

基于因果分析与 CNN 模型的临汾市 O₃ 浓度预测

宋 朕^{1,2}, 营 娜^{1,2}, 王璟煦^{1,2}, 朱向哲^{1,2}, 薛志钢^{1,2}

1. 中国环境科学研究院大气环境研究所, 北京 100012

2. 中国环境科学研究院环境基准与风险评估国家重点实验室, 北京 100012

摘要:近年来,我国 O₃ 浓度上升明显。临汾市既是我国三大焦煤生产基地之一,又属于大气污染防治重点区域,因此开展临汾市 O₃ 浓度预测研究对于该区域 O₃ 污染防控以及空气质量进一步改善具有重要意义。基于 2020—2022 年临汾国控点的污染物监测数据及气象数据,采用因果分析方法研究站点间的 O₃ 空间分布及联系,通过卷积神经网络 (CNN) 模型预测未来 O₃ 浓度。结果显示,因果分析可为模型筛选空间特征,使结合该空间特征构建的预测模型 CNN-1 的预测精度得到有效提升。临汾市各站点间存在显著的 O₃ 传输规律,市委与城南两个站点对其他站点影响大,临钢医院站点受其他站点影响较小。所构建的 CNN 模型在夏秋季拟合更佳。削减市委和城南站点的 O₃ 浓度,可有效改善临钢医院站点的空气质量。该方法可精准识别 O₃ 传输源,为准确预测并提前应对 O₃ 污染提供技术支持。

关键词: O₃; 收敛交叉映射; 空间特征; 卷积神经网络; 浓度预测

中图分类号: X511

文献标志码: A

文章编号: 1002-6002(2025)S1-0034-07

DOI: 10.19316/j.issn.1002-6002.2025.S1.05

Prediction of O₃ Concentration for Linfen City Based on Causality and CNN Model

SONG Zhen^{1,2}, YING Na^{1,2}, WANG Jingxu^{1,2}, ZHU Xiangzhe^{1,2}, XUE Zhigang^{1,2}

1. Institute of Atmospheric Environment, Chinese Research Academy of Environmental Sciences, Beijing 100012, China

2. State Key Laboratory of Environmental Criteria and Risk Assessment, Chinese Research Academy of Environmental Sciences, Beijing 100012, China

Abstract: In recent years, there has been a marked increase in O₃ concentrations in China. As one of the China's three major coking coal bases and a key area in the national strategic layout for air pollution prevention and control, research on O₃ concentration prediction in Linfen City is of significant importance for controlling local O₃ pollution and further improving regional air quality. Based on pollutant monitoring data and meteorological data from national control sites in Linfen City from 2020 to 2022, this study applies causal analysis methods to examine the spatial distribution and interconnections of O₃ among monitoring sites. A Convolutional Neural Network (CNN) model is employed to predict future O₃ concentrations. The results show that causal analysis helps screen spatial features for the model, and by integrating these features, a predictive model termed CNN-1 is developed to enhance forecasting accuracy. This study reveals notable O₃ transport patterns among the sites in Linfen City; the Municipal Committee and Chengnan sites exhibit considerable influence on other sites, whereas the Lingang Hospital site is relatively less affected by others. The established CNN model demonstrates better fitting performance in summer and autumn. The research indicates that reducing O₃ concentrations at the Municipal Committee and Chengnan sites can effectively improve air quality at the Lingang Hospital site. This proposed method can accurately identify O₃ transport sources and facilitate early prediction and response to O₃ pollution.

