

DOI:10.3969/j.issn.1003-5060.2025.03.003

# 基于 MGASA 的装配车间物流协同优化方法研究

林健树, 王小巧

(合肥工业大学 机械工程学院, 安徽 合肥 230009)

**摘要:**针对乘用车发动机装配车间内处理大规模订单排产和产品配送调度方案存在求解时间长、效率低、协同优化效果不明显的问题,文章提出一种基于改进遗传模拟退火算法(modified genetic algorithm and simulated annealing, MGASA)的装配车间物流协同优化方法。分析多品种小批量面向订单式生产的乘用车装配车间物流的特点,确定优化目标为最小化客户期望时间、提前延迟成本和物流配送成本;针对问题特征提出装配订单生产配送调度的优先级判定规则和 4 类特征指标以便进行问题编码和适应度计算,并在同一温度下多次进行种群迭代进化和淬火操作,扩大可行解的邻域范围,以期获得全局最优解,得到装配车间内的生产配送调度方案;最后在不同规模的数据集上进行实例验证。实验结果表明,该方法可达到较高的求解效率,实现乘用车装配车间物流协同优化调度方案的快速制定,具有一定的应用价值。

**关键词:**装配车间物流;车辆路径优化;协同优化;改进遗传模拟退火算法(MGASA);时间窗

**中图分类号:**TH186 **文献标志码:**A **文章编号:**1003-5060(2025)03-0302-08

## Research on collaborative optimization of assembly workshop logistics based on MGASA

LIN Jianshu, WANG Xiaoqiao

(School of Mechanical Engineering, Hefei University of Technology, Hefei 230009, China)

**Abstract:** To address the challenges of prolonged solution times, low efficiency, and inadequate collaborative optimization in handling large-scale order scheduling and product distribution scheduling in passenger car engine assembly workshops characterized by multi-variety, small-batch, and order-oriented production, this paper proposes a collaborative optimization method based on modified genetic algorithm and simulated annealing (MGASA). The optimization model aims at minimizing customer expectation time, earliness-tardiness costs, and logistics distribution costs. A priority rule and four categories of characteristic indicators are adopted for problem encoding and fitness evaluation. Iterative population evolution and neighborhood solution generation are repeatedly executed at the same annealing temperature to expand the neighborhood of feasible solutions, facilitating the attainment of a globally optimal solution. Consequently, the production and logistics scheduling schemes for the assembly workshops are determined. Experimental validation conducted on datasets of various sizes demonstrates that the proposed method significantly enhances solution efficiency and supports rapid decision-making in collaborative logistics scheduling, highlighting its practical applicability to passenger car engine assembly workshops.

**Key words:** assembly workshop logistics; vehicle routing optimization; collaborative optimization; modified genetic algorithm and simulated annealing(MGASA); time window

收稿日期:2023-03-04;修回日期:2023-04-07

基金项目:安徽省科技攻关计划资助项目(JZ2016AKKG0837)

作者简介:林健树(1997—),男,福建福州人,合肥工业大学硕士生;

王小巧(1989—),男,安徽蚌埠人,博士,合肥工业大学讲师,硕士生导师,通信作者, E-mail: wxq20061087@163.com.

## 0 引言

生产物流是指产品生产制造过程中,原材料、在制品、半成品和产成品等在企业内部的实体流动<sup>[1]</sup>。在面向订单式生产的发动机装配车间中,由于处于生产物流的末端,与供应物流相衔接,车间内多品种小批量的生产运作模式所带来的工艺切换将导致装配车间物流较为复杂,物流效率直接影响发动机完工配送的时长。

本文将研究乘用车发动机的生产配送问题,以发动机产品经过装配车间瓶颈工位后送往园区内客户收货点为例,在瓶颈工位加工完成后,通过物流部门的配送车辆将发动机运往规定地点,每辆车都有固定的载重限制,且配送地分散在工业园区的不同位置。显然配送计划将受到生产排产和配送次序的影响,因此需要一种综合调度方法来实现生产排产和物流配送的整体优化。

乘用车发动机制造企业大多在生产部门与物流部门单独优化各自的流程,生产部门确定发动机订单排产方案,主要目标为最小化订单完工时间;物流部门确定物流配送方案,主要目标为最小化客户期望时间、车辆行驶距离和提前延迟成本。传统的优化为两阶段优化,因为物流配送方案需基于生产部门的订单排产方案进行寻优,所以割裂的独立优化方法很难达到理想的整体优化效果,如何进行装配车间的生产物流协同优化成为了难题。

