acta Scientiae Circumstantiae, 2024, 44(1): 47-61.
- [2] 吴瑞丽, 张强, 赵红艳, 等. 中国337城市大气PM<sub>2.5</sub>污染健康损失的来源贡献特征[J]. 环境科学学报, 2023, 43(11): 173-181.  
WU R L, ZHANG Q, ZHAO H Y, et al. Source contributions of PM<sub>2.5</sub>-associated health impacts of 337 cities in China [J]. Acta Scientiae Circumstantiae, 2023, 43(11): 173-181.
- [3] 张雨晨, 王国镇, 洪启浩, 等. 基于转录组测序探究PM<sub>2.5</sub>引起THP-1细胞发生炎症反应的关键因子[J]. 环境科学学报, 2023, 43(8): 454-463.  
ZHANG Y CH, WANG G ZH, HONG Q H, et al. Transcriptome sequencing to explore key factors in the inflammatory response of PM<sub>2.5</sub>-induced THP-1 cells[J]. Acta Scientiae Circumstantiae, 2023, 43(8): 454-463.
- [4] XU F, HUANG Q, YUE H, et al. The challenge of population aging for mitigating deaths from PM<sub>2.5</sub> airpollution in china[J]. Nature Communications, 2023, 14(1): 5222.
- [5] PENG Y, SUI Z, ZHANG Y, et al. The effect of moisture on particulate matter measurements in an ultra-low emission power plant[J]. Fuel, 2019, 238: 430-439.
- [6] FEENSTRA B, PAPAPOSTOLOU V, HASHEMIN-ASSAB S, et al. Performance evaluation of twelve low-cost PM<sub>2.5</sub> sensors at an ambient air monitoring site[J]. Atmospheric Environment, 2019, 216: 116946.
- [7] 关泽, 范晨阳, 王站成, 等. 柴油发动机超细颗粒物数量检测方法研究进展[J]. 仪器仪表学报, 2022, 43(7): 454-463.  
GUAN Z, FANG CH Y, WANG ZH CH, et al. Review on determining ultra-fine particle number emissions from modern diesel engines[J]. Chinese Journal of Scientific Instrument, 2022, 43(7): 454-463.
- [8] DAO M S, ZETTISU K, RAGE U K. Image-2-aqi: Aware of the surrounding air qualification by a few images[C]. International Conference on Industrial, Engineering and Other Applications of Applied Intelligent Systems, 2021: 335-346.
- [9] ZHANG G, SHI Y, XU M. Evaluation of LJ1-01 nighttime light imagery for estimating monthly PM<sub>2.5</sub> concentration: A comparison with NPP-VIIRS nighttime light data [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 3618-3632.
- [10] OLAGOKE A S, HAIDI I, TEOH S S. Literature survey on multi-camera system and its application [J]. IEEE Access, 2020, 8: 172892-172922.
- [11] ZHANG T, DICK P R. Estimation of multiple atmospheric pollutants through image analysis[C]. 2019 IEEE International Conference on Image Processing, IEEE, 2019: 2060-2064.
- [12] SU P, LIU Y, TARKOMA S, et al. Retrieval of multiple atmospheric environmental parameters from images with deep learning[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.
- [13] WANG Z, YUE S, SONG C. Video-based air quality measurement with dual-channel 3-D convolutional network [J]. IEEE Internet of Things Journal, 2021, 8(18): 14372-14384.
- [14] WANG G, SHI Q, WANG H, et al. Multi-modal image feature fusion-based PM<sub>2.5</sub> concentration estimation [J]. Atmospheric Pollution Research, 2022, 13(3): 101345.
- [15] LIU Q, LIU L, DENG Y, et al. Apparent distance theory revision for low-light-level night vision system based on noise factor [J]. Optical and Quantum Electronics, 2017, 49: 1-15.
- [16] HE K, SUN J, TANG X. Single image haze removal using dark channel prior [J]. IEEE Trans Pattern Anal Mach Intell, 2010, 33(12): 2341-2353.
- [17] CHEN H, YANG W, LIAO Q. Two-stream non-uniform concentration reasoning network for single image air pollution estimation [C]. 2022 IEEE International Conference on Image Processing, IEEE, 2022: 501-505.
- [18] HSIEH C H, CHEN K Y, JIANG M Y, et al. Estimation of PM<sub>2.5</sub> concentration based on support vector regression with improved dark channel prior and high frequency information in images [J]. IEEE Access, 2022, 10: 48486-48498.
- [19] LI Y, TAN R T, BROWN M S. Nighttime haze removal with glow and multiple light colors [C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 226-234.
- [20] NARASIMHAN S G, NAYAR S K. Shedding light on the weather [C]. 2003 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, IEEE, 2003.
- [21] 张强, 田野. PM<sub>2.5</sub>激光散射法传感器校准研究[J]. 中国仪器仪表, 2018(2): 56-60.  
ZHANG Q, TIAN Y. PM<sub>2.5</sub> Calibration research of laser

