Geekbang. 极客邦科技 InfoQ

QCon 全球软件开发大会 【北京站】2016

Spark在360的大规模实践与经验分享

李远策

Intemational Software Development Conference

题纲

360Spark平台介绍

业务及应用案例

经验 & 改进分享

360-Spark集群概况

集群类型	节点数	内存	部署方式	业务	作业数
通用计算	3000+	64G	与MR混部	SparkSQl/通用计算	1.5W+/day
机器学习	500+	288G	独占	机器学习/图计算	5000+/day

Spark在360的演进

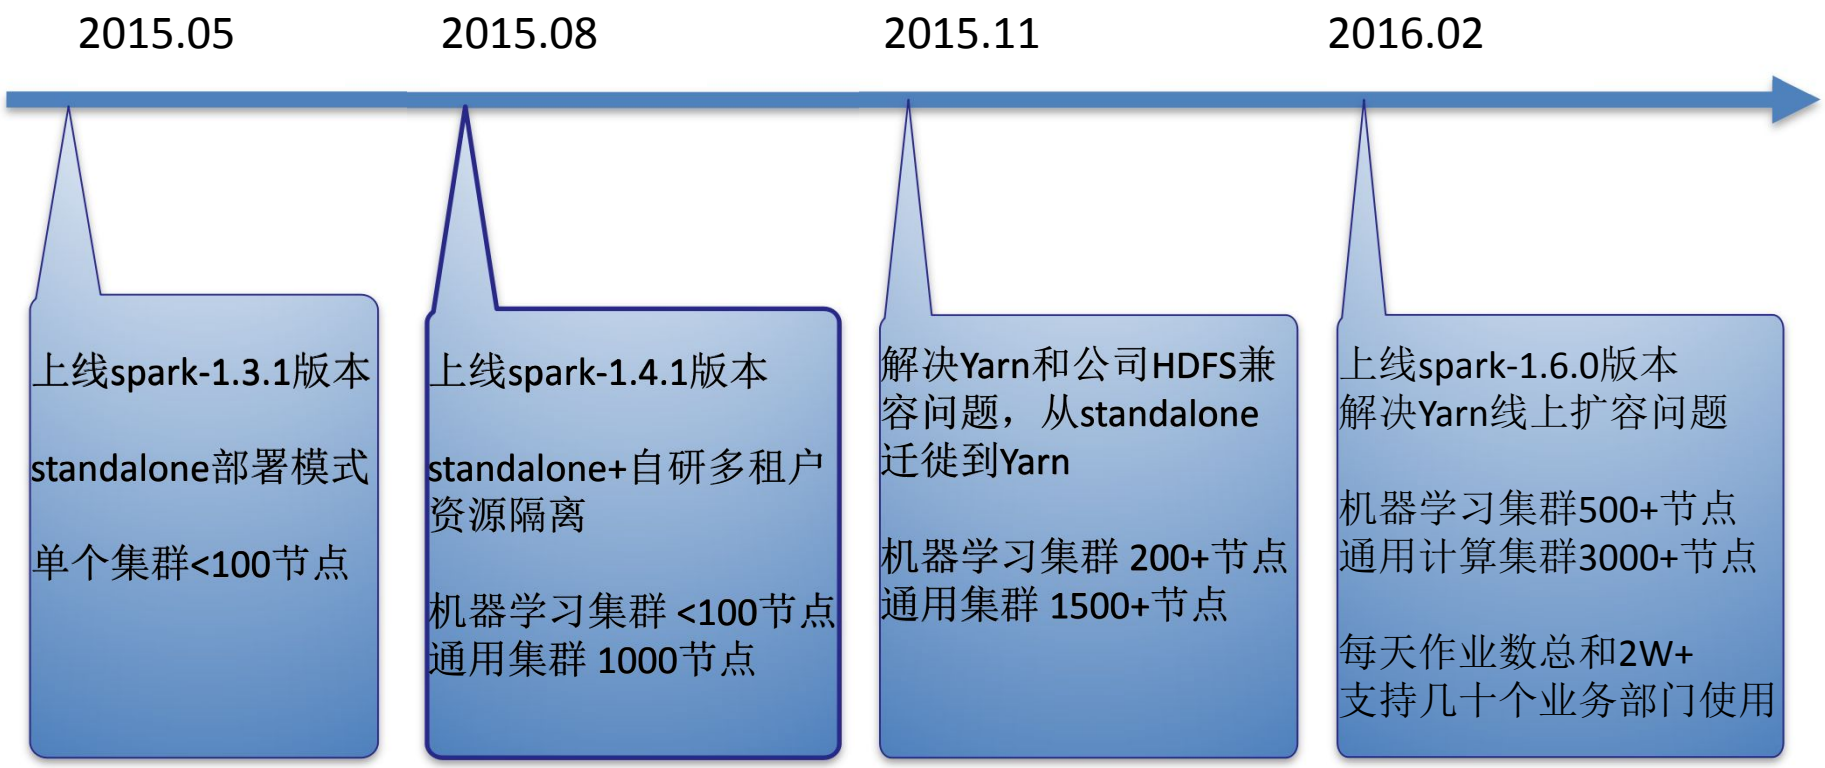

题纲

360Spark平台介绍

业务及应用案例

经验 & 改进分享

360-Spark应用

- ***MLLib***
  - 算法：LDA、LR、FP-Growth、ALS、KMeans、随机深林等。
  - 业务：新闻主题分类、新闻推荐、APP推荐、恶意代码识别、恶意域名检测等。
- ***GraphX***
  - 算法：PageRank、Louvain、LPA、连通子图等。
  - 业务：搜索PageValue、网站安全监测等。
- ***SparkSQL***
  - 采用HiveContext替换公司90%以上的Hive作业，每天例行1.5W+作业。
  - 每个Hive SQL平均3轮MR作业，平均性能提升2~5倍。