目前,国内外学者对生产物流协同优化的研究主要分为物流优化、协同性优化、配送路径优化、算法求解等4个方面进行研究。

在物流优化方面,文献[2]对不同的车辆调度问题(vehicle scheduling problem, VSP)进行总结提炼,针对不同约束提出复杂情形下的改进算法。文献[3]针对药品配送的独特特点,考虑使用混合粒子群智能启发式算法进行对车辆分配和路线优化问题进行求解,但均未考虑到生产与物流的协同优化。

在协同性优化方面,文献[4]为解决生产-物流资源的协同问题,提出一个完全反应式调度信息-物理系统框架,但实验表明部分指标抗扰动能力较弱;文献[5]将CTA(completion time arrangement)算法与禁忌搜索算法相结合,着眼于解决单机模式下生产、库存和配送的协同优化调度,但未考虑到多台机器以及配送路径的优化问题;文献[6]提出在多载量自动引导车(automated

guided vehicle, AGV)物流运输模式下采用一种订单动态插入的生产与物流协同调度策略,但未考虑到交货时间窗的限制;文献[7]基于约束理论构建物联网环境下的三层两级生产物流联动机制,为后续研究提供良好的启发。

在配送路径优化方面,文献[8]利用改进的遗传算法研究二维环境下机器人运动规划问题,但未考虑配送车辆的任务组合和分车问题。

在算法求解方面,文献[9]针对众包配送模式下的生产配送协同问题,设计一种非支配排序遗传算法(non-dominated sorted genetic algorithm, NSGA)多目标遗传算法用于模型求解,但算例规模略大时,该算法效率就开始下降;文献[10]提出一种基于遗传算法和反向邻域搜索的混合智能优化算法,但文中未考虑到车辆数量、载量等条件限制。

由上述研究可知,国内外学者对生产物流协同调度和实际应用的研究为本文提供了坚实的基础,但存在以下4个方面的不足之处:①考虑乘用车装配车间的生产物流协同较为少见;②部分场景下未能充分考虑生产物流的协同优化;③问题规模变化算法存在鲁棒性不强、求解效率不高不足,容易陷入局部最优;④部分场景下假设较为简单,未考虑车辆路径或未考虑订单分车和任务配发等问题。

基于上述问题,本文提出一种改进的遗传退火算法用于发动机装配车间物流协同优化,以期得到最优生产排产和物流配送方案,实现客户期望时间、提前延迟成本和物流配送成本的多目标最小化,以此使得企业利润最大化。最后利用不同规模的数据集进行实例验证,证明该算法的有效性。

## 1 问题模型

本文主要研究由发动机装配车间和园区多个客户装货区构成的生产物流协同优化调度问题。装配车间接受 $m$ 个客户的 $m$ 个订单,装配订单作业记为 $J_i(i=1, 2, \dots, m)$ ,其所需的加工时间为 $P_i(P_i>0)$ ,质量为 $w_i$ 。在生产过程中,订单装配作业不会出现中断。对于任意订单装配作业 $J_i$ ,假定其装配开始时间为 $S_i$ ,装配完成时间为 $C_i$ 。制造商装配车间采用分批方式由同质车辆依次为园区不同位置的客户装货区进行订单配送,车辆的载重限制 $Q$ ,一个配送批次只由1台车辆配送,且任意车辆配送作业的承重和 $w_i$ 小于等于载重

限制  $Q$ 。 $m$  个订单作业的配送批次数为  $Z$ 。车辆任意配送批次  $z$  ( $z=1, 2, \dots, Z$ ) 的配送开始时间由该配送批次中的最后一个装配的客户订单的完工时间决定, 车辆按照一定的配送顺序配送订单, 考虑订单配送到达客户的服务时间窗  $[L_i^l, L_i^r]$  约束, 客户  $i$  与  $j$  之间的行驶时间为  $t_{ij}$ , 且  $t_{ij} = t_{ji}$ , 所有的客户订单配送完后直接返回制造商装配车间。

对于任意装配订单作业  $J_i$ , 通过任意配送方案进行配送, 可获得装配订单作业对应客户装货区收货时间, 即客户期望时间为  $E_i$ , 客户期望时间影响其对订单的满意程度, 由此产生的客户期望时间成本  $F_E$  的计算公式为:

$$F_E = \mu \sum_{i=1}^m E_i \quad (1)$$

其中,  $\mu$  为反映客户满意度的制造商信誉惩罚因子。提前延迟成本的计算公式为:

$$F_L = \alpha \sum_{i=1}^m \max\{L_i^l - E_i, 0\} + \beta \sum_{i=1}^m \max\{E_i - L_i^r, 0\} \quad (2)$$

