MongoDB在大规模数据获取和准实时分析中的应用

Proudly Powered by MongoDB

张锦杰
深圳市一面网络技术有限公司

知识发现

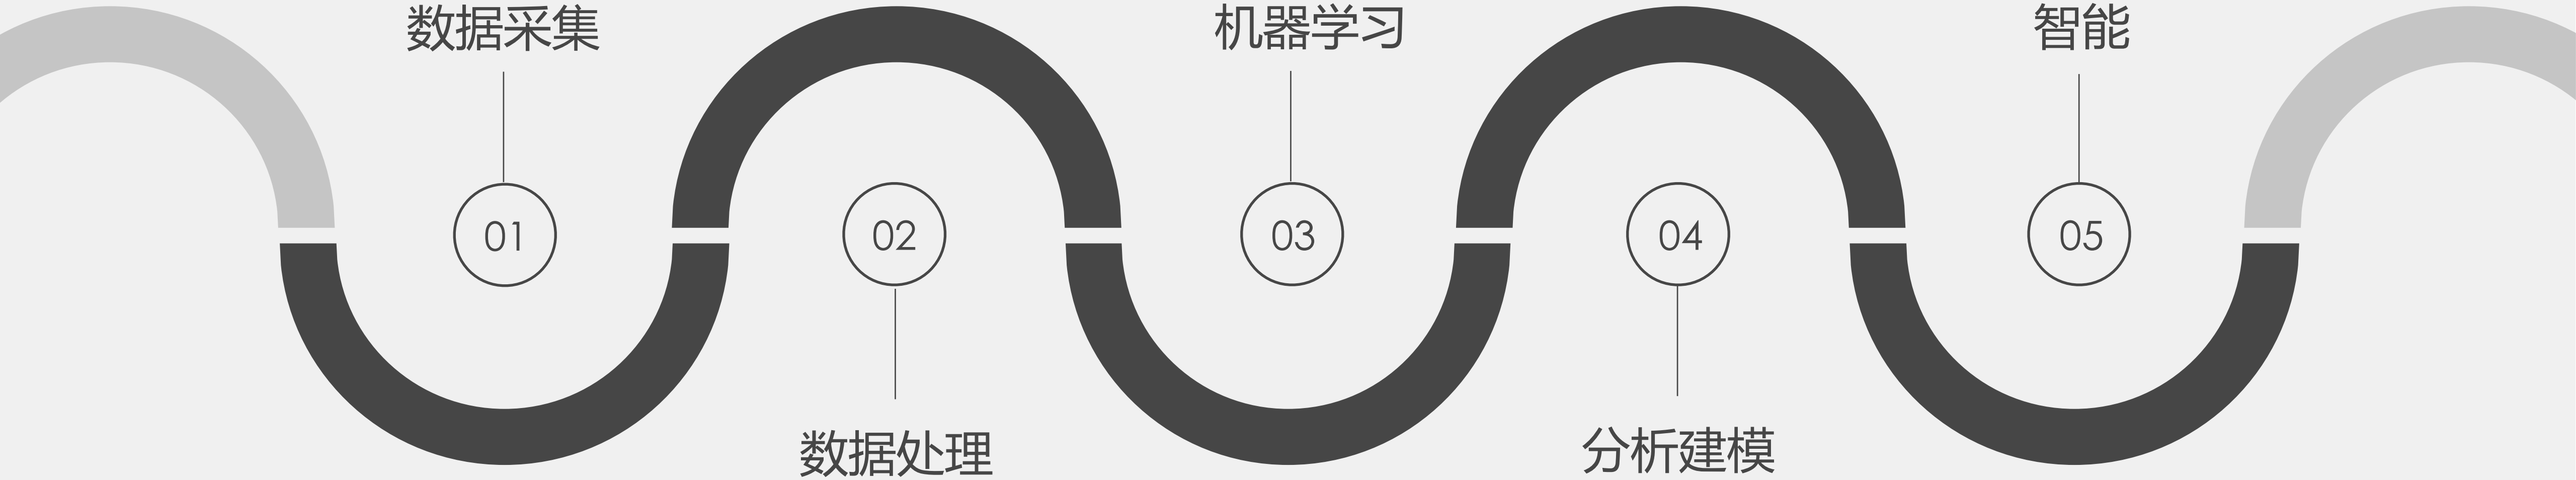

01

电商

社交网络

新闻媒体

企业内部数据

数据采集

02

数据处理

数据清洗

自动化ETL

03

自然语言处理

图像识别

机器学习

04

分析建模

关联规则

聚类、分类

预测分析

05

可视化

前端自助分析

智能

数据沉淀

电商A

15万个品牌， 23亿件商品，
90亿张图片, 35亿条评论

电商B

15万个品牌， 21亿件商品，
70亿张图片, 15亿条评论

电商C

2.8万个品牌， 390万件 商品，
1千万张图片, 7千万条评论

电商D

