




中国科技期刊卓越行动计划项目入选期刊

# 控制与决策

CONTROL AND DECISION



## 不确定环境下的航空发动机装配线适应性调度方法

王怡琳, 刘鹏, 乔非, 张家谔

引用本文:

王怡琳, 刘鹏, 乔非, 张家谔. 不确定环境下的航空发动机装配线适应性调度方法[J]. *控制与决策*, 2024, 39(5): 1629–1635.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0989>

### 您可能感兴趣的其他文章

#### Articles you may be interested in

#### 面向人景物三元数据的热轧调度问题研究

Research on hot rolling scheduling problem oriented to human–cyber–physical data

*控制与决策*. 2021, 36(11): 2825–2831 <https://doi.org/10.13195/j.kzyjc.2020.0551>

#### 基于深度强化学习与迭代贪婪的流水车间调度优化

Scheduling optimization for flow–shop based on deep reinforcement learning and iterative greedy method

*控制与决策*. 2021, 36(11): 2609–2617 <https://doi.org/10.13195/j.kzyjc.2020.0608>

#### 基于双种群模糊引力搜索算法的舰载机甲板作业调度

Flight deck operations scheduling based on dual population fuzzy gravitational search algorithm

*控制与决策*. 2021, 36(11): 2751–2759 <https://doi.org/10.13195/j.kzyjc.2020.0523>

#### 离散蝙蝠算法在三阶段装配流水线调度问题的应用

Discrete bat algorithm in three–stage assembly flowshop scheduling problem

*控制与决策*. 2021, 36(9): 2267–2278 <https://doi.org/10.13195/j.kzyjc.2020.0054>

#### 基于负荷平衡的柔性预约决策

Flexible outpatient appointment decision model with loading balance

*控制与决策*. 2021, 36(1): 226–233 <https://doi.org/10.13195/j.kzyjc.2019.1690>

# 不确定环境下的航空发动机装配线适应性调度方法

王怡琳<sup>1</sup>, 刘 鹏<sup>1</sup>, 乔 非<sup>1†</sup>, 张家谔<sup>2</sup>

(1. 同济大学 电子与信息工程学院, 上海 201800; 2. 中国航空制造技术研究院, 北京 100020)

**摘要:** 航空发动机装配是航空发动机制造过程的关键环节,其工序多,流程复杂,生产过程中扰动频发,如装配时间波动、不合格返工等. 针对不确定环境下的航空发动机装配线的调度问题,提出一种基于门控循环神经网络(GRU)的适应性调度方法. 该调度方法包含扰动识别和调度规则调整两个部分:扰动识别模块以滑动时间窗口为周期,利用GRU神经网络进行渐进型扰动的识别;调度规则调整模块以扰动识别的结果为触发,通过构建基于GRU神经网络的调度规则决策模型,输出适配当前生产状态的新的调度规则,用以指导生成更新的调度方案. 最后,以某航空发动机装配线为研究案例,对所提出适应性调度方法进行验证分析. 对比实验结果表明,所提出方法能够有效提升装配线的设备利用率、日均生产率等性能.

**关键词:** 适应性调度; 扰动识别; 深度学习; 门控循环神经网络; 航空发动机装配; 调度规则

中图分类号: TP391.9

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.0989

引用格式: 王怡琳,刘鹏,乔非,等. 不确定环境下的航空发动机装配线适应性调度方法[J]. 控制与决策, 2024, 39(5): 1629-1635.

## Adaptive scheduling method of aero-engine assembly line in uncertain environment

WANG Yi-lin<sup>1</sup>, LIU Juan<sup>1</sup>, QIAO Fei<sup>1†</sup>, ZHANG Jia-e<sup>2</sup>

(1. College of Information Science and Engineering, Tongji University, Shanghai 201800, China; 2. AVIC Manufacturing Technology Institute, Beijing 100020, China)

**Abstract:** Aero-engine assembly is the key part of the manufacturing process of aero-engine which are composed of many complex productions. And disturbances appear frequently in the manufacturing process, such as assembly time fluctuation, unqualified rework, etc. Aiming at the scheduling problem of the aero-engine assembly line under uncertain environment, the adaptive scheduling method based on a gate recurrent unit (GRU) neural network is studied. The scheduling method includes two core modules: Disturbance identification and scheduling scheme adjustment. In the disturbance recognition module, a GRU neural network is built to identify progressive disturbances in rolling time windows. Once disturbances are recognized, the scheduling adjustment module will be driven, and the best scheduling rules on current scenarios based on the GRU neural network are output, which are used to update scheduling scheme. Finally, a case study is carried out for an aero-engine assembly line. The comparative experiments show that the proposed method can effectively improve the equipment utilization rate and daily productivity of the assembly line.

