

城市固废焚烧过程数据驱动建模与自组织控制

丁海旭^{1,2} 汤健^{1,2} 乔俊飞^{1,2}

摘要 城市固废焚烧 (Municipal solid waste incineration, MSWI) 是处置城市固废 (Municipal solid waste, MSW) 的主要手段之一. 中国 MSW 来源范围广、组分复杂、热值波动大, 其焚烧过程通常依靠人工干预, 这导致 MSWI 过程智能化水平较低且难以满足日益提升的控制需求. MSWI 具有多变量耦合、工况漂移等诸多不确定性特征, 因而难以建立其被控对象模型并设计在线控制器. 针对以上问题, 提出了一种面向 MSWI 过程的数据驱动建模与自组织控制方法. 首先, 构建了基于多输入多输出 Takagi Sugeno 模糊神经网络 (Multi-input multi-output Takagi Sugeno fuzzy neural network, MIMO-TSFNN) 的被控对象模型; 然后, 设计了基于多任务学习的自组织模糊神经网络控制器 (Multi-task learning self-organizing fuzzy neural network controller, MTL-SOFNNC) 用于同步控制炉膛温度与烟气含氧量, 其通过计算神经元的相似性与多任务学习 (Multi-task learning, MTL) 能力对控制器结构进行自组织调整; 接着, 通过 Lyapunov 定理对 MTL-SOFNNC 稳定性进行了证明; 最后, 通过北京市某 MSWI 厂的过程数据验证了模型与控制器的有效性.

关键词 城市固废焚烧, 多任务学习, 自组织控制, 数据驱动建模, 模糊神经网络

引用格式 丁海旭, 汤健, 乔俊飞. 城市固废焚烧过程数据驱动建模与自组织控制. 自动化学报, 2023, 49(3): 550–566

DOI 10.16383/j.aas.c220570

Data-driven Modeling and Self-organizing Control of Municipal Solid Waste Incineration Process

DING Hai-Xu^{1,2} TANG Jian^{1,2} QIAO Jun-Fei^{1,2}

Abstract Municipal solid waste incineration (MSWI) is one of the main means to dispose of municipal solid waste (MSW). MSW in China has a wide range of sources, complex components, and large fluctuations in calorific value. Its incineration process usually relies on manual intervention. This will lead to a low degree of intelligence in the MSWI process and it is difficult to meet the increasing control requirements. MSWI has many uncertain characteristics such as multivariable coupling and working condition drift, so it is difficult to build the model of controlled object and design the on-line controller. To solve the above problems, this paper proposes a data-driven modeling and self-organizing control method for MSWI process. Firstly, the model of controlled object based on multi-input multi-output Takagi Sugeno fuzzy neural network (MIMO-TSFNN) is constructed. Secondly, a multi-task learning self-organizing fuzzy neural network controller (MTL-SOFNNC) is designed to synchronously control the furnace temperature and flue gas oxygen content, which can self-organize the structural parameters of the controller by calculating the similarity of neurons and the ability of multi-task learning (MTL). Meanwhile, the stability of MTL-SOFNNC is proved by Lyapunov theorem. Finally, the effectiveness of the model and controller is verified by the process data of an MSWI plant in Beijing.

Key words Municipal solid waste incineration (MSWI), multi-task learning (MTL), self-organizing control, data-driven modeling, fuzzy neural network

Citation Ding Hai-Xu, Tang Jian, Qiao Jun-Fei. Data-driven modeling and self-organizing control of municipal solid waste incineration process. *Acta Automatica Sinica*, 2023, 49(3): 550–566

收稿日期 2022-07-12 录用日期 2022-09-01

Manuscript received July 12, 2022; accepted September 1, 2022
科技创新 2030 —— “新一代人工智能”重大项目 (2021ZD0112300), 国家自然科学基金创新群体项目 (62021003), 国家科技重大专项 (61890930), 国家自然科学基金 (62073006), 北京市自然科学基金 (4212032, 4192009) 资助

Supported by Science and Technology Innovation 2030 —— “New Generation Artificial Intelligence” Major Project of China (2021ZD0112300), Innovative Research Group Project of the National Natural Science Foundation of China (62021003), National Science and Technology Major Project of China (61890930), National Natural Science Foundation of China (62073006), and Natural Science Foundation of Beijing (4212032, 4192009)

本文责任编辑 杨涛

随着我国工业化和城镇化建设的推进, 截至 2019 年底, 中国设市城市已达到 684 个, 城镇常住人口已占据总人口数的 60.6%, 城市发展已从大规模增量建设转为存量提质改造和增量结构调整并重的新阶段^[1]. 伴随着城市人口的增长, 城市固体废物弃

Recommended by Associate Editor YANG Tao

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

1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124 2. Beijing Laboratory of Smart Environmental Protection, Beijing 100124

物 (Municipal solid waste, MSW) 也在急剧增加。截至 2018 年, 全世界 MSW 年产生量已达到 20.1 亿吨, 其中 33% 没有得到妥善处理。预计到 2050 年, 其年产生量将达到 34 亿吨^[2-3]。目前, 我国多数城市已没有足够的垃圾填埋场用于处理体量如此庞大的 MSW, 如何合理处置 MSW 已成为当前中国城市发展面临的主要问题之一^[4-5]。城市固废焚烧 (Municipal solid waste incineration, MSWI) 法具有减容效果好、消毒彻底、资源利用率高、占地面积小等优势^[6-8], 已逐渐成为中国大中型城市处理 MSW 的主要技术手段^[9-10]。国家发改委、住建部在《“十四五”全国城镇生活垃圾无害化处理设施建设规划》中明确提出: 到 2025 年底, 全国城市生活垃圾资源化利用率达到 60% 左右, 全国城镇生活垃圾焚烧处理能力达到 80 万吨/日左右, 城市生活垃圾焚烧处理能力占比 65% 左右^[11]。

我国 MSWI 技术发展始于 20 世纪 80 年代, 受制于部分发达国家的技术封锁, 其发展经历了将火力发电厂改造为 MSWI 发电厂、引进国外焚烧炉并聘请外籍专家、自主研发国产焚烧设备三个阶段^[12]。中国 MSW 处理行业经历了数十年的发展, 整体发展迅速, 实现了跨越式发展。但仍有许多城市的 MSW 处理率处于低水平状态, 缺乏有效的处理处置手段, 先进技术与落后技术共存, MSW 处理的区域发展很不平衡。众多内地城市也开始引进国内外先进的焚烧工艺和设备处理 MSW。整体来说, 中国 MSWI 技术正向着多功能、资源化、智能化、环保高标准化方向发展, 但是中国垃圾分类正在起步阶段, 且存在垃圾清运能力增速不足、城乡发展不均衡等诸多问题。此外, 国内尚未掌握成熟的 MSWI 技术, 在建设与运行中均缺乏可靠的技术支撑, 这都为我国 MSWI 技术发展带来了挑战。同时, 针对我国国情, MSWI 在实际运行过程中仍面临着以下问题: 其一, 不同地域的居民生活水平与生活习惯不同, 导致 MSW 的热值差异较大; 其二, 不同地域、气候存在差异, 导致 MSW 的含水率波动较大^[13]。因此, 即便焚烧炉通常配备有自动燃烧控制 (Automatic combustion control, ACC) 系统, 然而其实际运行过程中也难以直接投入使用, 且 ACC 的控制策略相对单一且缺乏智能, 难以满足组分复杂的 MSWI 控制需求^[14]。当前 MSWI 的运行过程仍需要人工干预以应对复杂多变的焚烧工况, 然而依靠专家经验的控制过程存在主观性和随意性, 其控制精度较低、波动范围大, 耗费大量人工成本的同时, 也会导致污染物排放超标、焚烧效率低下等问题^[15]。工业自动化与信息技术的发展为 MSWI 的优化运行提供了思路与方案^[16-18], 其中, 研究 MSWI

过程的建模与控制方法是亟待解决的关键问题。

构建 MSWI 被控对象模型是研究其优化控制的基础, 数据驱动的建模方法能够在不需要先验知识的情况下, 对复杂工业过程进行快速模拟。根据之前的研究工作^[19], 本文以多输入多输出 Takagi Sugeno 型模糊神经网络 (Multi-input multi-output Takagi Sugeno fuzzy neural network, MIMO-TSFNN) 为基础, 建立了 MSWI 被控对象模型, 其由共享神经元与多后件子网络组成, 能够针对同一系统的多输出任务进行学习, 计算速度快, 能够良好地用于构建 MSWI 的被控对象模型。

在 MIMO-TSFNN 被控对象模型的基础上, 需要进一步研究其控制方法以实现多变量控制。传统的工业控制多使用比例-积分-微分 (Proportional-integral-derivative, PID) 控制器, 其具有结构简单、参数整定技术成熟等优点^[20-21]。针对多变量控制问题, 一些学者在 PID 控制的基础上, 构建了多回路 PID 控制器^[22]。文献 [23] 设计了一种多回路 PID 控制器用于同步控制地热发电厂的流量、压力和不凝性气体的含量, 保证了系统在不确定性扰动和环境温度变化时的稳定性。文献 [24] 针对流化催化裂化装置的多输入多输出 (Multi-input multi-output, MIMO) 过程, 设计了具有多个独立回路的多变量控制系统, 同时计算了各个闭环的局部损失函数与全局成本函数, 实现了对多变量的协同控制。多回路 PID 控制器满足了系统的多变量控制需求, 然而随着回路的增加, 多个控制器需要整定的参数也随之增加, 这将导致多变量间的耦合关系难以协调。

神经网络控制器 (Artificial neural network controller, ANNC) 在解决多变量耦合的控制问题时具有明显的优势。ANNC 作为一种基于黑箱模型的控制器的内部神经元能够在多个输入变量与多个输出变量之间建立连接通道, 具有强大的解耦能力。文献 [25-26] 构建了一种自适应模糊神经网络控制器实现了污水处理中的 $\text{NO}_3\text{-N}$ 和 DO 浓度的多变量控制。文献 [27] 构建了基于级联神经网络和规则推理两层递阶结构的控制器, 实现了对赤铁矿磨矿过程的优化控制。虽然 ANNC 能较好地解决复杂系统的多变量控制问题, 然而, 当出现外界扰动或操作条件改变时, 固定结构的 ANNC 会出现信息表征不足或结构冗余现象, 进而导致控制性能下降。

ANNC 中神经元的活跃性是影响控制效果的关键因素, 构建具有自组织能力控制器是提升其鲁棒性的关键。文献 [28] 构建了一种基于自适应神经模糊推理, 通过模糊聚类 and 主成分分析法以调整控制器规则, 实现了在不同温度下溶解氧和回流量

控制. 文献 [29] 针对一类不确定非线性 MIMO 系统, 设计了一种鲁棒自组织模糊神经网络控制器, 通过计算匹配度对神经元进行自适应增长与删减, 其在外部分扰的情况下取得了良好的控制效果. 然而, 现有自组织机制通常难以平衡多个任务之间的协调性, 且在避免结构阈值的同时, 又引入了其他阈值条件. 根据以上分析, 本文提出了一种基于多任务学习的自组织模糊神经网络控制器 (Multi-task learning self-organizing fuzzy neural network controller, MTL-SOFNNC), 其通过计算神经元的相关性与多任务学习 (Multi-task learning, MTL) 能力, 对网络结构进行自适应调整, 实现对多变量的在线跟踪控制.

综上所述, 本文提出了一种面向 MSWI 过程的数据驱动建模与自组织控制方法, 主要工作如下:

1) 在数据驱动模型的基础上构建了 MSWI 多变量控制系统, 其通过构建共享神经元与多后件子网络对 MSWI 的多变量进行在线跟踪控制;

2) 设计了基于多任务学习的自组织机制, 通过计算神经元间的点互信息 (Pointwise mutual information, PMI) 与欧氏距离 (Euclidean distance, ED) 对神经元相似性与贡献度进行评价, 并以此对网络结构进行自适应调整;

3) 设计了控制器在线参数学习策略, 分别对控

制器的共享参数与多任务学习参数进行在线更新;

4) 通过 Lyapunov 定理对控制系统的稳定性进行证明, 并给出了一般性的稳定收敛条件.

