



Contents lists available at ScienceDirect



Engineering

journal homepage: www.elsevier.com/locate/eng

Research
Smart Process Manufacturing—Review

数据驱动选矿过程优化研究进展

丁进良^{*}, 杨翠娥, 柴天佑

State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang 110819, China

ARTICLE INFO

Article history:

Received 23 January 2017

Revised 9 March 2017

Accepted 10 March 2017

Available online 21 March 2017

关键词

数据驱动的优化方法

生产全流程的全局优化

选矿过程

运行优化

摘要

在全球化的市场环境下,经济和环境的因素对复杂工业生产过程综合生产指标的优化提出了更高的要求,如提高生产效率、提高产品质量和产量,以及降低能源和资源的利用。本文简述了基于数据驱动的混合智能优化方法和技术在提高选矿过程全流程运行指标性能方面的最新进展。首先描述了选矿工业过程全流程综合指标优化问题,进而对涉及的数据驱动的优化方法进行总结。该全流程综合指标优化包含四个层次:综合生产指标优化(月综合生产指标)、日综合生产指标优化、运行指标优化和自动化系统设定值优化。最后,本文给出了选矿过程数据驱动优化的未来研究方向。

© 2017 THE AUTHORS. Published by Elsevier LTD on behalf of the Chinese Academy of Engineering and Higher Education Press Limited Company. This is an open access article under the CC BY-NC-ND license (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

1. 引言

选矿生产是典型的复杂工业过程,由多个生产单元、工序或设备组成,一个单元、工序或设备的输出是另一个单元、工序或设备的输入[1]。每个单元、工序或设备都有自己的功能,并且用不同的性能指标去评价其生产质量和效率。每个生产单元操作都有其独自的控制和优化系统,以确保运行指标(质量、效率和生产过程能量和资源的消耗)在其指标范围内,进而转化成控制系统的设定值[2,3]。所有的生产单元组合在一起完成最终产品的生产。各个生产单元的性能指标也称为运行指标,表示产品质量、生产效率等。最终产品的质量等级指标作为衡量全流程生产的生产指标。实际上,生产单元的运行指标直接决定了全流程的生产指标。

众所周知,生产单元的局部优化并不能保证生产全流程的全局优化。因此,需要通过协调各个生产单元的运行指标以实现全流程生产指标的优化[4–8]。如何协调优化各个生产单元达到全流程生产指标(如最终的质量、产量、成本和消耗等)的优化是非常重要的。

近年来,工业过程的运行控制和优化引起了越来越多的关注[4–6,9–12]。化工过程通过实时优化(RTO)和模型预测控制(MPC)的双层系统来保证生产单元的运行优化已经广泛应用[13]。同时,一系列有关RTO的改进和自适应策略来解决RTO需要稳态模型问题的方法也逐渐被提出[6–8,14]。然而RTO是基于模型的方法,无法应用于难以建立数学模型的复杂工业过程。在大规模流程工业如选矿工业中,复杂的物理和化学反应造成了运行指标和控制变量的强非线性和强耦合。此外,运行指标和控制变

* Corresponding author.

E-mail address: jlding@mail.neu.edu.cn

量存在大量不确定性，因此，建立精确的数学模型是非常困难的。目前存在的方法大都是基于单个生产单元的优化而忽略生产单元的耦合关系，从而容易陷入生产单元运行指标的局部最优，并不能确保生产全流程的优化。

为了解决上述问题，近年来基于数据驱动的生产全流程混合智能优化方法相继提出。这些研究的目的在于解决动态环境下全流程运行指标的优化。这些方法的优点在于不需要数学模型而是生产过程的数据。另外，该方法采用了由控制理论的概念组成的闭环策略(如反馈、反馈预测控制和动态调节器等)以适用于动态环境。这些数据驱动的混合智能优化方法的有效性已通过仿真系统或选矿工业应用的验证。

本文概述了选矿工业过程中基于数据驱动优化的最新进展。本文内容如下：第2节描述选矿工业过程问题；第3节简述了基于数据驱动的选矿工业过程的优化方法；第4节总结全文并指出该领域的未来发展方向。

