

张伟, 王自发, 安俊岭, 等. 2009. 利用 BP 神经网络提高奥运会空气质量实时预报系统预报效果 [J]. 气候与环境研究, 15 (5): 595 - 601. Zhang Wei, Wang Zifa, An Junling, et al. 2009. Update the ensemble air quality modeling system with BP model during Beijing Olympics [J]. Climatic and Environmental Research (in Chinese), 15 (5): 595 - 601.

利用 BP 神经网络提高奥运会空气质量 实时预报系统预报效果

张伟^{1,2} 王自发^{1,3} 安俊岭¹ 杨婷^{2,3} 唐晓^{1,2,3}

1 中国科学院大气物理研究所大气边界层与大气化学国家重点实验室, 北京 100029

2 中国科学院研究生院, 北京 100049

3 中国科学院大气物理研究所竺可桢-南森国际研究中心, 北京 100029

摘要 将 BP (Back Propagation) 神经网络方法引入到奥运空气质量预报工作中, 利用 MATLAB 神经网络工具箱搭建运行平台, 将高时效性的观测结果与多模式集成实时预报系统的模式输出结果相结合, 做出 BP 神经网络拟合预报结果。在对北京大学医学部站点 2008 年 7 月 7 日到 8 月 26 日模式模拟结果、观测结果以及 BP 神经网络拟合结果的对比研究中发现: BP 神经网络能大大提高模式预报效果, 平均误差率减少 34.7%, 相关系数提高 39%, 特别是在模式模拟效果较差的情况下, 对提高预报效果更明显。对 BP 神经网络样本问题进行敏感性实验结果表明, 样本数目多少并不是决定拟合效果的决定性因素, 应选取具有稳定映射关系的样本, 才是提高拟合预报效果的关键。

关键词 BP 神经网络 空气质量预报 北京奥运会

文章编号 1006-9585 (2010) 05-0595-07 **中图分类号** P401 **文献标识码** A

Update the Ensemble Air Quality Modeling System with BP Model during Beijing Olympics

ZHANG Wei^{1,2}, WANG Zifa^{1,3}, AN JunLing¹, YANG Ting^{2,3}, and TANG Xiao^{1,2,3}

1 *State Key Laboratory of Atmospheric Boundary Layer Physics and Atmospheric Chemistry, Institute of Atmospheric Physics, Chinese Academy of Sciences, Beijing 100029*

2 *Graduate University of Chinese Academy of Sciences, Beijing 100049*

3 *Nansen-Zhu International Research Center, Institute of Atmospheric Physics, Chinese Academy of Sciences, Beijing 100029*

Abstract Back Propagation neural network model (BP model) was applied to the Olympic air quality forecasting. By using MATLAB neural network toolbox, assembled air quality modeling forecasting system was combined with nearly real-time observations to fit BP neural network forecasting results. The measurements were made from 7 July to 26 August 2008 in the Peking University Health Science Center. Using these data, the performance of the BP neural network results is assessed. The results show that BP neural network can significantly improve the simulation

收稿日期 2010-04-06 收到, 2010-07-21 收到修定稿

资助项目 北京市科委重大项目“北京及近周边区域 大气复合污染形成机制及防控措施研究示范”课题“区域大气污染模拟、预测、预警与示范”

作者简介 张伟, 男, 1984 年出生, 硕士, 主要从事区域污染问题研究。E-mail: frog.mdk@163.com

results, with the average error rate decreasing by 34.7% and the correlation coefficient increasing by 39%. The advantage of BP neural network is more obvious when the original simulation results are poor. The sensitivity experiment of BP neural network sample size indicates that the number of samples is not the decisive factor in deciding fitting effect, and the stability of mapping relationship in samples plays a crucial role in raising the effect of prediction.

Key words BP neural network, air quality forecasts, the Beijing Olympic Games

1 引言

20 世纪 80 年代以来,伴随着计算机技术的发展人工神经网络(Artificial Neural Network)技术得到了飞速的发展。由于它与数学、统计学的紧密联系,在处理线性与非线性规划问题、数值逼近及统计计算方面具有传统方法不具有的并行处理,容错性以及自学习功能,使其在众多科学领域取得了大量的应用研究成果。近年来,人工神经网络在空气质量预报中的应用也得到了很大的发展,其中刘罡等(2000)利用人工神经网络对非线性现象的刻画能力,利用长达 10 年的观测资料建立起时间序列与大气污染物浓度的非线性映射关系,从而实现大气污染物浓度的预报,并得到了较好的结果。王俭等(2002)将 BP 网络(Black Propagation Network)模型引入到大气污染预报中,利用大气污染物含量与气象要素的关系建立起关于气象要素的大气污染物预报模型。于文革等(2008)将基于主成分分析的 BP 神经网络

