

# 基于改进候鸟优化算法的整车多关联车间协同排产方法

肖海宁<sup>1\*</sup> 孙慧慧<sup>1</sup> 彭明花<sup>1,2</sup> 王健洲<sup>1</sup>

1. 盐城工学院机械工程学院, 盐城, 224051

2. 西安科技大学管理学院, 西安, 710054

**摘要:** 为了满足汽车整车焊装、涂装及总装车间不同的车身排产序列需求, 以最小化产线停产时间和成本为综合优化目标, 建立了整车多关联车间协同排产优化数学模型, 并设计了一种基于改进候鸟优化算法的协同排产方法。为了快速获取候鸟个体对应的多关联车间协同排产方案, 设计了基于启发式排产规则的解码策略; 针对传统候鸟优化算法邻域结构单一导致算法收敛速度慢的缺陷, 设计了基于多种邻域结构的领飞鸟进化策略; 为了提升算法的全局寻优能力, 设计了融合交叉与邻域搜索的跟飞鸟进化策略。最后以某新能源汽车生产线为实例, 开发了整车多关联车间协同排产仿真分析平台以验证所提排产方法。仿真实验结果表明, 与改进的遗传算法、改进的蚁群算法等方法相比, 所设计的改进候鸟优化算法能够获得更优的解集。

**关键词:** 汽车排产问题; 改进候鸟优化算法; 汽车总装; 汽车焊装; 汽车涂装

**中图分类号:** TP278

DOI:10.3969/j.issn.1004-132X.2025.08.015

开放科学(资源服务)标识码(OSID):



## An IMBOA Based Collaborative Sequencing Method for Automotive Multi Associated Workshops

XIAO Haining<sup>1\*</sup> SUN Huihui<sup>1</sup> PENG Minghua<sup>1,2</sup> WANG Jianzhou<sup>1</sup>

1. College of Mechanical Engineering, Yancheng Institute of Technology, Yancheng, Jiangsu, 224051

2. School of Management, Xi'an University of Science and Technology, Xi'an, 710054

**Abstract:** To meet the different body production sequence requirements of the automotive body welding, painting and final assembly workshops while aiming to minimize production line downtime and costs, a mathematical model for collaborative car sequencing optimization of multi-related workshops was established, and a collaborative sequencing method was proposed based on the IMBOA. To efficiently obtain the collaborative sequencing scheme for multiple associated workshops that aligned with individual migratory birds, a decoding strategy was designed based on heuristic scheduling rules. Addressing the limitation of a single neighborhood structure in IMBOA, a leading bird evolution strategy relying on multiple neighborhood structures was developed. To improve the global optimization ability of the algorithm, a bird following evolution strategy combining crossover and neighborhood search was designed. Finally, taking a new energy vehicle production line as an example, a simulation analysis platform for collaborative sequencing of multiple associated workshops for the entire vehicle was developed to verify the proposed sequencing method. Simulation experimental results show that compared with methods such as improved genetic algorithm (IGA) and improved ant colony algorithm (IACO), the designed IMBOA may obtain a better solution set.

**Key words:** car sequencing problem; improved migrating bird optimization algorithm (IMBOA); automotive assembly; automotive welding; automotive painting

### 0 引言

汽车整车生产线由冲压、焊装、涂装和总装四

大工艺车间组成, 由于冲压车间仅生产车门、侧围、舱盖、顶盖等各种车身覆盖件, 故冲压车间与其他车间的关联性不强。而车身自焊装车间开始成形并赋予唯一的车身识别码, 因此, 焊装、涂装和总装三大车间构成了相互关联的整车流水线。然而, 由于各车间各自优化目标和工艺约束的差异性, 每个车间均有各自的排产需求, 研究满足各车间车身序列需求的排产模型及算法是当前汽车

收稿日期: 2024-07-12

基金项目: 国家自然科学基金(52005427); 江苏省产学研合作项目(BY20221007); 江苏高校“青蓝工程”项目(2022); 江苏省研究生科研与实践创新计划(SJCX23\_1862); 盐城工学院研究生科研与实践创新计划(KYCX24\_XY032)

生产车间管理研究领域的热点及难点。近年来,国内外研究人员针对各车间的排产需求,设计了相应的排产算法。针对焊装车间的排产优化问题,LU等<sup>[1]</sup>将其简化为加工时间可控的流水车间调度问题,建立了以最小化额外资源消耗和最长完工时间为优化目标的混合整数规划模型,并设计了相应的多目标灰狼优化算法。孟磊磊等<sup>[2]</sup>以最小化最长完成时间为目标,考虑共用焊机以及峰值功率等约束,建立了焊接车间混合整数规划(mixed integer programming, MIP)模型,并通过CPLEX的CP引擎对模型进行了求解和验证。WANG等<sup>[3]</sup>以最小化最长完工时间和总能耗为目标,设计了一种合作模因算法。为了应对焊装车间中的动态干扰事件,WANG等<sup>[4]</sup>设计了基于灰狼优化算法的焊装车间逆调度模型和算法。为了最大限度地减少焊装作业总延迟和机器交互产生的惩罚,RAO等<sup>[5]</sup>提出了一种嵌入重启策略的非支配排序遗传算法。针对涂装车间的排产问题,KRYSTEK等<sup>[6]</sup>为了减少喷枪清洗次数,提出了将颜色切换与喷枪定期清洗协调一致的控制策略;WINTER等<sup>[7]</sup>根据涂装车间的约束和求解目标,建立了新的约束规划模型,并对比了传统动态规划、元启发式和混合方法三类方法的求解效果。总装车间的排产模型及算法方面,CHUTIMA等<sup>[8]</sup>针对平行相邻的U形装配线(PAUL)产能提升优化问题,分别设计了新型元启发式算法、差分进化算法和模糊自适应扩展偶合算法;THIRUVADY等<sup>[9]</sup>为了避免排产不合理造成的瓶颈装配工位连续作业超时,建立了MIP排产模型,并设计了相应的大邻域搜索(large neighborhood search, LNS)算法。李焱等<sup>[10]</sup>针对总装车间混流装配调度问题,建立了以瓶颈工位负载平衡化和考虑换装与提前作业时间的作业超时次数最小化为目标的优化模型,并设计了一种改进的蚁群算法。ZHANG等<sup>[11]</sup>针对混流装配线平衡及排产集成优化问题,以降低能耗及装配线平衡为综合优化目标,设计了基于细胞策略的多目标遗传算法。LOUIS等<sup>[12]</sup>的研究表明,混流装配线平衡及排产的集成优化更有利于提升排产质量。SHI等<sup>[13]</sup>将实例推理(case-based reasoning, CBR)与排产规则相结合,设计了一种结合相似性的先前案例检索算法,实现了排产序列的快速决策。GUO等<sup>[14]</sup>以最大限度地提高生产效率并降低成本为目标,设计了基于深度强化学习的排产方法。但上述研究均聚焦于单一车间,建立了

单一车间的排产模型及算法,却忽略了各车间的关联性。

考虑到三大车间的关联性和协同生产关系,研究人员对多车间的联合排产问题进行了研究。沈振宇等<sup>[15]</sup>根据焊接、涂装和总装车间对订单排序方式的不同需求,以最小化总成本为优化目标,建立了多级流水车间调度模型,并通过改进变异算子设计了一种文化基因算法,然而该研究假定各车间按相同的车身序列生产,但在实际生产中,为了更好地满足各车间的生产工艺需求,各车间均采用各自的排产序列。而各车间排产序列的差异要求在车间之间设置相应的车身调序缓存区。目前,各大车企产线普遍采用的方案是:在焊装车间与涂装车间设置白车身存储区(welded body storage area, WBS),在涂装车间与总装车间之间设置彩车身存储区(painted body storage area, PBS)。因此,多车间的协同排产问题不仅需要综合考虑不同车间排产需求的差异,还需考虑缓存区的车身调序能力。杜宝钗<sup>[16]</sup>针对多车间多产线工厂布局下的汽车关联排序问题,对比分析了无缓冲区和带线性缓存区的多车间关联排产模型及算法,证明了带缓存区的整体排产效果更好。李聪波等<sup>[17]</sup>针对具有线性缓存区的多关联车间协同排产问题,以最小化涂装车间换色成本、总装车间总超载和空闲时间、线性缓冲区重排序成本等为目标,构建了整车多目标协同排产优化模型,并提出了结合启发式出入缓存区规则的非支配排序遗传算法。针对涂装车间与总装车间的协同排产问题,WU等<sup>[18]</sup>建立了考虑线性PBS调序能力的协同排产模型,并设计了相应的元启发式算法。YANG等<sup>[19]</sup>为了应对汽车生产中的紧急插单问题,以减少生产成本和交付延迟为目标,建立了集成焊装、涂装及总装的排产数学模型,并设计了相应的重排序进化算法。然而,上述多关联车间的联合排产优化模型及算法多针对传统线性WBS和PBS。虽然传统线性WBS和PBS建造成本低,但也存在占地面积大、调序能力弱的缺点。近年来,为了加速实现多品种、小批量混流生产模式,越来越多的车企已开始引入由立库和堆垛机组成的随机存储缓存区来替代传统线性WBS和PBS,这类随机存储缓存区不仅占地面积小,而且具有较强的随机调序能力。然而,较强随机调序能力的引入在增强调序能力的同时,也增加了多关联车间协同排产问题的解空间规模,所以有必要设计相应的协同排产方法。目前,这方面的研

究还鲜见报道。

本文以某新投产的以立体库作为车身缓存区的新能源汽车产线为研究对象,梳理并分析焊装、涂装及总装三大车间各自的工艺特点和优化目标,考虑立体库的随机调序范围约束,建立三大关联车间的协同排产数学模型,并结合启发式排产规则与智能优化算法两者的优势,设计相应的协同排产方法。

