

DOI: 10.19650/j.cnki.cjsi.J2209618

基于正则化 AdaBound 的区间二型模糊神经网络软测量建模*

冯琳¹, 赵涛岩¹, 曹江涛¹, 李平², 商瑀³

(1. 辽宁石油化工大学信息与控制工程学院 抚顺 113001; 2. 辽宁科技大学电子与信息工程学院 鞍山 114051;
3. 中国石油天然气股份有限公司抚顺石化分公司烯烃厂 抚顺 113004)

摘要:针对复杂化工过程中存在强非线性、多变量耦合、参数时变及大时滞等因素,导致监测变量软测量精度不高的问题,提出了一种基于正则化 AdaBound 的区间二型模糊神经网络(RAIT2FNN)软测量建模方法。首先为了解决区间二型神经网络(IT2FNN)结构难以确定的问题,提出了一种采用激励强度和相似度定义增长和删减指标的自组织产生规则的算法。该算法利用激励强度的大小决定是否产生规则,并根据相似度进行规则的删减从而确定了区间二型模糊神经网络的结构。其次,本文提出正则化和 AdaBound 相结合的算法对 RAIT2FNN 模型相关参数进行修正,使得不同参数具有有界的自适应学习速率。最后将 RAIT2FNN 作为软测量模型应用于环己烷无催化氧化过程尾氧浓度预测问题中。实验结果为测试时间为 0.008 2,训练 RMSE 为 0.018 2,测试 RMSE 为 0.009 6,表明 RAIT2FNN 作为软测量模型具有预测及时且预测精度较高的优点。

关键词: 区间二型模糊神经网络;软测量;环己烷无催化氧化过程;尾氧浓度

中图分类号: TH865 TP173 **文献标识码:** A **国家标准学科分类代码:** 510.80

A soft sensor modeling method based on the regularized AdaBound interval type-2 fuzzy neural network

Feng Lin¹, Zhao Taoyan¹, Cao Jiangtao¹, Li Ping², Shang Yu³

(1. School of Information and Control Engineering, Liaoning Petrochemical University, Fushun 113001, China;
2. School of Electronic and Information Engineering, University of Science and Technology Liaoning, Anshan 114051, China;
3. Olefin Plant of Fushun Petrochemical Branch of CNPC, Fushun 113004, China)

Abstract: The complex chemical process has problems of strong nonlinear, multivariable coupling, parameters time-varying and large time delay, which result in low accuracy of soft sensor. To address these issues, a soft sensor modeling method based on the regularization AdaBound interval type-2 fuzzy neural network (RAIT2FNN) is proposed. Firstly, to solve the problem that the structure of interval type-2 neural network (IT2FNN) is difficult to determine, an algorithm for self-organizing generation rules that uses firing strength and rule similarity to define growth and deletion indicators is proposed. The algorithm uses the firing strength to determine whether to generate rules, and deletes the rules according to the similarity. In this way, the architecture of the IT2FNN is determined. Secondly, this article proposes AdaBound with regularization to modify the relevant parameters of the RAIT2FNN model. And different parameters have bounded adaptive learning rates. Finally, RAIT2FNN is used as a soft sensor model to predict the tail oxygen concentration for uncatalysed oxidation of cyclohexane process. The experimental results are that the test time is 0.008 2, the training RMSE is 0.018 2, and the test RMSE is 0.009 6, indicating that RAIT2FNN as a soft sensor model has the advantages of timely prediction and high prediction accuracy.

Keywords: interval type-2 fuzzy neural network; soft sensor; uncatalysed oxidation of cyclohexane; tail oxygen concentration

收稿日期:2022-04-15 Received Date: 2022-04-15

* 基金项目:国家自然科学基金(61673199)、辽宁省教育厅科学研究经费项目(L2019042)、辽宁石油化工大学博士科研启动基金(2019XJL-017)项目资助

0 引言

在现代化生产过程中,一些对经济效益和生产安全起决定性作用的关键变量,由于经济或技术限制会导致其难以或不可能在线测量的问题^[1-2]。这些关键变量的测量值一般是通过实验室离线对样品进行分析确定,这会产生很大的滞后对于各种先进控制和在线优化方案的实施是很不利的。因此,需要一种新的技术手段来实时监控和测量这些难以直接测量、又对生产过程十分重要的关键变量,以提高整个生产装置的自动化水平^[3]。软测量技术是对过程控制和故障诊断的一种有效补充,它是一种虚拟传感技术,通过对一些容易测量并且直接影响关键变量(主导变量)的变量(辅助变量)进行推断和估计,为昂贵或不切实际的物理测量传感器提供可行和经济的替代方案^[4]。与传统的硬件传感器相比,软测量是数学模型、数据处理和智能方法的组合。从20世纪90年代以来,软测量技术在化工生产过程方面得到了大量地应用,并被用来满足如关键变量的获取、过程监控和过程故障检测等任务要求^[5-14]。

软测量建模方法的一般步骤包括:数据采集与预处理、选择合适的辅助变量、建立软测量模型^[15]。其中最重要的步骤就是软测量模型的建立。随着智能方法的快速发展,模糊神经网络受到了学者的广泛关注。模糊神经网络不仅可以利用模糊推理处理非线性和不确定性问题,而且具有神经网络并行计算、分布式信息存储和自适应学习等优点,其作为软测量模型得到了很多应用。丁海旭等^[16]提出了一种自组织递归模糊神经网络,该方法通过建立内部递归节点来增强网络描述系统动态特性的能力,并建立了污水处理过程生化需氧量的软测量模型。尤海辉等^[17]提出了一种基于减法聚类的自适应模糊神经网络软测量模型,并成功地应用到了循环流化床入炉垃圾热值预测问题中,实验结果与BP神经网络相比具有更好的测试精度。安许锋等^[18]提出一种基于广义动态模糊神经网络的软测量模型,该模型具有实时性好、精度高的优点。郭民等^[19]提出了一种多输入多输出的模糊神经网络软测量模型,网络参数通过自适应二阶算法进行调整以提高模型的预测精度,最后将提出的软测量模型进行封装,并在污水处理过程的出水总磷和出水氨氮问题中进行了测试,取得了理想的结果。王介生等^[20]利用模糊迁移方法对动态模糊神经网络软测量模型进行动态重构,然后将其应用到了聚合过程转化速率建模问题中,实验结果显示该方法具有很高的预测精度。

