

# 控制与决策

Control and Decision

## 智能制造系统基于数据驱动的车间实时调度

吴秀丽, 孙琳

引用本文:

吴秀丽, 孙琳. 智能制造系统基于数据驱动的车间实时调度[J]. 控制与决策, 2020, 35(3): 523–535.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2018.0849>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

### 面向协同检测与跟踪的多传感器长时调度方法

Non-myopic scheduling algorithm for multi-sensor collaborative detection and tracking

控制与决策. 2020, 35(4): 799–806 <https://doi.org/10.13195/j.kzyjc.2018.0835>

### 基于随机模型预测控制的含大规模风电接入的电力系统优化调度

Optimization and scheduling of power system stochastic model predictive control based optimization and scheduling for power system with large scale wind integrated

控制与决策. 2019, 34(8): 1616–1625 <https://doi.org/10.13195/j.kzyjc.2018.1418>

### 求解区间柔性作业车间调度的多目标进化算法

Multi-objective evolutionary algorithm to solve interval flexible job shop scheduling problem

控制与决策. 2019, 34(5): 908–916 <https://doi.org/10.13195/j.kzyjc.2017.1492>

### 改进人工蜂群算法求解分布式柔性作业车间调度问题

Improved artificial bee colony algorithm for distributed and flexible job-shop scheduling problem

控制与决策. 2019, 34(12): 2527–2536 <https://doi.org/10.13195/j.kzyjc.2018.0336>

### 考虑学习/遗忘特性的软件项目调度多目标优化方法

Multi-objective software project scheduling optimization method with the learning and forgetting effect

控制与决策. 2018, 33(2): 203–210 <https://doi.org/10.13195/j.kzyjc.2016.1546>

### 灾后动态环境下基于MPC的应急运输实时调度

Real-time relief transportation planning based on MPC in post-disaster dynamic environment

控制与决策. 2018, 33(12): 2131–2141 <https://doi.org/10.13195/j.kzyjc.2017.0928>

### 最小化碳排放的可持续机器调度问题

Sustainable machine scheduling problem to minimize carbon emission

控制与决策. 2017, 32(6): 1063–1068 <https://doi.org/10.13195/j.kzyjc.2016.0397>

### 某一转炉或精炼炉故障下炼钢-连铸生产重调度方法及应用

Rescheduling method of steelmaking and continuous casting with breakdown of converter or refining furnace

控制与决策. 2015, 30(11): 1921–1929 <https://doi.org/10.13195/j.kzyjc.2014.1415>

# 智能制造系统基于数据驱动的车间实时调度

吴秀丽<sup>†</sup>, 孙 琳

(北京科技大学 机械工程学院, 北京 100083)

**摘 要:** 智能制造系统采用大量先进的信息技术,为车间实时调度提供技术基础. 各类信息技术在生产制造过程中的广泛应用使得制造系统积累了大量与生产调度相关的数据,因此,通过利用历史生产调度数据和智能装备收集到的实时生产数据,建立基于数据驱动的生产实时调度方法成为新型制造环境下实现高效调度的新思路. 针对智能制造环境下的混合流水车间实时调度问题,提出基于 BP 神经网络的数据驱动的实时调度方法,从历史近优的调度方案中提取用于调度知识挖掘的样本数据,通过 BP 神经网络训练学习获取生产系统状态与调度规则的映射关系网络,并将其应用于生产在线实时调度. 数值实验表明,所提出的方法优于固定单一调度规则,在不同的调度性能指标下其效果均稳定且良好.

**关键词:** 智能制造; 混合流水车间; 实时调度; 机器学习; 人工神经网络

**中图分类号:** TP18

**文献标志码:** A

## Data-based real-time scheduling in smart manufacturing

WU Xiu-li<sup>†</sup>, SUN Lin

(School of Mechanic Engineering, University of Science and Technology Beijing, Beijing 100083, China)

**Abstract:** The smart manufacturing system employs a large number of advanced information technologies, which makes it possible to collect real-time data in production systems. The wide application of various types of information technology in the manufacturing process has enabled the manufacturing system to accumulate a large amount of data relating to production scheduling. Therefore, the historical production scheduling data and the real-time production data collected by smart equipments are used to establish a data-driven production scheduling method. Focusing on real-time hybrid flow shop scheduling problems, a real-time data-driven scheduling method based on the BP neural network is proposed. Firstly, the sample data for scheduling knowledge mining is extracted from the historical optimal and near-optimal scheduling scenarios. Through the BP neural network, the mapping relationship network between the production system state and the dispatching rules is obtained, which is then applied to production online real-time scheduling. Finally, numerical experiments verify that the proposed method outperforms the fixed single dispatching rule, and is stable under different scheduling objectives.

**Keywords:** smart manufacturing; hybrid flow shop; real-time scheduling; machine learning; artificial neural network

## 0 引 言

信息技术的飞速发展推动了制造业信息化、智能化以及知识化的进程,全球范围内逐渐将智能制造作为制造业的核心. 随着德国“工业 4.0”的提出,被称为世界“制造中心”的中国在此基础上将要开始一场规模空前的工业革命——“中国制造 2025”. “中国制造 2025”以中国制造业目前的发展水平为基础,其目的在于提高制造业的智能化水平,并向无人工厂、智能制造模式转型<sup>[1]</sup>. 智能制造 (smart manufacturing, SM) 是制造业与信息技术深度融合的必经之路,是建立制造业竞争优势的关键措施. 智能

制造是制造业升级和优化的必由之路,也是推动中国成为世界真正产业前沿的关键<sup>[2]</sup>. 新一轮工业革命带动了“两化”深度融合,信息技术向制造企业的全面嵌入,将完全转变传统的生产流程和生产模式,这都将极大地推动传统制造业加快转型升级的步伐,最终实现智能制造. 智能制造在实际生产中的代表即为智能工厂<sup>[3]</sup>,智能工厂中采用的信息感知技术能够实现生产过程中对各种物料资源和信息资源的动态感知和智能控制<sup>[4]</sup>,从而大量的生产调度数据将积累于制造系统中. 传统调度问题研究往往忽视了隐藏在制造系统中的生产调度数据中有价值的规律和知识,

收稿日期: 2018-06-21; 修回日期: 2018-10-12.

基金项目: 国家自然科学基金项目 (51305024).

责任编辑: 樊治平.

<sup>†</sup>通讯作者. E-mail: wuxiuli@ustb.edu.cn.

因此,在新的智能制造模式下,研究基于数据驱动的生产调度方法具有重要意义。

许多国内外学者对基于数据的生产调度问题进行了相关研究。Ma等<sup>[5]</sup>提出了一种基于极端学习机器的动态调度模型,实验表明,所提出的方法优于单一规则并表现出了良好的系统性能;Wu等<sup>[6]</sup>基于历史数据,采用遗传算法作为特征选择工具,以 $k$ 近邻算法作为分类器选择调度规则,测试结果验证了该方法的实用性和有效性;袁龙等<sup>[7]</sup>针对作业车间调度的信息闭塞、方法时滞性等问题,研究了动态车间环境下调度规则动态选择的方法,基于遗传算法和神经网络算法提出了动态调度规则选择方法;Bouazza等<sup>[8]</sup>提出了一种基于强化学习的方法来处理部分柔性作业车间调度问题,实验结果验证了所提出方法的有效性;吴启迪等<sup>[9]</sup>针对半导体生产线调度问题,提出了一种基于机器学习的动态调度框架,能够跟随当前生产状态实时切换最佳的调度规则;Zhang等<sup>[10]</sup>提出了一种基于模糊神经网络的优化调度决策机制,实验结果验证了该决策机制方法求解的有效性;Li等<sup>[11]</sup>提出了一种基于自适应调度规则的调度框架,并将其应用在半导体制造系统中;Su等<sup>[12]</sup>提出了基于树的遗传规划和基因表达规划等进化计算方法,设计了新的调度规则求解动态作业车间调度问题;Zhang等<sup>[13]</sup>提出了一种基于动态博弈论的双层调度方法,实现了制造车间的实时数据驱动优化,提高了生产效率;Wang等<sup>[14]</sup>利用时间Petri网描述作业车间的调度过程,提出了基于数据挖掘的调度知识获取框架;Priore等<sup>[15]</sup>提出了一种使用支持向量机和基于案例推理的调度方法,获得了调度知识,从而可以确定每个特定时刻的正确调度规则,仿真结果表明,该方法可行有效的;Olafsson等<sup>[16]</sup>使用基于数据挖掘技术两阶段学习法从历史调度数据中学习新的调度规则。

综上所述,在智能制造环境下,大部分学者研究的领域为作业车间以及柔性作业车间,鲜少有学者研究该环境下的基于数据的混合流水车间实时调度问题,而轮胎模具等<sup>[17-18]</sup>流程工业中的生产方式大多是流水作业,其加工生产过程可抽象为混合流水车间调度问题,并且当前已有企业将智能制造布置于车间中<sup>[18]</sup>,因此,研究新型环境下的混合流水形式的生产调度问题具有重要的研究意义。为此,本文着手于智能制造环境下的混合流水车间的实时调度问题(real-time hybrid flow shop scheduling in smart manufacturing, RTHFS-SM),通过基于BP神经网络(back propagation neural network, BPNN)的调度知识学习机制挖掘历史调度数据中隐含的调度知识,

