

基于深度学习的空气污染多城市联合预测模型

杨武霖¹, 杨昊¹, 周航¹, 董元昌², 陈朝平³, 李绍涵¹

(1. 成都信息工程大学 计算机学院, 四川 成都 610225; 2. 中国气象局成都高原气象研究所/高原与盆地暴雨旱涝灾害四川省重点实验室, 四川 成都 610072; 3. 四川省气象台, 四川 成都 610071)

摘要: 传统的城市空气污染预测模型仅对成都市历史数据进行时间建模, 忽略了周边城市污染物扩散空间维度的影响。为此, 提出一种基于深度学习的空气污染多城市联合预测模型 Res-Att-SimVP, 包括空间特征提取模块、时间特征提取模块、特征筛选模块、预测模块。其中, 空间特征提取模块使用残差网络提取各城市之间的空间特征信息; 时间特征提取模块使用 Inception 网络进行时序建模; 特征筛选模块使用通道注意力机制和空间注意力机制, 选择性关注不同区域与时刻的特征信息; 预测模块使用全连接网络实现空气污染物浓度预测。集成所有模块可以有效缓解周边城市污染物扩散带来的影响。采用成都市及周边 12 个城市逐小时的气象数据、空气污染物数据、成都市与周边城市间的距离信息, 测试该方法与对照方法在不同时间尺度下对空气污染物浓度的预测性能。结果表明, 与 Res-ConvLSTM 模型相比, Res-Att-SimVP 模型对 PM_{2.5}、PM₁₀、NO₂ 在不同预测时长下的 RMSE、MAE 平均值分别下降 12% 和 15%、11% 和 15%、12% 和 22%, 具有较高的准确性。

关键词: 空气污染预测; 深度学习; 时空数据; 多城市联合; 时间序列

DOI: 10.11907/rjdk.232146

开放科学(资源服务)标识码(OSID):



中图分类号: TP183

文献标识码: A

文章编号: 1672-7800(2024)011-0107-09

Deep Learning-Based Joint Multi-City Prediction Model for Air Pollution

YANG Wulin¹, YANG Hao¹, ZHOU Hang¹, DONG Yuanchang², CHEN Chaoping³, LI Shaohan¹

(1. School of Computer Science, Chengdu University of Information Engineering, Chengdu 610225, China; 2. Sichuan Key Laboratory of Heavy Rainfall, Drought and Flood Hazards in Plateau and Basin, Chengdu Institute of Plateau Meteorology, China Meteorological Administration, Chengdu 610072, China; 3. Sichuan Meteorological Station, Chengdu 610071, China)

Abstract: The traditional urban air pollution prediction model only models the historical data of Chengdu over time, ignoring the influence of the spatial dimension of pollutant diffusion in surrounding cities. To this end, a deep learning based multi city joint prediction model for air pollution, Res Att SimVP, is proposed, which includes spatial feature extraction module, temporal feature extraction module, feature screening module, and prediction module. Among them, the spatial feature extraction module uses residual networks to extract spatial feature information between cities; The time feature extraction module uses Inception network for temporal modeling; The feature filtering module uses channel attention mechanism and spatial attention mechanism to selectively focus on feature information in different regions and time periods; The prediction module uses a fully connected network to achieve air pollutant concentration prediction. Integrating all modules can effectively alleviate the impact of pollutant diffusion in surrounding cities. The hourly meteorological data, air pollutant data, and distance information between Chengdu and surrounding cities were used to test the predictive performance of this method and the control method for air pollutant concentrations at different time scales. The results showed that compared with the Res ConvLSTM model, the Res Att SimVP model reduced the average RMSE and MAE of PM_{2.5}, PM₁₀, and NO₂ by 12% and 15%, 11% and 15%, and 12% and 22%, respectively, at different predic-

收稿日期: 2023-11-10

扫描二维码阅读全文:



基金项目: 四川省科技计划项目(2022YFS0542, 2023JDZH0034)

作者简介: 杨武霖(1999-), 男, 成都信息工程大学计算机学院硕士研究生, 研究方向为智慧气象; 杨昊(1981-), 男, 博士, 成都信息工程大学计算机学院副教授、硕士生导师, 研究方向为智慧气象、人工智能与计算优化; 周航(1991-), 男, 博士, 成都信息工程大学计算机学院讲师, 研究方向为机器学习与高性能计算; 董元昌(1989-), 男, 中国气象局成都高原气象研究所副研究员, 研究方向为高原与盆地天气; 陈朝平(1979-), 女, 四川省气象台正高级工程师, 研究方向为数值预报释用与智能网格预报技术; 李绍涵(1999-), 男, 成都信息工程大学计算机学院硕士研究生, 研究方向为智慧气象。本文通讯作者: 杨昊。

tion durations, demonstrating high accuracy.

