

DOI: 10.3969/j.issn.1673-6141.2023.02.009

# 基于卫星数据和深度学习方法预测京津冀地区地表 NO<sub>2</sub> 浓度

范轩硕<sup>1</sup>, 吴海滨<sup>2\*</sup>, 陈新兵<sup>2</sup>, 宋伟<sup>2</sup>

(1 安徽大学物质科学与信息技术研究院, 安徽 合肥 230601;

2 安徽大学物理与材料科学学院, 安徽 合肥 230601)

**摘要:** 二氧化氮 (NO<sub>2</sub>) 对人类健康和气候变化有着诸多负面影响, 随着中国城镇化和工业化进程加速, NO<sub>2</sub> 污染成为人们日益关注的问题。相关研究表明传统的单个站点监测结果只能代表数平方公里内的污染物水平, 无法提供大尺度的污染物分布信息。相比于站点监测, 卫星遥感可以提供大尺度且时空连续的数据, 为研究大气污染提供了新的角度。基于哨兵 5P 卫星的 NO<sub>2</sub> 柱浓度数据和气象、人口密度等其他辅助数据, 构建了对地表 NO<sub>2</sub> 进行预测的深度神经网络 (DNN) 模型。并使用两种交叉验证方法对该模型进行验证。在基于样本的验证中, 模型的决定系数  $R^2$ 、均方根误差 (RMSE) 和平均预测误差 (MAE) 分别为 0.80、7.72  $\mu\text{g}/\text{m}^3$  和 5.31  $\mu\text{g}/\text{m}^3$ ; 在基于站点的验证中, 模型的  $R^2$ 、RMSE 和 MAE 分别为 0.74、8.95  $\mu\text{g}/\text{m}^3$  和 6.01  $\mu\text{g}/\text{m}^3$ , 两种验证结果都表明 DNN 模型具有较好的整体预测能力和空间泛化性。此外, 与经典的地学统计和机器学习算法对比结果表明 DNN 预测性能优于其它方法。最后用训练好的模型获得了京津冀地区 0.1° 的 NO<sub>2</sub> 分布图。

**关键词:** 二氧化氮; 机器学习; 哨兵 5P; 遥感

中图分类号: X511

文献标识码: A

文章编号: 1673-6141(2023)02-181-010

## Deep learning architecture based on satellite remote sensing data for estimating ground-level NO<sub>2</sub> across Beijing-Tianjin-Hebei Region

FAN Xuanshuo<sup>1</sup>, WU Haibin<sup>2\*</sup>, CHEN Xinbing<sup>2</sup>, SONG Wei<sup>2</sup>

(1 Institute of Material Science and Information Technology, Anhui University, Hefei 230601, China;

2 School of Physics and Material Science, Anhui University, Hefei 230601, China)

**Abstract:** Nitrogen dioxide (NO<sub>2</sub>) has many adverse impacts on human health and climate change. With the acceleration of urbanization and industrialization in China, NO<sub>2</sub> pollution has become a growing concern. However, relevant research shows that the traditional monitoring results of a single site can only represent the concentration of pollutants within a few square kilometers, and cannot provide large-scale pollutant

基金项目: 科技部创新基金 (07C26213400516)

作者简介: 范轩硕 (1995-), 安徽宿州人, 硕士研究生, 主要从事红外测温、机器学习方面的研究。E-mail: 528694842@qq.com

导师简介: 吴海滨 (1962-), 安徽合肥人, 硕士, 高级工程师, 硕士生导师, 长期从事光电检测技术及相关设备的研究开发。

E-mail: whb62@163.com

收稿日期: 2021-06-04; 修改日期: 2021-08-04

\*通信作者。

distribution information. Compared with site monitoring, satellite remote sensing can provide large-scale and spatiotemporal continuous data. Based on  $\text{NO}_2$  column densities of Sentinel-5 Precursor and other auxiliary data such as weather and population density, a deep learning model (DNN) to predict ground-level  $\text{NO}_2$  concentration is built in this work, and then the model is verified by two cross-validation strategies. In the sample-based cross validation, the determination coefficient  $R^2$ , root mean square error (RMSE) and mean absolute error (MAE) of the model are 0.80、7.72  $\mu\text{g}/\text{m}^3$  and 5.31  $\mu\text{g}/\text{m}^3$ , respectively, while in the site-based cross validation, they are 0.74、8.95  $\mu\text{g}/\text{m}^3$  and 6.01  $\mu\text{g}/\text{m}^3$ , respectively. Both of the two cross-validation results indicate that the DNN model has excellent overall predictive performance and spatial generalization ability. In addition, the comparisons with the other classic geostatistics and machine learning algorithms also show that the predictive performance of the deep learning algorithm is better than that of the other methods. Finally, the trained model is applied to generate  $\text{NO}_2$  distribution with  $0.1^\circ$  spatial resolution across Beijing-Tianjin-Hebei region.

