

考虑动态客户需求的物资配送问题求解方法

张玉州, 张子为

(安庆师范大学计算机与信息学院, 246133, 安徽安庆)

摘要: 为明确需求预测方向和减少预测偏差,提出了一种考虑动态客户需求的物资配送问题求解方法。依据客户历史需求,以泊松分布模拟需求变化情况,建立需求预测模型,得到客户初始预测需求,并在此基础上建立了需求不确定的物资配送模型。为求解该模型,设计了一种预测需求可调节的遗传算法。在遗传算法局部搜索阶段,提出了需求调节算子。该算子以一定概率对客户初始预测需求进行调节,以符合泊松分布的需求变化量减少预测需求,同时对车辆间的顾客进行调整,顾客以调节后的预测需求挑选最小需求客户,移动该客户至其他最低载货车辆中并调整该车辆服务的顾客顺序,整个调节过程以最低配送成本为标准,保留最优配送路径。从标准车辆路径问题测试数据库中挑选10个典型样例进行测试,结果表明,与经典的最近邻算法和遗传算法对比,所提算法在所有算例中均取得了总成本最小值,在90%的算例中取得了运输成本最小值,在70%的算例中取得了车辆成本最小值。

关键词: 动态客户需求;车辆路径问题;遗传算法;需求调节算子

中图分类号: TP301 **文献标志码:** A

DOI: 10.7652/xjtuxb202008016 **文章编号:** 0253-987X(2020)08-0124-08



OSID 码

A Strategy for Solving Material Distribution Considering Dynamic Customer Demand

ZHANG Yuzhou, ZHANG Ziwei

(School of Computer and Information, Anqing Normal University, Anqing, Anhui 246133, China)

Abstract: To clarify the direction of demand forecast and reduce the forecast deviation, a strategy considering dynamic customer demand is proposed for material distribution. Following the historical demand of the customers, a Poisson distribution is used to simulate the changes in demand, and a demand forecasting model is established to obtain the initial forecasted demand for the customers. Then a material distribution model with uncertain demand is constructed. To solve the distribution model, a genetic algorithm with adjustable forecasting demand (GAAFD) is designed. In the local search stage of GAAFD, a demand adjustment operator is introduced. This operator adjusts the initial forecasted demand with a certain probability to obey Poisson distribution of the demand changes so that the forecasted demand can be reduced, and it simultaneously adjusts the customers between vehicles. The customers are moved to the other lowest cargo vehicle and sequenced for the vehicle service. The lowest delivery cost is treated as the purpose and the optimal delivery routes are saved. To verify the proposed GAAFD, ten typical test instances are selected from the benchmark test database of the vehicle routing

problem, and compared with the representative algorithms, i. e. the classic nearest neighbor algorithm and genetic algorithm without the adjusting operator. The results show that for the ten test instances, GAAFD reaches the minimum total cost obtained in all instances, and in 90% of the instances the minimum transportation cost is achieved, in 70% of the instances the minimum vehicle cost is achieved.

Keywords: dynamic customer demand; vehicle routing problem; genetic algorithm; demand adjustment operator

随着科技发展,网络已经介入人们生活的方方面面,从计划经济时代的凭票实地购买到现在的网络移动支付,购物方式越来越便捷,对商品的需求量也不断增加,商品的配送模式也更加注重时效与经济效益,然而现实生活中,存在很多不确定因素影响商品的配送成本,从而影响经济效益。针对此问题,国内外很多学者对动态车辆路径问题(DVRP)^[1]进行研究,考虑多种动态因素,对DVRP做出了不同的定义^[2]。

从不同的研究角度来看,对需求不确定的动态车辆路径问题,Pillac等提出一个事件驱动的框架灵活适应需求的随机变动^[3]。若产生新客户,需求也同样发生变化,考虑新增客户需求产生的影响,Armas等用可变领域搜索的元启发式算法来重新优化路线解决这一特定问题^[4],这项工作中开发的软件也运用到实际车队的管理系统中。对客户不确定的动态车辆路径问题,Azi等按客户请求发生变动的情况提出自适应大领域搜索启发式算法进行求解^[5]。Abdallah等用改进的遗传算法来解决该问题,结果比基于时间和加权适合度评估方法的效果要好^[6]。胡乔宇等设计了一种基于蒙特卡洛仿真的高效优化方法解决多级随机客户的车辆路径问题^[7]。对时间信息不确定的动态车辆路径问题,Kuo等以最大化服务客户数量和最小化客户的等待时间为目标,提出一种改进的模糊蚁群算法来求解^[8]。出现实时服务的请求情况时,Haghani等用遗传算法来解决,将时间信息的不确定性按不同程度比较静态和动态路由策略,在实时服务请求问题场景下动态路由策略更优^[9]。段征宇等利用非支配排序蚁群算法求解随机时变车辆路径问题^[10]。

