

DOI: 10.13382/j.jemi.2017.01.007

# 利用 RBF 网络的火电厂氮氧化物浓度检测方法\*

严玥<sup>1</sup> 江贇<sup>1</sup> 严实<sup>2</sup>

(1. 重庆工商大学 检测控制集成系统重庆市市级工程实验室 重庆 400067;

2. 重庆川仪分析仪器有限公司 重庆 400060)

**摘要:**火电厂排放气体中的氮氧化物( $\text{NO}_2$ 、 $\text{NO}$ 、 $\text{N}_2\text{O}$ 等)浓度一直是环保检测的重要指标。针对基于光谱分析的氮氧化物浓度检测精度受到多种因素制约和干扰(如温度、粉尘、水分、电器噪音、光学镜片老化、多组分气体吸收峰值交叉干扰等),很难采用单一方法进行改进的问题。首先设计硬件预处理装置用于气体组分的过滤和提纯,然后利用构建的径向基函数(RBF)网络对传感器测试值进行校正。RBF神经网络的自学习自训练能力省去了传统的对干扰因素进行补偿的研究建模,使得检测中数据处理工作效率更高。随机抽取国内某大型火电厂2015年实际数据进行仿真实验以及预测、分析,综合平均相对误差为0.841%,表明方法的有效性。

**关键词:**氮氧化物;浓度检测;干扰;神经网络

**中图分类号:** TP212.2; TN911.72 **文献标识码:** A **国家标准学科分类代码:** 510.40

## Detection method of $\text{NO}_x$ concentration in coal fired power plant using RBF network

Yan Yue<sup>1</sup> Jiang Yun<sup>1</sup> Yan Shi<sup>2</sup>

(1. Chongqing Engineering Laboratory for Detection, Control and Integrated System, Chongqing Technology and Business University, Chongqing 400067, China; 2. Chongqing Chuanyi Analyzer Co. Ltd., Chongqing 400060, China)

**Abstract:** The concentration of nitrogen oxides ( $\text{NO}_2$ ,  $\text{NO}$ ,  $\text{N}_2\text{O}$ , etc.) in power plant is an important index of environmental protection. Aiming at the problem that the detection accuracy of nitrogen oxides concentration based on spectral analysis could be interfered by all kinds of factors, such as temperature, moisture content, tar, naphthalene, noise of electric devices, optical lens aging, interference at spectral absorption characteristics of polluting gases etc, it is difficult to improve in a single way. At first, the hardware modification is favorable for gas purification and filter. And then, the self-learning and self-training ability of RBF neural network can save the traditional model for the study of interference factors, and make the data processing more efficient. On the basis of a large thermal power plant's real data in 2015, the computer simulation and analysis show that this method can improve the accuracy effectively. The overall-average deviation is 0.841%.

**Keywords:** nitrogen oxides; concentration detection; interferes; neural network

## 1 引言

工业废气排放检测中多组分气体分析一直以来是气体浓度检测仪的主要发展方向。以火电厂排放尾气为例,需要检测的气体主要有氮氧化物( $\text{NO}_2$ 、 $\text{NO}$ 、 $\text{N}_2\text{O}$ )、

$\text{SO}_2$  以及  $\text{CO}$ 、 $\text{CO}_2$  等,目前基于多通道光谱分析技术和积分吸收光谱算法,能够同时测量多组分气体的浓度,被广泛应用于烟气排放连续监测系统、工业过程气体分析系统。而现实环境中基于光谱分析的微量气体浓度检测受到很多不确定因素的影响:多组分气体吸收峰值交叉干扰、光源衰减、光学镜片污染、电子元器件敏感范围、

NO 传感器的零点漂移,以及环境温度、气压(大气压以及烟气压力)、焦油、苯萘以及水分和微细颗粒物干扰、电子器件不可避免的电器噪音,因此很难以某一单一方法(比如插值法和最小二乘法等)提高检测精度。

