

基于 Transformer 大模型的船体曲面分段车间排产与调度优化

徐胜超¹, 吕峻闽¹, 蒋大锐¹, 秦泰²

(1. 广州华商学院 人工智能学院, 广州 511300;

2. 武汉凌久微电子有限公司, 武汉 430077)

摘要: 提出基于 Transformer 大模型的船体曲面分段车间排产与调度优化方法; 设计资源冲突消解策略处理车间资源冲突问题, 合理设置工件移动路径并进行工序分割, 然后将船体曲面分段建造资源冲突消解策略、工序分割结果以及当前分段建造任务数量、工作班组数量等作为输入, 利用 Transformer 大模型, 以总完工时间最小为目标构建排产与调度目标函数, 并将资源均衡性作为重要考量指标, 输出排产与调度优化结果; 实验表明: 该方法能科学管控任务和多班组协作, 有效提升资源利用率与执行效率; 资源均衡性表现优异, 10 种设备资源均衡度均在 0.7 以上; 建造任务的实际耗时均低于预计时间, 能够显著缩短任务完成时间, 为船舶制造行业提供了创新有效的生产优化途径。

关键词: 人工智能; 大模型; 船体曲面; 分段车间; 排产与调度; 优化方法

Optimization of Production and Scheduling for Ship Surface Segmentation Workshop Based on Transformer Large Model

XU Shengchao¹, LÜ Junmin¹, JIANG Darui¹, QIN Tai²

(1. School of Artificial Intelligence, Guangzhou Huashang College, Guangzhou 511300, China;

2. Wuhan Lingjiu Microelectronics Co., Ltd., Wuhan 430077, China)

Abstract: Based on a Transformer big model, a production and scheduling optimization method for ship surface segmentation workshop was proposed. Design a resource conflict resolution strategy to address workshop resource conflicts, reasonably set a movement path for a workpiece, and perform a process segmentation. Then, by taking the segmentation construction resource conflict resolution strategy for the ship surface, the process segmentation results, the numbers of current segmented construction tasks, and the numbers of work teams as inputs, the Transformer large model is utilized to construct a production scheduling and dispatching objective function with the minimum total completion time as the goal, while considering resource balance as an important indicator, ultimately outputting the optimal production scheduling and dispatching results. Experimental results shows that this method can scientifically control tasks and multi-team collaboration, effectively improving resource utilization and execution efficiency, with an excellent resource balance performance, and the resource balance for 10 types of devices reaches over 0.7. The actual time taken for the task is consistently lower than the expected time, which can significantly shorten the completion time of the task, providing an innovative and effective production optimization approach for the shipbuilding industry.

Keywords: artificial intelligence; large model; ship surface; segmented workshop; production and scheduling; optimization method

收稿日期: 2025-07-26; 修回日期: 2025-10-27。

基金项目: 国家自然科学基金面上项目(61772221); 广州华商学院校级重点培育科研项目(2024HSZD01); 武汉凌久微电子有限公司 2025 年企业开放课题(2025HSHX08)。

作者简介: 徐胜超(1980-), 男, 硕士, 副教授。

吕峻闽(1970-), 男, 博士, 教授。

蒋大锐(1986-), 男, 博士, 副教授。

引用格式: 徐胜超, 吕峻闽, 蒋大锐, 等. 基于 Transformer 大模型的船体曲面分段车间排产与调度优化[J]. 计算机测量与控制, 2026, 34(4): 224-231.

0 引言

当下船舶制造产业蓬勃发展,船体曲面分段车间的高效运作极为重要^[1]。其生产涉及复杂工序与大量资源调配,各工序关联紧密,设备资源有限且任务分配动态,排产调度极具挑战。传统人工经验方式难以满足需求,致使效率低、浪费大、工期常延误,增加成本并削弱竞争力。引入先进优化技术成为行业突破瓶颈的关键^[2-3]。现在已有很多学者研究船体曲面分段车间排产与调度优化方法。

文献[4]提出生产线数字孪生的排班优化方法,该方法构建生产线的数字孪生模型,利用数字孪生模型对不同的排产方案进行模拟,实现车间排产与调度优化。但数字孪生模型与实际生产线存在偏差,从而影响排产与调度优化的效果。文献[5]提出生产调度优化模型,确定约束条件,依据粒子群优化算法对该模型进行求解后,实现车间排产与调度优化。但生产车间的环境是动态变化的,模型难以快速适应,准确性受限。文献[6]提出生产订单的联合调度维修任务排序方法,组建决策群体,利用启发式算法生成排产与维修任务排序方案,实现车间排产与调度优化,但群体决策成员过多,在面对紧急生产情况或复杂问题时,难以快速做出决策。文献[7]提出了基于时空约束的船体曲面分段车间调度方法研究,构建了融合吊装运输空间限制、设备协同约束及工序逻辑关系的多维约束模型,采用改进的遗传算法进行多目标优化,设计了时空冲突检测机制与动态优先级调整策略,并引入模拟退火算法增强局部搜索能力,有效缩短典型曲面分段生产场景中工期。但实际车间存在设备故障、任务变更等突发扰动,静态优化方法可能无法实时调整调度方案,影响鲁棒性。文献[8]提出了基于人工智能大模型的舰船调度优化方法,通过构建港口—船舶—航线的多维数字孪生环境,利用分层强化学习框架分别训练港口资源分配智能体和船舶路径规划智能体,并在仿真环境中进行协同策略优化,从而实现动态环境下的全局调度决策。该方法的实施成本和复杂性非常高,模型的性能可能会急剧下降。

