Twitter实时搜索引擎进化历程

Geekbang.
极客邦科技

整合全球最优质学习资源，帮助技术人和企业成长

Growing Technicians, Growing Companies

InfoQ

专注中高端技术人员的
技术媒体

EGO EXTRA GEEKS' ORGANIZATION NETWORKS

高端技术人员
学习型社交网络

StuQ

实践驱动的
IT职业学习和服务平台

GiT GEEKBANG INTERNATIONAL TRAINING

一线专家驱动的
企业培训服务

地址：北京市朝阳区洛娃大厦C座6层1607室　　网址：www.geekbang.org

个人介绍

王天

2003年本科毕业于清华大学计算机系；

2005年硕士毕业于University of North Carolina Chapel Hill；

2005年7月加入Google，从事移动搜索、新闻搜索、搜索质量等工作；

2011年3月加入Twitter搜索部门，工作至今。

带领Twitter的搜索质量团队，改进实时搜索产品。

@wangtian

www.twitter.com/wangtian

www.linkedin.com/in/wangtian

Twitter搜索概况

- 2008年始于收购的Summize公司
- 核心服务：关键字搜索、相关性搜索、Facets搜索、Term统计…
- 相关服务：自动建议、拼写检查、相关推荐…
- 6700亿条推文全部纳入索引
- 来自Twitter搜索产品
  - Web、Android、iOS、TweetDeck、…
- 来自公共、合作伙伴及内部API
  - 其他开发者的程序、网站、移动应用、桌面应用
  - 商业搜索服务订阅者（如GNIP）


04:28
#TimPeake
James Walsh
@Tim_Burgess ha ha. Glad I checked you're timeline. I was going to make the very same gag! #timpeake #timpeaks
BBC News (UK)
"We will be with you every step of the way, watching with admiration and wonder" - PM David Cameron to #TimPeake bbc.in/1O2qkzd
USA TODAY
We have liftoff! U.S., Russian and British astronauts blast off for @space_station usat.ly/1O2pHpr #timpeake
AP
0:56
USA TODAY
Mark Gatiss


04:28
#TimPeake
RELATED SEARCHES
#timpeake live
#timpeake launch
#iss
@astro_timpeake
soyuz launch
Kathy Burke
Big hot blast. Thrust builds. Happens slowly. Pushed back into seat. Quite easily topple over. Leave earths atmosphere. #TimPeake #menopause
ITV News
Watch the moment British astronaut Major #TimPeake blasts off into space on his #ISS mission
itv NEWS

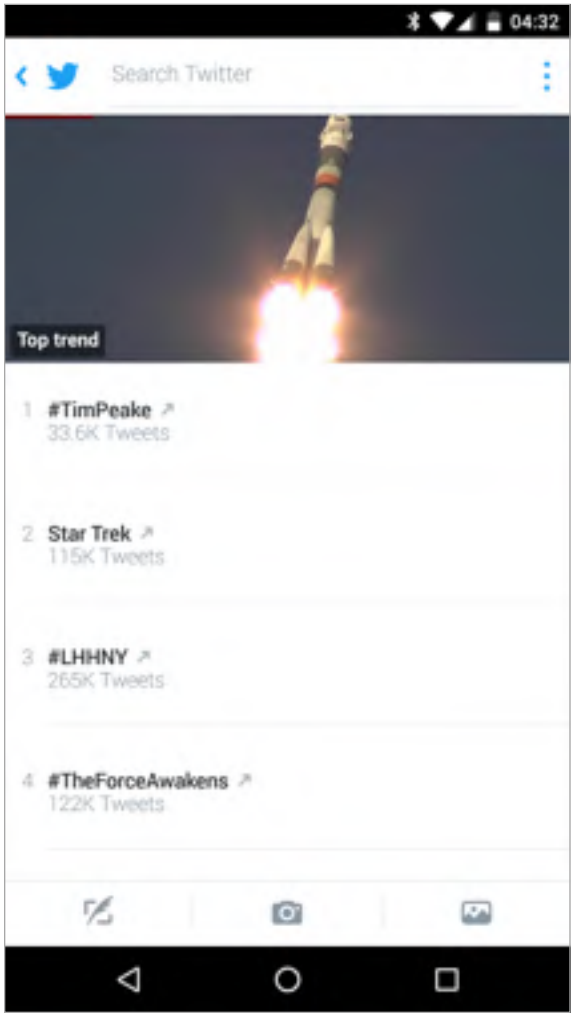
04:32
Search Twitter
Top trend
1 #TimPeake
33.6K Tweets
2 Star Trek
115K Tweets
3 #LHHNY
265K Tweets
4 #TheForceAwakens
122K Tweets

2008 ~ 2009

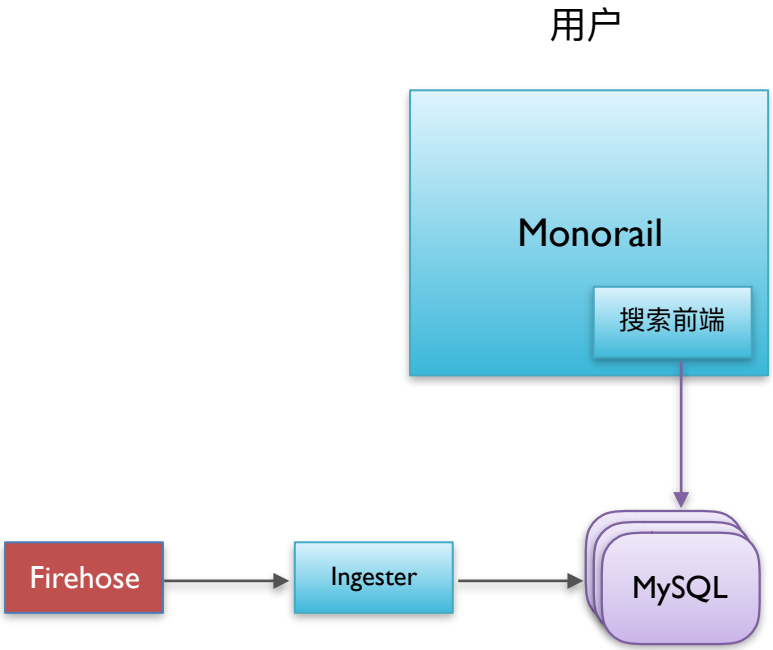

- 推文被直接写到数据库
- 写满一个表就开启下一个
- 搜索直接在数据库进行
- 只支持三天左右的数据

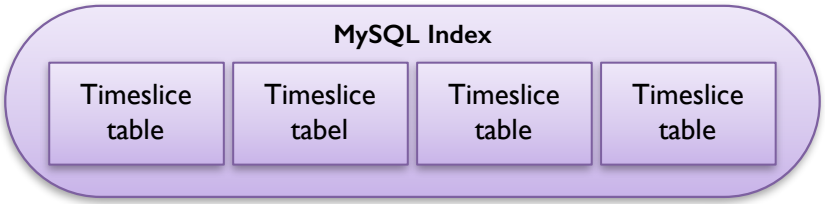

基于数据库的索引

问题

性能

- 容量有限，扩展困难
- 搜索并发性低
- 实时程度受数据库索引更新影响

功能前景

- 难以添加新数据
- 难以支持复杂的查询语法
- 无法支持相关性搜索
- 搜索前端存在于更大系统中，难以开发

基于Lucene的索引重写

- API兼容情况下重写存储层posting list结构
  - 实时更新、多线程无锁读访问
  - 优先支持逆时间序的搜索
  - 支持提前结束搜索
  - 全内存索引
  - 支持地理数据
- 新树状可扩展query结构
  - Lucene query上面独立包装的数据结构
  - 规范query元素
- 从time partition到hash partition
- 速度提升：5ms中值延迟
- 服务容量提升：10x
- 反向贡献至Lucene开源社区

查询语言：Search Query

新一代索引服务器：Earlybird（2010）

- Earlybird既是一个索引器(Indexer)也是一个索引服务器(Index Server)
- MySQL现在仅用于同步和散播数据，保存序列化的文档（推文）
- 搜索前端代码需要和所有Earlybird partition通信