**Keywords:** adaptive scheduling; disturbance recognition; deep learning; gate recurrent unit; aero-engine assembly line; dispatching rules

## 0 引言

航空发动机是一种可在极端环境下长期稳定工作的热力机械,是飞机的核心器件<sup>[1]</sup>. 航空发动机的研制一直是我国航空装备制造重点部署的项目,其中航空发动机的整机装配环节涉及的装配技术困难,物料供应关系繁多,环境因素多变. 近年来,如何进一步

提高装配质量和效率,优化装配过程中的资源分配和调度方案,成为航空发动机生产中重要的研究课题.

现阶段,航空发动机装配以手工为主,常因辅具短缺、垫片尺寸不合格等问题,引发装配时间波动,且在发动机装配过程中还可能出现2次试车不合格造成的返工. 这些不确定因素会造成生产任务无法按

收稿日期: 2022-06-06; 录用日期: 2023-02-25.

基金项目: 国家自然科学基金重点项目(62133011); 国家自然科学基金面上项目(61973237, 61873191).

责任编辑: 王凌.

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

期完成,对生产调度排程造成了较大的困难。

随着传感技术、大数据技术的发展,大量的生产状态数据可被及时地获取,驱动智能调度系统根据生产状态的变化及时调整调度策略,保证生产的平稳性。这样根据生产状态实时改变调度策略、降低不确定事件对系统性能影响的调度方式即为适应性调度。如杨能俊等<sup>[2]</sup>在生产过程中采集制造车间的信息,通过Q-learning算法实时改变调度策略,解决了动态扰动频发的车间调度问题;龙建宇<sup>[3]</sup>为了保证钢铁连铸生产过程的稳定性和连续性,在扰动出现的时刻,基于变邻域搜索算法修改了失效的调度策略。

当前关于航空发动机装配领域的适应性调度研究较少。冯亚芳<sup>[4]</sup>研究了设备故障、工人短缺等突发情况下的装配线调度,利用改进的遗传算法进行再调度;Zhu等<sup>[5]</sup>针对原料随机到达的扰动,利用邻域搜索算法对调度成本进行了优化;万晓琴等<sup>[6]</sup>针对发动机试车不合格返工问题进行了研究,采用禁忌搜索算法改变装配组配置和并行设备的选择,实现了最小化产品完工成本和班组重构成本。

上述调度方法考虑了航空发动机装配过程中部分常见扰动,如设备故障、原料随机到达等。这些扰动的发生均有明显的标志,易于识别,属于突发型的扰动。而在实际的装配过程中,常会出现一些渐近型扰动,如手工作业中常见的因加工技术引发的加工时间波动、物料到达时间延迟等。这些渐近型扰动不会立即对装配线造成影响,但是当扰动逐渐累积,会对装配线的性能造成严重的干扰,使得原有的调度方案失效。渐近型扰动研究的难点在于如何准确地判定扰动使得原有调度方案失效的时间点。而目前关于界定渐近扰动的发生没有一致的标准,无法判别调整原调度方案的时间点,故研究一种针对渐近型扰动的识别机制是极为重要的。

在调度方案调整方面,现有文献普遍采用智能搜索算法<sup>[7-8]</sup>,迭代计算时对硬件算力的需求高,且实时性不强。近年来,机器学习算法的出现为解决调度优化提供了新的思路。机器学习算法可与调度规则相结合,从优化的调度样本中学习调度知识,通过选择在不同生产场景下的最优调度规则实现调度方案的调整。在机器学习的算法中,深度学习在决策优化领域的应用较为广泛。如Azadeh等<sup>[9]</sup>使用了仿真数据集训练人工神经网络,进一步在候选调度规则中进行搜索,寻找使当前车间性能最优的调度规则;吴秀丽等<sup>[10]</sup>构建了BP神经网络用于混合流水车间生产线的实时调度;Ahn等<sup>[11]</sup>将k-means算法与人工神经网络

相结合解决批调度问题;Sim等<sup>[12]</sup>将神经网络与启发式算法相结合用于解决车间作业调度问题。这些方法基于分类的思想,通过神经网络建立了生产状态与调度规则的映射。但是,存在实时性不高、问题规模较小等问题,也没有针对动态调度中的扰动进行处理。