**Key words:** nitrogen dioxide; machine learning; Sentinel 5P; remote sensing

## 0 引言

$\text{NO}_2$ 会对人体健康带来直接损害,暴露在高浓度的 $\text{NO}_2$ 中会导致哮喘、肺癌等呼吸系统疾病,同时 $\text{NO}_2$ 也是臭氧和颗粒物的重要前体污染物,多种空气污染物混合会对人体健康带来更大负面作用<sup>[1]</sup>。从2013年开始,我国陆续建立了1500多个空气质量监测站点,对包括 $\text{NO}_2$ 在内的多种空气污染物进行监测。站点监测数据是研究空气质量的重要数据来源,一些流行病和污染物暴露风险评估的研究基于站点监测数据,通过空间插值得到一定尺度的空气污染数据<sup>[2-4]</sup>。然而单个站点只能反映小范围(0.25~16.25  $\text{km}^2$ )的污染物状况,并且站点的分布极不均匀,大部分站点分布在中东部的城市区域,这会使插值结果出现不确定性<sup>[5]</sup>。

为了得到准确的污染物分布信息,一些地学统计模型被开发出来,土地利用回归模型(LUR)由Briggs等<sup>[6]</sup>于1997年提出,并逐步发展成模拟小区域尺度大气污染物时空分布的通用模型。LUR建立站点周围环境条件与污染物浓度的线性关系,再对没有站点区域的污染物浓度进行预测,其构建简单、拟合效果好,广泛应用于大气污染研究中。但是LUR以地理要素具有同质性作为前提,而大气污染具有很强的时空异质性<sup>[7-9]</sup>,因此LUR在大尺度区域的研究上表现不理想。针对这一问题,一些学者利用地理加权回归(GWR)来寻找污染物的空间相关性<sup>[10,11]</sup>,GWR以空间距离度量地理位置的临近关系,通过构建空间核函数进行权重计算,非常直观地体现了地理关系的非平稳性。

LUR和GWR的搭建均基于线性回归(LR)算法,然而大气污染物与预测变量之间存在复杂的多阶相互作用,基于LR的模型很难准确地建立这些非线性关系。相比于线性模型,机器学习(ML)因其复杂且灵活的网络结构,可以从数据中提取深层次信息,因此被广泛应用于大尺度空气污染的研究。很多ML模型表现出良好的性能,包括随机森林(RF)<sup>[12]</sup>、支持向量机回归(SVR)<sup>[13]</sup>、广义回归神经网络(GRNN)<sup>[14]</sup>等。

随着计算机算力的快速发展,深度学习凭借对大数据的强大处理能力,从众多机器算法中脱颖而出。在较少的数据量下,机器学习算法使用定制的算法规则,并借助特征工程减少数据复杂度,模型性能会比深度学习好。而在大数据背景下,深度学习尝试从数据中直接获取高等级的特征,凭借更多的可训练参数达到更

高的性能<sup>[15,16]</sup>。同时,卫星遥感技术发展迅速,为大气污染监测提供了海量数据,深度学习模型的搭建有了数据支持。本文基于哨兵5P(S5P)卫星NO<sub>2</sub>柱浓度数据建立深度神经网络(DNN)模型,对京津冀地区地表NO<sub>2</sub>浓度进行预测。模型验证采用两种10折交叉验证(CV10)方法<sup>[17,18]</sup>,并与经典的地理统计和机器学习模型进行对比。试验结果表明DNN模型具有良好的预测性能和空间泛化性,优于多种常用模型。DNN的空间预测结果和站点监测值有较高的一致性,本研究可以准确地绘制NO<sub>2</sub>的时空分布,为流行病、污染物暴露风险等后续研究提供方法参考和基础数据支持。

## 1 研究区和数据介绍

### 1.1 研究区和NO<sub>2</sub>监测站点

研究区和站点位置如图1所示。京津冀地区位于我国北部,占地面积约21.8万平方千米,人口约为1.1亿。作为我国重工业基地,该区域人口密度较大、空气质量较差,将其作为研究区有很大的社会经济意义。研究区内空气质量监测站点共有87个,站点提供包括NO<sub>2</sub>在内的六种污染物每小时均值,数据由中国环境监测中心(CNEMC, <http://www.cnemc.cn>)发布。本工作使用2019年1月到2020年8月的数据。

