

# 基于机器学习的北京市 PM2.5 浓度预测模型及模拟分析

曲悦<sup>1 2)</sup>, 钱旭<sup>1)</sup>, 宋洪庆<sup>2 3)</sup>✉, 何杰<sup>4)</sup>, 李剑辉<sup>2 3)</sup>, 修昊<sup>4)</sup>

1) 中国矿业大学(北京)机电与信息工程学院, 北京 100083 2) 大数据分析 & 计算技术国家地方联合工程实验室, 北京 100190

3) 北京科技大学土木与资源工程学院, 北京 100083 4) 北京科技大学计算机与通信工程学院, 北京 100083

✉通信作者, E-mail: songhongqing@ustb.edu.cn

**摘要** 对北京市周边 8 个点多个压力高度的温度、湿度和风速数据, 以及北京市 PM2.5 污染数据进行了分析和归一化处理, 建立了反向传播神经网络(back propagation, BP)、卷积神经网络(convolutional neural network, CNN)和长短期记忆模型(long short-term memory, LSTM)对上述气象数据和污染数据进行训练, 训练结果表明: 反向传播神经网络模型和卷积神经网络模型对未来 1 h 的 PM2.5 污染等级的预测准确率较低, 而长短期记忆模型的准确率较高。使用长短期记忆模型预测未来 1 h 的 PM2.5 污染值与实际值十分接近, 表明北京市的 PM2.5 污染与其周边地区的气象条件关系密切。通过利用长短期记忆模型对不同压力高度的气象数据进行训练和对比, 得出在利用气象数据预测污染时, 仅使用近地面气象数据比使用多个高度上的气象数据更加准确。

**关键词** 机器学习; PM2.5; 气象条件; 神经网络; 长短期记忆; 污染预测

**分类号** X831; TP391

## Machine-learning-based model and simulation analysis of PM2.5 concentration prediction in Beijing

QU Yue<sup>1 2)</sup>, QIAN Xu<sup>1)</sup>, SONG Hong-qing<sup>2 3)</sup>✉, HE Jie<sup>4)</sup>, LI Jian-hui<sup>2 3)</sup>, XIU Hao<sup>4)</sup>

1) School of Mechanical Electronic and Information Engineering, China University of Mining and Technology (Beijing), Beijing 100083, China

2) National and Local Joint Engineering Lab for Big Data Analysis and Computing Technology, Beijing 100190, China

3) School of Civil and Resource Engineering, University of Science and Technology Beijing, Beijing 100083, China

4) School of Computer and Communication Engineering, University of Science and Technology Beijing, Beijing 100083, China

✉Corresponding author, E-mail: songhongqing@ustb.edu.cn

**ABSTRACT** In recent years, the air quality in China has become a matter of serious concern. Among the available indicators for evaluating air quality, PM2.5 is one of the most important. It comprises a complex mixture of extremely small particles and liquid droplets emitted into the air, whose diameters are no more than 2.5  $\mu\text{m}$ . Environments with a high PM2.5 index are extremely harmful to human health. Once inhaled, these particles can affect the heart and lungs and cause serious health problems. Air pollution is closely related to meteorological conditions such as wind speed, wind direction, atmospheric stability, temperature, and air humidity. With the development of various machine learning methods, deep learning models based on neural networks are increasingly applied in air pollution research. In this study, the temperature, humidity, wind velocity data at different pressure altitudes from 8 locations around Beijing and average of PM2.5 data in Beijing were analyzed and normalized. Multi-dimensional data was ideal for research applications using machine learning methods. and three neural network models were built, including the back propagation (BP), convolutional neural network (CNN), and long short-term memory (LSTM) models, and trained them using the meteorological and PM2.5 data.

收稿日期: 2018-02-21

基金项目: 中央高校基本科研业务费专项资金资助项目(FRF-TP-17-001C1); 北京市科技新星计划资助项目(Z171100001117081)

The results indicate that the accuracies of the back propagation and convolutional neural network models in predicting the PM<sub>2.5</sub> pollution level in the next hour is much lower than that of the long short-term memory model. The PM<sub>2.5</sub> pollution index predicted for the next hour by the long short-term memory model is very close to the actual value. This result reveals the strong relationship between the PM<sub>2.5</sub> pollution index of Beijing and the local meteorological conditions. The long short-term memory model is trained using meteorological data from different pressure altitudes, and found it to be more accurate in predicting pollution levels when using near-surface meteorological data than that obtained from multiple altitudes.

