



## 基于深度学习的柔性流水车间排产优化问题研究

韩忠华, 黎恺嘉, 周晓锋, 王继娜, 孙亮亮

引用本文:

韩忠华,黎恺嘉,周晓锋,王继娜,孙亮亮. 基于深度学习的柔性流水车间排产优化问题研究[J]. 智能系统学报, 2023, 18(3): 468–479.

HAN Zhonghua,LI Kaijia,ZHOU Xiaofeng,WANG Jina,SUN Liangliang. Research on the optimization of flexible flow shop scheduling based on deep learning[J]. *CAAI Transactions on Intelligent Systems*, 2023, 18(3): 468–479.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202112028>

## 您可能感兴趣的其他文章

### 含忽略工序和不相关机的混合流水车间调度

Hybrid flowshop scheduling with missing operations and unrelated machines

智能系统学报. 2022, 17(3): 459–470 <https://dx.doi.org/10.11992/tis.202103006>

### 深度多尺度融合注意力残差人脸表情识别网络

Deep multiscale fusion attention residual network for facial expression recognition

智能系统学报. 2022, 17(2): 393–401 <https://dx.doi.org/10.11992/tis.202107028>

### 基于注意力融合的图片描述生成方法

An image caption generation method based on attention fusion

智能系统学报. 2020, 15(4): 740–749 <https://dx.doi.org/10.11992/tis.201910039>

### 改进猫群算法求解置换流水车间调度问题

Improved cat swarm optimization for permutation flow shop scheduling problem

智能系统学报. 2019, 14(4): 769–778 <https://dx.doi.org/10.11992/tis.201804016>

### 萤火虫算法的电动汽车综合成本运行优化研究

Optimizing the composite cost of electric vehicles based on the firefly optimization model

智能系统学报. 2017, 12(2): 166–171 <https://dx.doi.org/10.11992/tis.200603024>

### 柔性流水车间排产问题的一种协同进化 CGA 求解方法

A co-evolution CGA solution for the flexible flow shop scheduling problem

智能系统学报. 2015(4): 562–568 <https://dx.doi.org/10.3969/j.issn.1673-4785.201503045>

DOI: 10.11992/tis.202112028

网络出版地址: <https://kns.cnki.net/kcms2/detail/23.1538.TP.20230320.1533.010.html>

# 基于深度学习的柔性流水车间排产优化问题研究

韩忠华<sup>1,2</sup>, 黎恺嘉<sup>1</sup>, 周晓锋<sup>2</sup>, 王继娜<sup>3</sup>, 孙亮亮<sup>1</sup>

(1. 沈阳建筑大学 信息与控制工程学院, 辽宁 沈阳 110168; 2. 中国科学院沈阳自动化研究所 数字工厂研究室, 辽宁 沈阳 110016; 3. 辽宁省先进装备制造业基地建设工程中心 辽宁省信息安全与软件测评认证中心, 辽宁 沈阳 110001)

**摘要:** 求解柔性流水车间排产优化问题的全局优化算法常采用群体进化算法或数学规划算法, 但对新的投产任务进行排产优化过程中, 这些优化方法每次都需重新进行耗时的迭代寻优计算, 因此提出了一种基于深度学习的智能排产优化方法, 通过历史生产数据训练基于门控循环单元构建的序列到序列深度学习模型, 重点研究排产数据中生产任务信息、工艺信息与排产结果的相关性, 并将其作为模型编码器的输入; 模型解码器的输出为工件的上线序, 依据该上线序可以快速给出有效的排产结果, 并通过引入注意力机制进一步提高寻优的精度和速率。仿真实验结果表明, 基于深度学习的柔性流水车间排产优化方法可以快速获取较好的排产优化结果。

**关键词:** 深度学习; 排产优化; 加工上线序; 柔性流水车间; 门控循环单元; 序列到序列; 注意力机制; 历史生产数据

中图分类号: TP183 文献标志码: A 文章编号: 1673-4785(2023)03-0468-12

中文引用格式: 韩忠华, 黎恺嘉, 周晓锋, 等. 基于深度学习的柔性流水车间排产优化问题研究 [J]. 智能系统学报, 2023, 18(3): 468-479.

英文引用格式: HAN Zhonghua, LI Kaijia, ZHOU Xiaofeng, et al. Research on the optimization of flexible flow shop scheduling based on deep learning[J]. CAAI transactions on intelligent systems, 2023, 18(3): 468-479.

## Research on the optimization of flexible flow shop scheduling based on deep learning

HAN Zhonghua<sup>1,2</sup>, LI Kaijia<sup>1</sup>, ZHOU Xiaofeng<sup>2</sup>, WANG Jina<sup>3</sup>, SUN Liangliang<sup>1</sup>

(1. Faculty of Information and Control Engineering, Shenyang Jianzhu University, Shenyang 110168, China; 2. Department of Digital Factory, Shenyang Institute of Automation, the Chinese Academy of Sciences, Shenyang 110016, China; 3. Liaoning Information Security and Software Testing & Certification Center, Liaoning Province's Construction and Engineering Center for Advanced Equipment Manufacturing Base, Shenyang 110001, China)

**Abstract:** The global optimization algorithm for solving the production scheduling optimization problem of the flexible flow shops often adopts the group evolution algorithm or the mathematical programming algorithm. In the process of scheduling and optimizing new production tasks, these optimization methods need to perform time-consuming iterative optimization calculations again every time. Therefore, an intelligent scheduling optimization method based on deep learning is proposed to solve above problem. Through historical production data training, a sequence-to-sequence (Seq2Seq) deep learning model based on gated recurrent unit (GRU) is used to focus on the correlation between the production task information and process information in the scheduling data and the scheduling results. And further this correlation is used as the input of the model encoder; and the output of the model decoder is the on-line sequence of the workpiece. According to the on-line sequence, effective scheduling results can be quickly given, and the accuracy and speed of optimization can be further improved by introducing an attention mechanism. The results of simulation experiment show that the flexible flow shop scheduling optimization method based on deep learning can quickly obtain better scheduling optimization results.

**Keywords:** deep learning; production scheduling optimization; processing on-line sequence; flexible flow shop; gated recurrent unit; sequence-to-sequence; attention mechanism; historical production data

收稿日期: 2021-12-15 网络出版日期: 2023-03-21.

基金项目: 国家自然科学基金项目(61873174); 辽宁省重点研发计划项目(2020JH2/10100039); 辽宁省教育厅高等学校基本科研项目重点项目(LJKZ0583); 沈阳市科技项目(Z18-5-015).

通信作者: 黎恺嘉. E-mail: [lkj199703@163.com](mailto:lkj199703@163.com).