上述方法在模糊神经网络模型中都采用了传统的模糊逻辑系统(也叫一型模糊逻辑系统),随着近十多年区间二型模糊系统的兴起,利用区间二型模糊神经网络(interval type-2 fuzzy neural network, IT2FNN)建模受到了越来越多学者的关注。与一型模糊逻辑系统相比,区间二型模糊系统在抗干扰性、处理不确定性及系统设计自由度方面都较其具备一定的优势。韩红桂等^[21]建立了一种基于区间二型模糊神经网络的软测量模型,并利用梯度下降法优化网络参数以达到提升模型精度的目的,最后成功地应用到了污水处理过程出水氨氮预测问题中。张文涛^[22]提出了一种带补偿因子的区间二型模糊递归神经网络软测量模型,通过利用补偿性模糊推理来优化网络结构,提高网络预测精度和实时性,并将其用于TE化工过程辨识中。曲星宇等^[23]设计了一种基于数据融合的区间二型模糊神经网络的磨煤机料位检测模型,仿真结果表明该方法具有很好地自学习、并行处理能力和检测精度。Zhao等^[24]构建了一种递归自组织区间二型模糊神经网络软测量模型,该模型利用基于高斯核有效性指标的自适应模糊核聚类算法确定结构,所有模型参数的调整利用梯度下降法根据不同的区域进行,最后应用到了乙烯收率的预测中。二型模糊神经网络对初始参数较为敏感,初值对其建模精度影响较大,初值不合适会导致模型建模精度下降。目前,很多对二型模糊神经网络的研究都关注在网络学习算法的改进方面却忽略了二型模糊神经网络结构难以确定的问题,如何设置规则数量,确定初始的参数,提高模型精度仍是需要解决的问题。

本文提出一种基于正则化 AdaBound 的区间二型模糊神经网络(regularization AdaBound interval type-2 fuzzy neural network, RAIT2FNN)的软测量建模方法。本文提出的 RAIT2FNN 模型具有以下特点:首先,为了解决 IT2FNN 网络结构不容易在线确定的问题,利用一种依据在线激励强度定义的规则增长指标来判断是否产生规则,若达到指标要求则产生新的规则否则不产生,从而实现了网络结构的自主生成;其次为了提高网络的泛化能力、在线获得紧凑的网络结构,在 RAIT2FNN 中采用规则相似度来删减不必要的规则;采用正则化和 AdaBound 相结合的算法进行参数学习,可以使不同参数具有有界的自适应学习速率并且防止过拟合;再次,RAIT2FNN 模型在降型过程中采用直接降阶算法,该方法较常用的 Karnik-Mendel 降型算法具有结构简单、计算成本低,并且计算过程不需要找左、右转折点的特点;最后,将提出的 RAIT2FNN 软测量模型应用于环己烷无催化氧化过程尾气浓度预测问题中,实验结果显示提出的方法具有良好的性能。

1 基于 RAIT2FNN 的软测量模型

1.1 RAIT2FNN 结构

本文中 RAIT2FNN 的模糊规则采用 TSK 形式,如下式所示:

$$R^j: \text{If } x_1 \text{ is } \bar{A}_1^j \text{ and } x_2 \text{ is } \bar{A}_2^j \cdots \text{ and } x_I \text{ is } \bar{A}_I^j,$$

$$\text{then } y^j = c_0^j + \sum_{i=1}^I c_i^j x_i \quad (1)$$

其中, $x_i (i=1, 2, \dots, I)$ 和 $y^j (j=1, 2, \dots, J)$ 分别表示输入变量和模糊规则的输出。 $\bar{A}_i^j = [A_i^j, \bar{A}_i^j]$ 表示区间二型模糊集合,是模糊规则的前件, j 是规则数 ($j=1, 2, \dots, J$)。 $c_i^j (i=0, 1, \dots, I)$ 为模糊规则后件参数,其表达式如下:

$$c_i^j = [a_i^j - b_i^j, a_i^j + b_i^j], i=0, 1, \dots, I \quad (2)$$

每个的规则的输出值是一个区间 $[w^j, \bar{w}^j]$, 根据式(1)和(2)可得规则的输出值为:

$$[w^j, \bar{w}^j] = [a_0^j - b_0^j, a_0^j + b_0^j] + \sum_{i=1}^I [a_i^j - b_i^j, a_i^j + b_i^j] \times x_i \quad (3)$$

$$\text{即: } w^j = \sum_{i=0}^I a_i^j x_i - \sum_{i=0}^I |x_i| \times b_i^j \quad (4)$$

$$\bar{w}^j = \sum_{i=0}^I a_i^j x_i + \sum_{i=0}^I |x_i| \times b_i^j \quad (5)$$

其中, $x_0 = 1$ 。

本文提出的 RAIT2FNN 是 1 个 5 层的网络结构,如图 1 所示。




图 1 RAIT2FNN 结构
Fig. 1 Structure of RAIT2FNN

RAIT2FNN 每层的具体功能如下:

第 1 层为输入层,该层的节点直接与输入变量连接,将输入值传送到下一层。第 i 个节点输出如下式所示:

$$u_i = x_i \quad (6)$$

第 2 层为模糊化层,也称隶属度函数层,每个节点代

表一个区间二型隶属函数。根据输入变量与均值的关系,该层节点的输出可利用区间二型模糊集的不确定迹 (foot of uncertain, FOU) 的上界和下界隶属函数直接计算得到。本文使用具有不确定中心的高斯区间二型隶属度函数,其表达式如下所示:

$$\mu_{\bar{A}_i^j}(x_i) = \exp\left\{-\frac{1}{2}\left(\frac{x_i - m_i^j}{\sigma_i^j}\right)^2\right\}, m_i \in [m_i^j, \bar{m}_i^j] \quad (7)$$

其中,

$$\mu_{\bar{A}_i^j}(x_i, m_i^j, \bar{m}_i^j, \sigma_i^j) = \begin{cases} \exp\left\{-\frac{1}{2}\left(\frac{x_i - m_i^j}{\sigma_i^j}\right)^2\right\}, & x \leq \frac{m_i^j + \bar{m}_i^j}{2} \\ \exp\left\{-\frac{1}{2}\left(\frac{x_i - \bar{m}_i^j}{\sigma_i^j}\right)^2\right\}, & x \geq \frac{m_i^j + \bar{m}_i^j}{2} \end{cases} \quad (8)$$

$$\bar{\mu}_{\bar{A}_i^j}(x_i, m_i^j, \bar{m}_i^j, \sigma_i^j) = \begin{cases} \exp\left\{-\frac{1}{2}\left(\frac{x_i - m_i^j}{\sigma_i^j}\right)^2\right\}, & x < m_i^j \\ 1, & m_i^j \leq x \leq \bar{m}_i^j \\ \exp\left\{-\frac{1}{2}\left(\frac{x_i - \bar{m}_i^j}{\sigma_i^j}\right)^2\right\}, & x > \bar{m}_i^j \end{cases} \quad (9)$$