络预报方法引入大气污染预报,建立了 SO_2 浓度预报模型。并讨论了 BP 神经网络隐层节点数对训练结果的影响。

2008 年初,中国科学院大气物理研究所在北京环境监测中心搭建了空气质量多模式集成实时预报系统(以下简称为多模式集成实时预报系统),预报时长为 72 小时,系统具有较高时效性,每日模式计算在 08 时(北京时间,下同)以前完成。这一系统的搭建完成成为北京空气质量数值预报尤其是奥运会空气质量预报提供坚实的数值模式数据基础。

作为奥运会空气质量保障项目的重要部分,2008 年 7~8 月,中国科学院大气物理研究所、北京大学等几家单位在北京市内及北京市周边地区建立了近 20 个空气主要污染物观测站点(站点位置见图 1b),由于奥运会空气质量保障项目的特殊性,本次污染物观测结果每日 15 时更新,最近观测时间点为当日 12 时。

由于排放源、气象场输入等与真实情况的差异以及空气质量模式自身的原因,模式预报结果




图 1 (a) 模拟区域设定及 (b) 观测站点位置

Fig. 1 (a) The modeling domains and (b) observation sites

总会与观测值存在一定的偏差, 本文尝试在多模式集成预报系统的基础上引入 BP 神经网络, 并利用 BP 神经网络模型建立模式预报结果与观测值之间的非线性映射关系, 减少模式偏差, 提高预报准确度。

2 研究方法

2.1 多模式集成实时预报系统

多模式集成实时预报系统采用中国科学院大气物理研究所自主开发的 NAQPMS (Nested Air Quality Prediction Model System) 模式 (王自发等, 2006), 美国 EPA (Environmental Protection Agency) 的 Model-3/CMAQ (Community Multi-scale Air Quality Modeling) 模式及美国 Environ 公司在城市大气化学中广泛应用的 CAMx 模式作为空气质量数值预报的核心空气质量模式, 为了更准确客观地评估各模式系统的性能, 避免气象场和排放源差异对模式模拟效果的影响。此系统采用中尺度气象模式 MM5 (Grell et al., 1995) 为各空气质量模型提供气象驱动, 并采用 SMOKE 排放源处理模型统一处理排放清单, 以提供各空气质量子模式统一排放源, 通过气象—化学及排放源—化学交互模块实现 MM5 气象模式及 SMOKE 排放源模型与空气质量模式的对接。

2.1.1 模式设定

多模式集成实时预报系统里所有模式采用同样的网格设定, 模拟区域设定如图 1a 所示, 网格为 4 重嵌套网格, 第一重嵌套网格中心点为 (35°N, 110°E)。第一到第四重嵌套网格水平隔距分别为 81 km×81 km、27 km×27 km、9 km×9 km、3 km×3 km。

在多模式集成实时预报系统中, MM5 气象场模拟过程中采用了 Lin 微物理过程方案, GFDL (Geophysical Fluid Dynamics Institute) (Eta) 长短波方案, Noah 陆面过程方案, Eta Mellor-Yamada-Janjic TKE (湍流动能) 边界层方案以及浅对流 Kain-Fritsch (new Eta) 积云参数化方案。NAQPMS 模式采用 CBM-Z (Carbon Bond Mechanism version Z) 化学机制, 采用双向嵌套的方式进行计算。CMAQ 模式采用 CB4 (Carbon Bond mechanism version 4) 化学机制, 以单向嵌套的

方式进行计算, CAMx 模式采用 CB4 化学机制, 以双向嵌套的方式进行计算。

在模式预报中, MM5 模式的初始和边界条件取自 NOAA 的全球预报气象场 GFS (Global Forecasting System) 数据集 [AVN (Aviation Model) 分析资料]。MM5 气象预报 96 小时, 下载获得预报起始时间每日协调世界时 12 时, 即北京时间 20 时, 24 小时一次的 GFS 数据集为 MM5 模式提供初始及边界条件。空气质量模型都采用前一天预报结果作为当日模拟预报初始条件。