Keywords: O₃; convergent cross mapping; spatial features; convolutional neural network (CNN); concentration prediction

全球性的空气污染问题对公众健康构成了严重威胁,这一点已获得广泛的国际关注^[1-3]。我国的快速工业化与城市化进程正持续加剧区域性的大气环境压力^[4-5]。近年来,我国在 PM_{2.5} 污染治理方面成效显著^[4],但 O₃ 污染问题却日益突出。

据统计,2022 年多数重点城市 O₃ 浓度呈上升趋势, O₃ 对空气污染的贡献加大^[6-8]。O₃ 污染不仅威胁人体健康,还会抑制农作物的正常生长,造成经济损失^[9-12]。临汾市作为重要煤炭产业基地,近年来 O₃ 浓度持续超标,防治形势严峻^[13]。

收稿日期: 2025-10-13; 修订日期: 2025-10-29

基金项目: 国家重点研发计划(2023YFC3705603); 大气重污染成因与治理攻关项目(DQGG202111)

第一作者简介: 宋 朕(1999-), 男, 河北唐山人, 硕士。

通讯作者: 薛志钢

在大气环境保护新形势下,建立精准的 O₃ 污染预测体系成为关键需求。运用机器学习等先进技术提升城市 O₃ 污染防控能力,具有重要的理论价值和实践意义^[14-15]。监测站点距离较近时,传统线性相关方法常因站点间 O₃ 浓度的高相关性,而难以有效解析其传输过程。本文采用可识别因果关系的深度学习模型,拟精确识别污染传输路径,旨在实现站点级、小时级 O₃ 污染精准预报。

1 数据与方法

1.1 研究区域和数据来源

临汾市位于山西西南汾河盆地,三面环山,呈“凹”形地貌,不利于污染物扩散。作为重化工基地,临汾市煤炭、焦化等产业集中,大量排放 VOCs 和 NO_x,造成区域性大气污染突出。

本研究的研究数据涵盖了临汾市 2020—2022 年空气污染及气象数据。其中,空气污染物浓度数据来源于山西省临汾生态环境监测中心,整合了当地 6 个国控站点监测结果,监测指标包括 NO₂ (μg/m³)、SO₂ (μg/m³)、PM_{2.5} (μg/m³)、PM₁₀ (μg/m³)、O₃ (μg/m³) 和 CO (mg/m³)。同期气象数据则取自中国气象数据网 (<http://data.cma.gov.cn/>),包含了气温(TEM)、气压(PRS)、露点温度(DPT)、能见度(VIS)、相对湿度(RHU)及 10 min 平均风速(WIN_10)。

1.2 研究方法

1.2.1 数据预处理

工商学校监测站点于 2021 年停止运行,导致数据缺失严重,排除该站点所有资料,剔除异常数据,采用拉格朗日插值法处理数据中的缺失值,计算方法如下:

对于一个已知函数 $g(x)$ 的第 $i+1$ 个离散数据点 (x_j, y_j) ,若所有 x_j 均不相等,则可以通过构建一个多项式来逼近该函数。如公式(1)所示:

$$L(x) = \sum_{j=0}^i y_j l_j(x) \quad (1)$$

其中, $l_j(x)$ 代表拉格朗日基本多项式,见公式(2)。

$$l_j(x) = \prod_{k=0, k \neq j}^i \frac{x - x_k}{x_j - x_k} = \frac{x - x_0}{x_j - x_0} \dots \frac{x - x_{j-1}}{x_j - x_{j-1}} \frac{x - x_{j+1}}{x_j - x_{j+1}} \dots \frac{x - x_i}{x_j - x_i} \quad (2)$$

式中: x_j 的取值为 1;对于其他点 x_k ,当 $k \neq j$ 时,取

值为 0。随后,将待插值点的 x 值代入该公式,即可求得缺失值的估计值,从而完成数据集填补。

1.2.2 因果分析

收敛交叉映射 (CCM) 是基于混沌动力学原理的非线性因果分析技术,通过相空间重构捕获时序变量的动态特征。该方法的核心思想是通过相空间重构来捕捉时间序列变量的内在动态特性。在应用 CCM 模型时,假设存在两个动态耦合系统,并从中观测到长度为 L 的两个时间序列,分别记为 X 和 Y 。

