

ES的垂直搜索平台架构思考

吴英昊 丰坚



垂直搜索平台架构

- **Elasticsearch与垂直搜索平台**
- **离线索引和实时索引**
- **query分析**
- **打分和排序**
- **其他问题**
- **总结**



Elasticsearch和垂直搜索平台



垂直搜索

- 电商类搜索引擎
- 旅游类搜索引擎
- 文档类搜索引擎



垂直搜索特点

- 一般没有爬虫系统
- 数据比较结构化
- 支持各种维度的排序
- 数据实时性要求非常高
- 与推荐系统和广告系统的融合

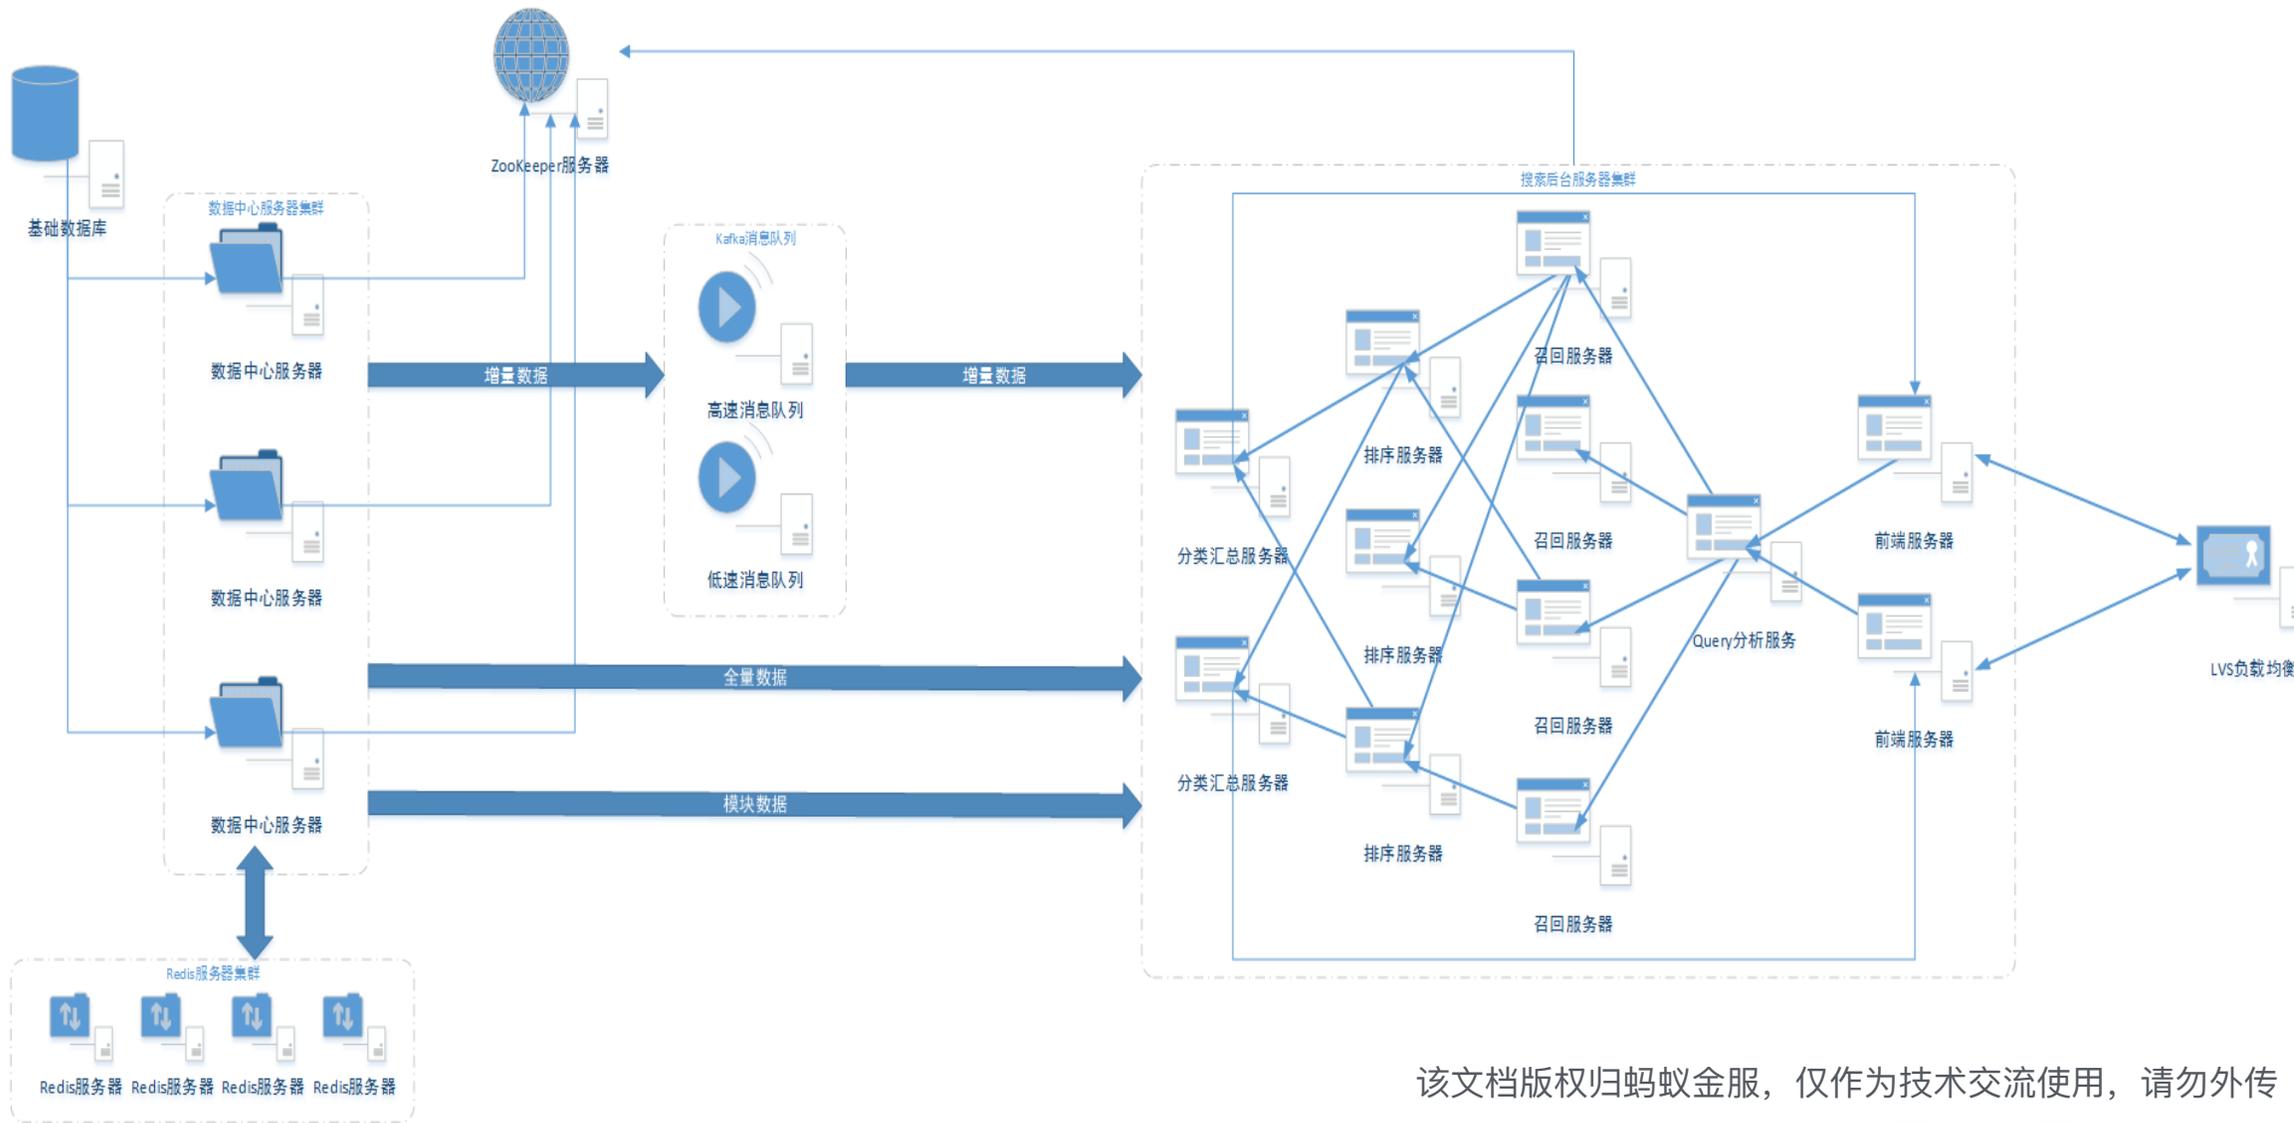


垂直搜索引擎模块

- 索引器 (Elasticsearch)
- 检索器 (Elasticsearch)
- query分析 (plugin)
- 离线打分排序
- 在线打分排序 (plugin)