PageRank on Spark

千亿量级

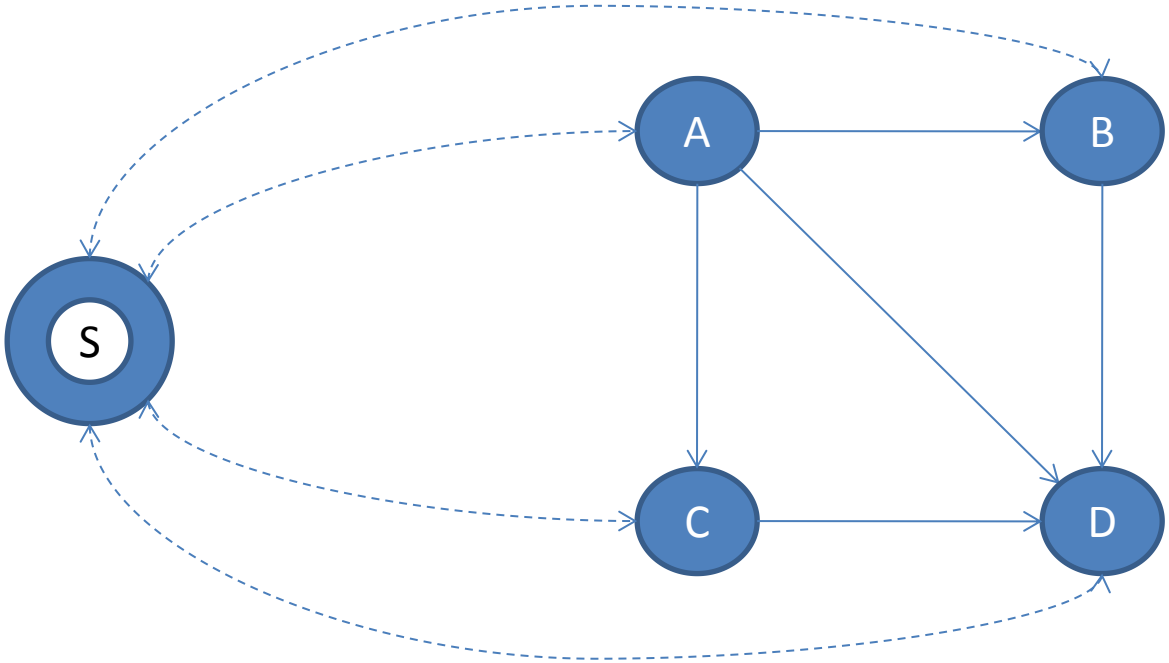

计算公式： W = alpha * Wp+ (1 - alpha) * Random

PageRank on Spark

内置org.apache.spark.graphx.lib.PageRank算法不适合 

GraphX在千亿边规模上难以胜任 

自己动手

PageRank on Spark （续）

核心代码：

```
val links = … //网页传递概率RDD [(pageId,[(pageId, ratio)])]
val ranks = … //网页value RDD [(pageId, rank)]
val ratios =… //网页赋值权重RDD [(pageId, ratio)]
val totalZ = … //网页权重总和 Long
val alpha = … //网也权重转义比例 float
循环 {
      val contribs = links.join(ranks).values.flatMap{ case (urls, rank) =>
urls.map(url => (url._1, url._2*rank))}
      val ranksTmp = contribs.reduceByKey(_ + _).mapValues(alpha * _)
      val contribsZ= ranksTmp.map(x => x._2).sum()
      val superZ = totalZ - contribsZ
      val ranksZ = ratios.map{x => (x._1, x._2*superZ)}
      ranks = ranksTmp.rightOuterJoin(ranksZ).map{case(pageId, (rankTmp,
rankZ)) => (pageId, rankTmp.getOrElse(0.0) + rankZ) }
}
```

社群发现在网络安全的应用-恶意域名发现

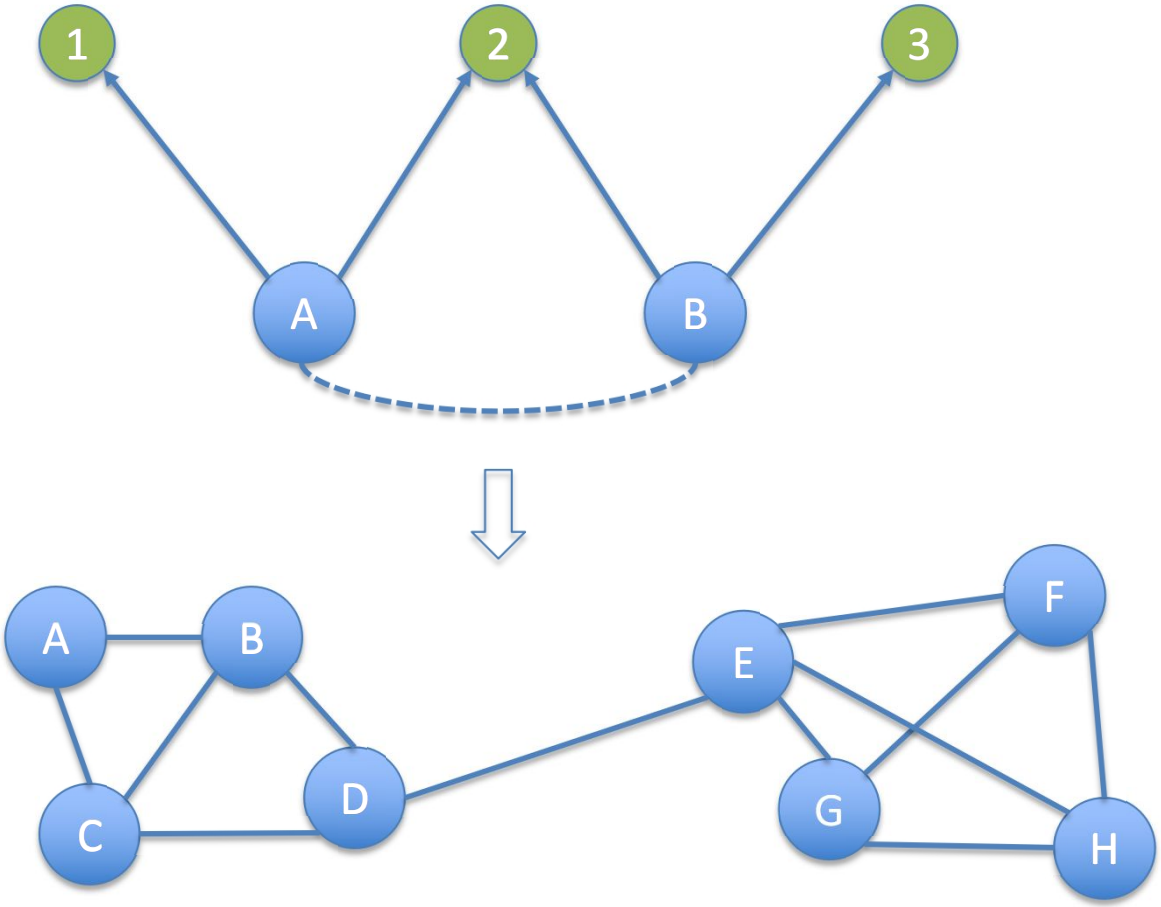

社群发现在网络安全的应用-恶意域名发现

社群发现结果：

社群1：A、B、C、D

社群2：E、F、G、H

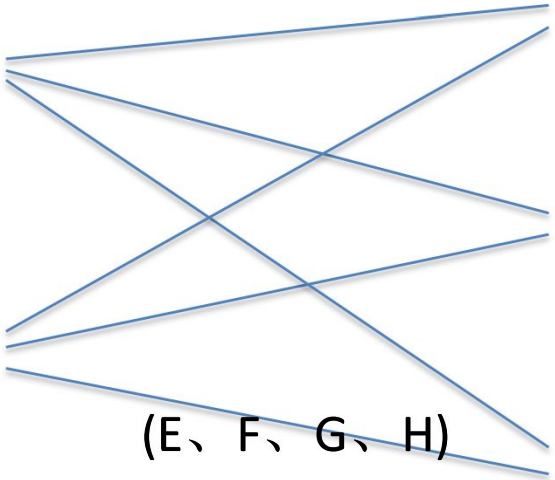

(E、F、G、H)

