

基于在线大数据的中国商品价格粘性研究*

姜婷凤 汤珂 刘涛雄

内容提要: 近年来, 数字经济迅速发展, 同时宏观经济的短期波动变得愈加频繁, 理解宏观经济短期分析的基础——价格粘性、减少宏观政策时滞变得愈加重要。本文利用来自 100 多个网站的高频价格大数据(囊括 CPI 篮子的 8 大类、46 中类、262 子类的 1970 多万条日度商品价格), 测度中国商品价格粘性程度、识别价格调整模式, 并将微观测度结果用于测算货币政策有效性。研究发现: 中国总体上调价较为频繁(调价周期小于 2 个月)、调价幅度较大(14%—20%)、部门异质性明显、不对称性显著(上调频率及上调幅度更大); 调价模式是异质性的时间相依(TDP)和状态相依(SDP)相结合; 调价频率(负向)、调价大小的峰度(正向)、异质性部门数量(正向)等均会影响货币非中性程度。相同的货币冲击对各行业的影响有显著的异质性。本文为洞察数字经济对商家调价行为和宏观经济动态的影响抛砖引玉, 对大数据时代的货币政策制定和通货膨胀管理具备一定的参考意义。

关键词: 在线大数据 价格粘性 调价模式 货币非中性程度 数字经济时代

一、引言

近年来, 数字经济和大数据技术迅速发展, 正在对经济社会各方面产生深远影响。习近平总书记在给 2019 中国国际数字经济博览会的贺信中指出“中国高度重视发展数字经济, 正在积极引导数字经济和实体经济深度融合”。^①与此同时, 国内外宏观经济金融的短期波动变得更加频繁, 其中新冠肺炎疫情(COVID-19 Epidemic)对全球经济产生较大冲击是一个典型代表, 理解宏观经济的微观基础、减少宏观政策时滞、创新和加强宏观调控变得愈加重要。价格粘性(price stickiness)是凯恩斯主义的宏观经济短期分析的基础, 是货币政策短期有效的关键假设。那么数字经济和信息技术的快速发展会影响商品价格调整行为吗? 微观数据缺乏一直是制约中国价格粘性研究深入的重要因素, 那么随着大数据时代的到来, 能否为该重要问题找到新的解决方法?

与价格粘性紧密相连的是调价模式, 这二者如同一体的两面, 公司的调价模式会直接影响其调价规律及对外部冲击的反应, 进而影响其价格粘性。公司有两种基本的调价模式, 一种是时间相依调价模型(time-dependent pricing, 简称 TDP; 例如 Calvo, 1983; Carvalho, 2006), 即公司在固定时间调整价格, 而价格变化频率是外生的。另一种是状态相依调价模型(state-dependent pricing, 简称 SDP; 例如 Golosov & Lucas, 2007; Nakamura & Steinsson, 2010), 即一家公司权衡调价的收益和成本, 以决定是否调价。至于调价成本, 包括菜单成本(Sheshinski & Weiss, 1977)、观察成本(Alvarez et al., 2011)等。那么在数字经济崛起的背景下, 商家调价模式是否会发生改变呢? 传统的调价模

* 姜婷凤, 对外经济贸易大学金融学院, 邮政编码: 100029, 电子信箱: jiangtf@uibe.edu.cn; 汤珂(通讯作者), 刘涛雄, 清华大学社会科学学院经济学研究所、清华大学创新发展研究院, 邮政编码: 100084, 电子信箱: ketang@tsinghua.edu.cn, liutx@mail.tsinghua.edu.cn。本研究得到国家自然科学基金面上项目(71973075)、国家社科基金重大项目(16ZDA008)、对外经济贸易大学中央高校基本科研业务费专项资金(19QD08)的资助。作者感谢 UC Berkeley 的 Brian Wright 教授及 Yuiry Gorodnichenko 教授、中国人民大学统计与大数据研究院艾春荣教授、清华大学社科学院孙震助理教授对本文提出的宝贵意见和建议, 感谢 iCPI 项目组其他成员的支持。作者衷心感谢两位匿名审稿专家提出的极具建设性的建议, 当然文责自负。

^① 参见《习近平向 2019 中国国际数字经济博览会致贺信》, 新华网, http://www.xinhuanet.com/politics/leaders/2019-10/11/c_1125091565.htm, 2019-10-11。

型是否能解释现有的经验证据呢?

价格粘性是通胀动态形成机制的微观基础(根据新凯恩斯菲利普斯曲线推导,例如陈彦斌,2008;Gali 2015),而调价模式会影响货币政策传导机制分析框架(Alvarez et al. 2016)。通胀动态的本质和货币政策的有效性,在很大程度上取决于价格粘性和调价模式的特点。如果能借助大数据进行价格粘性研究,这对当下的宏观经济与政策分析有什么启示呢?可以预见的是,如果经济学家们能不受微观数据制约、清晰地看到调价行为,相当于拥有“宏观经济的显微镜”,那么他们对宏观通胀动态和货币政策实际作用的认识无疑会更加深入而全面。

相比于价格粘性的理论研究,受制于样本因素,微观经验研究则相对缓慢。早期主要是分析特定类别的商品调价,但是商品数量很少,例如Kashyap(1995)研究了12种目录商品(半年一次)在35年间的价格变化,发现调价周期在1年以上。Bils & Klenow(2004)则开创了采用国家(美国)统计局数据测度价格粘性的先河,有效地提高了商品数量(350种)和采价频率(月度),发现超过一半商品的调价周期低于4.3个月。Sheremirov(2019)采用美国超市扫描价格数据(周度),再次扩大数据源并提高了数据频率,发现促销对于解释正常价格波动有重要作用。电子商务的发展则进一步增加新的价格来源并提高了分析频率,例如,Cavallo(2017)通过对比10个国家56家零售商的线上线下价格差异,发现二者约72%的时间相同,线上价格有较好的代表性。总之,价格粘性的微观研究样本经历了一个由极少量商品到统计局采价商品、再到超市扫描价格、最后到网络价格数据的发展过程,研究频率则相应地由半年、到月度、再到周、最后到日。然而,不断丰富的数据也为价格粘性研究带来了新的问题,微观数据中的促销、部门异质性和较大的特殊价格波动等因素对实证研究结果均会产生较大的影响,这些问题现在并没有统一结论。

在中国,或受限于微观数据的可获得性,基于微观数据的价格粘性研究还较为有限,代表性研究有:渠慎宁等(2012)采用国家发改委价格监测中心的116种商品和服务价格数据,发现总体上居民消费价格和状态相关、服务价格粘性程度更强;金雪军等(2013)采用一淘网数据,发现调价周期中值为3.4个月、调价模式符合状态相依模型。有的学者则结合宏观经济指标间接测算价格粘性,代表性研究有:蔡晓陈(2012)结合季度GDP平减指数间接估计价格粘性程度,发现调价周期为3.4—8.1个月;侯成琪和龚六堂(2014)在多部门新凯恩斯模型基础上,利用宏观经济数据估计出CPI八大类的价格粘性程度(例如食品的季度价格粘性指数为26.98%),发现货币政策冲击对价格粘性较强的部门的通胀影响更小、产出影响更大。这些研究为理解中国价格粘性做出了诸多有益的探索,为后续研究提供了良好的参考与借鉴。但是现有的国内外研究对于商品价格粘性及调价模式的结论并非一致,仍然存在一定的争议。

据此,本研究采用在线价格大数据,从静态视角测度中国商品价格粘性程度,从动态视角识别价格调整模式,并将经验测度结果用于分析货币政策有效性,挖掘其在实时高频物价指标设计和通货膨胀实时预测等方面的应用价值,具有重要的理论意义和现实意义。

本文的创新和贡献主要有:(1)在研究数据方面,本文采用独特的高频微观价格大数据,即覆盖统计局整个CPI篮子的商品和服务日度数据,包括8大类、46中类、262子类,且来自100多个线上平台,研究结果具有较好的代表性;(2)在研究方法(视角)方面,本文采用多种方法测度中国的商品价格粘性,首次将生存分析运用到中国调价模式识别上,并将微观测度结果用于分析货币政策有效性,有效地打通了中国价格粘性的微观测度和宏观应用的联系;(3)在研究发现方面,本文发现中国线上价格粘性较弱、调价幅度较大、不对称性显著、部门异质性明显;调价模式是异质性的状态相依和时间相依相结合,两种调价方式都很重要;相同的货币冲击对各细分行业的影响有显著的异质性,考虑的异质性部门越多,越能更好地解释经济波动;(4)在研究价值方面,本文的价格粘性测度结果为我国构建更具微观基础的宏观模型提供了新的经验证据,为分析货币政策对行业层面的影响提供有效依据;特别地,此次新冠肺炎

