DOI: 10.3901/JME.2021.20.277

大数据驱动的离散制造车间生产过程智能管控方法研究*

方伟光^{1,2} 郭宇¹ 黄少华^{1,3} 刘道元¹ 崔世婷¹
廖文和¹ 洪东跑²

- (1. 南京航空航天大学航空宇航制造工程系 南京 210016;
2. 中国运载火箭技术研究院 北京 100076;
3. 清华大学工业工程系 北京 100084)

摘要: 在智能制造背景下, 离散制造企业对利用大数据技术提高车间生产管控水平提出了迫切的需求。研究大数据驱动的离散制造车间生产过程智能管控方法, 在明确离散制造车间特点与管控需求的基础上, 分析了传统方法的局限性和大数据方法的优势, 进而提出大数据驱动的离散制造车间生产过程管控总体框架, 以制造大数据的“采集-处理-分析-服务”为主线开展研究。在“进度预测-瓶颈发现-异常溯源-智能决策”的生产过程闭环管控机制中, 分别提出: 基于堆叠稀疏自编码器的生产进度在线预测技术, 基于平行门控循环单元的生产瓶颈漂移发现技术, 基于密度峰值-模糊C均值的生产异常溯源分析技术和基于多智能体强化学习的生产过程智能决策技术。最后, 以某航空企业典型离散制造车间作为对象, 对所提出的大数据分析与智能决策方法进行了原型系统开发和应用验证。

关键词: 离散制造车间; 制造大数据; 生产过程管控; 数据分析; 智能决策

中图分类号: TH186; TP391

Big Data Driven Intelligent Production Control of Discrete Manufacturing Process

FANG Weiguang^{1,2} GUO Yu¹ HUANG Shaohua^{1,3} LIU Daoyuan¹ CUI Shiting¹
LIAO Wenhe¹ HONG Dongpao²

- (1. Department of Manufacturing Engineering of Aeronautics & Astronautics,
Nanjing University of Aeronautics and Astronautics, Nanjing 210016;
2. China Academy of Launch Vehicle Technology, Beijing 100076;
3. Department of Industrial Engineering, Tsinghua University, Beijing 100084)

Abstract: Under intelligent manufacturing era, there is pressing demands from discrete manufacturing enterprise to utilize big data (BD) technologies for enhancing the level of production management and control (PM&C). The BD driven intelligent PM&C in discrete manufacturing process is studied. Based on the determination of characteristics and demands for PM&C, the architecture of BD driven PM&C is firstly constructed, which the main flow is “collection-processing-analysis-service” of manufacturing BD. Based on the closed-loop mechanism “progress prediction-bottleneck discovery-anomaly tracing-decision making” for PM&C, the key technologies are respectively proposed, which are: “A stacked sparse auto-encoder model for production progress prediction”, “The parallel gated recurrent units model for shifting bottleneck discovery”, “The density peak-weighted fuzzy C-means method for anomaly tracing” and

* 国家自然科学基金(52105522)、江苏省自然科学基金(BK20202007)和国防基础科研重点(JCKY2016605B006)资助项目。20200630 收到初稿, 20210421 收到修改稿

“The multi-agents reinforcement learning for production decision-making”. Finally, an aircraft discrete manufacturing workshop is selected as the application scenario to verify the developed prototype system.

Key words: discrete manufacturing workshop; manufacturing big data; production management and control; data analysis; intelligent decision-making

0 前言

在当前多品种、变批量的订单生产模式下, 各类不确定性扰动事件频发、生产任务变更与计划调整频繁、生产决策效率低下且人为干预严重, 缺乏系统性、科学、有效的生产过程分析方法, 给车间生产管控带来的极大的难度和不确定性。以某卫星制造厂的精密加工车间为例, 有数百台已联网的加工及检测设备, 主要完成金属壁板、舱段、支架、框类、特殊结构件等几十种零部件混线加工, 然而生产过程中人员变动、设备故障、质量返工、物料短缺、加工延迟等各种不确定性扰动事件频发, 导致订单实际生产进度与生产计划的偏差长达两周以上, 给一些重要型号产品的按时交付带来了极大的困难。因此, 传统离散制造企业对利用大数据技术提升车间生产管控水平提出了迫切的需求。

随着信息技术的飞速发展, 传统离散制造企业大多已完成了信息化改造, 特别是传感器、RFID、UWB 等数据采集装置在车间底层中大量部署, 使车间实现了从自动化迈向信息化的跨越^[1-2]。车间制造过程中产生的海量制造数据具有典型的大数据特征, 即规模性、多样性和高速性, 以某型号航天产品金属结构件制造过程产生的数据为例, 车间内部制造要素种类繁多, 涉及设备运转数据、工件状态数据、质检数据、出入库数据等, 数据来源多样, 并且数据体量大、采集频率快的特点, 单台金属三维检测设备每天能生成 10 GB 数据, 每年共收集超过 3 TB 数据, 一个部署 100 台 RFID 读写器的结构件车间每秒钟就可以产生 1.2 万条在制品流转数据。

传统离散制造车间运行分析主要依赖 Petri 网、贝叶斯网络、系统动力学等模型, 通过不同的方式表达制造系统的组成结构和制造要素、生产活动之间的关系。在运行分析的基础上, 车间生产过程决策主要依赖于建立复杂、精确的数学模型描述问题对象, 然后在一定约束条件下, 设计算法对模型进行求解, 从而将优化结果作为决策策略。相较于传统方法, 大数据通过生产过程

中产生的海量数据, 挖掘和量化数据分布中的特征及数理关系, 从而更方便、高效、精确地分析离散制造车间中复杂事物之间的内在关联, 为生产决策人员观察并分析车间中事物的运行提供了崭新的视角^[3]。具体而言, 将大数据技术应用于离散制造车间生产过程管控的研究中优势表现如下。

(1) 描述性方面。传统制造系统运行分析方法难以完全真实映射车间多扰动、不确定性等真实运行特性, 未能充分利用海量数据来全面分析影响制造系统协调稳定运行的外、内在因素, 较难精准地把握复杂环境下的车间运行规律。而生产过程中产生的海量数据作为车间中各类制造要素进行生产活动的“缩影”, 本身就是对生产过程中制造要素状态变化的客观表达, 车间运行过程的动态事件都直接或间接的体现在制造数据的变化之中, 因此, 制造大数据具备对离散制造车间中各类制造要素状态及车间性能演变的描述性。

