

基于局部斜率更新的数据驱动动态定价策略

陈吉, 田林*, 徐以汎

(复旦大学管理学院, 上海 200433)

摘要: 基于某经济型连锁酒店的实际入住数据, 研究针对未知需求的数据驱动动态定价策略的应用. 提出一种新的非参数的需求函数刻画方法, 称为“局部斜率更新”. 该方法替代以往数据驱动策略中所使用的最小二乘法, 得到新的数据驱动定价策略: 基于“局部斜率更新”方法的短视(被动学习)动态定价策略, 称为 IL 策略; 基于“局部斜率更新”方法的主动学习动态定价策略, 称为 CIL 策略. 新方法能够克服价格内生性的难题, 解决以往数据驱动策略的应用困境. 数据实验表明, 新方法的拟合优度接近最小二乘法. 在线性和非线性需求函数形式的假设下, “局部斜率更新”方法的拟合优度与最小二乘法分别只相差 7.19% 和 4.69%. 酒店实际数据验证表明, 结合新方法的数据驱动定价策略明显优于酒店经理的实际定价决策, 其中 IL 可降低 60% 的后悔值, CIL 可降低 77.59% 的后悔值. 本文提出的需求函数刻画方法及结论有助于指导未知需求数据驱动收益管理理论的应用实践.

关键词: 动态定价; 未知需求; 价格内生性; 数据驱动; 收益管理

中图分类号: TP273 文献标识码: A 文章编号: 1000-5781(2020)01-0033-15

doi: 10.13383/j.cnki.jse.2020.01.004

Data-driven revenue management strategy based on local-slope update

Chen Ji, Tian Lin*, Xu Yifan

(School of Management, Fudan University, Shanghai 200433, China)

Abstract: Based on the real data of one economical hotel group, this paper studies the application of data-driven revenue management with unknown demand. To tackle price endogeneity, a new non-parametric approach of demand estimation, called local-slope update, is proposed to replace the OLS used by current data-driven policies. New dynamic pricing policies, namely iterated local-slope (IL) and constrained iterated local-slope (CIL), are also developed. The results show that the forecasting accuracy of local-slope update is less than that of OLS only by 7.19% and 4.69% for linear and nonlinear demands, respectively. Both the IL policy and CIL policy can significantly improve hotel revenue. The CIL can reduce 77.59 percent of the regret value and IL can reduce 60 percent of the regret value. This non-parametric approach of demand estimation helps the applications of data-driven revenue management methods in practice.

Key words: dynamic pricing; unknown demand; price endogeneity; data-driven; revenue management

1 引言

近几年, 中国经济型快捷连锁酒店行业飞速发展. 以某经济型连锁酒店管理集团为例, 在过去七年时间里, 平均每年以 50% 左右的增速进行扩张. 仅在 2014 年, 其新增运营门店达到 570 家, 占其原有门店

收稿日期: 2017-03-23; 修订日期: 2017-12-19.

基金项目: 国家自然科学基金资助项目(71531005; 71922008; 71372113; 71702093); 复旦-台大合作研究基金资助项目(201502).

*通信作者

的40%。伴随着经营规模的不断扩大,该连锁酒店在收益管理上面临着严峻的挑战。单间客房的平均收益逐年下降,由2010年的183元下降至2014年的159元。经营规模的扩大需要大量的新增门店,而对于这些门店而言,不仅在管理上需要一定时间的磨合,而且还需要重新去认识未知的市场环境。这一管理难题致使该经济型连锁酒店管理集团的平均收益水平逐年下降。

本文将探讨对于未知需求的数据驱动收益管理(动态定价)策略的实践应用问题。对于运营多年的门店,决策者在定价时可以通过大量成熟的历史数据和分析工具进行有效的需求预测,以指导最优化定价。但是对于新开门店,决策者没有任何历史数据可作参考,往往对市场需求信息一无所知。为此,本文采用数据驱动的方法来应对这一难题。该方法通过不断地探索以学习背后的需求函数,并利用其优化收益管理决策。

传统收益管理研究中多假设已知的需求函数。毕文杰等^[1]和毕功兵等^[2]假设简单的线性需求函数,并分别考虑参考价格和替代品的影响。Gallego等^[3]假设指数型的需求函数,研究给定库存水平下的有限时间动态定价策略。Feng等^[4]研究动态定价策略的时间决策机制,发现对于季节性较强的产品,应该在特定时机选择降价;而对于机票酒店产品,则应该在特定时间选择提价。调整价格的时机与所剩库存有关。Bitran等^[5]假设消费者以泊松过程到达,研究连续时间模型下的动态定价策略,发现最优定价随时间而下降。Zhao等^[6]假设消费者以非齐次泊松过程到达,发现最优定价随着库存的增大而降低。当满足一定条件时,在给定的库存水平下,最优定价随时间降低。注意,以上经典的收益管理(动态定价)研究均假设具体的需求函数。但在实际问题中,需求函数对于决策者而言多是未知的。

近年来,基于未知需求的数据驱动收益管理研究备受学者关注,主要可分为两类。第一类文献对需求没有具体的假设,在制定策略时省略需求预测,直接通过历史信息计算得出。Ball等^[7]利用占线算法(online algorithm)进行收益管理。该算法计算每个策略的竞争比(competitive ratio),并选择最大化竞争比的策略。同样,Lan等^[8]则通过需求的最大值和最小值进行各策略的竞争分析,以获得所有需求情况下的确定性收益保证。第二类文献则先假设需求函数的具体形式,然后在每一期基于新数据进行需求函数参数的估算与更新,最后基于需求函数进行最优化定价。本文研究属于第二类。对需求函数的预测过程被称为“学习”(learning),基于需求函数的定价优化过程被称为“获利”(earning)。一些研究着重关注“获利”,在不完全学习(incomplete learning)的情况下,聚焦于最大化当期收益的短视策略或贪婪策略。Arman等^[9]研究无限阶段下的非易腐物品的动态定价策略,提出以贝叶斯更新为需求预测方法的贪婪算法。Harrison等^[10]指出基于当前利益最大化的短视贝叶斯策略是普遍存在的,但当满足一定条件时,短视贝叶斯策略相较于最优策略的后悔值能够被控制在常量之内,与阶段总数大小无关。Keskin等^[11]探讨通过最小二乘法进行需求预测与更新的ILS(iterated least squares)短视动态定价策略。注意,上述短视策略因为注重短期获利,定价会集中在某个狭小的范围,致使新获取的价格信息质量具有局限性,会影响需求函数“学习”的效果,属于不完全学习,也称为被动学习。因为预测的需求函数不准确,所以被动学习会减弱长期获利,影响总体获利水平。

更多基于未知需求的收益管理研究聚焦于主动学习策略。Besbes等^[12]将销售期分成两部分:在前期使用不同价格对各自所处区间的需求进行观测;在后期,每个阶段都使用由前期学习所得的最优定价。该策略可以有效降低其相对于最优策略(需求函数已知)的后悔值。Broder等^[13]通过极大似然估计对需求函数的参数进行学习,将总产品周期分成多个长度逐渐增加的阶段,在每个阶段的前期固定价格用于学习,后半段采用短视策略定价获取收益。Boer等^[14]提出了控制差异定价(controlled variance pricing)策略,该策略使得定价保持一定的波动性(variance),以提高极大似然估计方法对需求函数的学习效果。Wang等^[15]所提出的策略则将学习和获利融合在一起考察。他们将每一阶段的定价范围等分成多个价格区间,分别学习各个区间内的需求信息。基于这些信息缩小下一阶段的价格搜索范围,以采取较优的定价而获取较高的收益。Keskin等^[11]以ILS策略为基础,运用最小二乘法,提出将学习和获利融合在一起的CILS(constrained iterated least squares)主动学习策略。这些文献能够较好地把握“学习”和“获利”之间的关系。

但注意,上述研究在反馈给定价格的需求数据时,均使用仿真数据(即基于预先假定的需求函数),并没有结合企业的真实数据进行验证分析。实际中,企业的真实需求函数是不可知的,需要根据已有的所

有样本进行估计. 本文对某经济型快捷连锁酒店的真实数据进行分析时, 发现排除星期, 月份, 旬度, 节假日, 竞争对手价格, 以及需求截断等因素的影响后, 价格与需求之间呈现显著的正相关关系. 这是典型的“价格内生性”问题 (Hausman^[16]), 即价格与需求之间的因果关系发生逆转. 在“价格内生性”问题下, 无法通过极大似然法或者最小二乘法直接利用现实数据估计真实的需求函数. 为应对实际数据的内生性问题, 在无法找到有效工具变量的前提下, 本文提出一种新的非参数的需求刻画方法, 称为“局部斜率更新 (iterated local-slope)”. 结合该方法, 本文提出代表被动学习的 IL (iterated local-slope) 和代表主动学习的 CIL (constrained iterated local-slope) 数据驱动动态定价策略.