式中: $\mu_{\bar{A}_i^j}$ 和 $\bar{\mu}_{\bar{A}_i^j}$ 是下界和上界隶属函数, $[m_i^j, \bar{m}_i^j]$ 和 σ_i^j 分别是隶属函数的不确定均值和标准差。

第 3 层是模糊规则层,该层每一个节点对应一个模糊规则,每个节点通过代数 product-norm 操作对从第 2 层输出的节点进行 meet 运算来获取激励强度 F^j 。计算公式如下:

$$F^j = [f_l^j, f_r^j] \quad (10)$$

$$f_l^j = \prod_{i=1}^I \mu_{\bar{A}_i^j}, f_r^j = \prod_{i=1}^I \bar{\mu}_{\bar{A}_i^j} \quad (11)$$

第 4 层为降型层,该层主要完成区间二型模糊系统的降型操作,通过对前件激活强度和后件权值执行 Center-of-sets 降型处理得到输出变量,其输出为一个传统的模糊集合,可表示为 $[y_l, y_r]$ 。本文采用直接降型算法进行降型,该层的输出如下:

$$y_l = \frac{\sum_j f_l^j y^j}{\sum_j f_l^j} \quad (12)$$

$$y_r = \frac{\sum_j f_r^j y^j}{\sum_j f_r^j} \quad (13)$$

其中, $y^j = c_0^j + \sum_{i=1}^I c_i^j x_i$ 。

第5层为输出层,其节点表示整个网络的输出。最终输出的计算过程通常取降型集合 $[y_l, y_r]$ 的均值,为了提高网络的性能,网络的输出定义为 y_l 和 y_r 的加权求和的形式,由此引入权重系数 q ,网络输出如下所示:

$$y = qy_l + (1 - q)y_r \quad (14)$$

其中,权重系数满足 $\sigma_{i,1} = \sigma_0$,通过自适应调节权重系数 q 值改变 y_l 和 y_r 的比例以提升网络的建模精度。

1.2 RAIT2FNN 结构学习算法

结构学习算法目的就是为了实现能够通过在线学习产生规则,从而修正网络结构。结合规则前件激励强度和规则相似度对规则层进行增长和删减。将规则前件激活强度 $f = [f_l, f_r]$ 作为决定模糊规则产生与否的标准,由于规则前件激活强度是区间有界的,这里选择激活强度的中心值 f_c 作为产生规则的标准。增长指标定义如下:

$$f_c = \frac{1}{2}(f_l + f_r) \quad (15)$$

当有新的输入数据输入后,在已有规则中最大激活强度中心值表示为:

$$I_1 = \arg \max_{1 \leq j \leq M(t)} f_c^j(x) \quad (16)$$

其中, $M(t)$ 表示 t 时刻已有的规则数,如果 $I_1 \leq f_{th}$,表明已有规则不能满足新的输入数据,因此产生新的规则,其中 $f_{th} \in (0, 1)$ 是预先设定的阈值,这里设置 f_{th} 为 0.06。新规则按照式(17)~(19)产生:

$$m_{i,new} = x_i - \zeta \quad (17)$$

$$\bar{m}_{i,new} = x_i + \zeta \quad (18)$$

$$\sigma_{i,new} = |m_{i,1} - x| \quad (19)$$

其中, $\zeta = 0.2$ 。网络规则更新后有 $M(t + 1)$ 条规则:

$$\underline{m}_{i,M(t)+1} = [\underline{m}_{i,1}; \dots; m_{i,M(t)}; \underline{m}_{i,new}] \quad (20)$$

$$\bar{m}_{i,M(t)+1} = [\bar{m}_{i,1}; \dots; m_{i,M(t)}; \bar{m}_{i,new}] \quad (21)$$

$$\sigma_{i,M(t)+1} = [\sigma_{i,1}; \dots; \sigma_{i,M(t)}; \sigma_{i,new}] \quad (22)$$

这样产生规则的隶属度函数中心和宽度不可避免地会有重合或者距离相近的情况,即规则相似,那么就会造成规则的冗余,需要删减不必要的规则。相似度即删减指标定义如下:

$$I_s = \max \left(\sum_{i=1}^l \theta_{id} / I \right) \quad (23)$$

其中, θ_{id} 为任意两个区间二型高斯隶属度函数的中心或宽度差值,即 $\underline{m}_{id}, \bar{m}_{id}, \sigma_{id}$ 。当 $I_s \leq \beta$ 时说明规则相似,需要删掉其中激励强度小的规则。其中 $v_i = \beta_2 v_{i-1} + (1 - \beta_2) g_i^2$ 是相似度阈值,设置为 0.06。

综上所述本文提出的结构学习算法步骤为:

1) 初始化,如果 x 是第一个新的数据集,则将参数初始化,生成初始规则。

2) 计算激励强度中心值 f_c ,由式(11)得到 f_l 和 f_r 并

按照式(14)得到 f_c ,根据式(16)得到已有规则的最大激励强度中心值 I_1 ,若 $I_1 \leq f_{th}$,则按照式(17)~(19)产生一条新规则。

3) 删减相似规则。按照式(23)计算相似度 I_s ,当 $I_s \leq \beta$ 时规则相似,要删掉其中激励强度小的规则。

1.3 RAIT2FNN 参数学习算法

学习速率是神经网络训练中一个非常重要的参数,在调整学习率的各种方法中,深度学习中的 Adam 得到了广泛应用。它利用梯度的第一和第二矩估计为每个不同的模型参数计算出自适应学习率。从本质上讲,它结合了 Adagrad 和 RMSProp 的优点,前者可以很好地处理稀疏梯度,后者可以很好地处理在线和不稳定情况。本文采用的 AdaBound 算法是 Adam 的改进算法。它限定了个性化的自适应学习率从上到下的范围,使学习速率不能出现太大或太小的情况,因此 AdaBound 比 Adam 具有更快的收敛速度和更好的泛化能力。

RAIT2FNN 将正则化和 AdaBound 结合在一起进行参数学习,这里选择采用 ℓ_2 正则化损失函数如下:

$$E = \frac{1}{2} \sum_{t=1}^{Nbs} (y(t) - \hat{y}(t))^2 + \frac{\lambda}{2} \sum_{j=1}^J \sum_{i=1}^I c_i^2 \quad (24)$$

