

# 基于AERMOD和POA-BP神经网络的工业园区CO<sub>2</sub>排放源反演

汪颖翔<sup>1</sup>, 邓广宇<sup>2</sup>, 杜治<sup>3</sup>, 贺继锋<sup>3</sup>, 周志强<sup>3</sup>, 陈远<sup>4</sup>, 周思璇<sup>1</sup>, 雷何<sup>1</sup>, 李斯吾<sup>1</sup>,  
张晓星<sup>2</sup>

(1. 国网湖北省电力有限公司经济技术研究院, 武汉 430000; 2. 新能源及电网装备安全监测湖北省工程研究中心(湖北工业大学), 武汉 430068; 3. 国网湖北省电力有限公司, 武汉 430000; 4. 湖北碳排放权交易中心, 武汉 430000)

**摘要:** 工业园区CO<sub>2</sub>排放在全国CO<sub>2</sub>排放总量中占比约31%, 园区低碳发展对于缓解气候变化具有重要作用。以湖北省某工业区为例, 对工业园区单、多CO<sub>2</sub>排放源关键信息进行了反演研究。基于AERMOD系统建立了工业园区内CO<sub>2</sub>扩散的正向模型, 获取反演所需数据集。利用粒子群优化算法(particle swarm optimization, PSO)、鲸鱼优化算法(whale optimization algorithm, WOA)和鹈鹕优化算法(pelican optimization algorithm, POA)优化后的反向传播(backpropagation, BP)神经网络对工业园区中CO<sub>2</sub>排放源位置及排放强度进行反演计算。结果表明: POA-BP反演模型对于单排放源坐标的反演结果R<sup>2</sup>为0.965, 对排放强度的反演R<sup>2</sup>为0.938; 对于多排放源坐标的反演结果R<sup>2</sup>为0.97, 对排放强度的反演R<sup>2</sup>为0.988, 相较于其他模型来说具有较高的反演精度和稳定性, 可以对工业园区内CO<sub>2</sub>排放源实现较为精确的定位, 为工业园区应对气候变化和推进绿色转型提供决策支持。

**关键词:** 工业园区; CO<sub>2</sub>反演; AERMOD模型; PSO算法; WOA算法; POA算法

## CO<sub>2</sub> Emission Source Inversion in Industrial Parks Based on Aermod and POA-BP Neural Networks

WANG Yingxiang<sup>1</sup>, DENG Guangyu<sup>2</sup>, DU Zhi<sup>3</sup>, HE Jifeng<sup>3</sup>, ZHOU Zhiqiang<sup>3</sup>, CHEN Yuan<sup>4</sup>,  
ZHOU Sixuan<sup>1</sup>, LEI He<sup>1</sup>, LI Siwu<sup>1</sup>, ZHANG Xiaoxing<sup>2</sup>

(1. Economic and Technical Research Institute of State Grid Hubei Electric Power Co., Ltd., Wuhan 430000, China; 2. Hubei Engineering Research Center for Safety Monitoring of New Energy and Power Grid Equipment, Hubei University of Technology, Wuhan 430068, China; 3. State Grid Hubei Electric Power Co., Ltd., Wuhan 430000, China; 4. Hubei Carbon Emission; Exchange Center, Wuhan 430000, China)

**Abstract:** CO<sub>2</sub> emissions from industrial parks account for about 31% of the total national CO<sub>2</sub> emissions, and the low-carbon development of parks plays an important role in mitigating climate change. In this paper, the key information of single and multiple CO<sub>2</sub> emission sources in industrial parks is inverted and studied by taking an industrial zone in Hubei Province as an example. A forward model of CO<sub>2</sub> diffusion in the industrial park is established based on the AERMOD system to obtain the data set required for inversion. The BP neural network optimized by particle swarm optimization (PSO), whale optimization algorithm (WOA) and pelican optimization algorithm (POA) is used to calculate the inversion of CO<sub>2</sub> emission source location and emission intensity in the industrial park. The results show that the POA-BP inversion model has an R<sup>2</sup> of 0.965 for single source coordinates and an R<sup>2</sup> of 0.938 for emission intensity, and an R<sup>2</sup> of 0.97 for multiple source coordinates and an R<sup>2</sup> of 0.988 for emission intensity, which has a higher inversion accuracy and stability than other models, and it can achieve a more accurate location of CO<sub>2</sub> sources in the industrial park and provide a better solution for the industrial park. It can realize more accurate positioning and provide decision support for industrial parks to cope with climate change and promote green transformation.

**Key words:** industrial parks; CO<sub>2</sub> inversion; AERMOD model; PSO algorithm; WOA algorithm; POA algorithm

基金项目: 国家自然科学基金资助项目(52107145)。

Foundation item: Supported by the National Natural Science Foundation of China (52107145).

## 0 引言

截止到2021年,我国共有国家级和省级工业园区2 728家,对整个中国经济的贡献达到30%以上。然而,当前工业园区中生产活动聚集,能源消耗种类繁多且复杂,导致了大量污染物的排放,对区域环境的生态质量造成了显著的影响。园区在发展的早期污染防治手段及环境管理能力落后于经济发展步伐,使其成为了高污染区域的代名词<sup>[1-3]</sup>。要想实现有效的CO<sub>2</sub>排放管理,必须从源头进行治理。然而,当前中国工业园区温室气体普遍使用碳排放因子对CO<sub>2</sub>排放进行核算,并没有实际考虑到CO<sub>2</sub>排放源位置<sup>[4-7]</sup>。所以依据大气中气体的扩散效应对CO<sub>2</sub>排放源的关键信息进行反演,成为当下温室气体减排的一个研究方向。

