

## 考虑激增需求下前置仓两阶段选址研究\*

卢汉松, 魏海蕊

(上海理工大学 管理学院, 上海 200093)

**摘要:**【目的】考虑时效、成本、效率等关键词目标下,对激增需求下生鲜电商前置仓的两阶段选址问题进行研究。【方法】首先基于前置仓的配送范围和订单处理量,以生鲜电商企业的利润最大化为目标函数,建立了正常需求与激增需求下的前置仓选址模型,并运用一种基于遗传算法的K-means聚类算法对两阶段选址进行求解。【结果】与以往从备选地址中选择最终地址的研究不同,在本研究中通过直接考虑用户地址和需求情况进行建模求解,验证了改进后的方法的可行性和有效性。【结论】结合需求激增,刻画了需求变化情况下的两阶段选址的动态过程。

**关键词:**K-means 聚类算法;遗传算法;前置仓选址;需求激增

**中图分类号:**O224

**文献标志码:**A

**文章编号:**1672-6693(2023)01-0073-09

受疫情影响,自2020年以来消费者对生鲜到家的需求急速增长,生鲜电商市场交易规模有明显提升,预计到2023年,生鲜电商市场交易规模将超过8000亿元<sup>[1]</sup>。目前,生鲜电商行业已进入追求配送效率的生鲜到家时代,前置仓模式生鲜电商将商品前置到距离消费者更近的场景,提高了物流配送效率及消费者的体验感,进而受到了资本市场的广泛关注。前置仓的选址是决定生鲜城市配送网络前期投入和运营效率与成本的关键,也是生鲜电商前置仓模式发展的重要基础。面对急速增长的市场需求,必须在现有基础上增加新的选址,以满足用户需求的同时保证企业效用最大。因此,有必要建立需求激增情况下的生鲜电商前置仓两阶段选址模型,用于选择需要新增前置仓的数量和位置,为进一步决策提供参考。

关于生鲜电商配送模式已得到较多研究。朱湘晖等人<sup>[2]</sup>将生鲜电商配送模式总结分为4种模式:第三方物流模式、自建物流模式、社区配送模式和便利店+O2O模式,并从配送的成本、范围和速度共3个维度对比分析各种模式的优缺点,最后提出生鲜电商企业可以从企业的运作模式、配送需求、客户体验等维度考虑,从而选择合适的配送模式。李伟春等人<sup>[3]</sup>从物流成本和配送速度等维度对现有的4种物流模式优缺点进行对比分析,并指出企业可以从企业特点、不同产品的种类属性和用户的需求情况等维度选择合适的配送模式。而前置仓配送模式是近几年国内新兴的生鲜电商配送模式,目前国内外学者关于前置仓的理论研究较为匮乏。邱天<sup>[4]</sup>以每日优鲜为例,发现前置仓模式目前存在产品种类不足、盈利模式单一等问题,并提出建立前置仓网络、拓展业务范围的建议。邢惠淳<sup>[5]</sup>将前置仓模式的每日优鲜和线上线下一体化的盒马鲜生做对比,从价值主张、价值传递、价值实现等3个角度进行分析,研究了中国生鲜电商的发展模式并提出了相关建议。因此,对生鲜电商前置仓物流运作模式进行研究,在丰富生鲜电商配送领域的理论研究和指导生鲜电商运营方面都具有重要的意义。

关于生鲜产品物流中心的选址研究,一般可以分为离散型选址和连续型选址问题。目前已有的研究大多数讨论的是关于有备选中心的离散型选址问题,例如梁海红<sup>[6]</sup>针对生鲜农产品的特质,考虑了产品新鲜度、品质度及时间窗等因素,运用线性规划理论对物流中心选址进行建模,并用启发式算法进行求解。尹小庆等人<sup>[7]</sup>针对城市冷链物流配送时效性的问题,考虑到恶劣的城市交通环境及高度分散的客户等因素,从行程时间可靠性角度出发,提出一种基于复杂网络的冷链物流末端配送中心选址模型。邹筱等人<sup>[8]</sup>在冷链物流配送中心的选址问题上,考虑了准时达的限制条件以及增加货损成本目标函数,并在传统CFLP法的基础上构建了新的混合整数

\* 收稿日期:2021-08-08 修回日期:2022-08-08 网络出版时间:2023-02-22 15:01

资助项目:国家自然科学基金(No. 71801150)

第一作者简介:卢汉松,男,研究方向为物流系统优化,E-mail:luhansong\_usst@163.com;通信作者:魏海蕊,女,讲师,博士,E-mail:hrwei@shmtu.edu.cn

网络出版地址:https://kns.cnki.net/kcms/detail/50.1165.N.20230222.1324.014.html

非线性规划模型。赵泉午等人<sup>[9]</sup>在考虑了多业态零售门店覆盖范围及冷链设施配置、冷藏品类选择等特征因素基础上,构建了关于生鲜电商企业多业态门店的选址以及需求点分配的非线性混合整数规划模型,并提出混合拉格朗日松弛算法求解模型。相对于离散型选址问题,连续型选址可以为决策者提供更多的可能性和选择性。目前,已有部分学者对连续性选址问题进行研究,例如 Hua 等人<sup>[10]</sup>针对物流系统网络优化问题,建立了连续型物流配送中心选址的数学模型,并提出了一种具有非线性惯性权重和时变加速度系数的自适应粒子群优化算法。魏洁等人<sup>[11]</sup>研究了关于生鲜产品多配送中心连续选址的问题,以最小距离为目标建立了选址模型,并提出模糊 C 均值聚类-改进模拟退火(FCM-ISA)算法对模型进行求解。

