

# 大数据与AI的发展应用

何宝宏

中国信息通信研究院



微信订阅号：何所思

## ●●● 个人画像

20余年互联网研究的**老兵**。

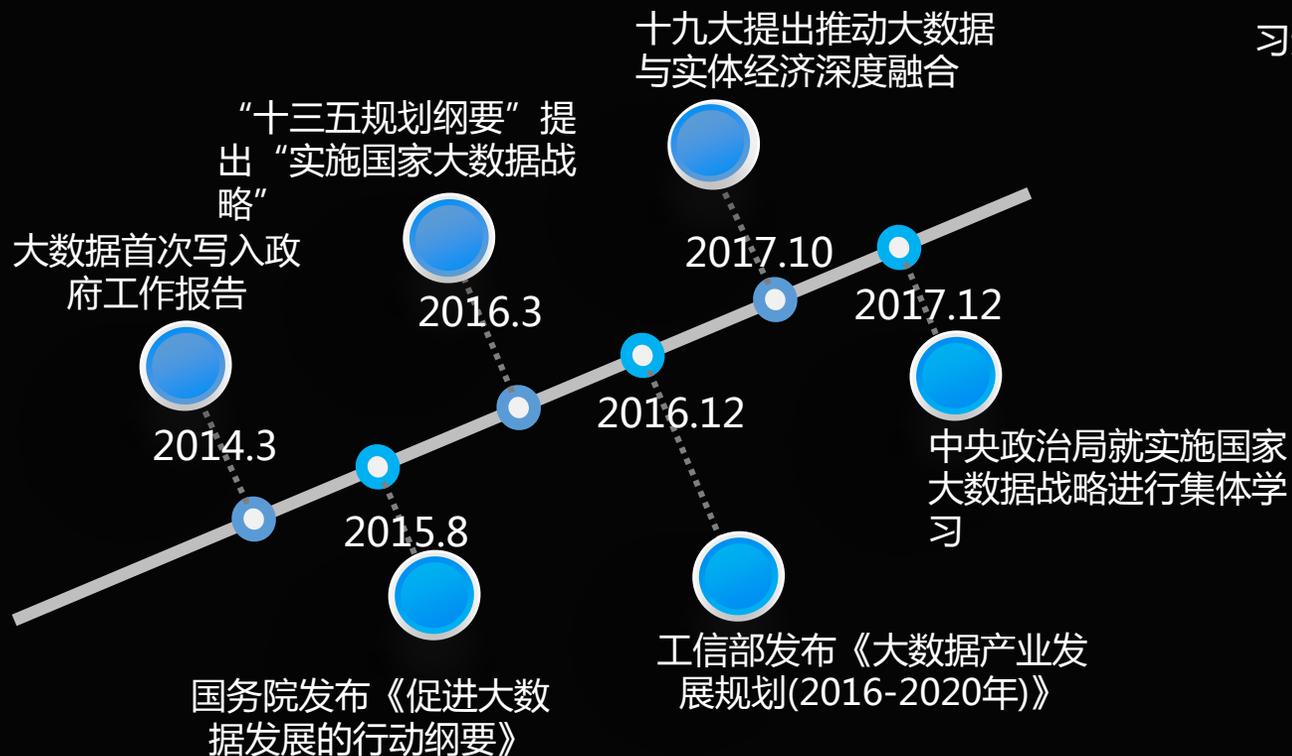
现主要**禅修**如何为互联网技术**相面**。

1999年毕业于中科院计算所，获计算机应用博士学位。



# ① 大数据

# 大数据政策热度持续攀升

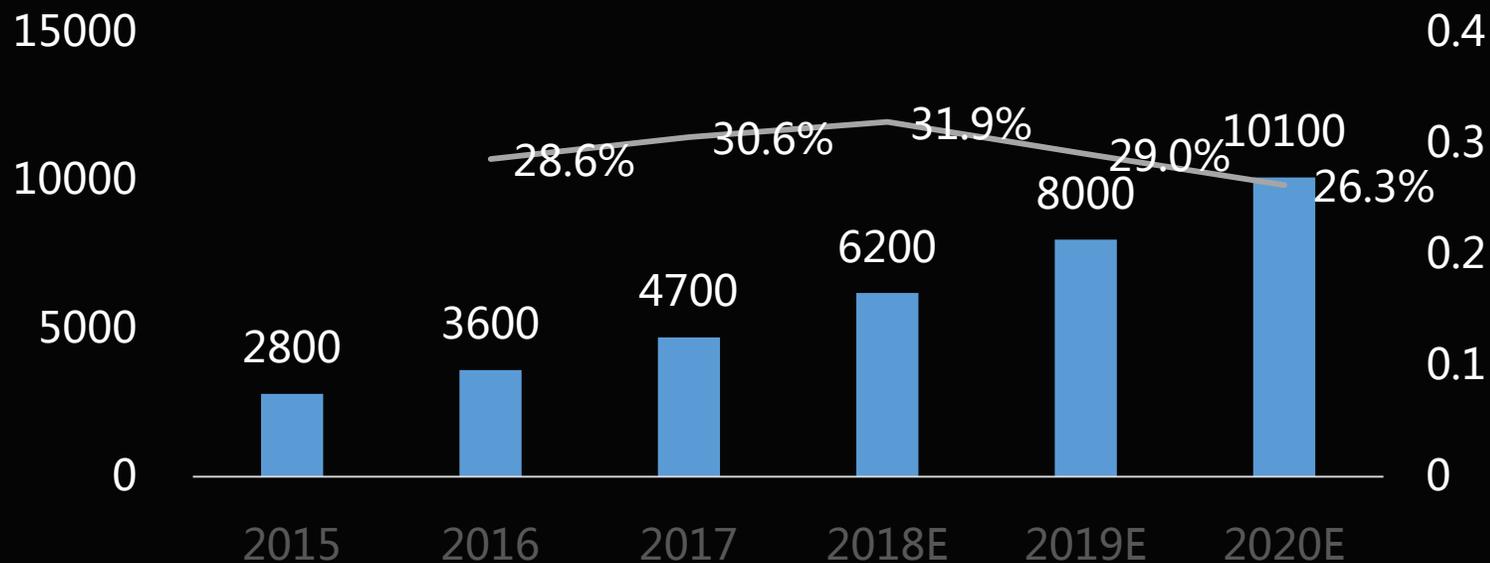


习近平总书记提出了五个方面的要求

- 1 推动大数据技术产业创新发展
- 2 构建以数据为关键要素的数字经济
- 3 运用大数据提升国家治理现代化水平
- 4 运用大数据促进保障和改善民生
- 5 切实保障国家数据安全

## ●●● 我国大数据产业规模达到4700亿

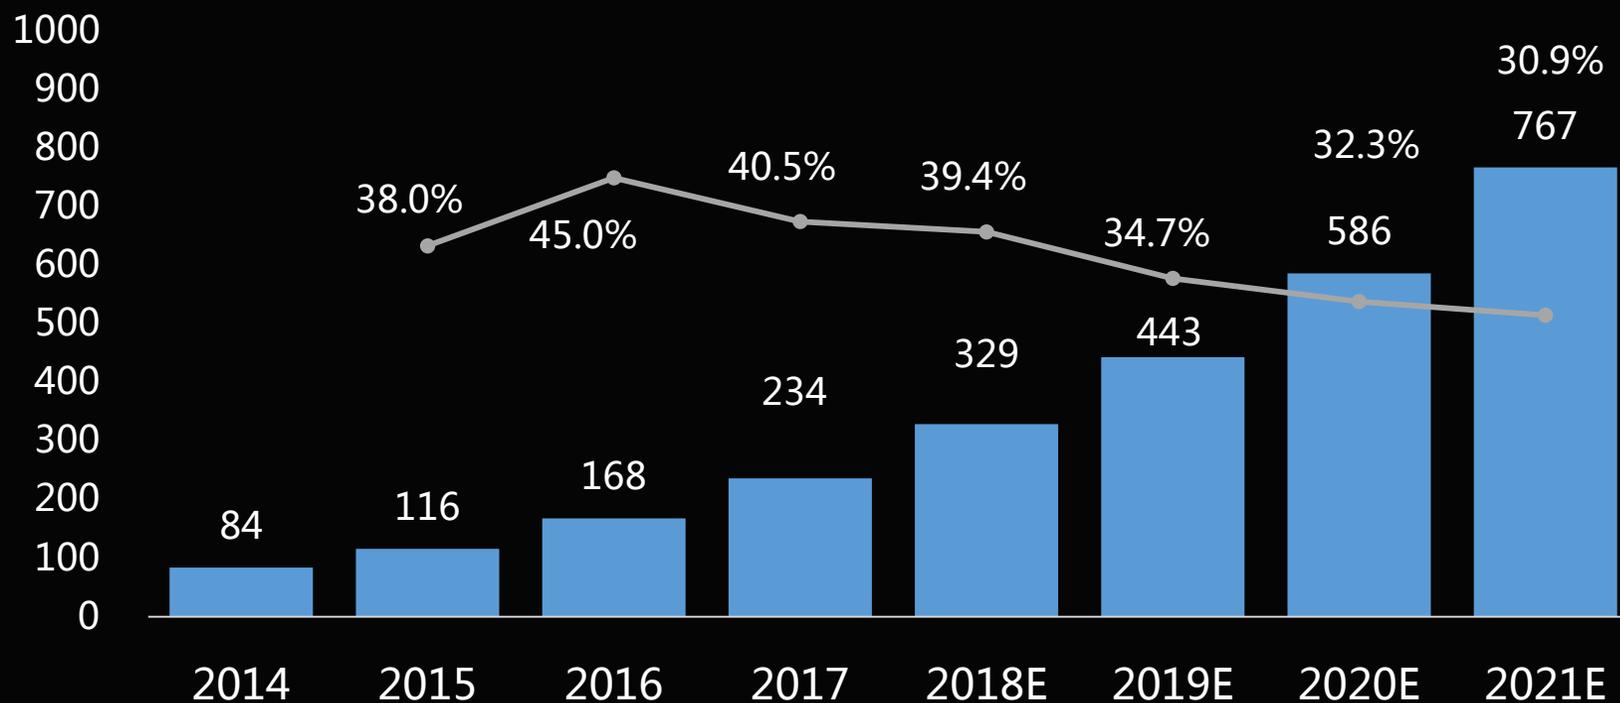
中国信息通信研究院结合对大数据相关企业的调研测算，2017年我国大数据产业规模为4700亿元人民币，同比增长30.6%。



