

文章编号: 1001-0920(2001)05-0549-05

自适应监督式分布神经网络及其工业应用

王雅琳, 桂卫华, 阳春华, 吴敏

(中南工业大学 信息科学与工程学院, 湖南 长沙 410083)

摘要: 针对工业生产过程的复杂性和时变性, 提出一种用于工业生产过程建模的自适应监督式分布神经网络(SDNN)。介绍了 SDNN 网络的结构和自适应学习方法, 并将 SDNN 网络与传统建模方法相结合, 应用于铅锌烧结过程的烧结块成分预测。工业应用结果表明, SDNN 模型具有较高的预测精度, 与传统建模方法有机结合能更好地描述工业生产过程。

关键词: 监督式分布神经网络; 自适应学习; 铅锌烧结过程; 成分预测

中图分类号: TP 216

文献标识码: A

Adaptive Supervised Distributed Neural Networks and Its Industrial Application

WANG Ya-lin, GUI Wei-hua, YANG Chun-hua, WU Min

(College of Information Science & Engineering, Central South University of Technology, Changsha 410083, China)

Abstract: Considering the complexity and the time-variability of industrial process, an adaptive Supervised Distributed Neural Networks(SDNN) is proposed for modeling of industrial process. The structure and the adaptive learning methods of the SDNN are introduced. The SDNN combined with conventional modeling methods is applied to prediction of agglomerate s composition in Pb-Zn sintering process. Results of industrial applications show that the SDNN has higher precision, which combined with other modeling methods is effective in modeling of industrial process.

Key words: supervised distributed neural networks; adaptive learning; Pb-Zn sintering process; composition prediction

1 引言

工业生产过程的模型化研究非常重要, 它是工业过程控制与决策、故障诊断以及运行状态评价的基础。一般的工业过程机理都较复杂, 变量间关联严重, 并且存在非线性、时变时滞、分布参数特性以及种类繁多的扰动。基于物质、能量守恒的精确机理建模和解析数值计算的传统系统辨识方法, 难以很好

地描述实际工业过程, 因此将智能化技术和理论应用于工业过程建模倍受人们的关注。

作为一种智能化技术, 人工神经网络(ANN)可任意逼近非线性^[1,2], 且在处理多变量、强耦合方面具有优越性, 已广泛用于复杂工业过程的系统建模^[3~5]。神经网络建模方法是基于数据的黑箱辨识方法, 依据大量的工业生产历史数据理论上可很好

收稿日期: 2000-05-31; 修回日期: 2000-09-18

基金项目: 国家 863/CMS 项目(863-511-9845-003, 863-511-945-014)

作者简介: 王雅琳(1973—), 女, 广东惠州人, 博士生, 从事复杂过程建模、优化和控制等研究; 桂卫华(1950—), 男, 湖北襄樊人, 教授, 博士生导师, 从事大系统理论、复杂过程建模等研究;

地拟合工业过程。但若实际工业过程异常复杂,工况波动频繁,可测信息有限且相互干扰严重,则传统的NN模型往往规模庞大,运算速度慢,易产生过拟合现象,难以得到理想的结果。分布式神经网络^[6,7]按某种标准将学习样本集划分为多个具有不同特征值的子空间,再用不同NN分别描述工业过程,可在一定程度上解决上述问题。由于分布式NN的样本划分标准仅仅基于输入变量,而忽略了输出变量对样本分布空间的影响,因而这种无监督的聚类方法易造成网络学习无效^[8]。为此,本文提出一种自适应监督式分布神经网络,并将所提出的模型与传统辨识方法相结合,应用于铅锌烧结过程的烧结块成分预测。工业应用结果表明,该模型具有较高的预测精度。

2 监督式分布神经网络

当学习样本存在严重非线性且相互间存在某些矛盾时,首先按某种标准将学习样本划分为不同的子类,然后分别用神经网络学习,则相对容易实现。本文基于这种思想,提出一种监督式分布神经网络,其结构如图1所示。