炎疫情再次凸显了数字经济和线上价格研究的重要性。本文为洞察数字经济对商家调价行为和宏观动态的影响抛砖引玉,对数字经济时代的货币政策制定和通货膨胀管理具备一定的参考意义。

本文的其余部分组织结构为:第二部分是数据、变量与指标;第三部分是静态的价格粘性测度结果;第四部分是动态的价格调整模式识别;第五部分结合价格粘性测度结果分析货币政策非中性程度;第六部分是结论与启示。

二、数据、变量与指标

(一) 数据来源

本文采用的数据来自于清华大学 iCPI 项目组。^① 项目组通过网页爬虫(web scrapping) 技术,实时采集了 100 多个线上平台的价格数据,覆盖了整个居民消费的篮子,囊括官方 CPI 中的 8 大类、46 中类和 262 子类的物价。因而,本研究的价格信息种类多、来源广,有充分的代表性。

此外,与线下价格数据相比,线上价格在价格粘性研究方面还有一些优势。第一,价格数据是日度的,不存在时间平均问题,可以灵活捕捉各种价格变动。^② 第二,价格数据来自多个平台,不受单个平台影响,而且这多个平台不是通过比价网获取,而是分别独立抓取各个网站的数据。^③

(二) 数据预处理

由于数据是从网上抓取,会存在一定的噪音,所以先对数据进行预处理很重要,否则会影响后面研究的可靠性。本文预处理方法参考有关文献,并结合了中国互联网价格的特点,具体如下:

1. 缺失值处理。本研究采用的数据集是高频的日价格,可能由于一些偶然因素(如网络问题)导致某天价格缺失,需要对缺失值进行补充。本文缺失时间窗口选为 1 个月。^④ 具体处理方法为:如果商品第 t 日价格缺失,用第 $t-1$ 日的价格补充,一直到商品出现价格,如果价格连续缺失超过 30 天(如第 $t+31$ 日还没有价格),则不再补充缺失值,而将该商品视为下架。考虑到样本量较大,而且是日数据,该缺失值处理方法不会对价格粘性测度结果产生实质性影响。

2. 异常值处理。对于易于波动的网络价格,更需要注意异常值,设定阈值是文献中常用的方法。本文在主体分析中,将日价格上调幅度大于 100% 或下调幅度大于 50% 的调价,作为异常值处理。^⑤ 因为日价格波动容易受到一些事件干扰,阈值设定不会对结果产生实质性影响。

3. 区分常规调价和打折调价。对于在线价格变化,区分常规调价与打折调价很重要,因为二者包含的价格调整信息不同(Nakamura & Steinsson, 2010)。常用的区分打折的方法是“V 型”判断法,即如果价格下降后持续一段时间,然后又回到原价,那么这种情况视为商家促销行为的调价。不同学者选取了不同的持续时间窗口(打折窗口),这也与数据频率有关,对于低频数据,打折窗口往往较长,对于高频数据,打折窗口相对较短。^⑥ 考虑到中国很多节假日都是以周为单位或在一周内,如春节黄金周、国庆黄金周、五一黄金周、“11.11”购物狂欢节等,很多在线商家以此为契机,推

^① 清华大学 iCPI 项目组成立于 2015 年 9 月, iCPI 具体指数实时发布于网站 www.bdecon.com,并于 2017 年 6 月在国际著名金融信息服务商 Bloomberg 上线,2019 年 8 月在国内重要金融信息服务商 Wind 上线。

^② Cavallo(2018)指出利用统计局收集的 CPI 数据或者超市的扫描数据测度价格粘性,会存在时间平均的问题,因为 CPI 数据一般是月度数据,超市扫描数据是周数据,它们会平滑价格波动,影响价格粘性测度。

^③ Ellison & Ellison(2009)表明使用比价网的数据会增加调价频率并减小变化幅度,因为比价网上的零售商面临的竞争环境更为激烈。

^④ 本文借鉴文献中常用的方法,对缺失值进行补充,但是在具体处理细节上有差异,国外有的学者补充 5—6 个月(Nakamura & Steinsson, 2008; Cavallo, 2018)。考虑到本文所用数据集为 3 年左右,中国电商商品更换较为频繁,本文补充 1 个月。

^⑤ Cavallo(2018)在利用大型零售商的线上数据测度价格粘性时,把价格上调幅度大于 200% 或下调幅度大于 70% 的调价,按照异常值处理,不纳入价格粘性测度。本文借鉴该处理方法,并结合中国互联网价格波动的特点,选取合适的阈值。

^⑥ 例如, Nakamura & Steinsson(2008)和 Kehoe & Midrigan(2015)均采用月度数据,打折窗口都选为 1 个月; Gorodnichenko et al.(2018)运用日度数据,打折窗口选为 7 天和 14 天两种。

出有关的打折促销活动,而且本文样本是高频的日度数据,本文打折时间窗口选为7天。

(三) 数据描述

本文的所有数据处理和模型回归均采用R软件。数据的描述性统计具体如表1所示。样本期间从2016年1月1日到2019年2月12日,共计1138天。总样本数为19726466,来自107个平台,进行调价的记录有1470636条,占比7.46%;通过“V型”判断法,发现打折调价的记录有901087条,占比4.57%;不考虑打折的常规调价记录有569549,占总观测值的2.89%。价格变化幅度从-50%到100%不等的观测值为19593315(包括价格变化大小等于零),占观测总数的99.33%。本文主体分析采用这一范围的样本,即异常值剔除比例为0.67%,且价格粘性测度时仅考虑“常规调价”。此外,不同类别的观测值不同,详尽的大类、中类和子类数据为分析部门价格粘性异质性提供了良好的数据基础。

(四) 价格粘性衡量指标

常用的价格粘性衡量指标包括价格变化频率(frequency of price changes)、价格变化周期(duration of price changes)、价格变化幅度(size of price changes)等,下面具体介绍测算方式。

1. 价格变化频率^①

根据国内外相关研究,有三种常用的价格调整频率估算方法:一是通过设定关于价格调整频率的二次方程,计算出其非负单位根(Bils & Klenow 2004; Nakamura & Steinsson 2008)。二是通过假设每期价格调整次数服从泊松分布、采用极大似然估计法(MLE)测算价格变化频率(如Klenow & Krystov 2008; 渠慎宁等 2012)。三是通过算出相同商品的样本观测值中的价格变化次数占比,并结合算术平均或者中位数等方法算出各类别的调价频率(Gopinath & Rigobon 2008)。其中,第一、第二种方法在月度数据中应用较多,一个月可能有多个观测值,例如,Nakamura & Steinsson(2008)和Klenow & Krystov(2008)都采用了美国劳工局的月度数据。第三种方法在高频的大样本中使用较多,如Cavallo(2017)、Cavallo(2018)、Gorodnichenko et al.(2018)、^②金雪军等(2013)。考虑到本文采用高频大数据,每天对应一个观测值,本文借鉴第三种方法估算。计算主要分为五步,具体步骤如下:

第一步,算出商品价格变化(上调/下调)频率。计算属于*d*大类(division)、*g*中类(group)、*c*子类(class)下的*i*商品(url)的总有效观测值中的价格变化(上调/下调)频次,得到商品价格变化(上调/下调)频率,即:

$$pcf_{dgc} = \frac{npc_{dgc}}{obs_{dgc}} \quad (1)$$

其中, *npc* 是价格变化(上调/下调)数量, *obs* 是观测值数量, *pcf* 是价格变化(上调/下调)频率。

第二步,计算子类的价格变化(上调/下调)频率,由商品的变化频率到子类层面的变化频率,根据统计局CPI编制方法,^③因为每种商品在子类中的权重难以确定,在这一层面没有权重,统一采用算术平均法,算出*d*大类、*g*中类下的*c*子类价格变化(上调/下调)频率,即:

$$pcf_{dgc} = \text{mean}(pcf_{dgc}) \quad (2)$$

第三步,计算中类的价格变化(上调/下调)频率,由子类到中类的变化频率,可以采用算术平均法、中位数法、加权平均法,分别算出相应中类价格变化(上调/下调)频率,即:

^① “价格变化频率”有两种定义方式,一是指样本在单位时间内的调价次数,二是指样本所有观测值中的价格发生变化的百分比。在高频的日度数据中,“单位时间”是指每天,由于相同样本每天观测值只有1个,每天调价次数不会超过1次,这两种定义方式是相类似的。当单位时间内的观测值数量大于1(即1单位时间和1个观测值不是一一对应的),单位时间内调价次数可能大于1时,两种定义有所不同,估算时应该注意差异。

^② Gorodnichenko et al.(2018)指出,这几种估算方法类似,并采用了第三种方法估算美国和英国的线上日度调价频率。

^③ 国家统计局城市司《走进CPI——CPI的个体指数是如何计算的?》,http://www.stats.gov.cn/zjtc/tjzs/zjcpi/201106/120110610_71493.html。

$$pcfme_{dg} = \text{mean}(pcf_{dgc}) \quad pcfmd_{dg} = \text{median}(pcf_{dgc}) \quad pcfwm_{dg} = \sum w_{dgc} * pcf_{dgc} \quad (3)$$

第四步, 计算大类的价格变化(上调/下调)频率, 由中类到大类的变化频率, 可以采用算术平均法、中位数法、加权平均法, 分别算出相应大类下价格变化(上调/下调)频率, 即:

$$pcfme_d = \text{mean}(pcfme_{dg}) \quad pcfmd_d = \text{median}(pcfmd_{dg}) \quad pcfwm_d = \sum w_{dg} * pcfwm_{dg} \quad (4)$$

最后, 计算总体的价格变化(上调/下调)频率, 由大类到总体的变化频率, 可采用算术平均法、中位数法、加权平均法, 分别算出属于总体价格变化(上调/下调)频率, 即:

$$pcfme_w = \text{mean}(pcfme_d) \quad pcfmd_w = \text{median}(pcfmd_d) \quad pcfwm_w = \sum w_d * pcfwm_d \quad (5)$$

2. 价格变化周期

价格变化周期是指所有产品都进行一轮价格调整所花费的平均时间, 是一种更直观的度量价格粘性程度的指标。本文将调价周期记为 pcd , 调价频率记为 pcf , 二者转化公式为:

$$pcd = \frac{-1}{\ln(1 - pcf)} \quad (6)$$

3. 价格变化幅度及分布

关于价格变化幅度, 估计方法与价格变化频率的估计方法相似。对于在第 t 期价格变化的商品(没有进行调价的不考虑在内), 价格变化大小计算如下:

$$pcsize_{dgcit} = \frac{P_{dgcit} - P_{dgcit-1}}{P_{dgcit-1}} * 100\% \quad (7)$$

价格变化幅度(绝对值)计算如下:

$$abspsize_{dgcit} = \left| \frac{P_{dgcit} - P_{dgcit-1}}{P_{dgcit-1}} \right| * 100\% \quad (8)$$

表 1 价格粘性测度的基本数据概况

指标	总体	食品 烟酒	衣着	居住	生活用品 及服务	交通和 通信	教育文化 和娱乐	医疗 保健	其他用品 和服务
样本量(Obs)	19726466	5284476	3178874	1164811	3761094	1196941	3145579	1210504	784187
中类	46	19	4	4	6	2	4	5	2
子类	262	63	39	14	36	30	41	23	16
价格变化幅度为[-50%, 100%]的样本量	19593315	5264553	3143564	1158985	3733545	1189048	3134073	1191614	777933
价格变化幅度为[-50%, 100%]样本比(%)	99.33	99.6	98.9	99.5	99.3	99.3	99.6	98.4	99.2
商品量(URLs)	48832	12785	9580	3095	8725	3231	6436	2926	2054

数据来源: 清华大学 iCPI 项目组(<http://www.bdecon.com/>)。

三、价格粘性测度: 静态视角

这部分结合在线价格大数据测度中国商品价格粘性, 分别得到子类、中类、大类和总体的价格粘性指标, 具体见表 2。^①

第一, 从总体上看, 中国线上价格粘性相对较弱, 价格上调频率高于价格下调频率。通过中位

^① 由于篇幅原因, 中类和子类的价格粘性测算结果图表没有放入文中。如有读者感兴趣, 可向作者索要完整版本, 或可参见 iCPI 官网的工作论文栏目 <http://www.bdecon.com/workIndex>。

数法、算术平均法、加权平均法^①得到整个篮子的价格调整周期分别为44天、25天和47天,均小于2个月。特别地,平均价格变动频率3.99%远高于中位数价格变化频率2.24%,后者更接近加权平均变化频率2.33%,表明价格变化频率分布呈现出明显的正偏态。进一步与现有研究结果对比,本文的发现与 Gorodnichenko et al. (2018) 发现的“美国为4.7—13.9周、英国为4.5—14.5周”有相似之处,和 Cavallo (2018) 发现的“巴西为1.48个月”较为接近,但是低于大部分研究发现,例如 Klenow & Kryvtsov (2008) 的4—7个月(美国)、金雪军等(2013)的2.7—3.4个月(中国)。这综合表明中国线上调价周期相对较短,调价较为频繁。

此外,通过中位数法、算术平均法、加权平均法得到的价格上调频率分别为1.31%、2.27%、1.12%,价格下调频率分别为0.99%、1.72%、0.96%,前者高出后者17%—32%,说明总体上价格上调频率高于价格下调频率。这一发现与 Nakamura & Steinsson (2008) 发现线下CPI篮子中“64.8%的价格变化是上调”有相似之处,表明在常规调价中,在线商家仍倾向于把价格上调,线上调价频率有明显的不对称性,这和线下较为相似。

第二,从总体上看,中国线上的调价幅度相对较大,价格上调幅度显著高于下调幅度。从整个篮子来看,通过中位数法、算术平均法、加权平均法得到的价格调整幅度,分别为19.49%、20.07%、13.53%,算术平均略高于中位数,两者均显著高于加权平均,三种方法均高于之前的一些研究结果。例如, Klenow & Kryvtsov (2008) 发现基于美国劳工局数据的平均调价幅度为10%, Gorodnichenko et al. (2018) 发现美国在线调价幅度中位数是11%。

值得注意的是,对于整个篮子,采用三种估算方法的价格上调幅度明显高于价格下调幅度,调价幅度也有显著的不对称性。通过中位数法、算术平均法、加权平均法得到的价格上调幅度分别为20.94%、22.96%、15.44%,价格下调幅度分别为17.18%、17.16%、11.21%,前者高出后者21%—38%。综合结果表明,在线上常规调价中,无论是调价频率还是调价幅度,均有明显的不对称性,商家倾向于将价格上调更大的幅度,且上调频率大于下调频率,二者综合导致整体的价格变化大小为正(约3%—6%)。

第三,从大类来看,基于不同估算方法得到的各大类调价频率、调价幅度均存在较大差异,但是上调频率均一致地高于对应的下调频率,上调幅度基本上明显地高于下调幅度。例如,基于加权平均算法,八大类的价格调整周期为25—485天,其中“生活用品及服务”大类价格粘性最弱,而“居住”大类粘性最强;价格调整幅度为4.25%—26.22%,价格调整大小为-0.13%—7.23%,其中“衣着”调价幅度最大,“医疗保健”调价大小最大。虽然不同算法、不同大类的调价频率或调价幅度数值存在较大的差异,但是三种算法、八大类的上调频率均高于相应的下调频率,上调幅度绝大部分情况都大于下调幅度。

