邹敏红. 基于改进无模型自适应控制的磨矿过程优化控制分析[J]. 智能计算机与应用,2026,16(5):147-153. DOI:10.20169/j.issn.2095-2163.25111904

基于改进无模型自适应控制的磨矿过程优化控制分析

邹敏红
(矿冶科技集团有限公司, 北京 100160)

摘 要: 针对磨矿过程人工调控易导致生产波动、传统基于模型控制方法效果不佳以及生产数据难以有效利用的问题,本文提出将改进的无模型自适应控制(Model-Free Adaptive Control, MFAC)方法应用于磨矿过程优化控制。通过收集某选矿车间半自磨机工业数据,建立非线性多元回归模型;同时构建小型球磨机实验模型和自主设计的工业级磨矿流程数字孪生模型,分别从单设备、小型流程到工业级全流程 3 个层级,对改进的 MFAC 算法开展仿真验证。结果表明,改进的 MFAC 算法在磨矿过程中具有良好的有效性与可靠性,能够快速响应期望指标切换,有效滤除干扰,精确控制关键参数,为磨矿过程的智能化、数字化升级提供可行的技术方案。

关键词: 磨矿过程; 无模型自适应控制; 数据驱动; 数字孪生; 仿真验证
中图分类号: TP181 **文献标志码**: A **文章编号**: 2095-2163(2026)05-0147-07

Optimization control analysis of grinding process based on improved model free adaptive control

ZOU Minhong
(BGRIMM Technology Group, Beijing 100160, China)

Abstract: Addressing the issues of production fluctuations easily caused by manual regulation in the grinding process, poor performance of traditional model-based control methods, and difficulties in effectively utilizing production data, this paper proposes applying an improved Model-Free Adaptive Control (MFAC) method to optimize control in the grinding process. By collecting industrial data from a semi-autogenous mill in a mineral processing workshop, a nonlinear multiple regression model is established. Simultaneously, with a small ball mill experimental model and an independently designed digital twin model of an industrial-scale grinding process constructed, the improved MFAC algorithm is validated through simulations at three levels: single equipment, small-scale process, and full industrial-scale process. The results demonstrate that the improved MFAC algorithm exhibits good effectiveness and reliability in the grinding process. It can quickly respond to desired indicator switches, effectively filter out disturbances, and precisely control key parameters, providing a feasible technical solution for the intelligent and digital upgrade of the grinding process.

Key words: grinding process; model-free adaptive control; data-driven; digital twin; simulation verification

0 引 言

磨矿过程是选矿生产关键环节,其效果直接影响后续浮选等环节的产品质量、生产效率及企业效益。传统磨矿过程依赖人工调控,受操作人员经验差异、矿石特性动态变化等因素影响,调控滞后且易波动,难以满足高质量生产需求。随着工业智能化与数字化发展,磨矿过程优化控制成为企业提效的关键方向,但磨矿系统存在非线性、多变量耦合、强干扰特性,传统模型控制因建模难、控制精度不足而应用受限。同时,磨矿生产产生的大量运行数据如何有效用于驱动控制算法优化,是解决磨矿控制难题的核心[1]。无模型自适应控制(MFAC)[2]作为数据驱动方法,无需精确系统数学模型,仅通过输入输出数据即可实现控制,为解决磨矿复杂控制问题提供新思路。

本文针对磨矿控制需求改进 MFAC 算法:引入非线性跟踪微分器(Nonlinear Tracking Differentiator, NTD)提升抗干扰能力,加入迭代学习控制(Iterative Learning Control, ILC)加快响应速

作者简介: 邹敏红(1988—),女,硕士。主要研究方向:仪器仪表自动化及智能化控制,信息安全管理。Email:951590080@qq.com。

收稿日期: 2025-11-19

度。通过建立半自磨机工业数据回归模型、采用小型球磨机实验模型及工业级磨矿流程数字孪生模型[3],分层次验证改进算法控制性能,为磨矿优化控制提供有效技术支撑[4]。

1 模型建立与算法设计

1.1 半自磨机工业数据回归模型建立

1.1.1 工业数据收集

选取某选矿车间的 SABC 磨矿流程[5]为研究对象,该流程中半自磨机作为破碎环节后的首个关键设备,其工作状态直接影响后续水力旋流器、球磨机及浮选环节的运行效果[6]。半自磨机可通过调节给矿量、给水量直接影响磨矿效果,相比球磨机建模难度更低,过程更简便。确定以半自磨机为研究对象、通过回归模型验证算法有效性后,经建模算法筛选,最终选用非线性多元回归构建数据模型[7],建模思路如图 1 所示。通过现场传感器采集半自磨机运行数据,并结合部分人工测量数据与相关算法进行扩展补充,共获取大量有效数据,涵盖给矿量、给水量、磨机功率、磨矿浓度、轴压、顽石量等关键参数,部分数据见表 1。

