

3-22-2022

Job Shop Rescheduling Under Recessive Disturbance Based on Digital Twin

Dinghui Wu

1. Key Laboratory of Advanced Process Control for Light Industry, Jiangnan University, Wuxi 214122, China; wh033098@163.com

Tongrui Zhang

1. Key Laboratory of Advanced Process Control for Light Industry, Jiangnan University, Wuxi 214122, China; ztrdaydayup@foxmail.com

Xiuli Zhang

2. Wuxi Institute of Technology, Wuxi 214122, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Job Shop Rescheduling Under Recessive Disturbance Based on Digital Twin

Abstract

Abstract: A new shop rescheduling model driven by digital twin is proposed to solve the problems of disturbance cumulative rescheduling. *A scheduling parameter updating method is proposed and a random probability distribution is used to describe the distribution of scheduling parameters to improve the accuracy of scheduling parameters. An implicit disturbance detection model is built based on Siamese Network using real-time data as input to realize the start time of rescheduling. The sample data for scheduling knowledge mining are extracted from the historical scheduling scenarios. Through the Pseudo-Siamese CNN, the mapping relationship between the Process state and machine state is obtained, which is applied to production online rescheduling.* Simulation experiments show the feasibility of the proposed digital twin driven shop rescheduling model.

Keywords

recessive disturbance, digital twin, siamese network, dispatching rule mining

Recommended Citation

Dinghui Wu, Tongrui Zhang, Xiuli Zhang. Job Shop Rescheduling Under Recessive Disturbance Based on Digital Twin[J]. Journal of System Simulation, 2022, 34(3): 573-583.

扰动累积下基于数字孪生的车间重调度

吴定会¹, 张桐瑞^{1*}, 张秀丽²

(1. 江南大学 轻工过程先进控制教育部重点实验室, 江苏 无锡 214122; 2. 无锡职业技术学院, 江苏 无锡 214122)

摘要: 针对隐性扰动累积下车间重调度问题, 搭建车间重调度决策服务, 实现数字孪生驱动的扰动累积下的车间重调度。提出一种调度参数更新的方式, 采用随机概率分布来描述调度参数的分布, 提升调度参数的准确性; 利用孪生网络搭建隐性扰动检测模型, 以实时数据为输入, 实现重调度的启动时刻的判定; 从历史调度数据中提取用于调度知识挖掘的样本数据, 利用伪孪生网络获取工序和机器的状态数据的映射关系作为调度规则, 用于车间的重调度。仿真实验证明了所提数字孪生驱动的重调度模式的可行性。

关键词: 扰动累积; 数字孪生; 孪生网络; 调度规则挖掘

中图分类号: TP391.9

文献标志码: A

文章编号: 1004-731X(2022)03-0573-11

DOI: 10.16182/j.issn1004731x.joss.21-0110

Job Shop Rescheduling Under Recessive Disturbance Based on Digital Twin

Wu Dinghui¹, Zhang Tongrui^{1*}, Zhang Xiuli²

(1. Key Laboratory of Advanced Process Control for Light Industry, Jiangnan University, Wuxi 214122, China;

2. Wuxi Institute of Technology, Wuxi 214122, China)

Abstract: A new shop rescheduling model driven by digital twin is proposed to solve the problems of disturbance cumulative rescheduling. A scheduling parameter updating method is proposed and a random probability distribution is used to describe the distribution of scheduling parameters to improve the accuracy of scheduling parameters. An implicit disturbance detection model is built based on Siamese Network using real-time data as input to realize the start time of rescheduling. The sample data for scheduling knowledge mining are extracted from the historical scheduling scenarios. Through the Pseudo-Siamese CNN, the mapping relationship between the Process state and machine state is obtained, which is applied to production online rescheduling. Simulation experiments show the feasibility of the proposed digital twin driven shop rescheduling model.

Keywords: recessive disturbance; digital twin; siamese network; dispatching rule mining

引言

车间生产过程中充满各种不确定性, 其中如到达时间不准及操作时间波动等隐性扰动以累积的形式影响生产, 但隐性扰动累积到一定程度则会使生产计划发生偏离, 然后触发重调度。因此, 解决扰动累积下的调度问题的关键点之一就是如

何确定隐性扰动是否超过可控范围^[1]。同时, 如何为扰动累积下的调度问题选择合适的调度方法, 也是重调度问题必不可少的一环^[2]。常见的调度方法有调度规则、运筹学方法、智能搜索算法、机器学习等, 这些方法都在车间调度问题得到了广泛应用^[3]。而现代制造车间的生产过程日趋复杂,

收稿日期: 2021-02-05 修回日期: 2021-05-18

基金项目: 国家重点科研项目(2020YFB1711102)

第一作者: 吴定会(1970-), 男, 博士, 教授, 研究方向为智能制造。E-mail: wh033098@163.com

通讯作者: 张桐瑞(1995-), 男, 硕士生, 研究方向为智能制造。E-mail: ztrdaydayup@foxmail.com

使得隐性扰动这类不确定因素对生产过程的影响越来越难以控制，制造企业的生产效率难以提升。所以考虑隐性扰动累积条件下的生产调度是保证生产系统平稳、高效运行的重要部分之一。

目前，对隐性扰动累积下的车间调度问题的研究相对较少。唐秋华等利用累积误差时间量化隐性扰动，并建立了一种基于机器学习重调度决策机制^[1]；刘壮等^[4]采用基于最晚完工的混合重调度机制驱动重调度决策；Akkan^[5]采用被动触发式重调度驱动规则对隐性扰动的重调度决策进行了研究；左乐^[6]提出一种基于移位系数的混合重调度驱动机制，以降低隐性扰动的影响。然而，在我国制造业逐渐转型为智能制造^[7]的今天，大多数研究可能难以满足企业数字化、智能化和网络化的要求。而数字孪生技术的出现，为车间的智能化提供了有效的解决方案。数字孪生在许多领域都得到了应用^[8]，而在车间调度方面，陶飞等^[9]提出了一种基于数字孪生的车间生产调度优化的设想，以实现更为智能的调度决策和更为精准的过程管控。费永辉^[10]、Fang^[11]等基于数字孪生设计了智能调度新模式，并验证了其有效性。

