

网约车平台信息机制设计与司机工作模式选择

李玲芳* 卢向华 符琳 黄少卿

摘要：网约车平台乘客目的地透明机制会导致网约车司机产生主动式选单与被动式接单两种工作模式，在社会上引起广泛争议而被取消。本文以滴滴平台上 2015 年 12 月北京市网约车司机的随机抽样数据为样本，实证分析乘客目的地透明机制下两种司机工作模式的绩效差异，以及在不同市场需求环境下该绩效差异的变化。运用倾向评分匹配（PSM）的研究方法，本文发现乘客目的地透明机制引发的主动式选单行为会帮助司机获得超额回报。在市场波动的高峰期，主动式选单模式产生的边际收入递减，但是任何市场环境下，司机从被动式接单向主动式选单模式转型总能获得更好的绩效回报。主动式选单模式对司机本人的绩效影响总是正向的，因此司机通过更少的接单获得更高的每日收入、平均每销售收入、更高载客率等。本研究为乘客目的地透明机制的司机行为正向激励效应提供了新的证据，同时也为网约车平台进一步优化司机激励机制提供经验支持。

关键词：共享经济；网约车平台；信息机制设计；激励机制设计

一、引言

随着互联网、大数据、云计算等新一代信息技术与交通行业的深度融合，Uber、滴滴、神州租车等网约车平台在全球范围内迅速普及。一方面，网约车平台为城市居民出行提供便捷，但是另一方面，网约车平台机制设计的不合理很可能会导致司机与乘客发生利益冲突，降低网约车服务质量（黄雷彩等，2020）。

其中，网约车平台的乘客目的地透明机制由于引发司机“拒载”行为而备受争议。以滴滴共享平台为例，2017 年以前，平台允许司机获悉乘客最终目的地，由司机决定是否应答。这种机制设计虽然可以帮助平台服务供给者和服务需求者之间更好地匹配，但是也造成了司机出现两种策略性工作模式——主动选单（选择长距离订单）和被动接单（不挑选订单），进而产生司机拒载行为，降低乘客满意度。为此，2017 年，上海市交通委决定网约车平台不得显示乘客目的地相关功能^①。

现有研究对网约车平台如何激励司机行为进行了大量探讨。例如探讨网约车平台根据市场需求变化采取不同的定价模式和策略，从而优化司机接单行为（Diakopoulos, 2015）；实证研究证实了平台帮助司机与乘客之间实现信息共享，可以降低总体出行费用的 60%，降低司机之间的恶性竞争（Zhan 等，2016），节约乘客与司机获悉搜寻与等待接单的时间，是时间成本最小化与乘车收入最大化的关键点（Gabel, 2016）。网约车平台在机制设计上需要在司机个体利益最大化与市场

* 李玲芳，复旦大学管理学院，教授；卢向华，复旦大学管理学院，教授；符琳，银联国际有限公司，研究员；黄少卿，上海交通大学安泰经济与管理学院，教授。通信作者：李玲芳，Email:Lingfangli@fudan.edu.cn。本文为国家自然科学基金重大项目“数字经济反垄断科学监管创新研究”（批准号：72192845）、国家自然科学基金重点项目“数字化平台模式与机制设计”（72131004）、上海市曙光人才项目“市场机制设计在网络平台上的应用”（批准号：17SG05）、国家交通运输部专项课题“促进出租汽车监管信息平台建设”、上海交通大学“文理交叉”课题“网约车监管平台和监管体系研究”的阶段性成果。

① 资料引自 2017 年《上海市巡游出租汽车预约调度服务管理规定》。

需求尽可能满足间实现激励相容(周乐欣, 2020)。现有研究主要从乘客交易价格变化、乘客等待时间等因素出发探讨司机行为的激励效应, 缺乏探讨乘客目的地已知情境下司机不同工作模式的绩效差异。

为探讨上述研究缺口, 本文作者与滴滴平台合作, 针对其 2015 年抢派结合模式探索阶段, 以随机抽样网约车司机脱敏数据为研究样本, 并选取北京市限行^①产生市场需求快速波动时间段为自然实验事件, 聚焦于回答以下两个研究问题: 第一, 网约车平台乘客目的地已知情况下, 司机主动式选单模式是否一定比被动式接单模式产生更好的绩效? 第二, 当市场需求发生快速变化时, 司机主动式选单是否仍然维持绩效优势?

本文采用倾向评分匹配(PSM)的研究方法对滴滴出行网约车数据进行分析, 发现无论市场需求是高或者低, 主动选择模式下司机在每日总收入、每小时收入以及载客率上都优于被动接单的司机。但是, 主动选单司机的边际收入在市场高需求期间递减, 即限行期的高需求市场会削弱挑选长距离订单的司机与不挑选长距离订单司机之间的收入差距。这个研究结果表明, 司机主动式选单回报要优于被动式选单。由此可以推测, 随着司机网约车经验的增加, 将有越来越多的挑单行为发生, 因此会出现对于短途出行的需求不平衡和不匹配。

相对已有文献, 本文的理论贡献在于:

① 以往对于网约车平台的机制设计研究主要关注平台订单类型设计、订单时长设计与订单报价设计对司机工作模式的影响(Zheng 等, 2016; 程絮森等, 2015; Cici, 2015), 缺乏关注乘客目的地信息机制与司机工作模式选择之间的关系。本文发现乘客目的地机制设计的缺陷会导致部分市场失灵现象出现, 具体表现为司机在利益最大化驱动下选择长途单而忽视短途单, 短途出行需求得不到匹配, 由此揭示了乘客目的地信息机制下市场失灵的内在机理。

