

基于自变权的CNN & LSTM组合 PM_{2.5}浓度预测

——以北京为例

严 洁, 王桂芝*

南京信息工程大学数学与统计学院, 江苏 南京

收稿日期: 2022年3月26日; 录用日期: 2022年4月21日; 发布日期: 2022年4月28日

摘 要

本文基于CNN和LSTM神经网络模型, 构建自变权的CNN & LSTM组合模型。首先分析污染物因子和气象因子与PM_{2.5}的相关性, 确定PM_{2.5}浓度的预测因子, 再对数据进行标准化预处理, 用CNN模型和LSTM模型分别进行预测, 最后, 采用基于自变权的CNN & LSTM组合模型进行预测, 并比较不同模型的预测效果。结果表明: 1) PM_{2.5}浓度与空气污染物(PM₁₀, SO₂, NO₂, CO, O₃)之间的相关性总体高于PM_{2.5}浓度与气象因子变量(温度、湿度、风速、气压、降水量)之间的相关性, 其中NO₂与PM_{2.5}相关性最强, 降水量与PM_{2.5}相关性最弱; 2) CNN-LSTM (variable)模型的预测结果优于LSTM、CNN、CNN-LSTM (equal)、CNN-LSTM (residual)模型; 3) CNN-LSTM (variable)模型的RMSE、MAE和MAPE的值分别为2.07%、9.66%和8.66%。

关键词

LSTM, CNN, PM_{2.5}预测, 变权组合

Combined PM_{2.5} Concentration Prediction Model Based on CNN & LSTM of Variable Weight

—A Case Study of Beijing

Jie Yan, Guizhi Wang*

School of Mathematics and Statistics, Nanjing University of Information Science and Technology, Nanjing Jiangsu

Received: Mar. 26th, 2022; accepted: Apr. 21st, 2022; published: Apr. 28th, 2022

*通讯作者。

Abstract

An adaptive weighting method based on CNN and LSTM was designed to build a combined CNN model and LSTM network with variable weights. Firstly, analyze the correlation between pollutant factors and meteorological factors and $PM_{2.5}$, and determine the predictive factors of $PM_{2.5}$ concentration. Then, the preprocessed data sets were input into CNN model and LSTM model for prediction respectively. Finally, the CNN & LSTM combined model based on the variable weight is used for prediction, and the prediction effects of different models are compared. The results show that: 1) The correlation between pollutant variables and $PM_{2.5}$ is generally higher than that between meteorological variables and $PM_{2.5}$, in which NO_2 is the strongest correlation with $PM_{2.5}$ and precipitation is the weakest correlation with $PM_{2.5}$; 2) The prediction results of the CNN-LSTM (variable) model are better than those of the LSTM, CNN, CNN-LSTM (equal) and CNN-LSTM (residual) models; 3) The values of RMSE, MAE and MAPE for CNN-LSTM (variable) model are 2.07%, 9.66% and 8.66%, respectively.

Keywords

LSTM, CNN, $PM_{2.5}$ Prediction, Variable Weight Combination

Copyright © 2022 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

$PM_{2.5}$ (fine particulate matter)是悬浮于大气中的一种细颗粒物, 根据空气动力学当量直径指标, $PM_{2.5}$ 是指当量直径小于等于 $2.5 \mu m$ 的细颗粒物[1], $PM_{2.5}$ 是雾霾的主要组成成分, 将对空气质量造成巨大影响。同时, $PM_{2.5}$ 也会对人类的出行造成一定的困扰, 甚至危害人类身心健康[2]。社会经济快速发展的同时, 随之而来的是环境污染问题, 其中雾霾污染问题不容小视。近年来, 由 $PM_{2.5}$ 造成的空气污染问题已经引起了国家和政府以及社会的重视[3]。一些研究表明, 一些疾病的发生以及死亡都与 $PM_{2.5}$ 污染有着显著相关关系[4]。因此, $PM_{2.5}$ 的预测和预警至关重要, 意义非凡。

Mishra 等[5]利用 Neuro-Fuzzy 模型预测印度德里市区的雾霾; Wang 等[6]利用新一代天气研究预测和化学模式 WRF-Chem 对长三角地区城市空气质量和区域雾霾污染进行预测; 杜续等[7]利用随机森林回归算法设计 $PM_{2.5}$ 浓度预测模型, 对西安市气象数据进行实证分析, 结果表明, 与 BP 神经网络模型相比, 该模型的预测精度更高; Liu 等[8]通过自回归移动平均模型(ARIMA)、人工神经网络(ANNs)模型和指数平滑法(ESM)预测 $PM_{2.5}$ 浓度; 李芬等[9]对天气类型进行聚类分析, 建立不同天气类型下的 $PM_{2.5}$ 浓度短期预测模型; 于伸庭等[10]构建 LSTM-CNN 组合模型, 预测未来 6 小时 $PM_{2.5}$ 浓度; 刘旭林等[11]提出了一种基于 CNN 和 Seq2Seq 的深度学习模型, 对北京市 $PM_{2.5}$ 浓度进行实证分析; 艾洪福等[12]建立了 BP 神经网络预测模型, 对长春市的 $PM_{2.5}$ 浓度进行预测; 张浩等[13]利用广义隐马尔可夫模型, 对北京市 11 个站点的 $PM_{2.5}$ 浓度数据进行实证分析; 谢崇波等[14]基于遗传算法, 采用门控循环单元, 建立神经网络混合模型, 预测绵阳市 $PM_{2.5}$ 浓度。先前很多研究多只考虑空气污染物对 $PM_{2.5}$ 浓度预测的影响, 常常忽略气象因子对 $PM_{2.5}$ 浓度的影响, 或未考虑预测因子与 $PM_{2.5}$ 之间的非线性关系。本研究利用北京