对于隐性扰动累积下的调度问题，合适的重调度触发条件是难以确定量化的，而当前的解决方案大多采用周期重调度和人工调整。周期重调度是让生产系统每隔一定时间就重新调整调度方案，这种方式会频繁地打断原生产计划，影响车间生产的稳定性。而人工调整的方式则是工人根据经验判断生产状态是否发生扰动，然后再调整调度方案，但工人的经验水平不同，很难保证判断的准确性。为解决扰动累积下的调度问题，同时探索具有自主性和智能性的调度方式，本文以陶飞提出的数字孪生的五维结构模型^[9]为依据，设计了一种针对隐性扰动累积下的车间重调度问题的调度模式，以孪生数据为核心，搭建了重调度决策服务，为企业实现的智能制造提供一个参考。首先，提出一种调度参数更新的方式，根据对历史调度状态数据的分析，获得调度参数的概率分

布，为虚拟调度车间提供更准确的调度参数；然后利用孪生网络^[12]搭建隐性扰动检测模型，并设计其子网络，利用数字孪生的特性以虚拟和物理的实时生产状态数据为输入，实现隐性扰动累积程度的判定；同时从历史调度数据中提取用于调度知识挖掘的样本数据，利用伪孪生网络^[13]训练学习获取工序和机器的调度状态的映射关系，作为调度规则应用于车间的重调度。最后，通过调度实例证明了数字孪生驱动扰动累积下车间重调度的可行性。

1 基于数字孪生的车间重调度框架

1.1 框架描述

随着数据采集系统、信息技术和网络技术的发展，大量的智能传感器和数据采集装置被应用到制造车间当中，更多更准确的生产数据被获得。想要利用积累的生产数据提高生产效率，实现制造系统的智能化，如何实现信息物理融合是关键。数字孪生技术通过在虚拟世界中构建一种虚拟的、动态的模型，与现实世界中对应的物理实体相互映射，能够及时地模拟物理实体的特征、行为、性能等，有效促进了信息层数据和物理数据的相互融合^[14]。针对车间调度中隐性扰动累积的问题，本文提出以数字孪生为基础的重调度模式，其总体框架如图1所示。

基于数字孪生的车间重调度框架包括物理调度车间、虚拟调度车间、重调度决策服务和孪生数据4个部分。物理调度车间是包含制造设备、人和生产活动等客观存在的实体，借助传感器以及信息控制技术，可以实现车间数据的采集上传以及生产指令的执行；虚拟调度车间则是从要素、行为和规则3个层面建立的虚拟模型集合，在虚拟空间中以数据的形式反映车间的状态，并仿真模拟整个生产流程；重调度决策服务是以数据为驱动的功能集合，主要包括调度参数更新、基于孪生网络的隐性扰动累积检测和基于伪孪生网络

的重调度方案的生成; 虚拟调度车间、物理调度车间和重调度决策服务这三者本身的数据以及互

相交产生的数据构成了孪生数据, 是整个系统运行的重要支撑。

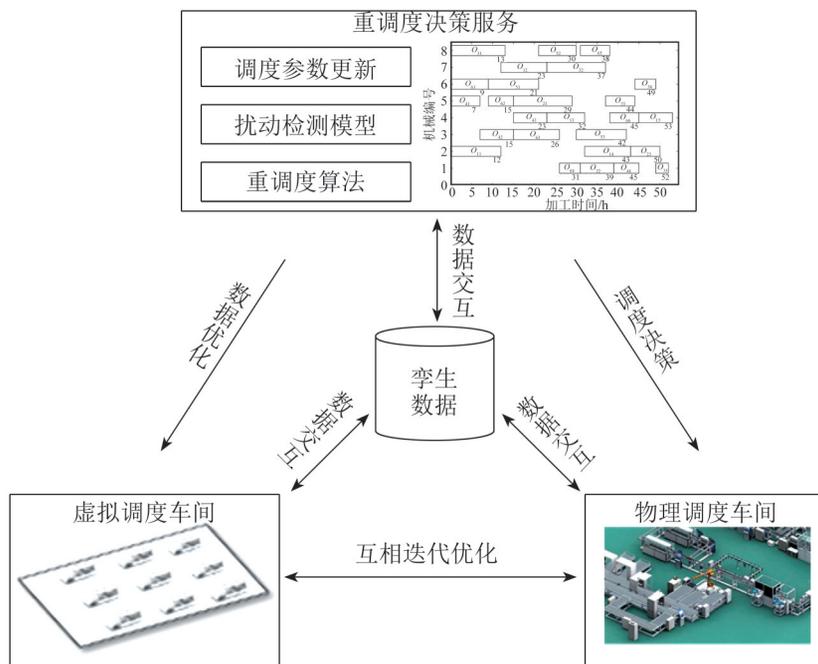


图 1 隐性扰动累积下的车间重调度框架

Fig. 1 Framework of workshop rescheduling under the accumulation of hidden disturbances

1.2 调度问题描述

车间运行方式可以描述为: 车间有 m 台机器, N 种不同的工件依次加工 n_i 道工序, 同时, 生产过程中会发生许多扰动。而本文研究的问题是在隐性扰动累积的情况下为工件重新分配加工机器, 减小车间生产的偏差。车间在生产过程中需要遵守以下条件:

- (1) 一台机器不能同时处理多道工序;
- (2) 一个工件不可同时被多台机器加工, 不允许插队;
- (3) 在零时刻所有工件具有相同的被选择的概率;
- (4) 同工件的工序不可调换加工次序, 不同工件的工序则可以;
- (5) 不同工件优先级一致。

车间内相关符号变量的说明如下:

$M = \{M_k | 1 \leq k \leq m\}$, 表示机器集;

$J = \{J_i | 1 \leq i \leq N\}$, 表示工件集;

$O_i = \{O_{ij} | 1 \leq j \leq n_i\}$, 表示工件 J_i 的工序集;

$M_{ij} = \{M_k | X_{ijk} = 1\}$, 表示工件 J_i 的工序 O_{ij} 的可用机器集;

C_i 表示工件 J_i 的完工时间;

P_{ijk} 表示机器 M_k 加工工件 J_i 的第 j 道工序的时间;