$$X = X(1), X(2), X(3), X(4), \dots, X(L) \quad (3)$$

$$Y = Y(1), Y(2), Y(3), Y(4), \dots, Y(L) \quad (4)$$

通过滞后变量 τ (取最小单位 1),创建 X 与 Y 的时滞向量,形成影子流形 M_X 与 M_Y 。

$$x(t) = \{X(t), X(T - \tau), X(T - \tau), X(T - \tau), \dots, X[t - (E - 1)\tau]\} \quad (5)$$

$$y(t) = \{Y(t), Y(T - \tau), Y(T - \tau), Y(T - \tau), \dots, Y[t - (E - 1)\tau]\} \quad (6)$$

式中: $\tau > 0$; E 为影子流形的嵌入维度; $1 + (E + 1) \leq t \leq L$ 。最优嵌入维数 E 的筛选通过预映射方法完成。通过在影子流形 M_X 上确定与 $X(t)$ 最邻近的 $E + 1$ 个邻近点,并据此构造相应的权重 w_i ,对响应变量 Y 对应的 $E + 1$ 个取值进行加权线性组合,从而形成 $Y(t)$ 的交叉映射估计量。

$$\hat{Y}(t) | M_X = \sum_{i=1}^{E+1} w_i Y(t_i) \quad (7)$$

式中: $\hat{Y}(t) | M_X$ 代表 $Y(t)$ 的交叉映射估计; $Y(t_i)$ 代表 $Y(t)$ 的同期值; w_i 表示 $X(t)$ 与其在影子流形 M_X 上第 i 个邻近点之间的间隔。 w_i 计算公式如下:

$$w_i = u_i / \sum_{j=1}^{E+1} u_j \quad (8)$$

$$u_i = \exp\{-d[x(t), x(t_i)] / d[x(t), x(L)]\} \quad (9)$$

式中: \exp 表示指数函数, d 为向量间的欧氏距离。交叉映射估计值与真实值之间的相关系数称为 CCM 相关系数,表示响应因素对触发因素的预测能力。

$$\rho_{x \rightarrow y} = \text{cor}[Y(t), \hat{Y}(t) | M_X] \quad (10)$$

随着时长 L 的增加,当且仅当预测值收敛时,CCM 因果关系成立。

1.2.3 梯度提升决策树 (XGBoost)

XGBoost 作为梯度提升框架的改进版本,通

过集成多棵决策树实现高效预测。设 $F_k(x)$ 为第 k 棵树的预测输出, $T_k(x)$ 为 x 在第 k 棵树上的叶子节点区域, w_{qk} 为第 k 棵树中第 q 个叶子节点的权重, y_i 为第 i 个样本目标, 则 XGBoost 的实现方法如下:

$$\hat{y}_i = \sum_{k=1}^K F_k(x_i) = \sum_{k=1}^K \sum_{q=1}^Q w_{qk} I(x_i \in T_{qk}) \quad (11)$$

式中: K 和 Q 分别代表决策树的数量与叶子节点的数量; $I(x_i \in T_{qk})$ 为指示函数, 若样本 x_i 位于第 q 个叶子节点所对应的区域内, 则该函数取值为 1, 反之则为 0。

$$L(j) = \sum_{i=1}^n l[y_i, F_{j-1}(x_i) + f_j(x_i)] + \Omega(f_j) \quad (12)$$

式中: l 为损失函数, $\Omega(f_j)$ 表示正则化项。采用 L_1 和 L_2 正则化来控制相关复杂度。本文将 XGBoost 主要作为预测模型的特征筛选与重要性排序工具进行应用。

1.2.4 卷积神经网络(CNN)

CNN 的设计灵感源于感受野理论。该理论源自猫视觉皮层研究, 其发现神经元会对局部刺激产生特异性反应。LECUN 等^[16] 据此构建 CNN 架构, 通过局部感知与参数复用机制实现高效特征学习。如图 1 所示, 该网络由卷积层(提取空间特征)、池化层(压缩维度提升鲁棒性)、全连接层(整合信息)、分类器(输出预测)4 部分组成, 在视觉任务中表现优异。本研究用 CNN 模型的关键超参数设置如下: 样本数量为 64, 训练轮次为 20, 学习率为 0.001, 隐藏层维度为 100。




