

doi: 10.3969/j.issn.1005-3026.2017.06.004

神经网络预测控制在 SCR 烟气脱硝系统中应用

孟范伟¹, 徐 博², 吕晓永¹, 刘胤圻¹

(1. 东北大学秦皇岛分校 控制工程学院, 河北 秦皇岛 066004; 2. 吉林省电力科学研究院有限公司, 吉林 长春 130021)

摘 要: 以自某热电厂 350 MW 燃煤机组的选择性催化还原(SCR)反应系统所采集的数据为依托,使用神经网络预测控制方法,研究电厂尾气中氮氧化物排放的预测及控制问题. 利用神经网络的方法进行模型辨识,利用预测控制的思想对喷氨量进行控制,既可使尾气达到限排标准,亦能减少用氨量,提升经济效益的同时减少氨逃逸. 采用最速梯度方法进行控制器的优化,并通过性能函数来约束控制量,达到预期输出. 最后将仿真结果与现场所测数据进行对比,结果表明神经网络预测控制方案可以较准确地预测出未来有限时刻所需的喷氨量.

关 键 词: 选择性催化还原;神经网络;预测控制;非线性自回归算法;模型辨识

中图分类号: TP 273 **文献标志码:** A **文章编号:** 1005-3026(2017)06-0778-05

Application of Neural Network Predictive Control in SCR Flue Gas Denitration System

MENG Fan-wei¹, XU Bo², LYU Xiao-yong¹, LIU Yin-qi¹

(1. School of Control Engineering, Northeastern University at Qinhuangdao, Qinhuangdao 066004, China;
2. Jilin Electric Power Research Institute Co., Ltd., Changchun 130021, China. Corresponding author: LYU Xiao-yong, E-mail: mengfanwei@neuq.edu.cn)

Abstract: Based on the data collected from selective catalytic reduction (SCR) reaction system of a 350 MW coal-fired unit in a thermal power plant, neural network predictive control method was used to study the prediction and control of nitrogen oxides emission in power plant tail gas. Firstly, the non-linear model of SCR denitrification system was modeled and nonlinear autoregressive model was used to estimate the model. Then, by using the predictive control method to control the ammonia injection, the tail gas could achieve the standard of discharge limitation, and the amount of ammonia and ammonia escape could also be reduced, resulting in the enhancement of economic efficiency. The controller was optimized by the steepest gradient method and the control variable was constrained by the performance function to achieve the expected output. Finally, compared with the measured data in the field, the simulation results show that the neural network predictive control scheme can predict the amount of ammonia sprayed in the future at a finite time.

Key words: selective catalytic reduction (SCR); neural networks; predictive control; nonlinear auto regressive algorithm; model identification

SCR(selective catalytic reduction)——选择性催化还原法是目前技术最成熟、应用最广泛的烟气脱硝技术^[1]. 脱硝系统中,在催化剂的作用下,利用还原剂 NH₃ 有选择性地与烟气中的 NO_x 反应并生成无毒无污染的 N₂ 和 H₂O. 脱硝控制系统根据计算得出的氨气流量值来控制氨气调节

门的开度,进而实现氨气流量的自动控制.

目前电厂普遍采用 PID 控制喷氨量,当机组的负荷在稳定状态时,可取得较好的控制效果,但在变工况条件下,系统呈现出非线性、大滞后性,则难以确保最佳喷氨量. 喷氨量过少,无法保证 NO_x 排放标准;喷氨量过多,不仅造成氨的浪费,

收稿日期: 2016-10-09

基金项目: 河北省高等学校科学技术研究项目(ZD2016203); 国网吉林省电力有限公司电力科学研究院科技项目.

作者简介: 孟范伟(1981-),男,黑龙江青冈人,东北大学秦皇岛分校讲师,博士.

而且又造成新的污染. 因此采用常规的控制方式往往难以取得较好的控制效果.

