

基于 RBF 神经网络模型的臭氧浓度软测量研究

张海传*, 刘钟阳, 许东卫, 王宁会

(大连理工大学 电气工程学院, 辽宁 大连 116024)

摘要: 目前的臭氧浓度在线分析测试仪器在臭氧发生器中的应用受到很大限制. 通过监测影响臭氧产生浓度的 6 个参量, 基于 RBF 神经网络模型实现了臭氧浓度软测量. 该模型采用梯度下降法确定 RBF 基函数的中心及输出层权值, 可离线和在线校正所建立的神经网络模型. 实验证明, 软测量模型输出结果与臭氧浓度分析仪测量结果的绝对误差小于 5 g/m^3 的达 93% 以上, 绝对误差小于 1 g/m^3 的达 33% 以上, 且响应时间小于 1 s.

关键词: 臭氧浓度; 径向基函数(RBF); 神经网络; 软测量

中图分类号: TP212; TQ123 **文献标志码:** A

0 引言

臭氧(O_3)具有极强的氧化性和杀菌性能, 同时具有良好的生态环境效应, 具有其他化学氧化、杀菌剂无法比拟的优点^[1], 在医学、卫生、化工、污水处理等方面得到了广泛的应用^[2,3]. 工业用臭氧发生器主要采用放电等离子体合成的方式, 其合成过程是一个强耦合、非线性过程. 在臭氧生产及应用的工艺过程中, 臭氧浓度是一个非常重要的技术指标. 但由于臭氧浓度在线分析测试仪器不仅价格昂贵, 而且测量滞后大, 维护保养复杂, 在臭氧发生器中的应用受到很大限制. 随着臭氧发生器应用领域的不断拓展, 其臭氧浓度的在线实时、精确测量成为一个急待研究解决的问题. 文献[4]提出了应用混合 BP 神经网络的方法建立臭氧浓度的软测量模型, 但是它仅进行了简单的初期探讨, 辅助变量的选取不全面, 而且 BP 神经网络存在网络学习速度慢、容易陷入局部最小和隐含层节点个数不易确定等问题, 导致建立的软测量模型测量误差大, 不能实际应用.

RBF 神经网络^[5]结构简单, 有较快的收敛速度, 具有全局逼近的性质和最佳逼近性能, 非常适合于非线性系统的建模^[6]. 本文基于 RBF 神经网络模型实现臭氧浓度的软测量, 并对软测量模型

进行仿真实验验证, 以期对臭氧浓度的实时、在线测量提供一种很好的方法.

1 臭氧生产的工艺过程

臭氧生产的工艺流程图如图 1 所示, 主要由放电反应器、电源系统、监测系统和冷却系统组成.




图 1 臭氧生产的工艺流程图

Fig. 1 The process flow chart of the production of ozone

放电反应器由两电极以及它们之间的介质层和空隙组成, 经过放电反应器的原料气体在两个电极产生的高频高压电作用下放电合成臭氧. 电源系统经过整流、滤波、逆变、升压后产生高频高压电使放电反应器中的气体放电. 监测系统对影响臭氧发生器性能的 6 个重要参量进行监测, 包括输入功率, 原料气体的流量、温度及温升, 冷却

水的温度及温升. 由于在放电合成臭氧的过程中会产生大量的热量, 应用冷却系统对放电反应器进行散热.

2 基于 RBF 神经网络模型的臭氧浓度软测量

2.1 RBF 神经网络的结构及其算法

RBF 神经网络是只有 1 个隐含层的 3 层前馈神经网络结构, 其结构如图 2 所示.




图 2 RBF 神经网络结构

Fig. 2 Structure of RBF neural network

第 1 层是信号输入层, 由信号源节点组成; 第 2 层是隐含层, 其节点变换函数是一种局部分布的对中心点径向对称衰减的非负非线性函数; 第 3 层是输出层, 从隐含层到输出层是线性变换. 隐含层节点的变换函数可以选择很多种, 最常用的是高斯函数, 如下:

$$\phi(v) = \exp(-v^2/2\sigma^2) \quad (1)$$

其中 σ 是高斯函数的宽度.

由图 2 所示的 RBF 神经网络中有 P 个输入节点, M 个隐含层节点, 一个输出层节点, 以高斯函数为 RBF 传递函数, 则整个网络的输出可表示为

$$y = f(\mathbf{X}) = w_0 + \sum_{i=1}^M w_i \phi(\|\mathbf{X} - \mathbf{r}_i\|) \quad (2)$$

式中: $\mathbf{X}$ 表示输入向量, $\|\cdot\|$ 表示欧氏距离, w_i 是隐含层第 i 个节点与输出节点之间的权值, w_0 是输出节点的偏移量, $\mathbf{r}_i$ 是隐含层第 i 个节点的中心向量.

在隐含层加一个节点, 使此节点的输出恒等于 1, 即令 $\mathbf{r}_0 = \mathbf{X}$, 则式(2) 可写成如下形式:

$$y = f(\mathbf{X}) = \sum_{i=0}^M w_i \phi(\|\mathbf{X} - \mathbf{r}_i\|) \quad (3)$$

RBF 神经网络的关键问题是径向基函数数据中心的选取^[7] 以及输出权值的确定. 本文采用监督训练方法来确定 RBF 的中心以及网络的其

他自由参数^[8], 具体算法如下.

