

doi:10.19920/j.cnki.jmsc.2023.05.003

# 大数据驱动的决策范式转变<sup>①</sup>

——以个性化O2O即时物流调度为例

代宏砚<sup>1</sup>, 陶家威<sup>2\*</sup>, 姜海<sup>2</sup>, 周伟华<sup>3</sup>

(1. 中央财经大学商学院, 北京 100081; 2. 清华大学工业工程系, 北京 100084;  
3. 浙江大学管理学院, 杭州 310058)

**摘要:** 大数据环境下传统的决策范式正转变为基于数据的决策范式, 本文以O2O即时服务这种新型商业模式为情景, 研究大数据驱动的新决策范式下的O2O即时物流调度模型. 本文跨域融合物流部门、其他运营部门以及外部环境信息构成全景式数据, 同时放宽传统决策范式的经典假设, 实现从无差异化配送时间到个性化配送时间的转变, 以及需求服从先验分布到考虑未来需求时空属性的转变. 本文融合机器学习和运筹优化方法, 实现新决策范式下的O2O即时物流调度模型. 在预测层面, 构建个性化众包配送时间预测模型和基于订单集时空相似性的需求场景预测算法; 在决策层面, 同时考虑个性化预测模型的点估计及其不确定性, 并考虑未来订单集的时空分布, 构建考虑预测不确定性的调度模型, 同时设计同步预测和决策算法求解. 本文与中国主流的O2O商超平台合作, 通过基于真实数据的模拟仿真, 验证了新决策范式下的O2O即时物流调度模型的可行性和有效性. 相较于传统的决策范式, 本文提出的模型能实现更精准的供需匹配, 降低延误订单数、平均配送时间和配送成本.

**关键词:** 决策范式转变; 大数据驱动的决策; O2O即时物流; 个性化

**中图分类号:** F224.3 **文献标识码:** A **文章编号:** 1007-9807(2023)05-0053-17

## 0 引言

移动互联网、人工智能等新兴技术的发展和普及催生了大量新的商业模式. 这些新模式面临高度不确定的环境, 决策颗粒度和时效性要求极高, 传统的模型驱动的决策范式不再适用, 基于数据分析的决策逐渐成为主流<sup>[1]</sup>. 决策范式的转变主要体现在四个方面. 第一, 决策所涵盖的信息范围从单一领域向跨域融合转变; 第二, 决策者与受众的角色逐渐交互融合; 第三, 决策的理念假设从经典假设向宽假设, 甚至无假设转变; 第四, 决策流程从线性、分阶段过程向非线性过程转变<sup>[2]</sup>. 本文以O2O即时服务(Online-to-Offline on-

demand service)这种新型商业模式为背景, 聚焦跨域融合和宽假设这两个维度的转变, 研究大数据驱动的新决策范式下的O2O即时物流调度模型.

O2O即时服务是利用互联网使线下商品(或服务)与线上融合, 线上生成订单, 线下即时完成交付(通常需在半小时内到一小时内送达)的一种新型商业模式<sup>[3,4]</sup>. 基于庞大的国内消费市场和广泛普及的移动互联网, 中国已在O2O商业模式上走在世界前列. 以O2O外卖领域为例, 2020年中国O2O用户规模达4.56亿人, 市场规模达6646.2亿元<sup>[5]</sup>, 是我国经济主战场之一.

目前, 在O2O即时服务的物流实践中, 主流的平台采用系统派单模式, 例如美团外卖平台上

① 收稿日期: 2021-12-31; 修订日期: 2022-12-26.

基金项目: 国家自然科学基金资助重大研究计划培育项目(91646125); 国家自然科学基金资助项目(72172169); 国家自然科学基金资助重大项目(72192823); 中央高校基本科研业务费专项资金资助项目.

通讯作者: 陶家威(1995—), 男, 浙江临海人, 博士生. Email: taojw17@tsinghua.org.cn

的美团专送服务<sup>[6,7]</sup>。平台决定订单的分派和配送路线的规划,统筹考虑所有配送员的位置、待配送订单数目和所有订单的时间限制,以降低系统的总体成本为目标,完成订单分派。但目前基于现有配送算法的O2O即时物流的精细化管理水平还有待提升,物流配送的成本较高。比如美团外卖2021年的物流费用占平台年收入的70.79%,高达682亿<sup>[8]</sup>。目前业界O2O即时物流精细化管理水平较低的瓶颈体现在供需之间在空间和时间上的不匹配,具体体现在以下两个方面。

1) 在供给端,现有调度系统对于数据维度的使用不充分,只利用了订单维度数据,没有充分利用配送员维度的数据,从而导致决策不精准。

现有调度系统在优化订单分派时,多从订单这一个维度出发进行优化,而没有充分考虑配送员差异化配送速度的影响。Xu等<sup>②</sup>研究发现,在O2O即时物流场景中,众包配送员个人的能力、经验、行为不同,对于外部环境、平台激励机制的反应也不同,例如评级较高的配送员对于收入激励的敏感性较低,评级较低的配送员对于收入激励的敏感性较高。不考虑人和环境差异化的决策使得供需匹配不准确,一方面浪费能力强的配送员的配送能力,降低效率;另一方面增加能力较差的配送员的配送压力,造成更多的延误订单。因此建模时有必要同时考虑订单和配送员两个维度。然而现有研究通常假设将同一订单分配给不同配送员时,其需要的配送时间是一样的<sup>[9-18]</sup>。尽管部分研究也考虑配送速度受时间、路况天气或配送员类型的影响,及其对于订单分派的决策带来的挑战<sup>[19-21]</sup>。例如周鲜成等<sup>[19]</sup>考虑车辆不同出发时刻对行驶时间的影响,分析车辆时变速度、载重与碳排放率之间的关系,但仍假设不同配送员(或车辆)的速度是一致的,即不同配送员(或车辆)配送同一订单所花费的时间是一致的。这些研究的决策没有充分考虑人的维度的影响。因此O2O即时物流决策需要新的算法将配送员维度的特点也纳入建模考量,实现精准匹配配送员和订单,增加决策精准度,降低系统成本。

2) 在需求端,现有调度系统大多没有考虑未

来订单集的时空属性,从而无法进行全局优化。

现有调度系统大多只考虑当前已经出现的订单,没有考虑未来订单。然而在O2O即时物流场景中,由于订单的数目和分布随时间波动性高,低估未来的订单数目而将所有的运力都分配给当前的订单,可能造成未来的运力不足和更多的延误;高估未来的订单数目而保留部分目前的运力等待未来的订单,则可能造成运力的浪费和当前订单的延误。因此在O2O即时物流场景中考虑未来的需求非常必要。此外,O2O即时物流的需求不仅与订单的数目和时间分布有关,也与订单的空间分布强相关。因此建模时有必要同时考虑未来订单集的时间和空间两个维度。然而现有研究大多没考虑未来需求<sup>[9-23]</sup>,部分研究考虑未来需求时,假设未来需求服从特定的先验分布。例如Daryarian和Savelsbergh<sup>[24]</sup>考虑未来订单和顾客到达的概率信息对决策的帮助;Voccia等<sup>[25]</sup>通过考虑未来订单的统计信息,给出车辆是否应该继续在仓库等待的判断标准;Ulmer等<sup>[26]</sup>构建价值函数估计方法去预测每个区域产生订单的概率,并整合到动态规划模型中。但上述这些基于先验分布假设的研究方法并未考虑需求的时空属性,无法适用O2O即时物流场景。因此,O2O即时物流决策需要新的方法来预测未来订单集的时空分布,否则决策是短视且不精准的。

由此可知,O2O即时物流优化决策问题和现有的物流配送问题有所不同<sup>[27]</sup>。本文旨在借助新的技术和方法,转变决策范式,构建大数据驱动的O2O即时物流调度新决策模型,解决O2O即时配送面临的上述挑战,实现精细化运营。

## 1 大数据背景下O2O即时物流调度的决策范式转变

本文提出的大数据背景下O2O即时物流调度的决策范式的转变具有四个核心要素:宽假设、全景式数据、同时考虑预测点估计及其不确定性,预测与决策同步。下面逐一具体介绍。

② Xu Y, Lu B, Ghose A, et al. The interplay of earnings, ratings, and penalties on sharing platforms: An empirical investigation[J]. Management Science, 2023, DOI: <https://doi.org/10.1287/mnsc.2023.4761>.

首先,新决策范式下的调度模型实现假设转变,将决策假设从历史的、静态的假设转变为宽假设(如图 1 所示). 现有的物流决策大多在供给端假设配送时间一致,在需求端假设需求分布函数已知. 然而如前分析,这两个假设与 O2O 即时物流决策环境中的实际情况不符,导致决策的精准性下降. 因此,新决策范式下的调度模型将原假设转变为宽假设:在供给端,假设每个配送员在不同情况下配送不同订单的配送时长是不一致的;在需求端,假设需求具有时空属性,需要同时考虑未来订单集的时间和空间两个维度来进行决策.

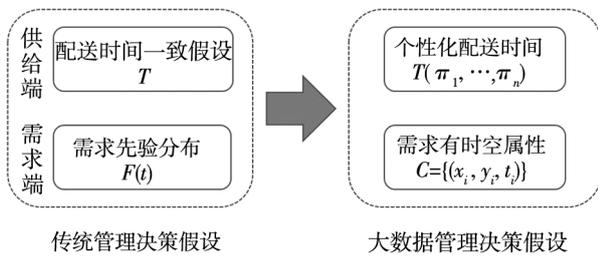


图 1 新决策范式下的 O2O 即时物流调度模型的假设转变

Fig. 1 The assumption transition of O2O on-demand logistics scheduling model under the new decision-making paradigm

其次,新决策范式下的调度模型实现跨域转变,将模型的数据输入从仅考虑物流相关数据转变为考虑物流、营销、企业外部等多维全景式数据(如图 2 所示). 要放宽配送时间一致的假设,需要了解众包配送员个人的能力、经验、行为,以及其对外部环境、平台激励机制的反应,否则无法准确预测个性化的配送时间. 此外,要放宽需求先验分布的假设,考虑未来订单集的时空分布,则需要了解企业促销、库存、app 运维等相关信息,以及外部的配送员分布和行为、天气、交通等信息. 这说明要实现宽假设,进行精细化管理,需要考虑内外部多维数据. 近年来,随着人工智能、大数据等技术的突破式发展,配送平台拥有庞大的交易量,凭借“互联网+智能手机”沉淀了海量数据,不仅包括内部物流部门的数据,还包括了其他部门的运营数据,以及外部的消费者、商家、配送员、环境的数据. 这为解决此问题提供了契机. 新决策范式下的调度模型利用企业沉淀下的海量数据<sup>[3,5]</sup>,将物流部门、其他运营部门、外部环境信息整合起来,进行跨界关联,构建全景式数据集来支持决策.