注：大数据产业指以数据生产、采集、存储、加工、分析、服务为主的相关活动，包括数据资源建设、大数据软硬件产品的开发、销售和租赁活动，以及相关信息技术服务。

● ● ● 其中，核心产业规模234亿

大数据软硬件产品产值约为234亿元人民币，同比增长39%。





## 技术发展的大事务，大融合

1

**大数据分析技术**

OLAP，2000年代转向分布式，快速迭代，软硬&AI融合

2

**大事务处理技术**

OLTP，生产系统/生命线/门槛高，目前正在转向分布式

3

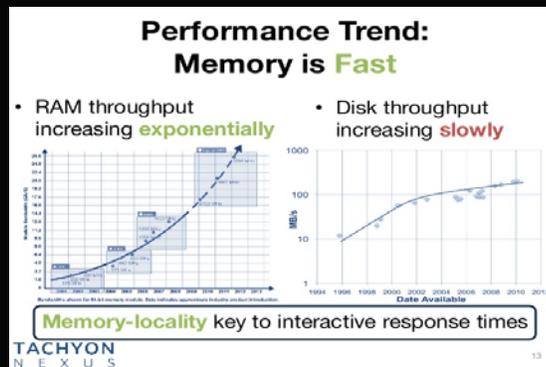
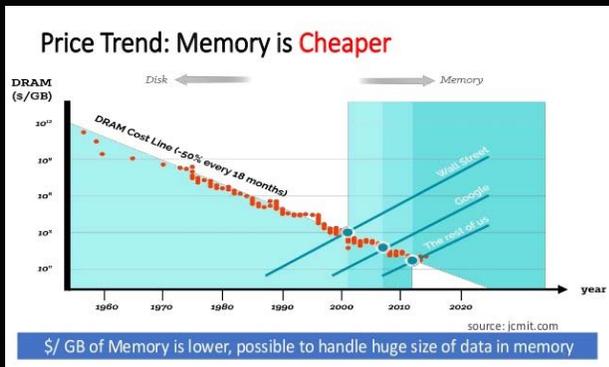
**大数据流通技术**

用技术手段缓解数据共享矛盾，以往技术力量被低估



# OLAP的分布式之旅

2000开启分，近几年快速迭代，软硬协同成为趋势

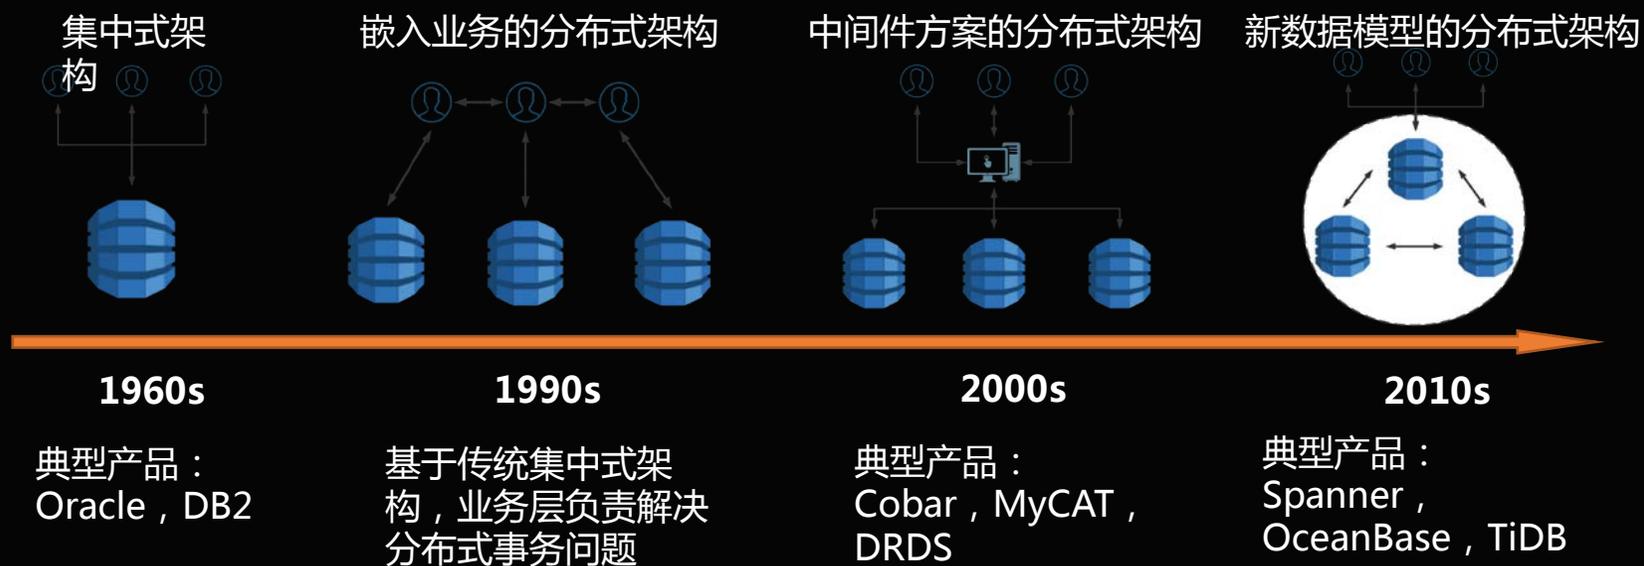


存储越来越快：NVRAM有可能替代DRAM成为主流

计算成为瓶颈：由单核向多核扩展，演变为GPU、FPGA和ASIC异构计算

# ●●● OLTP迎来分布式拐点

事务型数据处理业务的高实时、强一致性、高并发、高可靠强要求成为集中式向分布式转型的难点。但随着核心业务量增长，OLTP向分布式转型将迎来拐点。



● ● ● 大数据带来了隐私的烦恼

某耿直BOY: 中国人多数情况下愿意用隐私交换便捷性

欧盟GDPR: 个人隐私数据的明确同意和流动权，精益求精



● ● ● 大数据遭遇了“7年之痒”

“大数据：创新、竞争和生产率的下一个前沿”

2011年5月，麦肯锡

“大数据时代降临”

2012年2月，纽约时报



● ● ● 大数据的烦恼，只因又一个三角困境

国家安全



个人隐私

便利性

“不可能既享有100%的安全又享有100%的隐私，而且没有丝毫不便，我们不得不做出选择。”

