C2C市场中推荐系统的机遇与挑战

张相於

自我介绍

- 张相於
  - 毕业于中国人民大学
  - 转转推荐算法部负责人
  - 推荐系统、机器学习系统
  - 联系方式：zhangxy@live.com

分享提纲

- C2C市场及其特点介绍
- 挑战与应对
- 总结

分享提纲

- C2C市场及其特点介绍
- 挑战与应对
- 总结

C2C市场

- 真·个人对个人的marketplace
- C2C平台的意义
  - 物品交易
  - 技能交换
  - 发现世界

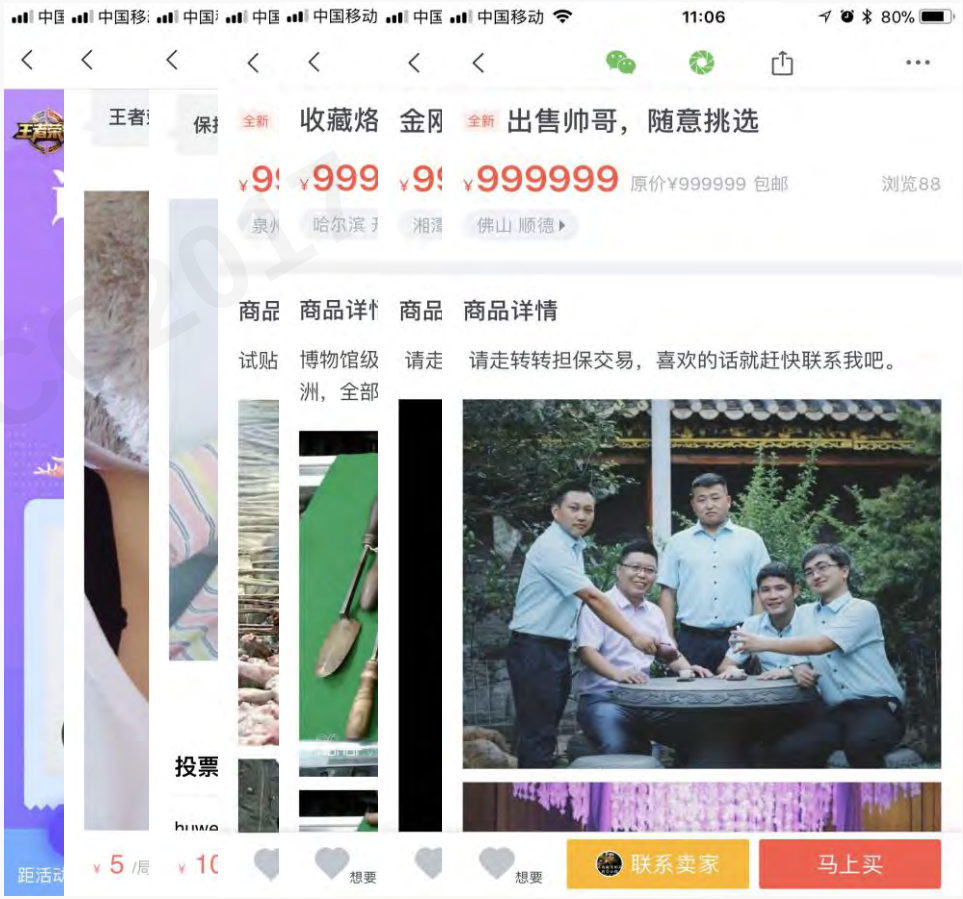

C2C市场的特点

- 信息发布随意性强
- 商品库存唯一性
- 时效敏感性

分享提纲

- C2C市场及其特点介绍
- 挑战与应对
- 总结

挑战1：数据异质性高

数据异质性的含义

- 信息发布的随意性
- 结构异质性
  - 结构信息少
