大趋势

—Big Data

国内大数据

马云对将来的预测，是建立在对顾客行文分析的基础上。“2023年初,阿里巴巴平台上整个买家询盘数急剧下滑，欧美对中国采购在下滑。海关是卖了货,出去后来再取得数据;而我们提前六个月时间从询盘上推断出世界贸易发生变化了。”
腾讯在天津投资建立亚洲最大的数据中心；
百度也在投资建立大数据处理中心；

*

美国的大数据战略

2023年3月，美国奥巴马政府宣告投资2亿美元开启“大数据研发计划”，旨在提升和改善从海量和复杂数据中获取知识的能力，加速美国在科学和工程领域发明的步伐，增强国家安全。

这是继1993年美国宣告“信息高速公路”计划后的又一次重大科技发展布署，由美国国家科学基金会、能源部等6个联邦部门共同投资。

目录

*

大数据时代的背景

“大数据”的诞生：

半个世纪以来，伴随计算机技术全方面融入社会生活，信息爆炸已经积累到了一种开始引起变革的程度。它不但使世界充斥着比以往更多的信息，而且其增长速度也在加紧。信息爆炸的学科如天文学和基因学，发明出了“大数据”这个概念*。如今，这个概念几乎应用到了全部人类智力与发展的领域中。

二十一世纪是数据信息大发展的时代，移动互联、社交网络、电子商务等极大拓展了互联网的边界和应用范围，各种数据正在迅速膨胀并变大。

互联网（社交、搜索、电商）、移动互联网（微博）、物联网（传感器，智慧地球）、车联网、GPS、医学影像、安全监控、金融（银行、股市、保险）、电信（通话、短信）都在疯狂产生着数据。

*

数据大爆炸

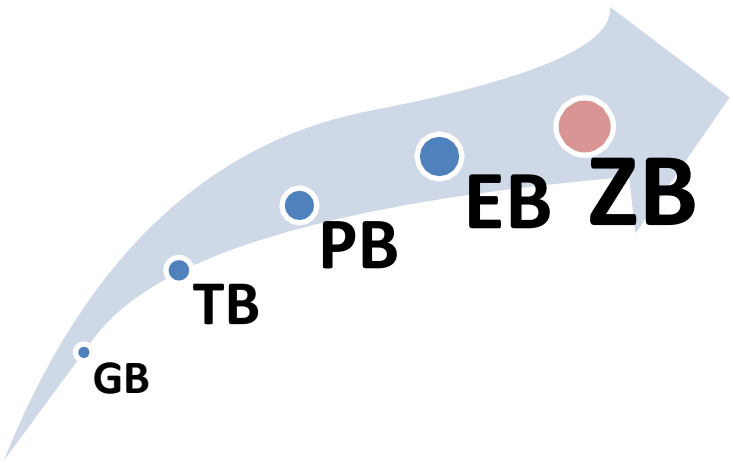

地球上至今总共的数据量：

在**2023** 年，个人顾客才刚刚迈进**TB**时代，全球一共新产生了约**180EB**的数据；

在**2023** 年，这个数字到达了**1.8ZB**。

而有市场研究机构预测：
到**2023** 年，整个世界的数据总量将会增长**44** 倍，到达**35.2ZB（1ZB=10** 亿**TB）！**

1PB = 2^50字节
1EB = 2^60字节
1ZB = 2^70字节

想驾驭这庞大的数据，我们必须了解大数据的特征。

大数据的4V特征

体量Volume	*非构造化数据*的超大规模和增长 总数据量的80~90% 比构造化数据增长快10倍到50倍 是老式数据仓库的10倍到50倍
多样性Variety	大数据的异构和多样性 诸多不同形式（文本、图像、视频、机器数据） 无模式或者模式不明显 不连贯的语法或句义
价值密度Value	大量的不有关信息 对将来趋势与模式的可预测分析 深度复杂分析（机器学习、人工智能Vs老式商务智能(征询、报告等）
速度Velocity	*实时分析*而非批量式分析 数据输入、处理与丢弃 立竿见影而非事后见效