近年来将人工神经网络,如误差反向传播(error back propagation, BP)神经网络、径向基函数(radial basis function, RBF)神经网络<sup>[1-3]</sup>、粒子群优化算法<sup>[4]</sup>、语义分析等引入到分析仪中的非线性补偿、温度补偿、各种误差校正中,文献[5]中利用 L-M 算法建立的 BP 神经网络模型,用于微量药品动态称重系统中称重传感器的非线性特性的有效校正是对压力传感器的非线性校正;谢宇等人<sup>[6]</sup>确定了即便是在灵敏度较高的电阻应变式称重传感器中同样可以利用神经网络 PID 控制颗粒物料称量系统;文献[7]中也给出了 BP 神经网络和遗传算法相结合,根据具体应用环境改变 BP 神经网络中的适应度函数以提供系统判别精度的方法。这些研究充分证明了神经网络在提高仪器检测精度以及结构设计上的有效性。但这些研究在多组分气体分析、气体样本归一化、干扰因素分析和处理、产品工程化等方向上还有很大的研究空间。从算法的发展来看,为了能更好地逼近复杂非线性函数,克服网络权值巨大、初始值以及学习率不易确定、避免陷入局部最优解等 BP 神经网络存在的问题,层叠降噪自动编码器<sup>[8]</sup>、DBN<sup>[9]</sup>、DCN<sup>[10]</sup>等深度学习模型被陆续提出。

本文针对火电厂排放中氮氧化物浓度检测不再一味追求仪器最小量程,在现有仪器电子元器件敏感范围的基础上,首先采用预处理硬件装置提高仪器进气质量,然后进一步用 RBF 神经网络对数据进行校正。文中以实际火电厂工业排放数据为训练样本,根据拟合过程中的系统响应时间以及目标误差,确定最佳的中心宽度以及网络结构,完成网络训练。然后模拟实际工业环境中浓度范围,设置测试数据进行计算机仿真,以相对误差、绝对误差、响应时间以及数据量等因素分析其有效性。

## 2 实验说明

### 2.1 现状分析及解决方案提出

目前大中型火力发电厂排放烟囱高度为 180 ~ 210 m,样气采集高度 90 m,从施工安置及成本考虑通常采用单一传感器测量经转换后的 NO 浓度(通过高温催化还原方式将 NO<sub>2</sub> 等转换为 NO)作为氮氧化物浓度总量,常见监测精度一般只能控制在 1%。

由于火电厂整个工艺实际操作流程不能完全稳定(比如煤炭质量、燃烧温度以及为达到产品质量而进行的其他工艺流程控制等),导致样气(被检测气体)的压力(大气压以及烟气压力)、焦油、苯萘以及水分和微细颗粒物、温度以及气体流速都不相同。要想提高精度就必

须要尽可能确保样气各项指标在进入仪器前稳定一致以避免上述干扰。因此需要改进现有简单样气除尘过滤装置,设计预处理装置对排放气体进行预处理,严格控制进入气体分析检测单元的样气相关参数指标。

经过预处理装置的样气仍然无法避免光源衰减、光学镜片污染、电器噪音等干扰,特别是因水分吸收峰值连续导致多组分气体吸收峰值交叉干扰(火电厂排放废气水分含量通常为 13% ~ 15%,经过本文预处理装置处理后为 0.8%,现实工业环境无法做到零水分)。由于干扰因素多且复杂,很难完成单一数学建模,因此设计一个 RBF 网络对仪器测试数据进行进一步校正,以达到进一步提高数据精度的目的。

### 2.2 分析仪器说明

以川仪 P200-UV 为分析检测单元。其仪器的样气相关主要参数指标:线性误差不超过  $\pm 2\%$  FS(满量程);重复性误差不大于 1%;输出波动不大于 1% FS;当测量氮氧化物时,零点、量程漂移不超过 5%。样气不得含有高腐蚀性的气体成分,如氯(Cl<sub>2</sub>)和氯化氢(HCl)气体或气溶胶。仪器气体分析单元结构如图 1 所示。




图 1 P200-UV 仪器结构

Fig. 1 Structure of P200-UV

### 2.3 实验样本数据及实验模型建立流程

将预处理装置及分析检测单元进行成套设计后置于国内某大型火力发电厂排放烟囱,从 2015 年 1 月在线实时监测系统监测数据中随机抽取 150 个数据样本。经过 RBF 网络的学习、训练以后,确定 RBF 网络,最终完成整个实验模型的建立。RBF 神经网络的自学习自训练能力省去了传统的对干扰因素进行补偿的研究建模的过程,使得检测中数据处理速度更快,并且由于所涉及的硬件单一,更容易被工程化,可直接用于现有分析仪器结构改造。

