

神盾开放通用推荐系统

雷小平

qq:106093647

email:leixp3636@qq.com

腾讯 社交网络事业群 数据中心

QCon

2016.10.20~22
上海·宝华万豪酒店

全球软件开发大会 2016

[上海站]



购票热线: 010-64738142
会务咨询: qcon@cn.infoq.com
赞助咨询: sponsor@cn.infoq.com
议题提交: speakers@cn.infoq.com
在线咨询 (QQ): 1173834688

团 · 购 · 享 · 受 · 更 · 多 · 优 · 惠

7折 优惠 (截至06月21日)
现在报名, 立省2040元/张



个人团队介绍

个人简介

雷小平 QQ大数据团队平台组组长
推荐系统/分布式计算

团队简介

QQ的基础数据挖掘系统

产品应用系统的研发和运营

<http://www.csdn.net/article/2014-07-03/2820520>

大数据解决方案

- | | |
|----------------|---------------------------|
| 神盾 | - 开放通用推荐系统 |
| ADS | - 数据集市解决方案(第29届中国数据库学术会议) |
| COW | - 分布式流数据存储系统 |
| R ² | - 分布式实时计算系统(2014年全球互联网大会) |
| LBS云 | - 提供统一的LBS云服务 |
| 其他 | - hadoop、storm、spark |

目录

1. 背景介绍
2. 架构介绍
 2. 1 架构总览
 2. 2 分布式计算
 2. 3 数据引擎
 2. 4 海量画像
 2. 5 实时ABTEST
 2. 6 立体监控
 2. 7 通用开放
3. 运营情况

目录

1. 背景介绍
2. 架构介绍
 2. 1 架构总览
 2. 2 分布式计算
 2. 3 数据引擎
 2. 4 海量画像
 2. 5 实时ABTEST
 2. 6 立体监控
 2. 7 通用开放
3. 运营情况

1 背景介绍(1) - 有哪些产品?

好友推荐

聂树林 广东 广州 + 好友

张龙 江苏 南京 + 好友

附近的人

P1G_ 100米以内 + 好友

推荐群

许巍—深圳站 海内存知己 天涯若比邻 94/200 +加群

深圳户外旅游 深圳户外旅游 1964/2000 +加群

★ 推荐

荀你... 锤执着 今天09:17 ★ 热恋过后-庄心妍

动态 与我相关 我的空间 复现

热门歌单

画面太美! 歌后与王兀合作也可以... 中国好歌曲 A.S...

如果时光能倒回

周日22:00, 猜猜志炫会唱什么? 谁是大歌神

更多视频

红领巾工作室 10月 10:28 腾讯视频

必备 热门专栏 腾讯 礼包 赚钱宝

抢鲜体验

下厨房 民间秘传菜单

优惠生活

领十元现金 提现或抵快递

买卖宝商城

3.5分 343万人下载 4.6MB 提到付款，方便有趣的购物平台

轩辕剑

3.2分 5754人下载 73.0MB RPG 版本

动态 游戏中心 搜索

NEW 新游 排行 分类 棋牌

师徒系统来袭，必送45Q币！

龙珠激斗 (七龙珠...) 近7日有118.6万次下载

热游推荐

穿越火线：枪... 三亿手机枪战梦想

热血传奇 重燃热血再战传奇

天天酷跑 最炫最燃的跑酷

中国移动 16:08 我的QQ会员

<返回 更多 >

生活福利

疯抢15元大红包 生活礼券福利不断

免费领10元红包 京东福利天天抢

免费领10元红包 电影大狂欢

抢限量自拍杆 领80元购物优惠券

速抢30M流量 三重好礼惊喜不断

免费领15元红包 美食玩乐享福利

游戏特权

王者荣耀 钻石*60、2级符文:白刃(红色符文)

天天酷跑3D 积分*188 +经验糖果*5

全民突击 钻石*10, 金币*3888, 扫荡券*2, 集火*3, ...

关系链

文本/音频/视频

APP

特权

1

背景介绍(2) - 有哪些场景？



QQ



企鹅FM



全民K歌



QQ音乐

LBS推荐

相关推荐

社会化推荐

兴趣推荐

1

背景介绍(3) - 有哪些交互 ?



QQ会员



企鹅FM



QQ空间



腾讯课堂

用户浏览

产品push

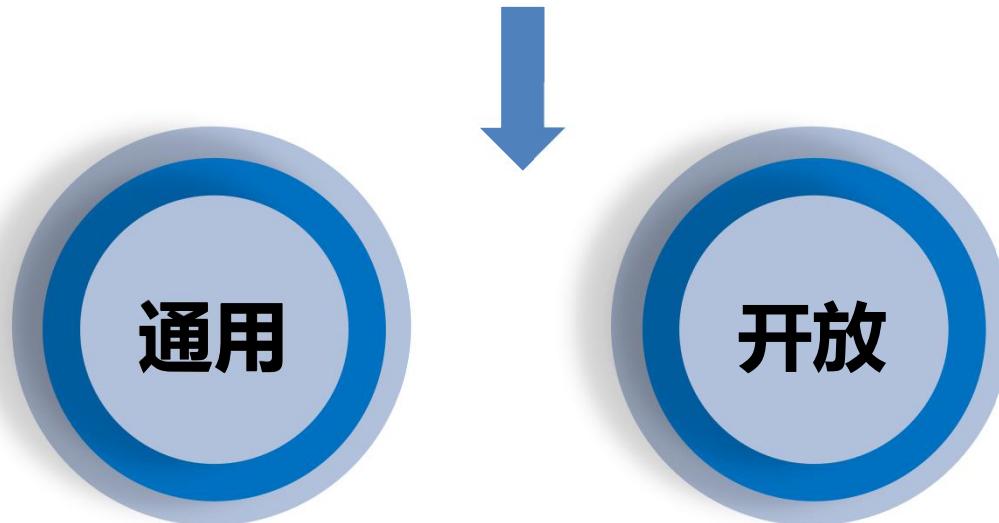
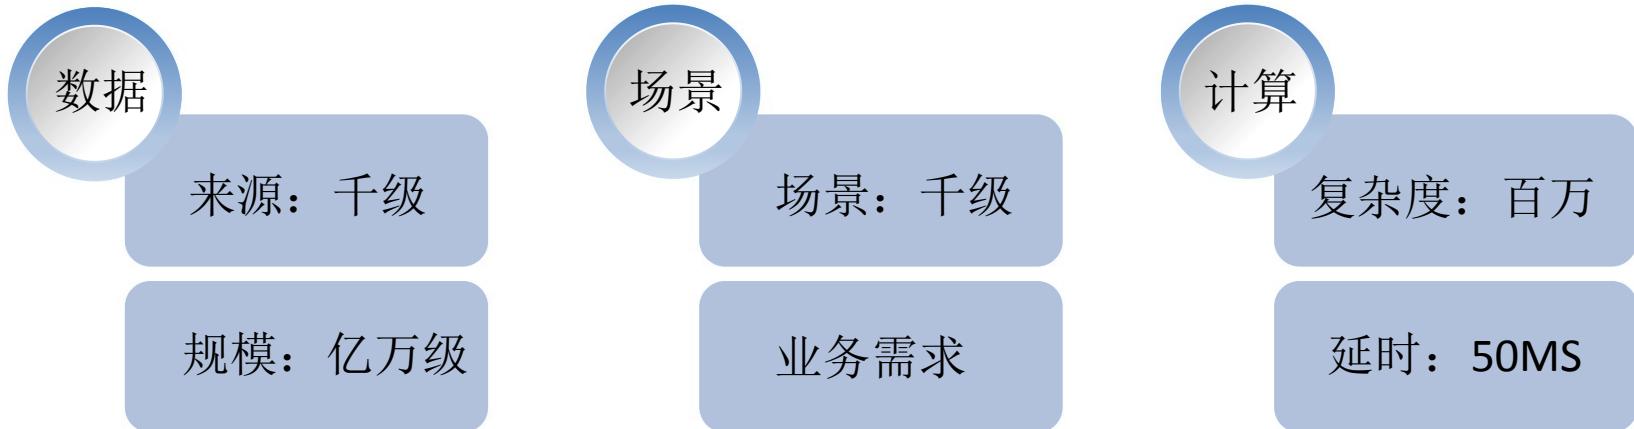
用户反馈

