



数据仓库 开源融合 极致演绎

2016 | Teradata 大数据峰会

Hortonworks  
与Apache开源社区

王健夫

Hortonworks 中国区 销售总监

13910191946

# 议程

- Apache开源社区
- Hortonworks的介绍
- Hortonworks的开源理念
- 案例分享
- 问答环节



# Apache软件基金会

Apache软件基金会（也就是Apache Software Foundation，简称为ASF），是专门为支持开源软件项目而办的一个非盈利性组织。在它所支持的Apache项目与子项目中，所发行的软件产品都遵循Apache许可证（Apache License）

项目管理委员会

项目管理委员会（Project Management Committees，简称为PMC），主要负责保证一个或者多个开源社区的活动都能运转良好

Apache 图标



# Apache



# Apache社区的重要项目

- Apache Hadoop
  - 开源大数据技术的鼻祖，包括分布式文件系统，资源管理框架和计算框架。
- Apache NIFI
  - 数据流采集和传导数据, 可以将物联网各类型的数据安全传导各类数据库
- Apache Spark
  - UC Berkeley AMP lab所开源的类Hadoop MapReduce的通用并行框架
- Apache TEZ
  - Tez是Apache开源计算框架, 它可以将多个有依赖的作业转换为一个作业从而大幅提升DAG作业的性能
- Apache Ambari
  - Apache Ambari是一种基于Web的工具, 支持Apache Hadoop集群的供应、管理和监控

.....




# Apache社区对Hadoop发展的作用



- 开源已经成为一种趋势
  - 随着计算机技术的发展，尤其是互联网技术和相关企业的兴起，开源软件在操作系统、编译工具链、数据库、WEB服务器、移动操作系统等各个方面已经成为企业的主流选择
- Apache开源社区在主导现代Hadoop数据架构
  - Hadoop的相关组件繁多,迭代迅速,任何单一的公司或者组织都无法全面的推动,需要大数据生态系统中的很多公司集体创新.
  - Apache社区中.汇聚了诸多优秀的公司与工程师,他们一起创新推动Apache社区的发展,时至今日, Hadoop技术的发展主要是由Apache社区推动。

# Hadoop(概念拆分)

- 一般人们会对Hadoop有两种不同的解释
- Apache Hadoop项目
- 其他Apache Hadoop相关的项目集合



# ASF培养的Hadoop动物园





# Hadoop 周期表

Apache Hadoop 有多个分支版本

核心	1 <b>M</b> MAPREDUCE	2 <b>H</b> HDFS	26 <b>Y</b> YARN								
处理											
分析	0 <b>So</b> SOLR	28 <b>Te</b> TEZ	33 <b>St</b> STORM	6 <b>Ma</b> MAHOUT	39 <b>Da</b> DATAFU	5 <b>Z</b> ZOOKEEPER	22 <b>Am</b> AMBARI	17 <b>Sq</b> SQOOP	40 <b>Pa</b> PARQUET	32 <b>Se</b> SENTRY	20 <b>O</b> OOZIE
管理											
数据管理	3 <b>Hb</b> HBASE	30 <b>Sp</b> SPARK	4 <b>P</b> PIG	8 <b>Hi</b> HIVE	59 <b>Im</b> IMPALA	11 <b>W</b> WHIRR	16 <b>F</b> FLUME	19 <b>K</b> KAFKA	27 <b>Kn</b> KNOX	13 <b>Hu</b> HUE	38 <b>Sl</b> SLIDER
安全											
其他											

# Hadoop及其相关元素表

其他Hadoop相关的ASF项目以及非ASF项目

7 <b>Ha</b> HAMA	31 <b>Sa</b> SAMZA											61 <b>Ku</b> KUDU	15 <b>Mu</b> MRUNIT	EMC ISILON
9 <b>C</b> CASSANDRA	37 <b>Fl</b> FLINK	48 <b>As</b> ASTERIXDB	53 <b>Ap</b> APEX	14 <b>T</b> TAJO	36 <b>Mq</b> MRQL	54 <b>Hq</b> HAWQ	12 <b>Ch</b> CHUKWA	10 <b>A</b> AVRO	45 <b>N</b> NIFI	64 <b>Ar</b> ARROW	18 <b>B</b> BIGTOP	MAPR-FS		
21 <b>G</b> GIRAPH	43 <b>I</b> IGNITE	50 <b>Ge</b> GEODE	58 <b>Sg</b> S2GRAPH	25 <b>D</b> DRILL	44 <b>K</b> KYLIN	55 <b>Md</b> MADLIB	29 <b>Fa</b> FALCON	24 <b>Cr</b> CRUNCH	51 <b>At</b> ATLAS	42 <b>R</b> RANGER	34 <b>Tw</b> TWILL	IBM BIG SQL		
23 <b>Ac</b> ACCUMULO	47 <b>Ti</b> TINKERPOP	53 <b>Tr</b> TRAFODION	63 <b>Be</b> BEAM	35 <b>Ph</b> PHOENIX	46 <b>Z</b> ZEPPELIN	59 <b>Sm</b> SYSTEMML	49 <b>My</b> MYRIAD	41 <b>Ca</b> CALCITE	56 <b>Ry</b> RYA	57 <b>Ea</b> EAGLE	62 <b>Me</b> METRON	AMAZON S3		