**KEY WORDS** machine learning; PM<sub>2.5</sub>; meteorological condition; neural networks; long short-term memory; pollution prediction

近年来 空气质量成为人们越来越关心的问题之一。而评价空气质量的指标中,PM<sub>2.5</sub>是最重要的指标之一,高 PM<sub>2.5</sub> 指数的环境对人类健康的危害极为严重。众多研究结果表明,PM<sub>2.5</sub> 的产生和气象条件存在紧密的联系<sup>[1-10]</sup>。随着各种机器学习方法的成熟,基于神经网络的深度学习模型开始用于空气污染的研究<sup>[11-13]</sup>。基于径向基神经网络(radial basis function,RBF)、反向传播神经网络(back propagation,BP)、基于深度信念网络(deep belief networks,DBNs)、支持向量机(SVM)和粒子群优化(PSO)等深度学习方法已被众多学者用于研究空气质量与气象数据之间的非线性关系<sup>[14-16]</sup>。本文通过对北京周边不同地点各个高度的气象数据进行处理,利用反向传播神经网络、卷积神经网络、长短期记忆模型的深度学习模型对气象数据和北京 PM<sub>2.5</sub> 污染数据进行学习,预测 1 h 的 PM<sub>2.5</sub> 数值,力求找到适合于此类数据的深度学习最优模型。

### 1 数据选取与处理

本研究中采用了气象数据和 PM<sub>2.5</sub> 污染物数据用于分析研究。气象数据来自中国科学院国家空间科学中心的卫星数据。数据包含了北京市周围 8 个点的气象数据,这 8 个点位置如图 1 中 P1-P8 所示。

气象数据中最多有 17 个压力高度,从 10<sup>5</sup> 到 10<sup>3</sup> Pa 不等距分布。每个压力高度包含温度、相对湿度和风速数据。温度数据使用绝对温度表示,单位为 K。相对湿度使用百分数表示,取值区间为 0~100。风速使用正交的  $u$ 、 $v$  两个方向的分量表示,因此由于风向的不同数据有正负之分,单位为 m·s<sup>-1</sup>。在时间尺度上共有 2013~2016 年这四年中每天的 0:00、6:00、12:00 和 18:00 四个时刻的气象数据。

PM<sub>2.5</sub> 污染数据为 2013~2016 年间美国驻中国大使馆所测得的每小时 PM<sub>2.5</sub> 的平均值。这 4 年 PM<sub>2.5</sub> 曲线如图 2 所示。从图中可以看出,每张图中的数据都出现两头高中间矮的现象,这说明冬季的污染指数明显高于夏季。2013 年中度污染

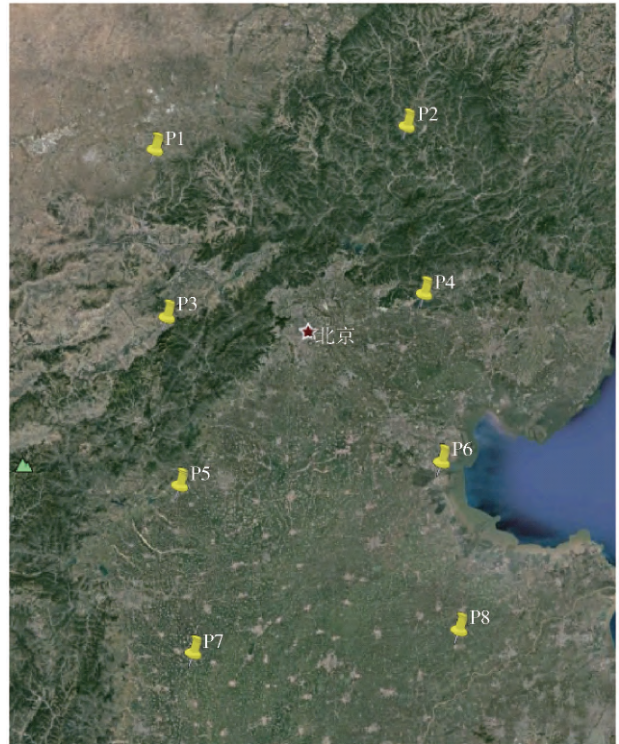


图 1 北京周围采集的气象数据点位置  
Fig. 1 Meteorological data points around Beijing

(PM<sub>2.5</sub> 值大于 150 μg·m<sup>-3</sup>) 及以上的天数达到 72 d 2014 年中度污染及以上的天数达到 66 d 2015 年中度污染及以上的天数达到 53 d 2016 年中度污染及以上的天数达到 39 d 2013 年整体污染要比其他几年更为严重。

