

郑重（卢梭），阿里云技术专家

21天搭建推荐系统

目录

content

阿里云推荐引擎介绍

第一阶段：基本功能

Day1. 环境准备

Day2-3. 数据准备

Day4-5. 基本配置和离线计算

Day6-8. 推荐API集成

第二阶段：高级功能

Day9-11. 效果报表

Day12-15. 优化

Day16-20. 实时修正

Day21. 监控和告警

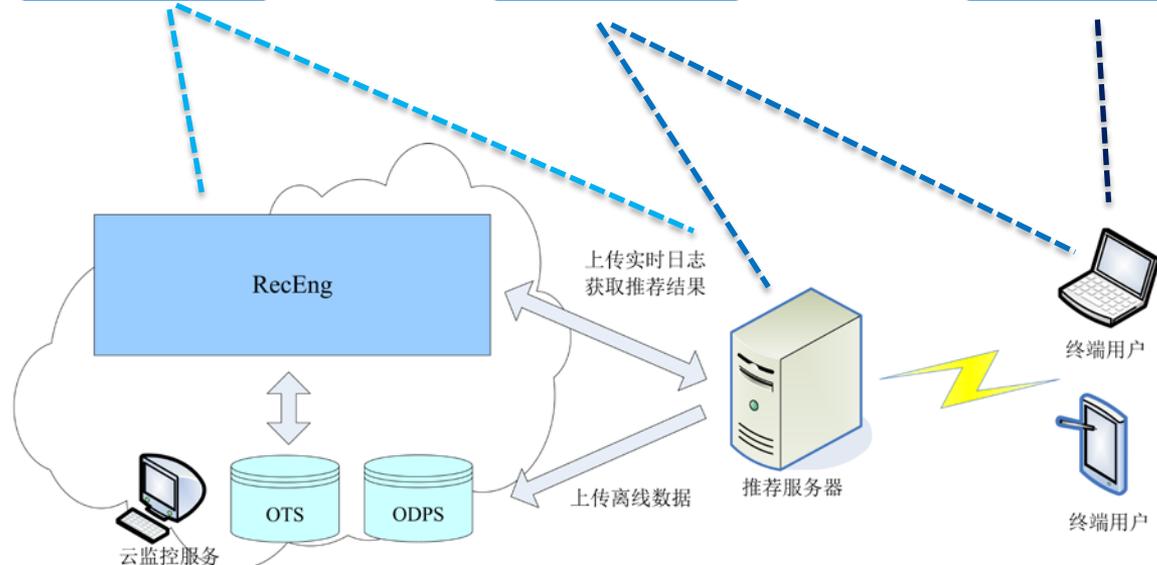
Future Work

Conclusion

阿里云推荐引擎介绍



推荐系统一般包括展现子系统、日志子系统和算法子系统三个部分



阿里云推荐引擎 (RecEng) 是推荐系统的一部分，主要实现的是算法子系统，需要和其他子系统配合工作

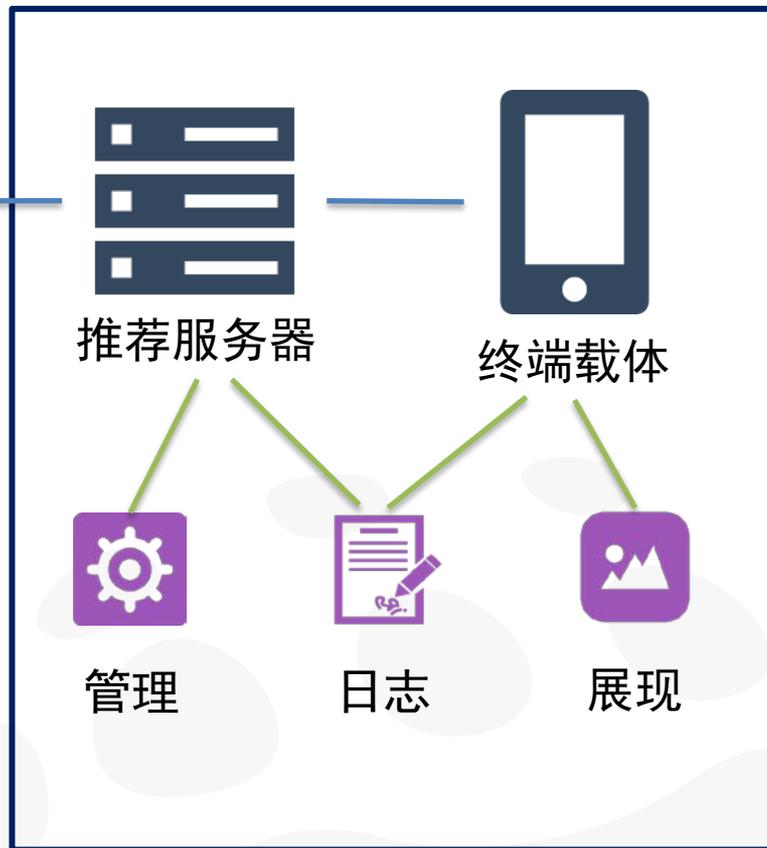
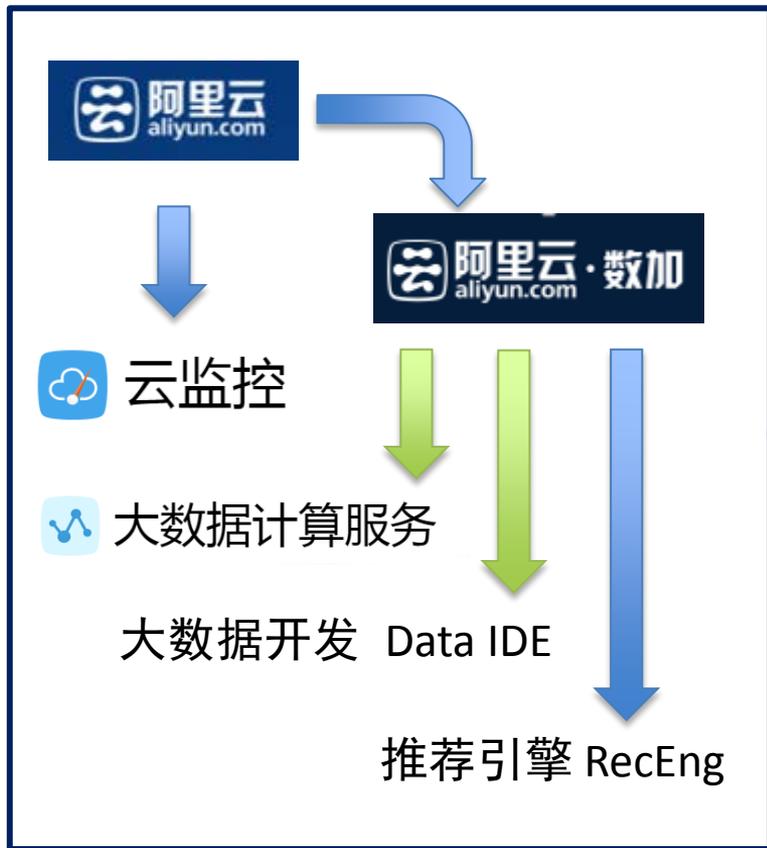
<http://data.aliyun.com/product/re>

目录

content

第一阶段：基本功能

Day1. 环境准备



Day2-3. 数据准备

格式规范

行为表 (user_behavior)

