

引用格式:李亚宏,周城旭,段立娟,等. 基于机器感知与学习的空气颗粒物智能检测、识别与预警方法研究综述[J]. 北京工业大学学报, 2024, 50(2): 195-206.

LI Y H, ZHOU C X, DUAN L J, et al. Review of intelligent detection, identification and warning methods for airborne particulate matter based on machine perception and learning[J]. Journal of Beijing University of Technology, 2024, 50(2): 195-206. (in Chinese)

# 基于机器感知与学习的空气颗粒物智能检测、识别与预警方法研究综述

李亚宏,周城旭,段立娟,王思梦,顾 镡  
(北京工业大学信息学部,北京 100124)

**摘要:**随着空气污染问题的不断加剧,准确检测和及时预警空气颗粒物(particulate matter, PM)的重要性日益突出。传统方法依赖专业设备,不适用于实时检测。与传统方法相比,基于机器感知与学习的方法体现出技术优势,具有可实时检测、准确性高等优点。因此,对近几年的基于机器感知与学习的PM智能检测、识别与预警方法进行详细综述。首先,对PM的标准和来源进行介绍;然后,从检测、识别和预警这3个方面详细总结了各类方法,并对比各方法的特点和性能,其中,基于机器学习和深度学习的方法在各研究中取得了较大进展;最后,总结全文主要内容,并提出当前领域面临的挑战以及未来的重点研究方向。未来的研究应该继续关注技术创新和数据质量,以实现更好的空气质量监测和管理。

**关键词:**空气污染;机器感知;颗粒物(particulate matter, PM);智能检测;空气质量指数(air quality index, AQI);深度神经网络

中图分类号: U 461; TP 308

文献标志码: A

文章编号: 0254-0037(2024)02-0195-12

doi: 10.11936/bjtxb2023070048

## Review of Intelligent Detection, Identification and Warning Methods for Airborne Particulate Matter Based on Machine Perception and Learning

LI Yahong, ZHOU Chengxu, DUAN Lijuan, WANG Simeng, GU Ke  
(Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China)

**Abstract:** As air pollution problems continue to grow, accurate detection and timely warning of particulate matter (PM) are becoming increasingly important. Traditional methods rely on specialized equipment and are not suitable for real-time monitoring. In comparison, machine perception and learning-based methods have technological advantages such as real-time monitoring and high accuracy. Therefore, a detailed review of intelligent PM detection, identification and early warning methods based on machine perception and learning in recent years was presented. First, an introduction to the standards and sources

收稿日期: 2023-07-31; 修回日期: 2023-10-09

基金项目: 国家自然科学基金资助项目(62176009)

作者简介: 李亚宏(1996—), 男, 博士研究生, 主要从事计算机视觉、人工智能方面的研究, E-mail: liyahong1130@163.com

通信作者: 顾 镡(1987—), 男, 教授, 主要从事机器感知、环境监测、图像处理方面的研究, E-mail: guke@bjut.edu.cn

of PM was presented. Then, various methods from the detection, identification, and warning fields were comprehensively summarized, highlighting the characteristics and performance differences among them. Methods based on machine learning and deep learning have made significant progress in each of these research areas. Finally, the paper concluded by summarizing the main content and suggesting the current challenge in the field and future research direction. Future research effort should continue to prioritize technological innovation and data quality to achieve improved air quality monitoring and management.

**Key words:** air pollution; machine perception; particulate matter (PM); intelligent detection; air quality index (AQI); deep neural networks

随着工业化和城市化的发展,空气污染成为世界范围内关注的热点问题。随着人类活动的增加和能源消耗的不断上升,大量的废气和有害物质被排放到大气中,颗粒物(particulate matter, PM)作为主要的污染源之一,引起了人们广泛的关注和担忧。

PM是指悬浮在空气中的微小固体或液体颗粒,直径通常小于 $10\ \mu\text{m}$ ,其人为源包括工业生产、交通运输、建筑施工和燃烧过程等,被用作衡量空气污染的标准<sup>[1]</sup>。准确地监测PM对人类健康和了解PM来源至关重要。暴露于空气污染与慢性阻塞性肺病、哮喘等呼吸系统疾病以及死亡风险增加有关。相关研究分析了 $\text{PM}_{2.5}$ 、 $\text{SO}_2$ 和CO等污染物的质量浓度、暴露时间以及孕妇在妊娠后期的暴露情况与新生儿胆红素水平的关系<sup>[2]</sup>。空气污染暴露是新生儿黄疸的一个高危因素,新生儿和孕妇在妊娠后期的空气污染暴露都会增加新生儿胆红素水平,从而增加新生儿黄疸的风险。因此,改善空气质量对降低新生儿黄疸的风险具有重要意义。虽然空气污染对人类身体的影响有据可查,但对情绪状态和健康的影响可能更大。文献[3]使用心理物理学方法和实验来探索空气污染对人们主观幸福感(subjective well-being, SWB)的影响。结果发现,随着空气污染的加剧,人们的SWB呈现出自负相关,但在不同阶段有不同的变化速度和敏感度。当 $\text{PM}_{2.5}$ 的质量浓度增大到使空气质量指数(air quality index, AQI)约为150时,会引发负面情绪。

目前,用于监测大气中PM常用的方法有:质量法、振荡法、射线法、光学法等<sup>[4]</sup>。质量法是一种广泛使用的传统方法,通过在采样过程中捕集PM,并使用天平等仪器测量其质量。振荡法利用PM与流体之间的相互作用,通过对PM在振动场中的运动行为进行分析获得有关其质量和尺寸分布的信息。射线法是利用辐射能量与PM之间的相互作用来测量和分析PM特性的方法。光学法是一种基于光学原理的方法,利用光在PM中的散射和吸收特性来测量和分析PM的特征。这些方法各自具有独特的

优势和适用范围,在不同领域中发挥着重要作用。关于PM检测的研究,文献[5]介绍了在线PM组分测量的仪器和方法,包括在线质量浓度测量和在线质谱技术,以及基于这些数据的源解析模型和结果。在线质量浓度测量仪器昂贵且复杂,不适合长期在线监测。通过分析图像对PM进行检测与质量浓度估计为空气质量监测提供了有效的解决方案<sup>[6-7]</sup>。

基于上述问题,本文旨在对基于机器感知与学习的大气PM检测、识别和预测的研究进行系统综述,清晰地描述所需要的模型和算法,并根据PM的研究现状给出结论和思考。

## 1 PM

### 1.1 PM的标准

PM的标准由各个国家和地区的环境保护机构或卫生部门制定,旨在限制和监管空气中PM的质量浓度,以保护公众健康和环境质量。世界卫生组织(World Health Organization, WHO)发布的《全球空气质量指导值(2021)》,全面修订了覆盖 $\text{PM}_{2.5}$ 、 $\text{PM}_{10}$ 、 $\text{NO}_2$ 等6项污染物在内的空气污染物指导值及过渡阶段目标值, $\text{PM}_{2.5}$ 年均目标值由 $10\ \mu\text{g}/\text{m}^3$ 加严至 $5\ \mu\text{g}/\text{m}^3$ <sup>[8]</sup>。