### 1 问题描述及数学模型

#### 1.1 问题描述

某采用立体库作为车身缓存区的新能源汽车产线布局示意图见图1,其中,焊装车间按照焊装排产序列以流水方式依次途经机舱、下车体总成、侧围总成、车身总拼、机罩装配、行李箱盖装配、前后门装配、检测调整等工位,将各车身覆盖件焊接、组装成白车身。完工后的白车身进入立体库,等待涂装车间按照涂装排产序列调度出库。涂装车间依次对白车身进行喷涂作业,主要涂装工序包括前处理、电泳、烘干、密封涂胶及烘干、打磨、中涂及烘干、面漆及烘干、装饰注蜡等,完工后的车身称为彩车身。彩车身同样进入立体库,等待总装车间按总装排产序列调度出库。总装车间是汽车生产的最终车间,主要由内饰装配线、底盘装配线、最终装配线、淋雨线、终检线等组成,负责将自立体库进入的彩车身装配成合格的整车交付客户。

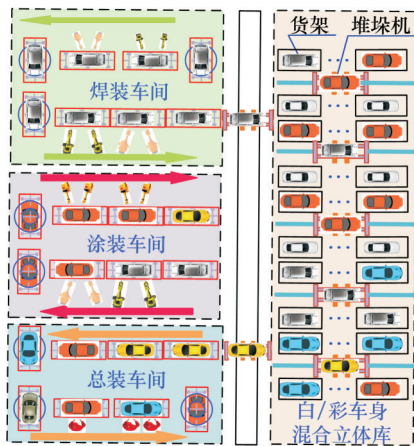


图1 采用立体库作为车身缓存区的新能源汽车产线  
Fig.1 A new energy vehicle production line using a stereoscopic warehouse as the car body buffer area

整车多关联车间协同排产优化问题可描述如下:在一个投产批次有  $N_Q$  个客户订单,构成订单集,涵盖  $N_K$  种车型、 $N_C$  种颜色、3种配置,要求确定所有客户订单分别在焊装车间、涂装车间及总装车间的排产顺序编号,分别构成焊装车间排产

编号集合  $\Omega^W$ 、涂装车间排产编号集合  $\Omega^P$  和总装车间排产编号集合  $\Omega^A$ 。为了聚焦汽车整车多关联车间协同排产优化问题,对各车间生产流程及车身出入库作业作以下假设:①所有订单的优先级相同,焊装、涂装、总装三大车间拥有各自的排产序列;②焊装、涂装、总装三大车间生产节拍一致,产线所有设备均满足节拍需求;③忽略因设备故障、维护、物料供应短缺等因素导致的停产问题,忽略因紧急插单、车辆检测不合格返修等因素引发的排产序列重排序问题;④不考虑白车身及彩车身入库时的堆垛机及库位选择调度问题。

#### 1.2 汽车整车多关联车间协同排产优化数学模型

##### 1.2.1 符号定义

本文所使用的符号定义见表1。

表1 符号定义

Tab.1 Symbol definition

符号	定义
$N_Q$	客户订单总数
$Q_i = (D_i, C_i, O_i, t_i^{QE})$	第 $i$ 个客户的订单信息
$N_D$	可选车型的总数
$D_i$	客户订单 $Q_i$ 的车型编码, $D_i \in \{A, B, C, \dots\}$
$N_C$	可选车身颜色总数
$C_i$	客户订单 $Q_i$ 的车身色编码, $C_i \in \{\text{红, 白, 蓝, } \dots\}$
$O_i \in \{H, M, L\}$	客户订单 $Q_i$ 的配置编码, H:高配置, M:中配置, L:低配置
$t_i^{QE}$	客户订单 $Q_i$ 的合同约定交付时间
$t_i^{QK}$	客户订单 $Q_i$ 的实际交付时间
$\lambda$	订单拖期违约金支付系数
$\Omega_Q = \{Q_i   i \in NH, 1 \leq i \leq N_Q\}$	客户订单的集合
$S^W(Q_i)$	客户订单 $Q_i$ 在焊装车间的排产序号
$\Omega^W = \{S^W(Q_i)   \forall Q_i \in \Omega_Q\}$	焊装车间排产序号集合
$S^P(Q_i)$	客户订单 $Q_i$ 在涂装车间的排产序号
$\Omega^P = \{S^P(Q_i)   \forall Q_i \in \Omega_Q\}$	所有客户订单在涂装车间的排产序号集合
$S^A(Q_i)$	客户订单 $Q_i$ 在总装车间的排产序号
$\Omega^A = \{S^A(Q_i)   \forall Q_i \in \Omega_Q\}$	所有客户订单在总装车间的排产序号集合
$T$	生产节拍
$a_c$	涂装车间单次换色所需成本
$\Omega_J = \{J_j   j \in NH, 1 \leq j \leq N_j\}$	关键重要零部件的集合
$N_j$	关键重要零部件的种类数
$\theta_w$	焊装车间单次切换车型造成的停产时间
$\mu_w$	焊装车间单次切换车型增加的生产成本
$N_w^C$	焊装车间排产序列车型切换次数

续表

符号	定义
$S_{i,j}$	涂装车间相邻车身颜色是否不同,为1表示颜色不同,反之则为0
$N_W^{\text{MIN}}$	焊装车间最小批量,每批次批量为 $N_W^{\text{MIN}}$ 的整数倍
$N_C^{\text{MAX}}$	在无需清洗喷枪的前提下,涂装车间能够连续喷涂的车身数
$\theta_c$	涂装车间单次切换颜色造成的停产时间
$N_C^c$	涂装车间连续喷涂相同颜色车身时的喷枪清洗次数
$\bar{T}_{\text{pr}}$	总装车间各工位工人所需的休息时间平均值
$T_i^{\text{ap}}$	总装车间某工位装配第 <i>i</i> 辆车后产生的休息时间拖欠额
$\bar{T}^{\text{ap}}$	各订单装配后休息时间拖欠额的平均值
$T^{\text{as}}$	总装车间某工位装配作业所需工时
$a_f$	总装车间各订单平均返修一次所需成本
$\delta(\bar{T}^{\text{ap}})$	总装车间订单平均返修率
$x_{n,j} \in \{0,1\}$	总装车间排产顺序编号为 <i>n</i> 的车辆是否装关键重要零部件 <i>J<sub>j</sub></i> ,1:装,0:不选装
$\bar{V}_j$	总装车间所有客户订单对关键重要零部件 <i>J<sub>j</sub></i> 的平均消耗速率
$\bar{V}_j^r$	总装车间前 <i>r</i> 个排产序列对关键重要零部件 <i>J<sub>j</sub></i> 的平均消耗速率
$a_{\bar{V}}$	总装车间平均物料供应成本
$N_{\text{max}}^{\text{V}}$	立体库车位容量
$N_{\text{max}}^{\text{TW}}$	立体库对白车身调序的最大范围
$N_{\text{max}}^{\text{TP}}$	立体库对彩车身调序的最大范围

1.2.2 决策变量

针对汽车整车三大关联车间的协同排产优化问题,本文建立的数学模型决策变量如下:①焊装车间排产序号集合 $\Omega^W$ ;②涂装车间排产序号集合 $\Omega^P$ ;③总装车间排产序号集合 $\Omega^A$ 。

1.2.3 优化目标

1)焊装车间优化目标。近年来,为了满足日益多样化、个性化的客户需求,焊装车间多采用多品种小批量混流生产模式,一些车企单线混装车型数多达十余种。然而同一工位不同车型的焊装夹具不同,当相邻车型不同时,需要临时停产并切换夹具。因此,焊装车间的首要目标是最小化因车型切换造成的停产时间,即

$$f_{1,1} = \min(\theta_w, N_w^c) \quad (1)$$

其次,夹具频繁切换会增加夹具磨损并降低定位精度,从而影响车辆的质量并增加成本,因此,焊装车间的第二个优化目标是最小化因车型切换而增加的成本,即

$$f_{1,2} = \min(\mu_w, N_w^c) \quad (2)$$

2)涂装车间优化目标。与焊装车间类似,涂装车间同样采用多品种小批量混流生产模式,一些车企可选的车身颜色可多达十余种。当不同喷

涂颜色切换或连续长时间连续喷涂导致输漆管堵塞时,均需要临时停产,并对管路和喷枪进行全面清洗,因此,涂装车间的首要目标是 minimized 因喷枪及管路清洗造成的停产时间,即

$$f_{2,1} = \min \theta_c (N_C^c + \sum_{\forall Q_i, Q_j \in \Omega_Q} S_{i,j}) \quad (3)$$

其次,清洗喷枪及管路会增加成本,因此,涂装车间的另外一个优化目标是减少因喷枪清洗而增加的成本,即

$$f_{2,2} = \min a_c (N_C^c + \sum_{\forall Q_i, Q_j \in \Omega_Q} SP_{i,j}) \quad (4)$$

3)总装车间优化目标。与焊装车间及涂装车间的高度自动化不同,总装车间以人工装配为主,而各工位装配作业所需工时由车辆配置决定,由长至短依次为:高配置,中配置车,低配置车。为了保证装配作业能够在生产节拍内按时完成,产线生产节拍一般略大于高配置车辆在各工位所需最大工时,所以工人在装配作业前后会有一定的休息时间。利用该休息时间,工人可短暂休息并为下一装配作业作适当准备。若一直装配高配置车,工人将一直处于高负荷工作状态且为下一订单装配的准备不够充分,这种状态称为休息时间的拖欠,休息时间拖欠额的计算公式为

$$T_i^{\text{ap}} = \max(0, T_{i-1}^{\text{ap}} + T^{\text{as}} + \bar{T}_{\text{pr}} - T) \quad (5)$$