1 MSWI 过程描述

1.1 MSWI 工艺流程

截至 2020 年, 国内已运行 MSWI 厂共有 492 座, 包括 1202 台焚烧炉, 其中, 机械炉排炉占比超过 86%. 按照处理量分析, 全国机械炉排炉合计处理能力超过 4.8×10^5 吨/日, 炉排炉已经成为我国 MSWI 厂所采用的主要焚烧炉型^[12].

基于炉排炉的 MSWI 工艺流程如图 1 所示, 其包括: 固废储运系统、固废焚烧系统、余热锅炉系统、蒸汽发电系统、烟气处理系统与烟气排放系统, 各个系统的运行过程如下.

1) 固废储运系统: MSW 由压缩收集车运输到 MSWI 发电厂, 经过地磅称重后, 倾倒入固废池, 抓斗对固废池内的 MSW 进行搅拌与混合, MSW 在此处进行发酵与脱水, 此过程通常历时 7 天.

2) 固废焚烧系统: 首先, 抓斗将发酵完成的 MSW 投入到料斗中, 料斗内的 MSW 在重力的作用下经过料槽滑落至进料器上; 然后, 进料器将 MSW 推至干燥炉排, 其在此处受到热辐射和一次风的吹

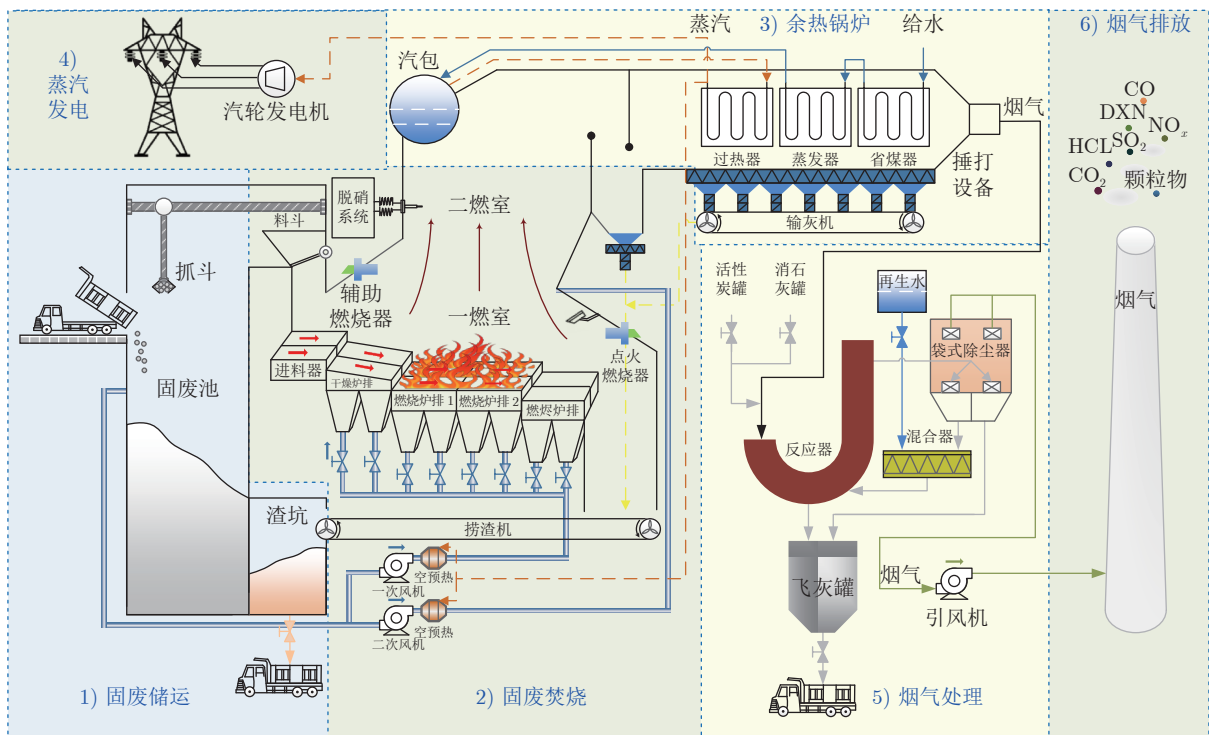


图 1 MSWI 的工艺流程

Fig.1 MSWI process flow

烘, 进而脱去剩余水分, 并由干燥炉排继续将其推至燃烧炉排; 之后, MSW 依次在燃烧 1 段炉排和燃烧 2 段炉排上充分燃烧, 同时由一次风在炉排底部提供助燃空气, 二次风在炉膛上方提供助燃空气并形成湍流; 最后, 燃烧产生的炉渣在燃烬炉排上充分燃烬并被推出炉膛。

3) 余热锅炉系统: 高温烟气在余热锅炉中进行能量转换, 其中间介质为水; 锅炉给水先在烟道尾部的省煤器中吸收低温烟气热量后进入蒸发器, 蒸发器受热面将给水转换成不饱和蒸汽后送入至汽包, 汽包继续对水蒸气加热形成饱和蒸汽, 饱和蒸汽输入至烟气温度最高的过热器中, 输出过热蒸汽。

4) 蒸汽发电系统: 接收余热锅炉输出的过热蒸汽, 其进入汽轮机中推动转子旋转, 发电机设有励磁绕组, 利用电磁感应原理把机械能转换成电能, 产生的电能为 MSWI 厂供电, 同时将富余的电量升压后接入电网。

1.2 MSWI 控制特性分析

依据环保部发布的《生活垃圾焚烧污染控制标准》(GB18485-2014) 可知: MSWI 过程的炉膛温度不得低于 850 °C, 炉渣热灼减率应低于 5%, 二噁英排放浓度应低于 0.1 ng-TEQ/Nm³, CO 浓度日均值应低于 80 mg/m³, NO_x 浓度日均值应低于 250 mg/m³。同时, 结合实际 MSWI 控制过程和焚烧机理可知: 炉膛温度与 MSW 热解、消毒以及发电效率密切相关, 烟气含氧量与燃烧状态、污染物排放浓度密切相关。因此, 本文选取炉膛温度和烟气含氧量作为关键被控变量。在操纵变量选择中, 首先, 依据专家知识将 MSWI 控制过程概括为一个空气分配与物料分配的过程, 其主要操作变量包括干燥炉排速度、燃烧炉排 1 速度、燃烧炉排 2 速度、一次风总流量及其各个子风管流量、二次风流量; 接着, 提取 MSWI 厂的实际运行数据, 采用皮尔森相关系数对数据之间的相关性进行评估:

$$\rho_{UY} = \frac{N \sum_{l=1}^N U_l Y_l - \sum_{l=1}^N U_l \sum_{l=1}^N Y_l}{\sqrt{N \sum_{l=1}^N U_l^2 - (\sum_{l=1}^N U_l)^2} \sqrt{N \sum_{l=1}^N Y_l^2 - (\sum_{l=1}^N Y_l)^2}} \quad (1)$$

式中, U_l 和 Y_l 为操作量与被控量的样本数据, N 为样本总数, ρ_{UY} 的取值范围为 $[-1, 1]$ 。

结合焚烧机理可知, 燃烧的三要素包括可燃物、助燃材料和点火源, 分析实际 MSWI 厂的专家知识与控制规则, 并结合之前的研究工作^[19], 本文选取的关键操作变量包括一次风总流量、干燥炉排速度

百分比、二次风流量。新入炉的 MSW 依靠炉内前段 MSW 引燃, 一次风、二次风可用于调节助燃空气, 干燥炉排速度百分比可用于调节可燃物料。

2 被控对象模型

2.1 MIMO-TSFNN 模型

根据控制特性分析, 构建 MIMO-TSFNN 模型如图 2 所示, 其由前件网络和后件网络组成, 具体描述如下。

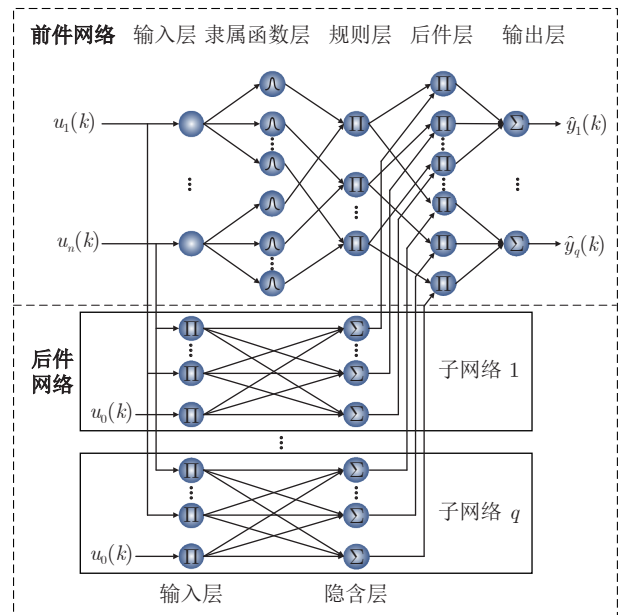


图 2 MIMO-TSFNN 模型
Fig.2 MIMO-TSFNN model

1) 前件网络

输入层. 设有 n 个神经元, 其数量与操作量的数量对应, 当样本 k 输入时, 该层输出为

$$u_i(k), i = 1, 2, \dots, n \quad (2)$$

共享隶属函数层. 设有 $n \times m$ 个神经元, 其作用是计算每个输入量对应的隶属度值, 可表示为

$$\gamma_{ij}(k) = \exp \left[-\frac{(u_i(k) - c_{ij}(k))^2}{b_{ij}(k)} \right], j = 1, 2, \dots, m \quad (3)$$

式中, $c_{ij}(k)$ 和 $b_{ij}(k)$ 分别为隶属函数的中心和宽度。

共享规则层. 设有 m 个神经元, 其通过连乘算子计算每个规则神经元输出为

$$w_j(k) = \prod_{i=1}^n \gamma_{ij}(k) \quad (4)$$

对输出规则进行解模糊后得到:

$$\theta_j(k) = \frac{w_j(k)}{\sum_{j=1}^m w_j(k)} \quad (5)$$

后件层. 设有 $m \times Q$ 个神经元, 其作用是将后件网络得到的后件参数传递至输出层, 将该层输出表示为 $\mu_j^q(k)$.

输出层. 设有 Q 个神经元, 其作用是对输入参数进行加权求和, 计算其输出为

$$\hat{y}_q(k) = \sum_{j=1}^m \theta_j(k) \mu_j^q(k) \quad (6)$$

2) 后件网络

输入层. 设有 $n + 1$ 个神经元, 其中第 0 个节点的输入为常数, 即 $u_0(k) = 1$, 用于提供模糊规则后件部分的常数项, 其余输入和前件网络的输入层相同.

隐含层. 设有 m 个神经元, 其作用是计算模糊规则后件参数, 将其表示为

$$\mu_j^q(k) = p_{0j}^q(k)u_0(k) + p_{1j}^q(k)u_1(k) + \dots + p_{nj}^q(k)u_n(k), \quad q = 1, 2, \dots, Q \quad (7)$$

式中, $p_{0j}^q(k), p_{1j}^q(k), \dots, p_{nj}^q(k)$ 是模糊系统的参数.

2.2 模型参数学习

本节设计的 MIMO-TSFNN 模型采用梯度下降算法调整网络参数, 相关定义如下.

将误差函数定义为

$$e_q(k) = \frac{1}{2} (y_q(k) - \hat{y}_q(k))^2 \quad (8)$$

式中, $y_q(k)$ 是第 k 个输入样本对应的第 q 个实际输出.