人工智能大模型其优势在于强大的数据处理与智能决策能力^[9]。大模型能够高效整合船体曲面分段车间排产与调度多源异构数据,包括设备状态、工序逻辑、空间约束等,通过深度学习与强化学习算法实现复杂约束下的动态优化排产,显著减少传统方法中常见的时空冲突与资源闲置问题。大模型支持多目标协同优化,在工期、成本、能耗等关键指标间实现平衡,避免单一目标导向的局限性^[10]。此外,大模型的自然语言交互能力为车间管理人员提供直观的决策支持,通过可解释的调

度建议降低人机协作门槛。这些特性使大模型成为提升船体曲面分段制造效率与灵活性的关键技术,推动造船车间向智能化、自适应方向演进。

本文提出基于Transformer大模型的船体曲面分段车间排产与调度优化方法,设计资源冲突消解策略与工序分割方法,并融合Transformer架构创建智能优化模型。利用多约束条件下的资源冲突智能消解算法,以最小化总完工时间为目标的Transformer强化学习框架,同步优化资源均衡性。

本研究克服了传统调度局限,实现三大突破:配件任务完成时间明显缩短,显著压缩生产周期;10类设备均衡度均超0.7;支持多班组协同作业的动态优化。研究成果为船舶智能制造提供了可参考的高效排产范式,其人工智能驱动的方法论可扩展至其他复杂装备制造场景。

1 资源冲突消解处理策略

船体曲面分段车间排产与调度问题可定义为在有限资源(设备、人力、空间)与复杂工艺约束下,对多品种、小批量的曲面分段建造任务进行工序排序、资源分配与时间安排,以实现总完工时间最短、资源利用率最高等优化目标的组合优化问题。该问题的复杂性源于其多工序耦合、资源竞争激烈以及时空约束严苛等特点:工序间存在严格的先后逻辑关系,部分关键设备(如大型焊接机器人、折弯机)成为瓶颈资源,不同分段在车间内的吊装、转运路径存在空间干涉风险。此外,任务动态到达、设备故障等随机扰动进一步增加了调度的不确定性。传统方法在全局优化与动态响应方面存在局限,亟需引入能够捕捉长程依赖、处理多源异构数据并支持实时决策的智能优化方法。

构建资源冲突消解模型,在资源冲突消解模型内,将资源、管理、产品均视为智能体,先利用资源智能体对当前资源进行检测,若存在资源冲突,则将冲突的资源放入阻塞队列中^[11-13],然后使用管理智能体对资源冲突类型进行分析,依据分析结果,使用产品智能体选择适当的冲突消解策略。

在上述过程中,冲突消解策略定义与量化方法如下:

1) 关键任务优先策略:

在船体曲面分段建造多个生产任务共同进行时^[14],当生产任务 T_i 和 T_j 竞争同一资源而产生冲突时,采用该策略。任务的关键程度 $C(T_k)$ 通过其在项目关键路径上的位置及其延期对总工期的影响来量化评估。具体定义为:

$$C(T_k) = \alpha \cdot I_{\text{CPM}}(T_k) + \beta \cdot \frac{LST_k - EST_k}{T_{\text{total}}} \quad (1)$$

其中: $I_{\text{CPM}}(T_k)$ 为关键路径法(CPM)标识符,若

任务 T_k 位于关键路径上则取值为 1，否则为 0； LST_k 与 EST_k 分别为任务 T_k 的最晚开始时间与最早开始时间； T_{total} 为项目总工期估计； α 与 β 为权重系数，满足 $\alpha + \beta = 1$ ，用于平衡关键路径状态与时间浮动的影响。依据此量化评估，将关键程度 $C(T_k)$ 较高的生产任务 T_k 优先分配资源并执行。

