DOI: 10.3969/j.issn.1673-6141.2025.05.005
CSTR: 32220.14.gk202505005

近地面一次气态污染物遥感反演—以山西吕梁为例

刘 旺[1], 秦 凯[1*], 陆凌霄[1], 王璐瑶[2], 史来亮[3]

(1 中国矿业大学环境与测绘学院, 江苏 徐州 221000;
2 中国科学院地球环境研究所, 陕西 西安 710061;
3 山西省地球物理化学勘查院, 环境遥感应用山西省重点实验室, 山西 运城 044000)

摘 要: 一氧化碳 (CO)、二氧化硫 (SO_2)、氮氧化物 (NO_x) 等一次气态排放物是空气污染源头控制的重要对象，卫星遥感可实现对其大范围的浓度监测，是对地面站点监测的重要补充。本文基于山西省国控站点、吕梁市微型监测站点、Sentinel-5P/Tropomi 卫星和 MODIS 的相关观测数据、气溶胶光学厚度、气象及其他辅助数据，开展了吕梁市地区 0.01° 空间分辨率的一次气态排放物浓度估算与制图研究。首先使用 DINEOF 方法进行卫星遥感缺失数据重构，然后采用极端梯度提升 (XGBoost) 方法进行浓度估算。研究结果表明，相关一次气态排放物的估算浓度与站点观测值具有良好的一致性，反演结果能更准确地反映城市不同区域的一次气态排放物浓度分布差异性，弥补了因国控站点分布稀疏带来的缺陷，为城市空气质量精准管控提供了更好的服务。

关 键 词: 一次气态污染物; 机器学习; 卫星遥感; 浓度反演
中 图 分 类 号 : TP79 **文 献 标 识 码 :** A **文章编号:** 1673-6141(2025)05-610-012

Remote sensing inversion of primary gaseous pollutants near surface—Taking Lüliang, Shanxi as an example

LIU Wang[1], *QIN Kai*[1*], *LU Lingxiao*[1], *WANG Luyao*[2], *SHI Lailiang*[3]

(1 College of Surveying and Mapping, China University of Mining and Technology, Xuzhou 221000, China;
2 Institute of Earth Environment, Chinese Academy of Sciences, Xi′an 710061, China;
3 Shanxi Key Laboratory of Environmental Remote Sensing Applications, Geophysical and Geochemical Exploration Institute of Shanxi Province, Yuncheng 044000, China)

Abstract: Primary gaseous pollutants such as carbon monoxide (CO), sulfur dioxide (SO_2) and nitrogen oxides (NO_x) are important targets for controlling sources of air pollution. Satellite remote sensing can achieve large-scale concentration monitoring of these pollutants, which serves as a significant supplement to ground-based station monitoring. Based on the observation data including primary gaseous pollutants, aerosol optical depth, meteorological and other auxiliary data from Shanxi Province's national control stations, Lüliang City's micro monitoring stations, Sentinel-5P/Tropomi satellite and MODIS, this work

基金项目: 国家自然科学基金 (42375125)
作者简介: 刘 旺 (2000-), 湖南衡阳人, 硕士研究生, 主要从事机器学习应用大气气体反演方面的研究。E-mail: TS22l60040A31TM@cumt.edu.cn
导师简介: 秦 凯 (1981-), 山西长治人, 博士, 教授, 博士生导师, 主要从事大气环境遥感、碳监测、遥感信息方面的提取研究。E-mail: qinkai@cumt.edu.cn
收稿日期: 2023-11-03; **修改日期:** 2023-11-28
*通信作者。

conducts a study on the estimation and mapping of the concentrations of these primary gaseous pollutants (CO, NO_2, SO_2) with a spatial resolution of 0.01° in Lüliang City, China. Firstly, the DINEOF method is employed to reconstruct the missing data of satellite remote sensing, and then the eXtreme Gradient Boosting (XGBoost) method is utilized for concentration estimation. The finding reveals a strong correlation between the estimated concentrations and the station observation data of primary gaseous emissions, and the inversion results effectively illustrate the variations in the distribution of primary gaseous emissions across different regions within the city. It is indicated tht this approach compensates for the limitations posed by the sparse distribution of national control stations and enhances the precision of urban air quality control.

Key words: primary pollutant emission; machine learning; satellite remote sensing; concentration inversion

0　引　言

一氧化碳 (CO)、二氧化硫 (SO_2) 和氮氧化物 (NO_x) 等直接排入环境的污染物，其物理和化学性状未发生变化，被称为一次气态污染物[1]。这些一次污染物进入大气后，可能转化为二次污染物，或与其它物质发生化学反应，或催化其它污染物生成，进而对人体健康产生危害、对大气环境质量产生影响，是我国主要的空气污染源之一[2-4]。因此，对于一次污染物浓度的准确测量是评估和减轻人为排放对环境的影响、为空气污染物与温室气体进行协同控制[5]、针对空气污染和其他环境问题实施科学减排策略的关键[6]。卫星遥感技术具有大范围覆盖的优势，是对地面观测的有益补充。目前利用卫星遥感观测数据估算近地面气体浓度，常见的方法主要有比例因子法[7]、物理经验法[8]和统计模型法 3 类[9]。比例因子法利用大气化学传输模型 (CTM) 模拟的比例关系因子，基于卫星数据实现近地面细颗粒物浓度的估算。统计模型法通过建立回归统计模型进行浓度估算，包括 Wang 和 Christopher 建立的简单线性回归方程[10]、预测水平显著高于简单线性回归的多元线性回归模型方法[11-13]、随机森林 (RF)[14,15]、地理加权回归模型 (GWR)[16]、地理时空加权回归方法(GTWR)[17,18]、神经网络[19,20]等方法。

在卫星选用上，早期多选用 GOME (Global ozone monitoring experiment)[21]、GOME-2[22]、OMI (Ozone monitoring instrument)[23]、日本葵花 8 号卫星 (Himawari-8/AHI)[24]等反演近地面气体浓度的遥感估算。目前国产的资源卫星、环境卫星、高分系列以及近年来欧洲航天局 (ESA) 发射的哨兵系列、韩国的 GEMS 传感器卫星遥感数据等都被广泛应用于近地面气体浓度遥感估算[25]。