从不同的求解方法来看,解决该问题不仅要确定动态信息的更新方式还要研究其路径的优化方法。文献[11-12]研究动态需求的车辆路径问题时规定一定时间间隔后进行信息更新。饶卫振等提出在动态事件出现时进行信息更新,再逐步改进线路^[13-14]。优化路径的算法多样,大多学者采用启发

式算法求解,如禁忌搜索算法、领域搜索算法、遗传算法等^[15-18]。

综上,DVRP的动态信息主要表现在需求的变化、客户实时请求的增加和时间信息不确定等方面,存在两点不足:①预测对象单一,不仅可以对数据进行预测,在统计技术与大数据分析被应用到DVRP问题的背景下,还可以对某一事件进行预测。如日常生活中出现一些特殊情况,就日常生活用品而言,雨天会增加人们对雨伞的需求量,雨伞需求量的变动就存在一定的规律。这一类物资常采用及时配送的形式,品种多样但数量有限,如果按平时的需求配货可能不满足人们的需求,面对物品的需求量增多或减少的情况会产生更多的成本,可以通过对这一事件的预测来调整配送需求量。②在现有研究的求解过程中,往往根据数据等信息的变动情况来预测未来,然而在这一阶段,预测会产生偏差,对减少这种预测产生偏差的影响研究较少。

本文针对这两种情况,以泊松分布模拟需求变化情况对需求进行预测,并在局部搜索中加入新的算子减少这种预测偏差产生的影响,设计了一种预测需求可调节的遗传算法(GAAFD)来求解本文预测型物资配送模型。基于VRP国际标准数据集集中的算例进行实验,对比其他算法,本文算法在求解需求变动下的路径优化问题具有良好的求解性能。

1 问题描述及模型建立

1.1 问题描述

本文求解需求不确定的动态车辆路径问题,以单仓库的物资配送为背景进行问题描述:区域内有一个仓库,配有最大载质量为 C 的 K 辆车,车辆从仓库出发,对 n 个客户进行物资配送,并返回仓库。求在满足车载量的约束条件下,完成物资配送的车辆调度方案,包括每辆车的客户服务顺序和总使用的车辆数,目标是在此过程中总的配送成本最小。

1.2 泊松分布需求预测模型

实际配送中,客户需求具有不确定性,车辆在派

出之前不可预知即将配送客户的需求量,因此要建立需求预测模型。本文建立的预测模型有一定的应用范围,是因为VRP问题本身存在车载容量约束,适用于需求的变动有一定的规律且需求变化量较小的情况,这样在满足约束的条件下,使预测有意义也减少了总成本。在实际交通流中,车辆到达数据、客户到达时间常表示为服从泊松分布^[19-20],泊松分布也对仓库配件等的预测起到一定作用^[21]。

本文将泊松分布应用到物资配送问题中,并将客户需求变化量记为 ΔD 。假设已知的客户需求变化情况符合泊松分布,在单位时间内,所有客户的需求变化可看作是离散稀有事件,其概率满足泊松分布,表达式为

$$P(X=k) = P(k;\lambda) = \frac{\lambda^k}{k!} e^{-\lambda}, k \in \{0,1,2,\dots\} \quad (1)$$

式中: X 表示随机事件; k 表示随机事件发生的次数; λ 为泊松分布参数。

需求变化量 ΔD 可表示为 $t_i \sim t_{i+1}$ 之间客户需求量变化发生的概率与横坐标所组成的面积,表达式为

$$\Delta D = \int_{t_i}^{t_{i+1}} P(x,\lambda) dx \quad (2)$$

物资配送问题中的需求预测模型,一般基于之前单位时间内的历史数据统计,得到历史需求量记为 O 。以 O 为基础对需求进行预测,需求不断变化的同时,对车辆的客户服务顺序进行调整,使配送成本最小,此时预测需求记为 F ,表达式为