反演的过程需要基于正演过程进行考虑计算,气体排放的正演过程为:采用大气扩散模型计算气体在温度、风速等气象条件的影响下从排放源处向监测点扩散之后的监测点浓度。AERMOD模型在我国《环境影响评价技术导则大气环境》(HJ2.2—2008)<sup>[8]</sup>中被确立为推荐的大气扩散预测模型。国内外研究表明该模型在模拟气体扩散方面准确性高,为环境影响评价提供了有力的技术支持<sup>[9-10]</sup>。文献[11]使用AERMOD对某工业区SO<sub>2</sub>和NO<sub>2</sub>等污染物的分布情况进行模拟研究,进而建立了企业工业排放的SO<sub>2</sub>和NO<sub>2</sub>污染物排放模型,并对人员健康风险进行评估。文献[12]采用AERMOD模型对某石化园区进行大气环境评价并分析了模型的适用性。文献[13]使用AERMOD模型模拟了北京主要道路的污染物排放,探究了机动车尾气排放和气象条件的关系。以上研究表明使用AERMOD模型模拟大气中气体的扩散具有可行性,因此本文使用AERMOD模型完成了工业园区CO<sub>2</sub>反演正向模型的搭建。

反演问题为:依据在监测点获得的浓度信息及数据并与大气中气象参数变化相结合,进而反演得到排放源的相关信息。随着计算机科学的发展,基于优化算法的BP神经网络逐渐应用于各类预测反演研究。文献[14]深入探讨了气体点源排放率的反演计算方法,基于下风向距离、侧风距离、风力以及大气稳定度等7项关键变量,采用BP神经网络进行了精确计算。研究结果表明,在处理大气扩散

领域中众多以非线性方式相互作用的变量时BP神经网络具有高效性,计算效果理想。文献[15]采用PSO算法优化BP神经网络预测CO<sub>2</sub>通量,结果表明PSO-BP神经网络能较好地表达出CO<sub>2</sub>通量与主要气象因素之间的非线性关系。文献[16]采用遗传算法(genetic algorithms, GA)优化后的神经网络来反演核事故的源点信息,结果表明GA-BP能够依据污染物在大气中的扩散较为精确地反演出核事故发生的源点信息。文献[17]利用WOA优化BP神经网络对海底管道的腐蚀速率进行了预测,结果表明WOA-BP相较于GA-BP具有较高的预测精度。这些研究成果证明了BP神经网络适用于反演计算,并且拥有较高的精确度与稳定性。

目前,工业园区内CO<sub>2</sub>的排放监测多采用布点监测的方法对园区内某些位置CO<sub>2</sub>排放量进行监测,以此来对CO<sub>2</sub>排放量进行简单评估,并没有考虑CO<sub>2</sub>排放源与气体的扩散效应的影响。因此,结合气体扩散模型和反演算法预测工业园区CO<sub>2</sub>排放源对碳排放监测和精准减排有重要的指导意义。

基于以上分析,本文利用AERMOD模型建立了工业园区内CO<sub>2</sub>扩散的正向模型,并分析整理了监测点CO<sub>2</sub>位置及浓度的数据集。引入PSO算法、WOA算法和POA算法优化BP神经网络对工业园区内CO<sub>2</sub>排放源的位置及强度反演进行建模。分析比较了单一BP神经网络、PSO-BP、WOA-BP和POA-BP的反演结果与误差,并验证了反演模型的预测效果和可行性。

## 1 大气扩散模型及反演算法描述

### 1.1 AERMOD大气扩散模型

AERMOD大气扩散模型在实际环评工作中应用广泛,它是以扩散统计理论为基础的一种稳态烟羽模型,使用该模型的前提是需要假定气体在大气中的扩散遵循高斯分布。模型系统包括AERMET、AREMAP和AERMOD这3个模块,模型的适用范围一般小于50 km<sup>[18]</sup>。

AERMET作为气象数据的预处理工具,其核心功能在于精确计算模型运行所必需的边界层参数,从而确保气象数据的有效整合与利用,提供模型所需的气象数据。AREMAP模块是地形数据的预处理器,它能够把输入的地理位置参数转化为模型所需的地形数据,在模拟污染物浓度之前将经过

预处理的气象数据和地形数据导入 AERMOD 模块中。随后,为了确保模拟的准确性需要输入一系列必要的参数,这些参数涵盖了气象条件、地形特征以及污染物排放源的强度等。完成参数设置后 AERMOD 模型基于这些输入数据计算关注点污染物浓度<sup>[19]</sup>。图 1 为 AERMOD 模型的全部模块与工作流程。




图 1 AERMOD 模型模块与工作流程

Fig. 1 AERMOD model module and workflow

## 1.2 BP神经网络及优化算法原理

### 1.2.1 BP神经网络原理

BP神经网络<sup>[20-22]</sup>即反向传播神经网络,是一种基于误差反向传播算法进行训练的多层次前馈网络结构。它通过逐层向前传递信息,并在输出层与期望输出进行比较,随后将误差逆向传播至各层,以调整网络权重,直至达到预设的精度要求。网络拓扑结构如图 2 所示。

神经网络的架构设计遵循特定的原则,其中输入层和输出层的节点数直接取决于输入与输出数据的维度。而隐含层的节点数则通过式(1)进行计算




图 2 BP神经网络结构

Fig. 2 Structure of BP neural network

确定。该网络的工作原理在于将大量数据输入至神经网络中,随后利用误差反向传播机制,对网络中的权值和阈值进行持续优化,以实现复杂变量间非线性关系的精确映射。

$$m = \sqrt{n + l} + \alpha \quad (1)$$

式中:  $m$  为隐含层节点的数量;  $n$  为输入层节点的数量;  $l$  为输出层节点的数量;  $\alpha$  为 1~10 之间的常数。

### 1.2.2 粒子群优化算法

粒子群优化算法 (particle swarm optimization, PSO)<sup>[23-24]</sup>的基本思想是用粒子代替鸟,通过粒子间共享信息来优化各自速度和位置,直至找到全局最优解。