字段描述

| 列名 | 数据类型 | 注释 |
|----------|--------|--|
| user_id | string | 用户ID |
| item_id | string | 物品ID |
| bhv_type | string | 行为类型： view：物品曝光 click：用户点击物品 collect：用户收藏了某个物品 uncollect：用户取消收藏某个物品 search_click：用户点击搜索结果中的物品 comment：用户对物品的评论 share：分享 |

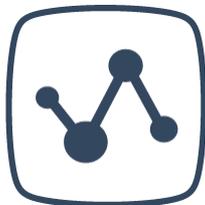


Day2-3. 数据准备

数据上传



推荐服务器



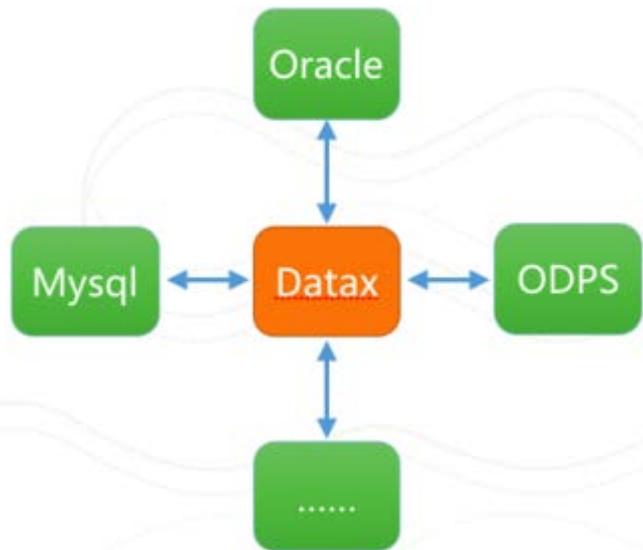
大数据计算服务

利用Tunnel命令上传

1. 集成在ODPS console中
2. `tunnel upload log.txt test_project.test_table/p1="b1"`

定制DataX上传

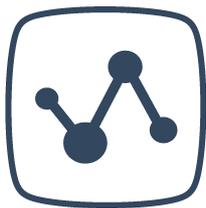
1. 下载DataX
2. 配置DataX的配置文件
3. `python datax.py ./mysql2odps.json`



Day2-3. 数据准备

格式转换

大数据开发 Data IDE



大数据计算服务

The screenshot displays the Data IDE interface for a task named 'testtask1'. The main workspace shows a workflow diagram with the following nodes:

- 数据同步 (Data Sync) - 数据同步
- 预处理_1 (Preprocessing_1) - ODPS SQL
- etl成用户表 (ETL User Table) - ODPS SQL
- etl成物品表 (ETL Item Table) - ODPS SQL
- etl行为表 (ETL Behavior Table) - ODPS SQL

The right-hand panel contains configuration options:

- 基本属性** (Basic Attributes):
 - 任务名称: testtask1
 - 责任人: basedemo002
 - 类型: 工作流任务
 - 描述: 请输入节点描述
- 调度属性** (Scheduling Attributes):
 - 调度状态: 暂停
 - 生效日期: 1970-01-01 至 2115-04-22
 - 调度周期: 天
 - 具体时间: 01 时 30 分
- 依赖属性** (Dependencies):
 - 依赖属性
 - 跨周期依赖

```
> insert overwrite table user_meta  
> partition(ds='20160427')  
> select uid, tag;
```

Day4-5. 基本配置和离线计算



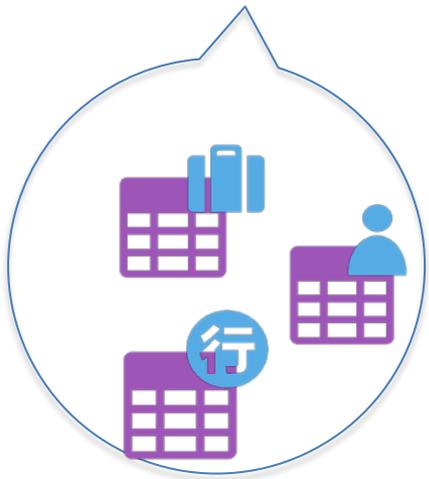
业务



场景



算法流程



首页



详情页

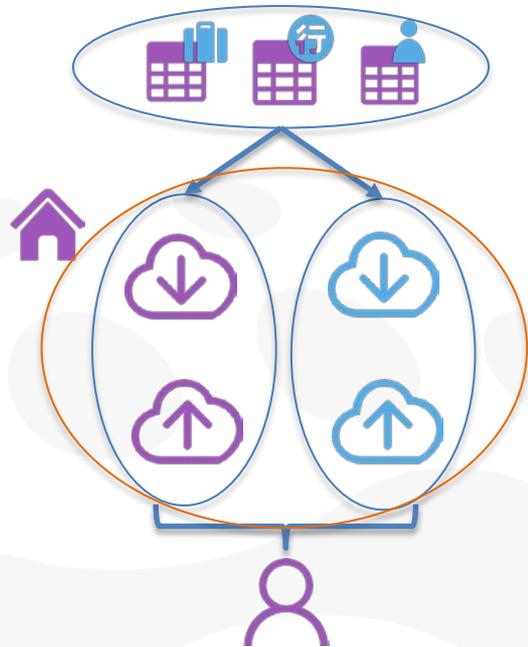


搜索



O2O

.....



手淘首页



必抢、清单会场首图个性化

人群会场首图个性化

类目会场首图个性化

Day4-5. 基本配置和离线计算

配置业务基本信息 业务Code (即biz_code) 唯一标示业务的配置信息

业务名称*

业务Code*

配置场景和算法 自动配置场景和算法 系统自动为当前业务添加首页推荐和相关推荐两个场景,并为每个场景配置一个默认的推荐算法流程。您可以在场景管理中进行更改。

配置业务依赖云资源 本产品依赖您开通的大数据计算服务(Max Compute,原名ODPS)和表格存储(Table Store)资源,您可以在**资源管理**中进行添加和管理

大数据计算资源*

表格存储资源*

配置业务数据表 使用本产品日志API接收日志

用户表* 描述用户元信息的数据表

用户属性维度表 定义用户表中各元信息数据的类型

物品表* 描述物品元信息的数据表

物品属性维度表 定义物品表中各元信息数据的类型

行为表* 描述用户对物品的行为(包括搜索、点击、浏览、收藏等)信息的数据表

可推荐物品表 可被推荐给用户的物品信息数据表,通常是物品表的子集

新建推荐场景

[返回我的推荐](#)

1 配置推荐场景

2 配置API参数

3 配置推荐算法流程

推荐所需的数据来自于业务,业务定义了算法所能使用的数据范围。 [了解更多](#)

推荐场景code*

推荐场景名称*

所属业务* lusuo_biz1 lusuo_test

上一步

下一步

新建推荐场景

[返回我的推荐](#)

1 配置推荐场景

2 配置API参数

3 配置推荐算法流程

配置“获取推荐结果API”所需要的输入参数。

场景指的是推荐的上下文,即场景由推荐时可用的参数决定,在推荐引擎中体现为“在线获取推荐结果API”的输入参数。

有两种场景最为常见,分别是首页推荐场景和详情页推荐场景。在执行首页推荐时,可用的参数只有用户信息;而在执行详情页推荐时,可用的参数除了用户信息,还包括当前详情页上所展示的物品信息。