然而，受天气条件、传感器运行故障等因素限制，卫星数据通常存在大量无规律缺失，影响数据时空连续性[26]。对缺失数据进行有效重构可以提高数据的利用率，因此本文利用经验正交函数插值 (DINEOF)[27] 方法对对流层监测仪 (TROPOMI) 卫星缺失数据进行重构。该方法基于长时间序列观测数据集，通过构建经验插值模型，对缺值区域的观测值进行填补[28,29]。结果表明重构的数据具有较好的时空连续性，为进一步反演提供了更多的学习样本。随后将重构数据与地面站点的数据作为输入，利用机器学习方法反演近地面的气体浓度，得到区域内当天的精细化气体浓度分布图，为区域环境监测以及环境污染政策的制定提供参考。

1 研究区域和数据

1.1 研究区域概况

本文研究区域为吕梁市 (36°43′N～38°43′N，110°22′E～112°19′E)，属于山西省的地级市，位于山西中部西侧。该区域西濒黄河，与陕北隔河相望；东临汾水，毗邻晋中；北接忻州，南连临汾。据我国生态环境部发布的2022年全国空气质量城市排名，吕梁市周边城市大部分位于倒数后20名内 (https://www.mee.gov.cn/ywdt/xwfb/202301/t20230128_1014006.shtml)。吕梁市区大气污染物浓度偏高，除本地排放叠加外，更因南北纵贯的山脉阻滞气流、削弱扩散，使污染物易聚难散。

1.2 数据

1.2.1 Sentinel-5P/Tropomi

Sentinel-5P是ESA于2017年10月13日发射的全球大气污染监测卫星，搭载在该卫星上的TROPOMI[30]的轨道扫描宽幅为2600 km，最高空间分辨率 (2019年8月6日后) 为3.5 km × 5.5 km，位于太阳同步轨道，每日可覆盖全球一次。TROPOMI通过在大气层顶部采集扫描紫外到可见 (270～500 nm)、近红外 (710～770 nm) 和短波红外 (2314～2382 nm) 波长范围内地球反射的太阳辐射来实现对全球大气成分的监测，其主要监测的大气成分包括：NO_2、SO_2、O_3、CO、HCHO等重要的与人类活动密切相关的指标。其中，NO_2和SO_2是基于紫外波段光谱采用差分光学吸收光谱技术 (DOAS) 反演获得；CO采用改进的太阳短波红外反演算法 (SCIOR) 获得。已有相关研究对TROPOMI产品精度进行了验证对比，与OMI相比，TROPOMI对NO_2和SO_2的监测具有更优越的性能和更高的精度[31,32]。对2019年江苏省地面监测NO_2和TROPOMI NO_2的检验和验证研究表明，两者在月平均尺度上的相关系数高达0.9[33]；而TROPOMI CO与全球总碳柱观测网 (TCCON) 站点观测的CO总柱浓度相比具有很好的一致性，表明TROPOMI CO数据产品已达到发射前的要求[34,35]。

本研究使用的TROPOMI CO、NO_2、SO_2数据产品为2022年1月1日至2022年12月31日的离线处理数据，从谷歌地球引擎下载，TROPOMI CO下载网址为 (https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S5P_OFFL_L3_CO)、TROPOMI NO_2下载网址为 (https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S5P_OFFL_L3_NO_2)、TROPOMI SO_2下载网址为 (https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S5P_OFFL_L3_SO_2)。

1.2.2 AOD数据

MODIS (Moderate-resolution imaging spectroradiometer) 中分辨率成像光谱仪，由美国宇航局研制，主要搭载在Terra和Aqua卫星上[36]。MODIS仪器的地面分辨率为250 m、500 m和1000 m，扫描宽幅为2330 km，每日或每两日可获取一次全球观测数据[36]。本研究使用的是2022年1月1日至2022年12月31日MCD19A2 V6.1数据产品，时间分辨率为每天，空间分辨率为1 km，该产品是对MODIS的L1级数据采用多角度大气校正算法 (MAIAC) [37]得到，数据从谷歌地球引擎下载，下载网址为 (https://developers.google.com/earth-engine/datasets/catalog/MODIS_061_MCD19A2_GRANULES)。

1.2.3 地面站点数据

中国环境监测总站 (CNEMC)[38]的国控站点数据，每小时实时发布一次我国的环境监测数据，采样的内

容包括 SO_2、NO_2、PM_{10}、$PM_{2.5}$ 等监测指标 (http://106.37.208.233:20035[2023-07-10])。国控站点数值通常被认为是地面数据真值，用来验证气体反演精度[39]。如图 1 (a) 所示，研究选取了 2022 年山西省的国控站点数据，国控站点在每个市都有分布，一共有 58 个国控站点。同时在结果部分使用了位于吕梁市的国控站点的数据进行对比验证，并且在实验中加入了吕梁市区当地的微型环境监测站点，如图 1 (b) 所示，一共有 69 个当地站点，分布比较集中，大多在吕梁市区的中心。

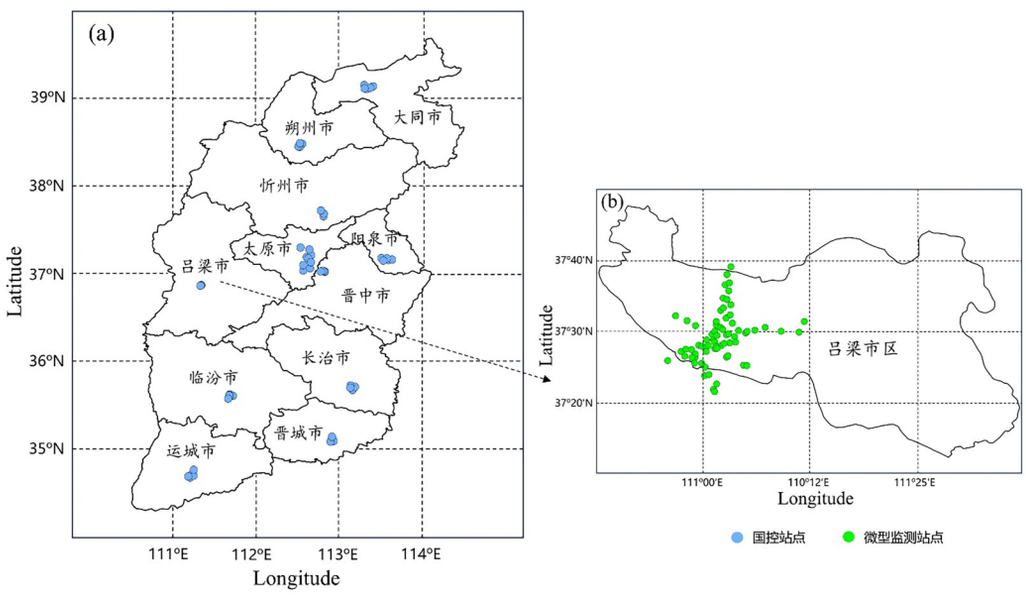

图 1　山西省的国控站点 (a) 和吕梁市微型环境监测站点 (b) 分布图

Fig. 1　Distribution map of state-controlled monitoring sites in Shanxi Province (a) and micro monitoring stations in Lüliang City (b)