交互式推荐

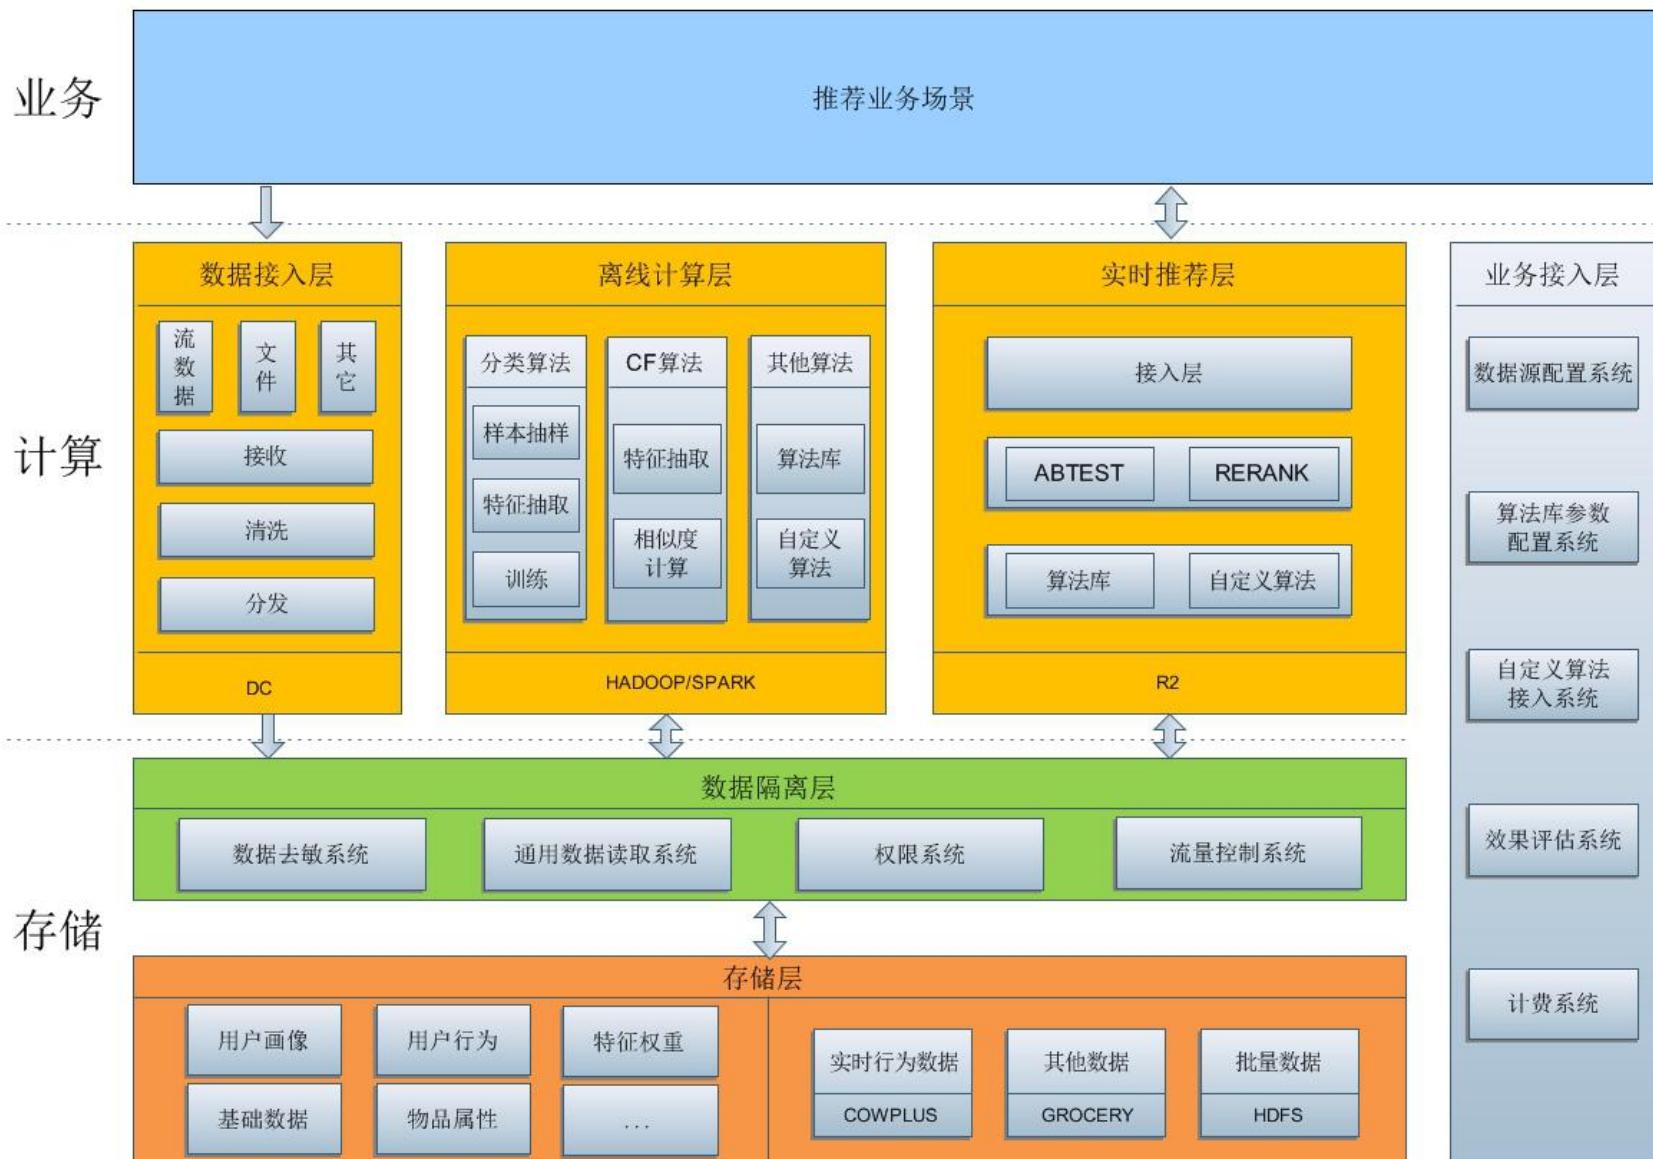
目录

1. 背景介绍
2. 架构介绍
 2. 1 架构总览
 2. 2 分布式计算
 2. 3 数据引擎
 2. 4 海量画像
 2. 5 实时ABTEST
 2. 6 立体监控
 2. 7 通用开放
3. 运营情况

