




尽管披着大数据的外衣
但这是一本常识书
每个人都可以从数据中获得知识和快乐

数据不说谎

大数据之下的世界

城市数据团◎编著



清华大学出版社

数据不说谎

大数据之下的世界

城市数据团◎编著

清华大学出版社
北 京

内 容 简 介

这是一本让你“脑洞大开”的图书,让你尝试从大数据角度来解读这个世界,你会发现,有些问题,和你的直觉完全不一样。本书内容分为三部分:第一部分可概括为“脑洞大开”,以淘宝、旅游、餐馆取名等不同的角度切入,说明数据可以用于做许多有趣的事情;第二部分为数据与工作,包括公务员、二三线城市的衰落、创业等若干热门话题;第三部分为数据与生活,包括用数据帮助理解生活现象、用数据挖掘生活中的趣味,以及用数据看房市三个专题。

本书既适合大中专学生作为开阔眼界,拓展思维,帮助学习之用,也适合职场人士提升技能、辅助工作决策所用,是一切数据思维爱好者不可多得的好书。

本书封面贴有清华大学出版社防伪标签,无标签者不得销售。

版权所有,侵权必究。侵权举报电话:010-62782989 13701121933

图书在版编目(CIP)数据

数据不说谎:大数据之下的世界/城市数据团编著. —北京:清华大学出版社,2017
ISBN 978-7-302-46629-1

I. ①数… II. ①城… III. ①数据处理 IV. ①TP274

中国版本图书馆 CIP 数据核字(2017)第 030992 号

责任编辑:刘志彬

封面设计:汉风唐韵

责任校对:宋玉莲

责任印制:杨 艳

出版发行:清华大学出版社

网 址: <http://www.tup.com.cn>, <http://www.wqbook.com>

地 址:北京清华大学学研大厦 A 座 邮 编:100084

社 总 机:010-62770175

邮 购:010-62786544

投稿与读者服务:010-62776969, c-service@tup.tsinghua.edu.cn

质量反馈:010-62772015, zhiliang@tup.tsinghua.edu.cn

印 装 者:北京亿浓世纪彩色印刷有限公司

经 销:全国新华书店

开 本:170mm×240mm 印 张:20

字 数:318 千字

版 次:2017 年 6 月第 1 版

印 次:2017 年 6 月第 1 次印刷

定 价:69.00 元

产品编号:070835-01

前言 我们在用数据做什么

在这本书的最开始, 我们想要提出这样一个问题:

谁最了解你?

是自己?

是配偶/恋人?

是父母/子女?

是同学/同事/朋友?

毫无疑问, 以上几种人都存在于我们的生命中。

但是, 跟“它”比起来, 以上几种人对我们的了解恐怕都不够全面和客观。

没错, “它”就是手机, 与我们形影不离的手机。

看看你手机上的那一大堆 APP——

微博和朋友圈知道, 你今天心情好不好。

支付宝知道, 你买了什么东西、花了多少钱。

微信和 QQ 知道, 你都有哪些朋友, 你跟哪些朋友的交流更密切。

豆瓣、知乎、每日头条知道, 你都喜欢浏览哪些帖子和新闻。

虾米和酷狗知道, 你喜欢听什么歌。

优酷和 B 站知道, 你喜欢看什么视频。

饿了么和美团知道, 你喜欢什么菜系和口味。

.....

就算你什么 APP 也没装,只要你有一部手机,“它”就知道你什么时候工作,什么时候休息,知道你去了哪里,待了多久。

在手机面前,我们简直无所遁形。手机所知道的你,可能比你所知道的自己,更为真实。

而这些,都是我们自己告诉手机的。我们的每一次浏览、点赞、评论、下单、聊天,都以数据的形式被记录、被沉淀,最终塑造出了我们自己。

所以,请不要被“大数据”“开放数据”“数据挖掘”“深度学习”“神经网络”“云计算”“DMP”等奇奇怪怪的词汇所吓倒。我们每个人每天的生活起居、衣食住行,都在产生数据,并享受着数据给我们带来的便利服务。

事实上,数据已经和我们的视觉、听觉、触觉一样,成为了帮助我们去了解自己、了解他人、了解事物的重要方法。

与其他信息源相比,数据更有可能提供全面和客观的信息,从而帮助我们更快速和高效地了解问题、解决问题。

例如,你母亲催你去相亲,并提供了 100 位相亲者的资料。显然,你不可能一个个把他们约出来见面,一个个去了解和评价他们——你甚至都不可能仔细读完这 100 份资料。