② 本文发现在乘客目的地信息机制影响下的市场失灵中, 市场需求的波动性不会产生根本性影响, 主动式选单工作模式的绩效总是优于被动式接单工作模式; 指出了这种类型的市场失灵具有鲁棒性效应, 不会随着市场波动而变化, 推进了现有网约车领域研究对该现象的理解。

③ 对于乘客目的地信息机制设计, 本文一方面揭示了可能会出现的市场失灵现象, 另一方面也指出该机制对策略性司机群体具有正向激励效应, 有助于提高司机参与度和订单应答效率。本文的研究结论有助于网约车及其他共享经济平台(例如共享单车)改进乘客目的地信息披露模式, 对平台的长远发展有一定的推动作用。

二、网约车平台机制设计文献回顾

共享经济平台资源配置的特性使得平台承担了部分市场组织者的职能(Hurwicz, 1973)。如何在非理想条件下实现资源的有效配置是平台发展的关键, 也是经济学的重要议题——市场(机制)设计理论研究的主要内容(李玲芳和洪占卿, 2015)。平台的参与者会按照平台设定的规则进行经济活动, 因此, 平台的机制设计会对参与者的行为产生较大的影响(Maskin, 2008), 如果设计不当, 则会对平台自身和市场的公平与效率产生影响。比如: 电商平台 eBay 一开始的评论系统里面允许买卖双方互评, 但是后来发现这样的平台机制设计会导致买家不敢留下真实的差评, 因此在 2013

^① 资料引自中国新闻网《北京雾霾爆表! 交通委: 将实行更严格的限行措施》, 指出北京市政府因为雾霾天气制定私家车单双号限行, 导致网约车与公共交通需求激增, 为研究不同市场需求变动下司机行为提供了自然实验机会。

年禁止卖家给买家留差评。

现有研究对网约车平台的机制设计进行了大量探讨。在订单类型选择方面,研究发现司机在可以预期接到很多订单时,存在通过多接一些距离小于起步价距离的订单来提高收入的情况,网约车平台的出现使得司机更愿意接短单了(Zheng等,2016)。与之相反,有学者的研究证实了当起步价的收入远高于多跑一公里的收入时,司机更愿意多接短单来获得更多的起步价(Dong,2016)。与前者结论均不同的是,将司机按收入高低分为四组,四组司机的平均每单车程的概率分布曲线相同,结论认为司机不能通过接长单、少接单来获取更多收入(Zhang等,2016)。但是,这些研究并没有以有可比性的司机为研究对象进行分组,从而研究司机的工作策略,也缺少在市场需求波动情景下司机的策略行为的研究。

在订单工作时长方面,共享机制下,司机可以自由选择工作时长,司机的工作时长问题以及其与传统出租车司机的工作效率和行为模式比较成为了近期研究关注的热点。在共享机制下,司机倾向于在工资高时投入更多的工作时间(Cachon等,2015)。其中,以Uber为例,司机的平均每小时收入并不随着一周内工作时间的长短而变化(Hall和Krueger,2017)。相较出租车司机,Uber司机工作时间的弹性更大,平均每小时收入更高,且每周工作更少时间。在资源利用效率上,Uber司机载客时间比率(载客时间占总工作时间的比率)以及载客路程比率(载客时间占总工作时间的比率)都显著高于出租车司机(Cramer和Krueger,2016)。在Uber平台被采用的城市,总就业人数有所增加,传统出租车司机的收入下降部分被Uber司机收入的增长部分所抵消(Berger等,2018)。

在订单报价方面,现有网约车平台采取司机接受或者拒绝的定价交易机制,可以帮助平台优化司机的实际运行成本和期望收益(程絮森,2015)。网约平台动态定价模式是竞争性报价交易机制在共享经济平台的表现(McAfee,1992;Cici等,2015)。通过实证分析数据发现,在线乘车系统的动态价格匹配机制可以使得司机乘客匹配率高达78%。另有研究证实了动态价格机制在提高市场效率和提升乘客服务体验上均优于固定价格机制(Pueboobpaphan等,2017)。

针对中国网约车市场的研究,一些学者对出租车司机及滴滴司机的工作方式选择进行了新的探讨。有研究按照每日收入高低将司机分为3组,发现供需关系、搜索距离、费用率、车速是影响司机收入的主要因素。但是在低需求地区不代表着低收入,长订单也不代表着高收入(Qin等,2017)。而这正是本文可以进一步解释的。低需求地区的挑单司机一样可以获得高收入,挑选长订单的司机一定程度上会受到订单需求的影响。

综上所述,现有研究已经意识到网约车平台机制设计的重要性,并从司机订单类型、订单时长、订单价格等方面探讨对司机行为的激励效应,然而缺乏探讨在订单目的地已知情况下不同司机行为的绩效差异。

三、理论与假说

(一) 基础理论模型:司机工作方式对司机绩效的影响

所有司机都有动机在有限工作时间内以更高效的工作方式获得更高的收入。过去我们观察到出租车司机更偏好于接长订单,尤其是机场和火车站的订单。在这种情况下,一些司机会更具策略性,只回应价值较高的订单,即长订单。因为他们认为,即使他们可能会牺牲一些短距离订单,导