(2) 模型构建复杂性方面。离散制造车间由多个制造单元有机串、并联接而成, 运行过程受到设备、人员、物料、配送等多源效应作用, 生产过程中制造要素状态的变化具有联动式的影响, 往往具有非线性、强耦合的特点, 导致针对复杂离散制造系统的建模困难、复杂度高。通过海量数据构建的统计学习模型, 丰富的数据样本在一定程度上就能够保证模型分析结果有效性, 并且采用“线下训练-线上应用”机制, 以“输入-输出”形式从历史数据中学习模型结构及参数组合, 能够面对不同工况动态分析车间运行性能及异常问题。

(3) 预见性方面。离散制造车间物料配送延迟、设备故障, 生产计划变更等情况时有发生, 但传统方法往往是在问题发生时才进行决策响应, 经常出现刚消除旧问题又出现新问题的情况, 导致了传统方法对于问题分析与决策响应的滞后性; 通过大数据统计学习方法能够在历史数据中深入挖掘制造数据中复杂的非线性关系, 并且动态考虑由生产状态变化所带来的数据时效变化, 从而在问题发生前就对其具备预见性, 从而能够

提前制定管控策略以规避问题的发生。

目前,已有部分学者对制造大数据技术及相关应用框架进行了论述。KUSIAK^[4]在《Nature》发表的评论文章指出智能车间必须“拥抱”大数据技术,并提出发展大数据驱动的预测性模型与车间控制策略等技术方向;张洁等^[3]提出了“关联+预测+调控”的运行分析与决策模式,为后续大数据技术在智能车间应用模式的研究提供了宝贵思路;ROSSIT 等^[5]提出了一种数据驱动的调度体系架构,通过挖掘制造数据中隐藏的知识,依据车间状态信息提前做出调度决策;TAO 等^[6]提出了制造大数据生命周期的概念,并明确了数据驱动的智慧设计、智慧工艺规划、智慧物流等方向,并结合晶圆生产过程提供了应用案例;任杉等^[7]针对复杂产品全生命周期中产生的大数据,提出了一种面向智能制造服务的新模式,构建了面向设计闭环创新、生产过程优化和运维服务的数据驱动机制。针对制造大数据技术具体应用方向的研究中,ZHANG 等^[8]提出了大数据驱动的绿色制造框架,并结合实际的复杂产品案例,验证了大数据技术框架在产品生命周期过程中的有效性;MORARIU 等^[9]通过大数据技术处理制造系统中的实时信息流,试验生产异常检测和资源重新分配;汤洪涛等^[10]在制造数据预处理的基础上,对调度相关数据进行扰动属性聚类,并生成不同扰动环境下的调度规则;ZHONG 等^[11]通过车间内部署的 RFID 设备,采用大数据技术挖掘制造车间内部物流配送的频繁轨迹,并实现车间物流配送优化。在上述文献研究中,已经初步构建了大数据驱动的制造过程分析与决策体系架构,部分着眼于宏观层面,从数据分析角度阐述了大数据在车间的应用,但与实际车间管控逻辑结合不够紧密,且通常缺少对车间生产过程管控中具体问题的分析与决策,尚未形成闭环的运行控制逻辑。

综上所述,大数据技术在制造车间中的应用模式已经进行了相关的探索,本文在前人研究的基础上,进一步聚焦大数据技术在离散制造过程管控中的分析与决策方法,搭建面向离散制造车间的“数据采集-数据处理-数据分析-数据服务”体系架构。并结合生产过程管控业务逻辑提出了“进度预测-瓶颈发现-异常溯源-智能决策”的闭环生产过程管控逻辑,重点围绕生产进度预测技术、生产瓶颈漂移发现技术、生产异常溯源分析技术和生产过程智能决策技术开展研究,为大数

据环境下离散制造过程管控提供理论依据和技术支持。

1 大数据驱动的离散制造车间生产过程管控方法

1.1 大数据驱动的离散制造车间生产过程管控总体框架

大数据驱动的离散制造车间生产过程管控总体框架是以全局化的视角概括系统组成与各部分之间的依托关系,为后续关键技术与系统开发提供框架支撑。结合制造大数据的生命周期与生产过程管控的需求,本研究以制造大数据的“采集-处理-分析-服务”为主线,搭建大数据驱动的离散制造车间生产过程管控总体框架,如图 1 所示。

(1) 数据采集层。离散制造车间中设备、人员、物料、工具、在制品等各类制造要素在进行生产活动中所产生的实时、多源数据是生产过程优化与控制的基础,针对不同制造要素的特点和数据采集需求,在车间现场部署 RFID、传感器、UWB 等各类感知设备,实现对各类制造要素的互联互通与数据采集,确保制造车间生产过程的多源信息能够实时、可靠的获取,对大数据分析与智能决策提供重要的数据保障。

(2) 数据处理层。针对数据采集层中不同传感设备的传输特点与需求,需要通过互联网、工业以太网、现场总线等对实时感知信息进行传递与交换;其次,针对制造要素状态数据变化的时空特性,采用制造大数据时空建模方法^[12],从制造要素对象的状态、时间和空间不同维度,对车间制造大数据建模,为后续研究提供高效的数据访问接口;此外,利用 MongoDB 所提供分布式节点的数据存储方案,存储车间中现场的静态与动态数据,保证制造大数据的安全性;最后,针对车间数据采集环境复杂、生产工况多变、生产环境开放等车间特性所导致的数据冗余、乱序、缺省等问题,对制造数据进行校验、平滑、过滤、融合等预处理^[13],转化为生产过程管控中可用的数据资源。

(3) 数据分析层。在车间制造数据资源进行统一整合的基础上,分别针对生产进度预测技术、生产瓶颈漂移发现技术、生产异常溯源分析技术和生产过程智能调度技术进行深入研究,采用特征提取、回归预测、时序挖掘和强化学习等大数

据分析与决策方法,从海量制造数据中提取有价值的车间运行复杂特性与规律性知识,形成面向离散制造车间生产过程管控的“进度预测-瓶颈发

现-异常溯源-智能决策”闭环管控机制,为数据服务层中各类大数据驱动的应用功能模块开发提供算法支撑。

图1 大数据驱动的离散制造车间生产过程管控总体框架

(4) 数据服务层。开发面向离散制造过程的大数据分析与智能决策支持平台,将车间生产过程采集的大数据用于车间的实时生产监控、分析与决策,针对研究中所涉及的四项关键技术,在制造大数据分析与智能决策支持平台中开发了订单生产进度在线预测、车间生产瓶颈漂移发现、生产异常溯源分析和生产过程智能调度四项功能模块,为离散制造车间的生产过程管控业务提供数据价值增值服务。并通过统一的数据集成接口实现与制造执行系统(Manufacturing execution system, MES)、企业资源计划(Enterprise resource planning, ERP)、产品数据管理(Product data

management, PDM)等信息系统的紧密集成,在多种可视化终端上实现制造现场的透明化、实时化和精准化管理、控制与优化。

1.2 大数据分析与智能决策技术与生产过程管控的业务集成逻辑

离散制造车间的运行过程是以客户订单作为输入,以生产任务为导向,在订单完工期的要求下将各类生产资料转化为订单内所需产品的过程。针对离散制造过程管控对大数据技术的需求,提出面向车间生产过程管控的“进度预测-瓶颈发现-异常溯源-智能决策”大数据关键技术逻辑,并在计划执行过程中与生产管控业务集成,形成面向离散制造过