3万个品牌， 2千万件商品，
9千万张图片, 3千万条评论

电商E

4400个品牌， 26万件商品，
120万张图片, 1千万条评论

电商F

3.4万个品牌， 230万件商品，
930万张图片, 300万条评论

棱镜

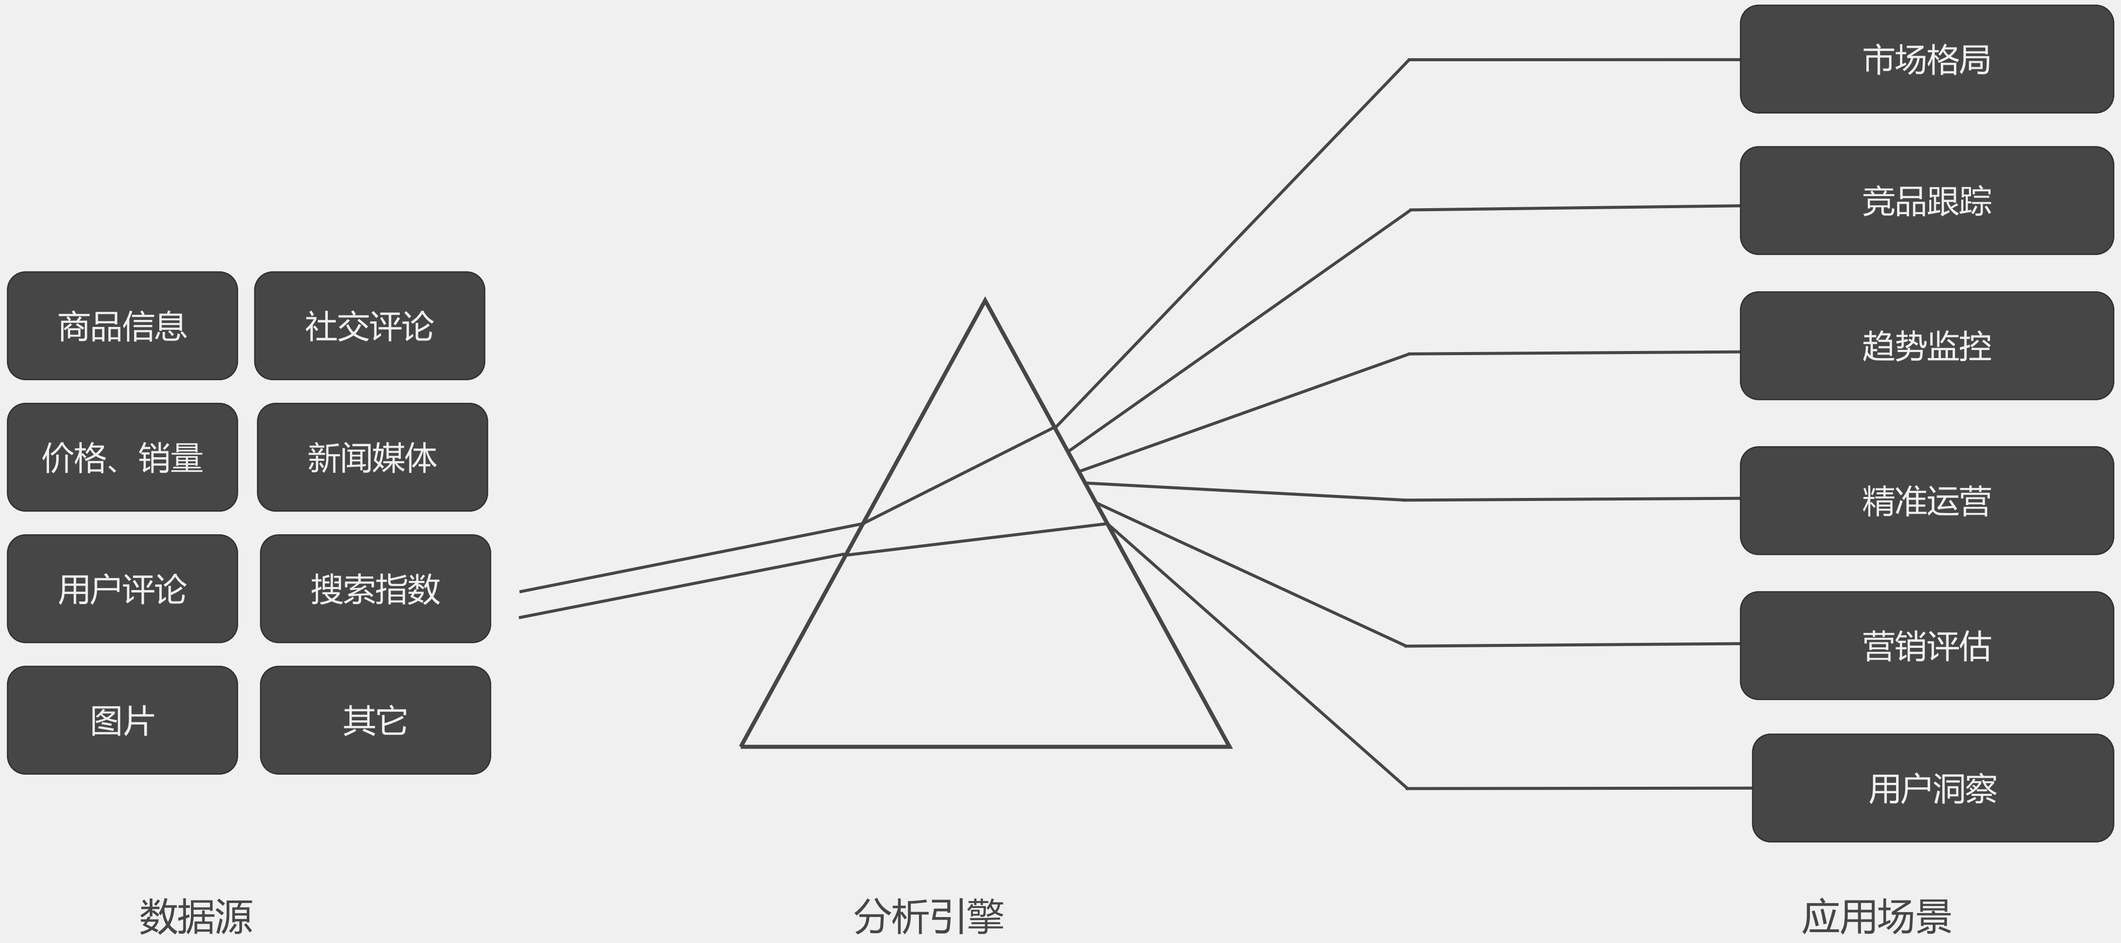
商品信息
社交评论
价格、销量
新闻媒体
用户评论
搜索指数
图片
其它
市场格局
竞品跟踪
趋势监控
精准运营
营销评估
用户洞察
数据源
分析引擎
应用场景

技术栈

多维分析 | 事件通知及预警 | 可视化

营销评估 | 竞品跟踪 | 趋势监控 | GMV | 用户洞察

精准运营 | 市场格局

索引、聚合、统计

数据清洗、标准化 | 自然语言处理

结构化数据（价格、销量、促销等） | 非结构化数据(用户评论，图片)