核心

分析

数据处理

其他

处理

管理

安全

非ASF

# 议程

- Apache开源社区
- Hortonworks的介绍
- Hortonworks的开源理念
- 案例分享
- 问答环节

# 关于Hortonworks



成立于 2011 年

由Yahoo最初的24名  
原创Hadoop的架构师及软件工  
程师创立

800+

雇员

1500+

合作伙伴

## 客户概要

- 800+客户（截至2015年底）
- 2015年Q3一个季度增加152位客户
- 纳斯达克上市企业, 代码：HDP


## Hortonworks 数据平台

- 一个适用于任意程序和数据且完全开放的多租户数据服务平台
- 具备了一个稳定的企业级平台服务所应具有的安全性，可操作性和可管理性

## 协助客户获得成功的伙伴

- 一个致力于满足企业级需求的开源社区的领导者
- 灵活的订阅模式为企业提供Hadoop技术支持服务

# Hortonworks 引领市场



## Hortonworks领导者

在Hadoop市场，Hortonworks为40%的全球100强提供支持，包括：

- 75% 的全球电信运营100强
- 65% 的保险公司
- 55% 的全球制造100强
- 46% 的全球零售100强
- 40% 的全球健康保险100强

“Hortonworks热爱开源创新，并以此为生。”

# Hortonworks的营收



Hortonworks: \$121.9 million in 2015 revenues



Hortonworks is the fastest software company ever to reach \$100 million in revenues.


FIGURE 1

Fastest To Reach \$100mn in Revenue

Company	\$100mn Year	Founded In	Years to \$100mn	Company	\$100mn Year	Founded In	Years to \$100mn
Hortonworks*	2015	2011	4	FireEye	2013	2004	9
Salesforce	2004	1999	5	Intuit	1992	1983	9
Palo Alto	2011	2005	6	Microsoft	1984	1975	9
Workday	2011	2005	6	NetSuite	2007	1998	9
Informatica	2000	1993	7	Tableau	2012	2003	9
LogMeIn	2010	2003	7	Varonis	2014	2005	9
MobileIron	2014	2007	7	Red Hat	2003	1993	10
Citrix	1997	1989	8	Cornerstone	2012	1999	13
ServiceNow	2011	2003	8	Five9	2014	2001	13
Splunk	2011	2003	8	Paycom	2013	1998	15
Demandware	2013	2004	9	QlikTech	2008	1993	15

Source: Company Data, Barclays Research. Note: Hortonworks represents a potential future event

# Hortonworks 产品



# Hortonworks数据平台



数据管理

数据访问

数据治理

数据安全


平台运维

云端部署



由Apache Hadoop驱动

# Hortonworks数据平台



HDP 是业内唯一一款基于集中化架构 (YARN)、真正安全、可用于企业的开源 Apache™ Hadoop® 分布式系统。HDP 可满足静态数据的全部需求，助力实时客户应用程序，并提供可加速决策和创新进程的可靠分析

# Hortonworks数据流 采集, 传导 & 转换



由Apache NiFi驱动

## 采集所有类型的数据

通过高度安全的轻量级代理进行数据采集。

## 传导数据可信度高

传导点对点, 双向信息流

## 转换数据

在保留其来源及变化过程的元数据的同时转换数据。

## 过程完全透明可控

追踪数据的流, 图形到动态的调整。

## 数据安全并加密

企业级的授权服务, 能够频繁改变授权

## 灵活安全

可以将IOT的数据 安全可视化传到到任何数据源中


# 最简约的多数据源接入



数据处理  
和分析



数据源



ORACLE




数据存储



TERADATA  
APACHE  
HBASE



# Hortonworks支持UDA




# 议程

- Apache开源社区
- Hortonworks的介绍
- Hortonworks的开源理念
- 案例分享
- 问答环节




# Hadoop 发行版时间轴





# 最终的Hadoop 发行版厂商



# HDP的Apache项目

1 <b>M</b> MAPREDUCE	2 <b>H</b> HDFS	26 <b>Y</b> YARN	0 <b>So</b> SOLR	3 <b>Hb</b> HBASE	23 <b>Ac</b> ACCUMULO	28 <b>Te</b> TEZ	30 <b>Sp</b> SPARK	33 <b>St</b> STORM	4 <b>P</b> PIG	6 <b>Ma</b> MAHOUT	8 <b>Hi</b> HIVE	35 <b>Ph</b> PHOENIX
39 <b>Da</b> DATAFU	5 <b>Z</b> ZOOKEEPER	22 <b>Am</b> AMBARI	29 <b>Fa</b> FALCON	16 <b>F</b> FLUME	17 <b>Sq</b> SQOOP	19 <b>K</b> KAFKA	41 <b>Ca</b> CALCITE	50 <b>At</b> ATLAS	27 <b>Kn</b> KNOX	42 <b>R</b> RANGER	13 <b>Hu</b> HUE	20 <b>O</b> OOZIE
38 <b>Sl</b> SLIDER												

