

考虑驾驶习惯的电动车路径规划研究

张颖严, 刘媛华*, 张 顺

上海理工大学管理学院, 上海

收稿日期: 2024年11月19日; 录用日期: 2024年12月20日; 发布日期: 2024年12月31日

摘 要

在电动车辆路径优化问题中,考虑驾驶员个性化驾驶习惯能够有效提升路径规划的适用性与用户满意度。不同驾驶员在加速、减速、速度选择及路线偏好方面存在显著差异,而这些驾驶习惯直接影响到电动车的能耗、行驶时间及充电需求。为了实现个性化的路径优化,本文提出了一种基于改进最大最小蚂蚁系统(Min Max Ant System)的求解方法,将驾驶员的驾驶特征(如急加速频率、平均速度、路线偏好等)融入优化模型中,从而更加准确地预测能耗和最佳路径。以自适应大邻域搜索算法(Adaptive Large Neighborhood Search)为改进方法的IMMAS算法来求解该车辆路径规划模型,通过随机破坏贪心修补,多次试验来确保算法的稳定性。实验结果表明,改进后的最大最小蚂蚁系统在电动车辆个性化路径优化问题上表现出较好的求解效率和适应性,与传统算法相比,在能耗、行驶时间和驾驶员偏好方面均表现出显著优势。该研究为电动车辆智能路径优化提供了新的方法和思路,有助于未来智能交通系统的个性化发展。

关键词

驾驶习惯, 最大最小蚂蚁系统, 电动车辆路径问题, 个性化因素, 自适应大邻域搜索

Research on Path Optimization of Electric Vehicles with Integrated Driving Styles

Haoyan Zhang, Yuanhua Liu*, Shun Zhang

Business School, University of Shanghai for Science and Technology, Shanghai

Received: Nov. 19th, 2024; accepted: Dec. 20th, 2024; published: Dec. 31st, 2024

Abstract

In the optimization problem of electric vehicle paths, considering the personalized driving style of drivers can effectively improve the applicability and user satisfaction of path planning. There are significant differences in acceleration, deceleration, speed selection, and route preferences among

*通讯作者。

文章引用: 张颖严, 刘媛华, 张顺. 考虑驾驶习惯的电动车路径规划研究[J]. 理论数学, 2024, 14(12): 186-197.

DOI: 10.12677/pm.2024.1412420

different drivers, and these driving styles directly affect the energy consumption, travel time, and charging requirements of electric vehicles. In order to achieve personalized path optimization, this paper proposes a solution method based on the improved Min Max Ant System, which integrates the driving style characteristics of the driver (such as acceleration frequency, average speed, route preference, etc.) into the optimization model to more accurately predict energy consumption and optimal path. The IMMAS algorithm, improved by the Adaptive Large Neighborhood Search algorithm, is used to solve the vehicle path planning model. The stability of the algorithm is ensured through random damage greedy repair and multiple experiments. The experimental results show that the improved maximum minimum ant system exhibits good efficiency and adaptability in solving personalized path optimization problems for electric vehicles. Compared with traditional algorithms, it shows significant advantages in energy consumption, travel time, and driver preferences. This study provides new methods and ideas for intelligent path optimization of electric vehicles, which will contribute to the personalized development of future intelligent transportation systems.

Keywords

Driving Style, Maximum Minimum Ant System, Electric Vehicle Routing Problem, Personalized Factors, Adaptive Large Neighborhood Search

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

电动车辆路径规划在现代物流运输和智慧城市中具有重要的应用价值。相比传统燃油车辆，电动车辆因使用电能驱动，具有低碳、环保的优势，能有效减少碳排放。然而，电动车辆普遍面临续航里程有限、充电站分布不均、充电时间长等问题，因此高效的路径规划显得尤为关键。合理的路径规划不仅能减少行驶距离，降低电耗，还能帮助电动车辆在能源有限的情况下最大化覆盖配送任务，从而提升运营效率。在物流运输需求急剧增加的背景下，优化电动车辆的路径可有效降低配送成本，提升物流配送的可持续性。此外，电动车辆路径规划是解决智慧城市中交通拥堵和资源调度问题的有效手段，通过合理的路径安排可以减少高峰期交通压力，并降低城市总体能耗。带时间窗的路径规划问题(如EVRP-TW)还需兼顾客户的时间要求，使得规划问题更加复杂，但也是实现高效和满足客户需求的重要手段。因此，电动车辆路径规划对提高能源利用效率、减少环境污染和提升物流行业的智能化水平具有重要意义。