从而实现实时生产状态与调度规则的动态匹配,指导混合流水车间的实时生产调度过程。

## 1 智能制造混合流水车间调度架构

### 1.1 架构描述

智能制造环境下的混合流水车间不同于以往传统的车间,它融入了大量的先进信息技术,如无线射频识别技术(radio frequency identification, RFID)等,车间同时配备了大量的无线传感装置,比如RFID标签、RFID读写器、无线网络及蓝牙设备等。这些信息采集设备为车间内的人员、设备以及各类设施提供了能够实时信息交互和沟通的渠道。

图1展示的是智能制造环境下的混合流水车间调度架构。每个阶段均存在一个工件缓冲区,在缓冲区的入口处装有RFID读写器,用于采集工件到达缓冲区的实时信息。每台机器配有固定式读写器,可以检测感应工件等资源,同时为机器操作人员提供理论帮助,每名机器操作人员配有RFID员工卡用于认证身份以及确认相应的工作内容,当机器操作员将员工卡放在固定式读写器上感应成功后,就会显示该机器需要加工缓冲区中的哪个工件,然后前往缓冲区取对应工件进行加工。各阶段之间存在多名外部物流操作员,通过手持RFID获取需要执行的搬运任务,从而及时地将加工完的工件通过搬运小车从上阶段搬运至下阶段缓存区。

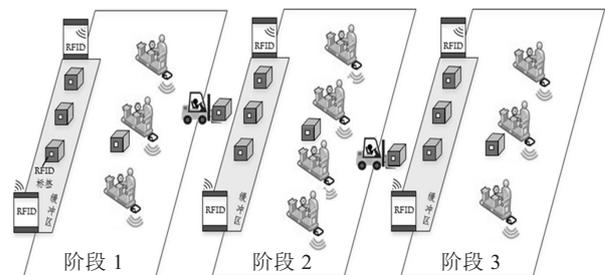


图1 RTHFS-SM架构

智能制造环境下的混合流水车间实时调度问题描述如下:车间中会陆续动态到达一系列需要加工的任务,这些任务包含各种信息,如到达时间、各阶段加工时间和交货期等。在每个阶段内存在一系列相同功能的并行机,对于每个工件而言,必须经过所有的阶段并且在某一阶段的某一台确定的机器上进行加工,每个阶段内的工件缓冲区存放着上游阶段加工完成的工件,阶段管理员根据手持RFID接收工件缓冲区和机器的实时状态信息,实时作出合理的决策,即通过智能装置的信息辅助从阶段缓冲区中众多待加工工件中选择下一步即将加工的工件并安排到当前空闲机器上,如何做到合理选择,从而实现生产调度性能指标的最优,便是本文关注的问题所在。

### 1.2 假设条件

- 1) 每个工件必须经过所有阶段才能完成加工, 每道工序在每个阶段必须在某一台确定机器上进行加工.
- 2) 每台机器同一时刻只能加工一个工件.
- 3) 忽略工件在缓冲区与机器之间的搬运时间.
- 4) 每个阶段均有一系列的相同功能的并行机, 工件在同一阶段的各并行机上的加工时间相同.

### 1.3 符号说明

本文使用的符号说明如表1所示.

表1 符号定义表

符号	含义
$t$	时间决策点
$K$	阶段总数
$i$	工件号
$j$	工序号
$P_{i,j}$	工件 $i$ 在第 $j$ 阶段的加工时长
$r_{i,j}$	工件 $i$ 到达第 $j$ 阶段缓冲区的时刻
$D_i$	工件 $i$ 的交货期
$S_t$	时间决策点 $t$ 所处阶段
$J_{S_t}$	时间决策点 $t$ 时阶段 $S_t$ 缓冲区内待加工工件集
$M_{S_t}$	时间决策点 $t$ 时阶段 $S_t$ 的空闲机器集

## 2 智能制造系统混合流水车间实时调度方法

### 2.1 总体架构

传统的调度优化方法已经无法适应智能制造环境下车间中生产状态的实时变化, 因此很难继续沿用传统优化方法求解新型环境下的车间调度问题. 随着信息技术的迅速发展和在生产制造系统中的广泛应用, 制造系统中积累了大量与调度相关的历史数据, 这些数据中蕴含着有价值的调度知识, 一种可行的实时调度研究思路就是利用已有的历史调度数据, 通过数据挖掘方法获取其中潜在的调度知识, 建立生产系统的当前状态与对应状态下最优调度规则的映射知识网络, 即构建基于数据驱动的调度决策系统, 最终通过利用先进信息技术采集到的实时数据动态快速切换调度规则, 对工件进行合理的调度决策, 指导车间生产调度过程, 从而实现调度过程的智能连续性反应, 提高生产调度决策的实时性和智能性. 此类研究思路与传统调度不同之处在于, 它更加注重对调度知识的学习, 对隐藏在数据中的调度知识进行表达或描述, 从而实现调度知识在生产调度中的重要指导作用.

迄今已提出的基于数据的调度知识获取方法主要为基于学习机制的调度知识获取方法, 调度知识的学习方法主要有决策树、神经网络、聚类、归纳学习

和分类学习等<sup>[19]</sup>. 其中人工神经网络<sup>[20]</sup>作为数据挖掘的一种重要工具已被广泛使用, 其具备较强的学习能力和容错能力, 可以根据不断更新的样本数据进行自我学习训练, 自动调整其网络权重参数以对应多变的问题环境, 因此本文选取人工神经网络作为实时调度的核心技术, 通过神经网络进行调度知识的挖掘.

本文以智能制造环境下的混合流水车间为研究对象, 提出一种基于数据驱动的混合流水车间实时调度方法, 其总体架构如图2所示. 该调度架构包含调度知识离线学习和车间在线调度两个阶段. 调度知识离线学习部分包含训练数据获取和基于BP神经网络的知识学习模块, 用以生成在线调度所需的调度决策知识. 其中: 训练数据获取模块是通过收集车间历史调度数据中各调度决策点对应的生产状态和调度规则的数据, 组成调度知识学习需要的样本数据; 基于BP神经网络的知识学习模块则是通过BP神经网络对获取的训练数据进行挖掘, 从中发现生产系统状态与对应状态下调度规则的映射关系知识. 车间在线调度部分包含车间生产线运转和在线调度决策器两个部分. 其中: 混合流水车间生产线进行实际的生产, 车间中配备的智能感知等装置实时采集生产系统状态和工件设备等生产要素的状态并将其传递给在线调度决策器, 为其提供调度决策所需的数据; 在线调度决策器的作用是车间调度作出调度决策, 即将车间收集到的生产系统状态输入到调度决策器中, 得到一个调度分配规则, 通过该规则选出优先级最高的工件, 将该调度决策返回车间生产线, 指导车间实时调度生产.

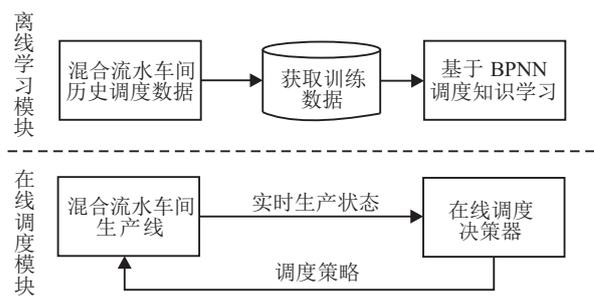


图2 RTHFS-SM求解方法总体架构

该总体架构中最关键的模块为基于BP神经网络的调度知识学习模块, 即根据神经网络的原理及学习算法建立以挖掘调度知识为目标的神经网络模型, 该模型在各决策点根据生产状态参数, 选择合适的调度规则. 该模块根据历史数据信息训练神经网络, 并将训练好的神经网络用于实时调度. 该模块的目的是挖掘生产系统状态与对应状态下调度规则的映射关系知识. 调度规则一般包含和涉及的信息是基于工件的到达时间、加工时长或交货期等信息的. 目前,

表2 调度规则

序号	规则名称	规则含义	数学表达式
1	SPT	待加工工件集中越短加工时长的工件越优先	$\min_{i \in J_{S_t}} \{p_{iS_t}\}$
2	FIFO	待加工工件集越早到达本阶段缓冲区的工件越优先	$\min_{i \in J_{S_t}} \{r_{iS_t}\}$
3	LWR	待加工工件集中剩余加工时长越短的工件越优先	$\min_{i \in J_{S_t}} \left\{ \sum_{j=S_t}^K p_{ij} \right\}$
4	MDD	待加工工件集中修正交货期越小的工件越优先	$\min_{i \in J_{S_t}} \left\{ \max \left( D_i, t + \sum_{j=S_t}^K p_{ij} \right) \right\}$
5	HRN	待加工工件集中等待时间与加工时长之差与加工时长之比越大的工件越优先	$\max_{i \in J_{S_t}} \left\{ \frac{t - p_{iS_t} - r_{iS_t}}{p_{iS_t}} \right\}$
6	CR	待加工工件集中工序临界比越小的工件越优先	$\min_{i \in J_{S_t}} \left\{ \frac{D_i - t}{\sum_{j=S_t}^K p_{ij}} \right\}$

调度规则在许多文献中被大量研究,很多国内外学者<sup>[21-23]</sup>对调度规则的性能进行了研究,但由于调度规则的效率取决于系统特征、加工条件参数和调度目标,因此没有一个规则在所有的性能指标下都比其他规则要好.