程的车间闭环管控逻辑。制造大数据技术与生产过程管控业务集成逻辑如图 2 所示。

图 2 制造大数据技术与生产过程管控的业务集成逻辑

当车间收到客户的订单需求后, MES 会对订单产品所需求的零、部件工艺路线的进行确认, 并编制生产计划下发生产任务到各个制造单元和相关职能部门, 如刀具管理、物料管理、配送管理、工装管理等, 设备操作人员按照生产计划中指定的工艺要求在不同制造单元对工件进行加工, 物料配送单元根据任务需求对毛坯和物料进行搬运到指定制造单元, 直到订单中的所有工件被加工完成。

当订单生产计划确定后, 车间中制造资源调配按照生产计划的指定就能够满足订单完工期的要求, 然而在实际生产过程中设备故障、质量问题、物料短缺等不确定性因素随机发生, 导致实际的生产进度难以按照计划要求, 最终导致订单交付延误。而生产过程管控的目标就是保证生产造系统在各种扰动下能够始终完成生产计划的内容。在制造大数据背景下, 提出“进度预测-瓶颈发现-异常溯源-智能决策”的关键技术运行逻辑, 并开发大数据分析平台, 能够在生产过程中前瞻性地预测订单未来生产进度, 当进度预测结果与生产计划产生偏差时, 通过生产瓶颈发现技术定位导致进度产生偏差的瓶颈单元, 并对瓶颈单元中所发生的具体异常问题进行溯源分析, 找到引起瓶颈发生的诱发因素, 进而通过智能决策方法针对具体异常因素对当前生产计划动态修正, 并将更新后的生产计划下发至每一个工位, 从而根据加工状态选择合适的时机切

换至新的生产计划, 最终保证生产订单的按期交付。

综上所述, 制造大数据技术一方面可以在离散制造过程中形成了不断循环、闭合的车间运行管控逻辑, 为车间在不确定性因素下的稳态运行提供了保障机制; 另一方面, 由于数据本身就蕴藏着制造过程中大量复杂的因果逻辑关系, 通过大数据技术可以量化生产要素状态间的内在联系, 挖掘车间状态的演化规律, 探究系统内部的运行机理, 为未来离散制造过程管控积累有价值的规律性知识。

2 大数据驱动的离散制造过程管控关键技术

在当前多品种、变批量的订单生产模式下, 离散制造车间需要能够灵活应对生产过程中出现的各类不确定因素, 准确评估车间性能的演化规律, 发现车间复杂网络中的薄弱环节, 分析导致薄弱环节产生的诱发因素, 并迅速制定智能的生产决策方案, 改善车间运行过程出现的“振荡”、“失稳”等现象。在制造大数据的支撑下, 本节对所提出的由“进度预测-瓶颈发现-异常溯源-智能决策”组成的离散制造过程闭环管控机制(图 3)进行了详细论述, 形成大数据驱动的离散制造过程管控体系。

图 3 大数据驱动的离散制造过程闭环管控制制

2.1 基于堆叠稀疏自编码机的订单生产进度在线预测技术

在离散制造过程中，生产进度能否按照所指定的生产计划执行，直接影响到订单最终的按时交付和生产成本。因此，研究订单生产进度在线预测方法，以生产过程数据作为制造要素状态的客观映射，预测未来车间运行过程的生产进度，为生产过程决策提供触发依据。目前，已有部分学者采用大数据

方法对生产周期^[14]、完工期^[15]预测及其关键影响因素识别^[16-17]等问题进行了相关研究，但较少采用车间现场实时数据，在生产过程中对生产进度动态预测，且采用浅层网络模型的结构，在小样本、低维度数据样本的训练中具备良好的精度，但在当前离散制造过程中所采集的高维度、复杂、非线性数据特征时，浅层模型在表征、泛化能力有明显不足。

针对生产进度预测问题，提出基于堆叠稀疏自编码器(Stacked sparse autoencoder, S-SAE)的订单生产进度在线预测技术^[18-19](图 4)。首先，对影响生产进度 PP 的订单任务状态 TC^t 、在制品实时状态 PS^t 及制造单元实时状态 MC^t 等定性因素进行分析，构建面向订单生产进度预测的形式化描述模型如下

$$FS = (TC^t, PC^t, MC_m^t) = \left(\sum_1^K P_{K,1}^t, \sum_1^K P_{K,2}^t, \dots, \sum_1^K P_{K,N}^t, N_WIP^t, \right. \\ \left. WIP_{m-in,1}^t, WIP_{m-in,2}^t, \dots, WIP_{m-in,x}^t, \right. \\ \left. WIP_{m-out,1}^t, WIP_{m-out,2}^t, \dots, WIP_{m-out,x}^t, \right. \\ \left. WIP_m^t, PT_m^t, QI_{WIP,m}^t, QR_{WIP,m}^t, \right. \\ \left. WS_m^t, UR_m^t, WT_m^t \right) \quad (1)$$

图 4 基于堆叠稀疏自编码机的生产进度在线预测技术

在形式化模型 FS 中分别包含：订单 K 中产品类型 N 的数量 $P_{K,N}$ ，在制品总量 N_WIP^t ，入缓

存等待加工与出缓存等待转运的在制品排队序列 $WIP_{m-in,x}^t$ 与 $WIP_{m-out,x}^t$ ，设备 m 正在加工的在制品种

类 WIP_m^t 与工序额定工时 PT_m^t , 正在质检的在制品种类 $QI_{WIP,m}^t$ 与质检结果 $QR_{WIP,m}^t$, 制造单元的实时状态 WS_m^t 、利用率 UR_m^t 和维修后的持续工作时间 WT_m^t 。