  - 结构信息不确定
- 内容异质性
  - 信息量不确定
  - 用词多样化
  - 歧义多

- “iPhone7 128G 国行 无拆无修 发票齐全……”
- “iPhone6 如图”
- “卖一部iPhone6，要买iPhone7”
- ……

异质数据带来的问题

结构信息少-> 难以制定策略

信息不确定-> 策略覆盖不全

歧义多->策略准确率低

异质数据的优点

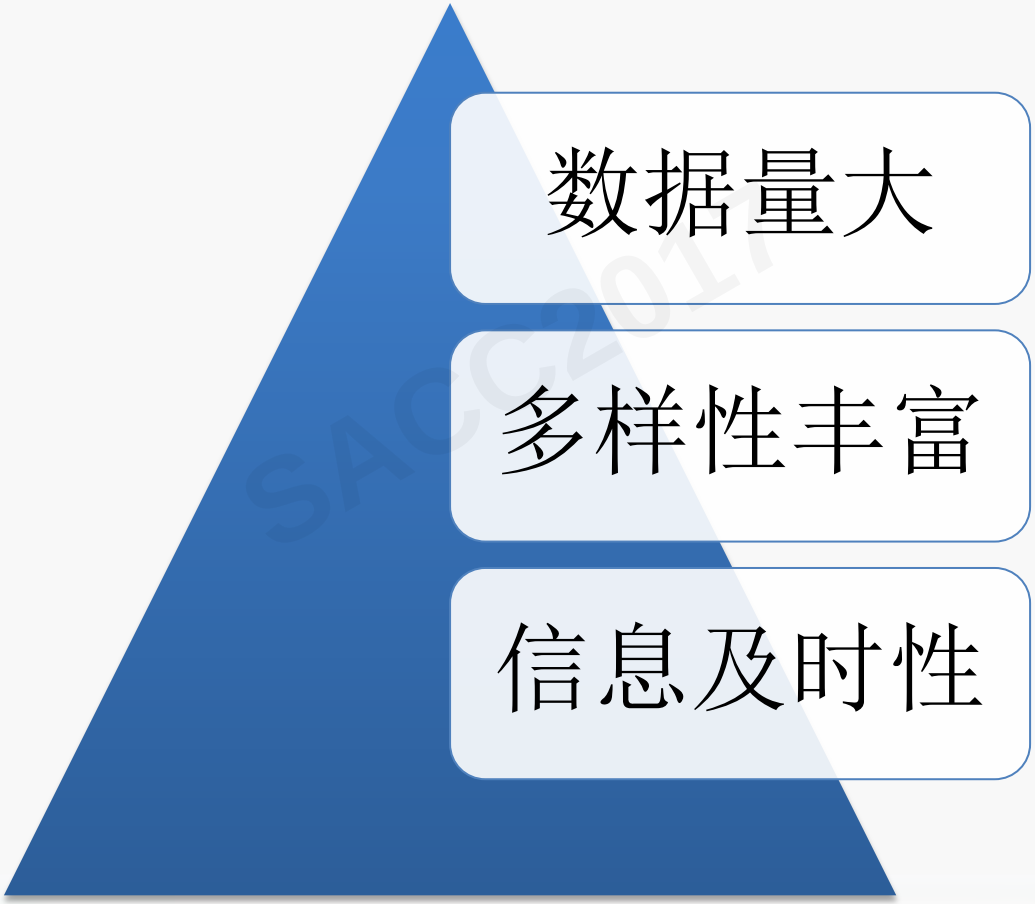

异质数据应对方案

- 将非结构化数据转为结构化数据
- 按照结构化数据方法来使用
- 优点：
  - 含义明确清晰
  - 适用范围广
- 缺点：
  - 提取难度高
  - 信息有损失

- 用NLP的方法提取非结构化信息
- 用作召回/排序特征
- 优点：
  - 成熟方法较多
  - 信息含量大
- 缺点：
  - 信息噪音多
  - 可解释性较弱