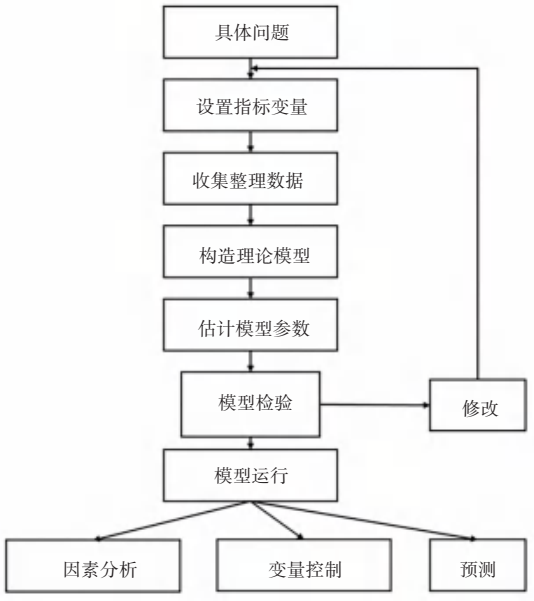


图 1 多元回归预测模型

Fig. 1 Multiple regression prediction model

表 1 半自磨机部分运行数据

Table 1 Partial operating data of the Semi-Autogenous Mill

序号	给矿量/(t·h^{-1})	给水量/(t·h^{-1})	磨机功率/kW	磨矿浓度/%	轴压/MPa	顽石量/(t·h^{-1})
1	534.06	216.95	4 350.44	70.38	52.30	95.12
2	533.44	216.91	4 350.83	70.38	52.40	94.36
3	532.99	216.92	4 349.39	70.37	52.40	93.65
			……			
7 036	481.99	222.29	4 395.50	69.31	52.60	89.33
7 037	480.93	222.23	4 395.92	69.32	52.60	89.25
7 038	480.93	222.21	4 397.61	69.33	52.60	89.22
			……			
15 662	558.34	221.72	4 369.08	69.41	52.20	86.56
15 663	557.92	221.81	4 368.39	69.41	52.30	86.42
15 664	555.50	221.75	4 368.28	69.40	52.30	86.45
			……			

1.1.2 非线性多元回归模型构建

通过相关性分析发现,给矿量、给水量与磨机功率等参数具有强相关性,若单独控制某一参数易导致模型脱离实际。考虑到磨机功率稳定时其他指标通常也保持稳定,因此选取给矿量 x_{1k} 和给水量 x_{2k} 作为自变量,磨机功率 y_k 作为因变量,采用非线性多元回归方法建立模型。建模流程如下:

(1)明确变量定义:设置指标变量,明确自变量(给矿量、给水量)与因变量(磨机功率)的对应关系;(2)数据预处理:收集并整理现场运行数据,确保数据的完整性与有效性;(3)模型结构确定:构造理论模型框架,结合数据特性确定非线性回归的模型形式;(4)参数估计优化:采用最小二乘法估计模型参数,该方法的目标是使实际值与估计值的误差平方和最小,公式如下:

$$Q = \sum_{k=1}^{n} (y_{xk} - \hat{y}_k)^2 \tag{1}$$

式中:y_{xk} 为磨机功率实际值,$\hat{y}_k$ 为模型估计值,n 为数据样本数量。

最后进行模型检验与修改，确保模型的合理性与有效性。经过多次测试与参数优化，最终建立半自磨机功率回归模型，公式如下：

$$y_k = 16.948\,2x_{1k} + 1.129\,8x_{2k} - 0.017\,1x_{1k}^2 + 10 \tag{2}$$

式中：y_k 为磨机功率，x_{1k} 为给矿量，x_{2k} 为给水量。

模型预测功率与实际功率对比结果如图 2 所示，该模型虽无法精确预测每个时刻的功率值，但能将误差控制在较小范围内，且能准确反映实际功率的变化趋势，可用于模拟现场半自磨机系统的输入输出特性，为后续算法验证提供数据支撑。