以车间历史生产过程中采集的数据作为训练样本, 设计 S-SAE 进行订单生产进度 PP 的在线预测, 量化车间生产状态及任务的变化对生产进度 PP 所产生的动态影响。在 S-SAE 模型构建过程中, 首先搭建多个自编码器 SAE 对原始数据进行特征提取与降噪, 并在其损失函数中加入伯努利相对熵作为惩罚因子 $KL(\rho \parallel \hat{\rho}_j)$, 对车间运行中产生的高维制造数据进行特征表示学习, 从而获取原始数据的稀疏性表达。其次, 将训练后的 n 个 SAE 中间层 $h^{(1)}(X) \cdots h^{(n)}(X)$ 的权重信息 $W^{(1)} \cdots W^{(n)}$ 与偏置信息 $b^{(1)} \cdots b^{(n)}$ 进行迁移与堆叠, 最终形成 S-SAE 的模型结构, 以历史数据集 (TC^t, PC^t, MC_m^t) 为输入, 以 t 时刻下所对应的未来进度 PP^t 为输出, 从而实现模型对高维制造数据的泛化表示及高精度的生产进度预测, 预测模型可以对未来生产进度是否满足生产计划要求进行在线判断, 为离散制造车间生产过程智能决策调控提供预见性的判断条件。

2.2 基于平行门控循环单元模型的车间生产瓶颈漂移发现技术

针对生产进度预测值偏离计划值超出阈值的情况, 需要寻找当前车间中阻碍生产计划顺利执行的制造单元, 从而定位影响车间正常运行的瓶颈位置。传统生产瓶颈研究多面向于流程制造中的产量瓶颈^[20-21], 同时部分研究^[22-23]分析瓶颈时虽然考虑了瓶颈在时间维度上的漂移, 但仅限于考虑制造资源本身的使用情况(停机时间, 工作时间, 排队数量等), 缺少车间整体生产状态对瓶颈单元转移影响的分析, 导致构建的统计模型无法完全表征车间生产瓶颈的动态变化, 且采用的时序挖掘模型 ARMA、ARIMA 等难以刻画实时状态, 不具备长时间序列记忆能力”。

为准确追踪生产瓶颈的产生与时空漂移过程, 提出基于平行门控循环单元模型(Parallel-Gated recurrent units, P-GRUs)的生产瓶颈漂移发现技术^[24](图 5), 首先对生产过程中瓶颈产生的原因进行了分析, 采用制造单元对生产任务的相对延迟 $RL_{i,j}^t$ 占订单总延迟 $RL_{order,k}^t$ 的比重 $RL_{rp,j}^t$ 作为量化瓶颈程度的标准, 并将不同时间维度与空间维度下的瓶颈程度作为主要数据 X_{main}^t , 此外, 为准确刻画瓶颈产生时的制造单元状态, 将同一时间尺度下相关生产状态数据作为瓶颈发现辅助数据 X_{aux}^t 。

图 5 基于平行门控循环单元模型的生产瓶颈漂移发现技术

在生产瓶颈程度量化的基础上, 提出采用主要数据 X_{main}^t 与辅助数据 X_{aux}^t 并联的方式, 分别描述车间中各制造单元瓶颈程度和制造单元实时状态, 并针对不同时间尺度下的时序数据进行序列式处理, 将时序数据转换为 P-GRUs 的输入-输出形式

$$\begin{aligned}
 RL^{t+1} = & F(X_{main}^t, \dots, X_{main}^{t-n\Delta t}, X_{aux}^t, \dots, X_{aux}^{t-n\Delta t}) = \\
 & F(RL^t, \dots, RL^{t-n\Delta t}, Num_p^t, \dots, Num_p^{t-n\Delta t}, \\
 & WL_i^t, \dots, WL_i^{t-n\Delta t}, UW_i^t, \dots, UW_i^{t-n\Delta t}, \\
 & Ur_i^t, \dots, Ur_i^{t-n\Delta t}, Ft_i^t, \dots, Ft_i^{t-n\Delta t}) \quad (2)
 \end{aligned}$$

式中, F 表示 P-GRUs 的模型映射, Num_p^t 、 WL_i^t 、 UW_i^t 、 Ur_i^t 和 Ft_i^t 分别表示在当前时刻 t 下的制造单元中每种排队工件的数量、排队长度、工序不合格品数量、设备利用率和发生故障的时间等 X_{aux}^t 中的信息, RL^{t+1} 代表 $t+1$ 时刻所有制造单元的相对延迟比重。以 X_{main}^t 和 X_{aux}^t 所组成的瓶颈发现数据集为基础, 为准确追踪生产瓶颈在车间运行过程中的时空漂移, 设计了具有平行输入结构的 P-GRUs 模型, 利用 GRU 层提取主要数据与辅助数据中的时序变化特征 h_b^t 与 h_s^t

$$\text{GRU 主要输入端: } h_b^t = H(X_{main}^{t-1}, h_b^{t-1}) \quad (3)$$

$$\text{GRU 辅助输入端: } h_s^t = H(X_{aux}^{t-1}, h_s^{t-1}) \quad (4)$$

随后, GRU 层时序特征向量通过进行特征连接层相连为 $h_t = h_b^t \oplus h_s^t$, 并通过全连接层最终输出短期、中期和长期不同时间跨度下的制造单元瓶颈程度, 从而捕获发现车间中瓶颈漂移的趋势, 实现对离散制造车间中瓶颈的准确定位与追踪。

2.3 基于密度峰值-模糊 C 均值聚类生产异常溯源分析技术

离散制造车间中生产瓶颈的产生与漂移是多种

动态事件交互叠加、协同作用的结果, 受到设备状态、订单组成、在制品状态等多源因素的影响, 在第 2.2 节中定位制造车间中的瓶颈位置后, 需要进一步寻找引起瓶颈产生的诱发因素, 检测制造单元内部的生产异常。生产异常检测旨在发现一个或一组物体是否在正确的时间出现在正确的地点发生了正确的事件, 传统的异常检测方法多依赖于制定正确的事件规则^[25], 通过对事件的创建、关联、聚合以及对规则的定义、匹配和挖掘等方法^[26], 实现对生产过程各类事件的实时监测和分析^[27]。而实际生产过程包含的资源种类繁多, 具有典型的强关联性和时序性特点, 事件规则定义繁多且复杂, 而且制造过程中的随机性和不确定性强, 固定的事件规则不能较好地适应生产过程中的各种不确定性。

为准确分析制造过程中存在的各类异常事件, 将瓶颈诱因定位在制造单元级, 提出一种基于密度峰值-模糊 C 均值(Density peak-weighted fuzzy C-means, DP-WFCM)聚类的异常溯源技术^[28](图 6)。假设与异常关联的特征集 Set_x 包含 X 个特征