本文选取调度规则如表2所示,用于衡量调度规则性能的5个生产指标如表3所示.生产系统状态用于记录生产过程中关于工件、机器等生产元素的状态,比如待加工队列中的工件数、工件平均加工时长、当前空机数量等.本文选取的生产系统状态如表4所示.

表3 生产调度性能指标

序号	生产调度性能指标	符号	表达式
1	最大完工时间	$C_{\max}$	$\max\{c_i\}$
2	平均拖期时间	$\bar{T}$	$\frac{\sum_{i=1}^N \max(0, c_i - D_i)}{N}$
3	总拖期	$\sum T$	$\sum_{i=1}^N \max(0, c_i - D_i)$
4	平均流动时间	$\bar{F}$	$\frac{\sum_{i=1}^N (c_i - r_{i1})}{N}$
5	最大延迟时间	$L_{\max}$	$\max(c_i - D_i)$

表4 生产系统状态属性

序号	生产系统状态	描述	数学表达式
1	Stage	当前时间决策点 $t$ 时所处阶段	$S_t \in K$
2	Idle_mach	当前时间决策点 $t$ 时对应阶段空闲机器数目	$M_{S_t}$
3	Waiting_job	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件数目	$ J_{S_t} $
4	Min_pt	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的最小加工时长	$\min_{i \in J_{S_t}} \{p_{iS_t}\}$
5	Max_pt	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的最大加工时长	$\max_{i \in J_{S_t}} \{p_{iS_t}\}$
6	Mean_pt	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的加工时长的平均值	$\frac{\sum_{i \in J_{S_t}} p_{iS_t}}{ J_{S_t} }$
7	Std_pt	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的加工时长的标准差	$\sqrt{\frac{1}{ J_{S_t} } \sum_{i \in J_{S_t}} (p_{iS_t} - \text{Mean\_pt})^2}$
8	Min_CR	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的工单临界比最小	$\min_{i \in J_{S_t}} \left\{ \frac{D_i - t}{\sum_{j=S_t}^K p_{ij}} \right\}$
9	Max_CR	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的工单临界比最大	$\max_{i \in J_{S_t}} \left\{ \frac{D_i - t}{\sum_{j=S_t}^K p_{ij}} \right\}$
10	Mean_CR	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的工单临界比平均值	$\frac{\sum_{i \in J_{S_t}} \frac{D_i - t}{\sum_{j=S_t}^K p_{ij}}}{ J_{S_t} }$

表4 (续)

序号	生产系统状态	描述	数学表达式
11	Std_CR	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的工单临界比标准差	$\sqrt{\frac{1}{ J_{S_t} } \sum_{i \in J_{S_t}} \left( \frac{D_i - t}{K} - \text{Mean\_CR} \right)^2}$
12	Min_MDD	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的工序交货期最小	$\min_{i \in J_{S_t}} \left\{ D_i - \sum_{j=S_t+1}^K p_{ij} \right\}$
13	Max_MDD	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的工序交货期最大	$\max_{i \in J_{S_t}} \left\{ D_i - \sum_{j=S_t+1}^K p_{ij} \right\}$
14	Mean_MDD	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的的工序交货期平均值	$\frac{\sum_{i \in J_{S_t}} D_i - \sum_{j=S_t+1}^K p_{ij}}{ J_{S_t} }$
15	Std_MDD	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的工序交货期标准差	$\sqrt{\frac{1}{ J_{S_t} } \sum_{i \in J_{S_t}} \left( D_i - \sum_{j=S_t+1}^K p_{ij} - \text{Mean\_MDD} \right)^2}$
16	Min_EDD	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的交货期最小	$\min_{i \in J_{S_t}} \{ D_i \}$
17	Max_EDD	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的交货期最大	$\max_{i \in J_{S_t}} \{ D_i \}$
18	Mean_EDD	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的交货期标准差	$\frac{\sum_{i \in J_{S_t}} D_i}{ J_{S_t} }$
19	Std_EDD	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的交货期平均值	$\sqrt{\frac{1}{ J_{S_t} } \sum_{i \in J_{S_t}} (D_i - \text{Mean\_EDD})^2}$
20	Min_SL	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的松弛时间最小	$\min_{i \in J_{S_t}} \left\{ D_i - t - \sum_{j=S_t}^K p_{ij} \right\}$
21	Max_SL	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的松弛时间最大	$\max_{i \in J_{S_t}} \left\{ D_i - t - \sum_{j=S_t}^K p_{ij} \right\}$
22	Mean_SL	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的松弛时间标准差	$\frac{\sum_{i \in J_{S_t}} D_i - t - \sum_{j=S_t}^K p_{ij}}{ J_{S_t} }$
23	Std_SL	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的松弛时间平均值	$\sqrt{\frac{1}{ J_{S_t} } \sum_{i \in J_{S_t}} \left( D_i - t - \sum_{j=S_t}^K p_{ij} - \text{Mean\_SL} \right)^2}$
24	Min_SWKR	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的单位剩余工作量松弛时间最小	$\min_{i \in J_{S_t}} \left\{ \frac{D_i - t - \sum_{j=S_t}^K p_{ij}}{\sum_{j=S_t}^K p_{ij}} \right\}$
25	Max_SWKR	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的单位剩余工作量松弛时间最大	$\max_{i \in J_{S_t}} \left\{ \frac{D_i - t - \sum_{j=S_t}^K p_{ij}}{\sum_{j=S_t}^K p_{ij}} \right\}$
26	Mean_SWKR	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的单位剩余工作量松弛时间标准差	$\frac{\sum_{i \in J_{S_t}} \frac{D_i - t - \sum_{j=S_t}^K p_{ij}}{\sum_{j=S_t}^K p_{ij}}}{ J_{S_t} }$
27	Std_SWKR	当前时间决策点 $t$ 时对应阶段缓冲区中待加工工件的单位剩余工作量松弛时间平均值	$\sqrt{\frac{1}{ J_{S_t} } \sum_{i \in J_{S_t}} \left( \frac{D_i - t - \sum_{j=S_t}^K p_{ij}}{\sum_{j=S_t}^K p_{ij}} - \text{Mean\_SWKR} \right)^2}$

## 2.2 离线学习模块

离线学习的目的就是从小制造系统以往离线的调度数据中挖掘潜在的调度知识及经验,从而为以后的生产调度过程提供高效、准确的调度决策预测。而调度知识提取的首要步骤就是构建用于挖掘知识的训练数据。基于数据驱动的混合流水车间实时调度架构的第1阶段为调度知识的离线学习。通过基于BP神经网络的学习机制对历史调度数据进行知识挖掘,由此获得不同生产性能指标下的关于生产状态与调度规则的映射关系,将其作为可供在线调度使用的调

度决策选择器,指导车间在线实时生产过程。

### 2.2.1 样本数据构建

生产调度过程实际上是一种实时动态决策的过程,当生产系统中出现设备选择工件的调度决策点时,通过调度规则确定等待加工的工件集合中工件的优先级,然后选择具有最高优先级的工件进行加工,最终实现生产目标的最优化。挖掘调度知识的目的就是建立生产调度过程的当前系统状态到所需的最佳调度规则的映射知识模型,从而动态选择最佳优先调度规则。因此,在生产系统状态与对应状态下所选

用的调度规则即为待挖掘的样本数据. 通过从历史较优调度方案中获取不同调度决策时刻对应的生产系统状态(调度知识中的输入参数)与调度分配规则(调度知识中的输出参数)组成的数据对, 构成用于调度知识挖掘的训练数据.

### 2.2.2 样本数据预处理

由于神经网络的各维度输入量纲可能存在较大差异, 在启用调度知识学习模块进行训练之前, 需要对样本数据进行预处理, 即通过归一化变换将网络的输入输出数据限制在 [0,1] 区间内, 避免在训练时出现某些维度占主导地位而导致的训练速度减慢.

对于某一状态属性下收集到的数据集  $X$ , 某一个原始数据记为  $x$ , 本文采用式 (1) 进行归一化. 其中:  $y$  表示  $x$  归一化变换后的数据,  $x_{\min}$  表示  $X$  的最小值,  $x_{\max}$  表示  $X$  的最大值, 从而将  $x$  变换为 [0, 1] 区间的值, 所有的  $y$  形成向量集  $Y$ .

为了详细介绍归一化过程, 通过一个例子进行说明, 如图3所示.

假设收集到的生产状态属性 Min\_MDD 的数据共 8 组, 图3中原始数据为该 8 组数据, 则对该生产状态属性数据的归一化过程如图3所示.

