

曾穗平, 赵茜雅, 田健. 基于智能算法的大气污染防治知识图谱: 研究方法、演化路径与应用展望[J]. 灾害学, 2022, 37(1): 120–128. [ZENG Suiping, ZHAO Xiya and TIAN Jian. Knowledge Graph of Air Pollution Control Based on Intelligent Algorithms: Research Methods, Evolution Paths and Application Prospects[J]. Journal of Catastrophology, 2022, 37(1): 120–128. doi: 10.3969/j.issn.1000-811X.2022.01.021.]

# 基于智能算法的大气污染防治知识图谱: 研究方法、演化路径与应用展望\*

曾穗平<sup>1</sup>, 赵茜雅<sup>1</sup>, 田健<sup>2,3</sup>

(1. 天津城建大学 建筑学院, 天津 300384; 2. 天津市城市规划设计研究总院有限公司, 天津 300190;  
3. 天津大学 建筑学院, 天津 300072)

**摘要:**大气污染防治是保障人民健康与生命安全重要的研究课题, 智能算法是大气污染防治及预测预警的重要工具手段。通过 Citespace 对 Web of Science 核心数据库中 1998—2021 年智能算法在大气污染防治中应用的文献进行可视化分析。结果表明: ①智能算法在大气污染防治应用历经“数理统计—遥感监测—数字模拟—神经网络算法”四个阶段; ②研究主题集聚为“神经网络模型”“智慧健康检测系统”和“城市空间的大气污染”三个核心聚类演变路径; ③应用方式包括“大气污染时空分布”“大气污染因素相关性”“大气污染事件预测”“空气质量优劣评估”与“健康韧性城市应用”五个方面。未来智能算法在大气污染防治中的应用趋势, 将体现“高精度预测—全周期评估—健康化理念”的特点。

**关键词:** 智能算法; 大气污染防治; 知识图谱; 空间布局; 控污物理环境

**中图分类号:** X43; X915.5; X831 **文献标志码:** A **文章编号:** 1000-811X(2022)01-0120-09

doi: 10.3969/j.issn.1000-811X.2022.01.021

大气污染防治是保障人民健康与生命安全重要的研究课题。伴随着人工智能时代的来临, 智能算法为大气污染防治和健康城市建设提供了新的研究方法。目前, 研究大气污染防治机理的方法经历了“数值模型—遥感监测—数字模拟—神经网络模型”四个阶段<sup>[1]</sup>。传统的统计方法、有限回归模型方法, 已无法满足大气污染防治高效、全面与精准实时的新要求, 因此, 通过梳理智能算法在大气污染防治方面的应用方法, 进一步探索该算法的应用前景, 为我国国土空间规划背景下生态和健康城市的建设提供理论支撑。

## 1 大气污染防治的传统模拟预测方法及当代智能演进

### 1.1 大气污染防治及其模拟预测的传统技术方法

传统的大气污染防治及其模拟预测方法包括: 统计分析地面观测站数据, 通过统计分析和模拟预测未来的发展趋势, 技术方法包括: 地面监测或卫星遥感监测, 或利用空气质量模型(CMAQ)、自回

归移动平均(ARMA)模型等数字模型模拟分析, 其存在问题是研究的空间精度较差, 仅聚焦于城市大、中尺度<sup>[2]</sup>, 同时, 表现出数据模型预测精度不高, 对海量数据处理能力有限的特点(表1)。

### 1.2 基于智能算法的大气污染防治技术的当代应用

为了应对上述研究方法的不足, 智能算法在大气污染防治中的应用得到充分的重视, 其当代应用经历了“预测模拟—评估测算—城市体检”三个阶段(图1), 并呈现出“单一向复合”神经网络算法转化的特征(表2)。通过从海量数据中提取出复杂的非线性规律, 在高粒度实时分析中确定多因素影响中各自权重<sup>[2]</sup>, 它弥补了传统方法中对动态、非线性和多因素研究的不足。目前, 基于时间序列的智能算法有长短期记忆(LSTM)网络、递归神经网络(RNN)、和门控递归单元(GRU)网络; 适用于空间特征提取的体系结构的有卷积神经网络(CNN)和深度信念网络(DBN)等模型<sup>[2]</sup>; 在城市规划领域, 智能算法多用于预测大气污染的时空分布状况, 并结合人口密度等多种影响因素评估并指导健康与韧性城市的建设。

\* 收稿日期: 2021-05-24 修回日期: 2021-09-30

基金项目: 国家自然科学基金项目(52078320; 51708387); 教育部人文社科基金(17YJCZH013)