我国的《环境空气质量标准》最初于1982年制定,是第一个旨在改善空气质量的官方文件。随后经历了3次修订,如图1所示。第1次修订发生在1996年,主要集中于监测指标和标准值的调整,包括 $\text{SO}_2$ 、 $\text{NO}_2$ 、PM和CO等。2000年进行了第2次修订,增强了原有标准,首次引入了 $\text{PM}_{10}$ 和 $\text{PM}_{2.5}$ 的监测标准,以更准确反映空气质量,并新增和修订了 $\text{O}_3$ 等污染物。第3次修订于2012年启动,于2016年正式实施,主要加强了对 $\text{PM}_{2.5}$ 的监测和管理要求,将其列为核心监测指标,以强化 $\text{PM}_{2.5}$ 的控制。此外,也对 $\text{SO}_2$ 、 $\text{NO}_2$ 、 $\text{O}_3$ 、CO等污染物的标准进行了调整和优化。

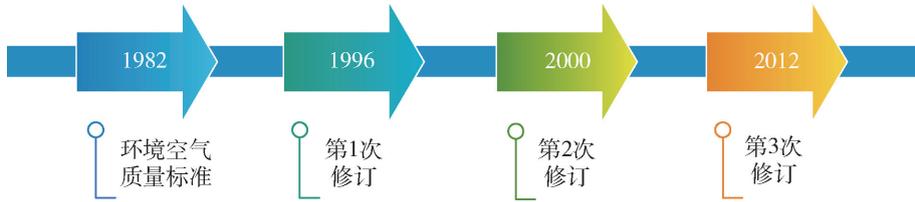


图1 中国环境空气质量标准的历史演变

Fig. 1 Historical evolution of ambient air quality standards in China

我国根据 24 h 的  $PM_{2.5}$  的平均值将空气质量标准分为 6 个等级,分别为优、良、轻度污染、中度污染、重度污染和严重污染,如表 1 所示。这些标准是根据国内外科学研究和实践经验制定的,旨在保护公众健康和生态环境。图 2 展示了 2014—2022 年北京、上海、广州、成都 AQI 和  $PM_{2.5}$  质量浓度的变化。从图中可看出,经过有效地治理,各个指标都呈现出下降趋势,广州的指标一直处于较低的水平。

表 1 空气质量标准

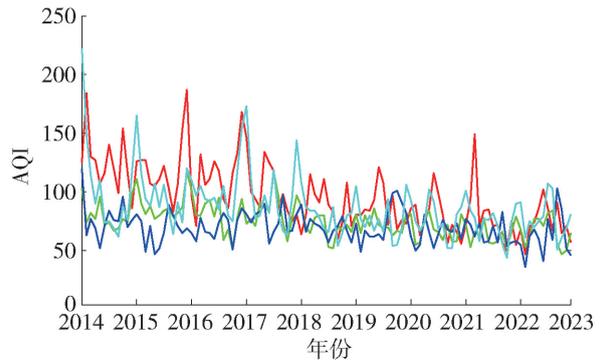
Table 1 Air quality standards

| 空气质量等级 | AQI       |
|--------|-----------|
| 优      | 0 ~ 50    |
| 良      | 51 ~ 100  |
| 轻度污染   | 101 ~ 150 |
| 中度污染   | 151 ~ 200 |
| 重度污染   | 201 ~ 300 |
| 严重污染   | 大于 300    |

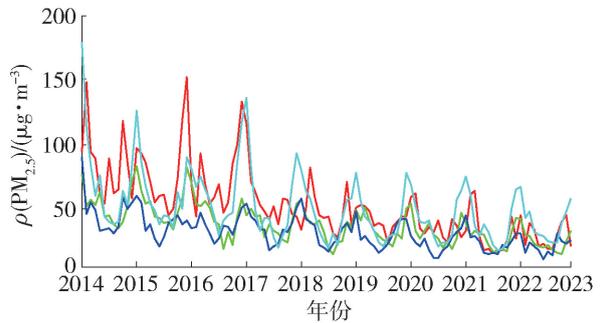
### 1.2 PM 的来源

PM 的来源可分为原生和次生 2 类。原生 PM 是直接由排放源进入大气,如车辆排放、居民生物质燃烧、工业金属排放等。次生 PM 是由气态前体经过化学反应形成的,如次生无机气溶胶(由  $NH_3$ 、 $SO_2$ 、 $NO_x$  等形成的  $NH_4^+$ 、 $NO_3^-$ 、 $SO_4^{2-}$  等)和次生有机气溶胶(由生物或人为挥发性有机化合物经过氧化和凝聚形成的复杂有机物)。欧洲的 PM 质量浓度主要受到次生无机气溶胶、地壳物质和次生物有机气溶胶的控制<sup>[9]</sup>。中国的 PM 质量浓度则受到原生 PM 和次生无机气溶胶(如硫酸盐)的影响。一些研究表明, $PM_{10}$  的源解析结果与  $PM_{2.5}$  类似,但尘土和海盐的贡献比例更高。这表明尘土和海盐在较大 PM 中的贡献更为显著<sup>[10]</sup>。因此,控制尘土和海盐的排放是减少  $PM_{10}$  污染的重要措施。

本文的整体概述见图 3。PM 的检测方法可以



(a) 2014—2022年AQI变化



(b) 2014—2022年 $PM_{2.5}$ 质量浓度变化

—北京 —上海 —广州 —成都

图2 各城市 AQI 和  $PM_{2.5}$  质量浓度的变化

Fig. 2 Changes of AQI and mass concentration  $PM_{2.5}$  in cities

大致分为传统算法和深度学习算法两大类。传统算法通常包括支持向量机 (support vector machine, SVM)、K-means 聚类等方法。深度学习算法则集中在工业烟雾排放检测、双通道模型的烟雾检测及烟雾检测算法的性能优化等方面的研究。PM 的识别方法涵盖传统监测方法和基于图像的 PM 估计 2 个主要方向。传统监测方法包括质量法、光学法和天平法等。相比之下,基于图像的方法常常采用线性回归方程、非线性映射和卷积神经网络 (convolutional neural networks, CNN) 等技术,以便更精确地估算 PM 浓度。至于 PM 的预警方法,可以分为非深度学习和深度学习 2 类。前者依赖于人工神经网络、随机森林预测和聚类分析等技术,而后

## 空气颗粒物智能检测、识别与预警方法研究

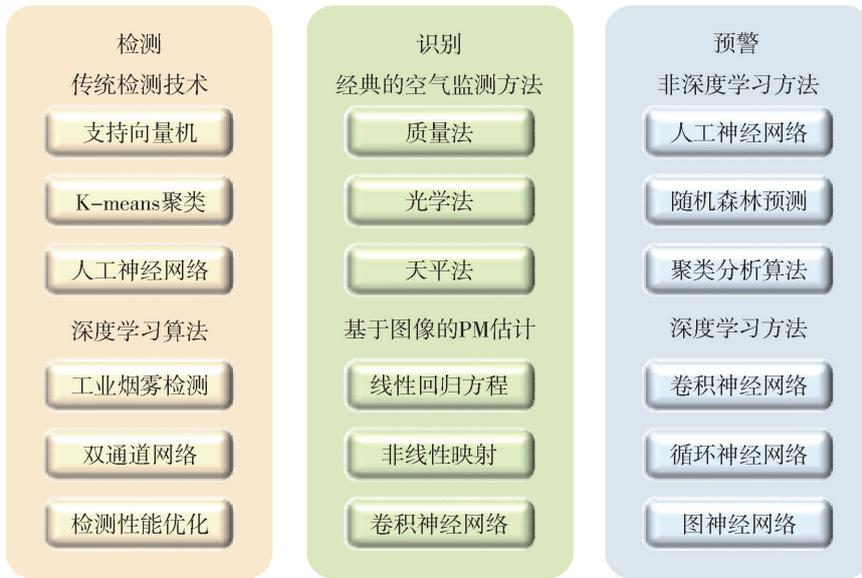


图3 本文的整体概述

Fig. 3 Overall overview of this paper

者则依赖 CNN、循环神经网络 (recurrent neural networks, RNN) 和图神经网络 (graph neural networks, GNN) 等方法。这些不同方法在 PM 领域各具特点,综合运用有望为空气质量监测和管理提

