


知乎大数据平台架构实践

王雨舟

知乎数据平台负责人

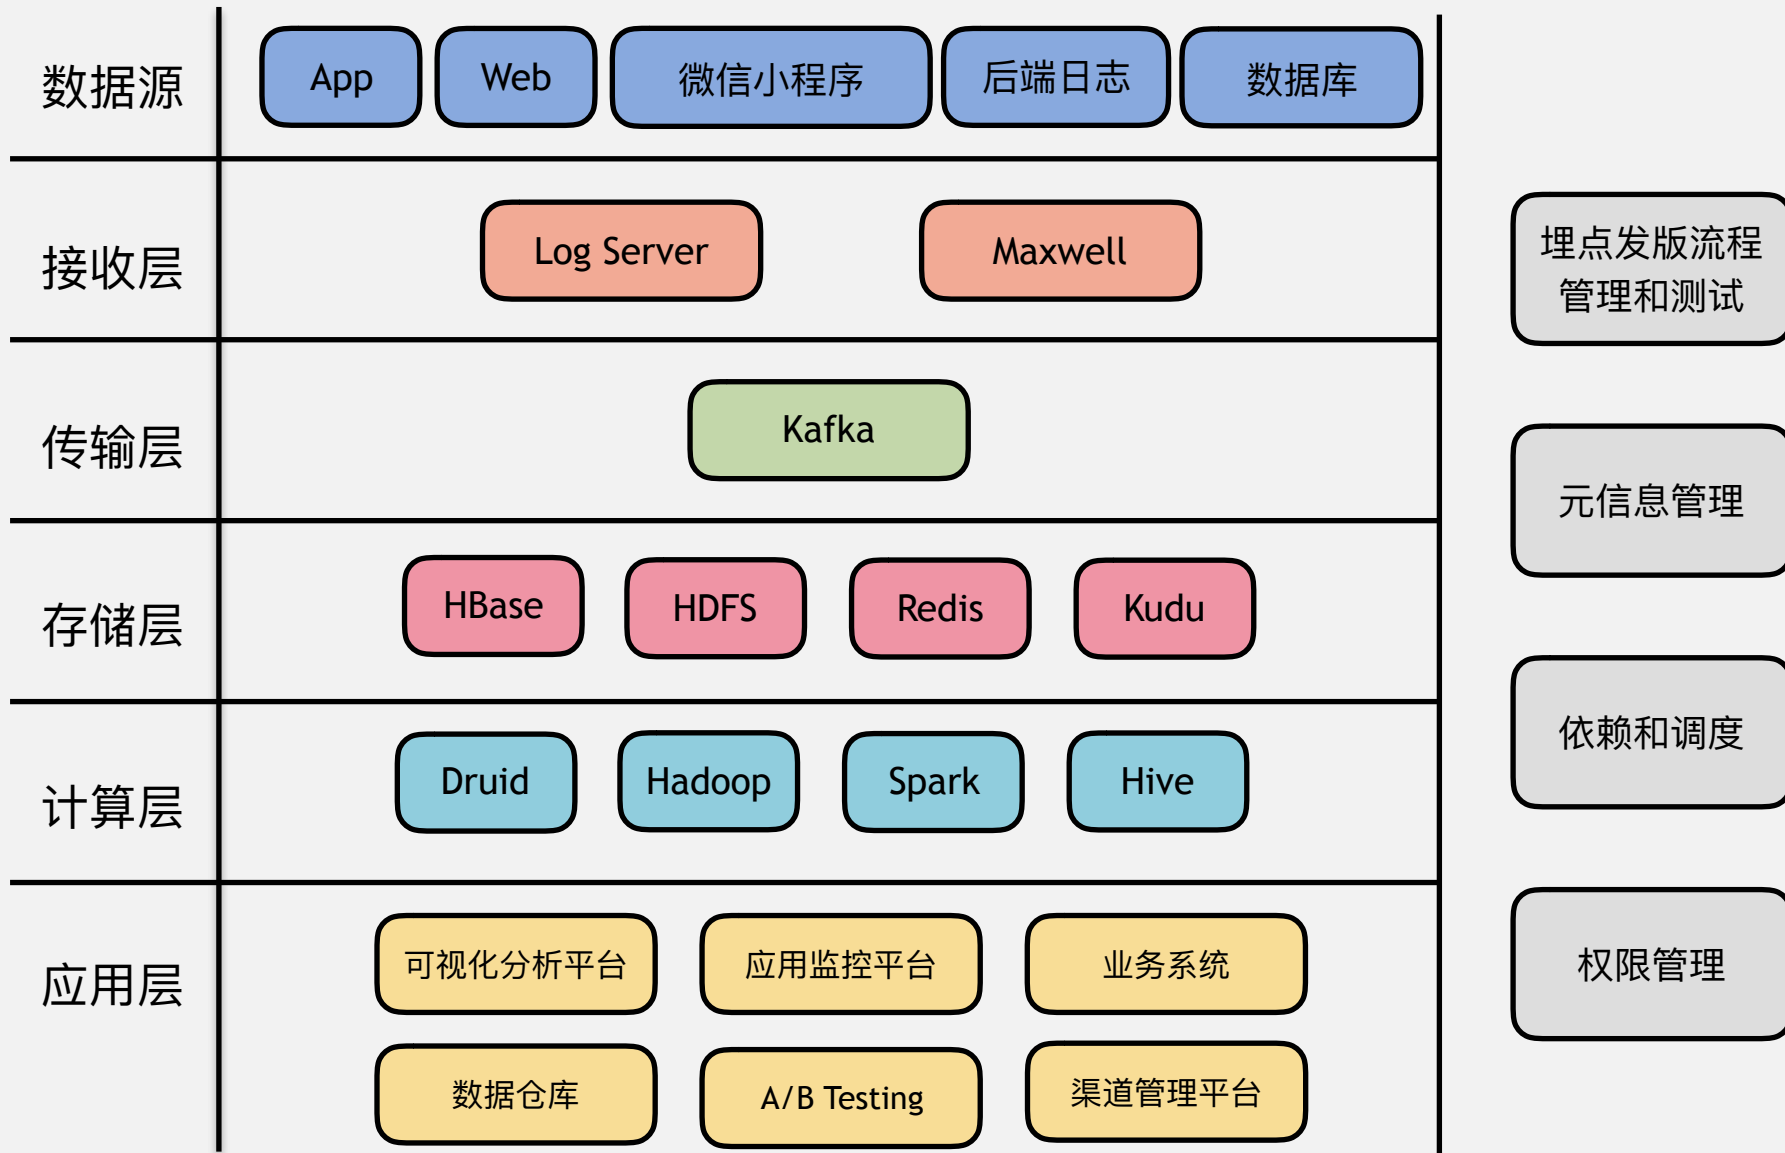


1. 数据平台架构
2. 数据可视化 Demo
3. 更多实际应用



知乎

数据平台整体架构

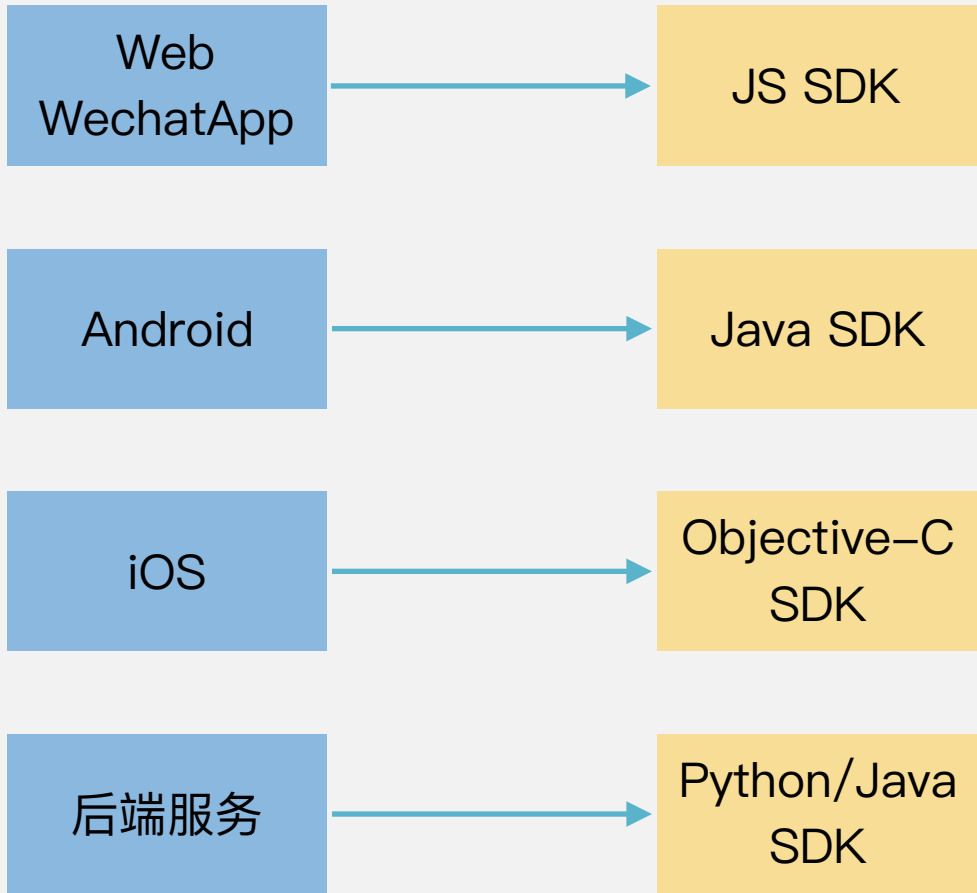


埋点

埋点发版流程
管理和测试

1. 产品经理提出埋点需求
2. 数据分析师写埋点文档
3. 交付工程师开发
4. 埋点回归测试
5. 客户端发版

使用 Protobuf 做埋点标准化



1. 埋点工程师不容易写错
2. 修改提 Code Review
3. 统一命名管理
4. 序列化数据的平台无关性
5. 传输体积小，省流量
6. 支持多语言， 向后兼容

Who & When

- IDInfo
- ClientInfo
- TimeInfo
- NetworkInfo

Where

- Action
- Url
- Element
- Module
- Name

What

- ExtraInfo



- 内容由业务后端序列化好 PB, Base64 成 string 后下发
- 客户端传回后端下发 string, 数据平台反序列化
- 客户端主动收集内容上报, 例如页面加载时间等

客户端 Hybrid 框架埋点的核心要素

- 前端 JS 库通过 Native 提供的端能力进行打点统计
- Hybrid 框架保证只发一次页面展现
- Hybrid 框架处理 Referrer

2016.02.16 - 2017.07.28 一共有 1187 次提交
埋点日志格式文件行数 2568

☆ Star

16

🍴 Fork

42

SSH ▾

git@git.in.zhihu.com:data/za-
f



Files (5.4 MB)

Commits (1,187)

Branches (12)

Tags (229)

Readme

Add Changelog

Add License

```
message MonitorInfo {  
  ...  
  // App 页面加载信息  
  optional AppPerformancePageLoadInfo app_performance_load = 7;  
  // App 卡顿信息  
  optional AppPerformanceBlockInfo app_performance_block = 8;  
}
```