$$F = O + \Delta D \quad (3)$$

1.3 需求不确定的物资配送模型

1.3.1 约束条件 客户需求不确定的物资配送模型更加贴合实际生活,为了将实际中该问题抽象为数学模型,需满足如下约束。

(1)模型只有一个仓库,所有的车辆均从仓库出发完成配送后回到仓库。

(2)配送车辆为同一型号,最大车载量不能超过车容量。

(3)客户需求量不确定,配送之前具体需求量未知,且客户需求量不能超过车容量。

(4)客户与仓库位置是确定的,且各节点之间的距离已知。

(5)所有客户都要被配送车辆服务且只能被服务一次。

1.3.2 数学模型 本文数学模型参数定义为: F 。

为配送车辆单位距离的运输成本; F_k 为第 k 辆配送车辆的固定成本; C 为配送车辆的最大载质量; d_{ij} 表示客户 i 与客户 j 之间的距离; D 为客户 i 的实际需求量; c_{ij}^k 为车辆 k 从客户 i 到客户 j 的载货量; X_{ij}^k 为车辆 k 从节点 i 行驶到节点 j 为1,否则为0,其中 $i \neq j$; Y_{ik} 为客户 i 由车辆 k 配送为1,否则为0。得到的数学模型如下。

目标函数

$$\min Z = \sum_{k=1}^K \sum_{i=0}^n \sum_{j=0}^n d_{ij} X_{ij}^k F_s + \sum_{k=1}^K F_k \quad (4)$$

$$\text{s. t. } \sum_{k=1}^K Y_{ik} = 1, \forall i \quad (5)$$

$$\sum_{i=1}^n D Y_{ik} \leq C \quad (6)$$

$$\sum_{i=1}^n X_{ij}^k = Y_{jk}, \forall j, k \quad (7)$$

$$\sum_j X_{ij}^k = Y_{ik}, \forall i, k \quad (8)$$

$$\sum_{i=0}^n X_{ij}^k (c_{ij}^k - D) \geq 0, \forall j, k \quad (9)$$

$$\sum_{j \in U} X_{0j}^k = 1, \forall k \in K \quad (10)$$

$$\sum_{i \in U} X_{i0}^k = 1, \forall k \in K \quad (11)$$

式(4)为目标函数,表示配送过程中的成本最小,包括车辆的固定成本和运输成本;式(5)表示每个客户都能被配送车辆服务;式(6)表示车子的装载量不能超过其最大载质量;式(7)(8)保证每个客户有且只有一辆车对其进行服务;式(9)表示车辆对客户进行服务时,不存在给客户配送一部分物资的情况,在对任一客户进行配送之前,车子有足够的物资提供给这个客户;式(10)(11)表示每辆车从仓库出发,完成配送后回到仓库。

2 预测需求可调节的遗传算法

2.1 算法流程

在配送物资过程中,实际的需求在车辆没有到达客户时是不确定的。仿真实际生活,面对需求未知且必须要配送的情况,一般都采用依据历史需求来安排服务客户的顺序,而这样的处理方式并不能保证成本最小化、利益最大化的要求。因为车辆有最大载质量,若发生特殊情况,历史需求与实际需求相差比较大时,会产生车辆剩余的载货量过多或规定客户服务不完两种情况。前者没有发挥车辆的最大效能,造成车辆配送时固定发车成本的增加;后者会导致原先规划好的服务顺序出现偏差,增派车辆

进行配送的同时直接增加了车辆总行驶距离。

对这类动态问题,本文求解的基本思路是:对历史数据进行处理,根据可能发生的情况判断需求的变化趋势,基于历史需求进行预测得到预测需求,转换为特殊情况下的静态问题求解,即路径优化以预测需求为初始值,这时需求经过第 1 次变化。在局部搜索阶段,加入新的调节算子减少这种预测偏差产生的影响,进行需求的第 2 次变化,同时进行车辆间的顾客调整,寻求最优解。具体步骤如下。

- (1)依据式(3)得出预测需求 F ,作为初始值。
- (2)设置遗传算法参数,初始化种群。
- (3)设初始代数为 1,计算初始种群中染色体的适应度。

(4)根据适应度选择父代个体,再依据一定概率进行交叉操作和局部搜索操作,生成新一代种群且保留最优个体,子代代替父代,直到初始化代数满足迭代次数为止,并得到最终的配送路径。

