



·大科学装置运维·

## 面向大型激光装置的智能装配调度\*

熊 召, 尹灵钰, 裴国庆, 王成程, 周 海

(中国工程物理研究院 激光聚变研究中心, 四川 绵阳 621900)

**摘 要:** 针对大型激光装置精密装校过程中的智能装配调度问题, 提出一种基于人工神经网络的调度优先规则获取方法。该方法离线阶段通过遗传算法对典型算例进行优化求解, 从优化解中抽取任务比较轨迹及特征数据, 采用神经网络学习生成任务优先模型; 在线阶段基于该模型构建闭环调度决策模式, 实现动态不确定生产环境下的快速响应与精准决策。数据实验和实际应用案例验证了该方法的有效性, 随着光机模块数量增加, ANN 调度算法的优势更加明显, ANN 调度算法和 GA 算法二者优化结果小于 6% 时, 前者的计算效率是后者的 400 倍以上。

**关键词:** 神经网络; 调度规则; 智能装配调度

**中图分类号:** TG156

**文献标志码:** A

**doi:** 10.11884/HPLPB202335.230170

## Intelligent assembly scheduling for large laser devices

Xiong Zhao, Yin Lingyu, Pei Guoqing, Wang Chengcheng, Zhou Hai

(Laser Fusion Research Center, CAEP, Mianyang 621900, China)

**Abstract:** Aiming at the assembly scheduling problem of optical and mechanical modules for large laser devices, a scheduling priority rule acquisition method based on artificial neural networks (ANNs) is proposed. In the offline phase, this method optimizes the scheduling data through genetic algorithms, extracts task comparison trajectories and feature data from the optimization solution, and uses ANNs to learn the task priority comparison model. In the online phase, a closed-loop decision scheduling mode is constructed based on this model to achieve rapid response and accurate decision-making in dynamic uncertain production environments. Data experiments and practical application cases verify the effectiveness of this method. With the increase of the number of optical-mechanical modules, the advantages of ANN scheduling algorithm become more obvious. When the optimization results of ANN scheduling algorithm and GA algorithm are less than 6%, the computational efficiency of the former is more than 400 times that of the latter.

**Key words:** artificial neural network, scheduling rules, intelligent assembly scheduling

大型激光装置是研究聚变清洁能源的重要基础设施, 是典型的大科学装置。因为其规模庞大、高精度、高洁净等特点, 装置集成安装面临巨大的挑战<sup>[1]</sup>。为完成该装置中数以万计的光机模块精密装校任务, 提升装校效率和质量一致性, 开展了面向智能制造的数字化车间建设, 其中精密装校管控平台中的智能调度问题研究是一项重要课题。特别是由于精密装校过程经常会出现各种突发状况, 导致实际集成安装过程与理想状态发生偏差, 需要引入智能调度模式对精密装校过程中出现的突发事件做出快速响应, 通过智能调度寻求最优解, 确保达到预期调度目标。该类问题属于柔性装配作业车间调度问题, 当前实际应用中常用启发式调度规则方法求解。该方法是在决策时刻按照事先定义规则计算优先级, 然后按照优先级对待安排对象进行排序。Panwalkar 等<sup>[2]</sup>总结了 113 条常用调度规则, 分别针对不同的求解问题。张泽群等<sup>[3]</sup>采用基于规则的完全反应式调度实现了离散车间自组织生产。龙田等<sup>[4]</sup>利用离散事件仿真系统对各类调度规则进行了分析, 发现调度目标和各种车间结构参数都对调度规则选取有很大影响。总之, 虽然规则调度获得了较为广泛的应用, 但其局部优化特性导致所求解质量并不高, 而且

\* 收稿日期: 2023-06-06; 修订日期: 2023-08-25  
基金项目: 四川省科技计划项目 (2022ZYD0114)  
联系方式: 熊 召, xiong\_022111@163.com。  
通信作者: 王成程, wchch\_caep@163.com。

没有一种调度规则可以在任意调度场景和性能指标下取得优于调度规则的求解性能<sup>[5]</sup>。近年来,随着机器学习技术的蓬勃发展,很多学者将其应用到生产调度领域。机器学习可以通过学习历史数据来预测未来状态,并选择最佳的规则以优化调度决策<sup>[6]</sup>。Mouelhi-Chibani W等<sup>[7]</sup>针对车间动态调度问题,提出了一种利用神经网络模型选择合适调度规则的方法。Golmohammadi<sup>[8]</sup>提出了一种基于神经网络的决策支持模型,可以无需真正调度就能预测调度目标值。张利平等<sup>[9]</sup>提出了一种作业车间调度规则发现方法,该方法从近优调度方案中提取高质量训练样本,试验证明可显著提高规则调度性能。但上述研究主要将机器学习应用于单机、并行机、作业车间等问题的调度规则选择,对精密装校车间这类调度问题还未检索到相关文献。因此,结合大型激光装置实际课题需求开展精密装校车间调度问题研究具有非常强的必要性。