K-means聚类结果：

簇1：A、B

簇2：C、D

簇3：E、F、G、H

(E、F、G、H) → (E、F、G、H)

Spark做社群发现的历程（1）

内置org.apache.spark.graphx.lib.LabelPropagation在大规模场景下性能太差，原因：

```
def mergeMessage(count1: Map[VertexId, Long], count2: Map[VertexId, Long])
  : Map[VertexId, Long] = {
  (count1.keySet ++ count2.keySet).map { i =>
    val count1Val = count1.getOrElse(i, 0L)
    val count2Val = count2.getOrElse(i, 0L)
    i -> (count1Val + count2Val)
  }.toMap
}
```

存在大量的内存拷贝开销，使用scala.collection.mutable.Map做内存优化性能提升数倍

Spark做社群发现的历程（2）

内置org.apache.spark.graphx.lib.LabelPropagation经常出现超大社区的问题，效果不太理想。

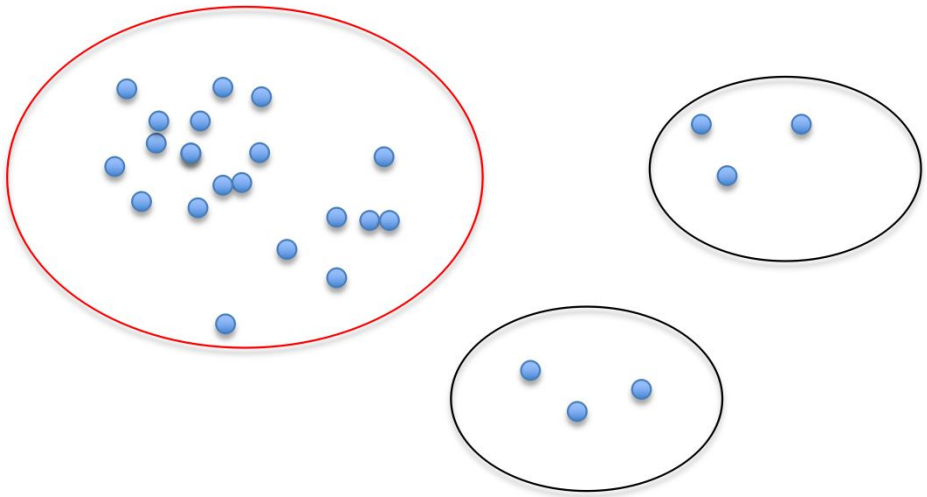

Spark做社群发现的历程（3）

自研Louvain算法，支持：

1、边权重
2、有向图
3、分层结果保存
4、增量计算

SparkSQL替换Hive

Hive迁移到SparkSQL的“正确打开方式”：

1、编译Spark加上-Phive -Phive-thriftserver参数
2、部署Spark（Yarn）集群
3、配置SparkSQL共用Hive的元数据库
4、用spark-hive（spark-sql）工具替换原有的hive命令
5、-e/–f 或者thriftserver提交作业。

