

基于联合配送的城市物流配送路径优化

葛显龙¹, 许茂增¹, 王伟鑫²

(1. 重庆交通大学 管理学院, 重庆 400074; 2. 四川外国语大学 国际商学院, 重庆 400051)

摘要: 针对城市多区域协同发展造成的商业中心相对分散的现状, 提出“多对多”的城市网络化联合配送机制. 以运输距离、实载率等与成本密切相关的油耗成本为优化目标, 建立面向城市多区域配送需求的车辆路径模型; 同时, 利用量子比特位设计染色体结构, 利用云模型云滴随机性与稳定性改进遗传算子, 设计云量子遗传算法对所建立的联合配送模型进行求解. 最后, 结合不同算例对模型和算法进行了仿真实验分析.

关键词: 城市物流配送; 联合配送; 车辆路径问题; 云量子遗传算法

中图分类号: TP273

文献标志码: A

Route optimization of urban logistics in joint distribution

GE Xian-long¹, XU Mao-zeng¹, WANG Wei-xin²

(1. School of Management, Chongqing Jiaotong University, Chongqing 400074, China; 2. School of International Management, Sichuan International Studies University, Chongqing 400051, China. Correspondent: GE Xian-long, E-mail: gexianlong@cqjtu.edu.cn)

Abstract: For the dispersive situation of business centers in cities caused by regional developing, networked many-to-many distribution mechanisms is proposed. And the vehicle routing optimization model for regional distributing in cities is established, taking the fuel consumption as the optimal target which is closely related to shipment distance, actual load rate and so forth. Then the cloud quantum genetic algorithm, with chromosome structure designed by utilizing quantum bits and genetic operator improved by adopting randomness and stability of cloud droplet in the cloud model, is designed to solve the routing optimization model for joint distribution. For the comparison, several different cases are conducted to illustrate the established model and solving algorithm.

Keywords: urban logistics; joint distribution; vehicle routing problem; cloud quantum genetic algorithm

0 引言

随着城市化进程的不断加快与城市经济的蓬勃发展, 我国已经形成一批特大城市与大城市群, 在这些大城市中形成多个人群聚集区与商业中心. 城市物流配送是城市经济发展与居民生活的重要支撑系统, 然而落后的城市交通基础和拥堵的交通现状, 粗放式的物流管理模式已经难以支持城市物流配送需求, 并已严重影响城市居民的日常生活, 如何实现城市物流集约化配送已成为学者和业界关注的热点问题. 物流配送的核心问题是车辆路径问题 (VRP), VRP 产生于公路交通管理领域^[1], 在公路交通、航班安排、生产计划等不同领域拥有巨大的应用价值, 一直是国内外学者研究的热点问题.

由于城市规模大、商业中心相对分散、基础交通落后, 一般城市物流多采取分区式配送, 根据客户群规模设置多个配送中心, 每个配送中心负责一个区域的客户服务, 该问题可以抽象为多配送中心车辆路径问题 (MDVRP). MDVRP 是由 VRP 衍生而来, 经过近年的研究在模型建立和求解方法上取得了一定成果. Andrea 等^[2]构建以运输距离最短为优化目标的多车型 MDVRP 模型; Dondo 等^[3]研究了带时间窗约束的 MDVRP; Rahimi 等^[4]研究了多周期 MDVRP; Pessoa 等^[5]通过引入“车队模式”定义, 研究多车型 MDVRP; Seixas 等^[6]研究了带时间窗的 MDVRP, 分析了不同车辆的混合装载能力与行驶速度对配送的影响; 王晓博等^[7]针对电子商务客户多样化和个性化需求, 建立

收稿日期: 2014-12-16; **修回日期:** 2015-04-02.

基金项目: 国家自然科学基金项目(71502021); 教育部人文社会科学基金项目(2014YJC630038); 教育部人文社会科学基金项目(15XJC630007); 重庆市教委自然科学基金项目(KJ400311).

作者简介: 葛显龙(1984—), 男, 副教授, 从事城市物流、电商配送与网络优化等研究; 许茂增(1960—), 男, 教授, 博士生导师, 从事网络规划、城市物流等研究.

了多车型多配送中心的装卸混合车辆调度模型; Liu等^[8]综述了MDVRP的定义、求解方法、问题的演变,并指出该问题在城市配送与电子商务时代应给予更多关注. 但已有MDVRP的研究主要集中在如何将多配送中心问题转化为单配送中心,由单个配送中心固定负责一个区域客户的服务. 显然,这种分区式配送难以有效利用物流资源,尤其是客户分散、配送规模增大及需求变动时,分区式配送更难以适应实际需求.

已有文献在MDVRP求解算法方面的研究主要集中在精确算法和智能启发式算法,其中精确算法的研究有: Andrea等^[2]利用分支定界算法研究了多车型MDVRP模型; Bettinelli等^[9]利用分支定界算法研究了带时间窗的MDVRP模型; Righini等^[10]利用动态规划算法研究了最短路径的车辆路径问题. 由于MDVRP模型在求解方面要远复杂于标准VRP模型,精确算法求解MDVRP模型方面研究比较少,求解效果也不理想. 现代启发式算法是重要的研究方向, Dondo等^[3]利用混合遗传算法研究了带时间窗的MDVRP模型; Necati等^[11]利用禁忌搜索算法研究了车辆可选的MDVRP; Pessoa等^[12]针对MDVRP模型设计了遗传算法与禁忌搜索算法相结合的混合启发式算法; 李坤等^[13]利用遗传算法研究了集装箱区域配送模型; 许维胜等^[14]利用Memetic算法研究了车辆路径模型; 张军等^[15]设计了分区搜索算法对MDVRP模型进行求解; 马华伟等^[16]设计了两阶段启发式算法对MDVRP模型进行求解. 由于常用启发式算法在求解大规模、需求复杂的MDVRP模型时存在收敛效率低、求解质量不高、易早熟等难以克服的缺陷,改进和设计新的启发式算法已成为复杂VRP模型求解算法的重要研究方向. 如Narayanan等^[17]提出将量子理论应用于启发式算法设计,利用量子矢量态的表达形式设计量子比特染色体编码,即量子遗传算法(QEA),提高了算法的全局搜索能力; Zhao等^[18]采用实数编码混沌量子遗传算法,并通过VRP算例检验了算法的性能优越于一般启发式算法; Wang等^[19]将量子进化算法应用于物流配送问题的求解; Wang等^[20]将量子进化算法应用于混沌系统的参数估计; 钱洁等^[21]总结归纳了近年来量子进化算法在算法机理设计和性能改进方面的研究成果,并提出了量子进化算法在模式理论、算法融合与创新、应用等方面进一步的研究内容. 由于城市联合配送涉及不同主体物流资源共同使用等问题,在数学建模和求解算法方面均与传统的车辆路径问题有较大区别,已有的研究文献多是将多配送中心简单转化为单配送中心,沿用传统车辆路径问题的研究方法,显然不能有效对物流资源进行优化配置.