## 1 问题描述与建模

### 1.1 精密装校过程简介

精密装校过程主要包括光学元件清洗处理、光学元件涂膜、机械框清洗处理、机械框烘烤、光机集成装配等环节,其中光学元件与机械框清洗可以并行处理,两者完成后再进行光机装配。光机装配属于核心工艺环节,包括机械件组装与光机组装。典型产品工艺如图1所示。

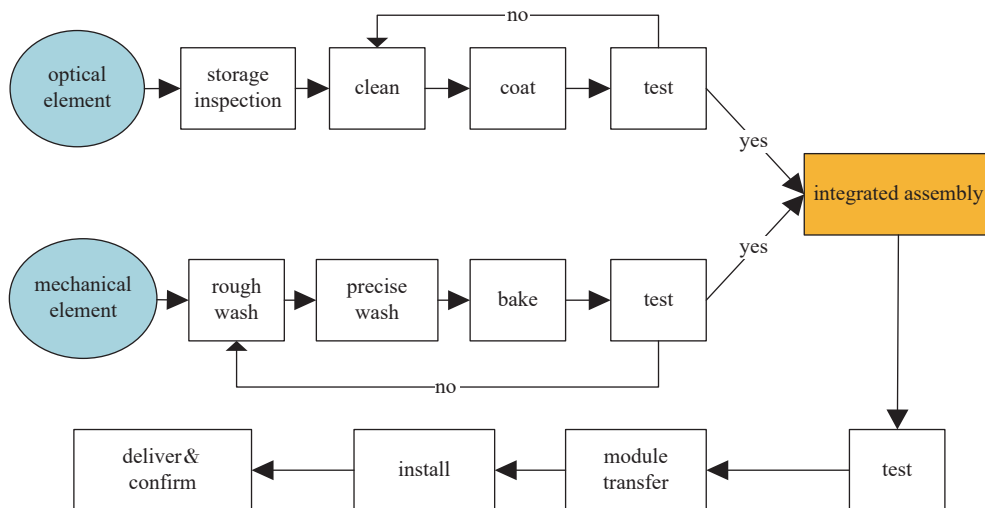


Fig. 1 Typical optical-mechanical modules precision assembly and calibration process

图1 典型光机模块精密装校工艺过程

### 1.2 问题假设

设  $m$  个光机模块在  $n$  台设备上进行精密装校。每个光机模块有若干道不同工序,每道工序由一个工作中心完成。每个工作中心内包含若干台相同设备,工序在不同设备上装校的时间一定。调度目标是为工序选择合适的设备,并确定各设备上工序的加工顺序,使光机模块装校最大完成时间尽可能最小。此外,精密装校车间调度问题还需包含以下假设:1)所有光机模块和设备在0时刻均处于就绪状态;2)同一时刻一台设备只能装校一道工序;3)同一道工序在同一时刻只能在一台设备进行装校;4)工序一旦开始加工就不允许中断;5)仅考虑同一光机模块内工序加工的先后次序约束,不同光机模块间工序优先级相同;6)不考虑检测引起的多次返工问题,保证每道工序只有一个后续节点。

### 1.3 问题数学模型

精密装校车间调度问题可以表示为如下整数规划模型。

首先,定义符号变量: $M$ 为光机模块集合; $N$ 为设备集合; $J$ 为工序任务集合; $O_{mj}$ 为第  $m$  个光机模块的第  $j$  道工序任务; $N_{mj}$ 为工序任务  $O_{mj}$  可以选择的设备集合; $R_{mj}$ 为工序任务  $O_{mj}$  的前置工序集合; $P_{mj}$ 为工序任务  $O_{mj}$  的处理时间; $C_m$ 为第  $m$  个光机模块的完工时间; $S_{mjn}$ 为工序任务  $O_{mj}$  在设备  $n$  上的开始时间; $f_{mjn}$ 为工序任务  $O_{mj}$  在设备  $n$  上的完成时间。