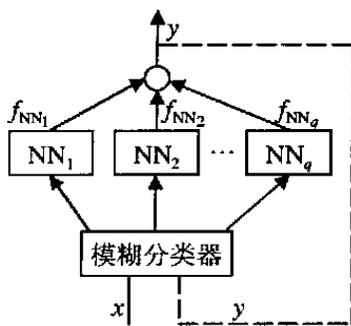


图1 监督式分布神经网络模型

网络学习样本的划分标准采用监督式聚类方法,其特点在于学习样本聚类时,不仅基于样本的输入变量,而且综合考虑了输出变量对样本空间分布的影响。这种有监督的聚类方法充分利用了输出所包含的过程信息,使样本空间的划分更加均匀合理。对于学习样本集 $\{x(k), y(k) \mid x \in R^n, y \in R^1, k = 1, 2, \dots\}$,监督式聚类算法如下:

1) 将输出加到输入变量中组成增广输入变量,从而获得聚类样本集

$$\tilde{x}(k) = [x(k), \beta y(k)], \quad k = 1, 2, \dots \quad (1)$$

式中 β 为控制 $y(k)$ 对聚类结果影响程度的参数, β 越小, $y(k)$ 对聚类结果影响越小。

2) 按Subtractive clustering方法^[9]确定聚类样本集的初始聚类中心个数 q 和初始聚类中心 $v_i, i = 1, 2, \dots, q_0$

3) 对聚类样本集中的每个增广输入向量 $\tilde{x}(k)$,依输入样本密度确定最近中心点 v_c

$$\begin{cases} p_c \tilde{x}(k) - v_c = \min_j p_j \tilde{x}(k) - v_j \\ p_j = n_j / \sum_{i=1}^q n_i \end{cases} \quad (2)$$

并修正聚类中心 v_c

$$\begin{cases} n_c = n_c + 1 \\ a_c = 1/n_c \\ v_c(k+1) = v_c(k) + a_c(\tilde{x}(k) - v_c(k)) \\ v_j(k+1) = v_j(k), \quad j \neq c \end{cases} \quad (3)$$

4) 聚类中心修正结束后,固定聚类中心 $v_i (i = 1, 2, \dots, q)$,确定每个子空间的边界(或半径)。即对聚类样本集中的每个增广输入向量 $\tilde{x}(k)$,定义

$$\tilde{x}(k) - v_c = \min_j \tilde{x}(k) - v_j \quad (4)$$

$$\begin{cases} \text{if } \tilde{x}(k) - v_c > r_c(k) \\ \text{then } r_c(k+1) = \tilde{x}(k) - v_c \\ \text{if } \tilde{x}(k) - v_c \leq r_c(k) \\ \text{then } r_c(k+1) = r_c(k) \end{cases} \quad (5)$$

通过监督式聚类可得 q 个聚类中心 $v_i (i = 1, 2, \dots, q)$ 及其半径 $r_i (i = 1, 2, \dots, q)$ 和样本数 $n_i (i = 1, 2, \dots, q)$ 。依据 q 个子样本集 $\{x_j(k), y_j(k) \mid j = 1, 2, \dots, q; k = 1, 2, \dots, n_j\}$,可分别采用不同的NN建立子模型

$$y_j = f_{NN_j}(x) \quad (6)$$

对于整个样本空间,这些相对分散的子网不利于应用,为此模糊分类器将各子网综合,得到整个网络的输出为

$$y = \frac{\sum_{i=1}^q \mu_i y_i}{\sum_{i=1}^q \mu_i} \quad (7)$$

$$\mu_i = \begin{cases} 1 - \frac{\tilde{x} - v_i}{r_i}, & \tilde{x} - v_i \leq r_i \\ 0, & \tilde{x} - v_i > r_i \end{cases}$$

其中, \tilde{x} 为模型输入输出按式(1)组成的增广输入, μ_i 为每个类的隶属函数。

监督式分布神经网络在聚类时将用到样本期望输出,为此用该网络预测时,最好能与其它建模方法(如线性辨识和规则模型等)配合使用。首先利用线性辨识和规则模型进行粗预测,然后将样本的输入和粗预测的输出作为监督式分布神经网络的输入来进行精确预测。