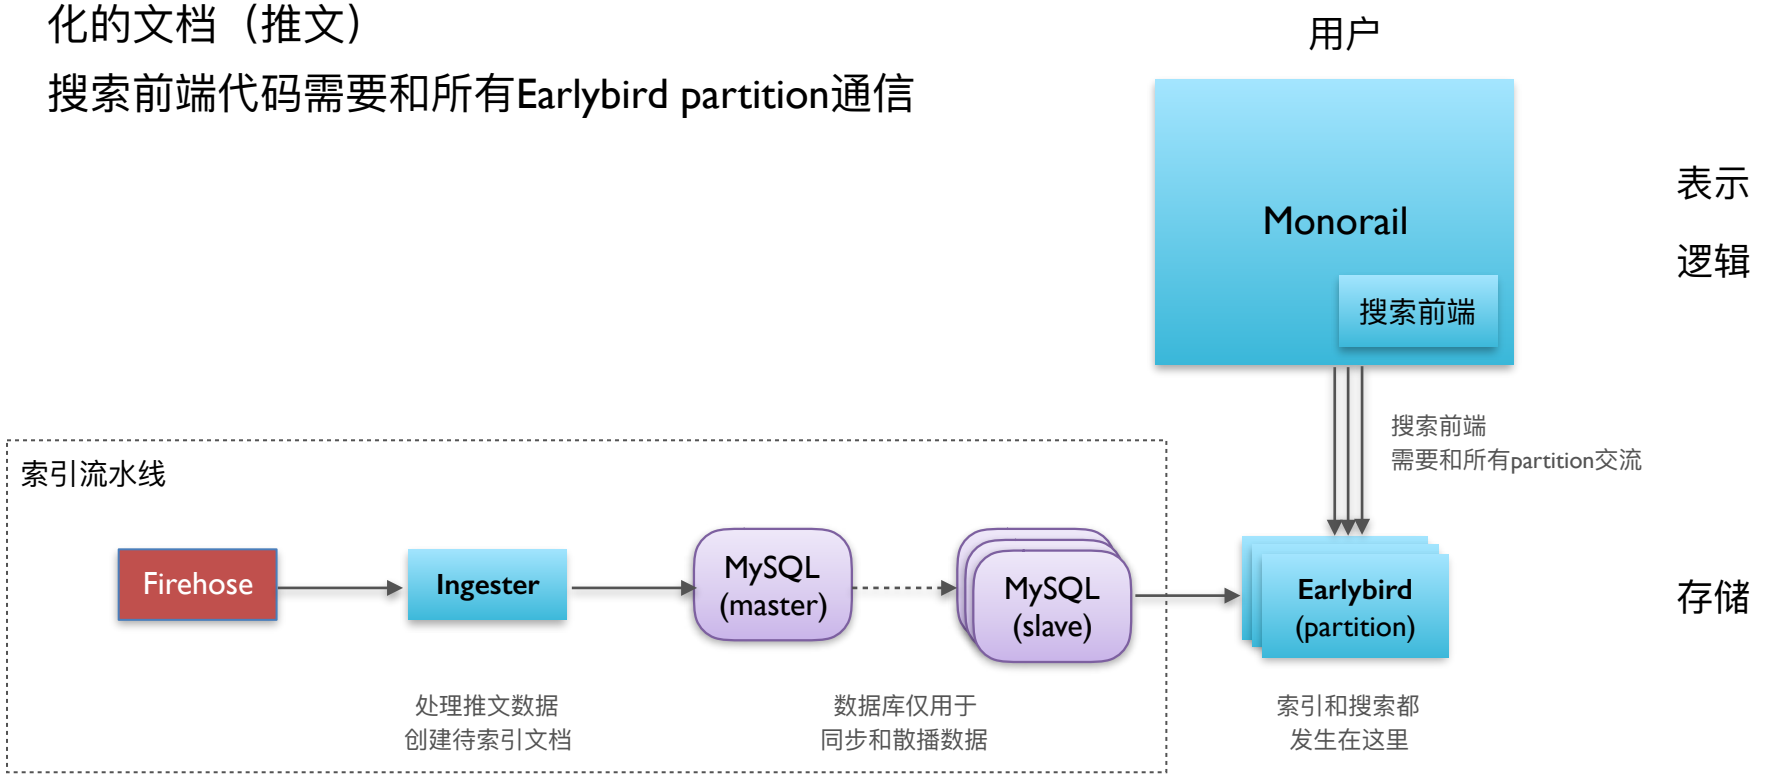

Earlybird

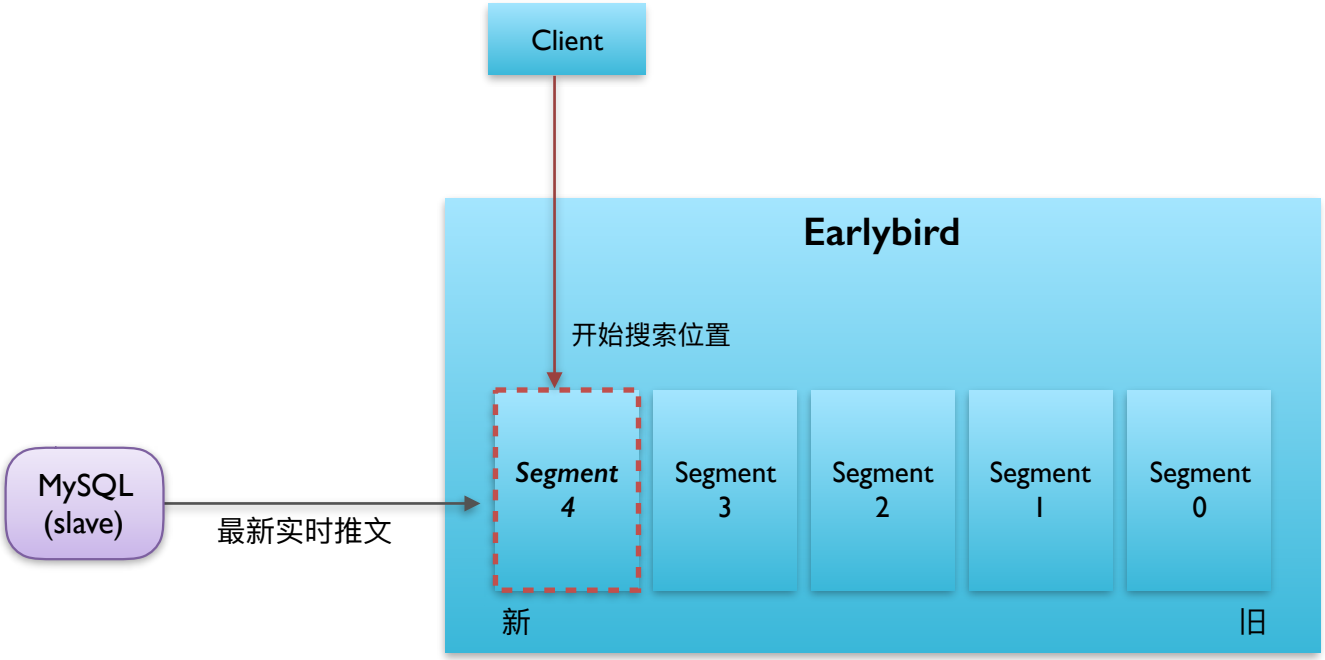

Segment: 一个物理独立的Lucene Index

Posting List中documents按照时间逆序排列

新一代搜索服务器：Blender（2011）

- 一开始作为一个中间层的Earlybird根节点出现
- 附带进行其它附加操作：过滤、填充结果、…
- 设计初期即考虑了通用性，支持多workflow*
- 各种运营便利：
  - 彻底解耦表示和逻辑
  - 对于后台service的统一包装
  - 统一错误处理和跟踪

