

# 用户洞察平台介绍

魅族 — 黄振贤

# 目录

## 1 总体介绍

- 1.1 用户洞察平台是什么？
- 1.2 核心需求
- 1.3 数据流视图
- 1.4 总体架构

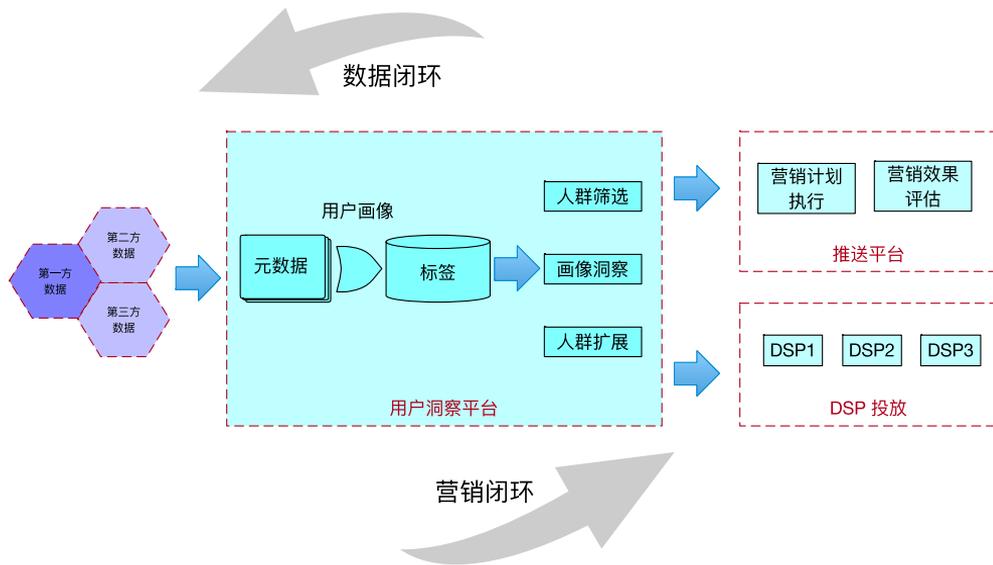
## 2 标签生成

## 3 标签存储

## 4 平台功能

# 1.1 用户洞察平台的定位

