

DOI: 10.13205/j.hjgc.202504010

梁常德, 尹民, 胡清, 等. 人工智能技术在大气环境领域的应用[J]. 环境工程, 2025, 43(4): 98-109.

LIANG C D, YIN M, HU Q, et al. Applications of artificial intelligence technology in the atmospheric environment field[J]. Environmental Engineering, 2025, 43(4): 98-109.

人工智能技术在大气环境领域的应用

梁常德¹ 尹民¹ 胡清² 游勇¹ 黄芊蕙² 许盛彬^{2*}

(1. 深圳市生态环境智能管控中心, 广东 深圳 518000; 2. 南方科技大学 环境科学与工程学院, 广东 深圳 518000)

摘要:近年来,人工智能技术迅速发展,引起了各领域研究人员的关注,在农业、气候、安全、环境等不同学科领域均取得了丰硕成果。首先对模糊逻辑、遗传算法、人工神经网络、支持向量机、轻量级梯度提升机等人工智能技术的基本原理、技术特征和适用范围进行了总结,重点阐述混合智能系统的技术先进性和优势;其次,以大气环境领域为例,调研了人工智能技术在环境领域的应用进展,借助具体案例说明了常见的输入参数类型和性能评价指标;最后,从环境要素数据集、模型训练方式、算法自有缺陷3个方面分析了现阶段人工智能技术在大气环境领域存在的挑战,提出了人工智能技术在大气环境领域未来的应用发展趋势主要为混合智能系统组合研究、多环境要素综合分析及其与环保平台的协同应用。

关键词:人工智能;大气环境领域;模糊逻辑;遗传算法;人工神经网络

Applications of artificial intelligence technology in the atmospheric environment field

LIANG Changde¹, YIN Min¹, HU Qing², YOU Yong¹, HUANG Qianhui², XU Shengbin^{2*}

(1. Shenzhen Ecological Environment Intelligent Management and Control Center, Shenzhen 518000, China;

2. School of Environmental Science and Engineering, Southern University of Science and Technology, Shenzhen 518000, China)

Abstract: In recent years, the rapid development of artificial intelligence technology has attracted the attention of researchers in most fields, and fruitful achievements have been made in agriculture, climate, security, and the environment. Firstly, the review summarized the basic principles, technical characteristics, and application scope of artificial intelligence technologies such as fuzzy logic, genetic algorithms, artificial neural networks, XGBoost, LightGBM, etc. Moreover, it focused on the technical advancements and advantages of hybrid intelligent systems which combined artificial neural networks and different artificial intelligence technologies. Secondly, taking the field of atmospheric environment as an example, the application progress of artificial intelligence technology in environmental fields was investigated. Especially, by summarizing the common input parameter types and performance evaluation indexes for the prediction of different air pollutants, the prediction applications in the field of atmospheric environment of single artificial intelligence models and hybrid artificial intelligence models were illustrated with specific cases. Generally, artificial model prediction accuracy is affected by various factors, including the input parameters and model types. Compared to single neural network models, hybrid intelligent models have a relatively higher predictive performance. Finally, the challenges of artificial intelligence in the atmospheric environment field

收稿日期: 2024-06-27; 修改日期: 2024-08-22; 接收日期: 2024-10-22

基金项目: 国家重点研发计划“区块链边缘计算原型系统设计和应用开发”(2023YFB2704604); 深圳市国家智能社会治理实验特色基地(环境治理)项目(SZDL2023001177)

第一作者: 梁常德(1980-), 男, 硕士, 高级工程师, 主要研究方向为生态环境大数据技术与应用。836780343@qq.com

* 通信作者: 许盛彬(1990-), 男, 硕士, 中级工程师, 主要研究方向为生态环境大数据技术与应用。xusb@mail.sustech.edu.cn

were analyzed from environmental element data sets, model training methods, and algorithm defects. In the future, the applications of artificial intelligence technology in the atmospheric environment field should be improved from the following aspects: hybrid intelligent system combinations, comprehensive analysis of complicated environmental elements, and cooperative working with environmental protection platforms.

Keywords: artificial intelligence; atmospheric environmental field; fuzzy logic; genetic algorithm; artificial neural network

0 引言

早在1956年“人工智能”(artificial intelligence, AI)的概念已经被提出^[1],但直到20世纪80年代,AI在计算能力、数据可用性和新算法等方面才得到了跨越式发展。AI主要涵盖模糊逻辑(fuzzy logic, FL)、遗传算法(genetic algorithm, GA)、人工神经网络(artificial neural network, ANN)、支持向量机(support vector machine, SVM)、轻量级梯度提升机(light gradient boosting machine, LightGBM)、极端梯度提升(extreme gradient boosting, XGBoost)、随机森林(random forest, RF)等分支,目前已经广泛应用于农业、气候、安全等各学科^[2-6]。由于目前全球环境问题日益突出,环境污染治理往往需要结合大量环境数据监测分析、仿真预测、系统建模等工作,传统的依靠人力监测、监管、治理环境问题的方法和技术手段已难以满足当前的环境保护需求^[7]。在这种情况下,AI能够快速处理复杂数据集,有效解决复杂、难以定义的技术问题,辅助优化资源管理、实施环境决策。同时,人工智能技术具有自我学习能力,可以通过训练以适应新的环境问题,不断泛化^[8],为高效解决社会广泛关注的环境污染问题提供了新的研究方向。在解决现实问题中,在面临具有非线性、多源性、相互关联性等特性的环境数据时,多元线性回归(multiple linear regression, MLR)、响应面方法(response surface methodology, RSM)等数学统计模型存在影响参数难以完全涵盖、输出结果存在偏差等问题,相比之下,AI在环境领域的应用具有更好的表现,包括更好的拟合优度、鲁棒性和预测能力^[9-11],因此将人工智能技术应用到环境领域具有现实需求。人工智能技术在环境领域的应用正日益广泛且不断深入,特别是在大气环境领域,有关AI技术应用发展已达到了较高的成熟度。因此,本文将以大气环境领域为例,介绍人工智能技术在环境领域的应用情况。

本文对人工智能技术在大气环境领域的发展、


具体领域应用进行梳理,涉及部分典型案例,提出了现阶段人工智能技术在大气环境领域面临的挑战和未来发展趋势,以期为进一步拓展人工智能技术在环境领域的应用提供支持。

1 人工智能技术简介

人工智能技术在环境领域的应用最早可以追溯到1978年。Beck等^[12]尝试将FL应用于污水处理,选取英国诺里奇污水处理厂的现场监测数据对硝化模型进行了识别和验证,但由于实验数据质量较低,在BOD和SS去除率的预测方面未取得预期效果。到20世纪80年代,随着反向传播网络多层感知器(multilayer perceptron, MLP)、递归神经网络(recursive neural network, RNN)、径向基函数神经网络(radial basis function network, RBFN)等新的人工智能技术相继提出,更多研究学者尝试在大气环境领域进行人工智能应用探索^[13]。基于应用的人工智能技术种类与数量,人工智能技术可分为2类方法(单一方法和混合方法)^[14,15],在大气环境领域中广泛应用的人工智能技术分类树如图1所示。其中,以MLP、RNN、RBFN、卷积神经网络(convolutional neural network, CNN)、长短期记忆网络(long short-term memory, LSTM)等^[16-19]为代表的ANN被认为是主流的人工智能技术,这些技术在水^[20]、空气^[21]、土壤^[22]、噪声^[23]等环境要素领域均取得了重要进展。此外,除了单一模型外,研究人员也会选择模糊神经网络(fuzzy neural network, FNN)、基于自适应网络的模糊推理系统(adaptive neuro fuzzy inference system, ANFIS)、混合人工神经网络(ANN-ANN)等混合智能系统解决更多环境领域实际问题,混合智能系统能够克服单一人工智能方法的局限性,实现协同优势。