综上所述,已有研究中关于电商企业的前置仓两阶段选址问题的讨论较少。考虑到用户需求量激增对前置仓选址有着重要影响,本文以生鲜电商的前置仓选址为出发点,研究激增需求下生鲜电商前置仓两阶段选址问题。本文首先对正常情况下和激增情况下用户需求量进行描述;然后以生鲜电商企业的利润最大化为目标函数,建立了正常需求与激增需求下的前置仓选址模型;最后运用一种基于遗传算法的 K-means 聚类算法(GKA)对两阶段选址模型进行求解,为发生激增需求情况下生鲜电商企业前置仓选址问题提供一定的参考。

## 1 激增需求下生鲜电商前置仓两阶段选址模型设计

### 1.1 问题描述

本文研究的是激增需求下生鲜电商前置仓的两阶段选址,以考虑用户需求量的同时实现企业利润最大化。在传统的物流中心选址模型中,大都假设物流系统中所涉及的库存费用、车辆费用、需求量、运输时间等关键因素为已知常数,然后根据要求确定一个或多个物流中心的选址问题。对于激增需求下的生鲜电商前置仓的两阶段选址研究较少,并且用户订单量的变化对生鲜电商前置仓的选址和经营有着重要影响,需建立一个基于需求激增的前置仓两阶段选址模型。

本文提出数项基本模型假设:

- 1) 前置仓选址的过程和配送过程不考虑天气的影响;
- 2) 每辆前置仓配送车辆运载满载且不超载;
- 3) 假设生鲜产品在运送过程中的质量损失与配送距离有关,且单位距离的损失为定值;
- 4) 每个前置仓的最大服务半径和最大处理订单量都是统一的定值;
- 5) 各个前置仓建设规模、运营成本相同;
- 6) 每个客户仅有 1 个前置仓供货,各前置仓直接相对独立。

### 1.2 参数说明

$M$  为前置仓的集合,  $i \in M$ ;  $N$  为需求点的集合,  $j \in N$ ;  $F_i$  为前置仓  $i$  的管理成本;  $T_i$  为前置仓  $i$  的租金成本;  $G_i$  为前置仓  $i$  的配送人员数量;  $R_i$  为前置仓  $i$  的总订单量;  $r_j$  为需求点  $j$  的实际订单量;  $p_j$  为需求点  $j$  的需求量;  $e$  为平均客单价;  $c_1$  为生鲜产品单位配送距离的损失成本;  $c_2$  为配送员每单的配送提成;  $s$  为配送员的平均基本工资;  $\alpha$  为需求点发生激增的概率;  $[c, d]$  分布为需求量激增倍数的上下限;  $z_{ij}$  表示需求点  $j$  由前置仓  $i$  服务为 1, 否则为 0;  $U_i(x_{1i}, y_{1i})$  为前置仓的实际位置坐标;  $V_j(x_{2j}, y_{2j})$  为需求点的实际位置坐标;  $d(U_i, V_j)$  为前置仓  $i$  到需求点  $j$  的距离, 其中前置仓的实际位置坐标为决策变量。

### 1.3 数学模型

在前置仓选址模型中,如何确定前置仓的数量和位置,使得生鲜电商前置仓满足辐射区域内的客户订单需求的同时,实现企业利润最大化是重点研究的问题。而如前所述前置仓系统可能面临两种类型的需求,正常需求和激增需求。尤其是生鲜电商作为最贴近民生的基本需求服务,是否很好地满足应急状态下的激增需求对于客户的满意度和忠实度有重要影响。因此,本文在前置仓选址模型设计时将同时考虑客户两种状态下的需求,本文分别对正常需求和激增需求状态进行数学描述,在此基础上构建两种需求下的前置仓选址模型。

1.3.1 正常情况下需求量描述 正常情况下,小区居民对生鲜电商产品一天的需求量是一种随机事件,且满足某种离散随机分布。泊松分布适合于描述单位时间内随机事件发生的次数,如某一服务设施在一定时间内到达的人数、汽车站的候客人数等。Roni 等人<sup>[12]</sup>使用泊松分布对正常需求进行了描述:

$$p_c(X=r_c) = \lambda^{r_c} e^{-\lambda} / r_c!, r_c = 1, 2, 3, \dots, \quad (1)$$