SCR 喷氨系统控制方面的研究起初主要是针对现有的 PID 控制系统进行优化,如引入负荷和参数整定等^[2]. 文献[3]提出基于混合结构径向基函数网络型系数的自回归模型(RBF-ARX, radial basis function - auto-regressive with extra inputs)来预测控制喷氨量,但采用的是几个固定负荷点上的数据来建立模型,与控制系统实际运行情况存在较大偏差. 文献[4]设计了基于混结构 RBF 神经网络的喷氨流量最优控制系统,但隐含层的神经元个数选择为固定值,不能保证所选择的隐含层个数是最优值. 文献[5]将 Smith 预估器与自抗扰控制技术相结合,用于 SCR 脱硝控制系统. 文献[6]针对变工况情况,采用 SA-RBF(sensitivity analysis - radial basis function)神经网络控制方法能够精确地控制喷氨量,具有良好的适应能力. 文献[3-6]所采用的先进方法仅是与传统的 PID 进行了比较,先进控制方法明显优于 PID 控制. 而文献[7]采用先进预测控制(MPC, model predictive control)方法进行仿真分析,并且与现场实测进行了对比,结果表明 MPC 可使出口 NO_x 的波动范围变小. 预测控制技术因其对模型要求较低、易于在线计算、控制效果较好等优点,逐渐在过程控制领域得到越来越广泛的应用. 相关文献中,神经网络在预测控制中可以有 两个用途^[3-6]:一是非线性系统的神经网络建模;二是滚动优化问题的神经网络求解. 本文先通过神经网络模型辨识出 SCR 系统,然后用神经网络进行滚动优化,从而对喷氨量进行有效控制.

1 预测控制的基本方法原理

预测控制框图如图 1 所示^[8]. 图中: v 为可测扰动, r 为输出目标值, u 是控制量. d 是不可测扰动,直接作用于目标. y 是测量的输出,可以评估实际输出值的准确性与否. z 是影响测量准确性的噪声. y_r 为设定目标值, \bar{y} 是实际输出值.

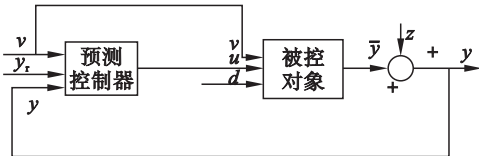


图 1 模型预测控制框架

Fig. 1 Model predictive control framework

预测控制算法首先估计系统的模型,在基于

模型的前提下,利用过程模型预测出系统在一定激励的作用下之后有限时刻内的响应. 之后,在限定条件下和惩罚函数的作用下一步一步求解最优值,将得到的当前控制量作用于系统. 通过检测实时的系统输出信息来对未来动态行为的预测进行及时修正. 预测控制可分为 3 个步骤,归结为预测模型、滚动优化和反馈校正 3 条原理^[9].

2 SCR 系统模型的建立

2.1 样本的选取

为了能给模型网络提供全面、正确反映系统特性的输入与输出数据对,采集并投入网络训练的数据应满足以下 3 点特性:遍历性、致密性和相容性^[10]. 使学习样本尽可能囊括对象可能存在的所有状态空间情况,并且在一定空间范围内的学习样本密度要合适,这样才能把对象特性采集到.

本文讨论的影响 SCR 脱硝效率的因素主要有:①入口 NO_x 浓度;②SCR 反应装置处的温度;③机组负荷(发电机有功功率);④SCR 装置喷氨量. 在电厂中上述因素通过现场监测系统可获得,测得的数据分为 A 组和 B 组. 考虑到脱硝机组是对称的,故这里只讨论 A 组情况. 输入数据如图 2 所示. 输出数据如图 3 所示.