电动车辆路径规划问题(Electric Vehicle Routing Problem, EVRP)是一个典型的多目标问题，需要优化诸如配送路径短及配送费用低等目标。现实情况下，同时优化设定的所有目标是矛盾的，所以在该领域有较多的研究空间。在以往的研究中，不同学者对如何实现最短路径，降低求解时间上给出了很多方案，文献[1]设计了包括杂交蚁群优化和人工蜂群算法的两阶段求解方法，对目标进行标量化，得出了更合理的折中解。文献[2]提出了一种基于二维编码方案的扩展的自适应大邻域搜索算法，集成多个移除和插入算子并将可变邻域下降与之结合，进一步提高算法性能。文献[3]设计了一种混合人工蜂群算法对环境电动车辆路径问题进行求解，并得出改进后的算法比原算法平均性能高出5%。可以看出由于精确算法只适合于规模较小的EVRP问题，所以启发式算法是更适用于该问题的解法。

降低电动车辆的运营成本，是电动车辆路径规划最为重要的目标之一。在如何控制成本，使得电动

车辆成为更适配运输的工具上,不同的学者给出了不同的解法。不同驾驶员在加速、刹车、匀速行驶的偏好上存在显著差异,这些行为将影响电量消耗,进而影响路径的实际能效表现。例如,偏向急加速的驾驶习惯会增加瞬时能耗,使得车辆电量快速下降,而平稳驾驶则有利于节能和延长续航。因此,路径规划中引入驾驶员驾驶习惯,有助于更准确地预测电动汽车的实际能耗,并设计出更符合驾驶员习惯的节能路径。驾驶习惯对于路径规划的研究有重要的意义,不同学者对驾驶习惯进行深刻研究后,取得有意义的成果。文献[4]分析并设计了路径行驶时间、路径转弯次数以及路径节点周期长度三种影响驾驶行为的关键因素的归一化计算方法;最终,通过综合评分法确定车辆在相邻检测点之间的最可能行驶路径。文献[5]针对不同驾驶员的驾驶习惯,对自动变速器的换挡策略进行适应性优化。在分析驾驶员操控行为的基础上,提出了一种基于相空间重构和驾驶习惯评价指数的驾驶习惯识别方法,以实现驾驶习惯的精准识别。文献[6]开发了一种用于驾驶行为分割和聚类的两步算法,该算法基于8个动作状态变量对跟车行为进行分割和聚类,并根据状态和动作聚类的结果定义驾驶员的驾驶模式。文献[7]使用多层感知器、SVM、随机森林和贝叶斯网络等四种算法来识别攻击性驾驶行为模式(快速变道、转弯、制动、加速等),文献[8]使用包括加速度、重力、油门、速度和每分钟转数(RPM)在内的参数来识别五种类型的驾驶方式,包括正常、激进、分心、昏昏欲睡和酒后驾驶。

研究驾驶习惯与路径规划具有重要意义,这是智能交通、驾驶辅助系统以及自动驾驶技术发展的关键需求。驾驶习惯是驾驶员长期驾驶过程中形成的独特行为模式,包括加速、刹车、转向等操作特征,这些习惯直接影响驾驶安全性、车辆能耗和交通流效率。而路径规划作为车辆行驶的重要环节,其合理性不仅决定了行驶效率,还会潜移默化地影响驾驶员的操作行为。因此,将驾驶习惯与路径规划相结合,不仅能够优化驾驶体验,还能为智能驾驶技术提供更加个性化的解决方案。研究驾驶习惯与路径规划可以提升驾驶安全性。通过分析驾驶员的习惯,可以识别潜在的危险行为,并结合路径规划提供更加安全的行驶方案。例如,针对倾向于急刹车的驾驶员,系统可以优先规划急弯较少的路径,从而降低事故风险。在推动智能驾驶技术方面,结合驾驶习惯的路径规划可以帮助系统更好地适应不同驾驶员的个性化需求。这不仅提高了人机协同的效果,也增强了驾驶员对智能系统的接受度。而在缓解交通拥堵方面,考虑驾驶习惯的路径规划能够平衡道路资源分配,减少因驾驶行为差异引发的交通波动。

2. 问题描述

在电动汽车(EV)路径规划问题中,驾驶习惯对路径的选择、续航管理和能耗预测有影响。传统路径规划算法主要考虑最短路径或最快路径,在电动车辆的情境下,需要额外关注电池续航里程和充电站分布,而驾驶员的驾驶习惯会直接影响这些因素,进而影响路径规划的结果。

具体而言,驾驶习惯(如急加速、急减速、超速频率和平稳驾驶指数)会影响电动车辆的能耗速率。频繁的快速加速和急剧减速会导致能源消耗增加。进而缩短车辆的实际续航里程。这种能耗波动会使得续航里程的预测更具不确定性,增加了路径规划的难度。另一方面,如果驾驶员习惯平稳驾驶,则可能获得更接近理论值的续航表现,从而扩大路径规划的选择范围。