本文分别通过仿真数据实验和实际数据研究论证“局部斜率更新”的有效性. 该方法在牺牲极小估计准确性的情况下, 规避传统估计方法所存在的价格内生性问题, 能够在实际问题中有效地帮助酒店提升收益水平. 同时, 本文通过对酒店实际运营数据的分析, 进一步巩固已有文献的相关理论结果: 主动学习定价策略在未知需求的收益管理中显著优于被动学习定价策略. 本文提出的需求函数刻画方法及结论有助于指导未知需求数据驱动收益管理理论的应用实践.

2 数据驱动下的收益管理问题描述

假设某连锁酒店新开一家门店, 运行 T 期. 各期的需求函数独立同分布. 具体如下

$$\tilde{D}_t(p_t) = D(p_t) + \varepsilon_t, \quad t = 1, 2, \dots, T, \quad (1)$$

其中 $D(p_t)$ 是关于价格 p_t 的函数. 需求的随机扰动项为 ε_t . 本文假设该随机扰动项在时间 t 上独立同分布, 且服从均值为零的随机分布.

设价格决策范围为 P . 为满足需求值的非负性, 随机扰动项 ε_t 还需满足 $\min_{p_t \in P} D(p_t) + \min \varepsilon_t > 0$, 即随机扰动项足够小, 使得需求值永远为正.

该酒店的问题是如何制定各期价格 $p_t, t = 1, 2, \dots, T$ 以最大化 T 期的总期望收益 $E \sum_{t=1}^T p_t \tilde{D}(p_t)$. 如果函数 $D(p_t)$ 的具体形式已知, 最优策略为 $p_t = p^* = \arg \max E[p \tilde{D}(p)] = \arg \max [p D(p)], t = 1, 2, \dots, T$. 但通常情况下, $D(p)$ 的具体形式及参数是未知的, 这对价格决策造成巨大困难. 不过, 决策者在前期做出的价格决策以及所观测到的需求数据可以为后期的定价提供支持. 比如, 在第 t 期时, 前面 $t-1$ 期的价格及需求数据是已知的, 定义为 $H_t = \{(p_1, d_1), (p_2, d_2), \dots, (p_{t-1}, d_{t-1})\}$. 决策者可以根据 H_t 来估计需求函数, 决定第 t 期价格 p_t , 然后再根据第 t 期的需求数据 d_t 更新需求函数, 如此循环, 以最大化自己的收益 (如图 1 所示).

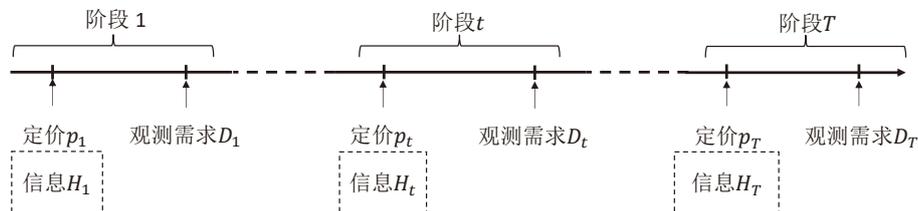


图 1 决策示意图

Fig. 1 Decision sequence

上述问题有两个难点: i) 动态定价, 即如何依照需求函数动态制定价格; ii) 需求更新, 即如何根据历史信息 H_t 预测或更新需求函数. 注意, 动态定价与需求更新并不是相互独立的, 动态定价策略 (被动学习/主动学习) 将直接影响需求更新的质量, 而需求更新反过来会影响定价的有效性. 本节先介绍两种类型的动态定价策略, 然后介绍需求更新中真实数据存在的“价格内生性”难题.

2.1 动态定价

未知需求背景下数据驱动动态定价策略可分为被动学习和主动学习两类. 为保持一致性, 本文

以 Keskin 等^[11]提出的 ILS (iterated least square) 被动学习策略和 CILS (constrained iterated least square) 主动学习策略为例, 介绍两种需求学习方法的思路。

在 ILS 策略下, 决策者基于当前估计的需求函数, 选取收益最高的价格进行定价, 并获取新的信息, 如此循环。具体而言, 在第 t 期, 给定需求函数 $D_{t-1}(\cdot)$, 选择使收益最大化的价格 $p_t^* = \arg \max[pD_{t-1}(p)]$ 作为定价。在 ILS 策略下, 学习过程只能被动地接受“最优价格”下的需求信息, 因此 ILS 定价策略属于被动学习的范畴。同时, 由于 ILS 策略只考虑当前阶段的收益最大化, 缺乏对总体收益的全局考量, 所以被称为短视策略 (myopic policy)。在 ILS 策略下, 定价往往只在较小范围内波动, 所以获取的信息具有一定局限性, 影响对需求函数的估计, 并影响“最优定价”的判断。所以, 通常情况下, ILS 策略的总体收益难以实现最大化。

与 ILS 策略不同, CILS 策略兼顾“学习”与“获利”: 如果基于当前信息的最优价格总是在小范围内变化, 甚至呈现出收敛的趋势, 该策略会使得新定价跳出局部范围, 以获取新的有效信息。假设在第 t 期, 前一期更新的需求函数为 $D_{t-1}(\cdot)$, 而基于 $D_{t-1}(\cdot)$ 使阶段 t 收益最大的价格为 p_t^* , 则具体定价策略如下

$$p_t = \begin{cases} \bar{p}_{t-1} + \text{sgn}(\delta_t)kt^{-\frac{1}{4}}, & |\delta_t| < kt^{-\frac{1}{4}} \\ p_t^*, & |\delta_t| \geq kt^{-\frac{1}{4}}, \end{cases} \quad (2)$$

其中 \bar{p}_{t-1} 为前 $t-1$ 期的平均定价, $\delta_t = p_t^* - \bar{p}_{t-1}$, k 为固定常数, $\text{sgn}(\cdot)$ 为符号函数, 即

$$\text{sgn}(x) = \begin{cases} 1, & x > 0 \\ 0, & x = 0 \\ -1, & x < 0. \end{cases}$$

不难发现, 在 CILS 策略下, 新的定价与平均价格的距离不会小于 $kt^{-1/4}$, 可以更好地“学习”需求函数。若当前最优定价 p_t^* 与历史平均价格之间的差距大于 $kt^{-1/4}$, 则按最优定价制定价格, 保证“获利”。若当前最优定价 p_t^* 与历史平均价格之间的差距小于 $kt^{-1/4}$, 则不按当前最优价格定价, 而是在历史平均价格的基础上加上或减去 $kt^{-1/4}$ 进行定价, 保证“学习”。参数 k 是对“学习”和“获利”权衡的体现, $k=0$ 等价于被动学习。 $kt^{-1/4}$ 随着 k 的增加而增大。 k 越大, 则算法学习的价格范围更广, 因而对需求函数的判断也更加准确。但另一方面, k 越大, 也意味着在有限时间范围内“获利”的空间更少。Keskin 等^[11]通过仿真数据验证并证明在 $k > 0$ 且满足一定要求时, CILS 主动学习策略的后悔值 (与已知需求函数下最优策略之间的差距) 是以 $\ln(T)$ 上升的, 优于 ILS 策略。

2.2 需求更新-价格内生性

无论是 ILS 策略, 还是 CILS 策略, Keskin 等^[11]均采用最小二乘法对需求函数进行估计与更新。文献中需求学习的方法并不限于最小二乘法, 还包括最大似然估计法 (如 Broder 等^[13]) 与贝叶斯更新法 (如 Arman 等^[9])。但注意, 文献中使用的是仿真数据, 即先假设具体的需求函数, 如 $D(p)$ 的具体形式及参数。在第 t 期, 给定价格 p_t 后, 按照 $\tilde{D}(p_t)$ 反馈需求数据 d_t 。然后, 决策者会依据这一价格需求数据 (p_t, d_t) 与相应方法更新对 $D(p)$ 的估计。实际中, 企业的真实需求函数是不可知的 ($D(p)$ 不是预先给定的), 需要根据已有的所有样本进行估计。由于仿真数据中的需求是假定的, 在理论模型中不存在价格内生性的问题, 但这可能存在于实际数据中。

表 1 对象门店基本信息

Table 1 Information of hotels

门店编号	开业时间	总房量	入住均值	入住标准差	价格均值	价格标准差
1	2014-01-10	68	61.32	12.60	171.12	22.93
2	2014-04-04	48	43.06	7.02	141.95	13.09
3	2014-04-30	102	77.04	18.65	129.37	13.06
4	2014-05-04	364	302.47	51.66	317.92	66.82
5	2014-05-19	61	52.29	8.98	127.63	11.64
6	2014-06-04	47	43.33	6.59	242.14	62.34