数据结构化策略

数据结构化-例子

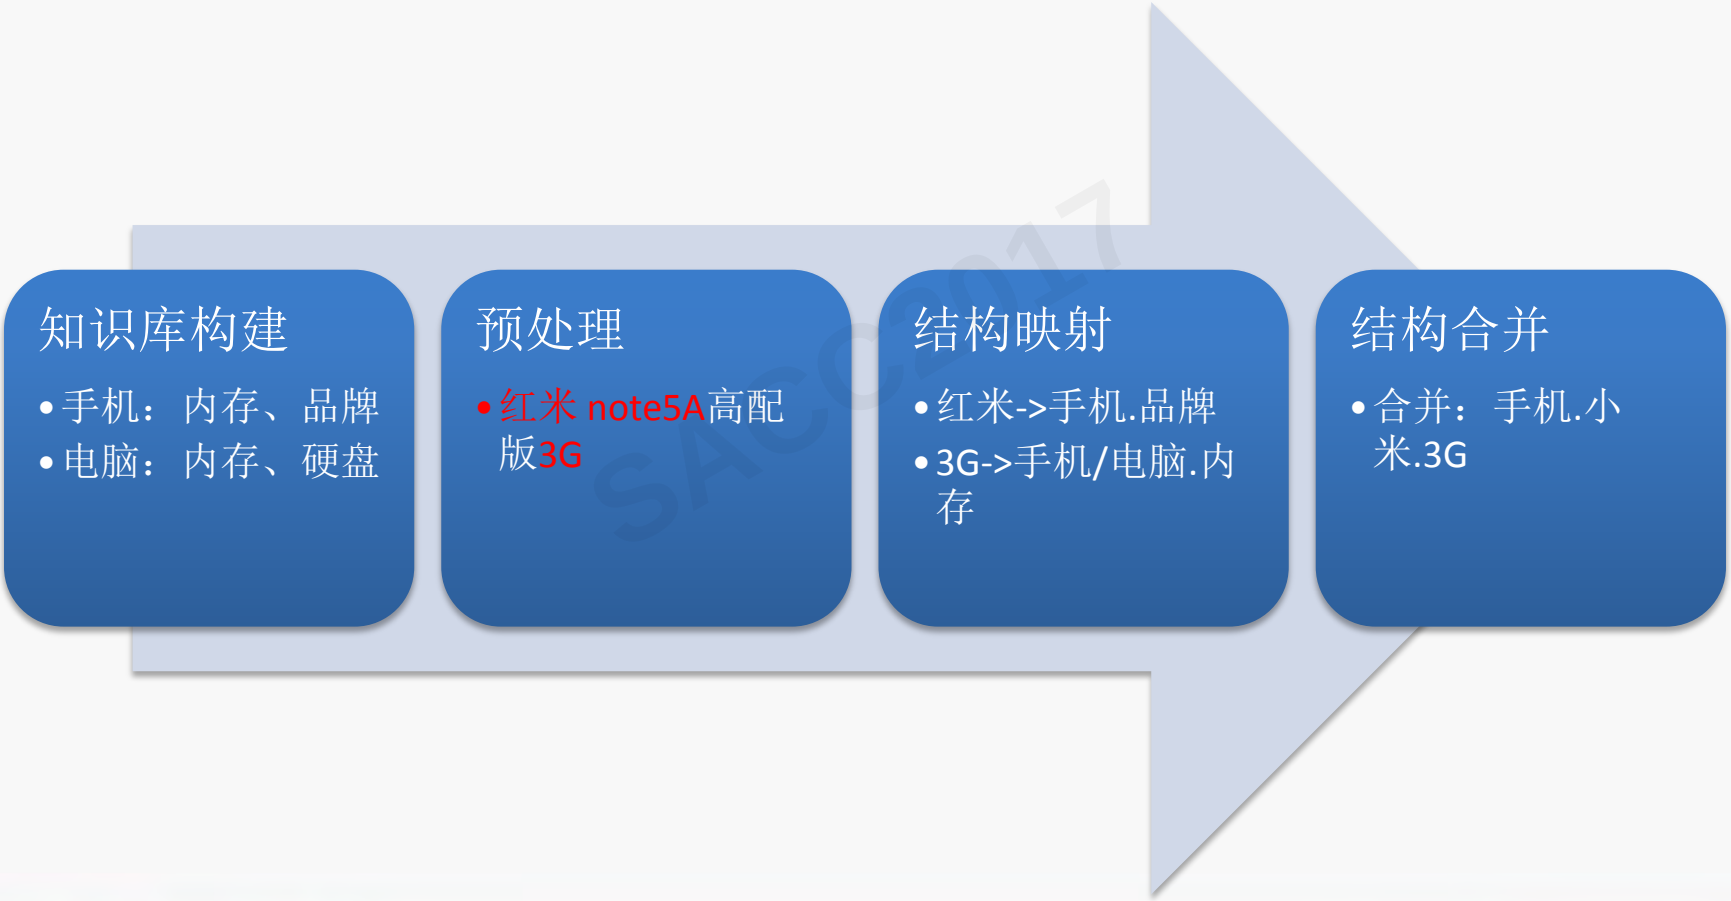

非结构化数据处理

词袋模型

- 适用面广、召回率高、噪音多

文本主题模型（LDA、pLSA）

- 抽象度高、用法多样、实时性能

嵌入表示模型（xxx2vec）

- 局部敏感、连续空间、时序敏感

《自然语言处理技术在推荐系统中的应用》
http://geek.csdn.net/news/detail/208281

挑战2：时效敏感性

时效敏感性的含义

通用时效性

- 对用户的行为作出实时反馈

卖家维度

- 希望自己发布的商品尽快得到注意

买家维度

- 倾向于与新发布的商品进行交互

时效敏感性的挑战

- Vanilla CF算法无时效性概念
- 新发布商品行为数据稀疏
- 用户/商品画像离线、分散生成
- 格式、逻辑不统一，实时化难度大

时效性应对方案：CF侧

- CF召回策略实时化
  - 基于实时行为召回CF相关商品
- CF算法时效性优化
  - 使用时效性更强的数据
  - 鼓励行为时间间隔短的行为
  - 使用nearline方式计算近实时增量Cf数据

