

第 5 章 即时配送的大数据预测技术及应用

本章讨论即时配送中的大数据预测技术。

5.1 业界常见预测问题介绍

预测问题在工业界，特别是互联网产品中很常见（如图 5.1 所示）。例如：在视频推荐中，需要预测点击率（Click-Through Rate, CTR）；在网页搜索中，预测相关性；在广告系统中，也需要预测点击率；在电商系统中，则是预测转化率（Conversion Rate, CVR）。这些预测模块与其他模块相互协同，共同提升业务效果。

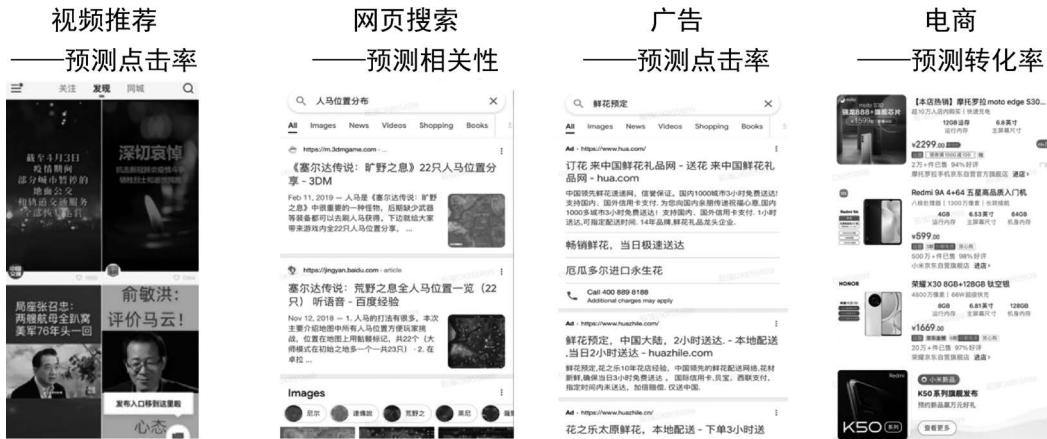


图 5.1 互联网产品中的预测问题

5.1.1 预测点击率与预测转化率

进一步对每一类系统展开讨论。首先是推荐系统，通常包括对 CTR 和 CVR 的预估。在视频推荐中，CVR 通常指用户点击视频后观看超过一定时长的比例。此外，推荐系统还需考虑多样性问题，避免给用户推荐过于相似的内容，产生审美疲劳。多样性模块并非单

纯的预测问题,该模块与 CTR 和 CVR 预估模块共同提升视频推荐系统的观看时长和日活用户(Daily Active Users,DAU)数量,这是视频业务的主要目标。

其次是搜索引擎,其中关键的预测模块是相关性,另一个同样重要的模块是权威性。权威性是网页重要程度的指标,Google 公司的 PageRank 算法便是一个著名的计算权威性的例子。相关性和权威性共同提升搜索结果的丰富性和准确性,从而提升搜索量。

再次在广告系统中,CTR 是关键的预测模块,拍卖机制同样至关重要。拍卖机制涉及博弈问题,通过机制的设计可以最大化广告平台的收益和广告主的投资回报率(Return on Investment,ROI)。此外,广告系统也要考虑相关性约束,以确保广告的展示符合用户需求,从而提升 CTR 和收益。这些模块共同提升广告平台的收益和广告主的 ROI。其中,预测模块在广告系统中扮演着重要角色,CTR 预估尤为关键。广告预测技术的发展历史悠久,可以作为预测技术演进的典型代表,接下来进行详细介绍。

从广告平台的业务目标出发,其核心目标之一是最大化盈利能力,而盈利能力的关键指标之一是 eCPM(每千次展示平台可获得的收益)。对于按点击计费的广告而言,eCPM 的计算公式可以分解为 CTR 乘以 Bid,其中 CTR 代表点击率,而 Bid 则是广告主对一次点击的出价。由于出价是广告主的行为,因此,最大化收益的关键在于准确预测 CTR,进而计算不同广告的展示收益,实现收益最大化的目标。

CTR 预估适合使用机器学习技术解决的原因有两方面:第一,需要利用历史数据来预测未来的点击率;第二,在这个场景中包含了大量的信息,难以通过传统的推理方式得出准确结果。因此,需要利用大量的历史数据来“拟合”一个模型,以预测未来的情况,这非常适合使用机器学习技术来解决。

5.1.2 利用机器学习构建预测模型

上文介绍了 CTR 预估模块的重要性,那么如何利用机器学习技术来构建这样一个预测模型,以应对广告系统中的挑战呢?接下来围绕这一问题,重点关注机器学习技术的三个基本要素:样本、特征和模型。

在广告系统中,样本和特征的定义相对清晰。一个广告曝光给用户后,如果用户点击了该广告,则被认为这是一个正样本;反之,则被视为一个负样本,历史上所有展示的正样本和负样本可以构建一个样本集合。在特征方面,通常可划分为三大类特征:(1)用户特征,包括用户历史行为统计和建模等;(2)广告特征,包括广告本身的文本描述或图片等信息,从中可提取丰富的特征;(3)环境特征,如星期几、是否节假日、广告展示时的页面元素、天气等外界环境信息。将特征完整刻画出来,结合之前的样本集合,便构造了一个机器学习问题的完整数据集。接下来,可以设计模型去求解这个问题。

在广告系统中,早期使用较多的模型是逻辑回归(Logistic Regression, LR)模型。LR 模型是关于特征和参数的线性表达式,通过 Sigmoid 函数将表达式的值映射到 0 和 1 之间,因此可以作为一个二分类问题的概率值。LR 模型的特点是非常简单易行,具有很强的可解释性,可以清晰地说明每一个特征的重要程度。而且计算速度很快,非常适用于处理广告场景的大量离散特征的并行计算。大约从 2008 年开始,各大互联网公司的广告平台普遍采用 LR 模型进行 CTR 预估,可以说,LR 是广告系统 CTR 预估的第一代模型。但它的不足在于模型本身表达能力不强,因此需要大量的基于人工经验的组合特征设计来提升预测效果。

LR 模型的数学表述如下:

$$\hat{y}(x) = \frac{1}{1 + e^{-w^T x}}$$

$$w^T x = w_0 + w_1 x_1 + \dots + w_n x_n$$

得到模型后,需要对它的效果进行评估。针对模型输出的分数,可以设定一个阈值来假设是否点击。例如,设定概率大于 0.5 时,认为用户会点击展示的广告;而概率不大于 0.5 时,则视为不点击。通过这样设定概率阈值,可以预测一个样本是正样本还是负样本,而同时每个样本也有真正的是否点击的标签。如果对实际的正样本预测正确,则称为真阳性(True Positive, TP),如果将实际的正样本预测为负样本,则称为假阴性(False Negative, FN),对负样本的预测类似,表 5.1 展示了预测值和实际值的四种情况。

表 5.1 CTR 预测: 离线评估

实际值	预测值	
	阳性	阴性
正	TP	FN
负	FP	TN

通过真阳性率(True Positive Rate, TPR)和假阳性率(False Positive Rate, FPR)可以评估模型的效果,其中 TPR 和 FPR 定义为

$$TPR = \frac{TP}{TP + FN}$$

$$FPR = \frac{FP}{FP + TN}$$

当设定不同的概率阈值时,预测一个样本为正样本或负样本的结果会发生变化,TPR 和 FPR 也会随之改变。例如,将阈值设定为 0.1、0.2……0.9 等不同值,就可以得到一系列 TPR 和 FPR 取值,并绘制成一条曲线,如图 5.2 所示。如果模型对正负样本是随机预测

的,则这条曲线是一条斜率为 45 度的直线。如果模型表现良好,那么曲线在这条直线的上方,可以通过计算曲线下方的面积(Area Under Curve, AUC)来评估模型的效果。AUC 是 CTR 预估模型的常用评估指标,如果 AUC 达到 0.8 左右,可以说明模型的效果非常优秀。