Key Words: air pollution prediction; deep learning; spatio-temporal data; multi-city joint; time series

0 引言

近年来,全球范围内空气污染问题日益严峻,对人类健康造成巨大威胁^[1-2]。据世界卫生组织统计,每年约有420万人由于室外空气污染导致死亡^[3]。尤其是在城市地区,大量机动车排放、工业生产和能源消耗等因素导致空气质量不断恶化,给人们带来健康影响和经济负担^[4-5]。

成都作为中国西南地区的重要城市,其独特的历史文化与繁荣的经济发展使之成为焦点^[6]。然而,随着城市的迅猛发展和人口数量的持续增加,空气污染问题日益凸显。成都市是国内空气污染最严重的5个城市之一,其空气质量一直是市民关心的热点话题,也是城市可持续发展面临的重大挑战之一^[7,8]。多项研究表明,空气污染物与心血管疾病、呼吸系统疾病和精神疾病等存在关联^[9-11]。此外,空气污染还会影响能见度,增加交通事故风险^[12]。因此,及时有效地预测空气污染程度对于保障居民健康与城市可持续发展至关重要。

1 相关研究

现有空气污染预测方法主要包括数值预报方法、统计方法和人工智能方法3种。数值预报方法使用观测数据建立大气化学模型和物理模型,模拟大气中污染物的传输、扩散、反应和沉降过程^[13]。该方法可以预测污染物浓度和分布情况,但是无法完全捕捉大气中所有的物理和化学过程,因此预测结果常常受到模型不确定性的影响。

统计方法基于历史数据和统计模型建模,不依赖大气化学和物理过程^[14]。例如,Cortina等^[15]利用聚类算法寻找PM10与气象变量之间的关系,然后利用多层回归对PM10浓度进行预测,发现气象变量是空气污染预测的重要因素,但是忽略了非线性关系,导致模型预测精度较低;Mirsanjari等^[16]利用自回归、移动平均值、自回归移动平均值、自回归综合移动平均值与季节自回归综合移动平均值等5个时间序列指标预测空气污染物浓度的变化,但是该方法无法捕捉到复杂的时空关系。

人工智能方法主要包括机器学习和深度学习方法,主要思想是通过模拟人类大脑神经元之间的连接方式构建和训练具有多层结构的神经网络模型,从而实现数据的高层次抽象与表征学习^[17]。例如,Murali等^[18]采用随机森林回归、LASSO回归、弹性网络回归等机器学习算法实现了空气质量的预测,但是需要手动提取特征,工作量繁重且耗时较多;Bihter等^[19]比较了循环神经网络(Recurrent Neural Network, RNN)和长短期记忆网络(Long Short-Term Memory, LSTM)模型对PM10和SO₂等空气污染物的

预测效果,结果表明LSTM具有更好的预测性能;王健等^[20]利用LSTM对合肥地区的PM2.5浓度进行预测,虽然考虑了时间依赖关系,但是没有考虑城市空气污染物的空间相关性;Liu等^[21]使用CNN-LSTM(Convolutional Neural Networks-LSTM)集成模型对PM2.5进行时间序列预测,集成了两个模块的优点,但深层网络容易导致梯度消失,模型精度较低;Li等^[22]提出TCN-BiLSTM-DMAttention模型,实现了对空气污染物1h的短期预测,但模型结构不适合长期预测;Zhang等^[23]提出Res-ConvLSTM模型对城市污染物浓度和气象数据进行时空特征提取,实现了PM2.5浓度的预测,但长期预测效果不佳。

空气污染预测不仅需要关注时序性,而且需要关注空间维度的区域扩散问题^[24-25]。为提取区域内相邻城市之间的空间相关特征,需要充分利用气象数据和污染数据。利用相邻城市对目标城市进行空气污染预测可以看作是一个时空预测任务,因此本文选择Gao等^[26]提出的视频预测模型SimVP作为基线模型。同时,综合成都市及周边12个城市的空气污染物数据、气象数据、成都市与周边城市的距离信息,提出一种基于深度学习的多城市联合预测模型Res-Att-SimVP,用于成都市空气污染物浓度的预测。本文主要贡献如下:①提出一种包含残差块的空间特征提取模块,可以在建立深层模型的同时防止梯度消失和爆炸,更好地提取空间特征;②提出一种包含通道注意力机制和空间注意力机制的特征筛选模块,使得该网络可对不同时刻的历史数据分配不同权重的注意力以及有选择地强调或抑制特定区域的特征,从而进一步提高模型的预测精度;③充分考虑周边城市对成都市的影响,包括空气污染物数据、气象数据、与成都市的距离信息等;④在真实数据集上从不同角度评估Res-Att-SimVP模型与其他多种模型的预测性能。

2 空气污染预测模型构建

2.1 SimVP模型

SimVP没有使用RNN、LSTM、Transformer等复杂模块,是一种完全基于CNN,采用均方误差损失估计方法进行端到端训练,且具有较高精度的简单视频预测模型,因此可以作为一个普通的基线模型^[27]。SimVP的各个模块均以CNN为基础,由编码器、翻译器与解码器组成,结构如图1所示。其中,编码器用于提取空间特征;翻译器学习时间演化;解码器整合时空信息用于预测未来帧。

2.2 Res-Att-SimVP模型

Res-Att-SimVP是基于残差块与注意力机制的SimVP时空预测模型,其中“Res”为残差网络,“Att”为注意力机制网络。该模型的训练过程可描述为从原始输入到期望