其中:  $\alpha$  为提前到达惩罚因子;  $\beta$  为延迟到达惩罚因子。

物流配送成本  $F_T$  由初始启动成本  $F_1$ 、配送距离成本  $F_D$  和违反载重约束的惩罚成本  $F_P$  构成, 计算公式为:

$$F_T = F_1 + F_D + F_P \quad (3)$$

$$F_1 = FZ \quad (4)$$

$$F_D = \lambda \sum_{z=1}^Z (T_z^c - T_z^s) \quad (5)$$

$$F_P = k \sum_{z=1}^Z \max\{\omega_z - Q, 0\} \quad (6)$$

其中:  $F$  为每辆车的固定发车成本; 对于任意配送批次  $z$ , 其配送开始时间记为  $T_z^s$ , 该配送完成时间记为  $T_z^c$ ; 配送距离成本  $F_D$  由配送的路径选择和客户装货区与客户装货区、制造商装配车间之间的距离决定;  $\lambda$  为车辆运行成本和行驶时间的转换系数;  $k$  为违反载重约束的惩罚因子。该生产配送调度的目标  $f$  是追求客户期望成本、提前延迟成本和配送成本之和最小化, 即

$$f = \min(F_E + F_L + F_T) \quad (7)$$

以上为本文研究的发动机装配车间有订单交付时间限制和物流配送车辆载重限制的两阶段协同优化的生产物流调度模型, 模型中引入了与客户期望时间的惩罚因子和与客户各收货时间延期/提前的惩罚因子来处理复杂的约束, 以期通过

合理的算法寻优来获得最佳的装配订单排产方案和发动机物流配送方案。

物流车辆一次性装载不同的客户订单, 并确定订单的配送顺序, 通过合理的生产排产方案、订单按序分车以及车辆路径优化, 实现装配车间生产物流的协同优化。

## 2 问题分析

按照本文问题模型, 给出装配订单调度优先级判定: 存在优化方案, 使得同一配送批次的各客户订单在加工次序上彼此相邻。

为描述方便, 用  $M_z^c$  表示装配订单生产排产在配送批次  $z$  中但属于配送批次  $z'$  的虚拟订单, 用  $M_z^s$  表示生产排产配送均在批次  $z$  中的虚拟订单,  $M_z^c \in M_z^s$ , 如图 1 所示。用  $T_P$  表示  $M_z^c$  的总加工时间, 则虚拟订单  $M_z^c$  的配送调整方案有以下 2 种。

这里假定各配送批次的订单配送次序已经最优而不发生改变, 目标函数中物流配送成本  $F_T$  部分不发生变化, 只需考虑订单加工次序变化对目标函数中客户期望时间成本  $F_E$  的影响。




图 1 装配订单排产配送示意图

1) 将  $M_z^c$  所处的配送批次调整至批次  $z$  前, 使  $z' < z$ 。与原方案比较, 虚拟订单  $M_z^c$  的装配完成时间  $T_C$  和开始配送时间  $T_0$  减少, 故客户期望时间  $T_E$  减少, 优化幅度取决于原位置前序的批次  $z$  订单数量; 与虚拟订单  $M_z^c$  类似, 对于配送批次  $z$  也存在相同的优化, 减少的时间则与加工时间  $T_P$ 、配送批次  $z$  的订单数量有关。

2) 将  $M_z^c$  所处的配送批次调整至批次  $k$  后, 使  $z' > z$ 。与原方案比较, 虚拟订单  $M_z^c$  的加工完成时间  $T_C$  和开始配送时间  $T_0$  延迟, 故客户期望时间  $T_E$  延迟, 延迟的时间取决于原位置后续的批次  $k$  订单数量。配送批次  $z$  得到优化, 优化程度与  $T_P$ 、配送批次  $z$  的订单数量有关。虽然存在一定程度的效益悖反, 但是仍可以使用算法中最大保留交叉算子来调整两虚拟订单的先后顺序达到优化目的。

按照本文问题模型, 虚拟订单加工顺序变化不影响目标函数物流费用部分, 可以进行批次内

次序调整降低客户期望时间成本。

虚拟订单的开始配送时间  $T_0$  取决于订单内完工时间  $T_c$ 。因为本文考虑的是装配车间内单一混流产线的瓶颈工位,所以虚拟订单内各订单的次序调整不影响装配完工时间和批次开始配送时间;各订单的园区装货区位置不同,装货区与装货区、制造商装配车间的距离不同,因此订单次序调整将对客户期望时间成本产生影响。可以考虑使用 2-交换变异来调整虚拟订单内排产先后顺序进行优化。

