

大数据像中医，有疗效，别神化

——专访国家特聘专家王晓阳教授

本报记者 曹刚



“大数据的魅力是全面,而非精准”

记者:能否通俗解释大数据的概念?

王晓阳:何为大数据,学界没有统一一定论。按照我的理解,我想了一个比喻。

以前采集数据像西医看病,验血、测心率、查病毒,具体而直接。而大数据的采集方式不同,有点像中医问诊,望闻问切,看面色、舌苔、脉象,全方位观察病人。大数据涉及更庞杂的数据,不见得精准、专业,但是有用。它的魅力是全面,而非精准。

传统的民意调查像西医,先设计问卷,确定样本,再抽样获得信息。大数据的做法有点像中医法则,以微博数据为例,成千上万博主都在表达某些感觉或想法,用微博数据来调查民意就如同整体搭搭脉,虽有些模糊,但能很好把握社会热点和舆论倾向等。

精准数据其实是我们向往的,但它有个成本问题,不太可能全面覆盖。大数据的特征包括数量大、信息杂、传输快。在许多情况下,“大”和“杂”提供好的覆盖性,“快”则使大数据更具适时性。

大数据固然重要,但过于依赖大数据,肯定也不行,对事物的详细了解还是需要精准数据。中医看整体而粗犷,西医管局部而细致,“中西医结合”更有效。

记者:在社会生活应用中,大数据能发挥什么作用?

王晓阳:许多应用都涉及一个关键词:二次利用。数据采集之初,原为某些特定需求,但二次利用后,又产生新的奇妙结果。

搜索引擎起初只是给用户提供便利,查询知识。经过巧妙再利用,便能预测流感趋势,比政府部门的数据更快。

城市里有很多摄像头,初衷是为防盗和监控路况。大量视频数据经过分析,能全面掌握城市脉搏,帮管理者做决策。

微博一开始只为表达自我,和舆情无关。但后来发现,还能了解舆情。

交通数据也会透露其他信息——演唱会举办期间,可以从场地附近的交通拥堵程度,判断明星受欢迎程度;微软中国研究院曾为北京上千辆出租车装 GPS 设备,记录数月行动轨迹。分析这些交通数据,结合人们的交通出行习惯,能发现各城市区域的属性,是商业区、住宅区还是娱乐区。

“收敛浮躁,核心技术是长远之道”

记者:海量数据与信息爆炸早就存在,大数据的概念为何近两年才出现?

王晓阳:海量数据和信息爆炸都与因特网相伴而生。起初我们的网速很快,但没多少数据在上面跑。

现在大不一样,尤其是近十年,制造数据的人和设备大增。电脑的功能越来越强大,价格也日益亲民。智能手机、平板电脑等移动终端很容易获取。

传感器、摄像头、计算机、POS 机、天上的卫星、地下的感应线圈,都在采集数据,导致数据量大爆炸,远超出原来的规模。

软件开源运动(开放源代码)兴起后,软件也越来越便宜,容易得到。

技术进步还催生了“云计算”,就是把很多便宜的电脑串在一起,大大提高计算能力;和网络结合后,无需拥有这些机器,也能采集、处理数据。

社会上各种脉搏跳动近几年越来越多——发微博,手机签到,网上搜索,哪怕是网购一件小商品,也能反映某种需求或流行……这些都是催生大数据的因素。

记者:我国大数据应用领域很热闹,技术研发的现状如何?

王晓阳:大数据最炫的地方在应用,核心技术往往被忽视。

采集、存储和分析等核心技术,主要掌握

在美国人手里。国内投资很少,大家都看重结果,所以应用领域很热闹,还在国际上发表了不少应用方面的学术论文。

大数据刚起步,我们完全有机会和美国站上同一起跑线,现在却只能跟在人家后面跑。等别人研发出新一代技术,我们马上一窝蜂地拿来用。

浮躁是原因之一,整个科技创新环境都比较浮躁。从国家层面讲,应当重视扶植大数据的核心技术研发。

我们要收敛浮躁,保持冷静,认识到核心技术才是长远之道。不要神化大数据,以为掌握了许多数据,再买来机器,就万事大吉。这是很不负责任的想法。

“数据庞杂冰冷,需人的智慧激活”

记者:谷歌预测流感;微软预言奥斯卡,都靠大数据,怎么做到的?

