城市固废焚烧过程烟气含氧量自适应预测控制

孙 剑 [1,2,3] 蒙 西 [1,2,3] 乔俊飞 [1,2,3]

摘 要 在城市固体废弃物焚烧 (Municipal solid waste incineration, MSWI) 过程中, 烟气含氧量是影响焚烧效果的重要工艺参数. 由于固废焚烧过程的复杂性, 在实际应用过程中, 难以实现烟气含氧量的有效控制. 面向城市固废焚烧过程烟气含氧量控制的实际需求, 提出一种基于数据驱动的烟气含氧量自适应预测控制方法. 首先, 采用自适应模糊 C 均值 (Fuzzy C-means, FCM) 算法辅助确定径向基函数 (Radial basis function, RBF) 神经网络隐含层神经元个数及初始中心, 建立基于 FCM 算法的径向基函数神经网络预测模型, 并在控制过程中通过自适应更新策略在线调节预测模型参数; 然后, 利用梯度下降算法求解控制律, 并基于李雅普诺夫理论分析了所提控制方法的稳定性; 最后, 基于城市固废焚烧厂实际数据, 验证了所提控制方法的有效性.

关键词 城市固体废物焚烧, 烟气含氧量, 自适应预测控制, 径向基函数神经网络, 梯度下降

引用格式 孙剑, 蒙西, 乔俊飞. 城市固废焚烧过程烟气含氧量自适应预测控制. 自动化学报, 2023, **49**(11): 2338−2349

DOI 10.16383/j.aas.c210935

Adaptive Predictive Control of Oxygen Content in Flue Gas for Municipal Solid Waste Incineration Process

SUN Jian[1,2,3] MENG Xi[1,2,3] QIAO Jun-Fei[1,2,3]

Abstract Oxygen content in flue gas is an important process parameter for incineration efficiency in municipal solid waste incineration (MSWI). Due to the complexity of municipal solid waste incineration process, it is difficult to achieve effective control of oxygen content in flue gas in practical application. A data-driven adaptive predictive control method for oxygen content in flue gas in MSWI process is proposed in this paper. Firstly, an adaptive fuzzy C-means (FCM) algorithm is used to determine the number of hidden layer neurons and the initial clustering center of radial basis function (RBF) neural network model, and the radial basis function neural network prediction model based on FCM algorithm is established. During the control process, the prediction model parameters are adjusted adaptively by an online updating strategy. Then, the gradient descent method is exploited to solve the control law, and the stability of the control system is analyzed based on the Lyapunov theory. Finally, the effectiveness of the proposed control method is verified based on the actual data of the municipal solid waste incineration plant.

Key words Municipal solid waste incineration (MSWI), oxygen content in flue gas, adaptive predictive control, radial basis function neural network, gradient descent

Citation Sun Jian, Meng Xi, Qiao Jun-Fei. Adaptive predictive control of oxygen content in flue gas for municipal solid waste incineration process. *Acta Automatica Sinica*, 2023, **49**(11): 2338−2349

随着人口增长、快速城市化和全球化, 全球每年约产生 20 亿吨城市固体废弃物 (Municipal solid waste, MSW), 预计到 2030 年, 将达到 25.9 亿吨, 城市固体废弃物处理问题日益突出[1]. 目前, 对于不能直接资源回收的 MSW, 一般采用卫生填埋、堆肥和焚烧等方式进行处理. 相比其他处理方法, 城市固体废弃物焚烧 (Municipal solid waste incineration, MSWI) 技术具有无害化、减容化和资源化的优点, 代表了 MSW 处理技术的发展趋势. 截至 2019 年底, 中国已建有 MSWI 处理厂 389 座, 年无害化处理固体废弃物 12 174.2 万吨[2]. 然而, MSW 成分复杂且随季节天气变化, 其热值的稳定性难以保证. 因此, 高效、稳定的焚烧控制技术一直是 MSWI 过程控制的研究重点.

烟气含氧量是焚烧炉运行过程中的重要工艺参

收稿日期 2021-09-29 录用日期 2022-02-10
Manuscript received September 29, 2021; accepted February 10, 2022
国家自然科学基金 (62021003, 61890930-5, 61903012), 科技创新 2030 —— "新一代人工智能"重大项目 (2021ZD0112301, 2021ZD0112302) 资助
Supported by National Natural Science Foundation of China (62021003, 61890930-5, 61903012) and National Key Research and Development Program of China (2021ZD0112301, 2021ZD0112302)
本文责任编委 诸兵
Recommended by Associate Editor ZHU Bing
1. 北京工业大学信息学部 北京 100124 2. 智慧环保北京实验室 北京 100124 3. 智能感知与自主控制教育部工程研究中心 北京 100124
1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124 2. Beijing Laboratory of Smart Environmental Protection, Beijing 100124 3. Engineering Research Center of Intelligence Perception and Autonomous Control, Ministry of Education, Beijing 100124

数之一, 与实际焚烧过程关系密切. 若烟气含氧量不足, 则说明炉内焚烧不充分, 不完全焚烧热损失就会增加, 飞灰含碳量也会增大; 若烟气含氧量过高, 则排烟损失就会增加, 不仅带走大量的热量, 还会增加排烟耗电量, 焚烧效率也会降低. 此外, 烟气含氧量不足还会使炉膛中产生还原性气体, 在这种气氛中, 灰中熔点较高的三氧化二铁 (Fe_2O_3) 和一氧化碳 (CO) 等还原性气体反应生成熔点较低的氧化铁 (FeO), 易造成炉膛结焦, 影响生产安全[3].

在传统工业燃烧过程控制中, 一般通过专家经验调节给风量和给料量, 进而控制烟气含氧量. 但是, 由于操作员的经验、专长与水平不同, 以及控制过程中经常出现的异常情况, 烟气含氧量的精准控制一直是燃烧过程控制的难题之一. 比例–积分–微分 (Proportion-integration-differentiation, PID) 控制器因具有操作简单、运行可靠和调节方便等优点, 已在工业过程控制中得到广泛应用[4−6]. 虽然 PID 控制方法原理简单, 工程实现容易, 但很容易产生超调或振荡, 且难以胜任多输入/多输出 (Multi-input and multi-output, MIMO) 复杂系统的优化控制任务. 随着智能控制技术的发展应用[7−9], 自抗扰控制[10]、线性二次调节控制[11]、神经网络控制[12]等方法也已成功应用于各种燃烧过程的烟气含氧量控制. 其中, 模型预测控制 (Model predictive control, MPC) 是一种基于特定范围内目标函数优化的先进控制策略[13−15], 能够处理有约束、多变量、多目标的控制问题, 在普通燃煤锅炉、焦炭炉和流化床等燃烧过程烟气含氧量控制中已获得一些应用. 例如, 文献 [3] 建立基于最小二乘支持向量机的锅炉烟气含氧量预测模型, 并在此基础上结合粒子群算法求解预测控制中的非线性优化问题, 实现锅炉烟气含氧量控制. 文献 [16] 提出一种基于混合数据驱动建模和预测函数控制策略的工业焦炉氧量调节方法. 文献 [17] 采用数据驱动的模糊 C 均值 (Fuzzy C-means, FCM) 聚类和子空间辨识方法对模型参数进行识别, 将模型预测控制与模糊多模型相结合以控制烟气含氧量.

上述研究方法主要集中于解决 MPC 应用中存在的两个关键问题, 即非线性系统的预测模型建模和 MPC 的非线性优化问题求解. 然而, 在实际工业过程中, 由于设备老化、结焦污垢和外部干扰等变化, 过程模型往往也会随时间发生变化, 使用离线训练的机器学习模型在干扰出现后可能无法正确预测系统未来动态, 最终影响模型预测控制性能[18−19]. 近年来, 使用过程数据在线更新预测模型是处理 MPC 模型失配的一种可行方案. 文献 [20] 提出一种基于在线支持向量回归的非线性模型预测控制方法, 利用在线支持向量回归的在线学习能力, 实现模型在线自校正. 文献 [21] 针对具有外部扰动和参数不确定性的非线性系统, 通过多层感知机的在线训练, 提出一种基于多层感知机的非线性自适应模型预测控制方法. 文献 [22] 利用在线更新递归神经网络模型的方法, 捕获过程模型存在的不确定性, 并建立基于递归神经网络的预测控制方案.

针对 MSWI 过程烟气含氧量难以有效控制的问题, 本文提出一种数据驱动的烟气含氧量自适应预测控制方法. 该方法采用自适应 FCM 算法确定径向基函数 (Radial basis function, RBF) 神经网络隐含层神经元个数及初始中心, 辅助建立准确的 RBF 神经网络预测模型, 并且在实时控制过程中, 根据预测误差自适应调节模型参数. 另外, 借助梯度下降算法在滚动优化周期内优化控制目标函数, 在线求解控制律, 并基于李雅普诺夫稳定性理论分析控制系统的稳定性. 最后, 通过 MSWI 厂实际数据, 验证了本文方法在烟气含氧量预测建模和控制方面的可行性.

1 MSWI 过程概述及烟气含氧量自适应预测控制策略

1.1 MSWI 过程概述

MSWI 过程是通过热分解、燃烧、熔融等过程, 使 MSW 中的碳、氢、硫等元素与氧发生化学反应, 达到无害化处理、资源化利用和快速缩减体积的目的. 早期的固体废弃物焚烧炉设计和运行主要借鉴了比较成熟的燃煤技术. 目前, 机械炉排焚烧炉技术在中国新建的 MSWI 厂中占据主流, 大多数焚烧处理厂使用的机械炉排技术主要从德国、丹麦、瑞士和比利时等发达国家引进[23]. 本文以北京某 MSWI 厂使用的日本田熊公司生产的 SN 型阶梯式 (倾斜 + 水平) 顺推炉排焚烧炉为例, 介绍 MSWI 过程, 具体工艺流程如图 1 所示.

