

AI 自适应调度与制造资源动态配置策略

郑友刚

(九江学院, 江西 九江 332005)

摘要: 随着全球市场竞争的加剧与客户需求的日益个性化, 传统刚性生产模式的弊端日益凸显, 柔性制造已成为智能制造的核心诉求。本文聚焦于贯穿设计、工艺、制造的数字线程, 研究人工智能技术如何在此环境下实现自适应调度与制造资源的动态配置。论文首先分析了传统生产调度系统在应对实时扰动时的局限性, 继而构建了一个基于数字线程的 AI 自适应调度框架。该框架整合了实时订单数据、设备状态信息、物料库存等多源异构数据, 利用深度学习、强化学习等 AI 算法, 实现生产排程的自主决策与动态优化。重点探讨了面向扰动响应的动态调度策略、基于负载均衡的资源弹性配置方法, 以及数字孪生技术在策略仿真与验证中的应用。最后, 通过一个仿真案例验证了所提策略在缩短订单交付周期、提高设备利用率和增强系统抗扰动能力方面的有效性, 并对未来研究方向进行了展望。

关键词: 人工智能; 自适应调度; 资源动态配置; 数字线程; 柔性制造; 数字孪生

一、引言

机械设计制造领域正经历着以智能制造为核心的深刻变革。市场的动态多变性与客户需求的个性化、小批量趋势, 对制造系统的柔性、响应速度和效率提出了前所未有的挑战。传统的生产计划与调度模式通常基于静态或周期性的规划, 难以有效应对生产过程中随时出现的订单插单、紧急订单变更、设备突发故障、物料配送延迟等不确定性扰动^[1]。这种刚性调度模式往往导致生产计划与实际执行脱节, 造成设备利用率低下、在制品库存积压、订单交付周期延长等问题。

在此背景下, 构建能够实时感知环境变化、并快速做出智能化决策的自适应生产调度与资源管理系统, 成为实现真正意义上柔性制造的关键。人工智能技术, 特别是机器学习、深度学习和强化学习, 因其强大的数据处理、模式识别和决策优化能力, 为解决这一复杂动态优化问题提供了全新的技术路径。同时, 数字线程技术的成熟, 实现了产品从设计、工艺规划到制造执行全生命周期数据的无缝链接与双向流动, 为 AI 决策提供了实时、准确、一致的数据基础。

本文的研究核心在于: 如何利用 AI 技术, 在数字线程构建的透明化、集成化环境中, 根据实时订单变化、设备状态等信息, 动态地、自洽地调整生产排程和资源分配策略。本研究旨在提出一套系统的 AI 自适应调度与资源动态配置策略, 以提升制造系统在面对内外部扰动时的韧性、效率与灵活性, 为推进智能制造落地提供理论模型与实践参考。

二、AI 自适应调度与资源动态配置的理论框架

2.1 传统调度系统的局限性

传统生产调度系统大多基于数学规划(如混合整数规划)、启发式规则(如最短加工时间优先 SPT、先到先服务 FCFS)或仿真优化。这些方法虽然在特定条件下能取得较好效果, 但普遍存在以下局限性:

1. 静态性与滞后性: 方案一旦制定, 缺乏对生产现场实时动态变化的响应能力, 调整

作者简介: 郑友刚(1985-), 男, 研究生, 工程师, 研究方向为以“教育技术”为核心, 赋能制造业。

往往依赖人工干预，响应迟缓。

2. 局部优化：大多数启发式规则只关注单一目标（如最小化完工时间），难以处理多目标（如交货期、成本、资源利用率）协同优化的复杂场景。

3. 模型依赖性：数学规划方法严重依赖精确的数学模型，而对现代制造系统中普遍存在的不确定性和非线性关系描述能力不足。

2.2 基于数字线程的 AI 自适应调度框架

为解决上述问题，本文构建了一个集成数字线程的 AI 自适应调度与资源动态配置框架，如图 1 所示，该框架展示了从底层数据采集到顶层决策执行的全过程。数据感知层通过物联网设备采集制造现场实时数据。数字线程与数字孪生层汇聚多源数据，构建并驱动与物理实体同步的高保真虚拟模型，为上层决策提供一致的数据环境。AI 决策层是核心，利用内置算法分析孪生数据，生成自适应调度与资源配置方案。执行与控制层将决策指令下发至制造系统执行，并将执行结果反馈至感知层，形成“感知-认知-决策-执行”的闭环自适应控制。数字线程（虚线）贯穿始终，确保数据在各层间双向、无缝流动。

