

DOI:10.11784/tdxbz202411008

一种考虑显隐性干扰的节能车间动态调度方法

田 颖¹, 黄源博¹, 孙超伟²

(1. 天津大学机械工程学院, 天津 300350; 2. 河南省科学院, 郑州 450046)

摘要: 在实际生产制造中, 复杂的车间环境通常伴有显性和隐性动态干扰。显性干扰包括随机工件到达、机器故障、订单取消等, 可能直接导致系统停工; 隐性干扰如设备装夹、运输问题引发的机器空转和生产状态偏差, 会逐渐导致能源浪费和系统性能下降。针对上述问题, 本文提出一种低碳柔性作业车间 (FJSP) 自适应动态调度方法。该方法利用车间状态数据, 针对显性干扰构建多目标动态调度模型, 以最小能耗、最大完工时间、设备总负载和稳定性为优化目标, 通过部分重调度保障车间生产稳定性。针对隐性干扰, 设计了量化动态生产状态的 14 维决策特征, 基于仿真数据建立生产状态数据集, 并结合反向传播神经网络 (BPNN) 为基础构建自适应动态调度决策模型, 该模型可进行 3 种典型调度策略的自适应选择, 有效应对隐性干扰的影响。实验结果表明: 该策略在决策精度和生产优化方面均表现出优异性能, 显著提升了车间的低碳生产效率和系统适应能力。

关键词: 显性干扰; 隐性干扰; 动态调度; 神经网络

中图分类号: TH16; TH186; TP18

文献标志码: A

文章编号: 0493-2137(2026)07-0741-12

An Energy-Efficient Shop Floor Dynamic Scheduling Method Considering Explicit and Hidden Disturbances

Tian Ying¹, Huang Yuanbo¹, Sun Chaowei²

(1. School of Mechanical Engineering, Tianjin University, Tianjin 300350, China;

2. Henan Academy of Sciences, Zhengzhou 450046, China)

Abstract: In actual manufacturing, complex workshop environments are often accompanied by explicit and hidden dynamic disturbances. Explicit disturbances include random job arrivals, machine breakdowns, order cancellations, and other explicit dynamic disturbances, which may directly lead to system shutdowns. Hidden disturbances, such as machine idling and production state deviation owing to problems with machine equipment clamping and transportation, gradually result in considerable energy consumption and system performance decline on the shop floor. To solve the above problems, this study proposes a low-carbon flexible job shop (FJSP) adaptive dynamic scheduling method. It utilizes the state data of a production plant to establish a multi-objective FJSP dynamic scheduling model for explicit disturbances with minimum energy consumption, maximum completion time, and total equipment load and stability, workshop production stability is ensured through partial rescheduling. For hidden disturbances, a 14-dimensional decision feature to quantify the dynamic production state is designed. Based on the simulation data, the production state dataset of the workshop under hidden disturbances is established, and an adaptive dynamic scheduling decision-making model is established based on the back propagation neural network (BPNN). The model can adaptively select among three typical scheduling strategies, effectively coping with the impact of implicit disturbances. The results show that the proposed strategy has good performance in terms of decision accuracy and production optimization, and considerably improves the low-carbon production efficiency and system adaptability of the workshop.

收稿日期: 2024-11-04; 修回日期: 2025-03-17.

作者简介: 田 颖 (1977—), 女, 博士, 副教授, tianying@tju.edu.cn.

通信作者: 黄源博, hybwangyi@163.com.

基金项目: 国家自然科学基金资助项目 (51975407).

Supported by the National Natural Science Foundation of China (No. 51975407).

Keywords: explicit disturbance; hidden disturbance; dynamic scheduling; neural network

随着“工业 4.0”和“中国制造 2025”政策的不断深入,我国制造业正向着智能化快速迈进.车间调度是生产制造的重要环节,智能化背景下传统静态调度方法已无法满足智能制造需求,企业需要具有更高程度的生产自动化和流程灵活性,以提高其内部产品生产能力和应对外部不确定性的能力^[1].制造业的持续增长也带来了严重的环境污染与资源浪费,绿色化成为制造业转型升级过程中的重点.我国制造业能耗总量巨大,2022 年我国制造业能源消耗量为 30.7 亿吨标准煤,占工业能耗总量的 84.5%^[2],具有巨大的节能潜力,因此,降低能源消耗成为制造企业的—个关键目标.

在制造过程中,机床的能耗大部分来源于非加工操作^[3],而加工操作所消耗的能量占比不到 20%^[3].因此,在动态调度中,不仅要考虑动态干扰带来的影响,还需要在重调度过程中从机床本身出发,降低非加工任务的能源消耗. Wu 等^[4]针对 FJSP 的节能问题,选择启停机策略、可变加工速度策略降低生产过程中的能耗. Gong 等^[5]基于柔性作业车间(flexible job shop, FJSP)提出一种考虑节能的新型 FJSP 数学模型,该模型对机器的重启时间进行优化,有效降低了车间总能耗. Cheng 等^[6]针对制造单元的节能问题展开研究,提出了一种混合节能优化策略,该策略包含机器开关、速度缩放和运输优化 3 种主要策略,并验证了该方案的有效性与优越性.

实际车间生产易受各种动态干扰影响,每次干扰都会导致额外的能源消耗和效率降低.因此,降低动态干扰对生产系统的影响,已成为企业亟待解决的难题. Tian 等^[7]针对故障持续时间不确定的问题,提出一种基于虚拟队列控制的自适应调度方法,并通过实验验证了该方法的有效性,该方法保证了车间发生扰动时的运行可靠性和稳定性.针对车间中的各类显性干扰, Zhao 等^[8]提出了一种基于强化学习的启发式算法,用以解决分布式车间调度过程中的插单重调度问题. Luo 等^[9]提出了一种知识驱动的两阶段算法,用以减轻机器突发故障对车间调度的影响,同时降低生产能耗,但以上两者未考虑多种动态事件干扰影响下的重调度问题. Lü 等^[10]提出了一种基于多智能体强化学习的动态调度方法,可以在故障干扰下快速准确地进行车间动态调度,但该方法在面临新的任务时,需要对策略进行重新训练,耗时较长. Gao 等^[11]提出了一种由数字孪生(digital twin, DT)技术驱动的动态调度策略,实现突发事件干扰下的快速重调度,

并通过某航天企业车间案例验证了所提方法的有效性.