其中: $\lambda > 0$  为常量。(1)式表示正常时需求量为  $r_c$  的概率。

1.3.2 激增情况下需求量描述 激增情况下,小区居民对生鲜电商产品一天的需求量会成倍数的增长,规模是高度随机的,范围可能相当广泛。但同时,相较于高倍数的激增需求,低倍数的激增需求更容易发生。Roni 等人<sup>[12]</sup>使用泊松分布和一个离散分布的复合对激增需求进行描述,该离散分布如下:

$$P(X=r)=2(d-r+1)/[(d-c+2)(d-c+1)], \quad (2)$$

其中: $r \in [c, d]$ ,  $r$  为整数,  $d > c > 0$  且为整数。(2)式表示在激增情况下用户需求量激增  $r$  倍的概率。故激增情况下需求量的总体描述如下:

$$r_z = r_c \times r, \quad (3)$$

$$P_z(X=r_z) = \sum_{r_c \times r = r_z} P_c(X=r_c) p(X=r), \quad (4)$$

其中: $r_z$  为激增情况下的需求量,  $r_c$  为正常情况下的需求量,  $r$  为需求量的激增倍数。(4)式表示激增情况下需求量为  $r_z$  的概率。

由于任意用户的需求分布只满足两种结果:正常需求和激增需求。假设任意用户的需求量发生激增的概率为  $\alpha$ , 则正常的概率为  $(1-\alpha)$ 。从概率论的角度分析,定义随机变量  $Z$ ,  $Z$  只可能取 0、1 两个值,值为 1 时表示为发生激增情况的需求,值为 0 时表示为正常情况下的需求,则  $Z$  服从以  $\alpha$  为参数(0-1)分布。

利用全概率公式得到任意用户的需求量满足分布:

$$P(X=D) = P(X=D|Z=1) \times P(Z=1) + P(X=D|Z=0) \times P(Z=0) = \alpha P_z(X=D) + (1-\alpha) P_c(X=D), \quad (5)$$

其中: $\alpha$  的取值可以根据历史数据统计及专家经验进行确定; $P_z(X=D)$  表示发生激增情况下需求量为  $D$  的概率; $P_c(X=D)$  表示正常情况下需求量为  $D$  的概率;(5)式表示任意一需求点需求量为  $D$  的概率。

1.3.3 数学模型 本节以最大利润为目标函数,用前置仓订单的处理量与前置仓的服务半径及配送员的配送量为约束,各前置仓位置坐标为决策变量,考虑正常与激增情况下需求量建立数学模型,表示如下:

$$\max P = \sum_{j \in N} r_j e - \left( \sum_{i \in M} F_i + \sum_{i \in M} T_i \right) / 30 - \sum_{i \in M} \sum_{j \in N} d(U_i, W_j) z_{ij} r_j c_1 - \sum_{i \in M} G_i s / 30 - \sum_{i \in M} R_i c_2, \quad (6)$$

$$\text{s. t. } 0 \leq \max d(U_i, W_j) \leq 2.5, \forall i \in M, j \in N, \quad (7)$$

$$\max R_i \leq 2000, \forall i \in M, \quad (8)$$

$$R_i / G_i \leq 150, \forall i \in M, \quad (9)$$

$$p_j \geq r_j, \forall j \in N, \quad (10)$$

$$p\left(\sum_j r_j - d_j \geq 0\right) \geq \beta, \forall j \in N, \quad (11)$$

$$z_{ij} \in (0, 1), \quad (12)$$

$$x_{1i}, y_{1i}, x_{1j}, y_{1j} \in \mathbf{R}, \forall i \in N, \forall j \in M. \quad (13)$$

目标函数(6)为最大化前置仓选址利润,由订单的总收入减去每日平均的总支出,包括前置仓每日的平均管理成本、租金成本、配送过程产品的损失成本、配送员的基本成本及配送员的订单提成支出;约束(7)表示每个前置仓到该配送区域的需求点的最大距离  $\max d(U_i, W_j)$  不超过 2.5 km;约束(8)表示一个前置仓每日最大订单处理量  $\max R_i$  不超过 2 000 单;约束(9)表示每个前置仓配送员平均每天最大的配送量不超过 150 单;约束(10)表示任意用户点的实际订单量不超过需求量;约束(10)表示前置仓的实际订单处理量能够满足每个需求点需求量的概率大于等于置信水平  $\beta$ ;约束(12)表示变量只能取 0 或 1;约束(13)表示实际经纬度坐标,其中  $x_{1i}, y_{1i}$  为决策变量。

## 2 基于 GKA 的模型求解

$K$ -means 聚类算法常用来解决设施选址规划问题,但传统的  $K$ -means 算法对初始聚类中心敏感,容易受初始选定的聚类中心的影响而过早地收敛。因此,本文运用 GKA<sup>[13]</sup>进行求解。利用遗传算法为  $K$ -means 算法提供优化的初始聚类中心,以提升  $K$ -means 算法寻求全局优化的能力,并在此算法的基础上结合本文实际问题,考虑了订单量及服务能力等因素,对激增需求下的两阶段选址模型进行了求解。

