

DOI: 10.3901/JME.2023.04.308

# 改进自适应遗传算法求解“货到人”拣选系统订单分批问题\*

李昆鹏<sup>1</sup> 刘腾博<sup>1</sup> 李文莉<sup>2</sup>

(1. 华中科技大学管理学院 武汉 430074;  
2. 武汉纺织大学管理学院 武汉 430200)

**摘要:** “货到人”拣选系统采用自动导引运输车(Automated guided vehicle, AGV)实现自动拣选作业, 由AGV搬运货架到拣选站台, 再由拣选人员从货架上拣取商品。订单分批作为拣选作业的准备工作, 是影响AGV搬运次数和人工拣货次数的关键因素, 优化订单分批策略对提高“货到人”拣选系统效率至关重要。在电商智能仓库背景下, 综合考虑订单需求多种商品、商品多货架分布存储、订单与货架供需匹配关系未知等实际因素, 以人工拣选成本和AGV搬运成本之和最小为目标构建数学模型, 并设计改进自适应遗传算法求解。该算法采用启发式策略生成初始种群, 引入具有自适应变换概率的交叉和变异算子, 并加入局部搜索过程以增强寻优能力。最后通过试验测试验证模型和算法的有效性, 证明种群初始化方法的优势, 并采用灵敏度分析给出合理的周转箱数量配置建议。研究可为电商企业通过订单分批优化提高拣选效率、降低拣选成本提供实践指导, 为“货到人”拣选系统的实际应用提供科学依据。

**关键词:** “货到人”拣选; 订单分批; AGV自动导引车; 改进自适应遗传算法

**中图分类号:** TP11; F253

## Improved Adaptive Genetic Algorithm for Order Batching of “Part-to-picker” Picking System

LI Kunpeng<sup>1</sup> LIU Tengbo<sup>1</sup> LI Wenli<sup>2</sup>

(1. School of Management, Huazhong University of Science & Technology, Wuhan 430074;  
2. School of Management, Wuhan Textile University, Wuhan 430200)

**Abstract:** “Part-to-picker” picking system adopts automated guided vehicle(AGV) to realize automatic picking operation. Shelves are transported by the AGV to the picking station, where they are used by the pickers to pick the goods. As the preparation for picking operations, order batching is a key factor affecting the number of AGV transporting and manual picking times. Optimizing the order division strategy is critical to improve the efficiency of the “part-to-picker” picking system. In the context of e-commerce intelligent warehouse, practical factors such as order demand for multiple goods, multi-shelf distributed storage of goods, unknown matching relationship between supply and demand of orders and shelves, etc., need to be comprehensively considered. Based on this, the objective of mathematical model construction is to minimize the sum of manual picking cost and AGV transporting cost. To solve the problem, an improved adaptive genetic algorithm is designed. The algorithm uses a heuristic strategy to generate the initial population, introduces crossover and mutation operators with adaptive transformation probability, and adds a local search process to enhance the ability of optimization. Finally, the validity of the model and algorithm is verified by experimental tests, and the superiority of the population initialization method is proved. According to the result, the sensitiveness analysis is used to give the reasonable allocation suggestion of turnover box quantity. This study can not only provide practical guidance for e-commerce enterprises to improve picking efficiency and reduce picking cost through order batch optimization, but also provide scientific basis for the practical

\* 国家自然科学基金(71831007)和湖北省教育厅(20Q065, 20Y084)资助项目。  
20220225 收到初稿, 20220701 收到修改稿

application of “part-to-picker” picking system.

**Key words:** “part-to-picker” picking; order batching; AGV automatic guided vehicle; improved adaptive genetic algorithm

## 0 前言

近年来,随着移动终端的普及和生活水平的提高,网络购物已成为当今社会的主流消费模式,电商订单结构也逐渐向“多品种、小批量”转变,如何以最快速度满足多样化的客户需求,成为电商企业发展核心竞争力的关键。据统计,在采用传统人工拣货模式的电商仓库中,订单拣选成本占比超过60%,耗费时间占比高达40%,是最耗时、耗力的环节之一<sup>[1]</sup>。在自动化技术日益成熟的背景下,各大电商企业纷纷引入自动导引运输车(Automated guided vehicle, AGV)打造智能仓库,实现“由人取货物”到“货物送到人”的转变。实践证明,采用AGV的“货到人”拣选系统可将拣选效率提高3~4倍,拣选准确率达99.99%以上<sup>[2]</sup>,已成为我国物流仓储转型升级的新方向。在该系统中,订单分批作为准备工作具有至关重要的作用,有效的分批方式可最大程度地降低拣选成本。如何设计符合AGV拣选特点的订单分批策略,在保证拣选效率的同时降低作业平台的人工操作成本和AGV搬运货架的运输成本,是电商企业实现降本增效十分有必要关注的问题,也是本文研究的重点。

“货到人”拣选系统主要流程如图1所示,首先,对于一定时间内的电商订单,根据一定规则将它们划分为不同批次,并将批次分配至不同拣选站台,每个批次作为一个拣货单元;然后,指派AGV将目标货架搬运至相应拣选站台,由人工从货架上拣取批次所需商品,并将它们放置于订单所对应周转箱中,拣货完成后AGV再将货架运回原位。在整个过程中,人工拣取商品次数和AGV搬运货架次数是影响拣选成本和拣选时间的关键因素。由于批次商品类型数决定人工拣货次数,批次所需货架数影响AGV搬运次数,因此本文综合考虑两种因素探索有效的订单分批方式,从整体上降低拣选成本、提高拣选效率。目前国内外学者关于“货到人”拣选系统的研究主要集中于AGV行驶路线优化及多AGV避撞策略设计,而对该系统的订单分批问题关注较少。随着消费者需求不断趋于多样化,如果能将商品需求和目标货架相同的订单合并为一个批次拣选,则人工拣取商品一次可放入多个订单周转箱,AGV搬运货架一次可供应多个订单需求,由此可

