

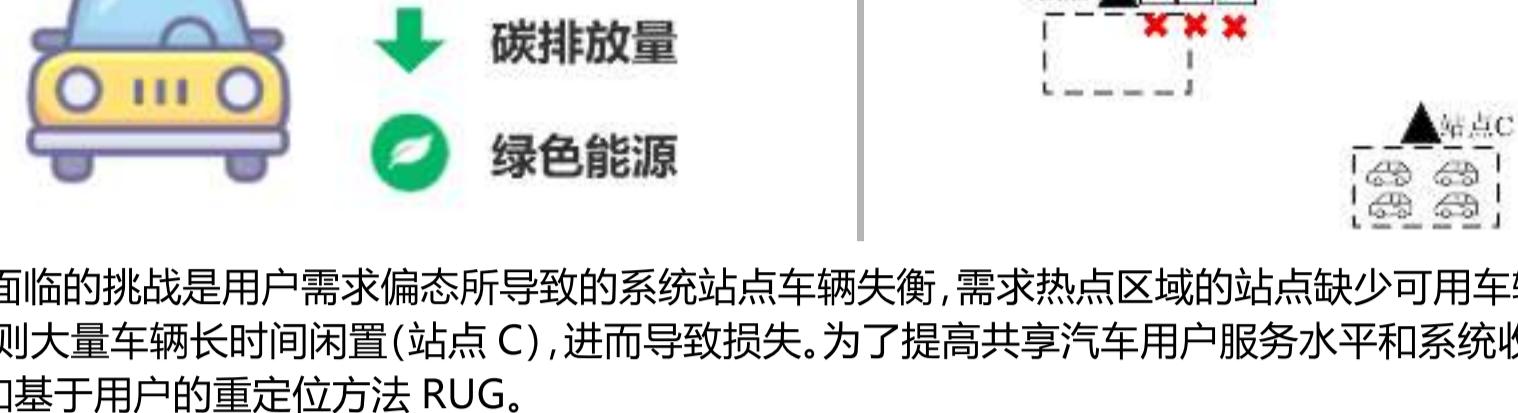
# RUG：收益驱动的单向共享汽车用户重定位

马毓哲<sup>1\*</sup> 王蒙<sup>2\*</sup> 李辉<sup>†</sup> 崔江涛<sup>†</sup> 刘俊华<sup>\*</sup> 李瑞蒙<sup>\*</sup>  
a17603869707@163.com, wangmeng@xpu.edu.cn,  
{hli, cuijt}@xidian.edu.cn, liujunhua@xpu.edu.cn,  
liruimeng106@qq.com