图 1 CNN 模型结构

Fig. 1 CNN model architecture

2 结果与讨论

2.1 模型训练特征筛选

利用 CCM 方法得到各站点的 O_3 传输关系,

如图 2 所示。市委站点对其他站点的传输影响显著。以往研究表明, 5—9 月偏南风时 O_3 容易超标。城南站点受南面污染气团输入影响, O_3 污染的影响范围较广。临钢医院站点由于地理位置相对较远, O_3 浓度受区域传输影响较小。为减小其他因素干扰, 选择临钢医院站点作为实验对象。




图 2 站点 O_3 浓度传输网络模型

Fig. 2 Concentration transport network model for site O_3

ACF 自相关系数分析显示, 临汾 O_3 浓度呈 24 h 周期性自相关(图 3), 且滞后时间越长, O_3 时间序列的自相关性越弱, 预测效果越差。因此, 以 24 h 作为模型训练的时间尺度。




图 3 O_3 浓度时间序列自相关图

Fig. 3 Autocorrelation plot of O_3 concentration time series

运用 XGBoost 评估 24 h O_3 预测特征重要性发现(表 1), 时序 O_3 数据贡献最大, 当前时刻 O_3 浓度得分达 0.729 2, 显著领先其他特征。气象要素中, 近 3 h 气温及当前湿度、风速影响突出。统计特征显示, 气压、温度和湿度出现频率最高, 证实气象条件对 O_3 预测具有关键影响。

表 1 未来 24 h 重要特征前 30 名
Table 1 Top 30 key features for the next 24 hours

名次	特征	得分	名次	特征	得分
1	O ₃ _0	0.729 2	16	O ₃ _17	0.424 7
2	O ₃ _3	0.481 7	17	O ₃ _21	0.422 2
3	O ₃ _13	0.481 4	18	O ₃ _4	0.421 4
4	O ₃ _15	0.462 8	19	O ₃ _10	0.418 1
5	O ₃ _1	0.457 3	20	O ₃ _2	0.417 6
6	O ₃ _6	0.456 3	21	O ₃ _8	0.414 3
7	O ₃ _14	0.455 7	22	O ₃ _9	0.372 9
8	O ₃ _7	0.452 9	23	TEM_0	0.228 6
9	O ₃ _5	0.449 9	24	RHU_0	0.173 3
10	O ₃ _19	0.445 2	25	O ₃ _23	0.129 2
11	O ₃ _18	0.444 7	26	NO ₂ _0	0.121 7
12	O ₃ _20	0.438 5	27	WIN_10_0	0.113 4
13	O ₃ _16	0.430 2	28	TEM_1	0.112 6
14	O ₃ _12	0.425 7	29	O ₃ _22	0.107 6
15	O ₃ _11	0.424 8	30	TEM_2	0.105 7

注:各特征结尾数值(0、3、13 等)代表相对于当前时刻的未来小时数。下同。

表 2 列出了重要性评分最低的 30 项特征,其中未来 23 h SO₂ 浓度仅得 0.006 4 分,位居末位。低分特征中,污染物以 SO₂ 和 CO 为主,气象参数则主要包含 10 min 风速均值和能见度,这种现象或与临汾近期频繁出现的静稳天气条件相关。基

于上述分析,最终确定 O₃、NO₂、PM₁₀、PM_{2.5}、气压、温度、湿度 7 个关键指标,用以构建基础预测模型(CNN-0)。经测试,CNN-0 模型的预测误差随步长的增加而上升,其 24 h 内的均方根误差从 0.334 增大至 0.444。