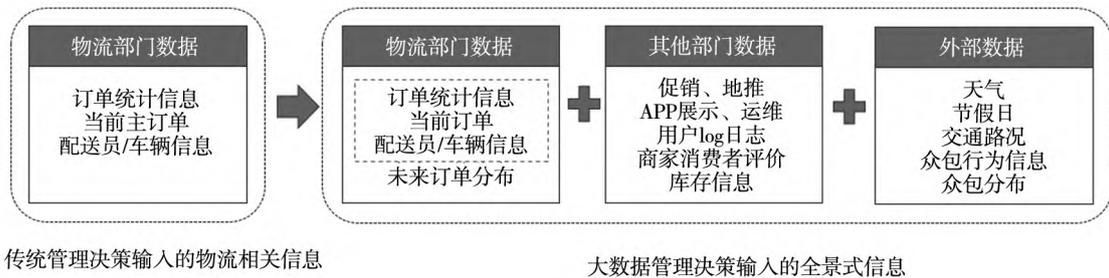


图 2 新决策范式下的 O2O 即时物流调度模型的跨域转变

Fig. 2 The cross-domain transition of O2O on-demand logistics scheduling model under the new decision-making paradigm

在上述两个假设转变的基础上,本文构建预测和决策两类模型,并进行有机融合. 预测层面,首先,充分利用订单、配送员和外部环境等多个维度的数据,基于机器学习的算法建立个性化众包配送时间预测模型,预测众包配送员个性化的配送时间. 其次,利用历史订单时空分布和外部环境两个维度的数据,构建订单集时空相似性度量方法,据此建立数据驱动的需求场景预测算法(scenario-based demand forecast algorithm)预测未来订单集. 决策层面,考虑未来订单集时空预测结果,并将个性化配送时间预测结果一起整合到配送决策模型中,实现精准的个性化决策.

在融合预测模型的配送决策模型的构建过程中,需要同时考虑预测点估计及其不确定性. 在配送决策模型的求解过程中,需同步预测和决策的特点,具体如下:

O2O 配送管理极高的时效性要求使得对配送时长的估计需要非常准确,而个性化配送时间受到内外部多维因素的影响,设计的特征集合可能无法穷尽所有的影响因素,这些无法刻画的因素会使得预测模型的点估计(point estimate)存在偏差. 预测结果的不确定性(forecast uncertainty)进而会影响派单和路径规划模型的决策质量. 例如,某一订单需要在 30 min 内完成配送,基于预

测模型对配送员 A 和配送员 B 完成该订单时间的点估计,二者都将会在 28 min 内完成.但配送员 A 和配送员 B 的预测结果的不确定性不同,即配送员 A 在 [25, 30] min 内完成,配送员 B 在 [24, 34] min 内完成.基于此信息,平台应该选择配送员 A.因为该决策一方面可以充分利用配送员 A 的服务能力,实现精准匹配;另一方面,可以降低配送员 B 的配送压力,减少延误概率,提高配送效率.然而,目前的配送决策缺乏系统性的方法来同时考虑配送时长预测的点估计及其不确定性.因此,本文提出一个预测不确定性的估计方法,并将预测的点估计及其不确定性一起建模到优化模型中.

将新决策范式下的数据驱动的预测模型融入到 O2O 即时物流调度模型中时,预测模型和决策模型深度耦合,对模型求解提出了新的挑战.目前的配送模型采用异步的方式进行决策,即在进行

配送决策之前,预测模型就已经计算出所有订单需要的配送时间<sup>[28-30]</sup>.而在 O2O 即时物流调度模型中,异步的思路是不可行的<sup>[31-34]</sup>.这是因为配送员配送订单需要的配送时间具有高度不确定性,与配送员的类型、订单的数目、订单之间的距离等多个因素直接相关,而这些特征由派单和路径规划决策决定,因此在给出具体的物流决策方案之前,预测模型无法给出每个配送员需要的配送时间,而决策模型通过最小化成本给出决策,配送员的配送时间会直接影响订单的延误,进而影响决策的成本.因此新范式从预测和决策异步进行转变为将预测和决策统一在同一框架下同步进行.

以上四点是大数据背景下 O2O 即时物流调度的决策范式转变的要素,如图 3 所示.下文将具体介绍新决策范式下的 O2O 即时物流调度模型,以阐述上述决策范式的转变是如何实现的.

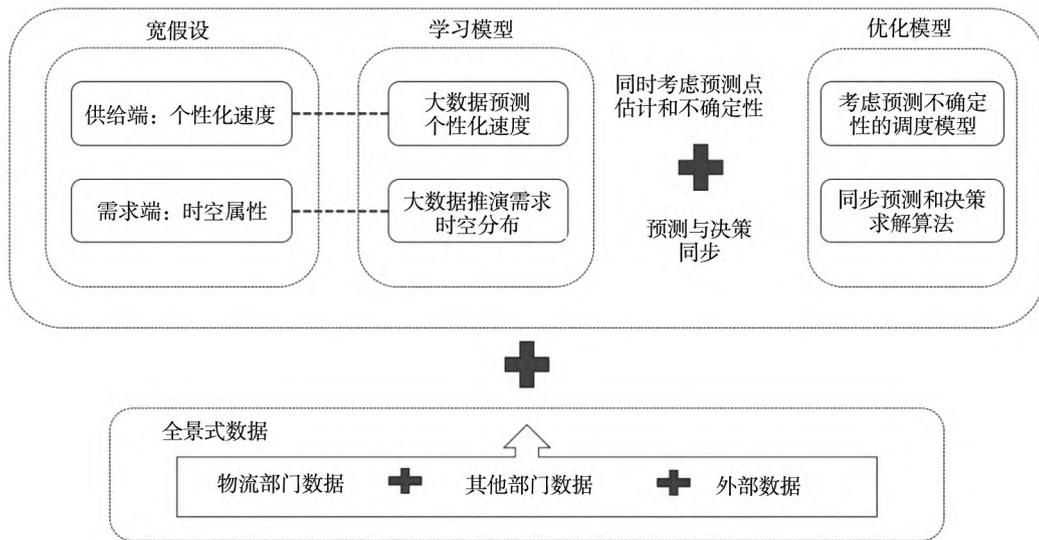


图3 大数据背景下 O2O 即时物流调度的决策范式转变框架

Fig. 3 The framework of decision-making paradigm transition of O2O on-demand logistics system in the context of big data

## 2 新决策范式下的 O2O 即时物流调度模型

在 O2O 即时物流场景中,需求端订单的数目和位置存在高度不确定性,供给端的众包配送员服务订单的配送时间存在高度不确定性.针对供需两端的不确定性,一方面,本文基于历史订单数

据、历史物流日志、外部环境信息以及平台反馈的订单、轨迹等特征,建立个性化众包配送时间预测模型,给出个性化的配送时间.另一方面,本文基于订单集时空相似性的需求场景预测算法,通过比较当前场景和历史场景的相似性,从历史数据中选择合适的场景作为未来订单集的预测.通过将两个预测模型融入调度决策模型,建立新决策范式下的考虑预测不确定性的 O2O 即时物流调度模型.

第 2.1 节介绍 O2O 即时物流调度问题的定义,第 2.2 节介绍个性化众包配送时间预测模型的实现方法,第 2.3 节介绍基于订单集时空相似性的需求场景预测算法的实现方法,第 2.4 节介绍考虑预测不确定性的 O2O 即时物流调度模型的实现方法。

### 2.1 O2O 即时物流调度问题定义

O2O 即时物流系统中,平台会不断地收到用户的新订单.每隔一段时间,平台需要根据新收到的订单和当前的配送员信息将订单分派给不同的配送员并规划他们的路径.因此,该调度问题可以被描述为一个动态的派单和路径规划问题,通常以一天的工作时间  $T$  为一个运营周期,例如早上 8 点至晚上 11 点.在一个运营周期  $[0, T]$  内,顾客通过在线平台实时下单,每隔一个固定的时间段  $T_d$ ,例如 5 min,平台会执行一次派单和路径规划决策,将订单分派给合适的配送员并让配送员按给定的配送顺序完成订单的配送,这个过程被称为一个调度周期.假设  $T$  是  $T_d$  的倍数,则一个运营周期包含的调度周期可以表示为  $\Gamma = \left\{1, \dots, \frac{T}{T_d}\right\}$ .对于  $\Gamma$  中的每个调度周期  $t$ ,平台需要将订单分派给配送员,并为每个配送员找到最优的配送路线.

本文通过建立基于订单集时空相似性的需求场景预测算法,同时考虑未来订单集的数目和空间分布,从而提高决策的精准度.在每个调度周期的优化决策中,需要考虑三种类型的订单.第一种类型是已分派但未完成的订单,它们在调度周期  $t$  之前已经生成,在之前的调度周期中分派给配送员,但配送员尚未完成他们的配送,平台无法调整这些订单的分派,但可以调整这些订单的配送次序.第二种类型是当前订单,它们是在调度周期  $t$  中创建的.第三种类型是未来订单,通过建立模型来预测未来的订单分布,可以避免调度决策陷入短视.