## 2.1 考虑距离和订单量约束的 $K$ -means 算法设计

$K$ -means 聚类算法常用距离作为相似性评价系数,将数据集  $M$  中  $n$  个对象分为  $k$  类,使得每个分类内部相似度较高,而不同分类之间相似度较低。 $K$ -means 算法首先在数据集  $M$  中随机选择  $k$  个对象作为聚类中心,计算数据集中其他对象到每个聚类中心的距离,并将它划分到最近的聚类中心,然后根据新划分的类重新计算聚类中心,不断重复此过程,直到聚类中心不再变化。在前置仓的选址中,需要在满足距离和服务订单量约束以及覆盖所有重点用户需求点的情况下,为实现企业利润最大化而尽可能少的建立前置仓,基于此本文使用考虑距离和订单量约束的  $K$ -means 算法确定所需建立前置仓的数量。

此时  $K$ -means 聚类算法具体求解步骤如下:

- 1) 给定大小为  $n$  的数据集  $M$ ,初始令  $k=1$ ,从数据集中随机选择  $k$  个聚类中心  $c_i, i=1,2,\dots,k$ ;
- 2) 计算数据集  $M$  中其他数据对象与聚类中心的距离  $d(c_i, x_j), i=1,2,\dots,k, j=1,2,\dots,n$ 。将每个数据对象按照最小距离划分到对应得聚类中心;
- 3) 根据划分的分类重新计算聚类中心  $c_i^* = 1/n_i (\sum_{x_m \in c_i} x_m), i=1,2,\dots,k$ ,其中  $n_i$  为类  $c_i$  中对象的个数;
- 4) 如果  $c_i^* \neq c_i$ ,则用  $c_i^*$  取代  $c_i$  转至 2);
- 5) 判断每个分类中数据对象与聚类中心的最大距离  $\max d(c_i, x_m) \geq 2.5 \text{ km}, x_m \in c_i, i=1,2,\dots,k$ ,则  $k=k+1$  转至 1);
- 6) 根据数据集  $M$  产生订单量集  $O$ ,计算每个聚类中心的总订单量  $r_i, i=1,2,\dots,k$ ;
- 7) 判断  $r_i \geq 2000, i=1,2,\dots,k$ ,则  $k=k+1$  转至 1), 否则输出聚类结果。

## 2.2 第一阶段正常需求下选址

遗传算法是模拟生物在自然环境中的遗传和进化过程而形成的一种自适应全局优化搜索算法。在进化过程中进行的遗传操作包括编码、选择、交叉、变异和适者生存选择。它以适应度函数为依据,通过对种群个体不断进行遗传操作实现种群个体一代代地优化并逐渐逼近最优解。GKA 的基本思想是:首先从要聚类的样本集选出初始种群,并对它执行遗传算法;对执行完遗传算法后产生的较优的新种群再进行  $K$ -means 聚类。如此反复循环,直到寻找出聚类问题的最优方案。

此时第一阶段选址具体求解步骤如下:

- 1) 利用 2.1 节中考虑距离和订单量约束的  $K$ -means 算法设计确定聚类数量  $k$ ;
- 2) 设置遗传参数:聚类数  $k$ (由 2.1 节  $K$ -means 聚类算法结果可得),种群规模  $m$ ,最大迭代次数  $T$ ,交叉概率  $P_c$ ,变异概率  $P_m$ ;
- 3) 种群初始化:从样本中随机选取  $k$  个点作为聚类中心  $c_i, i=1,2,\dots,k$ ;并进行编码  $(x_{11}, x_{12}, x_{21}, x_{22}, \dots, x_{k1}, x_{k2}), c_i = (x_{i1}, x_{i2}), i=1,2,\dots,k$ ,重复  $m$  次,产生初始种群;
- 4) 计算群体中各个体的适应度  $f_i = P, i=1,2,\dots,m$ ,由(6)式可得:

$$f_i = \sum_j r_j e_j - (\sum_i F_i + \sum_i T_i) / 30 - \sum_i \sum_{x_m} d(c_i, x_m) r_m c_1 - \sum_i G_i s / 30 - \sum_i R_i c_2,$$

其中:  $x_m \in c_i, i=1,2,\dots,k, j=1,2,\dots,n$ 。

- 5) 根据计算的各个体的适应度  $f_i, i=1,2,\dots,m$ ,通过轮盘赌的方式挑选下一代,重复  $m$  次达到新的种群规模;

6) 交叉:按照交叉概率  $P_c$ ,本文采用由两个个体的线性组合而产生出两个新个体的算术交叉算子的方式,对两个相互配对的染色体进行部分基因的交换: 
$$\begin{cases} X_i = \alpha X_j + (1-\alpha) X_i \\ X_j = \alpha X_i + (1-\alpha) X_j \end{cases}, X_i = (x_{11}, x_{12}, x_{21}, x_{22}, \dots, x_{k1}, x_{k2}),$$
  $i, j=1,2,\dots,m, \alpha$  为  $(0,1)$  范围内符合均匀概率分布的一个随机数;

7) 变异:对每个编变异点,变异概率  $P_m$  从对应基因取值范围内取一个随机数来代替原有值。其中变异点的新基因值为:  $X_i = V_{\min} + \beta(V_{\max} - V_{\min}), [V_{\min}, V_{\max}]$  为每个基因点的取值范围,  $\beta$  为  $(0,1)$  范围内符合均匀概率分布的一个随机数;

- 8) 将上述结果代入  $K$ -means 聚类算法,产生新一代群体;