本文针对城市多区域配送中物流资源难以集成共享的现实需求,打破传统分级分区式配送机制,提出“多对多”的网络化联合配送机制,并设计考虑多重因素的车辆与配送中心匹配矩阵,根据任务需求采取实行开放式的车辆停靠策略,从整体配送系统的角度研究不同主体资源的有效共享. 同时,在分析运输成本和实载量与车载率关系的基础上,建立以油耗为优化目标的城市多区域联合配送模型. 针对联合配送模型复杂难求解问题,提出利用量子理论和云模型理论改进遗传算法. 最后,结合不同算例对联合配送模型和云量子遗传算法进行了仿真实验分析.

1 问题描述

随着城市规模的扩大和商业中心的相对分散,城市多区域配送和连锁超市配送的需求越来越多,如何实现物流资源的有效整合,降低城市物流配送成本成为当前城市物流配送亟待解决的问题. 城市多区域配送问题是典型的MDVRP,涉及多个配送中心共同参与完成配送需求,与单配送中心VRP问题的主要区别是MDVRP中不同配送中心如何共同参与配送过程. 目前,城市大型车辆受到交通限行政策的影响,大多企业的物流配送均采用分级配送,在市郊设置大型仓库,通过不受限的中小型企业车辆将商品送至各配送中心,由配送中心采取分区式配送模式负责各个区域的客户服务,如图1所示.




图1 多配送中心车辆路径问题示意图

MDVRP一般描述为: 在物流网络中由多个配送中心负责客户的配送服务,对于静态MDVRP中配送中心和客户的位置是已知的,同时假设仓库和配送中心的货物能够满足所有客户的需求,不同客户需求货物相互可以混装,要求每个客户的需求量不超过车辆的最大载重量,并且仅由一台车辆负责,不允许需求拆分. 假定车辆的最大载重量已知、不允许超载,配送一次的最大行驶距离已知,不允许违反. 配送中心与客户之间以及客户相互之间的配送距离已知,要求配送任务开始时车辆均从配送中心出发,且要求任务完成后返回原配送中心.

2 建立城市多区域联合配送模型

2.1 设计网络化联合配送机制

目前分区式物流配送是城市物流配送的主要形

态,已有的文献也对该问题进行了较多研究.以往针对MDVRP的研究主要集中在设计客户分配算法或规则,将多配送中心问题转化为单配送中心问题,先对单配送中心问题求解,进而实现对多配送中心问题求解.城市物流配送在企业管理中多采取项目制管理模式,采取分级管理分配送,公司仓库为每个配送中心分拨,各个配送中心负责各自区域的客户需求.这种“一对多”的分区式配送机制在货物供应比较单一、需求稳定时能很好地满足配送需求,但当货物种类增多、需求动态变化时,分区配送机制则难以实现城市物流集约配送目标,如图2所示.




图2 传统分级分区式配送机制

当配送网络客户比较少、少批次大批量需求时,这种分级分区配送模式能较好地满足需求,同时效率也较高.然而,城市多区域配送是一个十分复杂的配送系统,客户需求分散,货物种类千差万别,并且配送要求复杂.显然,传统分级分区式配送割裂了隶属同一主体的各个配送中心间的相互联系,客户固定由某一配送中心负责,造成各个配送中心忙闲不均、客户响应效率低、车辆闲置或返程空驶、迂回运输等资源浪费现象严重,物流资源没有形成有效集成与共享.为了更好地实现城市集约化配送,本文提出面向城市多区域配送需求的网络化联合配送机制,从全局视角设计“多对多”物流配送网络结构,打破传统分级分区配送模式中不同区域不同资源相互割裂的问题,从整体配送系统出发对客户要求进行网络化联合配送服务,如图3所示.




图3 “多对多”的网络化联合配送模式

在网络化联合配送机制中,不再对客户采取固定分区由单个配送中心负责服务,而是根据每次具体配送任务动态化分配车辆停靠的配送中心,让隶属配送中心的车辆可以根据配送任务、成本等因素在任意配送中心停靠及补充货物,并且不同配送中心的车辆可以依据当前任务的完成情况及配送成本对配送区域内的任何需求客户进行灵活响应,最大限度地提高城市物流配送的响应能力.同时,不同配送中心间可以相互补充货物及均衡货物需求,打破分区式配送机制中分级管理的各配送中心独立运营的限制,最大可能实现城市物流资源的集成与共享.因此,网络化联合配送机制加强了城市多区域配送间的合作和配送资源的共享,减少了造成城市交通拥堵与环境污染的车辆返空、交叉运输等资源浪费现象,提高了城市物流配送效率.

2.2 设计车辆停靠的最优匹配矩阵

在传统多配送中心车辆路径问题中,将客户划分为不同配送中心负责,车辆都是停靠固定配送中心,所以不存在车辆与配送中心匹配问题.然而,在城市多区域联合配送中涉及隶属不同配送中心车辆的任意停靠,如何选择车辆最优停靠的配送中心是资源共享与全局优化的关键.

在网络配送模式中,车辆完成配送任务后选择停靠配送中心时,将受到多种因素的限制,如配送中心的繁忙程度、车辆距配送中心的距离、配送中心货物保有量等.本文在综合考虑这些因素的基础上,设计车辆与配送中心的匹配矩阵,如表1所示.