Fig. 1 SimVP model structure
图1 SimVP模型结构

输出的映射, 其中输入为成都市及周边共 13 个城市过去 N 小时的污染物浓度、气象数据、成都市与周边城市间的距离信息; 输出为成都市未来 T 小时的污染物浓度。Res-Att-SimVP 模型由空间特征提取模块、时间特征提取模型、特征筛选模块、预测模块组成, 结构如图 2 所示。其中, 空间特征提取模块采用堆叠残差模块提取数据的空间信息; 时间特征提取模块采用堆叠的 Inception 模块提取时间信息; 特征筛选模块采用双注意力机制模型对空间特征提取模块和时间特征提取模块提取的空间和时间特征进行筛选, 帮助网络更好地选择哪些特征对当前任务最有用, 从而减少冗余信息, 提高模型性能; 预测模块采用全连接网络整合之前模块提取的时空特征, 完成最后预测。

2.2.1 空间特征提取模块

SimVP 堆叠多个 ConvNormReLU 模块提取空间特征, 其中 ConvNormReLU 模块由 Conv2d、LayerNorm 与 LeakyReLU 组成, 在加大网络深度时会导致梯度消失, 提取空间特征信息效果不理想。因此, 本文加入残差块解决该问题。残差块结构如图 3 所示, 输入数据 x 通过一系列卷积层后得到新数据, 新数据与原始输入数据相加, 通过激活函数得到残差块的输出。残差块的核心公式为:

$$X_{i+1} = F(X_i, W_i) + h(x_i) \quad (1)$$

式中: $F(X_i, W_i)$ 为残差映射部分, $h(x_i)$ 为恒等映射部分。

2.2.2 时间特征提取模块

时间提取模块使用 N_i 个 Inception 模块学习时间演化, 即在 (H, W) 上卷积 $T \times C$ 通道。Inception 模块包含一个 1×1 内核的 Conv2d, 后接 GroupConv2d 并行运算符, 结构如图 4 所示。该模块采用多个不同尺度的卷积核, 可同时捕捉多种不同尺度的特征, 以及数据中的抽象模式和结构, 能有效处理复杂的时间序列数据。隐藏的特征公式为:

$$z_j = \text{Inception}(z_{i-1}), N_s < j \leq N_s + N_i \quad (2)$$

式中: 输入 z_{j-1} 和输出 z_j 形状分别为 $(T \times C, H, W)$ 和 $(\hat{T} \times \hat{C}, H, W)$ 。

2.2.3 特征筛选模块

不同特征信息对模型预测有不同的贡献程度, 不重要的噪声信息会造成预测精度下降。为此, 本文提出一种将通道注意力机制与空间注意力机制相结合的双注意力机




Fig. 2 Res-Att-SimVP model structure
图2 Res-Att-SimVP模型结构

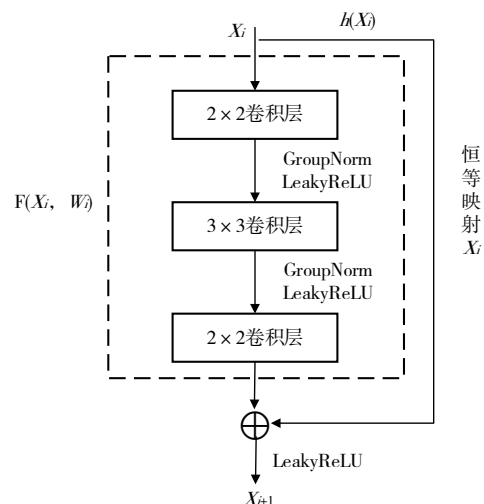


Fig. 3 Residual block structure
图3 残差块结构

制, 实现对数据中两种特征信息的筛选, 使该网络可对不同时刻的历史数据分配不同权重的注意力, 有选择地强调




Fig. 4 Inception module structure

图4 Inception模块结构

或抑制特定区域的特征,进一步提高模型预测精度。该模块结构如图5所示。




Fig. 5 Feature filtering module

图5 特征筛选模块

(1)通道注意力机制。该机制主要用于处理CNN中的通道信息,自动学习不同通道能提高模型性能。首先,对输入的特征图进行全局平均池化和最大全局池化,得到两个特征图;其次,将这两个特征图输入到两个全连接层中,并对其求和;再次,通过 sigmoid 函数接收最终的输出特征图,以获得0~1之间的权重系数;最后,将权重系数与输入特征图相乘,得到输出特征图。具体计算公式为:

$$M_c(F) = \sigma(MLP(AvgPool(F)) + MLP(MaxPool(F))) = \sigma(W_1(W_0(F_{avg}^c) + W_1(W_0(F_{max}^c)))) \quad (3)$$

式中: σ 表示sigmoid函数; $W_0 \in \mathbb{R}^{r \times c}$, $W_1 \in \mathbb{R}^{c \times r}$ 。

(2)空间注意力机制。该机制关注不同位置的信息并有选择地强调或抑制特定区域的特征。首先,空间注意力模块对输入特征分别进行最大池化和平均池化,得到的两个特征图通过一个卷积层缩减到一个通道;其次,通过 Sigmoid 层生成空间权重系数;最后,将空间权重系数与输入特征相乘后获得最终特征图。具体计算公式为:

$$M_s(F) = \sigma(f^{7 \times 7}([AvgPool(F); MaxPool(F)])) = \sigma(f^{7 \times 7}([F_{avg}^s; F_{max}^s])) \quad (4)$$