您完全可以根据自己的需求建立全新的场景,比如针对搜索关键词的推荐场景,这时可用的参数除了用户信息,还有用户所输入的关键词。

设置OTS预留读写量:

请选择推荐API所用的参数:

- biz_code 表示业务code
- scn_code 表示场景code
- user_id 表示用户的id
- item_id 表示物品的id

上一步

下一步

Day4-5. 基本配置和离线计算

1 配置推荐场景

2 配置API参数

3 配置推荐算法流程

推荐算法流程指数据端到端的处理流程，即从客户的原始输入数据开始（如用户数据、物品数据、行为数据等），一直到产出能够被客户产品在线获取的推荐结果为止。

算法流程由离线流程和在线流程两部分组成，分别完成离线计算和在线推荐。 [了解更多](#)

+新建算法流程

开发测试环境

线上生产环境

发布

| 算法流程code | 离线流程 | 在线流程 | 操作 |
|-----------|--------------------|--------------------|--|
| test_path | 修改 | 修改 | 删除 回滚 在线流程调试 |

添加算法流程

✕

上一步

完成

算法流程代码*

test_path



离线计算模版

main ofl

默认首页推荐离线计算
流程

在线计算模版

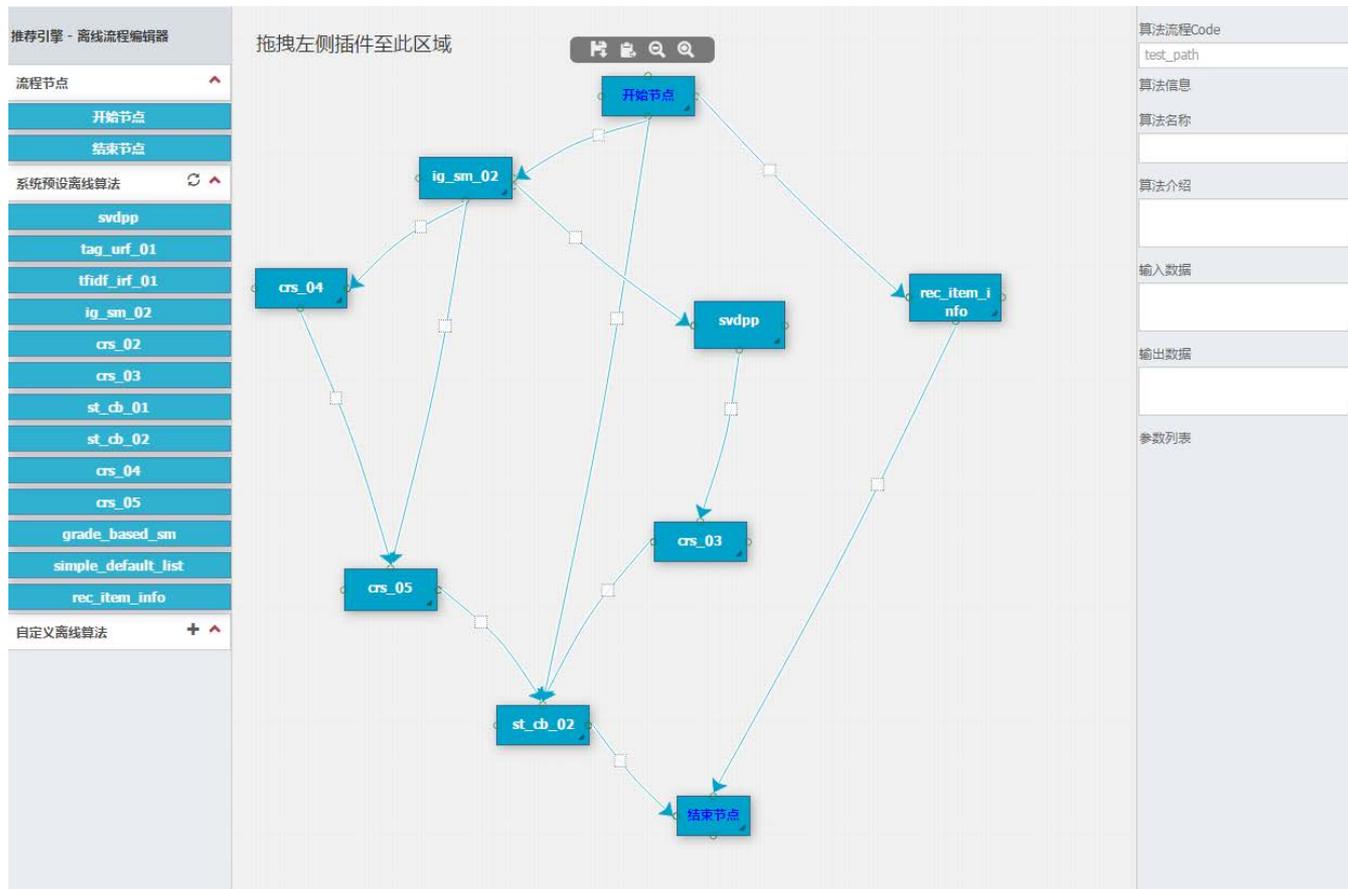
detail ol

默认详情页推荐在线计
算流程

关闭

提交

Day4-5. 基本配置和离线计算



Day4-5. 基本配置和离线计算

推荐引擎 - 在线流程编辑器

流程节点

开始节点 结束节点

选择离线数据

RD_UBRC RD_IBRC
 RD_UF RD_IF
 RD_DFLT RD_MODEL

系统预设在线算法

get_topn
mock_input
get itm_based_rec
get_usr_based_rec
mg_usr_itm_reclist
uniq_reclist
get_default_rec
get_rec_item_info

自定义在线算法 +

拖拽左侧插件至此区域

```
graph TD; Start[开始节点] --> mg_usr_itm_reclist[mg_usr_itm_reclist]; mg_usr_itm_reclist --> uniq_reclist[uniq_reclist]; uniq_reclist --> get_topn[get_topn]; get_topn --> End[结束节点];
```