1.1 单一技术

表1介绍了几种典型单一技术的基本原理及特性,这些技术对解决大气环境领域中较为复杂的、非线性问题表现出良好的泛化能力。



注:GA-ANN为遗传算法与人工神经网络;ES-ANN为专家系统与人工神经网络;ANN-ANN为由2种或以上ANN技术组合的混合人工神经网络系统;PSO-ANN为粒子群优化神经网络;GRU为循环神经网络。

图1 大气环境领域的人工智能分类树

Figure 1 A classification tree of AI for atmospheric environmental fields

表 1 不同人工智能技术简介

Table 1 Introduction to different AI technologies

类型	机制	优势	短板
MLP	各层神经元全连接,无层内连接,无跨层连接	非线性映射、有利于并行运算	泛化能力差、处理多维数据能力差
RBFN	只有1个隐藏层,具有局部映射的特征	具有极快的学习收敛速度,具有最佳逼近性能和全局最优特性	解释性差,数据不充分时无法工作,难以确定隐藏层节点数、节点中心和宽度
RNN	隐藏层节点输出取决于当前节点输入和上个节点值,实现层内神经元连接和循环	提取时序特征能力强、泛化能力相对较好,适合解决时间依赖性问题 ^[24]	输入输出序列不同、处理长期依赖精度下降,存在梯度爆炸和梯度消失问题 ^[25]
LSTM	RNN的改良体,细胞状态,只有少量线性交互	在序列建模问题上有一定的优势,具有长时记忆功能	并行处理存在劣势,训练时间较长,效率较低,处理小规模数据效果不理想
CNN	神经元之间局部连接,卷积核特征提取 ^[26]	稀疏连接、权值共享、计算量小、无需复杂的预处理 ^[26]	输入图像尺寸固定
SVM	基于结构化风险最小化原则,用二次元求解支持向量	高鲁棒性、全局搜索能力,所需数据量小,过拟合概率小 ^[27]	大数据集效率低 ^[28] ,批量运行时内存及CPU需求量大
GA	模拟了生物进化论中的自然选择和遗传机制	具有良好的全局优化能力,与其他模型方法结合较灵活 ^[28]	计算量大 ^[28] ,在达到理想效果前需要多次试错
FL	一种类似于人类推理的推理方法,涉及YES和NO之间的所有中间可能性	鲁棒性强,较强的容错能力,构建任意复杂性的非线性函数的能力 ^[29]	精度较低,难定义控制目标 ^[28]
XGBoost	基于预排序方法的决策树算法	支持并行计算,准确精度较高 ^[30] ,可扩展性高 ^[31] ,可进行缺失值处理	内存空间消耗大
LightGBM	弱分类器(决策树)迭代训练,利用网络通信算法来优化并行学习	逐叶树木生长式算法,训练时间短,支持高效并行处理,内存消耗少 ^[32]	可能发生过拟合

1.1.1 ANN

ANN是一种模仿人脑神经网络的计算系统,通常由2个或多个神经元组成,具有大规模并行分布式结构和学习、泛化能力等特性,极适合用于寻找复杂问题的近似解。ANN由若干个称为神经元的互连非线性处理单元组成,如图2所示,这些单元通常排列在网络的3个部分中:表示输入参数的输入层、1个或多个隐藏层以及表示目标参数的输出层^[33]。ANN在捕获复杂系统中变量(多模量输入/输出)之间存在的

非线性关系方面具有良好的求和、自学习和训练函数,目前已得到了广泛应用^[34-37]。

不同类型ANN主要区别于网络架构和用于确定输入和神经元(训练)权重及函数的方法^[38]。MLP是一种最基本的ANN算法,这种前馈神经网络是函数逼近和分类应用的最常用的神经网络,在大气环境领域常用于基于简单参数的环境预测,例如Shams等^[39]利用MLP预测德黑兰空气中SO₂浓度。RBFN是一种特殊的使用非线性分类器的前馈神经网络,目




图2 不同神经网络结构特征

Figure 2 Structural characteristics of different ANNs

前常用于非线性函数逼近、时间序列分析等,例如Li等^[40]借助RBFN模拟和预测地下水位,因其简单的拓扑结构及显化方式,有效解决了识别非线性模型结构的难题。CNN也是基于MLP的前馈神经网络^[41],但使用卷积层进行特征提取,它的结构包括特征提取、映射和子采样,使其特别适用于分类任务,例如Vahdatpour等^[42]将天空的原始图像作为输入馈送到CNN进行分类,在大气污染方面达到约59.38%的准确度。与前馈神经网络不同,RNN至少有一个反馈回路^[43],它将隐藏层的输出反馈给自身,使用隐藏层节点存储来自先前序列的信息,使其适用于时间预测、解决时间依赖性问题。Li等^[44]研究表明,相较于MLP、支持向量回归(SVR),RNN模型具有更高的稳定性和准确性,但由于该网络内复杂的信号移动,其训练过程比前馈网络更具挑战性。LSTM是一种具有学习长期依赖关系能力的RNN,在一定程度上缓解了RNN的长期依赖问题,解决了RNN的梯度消失问题^[45],但由于LSTM本身模型结构相对复杂,导致处理效率相对较低。Zhang等^[46]采用LSTM模型估算了从100 hPa到地表低平流层、对流层的臭氧浓度,结果表明,基于LSTM的训练模块能够比较稳定地捕捉到大气臭氧分布的变化。为提高预测准度,Moniz等^[47]提出嵌套LSTM(NLSTM)神经网络,Jin等^[48]利用多任务多通道NLSTM网络进行多元AQI数据预测,结果表明,该方法在拟合性能和预测误差方面均优于同类方法。

1.1.2 SVM

SVM是机器学习中的一种二元线性分类技术^[49],它将边界线实例(称为支持向量)之间具有最大间隙(称为最佳边距)的类分开。对于非线性可分数据问题,SVM已经使用内核进行了扩展,其内核是将数据从给定空间(称为输入空间)转换到新的高维空间(称为特征空间)的数学函数,其中数据可以用线性表面(称为超平面)分离,使得SVM能够高效解决非线性问题。SVM是常见的数据挖掘算法,因较好的稳健性和准确性被广泛应用^[50]。迄今为止,SVM已被广泛用于各种场景的数据分析,例如回归、分类和非线性函数逼近问题,如Leong等^[51]引入SVM预测了马来西亚霹雳州和檳城州的空气污染指数(API)。