此外,驾驶习惯还会影响充电策略的制定。对续航要求较高的路线中,急加速和急减速会增加电池的消耗,可能需要更频繁地规划到充电站充电,从而增加了行驶时间和路径复杂度。因此,为了实现更高效的路径规划,应考虑构建一种包含驾驶习惯的动态能耗模型,将驾驶习惯和实际能耗关系量化,进而对路径选择、充电站布点和电池续航管理提供支持,使路径规划更加精准、可靠。

本文将驾驶员行驶的影响因素分为以下几个方面来确定驾驶员的行驶习惯:

1) 加速和减速

加速率(a_{avg})可以很好的反映驾驶员的加速习惯,其通过每次加速的平均加速的来量化。

$$a_{avg} = \frac{1}{n} \sum_{i=1}^n \frac{v_i - v_{i-1}}{t_i - t_{i-1}} \quad (1-1)$$

其中, v_i 和 v_{i-1} 表示第 i 次和第 $i-1$ 次的速度, $t_i - t_{i-1}$ 表示两次速度变化的时间间隔, n 为总次数。

急加速频率(f_{acc})和急减速频率(f_{brake})分别反映驾驶员是否倾向于突然加速和是否频繁急刹车, 可以通过定义阈值来计算其频率, 计算方法如下:

$$f_{acc} = \frac{\text{急加速次数}}{\text{总加速次数}} \quad (1-2)$$

$$f_{brake} = \frac{\text{急减速次数}}{\text{总减速次数}} \quad (1-3)$$

2) 超速频率

平均速度(v_{avg})为基本驾驶习惯量化指标, 反映驾驶员整体速度偏好。

$$v_{avg} = \frac{1}{T} \int_0^T v(t) dt \quad (1-4)$$

其中 T 为总行驶时间, $v(t)$ 为 t 时刻的速度。超速频率(f_{over})则反映驾驶员是否经常超速, 通过超速时间占比可以将其量化。

$$f_{over} = \frac{t_{over}}{T} \quad (1-5)$$

其中 t_{over} 为超速时间。

3) 路线偏好

尽管作为多目标优化问题, 驾驶员路线偏好可能与路径优化存在偏差。但在实际应用场景中, 驾驶员的路线偏好往往可以进一步优化路径, 因此也可进一步通过权重来体现路线偏好。可以用不同的路况比例来量化这一偏好:

$$p_{urban} = \frac{t_{urban}}{T} \quad (1-6)$$

$$p_q = \frac{t_q}{T} \quad (1-7)$$

其中 p_{urban} 为城市道路偏好, t_{urban} 为城市道路行驶时间, p_q 为高速道路偏好, t_q 为高速道路行驶时间。

4) 平稳驾驶指数

为判断驾驶员行驶是否平稳引入以下两个指数。加速度标准差(σ_a)反应加速度的波动性, 标准差越小, 驾驶越平稳。

$$\sigma_a = \sqrt{\frac{1}{n} \sum_{i=1}^n (a_i - a_{avg})^2} \quad (1-8)$$

转向平稳性(S)通过方向盘转角变化的标准差来判断平稳性, 方向盘转角波动越小说明驾驶员在转弯或变道时更平稳。

$$S = \sqrt{\frac{1}{n} \sum_{i=1}^n (\theta_i - \theta_{avg})^2} \quad (1-9)$$

其中, θ_i 是第 i 次的方向盘转角, θ_{avg} 为平均方向盘转角。

通过研究以上参数我们可以识别出几种基本的驾驶员行驶风格如表 1:

Table 1. Recognition of driving habits
表 1. 驾驶习惯识别

驾驶习惯	风格特点
平稳型	急加速/减速频率较少, 车辆速度和加速度变化较慢, 方向盘变化夹角较小
标准型	急加速/减速频率适中, 车辆速度和加速度变化适中, 方向盘变化夹角适中
激进型	急加速/减速频率较多, 车辆速度和加速度变化较快, 方向盘变化夹角较大

通过表 1 的驾驶员行为初步得到其与电动车辆路径优化之间的关系。在驾驶员的行驶习惯中, 不同的驾驶习惯会间接或直接影响行驶成本。急加速和急减速会增加燃油消耗加快车辆磨损; 而超速行驶会增加燃油消耗且可能导致交通罚款; 选择城市道路会比高速公路增加燃油消耗; 平稳驾驶会减少燃油消耗, 降低车辆维修成本。因此将每一项驾驶习惯赋予费用增量因子, 通过这些因子计算总的行驶费用。式(1-10)、(1-11)和(1-12)表示在驾驶员行驶习惯影响下, 对成本的影响。

$$C_{total} = P_{fuel} + C_{wear} + F_{over} \quad (1-10)$$

$$P_{fuel} = (E_{fuel} \times (1 + f_{acc} + f_{break} + f_{over})) \times P_{fuel} \quad (1-11)$$

$$C_{wear} = c_{wear} \times (1 + f_{acc} + f_{break}) \quad (1-12)$$

3. 模型建立

3.1. 符号说明

为了方便表述, 相关符号说明分为集合、参数和变量表格见表 2~4:

Table 2. Point set
表 2. 点集

符号	说明
N	点集合($i = 0, 1, 2, 3, \dots, n$), 其中 0 为配送中心
R	充电站集合
Z	$Z = \{0\} \cup N \cup R$
K	车队的车辆集合($k \in K$)

Table 3. Parameters
表 3. 参数

符号	说明
d_{ij}	客户 i 到客户 j 的距离(km)
t_{ij}	客户 i 到客户 j 的行驶时间(h)
s_i	客户点 i 的服务时间(h)
g_v	电量消耗率(kWh/km)
g_r	充电桩充电速率(Wh/h)
w_r	单位电量费用(元/kWh)
α	电池衰减因子
β	充电量上限系数

续表

B	电动汽车电池最大容量(kWh)
Q	车辆最大负载(kg)
c	车辆固定成本(元/辆)
m	单位距离耗电成本(元/km)
m_1 、 m_2	表示违反时间窗的惩罚成本(元)
P_{fuel}	燃油价格
P_{fuel}	燃油成本
E_{fuel}	燃油效率
C_{wear}	每公里基本磨损成本
F_{over}	罚款成本
C_{total}	综合成本

Table 4. Variables

表 4. 变量

符号	说明
p_i	车辆到达客户 i 时的载重量(kg)
t_a	车辆到达点 i 的时间
t_l	车辆离开点 i 的时间
q_i	客户点 i 的需求(kg)
$[e_i, l_i]$	客户 i 服务时间窗
τ_i	车辆到达客户点 i 的时间(min)
h_i	电动汽车到达客户点 i 时的剩余电量(W)
h'_i	电动汽车离开客户点 i 时的剩余电量(W)
r_i	电动汽车在充电桩 i 的电量(kWh)
T_i	电动汽车在充电桩 i 的充电时间(h)
x_{ijk}	0-1 变量, 车辆 k 从 i 驶向 j 时为 1, 否则为 0
y_i	0-1 变量, 电车 k 在 i 处充电为 1, 否则为 0
z_{ik}	当车辆 k 在充电站 i 处进行充电时取值为 1, 否则为 0, $k \in K$, $i \in R$

3.2. 建立目标函数及模型

多目标问题的目标函数应当是各目标最优解的总和。假设车辆电池容量限制、充电站位置和数量、充电时间和速率、电能消耗率、车辆的初始电量、车辆和客户数已知, 那么各成本的表示情况如下。固定成本与从配送中心处出发的车辆总数和每辆车的固定使用成本有关, 即出发就会产生的车辆成本, 用 C_1 表示; 行驶成本为 EV 在行驶过程中产生的费用, 与行驶距离线性正相关, 考虑城市配送, 可能面临的如拥堵等状况, 选择单位耗电能为较为准确的计算行驶成本, 用 C_2 表示; 目前 EV 的电池容量仍是 EVRP 问题的主要限制因素, 充电成本为当 EV 无法完成配送时, 途中的充电费用, 用 C_3 表示; 电池损耗是 EV 不可避免的问题, 快速充电技术的发展造成的电池发热会对电池寿命造成更大的影响。配送时要考虑到时间窗的约束, 所以早到或者晚到节点都属于违反时间窗的约束, 因此给出时间窗惩罚成本, 其用 C_4 表示。

各成本表示如下:

$$C_1 = c \sum_{k \in K} \sum_{(i,j) \in A} x_{ijk} d_{ij} \quad (2-1)$$

$$C_2 = m \sum_{k \in K} \sum_{(i,j) \in A} x_{ijk} d_{ij} \quad (2-2)$$

$$C_3 = w_r \sum_{k \in K} \sum_{(i,j) \in A} x_{ijk} d_{ij} g_v \quad (2-3)$$

$$C_4 = m_1 t_a + m_2 t_l \quad (2-4)$$

所以, 目标函数公式为:

$$\min F = C_1 + C_2 + C_3 + C_4 \quad (2-5)$$

约束条件为:

$$\sum_{i \in N, i \neq j} \sum_{k \in K} x_{ij} = 1, \forall j \in Z \quad (2-6)$$

$$\sum_{k \in K} x_{0jk} \leq K, \forall j \in N \quad (2-7)$$

$$\sum_{k \in K} \sum_{i \in Z, i \neq j} x_{ijk} = \sum_{k \in K} \sum_{i \in Z, i \neq j} x_{jik}, \forall j \in Z \quad (2-8)$$