©《智能系统学报》编辑部版权所有

为面对不断加剧的市场竞争压力, 企业除了改进现有制造工艺和生产设备技术水平, 还可以通过引入基于人工智能的排产优化算法来缩短加工时间、降低能耗、制定出更契合企业实际生产

运作规律的生产计划, 进一步挖掘企业现有的生产潜力。对新的投产任务进行排产优化过程中, 基于常规群体进化算法或数学规划算法的排产优化算法每次都需要复杂的迭代寻优计算才能获得较好的优化结果, 如果排产优化过程较慢, 会增加计划人员的排产工作时间, 特别是当生产计划进行调整或是重排时, 车间工况随着时间也在不断变化, 更需要快速给出排产优化结果。同时, 对于复杂的生产优化问题很难构建精准的生产优化模型, 并且这些问题求解过程比较复杂, 因此更需要探索一种充分依托历史生产数据, 并可以快速给出合理排产结果的方法来解决上述问题。深度学习具有无需人工建模、快速提取数据潜在特征以及并行计算等特点, 近年来在语言处理和回归分析领域都有比较成功的应用案例, 因此将深度学习算法引入到生产优化领域中, 利用深度学习算法挖掘历史排产数据中隐含的排产知识, 获取排产数据与排产结果的映射关系网络, 从而指导柔性流水车间的实时生产。

本文针对制造业典型的柔性流水车间<sup>[1-2]</sup>排产优化问题进行研究, 将深度学习应用于求解这类排产优化问题。在柔性流水生产车间优化方向上, 当前学者都进行了深入的探索。文献[3]结合遗传算法和模拟退火算法的优点, 提出一种改进混合遗传模拟退火算法, 提高了算法自身的收敛速度和寻优能力。文献[4]提出一种混合蛙跳算法, 通过对全解空间禁忌搜索, 扩大了算法解空间, 提高了算法的有效性和优越性。文献[5]通过设计一种改进的蝙蝠算法来解决部分设备维护时的车间调度问题, 并通过验证证明了方法的有效性。上述文献的方法侧重于对智能排产优化算法<sup>[6-9]</sup>的改进, 但当需求产能出现变动导致需要快速重新编制生产计划的时候, 常用的群体进化算法和数学规划算法都需要重新进行耗时的迭代寻优计算过程, 难以快速给出较好的优化结果。

深度学习算法<sup>[10-12]</sup>可以充分利用历史数据<sup>[13]</sup>, 找到数据之间的关联关系, 快速给出智能决策结果, 在图像分类、场景建模、网络安全、自然语言处理等领域得到广泛, 但在生产优化领域的应用研究目前还处于起步阶段, 并且学者多侧重于研究生产调度和局部指派问题, 文献[14]提出基于BP神经网络的数据驱动实时调度方法, 神经网络通过对历史样本数据进行挖掘学习, 形成生产系统状态与调度规则的映射关系网络, 最后将其应用在生产在线实时调度, 其性能指标良好。文献[15]提出一种嵌入指针网络的长短期记忆(long

short-term memory, LSTM)深度学习模型, 模型通过对实际生产数据进行挖掘训练, 利用指针网络来选择工件优先进入缓冲区, 提高了模型的有效性和可靠性。文献[16]使用BP神经网络对历史生产信息进行分析, 将数据归一化之后进行计算, 预测产品完工时间。文献[17]针对柔性作业车间调度问题, 提出一种改进的多阶段优化调度方法和结合了遗传算法与神经网络的小范围竞争择优策略, 通过仿真实验证明了该算法的优良性。

上述文献表明深度学习算法在局部指派和工时预测方面已经得到了一定程度的应用, 但多数情况下还是将其用以解决智能决策问题, 为了进一步扩展和探索深度学习算法在生产优化领域的应用, 本文将深度学习算法引入到求解排产优化问题中。工件加工上线序实质上是多个工件互有关联的工件序列, 在目前主流的深度学习体系中, 序列到序列(Seq2Seq)方法具有良好的处理和生成序列的能力, 其在许多领域已经得到了应用, 文献[18]提出一种基于改进Seq2Seq的短时自动识别系统(automatic identification system, AIS)轨迹序列预测模型, 选取两类典型河段的数据对模型进行训练, 最终验证了该模型能够有效提高短时轨迹序列预测的准确性和效率。文献[19]提出一种新的台风等级预测模型SeqTyphoon, 模型结合了Seq2Seq与卷积神经网络, 通过对历史台风图像进行训练预测, 利用卷积神经网络对预测的台风图像进行评级, 提高了预测的精度和速率。

基于上述研究成果, 本文提出了一种基于深度学习的智能排产优化方法, 重点研究生产数据中生产任务信息、工艺信息与排产结果的相关性, 通过对历史生产数据的学习, 训练能够快速给出有效的排产结果的智能优化模型。提出面向排产优化问题的基于门控循环单元(gated recurrent unit, GRU)构建的Seq2Seq深度学习模型(sequence-to-sequence deep learning model based on gated recurrent unit, SeqGRU), 该模型神经元采用门控循环单元, 构建序列到序列模型的编码器和解码器, 模型解码器输出为工件上线序, 并进一步引入注意力机制提高寻优的精度和速率。

## 1 柔性流水车间排产优化问题概述

柔性流水车间排产优化问题描述为:  $N$ 个工件按照同一加工顺序在 $M$ 道工序上进行加工,  $M$ 道工序之中至少有一道工序的并行机器数多于一台( $E_j \geq 2$ )。同一工件的同一工序, 所有机器上的加工时间相同, 工件在各工序的加工顺序一



致。加工时间为已知量。柔性流水车间如图 1 所示。优化目标是找到  $N$  个工件进入车间加工的上线序, 最小化最大完工时间。并在其生产过程中存在多种假设条件包括: 同一时刻同一台机器只能加工一道工序; 每个工件在某一时刻只能在一台机器上加工; 同一工件的工序有先后约束, 不同工件的工序之间没有先后约束; 不同工件具有相同的优先级; 任何操作在加工过程中不能中断。




图 1 柔性流水车间示意

Fig. 1 Schematic of flexible flow workshop

模型中主要参数包括:  $N$  表示工件总数,  $M$  表示工序总数,  $i$  表示工件的序号,  $j$  表示第  $j$  道工序的序号,  $E_j$  表示第  $j$  道工序的设备数目, 其中  $j \in \{1, 2, \dots, M\}$ ,  $W_{j,k}$  表示第  $j$  道工序的第  $k$  个设备工位,  $S_{i,j}$  表示工件  $i$  在第  $j$  道工序的开工时间, 其中  $i \in \{1, 2, \dots, N\}$ ,  $F_{i,j}$  表示工件  $i$  在第  $j$  道工序的完工时间,  $T_{i,j}$  表示工件  $i$  在第  $j$  道工序的加工时间,  $F_{\max}$  表示最大完工时间。

针对柔性流水车间生产过程的约束条件主要约束开工时间、完工时间关系, 连续加工工序间的关系。

$$F_{i,j} = S_{i,j} + T_{i,j}, \quad i \in \{1, 2, \dots, N\}, j \in \{1, 2, \dots, M\} \quad (1)$$

$$S_{i,j} \geq F_{i,j-1}, \quad i \in \{1, 2, \dots, N\}, j \in \{1, 2, \dots, M\} \quad (2)$$

式 (1) 表示工件  $i$  在第  $j$  道工序的完工时间与开工时间的关系; 式 (2) 表示工件  $i$  需要在上一道工序完工之后才可以进入下一道工序进行加工。