其中, β_1' 和 β_1' 分别为 RAIT2FNN 模型输出和期望输出; $Nbs \in [1, N]$ 为小批量值; $\lambda \geq 0$ 是正则化参数; c_i' 是后件参数。

参数更新公式如下:

$$\theta_t = \theta_{t-1} - \alpha \frac{\partial E}{\partial \theta_{t-1}} \quad (25)$$

其中, θ 代表需要更新的前件和后件参数。令 $g_t = \frac{\partial E}{\partial \theta_{t-1}}$ 。

在 ℓ_2 正则化下:

$$g_t(i) = g_t(i) + \lambda \theta_{t-1}(i) \quad (26)$$

AdaBound 算法为:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (27)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (28)$$

$$g_t^2 = g_t \odot g_t \quad (29)$$

$$\hat{m}_t = \frac{m_t}{1 - \beta_1} \quad (30)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2} \quad (31)$$

$$\hat{\alpha} = \max \left[l(t), \min \left(u(t), \frac{\alpha}{\sqrt{\hat{v}_t} + \varepsilon} \right) \right] \quad (32)$$

$$l(t) = 0.01 - \frac{0.01}{(1 - \beta_2)t + 1} \quad (33)$$

$$u(t) = 0.01 + \frac{0.01}{(1 - \beta_2)t + 1} \quad (34)$$

$$\theta_t = \theta_{t-1} - \hat{\alpha} \odot \hat{m}_t \quad (35)$$

其中, m_t 和 v_t 分别是对梯度的一阶矩和二阶矩, AdaBound 中矩估计的指数衰减率 $\beta_1 = 0.9, \beta_1'$. β_1' 表示矩阵的相同位置的乘积. 为了防止一阶和二阶矩初始值的结果过大, 在式 (30) 和 (31) 中进行偏置修正, 其中 β_1' 和 β_2' 表示 β_1 和 β_2 的 t 次幂. $l(t), u(t)$ 分别是下界和上界函数, 为了防止分母为 0, 使用一个非常小的数值 ε 进行平滑, ε 一般取 10^{-8} .

具体的推导过程如下:

$$\frac{\partial E(t)}{\partial m_t^j(t)} = \frac{\partial E(t)}{\partial y} \times \left(\frac{\partial y}{\partial y_l} \frac{\partial y_l}{\partial f_{-l}^j} \frac{\partial f_{-l}^j}{\partial \mu_{-l}^j} \frac{\partial \mu_{-l}^j}{\partial m_t^j} + \frac{\partial y}{\partial y_l} \frac{\partial y_l}{\partial f_{-l}^j} \frac{\partial f_{-l}^j}{\partial \mu_{-l}^j} \frac{\partial \mu_{-l}^j}{\partial m_t^j} + \frac{\partial y}{\partial y_r} \frac{\partial y_r}{\partial f_{-r}^j} \frac{\partial f_{-r}^j}{\partial \mu_{-r}^j} \frac{\partial \mu_{-r}^j}{\partial m_t^j} + \frac{\partial y}{\partial y_r} \frac{\partial y_r}{\partial f_{-r}^j} \frac{\partial f_{-r}^j}{\partial \mu_{-r}^j} \frac{\partial \mu_{-r}^j}{\partial m_t^j} \right) \quad (36)$$

$$\frac{\partial E(t)}{\partial \bar{m}_t^j(t)} = \frac{\partial E(t)}{\partial y} \times \left(\frac{\partial y}{\partial y_l} \frac{\partial y_l}{\partial f_{-l}^j} \frac{\partial f_{-l}^j}{\partial \mu_{-l}^j} \frac{\partial \mu_{-l}^j}{\partial \bar{m}_t^j} + \frac{\partial y}{\partial y_l} \frac{\partial y_l}{\partial f_{-l}^j} \frac{\partial f_{-l}^j}{\partial \mu_{-l}^j} \frac{\partial \mu_{-l}^j}{\partial \bar{m}_t^j} + \frac{\partial y}{\partial y_r} \frac{\partial y_r}{\partial f_{-r}^j} \frac{\partial f_{-r}^j}{\partial \mu_{-r}^j} \frac{\partial \mu_{-r}^j}{\partial \bar{m}_t^j} + \frac{\partial y}{\partial y_r} \frac{\partial y_r}{\partial f_{-r}^j} \frac{\partial f_{-r}^j}{\partial \mu_{-r}^j} \frac{\partial \mu_{-r}^j}{\partial \bar{m}_t^j} \right) \quad (37)$$

$$\frac{\partial E(t)}{\partial \sigma_t^j(t)} = \frac{\partial E(t)}{\partial y} \times \left(\frac{\partial y}{\partial y_l} \frac{\partial y_l}{\partial f_{-l}^j} \frac{\partial f_{-l}^j}{\partial \mu_{-l}^j} \frac{\partial \mu_{-l}^j}{\partial \sigma_t^j} + \frac{\partial y}{\partial y_l} \frac{\partial y_l}{\partial f_{-l}^j} \frac{\partial f_{-l}^j}{\partial \mu_{-l}^j} \frac{\partial \mu_{-l}^j}{\partial \sigma_t^j} + \frac{\partial y}{\partial y_r} \frac{\partial y_r}{\partial f_{-r}^j} \frac{\partial f_{-r}^j}{\partial \mu_{-r}^j} \frac{\partial \mu_{-r}^j}{\partial \sigma_t^j} + \frac{\partial y}{\partial y_r} \frac{\partial y_r}{\partial f_{-r}^j} \frac{\partial f_{-r}^j}{\partial \mu_{-r}^j} \frac{\partial \mu_{-r}^j}{\partial \sigma_t^j} \right) \quad (38)$$

$$\frac{\partial E(t)}{\partial c_t^j(t)} = \frac{\partial E(t)}{\partial y} \left(\frac{\partial y}{\partial y_l} \frac{\partial y_l}{\partial c_t^j} + \frac{\partial y}{\partial y_r} \frac{\partial y_r}{\partial c_t^j} \right) + \frac{\lambda}{2} \frac{\partial E}{\partial c_t^j} \quad (39)$$

$$\frac{\partial E(t)}{\partial q(t)} = y_l - y_r \quad (40)$$

$$\frac{\partial E(t)}{\partial y} = (y(t) - \hat{y}(t)) \quad (41)$$

$$\frac{\partial y}{\partial y_l} = q, \quad \frac{\partial y}{\partial y_r} = 1 - q \quad (42)$$

$$\frac{\partial f_{-l}^j}{\partial \mu_{-l}^j} = \prod_{\substack{k=1 \\ k \neq i}}^l \mu_{-l}^k, \quad \frac{\partial f_{-l}^j}{\partial \mu_{-l}^j} = \prod_{\substack{k=1 \\ k \neq i}}^l \mu_{-l}^k \quad (43)$$