致等待时间更长，但长订单的利润会覆盖掉成本。如北京出租车（早 5:00—晚 22:59）的起步价为 10 元（三公里以内），超出（含）三公里至十五公里以内的公里数每公里按 2 元计费。超出（含）十五公里的公里数（每公里加收 50%空驶费）按 3 元计费。显然，司机更偏好距离超过十五公里的长订单。

有学者的研究发现，与出租车司机相反，网约车司机在可以预期接到很多订单时，存在通过多接一些小于起步价距离的订单来提高收入的情况，网约车平台的出现使得司机更愿意接短单了（Dong, 2016; Tang, 2017）。其他学者的研究进一步证实了司机不能通过接长单、少接单来获取更多收入（Zhang 等, 2016）。

假说 1：司机挑选长距离订单会获得超额回报。

（二）需求波动对司机行为模式与绩效的影响

在高峰期，挑长单的策略效果减弱。低峰期没有足够的短单，使得司机无法实现多接单接短单策略。高峰期情况下，市场订单足够多，司机的寻客成本更低，司机多接短订单也可以实现高收入。我们将司机划分为挑选长订单的主动选单组，和不挑选长订单的被动接单组。经检验，确实两者收入差距在高峰期减少，说明在不挑选长订单的司机中有一部分司机采用了多接单、接短单策略，从而获得更高的收入。

假说 2：高需求市场下，主动选单的工作策略的边际效应降低。

（三）司机行为模式转换对司机绩效的影响

正如前面所述，在高需求模式下，司机即使不挑单也能有足够的订单数，因此很多司机会选择维持低需求模式下的工作方式。但另一方面，高需求模式提供了一个更好的挑单环境，也就是说高需求模式下，订单量足够多，更允许司机对订单进行有目的性的选择。那么一个自然的问题就是，在需求波动的情况下，司机改变其工作方式会带来更高还是更低的边际收入？考虑到这一问题背后有着两种不同的机制在影响着司机的决策，我们尚未知哪一种机制产生的作用更大，因此，我们提出两个竞争性的假设：

假说 3a：司机在市场需求波动的情况下转换为主动选单工作策略，会带来更高的边际收入。

假说 3b：司机在市场需求波动的情况下转换为主动选单工作策略，会带来更低的边际收入。

四、样本选择、指标构建与变量统计

（一）样本选择

2015 年 12 月，北京市政府实施了 7 天“单双车禁”政策（12 月 9 日-12 日和 12 月 20 日-22 日），要求车辆按照车牌号的奇偶分天数限行，以缓解雾霾和交通拥堵。这个政策导致公共交通和私家车共享需求急剧增加，12 月 7 日滴滴顺风车的预约量相比前一日大幅增长了 93.5%^①。政策期和非政策期创造出了相应的高需求市场和低需求市场，对此，我们构建实证模型检验需求波动对网约车司机的工作方式的影响。

^① 数据引自中国新闻网《北京雾霾限行首日 滴滴顺风车预约量狂增 93.5%》。

在本研究中，我们与滴滴平台合作，随机抽取了 2015 年 12 月 1 日至 12 月 31 日北京 1000 名网约车司机的脱敏数据。2015 年滴滴仍处于抢派结合模式的探索阶段，订单优先派送距离乘客一定半径范围内的司机，播报订单的起始位置和目的地位置信息（播报时间 3-5 秒），如果没有司机抢单，系统会扩大播报半径直至有司机接单。因此在这个过程中，一些司机会策略性选择距离更长、价值更高的订单。

为了确定哪些是主动选单司机哪些是被动接单司机，我们计算了正常需求期间（即没有单双车禁止期，共 21 天）每个驾驶者的平均每程行程距离。如果司机的平均行程距离高于平均值的 3/4 标准偏差，我们将他们定义为主动选单司机，最终在 1000 名司机中有 255 名主动选单司机，而其他 745 名司机则更倾向于随机地选择这些订单。

为了更好地比较主动选单司机与被动接单司机的行为差异，我们要排除这两类司机的自我选择偏差，即两类司机除了抢单方式之外，在经验、工作时间、车辆配置等方面没有显著的偏差。因此，基于这 255 名司机的信息，我们采用倾向得分匹配（PSM）方法，在 745 名剩余的司机中采用一对一最近邻居匹配（无替换）算法（Brodeur, 2018），匹配了 255 名被动接单司机，即这些司机在正常需求期间不会刻意地去抢长单。表 1 是经过 PSM 匹配后两组司机的特征比较结果，我们发现匹配后，四项特征的 t 检验均不显著，提示两组司机的工作时间、经验、车辆价格、车的排量方面均相似，这两组之间的唯一区别是司机所选择的平均行程距离。

表 1 低需求市场下 PSM 结果

| 变量 | 匹配 | 组别 | 均值 | 偏差 (%) | T 检验 |
|-----------------------|-----|-------|---------|--------|-----------------|
| 工作时长 work_hour | 匹配前 | 主动选单组 | 5.009 8 | -20.1 | -2.57** (0.010) |
| | | 被动接单组 | 5.545 2 | | |
| | 匹配后 | 主动选单组 | 5.009 8 | -4.5 | |
| | | 被动接单组 | 5.129 6 | | |
| 经验 experience | 匹配前 | 主动选单组 | 261.58 | 11 | 1.64 (0.102) |
| | | 被动接单组 | 249.91 | | |
| | 匹配后 | 主动选单组 | 261.58 | 4 | |
| | | 被动接单组 | 257.31 | | |
| 车辆价格 price | 匹配前 | 主动选单组 | 17.017 | 10.1 | 1.19 (0.233) |
| | | 被动接单组 | 16.278 | | |
| | 匹配后 | 主动选单组 | 17.017 | -11.7 | |
| | | 被动接单组 | 17.873 | | |
| 车辆排放量 displacement | 匹配前 | 主动选单组 | 1.937 6 | -0.6 | -0.08 (0.934) |
| | | 被动接单组 | 1.939 9 | | |
| | 匹配后 | 主动选单组 | 1.937 6 | -1.4 | |
| | | 被动接单组 | 1.942 5 | | |