第一作者简介: 曾穗平(1987-), 女, 汉族, 广东平远人, 博士后, 副教授, 硕士生导师, 主要从城市物理环境优化方面的研究。

E-mail: 176116126@qq.com

通讯作者: 田健(1986-), 男, 汉族, 河北孟村人, 博士, 高级规划师, 硕士生导师, 主要从事城乡规划、城市设计方面的研究。

E-mail: 693339189@qq.com

表1 大气污染防控传统技术方法的优缺点分析

| 方法                             | 研究尺度   | 原理                            | 公式  | 公式说明  | 特点   | 应用  |
|--------------------------------|--------|-------------------------------|---|---|--|---|
| 地面监测                           | 城市街区   | 基于定电位电解传感器原理                  | $I_k = \frac{\rho_k - \rho_{k,j}}{\rho_{k,j+1} - \rho_{k,j}} (I_{K,j+1} - I_{K,j}) + I_{K,j}$   | $I_k$ 为污染物的分指数  | 优势：对特定区域监测准确。<br>局限性：空间覆盖范围有限，成本高。           | ①观测天气；<br>②观测气候；<br>③动态实时监测污染浓度。                    |
| 空气质量模型(CMAQ) <sup>[3]</sup>    | 区域城市街区 | 应用梯度输送理论、统计理论和相似理论对空气质量进行仿真模拟 | $\frac{\partial c}{\partial t} = -\nabla(Uc) + \nabla(K\nabla c) + R + S$   | $C$ 为污染物浓度， $U$ 为风速， $K$ 为扩散系数， $R$ 为化学反应， $S$ 为污染物的源和汇   | 优势：解析大气污染物输送及化学反应机制。<br>局限性：模拟结果可比性差。        | ①模拟大气污染物迁移扩散；<br>②环境影响评价；<br>③解析大气污染物成因来源。          |
| 自回归移动平均(ARMA)模型 <sup>[4]</sup> | 区域     | 借助时间序列的随机性描述平稳序列的相关信息         | $y_t - \mu = \varphi_1(y_{t-1} - \mu) + \varphi_2(y_{t-2} - \mu) + \cdots + \varphi_p(y_{t-p} - \mu) + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \cdots - \theta_q e_{t-q}$ | $y$ 是变量， $\varphi_i$ 和 $\theta_j$ 分别是自回归和移动平均参数的第 $i$ 阶和第 $j$ 阶， $\mu$ 是平均值， $e_t$ 是白噪声项                        | 优势：短期预测效果好，适用性强。<br>局限性：必须满足平稳性要求。           | ①预测不同时间序列中的API趋势；<br>②预测疾病发病率；<br>③预测污染物浓度。         |
| 多元线性回归(MLR)模型 <sup>[5]</sup>   | 区域城市   | 分析多个变量共同影响一个变量                | $y = \beta_0 + \sum_{k=1}^9 \beta_k x_k + \varepsilon$  | $y$ 为因变量， $(x_1, \cdots, x_k)$ 是自变量， $\beta_k$ 是回归系数， $\varepsilon$ 是随机误差                                       | 优势：拟合效果好。<br>局限性：较好效果需要较长训练时间。               | ①建立AQI定量预测模型；<br>②探究大气污染物与气象变量之间的关系；<br>③短期预测颗粒物浓度。 |
| 地理加权回归(GWR)模型 <sup>[6]</sup>   | 区域     | 运用邻近区域信息对局部回归参数进行估计           | $y_i = \beta_0(u_i, v_i) + \varepsilon_i + \sum_{j=1}^k \beta_j(u_i, v_i) x_{ij}$   | $y_i$ 是因变量， $i$ 表示研究区域内的城市，驱动因素用 $x_{ij}$ 表示， $\beta_j$ 是估计系数， $(u_i, v_i)$ 是观察 $i$ 的位置， $\varepsilon_i$ 是随机误差项 | 优势：分析空间关系的空间特征。<br>局限性：时间维度异质性分析差。           | ①污染物浓度的空间变化；<br>②影响因素的空间异质性分析；<br>③研究土地利用程度。        |
| 卫星遥感监测 <sup>[7]</sup>          | 区域城市   | 气溶胶光学厚度(AOD)是气溶胶消光系数在垂直方向上的积分 | $AOD = \int_0^{\infty} \sigma_{a,0} \cdot e^{-\frac{z}{H}} dz = \sigma_{a,0} \cdot H$   | $Z$ 代表垂直高度， $\sigma_{a,0}$ 是 $0.55 \mu\text{m}$ 时的表面气溶胶消光系数， $H$ 代表气溶胶尺度高度                                      | 优势：高空间分辨率，覆盖范围广，低成本。<br>局限性：需要通过反演得到污染物浓度数值。 | ①探究大气颗粒物的时空分布；<br>②探究大气颗粒物的演变特征；<br>③监测预警森林火灾。      |

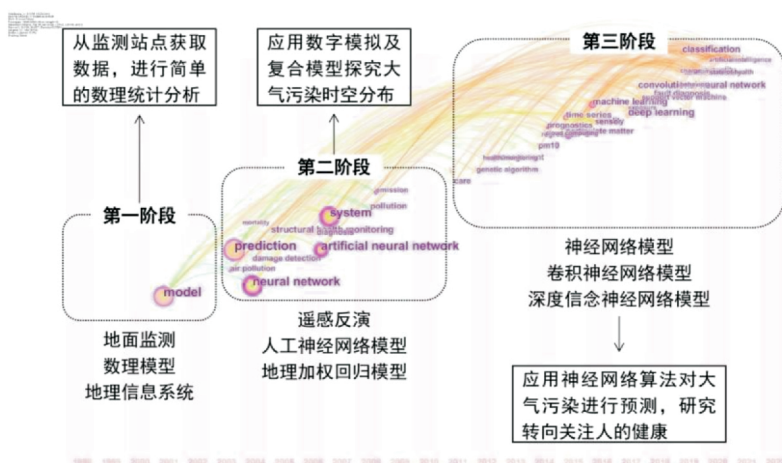
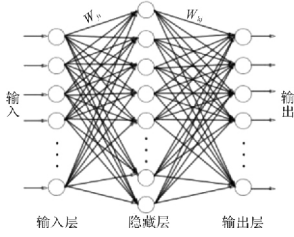
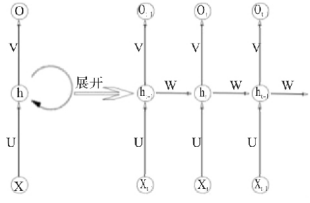
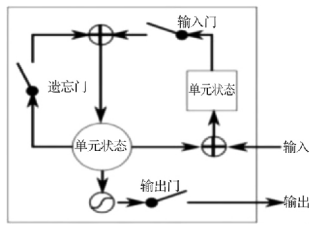
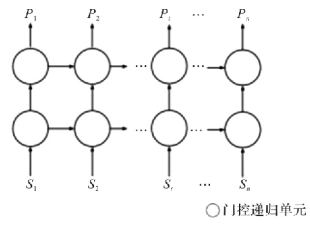
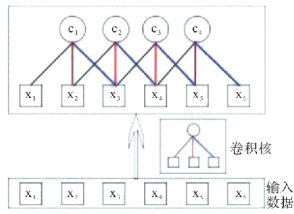
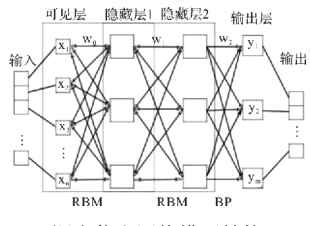