MSW 由收集车从收集点或转运站装车后被运送至固废焚烧厂, 并被倾倒在一个大型的固废池中. 经过 5 至 7 天的充分发酵, 渗滤液慢慢流入渗滤液储存池. 通过自然压缩、发酵作用和混合操作, 可以降低 MSW 含水量, 提高入炉 MSW 热值, 获得较为均质的燃烧物, 从而改善固废焚烧效果. 固废池上方的抓斗混合 MSW 后投入料斗. 在进料器溜槽的底部, MSW 被推送至液压驱动炉排, 依次通过炉排的干燥炉排、燃烧炉排 1、燃烧炉排 2 和燃烬炉排进行焚烧. 焚烧阶段的助燃空气取自固废池, 在满

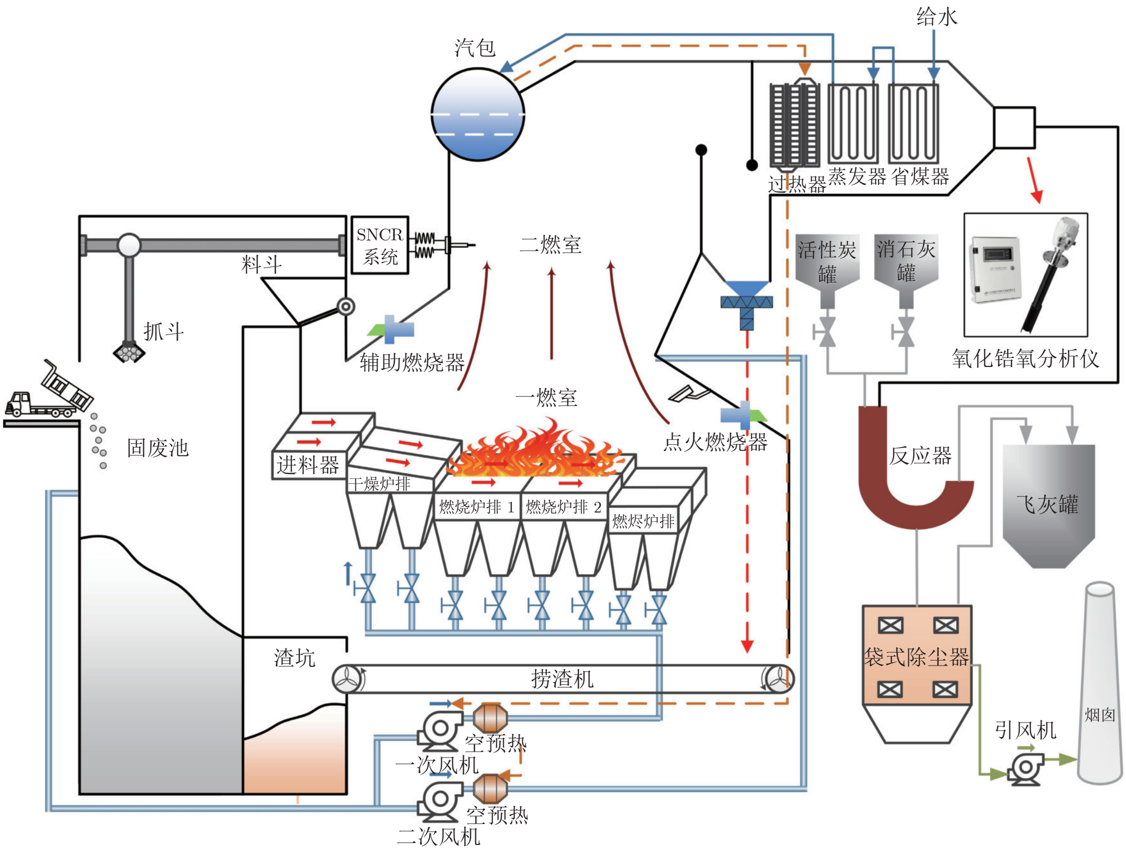

图 1 MSWI 炉排炉工艺流程

Fig. 1 MSWI process with grate furnace

足 MSWI 所需空气的同时, 也有效防止了臭气外溢. 助燃空气主要分为一次风 (从炉排下方送入) 和二次风 (从炉排上方送入). 一次风透过炉排上的气孔吹送燃烧所需的大部分氧气, 二次风通过炉排上方壁的气孔加入到燃烧过程中, 其主要作用是辅助炉排上方的高温烟气进行二次燃烧. 当焚烧温度达到 850 ℃ ~ 950 ℃ 时, 有毒有害物质将得到充分分解. 同时, 为达到脱除氮氧化物的目的, 采用选择性非催化还原 (Selective non-catalytic reduction, SNCR) 工艺, 向焚烧炉内喷入尿素溶液. 然后, 在余热锅炉中对高温气体进行热利用, 水被加热成蒸汽用于驱动汽轮发电机产生电力. 烟气产物主要由氮氧化物、二噁英、碳氧化物、水、氧气、非焚烧残留物和其他酸性气体 (如二氧化硫 (SO_2)、氯化氢 (HCL)) 组成[24]. 为防止二次污染, 需要采用消石灰脱酸、活性炭吸附重金属和有毒有害气体, 再经过烟气净化系统的除尘操作后, 净化后的烟气在引风机的作用下, 经烟囱排出[25].

由上述焚烧过程分析可知, MSWI 过程是非线性且时变的复杂动态过程, 内部发生着多种物理和化学反应, 传热传质和多相流体流动, 同时伴有高温、高压、多相耦合和多物理场共存相互作用, 传统的机理建模方法很难建立准确的数学模型. 而且, 机理模型通常要求具有足够多能够反映工况变化的过程参数, 这在很大程度上依赖于科研和工程开发人员对实际工业过程物理和化学反应过程的认识, 并需要在苛刻的假设条件下才能成立, 例如假定模型是一维模型、助燃剂是空气且由氧气和氮气组成、忽略挥发分析出时引起的热量变化等. 因此, 机理模型的精度难以得到保证, 也无法满足 MSWI 过程烟气含氧量控制的实际需求. 针对 MSWI 过程烟气含氧量控制问题, 可以采用数据驱动方式建立 MSWI 过程非线性系统模型, 并在此基础上验证本文提出的自适应预测控制方法的有效性.

1.2 烟气含氧量自适应预测控制策略

烟气含氧量控制是 MSWI 过程控制的重要一环, 其稳定控制与否直接影响焚烧效率、处理成本和有毒有害污染物排放等方面. 根据 MSWI 过程现场控制经验, 烟气含氧量一般应控制在 4% ~ 8% 较为理想. 目前, 在中国 MSWI 实际过程中, 普遍采用的是人工控制和 PID 控制. 然而, MSWI 过程非线性和时变性的特点使得传统的控制方法难以实现精准的跟踪控制. 因此, 为了提高烟气含氧量的控

制性能, 需要研究以预测控制为代表的先进控制技术.

MPC 的控制性能很大程度上依赖于预测模型的精度, 当实际系统参数发生变化时, 会存在标称模型与实际系统失配的问题, 此时如果仍采用标称模型的预测控制器, 会导致系统控制性能变差甚至不稳定[26]. 为解决这个问题, 本文提出基于数据驱动的自适应 MPC 方法, 通过实际预测误差实时在线调整预测模型的参数, 使其与被控对象的动态变化保持一致. 基于 FCM-RBF 模型的烟气含氧量自适应预测控制 (FCM-RBF neural network based MPC, FCM-RBF-MPC) 策略如图 2 所示, 主要包括参考轨迹、基于梯度下降方法的滚动优化、基于 FCM-RBF 网络的烟气含氧量预测模型和反馈校正等部分.

假设现在和未来控制时域内的控制动作集合为 $\Delta u(t)$, $\Delta u(t+1)$, $\cdots$, $\Delta u(t+H_u)$, 则通过预测模型可以预测未来时域 H_p 内的系统输出 $\hat{y}(t+1|t)$, $\hat{y}(t+2|t)$, $\cdots$, $\hat{y}(t+H_p|t)$. 一般要求控制时域 H_u 小于预测时域 H_p. 通过设计模型预测控制器, 将烟气含氧量的参考值跟踪问题转化为最小化目标函数式 (1) 的优化问题. 本文采用在线梯度下降方法求解该优化问题:

$$J=\sum_{i=1}^{H_p}[y_r(t+i)-\hat{y}(t+i)]^{\mathrm{T}}W_i^y[y_r(t+i)-\hat{y}(t+i)]+\sum_{j=1}^{H_u}(\Delta u(t+j-1))^{\mathrm{T}}W_j^u\Delta u(t+j-1) \tag{1}$$

式中, W_i^y 和 W_j^u 为烟气含氧量预测控制的权重参数, $y_r(t)$ 为需要跟踪的烟气含氧量参考值, $\hat{y}(t)$ 是经过反馈校正补偿后的预测值.

1) 参考轨迹. 为了把当前输出 $y(t)$ 平滑地引导到设定值 $y_{sp}(t)$, 采用一阶平滑滤波形式将参考轨迹设置如下:

$$\begin{cases}y_r(t)=y(t)\\ y_r(t+j)=\alpha_r y_r(t+j-1)+(1-\alpha_r)\,y_{sp}(t)\end{cases} \tag{2}$$

式中, a_r 是调整因子, $0<a_r<1$.