本文使用  $O_a^t = \{1, \dots, n_a^t\}$ ,  $O_c^t = \{n_a^t + 1, \dots, n_a^t + n_c^t\}$ ,  $O_f^t = \{n_a^t + n_c^t + 1, \dots, n_a^t + n_c^t + n_f^t\}$ ,  $D_a^t = \{n_a^t + n_c^t + n_f^t + 1, \dots, 2n_a^t + n_c^t + n_f^t\}$ ,  $O_c^t = \{2 \times n_a^t + n_c^t + n_f^t + 1, \dots, 2n_a^t + 2n_c^t + n_f^t\}$  和  $O_f^t = \{2n_a^t + 2n_c^t + n_f^t + 1, \dots, 2n_a^t + 2n_c^t + 2n_f^t\}$  分别代表三种类型订单的起点和终点集合,其中  $n_a^t$ ,  $n_c^t$  和  $n_f^t$  分别

已分派、当前和未来的订单数目,  $n^t = n_a^t + n_c^t + n_f^t$  代表总订单数目.每个订单  $c_i$  包含一个起点  $i$  和一个终点  $i + n^t$ .

本文用有向图  $G^t = (N^t, A^t)$  代表 O2O 即时物流调度问题的网络,其中  $N^t = O_a^t \cup O_c^t \cup O_f^t \cup D_a^t \cup D_c^t \cup D_f^t \cup \{0\}$  代表所有地点的集合,其中  $\{0\}$  为本文添加的虚拟节点.  $A^t$  代表所有地点之间的路径的集合.对于任意  $(i, j) \in A^t$ ,令  $d(i, j)$  代表从节点  $i$  到节点  $j$  的距离,两个实际节点之间的距离  $d(i, j)$  由高德 API 计算,虚拟节点与其他任意节点的距离为 0.对于每个节点  $i$ ,令  $q_i$  代表节点的类型:当  $q_i = 1$  时,代表节点  $i$  是出发点;当  $q_i = -1$  时,代表节点  $i$  是目的地.对于每个节点  $i$ ,均有时间窗  $[e_i, l_i]$  代表可行的时间,其中  $e_i$  为对应订单生成的时间,  $l_i = e_i + T_{\max}$ ,  $T_{\max}$  为平台承诺的订单配送时间的上限.  $O_h^t \cup D_h^t$  和  $\{[e_i, l_i]\}$ ,  $i \in O_h^t \cup D_h^t$ , 分别代表三种类型订单集  $C_h^t$ ,  $h = a, c, f$  的空间和时间信息.当订单的完成配送时间大于  $l_i$  时,会产生额外的延误成本.

本文定义  $K^t = \{1, \dots, m^t\}$  代表调度周期  $t$  所有可用的配送员的集合,其中  $m^t$  代表可用的配送员的数目.他们在调度周期  $t$  时的初始位置  $O_k^t = \{2n^t + 1, \dots, 2n^t + m^t\}$ .对于每个配送员  $k$ ,本文使用  $Q_k^t$  代表每个配送员的配送能力.

### 2.2 个性化众包配送时间预测模型

为了放松配送时间一致这个假设,需要构建个性化配送时间预测模型.该预测模型构建的挑战在于预测精度和颗粒度之间的矛盾.O2O 即时物流场景中,众包配送员的服务能力存在差异<sup>[5]</sup>,因此在建立众包配送时间预测模型时,一方面,针对所有配送员训练一个预测模型,预测颗粒度太大,会造成预测模型无法刻画配送员的个性化特点;另一方面,针对每一个配送员训练一个配送时间预测模型,虽然可以得到更加符合每个配送员个人特征的预测结果,但在现实环境中,部分众包配送员由于工作时间短、服务订单数少等原因,产生的订单数据较少.对这些配送员,预测模型的训练样本少,会使得预测模型欠学习,导致预测精度差,影响后续精准建模.

为解决预测精度和颗粒度之间的矛盾,本文提出基于聚类的配送员个性化配送时间预测的算

法,通过聚类,将个人能力、经验、偏好相似的配送员合并到同一个集合中,利用集合内所有配送员的数据完成配送时间预测模型的训练,以解决训练数据样本不足的问题. 本文提取  $\{F_k\}_{k \in K}$  作为配送员的聚类特征,包括配送员的工作时间、接单数、绩效、延误率等指标. 构建该聚类模型挑战在于如何确定聚类的类目数量. 聚类的类目数量太多则可能存在有些类目包含的样本量少,无法解决预测欠学习的问题;聚类的类目数量太少则较多配送员样本混合,每一类配送员的行为偏差变大,个性化预测能力降低.

本文通过建立同步聚类和预测的模型来确定聚类的类目数量,即设定优化目标为:寻找最优的类目数量  $L$  和聚类方案,使得全部配送员的配送时间模型预测误差最小. 如式(1)所示.

$$\min_L \min_{k \in K} e_k = \min_L \min_{l=1}^L \sum_{k \in K_{l,L}} \|g_{l,L}(\Pi_k) - T_k\| \tag{1}$$

其中  $K$  表示全部配送员的集合,  $e_k$  表示配送员  $k$  的配送时间预测误差,  $T_k$  表示配送员  $k$  的从一个地点到另一个地点的实际配送时间,  $\Pi_k$  为预测函数的特征矩阵.  $L$  代表聚类的类目总数,  $l$  代表聚类后的第  $l$  个配送员集合.  $K_{l,L}$  为聚类的类目总数为  $L$  时,第  $l$  个配送员集合中的全部配送员,  $g_{l,L}(\cdot)$  为将集合  $K_{l,L}$  中全部配送员的样本输入机器学习算法得到的配送时间预测模型,将配送员  $k$  的配送时间特征矩阵  $\Pi_k$  代入模型中即可得到配送员  $k$  对应配送时间的预测值  $g_{l,L}(\Pi_k)$ .

预测模型的特征选取对于预测的精度至关重要, Xu 等和 Dai 等<sup>[35, 36]</sup> 针对影响配送员的配送意愿的相关因素展开了实证研究,基于已有研究

和对 O2O 企业运营的调研,本文跨域融合配送员的个人能力、经验、偏好、历史参与、天气、节假日、取送点属性、需求分布等信息,构建全景式数据,从中挖掘多个维度的与配送时间相关的特征,具体如下:

- 1) 轨迹相关的特征:通过接单数、总距离等特征刻画配送员从门店出发到配送完成所有订单的一趟轨迹;
- 2) 配送员相关的特征:通过工作天数、延误订单数等特征刻画配送员的个人能力、经验、偏好、历史参与;
- 3) 区域相关的特征:通过该区域访问次数等特征刻画配送员对不同区域的熟悉程度;
- 4) 外部环境相关的特征:通过天气、节假日等特征刻画配送员工作环境的变化.

基于上述多维度的特征,可以更好地刻画配送员的配送时间受个人能力、经验、行为、外部环境等因素的影响.

本节建立的同步聚类和预测的配送员个性化配送时间预测算法不依赖于预测函数  $g_{l,L}(\cdot)$  的具体形式. 在数值实验部分,本文将采用 LASSO、随机森林、SVR 等多种基本的预测算法进行训练,并比较不同算法的预测精度. 式(1)的求解过程如表 1 所示. 将全部配送员依据聚类特征分成  $L$  类,并对每一类配送员进行预测,计算预测误差总和,选择使得所有配送员的预测误差总和最小的类目数量  $\hat{L}$ . 通过同步处理聚类和预测,该算法可以针对所有配送员找到合适的聚类类目数量,以保证每一个类目下的配送员行为特点相似,且有足够的训练样本以避免欠学习的情况发生.

表 1 基于聚类的配送员个性化配送时间预测算法  
Table 1 Clustering-based personalized delivery time forecast algorithm

输入	全部配送员的聚类特征 $\{F_k\}_{k \in K}$ , 配送时间 - 特征矩阵 $\{T_k, \Pi_k\}_{k \in K}$ , 聚类的类目数量上限 $L_{\max}$ , 聚类迭代步数 $I_{\max}$
输出	聚类结果和预测模型
1	for $L = 1; L \leq L_{\max}, L++$ do
2	随机选择 $L$ 个配送员作为初始配送员集合 $\{K_{l,L}\}_{l \in L}$
3	for $i = 1; i \leq I_{\max}; i++$ do
4	对于每个配送员集合 $l$ , 计算配送员集合质心 $u_{l,L} = \sum_{k \in K_{l,L}} F_k /  K_{l,L} $
5	对于每个配送员, 计算配送员 $k$ 与每个配送员集合 $K_{l,L}$ 质心的距离 $dis_{k,l,L} = \ F_k - u_{l,L}\ $
6	选取距离最小的集合 $K_{l^*,L}$ , 即 $l^* = \underset{l}{\operatorname{argmin}} dis_{k,l,L}$

续表 1  
Table 1 Continues

输入	全部配送员的聚类特征 $\{F_k\}_{k \in K}$ , 配送时间 - 特征矩阵 $\{T_k, \Pi_k\}_{k \in K}$ , 聚类的类目数量上限 $L_{\max}$ , 聚类迭代步数 $L_{\max}$
输出	聚类结果和预测模型
7	将配送员 $k$ 分配到配送员集合 $K_{l^*, L}$
8	end for
9	对于每个配送员集合, 基于基础预测算法 $\Delta$ 用配送员集合 $K_{l, L}$ 的全部样本训练配送时间模型
10	利用验证集计算配送员集合 $K_{l, L}$ 的预测误差 $e_{K_{l, L}} = \ g_{l, L}(\Pi_k) - T_k\ $
11	计算所有配送员的预测误差总和 $\sum_{l=1}^L e_{K_{l, L}}$
12	end for
13	选取使得所有配送员的预测误差总和最小的 $\hat{L}$
14	记录聚类的类目数量为 $\hat{L}$ 时的配送员配送时间预测模型

2.3 基于订单集时空相似性的需求场景预测算法

要实现考虑未来订单时空分布这个宽假设, 需要构建一个预测算法, 以实现对未来订单集的时间 - 空间属性的预测, 然而目前没有一个针对需求时间 - 空间属性的预测算法. 在传统决策中, 通常假设未来的需求服从先验分布, 从而实现对未来需求的预测. 但在 O2O 即时物流场景中, 订单出现的位置是高度不确定的, 因此订单的数目和空间分布都会影响订单的分派决策, 这给未来订单集的预测带来了极大的挑战. 基于先验分布假设的研究方法通常仅考虑需求的数目, 没有考虑需求的空间属性. 通常考虑数目和空间属性的方法是估计每一个消费者的购买概率或每个区域的订单出现概率, 基于这些规律随机生成未来的订单<sup>[37, 38]</sup>. 但在 O2O 即时物流场景中, 其配送规模很大, 拥有数量庞大的商家和消费者, 通常在 1 个 5 km × 5 km 的配送区域内, 拥有超过 100 个商家, 近万的消费者, 组成一个大规模的配送网络, 但对于一个调度周期, 配送区域内的 5 min 的订单数目一般不到 100 个, 配送网络的连接非常稀疏. 对于大规模的稀疏网络, 消费者的购买概率非常小, 从消费者或订单个体层面来预测订单集会产生较大偏差, 是不可行的.