综上所述,为提升生产系统应对动态干扰的能力,保证制造车间生产稳定性,本文研究了低碳调度、动态调度的集成,以实现车间性能优化,主要研究内容如下:①针对显性干扰问题提出基于非支配排序遗传算法(non dominated sorting genetic algorithm II, NSGA- II)的重调度方法;②针对隐性干扰问题量化了生产调度信息,基于公开生产数据建立了携带调度特征的调度数据集,构建了特定生产情况与修复策略之间的复杂映射关系;③利用反向神经网络(back propagation neural network, BPNN)进行调度决策模型训练,实现生产系统自适应重调度功能,保持车间高效运行;④通过一个柔性作业车间调度问题案例验证优化模型的有效性,表明该方案可降低车间能耗,保持车间生产性能.

对比现有研究,本文的创新点在于:

(1) 提出针对显性动态干扰与隐性动态干扰的建模方法,并在此基础上提出一种结合 NSGA- II 和 BPNN 的自适应动态调度方法;

(2) 针对显性干扰,以总能耗、完工时间、设备总负载和系统稳定性为优化目标,构建多目标调度优化模型.采用部分重调度策略,通过 NSGA- II 优化算法在显性干扰发生后实现快速有效的调度修复;

(3) 在不同干扰模式下实现了动态调度策略的自适应切换,与以往单一干扰优化方法相比,更好地平衡了显性干扰的直接性和隐性干扰的累积性影响.

1 问题描述

本节介绍动态调度决策问题,包括所涉及的干扰类型、性能指标和重调度策略空间.此外,本节还介绍了约束条件和假设.为了更好地理解所研究的问题,本文使用的符号说明如表 1 所示.

柔性作业车间调度问题可表述为:初始时刻车间共有 n 种待加工工件 $J = \{J_i\}$, $i = 1, 2, \dots, n$,其中工件 J_i 有 S_i 道加工工序 $O = \{O_{i,j}\}$, $j = 1, 2, \dots, S_i$,这些工序可选在 k 台机器 $M = \{M_m\}$, $m = 1, 2, \dots, k$ 上进行加工.柔性作业车间调度问题需要满足以下假设条件:①每台机床同一时刻仅可加工一道工序,每道工序同一时刻仅可在—台机床上加工;②同一工件上的不同工序存在加工顺序约束,不同工件的工序之间无加工顺序约束;③若无突发事件干扰,加工任务在未完工前不能中断;④工件在不同机床间的运

输时间可忽略不计。

表 1 符号说明

Tab.1 Explanation of symbols

符号	描述	符号	描述
i	工件序号	n	工件数量
j	工序序号	k	机床数量
m	机床序号	N	工序数量
J_i	第 i 个工件	M_m	第 m 个机床
l_m	机床 M_m 的加工任务数量	S_i	工件 J_i 的工序数量
$O_{i,j}$	工件 J_i 的第 j 个工序	r	机床加工任务序号
P_{ijm}	在机床 M_m 上加工的总功率	E_c	车间机床的总加工能耗
P_{dm}	机床 M_m 的动态加工功率	E_{Re}	车间机床的总开关机能耗
P_{sm}	机床 M_m 的静态功率	E_{ct}	车间机床的总换刀能耗
P_{ctm}	机床 M_m 的换刀功率	E_s	车间机床的总待机能耗
P_{Add}	车间的附加功率	E_{Add}	车间附加能耗
PT_{ijm}	工序 $O_{i,j}$ 在机床 M_m 上加工的持续时间	ST_{mr}	机床 M_m 的第 r 项工序的开始时间
ST_{ij}	工序 $O_{i,j}$ 的开始时间	t_{ctm}	机床 M_m 刀具的换刀时间
η_{mr}	如果机床 M_m 在第 r 项加工任务前关机, $\eta_{mr} = 1$; 否则, $\eta_{mr} = 0$	λ_{mr}	如果机床 M_m 在第 r 项加工任务前换刀, $\lambda_{mr} = 1$; 否则, $\lambda_{mr} = 0$
CT_{mr}	机床 M_m 的第 r 项工序的结束时间	γ_{ijmr}	如果工序 $O_{i,j}$ 在机床 M_m 上加工, $\gamma_{ijmr} = 1$; 否则 $\gamma_{ijmr} = 0$
t_m	机床 M_m 刀具的使用时间	N_{rest}	受干扰加工任务的数量
N_{rs}	受干扰工序数量	$\overline{ST}_{ij}$	$O_{i,j}$ 调整后的开始时间
y_{ijm}	如果在干扰前的方案中在 M_m 中处理 $O_{i,j}$, 则 $y_{ijm} = 1$, 否则 $y_{ijm} = 0$	y_{ijm}	如果在干扰后的方案中在 M_m 中处理 $O_{i,j}$, 则 $y_{ijm} = 1$, 否则 $y_{ijm} = 0$
C_{max}^{ori}	干扰前调度方案的完工时间	TW_{total}^{rs}	干扰后调度方案的刀具磨损量
C_{max}^{re}	干扰后调度方案的完工时间	L^{ori}	干扰前调度方案的总负载
TL_{ijm}	机床 M_m 加工工序 $O_{i,j}$ 时的刀具寿命	e_{ijm}	机床 M_m 加工工序 $O_{i,j}$ 的相对运行效率
E_{total}^{ori}	干扰前调度方案的总能耗	E_{total}^{rs}	干扰后调度方案的总能耗
TW_{total}^{ori}	干扰前刀具磨损量	T_{Rm}	空载平衡时间

1.1 动态干扰

本节基于刘明周等^[12]的研究,以干扰事件对生产系统影响的程度进行划分,将其分为显性干扰和隐性干扰。显性干扰会直接致使生产系统运行停滞,造成大量生产资源浪费,主要包括机器突发故障、订单插入与订单取消等。隐性干扰一般对系统性能的即时影响较小,但随着时间的推移影响会逐渐积累,导致系统性能下降。在本文中,隐性干扰主要表现为加工

时间的波动。

1.1.1 设备故障

设备故障是车间生产过程中最为常见的动态干扰事件^[13]。设备故障会导致设备停止加工,直至完成修理或更换,故障设备上正在加工的工序需要重新进行加工。

1.1.2 插单与紧急订单

插单与紧急订单涵盖了插单、紧急订单以及订单取消这 3 种类型。所谓插单与紧急订单,是指那些并未被纳入当前生产周期安排,然而因特定缘由,必须在既定交货时间之前优先完成交付的订单,或者是需要撤销的订单。这类订单的出现,往往会对预先制定好的生产计划造成干扰。