表1 车辆与配送中心的匹配矩阵

影响因素	D_1	D_2	D_3	...	因素权重
配送中心繁忙程度	Δ_{11}	Δ_{21}	Δ_{31}	...	θ_1
配送中心货物保有量	Δ_{12}	Δ_{22}	Δ_{32}	...	θ_2
车辆距配送中心距离	Δ_{13}	Δ_{23}	Δ_{33}	...	θ_3
车辆的实载率	Δ_{14}	Δ_{24}	Δ_{34}	...	θ_4

表1中 D 表示配送中心, θ 表示影响因素的权重, Δ_{ij} 表示第 i 个配送中心在第 j 个影响因素下的评价情况;配送中心繁忙程度表示配送中心已有配送任务的规模及是否有空闲资源为其他客户提供服务,其计算公式为配送中心的配送任务量与配送网络中总配送任务的比值,目的是均衡配送网络中不同配送中心的运作负荷;配送中心货物保有量表示配送中心在保证已有配送任务的前提下是否能拥有足够的货物为停靠车辆补充货物,其计算公式为配送中心货物总量减去已分配任务量;车辆距配送中心距离表示车辆需要停靠时可供选择配送中心的距离;车辆实载率表示车辆的实际装载量与最大装载量的比率,是衡量车辆使用效率的重要指标;因素权重表示某个影响因素根

据其重要程度赋予的数值。

车辆与配送中心最佳匹配算法如下:

Step 1: 对匹配矩阵中不同指标进行标准化处理。

对于收益性指标, 有

$$r_{ij} = (\Delta_{ij} - \min(\Delta_{ij})) / (\max(\Delta_{ij}) - \min(\Delta_{ij}));$$

对于成本型指标, 有

$$r_{ij} = (\max(\Delta_{ij}) - \Delta_{ij}) / (\max(\Delta_{ij}) - \min(\Delta_{ij})).$$

Step 2: 采取统计比较打分方式确定, 并进行归一化处理各影响因素的权重。

Step 3: 计算每个配送中心停靠的综合评价值

$$W_j = \sum_i r_{ij} \partial_i, j \in \{D_1, D_2, D_3, \dots\}.$$

依据综合评价值的大小, 选择综合评价值最大的配送中心作为车辆最佳停靠的配送中心。

2.3 建立以油耗成本为优化目标的数学模型

已有文献对车辆路径问题的研究主要以路径最短或车辆最少为优化目标, 然而这两个目标均没有考虑运输量与车载率这两个重要影响因素, 造成物流配送路径优化不够彻底。比如, 在送货车辆路径问题中, 车辆路径往往是一个封闭的哈密顿圈, 由于车辆空载时油耗少, 在送货问题中应选择离配送中心最近的一端开始配送, 以降低配送成本。若仅以路径最短为优化目标, 则忽略了对该细节的优化。

物流配送成本主要由固定成本和可变成本构成, 其中车辆实载率与可变成本有着密切关系, 是衡量车辆有效利用的重要指标, 实载率越高油耗成本越高, 但货物每公里运输成本却较低, 因此, 以油耗成本为优化目标能够对物流配送成本进行更为综合与彻底的优化。车辆实载率主要考虑在配送过程中车辆行驶距离与货物装载量两个方面的变量, 由于二者的纲量不一样, 在不同的文献中有不同的处理方式。文献[22]以车辆实际装载量除以最大装载量为实载率, 并结合车辆空载油耗与满载油耗, 计算车辆不同装载状态下的油耗成本。这种方式很好地考虑了行驶距离和装载量, 因此本文将沿用此方式。在非满载VRP中车辆实际装载量是变化的, 因此实载率也将不断变化, 不同路段产生的油耗成本各不相同。记: 在车辆第*i*段运输距离中实载率为 p_i , 运输量为 g_i , 车辆的最大装载量为 Q , 则车辆的实载率为 $p_i = g_i/Q$ 。由于车辆的油耗成本与装载量呈正向相关性, 在此, 沿用文献[22]的研究成果, 车辆在第*i*段运输距离中的单位油耗为

$$e'_i = e_1 + p_i(e_2 - e_1). \quad (1)$$

其中: e_1 为车辆空载时的单位距离油耗, e_2 为满载时的单位距离油耗。若车辆的装载量为 g_i , 运输距离

为 s_i , 则车辆在第*i*段运输距离中的油耗为

$$C = s_i[e_1 + p_i(e_2 - e_1)] = e_1 s_i + s_i p_i(e_2 - e_1). \quad (2)$$

以配送总油耗成本最小为优化目标, 建立面向城市多区域配送需求的联合配送模型如下:

$$\min Z = \sum_{h=1}^H \sum_{k=1}^{K_h} \left\{ e_1 d_{r_{hk} n_{hk} r_{hk0}} + \sum_{i=1}^{n_{hk}} d_{r_{hk(i-1)} r_{hki}} [e_1 + p_{r_{hk(i-1)}}(e_2 - e_1)] \right\}. \quad (3)$$

$$\text{s.t. } p_{r_{hki}} = \left(\sum_{i=1}^{n_{hk}} q_{r_{hki}} - \sum_{j=1}^i q_{r_{hki}} \right) / Q, \\ h = 1, 2, \dots, H, k = 1, 2, \dots, K_h, i \in R_{hk}; \quad (4)$$

$$\sum_{i=1}^{n_{hk}} q_{r_{hki}} \leq Q, \\ h = 1, 2, \dots, H, k = 1, 2, \dots, K_h; \quad (5)$$

$$\sum_{i=1}^{n_{hk}} d_{r_{hk(i-1)} r_{hki}} + d_{r_{hk} n_{hk} r_{hk0}} \leq D, \\ h = 1, 2, \dots, H, k = 1, 2, \dots, K_h; \quad (6)$$

$$\sum_{h=1}^H \sum_{k=1}^{K_h} n_{hk} = L; \quad (7)$$

$$R_{hk} = \left\{ \frac{r_{hki}}{r_{hki}} \in \{1, 2, \dots, L_h\}, i = 1, 2, \dots, n_{hk} \right\}, \\ h = 1, 2, \dots, H, k = 1, 2, \dots, K_h; \quad (8)$$

$$R_{hk_1} \cap R_{hk_2} = \phi, \forall hk_1 \neq hk_2. \quad (9)$$

其中: H 为配送中心的个数; L 为配送网络中客户的个数; L_h 为由第*h*个配送中心负责配送客户的个数; K_h 为第*h*个配送中心拥有车辆的个数; Q 为车辆的最大装载重量; D 为车辆的最大行驶距离; q_i 为第*i*个客户的需求量; n_{hk} 为由第*h*个配送中心的第*k*辆车负责配送的客户个数 ($n_{hk} = 0$ 表示该车辆未参与配送); d_{ij} 为客户*i*与客户*j*的路径长度或实际距离; r_{hki} 为在第*h*个配送中心的第*k*辆车的配送路径上顺序为*i*的客户 (令 $r_{hk0} = 0$ 表示车辆的出发地——配送中心); R_{hk} 为第*h*个配送中心的第*k*辆车的配送路径。 n_{hk} 是决策变量, 与 L_h 、 K_h 共同决定了 R_{hk} 需要配送的客户个数。