S_{ijk} 表示机器 M_k 加工工件 J_i 的第 j 道工序的时间起始点;

E_{ijk} 表示机器 M_k 加工工件 J_i 的第 j 道工序的结束时间;

X_{ijk} 取值为 0 或 1, $X_{ijk} = 1$ 表示工序 O_{ij} 是在机器 M_k 上加工;

R_{ijegk} 取值为 0 或 1, $R_{ijegk} = 1$ 表示工序 O_{ij} 和 O_{eg} 同时在机器 M_k 上加工时, O_{ij} 优先。

本文所研究的柔性作业车间调度问题以最小化工件的最大完工时间为目标, 其数学模型和约

束条件描述如下:

目标函数为最小化工件的最大完工时间:

$$f = \min(\max(C_i)) \quad (1)$$

约束条件:

(1) 设备约束

$$E_{ijk} - E_{egk} \geq P_{ijk}, R_{ijegk} = 1, X_{ijk} = X = 1 \quad (2)$$

式(2)表示一台机器不可同时处理多个工件或多个工序。

(2) 过程约束

$$E_{ijk} - S_{ijk} = P_{ijk}, X_{ijk} = 1 \quad (3)$$

式(3)表示某道工序开始加工后就不可以被打断。

(3) 工艺约束

$$E_{ijk} - S_{ijk} - E_{i(j-1)h} \geq 0, X_{ijk} = X_{i(j-1)h} = 1 \quad (4)$$

式(4)表示同一工件的工序不可调换加工次序,而不同工件的工序可以。

本文根据该调度问题的约束条件模拟数字孪生车间的运行,通过给予的加工时间的不同来模拟虚拟调度车间和物理调度车间的不同生产状态。

2 重调度决策服务的搭建

重调度决策服务包含2个阶段:离线学习和在线调度。离线学习是利用孪生数据提供的历史数据进行调度知识学习的阶段,通过使用概率分析、孪生网络和伪孪生网络对虚拟调度车间和物理调度车间的调度数据进行分析处理获取调度知识。而在线决策部分则是以孪生数据提供的虚拟调度车间和物理调度车间的实时调度数据为输入,使用所获得的调度知识进行决策。

2.1 调度参数更新

实际生产车间中的许多调度参数都是不确定的^[15],因此在安排生产计划的时候往往使用人工经验值。以机器加工时间为例,在实际生产中机器的加工能力、操作者对机器的熟练程度和工件

制作工艺等的变化都会影响加工时间,而这些因素很难量化,所以以人工经验值为依据的生产计划的完工时间很容易出现偏差。

调度参数的不确定性可以归类为可预知的不确定性^[15],针对该种不确定性问题通常可以通过对历史信息的统计分析来量化。常用的方法有确数、模糊理论和概率分布等,其中概率分布是一种简单有效的方法。而概率分布对于可知历史数据的依赖问题,在生产信息化快速发展的今天可以得到较好的解决。

通过概率分布来描述调度参数的分布情况,即利用统计分析的手段分析生产历史数据,获得调度参数的概率分布。通过概率分布的方法,生产系统可以得到更加精确的调度参数以及更好的干扰预测能力,同时虚拟调度车间可以通过调度参数的准确更新进一步优化自身,得到更贴近实际的仿真结果。并且随着数据的积累,调度参数的准确性会逐步提升,调度决策的抗干扰能力也会逐步提高。

2.2 基于孪生网络的扰动检测

本文提出一种基于孪生网络的扰动检测方法,通过深度学习的方法挖掘人工判定扰动时生产状态数据的内部规律,以虚拟车间和物理车间的实时状态数据为输入,实时地检测隐性扰动累积是否达到触发重调度的条件。

Chopra^[12]提出的孪生网络主要用于二分类,以2组数据为输入,比较2组数据的相似程度,其网络结构如图2所示。

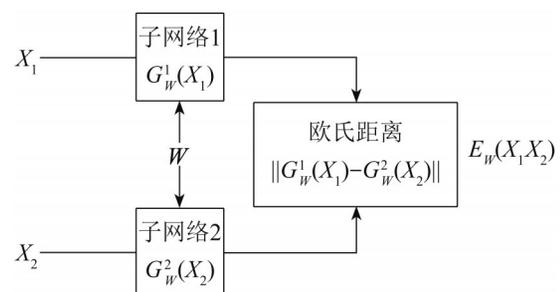


图2 孪生网络结构

Fig. 2 Siamese network structure

图 2 中, X_1 和 X_2 为输入的 2 组数据; W 为 2 个子网络之间的共享权值向量; G_w^1 和 G_w^2 是 2 个子网络进行特征提取的函数; $\|G_w^1(X_1) - G_w^2(X_2)\|$ 代表子网络输出值的欧氏距离, 值越大代表 2 组数据的相似程度越高。 $E_w(X_1, X_2)$ 可以表示为

$$E_w(X_1, X_2) = \|G_w^1(X_1) - G_w^2(X_2)\| \quad (5)$$

孪生网络的结构可充分利用数字孪生的“孪生”特点, 将同一时刻分别来自物理车间和虚拟车间的实时状态数据作为网络的输入, 然后用网络的输出值来衡量两者生产状态之间的偏差。如果输出值过小则说明两者的生产状态相似程度较大, 两者生产状态之间的偏差较小; 反之则两者的生产状态相似程度较小, 两者生产状态之间的偏差较大。

由于本文利用孪生网络学习人工判定的生产状态数据来界定隐性扰动的累积扰动程度是否达到重调度的标准, 所以本文在孪生网络的基础上加上一个全连接层, 使网络可以用于二分类, 以达到实时检测隐性扰动的累积程度的目的, 其示意图如图 3 所示。

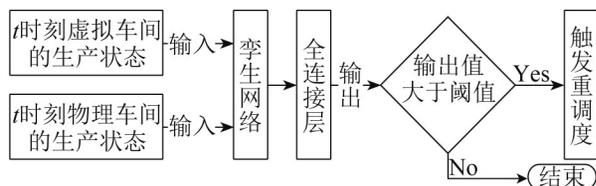


图 3 基于孪生网络的扰动检测的示意图

Fig. 3 Schematic diagram of hidden disturbances detection based on Siamese network

