

9-18-2020

Dynamic Vehicle Distribution Path Optimization Based on Improved Intelligent Water Drop Algorithm

Shuangnan Fan

1. Department of electrical and Information Engineering, Hunan Institute of Traffic Engineering, Hengyang 421009, China; ;

Jiming Chen

2. School of Computer and Information Science, Hunan Institute of Technology, Hengyang 421002, China;

Weimin Gao

2. School of Computer and Information Science, Hunan Institute of Technology, Hengyang 421002, China;

Zengfeng Wang

1. Department of electrical and Information Engineering, Hunan Institute of Traffic Engineering, Hengyang 421009, China; ;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Dynamic Vehicle Distribution Path Optimization Based on Improved Intelligent Water Drop Algorithm

Abstract

Abstract: In view of the unreasonable distribution path, low distribution efficiency and demand uncertainty in the current vehicle distribution process, *a dynamic vehicle distribution path optimization method based on the improved intelligent drop algorithm is proposed. According to the customer's demand for delivery time, the soft time window penalty function and customer satisfaction function are constructed. Based on the characteristics of vehicle speed, damage cost, penalty cost and customer satisfaction of vehicle distribution, a vehicle path optimization model is established. The vehicle path optimization model is solved by the intelligent water droplet algorithm. The grey wolf optimization algorithm is used to improve the search ability of the intelligent water droplet algorithm to obtain optimization path.* Experiment results show that the method can provide the real-time optimization path and reduce the allocation cost.

Keywords

dynamic vehicle path optimization, delivery time, intelligent water droplet algorithm, gray wolf optimization

Recommended Citation

Fan Shuangnan, Chen Jiming, Gao Weimin, Wang Zengfeng. Dynamic Vehicle Distribution Path Optimization Based on Improved Intelligent Water Drop Algorithm[J]. Journal of System Simulation, 2020, 32(9): 1808-1817.

基于改进智能水滴算法的动态车辆配送路径优化

范双南¹, 陈纪铭^{2*}, 高为民², 王增凤¹

(1. 湖南交通工程学院电气与信息工程学院, 湖南 衡阳 421009; 2. 湖南工学院计算机与信息科学学院, 湖南 衡阳 421002)

摘要: 针对当前车辆配送过程中存在的配送路径不合理、配送效率低和需求不确定性等问题, 提出一种基于改进智能水滴算法的动态车辆配送路径优化方法。构建软时间窗惩罚函数, 考虑顾客对配送时间的要求, 建立顾客满意度函数。综合车辆配送过程的车速、货损成本、惩罚成本、顾客满意度等特征, 建立车辆路径优化模型。采用智能水滴算法对车辆路径优化模型进行求解, 使用灰狼优化算法改善智能水滴算法的搜索能力, 获取最优路径。实验结果表明该方法能够提供实时优化的路径, 减少调配成本。

关键词: 动态车辆路径优化; 配送时效; 智能水滴算法; 灰狼优化

中图分类号: TP30

文献标识码: A

文章编号: 1004-731X (2020) 09-1808-10

DOI: 10.16182/j.issn1004731x.joss.19-0374

Dynamic Vehicle Distribution Path Optimization Based on Improved Intelligent Water Drop Algorithm

Fan Shuangnan¹, Chen Jiming^{2*}, Gao Weimin², Wang Zengfeng¹

(1. Department of electrical and Information Engineering, Hunan Institute of Traffic Engineering, Hengyang 421009, China;

2. School of Computer and Information Science, Hunan Institute of Technology, Hengyang 421002, China)

Abstract: In view of the unreasonable distribution path, low distribution efficiency and demand uncertainty in the current vehicle distribution process, a dynamic vehicle distribution path optimization method based on the improved intelligent drop algorithm is proposed. According to the customer's demand for delivery time, the soft time window penalty function and customer satisfaction function are constructed. Based on the characteristics of vehicle speed, damage cost, penalty cost and customer satisfaction of vehicle distribution, a vehicle path optimization model is established. The vehicle path optimization model is solved by the intelligent water droplet algorithm. The grey wolf optimization algorithm is used to improve the search ability of the intelligent water droplet algorithm to obtain optimization path. Experiment results show that the method can provide the real-time optimization path and reduce the allocation cost.

Keywords: dynamic vehicle path optimization; delivery time; intelligent water droplet algorithm; gray wolf optimization

引言

随着电子商务、物联网的快速发展, 人们对物

流配送速度的要求越来越高。面对日益增加的物流配送任务, 如何提高配送速度又节省配送成本, 是当前物流运输行业必须解决的关键问题之一^[1-2]。而通过对车辆配送的各个环节进行分析, 结合智能交通系统, 对车辆配送路径进行优化, 是提高配送效率, 降低配送成本的重要方法。

国内外学者对车辆配送路径优化问题进行了大



收稿日期: 2019-07-24 修回日期: 2020-04-15;
基金项目: 湖南省教育厅科学研究重点课题(16A063);
作者简介: 范双南(1971-), 男, 湖南邵阳, 硕士, 副教授, 研究方向为算法与人工智能; 陈纪铭(通讯作者 1978-), 男, 湖南东安, 硕士, 讲师, 研究方向为人工智能; 高为民(1975-), 男, 湖南祁东, 硕士, 教授, 研究方向为人工智能。