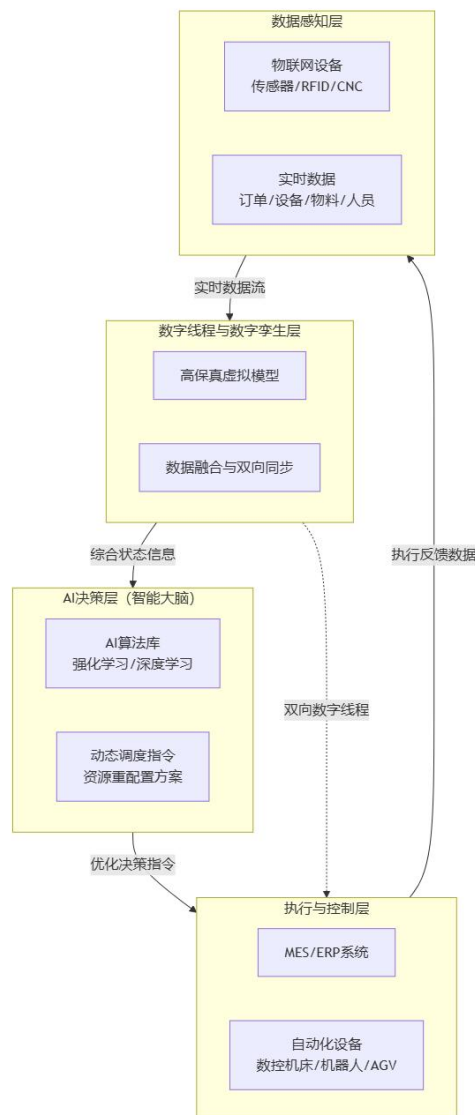


图 1：AI 自适应调度与资源动态配置框架

该框架分为四个层次：

数据感知层：通过物联网技术，实时采集制造现场数据，包括设备运行状态（OEE、故障报警）、订单执行进度、物料消耗与库存、人员状态、能源消耗等。这是系统感知环境的“感官神经”。

数字线程与数字孪生层：作为核心支撑平台。数字线程将数据感知层获取的实时数据，与产品设计（CAD）、工艺规划（CAPP）、制造执行系统（MES）、企业资源计划（ERP）等系统中的模型和数据关联起来，形成一个全要素、全流程、全业务无缝集成的数据闭环。数字孪生则在此基础上，构建物理实体的虚拟映射，为仿真、分析和决策提供高保真模型^[2]。

AI 决策层：这是框架的“智能大脑”。它接收来自数字孪生层的综合信息，利用内置的 AI 算法库（如深度 Q 网络 DQN 用于动态调度决策、卷积神经网络 CNN 用于设备故障预测、图神经网络 GNN 用于资源网络优化）进行实时分析、预测和优化。其核心输出是自适应调度指令和资源重配置方案。

执行与控制层：将 AI 决策层的指令下发至现场的 MES、自动化设备（如 AGV、机器人、数控机床）和资源管理系统，驱动物理实体执行调整后的生产任务和资源分配。

三、 核心策略研究：AI 驱动的动态调度与资源配置

3.1 面向多源扰动的动态重调度策略

生产过程中的扰动主要分为两类：资源相关扰动（如设备故障、工具短缺、操作员缺席）和任务相关扰动（如订单紧急插入、订单取消、优先级变更、工艺变更）。AI 动态重调度策略旨在最小化扰动对生产目标的负面影响。本文提出的策略采用事件驱动与周期驱动相结合的混合触发机制。对于重大扰动（如设备宕机），采用事件驱动立即触发重调度；对于一般性波动，采用短周期（如每 15 分钟）的周期驱动进行微调。