2.1.2 模式输出

系统预报时长为 72 小时, 结果输出为小时均值, 除了 3 个模式的模拟结果以外还输出模式平均结果。由于采用一致的气象场及排放源, 模式结果大体趋势保持一致, 而在很多情况下, 模式集合平均结果好于单个模式的输出结果。

2.2 BP 神经网络模型的建立

BP 网络 (Black Propagation Network) 是 1986 年由 Rumelhart 和 McClelland 为首的科学家小组提出的一种按误差逆传播算法训练的多层前馈网络, 是目前应用最广泛的神经网络模型之一。BP 网络能学习和存贮模型输入与输出映射关系, 而无需事前揭示描述这种映射关系的数学方程。它学习规则是使用最速下降法, 利用反向传播来不断调整网络的权值与阈值, 使网络的误差最小。

BP 神经网络模型拓扑结构包括输入层, 隐含层和输出层。BP 网络结构是通过确定网络层数、每层节点数、传递函数、初始权系数、学习算法来确定的。本文借助于 MATLAB 神经网络工具箱来实现 BP 网络模型的建立, 免去了大量编程工作。在建立网络模型过程中选用单层隐含层结构, 隐含层传递函数选用 tansig 函数, 输出层传递函数选用 logsig 函数。隐含层节点数目直接关系到训练效率, 最适合的隐含层节点数与所建立的 BP 神经网络模型结构及计算环境有关, 本文通过改变隐含层节点数对网络进行训练, 在样本数为 100 的情况下训练结果见表 1, 当隐含层节点数为 11 时 BP 网络系统误差最小。

集合预报系统多模式早些时候的输出结果作为学习样本, 同一时间观测结果作为输出期望训练网络。训练完成以后, 输入当天预报结果即得到 BP 神经网络拟合预报结果 (图 2)。




图 2 BP 神经网络模型拓扑结构

Fig. 2 The topology frame of BP model

表 1 BP 神经网络模型拓扑结构

Table 1 The training system error of hidden layer nodes under the conditions of a single hidden layer

隐含节点数	系统误差
7	0.196
8	0.187
9	0.219
10	0.071
11	0.034
12	0.187
13	0.208

本文模式模拟时间内存在排放源改变的情况,排放源改变前后模拟结果与观测值之间的映射关系发生了改变。因此在选取样本的时候采取两段法,从 2008 年 7 月 7 日开始,初始样本为 28 个,随着时间样本数逐渐增加,直到样本数到达 100 个,而后保持样本数不变,取最接近预报日期的 100 组观测模拟值作为样本继续拟合预报。到 7 月 25 日样本数又从 28 个重新开始累积,最大样本数仍然为 100 个。

模型建立于 LINUX 版 MATLAB2008Ra 计算平台,该平台运行于 IBM X3850M2 服务器,该服务器配备 16 个 CPU 及 20 G 内存。经验证计算环境对 BP 神经网络拟合结果有一定影响,由于内存分配等原因,运行于 LINUX 版拟合结果好于运行于 WINDOWS 结果。

2.3 BP 神经网络模型拟合预报

受观测制约, BP 神经网络模型拟合预报从 2008 年 7 月 7 日开始,初始样本数 28 个。预报时长 72 小时,与多模式集成实时预报系统一致,本文截取前 24 小时作为研究对象。

作为北京夏秋季节最主要的污染物,可吸入颗粒物与臭氧受到了广泛的关注(宋宇等, 2002;

李昕等, 2003; 吴瑞霞等, 2005; 安俊岭, 2006; 隋珂珂等, 2007; Chan and Yao, 2008)。在奥运会期间也有大量针对可吸入颗粒物及臭氧的控制措施被施行。由此本文将其作为主要对象进行分析。由于臭氧与可吸入颗粒物性质上存在很大的差异,日变化规律及污染类型也截然不同,臭氧为二次污染物,具有明显的日变化,可吸入颗粒物是一次污染物,日变化不明显,使用 BP 神经网络模型对其分别进行拟合分析更能说明 BP 神经网络模型的拟合效果及适用性。由于观测限制,本文使用 PM_{2.5} 代表可吸入颗粒物进行讨论。

观测站点分布如图 1b 所示,其中北京市区内站点分别位于北京大学医学部(以下简称为北医),北京大学(以下简称为北大)及中国科学院大气物理研究所(以下简称为大气所) 325 m 铁塔,由于北医位于三环以内,大气所 325 m 铁塔位于北三环到北四环之间,北大位于北四环以外。北医与北大观测资料较好而大气所 325 米铁塔由于仪器损坏造成部分物种观测缺失。基于地理位置及观测结果的考虑,本文将北医作为主要分析站点。