$$\frac{\partial f_{-r}^j}{\partial \mu_{-r}^j} = \prod_{\substack{k=1 \\ k \neq i}}^l \mu_{-r}^k, \quad \frac{\partial f_{-r}^j}{\partial \mu_{-r}^j} = \prod_{\substack{k=1 \\ k \neq i}}^l \mu_{-r}^k \quad (44)$$

$$\frac{\partial \bar{\mu}_{\lambda_i}^j}{\partial m_t^j} = \begin{cases} \bar{\mu}_{\lambda_i}^j(x_i(t), \underline{m}_t^j, \sigma_t^j) \frac{(x_i(t) - \underline{m}_t^j)}{(\sigma_t^j)^2}, & x_i(t) \leq \underline{m}_t^j \\ 0, & \underline{m}_t^j \leq x_i(t) \leq \bar{m}_t^j \\ 0, & x_i(t) > \bar{m}_t^j \end{cases} \quad (45)$$

$$\frac{\partial \bar{\mu}_{\lambda_i}^j}{\partial m_t^j} = \begin{cases} 0, & x_i(t) \leq \frac{m_t^j + \bar{m}_t^j}{2} \\ \bar{\mu}_{\lambda_i}^j(x_i(t), \underline{m}_t^j, \sigma_t^j) \frac{(x_i(t) - \underline{m}_t^j)}{(\sigma_t^j)^2}, & x_i(t) > \frac{m_t^j + \bar{m}_t^j}{2} \end{cases} \quad (46)$$

$$\frac{\partial \bar{\mu}_{\lambda_i}^j}{\partial m_t^j} = \begin{cases} 0, & x_i(t) < \bar{m}_t^j \\ 0, & \underline{m}_t^j \leq x_i(t) \leq \bar{m}_t^j \\ \bar{\mu}_{\lambda_i}^j(x_i(t), \bar{m}_t^j, \sigma_t^j) \frac{(x_i(t) - \bar{m}_t^j)}{(\sigma_t^j)^2}, & x_i(t) > \bar{m}_t^j \end{cases} \quad (47)$$

$$\frac{\partial \bar{\mu}_{\lambda_i}^j}{\partial m_t^j} = \begin{cases} \bar{\mu}_{\lambda_i}^j(x_i(t), \bar{m}_t^j, \sigma_t^j) \frac{(x_i(t) - \bar{m}_t^j)}{(\sigma_t^j)^2}, & x_i(t) < \frac{m_t^j + \bar{m}_t^j}{2} \\ 0, & x_i(t) \geq \frac{m_t^j + \bar{m}_t^j}{2} \end{cases} \quad (48)$$

$$\frac{\partial \bar{\mu}_{\lambda_i}^j}{\partial \sigma_t^j} = \begin{cases} \bar{\mu}_{\lambda_i}^j(x_i(t), \bar{m}_t^j, \sigma_t^j) \frac{(x_i(t) - \bar{m}_t^j)^2}{(\sigma_t^j)^3}, & x_i(t) < \frac{m_t^j + \bar{m}_t^j}{2} \\ 0, & \underline{m}_t^j \leq x_i(t) \leq \bar{m}_t^j \\ \bar{\mu}_{\lambda_i}^j(x_i(t), \underline{m}_t^j, \sigma_t^j) \frac{(x_i(t) - \underline{m}_t^j)^2}{(\sigma_t^j)^3}, & x_i(t) > \frac{m_t^j + \bar{m}_t^j}{2} \end{cases} \quad (49)$$

$$\frac{\partial \bar{\mu}_{\lambda_i}^j}{\partial \sigma_t^j} = \begin{cases} \bar{\mu}_{\lambda_i}^j(x_i(t), \underline{m}_t^j, \sigma_t^j) \frac{(x_i(t) - \underline{m}_t^j)^2}{(\sigma_t^j)^3}, & x_i(t) < \underline{m}_t^j \\ 0, & \underline{m}_t^j \leq x_i(t) \leq \bar{m}_t^j \\ \bar{\mu}_{\lambda_i}^j(x_i(t), \bar{m}_t^j, \sigma_t^j) \frac{(x_i(t) - \bar{m}_t^j)^2}{(\sigma_t^j)^3}, & x_i(t) > \bar{m}_t^j \end{cases} \quad (50)$$

RAIT2FNN 参数学习的具体步骤为:

1) 计算需要更新参数的梯度,即计算 g_i 。根据式(24)得到损失函数 E ,然后计算 $g_i = \frac{\partial E}{\partial \theta_{i-1}}$,其中 θ 代表需要更新的前件和后件参数。

2) ℓ_2 正则化。按照式(26)得到正则化后的 $g_i(i)$ 。将正则化加入到参数学习中可以防止过拟合。

3) AdaBound 更新参数。按照式(27)~(35)进行参数 θ_i 更新。AdaBound 可以使学习速率自适应变化,参数优化过程加速收敛,减少震荡。

2 应用实例

将提出的 RAIT2FNN 应用于环己烷无催化氧化过程尾氧浓度预测问题中。为了验证其性能,我们引入均方根误差(root mean squared error, RMSE)、积分平方误差(integral square error, ISE)和均方误差(mean square error, MSE)3个性能指标进行评价,如式(51)~(53)所示。

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y(t+1) - \hat{y}(t+1))^2} \quad (51)$$

$$ISE = \int_0^{\infty} ((y(t+1) - \hat{y}(t+1))^2) dt \quad (52)$$

$$MSE = \frac{1}{N} \sum_{t=1}^N (y(t+1) - \hat{y}(t+1))^2 \quad (53)$$

其中, N 表示采样数据数, $y(t+1)$ 表示 RAIT2FNN 模型输出, $\hat{y}(t+1)$ 表示现场测量值。

2.1 案例描述

环己烷无催化氧化过程是一个典型的高危化工过程。反应器结构采用5个串联气升式环流反应器。在铂催化剂的作用下,原料苯和氢气进行气相加氢反应生成高质量的液相环己烷并进入换热器换热。换热后的液相环己烷,由底部进入第一个反应器,然后依次进入后面4个反应器。空气、氧气和氮气同时送入空气分布器,3种气体混合产生一定量含氧的空气,经过空气分布器的调节进入各个反应器中,气体向上的同时带动反应器底部的液体向上流动,之后在反应器上部 and 液态环己烷相遇产生化学反应,最后在反应器顶部进行反应物的气液分离。环己烷氧化反应过程中未参与反应的环己烷蒸汽、氧气等混合气体会聚集在反应器顶部进入尾气管道,此时如果尾气中氧气的浓度过高就会容易出现爆炸事故。因此,在实际生产过程中对尾氧浓度的实时监测就显得尤为重要。尾氧浓度也被看作是环己烷无催化氧化过程中最重要的安全指标。一般情况下,在实际生产过程中绝大多数石化厂都将尾氧浓度控制在3%以内,如果超出安全指标值就会报警。