在求解柔性流水车间排产优化问题过程中, 最常用的评价指标是最小最大完工时间, 即最小化全部工件在最后一道工序加工完工时间中的最大值。

$$F_{\max} = \max\{F_{1,M}, F_{2,M}, \dots, F_{n,M}\} \quad (3)$$

$$\min F_{\max} \quad (4)$$

式 (3) 表示最大完工时间为所有工件完成最后一道工序  $M$  的完工时间集合中的最大值, 式 (4) 为最小化最大完工时间。

## 2 基于深度学习的智能排产方法设计

本文提出一种针对柔性流水车间排产优化问

题的深度学习方法, 该方法主要是运用 SeqGRU 深度学习模型来解决生产优化问题, 该方法的主要步骤和处理流程如图 2 所示。

该方法首先对历史生产数据进行预处理, 再将预处理后的数据集划分为训练集、验证集和测试集输入到模型中; 数据经过模型的编码层转化为向量, 并通过引入注意力机制增强模型输入信息与排产结果相关性; 在训练阶段, 模型解码层利用历史已优化上线序的先验经验生成上线序, 再通过该上线序与已优化上线序进行对比分析, 调整模型参数; 待训练完成后, 模型输入工件信息, 模型解码层可输出有效的排产结果。

### 2.1 构造仿真数据

仿真数据来源于某制造企业柔性流水生产车历史生产加工数据, 从中随机选取 4 185 组历史生产数据构建实验数据集。该数据集每组数据都包含了若干工件和若干道工序, 每个工件包括了工件各工序加工时间, 工件开工时间, 工件完工时间和工件基本信息等属性, 数据集输出为该 4 185 组数据对应的已优化上线序和最小最大完工时间。数据集数据的类型主要分为浮点型和字符串型。

### 2.2 数据集的预处理

深度学习模型在训练时, 输入数据多采用数值型数据, 而该数据集的数据具有多样性和类型复杂性, 因此需要对该数据集进行预处理。对数据集的预处理过程分为 3 步: 数值化处理、归一化处理和编码处理。

#### 1) 数值化处理

数据集的数据具有多样性和类型复杂性, 例如每组数据对应的已优化上线序有起止符号 start 和 end, 使用独热编码可以将字符型数据转换为以 0 和 1 表示的二进制数据, 通过独热编码转换后, 1 代表 start, 0 代表 end。

#### 2) 归一化处理

由于某些工件的工序加工时间过长, 数值化处理后的数据特征属性差异相对较大, 导致模型训练速度减缓。因此需要将数据进行归一化处理, 标准化值全部分类到  $[0, 1]$  区间之中。进行归一化处理的计算公式为

$$G' = \frac{G_i - G_{\min}}{G_{\max} - G_{\min}} \quad (5)$$

式中:  $G$  是归一化前的一组生产数据,  $G_i$  是一组生产数据中第  $i$  位数据,  $G_{\min}$  是这组生产数据中的最小值,  $G_{\max}$  是这组生产数据中的最大值,  $G'$  是归一化之后的生产数据。

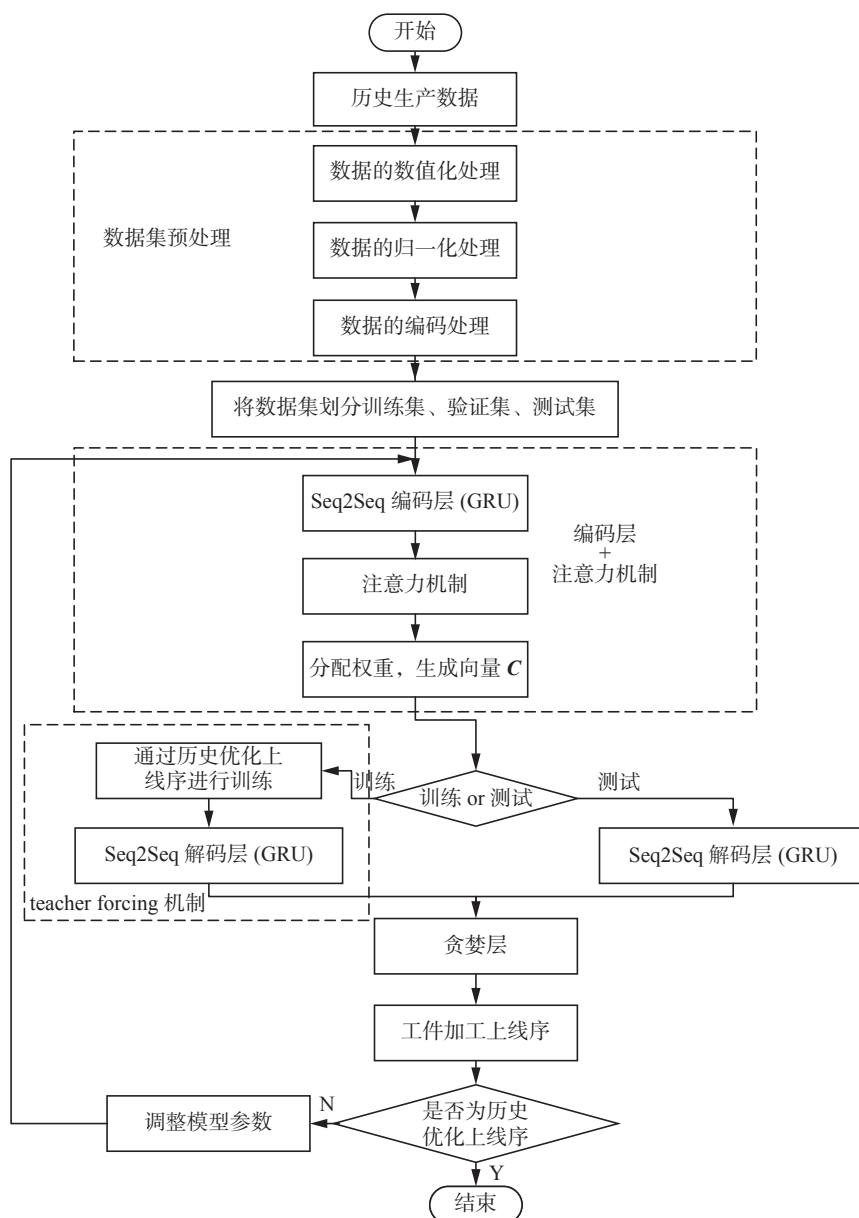


图2 基于深度学习的智能排产优化方法整体流程图

Fig. 2 Overall flow chart of the intelligent scheduling optimization method based on deep learning

### 3) 编码处理

由于 SeqGRU 模型的输入需为向量形式, 因此需要对历史生产数据进行相应的变化。历史生产数据在输入到深度学习模型前可以通过 Tensorflow 的 Embedding 函数实现对数据编码处理, 将输入数据映射成向量。每一次迭代训练提取 64 组生产数据, 将数据编码成三维的向量, 数据编码处理维度变化见表 1。