1.2.4　其它数据集

为获得大范围的气象数据，本文使用了欧洲中期天气预报中心 (ECMWF) 的 ERA5 气象数据 (Fifth generation atmospheric reanalysis)[40]，其时间分辨率为逐小时，空间分辨率为 0.25°。主要使用了 8 个气象参数，即地表气压、向下紫外辐射、边界层高度、2 m 相对湿度、2 m 露点温度、2 m 气温、10 m 经向风和 10 m 纬向风[38]。

人口数据来自于世界人口网站 WorldPop (https://www.worldpop.org[2023-07-10])，其通过人口普查及 Top-down 的估计方法得到 100 m 空间分辨率的网格化数据[41,42]，研究选用 2020 年的年均数据。土地利用数据来源于清华大学发布的 FROM-GLC 分类模型 (Finer resolution observation and monitoring of global land cover)[43]。

2　方　法

首先采用 DINEOF 方法对卫星缺失数据部分进行填补，方法流程简述如下：

1) 将时间序列影像组成一个 $m \times n$ 的矩阵 (空间像元点数量 × 时间维数)，随机取出有效数据总量的 1% 作为交叉校正集，设 $\boldsymbol{I}$ 为待重构的缺失数据点集，特征模态参数集为 $\boldsymbol{Q}$。先对数据集进行对数变换，再减去其数据集时空均值，并将缺失点的值设定为 0 (视为无偏估计)，令此时的模态数 $P=1$，$P \in \boldsymbol{Q}$。

2) 对矩平化处理后的矩阵$\boldsymbol{X}$进行奇异值分解后，利用式 (1) 补齐缺失点值，得到重构矩阵$\boldsymbol{X}^{re}$为

$$\boldsymbol{X}_{ij}^{re}=\sum_{t=1}^{P}a_t\left(u_t\right)_i\left(v_t^{\mathrm{T}}\right)_j, \tag{1}$$

式中$(i,j)\in\boldsymbol{I}$, u_t和v_t分别是空间和时间特征模态的第t列，a_t为对应的奇异值，T表示矩阵转置。

然后根据式 (2) 计算重构的均方根误差 (RMSE, E_{RMS})，表达式为

$$E_{\mathrm{RMS}}=\sqrt{\frac{1}{N}\sum_{t=1}^{N}\left(\boldsymbol{X}_t^{re}-\boldsymbol{X}_t^{c}\right)^2}, \tag{2}$$

式中N为校正集$\boldsymbol{X}^c$的数据点数。

3) 用一次分解后补齐的矩阵代替原始矩阵继续进行分解，若前后2次迭代在交叉验证点的结果RMSE小于阈值时，认为迭代收敛。

4) 重复步骤2) 和3)，完成对缺失数据的重构，得到的矩阵仍记为$\boldsymbol{X}$，将$\boldsymbol{X}$加上步骤1) 中的均值，并进行反对数变换，得到最终的重构矩阵。

反演部分本文使用集成式机器学习方法，即Boosting的极端梯度提升XGBoost[44]。XGBoost由梯度提升决策树 (GBDT) 演化而来。GBDT的精髓在于：每轮迭代都沿着残差负梯度方向追加一棵新的基学习树，从而把一组弱分类器层层累加成强分类器。XGBoost在此基础上进一步对损失函数做二阶泰勒展开，并引入正则化项，同时借助并行计算，有效抑制过拟合，提升训练效率与泛化性能。技术路线如图2所示，首先将TROPOMI的气体柱浓度数据、AOD数据、气象数据、土地利用类型数据等与CO、NO_2、SO_2站点数据等进行时空匹配，选用最临近插值作为时空数据匹配的主要手段 (空间匹配选用0.01°×0.01°空间分辨率网格，即将数据重采样到0.01°的空间分辨率)；其次对数据进行清洗，将地面站点在部分时间收集存在明显误差值去除，使得数据分布均匀利于模型训练；然后将数据划分为训练集和测试集 (比例为7∶3), 并以二维表格的形式通过XGBoost方法进行模型训练，利用FLAML (Fast lightweight autoML) 自动机器学习框架搭建

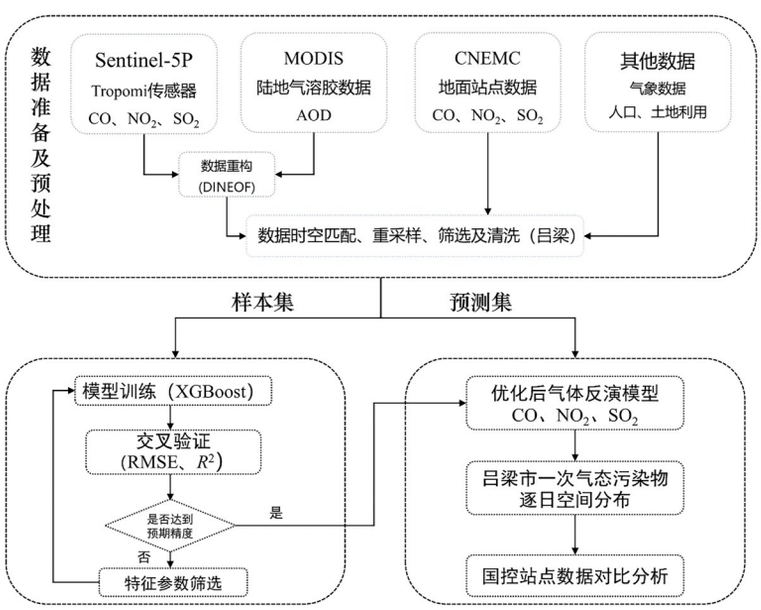

图 2 一次气态排放物反演流程图

Fig. 2 Flow chart of primary gaseous emission inversion

训练环境并对XGBoost相关参数进行设置和调整，主要参数设置见表1；最后选取最优模型反演一次气态污染物近地面浓度，将反演结果与吕梁市的国控站点实际测量值进行对比分析，并采用决定系数R^2和均方根误差RMSE进行评估。

表 1　XGBoost 主要参数设置表

Table 1　XGBoost main parameter settings table

气体	N_estimators	Max_leaves	Learning_rate	Subsample
CO	44	21	0.18	0.84
NO_2	38	17	0.64	0.91
SO_2	20	12	0.26	0.88