图1 智能算法在大气污染防控研究领域的关键词时空演化图

表 2 大气污染防控的单一神经网络算法的类型分析

| 方法                                | 研究尺度     | 原理   | 结构关系   | 特点  | 应用领域   |
|-----------------------------------|----------|--|--|---|--|
| 人工神经网络 (ANN) <sup>[8]</sup>       | 城市       | 由输入层接收数据信息, 隐藏层通过动态权重以及复杂函数对数据进行处理, 并通过输出层输出隐藏层处理后的数据          |  <p>人工神经网络结构示意图</p>             | <p>优势: 拟合复杂非线性关系; 自学习复杂系统。</p> <p>局限性: 收敛速度慢; 出现局部最小值。数据样本宜小。</p>           | <p>①预测大气污染物浓度;</p> <p>②解析大气污染源;</p> <p>③预测大气污染影响下的患病风险。</p>          |
| 递归神经网络 (RNN) <sup>[9]</sup>       | 区域       | 不同时间序列上的数据作为输入值的人工神经元依次输入各隐藏层单元, 输入值的来源通常是上一隐藏层的输出值            |  <p>递归神经网络结构示意图</p>             | <p>优势: 有效建立时间维度的模型。</p> <p>局限性: 易出现梯度消散问题; 仅适用于短期记忆。数据样本具有时间序列特点。</p>       | <p>①动态监测空气质量;</p> <p>②分类预测空气质量;</p> <p>③实时预测交通流量。</p>                |
| 长短期记忆神经网络 (LSTM) <sup>[10]</sup>  | 区域       | 通过单元状态传递信息, 且“输入门”、“遗忘门”和“输出门”决定序列数据在 Sigmoid 函数运算中丢弃或保留       |  <p>长短期记忆神经网络 (LSTM) 结构示意图</p> | <p>优势: 有利于解决长期依赖问题; 避免梯度消失和梯度爆炸。</p> <p>局限性: 输入数据具有重叠性。数据样本具有多变量、长期性特点。</p> | <p>①预测污染风险;</p> <p>②交通流、风力预测;</p> <p>③解析大气污染与产业发展以及经济等多种因素之间的关系。</p> |
| 门控递归单元 (GRU) 神经网络 <sup>[11]</sup> | 区域、城市、街区 | 通过隐藏状态来传输信息, 利用“更新门”和“重置门”决定丢弃或新增信息, 输出由激活函数 Sigmoid 的全连接层计算得到 |  <p>门控递归单元的网络结构</p>           | <p>优势: 模型简单; 训练速度快。</p> <p>局限性: 不可并行计算, 计算成本高。数据样本具有长时间跨度特点。</p>            | <p>①预测长期空气质量变化趋势;</p> <p>②预测短期风速;</p> <p>③预测大气污染物浓度。</p>             |
| 卷积神经网络 (CNN) <sup>[12]</sup>      | 城市       | 利用反向传播算法训练隐藏层的单元权重, 并在卷积层中实现卷积核权值共享, 实现特征缩聚, 最后进行输出            |  <p>卷积神经网络模型结构</p>            | <p>优势: 具有较好鲁棒性和容错能力, 训练速度快。</p> <p>局限性: 输入数据维数需一致。数据样本较少, 提取样本的浅层特征值。</p>   | <p>①预测大气污染物的浓度;</p> <p>②监测诊断故障;</p> <p>③监测人群密度。</p>                  |
| 深度信念网络 (DBN) <sup>[13]</sup>      | 区域       | 通过输入的训练数据求得每层 RBM 的权值, 接着通过 BP 算法反向传播网络进行求解                    |  <p>深度信念网络模型结构</p>            | <p>优势: 实现在线实时计算, 深度特征提取。</p> <p>局限性: 输入数据是一维数据。数据样本的空间特性预测能力强。</p>          | <p>①监测并探究大地理区域的空气污染时空特征;</p> <p>②预测交通流;</p> <p>③预测大气污染物浓度。</p>       |

## 2 智能算法在大气污染防控研究中的演化路径分析

### 2.1 数据来源及研究方法

研究以“人工智能 + 污染防控”为主题, 选取时间段为2000—2021年, 在Web of Science中采用检索式用“TI = ((intelligent OR neural network) AND (air pollution OR air Pollution Forecasting OR spatial distribution OR air quality OR health OR space influence factor))”, 将检索到的995篇文献, 用Citespace进行知识图谱的可视化分析, 解析智能算法在大气污染防控研究中的演变路径, 推演未来发展趋势。

### 2.2 研究阶段及研究技术的演化图谱

将智能算法在污染防控方面的关键词进行聚类分析, 大致可以将研究历程分为三个阶段(见图1)。具体表现为: 第一阶段为基于地面站点与数理统计的污染监测、第二阶段为结合遥感影响与数字模拟的污染监测、第三阶段为基于人工智能算法的技术手段导入。

第一阶段存在监测站点稀疏、成本高, 观测结果精度较差的特征, 难以承担对功能区或街区等层面的污染观测, 也无法实现大尺度区域时空范围的测量; 第二阶段运用卫星遥感观测大气污染的时空分布问题<sup>[14]</sup>。例如, 使用气溶胶光学厚度(AOD)、气象数据和土地利用的卫星观测数

据, 并应用线性混合效应模型、广义加性模型等数学模型分析卫星遥感数据, 以研究大气污染的时空分布规律<sup>[15]</sup>。这些技术弥补了监测站点覆盖范围不足的缺陷, 积累了长周期大气污染的时空演变数据, 为认识区域尺度大气污染传输规律及联防联控的策略提供了技术支持; 第三阶段依托人工智能算法引入, 科学确定出气象、地形、社会和经济等多因素影响的权重, 为提出精准治理方法提供了技术支持。如应用地理和时间加权回归模型, 实现高精度探究大气污染物构成组分<sup>[16]</sup>, 采用多元线性回归和地理加权回归(GWR)模型, 以及非线性主成分分析地理加权回归法(NLPCA - GWR)和非线性主成分分析地理时间加权回归法(NLPCA - GTWR)的应用, 对污染物浓度进行了相对精准的时空分布预测<sup>[17-18]</sup>。同时, 从关注“物”向“人”过渡, 结合人群暴露度的大小, 分区、分级提出污染防控策略, 进而为健康城市的建设, 提供科学的精准指导, 形成了“全方位 + 多尺度 + 量化”的研究体系(图2)。

### 2.3 演化路径与关键研究问题分析

从大气污染防控研究的Citespace的关键词共现时间轴图谱可以看出, 该研究领域形成了神经网络、数据驱动的损伤识别框架、智能云计算、城市空间的空气污染、智能健康监测系统7个聚类(图3)。由于篇幅所限, 本文重点分析“神经网络模型”、“城市空间的空气污染”以及“智慧健康监测系统”3个核心聚类的演进内容。