$$\sum_{i \neq j} \sum_{k \in K} q_i x_{ijk} \leq Q, \forall i \in N, j \in Z \quad (2-9)$$

$$p_j \leq p_i - q_i x_{ijk} + Q(1 - x_{ijk}), \forall i, j \in N \quad (2-10)$$

$$e_i \leq \tau_i \leq l_i, \forall i \in N \quad (2-11)$$

$$\tau_j \geq \tau_i + (t_{ij} + s_i) x_{ijk} - l_0 (1 - x_{ijk}), \forall i, j \in N \quad (2-12)$$

$$\tau_j \geq \tau_i + t_{ij} x_{ijk} + T_i y_i - l_0 (1 - x_{ijk}), \forall i \in R, j \in \{0\} \cup N \quad (2-13)$$

$$h_j \leq h_i - d_{ij} g_v x_{ijk} + B(1 - x_{ijk}), \forall i \in N, j \in Z \quad (2-14)$$

$$h_j \leq h'_i + r_i y_i - d_{ij} g_v x_{ijk} + B(1 - x_{ijk}), \forall i \in N, j \in Z \quad (2-15)$$

$$0 \leq h_i \leq \beta B, \forall i \in \{0\} \cup N \quad (2-16)$$

$$0 \leq h_i + r_i \leq B, \forall i \in R \quad (2-17)$$

$$h_i = h'_i, \forall i \in N \quad (2-18)$$

$$T_i = r_i / g_r, \forall i \in R \quad (2-19)$$

$$x_{ijk} \in \{0, 1\}, \forall i, j \in Z \quad (2-20)$$

$$y_i \in \{0, 1\}, \forall i \in Z \quad (2-21)$$

$$G_k \in \{0, 1\}, \forall k \in K \quad (2-22)$$

其中, 目标函数式(2-5)表示车队配送成本的最小值。约束式(2-6)表示每个客户只被服务一次; 约束式(2-7)规定使用的车辆数不超过车队车辆的总数, 约束式(2-8)为流量的平衡, 即每辆车进入节点的次数等于其离开的次数; 约束式(2-9)限制车辆载重不能超过额定载荷; 约束式(2-10)、表示车辆在两相邻客户之间的载重量约束; 约束式(2-11)表示服务时间满足客户时间窗约束; 约束式(2-12)表示相邻的两个客户之间的时间窗约束, 约束式(2-13)为电动汽车在访问充电站后的时间窗约束; 约束式(2-14)、式(2-15)分别表示电动汽车在离开客户点和充电站后的电池电量约束; 约束式(2-16)和约束式(2-17)分别表示

电动汽车在行驶和充电中的电量约束，为避免过度充电损伤电池，设置充电量上限；约束式(2-18)表示电动汽车在服务客户中不消耗电量；约束(2-19)为充电时间的计算公式；约束式(2-20)、式(2-21)和式(2-22)表示 0-1 变量。

4. 求解算法设计

4.1. 改进算法

4.1.1. 最大最小蚂蚁系统

最大最小蚂蚁系统通过步骤上的变化，使其变成蚂蚁算法的科学改进方法，流程上具有以下步骤：

- 1) 每次迭代只有最优蚂蚁或当前迭代最佳蚂蚁更新信息素，来增加对所选解决方案的利用。
- 2) 具有一种简单的机制来避免过早收敛，即限制给定定点中的信息素数量在最大值和最小值之间。
- 3) 信息素轨迹被初始化为他们的最大值 τ_{\max} ，使得在算法开始时实现对解决方案的更高探索。

4.1.2. 自适应大邻域搜索算法

为了进一步确保路径问题取得最优值，引入自适应大邻域搜索算法的思想对已取得的最优解进行进一步的优化。ALNS 算法是一种启发式优化算法，结合局部搜索和大邻域搜索的特点，即随机破坏和贪心修补。表现好的破坏和修补方法会获得更高的权重，进而得到一种高效的组合方法，在初始解(即 MMAS 求得解)的基础上找到更为准确解，提高算法寻优能力及准确度。

4.2. 算法更新规则

4.2.1. 转移概率

在 MMAS 中蚂蚁由客户 i 转移到客户 j 转移概率如下：

$$p_{ij} = \begin{cases} \frac{[\tau_{ij}]^\alpha [\eta_{ij}]^\beta}{\sum_{l \in L_i} [\tau_{il}]^\alpha [\eta_{il}]^\beta}, & \text{若 } j \in L_i \\ 0, & \text{否则} \end{cases} \quad (3-1)$$

其中 τ_{ij} 为跟踪的信息素强度和 $\eta_{ij} = 1/d_{ij}$ 为客户 j 到客户 i 的接近度，也称为启发式信息。 α 、 β 分别是确定信息素强度和启发式信息相对重要性的参数。 L_i 是蚂蚁尚未访问的客户集，同时位于客户 i 的位置。

