

应用 SVM 的 PM_{2.5} 未来一小时浓度动态预报模型

张长江¹, 戴李杰¹, 马雷鸣²

(1. 浙江师范大学 数理与信息工程学院, 浙江 金华 321004; 2. 上海市浦东新区气象局, 上海 200135)

摘要: 目前现有的 PM_{2.5} 模式预报值偏离实况观测值较大。针对上述问题, 从上海浦东气象局获得 2012 年 11 月~2013 年 11 月的 PM_{2.5} 实况观测浓度、PM_{2.5} 模式预报(WRF-CHEM)浓度和主要气象影响因子的模式预报数据资料, 在 PM_{2.5} 模式预报数据的基础上, 加入另外 5 个主要气象影响因子的模式预报数据, 应用支持向量机(SVM)建立动态预报模型, 提高 PM_{2.5} 未来一小时浓度预报的精度, 并且与径向基神经网络(RBFNN)、多元线性回归法(MLR)、WRF-CHEM 作对比。实验结果表明: 该算法较大提高了 PM_{2.5} 未来一小时浓度预报的精度, 预报精度优于 RBFNN、MLR 和 WRF-CHEM, 并且对 PM_{2.5} 浓度变化剧烈的情況具有较好地预报能力。

关键词: PM_{2.5}; 浓度预报; 支持向量机; 动态模型

中图分类号: P49 **文献标志码:** A **DOI:** 10.3788/IRLA201746.0226002

Dynamic model for forecasting concentration of PM_{2.5} one hour in advance using support vector machine

Zhang Changjiang¹, Dai Lijie¹, Ma Leiming²

(1. College of Mathematics, Physics and Information Engineering, Zhejiang Normal University, Jinhua 321004, China;

2. Shanghai Meteorological Bureau, Pudong New Area, Shanghai 200135, China)

Abstract: Current PM_{2.5} model forecasting data greatly deviate from the measured concentration. In order to solve this problem, support vector machine (SVM) was applied to set up a dynamic model. The data of PM_{2.5} model forecasting (WRF-CHEM) concentration and the five main model forecasting meteorological factors were used as training data of SVM. The data were provided by Shanghai Meteorological Bureau in Pudong New Area (from November in 2012 to November in 2013). The dynamic model was used to improve the forecasting accuracy of PM_{2.5} concentration one hour in advance. SVM model was compared with radical basis function neural network (RBFNN), Multi-variable Linear Regression (MLR) and WRF-CHEM. Experimental results show that the proposed algorithm greatly improves the forecasting accuracy of PM_{2.5} concentration one hour in advance. SVM model performs better than RBFNN, MLR and WRF-CHEM, and has better forecasting ability for the condition with concentration dramatic changing.

Key words: PM_{2.5}; concentration forecast; support vector machine; dynamic model

收稿日期: 2016-06-10; 修订日期: 2016-07-20

基金项目: 国家自然科学基金(41575046); 浙江省科技厅公益性技术应用研究计划(2016C33010); 浙江省金华市科技计划(2014-3-028)

作者简介: 张长江(1974-), 男, 教授, 硕士生导师, 博士, 主要从事信号与信息处理方面的研究。Email: zcj74922@zjnu.edu.cn

0 引言

造成霾天气的主要成因是 PM_{2.5}, 由于 PM_{2.5} 颗粒直径 $\leq 2.5 \mu\text{m}$ 的细颗粒物, 可直接通过呼吸道进入肺部, 诱发肺部疾病。目前关于 PM_{2.5} 的研究国内才刚刚起步, 因为观测数据资料缺乏, 所以对于 PM_{2.5} 浓度的预报手段还很粗糙, 实际预报效果不尽人意, 因此 PM_{2.5} 浓度的准确预报有着重要的理论研究意义和实际应用价值。目前 PM_{2.5} 浓度的预报主要包括数值模式预报和统计预报两种方法。由于数值模式预报对污染与气象数据的要求较高, 相关数据往往很难获得^[1], 所以数值模式预报方法在国内大多城市并不成熟。目前, 国内外主要通过统计模型对 PM_{2.5} 浓度进行预报, 主要包括回归模型(线性和非线性回归模型)、神经网络模型、支持向量机(SVM)模型、灰度系统模型及马尔科夫模型等。