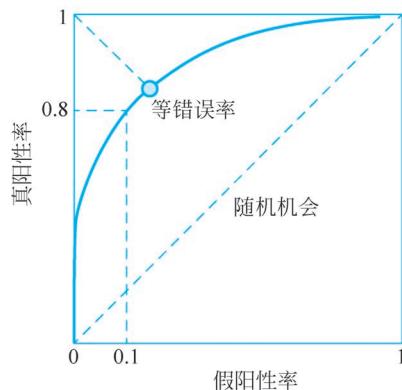


图 5.2 ROC 曲线

如果离线评估 AUC 有提升,那么预期上线后可能会产生业务收益,例如提升点击率或收入。这时可以考虑上线小流量实验,例如,抽取 5% 的流量进行 AB 实验,比较实验组和对照组在业务指标上的差异。举例来说,如果通过 AUC 提升了 1 个百分点,收入增长了 100 万,那么这个模型效果就比较好。然而,在实际情况中,很多时候会发现业务效果未达预期,即上线后收入和点击率没有增加。这时需要进一步分析原因,并进行策略迭代和再次实验,直到业务效果变得正向,才可以考虑进行全量推广。

5.2 即时配送中的预测问题

5.1 节介绍了工业界常见的预测问题,及其在互联网产品中的广泛应用。这些问题在优化产品体验和提高业务效益方面发挥着关键作用。本节将聚焦即时配送领域中的预测问题,即时配送在当今互联网生态系统中扮演着重要角色,而预测技术的应用对于提升即时配送的效率和质量至关重要。

5.2.1 预测送达时间

在外卖配送场景中,存在着多种预测问题需要解决,其中最常见的是预测送达时间(Estimated Time of Arrival,ETA)。在产品交互中,用户会在三个页面上看到预计送达时间:列表页、下单页和详情页。列表页上的时间是在用户还未点餐时展示的,在此阶段无法得知餐品制作的时间长短,因此通常是相对粗略的预估。而在下单页,用户已经点

完餐,所有信息都已确定,因此这个时间会更准确。在详情页,用户完成点餐后会显示一个小地图,其中标注了骑手的定位,预计送达时间会实时刷新。通过用户调研,发现93%的用户在点餐时会考虑送达时间,大约一半的用户认为时间是他们决策是否下单的一个关键因素。

用户看到的时间是从下单到最终送达的时长,而ETA背后的算法需要对中间过程进行比较详尽的预测。用户下单后,会发生许多事件,这些事件都对配送时间有重要影响,如图5.3所示,底色模块都是需要进行建模和预测的。总体而言,在商家出餐和骑手到达小区交付之间的过程比较复杂较难预测,因为涉及诸多不确定因素,如室内情况、等待电梯以及交通状况等,而传统ETA问题中的行驶阶段则相对容易预测。

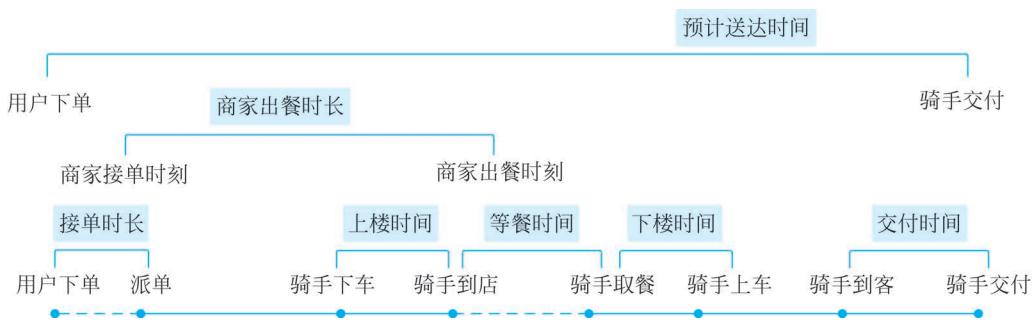


图5.3 配送过程的时间预测

除了前述问题,还需要对骑手配送的序列和时间进行建模,将在5.4节详细展开。此外,还需要预测供需情况,外卖配送是一个供需波动非常大的场景,就餐时段订单量集中,而闲时订单则相对较少,准确预测供需对于运力规划和时间预留至关重要。另外,在用户和骑手方面,还会对用户和骑手的体验进行建模,包括用户的满意度和复购率,以及骑手的订单接受意愿和持续接单情况(留存率)等。

5.2.2 即时配送预测模块的作用

即时配送的预测模块在多方面发挥着重要作用。

第一,预测模块与终端用户进行交互。如为用户提供餐品送达的时间预期,方便用户根据个人需求进行选择,向骑手展示商家出餐的时间,这可以帮助骑手合理安排到店时间,以便及时取餐。

第二,预测模块作为算法模块,支持决策。如帮助系统判断骑手与订单的匹配度,从而优化配送路线和配送效率。

第三,预测模块在业务规划方面发挥关键作用。通过对供需情况的准确预测,可以指导骑手的排班安排或提前规划运力,以应对不同时间段订单量的波动,更好地满足用户的

需求并提高服务水平。

5.3 即时配送预测问题的常见挑战及解法

5.2 节介绍了即时配送中的预测问题,本节将重点探讨解决这些问题过程中遇到的挑战及解法。

5.3.1 预估商家出餐时间建模

首先是商家出餐时间预估,其主要应用在骑手调度上,目的是让骑手能够在商家正好出餐的时间到达店里,避免骑手长时间等待或餐品长时间

滞留。如图 5.4 所示的情景中,如果不考虑出餐时间,骑手可能会按照距离的远近顺序依次前往商家取餐,然后再逐一配送。这种做法表面上看起来合理,但实际上,由于商家出餐时间的不确定性,可能导致骑手在某个商家等待较长时间。然而,商家出餐时间预估存在不确定性较高,主要是因为商家后厨流程的非标准化和非数字化,以及部分订单出餐时间过长的长尾问题。

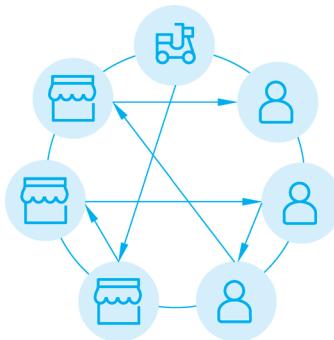


图 5.4 商家出餐示例图

针对预估不准确的挑战,解决思路之一是建模预估商家出餐时间的概率分布,为调度决策提供更丰富的信息,提高决策的合理性。举例来说,如果根据概率分布得出商家的出餐不够稳定,那么需要为骑手预留更多的时间,这种方法能够提高效率,有效缓解等餐长尾问题的出现。

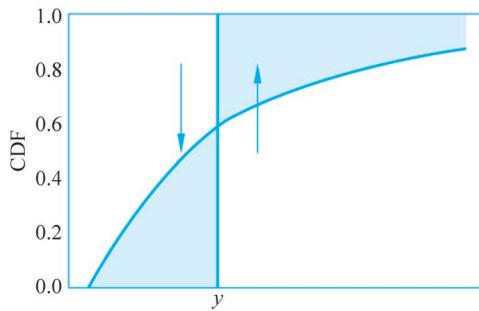
在建模预估商家出餐时间的传统回归方法中,建模的目标是一个具体的数值。设 $\hat{y}_i = f(X_i, \theta)$ 是模型的预测值,如果预测值和实际值有一定的差距,这个差距的绝对值就是模型的损失,即损失函数(Loss Function, Loss)。通常希望整体的平均绝对误差(Mean Absolute Error, MAE),即平均损失最小。其具体数学形式为

$$\text{MAE} = \frac{1}{n} \sum_i |\hat{y}_i - y_i|$$

但是如果要建模概率分布,建模的目标就变成了累积分布函数(Cumulative Distribution Function, CDF), $F_i = f(X_i, \theta)$ 。此时,根据连续分级概率评分(Continuous Ranked Probability Score, CRPS)的方法替换上述常规回归方法的损失函数,其表达式为

$$\text{CRPS}(F, y) = \int_{-\infty}^y F(x)^2 dx + \int_y^{\infty} [1 - F(x)]^2 dx$$

如图 5.5^[45]所示,CRPS 用于评估概率分布在真实值附近的聚集程度,CRPS 越小说明预测效果越好。以 CRPS 作为损失函数,可以求解出模型参数。

图 5.5 CDF 曲线^[45]