上述模型中, 式(3)为模型的优化目标, 即要求城市多区域配送任务所需要的总油耗成本最小; 式(4)为车辆在客户 $r_{hk(i-1)}$ 到客户 r_{hki} 运输过程中的实载率, 式(5)为保证每个配送中心的每辆车在配送过程中均不能超载; 式(6)为保证每个配送中心的每辆车的行驶距离均不能超过车辆的最大行驶距离; 式(7)为每个配送中心的每辆车负责配送的客户数之

和等于总客户数; 式(8)为每个配送中心中每辆车负责配送的客户的集合; 式(9)限制每个客户有且只有一辆车为其配送, 不论其由哪个配送中心负责。

3 设计求解算法

3.1 云量子遗传算法

1996年, Narayanan等^[17]将量子多宇宙的概念引入启发式算法, 并提出量子遗传算法(QGA)。QGA是一种基于量子计算理论的新型启发式算法, 利用量子比特位的态矢量设计染色体编码结构, 通过量子比特位一个个体可以表达多个状态的叠加性来增强种群个体的多样性, 大大提高了算法的全局搜索能力。云量子遗传算法(CQGA)^[23]是将李德毅院士^[24]提出的云模型理论应用于QGA, 改进遗传算法中交叉与变异概率的设置方式, 根据个体的适应度与种群平均适应度的比较动态选择参与交叉操作与变异操作的个体, 当个体适应度低于种群平均适应度时赋予其较大的概率参与遗传操作, 当其适应度高于种群平均适应度时赋予其较小的概率, 以避免降低其参与遗传操作而被破坏, 大大提高算法的收敛能力。

为了提高算法的求解能力以满足城市多区域联合配送模型求解的需求, 对CQGA作以下两方面的改进:

1) 保持GA中遗传操作对种群的进化驱动机制, 增加量子门更新操作, 实现个体染色体基因的进化, 通过遗传操作和量子门旋转双重进化驱动, 提高算法的收敛能力;

2) 在种群进化过程中增加种群扩张机制, 改进了传统进化算法只利用当前种群信息, 忽略往代种群中优秀个体基因的保护, 将上代种群中优秀个体根据种群规模以一定的比例或个数直接进入下一代, 在完成进化操作过程后, 根据选择算子只保留原种群相同数据的个体, 如此便增加了种群的搜索范围, 提高了算法的搜索能力。

由云模型X发生器根据个体适应度生成交叉概率 P_c 和变异概率 P_m 。

P_c 的生成算法如下:

$$\begin{aligned} E_x &= \bar{f}, \\ E_n &= (f_{\max} - \bar{f})/C_1, \\ H_e &= E_n/C_2, \\ E'_n &= \text{Norm}(E_n, H_e); \\ P_c &= \begin{cases} k_1 e^{\frac{(f' - E_x)^2}{2(E_n)^2}}, & f' \geq \bar{f}; \\ k_3, & f' < \bar{f}. \end{cases} \end{aligned}$$

其中: \bar{f} 为种群平均值; f' 为交差操作中较大的适应值; C_1, C_2 为控制系数; k_1, k_3 为[0,1]内的常数, 在此

取 $k_1 = k_3 = 1$ 。

P_m 的生成算法如下:

$$\begin{aligned} E_x &= f, \\ E_n &= (f_{\max} - f)/C_3, \\ H_e &= E_n/C_4, \\ E'_n &= \text{Norm}(E_n, H_e); \\ P_m &= \begin{cases} k_2 e^{\frac{(f - E_x)^2}{2(E_n)^2}}, & f \geq \bar{f}; \\ k_4, & f < \bar{f}. \end{cases} \end{aligned}$$

其中: f 为变异个体; C_3, C_4 为控制系数; k_2, k_4 为[0, 1]内的常数, 在此取 $k_2 = k_4 = 0.5$ 。

3.2 设计云量子遗传算法

1) 量子比特染色体。

利用量子比特位的叠加性增强染色体的多样性, 设计量子比特染色体结构, 对于 L 个客户的VRP可以用 L 个概率幅的量子比特系统表示, 如

$$\begin{bmatrix} \alpha_1 & \alpha_2 & \cdots & \alpha_L \\ \beta_1 & \beta_2 & \cdots & \beta_L \end{bmatrix}, \alpha_i^2 + \beta_i^2 = 1, i = 1, 2, \dots, L. \quad (10)$$

系统(10)中共有 2^L 个状态叠加信息, 将此 2^L 个状态随机构造 $L \times L \times 2$ 的三维量子比特矩阵, 利用三维量子比特矩阵表示量子染色体, 并通过解码将其转化为自然数染色体。首先, 通过对所构造的 $L \times L \times 2$ 三维矩阵进行观察, 将每行每列只有一个1的矩阵保留下来, 按照行为客户编号、列为服务顺序, 将矩阵转化为自然数顺序编码, 如6个客户的VRP问题, 量子染色体矩阵如下:

$$\begin{bmatrix} 0 & 0 & 1 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix}.$$

按照以上矩阵规则生成客户服务顺序为: 2→4→1→6→3→5; 然后, 以贪婪算法根据车辆的最大载重量生成车辆的服务路径, 当车辆超载时按照客户服务顺序重新启用另一辆车, 如(0, 2, 4, 1, 0, 6, 3, 0, 5, 0), 表示6个客户的配送服务需要3辆车完成, 0表示配送中心。

2) 初始化种群。

根据算法需要生成一定量的量子比特染色体结构的个体, 然后按解码方法将量子比特种群转化为自然数编码种群, 并进行相应的遗传操作, 实现种群进化。当种群需要进行量子门更新时, 依照解码方法按逆顺序将自然数编码种群转换为量子比特种群, 通过