3 网络自适应学习

生产过程是异常复杂的, 其时变性要求网络应具有自适应功能, 并根据生产数据不断学习和修正。监督式分布神经网络的自适应功能对于新样本是否在已划分样本空间的不同情况, 其学习机制不同。

若新数据样本在已划分的样本空间内, 但网络预测的结果与实际值误差较大, 即

$$\mu_i = 0 \text{ 且 } |e| > \epsilon_{\min} \quad (8)$$

其中 q 表示用于预测的子网个数, 则对样本所在的子网进行修正, 即对 $\tilde{x} - v_l - r_l$ 的第 l 个子网, 用新数据更新其权值。

若新数据样本不在已划分的样本空间内, 即

$\mu_i = 0$, 则按如下 3 种情况自适应修正网络:

1) 如果新数据样本组成的增广输入向量与所有聚类中心间距离的最小值

$$D_{\min} = \min_{j=1}^N |\tilde{x} - v_j| - r_{\max} \quad (9)$$

r_{\max} 为子类允许的最大半径, 其中所有聚类中心包括自适应修正中用于预测的 $1 \sim q$ 个子类和不用于预测的 $q+1 \sim N$ 个子类的中心。则网络将增加一个子类, 该子类以新数据样本的增广输入向量为聚类中心, 初始聚类半径为零。

2) 如果 $D_{\min} < r_{\max}$, 同时 D_{\min} 所对应的子类 d 的样本数 n_d 小于子类允许学习和预测的最小样本数 n_{\min} , 即 $q+1 \leq d \leq N$, 则对于子类 d , 仅按

$$\begin{cases} v_d(k) = v_d(k-1) + [\tilde{x} - v_d(k-1)]/n_d \\ r_d(k) = \max\{|\tilde{x} - v_d(k)|, r_d(k-1) + v_d(k) - v_d(k-1)\} \end{cases} \quad (10)$$

修改聚类中心和半径, 而不需进行子网的学习和预测。

3) 如果 $D_{\min} < r_{\max}$, $n_d \geq n_{\min}$, 即 $1 \leq d \leq q$, 则对 $1 \sim q$ 个子类首先按

$$r_i(l) = r_i(l-1) + \gamma r_i(0) \quad (11)$$

不断增加聚类半径, 直到满足 $\mu_i = 0$, 然后用新数据样本更新 $\mu_j = 0$ 的子网 j 的权值, 其中, $r_i(0)$ 为调整前 $1 \sim q$ 个子网的聚类半径, γ 为半径增长率, $0 < \gamma < 1$ 。

在网络自学习过程中, 参数 r_{\max} 和 n_{\min} 的设定非常重要, 其中 r_{\max} 决定了每个子网最大可涵盖的

样本空间, n_{\min} 不仅控制了可用于预测的子网个数, 而且对于一些突变的数据干扰有一定的抑制作用。由此可见, 这两个参数直接影响着网络的结构。

4 工业应用实例

铅锌烧结过程是密闭鼓风炉铅锌冶炼过程的第一道工序, 它通过高温烧结, 使烧结混合料中的铅锌精矿氧化脱硫, 固结成具有一定强度和孔隙度的铅锌烧结块, 为鼓风熔炼提供原料。烧结块中的铅和锌含量是烧结生产中的重要指标之一, 其实时预测对指导烧结配料计算、稳定烧结块成分以及稳定熔炼生产具有重要的意义。

依据物料平衡计算, 可粗略得到烧结块铅和锌成分预测模型为

$$\begin{cases} S_{Pb} = \frac{M_{Pb} - L_{Pb}}{1 - R_L} - (1 - R_S) \Delta_{Pb} \\ S_{Zn} = \frac{M_{Zn} - L_{Zn}}{1 - R_L} - (1 - R_S) \Delta_{Zn} \end{cases} \quad (12)$$