目前有部分研究通过场景推演的思路来预测未来需求的时空分布, 例如 Li 等<sup>[39]</sup> 选取历史场景片段的订单集作为未来的需求场景, 改善调度决策的精准性. 现有的场景推演算法直接选取之前若干天的历史场景片段, 未考虑场景变化的规

律. 但在 O2O 即时物流场景中, 不同场景的变化很大. 选择不合适的场景时, 由于订单的数目和分布与真实情况存在较大的偏差, 会使得平台无法给出精准的决策, 甚至使决策的绩效低于仅考虑当前订单的决策. 例如, 给决策模型输入的订单集显示未来的订单数目较少, 因此平台优先保障当前订单的配送任务, 将尽可能多的运力用于完成当前的订单, 而实际上未来的订单数目较多, 这就会造成平台在未来承担更多的延误. 因此对于场景推演算法, 核心的挑战是如何找到与当前场景最相似的历史场景, 从而实现更精准的预测.

为解决该挑战, 本文提出基于订单集时空相似性的需求场景预测算法 (如表 2 所示). 该算法融合内外部跨域信息, 考虑了外部和内部两大类特征. 首先计算当前场景与历史场景外部和内部特征的距离  $dis_1^{t, s}$  和  $dis_2^{t, s}$ , 然后计算当前时刻与历史场景库中不同场景的加权时空距离  $D^{t, s} = \sum_{i=1}^n \rho_i dis_i^{t, s}, n = 2$ . 选取最小的加权时空距离所对应的场景  $s^*$ , 将场景  $s^*$  往后时长  $\tau^s$  的订单集作为预测的未来订单集  $C_f^s$ , 订单集中的每个订单  $c_i$  应包括起点  $o_i$ 、终点  $d_i$  和时间窗  $[e_i, l_i]$ , 以期实现对未来需求场景准确的时空分布预测.

该算法的重点如何计算  $dis_1^{t, s}$  和  $dis_2^{t, s}$ , 具体阐述如下:

1) 外部特征距离  $dis_1^{t, s}$ . Huang 等<sup>[40]</sup> 和 Dai 等<sup>[41, 42]</sup> 对影响即时物流系统的订单数目的相关特征进行了研究, 本文基于已有研究和对企业运营的调研, 挖掘物流部门之外其他部门的信息, 以

及外部环境信息,构建外部特征集  $F_1^t = [f_{1,1}^t, \dots, f_{1,m}^t]$ ,特征包括天气、节假日、周几、促销信息等  $m$  个特征,对于历史场景  $s$ ,提取场景  $s$  的外部环境特征  $F_1^s = [f_{1,1}^s, \dots, f_{1,m}^s]$ .对所有特征做归一化处理,采用余弦距离计算当前时刻与场景  $s$  的外部环境距离为

$$dis_1^{t,s} = \frac{\sum_{i=1}^m f_{1,i}^t \cdot f_{1,i}^s}{\sqrt{\sum_{i=1}^m f_{1,i}^t{}^2} \cdot \sqrt{\sum_{i=1}^m f_{1,i}^s{}^2}} \quad (2)$$

2) 内部特征距离  $dis_2^{t,s}$ . 基于物流部门积累的历史订单信息,可以分析订单场景的演变规律.对于调度周期  $t$ ,提取  $t-p, \dots, t-1$  时刻的订单集  $C_{t-p}, \dots, C_{t-1}$ .对于过去的备选场景  $s$  对应的时刻  $t'$ ,同样可以得到订单集  $C_{t'-p}, \dots, C_{t'-1}$ .通过分析两个时刻过去的订单集之间的时空相似性,可以比较两个时刻的场景相似性.

订单集之间的时空相似性度量  $D^{CC}(C_{t-i}, C_{t'-i})$  是该算法设计的难点.本文参考已有文献<sup>[43,44]</sup>,进一步考虑订单数目、订单的时间-空间分布关系,提出的订单集时空相似性度量计算过程如下:

首先,本文定义订单  $c_i, c_j$  之间的距离如式(3)所示.该式的含义为将一个订单变动为另一个订单时,变动订单起点和终点所需的空间距离与变动订单生成时间的距离的加权和,其中  $\bar{v}$  代表所有配送员的平均配送速度

$$D^{cc}(c_i, c_j) = \frac{d(i, j) + d(i + n, j + n)}{\bar{v}} + |e_i - e_j| \quad (3)$$

其次,本文定义订单  $c_i$  和订单集  $C_j$  之间的时空相似性如式(4)所示.该式的含义为该订单  $c_i$  离订单集  $C_j$  中的每个订单的距离  $D^{cc}(c_i, c_k), \forall c_k \in C_j$  的最小值

$$D^{CC}(c_i, C_j) = \min_{c_k \in C_j} D^{cc}(c_i, c_k) \quad (4)$$

最后,本文给出两个订单集  $C_i, C_j$  之间的距离度量公式,定义为每个订单集中的每个订单  $c_k$  到另一订单集的距离  $D^{CC}(c_i, C_j), \forall c_k \in C_i$  的平均值,如式(5)所示

$$D^{CC}(C_i, C_j) = \frac{\sum_{c_k \in C_i} D^{CC}(c_k, C_j) + \sum_{c_k \in C_j} D^{CC}(c_j, C_i)}{|C_i| + |C_j|} \quad (5)$$

基于式(3)~式(5),通过分析一个订单集变动为另一个订单集需要的移动距离,可以得到衡量两个订单集时空相似性的度量指标  $D^{CC}(C_i, C_j)$ .基于该度量,则两个场景的订单集时空相似性度量为过去  $p$  个订单集的时空相似性的均值,如式(6)所示.

$$dis_2^{t,s}(t, t') = \frac{\sum_{i=1}^p D^{CC}(C_{t-i}, C_{t'-i})}{p} \quad (6)$$

基于式(2)和式(6),可得到不同场景的内外部特征的距离度量.

表 2 基于订单集时空相似性的需求场景预测算法

Table 2 Spatiotemporal similarity-based demand scenario forecast algorithm

输入	调度周期 $t$ , 调度决策周期时长 $\tau^a$ , 场景片段时长 $\tau^s$ , 历史场景库 $S$
输出	与当前调度场景最相似的场景所包含的订单集 $C_j^t$
1	提取调度周期 $t$ 的场景特征集 $\hat{F}^t = \{F_1^t, \dots, F_n^t\}$ , 场景特征集由若干类不同维度的特征组成
2	for $s \in S$ do
3	对于场景 $s$ , 提取场景的特征集 $\hat{F}^s = \{F_1^s, \dots, F_n^s\}$
4	计算调度时刻 $t$ 的场景与场景 $s$ 的特征子集 $F_i^t, F_i^s (i = 1, \dots, n)$ 之间的距离 $dis_i^{t,s}$
5	调度时刻 $t$ 的场景与场景 $s$ 的距离是多维特征的距离的加权平均, $D^{t,s} = \sum_{i=1}^n \rho_i dis_i^{t,s}$ , 其中 $\sum_{i=1}^n \rho_i = 1$
6	选取与当前场景距离最小的场景 $s^*$ , 其中 $s^* = \min_s D^{t,s}, s \in S$
7	提取场景 $s^*$ 往后时长 $\tau^s$ 的订单集作为预测的未来订单集 $C_j^t$
8	end for

### 2.4 考虑预测不确定性的 O2O 即时物流调度模型

在众包配送员的配送时间存在差异的情况下,需要在配送决策过程中,实时预测某个订单/订单集分派给不同配送员需要的配送时间,并基于未来订单集的时空预测结果,给出符合配送员个人配送能力的订单分派和路径规划方案,提高决策精准度.

具体来讲, O2O 即时物流调度模型的优化目标为最小化延误成本和旅行成本.优化的决策包括:配送员  $k$  是否经过从节点  $i$  到节点  $j$  的边  $x_{ijk}^t$  ( $0-1$  变量,  $x_{ijk}^t = 1$  代表配送员  $k$  经过从节点  $i$

到节点  $j$  的边, 否则  $x_{ijk}^t = 0$ ); 订单  $i$  是否被分配给配送员  $k$  完成配送  $y_{ik}^t$  ( $0-1$  变量,  $y_{ik}^t = 1$  代表订单  $i$  被分配给配送员  $k$ , 否则  $y_{ik}^t = 0$ ).

将个性化众包配送时间预测模型和基于订单集时空相似性的需求预测场景算法纳入即时物流调度模型, 给出优化的目标函数如下

$$\min_{X, Y} \sum_{i \in D_a \cup D_c \cup D_f} \hat{c}_p (\tilde{B}_i^t - l_i^t)^+ + \sum_{k \in K^t} \hat{c}_d \bar{L}_k^t \quad (7)$$

其中  $\tilde{B}_i^t$  表示订单  $i$  的配送完成时间,  $l_i^t$  表示订单  $i$  的最晚送达时间,  $\bar{L}_k^t$  表示配送员  $k$  的总旅行时间,  $\hat{c}_p$  和  $\hat{c}_d$  分别表示延误时间和旅行时间的单位成本.