SparkSQL部署方案

新版数据仓库方案

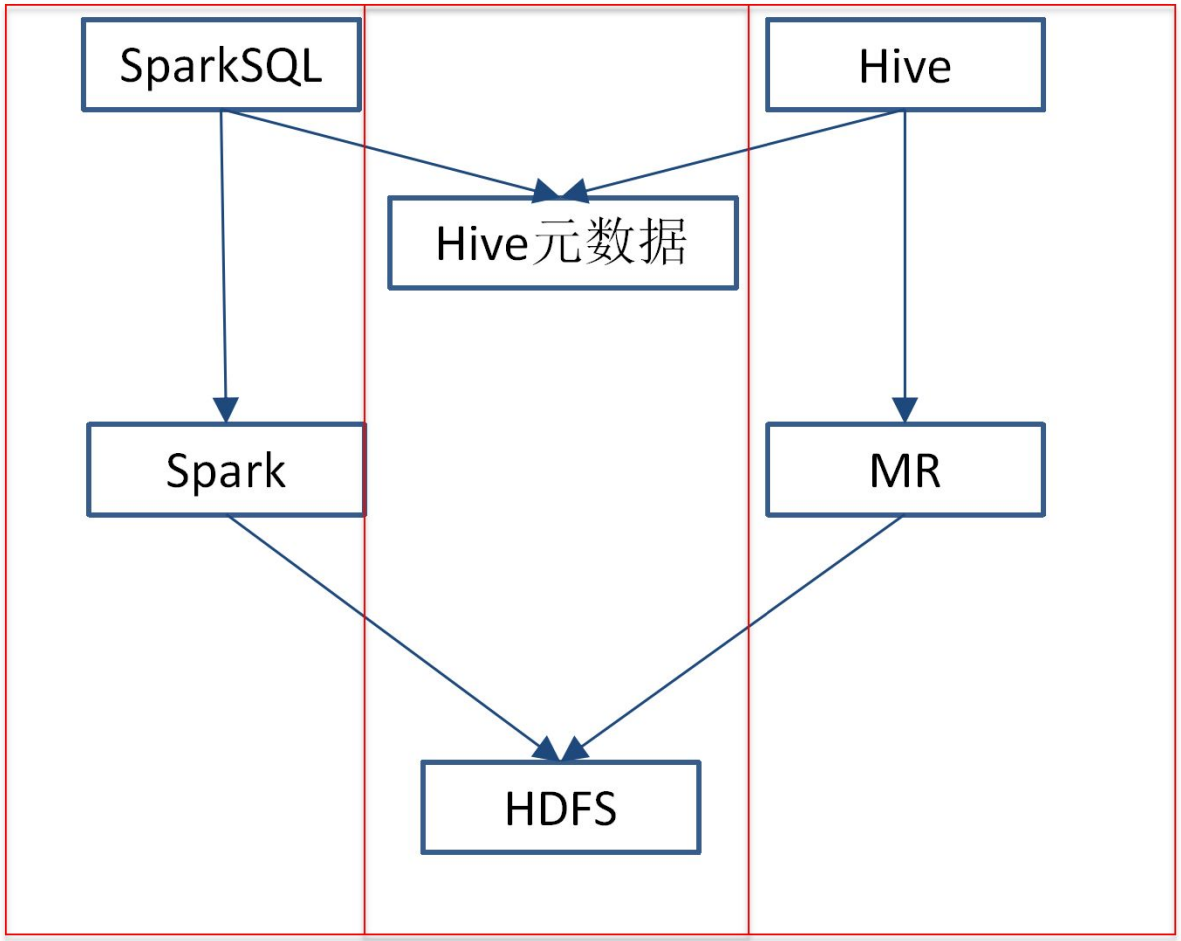

之前数据仓库方案

Hive迁移SparkSQL – 迁移方法

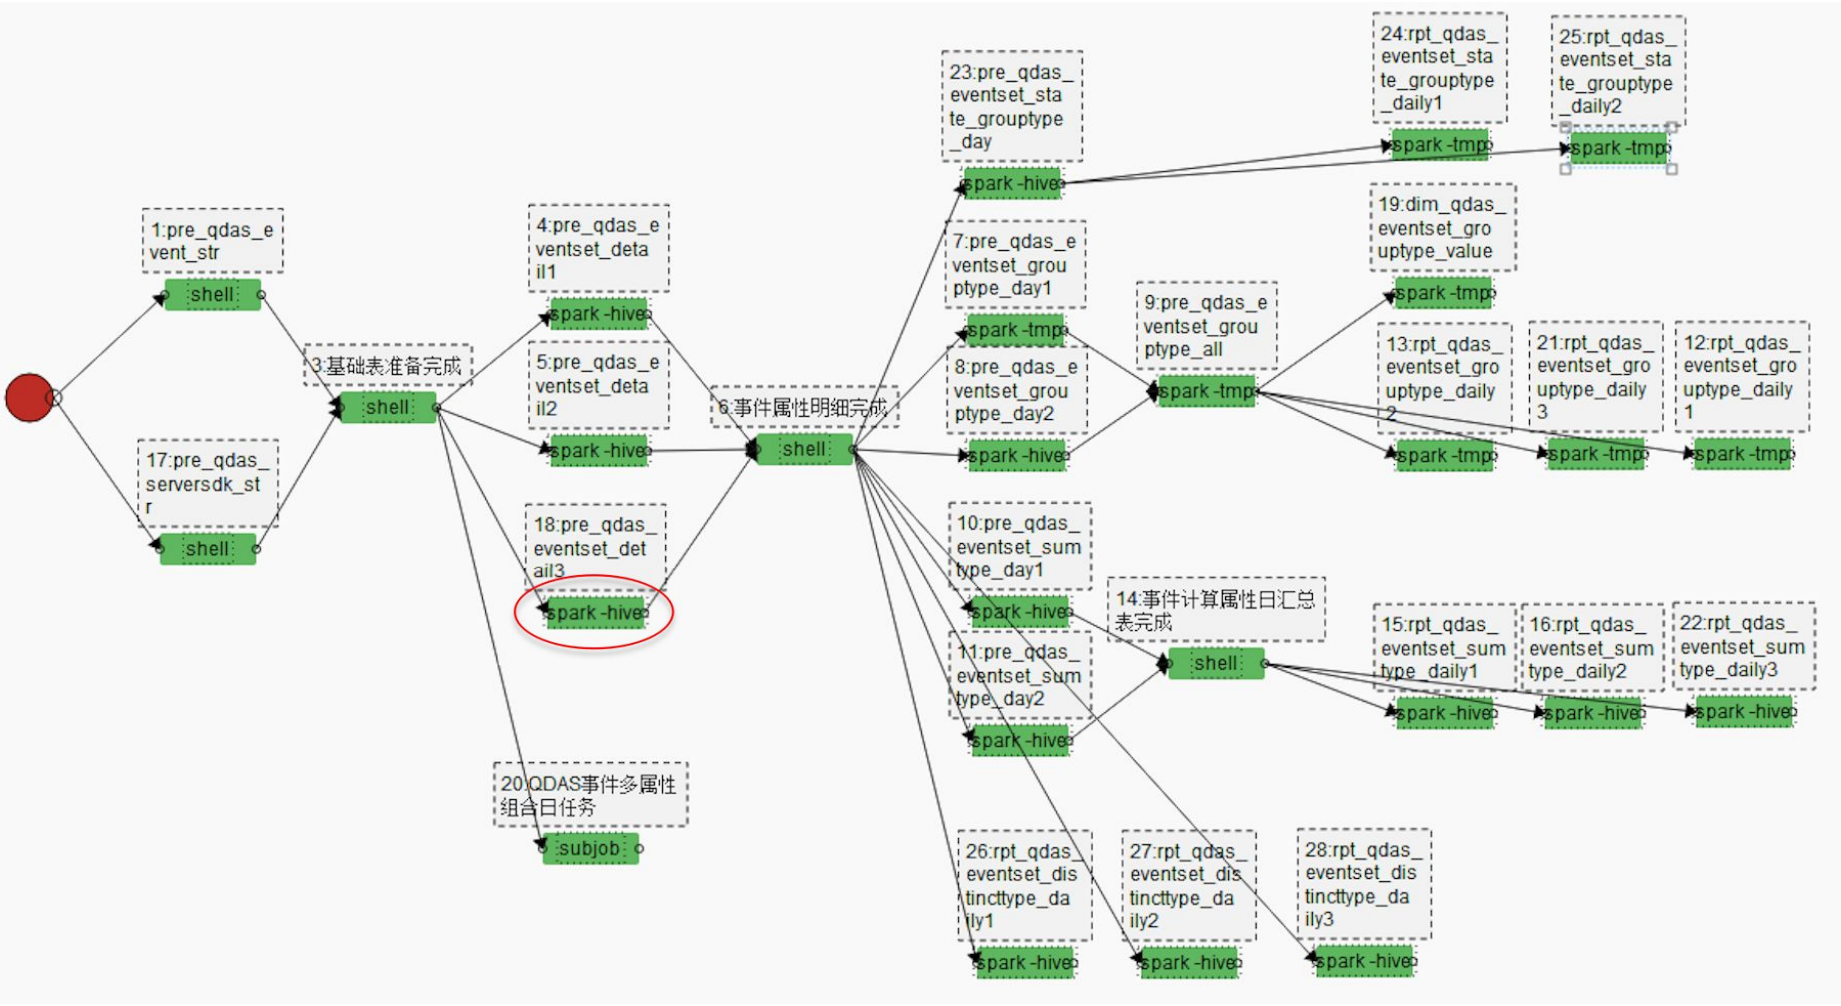

SparkSQL 版本选择

SpakSQL-1.4 VS SparkSQL-1.6

	1.4.1	1.6.0
Join	默认HashJoin，支持BroadcastHashJoin和SortMergeJoin	默认SortMergeJoin，支持BroadcastHashJoin
outer join	仅支持HashOuterJoin	支持SortMergeOuterJoin，BroadcastHashOuterJoin
Aggregation	HashAggregation	SortBasedAggregation
count(distinct)	单节点	分布式