算法流程Code

test_path

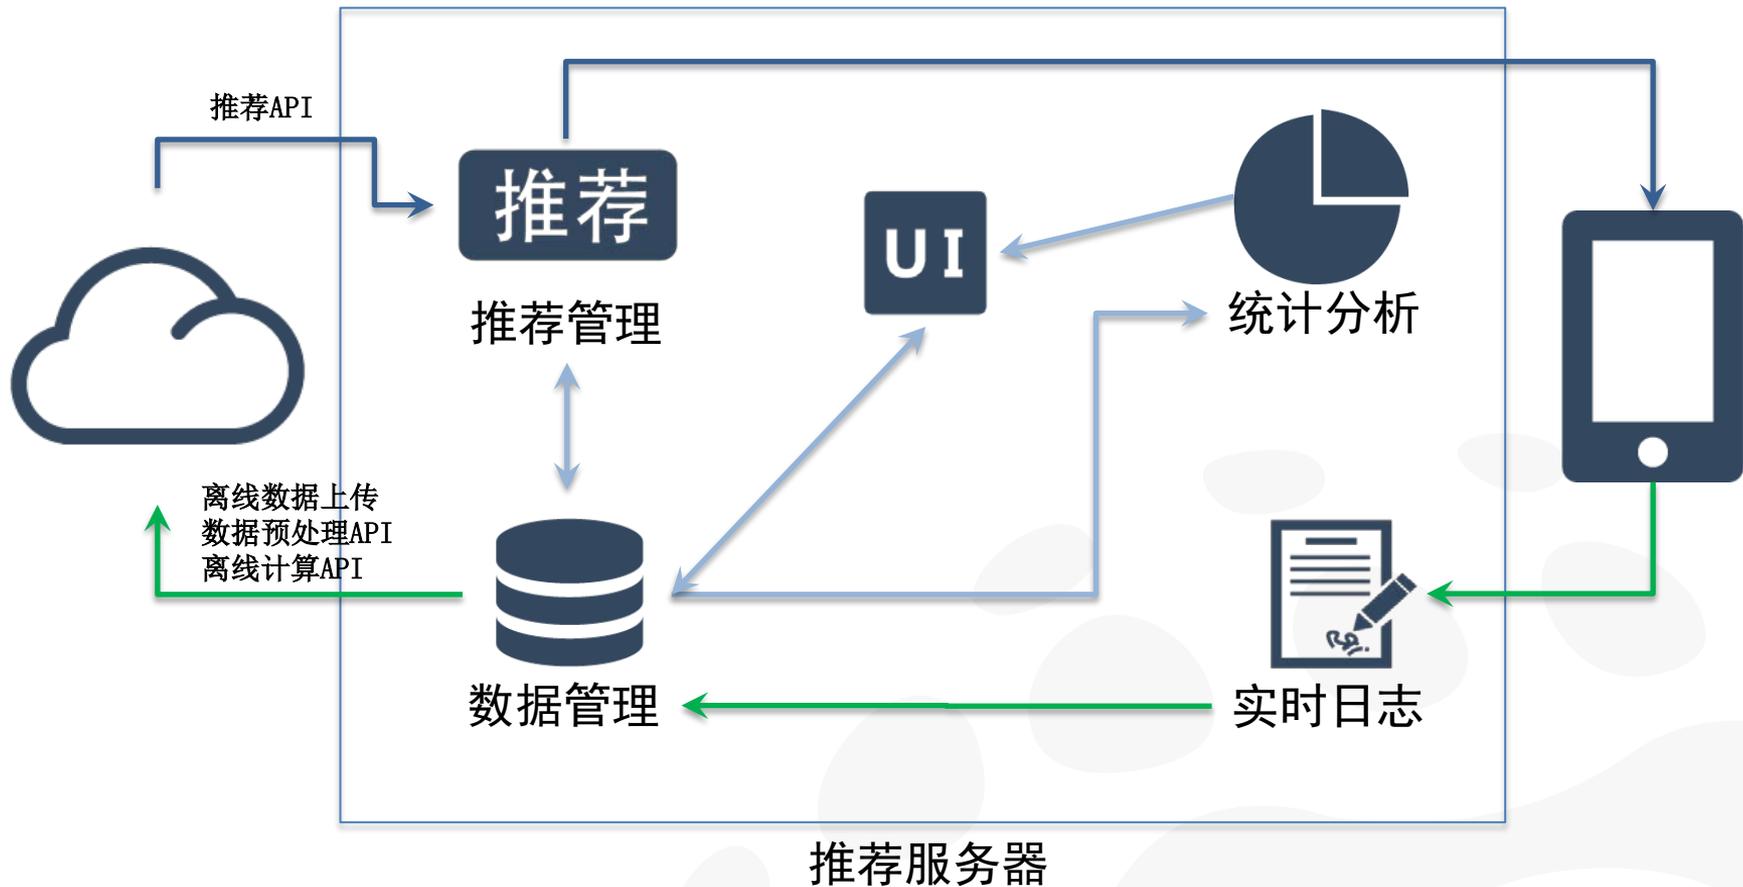
算法信息

算法名称

算法介绍

参数列表

Day6-8. 推荐API集成



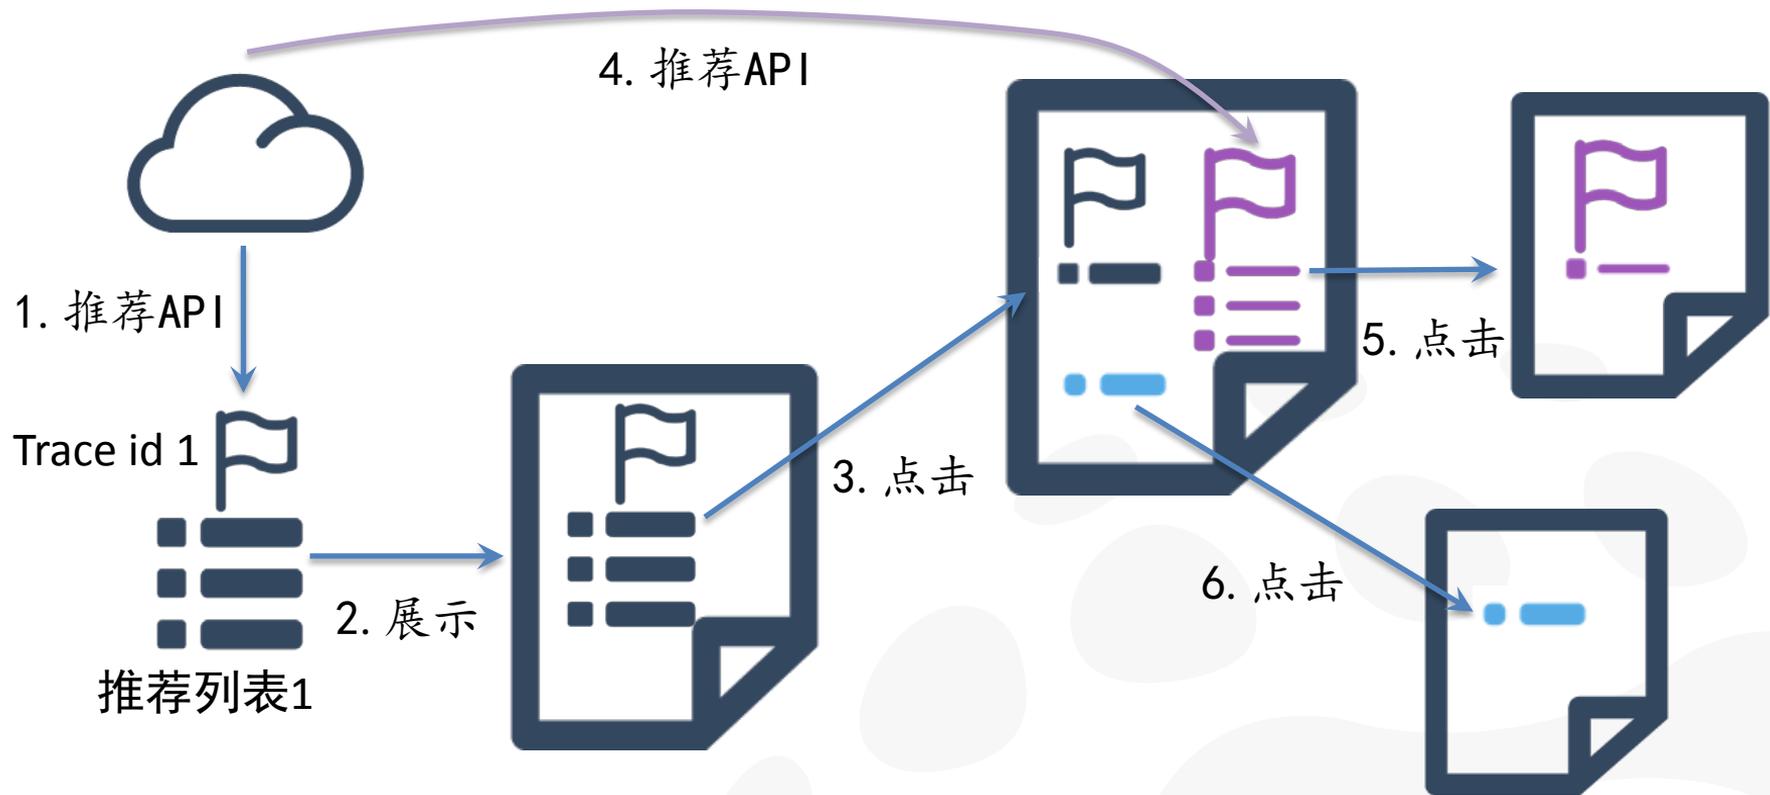
目录

content

第二阶段：高级功能

Day9-11. 效果报表

Trace ID的生命周期



Day9-11. 效果报表

效果计算