时效性应对方案：画像侧

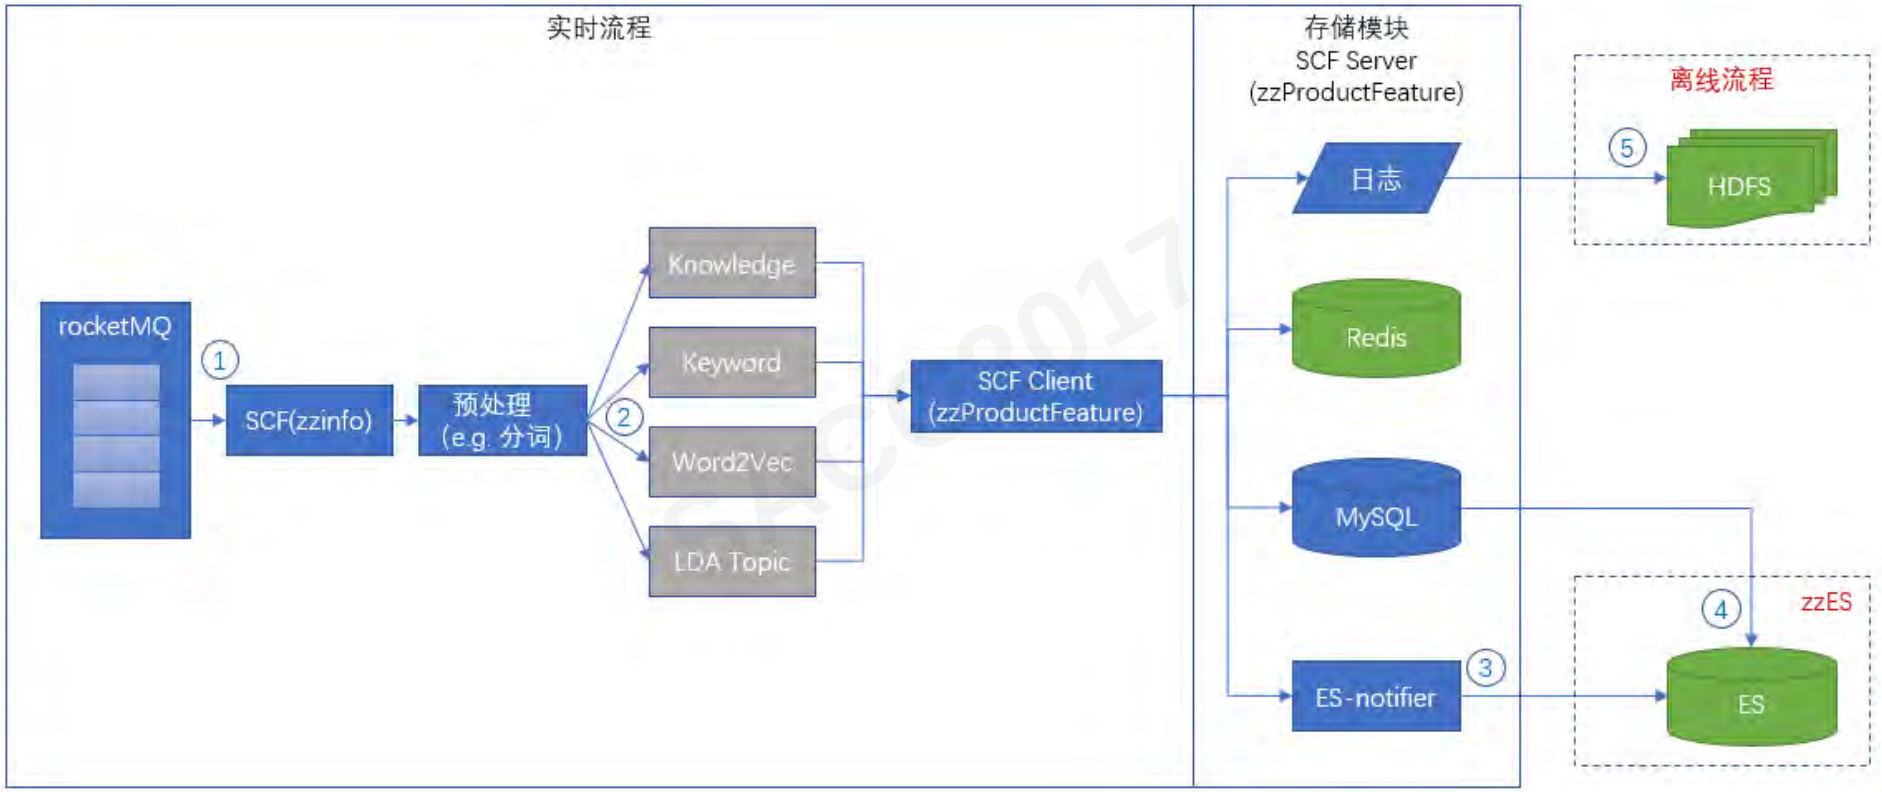
实时流程
存储模块
SCF Server
(zzProductFeature)
离线流程
rocketMQ
1
SCF(zzinfo)
预处理
(e.g. 分词)
2
Knowledge
Keyword
Word2Vec
LDA Topic
SCF Client
(zzProductFeature)
日志
Redis
MySQL
ES-notifier
3
5
HDFS
4
zzES
ES