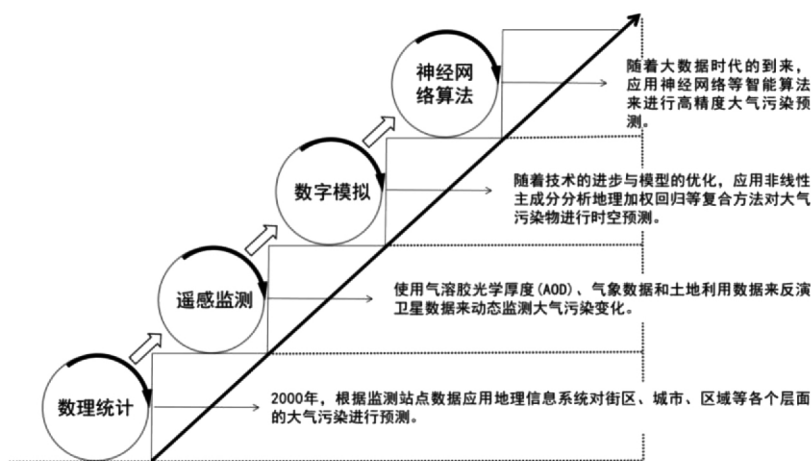


图2 大气污染防控技术转型升级

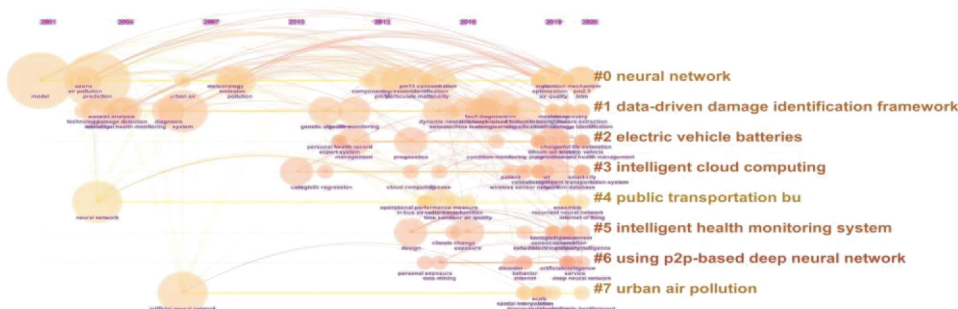


图3 关键词共现时间轴图谱



### 2.3.1 方法演进：以“神经网络模型”为聚类研究路径分析

该路径以“人工神经网络-长短期记忆神经网络-深度信念神经网络-复合神经网络”关键词为演进主线。从“时间-空间-时空”3个维度对变量进行预测模拟，神经网络模型具有“数据处理效率高+变化趋势预测准+影响因素涵盖广”的特征。例如，时间维度上，CHANG-HOI, H<sup>[19]</sup>等人应用递归神经网络模型与空气质量模型(RNN-CMAQ)相结合的混合模型，预测韩国首尔市区的PM<sub>2.5</sub>浓度，提升了季节性浓度预测精度；空间维度上，ASLI Bozda<sup>[20]</sup>等人通过机器学习算法，预测安卡拉地区PM<sub>10</sub>浓度空间分布特征，制定土地利用规划策略；时空维度上，LUO Yi<sup>[21]</sup>等人应用反向传播人工神经网络(BPANN)和e-支持向量回归混合模型，探索了京津冀、长三角和珠三角等区域的PM<sub>2.5</sub>时空特征，得到区域污染物浓度下降，内陆城市多为PM<sub>2.5</sub>热点区域的结论。综上，神经网络模型方法逐步由单一神经网络模型，向复合神经网络模型演变，进而提高了预测精度。

### 2.3.2 空间聚焦：以“城市空间大气污染”为聚类的路径分析

该路径以“工业城市-城市建成区-城市中心区”为空间演进线索。研究热点从工业城市逐步向城市建成区和城市中心区扩展，形成了“城市空间与空气污染”的研究聚类，其关注点集中在与城市形态、城市结构与人群暴露度的评估等方面。例如，具有“监测-报警-响应”功能的工业物联网智能污染监控系统提高了污染防治的效率<sup>[22]</sup>；香港则采用耦合城市形态与污染物排放等多源数据为一体的PRESS-HK系统，评估实时状况、预测街区层面的空气质量及评估人群的污染暴露度的关系<sup>[23]</sup>，并应用GIS技术，研究城市休闲场所的污染物时空分布规律，为环境公正提供理论支撑<sup>[24]</sup>。

### 2.3.3 健康导向：以“智慧健康监测系统”为聚类的路径分析

该路径以“颗粒物构成-暴露度-影响因素-韧性健康”为空间演进线索。随着健康中国战略的提出，学者关注到环境-规划-医学的多学科的融合，研究范围拓展到探索影响健康的因素与大

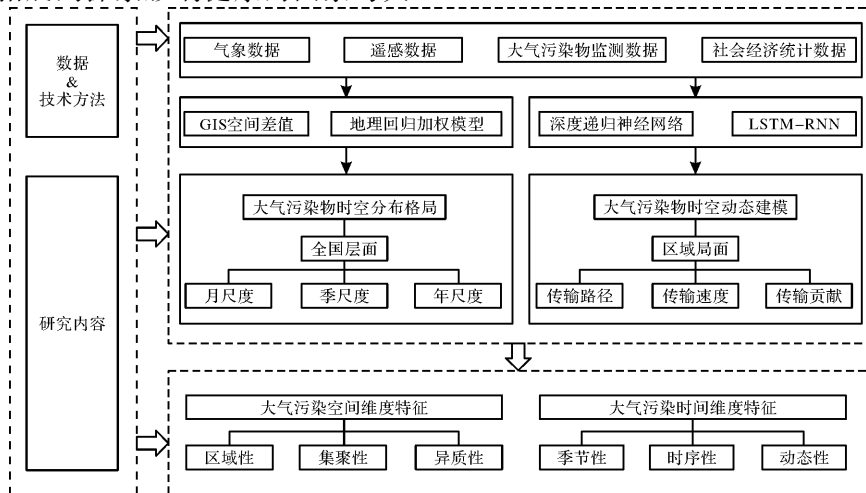
气污染之间的作用机制，探索污染物暴露水平与人类患病概率之间的关系，并着眼于韧性健康规划策略的相关研究。例如，规划学家应用遥感、GIS和智能算法等技术手段，对大气污染浓度人群患病概率等进行研究，得到大气污染物与相关因素之间的非线性关系，进而将其应用到功能布局优化及开发强度控制等方面。目前，该聚类对大气污染的研究逐步向“以人为本+健康韧性+提升幸福感”等方面转变。

## 3 智能算法在大气污染防控的应用方式

目前，智能算法在大气污染防控的应用方式贯穿于大气污染防控的“前一中一后”三个阶段，即贯穿前期的大气污染时空分布特征和污染影响因素、中期的大气污染评估预测研究和后期的健康城市规划的全过程。