供更多有力工具。

在误差评估领域,有许多评价指标被应用。本次综述所涉及指标的定义和公式如表 2 所示。其中: $m$  为实例总数; $\hat{y}_i$  为预测值; $y_i$  为实际值。

表 2 综述中所使用指标的定义和公式

Table 2 Definitions and formulas for indicators used in the review

| 指标        | 定义   | 公式   |
|-----------|--|--|
| $E_{MA}$  | 平均绝对误差 (mean absolute error, MAE)                | $E_{MA} = \frac{1}{m} \sum_{i=1}^m  y_i - \hat{y}_i $  |
| $E_{MS}$  | 均方误差 (mean squared error, MSE)                   | $E_{MS} = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2$                                      |
| $E_{MR}$  | 平均相对误差 (mean relative error, MRE)                | $E_{MR} = \frac{1}{m} \sum_{i=1}^m \frac{ y_i - \hat{y}_i }{ y_i }$                          |
| $E_{RMS}$ | 均方根误差 (root mean square error, RMSE)             | $E_{RMS} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2}$                              |
| $E_{MAP}$ | 平均绝对百分比误差 (mean absolute percentage error, MAPE) | $E_{MAP} = \frac{1}{m} \sum_{i=1}^m \left  \frac{y_i - \hat{y}_i}{y_i} \right  \times 100\%$ |

## 2 PM 检测

2023年5月,生态环境部发布了我国天空地一体化监测网络的初步建成,实现了监测网络的全覆盖,构建了守护祖国绿水青山的“监测天网”<sup>[11]</sup>。快速且精准的高效空气质量检测对维护人类健康的生产生活、推动国家发展具有重要意义。

在大气污染 PM 中,PM<sub>2.5</sub>等细颗粒物直径较小、质量浓度不高,无法直接通过人眼观察。相比之

下,燃烧生成的烟雾中所含的有害的 PM 更具有检测意义。传统的烟雾检测方法基于烟雾的物理特性,需要收集烟雾颗粒、温度和湿度等信息以触发报警,但该方法在室外环境下不适用,并且容易受到温度和湿度的影响。相较于传统的物理检测方法,基于计算机视觉的烟雾检测技术可以应用于室外环境,并且能够提供烟雾产生的位置和强度等信息,实现对烟雾的早期检测<sup>[12]</sup>。基于计算机视觉的烟雾检测技术主要利用烟雾的颜色、纹理、运动和形态等

视觉特征。

基于计算机视觉的烟雾检测算法主要集中在2个方面:1)手动设计复杂的烟雾特征,然后使用传统的机器学习算法进行图像分类;2)利用深度学习网络自动提取特征并进行分类<sup>[12]</sup>。

传统方法在PM检测领域有广泛的应用,但深度学习等现代技术的整合可以进一步提高检测性能,特别是在复杂情境下。在未来的研究中,需要平衡传统方法的可解释性和深度学习的泛化能力,以满足不同应用场景的需求。

## 2.1 传统的烟雾检测算法

基于人工设计的复杂特征的检测算法工作遵循图像预处理、特征提取和分类的目标检测框架<sup>[13-15]</sup>。该算法通过手动设计特定的复杂烟雾特征,并利用SVM、K-means聚类等分类器,将图像块分类为烟雾和非烟雾。

### 2.1.1 SVM

SVM由于其解决小样本、非线性和高维回归以及二分类问题的优势而被广泛应用。Appana等<sup>[16]</sup>通过颜色分割和帧差法确定视频帧中可能存在烟雾的区域,再对时差图像进行Gabor滤波和小波变换,提取烟雾的纹理信息和时空能量特征。最后,将这些特征输入SVM,完成烟雾与非烟雾帧的分类。Manivannan等<sup>[17]</sup>利用灰度共生矩阵和SVM进行PM的特征提取和分类,通过自动选择最佳的图像分割算法提高PM特征分析的准确性和效率。相较于基于直方图的SVM方法,该方法的准确率提升了30%。Tian等<sup>[18]</sup>建立了一个双字典模型,将单帧图像分离为准烟雾和准背景组件,并通过SVM判断烟雾的存在与否。然而,SVM在某些情况下可能表现出有限的泛化能力,特别是当面临复杂的环境和不同种类的PM时。

### 2.1.2 K-means 聚类

K-means是无监督学习中常用的算法,可用于分类和检测任务。它被认为是一种简单而高效的聚类算法,通常能够在相对短的时间内收敛到局部最小值。Shrivastava等<sup>[19]</sup>利用了烟雾的颜色和运动特征,首先将RGB色彩空间转换为CIELab色彩空间,然后利用背景减法和K-means聚类算法对视频帧中的烟雾像素进行分割和识别。Gu等<sup>[20]</sup>提出了一种基于视觉的火焰烟雾监测系统(vision-based monitor of flare soot, VMFS),用于检测石化企业中燃烧设备排放的火焰烟雾。VMFS分为3个阶段:快速火焰检测、火焰区域提取和火炬烟尘识别。该系统利用

颜色分析、显著性检测和K-means聚类等图像处理技术,实现了高效和准确的火炬烟尘监测。研究表明,VMFS的性能优于基于神经网络的方法。K-means聚类算法通常依赖于数据的分布情况,对于复杂、多样和不均匀分布的PM数据可能表现出有限的泛化能力。

## 2.2 基于深度学习的算法

传统的PM检测方法依赖于手动设计特征和分类器,这在处理复杂的PM图像时存在一定的局限性。深度学习算法通过多层神经网络的组合和训练,能够自动从原始数据中提取特征,并可实现对PM的准确识别。

### 2.2.1 工业烟雾排放检测

Tao等<sup>[21]</sup>提出了一个基于通道增强的时空网络(channel-enhanced spatiotemporal network, CENet),用于识别工业烟雾排放。CENet使用了足够的监督信息,包括二元类别、像素级烟雾密度和背景信息,来指导模型学习区分烟雾和非烟雾的特征表示,并在网络中间层加入了监督信息来提高特征提取能力。同时,设计了一些通道增强的模块,包括通道增强的池化、卷积和上采样,以解决标准池化和卷积操作在特征提取中的不足,选择性地增强或抑制不同通道的特征。Tao等<sup>[22]</sup>不仅考虑二值类别信息,而且将视频属性信息作为提高烟雾检测率的重要补充,利用摄像机特性、季节等作为辅助的监督信息指导模型学习更具辨别力的特征。为了提高对小型/轻微烟雾和烟雾似物的识别能力,设计了空间时间信息注意力模块和上下文信息注意力模块,分别捕获烟雾的运动信息和全局语义信息。