图 6 基于密度峰值-模糊 C 均值的生产异常溯源分析技术

$\{fe_1, fe_2, \dots, fe_x\}$, 采用互信息 $I(A; B)$ 和条件互信息 $I(A; B|C)$ 来描述无标签数据的特征相关度 $Rel(fe_x)$ 和冗余度 $Red(fe_x)$, 根据“最大相关-最小冗余”原则选取识别异常的关键特征 fe_x

$$fe_x = \arg \max_{fe_x \in Set_{X-x+1}^{init}} (Rel(fe_x) - Red(fe_x)) \quad (5)$$

获得携带初始特征集中全部或绝大部分信息量的行为特征子集 Set_x , 以提高异常分析效率与准确性。为解决异常数据样本数量相较于正常数据样本不均衡的问题, 通过数据过采样方法 SMOTE 对生产异常数据重新采样。在此基础上, 以密度峰值 DP 方法获得初始聚类中心 C_i , 并将基于互信息的样本相似度作为权重系数 w_j

$$w_j = I(X_j; S) \times \left(\sum_{j=1}^n I(X_j; S) \right)^{-1} \quad (6)$$

式中, $I(X_j; S)$ 为样本 X_j 与整个样本集合 S 的平均互信息, 在此基础上, 以最小化数据样本点 X_j 和聚类中心 C_i 之间的距离为目标

$$\min J(\mu, C, w) = \sum_{i=1}^c \sum_{j=1}^n w_j \mu_{i,j}^\nu \|C_i - X_j\|^2 \quad (7)$$

将聚类求解问题转化为使目标函数 $J(\mu, C, w)$ 达到极小值时的聚类中心 C_i 和隶属度矩阵 $\mu_{i,j}^\nu$ 求解问题, 完成对生产异常溯源分析, 通过对初始异常数据少数类的判别, 实现制造单元中的瓶颈诱因进行准确追溯。

2.4 基于多智能体强化学习的生产过程智能决策技术

在实际生产过程中, 合理的生产计划与均衡的资源分配是离散制造车间稳定运行的基本保障, 而车间中设备故障、物料短缺、交货期变更等异常现象频发, 需要根据实时生产状态对离散制造车间动态、合理地制定重调度策略, 以保证生产进度能够满足订单按时交付的要求。传统生产过程调度主要采用精确法(动态规划、分解法等数学规划方法)与近似法(启发式、元启发式等智能搜索算法)^[29]。在当前制造物联环境下制造车间调度的研究中^[30], 针对生产过程决策实时反馈、在线响应的需求, 已有部分学者研究了大数据驱动的车间实时调度决策问题^[31-32], 虽然调度决策触发机制上具备了实时性, 但调度方案仍沿用了传统“模型+算法”的优化机制, 在复杂离散制造过程中各类不确定异常现象动态发生时难以灵活、有效地应对。

在生产进度预测、瓶颈发现与异常溯源研究的

基础上, 需要进一步制定面向瓶颈缓解或抑制的动态反馈机制与调控策略, 在一定程度上“吸收”车间运行过程中由不确定性异常事件所引发的瓶颈问题, 最终缩短或消除生产进度与生产计划间的偏差, 提出一种基于多智能体强化学习 (Multi-agents reinforcement learning, MARL) 的生产过程智能决策技术(图 7), 首先根据异常溯源中所检测到的异常类型, 将生产进度 PP^t 与原计划 SP^t 的偏离程度作为智能决策触发条件

$$\frac{PP^t}{SP^t} \leq \delta \quad (8)$$

图 7 基于多智能体强化学习的生产过程智能决策技术

当实际进度与计划进度的比值小于订单交货期敏感因子 δ 时, 触发强化学习进行调度方案的制定。在 MARL 驱动的调度决策中, 首先构建孪生数据驱动的虚拟离散制造车间并在其中为虚拟车间中每个制造单元 m 构建强化学习智能体, 将虚拟车间作为强化学习智能体的学习环境, 智能体 m 在车间运行过程中进行车间状态属性 Sf_m 的感知, 状态属性集包括工件延迟时间 $Tar_{i,s}$ 、平均逗留时间 $Soj_{i,s}$ 、松弛时间 $Sl_{i,s}$ 等制造单元中相关的工件状态信息, 在此基础上, 智能体根据所对应的状态属性 Sf_m 选择决策动作 A_m , 智能体根据所感知到的状态, 在报酬函数 r_t 的指引下决策行为的自学习, 其中, 在每次学习迭代过程 $[\tau, \tau+1]$ 下智能体的报酬函数 r_t 可定义为

$$r_t = \frac{1}{m} \sum_{j=1}^m \int_{\tau}^{\tau+1} \delta_{M(j,k)}(t) dt \quad (9)$$

$\delta_{M(j,k)}(t)$ 代表设备 $M(j,k)$ 的示性函数, 在设备工作时 $\delta_{M(j,k)}(t)=1$, 设备空闲或故障时 $\delta_{M(j,k)}(t)=0$ 。为实现生产进度偏差的修正, 以最小

化生产进度偏差 $\text{Minimize}(PP^i - SP^i)$ 作为决策目标, 筛选智能体在车间各种异常状态下能够达到最大回报的决策行为。为平衡智能体学习过程中的探索与利用过程, 采用 ε -greedy 方法平衡智能体决策策略局部搜索和全局搜索, 以提高智能体在虚拟环境中的学习效率。此外, 通过经验共享机制分别维护智能体自身的状态-动作值函数 $Q_{\gamma}^{\pi}(s, a)$ 和其他智能体学习经验的状态值函数 $Q^{\epsilon}(s_{t+1}, a^*)$, 实现多强化学习智能体的协同决策。最后, 将训练完备的智能体在实际生产过程中应用, 实现根据车间实时生产状态进行决策行为的自主制定, 对离散制造车间中存在的确定性异常因素进行智能决策优化。

3 原型系统与应用验证

3.1 原型系统

根据离散制造车间对制造大数据分析 with 决策的应用需求, 在大数据驱动的离散制造车间生产过程管控总体框架下, 开发了制造大数据分析 with 智能决策支持平台, 原型系统模块划分如图 8 所示, 主要包括系统公共服务部分和生产管控服务部分。其中, 公共服务部分包括: 系统管理配置、数据采集和数据管理、车间可视化四个功能模块; 车间生产管控服务部分包括: 生产进度预测、生产瓶颈发现、生产异常分析和生产过程决策四个功能模块。

图 8 原型系统功能模块划分

为方便车间管理人员对车间实时状态进行监测, 原型系统中数据可视化模块如图 9 所示。通过总体框架数据处理层中的车间数据时空建模, 采用数据切片的方法分别对时间、空间和属性三个维度下的车间状态进行统计, 并且对于不同制造要素状态的统计结果在车间数据可视化界面中进行图表示