时效性应对方案：综合

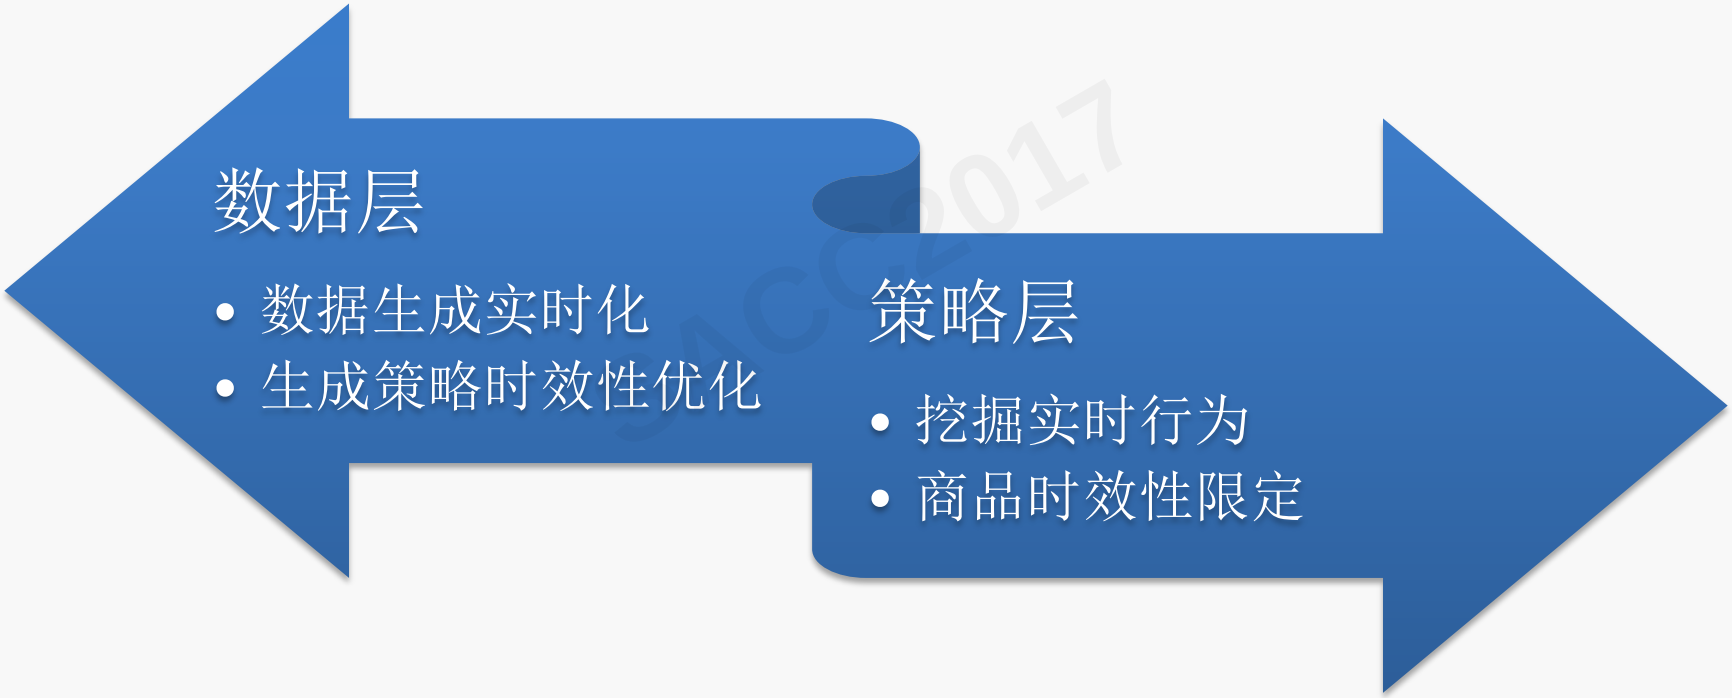

挑战3：复杂策略下的性能压力

复杂策略

相关性召回		
CF策略×6	用户画像策略×6	托底策略.....