4.2.2. 最大最小信息素值

为了避免停滞和过早收敛，MMAS 限制了信息素轨迹中信息素的量在范围内。通过适当选择 τ_{\min} 和 τ_{\max} 的值，使得所有顶点都有被选中的机会。初始化信息素为 τ_{\max} ，以增加算法早期迭代的探索性。该范围的限制由以下公式给出：

$$\tau_{\max} = \frac{1}{\rho \cdot C_{best}} \quad (3-2)$$

$$\tau_{\min} = \tau_{\max} \cdot X \quad (3-3)$$

其中 ρ 是信息素的挥发率，通常取值在(0,1)范围内， C_{best} 是在所有迭代中发现的最优解的成本，而 X 是一个用户指定的小于 1 的因子，用于确定最小信息素值与最大信息素值之间的比例关系。

4.2.3. 信息素更新

在所有蚂蚁构建了解决方案之后，所有信息素轨迹的浓度都会以常数因子 ρ 降低，模拟蒸发过程。

随后, 迄今为止的最优解蚂蚁在其所经过的顶点上沉积信息素。沉积的信息素量是迄今为止解决方案成本 C_{BSF} 的倒数。更新规则如下所示:

$$\tau_{ij}^{new} = (1 - \rho) \tau_{ij}^{old} + \Delta \tau_{ij}^{BSF} \quad (3-4)$$

$$\Delta \tau_{ij}^{BSF} = 1/C_{BSF} \quad (3-5)$$

4.3. 随机破坏和贪心修补规则

考虑到应用该规则取得最优解, 因此将此规则应用到 MMAS 算法取得的解上。即本步骤优化过程从 MMAS 取得的历史最优解上进一步优化。随机破坏和贪心修补步骤可重复多次, 考虑到破坏的随机性, 改进后的 MMAS 算法每次迭代需要进行五次的随机破坏, 每次随机破坏一直五个随机节点, 之后以路程最短为准则, 在邻域内探查有无小于或等于当前路径长度的解, 若有, 则进行贪心修补, 得到新的优化路径。经实验验证, 该策略极大地提高了搜索空间, 对比其他邻域搜索提高了收敛速度和算法的准确性。

5. 算例分析

本节进行了仿真实验及结果分析。实验环境基于 MATLAB R2023a 平台。选取 Solomon 数据集, 根据 K-means 聚类取得充电站坐标。为了方便展示取 Solomon-50 数据集, 即包含 50 个节点。另外 0 为车场, 51 至 55 表示充电站, 56 为距离车场较近的用于分时充电的充电站, 具体参数见表 5。

Table 5. Algorithm parameters

表 5. 算法参数

名称	参数	单位
车辆续航里程	280	km
车辆最大装载	400	kg
车辆使用成本	100	元
单位运费	5	元/km
单位距离电量消耗	1	kW·h/km
行驶速度	50	km/h
车辆最大使用数	5	辆
迭代次数	500	
电量消耗率	0.15	kWh/km
充电桩充电速率	150	kWh/h
单位电量费用	1.3	元/kWh
充电量上限系数	0.9	
电动汽车电池最大容量	80	kWh
车辆固定成本	500	元/辆
单位距离耗电成本	0.3	元/km
时间窗成本(早、晚)	10, 20	元

为突出驾驶习惯对求解结果的影响, 本节在保持其他所有模型参数不变的条件下, 假设仅有六位司

机完成当前配送任务,并设定这六位司机驾驶习惯比例在以下六种情形下变化:1. 所有司机均为平稳型;2. 所有司机均为标准型;3. 所有司机均为激进型;4. 平稳型:标准型:激进型 = 2:1:1;5. 平稳型:标准型:激进型 = 1:2:1;6. 平稳型:标准型:激进型 = 1:1:2,基于这6种情形,分别参照式(1-10)、(1-11)和(1-12)对成本进行进一步计算,结果如表5所示。

由于启发式算法具有近似性,因此在设计算法时,算法运行五次,每次输出结果为五次迭代完成的平均值,表中给出的平均值为5次迭代后平均值。下面是基本蚁群算法(Ant Colony Algorithm, ACA),最大最小蚂蚁系统(MMAS),自适应大邻域搜索算法改进的最大最小蚂蚁系统(IMMAS)的五次输出结果及平均值、最优最差结果及标准差,详细数据见表6。