2013年，奥巴马，时任美国总统

● ● ● 这些意味着什么？

**短期：一些大数据应用真正落地了**

**中期：保护隐私是未来3年工作的重中之重**

**长期：已20余年的互联网免费模式终结的开始？**



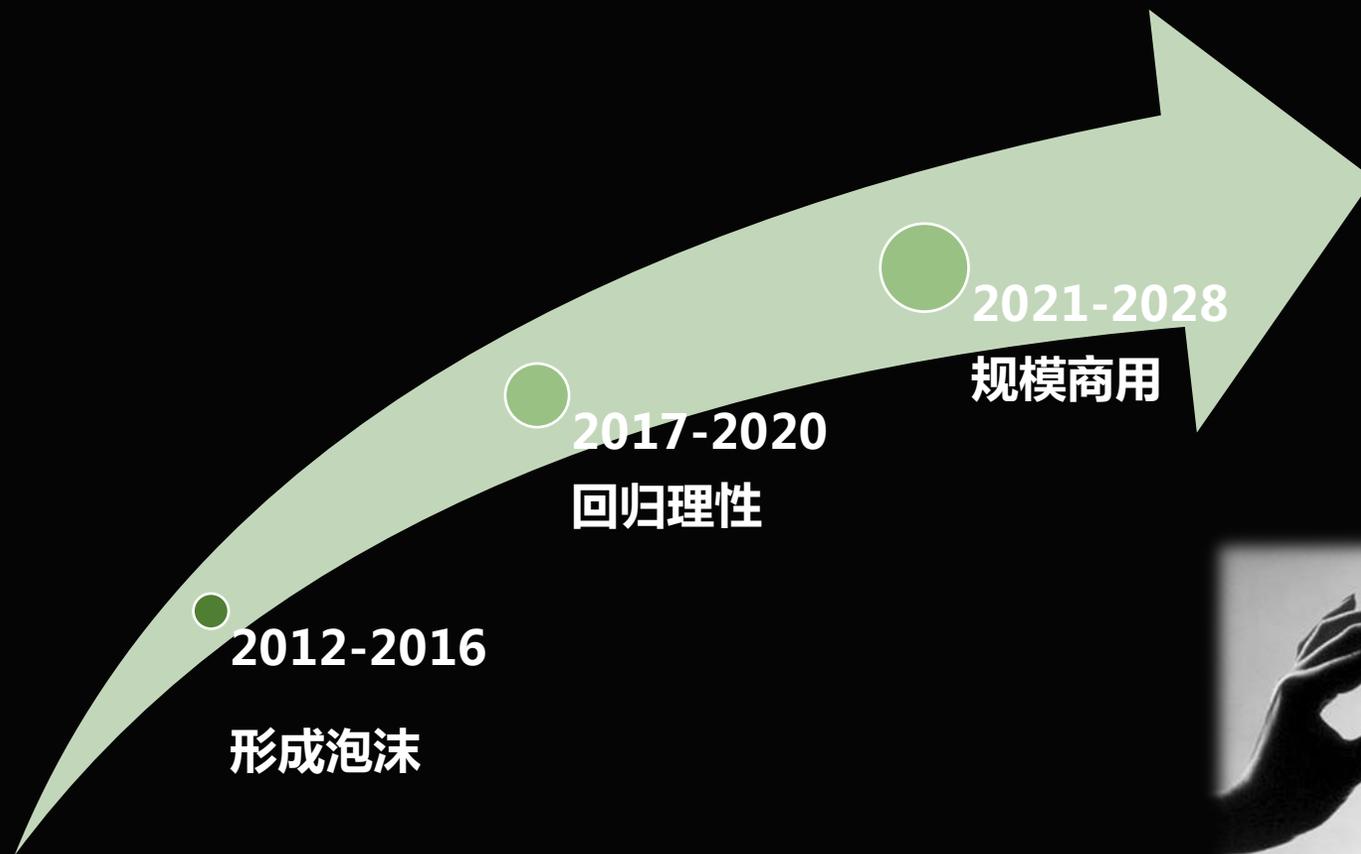
● ● ● Now , 2018年

从重点是发展 , 到重点是合规

从高估短期影响 , 到低估长期影响



● ● ● 从时间看，要准备过段“紧日子”



## ●●● 从应用看，金融大数据的痛点还很多

- 金融领域业务运营和创新需要数据治理标准
  - 统一数据指标体系
  - 元数据和主数据管理方案
  - 统一数据采集、交换标准
  - 形成数据质量监测、运营体系
- 金融监管机构对金融领域监管依赖于大数据治理
  - 数据的报送格式
  - 数据质量要求

### 2018年3月银监会（原）发布《银行业金融机构数据治理指引》

- ✓ 将数据治理纳入公司治理范畴，与公司治理评价和监管评级挂钩。
- ✓ 鼓励开展制度性探索
- ✓ 建立良好数据文化，树立数据是银行重要资产和数据应真实客观的理念与准则。
- ✓ 加强数据应用，发挥数据价值
- ✓ 强化数据安全意识，依法合规采集数据，防止过度采集、滥用数据，依法保护客户隐私。

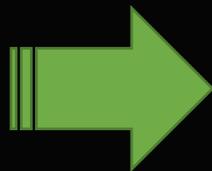
● ● ● 从算法看，关键是透明性

2018年

算法黑箱

算法歧视

算法疫情



2020年

开放算法

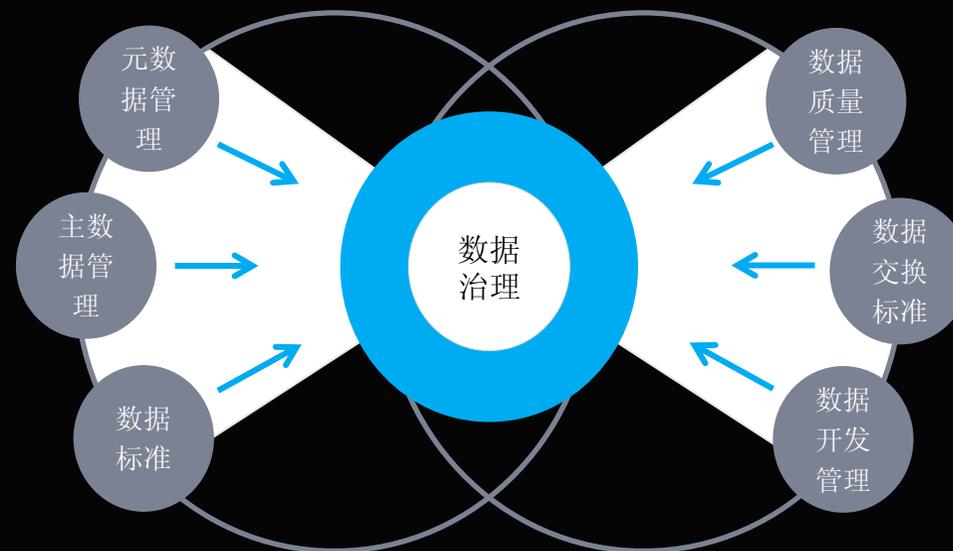
算法中立

监管算法



● ● ● 从资产看，KNOW 2 HOW

刚知道了数据是资产  
还不知道如何变资产



● ● ● 从流通看，现在是男耕女织，30年后的诺奖诞生地



从农工产品贸易到数字产品贸易的转折，从工业经济学到数字经济学的跃迁

# ●●● 新流通，新技术



**安全多方计算：**应用于联合数据分析、数据安全查询、数据可信交换等



**区块链：**应用于数据存证确权、精细数据授权使用、数据溯源等

同态加密

零知识证明

群签名

环签名

差分隐私

**技术特点**

可在不解密的情况下对密文进行计算和分析

证明者无需任何事件相关数据，就能向验证者证明事件的真实可靠

能为签名者提供较好的匿名性，同时在必要时又通过可信管理方追溯签署者身份

不需要分配指定的密钥，无法撤销签名者的匿名性

具有严谨的统计学模型，能够提供可量化的隐私保证

**适用场景**

云计算、电子商务、物联网等

电子商务、金融、银行、电子货币等

公共资源管理、电子商务、电子货币等

云存储、电子货币等

电子商务、物联网等

● ● ● 从价值看，发掘新价值新用途？

## 石油

早期

冶炼：煤油  
用途：照明

1879年

爱迪生危机

危机后

冶炼：汽油  
用途：动力

## 大数据

早期

冶炼：用户画像  
用途：营销风控

2018年

隐私危机

危机后？

冶炼：？  
用途：“非人”？

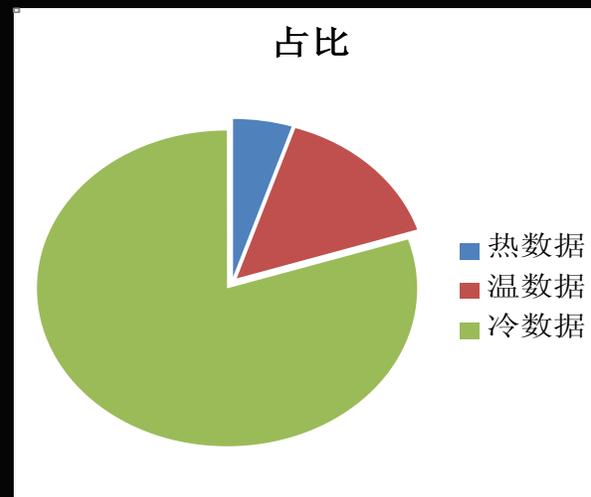
● ● ● 从归宿看，日益细分

普通数据，大多会“进冷宫”

GDPR，隐私数据能“要灭绝”

区块链，价值数据会“得永生”

介质原因，很多数据会“被失踪”