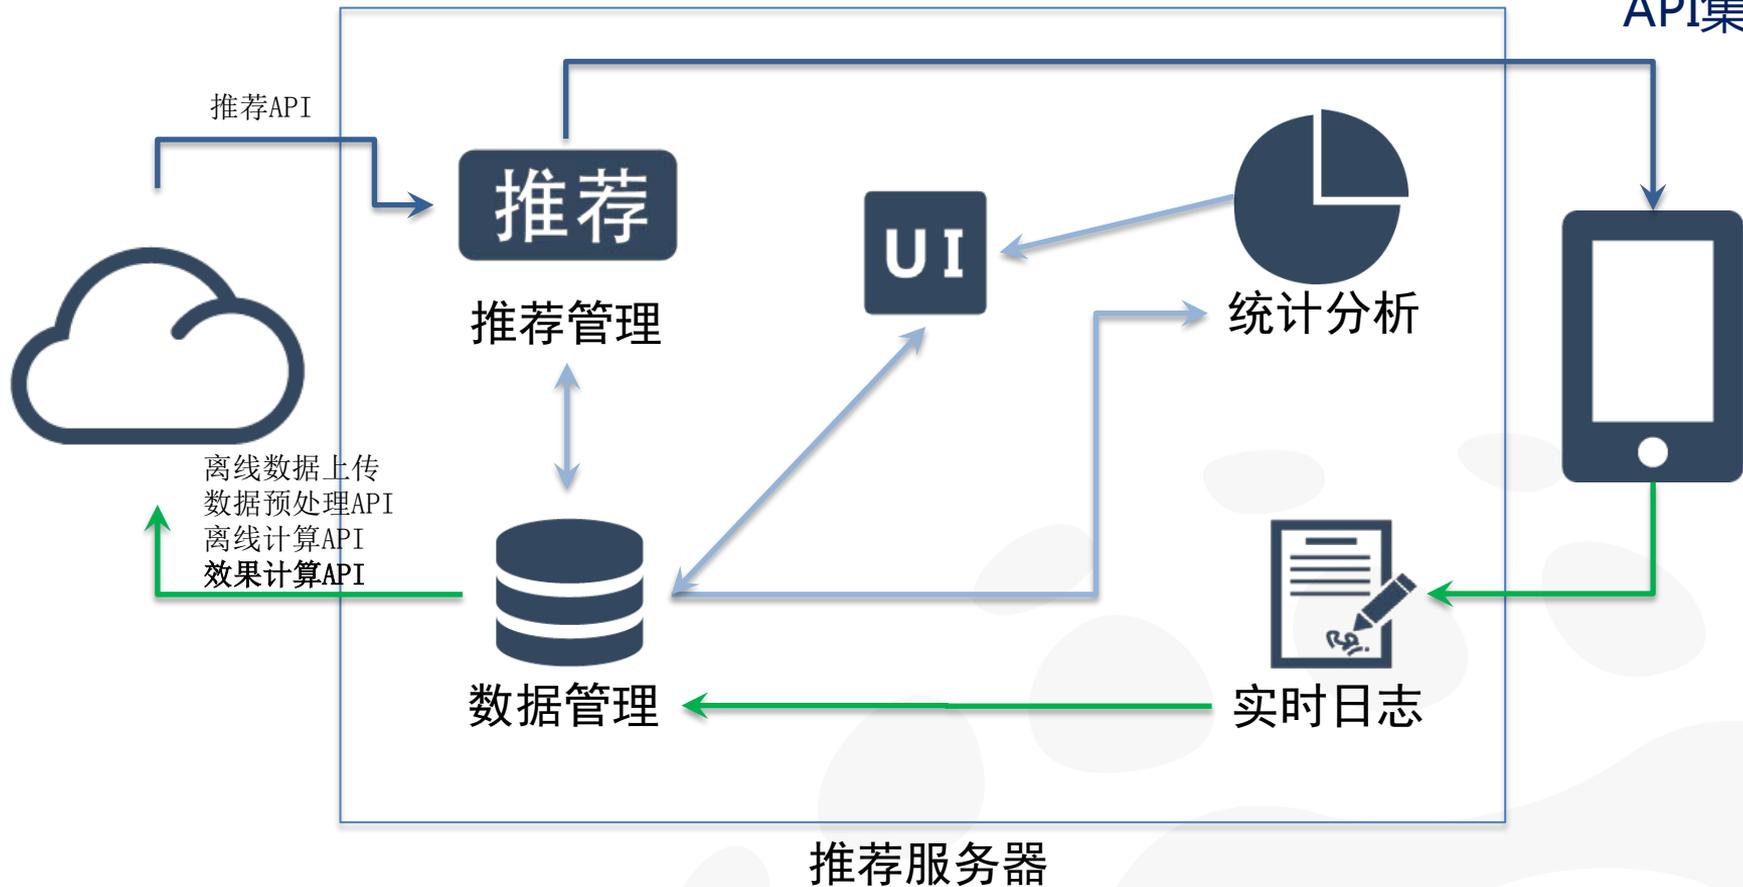
效果算法：以行为类型为参数，根据行为数据计算指标的算法

效果指标：明确行为类型、时间跨度、统计口径的效果算法实例。选择效果指标后即生成计算任务

效果报表：根据算好的效果指标，配置显示图表后的可视化展示

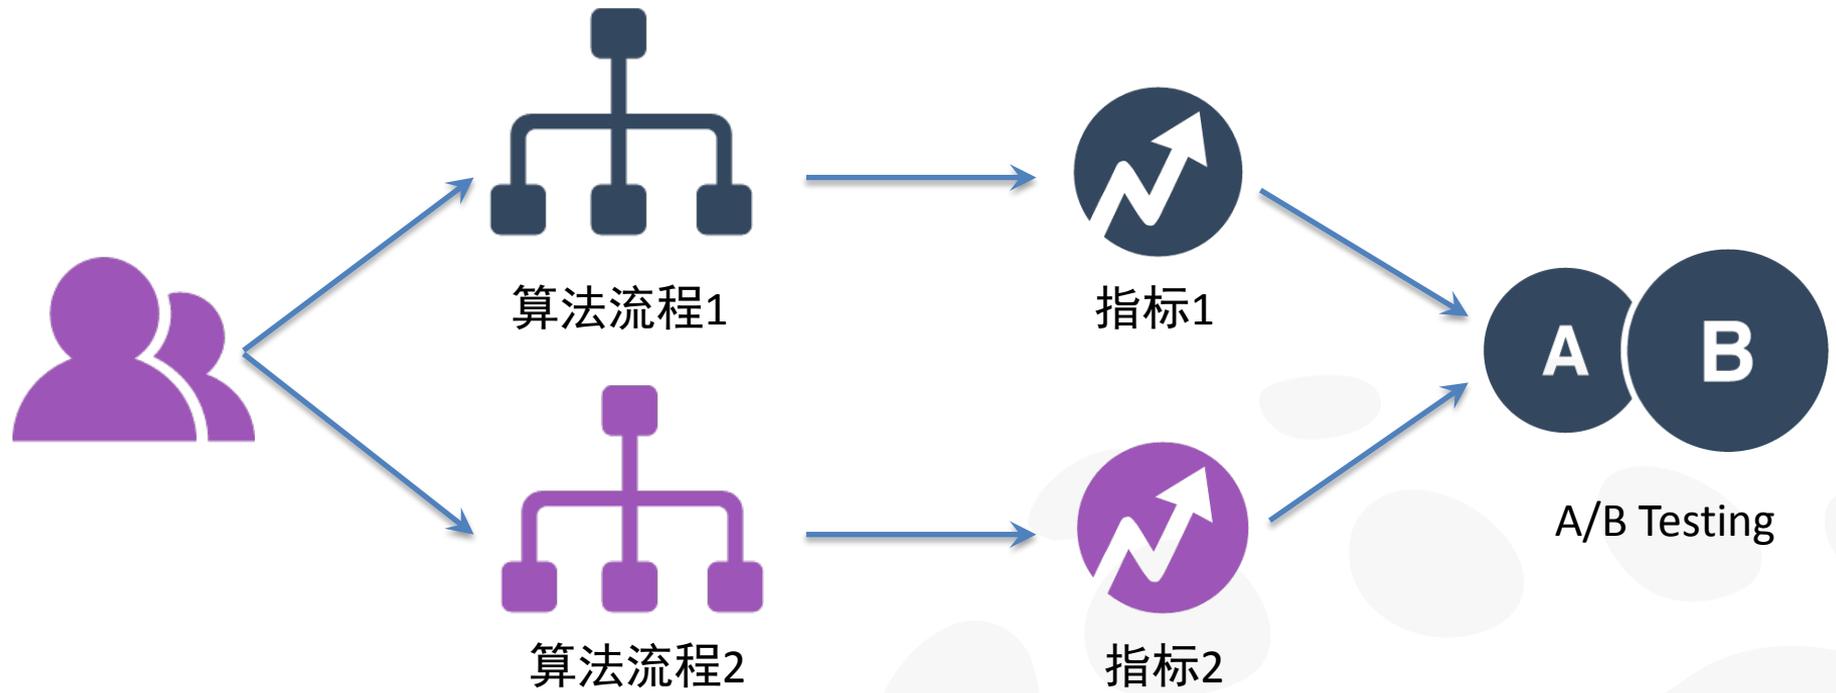
Day9-11. 效果报表

API集成

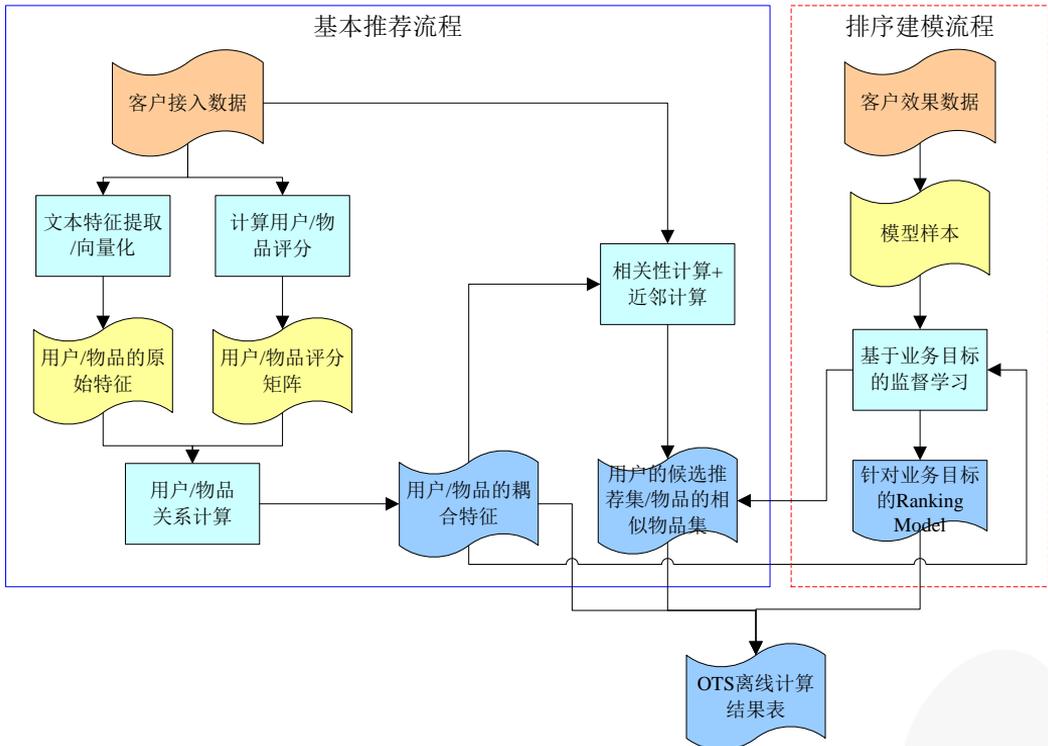