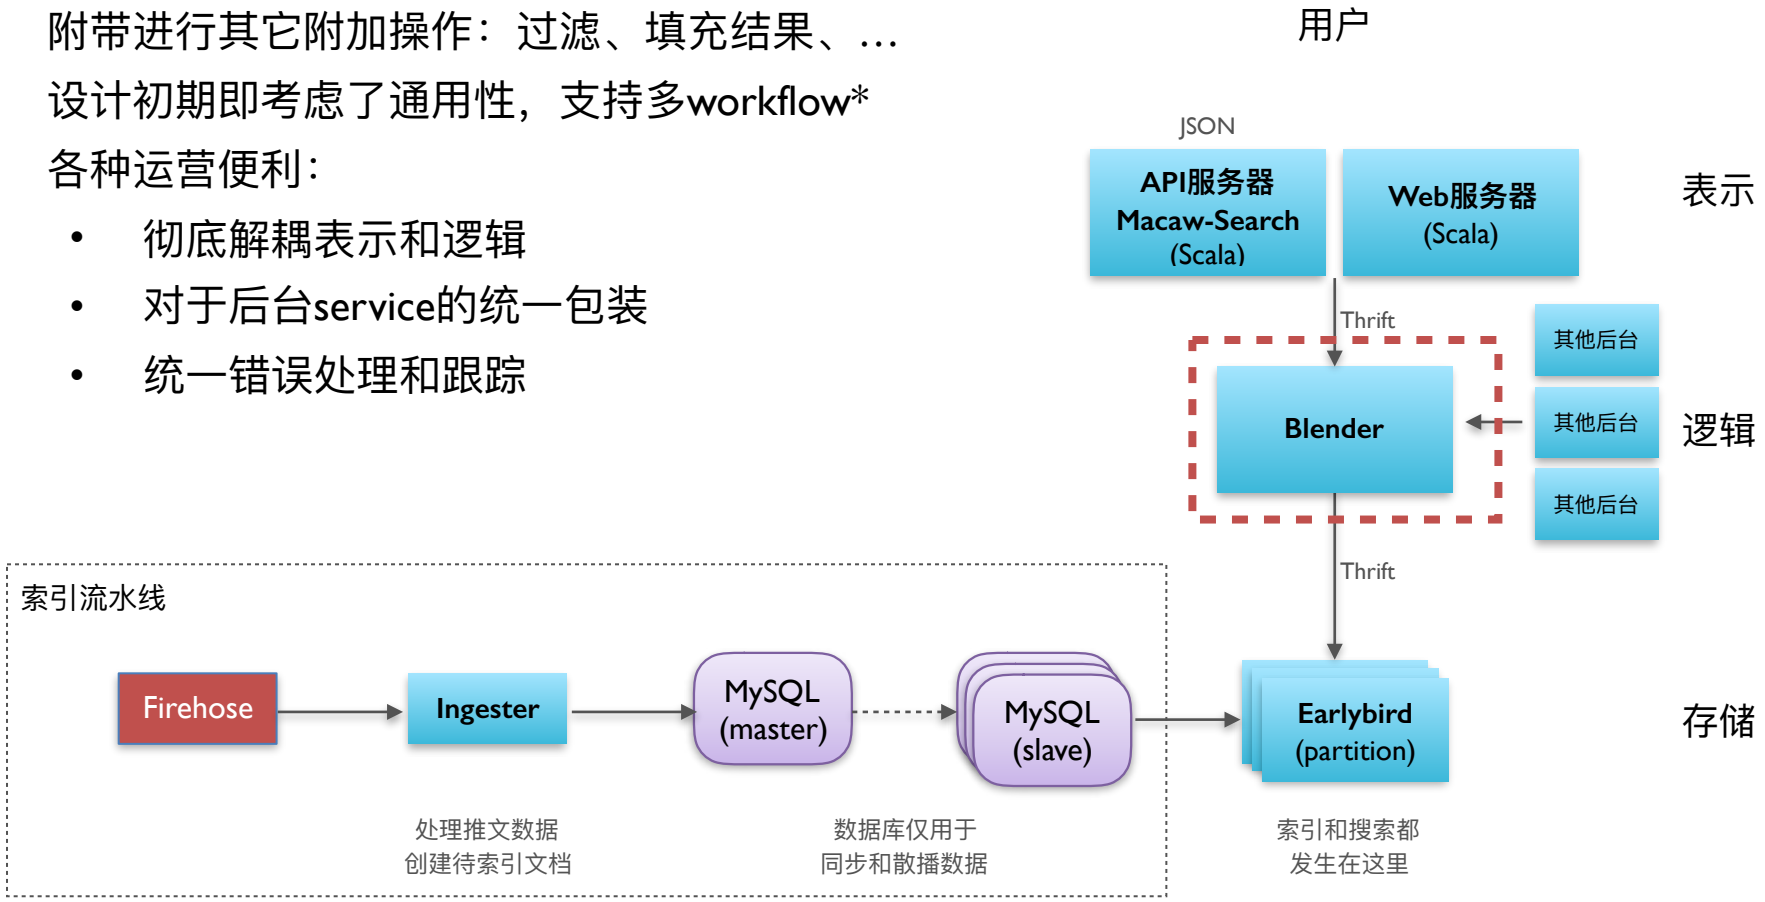

新索引服务器cluster出现

- 因为产品原因产生了多个索引的需求：
  - 实时搜索
  - 隐藏推文搜索
- 需要重新审视索引流水线和索引结构的一般性

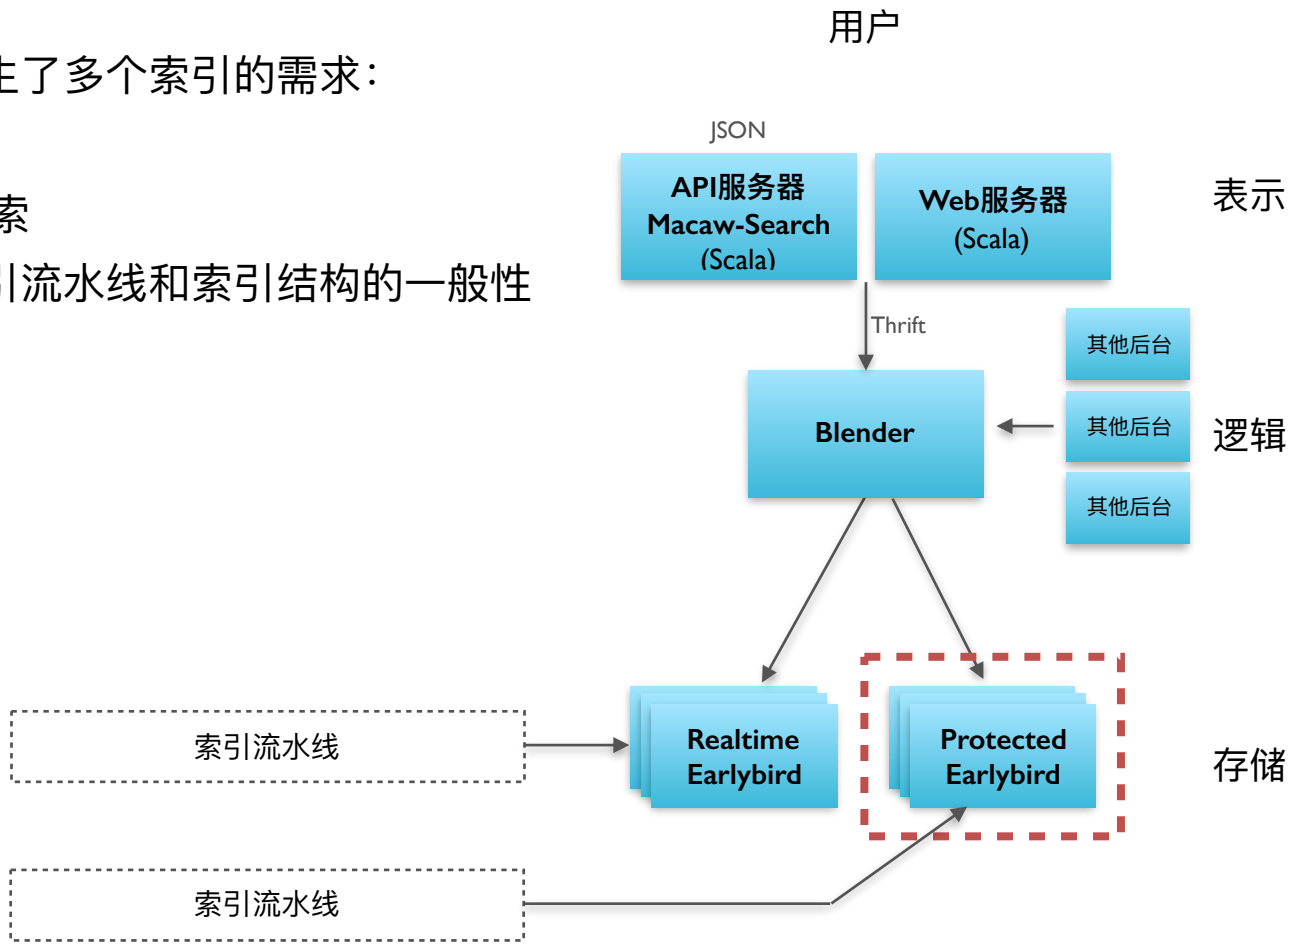

视图简化（一）：Root

- 提供partition无关的索引视图
- 增加轻量级索引根节点Root
- 隐藏索引cluster拓扑信息，统一处理结果合并问题

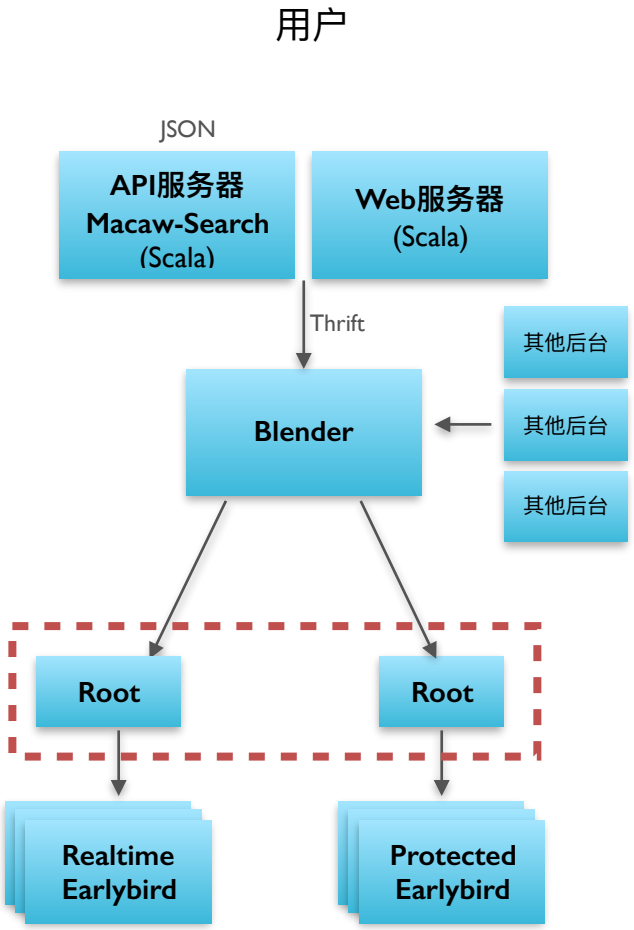

走向完全索引（一）

- 我们仍然只能搜索一周左右的推文
- Twitter从2006到现在累积了6700亿条历史推文
- 需要完整索引，但是按照Realtime索引方式实现代价不菲
- 计划分多阶段考察早期推文的搜索实用性
  - 2% Top (in-memory serve)
  - 16% Top (SSD)
  - Full Index (SSD)
    - 可扩展多层实现
    - 顺序搜索

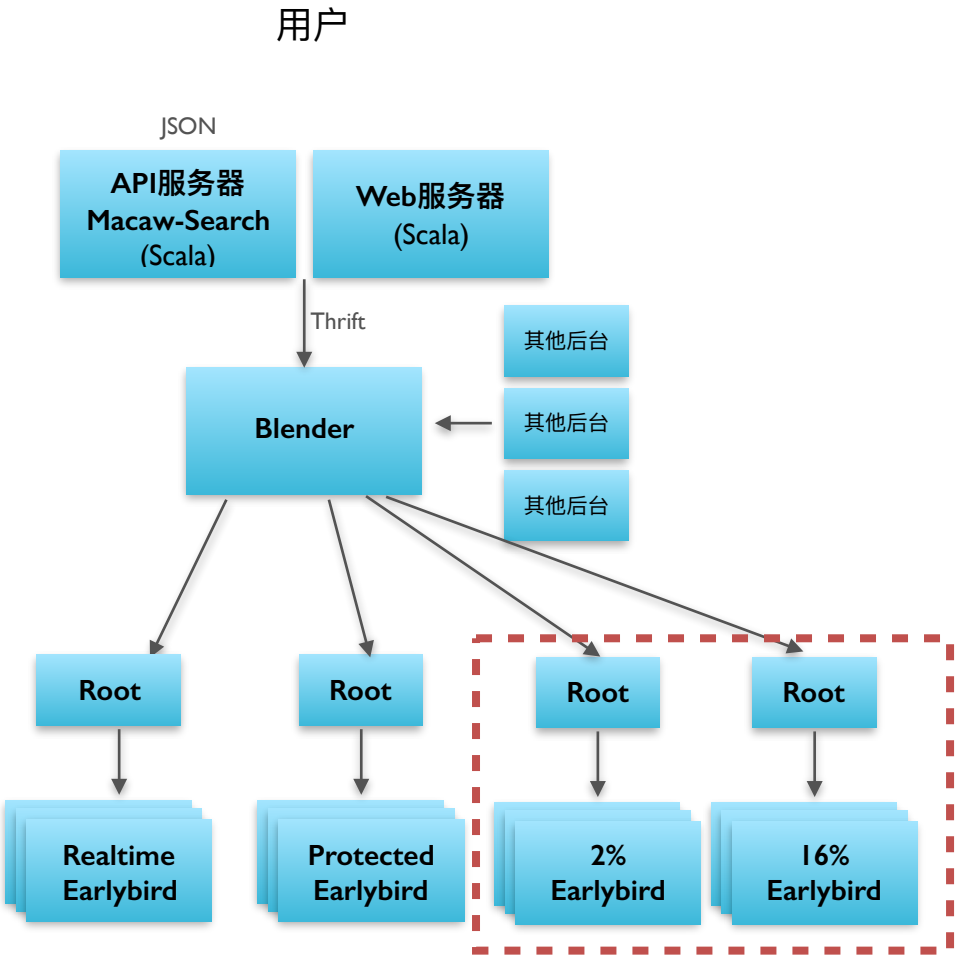

走向完全索引（二）

- 经过一年多的渐进实现，我们逐渐了解了完全索引的存在对用户行为的影响
- 实现了可垂直扩张的完全索引cluster

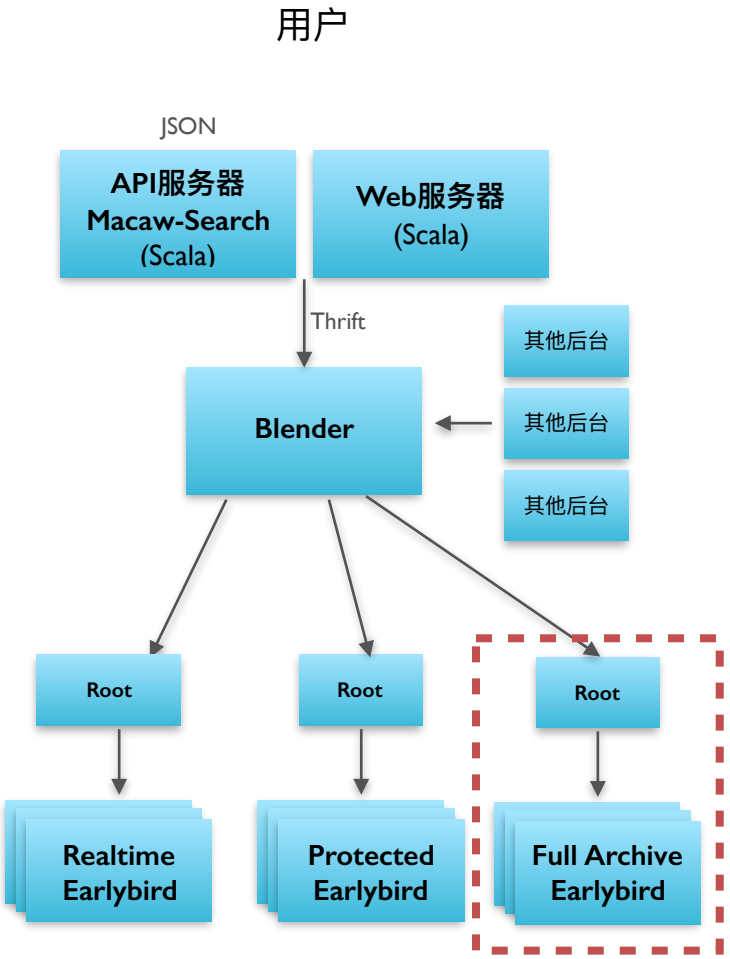

完全索引：Full Archive Index

- 按时间划分的多层索引
- 顶层索引每日更新（3天延迟）
- 一个tier装满后在上面建立新的tier
- 搜索总是从最新的tier开始
- 按用户ID来partition