1.1.3 加工时间波动

加工时间波动指实际加工时间相比计划时间出现偏差,这种影响会以二叉树的形式在剩余受影响工序中层层积累,导致整个系统的偏差^[14]。

1.2 重调度策略

重调度策略指为消除动态干扰所造成的影响而选用的调度策略。鉴于显性干扰会对生产系统形成直接冲击,本文采取部分重调度策略来应对此类干扰。而隐性干扰对调度方案的影响充满不确定性,为此,本文设计了一种自适应重调度策略,该策略能够从策略池中灵活选取并执行合适的策略,以此降低干扰带来的影响。

在综合考虑普适性与有效性的基础上,本文选取右移重调度、部分重调度以及完全重调度共同搭建起本文的策略空间。

1.2.1 右移重调度

右移重调度定义为推迟剩余受影响工序的开始时间,同时保持原有工序顺序,以此应对干扰并降低干扰造成的影响,由于右移重调度不改变剩余工序加工顺序,因此求解时间较短。

1.2.2 部分重调度

部分重调度定义为将决策点之后的所有受影响工序进行重新安排,未受影响工序保持原有调度方案不变,凭借该特性,部分重调度可以以较低的成本进行调度计划修复。

1.2.3 完全重调度

完全重调度指将决策点之后所有未开始加工工序及受影响工序都纳入到动态调度过程中,其目的是扩大解的搜索范围,寻找最优重调度方案。完全重调度因其计算量大,易导致响应时间过长,需谨慎使用。

1.3 车间多目标调度优化数学模型

基于柔性作业车间生产特性,本文所采用多目标

优化模型满足如下约束条件:

$$CT_{ij} - PT_{ij} \geq CT_{i(j-1)} \quad (1)$$

$$\begin{cases} ST_{m(r+1)} - ST_{mr} > 0 \\ ST_{m(r+1)} - CT_{mr} \geq 0 \end{cases} \quad (2)$$

$$\sum_{m=1}^k \gamma_{ijmr} = 1 \quad (3)$$

模型优化目标为

$$\begin{cases} \min C_{\max} \\ \min E_{\text{total}} \\ \min SI \\ \min WL \end{cases} \quad (4)$$

式中: SI 为稳定性指数; WL 为设备总负载.

1) 最大完工时间

$$C_{\max} = \max_m CT_m^{\max} \quad (5)$$

2) 车间生产总能耗

$$\begin{aligned} E_{\text{total}} = E_c + E_{\text{Re}} + E_{\text{ct}} + E_s + E_{\text{Add}} = \\ \sum_{m=1}^k \sum_{i=1}^n \sum_{j=1}^{s_i} \sum_{r=1}^{l_m} \gamma_{ijmr} P_{ijmr} PT_{ijmr} + \\ \sum_{m=1}^k \sum_{r=1}^{l_m} \eta_{mr} E_{\text{Rem}} + \sum_{m=1}^k \sum_{r=1}^{l_m} \lambda_{mr} P_{\text{ctm}} t_{\text{ctm}} + \\ \sum_{m=1}^k \sum_{r=1}^{l_m} P_{sm} (1 - \eta_{mr}) [(ST_{mr} - CT_{m(r-1)} + \\ P_{\text{Add}} C_{\max})] \end{aligned} \quad (6)$$

在本研究中,车间的总能耗 E_{total} 由加工能耗 E_c , 开/关机能耗 E_{Re} , 换刀能耗 E_{ct} , 待机能耗 E_s 和附加能耗 E_{Add} 5 部分组成,如式(6)所示. 机床动态加工功率 P_{dm} 与切削时间 t_m 的关系^[15-16]为

$$P_{dm} = K_1 n_v a_1 f^{a_2} a_p^{a_3} a_e^{a_4} + K_2 t_m^{a_5} f^{a_6} a_p^{a_7} a_e^{a_8} \quad (7)$$

式中: n_v 、 f 、 a_p 、 a_e 为切削参数; K_1 、 K_2 和 $a_1 \sim a_8$ 均为拟合系数.

由于机床的开/关机能耗 E_{Re} 只与机床的类型和性能有关,因此本文将每台机床的一次开/关能耗 E_{Re} 设为定值. 机床在刀具钝化前必须更换刀具,换刀能耗 E_{ct} 与换刀时间 t_{ctm} 和换刀功率 P_{ctm} 有关. 车间除加工能耗外,还产生照明、计算机等附加能耗,本文车间的附加功率 P_{Add} 设为常数.

3) 系统稳定性

一些动态调度策略在修复调度的同时,也会造成大规模的资源重新分配,致使与原调度计划出现较大程度的偏差,这种偏差会导致系统稳定性下降,因此提出稳定性指数 SI 衡量动态调度对系统的影响程度,稳定性指数 SI 定义为

$$SI = \min(MDI + ODI) \quad (8)$$

式中: MDI 为剩余工序中机器分配偏离原计划的数量占 N_{rest} 的比例; ODI 为所有剩余工序启动时间偏差之和占 $C_{\text{max}}^{\text{ori}}$ 的比例,即

$$MDI = \sum_{i=1}^n \sum_{j=1}^{s_i} \sum_{m=1}^k |y_{ijm} - \bar{y}_{ijm}| / N_{\text{rest}} \quad (9)$$

$$ODI = \sum_{i=1}^n \sum_{j=1}^{s_i} |ST_{ij} - \overline{ST}_{ij}| / C_{\text{max}}^{\text{ori}} \quad (10)$$

4) 设备总负载

$$WL = \sum_{i=1}^n \sum_{j=1}^{s_i} \sum_{m=1}^k \gamma_{ijm} PT_{ijm} \quad (11)$$

2 显性干扰下的动态调度方法

本节采用部分重调度策略应对显性干扰,动态重调度流程如图 1 所示.