举例说明休息时间拖欠额的产生及优化原理。假定高配(H)、中配(M)和低配(L)在某装配工位的工时 $T^{\text{as}}$ 分别为:H(55 s),M(50 s),L(45 s),该工位工人所需平均休息时间 $\bar{T}_{\text{pr}}=10$  s,生产节拍 $T=60$  s,假定某排产序列对应的配置序列为{H, M, H, M, M, L, L},对应的工时期序列为{55, 50, 55, 50, 50, 45, 45},第一个订单对应的配置为H,利用式(5)计算的休息时间拖欠额为:55+10-60=5 s,休息时间拖欠额会延续至第二个订单,而第二个订单对应的配置为M,该订单本身未产生额外的休息时间来平衡第一个订单传递的休息时间拖欠额,导致空余时间拖欠额继续延续并加剧,直至最后两个订单对应的配置为L,各自会产生额外的5 s休息时间,使得前序订单积欠的休息时间拖欠额得以降低并最终消除,因此,上述排产序列对应的休息时间拖欠额序列为:{5, 5, 10, 10, 10, 5, 0}。显然,该序列产生了较长时间的休息时间拖欠,会加剧工人的疲劳程度,极易造成漏装或错装问题,增加返修成本。为了改善这种状况,可将排产序列优化为:{H, L, M, M, H, L, M},优化后的工时期序列和休息时间拖欠额序列分别为:{55, 45, 50, 50, 55, 45, 50}、{5, 0, 0, 0, 5, 0, 0},显然,优化后的排产序列未产生长时间的休息时间拖欠,

从而能够降低返修率及成本。为此,平衡负荷以降低返修成本是总装车间的首要优化目标,具体可表示为

$$f_{3.1} = \min(a_i N_Q \delta(\bar{T}^{\text{ap}})) \quad (6)$$

其中,  $\bar{T}^{\text{ap}}$  为所有订单平均休息时间拖欠额;  $\delta(\bar{T}^{\text{ap}})$  为总装车间返修率,与休息时间拖欠额相关,根据调研企业的经验,有

$$\bar{T}^{\text{ap}} = \frac{1}{N_Q} \sum_{i=1}^{N_Q} T_i^{\text{ap}} \quad (7)$$

$$\delta(\bar{T}^{\text{ap}}) = \frac{\bar{T}^{\text{ap}}}{10T} \quad (8)$$

另外,总装车间物料种类多且消耗量大,这些物料可分为两类:一类是诸如转向盘、刹车盘、各类密封件等所有车型都需要的通用零部件;第二类是根据不同车型与配置所需的诸如真皮座椅、全景天窗、触摸屏等关键重要零部件(简称关重件)。由于所有车辆都需要通用零部件,故排产序列对通用零部件的消耗速率并无影响,而排产序列会影响关重件消耗的均衡性,物料消耗的不均衡会增加物料供应成本。因此,保持物料消耗的均衡进而降低物料供应成本是总装车间排产的另一重要优化目标,即

$$f_{3.2} = \min(a_{\bar{v}}(1 + \sigma_{\bar{v}})) \quad (9)$$

其中,  $\sigma_{\bar{v}}$  为所有关重件平均消耗速率的标准差,具体定义为

$$\sigma_{\bar{v}} = \frac{1}{N_j N_Q} \sum_{j=1}^{N_j} \sum_{r=1}^{N_Q} \sqrt{(\bar{V}_j^r - \bar{V}_j)^2} \quad (10)$$

其中,  $\bar{V}_j$  为一个投产批次中所有客户订单对关重件  $J_j$  的平均消耗速率;  $\bar{V}_j^r$  为总装车间前  $r$  个排产序列对关重件  $J_j$  的平均消耗速率,两者计算公式分别为

$$\bar{V}_j = \frac{1}{N_Q} \sum_{n=1}^{N_Q} x_{n,j} \quad (11)$$

$$\bar{V}_j^r = \frac{1}{r} \sum_{n=1}^r x_{n,j} \quad (12)$$

4) 客户订单交付准时性优化目标。实现所有客户订单的准时化交付是排产的重要目标,若订单  $Q_i$  未按时交付,需向客户支付相应的违约金  $a_{Q_i}$ ,即

$$a_{Q_i} = \begin{cases} 0 & t_i^{\text{QK}} < t_i^{\text{QE}} \\ \lambda(t_i^{\text{QK}} - t_i^{\text{QE}}) & \text{其他} \end{cases} \quad (13)$$

本文将最小化所有客户订单拖期违约金  $f_3$  作为客户订单交付准时性优化目标,即

$$f_4 = \min\left(\sum_{i=1}^{N_Q} a_{Q_i}\right) \quad (14)$$

5) 优化总目标。综合三大车间和客户订单交付准时性几方面的优化目标,本文的优化目标主要包括两方面,首先是最小化焊装及涂装车间总停产时间,其次是最小化总成本增加值(简称总成本),两者分别表示为

$$f_A = f_{1.1} + f_{2.1} \quad (15)$$

$$f_B = f_{1.2} + f_{2.2} + f_{3.1} + f_{3.2} + f_4 \quad (16)$$

#### 1.2.4 约束条件

1) 焊装车间约束条件如下:

$$\exists! S^W(Q_i) \quad \forall Q_i \in \Omega_Q \quad (17)$$

$$S^W(Q_i) \neq S^W(Q_k) \quad \forall Q_i, Q_k \in \Omega_Q \quad (18)$$

式(17)表示任一客户订单在焊装车间的排产序号须唯一存在;式(18)表示任意两个客户订单在焊装车间的排产序号应不同。

2) 涂装车间约束条件如下:

$$\exists! S^P(Q_i) \quad \forall Q_i \in \Omega_Q \quad (19)$$

$$S^P(Q_i) \neq S^P(Q_k) \quad \forall Q_i, Q_k \in \Omega_Q \quad (20)$$

式(19)表示任一客户订单在涂装车间的排产序号须唯一存在;式(20)表示任意两个客户订单在涂装车间的排产序号应不同。

3) 总装车间约束条件如下:

$$\exists! S^A(Q_i) \quad \forall Q_i \in \Omega_Q \quad (21)$$

$$S^A(Q_i) \neq S^A(Q_k) \quad \forall Q_i, Q_k \in \Omega_Q \quad (22)$$

式(21)表示任一客户订单在涂装车间的排产序号须唯一存在;式(22)表示任意两个客户订单在涂装车间的排产序号应不同。

4) 立体库约束条件。采用立体库替代传统线性 WBS 和 PBS 的优点是能够实现白车身和彩车身的随机调序,然而车身随机调序范围的增加意味着车身的库存和立体库空间也必然随之增加,会增加立库建造成本和车身库存成本,因此,车身的调序范围并非越大越好,企业一般会分别设置白车身调序的最大范围  $N_{\text{max}}^{\text{TW}}$  和彩车身调序的最大范围  $N_{\text{max}}^{\text{TP}}$ ,且立体库中存储的车身总数不得超过立体库容量  $N_{\text{max}}^{\text{V}}$ ,即

$$S^W(Q_i) - S^P(Q_i) \leq N_{\text{max}}^{\text{TW}} \quad \forall Q_i \in \Omega_Q \quad (23)$$

$$S^P(Q_i) - S^A(Q_i) \leq N_{\text{max}}^{\text{TP}} \quad \forall Q_i \in \Omega_Q \quad (24)$$

$$N_{\text{max}}^{\text{TP}} + N_{\text{max}}^{\text{TW}} \leq N_{\text{max}}^{\text{V}} \quad \forall Q_i \in \Omega_Q \quad (25)$$

由构建的上述数学模型可知,考虑立库调序范围约束的整车多关联车间协同排产问题不仅需要各车间的优化目标及约束条件,还需考虑立库调序范围及容量约束,再结合汽车生产节拍快、产能高的特点,这决定了汽车整车多关联车间协同排产优化问题具有问题规模大、约束条件及优化目标多的特点,问题复杂性远超单一车间排产优化问题。

## 2 基于改进候鸟优化算法的协同排产方法

针对整车多关联车间协同排产问题规模大、约束条件及优化目标多的特点,本文设计了结合智能优化算法与启发式排产规则两者优势的协同排产方法。候鸟优化算法(migrating birds optimization algorithm, MBOA)是一种模拟候鸟种群保持V行队列迁徙行为的新群智能优化算法,该算法具有较强的全局寻优能力,已被应用于求解作业车间调度<sup>[20]</sup>、混流装配线平衡<sup>[21]</sup>、路径优化<sup>[22]</sup>等问题,其应用研究表明:与人工蜂群(artificial bee colony, ABO)、混合变邻域搜索(mixed variable neighborhood search, MVNS)等算法相比,MBOA算法具有更好的收敛速度。然而,这些研究也暴露了MBOA算法的缺陷,如:基于单一邻域结构的领飞鸟进化会导致领飞鸟进方向单一,影响了算法收敛速度;仅有前序共享的跟飞鸟进化均会使鸟群趋于一致,导致算法易陷入局部最优等。本文针对上述缺陷,设计了一种改进的候鸟优化算法IMBOA,并结合IMBOA与启发式排产规则两者的优势设计了图2所示的基于IMBOA的多关联车间协同排产方法,主要包括基于车型的编码策略、基于启发式规则的解码策略、候鸟种群的初始化、基于多种邻域结构的领飞鸟进化、融合交叉及邻域搜索的跟飞鸟进化等方面。

