

数据驱动的城市固废焚烧过程多变量自适应预测控制

蒙西^{1,2,3} 徐光辉^{1,2,3} 岳思铭^{1,2,3} 乔俊飞^{1,2,3}

摘要 针对城市固废焚烧 (MSWI) 过程炉膛温度、烟气含氧量等关键工艺参数难以精准控制的问题, 提出一种数据驱动的多变量自适应预测控制方法. 首先, 通过引入操作变量约束和设计加权障碍函数, 构造无约束形式的目标函数以降低优化求解的复杂度; 其次, 提出一种稀疏在线牛顿算法, 通过稀疏分解海森矩阵, 实现控制律的高效求解; 同时, 设计针对多变量控制的加权系数动态分配策略, 能够根据实际运行状态自适应调整炉膛温度和烟气含氧量的权重, 进一步提升控制性能; 此外, 对所提控制方法的可行性和稳定性进行分析, 以确保其在实际应用中的可靠性; 最后, 采用 MSWI 厂实际运行数据验证了所提控制方法的可行性和有效性.

关键词 城市固废焚烧; 多变量自适应预测控制; 稀疏在线牛顿法; 加权障碍函数; 加权系数动态分配策略

引用格式 蒙西, 徐光辉, 岳思铭, 乔俊飞. 数据驱动的城市固废焚烧过程多变量自适应预测控制. 自动化学报, 2026, 52(9): 2019–2031

DOI 10.16383/j.aas.c250367 **CSTR** 32138.14.j.aas.c250367

Data-driven Multivariable Adaptive Predictive Control of Municipal Solid Waste Incineration Process

MENG Xi^{1,2,3} XU Guang-Hui^{1,2,3} YUE Si-Ming^{1,2,3} QIAO Jun-Fei^{1,2,3}

Abstract To address the issue of difficulty in precisely controlling key process parameters such as furnace temperature and flue gas oxygen content in the municipal solid waste incineration process, this paper proposes a data-driven multivariable adaptive predictive control method. Firstly, by introducing operational variable constraints and designing a weighted barrier function, an unconstrained form of the objective function is constructed to reduce the complexity of the optimization solution. Secondly, a sparsified online Newton algorithm is proposed, which achieves efficient solution of the control law through sparse decomposition of the Hessian matrix. Meanwhile, a dynamic weighting coefficient allocation strategy for multivariable control is designed, which can adaptively adjust the weights of furnace temperature and flue gas oxygen content according to the actual operating state, further enhancing the control performance. Additionally, the feasibility and stability of the proposed control method are analyzed to ensure its reliability in practical applications. Finally, the feasibility and effectiveness of the proposed control method are verified using actual operation data from a municipal solid waste incineration plant.

Keywords municipal solid waste incineration; multivariable adaptive predictive control; sparsified online Newton method; weighted barrier function; dynamic weighting coefficient allocation strategy

Citation Meng Xi, Xu Guang-Hui, Yue Si-Ming, Qiao Jun-Fei. Data-driven multivariable adaptive predictive control of municipal solid waste incineration process. *Acta Automatica Sinica*, 2026, 52(9): 2019–2031

随着经济发展以及人口增长, 我国城市固废

(municipal solid waste, MSW) 大量产生, MSW 污染问题已成为重大环境问题^[1]. 相较于卫生填埋与堆肥, 焚烧技术减容减量效果显著, 还能通过回收余热获取可再生能源, 已经成为国内外处理 MSW 的主流方式^[2–3]. 在城市固废焚烧 (municipal solid waste incineration, MSWI) 过程中, 炉膛温度和烟气含氧量是影响运行效果的重要因素. 其中, 炉膛温度直接关系到 MSW 燃烧的完全性和有害污染物的控制, 烟气含氧量则影响燃烧效率与污染物生成^[4]. 因此, 炉膛温度和烟气含氧量的精准控制是保证焚烧过程安全、高效运行的前提.

比例-积分-微分 (proportional-integral-deriv-

收稿日期 2025-08-01 录用日期 2026-01-12

Manuscript received August 1, 2025; accepted January 12, 2026

国家自然科学基金 (62273013, T2442012), 北京市科技新星计划 (20230484310) 资助

Supported by National Natural Science Foundation of China (62273013, T2442012) and Beijing Nova Program (20230484310)

本文责任编辑 刘毅

Recommended by Associate Editor LIU Yi

1. 北京工业大学信息科学技术学院 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. School of Information Science and Technology, Beijing University of Technology, Beijing 100124 2. Beijing Laboratory of Smart Environmental Protection, Beijing 100124 3. Engineering Research Center of Intelligent Perception and Autonomous Control, Ministry of Education, Beijing 100124

active, PID) 控制因其结构简单、易于实现,是目前工业过程中常用的控制策略,也广泛用于 MSWI 过程中^[5-6]。然而,由于 MSWI 过程具有高度非线性、时变性和强耦合等特点,传统 PID 控制在实际运行中往往面临控制精度下降等问题。为此,国内外学者针对 PID 控制进行相应改进。文献[7]提出一种基于径向基函数(radial basis function, RBF)神经网络的 PID 控制方法,通过引入 PID 参数动量因子和历史时刻信息,利用 RBF 网络在线调整 PID 参数,从而提高炉膛温度的控制精度。考虑到传统 PID 控制器难以有效处理多变量控制问题,文献[8]提出一种基于准对角递归神经网络多回路 PID 控制方法,实现对炉膛温度和烟气含氧量的控制。为处理 MSWI 过程中的干扰,文献[9]提出一种基于区间二型模糊宽学习神经网络的 PID 方法,利用区间二型模糊宽学习神经网络的不确定性处理能力应对干扰,有效地提升烟气含氧量的控制精度。随着信息技术的不断发展,越来越多的先进控制技术被引入到 MSWI 过程中。文献[10]利用神经网络调整模糊规则中前件隶属函数的参数与后件回归系数,实现对炉膛温度的控制。为应对 MSWI 过程复杂多变的工况,文献[11]引入自适应因子动态修正控制规则,以提升模糊控制器的鲁棒性。基于实际运行数据,Leskens 等^[12]分析模型预测控制(model predictive control, MPC)对烟气含氧量和主蒸汽流量控制的可行性。为提高预测模型精度,Kortela 等^[13]提出一种基于燃料湿度软传感器的线性 MPC 方法,结合燃料湿度软传感器来补偿线性模型,增强 MPC 在扰动条件下的跟踪能力。此外,针对烟气氧浓度传感器可能出现故障的问题,Sarkar 等^[14]提出一种基于数据协调的故障容错线性 MPC 方法,提升系统在非理想测量环境下的稳定性。Huang 等^[15]提出多模型模糊 MPC 算法,构建数据驱动的多工况模糊模型,并通过顺序二次规划(sequential quadratic programming, SQP)法求解控制律,提高不确定工况下烟气含氧量的控制精度。Böhler 等^[16]提出模糊 MPC 方法,将 MPC 与 Takagi-Sugeno 模糊系统中的隶属函数相结合,提升炉膛温度与烟气含氧量的控制效果。考虑到固废热值和含水量波动所带来的干扰问题,Zlatkovikj 等^[17]提出一种前馈 MPC 方法,将 PI 前馈控制器与 MPC 相结合,有效提升 MPC 方法的控制精度和抗干扰能力。针对烟气含氧量难以精准控制问题,Qiao 等^[18]提出一种数据驱动的事件触发自适应 MPC 方案,通过长短期记忆(long short term memory, LSTM)网络构建烟气含氧量预测模型,采用梯度下降(grad-

ient descent, GD)法求解控制律,并引入事件触发策略以降低计算负担和能耗,从而有效提升烟气含氧量的控制精度。孙剑等^[19]设计一种 MSWI 过程烟气含氧量自适应 MPC 方法,通过径向基神经网络建立烟气含氧量的预测模型,并使用梯度下降法求解控制律,实现烟气含氧量的高效控制。此外,Yan 等^[20]提出一种基于 MPC 的最优控制方法,利用随机配置网络建立烟气含氧量预测模型,同时采用改进的差分进化算法获取控制输入,以确保烟气含氧量的精确跟踪控制。针对炉膛温度难以稳定控制问题,胡开成等^[21]提出一种非线性 MPC 方法,利用随机配置网络建立炉温动态非线性预测模型,并通过改进的海鸥优化算法求解最优控制律,显著提升炉膛温度控制的鲁棒性。Wang 等^[22]提出一种基于区间二型模糊宽学习神经网络的 MPC 方法,结合区间二型模糊宽学习神经网络预测模型和梯度下降优化算法,提升炉膛温度的控制性能。