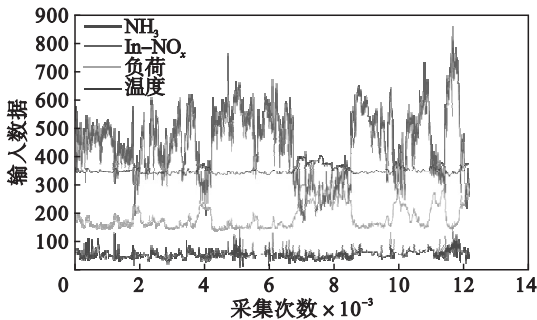


图 2 输入数据
Fig. 2 Input data

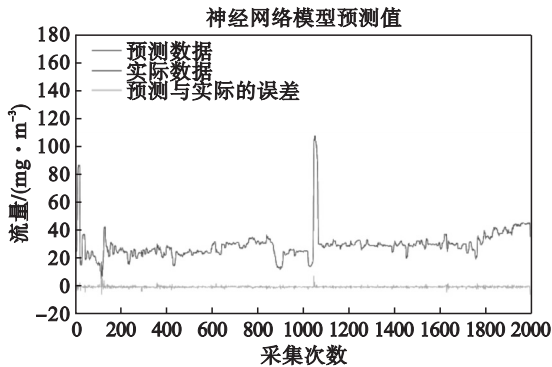


图 3 输出数据
Fig. 3 Output data

从图 3 可以看出,该输出值存在饱和现象.即当喷氨量达到一定上限时,SCR 脱硝系统输出 NO_x 浓度不再变低,即此时的喷氨量有一些是以氨逃逸的形式出去的,所以应从采集的数据中选取喷氨量相对不大的时间段数据.从图 2 中可以看出温度变化量不大,这里不再讨论.这里将采用动态神经网络,利用神经网络的无限逼近非线性性能,对 SCR 脱硝系统进行模型辨识.

2.2 训练数据的处理

由于现场存在一些高频信号,对这些数据先进行了高频滤波,得到如图 4 的输入数据和如图 5 的输出数据曲线.

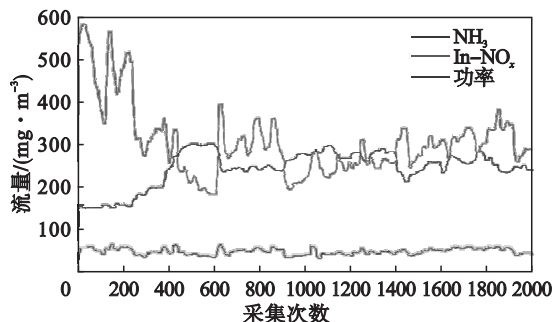


图 4 滤波后输入数据
Fig. 4 Filtered input data

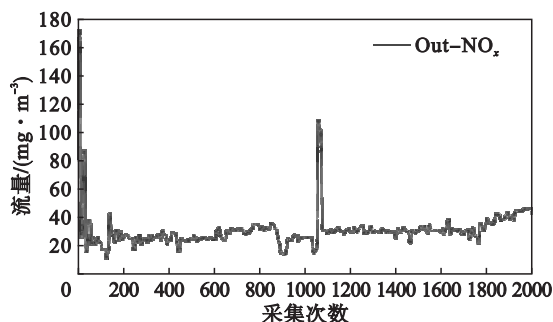


图 5 滤波后输出数据
Fig. 5 Filtered output data

2.3 模型辨识

BP 学习算法的性能评价函数是均方误差.不断地将网络输出与实际输出作比较,然后每走一步就检查偏离目标轨迹的程度.再在基于当前位置的情况下,调整下一步的行动方向.对于每个输入样本,网络实际输出就与期望输出比较,最速梯度法就会调整网络权值参数的大小,这样便可减小均方误差,优化性能函数^[8].

经过多次调试,选择输入层延时为 10 个采样周期,输出延时为 2 个采样周期,隐含层个数选择 60 个,隐含层激活函数选择了非负对数 logsig(x) 函数.得到的预测仿真图与实际比较如图 6 所示.由图 6 可知预测相对较准确,均方差为 0.755 3,

在数据跳跃较大处误差偏离会稍大,但仍然属于允许范围.为了进一步对网络模型进行分析,作出了线性回归曲线,如图 7 所示.