3 结果与讨论

3.1 BP 神经网络模型拟合预报结果

3.1.1 O₃ 拟合预报结果

使用 BP 神经网络模型完成 2008 年 7 月 7 日~8 月 26 日北医站点 O₃ 拟合预报,剔除由于模式故障及观测缺测导致日输出结果数目低于 6 个的部分,将结果整理为如图 3。为了方便区别本文将多模式集合实时预报系统多模式平均值简称为模拟值,将 BP 神经网络模型拟合预报值称为拟合值。

如图 3a 所示,与模拟值相比,拟合值在趋势与量级上都更接近与观测结果,模拟值在 7 月 25 日之前效果较差,而后半段时间效果明显改善,这是因为 7 月 20 日北京采取更严厉的车辆限行措施,系统排放源随之进行调整,调整后的排放源与实际情况更为接近的原因。但拟合值始终维持一个较高的水平。为了阐述不同模拟效果情况下 BP 神经网络模型对整个预报结果的作用。本文将整个模拟时间划分为两部分,7 月 7~24 日为第一部分,简称为时段 1,在此时段内模拟值与观测值存在较




图 3 北医 O₃拟合预报结果：(a) 日均值；(b) 日峰值
Fig. 3 The results of O₃ in Peking University Health Science Center: (a) Daily average; (b) daily maximum

表 2 北医 O₃日均值分时段统计结果
Table 2 The statistics of O₃ on daily average in Peking University Health Science Center

	时段 1		时段 2		全时段	
	平均误差 (ppb)	相关系数	平均误差 (ppb)	相关系数	平均误差 (ppb)	相关系数
神经网络拟合值	8.3	0.75	13.1	0.61	11.5	0.63
多模式平均值	22.8	0.54	11.8	0.54	15.6	0.31

大差距，7 月 25 日~8 月 26 日为第二部分，简称为时段 2，在此时段内模拟值与观测值符合较好。将北医 O₃ 日均值分时段统计结果整理如表 2。

在全时段内，观测平均值为 41.5 ppb (10^{-9})，模拟值平均误差为 15.6 ppb，平均误差率为 37.5%，相关系数为 0.31，而经过 BP 神经网络训练拟合以后拟合值的平均误差减少到 11.5 ppb，平均误差率减少 10%，相关系数提高了一倍多，达到 0.63。分时段结果中，前半时间段观测平均值为 41.9 ppb，此时段模拟效果较差，模拟值平均误差达到 22.8 ppb，误差率 54.5%，但 BP 神经网络对预报效果提升明显，与模拟值相比拟合值平均误差减少了将近三分之二，平均误差率减少达 34.7%，相关系数也从 0.54 提高到 0.75，但是后半时段 BP 神经网络拟合效果不太明显，拟合值平均误差甚至还低于模拟值。这说明了 BP 神经网络更适合模式模拟效果较差的情况，在模拟效果达到一定程度以后，BP 神经网络对预报提升不明显，甚至最终拟合结果还可能反比模拟效果差。

在臭氧日峰值结果中（图 3b），模式输出值

系统性偏低。时段 1 日均值模拟较差的时候，模拟值平均偏低 50 ppb；时段 2 日均值模拟效果较好的时候，模式值仍然平均偏低 18 ppb。拟合值并没有出现这样的系统性偏差，时段 1 拟合值平均偏高 9.8 ppb，时段 2 拟合值平均偏高 2.3 ppb，与模拟结果相比偏差值大大降低，这说明使用 BP 神经网络模型来修正系统性偏差是可行且有效的。

3.1.2 PM_{2.5} 拟合预报结果

作为化学活性较弱的一次污染物，PM_{2.5}（大气中直径小于 2.5 μm 的颗粒物）浓度提升是一个逐渐累积的过程，日变化并不明显。在图 4 中直接体现为日均值与日峰值趋势非常相近。其中观测值日均值与日峰值的相关系数为 0.90，模拟结果日均值与日峰值相关系数达 0.91，而拟合结果日均值与日峰值相关系数仅 0.61，与观测值相差较大。这可能是因为模拟值能反应现实物理化学过程，而拟合值只具有统计意义的关系。

排放源更新也影响到了 PM_{2.5} 的模拟效果，同样以 7 月 25 日 00 时为分界线将整个模拟时间划分为时段 1 与时段 2，如图 4a 所示，PM_{2.5} 模