5.3.2 删失数据处理

下面讨论删失数据的问题。在实际进行建模时，并非所有的样本都能够完整获取，特别是在即时配送业务中，存在许多无法获得完整数据的情况（如图 5.6 所示）。举例来说，考虑研究治疗方案对患者的影响，有时无法准确得知患者症状始于何时，这可能是一种左侧的缺失数据。或者有时无法确定患者何时康复，可能是在一段时间之后，才能知道确切的康复时间点。此外，在某些时间段内，如果患者未曾出现，也无法观察到其情况。因此，许多现实世界中的数据无法被完全数字化，这就会导致一些数据的缺失。



图 5.6 删失数据问题

在商家出餐时间预估中也会遇到类似的情况（如图 5.7 所示）。一种情况是，当骑手点击“已取餐”按钮时，如果已经在商家店里等待一段时间了，那么此时就能准确获得出餐时间，因为之前的等待时间没有出餐，然后骑手在出餐后立即取走，这是一种完全的样本。另一种情况是，骑手到达商家时已经出餐很久，即刻取走餐品，无法准确得知商家何时出餐，只知道在某个时间点左侧，这是一种左删失的样本。类似地，还有一种情况是，骑手到店时商家尚未出餐，前往其他商家取餐后再回来，此时商家已经出餐，骑手取走。因此骑手离开的那段时间无法得知具体的出餐时间，只知道在之前一次到店时没有出餐，在后来再次到店时已经出餐，这是一种区间删失的样本。

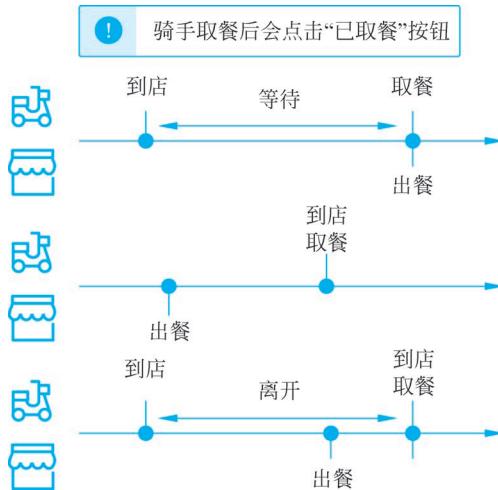
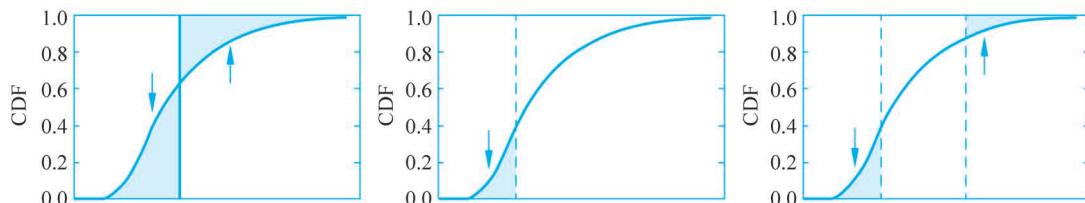


图 5.7 出餐环节的删失数据

常规的回归模型因为要求使用完整样本所以无法处理这类数据。但实际上，删失样本仍然能提供很多有效信息，真实情况下，这些样本大约占总体的 50%。那么能否将删失样本的信息也加以利用呢？这需要结合概率分布建模来实现。CRPS 损失函数能够有效应对概率分布预估问题。以区间删失样本为例，如图 5.8^[45] 所示，在区间删失的样本数据中，无法获取中间部分的信息，但对于已知的左侧和右侧部分，可以设定函数使损失尽可能小。比如，在左侧知道尚未出餐，因此将其概率设定得尽量小，而在右侧已经出餐的部分，则使其概率尽量大。通过结合概率分布预估，可以将删失数据充分利用起来，从而提升模型的效果，进而在实际业务中提升骑手取餐、用户点餐的双侧体验。

图 5.8 删失数据建模^[45]

5.3.3 建模目标选择

下面将介绍建模目标的选择问题。在这个问题上，许多人可能会有一些习惯性的错误。以预计送达时间为为例，在点餐过程中，用户经常会关注预计送达时间。在公司的问卷调查中，有 93% 的用户在点餐时会考虑到时间，47.02% 的用户认为时间是决定点餐的主要因素。这些数据表明了时间在用户体验和业务运营中的重要性。

接着更深入地探讨：上述问题和地图导航中的预计到达时间是否是同一类问题？是否属于同一类预测问题？这个问题涉及两个层面：首先，需要确定是否属于一个预测问题；其次，需要清楚这两个情景中的预测问题是否具有相同的本质。

在外卖配送场景，用户和平台之间存在着一种合约关系。用户支付了配送费以及商品的费用，而配送时间则是承诺的一部分。虽然双方没有签订任何的合同，但合约关系依然存在。在后续的履约过程中，必须遵循这个承诺的时间来安排最合适的骑手。骑手也会根据这个时间约束去进行配送。如果订单未能按时送达，用户可能会感到不满意并向平台投诉。如果用户购买了准时送达的保险，平台可能还需要进行赔偿。同时，骑手的体验也会受到影响，他可能因此无法获得完整的酬劳。综上所述，可以得出这是一个基于预测的决策问题。

而对于地图导航场景而言，其中并不存在任何合约关系。当用户查询路线时，预计到达时间仅作为一个参考指标。用户的实际行程和预估到达时间之间并不会相互影响。如果预估的时间不够准确，用户可能会仅发表意见或选择其他导航产品。因此，这就是一个典型的预测问题，只需尽可能准确地进行预测即可。

在业务领域中也存在一些常见的误区，即直接将业务目标（如时间、收入等）作为模型的标签，然后堆砌一些特征，供机器学习模型进行拟合，而不考虑其中的中间过程。然而，在实际应用中，有几个关键因素需要考虑。首先，预测结果不能够影响后续的事实。例如，在预测股票走势时，即使能够相对准确地进行预测，但如果将其发布出来，可能会影响到股票的走势。其次，预测的实例之间应该是相互独立的。例如，在预测配送时间时，如果两个订单的预计送达时间都是 40 分钟，但它们被分配给了同一个骑手，这可能会改变预测结果。最后，需要考虑对预测目标影响因素的了解程度。举例来说，当尝试预测股价时，由于一些影响因素是未知的，结果可能无法准确预测。只有当对这些影响因素有一定了解，并将这些信息提供给模型时，才能够有效地进行学习。

总结来说，外卖配送 ETA 是一个基于预测的决策问题（如图 5.9 所示）。所预测的到达时间直接影响用户是否下单的意愿，通常 ETA 越短，转化率越高。同时，是否按时送达也会影响用户的留存率。如果订单按时送达，用户的体验会更好，其复购率也会越高。除此之外，如果 ETA 较长，可以考虑将多个订单合并配送，这样的做法会使得性价比更高，降低配送成本。通过考虑不同业务目标的影响，可以建立相应的模型进行预测：转化率和复购率属于平台规模，而性价比或顺路率则属于平台成本。将这个问题抽象为三个预测问题，最终可以得出决策规模与成本之间的关系。因此，这个问题涉及如何考虑建模目标，并将其抽象为决策过程的一部分。

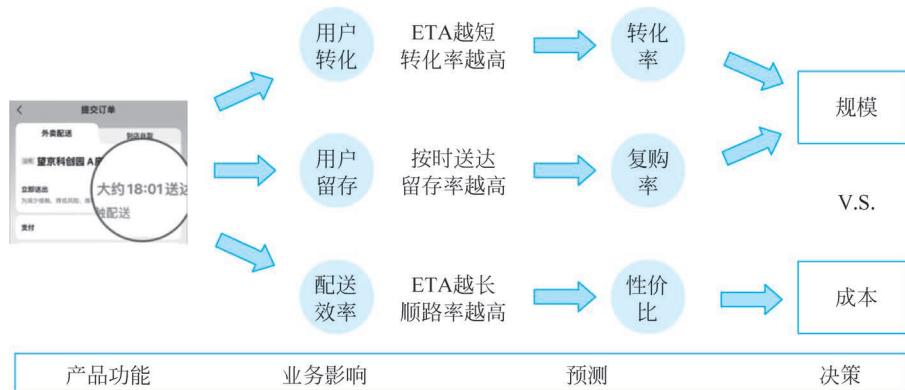


图 5.9 外卖配送 ETA：基于预测的决策问题

5.4 骑手配送顺序和时间预测

前文对配送中的预测问题进行了整体概述，本节主要就配送调度中最基础的两个预测问题进行针对性讨论。配送调度系统的一个核心的能力在于评估骑手与订单的匹配程度。这一环节直接影响配送效率和用户体验。为了合理地进行骑手与订单的匹配，调度系统需要获取两个关键预测信息输入：骑手可能的配送顺序和配送时间。这两个输入信息的准确与否直接决定了系统对于骑手、订单匹配度评估的准确性，进而决定了派单的合理性。接下来，我们将深入探讨骑手配送顺序和时间预测的相关内容，以便读者更好地理解配送调度系统的运作原理。