见,订单分批对拣选后续作业具有显著影响,十分有必要对该环节进行深入探讨。




图1 “货到人”拣选系统工作流程

无论是传统“人到货”拣选模式还是新兴的“货到人”拣选系统,对于订单分批问题的研究均可归属为聚类问题,二者主要区别在于聚类原则和优化目标不同。目前,关于“人到货”模式下订单分批问题的研究比较成熟,在设计聚类原则时大多依据存储位置相近,包括具有相同通道数最多<sup>[3]</sup>、共同覆盖区域范围最大<sup>[4]</sup>、商品存储点距离最近<sup>[5]</sup>、合并后增加巷道数最少<sup>[6]</sup>等。在构建模型时通常将拣选人员的行走距离或行走时间作为优化目标<sup>[3-9]</sup>。由于在“货到人”拣选系统中,采用AGV搬运货架代替人工行走拣货,拣选流程具有本质区别,相关研究成果不能直接应用。近年来,部分学者对“货到人”拣选系统的订单分批问题展开了初步探索。XIANG等<sup>[10-11]</sup>以最小化货架访问次数为目标建立模型,分别采用改进的变邻域搜索算法、改进的模拟退火算法求解;吴颖颖等<sup>[12-13]</sup>以单拣选站台耦合因子之和最大和料箱出入库数量最小为目标建立模型;李晓杰<sup>[14]</sup>以减少AGV往返运送货架次数为目标设计拣选策略;范继东<sup>[15]</sup>以最小化货箱总出入库次数为目标设计k-means订单分批算法。以上文献均仅考虑AGV搬运成本。李珍萍等<sup>[16-17]</sup>同时考虑人工拣货成本和AGV搬运成本,以总成本最小为目标构建模型,虽然考虑了两种成本,但假设每种商品只能在一个货架上存储,不能充分反映电商仓库的商品存储特点。

通过分析已有研究发现,订单分批问题大多依据相似度聚类,在传统人工拣货模式中考虑商品存储位置相近,进而减少人工行走距离或时间;在“货到人”拣选系统中,大部分研究仅考虑订单所需商品或调用货架相同,从单个角度衡量订单相似度,从而减少人工拣取商品次数或AGV搬运货架次数,极少有学者同时考虑两种因素。少数文献对问题进

行了简化,假设商品只能在单个货架存储,由此可知订单与货架的匹配关系,分批时只需比较订单所需货架是否相同,无法适用于实际拣选场景。综上,本文考虑每个订单需求多种商品、每种商品多货架存储、订单与货架匹配关系未知等实际情况,将订单划分为不同批次,为批次需求选择供应货架并决策供需数量。考虑以上因素会使问题复杂度大幅增加,但更符合电商仓库布局和企业实际需求。为解决此问题,本文首先以最小化人工拣货成本和 AGV 搬运成本为目标构建订单分批模型;然后提出改进自适应遗传算法求解,在算法中设计启发式策略生成初始种群,引入具有自适应变换概率的交叉、变异算子,并加入局部搜索过程;最后通过试验测试验证了模型和算法的有效性,证明了种群初始化方法的优势,并采用灵敏度分析给出了合理的周转箱数量配置建议。本文考虑拣选总成本最小,在理论上进一步丰富了“货到人”拣选系统的相关研究,在实践上能够从整体提高智能仓库运行效率。

## 1 数学模型

### 1.1 问题描述及假设

“货到人”拣选系统的订单分批问题描述如下:在采用 AGV 搬运货架到拣选站台的智能仓库中,共有  $h$  种商品存放在  $p$  个货架上,其中  $P=\{1,2,\dots,h\}$  表示商品集合,  $S=\{1,2,\dots,p\}$  表示货架集合。每个货架有多个储位,每种商品存放在不同货架上,即商品多货架存储。在拣选区共有  $t$  个拣选站台,每个拣选站台完成一个批次拣选任务,即分批后批次数为  $t$ ,  $W=\{1,2,\dots,t\}$  表示批次集合。每个拣选站台配备  $d$  个周转箱,每个周转箱对应一个订单,即批次最大订单数为  $d$ 。某时段内共有  $N$  个订单需要拣选,  $O=\{1,2,\dots,N\}$  表示订单集合,已知订单需求商品类型及数量,如何对订单分批使拣选总成本最小。订单分批对总成本的影响主要有两个方面,一是批次需求的商品类型数决定人工拣货成本,二是批次调用的货架数决定 AGV 搬运成本。基于此,本文以最小化拣选总成本为目标建立数学模型,决策多订单的批次分配及订单与货架的服务关系,最终得到合理的订单分批及货架调度方案。

为方便建模,考虑以下假设:① AGV 电量充足,且数量足够多;② 商品库存量充足,能够满足订单集合需求;③ 同一订单不能被分配至多个批次,以保证订单的完整性;④ 拣选人员拣取每种商品的成本相同;⑤ 在给定的时间段内每个货架只能

被 AGV 搬运一次,且每个货架的搬运成本相同。

### 1.2 模型建立

根据问题描述,设定符号及变量定义如表 1 所示,数学模型构建如下。

表 1 符号及变量定义

符号	定义
$q_{im}$	订单 $i$ 需求商品 $m$ 的数量
$Q_{pm}$	货架 $p$ 存储商品 $m$ 的数量
$c_{im}$	当订单 $i$ 需求商品 $m$ , 取值为 1, 否则为 0
$k_1$	人工从货架上拣取一种商品的成本
$k_2$	AGV 搬运一次货架的成本
变量	定义
$x_{ij}$	0-1 变量, 等于 1 表示订单 $i$ 分配至批次 $j$ , 否则为 0
$y_{jp}$	0-1 变量, 等于 1 表示批次 $j$ 由货架 $p$ 供应, 否则为 0
$u_{jm}$	0-1 变量, 等于 1 表示批次 $j$ 需求商品 $m$ , 否则为 0
$h_{jm}$	整数变量, 批次 $j$ 需求商品 $m$ 的数量
$z_{pjm}$	整数变量, 货架 $p$ 为批次 $j$ 供应商品 $m$ 的数量

$$\min \left( k_1 \sum_{j \in W} \sum_{m \in P} u_{jm} + k_2 \sum_{j \in W} \sum_{k \in S} y_{jk} \right) \quad (1)$$

$$\sum_{j \in W} x_{ij} = 1 \quad \forall i \in O \quad (2)$$

$$\sum_{i \in O} x_{ij} \geq 1 \quad \forall j \in W \quad (3)$$

$$\sum_{i \in O} x_{ij} \leq d \quad \forall j \in W \quad (4)$$

$$\sum_{k \in S} y_{jk} \geq x_{ij} \quad \forall i \in O, j \in W \quad (5)$$

$$\sum_{j \in W} y_{jk} \leq 1 \quad \forall k \in S \quad (6)$$

$$h_{jm} = \sum_{i \in O} q_{im} x_{ij} \quad \forall j \in W, m \in P \quad (7)$$