第四,从中类和子类来看,不同行业商家的调价频率和调价幅度存在较为明显的异质性,但调价频率和调价幅度的不对称性仍较为明显。以加权平均法为例,中类调价频率范围、调价幅度范围、价格变动大小范围分别为0.04%—6.72%、0.13%—27.50%、-4.22%—8.50%,表明不同中类价格粘性存在一定的异质性;而且中类的上调频率普遍地大于下调频率,上调幅度仍大于下调幅度。此外,子类价格变动频率范围为0%—94.42%、价格变化幅度范围为2.81%—67.10%,说明子类调价频率差异较大,异质性十分明显。特别地,89.21%的子类上调频率大于下调频率,96.27%的子类调价大小为正,仅有2.49%调价大小为负(还有1.24%调价大小为0)。这综合表明,各子类的价格粘性既存在显著的异质性,又有一定的规律,即调价中上调占比较高,导致正负影响抵消后的价格调整大小仍为正,最终推动价格普遍上涨。

^① 权重数据来自于清华大学 iCPI 项目组,可参考刘涛雄等(2019)。

表 2 总体及大类的价格粘性指标^①

算法	指标	总体	食品烟酒	衣着	居住	生活用品及服务	交通和通信	教育文化和娱乐	医疗保健	其他用品和服务
中位数法	价格变化频率(%)	2.24	3.2	1.49	0.72	3.02	2.12	2.74	2.35	1.84
	价格变化周期(天)	44	31	66	138	33	47	36	42	54
	价格上升频率(%)	1.31	1.72	0.82	0.44	1.65	1.18	1.44	1.44	0.99
	价格上升周期(天)	76	58	121	225	60	84	69	69	100
	价格下降频率(%)	0.99	1.48	0.65	0.3	1.3	0.97	1.39	1	0.84
	价格下降周期(天)	101	67	153	335	76	103	71	99	118
	价格变化大小(%)	5.49	5.62	6.47	1.95	6.11	4.4	4.23	8.44	5.35
	价格变化幅度(%)	19.49	19.1	23.8	19.88	22.53	15.47	16.75	22.77	17.48
	价格上升幅度(%)	20.94	22.29	27.21	18.71	26.84	17.7	18.64	26.74	19.59
算术平均	价格下降幅度(%)	17.18	16.8	20.18	20.28	18.14	12.29	13.59	16.53	17.56
	价格变化频率(%)	3.99	2.96	1.70	0.79	3.19	3.10	4.04	2.54	13.61
	价格变化周期(天)	25	33	58	126	31	32	24	39	7
	价格上升频率(%)	2.27	1.59	0.95	0.44	1.76	1.64	2.18	1.42	8.19
	价格上升周期(天)	43	62	104	225	56	60	45	70	12
	价格下降频率(%)	1.72	1.37	0.75	0.35	1.43	1.46	1.86	1.12	5.42
	价格下降周期(天)	58	73	133	286	69	68	53	89	18
	价格变化大小(%)	5.75	5.61	8.65	1.21	6.59	3.47	4.78	8.59	7.15
	价格变化幅度(%)	20.07	20.15	21.85	21.00	21.67	15.35	17.32	23.02	20.21
加权平均	价格上升幅度(%)	22.96	23.34	25.78	20.51	25.33	17.60	20.01	27.36	23.72
	价格下降幅度(%)	17.16	16.68	21.45	20.30	17.34	12.85	14.66	17.52	16.54
	价格变化频率(%)	2.08	2.63	2.68	0.21	3.95	1.21	3.69	2.31	2.71
	价格变化周期(天)	47	38	37	485	25	82	27	43	36
	价格上升频率(%)	1.12	1.41	1.46	0.11	2.21	0.65	1.91	1.29	1.65
	价格上升周期(天)	88	71	68	903	45	154	52	77	60
	价格下降频率(%)	0.96	1.22	1.22	0.10	1.74	0.57	1.79	1.02	1.06
	价格下降周期(天)	104	81	82	1048	57	176	55	98	94
	价格变化大小(%)	3.15	4.83	6.00	-0.13	5.07	0.90	2.24	7.23	3.01
	价格变化幅度(%)	13.53	17.74	26.22	7.01	17.56	5.42	11.87	20.74	4.25
	价格上升幅度(%)	15.44	20.56	30.85	6.63	20.43	6.31	13.95	24.48	4.61
	价格下降幅度(%)	11.21	14.68	20.97	6.18	14.39	4.63	10.70	16.05	1.45

资料来源: 作者根据测算结果整理而成。

^① 此外, 本文还进行了多种稳健性检验, 包括改变异常值的波动区间(将价格上涨超过 400% 或者下降超过 80% 的值定义为异常值)、选取不同的打折时间窗口(15 天或 30 天)、价格变化中不区分打折调价等, 发现线上调价频率仍然较为频繁、上调和下调的不对称性明显、部门异质性显著, 与主体测度结果一致。这些说明不同的数据处理方式对测度结果不会产生实质性影响, 主体结果较为稳健。但是由于篇幅原因, 稳健性检验没有放入正文中, 如果有读者感兴趣, 可以向作者索要完整版本, 或可参见 iCPI 官网的工作论文栏目 <http://www.bdecon.com/workIndex>。

四、价格调整模式识别: 动态视角

生存分析(survival analysis)是一种研究生物或人的生存时间特征及其影响因素的方法,它能较好地分析截断数据问题(Moore, 2016)。本文借鉴生存分析的思想,将价格变化视为被风险击中,采用非参法和半参法估计模型,从动态视角识别调价模式及其影响因素。

(一) 生存分析模型估计

1. 非参估计方法

非参法对变量分布没有任何限制,回归函数形式较为灵活,但无法估计其他因素对风险概率的影响,这可用于估计价格变化的风险概率函数。累积风险函数估计如下:

$$\widehat{H}(t) = \sum_{j: t_j \leq t} \frac{c_j}{n_j} \quad (9)$$

其中 $c_j, n_j, \frac{c_j}{n_j}$ 分别表示在 t_j 时价格变化的商品数、价格仍存在的商品数、价格变化率。

为了获得平滑的风险函数估计 $\widehat{h}(t)$, 可以结合核回归估计, 风险函数估计如下:

$$\widehat{h}(t) = \frac{1}{\lambda} \sum_{j: t_j \leq t} K\left(\frac{t - t_j}{\lambda}\right) \Delta \widehat{H}(t_j) \quad (10)$$

其中 $K(\cdot)$ 是对称的核密度函数, λ 是平滑窗宽。

2. 半参估计方法

Cox 比例模型是常用的半参估计法,特别地,当这是一个时间依赖的 Cox 比例模型时,可包含随时间变化的协变量,它提供了一个分析连续变量的调节效应的框架,可用于分析不同类型的影响因素对调价概率的影响。Cox 假设协变量 X 在共同基准函数上移动,即:

$$h(t) = h_0(t) \exp(X\beta + \varepsilon) \quad (11)$$

其中 $h_0(t)$ 是基准函数。Cox 比例模型的风险概率计算公式是:

$$\frac{h_1(t)}{h_0(t)} = \frac{h_0(t) \exp(X_1\beta)}{h_0(t) \exp(X_0\beta)} = \exp[(X_1 - X_0)\beta] \quad (12)$$

其中 β 是通过部分似然函数估计的,基准风险概率函数 $h_0(t)$ 被抵消,因此不需要估计。

(二) 基于非参估计的调价模式识别^①

总样本价格调整概率走势如图 1 所示。总体上看,中国互联网价格调整概率图呈现较为明显的波动特征,表明调价概率异质性较为明显;在某些间隔期,出现了不同的小峰形(peaks),说明有的部门在某些时期调价概率较大,可能是按照特定时期调价;而随着调价间隔的增大,整体调价概率有一定向上倾斜的趋势,符合 SDP 的特征。综合概率图的三点特征可以得到,线上价格调整可能是异质性的 SDP 与 TDP 相结合。

本文进一步比较八大类的价格调整的概率走势。^②八大类中,“食品烟酒”和“衣着”调价概率相对较高、波动幅度相对较大、出现很多峰形;而其他大类价格变动的风险率均有在小幅波动中向上倾斜的趋势,同时伴有一些峰形,与总体表现较为一致。结果表明,各大类的价格调整概率是 SDP 和 TDP 的组合,但不同模式在各大类中的作用程度有所不同。

