

大数据应用 ——数据安全和数据分析

周鑫

英特尔中国研究院

工作方向

- 关注实体行业
- 数据分析带动应用
- 数据将走上开放、共享和交易之路
- 关注沉淀的数据和实体来源的数据



案例分享




- 健康医疗

- 肿瘤研究


- 云服务

- ERP SaaS

实体行业推广的问题小结



数据的困境




基础设施的困境

- 集中 vs. 分散
 - 拥有权和使用权
- 回报效益的决定性因素、渐进式研究
- 基于去隐私化的技术对数据分析算法和平台的重构
- 数据服务
 - 稳定持续的数据服务提供平台

工作分享 —— Data Coffeehouse

- 可信任云平台建设
- 数据分享和数据分析平台建设


可信任云平台的目标问题



- 安全信任问题是一个深度的全栈的问题
 - 任意部位都可能成为突破点
- 通常的解决方案是基于软件，从 OS 开始
 - 用户认证、授权
 - 文件系统 ACL、防火墙
- 云服务使得问题复杂，从 OS 开始的解决方案不再足够
 - 硬件隔离使得威胁多样化，立体化
- 必须从硬件开始
 - 硬件认证
 - 主 OS 认证
 - 远程信任链管理


可信云平台综述

- 可信的运行环境
 - 硬件上基于 Intel TXT/TPM 技术
 - 软件上基于 CloudProxy
 - 防止用户的任务遭到服务提供商的监控或破坏
- 硬件安全
 - 硬件的认证
 - 远程可控的硬件认证环境
 - 主机直连块设备安全
 - 主 OS/VMM 镜像安全
- 硬件配置的信任链
 - 可远程建立信任链，自由根服务器
- 不能防范全部的内存攻击
 - 等待 SGX




可信云平台综述

- 计算隔离
 - 不同租户的任务运行在不同的虚机中
 - 防止不同租户间相互干扰或破坏
 - 不同虚机不同等级
不保护、保护、保护且加密
- 可靠的网络通信信道
 - 同一租户不同虚机间，以及同密钥服务器、认证服务器间均使用加密信道
 - 防止通信数据泄漏或被篡改
- 数据加密
 - 所有离开 TCB 边界的数据均加密（输入、输出以及中间结果）
 - 保证的数据的机密性和一致性




案例 1：Hadoop 改造



- 使用单独的可信虚机（VM2）将用户的计算与其他组件隔离
- 使用剪裁过的 JAR 包以减小 TCB
- 使用修改过的 Task Tracker 创建虚机 VM2
- 在 VM2 中添加一个加解密引擎负责对进出 VM2 的数据进行加解密。
- VM2 启动时，需要传入一个加密后的密钥用以初始化加解密引擎
- 可信虚机（VM2）通过普通管道或网络访问原有虚机（VM1）中的 HDFS API，进而读写 HDFS 文件

案例二：Spark 改造




- 使用单独的可信虚机（VM2/3）将用户的计算与其他组件隔离
- 使用剪裁过的 JAR 包以减小 TCB
- 使用修改过的 Worker 创建可信虚机
- 在可信虚机中添加一个加解密引擎负责对进出 VM 的数据进行加解密。
- 可信虚机启动时，需要传入一个加密后的密钥用以初始化加解密引擎
- 可信虚机（VM2/3）通过普通管道或网络访问原有虚机（VM1）中的 HDFS API，进而读写 HDFS 文件

经验总结

- 性能！
 - 启动慢
- 解决
 - Docker
 - 但是问题很多
 - 隔离差
 - 镜像管理
 - Spark 结合不好

数据分享和数据分析平台的目标



- 传统的基于权限控制的方案
 - 数据安全不再是零和一的选择
 - 授权必须授权以后还得控制
 - 加密可能是终极方案
 - 顶级大牛的说法
 - 但是，屌丝的思考可能跟不上大牛
 - 学术界认识到基于语意，数据可以分成不同的语意敏感级别
 - ID
 - QI
 - SA
 - Public
- 把基于语意分级的安全机制引入到大数据分析平台

数据安全的相关工作

- 静态数据安全
 - 访问控制：Apache Accumulo , Hbase
 - 加密：HADOOP-10150
- 数据脱敏 / 匿名化
 - 去标识符，但基于准标识符（quasi identifiers）仍能重新标识化
 - k-anonymity、L-diversity、T-Closeness
 - 差分隐私（differential privacy）
 - 隐私安全性和数据可用性的平衡
- 动态数据安全
 - 动态审计能力：数据泄露防护（Data Leakage Prevention）

数据分享和数据分析平台综述


- 数据提供者
 - 数据收集
 - 法务部门
- 数据使用者
 - 数据分析师
- 运营方
 - 运维

- 数据要求
 - 数据机密
 - 客户机密、业务机密
 - 数据大、流式数据
 - 保护规范
- 分析要求
 - 保护商业机密
 - 持续、反复运行分析程序
 - 降低学习曲线
- 运行要求
 - 成熟稳定平台


解决思路：

- 集中和分散结合 —— 中心云 + 私有云 / 本地云
- 简单明了的保护方案 —— 给予规则的数据访问保护

数据分享和数据分析平台 —— Data Coffeehouse




数据分享和数据分析平台实践之一



- 正在参与的共享医疗数据原型系统
 - 背景
 - 医疗数据具有长尾特性
 - 因为隐私保护等原因，诊所等医疗机构无法共享其数据
 - 问题
 - 如何将所有机构的医疗数据聚合起来，从而提高医学研究的成果
 - 解决方案
 - 创新性地使用基于 TPM 的软硬件协同方法建立一个云平台，实现安全的数据共享和数据处理

数据分享和数据分析平台实践之二

餐饮 ERP 系统的数据共享和数据分析平台



回顾和其他方案的比较

**Differential
Privacy**

**Encrypted
Database**

**Data
Coffeehouse**


开发用户接受度：

- 数据分析程序难易
- 数据理解难易
- 数据更新频率

运维接受度：

- 角色清晰度
- 保护管理可行度
- 新业务加入难度

总结



xin.zhou@intel.com

微信：

XinZhou Bookworm

Thanks!