2) 反馈校正. 由于容易受到系统干扰或模型失配等因素影响, 预测模型输出 $y_p(t)$ 与实际输出 $y(t)$ 之间会存在偏差. 为了缩小这种偏差, 一般利用被控对象实际输出与预测模型输出的偏差进行反馈补偿[27]. MPC 通过滚动优化目标函数的方式确定一系列未来的控制动作后, 它们并不会都逐一实施, 而只执行当前控制输入. 此外, 通过比较当前时刻的实际输出与预测模型输出, 得到两者的偏差, 并用于校正模型下一时刻的预测值, 从而使得预测结果更为准确. 具体校正公式如下:

$$err(t)=y(t)-y_p(t) \tag{3}$$

$$\hat{y}(t+j)=y_p(t+j)+err(t) \tag{4}$$

2 数据驱动 FCM-RBF 烟气含氧量预测建模

预测模型是模型预测控制算法的基础, 因此需要首先建立烟气含氧量的预测模型. 预测模型的作用是根据设定的输入以及历史信息来预测被控对象未来的输出. 在建立非线性动态预测模型时, 系统可以表示为以下形式的非线性自回归外生模型:

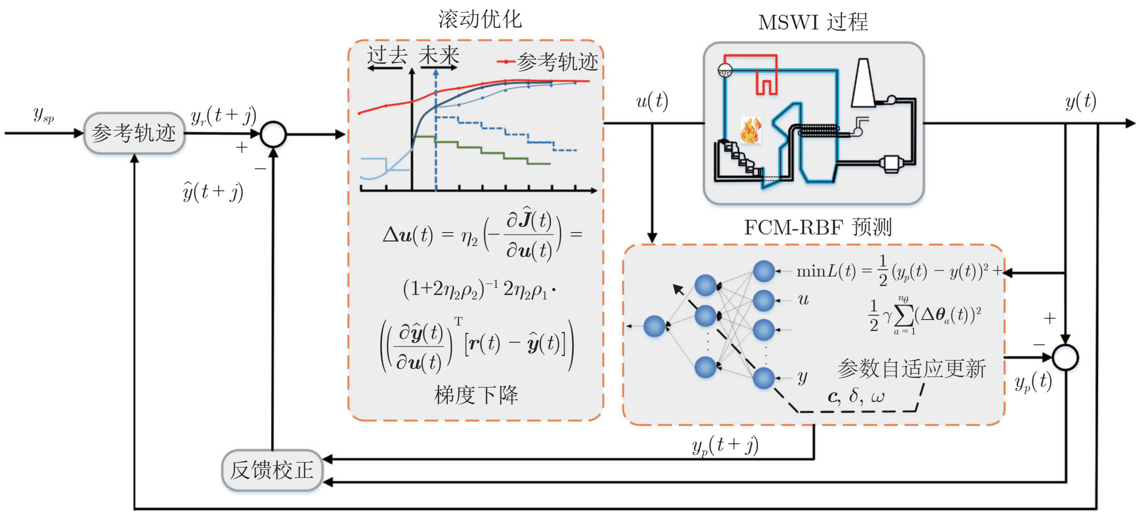

图 2 烟气含氧量自适应 FCM-RBF-MPC 策略

Fig. 2 Adaptive FCM-RBF-MPC strategy of oxygen content in flue gas

$$y_p(t)=f[y(t-1),\, y(t-2),\, \cdots,\, y(t-n_y),\\ u(t-1),\, u(t-2),\, \cdots,\, u(t-n_u)] \tag{5}$$

式中, $u(t)$ 和 $y(t)$ 表示过程的输入和输出, $f[\cdot]$ 是 MSWI 过程烟气含氧量的预测模型, n_y 和 n_u 是输出和输入的最大滞后. 在忽略噪声作用情况下, 对于式 (5) 所表示的系统, 当获得过去的输入/输出信息后, 系统的输出估计 $y_p(t)$ 可以借助已建立的神经网络预测模型得到. 因此, 为得到准确的输出估计, 需要建立能够反映系统动态的预测模型.

2.1 RBF 网络结构

RBF 网络是由输入层、隐含层和输出层构成的前向网络, 因其简单直观的结构和优良的逼近能力, RBF 网络一直是神经网络领域研究的热点[28]. 输入层节点个数等于输入向量的维数, 输出层节点个数等于输出向量的维数, 隐含层神经元个数根据需要确定. 单输出结构的 RBF 网络如图 3 所示. 隐含层节点的激活函数采用较为常见的高斯函数:

$$\phi_j(\boldsymbol{x},\, \boldsymbol{c}_j)=\exp\left(-\frac{\|\boldsymbol{x}-\boldsymbol{c}_j\|^2}{2\delta_j^2}\right) \tag{6}$$

网络输出为:

$$y_p=\sum_{j=1}^{hc}\omega_j\phi_j(\boldsymbol{x},\, \boldsymbol{c}_j) \tag{7}$$

式中, $\boldsymbol{x}=(x_1,\, x_2,\, \cdots,\, x_m)^{\mathrm{T}}$ 为 l 维输入变量, hc 代表隐含层神经元个数, y_p 表示输入为 $\boldsymbol{x}$ 时网络的输出, ω_j 为隐含层第 j 个神经元到输出层的权值, $\boldsymbol{c}_j$ 和 δ_j 分别是第 j 个神经元的中心向量和宽度. 采用梯度下降法对网络参数进行调整.

对于第 t 个样本, 网络实际输出和期望输出之间的误差 $e(t)$ 定义为:

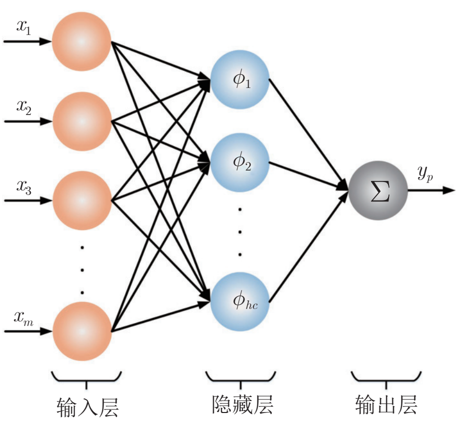

图 3 RBF 神经网络结构图

Fig. 3 RBF neural network framework

$$e(t)=\frac{1}{2}(y_p(t)-y(t))^2,\quad t=1,\, 2,\, \cdots,\, N \tag{8}$$

式中, y 为实际值, N 为样本个数. 隐含层第 j 个神经元的中心 $\boldsymbol{c}_j$、宽度 δ_j 和输出权值 ω_j 更新公式如下:

$$\boldsymbol{c}_{j+1}=\boldsymbol{c}_j-\eta_1\frac{\partial e(t)}{\partial \boldsymbol{c}_j} \tag{9}$$

$$\delta_{j+1}=\delta_j-\eta_1\frac{\partial e(t)}{\partial \delta_j} \tag{10}$$

$$\omega_{j+1}=\omega_j-\eta_1\frac{\partial e(t)}{\partial \omega_j} \tag{11}$$

式中, η_1 为学习率, 具体梯度公式如下:

$$\frac{\partial e(t)}{\partial \boldsymbol{c}_j}=(y_p(t)-y(t))\,\frac{\omega_j}{\delta_j^2}\phi_j(\boldsymbol{x},\, \boldsymbol{c}_j)(\boldsymbol{x}-\boldsymbol{c}_j) \tag{12}$$

$$\frac{\partial e(t)}{\partial \delta_j}=(y_p(t)-y(t))\,\frac{\omega_j}{\delta_j^3}\phi_j(\boldsymbol{x},\, \boldsymbol{c}_j)\|\boldsymbol{x}-\boldsymbol{c}_j\|^2 \tag{13}$$

$$\frac{\partial e(t)}{\partial \omega_j}=(y_p(t)-y(t))\,\phi_j(\boldsymbol{x},\, \boldsymbol{c}_j) \tag{14}$$

2.2 FCM-RBF 网络

在 RBF 神经网络建模过程中, 隐含层神经元个数、中心、宽度和网络权值等参数初始值通常使用人工试错验证的方法来确定, 所选参数初始值直接影响 RBF 神经网络建模效果, 其中 RBF 隐含层神经元个数和初始中心对建模效果影响较大. FCM 算法是一种基于划分的聚类算法, 基本思想是使被划分到同一类的对象之间的相似度最大, 而不同类之间的相似度最小[29], 但是需要人为给定初始聚类数目. 因此, 利用自适应 FCM 聚类算法迭代计算出训练样本的聚类数目和聚类中心, 作为 RBF 神经网络的隐含层神经元个数和初始中心.

假设 $\boldsymbol{P}=\{p_1,\, p_2,\, \cdots,\, p_n\}$ 是一个有限数据集, 其中, $\boldsymbol{p}_g=(p_{g1},\, p_{g2},\, \cdots,\, p_{gl})$ 是第 g 个一维对象, $\boldsymbol{B}=\{b_1,\, b_2,\, \cdots,\, b_b\}$ 表示 b 个聚类, $\boldsymbol{V}=\{\boldsymbol{v}_1,\, \boldsymbol{v}_2,\, \cdots,\, \boldsymbol{v}_b\}$ 表示 b 个 l 维聚类质心, $\boldsymbol{U}=(u_{ig})_{(b\times n)}$ 是模糊划分矩阵, u_{ig} 是第 g 个对象在第 i 个聚类中的隶属度, 其中:

$$\sum_{i=1}^{b}u_{ig}=1,\quad g=1,\, \cdots,\, n \tag{15}$$

目标函数是每个聚类中样本到聚类质心的加权距离平方和, 即:

$$J_{FCM}(\boldsymbol{U},\, \boldsymbol{V})=\sum_{i=1}^{b}\sum_{g=1}^{n}u_{ig}^m d_{ig}^2 \tag{16}$$

式中, $d_{ig} = \|\boldsymbol{p}_g - \boldsymbol{v}_i\|$ 表示第 g 个对象和第 i 个聚类质心之间的欧氏距离. m $(m > 1)$ 是模糊指数, 控制着类群之间模糊重叠的数量, 值越大, 表示重叠的程度越大.