隶属度函数的中心 $c_{ij}(k)$ 与宽度 $b_{ij}(k)$ 的修正算法如下:

$$c_{ij}(k) = c_{ij}(k-1) - \eta \frac{\partial \left(\sum_{q=1}^Q (e_q(k)) \right)}{\partial c_{ij}(k)} \quad (9)$$

$$b_{ij}(k) = b_{ij}(k-1) - \eta \frac{\partial \left(\sum_{q=1}^Q (e_q(k)) \right)}{\partial b_{ij}(k)} \quad (10)$$

式中, η 为 MIMO-TSFNN 模型的学习率.

模糊系统参数 $p_{ij}^q(k)$ 的修正算法如下:

$$p_{ij}^q(k) = p_{ij}^q(k-1) - \eta \frac{\partial e_q(k)}{\partial p_{ij}^q(k)} \quad (11)$$

3 多变量控制器

3.1 控制系统结构

根据 MSWI 中的多变量控制需求, 本节设计了一种基于 MTL-SOFNNC 的 MSWI 控制系统, 如图 3 所示. 图中, $r_{O_2}(t), r_T(t)$ 分别为烟气含氧量与炉膛温度的设定值; $y_{O_2}(t), y_T(t), y_S(t)$ 分别为烟气含氧量、炉膛温度和主蒸汽流量的实际输出值; $\hat{y}_{O_2}(t), \hat{y}_T(t), \hat{y}_S(t)$ 分别为烟气含氧量、炉膛温度和主蒸汽流量的模型预测值, 其中 $\hat{y}_S(t)$ 作为后续研究的优化指标变量; $e_{O_2}(t), e_T(t)$ 分别为模型预测值与设定值之间的误差; $\Delta e_{O_2}(t), \Delta e_T(t)$ 分别为模型预测值与设定值之间的误差变化量; $u_{dry}(t), u_{air\ I}(t)$ 分别为干燥炉排速度百分比与一次风总流量;

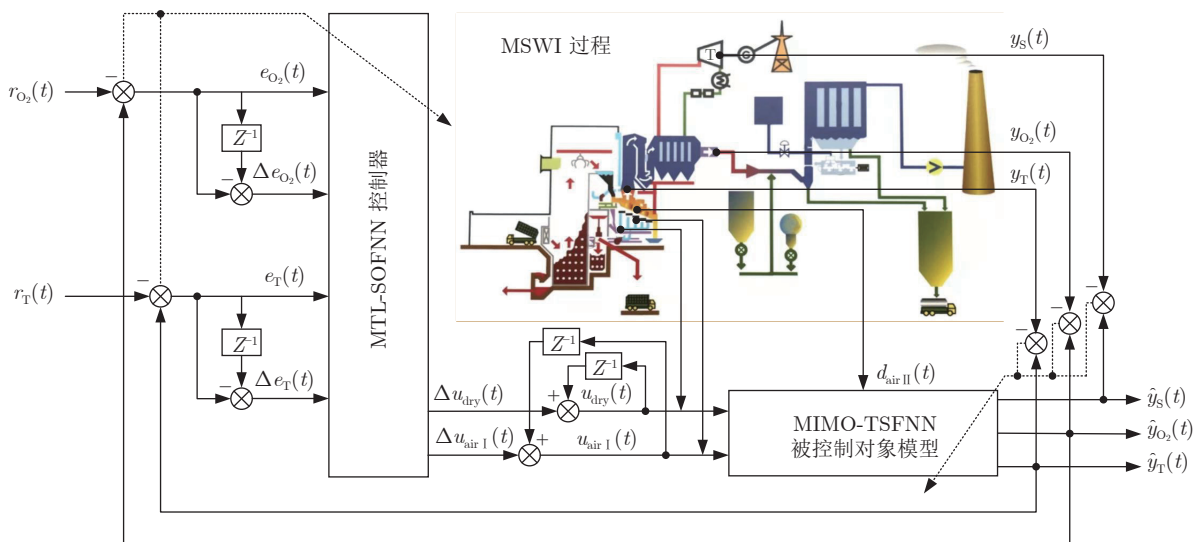


图 3 基于 MTL-SOFNNC 的 MSWI 控制系统
Fig.3 MSWI control system based on MTL-SOFNNC

$\Delta u_{\text{dry}}(t)$ 、 $\Delta u_{\text{air I}}(t)$ 分别为干燥炉排速度百分比与一次风总流量的变化量; $d_{\text{air II}}(t)$ 为二次风流量, 其作为扰动变量。

3.2 MTL-SOFNNC

MTL-SOFNNC 的设计原理是根据烟气含氧量与炉膛温度的控制误差及控制误差变化量, 通过求解干燥炉排速度百分比与一次风总流量的最优控制率, 以实现烟气含氧量与炉膛温度的跟踪控制, 控制器的输入为

$$\begin{cases} e_{\text{O}_2}(t) = r_{\text{O}_2}(t) - \hat{y}_{\text{O}_2}(t) \\ \Delta e_{\text{O}_2}(t) = e_{\text{O}_2}(t) - e_{\text{O}_2}(t-1) \\ e_{\text{T}}(t) = r_{\text{T}}(t) - \hat{y}_{\text{T}}(t) \\ \Delta e_{\text{T}}(t) = e_{\text{T}}(t) - e_{\text{T}}(t-1) \end{cases} \quad (12)$$

在烟气含氧量 $r_{\text{O}_2}(t)$ 与炉膛温度 $r_{\text{T}}(t)$ 设定值跟踪控制过程中, 可将其动力学系统描述为

$$\mathbf{y}(t) = \mathbf{h}(t) + \mathbf{g}(t)\mathbf{u}(t) \quad (13)$$

式中, $\mathbf{y}(t) = [y_{\text{O}_2}(t), y_{\text{T}}(t)]$, $\mathbf{h}(t)$ 和 $\mathbf{g}(t)$ 分别为状态量与操作量的函数, 推导最优控制率为

$$\mathbf{u}^*(t) = \mathbf{g}^{-1}(t) (\hat{\mathbf{y}}(t) - \mathbf{h}(t) + \mathbf{k}^{\text{T}}(t)\mathbf{e}(t)) \quad (14)$$

式中, \mathbf{k} 为反馈增益矩阵, 其作用是维持闭环控制系统的稳定性。

然而, MSWI 过程中系统动态模型 $\mathbf{h}(t)$ 和 $\mathbf{g}(t)$ 未知, 无法直接求取最优控制率 $\mathbf{u}^*(t)$ 。因此, 本节构建了一种基于 MTL-SOFNNC 的控制框架用于逼近最优控制率, 如图 4 所示, 其由 MTL-SOFNNC、结构自组织策略和参数学习策略三部分组成。

MTL-SOFNNC 的输出为操作量 $u_{\text{dry}}(t)$ 、 $u_{\text{air I}}(t)$ 的变化量, 可将其表示为

$$\Delta \hat{\mathbf{u}}(t) = [\Delta u_{\text{dry}}(t), \Delta u_{\text{air I}}(t)] \quad (15)$$

MTL-SOFNNC 的输出由控制器网络输出层得到, 可将其表示为

$$\Delta \hat{\mathbf{u}}(t) = \boldsymbol{\theta}^c(t)\boldsymbol{\mu}^c(t) \quad (16)$$

式中, $\boldsymbol{\theta}^c(t)$ 为输出权重向量, $\boldsymbol{\mu}^c(t)$ 为后件参数矩阵, 可将其表示为

$$\boldsymbol{\theta}^c(t) = [\theta_1^c(t), \dots, \theta_{m'}^c(t)] \quad (17)$$

$$\boldsymbol{\mu}^c(t) = \begin{bmatrix} \mu_1^{c,1}(t) & \cdots & \mu_{m'}^{c,1}(t) \\ \vdots & \ddots & \vdots \\ \mu_1^{c,Q'}(t) & \cdots & \mu_{m'}^{c,Q'}(t) \end{bmatrix}^{\text{T}} \quad (18)$$

式中, c 表示控制器网络, m' 为隐含层神经元数量, Q' 为输出层神经元数量。

计算控制器网络的输出权重向量为

$$\theta_{j'}^c(t) = \frac{w_{j'}^c(t)}{\sum_{j'=1}^m w_{j'}^c(t)} \quad (19)$$

式中, $w_{j'}^c(t)$ 为控制器网络共享规则层输出, 可将其表示为

$$w_{j'}^c(t) = \prod_{i'=1}^{n'} \left\{ \exp \left[-\frac{(v_{i'}(t) - c_{i',j'}^c(t))^2}{b_{i',j'}^c(t)} \right] \right\} \quad (20)$$

式中, $v_{i'}(t)$ 为控制器网络输入, $c_{i',j'}^c(t)$ 和 $b_{i',j'}^c(t)$ 分别为控制器网络隶属函数层的中心和宽度, n' 为输入层神经元数量。

计算控制器网络的后件参数为

$$\mu_{j'}^{c,q'}(t) = [1, \mathbf{v}(t)] \cdot [p_{0,j'}^{c,q'}(t), \dots, p_{n',j'}^{c,q'}(t)]^{\text{T}} \quad (21)$$

式中, $\mathbf{v}(t)$ 为控制器网络输入向量 $[e_{\text{O}_2}(t), \Delta e_{\text{O}_2}(t), e_{\text{T}}(t), \Delta e_{\text{T}}(t)]$; $p_{0,j'}^{c,q'}(t), \dots, p_{n',j'}^{c,q'}(t)$ 为控制器网络的模糊系统参数。

3.3 结构自组织策略

针对 MSWI 控制过程中的复杂动力特性及多变量控制需求, 本节设计了一种基于多任务学习的结构自组织策略, 其由增长机制、删减机制和恒定机制组成, 通过衡量规则层神经元的相似度与多任务学习能力以自适应调整规则数量, 从而获得结构更紧凑的网络结构。当神经元相似度大且对多任务学习能力小时, 表明该神经元是最冗余的, 需要被删减以保证网络结构紧凑; 当神经元对多任务学习能力大且相似度小时, 表明该神经元是最有效的, 需要在其基础上增长神经元以增强网络泛化性。本节采用 PMI^[30] 对相似度进行计算, 分析了神经元在滑窗内表现; 采用 ED 对多任务学习能力进行评估, 分析了神经元在当前时刻的表现。PMI 与 ED 计算简单, 且分别从历史时刻和当前时刻对控制器进行评估, 既能保证控制器的稳定性, 也能提升其动态响应能力。

使用 PMI 对每两个规则层神经元之间的相似度进行评估。首先, 将规则层神经元 α 和 β 在时间滑窗宽度为 τ 时的输出分别记为 $\omega_{\alpha}(t)$ 和 $\omega_{\beta}(t)$, 计算其信息熵为

$$\begin{cases} H(\omega_{\alpha}(t)) = -\sum_{t=1}^{\tau} \phi(\omega_{\alpha}(t)) \log_2[\phi(\omega_{\alpha}(t))] \\ H(\omega_{\beta}(t)) = -\sum_{t=1}^{\tau} \phi(\omega_{\beta}(t)) \log_2[\phi(\omega_{\beta}(t))] \end{cases} \quad (22)$$

式中, $\phi(\omega_{\alpha}(t))$ 和 $\phi(\omega_{\beta}(t))$ 分别为 $\omega_{\alpha}(t)$ 和 $\omega_{\beta}(t)$ 的