1.1.3 GA

GA是一种受自然遗传系统中生物进化原理启发的随机一般搜索技术,常被用于解决优化问题。该方法的一般优化策略是生成一个有表示的随机解的群体,然后应用选择、交叉和突变遗传算子来生成一个新的和更好的群体。GA易与其他人工智能技术结合应用^[28],一般情况下,将GA嵌入到ANN中,以更新初始权值、隐藏层的阈值和输出层,以克服局部最小值问题。GA-ANN常被用于空气污染预测等,例如Grivas等^[52]建立GA-MLP模型,通过输入风速、环境温度、降雨量等参数,对空气PM₁₀浓度进行预测,研究表明该预测方法所需变量更少、计算时间更短。Huang等^[53]研究表明,GA能够生成模糊规则,并优化

模糊集的隶属度函数,从而更高效地实现全局搜索功能。

1.1.4 FL

FL是相较于传统的逻辑系统而言的。不同于传统逻辑中的非黑即白,FL允许存在0~1之间的其他情况,也就是灰色地带,但其边界(或者说临界条件)是模糊的。近年来,模糊逻辑在评价中得到了越来越多的关注,常用的模糊综合评价法是模糊理论在评价中的初步应用,主要通过隶属度函数处理不确定性问题,以模仿人脑思维方式进行规则推理的能力较弱。而模糊逻辑一方面通过隶属度函数、模糊推理、去模糊化等方法,能够更好地处理非线性、主观性问题;另一方面,通过科学设置模糊推理的控制规则,可以反映评价指标间的影响关系。目前,FL常见于不同指标的评价研究,例如Riyaz等^[54]构建了基于模糊逻辑的智能模型进行印度城市地区的AQI预测。

1.1.5 XGBoost

XGBoost模型是一种可扩展的树提升机器学习系统。有别于传统GBDT算法一阶泰勒展开与人工填充缺失值的处理策略,XGBoost模型通过对损失函数进行二阶泰勒展开近似、自动处理数据中的缺失值从而进一步处理最小化目标函数。此外,XGBoost算法开发的决策树还可以通过正则化过程防止过度拟合,从而提高模型的泛化能力^[31]。目前,XGBoost已被广泛应用于大气颗粒物浓度预测^[55,56]、AQI预测^[57]、臭氧浓度预测^[58]等方面。

1.1.6 LightGBM

LightGBM是一种基于Boosting思想的算法模型,使用决策树作为学习算法的基分类器。LightGBM引入了基于梯度的单侧采样(gradient-based one-side sampling, GOSS)和独占特征捆绑(exclusive feature bundling, EFB)^[59]两种先进技术,通过合理减少数据实例和特征的数量来优化模型计算^[60]。由于其出色的计算、预测能力,LightGBM被广泛应用于许多大气污染治理工作,例如地面SO₂浓度预测^[61]、空气污染颗粒物(PM_{2.5}、PM₁₀)浓度监测^[62]、大气污染物空间分布模拟^[63]等方面。

1.2 混合智能系统

混合智能系统是在解决现实中复杂问题的过程中,为了克服单一技术的缺陷,使用多种智能技术以实现更高运行效率、推理能力的技术。1991年,AI领域的著名专家Minsky提出,研究混合智能系统是非常有必要的^[64],尤其是随着FL、GA等技术的不断发展,混合智能系统的研究进入蓬勃发展时期。但总的来说,相较于单一技术,混合智能系统的发展还处于起步阶段,在大气环境领域的发展需要更多的研究者从不同角度提出新的应用思路。目前,对于一些多目标优化控制问题,GA、ANN和FL的结合被认为是一种强大的集成过程建模和优化的方法^[53],例如Fan等^[14]指出,在对不同污染物去除效率评估方面,相较于单一算法模型,GA-ANN具有较高的相关系数(R^2)值,能够提供更准确的预测值。表2介绍了几种典型的混合人工智能系统的基本机制及技术组合优势。

表2 不同混合人工智能系统简介

Table 2 Introduction to different AI technologies

类型	机制	组合优势	文献
FNN	模糊逻辑理论、遗传算法、神经网络之间的协同协作	扩大处理范围(可处理定量和定性信息),提高信息处理速度	[65]
ES-ANN	融合ANN与ES系统	响应速度快、抗干扰、知识自动化获取能力及解释能力较强	[66,67]
ANFIS	基于ANN和FL的数据驱动建模技术,输入与输出映射通过基于网络形式的模糊规则连接	灵活性、处理速度和适应能力得到优化	[68-71]
PSO-ANN	包括内外两层,外层为PSO算法,内层为ANN网络,实现协同搜索计算	克服了局部最小值问题	[72]
GA-ANN	将GA与神经网络结合以迭代优化神经网络参数	网络配置得到优化,预测效率、灵活性及稳定性较高	[73]

2 人工智能技术在大气环境领域的实际应用

大气作为重要的环境要素之一,其污染问题与人类健康密切相关,亟需结合有效治理手段进行管控。目前在大气环境治理领域,人工智能技术主要

用于空气污染预测^[74],通过人工智能技术构建不同适用场景的空气质量模型,实现对单一大气污染物或混合污染物的污染预测。在大气环境领域,人工智能技术的主要环境预测指标包括空气污染指数

(API)、 $\text{PM}_{2.5}$ 、 PM_{10} 、 NO_x 和 SO_2 等常见污染指标^[75,76]。与经典统计学模型相比,人工智能算法能够在高维空间中对非线性函数进行回归近似,轻松处理多输入变量^[8],具有处理速度快、高精度、高容错性等优点^[29]。人工智能算法在空气污染预测方面的建模流程见图3^[29]。




图3 人工智能算法在空气污染预测中的建模流程^[29]

Figure 3 Modeling process flowchart for AI in air pollution forecasting^[29]

在单一人工智能模型预测应用方面,Cakir等^[77]通过构建前馈ANN模型实现了对 NO_2 、 O_3 和 PM_{10} 浓度的预测,并与MLR线性方法的预测能力进行比较。研究表明,MLR方法在预测 O_3 浓度方面拥有更好的预测性能。在两种模型的季节性表现方面,夏季和冬季的MLR方法与ANN模型性能无显著差异,但在春季,ANN模型的RMSE值明显更低。在预测 PM_{10} 浓度方面,ANN拥有更好的 PM_{10} 预测能力。但在 NO_2 浓度预测方面,两种模型的预测准确性之间无显著差异。为进一步提升ANN预测性能,研究者建议需对输入数据进行预处理、并为每个季节单独开发用于预测大气污染的ANN模型^[77]。Turias等^[78]分别评估了基于反向传播神经网络(BPNN)、整合移动平均自我回归模型(ARIMA)与MLR的预测模型在预测工业区 CO 、 SO_2 和悬浮颗粒物(SPM)浓度方面的性能,结果表明基于BPNN的模型具备更强的泛化能力。Lin