Table 6. Algorithm comparison and corresponding costs under different scenarios

表 6. 算法对比及不同情形下对应成本

	ACA	MMAS	IMMAS	情形 1	情形 2	情形 3	情形 4	情形 5	情形 6
1	8426.5	8301.2	8061.8	8045.2	7835.1	7801.3	7822.4	7922.8	7985.6
2	8573.6	8467.0	7849.3	8073.4	7855.8	7818.9	7895.7	7909.2	8002.1
3	8327.2	8196.9	7891.1	8052.6	7848.2	7807.4	7887.9	7915.0	7993.8
4	8507.3	8335.9	7812.7	8068.9	7852.3	7815.6	7893.2	7927.6	7998.4
5	8496.7	8237.0	7996.7	8070.9	7844.9	7820.2	7896.2	7923.9	8003.6
平均	8466.3	8307.6	7922.3	8061.8	7849.3	7812.7	7891.1	7905.2	7996.7
最优	8327.2	8196.9	7812.7	8045.2	7835.1	7801.3	7882.4	7909.2	7985.6
最差	8573.6	8467.0	8061.8	8073.4	7855.8	7820.2	7896.2	7927.6	8003.6

尽管 ACA 在许多场景中表现良好,但在某些问题实例上性能往往不如最大最小蚂蚁系统。MMAS 是一种改进的蚁群优化算法,能有效地避免信息素过度集中,促进了解空间的全面检索。进一步结合自适应大邻域搜索的 MMAS 即 IMMAS 在性能上又超越了 MMAS。IMMAS 通过在每次迭代中实施随机破坏和贪心修补策略,进一步增强了解的多样性和搜索深度。每次随机破坏移除部分节点,再通过贪心策略修补解,能有效打破局部最优陷阱,使得算法能够更全面地探索解空间。对比 MMAS 算法,IMMAS 算法得到的成本无论是最优值、最差值或平均值都要更优且标准差更小。在多次测试和实验中,IMMAS 不仅比 MMAS 更快地收敛,而且其解质量也更优越,能够找到更低成本的解决方案。综上,随着问题复杂度的增加,IMMAS 逐渐显现出其在处理复杂优化问题中的优势,成为一种更加有效的优化策略,MMAS 与 IMMAS 算法求得路线分别如图 1、图 2 所示。

在图 1 和图 2 中,红色向量表示未中途充电车辆的行驶路线,蓝色向量表示中途充电车辆行驶路线,在经过随机破坏和贪心修补后的算法得出的路线较为平滑,更适用于实际情况。

根据表 5 得,不同驾驶员风格对电动汽车路径优化(EVRP)的成本有显著影响。通过模拟六种驾驶员风格分布情形发现,当所有驾驶员均为冷静型时,配送成本最高,表明冷静型驾驶员的平稳驾驶方式虽然节约了能源消耗,但由于行驶时间较长,可能增加了部分时间相关成本;标准型驾驶员的成本次之,表明其驾驶风格在效率和节能之间取得了一定平衡;激进型驾驶员的配送成本最低,尽管其风格增加了耗能和维修成本,但快速完成配送任务的能力显著降低了时间相关成本。此外,在混合驾驶风格情形中,冷静型、标准型和激进型的比例对成本的影响不同,比例偏向标准型时的配送成本较低,表明适当的风格混合能实现更优的平衡。因此,综合驾驶风格和路径规划优化可以有效控制配送成本,提高电动汽车配送的经济性和效率。