### 3.1 时空融合：大气污染多尺度分布的特征研究

智能算法在大气污染时空分布特征应用，集中在探究大气污染物的时空变化分布规律，依托气象、遥感、大气污染物浓度及社会经济数据，采用深度递归神经网络<sup>[25]</sup>、长短期记忆神经网络-递归神经网络(LSTM-RNN)<sup>[25]</sup>方法，在区域、城市、街区等环境，研究大气污染物的不同时空尺度的分布特征，探索其传输路径、速度和各要素的贡献度。研究表明：大气污染物在空间维度具有“区域性+集聚性+异质性”的特征，在时间维度具有“季节性+时序性+动态性”的特征；同时，污染物的空间分布与用地布局具有强相关性，工业用地、绿地布局与污染物浓度的正或负相关的关系密切<sup>[26]</sup>。例如，ANA Russo等<sup>[27]</sup>对葡萄牙里斯本市的大气污染事件的研究中，构建了基于神经网络短期时间预测和空间随机模拟相结合的方法，将污染物的时空不确定性进行概率的量化。YOUSIF Alyousifi等<sup>[28]</sup>使用马尔可夫链模型，证实了马来西亚半岛空气污染的区域关联性和空间依赖性。图4为智能算法在大气污染时空分布特征方面研究的技术流程框图。



### 3.2 要素耦合: 大气污染影响因素的相关性分析

智能算法在大气污染防控的影响因素研究方面, 依托气象数据、大气污染监测数据、社会经济统计数据等多源数据进行多元线性回归和空间自相关分析, 并通过构建空间杜宾模型和 RBF 神经网络模型等智慧方法, 从自然<sup>[29]</sup>和社会<sup>[30]</sup>两个维度, 探索大气污染的作用机理以及异质性规律, 并得出大气污染的影响机理具有“综合性+复杂性+动态性+区域性”特征的结论。例如, CHAN Kit Yan 等<sup>[31]</sup>应用基于知识发现系统的神经网络算法, 得出风速与交通流量是影响 PM<sub>2.5</sub> 浓度的重要因素的结论; SHAO Jingjing 等<sup>[30]</sup>以河北省为研究对象, 应用耦合理论和空间回归分析方法, 发现了土地利用强度、土地投入水平和土地利用结构与 PM<sub>2.5</sub> 浓度呈正相关、土地产出效益与 PM<sub>2.5</sub> 浓度呈负相关的规律。图 5 是神经网络算法在大气污染相关因素研究的技术流程框图。

### 3.3 情景模拟: 大气污染事件的预测特征研究

大气污染预测是国土空间规划的重要组成部分, 一些学者基于气象数据、AOD 数据和土地利用等数据, 运用 BP 神经网络模型<sup>[32]</sup>、灰色关联度分析<sup>[33]</sup>、反向传播神经网络模型<sup>[34]</sup>、空气动力学

模型<sup>[35]</sup>、深度递归神经网络模型与长短期记忆神经网络模型<sup>[36]</sup>等方法, 对不同时空尺度的大气污染物浓度、扩散机理极端事件及社会影响等进行研究。如 GUO Qingchun 等<sup>[37]</sup>以西安和兰州两个城市为研究对象, 综合人工神经网络的非线性映射和小波变换的技术方法, 得出了基于多尺度分析的加权神经网络模型的预测性能明显更优的结论。目前, 大气污染预测的相关研究多具有“大时空范围+多尺度研究+多情景预测”的特征, 但对大气污染全过程监测、高精度的研究相对比较缺乏。图 6 是智能算法在大气污染预测方面研究的技术流程框图。

### 3.4 定量多维: 城市空气质量优劣的评估研究

智能算法在大气污染防控评估方面, 通常依托可拓神经网络模型、决策树<sup>[38]</sup>等方法, 从空气质量指数、污染持续时长、首要污染物三个维度对空气质量进行评估; 同时, 应用模糊数学综合评价法<sup>[39]</sup>、多元回归模型<sup>[40]</sup>等方法, 通过探究污染物浓度、影响范围等内容, 评估污染防治效果; 此外, 也经常采用人工神经网络模型<sup>[41]</sup>、随机森林<sup>[42]</sup>等方法, 对大气污染风险进行定量多维的评估。例如, OLVERA Garcia 等<sup>[43]</sup>应用加权模