图 9 车间数据可视化模块

示，使用户能够直观获取车间中不同制造要素状态的变化趋势，实现车间生产状态的实时监测。例如，用户可以直接在车间数据可视化界面中监测到车间中在制品数量走势、设备加工状态及运行效率变化、机床设备主轴转速等信息，实时掌握车间运行情况。

3.2 离散制造车间应用验证

研究选用某航空发动机柱塞液压泵加工车间，作为典型复杂离散制造车间案例进行应用验证，车间中部署有 8 个加工区域共 44 个制造单元(车间

布局如图 10 所示)，根据制造单元中加工设备的类型，制造单元种类及数量可划分为(A)加工中心 5 台；(B)铣床 4 台；(C)车床 8 台；(D)磨床 7 台；(E)钻床 4 台；(F)铰孔机 4 台；(G)电火花机 2 台；(H)钳工 10 台，此外，车间配备有自动配送车等转运设备，用于物料、工装、在制品等配送任务。车间可承接 13 种类型零件的加工任务(产品类型及工艺路线如表 1 所示)，车间现场实际环境及制造物联配置环境如图 11 所示。

图 10 复杂离散制造车间案例

表 1 案例车间中的产品类型及工艺路线

编号	种类	工艺路线	编号	种类	工艺路线
1	柱塞座	C-B-D-E-G-H	8	支架	C-B-A-H
2	斜盘	C-B-E-F-B-H	9	壳体	C-B-C-A-G-H
3	活塞	C-E-F-C-H	10	输出轴	C-B-G-E-F-H
4	油盘	C-B-E-F-D-H	11	柱塞	C-E-G-D-H
5	螺堵	C-B-E-F-H	12	转子	C-A-F-D-H
6	垫板	B-D-G-H	13	端盖	C-B-A-D-H
7	托架板	C-B-E-F-A-B			

如图 11 所示，在实际车间中部署了大量物联感知设备，固定式超高频 RFID 读写器部署在各制造单元、入缓存区、出缓存区等位置，Ubisense 传感器以单元成组的形式在车间现场进行部署，将所对应的 RFID 电子标签附着在工件等各类制造要素表面，Ubisense 标签附着在关重件、重要工装等的表面。此外，各类数控机床及检测设备等可针对性的采用串口、PLC 等方式，实现设备联网及运行状态数据的采集，并将运转状态实时显示在工位所配备的计算机与移动电子终端设备等。车间生产过程中所采集的数据分别通过 MQTT 客户端和 RFID 中间件端口接入至 OPC-UA 服务器，数控机床中部署的

传感器等设备通过 KEPServer 所提供的协议支持实现传感设备的接入，并共同通过一级 OPC 客户端将清洗后的制造数据实时传输至 OPC-UA 服务器。

图 11 车间现场实际环境及制造物联配置环境

为满足海量制造数据存储灵活性与安全性的要求，在 MongoDB 分布式数据存储集群中配置一个主节点和三个子节点(图 12)，主节点用于存储子节点数据索引、子节点操作记录等共 3 200 万条(0.5 TB)，子节点分别用于存储制造过程中涉及的物联监控数据、设备运行数据、质检数据、工艺数据、在制品流转数据、订单数据等共 5 600 万条(4.4 TB)，

在不同子节点集群中对数据进行交叉备份,并且最终同步在 MongoDB 主节点中以提高数据的安全性与访问速度,为原型系统中数据的高效利用提供重要支撑。

图 12 MongoDB 制造大数据分布式存储集群

针对研究中所提出的四项关键技术,在原型系统中分别对应生产进度在线预测、生产瓶颈漂移发现

(1) 订单生产进度预测模块

(2) 生产瓶颈漂移发现模块

(4) 生产过程智能决策模块

(3) 生产异常溯源分析模块

图 13 原型系统在实际订单生产过程中的应用案例

(2) 当明确生产进度偏差后,需要在后续生产中发现生产过程的瓶颈位置,定位制约生产进度顺利执行的制造单元。针对订单 NCT178-1680 未来的生产进度偏差,用户调用后台搭建的平行门控循环单元模型,并根据需要调整模型的长期、中期和短期

现、生产异常溯源分析和生产过程智能决策四个功能模块,并分别与生产过程管控中不同阶段的业务需求进行紧密的配合。为验证系统的现场实际应用效果,以实际订单生产过程为案例,采用订单生产过程中的车间状态数据,分别对四项功能模块进行了验证并阐述了其在生产过程管控中的运行逻辑,如图 13 所示,制造大数据分析平台与智能决策支持平台在车间现场的应用案例如下。

(1) 在订单生产进度预测模块中,显示订单 NCT178-1680 当前(8月5日16:00时)生产进度为 9.53%,车间管理人员可通过调用后台运行的堆叠稀疏自编码器模型,通过车间历史运行数据与实时生产数据,预测订单未来时间(8月12日16:00时)的生产进度为 29.4%,然而按照生产计划要求,订单在(8月12日16:00)的生产进度需要达到 32.11%,因此,可推测订单在未来存在生产进度偏差,从而触发后续生产瓶颈发现模块的运行。

期时间尺度参数,在(8月5日16:00时)通过生产瓶颈漂移发现模块找到生产瓶颈在(8月6日8:00)的“车床_6”瓶颈程度最严重,需要触发生产异常溯源分析模块,通过当前“车床_6”的运转数据,寻找引起“车床_6”产生瓶颈的诱发因素。

(3) 针对“车床_6”在(8月6日8:00)的生产瓶颈,运行生产异常溯源分析模块,通过调用后台的模糊C均值聚类模型,溯源到“车床_6”发生缺料异常,导致(8月6日8:00时)“车床_6”制造单元的生产任务拖期最严重,严重影响了生产计划的执行。

(4) 针对“车床_6”的缺料现象,一方面需要进行物流调配对其进行补料,另一方面在生产过程智能决策模块中,触发智能体重新选择缺料状态下所对应的调度决策方案,将原来生产计划中属于“车床_6”的后续生产任务提前或分配至其他车床,最后将调度方案在虚拟车间中进行仿真验证,将优化后的生产计划调整结果推送至物理车间执行。

针对传统离散制造车间生产过程不透明、生产数据应用价值增值低、车间运行分析依赖人工经验等现状,制造大数据分析 with 智能决策支持平台的部署与应用有效解决了状态监控、生产运行分析和决策执行调控三个方面问题,系统应用效果对比如表2所示。原型系统的部署实现了生产数据的实时采集和制造全过程的可视化监控,通过研究中提出的四项关键技术实现了生产进度的在线预测、生产瓶颈漂移的准确定位、生产异常的及时发现和生产过程的智能决策,有效提升了离散制造企业生产管控智能化水平,对于降低订单延误率、提高车间生产效率具有显著的推动作用。