王晓阳:谷歌 5 年前推出“流感趋势”服务,通过分析关键词,准确预测美国各地流感爆发情况。

这是大数据应用的典型案例。谷歌综合分析大量实时数据和历史数据,了解不同历史阶段流感爆发情况,以及对应时期的关键词、频率,判断哪些因素的相关性大,反复试错、调整,直到建立可靠模型。

微软猜准多项奥斯卡奖,也是相同套路——分析大量历史数据,找准多个相关因素,不断调试,建模型。说来简单,实际操作很复杂。

记者:最近中国股市行情惨淡,能借大数据之力预测涨跌吗?

王晓阳:按我的理解,股市可预测,但有效期很短,超出几秒甚至几毫秒,就不准了。天气预报也类似,报 7 天后的,基本没谱;报明天的,命中率相当好;如果报几分钟后的,更准。

华尔街有些公司,专在毫秒间买进卖出。时间短,对机器运行速度要求很高。公司就设在交易所旁边,以保证数据线尽可能短。

但对绝大多数股民来说,股市不能预测,因为等你买到手时,早过预测有效期了。

记者:大数据时代,机器的性能越来越强,人的作用还剩多少?

王晓阳:业内有观点认为人不重要,交给机器处理就行。我不赞同。数据庞杂而冰冷,需要人的智慧去激活。

美国人 Nate Silver 擅长预测,有“大数据

时代的巫师”之称。去年美国总统大选,他预言奥巴马有 90.9%的机会获胜,对全美 50 个州投票结果的预测全对。2008 年总统大选,他也猜对了。

Silver 不是靠蒙,而是收集众多民调数据,综合分析多方面因素。为什么准?因为他有独特洞察力,在纷繁复杂的数据里,能找准关键变量,建立靠谱模型。这是机器不能代替的。

大数据对人提出了更高要求。以前做抽样调查,预设问卷,再有针对性地分析结果,套路清楚、易学。现在数据铺天盖地,选哪些来支持预测和判断,如何建模型,都比原来难。

我想强调“概率”。Silver 预测再准,也从不讲绝对,而是用百分比说话。有不确定性,所以更需要依靠人的判断。假如今天降水概率 70%,你出门带不带伞?

“要彻底保护隐私,数据就没用了”

记者:社交媒体在大数据时代扮演什么角色?是否不可替代?

王晓阳:微信、微博、论坛等社交媒体,是给社会搭脉的重要途径。因为在这些地方,人们能充分表达情感。“我在哪,买了一杯咖啡,好不好喝,天气如何,心情怎样……”与态度、情绪有关的数据,只有这里能采集到。

媒体在街头做民意调查,问路人“你幸福吗”,获得的数据可能不准,倒不如去微博里寻找人们自发表达的内容。

记者:大数据正被越来越多商家利用,对消费者是好是坏?

王晓阳:如果大数据被商家正确使用,消费者确有需求,当然觉得方便;反之就成了骚

扰。一些购物网站常根据消费行为推荐商品。比如有人买了一本孕期保健书,网站几个月后便频频推荐尿布和奶粉。其实她是替朋友买的,与个人需求无关。

这不是大数据本身的问题,而是对数据的分析出了错,脉搏没搭清楚,就会带来负面影响。这也反映了人的智慧在分析数据时所起的重要作用。

记者:大数据时代对个人隐私的侵犯似乎防不胜防,如何规避数据开放带来的风险?

王晓阳:保护隐私确实是大数据面临的难题。有人曾想证明一个命题:能否既保护隐私,又保证数据有用?结果发现做不到,要彻

底保护隐私,数据大多就没用了,两者之间没有平衡点。如果完全关闭手机位置信息,确实保住了隐私,但导航等软件就不能用了。

保护隐私不是不能做,而是要在采集数据的环节及采集到数据后同时做。采集数据时应透明,要让用户知道什么数据在被采集,并征得用户同意。其实最严重的问题出在采集数据之后,谁可以用这些数据?如何用?现状是,采集者掌握众多隐私数据后,随意贩卖,给许多人带来困扰,甚至对大数据产生恐慌。

我国这方面法律不健全,必须加快立法。采集到隐私数据后,谁能用,能怎么用,如何告知消费者,违规了怎么处罚……都需法律规范。