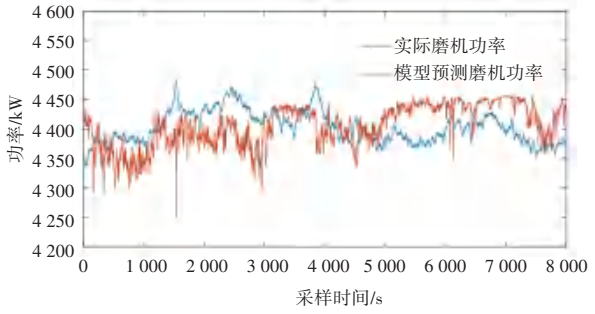


图 2　模型预测功率与实际功率对比

Fig. 2　Comparison between model-predicted power and actual power

1.2　改进无模型自适应控制算法设计

传统 MFAC 算法在磨矿过程控制中易受噪声干扰，且对期望指标切换的响应速度较慢[8]。为提升算法性能，本文对 MFAC 算法进行两方面改进：一是引入非线性跟踪微分器（NTD），增强算法的抗干扰能力，有效滤除现场噪声[9]；二是加入迭代学习控制（ILC）[10]，利用历史控制经验优化当前控制输入，加快系统对期望指标切换的响应速度，形成 MFAC-NTD 和 MFAC-ILC-NTD 两种改进算法[11]。初始磨机功率设置为 $\boldsymbol{y}(1)=\boldsymbol{y}(2)=4\,200$，初始的给矿量和给水量设置为 $\boldsymbol{u}(1)=\boldsymbol{u}(2)=[414\ 100]^{\mathrm{T}}$，初始的 PPDs 设置为 $\boldsymbol{\phi}(1)=\boldsymbol{\phi}(2)=[1\quad 1]^{\mathrm{T}}$，MFAC 的参数设置为 $\lambda=50$，$\rho=1$，$\mu=0.1$，$\eta=0.1$，NTD 的参数设置为 $r=10$，$h=0.005$，$a_1=70$，$a_2=20$，ILC 中自适应因子设置 $F_{f\max}=0.1$，$F_{f\min}=0.05$，$e_{\max}=100$。通过合理设置参数，确保算法在磨矿过程控制中具有良好的稳定性与控制精度。

2　仿真验证与结果分析

为全面验证改进 MFAC 算法的控制性能，分别在半自磨机功率回归模型、小型球磨机实验模型以及工业级磨矿流程数字孪生模型上进行仿真实验，从期望指标切换和抗干扰能力两个方面评估算法效果[12]。

2.1　半自磨机功率回归模型仿真验证

2.1.1　期望功率切换仿真

将半自磨机功率回归模型作为动态数据生成系统，为模拟现场噪声干扰，加入均值为 0、方差为 10 的高斯白噪声[13]。分别采用 MFAC、MFAC-NTD 和 MFAC-ILC-NTD 三种算法进行期望功率切换控制实验，初始条件设置为：初始磨机功率为 $\boldsymbol{y}(1)=\boldsymbol{y}(2)=4\,200$，初始的给矿量和给水量设置为 $\boldsymbol{u}(1)=\boldsymbol{u}(2)=[414\ 100]^{\mathrm{T}}$，初始的 PPDs 为 $\boldsymbol{\phi}(1)=\boldsymbol{\phi}(2)=[1\ 1]^{\mathrm{T}}$。

仿真结果表明，传统 MFAC 算法虽能实现功率控制，但受噪声干扰，输出功率存在小幅波动；MFAC-NTD 算法由于引入 NTD，有效滤除了噪声，功率波动明显减小，且能较好地跟踪期望功率变化，无明显滞后[14]；MFAC-ILC-NTD 算法在加入 ILC 后，经过 200 次迭代，在期望功率切换时响应速度显著加快，甚至能实现对期望功率的完全跟踪，控制效果最优。3 种算法的功率跟踪误差对比见表 2，MFAC-ILC-NTD 算法的均方根误差 RMSE 和最大误差 ERROR 远小于传统 MFAC 算法和 MFAC-NTD 算法，充分证明了改进算法在期望功率切换控制中的优越性。

表 2　半自磨机功率跟踪误差比较

Table 2　Comparison of tracking errors for semi-autogenous mills

控制方法	RMSE	ERROR
MFAC	1.46E+02	2.04E+02
MFAC-NTD	1.31E+01	2.02E+02
MFAC-ILC-NTD	6.41E+00	1.04E+01

2.1.2　功率抗干扰仿真

为模拟磨矿过程中可能出现的未知扰动，如矿石大块增多、衬板磨损等，在仿真第 700 s 时加入幅值为 500、持续时间为 100 s 的方波干扰信号，测试 3 种算法的抗干扰能力[15]。