2.1 架构总览 - 系统要解决的问题



2.1 架构总览 – 架构图



2.1 架构总览 - 架构特点

A

分布式计算引擎

B

数据引擎

C

海量画像

D

实时ABTEST

E

立体监控

F

开放通用

2.2 分布式计算引擎(1) – 计算流



- 获取有效池子
- 分人群等

- 性别，年龄，行为等用户属性
- CF，热传导等
- 识别某些CVR高，但是用户不喜欢的badcase
- 应用宝广告推荐提升超过20%

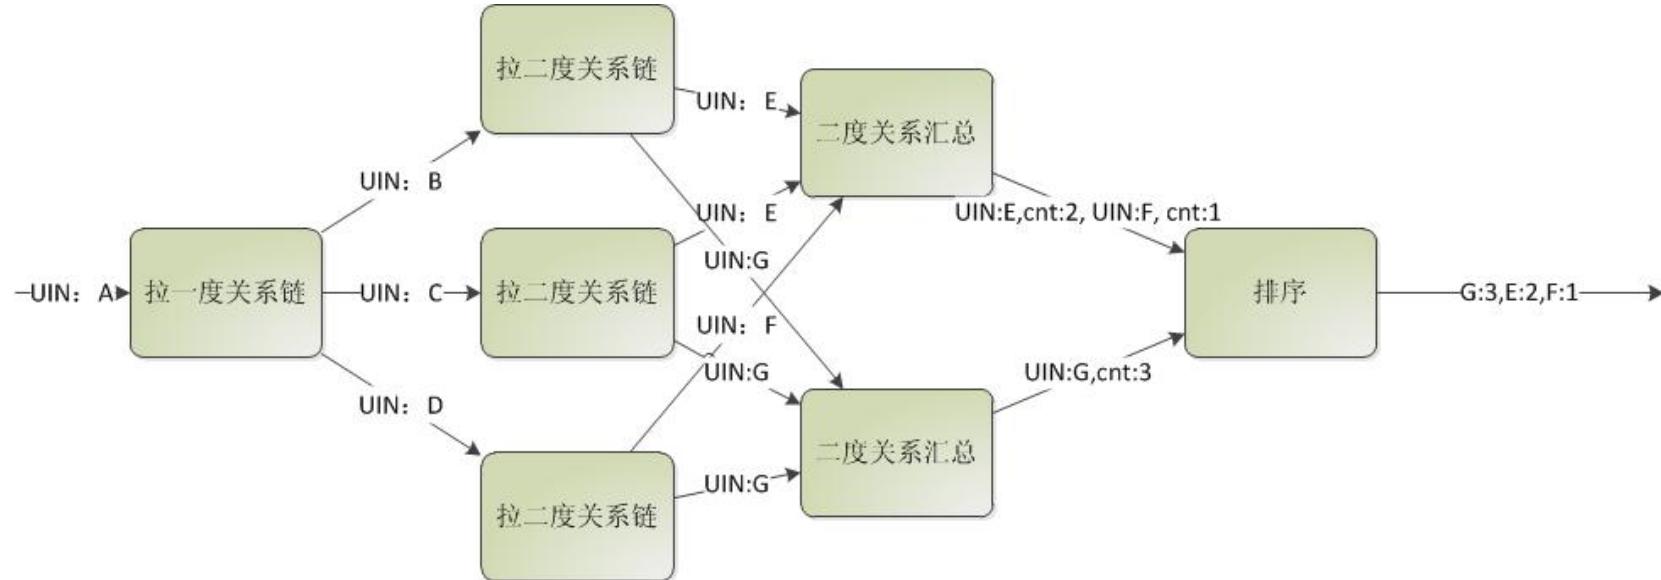
- LR/GBDT/CF等
- 多维度特征

- 曝光衰减
- 产品规则
- 其他badcase

2.2 分布式计算引擎(2) – 复杂计算

要解决的问题：复杂计算VS低延时要求

以QQ好友推荐的抽象逻辑为例：



常规计算

: $\text{sum}(t1)+\text{sum}(t2)+\text{sum}(t3)+\dots$

分布式实时计算