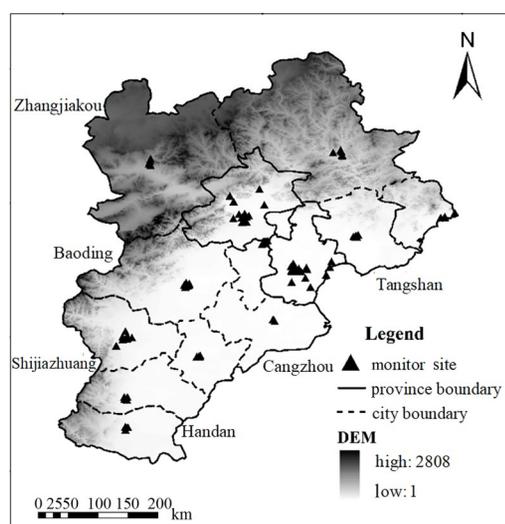


图1 研究区和地面监测站点分布

Fig. 1 Study area and distribution of ground-level monitor sites

### 1.2 卫星柱浓度数据

S5P是专用于大气痕量气体监测的卫星,S5P搭载了对流层观测仪(TROPOMI),成像幅宽达2600 km,每日覆盖全球各地,成像分辨率达到7 km × 3.5 km。相比于2004年发射的臭氧层监测仪,TROPOMI在技术特性上有大幅提升:其空间分辨率明显提高,并且信噪比提高了1~5倍<sup>[19]</sup>。S5P对NO<sub>2</sub>柱浓度反演方法有两种,第一种是差分光谱吸收法用于产生实时数据,另一种是GOME(Global ozone monitoring experiment)直接拟合法(GODFIT)用于产生高精度的离线再处理数据,选取GODFIT算法数据,数据由欧洲航天局(<https://copernicus.eu>)发布。

### 1.3 气象和其他辅助数据

气象数据使用欧洲中尺度天气预报中心的第五代气象再分析资料(ERA5, <https://cds.climate.copernicus>).

eu), 包括 2 m 温度 (t2m)、2 m 露点温度 (d2m)、10 m 径向风 (u10)、10 m 纬向风 (v10)、压强 (sp)、边界层高度 (blh) 和总降水 (tp)。高程数据使用 SRTM3 数据, 由 NASA (srtm.csi.cgiar.org) 发布, 空间分辨率为 90 m; 地表覆盖数据使用 GlobelLand30, 由国家地理信息中心 (<http://www.globallandcover.com>) 发布, 该数据集包含 10 个地表覆盖类别, 空间分辨率为 30 m; 人口密度使用 Gridded Population of World 第 4 版 (GPWv4) 数据集, 由 NASA (<http://sedac.ciesin.columbia.edu>) 发布, 空间分辨率为 30"。

所使用的数据信息以及来源均在表 1 列出。

表 1 数据信息

Table 1 Data information

Data	Spatial resolution	Time resolution	Source
Monitoring sites $\text{NO}_2/(\mu\text{g}\cdot\text{m}^{-3})$	-	hour	CNEMC
$\text{NO}_2$ column densities/ $(\text{mol}\cdot\text{m}^{-2})$	7.5 km $\times$ 3.5 km	day	S5P
Meteorological	0.25°	hour	ERA5
Elevation/m	90 m	-	SRTM3
Land use type	30 m	5 years	GlobelLan30
Population density $/( \text{people}\cdot\text{km}^{-2} )$	30 arc-second	5 years	GPWv4

#### 1.4 数据预处理

数据的预处理包括三个方面: 缺失值填补、数据重采样和标准化。

1) 站点监测数据和  $\text{NO}_2$  柱浓度数据中存在缺失值, 站点监测数据缺失值占比为 8.3%,  $\text{NO}_2$  柱浓度数据缺失值占比为 4.4%, 分别采用三次样条和克里金插值进行缺失值的填充。

2) 为了方便数据匹配, 将所有数据重采样到 0.1° 分辨率, 其中土地覆盖作为类别变量, 不适用一般地学插值算法。本文首先创建一个 0.1° 的网格, 根据网格经纬度使用 5 km  $\times$  5 km 的窗口在 GlobeLand30 数据集上采样, 在窗口内求出土地利用类型数量的距离加权得分, 得分最高的类型作为该网格的土地利用类型, 计算公式为

$$C_i = n_i d_i, \quad (1)$$

$$C = \max(c_1, c_2, \dots, c_{i-1}, c_i), \quad (2)$$

式中  $C_i$  为该类型的得分,  $i$  代表土地利用类型,  $n_i$  为该类型个数,  $d_i$  为该类型距离网格点的距离,  $C$  为该网格的土地利用类型。

其余数据采用克里金重采样, 完成重采样后, 监测站点落在哪个网格, 其监测值就作为该网格的  $\text{NO}_2$  浓度。这种匹配方法存在多个站点落在同一网格的情况, 即相同的预测变量对应不同的  $\text{NO}_2$  浓度, 考虑到深度学习算法在训练过程中以最小化损失函数目标, 在训练过程中会趋近不同  $\text{NO}_2$  浓度的均值, 故对这种情况不加以处理。