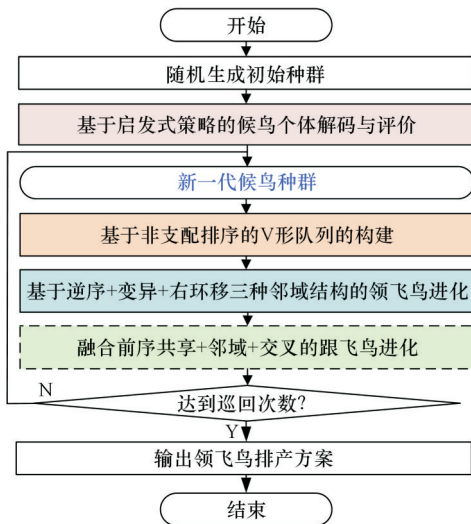


图2 基于IMBOA的协同排产方法流程图

Fig.2 Flowchart of the IMBOA based collaborative sequencing method

### 2.1 基于车型的编码策略

为了最大化地减少焊装车间车型切换次数,采用基于车型的编码方式,以某排产周期内的客户订单排产为例,具体步骤如下:首先统计排产周

期内每种车型所需生产的车辆数;其次初步以 $N_W^{MIN}$ 作为焊装车间所有车型车身的生产批量,根据批量 $N_W^{MIN}$ 以向上取整的方式确定排产周期内每种车型的批次;最后根据车型和批次数随机生成排产编码,在各完整编码中,每种车型出现的次数与批次数相同。以三种车型的车型生产为例,假定排产周期内的客户订单信息如表2所示,统计的排产周期内各车型所需生产的车身数、批量和批次数见表3,某可行的编码为: $G_i = \{A, B, A, C, B, A, C\}$ ,该编码表示焊装车间的投产顺序为:3辆A型车—3辆B型车—3辆A型车—3辆C型车—1辆B型车—2辆A型车—3辆C型车。

表2 客户订单信息列表

Tab.2 Customer order information list

$Q_i$	$C_i$ 对应车型	$C_i$ 对应颜色	$O_i$	$t_i^{QE}$ /月/日
1	A	白	H	6/1
2	B	黑	L	6/2
3	C	白	M	6/3
4	A	红	L	6/3
5	A	红	M	6/2
6	C	白	H	6/3
7	A	黑	L	6/1
8	B	白	L	6/2
9	C	红	L	6/1
10	A	红	M	6/2
11	A	白	H	6/1
12	C	黑	M	6/3
13	A	白	L	6/2
14	B	红	L	6/3
15	C	红	M	6/1
16	A	白	L	6/2
17	B	黑	M	6/1
18	C	白	M	6/2

表3 各车型所需生产的车身数、批量和批次信息

Tab.3 The number, batch and lot information of the car bodies to be produced for each car model

车型	所需数量	批量 $N_W^{MIN}$	批次
A	8	3	3
B	4	3	2
C	6	3	2

### 2.2 候鸟种群的初始化

#### 2.2.1 初始候鸟种群的生成

假定候鸟种群规模数为 $N_{POP}$ ,则根据排产周期内统计的各车型批次直接随机生成 $N_{POP}$ 个不相同的编码,这些构成初始候鸟种群 $\Omega = \{G_i | i \in N \text{ 且 } 1 \leq i \leq N_{POP}\}$ ,每个候鸟个体编码 $G_i$ 中各车型编码出现的次数与该车型批次一致。

2.2.2 基于启发式规则的候鸟个体解码与评价

由于汽车整车多关联车间协同排产优化问题规模大,为了提高解码速度,设计了基于启发式规则的候鸟个体解码与评价方法,其主要流程如图3所示,以  $G_i = \{A, B, A, C, B, A, C\}$  为例,结合表1与表2,具体解码与评价流程如下:

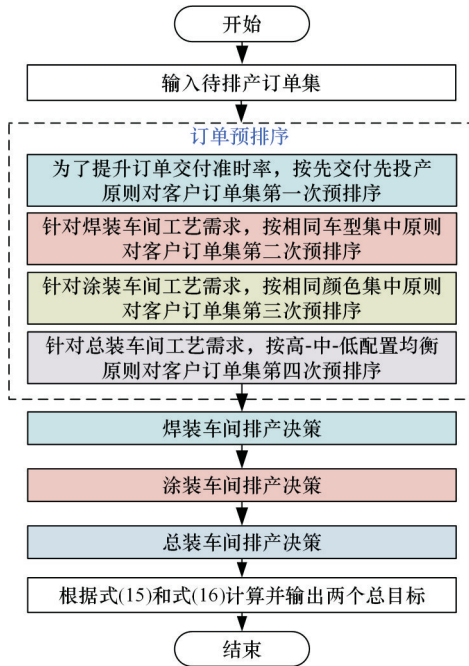


图3 基于启发式规则的候鸟个体解码与评价流程  
Fig.3 The decoding and evaluation process of the migrating birds based on heuristic rules

1)输入客户订单集,从排序规则库中依次采用多条启发式规则对客户订单进行预排序。首先为了提高订单交付的准时率、降低订单拖期违约

成本,按先交付先投产的原则对客户订单进行第一次预排序;其次为了减少焊装车间换车型的次数、减少总停产时间并降低成本,在第一次预排序的基础上,再按相同车型集中的原则对客户订单进行第二次预排序;为了减少涂装车间换色次数,减少总停产时间并降低成本,在第二次预排序的基础上,在相同车型内部再按相同颜色集中的原则对客户订单进行第三次预排序;最后为了均衡总装车间负荷,在第三次预排序的基础上,在相同颜色内部按低、中、高配置均衡的原则对客户订单进行第四次预排序,依次完成上述四次预排序后,进入步骤2),以表2所示订单为例,每次预排序后的结果见表4。

表4 客户订单集每次预排序结果

Tab.4 Each pre-sort result of the customer order collection

预排序次数	客户订单每次预排序后的订单编号序列
第一次	1,7,9,11,15,17,2,5,8,10,13,16,18,3,4,6,12,14
第二次	1,7,11,5,10,13,16,4,17,2,8,14,9,15,18,3,6,12
第三次	1,11,13,16,7,5,10,4,17,2,8,14,9,15,18,3,6,12
第四次	13,1,16,11,7,4,5,10,2,17,8,14,15,9,18,3,6,12

2)焊装车间排产决策。以  $N_w^{MIN}$  作为批量上限,按候鸟个体编码给定车型序列,从第四次预排序后的订单中依次取出对应车型的订单,获得的订单序列直接作为焊装车间的排产序列  $\Omega^w$ 。完成后转步骤3)。以表4所示预排序结果为例,假定候鸟个体编码为  $G_i = \{A, B, A, C, B, A, C\}$ ,  $N_w^{MIN} = 3$ ,焊装车间排产序列决策示意图见图4。

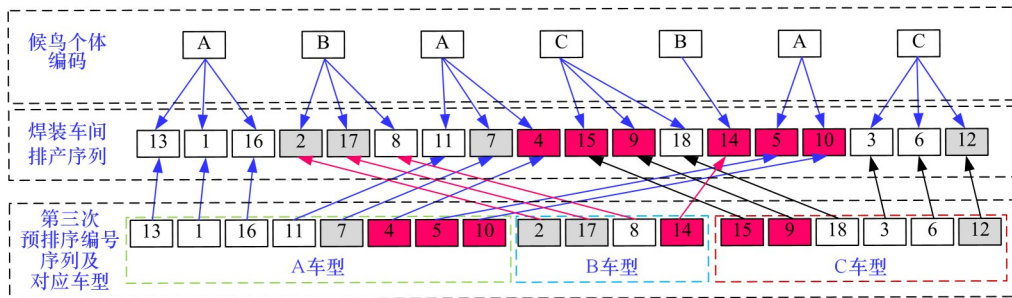


图4 焊装车间排产序列决策示意图

Fig.4 Schematic diagram of production sequence decision in welding workshop

3)涂装车间排产决策。以  $N_{max}^{TW}$  作为立体库白车身调序上限,按相同颜色集中原则对焊装车间的排产序列集合  $\Omega^w$  重新排序以获取涂装车间的排产序列集合  $\Omega^p$ 。完成后转步骤4)。以图4所示焊装车间排产序列  $\Omega^w$  和  $N_{max}^{TW} = 3$  为例,涂装车间排产序列决策示意图见图5。以客户订单8为例,其在焊装车间的排产顺序号为6,而在涂装

车间的排产顺序为4,需向前调序2位。  
4)总装车间排产决策。以  $N_{max}^{TP}$  作为立体库彩车身调序上限,按配置  $\{L, M, H\}$  的优先顺序对涂装车间的排产序列集合  $\Omega^p$  重新排序以获取总装车间的排产序列集合  $\Omega^a$ 。完成后转步骤5)。以图5所示涂装车间排产序列  $\Omega^p$  和  $N_{max}^{TP} = 3$  为例,总装车间排产序列决策示意图见图6。以客

户订单11为例,其在涂装车间的排产顺序号为5, 5)根据式(15)及式(16)计算两个总目标以评价候鸟个体,解码结束。




图5 涂装车间排产序列决策示意图

Fig.5 Schematic diagram of paint shop production sequence decision




图6 总装车间排产序列决策示意图

Fig.6 Schematic diagram of production sequence decision in the final assembly workshop

2.3 基于双目标非支配排序的V形队列构建策略

由构建的汽车整车多关联车间协同排产优化数学模型可知,本文以最小化焊装及涂装车间总停产时间和最小化成本为优化目标,属于双目标优化问题,具体可表示为

$$\min F(G) = \min \{ f_A(G), f_B(G) \} \quad (26)$$

s.t.  $G \in \Omega$

式中: $f_A(G)$ 、 $f_B(G)$ 分别为候鸟个体 $G$ 经解码后分别通过式(15)和式(16)计算的焊装及涂装车间总停产时间和总成本; $\Omega$ 为整个候鸟编码空间。

为了比较不同候鸟个体编码的优劣性,结合多目标优化理论,定义针对候鸟编码空间的Pareto支配、Pareto最优候鸟、Pareto最优候鸟集和Pareto候鸟前沿,具体如下:

**定义1** Pareto支配(简称支配)对于两个候鸟个体 $G_i$ 和 $G_j$ ,若有 $(f_A(G_i) \leq f_A(G_j))$ 且 $f_B(G_i) < f_B(G_j)$ 或 $(f_A(G_i) < f_A(G_j))$ 且 $f_B(G_i) \leq f_B(G_j)$ ,则称解 $G_i$ Pareto支配 $G_j$ ,记为 $G_i < G_j$ 。

**定义2** Pareto最优候鸟或非支配候鸟。在给定的候鸟种群内,若给定候鸟 $G_i$ 不受其他任何候鸟支配,则称 $G_i$ 为给定候鸟种群的Pareto最优候鸟或非支配候鸟。

**定义3** Pareto最优候鸟集或非支配候鸟集。给定候鸟种群中所有Pareto最优候鸟构成的集合称为Pareto最优候鸟集或非支配候鸟集。

**定义4** Pareto候鸟前沿。Pareto最优候鸟集在目标空间的投影称为Pareto候鸟前沿。

基于上述定义,提出针对候鸟种群的V形队列构建方法,具体步骤如下:

1)首先利用2.2节中设计的解码方法对候鸟

种群 $\Omega = \{G_i | i \in N \text{ 且 } 1 \leq i \leq N_{\text{POP}}\}$ 中所有候鸟解码和评价,获取每个候鸟个体 $G_i$ 对应的总停产时间 $f_A(G_i)$ 和总成本 $f_B(G_i)$ 。为了消除两个优化目标量纲不同带来的影响,对候鸟种群每个候鸟的目标函数值进行离差标准化<sup>[23]</sup>,以候鸟个体 $G_i$ 为例,两个目标函数值分别调整如下:

$$f'_A(G_i) = 100 \times (f_A(G_i) - f_A^{\min}) / (f_A^{\max} - f_A^{\min}) \quad (27)$$

$$f'_B(G_i) = 100 \times (f_B(G_i) - f_B^{\min}) / (f_B^{\max} - f_B^{\min}) \quad (28)$$

式中: $f_A^{\max}$ 、 $f_A^{\min}$ 、 $f_B^{\max}$ 、 $f_B^{\min}$ 分别为候鸟种群所有候鸟两目标函数的最大值和最小值。

候鸟种群全部候鸟完成离差标准化后,进入步骤2)。

2)将当前排序等级 $\beta$ 初始化为1并将候鸟种群所有候鸟均标记为未确定排序等级的候鸟,然后根据离差标准化后的目标函数值对候鸟种群进行非支配排序,确定每个候鸟的排序等级,方法如下:将候选种群中所有未确定排序等级的候鸟组成的种群称为未定级候鸟种群,根据定义4确定未定级候鸟种群的Pareto候鸟前沿,将当前Pareto候鸟前沿的每个候鸟等级均设置为当前排序等级 $\beta$ ,完成后更新排序等级 $\beta$ 为: $\beta \leftarrow \beta + 1$ ,重复上述步骤直至确定候鸟种群中所有候鸟的排序等级。完成后,进入步骤3)。

3)计算每个候鸟在候鸟种群中的拥挤度,方法如下:将候鸟种群所有候鸟根据两个目标函数 $f'_A$ 和 $f'_B$ 分别排序,计算所有候鸟经各目标函数排序后与相邻候鸟的距离。例如:若候鸟种群根据离差标准化后的目标函数值 $f'_A$ 排序后的序列为

$$\Omega = \{G_{i,1}, \dots, G_{j,m}, \dots, G_{k,N_{\text{POP}}}\} \quad (29)$$

式中: $G_{j,m}$ 为候鸟种群根据 $f'_A$ 排序后位于第 $m$ 位的候鸟 $G_j$ 。

则候鸟  $G_{j,m}$  在目标函数  $f'_A$  下与其相邻候鸟的距离  $d_A(G_{j,m})$  计算公式为

$$d_A(G_{j,m}) = |f'_A(G_{n,m+1}) - f'_A(G_{l,m-1})| \quad (30)$$

候鸟  $G_{j,m}$  的拥挤度  $CRO(G_{j,m})$  计算公式为

$$CRO(G_{j,m}) = d_A(G_{j,m}) + d_B(G_{j,m}) \quad (31)$$

式中:  $d_B(G_{j,m})$  为候鸟  $G_{j,m}$  按目标函数  $f'_B$  排序后与其相邻候鸟的距离。

计算完所有候鸟经各目标函数排序后与相邻候鸟的距离后,转步骤4)。

4)根据候鸟种群各候鸟排序等级和拥挤度构建V形队列,方法如下:从排序等级为1的候鸟中选择拥挤度最高的候鸟作为领飞鸟,其余候鸟按照排序等级逐级均匀分配至左右跟飞鸟种群,排序等级越低的跟飞鸟越靠近领飞鸟,相同排序等级则拥挤度越大的跟飞鸟越靠近领飞鸟,最终实现候鸟种群V形队列的构建。

### 2.4 基于多种邻域结构的领飞鸟进化策略

为了避免单一邻域结构造成领飞鸟进化方向单一,加快算法的收敛速度,本文设计了基于多种邻域结构的领飞鸟邻域搜索,三种邻域结构如下。

1)基于逆序的邻域结构。基于逆序的邻域候鸟示意图见图7,根据编码长度随机选择原候鸟编码中的两个位置  $POS_1$  和  $POS_2$ ,将原候鸟编码  $POS_1$  和  $POS_2$  之间的车型编码按照逆序重新排列,即可获得某个基于逆序的邻域候鸟。




图7 基于逆序的邻域候鸟示意图

Fig.7 Schematic diagram of the migrating birds in the neighborhood based on reverse sorting

2)基于单点变异的邻域结构。基于单点变异的邻域候鸟示意图见图8,随机选择原候鸟编码中车型不同的两个位置  $POS_1$  和  $POS_2$ ,将原候鸟编码  $POS_1$  和  $POS_2$  对应的车型交换位置,即可获得某个基于单点变异的邻域候鸟。

3)基于右环移的邻域结构。基于右环移1位的邻域候鸟示意图见图9,将原候鸟最低位的车型编码移至最高位,其余位置编码依次右移一位,即可获得基于右环移1位的邻域候鸟。每右环移1位即可获得原候鸟的一邻域候鸟,因此,通过右环移的方式最多可获得  $N_B - 1$  个邻域候鸟,其中  $N_B$  为候鸟编码的长度。




图8 基于单点变异的邻域候鸟示意图

Fig.8 Schematic diagram of the migrating birds in the neighborhood based on single-point mutation




图9 基于右环移1位的邻域候鸟示意图

Fig.9 Schematic diagram of the migrating birds in the neighborhood based on a right ring shift of 1 bit

通过上述三种邻域结构随机产生领飞鸟的  $N_N$  个邻域解,这些邻域解组成领飞鸟的进化解集,对进化解集进行非支配排序,确定其Pareto候鸟前沿,采用以下策略更新领飞鸟:①若Pareto候鸟前沿中存在支配领飞鸟的邻域候鸟,则从中随机选择某支配领飞鸟的邻域候鸟替代领飞鸟。②若进化解集中不存在支配领飞鸟的邻域候鸟,则不更新领飞鸟。

### 2.5 融合交叉与邻域搜索的跟飞鸟进化策略

传统跟飞鸟的进化根据前序共享的邻域实现跟飞鸟的进化,会使鸟群趋于一致,导致算法易陷入局部最优。为改善这一缺陷,本文引入NSGA-II的交叉遗传算子,设计了结合交叉与邻域搜索的跟飞鸟进化策略,具体如下:就左右跟飞鸟种群中的每个跟飞鸟而言,均需构建各自的进化候鸟集,进化候鸟集中的候鸟个体有以下三个来源:

1)前序候鸟提供的共享解。若是第一个跟飞鸟,则共享解是领飞鸟进化解集中的次优解;反之,则共享解是上一跟飞鸟进化解集中的次优解。

2)该跟飞鸟的邻域候鸟。根据2.4节定义的三种邻域结构,随机生成该跟飞鸟的多个邻域候鸟。

3)跟飞鸟交叉产生的新候鸟。随机选择  $N_p$  只位于该跟飞鸟前面的跟飞鸟(前列跟飞鸟),每个选择的前列跟飞鸟均可通过交叉的方式与该跟飞鸟产生一个新候鸟,通过跟飞鸟交叉产生新候鸟的示意图见图10,首先将原跟飞鸟和参与交叉的某前列跟飞鸟编码根据各车型在编码中出现的次数转变为带序列的编码;其次随机产生两个位置  $POS_1$  和  $POS_2$ ,将原跟飞鸟两位置间的编码根

据其在前列跟飞鸟中的顺序重新排列,从获得新的带序列跟飞鸟编码;最后去除编码中的序列,即可获得交叉后的新跟飞鸟。




图 10 通过跟飞鸟交叉产生新候鸟的示意图

Fig. 10 Schematic diagram of generating new migrating birds by crossing with following birds

对进化候鸟集中的每个个体进行解码评价,通过非支配排序获取进化候鸟集的 Pareto 候鸟前沿,若 Pareto 候鸟前沿中存在支配原跟飞鸟的进化候鸟,则以进化候鸟替代原跟飞鸟。

### 2.6 基于 IMBOA 的协同排产方法流程

本文设计的基于 IMBOA 的协同排产方法流程如图 2 所示,具体步骤如下:

1)初始化。随机生成初始候鸟种群,采用基于启发式规则的候鸟个体解码与评价方法对初始候鸟种群中的每个候鸟个体解码并评价,确定每个候鸟对应的总停产时间和总成本,完成后转步骤 2)。