由于对数据的归一化处理可以提升训练模型的收敛速度和精度,因此在训练之前,先对第  $k$  个数据进行归一化处理。对于温度数据,用到的归一化公式为:

$$T_k = (T_k - T_{\min}) / (T_{\max} - T_{\min}) \quad (1)$$

式中:  $T_{\min}$  为数据序列中的最小值,  $T_{\max}$  为数据序列中的最大值。

对于湿度数据,直接将其除以 100 即可。对于风速数据,用到的归一化公式为:

$$u_k = \left( \frac{u_k}{w_{\max}} + 1 \right) / 2 \quad (2)$$

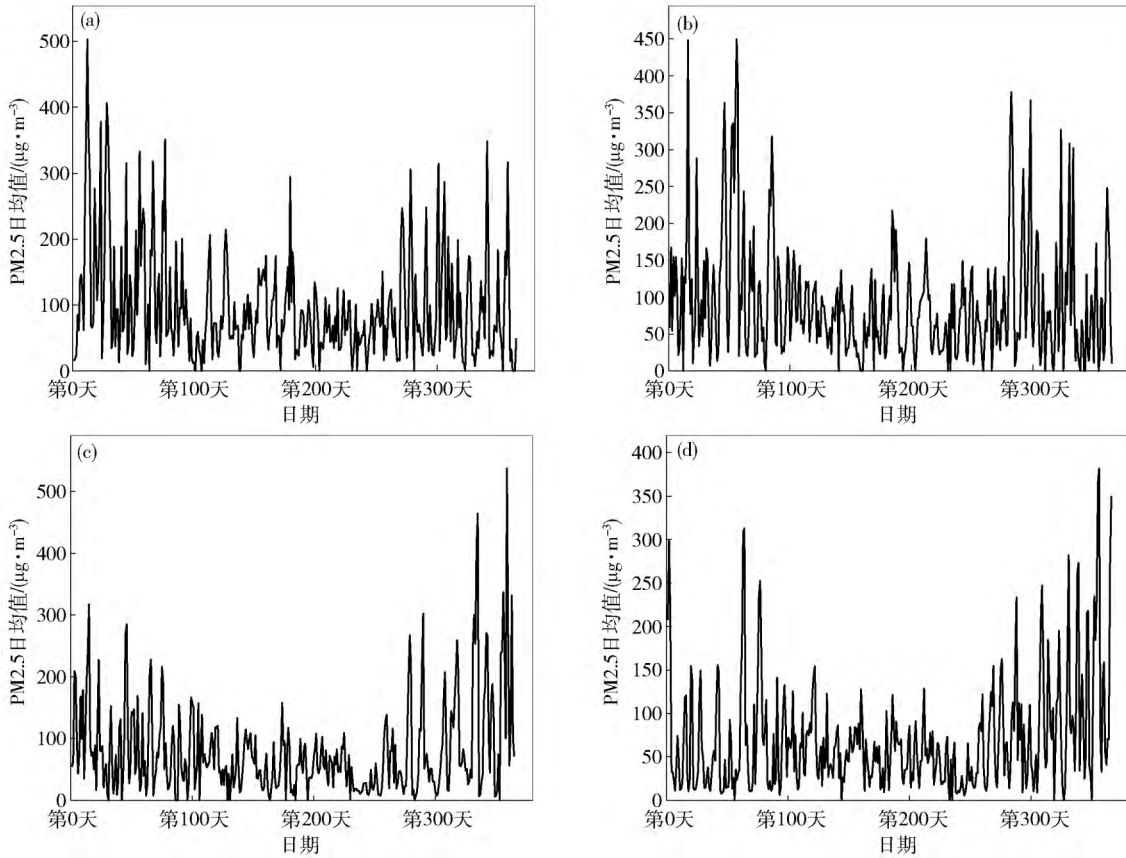


图2 2013~2016年PM2.5日均值。(a) 2013年; (b) 2014年; (c) 2015年; (d) 2016年

Fig.2 Daily average PM2.5 values from 2013 to 2016: (a) 2013; (b) 2014; (c) 2015; (d) 2016

$$v_k = \left( \frac{v_k}{w_{\max}} + 1 \right) / 2 \quad (3)$$

式中:  $w_{\max}$  为风速数据中最大绝对值.