由于存在未被刻画的特征、随机性因素的影响, 与预测模型的预测结果相比, 真实的配送时间存在不确定性, 因此  $\tilde{B}_i^t$  不是一个确定值, 与预测模型的预测不确定性相关. 因此, 本文基于预测函数  $g_{l, \hat{l}}(\cdot)$ , 计算配送员完成每个订单时的配送时间预估值, 并与数据集中记录的真实值  $T_k$  进行比较, 得到配送时间的预测误差. 记录数据集中的所有预测误差集合  $\{T_k - g_{l, \hat{l}}(\Pi_k) \mid k \in K\}$ , 可以得到误差的累积密度函数  $F_{l, \hat{l}}(x)$ ,  $F_{l, \hat{l}}(x)$  代表预测误差小于  $x$  的概率, 由预测误差集合中小于  $x$  的元素比例得到, 如式(8)所示, 据此可以度量配送时间预测模型的不确定性

$$F_{l, \hat{l}}(x) = \frac{|\{T_k - g_{l, \hat{l}}(\Pi_k) < x \mid k \in K\}|}{|\{T_k - g_{l, \hat{l}}(\Pi_k) \mid k \in K\}|} \quad (8)$$

基于个性化众包配送时间预测模型的预测残差分布, 计算出订单  $i$  的配送完成时间的概率分布  $p_{ik}^t(y) = p_{ik}^t(y - 1 < B_i^t + \varepsilon < y) = F_{l, \hat{l}}(y - B_i^t) - F_{l, \hat{l}}(y - 1 - B_i^t)$ , 从而得到完整的模型如下

$$\min_{X, Y} \sum_{i \in D_a \cup D_c \cup D_f} \sum_y p_{ik}^t(y) \hat{c}_p (y - l_i^t)^+ + \sum_{k \in K^t} \hat{c}_d \bar{L}_k^t \quad (9)$$

s. t.

$$\sum_{j \in N^t, j \neq i} x_{ijk}^t = y_{ik}^t, \forall i \in O_c^t \cup O_f^t, k \in K^t \quad (10)$$

$$\sum_{k \in K^t} y_{ik}^t = 1, \forall i \in O_c^t \quad (11)$$

$$\sum_{k \in K^t} y_{ik}^t \leq 1, \forall i \in O_f^t \quad (12)$$

$$\sum_{j \in N^t, j \neq i} x_{ijk}^t - \sum_{j \in N^t, j \neq i} x_{i+n^t, jk}^t = 0 \quad \forall i \in O_c^t \cup O_f^t, k \in K^t \quad (13)$$

$$\sum_{j \in N^t, j \neq i} x_{ijk}^t = \min\{1 - \hat{z}_{ik}^t, \hat{y}_{ik}^t\}, \forall i \in O_a^t, k \in K^t \quad (14)$$

$$\sum_{j \in N^t} x_{i+n^t, jk}^t = \hat{y}_{ik}^t, \forall i \in O_a^t, k \in K^t \quad (15)$$

$$\sum_{j \in N^t} x_{2n^t+k, jk}^t = \sum_{j \in N^t} x_{j0k}^t = 1, \forall k \in K^t \quad (16)$$

$$\sum_{j \in N^t, j \neq i} x_{ijk}^t - \sum_{j \in N^t, j \neq i} x_{ijik}^t = 0, \forall i \in N^t, k \in K^t \quad (17)$$

$$B_j^t \geq (B_i^t + g_{l, \hat{l}}(\Pi(x, y))) \left( \sum_{k \in K^t} x_{ijk}^t \right) \quad \forall i, j \in N^t, i \neq j \quad (18)$$

$$B_i^t \geq e_i, \forall i \in N^t \quad (19)$$

$$L_j^t \geq (L_i^t + g_{l, \hat{l}}(\Pi(x, y))) \left( \sum_{k \in K^t} x_{ijk}^t \right), \forall i, j \in N^t, i \neq j \quad (20)$$

$$\bar{L}_k^t \geq L_i^t x_{i0k}^t, \forall i \in N^t, k \in K^t \quad (21)$$

$$Q_{jk}^t \geq (Q_{ik}^t + q_j) x_{ijk}^t, \forall i, j \in N^t, i \neq j, k \in K^t \quad (22)$$

$$Q_{2n^t+k, k}^t \geq Q_k, \forall k \in K^t \quad (23)$$

$$\max\{0, q_i\} \leq Q_{ik}^t \leq \min\{Q_k, Q_k + q_i\} \quad \forall i \in N^t, k \in K^t \quad (24)$$

$$x_{ijk}^t \in \{0, 1\}, \forall i, j \in \hat{N}^t, i \neq j, k \in K^t \quad (25)$$

$$y_{ik}^t \in \{0, 1\}, \forall i \in O_c^t \cup O_f^t \quad (26)$$

$$B_i^t \geq 0, \forall i \in \hat{N}^t \quad (27)$$

$$L_i^t \geq 0, \forall i \in \hat{N}^t \quad (28)$$

$$Q_{ik}^t \geq 0, \forall i \in \hat{N}^t \quad (29)$$

其中约束(10)~约束(13)为订单唯一性约束, 保证每个订单只由一个配送员完成配送服务; 约束(14)~约束(15)为已分配订单约束, 为针对在调度决策时刻  $t$  之前已经被分配给配送员但尚未完成的订单的路径规划决策约束; 约束(16)~约束(17)为配送员的路径流量平衡约束, 保证配送员的路径的连续性以及每个节点只到达一次; 约束(18)~约束(21)为配送时间约束, 构建派单和路径规划决策和每个订单的完成时间、配送员的总旅行时间之间的关系; 约束(22)~约束(24)为容量约束, 保证配送员的接单数不超过其服务能力限制; 约束(25)~约束(29)为符号定义域约束,

确定每个决策变量的取值范围.

上述新决策范式下的调度模型和现有多数调度模型的差异主要体现在以下几个方面.

1) 放宽未来需求服从先验分布的假设, 跨域融合企业内外部多维数据, 基于订单集时空相似性的需求场景预测算法得到预测订单集合  $C'_j$ , 将这部分订单纳入模型中, 增加了调度决策模型中考虑的订单总数, 问题规模变大, 增加了求解复杂度.

2) 放宽配送时间一致的假设, 将跨域融合多维数据构建的个性化的配送时间预测模型纳入考量(见约束(18)和约束(20)中的  $g_{i,l}(\Pi(x, y))$ ), 支持精准决策, 对不同决策方案进行评估时, 需要基于个性化的配送时间预测模型给出每个配送员完成订单需要的配送时间, 与固定的配送时间相比, 增加了评估不同决策方案的复杂度.

3) 通过历史数据计算预测模型的残差分布函数  $F_{i,l}(\cdot)$ , 计算配送员完成订单需要的配送时间的概率分布  $p'_{ik}(\cdot)$ , 实现延误成本的准确估计. 这将预测模型的点估计及其不确定性同时纳入决策模型, 但增加了计算不同决策方案下目标函数的复杂度.

4) 个性化预测模型的融合使得传统的先预测再决策的异步求解方法(即先将特征值代入预测模型得到预测值, 再将预测值代入到优化模型中)失效. 因为个性化配送时间预测模型的特征  $\Pi(x, y)$  受模型决策变量的影响. 例如接单数、轨迹距离等特征, 受到派单决策的影响, 无法在给出决策方案前获得个性化配送时间预测模型的特征的具体值. 因此将预测模型融合到目标函数中后, 预测特征和决策方案的耦合, 使得无法在优化决策制定前完成预测.

上述特点对求解算法提出了挑战, 本文基于禁忌搜索的算法思路<sup>[34]</sup>, 建立同步预测和决策的算法来进行求解, 让二者在统一框架下同步完成, 实现预测和决策深度融合, 如表 3 所示. 算法首先生成一个初始决策方案作为当前决策方案, 然后通过移动一个订单的分派关系来寻找当前决策方案的邻域集, 对于邻域集中的每一个决策方案, 计算预测模型对应的特征, 基于预测模型得到每个订单的配送时间, 然后得到每一个决策方案的绩

效, 将邻域集中最优的决策方案作为下一个决策方案, 并将原方案加入禁忌列表. 通过该算法可以首先生成决策方案, 再结合预测模型来评估决策方案, 并通过搜索来寻找更优的决策方案, 从而解决了同步预测和决策的难点.

表 3 同步预测和决策的配送决策求解算法

Table 3 Delivery decision solving algorithm for simultaneous forecast and decision model

输入	订单集 $C'$ ; 配送员集合 $K'$ ; 最大迭代步数 $L$ ; 禁忌列表中的决策方案被禁止选择的迭代步数 $\theta$ ;
输出	订单分派决策 $y'_{ik}$ ; 路径规划决策 $x'_{ijk}$ ;
1	生成一个可行的初始决策方案作为当前决策方案 $(X_0, Y_0)$
2	将当前决策方案 $(X_0, Y_0)$ 作为最优方案 $(X_b, Y_b)$
3	for $l = 1; l \leq L; l++$ do
4	通过调整一个订单的分派或配送次序, 建立当前决策方案的邻域决策方案集合 $S_l$
5	检查 $S_l$ 中的每一个决策方案, 移除无法满足容量约束和在禁忌列表中的决策方案
6	针对决策方案集中的每一个方案 $(X_i, Y_i) \in S_l$ , 通过计算预测模型的特征 $\Pi(x, y)$ 、每个订单的配送时间, 得到总成本 $f_i$
7	选择决策方案集合 $S_l$ 中的最优决策方案 $i^* = \operatorname{argmin}_i f_i$
8	如果决策方案 $(X_{i^*}, Y_{i^*})$ 优于最优决策方案 $(X_b, Y_b)$ , 即 $f_{i^*} < f_b$ , 则选择决策方案 $(X_{i^*}, Y_{i^*})$ 作为最优决策方案 $(X_b, Y_b)$ , 即 $(X_b, Y_b) \leftarrow (X_{i^*}, Y_{i^*})$
9	将当前决策方案 $(X_0, Y_0)$ 加入禁忌列表, 并将禁忌列表中已保留 $\theta$ 次迭代的决策方案移除
10	选择 $(X_{i^*}, Y_{i^*})$ 作为新的当前决策方案, 即 $(X_0, Y_0) \leftarrow (X_{i^*}, Y_{i^*})$
11	end for
12	输出 $(X_b, Y_b)$ 作为最终决策方案

### 3 数值实验

本节基于真实的订单数据来验证本文提出的 O2O 即时物流调度决策模型的有效性, 以及放宽假设和跨域融合对于 O2O 即时物流调度决策的影响.