9) 重复 4)~8), 直到达到最大迭代次数  $T$ ;

10) 计算新一代群体的适应度, 以最大适应度的最佳个体为中心进行  $K$ -means 聚类, 输出聚类结果。

### 2.3 第二阶段需求激增下选址

关于需求激增的前置仓第二阶段选址, 是在正常情况选址的基础上对于需要新增前置仓的选择。在满足一定用户激增需求的同时, 还需保持原始前置仓的位置不变, 使新增一定数量的前置仓满足企业利益最大化。

此时第二阶段选址具体求解步骤如下:

1) 根据激增后的订单量, 利用 2.1 节中考虑距离和订单量约束的  $K$ -means 算法设计确定新的聚类数量  $l$ , 原始聚类数量为  $k$ , 则  $k < l$ ;

2) 种群初始化: 从样本中随机选取  $l - k$  个点与原始聚类中心  $c_i$  组成新的聚类中心  $c_j, j = 1, 2, \dots, l$ , 并进行编码, 重复  $m$  次, 产生初始种群;

3) 计算群体中各个体的适应度  $f_s, s = 1, 2, \dots, m$ , 根据计算的各个体的适应度  $f_s, s = 1, 2, \dots, m$ , 通过轮盘赌的方式挑选下一代, 重复  $m$  次达到新的种群规模;

4) 仅对每个种群  $X_i = (x_{k+1,1}, x_{k+1,2}, x_{k+2,1}, x_{k+2,2}, \dots, x_{l1}, x_{l2}), i = 1, 2, \dots, m$  部分进行交叉、变异;

5) 将上述结果代入  $K$ -means 聚类算法, 其中重新计算聚类中心  $c_j^* = 1/n_j (\sum_{x_m \in c_j} x_m), j = k, k+1, \dots, l$ , 产生新一代群体;

6) 重复 2)~5), 直到达到最大迭代次数  $T$ ;

7) 计算新一代群体的适应度, 以最大适应度的最佳个体为中心进行  $K$ -means 聚类, 输出聚类结果。

## 3 实例分析

根据建立的前置仓选址模型, 以上海市杨浦区各小区为需求点对模型进行验证。通过使用 Python 爬取上海链家网 (sh.lianjia.com) 相关信息, 得到杨浦区小区的名称和地址数据, 再通过高德地图 API 接口中地理编码功能将地址转换为经纬度数据。假设单位距离的损失成本  $c_1 = 3$ , 配送每单可得的收入  $c_2 = 3, \lambda = 8, c = 1, d = 3$ , 每个配送员的固定工资  $s = 3\ 600$ , 每个前置仓的管理成本  $F = 40\ 000$ 。

### 3.1 正常需求下前置仓选址

正常需求下,  $\alpha = 0$ , 前置仓能完全满足该区域内的用户需求, 即  $r_k = d_k$  用户订单量等于用户需求量。按照每个需求点订单数满足 (5) 式的概率分布产生订单随机数, 结果如图 1 所示。

将得到的经纬度数据作为数据集, 利用考虑距离和订单量约束的  $K$ -means 算法, 得到正常需求情况下最优的前置仓数量  $k = 11$ 。运用 Python 进行编程实现基于遗传算法的  $K$ -means 模型进行求解。将聚类中心进行利润最大化适应度计算, 设定种群数为 50, 迭代次数 50 次, 交叉概率 0.9, 变异概率 0.01, 以达到迭代次数为终止条件, 得到正常需求情况下选址结果如图 2 和表 1 所示。

