

融合多源信息及图像特征泛化的空气质量检测^{*}王晓婷¹ 崔雅博¹ 刘丽娜²

(1. 开封大学信息工程学院 开封 475004; 2. 郑州大学国家超级计算郑州中心 郑州 450001)

摘 要: 针对空气 $\text{PM}_{2.5}$ 浓度检测过度依赖专业设备的问题,提出了一种融合多源信息及图像特征泛化的空气质量检测算法。首先采用 EfficientNet-B0 作为主干网络对输入的大气可见光图像进行特征编码,将温度、湿度、风速、气压和光照强度等多源气象信息映射为与大气图像对应的特征向量,并与大气图像特征进行拼接融合;然后利用全连接层将全局特征输出为标量,并利用损失函数检测出空气的 $\text{PM}_{2.5}$ 浓度;最后在网络模型训练阶段,通过对大气图像不同尺度的特征进行随机泛化增强来丰富样本分布空间,使网络能够在有限的样本中学习更多特征,从而有效改善了检测网络的性能。实验结果表明:设计的检测方法与传统主流方法相比具有更高的检测精度和稳定性,在测试集上得到的 RMSE 和 R-squared 分别为 $21.55 \mu\text{g}/\text{m}^3$ 和 0.923,通过对 8 个场景检测,得到结果的平均误差仅为 5.2%,最大误差也仅为 7.6%,能够适应各类极端大气污染环境的空气质量检测任务。

关键词: 空气质量; $\text{PM}_{2.5}$ 检测; 卷积神经网络; 多源信息; 特征泛化增强; 特征融合

中图分类号: TN919.8; TP391.4 **文献标识码:** A **国家标准学科分类代码:** 520.60

Air quality detection based on multi-source information and
image feature generalizationWang Xiaoting¹ Cui Yabo¹ Liu Lina²

(1. School of Information Engineering, Kaifeng University, Kaifeng 475004, China; 2. National Supercomputing Center in Zhengzhou, Zhengzhou University, Zhengzhou 450001, China)

Abstract: In response to the issue of excessive reliance on professional equipment for detecting air $\text{PM}_{2.5}$ concentration, an air quality detection algorithm based on multi-source information and image feature generalization is proposed. Firstly, the EfficientNet-B0 was used as the backbone network for feature encoding of the input atmospheric visible image, the multi-source meteorological information, such as temperature, humidity, wind speed, pressure and light intensity, was mapped into feature vectors corresponding to the atmospheric image, and fused with the atmospheric image features. Then, the global features were output as scalars using a fully connected layer, and the $\text{PM}_{2.5}$ concentration in the air was detected using a loss function. Finally, the features of atmospheric images at different scales were randomly generalized and enhanced in the training phase of the network model to enrich the sample distribution space, making the network to learn more features from limited data samples, thereby effectively improving the performance of the detection network. The experimental results show that the designed air quality detection method has higher detection accuracy and stability compared to several mainstream methods, the RMSE and R-squared obtained on the test set are $21.55 \mu\text{g}/\text{m}^3$ and 0.923, respectively. The average error obtained by detecting 8 scenarios is only 5.2%, and the maximum error is only 7.6%, which can adapt to air quality testing tasks in various extreme atmospheric pollution environments.

Keywords: air quality; $\text{PM}_{2.5}$ detection; convolutional neural network; multi-source information; feature generalization enhancement; feature fusion

0 引 言

随着我国工业化和城市化进程的迅猛发展,高能耗、高

排放的产业规模持续扩大,给生态环境带来了前所未有的压力,其中空气污染问题尤为突出。近年来,雾霾天气在全国范围内频繁出现,严重影响到了人们的日常生活和健康,

已成为公众关注的焦点。细颗粒物 $\text{PM}_{2.5}$ 是构成雾霾的主要成分,其主要来源为火力发电厂、燃油汽车、船舶、飞机等排放的废气,以及工业生产过程中产生的粉尘和化学污染物。这些污染物悬浮在大气中,并与其他物质发生化学反应,形成细小的颗粒物,能够深入人体呼吸系统,甚至进入血液循环,对环境和人体健康造成极大危害^[1-3]。2013年世界卫生组织首次认定细颗粒物 $\text{PM}_{2.5}$ 致癌,还可引发心脑血管和呼吸道等疾病。根据生态环境部报告显示,2023年和2024年,全国339个地级及以上城市的细颗粒物 $\text{PM}_{2.5}$ 平均浓度分别为 $30 \mu\text{g}/\text{m}^3$ 和 $29.3 \mu\text{g}/\text{m}^3$,而世界卫生组织设定的 $\text{PM}_{2.5}$ 年均指导值为 $10 \mu\text{g}/\text{m}^3$ 。相比之下,我国的 $\text{PM}_{2.5}$ 浓度仍处于高位,且局部地区的空气质量形势依然非常严峻,需进一步加强空气污染的监测和治理。目前,细颗粒物 $\text{PM}_{2.5}$ 检测主要利用激光散射法进行测量,然后上传至环境监测部门数据中心进行处理和定时发布,该方法需要部署大量的监测站和专业设备,成本投入较高、部署复杂,限制了检测站点的覆盖范围。另一方面,由于地形、地貌以及街区结构复杂程度的不同,会导致各区域污染物的浓度差异较大,使得空气质量检测站点的测量结果难以代表整个区域的情况,尤其当遇到极端大气污染时,更不能满足特定场景对空气质量结果的精细化和实时性的要求^[4-5]。因此,如何在保证检测精度的同时,提高空气质量监测的便捷性、准确性和覆盖范围,已成为当前研究的热点。