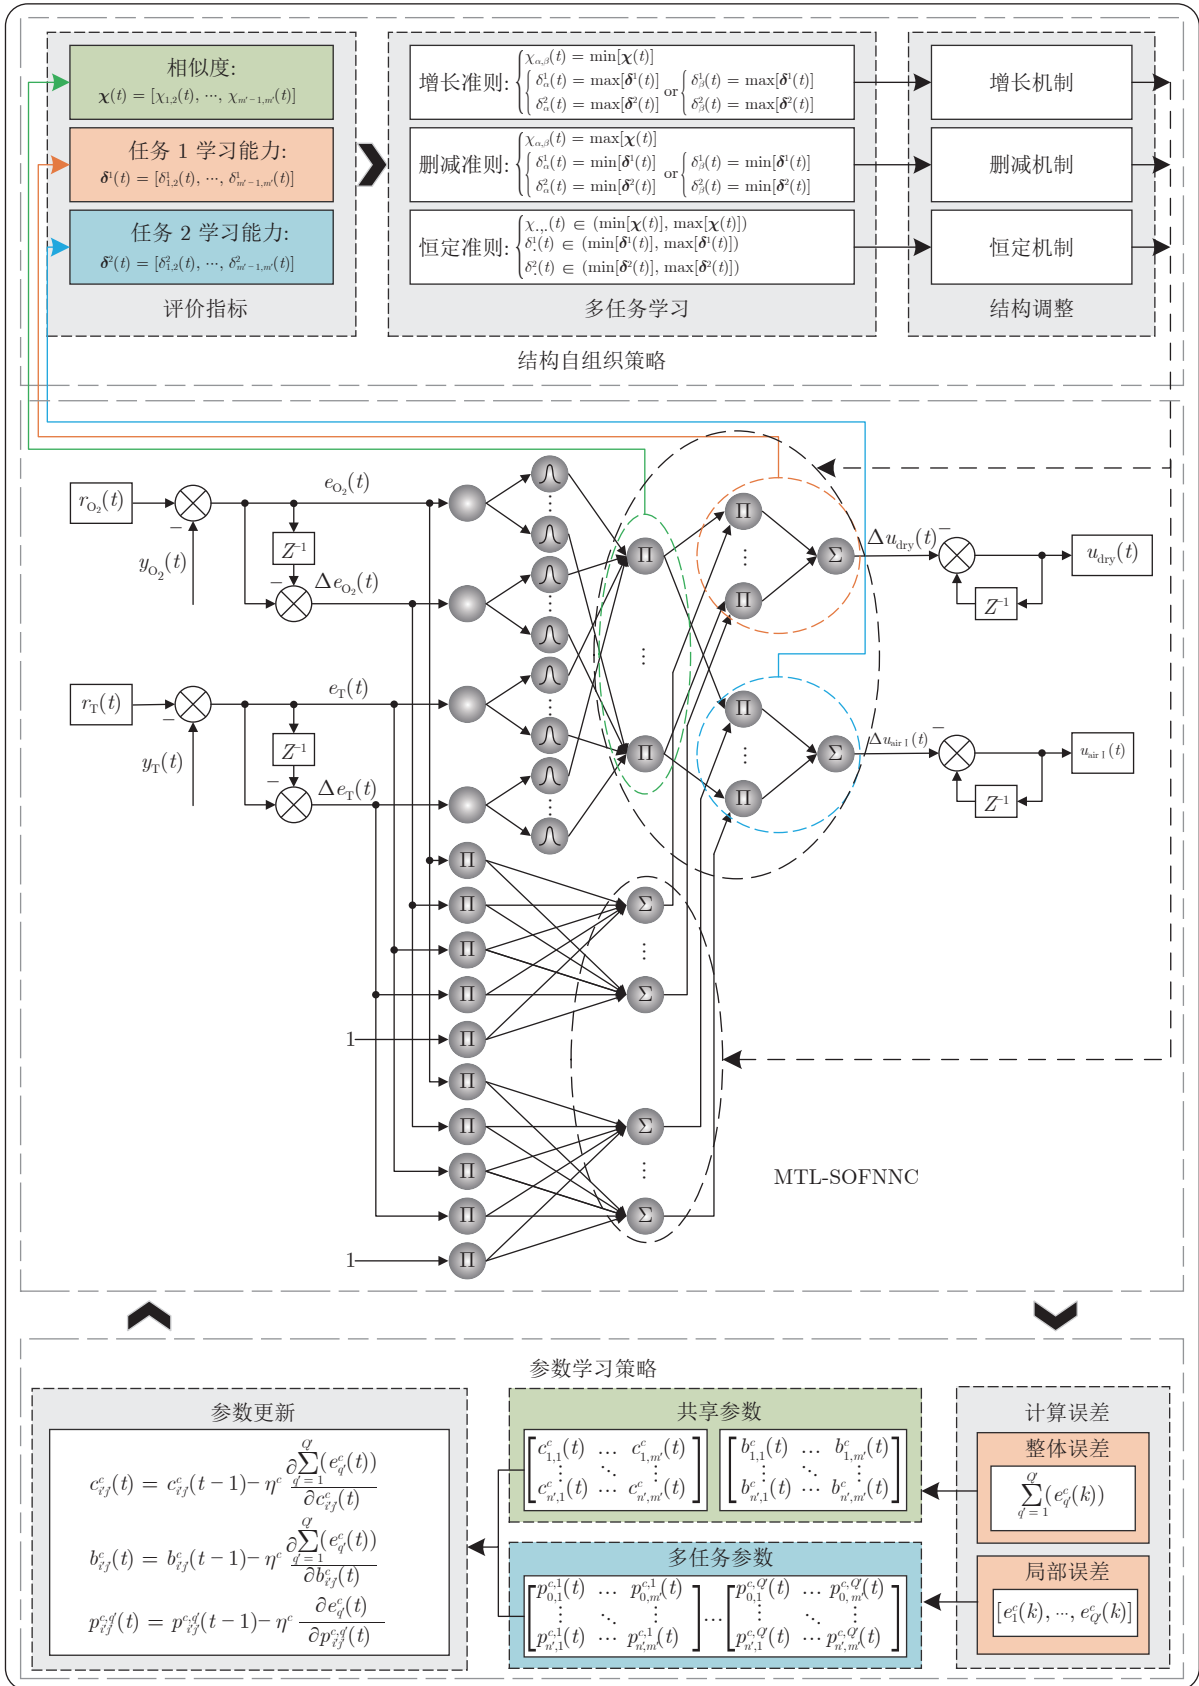


图 4 基于 MTL-SOFNNC 的控制框架

Fig. 4 Control structure based on MTL-SOFNNC

概率密度函数, 由于神经元输出为离散变量, 其概率密度可通过直方图法得到.

接着, 计算 $\omega_\alpha(t)$ 与 $\omega_\beta(t)$ 之间的联合熵, 其定义式如下:

$$H(\omega_\alpha(t), \omega_\beta(t)) = - \sum_{t=1}^{\tau} \sum_{t=1}^{\tau} \phi(\omega_\alpha(t), \omega_\beta(t)) \log_2[\phi(\omega_\alpha(t), \omega_\beta(t))] \quad (23)$$

式中, $\phi(\omega_\alpha(t), \omega_\beta(t))$ 为 $\omega_\alpha(t)$ 与 $\omega_\beta(t)$ 的联合概率密度函数.

综上, 计算 $\omega_\alpha(t)$ 与 $\omega_\beta(t)$ 之间的 PMI 值, 即神经元的相似度为

$$\chi_\alpha = H(\omega_\alpha(t)) + H(\omega_\beta(t)) - H(\omega_\alpha(t), \omega_\beta(t)) \quad (24)$$

使用 ED 对规则层神经元的多任务学习能力进行评估. 针对 MSWI 过程的多个控制任务需求, 分别计算规则层神经元对每个输出任务的学习能力. 首先, 将规则层神经元 j' 在时间滑窗宽度为 τ 时的输出记为 $\omega_{j'}(t)$, 将输出层神经元在时间滑窗宽度为 τ 时的输出分别记为 $\Delta u_1(t)$ 和 $\Delta u_2(t)$. 接着, 计算规则层神经元 j' 与被控变量之间 ED 值为

$$\begin{cases} D(\omega_{j'}(t), y_1(t)) = \sqrt{\sum_{t=1}^{\tau} (\omega_{j'}(t) - y_1(t))^2} \\ D(\omega_{j'}(t), y_2(t)) = \sqrt{\sum_{t=1}^{\tau} (\omega_{j'}(t) - y_2(t))^2} \end{cases} \quad (25)$$

式中, ED 值越小, 则表示神经元对输出的学习能力越强; $y_1(t)$ 、 $y_2(t)$ 为 $\Delta u_1(t)$ 、 $\Delta u_2(t)$ 作用下的输出被控变量. 因此, 这里将 ED 的倒数作为衡量神经元多任务学习能力的指标, 其定义为

$$\begin{cases} \delta_{j'}^1(t) = \frac{1}{D(\omega_{j'}(t), y_1(t))} \\ \delta_{j'}^2(t) = \frac{1}{D(\omega_{j'}(t), y_2(t))} \end{cases} \quad (26)$$

依据神经元相似度与多任务学习能力设计网络结构自组织策略, 具体如下.

1) 增长机制

当规则层神经元的相似度与多任务学习能力符合以下条件时, 触发神经元增长机制:

$$\begin{cases} \chi_{\alpha, \beta}(t) = \min[\chi(t)] \\ \left\{ \begin{array}{l} \delta_\alpha^1(t) = \max[\delta^1(t)] \\ \delta_\alpha^2(t) = \max[\delta^2(t)] \end{array} \right\} \text{ or } \left\{ \begin{array}{l} \delta_\beta^1(t) = \max[\delta^1(t)] \\ \delta_\beta^2(t) = \max[\delta^2(t)] \end{array} \right\} \end{cases} \quad (27)$$

式中, $\chi(t) = [\chi_{1,2}(t), \dots, \chi_{m'-1, m'}(t)]$ 为规则层神经

元的相似度向量, $\delta^1(t) = [\delta_{1,2}^1(t), \dots, \delta_{m'-1, m'}^1(t)]$, $\delta^2(t) = [\delta_{1,2}^2(t), \dots, \delta_{m'-1, m'}^2(t)]$ 分别为规则层神经元对任务 1 和任务 2 学习能力向量.

假设当网络处于增长机制时, 规则层神经元 α 与神经元 β 相似度最小, 且神经元 α 或 β 对任务 1 和任务 2 的学习能力均为最大, 这表明该神经元对网络贡献最大且具有唯一性. 因此, 此时需要在神经元 α 或 β 的基础上增长一个神经元, 以增强网络的泛化性能, 新增加神经元的初始参数设置为

$$\begin{cases} c_{i', m'+1}^c(t) = v_{i'}(t) \\ b_{i', m'+1}^c(t) = b_{i', \alpha}^c(t) \text{ or } b_{i', m'+1}^c(t) = b_{i', \beta}^c(t) \\ p_{i', m'+1}^{c, q'}(t) = \frac{\sum_{j'=1}^{m'} [w_{j'}^c(t) \mu_{j'}^{c, q'}(t)]}{\sum_{j'=1}^{m'} [w_{j'}^c(t)] \left[1 + \sum_{i'=1}^{n'} (v_{i'}(t)) \right]} \end{cases} \quad (28)$$

2) 删减机制

当规则层神经元的相似度与多任务学习能力符合以下条件时, 则触发神经元删减机制:

$$\begin{cases} \chi_{\alpha, \beta}(t) = \max[\chi(t)] \\ \left\{ \begin{array}{l} \delta_\alpha^1(t) = \min[\delta^1(t)] \\ \delta_\alpha^2(t) = \min[\delta^2(t)] \end{array} \right\} \text{ or } \left\{ \begin{array}{l} \delta_\beta^1(t) = \min[\delta^1(t)] \\ \delta_\beta^2(t) = \min[\delta^2(t)] \end{array} \right\} \end{cases} \quad (29)$$