表 2 未来 24 h 重要特征倒数 30 名
Table 2 Bottom 30 key features for the next 24 hours

名次	特征	得分	名次	特征	得分
1	SO ₂ _23	0.006 4	16	SO ₂ _21	0.029 5
2	NO ₂ _23	0.014 5	17	SO ₂ _19	0.029 6
3	WIN_10_23	0.016 5	18	VIS_23	0.030 4
4	PM ₁₀ _23	0.019 2	19	SO ₂ _20	0.030 4
5	WIN_10_22	0.019 5	20	SO ₂ _17	0.030 5
6	CO_23	0.021 4	21	VIS_20	0.031 4
7	WIN_10_21	0.021 7	22	CO_20	0.031 4
8	WIN_10_20	0.024 1	23	NO ₂ _22	0.032 3
9	WIN_10_19	0.024 4	24	CO_21	0.032 3
10	PM _{2.5} _23	0.026 9	25	WIN_10_16	0.032 3
11	VIS_22	0.028 0	26	CO_22	0.032 8
12	WIN_10_18	0.028 9	27	SO ₂ _1	0.033 3
13	VIS_21	0.028 9	28	WIN_10_17	0.033 7
14	SO ₂ _18	0.029 1	29	VIS_15	0.034 0
15	SO ₂ _22	0.029 4	30	VIS_12	0.034 0

2.2 实际预测结果分析

2.2.1 O₃ 浓度实际预测误差分析

采用 2022 年全年数据验证 CNN-0 模型 24 h 预测性能。图 4 显示,预测值与实测 O₃ 浓度高度吻合,多数偏差在 30 μg/m³ 以内。上述分析结果表明,CNN-0 模型具备良好的长期预测精度和稳定性。

图 5 为模型的不同月份预测结果的决定系数 (R^2)、均方根误差 (RMSE) 和平均绝对误差

(MAE),图 6 为 O₃ 预测浓度月均值。

由图 5 与图 6 可知,CNN-0 模型月度预测精度存在季节性差异,O₃ 浓度月均值变化趋势与 MAE 和 RMSE 相似。RMSE 方面,夏季较大,6 月达到峰值,为 25.43 μg/m³;冬季较小,12 月仅为 11.56 μg/m³。整体上,误差指标与 O₃ 浓度呈正相关。此外,各月 R^2 均超 0.6,其中 5、7、9 月拟合度突出 (>0.83)。污染季中,模型在 7 月的综合表现最优, R^2 达 0.87,且误差控制良好。




图4 O₃ 预测值与真实值散点图

Fig.4 Scatter plot of predicted and actual O₃ values

CNN-1 模型,并与 CNN-0 模型进行对比,探讨空间传输对 O₃ 浓度预测的影响。






图6 2022年 O₃ 预测浓度月均值


Fig.6 Monthly average forecast concentration of O₃ in 2022



(a) 不同月份RMSE



(b) 不同月份R²



(c) 不同月份MAE

图5 CNN模型不同月份预测结果的RMSE、R²、MAE柱状图

Fig.5 Bar chart of RMSE, R², and MAE for the CNN model across different months

在开展预测的前13 h内(图7),CNN-1的表现优于CNN-0, RMSE和MAE分别低0.77 μg/m³和0.64 μg/m³, R²高0.014,表明在短期预测中,空间特征的贡献明显。在14~24 h时段,CNN-1的性能波动增大,整体效果与CNN-0接近,其在长时序预测中的优势减弱。这可能是由于监测站点数量有限,空间信息不够充足,且忽略了气象要素如风场的动态变化的影响。随着预测时长的延长,单一空间浓度特征已难以全面反映污染物输送过程,限制了模型的学习效率。

借助XGBoost模型对各特征的重要性进行量化分析(表3),结果表明,城南站点和市委站点在24 h预测中的贡献最高,验证了站点间浓度存在显著关联性。这不仅说明空间特征确实影响CNN预测效果,提升了CNN-1的可解释性,同时印证了运用CCM方法分析O₃空间传输机制的合理性。