为了增强对生产状态的识别能力和实时监测能力,本文引入一种具有预测能力的门控循环神经网络(gate recurrent unit, GRU)进行扰动的识别和应对,该方法能够很好地预测扰动对系统的影响,并充分挖掘调度样本中的信息,建立生产状态与最优调度策略间的联系。

## 1 航空发动机装配线调度问题描述

### 1.1 航空发动机装配线对象介绍

航空发动机装配涉及的工艺流程复杂,需要重复地装配和拆卸,常分为若干个站位,每个站位有不同的工序,涉及部件装配、假装配、冷端装配、热端装配、附件传动和输出轴装配、管路装配、视觉检测、整机检验、试车以及总装分解等。1次总装结束后,进行试车和总装分解,进入2次拆装;2次部装、总装结束后再次进入检验试车。若检验合格,则结束;若检验不合格,则拆卸进入3次装配直至检验试车合格。流程如图1所示。

### 1.2 航空发动机装配线调度问题建模

为了便于研究,设置该案例的假设条件如下。

- 1) 每道工序装配具有连续性,不可被打断;
- 2) 总装配时长固定;
- 3) 所有站位遵循同样的调度规则;
- 4) 默认进行2次拆装,若2次试车不合格,则进行3次拆装,3次拆装视为扰动;
- 5) 默认装配过程中物料供应充足。

符号定义如下。

$i$ : 发动机的序号,表示投产的顺序, $i = 1, 2, \dots, I$ ,  $I$ 为完成加工的发动机总数。

$k$ : 装配阶段,正常情况下 $k = 1, 2$ ;若2次试车失败,则 $k = 1, 2, 3$ 。

$m$ : 第 $m$ 台设备,共有 $M$ 台设备。

$o_{ijk}$ : 第 $i$ 台发动机第 $k$ 装配阶段编号 $j$ 的工序。

$T$ : 总装配时长,订单下达时给定。

$J_{ik}$ : 发动机 $i$ 的第 $k$ 装配阶段的工序集合。

$e_{ijk0}$ : 工序的理论装配时间。

$e_{ijk}$ : 工序的实际装配时间。

$\Delta e_{ijk}$ : 装配时间的波动。

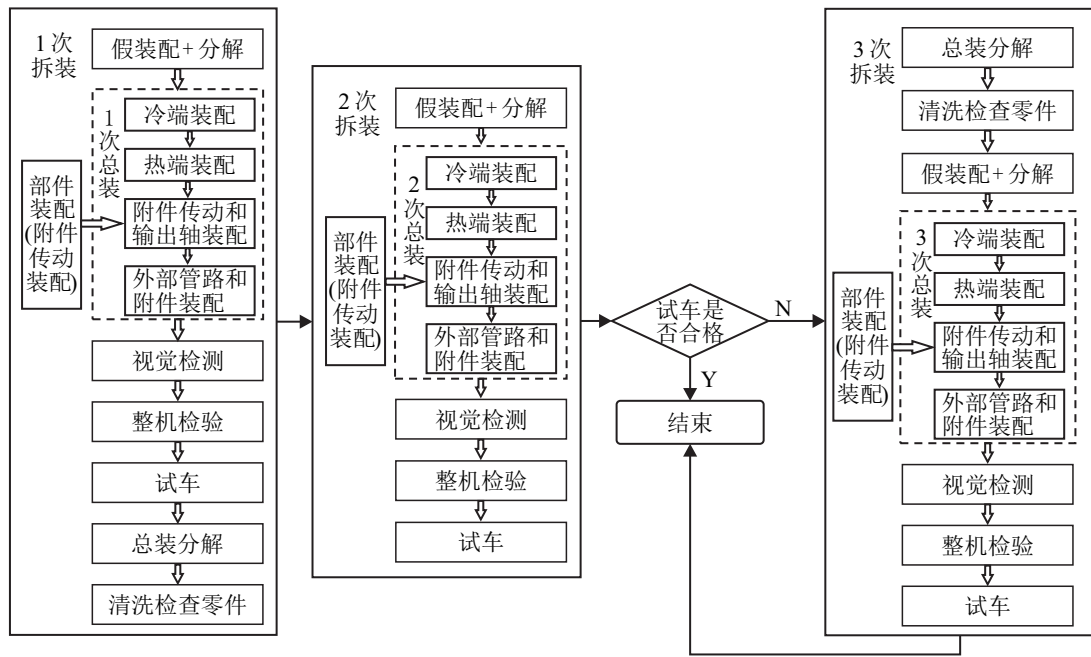


图1 航空发动机流程工艺

$o_{P(ijk)}$ :  $o_{ijk}$  的父工序.