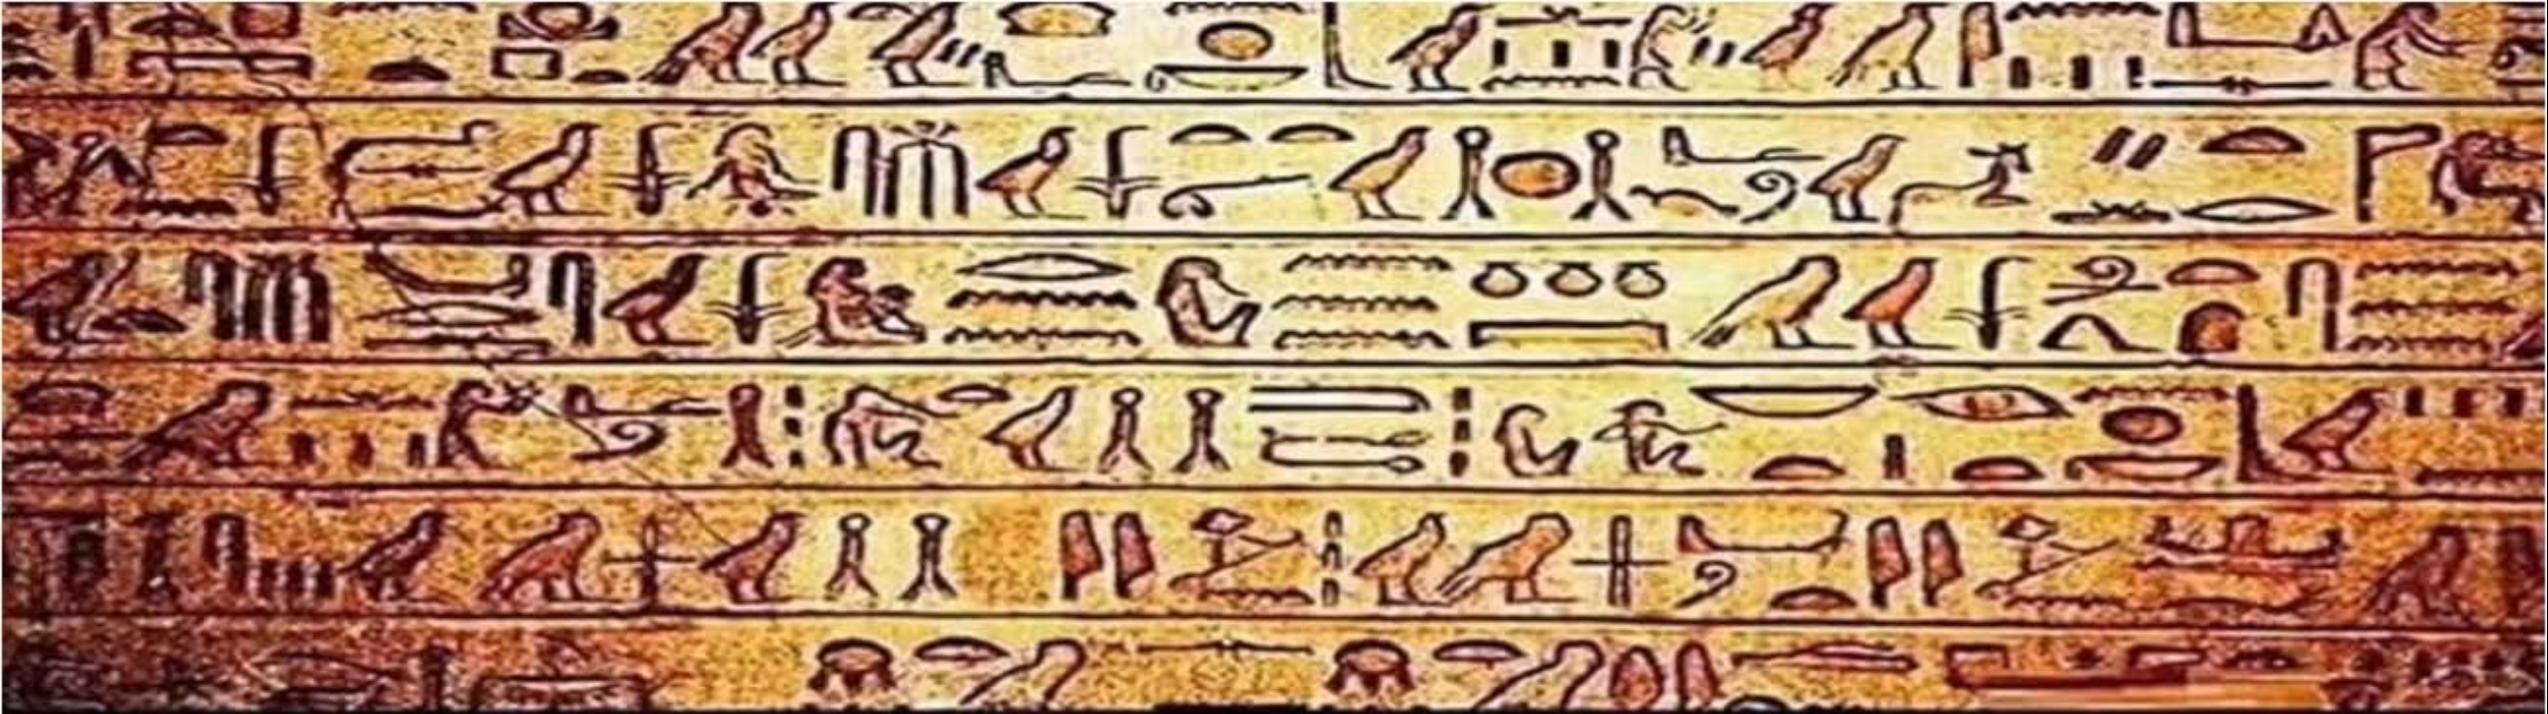
● ● ● 从风险看，哪里有风险哪里就有保险



● ● ● 未来，被机器遗忘将是一种幸福



千年后，如何考古呢？



公元前2018

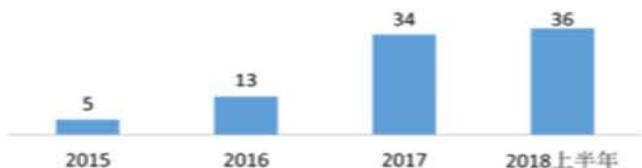
对

公元后2018



# 信通院大数据工作介绍

从2015年6月到现在，大数据产品能力评测形成了基础能力和性能专项两类评测，形成评测标准15项。截至第六批评测，已经有55产品通过评测，完成88个测试。信通院大数据部共发布白皮书和大数据调查报告10本，覆盖知识图谱、数据流通技术、分布式数据库、工业大数据架构、数据资产管理实践等方向。



类别	名称	目前版本
基础平台产品	大数据产品 Hadoop平台 第1部分：技术要求	1.0
	大数据产品 Hadoop平台 第2部分：基础能力测试方法	2.0
	大数据产品 Hadoop平台 第3部分：性能测试方法	2.0
	大数据产品 MPP数据库 第1部分：技术要求	1.0
	大数据产品 MPP数据库 第2部分：基础能力测试方法	1.5
	大数据产品 MPP数据库 第3部分：性能测试方法	1.0
数据管理产品	大数据产品 数据集成工具 第1部分：技术要求	1.0
	大数据产品 数据集成工具 第2部分：基础能力测试方法	1.0
	大数据产品 数据管理平台 第1部分：技术要求	1.0
	大数据产品 数据管理平台 第2部分：基础能力测试方法	1.0
分析工具	大数据产品 商务智能 (BI) 分析工具 第1部分：技术要求	1.0
	大数据产品 商务智能 (BI) 分析工具 第2部分：基础能力测试方法	1.0
	大数据产品 数据挖掘平台 第1部分：技术要求	1.0
	大数据产品 数据挖掘平台 第2部分：基础能力测试方法	1.0
应用和解决方案	大数据解决方案 用户行为数据分析 第1部分：技术框架和指标体系	1.0