如此转换实现种群的双重进化。

3) 配送中心选择机制。

当量子染色体解码为自然数编码时,由0将配送线路分开,如(0,2,4,1,0,6,3,0,5,0),则第2个和第3个0需要选择最优匹配的配送中心,在此,利用车辆与配送中心匹配矩阵,计算 Δ 值,并根据影响因素的重要性赋予其权重.本文4个因素权重为0.3、0.4、0.2、0.1,由车辆与配送中心匹配算法计算车辆停靠的最佳配送中心。

4) 适应度函数。

由于目标函数是求极小值,设计适应度函数为

$$\text{fitness}(x) = 1/Z(x),$$

其中 $Z(x)$ 是目标函数值,通过转换可得目标函数值越小的个体适应值越大。

5) 选择算子。

计算种群个体的适应值,并在云模型X发生器中生成交叉概率 P_c 和变异概率 P_m ,利用赌盘算子选择概率较大者参与遗传操作,生成下一代。

6) 交叉算子。

根据赌盘算子选择出来的个体,随机选择两个个体A和B,采取双点交叉法进行交叉操作,随机产生两个数 t_1 和 t_2 ($0 < t_1 < t_2 < L + H - 1$, L 为客户数, H 为配送中心数).当A和B中 t_1 和 t_2 的位置对应于0,否则改变 t_1 和 t_2 的值向与0最近的位置移动,将 t_1 和 t_2 的中间子串放到子代的前端,其余部分按原顺序进行重组,按贪婪算法重新放置0的位置。

7) 变异算子。

随机选择一个根据赌盘算子选择出来的个体

A,采取双点交换法进行变异操作,随机产生两个数 r_1 和 r_2 ($0 < r_1 < r_2 < L + H - 1$)选择个体进行变异操作.个体A中 r_1 和 r_2 的位置对应于非0,否则改变 r_1 和 r_2 的值向离非0最近的位置移动,交换 r_1 和 r_2 对应的两个数,生成新个体。

8) 种群扩展机制。

考虑到一般进化算法中只利用当前种群中个体的信息,忽略或破坏上代优秀个体的信息,为此在种群进化过程中增加种群扩张机制,将上代种群中优秀个体不经过遗传操作直接进入下一代(本文取上代种群中10%的优秀个体),新代种群进化操作完成后由选择算子保留与原种群相同数量的个体,如此可以实现优秀个体的最大权限保护,加速算法的全局收敛。

9) 量子门更新算子。

量子门更新算子是量子进化算法中种群进化的关键操作,经由量子门引导旋转实现量子比特位中间状态向其他状态进行变换与转移;因此,量子门更新算子是云量子遗传算法设计的关键.常见量子门有异或门、旋转门和hadamard变换门,本文设计量子门旋转如下:

$$\begin{bmatrix} \alpha_{(m,n)}^{t+1} \\ \beta_{(m,n)}^{t+1} \end{bmatrix} = U(\delta\theta) \begin{bmatrix} \alpha_{(m,n)}^t \\ \beta_{(m,n)}^t \end{bmatrix} = \begin{bmatrix} \cos(\delta\theta) & -\sin(\delta\theta) \\ \sin(\delta\theta) & \cos(\delta\theta) \end{bmatrix} \begin{bmatrix} \alpha_{(m,n)}^t \\ \beta_{(m,n)}^t \end{bmatrix}. \quad (11)$$

其中: δ 的取值与 α 和 β 的取值有关,记 $\delta = s(\alpha, \beta)$ 表示量子门旋转的方向,通过 δ 控制种群由低级向高级进化; θ 表示量子门旋转角,通过 θ 的取值控制种群进化的速度.具体取值可在表2中^[20]查取。

表2 旋转门查找表

$x(m, n)$	$b(m, n)$	$Z(x) < Z(b)$	θ	$s(\alpha, \beta)$			
				$\alpha\beta > 0$	$\alpha\beta < 0$	$\alpha = 0$	$\beta = 0$
0	0	False	0	0	0	0	0
0	0	Ture	0	0	0	0	0
0	1	False	0	0	0	0	0
0	1	Ture	0.005π	-1	1	± 1	0
1	0	False	0.01π	-1	1	± 1	0
1	0	Ture	0.025π	1	-1	0	± 1
1	1	False	0.005π	1	-1	0	± 1
1	1	Ture	0.025π	1	-1	0	± 1

表2中, $x(m, n)$ 为量子比特位中的某一位, $b(m, n)$ 为当前种群中最优个体的染色体中与之对应位置的取值, $Z(x)$ 为目标函数.当 $x(m, n) = 0$, $b(m, n) = 1$,且 $Z(x) < Z(b)$ 时,由于当前值比优秀个体对应的目标值小,应增加当前位置取0的概率以实现向更优目标的转移,即增大 $|\alpha|^2$ 的取值.若 (α, β) 在

一三象限,则按顺时针方向旋转;若 (α, β) 在二四象限,则按逆时针方向旋转。

10) 终止条件。

以种群平均值与最优个体适应值相等为种群收敛的判断条件;同时,设置预定的迭代次数。

11) 转2),直至满足条件(10)。

3.3 算法复杂度分析

由于云量子遗传算法是利用云模型理论和量子理论改进标准遗传算法而设计的,下面对云量子遗传算法的计算时间复杂度进行分析.云量子遗传算法与标准遗传算法相比在染色体编码转换、量子门更新、交叉与变异概率生成、种群扩张4个方面不同,其他操作基本一致.