市 PM_{2.5} 浓度历史数据、空气污染物数据以及气象因子数据, 设计基于自变权的 CNN & LSTM 组合预测模型。

2. 研究区域和数据

2.1. 研究区域

北京市(39°26'~41°03'N, 115°25'~117°30'E)位于中国华北地区, 面积约 16,410 km², 常住人口达 2189.31 万, 属于暖温带半湿润半干旱季风气候。北京是中国首都, 同时也是我国经济、文化、产业发展的中心, 其空气质量一直备受关注。

2.2. 数据来源

研究数据包括污染物浓度数据(PM_{2.5}, PM₁₀, SO₂, NO₂, CO, O₃)和气象因子数据(温度、湿度、风速、气压、降水量), 其中污染物浓度数据来源于中国环境监测总站的全国城市空气质量实时发布平台(<https://quotsoft.net/air/>), 气象因子数据来源于国家气象信息中心中国气象数据网(<http://data.cma.cn/>)。

2.3. 数据统计与分析

本研究选取北京市的空气污染物浓度小时数据和气象数据, 时间范围为 2021 年 1 月 1 日~2021 年 7 月 31 日, 共 5088 组数据, 统计性描述如表 1 所示。由于获取的数据会存在个别缺失的情况, 本研究通过填补方式进行缺失值补充, 采用缺失值前 1 小时与后 1 小时的均值进行填补。

Table 1. Statistical description of data set variables

表 1. 数据集变量统计性描述

变量	平均值	最大值	最小值	标准差
PM _{2.5} (μg/m ³)	39.8	448	1	44.31
PM ₁₀ (μg/m ³)	82.37	6450	1.06	190.40
SO ₂ (μg/m ³)	3.17	126	1	2.89
NO ₂ (μg/m ³)	24.95	108	0.97	15.55
CO (μg/m ³)	0.66	105	0.14	2.08
O ₃ (μg/m ³)	65.98	268	0.96	41.35
温度(°C)	13.95	36.8	-19.5	11.60
湿度(%)	51.31	97	7	25.23
风速(m/s)	2.18	14.3	0	1.50
气压(hpa)	1010.05	1039	990	10.19
降水量(mm)	0.07	33.6	0	0.72

3. 研究方法

3.1. 相关性分析

相关性分析是分析两个或两个以上变量的线性相关程度[15]。Pearson 相关系数的计算公式为:

$$\rho_{X,Y} = \frac{\text{cov}(X,Y)}{\sigma_X \sigma_Y} = \frac{E((X - \mu_X)(Y - \mu_Y))}{\sigma_X \sigma_Y} \quad (1)$$

式中, ρ 为变量 X, Y 之间的相关系数, μ_X, μ_Y 分别为 X, Y 的均值, σ_X, σ_Y 分别为 X, Y 的方差。

3.2. CNN

20 世纪 60 年代, Hubel 和 Wiesel [16] 提出了卷积神经网络(convolutional neural networks, CNN), 起初 CNN 主要应用于图像特征的提取与分类[17], 随着学者们的不断研究, 发现 CNN 同样可以应用于时间序列数据分析[18]。

3.3. LSTM

LSTM (Long Short-Term Memory)是由 Hpchreiter 和 Schmidhuber [19]在 1997 年提出的, LSTM 神经网络模型结构如图 1 所示:

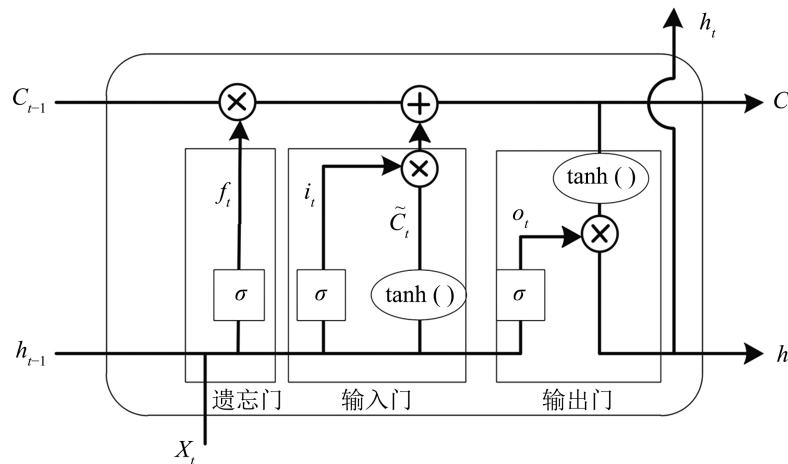


Figure 1. LSTM model structure
图 1. LSTM 模型结构

其计算公式如下:

$$f_t = \sigma(w_f \cdot [h_{t-1}, X_t] + b_f) \quad (2)$$

$$i_t = \sigma(w_i \cdot [h_{t-1}, X_t] + b_i) \quad (3)$$

$$C'_t = \tanh(w_c \cdot [h_{t-1}, X_t] + b_c) \quad (4)$$

$$C_t = f_t \times C_{t-1} + i_t \times C'_t \quad (5)$$

$$o_t = \sigma(w_o \cdot [h_{t-1}, X_t] + b_o) \quad (6)$$

$$h_t = o_t \times \tanh(C_t) \quad (7)$$

式中, f_t 为遗忘门的向量值, i_t 为输入门的向量值, C'_t 和 C_t 分别为上一时刻和当前时刻记忆单元的向量值, o_t 为输出门的向量值, h_t 表示 t 时刻单元输出, X_t 表示 t 时刻的输入。 w 和 b 在训练过程中会不断更新, 分别表示权重和偏置项, σ 和 \tanh 是激活函数。

3.4. 组合预测模型

3.4.1. 等值赋权及残差赋权组合模型

等值赋权组合模型即赋予每个单模型相同的权重, 而残差赋权组合模型各权重可由下式计算得出:

$$f(X_t) = \frac{1}{n} \sum_{i=1}^n \omega_i(t-1) f_i(X_t) \quad (8)$$

$$\omega_i(t) = \frac{1}{\bar{\varepsilon}_i(t-1)} \frac{1}{\sum_{i=1}^n \frac{1}{\bar{\varepsilon}_i(t-1)}} \quad (9)$$

$$\text{s.t. } \sum_{i=1}^n \omega_i(t-1) = 1, \omega_i(t-1) \geq 0 \quad (10)$$

其中, $\omega_i(t-1)$ 为 $t-1$ 时刻第 i 个模型的权重, $\bar{\varepsilon}_i(t-1)$ 为 $t-1$ 时刻第 i 个模型的预测误差绝对值。

3.4.2. 自变权组合模型

在残差赋权组合模型的基础上, 权重不再保持不变, 当前时刻的权重为前 m 个时刻的权重平均值, 并比较权重改变前后预测效果(本文 m 取 3):

$$\omega_j(t) = \frac{1}{m} \sum_{k=1}^m \omega_j(t-k) \quad (11)$$

对于 t 时刻, 残差赋权组合模型和自变权组合模型的预测值与真实值的误差绝对值分别为 $e_{i,t}$ 和 $e_{j,t}$, 即:

$$e_{i,t} = \left| \sum_{i=1}^n \omega_i(t) f_i(X_t) - f(t) \right| \quad (12)$$

$$e_{j,t} = \left| \sum_{j=1}^n \omega_j(t) f_j(X_t) - f(t) \right| \quad (13)$$

比较两者的大小, 若 $e_{i,t} > e_{j,t}$, 则说明该时刻自变权组合模型预测效果更优, 故使用新权重, 反之, 则仍保持原先权重。

3.5. 预测流程

预测流程如图 2 所示。

1) 数据预处理

对原始数据的缺失值进行填充处理以及标准化处理。

2) 单模型预测

将数据集按照 8:2 的比例划分为训练集和测试集, 将训练集分别输入 CNN 和 LSTM 模型中, 确定最优模型, 再对测试集进行预测。

3) 自变权组合模型预测

基于第 2) 步 CNN 和 LSTM 模型的预测结果, 采用 3.4 节所述赋权方法, 依次构建等值赋权组合模型 CNN-LSTM (equal), 残差赋权组合模型 CNN-LSTM (residual) 和自变权组合模型 CNN-LSTM (variable), 并进行预测。