### 2.2.2 双通道模型的烟雾检测

由于PM具有多重特征,双通道CNN能够将这些特征交叉融合,增强网络的表示能力。Gu等<sup>[23]</sup>设计了一种基于深度双通道神经网络的图像烟雾检测方法。其中2个子网络分别提取烟雾的细节信息和基础信息,通过连接操作将2个子网络的特征融合。该方法在公开的烟雾检测数据库上实现了超过99.5%的平均检测率,优于基于手工特征或深度学习的现有方法。Li等<sup>[24]</sup>使用了一个基于双边分割网络(bilateral segmentation network, BiSeNet)的双路径网络,由一个空间路径和一个上下文路径组成,分别负责提取空间信息和语义信息。空间路径中加入了金字塔池化模块,用于获取不同尺度的全局信息。上下文路径中使用了残差网络(residual network, ResNet)作为轻量级的骨干网络,并引入了高效的通

道注意力模块,用于增强特征的区别能力。

### 2.2.3 烟雾检测算法的性能优化

随着物联网和边缘计算设备的发展,出现了通过智能设备进行野火检测的研究。Dimitropoulos等<sup>[15]</sup>介绍了一种基于高阶线性动力系统的多维动态纹理分析方法,用于视频监控中的烟雾检测。该方法基于高阶线性动力系统模型,能够利用多个图像元,如RGB通道或方向梯度直方图(histogram of oriented gradient, HOG)特征的信息来描述动态纹理的变化,并结合了烟雾的时空特征(如运动和模糊效应)。该工作的主要局限性是计算量大、检测率低,导致帧率低。上述现有的最先进的烟雾探测方法仅适用于正常环境,在雾天和不确定环境中性能较差。为解决该问题, Khan等<sup>[25]</sup>设计了一种基于深度CNN的能效系统,用于在智能城市物联网环境下早期检测正常和雾霾环境中的烟雾,实现了准确性和时间效率的平衡。Almeida等<sup>[26]</sup>提出了一种基于深度学习的轻量级CNN模型,用于通过RGB图像检测野火。该模型能够嵌入边缘设备,并与闭路电视系统和无人机系统相结合,用于森林火灾的监测和检测。

## 3 PM 识别

PM的识别和监测是环境科学领域中的重要研究方向。随着全球范围内空气质量的恶化,准确、及时地识别和监测空气中的PM对环境保护和人类健康至关重要。

### 3.1 基于传统的方法

在过去的40年里,人们开发了多种监测空气质量的方法,可将其归为4类传统方法<sup>[27]</sup>:质量法<sup>[28]</sup>、天平法<sup>[29]</sup>、光学法<sup>[30]</sup>及射线法<sup>[31]</sup>。这些方法都存在一定的局限性:手动测量具有较高的精度,但操作复杂且成本较高,适用于特定研究场景或需要极高精度的监测,不太适合大规模、实时或长期监测任务;自动测量相对便捷,但需要频繁校准和维护。

在空气质量监测方面,传统方法主要采用了统计学习的原理。这些方法包括边缘检测和提取HOG等特征,通过对这些特征进行分析和计算获得关于空气质量的测量数值。Liu等<sup>[32]</sup>从室外图像中提取了6种图像特征,包括透射率、天空的平滑度和颜色等,并考虑了其他相关数据,如太阳位置、日期、时间等。Yang等<sup>[33]</sup>采用无人机携带传感器进行空气质量监测,并研究了如何推荐三维空间中最合适

的传感器位置以进行细粒度的AQI监测。除了运用统计方法,神经网络也已广泛应用于空气质量测量。Yang等<sup>[34-35]</sup>和Hu等<sup>[36]</sup>借助搭载在无人机上的传感器采集环境信息,并通过深度神经网络对这些数据进行拟合以估算当前的空气质量。Jiang等<sup>[37]</sup>将无监督学习和监督学习相结合。Chen等<sup>[38]</sup>利用一种多层前馈神经网络,通过反向传播(back propagation, BP)算法来探索PM<sub>2.5</sub>质量浓度和相应因素之间的非线性关系。

### 3.2 基于图像的方法

随着智能手机和视频监控装置的迅猛发展和人工智能技术的广泛运用<sup>[39]</sup>,图像质量不断提升,采集和收集也变得更为简便。这为利用图像处理和机器学习等人工智能方法监测图像中的空气质量提供了可能<sup>[40]</sup>。公众可以通过手机拍摄周围的场景图片,并利用建立好的空气质量图像识别模型进行分析,获取空气质量信息,并及时采取防护措施。

图像监测空气质量的方法具有多种优势。首先,它减少了对专业硬件设备的依赖以及维护所需的人力和物力资源,使其更加便捷和高效。其次,它提高了空气质量监测的空间粒度<sup>[27]</sup>。通过分析图像特征或应用深度学习方法,基于图像的空气质量评估可以将空气质量监测扩展到更广泛的区域。基于图像特征的方法和基于深度学习的方法是图像监测空气质量的2种主要方法。

#### 3.2.1 基于图像特征的方法

这些方法着重于讨论图像特征与PM指数之间的联系。Gao等<sup>[41]</sup>利用无人机搭载的高清摄像头拍摄360°的全景图像,从中提取出与雾霾相关的特征,然后通过线性回归模型估计AQI。Yue等<sup>[42]</sup>提出了一种基于照片的PM<sub>2.5</sub>质量浓度估计方法,通过分析不同PM<sub>2.5</sub>质量浓度下拍摄的照片的特征,提取梯度相似度和饱和度分布形状。通过结合这2类特征,得到一个初步的PM<sub>2.5</sub>质量浓度估计值,然后通过一个非线性函数映射到真实的PM<sub>2.5</sub>质量浓度。该方法仅考虑了图片的部分特征,没有充分利用图片中其他可能影响PM<sub>2.5</sub>质量浓度的因素,如拍摄时间、季节、天气等。Gu等<sup>[43]</sup>提出了第一个自然度统计模型来预测图片的PM<sub>2.5</sub>质量浓度。利用图片饱和度和图的熵特征,建立了基于良好天气图片的自然度统计模型,用来计算新图片的相似度。然后,用一个非线性函数将相似度转换为PM<sub>2.5</sub>质量浓度。与其他方法相比,预测精度高于80%。未来的研究可以继续探索多因素模型,综合考虑图像特征、时间、

季节、天气等多个因素,以提高  $\text{PM}_{2.5}$  质量浓度的准确性。

### 3.2.2 基于深度学习的方法

深度学习方法在图像特征学习领域取得了显著的突破,同时在解决经典计算机视觉问题方面取得了进展。Chakma 等<sup>[6]</sup>首次使用 CNN 进行了空气质量分析,该研究使用迁移学习的方法,将预训练的 CNN 微调或用作特征提取器,然后用随机森林分类器对自然图像进行分类。Zhang 等<sup>[44]</sup>提出了一种基于 CNN 的图片空气污染水平估计算法,并且设计了一个新的激活函数和一个负对数回归分类器来适应空气污染估计的任务。Gu 等<sup>[45]</sup>设计了一种基于图像的火炬烟密度识别网络 (flare soot density recognition network, FSDR-Net),利用模型无关的元学习算法在多个与火炬烟识别相关的任务上训练一个深度 CNN。该方法能够在只有少量样本的情况下,有效地识别火炬烟是轻烟灰还是浓烟灰。针对新的火炬烟密度识别任务,该方法利用不同的学习率和梯度步数生成多个预测结果,并通过一种新颖的选择性集成策略进行融合。结果表明,FSDR-Net 对火炬烟密度识别的准确率达到 97.5%,远高于其他深度 CNN。Gu 等<sup>[46]</sup>利用信息丰度测量和宽深度学习技术 (information abundance measurement and wide and deep learning, IAWD) 对照片中的  $\text{PM}_{2.5}$  进行监测,如图 4 所示。首先,将照片从 RGB 空间转换到暗度和饱和度 (darkness and saturation, DS) 空间,利用熵来衡量照片在 DS 空间中的信息丰富度,并作为特征输入;然后,结合宽神经网络的记忆能力和神经网络的泛化能力,学习从提取的特征到  $\text{PM}_{2.5}$  质量浓度的非线性映射。该部分采用了三步训练过程,分别对宽神经网络和神经网络进行预训练,对宽神经网络的权重进行优化,并对整个宽神经网络进行微调。未来可考虑融合多模态信息,如图像、时间序列数据和气象信息,以提高对空气质量的综合估计,并研究在线学习方法,使模型不断适应新的数据和环境条件,实现实时的空气质量估计。