2. 问题描述

选矿工业过程运行指标的决策过程涉及多时间尺度和多空间尺度，如图1所示。首先，企业决策部门根据

经验决定每月的综合生产指标 $Q_j(t_m)$ ($j=1, 2, \dots, J$, J 是生产指标的个数， t_m 是月时间尺度)及其范围。进而，计划和调度部门根据月综合生产指标 $Q_j(t_m)$ 决定出日综合生产指标 $Q_j(t_d)$ ($j=1, 2, \dots, J$, t_d 是日时间尺度)。技术部门将日综合生产指标 $Q_j(t_d)$ 分解为各个生产单元的运行指标 $r_{i,j}^*(t_h)$ ($i=1, 2, \dots, I$, t_h 是小时尺度)。运行优化控制系统根据运行指标产生控制回路的设定值 y^* ，控制系统跟踪该设定值。该运行指标决策系统的具体见参考文献[12]。

3. 数据驱动的混合智能建模与优化

为了实现上述决策过程，文献[12]提出了不同的时间尺度的分层优化结构，其目的是优化选矿生产的全流程生产指标，如图2所示。该系统包含四个层次：综合生产指标优化(月综合生产指标)、日综合生产指标优化、运行指标优化和自动化系统设定值优化[12]。下面主要概述基于数据的建模和优化方法的最新进展。