注：N_estimators: 代表决策树的数量；Max_leaves: 代表决策树的最大深度；Learning_rate: 代表模型的学习率；Subsample: 代表训练样本采样率。

3　结果与分析

3.1　数据预处理与模型分析

根据吕梁地区的区域范围，将其划分为 196 × 200 个网格单元，每个网格单元的空间分辨率为0.01° × 0.01°，在数据预处理中采用DINEOF方法对卫星数据进行缺失填补，部分结果见图3。每组图中左图为原始数据 (其中白色区域为原始数据的缺失部分)，右图为重构图。 通过图3可以看出DINEOF方法对不同污染气体以及不同数据缺失率的卫星数据都实现了完整的重构。同时绘制原始数据和重构结果的月均值概率密度分布图如图4，每个长方形的面积是每个区间的分布频率。可以发现，CO数据以2100 pmolec/cm^{2}为分界线，分界线左边的低值部分原始数据的月均概率分布普遍比重构数据高，而高值部分重构数据分布更多，

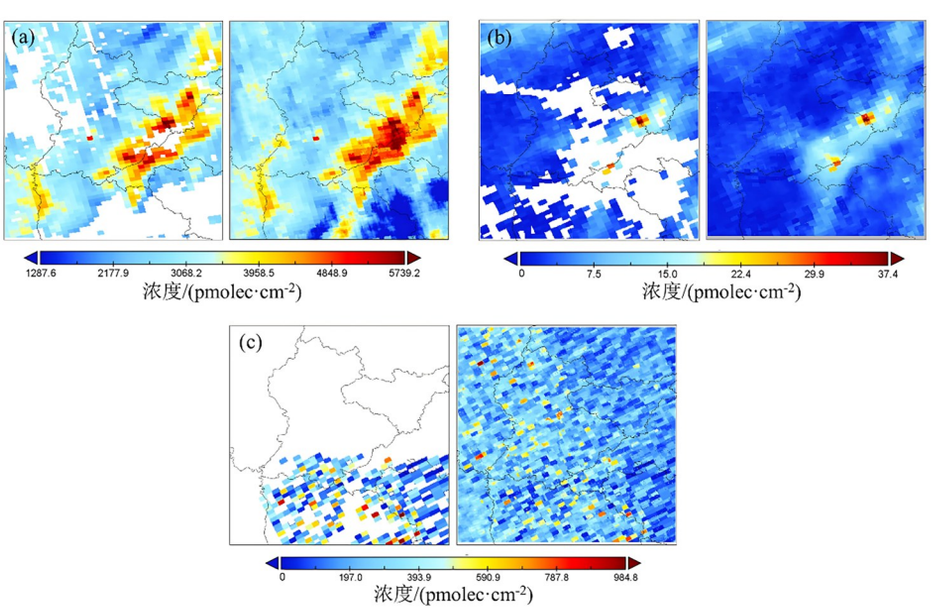

图 3　吕梁地区一次气态污染物DINEOF缺失数据重构示例。(a) CO (数据缺失率为38.01%)；(b) NO_2 (数据缺失率为40.77%)；(c) SO_2 (数据缺失率为73.18%)

Fig. 3　Example of DINEOF missing data reconstruction for primary gaseous pollutants in Lüliang area. (a) CO (with data missing rate of 38.01%); (b) NO_2 (with data missing rate of 40.77%); (c) SO_2 (with data missing rate of 73.18%)

因此对CO而言，重构之后，数据整体浓度值有明显提高；NO_2数据在数据分布最多的2～4 pmolec/cm^{2}部分重构数据有明显提升，而在0～2 pmolec/cm^{2}低值部分有明显下降，降低程度和升高程度近似；而SO_2与CO的分布规律类似，以30 pmolec/cm^{2}为分界线，重构数据在低值处降低，高值处普遍升高，但是在100 pmolec/cm^{2}以上的更高值处，重构结果比较原始数据分布更少。可以发现，CO与SO_2的月均值结果都在高值部分的像元数量有了显著增加，在低值处有了显著降低。经预处理，卫星遥感数据等通过最近邻插值映射至预设网格，经时空匹配后，每个气体各得到约2.6万条记录，合计约7.8万条样本。

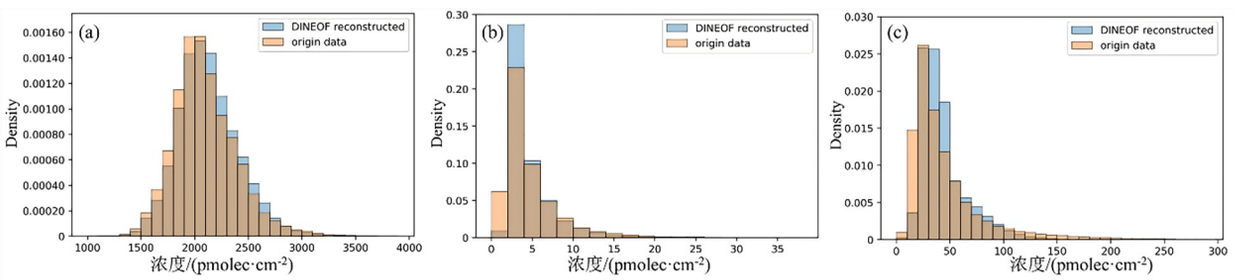

图4 吕梁地区2022年一次气态污染物原始数据与重构数据月均概率密度分布图。(a) CO；(b) NO_2；(c) SO_2

Fig. 4 Average monthly probability density distribution of original data and reconstructed data for primary gaseous pollutants in Lüliang area in 2022. (a) CO; (b) NO_2; (c)SO_2

在反演部分选择使用XGBoost模型来训练数据，将时空匹配得到的样本数据输入进行训练，将模型的预测集分别与模型的训练集和测试集进行比较(图5)，同时采用决定系数R^2、RMSE来评价模型性能。由图5可知，XGBoost模型在训练集、测试集与预测集的散点图中均呈现出高一致性，数据点分布均匀，离散程