表 1 数据编码维度变化

Table 1 Data encoding dimension changes

数据形状	数据维度	数据状态
(64, 100)	二维	编码前
(64, 100, 16)	三维	编码后

### 2.3 针对排产优化问题的深度学习模型设计

本文针对排产优化问题, 提出了基于深度学习的柔性流水车间排产优化方法, 该方法核心为基于门控循环单元构建的序列到序列深度学习模型 SeqGRU。模型中的 Seq2Seq 可以实现 2 个不同序列之间的转化, 通过历史生产数据对 SeqGRU 深度学习模型进行训练, 研究生产数据中生产任务信息、工艺信息与排产结果的相关性, 生成工件信息与排产结果的映射关系网络, 快速输出有效的排产结果, 实时指导生产。

#### 2.3.1 序列到序列模型

序列到序列模型 (Seq2Seq) 是一个编码器-解码器结构的神经网络, 模型结构如图 3 所示。




图 3 Seq2Seq 结构

Fig. 3 Seq2Seq structure

编码器和解码器一般都是由循环神经网络 RNN 构成, 其中编码器按照输入序列的顺序读取信息

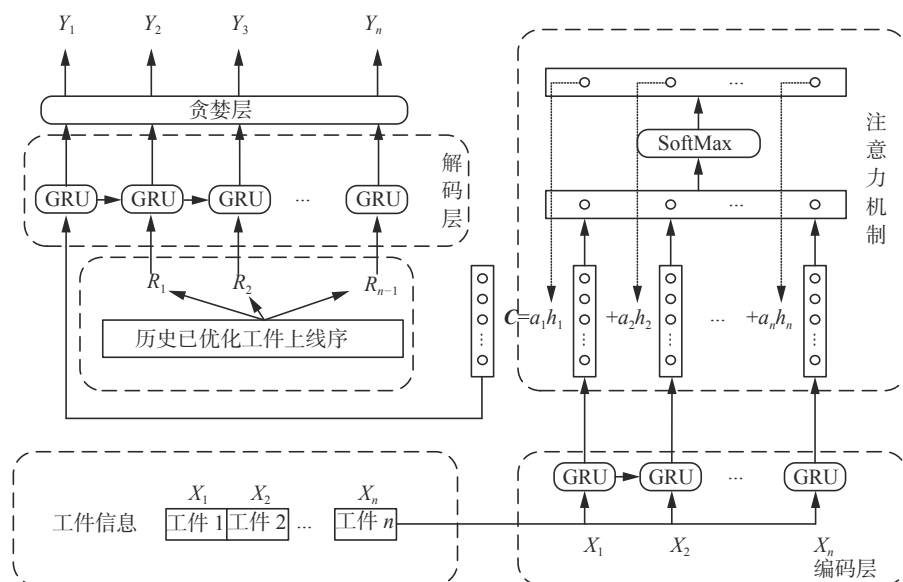


图 4 深度学习模型结构

Fig. 4 Structure of deep learning model

### 1) 门控循环单元

门控循环单元是对循环神经网络研究的较新成果, 门控循环单元有更新门、重置门和候选隐藏状态, 相比于循环神经网络简化了自身结构, 重置门和更新门的设计分别有助于捕捉时序数据中的短期和长期依赖关系, 在提取历史生产数据时序特征的同时还保证了信息的远距离传递。模型的编码层和解码层都是采用单层的门控循环单元组成的循环神经网络, 在编码层中, GRU 通过读取工件的生产信息, 改变自身神经元参数, 再将抽取到的信息特征通过注意力机制聚合成语义向量  $C$ ; 在解码层中, GRU 对语义向量  $C$  进行解码, 再通过贪婪策略选取当

$\{x_1, x_2, \dots, x_n\}$ , 读取信息时, 编码器自身网络的参数也会发生相应的变化, 最后编码器将一个可变长度的信息序列变成了一个固定长度的向量  $C$ , 紧接着解码器在给定隐藏状态条件下, 将固定长度的向量  $C$  变成可变长度的目标信息序列  $\{y_1, y_2, \dots, y_n\}$ 。

### 2.3.2 序列到序列模型应用与改进

Seq2Seq 模型中的递归神经网络 (recursive neural network, RNN) 在处理数据时易发生梯度消失和梯度爆炸, 因此本文使用 GRU 构建 Seq2Seq 模型的编码器和解码器, 门控循环单元神经网络利用自身循环反馈结构来存储历史信息, 保证了信息的远距离传输。模型的解码器生成工件上线序指导实际生产, 并进一步引入注意力机制提高模型的寻优精度和速率。最终将模型应用在实际企业柔性流水生产车间场景, 实现模型与实际工程项目相结合。深度学习模型结构如图 4 所示。

前时间步下概率最大的工件。GRU 结构如图 5 所示。




图 5 门控循环单元

Fig. 5 Gated loop unit

$z_t$ 代表更新门,  $r_t$ 代表重置门,  $g_t$ 代表候选隐藏状态,  $\sigma$ 是激活函数, 在当前时间 $t$ 下,  $x_t$ 代表第 $t$ 时间步的输入工件信息,  $h_{t-1}$ 和 $h_t$ 分别代表前一个时间步 $t-1$ 和当前时间步 $t$ 的记忆。

$$\begin{aligned} z_t &= \sigma(W_z[h_{t-1}, x_t]) \\ r_t &= \sigma(W_r[h_{t-1}, x_t]) \\ g_t &= \tanh(W[g_t * h_{t-1}, x_t]) \\ h_t &= (1 - z_t) * h_{t-1} + z_t * g_t \end{aligned}$$

## 2) 注意力机制

注意力机制可以通过分析输入与输出之间的联系, 对输入数据进行不同的权重分配, 使得模型更加侧重某些信息, 做出更精准判断。注意力机制按照权重取值、编码长度和模型深度3种分类标准可划分出不同的注意力机制模型<sup>[20-21]</sup>。从权重取值可分成软注意和硬注意, 软注意的权重在 $[0, 1]$ 之间; 硬注意力的每个权重要么为0要么为1。从模型深度可分成单层注意和多层注意, 多层注意是在单层注意的基础上对其再进行新的一次权重分配。从编码长度来说, 注意力机制可分为全局注意力和局部注意力。全局注意力不限制输入数据的长度, 可以自动根据输入数据长度来适配, 读取输入数据的所有信息; 局部注意力限制了注意力机制读取输入数据的范围, 有一个特定大小的区间, 当输入数据在区间外, 注意力机制自动进行舍弃。注意力机制可以通过上述3种分类标准中的模型任意组合, 但由于本文深度学习模型在解决排产优化问题需要读取所有的数据信息且每个数据对排产结果都有所影响, 因此本文使用的注意力机制为单层全局软注意力机制。

鉴于每条历史生产数据的工件信息对排产结果的贡献不同, 引入注意力机制来对信息赋予不同的权重。注意力机制的计算公式为

$$C = \sum_{i=1}^n a_i h_i$$

式中:  $n$ 是一组生产数据中包含的工件数目,  $h_i$ 是门控循环单元抽取的第 $i$ 个工件特征,  $a_i$ 是第 $i$ 个工件特征在语义向量中所占的权重,  $C$ 是聚合而成的向量。模型通过注意力机制对各个工件信息进行合理的权重分配, 提高模型寻优的精度。