图 1 显性干扰下的重调度流程

Fig.1 Rescheduling process under dominant interferences

2.1 决策点分析

本文考虑 3 种干扰情景. 情景 1: 设备均处于空闲状态,如图 2 所示,该状态下如果设备发生故障,则故障设备从可选设备集中被剔除,直至修复完成;如果发生插单与紧急订单,则将剩余工序和新插入的订单工序共同纳入重调度决策中;情景 2: 存在设备处于加工状态时插入订单,如图 3 所示. 该状态下若发生插单与紧急订单,正在加工工序无需中断,将剩余工序和新插入的订单工序共同纳入重调度决策中;情景 3: 存在设备处于加工状态时,发生故障,如图 4




图 2 情景 1

Fig.2 Scenario 1






图 3 情景 2
Fig.3 Scenario 2



(a) 正在加工工序中断



(b) 无工序中断

图 4 情景 3
Fig.4 Scenario 3

所示. 该情况下, 若有工序因故障被中断, 重调度过程中需要将该工序与剩余受影响工序共同纳入重调度决策中, 如图 4(a) 所示. 若无工序中断, 则与情景 2 类似, 如图 4(b) 所示.

2.2 基于 NSGA-II 的重调度算法

NSGA-II 算法是在第一代非支配排序遗传算法基础上优化得到的. 一方面简化了计算过程, 另一方面能够保存种群里的最优个体, 进而提高优化的精准度. 不仅如此, 该算法通过拥挤度计算操作将最优个体均匀拓展至整个 Pareto 域, 保障了种群多样性, 提升了解集质量^[17].

2.2.1 编码与解码

针对 FJSP 中的机器分配与工序排布问题, 采用双层编码方案, 将机器与工序编码为两段有序基因序列, 如图 5 所示. 初始编码方案经过算法交叉、变异等迭代操作, 最后通过半主动解码的方式得到可行调度解, 如图 6 所示.

2.2.2 交叉操作

交叉用于保持种群多样性和获得新解, 本文对工序编码和机器编码分别进行两种不同的交叉操作, 工序编码采用 IPOX 交叉, 机器编码采用 MPX 多点交叉.




图 5 双层编码方案
Fig.5 Two-layer coding scheme




图 6 解码方案
Fig.6 Decoding scheme

2.2.3 变异操作

变异操作与交叉操作作用相同, 用于产生新解、保障种群多样性, 同时有助于避免算法陷入局部最优. 本文针对机器编码进行染色体的变异操作, 随机选择父代染色体中的多个基因片段, 针对所选片段进行机器编码的重新选择, 生成子代染色体.

2.2.4 非支配排序

在 NSGA-II 求解多目标优化问题的过程中, 根据个体适应度值来判断种群中每个个体的支配关系, 对个体进行等级划分, 形成 Pareto 前沿.

2.2.5 算法流程

本文聚焦于典型多目标、多变量以及多约束的非线性组合优化难题, 因此基于 NSGA-II 算法进行求解. 求解过程分两个阶段: ①基于决策点将剩余工序整合为新的生产信息; ②基于阶段 1 所获取的生产信息, 通过 NSGA-II 算法生成重调度方案, 流程如图 7 所示.

2.3 基本信息更新

基于第 2.1 节对决策点的分析, 本节以决策点所处的时间作为关键分割依据, 划分出新的调度基本信息, 在此列举一个案例加以阐释, 详情如表 2 所示. 如图 8 所示, 初始生产方案中, 设备 M_1 在 4 时刻发生故障且此后保持不可用状态, 此时被加工工序 $O_{1,2}$ 与后续工序 $O_{1,3}$ 、 $O_{2,2}$ 、 $O_{3,2}$ 、 $O_{3,3}$ 均受到影响, 生成新的调度基本信息如表 3 所示. 基于表 3 生产信息进行重调度得到新的生产方案如图 9 所示.




图 7 基于 NSGA-II 的重调度方案生成流程

Fig.7 Flow chart of rescheduling scheme generation on NSGA-II

表 2 生产案例基本信息

Tab.2 Basic information of production case

工件编号	加工工序	可选设备	对应加工时间/min
J ₁	O _{1,1}	M ₁ /M ₂ /M ₃	4/9/8
	O _{1,2}	M ₁ /M ₂ /M ₃	6/8/7
	O _{1,3}	M ₂ /M ₃	3/10
J ₂	O _{2,1}	M ₁ /M ₂	6/8
	O _{2,2}	M ₁ /M ₂ /M ₃	4/5/9
J ₃	O _{3,1}	M ₁ /M ₃	4/7
	O _{3,2}	M ₂ /M ₃	5/10
	O _{3,3}	M ₁ /M ₃	4/9




图 8 初始静态调度方案

Fig.8 Initial static scheduling scheme

2.4 NSGA-II 改进部分

本文在 NSGA-II 的基础上, 针对柔性作业车间调度问题做了部分改进.

表 3 更新后的生产案例信息

Tab.3 Updated production case information

工件编号	加工工序	可选设备	对应加工时间/min
J ₁	O _{1,1}	M ₂ /M ₃	8/7
	O _{1,2}		3/10
	O _{1,3}		
J ₂	O _{2,1}	M ₂ /M ₃	5/9
	O _{2,2}		
J ₃	O _{3,1}	M ₂ /M ₃	5/10
	O _{3,2}		9
	O _{3,3}	M ₃	




图 9 重调度方案

Fig.9 Rescheduling scheme

1) 刀具退化和加工功率更新机制

机床加工过程通过该机床累积的加工时间, 利用第 1.3 节所建立的机床功率模型动态计算机床 M_m 即将进行下道工序的即时功率 P_m 以及刀具磨损程度 W_m , 即时功率 P_m 作为下一步加工任务的加工功率, 当机床 M_m 刀具磨损程度大于 1 时 ($W_m > 1$), 则在机床下一道工序加工之前进行该机床刀具更换. 具体机床刀具退化机制如图 10 所示.