其次,定义决策变量: $x_{mjn}$ 为工序任务  $O_{mj}$  分派到设备  $n$ ,则为1,否则为0; $y_{mjpnq}$ 为设备  $n$  的任务序列变量,如果工序任务  $O_{mj}$  先于工序任务  $O_{pq}$ ,则为1,否则为0。

目标函数

$$f = \min C_{\max} \quad (1)$$

调度约束

$$C_{\max} = \max \{C_m\}, \quad \forall m \in M \quad (2)$$

$$s_{pqn} \geq f_{mjn} + y_{mjpnq}, \quad \forall n \in N_{mj}, \quad \forall p, m \in M, \quad \forall q, j \in J \quad (3)$$

$$s_{mq} \geq f_{mj}, \quad \forall m \in M, \quad \forall j \in R_{mq} \quad (4)$$

$$\sum_{n \in N_{mj}} x_{mjn} = 1, \quad \forall m \in M, \quad \forall j \in J \quad (5)$$

$$c_m = \max(f_{mjn} + x_{mjn}), \quad \forall m \in M, \quad j \in J, \quad n \in N_{mj} \quad (6)$$

$$f_{mjn} = s_{mjn} + p_{mjn}, \quad \forall m \in M, \quad \forall j \in J, \quad \forall n \in N_{mj} \quad (7)$$

约束式(2)定义了所有光机模块最大完工时间;约束式(3)表示同一时刻一台设备只能装校一个光机模块的一道工序,同一台设备上后置工序的开始时间一定大于前置工序完成时间;约束式(4)表示加工顺序约束,即同一光机模块内只有前面所有工序完成后才能开始加工下道工序;约束式(5)表示每道工序会且仅会分配给一个设备;约束式(6)表示光机模块  $m$  的完工时间为其工序的最晚完工时间;约束式(7)设置了工序的完工时间为开始时间加上装校时间,即不允许中断。

## 2 求解方法

### 2.1 总体框架

针对上述大型激光装置中柔性装配作业车间调度问题,提出了一种基于神经网络(Artificial Neural Network, ANN)的调度优先规则生成方法。该方法总体框架如图2所示。