采用使用较多的二值交叉熵作为网络的损失函数, 定义为

$$loss(y_o, t) = -[t \ln(y_o) + (1 - t) \ln(1 - y_o)] \quad (6)$$

式中: y_o 为网络输出; t 为标签, 值为 0 或 1。

2.2.1 数据特征的选取和数据预处理方法

合适的特征数据能够很好地反应生产系统的状态, 比如各工件的工序约束关系、各工序的加工时间、机器的加工工序等。本文针对隐性扰动

累积的问题, 在采样时间点选取特征描述如表 1 所示。

表 1 生产系统状态特征

Table 1 State characteristics of the production system	
序号	特征描述
1	车间内空闲的机器数
2	车间内正在加工的机器数
3	车间内空闲的工件数
4	车间内正在加工的工件数
5	机器正在加工的工件编号
6	机器所要加工的工序数
7	机器还未加工的工序数
8	机器已经加工的工序数
9	机器加工时长的总和
10	机器空闲时间总和
11	工件正在被加工的机器编号
12	工件的工序数
13	工件还未加工的工序数
14	工件已经加工的工序数
15	工件加工时长的总和
16	工件空闲时间总和

在车间开始生产后每隔一段时间从虚拟调度车间和物理调度车间采集生产状态数据, 经过数据处理后构成样本数据以供训练和预测。本文选取 min-max 标准化方法实现数据的标准化:

$$y_i = (x_i - x_i^{\min}) / (x_i^{\max} - x_i^{\min}) \quad (7)$$

式中: x_i 为所选取的特征属性; x_i^{\max} 和 x_i^{\min} 为对应特征属性的最大和最小值; y_i 为标准化后的属性。

同时, 根据人工调整的时间点生成对应标签, 在此扰动时间点前的样本数据标签为 0, 表示累积扰动未到达触发条件; 而在此扰动时间点之后的样本数据标签为 1, 表示扰动累积程度达到调整标准。

2.2.2 子网络的设计

卷积神经网络作为深度学习代表算法, 在许多领域都取得优秀的成果, 尤其是在图像处理领域。VGG(visual geometry group)网络通过采用连续的 3×3 的卷积核提升网络的深度, 以此增强神经网络的性能。本文借鉴 VGG 网络的思想, 针对

一维的特征数据，使用连续的 3×1 卷积来设计孪生网络的子网络。

目前，使用最为广泛的一种激活函数就是Sigmoid函数，其特性对于二分类问题的处理有一定优势，并且该函数在处理特征相差较大或者较小的数据时，可以取得较好的求解结果。所以子网络的激活函数选择Sigmoid函数。但当输入数据过大或者过小时，会有梯度消失的现象，导致训练结果不佳^[16]。而批量归一化(batch normalization, BN)^[17]，能够有效消除梯度消失，使得模型正则化。因此，在每次卷积操作之后加入BN层，加快网络的训练过程。

为进一步提升网络的性能，使用VGG网络的双卷积结构，并将2个尺寸相同卷积核的卷积层以及对应的BN层、激活函数和池化层当成一个特征提取单元，5个特征提取单元构成了孪生网络的子网络，其结构如图4所示。

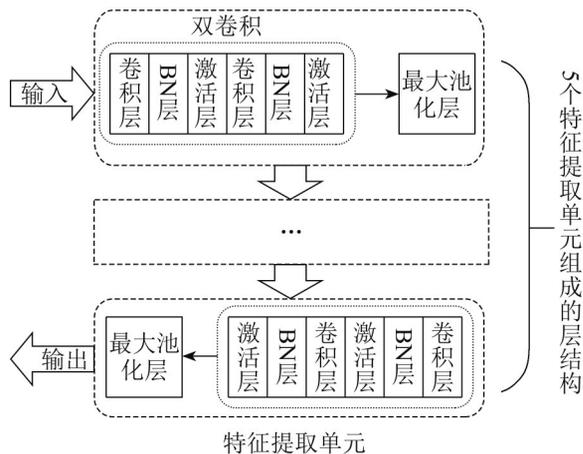


图4 孪生网络的子网络结构
Fig. 4 Sub-network structure of the Siamese network

2.3 基于伪孪生网络的调度规则挖掘

调度规则是在考虑生产约束的情况下解决工件的机器选择问题和机器的工件选择问题。与基于搜索的算法相比，调度规则可以在可接受的时间范围内产生较优的解，调度规则的计算量小，可融入调度专家知识、方便解释、计算效率等特点，使其非常适合用于动态调度或实时调度。但

是，在所有场景下，没有一个调度规则可以胜过其他任何规则，这可能导致调度决策的结果不是非常理想，因此从调度相关历史数据中提取用于求解调度问题的调度规则成为了一种解决方案。本文提出一种基于伪孪生网络的调度规则挖掘模型，挖掘出可用的调度规则，并用于隐性扰动累积下的重调度。

伪孪生网络^[13]与孪生网络最大的不同就是其子网络是完全独立的2个网络。在这样的结构中子网络的作用仅仅是进行特征提取然后融合特征用于后续网络的决策，虽然增加了网络的计算量，但是相比孪生网络更灵活，更适合来自不同类型的输入。基于伪孪生网络的调度规则挖掘模型的网络结构如图5所示。

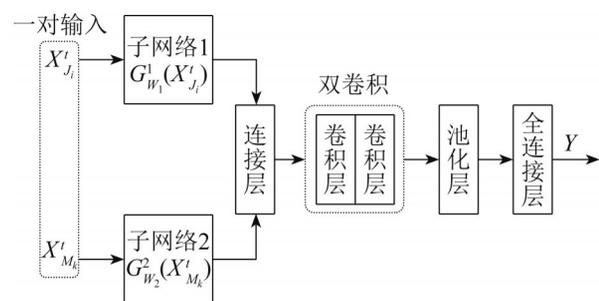


图5 基于伪孪生网络的调度规则挖掘模型
Fig. 5 Dispatch rule mining model based on pseudo-Siamese CNN