图 10 机床刀具退化机制

Fig.10 Machine tool degradation mechanism

2) 换刀与设备开/关机机制

添加了机床换刀和开/关机机制来确定何时打开/

关闭机器以及何时更换换刀位置。

步骤 1 执行如下操作：按照加工任务设定的起始及终止时间，计算空闲时隙，并将其与空载平衡时间进行对比。倘若空闲时隙大于空载平衡时间，说明具备关停机器的潜在条件，此时便转向步骤 2；反之，若空闲时隙未超过空载平衡时间，流程终止。

步骤 2 计算空闲时间槽启动时间与机器最近开机时间的差值，若该差值超安全时间阈值，空闲时隙起始时直接关闭机器，转至步骤 4；否则，转至步骤 3。

步骤 3 设机器最近的开机时间为 t_1 ，后续工序的开机时间为 t_2 。计算 $t_3 = t_1 + H_m$ 。如果 $t_2 - t_3 > T_{Rm}$ ，在 t_3 时关闭机器，转至步骤 4；否则结束。

步骤 4 判断每个设备是否同时存在换刀操作和启停机操作，若存在，转至步骤 5；否则结束。

步骤 5 判断在换刀操作前最近的启停机处的刀具剩余磨损程度 W_m 是否大于刀具成本附加系数。若是，则将换刀操作与启停机操作融合，实现提前换刀，并重新计算优化目标值；否则结束。

3) 引入自适应变异算子

NSGA-II 算法的性能很大程度上受变异操作中的变异率大小的影响，变异率过大导致算法搜寻效率低下，所求全局最优解精度低；变异率过小易导致种群多样性降低，出现早熟现象，本文结合差分进化算法思想，引入自适应变异算子，即

$$\lambda = e^{\frac{1-G_m}{G_m+1-G}} \quad (12)$$

$$F = 2^\lambda F_0 \quad (13)$$

式中： F_0 表示初始变异算子； G_m 表示最大进化代数； G 表示当前进化代数。在算法初始阶段自适应算子为 $2F_0$ ，具备较大值，可以保证种群多样性，随着算法的进展，变异算子逐步降低，加快算法收敛，避免最优解遭到破坏。

3 隐性干扰下的动态调度方法

如第 1 节所述，本文把隐性干扰下的重调度决策问题定义为一个多分类问题。本节设计了一组具备 14 个维度的决策特征，以此实现对生产状态的精准量化，同时依托基于 BPNN 的分类方法来训练决策模型。

3.1 决策特征设计

在重调度模型构建过程中，决策特征的设计质量对决策性能边界影响显著。为全面刻画突发事件对车间的干扰程度，以此进行重调度决策工作，本文基于原调度方案与右移重调度方案，构建了 14 维决策

特征，用于量化动态生产状态，为后续决策奠定基础，决策特征及定义如表 4 所示。

表 4 决策特征
Tab.4 Decision characteristics

特征名称	特征定义
完工时间相对变化量	$\Delta C_{\max} = C_{\max}^{\text{rs}} - C_{\max}^{\text{ori}}$
完工时间相对变化率	$\delta_{C_{\max}} = \Delta C_{\max} / C_{\max}^{\text{ori}}$
能耗相对变化量	$\Delta E_{\text{total}} = E_{\text{total}}^{\text{rs}} - E_{\text{total}}^{\text{ori}}$
能耗相对变化率	$\delta_{E_{\text{total}}} = \Delta E_{\text{total}} / E_{\text{total}}^{\text{ori}}$
能耗相对平均变化量	$\Delta \bar{E}_{\text{total}} = \Delta E_{\text{total}} / N$
刀具磨损相对变化量	$\Delta TW = TW_{\text{total}}^{\text{rs}} - TW_{\text{total}}^{\text{ori}}$
刀具磨损相对变化率	$\delta_{TW} = \Delta TW / TW_{\text{total}}^{\text{rs}}$
影响工序占有率	$PAP = N_{\text{rs}} / N_{\text{rest}}$
工序因子	$OPF = N_{\text{rest}} / N$
负载因子	$LPT = \sum_{o_{ijm} \in O_{\text{rest}}} PT_{ijm} / L^{\text{ori}}$
能耗因子	$EPT = \sum_{o_{ijm} \in O_{\text{rest}}} \frac{P_{ijm} \cdot PT_{ijm}}{E_{\text{total}}^{\text{ori}}}$
刀具磨损因子	$TPF = \sum_{o_{ijm} \in O_{\text{rest}}} \frac{P_{ijm} / TL_{ijm}}{TW_{\text{total}}^{\text{ori}}}$
系统灵活性因子 ^[18]	$PST = \sum_{i=1}^n \sum_{m=1}^k p_{im} \cdot \sum_{j \in \{I_m^{\text{ori}} \setminus I_i\}} e_{ijm}$
稳定性因子	$e_{ijm} = P_{ijm} \cdot PT_{ijm} / (\max_{m \in k} P_{ijm} \cdot PT_{ijm})$ $SI = \min(MDI + ODI)$

本文将动态生产状态转换为 14 维决策特征用作后续决策过程中的决策依据。

3.2 基于 BPNN 的预测建模方法

本节介绍了一种基于 BPNN(反向传播神经网络)的重调度策略分类预测方法。该方法能够依据 3.1 节中所设计的决策特征，进行最优重调度方案的类别预测，自适应选择最优重调度策略。本节 BPNN 基本框架如图 11 所示。




图 11 BPNN 的基本框架

Fig.11 Basic framework of BPNN

BP 神经网络构建了相对简洁的架构体系，其核心构成主要涵盖输入层、隐含层以及输出层这 3 个关键部分，诸多神经元依循特定层级分布其中^[19]。鉴于第 3.1 节所设计的具备 14 维特性的决策特征，输入

层的节点数量相应设定为 14 个;与此同时,依据第 1.2 节提及的 3 种重调度策略,输出层适配性地确立 3 个节点,以此确保信息输入与输出的精准对应.在这一架构中,隐含层的节点数量成为影响 BPNN 精度表现的关键要素,它与具体问题的求解需求以及输入、输出单元的数目紧密关联、相互制约.

本文基于王嵘冰等^[20]在确定隐含层节点个数方面的研究,利用基本经验公式(14)计算隐含层节点个数.

$$s = \sqrt{n+l} + \alpha \quad (14)$$

式中: $n+l = 17$; α 取值范围为 $1 \sim 10$, 本文取 $\alpha = 4$; 隐含层节点个数 s 为 8.

4 实验与分析

本节介绍了显性干扰下自适应调度的实验验证以及隐性干扰下所提自适应策略的数据集构建过程、模型训练流程和实验结果.所有实验均采用 MATLAB R2018b 软件在个人计算机环境下进行,计算机处理器为 AMD Ryze5 5600H with Radeon Graphics@3.30 GHz,内存为 16.0 GB.