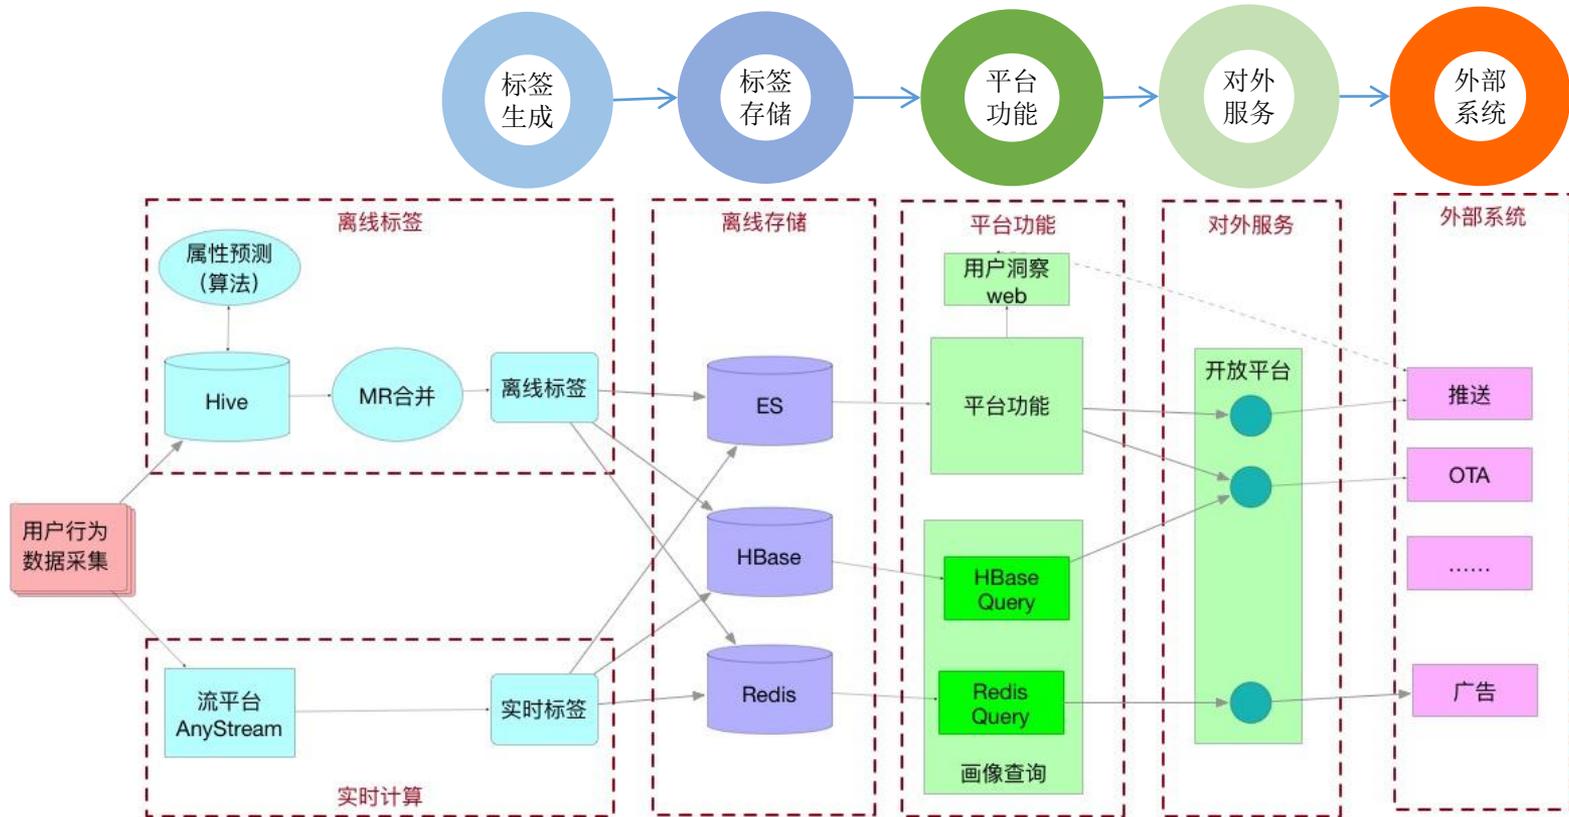
- 通过对三方受众数据的汇聚、清洗、智能运算，构建了庞大的精准人群数据中心，提供丰富的用户画像数据以及实时的场景识别力。
- 无缝对接各类业务平台的数据应用，如广告平台，PUSH推送，个性化推荐之间建立了数据通道，支持公司级的精准营销，消息及时送达服务等场
- 营销效果评估，反馈数据可进一步加工，用于提升画像标签质量