等^[79]通过构建基于应用策略的LSTM模型,有效提高了短期 $\text{PM}_{2.5}$ 浓度预测精度,尤其是针对高浓度范围的 $\text{PM}_{2.5}$ 预测。大气环境预测评价往往需要对较长时间的监测数据进行分析,因此以MLP为代表的擅长处理时序数列的模型往往会出现运行效率低、参数设置复杂等问题^[80],相比之下,LSTM等在大气环境领域具有更好的表现^[81,82]。

在混合人工智能模型预测应用方面,Yildirim等^[83]结合ANFIS模型评估气象参数对城市地区 SO_2 浓度及总悬浮颗粒物(TSP)浓度的影响,结果表明,通过输入历史污染物浓度、气象参数等,ANFIS模型对 SO_2 和TSP浓度的预测准确率分别达到75%~90%及69%~80%,该模型可以有效预测空气质量水平。在另一项研究中,Ghasemi等^[84]结合应用前向选择(FS)技术对ANFIS模型进行优化,同时通过系列实验探究潜在变量之间的多重共线性效应,有效提升了混合智能模型对 PM_{10} 、 SO_2 、 NO_2 、 CO 、 O_3 等空气污染物的预测性能。Unnikrishnan等^[85]通过使用时间序列ANN模型,结合输入污染物参数、气象参数和时间参数,对工业区内 SO_2 浓度进行模拟预测。在这项研究中,所有研究模型模拟结果的MSE值都接近0, R^2 值接近1,预测表现最佳的模型的MSE值为0.0115, R^2 值为0.8979,研究表明ANN模型可以有效预测大气污染物浓度,尤其是针对一次空气污染物的预测。研究者建议在使用ANN模型预测二次空气污染物浓度时,需结合其他反应机制和附加参数要求进行研究^[85]。其次,优化输入参数的相关方法及增加考虑气象参数等参数影响都有助于优化模型预测结果,未来混合ANN模型对预测 SO_2 浓度的研究可以深入探究模型输入与输出参数之间的关联机制。Ragab等^[86]采用基于CNN和指数自适应梯度(EAG)优化的深度学习模型对马来西亚巴生市未来空气污染指数(API)进行预测,该模型以指数方式累计历史梯度信息,以自适应调整参数学习率,有效提高了模型收敛性和泛化性能。在这项研究中,优化模型的主要性能评估指标平均绝对误差(MAE)、均方根误差(RMSE)、平均绝对百分比误差(MAPE)和相关系数(R -Squared)值分别为2.036、2.354、4.214和0.966,结果表明经过结合优化,与原基准模型相比,优化模型在整体预测性能、时间复杂度和一致性方面均得到了提升^[85]。

一般来说,模型预测准确度与模型的输入参数、模型类型的选择有关,混合模型的预测性能优于单一

神经网络模型^[87]。在实际污染预测应用中,不同人工智能技术的预测效果可能因不同模型学习算法、网络架构、输入数据质量而异。有研究表明,所有大气污染物冬季的浓度预测值要比夏季预测更加准确^[88],遗憾的是目前更深层次的原因尚未有定论,但这也为人工智能技术在大气环境领域的应用研究提供了一个方向。

3 人工智能技术在大气环境领域的挑战与发展趋势

3.1 人工智能技术在大气环境领域面临的挑战

对人工智能技术在不同大气环境要素领域中的应用进行梳理发现,人工智能技术在大气环境领域具有很好的潜力,同时不可避免会面临一些挑战。从现有人工智能技术的固有特点和在大气环境领域的应用成效(表3)来看,可能存在的风险主要包括3个方面:

表 3 人工智能技术在大气环境领域的应用

Table 3 Applications of AI technology in the atmospheric environment field

年份	类型	研究对象	输入参数	输出参数	性能评价指标	文献
2009	GA	空气污染预测	PM ₁₀ 样本数据	PM ₁₀	RMSE	[89]
2012	MLP、RBFN、GRNN	城市空气质量	气温、相对湿度、风速、空气质量监测数据	可吸入颗粒物、SO ₂ 、NO ₂	RMSE、MAE	[90]
2016	ANFIS	空气质量预测	气压、温度、湿度、能见度、露点、风速、降水等	SO ₂ 、NO ₂ 、CO、O ₃ 、PM ₁₀ 等	R ² 、NMRS等	[91]
2016	MLP	空气中CO浓度	温度、风速、湿度、CO、水分	CO浓度	MAE、R ²	[92]
2018	ARIMAX-MLP	PM _{2.5} 预测	温度范围、湿度范围、日照时长、风速、风向、NO ₂ 、SO ₂ 、O ₃ 、CO、PM _{2.5} 等	PM _{2.5}	RMSE、MAE、MAPE	[93]
2019	RNN、RF	空气污染物预测	气象学变量(温度、温度露点差、相对湿度、降水、风速、风向、大气压力和城市热岛)、大气污染物	污染物浓度	R、RSEM	[94]
2020	CNN	预测马来西亚巴生市空气污染指数	PM ₁₀ 、CO、O ₃ 、NO ₂ 、SO ₂ 等	API	MAE、RMSE、MAPE、R ²	[86]
2020	MLP	O ₃ 预测	温度、湿度、风速、风向、O ₃ 等	O ₃ 浓度	R ² 、MAE、RMSE	[95]
2020	CNN-LSTM	PM _{2.5} 短期预测	气温、风速、风向、气压、累计降雨量等气象因素	PM _{2.5}	RMSE、MAE、MAPE	[96]
2021	MLP、LSTM	空气质量评估和污染预测	PM ₁₀ 、温度、相对湿度、风速、风向	未来某段时间空气质量	MAE、MSE、MAPE	[97]
2021	LSTM	大气不同污染物相关性分析	O ₃ 、温度、NO _x 、光合有效辐射等	异戊二烯和PM ₁₀ 预测	—	[98]
2022	FL	城市空气质量决策支持	PM ₁₀ 污染水平和大气稳定性信息	不同领域空气质量评价	—	[99]
2024	基于应用策略的LSTM(ASLSTM)	PM _{2.5} 短期预测	PM _{2.5} 、O ₃ 、PM ₁₀ 、CO、SO ₂ 、NO、相对湿度、风速、风向、气温	污染物浓度	RMSE、MAE	[79]

1)尚未构建环境要素数据集,输入数据质量难把握。目前越来越多的复杂模型被开发设计用于不同环境要素领域,需要用于分析的数据量越来越大,但对模型输入的数据质量、输入方式却没有统一的评价标准。现有应用研究的环境数据集来源种类较多,基础数据多源于研究团队自行监测、政府部门或各行业的数据库,且数据集的格式、时间跨度、时效性情况也存在较大差异,导致不同研究模型的基础数据集质量良莠不齐。例如,在大气环境治理领域,采集到的大气污染物、气象等大量基础数据往往种类较多,且可能来源于不同空间的监测平台,人工智能算法必须有效地处理如此大规模的多源异构数