电信

工业

政务

金融

# 信通院大数据工作介绍

## 国内数据资产管理理论框架的构建者

数据成为资产已经形成共识，如何进行资产化是未来的研究重点，我们梳理了《数据资产管理实践白皮书》，在传统数仓构建的方法论基础上探索基于数据湖架构的管理框架。



## 国内分布式事务数据库标准和基准测试工具的制定者

- 制定业内首个《大数据产品 分布式事务数据库 第一部分：技术要求》
- 制定业内首个《金融分布式事务数据库白皮书 (1.0) 》



## 国内数据流通技术与政策研究的桥头堡

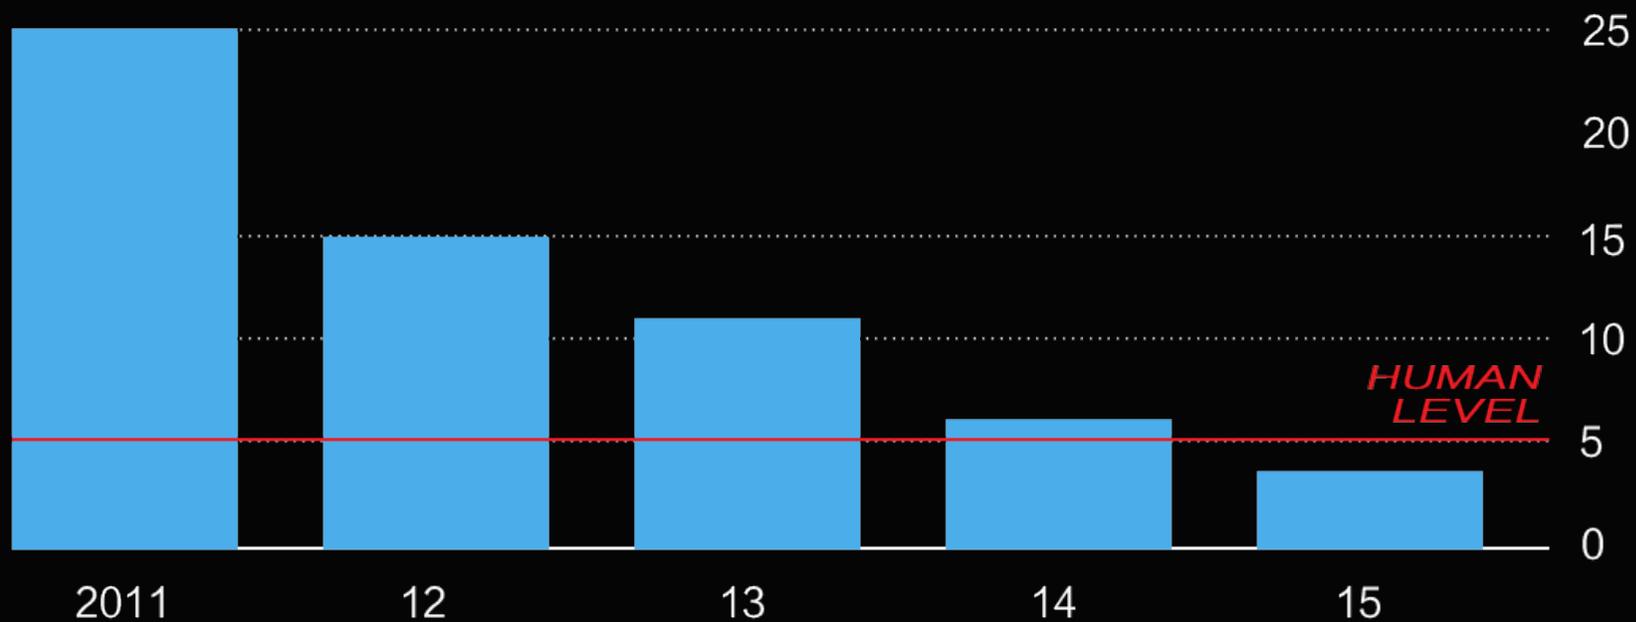
- 建立了首个数据流通合规的评测体系，完成8家企业的评测。
- 支持网信办发布“大数据行业自律公约”，发布《数据流通技术白皮书 (1.0) 》。
- 形成4个数据流通标准



## ② 人工智能

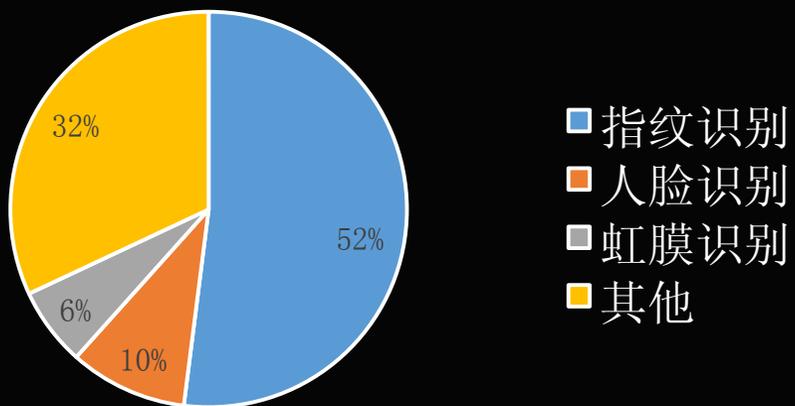
# ● ● ● 机器视觉/语音识别已超越人类.....