定义一个目标函数 ϵ , 即:

$$\epsilon = \frac{1}{2} \sum_{j=1}^N (y_j - y_j(\mathbf{X}))^2 \quad (4)$$

式中: y_j 为网络的期望输出; $y_j(\mathbf{X})$ 为当前网络的实际输出; N 为训练样本数.

对网络学习的要求是寻求网络的自由参数, 使得目标函数 ϵ 达到极小, 应用梯度下降法, 可得网络各参数的算法如下:

(1) RBF 函数数据中心算法

$$r_i(n+1) = r_i(n) - \eta_1 \frac{\partial \epsilon(n)}{\partial r_i(n)} \quad (5)$$

(2) 隐含层 - 输出层的连接权值算法

$$w_i(n+1) = w_i(n) - \eta_2 \frac{\partial \epsilon(n)}{\partial w_i(n)} \quad (6)$$

(3) 径向基函数的宽度算法

$$\sigma_i(n+1) = \sigma_i(n) - \eta_3 \frac{\partial \epsilon(n)}{\partial \sigma_i(n)} \quad (7)$$

式中: $i = 1, 2, \dots, M$, M 为隐含层神经元数目; n 表示 n 时刻; η_1, η_2, η_3 为学习速率.

2.2 臭氧浓度软测量模型

通过对臭氧产生机理及性质^[9] 的研究分析可知, 影响臭氧产生浓度的因素有很多, 但最主要的影响因素是输入功率、原料气体流量、初始温度和温升以及冷却水的初始温度和温升. 在本文中, 选择这 6 个参量作为软测量模型的输入, 臭氧发生器产生的臭氧浓度作为软测量模型的输出, 则可以得到臭氧浓度软测量模型如下:

$$C(t) = f(P(t), L(t), T_a(t), \Delta T_a(t), T_w(t), \Delta T_w(t)) \quad (8)$$

式中: $C(t)$ 表示臭氧浓度, $P(t)$ 表示臭氧发生器的输入功率, $L(t)$ 表示原料气体的流量, $T_a(t)$ 表示原料气体的初始温度, $\Delta T_a(t)$ 表示原料气体在臭氧发生器中的温升, $T_w(t)$ 表示冷却水的初始温度, $\Delta T_w(t)$ 表示冷却水在臭氧发生器中的温升. 令

$$\mathbf{X}(t) = (P(t) \ L(t) \ T_a(t) \ \Delta T_a(t) \ T_w(t) \ \Delta T_w(t))$$

则由式(3) 和(8) 可得臭氧浓度的软测量模型

$$C(t) = f(\mathbf{X}(t)) = \sum_{i=0}^M w_i \phi(\|\mathbf{X}(t) - \mathbf{r}_i\|) \quad (9)$$

2.3 软测量模型的训练和校正

建立如图 1 所示的臭氧产生试验系统, 采集建立软测量模型所需的辅助变量数据, 并对采样

数据进行异常数据剔除、滤波以及归一化处理,共采集 70 组数据作为样本数据,其中 50 组作为训练样本,其余 20 组用于模型的检验与校正。

为检验臭氧浓度软测量模型的精度,定义性能指标为

$$e_j = |y_j - y_j(\mathbf{X})|$$

(10)

其中 y_j 为第 j 个样本的实际输出, $y_j(\mathbf{X})$ 为第 j 个软测量模型的输出, e_j 为第 j 个样本实际输出与模型输出的误差绝对值。

借助 MATLAB 的 RBF 神经网络工具箱,完成基于 RBF 神经网络(RBFNN)的臭氧浓度软测量模型的建立和离线训练,应用检验数据检验已训练好的软测量模型,实际数据与模型输出数据对比结果和两者之间的绝对误差如图 3 和表 1 所示,图 3 中 n 为样本序号, C 为臭氧浓度。




图 3 RBFNN 软测量模型预测结果与校验数据对比

Fig. 3 The comparison between the prediction of RBFNN model and verifying data

表 1 RBFNN 软测量模型预测输出与校验数据误差的对比统计

Tab.1 The comparison statistics of the errors between the prediction of RBFNN model and verifying data

$e/(g \cdot m^{-3})$	数量	所占比例/%
$e \leq 1$	7	35
$1 < e \leq 2$	5	25
$2 < e \leq 3$	3	15
$3 < e \leq 5$	4	20
$e > 5$	1	5

从图 3 中可以看出,软测量模型预测的臭氧浓度能够很好地匹配检验数据,且能够准确地实时跟踪臭氧浓度的变化,在表 1 的模型预测输出与实验数据误差的对比统计中,其绝对误差绝大多数小于 5 g/m^3 ,证明了基于混合 RBF 神经网络