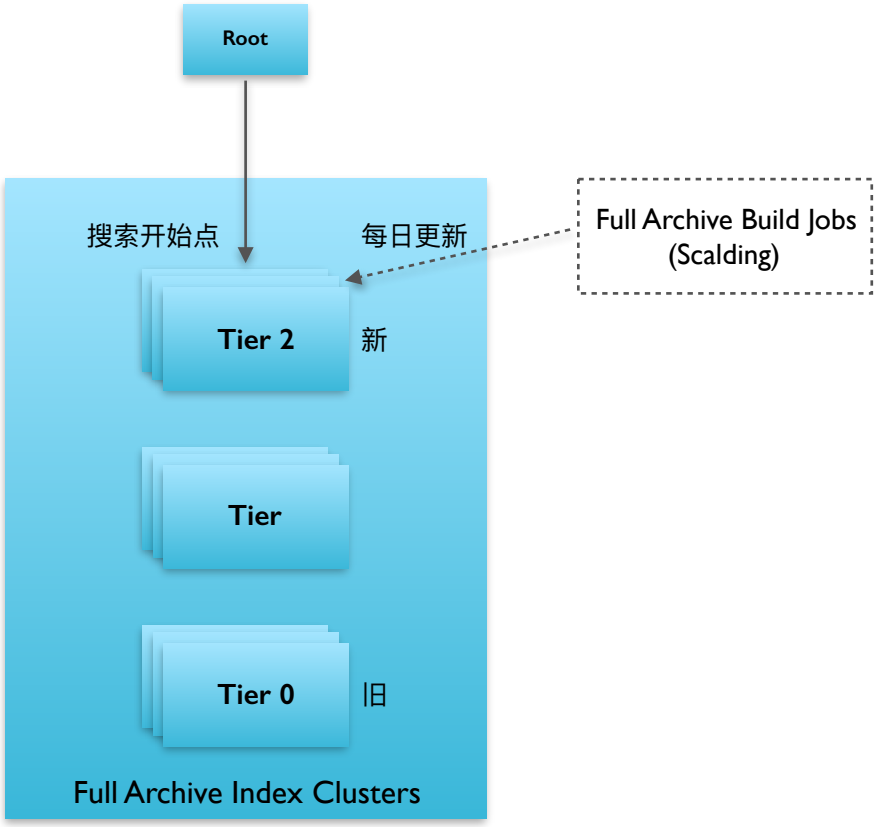

视图简化（二）：Superroot

- 提供简单的索引逻辑视图
- 原先分cluster的索引视图对于搜索产品本身的开发非常方便，但是新兴client并不需要着一些信息
- 提供简单的基础搜索功能入口