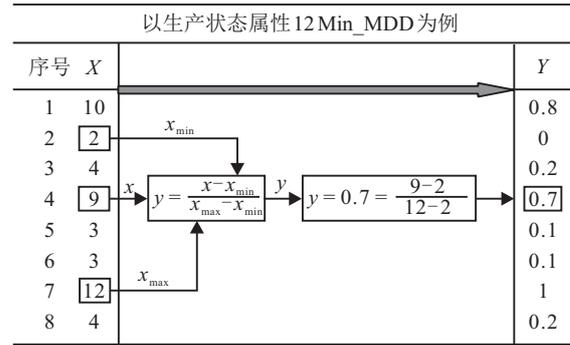


图3 归一化详细过程示例

对于输出数据的变化则为 0.1 或 0.9 的直接转换, 即被选中的规则对应的输出数值为 0.9, 未选中的规则对应的输出数值为 0.1.

$$y = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

为了便于理解, 通过表5对归一化之前的训练数据进行举例说明. 表5中的每行数据由调度知识的输入参数与输出参数组成, 分别显示了不同调度决策时刻下的生产系统状态和对应状态下选择的调度规则, 后续将会把这些数据按照生产系统状态属性分别进行归一化处理, 处理后的数据输入神经网络, 进而通过网络的训练学习实现调度知识网络的构建.

表5 训练样本数据集示例(归一化前)

序号	生产系统状态(输入样本)							调度规则(输出样本)						
	A1	A2	A3	A4	A5	...	A26	A27	R1	R2	R3	R4	R5	R6
1	1	3	11	10	12	...	-1.35	1.26	0.1	0.1	0.1	0.1	0.9	0.1
2	1	2	5	2	8	...	-2.51	-1.92	0.1	0.9	0.1	0.1	0.1	0.1
3	2	2	3	2	4	...	-33.17	-19.75	0.9	0.1	0.1	0.1	0.1	0.1
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

### 2.2.3 学习模型构建

人工神经网络是通过模拟生物神经系统特性以及人脑结构并借助数学方法从信息处理的角度建立的简化模型. 神经网络的优势在于其强大的非线性拟合能力及自适应和自学习能力, 可表达任意复杂的非线性关系, 而且其学习算法易于理解, 便于计算机实现.

神经网络由大量相互关联的神经计算单元以一定的拓扑结构组成, 一般分成若干层, 每一层的神经元接收来自前一层的每个神经的信息作为输入, 其输出通过网络连接传递给相邻后层的每个神经元. 神经网络拓扑结构中第1层为输入层, 最后一层为输出层, 中间其他各层为隐藏层, 网络通过对训练数据的反复学习, 不断调整神经元间的连接权值, 从而达到学习输入与输出之间映射关系的目的. 根据拓扑结构的不同和学习算法的区别, 人工神经网络

可以分为多种不同的类型, 其中后向传播学习的前馈型神经网络 (back propagation feed-forward neural network, BPNN) 应用最为广泛, 因此, 本文选择采用结构为 3 层的 BP 神经网络构建调度知识学习模型, 其中包括输入层、单层隐藏层以及输出层, 如图4所示. 此类神经网络结构简洁, 使用便捷, 且效率较高.

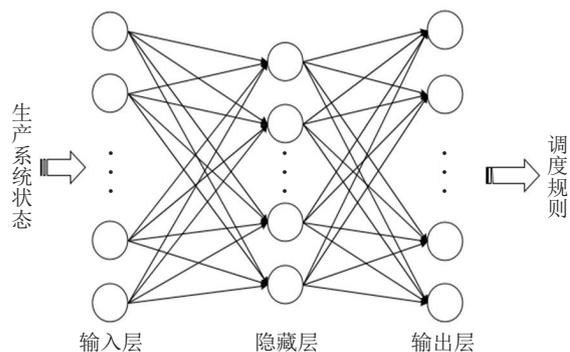


图4 基于BPNN的调度知识学习模型

对于输入层而言,输入的数据即调度知识中的输入参数,具体为一系列的生产系统状态,每个输入层的神经元对应着一个生产系统状态值,输入层神经元数目取决于生产系统状态的个数;调度知识中的输出参数对应着输出层神经元,由对应的调度规则组成,输出层神经元数目取决于调度规则的数目.一旦确定了输入和输出神经元的数量,接下来应该确定隐藏层的神经元数量.隐藏层神经元数的选定极为重要,若数少,则网络难以收敛,或网络容错性差,若数太多,则使网络学习时间过长,产生大量不必要的训练时间,且误差无法保证最小.因此,本文选取的隐藏层神经元的数目根据 Kolmogorov<sup>[24]</sup>定理得到,  $N_{hid} = 2N_{in} + 1$ ,  $N_{hid}$  为隐藏层神经元数量,  $N_{in}$  为输入层神经元数量.搭建完基于BP神经网络的调度知识学习模型后,将获取的训练数据输入到该模型中进行训练学习,通过逐步调整神经权重,直到网络将所有训练输入正确映射到相应的训练输出,得到生产系统状态与当前状态下的最佳调度规则的映射知识网络.该知识网络将作为调度决策器的角色被运用于车间的在线实时调度中,当车间出现调度决策触发点时,将当前生产状态输入调度知识学习模型后,便能快速得到适用于当前生产状态的最佳调度规则,实时指导车间生产过程.

### 2.3 在线调度模块

在获得关于生产系统状态与调度规则之间映射关系的调度知识网络后,便可将其用于混合流水车间的实际在线调度,具体流程如图5所示.在车间在线调度阶段,基于BP神经网络的调度知识学习模型能够依据调度决策时刻当前生产系统的状态,实时提供最佳调度规则,本质上该知识学习模型扮演着调度决策器的角色.在线调度流程步骤如下:

- 1) 工件动态陆续到达生产车间;
- 2) 智能装置实时收集各阶段缓冲区的待加工工件信息以及本阶段空闲设备状态信息;
- 3) 当检测到缓冲区中有多个待加工工件且存在空机时,即存在多工件等待加工的调度决策点时,通

过智能装置实时收集所需的生产状态信息,输入基于BP神经网络的调度决策器,获取当前状态下的最佳调度规则;

- 4) 运用所选调度规则,判断缓冲区中优先级最高的工件,将其安排至空机进行加工;
- 5) 依次完成所有调度决策点的抉择和加工.

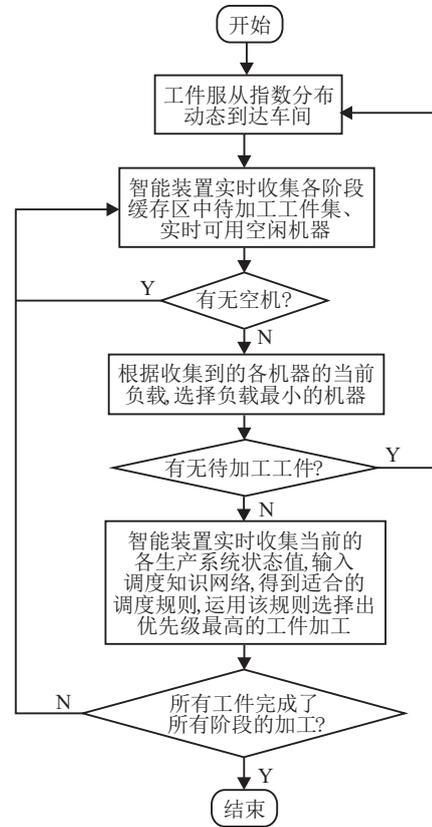


图5 在线调度流程

在线调度流程中最关键的步骤为通过本文建立的基于BP神经网络的调度决策器根据实时生产状态进行调度规则的选择,为了便于理解,在此通过示例进行说明.

假设生产系统目前正处于在某个调度决策点,此时的生产系统状态(鉴于系统状态总数较多,在此只展示部分状态值)如表6所示.将该生产状态实时输入到基于BP神经网络的调度决策器中,得到的结果如表7所示.

表6 某调度决策点的部分生产系统状态

Stage	Idle_mach	Waiting_job	Min_pt	Mean_CR	Max_MDD	Mean_MDD	...	Max_EDD	Std_SL	Max_SWKR
1	2	12	9	0.92	8.98	39.17	...	94.29	34.92	0.92

表7 知识网络决策结果

SPT	FIFO	LWR	MDD	HRN	CR
0.058	0.261	<b>0.852</b>	0.157	0.036	0.023

从表7可以看出,所得到结果中最大值为0.852,其对应的调度规则为LWR规则,故接下来将从缓冲区待加工工件中选出在此规则下优先级最高的工件

进行加工.以此类推,在线调度中出现的所有调度决策点都将按照该方式进行工件的智能选择和加工.

本文提出的基于BP神经网络的调度决策器充分考虑生产系统的实时状态和对应状态下的最优调度规则之间关系的调度知识,并根据生产系统的当前状态,实时切换调度规则,从而指导生产调度过程,实

现调度过程的智能连续性反应,提高生产调度决策的实时性和智能性.