: $\max(t1)+\max(t2)+\max(t3)+\dots$

2.2 分布式计算引擎(3) – why not storm

- 面向服务

- 稳定性
- 流量控制

- 性能

- 数据拷贝
- 资源

- 运维

- 动态负载均衡
- 自动扩缩容

- 开发

- 多线程调试

2.2 分布式计算引擎(4) – 解决方案R2

● 解决的问题

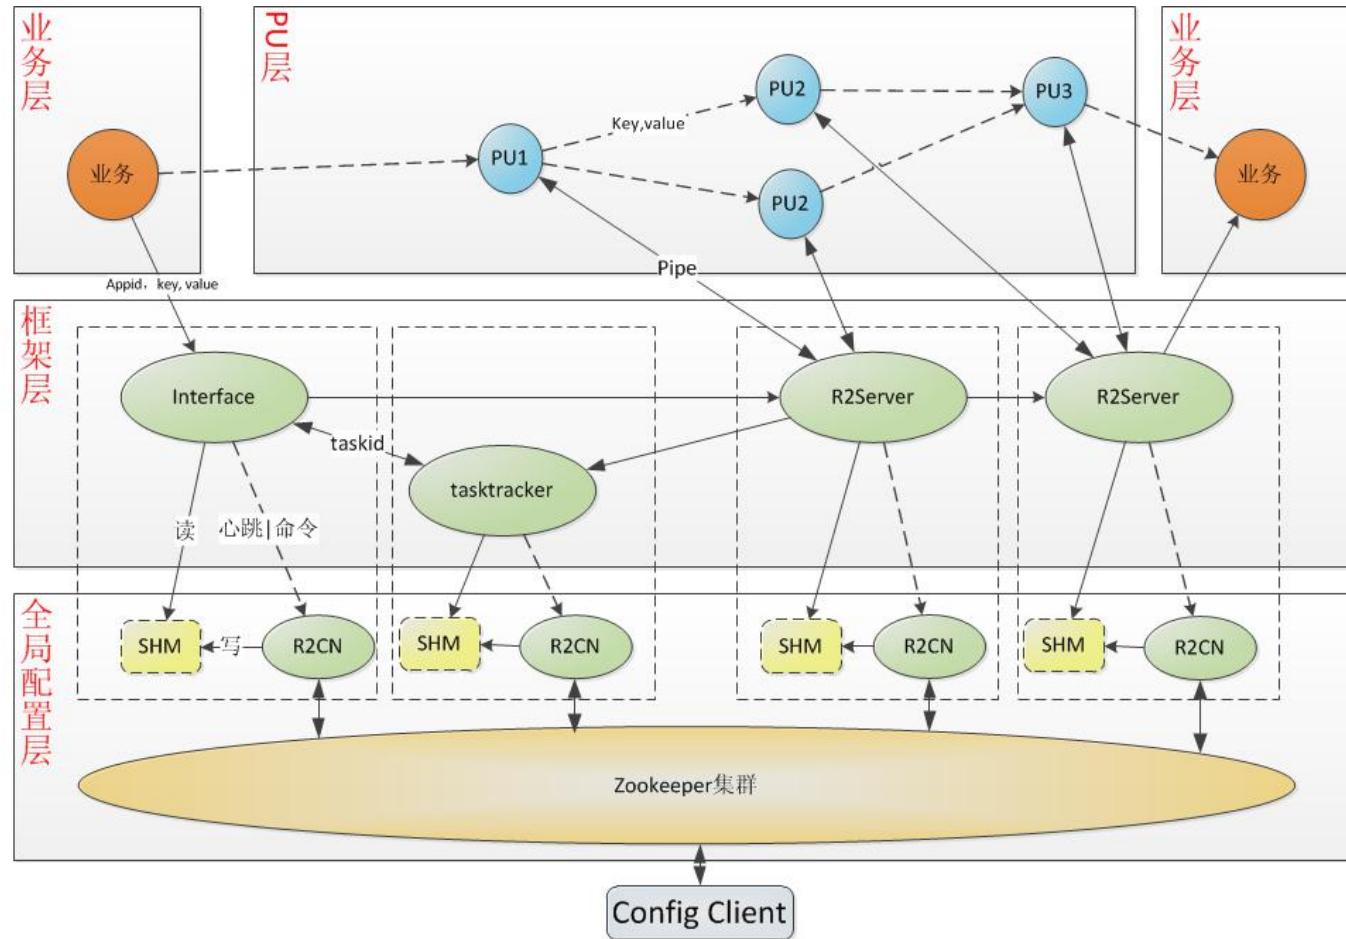
- 大计算量与低延迟
- 即时数据/处理/应用

● 适用业务

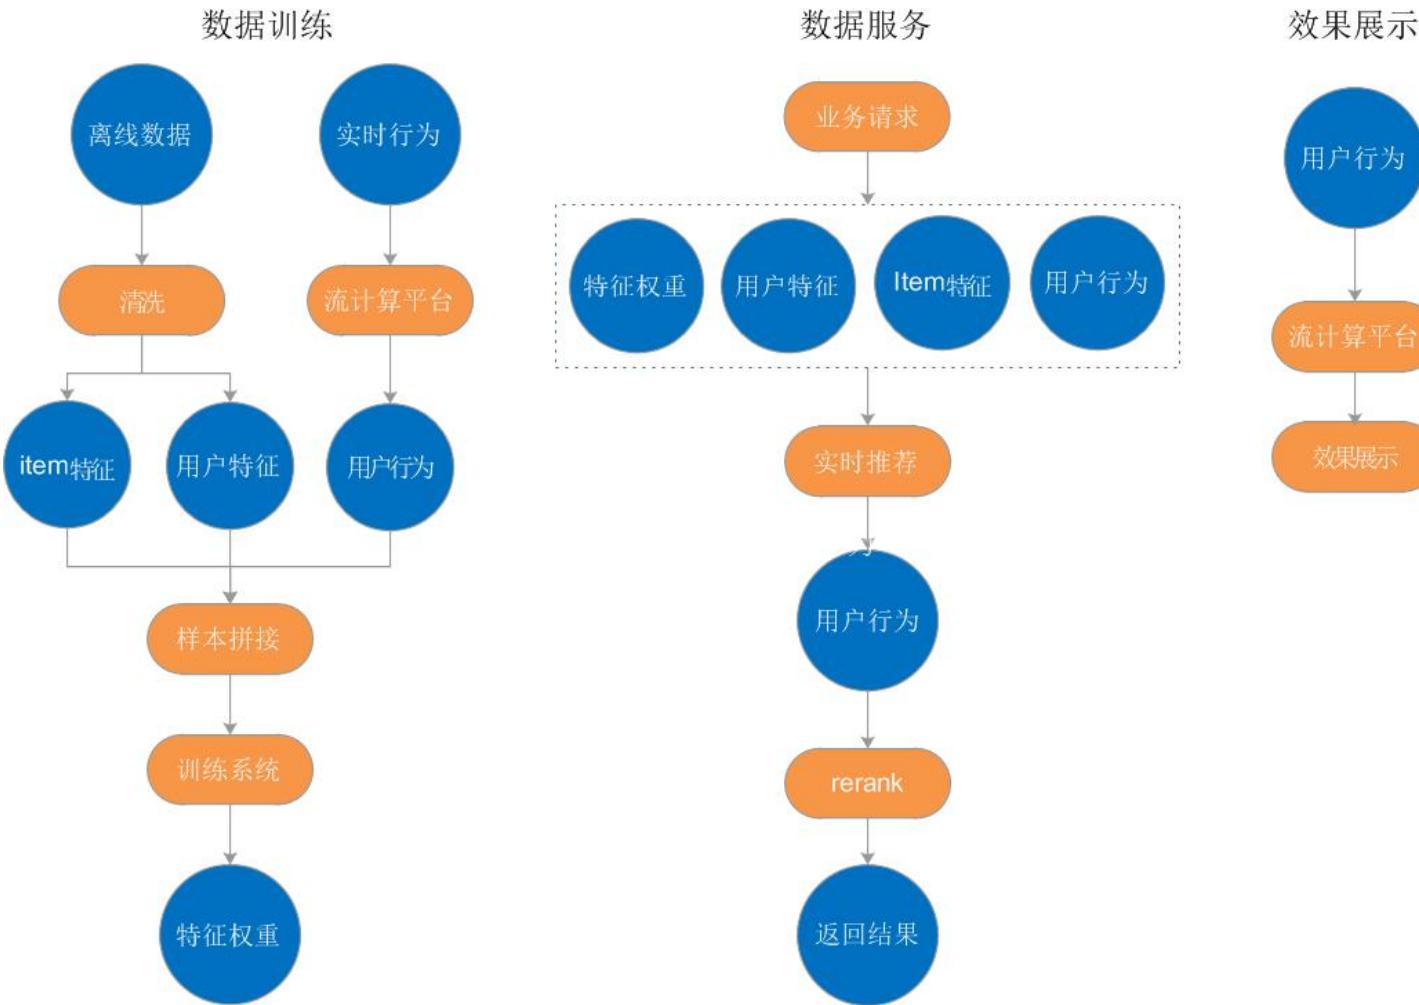
- 计算量比较大
- 对低延迟要求较高
- 实时数据计算&处理

● 计算模式

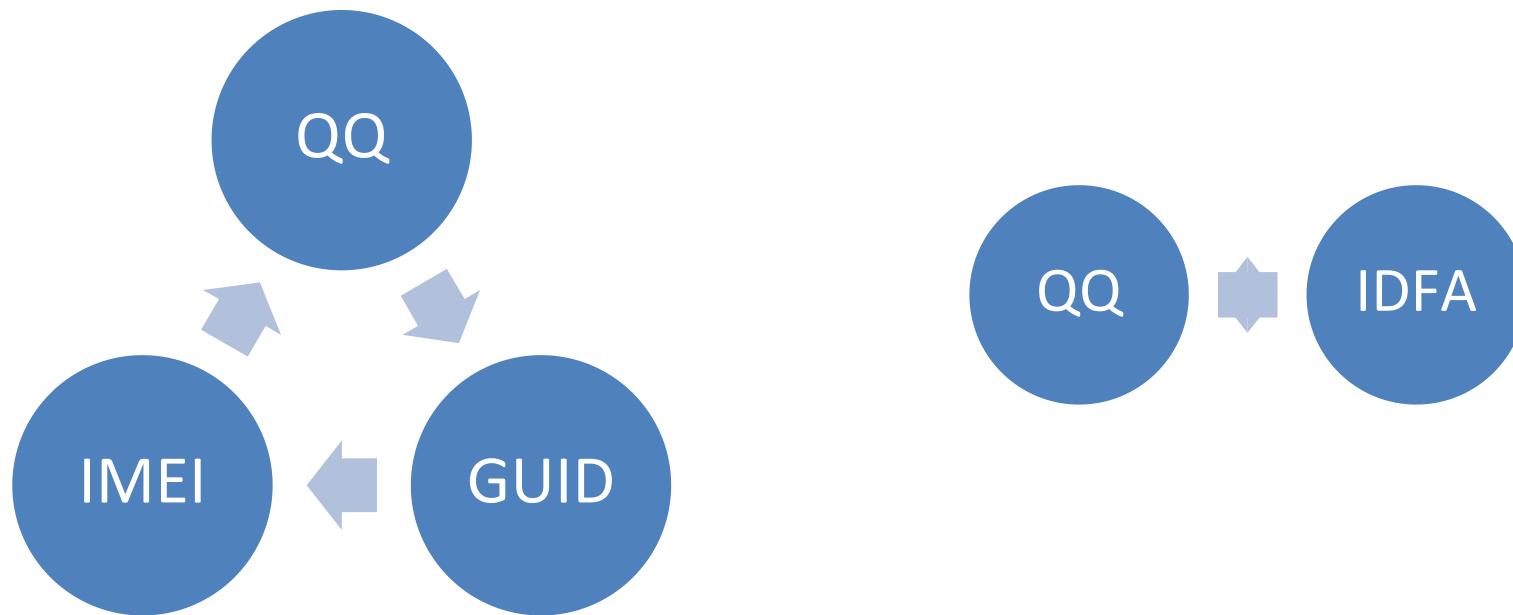
- 类map-reduce
- 实时化，多层次化



2.3 数据引擎(1) – 数据流

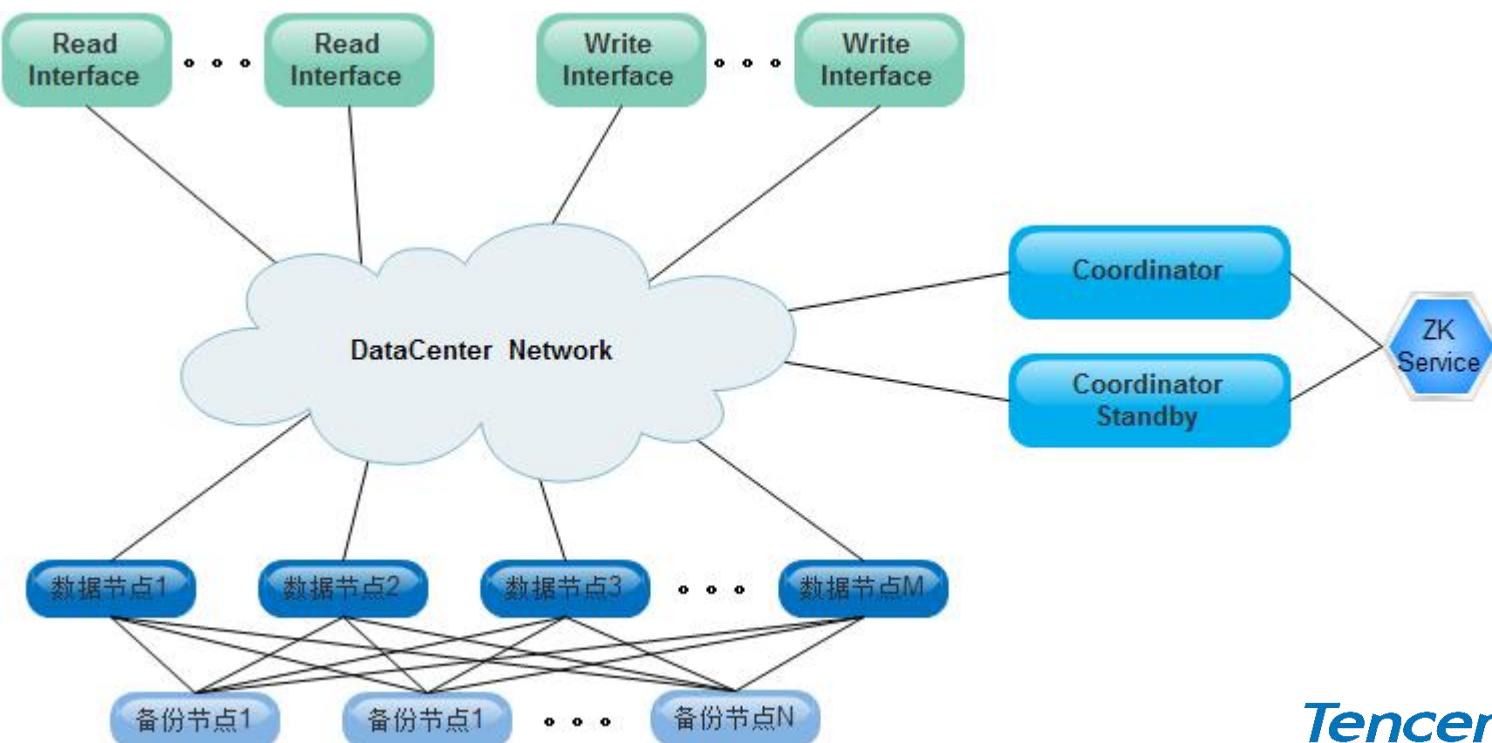