为了使实验模型性能分析结果更具实用性,根据国家 GB13223-2011 火电厂大气污染物排放标准以及发改委和环境保护部对火电厂大气污染物排放新标准、大气常见气体浓度范围以及传感器敏感范围,取氮氧化物浓

度范围为  $10 \sim 35 \text{ mg/m}^3$ , 在此范围内按均匀分布方法取 20 个测试点配置测试气体(其他可能影响检测精度的性能指标: 温度在  $3 \sim 50 \text{ }^\circ\text{C}$ ; 水分含量  $8\% \sim 15\%$ ;  $\text{SO}_2$  浓度  $< 35 \text{ mg/m}^3$ ;  $\text{O}_2$  含量  $4\% \sim 8\%$ ,  $\text{NO}_2$  浓度  $< 50 \text{ mg/m}^3$ ), 输入训练好了的实验模型进行预测, 以此作为性能比较分析依据。

### 3 实验模型设计

#### 3.1 预处理装置设计

通常情况下, 为了提高神经网络的训练效率, 减少训练时间, 需要对样本数据进行归一化处理, 较为经典的做法是最大最小分法, 近年来也将粗糙集理论用于样本归一化<sup>[11-12]</sup>。但这种设计必然导致硬件设计复杂度以及产品成本增加。另外现实环境中面临的是多组分气体的测试, 对应气体浓度区间范围不一, 如果对每种气体都分别设计归一化处理, 势必延长检测周期, 浪费硬件成本。因此设计预处理装置完成样本预处理, 如图 2 和 3 所示。




图 2 预处理装置内部结构

Fig. 2 Internal structure of preprocessing device



图 3 预处理装置实物

Fig. 3 The photo of preprocessing device

其基本处理过程可以描述为样气由抽气泵吸入, 先

经冷凝器降温, 继而通过气路切换阀进入过滤器完成粉尘过滤, 经流量调节单元进行流量调节。预处理装置的样气能达到分析仪器对温度、压力、流量、洁净度等技术指标的需要, 预处理完成后的样气方可进入气体分析单元完成气体浓度检测, 在预处理装置中设有专门入口口方便第 3 方标准气体对仪器进行精度检验以及废水出口。样气经预处理装置处理后, 前后相关性能参数如表 1 所示。

表 1 经预处理装置后样气相关指标对比

Table 1 Contrast of correlation index of sample gas through preprocessing device

	预处理装置前常见范围	预处理装置处理后
样气气压	$-1\ 000 \sim 1\ 000 \text{ Pa}$	$-500 \sim 1\ 000 \text{ Pa}$
样气温度	$40 \sim 50 \text{ }^\circ\text{C}$	$3 \sim 5 \text{ }^\circ\text{C}$
粉尘颗粒直径	$< 10 \text{ }\mu\text{m}$	$< 0.5 \text{ }\mu\text{m}$
样气流量 <sup>a)</sup>	-	$40 \sim 60 \text{ L/H}$
样气水分含量	$13\% \sim 15\%$	$0.8\%$

a) 样气可由预处理装置中抽气泵吸入, 其流量可以保证达到需要

其优势在于样气进入分析仪器之前进行处理: 如泄压、降温、除尘、降速等, 以保证样气达到分析仪器单元要求的敏感范围, 可达到保护仪器核心测试部件的作用; 另外对样气进行一次性预处理以后, 能够被用于多种气体, 甚至于多种不同的检测原理的气体检测中, 从而确保气体分析仪的成本; 另外硬件降噪的稳定性以及适用范围也高于软件方法。