3.1. 全流程综合生产指标优化

全流程综合生产指标的优化决策涉及两层不同时间

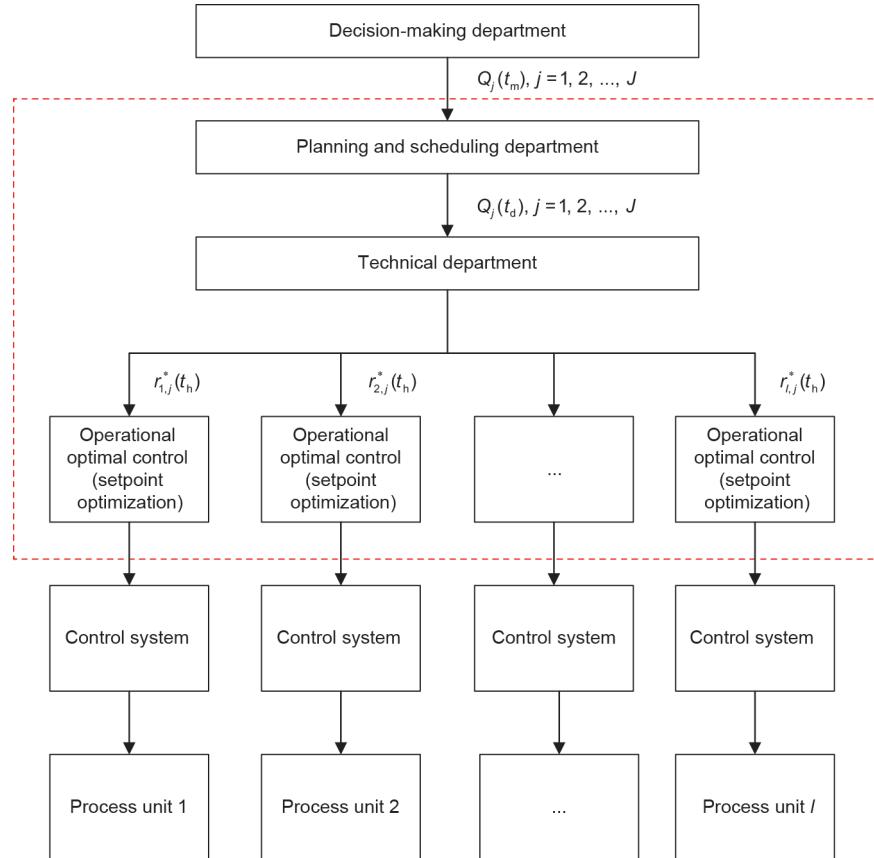


图1. 选矿过程的多层次优化问题描述。

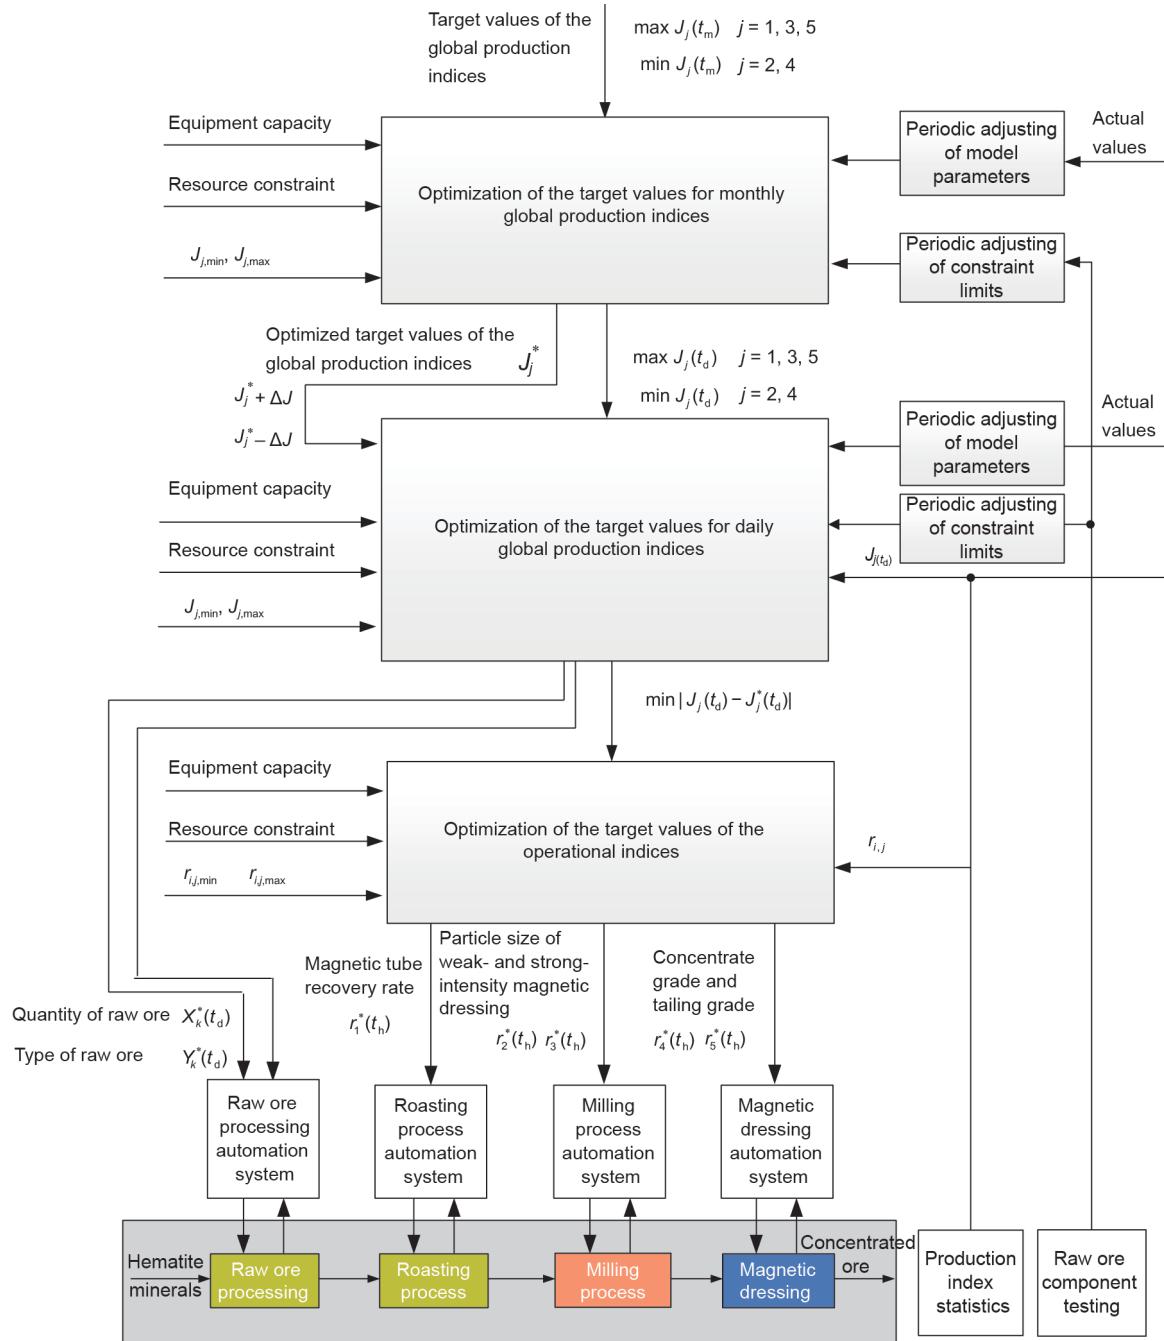


图2. 选矿过程的自动化系统的综合优化结构 (源自文献 [12])。

尺度的指标分解。生产指标的上层决策获得一系列期望的生产目标(主要基于月时间尺度)。而底层的决策是特定时间段(主要以天为周期)的优化, 以达到上层生产目标的期望值。

全流程综合生产指标优化主要关注一段时间内生产消耗的最小化和利润的最大化。文献[15–18]是生产指标优化的单目标调度方法, 目标优化生产效率、品位、生产消耗和利润的其中一个指标。Yu等[9]提出了

一种基于选矿生产指标非线性多目标的优化模型。该模型考虑到了精矿产量、品位、选矿比、金属回收率和生产成本等五个相互冲突的生产指标。同时, 提出了一种基于梯度的混合算子作为解决多目标优化的策略。文献[10]提出了一种电熔镁炉的三目标优化调度方法。文献[11]提出了综合计划和调度的双层结构优化方法, 该方法被证明了能够为决策者提供优化的原矿组合。化工生产过程的相似的工作, 如单阶段、多

阶段连续和多生产过程的计划和调度优化方法参见文献[19,20]。

3.2. 运行指标优化

运行指标是全流程生产指标在空间尺度的分解得到的，运行指标用来衡量单个生产单元的性能(如生产过程中的质量、效率和消耗)。由于运行指标和综合生产指标间的关系难以用数学模型描述，研究如何协调优化生产单元是非常重要的。文献[21]提出了一种动态环境下运行指标的闭环优化结构，如图3所示。该结构包含四个模块：运行指标优化、综合生产指标的预测模型、生产指标前验评估与动态校正和生产指标后验评估与动态校正。每个模块的功能如下。