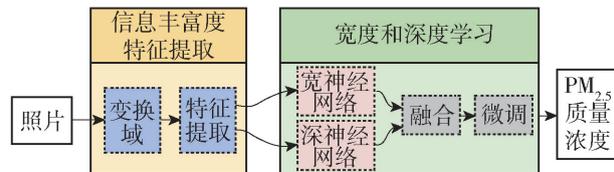


图4 IAWD模型<sup>[46]</sup>

Fig. 4 Model of IAWD<sup>[46]</sup>

## 4 PM 预警

据 WHO 报告,空气污染已成为全球最大的环境健康风险,每年导致至少 700 万人死亡<sup>[47]</sup>。除了对健康的影响外,空气污染也对许多发展中国家的经济产生了沉重的负担<sup>[48]</sup>。实际上,如果能够准确预测每个城市区域未来的 AQI,就可以通过有效的污染排放控制和及时的干预措施减少或预防潜在的空气污染造成的损失。关于 PM 预警的方法可分为 2 类:非深度学习方法和深度学习方法。

### 4.1 非深度学习方法

非深度学习方法大致包括 2 个主要模型:确定性模型和统计模型<sup>[49]</sup>。由于某些原因,例如,在确定模型结构和通过经验估计参数时使用理想理论,这些模型的预测性能有限<sup>[50]</sup>,统计方法因避免了复杂的理论模型而被广泛使用。

统计方法也可分为 2 类:经典统计方法和传统机器学习方法<sup>[51]</sup>。经典统计方法是指基于自动回归积分移动平均线模型 (autoregressive integrated moving average model, ARIMA) 的方法<sup>[52-53]</sup>,这些方法通常需要数据满足一定的统计性质,如平稳性。如果数据不符合这些条件,性能可能大幅下降。传统的机器学习方法通常使用支持向量回归 (support vector regression, SVR)<sup>[54]</sup>、神经网络<sup>[55]</sup>、随机森林<sup>[56]</sup>和聚类分析<sup>[57]</sup>。这些方法更具灵活性,能够适应不同类型的数据,但是它们可能需要大量的标记数据和参数调整来获得最佳性能,对于复杂的非线性问题,它们可能需要更复杂的模型来捕捉关系。

Gu 等<sup>[54]</sup>提出了一种基于循环策略的空气质量预测器 (recurrent air quality predictor, RAQP), RAQP 采用 SVR 模型来学习当前的输入变量和 1 h 后的输出变量之间的回归关系,然后递归地应用该模型来预测更长时间的空气质量。实验证明了 RAQP 在空气质量预测方面优于现有的技术和非循环方法。Li 等<sup>[55]</sup>利用 BP 神经网络和响应面法对生物质气化的合成气质量进行预测和优化。Masmoudi 等<sup>[56]</sup>结合了多目标回归方法和随机森林算法,通过特征选择和特征重要性评估,提高了同时预测多种空气质量的性能和准确度。Jiang 等<sup>[57]</sup>提出了一种基于小波包分解、改进的鸽子启发式优化、极限学习机和多尺度 K-means 聚类的混合学习方法,用于预测城市 AQI。此外,Gu 等<sup>[58]</sup>研究了一种新的适用于大型集会场合的空气污染预测模型。该模型考虑了训练样

本在时间域上的重要性差异,以及不同空气污染物之间的相关性,采用多任务学习的策略,构建了一个多任务时间 SVR 器。

非深度学习方法在 PM 预警中具有一定的适用性,但适用范围受到数据性质和问题复杂性的限制。未来的研究可以探索混合方法和针对特定场景的定制化方法,以提高 PM 预警的准确性和实用性。

## 4.2 深度学习方法

深度学习模型由于能够处理更复杂的数据和进行特征提取,在 PM 检测领域被广泛应用。通过对历史数据的学习和建模,能够识别出与 PM 质量浓度相关的模式和规律,并进行未来的预测。PM 预测中常用的深度学习框架有 CNN、RNN 和 GNN。

表 3 描述了深度学习方法的部分结果,可以得出结论,深度学习方法可以达到更高的精度。

表 3 深度学习模型在空气质量预测中的部分应用  
Table 3 Partial application of deep learning models in air quality forecasting

| 深度学习模型  | 污染物/AQI  | 城市       | 最佳模型  | 改善程度 <sup>①</sup>  |
|---|--|----------|---|--|
| 深度空气质量预测框架 (deep air quality forecasting framework, DAQFF) <sup>[59]</sup>                                | PM <sub>2.5</sub>  | 北京       | RNN   | 22.7% (RMSE), 29.90% (MAE)   |
| CNN-长短期记忆网络 (long short-term memory, LSTM) <sup>[60]</sup>  | AQI  | 德里       | 堆叠式 LSTM  | 3.87% (MSE), 0.37% (MAE), 0.37% (MAPE)   |
| K-means-LSTM <sup>[61]</sup>  | PM <sub>2.5</sub>  | 台北<br>台中 | 基于聚类的混合神经网络模型 (cluster-based hybrid neural network model, Cluster-based HNNM)                     | 台北: 57.06% (MAE)<br>台中: 34.33% (MAE)   |
| 地理时空门控循环单元 (geographic spatiotemporal gated recurrent unit, Geo-ST-GRU) <sup>[62]</sup>                   | PM <sub>2.5</sub>  | 北京       | ST-GRU  | 古城站: 1.59% (MAE),<br>-8.22% (MRE)<br>东四站: 0.73% (MAE), 14.29% (MRE)  |
| 嵌入空间注意力的循环神经网络 (spatio-attention embedded recurrent neural network, SpAttRNN) <sup>[63]</sup>             | PM <sub>2.5</sub> ,<br>PM <sub>10</sub> ,<br>NO <sub>2</sub> | 北京       | 地理感知的多级注意力网络 (multi-level attention networks for geo-sensory, GeoMAN)                             | PM <sub>2.5</sub> : 14.55% (MAE), 4.40% (RMSE)<br>PM <sub>10</sub> : 15.67% (MAE), 7.97% (RMSE)<br>NO <sub>2</sub> : 7.73% (MAE), 2.52% (RMSE) |
| 多对抗时空循环图神经网络 (multi-adversarial spatiotemporal recurrent graph neural network, MasterGNN) <sup>[64]</sup> | AQI  | 北京<br>上海 | 基于地理上下文的扩散卷积循环神经网络 (geo-context based diffusion convolutional recurrent neural network, GC-DCRNN) | 北京: 7.20% (MAE)<br>上海: 11.5% (MAE)   |
| MasterGNN <sup>+</sup> <sup>[65]</sup>  | AQI  | 北京<br>上海 | MasterGNN   | 北京: 4.85% (MAE)<br>上海: 3.88% (MAE)   |