综上所述,MPC 凭借良好的控制性能,已逐渐成为 MSWI 过程控制的主流方法。其中,预测模型的精度和控制律的高效求解是影响 MPC 方法控制效果的关键因素。现有研究多通过机理分析建立线性状态空间模型,然后采用线性二次规划方法求解最优控制律^[23-24]。然而,对于 MSWI 这一具有强非线性、动态耦合特性的复杂过程,线性或线性化模型难以准确刻画其动态特性,进而限制控制器的性能。此外,在线性模型基础上采用线性二次规划方法,也可能因模型不匹配导致控制效果下降,甚至引发系统不稳定。为此,数据驱动的建模方法正成为应用 MPC 的优先选择^[25-26],梯度类算法、启发式优化算法也广泛用于控制律的求解^[27-28],以进一步提升控制效果。针对上述问题,本文提出一种数据驱动的 MSWI 过程多变量自适应预测控制方法,以期实现对炉膛温度、烟气含氧量等关键工艺参数的高效控制。首先,采用 LSTM 网络建立多输入多输出预测模型,实现对炉膛温度和烟气含氧量变化趋势的准确预测;其次,考虑到实际运行中的约束条件,引入加权障碍函数法构建目标函数,将约束优化问题转化为无约束形式,从而简化求解过程;然后,提出一种稀疏在线牛顿(sparsified online Newton, SoNew)算法,通过对海森矩阵的稀疏化处理和高效分解,提升控制律的求解效率与精度;同时,设计一种被控变量加权系数的动态分配策略,在多变量控制中实现自适应权衡,提升控制过程的鲁棒性。在此基础上,对所提方法进行可行性和稳定性分析,并利用 MSWI 厂实际运行数据验证了所提方法的可行性和有效性。

本文的主要贡献如下:

1) 针对实际运行中的输入约束问题, 引入加权障碍函数法将约束优化问题转化为无约束形式, 并提出一种稀疏在线牛顿算法高效求解控制律, 在保证优化精度的同时显著提升计算效率.

2) 设计一种被控变量加权系数的动态分配策略, 根据运行状态自适应调整权重, 实现多变量控制间的平衡与协同, 增强控制器的鲁棒性.

3) 建立面向 MSWI 过程的多变量自适应预测控制框架, 实现对炉膛温度和烟气含氧量的高效控制.

1 MSWI 过程描述

1.1 MSWI 工艺流程简介

以北京某 MSWI 厂为例, MSWI 过程主要包括固废存储、固废燃烧、余热利用、烟气净化 4 个环节. 首先, 在固废存储环节, 废弃物会进行 5 ~ 7 天的自然发酵, 以降低含水率、提高热值, 进而提高燃烧效率和后端的发电量. 然后, 固废在焚烧炉中依次经过热解、燃烧、熔融等反应, 最终实现减容减量. 在该环节中, 通常会通过控制炉膛温度、烟气停留时间、湍流和过量空气的水平来保证燃烧效率和抑制有害气体的生成. 随后, 焚烧过程中产生的高温烟气通过热交换产生过热蒸汽, 进而驱动汽轮机发电, 实现资源的再生利用, 采用选择性非催化还原 (selective non-catalytic reduction, SNCR) 装置进行炉内烟气脱硝. 最后, 烟气通过脱酸塔、布袋除尘器、选择性催化还原 (selective catalytic reduction, SCR) 装置得以净化, 满足环保排放标准.

1.2 MSWI 过程难点分析

从上述工艺过程分析可知, 固废燃烧是 MSWI 全流程的核心环节, 不仅决定固体废弃物的消纳效果, 还对污染物的排放以及资源的再生利用起到直接作用. 其中, 炉膛温度和烟气含氧量是调控该工艺环节的两个关键工艺参数.

在实际生产过程中, 通常会通过调节给料器速度、炉排速度、一次风和二次风等操作变量实现对炉膛温度和烟气含氧量的控制. 当进料量增加时, 若供氧充足, 燃烧增强、炉温上升; 但若供氧不足, 则可能引发含氧量下降, 燃烧不完全, 反而导致炉温波动或下降. 类似地, 一次风的增加可暂时提高氧气浓度, 促进燃烧反应, 提升炉温; 但随之而来的氧气消耗也可能使含氧量在后期下降. 由此可见, 炉膛温度和烟气含氧量受到多个操作变量的共同影

响, 二者之间存在耦合关系. 此外, 由于 MSWI 过程存在强非线性、时变性和不确定性等特征, 实现两者的协同精准控制仍是一项挑战.

2 MSWI 过程多变量自适应预测控制

2.1 多变量自适应预测控制架构

如图 1 所示, 本文提出一种多变量自适应预测控制方法. 首先, 采用自组织 LSTM 网络^[29]构建多输入多输出预测模型, 实现对炉膛温度和烟气含氧量的精准预测; 其次, 针对系统控制输入的约束条件, 引入加权障碍函数将原始约束问题转化为无约束问题; 随后, 在滚动优化过程中提出稀疏在线牛顿法, 实现无约束目标函数的高效求解; 最后, 设计一种被控变量加权系数的动态调整策略, 利用熵权法在每个优化时刻自适应确定炉膛温度与烟气含氧量的最优权衡关系, 提升多变量协同控制的鲁棒性.

在图 1 中的 LSTM 网络中, $x(t-1)$ 、 $x(t)$ 、 $x(t+1)$ 分别表示对应时刻的输入层数据; $h(t-2)$ 、 $h(t-1)$ 、 $h(t)$ 、 $h(t+1)$ 分别表示对应时刻的隐含状态; $c(t-2)$ 、 $c(t-1)$ 、 $c(t)$ 、 $c(t+1)$ 分别代表贯穿整个时间轴的细胞状态; $y_1(t-1)$ 、 $y_2(t-1)$ 、 $y_1(t)$ 、 $y_2(t)$ 、 $y_1(t+1)$ 、 $y_2(t+1)$ 分别表示各个时刻经过输出层计算后得到的最终预测输出值. 在 LSTM 单元内部, $f(t)$ 、 $i(t)$ 、 $o(t)$ 分别代表遗忘门、输入门和输出门在 t 时刻的输出, 它们通过 sigmoid 激活函数 σ 将值映射到 $[0, 1]$ 中以控制信息的通过率, $\tanh$ 代表通过双曲正切激活函数.

2.2 基于加权障碍函数的无约束目标函数

MPC 是一种基于在线滚动优化的先进控制策略^[30]. 在每个采样时刻, MPC 通过最小化目标函数获取最优控制输入序列, 从而实现对炉膛温度与烟气含氧量的稳定跟踪. 定义优化目标函数如下:

$$J(t) = w_1 J_1(t) + w_2 J_2(t) \quad (1)$$

$$\left\{ \begin{array}{l} J_1(t) = \rho_1 \sum_{i=1}^{H_p} \|r_1(t+i) - \hat{y}_1(t+i)\|_F^2 + \\ \quad \rho_2 \sum_{j=1}^{H_u} \|\Delta u(t+j-1)\|_F^2 \\ J_2(t) = \rho_3 \sum_{i=1}^{H_p} \|r_2(t+i) - \hat{y}_2(t+i)\|_F^2 + \\ \quad \rho_4 \sum_{j=1}^{H_u} \|\Delta u(t+j-1)\|_F^2 \end{array} \right.$$




图1 MSWI过程多变量自适应模型预测控制方法框架

Fig.1 Framework of multivariable adaptive model predictive control method for MSWI process

$$\text{s.t. } u_{\min} < u(t+j) < u_{\max}, \quad \forall j \in [1, H_u - 1] \quad (2)$$

其中, $J(t)$ 表示综合目标函数, $J_1(t)$ 和 $J_2(t)$ 分别对应炉膛温度和烟气含氧量的目标函数, w_1 和 w_2 为加权系数, 满足 $0 < w_1 < 1$, $0 < w_2 < 1$, $w_1 + w_2 = 1$; $r_1(t+i)$ 和 $r_2(t+i)$ 分别表示炉膛温度和烟气含氧量的设定值, $\hat{y}_1(t+i)$ 和 $\hat{y}_2(t+i)$ 分别表示炉膛温度和烟气含氧量的预测值, $u(t+j)$ 为控制输入, $\Delta u(t+j-1) = u(t+j) - u(t+j-1)$ 为控制输入增量, $u_{\min}$ 表示控制输入的最小值, $u_{\max}$ 表示控制输入的最大值, $\rho_1, \rho_2, \rho_3, \rho_4$ 为控制权重因子, $i = 1, 2, \dots, H_p$ 和 $j = 1, 2, \dots, H_u$ 分别为预测步索引和控制步索引, H_p 表示预测时域, H_u 表示控制时域, 且 $H_u < H_p$.