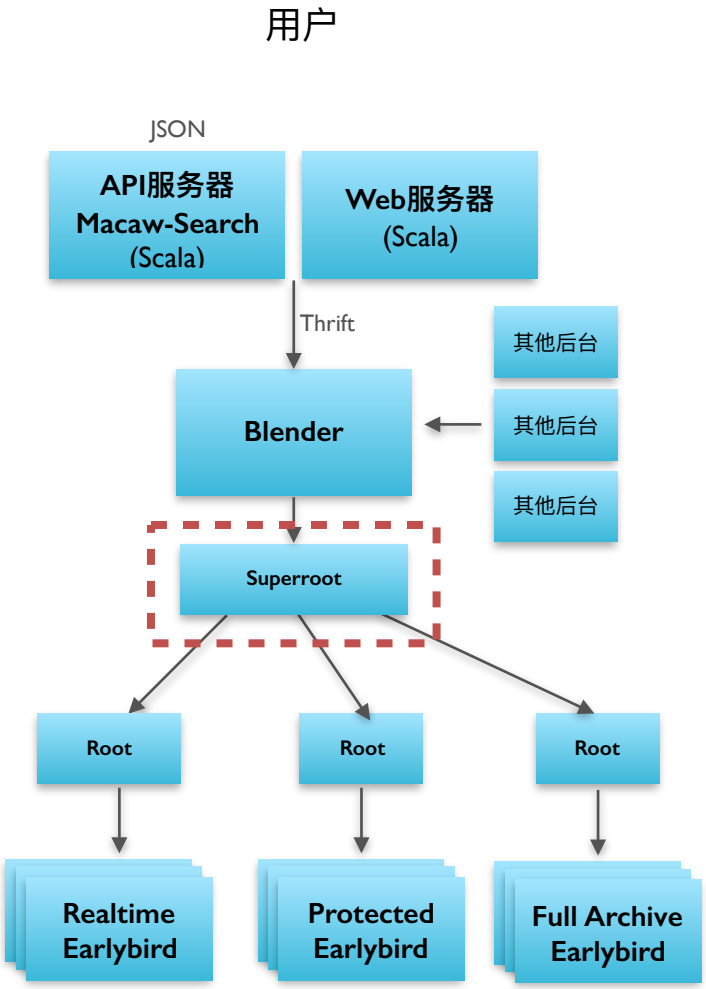

索引流水线的演进（一）

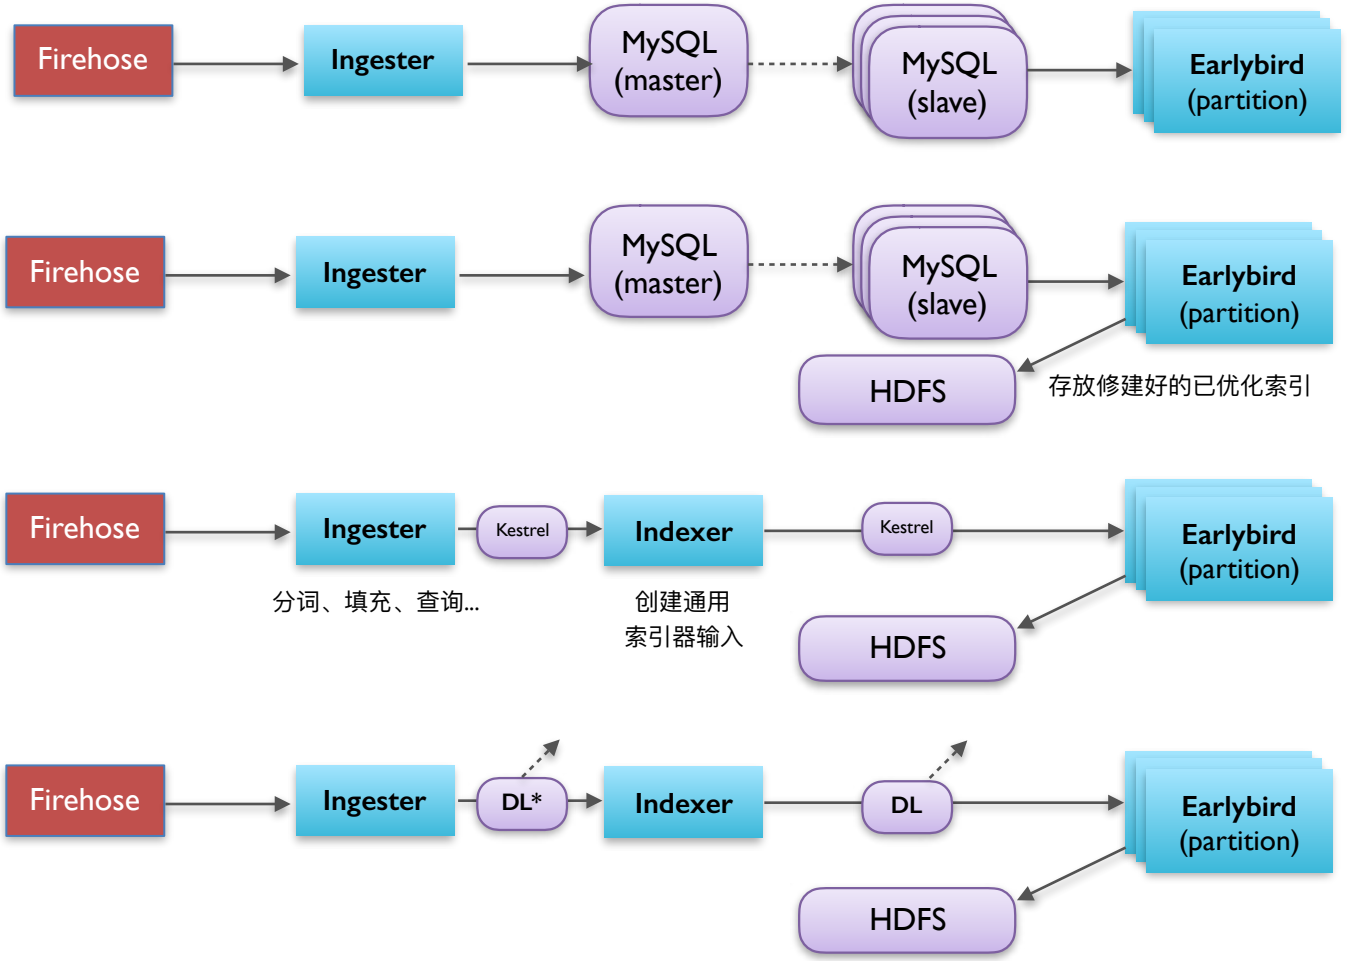

*DL: DistributedLog， Twitter内部开的基于Apache Bookkeeper和HDFS的队列系统

索引流水线的演进（二）

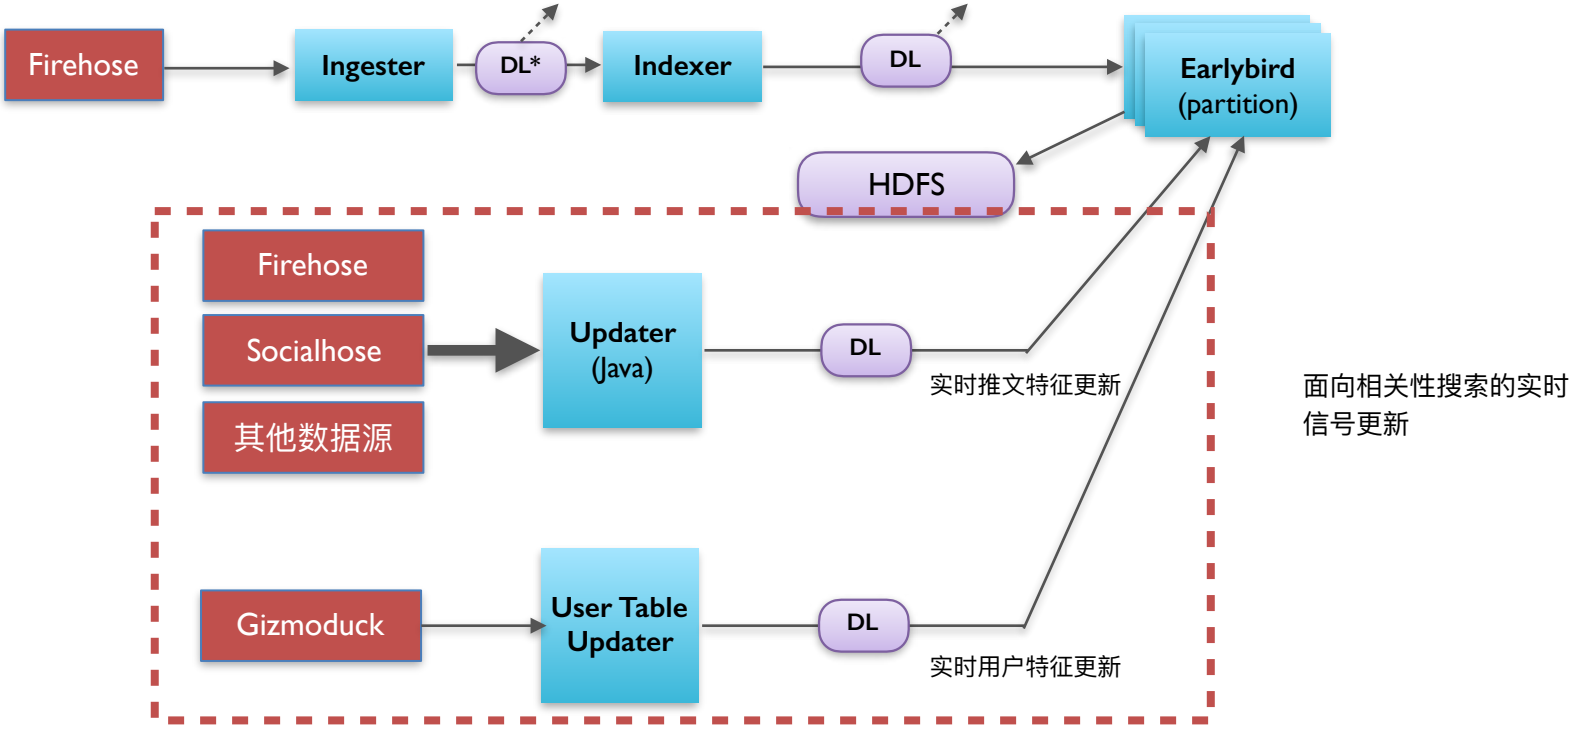
Firehose
Ingester
DL*
Indexer
DL
Earlybird
(partition)
HDFS
Firehose
Socialhose
其他数据源
Updater
(Java)
DL
实时推文特征更新
Gizmoduck
User Table
Updater
DL
实时用户特征更新
面向相关性搜索的实时
信号更新

索引流水线的演进（三）

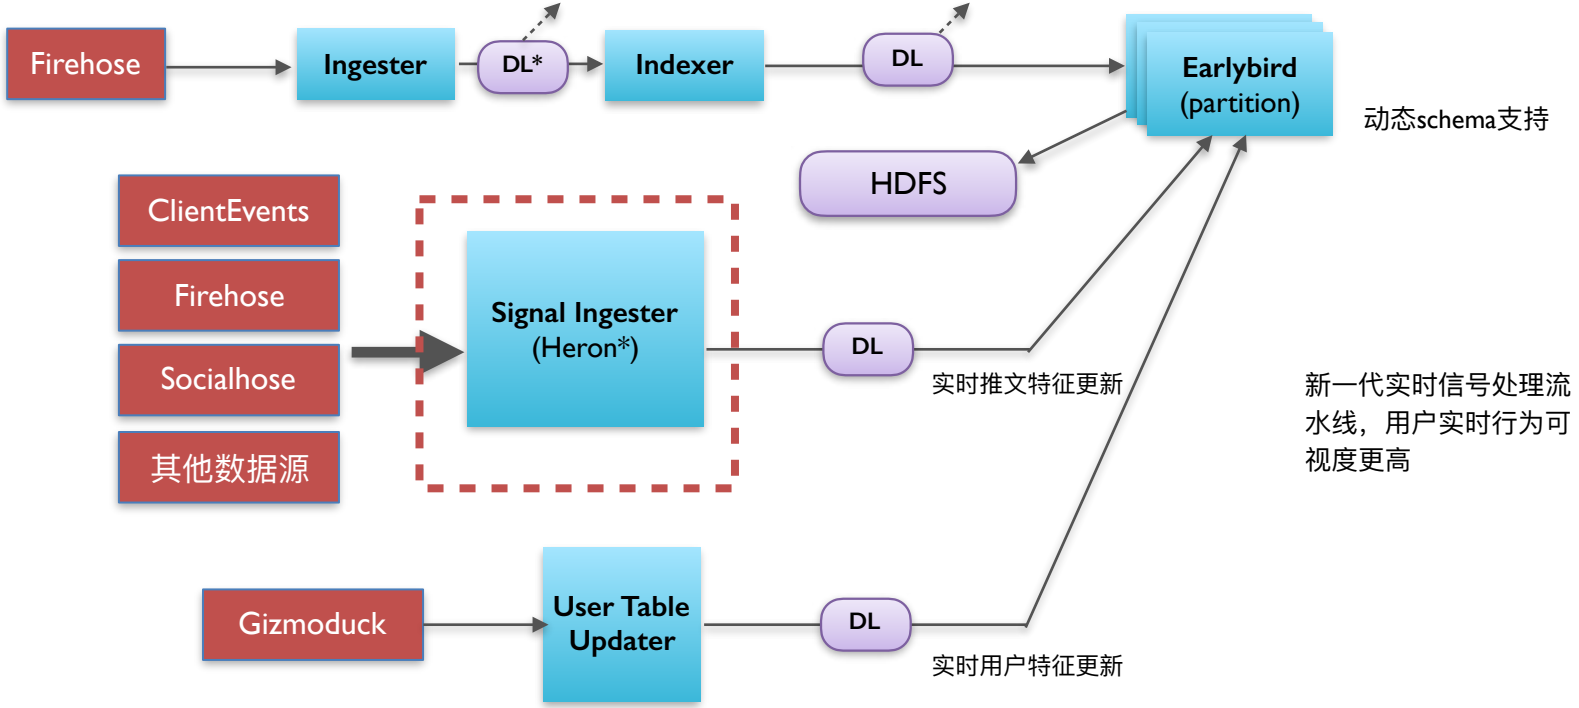

*Heron 是Twitter开发的新一代和Storm兼容的流计算执行引擎

搜索服务器

Blender

Workflow

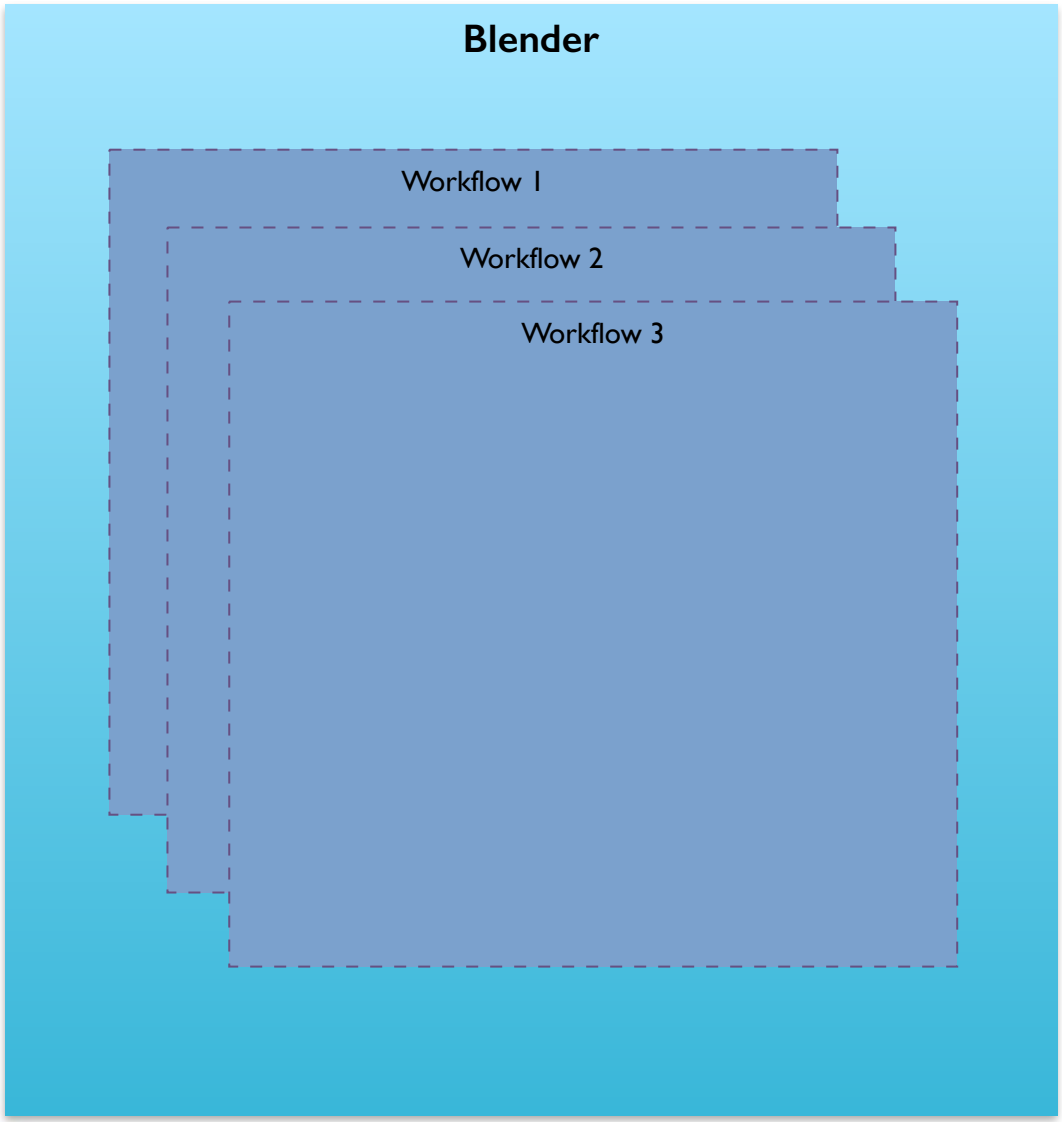

- Blender由多个Workflow组成
  - 同一个Blender可以包含很多完全不同的逻辑步骤
- 每一个Workflow是一个处理输入的特定方式
- 每个Workflow由一个DAG（有向无环图）组成，表示方法经历了若干变化
- Blender的请求中包含Workflow的ID用以选择处理流程