HDP 2.4 包含且仅包含了27个ASF项目

核心

分析

数据处理


其他

处理

管理

安全

# Hortonworks 100% 的开放



- **消除风险**

- 通过提供100% Apache开源技术避免锁定供应商风险。

- **社区创新最大化**

- 逾千家公司的逾千名开发者

- **无缝集成**

- 与其他业内领先的技术合作，共同进行工程开发


社区创新最大化

# Hortonworks的开源力量



Hortonworks的支持团队工作在 开源社区上，与Hadoop架构师、建设者和操作员直接互动。

- 最优秀的团队解决最复杂的Hadoop问题
- 全球丰富的Hadoop经验
- 作为领军者和创新者，只有Hortonworks能确保最新开放源代码产品的成功
- 与全球社区共同产生Hadoop路线图



Apache Project	Committees	PMC Members
<b>Hadoop</b>	<b>30</b>	<b>25</b>
Pig	5	5
Hive	18	6
Tez	16	15
HBase	6	4
Phoenix	4	4
Accumulo	2	2
Storm	3	2
Slider	11	11
Falcon	5	3
Flume	1	1
Sqoop	1	1
Ambari	36	28
Oozie	3	2
Zookeeper	2	1
Knox	13	3
Ranger	11	n/a
Spark	2	n/a
<b>TOTAL</b>	<b>169</b>	<b>113</b>



# Hortonworks社区的代码贡献率



Contributions to Apache Hadoop Core, 2011






Fig.3 Number of lines of code changed in 2014



# Hortonworks引领着Apache社区



APACHE HADOOP 提交者们

我们雇佣内容提交者。

-- 三分之一的Apache® Hadoop™ 项目内容提交者, 以及其他重要项目中的大部分。

我们的提交者富于创新

同时创新并扩展开放式企业 Hadoop和 Apache NiFi

我们影响着Hadoop的产品演变

通过我们在行业内的领导背景, 我们跟社区就关键要求保持沟通。




# Hortonworks的开源理念



Hortonworks的支持团队工作在 开源社区上，与Hadoop架构师、建设者和操作员直接互动。

- 与社区共同成长
- 注重分享意识，强调共赢
- 最优秀的团队解决最复杂的Hadoop问题
- 重点创新,广泛整合
- 与全球社区共同产生Hadoop路线图。



Apache Project	Committees	PMC Members
<b>Hadoop</b>	<b>30</b>	<b>25</b>
Pig	5	5
Hive	18	6
Tez	16	15
HBase	6	4
Phoenix	4	4
Accumulo	2	2
Storm	3	2
Slider	11	11
Falcon	5	3
Flume	1	1
Sqoop	1	1
Ambari	36	28
Oozie	3	2
Zookeeper	2	1
Knox	13	3
Ranger	11	n/a
Spark	2	n/a
<b>TOTAL</b>	<b>169</b>	<b>113</b>



# ODP开放标准数据平台



ODP开放标准数据平台  
Hortonworks  
OpenDataPlatform.org

PLATINUM

GE Hortonworks IBM Infosys

INTERNATIONAL TELCO Pivotal SSAS

GOLD

altiscale Capgemini CenturyLink EMC<sup>2</sup>

PLDT splunk> TERADATA verizon

vmware wandisco

# 议程

- Apache开源社区
- Hortonworks的介绍
- Hortonworks的开源理念
- 案例分享
- 问答环节

# Hortonworks: 多维度欺诈检测



项目：美国跨国  
银行与金融服务  
公司

客户：服务超过  
5000万客户和小  
企业

200K + 员工


## 问题：

- ✓传统的欺诈检测模型只考虑金融事件
- ✓评分模型大部分是基于规则的和已发生的事件信息
- ✓正确的对客户的综合的角度评价需要很多非金融事件信息
- ✓传统的存储和平台架的限制了基于大规模历史数据的规则模拟

## 解决方案：

- ✓金融和非金融性事件对客户进行多角度综合历史视图，进行闭环分析，不断提高检测精度
- ✓基于历史活动数据规则模拟测试
- ✓机器学习可以基于历史活动数据对欺诈活动做进一步分析

# Hortonworks: 多维度欺诈检测



# 议程

- Apache开源社区
- Hortonworks的介绍
- Hortonworks的开源理念
- 案例分享
- 问答环节



# Apache社区投入是否值得

- 开源社区带来的收益
- 快速创新，快速推出产品
- 共享技术，回报社区，提升能力
- 吸引人才
- 吸收整个社区的贡献
- 提高软件质量
- 提升社区的影响力，引导开源技术标准

# 私有化Hadoop的误区

- 私有化Hadoop技术的误区
- 很多Hadoop发行商借助Apache社区的技术,发展某些自己私有化的技术,在某些应用下确实能够解决一部分问题,但是这种私有化的技术由于只有自己去发展,技术会越来越重,而且越来越少人支持,所以离Hadoop的主要发展会越来越远



谢谢!

2016/5/6