日志接收

Log Server

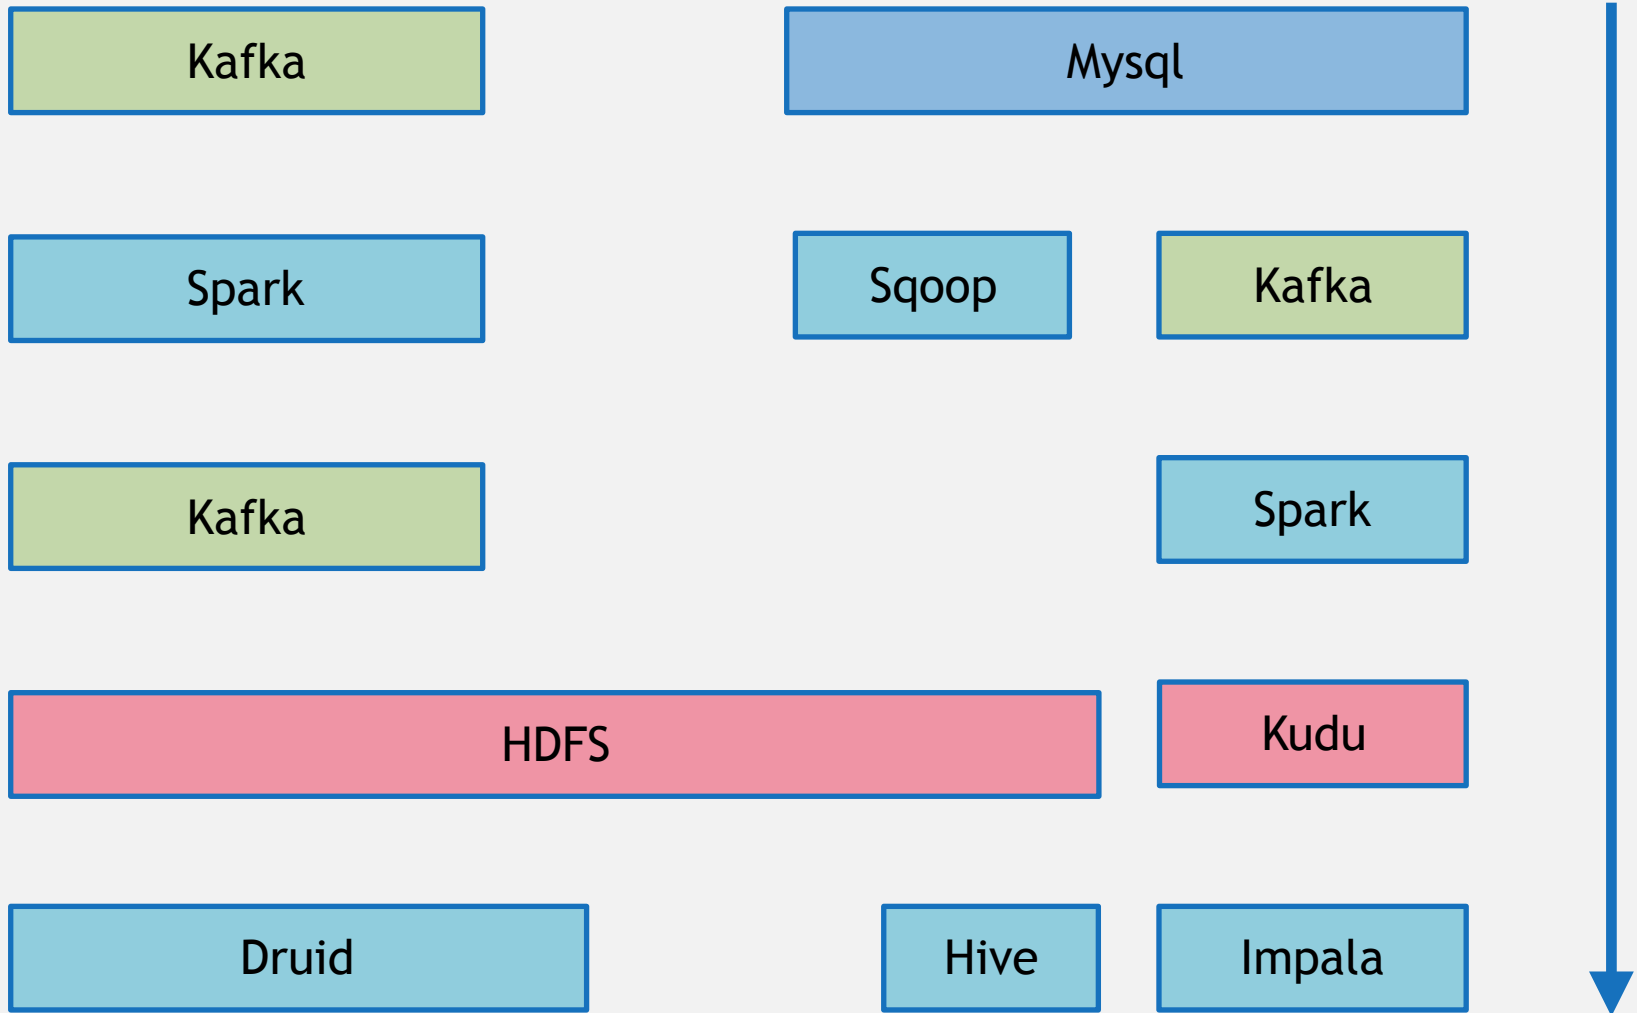
消息监听

Maxwell

- 接收 Protobuf、Json 和 String 类型格式数据
- 数据写入 Kafka
- 写入 Kafka 失败时存入本地 Leveldb
- 发送队列健康时，发送 Leveldb 数据到 Kafka

使用 Maxwell 接 Mysql Binlog 写 Kafka

计算层



批处理

- 自研批处理系统，读 Kafka 写 HDFS
- 读 HDFS 写 HDFS
- Sqoop 批量导出 Mysql 数据到 Hive
- 读 HDFS 写 Druid

实时处理

Spark Streaming ETL 写 Kafka

- IP 地址解析
- UserAgent 解析
- 业务数据分流

Tranquility 消费 Kafka 写 Druid

Spark Streaming 消费 Kafka 写 Kudu

查询层

- **Druid**
- Hive
- Impala

- 对多维分析和留存分析 Query 按时间拆分
- Query 结果按时间拆分后写入缓存
- 数据源重导后对应时间范围的缓存自动失效
- 检查缓存版本，只有数据未变动的查缓存

Mysql 数据实时 OLAP

- 2016.08 ~ 2017.07 Impala + Kudu

- 优点：查询速度快，实时性高
- 缺点：表结构变更后需要重导

- 2017.08 ~ 未来 TiSpark

- 7 月底 PingCAP 推出 TiSpark, 开始测试 TiSpark 性能

大数据的实时 OLAP

- 非固化需求
- 自定义多维分析
- 自定义留存分析

数据可视化 Demo

APMCon 2017 数据分析

1. 数据源导入
2. 自定义多维分析查询
3. 自定义留存分析

Hive 数据导入平台

Assist Settings

DATABASE

tmp