2) 等待时间最短策略：

当生产任务 T_i 和 T_j 之间存在资源冲突，且经评估二者关键程度 $C(T_i)$ 与 $C(T_j)$ 相同或差值低于预设阈值 δ 时，启用此策略。任务的等待时间 $W(T_k)$ 在此定义为：若该任务因资源冲突而被迫延迟，其预计需要等待资源释放的时间长度。该时间与任务本身所需的资源占用时长 D_k 正相关，并受资源当前被占用的剩余时长影响。策略将优先分配资源给等待时间较短的任务，即满足：

$$\min[W(T_i), W(T_j)] \tag{2}$$

此策略旨在最小化由资源竞争导致的系统总等待时间，从而降低资源闲置率，提升整体作业效率^[15]。

3) 先来先得策略：

当生产任务 T_i 和 T_j 之间存在资源冲突，且其关键程度 $C(T_k)$ 相近（差值低于阈值 δ ），同时预估的等待时间 $W(T_k)$ 也差别不大（差值低于另一阈值 θ ）时，采用此策略以保证分配的公平性与操作简洁性。该策略依据任务到达资源请求队列的时间戳 $A(T_k)$ 进行决策，优先处理先到达的任务，即：

$$\min[A(T_i), A(T_j)] \tag{3}$$

此策略避免了复杂的实时计算，在冲突任务优先级难以区分时，提供了一种稳定且易于实现的决策依据。

智能体资源监控工作机制如图 1 所示。




图 1 智能体资源监控工作机制框图

资源智能体通过嵌入式传感器、物料流转及数字孪生接口实时采集三元资源状态，构建多维监控数据池；管理智能体基于规则引擎解析数据；设备冲突检测采用负载率阈值模型，人力冲突采用技能-任务匹配度矩阵，物料冲突通过库存-需求时序偏差分析；当检测到冲突特征向量时，触发状态转移方程，将资源移入阻塞队列，同时激活产品智能体的多级决策模块，最终生成资源重分配指令闭环反馈至执行终端，实现冲突消解与系统状态跃迁。

2 船体曲面分段车间工件移动路径设置与工序分割

在船体曲面分段车间内，参加排产的工件存在较大差异，其在车间内不同工序间移动路径也不同，在对船体曲面分段车间排产时，需要先明确工序移动路径^[16-17]。但在船体曲面分段车间工序内，存在瓶颈资源，即产能相对不足、限制整体生产效率提升、使生产流程受到制约的资源^[18]。

比如在车间排产场景下，它是制约全局性排产优化的关键因素^[19-20]，对其利用率最大化是实现全局最优排产的关键。船体曲面分段车间内，有的工件加工需要经过瓶颈资源，有的工件均由非瓶颈设备加工，因此设置船体曲面分段车间工件移动路径如图 2 所示。




图 2 船体曲面分段车间工件移动路径

图 2 中，在船体曲面分段车间，加工任务分为两类。类别 1 的工件先经过非瓶颈资源加工，接着由瓶颈资源处理，最后再由非瓶颈资源完成后续加工；类别 2 的工件全程由非瓶颈资源进行加工，两类工件最终都形成成品。在船体曲面分段车间工件移动路径基础上，对船体曲面分段车间工件加工工序进行分割处理，为了提升瓶颈资源利用率^[21]，将瓶颈资源加工工序之前的工序按照倒排方式进行，瓶颈资源加工工序之后的工序按照正排方式进行，工序分割如图 3 所示。




图 3 工序分割示意图

图 3 中，工序分割策略的核心依据是约束理论 (TOC, theory of constraints)，旨在通过聚焦于瓶颈资源的管理来提升整个生产系统的产出。对于瓶颈工序之前的非瓶颈工序，采用“倒排”方式。即以瓶颈工序的计划开始时间为基准，反向推导前序各非瓶颈工序的最晚开始和结束时间。这种方式可以确保前序物料和半成品恰好在瓶颈资源需要时准备就绪，从而最大限度地减少瓶颈工序前的在制品库存和等待时间，避免资源闲置。对于瓶颈工序之后的非瓶颈工序，采用“正排”方

式。即以瓶颈工序的完成时间为起点,顺序安排后续各非瓶颈工序的最早开始时间。这种方式能够确保一旦工件离开瓶颈资源,便尽快流向后道工序并最终完成,加速物料流转,缩短订单的整体通过时间,并快速释放资源给后续任务。

将图3内的倒排阶段作为第1个阶段,正排阶段作为第2阶段,在第1个阶段所有工序完成后,再进行第2阶段工序生产。

3 基于Transformer船体曲面分段车间排产与调度优化

3.1 船体曲面分段车间排产与调度设计

船体曲面分段车间生产流程复杂,涉及众多工序与设备,大模型Transformer架构能同时关注输入序列(如工序顺序、设备状态等信息序列)的所有元素,直接建立任意两个元素间的联系,有效捕捉工序先后顺序、不同设备状态关联等长距离依赖关系,全面把握生产全局信息,为排产与调度优化提供精准信息支持。