### 3 数值实验

#### 3.1 实验设计

本文的实验均在 Intel Core i5-3210、2.50 GHz CPU、4.00 G RAM、Win 7 32 位操作系统和 Matlab 2013b 编程环境下编译运行. 算法的实验参数如表 8 所示.

表 8 实验参数

参数类型	参数名称	参数取值
BPNN 相关参数	训练样本数	30
	传递函数	Logsig
	训练函数	Traingdx
	输入层神经元数目	27
	输出层神经元数目	6
	隐藏层神经元数目	$27 \times 2 + 1 = 55$
车间相关参数	阶段数 $K$	4
	工件数 $N$	10, 30, 100
	机器数 $M$	$U(1, 3)$
	阶段加工时间 $P$	$U(1, 20)$
	工件到达时间间隔 $I$	$E(5)$
	调度性能指标 $O$	5
	调度规则数 $R$	6
生产系统状态数 $A$	生产系统状态数 $A$	27
	交货期紧张因子	$U(1, 4)$

本节通过模拟智能制造环境下的混合流水车间动态调度场景,采用本文提出的基于数据驱动的实时调度架构,将所提取的动态实时车间调度规则与传统经典调度规则进行对比,以验证所提出的实时车间调度方法的可行性和有效性. 由于实验数据来源有限,本文通过仿真获取的生产调度训练数据模拟制造系统的历史调度数据. 对于每种工件数目,按照参数设置范围随机产生 30 个实例,针对每个实例,共仿真 1 000 次,记录 1 000 次中最优方案中的生产系统状态与调度规则的数据组,即每组实例均能获得一个样本,因此,30 个实例总共获得的训练样本数也是 30.

#### 3.2 实验结果

本文共模拟了 3 组不同工件数量的数值实验,工件规模分为小、中、大 3 种,对应的工件数量分别为 10、30 和 100. 对于每组实验,随机产生 10 个实例,形成测试样本. 针对每个实例,进行单一调度规则和基于 BP 神经网络的学习机制的性能对比. 表 9~表 11 分别展示了小中大工件规模下各个调度规则在不同调度指标下的实验结果,表中的数据均为原始实验数据. 此外,虽然神经网络训练较为耗时,但对于网络的训练是在实时调度之前事先基于历史数据完成的,而调用训练好的神经网络,决策选择几乎是在瞬间完成,据实验统计,平均耗时大约仅需 0.01 s,因此并不

影响其在应用过程中的快速决策能力,完全满足实时调度的要求.

表 9  $N = 10$  实验结果数据

指标	序号	SPT	FIFO	LWR	MDD	HRN	CR	BPNN
$\sum T$	1	93.79	93.79	109.63	93.79	106.4	106.4	106.4
	2	30.25	30.25	30.25	30.25	30.25	30.25	30.25
	3	9.93	9.93	9.93	9.93	9.93	9.93	9.93
	4	3.92	3.92	3.92	3.92	3.92	3.92	3.92
	5	71.15	71.15	71.15	71.15	71.15	71.15	71.15
	6	11.48	11.48	11.48	11.48	11.48	11.48	11.48
	7	116.35	119.68	95.35	119.68	100.35	95.35	109.68
	8	36.97	45.2	25.12	35.97	39.35	37.35	22.64
	9	35.33	35.33	35.33	35.33	35.33	35.33	35.33
	10	69.04	75.23	65.32	79.95	78.32	78.32	47.32
$\bar{T}$	1	9.38	10.64	10.96	9.38	10.64	9.38	10.57
	2	3.03	3.03	3.03	3.03	3.03	3.03	3.03
	3	361.48	378.1	378.1	361.48	360.43	356.48	357.16
	4	5.31	7.77	7.77	5.31	5.21	5.21	6.97
	5	36.15	37.81	37.81	36.15	36.04	35.72	35.84
	6	1.15	1.15	1.15	1.15	1.15	1.15	1.15
	7	11.64	9.54	9.54	11.97	9.54	11.97	10.97
	8	3.7	3.93	2.51	3.6	3.73	4.52	2.13
	9	3.53	3.53	3.53	3.53	3.53	3.53	3.53
	10	6.9	7.83	6.53	8	7.83	7.52	5.18
$\bar{F}$	1	70.42	78.29	72.21	78.88	76.2	87.68	76.97
	2	59.39	61.65	61.42	62.15	58.92	62.89	61.65
	3	65.51	76.28	66.94	74.18	72.07	74.51	65.51
	4	58.32	64.57	61.06	64.53	60.47	66.45	61.04
	5	60.22	58.93	57.51	60.58	58.31	61.58	59.65
	6	51.35	56.38	54.94	54.93	54.56	59.29	53.15
	7	57.63	63.76	60.79	62.42	64.79	62.66	61.67
	8	58.75	60.01	60.67	62.66	60.4	63.21	61.44
	9	48.46	49.78	49	50.17	49.93	50.84	49
	10	65.82	70.91	67.4	74.04	70.22	76.34	69.56
$L_{\max}$	1	36.97	49.97	35.14	34.14	54.14	36.97	20.97
	2	24.21	24.21	24.21	24.21	24.21	24.21	24.21
	3	67.15	67.53	67.15	67.53	67.53	67.15	67.53
	4	3.92	3.92	3.92	3.92	3.92	3.92	3.92
	5	37.04	37.04	37.04	37.04	37.04	37.04	37.04
	6	11.48	11.48	11.48	11.48	11.48	11.48	11.48
	7	29.07	30.41	29.8	28.61	31.71	29.07	28.61
	8	33.12	21.64	25.12	25.64	25.12	22.64	22.64
	9	22.42	22.42	22.42	22.42	22.42	22.42	22.42
	10	47.22	34.1	47.22	35.82	35.82	47.22	35.93
$C_{\max}$	1	182.4	198.85	189.4	196.85	194.85	193.85	186.4
	2	196.02	204.02	204.68	211.02	202.68	213.68	193.68
	3	204.18	205.65	207.18	206.18	208.18	208.18	210.65
	4	188.73	183.73	185.73	191.73	179.73	179.73	189.73
	5	202.76	207.8	208.76	210.41	208.76	203.8	201.24
	6	242.56	242.56	242.56	242.56	242.56	242.56	242.56
	7	199.34	199.34	195.68	192.68	199.68	201.68	193.68
	8	202.07	199.48	198.48	202.07	200.48	208.07	211.07
	9	206.73	215.17	212.17	226.17	219.73	210.17	215.17
	10	218.53	218.53	213.91	214.3	213.91	218.53	213.91

表 10  $N = 30$  实验结果数据

指标	序号	SPT	FIFO	LWR	MDD	HRN	CR	BPNN
$\sum T$	1	2019	2125.34	2126.58	1995.4	2137.62	2103.62	1996.93
	2	993.6	1140.9	1187.93	1026.93	1108.78	1066.63	970.39
	3	1622.87	1597.16	1589.9	1591.44	1607.49	1597.16	1621.48
	4	1195.13	1282.54	1380.44	1189.99	1489.81	1215.79	1189.99
	5	714.95	801.52	775.92	712.95	775.12	775.72	715.53
	6	1018.43	1278.24	1232.95	1098.68	1298.17	1196.29	1084.61
	7	856.11	881.45	918.74	847.6	962.76	839.45	841.58
	8	1081.8	1057.59	1107.47	1023.25	1050.25	1065.59	1023.25
	9	1078.97	1059.47	1130	1075.69	1140.58	1103.52	1040.84
	10	1366.95	1446.45	1336.09	1346.95	1463.25	1445.45	1346.25
$\bar{T}$	1	69.32	71.25	67.3	70.12	70.89	70.84	66.51
	2	34.25	36.96	33.12	35.55	39.6	38.03	34.23
	3	53.72	53.58	54.1	53.24	53	53.24	53.05
	4	42.43	49.66	39.84	40.53	46.01	42.75	39.67
	5	26.72	25.84	23.83	25.86	25.86	26.72	23.77
	6	39.33	43.27	33.95	39.88	41.1	42.61	36.62
	7	26.4	32.09	28.54	27.98	30.62	29.38	28.25
	8	35.09	35.01	36.06	35.52	36.92	35.25	34.11
	9	36.19	38.02	35.97	36.78	37.67	35.32	35.86
	10	48.54	48.77	45.56	48.18	44.54	48.22	44.9
$\bar{F}$	1	51.72	50.65	51.92	51.72	51.75	52.05	51.72
	2	57.12	61.72	62.12	61.32	64.42	61.42	55.62
	3	44.3	45.1	44.3	44.3	45.1	44.3	44.3
	4	46.2	46.2	46.2	46.2	46.2	46	46.2
	5	58.7	64.71	58.44	61.85	66.41	61.14	58.7
	6	49.43	49.03	49.43	49.43	49.03	49.03	49.43
	7	45.15	45.15	45.15	45.15	45.15	45.15	45.15
	8	58.53	59.53	58.53	62.32	59.3	62.32	59.49
	9	57.77	61.77	59.63	62.59	61.71	64.39	57.01
	10	64.67	67.47	65.17	72.05	65.34	73.88	70.67
$L_{\max}$	1	166.47	190.85	164.13	183.47	185.47	176.83	164.36
	2	114.43	153.63	116.67	125.43	122.43	113.77	118.84
	3	181.55	184.55	184.55	184.55	184.55	184.55	175.3
	4	142.38	149.56	141.23	120.38	130.2	138.22	108.26
	5	99.21	126.01	101.21	102	122.21	121.21	99.21
	6	107.81	146.83	118.14	126.8	129.06	145.83	119.97
	7	141.74	136.74	132.74	129.74	154.74	127.74	131.74
	8	162.89	163.89	148.56	149.89	147.89	142.89	149.89
	9	131.46	154.64	129.05	149.64	148.24	147.46	129.46
	10	153.23	149.08	155.08	156.08	151.08	154.08	153.23
$C_{\max}$	1	194.25	199.45	196.45	196.45	203.25	201.25	200.25
	2	222.35	225.35	227.35	233.39	225.35	226.35	220.35
	3	185.55	185.55	194.9	192.9	189.9	188.55	195.55
	4	196.29	198.29	194.43	195.45	194.29	197.43	185.29
	5	208.85	213.85	224.06	226.85	208.06	227.85	218.85
	6	201.7	202.96	203.96	202.96	204.96	206.96	202.96
	7	167.1	178	175	178	170.1	171.1	170.1
	8	218.66	216.22	228.22	222.66	223.66	227.22	216.66
	9	214.42	214.42	211.42	221.02	214.42	211.42	214.02
	10	213.34	214.34	210.39	213.39	206.34	211.34	209.34