### 3 算法设计

#### 3.1 装配车间生产物流协同优化算法

改进的遗传模拟退火算法(modified genetic algorithm and simulated annealing, MGASA)是一种新的混合优化算法。为方便描述,该算法流程如图 2 所示。

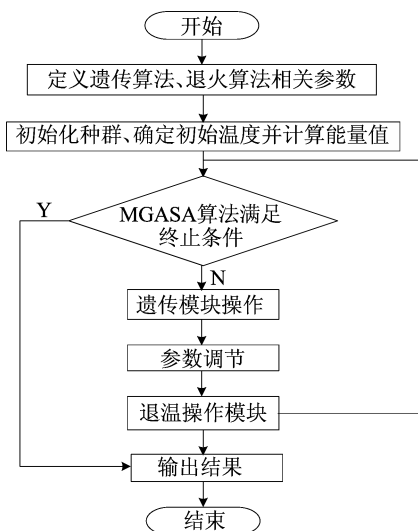


图 2 MGASA 算法流程

具体步骤为:

1) 定义模拟退火算法参数(退火系数  $\tau = 0.1$ 、初始温度  $T = 800\text{ }^\circ\text{C}$ 、降温策略为指数降温策略、淬火次数为 20)、遗传算法参数(交叉概率为 0.8、变异概率为自适应变异概率、最大种群数量为 50、迭代次数为 1 000)、能量函数、适应度函数及染色体编码方式,生成随机染色体。

2) 初始化种群、确定初始温度并按照式(7)计算目标函数能量值。

3) 判断是否达到算法终止条件,若是则转至步骤 7),否则转至步骤 4)。

4) 淬火操作,即多次对当前种群进行遗传模块操作,具体为随机选择种群内个体,与当前最优

个体进行交叉、变异,计算染色体适应度函数和接受概率判断是否替换原个体并更新种群。

5) 进行参数调节工作,例如接受概率调节、变异概率调节等。

6) 进行退温模块操作,在同一温度下进行充足的淬火操作后,根据降温策略和退火系数降低温度,模拟退火操作降低金属内部活跃度,随后继续转至步骤 2)。

7) 输出结果。

本文研究了一种 MGASA 算法,主要提出 2 种改进措施:① 使用最大保留交叉作为交叉算子,使用 2-交换变异、3-交换变异和单阈值自适应变异作为变异算子;② 将遗传算法的并行操作和 Go 编程语言结合,提高算法的求解效率。

#### 3.2 问题编码规则

采用  $2 \times m$  的矩阵对该算法染色体进行编码,其中矩阵的第 1 行为  $1 \sim m$  的数字排序表示订单  $\{1, 2, \dots, m\}$  对应任务的排产顺序;矩阵的第 2 行为 0-1 编码,用 1 标记每个物流车辆配送批次的最后一个完工任务。

根据上述编码方式,生产物流配送调度优化方案对应的染色体编码见表 1 所列。

表 1 染色体编码

排产顺序	4	2	3	5	7	1	6
配送批次	0	0	1	0	0	0	1

根据染色体可知排产顺序依次为 4—2—3—5—7—1—6,分两批进行顺序配送:4—2—3 为批次 I,5—7—1—6 为批次 II。需要注意的是,按照上述编码方式随机生成的染色体可能违反车辆的载重约束,因此需要对违反约束的染色体进行修复操作。

#### 3.3 初始化种群和适应度函数计算

改进的遗传退火算法种群数量为  $M$ 。初始种群的每一条染色体产生过程如下:首先随机生成一组从  $1 \sim m$  的随机排列代表生产排产顺序和一组由 0、1 字符组成的长度为  $m$  的序列代表物流配送批次,随后进行染色体修复操作并计算染色体能量值。

#### 3.4 选择算子

在个体染色体选择时,采用二元锦标赛选择策略。在改进的遗传退火算法每一次迭代过程中,采用不断从当前种群中选择个体作为父代染色体进行繁殖,生成新的子代染色体。

### 3.5 交叉算子

本文设计改进的遗传模拟退火算法采用最大保留交叉算子<sup>[11]</sup>,保证群体多样性的同时对优秀的子序列进行保护。

### 3.6 变异算子

本文设计的改进的遗传模拟退火算法采用 2-交换变异、3-交换变异算子及单阈值自适应变异<sup>[12]</sup>。具体做法如下:

1) 2-交换变异。交换子代染色体中 2 个随机数所在列进而生成新的染色体。

2) 3-交换变异。交换子代染色体中 3 个随机数所在的列进而产生 6 个新染色体,从 6 个染色体中选择适应度最高的一个作为变异后的新染色体。

3) 单阈值自适应变异。一方面保证当进化出优良个体时赋予较小的变异率,通过交叉重组进行优良模式的累积;另一方面对于较差个体能够通过较大的变异概率增强种群的探索能力。在对变异概率进行调整时,利用连续几代的最优染色体的适应度函数值作为收敛度阈值的计算依据。自适应调整的变异率  $p_m$  计算公式为:

$$p_m = p_{m0} + \psi/100 \quad (8)$$

其中: $p_{m0}$ 为变异概率初值; $\psi$ 为收敛度阈值,若最优适应度值  $f_1 = f_2 = \dots = f_n$ ,则收敛度阈值  $\psi = n - 1$ ,否则  $\psi = 0$ 。

需要注意的是,变异操作交换的是元素所在的列,也需要进行修复操作。

### 3.7 修复操作

当染色体不满足车辆承载限制时,需要对违反约束的染色体进行修复操作:计算每一个配送批次的物流车辆累计载重,如果该配送批次的累计装载质量在染色体第  $i$  列超出物流车辆载重限制,那么将染色体第 2 行第  $i - 1$  基因由 0 调整为 1。此外,染色体第 2 行最后一列必须为 1,以表示所有物流配送任务的结束。

### 3.8 并行操作

利用遗传操作的可并行性和 Go 语言的协程

调度、并行编程特性,将交叉、变异、修复的操作并行化,降低原有串行进化的时间消耗。

Go 语言拥有较 Java 语言更细粒度的协程调度,可同时调度大规模的协程进行并行作业,此外轻量级的协程结构能够使协程拥有更快的上下文切换速度,且协程合作式的调度方式能够在协程完成当前作业后尽快将剩余中央处理器(central processing unit, CPU)时间片分配出去,有效提高了 Go 语言的并行编程性能,使 Go 语言成为并行编程中的主流编程语言。

## 4 实验及数据分析

### 4.1 算例设计

本文的改进算法采用 Go 编程语言 1.17.2 版本进行编程,程序运行环境为 Intel Core i7 CPU,主频 2.30 GHz,内存为 32 GiB,操作系统为微软 Windows 11 系统。由于发动机装配车间生产物流协同优化问题缺少标准算例集,实验中各参数选取如下:

订单数量  $m \in \{20, 40, 80, 120, 150\}$ ;

客户收货时间与客户期望成本转换系数  $\mu = 0.1$ ,物流配送时间与配送成本转换系数  $\lambda = 0.8$ ;

装配任务加工时间取  $P_i \in U[5, 10]$ ,装配任务的质量取  $w_i \in U[10, 60]$ ,客户间的距离取  $t_{ij} \in U[10, 60]$ ;

车辆限重取  $Q \in \{200, 500\}$ ,车辆固定启动成本  $F = 50$ ;

客户收货时间窗概念采用按一定比例生成。

本文通过一个简单的算例来验证算法的正确性和有效性,并分析求解效果。此处假设客户订单数  $m = 15$ ,车辆限重  $Q = 200$ ,其余参数按照上述参数设计方案由电脑随机生成,见表 2、表 3 所列。

本文使用改进的遗传退火算法生成的具体生产配送调度方案见表 4 所列。

表 2 客户订单加工时间、任务质量及收货时间算例表

客户编号 $i$	1	2	3	4	5	6	7	8
$P_i$	7	8	7	9	5	8	8	7
$w_i$	27	26	26	21	12	29	58	56
$[L_i, L_i]$	[121, 201]	[179, 259]	[124, 204]	[85, 165]	[72, 152]	[102, 182]	[133, 213]	[96, 176]
客户编号 $i$	9	10	11	12	13	14	15	
$P_i$	7	5	6	7	9	7	5	
$w_i$	15	22	42	15	55	40	35	
$[L_i, L_i]$	[13, 93]	[45, 125]	[23, 103]	[121, 201]	[112, 192]	[185, 265]	[96, 176]	