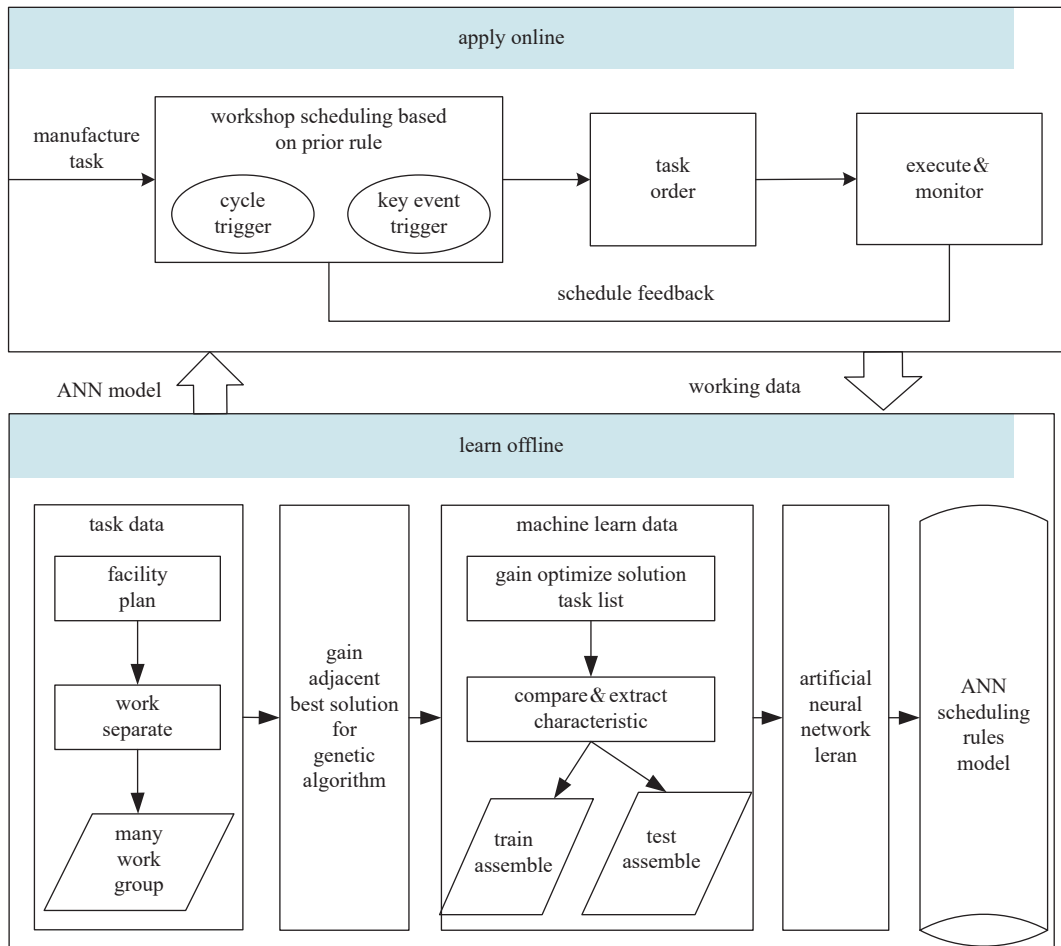


Fig. 2 A problem solving framework based on artificial neural network

图2 基于人工神经网络的问题求解框架

离线学习阶段,首先按照装置结构及工艺数据对装置各束组计划进行分解,生成多组装校任务作为精密装校车间典型测试算例;然后通过遗传算法多次迭代获取算例的近似优化解;再从优化解中获取任务比较轨迹作为机器学习训练与验证数据集;最后采用人工神经网络方法对其进行监督学习,形成基于 ANN 的调度规则模型。

在线应用阶段,采用基于 ANN 调度规则的调度算法。ANN 分派模型只需传入待比较任务相关特征就能返回任务优先关系,从而快速完成柔性装配作业车间的动态调度。调度完成后,控制指令会通过精密装校车间管控平台自动下达执行,并能从物联网自动获取指令执行状态。由于精密装校车间的动态不确定特性,系统支持周期性触发和关键异常事件触发两种重调度形式。在线应用构建了不断更新的“生产状态感知-调度分析决策-调度精准执行”的闭环决策模式,实现面对、复杂约束、多异常事件的生产环境进行快速响应与精准决策。

### 2.2 遗传算法获取优化解

任务数据生成后,选择遗传算法求解近似最优调度方案。一般来说遗传算法通过模仿生物遗传和自然选择机制,利用计算机对生物的进化过程进行仿真模拟,实现全局优化搜索<sup>[10]</sup>。遗传算法的主要步骤为:首先随机产生初始种群,然后评价种群中每个个体的适应度,采用复制、交叉和变异操作产生下一代种群,迭代循环直至满足算法终止条件输出最好的染色体个体,并将这个染色体解码为问题的解。

遗传算法采用排列法进行基因编码,用 1 到  $N$  之间的自然数表示工序任务之间的优先顺序,其中  $N$  为全部工序任务总数。解码时再从染色体的编码中读出工序任务的分派顺序,任务按照该顺序进行逐一分派,从而获取该染色体编码的适应度。在遗传操作上,采用二元锦标赛进行选择,采用部分映射交叉算子进行交叉运算,采用交换节点方法进行变异操作;终止条件采用评估次数超过 50 000 次。

### 2.3 特征建模

结合问题描述与模型,选择了如表 1 所示的 6 项特征作为工序之间的比较项,这六项特征的具体计算方法与文献 [2] 保持一致。

表 1 人工神经网络的输入特征

Table 1 Input characteristics of artificial neural network

No.	characteristics	remark
1	$t(\text{PT})$	processing time of this process
2	$t(\text{ES})$	the earliest start time of this process
3	$l(\text{WIQ})$	machining queue length of work center in this process
4	$l(\text{WINQ})$	machining queue length of work center in next process
5	$t(\text{NPT})$	processing time of next process
6	$t(\text{WKR})$	remaining processing time of optical-mechanical module

ANN 输入是一个六维向量,如下式

$$\mathbf{X} = (f_{\text{PT}}, f_{\text{ES}}, f_{\text{WIQ}}, f_{\text{NPT}}, f_{\text{WINQ}}, f_{\text{WKR}})^T \quad (8)$$

