



悦 享 品 质



爱奇艺Spark平台构建之路

2016-11-25

Who Am I?

- 顾亮亮
- 上海交大：2013毕业
- SAP：机器学习算法开发 1年
- 爱奇艺：大数据平台开发 3年
- 关注：分布式计算框架，流式计算



Agenda

- 第一阶段：裸用Spark
- 第二阶段：平台化管理Spark
- 第三阶段：不用写Spark
- 第四阶段：不只是Spark
- 平台构建经验

第一阶段：裸用Spark (2014)

- Spark-1.2.1、Spark-1.3.0
- Standalone x 4 + Spark on YARN x 1
- 入口机
- 100个Batch任务/天 + 0个Streaming任务




增值服务

- 提供优化过的Spark默认参数
 - `spark.yarn.executor.memoryOverhead=2048`
 - ...
- 提供库：解决用户问题
 - HBase Kerberos问题
 - ...
- 提供各种文档
 - 例子
 - 使用手册
 - 调优手册
 - Debug手册
 - ...



问题

- Standalone扩展不方便
- 入口机缺少HA
- 测试升级维护比较麻烦
- 缺少监控、重试、调试、查错、调度、管理等机制
- 运维占用大量时间
 - 为什么我的Spark任务失败了？
 - 为什么任务卡住了？
 - 为什么这么多failed task？
 - 为什么无法提交任务？
 - 为什么程序抛了这个错？
 - ...



第二阶段：平台化管理Spark (2015 - 2016)

- Spark-1.4.1、Spark-1.5.2、Spark-1.6.2、Spark-2.0.1
- 使用平台提交到Yarn上运行，Yarn集群 x 4
- 2015
 - 500个Batch任务/天 + 100个Streaming任务
- 2016
 - 2K个Batch任务/天 + 500个Streaming任务
 - 15K个核 + 50T内存



平台架构



增值服务



提交运行Spark程序

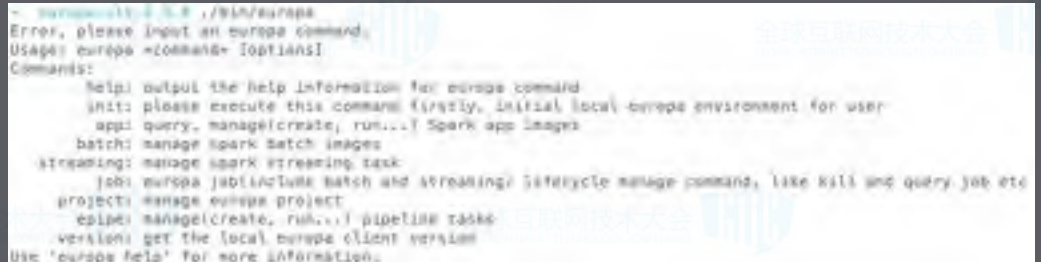
网页提交



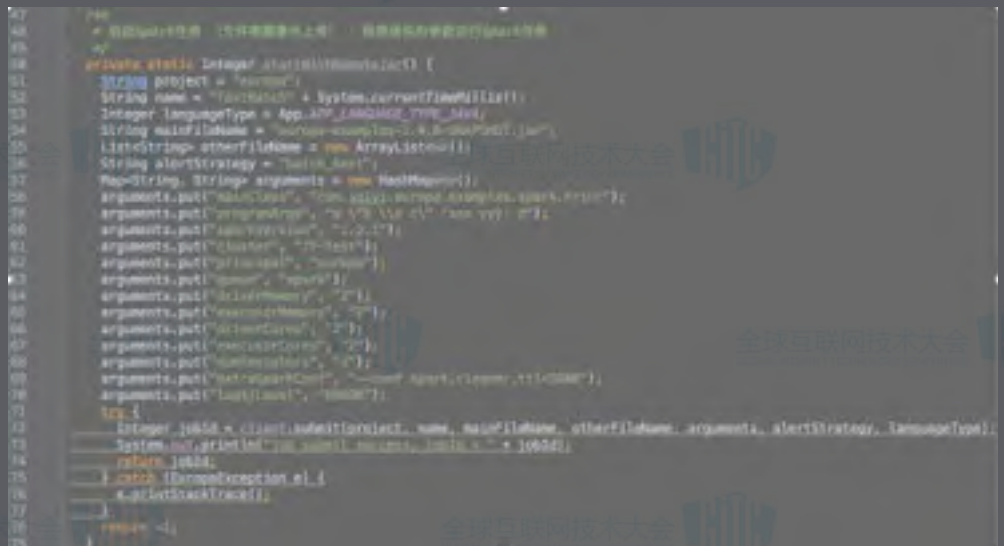
Maven插件提交



命令行提交 (Linux & Windows)