$X_{J_i}^t (1 \leq i \leq N)$ 和 $X_{M_k}^t (1 \leq k \leq m)$ 分别决策时间点 t 时的待决策工件以及其对应的可选机器集中机器的生产状态特征数据，每个工件的状态数据和其对应的可选机器的状态数据组成一对输入； W_1 和 W_2 分别为2个子网络的权值向量； $G_{W_1}^1$ 和 $G_{W_2}^2$ 是2个子网络进行特征提取的函数； Y 代表网络的输出值，表示工件与对应机器的匹配程度。

图5中伪孪生的连接层使用串联方式实现特征融合，连接层后使用的双卷积组成的网络用来进一步特征提取。基于伪孪生网络的调度规则挖掘同样是二分类问题，因此同样采用式(6)二值交叉熵作为伪孪生网络的损失函数。伪孪生网络的

子网络采用 2.2.2 节所设计的子网络。

2.3.1 数据特征的选取和数据预处理方法

通过采集较优的调度方案的状态数据, 经过数据处理后构成样本数据以供训练和预测。针对基于伪孪生网络的调度规则挖掘, 选取如表 2 和表 3 所示的工件和机器的相关特征作为输入数据的特征。

表 2 决策时间点工件的状态特征

Table 2 State characteristics of the job at the decision point in time

序号	描述
1	工件编号
2	工件待加工工序的编号
3	工件还未加工的工序数
4	工件已经加工的工序数
5	工件加工时长的总和
6	工件空闲时间总和

表 3 决策时间点机器的状态特征

Table 3 State characteristics of the machine at the decision point in time

序号	描述
1	机器编号
2	机器前一个加工工件编号
3	机器已经加工的工序数
4	机器加工时长的总和
5	机器空闲时间总和
6	待加工工序在机器上的预计加工时间

使用与 2.2.1 数据预处理方式, 即通过式(7)输入限定在[0,1]的数据, 防止减慢训练速度。

根据最优调度方案的工序与机器的选择来确定训练数据的标签, 输入的训练数据为工件和当前工序对应的机器数据, 则训练数据的标签为 1, 表示当前状态的工件与该机器匹配; 而输入的训练数据为工件和当前工序对应的可选机器集内其他机器的数据, 则训练数据的标签为 0, 表示当前状态的工件与该机器不匹配。

2.3.2 伪孪生网络调度规则的运用

通过伪孪生网络挖掘得到调度规则后, 就可以使用调度规则为待加工工件选择合适的机器, 或为空闲机器选择合适的工件。如图 6 所示, 工

件 J_i 的工序 O_{ij} 需要在其可选机器集中的机器 M_1 , M_2 和 M_4 中选择一台最合适的机器进行加工。首先, 获取决策时刻该工序对应的工件和可选机器的实时数据, 并在数据预处理后将工件 J_i 与 M_1 , M_2 和 M_4 的数据组成 3 对输入。在此基础上, 将 3 对输入依次输入到调度规则中获得输出结果, 输出结果为 [0, 1] 的数值, 表示当前状态的工件与可选机器的匹配程度, 若输出值大于 0.5, 则表示对应的机器可选。接着筛选出输出值大于 0.5 的机器, 然后从中选择输出值最大的对应机器为工件 J_i 的工序 O_{ij} 的加工机器。例如, M_1 , M_2 和 M_4 对应的输出值分别为 0.1, 0.8 和 0.9, 那么选取机器 M_4 作为工件 J_i 的工序 O_{ij} 的加工机器。

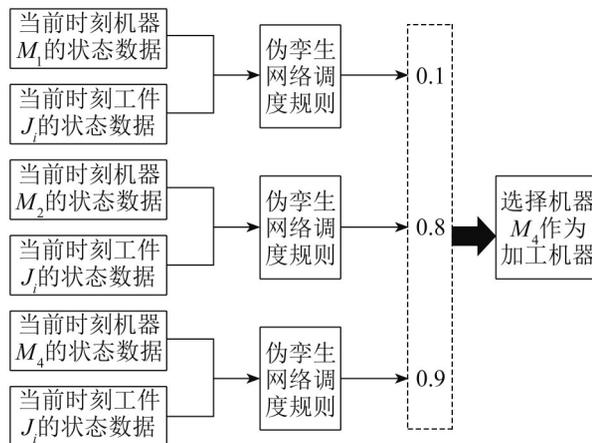


图 6 伪孪生网络调度规则的使用示例
Fig. 6 Example of dispatch rule based on pseudo-siamese CNN

3 仿真实验

3.1 仿真环境搭建

(1) 实验对象

本文选取文献[18]的 6 工件 8 机器共 26 道工序的柔性作业车间实例作为实验对象, 调度目标为最小化最大完工时间。

(2) 人工判定时间点的确定

为进一步贴合隐性扰动下的车间, 模拟调度参数的概率分布, 假设工件各工序在对应的机器

上的加工时间服从正态分布，各个工序对应的加工时间的正态分布以1为标准差，其期望值为对应的加工时间值。以工序 O_{11} 在机器 M_2 的加工时间为例，假设其理想的加工时间为12个单位时间，而实际加工时间为正态分布 $N(12, 1)$ 产生的随机值。

通过设置累积误差时间阈值的方法来确定人工判定扰动的时间点。针对工件而言，累积误差时间是其工序实际和计划开始时刻的差值。确定一个累积误差时间阈值，当累积误差时间大于等于阈值时，对应工序的开工时间则假设为人工判定扰动的时间点。设置累积误差时间阈值为4，然后获得各组调度方案对应的扰动时间点，再根据扰动时间点获取各个采样时间点特征数据对应的标签。

(3) 样本数据的生成

初始调度问题可以看成静态柔性作业车间调度问题，所以用于生成样本数据的调度方案由遗传算法生成。生产过程中的历史数据以仿真的形式获取，对于一个调度方案，虚拟车间以理想加工时间表为加工参数模拟车间的生产过程，而实际车间则以正态分布生成的实际加工时间表为加工参数模拟车间的生产过程。在车间模拟仿真运行的过程中每隔0.2个单位时间采集一次对应的实时状态数据，最后获得对应调度方案的状态数据集。然后根据孪生网络和伪孪生网络的标签判定标准为数据集内的数据打上对应的标签。多个不同调度方案的状态数据集组成用于训练的样本数据。