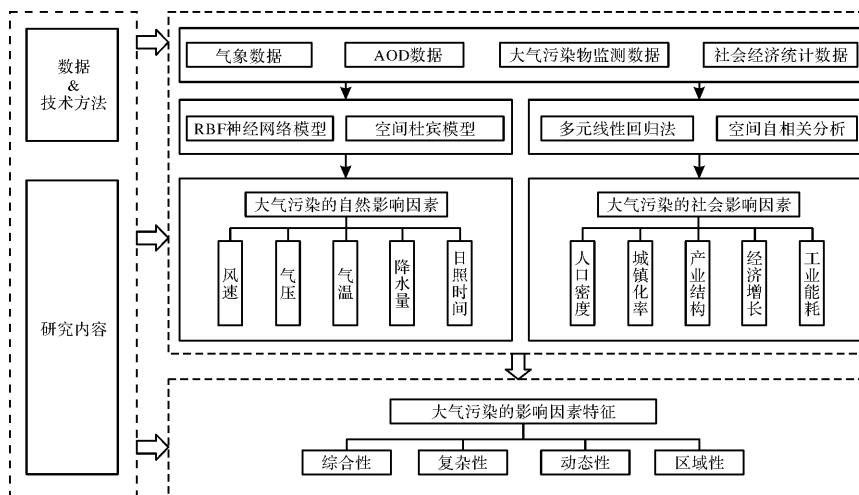


图5 智能算法在大气污染相关因素研究的技术流程框图

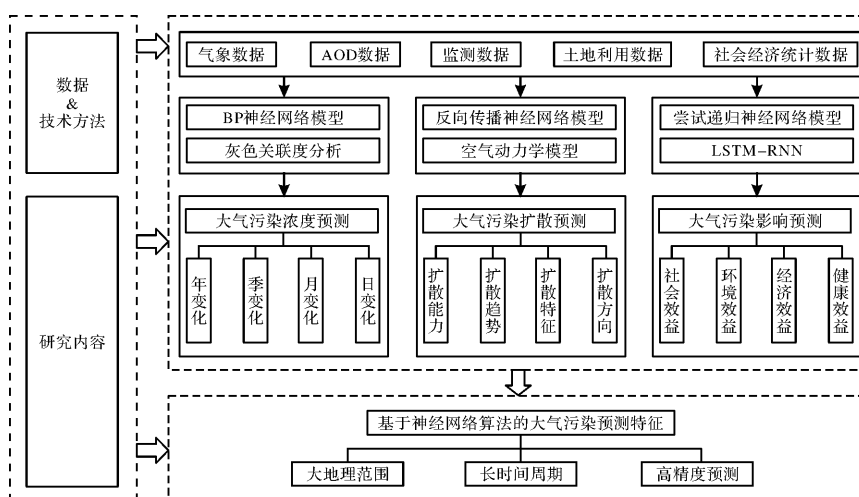


图6 智能算法在大气污染预测研究的技术流程框图

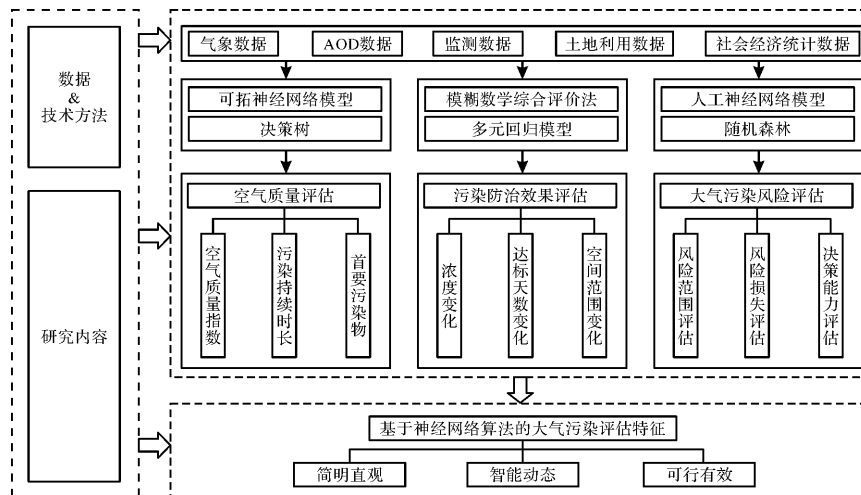


图7 智能算法在大气污染评估研究应用

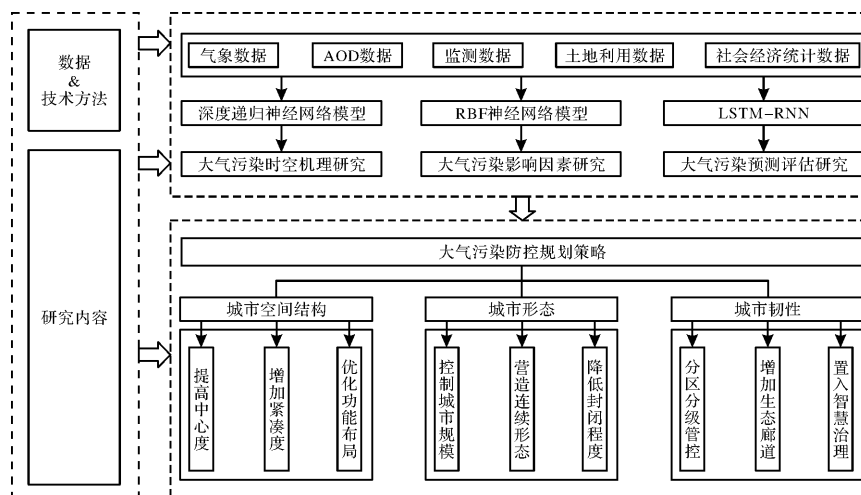


图8 智能算法在健康城市规划研究应用

糊推理系统,分析了墨西哥城及其大都市地区的空气质量,建立空气质量水平的指标;GU Kuiying等<sup>[44]</sup>采用改进的SAPSO算法和粒子群算法,并采用优化SVM模型参数评价模型,对深圳空气质量进行科学评估。目前,对于大气污染评估的方法朝着“简明直观+智能动态”的方向发展。图7是智能算法在空气质量优劣研究的技术流程图。

### 3.5 优化重构:健康韧性城市的规划应用研究

智能算法基于大气污染防治的健康城市规划打造方面,主要依托自然数据、社会经济数据,应用递归神经网络模型<sup>[45]</sup>、RBF神经网络模型<sup>[46]</sup>、长短期记忆神经网络模型<sup>[47]</sup>等方法,通过对大气污染的时空机理、影响因素以及疾病预测评估方面,构建健康评估模型,并从城市空间结构、形态、韧性三个维度,对大气污染防治进行施策,进行健康城市的环境优化及低碳、低污及生态重构方面的研究。例如,MARCO Helbich等<sup>[48]</sup>应用全卷积神经网络模型,从街景数据中提取蓝绿空间,通过多层次回归,得出蓝绿空间数量与老年人的抑郁症状呈负相关的结论。目前,基于健康城市的研究已从偏重于主观判断,逐步

向数据深度挖掘转变,进而实现精准施策。图8是智能算法在健康城市规划研究的技术流程图。

## 4 基于智能算法的大气污染防治技术的研究展望

智能算法在大气污染防治领域的应用仍处于发展阶段,在预测精度、评估周期、国土空间规划的应用方面有待提升,未来的研究趋势集中在高精度预测、全周期评估、健康呼吸城市建构三个方面。

(1)高精度预测:从“低精度+静态化”向“高精度+动态化”的转变。

智能算法作为概率模型,目前往往基于自然影响因素构建数字模型,处理的影响因素相对单一,预测的情景相对静止。未来则会构建基于自然、社会、经济和生态等的复合模型,逐步实现由“低精度+静态化”,向“高精度+动态化”转变。同时,依托大数据和3S技术,实现全域数据采集的海量数据分析,运用神经网络和暴露度模型进行精准防控评价,并运用遗传算法、模糊神经网

络等复合模型,进行实时反馈并实现精准防控的目的。

(2)全周期评估:从“单一化+局部性”向“多维度+全过程”的演化。

目前,大气污染防控研究正从依托传统的地面监测站点相对单一局部的数据,转变为处理“地-空-人”全要素多源数据,并将智能算法应用于污染防控的“预测-评价-响应”全周期。如在预测阶段的环境污染和空气质量预警,评价阶段的人口暴露度评价和呼吸系统疾病监控,以及响应阶段的都市功能区布局、形态优化和结构调整,与国土空间规划实现全周期对应,实现不同阶段的有效性传导,形成可操作、可复制和可落地的流程。

(3)健康化理念:从“环保+污染防控”向“健康+生态韧性”的转型。

建设高品质的健康韧性城市,是智能算法在大气污染防控中运用的最终愿景。未来将进一步应用智能算法,分析生态环境和景观格局,智慧评估大气环境容量,通过与大气污染相关的土地利用智慧模拟,实现健康城市构建目标下的城市形态、城市结构和开发强度最优化控制。同时,通过大数据及智能算法,模拟城市人群的行为活动和时空活动规律,构建城市空气质量保障模型,进行健康状况智慧评估,实现从“环保+污染防控”向“健康+生态韧性”的目标转化。