假设当网络处于删减机制时, 规则层神经元 α 与神经元 β 相似度最大, 且神经元 α 或 β 对任务 1 和任务 2 的学习能力均为最小, 这表明该神经元对网络贡献最小且冗余. 因此, 此时需要对神经元 α 或 β 进行删减, 以保证网络结构的紧凑性, 删减神经元的参数设置为

$$\begin{cases} c_{i', \alpha}^c(t) = 0 \\ b_{i', \alpha}^c(t) = 0 \\ p_{i', \alpha}^{c, q'}(t) = 0 \end{cases} \text{ or } \begin{cases} c_{i', \beta}^c(t) = 0 \\ b_{i', \beta}^c(t) = 0 \\ p_{i', \beta}^{c, q'}(t) = 0 \end{cases} \quad (30)$$

对与神经元 α 或 β 相似度最高神经元 β 或 α 进行参数补偿为

$$\begin{cases} \tilde{c}_{i', \beta}^c(t) = c_{i', \beta}^c(t) \\ \tilde{b}_{i', \beta}^c(t) = b_{i', \beta}^c(t) \\ \tilde{p}_{i', \beta}^{c, q'}(t) = \frac{\Delta \hat{u}_{q'}(t) \sum_{j'=1, j' \neq \alpha}^{m'} [w_{j'}^c(t)] - \sum_{j'=1, j' \neq \alpha, j' \neq \beta}^{m'} [w_{j'}^c(t) \mu_{j'}^{c, q'}(t)]}{\left[1 + \sum_{i'=1}^{n'} (v_{i'}(t)) \right] \tilde{w}_\beta^c(t)} \end{cases} \text{ or}$$

$$\begin{cases} \tilde{c}_{i',\alpha}^c(t) = c_{i',\alpha}^c(t) \\ \tilde{b}_{i',\alpha}^c(t) = b_{i',\alpha}^c(t) \\ \tilde{p}_{i',\alpha}^{c,q'}(t) = \\ \frac{\Delta \hat{u}_{q'}(t) \sum_{j=1, j' \neq \beta}^{m'} [w_{j'}^c(t)] - \sum_{j=1, j' \neq \alpha, j' \neq \beta}^{m'} [w_{j'}^c(t) \mu_{j'}^{c,q'}(t)]}{\left[1 + \sum_{i'=1}^{n'} (v_{i'}(t))\right] \tilde{w}_{\alpha}^c(t)} \end{cases} \quad (31)$$

3) 恒定机制

当规则层神经元的相似度与多任务学习能力符合以下条件时, 则触发神经元恒定机制:

$$\begin{cases} \chi_{\cdot, \cdot}(t) \in (\min[\chi(t)], \max[\chi(t)]) \\ \delta^1(t) \in (\min[\delta^1(t)], \max[\delta^1(t)]) \\ \delta^2(t) \in (\min[\delta^2(t)], \max[\delta^2(t)]) \end{cases} \quad (32)$$

当网络处于恒定机制时, 规则层全部神经元均处于活跃状态且网络结构紧凑, 这表明当前网络结构合适, 规则神经元能够满足控制需求。

综上所述, 在控制器的结构自组织过程中, PMI 与 ED 分别从神经元的贡献度与相似度进行评估, 能够及时剔除冗余神经元并保持隐含层神经元的活跃性, 增强了网络结构的稳定性, 机制的计算步骤少且运算量较小, 能够满足在线控制的需求。同时, 活跃的神经元与紧凑的网络结构也会提升控制器的控制效率。

3.4 参数学习策略

通过梯度下降算法对 MTL-SOFNNC 进行参数学习, 首先定义控制器的多输出误差与总误差分别为

$$e_{q'}^c(t) = \frac{1}{2} (r_{q'}(t) - \hat{y}_{q'}(t))^2 \quad (33)$$

$$E^c(t) = \sum_{q'=1}^{Q'} (e_{q'}^c(t)) \quad (34)$$

式中, $r_{q'}(t)$ 为控制器设定值, $\hat{y}_{q'}(t)$ 为控制系统得到的被控变量输出值。

将 MTL-SOFNNC 的参数学习向量表示为

$$\Psi(t) = [\Psi_1(t), \Psi_2(t)] \quad (35)$$

其由共享参数 $\Psi_1(t)$ 与多任务参数 $\Psi_2(t)$ 组成。将共享参数记为

$$\Psi_1(t) = [c_{i',j'}^c(t), b_{i',j'}^c(t)] \quad (36)$$

将多任务参数记为

$$\Psi_2(t) = [p_{i',j'}^{c,1}(t), p_{i',j'}^{c,2}(t)] \quad (37)$$

其中, 共享参数为神经元隶属函数的中心与宽度, 根据输入参数计算同一系统的共享规则, 从而获得多任务学习之间的共享信息, 多任务参数为后件子网络的模糊系统参数, 分别用于完成多个控制任务。同一系统的多变量控制之间可以彼此助益, 利用之间的共享信息实现协同控制。

参数更新过程计算如下:

$$\Psi(t+1) = \Psi(t) - \eta^c \mathbf{J}(t) \quad (38)$$

式中, η^c 为 MTL-SOFNNC 的学习率, $\mathbf{J}(t)$ 为参数误差的 Jacobian 向量, 其可表示为

$$\mathbf{J}(t) = \begin{bmatrix} \frac{\partial E^c(t)}{\partial c_{i',j'}^c(t)}, \frac{\partial E^c(t)}{\partial b_{i',j'}^c(t)}, \frac{\partial e_{i'}^c(t)}{\partial p_{i',j'}^{c,1}(t)}, \frac{\partial e_{i'}^c(t)}{\partial p_{i',j'}^{c,2}(t)} \end{bmatrix} \quad (39)$$

综上所述, 在控制器的参数学习过程中, 采用经典的梯度下降学习算法, 其具有通用性强、收敛速度快、泛化能力好、计算复杂度低、相对稳定等特点, 控制器沿梯度方向便能快速地收敛到函数最小值。此外, 本文针对多变量控制设计了共享规则层神经元, 能够在使用较少参数的情况下, 同时完成多个控制任务, 控制器仅需对共享隶属度神经元宽度、中心以及后件层参数进行更新即可实现多变量同步在线控制, 其计算量较小。

3.5 稳定性分析

稳定性是控制系统的重要特性之一, 为保证控制系统能够完成预期的控制任务, 本节基于 Lyapunov 定理分别对 MTL-SOFNNC 在参数学习过程和结构自组织过程的稳定性进行了分析。

1) 参数学习过程的稳定性分析

定理 1. MTL-SOFNNC 使用梯度下降算法进行参数更新, η^c 为 MTL-SOFNNC 的学习率, 因此存在欧几里得范数 $\lambda_{\max} = \max \left\| \frac{\partial(\hat{y}_1(t) + \hat{y}_2(t))}{\partial \Psi(t)} \right\|$ 。当 η^c 符合以下条件时, 则可保证控制器稳定收敛:

$$0 < \eta^c < \frac{2}{(\lambda_{\max})^2} \quad (40)$$

证明. 构建参数学习过程的 Lyapunov 函数 $\vartheta_1(t)$ 为

$$\vartheta_1(t) = \frac{1}{2} (E^c(t))^2 \quad (41)$$

计算 $\Delta \vartheta_1(t)$ 为

$$\Delta \vartheta_1(t) = \vartheta_1(t+1) - \vartheta_1(t) =$$

$$\frac{1}{2} \left[(E^c(t+1))^2 - (E^c(t))^2 \right] \quad (42)$$

式中, $E^c(t+1)$ 为

$$E^c(t+1) = E^c(t) + \Delta E^c(t) \quad (43)$$

式中, $\Delta E^c(t)$ 表示误差的变化量. 可将式 (42) 展开为

$$\begin{aligned} \Delta \vartheta_1(t) &= \frac{1}{2} \left\{ 2E^c(t) \Delta E^c(t) + [\Delta E^c(t)]^2 \right\} = \\ &= \frac{1}{2} \left\{ 2E^c(t) \left[\frac{\partial E^c(t)}{\partial \Psi(t)} \right]^T \Delta \Psi(t) + \right. \\ &\quad \left. \left\{ \left[\frac{\partial E^c(t)}{\partial \Psi(t)} \right]^T \Delta \Psi(t) \right\}^2 \right\} = \\ &= \left[\frac{\partial E^c(t)}{\partial \Psi(t)} \right]^T \eta^c E^c(t) \frac{\partial(\hat{y}_1(t) + \hat{y}_2(t))}{\partial \Psi(t)} \left\{ E^c(t) + \right. \\ &\quad \left. \frac{1}{2} \left[\frac{\partial E^c(t)}{\partial \Psi(t)} \right]^T \eta^c E^c(t) \frac{\partial E^c(t)}{\partial \Psi(t)} \right\} \quad (44) \end{aligned}$$

由 MTL-SOFNNC 的 Lyapunov 函数定义式可知, $\frac{\partial E^c(t)}{\partial \Psi(t)} = \frac{-\partial(\hat{y}_1(t) + \hat{y}_2(t))}{\partial \Psi(t)}$, 则可得到:

$$\begin{aligned} \Delta \vartheta_1(t) &= -\eta^c [E^c(t)]^2 \left\| \frac{\partial(\hat{y}_1(t) + \hat{y}_2(t))}{\partial \Psi(t)} \right\|^2 + \\ &= \frac{1}{2} (\eta^c)^2 [E^c(t)]^2 \left\| \frac{\partial(\hat{y}_1(t) + \hat{y}_2(t))}{\partial \Psi(t)} \right\|^4 = \\ &= - \left[\eta^c \left\| \frac{\partial(\hat{y}_1(t) + \hat{y}_2(t))}{\partial \Psi(t)} \right\|^2 - \right. \\ &\quad \left. \frac{1}{2} (\eta^c)^2 \left\| \frac{\partial(\hat{y}_1(t) + \hat{y}_2(t))}{\partial \Psi(t)} \right\|^4 \right] [E^c(t)]^2 = \\ &= -\zeta [E^c(t)]^2 \quad (45) \end{aligned}$$

令 $\lambda(t) = \frac{\partial(\hat{y}_1(t) + \hat{y}_2(t))}{\partial \Psi(t)}$, $\tilde{\eta}^c = \eta^c (\lambda_{\max})^2$, 则有:

$$\begin{aligned} \zeta &= \eta^c \left\| \frac{\partial(\hat{y}_1(t) + \hat{y}_2(t))}{\partial \Psi(t)} \right\|^2 - \\ &= \frac{1}{2} (\eta^c)^2 \left\| \frac{\partial(\hat{y}_1(t) + \hat{y}_2(t))}{\partial \Psi(t)} \right\|^4 = \\ &= \frac{1}{2(\lambda_{\max})^2} \|\lambda(t)\|^2 \tilde{\eta}^c \left[2 - \tilde{\eta}^c \frac{\|\lambda(t)\|^2}{(\lambda_{\max})^2} \right] \geq \\ &= \frac{1}{2(\lambda_{\max})^2} \|\lambda(t)\|^2 \tilde{\eta}^c (2 - \tilde{\eta}^c) \quad (46) \end{aligned}$$

因此, 满足式 (46) 则可保证网络稳定收敛, 即需满足:

$$\tilde{\eta}^c (2 - \tilde{\eta}^c) > 0 \quad (47)$$

则有:

$$\eta^c (\lambda_{\max})^2 [2 - \eta^c (\lambda_{\max})^2] > 0 \quad (48)$$

推导得出:

$$0 < \eta^c < \frac{2}{(\lambda_{\max})^2} \quad (49)$$

□

2) 结构自组织过程的稳定性分析

定理 2. 假设在 t 时刻时, MTL-SOFNNC 规则神经元数量由 m' 个增长为 $m' + 1$ 个, 控制器输入如式 (12), 控制率计算过程如式 (15) ~ 式 (21), 增长机制如式 (27)、式 (28), 则可保证控制器稳定收敛.