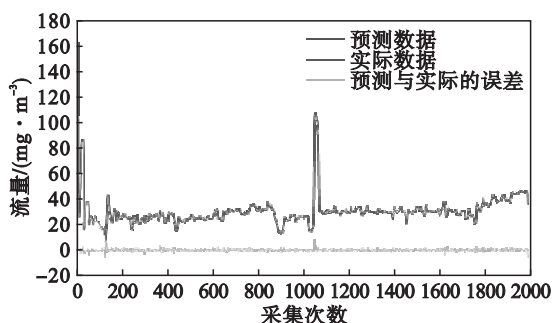


图 6 预测与实测对比

Fig. 6 Comparison between forecast and actual measurement

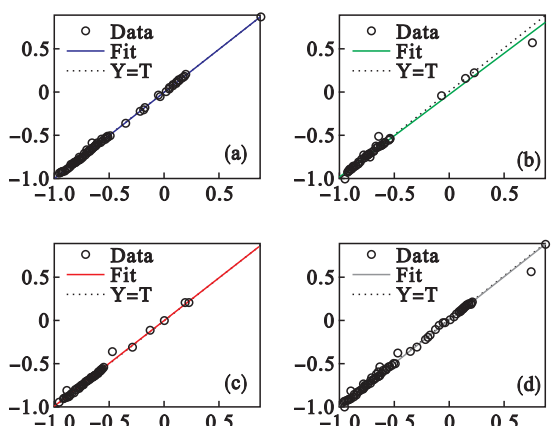


图 7 预测与实测线性回归性

Fig. 7 Predictive and measured linear regression

(a)—训练: $R=0.998\ 13$; (b)—验证: $R=0.993\ 60$;
(c)—测试: $R=0.994\ 99$; (d)—总体: $R=0.996\ 88$.

由图 7 可知,对于训练数据、测试数据、校验数据,其神经网络预测数据与实际数据的相似度都在 0.99 以上,整体相似度达到 0.996. 可知相似度较好.

3 神经网络预测控制

在预测控制作用中,为了实现对未来输出进行多步预测,在文献中已出现了多种方法^[11]. 其中的一种方法是当控制时域为 P 步时,就根据时间顺序建立 P 个网络,其中隐含层采用 Sigmoid 函数(神经元的作用函数),即

$$\varphi(x) = \frac{1}{1 + \exp(-\beta x)}, \beta > 0.$$

则第 s 个 BP 网络可表示为

BP _{s} :

$$x_i^s = w_{i0}^s + \sum_{j=1}^{n_b} w_{ij}^s u(k + s - j) +$$

$$\sum_{j=1}^{n_a} w_{i,j+n_b}^s y(k+s-j), z_i^s = \varphi(x_i^s),$$

$$\hat{y}(k+s) = w_0^s + \sum_{i=1}^m w_i^s z_i^s, s=1, \dots, P. \quad (1)$$

其中:角标 s 表示第 s 个 BP 网络; x_i 为第 i 个隐节点的输入,对应的输出为 z_i ; w_{ij}^s 表示输入节点 j 到隐节点 i 的连接权系数; w_0^s 表示隐节点 i 的输入偏移值; w_0^s 为输入节点的输入偏移值. 这 P 个网络的工作原理相同,都是采用非线性自回归原理建立的. 不同之处在于它们的输入量在时间上是相继错开的,这样便能使网络输出反映未来不同时刻的输出预测值. 而且这些网络在学习过程和实时预测都可以并行进行,因此该方法可行,且十分有效^[12-13].

2.3 节得到了 SCR 的预测模型,从而得到了输入输出的映射关系. 现在讨论其预测控制问题. 根据预测控制的基本思路,可以把神经网络的预测控制思路用图 8 表示.

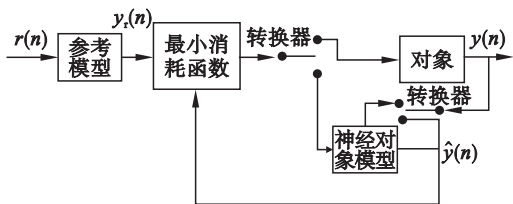


图8 神经网络预测控制框图

Fig. 8 Neural network predictive control block diagram

在图 8 中,通过不断向前求解代价函数的最小值. 在每一时刻,求解一个非线性优化问题,得到下一个控制作用量,以此类推,得到整个想要的控制域. 2.3 节中建立的神经网络模型,在这里有两个作用,一是作为预测模型,二是其逆映射可以作为一个性能函数 $J(k)$ 的优化根据,具体过程如下. 其中在时刻 k 的优化性能指标 $J(k)$ 可表示为

$$\min J(k) = \frac{1}{2} \sum_{h=1}^P (\hat{y}(k+h) - y_r(k+h))^2. \quad (2)$$

式中: $\hat{y}(k+h)$ ($h=1, \dots, P$) 是各个 BP 预测模型的预测输出值,它们是在未来输入为 $u(k+h-1)$ ($h=1, \dots, P$) 时的输出值; $y_r(k+h)$ ($h=1, \dots, P$) 是输出期望值.