4.1 显性干扰下的实验与分析

4.1.1 实验规模

某柔性作业车间共有 6 台机床,每台机床的型号、功率信息、空载平衡时间、安全阈值时间见表 5,车间 5 种待加工工件的工序信息、工艺路线下每道工序的可选机床和切削参数见表 6.

表 5 机床信息

Tab.5 Machine information

设备编号	静态功率 P_{sm}/W	换刀功率 P_{st}/W	换刀时间 t_{st}/s	空载平衡时间 T_{Rm}/s	安全时间 阈值 H_m/s
M ₁	500	200	50	50	120
M ₂	515	180	50	45	120
M ₃	450	300	75	47	100
M ₄	430	295	70	50	100
M ₅	350	160	35	35	75
M ₆	330	160	45	30	75

4.1.2 算法参数设置

通过正交实验进行算法的参数整定,本文 NSGA-II 算法参数设置为:种群数量为 200,最大迭代次数为 30,交叉概率为 0.8,初始变异概率为 0.2.

4.1.3 结果分析

通过 NSGA-II 算法获得原始静态调度方案如图 12 所示,该方案的最大完工时间 C_{max} 为 22.9 min,能耗 E_{total} 为 256.95 kW·min、设备总负载 WL 为 80.9 min. 图中: O 表示机床加工工序; on/off 表示机

床处于关闭状态; RCT 表示机床处于关闭状态,且在该时段内更换刀具; CT 表示换刀工序; CM 表示设

表 6 生产信息

Tab.6 Production information

工件编号	加工工序	可选设备	对应加工时间/min	对应切削参数 n_v, f, a_p, a_s
J ₁	O _{1,1}	M ₁	16.0	1 000, 0.15, 2.5, 2.0
		M ₂	16.0	1 000, 0.15, 2.5, 2.0
		M ₃	8.0	850, 0.17, 3.0, 4.0
		M ₅	8.0	850, 0.17, 3.0, 4.0
	O _{1,2}	M ₁	2.7	750, 0.15, 2.0, 1.5
		M ₃	2.7	750, 0.15, 2.0, 1.5
		M ₂	3.0	750, 0.15, 2.0, 2.0
	O _{1,3}	M ₃	3.0	750, 0.15, 2.0, 2.0
		M ₄	4.0	850, 0.14, 2.0, 2.0
		M ₆	4.0	850, 0.14, 2.0, 2.0
J ₂	O _{2,1}	M ₁	15.0	850, 0.17, 2.0, 2.5
		M ₂	15.0	850, 0.17, 2.0, 2.5
		M ₃	8.0	750, 0.17, 2.0, 5.0
		M ₅	8.0	750, 0.17, 2.0, 5.0
	O _{2,2}	M ₁	12.5	850, 0.15, 2.5, 2.0
		M ₂	12.5	850, 0.15, 2.5, 2.0
		M ₅	15.0	1 100, 0.14, 2.0, 2.0
	O _{2,3}	M ₆	15.0	1 100, 0.14, 2.0, 2.0
		M ₄	2.0	850, 0.14, 1.5, 2.5
J ₃	O _{3,1}	M ₁	16.5	850, 0.17, 3.0, 1.5
		M ₂	16.5	850, 0.17, 3.0, 1.5
		M ₃	8.0	750, 0.17, 2.0, 3.0
		M ₅	8.0	750, 0.17, 2.0, 3.0
	O _{3,2}	M ₃	4.0	850, 0.14, 2.0, 1.5
		M ₆	4.0	850, 0.14, 2.0, 1.5
		M ₁	1.5	750, 0.15, 2.0, 3.0
	O _{3,3}	M ₂	1.5	750, 0.15, 2.0, 3.0
		M ₃	2.0	850, 0.14, 2.0, 3.0
		M ₄	2.0	850, 0.14, 2.0, 3.0
	O _{3,4}	M ₁	2.4	850, 0.14, 1.0, 1.0
		M ₆	2.6	850, 0.14, 1.0, 1.0
J ₄	O _{4,1}	M ₁	16.4	850, 0.17, 3.0, 2.0
		M ₂	16.4	850, 0.17, 3.0, 2.0
		M ₃	8.2	750, 0.17, 3.0, 3.5
		M ₅	8.2	750, 0.17, 3.0, 3.5
	O _{4,2}	M ₂	1.5	650, 0.17, 2.0, 1.5
		M ₄	1.5	650, 0.17, 2.0, 1.5
		M ₁	1.5	750, 0.15, 2.0, 1.5
	O _{4,3}	M ₃	1.5	750, 0.15, 2.0, 1.5
		M ₂	1.4	850, 0.14, 1.0, 1.5
J ₅	O _{5,1}	M ₁	16.0	850, 0.17, 3.0, 3.0
		M ₂	16.0	850, 0.17, 3.0, 3.0
		M ₃	8.1	750, 0.17, 3.0, 3.5
		M ₄	8.1	750, 0.17, 3.0, 3.5
	O _{5,2}	M ₁	7.6	750, 0.15, 2.0, 2.0
		M ₃	7.6	750, 0.15, 2.0, 2.0
		M ₅	0.9	850, 0.14, 2.0, 1.0
	O _{5,3}	M ₅	0.9	850, 0.14, 2.0, 1.0
		M ₆	0.9	850, 0.14, 2.0, 1.0

备处于故障维修状态。

为研究针对显性干扰的重调度算法性能,本文研究了以下两种显性干扰情况,并利用原始遗传算法与改进遗传算法对问题进行对比求解:

- (1) 假定在 $t = 10 \text{ min}$ 时设备;
- (2) M_3 发生故障,故障修复时间为 2 min ;
- (3) 假定在 $t = 10 \text{ min}$ 时插入新订单,新订单如表 7 所示。




图 12 初始静态调度甘特图

Fig.12 Initial static schedule Gantt chart

表 7 新订单信息

Tab.7 New order information

工件编号	加工工序	可选设备	对应加工时间/min	对应切削参数 n_v, f, a_p, a_s
J ₆	$O_{6,1}$	M_1	16.0	850, 0.17, 2.0, 2.5
		M_2	16.0	850, 0.17, 2.0, 2.5
		M_3	8.0	750, 0.17, 2.0, 4.0
		M_6	8.0	750, 0.17, 2.0, 4.0
	$O_{6,2}$	M_1	2.7	750, 0.15, 1.0, 2.0
		M_3	2.7	750, 0.15, 1.0, 2.0
		M_6	2.7	750, 0.15, 1.0, 2.0
	$O_{6,3}$	M_1	3.0	750, 0.15, 2.0, 2.0
		M_2	3.0	750, 0.15, 2.0, 2.0
		M_3	4.0	850, 0.14, 2.0, 2.0
		M_6	4.0	850, 0.14, 2.0, 2.0