（二）变量定义与描述

在衡量司机绩效时，劳动供给理论的学者大多采用平均每日工资、工作时间、小时平均工资来衡量（Farber, 2005; Kim, 2018）。但有研究指出，以往研究司机绩效时忽略了司机空跑寻找乘客的成本，提出还需要考虑司机空载成本和单位时间效率（Tang 等, 2017）。因此，除每天每个司机的日收入（daily income）、平均每小时收入（hourly income）指标之外，本文增补了司机日订单数量（daily order）、日负载率（load rate）等指标作为因变量，从多个角度来衡量司机绩效。

每日收入和每日订单数量是指特定日期所有订单的总费用和订单数量。每日工作时间可以计算为司机的第一个和最后一个订单之间的时间差。然而,由于大多数共享汽车司机都是间断工作的,他们可能会在一天中选择自己的工作时间,因此,时差计算方法可能会高估总工作时间。在本研究中,我们假设当两个连续交易之间有一个小时的差距时,认为司机已经结束工作。这样,我们把司机的一天划分成几个时间段,并把这些时间段作为他的总工作时间加总,作为他的每日工作时间。据此,我们可以进一步计算每个司机每小时的收入为日收入除以每天的工作时间。每日接单时间则等于当日所有订单的时间长度的总和。基于每日接单时间得到司机日负载率,每个司机的载客时间除以她/他每天的总工作时间。载客时间是司机一整天所有订单的累计时间,我们可以把它命名为司机可以赚取利润的有效的工作时间。表2给出了所有的变量定义及描述性统计。

表2 变量定义与描述性统计

| 变量名 | 变量定义 | 均值 | 标准差 | 最小值 | 最大值 |
|--------------------|--|----------|--------|-------|----------|
| 日订单数 ordernum | 司机当天接到的所有订单数 | 11.00 | 7.03 | 1.00 | 46.00 |
| 日收入 income | 当天 0:00-24:00 司机的所有订单总收入 | 219.68 | 152.87 | 10.00 | 1 121.90 |
| 平均每小时收入 hincome | 当日收入/当日工作时间 | 37.05 | 11.85 | 2.29 | 145.50 |
| 日负载率 rate | 当天的接单时间/当天的工作时间 | 0.72 | 0.14 | 0.21 | 0.99 |
| 高需求时期 demand | 限行期 (12.8-12.10,12.19-12.22) 为高需求时期, demand=1, 其它时间, demand=0 | 0.181 | 0.385 | 0 | 1 |
| 司机类型 drivertype | 司机主动挑长单, drivertype=1; 司机被动接单, drivertype=0 | 0.475 | 0.5 | 0 | 1 |
| 经验 experience | 司机在滴滴上注册的时间(天) | 598.698 | 79.717 | 365 | 847 |
| 车价 price | 司机在滴滴上注册的车的价格(万) | 16.321 2 | 7.847 | 5 | 61 |
| 车的排量 displacement | 司机在滴滴上注册的车排量(L) | 1.853 | 0.296 | 0.1 | 3.6 |
| 工作时间 work_hour | 当天 0:00-24:00 司机工作的总时间(小时) | 6.064 | 3.871 | 0.233 | 25.43 |

根据表2的统计,共享车的平均载客率均值为72.3%,明显高出出租车的平均载客率35.18%^①。共享车司机平均每日收入均值为219.678元,标准差为152.865元,说明司机之间的收入差距大。司机平均每小时收入均值为37.05元,标准差为11.85元,说明司机之间的收入差距不仅仅只是工作时间的不同,司机之间的工作效率也有差异。

五、研究内容

(一) 研究一: 需求变动对司机绩效的影响检验

根据前面的分析,市场打车需求和司机行为模式影响司机绩效的路径是相互交织的,不同市场需求下,同样的司机行为模式可能会有不同的结果。图1报告了本文关注的四个因变量在高需求与日常需求(低需求)期间的描述性比较结果。我们可以大致了解,尽管主动选单司机的日常订单数量较少,但他们的日收入、小时收入和日负载率要高于被动接单司机,这表明他们的工作效率比被动接单司机高。这个结果与前人的研究一致,即高入出租车司机会在某些情况下拒绝乘客,并巧妙地选择他们喜欢的乘客的目的地(Zhang等,2016)。同时我们发现在高需求模式下,主动选单司机的整体绩效仍然要高于被动接单司机,尽管边际差异会有所缩小。