式中: σ 表示sigmoid函数; $f^{7 \times 7}$ 表示滤波器大小为7×7的卷积操作。

2.2.4 预测模块

预测模块的输入为前几个模块提取的时空特征,即N个特征节点;输出为成都市某时段的污染物浓度数值。该模块采用全连接层将模型前几个模块提取的时空特征转化为最终预测值,即将模型输出映射到所需的预测空间。全连接网络将前一层的特征信息传递给当前层的每个节点,实现了特征的全面传递与组合。通过不断调整权重和

偏置项使得输出值与实际值之间的差距最小化,从而实现输入数据的学习与预测。预测模块包含3个全连接层,其节点分别为256、128和T,其中T表示成都市未来T小时的污染物浓度。结构如图6所示。




Fig. 6 Prediction module structure

图6 预测模块结构

3 实验方法与结果分析

3.1 数据来源及预处理

选用四川省成都市及周边12个城市(德阳市、遂宁市、眉山市、绵阳市、南充市、乐山市、雅安市、内江市、巴中市、资阳市、阿坝州、宜宾市)2015年6月6日至2021年11月14日逐小时的气象数据、空气污染物数据以及成都市与周边城市间的距离信息,包括PM2.5、PM10、SO₂、NO₂、O₃、CO、AQI、温度、气压、相对湿度、风向、风速、降水、能见度与距离。成都市及周边城市分布如图7所示。

PM2.5、PM10与NO₂是成都市的主要空气污染物。分别对气象数据和污染物数据中与PM2.5、PM10和NO₂相关的因子进行 Pearson 相关性分析,结果见表1、表2。可以看




Fig. 7 Distribution of Chengdu and neighboring cities

图7 成都市及周边城市分布

出, PM2.5、PM10、NO₂ 与各项污染物因子以及气象因子之间均存在一定的相关性, 因此将污染物数据和气象数据的 14 个因子作为输入特征。

Table 1 Correlation analysis of pollutant factors

表 1 污染物因子相关性分析

污染物	PM2.5	PM10	NO ₂	SO ₂	O ₃	CO	AQI
PM2.5	1	0.9	0.5	0.5	-0.3	0.7	0.9
PM10	0.9	1	0.7	0.5	-0.2	0.6	0.9
NO ₂	0.5	0.7	1	0.4	-0.4	0.6	0.5

Table 2 Correlation analysis of meteorological factors

表 2 气象因子相关性分析

污染物	气压	相对湿度	风向	风速	降水	能见度	污染物
PM2.5	0.2	0.1	0.08	-0.3	-0.2	-0.6	PM2.5
PM10	0.2	0.1	0.09	-0.3	-0.2	-0.5	PM10
NO ₂	0.1	0.1	0.2	-0.5	-0.2	-0.3	NO ₂

计算成都市与周边 12 个城市空气质量的相关系数, 结果如表 3 所示。可以看出, 距离成都市越近, 相关性系数越高, 表明成都市除需预防本地污染物外, 还需注意预防周边城市污染物, 体现了空气污染物的空间相关性^[28]。考虑到周边城市对成都市污染物预测有不同程度的影响, 将与成都市的距离作为位置信息加入到输入特征中。

Table 3 Correlation analysis of air quality between Chengdu and neighboring cities

表 3 成都市与周边城市空气质量的相关性分析

城市	空气质量相关系数
眉山市	0.93
德阳市	0.92
乐山市	0.88
绵阳市	0.88
资阳市	0.87
内江市	0.82
遂宁市	0.82
雅安市	0.80
宜宾市	0.81
南充市	0.78
巴中市	0.69
阿坝州	0.48

为使数据适配模型并提高模型的预测精度, 在进行模型训练前需进行数据预处理, 步骤如下: ①数据填充。研究发现, 空气污染物数据与气象数据在大多数时间可保持稳定, 不经常出现突然的数值变化, 因此本文采用简单的均值法进行插值来处理缺失数据; ②数据特征融合。为了更好地捕捉空间和时间特征, 采用特征融合方法将每个城市逐小时的空气污染数据、气象数据、成都市与周边城市间的距离信息合并成一个 15 个因子的数据向量。具体来说, 每个城市 1 h 的数据被表示为一个维度为 1×15 的数据点, 13 个城市的数据集以一个 13×15 的矩阵形式呈现, 具体如图 8 所示; ③数据归一化。数据集包含多个特征, 不同的特征量纲会导致模型的收敛速度与精度不同。采用最大最小归一化方法, 将数据转换至 0~1 的范围, 计算公

式为 $x_{\text{归一化后}} = \frac{x_{\text{原始}} - \min}{\max - \min}$; ④数据集划分。将 2015 年 6 月 6 日—2021 年 11 月 14 日的数据按照 7:1.5:1.5 的比例划分为训练集、验证集和测试集。




Fig. 8 Data filling and feature fusion

图 8 数据填充与特征融合

3.2 评价指标

采用均方根误差 (Root Mean Squared Error, RMSE) 和平均绝对误差 (Mean Absolute Error, MAE) 作为评价指标衡量空气污染物浓度预测的精确度。评价指标数值越小, 模型预测精度越高。计算公式为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (6)$$