表 3 客户间距离所需运输时间

客户编号 $i$	客户编号 $j$															
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	0	43	69	46	79	81	37	83	61	16	89	53	56	48	49	40
1	43	0	58	45	26	66	97	22	38	11	32	98	46	29	77	13
2	69	58	0	25	95	64	57	76	57	29	73	57	70	59	36	46
3	46	45	25	0	88	71	47	91	44	76	98	73	76	12	57	22
4	79	26	95	88	0	83	89	90	24	85	52	49	50	81	83	19
5	81	66	64	71	83	0	58	65	24	57	27	95	83	21	42	35
6	37	97	57	47	89	58	0	67	26	85	27	90	34	10	70	62
7	83	22	76	91	90	65	67	0	66	53	82	83	67	50	49	29
8	61	38	57	44	24	24	26	66	0	37	27	46	25	47	44	36
9	16	11	29	76	85	57	85	53	37	0	48	10	85	13	92	19
10	89	32	73	98	52	27	27	82	27	48	0	22	50	37	87	27
11	53	98	57	73	49	95	90	83	46	10	22	0	28	89	62	84
12	56	46	70	76	50	83	34	67	25	85	50	28	0	40	79	17
13	48	29	59	12	81	21	10	50	47	13	37	89	40	0	54	54
14	49	77	36	57	83	42	70	49	44	92	87	62	79	54	0	59
15	40	13	46	22	19	35	62	29	36	19	27	84	17	54	59	0

表 4 最优生产配送调度方案

配送车辆		生产配送调度方案					
第 1 辆车	Route	0—9—11—10—5—8—12—0					
	$C$	$C[9]=7$	$C[11]=13$	$C[10]=18$	$C[5]=23$	$C[8]=30$	$C[12]=37$
	$E$	$E[9]=53$	$E[11]=63$	$E[10]=85$	$E[5]=112$	$E[8]=136$	$E[12]=161$
	$T_z^s, T_z^e$	$T_z^s=37$	$T_z^e=217$				
第 2 辆车	Route	0—15—4—1—7—0					
	$C$	$C[15]=42$	$C[4]=51$	$C[1]=58$	$C[7]=66$		
	$E$	$E[15]=106$	$E[4]=125$	$E[1]=151$	$E[7]=173$		
	$T_z^s, T_z^e$	$T_z^s=66$	$T_z^e=256$				
第 3 辆车	Route	0—6—13—3—2—14—0					
	$C$	$C[6]=74$	$C[13]=83$	$C[3]=90$	$C[2]=98$	$C[14]=105$	
	$E$	$E[6]=142$	$E[13]=152$	$E[3]=164$	$E[2]=189$	$E[14]=225$	
	$T_z^s, T_z^e$	$T_z^s=105$	$T_z^e=274$				
目标函数	$T_{cost}$	581.2					
	$E_{cost}$	203.7					
	$Z$	3.0					
	$L_{cost}$	0					
	$C_{total}$	784.9					

表 4 中:生产次序按照车辆编号的先后排序, Route 表示该车辆的配送订单次序和路径, 序列中编号为装配订单编号;  $C$  表示每个订单的装配生产完工时间;  $E$  表示客户订单的收货时间;  $T_z^s$  和  $T_z^e$  分别表示此配送批次的配送开始时间和配送完成时间;  $T_{cost}$  表示配送成本;  $E_{cost}$  表示客户期望时间成本;  $Z$  表示需要的车辆数;  $L_{cost}$  表示提前延迟成本;  $C_{total}$  表示总成本。

MGASA 算法与 2 种常用算法的收敛曲线对比如图 3 所示。

图 3 中, MGASA 算法初始种群适应度良好, 且兼顾局部搜索能力和全局搜索能力, 在算法参数相同情况下寻优效果更佳。

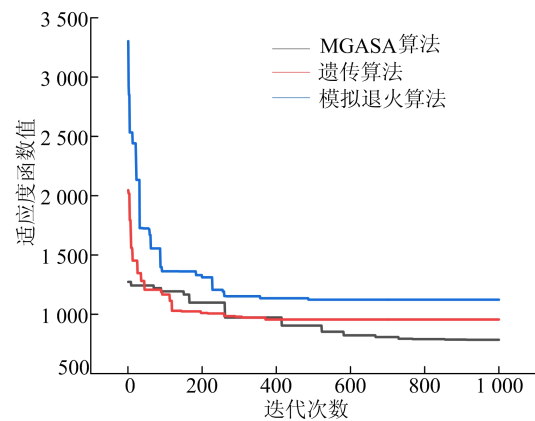


图 3 不同算法收敛曲线对比

为比较算法在并行/非并行模式下的求解效

率,对于不同订单规模,考虑问题总求解次数的 10 种不同情况,可以预见并行编程下算法的求解效率将显著提高,但针对问题规模较小或求解次数较少时,非并行编程的求解时间略低于并行编程,可能是由于 CPU 进行协程上下文切换的时间消耗高于并行编程的时间节省所带来的负面影响;但在问题规模上升或总求解次数增加时,并行编程的优势将大大凸显。