根据聚类准则, 适当地模糊划分矩阵 $\boldsymbol{U}$ 和聚类质心 $\boldsymbol{V}$, 可以通过最小化目标函数 J_{FCM} 获得, 基于拉格朗日乘子方法, $\boldsymbol{U}$ 和 $\boldsymbol{V}$ 分别由下式计算:

$$u_{ig}^{(s)} = \frac{1}{\sum\limits_{r=1}^{b}\left(\frac{d_{ig}^{(s)}}{d_{rg}^{(s)}}\right)^{\frac{2}{m-1}}} \tag{17}$$

$$\boldsymbol{v}_i^{(s)} = \frac{\sum\limits_{g=1}^{n}\left(u_{ig}^{(s)}\right)^m \boldsymbol{p}_g}{\sum\limits_{g=1}^{n}\left(u_{ig}^{(s)}\right)^m} \tag{18}$$

为了使类间距离应尽可能大, 类内距离应尽可能小, 采用如下有效性函数衡量聚类效果, 自适应确定模糊聚类数目[30]:

$$L_{FCM}(b) = \frac{\sum\limits_{i=1}^{b}\sum\limits_{g=1}^{n} u_{ig}^m \frac{\|\boldsymbol{v}_i - \bar{\boldsymbol{p}}\|^2}{b-1}}{\sum\limits_{i=1}^{b}\sum\limits_{g=1}^{n} \frac{u_{ig}^m \|\boldsymbol{p}_g - \boldsymbol{v}_i\|^2}{n-b}} \tag{19}$$

上述有效性函数 $L_{FCM}(b)$ 表示类间距离之和与类内距离之和的比值, 所以, $L_{FCM}(b)$ 越大, 表示聚类结果越可靠. 当 $L_{FCM}(b)$ 达到最大值时, 聚类数目 b 为最佳聚类数目. 其中, $\bar{\boldsymbol{p}}$ 表示整体数据的中心向量:

$$\bar{\boldsymbol{p}} = \frac{1}{n}\sum_{i=1}^{b}\sum_{g=1}^{n} u_{ig}^m \boldsymbol{p}_g \tag{20}$$

自适应 FCM 算法通过最小化目标函数 J_{FCM} 的迭代过程来实现更新 $\boldsymbol{U}$ 和 $\boldsymbol{V}$, 具体步骤如下:

1) 分配初始值的聚类数目 $b = 2$、$L_{FCM}(1) = 0$、模糊指数 m、最大迭代次数 $I_{\max}$ 和阈值 ξ;

2) 根据隶属度的约束, 随机初始化模糊划分矩阵 $\boldsymbol{U}^{(0)}$;

3) 根据式 (18) 计算 b 类聚类质心 $\boldsymbol{V}^{(s)}$;

4) 根据式 (16) 计算目标函数 $J_{\rm FCM}^{(s)}$. 如果 $|J_{\rm FCM}^{(s)} - J_{\rm FCM}^{(s-1)}| < \xi$ 或 $s > I_{\max}$, 则转至步骤 6); 否则, 继续执行 $s = s + 1$;

5) 根据式 (17) 计算 $\boldsymbol{U}^{(s+1)}$, 返回步骤 3);

6) 计算 $L_{FCM}(b)$. 如果 $L_{FCM}(b-1) > L_{FCM}(b-2)$ 且 $L_{FCM}(b-1) > L_{FCM}(b)$, 则停止迭代; 否则, 执行 $b = b + 1$ 并转至步骤 3).

2.3　模型参数自适应更新

由于城市固体废弃物成分的不确定性、操作员操作水平的差异性以及外部干扰的随机性影响, 难以用离线的非线性预测模型准确刻画时变的 MSWI 动态过程. 此外, 当实际过程的结构参数发生变化时, 容易造成模型失配, 会导致预测模型输出和实际系统输出之间的误差增大, 进而影响预测控制效果. 为此, 在控制过程引入模型参数自适应更新策略[31], 在保证实际系统输出与预测模型输出间误差最小的同时, 让每一时刻预测模型参数的变化也尽可能小, 在线调节预测模型参数. 模型参数自适应更新的目标函数定义如下:

$$\begin{aligned} &\min L(t) = \frac{1}{2}(y_p(t) - y(t))^2 + \frac{1}{2}\gamma\sum_{a=1}^{n_\theta}(\Delta\boldsymbol{\theta}_a(t))^2 \\ &\text{s.t.}\quad y_p(t) = \sum_{j=1}^{k}\omega_j\phi_j(\boldsymbol{x}, \boldsymbol{c}_j) \\ &\Delta\boldsymbol{\theta}_a(t) = \boldsymbol{\theta}_a(t) - \boldsymbol{\theta}_a(t-1) \end{aligned} \tag{21}$$

式中, $\gamma > 0$ 为权系数, 用以控制参数的变化速度, $\boldsymbol{\theta}$ 为 FCM-RBF 预测模型中的参数 $\{\boldsymbol{c}, \omega, \delta\}$, n_θ 为模型参数的个数.

对式 (21) 可以采用如下梯度下降公式更新参数向量:

$$\boldsymbol{\theta}(t+1) = \boldsymbol{\theta}(t) - \lambda\frac{\partial L}{\partial \boldsymbol{\theta}} \tag{22}$$

式中, λ 为学习率, $\dfrac{\partial L}{\partial \boldsymbol{\theta}}$ 可计算如下:

$$\begin{aligned} \frac{\partial L(t)}{\partial \boldsymbol{c}_j} = &\ (y_p(t) - y(t))\frac{\omega_j}{\delta_j^2}\phi_j(\boldsymbol{x}, \boldsymbol{c}_j)(\boldsymbol{x} - \boldsymbol{c}_j) + \\ &\ \gamma[\boldsymbol{c}_j(t) - \boldsymbol{c}_j(t-1)] \end{aligned} \tag{23}$$

$$\begin{aligned} \frac{\partial L(t)}{\partial \delta_j} = &\ (y_p(t) - y(t))\frac{\omega_j}{\delta_j^3}\phi_j(\boldsymbol{x}, \boldsymbol{c}_j)\|\boldsymbol{x} - \boldsymbol{c}_j\|^2 + \\ &\ \gamma[\delta_j(t) - \delta_j(t-1)] \end{aligned} \tag{24}$$

$$\begin{aligned} \frac{\partial L(t)}{\partial \omega_j} = &\ (y_p(t) - y(t))\phi_j(\boldsymbol{x}, \boldsymbol{c}_j) + \\ &\ \gamma[\omega_j(t) - \omega_j(t-1)] \end{aligned} \tag{25}$$

当满足设定精度要求或最大迭代次数的更新终止条件后, 即可求得 t 时刻自适应调整后的预测模型参数.

3　烟气含氧量自适应预测控制过程

3.1　在线梯度优化控制

在线优化控制的基本思想是在 MPC 未来的控

制序列中, 选择当前的控制输入来最小化目标函数[32]. 目标函数由以下向量重新定义:

$$\hat{\boldsymbol{J}}(t) = \rho_1[\boldsymbol{r}(t) - \hat{\boldsymbol{y}}(t)]^{\rm T}[\boldsymbol{r}(t) - \hat{\boldsymbol{y}}(t)] + \rho_2(\Delta\boldsymbol{u}(t))^{\rm T}\Delta\boldsymbol{u}(t) \tag{26}$$

式中, $\boldsymbol{r}(t)$ 和 $\hat{\boldsymbol{y}}(t)$ 的维度为 $H_p \times 1$, $\Delta\boldsymbol{u}(t)$ 的维度为 $H_u \times 1$. ρ_1 和 ρ_2 是控制权重因子.

$$\boldsymbol{r}(t) = [r(t+1),\, r(t+2),\, \cdots,\, r\,(t+H_p)]^{\rm T}$$
$$\hat{\boldsymbol{y}}(t) = [\hat{y}(t+1),\, \hat{y}(t+2),\, \cdots,\, \hat{y}\,(t+H_p)]^{\rm T}$$
$$\Delta\boldsymbol{u}(t) = [\Delta u(t),\, \Delta u(t+1),\, \cdots,\, \Delta u\,(t+H_u-1)]^{\rm T}$$

为了最小化 $\hat{\boldsymbol{J}}(t)$, 使用简便的梯度下降方法更新控制输入序列 $\boldsymbol{u}(t)$:

$$\boldsymbol{u}(t+1) = \boldsymbol{u}(t) + \Delta\boldsymbol{u}(t) = \boldsymbol{u}(t) + \eta_2\left(-\frac{\partial\hat{\boldsymbol{J}}(t)}{\partial\boldsymbol{u}(t)}\right) \tag{27}$$

式中, $\eta_2 > 0$ 是梯度下降的学习率. 由式 (27) 易知:

$$\Delta\boldsymbol{u}(t) = \eta_2\left(-\frac{\partial\hat{\boldsymbol{J}}(t)}{\partial\boldsymbol{u}(t)}\right) \tag{28}$$

通过目标函数 $\hat{\boldsymbol{J}}(t)$, 对 $\boldsymbol{u}(t)$ 微分, 可得:

$$\frac{\partial\hat{\boldsymbol{J}}(t)}{\partial\boldsymbol{u}(t)} = -2\rho_1\left(\frac{\partial\hat{\boldsymbol{y}}(t)}{\partial\boldsymbol{u}(t)}\right)^{\rm T}[\boldsymbol{r}(t) - \hat{\boldsymbol{y}}(t)] + 2\rho_2\Delta\boldsymbol{u}(t) \tag{29}$$