^① 该方法的判断依据是结合有关文献。在 Calvo(1983)的 TDP 模型中,调价概率外生给定,所以风险函数是水平的。在异质性 TDP 模型(Carvalho, 2006)中,由于不同公司调价概率不一致,总体调价概率表现为沿着水平线有不同峰形。在 SDP 模型(Golosov & Lucas, 2007)中,调价概率是内生的,风险概率向上倾斜,这是由于,随着时间推移,各种条件变化导致商品价格逐渐偏离最优价格,长期未调整的价格更有可能发生变化,调价收益相对较大,因此调价概率随着时间增加而增大。

^② 由于篇幅原因,八大类的价格调整的概率(风险率)走势图没有放入文中。如有读者感兴趣,可以向作者索要完整版本。

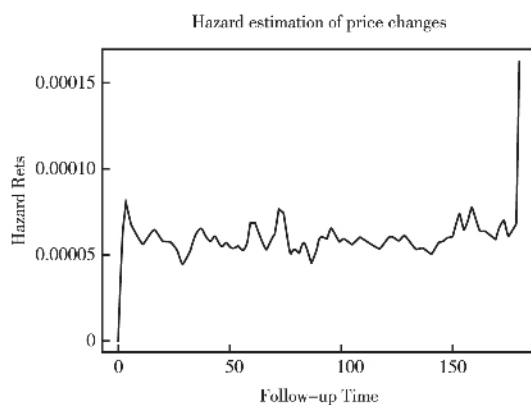


图1 总样本价格调整概率(风险率)走势

(三) 基于 Cox 比例模型的调价模式识别

这部分采用 Cox 比例模型研究不同因素对调价概率的影响,解释变量包括时间相依和状态相依变量,将大类作为控制变量。变量的定义和描述性统计如表 3 所示,回归结果如表 4 所示。

表 3 变量定义及描述性统计

变量符号	变量含义	均值	最小值	最大值	标准差
<i>Price Change</i>	价格变化为 1, 不变为 0	0.0223	0	1	
时间相依变量					
<i>Monday</i>	在星期一为 1, 否则为 0	0.1428	0	1	
<i>Tuesday</i>	在星期二为 1, 否则为 0	0.1429	0	1	
<i>Wednesday</i>	在星期三为 1, 否则为 0	0.1427	0	1	
<i>Thursday</i>	在星期四为 1, 否则为 0	0.1428	0	1	
<i>Friday</i>	在星期五为 1, 否则为 0	0.1429	0	1	
<i>Saturday</i>	在星期六为 1, 否则为 0	0.1429	0	1	
<i>Sunday</i>	在星期日为 1, 否则为 0	0.1430	0	1	
<i>January</i>	在一月为 1, 否则为 0	0.1206	0	1	
<i>February</i>	在二月为 1, 否则为 0	0.0867	0	1	
<i>March</i>	在三月为 1, 否则为 0	0.0785	0	1	
<i>April</i>	在四月为 1, 否则为 0	0.0773	0	1	
<i>May</i>	在五月为 1, 否则为 0	0.0763	0	1	
<i>June</i>	在六月为 1, 否则为 0	0.0774	0	1	
<i>July</i>	在七月为 1, 否则为 0	0.0780	0	1	
<i>August</i>	在八月为 1, 否则为 0	0.0754	0	1	
<i>September</i>	在九月为 1, 否则为 0	0.0743	0	1	
<i>October</i>	在十月为 1, 否则为 0	0.0776	0	1	
<i>November</i>	在十一月为 1, 否则为 0	0.0789	0	1	
<i>December</i>	在十二月为 1, 否则为 0	0.0989	0	1	
状态相依变量					

续表 3

变量符号	变量含义	均值	最小值	最大值	标准差
$price$	商品前一天价格水平(元)	1454	0.2	1830000	20464
gr_{cci}	滞后 1 期的消费者信心指数变化	0.47	-4.21	4.47	1.8957
π_{cpi}	滞后 1 期的通货膨胀率 (CPI 月环比变化, %)	0.16	-1.10	1.60	0.4989
gr_{ppi}	滞后 1 期的 PPI 月环比变化(%)	0.26	-1.00	1.60	0.5674
gr_{pmi}	滞后 1 期的 PMI 月环比变化(%)	0	-1.95	2.45	0.9829
gr_{m2}	滞后 1 期的 M2 月环比变化(%)	0.811	-0.34	2.63	0.7237
gr_{iav}	滞后 1 期的工业增加值月同比变化(%)	6.267	-2.12	15.43	2.2735
$gr_{exchange}$	同期人民币兑美元汇率日环比变化(%)	0.004	1.147	1.06	0.1931
gr_{icpi}	同期 iCPI 日环比变化(%)	-0.016	-2.64	2.16	0.2852
$return_{shci}$	同期上证综指日收益率(%)	-0.023	-7.04	4.26	0.9277
gr_{shibor}	同期上海同业拆借利率日环比变化(%)	-0.073	-24.23	73.74	4.0648

注: 由于篇幅原因, 八大类控制变量未在表中呈现, 其对应 7 个大类虚拟变量; 表中的星期、月份均为分类变量, 程序会自动挑选基准变量, 使得对应的虚拟变量数比总分类数少 1 个。资料来源: Wind 数据库、清华大学 iCPI 项目组。

表 4 中, 模型 1 只包含时间相依变量, 总体上看, 时间相依变量对商品调价概率有较显著的影响。与星期五相比, 星期日的系数显著为负, 且绝对值最大, 说明星期日调价概率最低。与四月份相比, 十一月系数显著为正, 且绝对值最大, 说明 11 月调价概率最大。这些表明时间相依变量会影响调价概率, 符合 TDP 模型。

模型 2 只包含状态相依变量, 总体上看, 不同的状态相关变量均十分显著, 但是影响大小和方向有所不同。从月度指标来看, 在 1% 的显著性水平下, 滞后一期的 PPI 月环比变化、消费者信心指数月环比变化、PMI 月环比变化等系数显著为正, M2 月环比变化、工业增加值月同比变化显著为负。从日度指标来看, 在 1% 的显著性水平下, 人民币汇率变化系数显著为正、上证综指收益率为负。这表明状态相依变量会影响调价概率, 符合 SDP 模型。

模型 3 同时加入两类变量, 其对数似然比(74871)明显高于只加入一类变量的模型 1(44445)和模型 2(57576)。结果发现, 虽然个别变量的显著性程度和系数不同于单独的时间相依或者状态相依模型, 但是大部分的时间相依和状态相依变量都会影响调价概率。这些综合表明中国在线价格调整模式是异质性 SDP 和 TDP 的组合, 进一步验证了非参估计结果。

表 4 基于 Cox 比例模型的总体价格调整模型^①

	模型 1: TDP	模型 2: SDP	模型 3: TDP + SDP
	<i>Price Change</i>	<i>Price Change</i>	<i>Price Change</i>
<i>Monday</i>	-0.108*** (0.00653)		-0.148*** (0.00658)
<i>Tuesday</i>	0.000925 (0.00586)		-0.00195 (0.00590)

^① 由于篇幅原因, 各时间相依和状态相依变量如何影响调价概率的详细分析未放入文中。此外, 与价格粘性指标的稳健性检验类似, 本文也进行了价格调整模式的稳健性检验, 几种检验均表明线上调价模式符合 TDP 和 SDP 相结合, 验证了主体模型的稳健性。但由于篇幅原因, 没有放入正文中。如果有读者感兴趣, 可以向作者索要完整版本。