我们通常的做法是,设立一些限制条件,对年龄、身高、学历、收入等进行筛选,再逐份阅读符合条件的相亲者的资料,直到将相亲对象数量减少到个位数。如此,我们的相亲效率就大大提高了。

然而,在享受数据给我们带来的高效便利的同时,我们还必须意识到:数据分析只能提供结果,不能提供结论;数据之所以能做许多事情,是因为使用数据的人做了很多的思考。

例如,2013 年,Amazon Studios 和 Netflix,美国的两家传媒公司,都对自己网站上客户的视频浏览行为进行了分析。接受分析的浏览行为包括客户看了什么视频、什么时候看的、在何处暂停、在何处跳过、在何处反复观看、给视频的评分等。

根据数据分析的结果,两家公司一致认为观众会对政治主题感兴趣,但在视频的体裁、制作等方面则有着完全不同的认知。而后,Amazon Studios 推出了由四位议员作为主角的情景喜剧,Netflix 则推出只有一位议员作为主角的电视连续剧。前一部作品名为《阿尔法屋》(Alpha House),观众反应平平;后一

部作品则是风靡一时、获奖无数的《纸牌屋》(House of Cards)。

所以,即使在一个“大数据”炙手可热、喧嚣尘上的时代,人仍然是主体,是人的智慧让数据具有了价值。

我们,城市数据团的小伙伴们,就是这样一群人:利用数据去了解城市的发展、挖掘城市生活中有趣的故事。对我们而言,数据是帮助我们认识城市的工具、帮助我们在城市里更好地生活的工具,而通过数据发现的东西才是价值和乐趣所在。我们乐意将这些发现拿出来共享。

本书由城市数据团组织编写,并写作了本书的大部分章节。城市数据团的主要成员包括高路拓、汤舸、王咏笑、王宇鹏等。参与了本书部分章节写作的其他数据团成员和合作伙伴包括(按文章收录顺序):

陈宇佳(1.1.2)、郭斌亮(1.2.1)、陈至奕(1.2.3/2.1.1)、冯里婧(2.1.2)、钱骏杰(3.1.2)、张慈(3.1.3)、曹新(3.1.5)、曹湛(3.2.4)、韩旭(3.2.5)、方娴(3.3.1)、张健(3.3.2)、衣霄翔(3.3.3)、陈晨(3.3.4)。

除写作团队之外,感谢以下机构对本书内容提供了数据支持和技术支持(按文章收录顺序):

- 银联智慧信息服务(上海)有限公司(1.1.1/3.1.1/3.2.3)
- 滴滴大数据研究中心(1.2.2/3.2.2)
- 小猿搜题(2.1.1)
- BDP 个人版(2.1.2/3.1.4)
- TalkingData(2.1.4/3.2.2/3.2.4)
- 阿里研究院(2.2.1)
- 大众点评研究院(2.2.2/3.1.2/3.1.3/3.2.5)
- 上海道融自然保护与可持续发展中心(3.1.5)
- 同策房产咨询(3.3.1)

本书由城市数据团这个活跃在互联网上的大数据团队完成。如果您看完本书以后,能够增加一些对这个数据时代的了解、愿意去热爱数据和使用数据,将是对我们莫大的鼓励。

城市数据团

2017 年 3 月

目 录

第 1 章

数据, 另一种视角 // 001

1.1 数据之下的中国 // 003

1.1.1 2015 年, 中国人是怎么花钱的 // 003

1.1.2 游遍全国, 我们的假期够吗 // 017

1.1.3 淘宝改变了哪些城市 // 025

1.2 数据之下的城市 // 35

1.2.1 人口疏解, 让城市更拥堵 // 035

1.2.2 在上海上班, 地铁和开车哪个快 // 048

1.2.3 上海餐馆取名大法 // 056

第 2 章

数据之于工作 // 067

2.1 学习/就业指南 // 069

2.1.1 好好学习, 是另一种童年 // 069

2.1.2 应该去哪里买书呢 // 077

2.1.3 月薪多少才配坐高铁 // 086

2.1.4 哪些公务员最辛苦 // 095

2.1.5 奔赴大城市, 还是回家乡 // 103

- 2.2 在创业的风口上 // 112
 - 2.2.1 一个估值 10 亿美元的养猪 O2O 项目 // 112
 - 2.2.2 大鹏猪肉，为红烧而生 // 121
 - 2.2.3 如何在上海开一家靠谱的餐馆 // 130
 - 2.2.4 快捷连锁酒店选址的空间陷阱 // 140