## 介绍

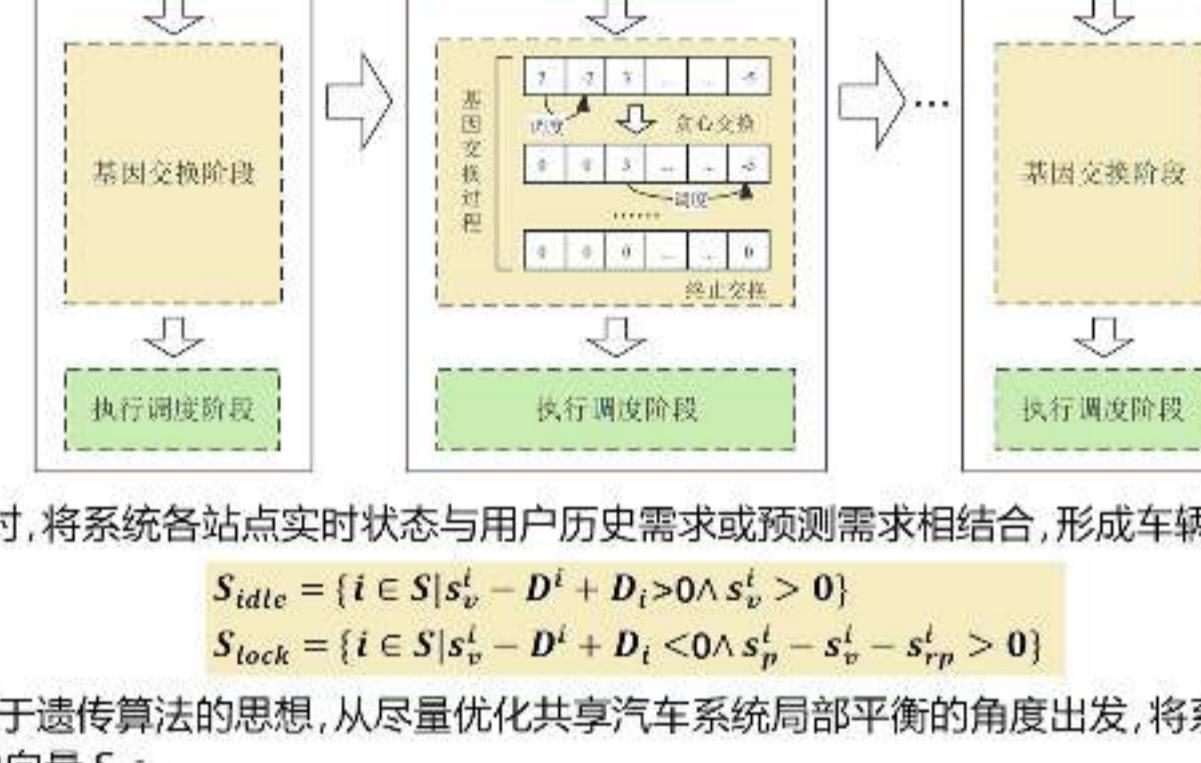
共享汽车是近年来兴起的城市交通新模式，在满足用户多样化出行需求的同时，具有显著的社会、环境和经济效益。



共享汽车系统面临的挑战是用户需求偏态所导致的系统站点车辆失衡，需求热点区域的站点缺少可用车辆(站点 A)，无法满足用户需求；需求冷门区域站点则大量车辆长时间闲置(站点 C)，进而导致损失。为了提高共享汽车用户服务水平和系统收益，我们提出了基于运营商的重定位方法 GA-ap 和基于用户的重定位方法 RUG。

## GA-ap模型

基于遗传算法思想的运营商重定位模型 GA-ap (Genetic Algorithm Approximation Relocation) 将一天划分为固定的时间段，在每个时段开始时计算确定重定位计划并由员工执行。下图展示了 GA-ap 模型各时段整体的调度和运营逻辑，其中每个时间窗由三个阶段构成：基因编码阶段、基因交换阶段和执行调度阶段。



准备工作： 每个时段开始时，将系统各站点实时状态与用户历史需求或预测需求相结合，形成车辆闲置站集和车辆稀缺站集

$$S_{idle} = \{i \in S | s_v^i - D^i + D_i > 0 \wedge s_v^i > 0\}$$
$$S_{short} = \{i \in S | s_v^i - D^i + D_i < 0 \wedge s_p^i - s_v^i - s_{rp}^i > 0\}$$

编码阶段： GA-ap 模型基于遗传算法的思想，从尽量优化共享汽车系统局部平衡的角度出发，将系统的闲置站和稀缺站按站点的净车辆数编码为闲置向量  $S_N^+$  和稀缺向量  $S_N^-$ 。

$$Fit(S_N) = \sum_{s_N^i \in S_N} |s_N^i|$$

交换阶段： 将车辆在各站点之间的不同调度计划作为基因交叉算子，交叉算子的选择以局部最优作为评估标准，直至满足各站点需求时得到最优解。

$$Sel(s_N^i, s_N^j) = \arg \max \{t_j^i | s^i \in S_N^+ \wedge s^j \in S_N^-\}$$

调度阶段： 由共享汽车的员工依次执行 GA-ap 生成的最优化重定位计划。

## RUG模型

本文通过将公交系统融入重定位行程、考虑用户接受重定位的概率、为用户提供与付出额外代价相符合的激励以及结合用户需求预测等方式，构建了一种新型的收益驱动的单向共享汽车用户重定位模型 RUG(Revenue-derive User-based Greedy relocation)。