Blender（一）：基于批次的执行器

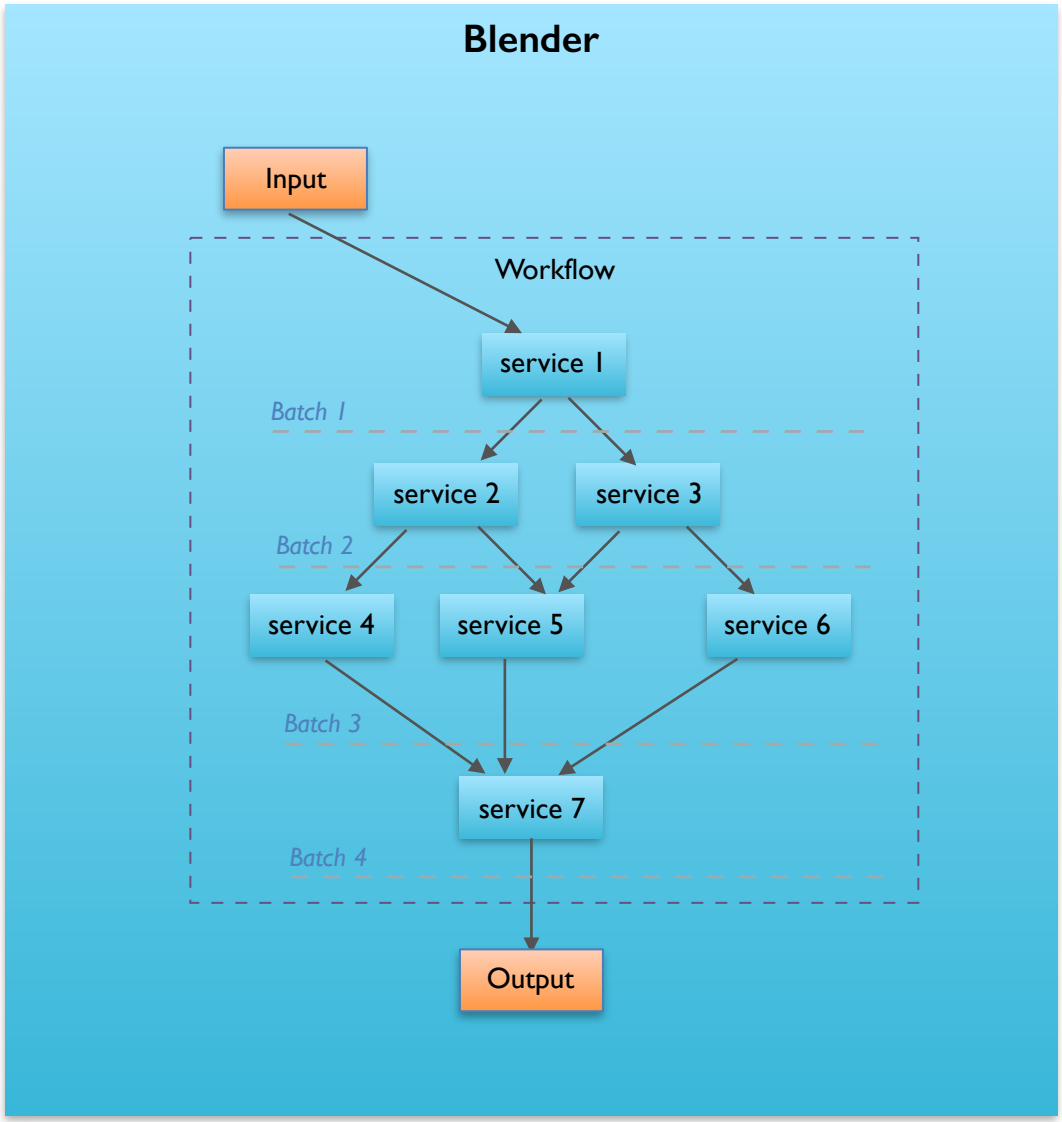

- 依赖关系图（DAG）由代码表示
- 以service调用为节点
- 对DAG拓扑排序后按批次（batch）之行，仅在批次内实现并行化

- 依赖关系清晰
- 实际依赖关系在于数据，而非产生数据的服务
- 服务难以重复调用
- 拓扑排序执行方式效率非最优
- 所有数据全局可见，无法防止任何一步获取它并未依赖的数据

Blender（二）：基于Finagle的执行器

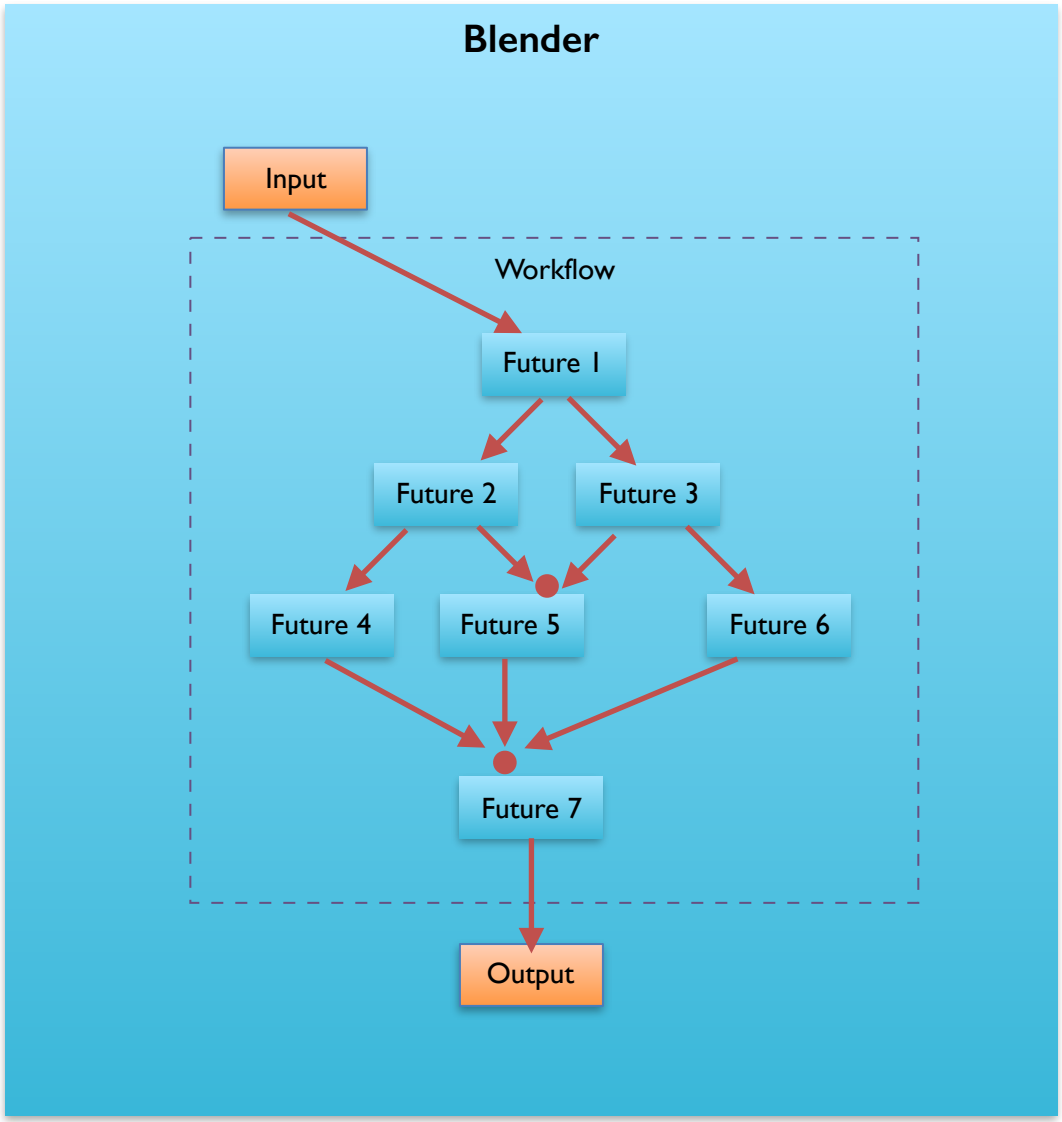

- Finagle是Twitter内部用于规范异步网络编程而出现的软件库
- 提供基于Future链的执行抽象、线程池管理、和失败处理
- 每一个**节点**是一个Future：对应一份可异步获取的数据
- 每一条**边**是一个Future操作：调用外部服务，或者进行本地计算
- 所有的操作都是Future上的代数
  - map
  - flatMap
  - collect
  - join
  - …