2)采取基于双目标非支配排序的 V 形队列构建策略实现候鸟种群 V 形队列,转步骤 3)。

3)采取基于多种邻域结构的领飞鸟进化策略实现领飞鸟进化,转步骤 4)。

4)采取融合交叉与邻域搜索的跟飞鸟进化策略实现跟飞鸟进化,转步骤 5)。

5)判断是否达到巡回次数,若已达到巡回次数,转步骤 6);否则,转步骤 2)。

6)对领飞鸟解码并评价,输出领飞鸟对应的排产方案,排产结束。

## 3 实验分析

### 3.1 仿真实验平台开发与主要参数设置

为了验证所设计的整车多关联车间协同排产方法效果,以西门子公司 Tecnomatix Plant Simulation 15.0 为开发工具,以国内新投产的某新能源汽车生产线为实例,开发考虑立库调序能力的整车多关联车间协同排产仿真分析平台。该新能源汽车生产线每天生产 8 h,一周生产 5 d,可

混流生产(A、B、C、D、E、F)6种车型,每种车型有高、中、低三种配置可供客户选择,每种配置有 12 种颜色,规划生产节拍为 60 s/辆;焊装车间主要参数如下:  $N_w^{\text{MIN}} = 20$ ,  $\theta_w = 6 \text{ min/次}$ ,  $\mu_w = 300 \text{ 元/次}$ ;涂装车间主要相关参数如下:  $\theta_c = 4 \text{ min/次}$ ,  $a_c = 200 \text{ 元/次}$ ,  $N_c^{\text{MAX}} = 20$ 辆;彩车身立体库由 5 台堆垛机组成,每台堆垛机可从两侧货架存取彩车身,每排货架有 6 层 5 行共 30 个车位,  $N_{\text{max}}^{\text{TW}} = 60$  辆,  $N_{\text{max}}^{\text{TP}} = 60$  辆;总装车间主要相关参数如下:  $a_t = 600 \text{ 元/次}$ ,  $a_v = 600 \text{ 元/辆}$ ,  $\lambda = 200 \text{ 元/d}$ ,利用该平台从以下方面验证本文方法。

### 3.2 多目标优化算法评价指标的选择

查阅文献[24-28]可知,评价多目标优化算法性能的指标主要有反向世代距离(IGD)、世代距离(GD)、超体积(HV), $\epsilon$  指标(Epsilon indicator)等,本文选用最广泛采用 IGD 和 HV 作为本文多目标优化算法的评估指标。两者含义及计算公式分别介绍如下:

1)IGD 表示真实 Pareto 最优候鸟集到算法所得近似 Pareto 最优候鸟集的平均最短欧氏距离,能够综合评价近似 Pareto 最优候鸟集的收敛性和多样性。IGD 值越小,意味着算法搜索到的近似 Pareto 最优候鸟集更接近真实的 Pareto 最优候鸟集,说明算法搜索性能越优越,IGD 值的计算公式如下:

$$IGD(\Omega^*, \Omega_{\beta=1}) = \frac{1}{|\Omega^*|} \sum_{G_i \in \Omega^*} \min_{G_j \in \Omega_{\beta=1}} \text{dis}(G_i, G_j) \quad (32)$$

式中:  $\Omega^*$  为真实 Pareto 最优候鸟集,本文设定为所有算法搜索得到的全部候鸟集的 Pareto 最优候鸟集;  $\Omega_{\beta=1}$  为待评价算法搜索到的近似 Pareto 最优候鸟集;  $|\Omega^*|$  为真实 Pareto 最优候鸟集中的候鸟数量;  $\text{dis}(G_i, G_j)$  为候鸟  $G_i$  与候鸟  $G_j$  在两个优化目标空间中的欧氏距离。

2)HV 值表示待评价算法搜索到的近似 Pareto 最优候鸟集中各候鸟与参考候鸟所围成的目标空间的体积, HV 值越大,表示算法的收敛性和多样性越好, HV 值的计算公式如下:

$$HV(\Omega_{\beta=1}, G_{\text{ref}}) = \text{vol}(\cup_{G_j \in \Omega_{\beta=1}} \text{sou}(G_j, G_{\text{ref}})) \quad (33)$$

式中:  $G_{\text{ref}}$  为参照候鸟,其被近似 Pareto 最优候鸟集  $\Omega_{\beta=1}$  中所有候鸟支配;  $\text{vol}()$  为超立方体的体积计算函数;  $\text{sou}(G_j, G_{\text{ref}})$  为候鸟  $G_j$  与参照候鸟  $G_{\text{ref}}$  所围成的超立方体。

### 3.3 算法改进策略的有效性验证

针对传统候鸟优化算法(traditional MBOA, TMBOA)的邻域结构单一、易陷入局部最优的缺陷,本文分别设计了基于多种邻域结构的领飞鸟进化策略、融合交叉与邻域搜索的跟飞鸟进化策略,为了验证上述两种策略的有效性,将 IMBOA

与三种变体算法进行对比,各算法主要参数如下:

1) TMBOA,  $N_{POP}$  为 40, 最大巡回次数为 600。

2) 基于多种邻域结构的候鸟优化算法 (MBOABMNS), 采用仅有前序共享的跟飞鸟进化,  $N_N$  为 10, 其他参数与 TMBOA 算法相同。

3) 结合交叉与邻域搜索的候鸟优化算法 (MBOACCNS), 采用基于单一邻域结构的领飞鸟进化,  $N_p$  为 3, 其他参数与 TMBOA 算法相同。

4) 本文提出的 IMBOA 算法,  $N_N$  为 10,  $N_p$  为 3, 其他参数与 TMBOA 算法相同。

以一周 2400 辆车的排产为例, 根据实际订单数据, 利用仿真平台每隔 5 min 采集上述四种算法各自搜索到的近似 Pareto 最优候鸟集, 将四种算法在 20 min 搜索到的近似 Pareto 最优候鸟集合并, 进而获取几种算法的综合 Pareto 最优候鸟集, 并将该综合 Pareto 最优候鸟集作为计算 IGD 时的真实 Pareto 最优候鸟集。每种算法仿真 5 次, 各算法在各时刻获取的近似 Pareto 最优候鸟集对应的 IGD 值和 HV 值分别如图 11、图 12 所示, 四种算法取得最优 IGD 值时对应的近似 Pareto 最优候鸟集如图 13 所示。

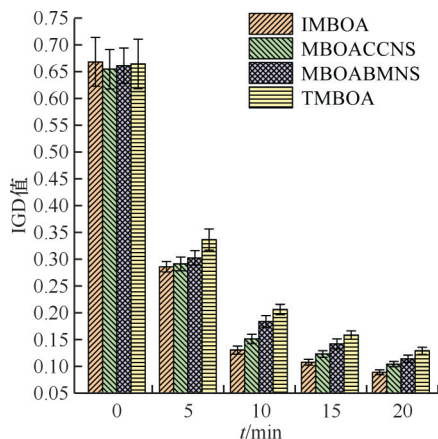


图 11 各算法近似 Pareto 最优候鸟集对应的 IGD 值  
Fig.11 IGD values corresponding to each approximate Pareto optimal migratory bird set of each algorithm at each time

由于四种算法的初始候鸟种群均通过随机方式生成, 故在 0 min 时, 几种算法获得的 IGD 值较大而 HV 值较小, 且标准差较大。随着巡回时间的增加, 几种算法 IGD 值显著减小的同时 HV 值显著增大, 而标准差明显降低, 这表明随着巡回时间的增加, 几种算法均能获得更优的 Pareto 最优候鸟集, 且具有较高的稳定性。对比四种算法可知, TMBOA 算法没有使用任何改进策略, 因此在各时刻对应的 IGD 值最高而 HV 值最低, 表明




图 12 各算法近似 Pareto 最优候鸟集对应的 HV 值  
Fig.12 HV values corresponding to each approximate Pareto optimal migratory bird set of each algorithm at each time

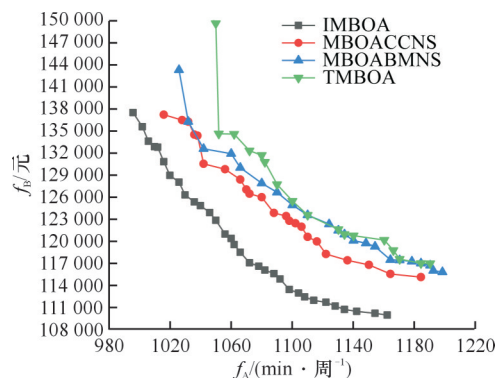


图 13 各算法最优 IGD 对应的近似 Pareto 最优候鸟集  
Fig.13 Approximate Pareto optimal migratory bird set corresponding to the optimal IGD of each algorithm

TMBOA 算法的寻优能力最差。MBOABMNS 算法采用基于多种邻域结构的领飞鸟进化以改善 TMBOA 算法收敛速度慢的缺陷, 故其对应的 IGD 和 HV 值均优于 TMBOA 算法, 但由于其没有保证种群的多样性, 易陷入局部最优, 其 IGD 值和 HV 值劣于 MBOACCNS 算法。而 MBOACCNS 算法采取的结合交叉与邻域搜索的跟飞鸟进化策略能够在一定程度上维持了鸟群多样性, 从而提高了整体寻优能力, 如图 11、图 12 所示, MBOACCNS 算法对应的 IGD 和 HV 值均优于 MBOABMNS 和 TMBOA 算法。而本文设计的 IMBOA 算法不仅采用基于多种邻域结构的领飞鸟进化以改善单一邻域结构导致的算法收敛速度慢的缺陷, 而且应用了结合交叉与邻域搜索的跟飞鸟进化策略以维持鸟群多样性, 不仅具有较快的收敛速度, 而且具有较好的全局寻优能力, 除 0 min 以外, IMBOA 算法在各时刻均能够获得最低的 IGD 值和最高的 HV 值。以 20 min 为例,