<http://www.china-simulation.com>

• 1808 •

量的研究。Yin 等^[3]指出: 解决车辆配送路径优化问题有两类算法: 一是精确优化算法; 二是启发式优化算法。启发式优化算法具有更快的搜索效率, 能快速的找到最优路径。吴艳群等^[4]中应用模拟退火算法对满载车辆路径问题进行求解, 该方法能找到最优的路径, 但对初始值的要求很高, 易陷入局部最优。为了避免对初始值的依赖, Ma 等^[5]构造了自适应蚁群算法用于配送车辆路径优化问题的求解, 该方法具有很好的自适应性, 对于初始值的要求较低, 但是存在计算时间较长的问题。张立毅等^[6]利用改进蚁群算法解决低碳物流车辆路径优化问题, 解决了计算时间过长的的问题, 但由于算法自身的参数设置过于依靠专家经验, 因此很难获得最优的路径。此外, 考虑到最优路径的优化包含最小化车辆数、最少行驶距离等多个目标, Wang 等^[7]研究了带时间窗的物流车辆路径问题, 构建了 5 个目标模型, 设计了解析、交叉等策略的多目标局部搜索和多目标进化算法 2 种方法进行求解。Guo 等^[8]考虑路段通行时间不确定性, 构建了最小化总行程时间和碳排放量的双目标鲁棒优化模型, 采用遗传算法求解。

综上所述, 目前的车辆配送路径优化研究存在容易陷入局部最优、计算时间长、建模复杂、依赖专家经验等问题, 且未建立实时道路情况和优化模型之间的联系。基于此, 本文提出一种基于改进智能水滴算法的动态车辆配送路径优化方法。本文以最小化配送成本、最小化配送时间、最大化顾客满意度为目标, 引入软时间窗惩罚函数和顾客满意度函数, 建立车辆路径优化模型; 采用智能水滴算法对车辆路径优化模型进行求解, 并用灰狼优化算法对其进行优化, 防止陷入局部最优、避免贪婪搜索产生的次优解。实验结果表明本文方法能够取得较好的优化效果, 可以提高车辆配送的效率, 降低运输成本, 提高顾客满意度。

1 模型构建

1.1 问题描述

本文研究的车辆路径优化问题是基于实时路

况信息的单供应点对多需求点的闭合车辆路径问题。具体描述如下: 物流配送中心需要完成对顾客群体的配送任务, 在物流配送中心部署若干配送车辆, 针对不同客户群体的需求, 结合实时路况信息, 制定合适的配送方案, 安排车辆在指定的时间内送达。车辆按照制定的路线进行逐一配送, 配送完成之后返回配送中心。一辆车可配送多个配送点的任务, 但所有配送点的总需求量不超过单车的最大载货量, 且一个配送点只能由一辆车配送。配送车辆必须在顾客指定的时间窗内进行配送, 早于或晚于该时间窗都会导致顾客的满意度降低, 同时根据超出时间产生不同的惩罚费用。本文研究的车辆路径优化问题要求根据顾客需求和实时路况信息制定合理的车辆配送路径, 减小配送过程中产生的配送成本和配送时间, 同时最大化顾客满意度。

在该问题中, 配送车辆一次配送所能行驶的最大行程为 S , 单车的最大载货量为 Q , 客户的数量为 N , 配送车辆的宽度为 L , 客户 i 的需求量为 q_i , 从客户 i 到 j 的行驶时间为 t_{ij} , 客户 i 到 j 之间的距离为 d_{ij} , 集合 P_k 表示的配送过程中的第 k 条路径, 集合中的任一元素 p_{ki} 表示的是客户在第 k 条路径上的位置为 i , 配送中心的位置可以表示为 p_{ko} , 配送车辆在第 k 条路径上的速度由 V_k 表示。

1.2 车辆路径优化模型

本文研究的配送车辆路径优化问题以最小化配送成本和配送时间、最大化顾客满意度为目标, 属于多目标优化问题。本文从智能交通信息云获取车辆所在位置的实时交通信息、天气信息, 在此基础上对配送时间、配送成本和顾客满意度进行分析, 建立配送车辆路径优化模型。

1.2.1 模型分析

(1) 车辆行驶时间

假设车辆的行驶速度为 V_i , 车道的宽度为 L_{Pi} , 允许车辆通行的吨位为 Q_{Pi} , 最长的行驶距离为 S , 客户对货物的需求量为 q_i 。只有当 L_{Pi} 大于车辆自身的宽度 L 时, 且 Q_{Pi} 大于车辆的载重时, 路径 i

才会被选择,根据行驶速度的大小以及路面拥堵的情况来计算通过所需要的时间 $t_{j(j-1)}$ 。

文献[9-10]分析了不同的道路拥堵情况对配送车辆车速的影响,本文在参考上述文献研究成果的基础上,结合从智能交通信息云中获取的不同时段、不同道路状况下的车速数据,建立了不同道路状况下的车速模型,如公式(1)所示。此时车辆行驶在该条路径完成配送任务的总时间 T 的计算公式如式(2)所示:

$$V = V_{\text{con}}(1 - \mu), \mu \in [0, 1] \quad (1)$$

$$T = \sum_{j=1}^N t_{j(j-1)} \quad (2)$$

式中: V 为不同道路拥堵情况下的车辆行驶速度; V_{con} 为车辆在无拥堵道路上行驶的速度; μ 为道路拥堵对车速的影响率,在区间[0,1]之间取值,道路拥堵越严重,其取值越大。 $t_{j(j-1)} = d_{ij}/V_j$, d_{ij} 为从客户 i 到客户 j 之间的距离; V_j 为在该路径上的行驶速度。