# 1.2 核心需求

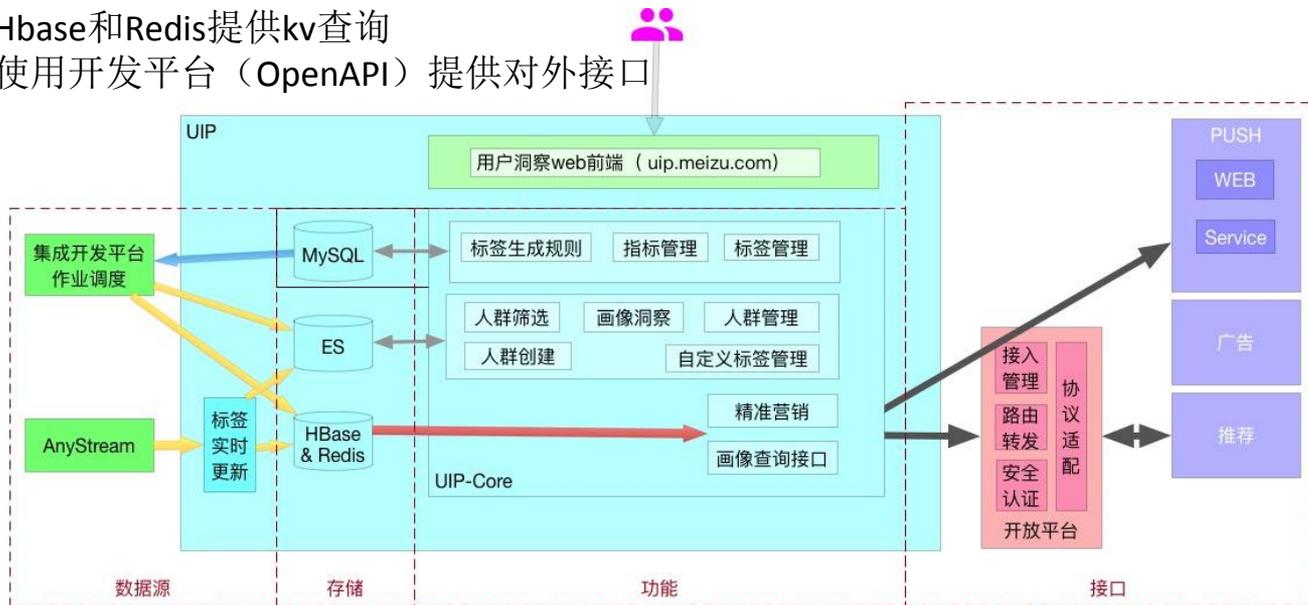


# 1.3 数据流视图



# 1.4 总体架构

- 集成开发平台之作业调度系统上，配置和运行离线计算任务（Hive&MR）
- 流平台(AnyStream)负责实时标签计算
- 管理模块生成的相关规则，存储在MySQL，供标签生成任务(Hive/MR/流平台)使用
- 用户画像（标签）宽表保存在ES上
- Hbase和Redis提供kv查询
- 使用开发平台（OpenAPI）提供对外接口