将式 (29) 代入式 (28), 则:

$$\Delta\boldsymbol{u}(t) = 2\eta_2\left(\rho_1\left(\frac{\partial\hat{\boldsymbol{y}}(t)}{\partial\boldsymbol{u}(t)}\right)^{\rm T}[\boldsymbol{r}(t) - \hat{\boldsymbol{y}}(t)] - \rho_2\Delta\boldsymbol{u}(t)\right) \tag{30}$$

$$\Delta\boldsymbol{u}(t) = (1+2\eta_2\rho_2)^{-1}2\eta_2\rho_1\cdot \left(\left(\frac{\partial\hat{\boldsymbol{y}}(t)}{\partial\boldsymbol{u}(t)}\right)^{\rm T}[\boldsymbol{r}(t) - \hat{\boldsymbol{y}}(t)]\right) \tag{31}$$

$$\frac{\partial\hat{\boldsymbol{y}}(t)}{\partial\boldsymbol{u}(t)} = \begin{bmatrix} \dfrac{\partial\hat{y}(t+1)}{\partial u(t)} & 0 & \cdots & 0 \\ \dfrac{\partial\hat{y}(t+2)}{\partial u(t)} & \dfrac{\partial\hat{y}(t+2)}{\partial u(t+1)} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ \dfrac{\partial\hat{y}\,(t+H_p)}{\partial u(t)} & \dfrac{\partial\hat{y}\,(t+H_p)}{\partial u(t+1)} & \cdots & \dfrac{\partial\hat{y}\,(t+H_p)}{\partial u\,(t+H_u-1)} \end{bmatrix}_{H_p\times H_u} \tag{32}$$

式中, $\dfrac{\partial\hat{\boldsymbol{y}}(t)}{\partial\boldsymbol{u}(t)}$ 是雅可比矩阵, 可以从预测模型中得到, 令:

$$\boldsymbol{X}(t) = [y(t-1),\, y(t-2),\, \cdots,\, y(t-n_y),\, u(t-1),\, u(t-2),\, \cdots,\, u(t-n_u)]^{\rm T} \tag{33}$$

可得:

$$\frac{\partial\hat{y}(t+n)}{\partial u(t+m-1)} = \frac{\partial f[\boldsymbol{X}(t+n)]}{\partial u(t+m-1)} + \sum_{i=m}^{n-1}\frac{\partial f[\boldsymbol{X}(t+n)]}{\partial\hat{y}(t+i)}\left[\frac{\partial\hat{y}(t+i)}{\partial u(t+m-1)}\right] \tag{34}$$

式中, $n = 1,\, 2,\, \cdots,\, H_p$, $m = 1,\, 2,\, \cdots,\, H_u$. 由文献 [33] 可知, 式 (34) 可简化为:

$$\frac{\partial\hat{y}(t+n)}{\partial u(t+m-1)} = \frac{\partial\hat{y}(t+n-1)}{\partial u(t+m-1)}\left\{1 + \frac{\partial f[\boldsymbol{X}(t+n-1)]}{\partial\hat{y}(t+n-1)}\right\} \tag{35}$$

对于 RBF 网络:

$$\frac{\partial\hat{y}(t+n-1)}{\partial u(t+m-1)} = \frac{\omega_j}{\delta_j^2}\phi_j(\boldsymbol{x},\, \boldsymbol{c}_j)(\boldsymbol{x}-\boldsymbol{c}_j)\frac{{\rm d}\boldsymbol{X}}{{\rm d}\boldsymbol{u}} \tag{36}$$

$$\frac{\partial f(\boldsymbol{X})}{\partial\hat{y}(t+n-1)} = \frac{\omega_j}{\delta_j^2}\phi_j(\boldsymbol{x},\, \boldsymbol{c}_j)(\boldsymbol{x}-\boldsymbol{c}_j)\frac{{\rm d}\boldsymbol{X}}{{\rm d}\hat{\boldsymbol{y}}} \tag{37}$$

其中

$$\frac{{\rm d}\boldsymbol{X}}{{\rm d}\boldsymbol{u}} = [0,\, 0,\, \cdots,\, 0,\, 1,\, 0,\, \cdots,\, 0]^{\rm T}$$
$$\frac{{\rm d}\boldsymbol{X}}{{\rm d}\hat{\boldsymbol{y}}} = [1,\, 0,\, \cdots,\, 0,\, 0,\, 0,\, \cdots,\, 0]^{\rm T}$$

当控制时域 H_u 为 1 时, 预测控制器的计算量较少, 可以克服该控制方法在求解优化问题时需要进行较大的矩阵运算问题, 并取得令人满意的控制效果[34]. 因此, 本文设置 $H_u = 1$, 则式 (31) 可表示为:

$$\Delta\boldsymbol{u}(t) = \mu\left(\boldsymbol{g}^{\rm T}(t)\boldsymbol{E}(t)\right) \tag{38}$$

式中, $\boldsymbol{E}(t) = \boldsymbol{r}(t) - \hat{\boldsymbol{y}}(t)$.

$$\mu = (1+2\eta_2\rho_2)^{-1}2\eta_2\rho_1 \tag{39}$$

$$\boldsymbol{g}(t) = \frac{\partial\hat{\boldsymbol{y}}(t)}{\partial\boldsymbol{u}(t)} = \left[\frac{\partial\hat{y}(t+1)}{\partial u(t)},\, \frac{\partial\hat{y}(t+2)}{\partial u(t)},\, \cdots,\, \frac{\partial\hat{y}(t+H_p)}{\partial u(t)}\right]^{\rm T} \tag{40}$$

3.2 稳定性分析

需要指出的是, 用式 (31) 计算的最优控制输入序列必须满足稳定的 MPC 迭代过程. 控制权重参数 ρ_1 和 ρ_2 一般取正数, 控制律序列的学习率 η_2 只

影响优化速度, 而且 η_2 的波动与控制稳定性无关.

定理 1. 将 μ 定义为 FCM-RBF-MPC 优化过程的参数, 如式 (39) 所示, 如果其满足下式条件, 则该过程就是稳定的:

$$0 < \mu < \frac{2}{\lambda_{\max}\left(\boldsymbol{g}(t)\boldsymbol{g}^{\mathrm{T}}(t)\right)} \tag{41}$$

式中, $\lambda_{\max}$ 是 $\boldsymbol{g}(t)\boldsymbol{g}^{\mathrm{T}}(t)$ 的最大特征值.

证明. 为了分析稳定性, 定义如下的李雅普诺夫函数:

$$V_C(t) = \boldsymbol{E}^{\mathrm{T}}(t)\boldsymbol{E}(t) \tag{42}$$

则李雅普诺夫函数 V_C 的差分形式为:

$$\begin{aligned}\Delta V_C(t) = {}& V_C(t+1) - V_C(t) = \\ & \boldsymbol{E}^{\mathrm{T}}(t+1)\boldsymbol{E}(t+1) - \boldsymbol{E}^{\mathrm{T}}(t)\boldsymbol{E}(t) = \\ & (\boldsymbol{E}(t) + \Delta\boldsymbol{E}(t))^{\mathrm{T}}(\boldsymbol{E}(t) + \Delta\boldsymbol{E}(t)) - \\ & \boldsymbol{E}^{\mathrm{T}}(t)\boldsymbol{E}(t) = \Delta\boldsymbol{E}^{\mathrm{T}}(t)(2\boldsymbol{E}(t) + \Delta\boldsymbol{E}(t))\end{aligned} \tag{43}$$

易知, $\boldsymbol{E}(t)$ 的时间导数为:

$$\Delta\boldsymbol{E}(t) = \frac{\partial\boldsymbol{E}(t)}{\partial\boldsymbol{u}(t)}\Delta\boldsymbol{u}(t) = -\frac{\partial\hat{\boldsymbol{y}}(t)}{\partial\boldsymbol{u}(t)}\Delta\boldsymbol{u}(t) \tag{44}$$

将式 (44) 代入式 (43), 可得:

$$\begin{aligned}\Delta V_C(t) = {}& \left(-\frac{\partial\hat{\boldsymbol{y}}(t)}{\partial\boldsymbol{u}(t)}\Delta\boldsymbol{u}(t)\right)^{\mathrm{T}}\left(2\boldsymbol{E}(t) - \frac{\partial\hat{\boldsymbol{y}}(t)}{\partial\boldsymbol{u}(t)}\Delta\boldsymbol{u}(t)\right) = \\ & -\mu\big(\boldsymbol{g}(t)\boldsymbol{g}^{\mathrm{T}}(t)\boldsymbol{E}(t)\big)^{\mathrm{T}}(2\boldsymbol{E}(t) - \\ & \mu\boldsymbol{g}(t)\boldsymbol{g}^{\mathrm{T}}(t)\boldsymbol{E}(t)) = -\mu\boldsymbol{E}^{\mathrm{T}}(t)\boldsymbol{g}(t)\boldsymbol{g}^{\mathrm{T}}(t) \times \\ & \left(2I - \mu\boldsymbol{g}(t)\boldsymbol{g}^{\mathrm{T}}(t)\right)\boldsymbol{E}(t)\end{aligned} \tag{45}$$

式中, I 是一个 H_p 阶的单位矩阵. □

引理 1. 定义矩阵函数 $(kI - A)\boldsymbol{X} = 0$, 其中 A 是 $H_p \times H_p$ 阶的对称矩阵, $\boldsymbol{X}$ 是 $H_p \times 1$ 阶的向量. 则 A 的特征值可以表示为 $k(a) = [k_1, k_2, \cdots, k_{H_P}]^{\mathrm{T}}$, 其中 $k_1 \geq k_2 \geq \cdots \geq k_{H_P}$.