*

目录

1、密不可分的大数据与云计算

大数据是落地的云

商业模式驱动

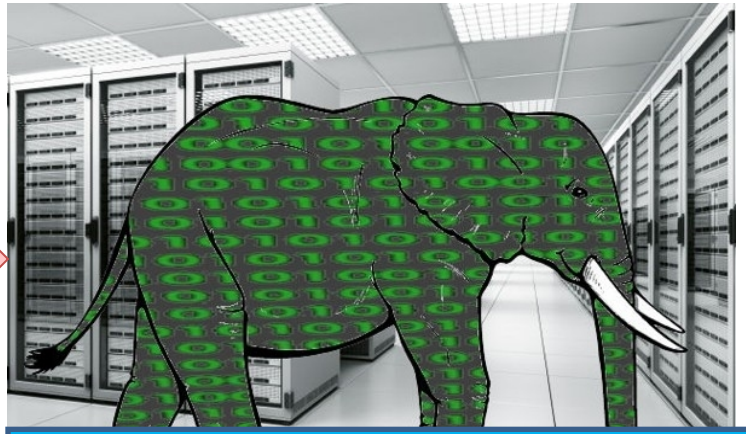

应用需求驱动

云计算本身也是大数据的一种业务模式

•云计算的模式是业务模式，本质是数据处理技术。
•数据是资产，云为数据资产提供存储、访问和计算。
•目前云计算更偏重海量存储和计算，以及提供的云服务，运营云应用，但是缺乏盘活数据资产的能力，挖掘价值性信息和预测性分析，为国家、企业、个人提供决策和服务，是大数据关键议题，也是云计算的最终方向。

*

2、大数据不但仅是“大”