# 目录

## 1 总体介绍

## 2 标签生成

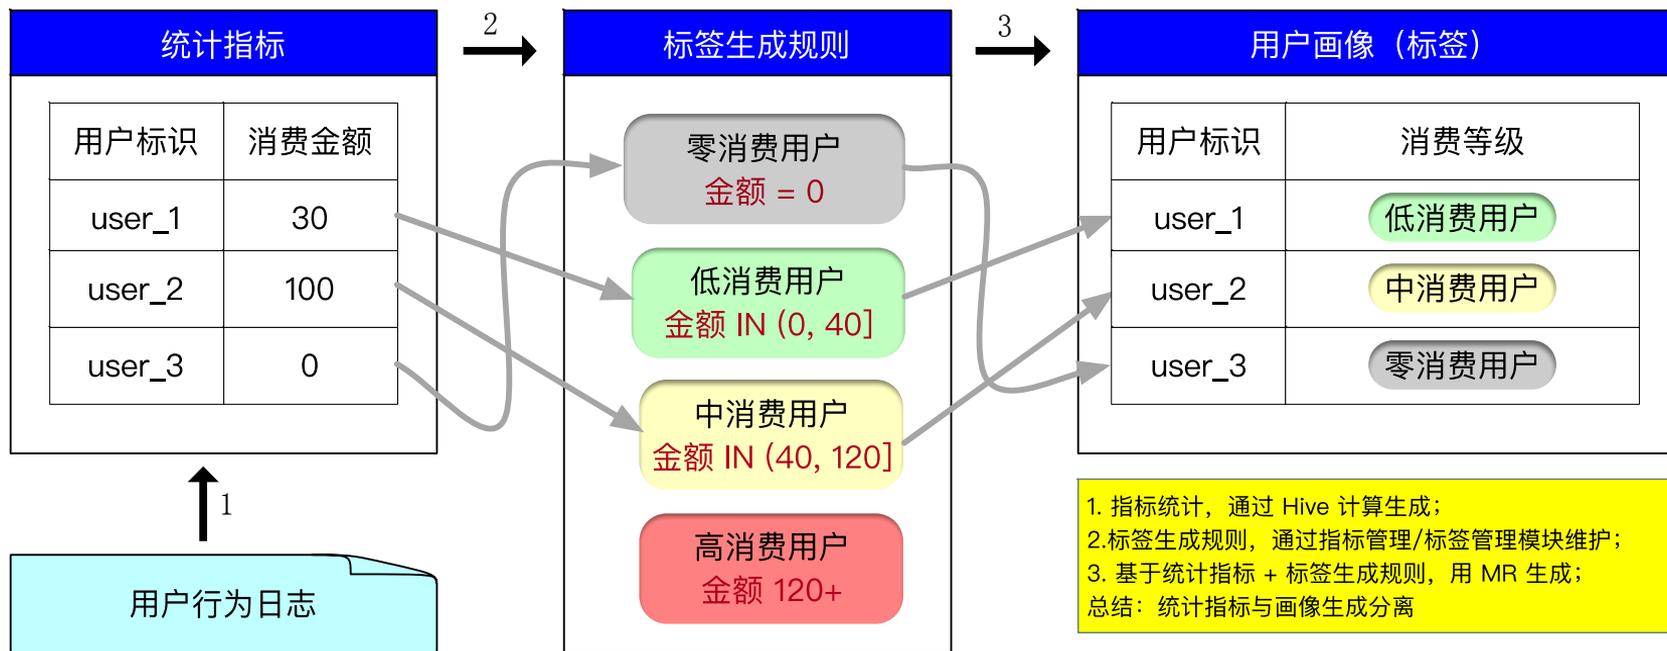
- 2.1 统计类标签
- 2.2 算法类标签
- 2.3 单值标签 & 多值标签
- 2.4 标签生成的过程
- 2.5 实时标签