Java SDK提交



监控报警 & 自动重启

- Streaming任务自动重启
- 自动错误诊断（基于规则）
 - Pending Batch超过1h
 - Kafka没有流量超过0.5h
 - Spark Stage卡住超过10min
- 自定义报警
 - Kafka QPS超过20w十分钟（需要申请更多计算资源）
- 资源使用异常检测（基于规则）
 - 申请1000个core，但是最大的并行度只有10

统一API访问不同数据库

- 问题：访问数据源的库
 - 官方提供：MySQL, Hive, Kafka
 - 第三方提供：Mongodb, Couchbase, HBase
 - 没有很好的开源实现：ActiveMQ
 - API不一致，功能也不一样，有些库还有Bug
- 包装成统一的API并发布

其他增值服务

- 高可用
- 定时任务
- 工作流
- 进一步优化SparkConf
 - 1个核: `-XX:+UseSerialGC`
 - n个核: `-XX:+UseParallelGC -XX:ParallelGCThreads=#n`
- 团队协作
- 版本管理
- 统计
- 计算资源的管理
- 下载YARN日志并保留7天
- 收集分析程序Metrics (JVM)
- 分布式Profiling (Flame Graph)

问题

- Spark学习成本很大
 - Scala、Java、Python、R
 - RDD、DataFrame、DataSet、DStream
 - DAG、Driver、Executor、YARN
 - SparkConf各种参数设置
- 需要1-2周才能写好Spark Batch程序
 - 逻辑正确
 - 稳定运行
 - 应对数据量的变化
- 需要近1个月才能写好Spark Streaming程序
 - 能处理流量波动和突增
 - Exactly once语义
 - 支持重启
 - 稳定运行
 - 程序升级



Sebastian Vettel shows his first FIA Super License in 2006.

第三阶段：不用写Spark (2016)


- Spark开发工具
 - 用户配置 + SparkSQL
 - 图形界面 + SparkSQL



Example

```
1 {
2   "test": {
3     "desc": "从Kafka读取json格式数据, 通过正则表达式抽取字符串, 并以parquet格式保存到HDFS",
4     "strategy": "SparkStreamingStrategy",
5     "compositor": [
6       {
7         "name": "KafkaStreamingCompositor",
8         "params": {"metadata.broker.list": "xxx.xxx.xxx.xxx:9092,...", "topics": "vis-nginx-cache-access"}
9       },
10      {
11        "name": "JSONTableCompositor",
12        "params": {"tableName": "raw_table", "schema": "dc:string,server:string,row:string"}
13      },
14      {
15        "name": "SQLCompositor",
16        "params": {"sql": "select dc, server, regexp_extract(row, '{{?=<= (tvid=)}}.+?(?=<= (&|,|\\s))}}' as tvid from raw_table"}
17      },
18      {
19        "name": "SQLParquetOutputCompositor",
20        "params": {"path": "/data/.../vis-nginx-cache-access.parquet/date=${yyyyMMdd}/hour=${HH}", "mode": "Append"}
21      }
22    ]
23  }
24 }
25 }
```

增值服务



增值服务

- Kafka Offset管理
- 引导用户使用Spark的方式
 - SparkSQL
 - UDF & UDAF
 - 自定义Parser
- 图形界面拖拽 + SQL编辑
- 用户数据源管理

第四阶段：不只是Spark (2017)

- 问题

- 基于日志真实时间
- Streaming实时性
- StreamingSQL
- ...

- 不只是Spark

- Flink
- Gearpump
- Apache Beam
- ...



增值服务

- 一个系统支持运行多个框架
- 一份代码运行到多个框架
-

平台构建经验




平台提供的增值服务
平台承担的责任

用户自由度
用户编程接口
用户关心的事情



抽象用户共同逻辑，由平台提供
用户只需要写业务相关代码（最好不用写代码），不用关心分布式问题

全球互联网技术大会




全球互联网技术大会



全球互联网技术大会



全球互联网技术大会



全球互联网技术大会




全球互联网技术大会




全球互联网技术大会




全球互联网技术大会



全球互联网技术大会



全球互联网技术大会



全球互联网技术大会