图 13 代表发生设备故障后的重调度方案,该方案的最大完工时间 $C_{\max}$ 、能耗 E_{total} 、设备总负载 WL 以及系统稳定性 SI 分别为 25.6 min、282.40 kW · min、




图 13 设备故障下的重调度甘特图

Fig.13 Rescheduling Gantt chart under equipment failure

64.3 min 和 0.86,重调度前后生产系统指标变化如图 15 所示。

图 14 代表发生插单后的重调度方案,该方案的最大完工时间 $C_{\max}$ 、能耗 E_{total} 、设备总负载 WL 及系统稳定性 SI 分别为 25.7 min、278.45 kW · min、93.6 min 和 0.82,重调度前后生产系统指标变化如图 16 所示。




图 14 订单插入后的重调度甘特图

Fig.14 Rescheduling Gantt chart after order insertion

由以上实验结果可知,生产系统稳定性均保持在 1 以内,说明该方法可以极大程度地降低干扰因素对系统运行造成的不利影响,进而满足复杂多变的生产需求。




图 15 设备故障下调度指标变化

Fig.15 Changes in scheduling indicators under equipment failure




图 16 订单插入后调度指标变化

Fig.16 Changes in scheduling indicators after order insertion

图 17 所示为改进算法与原始算法的种群个体最佳适应度变化曲线,通过曲线对比可知,引入自适应变异算子后的改进 NSGA- II 算法收敛性获得了极大

提升,更容易获得最优调度解。




图 17 适应度曲线对比
Fig.17 Comparison of fitness curves




图 18 基于 BPNN 的重调度决策技术路线
Fig.18 Technical route of rescheduling decision based on BPNN

因此,本文采用 BPNN 作为核心手段来快速构建重调度方案.由于神经网络训练必须依赖于坚实的数据基础,因此本节通过仿真实验构建决策数据集,该方法有效解决了现实生产过程中重调度数据难以大规模获取的问题,同时在相同的生产条件下进行调度决策,保证了实验结果的有效性.本文综合考虑决策过程中的 4 个绩效指标(完工时间、能耗、稳定性和设备负载),将与最佳调度相对应的策略作为决策标签。

数据集的构造流程包括第 3.1 节中决策特征的计算和标签的确定过程,该过程描述如下:

(1) 采用 NSGA-II 算法获取随机初始调度方案,并在初始调度方案中随机加入随机动态扰动,模拟隐性扰动下的车间生产过程;

(2) 对受到扰动时的车间进行生产状态信息的提取,同时实行右移重调度策略,结合右移重调度与初始车间生产信息计算 14 维决策特征;

(3) 对受到扰动的车间分别采用右移、部分、完全生成重调度方案,对 3 种调度方案进行评估,基于最优方案确定决策标签;

4.2 隐性干扰下的实验与分析

基于第 3 节的分析,本节构建了针对隐性干扰的车间动态干扰数据库,并实现调度方法的实验与验证,技术路线如图 18 所示。

4.2.1 数据集构建

传统的动态调度决策流程往往过度依赖人们的实践经验与既有知识储备,然而这种决策模式存在弊端,所生成的策略不仅缺乏可靠性,而且难以达到最优效果.若试图借助传统智能算法来确定最优重调度方案,势必要针对各式各样的调度策略逐一展开复杂计算,此过程会增加海量时间成本,这对于追求高效运营的企业而言是难以承受的。

(4) 将步骤 2 与步骤 3 所得的决策特征和标签合并成一个决策样本数据;

(5) 重复步骤 1~4,构造具有一定规模的数据集。

本节以 Brandimarte 标准数据集^[21]为基础进行大规模样本集的生成,针对该数据集中所缺少的参数(切削参数、刀具寿命等),本文采用随机生成的方式,在参数合理范围内随机生成对应数据,补充所缺少的生产参数。

本节所构建的数据集规模如表 8 所示。

表 8 重调度决策数据集的标签分布

Tab.8 Label distribution of rescheduling decision datasets


动态调度策略数量			总数
右移重调度	部分重调度	完全重调度	
164	3 151	775	4 090

4.2.2 决策模型训练


本节数据集中用于训练和测试的样本数量按照 8:2 的比例分配,决策模型的训练过程已在第 3.2 节中阐明。

神经网络训练结果如图 19 所示,该模型分类准

确率达 80%, 可满足调度决策的需要。



(a) 训练集分类结果, 准确率 = 81.540 3%



(b) 测试集分类结果, 准确率 = 80.684 6%

图 19 神经网络训练结果

Fig.19 Neural network training results

4.2.3 实例结果分析

本文以第 4.1.3 节柔性制造车间为例, 检测到机床 M_3 的工序 $O_{2,1}$ 的完工时间由 8 min 变更为 9 min, 此时系统及时响应, 利用第 4.2.2 节的神经网络模型得出决策最优决策方案为右移重调度如图 20 所示, 该方案采用右移重调度策略, 调度方案的 4 类优化指标分别为 [23.9, 0.26, 81.9, 266.15], 耗时 15 s. 若采用传统重调度方法, 右移重调度耗时 13 s, 部分重调度为 [23.9, 0.38, 81.9, 267.50], 耗时 208 s, 完全重调度的 4 项指标 [29.9, 1.80, 80.9, 315.63], 耗时 211 s. 通过对比图 21、图 22 可知, 自适应重调度方法有效降低了重调度所需时间, 获得了最优重调度方案。




图 20 自适应重调度甘特图

Fig.20 Adaptive rescheduling Gantt chart




图 21 调度策略指标对比

Fig.21 Comparison of scheduling strategy indicators




图 22 调度策略运算时间对比

Fig.22 Comparison of operation time of scheduling strategy

5 结 语

本文针对制造车间在复杂动态环境下的显性与隐性干扰问题, 提出了一种低碳柔性作业车间 (FJSP) 自适应动态调度方法. 通过结合 NSGA-II 算法和 BPNN 技术, 实现了显性与隐性干扰下的多目标调度优化, 提出的模型和算法为制造企业在实现低碳生产、提升动态响应能力方面提供了重要参考。