表2 系统应用效果对比

指标	系统应用前	系统应用后
数据采集	设备与环境两类要素 数据量:数百—数千条/天 人工记录,选择性采集	设备、人员、物料等七类要素联网,数据全面采集 数据量:有效数据>10万条(100M)/天 物联网设备自动、实时采集
运行分析	人工经验推测订单未来生产进度 瓶颈发生时才能明确瓶颈位置,无法预估瓶颈漂移 人工发现异常,耗时数秒至数小时,且异常捕获丢失较严重	生产进度在线预测,响应时间<1s,预测准确度96% 预知瓶颈位置,瓶颈短期漂移发现准确率89%,中期瓶颈78%及长期瓶颈73% 自动获取异常类型,耗时毫秒-秒级,异常捕获准确率达97.50%
决策执行	决策触发依赖动态事件判断或周期性触发 决策响应时间根据问题复杂程度,耗时数分钟~数小时 严格按方案执行,过程不可监不可控	决策触发依靠生产进度偏差程度实时响应 决策响应时间10s~1min,首先在虚拟车间中执行验证,且执行过程可监可控 方案效果提前仿真,执行过程可监可控

4 结论

制造大数据作为智能制造的核心资源,是赋予制造“智能”的关键要素。本文面向离散制造车间生产过程管控问题,研究在车间大数据环境下离散制造过程管控的新模式,为提升车间精准化与智能化的管控能力具有极其重要的意义。

(1) 分析了当前离散制造车间的背景与管控问题,以及当前生产管控模式的不足,在制造物联对车间生产过程数据全面采集的基础上,构建了以制造大数据的“采集-处理-分析-服务”为主线的离散制造车间生产过程管控总体框架。

(2) 根据离散制造车间生产过程的业务逻辑,将大数据分析 with 智能决策方法与生产管控业务紧密集成,并进一步提炼了“进度预测-瓶颈发现-异常溯源-智能决策”四项研究问题,形成大数据驱动的离散制造过程闭环管控机制。

(3) 在明确研究问题后,分别提出了“基于堆叠稀疏自编码机的订单生产进度在线预测”,“基于平行门控循环单元模型的车间生产瓶颈漂移发现”、

“基于密度峰值-模糊C均值聚类的生产异常溯源分析”与“基于多智能体强化学习的生产过程智能决策”四项关键技术,实现了大数据环境下车间生产过程管控的逻辑闭环。最后,开发了制造大数据分析与智能决策支持平台,并选用某航空发动机机加车间作为案例进行应用验证。

综上所述,本研究以制造物联所提供的制造大数据为支撑,将大数据驱动的分析、预测、和决策方法应用于离散制造车间管控中,以制造数据作为车间生产过程复杂演变规律的客观体现,分别通过深度学习、时序挖掘、聚类分析和强化学习等前沿人工智能方法,挖掘制造数据中所蕴含的离散制造车间运行的规律性知识和复杂特性,为实时、动态、自适应式地进行离散制造车间分析与决策控制提供了全新的理论方法与技术手段,也为推动智能制造技术在车间生产管控中的落地应用提供了参考。

参 考 文 献

- [1] 屈挺,张凯,罗浩,等. 物联网驱动的“生产-物流”动态联动机制、系统及案例[J]. 机械工程学报, 2015, 51(20): 36-44.

- QU Ting, ZHANG Kai, LUO Hao, et al. Internet-of-things based dynamic synchronization of production and logistics: Mechanism, system and case study[J]. Journal of Mechanical Engineering, 2015, 51(20): 36-44.
- [2] 黄少华, 郭宇, 查珊珊, 等. 离散车间制造物联网及其关键技术研究与应用综述[J]. 计算机集成制造系统, 2019, 25(2): 284-302.
- HUANG Shaohua, GUO Yu, ZHA Shanshan, et al. Review on Internet-of-manufacturing-things and key technologies for discrete workshop[J]. Computer Integrated Manufacturing Systems, 2019, 25(2): 284-302.
- [3] 张洁, 高亮, 秦威, 等. 大数据驱动的智能车间运行分析与决策方法体系[J]. 计算机集成制造系统, 2016, 22(5): 1220-1228.
- ZHANG Jie, GAO Liang, QIN Wei, et al. Big-data-driven operational analysis and decision-making methodology in intelligent workshop[J]. Computer Integrated Manufacturing Systems, 2016, 22(5): 1220-1228.
- [4] KUSIAK A. Smart manufacturing must embrace big data[J]. Nature, 2017, 544(7648): 23-25.
- [5] ROSSIT D, TOHMÉ F, FRUTOS M. A data-driven scheduling approach to smart manufacturing[J]. Journal of Industrial Information Integration, 2019, 15: 69-79.
- [6] TAO F, QI Q, LIU A, et al. Data-driven smart manufacturing[J]. Journal of Manufacturing Systems, 2018(48): 157-169.
- [7] 任杉, 张映锋, 黄彬彬. 生命周期大数据驱动的复杂产品智能制造服务新模式研究[J]. 机械工程学报, 2018, 54(22): 194-203.
- REN Shan, ZHANG Yingfeng, HUANG Binbin. New pattern of lifecycle big-data-driven smart manufacturing service for complex product[J]. Journal of Mechanical Engineering, 2018, 54(22): 194-203.
- [8] ZHANG Y, REN S, LIU Y, et al. A big data analytics architecture for cleaner manufacturing and maintenance processes of complex products[J]. Journal of Cleaner Production, 2017, 142: 626-641.
- [9] MORARIU C, MORARIU O, RILEANU S, et al. Machine learning for predictive scheduling and resource allocation in large scale manufacturing systems[J]. Computers in Industry, 2020, 120: 103244.
- [10] 汤洪涛, 费永辉, 陈青丰, 等. 基于工业大数据的柔性作业车间动态调度[J]. 计算机集成制造系统, 2020, 26(9): 2497-2510.
- TANG Hongtao, FEI Yonghui, CHEN Qingfeng, et al. Flexible job shop dynamic scheduling based on industrial big data[J]. Computer Integrated Manufacturing System, 2020, 26(9): 2497-2510.
- [11] ZHONG R Y, HUANG G Q, LAN S, et al. A big data approach for logistics trajectory discovery from RFID-enabled production data[J]. International Journal of Production Economics, 2015, 165: 260-272.
- [12] FANG W G, GUO Y, LIAO W H, et al. The spatio-temporal modeling and integration of manufacturing big data in job shop: An ontology-based approach[C/CD]// 2020 IEEE International Conference on Industrial Engineering and Applications (ICIEA), Bangkok, 2020.
- [13] LIU X, QI H, LI K, et al. Sampling bloom filter-based detection of unknown RFID tags[J]. IEEE Transactions on Communications, 2015, 63(4): 1432-1442.
- [14] WANG J L, ZHANG J. Big data analytics for forecasting cycle time in semiconductor wafer fabrication system[J]. International Journal of Production Research, 2016, 54(23): 7231-7244.
- [15] WANG C, JIANG P Y. Deep neural networks based order completion time prediction by using real-time job shop RFID data[J]. Journal of Intelligent Manufacturing, 2019, 30(3): 1303-1318.
- [16] 刘道元, 郭宇, 黄少华, 等. 一种面向订单剩余完工时间预测的 SOM-FWFCM 特征选择算法[J]. 中国机械工程, 2021(9): 1073-1079.
- LIU Daoyuan, GUO Yu, HUANG Shaohua, et al. A SOM-FWFCM based feature selection algorithm for order remaining completion time prediction[J]. China Mechanical Engineering, 2021(9): 1073-1079.
- [17] 汪俊亮, 张洁. 大数据驱动的晶圆工期预测关键参数识别方法[J]. 机械工程学报, 2018, 54(23): 185-191.
- WANG Junliang, ZHANG Jie. Big data driven key factor identification for cycle-time forecasting of wafer lots in semiconductor wafer fabrication system[J]. Journal of Mechanical Engineering, 2018, 54(23): 185-191.
- [18] HUANG S H, GUO Y, LIU D Y, et al. A two-stage transfer learning-based deep learning approach for production progress prediction in IoT-enabled manufacturing[J]. IEEE Internet of Things Journal, 2019, 6(6): 10627-10638.
- [19] FANG W G, GUO Y, LIAO W H, et al. Big data driven jobs remaining time prediction in discrete manufacturing system: A deep learning-based approach[J]. International Journal of Production Research, 2020, 58: 2751-2766.
- [20] LI L. A systematic-theoretic analysis of data-driven