(2) 运输成本

车辆的运输成本由 C_2 表示,其中占比最大的是运输油耗,其次还包括车辆的维修费用,配送路径越长,车辆的运输成本越高。如式(3)所示:

$$C_2 = \sum_{i=0}^n \sum_{j=0}^n c_{ij} x_{ij} \quad (3)$$

式中: c_{ij} 为从客户 i 到客户 j 之间的运输成本,并且 $c_{ij} = c_{ji}$, x_{ij} 的取值为 0 或 1,当它等于 0 时,表示配送车辆未经过该路径,等于 1 时,则表示经过了该条路径。

(3) 时间窗惩罚成本

客户对于物流配送的时间具有一定的要求,通常采用软时间窗的限制方法来实现这一要求。若是客户要求的理想时间范围内到达,则无需缴纳罚金;而超出理想配送时间,则需要承担一定的罚金。本文参考文献[11]的研究成果,建立配送车辆到达时间与惩罚成本的关系,此时产生的处罚成本用 C_3 表示,如式(4)所示。

$$C_3 = \omega_1 \sum \max[a_j - s_j, 0] + \omega_2 \sum \max[s_j - b_j, 0] \quad (4)$$

式中: ω_1 , ω_2 分别为车辆早到和晚到所带来的损

失成本; a_j, b_j 为要求到达客户 j 处的时间; s_j 为实际到达客户处的时间。

(4) 货损成本

在物流配送过程中货物可能会出现不同程度的损伤,尤其是生鲜产品容易受到运输时间和温度的影响,因此在进行成本分析是必须考虑货损成本,所以货损成本可以表示为:

$$C_4 = \sum_{i=1}^N q_i \cdot p \cdot e^{-\phi \cdot t_i} \quad (5)$$

式中: q_i 为客户 i 需要的货物量; p 为单位产品的价格; ϕ 为配送产品质量对时间的敏感度, ϕ 值越小,表示该产品对时间的敏感度越高; t_i 为货物送达配送点 i 的时间。

(5) 其他成本

运输车辆的成本还包括有驾驶员和押运员的工资和车辆损耗的成本 C_5 , $C_5 = f$ 为常数。此外,在配送时间有限制的情况下,配送过程中还会产生其它的一些费用,比如过高速时产生的费用,以及物品损耗产生的费用。该部分的成本如式(6)所示:

$$C_6 = \sum_{i=1}^m q_i m \quad (6)$$

(6) 顾客满意度

顾客满意度是物流配送环节中一个重要指标,反映了物流公司的服务水平。车辆是否按时到达、服务态度等是影响顾客满意度的主要因素,其中配送车辆在指定时间到达是最重要的因素[12-13]。本文对 200 位客户进行了满意度的问卷调查,根据顾客对配送时间的要求,建立了顾客满意度函数,其中配送车辆到达时间与顾客满意度的关系如图 1 所示,配送点 i 的顾客满意度函数如式(7)所示:

$$\xi_i(t_i) = \begin{cases} 0, & 0 < t_i < t_1 \text{ 或 } t_i > t_4 \\ 1 - \alpha_\xi \cdot (t_2 - t_i), & t_1 \leq t_i \leq t_2 \\ 1 - 1 / \exp(\beta_\xi \cdot (t_4 - t_i)), & t_3 \leq t_i \leq t_4 \\ 1, & t_2 \leq t_i \leq t_3 \end{cases} \quad (7)$$

式中: $\alpha_\xi, \beta_\xi (1/(t_2 - t_1) > \alpha_\xi > 0, \beta_\xi > 0)$ 根据顾客对配送时间的需求进行取值。




图 1 顾客满意度示意图

Fig. 1 Customer satisfaction diagram

1.2.2 模型建立

本文以最小化配送成本和时间, 最大化顾客满意度为优化目标, 建立了车辆配送路径多目标优化模型:

$$\text{Min} Z_1 = W_1 B + W_2 C \quad (8)$$

$$\text{Max} Z_2 = \sum_{i=1}^N \xi_i(t_i) / N \quad (9)$$

$$B = \sum_{j=1}^N t_{j(j-1)} + \sum_{j=1}^N t_j \quad (10)$$

$$C = C_1 + C_2 + C_3 + C_4 + C_5 + C_6 \quad (11)$$

$$\sum_{i=1}^N Q_{Pi} \leq Q \quad (12)$$

$$\sum_{i=1}^N d_{i(i-1)} \leq S \quad (13)$$

$$N_i = N_{i-1} + t_{i-1} + t_{\alpha} q_{i-1} + t_{i(i-1)}, i = 1, 2, \dots, N \quad (14)$$

$$t_i = \max\{a_i - s_i, 0\} \quad (15)$$

$$\sum_{i=1}^n \sum_{j=1}^n x_{ij} = N \quad (16)$$

$$P_i \cap P_j \neq \emptyset (i, j \in \{1, 2, 3, \dots, N\} | i \neq j) \quad (17)$$