2.2 辅助变量的选择及数据预处理

在环己烷无催化氧化实际生产过程中,尾氧浓度会随着进气氧含量的增加而增加;随反应温度升高而降低,且反应温度越高,尾氧浓度下降的越快;随进气量的增加呈线性增加。所以本文选择直接影响尾氧浓度的进气量、反应温度和进气氧含量作为 RAIT2FNN 软测量模型的输入变量,输出变量为尾氧浓度。建立 RAIT2FNN 软测量模型的目的就是实时监测尾氧浓度,保证装置生产安全。

采样数据的数量和质量会对软测量模型产生很大地影响。为了消除不同量纲数据对软测量模型的影响,在实验前我们会对采样数据进行归一化处理,如式(54)所示。

$$\bar{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (54)$$

2.3 结果分析

在某大型化工厂环己烷无催化氧化装置采集到100组现场数据,其中前60组数据作为训练数据用于建立尾氧浓度的软测量模型;而后40组数据作为测试数据对所建立模型的性能进行验证。所建立的 RAIT2FNN 软测量模型初始参数如下:最大迭代次数为300次,中心的学习率,宽度的学习率,后件参数的学习率,权重因子。经过自组织产生规则如图2所示,删减后规则如图3所示,最终规则数为4。




图2 根据激励强度生成的规则

Fig. 2 Rules generated according to firing strength

图4为尾氧浓度的训练结果,图5为训练过程的RMSE值。从图4和5中的曲线可以看出,RAIT2FNN软测量模型训练过程可以较好的跟踪现场数据,训练过程的RMSE值由于AdaBound的小批量梯度下降出现一定的振荡,从0.6逐渐下降后总体趋于相对稳定,误差较小,说明其具有较高地建模精度。

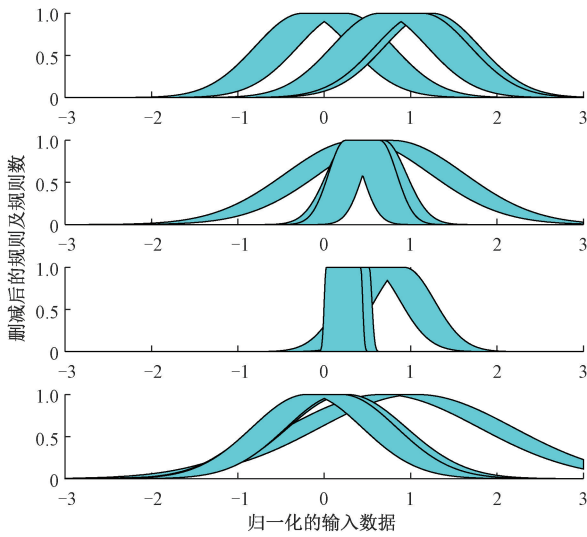


图3 根据相似度删减后的规则

Fig.3 Rules after pruning according to similarity

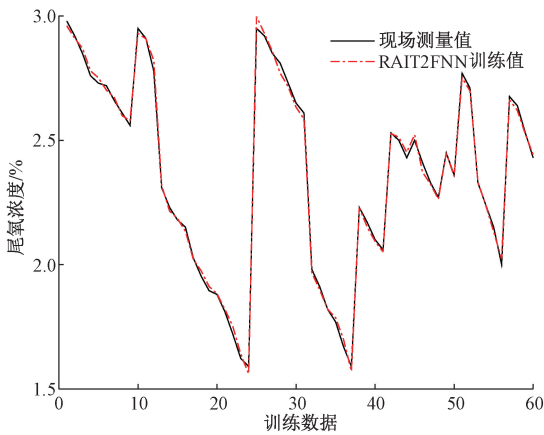


图4 尾氧浓度训练结果

Fig.4 Training results of tail oxygen concentration




图5 尾氧浓度训练均方误差

Fig.5 RMSE of tail oxygen concentration training

图6表示尾氧浓度的预测结果,图7表示测试过程的RMSE值。从图6中的曲线可以看出 RAIT2FNN 软测量模型测试曲线和现场测量值曲线基本拟合,图7中测试的均方误差(测试 RMSE)总体上呈递减状态,可以看出最终的值较小。通过比较图5和7可以看出训练过程和测试过程大体都呈下降趋势,模型经过训练过程后,测试过程的 RMSE 明显减小,训练效果明显,测试结果显著。




图6 尾氧浓度预测结果

Fig.6 Testing results of tail oxygen concentration




图7 尾氧浓度测试均方误差

Fig.7 RMSE of tail oxygen concentration testing

从实验结果图4~7可以总结出,无论是在训练过程还是在测试过程提出的 RAIT2FNN 软测量模型都可以很好地跟踪现场数据,并其具有很高地建模精度,能够适应复杂工业过程的建模要求。

表1列出了 RAIT2FNN 与其它软测量模型的测试时间,训练和测试过程 RMSE 值、ISE 值和 MSE 值。

在学习次数分别为100次,150次,2000次,100次,300次时对 BP 网络、RBF 网络、FNN、IT2FNN 和 RAIT2FNN 进行测试得到表1中各项性能指标值。从

表1 模型的性能指标值
Table 1 Performance comparison of models

模型	BP	RBF	FNN	IT2FNN	RAIT2FNN
学习次数	100	150	2 000	100	300
测试时间	0.047 8	0.069 5	0.149 5	0.094 7	0.008 2
训练 RMSE	0.058 2	0.046 2	0.020 4	0.019 7	0.018 2
测试 RMSE	0.031 8	0.036 9	0.022 8	0.024 1	0.009 6
训练 ISE	0.202 9	0.128 0	0.024 9	0.023 2	0.019 8
测试 ISE	0.040 5	0.054 4	0.020 7	0.023 2	0.003 6
训练 MSE	0.003 4	0.002 1	0.000 416	0.000 388 09	0.000 331 24
测试 MSE	0.001 0	0.001 3	0.000 519	0.000 580 81	0.000 009 21

表中的测试时间看出,提出的 RAIT2FNN 测试时间最小,说明其预测的实时性最好,并且表中的其它性能指标值中,提出的 RAIT2FNN 的各项性能指标值都小于其它模型,无论是在训练过程还是在测试过程中的性能整体表现都比较稳定。