众所周知,当空气中 $\text{PM}_{2.5}$ 达到一定浓度时,会形成不同程度的霾,导致空气中的光线发生散射,使人眼看到的景象变得模糊不清^[6]。同时,景象的颜色也会随之发生改变,例如:蓝天会变成灰色或黄色,这些变化都可以通过可见光图像的特征体现出来。另外,图像中的一些细节也可以反映出空气质量的变化情况,如果空气质量较差,灰尘和颗粒物会在建筑物、道路和车辆等物体表面留下明显的痕迹,使得某些细节变得模糊,这些特征为空气 $\text{PM}_{2.5}$ 检测提供了新思路。随着深度学习技术和计算机视觉的发展,一些学者开始探索将这些技术应用到空气质量检测中,通过提取和分析大气可见光图像的特征,可以检测出空气中细颗粒物浓度的变化情况,并取得了一定的成果。文献[7]根据暗通道先验理论,利用混合CNN对单幅图像进行分析,然后将得到的暗通道图与源图像作为混合神经网络的输入进行训练,再将得到的网络模型应用到空气质量检测中,获得了不错的效果;文献[8]针对空气质量检测精度较低的问题,基于收缩的时间卷积网络模型设计了空气质量检测方法,并借助特殊注意力机制优化了残差模块,有效降低了样本中的冗余信息占比,从而提高了对空气质量检测的准确率。文献[9]利用同步压缩小波变换算法对原始图像预处理,然后改进了麻雀搜索算法使其具有更佳的寻优性能,并将其应用在LSTM模型中对 $\text{PM}_{2.5}$ 浓度进行检测,从而在时间和空间层面提取更加有效的特征,实现了空气质量的高精度检测。虽然基于大气可见光图像的 $\text{PM}_{2.5}$ 检测方法取得

了一定的进展,但由于空气质量受多种因素的影响,单一图像信息往往无法充分捕捉环境的变化,导致检测精度受限。另外,现有的检测方法在面对复杂极端大气污染环境时,表现出了较弱的泛化能力和较大的检测误差。为此,本文设计了空气质量检测系统架构,并重点对检测算法进行了深入研究,提出了一种融合多源信息与图像特征泛化的空气质量检测算法。该算法基于EfficientNet-B0网络构建了空气 $\text{PM}_{2.5}$ 检测模型,通过结合温度、湿度、风速、气压和光照强度等不同气象参数,并与大气可见光图像特征进行融合,旨在提高模型在各种环境条件下的适应性和检测精度。在实验设计上,本文结合多源气象信息对设计的检测网络模型进行训练,还设计了特征泛化模块,实现自动化的特征增强,提升网络的泛化能力。最后在大样本数据集上进行了对比实验,结果表明提出的算法相较于传统方法在精度、稳定性和效率上均具有明显的优势,尤其在极端大气污染环境中的适应性,具有较高的实际应用价值,特别是在大规模部署的实时监测任务中,能够为环境保护和公共健康提供有力的技术支持。

1 空气质量检测系统总体架构

相关研究资料表明^[10],可见光图像的特征与空气中 $\text{PM}_{2.5}$ 的浓度有着密切的关系,然而空气 $\text{PM}_{2.5}$ 的浓度还会受到多种气象因素的影响,如:温度、湿度、风速、气压和光照强度等,所以基于单一图像的空气检测方法存在准确度低和泛化性能差的问题。为此,本文提出了一种融合多源信息及图像特征泛化的空气质量检测方法。

目前,能够获取图像的终端种类越来越多,如:监控摄像机、智能手机和车载摄像头等,但大多不具备GPU单元,运算能力相对较弱,无法独立完成检测网络模型的训练和实时的检测任务。针对这一问题,本文提出了将数据采集和空气 $\text{PM}_{2.5}$ 检测任务进行分离设计的思路,设计了空气 $\text{PM}_{2.5}$ 检测系统总体框架,该系统主要由检测终端、通信网络和后端检测服务器三部分组成。系统总体框架如图1所示。数据采集终端主要由图像采集模块、温度传感器、湿度传感器、风速传感器、气压传感器、光强传感器、5G传输模块等组成。后端检测服务器主要由搭建的空气 $\text{PM}_{2.5}$ 检测网络推理模型、训练模块、数据库以及网关等组成。该服务器具有强大的运算能力,通过对数据库中保存的数据进行训练,不断优化检测网络的性能。

数据检测终端主要负责采集图像、温度、湿度、风速、气压和光照强度等数据,并通过5G传输模块将采集到的数据发送到后端的空气 $\text{PM}_{2.5}$ 检测网络模型服务器。后端服务器实时接收数据检测终端发来的图像和数据进行处理,并将检测得到的 $\text{PM}_{2.5}$ 浓度数值返回给数据采集终端或者转发至第3方机构进行发布。由于目前大多数图像采集终端的集成度已经非常高,都具有成熟的图像采集和网络传输模块,所以本文将重点对 $\text{PM}_{2.5}$ 的检测网络设计方法进行