表 11  $N = 100$  实验结果数据

指标	序号	SPT	FIFO	LWR	MDD	HRN	CR	BPNN
$\sum T$	1	2383.31	2383.31	2383.31	2383.31	2383.31	2383.31	2383.31
	2	764.23	962.3	764.23	898.35	883.28	881.75	782
	3	923.84	984.68	888.75	980.38	972.08	987.63	855.14
	4	1346.47	1379.79	1323.47	1370.91	1355.79	1386.1	1327.47
	5	831.01	1254.07	908.46	992.28	1041.5	1241.26	845.62
	6	1095.02	1234.17	1161.19	1131.81	1150.06	1222.52	1135.2
	7	1391.38	1423.6	1382.94	1428.15	1428.15	1424.59	1372.28
	8	2070.14	2041.06	1961.84	2091.14	2083	2095.74	1930.44
	9	1342.47	1525.53	1339.56	1432.43	1437.65	1492.16	1284.16
	10	1018.41	1200.26	1010.49	1060.96	1094.45	1236.24	1025.82
$\bar{T}$	1	78.77	79.44	79.44	79.44	79.44	79.44	79.44
	2	26.77	32.08	25.47	29.44	29.95	29.39	26.07
	3	29.8	32.82	29.62	32.40	32.68	32.92	28.50
	4	45.02	45.99	44.12	45.19	45.70	46.20	44.25
	5	28.39	41.80	30.28	34.72	33.08	41.38	28.19
	6	36.48	41.14	38.71	38.34	37.73	40.75	37.84
	7	45.85	47.45	46.10	47.60	47.60	47.49	45.74
	8	65.27	68.04	65.39	69.43	69.70	69.86	64.35
	9	47.1	50.85	44.65	47.92	47.75	49.74	42.81
	10	36.51	40.01	33.68	36.48	35.37	41.21	34.19
$\bar{F}$	1	97.09	110	105	127	106	131	98
	2	94.84	117.71	114.46	137.69	108.82	148.86	98.52
	3	116.54	141.16	117.21	151.81	130.67	149.23	124.81
	4	118.32	152.32	140.21	154.97	138.19	159.81	136.68
	5	106.18	130.68	109.56	142.77	120.71	144.16	119.34
	6	62.06	67.47	62.56	72.73	67.59	74.18	64.46
	7	84.19	95.14	89.42	117.83	92.56	124.31	83.14
	8	90.59	110.15	93.35	143.28	104.68	140.17	94.19
	9	104.26	128.51	120.50	147.95	121.53	146.06	117.07
	10	115.99	142.86	122.94	173.49	135.08	168.13	124.99
$L_{\max}$	1	233.86	233.86	233.86	233.86	233.86	233.86	233.86
	2	114.34	118.01	118.35	156.01	128.83	136.46	118.46
	3	123.4	130.40	131.28	133.28	133.28	129.40	131.28
	4	158.92	141.59	151.92	178.13	145.13	171.79	145.92
	5	149.3	144.82	149.82	164.19	135.82	145.82	136.30
	6	127.18	147.29	124.28	155.29	131.18	151.29	124.18
	7	147.03	153.86	146.47	160.03	153.86	139.64	142.50
	8	187.09	186.80	175.38	204.01	186.80	166.62	182.80
	9	141.69	152.29	133.74	165.98	151.98	149.98	110.98
	10	125.89	126.89	129.28	138.19	128.80	138.10	119.80
$C_{\max}$	1	561.27	567.49	565.49	563.49	562.49	571.27	563.68
	2	625.61	630.61	615.61	622.61	631.28	623.61	620.28
	3	620.61	629.61	632.61	633.77	626.61	624.77	626.61
	4	575.77	574.13	581.91	579.13	577.30	576.91	572.91
	5	570.86	568.86	572.08	574.88	575.08	578.86	571.08
	6	559.2	560.53	560.20	560.53	556.53	559.47	560.20
	7	539.43	552.43	554.43	546.43	549.43	551.43	548.43
	8	552.71	550.71	556.71	560.43	549.71	563.71	550.43
	9	625.5	616.74	634.74	628.50	624.74	623.74	625.50
	10	616.73	616.73	624.73	623.73	622.57	618.73	623.57

由于原始数据表中数据不易观察各调度规则的表现,对其进行转换处理,即对于每一调度指标下的单次实验的原始数据,将每个数据除以该次实验数据中的最小值,即得到一系列的相对值,这些值均不超过1,等于1代表该值为本次实验中的最小值,即对应的调度规则表现最佳.经过原始数据向相对数据的转换后,即得到相对比值表示的数据后,针对每个调度指标,求出10组实例实验结果的平均值,然后对各调度规则进行表现排名,即得到平均值越接近1,该调度规则表现越好.

对表9~表11中的原始实验数据进行归一化和平均化的处理后,为了直观展示各调度规则的表现,将其以排名柱状图的形式进行展示,如图6~图8所示,3张图分别对应着不同工件规模下各个调度规则的排名情况,横坐标为各调度指标,纵坐标为排名,图中的柱形越短表明排名越靠前.

对于小规模工件数  $N = 10$ ,各调度规则表现如图6所示,在各个调度指标下,各调度规则表现均不相同.在总拖期指标下,BPNN调度器的表现排名首位,其次是LWR规则,排在第3位的是SPT规则,而其余的4种规则表现不是很突出;在平均拖期指标下,表现最佳的是BPNN调度器,其次是LWR规则和SPT规则;在平均流动时间指标上,排名首位的是SPT规则,其次是LWR规则,而BPNN调度器排名第3位,位于中上水平;在最大延迟指标上,BPNN调度器表现最佳,其次是MDD和CR规则;在最大完工时间指标下,SPT规则的表现最佳,BPNN调度器紧随其后,表现也较为良好.综合各个调度指标,虽然BPNN决策器并非在所有指标上都是最佳的,但其整体的表现均是较优的,在综合排名中可以看到,代表BPNN调度决策器的矩形的长度远远短于其他矩形,这表明在小

规模工件数目下基于BP神经网络的调度决策方法表现优于其他单一调度规则且性能稳定.

对于中规模工件数  $N = 30$ ,各规则在不同的调度指标下的表现如图7所示.在总拖期指标下,表现最佳的是BPNN调度器,其次是MDD规则和SPT规则;在平均拖期指标下,排名在前3名的分别是BPNN调度器、LWR规则和SPT规则;在平均流动时间指标下,SPT规则的表现最好,虽然BPNN调度器紧随其后位于第2名,但是性能也是较为良好的;在最大延迟指标下,表现最佳的规则依旧是BPNN调度器,其次是LWR规则和SPT规则;在最大完工时间指标下,表现最佳的是SPT规则,本文提出的BPNN调度器排名第2位.由此可以观察到,在不同调度指标下的BPNN调度器的表现始终良好,排名均靠前,在综合排名中其表现依旧位居首位,这表明在中规模工件情况下基于BP神经网络的调度决策方法表现依然稳定,能够在所有调度性能指标下始终如一地提供良好性能.

对于大规模工件数  $N = 100$ ,各规则在不同的调度指标下的表现如图8所示.在总拖期指标下,BPNN调度器的表现最为突出,排名首位;在平均拖期指标下,BPNN调度器代表的柱形依旧是最短的,表明在该调度指标下其表现最佳;在平均流动时间指标下,BPNN调度决策器的表现仅次于SPT规则位列第2;在最大延迟指标下,BPNN调度器的排名依旧处于首位;在最大完工时间指标下,SPT规则表现最佳,BPNN调度器位列第2名.由综合排名可知,BPNN调度器综合表现良好,整体性能稳定,不论何种指标,均能获得理想结果,因此,采用基于BP神经网络调度器进行调度决策要优于固定调度规则的表现.