#### 3.2 RBF 神经网络设计

已经证实, 只要能够确保 BP 神经网络中的隐藏层神经单元的数量足够多, 采用 2002 年 Hinton 提出的受限波尔兹曼机(restricted Boltzmann machines, RBM) 就能拟合任意离散分布, 其在识别与去噪、回归、分类等领域已经得到了相当广泛的运用<sup>[13-14]</sup>。但 BP 神经网络初始值的选取、隐藏层层数和学习率对 BP 神经网络的性能都有比较深刻的影响<sup>[15]</sup>, 因此其结构很大程度上取决于经验, 从而给其硬件实现增加了不少难度。在此基础上的 RBF 神经网络在非线性连续函数上的一致逼近性能的在仪器仪表相关很多领域中都有很广泛的应用价值<sup>[16-17]</sup>。本文的基本原理: 通过 RBF 神经网络, 能够逼近任意非线性函数进行补充的原理, 以实际工业环境中的数据为输入, 建立稳定的 RBF 神经网络结构, 使经过神经网络补偿后的氮氧化物检测精度更高。

本文中采用 RBF 网络其相关的主要设计如下。

1) 学习算法, 自组织选取中心算法, 采用模糊  $K$  均

值聚类算法确定径向基函数中心。

2) 以高斯径向基函数为基函数,如下:

$$R_i(x) = \exp\left(-\frac{1}{2}\left(\frac{x - C_i}{\sigma_i}\right)^2\right) \quad i = 1, 2, 3, \dots, n \quad (1)$$

式中:  $C_i$  为第  $i$  个隐含层节点的中心向量,  $\sigma_i$  为对应的第  $i$  个径向基函数的宽度。其定义如下:

$$\sigma_i = \frac{C_{\max}}{\sqrt{2}h} \quad i = 1, 2, 3, \dots, n \quad (2)$$

3) 采用最小二乘法得到隐含层和输出层之间的权值。

4) 输出层神经元的激发函数采用较为简单的线性函数,如下:

$$f_k(x) = \sum_{i=1}^M \omega_{ki} R_i(x) \quad i = 1, 2, 3, \dots, n \quad (3)$$

5) 样本数据,待测气体经过预处理装置处理后,不再进行归一化。

6) 采用批处理方式进行训练。

7) 由于 RBF 网络本身具有很好的训练效率,训练次数设定不宜过多,定为 200 次。

8) 学习率设定为 2。

9) 以均方误差 (MSE)、绝对误差以及相对误差作为性能分析依据。

### 3.3 神经网络实验过程

根据 RBF 网络特性,输入的节点数为输入向量  $x$  的维数  $m$ 。由于实际检测环境的复杂性,根本无法得到训练数据当时影响测试结果的其他因素的具体值(比如当时的气温和粉尘颗粒含量)。但经过预处理装置的待测气体尽可能地排除了上述干扰,因此不但增加了浓度检测的准确性,同时也降低了 RBF 网络输入量和训练时间。更具有工程化推广的价值。

$K$  均值聚类算法确定中心位置是实验的关键。样本与聚类中心的距离采用如式(4)计算。

$$i(x_k) = \arg \min \|x_k - t_i(n)\| \quad (4)$$

式中:  $x_k$  为训练数据中随机抽取的训练样本,  $t_i(n)$  为第  $n$  次迭代的第  $i$  个聚类中心。算法的基本流程就是要通过不断地迭代计算样本与聚类中心的距离,更新聚类中心的值,一直到聚类中心不再变化为止。

## 4 实验数据处理与性能分析

### 4.1 网络训练性能分析

根据实际测试气体浓度范围以及行业相关标准,设定期望值样本目标误差值为 0.001。仿真实验后的 RBF 神经网络的误差性能曲线如图 4 所示。通过该曲线可以看出,神经网络体现出了较好的收敛性,结合图

5 可以看出,神经网络的稳定性较好,随步数的增加,误差稳定递减,当步数达 9 时, MSE 达到 0.001。远小于事先假定的 200 次。另外,使用同一批训练数据样本,分别设定 goal 标量(MSE)为 0.005 以及 0.01 时,达到目标量所需要的训练步数分别为 6 次和 4 次。在同一型号计算机仿真时,时间消耗分别为 MSE 值 0.001 的 86.0% 以及 74%。也就是说,牺牲误差精度,并没有使神经网络的训练时间大幅度降低。由此可见,RBF 神经网络对氮氧化物浓度的预测效果较好,且性能相对稳定。