据,以便进行准确的预测和分析。同时,目前鲜有相关研究报道如何评估这些数据集的质量,环境要素数据准确归集难度仍然较大。因此,未来模型应用如何选取高质量的数据集、如何对数据进行有效预处理并进一步优化输入参数过程亟需更进一步的研究。

2)模型训练方式需要优化。虽然人工智能技术具有优越的学习和预测能力,但环境领域的治理应用往往涉及多学科、多方面的复杂相互作用,基于大量、准确参数数据集的模型优化训练过程也相当重要。针对同一种人工智能技术采用不同的训练模式,可能输出完全不同的结果。并且由于智能技术

复杂的网络结构和大量的数据样本,人工智能模型训练过程相当缓慢,这导致由训练过程引起的人工智能模型过拟合并降低预测性能也是需要研究解决的关键问题。例如,在大气环境领域,针对不同空气污染物浓度的监测和预测精确度往往会因为气象条件变化、污染源排放变化等因素的影响而产生时间与空间变异性,在训练人工智能算法进行空气质量评估与污染物浓度模拟预测时必须充分考虑这些变化因素,结合实际需求优化模型训练方式。对于人工智能技术而言,模型训练方法通常分为监督学习(适合MLP、RF、SVM、CNN等技术)、无监督学习(适合自动编码器、Kohonen网络、Hopfield神经网络等技术)、半监督学习(适合RNN、LSTM等技术)及混合学习(集成多种神经网络架构)等。针对不同环境领域的不同应用需求,需要研究选择针对性的训练模式,保障模型的精度和效率。

3)人工智能技术自有缺陷不容忽视。①单一技术可解释性不足。部分人工智能技术往往只能提供低级决策,无法兼顾全局和局部可解释性,导致智能模型应用的准确性和可解释性不足。但环境领域是一项学科交叉同时专业性很强的门类,在实践应用时往往需要整合当地相关法律标准、治理政策等实际情况,这对人工智能模型的透明性和可解释性提出了很高的要求。尤其是在实际监管阶段,执法人员会参考人工智能技术的结果进行检查,可解释性的缺乏会降低受监管对象对检查结果的信任度。②公平性不足。大气环境领域涵盖范围极广,人工智能技术会挖掘数据之间的关联,拟合数据分布特性。结合人工智能技术的环境管理决策可能对社会经济和环境质量产生重大影响,当基于人类的训练集数据存在偏见与歧视时,人工智能算法将会产生“类人”的认知规律,从而导致训练出的模型出现算法歧视问题,无法完全保证决策公平性。③数据安全性不足。人工智能技术在环境领域的大规模应用在一定程度上推动了公共和私人领域的融合和重叠,如在环境监测过程中,城市噪声监测的音视频数据收集与分析可能涉及市民个人隐私问题。随着由人工智能驱动的环境监测分析技术的普及应用,个人及企业相关隐私信息、环境监测数据等大量存储数据存在信息泄露风险,如何充分尊重主体隐私权、合规使用监测数据、防止敏感信息泄露和滥用仍需进一步研究。

3.2 人工智能技术在大气环境领域的发展趋势

人工智能技术在大气环境领域的研究需要以应用需求为导向,综合考虑人工智能技术的优势和相关环境领域的发展现状,人工智能技术在大气环境领域可能具有以下发展趋势:

1)倾向于混合智能系统的组合研究。这是由于在大气环境领域,混合智能系统能够结合不同单一算法的技术优势,有效解决智能模型应用过程中环境要素参数设置复杂、难以收敛、结果解释不清等问题,从而在复杂的计算环境中实现更高的准确性。未来研究应基于实际需求,比较不同模型之间的优劣,通过尝试将多种人工智能技术组合,提高人工智能实际应用的精度和效率,尤其是在环境要素污染预测及溯源方面。

2)更关注多环境要素的综合分析。随着“山水林田湖草一体化管理”“陆海统筹”等概念的提出,环境要素综合研究成为重要方向,但现有人工智能技术在大气环境领域的关注焦点主要是单一环境因素,对多环境要素一体化的监测分析和模拟预测研究较少。未来大气环境领域应用研究过程中,人工智能技术可以从具体的单一环境要素向模糊化的、适用范围更广的多环境要素协同领域拓展,例如大气污染沉降带来的水体污染预测等,最终实现环境综合智能化治理。

3)更加注重与环保平台的协同应用。随着社会现代化水平的不断提高,国内外不少环境监管机构搭建了生态环境智能化平台,平台属于基础数据庞大、涵盖各环境业务领域的高度集中系统。因此,人工智能技术环境治理领域未来发展应用过程中,可以基于已有智能化平台的数据资源,以及监测分析、模拟预测等子系统,与算法工程师、环境领域专家通过子系统进行协同探索,从数据集、算法模型优化等方面不断提升模型的精度和效率。

4 结束语

人工智能技术在大气环境领域的技术应用已趋成熟,本文以大气环境领域应用为例,综述了典型单一和混合人工智能技术在环境领域的应用现状与最新进展,证明了人工智能技术在大气环境领域中有广泛的应用前景。后续研究应从以下方面继续深化:

1)人工智能技术在实际应用中仍存在数据质量难把握、模型优化训练方式待优化、智能技术存在自

有缺陷等潜在风险。为规范人工智能技术应用,未来研究应结合大气环境领域的实际业务需求,考虑在规范环境要素数据集、优化模型训练模式、提升人工智能技术应用的可解释性、决策公平性与数据安全性等方面进一步展开研究,降低人工智能技术自身特性带来的负面影响。

2) 基于人工智能技术优势与环境领域发展现状,人工智能技术在大气环境领域的研究未来可能倾向于组合研究混合智能系统,同时更注重针对多环境要素的综合分析及与环保平台的协同应用,从而实现在大气环境领域的进一步探索和更深层次应用。