2.2 需求调节算子

本文前期对历史需求做出预测,考虑预测需求产生的需求变动可能不发生或反向发生的情况,在局部搜索阶段,采用需求调节算子(DAO)减少这种预测偏差产生的影响。在一次调整中,按照一定概率执行 DAO 改变任一客户的需求量,再以一定概率随机选取当前解中的任意一辆车,将其需求量最小的客户插入其他车辆中,重新对客户量发生变化的这两辆车进行优化。这里采用 Swap 交换算子进行优化,优化结束计算当前解,与原解相比较,若当前解更优则保留,同时替换原解。一次调节结束后,需求还原为初始值,再进行下一次调节。如图 1 所示,具体步骤如下。

步骤 1 当前进行局部搜索操作的染色体为 I ,假设需要 3 辆车进行服务,每辆车服务的客户集合分别为 I_1 、 I_2 和 I_3 。若当前概率 $p_{\text{tem}} < 0.5 p_m$, p_m 设置为变异概率,则进行步骤 2,否则进行步骤 3。

步骤 2 随机选取 I 中任意一个客户 i ,需求量为 F 。由 1.2 节可知,需求变化量 $\Delta D'$ 符合泊松分布,求得 $F' = F - \Delta D'$,此时客户 i 的需求量为 F' 。

步骤 3 随机选择一个客户集合,假设为 $I_2 = \{4, 5, 6, 7\}$,其中需求点最小的是客户 5。计算剩余两辆车的载货量,选择载货量少的一辆车,判断加入客户 5 之后载货量是否超过车子最大载重量,若超过,结束当前操作;若不超过,则进入步骤 4。

步骤 4 采用 Swap 交换算子将客户 5 插入 I_2 最优位置,计算调整后的染色体 I' 的解,并与原解比较,

若优于原解则替换,否则不产生变动。

步骤 5 需求调节完成之后,客户 i 的需求还原为 F ,整个算子结束。




图 1 需求调节算子过程

2.3 基本遗传算法

2.3.1 染色体编码 从产生初始解到得出最优解的过程中,每条染色体就是问题的一个完整解,代表一定约束条件下客户的服务顺序。为了简单直观地表示出这样一条路径,对每一个客户进行编号,所有客户随机排序,生成一条完整的数字序列且不能重复,完成染色体的编码。以车子的最大载货量为约束条件,可以得到每辆车所负责的客户及其配送顺序,即染色体解释为完整路径的过程。

2.3.2 初始化种群和适应度函数的计算 本文初始化种群是随机排列生成多条染色体,在小规模的车辆路径问题中,初始解可能会遍布整个解空间,这样遗传算法陷入局部最优的概率会降低。初始解的质量影响算法的收敛性,但对最优解影响很小。生成初始种群后,计算每一条染色体适应度,配送总成本是衡量适应度的标准,总成本越低则适应度越高。

2.3.3 选择算子与交叉算子 依据适应度值,采用轮盘赌法作为选择父代个体的方式,个体被选中的概率与其适应度成正比。对选中个体进行最优保留策略,按交叉概率采用本文设计的交叉方法进行重组,由于交叉算子是完全随机的,所以存在父代个体相同父代个体相同位置互换生成相同个体的情况,具体步骤如图 2 所示。

步骤 1 在两个父代染色体 A、B 中取同一位置的基因片段,得到片段 A1 和 B1。

步骤 2 以所选基因片段为分割段,把整条染色体分成 3 段,若所选基因片段在首或尾部,则将其中一段看成空集,但存放位置不受影响。把父代 A 中基因片段 A1 移到末尾,原先末尾段移至中间位;把父

代 B 中基因片段 B1 移至中间位,原先末尾段移至首位。

步骤 3 删除换位后的父代 A、B 中与所选基因片段 B1、A1 重复的基因。

步骤 4 将 A1、B1 插入已删除部分基因的父代 B、A 中。此时,B1 移至中间位,已删除的父代 A 按一定长度分割,分别移至首尾位;A1 移至首位,已删除的父代 B 按一定长度分割,分别移至中间位与尾位,完成交叉操作。这样不断地换位设计,能保证相同的父代也能产生不同的子代,增加了种群的多样性,种群解空间覆盖的范围更大。