Hive版本选择

Spark版本	支持的Hive *metastore版本*	hive execution版本
1.4.1	0.12/0.13	0.13.1
1.6.0	0.12/0.13/1.0/1.1/1.2	1.2.1

spark.sql.hive.metastore.version x.y.z

spark.sql.hive.metastore.jars /path/your/hiveJars

支持多Hive MetaStore版本

实现原理

1、HiveContext中创建一个URLClassLoader作为clientLoader加载不同版本的Hive metastore classes。

2、在ClientWrapper中调用Hive的接口时会切换到clientLoader中，然后借助HiveShim去反射Hive中对应函数。

自定义Hive MetaStore版本

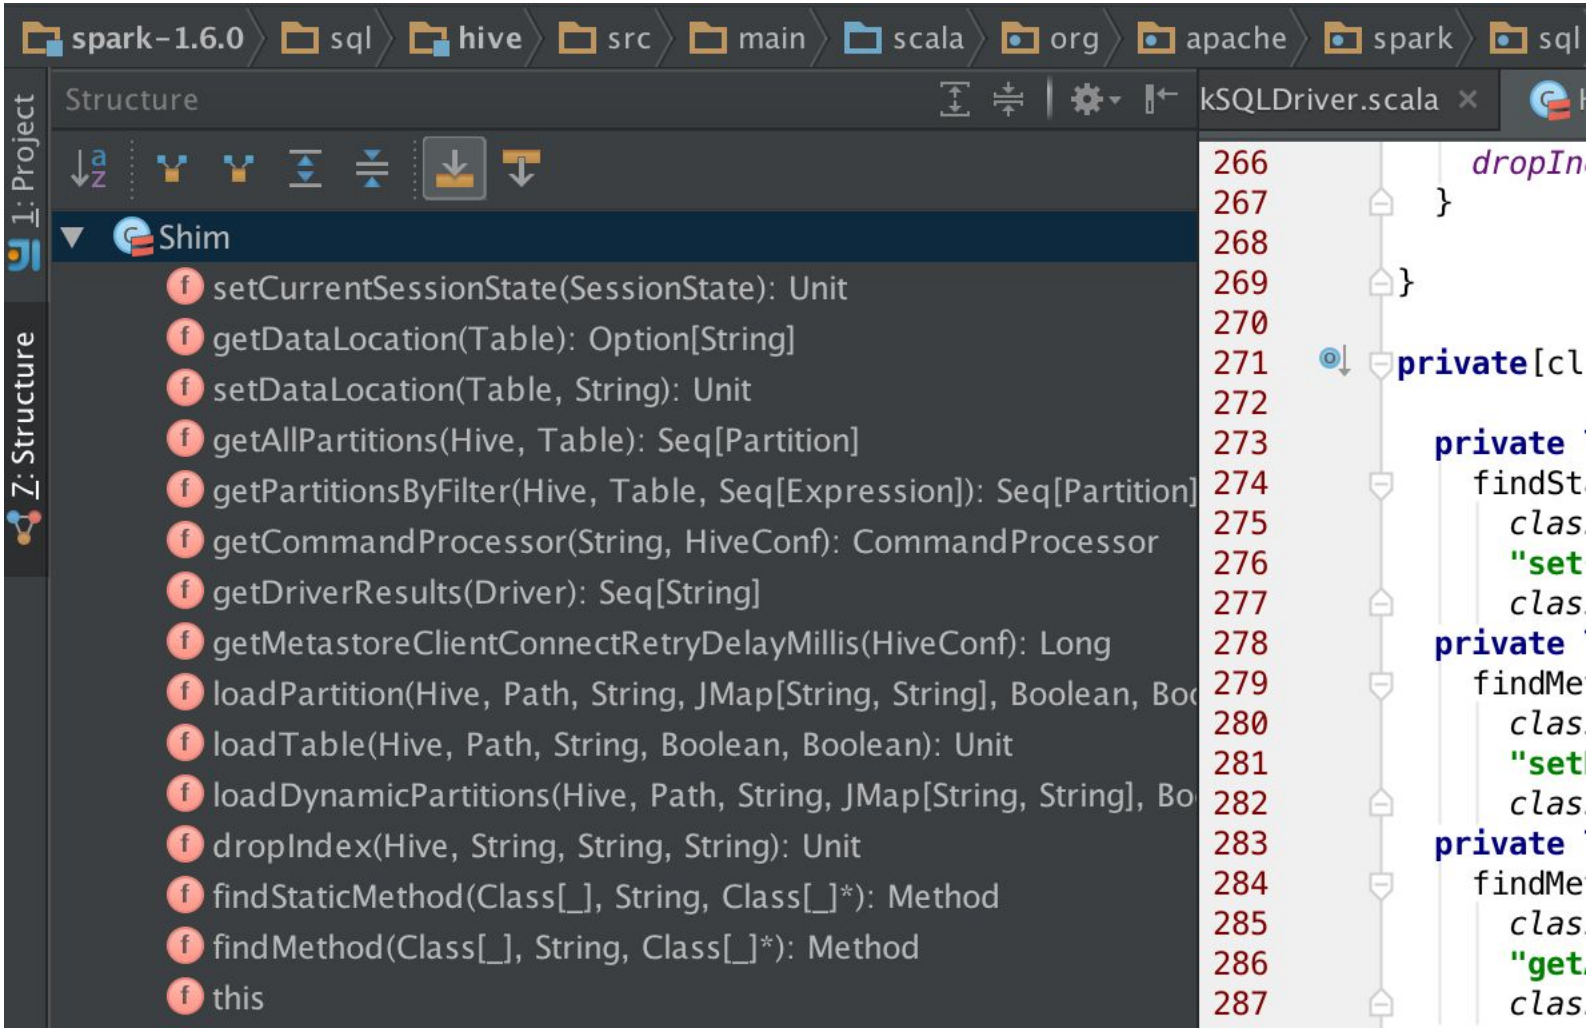

自定义Hive MetaStore版本

例如

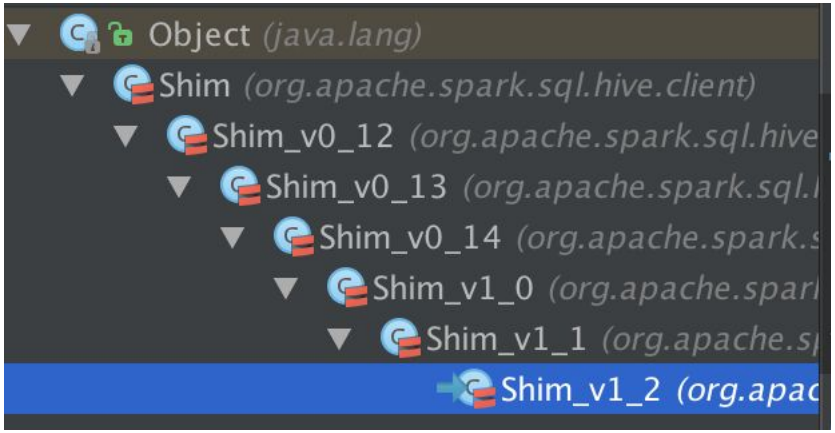


```
private[client] class Shim_v1_1 extends Shim_v1_0 {

  private lazy val dropIndexMethod =
    findMethod(
      classOf[Hive],
      "dropIndex",
      classOf[String],
      classOf[String],
      classOf[String],
      JBoolean.TYPE,
      JBoolean.TYPE)

  override def dropIndex(hive: Hive, dbName: String, tableName: String, indexName: String): Unit = {
    dropIndexMethod.invoke(hive, dbName, tableName, indexName, true: JBoolean, true: JBoolean)
  }

}
```

题纲

360Spark平台介绍

业务及应用案例

经验& 改进分享

Hive迁移SparkSQL – 坑 & 改进

- SQL兼容 （Insert overwrite [local] directory的支持）

  例如：insert overwrite directory ‘/tmp/testdir’ select * from T1;　Hive中支持，SparkSQL暂时不支持。

  因为SparkSQL-HiveContext的SQL解析调用了Hive的ParseDriver. parse完成，所以语法解析上不存在问题。

Hive迁移SparkSQL – 坑 & 改进