## 3 标签存储

## 4 平台功能

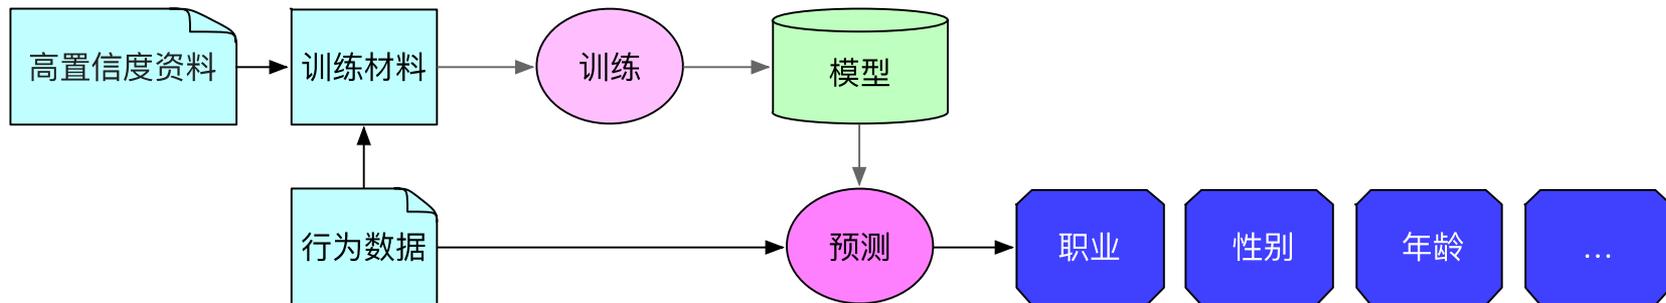
## 2.1 统计类标签

计算模式 行为日志 → 统计指标 → 生成标签



## 2.2 算法类标签计算

- 模型训练：选取高置信度资料（如用户注册信息）+用户行为数据作输入进行模型训练
- 属性预测：使用训练好的模型进行预测



## 2.3 单值标签与多值标签

### 单值标签

|      |                                     |                                    |                          |
|------|-------------------------------------|------------------------------------|--------------------------|
| 性别   | <input type="radio"/> 男             | <input checked="" type="radio"/> 女 | <input type="radio"/> 未知 |
| 婚姻状态 | <input checked="" type="radio"/> 未婚 | <input type="radio"/> 已婚           | <input type="radio"/> 未知 |
| 有子女  | <input type="radio"/> 是             | <input checked="" type="radio"/> 否 | <input type="radio"/> 未知 |

### 多值标签

|      |   |  |  |
|------|---|--|--|
| 内容偏好 | <input type="checkbox"/> 影视             | <input checked="" type="checkbox"/> 新闻 | <input type="checkbox"/> 旅行            |
|      | <input checked="" type="checkbox"/> 社交  | <input type="checkbox"/> 购物            | <input checked="" type="checkbox"/> 音乐 |
| 支付偏好 | <input checked="" type="checkbox"/> 支付宝 | <input checked="" type="checkbox"/> 微信 | <input type="checkbox"/> 银联            |
|      | <input type="checkbox"/> 神州付            |  |  |