- **运行指标优化模块：**该模块根据生产指标 $Q_j(t_d)$ ($j=1,2,\dots,J$)生成一系列的运行指标 $r_{i,j}$ ($i=1,2,\dots,I$)及其范围 $[r_{i,\min}, r_{i,\max}]$ 。
- **综合生产指标的预测模块：**该模块根据产生的运行指标来预测可能达到的综合生产指标的预测值 $\hat{Q}_k(t)$ 。
- **生产指标前验评估和动态校正：**该模块利用运行指标的目标值 $r_i^*(t)$ 和预测值 $\hat{r}(t)$ 的偏差来产生运行指标的补偿值 $\Delta\hat{r}(t)$ 。
- **生产指标后验评估和动态校正：**该模块根据实际的生产指标 $Q_j(T)$ 和生产指标的目标值 Q_j^* 产生运

行指标的补偿值 $\Delta r(T)$ ，其中， t 是采样周期， T 是测试周期，并有 $T=nt$ ， n 是整数。

3.2.1. 运行指标的优化

文献[21,22]提出了基于案例推理(CBR)和多目标进化计算(MOEA)的混合决策方法。该方法首先用MOEA对运行指标进行优化得到优化指标解集，然后用CBR根据经验值和MOEA得到的解集对当前状态的运行指标进行决策。文献[23]提出了一种多目标优化方法来求解选矿过程的多阶段生产问题。文献[24]提出了结合动态多目标优化和CBR的方法解决运行指标优化决策问题。实际上，运行指标优化决策问题本身是动态问题，为解决该动态问题，文献[25]提出了一种针对生产设备能力动态变化条件下的动态多目标综合生产指标优化方法。