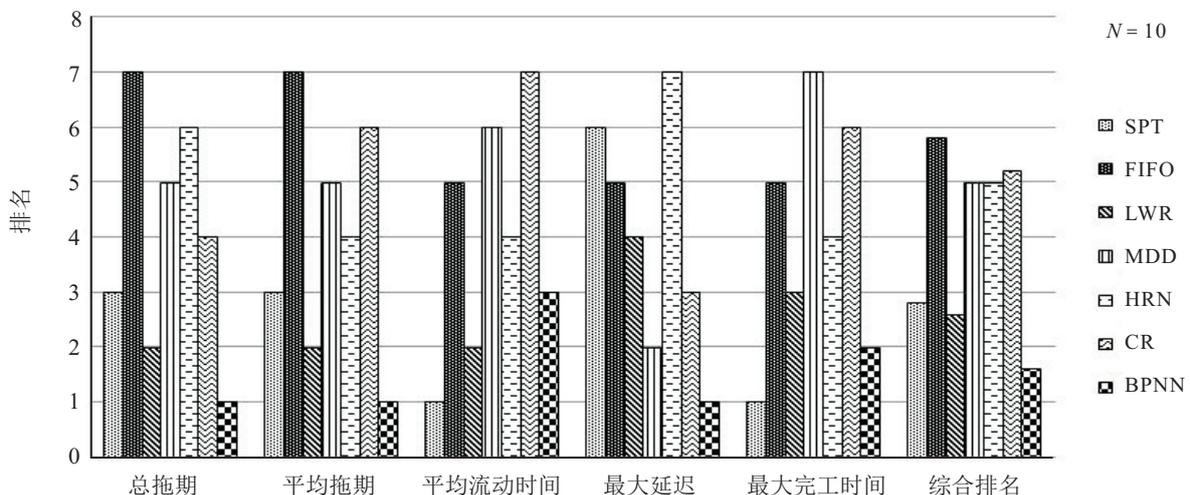


图6  $N = 10$  规则排名柱形图

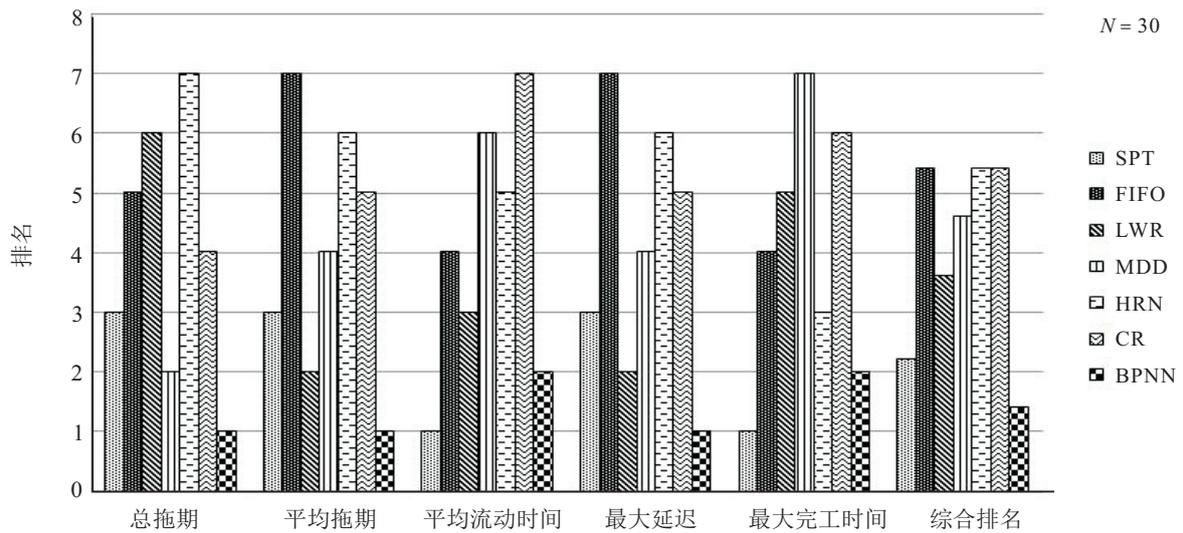


图7 N = 30规则排名柱形图

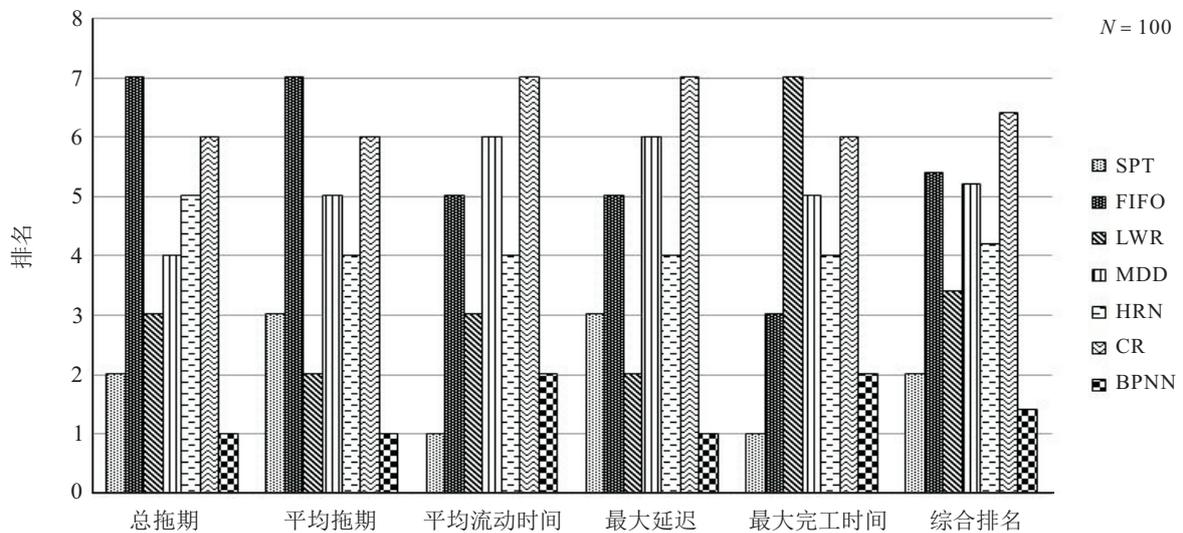


图8 N = 100规则排名柱形图

此外,考虑到不同工件数条件下的各个调度器之间的表现差异,建立一个工件数与调度器表现结果之间的映射关系,如图9~图14所示,图9~图13分别是不同调度指标下工件数与各调度规则的表现情况,图14是综合指标下各调度规则在不同工件数条件下的表现情况.