数据仓库

电商A | 电商B | 电商C | 电商D | 电商E | 电商F

数据应用

基于WEB的交互分析

跨平台、响应式布局

事件通知及预警

分析建模

数据处理

准实时查询

数据清洗、自动化ETL

机器学习

数据存储

分布式

大规模数据存储

大规模数据获取（电商数据）

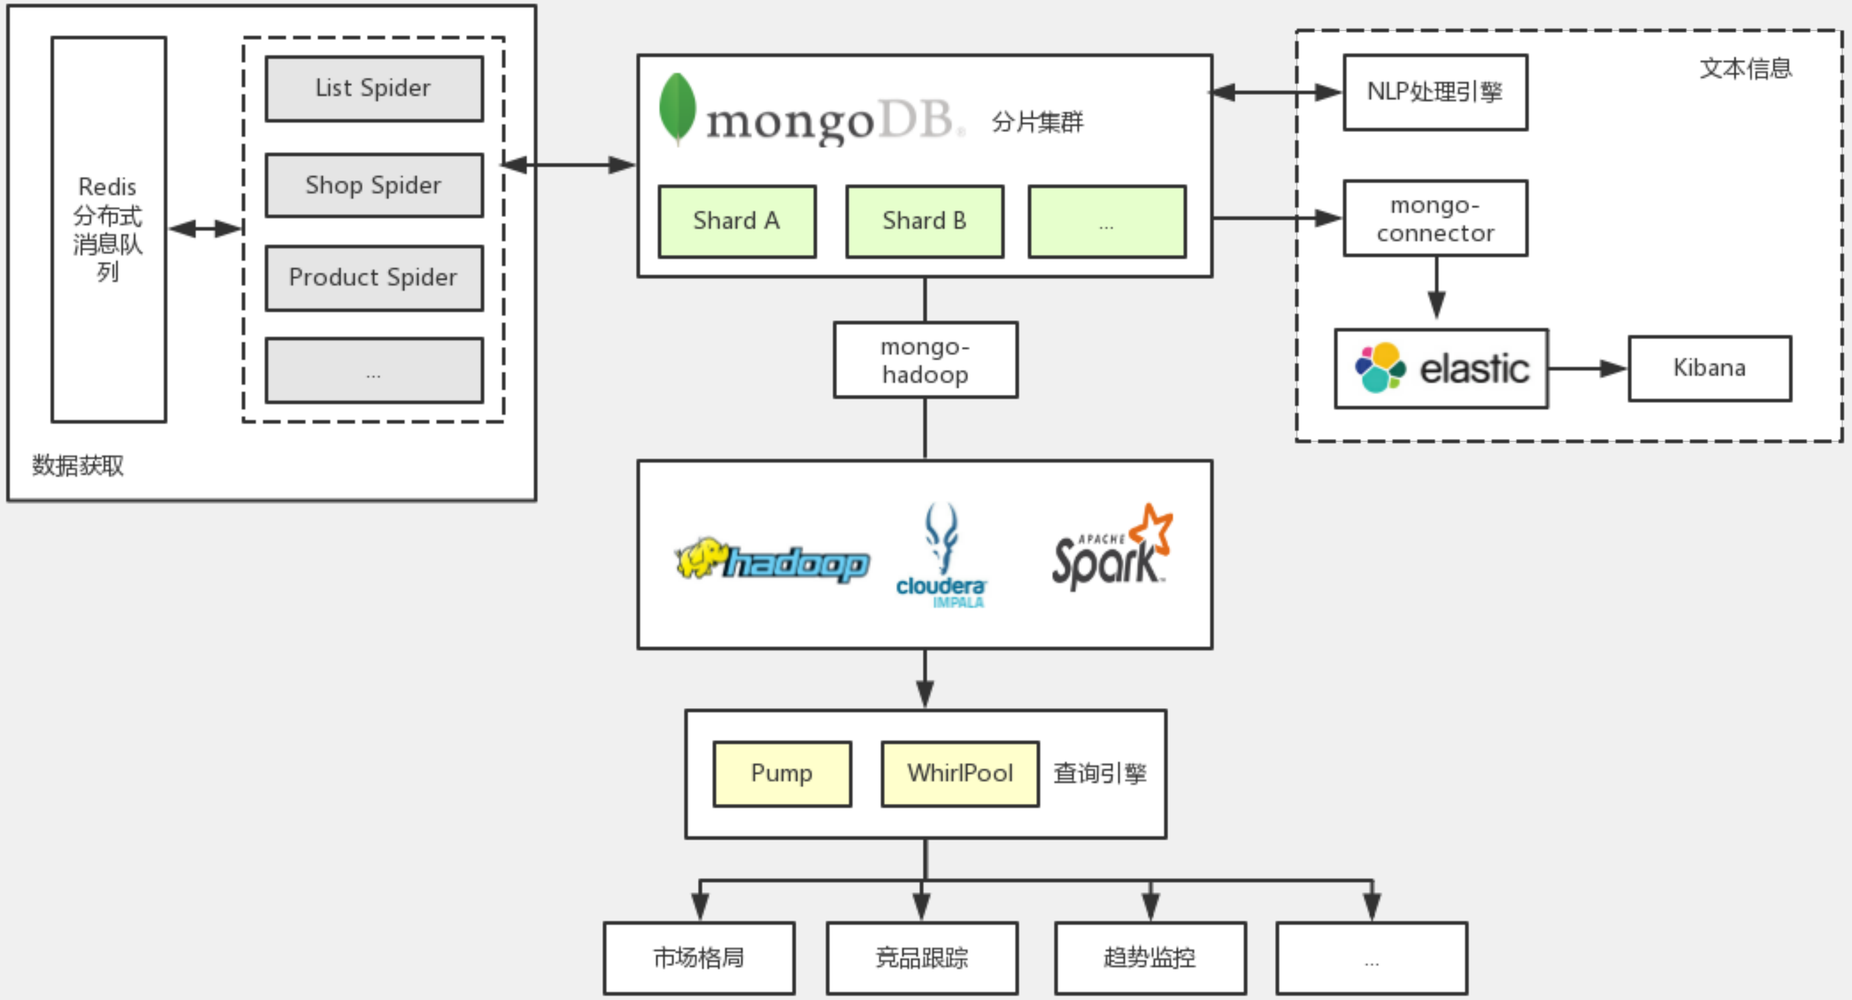

MongoDB分片集群

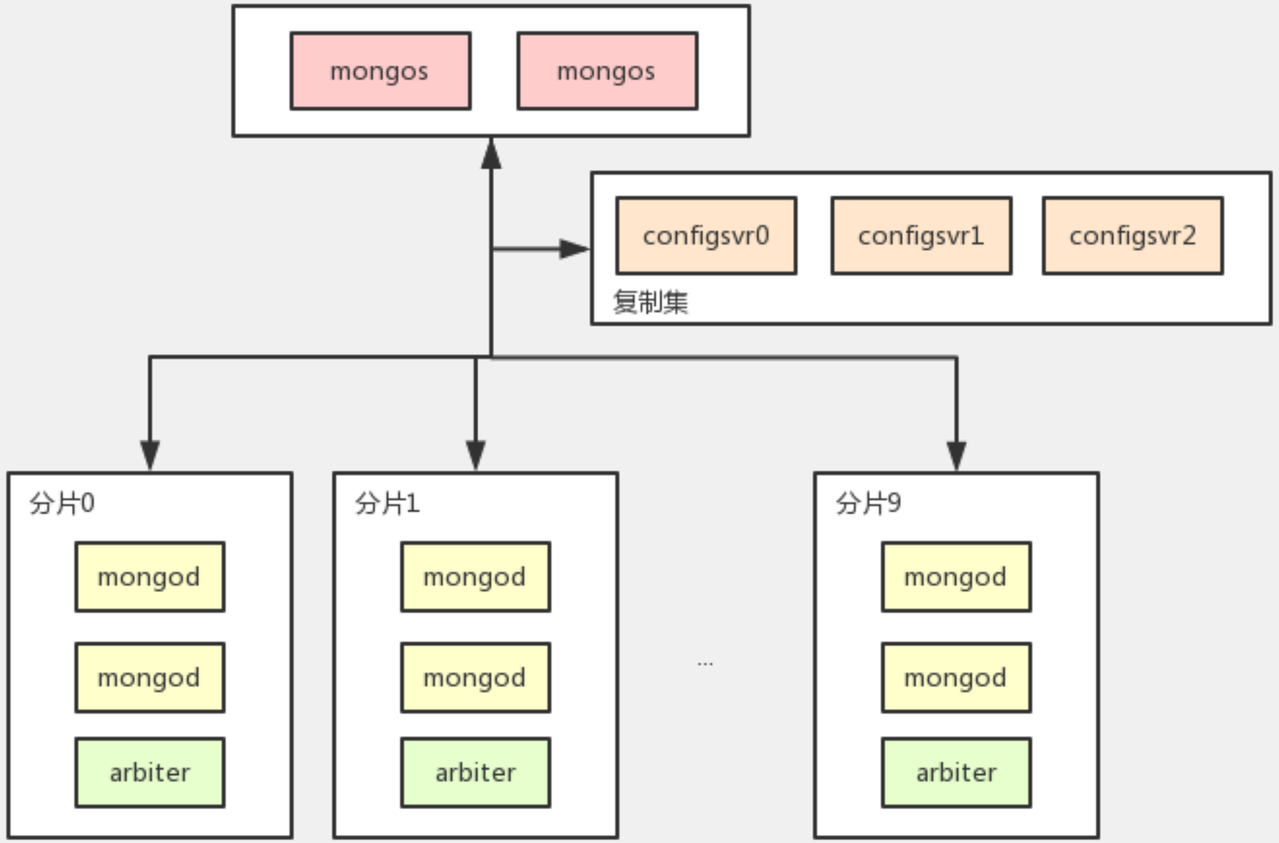

分片集群特点

- 10个分片，每分片2个数据节点、1个arbiter
- 交叉分布，分布在10台物理节点
- 2个mongos节点冗余备份
- 3个configsvr0形成复制集，存储集群元数据

MongoDB分片集群

Shard Key选择：

- 特异性（Cardinality）

  尽量每条记录有不同的值

- 并行写入能力（Write Scaling）

  每条记录的shard key具有一定的随机性

- 查询隔离（Query Isolation）

  每次查询尽量到一个分片或少量几个分片去查询

组合分区键

Product_ID + Date

集群性能

- 100TB数据存储
- 每小时3千万条记录写入

查询引擎

Pump查询引擎

- 支持多种数据源，提供统一访问接口

  MySQL、Impala、MongoDB、ElasticSearch

- JSON形式的HTTP API调用
- 提供数据查询缓存
- 提供客户端SDK，简化上层调用

```
{
    "ds_type": "sqla",
    "ds_dsn": "impala://ym-044:21050/tm_data_dress",
    "table": "shop",
    "metrics": [
        {
            "field": "*",
            "aggregation": "count",
            "alias": "total"
        },
        {
            "field": "shop_id",
            "aggregation": "count(distinct)",
            "alias": "different_shop_id_count"
        }
    ],
    "filters": [
        {
            "field": "created_at",
            "operator": "range",
            "value": ["2015-12-01", "2016-02-01"]
        }
    ],
    "groupby": ["week(created_at)"]
}
```