图 2 交叉算子示意图

2.3.4 局部搜索算子 本文在局部搜索中加入需求调节算子之前,使用了 3 个传统的局部搜索算子。

单点插入(SI)算子:考虑解是闭合曲线,将当前单个基因从原序列中提取出来,插入任意两个基因之间,遍历所有可插入的位置,比较解的优劣,用优质解替换原解。

双点插入(DI)算子:考虑解是闭合曲线,将当前两个连续基因从原序列中提取出来,插入任意两个基因之间,遍历所有可插入的位置,比较解的优劣,用优质解替换原解。

Swap 交换算子:将每个基因与其他基因交换位置,比较解的优劣,用优质解替换原解。

3 实验仿真

3.1 实验设计

DVRP 没有公开的标准测试案例库,现有文献大都是随机生成客户坐标与需求等基本数据,作为仿真算例或改造 Solomon 标准测试算例。本文以 VRP 国际标准数据集^[22]中的算例为基础数据,包括 32~80 之间 10 个不同规模客户的坐标与需求、车辆数和最大车载量等数据,这里将基础数据中的客户需求看成客户的历史需求。为验证本文提出算法与模型的有效性,所有算法均采用 Matlab 进行实验,其中对遗传算法的相关参数设置如下:种群规模为 50,最大迭代次数为 100,交叉概率为 0.8,变异概率为 0.2,泊松分布参数 λ 为 2,实验次数为 30

次,实验结果取其平均值。

3.2 实验结果与分析

3.2.1 多算例实验结果比较 最近邻算法(NN)是以距离作为选择客户的标准,车辆在当前位置选择距离最近的客户进行配送,直到满足容量约束。改进遗传算法 GA1 是将遗传算法中传统的变异算子改进为局部搜索算子进行实验,相比本文算法缺少需求调节算子,并且 GA1 算法与 NN 算法都缺少需求预测,均以历史需求来规划配送路线,当车辆到达客户处后,再以实际的客户需求进行配送,导致所用总成本较高。本文算法添加了需求预测模型,针对需求的变化情况在局部搜索阶段提出了一个需求调节算子。在历史需求的基础上预测生成需求,并以一定概率对预测需求进行调节,产生完整的配送路线,车辆按此路线以客户的实际需求对客户进行配送,完成配送所用总成本较低。

本文算法 GAAFD、最近邻算法 NN 和改进遗传算法 GA1 实验结果如表 1 所示,文中实验结果均为模拟值,表中加粗数据是 3 个对比项中的最小值。由于本文目标是成本最小化,所以数值越小结果就越好,可以看出本文算法 10 个算例的总成本都是最小值;90%的运输成本为最小值;70%的车辆成本也是最小值。对于车辆成本来说,3 种算法所用车辆数相差不大,同时存在并列最小的情况,是因为车子有容量限制,服务完所有客户,车辆数不会相差太多。

为了更直观地对比 3 种算法总成本,图 3 所示为 3 种算法 10 个算例的总成本趋势图,数字 1 到 10 分别代表算例 A1-n32-k5 到 A10-n80-k10。从中可以看出,GAAFD 算法与 GA1 算法的结果相近,而与 NN 算法相差较多,说明遗传算法有一定的寻优能力,其搜索范围与最近邻算法相比较大。相同遗传算法之间比较,GAAFD 算法加上需求预测模型后,结果更好一些。




图 3 3 种算法实验结果折线图

表 1 3 种算法下多测试算例重复 30 次的实验结果

算例名称	NN 算法			GA1 算法			GAAFD 算法		
	总成本	运输成本	车辆成本	总成本	运输成本	车辆成本	总成本	运输成本	车辆成本
A1-n32-k5	1 878. 87	1 378. 87	500. 00	1 812. 74	1 239. 41	573. 33	1 731. 28	1 174. 61	556. 67
A2-n36-k5	2 582. 86	1 982. 86	600. 00	1 884. 23	1 284. 23	600. 00	1 823. 83	1 223. 83	600. 00
A3-n39-k5	2 309. 23	1 709. 23	600. 00	1 996. 27	1 382. 94	613. 33	1 867. 35	1 267. 35	600. 00
A4-n45-k6	3 161. 91	2 361. 91	800. 00	2 415. 11	1 628. 44	786. 67	2 397. 33	1 640. 66	756. 67
A5-n48-k7	3 358. 22	2 458. 22	900. 00	2 705. 61	1 895. 61	810. 00	2 574. 03	1 764. 03	810. 00
A6-n53-k7	3 253. 01	2 353. 01	900. 00	2 760. 17	1 870. 17	890. 00	2 691. 27	1 817. 94	873. 33
A7-n60-k9	3 985. 44	2 885. 44	1 100. 00	3 630. 96	2 537. 63	1 093. 33	3 606. 98	2 523. 65	1 083. 33
A8-n64-k9	4 150. 09	3 050. 09	1 100. 00	3 745. 86	2 585. 86	1 160. 00	3 708. 58	2 571. 91	1 136. 67
A9-n69-k9	4 240. 57	3 140. 57	1 100. 00	3 365. 66	2 258. 99	1 106. 67	3 299. 34	2 196. 01	1 103. 33
A10-n80-k10	5 367. 29	4 067. 29	1 300. 00	4 639. 21	3 392. 54	1 246. 67	4 554. 47	3 327. 80	1 226. 67