$s_{ijk}$ : 工序  $o_{ijk}$  开始时间.

$c_{ijk}$ : 工序  $o_{ijk}$  结束时间.

$r$ : 调度决策.

$X_{ijk'jk'm}$ : 两道工序  $o_{ijk}$  与  $o_{i'jk'}$  在同一设备上装配的顺序关系, 当  $o_{ijk}$  和  $o_{i'jk'}$  均在设备  $m$  上装配时,  $o_{ijk}$  在  $o_{i'jk'}$  前加工时其值为1; 否则, 为0.

$A$ : 一个足够大的正数.

基于以上假设, 对航空发动机装配问题建模如下:

$$\max z = \max \left( \omega_1 \frac{I(\mathbf{r})}{T} + \omega_2 \frac{\sum_{i=1}^I \sum_{k=1}^K e_{ijk}(\mathbf{r})}{T} \right). \quad (1)$$

$$\text{s.t. } \mathbf{r} = [r_{t_1}, r_{t_2}, \dots, r_{t_n}], \quad 0 \leq t_1, t_2, \dots, t_n \leq T; \quad (2)$$

$$c_{ijk}(\mathbf{r}) - s_{ijk}(\mathbf{r}) = e_{ijk}(\mathbf{r}); \quad (3)$$

$$c_{P(ijk)}(\mathbf{r}) - s_{ijk}(\mathbf{r}) \geq 0, \quad i \in I, j \in J_{ik}; \quad (4)$$

$$e_{ijk}(\mathbf{r}) = e_{ijk0} + \Delta e_{ijk}; \quad (5)$$

$$s_{ij2}(\mathbf{r}) \geq c_{ij1}(\mathbf{r}) + \sum_{j=1}^{J_{i1}} e_{ij1}(\mathbf{r}); \quad (6)$$

$$c_{i'jk'}(\mathbf{r}) - c_{ijk}(\mathbf{r}) + A(1 - X_{ijk'jk'm}) \geq e_{ijk}; \quad (7)$$

$$c_{ijk}(\mathbf{r}) - c_{i'jk'}(\mathbf{r}) + AX_{ijk'jk'm} \geq e_{ijk}; \quad (8)$$

$$X_{ijk'jk'm} = 0, 1. \quad (9)$$

其中: 式(1)表示优化目标为最大化平均生产率  $P =$

$\frac{I}{T}$  以及设备平均利用率  $U = \frac{\sum_{i=1}^I \sum_{k=1}^K e_{ijk}}{T}$ ,  $P$  和  $U$  均为归一化后的值,  $\omega_1$  和  $\omega_2$  分别为两个指标的权值; 式(2)定义了决策变量  $\mathbf{r}$ , 表示所有决策时刻调度规则权重的集合,  $r_{t_x}$  为决策时刻  $t_x$  的调度规则权重; 式(3)保证装配不中断; 式(4)表示每道工序的最早开始时间不能早于其父工序结束的时间; 式(5)规定了发动机每道工序的实际装配时间; 式(6)规定了2次装配需在完成1次装配、检验和拆装等步骤后才能进行; 式(7)和(8)规定了同一个设备同一时刻只能装配1台发动机; 式(9)为变量  $X_{ijk'jk'm}$  的取值范围.

## 2 基于GRU的适应性调度方法

### 2.1 方法框架

本文基于门控循环神经网络 (gate recurrent unit, GRU) 的适应性调度方法主要由离线训练和在线调度两个阶段构成, 并在整个装配周期内将问题分解为多个窗口内的静态调度问题进行求解, 每个窗口内均进行扰动识别和调度方案的调整. 总体方法框架如图2所示.

在离线训练阶段, 从有扰动下的仿真数据集中获取生产状态  $[s_{t_1}, s_{t_2}, \dots, s_{t_n}]$ 、调度规则权重  $[r_{t_1}, r_{t_2}, \dots, r_{t_n}]$  以及性能数据  $[Z_{t_1}, Z_{t_2}, \dots, Z_{t_n}]$ , 进行数据预处理后, 划分滑动窗口; 输入至GRU神经网络进行训练, 得到扰动识别网络和调度方案调整网络, 前者用于预测滑动窗口末端的性能  $Z_{t_i+m}$ , 后者用于预测滑动窗口末端最优的调度规则权重  $r_{t_i+m}$ .