本研究使用人工智能大模型中的Transformer架构实现船体曲面分段车间排产与调度,该架构如图4所示。

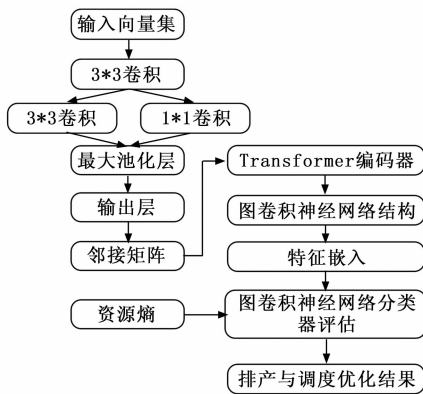


图4 人工智能大模型Transformer架构

Transformer架构通过多模块协同实现船体曲面分段车间排产优化:特征嵌入层将工序、设备等离散变量映射为连续向量空间并注入位置编码;多头自注意力层并行捕获工序间的长距离依赖关系,建立全局关联;前馈神经网络对特征进行非线性变换以增强模型表达能力;图卷积网络作为辅助模块,以工序为节点、设备关联为边,通过邻域聚合优化局部调度决策;解码器基于自注意力层和图卷积网络输出的全局一局部特征,动态生成排产序列并分配资源。各模块形成级联架构——嵌入层为输入表征基础,自注意力层与前馈网络构建全局特征,图卷积网络强化局部约束建模,解码器综合所有信息输出优化调度方案,最终实现生产周期最小化目标。

图4具体模块设计与参数设置如下:

1) 特征嵌入层:将工序类型、设备编号、资源状态等离散变量通过嵌入矩阵映射为512维连续向量,保留语义信息;同时引入正弦一余弦位置编码,以区分工序在序列中的先后顺序,增强模型对时序关系的建模能力。

2) 多头自注意力层:设置8个注意力头,每头维度为64,通过并行计算捕捉工序间复杂的依赖关系(如曲面焊接与分段装配的时序约束)。头数的选择基于输入特征维度(512)与计算效率的平衡,确保模型在捕捉全局信息的同时保持训练稳定性。

3) 前馈神经网络:采用两层全连接结构,隐藏层维度为2048,激活函数为GELU,以增强模型的非线性表达能力。该模块对自注意力层输出的特征进行进一步变换,提升模型对复杂调度规则的拟合能力。

4) 图卷积网络辅助模块:作为局部约束建模的补充,图卷积网络配置为两层图卷积结构,隐藏层维度为128,激活函数为ReLU。以工序为节点、设备关联为边,通过邻域聚合机制优化局部调度决策,增强模型对设备负载均衡等车间约束的感知能力。

5) 解码器:基于编码器输出的全局特征与图卷积网络提取的局部图结构特征,通过自回归方式动态生成排产序列,并分配资源。解码器同样采用多头自注意力机制,确保输出序列满足工序逻辑与资源约束。

为实现资源冲突的智能消解与动态响应,本研究将第2章所述的多级冲突消解策略(关键任务优先、等待时间最短、先来先得)深度集成至Transformer的前向推理过程中。具体而言,资源冲突的消解结果被编码为一系列优先级权重向量,与工序特征向量进行拼接,共同构成模型的输入序列。这一设计使得模型在生成调度方案时,能够同步考量工序间的逻辑关系与资源的实时竞争状态,从而实现对冲突策略的端到端学习与执行。

嵌入层为输入表征基础,自注意力层与前馈网络构建全局特征,图卷积网络强化局部约束建模,解码器综合所有信息输出优化调度方案,最终实现生产周期最小化目标。

3.2 调度实现过程

在人工智能大模型Transformer架构内,对船体曲面分段车间排产问题简化处理:令船体曲面分段车间内存在 P 个可调度的作业班组,有 N 个待加工的船体曲面分段建造配件,每个分段建造配件由 M 项工作任务组成,所有船体曲面分段任务完成消耗时间为 T ,然后构建船体曲面分段车间作业班组调度模型。

首先,构建工序时空占用矩阵:

$$M_i = \begin{bmatrix} x_i^{\min} & y_i^{\min} & t_i^{\text{start}} \\ x_i^{\max} & y_i^{\max} & t_i^{\text{start}} \end{bmatrix} \quad (4)$$

其中：定义子工序 l 的时空边界，其中 (x, y) 为二维车间平面坐标， t 为时间区间。

然后，计算空间重叠面积 $A_{ij}^{overlap}$ 可检测潜在的空间冲突检测。分析不同子工序的时空重叠现象，以优化车间排产方式，确定船体曲面分段车间调度子工序 i 与 j 在二维平面上的重叠区域面积计算函数 $A_{ij}^{overlap}$ 为：

$$A_{ij}^{overlap} = \max[0, \min(x_i^{max}, x_j^{max}) - \max(x_i^{min}, x_j^{min})] \times \max[0, \min(y_i^{max}, y_j^{max}) - \max(y_i^{min}, y_j^{min})] \quad (5)$$