## 3) teacher forcing 机制

GRU有2种训练模型, 一种是自由振荡模式, 即上一时间步的输出作为下一时间步的输入; 另一种是teacher forcing机制, 即每一时间步的输入都是前一时间步的正确输出结果<sup>[22-23]</sup>。对于本文的深度学习模型来说, 在训练阶段引入teacher

forcing机制不仅可以加快模型的训练速率, 还可以避免模型解码层受个别参数影响导致第一个时间步输出错误后, 之后的时间步输出连错, 加强了模型的稳定性。

## 4) 贪婪层

贪婪策略将求解整个时间步长内最优工件上线序问题分解成在各个时间步下寻求最优解工件, 最后按照时间步先后顺序将对应的工件进行排列, 得到排产结果。通过引入贪婪策略, 增加了模型的寻优稳定性。贪婪策略的原理如图6所示, 在每一时间步下, 选取概率最大的结果, 如概率最大的结果在之前已被选取, 则取用第2大概率的结果, 以此类推。




图6 贪婪策略原理

Fig. 6 Schematic of greedy strategy

## 2.3.3 模型评估方法

本文选取了均方根误差、寻优精度、最小最大完工时间和模型计算时间作为衡量模型的评价指标。

1) 均方根误差。深度学习模型通过训练不断优化输入数据与输出上线序之间关联性的过程实质是预测回归。均方根误差适用于回归问题, 因此引入均方根误差作为评价指标, 均方根误差越小, 说明模型拟合效果越好, 生成的排产结果也越好。本文使用均方根误差来对模型进行评估:

$$E_{\text{RMS}} = \sqrt{\frac{\sum_{i=1}^n (R_i - y_i)^2}{n}}$$

式中:  $R_i$ 是真实值,  $y_i$ 是预测值,  $n$ 表示工件数量。

2) 寻优精度。引入寻优精度评价指标来验证模型的寻优效果。模型每训练完一代, 从验证集中抽取适量数据输入到模型中进行计算, 检测模型输出的上线序是否与数据集中已优化上线序相同。

$$A_{\text{cc}} = \frac{D_t}{D}$$

式中:  $D$ 表示抽取的生产数据数量,  $D_t$ 表示输出的上线序与数据集中已优化上线序相同的生产数据数量。

3) 最小最大完工时间。在求解柔性流水车间排产优化问题过程中, 最常用的评价指标是最小最大完工时间。为体现本文深度学习模型在求解问题的有效性, 引入最小最大完工时间评价指标。



4) 计算时间。求解排产优化问题的深度学习模型只需进行一次初始的迭代训练,之后每次只需输入新的生产任务信息,便能快速得到优化结果。为体现本文深度学习模型在求解问题实时性上的优势,引入模型计算时间评价指标。

### 3 实验结果与分析

为了验证基于深度学习的柔性流水车间排产优化方法的有效性,分析基于门控循环单元构建的序列到序列深度学习模型 SeqGRU 在生产优化问题应用效果,进行多组仿真实验。实验在 Windows10 操作系统下进行,使用的 CPU 为 I7-9750H 六核处理器,使用的显卡为英伟达 RTX2060 显卡,运行内存为 16 GB。软件平台基于 Pycharm 和 Tensorflow1.14 神经网络框架。

#### 3.1 仿真实验数据准备与参数设置

本实验数据源自调研所在企业的柔性流水生产车间,由于企业车间已经具备完善的工件生产追踪和工件数据记录系统,企业保留有大量的工件生产加工数据记录,将这些记录进行整理,按照 6:2:2 的比例将其分为训练集、验证集和测试集,并在仿真实验过程中将数据进行预处理用于深度学习模型的训练。

数据经过编码层、解码层等模型结构自身维度会发生改变,设模型的神经元个数为 256,工件数为 10,预处理编码维度为 16,注意力层深度为 20,数据在模型中每层的输出形状如表 2 所示。

表 2 数据维度变化  
Table 2 Changes in data dimensions

名称	输出形状
输入层	(64, 40)
预处理层	(64, 40, 16)
编码层	(64, 40, 256)
注意力层	(64, 20)
解码层	(64, 11, 24)
输出贪婪层	(1, 10)

#### 3.2 多组方案对排产优化方法评估分析

为了验证基于深度学习的柔性流水车间排产优化方法的应用效果,深入研究 SeqGRU 模型的执行效率和性能,分别从模型中配置的神经元个数、学习率和神经元类型等方面进行仿真实验,并进一步分析引入注意力机制等改进方法对 SeqGRU 模型的影响,构建了 5 组仿真方案,由于基于深度学习的柔性流水车间排产优化方法核心是 SeqGRU 模型,因此前 3 组方案是对模型进行

分析,仿真方案 1,设置不同的神经元个数和学习率,分析 SeqGRU 模型参数对其训练过程中损失值的影响,并评估该模型的执行效率;仿真方案 2,SeqGRU 模型的神经元分别采用 LSTM 和 GRU 的门机制神经元,分析采用不同类型神经元对该模型在训练过程中精度和损失值的影响,进一步评估该模型的执行效率;仿真方案 3,通过在 SeqGRU 模型引入注意力机制,增强模型输入信息与排产结果相关性。建立仿真方案 4 和 5,对基于深度学习的柔性流水车间排产优化方法进行整体性能评估。仿真方案 4,基于深度学习的柔性流水车间排产优化方法有效性验证;仿真方案 5,基于深度学习的柔性流水车间排产优化方法快速性验证。

##### 3.2.1 SeqGRU 模型中神经元个数和学习率参数分析

对于深度学习模型来说,模型的相关参数会影响模型最终的效果。SeqGRU 模型的神经元个数和学习率对最终结果影响较大,因此需要设置不同的神经元个数和学习率来验证最优参数。为了验证门控循环单元中最合适的神经元个数,分别设置了神经元个数为 128、256、512 这 3 种情况进行实验。实验共训练 200 代,模型损失值与迭代次数关系如图 7 所示。




图 7 不同神经元个数下损失值与迭代次数关系

Fig. 7 Relationship between the loss value and the number of iterations under different numbers of neurons

从图 7 中可以看出,模型训练 200 代,3 种神经元个数的损失值都发生了收敛,其中神经元个数为 256 的损失值图像最好,收敛速度最快且最后的损失值可以达到 0.05。相比于神经元个数 256 来说,神经元个数 128、512 的图像收敛速度慢,需要更长的训练迭代次数才可以达到一个优秀的损失值,综上,当门控循环单元神经元个数为 256 时,SeqGRU 模型的效果最好。为了验证模型的最优学习率,设置神经元个数为 256 且分别设置了学习率为 0.05、0.01、0.005 这 3 种情况进行实验。实验共训练 200 代,模型损失值与迭代次数关系如图 8 所示。






图8 不同学习速率下损失值与迭代次数关系

Fig. 8 Relationship between the loss value and the number of iterations under different learning rates

学习率会影响深度学习模型的训练速度,学习率过大会使模型无法收敛,学习率过小会导致模型收敛速度变慢。从图8中可以看出,当学习率为0.01时,SeqGRU模型的损失值图像最好,收敛速度最快。综上2个实验,设置门控循环单元神经元个数为256,模型的学习率为0.01。