$$h_{jm} \leq \sum_{k \in S} Q_{km} y_{jk} \quad \forall j \in W, m \in P \quad (8)$$

$$h_{jm} = \sum_{k \in S} z_{kjm} \quad \forall j \in W, m \in P \quad (9)$$

$$z_{kjm} \leq Q_{km} y_{jk} \quad \forall k \in S, j \in W, m \in P \quad (10)$$

$$y_{jk} \leq \sum_{m \in P} z_{kjm} \quad \forall k \in S, j \in W \quad (11)$$

$$\sum_{i \in O} c_{im} x_{ij} \leq N u_{jm} \quad \forall m \in P, j \in W \quad (12)$$

$$x_{ij}, y_{jp} \in \{0, 1\} \quad \forall i \in O, j \in W, p \in S \quad (13)$$

$$u_{jm} \in \{0, 1\} \quad \forall j \in W, m \in P \quad (14)$$

$$h_{jm} \geq 0 \quad \forall j \in W \quad m \in P \quad (15)$$

$$z_{pjm} \geq 0 \quad \forall j \in W \quad p \in S \quad m \in P \quad (16)$$

目标函数(1)表示最小化订单拣选总成本, 包括人工拣货成本和 AGV 搬运成本; 式(2)保证每个订单均被分配至批次; 式(3)表示每个批次至少包含一个订单; 式(4)为批次的最大订单数限制; 式(5)保证每个批次均会被货架服务; 式(6)表示每个货架最多服务一个批次; 式(7)表示批次需求等于其所包含订单的商品需求量之和; 式(8)保证批次的商品需求都能被满足; 式(9)表示批次需求可被多个货架供应; 式(10)表示货架的供应量不能超过其存储量; 式(11)表示货架是否被搬运取决于其是否供应批次商品需求; 式(12)表示如果批次所包含订单对某种商品有需求, 则批次需求该商品, 从而得到批次的需求商品类型; 式(13)、(14)表示 0-1 变量; 式(15)、(16)表示整数变量。

## 2 改进自适应遗传算法

### 2.1 总体流程

考虑到遗传算法全局搜索能力强, 但存在前期早熟收敛、后期收敛速度慢的缺点, 本文提出一种改进自适应遗传算法(Improved adaptive genetic algorithm, IAGA), 在 GA 中引入自适应变换概率并加入局部搜索过程, 开发一种全局求泛、局部求精的混合优化算法。首先, 设计启发式策略生成初始种群, 提高第一代种群的随机性和多样性; 然后, 采用精英保留和轮盘赌相结合的方式选择个体, 并基于 Sigmoid 函数构造具有自适应变换概率的交叉和变异算子, 以此得到新种群; 最后, 从每个个体出发对子代种群展开更精细的局部搜索, 从而提高算法整体性能。IAGA 算法流程如图 2 所示, 主要步骤如下。

(1) 参数设置。设最大迭代次数为  $G_{\max}$ , 种群规模为  $N$ , 交叉概率为  $P_c$ , 变异概率为  $P_m$ , 在局部搜索过程中, 每个个体的最大搜索次数为  $L_{\max}$ 。

(2) 种群初始化。采用启发式策略产生  $N$  条染色体, 构成初始种群, 计算种群中每个个体的适应度值。令迭代次数  $gen=0$ 。

(3) 当  $gen < G_{\max}$ , 采用遗传操作(精英解保留和轮盘赌选择, 基于自适应变换概率的交叉算子、变异算子)更新种群, 并计算个体适应度值。

(4) 对于遗传操作产生的子代种群, 对每个个体展开局部搜索, 令子代搜索次数  $l=0$ 。计算个体适应度, 若得到改善, 则更新个体最优解, 否则保持

旧解不变。令  $l=l+1$ , 继续对子代种群个体进行局部扰动, 直到达到最大搜索次数  $L_{\max}$ 。令  $gen=gen+1$ , 若达到最大迭代次数  $G_{\max}$ , 则终止算法; 否则, 返回步骤(3)。

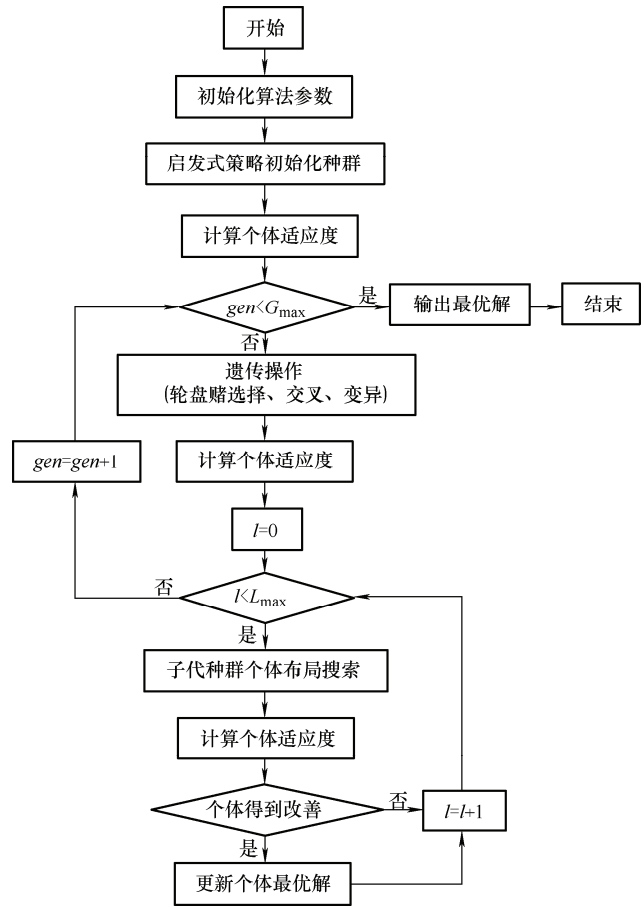


图 2 改进自适应遗传算法流程

### 2.2 详细设计

#### 2.2.1 染色体编码与适应度函数

本文采用实数编码表示染色体, 如图 3 所示。染色体中每个基因位代表一个订单, 基因位数对应订单编号, 基因总数为订单总数  $c$ , 即染色体长度为  $c$ ; 基因位上对应的基因值表示订单所属批次编号。该编码方式可以直接看出批次与订单的匹配关系, 例如, 在图 3 中, 批次总数为 5, 订单 1 属于第 5 批, 订单 2 属于第 1 批, 以此类推。