查询格式

```
ds = DataSource('mysql', 'mysql://root@localhost:3306/misc', 'shop')

q = Query(ds)

q1 = q \
    .count('*', 'count_*') \
    .cumsum('shop_id') \
    .count_distinct('shop_id', 'count_shop_id') \
    .metric('id', 'count', 'count_id') \
    .flt_range('created_at', ["2015-07-01", "2016-07-01"]) \
    .groupby(('created_at', 'week')) \
    .orderby('week(created_at)')
print(pretty(q1.to_dict()))
```

客户端SDK调用

查询引擎

WhirlPool查询引擎

- 基于Spark提供多维交叉分析

  利用RDD进行复杂的聚合运算

- 提供类似于ElasticSearch的DSL查询语言
  - HTTP API接口调用
  - 查询语言更加人性化
- 提供数据查询缓存

统计每个月每个品类商品在不同价格区间中的销量

```
{
  "aggs": {
    "date_histogram": {
      "field": "date",
      "interval": "month",
      "aggs": {
        "terms": {
          "field": "category",
          "aggs": {
            "histogram": {
              "field": "price",
              "interval": 10,
              "aggs": {
                "sum": {
                  "field": "sales"
                }
              }
            }
          }
        }
      }
    }
  }
}
```

Single View

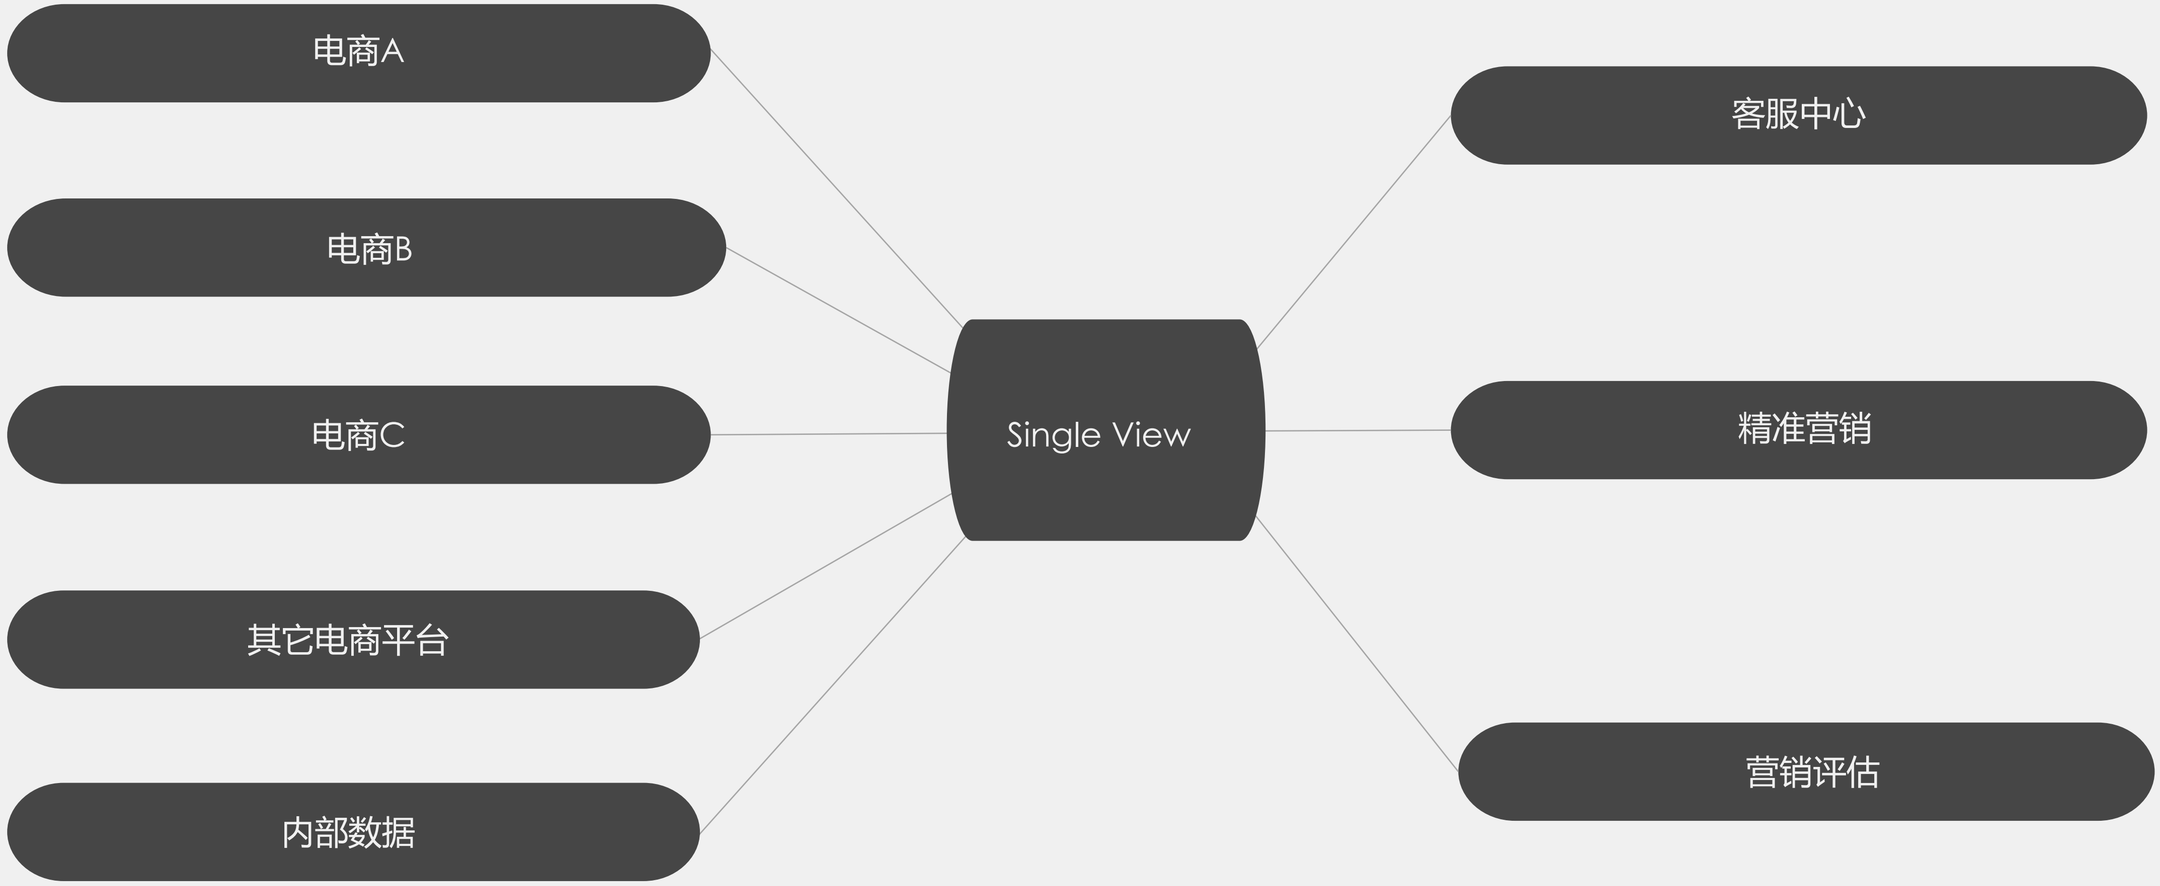

Single View

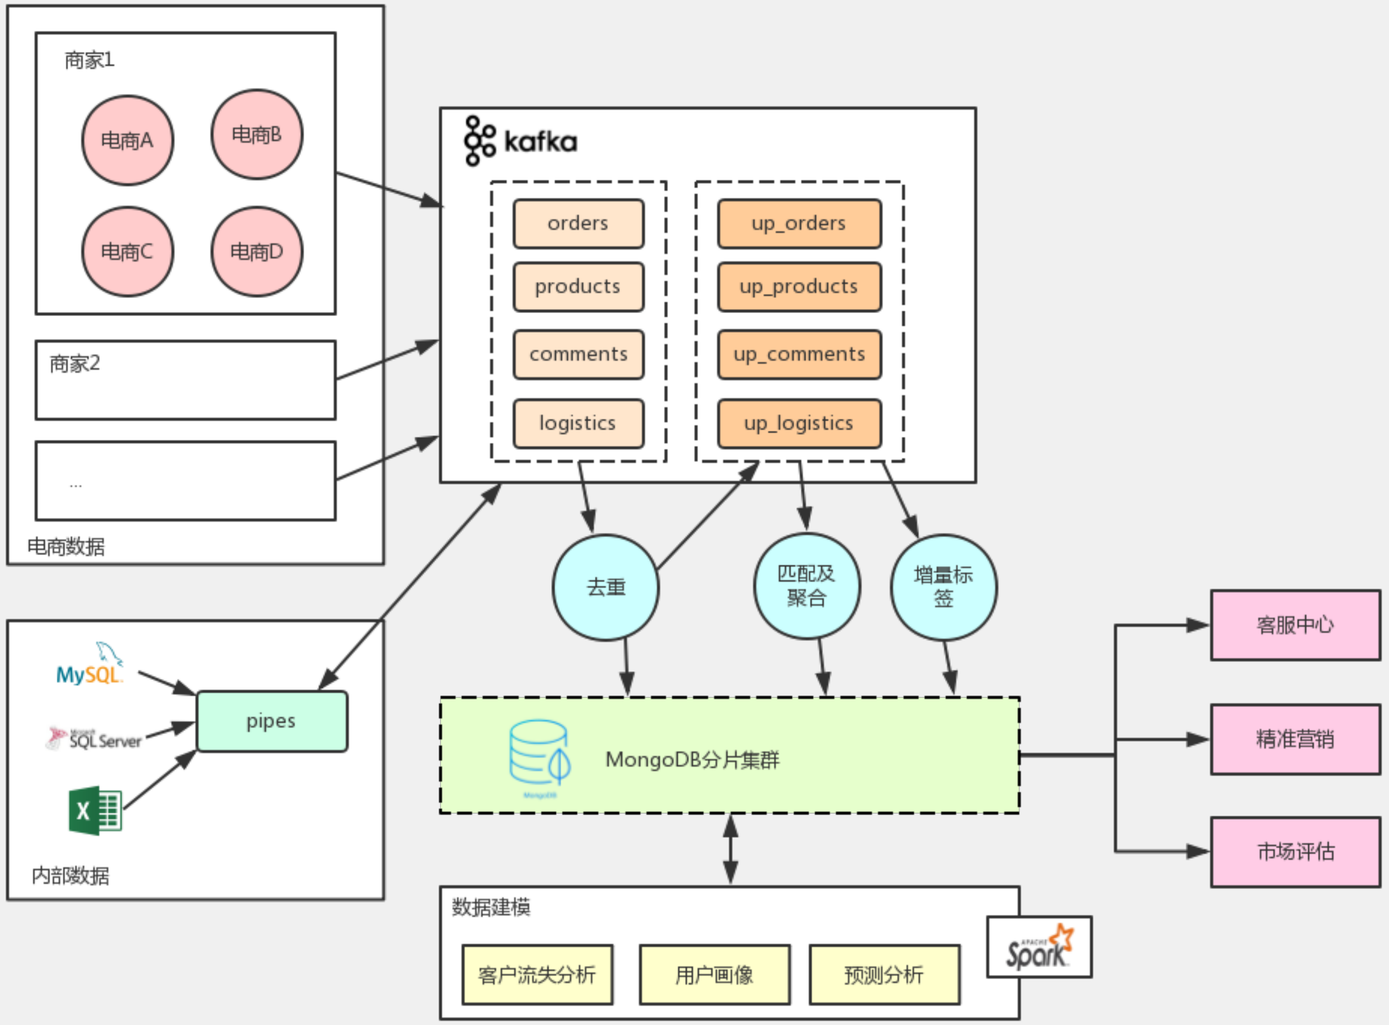
商家1
电商A
电商B
电商C
电商D
商家2
...
电商数据
kafka
orders
products
comments
logistics
up_orders
up_products
up_comments
up_logistics
去重
匹配及聚合
增量标签
MySQL
SQL Server
pipes
内部数据
MongoDB分片集群
客服中心
精准营销
市场评估
数据建模
客户流失分析
用户画像
预测分析
Spark

数据仓库进化史

数据仓库进化史

	优点	缺点
MongoDB	1.schema-free适合与爬虫应用场景； 2.提供完整的索引功能，包括secondary, compound索引； 3.自动分库，极强的水平扩展能力； 4.社区活跃，资料齐全；	1.不支持类型转换函数； 2.统计功能相对较弱，而且书写复杂，不易理解，比如实现count(distinct)功能；
Cassandra	1.去中心化，具有极强的水平扩展能力； 2.混合keyvalue和列式存储结构，需要极强的写入能力； 3.提供primary index和secondary index索引功能，但索引可能对性能有较大影响；	1.面向query的数据建模方式，上层query的更改对数据库有很大影响； 2.collection类型不支持嵌套； 3.集群运维不方便，添加节点、替换节点和删除节点需要遵从不同的操作流程和注意事项； 4.缺乏图形化的监控工具； 5.不能做aggregation统计； 6.文档资料不完善，社区不够活跃；

MongoDB的优势

高吞吐量

高的读写速度

每天上亿条数据ETL能力

Schema Free

异构化、分层存储

对JSON格式友好

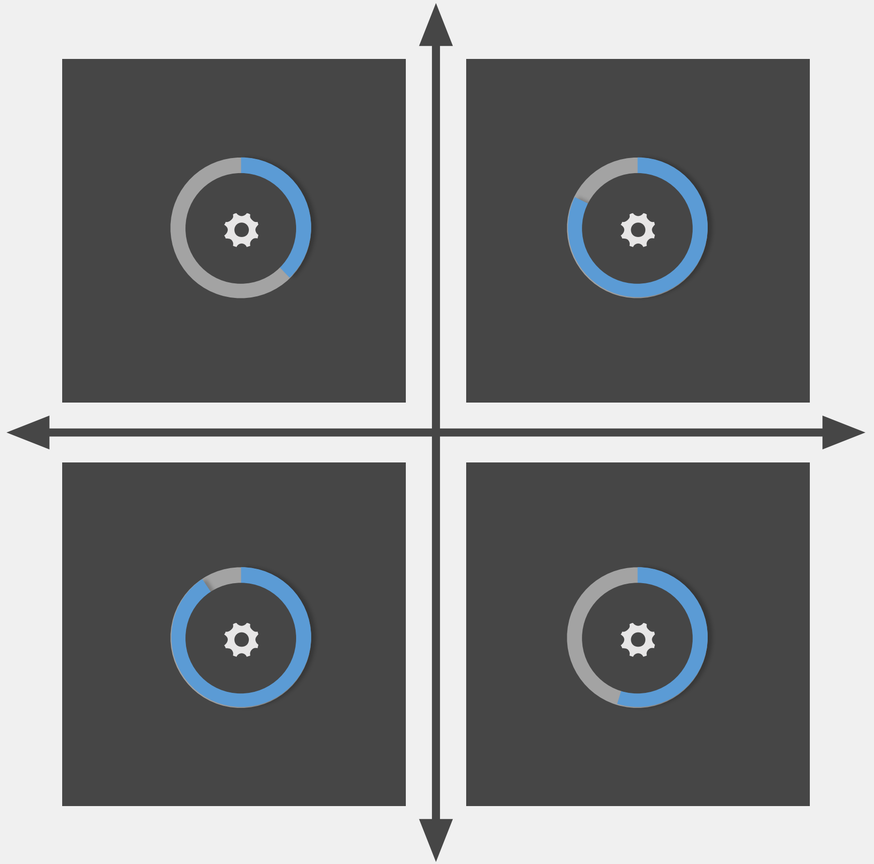

极好的水平扩展性

弹性扩容

大事件应对能力(11/11, 6/18)