仿真结果显示，当系统受到干扰时，3 种算法均能通过调整给矿量和给水量使磨机功率逐渐恢复至期望值，但恢复速度与波动程度存在显著差异：传统 MFAC 算法恢复时间长、功率波动大；MFAC-NTD 算法因 NTD 抗干扰作用，功率波动小，但恢复速度与传统 MFAC 相近；MFAC-ILC-NTD 算法在 ILC 作用下，随迭代次数增加，系统抗扰动能力增强，功率恢复速度显著加快，且波动幅度最小。结果表明，改进算法尤其是 MFAC-ILC-NTD 算法，在应对磨矿

过程未知扰动时鲁棒性更强[16]。

2.2 小型球磨机磨矿过程模型仿真验证

为验证改进算法的泛用性,采用文献[17]中广泛应用的小型球磨机磨矿过程实验模型开展仿真验证。该模型的传递函数见下式:

$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} \dfrac{-0.425}{11.7s+1} & \dfrac{0.1052(47.1s+1)}{11.5s+1} \\ \dfrac{2.977}{5.5s+1} & \dfrac{1.063e^{-2.26s}}{2.50s+1} \end{bmatrix} \begin{bmatrix} u_1 \\ u_2 \end{bmatrix} \tag{3}$$

式中:y_1 为磨矿溢流粒度,y_2 为磨矿处理量,u_1 为给矿速率,u_2 为泵池补水速率。

2.2.1 期望溢流粒度切换仿真

设置仿真采样周期为 1 s,为模拟现场实际工况,给溢流粒度和处理量分别加入均值为 0、方差为 0.001 和 0.005 的高斯白噪声。初始条件设置为:初始溢流粒度和处理量为 $\boldsymbol{y}(1)=\boldsymbol{y}(2)=[0.7 \quad 2]^{\mathrm{T}}$,初始给矿量和泵池补水量 $\boldsymbol{u}(1)=\boldsymbol{u}(2)=[0.4 \quad 0.7]^{\mathrm{T}}$,初始的 PPDs 为 $\boldsymbol{\phi}(1)=\boldsymbol{\phi}(2)=\begin{bmatrix} -0.5 & 5 \\ 5 & 0.5 \end{bmatrix}$。

仿真结果表明,传统 MFAC 算法在期望溢流粒度切换时,溢流粒度和处理量均出现较大波动,难以快速稳定至期望值;MFAC-NTD 算法通过 NTD 的滤波作用,有效减小了处理量的波动,溢流粒度的毛刺现象也明显改善,但由于需平衡跟踪性能与滤波效果,溢流粒度的跟踪速度略有下降;MFAC-ILC-NTD 算法在 ILC 的作用下,显著加快了溢流粒度对期望切换的响应速度,波动幅度大幅减小,但随着迭代次数的增加,处理量的波动略有增大。因此,在实际应用中需根据控制目标合理设置迭代次数,以实现溢流粒度与处理量的协同稳定控制。3 种算法的跟踪误差对比见表 3,在溢流粒度控制方面,MFAC-ILC-NTD 算法的 RMSE 和 ERROR 优于 MFAC 算法和 MFAC-NTD 算法,验证了改进算法在多变量磨矿过程控制中的有效性。

表 3 球磨机跟踪误差比较

Table 3 Comparison of ball mill tracking errors

控制指标	控制方法	RMSE	ERROR
溢流粒度	MFAC	3.13E-02	7.68E-02
	MFAC-NTD	1.18E-02	7.93E-02
	MFAC-ILC-NTD	8.70E-03	5.16E-02
磨机处理量	MFAC	1.30E-03	7.29E-02
	MFAC-NTD	8.80E-03	1.51E-02
	MFAC-ILC-NTD	9.22E-03	2.82E-02

2.2.2 溢流粒度抗干扰仿真

为测试算法在多变量耦合下的抗干扰能力,向溢流粒度加入扰动信号。仿真显示,随着 ILC 迭代次数增加,MFAC-ILC-NTD 算法对溢流粒度扰动的抵抗能力逐渐增强,最大误差降低,控制效果持续改善。但由于磨矿过程多变量强耦合,迭代次数过多会使球磨机处理量波动增大,甚至引发系统振荡。因此需构建综合控制指标,权衡溢流粒度与处理量的控制效果,确定最优迭代次数,以保障系统稳定运行。