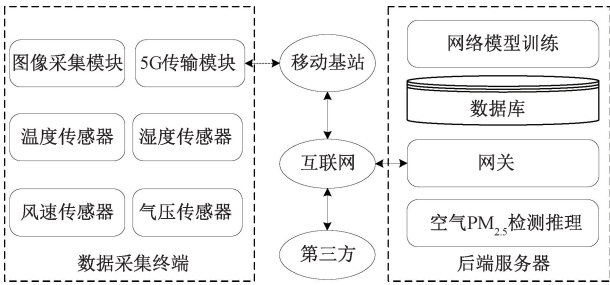


图 1 空气质量检测系统结构

Fig. 1 Structure of air quality detection system

行深入研究。

2 空气 PM_{2.5} 检测算法

针对单一图像的空气质量检测算法性能不足的问题,本文提出了一种融合多源信息及图像特征泛化的空气质量检测算法,该算法主要包含特征编码、特征融合和检测输出 3 个模块,算法整体框架如图 2 所示。

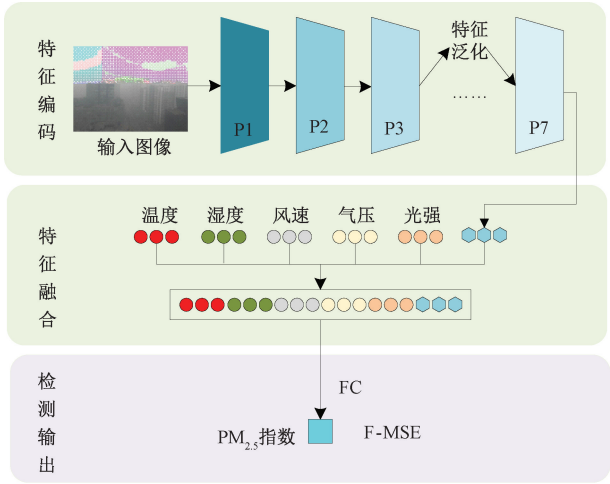


图 2 算法整体框架

Fig. 2 Overall framework of the algorithm

首先利用特征编码模块对大气可见光图像进行卷积、池化等操作,得到包含 PM_{2.5} 浓度信息的特征。然后利用特征融合模块将大气图像的特征与对应的温度、湿度、风速、气压和光照强度等多源气象信息向量进行拼接融合。最后检测输出模块则利用均方误差 (mean-square error, MSE) 损失函数对融合后的特征向量进行处理,从而检测出空气中 PM_{2.5} 的浓度。另外,本文设计了不同于原始数据层面增强的特征泛化模块,在网络训练阶段,利用随机噪声对大气图像特征进行泛化增强,并对隐藏维度上的特征相关性进行建模,使网络在有限的数据样本中自适应学习到更多的特征,有效提升网络的泛化能力,从而大幅改善了检测网络的性能。

2.1 主干网络 EfficientNet

为了学习更加抽象、丰富和深层次的语义特征,卷积神

经网络的设计通常采用增大图像的分辨率、网络深度和宽度的方案。然而,这些方法常常会增加模型的计算量和参数量,进而影响模型的性能。针对这一问题,本文综合考虑了模型尺寸和性能的平衡,采用 EfficientNet-B0 作为主干网络对大气图像进行特征编码,它是 EfficientNet 系列的基础模型,主要结构为 MBConv 模块,通过引入复合缩放策略,自动化搜索得到最佳的网络结构,在提升模型精度的同时,能够保持较小的计算量和较少的参数量,因此获得了更加优秀的性能,特别对精度和实时性要求较高的检测任务。EfficientNet-B0 网络结构参数如表 1 所示。

表 1 EfficientNet-B0 网络结构参数

Table 1 Parameters of EfficientNet-B0 network structure

阶段	运算操作	分辨率	通道数	层数
Input	Conv3×3	512×512	32	1
P1	MBConv1	256×256	16	1
P2	MBConv6	256×256	24	2
P3	MBConv6	128×128	40	2
P4	MBConv6	64×64	80	3
P5	MBConv6	32×32	112	3
P6	MBConv6	32×32	192	4
P7	MBConv6	16×16	320	1

输入的大气可见光图像首先经过 Conv3×3 卷积层进行初步特征提取,并通过批归一化和 Swish 激活函数进行处理。随后,MBConv 模块在 P1~P7 阶段逐步降低图像分辨率并增加通道数,从而提取不同尺度的特征,涵盖低级边缘、纹理以及高级语义特征,这样每个阶段的 MBConv 模块就逐渐构建出包含 PM_{2.5} 浓度信息的复杂特征表示。在 EfficientNet-B0 中,MBConv 模块作为一种经过优化的轻量级卷积层,引入了深度可分离卷积,在每个输入通道上独立进行卷积操作,然后再进行线性组合,这有效降低了计算复杂度,并同时保留了图像的高层次特征。此外,MBConv 还采用了瓶颈结构,由扩展层(Conv1×1 卷积)、深度卷积层(depthwise convolution)和压缩层(Conv1×1 卷积)组成。其中,扩展层通过 Conv1×1 卷积扩展特征维度,增加网络的表示能力;深度卷积层用来减少计算量;压缩层则恢复了特征的维度,最终输出更加丰富的特征表示。MBConv 模块结构如图 3 所示。

本文通过堆叠多个 MBConv 模块来提取大气可见光图像的多层次化特征,随着网络深度的增加,图像分辨率逐步降低,通道数逐渐增加,从而能够捕捉到更加抽象且复杂的语义信息。最后,通过全连接层进行处理,并用于检测 PM_{2.5} 浓度。采用这种方式,EfficientNet-B0 能够从大气可见光图像中高效提取有价值的特征,并与其他气象数据融合,实现 PM_{2.5} 浓度的高精度检测。