式中: 公式(8)是模型的目标函数, 以时间和成本作为优化目标; W_1, W_2 为优化模型根据物流配送过程中的重要性赋予的权重, 公式(9)将顾客满意度作为目标函数, 公式(10)为配送的总时间, 它是车辆的行驶时间和停留等待时间之和, 公式(11)为总成本。公式(12)表示的是客户的货物需求量小于配送车辆的最大装载量。公式(13)表示的是车辆配送行驶的最大距离必须小于车辆的最大行驶距离。公式(14)表示的是车辆到达下一个客户点的时刻, 其中 N_{i-1} 为车辆到达当前客户时刻; t_{i-1} 为等待卸货时间; $t_{\alpha} q_{i-1}$ 为卸货时间; $t_{i(i-1)}$ 为到下一客户的行驶

时间。公式(15)表示的是车辆在客户处等待时间, 若到达时刻早于服务时间窗开始时刻, 则车辆在客户处等待, 到达时刻晚于服务时间窗, 则等待时间为 0。公式(16)表示的是每个客户均会被服务到。公式(17)表示的是一辆车服务一个客户。

2 算法设计

车辆配送路径优化问题是一类 NP-Hard 组合优化问题, 常用启发式算法对该类问题进行求解。相比于其他类型的启发式算法, 智能水滴算法 (Intelligent water droplet algorithm, IWD) 的全局搜索能力更加优越, 同时它的鲁棒性也很强, 在解决车辆配送路径优化问题中具有理想的寻优效果^[14-15]。但是和大部分的智能算法相似, 传统的智能水滴算法也存在一些不足, 比如算法的收敛速度较慢, 在寻优过程中容易陷入局部最优, 不能得到最优解。所以在运用的过程中必须对传统的算法进行一定的改进。此外, 智能水滴算法的另一个特点是能够与其它优化算法结合使用, 组合算法可以进一步提高全局搜索能力, 同时解决收敛速度慢、易陷入局部最优等问题^[16]。因此, 本文结合灰狼优化算法的思想, 提出了基于灰狼优化的智能水滴算法 (Intelligent water droplet algorithm based on grey wolf optimization, IWDbGWO), 对构建的优化模型进行求解。

2.1 智能水滴算法求解

智能水滴算法的基本思想是通过水滴不断的流动最终找到它的最佳路径, 河流中水滴的流动具有一定的速度, 由于泥土的阻碍, 水滴的速度会减慢; 在流动的过程中速度快的水滴会带走更多的泥土; 而水滴流动的最终轨迹往往是泥土量少的那一条路径^[17]。

水滴的速度可由 V_{IWD} 表示, 水滴携带的泥土可由 $s(i, j)$ 表示, 在水滴运动的过程中, 这 2 个值是动态变化的。把水滴从位置 i 运动到位置 j 时的速度增量用 ΔV_{IWD} 表示, 它与 i 和 j 之间的泥土量

的多少有关, 泥土越多, 速度越慢, 所以增量通常是一个负数, 其关系如式(18)所示:

$$\Delta v_{IWD} = \frac{\partial_v}{b_v + c_v s^\alpha(i, j)} \quad (18)$$

式中: a_v, b_v, c_v, α 为根据实际需求设置的参数。

水滴从位置 i 运动到位置 j 时不仅是速度发生了变化, 2 个位置间的泥土量也会随着水滴的流动发生改变, Δs_{IWD} 表示的就是水滴的泥土增量, 用 $\Delta s(i, j)$ 表示 2 个位置间泥土减少的量为 $\Delta s(i, j)$, 在不考虑其它因素的影响的情况下, 水滴的泥土增量等于 2 个位置间泥土的减少量, 即:

$$\Delta s_{IWD} = \Delta s(i, j) \quad (19)$$

式中: $\Delta s(i, j)$ 与水滴在 2 个位置间运动的时间相关, 是一种负相关的关系, 如式(20)所示:

$$\Delta s_{IWD} = \frac{a_s}{b_s + c_s t^\beta(i, j)} \quad (20)$$

式中: a_s, b_s, c_s, β 均为根据实际需求设置的参数。

水滴从位置 i 运动到位置 j 的时间与两者之间的距离呈正相关, 如式(21)所示:

$$t(i, j) = \frac{d(i, j)}{v_{IWD}} \quad (21)$$

当水滴从位置 i 运动到位置 j 后, 由于水滴带走了一部分泥土, 则这 2 个位置间的泥土量需要进行一次更新, 其计算公式如式(22)所示:

$$s(i, j) = (1 - \rho)s(i, j) - \rho\Delta s(i, j) \quad (22)$$

式中: ρ 为局部泥土更新量参数, ρ 的取值范围是 $0 < \rho < 1$ 。

智能水滴中的泥土含量也会被更新, 更新计算公式为:

$$s_{IWD} = s_{IWD} + \Delta s_{IWD} \quad (23)$$

式中: 用 $P(i, j)$ 来表示水滴在位置 i 时选择位置 j 作为下一位置的概率, 它与位置 i 与位置 j 之间的泥土量呈负相关, 如公式(24)所示:

$$P(i, j) = \frac{f(s(i, j))}{\sum_k f(s(i, k))} \quad (24)$$

式中: $f(s(i, j))$ 为与位置 i 与位置 j 之间的泥土量相关的函数, 它可表示为:

$$f(s(i, j)) = \frac{1}{\eta + g(s(i, j))} \quad (25)$$

式中: η 为一个常量, 通常取 0.01, 引入它的主要目的是避免出现函数的分母为 0 的情况, 而引入 $g(\cdot)$ 是为了确保位置 i 与位置 j 之间的泥土量为正数, $g(\cdot)$ 可表示为:

$$g(s(i, j)) = \begin{cases} s(i, j), & \min s(i, j) \geq 0 \\ s(i, j), & \min s(i, j) < 0 \end{cases} \quad (26)$$