^① 出租车载客率数据引自《2015-2020年中国行业经营管理模式与投资发展预测分析报告》。




图 1 主动选单司机与被动接单司机在高低需求市场下的绩效对比

为了更系统地检验假设 1 和假设 2，即主动选单司机的收益效果，以及需求变化时主动选单行为是否仍然是一个有效的策略，我们构建公式 (1) 所示的模型，引入市场需求和司机类型的交叉变量来检验在市场需求高时挑选长距离订单的司机是否仍然能获得更好的绩效。如果交叉变量的系数 β_3 为负，说明高需求期能弱化司机主动选单行为对绩效的影响。为此，我们构建了模型 (1) - (4) 对假设 1 与假设 2 进行检验：

$$\begin{aligned} \text{ordernum}_{it} = & \beta_1 \text{demand}_t + \beta_2 \text{drivertype}_i + \beta_3 \text{drivertype}_i * \text{demand}_t + \beta_4 \text{workhours}_{it} \\ & + \beta_5 \text{experience}_i + \beta_6 \text{carprice}_i + \beta_7 \text{displacement}_i + \beta_8 \text{ordernum}_{it-1} \\ & + \beta_9 \text{ordernum}_{it-2} + \mu + \epsilon + \gamma_{it} \end{aligned}$$

$$\begin{aligned} \text{income}_{it} = & \beta_1 \text{demand}_t + \beta_2 \text{drivertype}_i + \beta_3 \text{drivertype}_i * \text{demand}_t + \beta_4 \text{workhours}_{it} \\ & + \beta_5 \text{experience}_i + \beta_6 \text{carprice}_i + \beta_7 \text{displacement}_i + \beta_8 \text{income}_{it-1} \\ & + \beta_9 \text{income}_{it-2} + \mu + \epsilon + \gamma_{it} \end{aligned}$$

$$\begin{aligned} \ln \text{income}_{it} = & \beta_1 \text{demand}_t + \beta_2 \text{drivertype}_i + \beta_3 \text{drivertype}_i * \text{demand}_t + \beta_4 \text{workhours}_{it} \\ & + \beta_5 \text{experience}_i + \beta_6 \text{carprice}_i + \beta_7 \text{displacement}_i + \beta_8 \ln \text{income}_{it-1} \\ & + \beta_9 \ln \text{income}_{it-2} + \mu + \epsilon + \gamma_{it} \end{aligned}$$

$$\begin{aligned}
 rate_{it} = & \beta_1 demand_t + \beta_2 drivertype_i + \beta_3 drivertype_i * demand_t + \beta_4 workhours_{it} \\
 & + \beta_5 experience_i + \beta_6 carprice_i + \beta_7 displacement_i + \beta_8 rate_{it-1} + \beta_9 rate_{it-2} \\
 (4) \quad & + \mu_i + \tau_t + \nu_{it}
 \end{aligned}$$

表3展示了模型(1)-(4)的回归结果。*demand*回归系数 β_1 在四个模型中均显著为正,在经济学意义上,说明在市场需求高时,相比市场需求较低时,所有司机的空载率降低了,接单更多了,收入也有显著提高;*drivertype*系数 β_2 在模型(2)(3)中均显著为正,在模型(1)(4)中显著为负,说明在市场需求低时,主动选单的司机相比被动接单的司机在相同条件下平均每小时收入更高,平均日收入也更高,而负载率和订单数明显低于被动接单司机,因此假设1成立,表明主动选单司机花费了更多时间在挑选订单上,而不是通过多接单来获取更高的收益。*demand * drivertype*交叉项系数 β_3 在模型(1)(3)(4)中均显著为负,说明在市场需求变得更高时,主动选单所能带来的绩效提升被削弱了,因此,主动选单司机和被动接单司机之间在订单数量、每小时收入和负载率上的差距被缩小,假设2被支持。不过在模型(2)中 β_3 为正但并不显著,表明在高需求时,主动选单所带来的收入与低需求时间相比,并没有显著差异,因此也是侧面支持了假设2。

表3 研究一回归结果

| 变量名 | 模型(1) | 模型(2) | 模型(3) | 模型(4) |
|----------------------|-----------|----------|-----------|------------|
| demand | 3.051*** | 44.75*** | 7.206*** | 0.0478*** |
| drivertype | -0.0878 | -1.997 | -0.378 | -0.004 |
| demand*drivertype | -1.321 | 43.50* | 11.06** | 0.0685 |
| work_hour | -1.071 | -24.54 | -4.674 | -0.0494 |
| experience | -0.468*** | 3.416 | -1.830*** | -0.0248*** |
| price | -0.124 | -2.828 | -0.538 | -0.0057 |
| displacement | 1.583*** | 34.93*** | -0.404*** | 0.000772** |
| Ratlag 1-2 | -0.00855 | -0.196 | -0.0372 | -0.000393 |
| Hincomelag1-2 | -0.0171* | -0.449** | -0.0586 | -0.000102 |
| Incomelag1-2 | -0.0094 | -0.215 | -0.041 | -0.000434 |
| Orderlag1-2 | 0.0937** | 0.786 | 0.397* | 0.00943*** |
| Driver fixed effects | -0.047 | -1.075 | -0.205 | -0.00217 |
| Constant | 0.908 | 30.56** | 4.394 | 0.119*** |
| Observations | -0.624 | -14.3 | -2.718 | -0.0288 |
| | Included | Included | Included | Included |
| | Included | Included | Included | Included |
| | Included | Included | Included | Included |
| | 8.593 | 190.9 | 56.39** | 0.358 |
| | -6.485 | -148.5 | -28.29 | -0.299 |
| | 9173 | 9173 | 9173 | 9173 |

注:***代表 $p < 0.01$, ** 代表 $p < 0.05$, * 代表 $p < 0.1$ 。

(二) 研究二: 司机行为模式转换对司机绩效的影响检验

司机可能在需求变动时改变自己的行为模式,而这也会影响司机的绩效。举例来说,被动接单司机可能在高需求时期转变为主动选单司机,因为他们同时拥有了更多的选择。这一转变行为可能导致过高地评估了被动接单司机的绩效。所以在这一部分的研究中,我们将司机转变行为模式的学习加入了我们的模型。我们通过构建*shift_{it}*变量来描述司机*i*是否在*t*时刻转换为另一种类型。我