算法流程如下:假定在一个  $d$  维度的空间中,对由  $N$  个粒子组成的一个种群进行初始化,并对变量进行设置:第  $i$  个粒子的位置用向量  $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{id}]$  表示;飞行速度用  $\mathbf{v}_i = [v_{i1}, v_{i2}, \dots, v_{id}]$  表示;第  $i$  个粒子自身搜索到的最优位置用  $\mathbf{p}_i = [p_{i1}, p_{i2}, \dots, p_{id}]$  表示;整个群体目前搜索到的最优位置用  $\mathbf{p}_g$  表示;基于式(2)~(3)来更新 PSO 算法中粒子的速度和位置。

$$\mathbf{v}_i(n+1) = \mathbf{v}_i(n) + c_1 r_1 (\mathbf{p}_i - \mathbf{x}_i(n)) + c_2 r_2 (\mathbf{p}_g - \mathbf{x}_i(n)) \quad (2)$$

$$\mathbf{x}_i(n+1) = \mathbf{x}_i(n) + \mathbf{v}_i(n+1) \quad (3)$$

式中:  $i=1, 2, \dots, N$ , 分别用于表示不同的粒子;  $c_1$ 、 $c_2$  为大于 0 的学习因子,一般情况下取  $c_1=c_2=2$ ;  $r_1$ 、 $r_2$  为随机数,介于  $[0, 1]$  之间;  $n$  为迭代次数,当达到预设的最大迭代步数时,算法终止。

### 1.2.3 鲸鱼优化算法

鲸鱼优化算法 (whale optimization algorithm, WOA)<sup>[25]</sup>是一种元启发式优化算法,基于座头鲸觅食行为的灵感成功构建了包括随机搜索捕食、包围捕食以及气泡网捕食在内的多种理论模型。这些模型为复杂问题的优化提供了新思路。通过结合 WOA 与 BP 神经网络<sup>[26]</sup>,规避了单一 BP 神经网络易于陷入局部最优和预测不稳定的风险,同时显著提升了算法在全局范围内的搜索和优化性能。

WOA 算法提出的主要数学方程如下。

$$X(t+1) = \begin{cases} X^*(t) - AD, & p < 0.5 \\ D'e^{bl} \cos(2\pi t) + X^*(t), & p \geq 0.5 \end{cases} \quad (4)$$

式中:  $D' = |X^*(t) - X(t)|$ ,  $D = |CX^*(t) - X(t)|$ ;



$A = 2ar - a$ ;  $C = 2rp$ ;  $r$ 为 $[0, 1]$ 之间的一个随机数;  $X(t)$ 和 $X^*(t)$ 分别为当前鲸鱼位置和每次迭代的最优解;  $D'$ 为第 $i$ 条鲸鱼的最佳捕食位置;  $b$ 为定义螺旋形状的常数;  $l$ 为 $[-1, 1]$ 的随机数;  $t$ 为迭代次数;  $A$ 为迭代过程中线性地从2减小到0的数值。

在式(4)中,前半部分旨在模拟座头鲸的包围机制,而后半部分则是对气泡网捕猎技术的数学再现。变量 $p$ 在这两部分间以均等的机会进行切换,反映了座头鲸觅食策略的灵活多变性。在WOA的框架下,每头参与捕猎的鲸鱼都象征着一个潜在的解决方案。在算法迭代的每一轮中鲸鱼们会根据随机选择,决定执行3种觅食策略中的哪一种:朝向最优位置的猎物捕猎,或运用包围策略收缩位置,以逐步逼近目标猎物。通过这种迭代更新,算法能够持续逼近并最终找到问题的最优解。

#### 1.2.4 鹈鹕优化算法

鹈鹕优化算法(pelican optimization algorithm, POA)由Pavel Trojovský和Mohammad Dehghani<sup>[27]</sup>于2022年提出,模拟鹈鹕在狩猎过程中的自然行为,算法描述如下。

在第一阶段,猎物位置在搜索空间中随机生成,鹈鹕对猎物位置进行定位,并向猎物靠近,针对这种狩猎方式进行建模,使得POA算法拥有扫描整个搜索空间的能力,并且能够使其探索整个搜索空间中的不同区域。鉴于猎物位置在搜索空间内的随机生成特性,POA算法在精确搜索问题的解决上展现出了增强的勘探能力。这一特性使得算法在应对复杂问题时能够更有效地探索潜在解空间,从而提高搜索的精确性和效率。

$$x_{i,j}^{p_i} = \begin{cases} x_{i,j} + N_{\text{rand}} \cdot (p_j - l \cdot x_{i,j}), & F_p < F_i \\ x_{i,j} + N_{\text{rand}} \cdot (x_{i,j} - p_j), & \text{其他} \end{cases} \quad (5)$$

式中:  $x_{i,j}^{p_i}$ 为基于第一阶段更新后第 $i$ 个鹈鹕的第 $j$ 维的位置;  $N_{\text{rand}}$ 为 $[0, 1]$ 范围内的随机数;  $l$ 为1或2的随机整数;  $p_j$ 为猎物的第 $j$ 维的位置;  $F_p$ 为猎物的目标函数值;  $x_{i,j}$ 为第 $i$ 个鹈鹕的第 $j$ 维的位置;  $F_i$ 为第 $i$ 个鹈鹕的目标函数值。

在POA算法的执行过程中,为了确保搜索的效率和准确性,需要不断地对鹈鹕的位置进行更新。一旦鹈鹕在特定位置实现了目标函数值的优化,算法将依据这一改进后的函数值,通过特定的

数学公式来更新鹈鹕的位置,从而引导搜索过程向更优解的方向进行,由式(6)~(7)进行描述。

在式(6)中定义了一个新的位置变量,记作 $X_i^{p_i}$ ,它表示第 $i$ 个鹈鹕经过更新后的位置。此外,还引入了一个变量 $F_i^{p_i}$ ,它表示第 $i$ 个鹈鹕在经历第一阶段更新后,其新位置对应的目标函数值。这两个变量共同构成了算法更新过程中的关键参数。

$$X_i = \begin{cases} X_i^{p_i}, & F_i^{p_i} < F_i \\ X_i, & \text{其他} \end{cases} \quad (6)$$

式中 $F_i$ 为第 $i$ 个鹈鹕的目标函数值。

在第二阶段,鹈鹕在搜索空间中不断寻找并最终到达猎物所在位置,在猎物所在区域内张开翅膀,将猎物向区域边界逼近,然后捕食猎物。这种狩猎方式使它们在狩猎范围内能够捕获更多的猎物。如果从数学建模的角度来说,这种策略需要检查鹈鹕位置附近的区域,以便算法可以在整个狩猎区域中收敛到更好的位置。这种狩猎行为可表示为:

$$x_{i,j}^{p_i} = x_{i,j} + R \cdot (1 - \frac{t}{T}) \cdot (2 \cdot N_{\text{rand}} - 1) \cdot x_{i,j} \quad (7)$$