在配送调度中，系统最核心的功能就是确定骑手与订单的匹配程度，并根据匹配度为骑手分派订单。那么，调度系统如何评估骑手与订单的匹配程度呢？这涉及配送顺序和时间预测的问题。举个例子，如图 5.10 所示，假设一个骑手收到了 ABCDE 五个订单，那么他到底是按照 ABCDE 的顺序配送，还是按照 ADBEC 的顺序进行配送？不同的配送顺序意味着完全不同的配送路线和配送时间，而配送路线可以用于评估订单的顺路与否，配送时间则可以用于评估订单的配送体验。订单配送的顺路性和配送体验也是调度系统最关注的核心指标。因此，对于调度系统而言，最重要的输入就是这两个关键预测问题的预测结果：骑手会采取何种配送顺序？以及按照这种顺序配送需要多长时间？

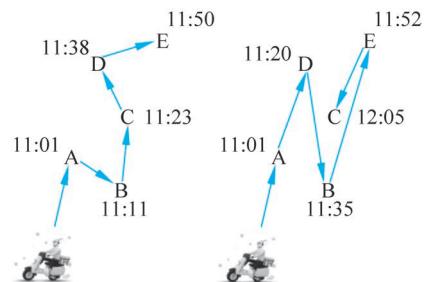


图 5.10 配送示例

5.4.1 时空数据预测

具体定义一下上述问题。对于一个骑手以及 N 个订单，需要预测骑手会按照什么顺序去配送这些订单。在这个问题中，唯一存在的预测约束在于，一个订单的取货点必须在送货点之前。同时，对于配送顺序中的每个节点，需要确定骑手具体的完成时间。这里涉及了两个序列：骑手配送节点序列以及配送时间序列（如图 5.11 所示）。

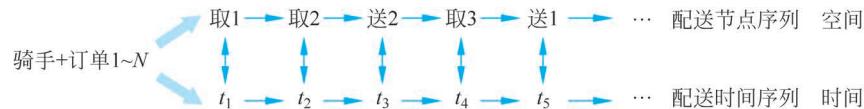


图 5.11 配送模型定义

骑手配送顺序预测和配送时间预测是比较典型的时空数据预测问题。接下来简要介绍一下时空数据。时空数据通常与日常生活密切相关。例如，大家平时关注的 $PM_{2.5}$ 数值，指的是某一时间在某一位置上的 $PM_{2.5}$ 值，其中时间是具体的时刻，而位置则是空间上的坐标。所有与时间、空间相关的数据都可以归属到时空数据的范畴。图 5.12 是对时空数据类型及其表达形式的总结，图 5.13 反映了各种任务在现有研究中的比例分布情况，更细节具体的数据和描述可以参照时空数据挖掘相关论文综述^[46]。从图 5.13 所示，预测问题在时空数据挖掘领域中占据着重要地位。而今天所介绍的骑手相关预测问题，也属于时空数据预测的范畴。

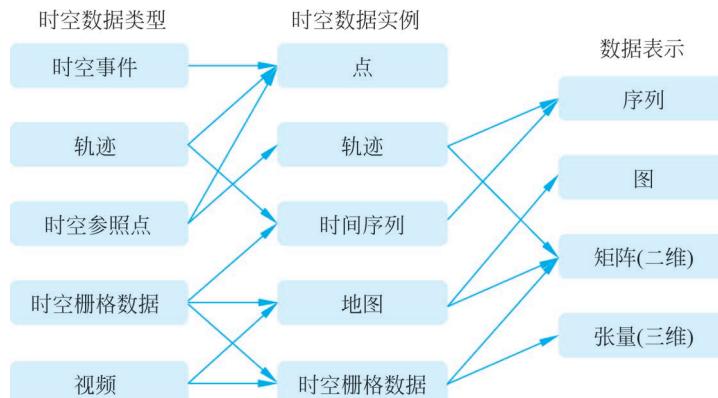


图 5.12 时空数据类型及其表达形式

时空数据预测指的是基于历史数据去预测未来的发展趋势。引用综述^[46]中的一句话：“时空预测学习的目标就是基于历史数据去预测未来的发现。”在具体的预测任务中，可以是预测未来某一个单点事件，比如预测未来某一个区域是否会发生犯罪事件；扩展到连续事件的预测，则涉及时序预测问题；而在空间方面的扩展，则可以是对空间图（Spatial

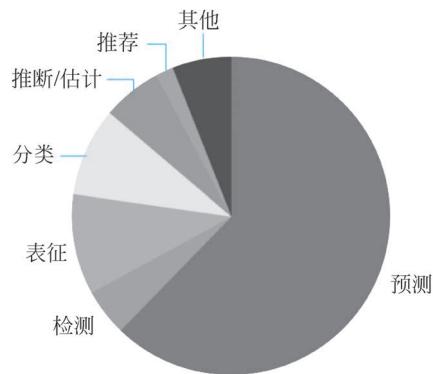


图 5.13 现有研究文献中各类任务占比

Maps)的预测。时序预测比较容易理解,涉及时序数据的连续变化;而空间图的预测,则是关注在一个空间范围内,数据的分布情况;当然,也可以同时在时间和空间上进行扩展栅格数据(ST Raster);除此之外,还有一类比较常见的时空预测问题,轨迹预测,比如预测人在行走中的移动路径,或车辆的行驶方向等,如图 5.14 所示。

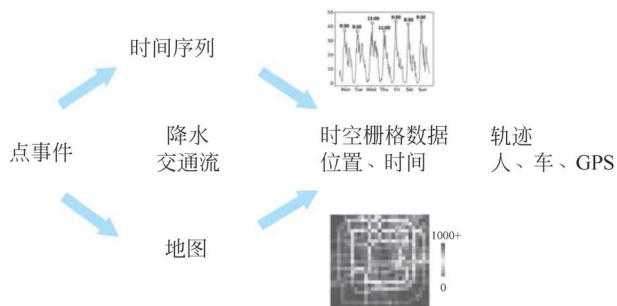
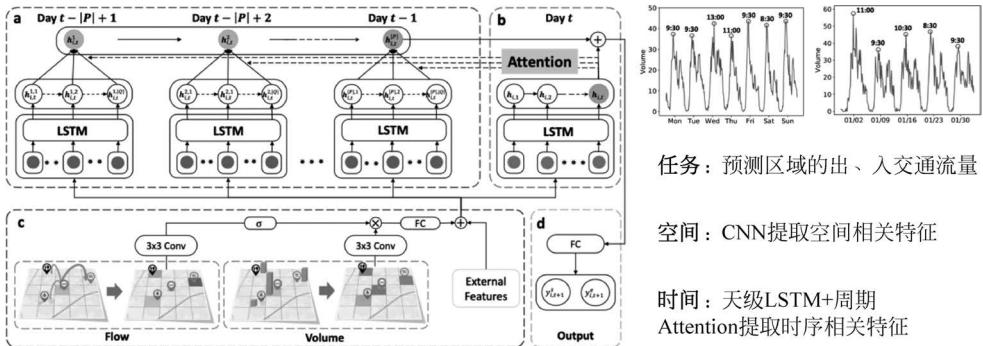
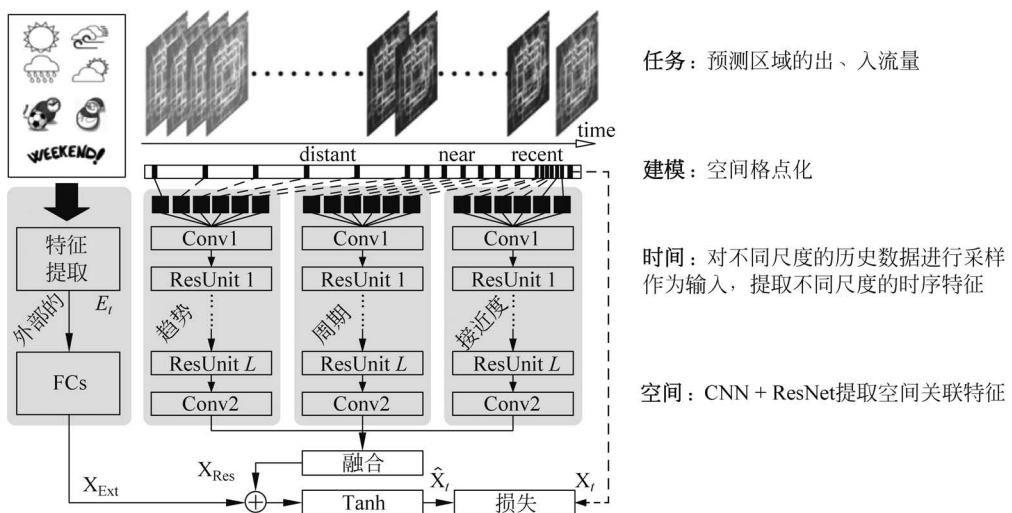