图4 北医PM2.5拟合预报结果：(a)日均值；(b)日峰值

Fig. 4 The result of PM2.5 in Peking University Health Science Center: (a) Daily average; (b) daily maximum

拟结果在前半段时间较差，而在后半段时间模拟效果稍有提升。将北医PM2.5日均值分时段统计结果整理如表3所示。

表3 北医PM2.5日均值分时段统计结果

Table 3 The statistics of PM2.5 on daily average in Peking University Health Science Center $\mu\text{g} \cdot \text{m}^{-3}$

	平均误差		
	时段1	时段2	全时段
神经网络拟合值	26.7	20.4	22.5
多模式平均值	61.2	43	49.3

与O₃相比，PM2.5模拟效果较差，全时段平均误差达49.3 $\mu\text{g} \cdot \text{m}^{-3}$ ，但同时神经网络与预报提升效果明显，全时段拟合值平均误差减少到了22.5 $\mu\text{g} \cdot \text{m}^{-3}$ 。与O₃结果不同的是，在时段2模拟效果提升的同时拟合效果也提高了。这说明在模拟较差的时候，模拟效果一定程度的提高可能会有利于拟合效果的提高。

3.2 样本数实验

本文BP神经网络模型的目的是为了寻找模拟结果与观测值之间的映射关系，样本状况直接决定了这种通过BP神经网络寻找出的映射关系是否合理，是否对下一时刻的预报有积极意义。因为本文所用样本数较少，其代表性值得怀疑，所以在此重新设定关于样本数的敏感性试验，讨论样本数目对拟合结果的影响，并期望找出最佳样本设置方案。

样本数实验仍以北医站点O₃与PM2.5为研究对象，不采用前文所述两段法选取样本，设定样本数分别为50、100、150、200、300、500以及极大值。所有实验情景都从7月7日开始，初始样本数为28个，随着时间进行样本数逐渐增加，直到各个实验情景所限定的数目。而后保持样本数目不变，取最接近拟合预报日期的模式结果作为样本继续进行拟合预报，对比整个模拟期间日均值结果，实验结果整理如表4。

表4 BP神经网络模型样本数实验结果

Table 4 The results of samples test in BP model

	O ₃ 模拟与观测相关系数	O ₃ 平均误差(ppb)	PM2.5 模拟与观测相关系数	PM2.5 平均误差/ $\mu\text{g} \cdot \text{m}^{-3}$
50 样本	0.38	14.3	0.74	22.5
100 样本	0.44	14.9	0.56	27.7
150 样本	0.49	14.0	0.68	25.8
200 样本	0.39	14.4	0.64	27.5
300 样本	0.46	12.1	0.68	26.8
500 样本	0.43	12.7	0.6	28.4
样本数量多	0.54	11.7	0.68	27.4
两段法样本	0.63	11.5	0.75	22.5
多模式平均值	0.31	15.6	0.18	29.3

如表4所示，各个样本数条件下拟合结果都优于模式模拟结果。在O₃的拟合结果中，样本数极大的情况下，拟合效果达到最佳，平均误差最低，相关系数最高。但拟合效果与样本数并没有单一的线性关系，所有样本数对应的拟合结果处

于平均误差 14.9~11.7 ppb, 相关系数 0.38 到 0.54 之间, 变化范围相对较小。而与之相反, PM_{2.5} 拟合结果中, 样本数最小的时候拟合效果最好, 但拟合效果与样本数同样也没有单一的线性关系。

本文所采用的模式模拟结果中存在排放源调整的情况, 在排放源调整的过程中, 模式模拟效果不可避免的会发生改变, 模拟结果与观测值之间的映射关系也会发生改变。这也就是前文所述两段法挑选样本得到的结果优于所有实验结果的原因。实验中的挑选方法不可避免会出现不同排放源情况下的模拟结果同处于一组样本中的情况, 这势必会影响最终拟合效果。

因此样本数目多少并不是决定拟合效果的决定性因素。选取拥有稳定映射关系, 高质量的样本才是提高拟合预报效果的关键。

4 结论

(1) 本文将 BP 神经网络模型引入到奥运会空气质量预报中, 利用神经网络模型建立起多模式集成实时预报系统输出结果与观测结果之间的非线性映射关系, 取得了较好的结果。与模式输出结果相比, BP 神经网络模型拟合结果与观测值更加接近, 降低了平均误差, 提高了相关系数。