2.3 工业级磨矿流程数字孪生模型仿真验证

半自磨机模型与小型球磨机模型仅针对单设备或小型流程,难以完全反映工业级磨矿流程的复杂性。为验证改进算法的工业现场应用能力,采用自主开发的工业级磨矿流程数字孪生模型开展仿真实验[18]。该模型基于现场设备参数与工艺流程,结合机理分析与数据驱动方法构建,可精准仿真球磨机、水力旋流器等关键设备,能动态调整以真实模拟运行状态,为磨矿流程的操作优化、故障诊断及经济指标分析提供量化支撑[19]。

本次仿真以某选矿厂一段常规磨矿流程为原型,关键控制设备为球磨机与水力旋流器。设置 3 个控制变量:给矿量、给水量、泵池补加水;2 个被控变量:磨机功率、溢流粒度。磨机功率直接反映设备功效,过高或过低会降低磨矿效率;溢流粒度决定矿石细化程度,影响后续浮选的矿物回收率与产品质量,二者共同构成磨矿过程的核心控制目标[20]。

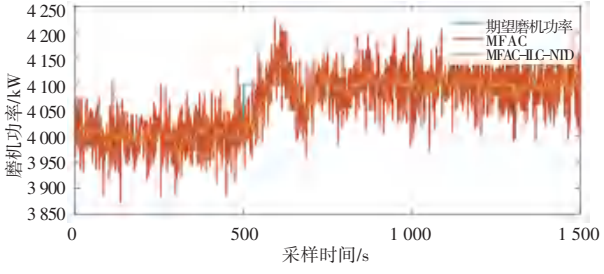
2.3.1 磨矿生产流程关键指标期望控制仿真验证

结合工业现场操作习惯,设置初始仿真条件:初始磨机功率与溢流粒度分别为 $\boldsymbol{y}(1)=\boldsymbol{y}(2)=[4\,000 \quad 0.65]^{\mathrm{T}}$;初始控制变量为 $\boldsymbol{u}(1)=\boldsymbol{u}(2)=[330 \quad 90 \quad 620]^{\mathrm{T}}$;为模拟现场测量噪声,给磨机功率与溢流粒度分别叠加均值为 0、方差为 40 和 0.01 的正态伪随机数;初始伪偏导数矩阵 PPDs 为 $\boldsymbol{\phi}(1)=\boldsymbol{\phi}(2)=\begin{bmatrix} 11 & 10 & 3 \\ -1.12 & 0.9 & 1.11 \end{bmatrix}$,算法参数设置如下:MFAC 基础参数 $\lambda=10$,$\rho=1$,$\mu=1$,$\eta=1$;NTD 参数分两路设置,一路 $r_1=5$,$h_1=0.005$,$a_{11}=-70$,$a_{12}=20$,另一路 $r_2=300$,$h_2=0.000\,1$,$a_{21}=300$,$a_{22}=10$;考虑到工业级模型中控制变量强耦合与大滞后特性,迭代外环 ILC 易导致系统控制性能劣化,故设置 ILC 自适应因子 $F_{j\max}=0$,$F_{j\min}=0$,$e_{\max}=0$,即暂不启用 ILC 迭代功能。仿真分两阶段进行期望指标切换控制如下:

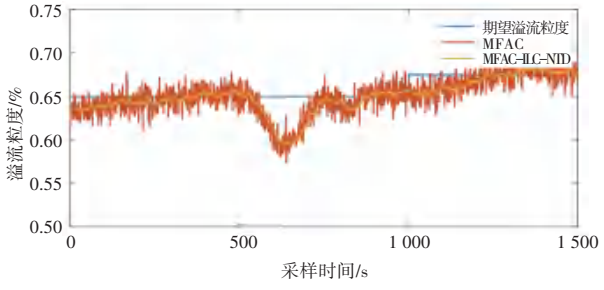
(1)磨机功率提升阶段:初始状态下,因矿石性

质波动与磨机工况不稳定，磨机功率维持在 4 000 kW（低于最佳能效区间）。500 s 时，为提升生产效率，将磨机功率期望目标调整为 4 100 kW。系统通过调节泵池补加水 u_3 间接改变磨机工作状态，虽导致溢流粒度短暂波动，但在 900 s 时刻，磨机功率稳定至 4 100 kW，溢流粒度恢复至初始期望 0.65，流程重新达到平衡。