式中, S_{Pb} 和 S_{Zn} 为烧结块中铅和锌的成分百分比, M_{Pb} 和 M_{Zn} 为混合料中铅和锌的成分百分比, L_{Pb} 和 L_{Zn} 为烧结过程中铅和锌的成分损失, Δ_{Pb} 和 Δ_{Zn} 分别表示返粉与烧结块铅和锌成分间的差值, R_S 为结块率, 即烧结块与烧结混合料的比重, R_L 为烧损率, 即烧结过程中物料的质量损失与烧结混合料的比重。实际生产中, M_{Pb} 和 M_{Zn} 已知, 其余变量则通过数据统计归纳得到。一般 Δ_{Pb} , Δ_{Zn} 和 R_L 变化不大, 在很长一段时间内可用常数表示; 而 L_{Pb} , L_{Zn} 和 R_S 与生产操作条件关系密切, 为便于短期预测, 根据专家经验对统计值进行实时修正。由此得到的经验机理模型能在一定程度上反映生产状况, 但模型中含有不少假设条件、统计数据和经验设定, 预测精度不高。

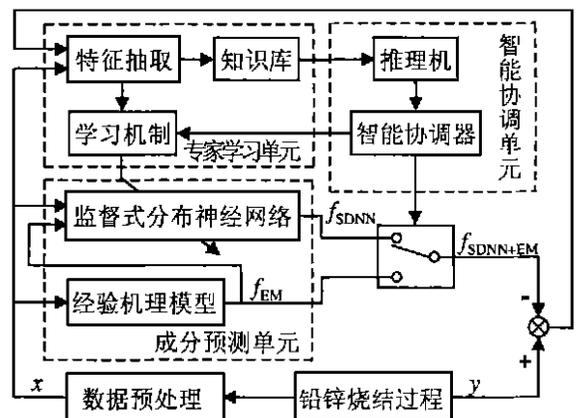


图 2 烧结块铅锌成分预测的集成模型

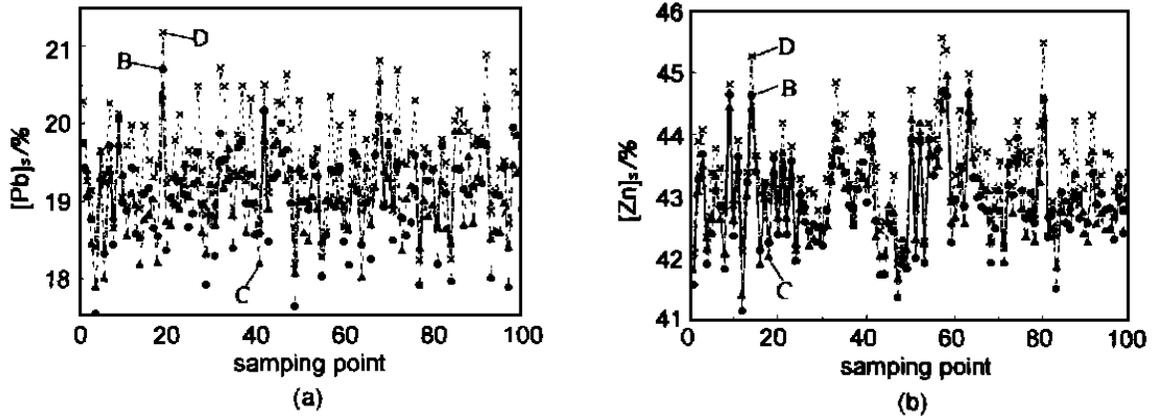


图3 SDNN与UDNN的烧结块铅锌成分预测结果比较

(a) 铅成分预测结果

(b) 锌成分预测结果

考虑到铅锌烧结过程物理、化学反应极为复杂,固、液、气三相共存,具有严重的非线性、强耦合和大滞后,过程影响因素繁多而可测信息有限,因此采用监督式分布神经网络(SDNN)与经验机理模型相结合的方法预测烧结块铅锌成分。成分预测的集成模型如图2所示,它主要由成分预测、智能协调和专家学习3部分组成。成分预测由SDNN和经验机理模型串并联组成,其中经验机理模型的输出引到SDNN的输入参加监督式聚类;智能协调单元用于协调SDNN和经验机理模型的输出,并决定SDNN何时进入学习状态以及采用何种学习机制;专家学习单元实时监督和评价智能协调单元的工作,并有效地充实和修改智能协调规则以及成分预测中的两个模型。集成模型通过在线更新和修正,可不断完善并进一步提高预测精度。