式中: n 表示测试集的总数量; y_i 表示污染物浓度的真实值; y'_i 表示模型预测的污染物浓度。

3.3 实验结果与分析

3.3.1 周边城市数量与距离对预测结果的影响

为分析城市数量对预测结果的影响, 分别选择成都市周边 8 个城市 (眉山市、绵阳市、南充市、乐山市、雅安市、内江市、巴中市、资阳市)、10 个城市 (眉山市、绵阳市、南充市、乐山市、雅安市、内江市、巴中市、资阳市、阿坝州、宜宾市)、12 个城市 (德阳市、遂宁市、眉山市、绵阳市、南充市、乐山市、雅安市、内江市、巴中市、资阳市、阿坝州、宜宾市) 进行比较, 实验结果如表 4 所示。可以看出, 选择较多、距离较近的城市有更好的预测效果。

Table 4 Prediction results for different numbers of cities

表 4 不同城市数量预测结果

污染物	8		10		12	
	RMSE	MAE	RMSE	MAE	RMSE	MAE
PM2.5	10.441	7.151	10.059	6.684	9.154	6.053
PM10	16.224	11.049	15.942	10.890	14.539	9.652
NO ₂	9.403	7.008	9.213	6.857	8.065	5.932

周边城市因距离不同对成都市的污染物预测有不同的贡献程度。为验证距离信息是否会提升模型的预测精度, 进行比较实验, 结果如表 5 所示。可以看出, 距离信息作为输入特征可以提高预测精度。

3.3.2 比较实验

为进一步验证 Res-Att-SimVP 模型的性能, 在不同预测时长上与现有常用空气污染预测模型进行比较, 包括 RNN、LSTM、CNN-LSTM、ConvLSTM、Res-ConvLSTM 模型。结果见图 9、图 10、图 11、图 12、图 13、图 14。可以看出, 所

Table 5 Effect of distance information on the prediction accuracy of model

表 5 距离信息对模型预测精度的影响

污染物	不含距离信息		含距离信息	
	RMSE	MAE	RMSE	MAE
PM2.5	10.233	7.055	9.154	6.053
PM10	15.784	10.793	14.539	9.652
NO ₂	9.476	7.080	8.065	5.932

有模型随着预测时长的增加预测效果逐渐下降,这是由于预测时间越长,各特征相关性越复杂,模型预测难度越大。其中,RNN 和 LSTM 模型忽略了城市之间的空间相关性,预测精度较低;CNN-LSTM、ConvLSTM 和 Res-ConvLSTM 模型考虑了时间和空间特征,预测准确率相较 RNN 和 LSTM 模型有一定提高;Res-Att-SimVP 模型在所有预测时长中的 RMSE 和 MAE 均为最低,特别是中长期预测表现突出。




Fig. 9 RMSE of PM2.5 prediction by various models
图 9 各模型 PM2.5 预测的 RMSE

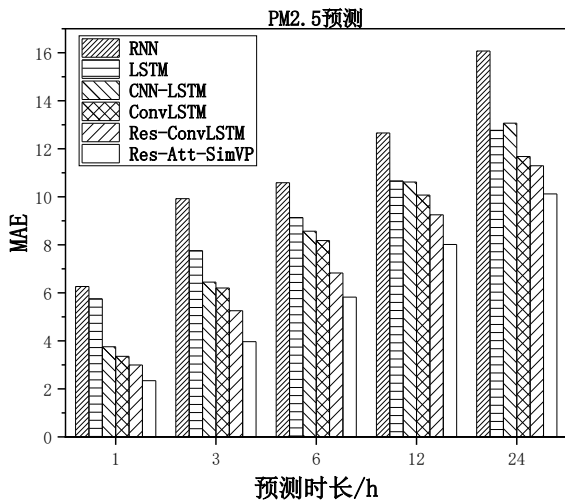


Fig. 10 MAE of PM2.5 prediction by various models
图 10 各模型 PM2.5 预测的 MAE

如表 6、表 7、表 8 所示,与对照模型中表现最好的 Res-ConvLSTM 模型相比,Res-Att-SimVP 模型在不同预测时




Fig. 11 RMSE of PM10 prediction for each model
图 11 各模型 PM10 预测的 RMSE

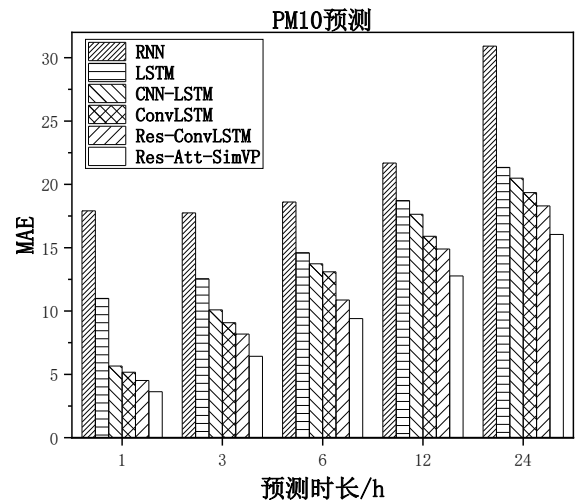


Fig. 12 MAE of PM10 prediction for each model
图 12 各模型 PM10 预测的 MAE




Fig. 13 RMSE of NO₂ prediction for each model
图 13 各模型 NO₂ 预测的 RMSE

长下预测 PM2.5、PM10、NO₂ 的 RMSE、MAE 平均值分别下降了 12% 和 15%、11% 和 15%、12% 和 22%。表中 (T, N)