表 2 各门店回归结果
Table 2 Results of regression at each hotel

门店编号	价格系数	T 值	双尾检验 P 值	样本量	R 方
1	0.395	9.04	0.000	534	0.103
2	0.215	4.70	0.000	450	0.089
3	0.560	7.03	0.000	424	0.095
4	0.118	3.14	0.002	420	0.047
5	0.315	7.16	0.000	405	0.109
6	0.147	5.01	0.000	388	0.108

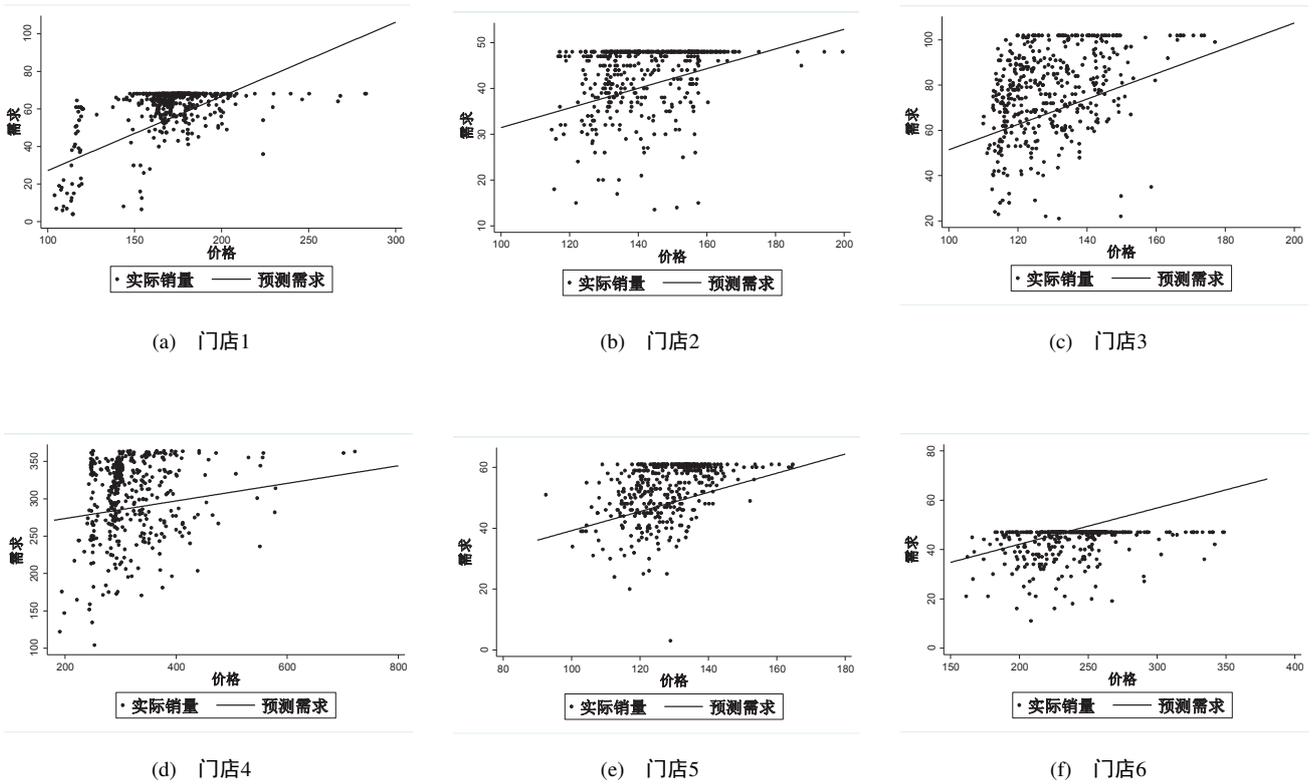


图 2 数据散点图及回归函数

Fig. 2 Scatter and regression function

通过对某连锁酒店集团在某地区 2014 年新开 6 家门店 (见表 1) 的样本数据进行分析, 本文发现排除星期, 月份, 旬度, 节假日, 竞争对手价格, 以及需求截断等因素的影响后, 价格与需求之间呈现显著的正相关关系. 表 2 展示各门店数据的截断回归结果. 图 2 展示各门店的数据散点图及对应的回归函数曲线. 在实际定价过程中, 门店经理会先对需求信息做出预判, 需求高则提高价格, 需求低则降低价格. 注意, 这是典型的“价格内生性”问题, 即价格与需求之间的因果关系发生逆转. 本来, 价格是因, 需求是果, 需求根据价格调整而变化; 现在, 需求是因, 价格是果, 根据需求变化制定价格.

在价格内生性问题下, 最小二乘法 and 最大似然估计法等传统需求预测方法无法适用, 因为预测估计的价格与需求之间的关系是正向的, 致使得得到错误结果: 价格越高越好. 这也致使 ILS 和 CILS 等定价策略在实际应用中陷入困境. 除酒店行业外, 价格内生性问题也广泛存在于其他各行各业. 为应对价格内生性问题, 许多研究引入价格的工具变量, 即影响价格但不被需求影响的变量. 最经典的价格工具变量由 Hausman^[16] 提出, 即同一个产品在其他地区的定价. 注意, 使用该方法的一个基本前提是, 产品单位成本与价格具有显著的正向关系. 然而, 经济型快捷酒店行业的可变成本普遍极低, 门店经理在定价时并不会考

虑变动成本的影响. 因此, 酒店行业并不适合引入该工具变量. 在无其他契合酒店行业特点工具变量的情况下, 本文提出“局部斜率更新法 (local-slope update)”, 可有效规避价格内生性的问题.

3 局部斜率更新

在收益管理企业实践中, 分段线性需求函数的运用极为广泛. 因为样本点总是有限的, 用某个价格 p 下对应的信息所得到的需求函数来预测该价格周围的价格点所对应的需求时会较准确, 但预测离该价格较远的价格点对应的需求时误差会较大. 采用分段线性函数的形式能够更加细致地反映不同价格区间内的价格敏感性. Hormby 等^[17]与 Koushik 等^[18]发现酒店行业的需求特征更适合用分段线性需求函数进行刻画. 因此, 本文也采用分段线性需求的形式.

给定期望收益函数 $r(p) = E[p\tilde{D}(p)] = pD(p)$, 最优价格下应满足 $\frac{dr}{dp} = 0$, 即 $D(p) + p\dot{D}(p) = 0$, 有 $\dot{D}(p) = -D(p)/p$. 对于任意线性需求函数 $D(p) = \theta - Ap$, 可得价格斜率系数 $A = D(p)/p$. 因此, 若当前价格 p 是最优价格, 则可以用对应需求 $D(p)$ 除以该价格来计算该价格点的斜率系数 A . 根据这种思路, 参照 Eichenbaum 等^[19]提出的弹性价格模型 (flexible price model), 可以用所观测到的每一组价格需求数据来近似计算该价格点的价格弹性 (斜率). 现实中, 酒店经理的绩效与酒店的收益直接挂钩. 门店经理在制定价格决策时, 必定会根据其所掌握的信息优化酒店收益. 然而, 门店经理所掌握的信息往往是局限的, 所以其决策不可能是全局最优的. 但由于酒店经理会尽可能地提高酒店收益, 基于分段线性函数的假设, 其决策可被近似看作是局部最优的. 即, 对于每一组观测值 (p_t, d_t) , 有

$$p_t d_t = \max_{p_t - \Delta \leq p \leq p_t + \Delta} \{pD(p)\}, \quad (3)$$

其中 $\Delta \geq 0$. 因此, 给定任意真实数据点 (p_t, d_t) , 可用 d_t/p_t 近似计算该价格点的价格斜率系数.

根据 Lagrange 中值定理, 当价格变动间距充分小时, 任意可导且斜率值有限的需求函数, 在该价格区间内的斜率值会非常接近. 酒店经理所制定的价格决策只细分至整数, 通过对实际数据的观测, 发现价格观测值的大致变动间距为 2 元~5 元. 可见, 样本中的价格间距已经足够小. 可近似地将某价格点所求得的需求函数斜率作为该价格点附近区间的统一斜率值. 基于该思路, 新的价格数据点可用于对其所处的局部价格区域进行斜率更新, 称该方法为“局部斜率更新 (local-slope update)”. 值得注意的是, 在本方法下计算得到的任意样本点局部范围内的价格斜率都是负的, 即价格需求之间的关系是负向的, 可有效规避价格内生性的问题. 下面先具体介绍“局部斜率更新”方法的步骤, 然后用实例验证该非参数需求预测方法的预测准确性.