分析 GAAFD 算法的优势可以知道,GA1 算法没有考虑需求可能发生变化,仅仅以历史需求为依据进行求解。生活中客户的需求受多种因素的影响,在显性条件下,需求的动态变化有相应的趋势,GAAFD 算法使用泊松分布模拟需求变化,对需求可能发生的变化进行预估,达到接近实际需求的效果。这不仅能最大可能实现车辆的满载,也在一定程度上拓宽了需求的可变范围,与前者相比,预测模型的优化了行驶路线,预测的性能展现了一定的优势。

3.2.2 单算例实验结果比较 GAAFD 算法建立预测模型使需求具有一定的可变范围,求出的最终总成本也同样会在一定范围内,为了更加清晰地表示单个算例 30 次的实验结果,这里以 100 为总成本的单个范围长度差对算例 30 次实验结果进行统计。以算例 A5-n48-k7 为例,展示基本实验数据与统计后的实验结果。

表 2 所示为 47 个客户和 1 个仓库的地理坐标及需求量数据,其中 N 为客户与仓库的序号,1~47 为客户序号,48 为仓库序号, X 、 Y 为横、纵坐标, O 为历史需求量, F 为预测需求量, D 为实际需求量。

表 3 显示了以 GA1 算法和 GAAFD 算法运行 30 次的 A5-n48-k7 算例的统计结果。可以看出:在 30 次实验的结果分布中,GAAFD 算法有 73% 的解都处于较优解 2 400~2 600 之间,而 GA1 仅为 27%,说明 GAAFD 算法的大部分解都优于 GA1 算法;对比较差解的占比情况,总成本超过 2 700 小于 2 800,GAAFD 算法占比 16%,GA1 算法占比 40%;当总成本超过 2 800 时解的质量差,GAAFD 算法仅占 3%,而 GA1 算法占比 23%。通过 30 次实验计算,得出 GAAFD 算法的最小值与平均值分

表 2 算例 A5-n48-k7 的地理坐标、需求量数据

N	X	Y	O	F	D	N	X	Y	O	F	D
1	1	19	20	24	21	25	3	63	16	16	16
2	97	35	14	17	16	26	47	95	12	12	13
3	23	79	5	7	10	27	53	75	15	16	16
4	77	87	11	12	12	28	73	55	9	9	11
5	3	9	22	25	26	29	81	71	2	6	5
6	5	27	25	28	25	30	89	75	10	11	14
7	41	53	2	3	4	31	11	9	2	2	4
8	51	87	18	21	20	32	27	37	3	3	6
9	67	73	10	11	12	33	95	59	20	21	22
10	89	45	26	27	30	34	63	63	3	3	4
11	71	99	14	16	16	35	37	21	13	17	17
12	11	1	22	24	25	36	33	47	25	27	25
13	85	85	9	10	11	37	23	63	23	26	26
14	57	11	11	13	15	38	13	55	8	9	11
15	57	85	18	18	23	39	47	93	16	16	19
16	71	33	24	25	27	40	45	43	9	10	11
17	61	13	15	20	15	41	83	7	14	15	16
18	39	15	23	29	24	42	69	91	4	6	5
19	13	59	16	17	18	43	13	11	13	16	13
20	43	99	14	15	16	44	37	15	7	13	8
21	87	73	8	9	13	45	53	59	16	18	16
22	11	37	5	7	6	46	97	83	18	23	20
23	21	11	12	14	14	47	75	31	16	16	17
24	77	81	8	11	11	48	47	5			

别为 2 413. 05 和 2 574. 03,GA1 算法的两个值分别为 2 423. 51 和 2 705. 61。结合以上结论,这组实验验证了 GAAFD 算法的合理性,以及在求得最优解

的有效性。

表3 算例 A5-n48-k7 的实验结果统计

总成本	运行次数	
	GA1 算法	GAAFD 算法
2 400~2 500	4	8
2 500~2 600	4	14
2 600~2 700	3	2
2 700~2 800	12	5
2 800 以上	7	1