Ever cleverer  
Error rates on ImageNet Visual Recognition  
Challenge, %



Sources: ImageNet; Stanford Vision Lab

# ● ● ● AI的典型场景



数据来源：平安证券

## 监控系统

- 车牌识别
- 嫌犯追踪
- 火灾识别

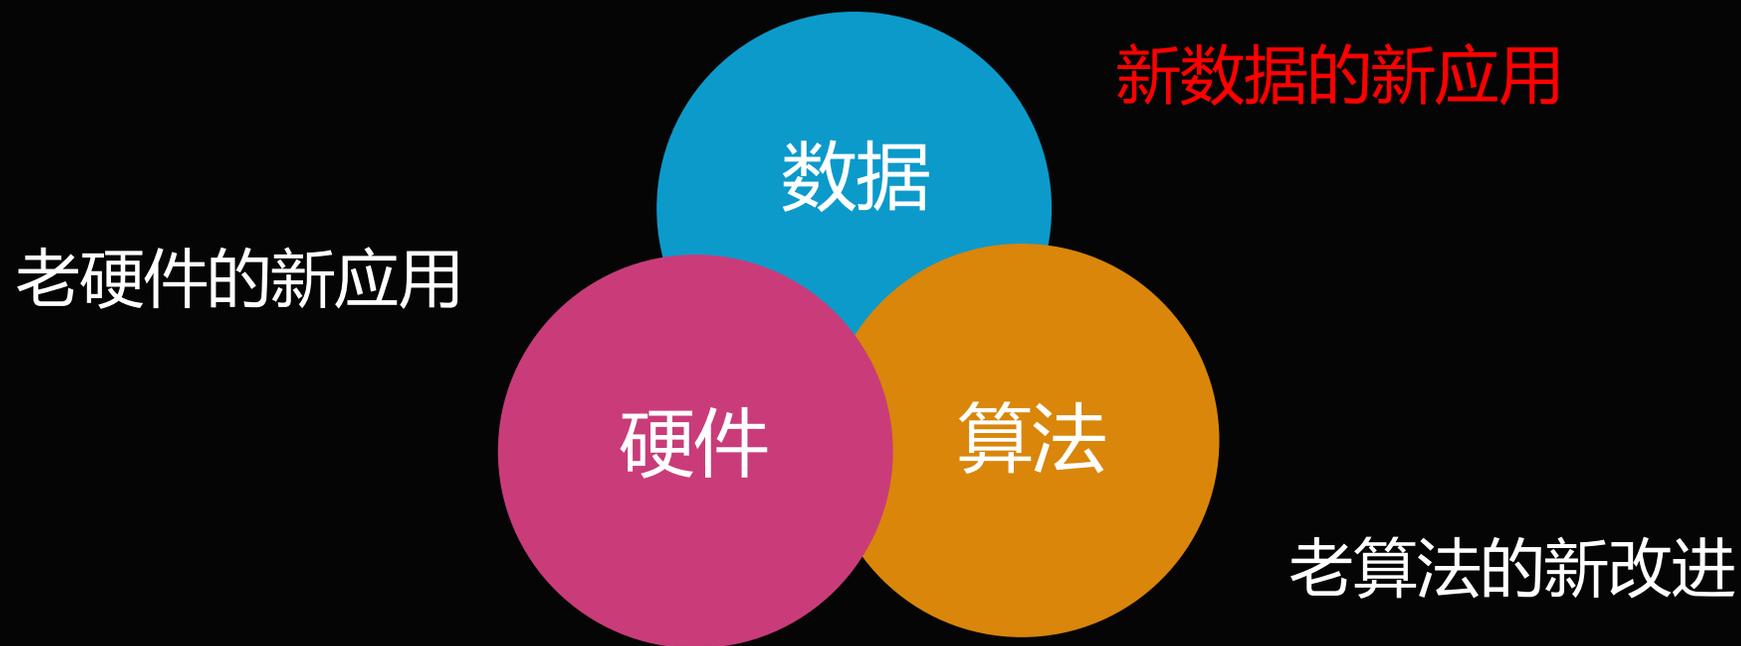
## 行为识别

- 情绪识别
- 动作识别
- 色情内容检测

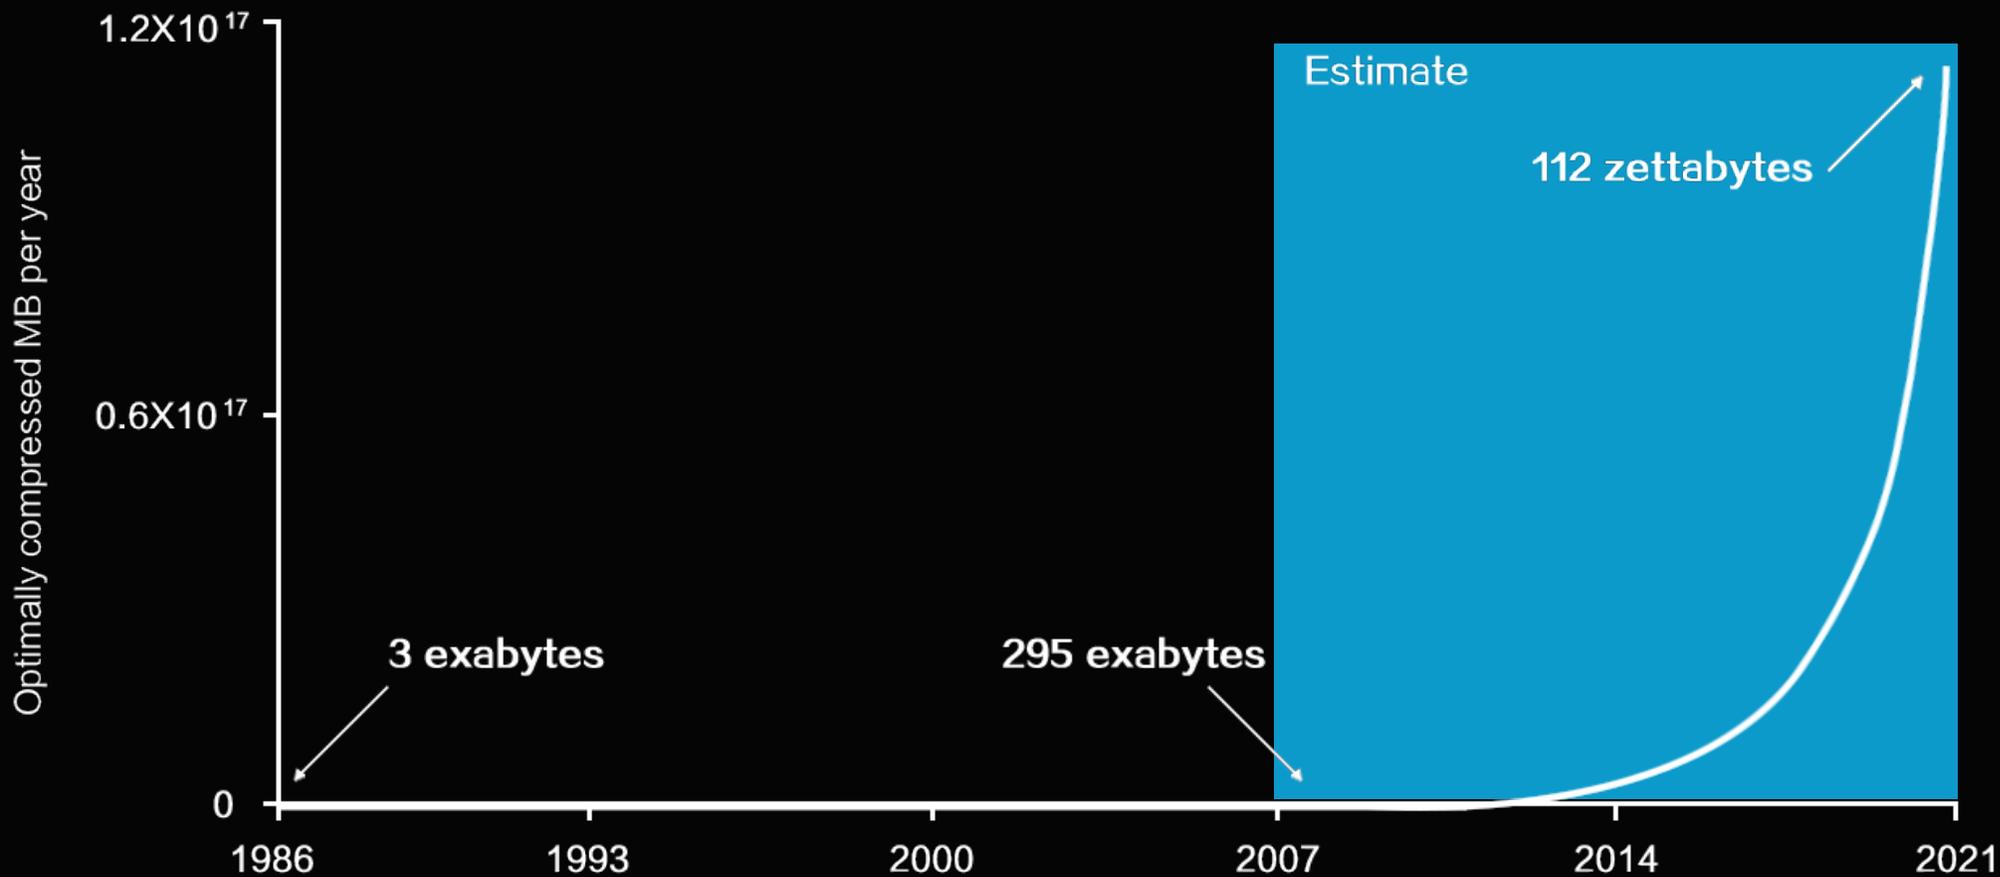
## 电商营销

- 用户画像
- 广告植入
- 门店营销

● ● ● AI的复兴



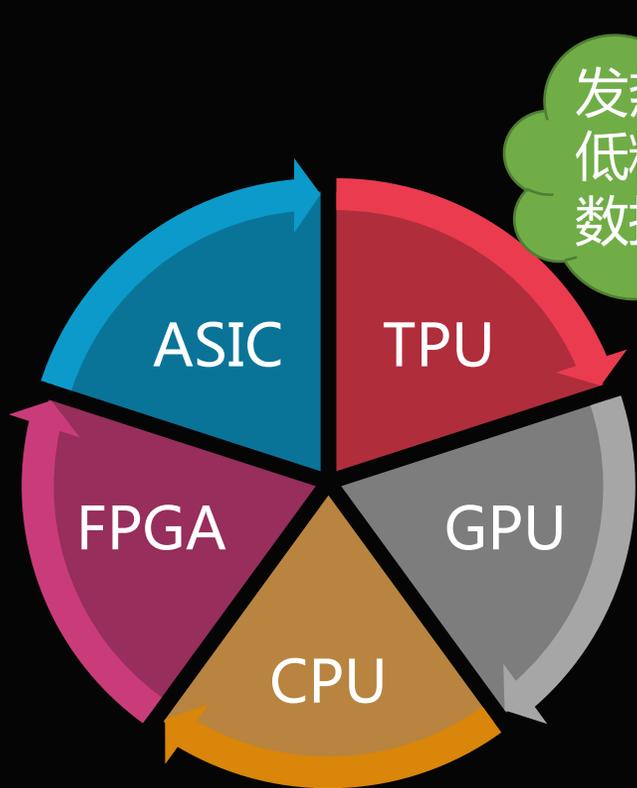
● ● ● 现在，训练数据是短板



图片来自网络

数据是人工智能的燃料 —— 吴恩达

● ● ● 未来，AI专用硬件有机会



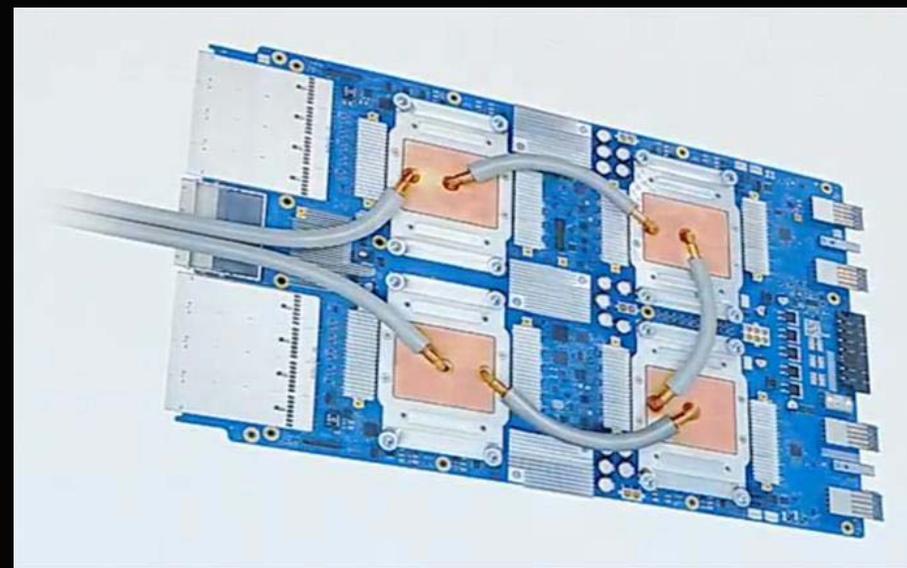
发热量的控制  
低精度容忍  
数据本地化

GPU是AI隔壁的老王

就像智能手机需要ARM，AI可能也需要新芯片

## ●●● 液冷：再大的风，也吹不凉它那滚烫的芯了

每平方米功率	数据中心密度	制冷方式
1.2 KW/机柜以下	超低密度数据中心	房间级-风冷
1.2-2.7 KW/机柜	低密度数据中心	房间级-风冷
2.7-7.5 KW/机柜	中、低密度数据中心	行间级-风冷/水冷
7.5-18 KW/机柜	中、高密度数据中心	行间级-水冷：液冷-冷板式
18-30 KW/机柜	高密度数据中心	液冷-冷板式：液冷-浸没式
30 KW/机柜以上	超高密度数据中心	液冷-浸没式