Day12-15. 优化

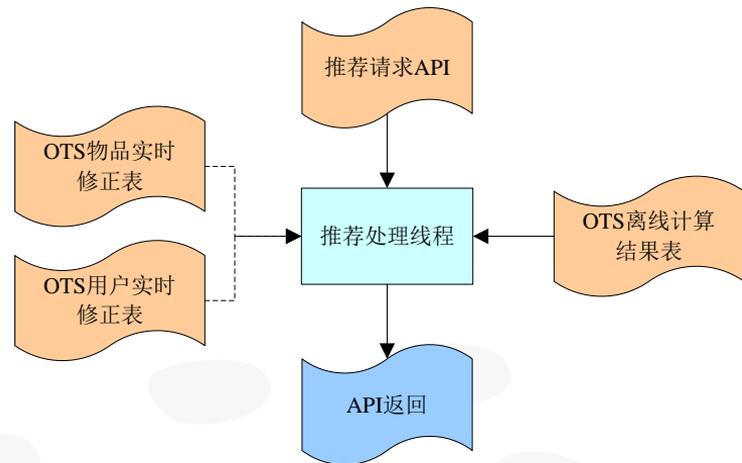
A/B Testing



Day12-15. 优化 算法流程



离线算法流程



在线算法流程

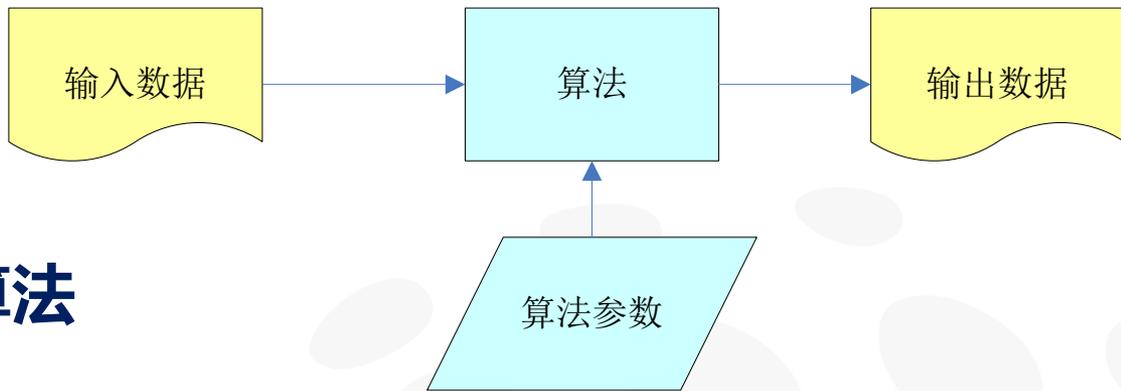
Day12-15. 优化

自定义算法

1

自定义离线算法

算法开发
单元测试
算法注册
流程测试