回归模型近年来被较多应用于 PM_{2.5} 浓度预报。如 W. Geoffrey Cobourn^[2]提出一种基于非线性回归和后推气流轨迹浓度的预报模型, 预报 PM_{2.5} 日均最大值, 该模型将 PM₂₄(基于逆风 PM_{2.5} 浓度)参数作为输入, 结果显示添加 PM₂₄ 为输入的模型预报精度高于未添加的模型。Kirk R. Baker 等^[3]人使用非线性回归模型对单一排放来源的 PM_{2.5} 浓度进行预报。

人工神经网络(ANN)能较好解决非线性问题, 近年来被应用于 PM_{2.5} 浓度预报。如秦珊珊^[4]提出基于人工智能优化神经网络模型, 对 PM_{2.5} 的小时浓度进行预报。Zhang Ping 等^[5]人用改进的 BP 人工神经网络, 并结合地理信息系统评估不同算法的 PM_{2.5} 预报效果, 结果显示当隐含层神经元数量为 20 时有较高的精度。

国内外有学者使用 SVM 对空气污染物的浓度进行预报, 如李龙等^[6]人选择多个特征向量结合最小二乘支持向量机能够较为准确地预报 PM_{2.5} 浓度, 泛化能力较强。刘杰等^[7]人提出应用 SVM 和模糊粒化时间序列相结合的方法, 能较好解决 PM_{2.5} 机理性建模方式下由于影响因素考虑不全而造成的预报结果不稳定。国内外这些学者使用 SVM 对空气污染物浓度进行预报, 所建立的模型基本上为静态模型, 该模型采用固定的数据进行训练, 然后用测试

数据进行预报。

近年来, 也有学者使用灰度系统模型及马尔科夫模型, 国内有 Li Jiayang 等^[8]人建立多元灰度模型来预报 PM_{2.5} 浓度。Sun Wei 等^[9]人提出改进的隐马尔可夫模型来预报日平均浓度。Dong Ming 等^[10]人提出一种隐半马尔可夫模型, 该模型将时间结构加入到隐马尔可夫模型预报未来 24 h PM_{2.5} 浓度。

由于 PM_{2.5} 与空气质量、气象因子之间是非线性的关系, 线性回归模型无法很好地解决非线性问题, 而神经网络能较好地解决非线性关系问题, 非线性拟合能力较强, 但仍然存在泛化能力及稳定性差、学习速度慢、容易过拟合和陷入局部极小值等问题。SVM 在解决小样本、非线性及高维模式识别中表现出许多特有的优势。国内外学者对空气污染物浓度进行预报, 所建立的模型基本上为静态模型。文中提出一种新的 PM_{2.5} 浓度预报方法, 通过使用 SVM 对历史数据进行训练, 通过实验试验对 SVM 中重要参数进行设定, 以得到较为准确的回归拟合模型, 然后通过导入下一小时的输入数据, 预报未来一小时的 PM_{2.5} 浓度, 文中所采用的方法是建立动态预报模型, 每次预报时, 训练建模所用数据为该时刻之前的 18 个小时, 所以每次都建立不同的预报模型, 以此提高 PM_{2.5} 的预报精度。

1 数据及预报方法

1.1 数据选取与处理

建模所用数据是由上海浦东气象局所提供的历史气象的小时数据(包括 2012 年 11 月~2013 年 11 月), 包括 PM_{2.5} 实况观测值、PM_{2.5} 模式预报值、2 m 高度处温度(T₂)、2 m 高度处相对湿度(RH₂)、10 m 高度处风速、海平面气压(SLVL)及边界层高度(PBLH)等气象要素模式预报数据。由于经过统计分析得出小时 PM_{2.5} 浓度与 5 个主要影响因素(T₂、RH₂、风速、SLVL、PBLH)相关性较大, 因此选择这 5 个气象因子模式预报数据和 PM_{2.5} 模式预报数据作为建模的训练输入。

文中预报的时间段为 2012 年 12 月~2013 年 11 月, 共 8688 次预报, 2012 年 11 月 30 日 6:00~23:00 为训练建模所用, 2012 年 12 月 1 日 0:00 为预报的第一