图 3 染色体编码方式

研究目标是使订单拣选总成本最小, 即最小化人工拣货成本和 AGV 搬运成本之和, 如式(17)所示。其中,  $k_1$  表示人工拣取一种商品的成本,  $k_2$  表示 AGV 搬运一次货架的成本。适应度函数为总成本的倒数,

在对个体评价时,总成本越小,适用度函数值越大,个体越优,被选中进行遗传操作的概率就越大。

$$f(x) = \frac{1}{k_1 \sum_{j \in W} \sum_{m \in P} u_{jm} + k_2 \sum_{j \in W} \sum_{k \in S} y_{jk}} \quad (17)$$

由染色体编码可知每个批次包含的订单,订单需求信息已知,计算可得批次需求商品类型及数量。对于人工拣货成本,根据批次的商品类型数及单种商品拣选成本  $k_1$ ,计算可得所有批次的人工拣货成本。对于 AGV 搬运成本,由于每种商品多货架分布、每个货架存储多种商品,因此每个批次对应多种货架组合。为了得到使 AGV 搬运次数较少的货架组合,本文设计批次选取货架规则,在此规则下为批次需求选择供应货架,然后,根据批次的调用货架数及单次货架搬运成本  $k_2$ ,计算可得所有批次的 AGV 搬运成本。

### 2.2.2 基于染色体的批次选取货架规则

由于每种商品多货架存储,需要首先对货架量化作为批次选取货架的依据。本文结合批次需求量和货架库存量的关系提出两种货架量化标准。其中,  $W_m$  表示批次需求商品  $m$  的数量,  $S_{km}$  表示货架  $k$  存储商品  $m$  的数量。两种标准:货架  $k$  存储或可满足批次需求商品的类型数,分别表示为  $C_k$  和  $P_k$ 。当批次需求商品  $m$ ,若货架  $k$  存储商品  $m$ ,即  $W_m > 0$ ,  $S_{km} > 0$ ,则  $C_k$  值加一;若货架  $k$  存储商品  $m$  且库存量满足需求量,即  $W_m > 0$ ,  $S_{km} \geq W_m$ ,则  $P_k$  值加一。检测所有商品需求得到货架  $k$  的  $C_k$  值和  $P_k$  值。

在对货架量化的基础上,为得到批次的较优货架组合,提出批次选取货架规则,主要步骤如下。

(1) 根据批次需求  $W_m$ ,计算每个货架的  $P_k$  值并选择最大值货架,若存在多个货架具有最大  $P_k$  值,则从中随机选择货架;若货架的  $P_k$  值均为 0,则随机选择具有最大  $C_k$  值的货架。

(2) 使该货架尽可能满足批次需求,更新批次需求  $W_m$  和货架库存  $S_{km}$ 。返回步骤(1),不断选择供应货架,直至批次的所有商品需求均被满足,由此得到批次的供应货架组合。

(3) 在当前货架集合下,计算每个批次所需货架数,将调用货架数最少的批次作为拣选批次,删除已建立供需关系的货架。返回步骤(1),基于当前货架集合继续为批次选择货架,得到所有批次的供应货架组合,据此计算 AGV 搬运成本。

### 2.2.3 生成初始种群

初始种群的质量直接影响遗传算法求解性能,完全随机生成虽具有良好的多样性,但也有一定的

盲目性。为了提高种群质量的同时保持个体多样性,本文设计启发式策略构造初始种群。考虑到批次商品类型数决定人工拣货次数,为了减少人工拣货成本,将所需商品相同的订单合并作为一个批次。基于此,本文引入商品相似度  $Simi$ ,计算方式为两两订单或批次和订单的相同商品类型数与总商品类型数之比。采用以下 3 种方式分别得到 1/3 种群规模的个体,将其汇总作为初始种群。其中,  $O$  表示未分批订单集合,  $W_k$  表示第  $k$  个批次包含的订单。

(1) 随机选择多个初始订单共同确定批次。

1) 随机为每个批次选择初始订单,将这些订单从集合  $O$  中移除。

2) 计算集合  $O$  中每个订单与各批次的相似度  $Simi$ ,若  $Simi_{\max} > 0$ ,将具有最大相似度的订单加入相应批次,更新集合  $O$  和批次  $W_k$ ;若  $Simi_{\max} = 0$ ,表明集合  $O$  中的订单不存在与任何批次所需商品相同,则在满足最大订单数限制的条件下,将集合  $O$  中的订单随机分配至批次。

(2) 随机选择单个初始订单依次确定批次。

1) 随机选择一个订单形成批次,将该订单从集合  $O$  中移除。

2) 计算集合  $O$  中每个订单与当前批次的相似度  $Simi$ ,若  $Simi_{\max} > 0$ ,将具有最大相似度的订单加入当前批次,更新集合  $O$  和批次  $W_k$ ,若  $W_k$  中订单数达到最大限制,则确定该批次,否则继续执行步骤 2);若  $Simi_{\max} = 0$ ,表明集合  $O$  中的订单不存在与当前批次所需商品相同,则确定该批次,返回步骤 1),继续形成批次,直到批次数等于拣选站台数。最后,在满足最大订单数限制的条件下,将集合  $O$  中的订单随机分配至批次。

(3) 随机选择合并订单组合共同确定批次。

1) 对于集合  $O$ ,每个订单各自作为一个批次。

2) 尝试将两两批次合并,对于合并后不超过最大订单数限制的组,随机选择一个合并;若合并后均超过限制,将包含订单数最少的批次拆分为单个订单,计算每个订单与未饱和批次的  $Simi$ ,在满足最大订单数限制的条件下,依次将具有  $Simi_{\max}$  的订单加入相应批次。继续执行步骤 2),直到批次数等于拣选站台数。

### 2.2.4 选择、交叉与变异

#### 2.2.4.1 选择算子

由于遗传操作具有很大随机性,可能会丢失适应度较好的个体,为了将表现较好的个体尽可能遗传到下一代,本文采用精英解保留和轮盘赌相结合的选择算子。设置保留参数  $g=2\%$ ,选择父代中前