3.2.2. 生产指标的预测

生产指标预测模型采用线性模型(主模型)和非线性误差补偿模型组成的混合建模结构[21,22,24]。线性模型给出生产指标和运行指标的主要关系，而基于最小二乘支持向量机的非线性误差补偿模型[26]用来补偿线性模型的误差，以提高预测模型的精度。文献[1]首次提出采用基于最小化模型误差的概率密度函数(PDF)和最小误差熵的方法来选择非线性补偿模型的参数。文献[27]提出了一种基于多模型综合生产指标预测方法。该

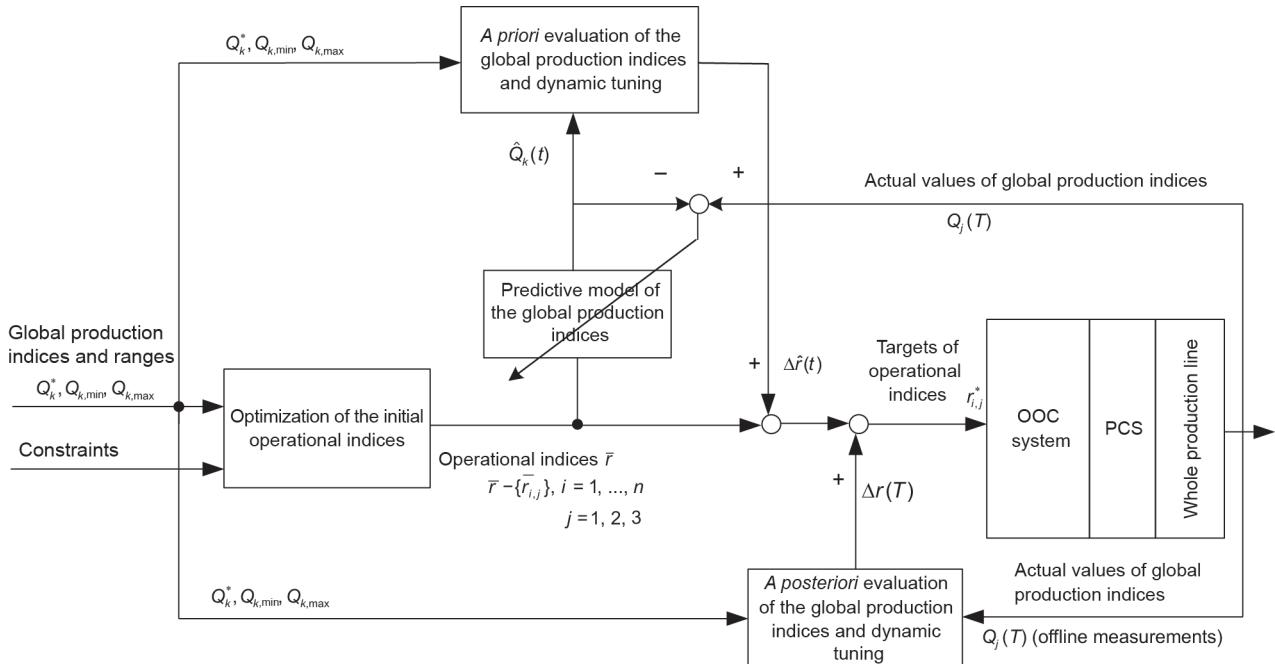


图3. 运行指标优化结构[21]。

方法将多模型、模糊聚类算法和机器学习算法相结合来预测多工况条件下的生产指标。为了实现在线预测，文献[28]提出了一种基于数据的自适应在线预测模型，通过使用训练样本方法的统计特性在线更新模型的参数，从而实现在线校正预测模型。文献[29]提出了一种通过修改Adaboost算法权重的鲁棒预测方法，该方法可以降低模型对异常值的敏感度。

3.2.3. 动态校正方法

文献[30]提出了一种基于知识的全流程运行指标优化方法。该方法最大限度地减少由选矿过程运行中的不确定性对生产造成的影响。该方法利用生产过程诊断出的自适应信息来建立闭环动态模型，同时提出了基于粗糙集的规则提取方法来产生补偿规则。此外，文献[24]将强化学习算法用于在两个不同的时间尺度下补偿不确定性和在线更正基准运行指标，这个学习循环基于Actor-Critic架构。