参考文献

- [1] 林作铨. 约翰·麦卡锡小传[J]. 计算机科学, 1993(4): 32-33
LIN Z Q. A short biography of John McCarthy [J]. Computer Science, 1993(4): 32-33
- [2] CHAMBERS D M R C M, THORNBURG L G, et al. Distinguishing petroleum (crude oil and fuel) from smoke exposure within populations based on the relative blood levels of benzene, toluene, ethylbenzene, and xylenes (BTEX), styrene and 2, 5-dimethylfuran by pattern recognition using artificial neural networks[J]. Environment Science Technology, 2018, 625 (5): 75-88.
- [3] HONG H, TSANGARATOS P, ILIA I, et al. Application of fuzzy weight of evidence and data mining techniques in construction of flood susceptibility map of Poyang County, China[J]. Science of the Total Environment, 2018, 625: 575-588.
- [4] LESNIK K L, LIU H. Predicting microbial fuel cell biofilm communities and bioreactor performance using artificial neural networks[J]. Environmental Science & Technology, 2017, 51 (18): 10881-10892.
- [5] NABAVI P A, RAFIEE S, MOHTASEBI S S, et al. Integration of artificial intelligence methods and life cycle assessment to predict energy output and environmental impacts of paddy production[J]. Science of the Total Environment, 2018, 631: 1279-1294.
- [6] ZHANG R, CHEN Z Y, XU L J, et al. Meteorological drought forecasting based on a statistical model with machine learning techniques in Shaanxi province, China[J]. Science of the Total Environment, 2019, 665: 338-346.
- [7] 马思远. 浅谈人工智能在环境工程中的应用[J]. 科学与信息化, 2020.
MA S Y. An introduction to the application of artificial intelligence in environmental engineering [J]. Science and Informatization, 2020.
- [8] PALANI S, TKALICH P, BALASUBRAMANIAN R, et al. ANN application for prediction of atmospheric nitrogen deposition to aquatic ecosystems[J]. Marine Pollution Bulletin, 2011, 62(6): 1198-1206.
- [9] CSÁBRÁGI A, MOLNÁR S, TANOS P, et al. Estimation of dissolved oxygen in riverine ecosystems: comparison of differently optimized neural networks [J]. Ecological Engineering, 2019, 138: 298-309.
- [10] FAROOQ M U, ZAFAR A M, RAHEEM W, et al. Assessment of algorithm performance on predicting total dissolved solids using artificial neural network and multiple linear regression for the groundwater data[J]. Water, 2022, 14(13): 2002.
- [11] TAOUFIK N, BOUMYA W, ACHAK M, et al. Comparative analysis of response surface methodology and some artificial intelligence models in the prediction of methyl green degradation by Fenton process [J]. International Journal of Environmental Analytical Chemistry, 2021: 1-18.
- [12] BECK M B, LATTEN A, TONG R M. Modelling and operational control of the activated sludge process in wastewater treatment [J]. 1978.
- [13] ENBUTSU I, BABA K, HARA N, et al. Integration of multi AI paradigms for intelligent operation support systems - fuzzy rule extraction from a neural network [J]. Water Science and Technology, 1993, 28(11-12): 333-340.
- [14] FAN M, HU J, CAO R, et al. A review on experimental design for pollutants removal in water treatment with the aid of artificial intelligence[J]. Chemosphere, 2018, 200: 330-343.
- [15] ZHAO L, DAI T, QIAO Z, et al. Application of artificial intelligence to wastewater treatment: a bibliometric analysis and systematic review of technology, economy, management, and wastewater reuse [J]. Process Safety and Environmental Protection, 2020, 133: 169-182.
- [16] BOGER Z. Application of neural networks to water and wastewater treatment plant operation[J]. ISA transactions, 1992, 31(1): 25-33.
- [17] SCHLEITER I M, BORCHARDT D, WAGNER R, et al. Modelling water quality, bioindication and population dynamics in lotic ecosystems using neural networks[J]. Ecological Modelling, 1999, 120(2/3): 271-286.
- [18] TRAUTMANN T, DENÈUX T. A constructive algorithm for SOM applied to water quality monitoring [J]. Intelligent Engineering Systems through Artificial Neural Networks, 1994, 4: 17-22.
- [19] WALLEY W, FONTANA V. Neural network predictors of average score per taxon and number of families at unpolluted river sites in Great Britain [J]. Water Research, 1998, 32 (3) : 613-622.
- [20] MAIER H R, DANDY G C. The use of artificial neural networks for the prediction of water quality parameters [J]. Water Resources Research, 1996, 32(4): 1013-1022.
- [21] SOHN S H, OH S C, YEO Y K. Prediction of air pollutants by using an artificial neural network[J]. Korean Journal of Chemical Engineering, 1999, 16(3): 382-387.
- [22] YANG C C, PRASHER S O, MEHUY S G R. An artificial neural

- network to estimate soil temperature[J]. *Canadian Journal of Soil Science*, 1997, 77(3): 421-429.
- [23] 张继萍, 吴硕贤. 人工神经网络在道路交通噪声预测中的应用[J]. *环境科学学报*, 1998(5): 25-31.
- ZHANG J P, WU S X. An application of artificial neural network to traffic noise prediction [J]. *Acta Scientiae Circumstantiae*, 1998(5): 25-31.
- [24] HAYKIN S. *Neural networks and learning machines*, 3/E [M]. Pearson Education India, 2009.
- [25] Pascanu R, Mikolov T, Bengio Y. On the difficulty of training recurrent neural networks [C]// *International Conference on Machine Learning*, PMLR, 2013: 1310-1318.
- [26] 雷健. 人工智能在水环境监测的关键技术研究工程实践[J]. *价值工程*, 2019, 38(22): 5.
- LEI J. Key technology research and engineering practice of artificial intelligence in water environment monitoring[J]. *Value Engineering*, 2019, 38(22): 5.
- [27] KIM K J. Financial time series forecasting using support vector machines[J]. *Neurocomputing*, 2003, 55(1/2): 307-319.
- [28] CHENG Y, BI X, XU Y, et al. Artificial intelligence technologies in bioprocess: opportunities and challenges [J]. *Bioresource Technology*, 2022: 128451.
- [29] MASOOD A, AHMAD K. A review on emerging artificial intelligence (AI) techniques for air pollution forecasting: fundamentals, application and performance [J]. *Journal of Cleaner Production*, 2021, 322: 129072.
- [30] SONG Y, ZHANG C, JIN X, et al. Spatial prediction of PM_{2.5} concentration using hyper-parameter optimization XGBoost model in China [J]. *Environmental Technology & Innovation*, 2023, 32: 103272.
- [31] CHEN T, GUESTRIN C. XGBoost[C]// *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining-KDD, F*, 2016 [C].
- [32] FAN J, MA X, WU L, et al. Light gradient boosting machine: An efficient soft computing model for estimating daily reference evapotranspiration with local and external meteorological data[J]. *Agricultural Water Management*, 2019, 225: 105758.
- [33] ROSENBLATT F. The perceptron: a probabilistic model for information storage and organization (1958) [M]. 2021: 183-190.
- [34] WANG F, CHEN W, NIU L. An improved InVEST ecological service evaluation model based on BP neural network optimization [J]. *Nature Environment and Pollution Technology*, 2020, 19: 991-1000.
- [35] BENEDETTI M, CESAROTTI V, INTRONA V, et al. Energy consumption control automation using artificial neural networks and adaptive algorithms: proposal of a new methodology and case study[J]. *Applied Energy*, 2016, 165: 60-71.
- [36] NIKPEY H, ASSADI M, BREUHAUS P, et al. Experimental evaluation and ANN modeling of a recuperative micro gas turbine burning mixtures of natural gas and biogas[J]. *Applied Energy*, 2014, 117: 30-41.
- [37] CHANNAPATTANA S, PAWAR A A, KAMBLE P G. Optimisation of operating parameters of DI-CI engine fueled with second generation bio-fuel and development of ANN based prediction model[J]. *Applied Energy*, 2017, 187: 84-95.
- [38] CAUDILL M, BUTLER C. *Understanding neural networks 1, basic networks* [Z]. PressMIT, Cambridge, Mass. 1992
- [39] SHAMS S R, JAHANI A, KALANTARY S, et al. The evaluation on artificial neural networks (ANN) and multiple linear regressions (MLR) models for predicting SO₂ concentration [J]. *Urban Climate*, 2021, 37: 100837.
- [40] LI Z, YANG Q, WANG L, et al. Application of RBFN network and GM (1, 1) for groundwater level simulation [J]. *Applied Water Science*, 2017, 7(6): 3345-3353.
- [41] DRAGOVIĆ S. Artificial neural network modeling in environmental radioactivity studies: A review[J]. *Science of the Total Environment*, 2022, 847: 157526.
- [42] VAHDATPOUR M S, SAJEDI H, RAMEZANI F. Air pollution forecasting from sky images with shallow and deep classifiers[J]. *Earth Science Informatics*, 2018, 11(3): 413-422.
- [43] DU J, VONG C M, CHEN C L P. Novel efficient RNN and LSTM-Like architectures: recurrent and gated broad learning systems and their applications for text classification [J]. *IEEE Transactions on Cybernetics*, 2021, 51(3): 1586-1597.
- [44] LI L, JIANG P, XU H, et al. Water quality prediction based on recurrent neural network and improved evidence theory: a case study of Qiantang River, China [J]. *Environmental Science and Pollution Research*, 2019, 26(19): 19879198-96.
- [45] HAQ M A, AHMED A, KHAN I, et al. Analysis of environmental factors using AI and ML methods [J]. *Scientific Reports*, 2022, 12(1): 13267.
- [46] ZHANG X, ZHANG Y, LU X, et al. Estimation of lower-stratosphere-to-troposphere ozone profile using long short-term memory (LSTM)[J]. *Remote Sensing*, 2021, 13(7): 1374.
- [47] MONIZ J R A, KRUEGER D. Nested LSTMS [C]// *Asian Conference on Machine Learning*, PMLR, 2017: 530-544.
- [48] JIN N, ZENG Y, YAN K, et al. Multivariate air quality forecasting with nested long short term memory neural network [J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(12): 8514-8522.
- [49] SAKIZADEH M, MIRZAEI R, GHORBANI H. Support vector machine and artificial neural network to model soil pollution: a case study in Semnan Province, Iran[J]. *Neural Computing and Applications*, 2017, 28(11): 3229-3238.
- [50] CHEN S, GAO C, ZHANG P. Incorporation of data-mined knowledge into black-box SVM for interpretability [J]. *ACM Trans Intell Syst Technol*, 2022, 14(1): 1-22.
- [51] LEONG W C, KELANI R O, AHMAD Z. Prediction of air pollution index (API) using support vector machine (SVM)[J]. *Journal of Environmental Chemical Engineering*, 2020, 8(3): 103208.