式中:  $x_{i,j}^{p_i}$ 为第 $i$ 个鹈鹕在第二阶段更新后第 $j$ 维的新位置;  $R$ 为一个随机整数,其值在0或2之间选择,用以影响算法的搜索方向;  $t$ 为当前迭代次数,用于跟踪算法的运行进度;  $T$ 为算法最大迭代次数,确保算法能够在合理的时间内收敛。

## 2 工业园区CO<sub>2</sub>排放源反演算法模型建立

### 2.1 模型搭建

将第一部分中AERMOD模型输出的浓度数据整理后输入到BP神经网络中,同时,基于前文所描述的PSO、WOA和POA优化算法原理对BP神经网络进行优化,分别构建工业园区CO<sub>2</sub>排放源反演模型即PSO-BP、WOA-BP和POA-BP反演模型。各优化算法优化及反演流程如图3所示。

### 2.2 模型评价指标

为了全面评估反演模型的性能,本文选取了多个评价指标。具体而言,除了决定系数 $R^2$ (其值用 $C_r$ )外,还引入了平均绝对百分比误差(mean absolute percentage error, MAPE, 其值为 $E_{\text{MAPE}}$ )和均方根误差(root mean square error, RMSE, 其值为 $E_{\text{RMSE}}$ )作为辅助的评估标准。这些指标能够从不同的角度反映模型的预测精度和稳健性,从而为模




图3 算法优化BP神经网络反演流程

Fig. 3 Algorithm optimization BP neural network inversion flow chart

型的优化和改进提供有力的依据。其中, 模型的 $R^2$ 值越接近1, MAPE和RMSE值越小, 模型的反演精度越高。评价指标的计算公式如式(8)~(9)所示。

$$C_{R^2} = \frac{\sum_{i=1}^N (\hat{y}_i - \bar{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (8)$$

$$E_{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (9)$$

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (10)$$

式中:  $y_i$  为第  $i$  个样本的真实值;  $\hat{y}_i$  为第  $i$  个样本的反演值;  $N$  为样本的数量。

### 3 实例计算

#### 3.1 样本数据的收集与预处理

本次 AERMOD 模拟范围是湖北省内某工业园区, 以东经 112.116°、北纬 32.088°为排放源所在

位置, 地面气象数据应包括: 时间、风向、风速和干球温度等。从编号为 57 265 的地面气象站点获取, 高空气象数据应包括: 时间、气压、离地高度和风速等。从某大学大气科学无线电探空仪档案馆<sup>[27]</sup>获取高空站点编号为 57 494 的探空气象数据。本文地表参数选取的数值如表 1 所示。

表1 城市类别地表参数设置

Table 1 Setting of urban surface parameters

| 季节 | 反照率  | 地表粗糙度 | 波纹比 |
|----|------|-------|-----|
| 冬季 | 0.30 | 1.5   | 1.4 |
| 春季 | 0.15 | 1.5   | 1.1 |
| 夏季 | 0.17 | 1.5   | 2.5 |
| 秋季 | 0.15 | 1.5   | 2.5 |

#### 3.1.1 单一排放源样本数据

图4为本文单排放源研究区域划分, 以园区中心为原点, 分为三重网格嵌套, 网格大小分别为 30 km、20 km、7.5 km。在研究区域内选定排放源所在位置, 在 AERMOD 模型中设定不同排放源强度以获取不同的样本数据, 设置排放源附近 8 个点为监测点。设置完成后选择监测点日均浓度作为计算方案, 运行 AERMOD 模型进行计算。




图4 单一排放源研究区域

Fig. 4 Single emission source research area

图5为排放源强度为 3 500 kg/h 时不同气象条件下模拟计算的气体扩散结果。如表2所示为由图5提取出的样本数据。单一排放源情况下样本数量为 800, 前 80 % 为训练集, 后 20 % 为反演集。由于篇幅有限, 本文仅列出排放源附近 8 个监测点浓度。通过对比图5可知, 尽管排放源的位置与强度

并未发生变化,但是监测点处的浓度信息随着气象条件的变化发生改变,故除监测点坐标、浓度以外,将影响监测点 CO<sub>2</sub> 浓度变化的气象条件参数也纳入数据集中。在针对简单平坦地形的监测任务中,最终确定了数据集的输入变量,这些变量包括监测点的坐标信息、浓度数据、地面气象数据中的温度参数和高空气象数据中的风速与风向,CO<sub>2</sub> 排放源位置及排放强度作为数据集的输出数据。




图5 单一排放源研究区域不同气象条件下模拟计算结果  
Fig. 5 Simulation calculation results under different meteorological conditions with single emission source

3.1.2 多排放源样本数据

图6为本文多排放源研究区域,嵌套网格大小与单排放源情况相同。在区域内选定4处排放源位置,在AERMOD模型中设定不同排放源强度以获取不同的样本数据。由于多排放源之间产生的叠加效应,减少不必要的浓度监测,故在各排放源附近选取5个点为监测点。设置完成后选择监测点日均浓度作为计算方案,运行AERMOD模型进行计算。

图7为排放源强分别为5 000、3 500、2 000和1 000 kg/h时不同气象条件下模拟计算的气体扩散结果。在多排放源情况下所提取用于训练的样本数




图6 多排放源研究区域  
Fig. 6 Research area of multiple emission source

量为2 000。训练集与反演集所占比例同单一排放源。本文仅列出4个不同排放源附近20个监测点浓度数据。表3为由图7提取出的样本数据。




图7 不同气象条件下模拟计算结果  
Fig. 7 Simulation calculation results under different meteorological conditions