由于式 (2) 存在控制输入约束条件, 使得直接求解非线性优化问题变得困难. 为此, 引入加权障碍函数^[31]来重新设计目标函数, 从而将约束问题转化为无约束问题.

式 (2) 中的约束条件可等价写为

$$\bar{g}_1(u) = u(t+j) - u_{\min} \geq 0 \quad (3)$$

$$\bar{g}_2(u) = u_{\max} - u(t+j) \geq 0 \quad (4)$$

构造加权障碍函数 $v_u(t)$ 如下:

$$v_u(t) = -\alpha_1(t) \ln(\bar{g}_1(u)) - \alpha_2(t) \ln(\bar{g}_2(u)) \quad (5)$$

其中, α_1 和 α_2 为加权因子. 为保证控制系统的稳定性, α_1 和 α_2 随优化过程逐渐减小, 即

$$\alpha_1(t) = \frac{(g_1(u)) \nabla v_u(t-1)}{(1 - \kappa_1)^2 \bar{g}_1^2(u)} \quad (6)$$

$$\alpha_2(t) = \nabla v_u(t-1) \quad (7)$$

其中, $\kappa_1 \in (0, 1)$, $\nabla v_u(t-1)$ 表示 $v_u(t-1)$ 在 $t-1$ 时刻的导数.

结合式 (5), 非线性约束优化问题 (1) 和 (2) 可等效地重构为如下非线性无约束优化问题, 即

$$\hat{J}(t) = w_1 J_1(t) + w_2 J_2(t) + v_u(t) \quad (8)$$

2.3 稀疏在线牛顿法求解控制律

在将原始有约束目标函数转化为无约束目标函数后, 本文提出一种稀疏在线牛顿法, 以高效求解控制律. 为便于后续推导, 炉膛温度和烟气含氧量目标函数定义如下:

$$J_1(t) = \rho_1 [\mathbf{R}_1(t) - \hat{\mathbf{Y}}_1(t)]^T [\mathbf{R}_1(t) - \hat{\mathbf{Y}}_1(t)] + \rho_2 \Delta \mathbf{U}^T(t) \Delta \mathbf{U}(t) \quad (9)$$

$$J_2(t) = \rho_3 [\mathbf{R}_2(t) - \hat{\mathbf{Y}}_2(t)]^T [\mathbf{R}_2(t) - \hat{\mathbf{Y}}_2(t)] + \rho_4 \Delta \mathbf{U}^T(t) \Delta \mathbf{U}(t) \quad (10)$$

其中, $\mathbf{R}_1(t)$ 、 $\mathbf{R}_2(t)$ 分别表示炉膛温度和烟气含氧

量设定值向量, $\hat{\mathbf{Y}}_1(t)$ 、 $\hat{\mathbf{Y}}_2(t)$ 分别表示炉膛温度和烟气含氧量预测值向量, $\Delta \mathbf{U}(t)$ 表示控制输入增量向量.

$$\mathbf{R}_1(t) = [r_1(t+1|t), \dots, r_1(t+H_p|t)]^T \quad (11)$$

$$\mathbf{R}_2(t) = [r_2(t+1|t), \dots, r_2(t+H_p|t)]^T \quad (12)$$

$$\hat{\mathbf{Y}}_1(t) = [\hat{y}_1(t+1|t), \dots, \hat{y}_1(t+H_p|t)]^T \quad (13)$$

$$\hat{\mathbf{Y}}_2(t) = [\hat{y}_2(t+1|t), \dots, \hat{y}_2(t+H_p|t)]^T \quad (14)$$

$$\Delta \mathbf{U}(t) = [\Delta u(t|t), \dots, \Delta u(t+H_u-1|t)]^T \quad (15)$$

由于二阶算法具有更快的求解效率, 采用二阶算法^[32]求解控制律如下:

$$\mathbf{U}(t+1) = \mathbf{U}(t) + \Delta \mathbf{U}(t) \quad (16)$$

$$\Delta \mathbf{U}(t) = -\eta \mathbf{H}^{-1}(t) \mathbf{g}(t) \quad (17)$$

其中, η 为学习率, $\mathbf{H}(t)$ 为海森矩阵, $\mathbf{g}(t)$ 为梯度向量, 计算如下:

$$\mathbf{H}(t) = \frac{\partial^2 \hat{J}(t)}{\partial \mathbf{U}^2(t)} \quad (18)$$

$$\mathbf{g}(t) = \frac{\partial \hat{J}(t)}{\partial \mathbf{U}(t)} \quad (19)$$

设误差向量 $\mathbf{E}_1(t) = \mathbf{R}_1(t) - \hat{\mathbf{Y}}_1(t)$, $\mathbf{E}_2(t) = \mathbf{R}_2(t) - \hat{\mathbf{Y}}_2(t)$, 根据式 (8) ~ (10), 梯度向量和海森矩阵可计算如下:

$$\begin{aligned} \mathbf{g}(t) = \frac{\partial \hat{J}(t)}{\partial \mathbf{U}(t)} = & w_1 \left[-2\rho_1 \left(\frac{\partial \hat{\mathbf{Y}}_1(t)}{\partial \mathbf{U}(t)} \right)^T \mathbf{E}_1(t) + \right. \\ & 2\rho_2 \Delta \mathbf{U}^T(t) \left. \right] + w_2 \cdot \left[-2\rho_3 \left(\frac{\partial \hat{\mathbf{Y}}_2(t)}{\partial \mathbf{U}(t)} \right)^T \mathbf{E}_2(t) + \right. \\ & 2\rho_4 \Delta \mathbf{U}^T(t) \left. \right] + \frac{\partial(v_u(t))}{\partial \mathbf{U}(t)} \end{aligned} \quad (20)$$

$$\begin{aligned} \mathbf{H}(t) = \frac{\partial^2 \hat{J}(t)}{\partial \mathbf{U}^2(t)} = & \frac{\partial}{\partial \mathbf{U}} \left\{ w_1 \left[-2\rho_1 \left(\frac{\partial \hat{\mathbf{Y}}_1(t)}{\partial \mathbf{U}(t)} \right)^T \cdot \right. \right. \\ & \mathbf{E}_1(t) + 2\rho_2 \Delta \mathbf{U}^T(t) \left. \right] + \\ & w_2 \cdot \left[-2\rho_3 \left(\frac{\partial \hat{\mathbf{Y}}_2(t)}{\partial \mathbf{U}(t)} \right)^T \mathbf{E}_2(t) + \right. \\ & 2\rho_4 \Delta \mathbf{U}^T(t) \left. \right] + \frac{\partial(v_u(t))}{\partial \mathbf{U}(t)} \left. \right\} \end{aligned} \quad (21)$$

其中, $\frac{\partial \hat{\mathbf{Y}}_1(t)}{\partial \mathbf{U}(t)}$ 、 $\frac{\partial \hat{\mathbf{Y}}_2(t)}{\partial \mathbf{U}(t)}$ 分别表示 LSTM 预测模型输出

的雅可比矩阵, $\frac{\partial \hat{\mathbf{Y}}_1(t)}{\partial \mathbf{U}(t)}$ 计算如下:

$$\frac{\partial \hat{\mathbf{Y}}_1(t)}{\partial \mathbf{U}(t)} = \begin{pmatrix} \frac{\partial \hat{y}_1(t+1)}{\partial u(t)} & \dots & 0 \\ \vdots & \ddots & \vdots \\ \frac{\partial \hat{y}_1(t+H_p)}{\partial u(t)} & \dots & \frac{\partial \hat{y}_1(t+H_p)}{\partial u(t+H_u-1)} \end{pmatrix} \quad (22)$$