①改善程度是指所提模型和最佳模型相比,误差指标降低的比例。

### 4.2.1 基于 CNN 的方法

CNN 通常应用于图像识别,有一些研究利用 CNN 来分析图像中的空气质量并估计 PM<sub>2.5</sub> 浓度。Yao 等<sup>[66]</sup>使用残差网络 ResNet 和一维 CNN 来处理图像数据和气象数据,并用决策层将它们融合成一个统一的框架。该方法可以利用智能手机拍摄的室外天空图像和最近气象站的气象记录,提供现场实时的空气质量推断。将 CNN 和 LSTM 相结合用于预测空气质量也是一种常用的方法。Du 等<sup>[59]</sup>设计了一个基于一维 CNN 和 Bi-LSTM 的联合混合深度

学习框架,用于多元空气质量相关时间序列数据的共享表示特征学习。前者用于提取局部趋势特征和空间相关特征,后者用于从相应时间序列数据中获取长依赖时间特征。Chhikara 等<sup>[60]</sup>首先利用基于粒子群优化的无人机定位方案,快速找到最危险的污染区域,然后将无人机收集的数据输入到一个轻量级 CNN-LSTM 模型中进行 AQI 预测。

### 4.2.2 基于 RNN 的方法

在深度学习模型中,RNN 非常适合解决空气质量预测问题,因为 RNN 擅长处理序列数据。Lo

等<sup>[61]</sup>提出一个基于聚类的 LSTM 神经网络模型。根据  $PM_{2.5}$  的小时变化,用 K-means 将 Airbox 设备分成不同的类别,并为每个类别构建一个 LSTM 模型。最后,将预测模型与 Line 平台结合,提供了一个实时的  $PM_{2.5}$  预测服务。除了 LSTM 之外,门控循环单元(gate recurrent unit, GRU)是 LSTM 的一种简化变体。许多研究人员用 GRU 进行了实验。Athira 等<sup>[67]</sup>比较了基本 RNN、LSTM 和 GRU 对空气质量的预测,实验表明 GRU 的性能最好。Liu 等<sup>[62]</sup>利用地理自组织映射,根据监测站的地理位置和时间序列特征进行聚类,然后为每个聚类构建一个 GRU 模型,并用高斯向量权重来考虑风的影响。该模型称为空间时序 RNN,用于预测北京的  $PM_{2.5}$  质量浓度。此外,注意力机制对于提高模型的准确性有一定的效果。Huang 等<sup>[63]</sup>提出一种基于空间注意力的 RNN,使用自环归一化邻接矩阵来增强基于图的注意力单元,从而学习监测站之间的关系。该方法综合利用监测站之间的动态空间-时间相关性,以解决污染物扩散的复杂空间-时间交互问题。

#### 4.2.3 基于 GNN 的方法

GNN 能够有效地处理图结构化的数据,捕捉监测站之间的非线性空间依赖关系,以及污染物的传

输现象,也能够利用图注意力机制,学习节点之间的重要性,从而提高模型的预测能力。Mandal 等<sup>[68]</sup>采用一种基于聚类的时空特征提取方法,能够处理空间异质性,并使用图注意力网络增强模型的效率,应用于印度德里的  $PM_{2.5}$  质量浓度预测。相关研究表明,对空气质量和天气联合预测的效果要优于单任务。Han 等<sup>[64]</sup>提出 MasterGNN 用于空气质量和天气的联合预测,该方法的结构如图 5 所示。该模型包括 3 个主要任务,将历史观测值和上下文特征作为模型的输入,利用异构循环 GNN 模拟空气质量和天气监测站之间的时空自相关,实现联合预测;通过微观和宏观的判别器抵抗观测噪声的传播,提高预测的鲁棒性;利用多任务自适应训练策略动态地调整多个判别器的优化权重,平衡不同的目标函数。在此基础上,Han 等<sup>[65]</sup>又考虑了空气质量和天气状况可能与远程监测站报告的观测结果有关,在时域中表现出复杂的自相关性,提出了 MasterGNN<sup>+</sup> 算法。相比于 MasterGNN,该方法引入了多视图图学习模块,增加了 2 个图来增强环境上下文之间的内在关系建模,通过一个专用的演化循环网络动态地捕捉每个监测站和时间槽的长期和独立的时间自相关。

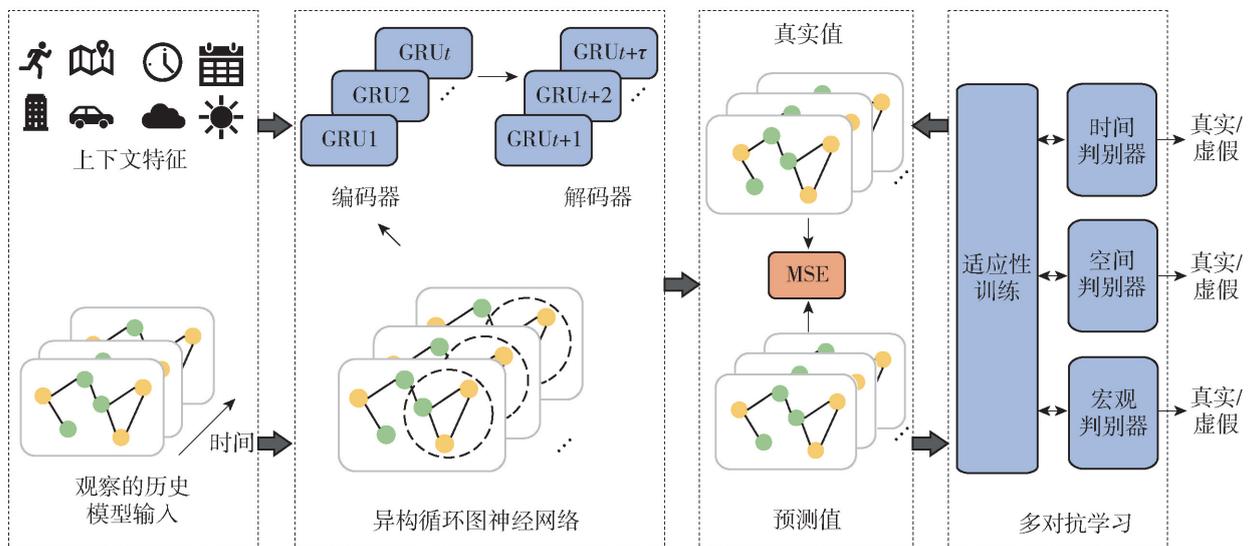


图 5 MasterGNN 模型<sup>[64]</sup>

Fig. 5 Model of MasterGNN<sup>[64]</sup>

## 5 结论与展望

准确地监测 PM 对了解 PM 来源和保护人类健康至关重要。本文提供了一些有效的解决方案,可以为 PM 检测、识别和预警提供参考。相比于传统方法,基于机器感知与学习的方法在各方面都展示

出优越性,但是,目前仍存在一些问题和挑战。例如:一些研究没有对不同类型的空气污染物和气象变量进行单独的预测,而是使用了统一的 AQI 和天气指数,这可能忽略了它们之间的差异和关联。