### 3.2.2 SeqGRU模型采用不同类型神经元分析

本文使用GRU构建Seq2Seq模型的编码器和解码器,为了验证门控循环单元神经元对模型的有效性,本文设置了2组不同类型的智能决策网络进行了对比实验,分别为:1)编码器和解码器为LSTM<sup>[24]</sup>的Seq2Seq模型;2)编码器和解码器为GRU的Seq2Seq模型。两者神经元个数设为256,模型学习率设为0.01,模型的精度和损失值与迭代次数关系如图9、10所示。




图9 不同类型的智能决策网络对SeqGRU模型损失值与迭代次数的关系

Fig. 9 Relationship between the loss value of the SeqGRU model and the number of iterations by different types of intelligent decision-making networks




图10 不同类型的智能决策网络对SeqGRU模型精度与迭代次数的关系

Fig. 10 Relationship between the accuracy of the SeqGRU model and the number of iterations by different types of intelligent decision-making networks

从图9、10可以看出,编解码器为GRU和LSTM都可以生成有效的排产结果。LSTM训练时长为950 s,GRU训练时长为640 s,GRU相比于LSTM训练时间更短,且在相同迭代次数下,GRU的损失值和精度总是优于LSTM,这是因为GRU结构比LSTM结构更简单,GRU相比于LSTM少了一个记忆细胞,参数变少,处理时间也相应变短。综上,当编码器和解码器为GRU网络时,模型的效果最好且消耗的计算资源最少。

### 3.2.3 SeqGRU模型中引入注意力机制分析

注意力机制根据历史生产数据中的工件信息重要程度赋予不同的权值,直接评估哪些输入是解码器的首选输入,提高模型的精度和运行速度。注意力机制在模型的编码层与解码层之间,设置模型GRU的神经元个数为256,模型的学习率为0.01,模型的精度和损失值图像如图11、12。




图11 引入注意力机制后损失值与迭代次数的关系

Fig. 11 Relationship between the loss value and the number of iterations after the introduction of the attention mechanism




图12 引入注意力机制后精度与迭代次数的关系

Fig. 12 Relationship between the accuracy and the number of iterations after the introduction of the attention mechanism

从图11、12可以看出,注意力机制可以加快SeqGRU模型的训练速度,并且在相同的迭代次数下,总可以达到更优的结果。同时模型每迭代训练一次,便会从验证集中抽取若干组生产数据放入模型中进行计算,再将得到的排产结果与数据集中的最优上线序进行比对,最终当模型收敛时,精度可以达到98%,验证了该模型对于解决排产优化问题具有良好的效果。

上述SeqGRU深度学习模型中的注意力机制

为单层全局软注意力机制,对于排产优化问题,每个输入数据对排产结果或多或少都有所影响,因此注意力机制必须选用全局软注意力机制,确保注意力机制可以读取到所有数据并给每个数据赋予一个精确的值。为验证 SeqGRU 深度学习模型中的单层全局软注意力机制更适用于解决排产优化问题,本文将单层全局软注意力机制与多层全局软注意力机制进行对比实验,实验结果如表 3 所示。

表 3 注意力机制对比  
Table 3 Attention mechanism comparison

名称	精度/%	收敛时间/min
单层全局软注意力机制	97.8	6
两层全局软注意力机制	97.5	9
三层全局软注意力机制	96.9	17
四层全局软注意力机制	95.8	28

从表 3 可以看出,随着全局软注意力机制层数的增多,注意力机制每一层都需要对上一层输出的数据重新进行分析并赋予权重,从而导致 SeqGRU 深度学习模型的运算量不断增加,因此模型收敛时间越来越长,并且由于注意力机制层数不断增加,模型对数据的过度分析导致了过拟合问题,模型的精度反而下降,因此 SeqGRU 深度学习模型需引入单层全局软注意力机制。

### 3.2.4 基于深度学习的智能排产优化方法验证

本文以柔性流水车间为应用对象的基于深度学习的智能排产优化方法利用历史生产数据进行学习训练,在训练完成后,只需要输入工件信息,便可直接输出有效的工件上线序指导实际生产。为验证本文排产优化方法在求解问题的有效性,引入最小最大完工时间作为评价指标,并将本文的排产优化方法与遗传算法 (genetic algorithm, GA) 和狼群算法 (wolf pack algorithm, WPA) 进行对比实验。

针对小规模数据,测试数据来自于 Carlier 和 Neron 针对柔性流水车间提出的标准算例,从中选取 3 组易解数据  $j_1$ 、 $j_2$ 、 $j_3$  和 3 组难解数据  $j_4$ 、 $j_5$ 、 $j_6$ ,将本文的排产优化方法与 GA、WPA 算法进行对比实验,实验结果如表 4 所示。 $B_s$  表示 Carlier 和 Neron 算例的最优解并在文献 [25] 中给出,为  $\min F_{\max}$  为算法求解的最小最大完工时间,通过偏差  $d$  来衡量模型的有效性,偏差  $d$  越小,模型的性能越好,偏差  $d$  的公式为

$$d = ((\min F_{\max} - B_s) / B_s) \times 100\%$$

表 4 小规模数据算法对比  
Table 4 Small-scale data algorithm comparison

数据	$B_s$ / min	深度学习模型		GA		WPA	
		$\min F_{\max}$ / min	$d$ / %	$\min F_{\max}$ / min	$d$ / %	$\min F_{\max}$ / min	$d$ / %
$j_1$	67	67	0	67	0	67	0
$j_2$	77	77	0	77	0	77	0
$j_3$	82	82	0	82	0	82	0
$j_4$	110	118	7.27	124	12.73	122	10.9
$j_5$	124	135	8.87	142	14.52	140	12.9
$j_6$	141	154	9.28	163	15.6	160	13.47

从表 4 可以看出,本文的排产优化方法和 GA、WPA 在求解易解数据时都可以达到最优的效果。对于难解数据来说,本文的排产优化方法偏差比其他 2 种算法要小很多。显然,对于小规模数据来说,本文的排产优化方法求解柔性流水车间排产优化问题具有有效性且比其他 2 种算法有更好的表现。

针对大规模数据,从测试集中选取 50、100、200、400 组数据进行测试, $\overline{B_s}$  为这些数据已优化的最小最大完工时间平均值, $\overline{\min F_{\max}}$  为算法求解的最小最大完工时间的平均值,通过偏差  $d$  来衡量模型的有效性,实验结果如表 5 所示。

表 5 大规模数据算法对比  
Table 5 Large-scale data algorithm comparison

数据 规模	$\overline{B_s}$ / min	深度学习模型		GA		WPA	
		$\min F_{\max}$ / min	$d$ / %	$\min F_{\max}$ / min	$d$ / %	$\min F_{\max}$ / min	$d$ / %
50	105.5	109.4	3.7	110.9	5.12	110.5	4.74
100	110.7	117.8	6.41	120.9	9.21	119.8	8.22
200	114.6	124.6	8.73	126.4	10.29	125.7	9.69
400	119.6	131.3	9.78	136.1	13.79	134.7	12.62