其中

$$f_{\text{PT}}(O_i, O_j) = t(\text{PT}_i) - t(\text{PT}_j) \quad (9)$$

$$f_{\text{ES}}(O_i, O_j) = t(\text{ES}_i) - t(\text{ES}_j) \quad (10)$$

$$f_{\text{WIQ}}(O_i, O_j) = l(\text{WIQ}_i) - l(\text{WIQ}_j) \quad (11)$$

$$f_{\text{NPT}}(O_i, O_j) = t(\text{NPT}_i) - t(\text{NPT}_j) \quad (12)$$

$$f_{\text{WINQ}}(O_i, O_j) = l(\text{WINQ}_i) - l(\text{WINQ}_j) \quad (13)$$

$$f_{\text{WKR}}(O_i, O_j) = t(\text{WKR}_i) - t(\text{WKR}_j) \quad (14)$$

公式(9)~(11)表达了本道工序特征属性差值,(12)~(13)表达了下道工序特征属性差值,公式(14)表示模块整体特征属性差值,从而全面地表达两道工序之间的比较关系。

如图 3 所示为基于人工神经网络的工序优先模型,ANN 作用为一个二元分类器,输出值  $Y$  为 0 或 1。当分类器返回类别为 1 时,任务  $O_i$  优先于任务  $O_j$ ;反之, $O_j$  优先于任务  $O_i$ 。

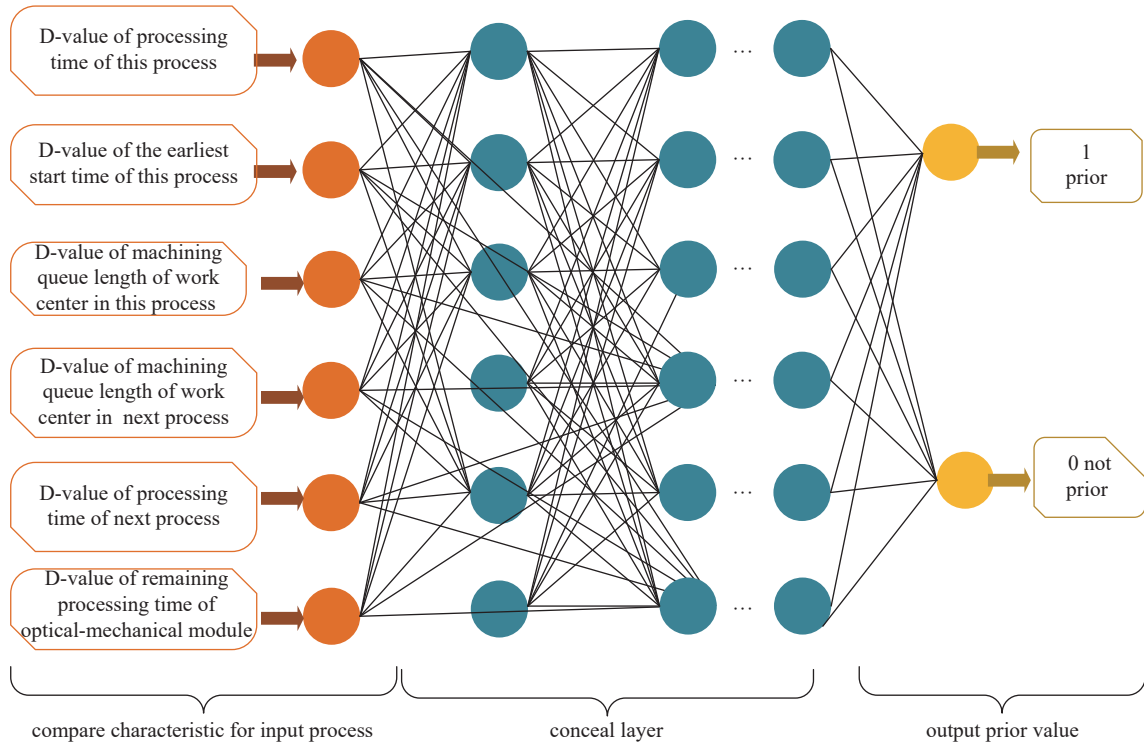


Fig. 3 Process priority model based on artificial neural network

图 3 基于人工神经网络的工序优先模型

## 2.4 任务比较轨迹数据获取

按照遗传算法获取的优化解序列, 从中获取任务比较轨迹数据作为机器学习的训练与测试数据。具体做法如图 4 所示: 依次循环优化解任务队列, 如图中的任务 1, 获取任务 1 分配时工序网络约束中所有入度为 0 的任务, 然后对这些任务产生 (1,8), (1,5), (1,4) 三组任务比较轨迹, 特征值标签为 1; 同时产生 (8,1), (5,1), (4,1) 三组反向比较轨迹, 其特征标签为 0。