TABLES

apm

apm_speaker

apm_visitor

```
1 select * from apm_speaker
```

Execute Save as... Explain or create a New query

Recent queries Query Log Columns **Results** Chart

	apm_speaker.corp	apm_speaker.title	apm_speaker.name	apm_speaker.date
0	销售易	技术VP	赵宇辰	2017-08-10
1	京东	资深架构师	张成远	2017-08-10
2	美团大众点评	高级技术专家	梁士兴	2017-08-10
3	奇虎360手机卫士	性能质量组技术经理	纪桐	2017-08-10
4	趣店集团	总架构师	徐章健	2017-08-10
5	微信客户端	开发团队负责人	陈岳伟	2017-08-10
6	阿里巴巴数据库事业部	高级技术专家	乔红麟	2017-08-10
7	百度	高级前端工程师	李文倩	2017-08-10
8	滴滴出行	技术专家	戴铭	2017-08-10
9	农行软件开发中心架构	管理办公室副主任工程师	赵勇	2017-08-10
10	支付宝	高级技术专家	董庭坚	2017-08-10
11	智能运维算法专家	清华计算机系副教授	裴丹	2017-08-10

在 Slack #za-feedback 频道提意见
查看 Wiki 上的 ZA 使用指南
在 ZA Test 环境 实时测试日志

数据源

数据源往往是一张表结构的数据

名称与显示名称

数据源的基本信息，便于归类、查找

apm_speakers

apm_speakers

数据库

hive 中的数据库名

tmp

数据表

hive 中的数据表名

apm_speaker

/user/yuzhou/apm/speaker

时间列

选择表中时间列与格式化设定

date (date)