从表 5 可以看出,本文的排产优化方法和 GA、WPA 随着数据规模不断扩大,偏差都增大,但 GA 和 WPA 的增长幅度更明显,且本文的排产优化方法在数据规模增长到一定规模后,偏差增长幅度变缓。由上述仿真结果可知,基于深度学习的柔性流水车间排产优化方法在处理大规模数据时比其他 2 种算法具有更好的效果。

### 3.2.5 基于深度学习的智能排产优化方法快速性验证

用于求解排产优化问题的 SeqGRU 深度学习模型只需进行一次初始的迭代训练,之后每次只

需输入生产任务信息,便能快速得到优化结果。为了验证本文排产优化方法在求解问题实时性上的优势,引入计算时间作为评价指标,将深度学习模型与GA、WPA进行了比较。随机抽取若干组工件信息输入到深度学习模型和GA、WPA中进行计算,横坐标为工件数据组数,纵坐标为模型计算时间,3组模型的对比如图13所示。




图13 深度学习模型与遗传算法、狼群算法的对比

Fig. 13 Comparison of deep learning model with genetic algorithm and wolf pack algorithm

由图13可以看出,GA和WPA随着组数不断增多,模型计算时间大幅度增加,且遗传算法增加幅度大于狼群算法,而本文的排产优化方法在训练一次之后,便可快速输出任意组新任务的优化结果,且随着组数增多,模型计算时间增加的并不明显,由此可以看出本文的排产优化方法在实时性上的优势。

## 4 结束语

本文提出的基于深度学习的智能排产优化方法通过对历史生产数据学习训练能够快速给出有效的排产结果。SeqGRU模型采用GRU构建Seq2Seq模型的编码器和解码器,模型解码器输出工件上线序,并引入注意力机制提高了寻优的精度和速率。最后通过实验验证了所提方法对解决全局排产优化问题的有效性和实时性。本模型填补了深度学习解决全局排产优化问题的空缺,下一步将对该模型进行扩展优化,引入更复杂的排产优化问题进行研究,并将该模型部署至实际的生产管理系统中,以测试模型的实际应用效果。

## 参考文献:

- [1] KHAMSEH A, JOLAI F, BABAEI M. Integrating sequence-dependent group scheduling problem and preventive maintenance in flexible flow shops[J]. The international journal of advanced manufacturing technology, 2015, 77(1): 173–185.
- [2] GERSTL E, MOSHEIOV G, SARIG A. Batch scheduling in A two-stage flexible flow shop problem[J]. Foundations of computing and decision sciences, 2014, 39(1): 3–16.
- [3] 王玉芳, 缪昇, 马铭阳, 等. 改进混合遗传算法的作业车间调度研究[J]. 现代制造工程, 2021(5): 32–38.  
WANG Yufang, MIAO Sheng, MA Mingyang, et al. Research on job shop scheduling based on improved hybrid genetic algorithm[J]. Modern manufacturing engineering, 2021(5): 32–38.
- [4] 孟磊磊, 张彪, 任亚平, 等. 求解分布式柔性作业车间调度的混合蛙跳算法[J/OL]. 机械工程学报: 1–10. [2021–07–11]. <http://kns.cnki.net/kcms/detail/11.2187.th.20210608.1314.213.html>.  
MENG Leilei, ZHANG Biao, REN Yaping, et al. Hybrid leapfrog algorithm for distributed flexible job shop scheduling[J/OL]. Chinese journal of mechanical engineering: 1–10. [2021–07–11]. <http://kns.cnki.net/kcms/detail/11.2187.th.20210608.1314.213.html>.
- [5] 李杨, 杨明顺, 陈曦, 等. 一种流水车间预测性维护与生产调度集成优化方法[J]. 机械科学与技术, 2022, 41(7): 1055–1061.  
LI Yang, YANG Mingshun, CHEN Xi, et al. Integrated optimization of predictive maintenance and production scheduling for flow-shop[J]. Mechanical science and technology for aerospace engineering, 2022, 41(7): 1055–1061.
- [6] 鲁华祥, 尹世远, 龚国良, 等. 基于深度确定性策略梯度的粒子群算法[J]. 电子科技大学学报, 2021, 50(2): 199–206.  
LU Huaxiang, YIN Shiyuan, GONG Guoliang, et al. A particle swarm optimization algorithm based on deep deterministic policy gradient[J]. Journal of University of Electronic Science and Technology of China, 2021, 50(2): 199–206.
- [7] 张强, 李盼池. 进化策略自主选择的改进混洗蛙跳算法[J]. 哈尔滨工程大学学报, 2019, 40(5): 979–985.  
ZHANG Qiang, LI Panchi. An improved shuffled frog leaping algorithm for the autonomous selection of evolutionary strategies[J]. Journal of Harbin Engineering University, 2019, 40(5): 979–985.
- [8] 王林, 吕盛祥, 曾宇容. 果蝇优化算法研究综述[J]. 控制与决策, 2017, 32(7): 1153–1162.  
WANG Lin, LYU Shengxiang, ZENG Yurong. Literature survey of fruit fly optimization algorithm[J]. Control and decision, 2017, 32(7): 1153–1162.
- [9] 张水平, 王碧, 陈阳. 基于逐层演化的群体智能算法优化[J]. 工程科学学报, 2017, 39(3): 462–473.  
ZHANG Shuiping, WANG Bi, CHEN Yang. Optimization for swarm intelligence based on layer-by-layer evolution[J]. Journal of university of science and technology Beijing, 2017, 39(3): 462–473.
- [10] LUO Shu, ZHANG Linxuan, FAN Yushun. Dynamic multi-objective scheduling for flexible job shop by deep