2.3 O₃ 污染治理建议

以临钢医院站点为目标站点,选取2020年6月15日开展控制实验:将城南站点和市委站点O₃浓度降低20%,运用CNN-1模型预测临钢医院站点未来24 h O₃浓度变化,并与原始预测值对比。如图8所示,上游站点O₃管控会对下游站点产生明显影响,临钢医院站点24 h内O₃浓度整体下降,大部分时段的降幅超过5%。其中,预测时长为3 h和9 h时的降幅最为显著,分别达20.84%和19.76%。研究结果揭示,对市委站点和城南站点实施O₃污染管控,能有效缓解临钢医院站点污染程度。因此,建议建立城南、市委、临钢医院3站联防联控机制,从源头和传输路径双向发力,提升O₃污染防治成效。

2.2.2 空间特征模型对比

基于CCM分析结果,选取城南站点和市委站点O₃监测数据作为空间特征,对基础CNN模型(CNN-0)进行重新训练,构建考虑空间特征的




图 7 模型性能对比

Fig. 7 Model performance comparison

表 3 未来 24 h O₃ 浓度预测重要性得分

Table 3 Predicted O₃ concentration importance scores for the next 24 hours

特征	重要性得分	特征	重要性得分
城南站点 O ₃ _0	0.644 3	TEM_0	0.178 4
城南站点 O ₃ _12	0.210 2	城南站点 O ₃ _9	0.174 6
市委站点 O ₃ _21	0.202 3	城南站点 O ₃ _19	0.172 0
市委站点 O ₃ _0	0.201 3	城南站点 O ₃ _4	0.172 0
城南站点 O ₃ _20	0.189 8	城南站点 O ₃ _5	0.170 2




图 8 降低 20% O₃ 浓度后的预测值降低百分比

Fig. 8 Percentage reduction in predicted values following a 20% decrease in O₃ concentration

3 结论

本研究运用 CCM 因果分析方法探究临汾市 O₃ 空间传输机制,并构建 CNN 深度学习模型开展浓度预测与防控策略研究。研究发现,O₃ 污染期内,各站点间的相互影响显著,其中市委站点和城南站点表现出较强的输出特性,而临钢医院站点受外部传输影响相对较小。这为后续建模和开展控制实验奠定了基础。CNN 模型在 2022 年 O₃ 浓度预测中表现优异,预测结果的 RMSE 和 MAE 分别为 17.961 µg/m³ 和 13.174 µg/m³, R² 高达 0.885。模型预测精度呈现明显的季节差异,夏秋季预测精度高于春冬季。通过融入市委站点和城南站点数据,改进后的 CNN 模型的短期预测精度得到有效提升,其 RMSE 和 MAE 分别降低了

0.77 µg/m³ 和 0.64 µg/m³,验证了空间特征对于 O₃ 浓度预测具有重要影响。基于模型模拟结果,当市委站点和城南站点 O₃ 排放浓度降低 20% 时,临钢医院站点 O₃ 浓度可降低 5%~20%,这进一步验证了协同管控的有效性。

参考文献 (References):

[1] MURRAY C J L, ARAVKIN A Y, ZHENG P, et al. Global Burden of 87 Risk Factors in 204 Countries and Territories, 1990-2019: A Systematic Analysis for the Global Burden of Disease Study 2019 [J]. The Lancet, 2020, 396: 1 223-1 249.

[2] BOWDALO D, PETETIN H, JORBA O, et al. Compliance with 2021 WHO Air Quality Guidelines Across Europe Will Require Radical Measures [J]. Environmental Research Letters, 2022, 17 (2): 021002.

[3] MARTINS N R, GRAÇA G C. Impact of PM_{2.5} in Indoor Urban Environments: A Review [J]. Sustainable Cities and Society, 2018, 42: 259-275.