## 2 预测模型

### 2.1 反向传播神经网络(BP)

神经网络是一种由大量节点以及节点之间相互连结构成的运算模型. 每个节点都代表一种函数运算. 节点之间的连结代表一个信号传输的权重. 神经网络的输出则根据节点之间的连接方式、权重以及节点上运算函数的不同而不同. 神经网络可以看作是对某种算法、函数的逼近, 或者是一种逻辑决策过程的表达.

反向传播神经网络是1986年由Rumelhart和McClelland<sup>[17]</sup>为首的科学家提出的概念, 是一种按照误差逆向传播算法训练的多层前馈神经网络. 反向传播神经网络的学习过程包括了信号的正向传播与误差的反向传播两个过程, 反向传播神经网络的网络结构如图3所示. 第一个过程中, 输入信号从输入层传入, 经各个隐含层处理后传向输出层. 如果输出层的输出与期望的输出相差较大则进入误差的反向传播阶段. 第二个过程中, 将输出进行转换,

然后通过隐含层向输入层逐层反馈, 并将误差分摊给各个层的所有单元, 此误差就是修正各单元权值的依据. 图中的  $x, y, z$  分别为每层单元的值; 各层之间  $w$  为信号传输的权重;  $i, h, j$  分别表示输入层、隐含层、输出层;  $\Delta$  为反向传播的误差;  $T$  为目标值;  $N$  表示对应层的单元数.




图3 三层BP神经网络示意图

Fig.3 Diagram of three-layer BP neural network

### 2.2 卷积神经网络(CNN)

20世纪60年代, Hubel和Wiesel<sup>[18]</sup>提出了卷积神经网络(convolutional neural networks, CNN). 他们在研究猫的大脑皮层中神经元的连接时, 发现了猫脑神经元细胞具有独特的网络结构, 从而为

CNN 的提出带来了启发性. 由于 CNN 能够自动的对图像提取特征, 避免了对图像复杂的预处理, 只需要输入原始图像, 因此在学术界得到了广泛应用.

一般地, CNN 由两部分组成, 第一部分为特征提取层, 包含卷积层和下采样层, 每一层的每个神经元与前一层的局部接受域相连, 用来提取这一局部的特征, 每一个局部特征的位置是固定的; 第二部分是 softmax 层, 用来对提取的抽象特征映射到相应的类别. CNN 的网络结构如图 4 所示. 图 4 是一个典型的实现识别图片字母功能的卷积神经网络, 输入层和输出层中间共有 6 层神经元, 32 × 32 的输入数据通过卷积操作得到第 1 中间层 6 个维度 28 × 28 大小的数据, 在图中表示为 C1: 6@28 × 28; 然后数据经取样操作得到第 2 中间层 6 个维度 14 × 14 大小的数据; 第 5 中间层数据经过全连接操作得到第

6 中间层一维向量大小为 84 的数据; 最后经高斯连接操作得到输出层的 10 个数据. 其中字母 C、S、F 分别表示卷积、取样、全连接.

卷积层的每一个神经元与前一层的局部接受域相连, 通过非线性变换计算激活, 公式为:

$$a_{ij} = f\left(\sum_{m=1}^H \sum_{n=1}^K w_{m,n} \cdot a_{i+m,j+n} + b\right) \quad (4)$$

式中:  $a_{ij}$  是相应的激活,  $f$  是非线性函数,  $w_{m,n}$  是  $H \times K$  的卷积核权重矩阵元素,  $b$  是偏置值,  $a_{i+m,j+n}$  表示连接到神经元  $(i, j)$  的上层神经元的激活.

二维的图像通常使用二维的卷积核进行卷积操作<sup>[19]</sup>, 一维的时间序列通常使用一维的卷积核进行卷积操作<sup>[20]</sup>. 带有多个卷积层的卷积神经网络, 能够学习对数据的分层表示, 更深层的卷积层用更抽象的方式表示数据.