通过机理分析和数据相关性分析,选择台车速度以及混合料中铅、锌、硫成分作为烧结块铅和锌成分神经网络模型的输入变量。用预处理后的烧结过程历史数据训练网络,确定网络模型SDNN-Pb和SDNN-Zn的子网结构为BP 4-15-1,网络训练采用加动量项的变学习率BP算法。定义相对预测均方差RMSE为

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N \left(\frac{y(k) - \hat{y}(k)}{y(k)} \right)^2} \quad (13)$$

式中 N 为参与预测的样本数。则仿真过程中模型SDNN-Pb的RMSE为3.21%,模型SDNN-Zn的RMSE为2.37%。相比铅、锌成分经验机理模型的RMSE都大于5%,说明SDNN具有较高的预测精度。

图3为SDNN与无监督式分布神经网络

UDNN烧结块铅锌成分预测结果的比较,曲线横标为数据样本点,纵坐标为烧结块中的铅或锌成分(%),B为实际成分分析值曲线,C为SDNN预测曲线,D为UDNN预测曲线。由图3可以看出,SDNN比UDNN预测精度高。其中,UDNN聚类算法中的聚类样本并非采用SDNN的增广输入变量,而是采用一般输入变量,UDNN与SDNN分类方法、网络结构和学习算法基本相同。

集成模型将SDNN与经验机理模型相结合,不仅使SDNN能借助于经验机理模型的结果进行精确预测,而且弥补了SDNN在生产异常时预测不准的缺陷。该模型已应用于某铅锌冶炼厂的烧结块铅、锌成分在线预测,实际运行结果表明,由SDNN与经验机理模型组成的集成模型具有较高的预测精度和较强的自学习功能。

5 结 语

自适应监督式分布神经网络采用监督式聚类方法,首先将学习样本有效地分成多个子空间,分别用不同的神经网络学习,然后综合描述工业过程,克服了传统建模方法和单个神经网络在工业过程建模中的缺陷。该网络运用多种学习机制进行自适应修正,在具有强时变性的工业生产过程建模中具有优势。由于该网络的空间分布与工业过程的输入输出变量都有关,因此与传统的建模方法有机结合将更有利于工业生产过程的准确描述。铅锌烧结过程烧结块成分预测的工业应用,验证了与其它建模方法相结合的监督式分布神经网络在工业生产过程的建模中的有效性和适用性。

(下转第556页)

$$\begin{bmatrix} 2.41 \times 10^6 & 3.69 \times 10^4 & 0 \\ 3.69 \times 10^4 & 1.20 \times 10^3 & 0 \\ 0 & 0 & 2.00 \times 10^2 \end{bmatrix}$$

通过求解 Riccati 方程得到稳态 Kalman 滤波增益 K_{Kal} 和误差方差 P_{Kal} 分别为

$$K_{Kal} = \begin{bmatrix} 0.2644 \\ 0.0040 \\ 0.0000 \end{bmatrix}$$

$P_{Kal} =$

$$\begin{bmatrix} 2.38 \times 10^6 & 3.64 \times 10^4 & 4.60 \times 10^{-1} \\ 3.64 \times 10^4 & 1.21 \times 10^3 & 0.10 \times 10^2 \\ 4.60 \times 10^{-1} & 0.10 \times 10^2 & 1.60 \times 10^2 \end{bmatrix}$$

当 $W = 0, V$ 不变时, 解得

$P_0 =$

$$\begin{bmatrix} 5.52 \times 10^2 & 8.77 \times 10^{-4} & -1.34 \times 10^{-9} \\ 8.77 \times 10^{-4} & 2.82 \times 10^{-9} & -8.93 \times 10^{-11} \\ -1.34 \times 10^{-9} & -8.93 \times 10^{-11} & 1.42 \times 10^{-9} \end{bmatrix}$$