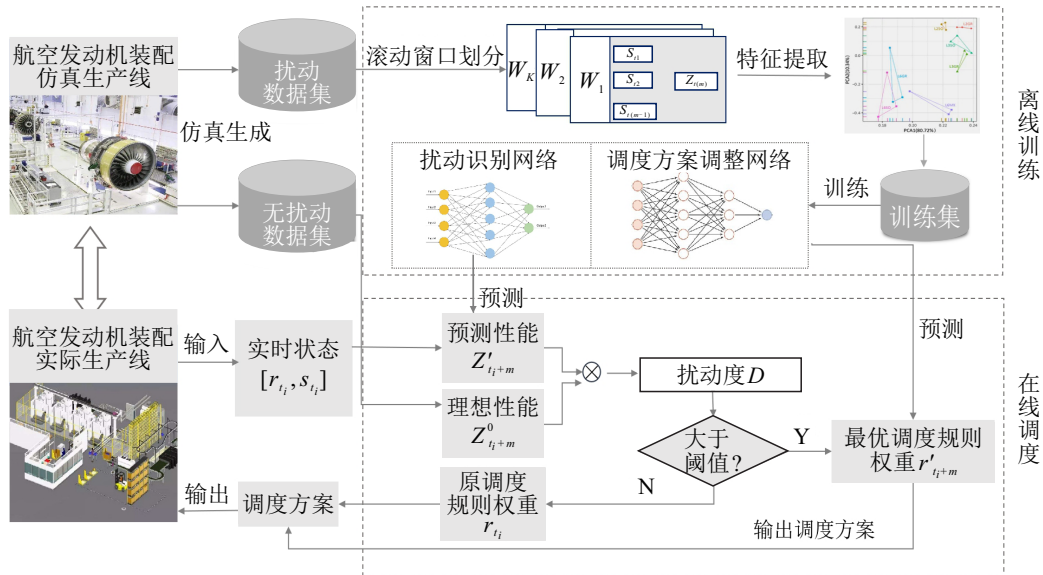


图2 基于GRU的适应性调度方法框架

在在线调度阶段,将装配线的实时数据输入扰动识别网络中,利用预测的性能结果  $Z'_{t+m}$  与无扰动下的平均性能  $Z^0_{t+m}$  的偏差计算扰动度,若大于设定的阈值,则判定为需要进行调度方案调整,此时,再将生产状态数据输入至调度方案调整网络,预测最优的调度规则权重,并反馈至实时装配线。

## 2.2 扰动识别方法

为了精确地识别扰动,首先应构建扰动度来评价当前扰动对装配线的影响程度。定义有扰动下的性能与无扰动下平均性能的偏差绝对值为扰动度  $D$ 。选取最大完工周期(MCT)以及累积移动步数(MOV)作为构成  $D$  的变量。最大完工周期反映了装配线的生产效率,是重要的生产性能指标,而累积移动步数的偏差反映了装配线的累积误差,故选取这两个指标作为渐近型扰动识别的依据。

在实际的装配过程中,实时跟踪生产状态数据是比较困难的,需要大量精密的感知仪器,且在装配过程中得到的生产性能数据往往有滞后性。为了增强扰动识别的实时性,采用一种带有预测性质的识别方法,即以生产性能预测值来代替实时的生产性能值,利用此预测值与无扰动下平均性能的偏差计算扰动度。本文采用GRU神经网络<sup>[13]</sup>对MCT和MOV进行预测。

GRU网络是LSTM神经网络的变体,LSTM神经网络是一类具有时序预测性质的神经网络<sup>[14]</sup>,适于生产状态和生产性能这样具有时序性数据的预测。在实际的研究中,常采用GRU神经网络进行预测,它的网络参数易于调整,网络结构相较于LSTM较为简单。

首先,利用扰动数据集对GRU网络进行训练,并将训练的网络模型保存至模型库中;在实时装配时,在每个时间窗  $i$  内,向已训练的网络中输入实时调度规则  $r_{t_i}$  和生产状态  $s_{t_i}$ ,输出预测性能  $M'_{t_{i+m}}$ 、 $C'_{t_{i+m}}$ 。通过计算与无扰动的平均性能  $M^0_{t_{i+m}}$ 、 $C^0_{t_{i+m}}$  的差值  $\Delta M$  和  $\Delta C$ ,并对其进行归一化得到  $\bar{M}$  和  $\bar{C}$ ,进而计算扰动度  $D = \alpha \bar{M} + \beta \bar{C}$ ,并将  $D$  与提前设定的阈值  $D'$  比较,若大于  $D'$ ,则输出调度方案调整信号。