个时刻,直到 2013 年 11 月 28 日 23:00 为预报的最后一个时刻。训练输入为 PM2.5 模式预报值和 5 个主要影响因子模式预报值,训练输出为相应时刻的实况观测值。预报输入数据为未来一小时的 PM2.5 模式预报值和 5 个影响因子的模式预报值,输出为未来一小时的 PM2.5 预报浓度值,以此可建立未来一小时的预报模型。

在训练之前,先对数据进行归一化处理,将数据都归一化到[0,1]范围,可消除各维数据之间的数量级差别,有利于提高模型的预报精度,所用到的归一化函数为:

$$x_k = (x_k - x_{\min}) / (x_{\max} - x_{\min}) \quad (1)$$

式中: x_{\min} 为数据序列中的最小值; x_{\max} 为数据序列中的最大值。

1.2 预报方法

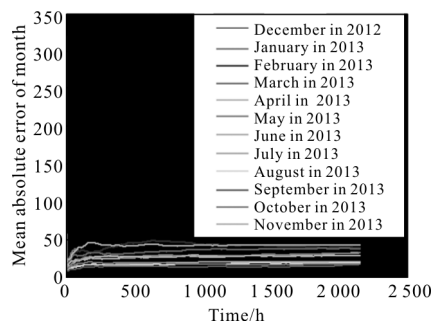
文中基于 2012 年 11 月~2013 年 11 月的数据,用 Matlab 语言编程,用 SVM、RBFNN 和 MLR 分别建立预报模型。使用 LIBSVM-3.11 版本的工具箱,SVM 类型选择 epsilon-SVR,核函数选择 RBF 核函数。首先对 8 688 次预报的建模所用数据进行回归拟合,以回归拟合均方误差(MSE)及平方相关系数(R)为目标,并使用改进的粒子群优化算法(PSO)辅助寻找 8 688 组 SVM 的惩罚参数 c 和核函数中的系数 g ,取其均值为 $c=11.4, g=5.8$,然后通过人工方法在附近选取最优的参数。最终,经实验测试和对比结果后,确定参数 $c=2.3, p=0.9, \rho=0.01$,参数 g 为核函数中的 γ ,参数 p 为 epsilon-SVR 中损失函数的值,即 ε 。

RBFNN 是一种三层前向网络,隐层节点激活函数为径向基函数,输出层节点激活函数为线性函数。文中用 newrbe 函数设计精确径向基网络,newrbe 创建神经网络时,RBF 神经元数等于输入样本数量。经过试验得扩展速度 SPREAD 设置为 0.2 时,RBFNN 预报准确度最高。

1.3 训练建模所用历史数据时间长度的确定


由于多元线性回归法的建模预报时间较短,因此选择多元线性回归对训练数据量的选取进行测试,分别取每个月的前 7 个小时(图上对应第一个点)~前 2160 个小时的数据量作为训练输入,通过每个月的平均绝对误差和平均相对误差来得出最优的历史数据训练量。如图 1(a)为每个月的月平均

绝对误差值的变化曲线,图 1(b)为关键位置放大后




(a) 月平均绝对误差

(a) Mean absolute error of month




(b) 图(a)局部放大图

(b) Partial enlargement drawing of Fig.(a)



(c) 月平均相对误差

(c) Mean relative error of month



(d) 图(c)局部放大图

(d) Partial enlargement drawing of Fig.(c)

图 1 误差图及其局部放大图

Fig.1 Drawing of error and partial enlargement

的图,图 1(c)为每个月的月相对误差值得变化曲线,图 1(d)为关键位置放大图。其中,由于 2012 年 12 月和 2013 年 1 月的历史数据量有限,笔者分别选取这两个月的前 7 h(图上对应第一个点)~前 90 h 作为训练数据量。

通过对训练数据量的测试后发现,误差曲线先下降然后上升,之后处于比较平稳的状态,当训练数据量取前 18 h(图上对应第 12 个点)的时候,每个月的平均绝对误差和平均相对误差较低。至此,我们确定当选取前 18 个小时的数据量进行训练建模时,PM2.5 的未来一小时预报准确度最高。

1.4 模型的建立

具体方案:

(1) 对缺失数据进行填补,并对数据进行归一化预处理。

(2) 用 SVM 与 RBFNN、MLR 分别建模,将 PM2.5 模式预报值和同时刻五个气象影响因子模式预报值作为训练输入,相应时刻的 PM2.5 实况观测值作为输出,训练数据取前 18 个小时的数据。

(3) 对已建好的模型,导入未来一小时 PM2.5 模式预报值及五个气象影响因子的模式预报值,预报未来一小时 PM2.5 浓度值。

应用 SVM 的 PM2.5 未来一小时浓度动态预报流程图如图 2 所示。

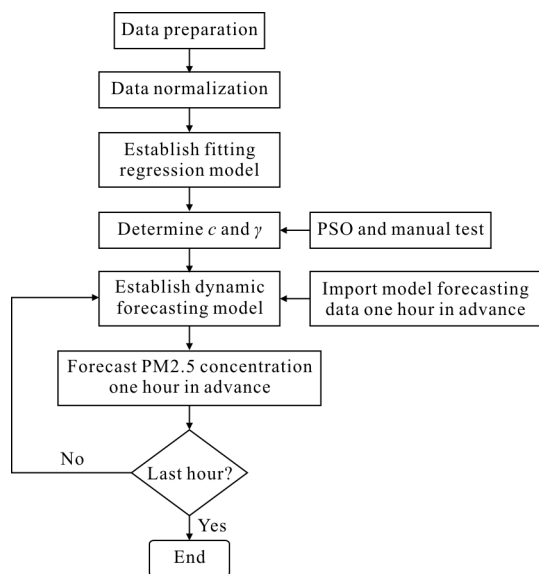


图 2 PM2.5 未来一小时浓度动态预报模型

Fig.2 Dynamic model for forecasting concentration of PM2.5 one hour in advance

2 ε-支持向量机非线性回归

用 SVM 进行非线性回归和预报是将数据通过非线性映射到高维特征空间 Ω 中,在该特征空间中进行线性回归^[11-13]。设数据样本 $\{(x_1, y_1), \dots, (x_n, y_n)\}$, $x_i \in R^d, y_i \in R, i=1, 2, \dots, n$, 则 SVM 回归模型的线性回归函数方程为: $f(x) = \omega \cdot x + b$ 将回归估计转化为一个最优化问题,引入 ϵ -不敏感损失函数、松弛变量 ξ_i 及 ξ_i^* ,且 ξ_i 及 ξ_i^* 均大于等于 0,则问题描述为^[14]:

$$\min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (2)$$

$$s.t. \begin{cases} y_i - \omega \cdot x_i - b \leq \epsilon + \xi_i \\ \omega \cdot x_i + b - y_i \leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0, i=1, 2, \dots, n \end{cases} \quad (3)$$

式中: C 为惩罚常数,用于控制对超出误差范围的样本的惩罚程度。用拉格朗日乘子法求解,将原空间中的非线性回归问题转化为高维特征空间中的线性回归进行求解,基本思想是将高维特征空间中的向量内积 $\varphi(x_i) \cdot \varphi(x)$ 用输入空间中的核函数 $K(x_i, x)$ 来替代^[15],即

$$K(x_i, x) = \varphi(x_i) \cdot \varphi(x) \quad (4)$$

回归函数可以写为:

$$f(x) = \sum_{i=1}^n (\alpha + \alpha_i^*) K(x_i, x) + b \quad (5)$$

式中: ω 为权向量; b 为阈值; $\alpha, \alpha_i^*, i=1, 2, \dots, n$, 为拉格朗日乘子; $K(x_i, x)$ 为核函数。

3 实验结果及分析

文中用 Matlab 语言编程,用 SVM、MLR 和 RBFNN 分别建模型。经实验得出每个月的未来一小时预报曲线、绝对误差柱状图。

3.1 2013 年 10 月预报结果及分析

3.1.1 预报曲线

以 2013 年 10 月的数据为例,用文中提出的 SVM 以及 RBFN、MLR 和 WRF-CHEM 等方法的未来一小时 PM2.5 浓度预报曲线如图 3 所示。