#### 3.1 数据集简介

本文使用的数据集来自全国最大的 O2O 商超配送平台之一. 数据集为北京市某区域 (14.25 ×

13.63 km<sup>2</sup>) 的运营数据, 包含该区域的 26 家门店从 2016 年 7 月 14 日—2019 年 4 月 12 日的运营信息, 涵盖订单、用户、仓储、促销、APP 运维、物流、配送员等多维度, 比如优惠券面值、发券数量、收货地址经纬度、商户和平台补贴、应付运费、商品评分、评价内容、商品可用库存、订单金额、下单时间、拣货时间、送达时间、配送员 ID、配送距离等, 共包含 8 530 185 条原始记录. 图 4 展示了门店和消费者的分布情况, 红点代表门店的位置, 黑点代表消费者的位置. 数据集时间段内, 共有消费者 52 984 人, 配送员 9 026 人, 订单 1 230 624 个.



图 4 数据集店铺及消费者位置分布

Fig. 4 The location distribution of merchants and customers

配送平台的工作时间为每天早上 8 点—晚上 12 点. 每 5 min, 平台对订单进行一次分派和路径规划决策. 基于平台实际运营的成本估计, 设置单位延误成本  $\hat{c}_p$  为 0.4 元/min, 单位旅行成本  $\hat{c}_d$  为 0.1 元/min, 作为调度模型的参数输入.

### 3.2 个性化众包配送时间预测模型数值实验结果

模型的训练集选取 2016 年 7 月 14 日—2018 年 10 月 31 日的数据, 测试集选取 2018 年 11 月 1 日—2018 年 12 月 31 日的数据. 选取了两个评价指标: 平均绝对误差 (Mean Absolute Error, MAE) 和平均相对误差 (Mean Absolute Percentage Error, MAPE).

本文基于真实数据, 跨域融合物流部门、其他运营部门、外部环境信息, 分析不同信息对配送时间的影响, 挖掘了与配送时间相关的特征共 94 个, 包括 1) 轨迹相关特征共 34 个, 例如轨迹总

距离、订单数、门店数等; 2) 配送员相关共 51 个, 包括配送员连续工作天数、历史配送速度、历史延误订单数等; 3) 区域相关特征共 3 个, 包括配送员是否访问过该区域、配送员访问该区域的次数等; 4) 外部环境相关特征共 6 个, 包括最高最低气温、天气、风速等.

基于表 1 的算法, 本文选取了多种不同的基础预测算法, 包括线性回归、LASSO、弹性网络、随机森林、线性支持向量回归、高斯核支持向量回归等预测模型. 基于真实数据集, 本文提取出 1 063 046 趟配送轨迹, 一趟配送轨迹代表配送员从一个地点到另一个地点真实花费的时间, 地点包括商店和订单所在的位置. 对于不同基础预测算法的模型, 根据训练集训练得到的模型, 在测试集中的预测精度结果如表 4 所示.

表 4 不同的基础预测算法对预测精度的影响

Table 4 The impacts of different basic forecast algorithms on prediction accuracy

预测模型	MAE	MAPE
线性回归	5.31	26.04%
LASSO	5.09	24.60%
弹性网络	5.08	24.56%
随机森林	4.87	23.49%
线性支持向量回归	5.02	26.01%
高斯支持向量回归	5.30	26.01%

通过表 4 可以验证, 本文提出的算法选取不同的基础预测算法都能得到稳定的预测结果, 具有较好的普适性. 在所有基础预测算法中, 采用随机森林作为基础预测算法时预测误差最小, 因此在后续的 O2O 即时物流调度模型中, 将选取随机森林作为基础预测算法.

进一步的, 本文与 Liu 等<sup>[34]</sup> 提出的预测模型进行了比较, 由于 Liu 等<sup>[34]</sup> 的预测模型针对从商店出发到完成所有订单的配送的完整配送轨迹的预测, 且每趟轨迹至少包括两个订单, 因此本文从数据集中提取 80 900 条完整轨迹进行预测结果的比较, 结果如表 5 所示. 结果显示本文提出的算法能够显著提升预测的精度, 这主要是由两个方面带来.

1) 相比 Liu 等<sup>[34]</sup> 仅考虑了轨迹相关的特征, 本文充分分析了配送员、外部环境等多维度的特

征,充分挖掘影响配送时间的因素.

2) 本文采用基于聚类的预测算法,通过聚类将具有相似行为模式的配送员分到同一类目进行模型训练,避免了过拟合和欠拟合的情况,提高了预测模型的精度.

表 5 不同的预测模型对预测精度的影响

Table 5 The impacts of different forecast models on prediction accuracy

预测模型	MAE	MAPE
Liu 等 <sup>[34]</sup> 提出的模型	8.24	37.90%
本文提出的模型	7.15	24.62%

### 3.3 考虑预测不确定性的 O2O 即时物流调度模型数值实验结果

本文基于 C 语言实现 O2O 即时物流调度模型,选取 2019 年 1 月 1 日—2019 年 3 月 31 日共 90 天的真实数据进行调度模型的数值仿真实验. 针对每一天的调度决策,本文重复进行了 20 次数值实验,并计算结果的均值,得到调度模型的性能. 考虑到 O2O 即时物流场景的特点,本文选取了 3 个指标:1) 延误订单数. O2O 即时物流最大的特点就是高时效性,因此延误订单数的多少是目前所有 O2O 企业绩效考核的最重要指标,减少延误订单可以提高消费者对服务的满意度. 2) 平均配送时间. 一方面, O2O 企业会向消费者承诺订单送达的时间范围,如果订单的平均配送时间更短,意味着企业可以承诺订单在更短的时间内送达,有利于提供其竞争力,另一方面,更短的平均配送时间意味着配送员可以更快地返回商店服务下一个订单,提高了系统的效率. 3) 成本. 目前 O2O 企业的物流配送成本高企,因此控制成本也是企业的重要发展指标.

表 6 展示了新决策范式下的调度模型和现有文献中的模型的对比. 现有文献选取了即时物流领域有代表性的两篇文章. Arslan 等<sup>[12]</sup>针对众包配送员参与的最后 1 km 问题进行研究,提供了一种动态派单算法,是基于众包的最后 1 km 配送领域最早的研究之一. 该算法没有考虑配送时间预测和未来订单集,也没有考虑个性化配送决策. Liu 等<sup>[34]</sup>在最后 1 km 问题的派单决策中,考虑了基于机器学习的配送距离预测,但没有考虑个性化派单和未来订单. 本文基于两篇文章的思路,将

其方法在该场景下应用,并在同一数据集中进行仿真实验,以对比新决策范式下的调度模型的性能.

表 6 不同方法下 O2O 即时物流调度模型的性能

Table 6 The performance comparison of O2O on-demand logistics management model under different methods

方法	结果	延误订单数 /个	平均配送时间 /min	成本 /元
Arslan 等 <sup>[12]</sup>	结果	365.37	30.97	4 858.9
Liu 等 <sup>[34]</sup>	结果	257.52	31.12	3 314.9
	提升	29.52%	-0.48%	31.78%
新决策范式下的调度模型	结果	81.26	23.76	2 074.6
	提升	68.45%	23.28%	57.30%

比较表 6 的结果可以发现, Liu 等<sup>[34]</sup>通过订单的分布特征,构建了配送时间的预测模型,相比 Arslan 等<sup>[12]</sup>降低了系统的延误订单数和成本. 本文提出的方法通过引入跨域多维特征、考虑个性化预测模型的点估计及其不确定性、未来订单集的预测,相比 Liu 等<sup>[34]</sup>的方法,对于系统的延误订单数、平均配送时间和成本三个指标,均有显著的降低. 这说明本研究所提出的新决策范式下的调度模型在满足 O2O 即时调度的特定要求方面有明显优势.

为进一步分析新范式是如何带来绩效提升, 本文将新决策范式下的调度模型的要素进行拆解, 比较分析不同要素如何影响绩效指标. 本文以 Arslan 等<sup>[12]</sup>的调度结果为基准模型, 即模型 1 (不考虑个性化众包配送时间预测模型和未来订单集, 即假设所有配送员的配送时间是一致的, 不考虑未来订单集), 对比了 4 种模型和它的区别. 表 7 汇总了不同调度模型的特点. 模型 2 相比模型 1, 多考虑了个性化配送时间预测模型的点估计及其不确定性. 模型 3, 模型 4 和新决策范式下的调度模型在模型 2 的基础上, 进一步考虑了未来订单集的影响. 但三个模型对未来订单集的预测方式不同, 模型 3 选择前一天的订单数据作为未来的订单集的预测结果<sup>[39]</sup>; 模型 4 和模型 5 采用基于相似度量度的方式来预测, 其中模型 4 仅考虑促销、天气等外部数据来预测, 新决策范式下的调度模型同时考虑内部和外部的全景式数据来进行预测.

表7 不同调度模型特点

Table 7 Characteristics of different scheduling models

模型	考虑个性化配送时间		考虑未来订单集		
	假设配送时间一致	同时考虑预测点估计及其不确定性	直接采用前一天	考虑外部特征	考虑内部特征
模型 1	√	×	×	×	×
模型 2	×	√	×	×	×
模型 3	×	√	√	×	×
模型 4	×	√	×	√	×
新决策范式下的调度模型	×	√	×	√	√

表 8 总结了考虑不同个性化配送时间预测方法和不同未来订单集预测方法对调度模型绩效的影响结果,每种方法的提升均为相比上一种方法结果的提升.其中模型 1 和模型 2 的对比,聚焦于是否有配送时间预测的比较,体现了

个性化配送时间假设转变的价值.模型 3,模型 4 和新决策范式下的调度模型的对比,聚焦于未来订单集的不同预测方法的比较,体现了需求时空属性假设转变的价值.具体价值实现路径分析如下.