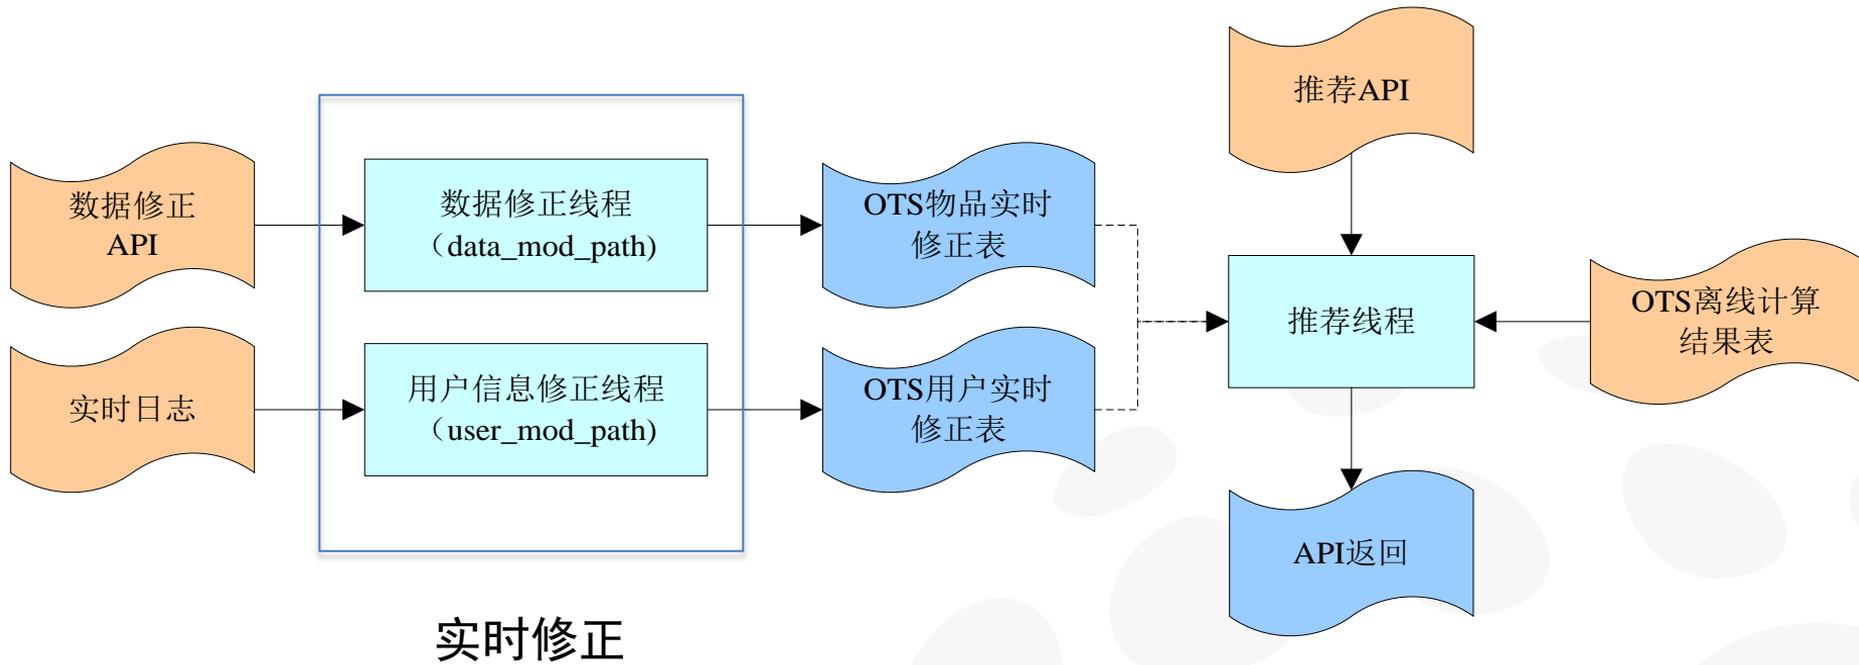
2

自定义在线算法

算法开发
单元测试
算法注册
流程测试

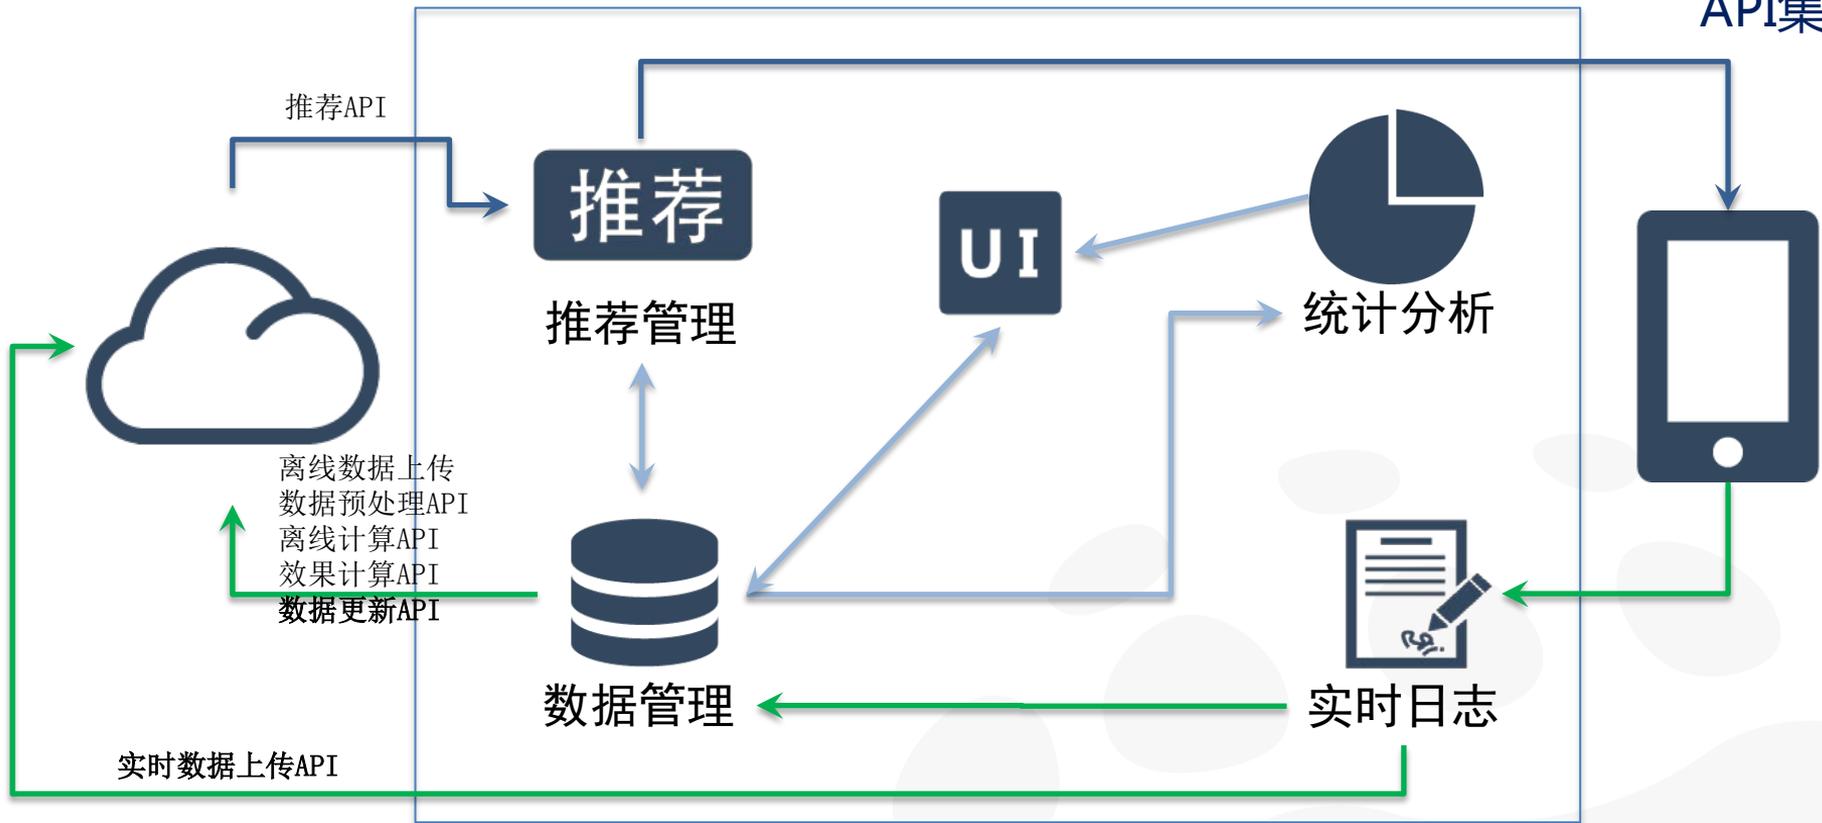
Day16-20. 实时修正

整体流程



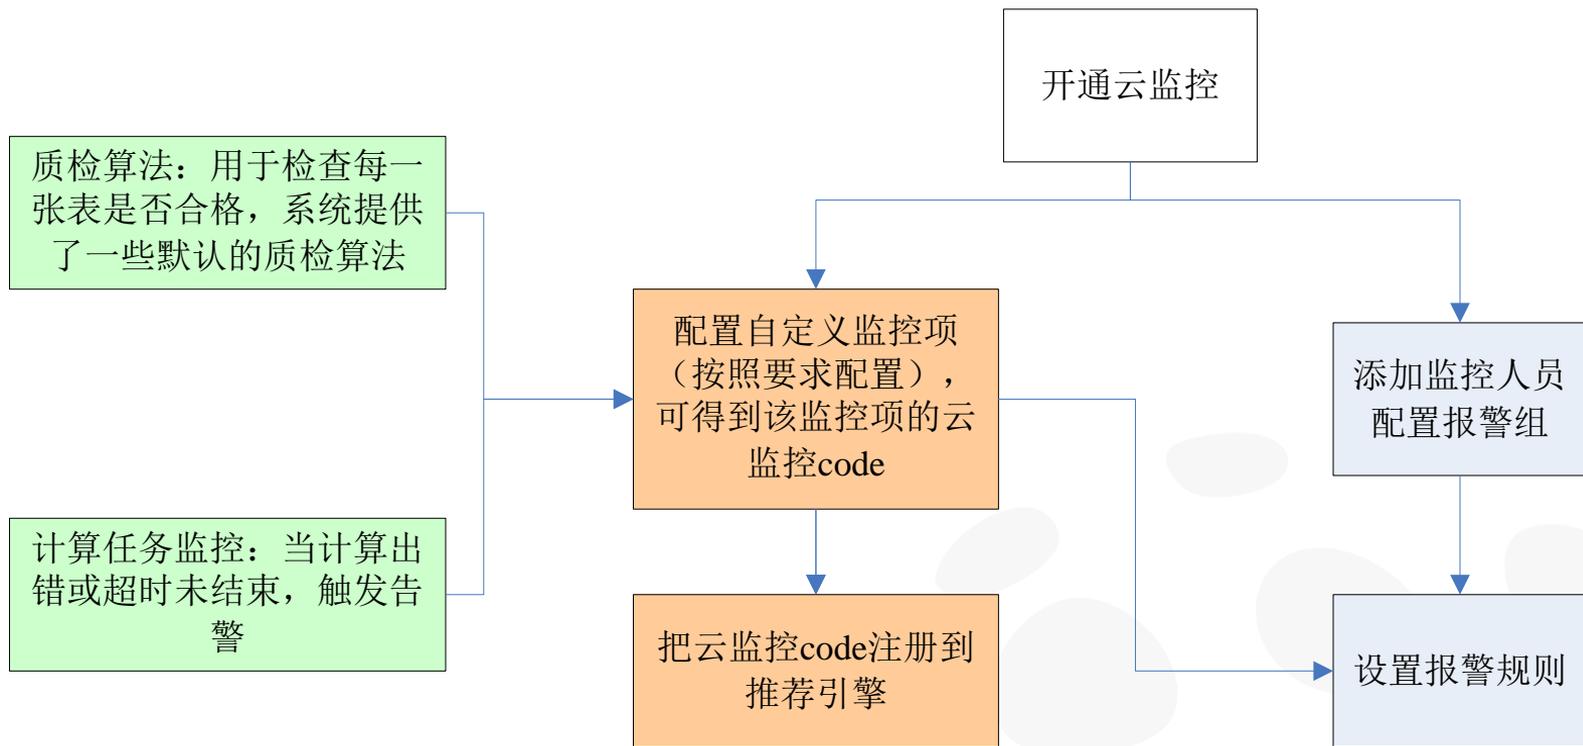
Day16-20. 实时修正

API集成



推荐服务器

Day21. 监控和告警



Future Work

简化基于规则的推荐

更好的集成业务和运营积累的知识

提供更多的算法

实现更多的推荐算法
针对行业的算法模板

推荐算法大赛

计划在下半年启动，敬请关注！

Conclusion

目标：让客户专注于推荐业务，不再被系统问题困扰

方法：通用的推荐引擎，集中实现与业务无关的内容

效果：推荐是个系统工程，算法很重要，但不是全部

关注我们

个性化推荐
钉钉交流群



该钉钉群二维码将在2017-06-13失效

关注云栖社区
微信公众号