2013 年 10 月为秋季,从预报曲线图可知,SVM 预报曲线趋势与实况观测值曲线最为接近,在 PM2.5 浓度转变剧烈区域,与实况观测值曲线较为

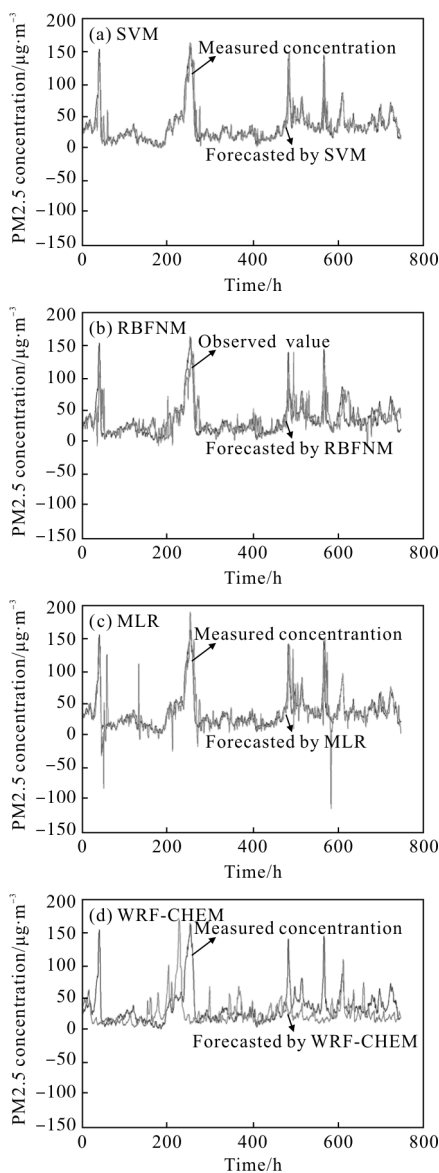


图 3 2013 年 10 月预报曲线

Fig.3 Forecasting curve in October, 2013

接近,但在少数区域有仍一定偏离。RBFNN 的预报曲线趋势与实况观测值曲线相近,但在一些波峰波谷等 PM2.5 浓度转变区域与实况观测值曲线有一定偏离。MLR 预报曲线波动较大,并且产生较多的负值,即使在 PM2.5 浓度变化平缓区域,预报曲线也有偏离。WRF-CHEM 预报曲线趋势有时与实况观测值曲线接近,有时与实况观测值偏离较大,在 PM2.5 浓度转变剧烈区域,与实况观测值曲线偏离较大。对于未来一小时的预报准确度,SVM、RBFNN 及 MLR 这三种方法都高于模式预报,RBFNN 和 MLR 与实况观测值相比有一定偏离,特别在 PM2.5 转变的波峰波谷区域,该两种方法预

报准确度下降,但两者曲线整体走势与实况观测值相近。相比之下,文中提出的 SVM 预报方法与实况观测值最为接近,在曲线转变的波峰波谷附近,对于未来一小时的 PM2.5 浓度能进行较好地预报。

3.1.2 绝对误差柱状图

从图 4 可知,3 个方法的绝对误差都比模式预报小,对于未来一小时的预报准确度都高于模式。相比几种方法,SVM 绝对误差柱状图绝大多数集中在误差最小的区间,频数超过 400,高于 RBFNN 及 MLR,而 MLR 有些分布在误差较大区域,误