同理, $\frac{\partial \hat{\mathbf{Y}}_2(t)}{\partial \mathbf{U}(t)}$ 计算如下:

$$\frac{\partial \hat{\mathbf{Y}}_2(t)}{\partial \mathbf{U}(t)} = \begin{pmatrix} \frac{\partial \hat{y}_2(t+1)}{\partial u(t)} & \dots & 0 \\ \vdots & \ddots & \vdots \\ \frac{\partial \hat{y}_2(t+H_p)}{\partial u(t)} & \dots & \frac{\partial \hat{y}_2(t+H_p)}{\partial u(t+H_u-1)} \end{pmatrix} \quad (23)$$

进一步, 将式 (21) 写成矩阵形式, 可便于数值求解:

$$\mathbf{H}(t) = \begin{pmatrix} \frac{\partial^2 \hat{J}}{\partial u^2(t)} & \dots & \frac{\partial^2 \hat{J}}{\partial u(t) \partial u(t+H_u-1)} \\ \vdots & \ddots & \vdots \\ \frac{\partial^2 \hat{J}}{\partial u(t+H_u-1) \partial u(t)} & \dots & \frac{\partial^2 \hat{J}}{\partial u^2(t+H_u-1)} \end{pmatrix} \quad (24)$$

为保证海森矩阵的正定性, 对海森矩阵进行处理如下:

$$\mathbf{H}(t) = \mathbf{H}(t) + \theta(t) \mathbf{I} \quad (25)$$

其中, $\mathbf{I}$ 为单位矩阵, $\theta(t)$ 为自适应调整参数, 即

$$\theta(t) = \delta(t) \theta(t-1) \quad (26)$$

$$\delta(t) = \frac{\tau^{\min}(t) + \theta(t-1)}{\tau^{\max}(t) + 1} \quad (27)$$

其中, $\tau^{\min}(t)$ 和 $\tau^{\max}(t)$ 分别为 $\mathbf{H}(t)$ 的最小和最大特征值.

为降低计算和存储成本, 引入图邻接结构思想^[33], 对海森矩阵进行稀疏化处理:

$$P_G(\mathbf{M})_{ij} = \begin{cases} \mathbf{M}_{ij}, & (i, j) \in E_G \\ 0, & (i, j) \notin E_G \end{cases} \quad (28)$$

其中, $P_G(\mathbf{M})$ 为投影算子, 用于将矩阵 $\mathbf{M}$ 投影到图 G 所对应的稀疏结构; $\mathbf{M}_{ij}$ 表示矩阵 $\mathbf{M}$ 中第 i 行第 j 列元素; 图 G 的节点集合为 $\{1, \dots, n\}$, n 为矩阵维度, E_G 表示图 G 中节点的边集, 即 $E_G \subseteq \{(i, j) \mid i, j \in G\}$. 若节点 i 与节点 j 之间存在边, 则 $(i, j) \in E_G$, 相应地, 矩阵中的元素 $\mathbf{M}_{ij}$ 被保留, 反之则将该元素置零, 该稀疏化策略的合理性证明见附录 A.

由于对任意结构的图进行稀疏化处理复杂度较高, 本文假设图 G 为固定的三对角结构图, 其边集定义为

$$E_G = \{(i, j) : |i - j| \leq 1, i \geq 1, j \leq n\} \quad (29)$$

即每个节点仅与自身及相邻节点相连, 对应的稀疏化海森矩阵 $\mathbf{H}'(t)$ 为三对角稀疏结构, 如下所示:

$$\mathbf{H}'(t) = \begin{pmatrix} \frac{\partial^2 \hat{J}}{\partial u^2(t)} + \theta(t)\mathbf{I} & \cdots & 0 \\ \frac{\partial^2 \hat{J}}{\partial u(t+1)\partial u(t)} & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \frac{\partial^2 \hat{J}}{\partial u^2(t+H_u-1)} + \theta(t)\mathbf{I} \end{pmatrix} \quad (30)$$

为进一步提高计算效率, 采用 $\mathbf{LDL}^T$ 分解形式计算 $\mathbf{H}'(t)$:

$$\mathbf{H}'(t) = \mathbf{LDL}^T \quad (31)$$

其中, $\mathbf{L}$ 为下三角矩阵, $\mathbf{D}$ 为对角矩阵, 计算如下^[34]:

$$\mathbf{L} = \begin{bmatrix} 1 & 0 & 0 & \cdots & 0 \\ -\frac{\mathbf{H}'_{21}}{\mathbf{H}'_{22}} & 1 & 0 & \cdots & 0 \\ 0 & -\frac{\mathbf{H}'_{32}}{\mathbf{H}'_{33}} & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ 0 & 0 & \cdots & -\frac{\mathbf{H}'_{t+H_u-1, t+H_u-2}}{\mathbf{H}'_{t+H_u-1, t+H_u-1}} & 1 \end{bmatrix} \quad (32)$$

$$\mathbf{D} = \begin{bmatrix} \mathbf{H}'_{11} - \frac{(\mathbf{H}'_{21})^2}{\mathbf{H}'_{22}} & 0 & \cdots & 0 \\ 0 & \mathbf{H}'_{22} - \frac{(\mathbf{H}'_{32})^2}{\mathbf{H}'_{33}} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \mathbf{H}'_{t+H_u-1, t+H_u-1} \end{bmatrix} \quad (33)$$

采用稀疏化海森矩阵 $\mathbf{H}'(t)$ 计算控制增量, 可得:

$$\Delta \mathbf{U}(t) = -\eta (\mathbf{LDL}^T)^{-1} \mathbf{g}(t) \quad (34)$$

由此, 结合式 (20) 和 (21), 控制律最终表示为

$$\begin{aligned} \Delta \mathbf{U}(t) = & \left[\mathbf{I} + (2\eta w_1 \rho_2 + 2\eta w_2 \rho_4) \cdot (\mathbf{LDL}^T)^{-1} \right]^{-1} \cdot \\ & \eta \left[2\rho_1 w_1 (\mathbf{LDL}^T)^{-1} \cdot \left(\left(\frac{\partial \hat{\mathbf{Y}}_1}{\partial \mathbf{U}} \right)^T \cdot \mathbf{E}_1(t) \right) + \right. \\ & 2\rho_3 w_2 (\mathbf{LDL}^T)^{-1} \cdot \left(\left(\frac{\partial \hat{\mathbf{Y}}_2}{\partial \mathbf{U}} \right)^T \cdot \mathbf{E}_2(t) \right) - \\ & \left. (\mathbf{LDL}^T)^{-1} \frac{\partial (v_u(t))}{\partial \mathbf{U}} \right] \end{aligned} \quad (35)$$

2.4 被控变量加权系数的动态分配策略

为提高多变量协同控制的鲁棒性, 本文采用熵权法动态确定各被控变量的加权系数。

首先, 计算各被控变量的信息熵, 以衡量其在系统性能中的相对影响程度. 设第 k 个被控变量的信息熵为 E_k , 则计算如下:

$$E_k = -\frac{1}{\ln(m)} \sum_{h=1}^m \left(\frac{J_{kh}}{\sum_{h=1}^m J_{kh}} \ln \frac{J_{kh}}{\sum_{h=1}^m J_{kh}} \right) \quad (36)$$

其中, $m > 1$ 为当前采样窗口的样本数, J_{kh} 为第 k 个被控变量在第 h 个采样时刻的目标函数值. E_k 越小, 说明该被控变量对控制性能的影响越显著, 权重应相应提高, 计算如下:

$$w_k = \frac{1 - E_k}{\sum_{k=1}^2 (1 - E_k)} \quad (37)$$

3 递归可行性与稳定性分析

MSWI 过程的动态系统可以描述为

$$\mathbf{Y}(t+1) = f(\mathbf{Y}(t), \mathbf{U}(t)), \mathbf{Y}(t) \in \mathcal{X} \quad (38)$$

其中, $f(\cdot)$ 为非线性函数, $\mathcal{X}$ 是系统状态集合, $\mathbf{U}(t) = \pi(\mathbf{Y}(t))$, $\mathbf{U}(t)$ 满足式 (2) 的约束条件, $\pi(\cdot)$ 为 MPC 策略。

算法 1. 基于稀疏在线牛顿法的 MPC 算法

输入. 初始化 MPC 参数.

输出. 控制输入 $\mathbf{U}(t)$.