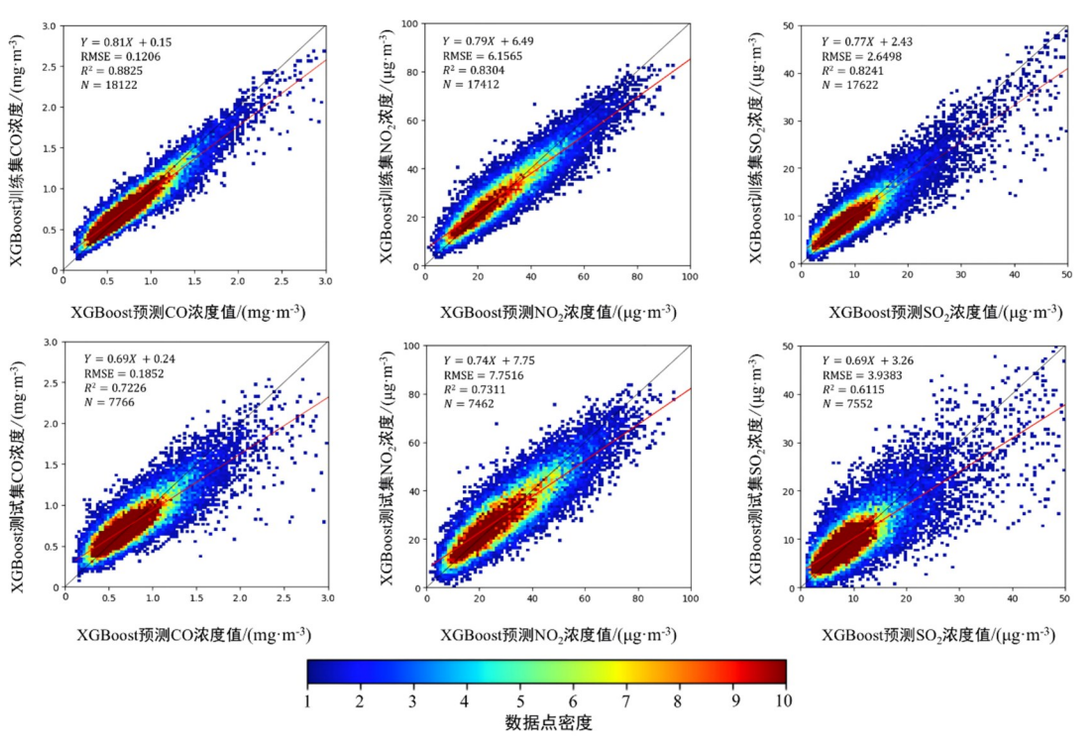

图5 XGBoost模型对吕梁地区2022年一次气态污染物的预测值、训练集与测试集对比图

Fig. 5 Comparison of predicted values of XGBoost model with training set and test set for primary gaseous pollutants in Lüliang area in 2022

也较好，不存在过度拟合的情况。

3.2　反演结果

估算结果及精细化反演图如图 6 所示，这里选取了 2022 年 1 月 1 日、2022 年 6 月 1 日和 2022 年 12 月 1 日这 3 天的反演结果，从图中可以较好地观测到吕梁市地区一次气态污染物的近地面浓度在不同时间、不同区域内的浓度变化。同时本文选取了位于吕梁市地区内的国控站点—2183A (37°31'15"N，111°08'26"E) 与反演值进行对比验证，图 7、8 分别为周浓度均值变化与月浓度均值变化的验证。

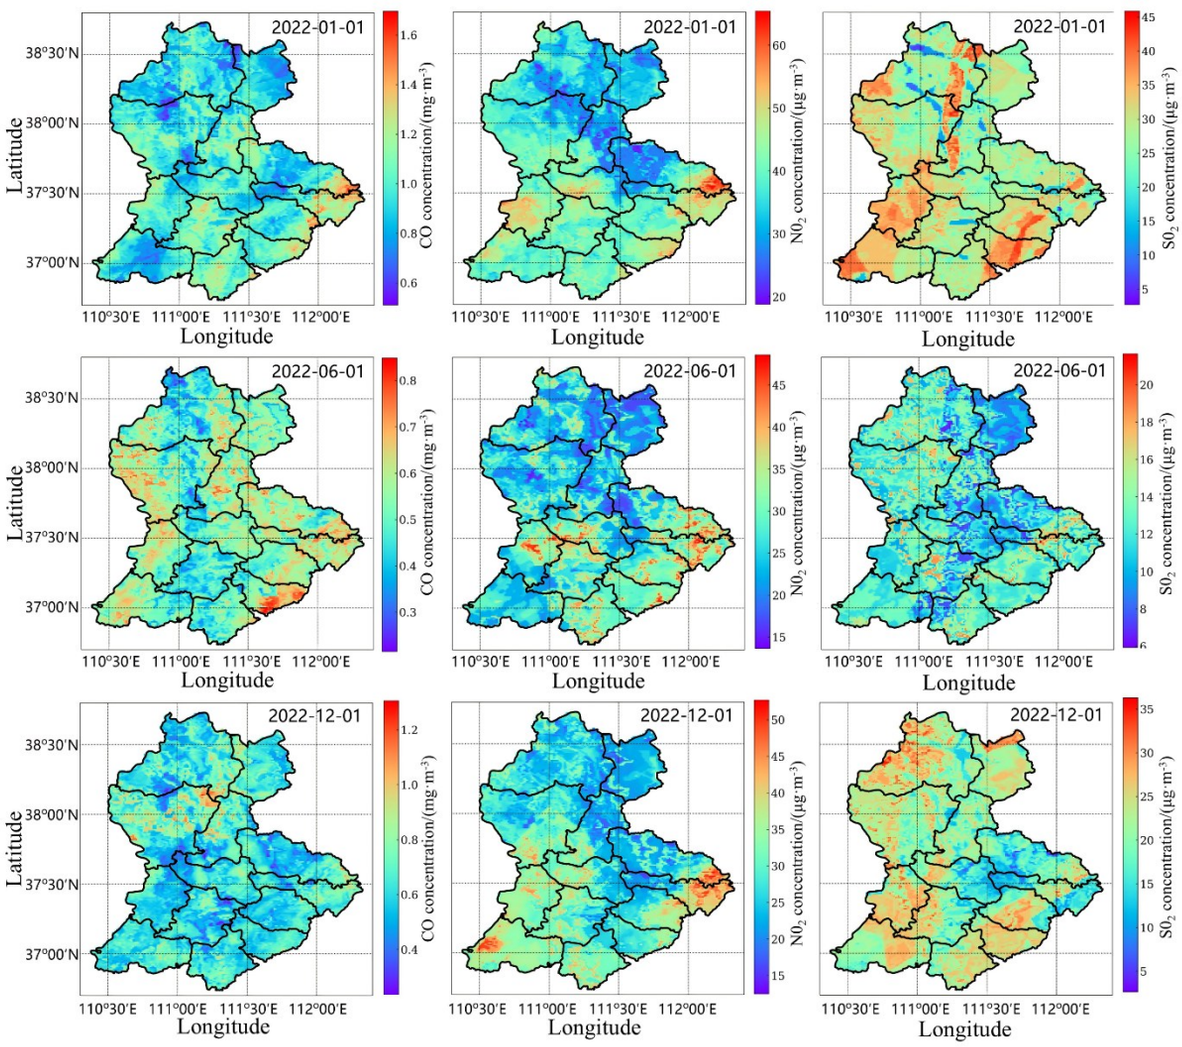

图 6　吕梁市地区一次气态污染物卫星遥感估算结果图

Fig. 6　Estimation results of primary gaseous pollutants by satellite remote sensing in Lüliang City