图 4 卷积神经网络结构图  
Fig. 4 Convolution neural network structure

### 2.3 长短期记忆模型(LSTM)

1997 年, Hochreiter 和 Schmidhuber<sup>[21]</sup> 对循环神经网络(recurrent neural network, RNN) 进行了修改, 修改的模型中含有长短期记忆单元(long short-term memory, LSTM), 能够解决循环神经网络中出现的梯度消失问题. 长短期记忆模型能够将误差保留, 然后按时间和层进行反馈, 使误差保持为稳定值, 从而对多个时间步进行学习. 长短期记忆模型使用了循环神经网络之外的控制单元, 这些单元能够对信息进行存取, 通过门的开关对存取的信息进行选择, 以及决定存取信息的时机. 这些门包含了 sigmoid 函数与元素的相乘操作. 控制门根据接收信号进行开关, 并且利用自身权重对信息进行筛选, 同时自身权重会通过循环神经网络的学习过程进行调整. 图 5 展示了数据在记忆单元中的流动过程. 与前述模型相似, 图中  $W$  表示权重;  $\varepsilon$  表示传入的误差值;  $y$  表示输出值;  $g$  和  $h$  分别表示输入和输出压缩;  $s$  表示记忆单元的值, 其会根据记忆和丢弃计算而更新. 图中的上标表示数据的来源,  $c$  表示来源于原有的计算流,  $in$  表示来源于输入门,  $\varphi$  表示来源于丢弃门,  $out$  表示来源于输出门. 每个记忆单元的输入、

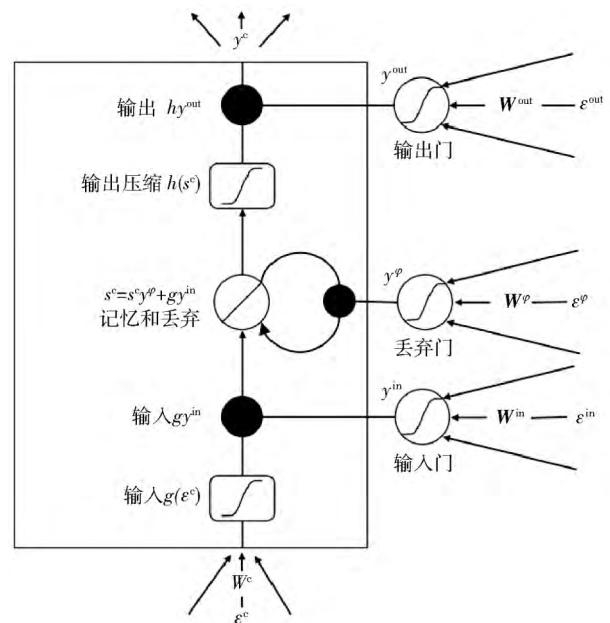


图 5 LSTM 模型中数据在记忆单元中的流动  
Fig. 5 Flow of data in memory unit in LSTM model

输出以及中间层都会通过各个对应的门将记忆中的值进行传入, 实现单元中的记忆功能. 长短期记忆模型 LSTM 非常适合于处理和预测时间序列中间隔



和延迟较长的重要事件.

### 3 预测结果分析

本文使用 Python 语言编程,分别用反向传播、卷积神经网络、长短期记忆模型三种模型对以上气象和污染数据进行学习,预测未来 1 h 后的污染情况.

#### 3.1 对污染等级的预测

根据国家环境保护标准环境空气质量指数技术规范,只使用 PM2.5 数据将空气质量指数分为 6 个等级(表 1).

表 1 空气质量指数级别与 PM2.5 对应值  
Table 1 Air quality index level and PM2.5 values

空气质量指数等级	空气质量指数类别	PM2.5/(mg·m <sup>-3</sup> )
一级	优	0 ~ 50
二级	良	51 ~ 100
三级	轻度污染	101 ~ 150
四级	中度污染	151 ~ 200
五级	重度污染	201 ~ 300
六级	严重污染	> 300

使用以上 3 个模型,将前 1500 d 的数据作为训练集,其余作为测试集进行训练. 由于气象数据中每天只有 4 个时刻的数值,而 PM2.5 污染数据中每天有 24 个时刻的数值,因此将缺少的气象数据值使用其前最近时刻的已有值补全. 利用第  $n$  时刻的气象数据和 PM2.5 污染数据进行学习,对第  $n + 1$  时刻的空气质量指数等级进行预测,每个时刻间隔为 1 h. 经过训练,BP 模型和 CNN 模型都得到了 48% 的准确率,LSTM 模型得到了 81% 的准确率.