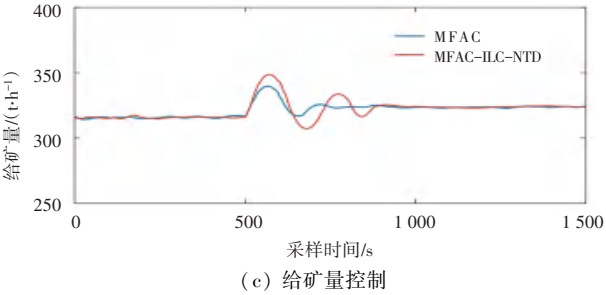
（2）溢流粒度优化阶段：为进一步提升产品质量，1 000 s 时将溢流粒度期望目标提升至 0.675。系统通过协同调整给矿量 u_1 与给水量 u_2，在维持磨机功率稳定的前提下，使溢流粒度在 1 200 s 后稳定至 0.675，实现多目标协同控制。仿真结果如图 3 所示，结合表 4 误差数据可知：传统 MFAC 算法虽能实现基本控制，但受噪声影响严重，被控变量曲线出现明显“毛刺”，在期望目标附近波动；改进的 MFAC- ILC-NTD 算法（暂未启用 ILC）通过 NTD 的滤波作用，有效消除了噪声干扰，磨机功率与溢流粒度的均方根误差 RMSE 和 ERROR 均下降了。尽管系统因工业级模型的大滞后特性，需约 300 s 才能达到新的稳定状态，但完全符合工业现场控制节奏，验证了改进算法在工业级流程中的适用性。



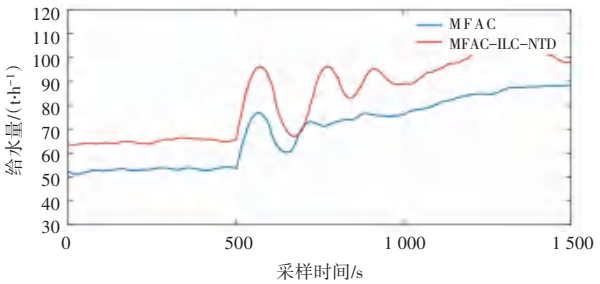
（a）磨机功率控制



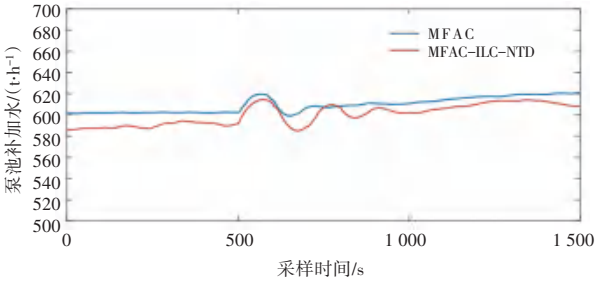
（b）溢流粒度控制



（c）给矿量控制



（d）给水量控制



（e）泵池补加水控制

图 3　磨矿生产流程关键指标期望控制仿真验证

Fig. 3　Simulation verification of expected control for key indicators in grinding production process

表 4　被控变量跟踪误差比较

Table 4　Comparison of tracking errors for controlled variables

控制指标	控制方法	RMSE	ERROR
磨机功率	MFAC	4.07E+03	3.98E+03
	MFAC-ILC-NTD	4.05E+03	3.88E+03
溢流粒度	MFAC	1.87E-02	7.95E-02
	MFAC-ILC-NTD	1.55E-02	6.14E-02

2.3.2　磨矿生产流程关键指标抗干扰仿真验证

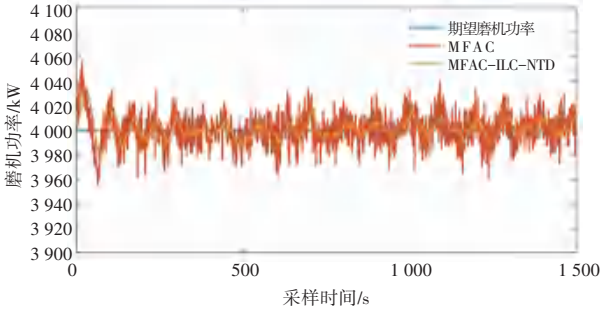
为测试改进算法在工业级流程中的抗干扰鲁棒性，分别针对溢流粒度与磨机功率施加扰动，观测系统动态响应。