为了验证噪声对 RAIT2FNN 软测量模型的影响,在

实验数据中加入了 30 dB 的白噪声,得到模型的性能指标值如表 2 所示,从表中的各项性能指标值可以看出,在输入噪声数据的情况下与其它 4 种模型相比,提出的 RAIT2FNN 软测量模型各项指标值仍是最小的,表明 RAIT2FNN 软测量模型抗干扰能力强,具有较强的稳定性,适合复杂化工过程的建模。

表2 噪声数据下模型性能指标值
Table 2 Performance index value of models with noise data

模型	BP	RBF	FNN	IT2FNN	RAIT2FNN
学习次数	100	150	2 000	100	300
训练 RMSE	0.059 8	0.078 5	0.086 2	0.041 1	0.028 6
测试 RMSE	0.054 4	0.024 4	0.074 1	0.037 9	0.013 1
训练 ISE	0.214 4	0.369 9	0.445 8	0.101 4	0.049 0
测试 ISE	0.118 5	0.023 9	0.219 6	0.057 3	0.006 9
训练 MSE	0.003 6	0.006 2	0.007 4	0.001 7	0.000 816 8
测试 MSE	0.003 0	0.000 59	0.005 5	0.001 4	0.000 172 47

3 结 论

针对复杂化工过程中存在强非线性、多变量耦合、参数时变及大时滞等因素,导致监测变量软测量精度不高的问题,本文提出了一种基于 RAIT2FNN 模型的软测量建模方法,其拥有以下 5 个特点:

1) 提出的 RAIT2FNN 软测量模型采用激励强度和相似度定义增长和删减指标的自组织产生规则的算法来确定区间二型模糊神经的结构,因此提升系统处理神经网络结构不确定性问题的能力。

2) 在 RAIT2FNN 软测量模型中通过自主产生参数,降低了对初始参数的敏感性。

3) RAIT2FNN 软测量模型采用自组织算法确定网络的结构和规则,而网络的学习算法采用正则化和

AdaBound 结合的算法。

4) 降型部分利用直接降型算法,避免降型过程计算复杂影响软测量实时性的问题。

5) 与 BP 网络、RBF 网络、FNN、IT2FNN 对比提出的 RAIT2FNN 模型适应性更强,准确度更高,预测效果更好,适合复杂化工过程的建模。

参考文献

- [1] 赵超,陈肇泉,王斌,等. 基于互信息和 IGSA 优化 ELM 的重整芳烃收率软测量[J]. 仪器仪表学报, 2019, 40 (3): 255-263.
ZHAO CH, CHEN ZH Q, WANG B, et al. Soft sensing of reformed aromatic yields based on mutual information and IGSA-optimized ELM [J]. Chinese Journal of Instrumentation, 2019, 40 (3): 255-263.
- [2] 邵伟明,葛志强,李浩,等. 基于循环神经网络的半监督动态软测量建模方法[J]. 电子测量与仪器学

- 报, 2019, 31(11): 7-13.
- SHAO W M, GE ZH Q, LI H, et al. Semi-supervised dynamic soft sensor modeling method based on recurrent neural network [J]. *Journal of Electronic Measurement and Instrumentation*, 2019, 31(11): 7-13.
- [3] 乔俊飞, 孙子健, 汤健. 面向工业过程软测量建模的概念漂移检测综述[J]. *控制理论与应用*, 2021, 38(8): 1159-1174.
- QIAO J F, SUN Z J, TANG J. Overview of concept drift detection for soft sensing modeling in industrial processes [J]. *Control Theory and Application*, 2021, 38(8): 1159-1174.
- [4] 万银, 刘丁, 任俊超, 等. 基于栈式自编码网络的直拉硅单晶生长过程 V/G 软测量建模[J]. *仪器仪表学报*, 2020, 41(10): 277-286.
- WAN Y, LIU D, REN J CH, et al. V/G soft sensing modeling of Czochralski silicon single crystal growth process based on stacked self-encoding network [J]. *Chinese Journal of Instrumentation*, 2020, 41(10): 277-286.
- [5] LU B, CHIANG L. Semi-supervised online soft sensor maintenance experiences in the chemical industry [J]. *Journal of Process Control*, 2018, 67: 23-34.
- [6] LIU Z W, GE Z Q, CHEN G J, et al. Adaptive soft sensors for quality prediction under the framework of Bayesian network [J]. *Control Engineering Practice*, 2018, 72: 19-28.
- [7] CAO P F, LUO X L, SONG X H. Modeling and identification for soft sensor systems based on the separation of multi-dynamic and static characteristics [J]. *Chinese Journal of Chemical Engineering*, 2018, 26(1): 137-143.
- [8] YUAN X F, GE Z Q, SONG Z H, et al. Soft sensor modeling of nonlinear industrial processes based on weighted probabilistic projection regression [J]. *IEEE Transactions on Instrumentation and Measurement*, 2017, 66(4): 837-845.
- [9] YUAN X F, HUANG B, WANG Y L, et al. Deep learning-based feature representation and its application for soft sensor modeling with variable-wise weighted SAE [J]. *IEEE Transactions on Industrial Informatics*, 2018, 14(7): 3235-3243.
- [10] YAO L, GE Z Q. Deep learning of semisupervised process data with hierarchical extreme learning machine and soft sensor application [J]. *IEEE Transactions on Industrial Electronics*, 2018, 66(2): 1490-1498.
- [11] 王康成, 尚超, 柯文思, 等. 化工过程深度神经网络软测量的结构与参数自动调整方法[J]. *化工学报*, 2018, 69(3): 900-906.
- WANG K CH, SHANG CH, KE W S, et al. Automatic structure and parameters tuning method for deep neural network soft sensor in chemical industries [J]. *CIESC Journal*, 2018, 69(3): 900-906.
- [12] 王宇红, 狄克松, 张姍, 等. 基于 DBN-ELM 的聚丙烯熔融指数的软测量[J]. *化工学报*, 2016, 67(12): 5163-5168.
- WANG H Y, DI K S, ZHANG SH, et al. Melt index prediction of polypropylene based on DBN-ELM [J]. *CIESC Journal*, 2016, 67(12): 5163-5168.
- [13] 邱禹, 刘乙奇, 吴箐, 等. 基于神经网络的多输出自适应软测量建模[J]. *化工学报*, 2018, 69(7): 3101-3113.
- QIU Y, LIU Y Q, WU J, et al. A self-adaptive multi-output soft sensor modeling based on deep neural network [J]. *CIESC Journal*, 2018, 69(7): 3101-3113.
- [14] 邵伟明, 田学民, 宋执环. 基于集成学习的多产品化工过程软测量建模方法[J]. *化工学报*, 2018, 69(6): 2551-2559, 2806.
- SHAO W M, TIAN X M, SONG ZH H. Ensemble learning-based soft sensor method for multi-product chemical processes [J]. *CIESC Journal*, 2018, 69(6): 2551-2559, 2806.
- [15] 曹鹏飞, 罗雄麟. 化工过程软测量建模方法研究进展[J]. *化工学报*, 2013, 64(3): 788-800.
- CAO P F, LUO X L. Modeling of soft sensor for chemical process [J]. *CIESC Journal*, 2013, 64(3): 788-800.
- [16] 丁海旭, 李文静, 叶旭东, 等. 基于自组织递归模糊神经网络的 BOD 软测量[J]. *计算机与应用化学*, 2019, 36(4): 331-336.
- DING H X, LI W J, YE X D, et al. BOD soft-sensing based on self-organizing recurrent fuzzy neural network [J]. *Computers and Applied Chemistry*, 2019, 36(4): 331-336.
- [17] 尤海辉, 马增益, 唐义军, 等. 循环流化床入炉垃圾热值软测量[J]. *浙江大学学报(工学版)*, 2017, 51(6): 1163-1172.
- YOU H H, MA Z Y, TANG Y J, et al. Soft measurement of heating value of burning municipal solid waste for circulating fluidized bed [J]. *Journal of Zhejiang University (Engineering Science)*, 2017, 51(6): 1163-1172.
- [18] 安许锋, 田洲, 钱锋. 基于广义动态模糊神经网络的聚乙烯分子量分布软测量[J]. *华东理工大学学报(自然科学版)*, 2018, 44(4): 529-534.
- AN X F, TIAN ZH, QIAN F. Soft sensing of