在订单数量  $m$  分别为 15、20、40、80 时将总求解次数逐步提高至 10 次,得到求解时间分组柱状图如图 4 所示。




图 4 不同规模下求解时间分组柱状图

#### 4.2 实验对比与数据分析

为客观反映算法性能,对于每种  $F$  情形,考虑订单数量  $m$  的 4 种不同情况,且每种都按照上述参数设置方法随机生成算例并统计了各算法的性能,每种算例进行 50 次随机实验, $F=50$  时 4 种订单个数下的箱型提琴图如图 5 所示。子图中分别对  $T_{cost}$ 、 $E_{cost}$ 、 $L_{cost}$  和  $C_{total}$  这 4 类特征指标进行统计。车辆固定启动成本较小和较大情形下的实验统计数据见表 5 所列,分析表 5 中的数据可知:

1) 对于每种问题情形,算法的解均能得到较为满意的解方案,不同订单规模下的 50 次随机实验最优解分布较为均匀。由此可知,MGASA 算法统筹考虑装配车间内生产配送的特点,并进行一定程度的协同优化。

2) 对于车辆初始启动成本不同的情形进行比较,表 5 中针对初始启动成本  $F$  较大的情况下,目标函数值的涨幅(28 763.0—21 484.4)与初始启动成本的涨幅( $44 \times 200 - 54 \times 50$ )相比变化不大,也验证了算法在迭代进化过程中能够采用尽可能少的分车批次、尽可能多的单批次多订单配送来与初始启动成本增大的结果进行对冲,验证了算法具有良好的鲁棒性。

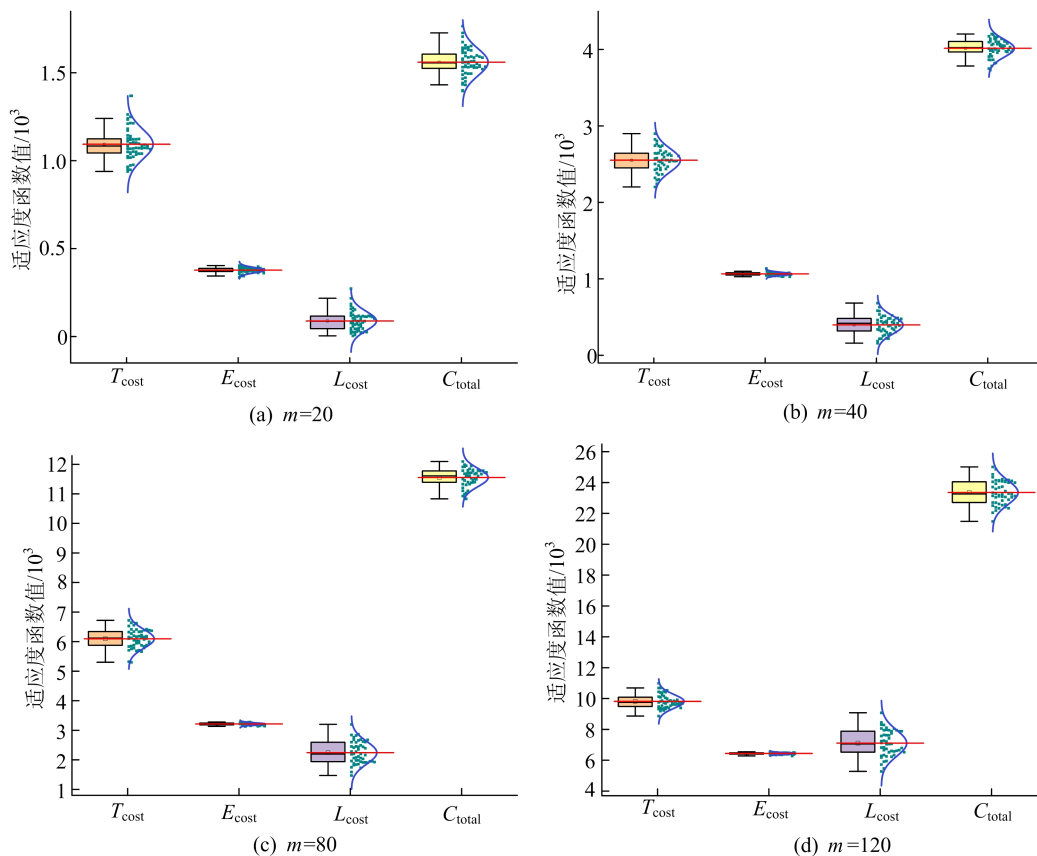


图 5 不同订单数量下箱型提琴图

3) 对于MGASA算法而言,同一温度下的淬火和接受几率的判断机制能够使得算法跳出局部极小的陷阱,同时也会消耗一些CPU时间。对于问题规模主要取决于装配订单任务个数 $m$ 的大小。但总体上MGASA算法的计算效率在绝大多数场景中是可以接受的。