表 8 O2O 即时物流调度模型的绩效比较

Table 8 The performance comparison of O2O on-demand logistics scheduling model under different methods

研究内容	模型	结果	延误订单数/个	平均配送时间/min	成本/元
个性化配送时间假设转变的价值	模型 1	结果	365.37	30.97	4 858.9
	模型 2	结果	95.14	24.66	2 303.7
		提升	73.96%	20.37%	53.59%
需求时空属性假设转变的价值	模型 3	结果	103.26	25.32	2 512.8
		提升	-8.53%	-2.68%	-9.08%
	模型 4	结果	88.27	24.11	2 193.6
		提升	14.52%	4.78%	12.70%
	新决策范式下的调度模型	结果	81.26	23.76	2 074.6
		提升	7.94%	1.45%	5.42%

1) 个性化配送时间假设转变的价值

比较模型 1 和模型 2 的结果可以发现,通过将本文提出的个性化众包配送时间预测模型的点估计及其不确定性纳入 O2O 即时物流调度模型,可以降低延误订单数 73.96%,降低平均配送时间 20.76%,降低系统成本 53.59%.个性化配送时间假设转变对系统绩效的提升主要有两个原因.

(a) 通过结合个性化众包配送时间预测模型,订单分派和路径规划模型可以更合适地匹配配送员和订单.如果平台不能准确预测配送时间,可能会将紧急的订单分配给没有经验的配送员,从而造成更多的延误;或将不紧急的订单分配给

经验丰富的配送员,造成运力的浪费,并可能导致未来有更多的订单产生延误.

(b) 预测模型存在误差,会影响订单分派和路径规划模型的决策质量.依据个性化众包配送时间预测模型,系统将订单分配给可以按时完成订单的配送员,但在真实环境中存在随机因素的影响,可能会造成未被预测到的配送时间变化.将预测模型的不确定性融入决策模型,可以使决策能够适应动态变化的场景,降低订单延误的概率.

2) 需求时空属性假设转变的价值

比较模型 2 和模型 3 的结果可以发现,在考虑未来需求时,如果方法不适合,比如直接利用前一天的订单信息作为未来订单信息的模拟,反而

会降低系统的绩效,造成延误订单数、平均配送时间和系统总成本均增加.这是因为不同天之间的订单分布规律存在较大差异,如果选取了差异较大的场景,会对物流决策模型造成误导.因此需要选取合适的场景作为未来订单集的模拟.

模型 4 相比与模型 3,降低了 14.52% 的延误订单数和 12.70% 的系统成本,说明基于本文提出的订单集时空相似性度量方法,可以更好地选择与当天实际情况更为相似的订单集作为未来订单集的模拟,从而提升系统的绩效.此外,模型 5 进一步降低了 7.94% 的延误订单数和 5.42% 的系统成本.这说明采用全景式数据,考虑的特征维度更丰富,能够更好的挖掘不同场景之间的信息,选择与当前更相似的场景,从而在物流调度中给出更好的决策,有效地提升系统绩效.需求时空属性假设转变对系统绩效的提升主要有两个原因.

(a)通过考虑未来需求,系统可以根据当前的配送员数目、当前的需求和未来的需求进行统筹决策.当未来的需求数目高、空间分布广时,系统可以保留部分配送员以应对未来的需求;当未来的需求数目低,空间分布小时,系统可以让更多的配送员参与到完成当前的需求的任务中.通过更好地匹配配送员与需求,可以提高配送员的利用率,降低订单的延误.

(b)通过基于订单集时空相似性的需求场景预测算法,可以获取未来需求的时空分布,提升决策精准度.比如,在系统进行配送决策时,可以让配送员提前前往需求数目较高的区域等待,从而提高配送员服务未来需求的能力,降低未来订单的延误.

## 4 结束语

本文通过分析 O2O 即时物流调度问题的特点,应用新的决策范式,将分散在不同领域、不同系统的数据整合起来,将配送时间一致和订单服从先验分布的假设转变为个性化的配送时间和考虑订单的时空属性的宽假设,并建立个性化配送时间预测模型和基于订单集时空相似性的需求场景预测算法.结合这两个基于大数据的预测模型,本文建立个性化 O2O 即时物流调度模型,该模型

将配送员的个性化配送时间和未来订单集的时空分布纳入考量.更进一步,本文将个性化配送时间预测模型的点估计及其不确定性同时融入优化函数,通过最小化期望延误成本和旅行成本来优化派单和路径规划决策.个性化的模型使得 O2O 即时物流调度模型的约束数量增加,同时数据和模型的深度融合需要同步处理配送时间的预测与派单和路径规划决策的优化,增加了问题的复杂度.本文设计了同步预测和决策的启发式算法,对模型进行求解.

本文与中国最大 O2O 商超平台之一合作,基于真实数据集进行分析,验证了考虑预测不确定性的 O2O 即时物流调度模型的有效性.并通过比较不同方法下的系统绩效,验证了新决策范式下的调度模型的有效性.通过考虑个性化众包配送时间预测模型和基于订单集时空相似性的未来需求场景预测算法,可以提高系统绩效,降低 77.76% 的延误订单数,23.28% 的平均配送时间和 57.30% 的配送成本.基于本文的研究结果,可以给 O2O 平台提供一些管理启示.

1)不同众包配送员的工作意愿是不同的,且会受到平台提供的收入、评级和惩罚的交互影响.不同的众包配送员在完成订单时,需要的配送时间是存在差异的,订单的配送时间不仅与众包配送员的个人经验和需要完成的订单集相关,也与外部环境相关,且不同的配送员,对于环境的反应也是不同的.因此本文指出,在 O2O 即时物流决策中需要同时考虑人和订单两个维度,需要对众包配送员进行分类,将具有相似行为模式的配送员分为一类,对同类的配送员建立配送时间预测模型,可以避免过拟合和欠拟合的情况,提高预测精度.

2)在平台进行订单分派和路径规划决策时,应该考虑不同配送员完成订单配送时不同的配送时间,以及预测模型的预测误差,这可以让平台提供更精准化的决策,避免运力的浪费和订单的延误.

3)对于平台的决策,考虑未来订单集的时空分布是有意义的,但需要对选取的场景进行相似性的分析.随机选取的场景如果与当前场景差异较大,反而会降低决策的质量.通过挖掘不同场景

之间的时空相似性,可以选取合适的场景,给出更优的决策。

本文基于决策范式转变的理念,对 O2O 即时物流调度问题进行了研究,但本文的模型也有一定局限性。首先,分析个性化的配送时间时,本文没有考虑目的地的小区布局、楼层等因素对配送

时间的影响,这些因素可以更好地帮助预测配送时间;其次,本文考虑了需求端订单数目和分布的不确定性,和运力端配送时间不确定性对物流调度问题的影响,但没有讨论运力供给端配送员数目和分布的不确定性对物流调度问题带来的影响。这些都有待在以后的工作中继续完成。

### 参考文献:

- [1] 陈国青, 吴刚, 顾远东, 等. 管理决策情境下大数据驱动的研究和应用挑战——范式转变与研究方向[J]. 管理科学学报, 2018, 169(7): 1-10.  
Chen Guoqing, Wu Gang, Gu Yuandong, et al. The challenges for big data driven research and applications in the context of managerial decision-making: Paradigm shift and research directions[J]. Journal of Management Sciences in China, 2018, 169(7): 1-10. (in Chinese)
- [2] 陈国青, 曾大军, 卫强, 等. 大数据环境下的决策范式转变和使能创新[J]. 管理世界, 2020, 2: 95-105.  
Chen Guoqing, Zeng Dajun, Wei Qiang, et al. Transitions of decision-making paradigms and enabled innovations in the context of big data[J]. Management World, 2020, 2: 95-105. (in Chinese)
- [3] Dai H, Ge L, Liu Y. Information matters: An empirical study of the efficiency of on-demand services[J]. Information Systems Frontiers, 2020, 22: 815-827.
- [4] Alnaggar A, Gzara F, Bookbinder J H. Crowdsourced delivery: A review of platforms and academic literature[J]. Omega, 2021, 98: 102139.
- [5] 艾瑞咨询. 中国外卖行业研究报告[EB/OL]. 2020. <https://data.iimedia.cn/data-classification/theme/44275772.html>. (in Chinese)  
Media Research. Chinese take-out industry research report[EB/OL]. 2020. <https://data.iimedia.cn/data-classification/theme/44275772.html>.
- [6] Dai H, Liu P. Workforce planning for O2O delivery systems with crowdsourced drivers[J]. Annals of Operations Research, 2020, 291(1): 219-245.
- [7] Dai H, Liu Y, Yan N, et al. Optimal staffing for online-to-offline on-demand delivery systems: In-house or crowd-sourcing-drivers? [J]. Asia-Pacific Journal of Operational Research, 2021, 38(1): 2050037.
- [8] 美团点评. 2021 年度报告[EB/OL]. 2021. <https://about.meituan.com/investor>.  
Meituan Reviews. 2021 Annual report[EB/OL]. 2021. <https://about.meituan.com/investor>. (in Chinese)
- [9] 慕静, 杜田玉, 刘爽, 等. 基于即时配送和收益激励的众包物流运力调度研究[J]. 运筹与管理, 2018, 27(5): 58-65.  
Mu Jing, Du Tianyu, Liu Shuang, et al. Research on crowdsourcing logistics capacity scheduling based on instant distribution and revenue incentives[J]. Operations Research and Management Science, 2018, 27(5): 58-65. (in Chinese)
- [10] 杨东林, 荣鹰. 在 O2O 情景下的送取货集成决策[J]. 管理工程学报, 2019, 33(2): 1-6.  
Yang Donglin, Rong Ying. Comparison of different pick-up and drop-off modes under the O2O environment[J]. Journal of Industrial Engineering/Engineering Management, 2019, 33(2): 1-6. (in Chinese)
- [11] Archetti C, Speranza M G, Savelsbergh M W P. The vehicle routing problem with occasional drivers[J]. European Journal of Operational Research, 2016, 254(2): 472-480.
- [12] Arslan A M, Agatz N, Kroon L, et al. Crowdsourced delivery: A dynamic pickup and delivery problem with ad hoc drivers [J]. Transportation Science, 2019, 53(1): 222-235.
- [13] Voccia S A, Campbell A M, Thomas B W. The same-day delivery problem for online purchases[J]. Transportation Science, 2019, 53(1): 167-184.
- [14] 陈萍, 李航. 基于时间满意度的 O2O 外卖配送路径优化问题研究[J]. 中国管理科学, 2016, 24(S1): 170-176.  
Chen Ping, Li Hang. Optimization model and algorithm based on time satisfaction for O2O food delivery[J]. Chinese Journal of Management Science, 2016, 24(S1): 170-176. (in Chinese)
- [15] 丁秋雷, 胡祥培, 姜洋. 基于前景理论的物流配送干扰管理模型研究[J]. 管理科学学报, 2014, 17(11): 1-9.