- [52] GRIVAS G, CHALOULAKOU A. Artificial neural network models for prediction of PM_{10} hourly concentrations, in the Greater Area of Athens, Greece [J]. *Atmospheric environment*, 2006, 40(7): 121612–121629.
- [53] HUANG M, MA Y, WAN J, et al. A sensor–software based on a genetic algorithm–based neural fuzzy system for modeling and simulating a wastewater treatment process [J]. *Applied Soft Computing*, 2015, 27: 1–10.
- [54] RIYAZ R, PUSHPA P. Air quality prediction in smart cities: a fuzzy–logic based approach; proceedings of the 2018 International Conference on Computational Techniques, electronics and Mechanical Systems (CTEMS), F, 2018 [C]. IEEE.
- [55] 李志生, 梁锡冠, 金字凯, 等. 基于树模型的北京市 $PM_{2.5}$ 预测效果对比分析[J]. *环境工程*, 2021, 39(6): 106–113.
- LI Z S, LIANG X G, JIN Y K, et al. A comparative study on edictive effect of $PM_{2.5}$ in Beijing based on tree models [J]. *Environmental Engineering*, 2021, 39(6): 106–113.
- [56] 黄春桃, 范东平, 卢集富, 等. 基于深度学习模型的广州市大气 $PM_{2.5}$ 和 PM_{10} 浓度预测 [J]. *环境工程*, 2021, 39(12): 135–140.
- HUANG C T, FAN D P, LU J F, et al. Prediction of $PM_{2.5}$ and PM_{10} concentration in Guangzhou based on deep learning model [J]. *Environmental Engineering*, 2021, 39(12): 135–140.
- [57] Jing H, Wang Y. Research on urban air quality prediction based on ensemble learning of XGBoost [C]//E3S Web of Conferences. EDP Sciences, 2020, 165: 02014.
- [58] ZHANG B, ZHANG Y, JIANG X. Feature selection for global tropospheric ozone prediction based on the BO–XGBoost–RFE algorithm [J]. *Scientific Reports*, 2022, 12(1): 9244.
- [59] KE G, MENG Q, FINLEY T, et al. Lightgbm: a highly efficient gradient boosting decision tree [J]. *Advances in neural information processing systems*, 2017, 30.
- [60] ZHANG W, WU C, TANG L, et al. Efficient time–variant reliability analysis of Bazimen landslide in the Three Gorges Reservoir Area using XGBoost and LightGBM algorithms [J]. *Gondwana Research*, 2023, 123: 41–53.
- [61] XU T, CHEN B, REN Y, et al. Estimation of the ground–level SO_2 concentration in eastern China based on the LightGBM model and Himawari–8 TOAR [J]. *Frontiers in Earth Science*, 2023, 10: 1037719.
- [62] JAMEI M, ALI M, MALIK A, et al. Air quality monitoring based on chemical and meteorological drivers: application of a novel data filtering–based hybridized deep learning model [J]. *Journal of Cleaner Production*, 2022, 374: 134011.
- [63] CHI Y, ZHAN Y, WANG K, et al. Spatial distribution of multiple atmospheric pollutants in China from 2015 to 2020 [J]. *Remote Sensing*, 2023, 15(24): 5705.
- [64] MINSKY M. Logical versus analogical or symbolic versus connectionist or neat versus scruffy [J]. *AI Mag*, 1991, 12: 34–51.
- [65] ZENG H, XU Z W. Industrial sewage evaluation based on fuzzy neural network [J]. *Procedia Environmental Sciences*, 2011, 10: 771–776.
- [66] SU H, ZHAO F. A novel substation fault diagnosis approach based on RS and ANN and ES [C]// Proceedings of the 2006 International Conference on Communications, Circuits and Systems, F, 2006, IEEE.
- [67] WEN C H, VASSILIADIS C. Applying hybrid artificial intelligence techniques in wastewater treatment [J]. *Engineering Applications of Artificial Intelligence*, 1998, 11(6): 685–705.
- [68] TIWARI M K, BAJPAI S, DEWANGAN U. Prediction of industrial solid waste with ANFIS model and its comparison with ANN model—a case study of Durg–Bhilai twin city India [J]. *International Journal of Engineering and Innovative Technology (IJEIT)*, 2012, 6(2): 192–201.
- [69] ABBASI M, EL HANANDEH A. Forecasting municipal solid waste generation using artificial intelligence modelling approaches [J]. *Waste management*, 2016, 56: 13–22.
- [70] IRAJI M S, ABOUTALEBI M, SEYEDAGHAEI N R, et al. Students classification with adaptive neuro fuzzy [J]. *International Journal of Modern Education and Computer Science*, 2012, 4(7): 42.
- [71] CHANG L C, CHANG F J. Intelligent control for modelling of real–time reservoir operation [J]. *Hydrological Processes*, 2001, 15(9): 1621–1634.
- [72] MAHMOODI B N, HEYDARI A, NEMATOLLAHZADEH A. Removal of methylene blue via bioinspired catecholamine/starch superadsorbent and the efficiency prediction by response surface methodology and artificial neural network–particle swarm optimization [J]. *Bioresource Technology*, 2019, 294: 122084.
- [73] EJIMOFOR M, EZEMAGU I, MENKITI M. RSM and ANN–GA modeling of colloidal particles removal from paint wastewater via coagulation method using modified Aguleri montmorillonite clay [J]. *Current Research in Green and Sustainable Chemistry*, 2021, 4: 100164.
- [74] CHANG H H, PARK I, OH H R, et al. Development of a $PM_{2.5}$ prediction model using a recurrent neural network algorithm for the Seoul metropolitan area, Republic of Korea [J]. *Atmospheric Environment*, 2021, 245.
- [75] DAI H, HUANG G, ZENG H, et al. $PM_{2.5}$ volatility prediction by XGBoost–MLP based on GARCH models [J]. *Journal of Cleaner Production*, 2022, 356: 131898.
- [76] ALLAMSETTY S, MOHAPATRO S. Feasibility of artificial neural networks and fuzzy logic models for prediction of NO_x concentrations in nonthermal plasma–treated diesel exhaust [J]. *IEEE Transactions on Plasma Science*, 2019, 47(5): 2637–2644.
- [77] CAKIR S, SITA M. Evaluating the performance of ANN in predicting the concentrations of ambient air pollutants in Nicosia [J]. *Atmospheric Pollution Research*, 2020, 11(12): 2327–2334.
- [78] TURIAS I J, GONZÁLEZ F J, MARTIN M L, et al. Prediction