2%的较优个体,使它们无需交叉和变异直接复制到下一代。新种群中其他个体采用轮盘赌从原种群中选择。该方式可防止父代中较优个体被破坏,同时保证适应度高的个体具有更大概率存活到下一代,从而提高算法的全局收敛性。

#### 2.2.4.2 自适应交叉与变异概率

遗传操作的交叉概率  $P_c$  和变异概率  $P_m$  直接影响算法的收敛性和稳定性。在标准 GA 中,两种概率值固定,对于交叉概率  $P_c$ ,过大将增加优良个体被破坏的可能性;过小时则会减慢种群的进化速度,导致搜索效率降低。对于变异概率  $P_m$ ,过大将变成单纯的随机搜索,不利于算法收敛;过小时会降低种群的多样性,不利于产生新个体<sup>[18]</sup>。因此,为了在保留优秀个体的同时防止算法陷入局部收敛,本文构造一种反馈学习机制,采用 Sigmoid 函数对  $P_c$  和  $P_m$  进行自适应控制<sup>[19]</sup>,如式(18)、(19)所示

$$P_c = \begin{cases} P_{cmin} + \frac{P_{cmax} - P_{cmin}}{1 + \exp \left[ A \frac{2(f' - f_{avg})}{f_{max} - f_{avg}} \right]} & f' \geq f_{avg} \\ P_{cmax} & f' < f_{avg} \end{cases} \quad (18)$$

$$P_m = \begin{cases} P_{mmin} + \frac{P_{mmax} - P_{mmin}}{1 + \exp \left[ A \frac{2(f - f_{avg})}{f_{max} - f_{avg}} \right]} & f \geq f_{avg} \\ P_{mmax} & f < f_{avg} \end{cases} \quad (19)$$

式中,  $P_{cmax}$  和  $P_{cmin}$  分别为最大和最小交叉概率;  $P_{mmax}$  和  $P_{mmin}$  分别为最大和最小变异概率;  $A$  为 Sigmoid 曲线平滑参数,取值为 9.903 438;  $f_{max}$ 、 $f_{avg}$  分别为种群中适应度的最大值和平均值;  $f'$  和  $f$  分别为待交叉两个个体中较大的适应度和待变异个体的适应度。通过 Sigmoid 函数对交叉和变异概率灵活调整,具有以下优势: ① 当个体适应度值较差时,给予更高的变换概率,而当适应度较高时变换概率较低,在尽力保留优秀个体的同时增加较差个体的变换能力; ② 当多数个体适应度接近  $f_{avg}$  时,  $P_c$  和  $P_m$  趋向最大,避免种群在进化初期停滞不前; ③ 当个体适应度接近  $f_{max}$  时,  $P_c$  和  $P_m$  逐渐减小,能够尽可能保证优秀解不被破坏。因此,采用此函数能够有效克服算法早熟和局部收敛的现象,满足种群在不同阶段的演化特点,增强遗传算法的鲁棒性。

#### 2.2.4.3 交叉算子

采用两染色体基因段互换交叉算子。先随机产

生两个交叉点  $X$  和  $Y$ ,再根据交叉概率  $P_c$ ,将父代个体在交叉点之间的基因段互换,如图 4 所示。

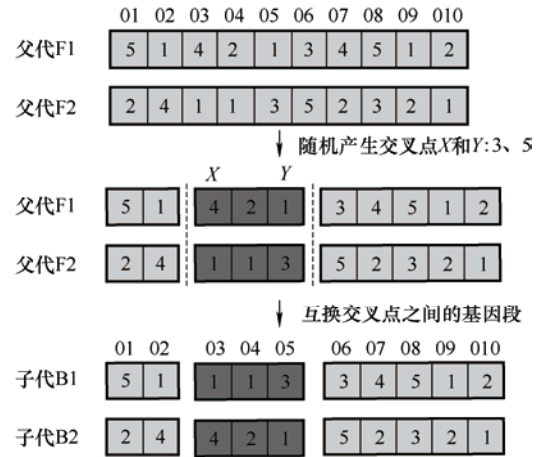


图4 交叉算子

#### 2.2.4.4 变异算子

采用单染色体基因值互换变异算子。先随机产生两个变异点  $M$  和  $N$ ,且变异点基因值的实数编码不同,再根据变异概率  $P_m$ ,将两个变异点的基因值互换得到新个体,如图 5 所示。

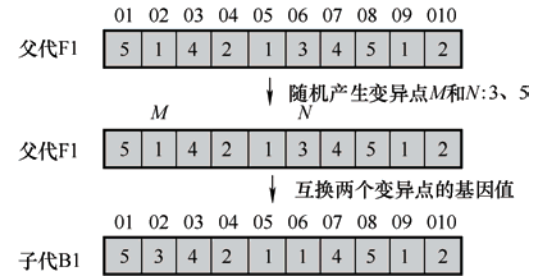


图5 变异算子

#### 2.2.4.5 种群修复

通过交叉和变异操作,基因位上的基因值可能发生改变,使得订单的所属批次发生改变。若变换后染色体的基因值缺少某批次编号,不符合每个批次均包含一定数量订单的条件,为不可行染色体。考虑到种群规模一定及“优胜劣汰”的自然法则,采用以下方式修复种群:将不可行染色体随机替换为适应度值前 10%的个体,从而确保种群中所有个体均为可行解。

#### 2.2.5 局部搜索

遗传算法通过种群进化过程,采用选择、交叉和变异操作扩大全局搜索范围。在此基础上,为了提高局部搜索能力,在新一代种群产生后,对每个个体以自身为搜索起点进行局部扰动,用局部最优解取代原个体在种群中的位置。本文采用全局搜索和局部寻优的方式,通过设置合理的遗传迭代次数