- Ding Qiulei, Hu Xiangpei, Jiang Yang. A model of disruption management based on prospect theory in logistic distribution [J]. *Journal of Management Sciences in China*, 2014, 17(11): 1–9. (in Chinese)
- [16] 饶卫振, 朱庆华, 金 淳, 等. 协作车辆路径成本分摊问题的 BT Shapley 方法[J]. *管理科学学报*, 2019, 22(1): 107–126.
- Rao Weizhen, Zhu Qinghua, Jin Chun, et al. A binary tree shapely method for cost sharing of the collaborative vehicle routing problem[J]. *Journal of Management Sciences in China*, 2019, 22(1): 107–126. (in Chinese)
- [17] 余海燕, 唐婉倩, 吴腾宇. 带硬时间窗的 O2O 生鲜外卖即时配送路径优化[J]. *系统管理学报*, 2021, 30(3): 584–591.
- Yu Haiyan, Tang Wanqian, Wu Tengyu. Vehicle routing problem with hard time windows for instant delivery of O2O fresh takeout orders[J]. *Journal of Systems & Management*, 2021, 30(3): 584–591. (in Chinese)
- [18] Dong J, Ibrahim R. Managing supply in the on-demand economy: Flexible workers, full-time employees, or both? [J]. *Operations Research*, 2020, 68(4): 1238–1264.
- [19] 周鲜成, 刘长石, 周开军, 等. 时间依赖型绿色车辆路径模型及改进蚁群算法[J]. *管理科学学报*, 2019, 22(5): 57–68.
- Zhou Xiancheng, Liu Changshi, Zhou Kaijun, et al. Improved ant colony algorithm and modelling of time-dependent green vehicle routing problem[J]. *Journal of Management Sciences in China*, 2019, 22(5): 57–68. (in Chinese)
- [20] Tao J, Dai H, Jiang H, et al. Dispatch ptimisation in O2O on-demand service with crowd-sourced and in-house drivers [J]. *International Journal of Production Research*, 2020: 1–15.
- [21] Huang Y, Zhao L, VanWoensel T, et al. Time-dependent vehicle routing problem with path flexibility[J]. *Transportation Research Part B: Methodological*, 2017, 95: 169–195.
- [22] Liu J, Sun L, Chen W, et al. Rebalancing bike sharing systems: A multi-source data smart optimization[C]. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016: 1005–1014.
- [23] Carlsson J G, Behroozi M, Mihic K. Wasserstein distance and the distributionally robust TSP[J]. *Operations Research*, 2018, 66(6): 1603–1624.
- [24] Dayarian I, Savelsbergh M. Crowdsipping and same-day delivery: Employing in-store customers to deliver online orders [J]. *Production and Operations Management*, 2020, 29(9): 2153–2174.
- [25] Voccia S A, Campbell A M, Thomas B W. The same-day delivery problem for online purchases[J]. *Transportation Science*, 2019, 53(1): 167–184.
- [26] Ulmer M W, Goodson J C, Mattfeld D C, et al. Offline-online approximate dynamic programming for dynamic vehicle routing with stochastic requests[J]. *Transportation Science*, 2019, 53(1): 185–202.
- [27] 张 朋, 谢云东, 吴 强, 等. 我国管理科学与工程学科研究热点及演化趋势[J]. *管理科学学报*, 2022, 25(5): 1–12.
- Zhang Peng, Xie Yundong, Wu Qiang, et al. Hot topics and thematic evolutionary trends of researches on management science and engineering in China[J]. *Journal of Management Sciences in China*, 2022, 25(5): 1–12. (in Chinese)
- [28] Bertsimas D, Mišić V V. Data-driven assortment optimization[J]. *Management Science*, 2015, 1: 1–35.
- [29] Ferreira K J, Lee B H A, Simchi-Levi D. Analytics for an online retailer: Demand forecasting and price optimization[J]. *Manufacturing & Service Operations Management*, 2016, 18(1): 69–88.
- [30] Mao W, Ming L, Rong Y, et al. On-demand meal delivery platforms: Operational level data and research opportunities[J]. *Manufacturing & Service Operations Management*, 2022, 24(5): 2535–2542.
- [31] 饶卫振, 徐 丰, 朱庆华, 等. 依托平台协作配送成本分摊的有效方法研究[J]. *管理科学学报*, 2021, 24(9): 105–126.
- Rao Weizhen, Xu Feng, Zhu Qinghua, et al. Fair and effective cost-sharing method for collaborative distribution based on a third-party platform[J]. *Journal of Management Sciences in China*, 2021, 24(9): 105–126. (in Chinese)
- [32] Oroojlooy A, Snyder L, Takáč M. Applying deep learning to the newsvendor problem[J]. *IIE Transactions*, 2019: 1–39.
- [33] Ban G Y, Keskin N B. Personalized dynamic pricing with machine learning: High-dimensional features and heterogeneous elasticity[J]. *Management Science*, 2021, 67(9): 5549–5568.
- [34] Liu S, He L, Max Shen Z J. On-time last-mile delivery: Order assignment with travel-time predictors[J]. *Management Science*, 2021, 67(7): 4095–4119.
- [35] Dai H, Ge L, Li C, et al. The interaction of discount promotion and display-related promotion on on-demand platforms[J]. *Information Systems and E-Business Management*, 2021: 1–18.
- [36] Tao J, Dai H, Chen W, et al. The value of personalized dispatch in O2O on-demand delivery services[J]. *European Jour-*

- nal of Operational Research, 2023, 304(3): 1022 – 1035.
- [37] Hvattum L M, Løkketangen A, Laporte G. Solving a dynamic and stochastic vehicle routing problem with a sample scenario hedging heuristic[J]. Transportation Science, 2006, 40(4): 421 – 438.
- [38] Schilde M, Doerner K F, Hartl R F. Metaheuristics for the dynamic stochastic dial-a-ride problem with expected return transports[J]. Computers & Operations Research, 2011, 38(12): 1719 – 1730.
- [39] Li D, Antoniou C, Jiang H, et al. The value of prepositioning in smartphone-based vanpool services under stochastic requests and time-dependent travel times[J]. Transportation Research Record, 2019, 2673(2): 26 – 37.
- [40] Huang W, Xiao Q, Dai H, et al. Sales forecast for O2O services; Based on incremental random forest method[C]. Proceedings of the 15th International Conference on Service Systems and Service Management, Hangzhou, China, 2018: 1 – 5.
- [41] Dai H, Xiao Q, Yan N, et al. Item-level forecasting for e-commerce demand with high-dimensional data using a two-stage feature selection algorithm[J]. Journal of Systems Science and Systems Engineering, 2022, 31(2): 247 – 264.
- [42] Dai H, Ge L, Li C, et al. The interaction of discount promotion and display-related promotion on on-demand platforms[J]. Information Systems and E-business Management, 2021, 6: 1 – 18.
- [43] Muelas S, LaTorre A, Pena J M. A distributed VNS algorithm for optimizing dial-a-ride problems in large-scale scenarios[J]. Transportation Research Part C: Emerging Technologies, 2015, 54: 110 – 130.
- [44] Barreto S, Ferreira C, Paixao J, et al. Using clustering analysis in a capacitated location-routing problem[J]. European Journal of Operational Research, 2007, 179(3): 968 – 977.

## Paradigm shift for big data-driven decision making: New paradigm for O2O on-demand logistics

*DAI Hong-yan*<sup>1</sup>, *TAO Jia-wei*<sup>2\*</sup>, *JIANG Hai*<sup>2</sup>, *ZHOU Wei-hua*<sup>3</sup>

1. Business School, Central University of Finance and Economics, Beijing 100081, China;

2. Department of Industrial Engineering, Tsinghua University, Beijing 100084, China;

3. School of Management, Zhejiang University, Hangzhou 310058, China

**Abstract:** The rapid development of big data has shifted the traditional decision-making to data-driven decision-making. This research aims to propose an O2O on-demand logistics scheduling model based on the new big data-driven paradigm. This model incorporates different data sources from the internal logistics departments, other operations departments and external environment to form a panoramic dataset. Based on this, the classical assumptions of the traditional decision-making paradigm are relaxed, and two new assumptions are proposed: Personalized delivery time is assumed instead of traditional consistent delivery time, and a temporal-spatial demand distribution considering future demand is assumed instead of the prior demand distribution. This research aims to realize the personalized O2O on-demand delivery management by applying both machine learning and operations research technologies. More specifically, a personalized delivery time forecast model and a scenario-based demand forecast algorithm are proposed. Considering the point estimate and forecast uncertainty of the delivery time forecast model, as well as the temporal-spatial distribution of future orders, a dispatch model is established which takes into account forecast uncertainties for O2O on-demand logistics systems. A forecast-while-optimizing algorithm is also developed to optimize the decision-making model based on the feature-dependent predictions. This research verifies the feasibility and effectiveness of our O2O on-demand logistics management model based on the new paradigm by analyzing a real dataset from one of the largest O2O platforms in China. Compared with the traditional mode, the model based on the big data-driven paradigm can precisely match the highly uncertain demand and supply, and reduce the number of delayed orders, average delivery time and delivery cost.

**Key words:** decision making paradigm shift; big data-driven decision-making; O2O on-demand logistics; personalization