从图9~图13可以看出,在不同的调度指标下,经典调度规则的表现迥然不同,时而平稳时而波动,

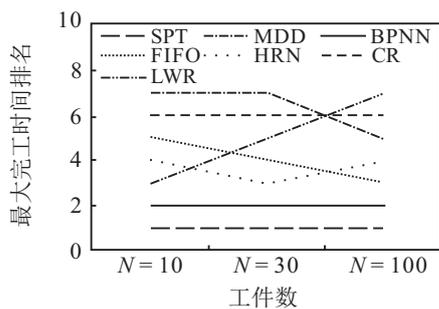


图9 最大完工时间下工件数与规则表现映射

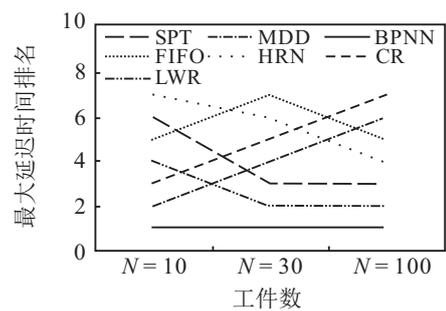


图10 最大延迟时间下工件数与规则表现映射

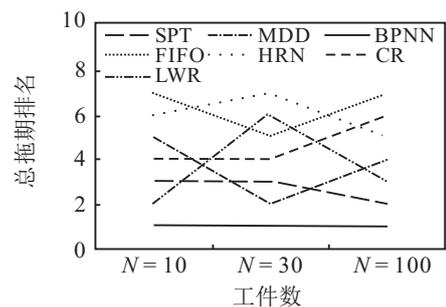


图11 总拖期下工件数与规则表现映射

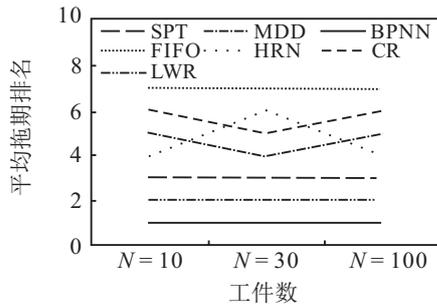


图12 平均拖期下工件数与规则表现映射

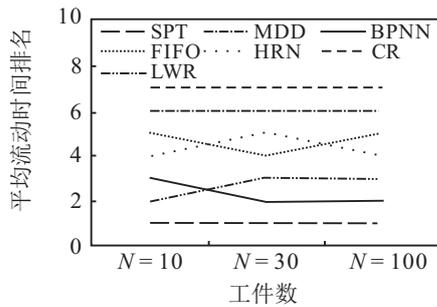


图13 平均流动时间下工件数与规则表现映射

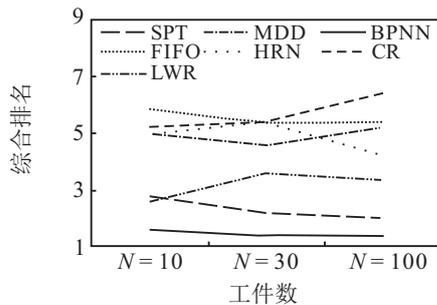


图14 综合指标下工件数与规则表现映射

由此可知,每种经典调度规则并不适用于所有调度目标,无法在各个指标上表现出稳定的特性,而本文提出的基于BPNN的调度决策器在各个指标上表现良好且稳定。

运用固定的经典调度规则最大限度上只可能为单个调度性能标准提供可行或理想的调度,而没有某种特定的调度规则可以为所有调度标准提供令人满意的调度结果。本文提出的基于BP神经网络的方法通过挖掘历史调度数据,挖掘出了生产系统状态与该状态下的最佳调度规则的潜在映射关系。该调度知识充分考虑了各个规则在不同的生产系统状态下的表现,因此,由于其通过对生产系统状态的判断并依据知识映射关系,实时切换到最佳调度规则,而不是固定的某种单一规则。故由上述实验结果可以看出,在不同的工件数量规模下,本文提出的基于BPNN的调度决策方法在各个调度性能指标上表现稳定且良好,虽然偶尔在某些指标上的表现并非很突出,但就整体综合排名而言,该方法效果是最好的。由此可知,本文提出的基于BPNN的实时调度方法表现稳定且

综合表现优于固定的单一调度规则,该方法形成的调度决策器为实时调度提供了在动态变化的制造系统状态中自适应选择最佳调度规则的能力。

## 4 结论

本文以智能制造系统下的混合流水车间实时调度问题为研究背景,提出了一种基于BP神经网络的调度决策方法,通过BP神经网络对历史调度数据进行挖掘,获取生产系统状态与对应状态下最佳规则的映射关系,然后运用获得的调度知识实时指导在线调度中的调度规则切换。数值实验表明,在不同的工件规模下,本文提出的基于BPNN的实时调度方法表现稳定且综合表现优于经典的单一调度规则,能够合理有效地实时指导车间生产调度过程。在今后的研究中,可以在约束更加复杂的混合流水车间调度问题上做进一步探讨,如考虑能力不等的并行机,加工前后是否有缓冲区等情况。这将是下一步的研究工作。

## 参考文献(References)

- [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.  
(Zhou J. Intelligent manufacturing—main direction of “made in China 2025” [J]. China Mechanical Engineering, 2015, 26(17): 2273-2284.)
- [2] Ji Z, Li P, Zhou Y, et al. Toward new-generation intelligent manufacturing[J]. Engineering, 2018, 4(1): 11-20.
- [3] 戴宏民, 戴佩华. 工业4.0与智能机械厂[J]. 包装工程, 2016, 37(19): 206-211.  
(Dai H M, Dai P H. 4.0 industrial and intelligent machinery plant[J]. Packaging Engineering, 2016, 37(19): 206-211.)
- [4] Zhong R Y, Xu X, Klotz E, et al. Intelligent manufacturing in the context of industry 4.0: A review[J]. Engineering, 2017, 3(5): 616-630.
- [5] Ma Y, Qiao F, Lu J. Learning-based dynamic scheduling of semiconductor manufacturing system[C]. IEEE International Conference on Automation Science and Engineering. Texas: IEEE, 2016: 1394-1399.
- [6] Wu W, Ma Y, Qiao F, et al. Data mining based dynamic scheduling approach for semiconductor manufacturing system[C]. Control Conference. Hangzhou: IEEE, 2015: 2603-2608.
- [7] 袁龙, 王俊棋, 陈宇轩. 动态作业车间调度知识推理方法研究[J]. 农业装备与车辆工程, 2017, 55(12): 89-92.  
(Yuan L, Wang J Q, Chen Y X. Research on inference method of scheduling in dynamic workshop[J]. Agricultural Equipment & Vehicle Engineering, 2017, 55(12): 89-92.)
- [8] Bouazza W, Sallez Y, Beldjilali B. A distributed approach

- solving partially flexible job-shop scheduling problem with a Q-learning effect[J]. IFAC-Papers Online, 2017, 50(1): 15890-15895.
- [9] 吴启迪, 马玉敏, 李莉, 等. 数据驱动下的半导体生产线动态调度方法[J]. 控制理论与应用, 2015, 32(9): 1233-1239.  
(Wu Q D, Ma Y M, Li L, et al. Data-driven dynamic scheduling method for semiconductor production line[J]. Control Theory & Applications, 2015, 32(9): 1233-1239.)
- [10] Zhang J, Qin W, Wu L H, et al. Fuzzy neural network-based rescheduling decision mechanism for semiconductor manufacturing[J]. Computers in Industry, 2014, 65(8): 1115-1125.
- [11] Li L, Sun Z, Ni J, et al. Data-based scheduling framework and adaptive dispatching rule of complex manufacturing systems[J]. International Journal of Advanced Manufacturing Technology, 2013, 66(9/10/11/12): 1891-1905.
- [12] Su N, Zhang M, Johnston M, et al. Automatic programming via iterated local search for dynamic job shop scheduling[J]. IEEE Transactions on Cybernetics, 2015, 45(1): 1-14.
- [13] Zhang Y F, Wang J, Liu Y. Game theory based real-time multi-objective flexible job shop scheduling considering environmental impact[J]. Journal of Cleaner Production, 2017, 167: 665-679.
- [14] Wang C L, Rong G, Weng W, et al. Mining scheduling knowledge for job shop scheduling problem[J]. IFAC Papers on Line, 2015, 48(3): 800-805.
- [15] Priore P, Pino R, Parreño J, et al. Real-time scheduling of flexible manufacturing systems using support vector machines and case-based reasoning[J]. Applied Artificial Intelligence, 2015, 3(1): 54-59.
- [16] Olafsson S, Li X. Learning effective new single machine dispatching rules from optimal scheduling data[J]. International Journal of Production Economics, 2010, 128(1): 118-126.
- [17] 吴立华. 不确定环境下模具制造车间前摄与反应式调度方法研究[D]. 广州: 广东工业大学机械工程学院, 2013.  
(Wu L H. Research on proactive and reactive scheduling for mould manufacturing workshop under uncertain environments[D]. Guangzhou: School of Electro-Mechanical Engineering, Guangdong University of Technology, 2013.)
- [18] Luo H, Fang J, Huang G Q. Real-time scheduling for hybrid flowshop in ubiquitous manufacturing environment[J]. Computers & Industrial Engineering, 2015, 84: 12-23.
- [19] 陈兵. 基于数据驱动的过程优化控制方法的研究[D]. 沈阳: 东北大学信息科学与工程学院, 2011.  
(Chen B. Research on optimization and control methods for process based on data-driven[D]. Shenyang: College of Information Science and Engineering, Northeastern University, 2011.)
- [20] Sieniutycz S, Szwasz Z. 4-neural networks—A review of applications[J]. Optimizing Thermal Chemical & Environmental Systems, DOI: 10.1016/B978-0-12-813582-2.00004-5.
- [21] Veronique Sels, Nele Gheysen, Mario Vanhoucke. A comparison of priority rules for the job shop scheduling problem under different flow time-and tardiness-related objective functions[J]. International Journal of Production Research, 2012, 50(15): 4255-4270.
- [22] Branke J, Su N, Pickardt C W, et al. Automated design of production scheduling heuristics: A review[J]. IEEE Transactions on Evolutionary Computation, 2016, 20(1): 110-124.
- [23] Branke J, Pickardt C W. Evolutionary search for difficult problem instances to support the design of job shop dispatching rules[J]. European Journal of Operational Research, 2011, 212(1): 22-32.
- [24] 赵振宇, 徐用懋. 模糊理论和神经网络的基础与应用[M]. 北京: 清华大学出版社, 1996: 85-86.  
(Zhao Z Y, Xu Y M. Introduction to fuzzy theory and neural networks and their application[M]. Beijing: Tsinghua University Press, 1996: 85-86.)

### 作者简介

吴秀丽(1977—), 女, 副教授, 博士, 从事制造过程智能优化调度算法等研究, E-mail: wuxiuli@ustb.edu.cn;

孙琳(1993—), 女, 硕士生, 从事智能制造系统生产调度的研究, E-mail: 18811349587@163.com.

(责任编辑: 闫妍)