其中： $A_{ij}^{overlap} > 0$ 若且时间区间重叠，则触发冲突预警。

最后，该模型将船体曲面分段建造的总完工时间最小作为目标，其目标函数 F 表达式如下：

$$F = \min \sum_{k=1}^N \sum_{j=1}^M \frac{Q_{kj}}{P \cdot A} \quad (6)$$

式中， Q_{kj} 为作业量，表示第 k 个分段中第 j 项工作任务的总作业量； A 表示人员作业能力，表示作业人员的平均作业能力。

设置船体曲面分段车间作业班组调度模型的约束条件如下：

- 1) 在建造第 M 个船体曲面分段时，前序作业完成后方可开始后序作业。
- 2) 每个作业班组至少完成一项工作，且每个船体曲面作业任务由一个作业班组完成。
- 3) 相同时刻和相同分段上的两个任务不可同时开展。
- 4) 船体曲面分段中的每个工作任务时间均为正数。

将上述约束条件、目标函数、资源冲突消解处理策略作为输入向量，共同输入到人工智能大模型 Transformer 架构内，Transformer 架构将调度问题视为序列生成任务，按照输入向量，输出满足公式 (3) 目标的船体曲面分段车间排产与调度结果。

为提升船体曲面分段车间排产作业排产与调度能力，在此考虑船体曲面分段车间的资源均衡性，将船体曲面分段车间资源均衡性作为船体曲面分段车间排产调度的重要考量指标，在对每种船体曲面分段任务进行排产调度时，尽量保障车间资源的均衡度数值最大^[22-23]。将每个左右舷资源分配量与总资源数量比值作为资源分布概率集合，由 (s_1, s_2, \dots, s_n) 表示，依据最大熵分布原则，计算船体曲面分段车间资源熵，公式如下：

$$Q_k = - \sum_{i=1}^{T_N} s_i \ln(s_i) \quad (7)$$

式中， Q_k 为第 k 类资源的资源熵； T_N 为第 k 类资源使用总时长。

将第类资源的资源熵最大作为船体曲面分段车间排产调度的均衡约束条件，经过人工智能大模型 Trans-

former 架构评估阶段后，输出大模型的船体曲面分段车间排产与调度优化结果。

4 实验验证与性能分析

4.1 实验的设置

以某大中型造船企业为例，其分段制造车间为“综合分段车间”模式，即在同一车间内同时生产多种船舶分段加工件。通过本文方法对船体曲面分段制造车间实施排产与调度优化，检验本文方法的实际优化效果。

本文实验设计如表 1~2 所示。

表 1 硬件参数

类别	配置说明	规格细节
计算集群	GPU 加速器	NVIDIA A100 80GB
模型规模	参数总量	3.2 亿参数
	网络结构	3.2 亿参数
数据规模	历史排产数据	5 年记录(12 万工序序列)
推理平台	部署测试设备	RTX 4090 显卡
存储系统	训练数据存储	PB 级分布式存储

表 2 软件配置表

类别	配置说明	规格细节
基础框架	PyTorch 2.0+ CUDA 11.7	计算基础
训练加速	FlashAttention-2	自注意力计算优化
	DeepSpeed Zero-3	显存优化与分布式训练
部署推理	TensorRT 8.6	生产环境推理引擎
优化验证	Gurobi	混合整数规划求解
	Plant Simulation	数字孪生方案验证
监控系统	Prometheus	硬件性能实时监控
应用系统	BigSHIP-AI	调度方案可视化平台

NVIDIA A100 集群 (8 节点 × 4 卡) 训练 3.2 亿参数模型；12 万工序历史数据存储于 PB 级分布式系统；RTX 4090 实现 800 ms 推理延迟，92% 显存利用率验证工业可行性。

Transformer 模型采用 6 层编码器，每层包含 8 头注意力机制，前馈网络维度 2 048，嵌入维度 512，激活函数为 GELU。GCN 配置为两层图卷积网络，隐藏层维度 128，使用 ReLU 激活函数，结合邻接矩阵与节点特征 (工序/资源属性) 进行图表示学习。输入特征维度统一为 512，Dropout 率设为 0.5。

实验设计如下：首先将工序特征、资源约束及冲突消解策略向量化，与 GCN 提取的工序关系图嵌入 (128 维) 拼接为 512 维输入序列。Transformer 编码器 (6 层/8 头) 学习全局依赖关系，输出特征经全连接层映射为调度决策。训练时采用 Adam 优化器，以总完工时间损失函数驱动端到端优化，验证集评估资源均衡性指标。在训练过程中，总完工时间损失函数定义为模型预测排产方案的实际总工期与理论最优值之间的均方误差

或绝对误差。该损失函数通过反向传播算法驱动 Transformer 编码器-解码器及图卷积网络模块的参数更新, 使模型能够端到端地学习从输入特征(工序关系、资源约束、冲突策略)到最优调度序列的复杂映射。通过最小化该损失, 模型逐步识别并强化那些有助于缩短关键路径、减少资源闲置的调度模式, 最终实现无需中间监督信号、直接以最终工期为优化目标的端到端智能排产。