图 5.14 常见数据类型与任务

(1) 下面来看几个具体案例。首先是一个交通流量预测的案例^[47]。如图 5.15 所示,这个任务旨在预测不同区域上的出入交通流量,例如,右上角所示的流量变化曲线。在具体预测之前,最关键的问题之一是如何提取时空上的特征。在空间方面,研究者采用了卷积神经网络(CNN)的方法来提取空间相关特征。研究者将地图映射成一个个格点区域,然后利用类似图像卷积的方式来提取特征。而在时间上,针对一天内的流量特征,研究者采用了长短期记忆(LSTM)网络进行特征提取。而对于不同日期的特征,他们结合了注意力机制(Attention Mechanism)来进行特征聚合,这是时间上的聚合。通过对时间和空间上特征的提取,研究者进一步将其应用到后续的预测模型中,以预测未来的流量数据。这是一个相对典型的时序预测案例,其中时空特征的提取问题至关重要。

(2) 接着是一个类似的人流量预测问题^[48],该研究旨在预测北京不同区域的人流出入情况。如图 5.16 所示,首先,将北京划分成规则的格点,其中图像上的每个像素代表一个格

图 5.15 交通流量预测案例^[47]图 5.16 人流量预测案例^[48]

点区域，其像素值表示流量。通过已知的历史人流出入数据，进行未来情况的预测。与之前的案例不同之处在于，研究者对不同尺度历史数据进行采样作为输入，包括远期、中期以及近期的三类数据。对于远期数据采用稀疏采样，而对近期数据则采用密集采样，以提取不同尺度的时间特征。而在空间上，则是通过 CNN 和 ResNet 结合来进行特征提取。这类时空预测工作的核心仍然在于时间和空间特征的提取。

(3) 接着，来看一个轨迹预测的案例^[49]。如图 5.17 所示，该研究涉及拥挤场景下人的移动轨迹预测，主要考虑的是人在自主移动过程中受到其他人影响下的移动情况。在具体对个体轨迹进行预测时，论文采用了 LSTM 模型。而在考虑人与人之间相互影响时，引入了 Social Pooling 的概念。所谓的 Social Pooling 指的是在考虑周边人影响时，选取周边一定距离范围内的人进行特征聚合。例如，在预测黑色点时，需要考虑周边其他人对其的影响。其中，蓝色和黄色点距离较近，红色点较远，因此只结合蓝色和黄色点对应的特征进行

聚合。通过基于距离进行特征聚合的方式,引入了空间上多轨迹间的相互影响。实际上,骑手配送顺序预测问题与这类轨迹预测问题较为接近。不同之处在于,此问题不是预测骑手骑着电动车具体如何移动,而是预测骑手的取送顺序和时间。

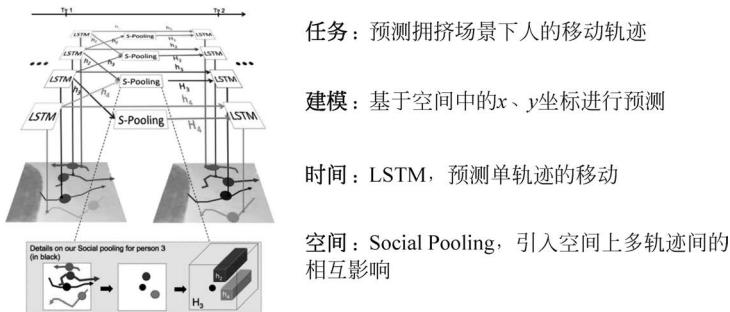


图 5.17 轨迹预测案例^[49]

5.4.2 骑手配送序列预测

上面介绍了一些时空预测以及序列预测的问题,那么这些问题与骑手配送序列预测有何不同呢?

(1) 在时空轨迹预测方面。时空轨迹预测通常是指预测时序上可能的轨迹位置,这些位置可能是空间中的任何一个点,同时通常是一个连续时间上的任务。而骑手配送顺序预测则不同,该问题中的点是固定的,只涉及确定的取点和送点,并且在时间上有明确的约束。

(2) 在序列预测方面,例如,点击率预估、导航时间预测,通常是针对单一任务进行预测,或者给定一个序列来预测另一个序列。而在骑手配送行为预测上,骑手的配送顺序会直接影响配送时间,反之配送时间同样会影响配送顺序,这两组序列预测任务是强耦合的。举个例子,图 5.10 中,在不同的配送顺序下,节点 D 的完成时间可能会有很大差异;同样地,如果节点 D 的剩余配送时长不同,也会影响骑手决策是否要优先配送 D。这是骑手配送序列预测问题与常见序列预测问题最大的差异。骑手配送序列预测是一个多任务耦合的预测问题。同时,在建模方面,还需要应对较多的骑手个性化以及复杂动态的现实配送环境问题。

要如何解决这些问题呢?在实际应用中,可以从单一序列预测开始解决,分别针对配送顺序和配送时间进行预测,然后通过序列的多任务协同进行联合优化。

(1) 首先是单序列的骑手配送顺序预测。在这个任务中,需要预测在给定骑手和订单的情况下,骑手的实际配送顺序。此任务的核心在于理解并学习骑手的配送行为,以准确预测其配送顺序。这里采用了基于模仿学习的方法进行骑手配送顺序的预测。简而言之,

试图通过模仿骑手的决策过程来预测具体的配送顺序。

具体到方法上,主要探索了两大类方法,即基于搜索优化的算法和基于骑手行为学习的方法。基于搜索优化的算法主要通过定义目标函数并结合搜索优化方法来获取骑手可能的配送顺序。其中,主要的挑战是目标函数的定义以及搜索方法的选择。这种方法的优点在于其良好的可解释性,以及在实际应用中快速高效的特点。而基于骑手行为学习的方法则是直接学习骑手的配送决策行为。相对于搜索优化方法,其优势是能够针对较为复杂的决策环境进行更加精细的建模。接下来,将详细介绍上述这两种方法。

第一种方法是基于专家知识驱动的搜索优化算法。该方法的核心思想是,根据给定的目标函数,通过搜索获取能够使目标函数值最佳的配送顺序。该方法的假设是,最优的目标函数值意味着优化结果与骑手实际行为最相似。在定义目标函数时,可以通过人工定义的方式,综合考虑顺路度、时长、骑手体验等多种因素的影响,直接给定经验目标函数。这在业务的初期通常是非常有效的。例如,可以将目标函数设定为距离最短,从而将问题简化为一个最短距离的配送问题。然而,在实际应用中,通常会同步考虑到其他因素,例如配送时长。目标函数确定以后,主要的挑战在于搜索求解。对于配送顺序,一种简单的搜索方式是暴力搜索,即遍历所有可能的顺序;然而,这种方法的问题在于求解效率过低,需要遍历的可能配送顺序规模巨大。为了提高搜索效率,我们考虑了更高效的启发式搜索算法,并设计了一个两阶段的搜索过程。首先,是初始化阶段,在这个阶段采用简单的规则生成初始的配送顺序。例如,在图5.18中的示例里,给定了一个初始的顺序,商家用小房子表示,用户用一个人像代表,即形成了一个取送的顺序。然后,是第二阶段的局部搜索,通过一些经验规则调整初始配送顺序。最后,找到其中超时最多的节点,尝试前移,或者找到剩余时长最多的节点,尝试后移,观察是否能够优化目标函数。通过这样的方式,能够找到目标函数值相对较优的配送顺序,作为预测结果。这样就得到了第一个配送顺序预测的解决方案。那么,接下来如何进一步优化呢?