续表 4

	模型 1: TDP	模型 2: SDP	模型 3: TDP + SDP
	<i>Price Change</i>	<i>Price Change</i>	<i>Price Change</i>
<i>Wednesday</i>	0.0220 ^{***} (0.00587)		0.00609 (0.00592)
<i>Thursday</i>	0.118 ^{***} (0.00537)		0.0861 ^{***} (0.00543)
<i>Saturday</i>	0.0240 ^{***} (0.00565)		-0.00470 (0.00568)
<i>Sunday</i>	-0.382 ^{***} (0.00652)		-0.399 ^{***} (0.00654)
<i>January</i>	0.131 ^{***} (0.0117)		0.322 ^{***} (0.0192)
<i>February</i>	0.0999 ^{***} (0.0119)		1.117 ^{***} (0.0314)
<i>March</i>	0.141 ^{***} (0.0103)		0.130 ^{***} (0.0207)
<i>May</i>	-0.0273 ^{***} (0.0103)		-0.404 ^{***} (0.0225)
<i>June</i>	0.224 ^{***} (0.0111)		0.0876 ^{***} (0.0156)
<i>July</i>	-0.0752 ^{***} (0.0126)		0.640 ^{***} (0.0208)
<i>August</i>	0.0503 ^{***} (0.0129)		-0.133 ^{***} (0.0224)
<i>September</i>	0.186 ^{***} (0.0132)		0.367 ^{***} (0.0212)
<i>October</i>	0.187 ^{***} (0.0135)		0.269 ^{***} (0.0236)
<i>November</i>	0.365 ^{***} (0.0133)		-0.0142 (0.0250)
<i>December</i>	0.359 ^{***} (0.0131)		0.570 ^{***} (0.0182)
$\ln(\text{Price})$		0.112 ^{***} (0.00427)	0.111 ^{***} (0.00426)
gr_{m2}		-0.104 ^{***} (0.00404)	-0.578 ^{***} (0.0149)
π_{cpi}		0.0430 ^{***} (0.00655)	-0.0430 ^{***} (0.0119)
gr_{ppi}		0.0251 ^{***} (0.00545)	-0.0200 ^{***} (0.00618)
gr_{cci}		0.0251 ^{***} (0.00155)	0.0141 ^{***} (0.00185)

续表4

	模型 1: TDP	模型 2: SDP	模型 3: TDP + SDP
	<i>Price Change</i>	<i>Price Change</i>	<i>Price Change</i>
gr_{pmi}		0.0710 *** (0.00343)	0.0796 *** (0.00466)
gr_{ian}		-0.0122 *** (0.000898)	-0.00453 *** (0.00123)
gr_{icpi}		0.395 *** (0.00605)	0.379 *** (0.00579)
$return_{shci}$		-0.00595 *** (0.00190)	-0.00194 (0.00190)
$gr_{exchange}$		0.176 *** (0.00849)	0.191 *** (0.00836)
gr_{shibor}		0.000579 * (0.000312)	0.000820 *** (0.000288)
Number of Obs	19593315	19593315	19593315
Number of Events	436398	436398	436398
Likelihood Ratio Test	44445	57576	74871
P value	0.000	0.000	0.000

注:第一、四月份、星期五、“生活用品及服务”大类的调价概率是基准风险率模型 $h_0(t)$ 这由程序本身决定;第二,由于篇幅原因,7个大类控制变量(在三个模型中均较为显著)未在表中呈现,如读者感兴趣,可以向作者索要完整版本;第三,括号中是稳健标准差;第四,***、**、* 分别表示在1%、5%、10%显著性水平。

五、价格粘性与货币政策非中性程度

价格粘性经验研究结果可用于宏观模型校准及货币非中性程度分析。Alvarez et al. (2016) 构建了一个统一的调价分析框架,通过嵌入多种调价模型,①发现货币政策产生实际作用的充分统计量是调价大小的峰度和调价频率,货币政策对总产出的实际累积影响与调价大小的峰度成正比、与调价频率成反比。本文将借鉴该方法,分析货币政策冲击对各部门以及整体的实际产出的影响。

(一) 模型介绍

假设劳动供给弹性为 $(1/\nu - 1)$, 货币冲击为 ξ , 总产出实际累积影响为 Ω , 在同质性下,有:

$$\Omega = \frac{\xi}{6\nu} \frac{Kur(\Delta p_i)}{f(\Delta p_i)} \quad (13)$$

其中 $p_i = \ln P_i$, $\Delta p_i = \ln P_i - \ln P_{i-1}$, 表示调价大小, $Kur(\Delta p_i)$ 是调价大小的峰度, $f(\Delta p_i)$ 是总调价频率,它由外生调价频率(TDP占比 κ)和内生调价频率(SDP占比 $1 - \kappa$)组成。

假设异质性部门 s 的权重、峰度、频率分别为 ω_s ($\sum_{s=1}^S \omega_s = 1$)、 $Kur(s)$ 、 $f(s)$, 则有:

$$\Omega = \frac{\xi}{6\nu} \sum_{s=1}^S \frac{\omega_s}{f(s)} Kur(s) \quad (14)$$

该货币非中性的充分统计量将峰度考虑进来,不但能反映调价的选择效应(selection effect);对

① 例如 Calvo(1983)、Golosov & Lucas(2007)、Nakamura & Steinsson(2010)等模型。

应 SDP) ,即在发生货币冲击后往往是最需要调价的那些公司更倾向于调价 ,还能反映调价的择时效应(timing effect; 对应 TDP) ,即公司挑选特定的时间点进行调价。

(二) 货币非中性程度测度

假设劳动供给弹性为 0(即 $v = 1$) ,货币政策冲击 $\xi = 1\%$,调价频率 $f(\Delta p_i)$ 采用前面的测度结果。^① 关于 $Kur(\Delta p_i)$ 根据前面算出的调价大小 ,将其标准化后 ,再算出其峰度。

1. 基于 262 子类部门的货币非中性程度测度

首先根据不考虑部门异质性的统计量(13) ,得到货币政策对不同子类部门的实际产出的影响。^② 再根据考虑异质性的统计量(14) ,得到基于子类部门异质性的总体货币非中性程度:

$$\Omega_{262\text{子类}} = \frac{\xi}{6v} \sum_{s=1}^{262} \frac{\omega_s}{f(s)} Kur(s) = \frac{1\%}{6} * 22.0548 = 3.676\%$$

不同子类的货币非中性程度存在较大的差异 ,货币政策对各部门的差异化作用与多种因素相关。以总体非中性程度 3.676% 为分界线 ,发现在分界线之上和之下的子类数相近。低于分界线的子类大多是服务类 ,如“洗浴”、“景点门票”等 ,说明货币政策冲击对服务业实际产出的影响相对较小 ,这可能是因为服务是人力较为密集的行业、或者依赖于自然资源 ,它们的实际产出变化相对较小。高于分界线的子类大多数属于食品类、衣着类 ,如“液体饮料”、“西服”等 ,这些类别市场化程度较高、竞争也较为充分、产出调整较为灵活 ,相对更易受货币政策的影响。

2. 基于 46 中类部门的货币非中性程度测度

首先根据同质性统计量(13) ,得到货币政策对不同中类部门的实际产出的作用。^③ 再根据异质性统计量(14) ,得到基于中类部门异质性的总体货币非中性程度:

$$\text{以加权平均法为例: } \Omega_{46\text{中类-加权平均}} = \frac{\xi}{6v} \sum_{s=1}^{46} \frac{\omega_s}{f(s)} Kur(s) = \frac{1\%}{6} * 10.8290 = 1.805\%$$

类似地 ,得到算术平均法、中位数法下的总体货币非中性程度分别为 0.754%、0.967% ,二者均小于加权平均法 ,这可能与中类的调价频率、调价大小的分布存在一定右偏有关。此外 ,测算还发现不同中类的货币非中性程度存在明显差异 ,相同大类下的不同中类受到货币冲击的影响也存在一定的差异 ,这也为分析细分行业受到货币冲击的异质性影响提供了证据。

3. 基于八大类和总类的货币非中性程度测度

首先根据同质性统计量(13) ,得到各大类的货币非中性程度 ,再根据异质性的统计量(14) ,得到基于八大类的总体货币非中性程度(计算过程同中类) ,结果见表 5。可以看出 ,不同大类、不同算法的货币非中性程度既存在一定差异 ,又有一定规律 ,即货币政策对“食品烟酒”、“居住”、“衣着”的实际作用都较大(属于前三) ,对于“其他用品和服务”的作用较小。

食品烟酒和居住的权重之和超过 50% ,在居民消费篮子中占有重要地位 ,货币冲击对这二者的实际产出影响都较大 ,但是原因有所不同。对于居住大类 ,它的调价频率在八大类中最低 ,调价大小的峰度居中 ,说明在相同的货币冲击下 ,居住大类价格调整缓慢 ,往往是通过调整产出来应对的 ,这可能是由于该大类中的很多价格是通过合同确定的 ,而合同签订往往是半年或者一年 ,临时调价的菜单成本相对较高。对于食品烟酒大类 ,它的调价频率较高 ,但是调价大小的峰度在八大类中最大 ,说明该大类虽然调价较为频繁、但主要是在固定时点调价 ,并不是及时地根据货币冲击调价 ,所以货币政策对它的实际产出影响仍然较大。