以某大型船体曲面建造车间作为实验对象, 车间配置参数见表 3。

表 3 船体曲面分段车间配置参数

项目	参数	备注
任务总量	16 033 个	—
分段	工序 1:曲板拼装	4 h
	工序 2:曲板焊接	4.5 h
	工序 3:内部焊接	4.5 h
	工序 4:板材折弯	6 h
	工序 5:零件装配	2.5 h
	工序 6:检查修补	9 h
工作人员 总数 45 人	焊接工人 18 人	工作能力均值 4.6, 车间内生产节拍为 7.5
	装配工人 15 人	
	检修工人 6 人	
	折弯工人 6 人	

其中, 工作能力均值 4.6、车间内生产节拍为 7.5 的取值依据主要来源于对实际生产流程的量化分析和历史数据统计。

工作能力均值 4.6 反映了各工种(如焊接、装配等)在单位时间内的任务完成效率, 该数值通常基于对工人技能等级、操作熟练度及历史任务完成率的综合评估, 并参考行业标准或企业内部制定的标准工时体系进行归一化处理。

生产节拍 7.5 则表示完成一个标准产品单元所需的平均时间, 其设定依据包括各工序的标准作业时间、设备运行效率、人员配置以及目标产能需求, 通过工艺流程分析和产能反推得出, 用于确保生产节奏与计划目标相匹配。

4.2 功能测试

该大型船体曲面建造车间, 需要装配和焊接 2 个作业班组, 焊接工人 18 人、装配工人 15 人, 将其分配为焊接组 A、焊接组 B, 装配组 A、装配组 B, 利用本文 Transformer 大模型对该船体曲面建造任务和工人进行排产和调度。其排产结果如表 4~5 所示。

焊接组调度: 焊接组 A 单独处理耗时最长的工序 6 (9 h), 确保关键路径不延迟。焊接组 B 按时间顺序处理工序 2 (4.5 h) 和工序 4 (6 h), 总耗时 10.5 h, 为焊接任务的最长耗时路径。

表 4 焊接组排产表

班组	工序	作业时间 /h	开始时间 /h	结束时间 /h
焊接组 A	工序 6	9	0	9
焊接组 B	工序 2	4.5	0	4.5
焊接组 B	工序 4	6	4.5	10.5

表 5 装配组排产表

班组	工序	作业时间 /h	开始时间 /h	结束时间 /h
装配组 A	工序 3	4.5	0	4.5
装配组 A	工序 5	2.5	4.5	7
装配组 B	工序 1	4	0	4

装配组调度: 装配组 B 处理耗时 4 h 的工序 1, 独立完成。装配组 A 先处理工序 3 (4.5 h), 随后处理工序 5 (2.5 h), 总耗时 7 h, 平衡班组工作量。

从表 4、表 5 及调度结果来看, 焊接组调度中, 焊接组 A 单独处理耗时最长的工序 6 (9 h), 确保关键路径不延迟, 焊接组 B 按顺序作业工序 2 (4.5 h) 和工序 4 (6 h), 总耗时 10.5 h, 两组工作量均衡, 避免负荷悬殊; 装配组调度上, 装配组 B 独立完成工序 1 (4 h), 装配组 A 先做工序 3 (4.5 h) 再衔接工序 5 (2.5 h), 总耗时 7 h, 任务衔接紧密且平衡了工作量。整体排产调度通过优先把控关键路径, 确保任务连续化并均衡各班组负荷, 有效提升了资源利用率与执行效率, 展现出对船体曲面建造任务及多班组协作的科学管控能力, 既保障关键工序进度, 又实现各班组高效配合, 减少闲置, 使整体作业流程顺畅有序。

4.3 资源均衡性性能测试

以大型船体曲面建造车间内 10 种设备资源作为实验对象, 测试使用本文方法对船体曲面建造任务进行排产和调度过程中的资源均衡性, 其中, 资源均衡度 (RBD, resource balance degree) 的计算公式为:

$$RBD = 1 - \frac{\sigma}{\mu} \quad (8)$$

其中: σ 表示各设备资源负载率的标准差, μ 为平均负载率。RBD 越接近 1, 表明资源分配越均衡。实验中, 首先统计每台设备的任务执行时间占比作为负载率, 再计算其标准差与均值, 最终得出 RBD。若 $RBD \geq 0.5$, 则满足均衡性要求。该指标通过离散事件仿真 (DES) 动态采集设备利用率数据, 结合方差分析验证调度策略的优化效果, 测试结果如图 5 所示。

本文方法在船体曲面建造任务排产调度中, 资源均衡性表现优异。测试设置资源均衡度不得低于 0.5, 而图 5 中 10 种设备资源的均衡度均在 0.7 以上, 部分更高。这表明该方法能有效优化资源分配, 避免资源过度