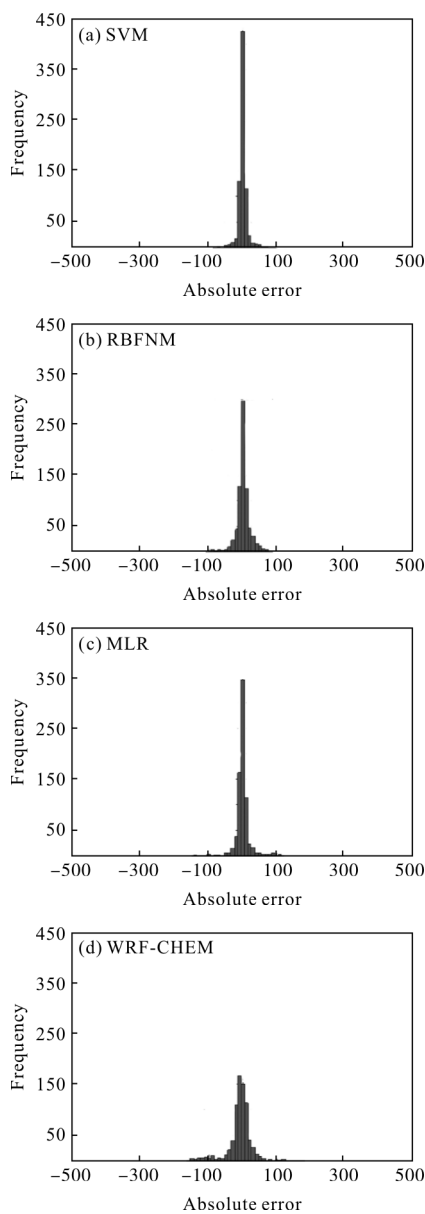


图 4 2013 年 10 月绝对误差柱状图

Fig.4 Histogram of absolute error in October, 2013

差间隔为 $10 \mu\text{g}/\text{m}^3$ 。模式预报的平均绝对误差为 $20.39 \mu\text{g}/\text{m}^3$, SVM 的平均绝对误差最小, 为 $7.03 \mu\text{g}/\text{m}^3$, 预报准确度比模式提高很多。相比之下, SVM 对于未来一小时的预报准确度最高, 相比模式预报

提高很多。

3.2 2012 年 12 月~2013 年 11 月预报结果及分析

2012 年 12 月~2013 年 11 月, 每个月及全年的平均绝对误差和平均相对误差如表 1 所示。

表 1 平均绝对误差与平均相对误差

Tab.1 Mean absolute error and mean relative error

Time	Mean absolute error				Mean relative error			
	SVM	RBFNN	MLR	WRF-CHEM	SVM	RBFNN	MLR	WRF-CHEM
2012.12	8.23	18.01	12.56	40.54	0.148 7	0.328 9	0.229 0	0.688 6
2013.1	13.79	32.05	20.37	67.79	0.182 3	0.458 0	0.276 2	0.630 1
2013.2	10.85	22.45	17.80	44.85	0.200 5	0.523 6	0.336 8	0.653 6
2013.3	10.10	20.85	13.49	43.76	0.198 4	0.467 6	0.311 5	0.665 8
2013.4	10.19	23.75	15.15	32.53	0.178 2	0.425 0	0.276 4	0.533 9
2013.5	8.00	17.69	10.52	36.59	0.163 9	0.408 3	0.226 5	0.784 2
2013.6	9.27	22.02	13.51	30.71	0.228 5	0.498 2	0.320 3	0.819 0
2013.7	8.53	15.60	11.39	20.64	0.244 2	0.471 9	0.332 7	0.554 5
2013.8	6.63	12.03	8.60	18.44	0.316 5	0.597 9	0.380 6	0.814 6
2013.9	5.61	12.30	7.65	22.50	0.240 5	0.572 2	0.345 4	1.100 2
2013.10	7.03	12.23	9.92	20.39	0.280 6	0.589 3	0.429 0	0.775 3
2013.11	12.47	22.57	19.03	52.76	0.238 4	0.389 2	0.342 5	0.818 7
Whole year	9.19	19.23	13.25	35.82	0.218 5	0.477 8	0.317 0	0.736 4

注: PM2.5 浓度单位 $\mu\text{g}/\text{m}^3$

3.2.1 绝对误差柱状图

绝对误差柱状图如图 5 所示。


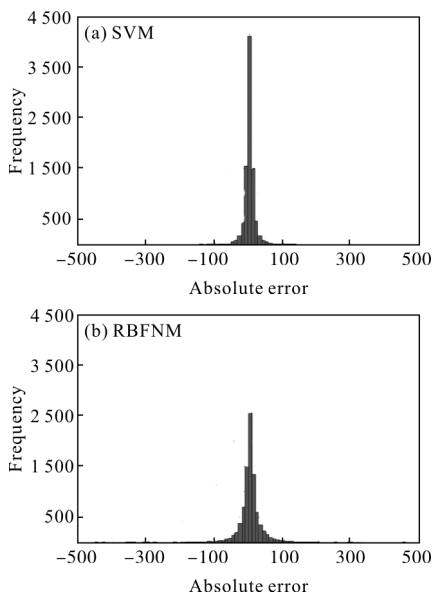


图 5 2012 年 12 月~2013 年 11 月绝对误差柱状图
Fig.5 Histogram of absolute error from December in 2012 to November in 2013