## 参考文献:

- [1] 张迪,赵隽颖,沈隽永,等.基于深度学习的大气细颗粒物污染时空预报[J].环境科学与技术,2020,43(9):141-154.
- [2] LIAO Q, ZHU M M, WU L, et al. Deep Learning for Air Quality Forecasts: a Review[J]. Current Pollution Reports, 2020, 6(4): 399-409.
- [3] ONWUKWE C, JACKSON P L. Evaluation of CMAQ modeling sensitivity to planetary boundary layer parameterizations for gaseous and particulate pollutants over a fjord valley[J]. Atmospheric Environment, 2020, 233: 117607.
- [4] WANG X K, LU W Z. Seasonal variation of air pollution index: Hong Kong case study[J]. Chemosphere, 2006, 63(8): 1261-1272.
- [5] TAI A P K, MICKLEY L J, JACOB D J. Correlations between fine particulate matter (PM<sub>2.5</sub>) and meteorological variables in the United States: Implications for the sensitivity of PM<sub>2.5</sub> to climate change[J]. Atmospheric Environment, 2010, 44(32): 3976-3984.
- [6] CHEN J, ZHOU C S, WANG S J, et al. Identifying the socioeconomic determinants of population exposure to particulate matter (PM<sub>2.5</sub>) in China using geographically weighted regression modeling[J]. Environmental Pollution, 2018, 241: 494-503.
- [7] LIN C Q, LI Y, YUAN Z B, et al. Using satellite remote sensing data to estimate the high-resolution distribution of ground-level PM<sub>2.5</sub>[J]. Remote Sensing of Environment, 2015, 156: 117-128.
- [8] PATELLA V, FLORIO G, PALMIERI M, et al. Atopic dermatitis severity during exposure to air pollutants and weather changes with an Artificial Neural Network (ANN) analysis[J]. Pediatric Allergy and Immunology, 2020, 31(8): 938-945.
- [9] KRISTIANI E, LEE C F, YANG C T, et al. Air quality monitoring and analysis with dynamic training using deep learning[J]. Journal of Supercomputing, 2021, 77(6): 5586-5605.
- [10] MELE M, MAGAZZINO C. A Machine Learning analysis of the relationship among iron and steel industries, air pollution, and economic growth in China[J]. Journal of Cleaner Production, 2020, 277: 123293.
- [11] JIN X B, YANG N X, WANG X Y, et al. Deep Hybrid Model Based on EMD with Classification by Frequency Characteristics for Long-Term Air Quality Prediction[J]. Mathematics, 2020, 8(2): 214.
- [12] SUN Q, ZHU Y M, CHEN X M, et al. A hybrid deep learning model with multi-source data for PM<sub>2.5</sub> concentration forecast[J]. Air Quality Atmosphere and Health, 2021, 14(4): 503-513.
- [13] LI T W, SHEN H F, YUAN Q Q, et al. Estimating Ground-Level PM<sub>2.5</sub> by Fusing Satellite and Station Observations: A Geo-Intelligent Deep Learning Approach[J]. Geophysical Research Letters, 2017, 44(23): 11985-11993.
- [14] LIN C Q, LIU G, LAU A K H, et al. High-resolution satellite remote sensing of provincial PM<sub>2.5</sub> trends in China from 2001 to 2015[J]. Atmospheric Environment, 2018, 180: 110-116.
- [15] MA Z W, LIU R Y, LIU Y, et al. Effects of air pollution control policies on PM<sub>2.5</sub> pollution improvement in China from 2005 to 2017: a satellite-based perspective[J]. Atmospheric Chemistry and Physics, 2019, 19(10): 6861-6877.
- [16] GUO B, WANG X X, PEI L, et al. Identifying the spatiotemporal dynamic of PM<sub>2.5</sub> concentrations at multiple scales using geographically and temporally weighted regression model across China during 2015-2018[J]. Science of the Total Environment, 2021, 751: 141765.
- [17] NARAYAN T, BHATTACHARYA T, CHAKRABORTY S, et al. Application of Multiple Linear Regression and Geographically Weighted Regression Model for Prediction of PM<sub>2.5</sub>[J]. Proceedings of the National Academy of Sciences India Section A - Physical Sciences, 2020: 1-13.
- [18] LI G C, CHEN W, LI R R, et al. Prediction of AOD data by geographical and temporal weighted regression with nonlinear principal component analysis[J]. Arabian Journal of Geosciences, 2020, 13(17): 1-12.
- [19] CHANG-HOI H, PARK I, OH H R, et al. Development of a PM<sub>2.5</sub> prediction model using a recurrent neural network algorithm for the Seoul metropolitan area, Republic of Korea[J]. Atmospheric Environment, 2021, 245: 118021.
- [20] BOZDAG A, DOKUZ Y, GOKCEK O B. Spatial prediction of PM<sub>10</sub> concentration using machine learning algorithms in Ankara, Turkey[J]. Environmental Pollution, 2020, 263: 114635.
- [21] LUO Y, TENG M F, YANG K, et al. Research on PM<sub>2.5</sub> estimation and prediction method and changing characteristics analysis under long temporal and large spatial scale - A case study in China typical regions[J]. Science of the Total Environment, 2019, 696: 133983.
- [22] JIA G Y, HAN G J, DU J X, et al. PMS: Intelligent Pollution Monitoring System Based on the Industrial Internet of Things for a Healthier City[J]. Ieee Network, 2019, 33(5): 34-40.
- [23] CHE W W, FREY H C, FUNG J C H, et al. PRAISE - HK: A personalized real-time air quality informatics system for citizen participation in exposure and health risk management[J]. Sustainable Cities and Society, 2020, 54: 101986.
- [24] JING Y, LIU Y L, CAI E X, et al. Quantifying the spatiality of urban leisure venues in Wuhan, Central China - GIS-based spatial pattern metrics[J]. Sustainable Cities and Society, 2018, 40: 638-647.
- [25] TONG W T, LI L X, ZHOU X L, et al. Deep learning PM<sub>2.5</sub> concentrations with bidirectional LSTM RNN[J]. Air Quality Atmosphere and Health, 2019, 12(4): 411-423.
- [26] HAN L, ZHAO J Y, GAO Y J, et al. Spatial distribution characteristics of PM<sub>2.5</sub> and PM<sub>10</sub> in Xi'an City predicted by land use regression models[J]. Sustainable Cities and Society, 2020, 61: 102329.
- [27] RUSSO A, SOARES A O. Hybrid Model for Urban Air Pollution Forecasting: A Stochastic Spatio-Temporal Approach[J]. Math-