3.1 局部斜率更新的具体步骤

“局部斜率更新”需求刻画方法的具体步骤如下:

1) 在第一个样本点 (p_1, d_1) . 以 $-d_1/p_1$ 为斜率, 通过点 (p_1, d_1) 作直线, 即得需求函数 $D_1(\cdot)$.

2) 在第 t 个样本点 (p_t, d_t) , 需求函数中价格 p_t 所对应的信息的导数为 $\dot{D}_t(p_t) = -d_t/p_t$. 假设信息 H_t 中所有价格的排序为 $p_{l_1} \leq p_{l_2} \leq \dots \leq p_{l_{t-1}}$. 将价格的决策范围 P , 分割成 t 个区间, 分别用 $P_1^{t-1}, P_2^{t-1}, \dots, P_t^{t-1}$ 表示. 其中, $P_1^{t-1} = [0, p_{l_1})$; $P_i^{t-1} = [p_{l_{i-1}}, p_{l_i})$, $i = 2, 3, \dots, t-1$; $P_t^{t-1} = [p_{l_{t-1}}, +\infty)$. P_i^{t-1} 代表价格波动的局部范围. 在更新需求函数时, 先对 p_t 附近价格区间的需求函数进行更新, 再对其他区间进行调整, 以保证需求函数连续且原有斜率不变.

下面分三种不同情况具体讨论需求函数的更新方法.

(i) 如果第 t 个样本点的价格比所有历史样本的价格都高, 即 $p_t > p_{l_{t-1}}$, 那么更新需求函数为

$$D_t(p) = \begin{cases} D_{t-1}(p) + \dot{D}_t(p_t)(p_{l_{t-1}} - p) + d_t - D_{t-1}(p_{l_{t-1}}), & p < p_{l_{t-1}} \\ \dot{D}_t(p_t)(p - p_t) + d_t, & p \geq p_{l_{t-1}} \end{cases} \quad (4)$$

如果新价格相比于所有历史价格是最高的, 需求函数在价格 p_t 附近的价格区间为 $P_t^{t-1} = [p_{l_{t-1}}, +\infty)$. 在该区间, 基于信息 (p_t, d_t) 及其导数 $\dot{D}_t(p_t)$, 需求函数更新为 $\dot{D}_t(p_t)(p - p_t) + d_t$. 而在其他价格区间 $(p < p_{l_{t-1}})$, 保留原有的价格斜率不变, 但对具体的需求值做相应调整. 在价格 $p = p_{l_{t-1}}$, 新函数的需求值为 $\dot{D}_t(p_t)(p_{l_{t-1}} - p_t) + d_t$, 原函数的需求值为 $D_{t-1}(p_{l_{t-1}})$. 因此, 新函数的需求调整幅度为 $\dot{D}_t(p_t)(p_{l_{t-1}} - p_t) + d_t - D_{t-1}(p_{l_{t-1}})$. 在价格区间 $p < p_{l_{t-1}}$ 的需求值都做出相同幅度调整, 如图3所示.

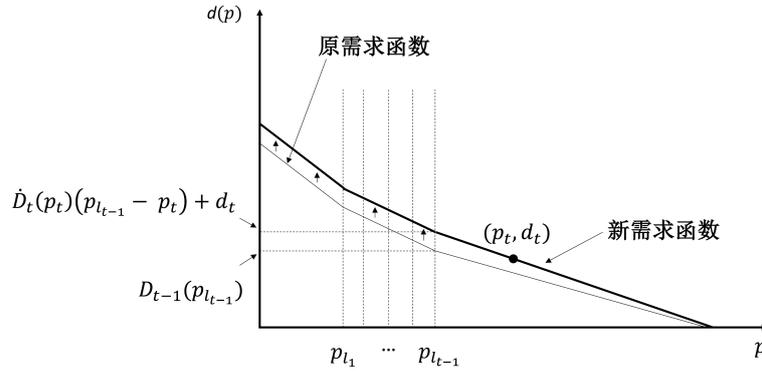


图 3 新价格大于历史价格时的需求函数更新

Fig. 3 Demand update when new price is greater than all historical prices

(ii) 如果第 t 个样本点的价格比所有历史样本的价格都低, 即 $p_t < p_{l_1}$, 那么更新需求函数为

$$D_t(p) = \begin{cases} D_{t-1}(p) + \dot{D}_t(p_t)(p_{l_1} - p_t) + d_t - D_{t-1}(p_{l_1}), & p \geq p_{l_1} \\ \dot{D}_t(p_t)(p - p_t) + d_t, & p < p_{l_1}. \end{cases} \quad (5)$$

如果新价格相比于历史价格是最底的, 价格 p_t 附近的区间为 $P_1^{t-1} = [0, p_{l_1})$. 在该区间, 基于信息 (p_t, d_t) 及其导数 $\dot{D}_t(p_t)$, 需求函数更新为 $\dot{D}_t(p_t)(p - p_t) + d_t$. 在价格 $p = p_{l_1}$ 处, 新函数的需求值为 $\dot{D}_t(p_t)(p_{l_1} - p_t) + d_t$, 原函数的需求值为 $D_{t-1}(p_{l_1})$. 在其他区间 $(p \geq p_{l_1})$ 的需求值在原函数的基础上做出 $\dot{D}_t(p_t)(p_{l_1} - p_t) + d_t - D_{t-1}(p_{l_1})$ 的调整, 如图 4 所示.

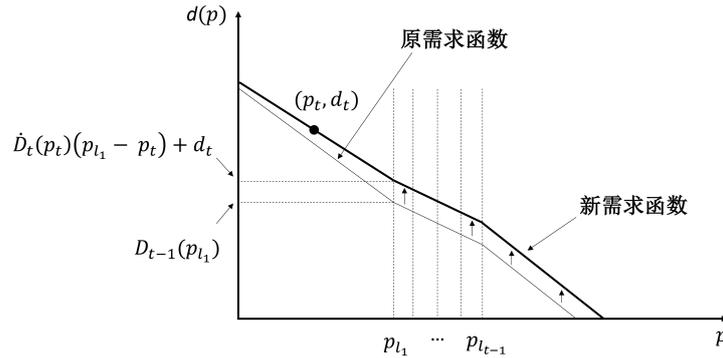


图 4 新价格小于历史价格时的需求函数更新

Fig. 4 Demand update when new price is less than all historical prices

(iii) 如果第 t 个样本点的价格位于历史样本价格之间, 假设有 $p_{l_1} \leq p_{l_2} \cdots \leq p_{l_c} < p_t \leq p_{l_{c+1}} \leq \cdots \leq p_{l_{t-1}}$, 其中 $1 \leq c \leq t - 2$, 那么更新后的需求函数为

$$D_t(p) = \begin{cases} D_{t-1}(p) + \dot{D}_t(p_t)(p_{l_c} - p_t) + d_t - D_{t-1}(p_{l_c}), & p < p_{l_c} \\ \dot{D}_t(p_t)(p - p_t) + d_t, & p_{l_c} \leq p < p_{l_{c+1}} \\ D_{t-1}(p) + \dot{D}_t(p_t)(p_{l_{c+1}} - p_t) + d_t - D_{t-1}(p_{l_{c+1}}), & p \geq p_{l_{c+1}}. \end{cases} \quad (6)$$

如果新价格位于历史价格区间内, 则价格 p_t 附近的区间为 $P_{c+1}^{t-1} = [p_{l_c}, p_{l_{c+1}})$. 在该区间, 基于信

息 (p_t, d_t) 及其导数 $\dot{D}_t(p_t)$, 需求函数更新为 $\dot{D}_t(p_t)(p - p_t) + d_t$. 在价格 $p = p_{l_c}$ 处, 新函数的需求值为 $\dot{D}_t(p_t)(p_{l_c} - p_t) + d_t$, 原函数的需求值为 $D_{t-1}(p_{l_c})$. 在价格区间 $p < p_{l_c}$, 新函数的需求值在原函数的基础之上做 $\dot{D}_t(p_t)(p_{l_c} - p_t) + d_t - D_{t-1}(p_{l_c})$ 的调整; 同样, 在价格 $p = p_{l_{c+1}}$ 处, 新函数的需求值为 $\dot{D}_t(p_t)(p_{l_{c+1}} - p_t) + d_t$, 原函数的需求值为 $D_{t-1}(p_{l_{c+1}})$. 在价格区间 $p \geq p_{l_{c+1}}$, 新函数的需求值在原函数的基础之上做 $\dot{D}_t(p_t)(p_{l_{c+1}} - p_t) + d_t - D_{t-1}(p_{l_{c+1}})$ 的调整, 如图 5.