4) 模型评价分析

计算各评价指标, 对个模型进行预测效果比较。

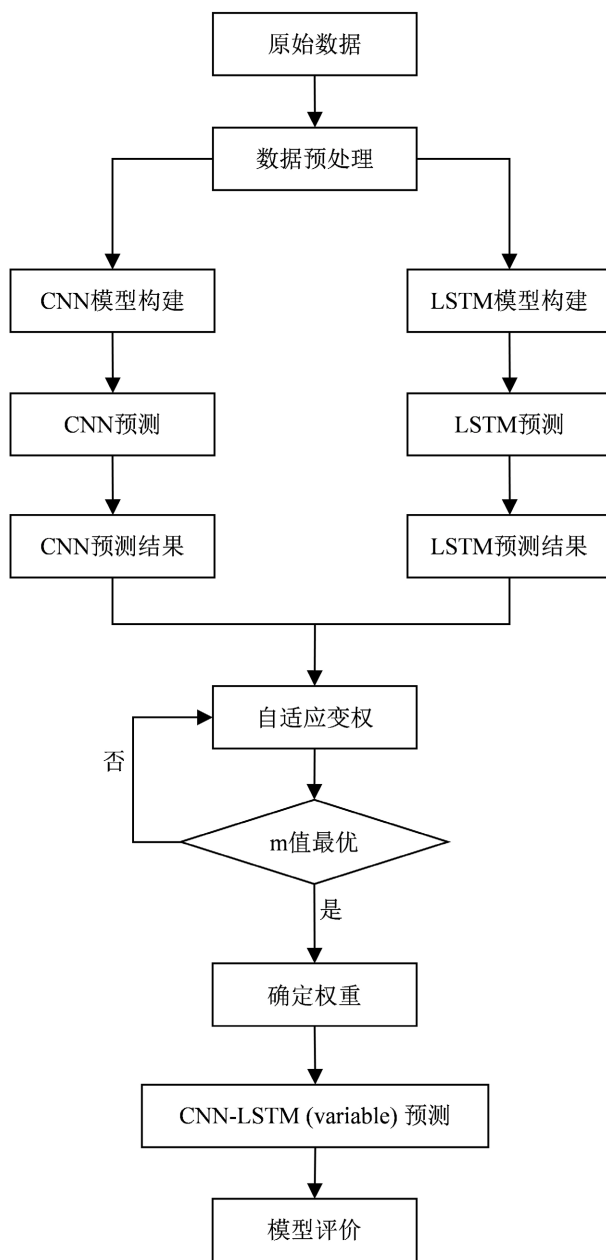


Figure 2. CNN-LSTM (Variable) model prediction flow
 图 2. CNN-LSTM (Variable)模型预测流程

3.6. 评价指标

为进行模型精度的比较, 本研究采用评价指标: 均方根误差(RMSE), 平均绝对误差(MAE)和平均绝对百分比误差(MAPE), 相应的计算公式为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \tag{14}$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \tag{15}$$

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (16)$$

式中, n 为样本量, y_t 为真实值, \hat{y}_t 为其预测值。误差越小, 则表示预测精度越高, 预测效果越好, 模型性能越好。

4. 结果与讨论

4.1. PM_{2.5} 现状分析

如图 3 及表 2 所示, 2021 年 1 月至 7 月, 3 月 PM_{2.5} 月均浓度最高, 为 83.54 μg/m³, 其中 3 月 15 日 9 时 PM_{2.5} 浓度最高, 为 448 μg/m³, 3 月 15 日平均浓度为 208 μg/m³。2021 年 3 月 PM_{2.5} 浓度突然升高, 主要是受北京当月沙尘暴影响。6 月~7 月, PM_{2.5} 小时浓度均低于 70 μg/m³, 6 月和 7 月 PM_{2.5} 小时浓度最高分别为 65 μg/m³ 和 43 μg/m³, 最低小时浓度均为 2 μg/m³, 而 7 月 PM_{2.5} 月均浓度是该年 1 月~7 月中最低的, 为 15.97 μg/m³。此外, 2 月 PM_{2.5} 日均最高浓度为 205 μg/m³, PM_{2.5} 小时最高浓度达 289 μg/m³, 仅次于 3 月。




Figure 3. Change in hourly PM_{2.5} concentrations January 2021~July 2021

图 3. 2021 年 1 月~2021 年 7 月 PM_{2.5} 小时浓度变化

Table 2. 2021.1.1~2021.7.31 PM_{2.5} daily and monthly average concentration

表 2. 2021.1.1~2021.7.31 PM_{2.5} 浓度日均浓度及月均浓度情况

时间	1 月	2 月	3 月	4 月	5 月	6 月	7 月
PM _{2.5} 小时最高浓度(μg/m ³)	146	289	448	159	249	65	43
PM _{2.5} 小时最低浓度(μg/m ³)	1.17	3	4	2	1	2	2
PM _{2.5} 日均最高浓度(μg/m ³)	49.25	205.00	207.92	73.50	82.63	44.42	31.13
PM _{2.5} 日均最低浓度(μg/m ³)	5.50	5.75	6.58	5.46	3.29	2.79	4.46
PM _{2.5} 月均浓度(μg/m ³)	39.45	62.47	83.54	33.96	25.96	18.58	15.97