3) 不同的预测变量往往具有不同的量纲, 会导致模型梯度下降很慢, 甚至会陷入局部最优的困境<sup>[20]</sup>。为了消除不同量纲的影响, 需要对数据进行标准化, 采用 z-score 方法, 将数据缩放到均值为 0, 方差为 1, 计算公式为

$$x = \frac{x - \mu}{\sigma}, \quad (3)$$

式中  $x$  为样本,  $\mu$  为样本均值,  $\sigma$  为样本标准差。

## 2 方 法

### 2.1 模型

#### 2.1.1 DNN 模型

DNN 总体结构是多个感知机的堆叠, 单个感知机的输入和输出之间为线性关系, 计算公式

$$y = \sum_i^n w_i x_i + b, \tag{4}$$

式中  $w$  为参数矩阵,  $x$  为预测变量,  $b$  为偏执项。

这种线性拟合无法解决较为复杂的问题, 因此 DNN 基于感知机进行了扩展, 每个感知机的计算结果会传入非线性激活单元 (tanh、ReLU 等函数), 以加强模型的表达能力, 并且在输入和输出之间添加隐藏层, 隐藏层中多个感知机密集连接以提高提取数据深层次信息的能力<sup>[21]</sup>。DNN 的网络结构如图 2 所示。计算过程分为前向传播和反向传播, 数据在前向传播中经过数个隐藏层后得到输出, 利用输出结果与真实值进行比较得到误差, 然后反向传播通过梯度下降将误差传回输出层, 在反向传播中每个感知机的参数都会进行更新, 网络不断迭代这个过程, 直到误差函数收敛到最小值。

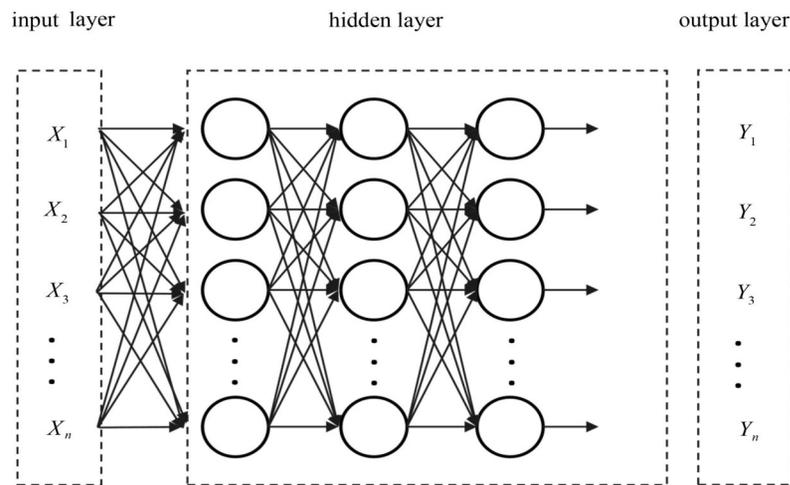


图 2 DNN 网络

Fig. 2 DNN network

搭建的 DNN 模型共有 5 个隐藏层, 每层神经元个数分别为 128、256、128、64、32, 为了使模型达到最佳效果, 引入了批量归一化 (BN)、Dropout 等结构。模型的结构通过试验确定, 不断增加隐藏层和神经元个数直到模型精度不发生变化, 具体结构如图 3 所示。

其他配置和超参数如下:

- 1) 损失函数采用均方根误差, 优化器采用 Adam, 初始学习率为 0.001。
- 2) 隐藏层激活函数使用 ReLU 函数, 输出层为线性函数。
- 3) 引入学习率自动衰减和 EarlyStopping 机制, 如果经过 10 轮训练, 验证数据的损失没有下降, 学习率衰减为原学习率的 0.2 倍; 如果经过 20 轮训练, 验证数据损失没有下降, 模型自动终止训练。
- 4) 在隐藏层中添加正则项以避免过拟合, 正则化 L2 参数设置为 0.01。