joda

比如 yyyy-MM-dd HH:m

指标

在 ZA 中出现的指标，设置项分别为列名、类型与名称

name

去重数

讲师人数

删除

指标

在 ZA 中出现的指标，设置项分别为列名、类型与名称

name ▾	去重数 ▾	讲师人数	删除
--------	-------	------	----

corp (string) ▾	整型加和数 ▾	指标名称	添加
-----------------	---------	------	----

维度

在 ZA 中出现的维度，设置项分别为列名、类型与名称。不添加则自动以时间列、指标列以外的列为维度。

corp ▾	默认 ▾	删除
--------	------	----

title ▾	默认 ▾	删除
---------	------	----

name ▾	默认 ▾	删除
--------	------	----

选择列... ▾	默认 ▾	添加
----------	------	----

每日同步时导入的时间段

每次自动同步时同步的时间段，可以用于增量同步

昨天 ▾

同步频率

定时任务执行时间

20 8 * * *

更新数据 SQL (选填)

如果需要每天更新数据，可以输入 hive 更新数据时使用的 SQL，会随指定频率执行任务

CREATE ...

每日同步时导入的时间段

每次自动同步时同步的时间段，可以用于增量同步

昨天 

同步频率

定时任务执行时间

20 8 ***

更新数据 SQL (选填)

如果需要每天更新数据，可以输入 hive 更新数据时使用的 SQL，会随指定频率执行任务

```
CREATE ...
```

数据源维护者

将有权限进行相关操作，并收到导入动作等相关通知

搜索用户...

保存数据源

展开高级选项



导入数据源 Workflow 的前置检查

创建指标

指标

当前数据源下的所有指标

创建指标

id	指标名称	说明	访问权限	操作
1061	讲师人数		分析师	编辑
1062	日志条数		分析师	编辑

名称与说明

指标的基本信息，便于归类、查找

自定义指标

指标的介绍...

指标使用的聚合参数

指标是如何被定义的

count

加...

减...

乘...

除...

整型加和数

浮点型加和数

整型最小值

浮点型最小值

整型最大值

浮点型最小值

近似直方图指标

百分位数

去重数

访问权限

只有指定权限以上的人才可以选择

分析师

单位与显示格式

美化指标的显示格式

数据单位

数字

名称与说明

指标的基本信息，便于归类、查找

创建指标 Demo

指标的介绍...

指标使用的聚合参数

指标是如何被定义的

title

去重数

包含

title

x

包括

高级

且

包含

corp

x

包括

集团

或

包含

corp

x

包括

公司

且

包含

选择维度

等于

- corp
- corp
- title
- title

过滤器

对以上条件筛选出的日志进行进一步筛选

包含 ▾ 选择维度 开头为 ▾

或

包含 ▾ 选择维度 正则匹配 ▾

或... 拆分 删除

且

包含 ▾ 选择维度 小于 ▾

或

包含 ▾ 选择维度 结尾为 ▾

且

包含 ▾ 选择维度 等于多种 ▾ 多个值使用半角逗号 (,) 分开

创建多维分析报表

创建报表

通过指定的维度与指标创建报表，稍后在报表展示页面可以调整报表的时间范围、粒度

数据源

不同数据源有不同的指标与维度，在产品管理页面切换产品

apm_speakers ↕

名称与说明

报表的基本信息，便于归类、查找

apm_speakers

报表说明

指标

通常以数字形式呈现，在图表上处于纵轴的位置。默认会以时间维度来切分数据

讲师人数 × 选择指标

默认查询粒度

可以为时间列查询设置默认查询粒度

天 ↕

维度

可以以不同维度的值来切分数据

corp × 选择维度

维度

可以以不同维度的值来切分数据

corp × 选择维度

过滤器

对以上条件筛选出的日志进行进一步筛选

+ 添加过滤条件

报表报警项

维度取值	指标	报警配置函数	粒度	操作
<input type="text" value="corp"/>	讲师人数 ↕	$(d1-d2)/d2 > 0.1$	天 ↕	添加

把报表分享给...

将显示在他们的「向我分享的报表」下

搜索用户...