图 4 误差性能曲线

Fig. 4 Error performance curve

NEWRB, neurons = 0, MSE = 0.32021
NEWRB, neurons = 2, MSE = 0.24329
NEWRB, neurons = 3, MSE = 0.0567665
NEWRB, neurons = 4, MSE = 0.00681144
NEWRB, neurons = 5, MSE = 0.00570639
NEWRB, neurons = 6, MSE = 0.00478988
NEWRB, neurons = 7, MSE = 0.00409607
NEWRB, neurons = 8, MSE = 0.0018648
NEWRB, neurons = 9, MSE = 0.000303293
NEWRB, neurons = 10, MSE = 0.000147457
NEWRB, neurons = 11, MSE = 9.87403e-005

图 5 网络训练过程

Fig. 5 The networks training process

### 4.2 实验模型性能比较分析

按前述设置的 20 个测试点配置测试样气,输入训练好了的实验模型进行预测,其测试结果如表 2 所示。由表 2 可以看出,在氮氧化物的可能取值范围内,由于样气浓度增加,绝对误差值在不断增加,但实验的平均相对误差比较均匀,并没有随浓度的升高出现误差增大的情况,整体性能比较稳定,综合平均绝对误差为 0.195,综合平均相对误差为 0.841%。从而避免了采用 BP 神经网络初始值不容易选定以及容易陷入局部最优的缺陷,也同时保证了产品工程化后的性能更趋于稳定。



表2 预测误差分析

Table 2 Prediction error analysis

氮氧化物浓度范围/ ( $\text{mg} \cdot \text{m}^{-3}$ )	平均绝对误差/ ( $\text{mg} \cdot \text{m}^{-3}$ )	平均相对 误差/%
$10.0 < p < 15.05$	0.12	0.85
$15.1 < p < 19$	0.14	0.80
$19.1 < p < 25.0$	0.21	0.843
$25.1 < p < 30.0$	0.23	0.832
$30.1 < p < 35$	0.31	0.883

注: 1) 绝对误差为网络实际输出-期望输出; 2) 相对误差为(网络实际输出-期望输出)/期望输出

## 5 结 论

在分析火电厂氮氧化物浓度检测误差原因的基础上, 利用预处理装置和 RBF 神经网络算法相结合的方法, 尽可能减少各种干扰, 从而为其浓度检测提供了准确度更高的手段, 其仿真实验效果高于实际工作环境中对氮氧化物浓度分析仪的要求, 具有一定的产品化价值。

## 参考文献

- [1] CHANG Y, YAO Y, WANG B, et al. Reduced grapheneoxide mediated SnO nanocrystals for enhanced gas-sensing properties [J]. Science China: Technological Sciences, 2013, 29(2): 157-160.
- [2] 庞鸿锋, 罗飞路, 陈棣湘, 等. 磁力仪温度误差的径向基神经网络补偿模型 [J]. 仪器仪表学报, 2012, 33(3): 695-700.
- PANG H F, LUO F L, CHEN D X, et al. Temperature compensation model of fluxgate magnetometers based on RBF neural network [J]. Chinese Journal of Scientific Instrument, 2012, 33(3): 695-700.
- [3] 马占龙, 王高文, 张健, 等. 基于有限元及神经网络的磨削温度仿真预测 [J]. 电子测量与仪器学报, 2013, 27(11): 1080-1085.
- MA ZH L, WANG G W, ZHANG J, et al. Simulation and forecast of the grinding temperature based on finite element and neural network [J]. Journal of Electronic Measurement and Instrument, 2013, 27(11): 1080-1085.
- [4] 李玉军, 汤晓君, 刘君华. 粒子群优化算法在改善传感器稳定性中的应用 [J]. 仪器仪表学报, 2010, 31(8): 1756-1762.
- LI Y J, TANG X J, LIU J H. Application of particle

swarm optimization algorithm in improving the stability of sensor [J]. Chinese Journal of Scientific Instrument, 2010, 31(8): 1756-1762.