- SQL兼容 （Insert overwrite [local] directory的支持）

  解决方案：
  1、解析AST中的TOK_DIR和TOK_LOCAL_DIR将其转化成新定义的逻辑计划WriteToDirectory
  2、将逻辑计划WriteToDirectory转换成新定义的物理计划WriteToDirectory。
  3、在物理计划WriteToDirectory执行方法中复用InsertIntoHiveTable中的saveAsHiveFile逻辑将结果写到HDFS中。
  4、如果是local directory则将结果再拉回到本地

Hive迁移SparkSQL – 坑 & 改进

- SQL兼容 （SQL二义性问题）

  例如：

```
select C.id from (
    select A.id from testb as A
    join
    (select id from testb ) B
    on A.id=B.id) C;
```

  C.id is A.id or B.id ?

Hive迁移SparkSQL – 坑 & 改进(续)

- transformation bugs （行尾部空列导致的数组越界）

例如：

001\tABC\t002\t → [001, ABC, 002]

003\tEFG\t\t → [003, EFG]

```
new GenericInternalRow(
    prevLine.split(ioschema.outputRowFormatMap("TOK_TABLEROWFORMATFIELD"))
    .map(CatalystTypeConverters.convertToCatalyst))
```

Hive迁移SparkSQL – 坑 & 改进(续)

- transformation bugs （Script的标准错误缓冲区打满导致transform流程卡住）

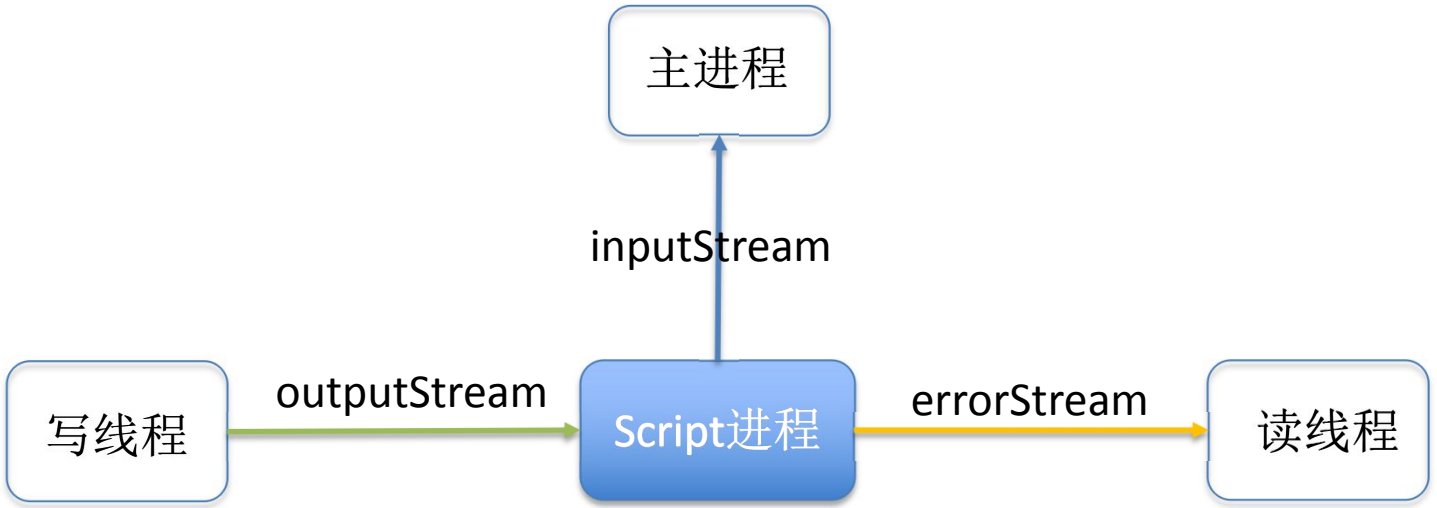

Hive迁移SparkSQL – 坑 & 改进(续)

- 输入小文件合并的改进 （增加支持自定义inputFormat类）
  默认采用建表时指定的InpurFormat，如果是默认的TextInputFormat，当小文件比较多是可能会导致RDD的partition数太多，导致性能下降。

  解决办法：通过参数允许用户指定InputFormat，在TableReader中反射生成对应的InputFormat对象并传入到HadoopRDD的构造函数中。

  使用方法：set spark.sql.hive.inputformat= org.apache.hadoop.mapred.lib.CombineTextInputFormat;

Hive迁移SparkSQL – 坑 & 改进(续)