的臭氧浓度软测量模型是有效的,且能达到很高的精度,能够满足实际的应用要求。

软测量模型建好后并不是一成不变的,它受生产原料性质、产品需求及工作环境等因素的影响,操作点会发生相应的改变,偏离建立软测量模型时的工作点,此时的模型将产生较大的误差。本文中,每个月都对模型进行定期校正,将采样值和预测值进行比较,如果误差在允许范围内,继续使用原来的软测量模型,否则,利用新的采样数据对 RBF 神经网络软测量模型进行在线校正,使之在生产条件等变化时仍有较高的预测精度。

3 实验验证

为进一步验证基于 RBF 神经网络模型的臭氧浓度软测量技术的有效性和实用性,建立可应用于工业现场的 DBD 型臭氧发生器及其监测系统^[10]。

现场采集了 30 组数据,这些数据经过预处理后输入所建立的软测量模型,得到的输出与现场应用在原公司(Ebara Jitsugyo)的 EG-2001B 型臭氧浓度测试仪得到的结果比较如图 4 和表 2 所示。




图 4 RBFNN 软测量模型预测结果与臭氧浓度测试仪测量数据对比

Fig. 4 The comparison between the prediction of RBFNN model and the measurement data with ozone concentration monitor

表 2 RBFNN 软测量模型预测输出与臭氧浓度测试仪测量数据误差的对比统计

Tab.2 The comparison statistics of the errors between the prediction of RBFNN model and the measurement data with ozone concentration monitor

$e/(g \cdot m^{-3})$	数量	所占比例/%
$e \leq 1$	10	33.3
$1 < e \leq 2$	9	30
$2 < e \leq 3$	6	20
$3 < e \leq 5$	3	10
$e > 5$	2	6.7

4 结 语

本文介绍的臭氧浓度软测量技术基于RBF神经网络模型,采用梯度下降法确定RBF神经网络模型的数据中心和连接权值,应用预处理后的样本数据对网络模型训练和校正,最终得到的臭氧浓度软测量模型具有相当高的精度。

仿真和实验结果表明,所建立的臭氧浓度软测量模型能够很好地匹配校验数据,并能跟踪臭氧浓度的变化,其输出与臭氧浓度分析仪测量结果的绝对误差小于 5 g/m^3 的达93%以上,绝对误差小于 1 g/m^3 的达33%以上,且其响应时间小于1 s,可实时在线监测,维护方便。应用臭氧浓度软测量技术,不仅能够在线实时监测臭氧浓度,而且为整个臭氧产生及应用过程实施闭环控制提供技术支持,提高臭氧生产及应用过程的自动化水平。

参考文献:

[1] BLAICH L, FRIEDRICH M, SHADIAKHY A H. Development of ozone technology and application [C] // *Proceedings of IOA 14th Ozone World Congress (Volume1)*. Berlin: International Ozone Association, 2000:203-215

[2] BOHME A. Ozone technology of German industrial enterprise [J]. *Ozone: Science and Engineering*, 1999, **21**(2):163-176

[3] GULYAS H. Processes for the removal of recalcitrant organics from industrial wastewaters [J]. *Water Science and Technology*, 1997, **36**(2-3):9-16

[4] 刘 敏,王宁会,刘钟阳. 基于混合神经网络的臭氧浓度软测量[J]. 计算机测量与控制, 2003, **11**(9): 660-662

[5] POGGIO T, GIROSI F. Networks for approximation and learning [J]. *Proceedings of the IEEE*, 1990, **78**(9):1481-1497

[6] 全卫国,杨耀权,金秀章. 基于RBF神经网络的气体流量软测量模型研究[J]. 中国电机工程学报, 2006, **26**(1):66-69

[7] 王旭东,邵惠鹤. RBF神经网络理论及其在控制中的应用[J]. 信息与控制, 1997, **26**(4):272-283

[8] 孙优贤,褚 健. 工业过程控制技术(方法篇)[M]. 北京:化学工业出版社, 2006:365-366

[9] 刘钟阳. 放电等离子体合成臭氧及应用中一些问题的研究[D]. 大连:大连理工大学, 2002

[10] 张海传,刘钟阳,许东卫. 基于PC104的臭氧生产工艺过程监测系统[J]. 南开大学学报(自然科学版), 2005, **38**(增刊):217-220

Research on software sensor of ozone concentration based on RBF neural networks model

ZHANG Hai-chuan*, LIU Zhong-yang, XU Dong-wei, WANG Ning-hui

(School of Electrical Engineering, Dalian University of Technology, Dalian 116024, China)

Abstract: The ozone concentration on-line analyzer apparatus is limited in the application of ozone generator greatly. The software sensor of the ozone concentration based on RBF neural networks model is presented with measuring six parameters which influence the ozone concentration. A gradient descent algorithm is introduced to decide the center of the RBF function and the weights of output layer in the model. It can be calibrated off-line or on-line. The experimental results prove that the absolute error of more than 93% is less than 5 g/m^3 and more than 33% is less than 1 g/m^3 between the output of model and the result measuring with the ozone concentration on-line analyzer, and the response time is less than 1 s.

Key words: ozone concentration; radial basis function (RBF); neural networks; software sensor