为进行比较, 假设系统对滤波误差的精度要求为 $\sigma^2 = 4 \text{diag}(P_{Kal})$ 。根据所给出的设计方法, 循环 3 次便得到满意鲁棒滤波增益

$$K = [0.5482, 0.0039, 0]^T$$

其容许系统的模型噪声强度为

$W_U =$

$$\begin{bmatrix} 1.12 \times 10^6 & 3.82 \times 10^3 & 1.02 \\ 3.82 \times 10^3 & 3.10 \times 10^2 & -2.23 \times 10^{-2} \\ 1.02 & -2.23 \times 10^{-2} & 7.99 \times 10^2 \end{bmatrix}$$

而与该模型噪声相应的滤波误差方差阵为

$P =$

$$\begin{bmatrix} 3.96 \times 10^6 & 4.00 \times 10^4 & 4.83 \times 10^{-1} \\ 4.00 \times 10^4 & 2.58 \times 10^3 & -2.64 \times 10^{-2} \\ 4.83 \times 10^{-1} & -2.64 \times 10^{-2} & 7.99 \times 10^2 \end{bmatrix}$$

由此可见, 当给定精度范围 $\sigma^2 = 4 \text{diag}(P_{Kal})$, 且传感器选定时, 便得到系统模型噪声的上界 W_U , 从而给出滤波器允许的适应目标的机动最大范围。

5 结 论

本文针对离散随机系统的当前估计型稳态 Kalman 滤波, 在模型和测量噪声固定时, 给出了基于 LM I 方法的求解方法。在此基础上, 给出了求解容许系统有尽可能大强度模型噪声的约束方差滤波方法。该方法也可推广用于研究含有噪声方差约束的其它工程问题。

参考文献:

- [1] Wang Zidong, Guo Zhi Robust constrained variance estimation for discrete systems with model noise intensity uncertainty and its application [J]. Chinese J of Automation, 1996, 8(3): 249-253
- [2] Zidong Wang, Zhi Guo, H Unbehauen Robust H_2/H_∞ -state estimation for discrete-time systems with error variance constraints [J]. IEEE Trans on Autom Contr, 1997, 42(10): 1431-1435
- [3] Guo Zhi A survey of satisfying control and estimation [A]. Proc of the 14th IFAC Congress [C]. Beijing, 1999 443-447.

(上接第 552 页)

参考文献:

- [1] Hornik K, Stinchcombe M, White H. Multilayer feed-forward networks are universal approximators [J]. Neural Networks, 1989, 2(5): 359-366
- [2] Chen S, Billings S A. Neural networks for nonlinear dynamic system modeling and identification [J]. Int J Control, 1992, 56(2): 319-346
- [3] Sungzoon Reliable roll force prediction in cold mill using multiple neural networks [J]. IEEE Trans on Neural Networks, 1997, 21(9): 981-996
- [4] Nikravesh M. Model identification of nonlinear time variant processes via artificial neural network [J]. Computers & Chemical Engineering, 1996, 20(11): 1277-1290
- [5] Wang Yalin, Gui Weihua, Chen Xiaofang *et al* Neural network modeling for composition prediction of Pb-Zn sinter in imperial smelting process [A]. Proc of the Annual Chinese Automation Conf in the UK [C]. Oxford: Paciland Int L imited, 1999 21-24
- [6] 王旭东, 邵惠鹤 基于神经网络的通用软测量技术 [J]. 自动化学报, 1998, 24(5): 702-706
- [7] 罗荣福, 邵惠鹤 分布式网络局部学习方法及其在推断控制中的应用 [J]. 自动化学报, 1994, 20(6): 739-742
- [8] Pedrycz W. Conditional fuzzy clustering in the design of radial basis function neural networks [J]. IEEE Trans on Neural Networks, 1998, 9(4): 601-612
- [9] Chiu S Fuzzy model identification based on cluster estimation [J]. J of Intelligent & Fuzzy Systems, 1994, 2(3): 267-278