对于种群规模为 P 、迭代次数为 T 、问题规模为 L 的VRP,迭代一次云量子遗传算法的时间复杂度为:初始化种群 $O(P \times L)$,解码 $O(P \times L)$,适应度计算 $O(P \times L)$,交叉与变异概率 $2 \times O(P)$,选择操作 $O(P^2)$,交叉操作 $O(p_c \times P \times L^2)$,变异操作 $O(p_m \times P \times L)$,种群扩展机制 $O(P + 10\%P)$,最优保留个体 $O(P)$,量子门旋转 $O(P \times L^2)$.则量子遗传算法的时间复杂度为

$$\begin{aligned}
 O(P, T, L) = & T \times 3 \times O(P \times L) + T \times 3 \times O(P^2) + \\
 & T \times O(P^2 \times P_c) + T \times O(p_c \times P \times L^2) + \\
 & T \times O(p_m \times P \times L) + T \times O(P + 10\%P) + \\
 & T \times O(P) + T \times O(P \times L^2) \approx \\
 & T \times O(P \times L^2). \tag{12}
 \end{aligned}$$

由式(12)可知,云量子遗传算法的计算时间复杂度与种群规模和VRP规模有关,在数量级上染色体编码转换、量子门更新、交叉与变异概率生成、种群扩张并没有增加算法的复杂度.因此,云量子遗传算法属于多项式算法,求解耗时与标准遗传算法相当.

4 仿真实验

4.1 数值实验

由于城市多配送中心问题没有标准实例,随机生成的算例缺乏比较,本文以文献[25]中的算例对模型和算法进行验证,具体数据见表3.补充数据:车辆最大载重量为10t,最大行驶距离均为50km,空载时每公里耗油0.2L,满载时每公里耗油0.5L,配送网络中3个配送中心的坐标分别为:配送中心A(9.56 km,

6.03 km)、B(6.44 km,11.28 km)、C(11.14 km, 11.10 km).要求合理安排配送路线以最小的总油耗完成配送任务.

表3 客户需求信息

编号	需求量	横坐标	纵坐标	编号	需求量	横坐标	纵坐标
1	1.8	2.96	13.36	16	0.7	11.92	13.1
2	0.4	19.81	14.38	17	1.8	10.48	10.76
3	2	6.52	18.82	18	2	10	19.27
4	0.5	7.27	5.26	19	0.6	13.6	7.98
5	0.2	14.9	16.45	20	0.2	19.14	8.53
6	0.8	7.04	14.25	21	1.8	11.74	8.43
7	1.5	6.14	5.03	22	1	11.59	2.67
8	1.9	0.62	14.85	23	1.1	18.02	10.56
9	1	14.45	12.08	24	1.6	19.21	12.43
10	1.7	1.29	1.42	25	1.6	11.7	16.9
11	0.8	3.9	9.09	26	1	11.85	19.9
12	1.3	15.1	17.9	27	0.2	12.8	12.18
13	0.9	0.33	11.47	28	0.4	0.51	11.1
14	1.9	12.28	0.34	29	1.3	3.55	8.27
15	1.9	2.33	15.85	30	0.6	17.61	1.01

在文献[25]中,采用扫描法将30个客户分配给3个配送中心,采取分区配送机制,利用禁忌搜索算法对每个单配送中心VRP进行求解,最后结果如表4所示.为了证明本文模型和算法的优势,利用本文的模型和算法对此算例重新求解,具体结果如表4所示.

由表4可见:文献[25]按扫描算法将多配送中心转化为单配送中心,通过对单配送中心VRP的求解实现配送网络的优化方法是一种局部优化,从整体来看并不是全局最优解;并且在文献中,计算结果中还存在错误,对25号客户进行了两次配送,而30号客户却没有进行配送;在C配送中心负责的第1条线路出现了超载现象.而本文打破传统对MDVRP的研究方式,提出网络化联合配送机制,将传统分级分区配送中独立运营的配送中心打破分隔,实现多区域配送资源集成共享,提高了物流资源利用效率.由此可见,无论行车距离还是实载率本文的求解结果均优于文献[25].

表4 计算结果对比分析

算例	配送中心	行车路线	实载率/%	行车距离	总油耗	总里程
本文计算结果	A	A-4-7-10-22-14-30-A	72	37.28	10.52	116.01
	B	B-11-29-28-13-8-15-1-B	90	20.81	6.84	
	C	C-6-3-18-26-12-5-25-C	89	29.57	9.62	
		C-17-21-19-20-23-24-2-9-27-16-C	94	28.35	8.45	
文献[25]结果	A	A-11-3-18-26-5-25-A	76	40.89		177.53
	B	B-9-12-6-15-4-28-B	59	41.14		
		B-29-10-4-1-B	53	23.08		
	C	C-19-14-22-21-8-16-17-25-20-C	115	42.18		
		C-24-27-2-13-23-C	42	31.04		

4.2 算法对比实验

下面将云量子遗传算法与 VRP 求解常用的量子遗传算法、禁忌搜索算法进行对比分析,对文献[25]中的算例,分别采用禁忌搜索算法^[26]、量子遗传算法^[27]和云量子遗传算法进行求解,对比分析其求解效果,各算法收敛结果如图 4 所示。

由图 4 可见,禁忌搜索算法收敛速度最快,云量

子遗传算法由于改进了染色体结构、交叉与变异概率的设置方式、遗传操作以及量子门更新双重进化驱动等方面,提高了算法的收敛速度,结果也明显优越于量子遗传算法。下面从求解最优值、最劣值、平均值、计算时间、搜索成功率等综合指标对算法的稳定性和求解效果进行综合分析,重复计算并统计结果,具体数据如表 5 所示。




图 4 算法收敛图

表 5 综合指标分析

算法	仿真实验结果					
	最优值	最劣值	平均值	计算时间	搜索成功率/%	平均搜索迭代次数
禁忌搜索算法	116.01	343.31	187.34	243	12	24.38
量子遗传算法	116.01	326.48	176.37	216	16	46.23
云自适应遗传算法	116.01	162.38	156.32	168	53	39.54

由表 5 可见,由于问题规模不大,3 种算法均能够搜索到全局最优解,若只从迭代次数来看,禁忌搜索算法显然效果比较好,但其计算时间最长,当问题规模增大时该算法将难以胜任。在最优值、最劣值、平均值、搜索成功率、计算时间与平均迭代次数构成的综合指标方面,云量子遗传算法完全优越于量子遗传算法,这是由于云量子遗传算法是在量子遗传算法的基础上设计了随个体适应度变化的交叉与变异概率,并增加了种群扩张机制。由实验结果可见,云量子遗传算法在求解规模不大的 MDVRP 效果显然优越于禁忌搜索算法与量子遗传算法。

4.3 标准测试实验

为了更进一步对云量子遗传算法的性能进行测试,从 VRP 网站 (<http://neo.lcc.uma.es/radio/WebVRP/>) 下载关于 VRP 的标准算例,车辆参数与实验 4.1 相同。针对不同规模和复杂程度的 VRP,利用 4.2 设计的程