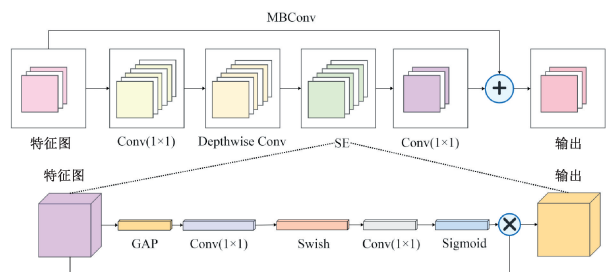


图 3 MBConv 模块

Fig. 3 MBConv module

2.2 特征泛化模块

特征泛化通常是指网络模型在训练阶段的一种学习能力,其目的在于使模型对不同样本或数据集的变化具备一定的适应性,特别是在数据样本有限的情况下,非常有助于网络模型学习到更加普遍的模式和规律,从而提高其在未曾遇到过的数据上的性能。传统的卷积神经网络主要通过不断的卷积运算来抽象其语义空间信息,并会对原始数据进行增强预处理,例如旋转、平移以及裁切等,来增大数据样本空间的分布,从而提升模型的泛化能力。然而,这些传统的数据增强方法无法适应极端环境下的空气检测任务,本文通过将特征泛化模块进行转换,并直接应用于特征空间,对不同尺度和不同语义的特征进行随机化增强,从而获得更大和更丰富的样本空间分布。特征泛化流程如图 4 所示。

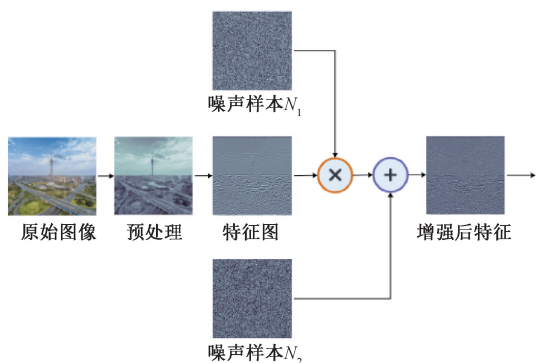


图 4 特征泛化流程

Fig. 4 Feature generalization flowchart

首先,从网络中的某一特定层选择输出的特征张量作为输入,这些特征张量代表了输入数据在该层的语义信息,包含了与 $\text{PM}_{2.5}$ 浓度相关的有用信息。本文将网络中某个给定的特征张量 x^i 作为特征编码第 i 层的输出,经过特征泛化增强后的结果描述如下:

$$\hat{x}^i = E(x^i) \quad (1)$$

式中: $E(\cdot)$ 表示特征增强的函数,将特征张量从原本的特征空间转换成更宽泛的特征空间。

然后,通过引入噪声对输入的特征进行随机化增强,扩展特征空间的多样性,并将来自两个不同类别的特征混合

到一个新的插值向量。本文使用正态分布生成随机噪声,并与输入特征进行加法和乘法运算操作,通过扰动特征空间中的信息,从而有效地增加了特征的多样性,提升了模型的适应性。数据增强过程如下:

$$\hat{x}^i = N_1 \odot x^i + N_2 \quad (2)$$

式中: N_1 和 N_2 属于与原始特征尺寸一致的噪声样本,且符合正态分布 $N(\mu, \sigma)$; \odot 为逐像素相乘运算。

在模型优化期间,可以结合特征的统计信息对正态分布 $N(\mu, \sigma)$ 进行更新。本文将 μ 设置为常数, σ 设置为常数对角矩阵,这样可将特征泛化公式转化为与数据无关的随机特征增强模块,采用这种参数化的处理,特征泛化函数可被视为随机扰动原始特征表示,而不偏向任何特定的扰动方向。权值 N_1 和偏移量 N_2 是从两个多元高斯分布中采样的,分别表示如下:

$$N_1 \sim N(1, \sigma_1 \mathbf{I}), N_2 \sim N(1, \sigma_2 \mathbf{I}) \quad (3)$$

式中: \mathbf{I} 是单位矩阵; σ_1 和 σ_2 均为超参数,本文设置 $\sigma_1 = \sigma_2$,通过减少超参数,便于降低运算量。

尽管通过加入随机噪声能够起到一定的泛化增强作用,但在实际中由标签噪声带来的影响可能会破坏这种效果。然而,通过均匀采样对角线噪声来扰乱特征编码,不考虑不同特征维度之间的相关性,这对网络学习的语义非常重要。为此,本文沿着数据跨越域分布的潜在方向进行更积极的采样,并且在不同类别跨越的潜在维度上进行抑制,提出了一个自适应协方差矩阵的噪声生成器,则特征泛化增强函数定义如下:

$$\hat{z}^i = N_1 \odot x^i + N_2 + \gamma \quad (4)$$

式中: γ 符合多元正态分布 $N(0, \Phi_b)$, $\Phi_b \in R^{B \times B}$, $b \in [1, B]$ 。

本文所采用的策略是通过观察数据协方差 Φ_b 来估计上文所提的类协方差变量。由于每个小批量数据中没有足够的准确数据,所以使用来自 B 个小批量的数据对协方差进行间歇性地估计,并使用指数移动平均 (exponential moving average, EMA) 在线更新:

$$\Phi_b = \eta \times \Phi_b + \sum_{i=1}^B \eta \times (1 - \eta)^i \times \Phi_{b-i} \quad (5)$$