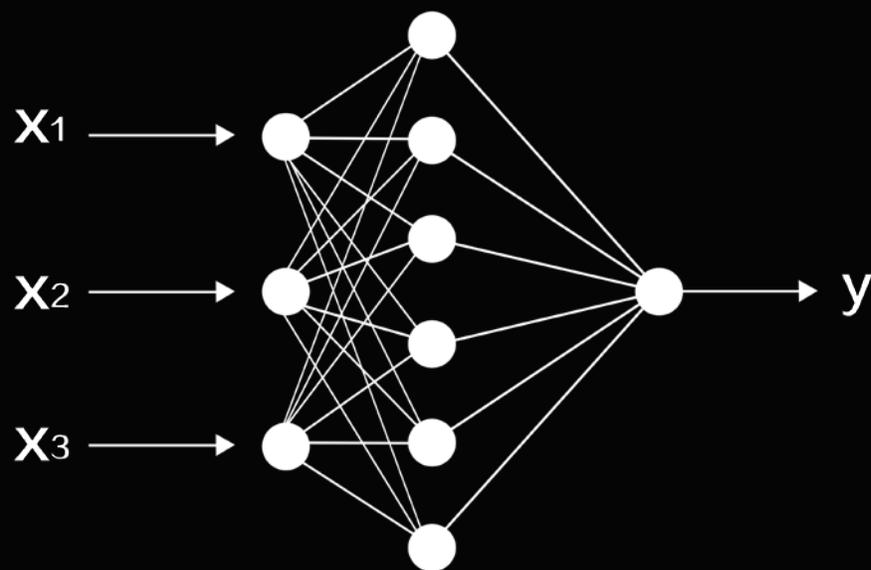
TPU 3.0的性能相比TPU 2.0有8倍的提升，专门设计了一套水冷系统降温。

2018年5月，

Google I/O大会

● ● ● 接下来，最需要突破的还是算法

机器学习

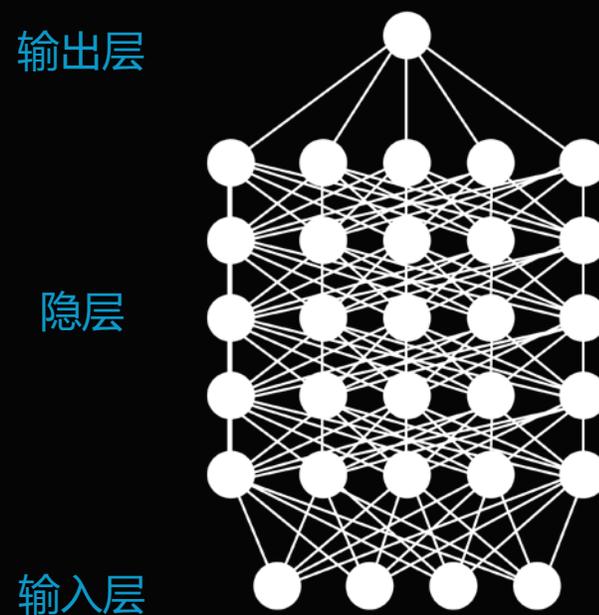


输入层

隐层

输出层

深度学习



输出层

隐层

输入层

输含多个隐层的深度学习模型

● ● ● 3年里，AI新工种将不断出现



数据民工

ImageNet

167个国家

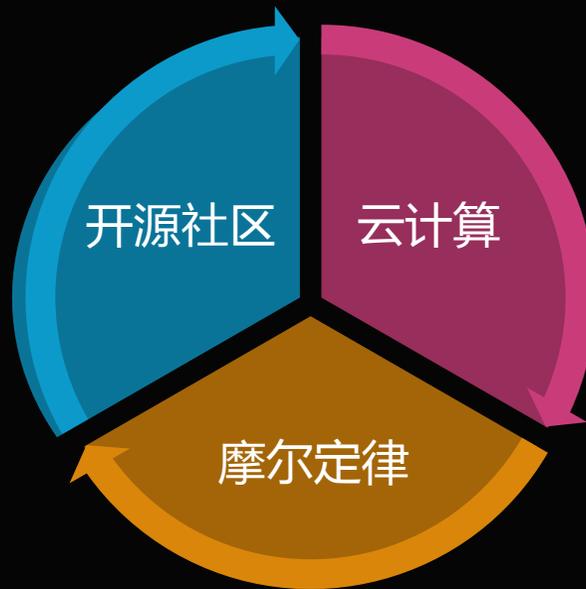
近5万人，2年

标记近10亿图片

得到1500万张

# ●●● AI的三大支撑

像Android一样做生态



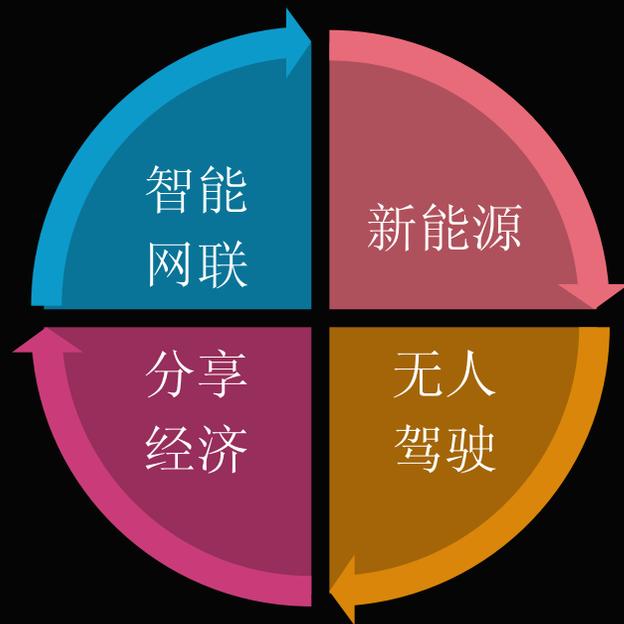
AI/FPGA/GPU  
as a Service

AI 是个“算老虎”

## ●●● AI为应用赋(智)能

- 1、人脸识别走向**商用**
- 2、智能音箱**爆发**(短期?)
- 3、智能服务机器人已开始在临床上**尝试**应用  
骨科、腹腔镜等手术机器人
- 4、高级智能辅助驾驶系统 (ADAS) **逐渐**成熟

# ●●● 汽车业，AI应用的新金矿



## 路线之争

- 为汽车增加智能
- 为计算机增加轮子

软件定义汽车

重新定义道路

## ● ● ● 3年里，AI将遇到技术的天花板

算法：还是黑盒子，调参主要靠运气

算力：蛮力计算的巨兽，摩尔定律的衰老

数据：有监督学习，数据改变信仰

其它：无记忆，无推理，无法与其它方式融合

● ● ● 理论已证明，至少这代AI不会觉醒

人的意识是非算法的，

基于图灵机的AI，无法建立起“自我”的概念，

未来控制人类的AI，不会基于图灵机。

●●● 人生最最痛苦的事情...