们将这 510 名司机按照在高需求时期的平均订单距离排序，并定义排序在前 255 名的司机为高需求时期的主动选单司机，剩下的 255 名司机为被动接单司机。如果司机 i 在低需求时期和高需求时期挑选订单的行为模式发生转换，则定义 $shift_{it}=1$ ，否则 $shift_{it}=0$ 。

$shift$ 变量将原有的两类司机进一步分为了四类：174 名持续型主动选单司机 (A^{ns})，174 名持续型被动接单司机 (B^{ns})，81 名从主动选单转换到被动接单的司机 (A^s)，以及 81 名从被动接单转换到主动选单的司机 (B^s)。我们关心的是，当一名主动挑长距离订单的司机在高需求市场条件下变得不那么挑单了，他们的收入会比一直挑单的司机有所降低吗？或者，如果一名不挑选长距离订单的司机在高需求市场条件下，转换为挑选长距离订单的司机了，他们会比不挑选长距离订单的司机更好吗？

图 2 显示了行为转换后带来的边际价值。我们可以发现四类司机均在高需求市场中获得更多的订单，这也进一步验证了限行政策创造了一个高需求的市場。不过从图 2 可以看出，被动式接单转换到主动式选单的司机 (B^s) 的效率获得了最大的提升，他们的日收入、平均每小时收入，以及日负载率的提升，和其它三类司机相比，都是最高的。




图 2 主动选单司机与被动接单司机在高低需求市场下的转换行为绩效对比

为了系统地检验司机行为转换的影响，本文构建了如下模型。表 4 显示了相关的回归结果。

$$\begin{aligned} \text{ordernum}_{it} = & \beta_0 + \beta_1 \text{drivertype}_i + \beta_2 \text{shift}_{it} + \beta_3 \text{shift}_{it} * \text{drivertype}_i + \beta_4 \text{workhours}_{it} \\ & + \beta_5 \text{experience}_i + \beta_6 \text{carprice}_i + \beta_7 \text{displacement}_i + \beta_8 \text{ordernum}_{it-1} \\ & + \beta_9 \text{ordernum}_{it-2} + \mu_i + \tau_t + \gamma_{it} \end{aligned}$$

$$\begin{aligned} \text{income}_{it} = & \beta_0 + \beta_1 \text{drivertype}_i + \beta_2 \text{shift}_i + \beta_3 \text{shift}_i * \text{drivertype}_i + \beta_4 \text{workhours}_{it} \\ & + \beta_5 \text{experience}_i + \beta_6 \text{carprice}_i + \beta_7 \text{displacement}_i \\ & + \beta_8 \text{income}_{it-1} + \beta_9 \text{income}_{it-2} + \mu_i + \tau_t + \gamma_{it} \end{aligned}$$

$$\begin{aligned} \text{hincome}_{it} = & \beta_0 + \beta_1 \text{drivertype}_i + \beta_2 \text{shift}_i + \beta_3 \text{shift}_i * \text{drivertype}_i + \beta_4 \text{workhours}_{it} \\ & + \beta_5 \text{experience}_i + \beta_6 \text{carprice}_i + \beta_7 \text{displacement}_i + \beta_8 \text{hincome}_{it-1} \\ & + \beta_9 \text{hincome}_{it-2} + \mu_i + \tau_t + \gamma_{it} \end{aligned}$$

$$\begin{aligned} \text{rate}_{it} = & \beta_0 + \beta_1 \text{drivertype}_i + \beta_2 \text{shift}_i + \beta_3 \text{shift}_i * \text{drivertype}_i + \beta_4 \text{workhours}_{it} \\ & + \beta_5 \text{experience}_i + \beta_6 \text{carprice}_i + \beta_7 \text{displacement}_i + \beta_8 \text{rate}_{it-1} + \beta_9 \text{rate}_{it-2} \\ & + \mu_i + \tau_t + \gamma_{it} \end{aligned}$$

(8)

表 4 研究二回归结果

| 变量名 | 模型 (5) 订单量 | 模型 (6) 总体收入 | 模型 (7) 小时收入 | 模型 (8) 负载率 |
|----------------------|-------------------------|----------------------|----------------------|--------------------------|
| drivertype | -1.473*** (0.323) | 50.63*** (7.649) | 8.326*** (1.626) | 0.0446*** (0.0118) |
| shift | 0.350 (0.340) | 20.20*** (7.648) | 4.938*** (1.668) | 0.0317*** (0.0117) |
| shift*drivertype | -0.375 (0.553) | -44.00*** (12.63) | -4.967* (2.597) | -0.0502*** (0.0186) |
| work_hour | 1.903*** (0.0270) | 41.10*** (0.610) | -0.911*** (0.131) | 0.00257*** (0.000962) |
| experience | -0.000853 (0.000962) | 0.0219 (0.0215) | 0.00746 (0.00488) | -5.76e-06 (3.40e-05) |
| price | 0.00328 (0.0160) | -0.0847 (0.357) | 0.0213 (0.0806) | -8.85e-06 (0.000566) |
| displacement | -0.241 (0.331) | -8.491 (7.401) | -1.892 (1.689) | -0.0169 (0.0117) |
| Ratelag 1-2 | | | | Included |
| Hincomelag1-2 | | | Included | |
| Incomelag1-2 | | Included | | |
| Orderlag1-2 | Included | | | |
| Driver fixed effects | Included | Included | Included | Included |
| Constant | 1.856*** (0.690) | -5.225 (15.23) | 42.00*** (3.591) | 0.483*** (0.0329) |
| Observations | 1226 | 1226 | 1290 | 1226 |