式中: η 表示权重因子。

综上所述,与白噪声基线相比,本文所采用策略能够对隐藏维度上的特征相关性进行建模,从而具有更优的数据增强的效果。值得注意的是,因为协方差是从所有实例中计算获得,并在同一域上进行聚合,较高的域间可变性的方向将由这些协方差建模。另外,在拟合类条件协方差过程包含了标签信息,所以在 Φ_b 中保留了类内变化。同时,由于来自同一类的小批量特征实例共享相同的噪声,所以本文设计的特征泛化增强模块可以在网络训练期间实现自动化的特征增强。

2.3 特征融合和损失函数

特征泛化模块主要针对图像特征编码过程中不同尺度

特征进行泛化增强,特征融合阶段则需要考虑不同信息之间的融合问题。由于温度、湿度、风速、气压和光照强度等气象信息对 $PM_{2.5}$ 浓度检测精准度有着显著的影响,本文提出了一种将气象信息特征与图像特征进行编码和融合的方法。首先特征编码层将语义空间中的对象 y_i 映射到向量空间中的低维向量。这个映射需要表示 one-hot 编码的 y_i 如下:

$$y_i \rightarrow \delta_{ia} \quad (6)$$

式中: i 表示 y_i 的索引; a 表示向量 δ_{ia} 的长度。

为了解决 one-hot 编码 δ_{ia} 的高维和稀疏问题,本文增加了一个额外的线性神经元层,其输出定义如下:

$$y_i \rightarrow \sum_{\alpha} \omega_{\alpha\beta} \times \delta_{ia} = \omega_{i\beta} \quad (7)$$

式中: $\omega_{\alpha\beta}$ 是连接 one-hot 编码层和特征编码层的权重; $\omega_{i\beta}$ 是特征编码层的编码结果; β 是 $\omega_{i\beta}$ 向量的长度。

由于嵌入层的输入是一个非负整数,将第 i 个图像对应的第 k 个气象特征值定义为 f_i^k , 其中 $f_i^k(\max)$ 和 $f_i^k(\min)$ 分别代表图像中的最大值和最小值; c_i^k 表示天气特征值的类别信息,描述如下:

$$c_i^k = \frac{f_i^k - f_i^k(\min)}{f_i^k(\max) - f_i^k(\min)} \quad (8)$$

式中: n 表示类别数。

本文将 n 设置为 100,并将 c_i^k 编码到嵌入层中来生成 128 维向量,对温度、湿度、风速、气压和光照强度的气象特征进行编码,然后将编码后的气象特征与全局平均池化层输出的图像特征进行拼接,最终实现特征融合。

为了进一步提高算法的性能,本文设计了损失函数 F-MSE 描述如下:

$$F - MSE = \frac{1}{N} \sum_{j=1}^3 \sum_{i=1}^N \alpha_i^j (z_i^{j'} - z_i)^2 + L(z_i^{j'}) \quad (9)$$

式中: z_i 和 $z_i^{j'}$ 分别是第 i 个图像的真实值和最终检测值, $i = 1, 2, \dots, N$; $z_i^{j'}$ 是模型第 j 个编码层的第 i 个图像的检测值, $j = 1, 2, 3$; $L(\cdot)$ 表示原始均方误差损失函数; α_i^j 是用于强调模型不同层次的检测误差的权重。 $L(\cdot)$ 和 α_i^j 分别定义为:

$$\begin{cases} L = \frac{1}{N} \sum_{i=1}^N (z_i^{j'} - z_i)^2 \\ \alpha_i^j = \left(S(z_i^{j'}) - \frac{1}{2} \right)^2 \end{cases} \quad (10)$$

式中: $S(\cdot)$ 为 sigmoid 函数,表达式如下:

$$S(z_i^{j'}) = \frac{1}{1 + \exp(-(z_i^{j'} - z_i))} \quad (11)$$

最后通过将模型每一层的检测结果作为辅助损失参与模型训练,能够大幅改善算法性能,从而提高对 $PM_{2.5}$ 浓度检测的精准度。

3 实验结果

为了验证本文提出算法对 $PM_{2.5}$ 浓度检测的有效性和

优越性,采用本文所提算法与几种主流的检测方法对河南省郑州市采集得到的图像和气象数据进行训练和测试对比。

3.1 数据集及参数设置

在不同地理位置和不同时间段,利用高清摄像机拍摄大气环境可见光图像共计 2 000 幅,图像的分辨率为 1 024 pixel×1 024 pixel,保证了图像的清晰度和细节捕捉能力,图片格式为 jpg,且以采集时间对每幅图像进行命名。同时,利用专业的设备获取每幅图像对应的温度、湿度、风速、气压、光照强度以及 $PM_{2.5}$ 指数等气象数据,以采集时间对该组气象数据进行编号,并保存在 txt 文件中,最终形成 2 000 行的文本文件。其中,txt 文件中的 $PM_{2.5}$ 值即为对应大气环境可见光图像的标注结果,通过训练程序的设定,根据图像名称和气象数据编号,便可自动读取对应的匹配数据,从而完成模型的训练。需要说明,为了使数据集更具代表性,拍摄的地理位置涵盖了城市的不同区域,包括市中心、郊区和工业区等,确保数据集的多样性;拍摄的时间包括春夏秋冬四季,从 6:00~18:00 的不同时间段,涵盖了雨雪天、晴天、阴天以及雾霾天等不同污染程度的多种气象条件。特别是在大气污染较为严重的冬季和秋季,采集了更多的大气环境图像,以增强数据集的代表性,适应不同气象条件下空气质量检测任务。同时,为了丰富和充实训练样本,进一步提升网络泛化性能,还对数据集进行了数据增强处理。最后,将经过处理后的数据集按照 8:2 的比例分成训练集和测试集两部分。