（1）溢流粒度扰动实验：200 s 时，给溢流粒度施加幅值为 0.1、持续 200 s 的方波干扰。如图 4 所示，由于溢流粒度与磨机功率存在强耦合且系统滞后显著，为维持磨机功率稳定，溢流粒度随干扰缓慢变化；400 s 干扰消失后，改进算法通过逐步调整泵池补加水与给水量，使溢流粒度在 600 s 左右恢复至期望目标，且磨机功率最大波动不超过 50 kW，远优于传统 MFAC 算法（功率波动超 80 kW）。

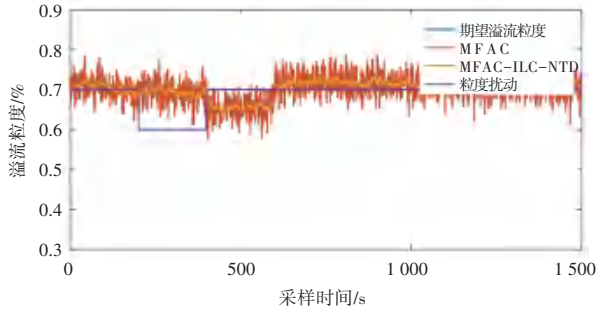
（2）磨机功率扰动实验：200 s 时，给磨机功率施加幅值为 300 kW、持续 200 s 的方波干扰。如图 5 所示，磨机功率瞬间降至 3 700 kW，系统立即启动控制策略，通过增加给矿量与减少给水量提升磨机负载；受系统滞后影响，400 s 干扰消失后，磨机功率

继续上升至 4 200 kW,随后逐步回落,最终在 700 s 稳定至 4 100 kW;期间溢流粒度随功率变化同步调整,最终恢复至 0.65,未出现持续波动。

被控变量抗干扰跟踪误差比较见表 5。



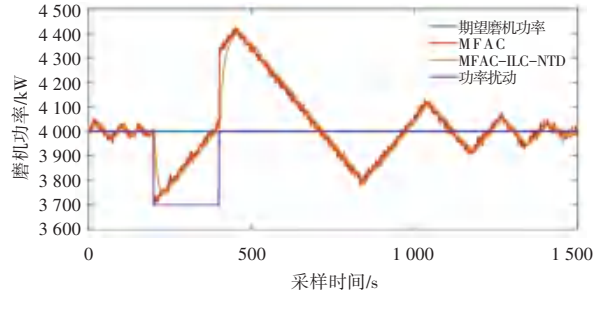
(a) 溢流扰动的磨机功率



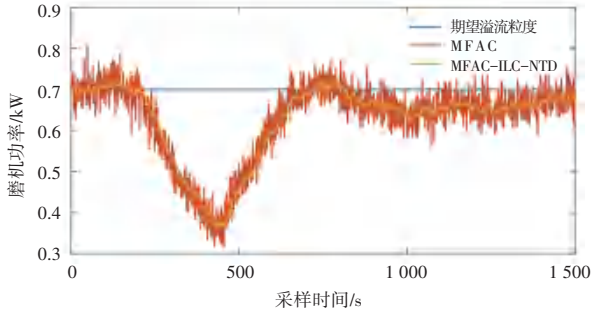
(b) 被扰动的溢流粒度

图 4 溢流粒度扰动仿真验证

Fig. 4 Overflow particle size disturbance simulation validation



(a) 被扰动的磨机功率



(b) 磨机功率扰动下的溢流粒度

图 5 磨机功率扰动仿真验证

Fig. 5 Mill power disturbance simulation verification

表 5 被控变量抗干扰跟踪误差比较

Table 5 Comparison of tracking errors of controlled variables against disturbances

扰动类型	控制指标	控制方法	RMSE	ERROR
磨机功率扰动	磨机功率	MFAC	5.16E+01	3.41E+01
		MFAC-ILC-NTD	2.71E+01	1.30E+01
	溢流粒度	MFAC	1.15E-01	3.22E-02
		MFAC-ILC-NTD	3.26E-02	2.12E-01
溢流粒度扰动	磨机功率	MFAC	1.46E+02	4.34E+02
		MFAC-ILC-NTD	1.35E+02	4.04E+02
	溢流粒度	MFAC	1.22E-01	8.24E-02
		MFAC-ILC-NTD	1.10E-02	2.79E-02