证明. 构建神经元增长过程的 Lyapunov 函数 $\tilde{\vartheta}_2(t)$ 为

$$\tilde{\vartheta}_2(t) = \vartheta_2(t) + \frac{1}{2} (E_{m'+1}^c(t))^2 \quad (50)$$

式中, $\vartheta_2(t)$ 为神经元增长之前的 Lyapunov 函数, $\tilde{\vartheta}_2(t)$ 为神经元增长之后的 Lyapunov 函数, $E_{m'+1}^c(t)$ 为控制器具有 $m' + 1$ 个规则神经元时的输出总误差, 可将其表示为

$$E_{m'+1}^c(t) = \sum_{q'=1}^2 \left(\Delta \hat{u}_{q'}^{m'+1}(t) - \Delta \hat{u}_{q'}^{m'}(t) \right) \quad (51)$$

式中, $\Delta \hat{u}_{q'}^{m'+1}(t)$ 为控制器具有 $m' + 1$ 个规则神经元时的第 q' 个输出, $\Delta \hat{u}_{q'}^{m'}(t)$ 为控制器具有 m' 个规则神经元时的第 q' 个输出.

由式 (16) ~ 式 (18), 可将式 (51) 拓展为

$$\begin{aligned} E_{m'+1}^c(t) &= \sum_{q'=1}^2 \left\{ \frac{\sum_{j'=1}^{m'} [w_{j'}^c(t) \mu_{j'}^{c,q'}] + w_{m'+1}^c(t) \mu_{j'}^{c,q'}}{\sum_{j'=1}^{m'} [w_{j'}^c(t)] + w_{m'+1}^c(t)} - \right. \\ &\quad \left. \frac{\sum_{j'=1}^{m'} [w_{j'}^c(t) \mu_{j'}^{c,q'}]}{\sum_{j'=1}^{m'} [w_{j'}^c(t)]} \right\} \quad (52) \end{aligned}$$

将式 (28) 代入, 可将式 (52) 推导为式 (53) 的形式 (见下页下方).

因此, 可得到:

$$\tilde{\vartheta}_2(t) = \vartheta_2(t) \quad (54)$$

□

定理 3. 假设在 t 时刻时, MTL-SOFNNC 规则神经元数量由 m' 个删减为 $m' - 1$ 个, 控制器输入如式 (12), 控制率计算过程如式 (15) ~ 式 (21), 删减机制如式 (29) ~ 式 (31), 则可保证控制器稳定收敛.

证明. 构建神经元删减过程的 Lyapunov 函数 $\tilde{\vartheta}_3(t)$ 为

$$\tilde{\vartheta}_3(t) = \vartheta_3(t) + \frac{1}{2} (E_{m'-1}^c(t))^2 \quad (55)$$

式中, $\vartheta_3(t)$ 为神经元删减之前的 Lyapunov 函数, $\tilde{\vartheta}_3(t)$ 为神经元删减之后的 Lyapunov 函数, $E_{m'-1}^c(t)$ 为控制器具有 $m'-1$ 个规则神经元时的输出总误差, 可将其表示为

$$E_{m'-1}^c(t) = \sum_{q'=1}^2 \left(\Delta \hat{u}_{q'}^{m'-1}(t) - \Delta \hat{u}_{q'}^{m'}(t) \right) \quad (56)$$

式中, $\Delta \hat{u}_{q'}^{m'-1}(t)$ 为控制器具有 $m'-1$ 个规则神经元时的第 q' 个输出, $\Delta \hat{u}_{q'}^{m'}(t)$ 为控制器具有 m' 个规则神经元时的第 q' 个输出.

由式 (16) ~ 式 (18), 以删减神经元为 α 为例, 可将式 (56) 拓展为式 (57) 的形式 (见本页下方).

将式 (30)、式 (31) 代入, 可将式 (57) 推导为式 (58) 的形式 (见本页下方).

因此, 可得到:

$$\tilde{\vartheta}_3(t) = \vartheta_3(t) \quad (59)$$

□

注 1. 定理 1 证明了 MTL-SOFNNC 在参数学习过程的稳定性; 定理 2、定理 3 证明了 MTL-SOFNNC 在结构自组织过程的稳定性. 综上所述, 本节所提出的 MTL-SOFNNC 是稳定有效的, 能够实现有效控制并指导实际应用.

4 实验结果

4.1 实验描述

本实验对北京市某 MSWI 发电厂的过程数据进行了采集, 采样频率为 1 s/次. 根据控制特性分析选取了关键的操作变量与被控变量, 相关的执行机构与检测设备如图 5 所示.

根据实际 MSWI 厂实验条件与控制规则, 确立实验对象的运行范围如表 1 所示. 仿真实验使用 Matlab R2019a 版本进行编程, 并在运行环境为 Microsoft Windows 10、中央处理器频率为 3.2 GHz、运行内存为 16 GB 的电脑上进行实验.

$$E_{m'+1}^c(t) = \sum_{q'=1}^2 \left\{ \frac{\sum_{j'=1}^{m'} [w_{j'}^c(t) \mu_{j'}^{c, q'}] + [1, \mathbf{v}(t)] [p_{0, m'+1}^{c, q'}(t), \dots, p_{n', m'+1}^{c, q'}(t)]^T}{\sum_{j'=1}^{m'} [w_{j'}^c(t)] + 1} - \frac{\sum_{j'=1}^{m'} [w_{j'}^c(t) \mu_{j'}^{c, q'}]}{\sum_{j'=1}^{m'} [w_{j'}^c(t)]} \right\} =$$

$$\sum_{q'=1}^2 \left\{ \frac{\sum_{j'=1}^{m'} [w_{j'}^c(t) \mu_{j'}^{c, q'}]}{\sum_{j'=1}^{m'} [w_{j'}^c(t)]} \frac{\sum_{j'=1}^{m'} [w_{j'}^c(t)] + \sum_{j'=1}^{m'} [w_{j'}^c(t) \mu_{j'}^{c, q'}]}{\sum_{j'=1}^{m'} [w_{j'}^c(t)] + 1} - \frac{\sum_{j'=1}^{m'} [w_{j'}^c(t) \mu_{j'}^{c, q'}]}{\sum_{j'=1}^{m'} [w_{j'}^c(t)]} \right\} =$$

$$\sum_{q'=1}^2 \left\{ \frac{\sum_{j'=1}^{m'} [w_{j'}^c(t) \mu_{j'}^{c, q'}]}{\sum_{j'=1}^{m'} [w_{j'}^c(t)]} - \frac{\sum_{j'=1}^{m'} [w_{j'}^c(t) \mu_{j'}^{c, q'}]}{\sum_{j'=1}^{m'} [w_{j'}^c(t)]} \right\} = 0 \quad (53)$$

$$E_{m'-1}^c(t) = \sum_{q'=1}^2 \left\{ \frac{\sum_{j'=1, j' \neq \alpha, j' \neq \beta}^{m'} [w_{j'}^c(t) \mu_{j'}^{c, q'}] + \tilde{w}_\beta^c(t) \tilde{\mu}_\beta^{c, q'}}{\sum_{j'=1, j' \neq \alpha, j' \neq \beta}^{m'} [w_{j'}^c(t)] + \tilde{w}_\beta^c(t)} - \frac{\sum_{j'=1}^{m'} [w_{j'}^c(t) \mu_{j'}^{c, q'}]}{\sum_{j'=1}^{m'} [w_{j'}^c(t)]} \right\} \quad (57)$$

$$E_{m'-1}^c(t) = \sum_{q'=1}^2 \left\{ \frac{\sum_{j'=1, j' \neq \alpha, j' \neq \beta}^{m'} [w_{j'}^c(t) \mu_{j'}^{c, q'}] + \tilde{w}_\beta^c(t) [1, \mathbf{v}(t)] [\tilde{p}_{0, \beta}^{c, q'}(t), \dots, \tilde{p}_{n', \beta}^{c, q'}(t)]^T}{\sum_{j'=1, j' \neq \alpha, j' \neq \beta}^{m'} [w_{j'}^c(t)] + \tilde{w}_\beta^c(t)} - \frac{\sum_{j'=1}^{m'} [w_{j'}^c(t) \mu_{j'}^{c, q'}]}{\sum_{j'=1}^{m'} [w_{j'}^c(t)]} \right\} =$$

$$\sum_{q'=1}^2 \left\{ \frac{\Delta \hat{u}_{q'}(t) \sum_{j'=1, j' \neq \beta}^{m'} [w_{j'}^c(t)]}{\sum_{j'=1, j' \neq \alpha, j' \neq \beta}^{m'} [w_{j'}^c(t)] + \tilde{w}_\beta^c(t)} - \frac{\sum_{j'=1}^{m'} [w_{j'}^c(t) \mu_{j'}^{c, q'}]}{\sum_{j'=1}^{m'} [w_{j'}^c(t)]} \right\} = \sum_{q'=1}^2 \left\{ \frac{\sum_{j'=1}^{m'} [w_{j'}^c(t) \mu_{j'}^{c, q'}]}{\sum_{j'=1}^{m'} [w_{j'}^c(t)]} - \frac{\sum_{j'=1}^{m'} [w_{j'}^c(t) \mu_{j'}^{c, q'}]}{\sum_{j'=1}^{m'} [w_{j'}^c(t)]} \right\} = 0 \quad (58)$$

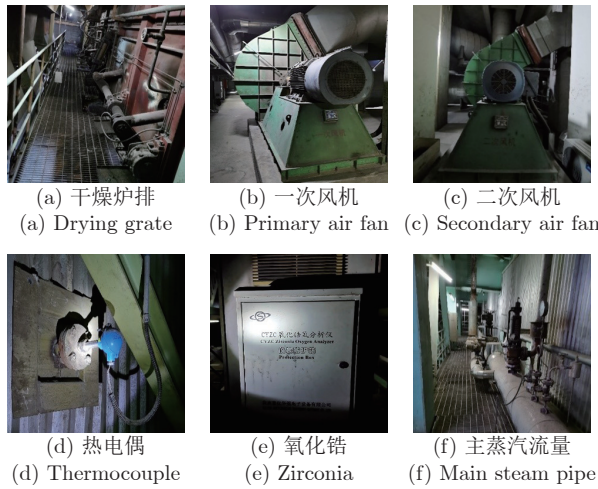


图 5 MSWI 执行机构和检测设备

Fig. 5 MSWI actuators and detection equipment

表 1 实验对象的运行范围

Table 1 Operating range of experimental subjects

变量名	运行范围	单位
一次风总流量	40 ~ 100	km ³ N/h
干燥炉排速度百分比	0 ~ 100	%
二次风流量	0 ~ 30	km ³ N/h
炉膛温度	850 ~ 1050	℃
烟气含氧量	2 ~ 14	%
主蒸汽流量	65 ~ 85	t/h

4.2 建模结果

本节通过现场数据验证所构建被控对象模型的有效性, 数据采集日期为 2020 年 10 月 26 日, 采集样本数量为 3 000 组, 将其中 80% 作为训练样本, 20% 作为测试样本. 模型参数设置如下: 输入层神经元为 3 个, 共享隶属度函数层神经元个数为 3×12 个, 共享规则层神经元个数为 12 个, 后件层神经元个数为 12×3 个, 输出层神经元为 3 个, 训练迭代步数为 500 次. 使用均方根误差 (Root mean squared error, RMSE) 与平均百分比误差 (Average percentage error, APE) 用于评估建模效果, 相关定义如下:

$$\text{RMSE}_q = \sqrt{\frac{\sum_{k=1}^K (y_q(k) - \hat{y}_q(k))^2}{K}} \quad (60)$$

$$\text{APE}_q = \frac{1}{K} \sum_{k=1}^K \left| \frac{y_q(k) - \hat{y}_q(k)}{y_q(k)} \right| \times 100\% \quad (61)$$

式中, K 是样本总数.

被控对象模型训练过程中的 RMSE 变化曲线如图 6 所示, 模型测试过程的拟合效果如图 7 所示. 为了验证该模型的有效性, 使用反归一化后的 RMSE 与 APE 作为性能评价指标, 被控对象模型的建模效果评价如表 2 所示.