Fig. 4 Example of task comparison trajectory

图 4 任务比较轨迹示例

工序比较轨迹获取之后, 需要按照特征建模要求获取 6 项比较特征数据。对这些特征数据进行归一化处理, 从而消除奇异样本数据导致的不良影响。由于特征值正负皆有可能, 因此将上述特征都归一化到  $[-1,1]$ 。

## 2.5 人工神经网络学习

任务比较轨迹数据准备就绪后, 采用开源机器学习框架 Encog 获取二元分类模型。Encog 支持各种学习算法,

提供了丰富的神经网络算法功能,包括各种规范化和数据处理的支持类。神经网络采用全连接方式,输入层为任务间比较向量,中间设置了5个隐藏层。由于需要将输出压缩到[0,1]的区间内,因此采用了 Sigmoid 激活函数。

$$f(x) = \frac{1}{1 + e^{-x}} \quad (15)$$

损失函数采用二元交叉熵函数。该函数能够有效地惩罚模型对错误分类的样本的预测结果,从而提高模型的性能。二元交叉熵函数是一种常用的损失函数(L),适用于二分类问题,计算公式如下

$$L = -\frac{1}{n} \sum_{i=1}^n [y_i \ln P(y_i) + (1 - y_i) \ln(1 - P(y_i))] \quad (16)$$

其中 $y_i$ 是二元标签值0或者1, $P(y_i)$ 是属于 $y_i$ 标签值的概率。

### 2.6 基于优先规则的调度

在线调度采用基于优先规则的调度方法。该方法将待安排工序任务按照优先规则逐一分派到设备上,形成详细的工序作业计划。算法流程如图5所示:

①依据工序任务网络,获取入度为0(前置工序均已调度)的工序任务集合,构建出可安排任务集合。

②按照任务选择规则(Job Select Rule, SR)可安排工序任务进行排序,选出最优先安排工序。本算法支持多种类型的JSR调度有限规则。如果两任务优先程度相同,则进行随机选择。

③选出最优先安排设备来进行安排,采用最早开工规则,即选择可以最早进行装配作业的设备。

④后续工序任务,再进行可安排工序任务集合的更新,依次循环,直至所有任务安排完成。

## 3 数值试验

### 3.1 试验数据

精密装校自动化装配车间主要设备包括提拉涂膜机2台、清洗设备6台、高温烘烤设备3台,机械件自动装配工位2个、光机自动装配工位4个等。典型光机模块工艺及工时如表2所示。

表 2 典型光机模块工艺路线及工时

Table 2 Process route and working hours of typical optical-mechanical modules

process	process name	processing time/min
10	storage inspection of optical elements	120
20	cleaning of optical elements	540
30	optical element coating	162
40	optical element detection	120
50	mechanical frame warehousing inspection	12
60	rough washing of mechanical frame	15
70	fine washing of mechanical frame	30
80	high temperature baking of mechanical frame	67
90	cleanliness detection of mechanical frame	120
100	mechanical assembly	720
110	optical-mechanical assembly and test	360
120	transfer and storage	288