3.2 反演模型参数设置

3.2.1 神经网络参数设置

本文首先设定了BP神经网络在初始训练阶段

表2 单排放源时监测点浓度计算结果

Tab. 2 Calculation results of monitoring point concentrations with single emission source

| 排放源坐标/m      | 排放源强度/(kg·h <sup>-1</sup> ) | 编号 | 监测点坐标/m            | 监测点浓度/(μg·m <sup>-3</sup> ) |        |        |
|--------------|-----------------------------|----|--------------------|-----------------------------|--------|--------|
|              |                             |    |                    | 气象条件 a                      | 气象条件 b | 气象条件 c |
| (0.76, 2.14) | 3 500                       | 1  | (-256.82, 75.55)   | 221.08                      | 159.89 | 203.22 |
|              |                             | 2  | (-183.86, -355.44) | 251.81                      | 198.65 | 248.27 |
|              |                             | 3  | (-146.02, 289.41)  | 146.62                      | 132.03 | 219.09 |
|              |                             | 4  | (121.52, -474.54)  | 114.71                      | 109.10 | 153.67 |
|              |                             | 5  | (197.96, 405.36)   | 115.19                      | 96.48  | 99.71  |
|              |                             | 6  | (433.72, -205.31)  | 194.66                      | 113.17 | 112.96 |
|              |                             | 7  | (567.71, 297.14)   | 271.25                      | 120.99 | 139.60 |
|              |                             | 8  | (424.71, 9.84)     | 179.68                      | 167.30 | 245.76 |



表 3 多排放源时监测点浓度计算结果

Tab. 3 Calculation results of concentrations at monitoring points with multiple emission sources

| 排放源坐标/m               | 排放源强度/<br>(kg·h <sup>-1</sup> ) | 编号 | 监测点坐标/m               | 监测点浓度/(μg·m <sup>-3</sup> ) |        |        |
|-----------------------|---------------------------------|----|-----------------------|-----------------------------|--------|--------|
|                       |                                 |    |                       | 气象条件 a                      | 气象条件 b | 气象条件 c |
| (725.37,894.76)       | 5 000                           | 1  | (1 597.27,802.89)     | 147.67                      | 140.73 | 133.54 |
|                       |                                 | 2  | (766.41,-223.81)      | 251.52                      | 249.06 | 245.82 |
|                       |                                 | 3  | (-198.33,336.32)      | 377.94                      | 370.02 | 349.72 |
|                       |                                 | 4  | (-681.66,-179.67)     | 367.53                      | 353.17 | 326.51 |
|                       |                                 | 5  | (-59.81,-669.61)      | 129.85                      | 127.99 | 127.47 |
| (-1 767.26,-1 749.85) | 3 500                           | 6  | (-2 291.03,-2 032.89) | 477.26                      | 498.17 | 517.06 |
|                       |                                 | 7  | (-1 880.72,-2 298.6)  | 241.89                      | 237.23 | 236.63 |
|                       |                                 | 8  | (-1 392.57,-1 450.47) | 350.50                      | 345.99 | 346.99 |
|                       |                                 | 9  | (-1 425.09,-1 760.2)  | 414.38                      | 401.19 | 392.41 |
|                       |                                 | 10 | (-745.16,-1 970.88)   | 185.48                      | 182.91 | 179.94 |
| (-1 103.56,-2 756.85) | 2 000                           | 11 | (-2 520.59,-2 597.73) | 222.88                      | 222.36 | 222.01 |
|                       |                                 | 12 | (-2 505.76,-2 968.05) | 269.33                      | 268.97 | 268.92 |
|                       |                                 | 13 | (-1 113.42,-3 319.72) | 180.86                      | 180.38 | 180.00 |
|                       |                                 | 14 | (-1 749.43,-2 837.59) | 297.74                      | 300.12 | 301.53 |
|                       |                                 | 15 | (-1 674.74,-3 482.41) | 173.94                      | 173.15 | 170.97 |
| (590.02,-2 516.54)    | 1 000                           | 16 | (-114.46,-2430.2)     | 126.41                      | 124.97 | 124.94 |
|                       |                                 | 17 | (-285.22,-3023.97)    | 175.15                      | 173.89 | 173.24 |
|                       |                                 | 18 | (390.18,-3397.51)     | 85.18                       | 84.86  | 84.58  |
|                       |                                 | 19 | (1454.02,-3403.49)    | 63.24                       | 63.04  | 62.81  |
|                       |                                 | 20 | (-152.86,-3788.92)    | 82.87                       | 82.63  | 82.40  |

的迭代次数为 1 000 次。这一设定旨在确保网络能够充分学习训练数据中的特征，并为后续的优化和测试奠定基础。然后把神经网络的学习速率设置为 0.01，最终将训练结果所能接受的最小误差设置为 0.000 01。在构建神经网络模型时通常需要根据一定的范围来设定隐含层的节点数。这一范围可以通过应用式(1)并采用试值法来确定。为了评估不同节点数对模型性能的影响，将区间内的每个数值逐一代入神经网络模型中进行计算，并得出了相应的运算结果，如图 8 所示。这一步骤可以后续的模式优化提供依据。在单排放源模型场景下当隐含层节点数设定为 11 时，模型所计算的均方误差值达到了最低点，具体数值为 0.102 02。而在多排放源模型的情况下，当隐含层节点数被设置为 13 时模型在训练阶段所计算的均方误差值呈现最小值，该值为 0.555 4。因此，针对本文所构建的神经网络反演模型，单排放源 BP 神经网络反演模型隐含层节点数设置为 11；多排放源 BP 神经网络反演模型隐含层节点数设置

为 13。




图 8 不同隐含层训练均方误差

Fig. 8 Mean square errors of different hidden layers trainings

3.2.2 优化算法初始化设置

经过前述分析，本文确定了单排放源反演模型的网络拓扑结构为 8-11-1，而对于多排放源反演模型，其网络拓扑结构则设定为 5-13-4。关于各个优

化算法的初始参数配置在表 4 中详细列出。

| 表 4 PSO、WOA 和 POA 参数设置                       |          |          |          |
|----------------------------------------------|----------|----------|----------|
| Tab. 4 Parameter settings of PSO、WOA and POA |          |          |          |
| 参数                                           | 数值       |          |          |
|                                              | PSO 值    | WOA 值    | POA 值    |
| 初始种群规模                                       | 30       | 30       | 30       |
| 最大进化次数                                       | 50       | 50       | 50       |
| 个体加速常数 $C_1$                                 | 1.494 45 |          |          |
| 社会加速常数 $C_2$                                 | 1.494 45 |          |          |
| 惯性权重                                         | 0.9      |          |          |
| 训练目标最小误差                                     | 0.000 01 | 0.000 01 | 0.000 01 |