3 结束语

为验证改进无模型自适应控制 MFAC 算法的实际应用价值,本文构建“单设备-小型流程-工业级全流程”三级验证体系并开展系统性测试。结果显示:基于选矿车间半自磨机工业数据构建的非线性多元回归模型,可精准刻画给矿量、给水量与磨机功率的动态关联,为算法验证提供贴合现场的数据支撑。改进 MFAC 算法性能显著优于传统算法:融入非线性跟踪微分器 NTD 的 MFAC-NTD 算法能有效滤除现场噪声,叠加迭代学习控制 ILC 的 MFAC-ILC-NTD 算法,大幅提升期望指标切换响应速度。经数据驱动、实验室模型及工业级数字孪生三级验证,改进算法具备优异的控制精度、抗干扰能力与稳定性,可适配磨矿过程大滞后、强耦合的工业工况,有效解决人工调控波动大、传统控制精度低的痛点,为磨矿过程智能化升级提供可行技术方案。未来可结合多座选矿厂工业数据优化算法参数,引入边缘计算实现实时控制,融合数字孪生与人工智能技术构建预测性维护模型,推动从“控制优化”到“全生命周期管理”的升级,进一步提升选矿生产智能化水平。

参考文献

[1] 张仁忠, 朱英洲, 史业龙, 等. 某矿山无模型自适应磨矿过程控制系统的开发与应用[J]. 现代矿业, 2022, 38(11): 156-160.

[2] ZHANG J. Data-driven model-free adaptive control for nonlinear industrial processes with measurement noise [J]. IEEE Transactions on Industrial Electronics, 2022, 69(8): 8321-8330.

[3] 郭锐, 刘丹, 杜钰, 等. 神经网络在矿物加工中预测应用的研究现状及展望[J]. 硅酸盐通报, 2020, 39(4): 1178-1185.

[4] 高皓一, 张玉金, 张瑞鑫, 等. 基于 RGB-红外校准互补的跨模态目标检测算法[J/OL]. 智能计算机与应用(2025-04-14)

[2025-12-11].
[5]邹敏红，刘道喜，周冶. 水力旋流器控制方法研究及应用[J]. 中国矿业，2023，32(S2)：92-96.
[6]卢绍文，张俊飞，袁致涛. 铝土矿磨矿过程粒度在线预测及优化控制[J]. 有色金属(选矿部分)，2024(2)：102-108.
[7]丁亮，刘伟峰，张红燕. 模糊神经网络—MFAC 在球磨机控制中的应用[J]. 自动化与仪表，2024，39(3)：45-50.
[8]佚名. 模糊 MFAC 方法优化磨矿过程基础回路控制[J]. 自动化技术与应用，2024，43(9)：89-94.
[9]MINCHALA A，RODRIGUEZ J，PEREZ M. Nonlinear model predictive control combined with MFAC for grinding circuit optimization[J]. Control Engineering Practice，2023，132：105489.
[10]周佳怡，孙凯旋，王晓丽，等. 磨矿分级过程控制知识在线提取与更新策略[J]. 控制理论与应用，2025，42(2)：217-225.
[11]王洪超，赵宏伟，李勇. 抗扰动多变量复合控制在磨矿分级过程中的应用[J]. 控制工程，2023，30(4)：678-684.
[12]代伟，桂卫华，阳春华. 案例推理—增强学习融合的磨矿过程优化设定[J]. 化工自动化及仪表，2023，50(7)：1123-1128.
[13]赵大勇，岳恒，柴天佑. 增益自适应内模—MFAC 复合控制在磨矿过程中的应用[J]. 系统仿真学报，2024，36(5)：987-995.
[14]ZHAO H W，DING L，LIU W F. RBF neural network-assisted model-free adaptive control for grinding particle size prediction[J]. Neural Computing and Applications，2023，35(18)：13245-13256.
[15]李凤英，季现伟，耿帅. 铁多金属矿选矿厂智能控制系统设计与应用[J]. 矿冶，2022，31(3)：145-150.
[16]ZHANG R Z，ZHU Y Z，SHI Y L，et al. Development and application of model-Free adaptive control system for semi-autogenous grinding process[J]. Modern Mining，2022，38(12)：45-52.
[17]范柄尧，张颖，张薇濯，等. 新型快速高稳非线性-线性跟踪微分器设计[J]. 工业控制计算机，2021，34(4)：79-82.
[18]张威，张强，王玲晓，等. 塔磨分级过程的智能控制方法及应用[J]. 现代矿业，2023，39(4)：135-139.
[19]ENG H L，YUAN Z T，LU J W，et al. Smith predictor-based model-free adaptive control for silo weight stabilization in HPGR process[J]. Journal of Central South University，2024，31(3)：890-899.
[20]吴文浩，赵金星，李晨，等. 基于 INDI 的四旋翼无人机容错控制研究与性能分析[J]. 智能计算机与应用，2025，15(9)：49-55.