3.2 扰动检测模型的验证

扰动检测模型的验证是以生成的50个不同的调度方案作为实验数据的来源。由于每个调度方案的完工时间有所不同，每组调度状态数据都包含不同对数的特征数据对，每条特征数据对包含2个分别来自虚拟车间和物理车间的特征数据向量。随机选取40个调度方案的数据作为训练集，剩下

10个调度方案的数据作为测试集。

对于 6×8 的柔性作业车间，孪生网络的子网络的输入维度为 88×1 ，卷积核的大小为 3×1 ，个数分别为16, 32, 64, 128, 128，滑动步长全部为1，对所有的卷积层做SAME处理，在边界上加入0填充，使得输入输出的尺寸一致。池化层的均为 2×1 的最大池化层，滑动步长全部为2。采用自适应矩估计算法对模型参数进行优化，模型进行80次迭代训练，每次迭代后验证一次。随着迭代次数的增加，验证精度和验证误差趋于平稳，最后一次验证的准确率为92.7%。

为验证扰动检测的有效性，随机生成一个调度方案进行验证，其扰动前后的甘特图如图7, 8所示。通过模拟获得特征数据，然后输入模型得到的输出如图7所示。图8中确定的人工调整时刻点在开工后42.91个单位时间，而在图9中，训练后的模型可以在43个单位时间时预测得出数值为0.577，表明扰动已经到达重调度触发条件。从图9中还可以观察到，在开工36个单位后，模型输出值明显上升且波动明显，这种现象在实际的生产过程中可以起到警示作用，为后续处理预留时间。

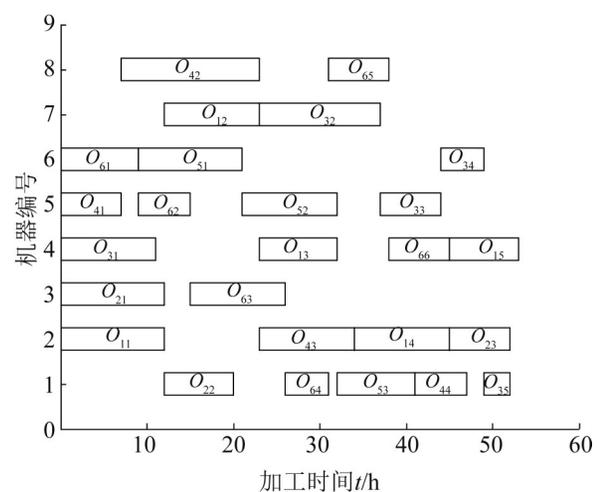


图7 原计划调度的甘特图
Fig. 7 Original scheduling Gantt chart

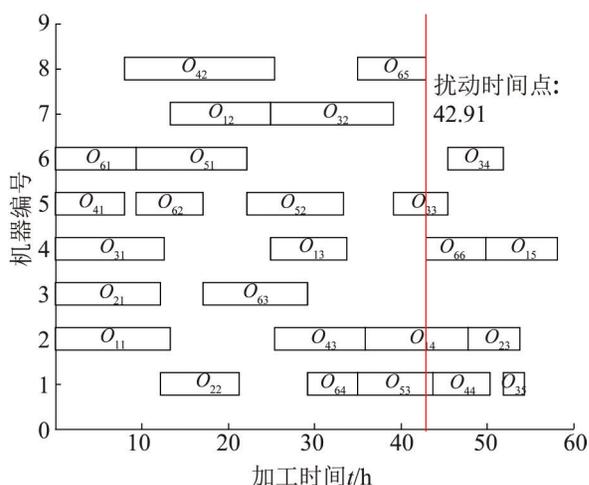


图 8 扰动后的调度甘特图

Fig. 8 Scheduling Gantt chart after disturbance

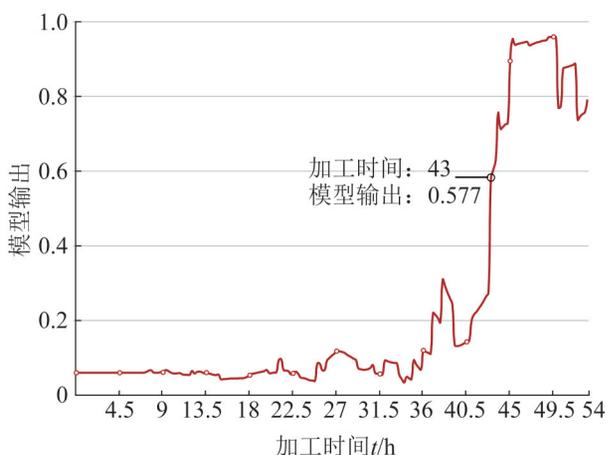


图 9 模型的输出

Fig. 9 Output of model

3.3 调度规则挖掘模型的验证

基于伪孪生网络的调度规则挖掘模型的训练数据来源为遗传算法生成的 500 个较优调度方案, 将 500 个调度方案进行模拟运行, 然后获取各决策点相关的特征数据并进行预处理用于网络的训练。对于本文的车间实例, 伪孪生网络的子网络的输入维度为 5×1 , 卷积核的大小全部为 3×1 , 个数分别为 16, 32, 64, 128, 128, 滑动步长全部为 1, 对所有的卷积层做 SAME 处理, 在边界上加入 0 填充, 使得输入输出的尺寸一致。池化层的均为 2×1 的最大池化层, 滑动步长全部为 2。连接层之后的卷积个数为 256, 256。同样采用 Adam

算法对模型参数进行优化。

下面通过一个实例来验证所得调度规则的可行性。首先, 生成一个初始调度方案, 然后通过正态分布模拟实际扰动加工时间, 生成扰动后的调度方案, 重调度触发点为开始生产后 34.58 个单位时间, 扰动前后的甘特图如图 10, 11 所示; 采用伪孪生网络调度规则进行重调度, 获得的重调度方案如图 12 所示; 在相同的条件下, 使用 SPT 调度规则生成的重调度方案作为对比, 其获得的重调度方案如图 13 所示。图 11~13 中红线部分标注的是扰动判定时刻, 被标红的工序则是进行重调度后调整的工序。