融入公共交通： 结合公交系统，突破传统方法调度距离的限制。用户重定位过程中使用公共交通的费用由运营商全额补贴。

用户激励计算： RUG 模型考虑用户利益，以用户额外花费总时间作为用户付出代价来构建激励计算公式具有更强的合理性，且可适用于所有用户重定位系统中。

$$\varepsilon = r_j^i \times \frac{\Delta t}{t_j^i}$$

用户接受概率计算： 基于时间感知学理论采用用户花费额外时间构建非线性模型来评估用户接受概率。相较传统方法更符合实际。

$$p = \frac{1}{e^{2\varepsilon/t_j^i}} - e$$

收益驱动重定位： 基于前景理论确定效应，RUG 模型优先满足普通订单；当遇到出发站或到达站无可用资源的出行需求，转为前景理论的反射效应，为用户构建最重定位计划。若用户同意则确定损失转化为收益，同时系统不平衡度降低。

结合需求预测： 采用 LSTM 方法构建用户需求预测模型，输入过去 2.5 个小时的用户出行到达需求，得到未来半个小时各个站点的出行到达需求。在制定重定位计划过程中结合未来需求更具前瞻性。

选择重定位行程： 当系统出现无法满足的用户需求时，系统基于站点现有状态和未来需求构建出发 / 到达重定位候选站集。再使用贪心算法从候选站集选择提供最大收益的站点作为最终重定位站。

$$O_R = \{i \in S | s_v^i - s_{rp}^i > 1 \wedge (s_v^i + s_{rp}^i - (D^i - D_i)) \div s_p^i > 0.3 \wedge i \notin \{o, d\}\}$$
$$D_R = \{i \in S | s_v^i - s_{rp}^i > 1 \wedge (s_v^i + s_{rp}^i - (D^i - D_i)) \div s_p^i > 0.7 \wedge i \in \{o, d\}\}$$
$$o' = \begin{cases} \arg \max \{r_d^o - l_d^o \times loss - \varepsilon - u_d^o \times cost_p\}, i \in O_R \wedge \max \{r_d^o - l_d^o \times loss - \varepsilon - u_d^o \times cost_p\} > 0 \\ \emptyset, \text{ 其他} \end{cases}$$
$$d' = \begin{cases} \arg \max \{r_d^o - l_d^o \times loss - \varepsilon - u_d^o \times cost_p\}, j \in D_R \wedge \max \{r_d^o - l_d^o \times loss - \varepsilon - u_d^o \times cost_p\} > 0 \\ \emptyset, \text{ 其他} \end{cases}$$

## 实验结果

实验采用真实用户出行数据，纽约 ZipCar 的站点位置、收费以及租金标准构建仿真实验来验证模型性能。设置了无外力干涉的基线方案和经典的基于运营商搬迁的 OVOS 模型作为对照组。结果显示 GA-ap 模型相较于基线有明显提升。融入需求预测的 RUG 模型对比 OVOS 具有显著优势，在服务订单数、收入和利润三个方面分别提升了 0.94、0.74、6.5 倍。此外，融入需求预测的 RUG 相较于未加预测可以提升 5.4% 的利润，说明加入用户需求预测可以帮助模型更精准的制定重定位计划。

	服务订单数	收入(\$)	利润(\$)	$\mathcal{R}_o$	$\mathcal{R}_i$	$\mathcal{R}_p$
基线	3063	29943	1967	-	-	-
OVOS	3831	37516	4985	25%	25%	153%
GA-ap	3469	34007	4683	13%	13%	138%
RUG-NoPre	7136	63554	35480	132%	112%	1703%
RUG	7458 ↑	65481 ↑	37399 ↑	143%	118%	1801%