第 3 章

数据之于生活 // 153

- 3.1 理性生活：那些你所不知道的事 // 155
 - 3.1.1 你的消费水平给上海拖后腿了吗 // 156
 - 3.1.2 如何面对注定平庸的人生 // 165
 - 3.1.3 下雨天外卖会变多吗 // 175
 - 3.1.4 “双 12”规避“假折扣”指南 // 183
 - 3.1.5 上海的水源安全吗 // 189
 - 3.1.6 “控制人口”——开给上海的一剂毒药 // 198
- 3.2 感性生活：八卦新玩法 // 212
 - 3.2.1 高颜值的人都在哪儿 // 212
 - 3.2.2 中国正在二次元化吗 // 221
 - 3.2.3 如何像白富美一样生活 // 232
 - 3.2.4 长三角城市那些不得不说的八卦 // 242
 - 3.2.5 上海哪所高校的吃货最幸福 // 249
- 3.3 生活之重：生为房奴 // 259
 - 3.3.1 上海的房子都被谁买走了 // 259
 - 3.3.2 上海购房攻略 // 268
 - 3.3.3 遥不可及的学区梦 // 278
 - 3.3.4 房地产泡沫有多大 // 287

附录 1：

我们是怎么学会玩城市数据的？ // 297

附录 2：

城市数据团工作方法简介 // 305

第1章

数据，另一种视角

你消费吗？旅游吗？上班吗？

你知道别人是怎么消费、怎么旅游、怎么上班的吗？

我们对于世界和城市的认知，往往来源于自己和身边其他人的生活经验。

所以，我们的认知往往是主观化和碎片化的。

但是，当我们拥有了“数据”这个工具的时候，我们就获得了重新认识世界的机会。

1.1 数据之下的中国

本节内容主要涉及一个主题：如何脑洞大开地搜集和利用各种数据，以非常规的方式呈现出中国经济发展的三个截面。

数据之下的中国，是一个让你既熟悉又新鲜的中国。

1.1.1 2015年，中国人是怎么花钱的

在一波接一波的寒潮侵袭之后，期盼已久的春节假期终于到了。

同事同学们纷纷放假回家，连亲爱的学姐也不在上海，只留我一个人凄冷地坐在工作台前，独自迎接假期前最难熬的几天。

一个人的时候，总是会想很多。

是的。回首即将逝去的羊年，我感慨万千。虽然不出意外地又（为什么要加一个又字呢）穷困潦倒地度过了漫长的一年，但幸运的是在这期间认识了不少天南海北的朋友。

因此，虽然还在孤独地加班，但我仍然心系着祖国人民，安静地准备完成春节前的最后一项数据工作：

年度全国消费数据总盘点。

好吧，问题来了——

Q1：2015 年，全国人民到底花了多少钱？

2015 年全球范围内可使用银联卡商户共 3 390 万家，ATM 共 200 万台，境外共发行银联卡 5 200 万张。

根据刷卡交易统计，2015 年全年，全国人民的刷卡交易总金额达到 53.9 万亿元。

53.9 万亿元，是个什么概念呢？

我们可以想象一下：如果把这 53.9 万亿元全换成 100 元的人民币钞票，并将其一张一张紧挨着排列起来的话，这些钱大概可以绕地球赤道 2 100 圈；从地球排到太阳的话，可以走一半多一点的路程。

假如这还想象不出来的话，我们可以换个角度来看：

根据国家统计局的数据，2015 年，全国 GDP 总额约为 67.7 万亿元。也就是说，仅是刷卡消费，全国人民就刷掉了年度国内生产总值的 79.6%。

亲爱的，你 2015 年创造了多少 GDP？又刷掉了多少份额呢？

算好了吗？

好的话，我们不妨再来研究一下第二个问题，看看你的消费和全国总体水平相比如何呢？问题来了。

Q2：这 53.9 万亿元，都是怎么花掉的呢？

首先，让我们来看看这些钱是在什么时间内被花掉的呢？

我们统计了境内日均刷卡的交易金额，并将其细分到每一个小时。2015年日均逐小时交易曲线见图1-1，银联卡交易类型占比见图1-2。




图 1-1 日均逐小时交易曲线




图 1-2 2015 年银联卡交易类型占比

假如我们把 2015 年全年浓缩到一天来看的话，可以发现：14:00~15:00 和 8:00~9:00 是全国人民刷卡的高峰时段，分别占全天交易总额的 12% 与 8%。