1. 构建 LSTM 预测模型, 根据文献 [29], 更新 LSTM 结构, 计算预测输出 $\hat{\mathbf{Y}}_1(t)$ 、 $\hat{\mathbf{Y}}_2(t)$;
2. 根据式 (3) ~ (8) 构建无约束目标函数;
3. **for** $t = 1 : T$
4. 根据式 (36) 计算被控变量的熵值 E_k ;
5. 根据式 (37) 计算被控变量的加权系数 w_k ;
6. 根据式 (20) 和 (21) 计算梯度 $\mathbf{g}(t)$ 和海森矩阵 $\mathbf{H}(t)$;
7. 根据式 (30) 和 (31) 计算稀疏海森矩阵 $\mathbf{H}'(t)$;
8. 根据式 (35) 计算控制增量 $\Delta \mathbf{U}(t)$;
9. 根据式 (16) 计算控制输入 $\mathbf{U}(t)$;
10. **end for**

假设 1^[35-36]. 存在一个 MPC 策略 $\pi(\cdot)$, 在满足式 (2) 所述的约束条件的前提下, 能够使得对于任意 $\mathbf{Y}(t) \in S_f$, $\mathbf{Y}(t+1) \in S_f$, $S_f \subset \mathcal{X}$, S_f 为约束状态集。

定理 1. 如果假设 1 成立, $\mathbf{U}(0)$ 在 $t = 0$ 时是可

行的, $\mathbf{U}(t)$ 满足控制系统对于 $\mathbf{Y}(t)$ 的优化控制问题的约束条件, 那么 $\mathbf{U}(t+1)$ 也满足控制系统对于 $\mathbf{Y}(t+1)$ 的优化控制问题的约束条件, 可以证明 $\mathbf{U}(t)$ 在所有时间步 $t \geq 0$ 上都是可行的.

证明. 时间步 t 时的最优控制序列及最优输出序列表示为

$$\mathbf{U}^*(t) = [u^*(t|t), u^*(t+1|t), \dots, u^*(t+H_u-1|t)]^T \quad (39)$$

$$\mathbf{Y}^*(t+1) = [y^*(t+1|t), \dots, y^*(t+H_p-1|t), y^*(t+H_p|t)]^T \quad (40)$$

其中, $\mathbf{U}^*(t)$ 满足式 (2) 的约束条件, $\mathbf{Y}^*(t+1) \in S_f$. 在时间步 t , 根据 $y^*(t+H_p|t) \in S_f$ 和假设 1, 存在一个满足式 (2) 的约束条件的 MPC 策略 $\pi(y^*(t+H_p|t))$, 使得对于所有 $y^*(t+H_p|t) \in S_f$, 对应的输出 $y(t+H_p+1|t) \in S_f$.

构建时间步 $t+1$ 的控制动作序列^[37]:

$$\begin{aligned} \mathbf{U}(t+1) &= [u^*(t+1|t), u^*(t+2|t), \dots, \\ &\quad u^*(t+H_u-1|t), u(t+H_u|t+1)]^T = \\ &\quad [u^*(t+1|t), u^*(t+2|t), \dots, \\ &\quad u^*(t+H_u-1|t), \pi(y^*(t+H_p|t))]^T \end{aligned} \quad (41)$$

其中, $u(t+H_u|t+1) = \pi(y^*(t+H_p|t))$.

从而产生以下时间步 $t+1$ 的输出序列

$$\begin{aligned} \mathbf{Y}(t+2) &= [y^*(t+2|t), \dots, \hat{y}^*(t+H_p|t), \\ &\quad \hat{y}(t+H_p+1|t)]^T \end{aligned} \quad (42)$$

观察式 (41) 和 (42), 可以发现式 (41) 的前 H_u-1 项属于 $\mathbf{U}^*(t)$, 满足式 (2) 的约束条件, 根据假设 1, $\pi(y^*(t+H_p|t))$ 同样满足式 (2) 的约束条件, 因此 $\mathbf{U}(t+1)$ 中的所有元素均满足式 (2) 的约束条件. 式 (42) 的前 H_p-1 项属于 $\mathbf{Y}^*(t+1)$; 而且 $y(t+H_p+1|t) \in S_f$, 因此 $\mathbf{Y}(t+2)$ 中的所有元素均满足 S_f , $\mathbf{U}(t)$ 在所有时间步 $t \geq 0$ 上都是可行的. $\square$

定义 1. 对于给定的 $T+1$ 个时间步, 容许集定义如下:

$$\begin{aligned} Z_T &= \{(\hat{\mathbf{Y}}(t+k), \mathbf{U}(t+k)) \mid \hat{\mathbf{Y}}(t+k) \in \mathbf{R}^{n_y}, \\ &\quad \mathbf{U}(t+k) \in \mathbf{R}^{n_u}, \hat{\mathbf{Y}}(t+1) = g(\hat{\mathbf{Y}}(t), \mathbf{U}(t)), \\ &\quad \hat{\mathbf{Y}}(t+T) = \hat{\mathbf{Y}}^*(t+T), k=0, \dots, T\} \end{aligned} \quad (43)$$

其中, $\hat{\mathbf{Y}}(t) = [\hat{y}_1(t), \hat{y}_2(t)]^T$, n_y 和 n_u 分别是输出与输入的最大滞后量. 在最优解 $\mathbf{U}^*(t)$ 处, $g(\hat{\mathbf{Y}}(t), \mathbf{U}(t))$ 满足 $g(\hat{\mathbf{Y}}^*(t), \mathbf{U}^*(t)) = \hat{\mathbf{Y}}^*(t)$. $g(\cdot)$ 表示基于

LSTM 网络的预测模型.

假设 2^[38-39]. 对于给定的乘数 λ_s , 通过求解以下问题, 可以得到优化问题的唯一解 $\mathbf{U}^*(t)$

$$\min_{u_{\min} \leq u(t) \leq u_{\max}} \hat{J}(t) + \lambda_s (\hat{\mathbf{Y}}(t) - g(\hat{\mathbf{Y}}(t), \mathbf{U}(t)))^T \quad (44)$$

定理 2. 设存在一个 $\lambda_s > 0$ 满足假设 2, 则闭环系统 (38) 产生的稳态解是渐近稳定的.

证明. 根据假设 2, 存在一个目标函数

$$L(t) = \hat{J}(t) + \lambda_s (\hat{\mathbf{Y}}(t) - g(\hat{\mathbf{Y}}(t), \mathbf{U}(t)))^T - \hat{J}^*(t) \quad (45)$$

满足

$$L(t) \geq \beta(|\hat{\mathbf{Y}}(t) - \hat{\mathbf{Y}}^*(t)|) \quad (46)$$

其中, $\hat{J}^*(t)$ 由最优解 $\mathbf{U}^*(t)$ 计算得出, 目标函数能够在最优点 $\mathbf{U}^*(t)$ 处达到最小值, $\beta(|\hat{\mathbf{Y}}(t) - \hat{\mathbf{Y}}^*(t)|)$ 定义为 K_∞ 函数.

为证明控制系统的稳定性, 定义如下 Lyapunov 函数

$$V(t) = \sum_{k=0}^{T-1} \hat{J}(t+k) + \lambda_s (\hat{\mathbf{Y}}(t) - \hat{\mathbf{Y}}^*(t))^T - \sum_{k=0}^{T-1} \hat{J}^*(t+k) \quad (47)$$

根据定义 1, 式 (47) 可以写为

$$\begin{aligned} V(t) &= \sum_{k=0}^{T-1} (\hat{J}(t+k) + \lambda_s (\hat{\mathbf{Y}}(t+k) - g(\hat{\mathbf{Y}}(t+k), \\ &\quad \mathbf{U}(t+k)))^T) - \sum_{k=0}^{T-1} \hat{J}^*(t+k) = \sum_{k=0}^{T-1} L(t+k) \end{aligned} \quad (48)$$

因此, Lyapunov 函数 $V(t)$ 的变化为

$$V(t+1) - V(t) = -L(t) \leq -\beta(|\hat{\mathbf{Y}}(t) - \hat{\mathbf{Y}}^*(t)|) \quad (49)$$

根据上述分析, 当时间步 t 趋于无穷大时, $V(t)$ 的值将趋近于零. 因此, 当 $t \rightarrow \infty$ 时, $\mathbf{U}(t+T)$ 趋近于 $\mathbf{U}^*(t+T)$, 这意味着 $\hat{J}(t+T)$ 趋近于 $\hat{J}^*(t+T)$. 由此可得

$$\hat{J}(t+1) \leq \hat{J}(t) \quad (50)$$

因此闭环系统 (38) 产生的稳态解是渐近稳定的. $\square$

4 实验分析与结果

4.1 实验描述

本文采用北京市某 MSWI 厂 2023 年 11 月 5 日的运行数据进行实验验证, 采样间隔时间为 10 s, 最终实验数据包括炉排速度、给料器速度、一次风入口流量、一次风加热温度、二次风入口流量、炉膛

温度及烟气含氧量 7 个变量, 共有 4000 组数据.