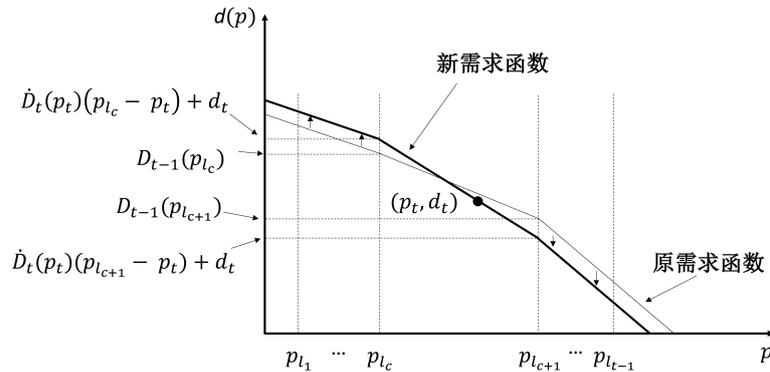


图 5 新价格位于历史价格区间时的需求函数更新

Fig. 5 Demand update when new price is in historical intervals

3) 需求函数再调整. 在第 2) 步, 需求函数依次更新直到最后一个需求信息 (p_T, d_T) 更新完成. 注意, 此时需求函数 $D_T(\cdot)$ 以最后的信息点 (p_T, d_T) 为基准. 然而, 在实际问题中, d_T 的观测值是随机的. 微小的波动会造成整条需求函数的巨大偏差. 因此, 需要对需求函数做进一步调整, 以使其反映平均意义上的需求信息. 基于所有样本, 假设平均定价为 \bar{p} , 平均需求为 \bar{d} . 在 $p = \bar{p}$ 处, 原需求函数得到的需求值为 $D_T(\bar{p})$. 将该值调整至平均需求 \bar{d} , 调整幅度为 $\bar{d} - D_T(\bar{p})$. 同时, 在其他价格区域内, 保持需求函数斜率不变, 进行相应的平移. 设调整后的需求函数为 $D(p)$, 有

$$D(p) = D_T(p) + \bar{d} - D_T(\bar{p}). \quad (7)$$

本文将此需求函数作为酒店的总体需求函数. 图 6 是根据门店 6 的样本数据所刻画的需求函数.

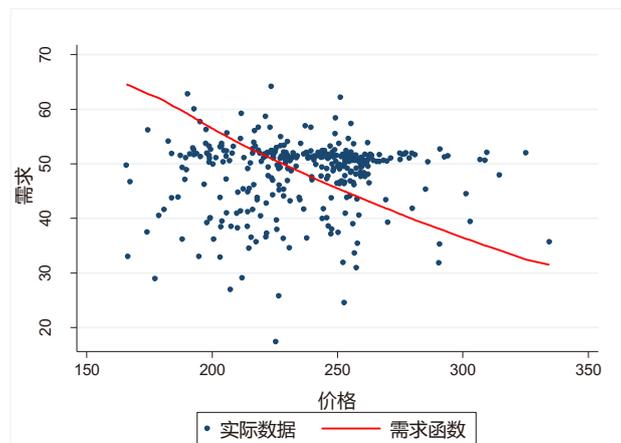


图 6 需求函数刻画

Fig. 6 Demand estimation by Local-slope

为验证“局部斜率更新”需求刻画方法的预测准确性, 本文实施以下仿真数据实验. 鉴于后续酒店实际数据分析中使用的动态定价策略借鉴于 Keskin 等^[11], 本文选择其使用的最小二乘法作为基准进行比较, 并用

拟合优度作为衡量指标. 假设估计所得的需求函数预测的需求值为 \hat{d}_t , 拟合优度的计算公式如下

$$R^2 = 1 - \frac{\sum_{t=1}^T (d_t - \hat{d}_t)^2}{\sum_{t=1}^T (d_t - \bar{d})^2}. \quad (8)$$

仿真数据实验分成两组: 线性函数实验组和非线性函数实验组. 两组实验中均使用式 (2) 所代表的主动学习定价策略 (注意, 当 $k = 0$ 时, 该策略是被动学习). 价格波动范围为 $(0, 140)$. 定价周期 T 为 400. 采用两种随机分布类型仿真模拟随机扰动项: 截尾正态分布(truncated normal distribution)和均匀分布. 服从正态分布 $N(0, \sigma)$ 的随机变量, 若其波动范围被限制在 $[a, b]$, 则该随机变量服从截尾正态分布, 其概率密度函数为

$$g(x) = \frac{\phi(\frac{x}{\sigma})}{\sigma(\Phi(\frac{b}{\sigma}) - \Phi(\frac{a}{\sigma}))}, \quad (9)$$

其中 $\phi(\cdot)$ 表示标准正态分布的概率密度函数, $\Phi(\cdot)$ 表示标准正态分布的累积概率密度函数.

在仿真数据实验中, 截尾正态分布的变动范围为 $[-30, 30]$, 以满足需求值的非负性. 用 $TN(0, \sigma^2)$ 表示该截尾正态分布. 用 $U(a, b)$ 表示波动范围为 $[a, b]$ 的均匀分布.

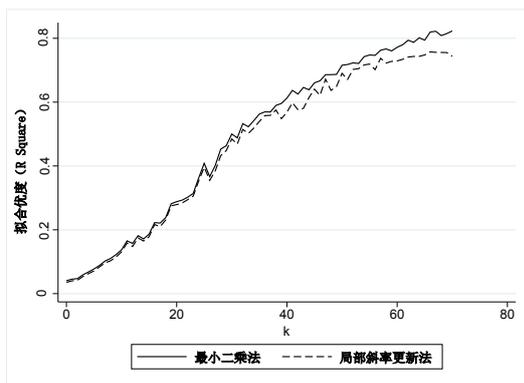


图 7 线性函数实验组拟合优度比较

Fig. 7 Comparison of R Squares in the group with linear demand

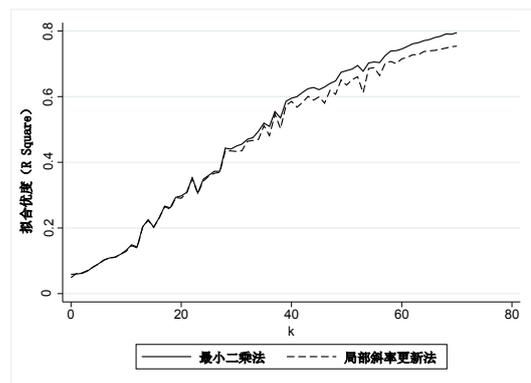


图 8 非线性函数实验组拟合优度比较

Fig. 8 Comparison of R Squares in the group with nonlinear demand

图 7 和图 8 分别展示不同实验组中两种方法的拟合优度关于 k 值的变化. 其中图 7 的需求函数为 $\tilde{D} = 200 - p + \varepsilon, 0 < p < 140$; 图 8 的需求函数为 $\tilde{D} = \frac{1}{300}(300 - p)^2 + \varepsilon, 0 < p < 140$. 两个需求函数中扰动项 ε 均服从截尾正态分布 $TN(0, 10^2)$. 本文总共比较四十组不同参数 (不同需求函数), 具体结果见表 3, 其中每一个单元格是对应方法的平均 (基于 k 值) 拟合优度.

可以发现, 无论是在线性函数假设下, 还是在非线性函数假设下, 虽然最小二乘法的拟合优度普遍高于“局部斜率更新”方法, 但是两种方法的拟合优度的差距并不大. 其中, 两种方法的拟合优度在线性函数下的平均差值为 0.042, 在非线性函数下的平均差值为 0.026. 相对而言, 在线性函数实验组, “局部斜率更新”方法的拟合优度较最小二乘法平均低 7.19%; 在非线性函数实验组, “局部斜率更新”方法的拟合优度较最小二乘法平均低 4.69%. 总体可见, “局部斜率更新”方法在预测准确性上稍弱于最小二乘法, 但其可以绕过价格内生性的问题. 现实中, 当真实数据存在价格内生性问题, 又无法找到有效的工具变量解决该问题时, 完全可以使用“局部斜率更新”需求刻画方法, 牺牲极小部分的估计准确性, 以规避价格内生性带来的影响, 提高数据驱动收益管理策略在实践中的适用性.