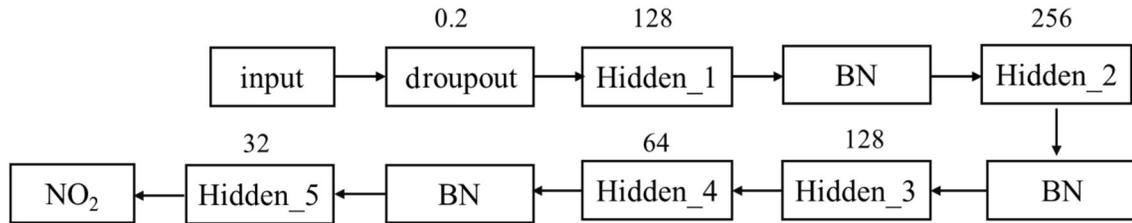


图3 模型结构

Fig. 3 Model structure

### 2.1.2 对比模型

对比模型包括LR、GWR、SVR、GRNN和RF。LR作为最基础的回归模型,在预测变量和实际观测值之间模拟一条线性方程,通过最小二乘法求解该方程,是本文的基线模型。GWR在LR基础上考虑到变量间关系的空间非平稳性,将样点数据的地理位置嵌入到回归参数之中,本文中GWR模型空间核函数使用高斯核函数,采用Akaike信息准则作为建模评价标准<sup>[22]</sup>。SVR可以在LR拟合的线性方程两侧创建间隔带,落在带内的样本将不会计算损失,以此避免过拟合。重要的是,SVR采用核函数对样本进行升维,使其具备非线性拟合能力<sup>[23]</sup>。本文SVR模型核函数使用径向基函数,惩罚系数为430。GRNN是基于径向基神经网络的一种,以样本数据作为后验概率验证条件并进行非参数估计,最后从训练样本中计算GRNN网络中因变量和自变量之间的关联密度函数<sup>[24]</sup>。影响GRNN的主要参数是平滑系数,本文使用的系数为0.1。RF是基于决策树的集成模型,它平均每个决策树的预测结果作为模型的最终输出<sup>[25]</sup>,决策树的个数选定为200,每棵决策树最大深度为17。

## 2.2 模型评价方法

交叉验证(CV)是建模中普遍采用的性能评价方法<sup>[26]</sup>,CV是指在给定的建模样本中,拿出大部分数据用于模型训练,剩余的部分用于模型验证,本文中使用两种CV方法:基于样本的CV(Sample-CV)、基于站点的CV(Site-CV)。

1) Sample-CV是指把所有数据(46693条)随机分为10份,取其中一份作为验证数据,其他9份作为训练数据,并将此过程循环10次以保证每组数据都被验证一次。将10次验证的结果汇总作为模型的最终评价,这种CV方法可以评价模型的整体拟合能力。

2) Site-CV是指将研究区内所有站点(87个)随机分为10份,执行与第一种CV相类似的循环。这种CV方法使验证站点的数据从未参加过模型训练,偏向于评价模型的空间泛化能力<sup>[27]</sup>。

选择的评价指标为:均方根误差(RMSE,  $E_{\text{RMS}}$ )、平均预测误差(MAE,  $E_{\text{MA}}$ )和决定系数 $R^2$ 。计算公式为

$$E_{\text{RMS}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_i^*)^2}, \quad (5)$$

$$E_{\text{MA}} = \frac{1}{n} \sum_{i=1}^n |y_i - y_i^*|, \quad (6)$$

$$R^2 = \frac{R_{\text{SS}}}{T_{\text{SS}}}, \quad (7)$$

式中 $y_i$ 和 $y_i^*$ 分别表示真实值和预测值, $R_{\text{SS}}$ 和 $T_{\text{SS}}$ 分别表示预测值和观察值序列的回归平方和以及总离差平方和。

### 3 结 果

两种 CV 结果如图 4 所示。由图 4 (a) 可知, 在 Sample-CV 中,  $R^2$ 、RMSE、MAE 分别为 0.80、7.72  $\mu\text{g}/\text{m}^3$  和 5.31  $\mu\text{g}/\text{m}^3$ , 表明模型有优秀的拟合能力。与 Sample-CV 结果相比, Site-CV 的  $R^2$  下降了 0.06、RMSE 和 MAE 略有上升, 分别为 0.74、8.95  $\mu\text{g}/\text{m}^3$  和 6.01  $\mu\text{g}/\text{m}^3$ , 意味着在不参与训练的站点上, 模型的预测能力会下降。总体来看, 模型在两种 CV 中都表现良好, 具有很强的预测能力和空间泛化性。

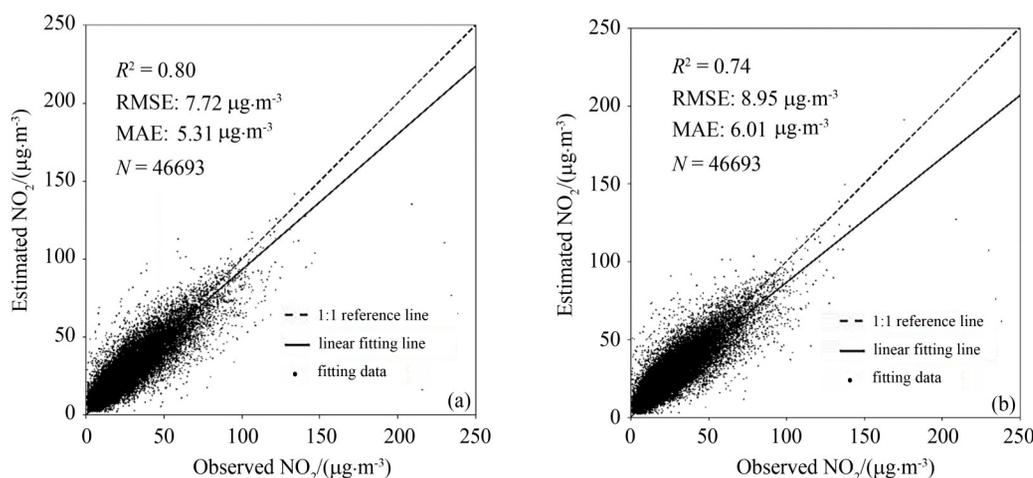


图 4 Sample-CV (a) 和 Site-CV (b) 的散点图

Fig. 4 Scatter plots of Sample-CV (a) and Site-CV (b)