IMBAO算法对应的IGD值和HV值分别为0.089和0.979,比TMBOA算法所能实现的0.129和0.842分别降低或提高31.05%和14.00%。如图13所示,IMBAO算法取得最优IGD值时对应的近似Pareto最优候鸟集不仅支配其余三种算法获得的近似Pareto最优候鸟集,而且各候鸟在非支配前沿的分布更为均衡,证明了本文改进策略的有效性。

### 3.4 IMBAO与其他算法的对比

为了进一步验证IMBAO算法的有效性,将IMBAO算法与非支配排序遗传算法-II(NSGA-II)、传统蚁群算法(TACA)及已有的求解类似汽车排产问题的改进的蚁群算法(IACA)<sup>[10]</sup>、非支配排序遗传算法-III(non-dominated sorting genetic algorithm III, NSGA-III)<sup>[17]</sup>进行对比,各算法主要操作及参数如下:

1)NSGA-I。编码与解码方式与本文提出的IMBAO算法相同,遗传算子仅包括经典的双点交叉、双点变异算子。由于NSGA-II算法采取带精英保留的非支配排序策略,即在每代种群更新时均将父代种群和子代种群合并,通过非支配排序确定每个个体在种群中的等级和拥挤度,低等级且拥挤度高的个体被选中进化的概率越高。该策略能够保证新种群是父代和子代的优秀个体,故本文实验时交叉率和变异率均设置为1。种群规模为50,进化代数数为600。

2)TACA。一定数量的蚂蚁构成蚂蚁种群,每个蚂蚁均对应焊装车间的一个可行的车型切换序列,再采用本文设计的解码方法对车型切换序列解码,即可获得蚂蚁对应的排产方案。而每个蚂蚁生成时先随机选择一个车型作为起始车型,然后根据信息素浓度选择下一车型,蚂蚁从当前车型 $D_i$ 切换至下一车型 $D_j$ 的概率为 $P_{ij}$ ,其计算公式为

$$P_{ij} = \begin{cases} \frac{\epsilon_{ij}}{\sum_{D_j \in allowed(D_i)} \epsilon_{ij}} & D_j \in allowed(D_i) \\ 0 & D_j \notin allowed(D_i) \end{cases} \quad (34)$$

式中: $\epsilon_{ij}$ 为信息素浓度函数; $allowed(D_i)$ 为当前车型 $D_i$ 可切换的下一车型集合。

每个蚂蚁基于上述概率函数随机确定下一车型,最终形成的车型序列。根据文献[10]中的信息素更新策略,蚂蚁种群形成后首先确定总成本最小的蚂蚁,若总成本最小存在多个蚂蚁,则寻找其中总停产时间最小的蚂蚁,根据该蚂蚁的车型切换序列按文献[10]中的式(10)和式(11)进行全局信息素更新。下一次搜索时,种群中的每个蚂蚁再

根据更新后的信息素重新搜索更优序列。重复上述步骤,直至达到搜索代数。蚂蚁种群规模为50,搜索代数数为600。

3)IACA<sup>[10]</sup>。IACA算法的编码与解码、蚂蚁搜索流程等与TACA算法基本相同。改进之处在于:为改善TACA难以维持蚁群多样性、易陷入局部最优的缺陷,文献[10]引入信息素局部更新策略,当每只蚂蚁完成搜索时均根据其序列更新局部信息素,以避免其他蚂蚁搜索时做出同样选择。另外,为了加快算法收敛速度,在概率 $P_{ij}$ 中加入了启发函数。参考该策略,本文实验时将IACA算法的 $P_{ij}$ 更新为

$$P_{ij} = \begin{cases} \frac{\epsilon_{ij} \partial_{ij}^{0.5}}{\sum_{D_j \in allowed(D_i)} \epsilon_{ij} \partial_{ij}^{0.5}} & D_j \in allowed(D_i) \\ 0 & D_j \notin allowed(D_i) \end{cases} \quad (35)$$

其中, $\partial_{ij}$ 为启发函数,计算公式为

$$\partial_{ij} = \frac{1}{1 + \Delta f_{1,1}(ij)} \frac{1}{1 + \Delta f_{1,2}(ij)} \quad (36)$$

式中: $\Delta f_{1,1}(ij)$ 、 $\Delta f_{1,2}(ij)$ 分别为焊装车间从当前车型 $D_i$ 切换至下一车型 $D_j$ 时焊装车间分目标函数 $f_{1,1}$ 和 $f_{1,2}$ 的变化量。

4)NSGA-III<sup>[17]</sup>。文献[17]采用的NSGA-III算法与NSGA-II算法步骤基本相同,区别主要在新种群个体选择机制。NSGA-II算法根据个体的排序等级和拥挤度选择新一代个体,而NSGA-III算法则采用基于参考点和小生境操作的新个体选择机制。试验时所有参数与NSGA-II算法相同,每次产生的参考点数量与种群数相同。

利用仿真平台每隔5 min采集上述四种对比算法搜索到的近似Pareto最优前沿,每种算法仿真5次,IMBOA、IMBOA算法及四种对比算法在各时刻获取的近似Pareto最优解集对应的IGD和HV值分别如图14、图15所示,6种算法取得最优IGD值时对应的近似Pareto最优解集如图16所示。




图14 各时刻各算法近似Pareto最优解集对应的IGD值  
Fig.14 IGD values corresponding to the approximate Pareto solution set of each algorithm at each time

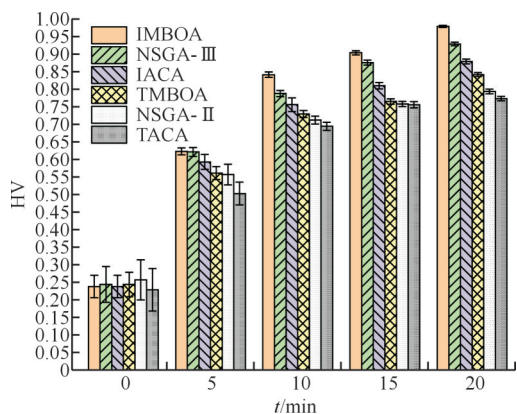


图15 各时刻各算法近似 Pareto 解集对应的 HV 值

Fig.15 HV values corresponding to the approximate Pareto solution set of each algorithm at each time

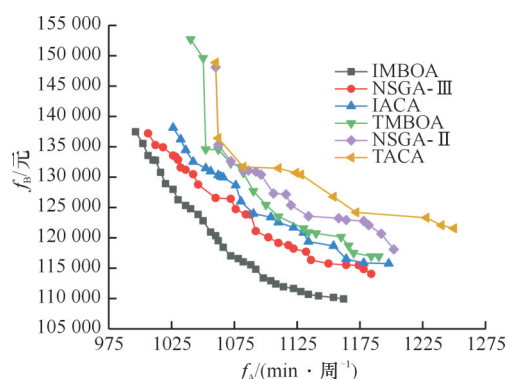


图16 各算法最优 IGD 对应的近似 Pareto 最优解集

Fig.16 Approximate Pareto optimal solutions corresponding to the optimal IGD of each algorithm

图14和图15中,在0 min时,各种算法均通过随机方式产生初始种群,因此,各算法非支配前沿对应的IGD值较高而HV值较低,两者标准差较高。随着寻优时间的增加,各算法IGD值逐步减小而HV值逐步增加。这表明随着寻优时间的增加,各算法均能够向非支配前沿方向收敛。对比几种算法可知,TACA算法由于仅在每轮搜索结束后通过最优蚂蚁释放信息素实现正反馈的方式实现寻优,故其收敛速度慢,且各蚂蚁在搜寻过程中基于相同的信息素状态,难以维持蚂蚁种群的多样性,易陷入局部最优,其在各时刻对应的IGD值最高而HV值最低。而NSGA-II算法通过交叉操作以实现父代种群的优秀基因遗传至子代个体,通过变异算子避免算法陷入局部最优,如图14和图15所示,其IGD和HV值略优于TACA算法。TMOBA算法不仅在领飞鸟进化中采用单一结构邻域搜索,而且跟飞鸟进化中应用了与前序候鸟的邻域共享机制,这两种策略均能够提升算法的收敛速度,因此其IGD和HV值总体优于TACA和NSGA-II算法。在TACA算法的

基础上,IACA算法采取信息素局部更新策略避免各蚂蚁在每轮搜索时做出相同决策,能够提高蚂蚁群的多样性,并在概率函数中增加了启发函数以提升算法收敛速度,因此IACA算法的性能优于TACA、NSGA-II和TMOBA算法。NSGA-III算法则采用基于参考点和小生境操作的在新个体选择机制,能够提高种群个体分布的均衡性,从而提高算法全局寻优性能,因此,其IGD和HV值显著优于上述TACA、NSGA-II等四种算法。而本文IMBOA算法不仅在领飞鸟进化中采取基于多邻域结构的邻域搜索策略,而且在跟飞鸟进化中引入了NSGA-II算法的交叉遗传算子,采取结合交叉与邻域搜索的跟飞鸟进化策略,取得了较优的全局寻优能力,如图14和图15所示,IMBOA算法在各时刻均能够获得比其他几种算法更优的IGD和HV值。如图16所示,与其他几种算法相比,IMBOA算法取得最优IGD值时对应的近似Pareto最优候鸟集不仅更接近非支配前沿,而且各前沿个体在前沿的分布更为均衡,从而证明了IMBOA算法的有效性。