## 2.3 调度方案调整方法

生产调度问题经常为“NP难”问题,即使是小规模的调度问题也难以通过经典的最优化算法得到最优解,因此在当今的实际生产中,调度领域较为常用的调度方法是更简单有效的调度规则。单一确定的调度规则难以获得全局最优解,因此,根据不同生产状态选取最优的调度规则或其组合成为解决“NP难”问题的思路之一<sup>[15]</sup>。

同样利用生产样本的时序性,通过对GRU网络进行改进,即可预测出不同生产状态下最优的调度规则组合。此处对GRU网络的改进是在隐层增加Dense层,并在最后的输出层增加softmax层,这样就提高了特征空间的转换能力,将对生产性能的预测转换为对最优调度规则的预测。

在离线训练阶段,从扰动数据集中选取每个滑动时间窗末端生产性能较优的数据作为训练集训练神经网络。当识别到扰动时,将实时的生产状态  $s_{t_i}$  输入至模型库,应用训练好的调度模型预测时刻  $t_{i+m}$  的最优调度规则权重  $r'_{t_{i+m}}$ ,由此建立动态环境下的生产状态到最优调度规则权重的映射。将此最优调度规则权重输入至实际装配线中完成调度方案的调整。

### 3 案例研究

本文以某航空发动机制造厂的航空发动机装配线为研究对象,为了验证所提出基于GRU的适应性调度方法的有效性,首先说明适应性调度方法的实现过程,验证该方法的可行性;随后与常规的智能搜索调度规则方法进行对比实验,表明所提出方法的优越性.建模优化算法采用Python编写,在Windows 10 64位环境下运行,计算机内存8 GB,处理器 Intel (R) Core (TM) i5-8265.

#### 3.1 实验条件展示

生产参数设置如下:总生产周期为80天,结合1台发动机生产的平均时长,设置预热时间为10天,此后每10天预测一次是否进行调度方案调整,直至第70天;采用3种调度规则(EDD(工单的交货期越早越优先)、SRPT(工序的正交货期越早越优先)、CR(工单临界比越小越优先))及其组合式调度规则作为调度规则调整的规则库;实验初始的调度规则权重采用历史数据中较优的规则权重进行调度.初始状态下该组合中3种规则的权重为[0.7, 0.2, 0.1].

扰动设置如下:每台发动机约有1%的概率会发生3次试车;在第1~6、12~17道装配工序中,约有10%的概率会发生因装配技术引起的工序时间延长,一般造成工序时间延长1~2小时;本实验中设为相应工序中有10%的概率会发生加工时间的延长,延长时间在[40, 80]间均匀分布(单位: min).

#### 3.2 适应性调度方法实现

##### 3.2.1 数据处理

分别在有扰动和无扰动环境下产生仿真数据用于后续实验,包括生产状态数据和生产性能数据.

对数据进行最大最小归一化处理,并通过主成分分析(principal component analysis, PCA)保留前10个主成分.

##### 3.2.2 扰动识别网络训练

建立扰动识别网络,输入为当前的调度规则、各产品在制品数、各站位排队数、加工时间波动等.根据输入数据的维数设置各层网络结构,结构如表1所示;损失函数采用均方误差(mean-square error, MSE);采用网格搜索确定训练轮次和批次大小.经过参数调整,扰动识别网络最终在测试集上的误差为 $7e-4$ .

表1 扰动识别神经网络参数

	神经网络结构	神经元个数	是否输出到下一级	激活函数
输入层	GRU	64	是	ReLU
隐藏层	GRU	32	是	linear
输出层	Dense	2	否	-

##### 3.2.3 调度方案调整网络训练

建立调度方案调整网络,输入为当前的调度规则、各产品在制品数、各站位排队数等,输出10天后最优规则的预测值.同样采用网格搜索确定各网络的参数,最终确定神经网络的结构参数如表2所示.调度方案调整网络的训练最终误差为 $3.1e-4$ .

表2 调度方案调整网络参数

	神经网络结构	神经元个数	是否输出到下一级	激活函数
输入层	GRU	64	是	ReLU
隐藏层	GRU	32	是	linear
隐藏层	Dense	16	是	sigmoid
输出层	Dense	3	否	softmax

##### 3.2.4 在线调度

设置扰动度为 $D = 0.8\bar{M} + 0.2\bar{C}$ ,设定扰动度大于1时进行调度规则调整.图3为扰动度随生产时间的变化.由图3可见,通过对偏差的预测,判定第30天为调度方案开始调整的时间,调度规则的权重改变,并在之后的调整时间点上均进行改变.