和局部搜索次数,实现对种群优良信息的广泛推广以及对较好个体的细致搜索,从而提高获得全局最优解的可能性。局部搜索过程如下。

首先,设  $S(t)=\{S_1(t), S_2(t), \dots, S_i(t), \dots, S_m(t)\}$ ,  $S(t)$  表示第  $t$  代种群,  $m$  表示种群中的个体数,  $S_i(t)$  表示第  $t$  代种群的第  $i$  个个体;然后,对  $S(t)$  中的每个个体  $S_i(t)$  进行局部搜索,设置最大局部搜索次数为  $L_{\max}$ ,  $S_{ij}(t)$  表示第  $t$  代种群中第  $i$  个个体经过第  $j$  次搜索后的结果,若  $S_{ij}(t)$  优于上一次迭代结果,则接受新解替代旧解,否则保持旧解不变,继续下一轮局部扰动,直到达到最大搜索次数  $L_{\max}$ ;最后,通过不断迭代更新每个个体局部搜索后的最优解,得到优化后的第  $t$  代种群  $S(t)$ 。其中,局部扰动包括移除和修复两个步骤:① 移除。随机选择 20% 的批次,删除其供应货架放入未调用货架集合;② 修复。采用货架选取规则,为这些批次重新选择货架,计算个体适用度值。

### 3 仿真试验及数据测试

本文所有测试在 Intel Core i5 2.11GHz CPU 16GB RAM 的计算机上运行,采用 12.9 版本的 CPLEX 作为模型求解器,启发式算法采用 C++ 编

码,在 Visual studio 2019 平台上实现。根据文献[16]计算方法,人工拣选每种商品的成本大约为  $k_1=0.4$  元,AGV 搬运每次货架的成本大约为  $k_2=0.57$  元。参考文献[20],在试验中设置 Sigmoid 函数的最大和最小交叉概率  $P_{c\max}$  和  $P_{c\min}$  分别为 0.8、0.05;最大和最小变异概率  $P_{m\max}$  和  $P_{m\min}$  分别为 0.1、0.01。设置种群规模  $N=100$ ,最大迭代次数  $G_{\max}=200$ ,每代个体局部搜索次数  $L_{\max}=20$ 。

#### 3.1 模型有效性验证

为了验证数学模型的正确性和改进自适应遗传算法的有效性,将 CPLEX 求解模型结果与算法结果对比分析,试验数据来源为某电商仓库。通过初步试验发现,由于 CPLEX 求解能力有限,当商品数、货架数、订单数过多时无法在一定时间内获得最优解,因此采用较小规模数据测试,结果如表 2 所示。其中,第 1 列表示算例(包括商品数 P\_订单数 O\_货架数 S\_批次数 B\_周转箱数 M);第 2~5 列表示 CPLEX 测试结果;第 6~9 列表示 IAGA 算法测试结果; $C_1$  和  $C_2$  分别表示人工拣选成本和 AGV 搬运成本, $C_c$  和  $C_l$  分别表示 CPLEX 和 IAGA 算法的拣选总成本; $t$  表示求解时间;Gap C 表示二者在总成本上的差异,计算公式为  $\text{Gap C}=100 \times (C_l - C_c) / C_H$ 。

表 2 模型与算法求解结果对比

算例	CPLEX				IAGA				Gap C (%)
	$C_1$	$C_2$	$C_c$	求解时间 $t/s$	$C_1$	$C_2$	$C_c$	求解时间 $t/s$	
P10_O10_S30_B4_M3	8.8	3.99	12.79	9.16	8.8	3.99	12.79	2.932	0
	10	3.99	13.99	11.85	10	3.99	13.99	4.421	0
P12_O12_S35_B4_M3	11.2	5.7	16.9	21.45	12	5.13	17.13	3.944	1.34
	14.4	6.27	20.67	472.69	14.4	6.27	20.67	4.724	0
P14_O14_S40_B4_M4	15.6	5.13	20.37	461.00	15.6	5.13	20.37	6.373	0
	15.2	5.7	20.9	299.18	15.6	5.7	21.3	9.597	1.88
P16_O16_S45_B4_M4	20	6.27	26.27	673.23	20.9	6.84	27.74	11.545	5.29
	20	6.84	26.84	1 969.23	20	8.55	28.55	9.723	5.98
P18_O18_S50_B4_M5	22.8	6.27	29.07	74 594.68	23.2	7.41	30.61	10.937	5.03
	21.6	7.41	29.01	32 400.72	22	9.12	30.39	9.697	4.54
Ave.				11 091.32				7.389	2.41

测试结果显示:① 随着订单规模增大,拣选总成本不断增加,人工拣选成本总是高于 AGV 搬运成本,且变化幅度较明显。由此可见,订单规模对人工拣选成本影响较大,该成本控制也是实现降本增效的关键;② 对于 5 种不同规模的 10 组算例,当规模较小时,算法能够对 4 组算例求得最优解;

当求解规模逐渐增大时,算例能够获得近似最优解,与最优解差距均能控制在 6% 范围内,平均 Gap 仅为 2.41%;③ 在求解时间上,CPLEX 求解时间随算例规模的增大呈指数型增长,平均运行时间 11 091.32 s,而算法平均求解时间 7.389 s,可在短时间内获得最优解或近似最优解。由此可见,本文

数学模型是正确且有效的, IAGA 算法在求解能力和求解效率上表现优异。

### 3.2 种群初始化方法有效性分析

为了验证本文种群初始化方法的有效性, 将采用随机生成方法与采用本文启发式生成方法的求解结果对比分析, 二者分别表述为随机方法(Ran)和启发式方法(Heu)。算例规模设置订单数为 30、货架数为 100、商品种类为 15、批次数为 5、周转箱数为 6,

对一组试验数据测试 5 次, 结果如表 3 所示。第 2~5 列表示随机方法结果; 第 6~9 列表示启发式方法结果; 第 10~11 列表示 CPLEX 在 12 h 运行时间内获得的上界(UB)和下界(LB)。C<sub>0</sub> 表示初始种群的平均适应度; C 表示最终优化结果, 即拣选总成本; Var C 和 Avg C 分别为求解结果的方差和均值; Gap C<sub>0</sub> 和 Gap C 表示两种方法在初始种群平均适应度和最终结果上的差异, 计算公式为  $100 \times (\text{Ran} - \text{Heu}) / \text{Ran}$ 。

表 3 种群初始化方法比较

测试	IAGA (Ran)				IAGA (Heu)				CPLEX		Gap C <sub>0</sub> (%)	Gap C (%)
	C <sub>0</sub>	C	时间/s	Var C	C <sub>0</sub>	C	时间/s	Var C	UB	LB		
test1	39.893 3	37.17	16.85	0.3128	39.711 2	36.77	17.81	0.081 8			0.45	1.07
test2	39.939 2	36.20	17.41		39.668 7	36.60	17.44				0.67	-1.11
test3	39.941 2	37.40	17.03	Avg C	39.736 6	36.60	15.65	Avg C	35.920 0	25.673 4	0.51	2.14
test4	39.929 3	36.60	16.24	36.708	39.698 5	36.03	17.58	36.474			0.57	1.55
test5	39.892 9	36.17	15.89		39.669 9	36.37	16.90				0.56	-0.55