量子计算的时代还远未到来，

3年里，AI肯定**不会**控制人类。

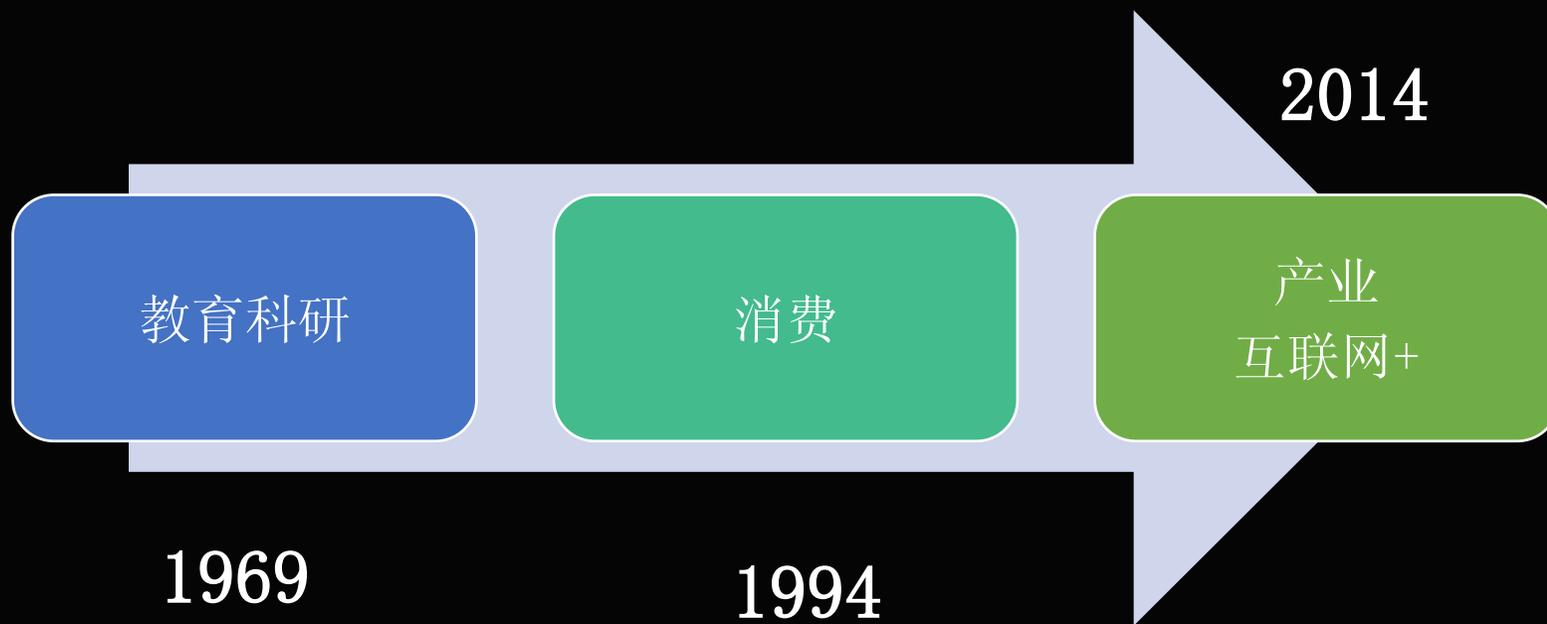
人还在，工作却没了。

不要害怕

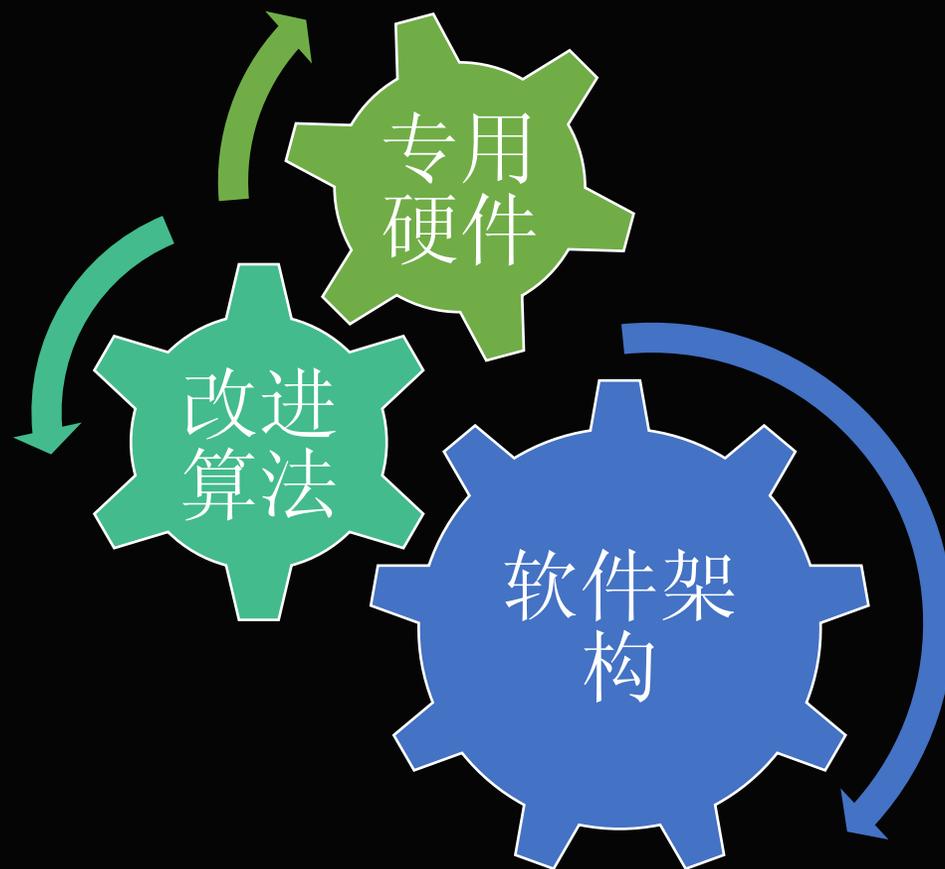


## ③ 小结

●●● 产业互联网时代，金融本是数据产业



● ● ● 当摩尔定律老去...

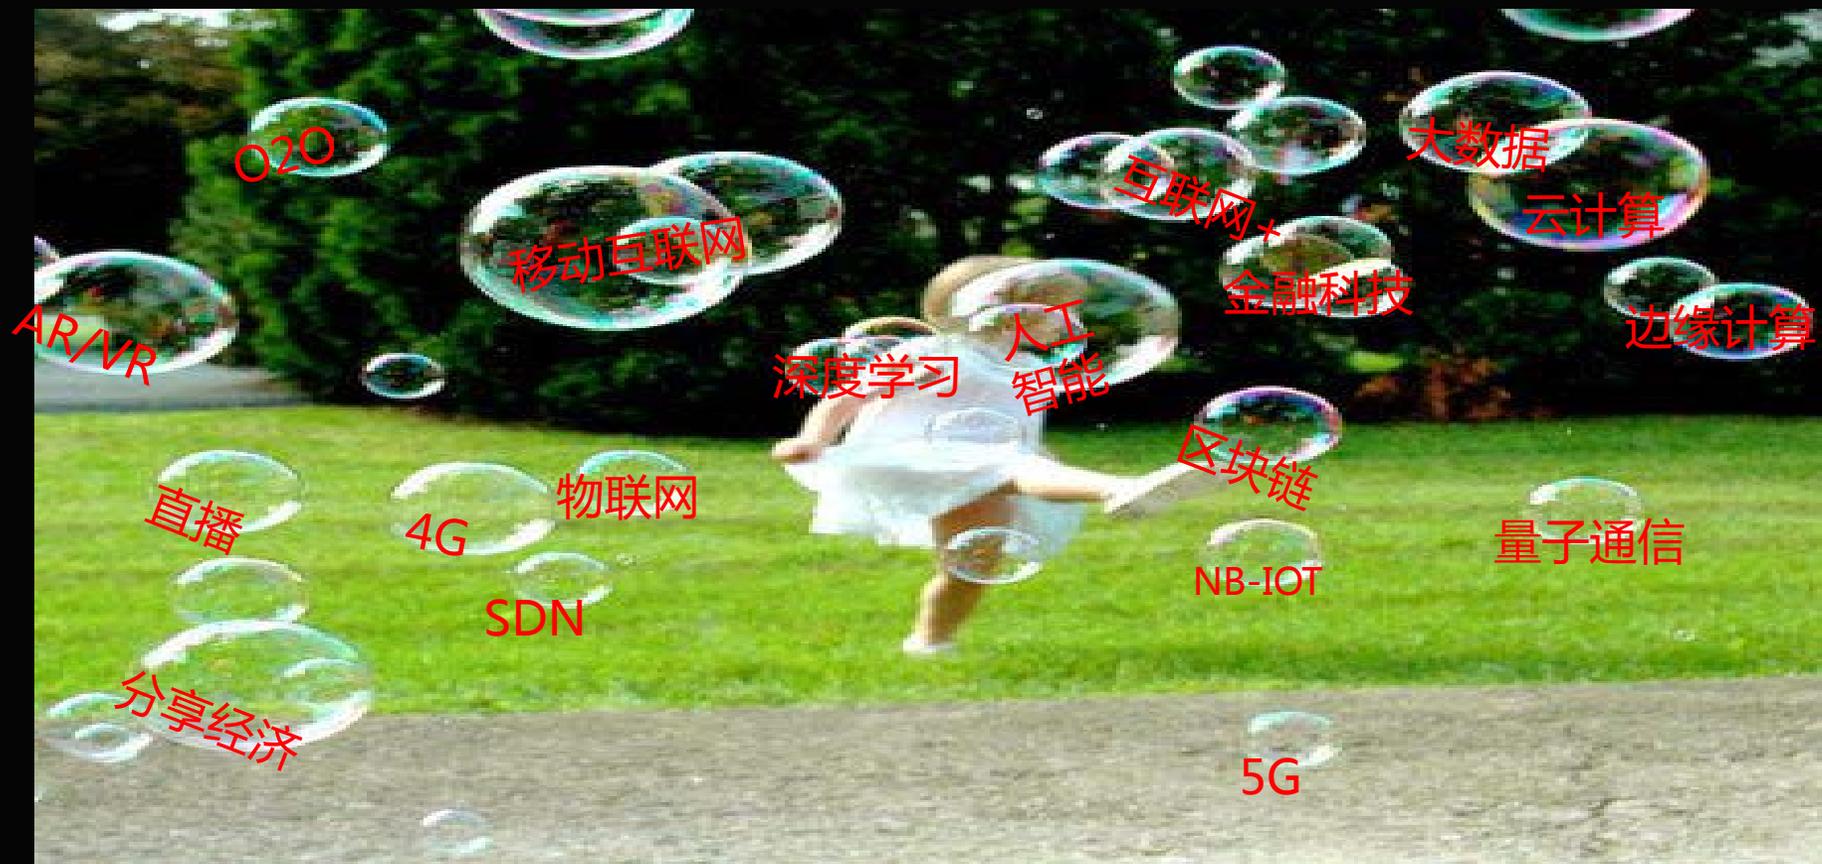


● ● ● **当前行业发展的主要矛盾**

**100年前，  
是信息技术跟不上工业革命的步伐**

**100年后，  
是人类社会跟不上信息革命的步伐**

● ● ● 这10年，我们曾经追过的...



● ● ● 2018年，浪潮之巅？

始于2008年的这波技术浪潮，

**滞涨期**即将到来？

● ● ● 接下来的主要机会

...互联网、大数据、人工智能与实体经济深度融合。

# 谢谢！

个人观点

仅供交流



微信订阅号：何所思