实验过程中, 给料器速度、炉排速度和一次风入口流量为控制变量, 一次风加热温度和二次风入口流量为干扰变量. 基于稀疏在线牛顿法的 MPC (MPC based on SoNew, MPC-SoNew) 方法 (算法 1), 参数设置如下: $H_p = 3$, $H_u = 1$, $\rho_1 = 0.1$, $\rho_2 = 0.1$, $\rho_3 = 0.001$, $\rho_4 = 0.2$, $n_y = n_u = 2$; LSTM 网络初始隐含层神经元个数为 15; 炉膛温度与烟气含氧量初始设定值为 $950\text{ }^{\circ}\text{C}$ 和 6.5% ; 在采样时刻 500 s 时, 分别改变设定值为 $940\text{ }^{\circ}\text{C}$ 和 7% ; 在采样时刻 950 s 时, 分别改变设定值为 $950\text{ }^{\circ}\text{C}$ 和 6.5% .

此外, 为验证所提 SoNew 算法的性能, 将其与 GD 算法、牛顿算法以及 SQP 算法三种不同的滚动优化算法进行比较. 对比实验均采用加权障碍函数法和被控变量加权系数的动态分配策略.

4.2 控制实验结果

烟气含氧量和炉膛温度的跟踪控制效果如图 2 和图 3 所示, 跟踪误差如图 4 和图 5 所示. 图 2 ~ 5 的结果表明, MPC-SoNew 方法在收敛速度与控制误差方面均优于基于梯度下降法的 MPC (MPC based on GD, MPC-GD) 方法、基于牛顿法的 MPC (MPC based on Newton, MPC-Newton) 方法, 尽管基于顺序二次规划法的 MPC (MPC based on SQP, MPC-SQP) 方法在初始调节阶段的收敛速度比 MPC-SoNew 方法快, 但是其在变设定值跟踪时的误差较大, 难以满足精确控制需求. 图 6 ~ 8 展示了控制变量的变化曲线, 其中, 给料器速度和炉排速度用最大速度的相对值进行表示. 图 9 和图 10 分别展示了不同控制方法在控制过程中烟气含氧量和炉膛温度的加权系数变化过程. 图 9 和图 10 的




图 2 炉膛温度控制效果

Fig.2 Control performance of furnace temperature




图 4 炉膛温度控制误差

Fig.4 Control error of furnace temperature




图 3 烟气含氧量控制效果

Fig.3 Control performance of flue gas oxygen content




图 5 烟气含氧量控制误差

Fig.5 Control error of flue gas oxygen content




图 6 给料器速度变化

Fig.6 Variation of feeder speed




图 7 一次风流量变化

Fig.7 Variation of primary air flow






图 8 炉排速度变化

Fig.8 Variation of grate speed

图 9 被控变量的加权系数 w_1 的分配Fig.9 The allocation of the weighting coefficient w_1 of the controlled variable图 10 被控变量的加权系数 w_2 的分配Fig.10 The allocation of the weighting coefficient w_2 of the controlled variable

结果表明, 加权系数动态分配策略能够有效地为不同的控制方法分配加权系数, 在不同的迭代时刻, 烟气含氧量和炉膛温度的加权系数均有所不同, 且不同控制方法的加权系数分配结果也不同. 这主要是因为不同控制方法的优化算法不同, 从而导致优化过程中侧重的优化对象不同, 由此可见, 加权系数动态分配策略能够增强控制方法的灵活性和适应性.

为进一步验证加权系数动态分配策略的有效性, 将无加权系数动态分配策略的 MPC-SoNew (MPC-SoNew based unweighted dynamic strategy, MPC-SoNew-UDS) 实验与 MPC-SoNew 实验进行对比, 所有初始参数均保持一致. 图 11 和图 12 分别展示了采用 MPC-SoNew 方法和 MPC-SoNew-UDS 方法对炉膛温度与烟气含氧量进行控制时的效果. 结果表明, 与 MPC-SoNew-UDS 方法相比,




图 11 不同滚动优化策略炉膛温度跟踪曲线

Fig.11 Tracking curves of furnace temperature with different rolling optimization strategies




图 12 不同滚动优化策略下烟气含氧量跟踪曲线

Fig.12 Tracking curves of flue gas oxygen content with different rolling optimization strategies

MPC-SoNew 方法虽然在初始响应速度方面较为缓慢,但是在炉膛温度的收敛速度和控制精度上有较大的提升.综上所述,虽然加权系数动态分配策略会牺牲控制器部分初始响应速度性能,但是能保证系统更平稳、快速地跟踪炉膛温度和烟气含氧量.

此外,本文采用积分绝对误差 (integral of ab-

solute error, IAE)、绝对误差与时间乘积积分 (integral time absolute error, ITAE)、积分平方误差 (integral squared error, ISE) 以及平均上升时间来作为评估控制器性能的部分指标^[40-41]:

$$IAE_i = \sum_{t=1}^T |e_i(t)| \quad (51)$$

$$ITAE_i = \sum_{t=1}^T t |e_i(t)| \quad (52)$$

$$ISE_i = \sum_{t=1}^T |e_i(t)|^2 \quad (53)$$

$$\bar{t}_r = \frac{\sum_{n=1}^N t_{r,n}}{N} \quad (54)$$

其中, $e_i(t) = r_i(t) - \hat{y}_i(t)$, $i = 1, 2$. T 是样本个数, N 为控制时间段内设定值变化的次数, $t_{r,n}$ 是被控变量从设定值的 10% 上升到设定值的 90% 所需的时间. $\bar{t}_r$ 指标衡量的是算法动态响应能力.

为进一步全面评估控制器的综合性能,本文引入收敛时间作为衡量系统收敛速度的关键指标.在本研究中,该时间定义为从初始状态开始,到目标函数值在相邻两次迭代间的变化量 (绝对误差) 低于特定容忍误差阈值时所经历的时间^[42],定义平均收敛时间指标为 $\bar{t}_c$.

表 1 给出不同方法在控制性能指标上的对比结果.可以看出,在炉膛温度与烟气含氧量的控制方面, MPC-SoNew 方法的上升时间最短,分别为 25.7 s 和 22.7 s.与 MPC-Newton 方法相比,本文所提方法在上升时间指标上分别缩短 56.22% 和 68.47%;相较于 MPC-GD 方法, MPC-SoNew 方法上升时间分别缩短 71.12% 和 90.63%. MPC-SoNew 方法的收敛时间同样最短,分别为 19.7 s 和 50.7 s,与 MPC-Newton 方法相比,本文所提方法收敛时间分别缩短 7.51% 和 45.89%,相较于 MPC-GD 方法,收敛时间分别缩短 65.44% 和 79.02%.与 MPC-GD 方法、MPC-Newton 方法相比, MPC-SoNew

表 1 不同控制算法的比较结果

Table 1 Comparison results of different control algorithms

方法	炉膛温度					烟气含氧量				
	ISE	IAE	ITAE	$\bar{t}_r$ (s)	$\bar{t}_c$ (s)	ISE	IAE	ITAE	$\bar{t}_r$ (s)	$\bar{t}_c$ (s)
MPC-SQP	139 820.0	10 740.0	6 800 300.0	64.3	135.7	255.8	240.1	155 250.0	182.0	77.0
MPC-GD	586 080.0	12 495.0	2 844 300.0	89.0	57.0	5 633.3	1 134.4	222 270.0	242.3	241.7
MPC-Newton	501 370.0	11 919.0	3 955 900.0	58.7	21.3	4 367.5	882.9	146 610.0	72.0	93.7
MPC-SoNew	237 080.0	8 452.8	2 850 400.0	25.7	19.7	2 637.1	622.3	131 570.0	22.7	50.7