#### □ 单值标签：

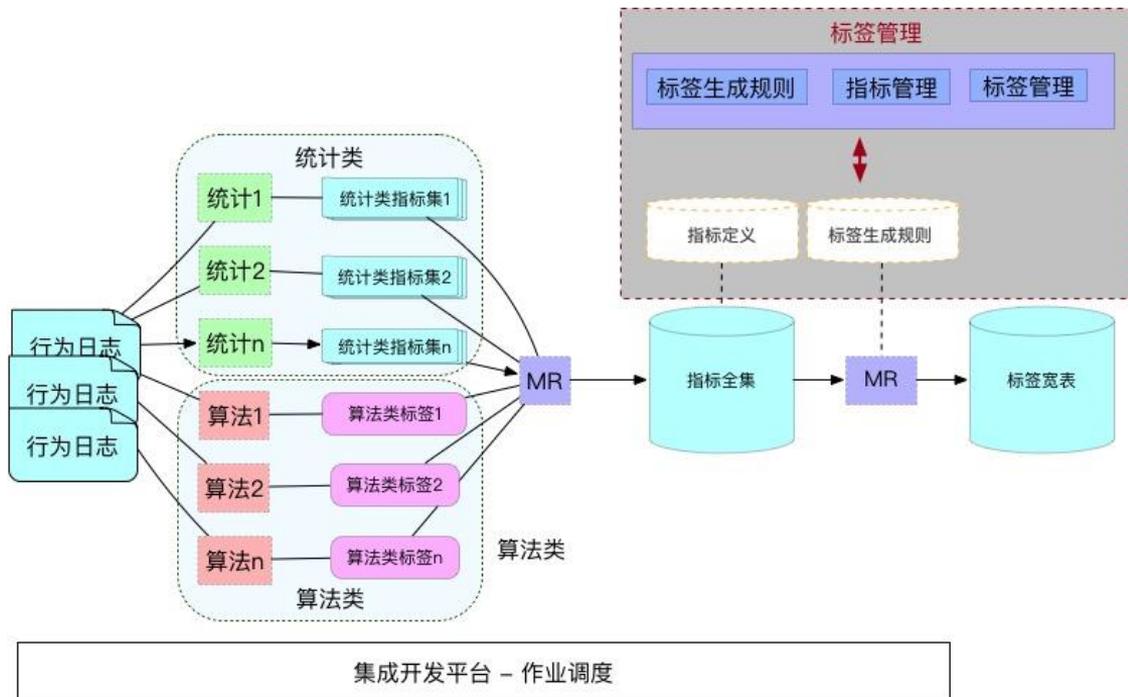
用户在该标签下只能取一个值，不能多选。

#### □ 多值标签：

用户可以取该标签下的多个取值组合。比如用户可以有多个兴趣爱好。

多值标签的存在，会影响存储查询引擎的选型和存储结构设计

## 2.4 标签生成过程



### ■ 优点:

- 1、配置化管理，提供 Web UI 管理标签的生命周期
- 2、基于配置生成标签，标签宽表数据与元数据100%一致


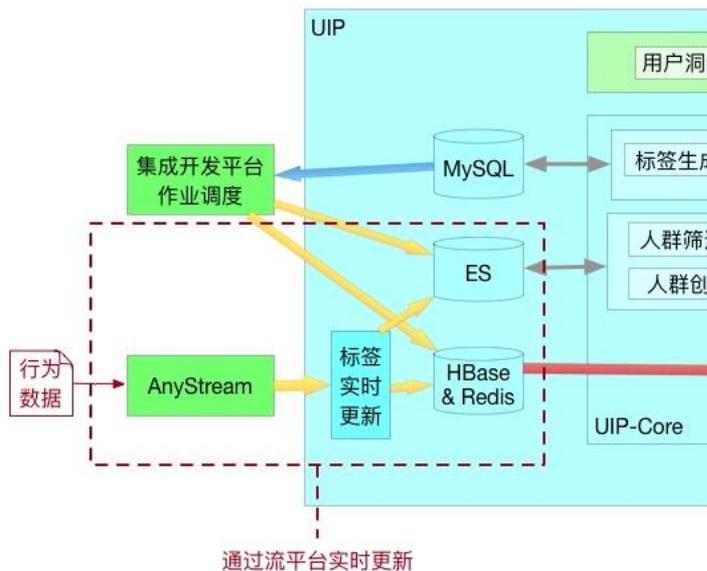
### ■ 尚存不足

目前配置化管理只涵盖到最终的标签宽表生成。与上游的指标统计和算法预有脱节。

- 1、上游计算过程是单独开发，指标定义只是另外配置的数据描述（可能存在不一致）
- 2、一些标签下线（废除）后，相应的上游任务的依赖需要另外废除，否则会遗留无用的作业浪费计算资源