3.3. 运行优化控制 / 设定值优化

设定值是通过将运行指标进一步分解得到最终的决策。一般来说，设定值的优化应该考虑生产设备的特性[31]。例如，文献[32]提出了一种用于竖炉焙烧过程的混合智能控制方法，该方法可以通过在线调整控制回路的设定点来将运行指标控制在所需范围内。文献[33]提出了基于智能的监控控制策略的磨矿系统设定值优化方法，该方法包括控制回路设定值优化模块、基于人工神经网络的软测量模块、基于模糊逻辑的动态调节器等，并集成了一个基于专家知识的负荷诊断和调整模块来实现设定值优化的功能。更多详细内容可以参考文献[31,34]。

4. 结论和未来发展方向

复杂工业生产包含多个过程单元，并且这些过程通常存在不确定性，该不确定性需要整个生产线全局综合生产指标的优化，即表征生产全流程与质量、产量、效率和成本相关的性能指标的优化。本文针对选矿工业生产全流程优化相关的建模与优化方法问题进行了简单回顾和总结。

如文献[12]所述，对企业各部门的优化决策，包括计划调度、运行指标优化、全流程优化与控制等，进行统一考虑，实现一体化的优化决策与控制，对实现生产

全流程的全局优化具有重要的意义。此外，进一步深入探讨文献[21]提出的数据驱动混合智能优化结构的有效性和普遍性，并且研究相应各个模块的设计方法与性能分析方法，对实现生产过程的全流程优化同样具有重要意义。

致谢

本文由国家自然科学基金项目(61525302, 61590922)和辽宁省项目(2014020021和LR201502)资助。

Compliance with ethics guidelines

Jinliang Ding, Cuie Yang, and Tianyou Chai declare that they have no conflict of interest or financial conflicts to disclose.

References

- [1] Ding J, Chai T, Wang H. Offline modeling for product quality prediction of mineral processing using modeling error PDF shaping and entropy minimization. *IEEE Trans Neural Netw* 2011;22(3):408–19.
- [2] Jäschke J, Skogestad S. NCO tracking and self-optimizing control in the context of real-time optimization. *J Process Contr* 2011;21(10):1407–16.
- [3] Würth L, Hannemann R, Marquardt W. A two-layer architecture for economically optimal process control and operation. *J Process Contr* 2011;21(3):311–21.
- [4] Engell S. Feedback control for optimal process operation. *IFAC Proc Vol* 2006;39(2):13–26.
- [5] Mercangöz M, Doyle FJ III. Real-time optimization of the pulp mill benchmark problem. *Comput Chem Eng* 2008;32(4–5):789–804.
- [6] Adetola V, Guay M. Integration of real-time optimization and model predictive control. *J Process Contr* 2010;20(2):125–33.
- [7] Qin SJ, Cherry G, Good R, Wang J, Harrison CA. Semiconductor manufacturing process control and monitoring: A fab-wide framework. *J Process Contr* 2006;16(3):179–91.
- [8] Bartusiak RD. NLMPc: A platform for optimal control of feed- or product-flexible manufacturing. In: Findeisen R, Allgöwer F, Biegler LT, editors *Assessment and future directions of nonlinear model predictive control*. Berlin: Springer; 2007. p. 367–81.
- [9] Yu G, Chai T, Luo X. Multiobjective production planning optimization using hybrid evolutionary algorithms for mineral processing. *IEEE Trans Evol Comput* 2011;15(4):487–514.
- [10] Kong W, Ding J, Chai T, Zheng X, Yang S. A multiobjective particle swarm optimization algorithm for load scheduling in electric smelting furnaces. In: *Proceedings of the 2013 IEEE Symposium on Computational Intelligence for Engineering Solutions (CIES)*; 2013 Apr 16–19; Piscataway: IEEE; 2013. p. 188–95.
- [11] Yu G, Chai T, Luo X. Two-level production plan decomposition based on a hybrid MOEA for mineral processing. *IEEE Trans Autom Sci Eng* 2013;10(4):1050–71.
- [12] Chai T, Ding J, Yu G, Wang H. Integrated optimization for the automation systems of mineral processing. *IEEE Trans Autom Sci Eng* 2014;11(4):965–82.
- [13] Marchetti AG, Ferramosca A, González AH. Steady-state target optimization designs for integrating real-time optimization and model predictive control. *J Process Contr* 2014;24(1):129–45.
- [14] Chachuat B, Srinivasan B, Bonvin D. Adaptation strategies for real-time optimization. *Comput Chem Eng* 2009;33(10):1557–67.
- [15] Chen VYX. A 0–1 goal programming model for scheduling multiple maintenance projects at a copper mine. *Eur J Oper Res* 1994;76(1):176–91.
- [16] Bevilacqua M, Ciarapica FE, Giacchetta G. Critical chain and risk analysis applied to high-risk industry maintenance: A case study. *Int J Proj Manag* 2009;27(4):419–32.