图3 扰动度随生产日期的变化

分别比较无扰动下采用组合式规则调度、有扰动下采用GRU适应性调度方法、有扰动下不进行重调度得到的综合性能,设置综合性能 $Y = 0.8\bar{P} + 0.2\bar{U}$ ,绘制综合性能随日期变化图像如图4所示.图4显示出在有扰动的情况下,装配线生产性能出现劣化,无论是否采用调度方法,表现出的综合性能均比无扰动时低,而采用GRU适应性调度方法,在调度方案调整后,装配线性能有所回升,最终的综合性能比不进行调度方案调整的综合性能高,更接近于无扰动的情况.




图4 综合性能变化

3.3 综合实验验证和分析

为了验证所提出适应性调度方法的有效性,将所提出方法与采用遗传算法(genetic algorithm, GA)搜

索组合式调度规则的方法做20次对比实验,并将增加2个扰动程度5%和15%,最终结果如表3和图5~图7所示。

表3 不同扰动程度下各调度方法的对比

性能	日均生产率均值(个/天)			设备利用率均值			综合性能指标均值			用时/s
	5%	10%	15%	5%	10%	15%	5%	10%	15%	
GRU	0.9275	0.905	0.8363	0.599	0.5968	0.5914	0.829	0.8143	0.7628	6.85
GA	0.9025	0.8825	0.8306	0.584	0.5892	0.5824	0.8209	0.7945	0.7562	22.85
无调度	0.8491	0.8075	0.78	0.5542	0.56	0.5626	0.7606	0.7332	0.7148	-




图5 日均生产率对比




图6 设备平均利用率对比




图7 综合性能对比

在日均生产率这一项中:在5%和10%两种扰动程度下采用GRU方法得到的均值为0.9275、0.9050(个/天),比GA方法得到的日均生产率高;在15%扰动程度下,所提出方法与GA方法得到的结果值相似,但是,由图5可见,GRU方法的结果较GA方法变化范围较为集中。

在设备利用率这一项中,不同扰动程度下采用GRU方法得到的值分别为0.5990、0.5968、0.5914,

均比GA方法得到的结果高,且分布较为集中。

在综合性能指标这一项中:在10%和15%扰动程度下采用GRU方法得到的结果为0.8143、0.7628,比GA方法得到的结果高;在5%扰动下得到的结果为0.8290,与GA的结果较为接近。由图6可见,GRU方法得到的综合性能值分布均较为集中,调度结果较为稳定。

由表3可见,在相同的扰动程度下,在生产率、设备利用率、综合性能指标这3项上,均是所提出GRU调度方法得到的性能较好,数据较为集中,采用GA方法进行调度方案调整虽然也取得了一定的效果,但是变化范围大,不够稳定;同时,随着扰动程度的加大,不同的调度方法得到的性能均有所劣化。此外,统计两种调度方法的算法效率,GA平均用时为22.83s,所提出GRU平均用时为6.85s,这是由于GA搜索调度规则是基于仿真进行的,耗时较长。

以上实验结果表明,所提出方法在综合性能优化和计算效率方面均有超越一般智能搜索方法的表现。

4 结论

本文针对不确定环境下的航空发动机装配线调度问题,提出了基于GRU的适应性调度方法。该方法利用有扰动和无扰动下的装配线仿真数据样本,分别训练扰动识别网络和调度方案调整网络,实现了生产过程中的扰动在线识别以及调度方案的适应性调整。实验结果表明,所提出方法能够准确地实现对航空发动机生产线未来性能的预测,捕捉装配线出现的渐近扰动,减少了渐近型扰动对生产性能带来的影响,提升了制造系统对不确定环境的及时响应和应对能力。本文关于渐近型扰动的研究中仅考虑由装配技术引起的工序时间延长这一类型扰动,然而,在实际装配过程中,会同时发生多种扰动事件,如物料延迟到达、设备故障、人员操作失误等,每种扰动对装配线的影响机理和效果均不同,综合分析多种扰动与生产性能间的耦合关联关系,研究考虑多种扰动的适应