在重调度算法上，重点应用强化学习方法。将生产调度问题建模为一个马尔可夫决策过程（MDP）：

1. 状态（State）：t 时刻的系统状态，包括所有作业的完成情况、各设备状态、当前排队队列、物料可用性。

2. 动作（Action）：决策动作，如为下一空闲设备分配哪个待加工作业、是否启动备用设备等。

3. 奖励（Reward）：根据调度目标设计奖励函数，例如，按时完成订单给予正奖励，延迟则给予负奖励；提高设备利用率给予奖励，设备空闲过长则惩罚。

通过大量仿真环境下的训练，RL 智能体能够学习到在不同系统状态下应采取的最优调度策略^[3]。当扰动发生时，智能体能够基于当前状态快速给出近乎最优的重调度方案，而非从头开始计算，极大提高了响应速度。

3.2 基于负载均衡的制造资源弹性配置策略

资源动态配置的目标是根据实时生产任务负载，弹性地分配机床、刀具、物料、AGV、人员等制造资源，避免资源瓶颈或闲置。本文策略的核心是基于预测的主动配置。

1. 负载预测：利用时间序列分析或 LSTM 神经网络，基于订单计划与实时进度，预测未来一段时间内各工作中心的任务负载。

2. 资源画像与匹配：为每类资源建立动态能力画像（如机床加工范围、精度、效率；AGV 运载能力、速度）。当预测到某个工作中心将出现负载高峰时，AI 系统会从资源池中智能匹配符合条件的闲置或低负载资源（如共享的精密加工中心、柔性高的复合机器人），并提前进行任务分配和路径规划。

3. 多目标优化：资源配置是一个多目标优化问题，需权衡“资源利用最大化”、“任务完成时间最短”、“资源配置成本最低”等多个目标。可采用多目标强化学习或进化算法（如 NSGA-II）来求解帕累托最优解集，为决策者提供多种可选方案。

3.3 数字孪生驱动的策略仿真与验证

在将 AI 决策方案应用于物理生产线之前，必须对其进行验证与评估。数字孪生技术在此环节扮演了关键角色^[4]。通过在虚拟空间中构建与物理生产线完全一致的高保真模型，可以将 AI 生成的调度与资源配置方案注入数字孪生中进行“预演”。

仿真过程可以评估方案在各种指标（如总完工时间、设备利用率、订单延迟率）上的表现，并能模拟极端情况（如突发故障）来测试方案的鲁棒性。如果仿真结果不满足要求，可以快速调整 AI 模型参数或策略，重新生成方案并再次仿真，形成一个“决策-仿真-优化”的快速迭代循环，从而在投入实际生产前最大限度地降低决策风险，提高解决方案的质量。

四、 仿真案例分析与验证

为验证所提策略的有效性，本研究针对一个包含 5 台功能各异数控机床、2 台 AGV 及一个中央仓库的离散制造车间进行了仿真实验。仿真平台采用 Anylogic，并集成 Python 开发的 AI 决策模块。

1. 场景设置：模拟 8 小时的生产班次，初始排产 20 个常规订单。在生产过程中，设置以下扰动：

2. 事件

事件 1（第 2 小时）：一台关键机床突发故障，预计维修 1.5 小时。

事件 2（第 4 小时）：插入 3 个高优先级的紧急订单。

3. 对比方案：

方案 A（传统）：采用静态调度+人工重调度。故障发生后，计划员手动将受影响任务转移到其他可用机床；紧急订单插入后，计划员根据经验调整序列。

方案 B（本文策略）：采用基于强化学习的 AI 自适应调度与资源动态配置策略。

4. 结果分析：仿真结果如表 1 所示。

性能指标	方案 A（传统）	方案 B（本文策略）	提升幅度
总订单完成数量	22	23	4.50%
平均订单延误时间（分钟）	45.6	18.3	-59.90%
设备综合利用率（OEE）	76.20%	84.70%	11.20%
AGV 平均闲置率	22%	15%	-31.80%

表 1 仿真结果对比

分析表明，方案 B 在面对扰动时表现出显著优势。在事件 1 中，AI 系统几乎在故障发生瞬间就完成了受影响任务的重新分配和 AGV 路径的实时优化；在事件 2 中，AI 系统通过动态调整所有订单的优先级和资源分配，在保证紧急订单优先的同时，最小了对常规订单的冲击。这充分验证了 AI 自适应调度策略在提升系统柔性、效率和抗扰动能力方面的有效性。