访问简单

无感知的分片访问

MongoDB的劣势

复杂查询

Hive & Impala

文本挖掘

ElasticSearch

分析建模

Spark

通过用户评论改善产品质量

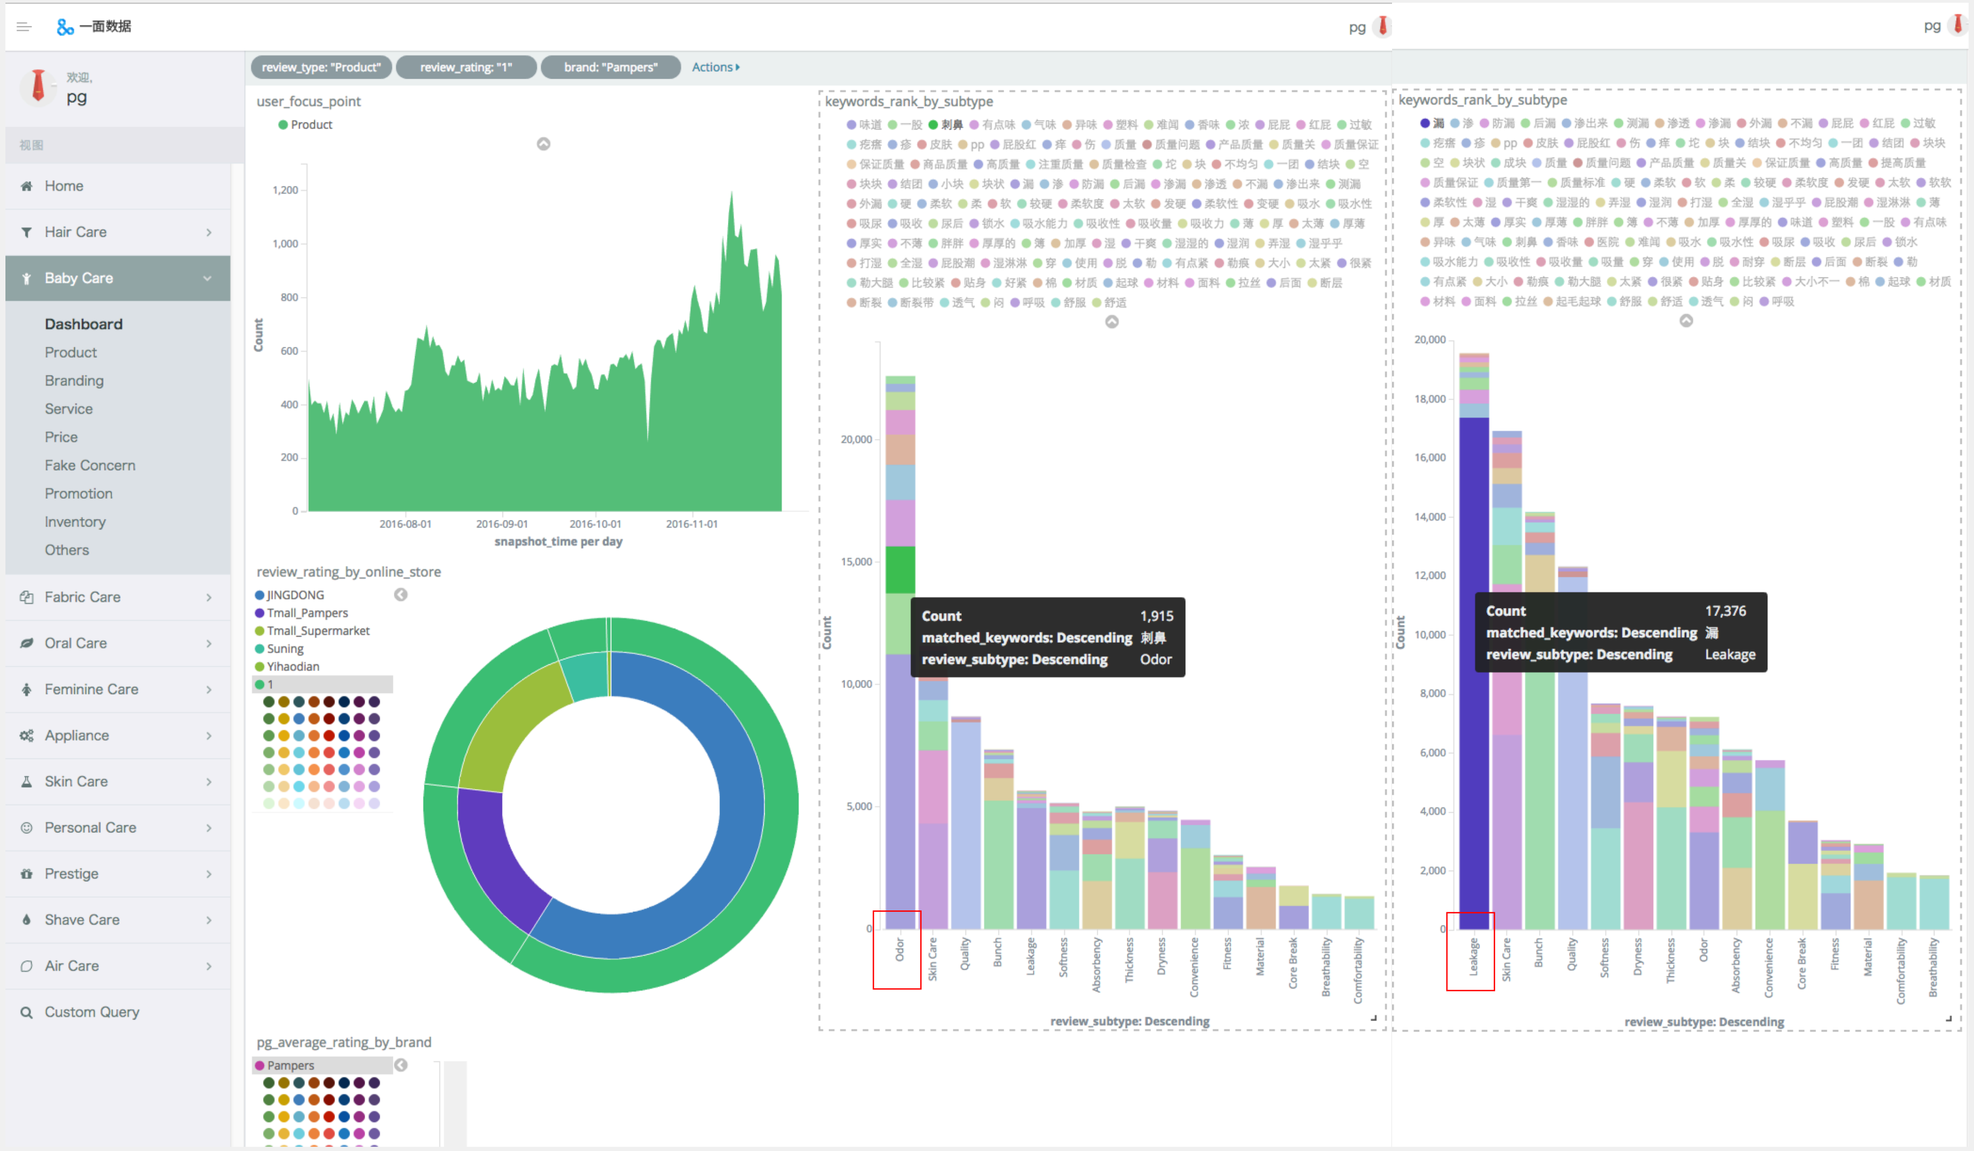

A品牌(某产品)