性调度方法,对于实际装配线具有更重要的现实指导意义,也是未来工作的重点研究方向。

### 参考文献(References)

- [1] 黄江, 杨海, 史小强, 等. 面向智能制造的航空发动机数字化总装生产线建设研究[J]. 航空制造技术, 2020, 63(6): 34-42.  
(Huang J, Yang H, Shi X Q, et al. Research on the construction of aero-engine digital assembly line oriented to intelligent manufacturing[J]. Aeronautical Manufacturing Technology, 2020, 63(6): 34-42.)
- [2] 杨能俊, 郭宇, 方伟光, 等. 实时数据驱动的离散制造车间自适应调度方法[J]. 组合机床与自动化加工技术, 2020(9): 175-179.  
(Yang N J, Guo Y, Fang W G, et al. Real-time data driven adaptive scheduling method of discrete manufacturing workshops[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2020(9): 175-179.)
- [3] 龙建宇. 炼钢厂生产实时调度建模及优化算法研究[D]. 重庆: 重庆大学, 2017: 22-23.  
(Long J Y. Study on modeling and optimization algorithm of production realtime scheduling in steel plants[D]. Chongqing: Chongqing University, 2017: 22-23.)
- [4] 冯亚芳. 双资源约束的航空发动机作业车间调度研究[D]. 重庆: 重庆大学, 2019.  
(Feng Y F. Research on aero engine job shop scheduling with dual resource constraints[D]. Chongqing: Chongqing University, 2019.)
- [5] Zhu H W, Lu Z Q, Lu C Y, et al. A reactive scheduling method for disturbances in aircraft moving assembly line[J]. International Journal of Production Research, 2021, 59(15): 4756-4772.
- [6] 万晓琴, 严洪森. 面向航空发动机装配线的知识化制造系统重调度和自重构[J]. 控制理论与应用, 2017, 34(7): 903-911.  
(Wan X Q, Yan H S. Rescheduling and self-reconfiguration of knowledgeable manufacturing system oriented to aircraft engine assembly line[J]. Control Theory & Applications, 2017, 34(7): 903-911.)
- [7] 燕洁晨, 陈红雨, 张文新, 等. 加工时间不确定的炼钢-连铸鲁棒优化调度方法[J]. 控制与决策, 2023, 38(6): 1661-1669.  
(Yan J C, Chen H Y, Zhang W X, et al. Robust optimization method for steelmaking-continuous casting scheduling with uncertain processing times[J]. Control and Decision, 2023, 38(6): 1661-1669.)
- [8] 李佳磊, 顾幸生. 双种群混合遗传算法求解具有预防性维护的分布式柔性作业车间调度问题[J]. 控制与决策, 2023, 38(2): 475-482.  
(Li J L, Gu X S. Two-population hybrid genetic algorithm for distributed flexible job-shop scheduling problem with preventive maintenance[J]. Control and Decision, 2023, 38(2): 475-482.)
- [9] Azadeh A, Negahban A, Moghaddam M. A hybrid computer simulation-artificial neural network algorithm for optimisation of dispatching rule selection in stochastic job shop scheduling problems[J]. International Journal of Production Research, 2012, 50(2): 551-566.
- [10] 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.  
(Wu X L, Sun L. Data-based real-time scheduling in smart manufacturing[J]. Control and Decision, 2020, 35(3): 523-535.)
- [11] Ahn G, Hur S. Clustering and dispatching rule selection framework for batch scheduling[J]. Mathematics, 2020, 8(1): 80.
- [12] Sim M H, Low M Y H, Chong C S, et al. Job shop scheduling problem neural network solver with dispatching rules[C]. IEEE International Conference on Industrial Engineering and Engineering Management. Singapore, 2021: 514-518.
- [13] Cho K, van Merriënboer B, Bahdanau D, et al. On the properties of neural machine translation: encoder-decoder approaches[J/OL]. 2014, arXiv: 1409.1259v2.
- [14] Graves A. Long short-term memory[M]. Berlin: Springer, 2012: 1735-1780.
- [15] Shaw M J, Park S, Raman N. Intelligent scheduling with machine learning capabilities: The induction of scheduling knowledge[J]. IIE Transactions, 1992, 24(2): 156-168.

### 作者简介

王怡琳(1999-), 女, 硕士生, 从事数据驱动的生产调度的研究, E-mail: 1419335416@qq.com;

刘鹏(1992-), 女, 博士后, 从事复杂制造系统生产调度和智能调度算法等研究, E-mail: juanliu0720@tongji.edu.cn;

乔非(1967-), 女, 教授, 博士, 从事复杂制造系统计划调度和能源管理等研究, E-mail: fqiao@tongji.edu.cn;

张家谔(1987-), 男, 高级工程师, 博士, 从事航空数字化制造技术和智能优化计算等研究, E-mail: zhangjia@hotmail.com.