针对这些问题和挑战,未来的研究可以从以下几个方面展开:1) 探索使用其他类型的摄像机或传

感器来扩展所提出方法的适用范围和准确度;2)对不同类型的空气污染物和气象变量进行细粒度的预测,以揭示它们之间更复杂的相互作用关系;3) MasterGNN 联合空气质量和天气预测的模型,显式地模拟2个预测任务之间的相关性和交互性,这比仅预测空气质量效果更好。未来工作可考虑更多的环境因素,如交通流量等,来提高预测的准确性和可解释性。

### 参考文献:

- [1] World Health Organization. How air pollution is destroying our health [EB/OL]. [2023-07-06]. <https://www.who.int/zh/news-room/spotlight/how-air-pollution-is-destroying-our-health>.
- [2] ZHANG L Q, LIU W W, HOU K, et al. Air pollution exposure associates with increased risk of neonatal jaundice [J]. *Nature Communications*, 2019, 10(1): 3741.
- [3] LI Y, GUAN D B, YU Y N, et al. A psychophysical measurement on subjective well-being and air pollution [J]. *Nature Communications*, 2019, 10(1): 5473.
- [4] GRANT-JACOB J A, MILLS B. Deep learning in airborne particulate matter sensing: a review[J]. *Journal of Physics Communications*, 2022, 6(12): 122001.
- [5] WANG F, YU H F, WANG Z Y, et al. Review of online source apportionment research based on observation for ambient particulate matter [J]. *Science of the Total Environment*, 2021, 762: 144095.
- [6] CHAKMA A, VIZENA B, CAO T T, et al. Image-based air quality analysis using deep convolutional neural network [C] // *IEEE International Conference on Image Processing*. Piscataway, NJ: IEEE, 2017: 3949-3952.
- [7] CONNOLLY R E, YU Q, WANG Z M, et al. Long-term evaluation of a low-cost air sensor network for monitoring indoor and outdoor air quality at the community scale[J]. *Science of the Total Environment*, 2022, 807: 150797.
- [8] GEWIN V. How a dangerous stew of air pollution is choking the United States [J]. *Nature*, 2022, 612: 204-207.
- [9] DAELLENBACH K R, UZU G, JIANG J H, et al. Sources of particulate-matter air pollution and its oxidative potential in Europe[J]. *Nature*, 2020, 587: 414-419.
- [10] HOPKE P K, DAI Q L, LI L X, et al. Global review of recent source apportionments for airborne particulate matter[J]. *Science of the Total Environment*, 2020, 740: 140091.
- [11] 冯维维. 我国天空地一体化监测网络初步建成[N]. *中国科学报*, 2023-05-30(001).
- [12] PENG Y S, WANG Y. Real-time forest smoke detection using hand-designed features and deep learning [J]. *Computers and Electronics in Agriculture*, 2019, 167: 105029.
- [13] BAEK J, ALHINDI T J, JEONG Y S, et al. A wavelet-based real-time fire detection algorithm with multi-modeling framework [J]. *Expert Systems with Applications*, 2023, 233: 120940.
- [14] FILONENKO A, HERNÁNDEZ D C, JO K H. Fast smoke detection for video surveillance using CUDA[J]. *IEEE Transactions on Industrial Informatics*, 2017, 14(2): 725-733.
- [15] DIMITROPOULOS K, BARMPOUTIS P, GRAMMALIDIS N. Higher order linear dynamical systems for smoke detection in video surveillance applications[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2016, 27(5): 1143-1154.
- [16] APPANA D K, ISLAM R, KHAN S A, et al. A video-based smoke detection using smoke flow pattern and spatial-temporal energy analyses for alarm systems[J]. *Information Sciences*, 2017, 418: 91-101.
- [17] MANIVANNAN K, AGGARWAL P, DEVABHAKTUNI V, et al. Particulate matter characterization by gray level co-occurrence matrix based support vector machines[J]. *Journal of Hazardous Materials*, 2012, 223: 94-103.
- [18] TIAN H D, LI W Q, OGUNBONA P O, et al. Detection and separation of smoke from single image frames[J]. *IEEE Transactions on Image Processing*, 2017, 27(3): 1164-1177.
- [19] SHRIVASTAVA M, MATLANI P. A smoke detection algorithm based on K-means segmentation [C] // *International Conference on Audio, Language and Image Processing*. Piscataway, NJ: IEEE, 2016: 301-305.
- [20] GU K, ZHANG Y H, QIAO J F. Vision-based monitoring of flare soot [J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(9): 7136-7145.
- [21] TAO H J, XIE C, WANG J, et al. CENet: a channel-enhanced spatiotemporal network with sufficient supervision information for recognizing industrial smoke emissions[J]. *IEEE Internet of Things Journal*, 2022, 9(19): 18749-18759.
- [22] TAO H J, LU M H, HU Z W, et al. Attention-aggregated attribute-aware network with redundancy reduction convolution for video-based industrial smoke emission recognition[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(11): 7653-7664.
- [23] GU K, XIA Z F, QIAO J F, et al. Deep dual-channel