利用式 (45) 和引理 1, 根据式 (41) 设置最优参数 μ, 可得 $\Delta V_C(t) < 0$. 根据李雅普诺夫稳定性理论, 采用一阶梯度优化方法的 FCM-RBF-MPC 过程是稳定的.

3.3 实现步骤

本文以特定工况下的 MSWI 数据驱动过程模型为研究对象, 借助现场运行数据, 首先, 建立基于 FCM-RBF 网络的烟气含氧量预测模型, 使用自适应 FCM 算法, 确定 RBF 网络隐含层神经元个数及初始中心; 其次, 通过反馈校正环节对预测模型结果进行修正, 并采用模型参数自适应更新策略在线更新预测模型参数; 最后, 采用梯度下降方法, 在线求解每一时刻的最优控制量. 烟气含氧量自适应预测控制算法的实现步骤如下:

1) 选择合适的参数. 包括 RBF 神经网络参数如学习率 η_1、网络权值等; 控制参数如预测时域 H_p, 控制时域 H_u, 参考值调整因子 a_r, 控制权重因子 ρ_1、ρ_2, 控制输入的学习率 η_2 和模型参数自适应更新学习率 λ.

2) 选择特定工况下分散控制系统采集的输入/输出数据构成样本集, 划分为训练集和测试集, 并进行数据归一化处理. 使用自适应 FCM 算法确定 RBF 神经网络隐含层神经元个数及初始中心, 离线训练 FCM-RBF 神经网络预测模型.

3) 给定烟气含氧量的设定值, 并通过式 (2) 计算参考估计 $y_r(t+i)$, $i = 1, 2, \cdots, H_p$. 根据已知的系统控制量 $\boldsymbol{u}(t)$, 系统实际输出 $y(t)$, 计算实际输出与预测输出之间的偏差 $err(t)$.

4) 在第 $t+1$ 时刻, 基于历史输入/输出数据, 通过 FCM-RBF 网络预测模型, 可迭代求得预测输出 $y_p(t+i)$, 然后通过偏差 $err(t)$ 修正该预测输出.

5) 在预测时域 H_p 内, 使用梯度下降方法得到雅可比矩阵 $\dfrac{\partial\hat{\boldsymbol{y}}(t)}{\partial\boldsymbol{u}(t)}$, 依据式 (31) 计算控制时域 H_u 内的控制增量序列 $\Delta\boldsymbol{u}$, 并代入被控对象的数据驱动模型, 得到系统实际输出.

6) 利用梯度下降法求解式 (21) 预测模型参数自适应优化问题, 更新 FCM-RBF 预测模型参数.

7) 返回步骤 3), 重复整个过程.

4 仿真实验与分析

本文使用的数据来自于现场分散控制系统采集的 3800 组实测数据, 采样间隔时间为 1 s. 选取 2660 组数据 (占 70%) 作为训练样本, 1140 组数据 (占 30%) 作为测试样本, 建立基于自适应 FCM-RBF 网络的离线预测模型, 并在控制过程中采用模型参数自适应更新策略在线更新模型. 为评估本文控制方法的有效性, 利用带有外部干扰的城市固废焚烧过程烟气含氧量控制实验进行实验验证.

4.1 自适应 FCM-RBF 网络的烟气含氧量预测性能

由于 MSW 成分繁杂和焚烧过程的不确定性, 实际 MSWI 过程的运行情况复杂多变. MSW 质量流量和负荷波动是工况变化的重要表现, 但是现场很难直接获得具体数值. 而给料速度调节量和炉排速度调节量能够间接表征 MSW 质量流量和负荷变

化, 从而识别不同工况. 其中, 炉排速度调节量又分为干燥炉排、燃烧炉排 1、燃烧炉排 2 和燃烬炉排共 4 个区间, 每段炉排下方分别对应有一次风流量分量. 为设计和说明方便, 本文仅对给料速度和各阶段炉排速度调节量稳定时的一种典型工况进行建模研究. 在该种工况下, 烟气含氧量 (y_o) 被限定为主要与风量, 即干燥炉排一次风流量 x_{p1} 、燃烧炉排 1 一次风流量 x_{p2} 、燃烧炉排 2 一次风流量 x_{p3} 、燃烬炉排一次风流量 x_{p4} 和二次风流量 x_s 有关. 所选输入/输出变量数据变化范围见表 1.

表 1 输入/输出变量变化范围

Table 1 Range of input and output variables

变量名	变量符号	变化范围
干燥炉排一次风流量 (km³/h)	x_{p1}	10.75 ~ 14.76
燃烧炉排 1 一次风流量 (km³/h)	x_{p2}	25.90 ~ 35.56
燃烧炉排 2 一次风流量 (km³/h)	x_{p3}	11.25 ~ 15.72
燃烬炉排一次风流量 (km³/h)	x_{p4}	2.27 ~ 5.06
二次风流量 (km³/h)	x_s	18.91 ~ 21.84
烟气含氧量 (%)	y_o	4.6 ~ 7.6

为避免输入变量物理意义和单位不同对结果的影响, 需要首先进行数据归一化预处理. 此外, 选取合适且精简的特征变量是模型准确构建的前提, 操作变量与烟气含氧量的皮尔森相关系数 γ 如表 2 所示, 需要剔除 [−0.11, 0.11] 范围内相关性弱的变量, 即最终选择干燥炉排一次风流量 x_{p1} 、燃烧炉排 1 一次风流量 x_{p2} 和二次风流量 x_s 作为特定工况下的操作变量, 烟气含氧量 y_o 作为被控变量.

表 2 操作变量与烟气含氧量的皮尔森相关系数

Table 2 Pearson correlation coefficient between manipulated variables and oxygen content in flue gas

操作变量名	操作变量符号	γ
干燥炉排一次风流量	x_{p1}	−0.4303
燃烧炉排 1 一次风流量	x_{p2}	0.3015
燃烧炉排 2 一次风流量	x_{p3}	−0.1034
燃烬炉排一次风流量	x_{p4}	0.0697
二次风流量	x_s	0.1413

在建立烟气含氧量预测模型时, 选取模型输入/输出阶数 $n_y = n_u = 2$, 则预测模型的输入变量可写为如下形式:

$$x(t) = [y(t-1),\ y(t-2),\ u_1(t-1),\ u_1(t-2),\\ u_2(t-1),\ u_2(t-2),\ u_3(t-1),\ u_3(t-2)] \tag{46}$$

通过试凑法确定, 设置自适应 FCM 算法模糊指数 m 为 5, 最大迭代次数 $I_{\max}$ 为 100, 阈值 ξ 为 0.00001, 最终得到最优聚类数目 b 为 26. 将该最优聚类数目作为 RBF 网络隐含层神经元个数, 聚类中心作为神经元的初始中心. 初始权值、宽度随机设置, 学习率 $\eta_1 = 0.05$, 训练的期望均方误差 (Mean square error, MSE) 设为 0.01, 最大训练步数为 200 步, 采用梯度下降法对该网络进行训练. 本文 FCM-RBF 神经网络与多层感知机 (Multi-layered perceptron, MLP) 神经网络、RBF 神经网络的烟气含氧量预测效果如图 4 所示.

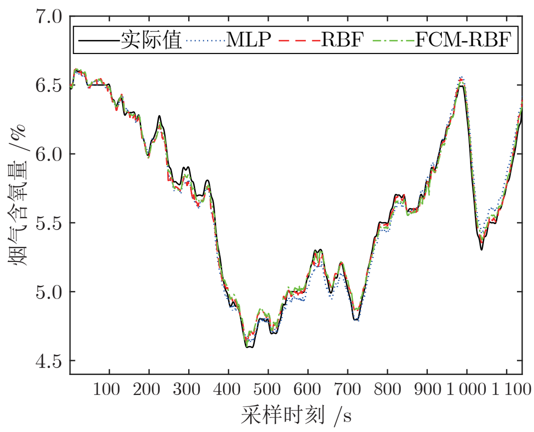

图 4 不同建模方法的烟气含氧量预测效果

Fig. 4 Prediction effect of oxygen content in flue gas with different modeling methods

由图 4 可以看出, RBF 神经网络和 FCM-RBF 神经网络的烟气含氧量预测准确性均优于 MLP 神经网络, 但在波峰和波谷位置, 两种网络仍有较明显的预测偏差. 为了进一步验证 FCM-RBF 神经网络预测烟气含氧量的有效性, 采用均方根误差 (Root mean square error, RMSE)、平均绝对百分比误差 (Mean absolute percentage error, MAPE) 和平均绝对误差 (Mean absolute error, MAE) 评估预测性能. 表 3 列出了不同模型独立运行 30 次的预测性能指标平均值.

$$\text{RMSE} = \sqrt{\frac{1}{Q}\sum_{t=1}^{Q}(y_d(t) - y_p(t))^2} \tag{47}$$

$$\text{MAPE} = \frac{1}{Q}\sum_{t=1}^{Q}\left|\frac{y_d(t) - y_p(t)}{y_d(t)}\right| \tag{48}$$

表 3 不同建模方法的烟气含氧量预测评价指标对比

Table 3 Comparison of prediction evaluation indexes of oxygen content in flue gas with different modeling methods

模型	MAE	MAPE	RMSE
MLP	0.0467	0.0086	0.0585
RBF	0.0357	0.0065	0.0449
FCM-RBF	**0.0307**	**0.0056**	**0.0417**

$$\mathrm{MAE}=\frac{1}{Q}\sum_{t=1}^{Q}|y_d(t)-y_p(t)| \tag{49}$$

式中, $y_d(t)$、$y_p(t)$ 和 Q 分别为观测值、预测值和样本数.