- throughput bottleneck detection of production systems[J]. *Journal of Manufacturing Systems*, 2018, 47: 43-52.
- [21] LAI X J, SHUI H Y, NI J. A two-layer long short-term memory network for bottleneck prediction in multi-job manufacturing systems[C/CD]// *Proceedings of the ASME 2018 13rd ASME International Manufacturing Science and Engineering Conference*, Texas, 2018.
- [22] SUBRAMANIYAN M, SKOOGH A, SALOMONSSON H, et al. A data-driven algorithm to predict throughput bottlenecks in a production system based on active periods of the machines[J]. *Computers & Industrial Engineering*, 2018, 125(11): 533-544.
- [23] 李晓娟, 孙文磊, 袁逸萍, 等. 扰动环境下作业车间网络多瓶颈识别方法研究[J]. *西安交通大学学报*, 2016, 50(12): 64-72.
- LI Xiaojuan, SUN Wenlei, YUAN Yiping, et al. Multi-bottleneck identification for job-shop network in disturbance environment[J]. *Journal of Xi'an Jiaotong University*, 2016, 50(12): 64-72.
- [24] FANG W G, GUO Y, LIAO W H, et al. A parallel gated recurrent units (P-GRUs) network for the shifting lateness bottleneck prediction in make-to-order production system[J]. *Computers & Industrial Engineering*, 2020, 140: 106246.
- [25] CHIEN C, LIU C M, CHUANG S, et al. Analysing semiconductor manufacturing big data for root cause detection of excursion for yield enhancement[J]. *International Journal of Production Research*, 2017, 55(17): 5095-5107.
- [26] CAO X, LI T J, WANG Q, et al. RFID-based multi-attribute logistics information processing and anomaly mining in production logistics[J]. *International Journal of Production Research*, 2019, 57(17): 5453-5466.
- [27] ZHANG Y, WANG W, WU N, et al. IoT-enabled real-time production performance analysis and exception diagnosis model[J]. *IEEE Transactions on Automation Science and Engineering*, 2016, 13(3): 1318-1332.
- [28] HUANG S, GUO Y, YANG N, et al. A weighted fuzzy c-means clustering method with density peak for anomaly detection in IoT-enabled manufacturing process[J]. *Journal of Intelligent Manufacturing*, 2020, 40(5): 1-8.
- [29] 吕盛坪, 乔立红. 工艺规划与车间调度及两者集成的研究现状和发展趋势[J]. *计算机集成制造系统*, 2014, 20(2): 290-300.
- LÜ Shengping, QIAO Lihong. Current status and developing trend of process planning and Job Shop scheduling[J]. *Computer Integrated Manufacturing Systems*, 2014, 20(2): 290-300.
- [30] ZHONG R Y, HUANG G Q, LAN S, et al. A two-level advanced production planning and scheduling model for RFID-enabled ubiquitous manufacturing[J]. *Advanced Engineering Informatics*, 2015, 29(4): 799-812.
- [31] JI W, WANG L. Big data analytics based fault prediction for shop floor scheduling[J]. *Journal of Manufacturing Systems*, 2017, 43: 187-194.
- [32] WANG C, JIANG P. Manifold learning based rescheduling decision mechanism for recessive disturbances in RFID-driven job shops[J]. *Journal of Intelligent Manufacturing*, 2018, 29(7): 1485-1500.
-
- 作者简介: 方伟光, 男, 1990 年出生, 博士。主要研究方向为制造大数据、智能制造技术、车间生产管控。
E-mail: fang_weiguang@hotmail.com
- 郭宇(通信作者), 男, 1971 年出生, 教授, 博士研究生导师。主要研究方向为智能制造技术、制造物联网、制造大数据技术、制造系统仿真与优化。
E-mail: guoyu@nuaa.edu.cn
- 黄少华, 男, 1990 年出生, 博士后。主要研究方向为智能制造技术、制造物联网技术、车间生产管控。
E-mail: shaohuah@nuaa.edu.cn
- 刘道元, 男, 1995 年出生, 博士研究生。主要研究方向为制造大数据分析、车间调度。
E-mail: 11562773948@163.com
- 崔世婷, 女, 1996 年出生, 硕士研究生。主要研究方向为制造大数据分析、车间生产异常检测。
E-mail: 1767493582@qq.com
- 廖文和, 男, 1965 年出生, 教授, 博士研究生导师。主要研究方向为智能制造技术、微小卫星技术、CAD/CAM、高端机器人装备等。
E-mail: cnwho@mail.njust.edu.cn
- 洪东跑, 男, 1983 年出生, 博士, 研究员。主要研究方向为装备智能保障体系、装备健康管理 and 飞行器总体设计。
Email: hloving@163.com