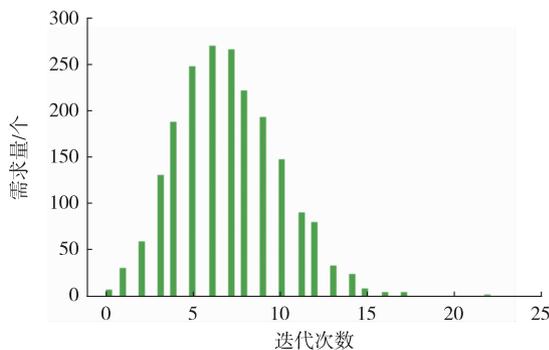


图 1 正常需求下用户需求量分布

Fig. 1 User demand distribution under normal demand

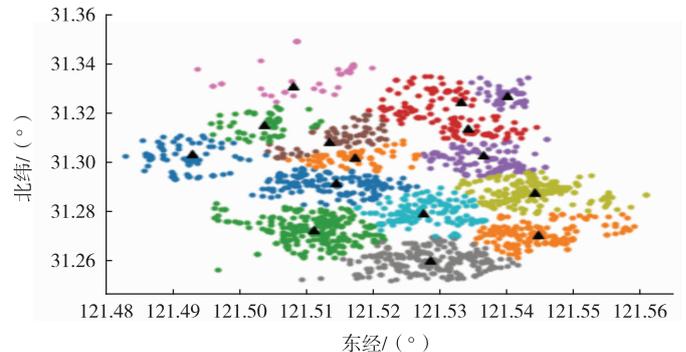


图 2 正常需求下选址结果

Fig. 2 Location results under normal demand

表 1 正常需求下选址结果

Tab. 1 Location results under normal demand

聚类中心	经纬度坐标/(°)	覆盖数量/个	平均距离/km	利润/元	聚类中心	经纬度坐标/(°)	覆盖数量/个	平均距离/km	利润/元
K1	(E121.515,N31.292)	144	0.63	52 491.76	K7	(E121.508,N31.331)	82	0.50	29 108.82
K2	(E121.545,N31.271)	75	1.14	25 044.86	K8	(E121.529,N31.261)	280	0.73	100 731.05
K3	(E121.511,N31.273)	218	0.77	76 096.82	K9	(E121.533,N31.323)	156	0.82	55 363.31
K4	(E121.533,N31.325)	288	0.82	108 579.34	K10	(E121.528,N31.280)	134	0.67	44 659.23
K5	(E121.537,N31.303)	155	0.70	62 264.32	K11	(E121.493,N31.303)	170	0.76	63 684.97
K6	(E121.514,N31.309)	286	1.15	96 807.23					

### 3.2 激增需求下前置仓选址

激增需求下,取  $\alpha=0.5$ ,置信水平  $\beta=0.8$ ,按照每个需求点需求量满足(5)式的概率分布产生订单随机数,用户订单量满足  $p(\sum_k r_k - d_k \geq 0) \geq \beta$ ,最后计算得用户订单量结果如图 3 所示。

激增需求下前置仓选址是在正常情况选址的基础上发生的,因此将上文正常需求情况下的选址结果作为已确定的前置仓。然后利用考虑距离和订单量约束的  $K$ -means 算法,得到激增需求情况下最优的前置仓数量  $k=15$ 。运用 Python 进行编程实现基于遗传算法的  $K$ -means 模型进行求解。将聚类中心进行利润最大化适应度计算,设定种群数为 50,迭代次数 50 次,交叉概率 0.9,变异概率 0.01,以达到迭代次数为终止条件。得到激增情况下的选址结果如图 4 和表 2 所示。

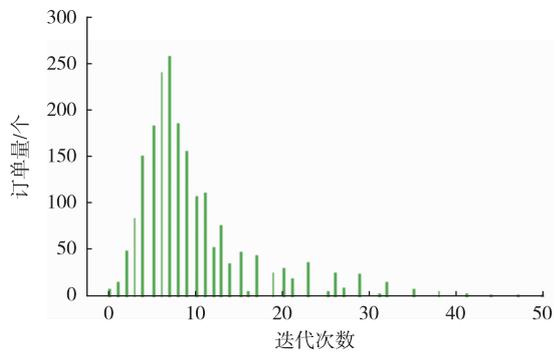


图 3 激增需求下用户订单量分布

Fig. 3 The distribution of customer orders under the surge demand

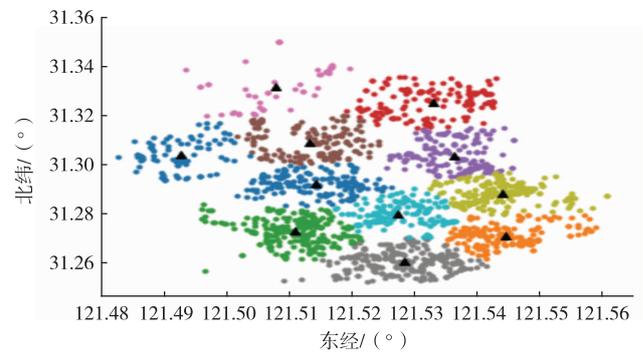


图 4 激增需求下选址结果

Fig. 4 Location results under surge demand

表 2 激增需求下选址结果

Tab. 2 Location results under surge demand

聚类中心	经纬度坐标/(°)	覆盖数量/个	平均距离/km	利润/元	聚类中心	经纬度坐标/(°)	覆盖数量/个	平均距离/km	利润/元
K1	(E121.515,N31.292)	130	0.60	71 902.60	K9	(E121.544,N31.288)	164	0.50	86 347.19
K2	(E121.545,N31.271)	179	0.57	87 314.53	K10	(E121.528,N31.280)	159	0.56	72 276.98
K3	(E121.511,N31.273)	168	0.59	85 403.63	K11	(E121.493,N31.303)	93	0.71	43 557.13
K4	(E121.533,N31.325)	166	0.81	80 805.09	K12	(E121.508,N31.293)	85	0.41	45 789.92
K5	(E121.537,N31.303)	189	0.72	98 969.49	K13	(E121.514,N31.267)	96	0.54	49 602.32
K6	(E121.514,N31.309)	163	0.75	78 355.90	K14	(E121.535,N31.259)	99	0.63	51 534.11
K7	(E121.508,N31.331)	51	1.05	29 632.73	K15	(E121.539,N31.285)	91	0.40	38 007.77
K8	(E121.529,N31.261)	155	0.61	67 927.75					

### 3.3 算法的比较

为验证算法的有效性,本文利用正常需求和激增需求下的数据,分别利用遗传算法、粒子群算法(PSO)、K-means 算法和 GKA 进行求解,其中前置仓的数量统一用考虑距离和订单量约束的 K-means 算法得到的最优聚类个数,遗传算法和 GKA 都设定种群数为 50,迭代次数为 50,交叉概率 0.6,变异概率 0.3,分别得到 3 个算法的最优结果(表 3)。