2.3 数据引擎(2) - 账号体系打通



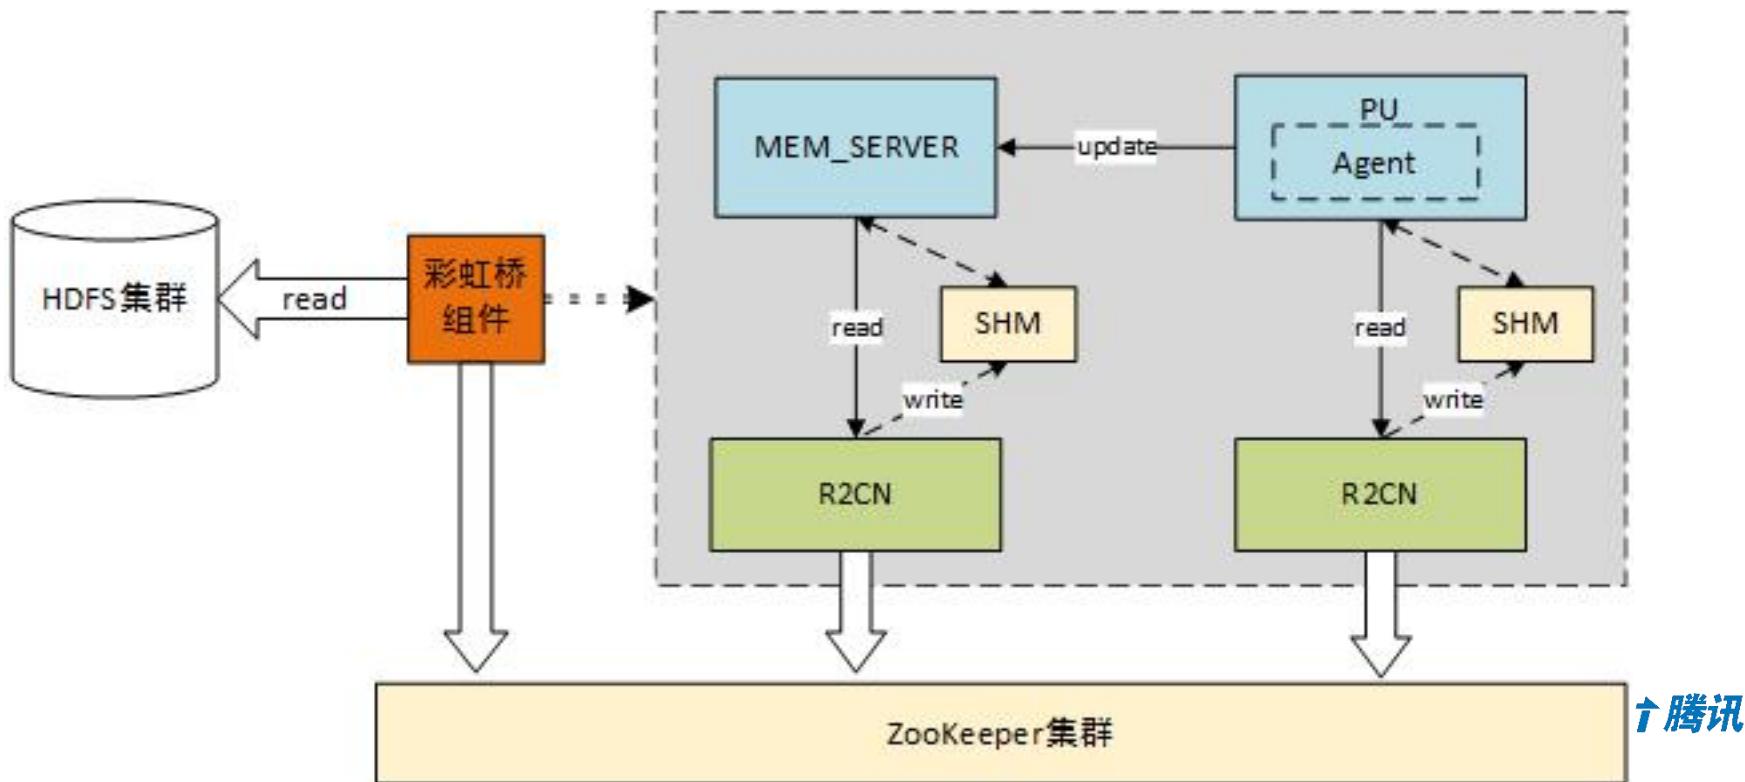
2.3 数据引擎(3) – 行为数据存储cowplus

- 数据量: 300T+
 - 访问量: 百亿级访问
 - 多场景, 多维度读取
- ➡
- 时间维度淘汰
 - 多索引查询
 - 简单计算



2.3 数据引擎(4) – 高速cache

- 每秒千万级读写
 - 随时更新，秒级生效
 - 数据一致性
 - 通用数据格式
-
- Client按需拉取
 - 数据一致性：MD5+ VERSION
 - 数据更新不影响服务：主备切换



2.3 数据引擎(5) - 多数据源读取优化

- 读取多种存储系统
 - 同步编码：开发快，性能差
 - 异步编码：性能高，开发慢
- 
- 协程
 - 多数据源同步编码，异步执行
 - 通用接口
-
- STEP1: 同步编码获取数据源
 - STEP2: 异步并行拉取数据源

```
//同步编码 -- 获取数据源1
get_source1()
{
    //打包
    pack_1(...);
    //收发包API
    send_and_recv();
    //解包
    unpack_1(...);
}
//同步编码 -- 获取数据源2
get_source2()
{
    pack_2(...);
    send_and_recv();
    unpack_2(...);
}
```

```
//将获取数据源1的实现函数放到集合
closures.push(&get_source1);
//将获取数据源2的实现函数放到集合
closures.push(&get_source2);
//异步并行执行多数据源读取
closures.action();
```

2.4 海量画像

- 10多亿用户，几十款产品
- 上千种画像维度
- 多渠道准确度评估

SNG基础画像

- 人口属性
 - 自然属性
 - 家庭属性
 - 教育属性
 - 职业属性
 - 地域属性
 - 财富属性
 - 消费属性
 - 饮食属性
- 用户兴趣
- 上网特征
- 社交图谱