- ematical Geosciences, 2014, 46(1): 75–93.
- [28] ALYOUSIFI Y, IBRAHIM K, KANG W, et al. Modeling the spatio-temporal dynamics of air pollution index based on spatial Markov chain model[J]. Environmental Monitoring and Assessment, 2020, 192(11): 1–24.
- [29] LIU Q Q, WU R, ZHANG W Z, et al. The varying driving forces of PM<sub>2.5</sub> concentrations in Chinese cities: Insights from a geographically and temporally weighted regression model[J]. Environment International, 2020, 145: 106168.
- [30] SHAO J J, GE J F, FENG X M, et al. Study on the relationship between PM(2.5) concentration and intensive land use in Hebei Province based on a spatial regression model[J]. Plos One, 2020, 15(9): e238547.
- [31] CHAN K Y, JIAN L. Identification of significant factors for air pollution levels using a neural network based knowledge discovery system[J]. Neurocomputing, 2013, 99: 564–569.
- [32] WANG X H, WANG B Z. Research on prediction of environmental aerosol and PM<sub>2.5</sub> based on artificial neural network[J]. Neural Computing & Applications, 2019, 31(12): 8217–8227.
- [33] SHI K H, WU L F. Forecasting air quality considering the socio-economic development in Xingtai[J]. Sustainable Cities and Society, 2020, 61: 102337.
- [34] WANG Q, WANG Y, ZHAO J Y, et al. Diffusion factors of street canyon pollutants in the cold winter of Xi'an city based on back propagation neural network analysis[J]. Indoor and Built Environment, 2015, 24(8): 1082–1094.
- [35] LIN M Y, HUANG C W, KATUL G, et al. The simultaneous effects of image force and diffusion on ultrafine particle deposition onto vegetation: A wind tunnel study[J]. Aerosol Science and Technology, 2019, 53(4): 371–380.
- [36] ZHOU X L, TONG W T, LI L X. Deep learning spatiotemporal air pollution data in China using data fusion[J]. Earth Science Informatics, 2020, 13(3): 859–868.
- [37] GUO Q G H, HE Z F, LI S S, et al. Air Pollution Forecasting Using Artificial and Wavelet Neural Networks with Meteorological Conditions[J]. Aerosol and Air Quality Research, 2020, 20(6): 1429–1439.
- [38] MIHAITA A S, DUPONT L, CHERY O, et al. Evaluating air quality by combining stationary, smart mobile pollution monitoring and data-driven modelling[J]. Journal of Cleaner Production, 2019, 221: 398–418.
- [39] ABDULLAH L, KHALID N D. Classification of air quality using fuzzy synthetic multiplication[J]. Environmental Monitoring and Assessment, 2012, 184(11): 6957–6965.
- [40] SANCHEZ-PINERO J, MOREDA-PINEIRO J, CONCHA-GRANA E, et al. Inhalation bioaccessibility estimation of polycyclic aromatic hydrocarbons from atmospheric particulate matter (PM<sub>10</sub>): Influence of PM<sub>10</sub> composition and health risk assessment[J]. Chemosphere, 2021, 263: 127847.
- [41] MCCREDDIN A, ALAM M S, MCNABOLA A. Modelling personal exposure to particulate air pollution: An assessment of time-integrated activity modelling, Monte Carlo simulation & artificial neural network approaches[J]. International Journal of Hygiene and Environmental Health, 2015, 218(1): 107–116.
- [42] CHOUBIN B, ABDOLSHAHNEJAD M, MORADI E, et al. Spatial hazard assessment of the PM<sub>10</sub> using machine learning models in Barcelona, Spain[J]. Science of the Total Environment, 2020, 701: 134474.
- [43] OLVERA-GARCIA M A, CARBAJAL-HERNANDEZ J J, SANCHEZ-FERNANDEZ L P, et al. Air quality assessment using a weighted Fuzzy Inference System[J]. Ecological Informatics, 2016, 33: 57–74.
- [44] GU K Y, ZHOU Y, SUN H, et al. Prediction of air quality in Shenzhen based on neural network algorithm[J]. Neural Computing & Applications, 2020, 32(7): 1879–1892.
- [45] BIANCOFIORE F, BUSILACCHIO M, VERDECCHIA M, et al. Recursive neural network model for analysis and forecast of PM<sub>10</sub> and PM<sub>2.5</sub>[J]. Atmospheric Pollution Research, 2017, 8(4): 652–659.
- [46] JIANG S, LU C W, ZHANG S, et al. Prediction of Ecological Pressure on Resource-Based Cities Based on an RBF Neural Network Optimized by an Improved ABC Algorithm[J]. Ieee Access, 2019, 7: 47423–47436.
- [47] KHATIBI T, KARAMPOUR N. Predicting the number of hospital admissions due to mental disorders from air pollutants and weather condition descriptors using stacked ensemble of Deep Convolutional models and LSTM models (SEDCMLM)[J]. Journal of Cleaner Production, 2021, 280: 124410.
- [48] MITCHENER W G. Ranking with hamiltonian dynamics[J]. Physica D-Nonlinear Phenomena, 2020, 413: 132676.

## Knowledge Graph of Air Pollution Control Based on Intelligent Algorithms: Research Methods, Evolution Paths and Application Prospects

ZENG Suiping<sup>1</sup>, ZHAO Xiya<sup>1</sup> and TIAN Jian<sup>2,3</sup>

(1. School of Architecture, Tianjin Chengjian University, Tianjin 300384, China; 2. Tianjin Urban Planning and Design Institute, Tianjin 300190, China; 3. School of Architecture, Tianjin University, Tianjin 300072, China)

**Abstract:** Air pollution prevention and control is an important research topic to protect people's health and life safety. Intelligent algorithm is an important tool for air pollution prevention and control, prediction and early warning. In this paper, Citespace is used to make a visual analysis of the literature on the application of intelligent algorithm in air pollution prevention and control from 1998 to 2021 in the core database of Web of Science. The results show that: (1) the application history of intelligent algorithm in air pollution prevention and control includes four stages: mathematical statistics, remote sensing monitoring, digital simulation and neural network algorithm. (2) The research themes are clustered into three core cluster evolution paths: "neural network model", "smart health detection system" and "air pollution in urban space"; (3) The application methods include five aspects: "spatial and temporal distribution of air pollution", "correlation of air pollution factors", "prediction of air pollution events", "evaluation of air quality" and "application of healthy and resilient cities". In the future, the application trend of intelligent algorithms in air pollution prevention and control will reflect the characteristics of "high precision prediction – full cycle assessment – health concept".

**Key words:** intelligent algorithm; air pollution prevention and control; knowledge graph; spatial layout; control the physical environment