^① Alvarez et al. (2016) 校准价格粘性的一般均衡模型时 ,采用的是月度数据 ,为保持一致 ,本文也采用月度数据 ,把相应价格粘性指标转换为以月为单位 ,根据“月度调价周期 = 日度调价周期/30” ,通过公式(6) 可推算得到月度调价频率。

^② 由于篇幅原因 ,货币政策对不同子类(部门) 的实际作用大小没有放入文中。如有读者感兴趣 ,可以向作者索要完整版本。

^③ 由于篇幅原因 ,货币政策对不同中类(部门) 的实际作用大小没有放入文中。如有读者感兴趣 ,可以向作者索要完整版本。

表5 货币政策对各大类和总类的实际作用大小

类别	加权平均(%)	算术平均(%)	中位数(%)
总类	1.047	0.734	0.729
食品烟酒	0.647	1.078	0.919
衣着	0.640	0.952	1.049
居住	2.778	0.787	0.853
生活用品及服务	0.386	0.576	0.628
交通和通信	0.544	0.274	0.353
教育文化和娱乐	0.416	0.498	0.498
医疗保健	0.626	0.504	0.532
其他用品和服务	0.295	0.169	0.391

4. 不同异质性状况的总体货币非中性程度对比

根据总类的价格粘性指标和同质性的充分统计量(13),得到基于总类的货币非中性程度。综合前面不同部门异质性的总体货币非中性程度测度结果,总结得到表6。

表6 基于不同类别的总体货币政策实际作用大小

类别	加权平均(%)	算术平均(%)	中位数(%)
同质性-总类	0.622	0.537	0.977
异质性-8大类	1.047	0.734	0.729
异质性-46中类	1.805	0.754	0.967
异质性-262子类	—	3.676	—

如果以基于算术平均的同质性模型为对比基础(实际测度结果是0.537%),考虑262子类异质性的货币政策实际作用最大,将近是基础模型的7倍;其次是考虑46中类异质性的模型,基于加权平均算法的货币非中性程度是基础模型的3倍以上;再者是考虑8大类异质性的模型,基于加权平均算法的货币非中性程度是基础模型的2倍左右;最后是同质性模型,其中加权平均法和基础模型较为接近,但是中位数法作用较大,是基础模型的1.8倍。

这表明货币政策非中性程度和部门异质性紧密相关,在同种算法下,考虑的异质性部门越多,测度得到的货币非中性程度越高,考虑异质性能更好地解释经济周期波动。值得注意的是,基于中位数法的同质性模型(0.977%)和基于加权平均的八大部门异质性模型的货币政策非中性程度(1.047%)较为接近,这和Nakamura & Steinsson(2010)的发现相似之处。^①这种情况产生的原因可能和调价频率、调价大小的分布均存在较为明显的右偏有关,单部门的算术平均法很容易受到极端值影响,而中位数法则能较好地规避该问题,从而产生和多部门相近似的结果。

六、结论与启示

(一) 主要结论

本文利用独特的高频微观价格大数据,从静态角度测度中国价格粘性程度、从动态角度识别价格调整模式,并将微观结果用于测算货币政策有效性,打通了中国价格粘性微观测度与宏观应用之间的联系,使得微观结果能为宏观分析所用,宏观研究则更具微观基础,主要结论如下:

第一,本文发现中国商品和服务市场调价较为频繁、调价幅度较大、异质性明显、不对称性显著。从总体上看,中国线上价格粘性相对较弱、价格调整周期小于2个月,调价频率有明显的不对

^① Nakamura & Steinsson(2010)基于美国BLS商品数据校准模型发现:考虑了价格调整异质性的模型中货币非中性程度是未考虑异质性的三倍,用单部门模型的中位数(而不是算术平均)价格调整频率能产生和多部门模型相似的货币非中性程度。

称性(上调频率比下调频率高出 17%—32%);调价幅度相对较大(14%—20%)、价格上涨幅度比价格下降幅度高出 21%—38%(不对称性显著)。从不同部门来看,8 大类、46 中类和 262 个子类的调价频率和调价幅度均存在明显的异质性和不对称性。

第二,本文发现中国商品和服务的调价模式是异质性的时间相依(TDP)和状态相依(SDP)相结合。从非参的生存分析结果来看,总类和大类的调价概率函数图波动中有略向上倾斜的趋势,符合 SDP 的特征,而且在某些时间点有一些峰形,符合有异质性的 TDP 特征,说明线上价格调整可能是两种模式的结合。从半参的 Cox 比例模型结果来看,时间相依变量和状态相依变量都会影响总类和大类价格调整的概率,同时考虑两类变量能有效提高调价概率模型的拟合优度。

第三,本文结合价格粘性测度结果和货币政策实际作用大小的充分统计量,发现调价频率、调价大小的峰度、有无部门异质性等均会影响货币非中性程度。货币政策对实际产出的累积效应与调价大小的峰度成正比、与调价频率成反比。在同种算法下,考虑的异质性部门越多,货币非中性程度越高,考虑异质性能更好地解释经济波动。特别地,本文详细的分类数据为研究细分行业受到货币冲击的异质性影响提供了充分证据。

(二) 政策启示

本文考察了数字经济时代的中国商品和服务价格粘性变化及其对货币政策有效性的影响,对大数据时代的货币政策制定和通货膨胀管理具备一定的参考意义,政策启示如下:

第一,中国央行未来应该重视结构性货币政策的发展和运用、对于总量型货币政策运用要更加谨慎,并注意数字经济时代的价格粘性较弱,或将导致货币政策有效性减弱。货币政策冲击对 262 个子类、46 个中类、8 个大类部门的实际产出的影响差异较大,而且异质性部门越多、总体货币非中性程度越高,这对于我国货币政策制定及传导机制疏通有重要启示。货币政策通常要兼顾通货膨胀和经济增长的双重宏观目标,如果还要考虑促进经济结构转型、产业发展的中观目标,那么不同部门对货币政策的异质性反应(包括价格变化和产出变化),无疑会加大货币政策在多目标之间的协调难度。总量型货币政策对于各个部门都有影响,其影响大小和作用时滞与部门的价格灵活调整程度有关,各部门对总货币冲击反应的巨大差异和不一致性易加剧整个经济波动。

中国央行正积极推进货币政策框架从数量型向以利率为中间目标的新货币政策框架(价格型调控)转型,能否转型成功和货币政策的传导机制顺畅与否紧密相连。当下货币政策传导机制不甚顺畅的一个重要原因就是结构性问题,在总体流动性相对充裕的情况下,出现了“结构性流动缺口”,不同行业或不同类型的企业获得的信贷支持差异很大,尤其是实体经济部门相较于房地产业和金融行业。未来应该考虑到货币冲击对各个部门的差异性影响、部门特性及实际需求,创新并灵活运用结构性货币政策工具,实现“精准滴灌”,减少结构性错配。通过运用定向的结构性货币政策工具,引导信贷流向特定领域、产业和区域,为其提供相应的流动性支持;充分考虑部门异质性,针对局部性问题采取相应的货币政策、而非全局性政策,这对于疏通货币政策传导机制、提高金融服务实体经济的效率、促进产业结构转型并兼顾宏观经济金融稳定具有重要意义。

第二,较弱的线上价格粘性为利用在线价格大数据编制实时高频物价指标提供了微观基础,对于提高通胀预测时效性具有重要启示。较弱的线上价格粘性可以看作是高频物价指数的微观基础,主要有两条路径:一是从传导的角度,线上价格调整会带动线下价格调整,政策制定者根据线下价格得到的指标、制定政策,所以线上价格会影响政策;二是通过影响线上高频物价指数,价格粘性弱,其他消息对它的影响能通过价格调整反映出来,而容易调整的价格构成的高频指标能更好地反映现状。如果政策制定者能直接根据线上高频物价指标进行调整,那么政策能更及时。