- 输出小文件合并的改进 （增加自动合并结果文件）

当spark.sql.shuffle.partitions设置的比较大且结果数据集比较小时，会产生大量的小文件（文件数等同spark.sql.shuffle.partitions）。

解决办法：在最后的执行计划中加入一个repartition transformation。通过参数控制最终的partitions数且不影响shuffle partition的数量。

使用方法：set spark.sql.result.partitions=10;

Hive迁移SparkSQL – 坑 & 改进(续)

- 支持yarn-cluster模式，减小client的负载

  默认的yarn-client模式下Scheduler会运行在client上，加重client机器的负载。

  解决办法：让sparkSQL工具支持yarn-cluster模式。

  1）在Yarn集群上部署SparkSQL依赖的hive metastore jar包。

  2）开通Yarn nodemanager节点访问Hive metastore数据库的权限。

  3）解决“\”“转义问题。如 spark-hive –e “select * from user where name = \”张三””;在yarn-cluster模式中会触发两次command执行从而导致“\”被转义两次。

Hive迁移SparkSQL – 坑 & 改进(续)

Join数据倾斜

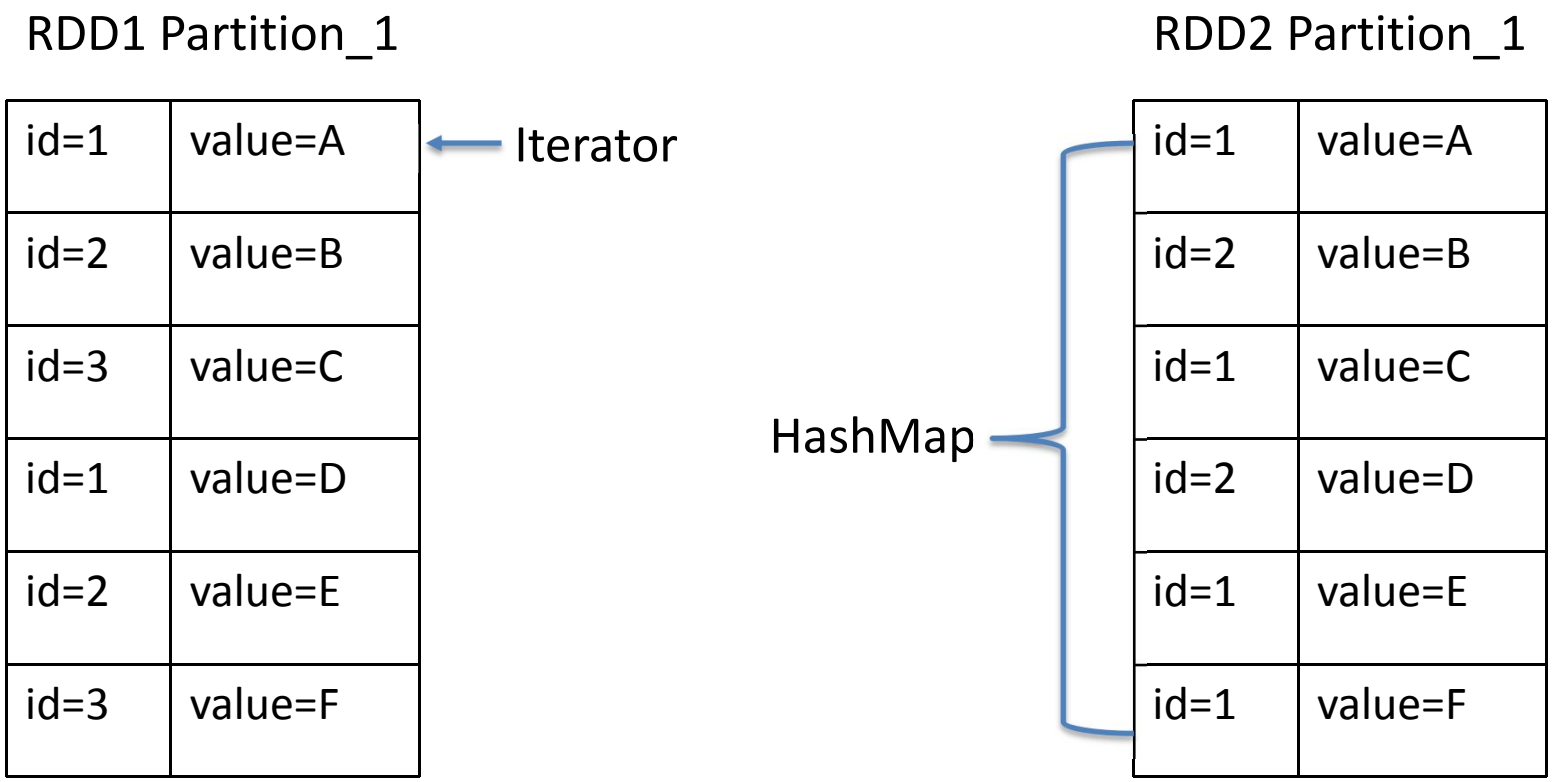

Spark-1.4.1 HashJoin

Hive迁移SparkSQL – 坑 & 改进(续)