4.2. 预测因子分析

4.2.1. PM_{2.5} 与空气污染物相关性分析

首先, 探索 PM_{2.5} 浓度与其它空气污染物因子(PM₁₀, SO₂, NO₂, CO, O₃)之间的关系, 散点图如图 4 所示。

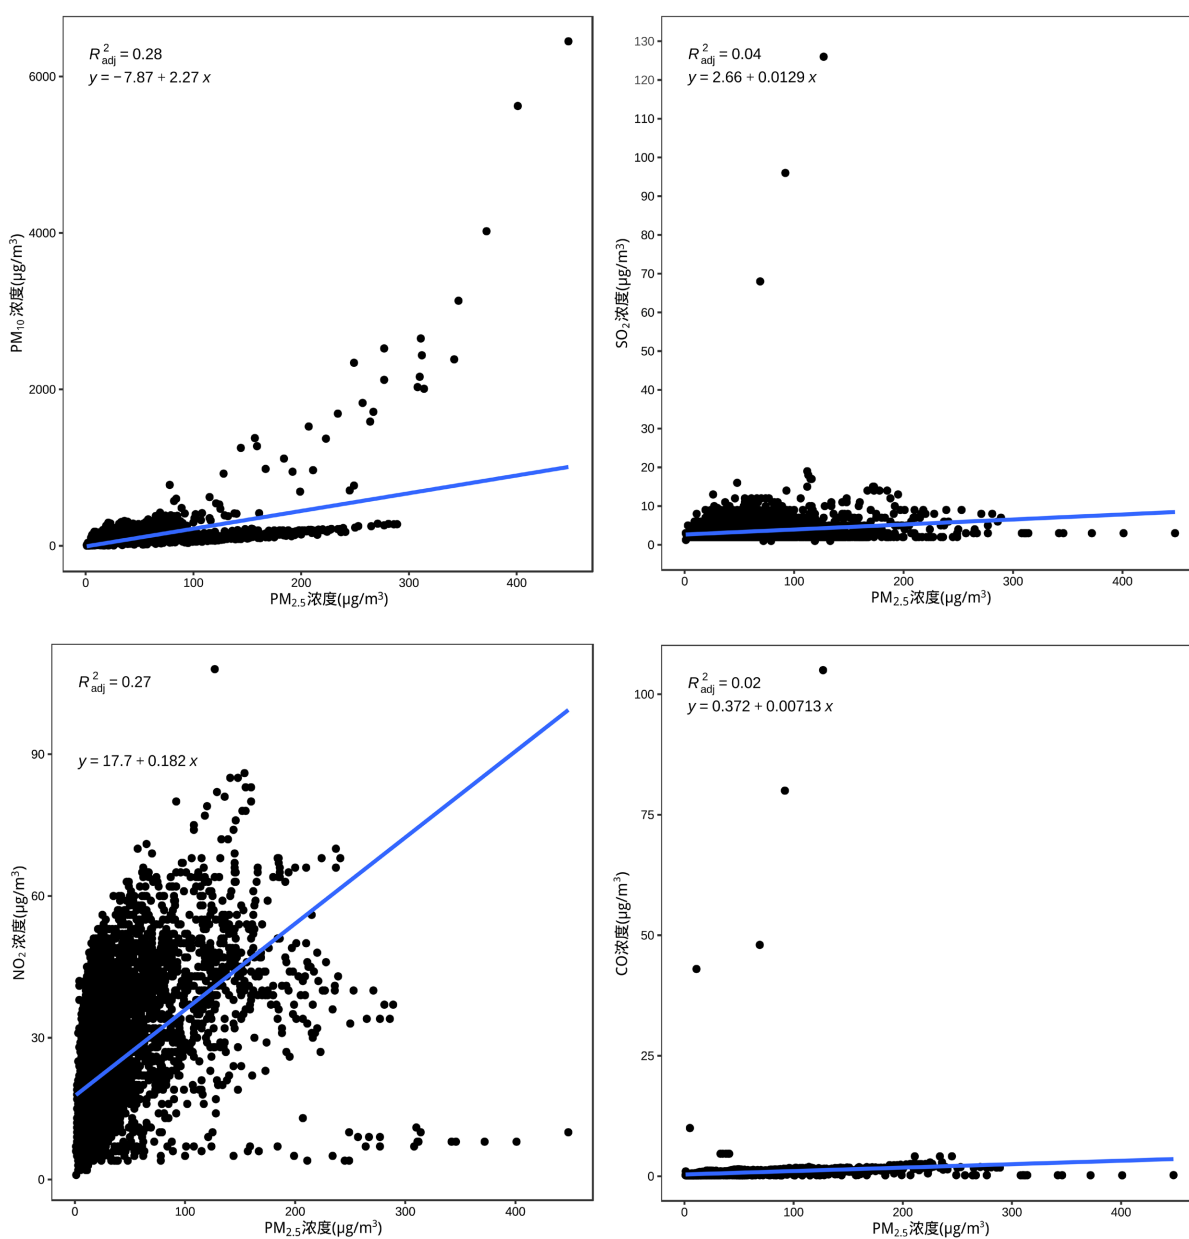
如图 4 所示, $PM_{2.5}$ 与其他空气污染物之间均存在一定的相关关系。其中 PM_{10} 、 NO_2 与 $PM_{2.5}$ 之间的相关关系较强, 而 SO_2 、 CO 与 $PM_{2.5}$ 之间的相关关系较弱。

综合表 3 分析, 确定预测因子为 SO_2 、 NO_2 、 CO 和 O_3 。其中, PM_{10} 与 $PM_{2.5}$ 有着极强相关性, 不将其放入预测因子中。

Table 3. Correlation coefficients between $PM_{2.5}$ concentrations and air quality factors

表 3. $PM_{2.5}$ 浓度与空气质量因素相关系数

空气污染物因子	PM_{10}	SO_2	NO_2	CO	O_3
相关系数	0.5276	0.1987	0.5193	0.1516	-0.2250






Figure 4. Correlation analysis of PM_{2.5} and air pollutants
图 4. PM_{2.5} 与空气污染物相关性分析

4.2.2. PM_{2.5} 与气象因子相关性分析

大量研究表明, 气象因子也对 PM_{2.5} 浓度有重要影响[20] [21] [22] [23]。利用研究区域 PM_{2.5} 浓度和气象因子数据, 计算它们之间的 Pearson 相关系数, 进行相关性分析。如表 4 所示, PM_{2.5} 浓度与本研究所选的气象因子之间均存在一定的相关性, 其中, PM_{2.5} 与温度、湿度、风速和降水量均呈负相关关系, 仅与气压呈正相关关系。