3.3 反演结果与误差检验

3.3.1 单源反演结果与误差

将样本数据中的监测点位置及浓度作为神经网络的输入数据, 对 CO<sub>2</sub> 排放源的位置进行反演, 各模型进行训练后的反演结果如图 9—12 所示, 表 5、表 6 为各模型误差计算结果。由图 9、图 11 可知, 4 种模型反演得到的结果与初始排放源设置值具有很好的—致性, 但优化过后的 BP 神经网络反演精度显著高于优化前的反演精度。由图 10、图 12 可以看出, BP 神经网络对源信息反演结果相对误差较大, 而经优化后的 3 种 BP 神经网络的反演结果相对误差明显降低, 稳定性也有较大的提高, 其中 POA-BP 神经网络的相对误差降低最为明显。




图 9 单排放源反演结果  
Fig. 9 Inversion results of single emission sources

由表 5 可知, 优化后的 3 种 BP 神经网络的  $R^2$  值均有所提升, RMSE 值明显下降, 说明优化后的 BP 神经网络反演结果的误差离散性较小, 其中 POA-BP 神经网络对于单排放源坐标反演  $R^2$  值为 0.965, 接近于 1, RMSE 值为 0.035, 在 4 种反演模型中精度最高; 对于排放强度的反演, 单一 BP 模型的反




图 10 各模型单源反演结果的相对误差  
Fig. 10 Relative error of single source inversion results for various models





图 11 多排放源反演结果  
Fig. 11 Inversion results of multiple emission sources

演结果  $R^2$  值为 0.344, RMSE 值为 0.393。而 POA-BP 模型反演的  $R^2$  值为 0.938, 比其他优化模型更加






图 12 各模型多源反演结果的相对误差

Fig. 12 Relative error of multi-source inversion results for each model

表 5 PSO、WOA 和 POA 参数设置排放源反演误差

Tab. 5 Emission source inversion errors of PSO、WOA 和 POA parameters

| 模型     | 坐标值反演误差指标        |        |        | 排放强度反演误差指标       |        |        |
|--------|------------------|--------|--------|------------------|--------|--------|
|        | R <sup>2</sup> 值 | MAPE 值 | RMSE 值 | R <sup>2</sup> 值 | MAPE 值 | RMSE 值 |
| BP     | 0.756            | 0.026  | 0.237  | 0.344            | 0.094  | 0.393  |
| PSO-BP | 0.769            | 0.024  | 0.158  | 0.669            | 0.043  | 0.19   |
| WOA-BP | 0.797            | 0.011  | 0.056  | 0.904            | 0.02   | 0.117  |
| POA-BP | 0.965            | 0.006  | 0.035  | 0.938            | 0.017  | 0.078  |

接近于 1，其 MAPE 值和 RMSE 值均低于其他优化模型，说明 POA-BP 模型对于排放强度的反演优于其他模型，有着较高的反演精度。

表 6 多排放源反演误差

Tab. 6 Inversion errors of multiple emission sources

| 模型     | 坐标值反演误差指标        |        |        | 排放强度反演误差指标       |        |        |
|--------|------------------|--------|--------|------------------|--------|--------|
|        | R <sup>2</sup> 值 | MAPE 值 | RMSE 值 | R <sup>2</sup> 值 | MAPE 值 | RMSE 值 |
| BP     | 0.712            | 0.005  | 0.492  | 0.653            | 0.033  | 0.182  |
| PSO-BP | 0.779            | 0.003  | 0.288  | 0.762            | 0.030  | 0.174  |
| WOA-BP | 0.842            | 0.002  | 0.312  | 0.891            | 0.016  | 0.125  |
| POA-BP | 0.97             | 0.002  | 0.101  | 0.988            | 0.009  | 0.094  |

在多排放源反演误差分析中，将各模型对 4 个源的位置及排放强度的反演结果误差取均值，表 6 为各算法所反演计算的平均误差。由表 6 可知，BP 神经网络、PSO-BP 神经网络、WOA-BP 神经网络和 POA-BP 神经网络对排放源坐标值反演的 MAPE 值分别为 0.534 %、0.315 %、0.223 %、0.203 %；对于排放强度反演的 MAPE 值分别为 3.364 %、

3.021 %、1.615 %、0.913 %，说明优化后的神经网络反演结果要优于单一 BP 神经网络模型的反演结果，并且 POA-BP 神经网络的反演结果又优于其它模型反演结果。从 RMSE 也可以进一步看出，优化后的 3 种 BP 神经网络反演精度均有明显的提升，其中同样以 POA-BP 神经网络反演精度最高。

综合表 5—6，通过比较 4 种反演模型反演结果与误差发现，优化后的 BP 神经网络反演精度均有较大提高，但是多源情况下对于排放源的强度反演精度要低于对于排放源位置的反演精度。原因可能在于浓度监测点数据变化较大，数据规律性较弱，而 BP 神经网络对于数据的要求较高，泛化能力弱，导致 BP 神经网络对于多源情况下的排放源强度反演精度较低。

综合单一 BP、PSO-BP、WOA-BP 和 POA-BP 反演模型对工业园区内单、多 CO<sub>2</sub> 排放源的坐标及排放强度的反演结果来看，POA-BP 模型反演结果精度较高，WOA-BP 和 PSO-BP 分别位于第 2 位和第 3 位，单一 BP 反演效果最差。

#### 4 结论

针对工业园区内 CO<sub>2</sub> 排放源位置与强度反演问题，本文采用 AERMOD 大气扩散模型建立工业园区 CO<sub>2</sub> 排放的正向模型，在 CO<sub>2</sub> 排放源附近设置监测点，通过计算获取监测点浓度信息，整理监测点的位置与浓度信息数据集，利用优化算法优化 BP 神经网络对数据集进行训练，最后将监测点位置及浓度信息导入训练后的网络中，对工业园区中单、多 CO<sub>2</sub> 排放源坐标及排放强度进行反演。得出结论如下。