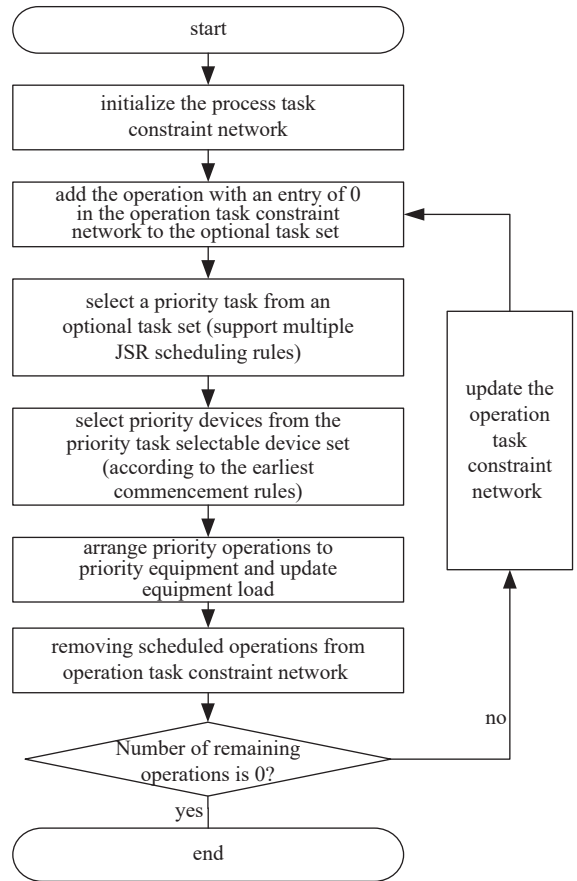


Fig. 5 Production scheduling based on scheduling rules

图 5 基于调度规则的排产

首先按照精密装车间特点产生多组典型测试算例数据, 然后采用遗传算法获取优化解, 再从中获取任务比较轨迹及特征, 形成机器学习原始数据 18 000 条。训练时采用十次十折交叉验证方法, 将原始数据集随机划分为 10 个不重叠的组, 利用其中 9 个组对调度策略进行训练, 将获得的调度规则模型在剩余的 1 组进行测试, 重复这个过程直到集合中每一个组都作为一个测试集使用一次。为了减少不同的样本划分方法而造成的误差, 我们使用不同的划分方法重复 10 次, 产生 100 个训练以及测试结果, 通过分析形成最终的任务比较模型。

### 3.2 算法比较

为验证人工神经网络 ANN 规则的有效性, 选择先进先出调度规则(FIFO)、最短加工时间规则(SPT)、最短剩余加工时间规则(LWKR)、遗传(GA)等算法与之进行相应的对比实验。测试方法是先随机选择一定数量的光机模块精密装校生产任务, 然后采用这些算法进行调度求解。测试服务器配置为“CPU: Intel(R) Core(TM) i7-1165G7 @ 2.80 GHz、内存: 8 G”。

表 3 中列举了 8 个算例, 其中列  $m$  表示光机模块数量, 列  $C$  为调度目标值, 列  $T$  为运行耗时。从中可以看出基于人工神经网络的 ANN 规则在调度效率与调度目标上具备良好的综合性能。与传统启发式规则算法 FIFO、SPT、LWKR 相比, 在所有 8 个算例中, 只有第 1 个算例调度效果略差, 7 个算例上均具有显著优势。而且通过数据对比分析也发现随着光机模块数量增加, ANN 调度算法的优势更加明显。与遗传算法 GA 相比, ANN 规则算法在性能上存在一些差距, 但差距范围均在 10% 之内。但遗传算法计算量庞大, 15 个光机模块调度时长都在 10 min 以上, 无法适应精密装校过程这种高度动态不确定环境。

表 3 五种调度算法运算结果  
Table 3 Operational results of five scheduling algorithms

No.	$m$	$C$					$T/s$				
		FIFO	SPT	LWKR	ANN	GA	FIFO	SPT	LWKR	ANN	GA
1	5	2322	2202	2036	2047	1998	0.19	0.19	0.21	0.63	280
2	5	2434	2193	2276	2149	2047	0.20	0.20	0.23	0.69	295
3	10	3111	3490	3070	2631	2582	0.39	0.41	0.46	0.88	510
4	10	3790	3361	3792	3007	2894	0.41	0.42	0.52	0.87	555
5	15	3931	3987	4478	3635	3428	0.61	0.62	0.77	1.21	613
6	15	4008	3965	3729	3321	3168	0.63	0.63	0.81	1.17	679
7	20	7284	7312	6953	6202	5997	0.91	0.92	1.09	1.53	1011
8	20	7220	7023	6897	6228	6082	0.97	0.95	1.19	1.48	997

## 4 实际应用

基于 ANN 规则的智能调度系统已经集成在中物院某大型激光装置精密装校管控平台中。该系统能够根据现场实时状态自动进行调度, 将派工控制指令通过物联网平台下达给相应的生产设备, 从而实现以智能调度为核心的装校车间自动化串接运行。

在对系统进行仿真运行过程中, 智能调度系统对异常突发事件能够实现秒级响应, 调度结果偏离度也控制在 10% 之内。系统有效解决了传统启发式方法求解质量不理想和不能持续优化等问题, 成为精密装校作业车间高效作业的重要手段。图 6 显示了 ANN 算法的调度结果资源甘特图。

## 5 结论

针对大型激光装置中智能装配调度的动态问题, 建立了考虑光机模块工序串并行关系的柔性装配车间整数规划模型, 提出了一种基于人工神经网络的调度规则获取方法。该方法从遗传算法优化解中抽取任务比较轨迹作为训练数据, 采用人工神经网络学习调度任务优先模型。通过数据实验显示该方法调度结果显著优于传统启发式调度规则, 实际应用中也取得了较好效果。未来进一步研究更多的作业车间场景验证算法的有效性, 考虑装校过程中洁净缓存库容量、检测返工等因素带来的影响, 同时开始研究一种基于多智能代理的装校过程自适应调度方法。