6个电商平台

120万条用户评论

20%负面评论来自于气味

B品牌(竞品)

5%负面评论来自于气味

但是15%负面评论来自于侧漏

竞争对手策略分析

商品

SPU/SKC数

类别 / 颜色 / 款式

价格/销售额/销量

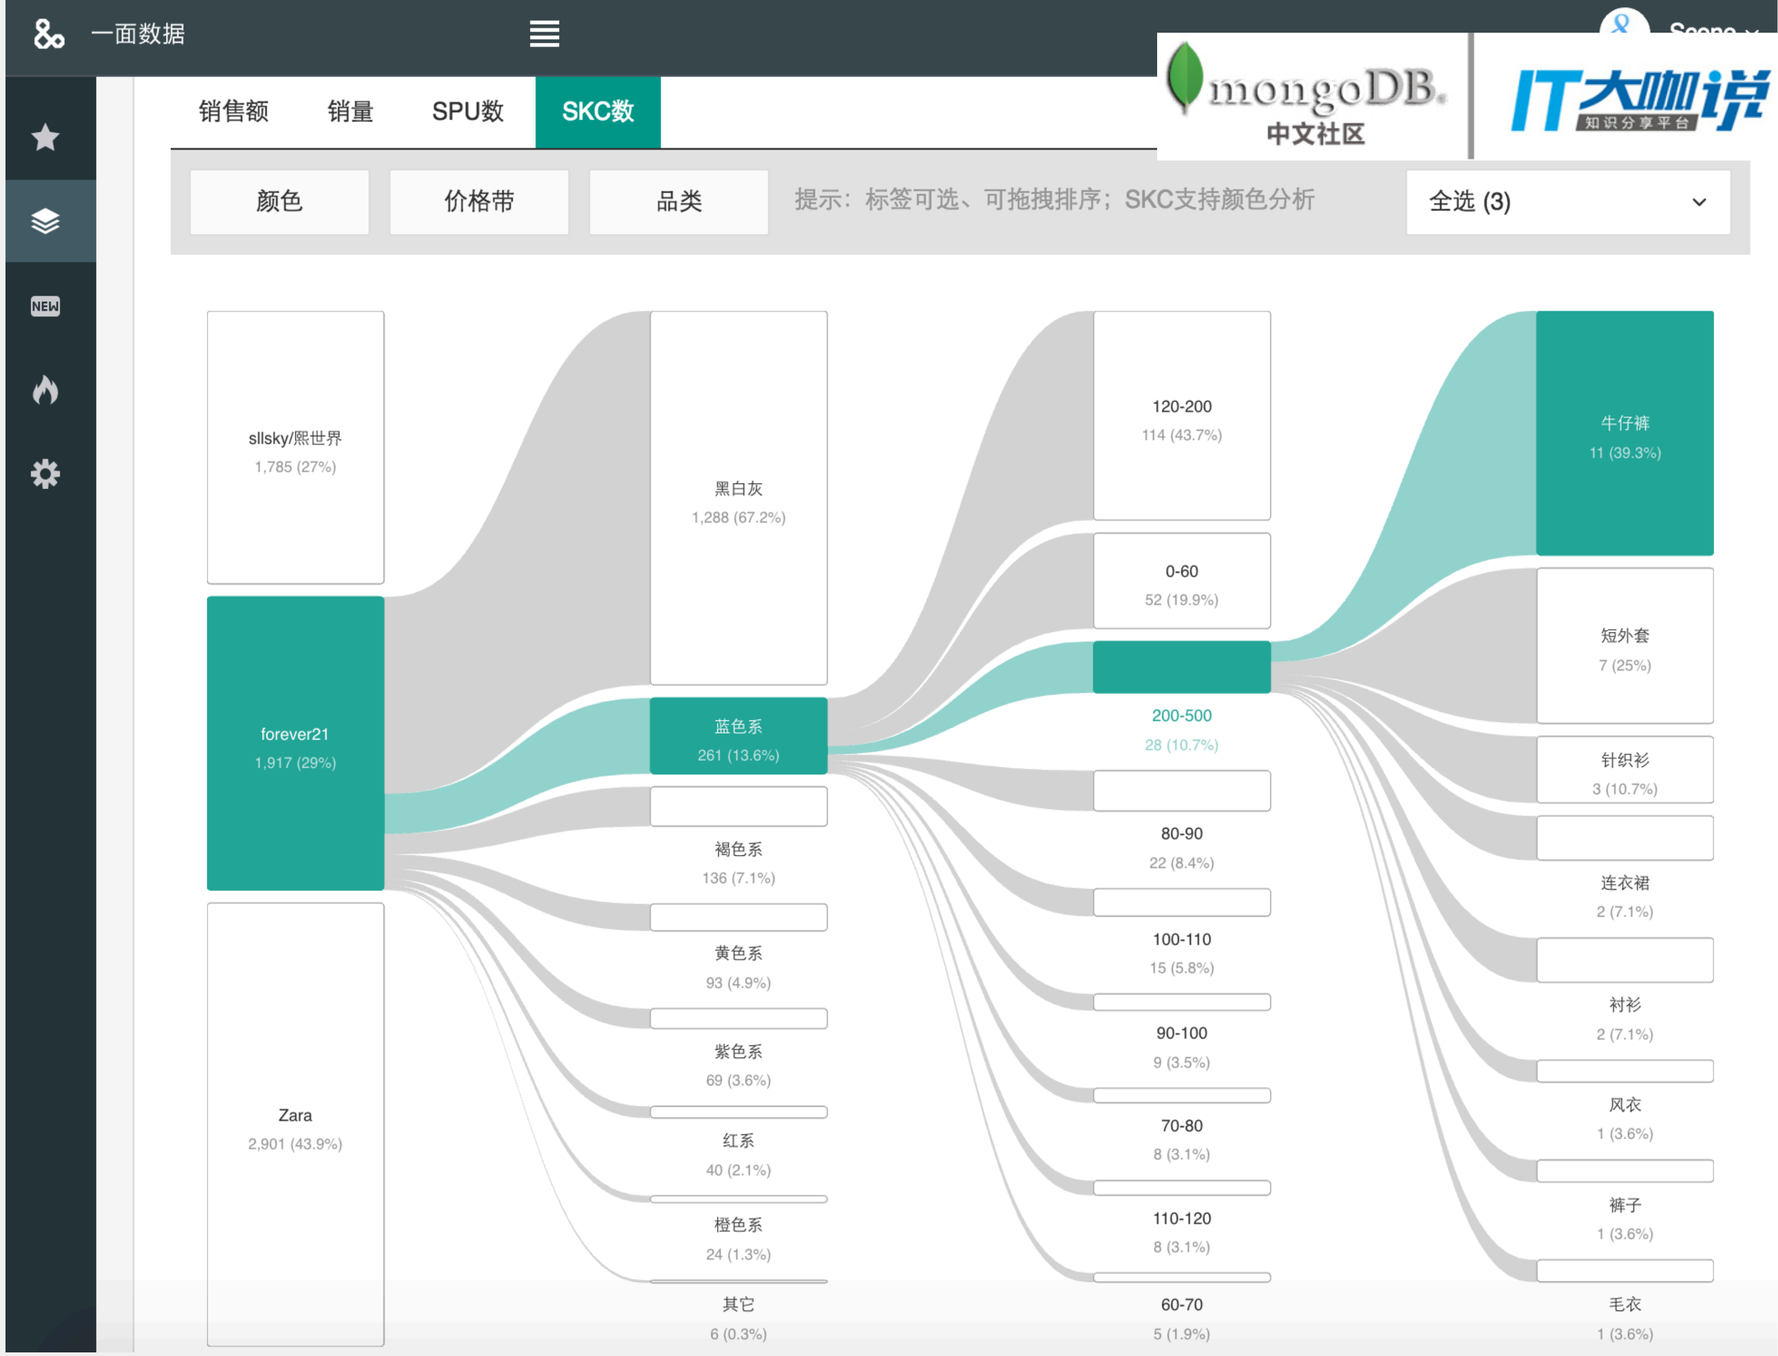

趋势监控

时尚女鞋

流行趋势

销售额/销量/SKU数

分类特征

品类

风格

跟型

跟头

开口

流行元素

颜色

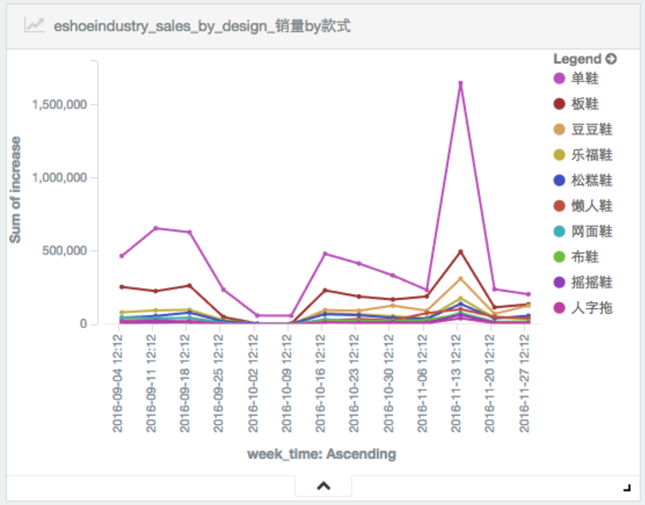