式中: 用 E_{IWD} 表示水滴流动过程中形成的路径, 其中包括最优路径, 用 E_{IWD}^k 表示最优路径的集合。通过对最优路径的反复迭代得到最优的路径解为

$$E_{IB} = \min \{E_{IWD}^k\} \quad (27)$$

假设当前的最优路径为 E_{TB} , 可用公式(28)对它进行更新:

$$E_{IB} = \begin{cases} E_{TB}, & E_{TB} > E_{IB} \\ E_{IB} \end{cases} \quad (28)$$

当最优路径的迭代结束后, 使用公式(29)对每一条最优路径中的泥土量进行一次更新:

$$s(i, j) = (1 + \rho_{IWD})s(i, j) - \rho_{IWD} \cdot \frac{s_{IWD}}{N_{IB} - 1} \quad (29)$$

智能水滴算法求解步骤如图 2 所示。




图 2 智能水滴算法求解步骤

Fig. 2 Solution steps of intelligent drop algorithm

由图 2 可知, 求解步骤为: 首先, 初始化算法的变量和参数; 再更新水滴的位置、速度和泥土含量; 然后进入迭代, 判断迭代出的最优解是否为全局最优解; 若是全局最优解, 则更新水滴最优解的泥土含量, 输出最优解; 反之, 从第一步继续下一轮迭代, 直至达到最大迭代次数终止循环, 最终输出最优解, 即最优的车辆配送路径。

2.2 基于 GWO 的参数优化

由于智能水滴算法的收敛速度较慢, 且容易陷入早熟, 因此有必要对智能水滴算法进行优化。本文采用灰狼优化算法(Grey Wolf Optimizer, GWO)对智能水滴算法进行优化, 改善其全局搜索能力, 加快收敛速度。

GWO 算法是一种新的启发式算法, 是模仿灰狼种群的行为提出来的智能算法^[18-19]。在灰狼种群中, 根据地位等级的不同, 将所有灰狼分为 alpha、beta、delta、omega。根据类似捕食的搜索机制, 分为接近、包围和攻击猎物 3 个步骤^[20]。在本文的车辆路径优化过程中, 这 3 个步骤等同于寻找路线、接近路线和优化完成。GWO 搜索行为可以分为以下几个主要的阶段: 追踪最佳路线; 直到发现路线时靠近目标; 最后完成路径的优化。这种类似捕食行为可以使用数学模型形象地表示出来。在使用 GWO 进行优化时, 统治级的 alpha 就是最优解, 次优解则包括 beta、delta 级, 而最低级别的 omega 被看作是候选解。因此, GWO 主要由 alpha, beta 和 delta 引导, omega 等级的站点跟随其他站点。灰狼种群捕食行为应用于参数优化时的数学模型如公式(30)~(31)所示。

$$\bar{D} = |\bar{C} * \bar{X}_p - \bar{X}(t)| \quad (30)$$

$$\bar{X}(t+1) = \bar{X}_p(t) - \bar{A} * \bar{D} \quad (31)$$

式中: t 为当前迭代的代数; $\bar{X}_p$ 为目标路线所在位置; $\bar{X}$ 是一条道路所在位置; $\bar{A}$ 和 $\bar{C}$ 是系数常量, $\bar{A}$ 和 $\bar{C}$ 计算为:

$$\bar{A} = 2\bar{a} * \bar{r}_1 - \bar{a} \quad (32)$$

$$\bar{C} = 2 * \bar{r}_2 \quad (33)$$

式中: $\bar{a}$ 随着迭代次数的增加从 2 到 0 线性的减少, $\bar{r}_1$ 和 $\bar{r}_2$ 是 [0,1] 内的随机向量。为了靠近和完成最佳路线, 在不断寻找最优路线的时候, 根据计算 alpha、beta 和 delta 之间的距离, 选择距离最小的路线进行移动, 从而实现位置的更新。采用公式(34)~(38)进行位置更新:

$$\bar{D}_\alpha = |\bar{C}_1 * \bar{X}_\alpha - \bar{X}| \quad (34)$$

$$\bar{D}_\beta = |\bar{C}_2 * \bar{X}_\beta - \bar{X}| \quad (35)$$

$$\bar{D}_\delta = |\bar{C}_3 * \bar{X}_\delta - \bar{X}| \quad (36)$$

$$\bar{X} = -\bar{X}_\alpha, \bar{A}_1 - \bar{D}_\alpha = \bar{X}_2, \bar{X}_\beta = \bar{A}_2 * \bar{D}_\beta, \bar{X}_3 = \bar{X}_\delta - \bar{A}_3 * \bar{D}_\delta \quad (37)$$

$$\bar{X}(t+1) = (\bar{x}_1 + \bar{x}_2 + \bar{x}_3) / 3 \quad (38)$$

公式(34)~(38)可以确保灰狼种群到达一个比当前位置更好的点, 即找到最优的路径, 同时 alpha、beta 和 delta 可以提高水滴到达最优位置的多样性, 即解的多样性。最终确保找到的更优的路线在更好位置出现时, $\bar{X}$ 将要被替换为当前更好的位置。