- [17] Kumral M. Genetic algorithms for optimization of a mine system under uncertainty. *Prod Plann Contr* 2004;15(1):34–41.
- [18] Cisternas LA, Gálvez ED, Zavala MF, Magna J. A MILP model for the design of mineral flotation circuits. *Int J Miner Process* 2004;74(1–4):121–31.
- [19] Li Z, Ierapetritou M. Process scheduling under uncertainty: Review and challenges. *Comput Chem Eng* 2008;32(4–5):715–27.
- [20] Pinto JM, Grossmann IE. Assignment and sequencing models for the scheduling of process systems. *Ann Oper Res* 1998;81:433–66.
- [21] Chai T, Ding J, Wang H. Multi-objective hybrid intelligent optimization of operational indices for industrial processes and application. *IFAC Proc Vol* 2011;44(1):10517–22.
- [22] Ding J, Chai T, Wang H, Wang J, Zheng X. An intelligent factory-wide optimal operation system for continuous production process. *Enterprise Inf Syst* 2016;10(3):286–302.
- [23] Ding J, Wang H, Liu C, Chai T. A multiobjective operational optimization approach for iron ore beneficiation process. In: Proceedings of the 2013 International Conference on Advanced Mechatronic Systems; 2013 Sep 25–27; Luoyang, China. Piscataway: IEEE; 2013. p. 582–7.
- [24] Ding J, Modares H, Chai T, Lewis FL. Data-based multiobjective plant-wide performance optimization of industrial processes under dynamic environments. *IEEE Trans Industr Inform* 2016;12(2):454–65.
- [25] Yang C, Ding J. Constraint dynamic multi-objective evolutionary optimization for operational indices of beneficiation process. *J Intell Manuf*. In press.
- [26] Ma Y, Sun Z, Gao H. Incremental associate data mining in real time database. *J Comput Res Develop* 2000;37(12):1446–51. Chinese.
- [27] Ding J, Chai T, Cheng W, Zheng X. Data-based multiple-model prediction of the production rate for hematite ore beneficiation process. *Control Eng Pract* 2015;45:219–29.
- [28] Liu C, Ding J, Toprac AJ, Chai T. Data-based adaptive online prediction model for plant-wide production indices. *Knowl Inf Syst* 2014;41(2):401–21.
- [29] Liu C, Ding J, Chai T. Robust prediction for quality of industrial processes. In: Proceedings of the 2014 IEEE International Conference on Information and Automation (ICIA); 2014 Jul 28–30; Hailar, China. Piscataway: IEEE; 2014. p. 1172–5.
- [30] Ding J, Chai T, Wang H, Chen X. Knowledge-based global operation of mineral processing under uncertainty. *IEEE Trans Industr Inform* 2012;8(4):849–59.
- [31] Chai T, Qin SJ, Wang H. Optimal operational control for complex industrial processes. *Annu Rev Contr* 2014;38(1):81–92.
- [32] Chai T, Ding J, Wu F. Hybrid intelligent control for optimal operation of shaft furnace process. *Cont Eng Pract* 2011;19(3):264–75.
- [33] Zhou P, Chai T, Sun J. Intelligence-based supervisory control for optimal operation of a DCS-controlled grinding system. *IEEE Trans Contr Syst Technol* 2013;21(1):162–75.
- [34] Zhou P, Lu S, Yuan M, Chai T. Survey on higher-level advanced control for grinding circuits operation. *Powder Technol* 2016;288:324–38.