由表 3 可知: ① 采用启发式方法比随机生成方法所得初始种群的平均适应度较好, 相差 0.4%~0.7%; 对于所得最终结果, 两种方法所得解的优劣存在一定波动, 说明算法后期的搜索效率和收敛效率优良, 可在一定迭代次数内对初始种群进行改善得到质量较优的解; ② 根据方差和均值可知, 启发式方法所得解的稳定性和质量均优于随机方法, 这是因为启发式方法能够尽可能减少每个批次的商品类型数, 从而减少人工拣选成本, 而且采用三种规则构造初始种群远比随机生成的初始种群分布均匀, 具有较好的多样性; ③ 从 CPLEX 求解结果来看, 在 12 h 内所得上界和下界之间的百分差为 28.52%, 说明随着算例规模增大, CPLEX 不能提供较紧的下界。对于两种方法所得结果的平均值, 与 CPLEX 所得上界分别仅相差 2.14% 和 1.5%, 表明随着 CPLEX 求解时间的增加, 算法结果与最优解的差距在可接受范围内, 而在求解时间上具有显著优

势, 进一步验证了算法的有效性和稳健性。

### 3.3 周转箱配置数量灵敏度分析

在采用“货到人”拣选模式的电商仓库中, 每个拣选站台配备一定数量的周转箱, 存放一个批次的订单所需商品, 由拣选人员从货架上拣取商品并放入订单相应周转箱, 待拣选完毕后直接以周转箱为单位进行订单包装和发货, 避免了二次分拣作业。在实际中, 周转箱数为批次所能包含的最大订单数, 数量过多将会占用空间且增加采购成本, 过少则会影响批次订单数量, 进而影响分批效果, 因此有必要探讨周转箱的合理配置数量。算例规模设置商品种类为 15, 货架数为 100, 批次数为 5, 在订单规模为 30、35、40、45 的情况下测试周转箱数变化对分批结果的影响, 结果如表 4 所示。其中, M 表示周转箱数; N<sub>1</sub> 表示人工拣选总次数; N<sub>2</sub> 表示 AGV 搬运总次数, C 表示拣选总成本。

表 4 周转箱数变化分析

O	M	N <sub>1</sub>	N <sub>2</sub>	C	O	M	N <sub>1</sub>	N <sub>2</sub>	C	O	M	N <sub>1</sub>	N <sub>2</sub>	C	O	M	N <sub>1</sub>	N <sub>2</sub>	C
	6	69	19	38.43		7	72	22	41.34		8	75	25	44.25		9	74	31	47.27
	7	66	19	37.72		8	68	21	39.17		9	69	24	41.28		10	73	28	45.61
	8	60	18	34.26		9	62	21	36.77		10	64	23	38.71		11	72	28	44.76
30	9	58	18	33.46	35	10	61	21	36.37	40	11	64	21	37.57	45	12	64	27	40.99
	10	56	19	33.23		11	59	20	35.00		12	62	21	36.77		13	63	27	40.59
	11	53	18	31.46		12	58	20	34.60		13	59	21	35.57		14	61	28	40.36
	12	52	18	31.06		13	56	20	33.80		14	58	21	35.17		15	59	27	38.99

由结果可知: ① 对于人工拣选总次数和 AGV

搬运总次数, 如图 5 所示, 在不同订单规模下, 随



着周转箱数的增加, 人工拣选次数减少趋势逐渐趋于平缓, AGV 搬运次数波动很小趋于不变。主要原因是, 周转箱数的增加使批次所能包含订单数增多, 在满足数量限制范围内, 订单不断加入与其相似度较大的批次, 人工拣选商品次数减少。由于货架商品库存比较充足, 当批次中订单数增加较少时, 所调用较优货架基本相同, 因此 AGV 搬运次数波动较小; ② 对于拣选总成本, 如图 6 所示, 与人工拣选次数变化相同, 在同一订单规模下, 基本呈现由陡峭到平缓的下降趋势。调查发现, 周转箱单价为 2.1 元/个, 当采购成本不足以节约更多拣选总成本时, 周转箱数量的增加无法带来经济效益。由结果可知, 在订单规模为 30、35、40、45 时, 较优的周转箱配置数量分别为 8、9、10、12, 此时成本减幅较大且周转箱利用率较高; ③ 由图 6 可知, 当订单数由 40 不断增加时, 拣选总成本增幅明显。主要原因是, 订单过多时, 单个货架的库存可能无法满足批次的某种商品需求, 需要调用多个货架, 导致 AGV 搬运次数增加较多。因此, 在拣选设备有限的条件下, 待分批订单并非越多越好, 过多将导致成本大幅增加, 在此数据规模下较合理订单数量为 30~40。通过灵敏度分析, 可为不同仓库规模的周转箱数量配置和订单数量设置提供参考。拣选总成本变化如图 7 所示。




图 6 人工拣选总次数与 AGV 搬运总次数变化图




图 7 拣选总成本变化图

## 4 结论

本文深入研究了电商企业智能仓库采用 AGV 实现“货到人”拣选的运行模式, 对该系统的订单分批与货架调度问题进行研究。首先, 在每个订单需求多种商品、商品多货架存储、货架与订单供需匹配关系未知等实际背景下, 综合考虑人工拣货成本和 AGV 搬运成本, 以拣选总成本最小为目标建立整数规划数学模型。然后, 结合问题特点提出了改进自适应遗传算法, 在算法中设计订单选取货架规则, 引入自适应交叉和变异概率, 并采用局部搜索加快收敛速度。最后, 通过试验测试表明: ① 本文模型是正确且有效的, 改进自适应遗传算法在求解质量和求解效率上具有明显优势; ② 本文遗传操作采用启发式策略构建初始种群, 所得解的稳定性和质量均优于随机生成种群方法; ③ 本文算法可探讨在给定配送中心规模与业务规模下的周转箱数量优化问题, 为配送中心的周转箱配置和订单数设置给出合理建议。综上所述, 在电商企业大力发展自动化拣选技术的背景下, 合理的订单分批策略可以帮助企业进一步减少运行成本、提高拣选效率, 本研究可为我国智能仓库建设提供理论指导和科学依据。在未来的研究中, 可以考虑缺货和补货的情况, 研究在线订单分批问题, 还会考虑商品属性和货架位置, 对不同拣选成本和搬运成本的订单分批问题进行深入探讨。