序禁忌搜索算法^[26]、量子遗传算法^[27]和云量子遗传算法对问题进行分别求解,分别统计最优解、平均值、误差,具体数据如表 6 所示。云量子遗传算法求解结果如图 5 所示。由表 6 可见,当算例规模较小、复杂度不高时,3 种算法均能取得最优解,但随着实验算例规模的增大,禁忌搜索算法的求解质量开始急剧下降,当算例复杂度增大时,量子遗传算法的求解质量也明显下降,而云量子遗传算法对 VRP 规模增大、复杂度提高的变化不大明显。由图 5 的结果可见,云量子遗传算法搜索的结果与标准答案相差无几。因此,可以得出结论:云量子遗传算法能够较好地胜任求解较大规模复杂的组合优化问题。

经过上述实验分析可以得出结论:本文设计的云量子遗传算法在求解效率和搜索质量上明显优于其他智能算法,能够很好保证城市多区域联合配送模型的求解需求。

表 6 测试数据统计结果

实例	已知最优解	量子遗传算法			禁忌搜索算法			云自适应遗传算法		
		最优值	平均值	误差/%	最优值	平均值	误差/%	最优值	平均值	误差/%
M-n33-k3	458	458	468	0.00	458	466	0.00	458	462	0.00
M-n46-k4	736	864	897	17.39	786	878	6.79	748	756	1.63
M-n35-k6	863	934	1048	8.23	912	998	5.68	868	884	0.58
M-n65-k6	972	1275	1384	31.17	1245	1342	28.09	996	1036	2.47
M-n21-k8	367	462	478	25.89	456	486	24.25	369	375	0.54

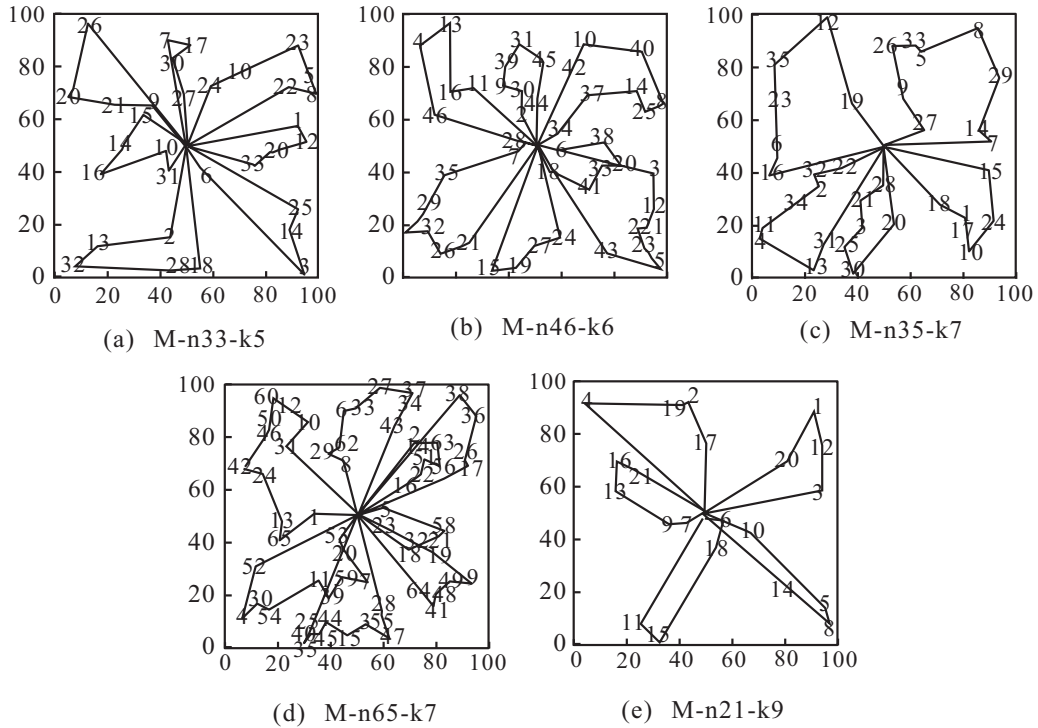


图5 标准算例最优解路径

5 结 论

本文针对城市多区域联合配送问题展开研究,改进传统采取分区式配送机制下配送资源难以集成与共享的方法,提出“多对多”的网络化联合配送机制.在综合考虑配送中心繁忙程度、货物保有量、距离和车载率等因素的基础上,设计了车辆与配送中心的匹配矩阵,从全局角度对物流资源进行优化配置.以运输距离、实载率等与配送成本密切相关的油耗成本为优化目标,建立面向城市多区域配送需求的联合配送模型;同时,采用量子比特位设计遗传算法染色体结构,利用云模型改进交叉与变异概率的设置方式,设计云量子遗传算法对城市多区域联合配送模型进行求解.为了增强算法的收敛速度,采取量子门旋转与遗传进化双重驱动进化方式,并设计种群扩张机制增加对往代种群优秀个体信息的利用.最后,通过3个算例对模型和算法进行了实验分析,从不同方面对算法进行检验,结果表明本文建立的模型和所设计的算法取得了较好的效果.

由于篇幅和精力原因,本文只对静态的城市多区域配送问题进行了研究,没有考虑交通网络的时变性及客户需求的动态性,这些实际问题是城市多区域配送问题不可忽视也难以回避的现实,下一步的研究将继续关注这两方面.

参考文献(References)

[1] Dantzig G B, Ramser J H. The truck dispatching problem[J]. Management Science, 1959, 4(6): 80-91.

[2] Andrea B, Alberto C, Giovanni R. A branch-and-cut-and-price algorithm for the multi-depot heterogeneous vehicle routing problem with time windows[J]. Transportation Research, 2011, 1(9): 723-740.

[3] Dondo R, Cerdá J. A hybrid local improvement algorithm for large-scale multi-depot vehicle routing problems with time windows[J]. Computers Chemical Engineering, 2009, 33(2): 513-530.

[4] Rahimi V A, Crainic T G, Gendreau M, et al. A path relinking algorithm for a multi-depot periodic vehicle routing problem[J]. J of Herustics, 2013, 19(3): 497-524.