- 执行效率高效
- 同步和异步过程得到统一
- 对于大型系统依赖关系变得不明显
- 模块交缠复杂，难以重用
- 难以阅读
- 难以测试

Blender（三）：Nodes

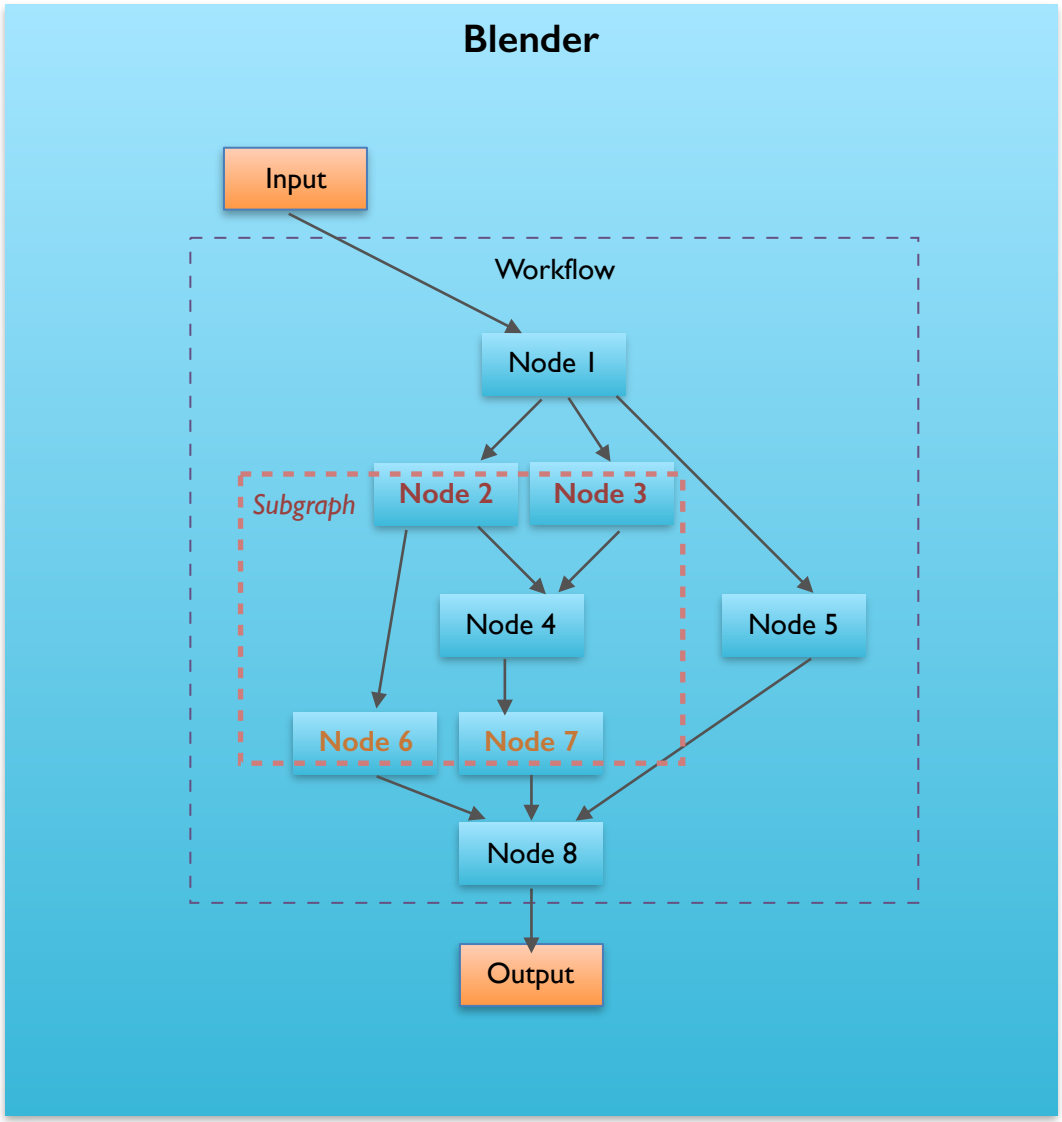

- 进一步抽象和包装Finagle基本Future原语
- **Node**是一个定义了输入依赖和数据类型的异步函数对象，包含**多个输入**和**一个输出**
- **Subgraph**是一系列Node的集合，包含位于边界的**多个输入**和**多个输出**

- 和第二代代码完全兼容，便于分阶段移植
- 清晰地依赖关系（自动可视化）
- 代码清晰易读
- 便于重用
- 便于测试
- 更强大的自动调试功能
- 和Blender本身解耦，可以用于执行任何依赖关系图
- 执行Overhead略高

一个Node

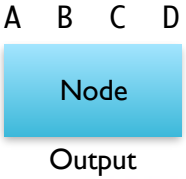

Workflow的滥觞

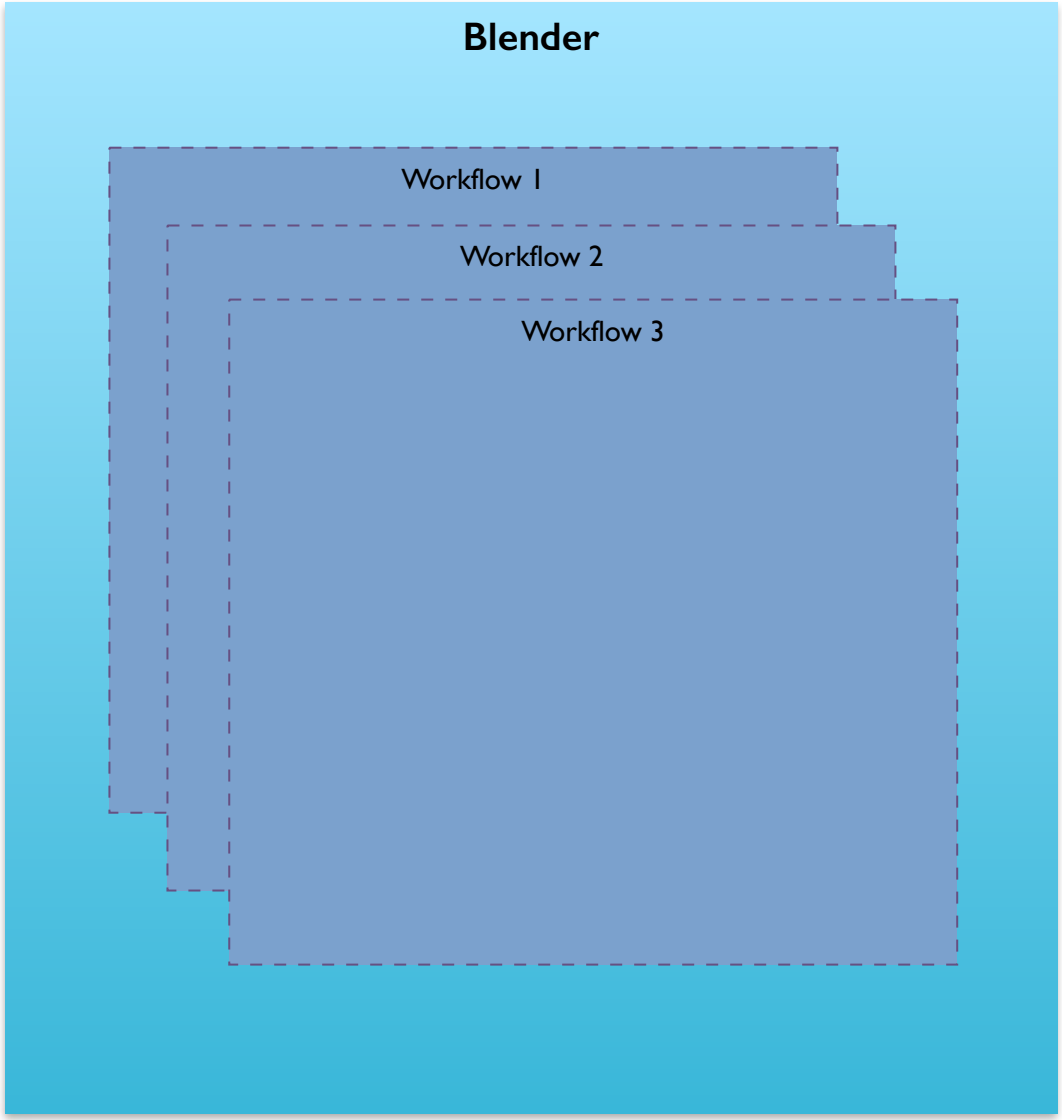

- Workflow的灵活性导致大量被应用
  - 累积了40个不同的workflow
- 因为历史原因，代码重用较差，出现了很多反复书写的类似逻辑

- **解决方法：**
  - 参数化Workflow，合并相似过程
  - 组合Workflow，把总是一起调用的Workflow合并为一个
  - 分拆Blender本身*，独立运营不同的workflow组合

最大的Workflow： Adaptive Workflow

- 提供当前Twitter搜索结果页面
- Twitter内最复杂的单个网络请求（之一?）
- 依赖关系图含有超过1000个节点（本地和远程）
- 耗时中值230ms左右
- 查询和计算超过15000条结果