- neural network for image-based smoke detection [J]. *IEEE Transactions on Multimedia*, 2020, 22(2): 311-323.
- [24] LI Y M, ZHANG W, LIU Y Y, et al. A lightweight network for real-time smoke semantic segmentation based on dual paths [J]. *Neurocomputing*, 2022, 501: 258-269.
- [25] KHAN S, MUHAMMAD K, MUMTAZ S, et al. Energy-efficient deep CNN for smoke detection in foggy IoT environment [J]. *IEEE Internet of Things Journal*, 2019, 6(6): 9237-9245.
- [26] ALMEIDA J S, HUANG C X, NOGUEIRA F G, et al. EdgeFireSmoke: a novel lightweight CNN model for real-time video fire-smoke detection [J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(11): 7889-7898.
- [27] ZHANG Q, FU F C, TIAN R. A deep learning and image-based model for air quality estimation [J]. *Science of the Total Environment*, 2020, 724: 138178.
- [28] BUONANNO G, DELL'ISOLA M, STABILE L, et al. Critical aspects of the uncertainty budget in the gravimetric PM measurements [J]. *Measurement*, 2011, 44(1): 139-147.
- [29] GREEN D, FULLER G W. The implications of tapered element oscillating microbalance (TEOM) software configuration on particulate matter measurements in the UK and Europe [J]. *Atmospheric Environment*, 2006, 40(29): 5608-5616.
- [30] HAJIEGHRARY O, STOEBER B, GREEN S. A light extinction-based concentration measurement in two phase gas-solid flow [J]. *International Journal of Multiphase Flow*, 2023, 164: 104446.
- [31] TRIANTAFYLLOU E, DIAPOULI E, TSILIBARI E M, et al. Assessment of factors influencing PM mass concentration measured by gravimetric & beta attenuation techniques at a suburban site [J]. *Atmospheric Environment*, 2016, 131: 409-417.
- [32] LIU C B, TSOW F, ZOU Y, et al. Particle pollution estimation based on image analysis [J]. *PLoS One*, 2016, 11(2): e0145955.
- [33] YANG Y Z, ZHENG Z J, BIAN K G, et al. Arms: a fine-grained 3D AQI realtime monitoring system by UAV [C] // *IEEE Global Communications Conference*. Piscataway, NJ: IEEE, 2017: 1-6.
- [34] YANG Y Z, ZHENG Z J, BIAN K G, et al. Real-time profiling of fine-grained air quality index distribution using UAV sensing [J]. *IEEE Internet of Things Journal*, 2018, 5(1): 186-198.
- [35] YANG Y Z, BAI Z X, HU Z W, et al. AQNet: fine-grained 3D spatio-temporal air quality monitoring by aerial-ground WSN [C] // *IEEE Conference on Computer Communications Workshops*. Piscataway, NJ: IEEE, 2018: 1-2.
- [36] HU Z W, BAI Z X, YANG Y Z, et al. UAV aided aerial-ground IoT for air quality sensing in smart city: architecture, technologies, and implementation [J]. *IEEE Network*, 2019, 33(2): 14-22.
- [37] JIANG Z F, MAO B Q, MENG X X, et al. An air quality forecast model based on the BP neural network of the samples self-organization clustering [C] // *International Conference on Natural Computation*. Piscataway, NJ: IEEE, 2010: 1523-1527.
- [38] CHEN J, LIU Z X, YIN Z T, et al. Predict the effect of meteorological factors on haze using BP neural network [J]. *Urban Climate*, 2023, 51: 101630.
- [39] YU J G, HUANG B G, CHENG X Z, et al. Shortest link scheduling algorithms in wireless networks under the SINR model [J]. *IEEE Transactions on Vehicular Technology*, 2017, 66(3): 2643-2657.
- [40] WANG Z Y, YUE S L, SONG C F. Video-based air quality measurement with dual-channel 3-D convolutional network [J]. *IEEE Internet of Things Journal*, 2021, 8(18): 14372-14384.
- [41] GAO J H, HU Z W, BIAN K G, et al. AQ360: UAV-aided air quality monitoring by 360-degree aerial panoramic images in urban areas [J]. *IEEE Internet of Things Journal*, 2020, 8(1): 428-442.
- [42] YUE G H, GU K, QIAO J F. Effective and efficient photo-based PM<sub>2.5</sub> concentration estimation [J]. *IEEE Transactions on Instrumentation and Measurement*, 2019, 68(10): 3962-3971.
- [43] GU K, QIAO J F, LI X L. Highly efficient picture-based prediction of PM<sub>2.5</sub> concentration [J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(4): 3176-3184.
- [44] ZHANG C, YAN J C, LI C S, et al. On estimating air pollution from photos using convolutional neural network [C] // *Proceedings of the 24th ACM International Conference on Multimedia*. New York: ACM, 2016: 297-301.
- [45] GU K, ZHANG Y H, QIAO J F. Ensemble meta-learning for few-shot soot density recognition [J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(3): 2261-2270.
- [46] GU K, LIU H Y, XIA Z F, et al. PM<sub>2.5</sub> monitoring: use information abundance measurement and wide and deep learning [J]. *IEEE Transactions on Neural Networks and*

- Learning Systems, 2021, 32(10): 4278-4290.
- [47] CAMPBELL-LENDRUM D, PRÜSS-USTÜN A. Climate change, air pollution and noncommunicable diseases[J]. Bulletin of the World Health Organization, 2019, 97(2): 160-161.
- [48] MATUS K, NAM K M, SELIN N E, et al. Health damages from air pollution in China [J]. Global Environmental Change, 2012, 22(1): 55-66.
- [49] LIU H, YAN G X, DUAN Z, et al. Intelligent modeling strategies for forecasting air quality time series: a review [J]. Applied Soft Computing, 2021, 102: 106957.
- [50] THONGTHAMMACHART T, ARAKI S, SHIMADERA H, et al. An integrated model combining random forests and WRF/CMAQ model for high accuracy spatiotemporal PM<sub>2.5</sub> predictions in the Kansai region of Japan [J]. Atmospheric Environment, 2021, 262: 118620.
- [51] ZHANG B, RONG Y, YONG R H, et al. Deep learning for air pollutant concentration prediction: a review [J]. Atmospheric Environment, 2022, 290: 119347.
- [52] KUMAR A, GOYAL P. Forecasting of daily air quality index in Delhi [J]. Science of the Total Environment, 2011, 409(24): 5517-5523.
- [53] ZHANG L Y, LIN J, QIU R Z, et al. Trend analysis and forecast of PM<sub>2.5</sub> in Fuzhou, China using the ARIMA model [J]. Ecological Indicators, 2018, 95: 702-710.
- [54] GU K, QIAO J F, LIN W S. Recurrent air quality predictor based on meteorology-and pollution-related factors [J]. IEEE Transactions on Industrial Informatics, 2018, 14(9): 3946-3955.
- [55] LI J S, YAO X W, XU K L. A comprehensive model integrating BP neural network and RSM for the prediction and optimization of syngas quality [J]. Biomass and Bioenergy, 2021, 155: 106278.
- [56] MASMOUDI S, ELGHAZEL H, TAIEB D, et al. A machine-learning framework for predicting multiple air pollutants' concentrations via multi-target regression and feature selection [J]. Science of the Total Environment, 2020, 715: 136991.
- [57] JIANG F, HE J Q, TIAN T H. A clustering-based ensemble approach with improved pigeon-inspired optimization and extreme learning machine for air quality prediction [J]. Applied Soft Computing, 2019, 85: 105827.
- [58] GU K, LIU H Y, LIU J, et al. Air pollution prediction in mass rallies with a new temporally-weighted sample-based multitask learner [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 2505915.
- [59] DU S D, LI T R, YANG Y, et al. Deep air quality forecasting using hybrid deep learning framework [J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 33(6): 2412-2424.
- [60] CHHIKARA P, TEKCHANDANI R, KUMAR N, et al. Federated learning and autonomous UAVs for hazardous zone detection and AQI prediction in IoT environment [J]. IEEE Internet of Things Journal, 2021, 8(20): 15456-15467.
- [61] LO C Y, HUANG W H, HO M F, et al. Recurrent learning on PM<sub>2.5</sub> prediction based on clustered airbox dataset [J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(10): 4994-5008.
- [62] LIU B, YAN S, LI J Q, et al. A spatiotemporal recurrent neural network for prediction of atmospheric PM<sub>2.5</sub>: a case study of Beijing [J]. IEEE Transactions on Computational Social Systems, 2021, 8(3): 578-588.
- [63] HUANG Y, YING J J C, TSENG V S. Spatio-attention embedded recurrent neural network for air quality prediction [J]. Knowledge-Based Systems, 2021, 233: 107416.
- [64] HAN J D, LIU H, ZHU H S, et al. Joint air quality and weather prediction based on multi-adversarial spatiotemporal networks [C] // Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto, CA: AAAI, 2021: 4081-4089.
- [65] HAN J D, LIU H, ZHU H S, et al. Kill two birds with one stone: a multi-view multi-adversarial learning approach for joint air quality and weather prediction [J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(11): 11515-11528.
- [66] YAO M Y, TAO D, WANG J T, et al. MARVAir: meteorology augmented residual-based visual approach for crowdsourcing air quality inference [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 2514310.
- [67] ATHIRA V, GEETHA P, VINAYAKUMAR R, et al. DeepAirNet: applying recurrent networks for air quality prediction [J]. Procedia Computer Science, 2018, 132: 1394-1403.
- [68] MANDAL S, THAKUR M. A city-based PM<sub>2.5</sub> forecasting framework using spatially attentive cluster-based graph neural network model [J]. Journal of Cleaner Production, 2023, 405: 137036.

(责任编辑 梁洁)