[5] Poggi A M, Uchoa E. A robust branch-and-cut-and-price algorithm for the heterogeneous fleet vehicle routing problem[J]. Networks, 2009, 54(4): 167-177.

[6] Seixas M P, Mendes A B. Column generation for a multitrip vehicle routing problem with time windows, driver work hours, and heterogeneous fleet[J]. Mathematical Problems in Engineering, 2013, 55(10): 49-61.

[7] 王晓博, 李一军. 多车场多车型装卸混合车辆路径问题研究[J]. 控制与决策, 2009, 24(12): 1769-1774. (Wang X B, Li Y J. Study on multi-depot and multi-type vehicles vehicle routing problem with backhauls[J]. Control and Decision, 2009, 24(12): 1769-1774.)

[8] Liu T T, Jiang Z B. A review of the multi-depot vehicle routing problem[J]. Energy Procedia, 2011, 11(13): 3381-3389.

[9] Bettinelli A, Ceselli A, Righini G. A branch-and-cut-and-price algorithm for the multi-depot heterogeneous vehicle routing problem with time windows[J]. Transportation

- Research Part C-Emerging Technologies, 2010, 19(5): 723-740.
- [10] Righini G, Salani M. New dynamic programming algorithms for the resource constrained elementary shortest path problem[J]. Networks, 2008, 3(51): 155-170.
- [11] Necati A, Deniz A, Mehmet T T. Selective multi-depot vehicle routing problem with pricing[J]. Transportation Research, 2011, 15(19): 866-884.
- [12] Poggi A M, Uchoa E. A robust branch-and-cut-and-price algorithm for the heterogeneous fleet vehicle routing problem[J]. Networks, 2009, 54(4): 167-177.
- [13] 李坤, 唐立新, 陈数发. 多集装箱堆场空间分配与车辆调度集成问题的建模与优化[J]. 系统工程理论与实践, 2014, 29(1): 115-121.
(Li K, Tang L X, Chen S F. Modeling and optimizing for the integrated problem with container storage allocation and truck scheduling[J]. Systems Engineering & Theory - Practice, 2014, 29(1): 115-121.)
- [14] 许维胜, 曾正洋, 徐志宇. 一种求解两级车辆路径问题的 Memetic 算法[J]. 控制与决策, 2013, 28(10): 1587-1590.
(Xu W S, Zeng Z Y, Xu Z Y. A Memetic algorithm for solving two-echelon vehicle routing problem[J]. Control and Decision, 2013, 28(10): 1587-1590.)
- [15] 张军, 唐加福, 潘震东, 等. 分散搜索算法求解带货物权重的车辆路径问题[J]. 系统工程学报, 2010, 25(1): 91-97.
(Zhang J, Tang J F, Pan Z D, et al. Scatter search algorithm for solving weighted vehicle routing problem[J]. J of Systems Engineering, 2010, 25(1): 91-97.)
- [16] 马华伟, 靳鹏, 杨善林. 时变车辆路径问题的启发式算法[J]. 系统工程学报, 2012, 27(2): 256-263.
(Ma H W, Jin P, Yang S L. Heuristic methods for time-dependent vehicle routing problem[J]. J of Systems Engineering, 2012, 27(2): 256-263.)
- [17] Narayanan A, Moore M. Quantum-inspired genetic algorithms[C]. IEEE Int Conf on Evolutionary Computation. Piscataway NJ: IEEE Press, 1996: 61-66.
- [18] Zhao S F, Xua G H, Tao T F, et al. Real-coded chaotic quantum-inspired genetic algorithm for training of fuzzy neural networks[J]. Computers and Mathematics with Applications, 2009, 57: 2009-2015.
- [19] Wang L X, Kowk S K, Ip W H. Design of an improved quantum-inspired evolutionary algorithm for a transportation problem in logistics systems[J]. J of Intelligent Manufacturing, 2012, 23(6): 2227-2236.
- [20] Wang L, Li L P. An effective hybrid quantum-inspired evolutionary algorithm for parameter estimation of chaotic systems[J]. Expert Systems with Applications, 2010, 37(2): 1279-1285.
- [21] 钱洁, 郑建国, 张超群, 等. 量子进化算法研究现状综述[J]. 控制与决策, 2011, 26(3): 321-328.
(Qian J, Zheng J G, Zhang C Q, et al. Reviews of current studying progress on quantum evolutionary computation[J]. Control and Decision, 2011, 26(3): 321-328.)
- [22] 葛显龙, 王旭. 动态需求的多车型车辆调度问题及云遗传算法[J]. 系统工程学报, 2012, 27(6): 823-832.
(Ge X L, Wang X. Multi-vehicle scheduling problems and cloud GA based on the dynamic needs[J]. J of Systems Engineering, 2012, 27(6): 823-832.)
- [23] 葛显龙. 面向云配送模式的车辆调度问题及算法研究[D]. 重庆: 重庆大学机械工程学院, 2011.
(Ge X L. Study on vehicle scheduling problems and algorithms based on cloud distribution model[D]. Chongqing: Chongqing University, School Of Mechanical Engineering, 2011.)
- [24] 李德毅. 不确定性人工智能[M]. 北京: 国防工业出版社, 2005: 137-156.
(Li D Y. Artificial intelligence with uncertainty[M]. Beijing: National Defense Industry Press, 2005: 137-156.)
- [25] 郎茂祥. 多配送中心车辆调度问题的模型与算法研究[J]. 交通运输系统工程与信息, 2006, 6(5): 65-86.
(Lang M X. Study on the model and algorithm for multi-depot vehicle scheduling problem[J]. J of Transportation Systems Engineering and Information Technology, 2006, 6(5): 65-86.)
- [26] 邢文训, 谢金星. 现代优化计算方法[M]. 北京: 清华大学出版社, 2009: 51-57.
(Xing W X, Xie J X. Modern optimization calculation method[M]. Beijing: Tsinghua University Press, 2009: 51-57.)
- [27] 王凌, 吴昊, 唐芳, 等. 混合量子遗传算法及其性能分析[J]. 控制与决策, 2005, 20(2): 156-162.
(Wang L, Wu H, Tang F, et al. Hybrid quantum genetic algorithms and performance analysis[J]. Control and Decision, 2005, 20(2): 156-162.)

(责任编辑: 孙艺红)