polyethylene molecular weight distribution based on generalized dynamic fuzzy neural network[J]. Journal of East China University of Science and Technology(Natural Science Edition), 2018, 44(4): 529-534.

- [19] 郭民, 祝曙光, 韩红桂. 基于模糊神经网络的出水总磷和氨氮软测量方法研究[J]. 计算机与应用化学, 2017, 34(1): 79-84.

GUO M, ZHU SH G, HAN H G. Soft-sensor method for total phosphorus and ammonia nitrogen based on fuzzy neural network[J]. Computers and Applied Chemistry, 2017, 34(1): 79-84.

- [20] 王介生, 郭秋平. 基于 D-FNN 的聚合过程转化速率软测量建模及重构[J]. 化工学报, 2012, 63(7): 2163-2169.

WANG J SH, GUO Q P. Soft-sensor modeling and reconfiguration of conversion velocity in PVC polymerization process based on D-FNN [J]. CIESC Journal, 2012, 63(7): 2163-2169.

- [21] 韩红桂, 陈治远, 乔俊飞, 等. 基于区间二型模糊神经网络的出水氨氮软测量[J]. 化工学报, 2017, 68(3): 1032-1040.

HAN H G, CHEN ZH Y, QIAO J F, et al. Soft-sensor method for effluent ammonia nitrogen based on interval type-2 fuzzy neural networks[J]. CIESC Journal, 2017, 68(3): 1032-1040.

- [22] 张文涛. 基于二型模糊神经网络的系统辨识算法研究[D]. 辽宁: 大连理工大学硕士学位论文, 2014.

ZHANG W T. Research of system identification based on type-2 fuzzy neural network [D]. Liaoning: Masteral Dissertation of Dalian University of Technology, 2014.

- [23] 曲星宇, 崔宝侠, 段勇, 等. 基于 Type-2 FNN 数据融合的双进双出磨煤机料位检测[J]. 控制与决策, 2011, 26(8): 1259-1263.

QU X Y, CUI B X, DUAN Y, et al. BBD ball mill material measure based on type-2 FNN data fusion[J]. Control and Decision, 2011, 26(8): 1259-1263.

- [24] ZHAO T Y, LI P, CAO J T. Soft sensor modeling of chemical process based on self-organizing recurrent interval type-2 fuzzy neural network [J]. ISA Transactions, 2019, 84: 237-246.

作者简介



冯琳, 2020 年于河南理工大学获得学士学位, 现为辽宁石油化工大学硕士研究生, 主要研究方向为复杂的非线性建模和控制、神经网络和二型模糊系统。

E-mail: fenglinedu668@163.com

Feng Lin received her B. Sc. degree from

Henan Polytechnic University in 2020. She is currently a master student at Liaoning Petrochemical University. Her main research interests include complex nonlinear modeling and control, neural networks, and type-2 fuzzy systems.



赵涛岩(通信作者), 分别在 2009 年和 2012 年于辽宁石油化工大学获得学士学位和硕士学位, 2019 年于西北工业大学获得博士学位, 现为辽宁石油化工大学信息与控制工程学院全职讲师, 主要研究方向为智能控制、复杂非线性建模和二型模糊系统。

E-mail: zhaotaoyan1986@126.com

Zhao Taoyan (Corresponding author) received his B. Sc. degree and M. Sc. degree both from Liaoning Petrochemical University in 2009 and 2012, and received his Ph. D. degree from Northwestern Polytechnical University in 2019. He is currently a full lecturer in the School of Information and Control Engineering at Liaoning Petrochemical University. His main research interests include intelligent control, complex nonlinear modeling and type-2 fuzzy systems.



李平, 分别在 1984 年和 1987 年于西北工业大学获得学士学位和硕士学位, 1995 年于浙江大学获得博士学位, 现为辽宁科技大学教授, 主要研究方向为过程控制与自动化, 化工过程控制系统的先进控制与优化。

E-mail: liping@lnpu.edu.cn

Li Ping received his B. Sc. degree and M. Sc. degree both from Northwestern Polytechnical University in 1984 and 1987, and received his Ph. D. degree from Zhejiang University in 1995. He is currently a full professor at University of Science and Technology Liaoning. His main research interests include process control and automation, especially the advanced control and optimization of chemical industry process control systems.



商瑀, 2011 年于辽宁石油化工大学获得学士学位, 现为中国石油抚顺石化公司烯烃厂工程师, 主要研究方向为化工工艺与安全管理。

E-mail: shangyu1989@126.com

Shang Yu received her B. Sc. degree from Liaoning Petrochemical University in 2011. She is currently an engineer at the olefin plant of PetroChina Fushun Petrochemical Company. Her main research interests include chemical process and safety management.