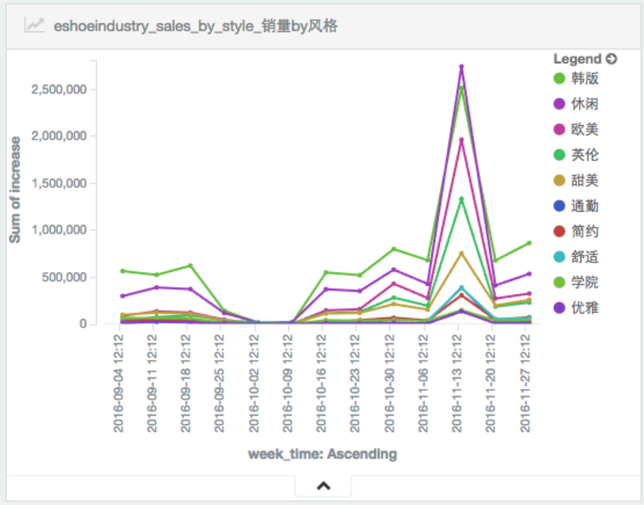

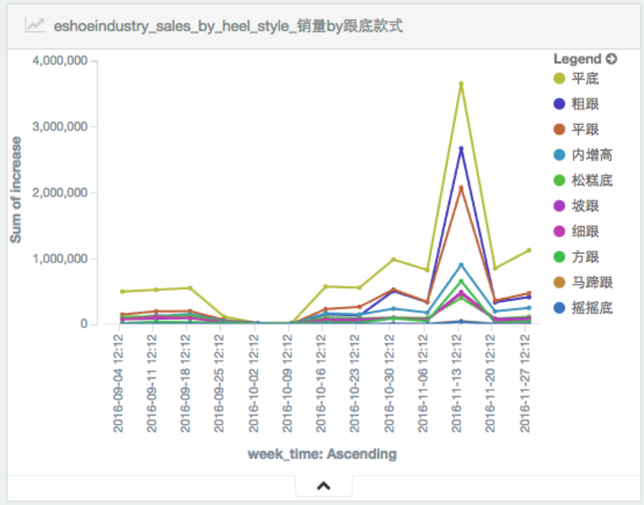

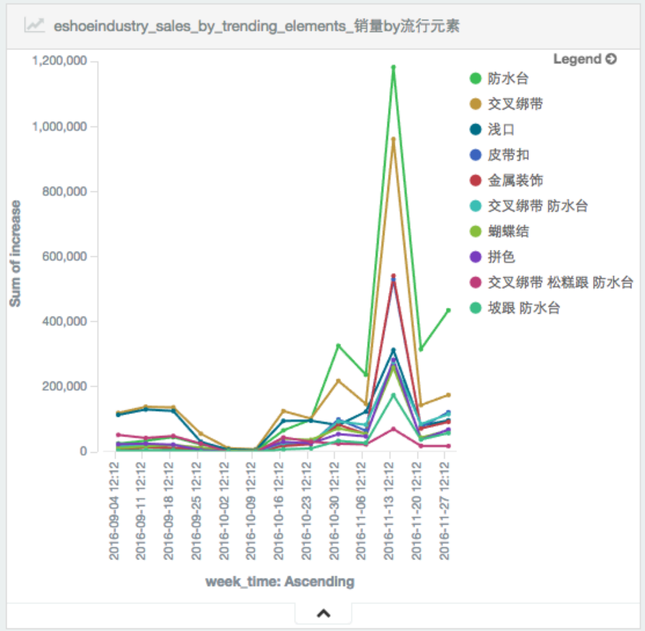

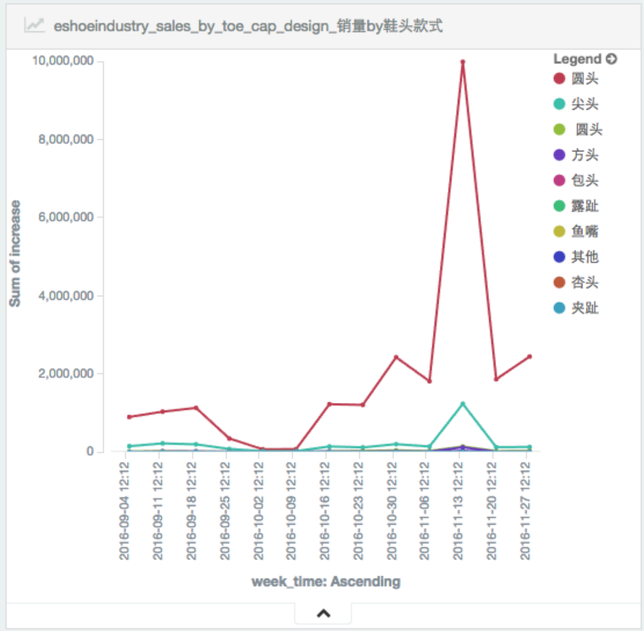

结束语

If you can't measure it,
you can't improve it.

EMAIL data@yimian.com.cn

http://yimian.com.cn

Phone +86 755 - 86503625