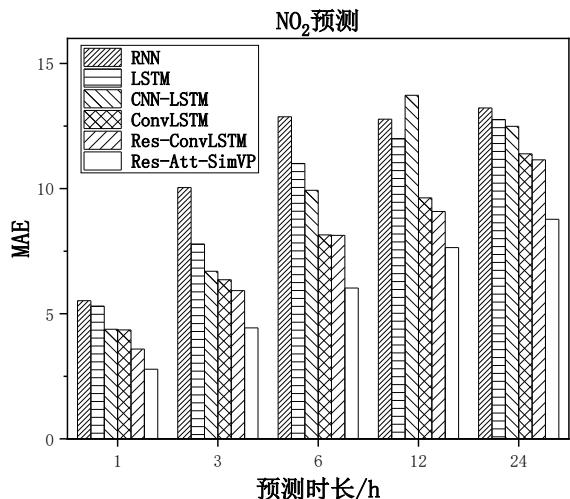


Fig. 14 MAE of NO₂ prediction for each model

图 14 各模型 NO₂ 预测的 MAE

表示使用过去 N 小时的历史数据预测 T 小时后成都市的空气中污染物浓度。

Table 6 PM_{2.5} prediction result comparison

表 6 PM_{2.5} 预测结果比较

(T, N)	Res-ConvLSTM		Res-Att-SimVP	
	RMSE	MAE	RMSE	MAE
(1, 3)	4.826	2.994	4.087	2.341
(3, 7)	7.640	5.256	6.257	3.964
(6, 10)	9.947	6.828	8.738	5.824
(12, 12)	13.286	9.252	11.921	8.016
(24, 18)	16.245	11.291	14.769	10.119
均值	10.389	7.124	9.154	6.053

Table 7 PM₁₀ prediction result comparison

表 7 PM₁₀ 预测结果比较

(T, N)	Res-ConvLSTM		Res-Att-SimVP	
	RMSE	MAE	RMSE	MAE
(1, 3)	7.124	4.515	6.218	3.625
(3, 7)	11.744	8.178	10.113	6.426
(6, 10)	15.515	10.867	13.841	9.400
(12, 12)	21.168	14.897	19.001	12.767
(24, 18)	25.674	18.298	23.521	16.043
均值	16.245	11.351	14.539	9.652

Table 8 NO₂ prediction result comparison

表 8 NO₂ 预测结果比较

(T, N)	Res-ConvLSTM		Res-Att-SimVP	
	RMSE	MAE	RMSE	MAE
(1, 3)	4.837	3.586	3.951	2.781
(3, 7)	7.938	5.923	6.281	4.434
(6, 10)	10.742	8.131	8.419	6.027
(12, 12)	11.908	9.084	10.086	7.641
(24, 18)	14.169	11.148	11.586	8.775
均值	9.189	7.574	8.065	5.932

为了更加直观地观察预测结果, 将 Res-Att-SimVP、Res-ConvLSTM 模型的预测值与真实值进行可视化比较, 结果如图 15、图 16、图 17 所示。可以看出, Res-ConvLSTM 模型的预测结果与真实值有一定差距, 峰值时更明显; Res-Att-SimVP 模型与 3 种污染物的真实值拟合效果

更好。




Fig. 15 Visualization of PM_{2.5} prediction results

图 15 PM_{2.5} 预测结果可视化




Fig. 16 Visualization of PM₁₀ prediction results

图 16 PM₁₀ 预测结果可视化




Fig. 17 Visualization of NO₂ prediction results

图 17 NO₂ 预测结果可视化

3.3.3 消融实验

对添加或改善后的各个模块进行消融实验, 以检验其有效性。以 SimVP 为基准模型, Att-SimVP 模型在基准模型的基础上增加了双注意力机制模块; Res-SimVP 模型在基准模型的基础上增加了残差块; Res-Att-SimVP 模型在基准模型的基础上同时增加了双注意力机制模块和残差块。为确保实验的一致性和公平性, 消融实验中的各个模型只改变了对应的模块, 不会改变训练数据集以及模型超参数。

图 18、图 19、图 20、图 21、图 22、图 23 分别为 SimVP、Att-SimVP、Res-SimVP、Res-Att-SimVP 模型在不同预测时长下对 PM_{2.5}、PM₁₀、NO₂ 的预测结果。可以看出: ①与 SimVP 相比, Att-SimVP 模型预测 PM_{2.5}、PM₁₀ 和 NO₂ 的 RMSE 和 MAE 有所下降, 表明双注意力机制的引入对模型预测性能有一定提升; ②与 SimVP 相比, Res-SimVP 模型