3.2 IL 策略与 CIL 策略

本文已阐述“局部斜率更新”方法的思路并验证其准确性. 将该需求刻画方法与定价方式结合起来, 本文提出两种新的定价策略: 基于“局部斜率更新”方法的短视 (被动学习) 动态定价策略, 称为 IL (iterated local-slope) 策略; 基于“局部斜率更新”方法的主动学习动态定价策略, 称为 CIL (constrained iterated local-slope) 策

略. 具体步骤如下

步骤1 第一期, 初始化定价 $p_1 \in P$, 观测到需求 d_1 , 通过“局部斜率更新”方法得到需求函数 $D_1(p)$;

步骤2 第 t 期, 基于需求函数 $D_{t-1}(p)$ 和式 (2), 制定当前阶段价格 p_t , 观测到需求 d_t ;

步骤3 将历史信息更新为 H_{t+1} , 通过“局部斜率更新”方法将需求函数更新为 $D_t(p)$; $t = t + 1$;

步骤4 如果 $t \leq T$, 跳至步骤2; 如果 $t > T$, 结束.

式 (2) 中, 若令 $k = 0$, 该定价策略为 IL 策略; 若 $k > 0$, 则为 CIL 策略.

表 3 拟合优度比较¹

Table 3 Comparison of goodness-of-fit

需求函数类型	需求函数	拟合方法	需求随机扰动项 ε			
			TN(0, 5 ²)	TN(0, 10 ²)	$U(-10, 10)$	$U(-20, 20)$
线性函数	$\tilde{D} = 200 - 0.8p + \varepsilon$	最小二乘法	0.647	0.488	0.642	0.339
		局部斜率更新	0.620	0.357	0.516	0.324
	$\tilde{D} = 200 - 0.9p + \varepsilon$	最小二乘法	0.685	0.433	0.648	0.400
		局部斜率更新	0.664	0.408	0.626	0.333
	$\tilde{D} = 200 - p + \varepsilon$	最小二乘法	0.762	0.488	0.737	0.438
		局部斜率更新	0.733	0.463	0.704	0.412
	$\tilde{D} = 200 - 1.1p + \varepsilon$	最小二乘法	0.757	0.533	0.716	0.462
		局部斜率更新	0.717	0.502	0.689	0.435
	$\tilde{D} = 200 - 1.2p + \varepsilon$	最小二乘法	0.732	0.559	0.709	0.492
		局部斜率更新	0.696	0.516	0.667	0.448
非线性函数	$\tilde{D} = \frac{1}{300}(300 - 0.8p)^2 + \varepsilon$	最小二乘法	0.672	0.450	0.646	0.353
		局部斜率更新	0.667	0.424	0.620	0.337
	$\tilde{D} = \frac{1}{300}(300 - 0.9p)^2 + \varepsilon$	最小二乘法	0.659	0.416	0.673	0.427
		局部斜率更新	0.633	0.406	0.647	0.405
	$\tilde{D} = \frac{1}{300}(300 - p)^2 + \varepsilon$	最小二乘法	0.689	0.471	0.630	0.384
		局部斜率更新	0.676	0.453	0.601	0.351
	$\tilde{D} = \frac{1}{300}(300 - 1.1p)^2 + \varepsilon$	最小二乘法	0.680	0.492	0.674	0.418
		局部斜率更新	0.640	0.452	0.634	0.401
	$\tilde{D} = \frac{1}{300}(300 - 1.2p)^2 + \varepsilon$	最小二乘法	0.721	0.518	0.660	0.410
		局部斜率更新	0.686	0.486	0.636	0.373

4 实际数据研究

本节重点通过实际数据研究, 对“局部斜率更新”方法所对应的动态定价策略的应用效果加以验证. 本文将以上 6 家新开门店 (表 1) 作为研究对象, 使用由其成立至 2015 年 6 月 27 日的实际数据进行针对 IL 和 CIL 策略的相关分析.

在实施实际数据研究之前, 需要对数据进行预处理, 主要包括两部分. 首先, 酒店的需求数据是右截断的: 入住数量最多只能等于总房量. 而实际需求有可能超过房量, 需要对被截断的需求数据进行还原. 其次, 酒店行业的需求有明显的季节性特征, 为得到需求与价格之间的关系, 需要先将季节性因子以及一些特殊因素从需求中剥离出去.

为了方便理解, 用 \mathbf{X}_t 表示包含所有影响需求变量的向量, 相应的变量系数向量为 $\boldsymbol{\rho}$, 那么需求函数可

¹表中 TN(0, σ^2) 表示波动范围为 $[-30, 30]$ 的截尾正态分布. 本文同时也比较了正态分布下的拟合优度, 虽然该分布不能保证需求值的非负性, 但也得到与截尾正态分布类似的结果.

表示为 $D_t = \varphi + \rho^T \mathbf{X}_t + \epsilon_t^2$. 其中 D_t 代表第 t 期的真实需求数据, ϵ_t 服从截尾正态分布 $TN(0, \omega^2)$. 假设酒店总房量为 C , 第 t 期实际入住数据为 S_t , 有 $S_t = \min\{C, D_t\}$. 需要依据 C 与 S_t 的取值还原 D_t 的取值. 截断数据的还原已有很成熟的方法, 其中最经典的是 Tobit 回归法 (Tobin^[20]). 本文采用该方法进行数据还原. 设数据研究中样本数据的时间范围为 N , 则观测到的样本数据为 $S = \{S_t, \mathbf{X}_t, t \in N\}$. Tobit 回归方法如下

若 $S_t = C$, 即实际入住数等于房量, 那么 $D_t \geq C$, 即实际需求不小于酒店房量, 有

$$\Pr(S_t = C) = \Pr(D_t \geq C) = \frac{\Phi\left(\frac{b}{\omega}\right) - \Phi\left(\frac{C - \varphi - \rho^T \mathbf{X}_t}{\omega}\right)}{\Phi\left(\frac{b}{\omega}\right) - \Phi\left(\frac{a}{\omega}\right)}. \quad (10)$$

若 $S_t < C$, 即实际入住数小于房量, 那么 $D_t = S_t$, 即实际需求等于实际入住数, 有

$$f(S_t) = \frac{\phi\left(\frac{S_t - \varphi - \rho^T \mathbf{X}_t}{\omega}\right)}{\omega \left(\Phi\left(\frac{b}{\omega}\right) - \Phi\left(\frac{a}{\omega}\right)\right)}. \quad (11)$$

基于所有样本可得似然函数

$$L(S, \varphi, \rho, \omega) = \prod_{S_t=C} \frac{\Phi\left(\frac{b}{\omega}\right) - \Phi\left(\frac{C - \varphi - \rho^T \mathbf{X}_t}{\omega}\right)}{\Phi\left(\frac{b}{\omega}\right) - \Phi\left(\frac{a}{\omega}\right)} \prod_{S_t < C} \frac{\phi\left(\frac{S_t - \varphi - \rho^T \mathbf{X}_t}{\omega}\right)}{\omega \left(\Phi\left(\frac{b}{\omega}\right) - \Phi\left(\frac{a}{\omega}\right)\right)}. \quad (12)$$

联立极大似然函数的一阶条件方程组, 求得各参数值, 从而得到需求公式 $\hat{D}_t = \varphi + \rho^T \mathbf{X}_t$. 对于需求被截断的数据点, 通过需求公式计算需求, 作为数据研究中的实际需求; 对于未被截断的数据点, 仍以原数据作为实际需求. 至此, 已经将样本数据还原成未截断状态下的数据. 设还原后的需求为 \hat{D}_t . 图 9 以门店 6 为例, 展示了截断数据还原前后的需求. 实线是被房量截断的实际需求, 虚线是还原后的需求.

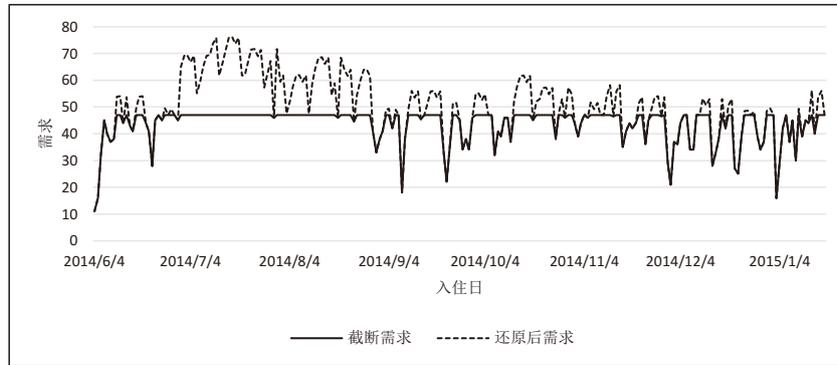


图 9 截断回归前后的需求数据

Fig. 9 Demand data before and after censored regression

通过与酒店门店经理的面谈和对数据的相关分析, 发现主要季节性因素包括星期, 旬度, 月度因素等, 而主要特殊因素有节假日, 会展等. 鉴于新开酒店有关节假日与会展的样本量较小, 直接将节假日与会展期间的数据去除, 然后基于剩余的样本数据完成星期, 旬度, 月度等因素的剥离工作.