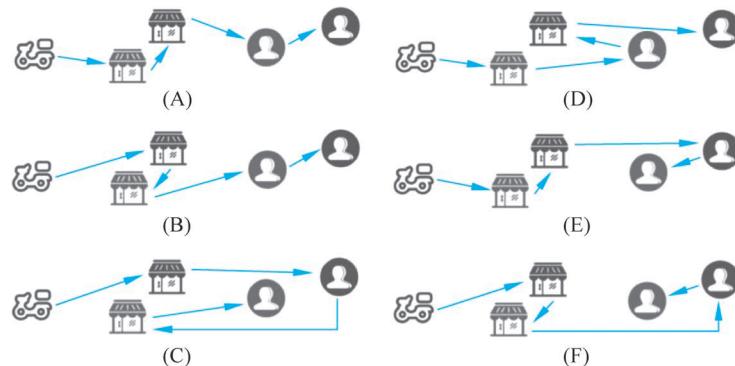


图5.18 搜索优化—专家知识驱动

为了进一步提升预测效果,一个手段是尝试优化目标函数,如图 5.19 所示,为目标函数引入更丰富的目标因子。例如,引入效率、顺路度、体验、空驶等因子,此时目标函数优化问题也就变成了一个多目标优化问题。其中,面临的一个比较直接的问题是,如何定义不同目标因子的权重,人工定义显然不太现实。为了解决这个问题,我们采用了基于逆强化学习的骑手目标函数学习方法,用来学习不同目标因子的权重。这里采用的演示集是骑手的真实配送顺序,优化目标是最大化演示集轨迹的出现概率。通过逆强化学习的方法,可以通过数据驱动的方式学习到比较合理的目标权重结果。然而,一个无法解决的问题是,随着引入目标函数项变得越来越多,目标函数项的设计会变得越来越复杂。但是人工设计的目标函数项很难刻画复杂的配送决策环境,这也是基于目标函数优化的一个瓶颈点。

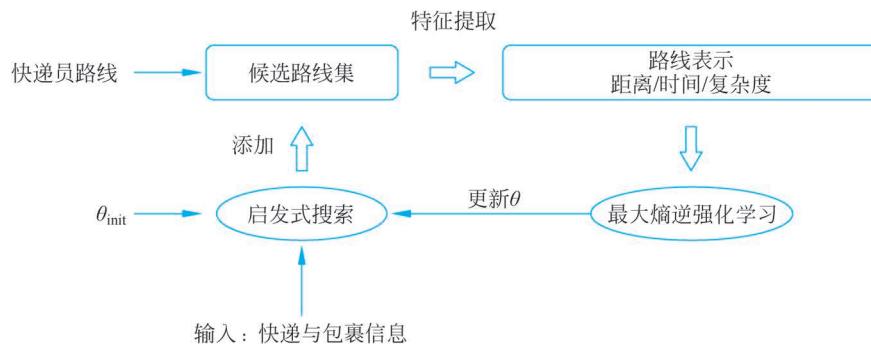


图 5.19 搜索优化—目标函数学习

(2) 为了解决目标函数的瓶颈点问题,一种可行的方式是直接去学习骑手面对复杂环境的决策行为,也就是行为克隆。这里需要的是对骑手在不同环境状态下的决策行为建模。例如,可以采用 MDP 建模,如图 5.20 所示,首先需要定义状态和具体的动作。状态可以包括骑手状态,比如位置、背单量等,订单的状态,比如重量、剩余时长等。动作则是选取下一个配送节点。利用骑手的历史配送数据进行训练,将问题建模成一个二分类问题,判断对应节点是否为下一节点。这时候,可以采用常用的 XGBoost、深度神经网络(DNN)模型。每次选取下一节点,直到所有节点选取完毕,形成最终的配送顺序。这种方法的优点在于建模相对简单直观。但是需要关注的是,一般来说我们需要显式地定义状态转移过程,包括骑手、订单的状态转移,比如骑手的位置变化,订单的剩余时间变化。是否有更好的方法呢?同时,配送过程具有一定的连续性,例如,骑手朝着一个方向配送,大概率会继续朝着同一方向,而不会折返配送。

如何在模型中引入这种上下文的影响呢?比较常用的方法是采用 Seq2Seq(Encoder-Decoder)建模(如图 5.21 所示),通过 Encoder Decoder 的方式来预测骑手配送顺序。在这种方法中,Encoder 的主要功能是提取所有订单的上下文特征,而在 Decode 过程中,通过隐

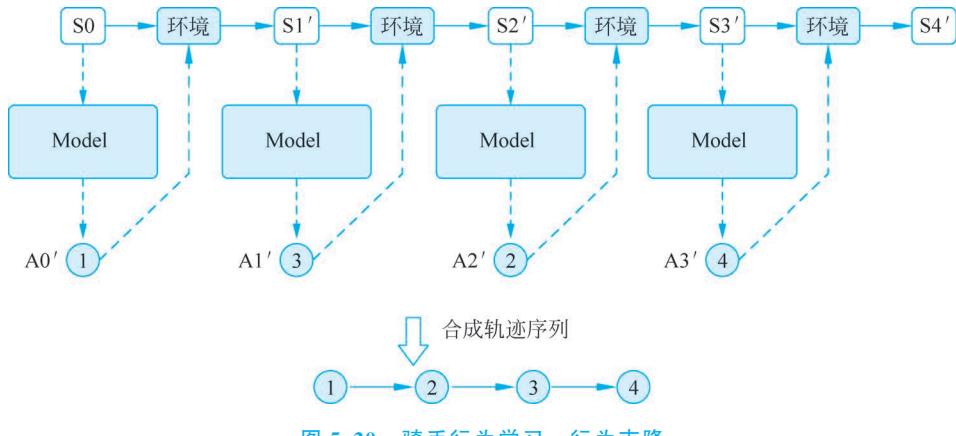


图 5.20 骑手行为学习—行为克隆

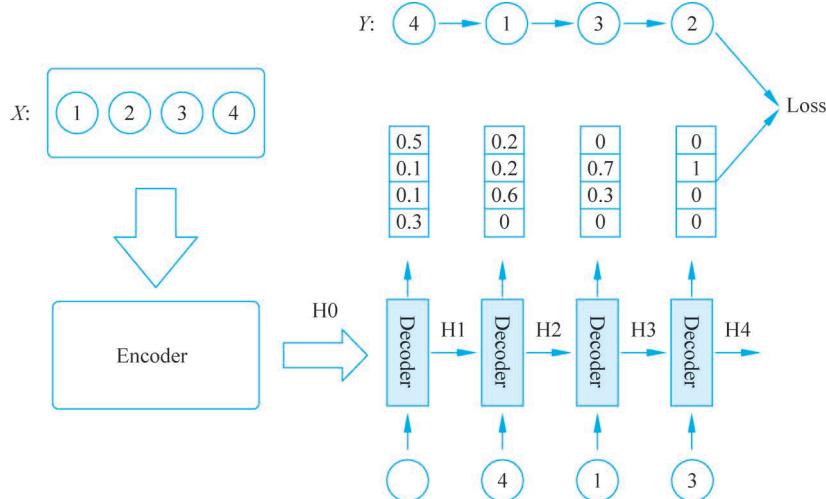


图 5.21 Seq2Seq 建模

状态的转移来隐式地表达配送过程的连续性。在具体建模中,可以采用 LSTM、Transformer 等常用的结构。这类方法的优点在于采用端到端建模的方式,一般来说不需要人工定义状态转移问题,同时能够比较好地关注序列上下文信息。然而,在实际应用中,尤其是在带有 LBS 属性的序列预测中,这种状态转移从实践来看并不能很好地表达出来。因此,在实践中需要强调的一点是,对于一些重点状态,比如骑手位置、剩余时间等,为了达到较好的预测效果,一般还需要单独进行建模。也就是说,隐状态转移与人工状态转移配合使用才能达到比较理想的效果。更进一步,在实际训练应用中,会发现一个序列预测中非常常见的问题,即训练集中没有覆盖到的决策问题如何处理。