Table 4. Correlation coefficients between PM_{2.5} concentrations and meteorological factors
表 4. PM_{2.5} 浓度与气象因子相关系数

气象因子	温度	湿度	风速	气压	降水量
相关系数	-0.2484	-0.2143	-0.1098	0.1926	-0.0473

4.3. 预测分析与对比

本研究构建基于自适应权的 CNN & LSTM 组合模型, 以北京为研究区域, 对未来 1 小时 PM_{2.5} 浓度进行短期预测。图 5 给出了 LSTM、CNN、等值赋权组合模型 CNN-LSTM (equal)、残差赋权组合模型 CNN-LSTM (residual)、自适应权组合模型 CNN-LSTM (variable)各自的预测结果。由图 5 可知, 组合模型的预测效果优于单机器学习模型的预测效果, 其中, 基于自适应权的 CNN&LSTM 组合模型预测效果最好, 预测精度最高, 预测值与真实值偏差最小。

如表 5 所示, LSTM 模型的评价指标数值分别为 RSME 为 9.39, MAE 为 10.58, MAPE 为 22.33%; CNN 模型的评价指标数值分别为 RSME 为 5.11, MAE 为 10.20, MAPE 为 32.49%; 而等值赋权组合模型 CNN-LSTM (equal)的评价指标数值分别为 RSME 为 3.08, MAE 为 9.83, MAPE 为 19.06%; 残差赋权组合模型 CNN-LSTM (residual)的评价指标数值分别为 RSME 为 2.10, MAE 为 9.71, MAPE 为 8.81%; 自适应权组合模型 CNN-LSTM (variable)的评价指标数值分别为 RSME 为 2.07, MAE 为 9.66, MAPE

为 8.66%。改进的自适应变权组合模型相较于传统等值赋权模型 CNN-LSTM (equal) RSME 提升了 32.8%，MAE 提升了 1.2%，MAPE 提升了 54.5%。