#### 3.2 对污染值的预测

同样使用以上 3 个模型,将前 1500 d 的数据作为训练集,其余作为测试集进行训练. 使用缺失数据前最近时刻的值将数据补全. 利用第  $n$  时刻的气象数据和 PM2.5 污染数据进行学习,对第  $n + 1$  时刻的 PM2.5 数值进行预测. 利用平均相对误差作为损失函数对预测的优劣进行评估. 经过训练,3 种方法训练和预测的损失值分别如图 6 所示. 从图中可以看出,反向传播神经网络模型和卷积神经网络模型的训练和测试损失值在 0.07 和 0.05 左右,长短期记忆模型的训练和损失值最小,为 0.0165 和 0.0092. 这说明长短期记忆模型的预测值得到的平均相对误差最小,此方法用于预测 PM2.5 数据值最可靠.

因此,使用长短期记忆模型,对 2016 年 12 月的

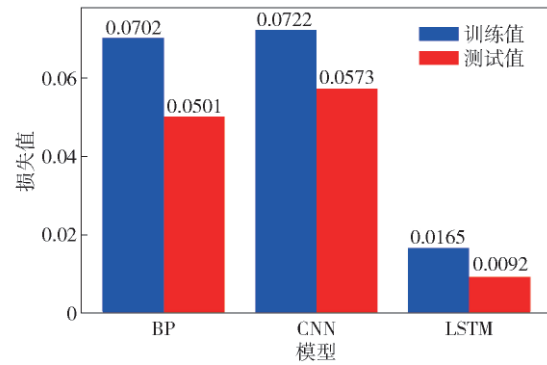


图 6 3 种方法的训练与测试损失值  
Fig. 6 Training and testing losses of three methods

PM2.5 数值进行预测,图 7 展示了预测值与实际值的对比. 从图中可以很直观的看出,长短期记忆模型的预测曲线与实际值曲线很接近.




图 7 长短期记忆模型对 2016 年 12 月 PM2.5 数值的预测曲线  
Fig. 7 PM2.5 prediction curve using LSTM model in December 2016

#### 3.3 不同压力高度数据预测

为了比较不同高度上气象数据对预测结果的影响,只使用与地面接近的  $10^5$  Pa 压力高度的气象数据对长短期记忆模型进行训练. 同样使用平均相对误差作为损失函数对预测的优劣进行评估. 图 8 展示了此次训练模型对 2016 年 12 月 PM2.5 的预测值与实际值的比较,并且得到此次训练的训练损失值为 0.0089,测试损失值为 0.0064. 本次训练的训练损失值与测试损失值都比图 6 中长短期记忆模型得到的损失值小,这说明只考虑地面附近的气象数据比考虑各个压力高度的气象数据能得到更好的污染预测效果,也说明了地面附近的气象条件与 PM2.5 的污染关系更为紧密. 然而众多学者提出逆温层是影响空气质量的主要气象因子之一<sup>[22-25]</sup>. 逆温层高度一般位于 600 m 以下,并且会随时间不断变化<sup>[26]</sup>. 本文使用的数据中,与地面接近的第二个压力高度为  $9 \times 10^4$  Pa,其实际高度约为 1000 m,达不到体现逆温层的数据精度要求,故还需要更高精度的数据对近地面不同高度的气象数据与 PM2.5

污染关系进行研究. 然而本文的预测模型对于逆温层数据的处理也是很适用的, 经过与前述相同的归一化处理后可以直接将数据输入得出预测结果.

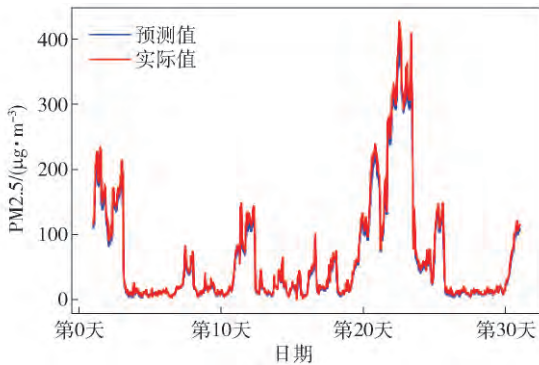


图 8 基于一个压力高度数据的 LSTM 模型对 2016 年 12 月 PM2.5 数值的预测曲线

Fig.8 PM2.5 prediction curve using LSTM model based on data from one pressure altitude in December 2016

## 4 结论

(1) 基于北京市及周边地区气象数据和 PM2.5 浓度数据, 建立了反向传播、卷积神经网络、长短期记忆模型三种机器学习模型, 对气象数据和污染数据进行训练, 其中长短期记忆模型能够实现对未来 1 h PM2.5 浓度预测.