预测PM2.5、PM10和NO₂的RMSE和MAE有所下降,表明残差连接的引入对模型预测性能有一定提升;③Res-Att-SimVP模型预测PM2.5、PM10和NO₂的RMSE和MAE最低,表明同时引入双注意力机制和残差连接对模型预测性能提升效果最佳,两个模块均有效。




Fig. 18 PM2.5 prediction ablation experiment RMSE index
图 18 PM2.5 预测消融实验 RMSE 指标




Fig. 19 PM2.5 prediction ablation experiment MAE index
图 19 PM2.5 预测消融实验 MAE 指标

4 结语

为更加准确及时地监测成都市的空气质量,本文提出一种基于深度学习的空气污染多城市联合预测模型 Res-Att-SimVP。该模型在 SimVP 网络的基础上引入残差块和注意力机制,解决了梯度消失、梯度爆炸和噪声信息干扰的问题;同时考虑了城市间污染物的空间关联性和时间关联性,有效提高了空气污染物浓度预测精度。与 LSTM、ConvLSTM、Res-ConvLSTM 等常用预测模型相比,所提模型表现出更优的预测性能。然而本研究未考虑周边城市




Fig. 20 PM10 prediction ablation experiment RMSE index
图 20 PM10 预测消融实验 RMSE 指标




Fig. 21 PM10 prediction ablation experiment MAE index
图 21 PM10 预测消融实验 MAE 指标

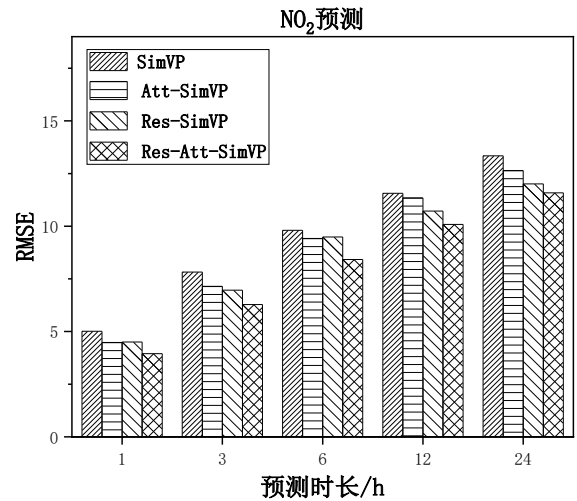


Fig. 22 NO₂ prediction ablation experiment RMSE index
图 22 NO₂ 预测消融实验 RMSE 指标

的方位信息以及其他复杂气象因素,后续将考虑使用位置编码技术对周边城市在预测中的权重进行更加深入的

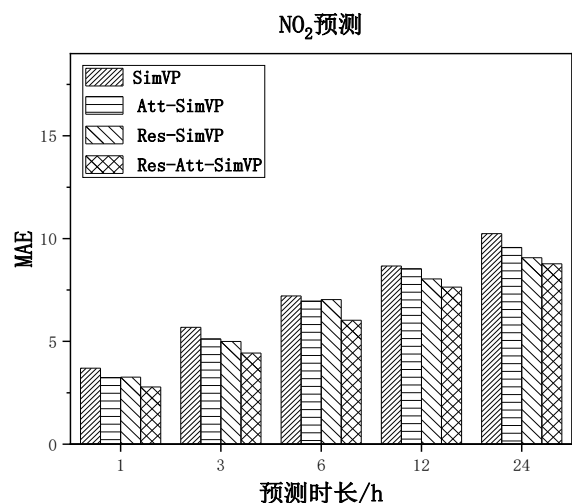


Fig. 23 NO₂ prediction ablation experiment MAE index

图 23 NO₂ 预测消融实验 MAE 指标

研究^[29]。

参考文献:

- RENTSCHLER J, LEONOVA N. Global air pollution exposure and poverty [J]. *Nature Communications*, 2023, 14(1): 4432–4442.
- KIM Y, RADOIAS V. Air pollution exposure and long-term health outcomes [J]. *International Journal of Environmental Research and Public Health*, 2022, 19(21): 14019–14027.
- SHADDICK G, THOMAS M L, MUDU P, et al. Half the world's population are exposed to increasing air pollution [J]. *NPJ Climate and Atmospheric Science*, 2020, 3(1): 23–27.
- SOLEIMANI M, AKBARI N, SAFFARI B, et al. Estimation of economic costs of air pollution caused by motor vehicles in Iran (Isfahan) [J]. *Environmental Science and Pollution Research*, 2021, 28(47): 66535–66555.
- ZIOLA N, LABY K S. The content of selected heavy metals and polycyclic aromatic hydrocarbons (PAHs) in PM₁₀ in urban-industrial area [J]. *Sustainability*, 2020, 12(13): 5284–5299.
- WANG M S, CHEN J J, GU W T. The exploration and practice of building new types of think tanks with Chinese local characteristics for the new era—taking Chengdu Economic Development Academy (Chengdu Economic Information Center) as an example [J]. *Think Tank: Theory&Practice*, 2023, 8(3): 99–108.
王萌森, 陈俊江, 顾雯婷. 新时代中国地方特色新型智库建设的探索与实践—以成都市经济发展研究院(成都市经济信息中心)为例 [J]. *智库理论与实践*, 2023, 8(3): 99–108.
- WANG X J, CHEN L, GUO K, et al. Spatio-temporal trajectory evolution and cause analysis of air pollution in Chengdu, China [J]. *Journal of the Air & Waste Management Association*, 2022, 72(8): 876–894.
- DENG S L. Exploring the paths of Chengdu's high-quality economic development under the goals of carbon peak and carbon neutrality [J]. *China Journal of Commerce*, 2023(14): 141–145.
邓苏玲. “双碳”目标下成都经济高质量发展路径探索 [J]. *中国商论*, 2023(14): 141–145.
- LI Y C, LIU J M, LI J. Chinese expert consensus on air pollution and cardiovascular disease [J]. *Chinese Circulation Journal*, 2021, 36(1): 14–21.
李镒冲, 刘佳敏, 李静. 空气污染与心血管疾病专家共识 [J]. *中国循环杂志*, 2021, 36(1): 14–21.
- GODOY A R L, SILVA A E. Short-term relation between air pollutants and hospitalizations for respiratory diseases: analysis by temporal association rules [J]. *Environmental Monitoring and Assessment*, 2023, 195: 854–876.
- HONG J, KANG J M, CHO S E, et al. Significant association between increased risk of emergency department visits for psychiatric disorders and air pollutants in south Korea [J]. *Journal of Exposure Science & Environmental Epidemiology*, 2023, 33(3): 490–499.
- ZHANG C, WU M, CHEN J U, et al. Weather visibility prediction based on multimodal fusion [J]. *IEEE Access*, 2019, 7(7): 74776–74786.
- FU C. Numerical forecasting system and its application in Guangzhou [J]. *Environmental Science and Management*, 2006, 31(7): 161–165.
符春. 数值预报方法在广州空气质量预报中的应用 [J]. *环境科学与管理*, 2006, 31(7): 161–165.
- HINOJOSA B I, INFANTE V O, VALLEJO M. Distribution of PM_{2.5} air pollution in Mexico city: spatial analysis with land-use regression model [J]. *Applied Sciences*, 2019, 9(14): 2936–2951.
- CORTINA J M G, QUINTANILLA D J, VEGA C A, et al. Development of a model for forecasting of PM₁₀ concentrations in Salamanca, Mexico [J]. *Atmospheric Pollution Research*, 2015, 6(4): 626–634.
- MIRSANJARI M M, ZARANDIAN A, MOHAMMADYARI F, et al. Investigation of the impacts of urban vegetation loss on the ecosystem service of air pollution mitigation in Karaj metropolis, Iran [J]. *Environmental Monitoring and Assessment*, 2020, 192: 501–523.
- JANIESCH C, ZSCHECH P, HEINRICH K. Machine learning and deep learning [J]. *Electron Markets*, 2021, 31(3): 685–695.
- MURALI M, SATISH M, RAJALAKSHMI V R. Prediction and analysis of air pollution using machine learning [J]. *SN Computer Science*, 2022, 3(6): 483–492.
- BIHTER D, OMER O D, SUAT T. Prediction of air pollutants for air quality using deep learning methods in a metropolitan city [J]. *Urban Climate*, 2022, 46: 101291–101302.
- WANG J, SONG Y, WU T. Prediction model based on LSTM network and error compensation [J]. *Computer Technology and Development*, 2023, 33(3): 133–138.
王健, 宋颖, 吴涛. 基于 LSTM 网络与误差补偿的预测模型 [J]. *计算机技术与发展*, 2023, 33(3): 133–138.
- LIU K, ZHANG Y H, HE H, et al. Time series prediction of the chemical components of PM_{2.5} based on a deep learning model [J]. *Chemosphere*, 2023, 342: 140153–140163.
- LI W L, IANG X C. Prediction of air pollutant concentrations based on TCN-BiLSTM-DMAAttention with STL decomposition [J]. *Scientific Reports*, 2023, 13(1): 4665–4676.
- ZHANG B, ZOU G J, QIN D M. RCL-learning: resnet and convolutional long short-term memory-based spatiotemporal air pollutant concentration prediction model [J]. *Expert Systems with Applications*, 2022, 207: 118017–118031.
- MCKINLEY G, ZUK M, HÖJER M, et al. Quantification of local and global benefits from air pollution control in Mexico city [J]. *Environmental Science & Technology*, 2005, 39(7): 1954–1961.
- ZHU J L, YI X, SUN C X, et al. An extended spatio-temporal granger causality model for air quality estimation with heterogeneous urban big data [J]. *IEEE Transactions on Big Data*, 2017, 3(3): 307–319.
- GAO Z, TAN C, WU L, et al. Simvp: simpler yet better video prediction [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 3170–3180.
- RUSLAN R, DENIS V, ALEXEY A, et al. Latent video transformer [DB/OL]. <http://arxiv.org/pdf/2006.10704>.
- HU J, WANG Y, YING Q, et al. Spatial and temporal variability of PM_{2.5} and PM₁₀ over the north China plain and the Yangtze river delta, China [J]. *Atmospheric Environment*, 2014, 95: 598–609.
- WASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [DB/OL]. <https://arxiv.org/abs/1706.03762>.

(责任编辑: 尹晨茹 毛宛婷)