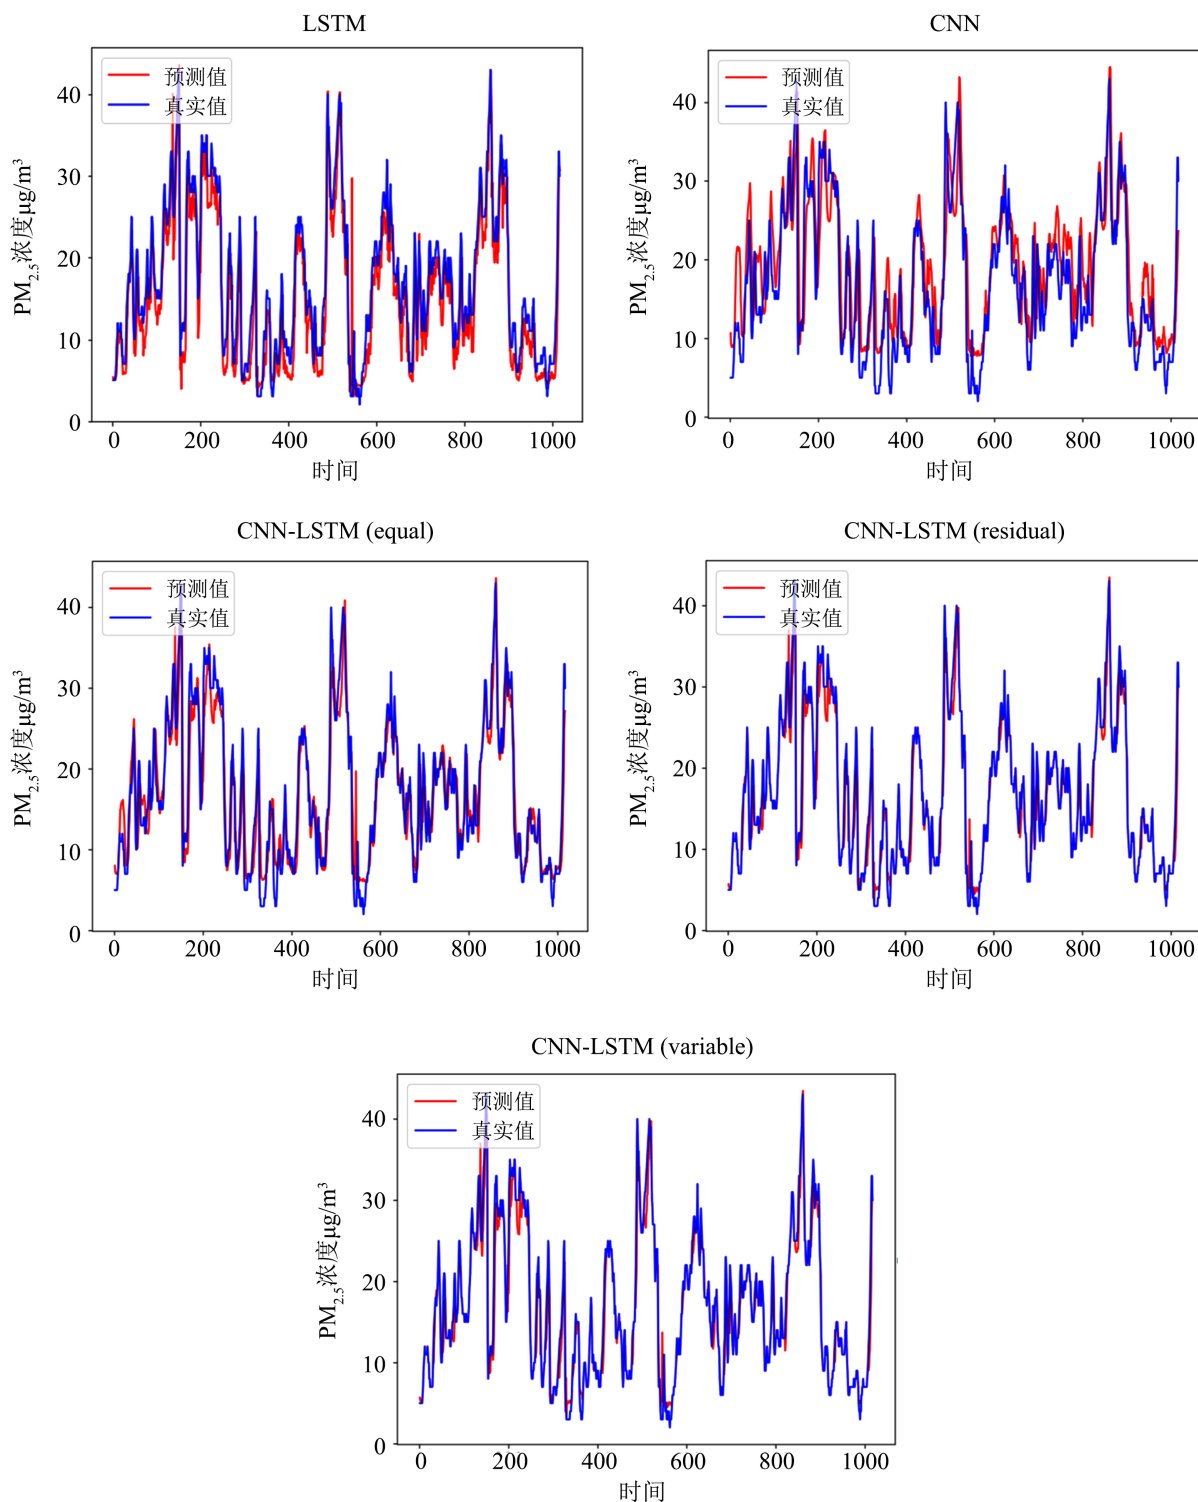


Figure 5. Predicted and true values for each model

图 5. 各模型预测值和真实值

Table 5. Comparison of the prediction accuracy of different evaluation indicators
表 5. 不同评价指标的预测精度比较

模型	RMSE	MAE	MAPE (%)
LSTM	9.39	10.58	22.33
CNN	5.11	10.20	32.49
CNN-LSTM (equal)	3.08	9.83	19.06
CNN-LSTM (residual)	2.10	9.71	8.81
CNN-LSTM (variable)	2.07	9.66	8.66

5. 结论

本研究基于 CNN 模型和 LSTM 网络进行一定改进得到自变权组合的 $PM_{2.5}$ 浓度预测方法, 该组合模型考虑了时间序列的相互关系, 同时考虑了 $PM_{2.5}$ 浓度与预测因子之间的非线性关系。研究发现:

1) 2021 年 1 月至 7 月, 3 月 $PM_{2.5}$ 月均浓度最高, 7 月 $PM_{2.5}$ 月均浓度最低。其中 3 月 15 日 9 时 $PM_{2.5}$ 浓度最高, 为 $448 \mu g/m^3$, 3 月 15 日平均浓度为 $208 \mu g/m^3$ 。

2) 由相关性分析可知, $PM_{2.5}$ 浓度与空气污染物(PM_{10} , SO_2 , NO_2 , CO , O_3)之间的相关性总体高于 $PM_{2.5}$ 浓度与气象因子变量(温度、湿度、风速、气压、降水量)之间的相关性, 其中 NO_2 与 $PM_{2.5}$ 之间是相关系数为 0.5193, 相关性最强, 降水量与 $PM_{2.5}$ 相关性最弱, 相关系数为 -0.0473。

3) 本研究构建的基于自变权的 CNN & LSTM 组合 $PM_{2.5}$ 预测模型考虑了数据的时间序列以及非线性特征。与单一的机器学习模型以及传统组合模型相比, 该模型与真实值的拟合效果更好, 偏差较小。