3 实验仿真及结果分析

为了验证本文提出方法的有效性, 本文以恒通物流运输公司在长沙城区配送蔬菜为例, 建立车辆配送路径模型, 采用本文所提算法进行优化求解。根据物流公司对配送时间和配送成本关注度的不同, 设置不同的权重, 并分别进行实验分析。最后对比分析了本文提出 IWDbGWO 算法与改进蚁群算法^[6](Improved Ant Colony Algorithm, IAC)、改进人工蜂群算法^[8](Improved Artificial Bee Colony Algorithm, IABC)、结合模拟退火的自适应遗传算法^[12](Adaptive Genetic Algorithm embed Simulated Annealing, AGAeSA)的实验结果。实验采用 windows 10 操作系统; 内存为 4.0 GB; 使用 Matlab 7.9 软件进行仿真。

3.1 仿真设置

根据实地调研的数据设置实验参数: 客户数量为 16, 车辆最大载重为 10 t, 配送车辆的固定运营成本为 250 元, 每辆车的单位运输成本为 20 元/km,

配送车辆时间窗惩罚因子 α_c, β_c 分别为 -10、-0.05，产品单价设置为 10 元/kg，产品质量对时间的敏感度 $\phi=1/200$ ，配送车辆平均速度为 30 km/h。此外，不同道路拥堵情况对车速的影响参数 μ 在不同时段分别设置为：(0:00-07:00, 22:00-24:00) 设置为 0，(07:00-09:00, 16:00-20:00) 设置为 0.3，(09:00-16:00, 20:00-22:00) 设置为 0.2。各个配送点的顾客满意度参数 (α_c, β_c) 分别为：(0.008, 0.06)，(0.006, 0.05)，(0.005, 0.07)，(0.008, 0.05)，(0.01, 0.06)，(0.009, 0.05)，(0.006, 0.07)，(0.01, 0.07)，(0.007, 0.06)，(0.005, 0.08)，(0.01, 0.05)，(0.006, 0.06)，(0.006, 0.07)，(0.008, 0.05)，(0.005, 0.06)，(0.009, 0.07)。IWDbGWO 算法中的水滴速度更新参数 $a_v=1.00$ ， $b_v=0.01$ ， $c_v=1$ ，水滴泥土量更新参数为 $a_v=1\ 000$ ， $b_v=0.01$ ， $c_v=1$ ，局部泥土含量更新参数 $\rho=0.9$ ，全局泥土量更新参数 $\rho=0.8$ ，初始路径泥土量为 $s_{lim}=1\ 000$ ，初始水滴速度 $V_{lim}=100$ ，灰狼数目 $m=16$ ，最大迭代次数 $iter_{max}=1\ 000$ 。配送中心的坐标为(0,0)，各个客户坐标、时间窗以及服务时间如表 1 所示。

表 1 实验参数
Tab. 1 Experiment parameters

序号	客户坐标	需求量/t	服务时间窗	服务时间/min
0	12,25	0	(09:00-11:00, 16:00-17:00)	0
1	18,23	1.7	(07:00-10:00, 15:00-17:00)	15
2	7,30	1.4	(06:00-08:00, 10:00-11:30)	13
3	20,28	0.4	(09:00-16:00)	5
4	16,17	1.2	(08:00-12:00, 19:00-21:00)	10
5	4,8	2.0	(07:00-08:00, 10:00-11:00)	18
6	6,13	0.2	(06:00-07:30, 12:00-14:00)	5
7	8,16	2.1	(12:00-14:00, 05:00-06:00)	20
8	25,16	0.9	(13:00-14:00)	10
9	23,29	1.6	(07:00-10:00, 15:00-17:00)	16
10	27,10	2.5	(08:00-10:00, 19:00-21:00)	25
11	23,22	2.8	(07:00-8:00, 12:00-14:00)	30
12	24,15	3.0	(06:00-7:30, 12:00-14:00)	30
13	12,16	0.5	(08:00-12:00, 19:00-21:00)	10
14	13,8	1.6	(06:00-10:00, 13:00-16:00)	20
15	30,18	0.4	(06:30-10:30, 13:00-18:00)	8
16	26,28	1.7	(09:00-12:00, 18:00-20:00)	15

3.2 实验结果分析

对配送时间和配送成本的不同权重进行了实验，设置 2 种情况，即 $w_1=0, w_2=1$ ； $w_1=1, w_2=0$ 。

其中，情况 1 得到的最优配送车辆为 3 辆，最优路径为：0→7→4→12→10→14→6；0→2→5→13→1→3；0→15→11→16→8→9。

情况 2 得到的最优配送车辆为 4 辆，最优路径为：0→7→4→6→10；0→2→13→11→5；0→15→16→8→9；0→1→14→12→3。在得到最优路径的前提下，它们的配送成本、总里程数、配送时间如表 2 所示。

表 2 不同权重实验结果比较
Tab. 2 Comparison of experimental results with different weights

权重	最优配送车辆	配送成本	总里程数/km	配送时间/h
$w_1=0, w_2=1$	3	1 886.32	76.3	2.63
$w_1=1, w_2=0$	4	1 956.46	79.6	2.17

由表 2 可知，当以最小化配送成本为主要目标时，运行算法得到的配送成本较低，但是总里程数和配送时间并不是最优的；相反，若以最小化配送时间为主要目标，则可以得到较低的配送时间，但是配送成本和总里程数相对较高。