图 6 模型训练过程的 RMSE

Fig. 6 RMSE of the model training process

对被控对象建模的实验结果进行分析可知:

1) 根据图 6 中模型训练过程中多变量的 RMSE 的变化曲线可以看出, MIMO-TSFNN 收敛速度快、模型在迭代步数达到 150 步之后即逐渐稳定, 且三个输出的 RMSE 变化曲线均较平滑. 这是因为 MIMO-TSFNN 既具有模糊系统的非线性处理和分析能力, 又对 MSWI 过程具有较强的动态学习能力和解模糊能力. 从图 7 可以看出, 本文提出的 MIMO-TSFNN 学习能力强、模型拟合效果好、建模精度高.

2) 表 2 的评价结果表明, MIMO-TSFNN 模型的训练 RMSE、APE 和测试 RMSE、APE 均较小, 可以满足被控对象的建模需求并用于在线控制过程中.

4.3 控制结果

本节对 MTL-SOFNNC 控制实验进行设计, 实验包括多变量恒定值跟踪控制 (设定点: 0 s), 多变量变设定值跟踪控制 (设定点: 1000 s, 2000 s), 单变量变设定值跟踪控制 (设定点: 2500 s). 采用绝

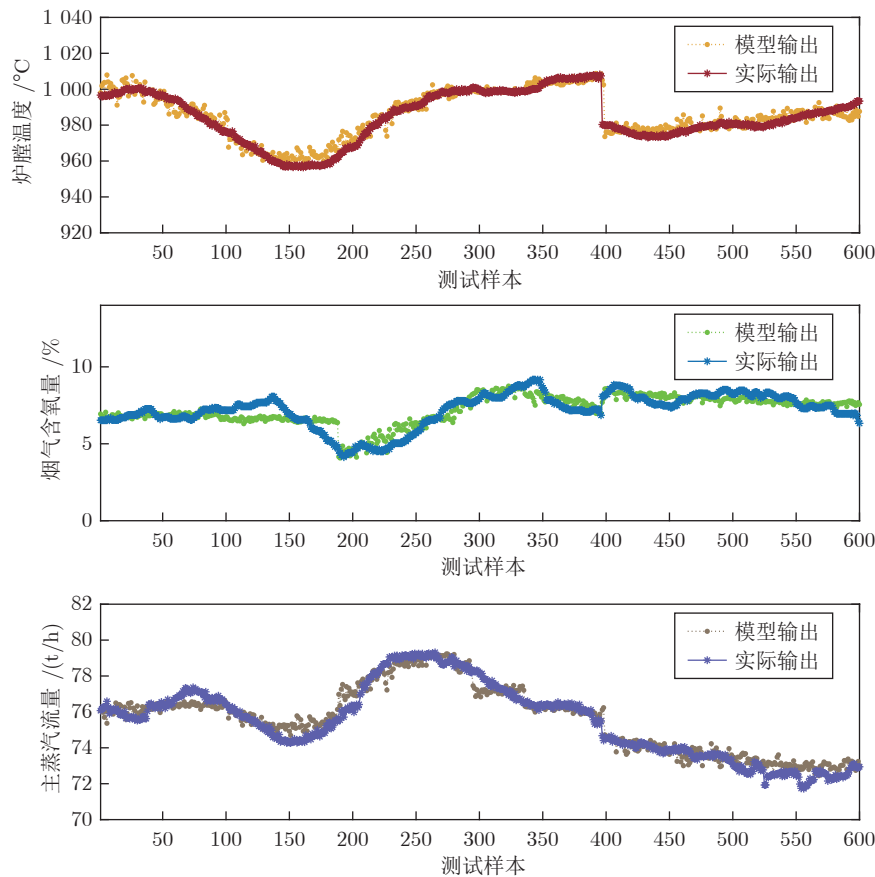


图 7 测试样本拟合效果

Fig.7 Testing samples fitting effect

表 2 被控对象建模效果评价
Table 2 Evaluation of modeling effect of controlled object model

被控模型	评价指标	炉膛温度模型	烟气含氧量模型	主蒸汽流量模型
MIMO-TSFNN	训练	RMSE	3.88 °C	0.30%
		APE	0.27%	3.16%
	测试	RMSE	4.18 °C	0.58%
		APE	0.31%	6.97%

对积分误差 (Integral of absolute error, IAE)、平方积分误差 (Integral of squared error, ISE)、平均超调量 ($\sigma\%$) 和平均上升时间 (\bar{t}_r) 对控制器的瞬态响应、平稳性和抗干扰能力进行评估, 相关定义如下:

$$IAE_{q'} = \frac{1}{t_f - t_0} \int_{t_0}^{t_f} |e_{q'}^c(t)| dt \quad (62)$$

$$ISE_{q'} = \frac{1}{t_f - t_0} \int_{t_0}^{t_f} (e_{q'}^c(t))^2 dt \quad (63)$$

$$\bar{\sigma}_{q'}\% = \frac{\sum_{\varpi=1}^{\Theta} (y_{q'}^{\varpi, \max} - \tilde{y}_{q'}^{\varpi})}{\tilde{y}_{q'}^{\varpi} \Theta} \times 100\% \quad (64)$$

$$\bar{t}_r^{q'} = \frac{\sum_{\varpi=1}^{\Theta} t_{r, 10\% \rightarrow 90\%}^{q', \varpi}}{\Theta} \quad (65)$$

式中, t_0 为控制起始时间, t_f 为控制结束时间, $\tilde{y}_{q'}^{\varpi}$ 和 $y_{q'}^{\varpi, \max}$ 是第 ϖ 次设定值变化后的稳态值和峰值, Θ 是控制时间段内设定值变化的次数, $t_{r, 10\% \rightarrow 90\%}^{q', \varpi}$ 是被控变量从 10% 上升到 90% 所需的时间。

MTL-SOFNNC 的结构在线自组织过程如图 8 所示, 其对操作量的一次风流量与干燥炉排速度的校正过程如图 9 所示。

为了验证 MTL-SOFNNC 的有效性, 将其控制效果与多变量直接自组织模糊神经网络控制 (Multi-variable direct self-organizing fuzzy neural network control, M-DSNNC)^[32]、自组织模糊控制 (Self-organizing fuzzy control, SOFC)^[33]、自组织 T-S 模糊神经网络控制 (Self-organizing T-S fuzzy neural network control, SOTSFNNC)^[34]、T-S 模糊神经网络




图 8 MTL-SOFNNC 的结构自组织过程

Fig.8 Self-organizing process of MTL-SOFNNC structure

络控制 (T-S fuzzy neural network control, TSFNNC) 进行比较, 多变量跟踪控制结果如图 10 所示, 控制误差如图 11 所示. 分别计算不同控制器的 IAE、ISE、 $\bar{\sigma}\%$ 和 \bar{t}_r , 多变量控制性能比较结果如表 3 所示.

根据以上控制实验结果进行分析:

1) 由图 8 可以看出, MTL-SOFNNC 可以根据控制效果在线增长和删减神经元, 保证了控制器网络中神经元的活跃性. 控制器在初始时刻或控制信号变化时及时调整网络结构, 在相对稳定时刻保持了网络结构恒定, 最长稳定时间达到了 866 s. 由图 9~图 11 可知, 在 MSWI 多变量控制实验中, MTL-SOFNNC 能够同时对多个关键操作量进行在线控制: 多变量变设定值设定点 (1000 s、2000 s)、单变量变设定值设定点 (2500 s). 与同类控制器相比, MTL-SOFNNC 具有良好的瞬态响应、平稳性和抗干扰能力, 控制器能够自适应调整网络结构, 控制过程更稳定. 这是因为 MTL-SOFNNC 具有同时响




图 9 操作变量的自校正过程

Fig.9 Self-tuning process of manipulated variables

应多个设定值控制信号的多回路解耦能力, 其可以在某一被控变量出现变化时, 及时进行补偿校正, 以实现多变量的同步控制.

2) 由表 3 可以看出, MTL-SOFNNC 的网络结构更加紧凑, 达到了最少的神经元数量 (10), 这表明该控制器的神经元活跃度较高; 控制器精度更高, 达到了最小的 IAE (1.883, 0.151)、ISE (28.828, 0.124) 和 $\bar{\sigma}\%$ (0.39%, 3.12%); 响应速度更快, 达到了最小的 \bar{t}_r (23.93 s (除 SOTSFNCC 外), 21.47 s). 这是因为 MTL-SOFNNC 结构自组织机制能够在控制状态变化时, 及时改变网络结构. 与同类自组织机制相比, 其无需依靠某一固定阈值, 而是依据神经

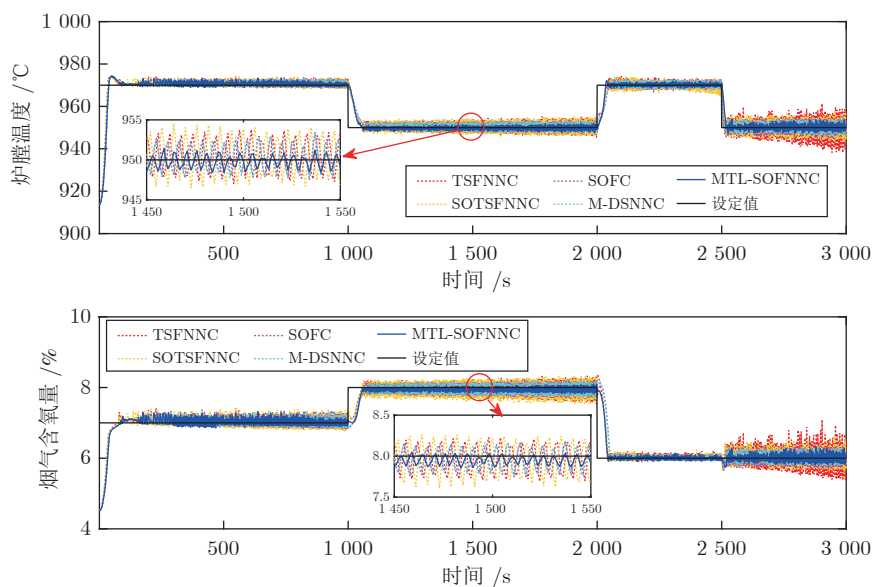


图 10 多变量跟踪控制结果

Fig.10 Multi-variables control tracking results

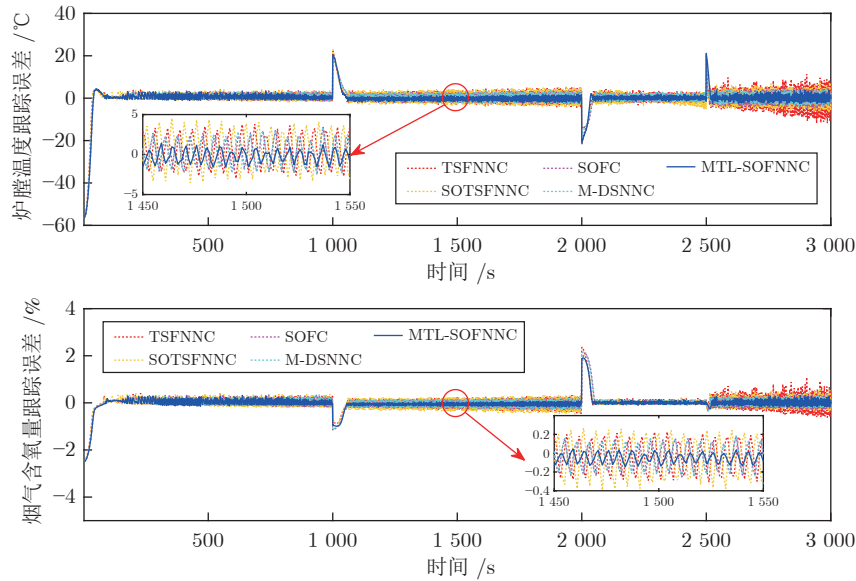


图 11 多变量跟踪控制误差

Fig.11 Multi-variables control tracking errors

表 3 MSWI 过程多变量控制器性能比较

Table 3 Performance comparison of multi-variable controllers for MSWI process

控制器	神经元个数	炉膛温度				烟气含氧量			
		IAE	ISE	$\bar{\sigma}\%$	\bar{t}_r (s)	IAE	ISE	$\bar{\sigma}\%$	\bar{t}_r (s)
MTL-SOFNNC	10	1.883	28.828	0.39%	23.93	0.151	0.124	3.12%	21.47
M-DSNNC	21	2.379	29.374	0.58%	25.68	0.188	0.150	3.14%	29.47
SOFC	20	2.464	30.229	0.46%	30.43	0.194	0.152	3.92%	29.37
SOTSFNNC	17	2.872	30.414	0.72%	23.38	0.214	0.136	4.13%	27.72
TSFNNC	20	2.854	30.728	0.75%	24.14	0.217	0.151	5.45%	34.77