图 6 的反演结果能较好地显示出吕梁市一次气态污染物在日均值不同区域的浓度分布，结合图 5 模型的测试集与预测集的线性关系和 RMSE (CO = 0.185；NO_2 = 7.75；SO_2 = 3.94) 以及图 7 和图 8 的估算值与站点测量值对比趋势可以看出，在周和月的周期尺度上，估算的结果与站点的测量值在总体的变化趋势上大体一致，呈现出较好的相关性；从单个气体分析，NO_2 与 CO 的估算值变化都比较接近站点的测量值变化，CO 在月周期一些时间段 (11～14 天、26～28 天) 会出现偏大的误差值，且误差值比测量最大值还要大，NO_2

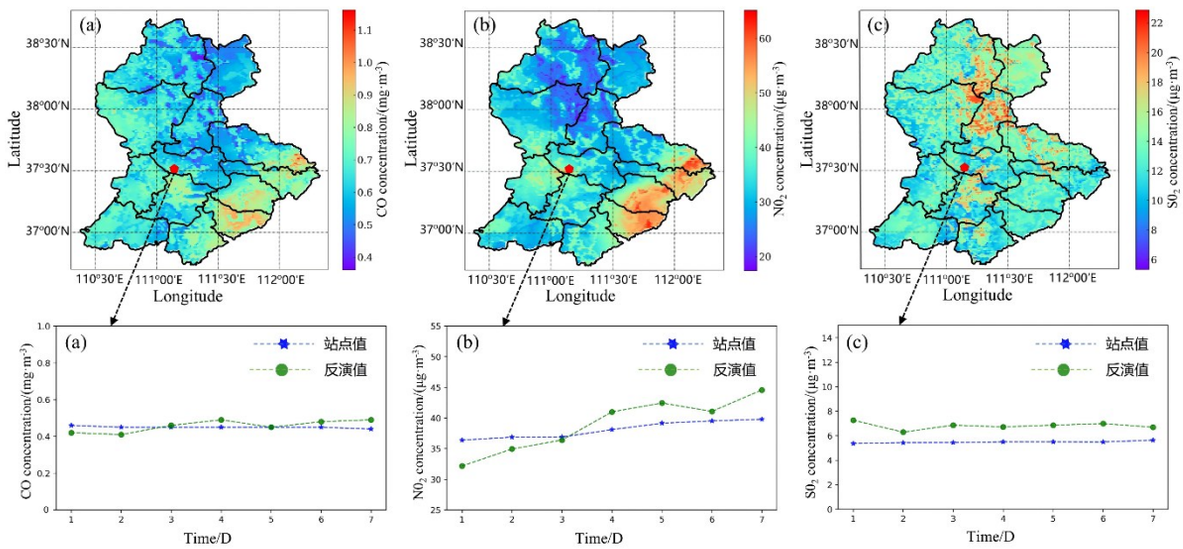

图 7 2022年第42周吕梁市国控站点一次气态污染物数据对比图。(a) CO；(b) NO_2；(c) SO_2

Fig. 7 Data comparison of primary gaseous pollutants from the national control station in Lüliang City in the 42nd week of 2022. (a) CO; (b) NO_2; (c) SO_2

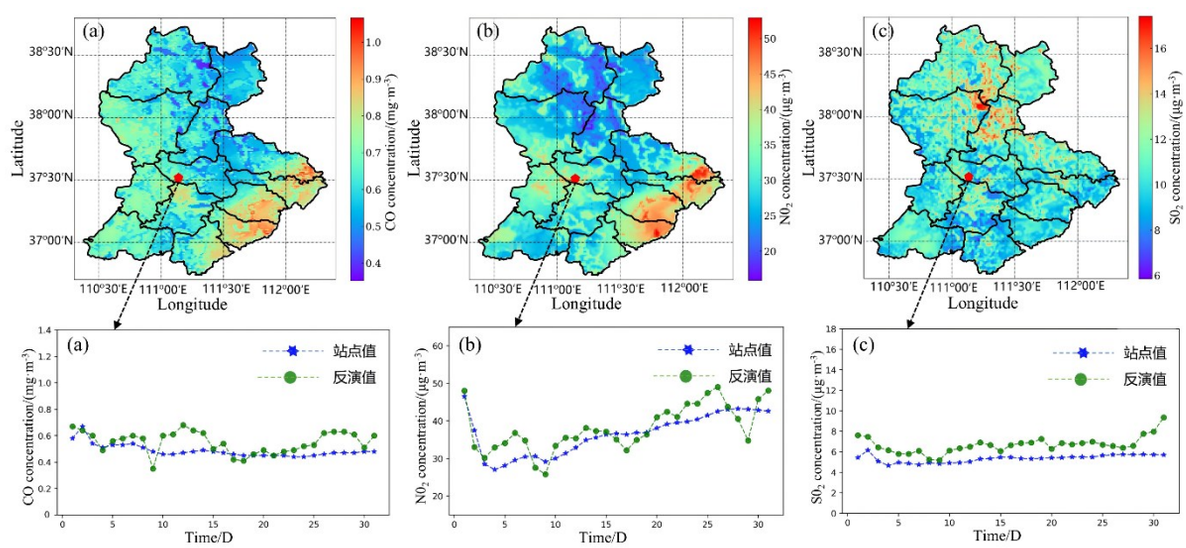

图 8 2022年10月吕梁市国控站点一次气态污染物数据对比图。(a) CO；(b) NO_2；(c) SO_2

Fig. 8 Data comparison of primary gaseous pollutant from the national control station in Lüliang City in October 2022. (a) CO; (b) NO_2; (c) SO_2

估算值在测量值趋势上交替变化；SO_2无论是从周还是月周期上，估算值总体比站点的测量值要偏大。造成SO_2估算值偏大的原因可能有几个方面：1) NO_2和SO_2大部分存在于大气的对流层和边界层区域，而TROPOMI提供的为SO_2总的柱浓度数据，数据精度相对可能较低；2) 地面站点分布不均，且站点测量值只能代表一定半径范围内情况，而城市中SO_2主要来自于燃煤工业的排放，工业排放区相比居民生活区SO_2的值普遍要高，站点周围有工厂排放也会造成SO_2反演值偏高；3) DINEOF数据重构在利用本身有效数据的基础上进行，虽然对数据缺失率没有最低要求，但重构结果的质量与缺失程度有关联，相比之下TROPOMI的SO_2缺失数据量远大于有效数据，重构结果不如CO和NO_2。