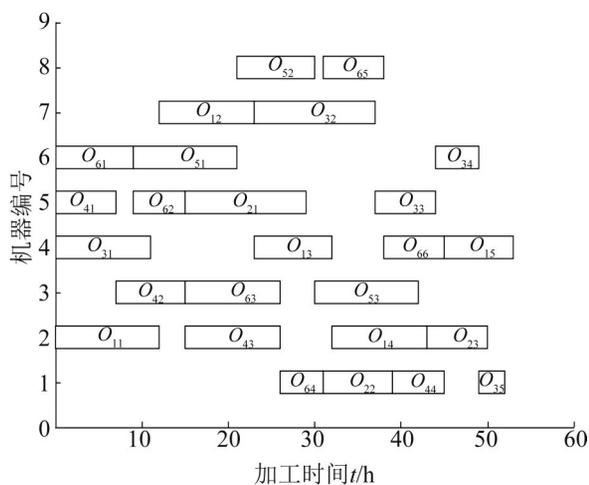


图 10 原计划调度方案

Fig. 10 Gantt chart of original scheduling program

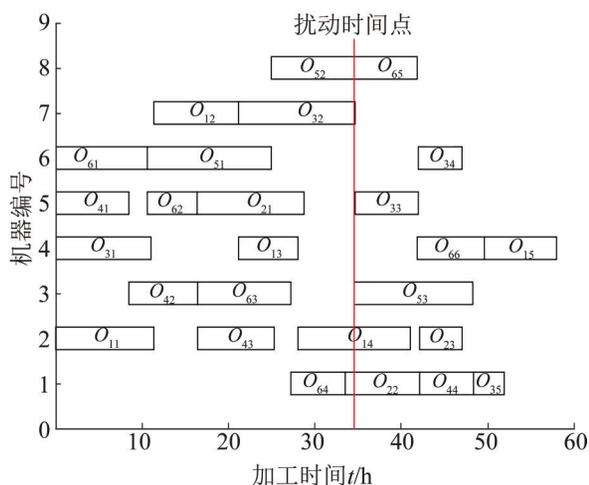


图 11 扰动后调度方案

Fig. 11 Gantt chart of scheduling program after disturbance

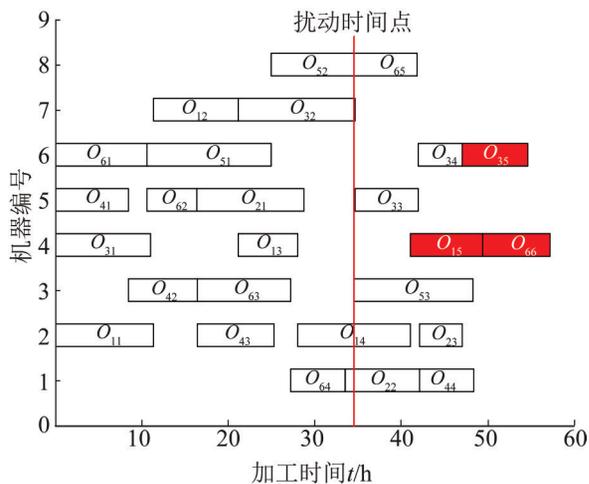


图12 伪孪生网络调度方案

Fig. 12 Gantt chart generated by pseudo-siamese CNN

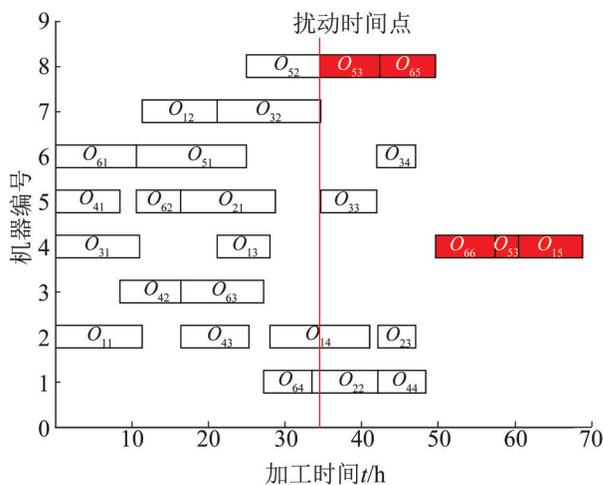


图13 SPT调度方案

Fig. 13 Gantt chart of scheduling program generated by SPT

扰动后未调整的调度方案、伪孪生网络调度方案和SPT调度方案的最大完工时间如表4所示。原计划生产的完工时间为53，而扰动后不做重调度的最大完工时间为57.99。以原计划调度方案的完工时间为基准，扰动后调度方案、伪孪生网络调度方案和SPT调度方案的完工时间偏差分别为4.99，3.86和15.9。可以看出，伪孪生网络生成的重调度方案的完工时间最优，虽然只略优于未做重调度调整的方案，但相比传统的SPT调度规则有很大优势。

表4 各方案的最大完工时间

Table 4 Results of each scheduling scheme h		
方案类型	最大完工时间	完工时间偏差
扰动后调度方案	57.99	4.99
伪孪生网络方案	56.86	3.86
SPT调度方案	68.90	15.90

同时，从图11~13可以看出，相比初始的调度方案，伪孪生网络的调度方案只调整了3个工序，这表明伪孪生网络的调度方案对于原生产计划的干扰较少，可以避免不必要的资源调度。通过上述比较可以看出，本文所提出的伪孪生网络的调度规则挖掘模型具有一定的可行性和有效性，虽然调度指标的提升并不明显，但相比传统的调度规则有较大的优势，同时也保留了传统调度规则计算量小、效率高等特点。而且，基于数字孪生的整体架构能积累更多的真实准确的调度数据，能够实现模型的自我学习，不断提升优化求解能力。

4 结束语

针对隐性扰动累积下的车间重调度问题，本文提出一种基于数据孪生的调度模式。首先，搭建了基于孪生网络的扰动检测模型，利用样本数据对模型进行训练，再以虚拟车间和物理车间的调度实时数据为输入，实时地检测隐性扰动累积是否达到触发重调度的条件。然后利用伪孪生网络从调度历史数据中挖掘调度规则，当隐性扰动累积达到触发重调度的条件时，使用挖掘的调度规则进行重调度。最后通过调度实例的仿真验证了本文所提调度方法的可行性和有效性。