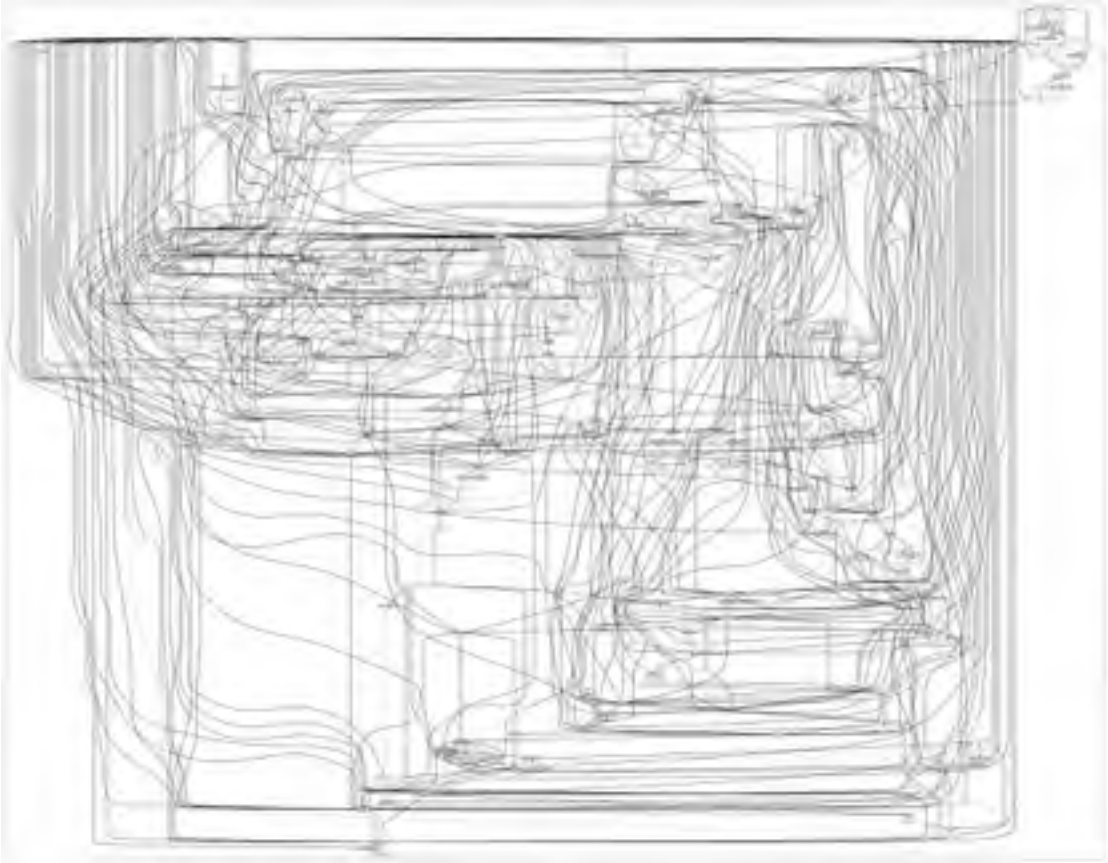

Blender的运营分拆和平台化

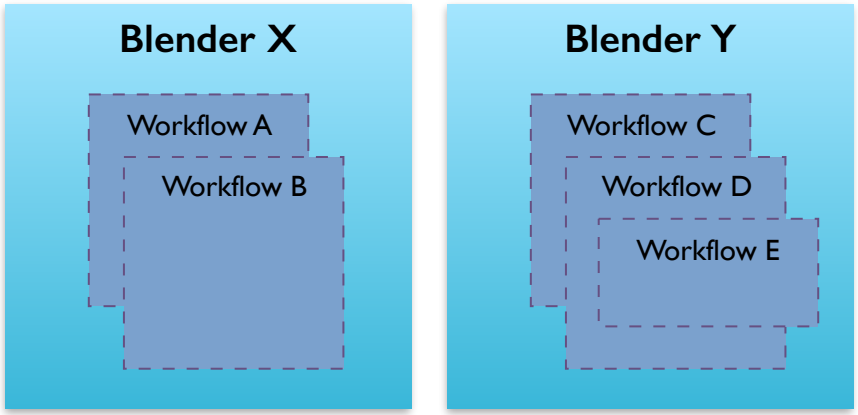

- 我们发现Blender各种Workflow用途区别明显，用户期待差异较大
- 搜索部门没有义务运行和维护所有Workflow
- Blender已经成为了便利的开发框架
- 拆分Blender为多个集群
  - 独立开发，Blender核心团队只提供技术指导和开发指南
  - 独立部署和运营
  - 独立维护
- 如果只需要运行既有Workflow，只需要配置文件变化即可编译和启动一个新集群

- Blender-adaptive：提供Twitter网站和应用上的搜索功能
- Blender-search：提供面向API和数据服务的搜索
- Blender-typeahead：提供Typeahead（自动补全）索引服务
- …

Twitter搜索技术历史

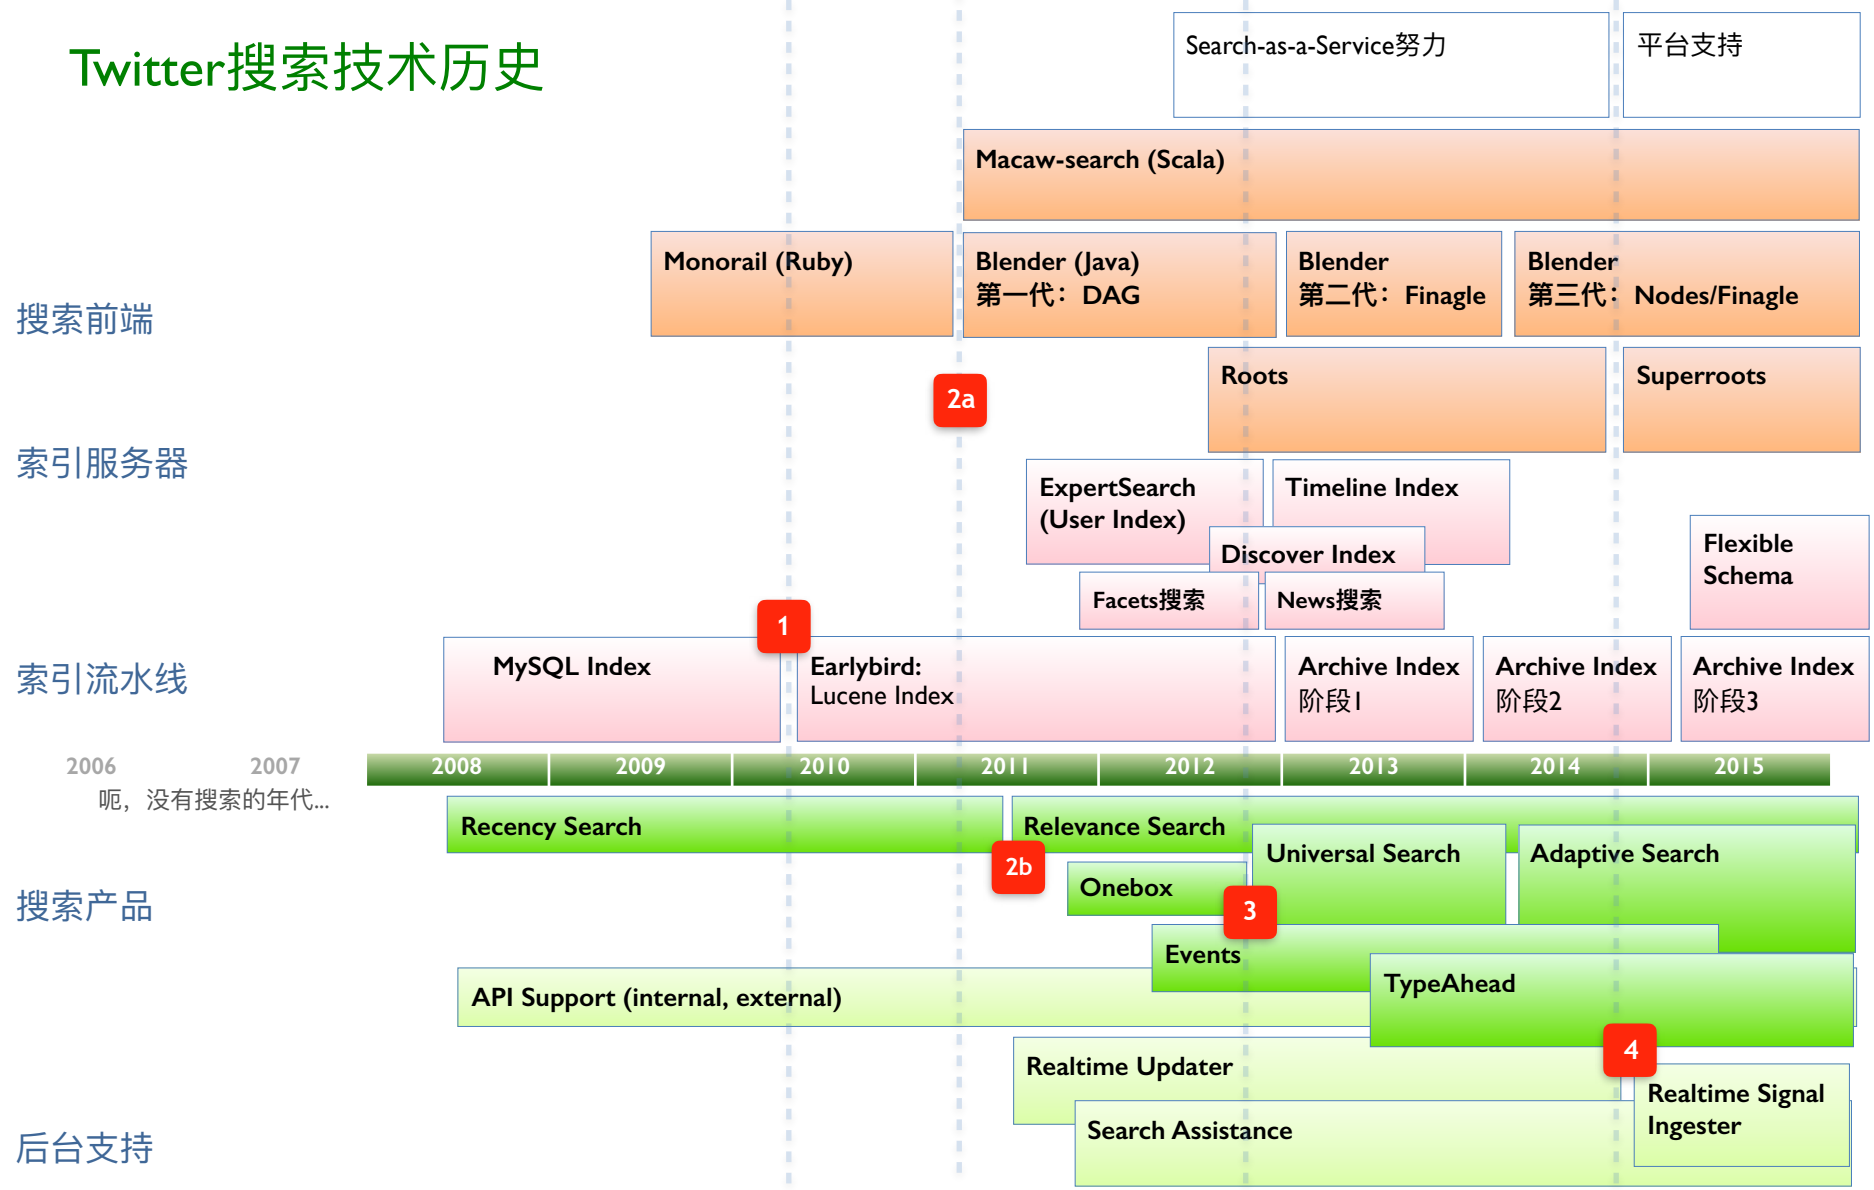

平台化和技术化

- Earlybird：平台化
  - 我们来开发
  - 我们来运行
  - 多客户需求竞争
  - 你出钱
- Blender：技术化
  - 我们出框架
  - 你自己开发
  - 你自己运行

维护质量底线

测试
- Unit Test
- Local End-to-end Test
- Smoke Test (请求重现)
- Quality Smoke Test
- Failover Test
- Stress/Redline Test

流量应对
- 自动功能退化
- 自动缓存策略
- 请求丢弃/快速失败

文档
- 完整的Runbook
- 开发者手册
- 示例代码

发布
- 灰度发布
- 试运行（canary）
- 暗读发布（dark read）
- 回滚支持
  - 自动生成回滚指南
- 向后兼容发布
- JIRA ticket跟踪全过程
- 用户实验发布（DDG）

监测和预警
- 数据输出
- 图表
- 细化预警规则
- 警报应对指南
- 自动/手动数据中心流量转移

- 得益于标准产品化规范，绝大部分质量保证都无需专门设计

Q & A

提问时间

Thanks!