五、 实施挑战与对策

尽管 AI 自适应调度前景广阔，但在实际应用中仍面临以下挑战：

1. 数据质量与集成：AI 决策严重依赖高质量、高时效的数据。企业需攻克多源异构数据采集、清洗、融合的技术难题，并建立统一的数据标准与接口规范^[5]。

2. 模型泛化能力：针对特定产线训练的 AI 模型，在产线结构或产品族发生变化时可能失效。未来需研究可迁移、可演化的 AI 模型，提高泛化能力。
3. 人机协同：完全自主的 AI 调度可能因“黑箱”问题而让管理者缺乏信任。系统应设计良好的人机交互界面，允许人工介入、解释决策逻辑，实现人机协同决策。
4. 初始投入成本：构建涵盖数字线程、数字孪生和 AI 平台的系统初期成本较高。企业可采取分阶段实施的策略，从关键产线或环节试点，逐步推广。

六、 结论与展望

本文系统研究了在数字线程环境下，AI 驱动的自我适应调度与制造资源动态配置策略。通过构建集成的理论框架，深入分析了基于强化学习的动态重调度、基于负载预测的资源弹性配置等核心方法，并借助数字孪生技术进行仿真验证。案例结果表明，所提策略能够显著提升制造系统应对动态变化的能力，是实现柔性制造的有效途径。

未来研究可从以下几个方面展开：一是探索多智能体强化学习在分布式、跨车间协同调度中的应用^[6]；二是深入研究联邦学习等隐私计算技术，在保证各企业数据安全的前提下，实现跨供应链的协同调度与资源优化；三是将生成式 AI 应用于调度策略的自动生成与创新，例如根据历史数据和市场趋势，自动生成多种可行的弹性生产方案供决策者选择。随着技术的不断突破，AI 自我适应调度必将成为驱动智能制造迈向更高水平的核心引擎。

参考文献：

- [1] 周济. 智能制造——“中国制造 2025”的主攻方向[J]. 中国机械工程, 2015, 26(17): 2273-2284.
- [2] TAO F, ZHANG M, CHENG J, et al. Digital twin and cloud-side-end collaboration for intelligent manufacturing[J]. Robotics and Computer-Integrated Manufacturing, 2022, 76: 102325.
- [3] SUTTON R S, BARTO A G. Reinforcement Learning: An Introduction[M]. 2nd ed. The MIT Press, 2018.
- [4] 邵志芳, 吴继伟, 项薇. 基于数字孪生的智能制造车间动态调度方法[J]. 计算机集成制造系统, 2020, 26(10): 2617-2628.
- [5] MNORI M, GROOVER M. Automation, Production Systems, and Computer-Integrated Manufacturing[M]. 4th ed. Prentice Hall, 2015.
- [6] ZHANG C, JI W. Dynamic resource allocation in smart manufacturing using a multi-agent reinforcement learning approach[J]. International Journal of Production Research, 2023, 61(5): 1544-1564.

AI-Driven Adaptive Scheduling and Dynamic Allocation of Manufacturing Resources

ZHENG Yougang

(Jiujiang University, Jiujiang, Jiangxi 332005, China)

Abstract: As global market competition intensifies and customer demand becomes increasingly personalized, the limitations of traditional rigid production models have become salient, making flexible manufacturing a core mandate of intelligent manufacturing. Focusing on the digital thread spanning design, process planning, and production, this paper investigates how artificial intelligence (AI) enables adaptive scheduling and dynamic allocation of manufacturing resources. We first analyze the constraints of conventional production scheduling systems in responding to real-time disruptions, and then construct a digital-thread-based AI adaptive scheduling framework. Integrating multi-source heterogeneous data—such as real-time order streams, machine status, and material inventories—and leveraging AI algorithms including deep learning and reinforcement learning, the framework achieves autonomous decision-making and dynamic optimization of production planning. We then examine disturbance-aware dynamic scheduling strategies, load-balancing-based elastic resource allocation, and the application of digital twin technology for strategy simulation and validation. Finally, a simulation case demonstrates the effectiveness of the proposed approach in shortening order lead times, improving equipment utilization, and enhancing system robustness against disruptions, followed by a discussion of future research directions.

Keywords: artificial intelligence; adaptive scheduling; dynamic resource allocation; digital thread; flexible manufacturing; digital twin