本文利用均方根误差 (root mean squared error, RMSE) 和 R 平方 (R-square) 和推理时间 (单位为 ms) 3 个评估指标对不同算法的综合性能进行评价^[11],计算公式如下:

$$RMSE = \sqrt{\frac{1}{M} \sum_{i=1}^M (z_i - z_i')^2} \quad (12)$$

$$R\text{-square} = 1 - \frac{\sum_{i=1}^M (y_i - y_i')^2}{\sum_{i=1}^M (z_i - z_i')^2} \quad (13)$$

式中: M 表示测量的总次数。

本文使用基于深度学习的 Pytorch 框架进行网络模型搭建,训练和测试均在 Ubuntu 20.04 系统和 Python 3.8 环境下进行,采用了 12 GB 显存的 NVIDIA RTX2080Ti 显卡。为了缩短模型训练,使用 ImageNet 数据集进行训练后的网络参数权重作为本文空气 $PM_{2.5}$ 检测网络的初始权重。在设置训练相关的超参数时,选择加速 SGD 并且一直震荡的 Momentum 方法作为网络优化方法,对参数进行优化和更新,设置动量值设为 0.9;初始学习率为 0.001, Batch_size 为 16;迭代次数为 800。

3.2 对比实验

采用本文所提算法与几种主流的算法对测试集中大气

图像进行检测,得到不同算法下的 RMSE 和 R-square,对比实验结果如表 2 所示。

表 2 对比实验结果

Table 2 Comparison of experimental results

模型网络	RMSE ↓	R-square ↑	推理时间/ms
EPF ^[12]	64.32	0.484	30.3
RBF-LSTM ^[13]	59.15	0.578	25.6
EfficientNet-B0	55.31	0.651	8.4
ContraLea ^[14]	46.03	0.725	40.0
ResNet50 ^[15]	41.54	0.809	12.3
Inception-V3 ^[16]	37.19	0.822	16.1
ResNet50-Weather	36.01	0.839	15.7
本文方法	21.55	0.923	9.6

从表 2 的结果可看出:ResNet50-Weather 和本文方法都是采用了图像和气象信息结合的检测方法,与 EfficientNet-B0 和 ResNet50 对比来看,有无气象信息对于网络模型的检测性能影响较大,带气象信息的网络性能都要优于无气象信息的网络,而本文算法不仅结合了图像和气象信息,还引入了特征泛化模块使得网络泛化性能大幅提升,从而使得检测性能更为突出。从具体数据来看,采用本文算法对大气中 PM_{2.5} 检测得到的 RMSE 和 R-squared 值分别为 21.55 μg/m³ 和 0.923,与对比算法中性能最好的 ResNet50-Weather 相比, RMSE 降低了 14.46 μg/m³, R-squared 提高了 8.4%,表明本文提出的算法能够更加精准地检测出空气中的 PM_{2.5} 浓度。在推理时间方面,本文方法表现出了较高的检测效率,推理时间为 9.5 ms,仅比效率最高的 EfficientNet-B0 高了 1.2 ms,主要原因是模型中增加了融合多源信息的计算开销,表明本文方法在保证较高检测精度的同时,依然能够在较短的时间内完成推理,满足 PM_{2.5} 检测的实时性要求。

3.3 消融实验

消融实验是机器学习和深度学习领域中常用的实验设计方法,旨在评估模型中设计的各组件对整个算法性能的作用^[17-18]。本文以 EfficientNet-B0 为主干网络,通过是否添加气象信息以及变换特征泛化模块的位置进行了多组消融实验,具体实验结果如表 3 所示。其中,特征模泛化块使用 FG 表示,FG-*h* 表示在 EfficientNet-B0 的 *h* 层后添加特征泛化模块。

从表 3 的结果可看出:在基础主干网络 EfficientNet-B0 上,通过添加气象信息可以使网络的 RMSE 从 55.31 μg/m³ 降低至 38.23 μg/m³,与大部分较优的对比算法性能接近,说明了气象信息对于空气质量检测网络的性能有极大的提升作用,与图像特征起到信息互补的作用。另外,经主干网络,不同尺度的特征逐次添加特征泛化模块后,本文提出算法的 RMSE 从 38.23 μg/m³ 依次降低至

21.55 μg/m³,达到了最佳效果。根据对特征泛化模块的分析可知,通过不同尺度的特征泛化使网络学习过程中的样本随机分布增强,自适应学习了更多不同分布的数据样本,网络在数据层面的增强获得了极大拓展,性能越来越好,消融实验结果证明了该理论的正确性。