(2) 计算结果表明反向传播神经网络模型和卷积神经网络模型对未来 1 h 的 PM2.5 污染等级的预测准确率较低, 而长短期记忆模型的准确率较高约 81%; 同时长短期记忆模型预测未来 1 h PM2.5 的污染值与实际值十分接近.

(3) 北京市的 PM2.5 污染与其周边地区的气象条件关系密切. 在利用气象数据预测污染时, 仅使用近地面气象数据比使用多个高度上的气象数据更加准确.

## 参 考 文 献

[1] Tai A P K, Mickley L J, Jacob D J. Correlations between fine particulate matter (PM<sub>2.5</sub>) and meteorological variables in the United States: implications for the sensitivity of PM<sub>2.5</sub> to climate change. *Atmos Environ*, 2010, 44(32): 3976

[2] Pateraki S, Asimakopoulos D N, Flocas H A, et al. The role of meteorology on different sized aerosol fractions (PM<sub>10</sub>, PM<sub>2.5</sub>, PM<sub>2.5-10</sub>). *Sci Total Environ*, 2012, 419: 124

[3] Zhao X J, Zhang X L, Xu X F, et al. Seasonal and diurnal variations of ambient PM<sub>2.5</sub> concentration in urban and rural environments in Beijing. *Atmos Environ*, 2009, 43(18): 2893

[4] Pan B F, Zhao Y L, Li J J, et al. Analysis of the scavenging efficiency on PM<sub>2.5</sub> concentration of some kinds of meteorological fac-

tors. *Environ Sci Technol*, 2012, 25(6): 41  
(潘本锋, 赵熠琳, 李健军, 等. 气象因素对大气中 PM<sub>2.5</sub> 的去除效应分析. *环境科技*, 2012, 25(6): 41)

[5] Yan W L, Zhou D P, Wang Y F, et al. Concentrations and size distributions of inhalable particles in summer and winter in Shenyang. *J Appl Meteorol Sci*, 2008, 19(4): 435  
(严文莲, 周德平, 王扬峰, 等. 沈阳冬夏季可吸入颗粒物浓度及尺度谱分布特征. *应用气象学报*, 2008, 19(4): 435)

[6] Liu J, Zhang X L, Xu X F, et al. Comparison analysis of variation characteristics of SO<sub>2</sub>, NO<sub>x</sub>, O<sub>3</sub> and PM<sub>2.5</sub> between rural and urban areas, Beijing. *Environ Sci*, 2008, 29(4): 1059  
(刘洁, 张小玲, 徐晓峰, 等. 北京地区 SO<sub>2</sub>、NO<sub>x</sub>、O<sub>3</sub> 和 PM<sub>2.5</sub> 变化特征的城郊对比分析. *环境科学*, 2008, 29(4): 1059)

[7] Dong X L, Liu D M, Yuan Y S, et al. Pollution characteristics and influencing factors of atmospheric particulates in Beijing during the summer of 2005. *Chin J Environ Eng*, 2007, 1(9): 100  
(董雪玲, 刘大猛, 袁杨森, 等. 北京市 2005 年夏季大气颗粒物污染特征及影响因素. *环境工程学报*, 2007, 1(9): 100)

[8] Sillman S. The relation between ozone, NO<sub>x</sub> and hydrocarbons in urban and polluted rural environments. *Atmos Environ*, 1999, 33(12): 1821

[9] Zhou J X. Correlative analysis on relationship between changes of several main contaminations and some meteorological elements. *J Appl Meteorol Sci*, 2005, 16(Suppl): 123  
(周江兴. 北京市几种主要污染物浓度与气象要素的相关分析. *应用气象学报*, 2005, 16(增刊): 123)

[10] Zhou L, Xu X D, Ding G A, et al. The correlation factors and pollution forecast model for PM<sub>2.5</sub> concentration in Beijing Area. *Acta Meteorol Sin*, 2003, 61(6): 761  
(周丽, 徐祥德, 丁国安, 等. 北京地区气溶胶 PM<sub>2.5</sub> 粒子浓度的相关因子及其估算模型. *气象学报*, 2003, 61(6): 761)