本文所提出的基于数据孪生的调度模式的调度性能受限于历史调度数据的准确性和适用性，下一步可以考虑历史调度数据的数据筛选、数据清洗等方面的研究，以进一步提升系统的调度性能。

参考文献:

- [1] 唐秋华, 成丽新, 张利平. 扰动累积下基于机器学习的

- 重调度方式选择[J]. 中国机械工程, 2019, 30(4): 472-479.
- Tang Qiuhua, Cheng Lixin, Zhang Liping. Re-Scheduling Mode Selection Under Recessive Disturbance Accumulation via Machine Learning[J]. China Mechanical Engineering, 2019, 30(4): 472-479.
- [2] Chuang Wang, Pingyu Jiang. Manifold Learning Based Rescheduling Decision Mechanism for Recessive Disturbances in RFID-Driven Job Shops[J]. Journal of Intelligent Manufacturing, 2018, 29(7): 1485-1500.
- [3] 刘民. 基于数据的生产过程调度方法研究综述[J]. 自动化学报, 2009, 35(6): 785-806.
- Liu Min. A Survey of Data-Based Production Scheduling Methods[J]. Acta Automatica Sinica, 2009, 35(6): 785-806.
- [4] 刘壮, 张中敏, 杜先军. 基于改进TOPSIS的制造车间重调度决策方法研究[J]. 组合机床与自动化加工技术, 2017(1): 157-160.
- Liu Zhuang, Zhang Zhongmin, Du Xianjun. Re-Scheduling Decision of Method Manufacturing Workshop Based on Improved TOPSIS[J]. Modular Machine Tool and Automatic Machining Technology, 2017(1): 157-160.
- [5] Can Akkan. Improving Schedule Stability in Single-Machine Rescheduling for New Operation Insertion[J]. Computers and Operations Research (S0305-0548), 2015, 64: 198-209.
- [6] 左乐. 不确定环境下柔性作业车间的多目标动态调度研究[D]. 北京: 北京交通大学, 2015.
- Zuo Le. Study on Multi-Objective Dynamic Production Scheduling Problem of Flexible Job Shop under Uncertainty[D]. Beijing: Beijing Jiaotong University, 2015.
- [7] 张洁, 秦威. 智能制造调度为先——《制造系统智能调度方法与云服务》导读[J]. 中国机械工程, 2019, 30(8): 1002-1007.
- Zhang Jie, Qin Wei. Intelligent Manufacturing Scheduling First-A Guide of Manufacturing System Intelligent Scheduling Method and Cloud Service[J]. China Mechanical Engineering, 2019, 30(8): 1002-1007.
- [8] 李欣, 刘秀, 万欣欣. 数字孪生应用及安全发展综述[J]. 系统仿真学报, 2019, 31(3): 385-392.
- Li Xin, Liu Xiu, Wan Xinxin. Overview of Digital Twins Application and safe Development[J]. Journal of System Simulation, 2019, 31(3): 385-392.
- [9] 陶飞, 刘蔚然, 刘检华, 等. 数字孪生及其应用探索[J]. 计算机集成制造系统, 2018, 24(1): 1-18.
- Tao Fei, Liu Weiran, Liu Jianhua, et al. Digital Twin and its Potential Application Exploration[J]. Computer Integrated Manufacturing Systems, 2018, 24(1): 1-18.
- [10] 费永辉. 基于数字孪生的柔性作业车间动态调度研究[D]. 杭州: 浙江工业大学, 2019.
- Fei Yonghui. Research on Flexible Job Shop Dynamic Scheduling Based on Digital Twins[D]. Hangzhou: Zhejiang University of Technology, 2019.
- [11] Fang Y, Peng C, Lou P, et al. Digital-Twin Based Job Shop Scheduling Towards Smart Manufacturing[J]. IEEE Transactions on Industrial Informatics (S1551-3203), 2019, 15: 6425-6435.
- [12] Chopra S, Hadsell R, Lecun Y. Learning a Similarity Metric Discriminatively, with Application to Face Verification[C]// 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05). San Diego, CA, USA: IEEE, 2005.
- [13] Hughes L H, Schmitt M, Mou L, et al. Identifying Corresponding Patches in SAR and Optical Images with a Pseudo-Siamese CNN[J]. IEEE Geoscience and Remote Sensing Letters (S1505-598X), 2018, 15(5): 784-788.
- [14] Fei Tao, Jiangfeng Cheng, Qinglin Qi, et al. Digital Twin-Driven Product Design, Manufacturing and Service with Big Data[J]. The International Journal of Advanced Manufacturing Technology (S0268-3768), 2018, 94: 3563-3576.
- [15] 侯智, 陈倩, 陈进. 制造过程中的不确定信息及其处理方法综述[J]. 机床与液压, 2018, 46(5): 121-126.
- Hou Zhi, Chen Qian, Chen Jin. Review of Uncertain Information and Its Processing Methods in Manufacturing Process[J]. Machine Tool and Hydraulics, 2018, 46(5): 121-126.
- [16] 蒋静静. 基于深度强化学习的离散型制造企业车间动态调度研究[D]. 西安: 西安理工大学, 2020.
- Jiang Jingjing. Research on Job Shop dynamic Scheduling of Discrete Manufacturing Enterprise Based on Deep Reinforcement learning[D]. Xi'an: Xi'an University of Technology, 2020.
- [17] Wei Zhang, Gaoliang Peng, Chuanhao Li, et al. A New Deep Learning Model for Fault Diagnosis with Good Anti-Noise and Domain Adaptation Ability on Raw Vibration Signals[J]. Sensors (S1424-8220), 2017, 17(2): 425.
- [18] 孔飞, 吴定会, 纪志成. 基于双层粒子群优化算法的柔性作业车间调度优化[J]. 计算机应用, 2015, 35(2): 476-480.
- Kong Fei, Wu Dinghui, Ji Zhicheng. Flexible Job Shop Scheduling Optimization Based on Two-Layer Particle Swarm Optimization Algorithm[J]. Journal of Computer Applications, 2015, 35(2): 476-480.