↓

模型排序		
特征查找×2	模型预测×2	日志记录.....

↓

业务规则		
商品过滤	业务降权	信息拼接.....

性能压力

召回

- 外部存储、网络交互
- 策略设计、多步交互

排序

- 特征运算、特征查找
- 模型预测、日志记录

业务

- 属性过滤、规则降权
- 信息拼接、其他需求

Pull-based架构特点

- 中心思想
  - 所有操作均在用户请求发生时实时进行
- 优点
  - 时效性、新鲜度
- 缺点
  - 性能压力大
  - 扩展难度高

Pull-based架构示意

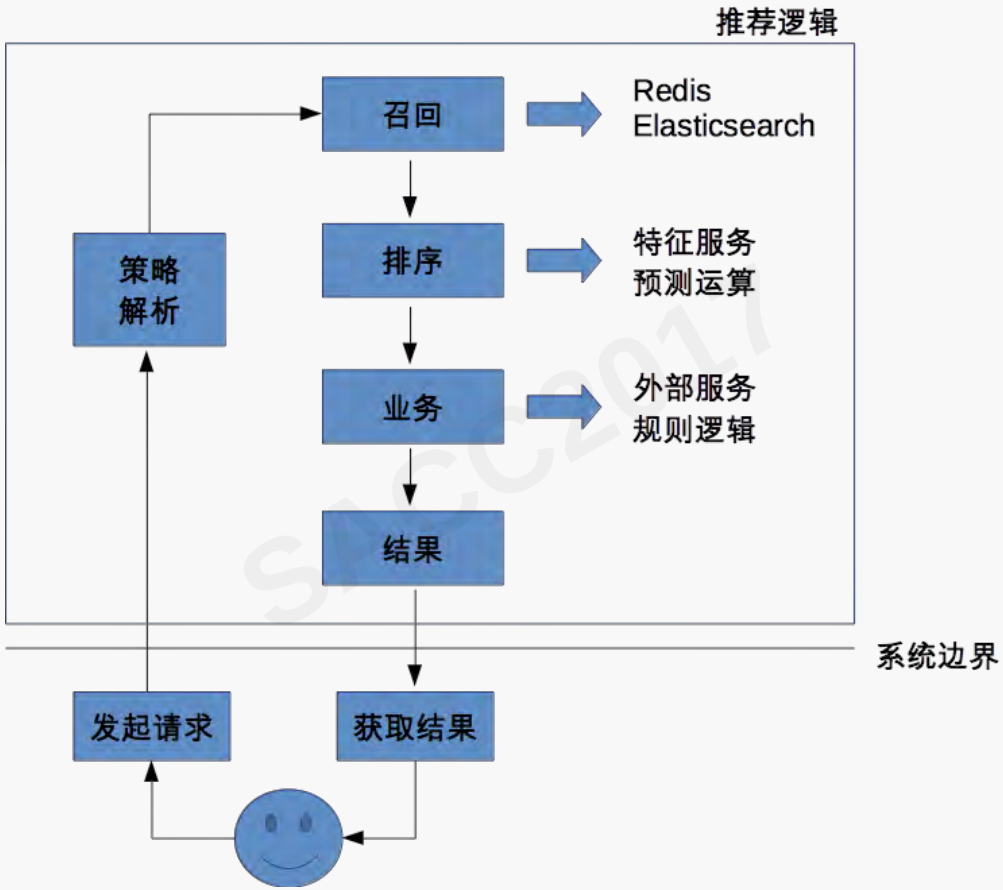

思考：实时计算的必要性

- 是否每个步骤都必须实时计算？
  - 离线相关策略每天计算一次即可
  - 实时相关策略可提前进行计算
- 还有哪些可行的计算触发时机？
  - 离线：凌晨计算、定期更新
  - 在线：行为发生时计算
- 牺牲的时效性/新鲜度如何弥补？
  - 缓存过期
  - 定时更新

新方案：推拉结合

- 最终目标
  - 将逻辑计算与请求处理尽量分离
  - 赋予系统更强的计算能力
- 推
  - 多维度触发时机主动推送数据变更
- 拉
  - 请求到来时直接获取计算好的数据
- 细节
  - 缓存过期、活跃度预测.....