具体来说,在模型应用时,可能会遇到一些训练样本空间中从未出现过的状态,简单行为克隆学习到的模型往往无法很好地进行预测。这也就是序列预测中常提到的暴露偏差

(Exposure Bias)问题。一般来说,为了解决这类问题,同时提高模型的预测精度,可以采用逆强化学习、对抗学习等方式进一步提升模型的泛化能力(如图 5.22 所示)。

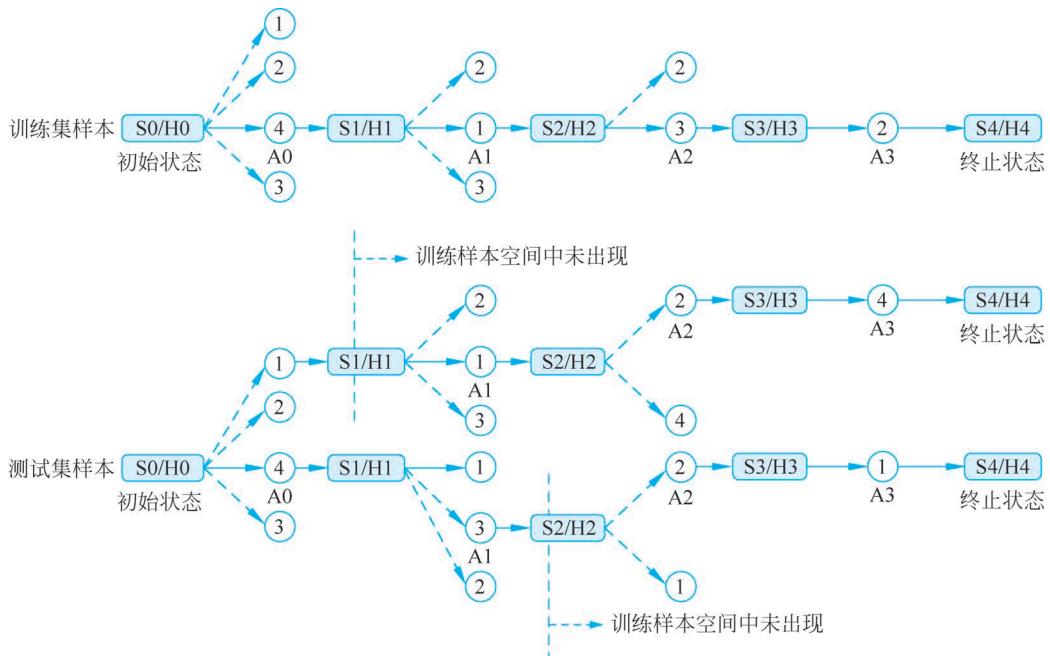


图 5.22 骑手行为学习—逆强化学习或对抗学习

(1) 总结一下配送顺序预测问题,首先,基于专家目标函数的搜索优化算法满足了配送顺序预测的线上基础应用;其次,基于逆强化学习的目标函数学习解决了目标函数权重设计问题。最后,行为克隆的骑手行为学习一定程度上弥补了目标函数无法描述复杂场景的骑手决策问题,通过逆强化学习、对抗学习可以进一步提升模型的预测能力。

(2) 介绍完配送顺序预测问题后,接着讨论配送时间预测问题(如图 5.23 所示)。在配送过程中,涉及许多时间过程。例如,用户下单后会有等待时间,然后才是签收;商家收到订单后会有接单时间,然后是准备餐品的时间;而对于骑手,则更加复杂,首先会接单,然后骑行到商家去取餐,在取餐过程中,需要下车步行到商家、在商家等餐,然后步行离开商家,到用户的地方同样涉及类似的多个时间段问题。具体来说,对于骑手的时间,可以将时间分为骑行段、取餐段、交付段这三大段。接着需要做的就是对每一个分段都进行建模。最简单的方式是采用机理建模的方式,即根据骑手配送执行的顺序,将各个分段的时间进行累加,得到最终的配送时间。在这里,每个分段的时间可以采用历史统计特征的方式,也可以单独进行建模预测。

更进一步,我们对每个分段都需要进行详细建模(如图 5.24 所示)。比如,骑手接单前需要对骑手的接单位置、接单时间进行预测;在取餐段,需要对商家的出餐时间、骑手的入

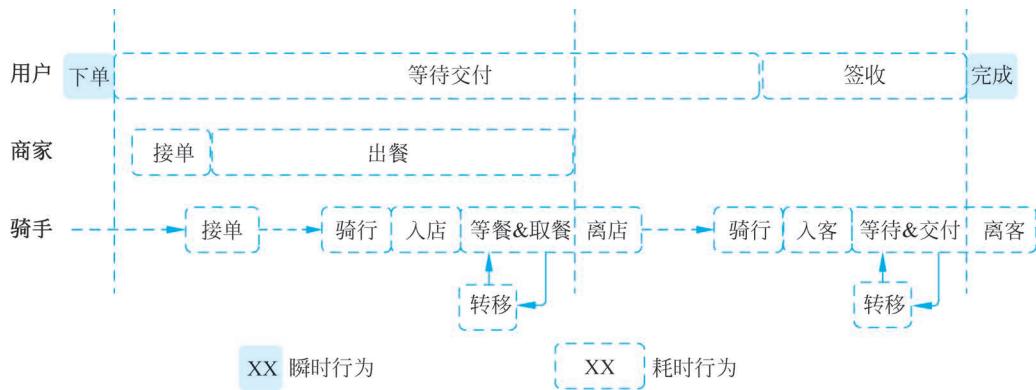


图 5.23 配送时间预测问题

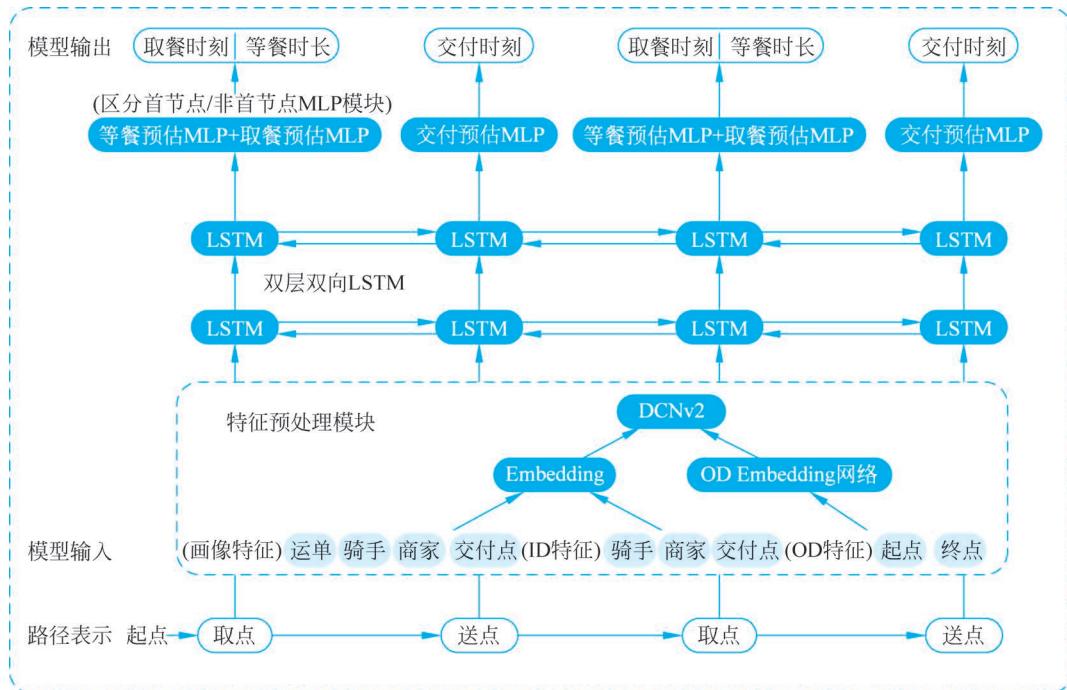


图 5.24 精细化配送环节建模

离店时间进行预测等。而在模型选用上，我们经历了从 XGB、DeepFM 到 RNN 模型，再结合多任务的方式进行进一步的优化。在具体预测任务上，一方面，需要对配送时长进行预测，另一方面，也进一步扩充到超时概率预测、时间分布预测等任务上。通过这些预测任务的组合，为调度提供完整的时间信息输入。实践中最重要的是：不要忽略任何一个可能引起预测误差的时间环节。这与大家通常接触到的单点建模问题有所不同，是一个系统性优化问题。