表 3 消融实验结果

Table 3 Results of ablation experiment

模型网络	RMSE ↓	R-square ↑
EfficientNet-B0 (无气象)	55.31	0.651
EfficientNet-B0 (气象)	38.23	0.817
EfficientNet-B0+FG-1(气象)	27.23	0.849
EfficientNet-B0+FG-2(气象)	26.97	0.854
EfficientNet-B0+FG-3(气象)	26.43	0.861
EfficientNet-B0+FG-4(气象)	25.56	0.869
EfficientNet-B0+FG-5(气象)	24.37	0.877
EfficientNet-B0+FG-6(气象)	22.73	0.899
本文方法(气象)	21.55	0.923

4 测试及应用验证

为了验证本文提出的检测算法在实际应用中的效果,采用本文设计的空气质量检测系统在河南省郑州市进行了测试。在不同空气污染程度的情况下,采用高清摄像机拍摄 8 个不同地理位置的大气环境可见光图像,同时使用专业的传感器(品牌为 Kestrel,型号为 NK3000)测量得到的空气温度、湿度、风速、气压和光强等信息,并采用专业的 PM_{2.5} 激光测量仪(品牌为聚一搏,型号为 JYB-6A)测量 PM_{2.5} 浓度,即空气 PM_{2.5} 浓度的真实值,从中随机选取 8 个可视化检测样本及对应的 PM_{2.5} 浓度进行展示,如图 5 所示。

然后分别采用 Inception-V3、ResNet50 和 ResNet50+Weather 三种性能较好的算法与本文提出的检测算法对这 8 幅图像进行检测,记录每张图像在不同检测算法下得到的 PM_{2.5} 浓度值,并与真实值进行对比,得到的检测结果如表 4 所示。

由表 4 的结果可看出,虽然 Inception-V3、ResNet50 和 ResNet50+Weather 和本文提出的检测算法均能检测出不同污染程度的 PM_{2.5} 数值,但 Inception-V3、ResNet50 和 ResNet50+Weather 的检测精度明显偏低,Inception-V3 检测的最大误差达到了 20.5%,平均误差为 13.8%,ResNet50 检测的最大误差达到了 19.3%,平均误差为 13.3%,ResNet50+Weather 检测的最大误差达到了 18.2%,平均误差为 11.5%。而本文提出的检测算法的最大误差仅为 7.6%,平均误差也仅为 5.2%,说明本文提出的融合多源信息及图像特征泛化的空气质量检测算法对检测网络性能提升具有明显的作用,充分保证了算法的检测

精度和稳定性,达到了设计的预期,能够适应各类极端大气污染的空气质量检测任务。



图 5 可视化检测样本
Fig. 5 Visual detection sample

表 4 不同检测算法下的 $PM_{2.5}$ 结果

图像	真实值	$(\mu\text{g}/\text{m}^3)$			
		Inception-V3	ResNet50	ResNet50 + W	本文方法
图 5(a)	13.0	12.0	14.6	11.5	12.8
图 5(b)	28.0	22.7	30.2	25.2	26.2
图 5(c)	62.0	69.1	71.7	68.4	57.8
图 5(d)	85.0	80.7	91.5	92.0	89.5
图 5(e)	119.0	136.7	138.4	108.8	120.7
图 5(f)	167.0	139.4	199.2	184.2	156.8
图 5(g)	228.0	262.9	198.1	186.4	217.4
图 5(h)	508.0	403.7	600.3	584.9	542.9

5 结 论

为了提高空气 $PM_{2.5}$ 浓度检测的便捷性和准确性,提出了一种融合多源信息及图像特征泛化的空气质量检测方法,采用 EfficientDet-D0 为主干网络对大气图像特征进行编码,并通过设计的特征泛化模块对不同尺度的图像特征进行随机增强,最大程度地拓展了数据样本空间,有效提升了网络的泛化能力。同时,结合温度、湿度、风速、气压和光照强度等多源气象信息与图像特征进行融合,找到 $PM_{2.5}$ 浓度与多源信息特征之间的关系,实现了更加准确和可靠的空气质量检测。实验结果表明,本文提出的算法与几种主流的空气质量检测算法相比可以更加准确地检测出空气中 $PM_{2.5}$ 浓度,在测试集上得到的 RMSE 和 R-squared 分别为 $21.55 \mu\text{g}/\text{m}^3$ 和 0.923,消融实验也验证了提出的编码模块、泛化模块和融合模块的有效性和优越

性,对 8 个不同场景中空气 $PM_{2.5}$ 检测的平均误差仅为 5.2%,最大误差也仅为 7.6%,表现出了更高的检测精度、稳定性和运算效率,能够适应各类极端大气污染环境的空气质量检测任务,可以替代传统的专业检测设备进行大规模的部署。

参考文献

[1] 全澍,刘禹函,刘森晗,等. 河南省 2014—2020 年 $PM_{2.5}$ 浓度时空分布特征及气象成因分析[J]. 中国环境监测,2023,39(1):69-80.
QUAN SH, LIU Y H, LIU M H, et al. Spatial and temporal characteristics and correlation analysis of meteorological factors on $PM_{2.5}$ concentration in henan province from 2014 to 2020 [J]. Environmental Monitoring in China, 2023, 39(1):69-80.

[2] 崔雅博,窦小楠,王昆,等. 基于通道剪枝的轻量化空气质量检测方法[J]. 仪表技术与传感器,2024(4):90-94,121.
CUI Y B, DOU X N, WANG K, et al. Lightweight air quality detection method based on channel pruning[J]. Instrument Technique and Sensor, 2024(4):90-94,121.