(2) 在模式模拟效果较差的情况下, BP 神经网络提升预报效果更加明显。

(3) 样本选取直接关系拟合效果好坏, 但样本数目多少并不是决定拟合效果的决定性因素。选取具有稳定映射关系的样本才是提高拟合预报效果的关键。

(4) 由于运行平台一致, BP 神经网络模型可以作为多模式集成实时预报系统有益的补充集成到系统中去, 在高时效观测数据的支持下有力提高预报效果。

参考文献 (References)

安俊岭. 2006. 北京近交通主干线地区的臭氧生成效率 [J]. 环境科学学报, 26 (4): 652-657. An Junling. 2006. Ozone production efficiency in Beijing area with high NO_x emission [J]. Acta Scientiae Circumstantiae (in Chinese), 26 (4): 652-657.

Chan C K, Yao X. 2008. Air pollution in mega cities in China [J]. Atmos. Environ., 42 (1): 1-42.

Grell G A, Dudhia J, Stauffer D R, et al. 1995. A Description of the Fifth-generation Penn State/NCAR Mesoscale Model; MM5 [R]. NCAR Tech. Note NCAR/TN-398+STR, 122pp.

李昕, 安俊琳, 王跃思, 等. 2003. 北京气象塔夏季大气臭氧观测研究 [J]. 中国环境科学, 23 (4): 353-357. Li Xin, An Junlin, Wang Yuesi, et al. 2003. Studies on the measurement of atmospheric ozone in summer with Beijing meteorological [J]. China Environmental Science (in Chinese), 23 (4): 353-357.

刘罡, 李昕, 胡非. 2000. 大气污染物浓度的神经网络预报 [J]. 中国环境科学, 20 (5): 429-431. Liu Gang, Li Xin, Hu Fei, et al. 2000. Prediction of atmospheric pollution concentration using artificial neural network [J]. China Environmental Science (in Chinese), 20 (5): 429-431.

宋宇, 唐孝炎, 张远航, 等. 2002. 夏季持续高温天气对北京市大气细粒子 (PM_{2.5}) 的影响 [J]. 环境科学, 23 (4): 33-36. Song Yu, Fang Xiaoyan, Zhang Yuanhang, et al. 2002. Effects on fine particles by the continued high temperature weather in Beijing [J]. Environmental Science (in Chinese), 23 (4): 33-36.

隋珂珂, 王自发, 杨军, 等. 2007. 北京 PM₁₀ 持续污染及其常规气象要素的关系 [J]. 环境科学研究, 20 (6): 77-82. Sui Keke, Wang Zifa, Yang Jun, et al. 2007. Beijing persistent PM₁₀ pollution and its relationship with general meteorological features [J]. Research of Environmental Sciences (in Chinese), 20 (6): 77-82.

王俭, 胡筱敏, 郑龙熙, 等. 2002. 基于 BP 模型的大气污染预报方法的研究 [J]. 环境科学研究, 15 (5): 62-64. Wang Jian, Hu Xiaomin, Zheng Longxi, et al. 2002. Study on forecasting of air pollution based on BP model [J]. Research of Environmental Sciences (in Chinese), 15 (5): 62-64.

王自发, 谢付莹, 王喜全, 等. 2006. 嵌套网格空气质量预报模式系统的发展与应用 [J]. 大气科学, 30 (5): 778-790. Wang Zif, Xie Fuying, Wang Xiquan, et al. 2006. Development and application of nested air quality prediction modeling system [J]. Chinese Journal of Atmospheric Sciences (in Chinese), 30 (5): 778-790.

吴瑞霞, 浦一芬, 张美根, 等. 2005. 北京市夏季臭氧变化特征的观测研究 [J]. 南京气象学院学报, 28 (5): 690-694. Wu Ruixia, Pu Yifen, Zhang Meigen, et al. 2005. Analysis of O₃ vertical variation in summer in Beijing area [J]. Journal of Nanjing Institute of Meteorology (in Chinese), 28 (5): 690-694.

于文革, 王体健, 杨诚, 等. 2008. PCA-BP 神经网络在 SO₂ 浓度预报中的应用 [J]. 气象, 34 (6): 97-101. Yu Wenge, Wang Tijian, Yang Cheng, et al. 2008. Application of PCA-BP neural network to SO₂ concentration forecast [J]. Meteorology Monthly (in Chinese), 34 (6): 97-101.