广告类

社交征信类

购物类相关

QQ健康领域

SNG基础画像 > 人口属性 > 自然属性

+ 性别 (i) 用户生理性别，请点击左侧 (i) 按钮获取更多信息

+ 星座 (i) 黄道十二星座

- 年龄 (i) 用户的生理年龄，精确到岁，误差正负2岁

大盘识别人数: 28,194 人 分段

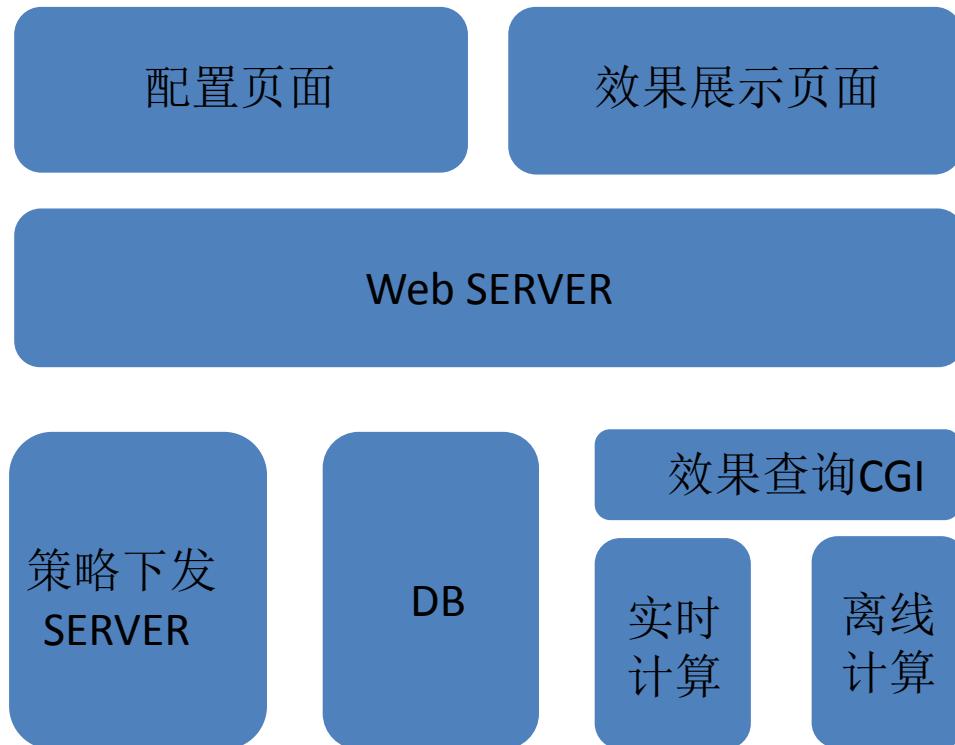
年龄	用户数(人)	人群占比
24	751	5.22%
25	405	4.98%
26	319	4.87%
22	484	4.51%
23	3035	4.48%
27	2379	4.47%
21	1876	4.32%
20	1296	4.27%
19	1732	4.14%
28	534	4.00%

0M 5M 10M 15M 20M 25M 30M 35M 40M 45M

更多

2.5 实时ABTEST(1) – 整体架构

- 分钟级别更新
- 小时维度展示



2.5 实时ABTEST(2) – 用户配置

● ABTEST策略配置

输出策略Id	策略名称	策略条件	策略参数
1005	LR-社会化	{"tail":{"begin":"0","end":"39"}}	{}
1004	LR-GBDT特征	{"tail":{"begin":"40","end":"79"}}	{}
1001	首页参考系-热度	{"tail":{"begin":"80","end":"99"}}	{}

● 效果指标配置

指标配置			
操作	序号 ▼ ^	指标来源	
+ -	1	曝光用户数	usrs101
+ -	2	曝光次数	cnt101
+ -	3	点击用户数	usrs102
+ -	4	自定义	[usrs102]/[usrs101]
+ -	5	点击次数	cnt102
+ -	6	自定义	[cnt102]/[cnt101]
+ -	7	报名用户数	usrs103
+ -	8	自定义	[usrs103]/[usrs102]
+ -	9	上课时长过去7天	times104

2.5 实时ABTEST(3) – 效果展示

- 恶意数据过滤
- 效果平滑处理
- 效果波动告警



2.6 立体监控(1) – 线上服务监控

● 业务总体监控

- 请求量 失败量 平均延时 . . .

四级模块: [通用推荐接入层] [接入] 主调模块: 神盾接入服务层测试 被调模块: REQUARE_APPID_GUAJIAN 接口: REQUARE_APPID_GUAJIAN	67 15	400	7.35	99.94%	6.77ms
四级模块: [通用推荐接入层] [接入] 主调模块: 神盾接入服务层测试 被调模块: FM 手Q资料卡推荐 - 默认图标 接口: RSQUARE_APPID_DEMOGRAPHIC_HOT	11 17	12 17	3.7 51	99.95%	7.3ms
四级模块: [通用推荐接入层] [接入] 主调模块: 神盾接入服务层测试 被调模块: 企鹅fm 接口: RSQUARE_APPID_DEMOGRAPHIC_HOT	195 303	3869	1.6 37	99.95%	7.31ms

● 重点函数调用次数监控

- 历史对比
- 波动告警



2.6 立体监控(2) – 其他监控

● 计算过程重放

实时流水查询																		
接口ID		环境设置		正式	测试	索引启动时间:		2016-04-05 15:03:53	索引状态:									
查询日期		开始时间		14	时	50	分	结束时间		15	时	50	分	最大记录数:		100		
uin																查询	导出excel	切换表头
#	reporttime	clientip	uin	imei	seq_no	rt	test_id	r2app_id	ruleid_out	output_value								
1	2016-04-14 14:50:05	████████.62	████████		1460616605		200106	60200	1009	rt: 2001%0Drulei...								
2	2016-04-14 14:50:05	████.0.19	██████		1460616605		200106	60200	1009	rt: 2001%0Drulei...								
3	2016-04-14 14:50:05	████.6.62	██████		1460616605		200106	60200	1009	rt: 2001%0Drulei...								
4	2016-04-14 14:50:05	████.233	██████		1460616605		200106	60200	1009	rt: 6001%0Drulei...								
5	2016-04-14 14:50:05	████.100	██████		1460616605		200106	60200	1009	rt: 2001%0Drulei...								

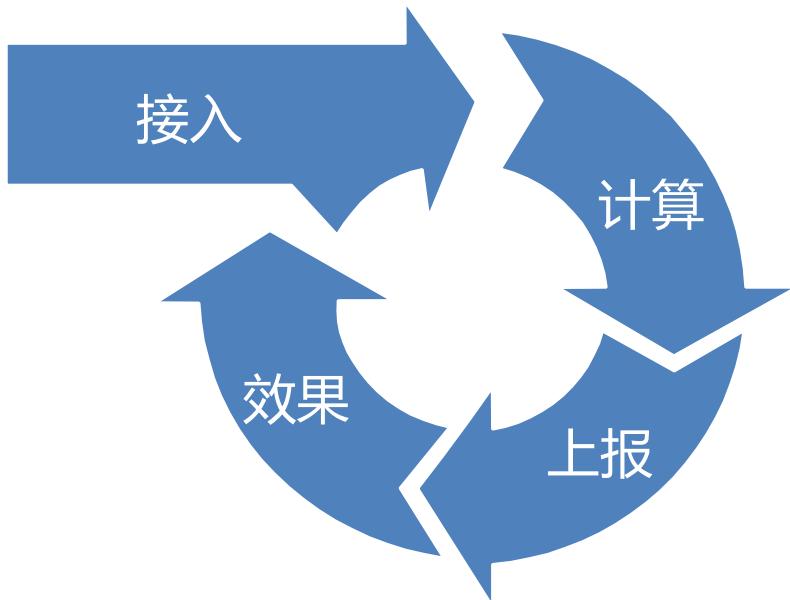
● 推荐效果监控

- 恶意数据过滤
- 效果平滑处理
- 效果波动告警

● 数据监控

- 数据依赖
- 失败告警/重传

2.7 通用开放(1) – 通用接入



- 接入
 - 系统注册
 - 接入API
- 计算
 - 算法选择
 - 参数配置
- 上报
 - 上报字段配置
 - 上报API
- 效果
 - 效果展示字段设置
 - 效果查看