- reinforcement learning[J]. Computers & industrial engineering, 2021, 159: 107489.
- [11] 朱泓睿, 元国军, 姚成吉, 等. 分布式深度学习训练网络综述 [J]. 计算机研究与发展, 2021, 58(1): 98–115.  
ZHU Hongrui, YUAN Guojun, YAO Chengji, et al. Survey on network of distributed deep learning training[J]. Journal of computer research and development, 2021, 58(1): 98–115.
- [12] 陈伟宏, 安吉尧, 李仁发, 等. 深度学习认知计算综述 [J]. 自动化学报, 2017, 43(11): 1886–1897.  
CHEN Weihong, AN Jiyao, LI Renfa, et al. Review on deep-learning-based cognitive computing[J]. Acta automatica sinica, 2017, 43(11): 1886–1897.
- [13] 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 Xiuli, SUN Lin. Data-based real-time scheduling in smart manufacturing[J]. Control and decision, 2020, 35(3): 523–535.
- [14] 任剑锋, 叶春明. 嵌入指针网络的深度循环神经网络模型求解作业车间调度问题 [J]. 计算机应用研究, 2021, 38(1): 120–124, 128.  
REN Jianfeng, YE Chunming. Method to solve job-shop scheduling problem using deep recurrent neural network model with embedded pointer network[J]. Application research of computers, 2021, 38(1): 120–124, 128.
- [15] 侯智, 陈进, 陈倩, 等. 面向不确定信息的神经网络完工期预测方法研究 [J]. 机械设计与研究, 2017, 33(3): 116–119, 130.  
HOU Zhi, CHEN Jin, CHEN Qian, et al. Predictive method of product due date toward uncertain information based on neural network[J]. Machine design & research, 2017, 33(3): 116–119, 130.
- [16] 何军红, 马国伟, 刘赛, 等. MES 柔性作业车间调度优化算法的研究 [J]. 工业仪表与自动化装置, 2020(1): 26–32.  
HE Junhong, MA Guowei, LIU Sai, et al. Research on MES flexible job shop scheduling optimization algorithm[J]. Industrial instrumentation & automation, 2020(1): 26–32.
- [17] 游兰, 韩雪薇, 何正伟, 等. 基于改进 Seq2Seq 的短时 AIS 轨迹序列预测模型 [J]. 计算机科学, 2020, 47(9): 169–174.  
YOU Lan, HAN Xuewei, HE Zhengwei, et al. Improved sequence-to-sequence model for short-term vessel trajectory prediction using AIS data streams[J]. Computer science, 2020, 47(9): 169–174.
- [18] 郑宗生, 刘敏, 胡晨雨, 等. 基于 Seq2Seq 和 Attention 的时序卫星云图台风等级预测 [J]. 遥感信息, 2020, 35(4): 16–22.  
ZHENG Zongsheng, LIU Min, HU Chenyu, et al. Prediction of typhoon grade with time series typhoon satellite images based on Seq2Seq and attention[J]. Remote sensing information, 2020, 35(4): 16–22.
- [19] 吴俊杰, 刘冠男, 王静远, 等. 数据智能: 趋势与挑战 [J]. 系统工程理论与实践, 2020, 40(08): 2116–2149.  
WU Junjie, LIU Guannan, WANG Jingyuan, et al. Data intelligence: trends and challenges[J]. Systems engineering theory and practice, 2020, 40(08): 2116–2149.
- [20] 王倩雯, 张延华, 付琼霄, 等. 基于双重注意力机制的降噪自编码器推荐算法 [J]. 高技术通讯, 2020, 30(12): 1234–1242.  
WANG Qianwen, ZHANG Yanhua, FU Qiongxiao, et al. A denoising autoencoder algorithm for recommendation based on dual attention mechanism[J]. Chinese high technology letters, 2020, 30(12): 1234–1242.
- [21] 张津, 魏峰远, 冯凡, 等. 基于注意力机制和编码解码网络的遥感影像分类 [J]. 测绘科学技术学报, 2020, 37(6): 610–615.  
ZHANG Jin, WEI Fengyuan, FENG Fan, et al. Remote sensing imagery classification based on attention mechanism and encoder-decoder network[J]. Journal of geomatics science and technology, 2020, 37(6): 610–615.
- [22] 刘敖迪, 杜学绘, 王娜, 等. 基于深度学习的 ABAC 访问控制策略自动化生成技术 [J]. 通信学报, 2020, 41(12): 8–20.  
LIU Aodi, DU Xuehui, WANG Na, et al. ABAC access control policy generation technique based on deep learning[J]. Journal on communications, 2020, 41(12): 8–20.
- [23] 苏佳媛. 基于深度学习技术的智能化无人机视觉系统设计研究 [J]. 工业设计, 2020(12): 152–153.  
SU Jiayuan. Research on the design of smart uav vision system based on deep learning technology[J]. Industrial design, 2020(12): 152–153.
- [24] KIM J, KIM J, HUONG L T T, et al. Long short term memory recurrent neural network classifier for intrusion detection[C]//2016 International Conference on Platform Technology and Service. Jeju: IEEE, 2016: 1–5.
- [25] SANTOS D L, HUNSUCKER J L, DEAL D E. Global lower bounds for flow shops with multiple processors[J]. [European journal of operational research](#), 1995, 80(1): 112–120.

## 作者简介:



韩忠华, 教授, 博士, 主要研究方向为生产运作管理、企业自动化系统集成技术、车间排产与生产调度算法工程应用。主持和参与国家级、省部级科研项目 24 项, 获知识产权共 16 项, 参与编制国家标准 2 项。发表学术论文 43 篇。



黎恺嘉, 硕士研究生, 主要研究方向为生产优化、深度学习。



周晓锋, 副研究员, 博士, 主要研究方向为工业大数据分析。

## 第三届国际人工智能会议 CAAI International Conference on Artificial Intelligence 2023

由中国人工智能学会主办, 第三届国际人工智能会议 (CAAI International Conference on Artificial Intelligence 2023, CICA I 2023) 将于 2023 年 7 月 22—23 日在中国福州召开。CICA I 2023 面向全球征集论文 (Paper) 及演示论文 (Demo), 以探讨人工智能领域的前沿技术、挑战和发展方向。CICA I 2023 录用的论文, 将由 Springer 出版社出版、EI 收录。此外, 本届会议还将推出 GigaVision 挑战赛, 旨在聚焦十亿像素级视觉智能的研究和应用。挑战赛提供丰厚奖金, 期待全球顶尖人才和团队积极参与。

### 论文投稿

CICA I 2023 投稿需为原创论文、英文撰写、单栏排版、长度不超过 10 页 (正文)+2 页 (参考文献)。会议将采用双盲审稿机制, 录用论文由 Springer 出版社出版, EI 收录。部分优秀论文将推荐投稿至“CAAI Artificial Intelligence Research”“Science China Information Sciences”“Journal of Tsinghua University (Science and Technology)”“Journal of Computer Science and Technology”等 SCI 期刊特辑进行发表。

### 演示投稿

CICA I 2023 演示论文投稿需原创论文、英文撰写、单栏排版、长度不超过 4 页 (正文)+2 页 (参考文献)、简短的视频介绍 (不超过 5min, 投稿系统中以补充材料形式上传)。演示投稿将采用单盲审稿机制。被录用的演示论文需要至少一位作者参会, 并进行会议现场演示。本次大会设立最佳演示奖用于鼓励原创性和实用性俱佳的演示论文。

### GigaVision 挑战赛

挑战赛聚焦 GigaVision 十亿像素大场景多对象复杂关系前沿技术, 共设置三大赛道, 包括十亿像素图像多对象检测 (GigaDetection)、十亿像素视频多对象轨迹预测 (GigaTrajectory)、十亿像素三维重建 (GigaReconstruction)。目前 GigaTrajectory、GigaReconstruction 赛道仍在报名中。为了鼓励广大人工智能爱好者积极参与、持续挑战, 赛道将开展冲刺进步奖 (6 月 15—21 日) 等多项激励活动, 期待您加入我们, 共享创新竞技生态!

### 重要信息

会议主页: <https://cicai.ccai.cn/>

挑战赛页: <https://gigavision.cn>

投稿网址: <https://cmt3.research.microsoft.com/CICA I 2023>

作者须知: <https://cicai.ccai.cn/#/instruction>

征文截止日期: 2023 年 6 月 30 日

会议录用通知日期: 2023 年 7 月 10 日

会议终稿截止日期: 2023 年 7 月 15 日

会议日期: 2023 年 7 月 22—23 日