推拉结合方案架构示意

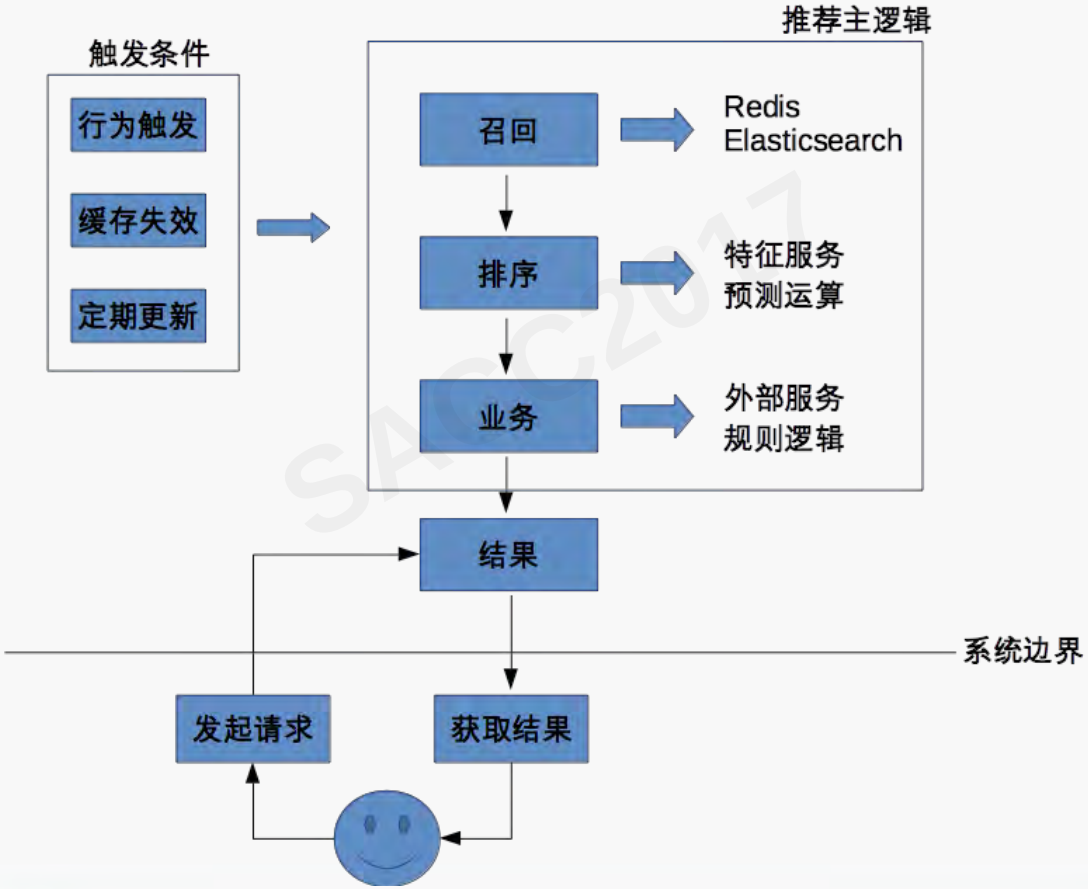

推拉结合优缺点分析

优点

- 计算分离，性能提升
- 近线计算，算能扩容

缺点

- 设计复杂，细节繁多
- 新鲜度缺乏足够保证

分享提纲

- C2C市场及其特点介绍
- 挑战与应对
- 总结

总结

挑战1：用户发布的数据异质性

挑战2：买卖双方的时效敏感性

挑战3：复杂策略下的性能压力


THANKS
zhangxy@live.com