1) 根据推荐的大气扩散模型获取所研究工业园区内 CO<sub>2</sub> 排放源位置和排放强度及反演所需各监测点的位置及浓度信息数据，由于不同气象条件下监测点浓度发生改变，所以反演数据集应包括气象数据与监测点的位置数据和浓度数据。

2) 分别采用单一 BP 模型、PSO-BP 模型、WOA-BP 模型以及 POA-BP 模型对工业园区中单、多 CO<sub>2</sub> 排放源位置及排放强度进行训练和反演。POA-BP 模型对坐标值和排放强度反演结果的 R<sup>2</sup> 与 RMSE 值均低于其它模型，具有较高的反演精度和鲁棒性。采用 POA-BP 模型反演得到 CO<sub>2</sub> 排放源相关信息可为工业园区减少 CO<sub>2</sub> 排放提供决策支持。

## 参考文献

- [1] 国家发展和改革委员会,科学技术部,原国土资源部,等.中国开发区审核公告目录(2018年版)[EB/OL].[https://www.gov.cn/zhengce/zhengceku/2018-12/31/content\\_5434045.htm](https://www.gov.cn/zhengce/zhengceku/2018-12/31/content_5434045.htm).
- [2] 刘艳丽,黄健,屈乐岩,等.异常事件下工业园区边缘节点集群自组织感知-控制功能迁移方法[J/OL].高压电器,1-14[2025-01-11].<http://kns.cnki.net/kcms/detail/61.1127.TM.20241206.1623.002.html>.  
LIU Yanli, HUANG Jian, QU Leyan, et al. Self-organizing sensing-control function migration method of edge node cluster in industrial park under abnormal events [J/OL]. High Voltage Apparatus, 1-14[2025-01-11].<http://kns.cnki.net/kcms/detail/61.1127.TM.20241206.1623.002.html>.
- [3] ZHA Jianping, FAN Rong, YAO Yao, et al. Framework for accounting for tourism carbon emissions in China: an industrial linkage perspective [J]. Tourism Economics, 2021, 27(7): 1430-1460.
- [4] GUO Yang, TIAN Jinping, ZANG Na, et al. The role of industrial parks in mitigating greenhouse gas emissions from China [J]. Environmental Science & Technology, 2018, 52(14): 7754-7762.
- [5] 何祥针,郑建平,左剑,等.电力现货市场竞争对广东电力碳排放的影响[J].南方电网技术,2023,17(9):49-56.  
HE Xiangzhen, ZHENG Jianping, ZUO Jian, et al. Impact of electricity spot market competition on guangdong electric power carbon emission [J]. Southern Power System Technology, 2023, 17(9): 49-56.
- [6] 冯帅,袁至,王维庆,等.碳交易背景下基于LGPG-P2G的微电网容量优化配置[J].电力工程技术,2023,42(3):157-167.  
FENG Shuai, YUAN Zhi, WANG Weiqing, et al. Optimization and configuration of microgrid capacity based on LGPG-P2G in the context of carbon trading [J]. Electric Power Engineering Technology, 2023, 42(3): 157-167.
- [7] 向怡,史学峰,吴玉生.大同盆地复杂地形下近场大气污染物扩散模型选取研究[J].环境污染与防治,2022,44(1):45-50.  
XIANG Yi, SHI Xuefeng, WU Yusheng. Study on the selection of near-field air pollutants diffusion model in complex terrain of Datong Bason [J]. Environmental Pollution & Control, 2022, 44(1): 45-50.
- [8] 环境保护部.环境影响评价技术导则大气环境:HJ2.2—2008[S].北京:中国环境科学出版社,2018.
- [9] MOUSAVI S S, GOUDARZI G, SABZALIPOUR S, et al. An evaluation of CO<sub>2</sub> and SO<sub>2</sub> emissions during continuous and non-continuous operation in a gas refinery using the AERMOD [J]. Environmental Science and Pollution Research, 2021, 28(40): 56996-57008.
- [10] HESAMI ARANI M, JAAFARZADEH N, MOSLEMZADEH M, et al. Dispersion of NO<sub>2</sub> and SO<sub>2</sub> pollutants in the rolling industry with AERMOD model: a case study to assess human health risk [J]. Journal of Environmental Health Science & Engineering, 2021, 19(2): 1287-1298.
- [11] 杨志森,赵东风,熊桂慧,等.AERMOD模型在石化园区大气规划环评中的应用[J].环境科学与技术,2016,39(S1):433-437.  
YANG Zhisen, ZHAO Dongfeng, XIONG Guihui, et al. The application research of AERMOD model in atmospheric environmental impact prediction and assessment of petrochemical industrial park [J]. Environmental Science & Technology, 2016, 39(S1): 433-437.
- [12] 王珮玮,杨道源,吴潇萌,等.基于AERMOD线源模式的城市路网一次PM<sub>2.5</sub>排放扩散特征研究[J].环境科学学报,2018,38(7):2728-2734.  
WANG Peiwei, YANG Daoyuan, WU Xiaomeng, et al. Analysis of emission dispersion features of primary PM<sub>2.5</sub> in urban road network based on AERMOD line-source mode [J]. Acta Scientiae Circumstantiae, 2018, 38(7): 2728-2734.
- [13] REGE M A, TOCK R W. A simple neural network for estimating emission rates of hydrogen sulfide and ammonia from single point sources [J]. Journal of the Air & Waste Management Association, 1996, 46(10): 953-962.
- [14] 杨帆,于鸣,李丹,等.基于粒子群算法优化BP神经网络的CO<sub>2</sub>通量预测[J].黑龙江大学自然科学学报,2017,34(4):481-485,505.  
YANG Fan, YU Ming, LI Dan, et al. A CO<sub>2</sub> flux prediction model based on particle swarm BP neural network algorithm [J]. Journal of Natural Science of Heilongjiang University, 2017, 34(4): 481-485, 505.
- [15] 凌永生,柴超君,赵丹,等.BP神经网络优化的无迹卡尔曼滤波核事故源项反演方法研究[J].安全与环境学报,2018,18(5):1931-1936.  
LING Yongsheng, CHAI Chaojun, ZHAO Dan, et al. On the source nuclide inversion approach to the unscented Kalman filter based on the BP neural network in nuclear accidents [J]. Journal of Safety and Environment, 2018, 18(5): 1931-1936.
- [16] 肖荣鸽,靳帅帅.基于WOA-BP算法的海底管道腐蚀速率预测[J].海洋科学,2022,46(6):116-123.  
XIAO Rongge, JIN Shuaishuai. Prediction of the submarine pipeline corrosion rate based on the whale optimization algorithm and back propagation (WOA-BP) algorithm [J]. Marine Sciences, 2022, 46(6): 116-123.
- [17] 崔磊,屈加豹,王鹏,等.火电企业超低排放改造对沧州市主城区大气环境影响研究[J].环境与发展,2020,32(9):16-18,20.  
CUI Lei, QU Jiabao, WANG Peng, et al. Study on the effect of ultra-low emission in thermal power industry on Cangzhou's air quality [J]. Environment and Development, 2020, 32(9): 16-18, 20.
- [18] 王成鑫,楚英豪,阮建辉,等.AERMOD模型地表参数更新对模拟效果影响[J].中国环境科学,2022,42(5):2070-2077.  
WANG Chengxin, CHU Yinghao, RUAN Jianhui, et al. Research on the influence of AERMOD model surface parameter update on simulation effect [J]. China Environmental Science, 2022, 42(5): 2070-2077.
- [19] 赵丹,凌永生,侯闻宇,等.基于BP神经网络的核事故多核素源项反演方法[J].南京航空航天大学学报,2016,48(1):130-135.  
ZHAO Dan, LING Yongsheng, HOU Wenyu, et al. Multi-nuclide source term inversion based on BP neural network during nuclear accident [J]. Journal of Nanjing University of Aeronautics & Astronautics, 2016, 48(1): 130-135.
- [20] 范德成,张修凡.基于PSO-BP神经网络模型的中国碳排放情景预测及低碳发展路径研究[J].中外能源,2021,26(8):