Join数据倾斜

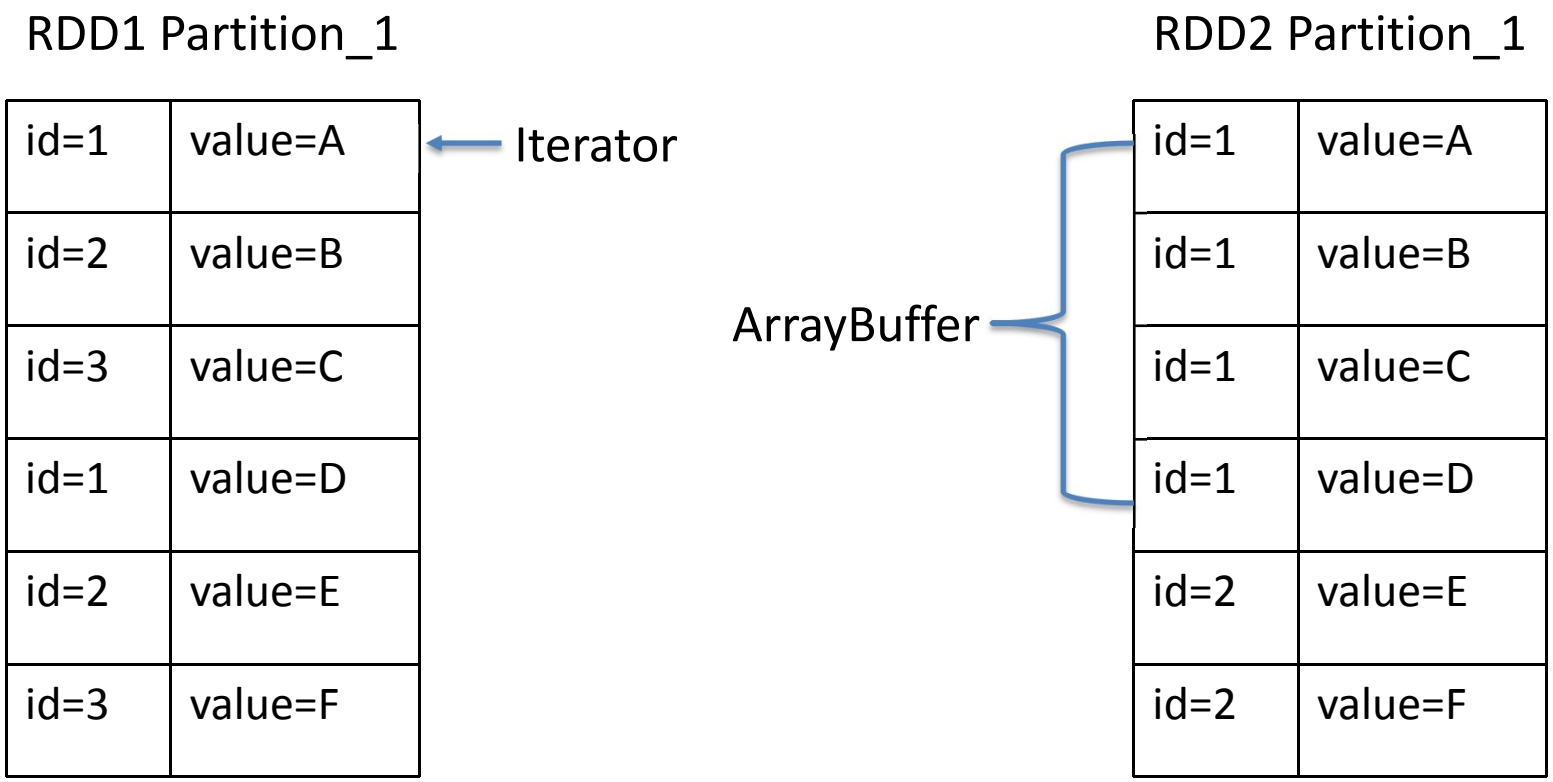

Spark-1.6.0 SortMergeJoin

Hive迁移SparkSQL – 坑 & 改进(续)

Join数据倾斜

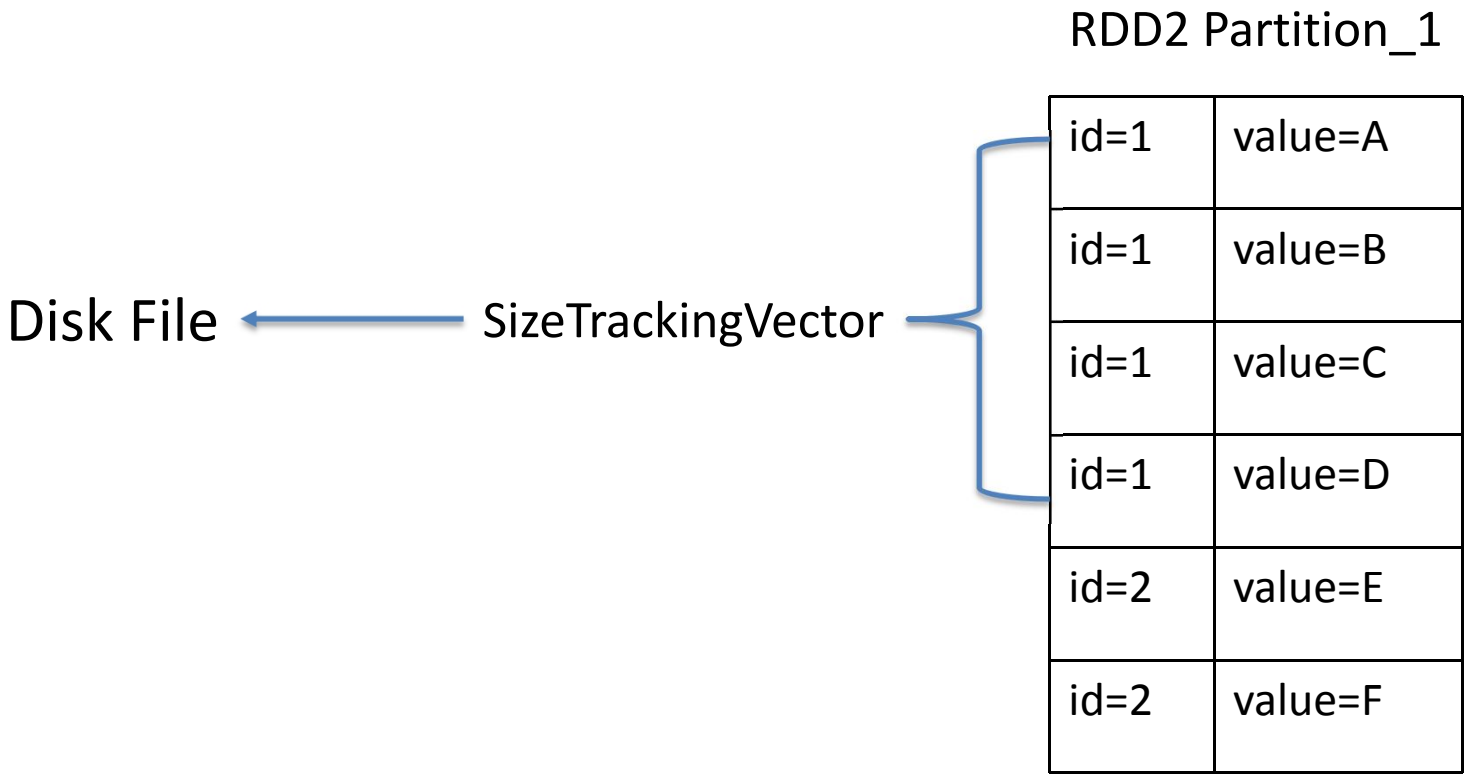

解决办法

Spark平台推广的一点感悟

- 平台推广要找到用户的痛点（性能、便捷、0/1问题）
- 新平台的推广要小处入手，单点突破
- 及时响应用户的问题，保证平台口碑
- deadline是第一生产力
- 对用户问题的总结和梳理

联系信息

姓名：李远策

电话：15201453364

邮箱：liyuance@gmail.com
liyuance@360.cn

急招大数据运维和运维开发人员，谢谢

Geekbang 极客邦科技 InfoQ

THANKS!

for your listening and sleeping