在表 3 中, FCM-RBF 神经网络预测烟气含氧量的 MAE、MAPE 和 RMSE 分别为 0.0307、0.0056 和 0.0417, 与 MLP 神经网络和 RBF 神经网络相比, FCM-RBF 神经网络的预测性能指标有明显提升. 这是因为自适应 FCM 算法能够帮助确定较优的 RBF 神经网络隐含层神经元个数及初始中心, 降低随机初始中心带来的不确定性, 提高 RBF 神经网络的预测精度. 该模型能够为模型预测控制提供反映 MSWI 过程烟气含氧量动态特性的精准预测模型.

4.2 自适应 FCM-RBF-MPC 的烟气含氧量控制性能

为了验证本文的自适应 FCM-RBF-MPC 方法的有效性, 对比了基于不同 RBF 神经网络预测模型的烟气含氧量控制效果. 选取预测时域 H_p 为 5, 控制时域 H_u 为 1, 参考值调整因子 a_r 为 0.1, 控制权重因子 ρ_1 和 ρ_2 为 1 和 150, 控制输入的学习率 η_2 为 0.1, 参数自适应更新学习率 λ 为 0.05, 最大更新步数为 200 步, 模型更新的期望均方误差设为 0.01, 控制时间间隔为 1 s. 由于 MSWI 实际过程存在不确定性干扰, 为了模拟这种情况, 在 100 s 和 300 s 处起分别施加幅值为 0.2 和 0.5 的干扰 $v(t)$ 如下:

$$v(t)=\begin{cases}0, & 0<t\le 100\\ 0.2, & 100<t\le 300\\ 0.5, & 300<t\le 400\end{cases} \tag{50}$$

考虑焚烧过程动态特性的非线性和不确定性, 需要跟随变化的烟气含氧量设定值, 并自适应调整控制器输出. 为了测试本文设计的自适应 FCM-RBF-MPC 控制有效性, 对比实验选取了采用 RBF、FCM-RBF 和自适应 RBF 神经网络作为预测模型的数据驱动 MPC. 烟气含氧量变设定值的 FCM-RBF-MPC 和自适应 FCM-RBF-MPC 控制器跟踪效果如图 5 所示, 操作变量具体变化如图 6 所示, 反馈校正误差补偿变化情况如图 7 所示. 由图 5 可以看出, 与 FCM-RBF-MPC 方法相比, 自适应 FCM-RBF-MPC 方法能够更及时地给出准确的控制输出, 使系统能够更快地跟踪烟气含氧量的参考轨迹. 由图 7 可以看出, 预测误差 $err(t)$ 在控制起始阶段、设定值变化阶段和干扰施加初始阶段的变化比较明显, 说明这些阶段中的模型自适应更新预测结果与实际值仍存在较大偏差. 当达到模型自适应更新的终止条件, 而预测结果与实际值仍存在偏差时, 反馈校正可以作为模型自适应更新的误差补偿来修正预测结果.

此外, 采用绝对误差积分 (Integral of absolute error, IAE)[35] 、绝对误差与时间乘积积分 (Integral time absolute error, ITAE)[35] 和最大绝对误差 (Maximal deviation from set-point, Dev$^{\max}$)[36] 评价控制效果, 具体公式如下:

$$\mathrm{IAE}=\frac{1}{K}\sum_{t=1}^{K}|e_{OC}(t)| \tag{51}$$

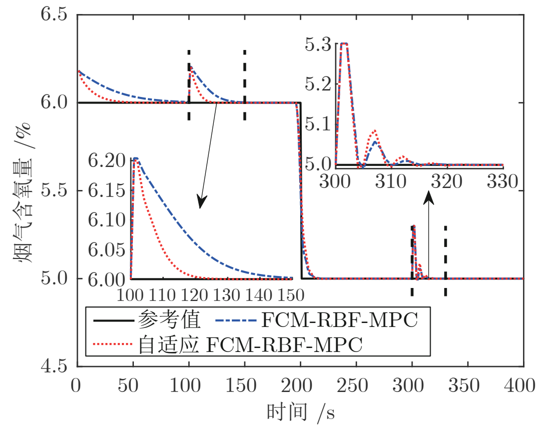

图 5 FCM-RBF-MPC 和自适应 FCM-RBF-MPC 控制效果

Fig.5 Control results of FCM-RBF-MPC and adaptive FCM-RBF-MPC

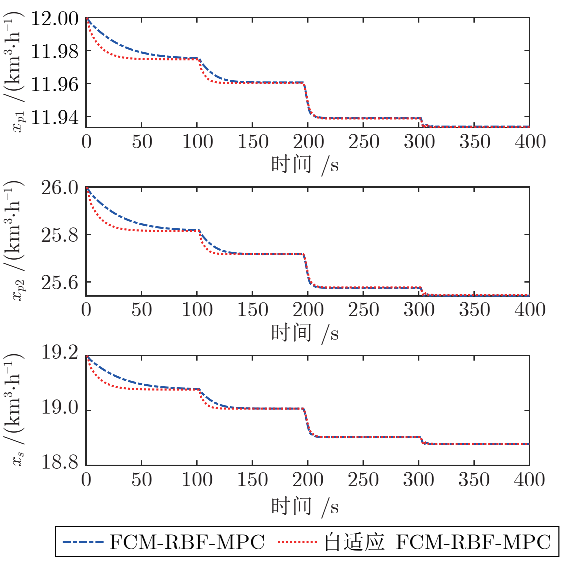

图 6 FCM-RBF-MPC 和自适应 FCM-RBF-MPC 的操作变量变化情况

Fig.6 Changes of manipulated variables of FCM-RBF-MPC and adaptive FCM-RBF-MPC

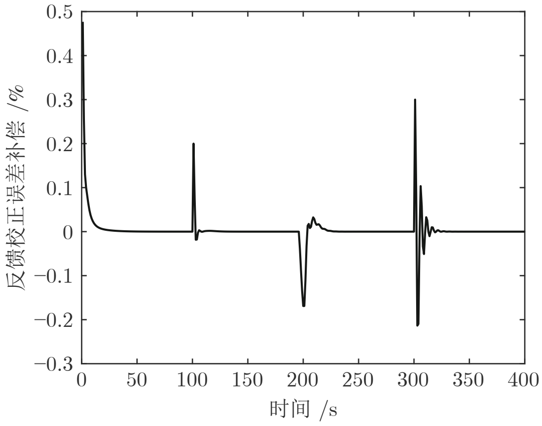

图 7 反馈校正误差补偿变化情况

Fig. 7 Changes of feedback correction error compensation

$$\text{ITAE} = \frac{1}{K}\sum_{t=1}^{K} t\,|e_{OC}(t)| \tag{52}$$

$$\text{Dev}^{\max} = \max\{|e_{OC}|\} \tag{53}$$

式中, K 是样本总数, e_{OC} 代表烟气含氧量参考值与真实输出值之间的误差.

表 4 给出了不同 RBF 神经网络预测控制器用于烟气含氧量控制的评价指标对比结果. 可以看出, 自适应 FCM-RBF-MPC 的 IAE、ITAE 和 $\text{Dev}^{\max}$ 分别为 0.0031、2.4152 和 0.4226, 与 FCM-RBF-MPC 算法相比, 分别降低了 27.90%、19.50% 和 14.61%; 与自适应 RBF-MPC 算法相比, 分别降低了 31.11%、30.23% 和 2.51%. 结果表明, 在给定的烟气含氧量变设定值情况下, 本文提出的自适应 FCM-RBF-MPC 方法具有更好的自适应性和抑制干扰能力, 能够对烟气含氧量实现更精准的控制.

表 4 不同 RBF 神经网络预测控制器性能指标对比

Table 4 Comparison of evaluation indexes of different RBF neural network predictive controllers

控制器	IAE	ITAE	$\text{Dev}^{\max}$
RBF-MPC	0.0056	4.3874	0.4991
FCM-RBF-MPC	0.0043	3.0002	0.4949
自适应 RBF-MPC	0.0045	3.4617	0.4335
自适应 FCM-RBF-MPC	**0.0031**	**2.4152**	**0.4226**

5 结束语

面向 MSWI 过程烟气含氧量精准控制需求, 本文提出一种自适应模型预测控制方法. 首先, 为降低随机初始 RBF 隐含层神经元个数及初始中心带来的不确定性, 建立基于数据驱动的自适应 FCM-RBF 神经网络烟气含氧量预测模型; 其次, 在控制过程中采用模型参数自适应调节策略, 提高了预测模型的动态自适应性; 接着, 利用梯度下降方法方便快速地求解 MPC 控制律, 并基于李雅普诺夫稳定性理论证明了控制系统的稳定性; 最后, 基于 MSWI 厂实际数据建模和控制实验, 表明本文自适应 FCM-RBF 网络建模方法具有较高的预测精度, 本文自适应 FCM-RBF-MPC 方法相对于其他 RBF 神经网络预测控制器, 具有更好的设定值跟踪性能, 验证了该方法在干扰存在情况下, 仍然具有很好的自适应控制能力. 后续将进一步研究该方法的节能应用效果和预测模型结构在线自适应调整机制捕获更多未知工况.

References

1 Maalouf A, Mavropoulos A, El-Fadel M. Global municipal solid waste infrastructure: Delivery and forecast of uncontrolled disposal. *Waste Management and Research*, 2020, **38**(9): 1028−1036

2 *China Statistical Yearbook*. Beijing: China Statistics Press, 2019.
(中国统计年鉴. 北京: 中国统计出版社, 2019.)