针对显性干扰, 本文通过多目标优化模型和部分重调度策略, 显著提升了车间在发生设备故障、插单等干扰事件后的调度修复效率; 针对隐性干扰, 基于初始调度方案与重调度方案设计能够全面刻画生产状态的多维决策特征, 并结合仿真数据和神经网络技术, 实现了隐性干扰条件下的高效调度决策. 实验结果验证了该方法在降低车间能耗、优化生产效率以及提升系统稳定性方面的有效性。

未来的研究可以在以下几方面进一步深入: ①扩展调度环境复杂性: 将方法推广至更加复杂的生产场景以验证其通用性和适应性; ②优化能耗模型的细化: 考虑更多实际因素对能耗的影响, 从而建立更精细的能耗优化模型; ③增强算法实时性: 研究更高效的算法, 以提升大规模调度问题的求解速度, 进一步缩短响应时间。

参考文献:

- [1] Li P S, Wu W, Zhao Z H, et al. Indoor positioning systems in industry 4.0 applications: Current status, opportunities, and future trends[J]. Digital Engineering, 2024, 3: 100020.
- [2] 国家统计局. 中国统计年鉴 2024[M]. 北京: 中国统计出版社, 2024.

National Bureau of Statistics. China Statistical Yearbook

- 2024[M]. Beijing: China Statistics Press, 2024(in Chinese).
- [3] Mouzon G, Yildirim M B, Twomey J. Operational methods for minimization of energy consumption of manufacturing equipment[J]. *International Journal of Production Research*, 2007, 45(18): 4247-4271.
- [4] Wu X L, Sun Y J. A green scheduling algorithm for flexible job shop with energy-saving measures[J]. *Journal of Cleaner Production*, 2018, 172: 3249-3264.
- [5] Gong G L, Chiong R, Deng Q W, et al. A two-stage memetic algorithm for energy-efficient flexible job shop scheduling by means of decreasing the total number of machine restarts[J]. *Swarm and Evolutionary Computation*, 2022, 75: 101206.
- [6] Cheng L P, Tang Q H, Wu Z J, et al. Mathematical model and enhanced cooperative co-evolutionary algorithm for scheduling energy-efficient manufacturing cell[J]. *Journal of Cleaner Production*, 2021, 326: 129310.
- [7] Tian S L, Wang T Y, Zhang L, et al. Real-time shop floor scheduling method based on virtual queue adaptive control: Algorithm and experimental results[J]. *Measurement*, 2019, 147: 106689.
- [8] Zhao F Q, Liu Y B, Xu T P, et al. A reinforcement learning hyper-heuristic algorithm for the distributed flowshops scheduling problem under consideration of emergency order insertion[J]. *Applied Soft Computing*, 2024, 167: 112461.
- [9] Luo C, Gong W Y, Lu C. Knowledge-driven two-stage memetic algorithm for energy-efficient flexible job shop scheduling with machine breakdowns[J]. *Expert Systems with Applications*, 2024, 235: 121149.
- [10] Lü L L, Fan J X, Zhang C J, et al. A multi-agent reinforcement learning based scheduling strategy for flexible job shops under machine breakdowns[J]. *Robotics and Computer-Integrated Manufacturing*, 2025, 93: 102923.
- [11] Gao Q L, Liu J H, Li H T, et al. Digital twin-driven dynamic scheduling for the assembly workshop of complex products with workers allocation[J]. *Robotics and Computer-Integrated Manufacturing*, 2024, 89: 102786.
- [12] 刘明周, 单 晖, 蒋增强, 等. 不确定条件下车间动态重调度优化方法[J]. *机械工程学报*, 2009, 45(10): 137-142.
- Liu Mingzhou, Shan Hui, Jiang Zengqiang, et al. Dynamic rescheduling optimization of job-shop under uncertain conditions[J]. *Journal of Mechanical Engineering*, 2009, 45(10): 137-142(in Chinese).
- [13] Sobaszek Ł, Gola A, Kozłowski E. Job-shop scheduling with machine breakdown prediction under completion time constraint[C]// *Proceedings of the 2018 Federated Conference on Computer Science and Information Systems*. Piscataway, USA, 2018: 437-440.
- [14] Abumaizar R J, Svestka J A. Rescheduling job shops under random disruptions[J]. *International Journal of Production Research*, 1997, 35(7): 2065-2082.
- [15] Tian C L, Zhou G H, Zhang J J, et al. Optimization of cutting parameters considering tool wear conditions in low-carbon manufacturing environment[J]. *Journal of Cleaner Production*, 2019, 226: 706-719.
- [16] 田 颖, 邵文婷, 王太勇. 车间生产过程能量足迹建模与加工参数协同优化[J]. *中国机械工程*, 2021, 32(22): 2744-2753.
- Tian Ying, Shao Wenting, Wang Taiyong. Energy footprint modeling and parameter optimization in workshop manufacturing process[J]. *China Mechanical Engineering*, 2021, 32(22): 2744-2753(in Chinese).
- [17] Deb K, Pratap A, Agarwal S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II [J]. *IEEE Transactions on Evolutionary Computation*, 2002, 6(2): 182-197.
- [18] Wahab M I M, Wu D S, Lee C G. A generic approach to measuring the machine flexibility of manufacturing systems[J]. *European Journal of Operational Research*, 2008, 186(1): 137-149.
- [19] 周启超. BP 算法改进及在软件成本估算中的应用[J], *计算机技术与发展*, 2016, 26(2): 195-198.
- Zhou Qichao. Improvement of BP algorithms and its application in software cost estimation[J]. *Computer Technology and Development*, 2016, 26(2): 195-198(in Chinese).
- [20] 王嵘冰, 徐红艳, 李 波, 等. BP 神经网络隐含层节点数确定方法研究[J]. *计算机技术与发展*, 2018, 28(4): 31-35.
- Wang Rongbing, Xu Hongyan, Li Bo, et al. Research on method of determining hidden layer nodes in BP neural network[J]. *Computer Technology and Development*, 2018, 28(4): 31-35(in Chinese).
- [21] Brandimarte P. Routing and scheduling in a flexible job shop by tabu search[J]. *Annals of Operations Research*, 1993, 41: 157-183.

(责任编辑: 王晓燕)