方法在炉膛温度与烟气含氧量 ISE 和 IAE 指标上均有显著改善; 虽然 MPC-SQP 方法的 ISE、IAE 指标较小, 但是 MPC-SQP 方法的炉膛温度 IT-AE 指标值较大, 其 ITAE 值是 MPC-SoNew 方法的 2.39 倍, 是 MPC-GD 方法的 2.39 倍, 是 MPC-Newton 方法的 1.72 倍, 这意味着 MPC-SQP 方法不能较好地实现炉膛温度与烟气含氧量协同控制。综上所述, 与所选方法相比, 本文所提的 MPC-SoNew 方法在解决 MSWI 过程的炉膛温度与烟气含氧量协同控制问题时, 在实时性和精确度方面具有更明显的优势。

5 结束语

为实现 MSWI 过程炉膛温度和烟气含氧量的协同高效控制, 本文提出一种数据驱动多变量自适应预测控制方法。首先, 引入加权障碍函数将非线性约束优化问题转化为无约束优化问题。然后, 提出一种稀疏在线牛顿法, 实现控制律的高效求解。此外, 引入熵权法自适应确定被控变量加权系数, 确保了多变量控制效果。最后, 通过实际运行数据验证了所提方法的优越性。

由于设定值是基于 MSWI 的实际运行过程人工给出的, 具有滞后性, 无法满足 MSWI 过程的全流程智能控制需求。此外, 控制器采用的是时间触发机制, 在每一时刻都会进行更新, 容易造成资源的浪费。在未来的工作中, 我们将进行以下研究: 1) 设计分层 MPC 策略, 分别求解设定值以及控制律, 实现 MSWI 并行优化控制; 2) 构建协同事件触发机制, 降低计算负担和控制器更新次数。

附录 A 稀疏化合理性的证明

证明. 首先引入 LogDet 散度^[43] 来评价稀疏化预处理的质量。LogDet 散度越小表明稀疏化质量越好。

$$D_{\text{LogDet}}(\mathbf{X}, \mathbf{Y}) = \text{tr}(\mathbf{XY}^{-1}) - \log \det(\mathbf{XY}^{-1}) - n \quad (\text{A1})$$

其中, $\text{tr}(\mathbf{XY}^{-1})$ 为矩阵 $\mathbf{XY}^{-1}$ 的迹, 即对角线元素之和; $\det(\cdot)$ 表示行列式, $\log \det$ 表示行列式的对数; n 为矩阵维度; $\mathbf{X}$ 和 $\mathbf{Y}$ 为同维度的正定矩阵。将期望稀疏化后的海森矩阵 $\mathbf{H}'(t)$ 代入 $\mathbf{X}$ 、海森矩阵 $\mathbf{H}(t)$ 代入 $\mathbf{Y}$, 可得:

$$D_{\text{LogDet}}(\mathbf{H}'(t), \mathbf{H}(t)) = \text{tr}(\mathbf{H}'(t)\mathbf{H}^{-1}(t)) - \log \det(\mathbf{H}'(t)\mathbf{H}^{-1}(t)) - n \quad (\text{A2})$$

由式 (A2) 可知, $\text{tr}(\cdot)$ 仅与 $\mathbf{H}'(t)$ 的非零元素有关, 因此在将 $\mathbf{H}(t)$ 按照式 (30) 的稀疏化策略进行稀疏后代入式 (A2) 将不会改变 LogDet 散度值, 那

么可以将式 (A2) 写成

$$D_{\text{LogDet}}(\mathbf{H}'(t), \mathbf{H}(t)) = \text{tr}(\mathbf{H}'(t)\mathbf{P}_G^{-1}(\mathbf{H}(t))) - \log \det(\mathbf{H}'(t)\mathbf{H}^{-1}(t)) - n \quad (\text{A3})$$

对式 (A3) 求关于 $\mathbf{H}'(t)$ 的最优解, 可得:

$$\nabla [\text{tr}(\mathbf{H}'(t)\mathbf{P}_G^{-1}(\mathbf{H}(t))) - \log \det(\mathbf{H}'(t)\mathbf{H}^{-1}(t))] = 0 \quad (\text{A4})$$

其中,

$$\nabla(\text{tr}(\mathbf{H}'(t)\mathbf{P}_G^{-1}(\mathbf{H}(t)))) = \mathbf{P}_G^{-1}(\mathbf{H}(t))$$

$$\nabla(\log \det(\mathbf{H}'(t)\mathbf{H}^{-1}(t))) = (\mathbf{H}'(t))^{-1}$$

因此, 式 (A4) 变为

$$\mathbf{P}_G^{-1}(\mathbf{H}(t)) - (\mathbf{H}'(t))^{-1} = 0 \quad (\text{A5})$$

可以得到, 当期望的稀疏化的矩阵 $\mathbf{H}'(t) = \mathbf{P}_G(\mathbf{H}(t))$ 时, $D_{\text{LogDet}}(\mathbf{H}'(t), \mathbf{H}(t))$ 最小, 因此稀疏化策略是合理的。□

参考文献

- Gómez-Sanabria A, Kiesewetter G, Klimont Z, Schoepp W, Haberl H. Potential for future reductions of global GHG and air pollutants from circular waste management systems. *Nature Communications*, 2022, **13**(1): Article No. 106
- Liu B, Wang P, Zhou J, Guo Y, Ma S J, Chen W Q, et al. Refocusing on effectiveness over expansion in urban waste-energy-carbon development in China. *Nature Energy*, 2025, **10**(2): 215–225
- Qiao Jun-Fei, Meng Xi, Tang Yun-Tao. Perspectives on intelligent optimized control of municipal solid waste incineration process under dual-carbon target. *Science Foundation in China*, 2024, **38**(4): 593–602
(乔俊飞, 蒙西, 汤云涛. 双碳目标下城市固废焚烧过程智能优化控制研究进展及展望. 中国科学基金, 2024, **38**(4): 593–602)
- Sun J, Meng X, Qiao J F. Data-driven optimal control for municipal solid waste incineration process. *IEEE Transactions on Industrial Informatics*, 2023, **19**(12): 11444–11454
- Falconi F, Guillard H, Capitanescu S, Raïssi T. Control strategy for the combustion optimization for waste-to-energy incineration plant. *IFAC-PapersOnLine*, 2020, **53**(2): 13167–13172
- Tian Hao, Tang Jian, Xia Heng, Wang Tian-Zheng, Yu Wen, Qiao Jun-Fei. Furnace temperature control using IT2FBLs-based reinforcement learning PID for MSWI process. *Acta Automatica Sinica*, 2025, **51**(7): 1626–1641
(田昊, 汤健, 夏恒, 王天铮, 余文, 乔俊飞. 基于 IT2FBLs 强化学习 PID 的 MSWI 过程炉膛温度控制. 自动化学报, 2025, **51**(7): 1626–1641)
- He Hai-Jun, Meng Xi, Tang Jian, Qiao Jun-Fei. ET-RBF-PID-based control method for furnace temperature of municipal waste incineration process. *Control Theory and Applications*, 2022, **39**(12): 2262–2273
(何海军, 蒙西, 汤健, 乔俊飞. 基于 ET-RBF-PID 的城市固废焚烧过程炉膛温度控制方法. 控制理论与应用, 2022, **39**(12): 2262–2273)
- Ding H, Tang J, Qiao J F. MIMO modeling and multi-loop control based on neural network for municipal solid waste incineration. *Control Engineering Practice*, 2022, **127**: Article No. 105280