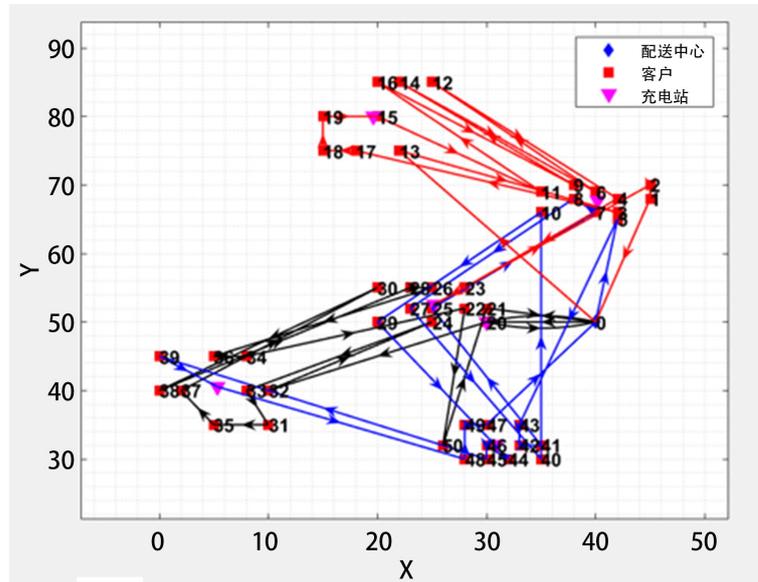


Figure 1. MMAS solution roadmap

图 1. MMAS 求解路线图

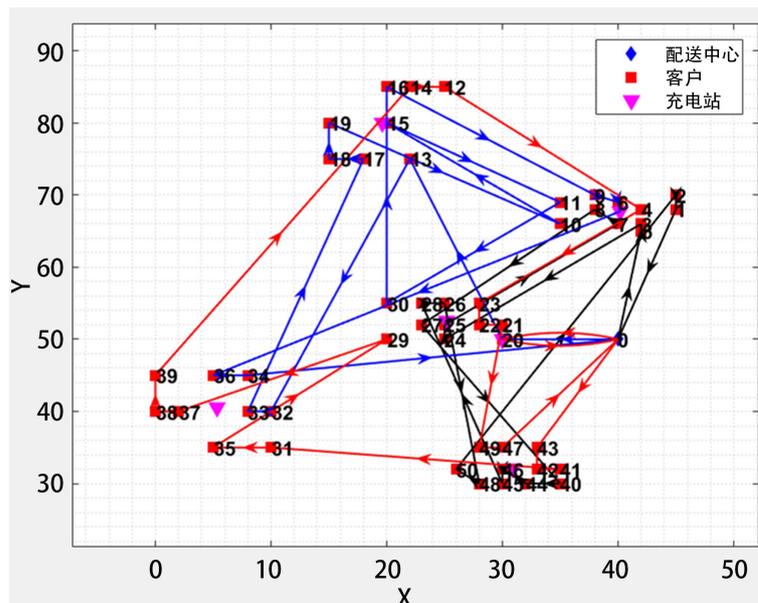


Figure 2. IMMAS solution roadmap

图 2. IMMAS 求解路线图

6. 总结

本文从考虑驾驶员行驶习惯入手，考虑了如何区分不同的驾驶习惯以及如何关联到成本中。同时，在选择算法方面也选择了与选题适应度极高的最大最小蚂蚁系统，以及自适应大邻域搜索算法进行改进。对比改进前后的两算法，得出改进后算法收敛得更快，并得出在需要增加驾驶员时选择平稳型可以节约成本的结论。

在未来，无论是更精细化的电价模型的开发，实施支持决策系统，还是政策和激励机制的影响，电动车辆路径规划问题，尤其是考虑驾驶员行驶风格，仍将是一个重要的研究方向。这一研究不仅能够进

进一步优化电动车辆的运营效率，节约成本，还能在节约成本的同时推动绿色物流的发展，具有广阔的应用前景和重要的社会意义。

基金项目

国家自然科学基金资助项目(72071130)。

参考文献

- [1] Comert, S.E. and Yazgan, H.R. (2023) A New Approach Based on Hybrid Ant Colony Optimization-Artificial Bee Colony Algorithm for Multi-Objective Electric Vehicle Routing Problems. *Engineering Applications of Artificial Intelligence*, **123**, Article ID: 106375. <https://doi.org/10.1016/j.engappai.2023.106375>
- [2] Zhang, S., Zhou, T., *et al.* (2024) A Novel Collaborative Electric Vehicle Routing Problem with Multiple Prioritized Time Windows and Time-Dependent Hybrid Recharging. *Expert Systems with Applications*, **244**, Article ID: 122990.
- [3] Zhang, S., Lee, C.K.M., Choy, K.L., Ho, W. and Ip, W.H. (2014) Design and Development of a Hybrid Artificial Bee Colony Algorithm for the Environmental Vehicle Routing Problem. *Transportation Research Part D: Transport and Environment*, **31**, 85-99. <https://doi.org/10.1016/j.trd.2014.05.015>
- [4] 吴磊, 朱文佳, 秦忱忱. 基于驾驶习惯的综合评分法识别车辆出行路径[J]. 黑龙江交通科技, 2024, 47(4): 165-168+172.
- [5] 夏光, 张洋, 魏振亚, 等. 驾驶员驾驶习惯识别与车辆自动变速换挡修正[J]. 机械工程学报, 2020, 56(20): 120-133.
- [6] Higgs, B. and Abbas, M. (2015) Segmentation and Clustering of Car-Following Behavior: Recognition of Driving Patterns. *IEEE Transactions on Intelligent Transportation Systems*, **16**, 81-90. <https://doi.org/10.1109/tits.2014.2326082>
- [7] Ferreira, J., Carvalho, E., Ferreira, B.V., de Souza, C., Suhara, Y., Pentland, A., *et al.* (2017) Driver Behavior Profiling: An Investigation with Different Smartphone Sensors and Machine Learning. *PLOS ONE*, **12**, e0174959. <https://doi.org/10.1371/journal.pone.0174959>
- [8] Shahverdy, M., Fathy, M., Berangi, R. and Sabokrou, M. (2020) Driver Behavior Detection and Classification Using Deep Convolutional Neural Networks. *Expert Systems with Applications*, **149**, Article ID: 113240. <https://doi.org/10.1016/j.eswa.2020.113240>