## 2.5 实时标签

- 实时位置标签，实时分析用户所处的场景（图例）
- 其它实时标签：搜索、支付等



# 目录

1 总体介绍

2 标签生成

3 标签存储

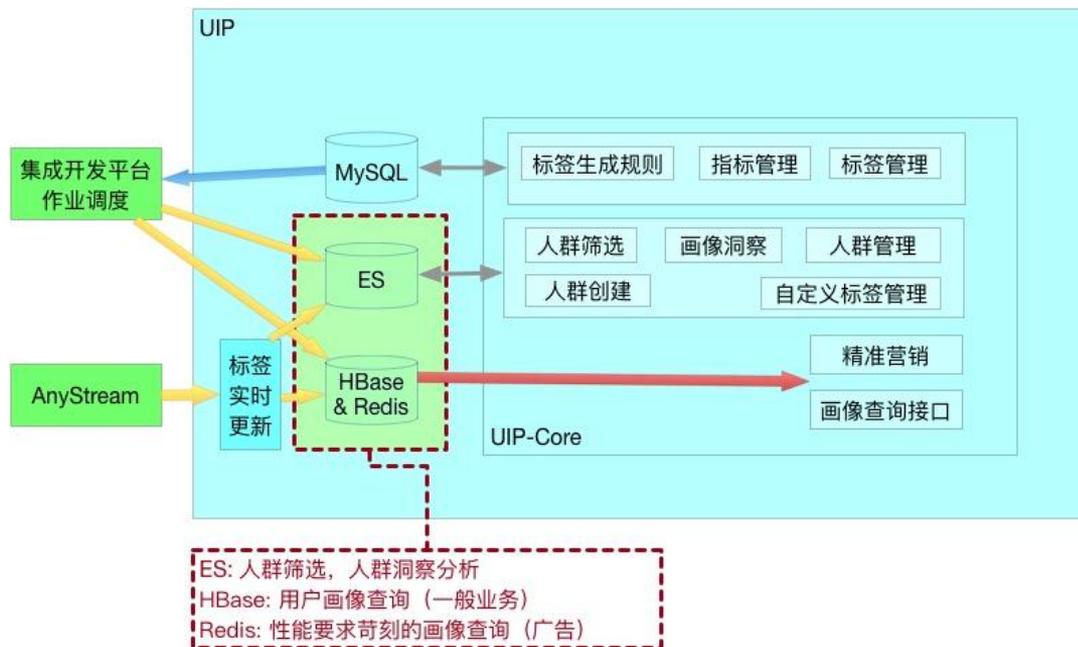
3.1 标签存储概览

3.2 ElasticSearch

3.3 HBase & Redis

4 平台功能

# 3.1 标签存储总览



- ElasticSearch (ES) 是一个基于Lucene构建的开源、分布式、RESTful搜索引擎。能够达到实时搜索，稳定，可靠，快速。
- 基于 ES 实现对全量用户任意标签进行在线筛选和聚合分析，秒及响应。
- Hbase 提供大吞吐量的 key/value 查询
- 性能要求更为苛刻的 key/value 查询 (广告平台) 通过使用 Redis 来实现