为了兼顾配送成本和配送时间，经过对 w_1, w_2 不同取值进行多次实验，发现当 $w_1=0.5, w_2=0.5$ 时能获得最佳的结果。因此，在相同硬件环境下，采取上面给出的相同的参数设置，分别运用本文的车辆配路径优化方法和 IAC、IABC、AGAeSA 算法对蔬菜配送实例问题进行了 100 次仿真实验，实验结果取 100 次实验的平均值。图 3~6 描述了不同算法的最优配送路径，其中每一个闭环表示一辆车承担的配送任务，不同颜色的闭环表示不同的车辆。

由图 3~6 可知，4 种不同算法的最优配送车辆均为 4 辆，而最优路径则有较大的差别。表 3 对 4 种不同算法得到的配送成本、顾客满意度、配送时间、迭代次数进行了比较。




图 3 本文算法最优路径

Fig. 3 Optimal route of algorithm in this paper




图 4 IAC 最优路径

Fig. 4 IAC Optimal Route




图 5 IABC 最优路径

Fig. 5 IABC Optimal Route




图 6 AGAeSA 最优路径

Fig. 6 AGAeSA Optimal Route

表 3 不同算法实验结果比较

Tab. 3 Comparison of experiment results of different algorithms

算法	配送车辆	总里程数/km	配送成本/元	顾客满意度	配送时间/h	迭代次数
IWDbGWO	4	78.8	1 908.35	0.989	2.35	653
IAC	4	79.9	2 036.29	0.982	2.61	687
IABC	4	80.5	2 096.51	0.984	2.65	556
AGAeSA	4	79.2	1 983.73	0.985	2.56	645

由表 3 可知, 经过多次迭代计算, 4 种算法均能得到最优的配送路径; 在配送成本方面, 本文算法 100 次实验的平均结果是 1 908.35, 相比于其它 3 种方法, 其成本分别降低了 6.2%、8.9%、3.8%。在顾客满意度方面, 本文算法具有最高的满意度, 达到 0.989, 其他 3 种方法的满意度也比较高, 总体而言, 都能达到较好的满意度。在配送时间方面, 本文算法的配送时间最少, 只有 2.35 h, 相比于其

他 3 种方法, 分别降低了 10%、11.3%、8.2%。

在迭代次数方面, IAC 算法收敛的较慢, 需要迭代 695 次才能得到最优解, IABC 在进行 556 次迭代后就寻到了最优解。综上所述, 本文算法在配送成本、配送时间、顾客满意度方面都具有优势, 在迭代次数方面性能适中。

此外, 为了更进一步验证本文方法的有效性和可行性, 本文还比较了本文算法与其它 3 种算

法的在求解最优解过程中出现的平均偏差、最大偏差、未得到最优解个数。其中平均偏差=(平均解-最优解)/最优解, 最大偏差=(最差解-最优解)/最优解, 平均解为 100 次实验的平均值。对比结果如表 4 所示。

表 4 不同算法偏差比较
Tab. 4 Comparisons of deviations between different algorithms

算法	最优解	平均解	平均偏差/%	最大偏差/%	未得到最优解个数
IWDbGWO	78.8	81.7	3.68	9.58	8
IAC	79.3	83.5	4.72	13.63	13
IABC	80.5	84.9	5.47	15.53	16
AGAEsa	79.2	82.3	4.21	17.62	11

由表 4 可知, 本文算法的平均偏差和最大偏差都最小, 同时未得到最优解的个数也最少, 因此, 相比于 IAC、IABC、AGAEsa 算法, 本文算法更加稳定和精确。综合上述分析可知, 本文所提出的算法具有较好的寻优效果, 在相同的条件下, 能够寻找到配送成本更低、配送时间更少、顾客满意度更高的车辆配送路径。上述实验验证了本文算法的可行性和有效性。

4 结论

本文针对当前物流配送领域出现的配送路径不合理、配送效率低和需求不确定性等问题, 提出一种基于改进智能水滴算法的动态车辆配送路径优化方法。该方法考虑顾客对配送时间的要求, 建立软时间窗惩罚函数和顾客满意度函数, 结合车辆配送过程的车速、货损成本、惩罚成本、顾客满意度等特征, 建立车辆配送路径多目标优化模型。采用智能水滴算法对车辆路径优化模型进行求解, 并用灰狼优化算法对其进行优化, 防止陷入局部最优、避免贪婪搜索产生的次优解。通过对应用实例的仿真实验, 将本文提出的方法与 IAC、IABC、AGAEsa 算法的实验结果进行比较和分析, 验证了本文方法的有效性。实验结果表明本文提出的方法在降低配送成本、减少配送时间、提高顾客满意

度方面具有较好的效果, 所提出的算法具有良好的应用前景。

参考文献:

- [1] Zhang Y, Zhang G, Fierro R, et al. Force-Driven Traffic Simulation for a Future Connected Autonomous Vehicle-Enabled Smart Transportation System[J]. IEEE Transactions on Intelligent Transportation Systems (S1524-9050), 2018, 19(7): 2221-2233.
- [2] Song L B. Research on Intelligent Path Planning Algorithm for Logistics Distribution Vehicles in Low-carbon Cities[J]. Journal of Advanced Oxidation Technologies (S1203-8407), 2018, 21(2): 602-609.
- [3] Yin Y, Zhang H Z. Improved Hybrid Bat Algorithm for Vehicle Routing Problem of Perishable Fresh Goods[J]. Journal of Computer Applications (S0974-1925), 2017, 37(12): 3602-3607.
- [4] 吴艳群, 董鹏. 供应链中车辆路径问题的改进模拟退火算法[J]. 计算机工程与应用, 2016, 19(12): 256-260.
Wu Yanqun, Dong Peng. An Improved Simulated Annealing Algorithm for Vehicle Routing Problem in Supply chain[J]. Computer Engineering and Application, 2016, 19(12): 256-260.
- [5] Ma C, Hao W, He R, et al. Distribution Path Robust Optimization of Electric Vehicle with Multiple Distribution Centers[J]. PLoS ONE (S1932-6203), 2018, 13(3): 189-205.
- [6] 张立毅, 王迎, 费腾. 混沌扰动模拟退火蚁群算法低碳物流路径优化[J]. 计算机工程与应用, 2017, 10(1): 63-68.
Zhang Liyi, Wang Ying, Fei Teng. Chaos Disturbance Simulated Annealing Ant Colony Algorithm for Low Carbon Logistics Path Optimization[J]. Computer Engineering and Application, 2017, 10(1): 63-68.
- [7] Wang J, Ying Z, Yong W, et al. Multiobjective Vehicle Routing Problems with Simultaneous Delivery and Pickup and Time Windows: Formulation, Instances and Algorithms[J]. IEEE Transactions on Cybernetics (S2168-2267), 2016, 46(3): 582-594.
- [8] Guo M, Ma C, He Y. Study on the Routing Optimization of Pickup & Delivery Vehicles under Road Travel Time Uncertainty[J]. Western China Communications Science & Technology (S1673-4874), 2017, 25(12): 100-105.
- [9] 叶威惠, 张飞舟. 真实路况下的快递配送路径优化研究[J]. 计算机工程与科学, 2017(8): 143-150.
Ye Weihui, Zhang Feizhou. Research on the Optimization of Express Delivery Distribution Path under

- Real Road Conditions[J]. Computer Engineering and Science, 2017(8): 143-150.
- [10] 郭琪, 韦金银, 郭鹏祥. 考虑实时路况下的商砼配送路径优化研究[J]. 软件工程, 2019, 22(4): 33-36.
Guo Qi, Wei Jinyin, Guo Pengxiang. Research on the Optimization of Commercial Concrete Distribution Route Considering Real-time Traffic Conditions[J]. Software Engineering, 2019, 22(4): 33-36.
- [11] Chai H, He R C, Ma C Q, et al. Path Planning and Vehicle Scheduling Optimization for Logistic Distribution of Hazardous Materials in Full Container Load[J]. Discrete Dynamics in Nature and Society (S1026-0226), 2017(1): 1-13.
- [12] 王恒, 徐亚星, 王振锋. 基于道路状况的生鲜农产品配送路径优化[J]. 系统仿真学报, 2019, 31(1): 126-135.
Wang Heng, Xu Yaxing, Wang Zhenfeng. Optimization of Fresh Produce Distribution Routes Based on Road Conditions[J]. Journal of System Simulation, 2019, 31(1): 126-135.
- [13] 葛显龙, 薛桂琴. 不确定环境下多品类共同配送路径优化[J]. 计算机工程与应用, 2019, 55(9): 270-276.
Ge Xianlong, Xue Guiqin. Optimization of Multi-category Common Distribution Path in Uncertain Environment[J]. Computer Engineering and Application, 2019, 55(9): 270-276.
- [14] Sun M Q, Pang D Z. Vehicle Routing Optimisation Algorithm for Agricultural Products Logistics Distribution[J]. International Journal of Applied Decision Sciences (S1755-8077), 2017, 10(4): 327-334.
- [15] Zhang Q, Xiong S Q. Routing Optimization of Emergency Grain Distribution Vehicles Using the Immune Ant Colony Optimization Algorithm[J]. Applied Soft Computing Journal (S1568-4946), 2018, 71(18): 917-925.
- [16] Kayvanfar V, Zandieh M, Teymourian E. An Intelligent Water Drop Algorithm to Identical Parallel Machine Scheduling with Controllable Processing Times: A Just-in-time Approach[J]. Computational & Applied Mathematics (S0101-8205), 2017, 36(1): 159-184.
- [17] Alijla B O, Lim C P, Wong L P, et al. An Ensemble of Intelligent Water Drop Algorithm for Feature Selection Optimization Problem[J]. Applied Soft Computing (S1568-4946), 2018, 65(12): 531-541.
- [18] 王敏, 唐明珠. 一种新型非线性收敛因子的灰狼优化算法[J]. 计算机应用研究, 2016(12): 3648-3653.
Wang Min, Tang Mingzhu. A Gray Wolf Optimization Algorithm with a New Nonlinear Convergence Factor[J]. Computer Application Research, 2016(12): 3648-3653.
- [19] Li Q, Chen H L, Huang H, et al. An Enhanced Grey Wolf Optimization Based Feature Selection Wrapped Kernel Extreme Learning Machine for Medical Diagnosis[J]. Computational and Mathematical Methods in Medicine (S1748-670X), 2017, 20(5): 1-15.
- [20] Emary E, Zawbaa H M, Grosan C. Experienced Gray Wolf Optimization Through Reinforcement Learning and Neural Networks[J]. IEEE Transactions on Neural Networks and Learning Systems (S2162-237X), 2018, 29(3): 681-694.