前面内容已经介绍了如何单独预测配送顺序以及时间。但实际上两者互相穿插，没有

完全分离,比如在讨论顺序预测时提到了时间约束,而具体的时间预测依赖于既定的配送该顺序。接下来讨论如何将两种预测能力进行结合。首先是基于搜索优化的配送顺序预测与时间预测的结合,即在目标函数中加入配送时间的目标函数项,然后通过迭代优化的方式来搜索优化;也就是在得到初始化配送顺序的同时,获取初始化的配送时间,得到目标函数结果。然后在局部搜索过程中,不断更新配送顺序、时间、目标函数值,以得到更优的配送顺序和时间。

(3) 将时间预测模型与配送顺序预测模型进行耦合,来实现骑手配送行为学习的配送顺序预测方法。下面是美团团队在 2021KDD 上发表的论文^[7],如图 5.25 所示,在模型结构中,将模型分为顺序预测和时间预测两个模块,将顺序预测结果作为时间预测的输入,同时将时间预测的输出作为顺序预测的输入。通过两个模型的互相依赖和协同训练,来达到配送顺序和时间协同优化的效果。其实在这基础上,可以在模型中引入更多的优化目标,比如时间约束、顺路约束、骑手偏好等。

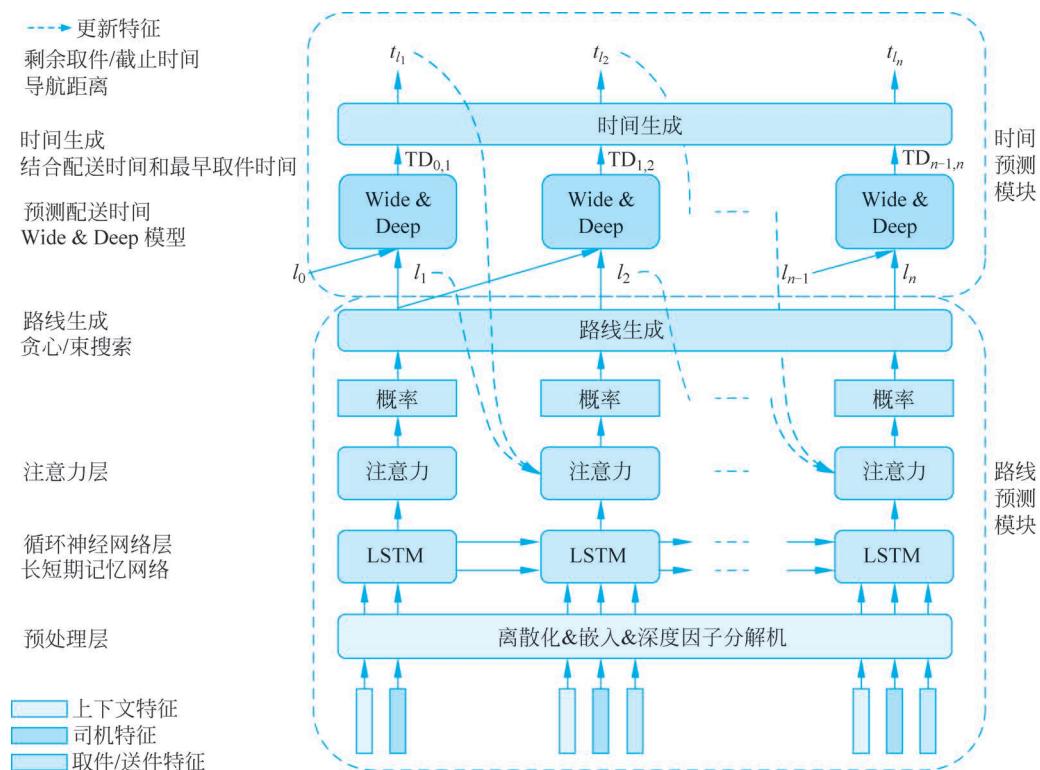


图 5.25 模型结构^[7]

目前已经整体介绍了配送顺序和时间预测的方法,接下来简单介绍一下评估方法。从评估角度来看,主要评估预测结果与骑手真实配送状态的相似程度。在配送顺序预测上,可以参考排序相关的指标,其中一个比较特别的是顺序一致率,即两个顺序的公共前缀长

度占比。因为在配送顺序预测中,一旦某一节点预测错误,那后续节点的预测将变得没有意义。而在时间上的评估则主要关注预测的MAE、N分钟置信度等指标。

5.4.3 骑手配送序列预测问题与挑战

下面讨论目前骑手配送顺序和时间预测存在的主要问题和技术挑战。如图5.26所示,在具体预测前,系统会收集骑手的实时状态数据,这里会存在一定的时间差。而在订单指派给骑手后,骑手会有一个接单时间差,然后在具体执行前,又会有一个时间差。也就是说,在整个系统运行过程中,会有非常多的时间差。这也就导致了预测使用的数据输入与真实环境是有差异的,如何弥补这种差异是目前的一个重要问题。同时,除预测和骑手实走顺序外,我们在骑手配送过程中也会根据骑手的实时状态为骑手推荐配送顺序,骑手可以参考推荐顺序进行配送。因此,系统中同时存在预测顺序、推荐顺序和骑手实走顺序这三种不同的配送顺序,由于具体顺序产生的时间和环境不同,三者间可能存在差异,而在理想情况下,我们的优化目标其实是三者尽量一致。这是一个非常复杂的问题,涉及系统、骑手的协同、协作问题。

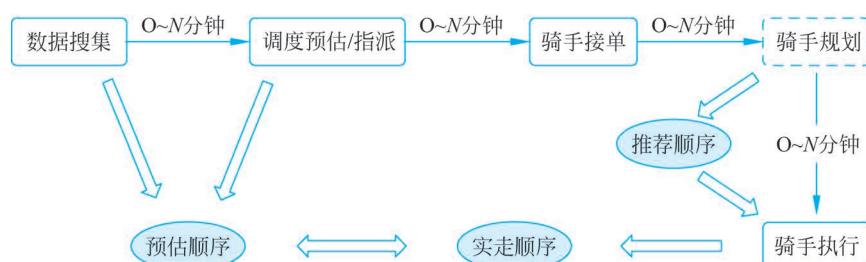


图 5.26 骑手、系统协同

而具体到技术挑战层面,涉及的主要是概率预测问题。这里涵盖了时间概率预测和配送顺序多方案概率预测问题。这两个问题在学术研究和工业应用中都相对欠缺,但对于实际应用却是非常必要的技术点。如图5.27所示^[50],假设有A和B两个时间分布预测,代表一个任务在两种不同方案下的可能完成时间。如果希望任务尽量保证在35分钟内完成,那么可以选择B方案;而如果希望任务有较高概率在25分钟内完成,则会选A方案。时间分布预测对于实际任务具有显著的应用价值。

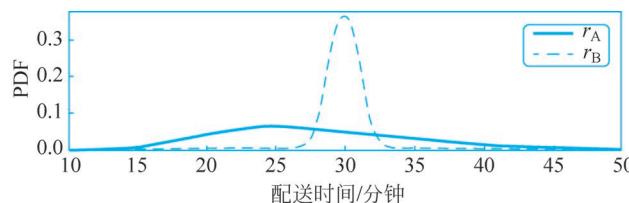


图 5.27 概率预测^[50]

通过优化预设的骑手目标函数,结合历史数据预测配送顺序;为配送过程各环节精细建模,预测配送时间;不断迭代满足序列间耦合约束。技术演进图示于图 5.28 中,从最初的规则搜索方法,到树模型,再到深度模型方法提升预测精度,目前主要的精力集中在序列建模以及协同预测上^[50-55]。



图 5.28 技术演进图

5.5 小结

首先,本章讨论了即时配送中大数据预测技术的重要性和实际应用,并深入探讨了即时配送的具体预测问题,如骑手配送顺序和配送时间预测。其次,在此基础上,介绍了使用机器学习技术来构建预测模型的方法,包括样本选择、特征工程和模型评估等。接着分析了商家出餐时间的不确定性和供需波动,以及如何通过概率分布预估和处理删失数据来提高预测准确性等问题。最后,本章概述了配送顺序和时间预测的具体建模方法。通过探讨上述问题,可实现对配送流程更精准的控制。