- scattering sensor[J]. China Instrumentation, 2018(2): 56-60.
- [22] 宋丹林, 陶俊, 张普, 等. 成都城区颗粒物消光系数特征及其与  $PM_{2.5}$  的关系[J]. 中国科学院研究生院学报, 2013, 30(6): 757-762.
- SONG D L, TAO J, ZHANG P, et al. Seasonal characterization of particle extinction coefficient and its relation with  $PM_{2.5}$  mass concentration in Chengdu[J]. Journal of University of Chinese Academy of Sciences, 2013, 30(6): 757-762.
- [23] YANG Y, HU Z, BIAN K, et al. ImgSensingNet: UAV vision guided aerial-ground air quality sensing system[C]. IEEE INFOCOM 2019-IEEE Conference on Computer Communications, IEEE, 2019: 1207-1215.
- [24] KINGMA D P, WELING M. Auto-encoding variational bayes[J]. ArXiv Preprint, 2013, ArXiv:1312.6114.
- [25] TIPPING M E. Sparse bayesian learning and the relevance vector machine [J]. Journal of Machine Learning Research, 2001, 1: 211-244.
- [26] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [27] FANG X, LI Z, YUAN B, et al. Image-based  $PM_{2.5}$  estimation from imbalanced data distribution using prior-enhanced neural networks [J]. IEEE Sensors J, 2024, 24(4): 4677-4693.
- [28] UTOMO S, JOHN A, PRATAP A, et al. AIX implementation in image-based  $PM_{2.5}$  estimation: Toward an ai model for better understanding [C]. 2023 15th International Conference on Knowledge and Smart Technology, 2023: 1-6.
- [29] LIAW J J, HUANG Y H, HSIEH C H, et al.  $PM_{2.5}$  concentration estimation based on image processing schemes and simple linear regression [J]. Sensors, 2020, 20(8): 2423.

## 作者简介



翔云, 2008年于浙江大学获得学士学位, 2014年于密歇根大学获得博士学位, 现为浙江工业大学网络空间安全研究院副教授, 主要研究方向为网络空间安全、机器学习、嵌入式系统和计算机视觉。

E-mail: xiangyun@zjut.edu.cn

**Xiang Yun** received his B.Sc. degree from Zhejiang University in 2008, received his Ph.D. degree in 2014 from University of Michigan. He is currently an associate professor at Institute of Cyberspace Security, Zhejiang University of Technology. His main research interests include cyberspace security, machine learning, embedded systems, and computer vision.



张凯华, 2016年于河海大学获得学士学位, 现为浙江工业大学硕士研究生, 主要研究方向为测量、预测和调度的理论和方法。

E-mail: kaihua\_zhang@foxmail.com

**Zhang Kaihua** received his B.Sc. degree in 2016 from Hohai University. He is currently a master student at Zhejiang University of Technology. His research interests include theory and method of measurement, forecasting, and scheduling.



陈作辉(通信作者), 2019年于浙江工业大学获得学士学位, 现为浙江工业大学博士研究生, 主要研究方向为计算机视觉、人工智能应用、人工智能安全。

E-mail: czuohui@gmail.com

**Chen Zuohui** (Corresponding author) received his B.Sc. degree in 2019 from Zhejiang University of Technology. He is currently a Ph.D. candidate at Zhejiang University of Technology. His research interests include computer vision, AI application, and AI security.



宣琦, 2008年与2014年于浙江大学分别获得学士、博士学位, 现为浙江工业大学网络空间安全研究院教授, 主要研究方向为网络科学、图数据挖掘、网络空间安全、机器学习和计算机视觉。

E-mail: xuanqi@zjut.edu.cn

**Xuan Qi** received his B.Sc. and Ph.D. degrees both from Zhejiang University in 2008 and 2014, respectively. He is currently a professor at Institute of Cyberspace Security, Zhejiang University of Technology. His main research interests include network science, graph data mining, cyberspace security, machine learning, and computer vision.