保存报表

apm_speakers

2017年08月10日 - 2017年08月11日

yuzhou 的报表, 以 apm_speakers 为数据源

不进行对比

[显示指标维度](#) [隐藏过滤条件](#) [隐藏维度报表](#) [在时间报表拆分维度](#)

报表过滤条件


+ 添加过滤条件

时间报表

天

[导出](#) [隐藏平均值](#) [显示极值](#) [自动切割纵轴范围](#)

折线图



讲师人数

维度报表

- 维度报表显示的数据，在当前查询时间范围（2017-08-10 - 2017-08-11）下的聚合值
- 排序功能目前只对已显示的数据进行排序

导出 显示总计百分比

表格 

corp	title	讲师人数 ↓
		48
爱卡汽车	移动研发团队负责人	1
白山云	联合创始人兼首席技术官	1
iTutorGroup集团微服务平台(TGOP)负责人	tutorabc	1
搜狐	研发中心架构师	1
数据运维部负责人	爱投资	1
数据库团队负责人	京东商城资深架构师	1
青云	基础设施部负责人	1
58集团技术工程平台群	高级技术经理	1
小红书	客户端iOS负责人	1
MIUI系统	框架负责人	1
滴滴出行	技术专家	1
招商银行数据中心	应用管理团队负责人	1

报表过滤条件


包含 ▾	title ×	包括 ▾	高级
或			
包含 ▾	title ×	包括 ▾	负责

时间报表

天 ▾

导出 隐藏平均值 显示极值 自动切割纵轴范围

折线图 ▾



维度报表

- 维度报表显示的数据，在当前查询时间范围（2017-08-10 - 2017-08-11）下的聚合值
- 排序功能目前只对已显示的数据进行排序

导出 显示总计百分比

表格 

corp	title	讲师人数↓
		21
青云	基础设施部负责人	1
搜狗	资深高级开发工程师	1
支付宝	高级技术专家	1
凡普金科	大数据高级架构师	1
陌陌	视频媒体技术负责人	1
知乎	大数据平台负责人	1
瓜子二手车	高级技术总监	1
百度	高级前端工程师	1
艺龙网	高级技术经理	1
海尔	全球运维中心高级主管	1
美团大众点评	高级技术专家	1
甲骨文中国技术产品	事业部高级技术总监	1
58集团技术工程平台群	高级技术经理	1

创建留存报表

The screenshot shows a database query tool interface. On the left, there is a sidebar with 'Assist' and 'Settings' tabs. Below them, the 'DATABASE' is set to 'tmp' and the 'TABLES' list includes 'apm', 'apm_speaker', and 'apm_visitor'. The main area contains a query editor with the SQL statement: `select * from apm_visitor`. Below the editor are buttons for 'Execute', 'Save as...', 'Explain', 'or create a', and 'New query'. The results are displayed in a table with columns 'apm_visitor.subject', 'apm_visitor.name', and 'apm_visitor.date'. The results show 11 rows of visitor data from 2017-08-10.

	apm_visitor.subject	apm_visitor.name	apm_visitor.date
0	陌陌直播智能CDN调度系统实践之路	visit1	2017-08-10
1	陌陌直播智能CDN调度系统实践之路	visit2	2017-08-10
2	陌陌直播智能CDN调度系统实践之路	visit3	2017-08-10
3	陌陌直播智能CDN调度系统实践之路	visit4	2017-08-10
4	陌陌直播智能CDN调度系统实践之路	visit5	2017-08-10
5	陌陌直播智能CDN调度系统实践之路	visit6	2017-08-10
6	陌陌直播智能CDN调度系统实践之路	visit7	2017-08-10
7	陌陌直播智能CDN调度系统实践之路	visit8	2017-08-10
8	陌陌直播智能CDN调度系统实践之路	visit9	2017-08-10
9	陌陌直播智能CDN调度系统实践之路	visit10	2017-08-10
10	视频直播的智能流量调度系统	visit11	2017-08-10

创建留存报表

通过规定指标、留存源过滤条件与留存目标过滤条件来创建留存报表

数据源

不同的产品（数据源）有不同的指标与维度，在产品管理页面切换产品

apm_visitor

名称与说明

报表的基本信息，便于归类、查找

APMCon 留存报表

报表说明

指标

以指定指标作为留存查询的依据

访客人数

默认查询粒度

为留存报表设置默认的查询粒度与长度

天

7天留存

维度

可以以不同维度的值来切分数据

subject 选择维度

留存源过滤

对指定的留存指标进行过滤，进入留存查询范围

+ 添加过滤条件

留存目标过滤

对留存查询结果进行进一步过滤

+ 添加过滤条件

整体过滤

同时对留存源与目标进行过滤

+ 添加过滤条件

把报表分享给...