设 $\bar{W}_i, i = 1, 2, \dots, 7, \bar{E}_j, j = 1, 2, 3, \bar{M}_k, k = 1, 2, \dots, 12$ 为样本数据中各星期, 旬度, 月度的平均需求, 如 \bar{W}_1 表示样本数据中入住日为星期一的平均需求, \bar{E}_1 表示样本数据中入住日为上旬的平均需求, \bar{M}_1 表示样本数据中入住日为一月份的平均需求. 令 \bar{D} 为总体平均需求, 各因子的计算公式如下

$$\text{星期因子: } \psi_i = \frac{\bar{W}_i}{\bar{D}};$$

$$\text{旬度因子: } \eta_j = \frac{\bar{E}_j}{\bar{D}};$$

²注意, 所选的变量都是与需求相关且统计分析显著的变量.

月度因子: $\xi_k = \frac{\bar{M}_k}{D}$.

最终剥离季节性因素的需求为

$$d_t = \frac{\hat{D}_t}{\sum_{i=1}^7 W_{ti} \psi_i \sum_{j=1}^3 E_{tj} \eta_j \sum_{k=1}^{12} M_{tk} \xi_k}, \quad (13)$$

其中 W_{ti}, E_{tj}, M_{tk} 均为 0-1 变量, 且满足 $\sum_{i=1}^7 W_{ti} = 1, \sum_{j=1}^3 E_{tj} = 1, \sum_{k=1}^{12} M_{tk} = 1$. 若入住日 t 处于一周中的第 i 天, 则 $W_{ti} = 1$, 否则 $W_{ti} = 0$; 若入住日 t 所处的旬度为 j , 则 $E_{tj} = 1$, 否则 $E_{tj} = 0$; 若入住日 t 所处的月份为 k , 则 $M_{tk} = 1$, 否则 $M_{tk} = 0$. $\sum_{i=1}^7 W_{ti} \psi_i$ 表示入住日 t 的星期因子值, $\sum_{j=1}^3 E_{tj} \eta_j$ 表示入住日 t 的旬度因子值, $\sum_{k=1}^{12} M_{tk} \xi_k$ 表示入住日 t 的月度因子值.

对原始需求数据进行截断数据还原与季节性因素剥离之后, 本文得到仅依赖于价格的需求数据. 图 10 以门店 6 为例, 展示了季节性因素剥离前后的需求: 虚线表示的是剥离季节性因素之前的需求, 实线表示的是剥离掉季节性因素之后的需求.

下面对 CIL 主动学习策略与 IL 短视策略进行验证分析. 本文以“后悔值”的大小作为评判标准, 分别从绝对后悔值 (与最优策略之间的差距) 和相对后悔值 (后悔值的相对大小) 两个角度进行分析.

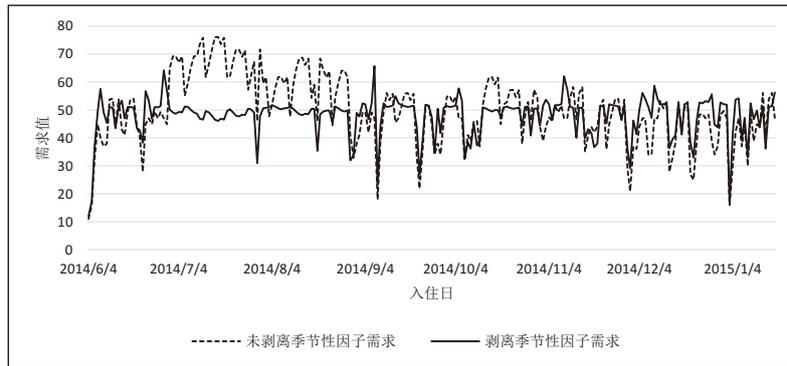


图 10 剥离季节性因素前后需求数据

Fig. 10 Demand data with and without peeling seasonality

通过局部斜率更新学习, 可以得到基于所有样本的需求函数 $D(p)$, 可将其视为真实的需求函数. 根据该需求函数以及总房量的限制, 最优定价为

$$\begin{aligned} p^* &= \arg \max_p [pD(p)] \\ \text{s.t. } & D(p) \leq C. \end{aligned} \quad (14)$$

设任意策略 π 的期望收益为 $R^\pi(T) = \sum_{t=1}^T p_t \min\{D(p_t), C\}$. 在最优策略下, 酒店的期望收益为 $R^*(T) = Tp^* \min\{D(p^*), C\}$. 策略 π 的后悔值为最优期望收益减去策略 π 下的期望总收益, 即 $\Delta^\pi(T) = R^*(T) - R^\pi(T)$. 后悔值越小, 表明策略 π 的期望收益更高, 离最优期望收益更近.

预处理后的数据反映的是酒店经理实际所做的决策, 用 $R(T)$ 表示其实际总体收益值, 那么实际决策下的后悔值为 $\Delta(T) = R^*(T) - R(T)$. 由于 6 家酒店的总体收益水平各不相同, 采用后悔值的相对值来进行分析, 即某策略 π 的后悔值与酒店实际决策后悔值的相对大小, 用 $\alpha^\pi(T)$ 表示, 有

$$\alpha^\pi(T) = \frac{\Delta^\pi(T)}{\Delta(T)} = \frac{R^*(T) - R^\pi(T)}{R^*(T) - R(T)}. \quad (15)$$

注意, $\alpha^\pi(T)$ 越小表明策略 π 的总体期望收益越接近于最优期望收益. 若 $\alpha^\pi(T) < 1$, 则策略 π 优于酒店实际决策; 若 $\alpha^\pi(T) > 1$, 则策略 π 比酒店实际决策差.

假设 IL 与 CIL 策略的后悔值分别为 $\Delta^{IL}(T)$ 与 $\Delta^{CIL}(T)$, 那么其相对后悔值分别为

$$\alpha^{IL}(T) = \frac{\Delta^{IL}(T)}{\Delta(T)}, \tag{16}$$

$$\alpha^{CIL}(T) = \frac{\Delta^{CIL}(T)}{\Delta(T)}. \tag{17}$$

4.1 数据验证分析

图 11 与图 12 展示的分别是门店 6 在两种策略下的收益和后悔值. IL 策略总体收益为 3 915 057 元; 当 $k = 47$ 时, CIL 策略的期望总收益达到最高, 为 3 957 447 元. 与酒店经理实际决策下 3 741 848 元的总体收益相比, IL 策略和 CIL 策略分别提升了 4.63% 和 5.76%. 在大约一年的周期里, IL 策略和 CIL 策略分别帮助酒店增加了 173 209 元和 215 599 元的总体收益. 在绝大多数情况下, CIL 策略下的总体收益水平高于酒店经理的实际决策. 可见, 无论是 IL 策略还是 CIL 策略, 经过需求学习的动态定价策略能够显著提升酒店的总体收益水平.

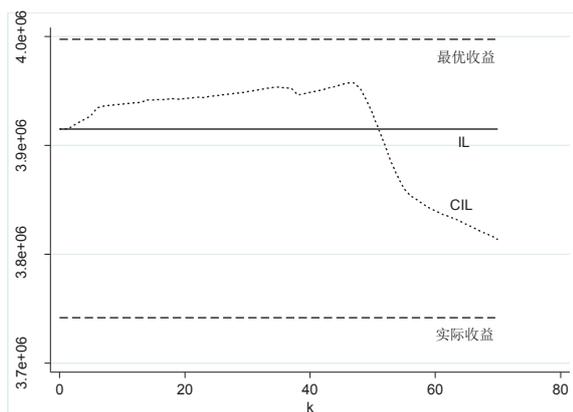


图 11 IL 策略与 CIL 策略的总体收益比较

Fig. 11 Revenue comparison between IL and CIL policies

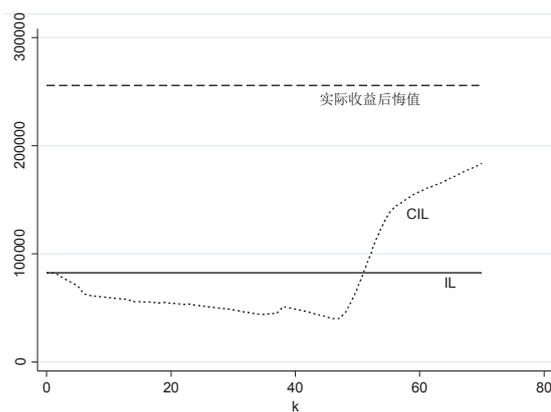


图 12 IL 策略与 CIL 策略的后悔值比较

Fig. 12 Comparison of regret values between IL and CIL policies

当学习参数 k 值不是很大时 ($k \leq 50$), CIL 策略要优于 IL 策略. 当 $k = 47$ 时, CIL 策略相比于 IL 策略增加了 42 390 元的额外收益. 此时, CIL 策略的后悔值为 40 092 元. 相比于 IL 策略 82 481 元的后悔值, CIL 策略降低了 51.39%. 可见, 给定合适的学习参数 k , 作为主动学习的 CIL 策略显著优于被动学习的 IL 策略.