基金项目

国家社会科学基金重大项目“大数据时代雾霾污染经济损失评估及防治对策研究”(17ZDA092)。

参考文献

- [1] Kaufman, Y.J., Tanré, D. and Boucher, O. (2002) A Satellite View of Aerosols in the Climate System. *Nature*, **419**, 215-223. <https://doi.org/10.1038/nature01091>
- [2] 王理伶. 我国主要城市 $PM_{2.5}$ 的社会经济影响因素实证研究[D]: [硕士学位论文]. 福州: 福建师范大学, 2018.
- [3] 赵文芳, 林润生, 唐伟, 周勇. 基于深度学习的 $PM_{2.5}$ 短期预测模型[J]. 南京师大学报(自然科学版), 2019, 42(3): 32-41.
- [4] Lim, S.S., Vos, T., Flaxman, A.D., Danaei, G., Danaei, G., Shibuya, K., Adair-Rohani, H., et al. (2012) A Comparative Risk Assessment of Burden of Disease and Injury Attributable to 67 Risk Factors and Risk Factor Clusters in 21 Regions, 1990-2010: A Systematic Analysis for the Global Burden of Disease Study 2010. *The Lancet*, **380**, 2224-2260. [https://doi.org/10.1016/S0140-6736\(12\)61766-8](https://doi.org/10.1016/S0140-6736(12)61766-8)
- [5] Mishra, D., Goyal, P. and Upadhyay, A. (2015) Artificial Intelligence Based Approach to Forecast $PM_{2.5}$ during Haze Episodes: A Case Study of Delhi, India. *Atmospheric Environment*, **102**, 239-248. <https://doi.org/10.1016/j.atmosenv.2014.11.050>
- [6] Wang, T., Jiang, F., Deng, J., Shen, Y., Fu, Q., Wang, Q., et al. (2012) Urban Air Quality and Regional Haze Weather Forecast for Yangtze River Delta Region. *Atmospheric Environment*, **58**, 70-83. <https://doi.org/10.1016/j.atmosenv.2012.01.014>
- [7] 杜续, 冯景瑜, 吕少卿, 石薇. 基于随机森林回归分析的 $PM_{2.5}$ 浓度预测模型[J]. 电信科学, 2017, 33(7): 66-75.
- [8] Liu, D. and Li, L. (2015) Application Study of Comprehensive Forecasting Model Based on Entropy Weighting Method on Trend of $PM_{2.5}$ Concentration in Guangzhou, China. *International Journal of Environmental Research and Public Health*, **12**, 7085-7099. <https://doi.org/10.3390/ijerph120607085>

- [9] 李芬, 杨程, 赵晋斌, 王转转. 基于天气类型聚类 and LSTM 的 $PM_{2.5}$ 短期预测模型[J]. 水电能源科学, 2021, 39(3): 199-202+151.
- [10] 于伸庭, 刘萍. 基于长短期记忆网络-卷积神经网络(LSTM-CNN)的北京市 $PM_{2.5}$ 浓度预测[J]. 环境工程, 2020, 38(6): 176-180+66.
- [11] 刘旭林, 赵文芳, 唐伟. 应用 CNN-Seq2seq 的 $PM_{2.5}$ 未来一小时浓度预测模型[J]. 小型微型计算机系统, 2020, 41(5): 1000-1006.
- [12] 艾洪福, 石莹. 基于 BP 人工神经网络的雾霾天气预测研究[J]. 计算机仿真, 2015, 32(1): 402-405+415.
- [13] 张浩, 于君毅, 刘晓慧, 雷洪. 基于广义隐马尔可夫模型的 $PM_{2.5}$ 浓度预测[J]. 化工学报, 2018, 69(3): 1215-1220.
- [14] 谢崇波, 李强. 基于 GA-GRU 环境空气污染物预测研究[J]. 测控技术, 2019, 38(7): 97-103.
- [15] 毛秀珍, 章璐杰, 毛天翔, 王友钊, 黄静. 基于 Pearson 相关分析和回归分析方法的基金影响力研究[J]. 浙江理工大学学报(社会科学版), 2017, 38(4): 306-311.
- [16] Hubel, D.H. and Wiesel, T.N. (1959) Receptive Fields of Single Neurones in the Cat's Striate Cortex. *The Journal of Physiology*, **148**, 574-591. <https://doi.org/10.1113/jphysiol.1959.sp006308>
- [17] 张佳琦, 张金艺, 楼亮亮. 基于分组特征赋权的动态视角图像特征融合[J]. 电子测量技术, 2021, 44(4): 144-148.
- [18] Skarbøvik, E., Stalnacke, P., Bogen, J. and Bønsnes, T.E. (2012) Impact of Sampling Frequency on Mean Concentrations and Estimated Loads of Suspended Sediment in a Norwegian River: Implications for Water Management. *Science of the Total Environment*, **433**, 462-471. <https://doi.org/10.1016/j.scitotenv.2012.06.072>
- [19] Hochreiter, S. and Schmidhuber, J. (1997) Long Short-Term Memory. *Neural Computation*, **9**, 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [20] 张小曳, 孙俊英, 王亚强, 李卫军, 张蕾, 王伟罡, 等. 我国雾-霾成因及其治理的思考[J]. 科学通报, 2013, 58(13): 1178-1187. <https://doi.org/10.1360/972013-150>
- [21] 周丽, 徐祥德, 丁国安, 苗秋菊, 魏凤英. 北京地区气溶胶 $PM_{2.5}$ 粒子浓度的相关因子及其估算模型[J]. 气象学报, 2003, 61(6): 761-768.
- [22] 杜锐, 张在一, 毛学峰. 城市雾霾消散的气象异质性研究[J]. 安全与环境学报, 2019, 19(4): 1383-1392.
- [23] 陈瑞敏, 吴雁, 康文英, 王荣英. 连续雾霾天气污染物浓度变化及天气形势特征分析[J]. 气候与环境研究, 2014, 19(2): 209-218.