将显示在他们的「向我分享的报表」下

保存报表

yuzhou 的报表，以 apm_visitor 为数据源

[显示指标维度](#) [隐藏报表过滤条件](#) [在留存报表拆分维度](#)

留存源过滤

对指定的留存指标进行过滤，进入留存查询范围

+ 添加过滤条件

留存目标过滤

对留存查询结果进行进一步过滤

+ 添加过滤条件

整体过滤

同时对留存源与目标进行过滤

+ 添加过滤条件

留存报表

以指定粒度来查看不同时长和粒度的留存

天

7天留存

[导出](#) [显示总计百分比](#)

表格

+ 添加过滤条件

留存目标过滤

对留存查询结果进行进一步过滤

+ 添加过滤条件

整体过滤

同时对留存源与目标进行过滤

+ 添加过滤条件

留存报表

以指定粒度来查看不同时长和粒度的留存

天

7天留存

导出 显示总计百分比

表格

时间↑	访客人数	第 1 天	第 2 天	第 3 天	第 4 天	第 5 天	第 6 天	第 7 天
08月10日	20	16	0	0	0	0	0	0
08月11日	16	0	0	0	0	0	0	0

数据请求时间: 2017年08月04日 23时42分16秒 打开报表查询通知 刷新报告数据 编辑报表 复制报表

8.10 听过 **CDN** 的人在 8.11 又听了**知乎**的有多少人?

APMCon 留存报表

2017年08月10日 - 2017年08月11日

yuzhou 的报表，以 apm_visitor 为数据源

[显示指标维度](#) [隐藏报表过滤条件](#) [在留存报表拆分维度](#)

留存源过滤

对指定的留存指标进行过滤，进入留存查询范围

包含 × 包括

留存目标过滤

对留存查询结果进行进一步过滤

包含 × 包括

整体过滤

同时对留存源与目标进行过滤

+ 添加过滤条件

留存报表

天

次日留存

以指定粒度来查看不同时长和粒度的留存

[导出](#) [显示总计百分比](#)

[表格](#)

时间 ↑	访客人数	第 1 天
------	------	-------

留存源过滤

对指定的留存指标进行过滤，进入留存查询范围

包含 包括

留存目标过滤

对留存查询结果进行进一步过滤

包含 包括

整体过滤

同时对留存源与目标进行过滤

+ 添加过滤条件

留存报表

以指定粒度来查看不同时长和粒度的留存

天

次日留存

导出 显示总计百分比

表格

时间↑	访客人数	第 1 天
08月10日	14	12
08月11日	0	0


数据请求时间: 2017年08月04日 23时55分14秒 打开报表查询通知 刷新报告数据 编辑报表 复制报表

更多实际应用

应用监控平台

- 页面加载时长
- App 启动时长
- 系统性能
- App 流量统计
- 页面卡顿信息
- 平台
- 系统版本
- 应用版本
- 机型
- 运营商
- 网络类型

业务后端对接



Growth

- 流量来源
- 客户端新增识别
- 渠道管理后台

流量来源

- 自然流量来源
 - 搜索引擎流量
 - 社交流量
 - 直接流量
- 付费流量来源
 - 使用人工 utm 标记

被 Scheme 或 Universal Link 唤醒的 App，在启动时报唤醒链接，数据平台组抽取链接中的 UTM 作为当前日志 UTM，会话切割后即可得到客户端流量来源

A/B Testing

- 配置下发
- 客户端生效后上报
- 数据可视化

知 知乎
★★★★★



打开



? 热门提问

有哪些健身服适合夏天在健身房穿有哪些健身服适合夏天?

打开

热门文章

北京有什么鲜为人知的，很好逛的街头小店?

打开



⚡ Live

黎贝卡：如何一小时内做出一顿家宴?

打开



电子书

日常经济学 2

打开

? 相关提问

有哪些流行得起来的小众奢侈品品牌?

打开

QA



THANK YOU