为了证明 DNN 的优势, 采用通用的 CV 方法进行多模型对比。CV 数据组织使用 Python numpy 库, 在随机划分数据集时指定了相同的随机数种子, 以此保证不同的模型严格使用相同的数据。对比结果如表 2 所示。由表可知, 所有模型在 Site-CV 中性能均出现下降, 相比于 LR 和 GWR, 机器学习模型精度更高, 其中 GRNN 在两种 CV 中差别不大, 但是由于其结构简单导致整体性能不佳。RF 在 Sample-CV 中的结果与 DNN 相似, 但是在 Site-CV 中性能下降严重, 因此可以确定 DNN 优于一般常用模型。

表 2 多种模型对比

Table 2 Comparison of the various models

Model	Sample-CV			Site-CV		
	$R^2$	RMSE	MAE	$R^2$	RMSE	MAE
LR	0.68	9.42	7.37	0.55	11.52	9.05
GWR	0.73	8.97	6.46	0.71	9.71	7.20
SVR	0.75	8.39	6.33	0.72	9.35	6.69
GRNN	0.75	8.04	6.32	0.73	8.85	6.28
RF	0.80	7.74	5.39	0.71	9.70	6.84
DNN	0.80	7.72	5.31	0.74	8.95	6.01

模型训练完成后, 在 2019 年 9 月、10 月随机选择三天生成了 NO<sub>2</sub> 浓度分布图 (图 5), 图中圆形标记为站点监测值。由图可以看出, 整体上 DNN 模型预测与站点监测值有较高的一致性, 表明模型具有良好的可靠性。在石家庄南部有监测点的监测值和预测值存在明显差异, 该监测点靠近山区, 地形和气候条件与市区存在较

大差异,模型没有捕捉到这种"异常"现象,需要空间分辨率更高的原始数据。研究区北部也为山区,NO<sub>2</sub>浓度明显比平原地带低,考虑到山区人类活动强度较小,这种预测结果符合NO<sub>2</sub>污染的先验知识,但是该区域没有监测点,无法验证预测结果。

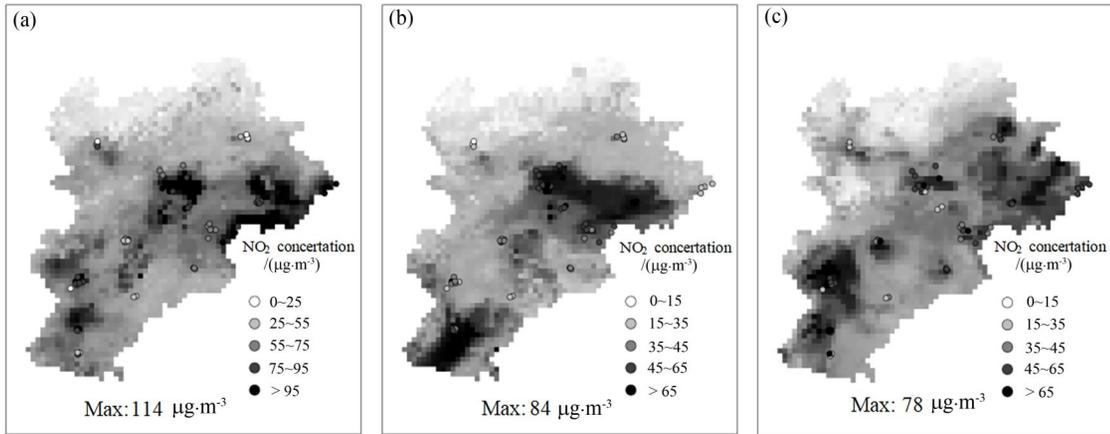


图5 NO<sub>2</sub>空间分布。(a) 2019年9月5日; (b) 2019年9月16日; (c) 2019年10月18日

Fig. 5 Spatial distribution of NO<sub>2</sub>. (a) September 5, 2019; (b) September 16, 2019; (c) October 18, 2019

## 4 结 论

构建了一种基于深度学习对地表NO<sub>2</sub>浓度进行预测的方法,该方法使用卫星遥感数据、气象数据和海拔高度等辅助数据作为输入,以空气质量监测站点的监测值作为真实值,基于DNN建立回归模型。通过两种交叉验证结果证明了该模型具有良好的预测能力和空间泛化性,与其他模型的对比试验表明DNN的性能优于常用的统计和机器学习模型,对NO<sub>2</sub>浓度进行空间预测的结果也与站点监测值高度吻合。试验中数据均为公开数据,易于获得,模型搭建简单、计算成本低且性能稳定,可以作为省级尺度NO<sub>2</sub>历史数据集重建的方法参考。