为了检验司机转换行为的影响，最直接的办法就是比较 A^{ns} 和 A^s 司机在高峰期绩效的差异，以及 B^{ns} 和 B^s 司机在高峰期绩效的差异。通过我们的模型，我们可以将四类司机在高峰期的绩效表示如下：

$$\begin{aligned} \text{Performance } (A^{ns}) &= \beta_0 + \beta_1 + \text{控制变量} \\ \text{Performance } (B^{ns}) &= \beta_0 + \text{控制变量} \end{aligned}$$

$$Performance(A^s) = \beta_0 + \beta_1 + \beta_2 + \beta_3 + \text{控制变量}$$

$$Performance(B^s) = \beta_0 + \beta_2 + \text{控制变量}$$

因此，对于低需求时期主动选单的司机来说，转换行为的影响可以表示为转换组与非转换组的差，即 $Performance(A^s) - Performance(A^{ns}) = \beta_2 + \beta_3$ ，而对于低需求时期被动接单司机来说，转换行为的影响可以表示为 $Performance(B^s) - Performance(B^{ns}) = \beta_2$ 。 $shift_{it}$ 变量的系数 β_2 检验了高需求市场下司机转换行为的有效性，它表明了在高需求时期转向另一种行为模式是否是值得的。 $shift_{it} * drivertype$ 变量的系数 β_3 则可以显示四种策略的司机中哪一类可以在转换行为模式中获益更多，如果系数 $\beta_3 > 0$ ，则表明主动选单的司机可以从转换行为中获益更多，否则则说明被动接单的司机在高需求市场中的转换行为可以获益更多。我们把表 4 的结果重新整理为表 5。

表 5 行为转化的效果

| | 模型 (5) | 模型 (6) | 模型 (7) | 模型 (8) |
|---------------------|--------|----------|----------|------------|
| | 订单量 | 总体收入 | 小时收入 | 负载率 |
| $\beta_2 + \beta_3$ | -0.025 | -23.8** | -0.029** | -0.0185*** |
| β_2 | 0.350 | 20.20*** | 4.938*** | 0.0317*** |

从表 5 的结果中我们可以看到，模型 (6)、(7)、(8) 中 $\beta_2 + \beta_3$ 均为负，说明如果主动接单司机在高需求时期转变为不挑选长距离订单的策略，他们的绩效就不如一直挑选长距离订单的司机，同时他们也没有多接订单。而模型 (6)、(7)、(8) 中 β_2 系数显著为正，说明原本被动接单司机，在经过行为转换后，能在高需求市场中获得更多的收益。因此我们的假设 3a 得到了支持，而 3b 没有得到支持，表明即使是高需求情况下，主动选单的行为仍能带来更大的边际价值。

六、研究结论和政策建议

在 2015 年网约车抢派结合模式探索阶段，我们基于 2015 年 12 月 1 000 名北京市网约车司机的随机抽样脱敏数据，初步探索了司机的工作模式行为选择，及在复杂交通情况影响下，司机的行为选择所带来的绩效差异。研究证实了我们的假设，即无论在高峰期还是低峰期，司机主动挑选长距离订单均会获得超额回报，但是在高峰期，即订单充足的情况下，被动接单与主动选单之间的回报差异显著缩小。因此我们可以发现，主动选单对司机本人绩效的影响总是正面的，司机可以通过更少的接单数获得更高的每日收入、平均每小时收入、更高的负载率等。负载率的提高一定程度上节约了资源，是资源利用效率提高的表现。不过这样的选择可能会对短途乘客造成负面的影响，后续研究可以从乘客角度做进一步的研究。同时，主动选择订单的行为会进一步削减被动接单司机的收入，造成平台司机的流失。

因此，从市场机制设计视角出发，假若网约车平台需要解决这个问题，就必须思考如何持续激励挑选短单的司机留在平台上。一方面，结合本文的结论，在订单充足的情况下，被动接单的司机也能获得较高的回报，平台可以向接单较多的司机优先派送订单，提高被动接单的司机收入；另一方面，平台可以限制司机的主动选单行为，弱化司机选单行为对乘客和平台的影响。当前网约车平台实施的乘客目的地不透明机制，一方面虽然可以减小司机拒载行为，提升乘客服务满意度，但是另一方面也会对司机造成负面影响。具体来说，本文在后续分析中发现主动选单的超额回报在高需求时期减少，所以在派单行为上可以进一步优化。另外，本文的研究也存在一定的不足。在转换效应的检验中，结果不够显著，可能是数据量不够造成的。我们期待在未来的研究中能够有更多的数据来完善，并且也希望有更多的学者利用共享经济的数据来研究人们工作模式对其绩效的影响。