表 3 算法有效性的比较

Tab.3 Comparison of algorithm effectiveness

		K-means 算法	POS	遗传算法	GKA
常规需求	平均距离/km	0.79	0.84	0.81	0.71
	总利润/元	714 831.72	700 113.21	712 187.44	720 041.45
激增需求	平均距离/km	0.62	0.71	0.69	0.61
	总利润/元	987 427.13	976 312.83	980 368.01	987 777.14

根据表 3 的结果可知,无论是在正常需求情况下还是激增需求情况下,由 GKA 得到的结果平均距离更短,说明相同速度下配送时间越快,使得用户满意度越高,并且总利润更大,由此可得 GKA 的优越性。

为进一步验证算法的适用性,本文将需求点数量增加至 10 000 左右,分别利用遗传算法、PSO、K-means 算法和 GKA 进行求解,其中前置仓的数量统一用考虑距离和订单量约束的 K-means 算法得到的最优聚类个数,遗传算法和 GKA 都设定交叉概率 0.6,变异概率 0.3,分别得到 3 个算法的最优结果见表 4,遗传算法、PSO 和 GKA 的种群迭代图见图 5、图 6、图 7。

表 4 算法适用性比较

Tab.4 Comparison of algorithm applicability

	K-means 算法	POS	遗传算法	GKA
平均距离/km	0.74	0.79	0.78	0.70
总利润/元	4 260 961.67	3 774 526.67	3 804 820.49	4 680 373.74
迭代次数	—	200	200	50
运算时间/s	15.489	812.142	770.996	577.146

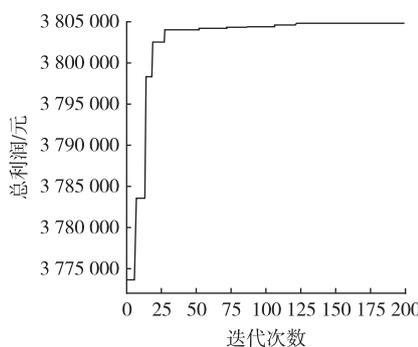


图 5 遗传算法种群迭代图  
Fig.5 Genetic algorithm population iteration graph

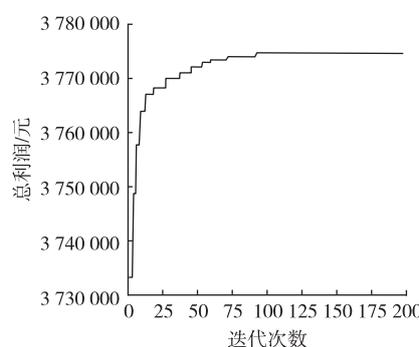


图 6 PSO 种群迭代图  
Fig.6 Pareicle swarm optimization population iteration graph

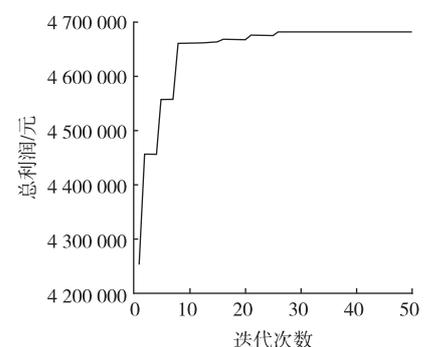


图 7 GKA 种群迭代图  
Fig.7 GKA population iteration graph

根据表 4 的结果可知,随着需求点数量的增加,GKA 的优越性更加明显,总利润和平均距离的最优解显著优于 K-means 算法、遗传算法和 PSO,并且由图 5、图 6 和图 7 种群的迭代图可知,PSO 需迭代 100 次左右,遗传算法需迭代 125 次左右才趋于稳定,而 GKA 在种群迭代 28 次左右就达到最优值,运算速度更快,由此可进一步

说明 GKA 在解决选址问题中的优越性。

## 4 结束语

生鲜电商前置仓模式的发展给居民生活带来了便捷,尤其在疫情期间,如叮咚买菜、每日优鲜等前置仓模式生鲜电商为许多居民足不出户的生活提供了可能。本文研究激增需求情况下前置仓两阶段选址问题,在构建模型时考虑了前置仓的配送半径、订单处理量以及激增情况下用户的需求量。最后通过实际案例分析,验证了模型的可行性以及 GKA 的优越性,可为生鲜电商企业前置仓模式面对突发情况时制定企业决策提供参考。本文的研究仅考虑了前置仓到需求点的欧氏距离,没有分析实际的配送距离和路径问题。在未来的研究中,前置仓物流配送中的路径优化问题可作为研究重点;同时可将生鲜电商前置仓模式和疫情下需求激增突发事件相结合,研究在满足激增情况下用户需求的同时考虑激增过后企业的长期利润。