元之间的内部关系进行在线增长或删减神经元,从而获得更好的控制性能。

5 结论

MSWI 是高度复杂的 MIMO 过程,其具有强耦合和强非线性特征,难以建立精准的被控对象模型并施加在线精准控制。针对以上问题,本文提出了一种 MSWI 的数据驱动建模与自组织控制方法,主要研究结论总结如下。

1) 建立了基于 MIMO-TSFNN 的被控对象模型。网络模型具有共享隶属函数层与共享规则层,实现了同时对多个被控量的精准拟合,为多变量在线控制奠定了模型基础。

2) 建立了基于 MTL-SOFNNC 的控制系统。控制器由增长机制、删减机制和恒定机制组成,通过衡量规则层神经元的相似性与多任务学习能力以

自适应调整规则数量,实现了在线多变量跟踪控制。

3) 证明了控制器的稳定性。基于 Lyapunov 定理对控制系统的稳定性进行分析,确保了 MTL-SOFNNC 在实际应用中的可行性。

综上所述,本文所提出的方法对 MSWI 过程具有良好的建模能力与在线控制性能。然而其设定值是基于 MSWI 的实际运行过程给出的,此外,控制器采用的连续控制机制会导致资源消耗等问题。因此,未来的研究将从以下几个方面展开: 1) 设计多目标优化算法,通过优化目标函数得到最优设定值,提升 MSWI 的控制品质; 2) 针对 MIMO 系统构建协同事件触发机制,降低计算负担并提高更新效率。

References

- 1 Editorial Board of China Urban Development Report. *China Urban Development Report 2020/2021*. Beijing: China City Press, 2021.

- (《中国城市发展报告》委员会. 中国城市发展报告 2020/2021. 北京: 中国城市出版社, 2021.)
- 2 Kaza S, Yao L, Bhadattar P, Woerden F V. *What a Waste 2.0: A Global Snapshot of Solid Waste Management to 2050*. Washington: World Bank Publications, 2018.
 - 3 Shah A V, Srivastava V K, Mohanty S S, Varjani S. Municipal solid waste as a sustainable resource for energy production: State-of-the-art review. *Journal of Environmental Chemical Engineering*, 2021, **9**(4): Article No. 105717
 - 4 Lu J W, Zhang S, 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
 - 5 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)
 - 6 Korai M S, Mahar R B, Uqaili M A. The feasibility of municipal solid waste for energy generation and its existing management practices in Pakistan. *Renewable and Sustainable Energy Reviews*, 2017, **72**: 338–353
 - 7 Bhatt M, Chakinala A G, Joshi J B, Sharma A, Sharma A. Valorization of solid waste using advanced thermo-chemical process: A review. *Journal of Environmental Chemical Engineering*, 2021, **9**(4): Article No. 105434
 - 8 Kalyani K A, Pandey K K. Waste to energy status in India: A short review. *Renewable and Sustainable Energy Reviews*, 2014, **31**: 113–120
 - 9 Cheng H, Hu Y. Municipal solid waste (MSW) as a renewable source of energy: Current and future practices in China. *Biore-source Technology*, 2010, **101**(11): 3816–3824
 - 10 Chen D, Christensen T H. Life-cycle assessment (EASEWASTE) of two municipal solid waste incineration technologies in China. *Waste Management & Research*, 2010, **28**(6): 508–519
 - 11 National Development and Reform Commission. The 14th five-year plan for the development of urban domestic waste classification and treatment facilities [Online], available: https://www.ndrc.gov.cn/xwdt/tzgg/202105/t20210513_1279764.html, May 13, 2021
(国家发展改革委. “十四五”城镇生活垃圾分类和处理设施发展规划 [Online], 获取自: https://www.ndrc.gov.cn/xwdt/tzgg/202105/t20210513_1279764.html, May 13, 2021)
 - 12 Ding H, Tang J, Qiao J. Control methods of municipal solid wastes incineration process: A survey. In: Proceedings of the 40th Chinese Control Conference. Shanghai, China: IEEE, 2021. 662–667
 - 13 Guo Hai-Tao, Tang Jian, Ding Hai-Xu, Qiao Jun-Fei. Combustion states recognition method of mswi process based on mixed data enhancement. *Acta Automatica Sinica*, DOI: [10.16383/j.aas.c210843](https://doi.org/10.16383/j.aas.c210843)
(郭海涛, 汤健, 丁海旭, 乔俊飞. 基于混合数据增强的 MSWI 过程燃烧状态识别. *自动化学报*, DOI: [10.16383/j.aas.c210843](https://doi.org/10.16383/j.aas.c210843))
 - 14 Pan X, Tang J, Ding H, Duan H, Qiao J. Air volume setting model of municipal solid waste incineration process based on color moment features of combustion flame. In: Proceedings of the China Automation Congress. Kunming, China: IEEE, 2021. 7984–7989
 - 15 Meng X, Tang J, Qiao J. NOx emissions prediction with a brain-inspired modular neural network in municipal solid waste incineration processes. *IEEE Transactions on Industrial Informatics*, 2022, **18**(7): 4622–4631
 - 16 Chai Tian-You. Development directions of industrial artificial intelligence. *Acta Automatica Sinica*, 2020, **46**(10): 2005–2012
(柴天佑. 工业人工智能发展方向. *自动化学报*, 2020, **46**(10): 2005–2012)
 - 17 Zhou Ping, Zhao Xiang-Zhi. Optimized modeling of dynamic process oriented towards modeling error PDF shape and goodness of fit. *Acta Automatica Sinica*, 2021, **47**(10): 2402–2411
(周平, 赵向志. 面向建模误差 PDF 形状与趋势拟合优度的动态过程优化建模. *自动化学报*, 2021, **47**(10): 2402–2411)
 - 18 Ding Jin-Liang, Yang Cui-E, Chen Yuan-Dong, Chai Tian-You. Research progress and prospects of intelligent optimization decision making in complex industrial process. *Acta Automatica Sinica*, 2018, **44**(11): 1931–1943
(丁进良, 杨翠娥, 陈远东, 柴天佑. 复杂工业过程智能优化决策系统的现状与展望. *自动化学报*, 2018, **44**(11): 1931–1943)
 - 19 Ding H, Tang J, Qiao J. MIMO modeling and multi-loop control based on neural network for municipal solid waste incineration. *Control Engineering Practice*, 2022, **127**: Article No. 105280
 - 20 Saab S S, Hauser M, Ray A. Multivariable nonadaptive controller design. *IEEE Transactions on Industrial Electronics*, 2020, **68**(7): 6181–6191
 - 21 Zhao D D, Li F, Ma R, Zhao G S, Huangfu Y G. An unknown input nonlinear observer based fractional order PID control of fuel cell air supply system. *IEEE Transactions on Industry Applications*, 2020, **56**(5): 5523–5532
 - 22 Wang Y, Wang Z, Zou L, Dong H. Multiloop decentralized H_∞ fuzzy PID-like control for discrete time-delayed fuzzy systems under dynamical event-triggered schemes. *IEEE Transactions on Cybernetics*, 2020, **99**: 1–13
 - 23 Çetin G, Özkaraç O, Keçebaş A. Development of PID based control strategy in maximum exergy efficiency of a geothermal power plant. *Renewable and Sustainable Energy Reviews*, 2021, **137**: Article No. 110623
 - 24 Arruda L V R, Swiech M C S, Neves-Jr F, Delgado M R. Um método evolucionário para sintonia de controladores PI/PID em processos multivariáveis. *Sba: Controle & Automação Sociedade Brasileira De Automatica*, 2008, **19**: 1–17
 - 25 Han H, Zhang L, Liu H, Qiao J. Multiobjective design of fuzzy neural network controller for wastewater treatment process. *Applied Soft Computing*, 2018, **67**: 467–478
 - 26 Qiao J, Hou Y, Zhang L, Han H. Adaptive fuzzy neural network control of wastewater treatment process with multiobjective operation. *Neurocomputing*, 2018, **275**(31): 383–393
 - 27 Dai W, Chai T, Yang S X. Data-driven optimization control for safety operation of hematite grinding process. *IEEE Transactions on Industrial Electronics*, 2014, **62**(5): 2930–2941
 - 28 Wan J, Huang M, Ma Y, Guo W, Wang Y, Zhang H, et al. Prediction of effluent quality of a paper mill wastewater treatment using an adaptive network-based fuzzy inference system. *Applied Soft Computing*, 2011, **11**(3): 3238–3246
 - 29 Chen C S. Robust self-organizing neural-fuzzy control with uncertainty observer for MIMO nonlinear systems. *IEEE Transactions on Fuzzy Systems*, 2011, **19**(4): 694–706
 - 30 Wu H, Qin S, Nie R, Cao J, Gorbachev S. Effective collaborative representation learning for multilabel text categorization. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, **99**: 1–15
 - 31 Ku C C, Lee K Y. Diagonal recurrent neural networks for dy-

namic systems control. *IEEE Transactions on Neural Networks*, 1995, **6**(1): 144–156

- 32 Zhang W, Qiao J. Multi-variable direct self-organizing fuzzy neural network control for wastewater treatment process. *Asian Journal of Control*, 2020, **22**(2): 716–728
- 33 Qiao J, Zhang W, Han H. Self-organizing fuzzy control for dissolved oxygen concentration using fuzzy neural network 1. *Journal of Intelligent & Fuzzy Systems*, 2016, **30**(6): 3411–3422
- 34 Qiao Jun-Fei, Fu Wen-Tao, Han Hong-Gui. Dissolved oxygen control method based on self-organizing T-S fuzzy neural network. *CIESC Journal*, 2016, **67**(3): 960–966
(乔俊飞, 付文韬, 韩红桂. 基于 SOTSFN 的溶解氧浓度控制方法. 化工学报, 2016, **67**(3): 960–966)



丁海旭 北京工业大学信息学部博士研究生. 主要研究方向为城市固废焚烧过程特征建模与智能控制.

E-mail: dinghaixu@emails.bjut.edu.cn

(**DING Hai-Xu** Ph.D. candidate at the Faculty of Information Technology, Beijing University of Technology. His research interest covers feature modeling and intelligent control of municipal solid waste incineration process.)

logy, Beijing University of Technology. His research interest covers feature modeling and intelligent control of municipal solid waste incineration process.)



汤健 北京工业大学信息学部教授. 主要研究方向为小样本数据建模, 城市固废处理过程智能控制.

E-mail: freeflytang@bjut.edu.cn

(**TANG Jian** Professor at the Faculty of Information Technology, Beijing University of Technology.

His research interest covers small sample data modeling and intelligent control of municipal solid waste treatment process.)



乔俊飞 北京工业大学信息学部教授. 主要研究方向为智能控制与智能信息处理, 环境感知和保护自动化技术. 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 intelligent control and intelligent information processing, environmental awareness, and protection automation technology. Corresponding author of this paper.)

Beijing University of Technology. His research interest covers intelligent control and intelligent information processing, environmental awareness, and protection automation technology. Corresponding author of this paper.)