将目标性能函数对输入值 $u(k+h-1)$ ($h=1, \dots, P$) 求偏导:

$$\frac{\partial J(k)}{\partial u(k+h-1)} = \sum_{s=1}^P \left[\frac{\partial J(k)}{\partial \hat{y}(k+s)} \frac{\partial \hat{y}(k+s)}{\partial u(k+h-1)} \right]. \quad (3)$$

式中,当 $s < h$ 时 $\hat{y}(k+s)$ 与 $u(k+h-1)$ 无关,那么,可以写成

$$\frac{\partial J(k)}{\partial u(k+h-1)} = \sum_{s=h}^P \left[\frac{\partial J(k)}{\partial \hat{y}(k+s)} \frac{\partial \hat{y}(k+s)}{\partial u(k+h-1)} \right]. \quad (4)$$

式(4)中等式右侧的 $\frac{\partial J(k)}{\partial \hat{y}(k+s)}$ 根据式(2)可以得到

$$\frac{\partial J(k)}{\partial \hat{y}(k+s)} = \hat{y}(k+s) - y_r(k+s), s=1, \dots, P. \quad (5)$$

而式(4)中等式右侧的 $\frac{\partial \hat{y}(k+s)}{\partial u(k+h-1)}$ 可由式(1)求得

$$\frac{\partial \hat{y}(k+s)}{\partial u(k+h-1)} = \sum_{i=1}^m \frac{\partial \hat{y}(k+s)}{\partial z_i^s} \frac{dz_i^s}{dx_i^s} \frac{\partial x_i^s}{\partial u(k+h-1)} = \sum_{i=1}^m w_i^s z_i^s (1 - z_i^s) w_{i,s-h+1}^s. \quad (6)$$

最终有

$$\frac{\partial \hat{y}(k+s)}{\partial u(k+h-1)} = \sum_{s=h}^P \{ (\hat{y}(k+s) - y_r(k+s)) \times \sum_{i=1}^m w_i^s z_i^s (1 - z_i^s) w_{i,s-h+1}^s \}. \quad (7)$$

这样,可以初始设置一组控制量 $u_m(k)$, 利用模型(1)计算出 $\hat{y}_{PM}(k)$, 然后代入性能函数(2)算出 $J(k)$ 中的 $\hat{y} - y_r$. 在此基础上,用梯度法改进控制量:

$$u^{\text{new}}(k+h-1) = u^{\text{old}}(k+h-1) - \alpha \frac{\partial J(k)}{\partial u(k+h-1)}. \quad (8)$$

其中 α 为步长,梯度值可根据式(7)计算得到. 将这一迭代过程反复进行,一直到得到最小的 $J(k)$,这时的 $u(k)$ 便可作为最优控制量作用到系统中实施.

在基于神经网络预测控制原理的基础上,搭建了控制系统框图. 系统框图主要由三部分组成: 信号输入(即输入时间序列)、控制优化部分、SCR 脱硝系统部分. 其中输入时间序列以采集到的数据为信号; 优化部分采用梯度下降法(采用步长为 0.5),编写了一个 S 函数, S 函数主要进行出口 NO_x 浓度的优化,通过不断迭代,利用最速梯度法求得最优的喷氨量; SCR 脱硝系统由得到的神经网络模型代替. 控制方案搭建框图如图 9 所示.

搭建好系统框图后,设置仿真环境. 设置仿真时间为 50 s,仿真步长为定步长 1.0 s,每 1 s 后读取时间序列里的数据,通过时间序列的不断推进,求得 NO_x 浓度的输出.

为了得到较理想的数据, S 函数里设定的迭