### 参考文献:

- [1] 上海艾瑞市场咨询有限公司. 中国生鲜电商行业研究报告(2020年)[R]. 上海:上海艾瑞市场咨询有限公司,2020:29.  
Shanghai Airui Market Consulting Co., Ltd. Research report on Chinese fresh e-commerce industry in 2020[R]. Shanghai: Shanghai Airui Market Consulting Co., Ltd, 2020:29.
- [2] 朱湘晖,胡雄鹰,张宗祥. 生鲜电子商务物流配送模式的比较[J]. 物流技术,2015(3):17-19.  
ZHU X H, HU X Y, ZHANG Z X. Comparison of fresh e-commerce logistics distribution mode[J]. Logistics Technology, 2015 (3):17-19.
- [3] 李伟春,吴尚恒,谈红,等. 生鲜电商物流配送模式比较分析[J]. 对外经贸,2017(7):89-91.  
LI W C, WU S H, TAN H, et al. Comparative analysis of fresh e-commerce logistics distribution mode[J]. Foreign Trade and Economic Cooperation, 2017(7):89-91.
- [4] 邱天. 前置仓模式下的供应链管理分析:以每日优鲜为例[J]. 商讯,2020(36):11-12.  
QIU T. Analysis of supply chain management under the mode of forward warehouse[J]. Business News, 2020(36):11-12.
- [5] 邢惠淳. “新零售”背景下生鲜电商商业模式比较分析:以盒马鲜生和每日优鲜为例[J]. 商业经济研究,2019(4):85-87.  
XING H C. Comparative analysis of fresh e-commerce business models under the background of “new retail”: taking HEMA fresh and daily excellent fresh as examples[J]. Business Economics Research, 2019(4):85-87.
- [6] 梁海红. “互联网+”时代物流配送中心选址优化模型构建[J]. 统计与决策,2016(22):51-53.  
LIANG H H. Establishment of logistics distribution center location optimization model in the era of “Internet plus”[J]. Statistics and Decision Making, 2016(22):51-53.
- [7] 尹小庆,莫宇迪,董陈晨,等. 考虑行程时间可靠性的城市冷链末端配送站选址研究[J]. 交通运输系统工程与信息,2019,19(6):176-183.  
YIN X Q, MO Y D, DONG C C, et al. Study on location of distribution station at the end of urban cold chain considering travel time reliability[J]. Transportation System Engineering and Information, 2019, 19(6):176-183.
- [8] 邹筱,张晓宁. 准时达限制条件的冷链物流配送中心选址模型[J]. 统计与决策,2020,36(12):185-188.  
ZOU X, ZHANG X N. Location model of cold chain logistics distribution center with punctual arrival constraints[J]. Statistics and Decision Making, 2020, 36(12):185-188.
- [9] 赵惠午,姚珍珍,林娅. 面向新零售的生鲜连锁企业城市配送网络优化研究[J]. 中国管理科学,2021,29(9):168-179.  
ZHAO Q W, YAO Z Z, LIN Y. Research on urban distribution network optimization of fresh food chain enterprises for new retail[J]. China Management Science, 2021, 29(9):168-179.
- [10] HUA X, HU X, YUAN W. Research optimization on logistics distribution center location based on adaptive particle swarm algorithm[J]. Optik-International Journal for Light and Electron Optics, 2016, 127(20):8443-8450.
- [11] 魏洁,王佳鑫. 生鲜农产品多配送中心连续选址 FCM-ISA 算法及应用[J]. 运筹与管理,2019,28(11):85-90.  
WEI J, WANG J X. FCM-ISA algorithm for continuous location of multiple distribution centers of fresh agricultural products and its application[J]. Operations Research and Management, 2019, 28(11):85-90.
- [12] RONI M S, JIN M Z, EKSIÖGLU S D. A hybrid inventory management system responding to regular demand and surge demand[J]. Omega, 2015, 52:190-200.

[13] 王娟. 一种基于遗传算法的  $K$ -means 聚类算法[J]. 微型机与应用, 2011, 30(20): 71-73.

WANG J. A  $K$ -means clustering algorithm based on genetic algorithm[J]. Microcomputer and Application, 2011, 30(20): 71-73.

## Operations Research and Cybernetics

### Study on Two-Stage Location of Forebay Considering Surge Demand

LU Hansong, WEI Hairui

(School of Business, University of Shanghai for Science & Technology, Shanghai 200093, China)

**Abstract:** [Purposes] In recent years, the pre-warehouse model that can be fully close to customers, flexible, and low in operation and maintenance costs has been favored by fresh food e-commerce companies, and has shown unique advantages especially under the surge in demand such as the epidemic. [Methods] Firstly, based on the distribution range and order processing capacity of the front warehouse, taking the profit maximization of fresh e-commerce enterprises as the objective function, the front warehouse location model under normal demand and surge demand is established, and a  $k$ -means clustering algorithm based on genetic algorithm is used to solve the two-stage location. [Findings] Different from the previous selection of the final address from the alternative address, the feasibility and effectiveness of the method were verified by directly considering the user address and demand for modeling solution. [Conclusions] Combined with the demand surge, the dynamic process of two-stage site selection under the situation of demand change is described.

**Keywords:**  $K$ -means clustering algorithm; genetic algorithm; location of front warehouse; demand surge

(责任编辑 黄 颖)