3.2.3 需求调节算子性能分析 本文在局部搜索阶段提出 DAO 算子,为分析算子性能,将去掉 DAO 算子的 GAAFD 算法记为 GA2。以表 1 中不同规模的 4 个算例为实验对象,采用 GAAFD 算法与 GA2 算法进行实验,结果取 30 次实验的平均值见表 4,表中数据越小代表结果越好。两种算法都是基于历史需求 O 得到预测需求 F ,进行路径规划,最后以实际需求进行配送计算总成本。两者之间不同之处为 GA2 算法缺少局部搜索过程中对需求的调节,即 DAO 算子。

表4 4 个算例重复 30 次的实验结果

算法	总成本			
	A2-n36-k5	A5-n48-k7	A6-n53-k7	A9-n69-k9
GA2	1 861.32	2 653.20	2 745.33	3 362.19
GAAFD	1 823.83	2 574.03	2 691.27	3 299.34

所选算例的客户规模各不相同,GAAFD 算法的结果均优于 GA2 算法。由此可见,DAO 算子在需求调节方面起到了作用,通过实现需求动态变化重新调整客户的配送顺序,一定程度上增大了解的搜索范围,同时减少了前期预测偏差产生的影响。

4 结束语

本文考虑动态需求要素建立预测型物资配送模型,基于历史需求,用泊松分布对需求的变化情况进行预测,并以预测需求对路径进行规划。设计的 GAAFD 算法符合特殊情况下需求变化的规律,加入需求调节算子,针对性地对前期预测可能产生的影响做出了一定程度的优化。实验阶段采用国际标准数据集中 10 个不同规模的算例进行实验,对比最近邻算法和改进遗传算法,本文算法实验结果占优,能有效降低总成本。对需求调节算子进行分析,证明提出的算子对降低总成本起到了一定作用。

由于预测基于历史数据,中长期内具有良好的

预测效果,而短期则难以精准预测,如何取得短期内的预测效果,是我们下一步思考的方向。如通过设定虚拟需求客户,将问题设计的区域按新需求出现的概率进行划分,设置车辆运行的数量,增加高概率区域对应车辆数,减少低概率区域车辆数。对新需求发生的客户,给予及时服务,减少改变当前路径的成本,达到减少总成本的目的。

参考文献:

[1] PSARAFTIS H N. Dynamic vehicle routing: status and prospects [J]. Annals of Operations Research, 1995, 61(1): 143-164.

[2] 周鲜成,王莉,周开军,等. 动态车辆路径问题的研究进展及发展趋势 [J]. 控制与决策, 2019, 34(3): 449-458.

ZHOU Xiancheng, WANG Li, ZHOU Kaijun, et al. Research progress and development trend of dynamic vehicle routing problem [J]. Control and Decision, 2019, 34(3): 449-458.

[3] PILLAC V, GUÉRET C, MEDAGLIA A L. An event-driven optimization framework for dynamic vehicle routing [J]. Decision Support Systems, 2012, 54(1): 414-423.

[4] ARMAS J A, BATISTA B M. Variable neighborhood search for a dynamic rich vehicle routing problem with time windows [J]. Computers & Industrial Engineering, 2015, 85: 120-131.

[5] AZI N, GENDREAU M, POTVIN J Y. A dynamic vehicle routing problem with multiple delivery routes [J]. Annals of Operations Research, 2012, 199(1): 103-112.

[6] ABDALLAH A M F M, ESSAM D L, SARKER R A. On solving periodic re-optimization dynamic vehicle routing problems [J]. Applied Soft Computing, 2017, 55: 1-12.

[7] 胡乔宇,杨琨,刘冉. 考虑随机客户需求的两级车辆路径问题研究 [J]. 工业工程与管理, 2018, 23(5): 74-81.

HU Qiaoyu, YANG Kun, LIU Ran. Vehicle routing problem with stochastic demands in two-echelon logistics [J]. Industrial Engineering and Management, 2018, 23(5): 74-81.

[8] KUO R J, WIBOWO B S, ZULVIA F E. Application of a fuzzy ant colony system to solve the dynamic vehicle routing problem with uncertain service time [J]. Applied Mathematical Modelling, 2016, 40(23/24): 9990-10001.