[4] 贾艳青, 兰杰, 刘秀丽. 山西省大气污染特征及对公众健康的空间影响 [J]. 中国环境监测, 2023, 39 (6): 78-89.

JIA Yanqing, LAN Jie, LIU Xiuli. Spatio-Temporal Evolution of Air Pollution and Its Spatial Impact on Public Health in Shanxi Province [J]. Environmental Monitoring in China, 2023, 39 (6): 78-89.

[5] 麦尔哈巴·图尔贡, 王鑫鑫, 史兴民. 西安市区主

- 要大气污染物暴露水平及健康风险评估[J]. 中国环境监测, 2024, 40(4): 100-110.
- TURHUN Marhaba, WANG Xinxin, SHI Xingmin. Exposure Level and Health Risk Assessment of Major Air Pollutants in Xi'an City [J]. Environmental Monitoring in China, 2024, 40(4): 100-110.
- [6] 生态环境部. 2021年中国生态环境状况公报(摘录)[J]. 环境保护, 2022, 50(12): 61-74.
- Ministry of Ecology and Environment. 2021 Report on the State of the Ecology and Environment in China (Excerpt) [J]. Environmental Protection, 2022, 50(12): 61-74.
- [7] 张晓娟. 基于Stacking模型的北京市近地面臭氧浓度预测[D]. 太原: 山西大学, 2023.
- [8] WEI J, LI Z Q, XUE W H, et al. The ChinaHighPM₁₀ Dataset: Generation, Validation, and Spatiotemporal Variations from 2015 to 2019 Across China [J]. Environment International, 2021, 146: 106290.
- [9] 北京大学统计科学中心环境统计组. 空气质量评估报告(十): “3+110”城市2013—2022年区域污染状况评估[R]. 北京: 北京大学, 2023.
- [10] ORELLANO P, REYNOSO J, QUARANTA N, et al. Short-Term Exposure to Particulate Matter (PM₁₀ and PM_{2.5}), Nitrogen Dioxide (NO₂), and Ozone (O₃) and All-Cause and Cause-Specific Mortality: Systematic Review and Meta-analysis [J]. Environment International, 2020, 142: 105876.
- [11] XIAO Q Y, GENG G N, XUE T, et al. Tracking PM_{2.5} and O₃ Pollution and the Related Health Burden in China 2013-2020 [J]. Environmental Science & Technology, 2022, 56(11): 6922-6932.
- [12] FENG Z Z, SUN J S, WAN W X, et al. Evidence of Widespread Ozone-Induced Visible Injury on Plants in Beijing, China [J]. Environmental Pollution, 2014, 193: 296-301.
- [13] 宋晓伟, 郝永佩, 朱晓东, 等. 临汾市臭氧污染变化特征、气象影响及输送源分析[J]. 中国环境科学, 2022, 42(8): 3626-3634.
- SONG Xiaowei, HAO Yongpei, ZHU Xiaodong, et al. Variations in Ozone Pollution and Their Meteorological Influences and Transmission Sources in Linfen City of China [J]. China Environmental Science, 2022, 42(8): 3626-3634.
- [14] 李娟, 尉鹏, 戴学之, 等. 基于机器学习方法的西安市数值模拟优化研究[J]. 环境科学研究, 2021, 34(4): 872-881.
- LI Juan, WEI Peng, DAI Xuezhì, et al. Optimization of Numerical Simulation in Xi'an Based on Machine Learning Methods [J]. Research of Environmental Sciences, 2021, 34(4): 872-881.
- [15] 高帅, 胡红萍, 李洋, 等. 基于MFO-SVM的空气质量指数预测[J]. 中北大学学报(自然科学版), 2018, 39(4): 373-379.
- GAO Shuai, HU Hongping, LI Yang, et al. Prediction of Air Quality Index Based on MFO-SVM [J]. Journal of North University of China (Natural Science Edition), 2018, 39(4): 373-379.
- [16] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-Based Learning Applied to Document Recognition [J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.