值得注意的是, 当 k 值大于 50 时, CIL 策略在收益表现上落后于 IL 策略. 大量的主动学习牺牲了较多的获利空间. 在有限的定价周期内, 主动学习所获取的需求信息并没有被及时运用到最终获利, 影响总体收益. 因此, 在实际的收益管理中, 决策者应该选取合适的 k 值, 以权衡学习和获利.

通过对所有 6 家酒店进行实际数据研究, 本文发现 CIL 策略均优于 IL 策略. 表 4 列举了 6 家酒店在 IL 策略下和在 CIL 策略下的相对后悔值. 每家酒店在 CIL 策略下的相对后悔值均低于 IL 策略. IL 策略的平均相对后悔值为 0.400, 表明短视定价策略相对于酒店经理的实际决策能够降低 60% 的后悔值; 而 CIL 策略的相对后悔值均值为 0.224, 表明其相对于酒店经理的实际决策能够降低 77.59% 的后悔值.

表 5 展示的是各酒店的总体收益提升水平. IL 策略提升酒店收益百分比的均值为 1.6%. 其中最高的收益提升比率为 4.63%, 最低的提升比率为 0.01%. CIL 策略提升酒店收益百分比的均值为 1.87%. 其中最高收益提升比率为 5.76%, 最低提升比率为 0.1%. CIL 策略的总体收益提升显著优于 IL 策略.

表 4 IL 策略和 CIL 策略的相对后悔值

Table 4 Relative regret values of IL and CIL policies

酒店	IL 策略相对后悔值	CIL 策略相对后悔值
1	0.424	0.416
2	0.106	0.027
3	0.433	0.105
4	0.938	0.574
5	0.178	0.066
6	0.323	0.157
均值	0.400	0.224

表 5 IL 策略和 CIL 策略的收益提升

Table 5 Revenue improvements by IL and CIL policies

酒店	IL 策略	CIL 策略
1	2.35%	2.38%
2	2.04%	2.21%
3	0.26%	0.41%
4	0.01%	0.10%
5	0.34%	0.38%
6	4.63%	5.76%
均值	1.60%	1.87%

5 结束语

本文利用某连锁酒店管理集团的实际数据探讨对于未知需求的数据驱动收益管理策略的实践应用. 本文提出一种新的非参数需求函数刻画方法, 能够有效规避真实数据中存在的价格内生性问题. 仿真数据实验表明, 在拟合优度的表现上, “局部斜率更新”方法非常接近最小二乘法. 同时, 本文结合“局部斜率更新”方法提出数据驱动动态定价策略: IL 策略和 CIL 策略. 通过 6 家门店的实际数据验证表明: 无论是 IL 策略还是 CIL 策略, 均能帮助酒店提升总体收益水平. 同时, 作为主动学习的 CIL 策略在总体上优于作为被动学习的 IL 策略. 本研究在数据驱动动态定价策略理论和实际应用之间建立桥梁, 有效地将理论方法运用到实际酒店运营中. 同时, 该方法也可应用于民用航空, 新产品定价等相关领域.

参考文献:

- [1] 毕文杰, 孙颖慧, 田柳青. 参考价格符合峰终定律的多产品动态定价模型. 系统工程学报, 2015, 30(4): 476–484.
Bi W J, Sun Y H, Tian L Q. Multi-product dynamic pricing model with reference price submitting to peak-end rule. Journal of Systems Engineering, 2015, 30(4): 476–484. (in Chinese)
- [2] 毕功兵, 王怡璇, 丁晶晶. 存在替代品情况下考虑消费者策略行为的动态定价. 系统工程学报, 2013, 28(1): 47–54.
Bi G B, Wang Y X, Ding J J. Dynamic pricing based on substitutes and strategic consumers. Journal of Systems Engineering, 2013, 28(1): 47–54. (in Chinese)
- [3] Gallego G, Ryzin G V. Optimal dynamic pricing of inventories with stochastic demand over finite horizons. Management Science, 1994, 40(8): 999–1020.
- [4] Feng Y, Gallego G. Optimal starting times for end-of-season and optimal stopping times for promotional fares. Management Science, 1995, 41(8): 1371–1391.
- [5] Bitran G R, Mondschein S V. Periodic pricing of seasonal products in retailing. Management Science, 1997, 43(1): 64–79.
- [6] Zhao W, Zheng Y. Optimal dynamic pricing for perishable assets with nonhomogeneous demand. Management Science, 2000, 46(3): 375–388.
- [7] Ball M O, Queyranne M. Toward robust revenue management: Competitive analysis of online booking. Operations Research, 2009, 57(4): 950–963.
- [8] Lan Y, Gao H, Ball M O, Karaesmen I. Revenue management with limited demand information. Management Science, 2008, 54(9): 1594–1609.
- [9] Arman V F, Caldentey R. Dynamic pricing for nonperishable products with demand learning. Operations Research, 2009, 57(5): 1169–1188.
- [10] Harrison J M, Keskin N B, Zeevi A. Bayesian dynamic pricing policies: Learning and earning under a binary prior distribution. Management Science, 2012, 58(3): 570–586.
- [11] Keskin N B, Zeevi A. Dynamic pricing with an unknown demand model: Asymptotically optimal semi-myopic policies. Operations Research, 2014, 62(5): 1142–1167.

- [12] Besbes O, Zeevi A. Dynamic pricing without knowing the demand function: Risk bounds and near-optimal algorithms. *Operations Research*, 2009, 57(6): 1407–1420.
- [13] Broder J, Rusmevichientong P. Dynamic pricing under a general parametric choice model. *Operations Research*, 2012, 60(4): 965–980.
- [14] Boer A V D, Zwart B. Simultaneously learning and optimizing using controlled variance pricing. *Management Science*, 2014, 60(3): 770–783.
- [15] Wang Z, Deng S, Ye Y. Close the gaps: A learning-while-doing algorithm for single-product revenue management problems. *Operations Research*, 2014, 62(2): 318–331.
- [16] Hausman J A. *Valuation of New Goods Under Perfect and Imperfect Competition*. Chicago: University of Chicago Press, 1996: 207–248.
- [17] Hormby S, Morrisom J, Deve P, et al. Marriott International increases revenue by implementing a group pricing optimizer. *Interfaces*, 2010, 40(1): 47–57.
- [18] Koushik D, Higbie J A, Eister C. Retail price optimization at InterContinental Hotels Group. *Interfaces*, 2012, 42(1): 45–57.
- [19] Eichenbaum M, Jaimovich N, Rebelo S. Reference prices, costs, and nominal rigidities. *American Economic Review*, 2011, 101(1): 234–262.
- [20] Tobin J. Estimation of relationships for limited dependent variables. *Econometrica*, 1956, 26(1): 24–36.
- [21] Aviv Y, Pazgal A. A partially observed Markov decision process for dynamic pricing. *Management Science*, 2005, 51(9): 1400–1416.
- [22] Farias V F, Roy B V. Dynamic pricing with a prior on market response. *Operations Research*, 2010, 58(1): 16–29.
- [23] Lin K Y. Dynamic pricing with real-time demand learning. *European Journal of Operational Research*, 2006, 174(1): 522–538.
- [24] Carvalho A X, Puterman M L. Learning and pricing in an internet environment with binomial demands. *Journal of Revenue & Pricing Managemnt*, 2005, 3(4): 320–336.
- [25] Lai T L, Robbins H. Iterated least squares in multiperiod control. *Advances in Applied Mathematics*, 1982, 3(1): 50–73.
- [26] Besbes O, Zeevi A. On the (surprising) sufficiency of linear models for dynamic pricing with demand learning. *Management Science*, 2015, 61(4): 723–739.

作者简介:

陈 吉 (1989—), 男, 浙江慈溪人, 博士生, 研究方向: 收益管理, Email: chenji14@fudan.edu.cn;

田 林 (1987—), 男, 湖北洪湖人, 博士, 副教授, 研究方向: 运营管理, Email: tianlin@fudan.edu.cn;

徐以汎 (1957—), 男, 山东济南人, 博士, 教授, 研究方向: 收益管理, Email: yfxu@fudan.edu.cn.