- 11 – 19.  
FAN Decheng, ZHANG Xiufan. Scenario prediction of China's carbon emissions based on PSO-BP neural network model and research on low carbon development path [J]. Sino-Global Energy, 2021, 26(8): 11 – 19.
- [21] 周慧康, 杨廷方, 罗屹豪, 等. 基于气吹原理的一体化防雷间隙快速灭弧方法[J]. 南方电网技术, 2023, 17(12): 119 – 126.  
ZHOU Huikang, YANG Tingfang, LUO Yihao, et al. Rapid arc-extinguishing method of integrated lightning protection gap based on the principle of air-blowing [J]. Southern Power System Technology, 2023, 17(12): 119 – 126.
- [22] ESPITIA H E, SOFRONY J I. Considerations for parameter configuration on vortex particle swarm optimization [J]. Theoretical Computer Science, 2019(773): 1 – 12.
- [23] 慕静茹, 喻锐, 曾祥君, 等. 考虑多扰动因子的含光伏电源低压台区漏电故障检测[J]. 南方电网技术, 2024, 18(10): 130 – 141.  
MU Jingru, YU Kun, ZENG Xiangjun, et al. Leakage Fault detection in low-voltage station area with photovoltaic power supply considering multi-disturbance factors [J]. Southern Power System Technology, 2024, 18(10): 130 – 141.
- [24] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016, 95: 51 – 67.
- [25] FANG Lingling, LIANG Xiyue. A novel method based on nonlinear binary grasshopper whale optimization algorithm for feature selection [J]. Journal of Bionic Engineering, 2023, 20(1): 237 – 252.
- [26] TROJOVSKÝ P, DEGHANI M. Pelican optimization algorithm: a novel nature-inspired algorithm for engineering applications [J]. Sensors, 2022, 22(3): 855.
- [27] University of Wyoming. Wyoming weather web [DB/OL]. (2022 – 9–28) [2023 – 11 – 28]. <http://weather.uwyo.edu/up-perair/buffraob.shtml>.

收稿日期: 2023-12-11; 网络首发日期: 2024-06-25

作者简介:

汪颖翔(1990), 女, 高级工程师, 硕士, 研究方向为电网规划及碳市场、碳资产, 50893862@qq.com;

邓广宇(1999), 男, 硕士研究生, 研究方向为高电压与绝缘技术, 1419234964@qq.com;

张晓星(1972), 男, 通信作者, 教授, 博士, 研究方向为电气设备在线监测与绝缘状态评估, xiaoxing.zhang@outlook.com。

(上接第 195 页 Continued from Page 195)

- [31] 邵必林, 纪丹阳. 基于 VMD-SE 的电力负荷分量的多特征短期预测[J]. 中国电力, 2024, 57(4): 162 – 170.  
SHAO Bilin, JI Danyang. Multi-feature short-term prediction of power load components based on VMD-SE [J]. Electric Power, 2024, 57(4): 162 – 170.
- [32] 王延峰, 曹育晗, 孙军伟. 基于多策略改进金豺算法优化 LSTM 的短期电力负荷预测[J]. 电力系统保护与控制, 2024, 52(14): 95 – 102.  
WANG Yanfeng, CAO Yuhang, SUN Junwei. Short-term power load forecasting based on multi-strategy improved golden jackal algorithm-optimized LSTM [J]. Power System Protection and Control, 2024, 52(14): 95 – 102.
- [33] 荆志朋, 柴林杰, 胡诗尧. 基于改进 LSTM-VAE 的配电网异常负荷检测方法研究[J]. 电测与仪表, 2024, 61(9): 71 –

76.

JING Zhipeng, CHAI linjie, HU Shiyao. Research on abnormal load detection method for distribution network based on improved LSTM-VAE [J]. Electrical Measurement & Instrumentation, 2024, 61(9): 71 – 76.

收稿日期: 2025-01-26; 网络首发日期: 2025-04-10

作者简介:

史茗元(2002), 男, 硕士研究生, 研究方向为面向新型电力系统和能源互联网的人工智能技术, 2470754@stu.neu.edu.cn;

钱本华(1999), 男, 硕士研究生, 研究方向为微电网分布式协同控制, 2714550698@qq.com;

王睿(1993), 男, 通信作者, 副教授, 博士生导师, 博士, 研究方向为能源互联网中分布式电源的协同优化, wangrui@ise.neu.edu.cn。