亲爱的，你的卡是不是在这个时段内被刷爆的呢？

看完了交易时间，我们再来看一下交易的类型。我们将年度刷卡交易总金额分配到交易类型上，如下所述。

(1) 从全国尺度上来看，最多的刷卡交易金额发生在批发行业，份额第

一,大概可以购买 16 个阿里巴巴。

(2) 份额第二的是金融行业,大概可以购买 7 个中国工商银行。

(3) 份额第三的是零售行业(俗称买买买),大概可以购买 5 个沃尔玛。

也许你会觉得,这种全国宏观尺度上的消费特征,和个人没什么关系。那么,我们不妨从个人消费者的角度出发,看一下与市民生活关系最大的消费门类吧。

一般而言,各种消费类型中,与市民生活关系最大的应该是衣食住行金融教育六个大类。结果如何呢?

(1) 排名第一:金融。毫无悬念。

(2) 排名第二:住房。其交易总额大约是金融类的三分之一。

(3) 排名第三:旅游。虽然交易总额排名第三,但也不过是住房类的零头而已。

(4) 排名第四:衣(衣物类零售)。其总额大约是旅游的三分之一。

(5) 排名第五:吃(餐饮)。交易总额与衣物类零售不相伯仲。

(6) 排名最后:教育。其交易总额大约是餐饮的 70%。没错,这个结果毫不意外、发人深省。

亲爱的,你的消费结构和全国人民相比,究竟怎样呢?

每个人的消费结构自然千奇百怪。

且不说个人,即使从省市的角度上去区分,也可以看到消费结构上的巨大差异。我们来看看:

Q3: 全国各省的消费结构有什么样的偏好呢?

我们仍然将数据聚焦在衣物、餐饮、住房、旅游、金融和教育六个大类上。然后将各类消费金额占总消费金额的比例作为消费偏好的核心指标,分配到各省,可以得到以下结果。

(1) 衣物类消费偏好前五名省市:云南、浙江、甘肃、山西、湖北。

想必云南四季如春,民族众多,姑娘们想怎么打扮就怎么打扮吧。见图 1-3。

(2) 餐饮类消费偏好前五名省市:海南、上海、西藏、宁夏、北京。

吃货集聚在上海、北京,这点毫不意外。但没想到海南、西藏、宁夏等边远

地区的吃货能量同样惊人，见图 1-4。




图 1-3 各省衣物类消费占比



图 1-4 各省餐饮类消费占比

(3) 住房类消费偏好前五名省市：海南、四川、贵州、北京、安徽。

非常出乎意料的，前三名竟然不是以高房价著称的北上广哦！看来虽然北上广的绝对房价居高不下，但从真实的消费结构上，海南和四川的房价水平也不容小觑。相比北京排名第四，而上海甚至都没有挤进前五，见图 1-5。




图 1-5 各省住房类消费占比

(4) 旅游类消费偏好前五名省市：西藏、海南、青海、新疆、云南。

从图 1-6 可以看到，西部的旅游消费偏好明显高于东部。而排名前五的省市，也都是以旅游胜地著称的地区。

(5) 金融类消费偏好前五名省市：福建、重庆、广东、湖南、上海。

从图 1-7 可以看到，我国东南地区在金融类消费偏好中可谓一枝独秀，福建省拔得头筹。排名前五的省市中，上海市已经是最北方的地区了。

(6) 教育类消费偏好前五名省市：陕西、四川、北京、海南、湖南。

从图 1-8 可以看到，陕西省、四川省在教育类消费上的偏好明显高于全国其他地区。我在想，这些地方的孩子们是不是从幼儿园就开始上补习班了？

说明一下：本书消费数据中没有统计到中国台湾地区的数据，所以地图上台湾地区的颜色与其他省市不同。



图 1-6 各省旅游类消费占比




图 1-7 各省金融类消费占比