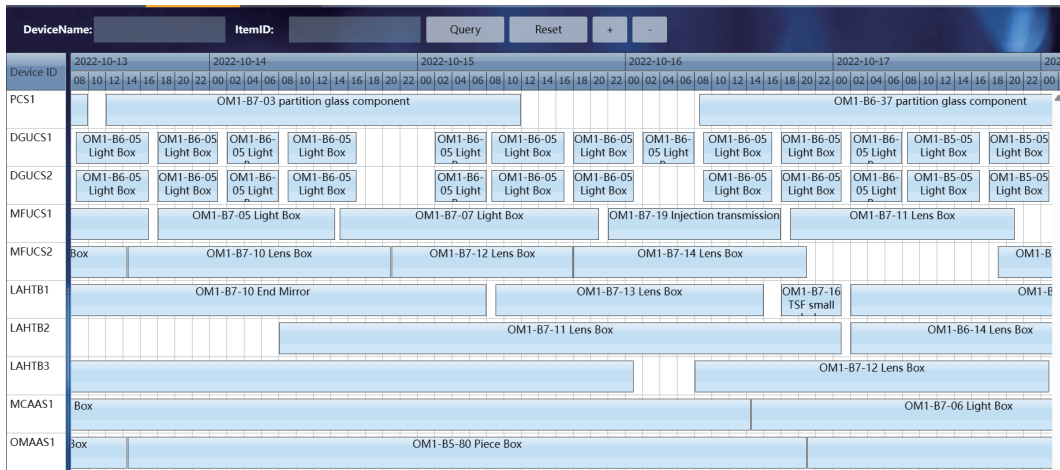


Fig. 6 Gantt chart of intelligent scheduling system for precision assembly and calibration workshop

图 6 精密装校车间智能调度系统甘特图

参考文献:

[1] 郑万国, 邓颖, 周维, 等. 激光聚变研究中心激光技术研究进展[J]. *强激光与粒子束*, 2013, 25(12): 3082-3090. (Zheng Wanguo, Deng Ying, ZhouWei, et al. Development of laser technology in research center of laser fusion[J]. *High Power Laser and Particle Beams*, 2013, 25(12): 3082-3090)

[2] Panwalkar SS, Iskander W. A survey of scheduling rules[J]. *Operations Research*, 1977, 25(1): 45-61.

[3] 张泽群, 唐敦兵, 金永乔, 等. 信息物联驱动下的离散车间自组织生产调度技术[J]. *机械工程学报*, 2018, 54(16): 34-44. (Zhang Zequn, Tang Dunbing, JinYongqiao, et al. Self-organizing production technology for discrete workshop scheduling driven by internet of things[J]. *Journal of Mechanical Engineering*, 2018, 54(16): 34-44)

[4] 龙田, 石宇强, 王俊佳. 柔性作业车间在线调度问题的仿真建模与分析[J]. *机械设计与制造*, 2015(12): 27-30. (Long Tian, Shi Yuqiang, Wang Junjia. Simulation modeling and analysis for online flexible job-shop scheduling problem[J]. *Machinery Design & Manufacture*, 2015(12): 27-30)

[5] Burke E K, Hyde M, Kendall G, et al. A survey of hyper-heuristics[R]. Nottingham: University of Nottingham, 2009.

[6] 范华丽, 熊禾根, 蒋国璋, 等. 动态车间作业调度问题中调度规则算法研究综述[J]. *计算机应用研究*, 2016, 33(3): 648-653. (Fan Huali, Xiong Hegen, Jiang Guozhang, et al. Survey of dispatching rules for dynamic job-shop scheduling problem[J]. *Application Research of Computers*, 2016, 33(3): 648-653)

[7] Mouelhi-Chibani W, Pierrel H. Training a neural network to select dispatching rules in real time[J]. *Computers & Industrial Engineering*, 2010, 58(2): 249-256.

[8] Golmohammadi D. A neural network decision-making model for job-shop scheduling[J]. *International Journal of Production Research*, 2013, 51(17): 5142-5157.

[9] Zhang Liping, Hu Yifan, Wang Chuangjian, et al. Effective dispatching rules mining based on near-optimal schedules in intelligent job shop environment[J]. *Journal of Manufacturing Systems*, 2022, 63: 424-438.

[10] Holland JH. Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence[M]. Cambridge: The MIT Press, 1992.