从表 1 可知,2012 年 12 月至 2013 年 11 月期间,SVM、RBFNN 及 MLR 的平均绝对误差比 WRF-CHEM 小,相比之下,预报准确度从高到低依次是 SVM、MLR、RBFNN 及 WRF-CHEM。该期间,SVM 预报方法的平均绝对误差最小,相比 WRF-CHEM 提高很多。绝对误差柱状图的误差间隔为 $10 \mu\text{g}/\text{m}^3$,从图 4 和图 5 可知,SVM 的绝对误差落在误差范围最小区间的频数最多,MLR 的预报误差比 RBFNN 小,三种方法的预报误差比模式低很多,RBFNN 及 MLR 有少量散布在误差较大区域。相比之下,SVM 对于 PM2.5 未来一小时的浓度预报准确度最高。

3.3 预报时间对比

该实验硬件环境为 DELL 工作站,处理器 Intel 2.8 GHz,内存 3 G,软件环境为 Matlab2009a,使用 Matlab 语言进行编程,SVM、RBFNN 及 MLR 对于 PM2.5 未来一小时的浓度预报时间如表 2 所示。

表 2 预报时间对比

Tab.2 Comparison of forecasting time

	SVM	RBFNN	MLR
Time/s	0.007 349	0.028 742	0.0085 80

从表 2 可知,SVM 对 PM2.5 未来一小时的浓度预报时间最短,由此可见,相比 RBFNN 及 MLR,文中所提出的预报方法具有快速和较高准确度的特点。

4 结论

文中基于上海浦东气象局所提供的 PM2.5 实况观测值、PM2.5 模式预报浓度值及气象影响因子模式预报数据,用 SVM 建立动态预报模型,并对比 RBFNN、MLR 建模预报效果,经实验得出如下结论:

(1) 文中在实验结果中选取 2013 年 10 月,对这个月的 SVM、RBFNN、MLR 及 WRF-CHEM 预报方法进行对比,通过预报曲线图和误差柱状图可知:对于未来一小时的预报准确度,三种预报方法比模式预报高,相比而言,SVM 的预报准确度最高,偏离实况观测值较小,并且在 PM2.5 浓度转变的波峰波谷附近仍能较好地预报,而 RBFNN 及 MLR 的预报准确度则下降。

(2) 文中分析了 2012 年 12 月至 2013 年 11 月

的预报结果,通过分析实验结果可知:该期间,SVM 模型的平均绝对误差 ($9.19 \mu\text{g}/\text{m}^3$) 及平均相对误差 (0.218 5) 最小,PM2.5 未来一小时的浓度预报准确度从高到低依次是 SVM、MLR、RBFNN 及 WRF-CHEM,对 PM2.5 浓度变化剧烈的情况,SVM 模型仍能对 PM2.5 未来一小时的浓度进行较好地预报,体现了动态预报模型的优势。

参考文献:

- [1] Liu Huijun. Developing pattern prediction, casual analysis and simulation of PM2.5 pollution in Wuhan City [D]. Changsha: Hunan University, 2014. (in Chinese)
刘慧君. 武汉市 PM2.5 污染的演变预测及成因分析和仿真[D]. 长沙: 湖南大学, 2014.
- [2] Cobourn W G. An enhanced PM2.5 air quality forecast model based on nonlinear regression and back-trajectory concentrations [J]. *Atmospheric Environment*, 2010, 44(25): 3015-3023.
- [3] Baker K R, Foley K M. A nonlinear regression model estimating single source concentrations of primary and secondarily formed PM2.5 [J]. *Atmospheric Environment*, 2011, 45(22): 3758-3767.
- [4] Qin Shanshan. Statistical analysis and forecasting of suspended particulate matters, PM10 and PM2.5 [D]. Lanzhou: Lanzhou University, 2014. (in Chinese)
秦珊珊. 悬浮颗粒物 PM10 与 PM2.5 的统计分析与预测[D]. 兰州: 兰州大学, 2014.
- [5] Zhang Ping, Zhang Tao, He Liang, et al. Study on prediction and spatial variation of PM2.5 pollution by using improved BP artificial neural network model of computer technology and GIS [J]. *Computer Modelling and New Technologies*, 2014, 18(12): 107-115.
- [6] Li Long, Ma Lei, He Jianfeng, et al. PM2.5 concentration prediction model of least squares support vector machine based on feature vector [J]. *Journal of Computer Applications*, 2014, (8): 2212-2216. (in Chinese)
李龙, 马磊, 贺建峰, 等. 基于特征向量的最小二乘支持向量机 PM2.5 浓度预测模型 [J]. 计算机应用, 2014, (8): 2212-2216.
- [7] Liu Jie, Yang Peng, Lv Wensheng, et al. Prediction model of PM2.5 mass concentrations based on fuzzy time series and support vector machine [J]. *Journal of University of Science and Technology Beijing*, 2014, 36(12): 1694-1702. (in Chinese)
刘杰, 杨鹏, 吕文生, 等. 模糊时序与支持向量机建模相结

- 合的 PM_{2.5} 质量浓度预测 [J]. 北京科技大学学报, 2014, 36(12): 1694–1702.
- [8] Li Jianyang, Yang Zhao, Shi Shenkai. The multivariate gray model approach to predict the concentration of atmospheric fine PM_{2.5} [C]//3rd International Conference on Energy and Environmental Protection, 2014: 2362–2365.
- [9] Sun Wei, Zhang Hao, Palazoglu Ahment, et al. Prediction of 24-hour average PM_{2.5} concentrations using a hidden Markov model with different emission distributions in Northern California [J]. *Science of the Total Environment*, 2013, 443: 93–103.
- [10] Dong Ming, Yang Dong, Kuang Yan, et al. PM_{2.5} concentration prediction using hidden semi-Markov model-based times series data mining [J]. *Expert Systems With Applications*, 2009, 36(5): 9046–9055.
- [11] Han Jun, Chang Bo, Lu Shaojun, et al. Image distortion calibration of imaging spectrometer with grating by SVM [J]. *Infrared and Laser Engineering*, 2014, 43(9): 3099–3104.
韩军, 常波, 路邵军, 等. SVM 的光栅成像光谱仪图像畸变校准方法 [J]. 红外与激光工程, 2014, 43 (9): 3099–3104.
- [12] Li Jiang, Guo Lihong. Target threat assessment using improved SVM [J]. *Optics and Precision Engineering*, 2014, 22(5): 1354–1362. (in Chinese)
李姜, 郭立红. 基于改进支持向量机的目标威胁估计 [J]. 光学精密工程, 2014, 22(5): 1354–1362.
- [13] Wang Fangbin, Hong Jin, Sun Xiaobing, et al. Prediction of polarization pattern by SVM [J]. *Optics and Precision Engineering*, 2014, 22(11): 2914–2922. (in Chinese)
汪方斌, 洪津, 孙晓兵, 等. 基于支持向量机预测偏振模式 [J]. 光学精密工程, 2014, 22(11): 2914–2922.
- [14] Liang Dong, Yang Qinying, Huang Wenjiang, et al. Estimation of leaf area index based on wavelet transform and support vector machine regression in winter wheat [J]. *Infrared and Laser Engineering*, 2015, 44(1): 335–340. (in Chinese)
梁栋, 杨勤英, 黄文江, 等. 基于小波变换与支持向量机回归的冬小麦叶面积指数估算 [J]. 红外与激光工程, 2015, 44(1): 335–340.
- [15] Jin Yan, Chu Zheng, Zhang Jin. Improved weighted support vector regression algorithm for vulnerability assessment of electronic devices illuminated or injected by high power microwave [J]. *High Power Laser and Particle Beams*, 2014, 26(12): 177–182. (in Chinese)
金焱, 褚政, 张瑾. 改进加权支持向量机回归方法器件易损性评估 [J]. 强激光与粒子束, 2014, 26(12): 177–182.