- models of CO, SPM and SO₂ concentrations in the Campo de Gibraltar Region, Spain: a multiple comparison strategy [J]. Environmental monitoring and assessment, 2008, 143: 131–146.
- [79] LIN M D, LIU P Y, HUANG C W, et al. The application of strategy based on LSTM for the short-term prediction of PM_{2.5} in city[J]. Science of the Total Environment, 2024, 906: 167892.
- [80] WANG G, GUO L, DONG X, et al. Artificial neural network prediction of air pollutants in Shenzhen city[J]. Chinese Journal of Environmental Engineering, 2015, 9(7): 3393–3399.
- [81] OSOWSKI S. Prediction of air pollution using LSTM [C]// Advances in Computational Intelligence: 16th International Work-Conference on Artificial Neural Networks, IWANN 2021, Proceedings, Part II 16. Springer International Publishing, 2021: 208–219.
- [82] SIWEK K, OSOWSKI S. Data mining methods for prediction of air pollution [J]. International Journal of Applied Mathematics and Computer Science, 2016, 26(2).
- [83] YILDIRIM Y, BAYRAMOGLU M. Adaptive neuro-fuzzy based modelling for prediction of air pollution daily levels in city of Zonguldak[J]. Chemosphere, 2006, 63(9): 1575–1582.
- [84] Ghasemi A, Amanollahi J. Integration of ANFIS model and forward selection method for air quality forecasting [J]. Air Quality, Atmosphere & Health, 2019, 12: 59–72.
- [85] UNNIKRISHNAN R, MADHU G. Comparative study on the effects of meteorological and pollutant parameters on ANN modelling for prediction of SO₂[J]. SN Applied Sciences, 2019, 1: 1–12.
- [86] RAGAB M G, ABDULKADIR S J, AZIZ N, et al. A novel one-dimensional CNN with exponential adaptive gradients for air pollution index prediction [J]. Sustainability, 2020, 12(23): 10090.
- [87] LIU H, WU H, LV X, et al. An intelligent hybrid model for air pollutant concentrations forecasting: a case of Beijing in China [J]. Sustainable Cities and Society, 2019, 47: 101471.
- [88] ŞAHİN Ü A, BAYAT C, UÇAN O N. Application of cellular neural network (CNN) to the prediction of missing air pollutant data[J]. Atmospheric Research, 2011, 101(1): 314–326.
- [89] SHAD R, MESGARI M S, ABKAR A, et al. Predicting air pollution using fuzzy genetic linear membership kriging in GIS [J]. Computers, Environment and Urban Systems, 2009, 33(6): 472–481.
- [90] SINGH K, GUPTA S, KUMAR A, et al. Linear and nonlinear modeling approaches for urban air quality prediction [J]. The Science of the Total Environment, 2012, 426: 244–255.
- [91] PRASAD K, GORAI A K, GOYAL P. Development of ANFIS models for air quality forecasting and input optimization for reducing the computational cost and time [J]. Atmospheric Environment, 2016, 128: 246–262.
- [92] ASADOLLAHFARDI G, MEHDINEJAD M, PAM M, et al. Predicting carbon monoxide concentrations in the air of Pardis City, Iran, using an artificial neural network [J]. Environmental Quality Management, 2016, 26(1): 37–49.
- [93] KALATE A I, SALARI M, SHADMAN A. Statistical models for multi-step-ahead forecasting of fine particulate matter in urban areas [J]. Atmospheric Pollution Research, 2019, 10(3): 689–700.
- [94] FENG R, ZHENG H J, GAO H, et al. Recurrent Neural Network and random forest for analysis and accurate forecast of atmospheric pollutants: a case study in Hangzhou, China [J]. Journal of Cleaner Production, 2019, 231: 1005–1015.
- [95] ALJANABI M, SHKOUKANI M, HIJJAWI M. Ground-level ozone prediction using machine learning techniques: a case study in Amman, Jordan [J]. International Journal of Automation and Computing, 2020, 17(5): 667–677.
- [96] SUN Q, ZHU Y, CHEN X, et al. A hybrid deep learning model with multi-source data for PM_{2.5} concentration forecast [J]. Air Quality, Atmosphere & Health, 2021, 14(4): 503–513.
- [97] CORDOVA C H, PORTOCARRERO M N L, SALAS R, et al. Air quality assessment and pollution forecasting using artificial neural networks in Metropolitan Lima-Peru [J]. Scientific Reports, 2021, 11(1): 24232.
- [98] LYU J, YIN S, SHANG C, et al. Sensitivity analysis of isoprene and aerosol emission in a suburban plantation using long short-term memory model [J]. Urban Forestry & Urban Greening, 2021, 64: 127303.
- [99] BRAZÁLEZ E, MACIÀ H, DÍAZ G, et al. FUME: an air quality decision support system for cities based on CEP technology and fuzzy logic [J]. Applied Soft Computing, 2022: 109536.