- [9] HAGHANI A, JUNG S. A dynamic vehicle routing problem with time-dependent travel times [J]. *Computers & Operations Research*, 2005, 32(11): 2959-2986.
- [10] 段征宇, 雷曾翔, 孙硕, 等. 随机时变车辆路径问题的多目标鲁棒优化方法 [J]. *西南交通大学学报*, 2019, 54(3): 565-572.
DUAN Zhengyu, LEI Zengxiang, SUN Shuo, et al. Multi-objective robust optimisation method for stochastic time-dependent vehicle routing problem [J]. *Journal of Southwest Jiaotong University*, 2019, 54(3): 565-572.
- [11] 李桃迎, 吕晓宁, 李峰, 等. 考虑动态需求的外卖配送路径优化模型及算法 [J]. *控制与决策*, 2019, 34(2): 406-413.
LI Taoying, LÜ Xiaoning, LI Feng, et al. Routing optimization model and algorithm for takeout distribution with multiple fuzzy variables under dynamics demand [J]. *Control and Decision*, 2019, 34(2): 406-413.
- [12] 张景玲, 赵燕伟, 王海燕, 等. 多车型动态需求车辆路径问题建模及优化 [J]. *计算机集成制造系统*, 2010, 16(3): 543-550.
ZHANG Jingling, ZHAO Yanwei, WANG Haiyan, et al. Modeling and algorithms for a dynamic multi-vehicle routing problem with customers' dynamic requests [J]. *Computer Integrated Manufacturing Systems*, 2010, 16(3): 543-550.
- [13] 饶卫振, 金淳, 刘锋, 等. 一类动态车辆路径问题模型和两阶段算法 [J]. *交通运输系统工程与信息*, 2015, 15(1): 159-166.
RAO Weizhen, JIN Chun, LIU Feng, et al. Model and two-stage algorithm on dynamic vehicle routing problem [J]. *Journal of Transportation Systems Engineering and Information Technology*, 2015, 15(1): 159-166.
- [14] 刘霞, 齐欢. 带时间窗的动态车辆路径问题的局部搜索算法 [J]. *交通运输工程学报*, 2008, 8(5): 114-120.
LIU Xia, QI Huan. Local search algorithm of dynamic vehicle routing problem with time window [J]. *Journal of Traffic and Transportation Engineering*, 2008, 8(5): 114-120.
- [15] ZHOU L, BALDACCIO R, VIGO D, et al. A multi-depot two-echelon vehicle routing problem with delivery options arising in the last mile distribution [J]. *European Journal of Operational Research*, 2018, 265(2): 765-778.
- [16] FERREIRA J C, STEINER M T A, GUERSOLA M S. A vehicle routing problem solved through some metaheuristics procedures: a case study [J]. *IEEE Latin America Transactions*, 2017, 15(5): 943-949.
- [17] OSTERMEIER M, HUBNER A. Vehicle selection for a multi-compartment vehicle routing problem [J]. *European Journal of Operational Research*, 2018, 269(2): 682-694.
- [18] HU C, LU J, LIU X, et al. Robust vehicle routing problem with hard time windows under demand and travel time uncertainty [J]. *Computers & Operations Research*, 2018, 94: 139-153.
- [19] 贺国光, 崔岩, 王桂珠. 单个交叉路口到车服从泊松分布条件下控制动态响应的仿真研究 [J]. *系统工程*, 2002, 20(5): 65-71.
HE Guoguang, CUI Yan, WANG Guizhu. Simulation study on dynamic response under the condition of Poisson arrival for an intersection [J]. *Systems Engineering*, 2002, 20(5): 65-71.
- [20] 高镜媚, 汪定伟. 基于仿真的优化及其在多级库存系统中的应用 [J]. *系统仿真学报*, 2009, 21(22): 47-52.
GAO Jingmei, WANG Dingwei. Simulation-based optimization and its application in multi-echelon inventory system [J]. *Journal of System Simulation*, 2009, 21(22): 47-52.
- [21] 温创新, 邱一凡, 孙军. 基于大数据和泊松分布的配件预测模型分析与建模 [J]. *计算机与数字工程*, 2014, 42(8): 1412-1414.
WEN Chuangxin, QIU Yifan, SUN Jun. Fitting prediction model analysis and modeling based on bulk data and Poisson distribution [J]. *Computer & Digital Engineering*, 2014, 42(8): 1412-1414.
- [22] University of Malaga. Capacitated VRP instances [EB/OL]. [2020-03-10]. <http://neo.lcc.uma.es/vrp/vrp-instances/>.

(编辑 杜秀杰 陶晴)