图 5 资源均衡性测试结果

集中或闲置，确保各设备利用合理。而任务排序和选择群体决策方法及时空约束方法下设备资源的均衡度远远低于本文方法，资源分配度较低。均衡的资源分配对排产调度至关重要，可提升整体效率，增强生产稳定性。本文方法通过良好的资源均衡性，这是因为本文方法利用人工智能大模型中的 Transformer 架构，以总完工时间最小为目标构建排产与调度目标函数，使得船体曲面分段车间调度效率有效提升。而其他两种传统方法缺少冲突消解策略的设计。导致船体曲面分段车间调度效率下降。

4.4 调度能力性能测试

以 10 个建造大型船体曲面配件任务作为实验对象，以任务完成时间作为衡量指标，再次验证本文方法对船体曲面分段车间排产与优化调度能力，测试结果如表 6 所示。

表 6 大型船体曲面配件任务完成时间

建造任务编码	预计完成时间	消耗时间/s		
		本文方法	任务排序和选择群体决策方法	时空约束方法
1	66.5	59.4	68.2	78.9
2	13.5	13	15.7	18.3
3	18	16.5	19.7	20.1
4	105	92.5	104.2	108.3
5	27.5	23	28.5	29.6
6	33	28.5	38.9	39.5
7	51.8	44.2	56.1	58.9
8	16.5	14.3	18.9	19.8
9	83.5	75.5	88.2	98.2
10	112	102.5	119.6	121.1

分析表 6 可知，本文方法在船体曲面分段车间排产与优化调度中效果显著。对比各建造任务编码的“预计完成时间”与“排产与调度后消耗时间”，如任务 1 预计 66.5 h，实际仅 59.4 h；任务 4 预计 105 h，实际 92.5 h，其余任务也均有不同程度缩短。而任务排序和选择群体决策方法对任务 1 预计为 68.2 h，对任务 4 预计为 104.2 h；而时空约束方法对任务 1 预计为 78.9 h，

对任务 4 预计为 108.3 h；这表明本文方法能精准优化调度，有效压缩任务耗时，提升生产效率。所有任务完成时间均低于预计，充分彰显了该方法在排产与调度上的强大能力，切实实现了资源高效利用与任务流程优化，为船体曲面分段车间的高效运作提供了有力支撑。这是因为本文大模型通过 Transformer 架构中的自注意力机制精准捕捉工序间的时空依赖关系，基于强化学习的冲突消解策略可动态预测资源竞争，提前规划最优路径，减少设备的等待时间；有效地降低耗时。

5 结束语

本文针对船体曲面分段车间的排产与调度难题，引入人工智能大模型。通过构建贴合实际的车间生产模型，有效整合多源数据，实现对生产流程全面且精准地排布。运用大模型强大的学习与优化能力，对排产与调度方案迭代寻优，显著缩短了总完工时间，提升了设备利用率，减少了生产能耗。本研究的主要创新点可系统性地总结如下：

1) 提出了融合多智能体与规则引擎的资源冲突动态消解机制。不同于传统静态策略，本文构建了资源-管理-产品智能体协同模型，并设计了关键任务优先、等待时间最短、先来先得三者结合的多级动态决策策略，通过量化评估任务关键程度与等待时间，实现了对设备、人力、物料冲突的精准感知与智能消解，显著提升了系统在动态环境下的鲁棒性。

2) 构建了面向排产调度问题的混合式 Transformer-GCN 建模框架。创新地将 Transformer 架构的全局序列建模能力与图卷积网络 (GCN) 的局部约束表征能力相结合。该框架不仅能通过自注意力机制捕捉工序间的长距离时空依赖，还能利用 GCN 对设备关联、工序逻辑等结构化约束进行有效编码，为复杂车间环境下的精准排产提供了强大的模型基础。

3) 实现了基于强化学习的多目标协同优化。本研究以最小化总完工时间为核心目标，同时将资源均衡性作为重要的优化指标，并创新性地引入资源熵概念作为均衡性约束。通过端到端的训练，使模型能够在工期与资源利用率等多个关键性能指标间自动寻找最优平衡点，克服了传统方法往往侧重单一目标的局限性。

4) 本研究通过详细的实验验证，在真实车间场景下证明了该方法在缩短任务耗时（所有测试任务实际耗时均低于预计）、提升资源均衡度（10 类设备资源均衡度均高于 0.7）以及支持多班组协同方面的显著有效性，为船舶智能制造提供了兼具前沿性与实用性的排产调度解决方案。

综上所述，这一成果为船舶制造企业提升生产效

率、降低成本提供了创新且有效的途径, 其 AI 驱动的方法论具备向其他复杂装备制造场景推广的潜力。

参考文献:

- [1] VOLPE D, CIRILLO G A, FANTINI R, et al. Quantum-compliant users scheduling optimization in joint transmission mobile access networks [J]. *Quantum Information Processing*, 2024, 23 (7): 262–294.
- [2] CANTU F, COELHO L C. Simulation-based optimization of pump scheduling for drinking water distribution systems [J]. *Engineering Optimization*, 2023, 55 (5): 841–855.
- [3] GUIDO R. Patient admission scheduling problems with uncertain length of stay: optimization models and an efficient matheuristic approach [J]. *International Transactions in Operational Research*, 2023, 31 (1): 53–87.
- [4] KRENCZYK D, PAPROCKA I. Integration of discrete simulation, prediction, and optimization methods for a production line digital twin design [J]. *Materials*, 2023, 16 (6): 2339–2360.
- [5] KOMASILOVS V, ZACEPINS A, KVIESIS A, et al. Model for hydrogen production scheduling optimisation [J]. *Modelling*, 2024, 5 (1): 265–275.
- [6] VARELA L, PUTNIK G, VIEIRA G, et al. Group decision making approach for ranking and selecting maintenance tasks for joint scheduling with production orders [J]. *International Journal for Quality Research*, 2024, 18 (1): 235–258.
- [7] 王梦莹, 景旭文, 周宏根, 等. 基于时空约束的船体曲面分段车间调度方法研究 [J]. *现代制造工程*, 2017 (9): 96–101.
- [8] 李尚富, 陈大伟. 基于人工智能技术的舰船自动驾驶控制系统 [J]. *舰船科学技术*, 2025, 47 (10): 181–184.
- [9] SADKI H, AQIL S, BELABID J, et al. Multi-objective optimization flow shop scheduling problem solving the makespan and total flow time with sequence independent setup time [J]. *Journal of Advanced Manufacturing Systems*, 2024, 23 (1): 163–184.
- [10] ALA A, SIMICV, DEVEC M, et al. Simulation-based analysis of appointment scheduling system in healthcare services: a critical review [J]. *Archives of Computational Methods in Engineering*, 2023, 30 (3): 1961–1978.
- [11] SHINGNE H, SHRIRAM R. Mutated deep reinforcement learning scheduling in cloud for resource-intensive iot systems [J]. *Wireless Personal Communications*, 2023, 132 (3): 2143–2155.
- [12] LINGKON M L R, Dash A. Multi-objective flexible job-shop scheduling with limited resource constraints in hospitals using hybrid discrete firefly algorithm [J]. *Journal of The Institution of Engineers (India): Series C*, 2025, 106 (1): 403–423.
- [13] GAMAL M, AWAD S, ABDEL K F, et al. Efficient offloading and task scheduling in internet of things-cloud-fog environment [J]. *International Journal of Electrical & Computer Engineering*, 2024, 14 (4): 2088–2708.
- [14] KAUR N, MITTAL A. MTFP: matrix-based task-fog pairing method for task scheduling in fog computing [J]. *International Journal of Information Technology*, 2024, 16 (5): 3205–3218.
- [15] KOUSARG N, KRISHNANC G. User task priority based resource allocation with multi class task scheduling strategy and load balancing in cloud environment [J]. *SN Computer Science*, 2024, 5 (8): 1–12.
- [16] GAO X, PENG D, KUI G, et al. Reinforcement learning based optimization algorithm for maintenance tasks scheduling in coalbed methane gas field [J]. *Computers & Chemical Engineering*, 2023, 170: 2–14.
- [17] CHIANGM L, HSIEHH C, CHENG Y H, et al. Improvement of tasks scheduling algorithm based on load balancing candidate method under cloud computing environment [J]. *Expert Systems with Application*, 2023, 212: 1–19.
- [18] AJOO A, HUY C, LIN X, et al. Slearn: a case for task sampling based learning for cluster job scheduling [J]. *IEEE Transactions on Cloud Computing*, 2023, 11 (3): 2664–2680.
- [19] ZHOU M T, REN T F, FENG D X Y. Task scheduling and resource balancing of fog computing in smart factory [J]. *Mobile networks & applications*, 2023, 28 (1): 19–30.
- [20] GOEL G, TIWARI R. IGWOA: improved grey wolf optimization algorithm for resource scheduling in cloud-fog environment for delay-sensitive applications [J]. *Peer-to-Peer Networking & Applications*, 2024, 17 (3): 1768–1790.
- [21] GUPTA S, TRIPATHI S. A comprehensive survey on cloud computing scheduling techniques [J]. *Multimedia Tools & Applications*, 2024, 83 (18): 53581–53634.
- [22] HESAR A S. Task scheduling using memetic intelligent water drops algorithm based on Tabu search: a case study on azure workflows [J]. *Soft Computing*, 2023, 27 (15): 10647–10663.
- [23] GüNTER B, SENJIC P. Intelligent scheduling based on discrete-time simulation using machine learning [J]. *Procedia CIRP*, 2024, 126: 48–51.