4 结　论

研究先利用DINEOF方法对卫星遥感产品的缺失数据进行填补，然后利用机器学习方法开展了吕梁市地区0.01°空间分辨率的一次气态污染物 (CO、NO_2、SO_2) 浓度反演和精细化制图，通过与国控站点数据对比分析，得到以下结论：

1) 吕梁市一次气态污染物反演制图结果可以较好地显示出气体在不同时间、不同地区的近地面浓度变化趋势。3种气体中NO_2和CO反演值与地面站点测量值有较好的一致性，而SO_2的反演值偏大，偏大的原因可能与卫星数据精度、气体排放源、站点测量范围以及重构数据质量等有关。

2) 由于被动遥感卫星观测容易受到云雨天气因素影响，加上轨道之间的缝隙等原因，遥感产品的缺失数据较多。建议在业务实践中先对卫星产品数据进行重构，再进行空气质量参数浓度的反演制图。

3) 结合相对稠密的城市控制站点和高覆盖率的卫星数据得到的一次气态污染物遥感估算制图结果，能够更好地反映出不同区域的分布差异性，为城市、区 (县) 两级政府开展精细化的空气质量治理提供了技术支撑。

参考文献:

[1] Naresh R, Sundar S, Shukla J B. Modeling the removal of primary and secondary pollutants from the atmosphere of a city by rain [J]. *Applied Mathematics and Computation*, 2006, 179(1): 282-295.

[2] Luo R, Wang X Z, Lin G L, *et al*. Study on the impact of primary pollutants on ozone formation [J]. *Research of Environmental Sciences*, 2006, 19(4): 26-30.
罗 蕊, 王学中, 林国梁, 等. 一次污染物对臭氧生成的影响研究 [J]. 环境科学研究, 2006, 19(4): 26-30.

[3] Zhu S Y, Yu C, Li X Y, *et al*. An overview of satellite-based formaldehyde retrieval and present status [J]. *China Environmental Science*, 2018, 38(5): 1685-1694.
朱松岩, 余 超, 李小英, 等. 紫外大气甲醛卫星遥感反演方法和研究现状 [J]. 中国环境科学, 2018, 38(5): 1685-1694.

[4] Cao J, Xu H, Xu Q, *et al*. Fine particulate matter constituents and cardiopulmonary mortality in a heavily polluted Chinese city [J]. *Environmental Health Perspectives*, 2012, 120(3): 373-378.

[5] 《中国空气质量管理评估报告2016》发布: 大气污染物与温室气体同根同源 大气污染防治产生减碳效应 [J]. 中国环境科学, 2016, 36(10): 2929.

[6] Wang Z, Ma P, Zhang L, *et al*. Systematics of atmospheric environment monitoring in China via satellite remote sensing [J]. *Air Quality, Atmosphere & Health*, 2021, 14(2): 157-169.

[7] Cameron M A, Jacobson M Z, Barrett S R H, *et al*. An intercomparative study of the effects of aircraft emissions on surface air quality [J]. *Journal of Geophysical Research: Atmospheres*, 2017, 122(15): 8325-8344.

[8] Zhang Y, Li Z Q. Estimation of $PM_{2.5}$ from fine-mode aerosol optical depth [J]. *Journal of Remote Sensing*, 2013, 17(4): 929-943.
张 莹, 李正强. 利用细模态气溶胶光学厚度估计$PM_{2.5}$ [J]. 遥感学报, 2013, 17(4): 929-943.

[9] Zhang Y, Li Z, Bai K, *et al*. Satellite remote sensing of atmospheric particulate matter mass concentration: Advances, challenges, and perspectives [J]. *Fundamental Research*, 2021, 1(3): 240-258.

[10] Wang J, Christopher S A. Intercomparison between satellite-derived aerosol optical thickness and $PM_{2.5}$ mass: Implications for air quality studies [J]. *Geophysical Research Letters*, 2003, 30(21): 2003GL018174.

[11] Koelemeijer R B A, Homan C D, Matthijsen J. Comparison of spatial and temporal variations of aerosol optical thickness and particulate matter over Europe [J]. *Atmospheric Environment*, 2006, 40(27): 5304-5315.

[12] Wu Y R, Guo J P, Zhang X Y, *et al*. Synergy of satellite and ground based observations in estimation of particulate matter in Eastern China [J]. *Science of the Total Environment*, 2012, 433: 20-30.

[13] Pan J X, Yan P Z, Sun F, *et al*. Application of ensemble forecast and linear regression method in improving $PM_{2.5}$ forecast over Beijing area [J]. Chinese Journal of Environmental Monitoring, 2019, 35(2): 43-52.
潘锦秀, 晏平仲, 孙 峰, 等. 多元线性回归方法对北京地区 $PM_{2.5}$ 预报的改进应用 [J]. 中国环境监测, 2019, 35(2): 43-52.

[14] Li D, Qin K, Cohen J B, *et al*. Combing GOME-2B and OMI satellite data to estimate near-surface NO_2 of mainland China [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 10269-10277.

[15] Qin K, Han X, Li D, *et al*. Satellite-based estimation of surface NO_2 concentrations over east-central China: A comparison of POMINO and OMNO2d data [J]. *Atmospheric Environment*, 2020, 224: 117322.

[16] Hu Z Y. Spatial analysis of MODIS aerosol optical depth, $PM_{2.5}$, and chronic coronary heart disease [J]. *International Journal of Health Geographics*, 2009, 8(1): 27.

[17] Huang B, Wu B, Barry M. Geographically and temporally weighted regression for modeling spatio-temporal variation in house prices [J]. *International Journal of Geographical Information Science*, 2010, 24(3): 383-401.

[18] Qin K, Rao L, Xu J, *et al*. Estimating ground level NO_2 concentrations over Central-Eastern China using a satellite-based geographically and temporally weighted regression model [J]. *Remote Sensing*, 2017, 9(9): 950.

[19] Ordieres J B, Vergara E P, Capuz R S, *et al*. Neural network prediction model for fine particulate matter ($PM_{2.5}$) on the US-Mexico border in El Paso (Texas) and Ciudad Juárez (Chihuahua) [J]. *Environmental Modelling & Software*, 2005, 20(5): 547-559.