# 3.2 Why Elasticsearch (ES)

## 历史

Vertica 社区版有 3 个节点和 1T 存储容量限制

随着数据规模和调用数暴增，性能出现瓶颈

对于多值标签，只能采用csv方式保存在varchar字段，性能低下

多值标签检索使用字符串 LIKE 操作；聚合虽能通过一些 trick 来支持，但性能太差。

## 现状

# ES

能够达到实时搜索，稳定，可靠，快速。

在线更新（实时/准实时更新）

水平扩展能力强

array type完美支持多值标签存储和分析场景

## 3.3 HBase 与 Redis

### Hbase

- 提供低成本，高吞吐量的 kv 查询
- 满足一般业务的查询
- 缺点是查询响应时间不太理想（针对广告业务而言）

### Redis

- 广告业务提出 50ms 内的查询延迟，这种苛刻要求需用 Redis 实现。
- Redis 存储目前只服务于广告平台的查询调用。

- 考虑成本因素，主要使用 Hbase 来提供 KV 查询
- 部分要求苛刻的业务，使用 Redis 作为补充

# 目录

1 总体介绍

2 标签生成

3 标签存储

4 平台功能

4.1 主要功能列表

4.2 画像洞察

4.3 受众分发

# 4.1主要功能列表

## 人群管理

可通过两种方式创建：1、指定标签条件；2、导入imei列表

对人群进行修改、删除等操作

## 人群筛选

指定标签条件选项，查询满足条件的用户数

## 画像洞察

Step 1. 指定标签条件选项选出用户群体

Step 2. 指定要分析的标签，通过聚合运算，分析用户特征。

## 受众分发

采取一定的技术手段，把指定人群推至下游的营销渠道（广告平台、推送平台、OTA等）

## 画像查询

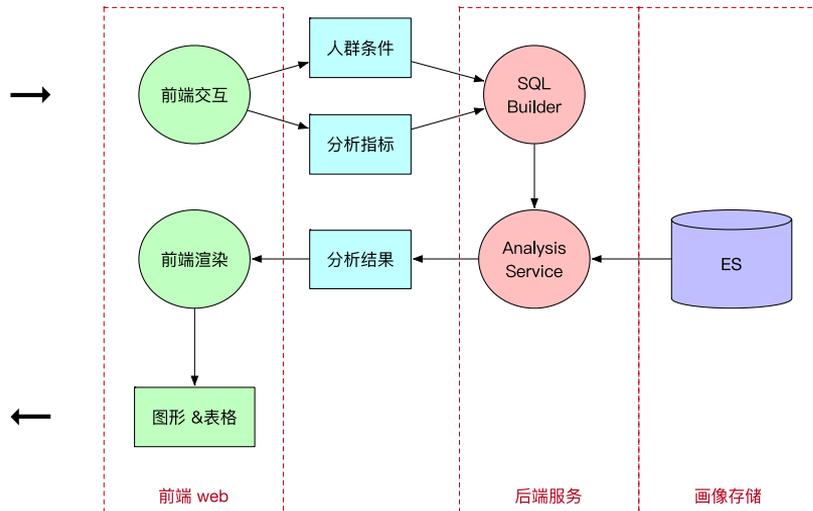
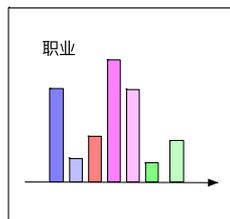

对下游系统提供查询接口，调用方指定用户标识（imei）查询该用户的画像标签

# 画像洞察

Step 1. 指定标签条件选项选出用户群体

Step 2. 指定要分析的标签，通过聚合运算，分析用户特征。

|      |                                      |
|------|--------------------------------------|
| 人群条件 | ( 性别: 女 or 父母: 是 ) and 常驻城市: 广州市,珠海市 |
| 分析指标 | 车主 职业                                |



# 受众分发

交互过程：

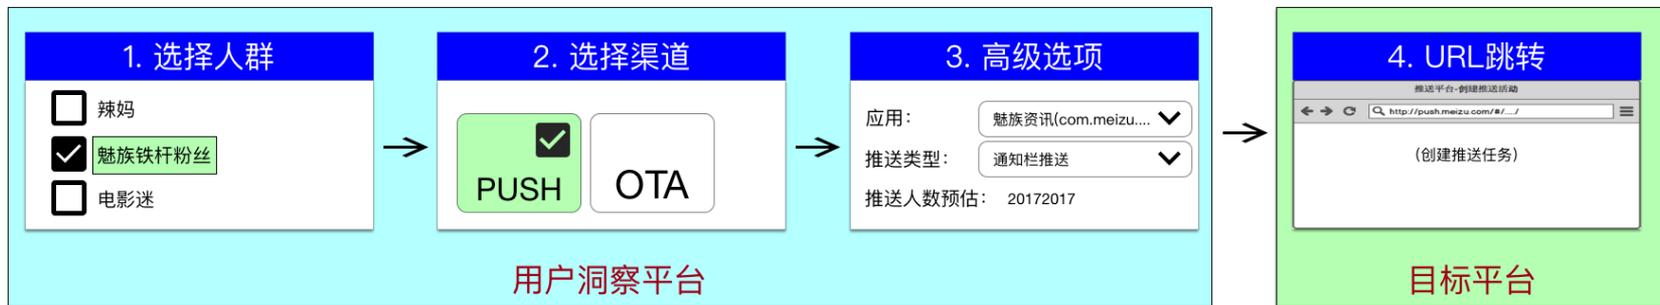
1. 选择人群 → 2. 选择分发渠道 → 3. 高级选项 → 4. 平台跳转

无缝对接

3. 高级选项因所选渠道而异，由服务器端动态生成，前端动态渲染。

3. 根据当前用户在目标平台拥有的权限来确定选项列表。

4. 跳转 URL 由目标平台动态生成，降低平台间的耦合，同时利于实现“无缝”对接



# Q&A

Thanks