参考文献

- [1] 程絮森、朱润格、傅诗轩. 中国情境下互联网约租车发展模式探究[J]. 《中国软科学》, 2015年第10期, 第36-46页。
- [2] 黄雷彩、高尚、蒋艳. 网约车新政下网约车平台与网约车司机的演化博弈分析[J]. 《管理工程学报》, 2020年第1期, 第55-62页。
- [3] 李玲芳、洪占卿. 关于双向声誉机制的作用机理及有效性研究[J]. 《管理科学学报》, 2015年第2期, 第1-12页。
- [4] 周乐欣、徐海平、李焱. 网约车平台双边报价交易机制创新及策略研究[J]. 《中国管理科学》, 2020年第3期, 第201-212页。
- [5] Berger T, Chen C, Frey C B. Drivers of disruption? Estimating the Uber effect[J]. *European Economic Review*, 2018, 110: 197-210.
- [6] Brodeur A, Nield K. An empirical analysis of taxi, Lyft and Uber rides: Evidence from weather shocks in NYC[J]. *Journal of Economic Behavior & Organization*, 2018, 152: 1-16.
- [7] Cachon G P , Daniels K M , Lobel R . The Role of Surge Pricing on a Service Platform with Self-Scheduling Capacity[J]. *SSRN Electronic Journal*, 2015.
- [8] Cici B, Markopoulou A, Laoutaris N. Designing an on-line ride-sharing system[J]. *Advances in Geographic Information Systems*, 2015:60-62
- [9] Colin Camerer, Linda Babcock, George Loewenstein and Richard Thaler. Labor Supply of New York City Cabdrivers: One Day at a Time, the *Quarterly Journal of Economics*, 1997
- [10] Cramer J, Krueger A B. Disruptive change in the taxi business: The case of Uber[J]. *American Economic Review*, 2016, 106(5): 177-82.
- [11] Diakopoulos N. How Uber surge pricing really works [N]. *The Washington Post*, 2015-04-17(2)
- [12] Dong Y, Zhang Z, Fu R, et al. Revealing New York taxi drivers' operation patterns focusing on the revenue aspect[C]//2016 12th World Congress on Intelligent Control and Automation (WCICA). IEEE, 2016: 1052-1057.
- [13] Farber H S . Is Tomorrow Another Day? The Labor Supply of New York City Cabdrivers[J]. *Journal of Political Economy*, 2005, 113(1):46-82.
- [14] Gabel D. Uber and the Persistence of Market Power[J]. *Journal of Economic Issues*, 2016, 2: 527-534.
- [15] Hall J V , Krueger A B . An Analysis of the Labor Market for Uber's Driver-Partners in the United States[J]. *Ihr Review*, 2017:001979391771722.
- [16] Hurwicz L. The Design of Mechanisms for Resource Allocation[J]. *American Economic Review*, 1973, 63(2):1-30.
- [17] Kim K , Baek C , Lee J D . Creative destruction of the sharing economy in action: The case of Uber[J]. *Transportation Research Part A: Policy and Practice*, 2018, 110:118-127.
- [18] Maskin E S. Mechanism Design: How to Implement Social Goals[J]. *American Economic Review*, 2008, 98(3):567-576.
- [19] McAfee R. A dominant strategy double auction[J]. *Journal of Economic Theory*, 1992, 56(2):434-450.
- [20] Pueboobpaphan S, Indra-Payoong N, Opananon S. Experimental analysis of variable surcharge policy of taxi service auction[J]. *Transport Policy*, 2017,8:1-15.
- [21] Qin G , Li T , Yu B , et al. Mining factors affecting taxi drivers' incomes using GPS trajectories[J]. *Transportation Research Part C Emerging Technologies*, 2017, 79:103-118.

- [22] Tang L, Sun F, Kan Z, et al. Uncovering distribution patterns of high performance taxis from big trace data[J]. ISPRS International Journal of Geo-Information, 2017, 6(5): 134.
- [23] Zhan X, Qian X, Ukkusuri S. A Graph-based approach to measuring the efficiency of an urban taxi service system[C]. IEEE Transactions on Intelligent Transportation Systems, 2016, 17(9): 2479-2489.
- [24] Zhang S, Wang Z. Inferring Passenger Denial Behavior of Taxi Drivers from Large-Scale Taxi Traces[J]. Plos One, 2016, 12(2):e0171876.
- [25] Zheng J, Ren F, Tan Y, et al. Optimizing Two-Sided Promotion for Transportation Network Companies: A Structural Model with Conditional Bayesian Learning[J]. Social Science Electronic Publishing, 2016.

Information Mechanism Design in Online Car Hailing Platform and Driver's Working Strategies

LINGFANG LI

(School of Management, Fudan University)

XIANGHUA LU

(School of Management, Fudan University)

LIN FU

(UnionPay International Co.Ltd.)

SHAOQING HUANG

(Antai College of Economics and Management, Shanghai Jiaotong University)

Abstract: The customer's destination information mechanism drive the car drivers into two kinds of working strategy, which is called active order choosing(AOC) and passive order acceptance(POA), and the mechanism is cancelled due to the debate in the society. In this study, we used data from Didi in Dec 2015 to study how drivers' working strategies (AOC vs POA) affect their payoffs, and how does the difference change under different market demand. From PSM analysis, we find that working strategically(AOC) make drivers better off, and the positive effect is diminishing when the market demand is high. We also find that working strategically (AOC) works better no matter how the market demand condition is, and drivers can get higher daily income, hourly income, and higher loading rate when they work strategically. The thrive of mobile car hailing Apps make the way of car hailing being different, for instance, passengers need to send their request on the Apps first, then drivers decide whether to take the order, and drivers can decide how long to work. This study provides empirical evidence for the positive effect of customer's destination information mechanism and offer experience for the platform to improve their driver incentive mechanism.

Keywords: Sharing Economy, Online Car Hailing Platform, Information Mechanism Design, Incentive Mechanism

JEL Classification: L2, L9

(执行编辑：华岳)