[20] Guo J P, Wu Y R, Zhang X Y, *et al*. Estimation of $PM_{2.5}$ over eastern China from MODIS aerosol optical depth using the back propagation neural network [J]. *Environmental Science*, 2013, 34(3): 817-825.
郭建业, 吴业荣, 张小曳, 等. BP 网络框架下 MODIS 气溶胶光学厚度产品估算中国东部 $PM_{2.5}$ [J]. 环境科学, 2013, 34(3): 817-825.

[21] Martin R V, Jacob D J, Chance K, *et al*. Global inventory of nitrogen oxide emissions constrained by space-based observations of NO_2 columns [J]. *Journal of Geophysical Research: Atmospheres*, 2003, 108(D17): 2003JD003453.

[22] Valks P, Pinardi G, Richter A, *et al*. Operational total and tropospheric NO_2 column retrieval for GOME-2 [J]. *Atmospheric Measurement Techniques*, 2011, 4(7): 1491-1514.

[23] Boersma K F, Eskes H J, Veefkind J P, *et al*. Near-real time retrieval of tropospheric NO_2 from OMI [J]. *Atmospheric Chemistry and Physics*, 2007, 7(8): 2103-2118.

[24] Wang W, Mao F, Du L, *et al*. Deriving hourly $PM_{2.5}$ concentrations from Himawari-8 AODs over Beijing-Tianjin-Hebei in China [J]. *Remote Sensing*, 2017, 9(8): 858.

[25] Zhang Y, Li Z Q, Zhao S H, *et al*. A review of collaborative remote sensing observation of atmospheric gaseous and particulate pollution with atmospheric environment satellites. [J]. *National Remote Sensing Bulletin*, 2022, 26(5): 873-896.
张 莹, 李正强, 赵少华, 等. 大气环境卫星污染气体和大气颗粒物协同观测综述 [J]. 遥感学报, 2022, 26(5): 873-896.

[26] Liu X, Wang M. Gap filling of missing data for VIIRS global ocean color products using the DINEOF method [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(8): 4464-4476.

[27] Alvera-Azcárate A, Barth A, Rixen M, *et al*. Reconstruction of incomplete oceanographic data sets using empirical orthogonal functions: Application to the Adriatic Sea surface temperature [J]. *Ocean Modelling*, 2005, 9(4): 325-346.

[28] Beckers J M, Rixen M. EOF calculations and data filling from incomplete oceanographic datasets [J]. *Journal of Atmospheric*

*and Oceanic Technolog*y, 2003, 20(12): 1839-1856.

[29] Huynh H T, Alvera-Azcárate A, Beckers J M. Analysis of surface chlorophyll a associated with sea surface temperature and surface wind in the South China Sea [J]. *Ocean Dynamics*, 2020, 70(1): 139-161.

[30] Veefkind J P, Aben I, McMullan K, *et al*. TROPOMI on the ESA Sentinel-5 Precursor: A GMES mission for global observations of the atmospheric composition for climate, air quality and ozone layer applications [J]. *Remote Sensing of Environment*, 2012, 120: 70-83.

[31] Van Geffen J, Boersma K F, Eskes H, *et al*. S5P TROPOMI NO_2 slant column retrieval: Method, stability, uncertainties and comparisons with OMI [J]. *Atmospheric Measurement Techniques*, 2020, 13(3): 1315-1335.

[32] Wang C, Wang T, Wang P, *et al*. Assessment of the performance of TROPOMI NO_2 and SO_2 data products in the North China Plain: Comparison, correction and application [J]. *Remote Sensing*, 2022, 14(1): 214.

[33] Zheng F B, Xia Y, Ge Q, *et al*. Comparison of satellite-retrieved NO_2 vertical column density with ground-level NO_2 concentration in a provincial scale region [J]. *IOP Conference Series: Earth and Environmental Science*, 2020, 615(1): 012123.

[34] Borsdorff T, Aan De Brugh J, Hu H, *et al*. Mapping carbon monoxide pollution from space down to city scales with daily global coverage [J]. *Atmospheric Measurement Techniques*, 2018, 11(10): 5507-5518.

[35] Sha M K, Langerock B, Blavier J L, *et al*. Validation of methane and carbon monoxide from Sentinel-5 precursor using TCCON and NDACC-IRWG stations [J]. *Atmospheric Measurement Techniques*, 2021, 14(9): 6249-6304.

[36] Lin F, Wang B, Liu H. Application of MODIS data in straw burning monitoring [J]. *Geomatics & Spatial Information Technology*, 2023, 46(S1):166-168.
林 峰, 王 博, 刘 航. MODIS数据在秸秆焚烧监测中的应用研究 [J]. 测绘与空间地理信息, 2023, 46(S1): 166-168.

[37] Lyapustin A, Wang Y, Laszlo I, *et al*. Multiangle implementation of atmospheric correction (MAIAC): 2. Aerosol algorithm [J]. *Journal of Geophysical Research*, 2011, 116(D3): D03211.

[38] Fan D H, Qin K, Du J, *et al*. Fine mapping of $PM_{2.5}$ based on measurements from geostationary satellites and grid monitoring stations [J]. *National Remote Sensing Bulletin*, 2022, 26(5): 1015-1026.
范东浩, 秦 凯, 杜 娟, 等. 地球静止卫星和网格化站点支持下的$PM_{2.5}$精细制图 [J]. 遥感学报, 2022, 26(5): 1015-1026.

[39] Zou B, Pu Q, Bilal M, *et al*. High-resolution satellite mapping of fine particulates based on geographically weighted regression [J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(4): 495-499.

[40] Hersbach H, Bell B, Berrisford P, *et al*. The ERA5 global reanalysis [J]. *Quarterly Journal of the Royal Meteorological Society*, 2020, 146(730): 1999-2049.

[41] Stevens F R, Gaughan A E, Linard C, *et al*. Disaggregating census data for population mapping using random forests with remotely-sensed and ancillary data [J]. *PLoS One*, 2015, 10(2): e0107042.

[42] Lloyd C T, Chamberlain H, Kerr D, *et al*. Global spatio-temporally harmonised datasets for producing high-resolution gridded population distribution datasets [J]. *Big Earth Data*, 2019, 3(2): 108-139.

[43] Gong P, Wang J, Yu L, *et al*. Finer resolution observation and monitoring of global land cover: First mapping results with landsat TM and ETM+ data [J]. *International Journal of Remote Sensing*, 2013, 34(7): 2607-2654.

[44] Chen T Q, Guestrin C. XGBoost: A scalable tree boosting system [C]. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York, USA. Association for Computing Machinery, 2016: 785-794.