#### 4 结语

汽车整车生产线中的焊装、涂装和总装车间构成了相互关联的流水车间,但由于各车间工艺需求和约束条件的差异,每个车间均有各自的排产需求和约束条件的差异,每个车间均有各自的排产需求。为了满足汽车整车各关联车间对车身排产序列的不同需求,本文首先以最小化总停产时间和平均总成本为优化目标,考虑各车间间立体库对白车身及彩车身的随机调序范围约束,建立了汽车整车多关联车间协同排产优化数学模型;然后提出了结合IMBOA算法与启发式规则的排产方法,为了改善单一邻域结构导致的算法收敛速度慢的缺陷,设计了基于多种邻域结构的领飞鸟进化策略,为了提升算法全局寻优能力,设计了结合交叉与邻域搜索的跟飞鸟进化策略;最后以国内新投产的某新能源汽车生产线为实例,开发了考虑立体库随机调序能力的整车多关联车间协同排产仿真分析平台,实验结果表明,与IGA、IACO、ATICA和TGA算法相比,IMBOA算法能够获得更优的解集,从而证明了所设计的IMBOA算法的有效性。在实验中,本课题组已发现立体库白车身和彩车身的最大调序范围的设置对总成本有较大影响,因此,汽车排产问题与立体库最大调序范围的集成优化问题将是课题组下一步的研究方向。

参考文献:

- [1] LU Chao, XIAO Shengqiang, LI Xinyu, et al. An Effective Multi-objective Discrete Grey Wolf Optimizer for a Real-world Scheduling Problem in Welding Production [J]. *Advances in Engineering Software*, 2016, 99(C):161-176.
- [2] 孟磊磊, 张超勇, 邵新宇, 等. 基于约束规划的焊接车间多资源约束调度研究[J]. *华中科技大学学报(自然科学版)*, 2018, 46(6):1-7.  
MENG Leilei, ZHANG Chaoyong, SHAO Xinyu, et al. Constraint Programming for Multi-resource Constrained Welding Shop Scheduling [J]. *Journal of Huazhong University of Science and Technology (Natural Science Edition)*, 2018, 46(6):1-7.
- [3] WANG Jingjing, WANG Ling, XIU Xia. A Cooperative Memetic Algorithm for Energy-aware Distributed Welding Shop Scheduling Problem [J]. *Engineering Applications of Artificial Intelligence*, 2023, 120:105877.
- [4] WANG Cuiyu, ZHAO Li, LI Xinyu, et al. An Improved Grey Wolf Optimizer for Welding Shop Inverse Scheduling [J]. *Computers & Industrial Engineering*, 2022, 163:107809.
- [5] RAO Yunqing, MENG Ronghua, ZHA Jing, et al. Bi-objective Mathematical Model and Improved Algorithm for Optimisation of Welding Shop Scheduling Problem [J]. *International Journal of Production Research*, 2020, 58(9):2767-2783.
- [6] KRYSSTEK J, BYSKO S. The Follow-up Control of the Body Sequencing Process at the Paint Shop [J]. *Mechanik*, 2019(7):462-464.
- [7] WINTER F, MUSLIU N. Constraint-based Scheduling for Paint Shops in the Automotive Supply Industry [J]. *ACM Transactions on Intelligent Systems and Technology*, 2021, 12(2):1-25.
- [8] CHUTIMA P, SUCHANUN T. Productivity Improvement with Parallel Adjacent U-shaped Assembly Lines [J]. *Advances in Production Engineering & Management*, 2019, 14(1):51-64.
- [9] THIRUVADY D, MORGAN K, AMIR A, et al. Large Neighbourhood Search Based on Mixed Integer Programming and Ant Colony Optimisation for Car Sequencing [J]. *International Journal of Production Research*, 2020, 58(9):2696-2711.
- [10] 李焱, 唐倩, 刘联超, 等. 基于改进蚁群算法的汽车混流装配调度模型求解[J]. *中国机械工程*, 2021, 32(9):1126-1133.  
LI Yi, TANG Qian, LIU Lianchao, et al. An Improved ACO Algorithm for Automobile Mixed-flow Assembly Scheduling Problems [J]. *China Mechanical Engineering*, 2021, 32(9):1126-1133.
- [11] ZHANG Beikun, XU Liyun, ZHANG Jian. A Multi-objective Cellular Genetic Algorithm for Energy-oriented Balancing and Sequencing Problem of Mixed-model Assembly Line [J]. *Journal of Cleaner Production*, 2020, 244:118845.
- [12] LOUIS A, ALPAN G, PENZ B, et al. Mixed-model Sequencing versus Car Sequencing: Comparison of Feasible Solution Spaces [J]. *International Journal of Production Research*, 2023, 61(10):3415-3434.
- [13] SHI Xiaolin, TIAN Xitian, GU Jianguo, et al. A Hybrid Approach of Case- and Rule-based Reasoning to Assembly Sequence Planning [J]. *The International Journal of Advanced Manufacturing Technology*, 2023, 127(1):221-236.
- [14] GUO Kai, LIU Rui, DUAN Guijiang, et al. Research on Dynamic Decision-making for Product Assembly Sequence Based on Connector-linked Model and Deep Reinforcement Learning [J]. *Journal of Manufacturing Systems*, 2023, 71:451-473.
- [15] 沈振宇, 唐倩, 黄涛, 等. 面向均衡生产的多级流水车间调度模型求解[J]. *计算机集成制造系统*, 2019, 25(11):2743-2752.  
SHEN Zhenyu, TANG Qian, HUANG Tao, et al. Solution of Multistage Flow Shop Scheduling Model for Leveling Production [J]. *Computer Integrated Manufacturing Systems*, 2019, 25(11):2743-2752.
- [16] 杜宝钗. 多车间多产线工厂布局下的汽车关联排序问题[D]. 北京: 北京交通大学, 2022.  
DU Baochai. Car Linkage Sequencing Problem for Multi Mixed-Assembly Lines in Multi Workshops [D]. Beijing: Beijing Jiaotong University, 2022.
- [17] 李聪波, 赵德, 杨秒, 等. 汽车整车多级生产线协同排序优化方法[J]. *计算机集成制造系统*, 2024, 30(6):2025-2035.  
LI Congbo, ZHAO De, YANG Miao, et al. Collaborative Sequencing Optimization Method for Automobile Multi-stage Production Line [J]. *Computer Integrated Manufacturing Systems*, 2024, 30(6):2025-2035.
- [18] WU Jiayi, DING Yongkang, SHI Leyuan. Mathematical Modeling and Heuristic Approaches for a Multi-stage Car Sequencing Problem [J]. *Computers & Industrial Engineering*, 2021, 152:107008.
- [19] YANG Miao, LI Congbo, TANG Ying, et al. A Collaborative Resequencing Approach Enabled by

- Multi-core PREA for a Multi-stage Automotive Flow Shop[J]. *Expert Systems with Applications*, 2024, 237:121825.
- [20] 王秋莲, 段星皓. 基于高维多目标候鸟优化算法的柔性作业车间调度[J]. *中国机械工程*, 2022, 33(21):2601-2612.
- WANG Qiulian, DUAN Xinghao. Scheduling of Flexible Job Shop Based on High-dimension and Multi-objective Migrating Bird Optimization Algorithm[J]. *China Mechanical Engineering*, 2022, 33(21):2601-2612.
- [21] ZHANG Zikai, TANG Qiuhua, HAN Dayong, et al. Multi-manned Assembly Line Balancing with Sequence-dependent Set-up Times Using an Enhanced Migrating Birds Optimization Algorithm[J]. *Engineering Optimization*, 2023, 55(7):1243-1262.
- [22] FU Yaping, MA Xiaomeng, GAO Kaizhou, et al. Multi-objective Migrating Birds Optimization for Solving Stochastic Home Health Care Routing and Scheduling Problems Considering Caregiver Working Time Constraints[J]. *Swarm and Evolutionary Computation*, 2024, 85:101484.
- [23] 肖海宁, 楼佩煌, 武星, 等. 多载量自动导引车系统防死锁任务调度方法[J]. *计算机集成制造系统*, 2022, 28(11):3325-3339.
- XIAO Haining, LOU Peihuang, WU Xing, et al. Deadlock-free Dispatching Method for Multiple-load Automatic Guided Vehicle System[J]. *Computer Integrated Manufacturing Systems*, 2022, 28(11):3325-3339.
- [24] ZITZLER E, THIELE L, LAUMANN M, et al. Performance Assessment of Multiobjective Optimizers: an Analysis and Review[J]. *IEEE Transactions on Evolutionary Computation*, 2003, 7(2):117-132.
- [25] GUERREIRO A P, FONSECA C M, PAQUETE L. The Hypervolume Indicator: Computational Problems and Algorithms[J]. *ACM Computing Surveys*, 2021, 54(6):1-42.
- [26] KOUKA N, BENSALID F, FDHILA R, et al. A Novel Approach of Many-objective Particle Swarm Optimization with Cooperative Agents Based on an Inverted Generational Distance Indicator[J]. *Information Sciences*, 2023, 623:220-241.
- [27] SHANG Ke, ISHIBUCHI H, HE Linjun, et al. A Survey on the Hypervolume Indicator in Evolutionary Multiobjective Optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2021, 25(1):1-20.
- [28] 王洪, 吴立辉, 陈达, 等. 基于孪生人工蜂鸟算法的多作业模式半导体封测环节调度[J]. *中国机械工程*, 2024, 35(2):260-267.
- WANG Hong, WU Lihui, CHEN Da, et al. Scheduling in SAT in Multi-operation Mode Based on Artificial Hummingbird Algorithm with Twin Population[J]. *China Mechanical Engineering*, 2024, 35(2):260-267.

(编辑 陈 勇)

作者简介:肖海宁\*,男,1985年生,副教授、博士。研究方向为车间智能调度、生产物流系统仿真分析与优化调控技术。发表论文20余篇。E-mail: xiao226563@163.com。

**本文引用格式:**

肖海宁, 孙慧慧, 彭明花, 等. 基于改进候鸟优化算法的整车多关联车间协同排产方法[J]. *中国机械工程*, 2025, 36(8):1796-1810.

XIAO Haining, SUN Huihui, PENG Minghua, et al. An IMBOA Based Collaborative Sequencing Method for Automotive Multi Associated Workshops[J]. *China Mechanical Engineering*, 2025, 36(8):1796-1810.