[11] Ong B T, Sugiura K, Zettsu K. Dynamically pre-trained deep recurrent neural networks using environmental monitoring data for predicting PM<sub>2.5</sub>. *Neural Comput Appl*, 2016, 27(6): 1553

[12] Lary D J, Faruque F S, Malakar N, et al. Estimating the global abundance of ground level presence of particulate matter (PM<sub>2.5</sub>). *Geospatial Health*, 2014, 8(3): 611

[13] Ong B T, Sugiura K, Zettsu K. Dynamic pre-training of deep recurrent neural networks for predicting environmental monitoring data // 2014 IEEE International Conference on Big Data (Big Data). Washington, DC, 2014: 760

[14] Zheng Y, Zhu C Z. A prediction method of atmospheric PM<sub>2.5</sub> based on DBNs. *J Shandong Univ Eng Sci*, 2014, 44(6): 19  
(郑毅, 朱成章. 基于深度信念网络的 PM<sub>2.5</sub> 预测. *山东大学学报(工学版)*, 2014, 44(6): 19)

[15] Dai L J, Zhang C J, Ma L M. Dynamic forecasting model of short-term PM<sub>2.5</sub> concentration based on machine learning. *J Comput Appl*, 2017, 37(11): 3057  
(戴李杰, 张长江, 马雷鸣. 基于机器学习的 PM<sub>2.5</sub> 短期浓度动态预报模型. *计算机应用*, 2017, 37(11): 3057)

[16] Li X, Peng L, Hu Y, et al. Deep learning architecture for air quality predictions. *Environ Sci Pollut Res*, 2016, 23(22):

- 22408
- [17] Rumelhart D E , McClelland J L. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Volume 1. Foundations*. Cambridge: MIT Press , 1986
- [18] Hubel D H , Wiesel T N. Receptive fields of single neurones in the cat's striate cortex. *J Physiol* , 1959 , 148( 3) : 574
- [19] Pigou L , Van Den Oord A , Dieleman S , et al. Beyond temporal pooling: Recurrence and temporal convolutions for gesture recognition in video. *Int J Comput Vision* , 2018 , 126( 2-4) : 430
- [20] Yang J B , Nguyen M N , San P P , et al. Deep convolutional neural networks on multichannel time series for human activity recognition // *Proceedings of the Twenty-Fourth International Conference on Artificial Intelligence*. Buenos Aires , 2015: 3995
- [21] Hochreiter S , Schmidhuber J. Long short-term memory. *Neural Comput* , 1997 , 9( 8) : 1735
- [22] Jia M W , Kang N , Zhao T L. Characteristics of typical autumn and winter haze pollution episodes and their boundary layer in Nanjing. *Environ Sci Technol* , 2014 , 37( 120) : 105  
( 贾梦唯, 康娜, 赵天良. 南京秋冬季典型霾污染过程及边界层特征分析. *环境科学与技术* , 2014 , 37( 120) : 105)
- [23] Zhang J H , Xu S R , Zhao S M. Analysis of effect of temperature inversion to atmosphere pollution. *Heilongjiang Environ J* , 2008 , 32( 2) : 24  
( 张继红, 徐盛荣, 赵淑敏. 逆温天气对大气污染的影响分析. *黑龙江环境通报* , 2008 , 32( 2) : 24)
- [24] Ning H W. *An Analysis on Meteorological Factors and Study on Predicting Air Pollution in Xi'an City* [Dissertation]. Nanjing: Nanjing University of Information Science and Technology , 2006  
( 宁海文. 西安市大气污染气象条件分析及空气质量预报方法研究[学位论文]. 南京: 南京信息工程大学, 2006)
- [25] Xiao T Y , Ren H Y , Zhang X W. Analysis and prediction of the winter inversion in Harbin. *J Northeast Agric Univ* , 2001 , 32( 2) : 139  
( 肖同玉, 任红玉, 张兴文. 哈尔滨冬季逆温规律分析及预报. *东北农业大学学报* , 2001 , 32( 2) : 139)
- [26] Cao H L , Chen Q. Inverse temperature characteristics of boundary layer and its relationship with air pollution in Xi'an. *J Shaanxi Meteorol* , 2014( 2) : 13  
( 曹红丽, 陈奇. 西安边界层逆温特征及其与空气污染的关系. *陕西气象* , 2014( 2) : 13)