- 9 Yang W, Tang J, Tian H, Yu W, Qiao J F. Flue gas oxygen content control based on interval type-2 fuzzy broad learning system and PID for MSWI process. *IEEE Transactions on Automation Science and Engineering*, 2025, **22**: 15473–15487
- 10 Chen W C, Chang N B, Chen J C. GA-based fuzzy neural controller design for municipal incinerators. *Fuzzy Sets and Systems*, 2002, **129**(3): 343–369
- 11 Shen K, Lu J, Li Z, Liu G. An adaptive fuzzy approach for the incineration temperature control process. *Fuel*, 2005, **84**(9): 1144–1150
- 12 Leskens M, Kesäniemi L B M V, Bosgra O H. Model predictive control as a tool for improving the process operation of MSW combustion plants. *Waste Management*, 2005, **25**(8): 788–798
- 13 Kortela J, Jämsä-Jounela S L. Modeling and model predictive control of the BioPower combined heat and power (CHP) plant. *International Journal of Electrical Power and Energy Systems*, 2015, **65**: 453–462
- 14 Sarkar P, Kortela J, Boriouchkine A, Zattoni E, Jämsä-Jounela S L. Data-reconciliation based fault-tolerant model predictive control for a biomass boiler. *Energies*, 2017, **10**(2): Article No. 194
- 15 Huang X Y, Wang J C, Zhang L W, Wang B H. Data-driven modeling 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
- 16 Böhler L, Krail J, Görtler G, Kozek M. Fuzzy model predictive control for small-scale biomass combustion furnaces. *Applied Energy*, 2020, **276**: Article No. 115339
- 17 Zlatkovikj M, Li H, Zaccaria V, Aslanidou I. Development of feed-forward model predictive control for applications in biomass bubbling fluidized bed boilers. *Journal of Process Control*, 2022, **115**: 167–180
- 18 Qiao J F, Sun J, Meng X. Event-triggered adaptive model predictive control of oxygen content for municipal solid waste incineration process. *IEEE Transactions on Automation Science and Engineering*, 2022, **21**(1): 463–474
- 19 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 (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)
- 20 Yan A, Gu T. Model prediction and optimal control of gas oxygen content for a municipal solid waste incineration process. *Instrumentation*, 2024(1): 101–111
- 21 Hu Kai-Cheng, Yan Ai-Jun, Wang Dian-Hui. Nonlinear model predictive control of furnace temperature for a municipal solid waste incineration process. *Control Theory and Applications*, 2024, **41**(11): 2023–2032 (胡开成, 严爱军, 王殿辉. 城市固废焚烧过程炉温非线性模型预测控制. 控制理论与应用, 2024, **41**(11): 2023–2032)
- 22 Wang B, Tang J, Tian H, Yu W, Qiao J. Improved interval type-II fuzzy broad MPC method for furnace temperature of municipal solid waste incineration process. *IEEE Transactions on Fuzzy Systems*, 2025, **33**(10): 3420–3432
- 23 Stanislawski R, Junga R, Nitsche M. Reduction of the CO emission from wood pellet small-scale boiler using model-based control. *Energy*, 2022, **243**: Article No. 123009
- 24 Böhler L, Fallmann M, Görtler G, Krail J, Schittl F, Kozek M. Emission limited model predictive control of a small-scale biomass furnace. *Applied Energy*, 2021, **285**: Article No. 116414
- 25 Wang B, Tang J, Wang W, Rong J. Interval type-II fuzzy broad model predictive control based on the static and dynamic hybrid event-triggering mechanism and adaptive compensation for furnace temperature in the MSWI process. *Applied Sciences*, 2025, **15**(19): Article No. 10329
- 26 Han H G, Wang Y, Sun H Y, Liu Z, Qiao J F. Data-driven tube based robust predictive control for constrained wastewater treatment process. *IEEE Transactions on Cybernetics*, 2024, **54**(11): 6742–6754
- 27 Han H G, Zhang Y, Sun H Y, Liu Z, Qiao J F. Data-knowledge-driven multiobjective adaptive optimal control for wastewater treatment processes under multiple operating conditions. *IEEE Transactions on Cybernetics*, 2025, **55**(3): 1056–1069
- 28 Qiu Z, Zhang L, Zhang H, Liang H, Li Y. A plunger lifting optimization control method based on APSO-MPC for edge computing applications. *Scientific Reports*, 2025, **15**(1): Article No. 4356
- 29 Sun Jian, Meng Xi, Qiao Jun-Fei. Data-driven predictive control of oxygen content in flue gas for municipal solid waste incineration process. *Control Theory and Applications*, 2024, **41**(3): 484–495 (孙剑, 蒙西, 乔俊飞. 数据驱动的城市固废焚烧过程烟气含氧量预测控制. 控制理论与应用, 2024, **41**(3): 484–495)
- 30 Huang Peng, Wang Ya-Wu, Wu Jun-Dong, Su Chun-Yi, Fukushima Edwardo-Fumihiko. Modeling and control of dielectric elastomer actuator based on neural ordinary differential equation and nonlinear model predictive control. *Acta Automatica Sinica*, 2025, **51**(1): 186–196 (黄鹏, 王亚午, 吴俊东, 苏春翌, 福岛 E. 文彦. 基于神经网络 ODE 和非线性 MPC 的 DEA 建模与控制. 自动化学报, 2025, **51**(1): 186–196)
- 31 Min X, Baldi S, Shi Y, Yu W. Safe control of multi-agent systems via low-complexity control barrier functions. *IEEE Transactions on Automatic Control*, 2025, **70**(10): 6831–6845
- 32 Deng H, Ohtsuka T. A parallel Newton-type method for nonlinear model predictive control. *Automatica*, 2019, **109**: Article No. 108560
- 33 Liu Y, Feng T, Rasouli S, Wong M. ST-DAGCN: A spatiotemporal dual adaptive graph convolutional network model for traffic prediction. *Neurocomputing*, 2024, **601**: Article No. 128175
- 34 Ding W, Xi Y, Li Y. A novel strict color image authentication scheme based on dual-complex LU decomposition. *Computational and Applied Mathematics*, 2024, **43**(4): Article No. 195
- 35 Convens B, Liao-McPherson D, Merckaert K, Vanderborght B, Nicotra M. A terminal state feasibility governor for real-time nonlinear model predictive control over arbitrary horizons. *IEEE Transactions on Control Systems Technology*, 2024, **32**(4): 1341–1356
- 36 Pin G, Parisini T. Networked predictive control of uncertain constrained nonlinear systems: Recursive feasibility and input-to-state stability analysis. *IEEE Transactions on Automatic Control*, 2010, **56**(1): 72–87
- 37 Wang X F, Jiang J, Chen W H. High-level decision making in a hierarchical control framework: Integrating HMDP and MPC for autonomous systems. *IEEE Transactions on Cybernetics*, 2025, **55**(4): 1903–1916
- 38 Shi X, Cao J, Huang W. Distributed parametric consensus optimization with an application to model predictive consensus problem. *IEEE Transactions on Cybernetics*, 2017, **48**(7): 2024–2035
- 39 Diehl M, Amrit R, Rawlings J B. A Lyapunov function for economic optimizing model predictive control. *IEEE Transactions on Automatic Control*, 2010, **56**(3): 703–707
- 40 Yao D, Li H, Shi Y. Adaptive event-triggered sliding-mode control for consensus tracking of nonlinear multiagent systems with unknown perturbations. *IEEE Transactions on Cybernetics*, 2022, **53**(4): 2672–2684

- 41 Sun H Y, Wang J J, Gao H H, Han H G. Robust fault tolerant control based on adaptive dynamic programming with experience replay for wastewater treatment processes. *IEEE Transactions on Fuzzy Systems*, 2025, **33**(9): 3307–3317
- 42 Zeilinger M N, Jones C N, Morari M. Real-time suboptimal model predictive control using a combination of explicit MPC and online optimization. *IEEE Transactions on Automatic Control*, 2011, **56**(7): 1524–1534
- 43 Minh H Q. Infinite-dimensional distances and divergences between positive definite operators, Gaussian measures, and Gaussian processes. *Information Geometry*, 2025, **8**(S1): 21–48



蒙 西 北京工业大学信息科学技术学院教授. 主要研究方向为人工神经网络结构分析与设计, 城市固废焚烧过程智能优化控制. 本文通信作者.

E-mail: mengxi@bjut.edu.cn

(MENG Xi Professor at the School of Information Science and Techno-

logy, Beijing University of Technology. Her research interests include analysis and design of artificial neural network structure and intelligent optimization control of municipal solid waste incineration process. Corresponding author of this paper.)



徐光辉 北京工业大学信息科学技术学院硕士研究生. 主要研究方向为城市固废焚烧过程多变量预测控制.

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

(XU Guang-Hui Master student at the School of Information Science

and Technology, Beijing University of Technology. His main research interest is multivariable predictive control of municipal solid waste incineration process.)



岳思铭 北京工业大学信息科学技术学院硕士研究生. 主要研究方向为城市固废焚烧过程多变量智能控制.

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

(YUE Si-Ming Master student at the School of Information Science

and Technology, Beijing University of Technology. His main research interest is multivariable intelligent control of municipal solid waste incineration process.)



乔俊飞 北京工业大学信息科学技术学院教授. 主要研究方向为计算智能与智能优化控制, 环保自动化.

E-mail: adqiao@bjut.edu.cn

(QIAO Jun-Fei Professor at the School of Information Science and Technology, Beijing University of

Technology. His research interests include computational intelligence and intelligent optimization control, and environmental protection automation.)