3 Long Wen, Liang Xi-Ming, Long Zu-Qiang. O_2 content in flue gas of boilers predictive control based on hybrid PSO and LSSVM. *Journal of Central South University (Science and Technology)*, 2012, **43**(3): 980−985
(龙文, 梁昔明, 龙祖强. 基于混合 PSO 优化的 LSSVM 锅炉烟气含氧量预测控制. 中南大学学报 (自然科学版), 2012, **43**(3): 980−985)

4 Zhang Y J, Jia Y, Chai T Y, Wang D H, Jun Fu J. Data-driven PID controller and its application to pulp neutralization process. *IEEE Transactions on Control Systems Technology*, 2017, **26**(3): 828−841

5 Moura J P, Neto J V F, Rêgo P H M. A neuro-fuzzy model for online optimal tuning of PID controllers in industrial system applications to the mining sector. *IEEE Transactions on Fuzzy Systems*, 2019, **28**(8): 1864−1877

6 Nath U M, Dey C, Mudi R K. Desired characteristic equation based PID controller tuning for lag-dominating processes with real-time realization on level control system. *IEEE Control Systems Letters*, 2021, **5**(4): 1255−1260

7 Li D P, Han H G, Qiao J F. Observer-based adaptive fuzzy control for nonlinear state-constrained systems without involving feasibility conditions. *IEEE Transactions on Cybernetics*, 2022, **52**(11): 11724−11733

8 Nguyen A T, Taniguchi T, Eciolaza L, Campos V, Sugeno M. Fuzzy control systems: Past, present and future. *IEEE Computational Intelligence Magazine*, 2019, **14**(1): 56−68

9 Shen D. Iterative learning control with incomplete information: A survey. *IEEE/CAA Journal of Automatica Sinica*, 2018, **5**(5): 1−17

10 Zhao Gang, Li Bin. Simulation on the optimal control of gas boiler combustion efficiency. *Computer Simulation*, 2017, **34**(1): 376−379
(赵钢, 李斌. 燃气锅炉燃烧效率优化控制仿真研究. 计算机仿真, 2017, **34**(1): 376−379)

11 Zhang R D, Cao Z X, Li P, Gao F. Design and implementation of an improved linear quadratic regulation control for oxygen content in a coke furnace. *IET Control Theory and Applications*, 2014, **8**(14): 1303−1311

12 Thai S M, Wilcox S J, Chong A Z S, Ward J. Combustion optimisation of stoker fired boiler plant by neural networks. *Journal of the Energy Institute*, 2008, **81**(3): 171−176

13 Xi Yu-Geng, Li De-Wei, Lin Shu. Model predictive control —— Status and challenges. *Acta Automatica Sinica*, 2013, **39**(3): 222−236

(席裕庚, 李德伟, 林姝. 模型预测控制 —— 现状与挑战. 自动化学报, 2013, **39**(3): 222−236)

14 Karamanakos P, Liegmann E, Geyer T, Kennel R. Model predictive control of power electronic systems: Methods, results, and challenges. *IEEE Open Journal of Industry Applications*, 2020, **1**: 95−114

15 He De-Feng, Ding Bao-Cang, Yu Shu-You. Review of fundamental properties and topics of model predictive control for nonlinear systems. *Control Theory and Applications*, 2013, **30**(3): 273−287
(何德峰, 丁宝苍, 于树友. 非线性系统模型预测控制若干基本特点与主题回顾. 控制理论与应用, 2013, **30**(3): 273−287)

16 Zhang R D, Jin Q B. Design and implementation of hybrid modeling and PFC for oxygen content regulation in a coke furnace. *IEEE Transactions on Industrial Informatics*, 2018, **14**(6): 2335−2342

17 Huang X Y, Wang J C, Zhang L W, Wang B H. Data-driven modelling and fuzzy multiple-model predictive control of oxygen content in coal-fired power plant. *Transactions of the Institute of Measurement and Control*, 2017, **39**(11): 1631−1642

18 Wang P, Yang C H, Tian X M, Huang D X. Adaptive nonlinear model predictive control using an online support vector regression updating strategy. *Chinese Journal of Chemical Engineering*, 2014, **22**(7): 774−781

19 Xiao H Z, Chen C L P. Incremental updating multi-robot formation using nonlinear model predictive control method with general projection neural network. *IEEE Transactions on Industrial Electronics*, 2019, **66**(6): 4502−4512

20 Chen Jin-Dong, Pan Feng. Online support vector regression-based nonlinear model predictive control. *Control and Decision*, 2014, **29**(3): 460−464
(陈进东, 潘丰. 基于在线支持向量回归的非线性模型预测控制方法. 控制与决策, 2014, **29**(3): 460−464)

21 Vatankhah B, Farrokhi M. Nonlinear adaptive model predictive control of constrained systems with offset-free tracking behavior. *Asian Journal of Control*, 2018, **20**(1): 1−13

22 Wu Z, Rincon D, Christofides P D. Real-time adaptive machine-learning-based predictive control of nonlinear processes. *Industrial and Engineering Chemistry Research*, 2020, **59**: 2275−2290

23 Lu J W, Zhang S K, Hai J, Lei M. Status and perspectives of municipal solid waste incineration in China: A comparison with developed regions. *Waste Management*, 2017, **69**: 170−186

24 Tan S T, Ho W S, Hashim H, Lee C T, Taib M R, Ho C S. Energy, economic and environmental (3E) analysis of waste-to-energy (WTE) strategies for municipal solid waste (MSW) management in Malaysia. *Energy Conversion and Management*, 2015, **102**: 111−120

25 Qiao Jun-Fei, Guo Zi-Hao, Tang Jian. Dioxin emission concentration measurement approaches for municipal solid wastes incineration process: A survey. *Acta Automatica Sinica*, 2020, **46**(6): 1063−1089
(乔俊飞, 郭子豪, 汤健. 面向城市固废焚烧过程的二噁英排放浓度检测方法综述. 自动化学报, 2020, **46**(6): 1063−1089)

26 Xie S W, Xie Y F, Huang T W, Gui W H, Yang C H. Generalized predictive control for industrial processes based on neuron adaptive splitting and merging RBF neural network. *IEEE Transactions on Industrial Electronics*, 2019, **66**(2): 1192−1202

27 Zhou P, Guo D W, Chai T Y. Data-driven predictive control of molten iron quality in blast furnace iron-making using multi-output LS-SVR based inverse system identification. *Neuro Computing*, 2018, **308**: 101−110

28 Qiao J F, Meng X, Li W J, Wilamowski B M. A novel modular RBF neural network based on a brain-like partition method. *Neural Computing and Applications*, 2018, **32**: 899−911

29 Ren M, Liu P Y, Wang Z H, Yi J. A self-adaptive fuzzy C-means algorithm for determining the optimal number of clusters. *Computational Intelligence and Neuroscience*, 2016: Article No. 2647389

30 Li Y, Yu F. A new validity function for fuzzy clustering. In: Proceedings of the International Conference on Computational Intelligence and Natural Computing. Wuhan, China: IEEE, 2009. 462−465

31 Ren Jun-Chao, Liu Ding, Wan Yin. Hybrid integrated modeling based adaptive nonlinear predictive control of silicon single crystal diameter. *Acta Automatica Sinica*, 2020, **6**(5): 1004−1016
(任俊超, 刘丁, 万银. 基于混合集成建模的硅单晶直径自适应非线性预测控制. 自动化学报, 2020, **6**(5): 1004−1016)

32 Han H G, Wu X L, Qiao J F. Real-time model predictive control using a self-organizing neural network. *IEEE Transactions on Neural Networks and Learning Systems*, 2013, **24**(9): 1425−1436

33 Noriega J R, Wang H. A direct adaptive neural-network control for unknown nonlinear systems and its application. *IEEE Transactions on Neural Networks*, 1998, **9**(1): 27−34

34 Lu C H. Wavelet fuzzy neural networks for identification and predictive control of dynamic systems. *IEEE Transactions on Industrial Electronics*, 2011, **58**(7): 3046−3058

35 Hou Z S, Xiong S S. On model-free adaptive control and its stability analysis. *IEEE Transactions on Automatic Control*, 2019, **64**(11): 4555−4569

36 Han H G, Liu H X, Li J M, Qiao J F. Cooperative fuzzy-neural control for wastewater treatment process. *IEEE Transactions on Industrial Informatics*, 2021, **17**(9): 5971−5981

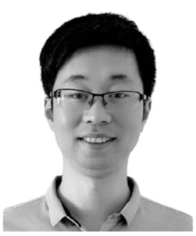

孙　剑　北京工业大学信息学部博士研究生. 主要研究方向为复杂工业过程数据驱动建模与智能控制.
E-mail: sun8927@163.com
(**SUN Jian**　Ph.D. candidate at the Faculty of Information Technology, Beijing University of Technology. His research interest covers data-driven modeling and intelligent control of complex industrial processes.)

蒙　西　北京工业大学信息学部副教授. 主要研究方向为神经网络, 学习系统和工业过程建模与控制.
E-mail: mengxi@bjut.edu.cn
(**MENG Xi**　Associate professor at the Faculty of Information Technology, Beijing University of Technology. Her research interest covers neural networks, learning systems, and industrial process modeling and control.)

乔俊飞　北京工业大学信息学部教授. 主要研究方向为神经网络, 智能系统和复杂工业过程建模与优化控制. 本文通信作者.
E-mail: adqiao@bjut.edu.cn
(**QIAO Jun-Fei**　Professor at the Faculty of Information Technology, Beijing University of Technology. His research interest covers neural networks, intelligent systems, and modeling and optimal control of complex industrial processes. Corresponding author of this paper.)