[3] 朱宗玖,赵艺伟. 基于 SSA-CNN-LSTM 模型的空气质量指数预测[J]. 长春大学学报, 2023, 33(8):1-7.
ZHU Z J, ZHAO Y W. Research of air quality index prediction based on SSA-CNN-LSTM model [J]. Journal of Changchun University, 2023, 33(8):1-7.

[4] 翔云,张凯华,陈作辉,等. 基于视觉的夜间细颗粒物浓度估计[J]. 仪器仪表学报,2024,45(5):33-42.
XIANG Y, ZHANG K H, CHEN Z H, et al. Vision-based night-time fine particulate matter concentration estimation [J]. Chinese Journal of Scientific

- Instrument, 2024, 45(5):33-42.
- [5] 张钰洁,王钰,杨杏丽.融合深度神经网络特征的ARIMAX雾霾PM_{2.5}预测[J].计算机技术与发展,2023,33(2):167-172.
- ZHANG Y J, WANG Y, YANG X L. Haze PM_{2.5} concentration prediction based on ARIMAX model with deep convolutional neural network features[J]. Computer Technology and Development, 2023, 33(2):167-172.
- [6] 段赛男,焦瑞莉,吴成来.一种基于K-means聚类算法的沙尘天气客观识别方法[J].气候与环境研究,2024,29(2):178-192.
- DUAN S N, JIAO R L, WU CH L. Objective identification method for dust weather based on the K-means clustering algorithm [J]. Climatic and Environmental Research, 2024, 29(2):178-192.
- [7] MA J, LI K, HAN Y, et al. Image-based air pollution estimation using hybrid convolutional neural network [C]. International Conference on Pattern Recognition, 2018: 471-476.
- [8] 林涛,吉萌萌,付崇阁,等.基于改进时间卷积网络的空气质量预测研究[J].计算机仿真,2022,39(10):451-456,501.
- LIN T, JI M M, FU CH G, et al. Research on air quality forecasting based on improved temporal convolutional networks [J]. Computer Simulation, 2022, 39(10):451-456, 501.
- [9] 朱菊香,谷卫,任明煜,等.基于SWT-ISSA-LSTM的地铁空气质量预测建模[J].国外电子测量技术,2023,42(7):164-174.
- ZHU J X, GU W, REN M Y, et al. Modeling of subway air quality prediction based on SWT-ISA-LSTM [J]. Foreign Electronic Measurement Technology, 2023,42(7):164-174.
- [10] 毕乐,冯春芳,陈湘国,等.基于多源城市数据的空气质量预测模型[J].计算机工程与设计,2024,45(7):2235-2241.
- BI L, FENG CH F, CHEN X G, et al. Air quality prediction model based on multi-source urban data[J]. Computer Engineering and Design, 2024, 45(7):2235-2241.
- [11] WANG J, BI L, MA X, et al. An efficient YOLOX-based method for photovoltaic cell defect detection[J]. Instrumentation, 2024, 11(2):83-95.
- [12] YEO I, CHOI Y, LOPS Y, et al. Efficient PM_{2.5} forecasting using geographical correlation based on integrated deep learning algorithms [J]. Neural Computing and Applications, 2021, 33(22):15073-15089.
- [13] CHEN Y C, LI D C. Selection of key features for PM_{2.5} prediction using a wavelet model and RBF-LSTM [J]. Applied Intelligence, 2021, 51(4):2534-2555.
- [14] JIANG Z, ZHENG T, BERGIN M, et al. Improving spatial variation of ground-level PM_{2.5} prediction with contrastive learning from satellite imagery[J]. Science of Remote Sensing, 2022, 5: 100052.
- [15] 张羽民,赵俊杰,梅强,等.一种面向细粒度空气质量分指数(IAQI)预测的时空因果卷积模型[J].地球信息科学学报,2023,25(1):115-130.
- ZHANG Y M, ZHAO J J, MEI Q, et al. A spatial-temporal causal convolution model for fine-grained individual air quality index (IAQI) prediction [J]. Journal of Geo-information Science, 2023, 25(1):115-130.
- [16] 薛晨兴,张军,邢家源.基于GoogLeNet Inception V3的迁移学习研究[J].无线电工程,2020,50(2):118-122.
- XUE CH X, ZHANG J, XING J Y. Research on transfer learning based on GoogLeNet inception V3 [J]. Radio Engineering, 2020, 50(2):118-122.
- [17] 孙凌宇,李文清,徐英杰,等.基于改进U-Net的水下图像增强算法[J].电子测量技术,2024,47(2):106-113.
- SUN L Y, LI W Q, XU Y J, et al. Underwater image enhancement algorithm based on improved U-Net[J]. Electronic Measurement Technology, 2024, 47(2):106-113.
- [18] 许凤魁,孙士保,贾少勇,等.改进DTW下界约束的Granger多元时序LSTM预测模型[J].计算机应用与软件,2024,41(5):233-239.
- XU F K, SUN SH B, JIA SH Y, et al. Granger multivariate time series lstm prediction model with improved dtw lower bound constraint[J]. Computer Applications and Software, 2024, 41(5):233-239.

作者简介

王晓婷(通信作者),高级工程师,硕士,主要研究方向为计算机软件与人工智能。

E-mail:xtking82@126.com

崔雅博,副教授,硕士,主要研究方向为智能算法与计算机应用。

E-mail:cyabob@126.com