不足之处主要有两点,首先在研究区北部属于高海拔山区,没有地面监测站点,很难验证在该区域的模型精度;其次在数据选择上,再分析气象资料分辨率较低,后续工作会尝试用气象站点监测数据代替再分析资料,并且添加NO<sub>2</sub>排放清单和道路密度等数据,进一步提高预测准确率。

## 参考文献:

- [1] Song G X, Jiang L L, Chen G H, *et al.* A time-series study on the relationship between gaseous airpollutants and daily mortality in Shanghai [J]. *Journal of Environment and Health*, 2006, 23(5): 390-393.  
宋桂香, 江莉莉, 陈国海, 等. 上海市大气气态污染物与居民每日死亡关系的时间序列研究 [J]. 环境与健康杂志, 2006, 23(5): 390-393.
- [2] Zhang T Y, Shen N C, Zhao X, *et al.* Spatiotemporal variation characteristics of ozone and its population exposure risk

- assessment in Chengdu-Chongqing urban agglomeration during 2015 to 2019 [J]. *Acta Scientiae Circumstantiae*, 2021, 41(10): 4188-4199.
- 张天岳, 沈楠驰, 赵雪, 等. 2015—2019年成渝城市群臭氧浓度时空变化特征及人口暴露风险评价 [J]. *环境科学学报*, 2021, 41(10): 4188-4199.
- [3] Jiang D S. Air quality assessment and exposure risk of different groups in Fujian Province in 2016—2018 [J]. *Low Carbon World*, 2019, 9(3): 12-13.
- 蒋冬升. 福建省2016—2018年空气质量评价及不同人群暴露风险研究 [J]. *低碳世界*, 2019, 9(3): 12-13.
- [4] Wang Q Q, Ye Y J, Zhang J Y, *et al.* Multi-site analysis of acute effects of air pollutants combination exposure on mortality in Jiangsu Province, China [J]. *Chinese Journal of Preventive Medicine*, 2019, 53(1): 86-92.
- 汪庆庆, 叶云杰, 张嘉尧, 等. 江苏省大气污染物联合暴露对人群死亡风险急性效应的多中心研究 [J]. *中华预防医学杂志*, 2019, 53(1): 86-92.
- [5] Shi X Q, Zhao C F, Jiang J H, *et al.* Spatial representativeness of PM<sub>2.5</sub> concentrations obtained using observations from network stations [J]. *Journal of Geophysical Research: Atmospheres*, 2018, 123(6): 3145-3158.
- [6] Briggs D J, Collins S, Elliott P, *et al.* Mapping urban air pollution using GIS: A regression-based approach [J]. *International Journal of Geographical Information Science*, 1997, 11(7): 699-718.
- [7] Zou Y X, Wu Z F, Cao Z. Assessing PM<sub>2.5</sub> exposure risk by coupling land use regression model and population weighted model [J]. *Journal of Geo-Information Science*, 2019, 21(7): 1018-1028.
- 邹雨轩, 吴志峰, 曹峥. 耦合土地利用回归与人口加权模型的PM<sub>2.5</sub>暴露风险评估 [J]. *地球信息科学学报*, 2019, 21(7): 1018-1028.
- [8] Zhao X, Hou L L, Wang X L, *et al.* Simulation of spatial distribution of PM<sub>2.5</sub> and PM<sub>10</sub> concentrations in Beijing in 2019 based on LUR model [J]. *Acta Scientiae Circumstantiae*, 2020, 40(11): 4060-4069.
- 赵雪, 侯丽丽, 王鑫龙, 等. 基于LUR模型的2019年北京地区PM<sub>2.5</sub>与PM<sub>10</sub>浓度空间分异模拟 [J]. *环境科学学报*, 2020, 40(11): 4060-4069.
- [9] Feng C L, Li R K. Spatiotemporal variation analysis of air pollution from 2013 to 2019 in Beijing based on land use regression model [J]. *Acta Scientiae Circumstantiae*, 2021, 41(4): 1231-1238.
- 冯春莉, 李润奎. 基于土地利用回归模型的北京市2013—2019年大气污染时空变化分析 [J]. *环境科学学报*, 2021, 41(4): 1231-1238.
- [10] Wei S M, Pan J H, Tuo W L. Estimation and spatial-temporal distribution characteristic of PM<sub>2.5</sub> concentration by remote sensing in China in 2015 [J]. *Remote Sensing Technology and Application*, 2020, 35(4): 845-854.
- 魏石梅, 潘竟虎, 妥文亮. 2015年中国PM<sub>2.5</sub>浓度遥感估算与时空分布特征 [J]. *遥感技术与应用*, 2020, 35(4): 845-854.
- [11] Deng Y, Liu J P, Liu Y, *et al.* Spatial distribution estimation of PM<sub>2.5</sub> concentration Beijing by applying Bayesian geographic weighted regression model [J]. *Science of Surveying and Mapping*, 2018, 43(10): 39-45.
- 邓悦, 刘纪平, 刘洋, 等. 北京PM<sub>2.5</sub>浓度空间分布的贝叶斯地理加权回归模拟 [J]. *测绘科学*, 2018, 43(10): 39-45.
- [12] Zhan Y, Luo Y Z, Deng X F, *et al.* Satellite-based estimates of daily NO<sub>2</sub> exposure in China using hybrid random forest and spatiotemporal kriging model [J]. *Environmental Science & Technology*, 2018, 52(7): 4180-4189.
- [13] Luo A R. *Research of Prediction Model on Atmospheric PM<sub>2.5</sub> Concentration Using Support Vector Regression* [D]. Beijing: Beijing University of Technology, 2018.
- 罗奥荣. 基于支持向量回归机的大气PM<sub>2.5</sub>浓度预测模型研究 [D]. 北京: 北京工业大学, 2018.
- [14] Yang L. *Optimal-Combined Model for Air Quality Index Forecasting—5 Cities in North China* [D]. Lanzhou: Lanzhou University, 2019.
- 杨玲. 最优-组合模型空气质量指标预测: 以中国华北的5城市为例 [D]. 兰州: 兰州大学, 2019.
- [15] Yuan Q Q, Shen H F, Li T W, *et al.* Deep learning in environmental remote sensing: Achievements and challenges [J].