2.7 通用开放(2) – 训练开放

特征构造

全选	特征库名	特征主键	特征副键	来源	来源(归一化)(可以为空)
<input type="checkbox"/>	pendant	cross_try_gender_dis	gender_dis	\${base:pendant:1}(*).\${base:pendant:1}_cnt_4w_gender_dis:.*}	\${base:gender_w_1}.\${pendant:try_cnt_4w_gender_dis:.*}
<input type="checkbox"/>	pendant	cross_try_vip	vip	\${base:pendant:1}(*).\${base:pendant:1}_cnt_4w_vip:.*}	\${base:vip:1}.\${pendant:try_cnt_4w_vip:.*}
<input type="checkbox"/>	pendant	cross_try_vip_dis	vip_dis	\${base:vip:1}.\${base:pendant:1}_cnt_4w_vip_dis:.*}	\${base:vip:1}.\${base:pendant:try_cnt_4w_vip_dis:.*}
<input type="checkbox"/>	pendant	set	.*	f_rcmd_feature_norm_score_d	f_rcmd_feature_norm_score_d
<input type="checkbox"/>	pendant	set_cnt_4w_age	.*	f_rcmd_feature_norm_score_d	f_rcmd_feature_norm_score_d

算法选择

全选	业务ID	业务名称	算法ID	算法名称	算法类型	样本表(可以为空)	抽样规则(可以为空)	更新周期(可以为空)	建模方式(1-按场景,2-按模型)
<input type="checkbox"/>	4	挂件推荐	40004	LR-新用户	LogisticRegression	f_rcmd_pendan..._sample_new_d	随机	w	1
<input type="checkbox"/>	4	挂件推荐	40005	LR-活跃用户	LogisticRegression	f_rcmd_pendan..._sample_active_d	随机	w	1
<input type="checkbox"/>	4	挂件推荐	40006	LR-流失用户	LogisticRegression	f_rcmd_pendan..._sample_losing_d	随机	w	1

特征选择

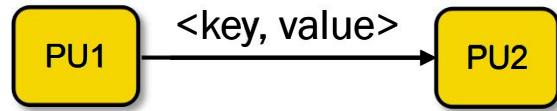
全选	算法ID	特征模块	特征类型	特征ID	取数模式	更新时间
<input type="checkbox"/>	50200	yyb	dis_app..._copair	.*	2	2016-04-16 13:50:00
<input type="checkbox"/>	50034	yyb	app_filter..._adpos1_cvr_day	.*	2	2016-04-16 12:56:07
<input type="checkbox"/>	50034	yyb	cross_care..._adpos1_cv..._adpos1_cvr_day_cross_discretization_dl_count	.*	2	2016-04-16 12:56:07

训练



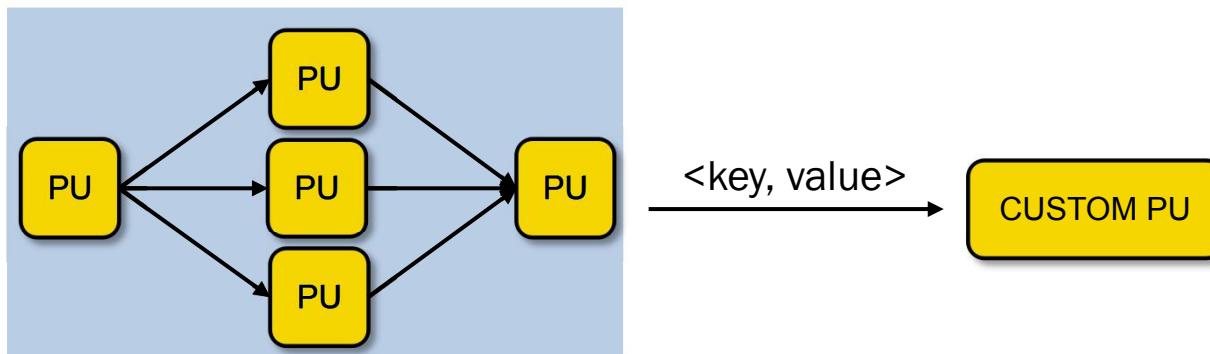
2.7 通用开放(3) – 计算开放

- 数据传递方式



- 计算逻辑

- 用户自定义custom pu逻辑



2.7 通用开放(4) - 自定义计算

●说明

- R2提供库文件，由用户引用
- 用户只用实现代码逻辑函数“proc”即可。（其余功能由系统完成）

●步骤

- step1 继承基类PuPB，实现proc函数

```
class PbApp:public r2::pu::PuPB
{
public:
    PbApp(){}
    ~PbApp(){}

    virtual int proc(const std::string & key, const std::string & value)
    {
        std::string key_out;
        std::string value_out;

        key_out=key+"_hello";
        value_out=value+"_world";
        send_pack("CLIENT", key_out, value_out);

        return 0;
    }

private:
};

```

- step2 make

```
[tashanji@PLT_Kdc_DE ~/R2_proj/trunk/app/per_test/L1PU]$ make
g++ -c -I ../../example/include/ -o l1_1.o l1_1.cpp
g++ -o l1_1 l1_1.o -L ../../example/lib/ -lappframe -lpthread
```

目录

1. 背景介绍
2. 架构介绍
 2. 1 架构总览
 2. 2 分布式计算
 2. 3 数据引擎
 2. 4 海量画像
 2. 5 实时ABTEST
 2. 6 立体监控
 2. 7 通用开放
3. 运营情况

3 运营情况(1) – 系统

- 海量
 - 日调用: 数十亿
 - 扩散量: 数百亿
- 实时
 - 90%以上请求在**20MS**之内
 - 所有请求处理延时**50ms**之内
- 稳定性
 - 系统稳定性**99. 95%**
 - 确保每个消息的可靠传递

3 运营情况(2) – 运营

- 典型业务



- 运营

- 场景：近200个
- 业务接入：2人

- 应用宝推荐效果

- 推荐分发占可控分发超过80%
- 为应用宝带来超过60%的收入提升

- 手游推荐

- Banner场景为业务带来530%的效果提升
- 每天带来的下载超过百万

欢迎加入腾讯QQ大数据团队