根据新凯恩斯菲利普斯曲线理论,微观的价格粘性会影响宏观的通胀动态,它通过作用于不同的因素(理性预期、通胀惯性、产出缺口等)对通胀水平产生影响。如果价格粘性变得很弱,很多基于传统官方指标的历史信息的通胀预测可能失效,尤其是在经济发生结构性变化时。本研究发现中国线上价格粘性较弱,弱于线下价格粘性程度;线上调价模式是异质性的状态相依与时间相依相结合,相比于线下调价也更为灵活。因此,中国应该积极探索利用在线价格大数据编制实时高频的物价指标,提高通胀预测时效性和准确性,增强通胀管理和预期引导的有效性,减少宏观政策时滞,基于弱价格粘性构建的线上高频通胀指标未来值得重视。

参考文献

- 蔡晓陈,2012《中国价格粘性的实证研究》,《中国经济问题》第6期。
- 陈彦斌,2008《中国新凯恩斯菲利普斯曲线研究》,《经济研究》第12期。
- 侯成琪、龚六堂,2014《部门价格粘性的异质性与货币政策的传导》,《世界经济》第7期。
- 金雪军、黄滕、祝宇,2013《中国商品市场名义价格粘性的测度》,《经济研究》第9期。
- 刘涛雄、汤珂、姜婷凤、仇力,2019《一种基于在线大数据的CPI指数的设计及应用》,《数量经济技术经济研究》第9期。
- 渠慎宁、吴利学、夏杰长,2012《中国居民消费价格波动:价格粘性、定价模式及其政策含义》,《经济研究》第11期。
- Alvarez, F., F. Lippi, and L. Paciello, 2011, "Optimal Price Setting with Observation and Menu Costs", *Quarterly Journal of Economics*, 126(4), 1909—1960.
- Alvarez, F., H. L. Bihan, and F. Lippi, 2016, "The Real Effects of Monetary Shocks in Sticky Price Models: A Sufficient Statistic Approach", *American Economic Review*, 106(10), 2817—2851.
- Bils, M., and P. J. Klenow, 2004, "Some Evidence on the Importance of Sticky Prices", *Journal of Political Economy*, 112(5), 947—985.
- Calvo, G. A., 1983, "Staggered Prices in A Utility-maximizing Framework", *Journal of Monetary Economics*, 12(3), 383—398.
- Carvalho, C., 2006, "Heterogeneity in Price Stickiness and the Real Effects of Monetary Shocks", *B. E. Journal of Macroeconomics*, 6(3), 1—58.
- Cavallo, A., 2017, "Are Online and Offline Prices Similar? Evidence from Large Multi-Channel Retailers", *American Economic Review*, 107(1), 283—303.
- Cavallo, A., 2018, "Scraped Data and Sticky Prices", *Review of Economics and Statistics*, 100(1), 105—119.
- Ellison, G., and S. F. Ellison, 2009, "Search, Obfuscation, and Price Elasticities on the Internet", *Econometrica*, 77(2), 427—452.
- Gali, J., 2015, *Monetary Policy, Inflation, and the Business Cycle: An Introduction to the New Keynesian Framework and Its Applications*, Princeton University Press.
- Golosov, M., and J. Lucas, 2007, "Menu Costs and Phillips Curves", *Journal of Political Economy*, 115(2), 171—199.
- Gopinath, G., and R. Rigobon, 2008, "Sticky Borders", *Quarterly Journal of Economics*, 123(2), 531—575.
- Gorodnichenko, Y., V. Sheremirov, and O. Talavera., 2018, "Price Setting in Online Markets: Does IT Click?", *Journal of European Economic Association*, 16(6), 1764—1811.
- Kashyap, A. K., 1995, "Sticky Prices: New Evidence from Retail Catalogs", *Quarterly Journal of Economics*, 110(1), 245—274.
- Kehoe, P., and V. Midrigan, 2015, "Prices Are Sticky After All", *Journal of Monetary Economics*, 75, 35—53.
- Klenow, P. J., and O. Kryvtsov., 2008, "State-dependent or Time-dependent Pricing: Does It Matter for Recent US Inflation?", *Quarterly Journal of Economics*, 123(3), 863—904.
- Moore, D. F., 2016, *Applied Survival Analysis Using R*, New York: Springer.
- Nakamura, E., and J. Steinsson, 2008, "Five Facts about Prices: A Reevaluation of Menu Cost Models", *Quarterly Journal of Economics*, 123(4), 1415—1464.
- Nakamura, E., and J. Steinsson, 2010, "Monetary Non-neutrality in A Multisector Menu Cost Model", *Quarterly Journal of Economics*, 125(3), 961—1013.
- Sheremirov, V., 2019, "Price Dispersion and Inflation: New Facts and Theoretical Implications", *Journal of Monetary Economics*, Available online <https://doi.org/10.1016/j.jmoneco.2019.03.007>.
- Sheshinski, E., and Y. Weiss, 1977, "Inflation and Costs of Price Adjustment", *Review of Economic Studies*, 44(2), 287—303.

The Stickiness of Online Prices in China

JIANG Tingfeng^a, TANG Ke^{b,c} and LIU Taoxiong^{b,c}

(a: School of Banking & Finance , University of International Business and Economics;

b: Institute of Economics , School of Social Sciences , Tsinghua University;

c: Institute for Innovation and Development , Tsinghua University)

Summary: The rapid development of the digital economy and big data technology has profound impacts on the economy and society. Along with this rapid development , short-term fluctuations in the macroeconomy and financial system have become more frequent. To reduce macroeconomic policy lags , it is important to understand the micro-foundations of the macroeconomic short-term fluctuations , namely price stickiness. However , due to the lack of price data , empirical evidence of price stickiness in China is relatively scarce. Online big data provide us with a new opportunity to study this important issue.

In this paper , we measure static price stickiness indicators and identify the dynamic price adjustment patterns in China using a unique daily online price dataset. The data come from the iCPI project (www.bdecon.com) of Tsinghua University and contain online prices from more than 100 websites covering the whole basket of goods used in the Chinese Consumer Price Index (CPI) , with over 19 million price records broken down into 8 divisions , 46 groups and 262 classes. We combine the empirical evidence with a sufficient statistic for the real effects of monetary shocks (Alvarez et al. , 2016) to measure the monetary non-neutrality of different heterogeneous sectors. We also explore the application of weak online price stickiness to construct a high-frequency online consumer price index and nowcast inflation.

We find that online prices in China are not very sticky: the average price change duration is less than two months (about 45 days) , lower than those found by most other studies. The weighted average absolute price change is about 14% , higher than what is found in the literature. The overall price-adjusting frequency is about 17% higher during price surges relative to price drops. The magnitude of the price increases is about 38% higher on average than that of the price decreases but with heterogeneity by class , consistent with the findings of Nakamura & Steinsson (2008) . Additionally , the non-parametric survival analysis reveals that the hazard rate of price changes inclines slightly upward with some peaks. A semi-parametric Cox proportional model shows that both time-dependent and state-dependent variables affect the price adjustment probability. These results indicate that the price adjustment pattern in China follows a typical combination of the time-dependent pricing model (TDP) and the state-dependent pricing model (SDP) . The price change frequency , kurtosis of the price change size , price adjustment mode and heterogeneity can all affect monetary non-neutrality. For example , monetary non-neutrality is positively and negatively linked to the kurtosis of the price change size and the price change frequency , respectively , and the same monetary shock can have heterogeneous impacts on different sectors. Considering more heterogeneous sectors improves the explanation for economic fluctuations.

We make three contributions. First , we use a unique high-frequency micro price dataset from China that has full coverage of the CPI basket and comes from multiple platforms , implying that our data are representative of the Chinese economy. Second , we connect the microeconomic evidence and macroeconomic applications of price stickiness in China and explore the influence of the rapid development of the digital economy on price adjustments and monetary non-neutrality. Third , we provide new empirical evidence and a micro-foundation for a better general equilibrium price adjustment model that fits Chinese facts. This paper provides insights into the impacts of the digital economy on price adjustments and macroeconomic dynamics. These findings have important implications for monetary policy formulation and its transmission mechanisms , the development of online real-time high-frequency price indicators and the improvement of inflation prediction timeliness in the digital economy and big data era.

Keywords: Online Big Data; Price Stickiness; Price Adjustment Model; Monetary Non-neutrality; Digital Economy Era

JEL Classification: E31 , E52 , E60

(责任编辑: 昱 池) (校对: 曹 帅)