表5  $F=50$  和  $F=200$  时的实验结果

$m$	$F=50$				
	$T_{\text{cost}}$	$E_{\text{cost}}$	$L_{\text{cost}}$	$C_{\text{total}}$	$Z$
20	939.2	389.3	72.0	1 400.5	4
40	2 368.0	1 029.3	335.0	3 732.3	12
80	5 692.4	3 183.4	1 955.0	10 830.8	31
120	9 831.2	6 377.2	5 276.0	21 484.4	54
150	12 380.4	9 464.2	11 070.0	32 914.6	71
$m$	$F=200$				
	$T_{\text{cost}}$	$E_{\text{cost}}$	$L_{\text{cost}}$	$C_{\text{total}}$	$Z$
20	1 369.2	362.5	34.0	1 765.7	7
40	3 760.8	1 077.1	270.0	5 107.9	10
80	9 655.2	3 229.0	1 688.0	14 572.2	27
120	14 923.2	6 436.8	7 403.0	28 763.0	44
150	21 047.2	9 624.4	14 053.0	44 724.6	61

## 5 结 论

本文研究了发动机装配车间有订单交付时间限制和物流配送车辆载重限制的协同优化的生产物流调度问题,协同优化的目标是考虑客户期望成本、提前延迟成本和物流配送成本之和的最小化,为此构造了改进的遗传退火算法用于问题模型求解。由于生产配送调度方案的优化效果受装配订单排程结果的影响,本文展开了对装配订单调度优先级判定的研究,这对后续的问题编码规则的确定、交叉算子的选用均有启发意义。在算法设计中使用模拟退火思想并采用自适应变异算子动态调整变异概率增大了算法局部寻优的能力,最后与Go语言并行编程结合实现了改进的遗传退火算法。通过在不同装配订单规模下进行了算例验证和数据分析表明,本文构造的算法能够在大多数现实场景中解决装配车间订单生产配送协同优化的调度问题。

另外,在订单规模增大后,并行编程将发生协

程争用的问题,这将降低算法的计算效率,后续还应应对代码进行性能分析,降低锁的争用和冲突概率;此外,在订单数量为40时,零星算法收敛曲线反映调度方案在寻优过程中表现不佳,后续应该针对此种情况寻找更加合适邻域寻优规则并尝试实现全订单规模适用。最后,本文提出的装配车间生产物流协同优化的调度方案均为静态调度方案,针对动态扰动下的生产物流协同调度将是下一步的研究方向。

## [参 考 文 献]

- [1] 宾厚,王欢芳,邹筱. 现代物流管理[M]. 北京:北京理工大学出版社,2019:213-214.
- [2] 钟石泉. 物流配送车辆调度智能优化方法研究[D]. 天津:天津大学,2004.
- [3] WU X, LI R, CHU C, et al. Managing pharmaceuticals delivery service using a hybrid particle swarm intelligence approach[J]. Annals of Operations Research, 2021, 308: 653-684.
- [4] 蔡磊,李文锋,罗云. 个性化定制车间生产-物流协同调度框架与算法研究[J]. 机械工程学报, 2022, 58(7): 214-226.
- [5] 李凯,周超,马英. 考虑释放时间的单机JIT调度问题[J]. 运筹与管理, 2016, 25(3): 71-77.
- [6] 葛艳红,李书珍,李文锋. 个性化定制车间生产与物流协同调度研究[J]. 南京理工大学学报(自然科学版), 2021, 45(6): 692-699.
- [7] 吴强,屈挺,颜志军,等. 工业园区中ATO订单拉动的“生产-物流”联动优化方法[J]. 工业工程, 2017, 20(4): 37-48.
- [8] KARAMI A H, HASANZADEH M. An adaptive genetic algorithm for robot motion planning in 2D complex environments[J]. Computers and Electrical Engineering, 2015, 43: 317-329.
- [9] 冯鑫,陈旋珊. 基于众包物流配送模式的生产配送协同调度多目标优化[J]. 系统工程, 2022, 40(5): 94-103.
- [10] 马文琼,王恺. 两阶段装配流水线车间加工与配送协同调度研究[J]. 工业工程与管理, 2016, 21(6): 103-110, 117.
- [11] 谢秉磊,李军,郭敦煌. 有时间窗的非满载车辆调度问题的遗传算法[J]. 系统工程学报, 2000, 15(3): 290-294.
- [12] 梁霞. 一种改进的自适应遗传算法及其在作业车间调度中的应用[D]. 大连:大连交通大学, 2006.

(责任编辑 吴 亮)