## 参 考 文 献

- [1] RENÉ D K, POORT E V D. Routing orderpickers in a warehouse: A comparison between optimal and heuristic solutions[J]. IIE Transactions, 1998, 30(5): 469-480.
- [2] DEBJIT R, SHOBHIT N, RENÉ de K, et al. Robot-storage zone assignment strategies in mobile fulfillment systems[J]. Transportation Research Part E, 2019, 122: 119-142.
- [3] 王旭坪, 张珺, 易彩玉. B2C 电子商务环境下订单拣选与配送联合调度优化[J]. 中国管理科学, 2016, 24(7): 101-109.  
WANG Xuping, ZHANG Jun, YI Caiyu. Integrated scheduling of order picking and delivery under B2C e-commerce[J]. Chinese Journal of Management Science, 2016, 24(7): 101-109.
- [4] HWANG H, LEE M K. Order batching algorithms for a man-on-board automated storage and retrieval system[J].

- Engineering Costs & Production Economics, 1988, 13(4): 285-294.
- [5] MENENDEZ S, PARDO E G, ALONSO-AYUSO A, et al. Variable neighborhood search strategies for the order batching problem[J]. Computers & Operations Research, 2016, 78(2): 500-512.
- [6] ROSENWEIN M B. A comparison of heuristics for the problem of batching orders for warehouse selection[J]. International Journal of Production Research, 1996, 34(3): 657-664.
- [7] MENENDEZ S, PARDO E G, ALONSO-AYUSO A, et al. Variable neighborhood search strategies for the order batching problem[J]. Computers & Operations Research, 2016, 78(2): 500-512.
- [8] KOCH S, WASCHER G. A grouping genetic algorithm for the order batching problem in distribution warehouses[J]. Journal of Business Economics, 2016, 86(1): 131-153.
- [9] HENN S. Order batching and sequencing for the minimization of the total tardiness in picker-to-part warehouses[J]. Flexible Services & Manufacturing Journal, 2015, 27(1): 86-114.
- [10] XIANG Xi, LIU Changchun, MIAO Lixin. Storage assignment and order batching problem in Kiva mobile fulfilment system[J]. Engineering Optimization, 2018, 50(11): 1941-1962.
- [11] NILS B, DIRK B, SIMON E. Parts-to-picker based order processing in a rack-moving mobile robots environment[J]. European Journal of Operational Research, 2017, 262(2): 550-562.
- [12] 吴颖颖, 孟祥旭, 王艳艳, 等. “货到人”拣选系统订单排序优化[J]. 机械工程学报, 2016, 52(4): 206-212.
- WU Yingying, MENG Xiangxu, WANG Yanyan, et al. Order sequence optimization for “part-to-picker” order picking system[J]. Journal of Mechanical Engineering, 2016, 52(4): 206-212.
- [13] 胡金昌, 马文凯, 杨栋, 等. 考虑客户收货顺序的“货到人”分拣系统的订单排序和客户分批优化[J]. 机械工程学报, 2020, 56(24): 246-253.
- HU Jinchang, MA Wenkai, YANG Dong, et al. “Part-to-picker” picking system order scheduling and customer batching considering commodities received by an order’s sequence[J]. Journal of Mechanical Engineering, 2020, 56(24): 246-253.
- [14] 李晓杰. 移动货架仓库系统中货位分配和订单分批联合优化研究[D]. 北京: 清华大学, 2016.
- LI Xiaojie. Joint storage location assignment and order batching in mobile-pods warehouse systems[D]. Beijing: Tsinghua University, 2016.
- [15] 范继东. 货到人系统拣选订单分批处理策略问题研究[J]. 物流技术, 2019, 38(12): 71-75.
- FAN Jidong. Study on batch picking strategy of “goods to person” picking system[J]. Logistics Technology, 2019, 38(12): 71-75.
- [16] 李珍萍, 田宇璇, 卜晓奇, 等. 无人仓系统订单分批问题及 K-max 聚类算法[J]. 计算机集成制造系统, 2021, 27(5): 1506-1517.
- LI Zhenping, TIAN Yuxuan, BU Xiaoqi, et al. The order batching problem of unmanned warehouse system and the k-max clustering algorithm[J]. Computer Integrated Manufacturing Systems, 2021, 27(5): 1506-1517.
- [17] 李珍萍, 付红叶, 卜晓奇, 等. 基于 AGV 的智能仓库系统订单分批问题研究[J]. 运筹与管理, 2020, 29(9): 1-9.
- LI Zhenping, FU Hongye, BU Xiaoqi, et al. Research on order batching problem of intelligent warehouse system based on AGV[J]. Operations Research and Management Science, 2020, 29(9): 1-9.
- [18] LI Danlian, CAO Qian, ZUO Min, et al. Optimization of green fresh food logistics with heterogeneous fleet vehicle route problem by improved genetic algorithm[J]. Sustainability, 2020, 12(5): 1-17.
- [19] 缪朝炜, 苏瑞泽, 张杰. 越库配送车辆调度问题的自适应遗传算法研究[J]. 管理工程学报, 2016, 30(4): 166-172.
- MIU Chaowei, SU Ruize, ZHANG Jie. An adaptive genetic algorithm for the truck scheduling problem in the crossdock[J]. Journal of Industrial Engineering, 2016, 30(4): 166-172.
- [20] GU X, HUANG M, LIANG X. An improved genetic algorithm with adaptive variable neighborhood search for FJSP[J]. Algorithms, 2019, 12(11): 243.
- 
- 作者简介: 李昆鹏, 男, 1978 年出生, 博士, 教授。主要研究方向为物流与供应链管理、生产运作管理。  
E-mail: likp@mail.hust.edu.cn
- 刘腾博, 女, 1997 年出生, 硕士研究生。主要研究方向为智能物流调度。  
E-mail: ltb@hust.edu.cn
- 李文莉(通信作者), 女, 1992 年出生, 博士, 讲师。主要研究方向为物流路径优化。  
E-mail: 614548702@qq.com