- [5] 庄育锋, 翟宇. 微量药品单元动态称重系统的设计与实现 [J]. 仪器仪表学报, 2013, 34(2): 379-386.
- ZHUANG Y F, ZHAI Y. Design and realization of microscale capsule dynamic weighing system [J]. Chinese Journal of Scientific Instrument, 2013, 34(2): 379-386.
- [6] 谢宇, 韩保红, 段云龙, 等. 基于神经网络 PID 控制的颗粒物料称量系统 [J]. 国外电子测量技术, 2013, 32(9): 15-17.
- XIE Y, HAN B H, DUAN Y L. Particles weighting system based on neural network PID [J]. Foreign Electronic Measurement Technology, 2013, 32(9): 15-17.
- [7] 江华丽. 神经网络混合算法的应用研究 [J]. 电子测量技术, 2014, 37(10): 59-61.
- JIANG H L. The research of the neural network algorithm application [J]. Electronic Measurement Technology, 2014, 37(10): 59-61.
- [8] VINCENT P, LAROCHELLE H, LAJOIE L. Stacked denoising autoencoders: learning useful representations in a deep network with a local denoising criterion [J]. Transportation Journal of Machine Learning Research, 2010, 11(12): 3371-3408.
- [9] HINTON G, SALAKHUTDINOW R. Reducing the Dimensionality of Data with Neural Networks [J]. Science, 2006, 313(5786): 504-507.
- [10] YU D, DENG L. Deep convex net: a scalable architecture for speech pattern classification [C]. Proceedings of the 12th Annual Conference of International Speech Communication Association, 2011: 2285-2288.
- [11] 毛清华, 马宏伟, 张旭辉. 改进邻域粗糙集的输送带缺陷特征约简算法 [J]. 仪器仪表学报, 2014, 35(7): 1676-1680.
- MAO Q H, MA H W, ZHANG X W. Conveyor belt defect reduction algorithm based on improved neighborhood rough sets [J]. Chinese Journal of Scientific Instrument, 2014, 35(7): 1676-1680.
- [12] 赵亮亮, 肖明清, 盛晟, 等. 基于多色集与概念格的多故障推理研究基于多色集与概念格的多故障推理研究 [J]. 仪器仪表学报, 2014, 35(12): 2690-2699.
- ZHAO L L, XIAO M Q, SHENG SH, et al. Study on reasoning of multi-failure based on polychromatic sets and concept lattice [J]. Chinese Journal of Scientific Instrument, 2014, 35(12): 2690-2699.
- [13] LAROCHELLE H, LAULY S. A neural autoregressive topic model [C]. Advances in Neural Information

Processing Systems, 2012: 2717-2725.

- [14] TANG Y, SALAKHUTDINOV R, HINTON G. Robust Boltzmann Machines for Recognition and Denoising [C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2012: 2264-2271.
- [15] 孙志军, 薛磊, 许阳明, 等. 深度学习研究综述[J]. 计算机应用研究, 2012, 29(8): 2806-2810.
- SUN ZH J, XUE L, XU Y M, et al. Overview of deep learning[J]. Application Research of Computers, 2012, 29(8): 2806-2810.
- [16] KEVIN H. Author training RBF network to tolerate single node fault [J]. Neurocomputing, 2011, 74 (6): 1046-1052.
- [17] 张琦, 潘孟春, 陈棣湘, 等. 基于线性化参数模型的三轴磁场传感器校准方法[J]. 传感技术学报, 2012, 25(2): 215-219.
- ZHANG Q, PAN M CH, CHEN D X, et al. Scalar calibration of tri-axial magnetometer with linearized parameter model [J]. Chinese Journal of Sensor and Actuators, 2012, 25(2): 215-219.


## 作者简介



**严玥**, 1976 年出生, 2005 年于重庆大学获得硕士学位, 现任重庆工商大学计算机与信息工程学院讲师。主要从事信号处理及运用、传感器技术方向研究。

E-mail: 1193173573@qq.com

**Yan Yue** was born in 1976, received M. Sc. from Chongqing University in 2005. She is now a lecturer in Chongqing Technology and Business University. Her present research interests include signal processing and application, and sensor technology.



**严实**, 1978 年出生, 2010 年于重庆大学获得硕士学位, 现任重庆川仪分析仪器有限公司高级工程师, 主要从事分析仪器仪表设计与研发。

E-mail: yanshicq@sina.com

**Yan Shi** was born in 1978, received M. Sc. from Chongqing University in 2010. He is now a senior engineer in Chongqing Chuanyi Analyzer Co. Ltd. His present research interest includes design and development of analytical instruments and meters.