- Remote Sensing of Environment*, 2020, 241: 111716.
- [16] Zaytar M A, Amrani C E. Machine learning methods for air quality monitoring [P]. *Networking, Information Systems & Security*, 2020.
- [17] Rodríguez J D, Pérez A, Lozano J A. Sensitivity analysis of kappa-fold cross validation in prediction error estimation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 32(3): 569-575.
- [18] Li T W, Shen H F, Zeng C, *et al.* A validation approach considering the uneven distribution of ground stations for satellite-based PM<sub>2.5</sub> estimation [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 1312-1321.
- [19] Li X W, Zhang Y, Jiang S, *et al.* Preliminary application of atmospheric pollution monitoring in Jiangsu Province with TROPOMI sensor onboard sentinel-5P satellite [J]. *Environmental Monitoring and Forewarning*, 2019, 11(2): 10-16.  
李旭文, 张悦, 姜晟, 等. "哨兵-5P"卫星TROPOMI传感器在江苏省域大气污染监测中的初步应用 [J]. *环境监控与预警*, 2019, 11(2): 10-16.
- [20] Baldi P. Gradient descent learning algorithm overview: A general dynamical systems perspective [J]. *IEEE Transactions on Neural Networks*, 1995, 6(1): 182-195.
- [21] Liu J W, Liu Y, Luo X L. Research and development on deep learning [J]. *Application Research of Computers*, 2014, 31(7): 1921-1930.  
刘建伟, 刘媛, 罗雄麟. 深度学习研究进展 [J]. *计算机应用研究*, 2014, 31(7): 1921-1930.
- [22] Qin W Z. *The Basic Theoretics and Application Research on Geographically Weighted Regression* [D]. Shanghai: Tongji University, 2007.  
覃文忠. 地理加权回归基本理论与应用研究 [D]. 上海: 同济大学, 2007.
- [23] Tang F M. *Study of Support Vector Machines Algorithm Based on Statistical Learning Theory* [D]. Wuhan: Huazhong University of Science and Technology, 2005.  
唐发明. 基于统计学习理论的支持向量机算法研究 [D]. 武汉: 华中科技大学, 2005.
- [24] Wei J Y, Ru F. Forecasting the traffic volume by the model of GRNN and studing it's realization [J]. *Journal of Changsha Communications University*, 2006, 22(2): 46-50.  
魏晋雁, 茹锋. 采用GRNN模型进行交通量预测及实现研究 [J]. *长沙交通学院学报*, 2006, 22(2): 46-50.
- [25] Du X, Feng J Y, Lv S Q, *et al.* PM<sub>2.5</sub> concentration prediction model based on random forest regression analysis [J]. *Telecommunications Science*, 2017, 33(7): 66-75.  
杜续, 冯景瑜, 吕少卿, 等. 基于随机森林回归分析的PM<sub>2.5</sub>浓度预测模型 [J]. *电信科学*, 2017, 33(7): 66-75.
- [26] Diego R J, Pérez A, Antonio L J. Sensitivity analysis of kappa-fold cross validation in prediction error estimation [J]. *IEEE transactions on pattern analysis and machine intelligence*, 2010, 32(3): 569-575.
- [27] Li T W, Shen H F, Yuan Q Q, *et al.* Geographically and temporally weighted neural networks for satellite-based mapping of ground-level PM<sub>2.5</sub> [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020, 167: 178-188.