多大？
至少PB级

比大更主要的是数据的复杂性，有时甚至大数据中的小数据如一条微博就具有颠覆性的价值

*

4、大数据的应用不但仅是精确营销

- 经过顾客行为分析实现精确营销是大数据的经典应用，但是大数据在各行各业尤其是公共服务领域具有广阔的应用前景

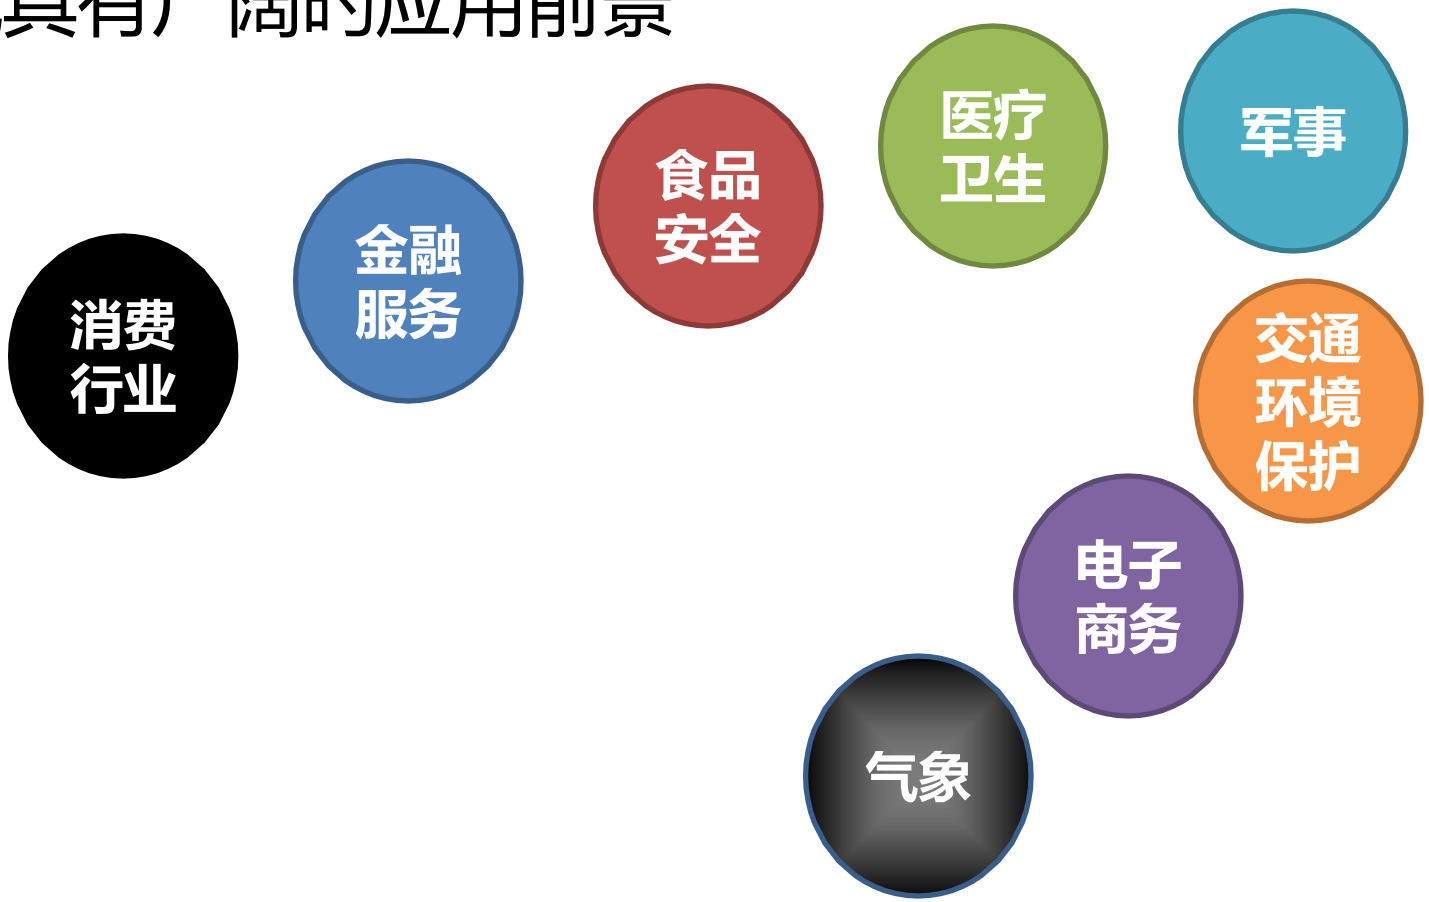

*

5、管理大数据“易”了解大数据“难”

- 虽然大数据是一种重大问题，真正的问题是让大数据更有意义
- 目前大数据管理多从架构和并行等方面考虑，处理高并发数据存取的性能要求及数据存储的横向扩展，但对非构造化数据的内容了解仍缺乏实质性的突破和进展，这是实现大数据资源化、知识化、普适化的关键
- 非构造化海量信息的智能化处理：自然语言了解、多媒体内容了解、机器学习等

目录

*

某些有关技术

Ø 分析技术：

- 数据处理：自然语言处理技术
- 统计和分析：A/B test; top N排行榜；地域占比；文本情感分析
- 数据挖掘：关联规则分析；分类；聚类
- 模型预测：预测模型；机器学习；建模仿真

Ø 存储

- 构造化数据：
  - p 海量数据旳查询、统计、更新等操作效率低
- 非构造化数据
  - p 图片、视频、word、pdf、ppt等文件存储
  - p 不利于检索、查询和存储
- 半构造化数据
  - p 转换为构造化存储
  - p 按照非构造化存储

Ø 大数据技术：

- 数据采集：ETL工具
- 数据存取：关系数据库；NoSQL；SQL等
- 基础架构支持：云存储；分布式文件系统等
- 计算成果呈现：云计算；标签云；关系图等

Ø 处理方案：

- Hadoop（MapReduce技术）
- 流计算（twitter旳storm和yahoo！旳S4）