- 商业因素排序 (plugin)
- 人工干预 (plugin)

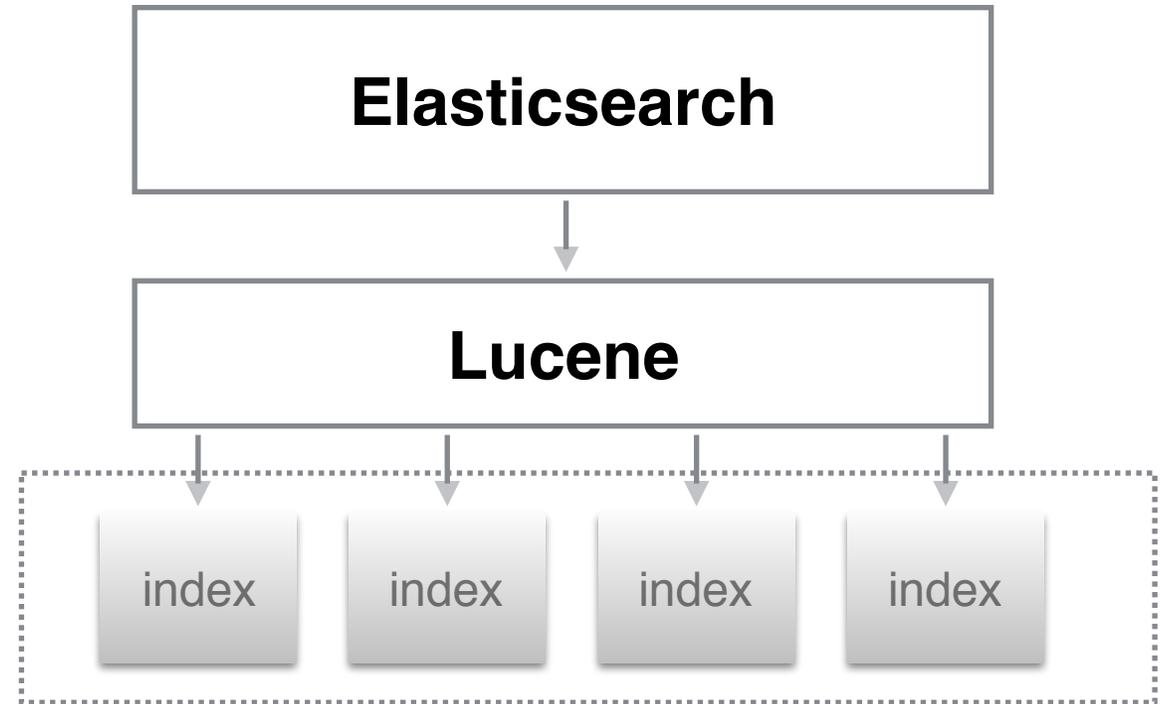


复杂的搜索平台



Elasticsearch

- 集成度高
- 部署简单
- 功能完整且强大
- 伸缩性和可靠性高
- 功能扩展能力强
- Lucene性能全面



围绕Elasticsearch进行扩展和改造

离线索引和实时索引

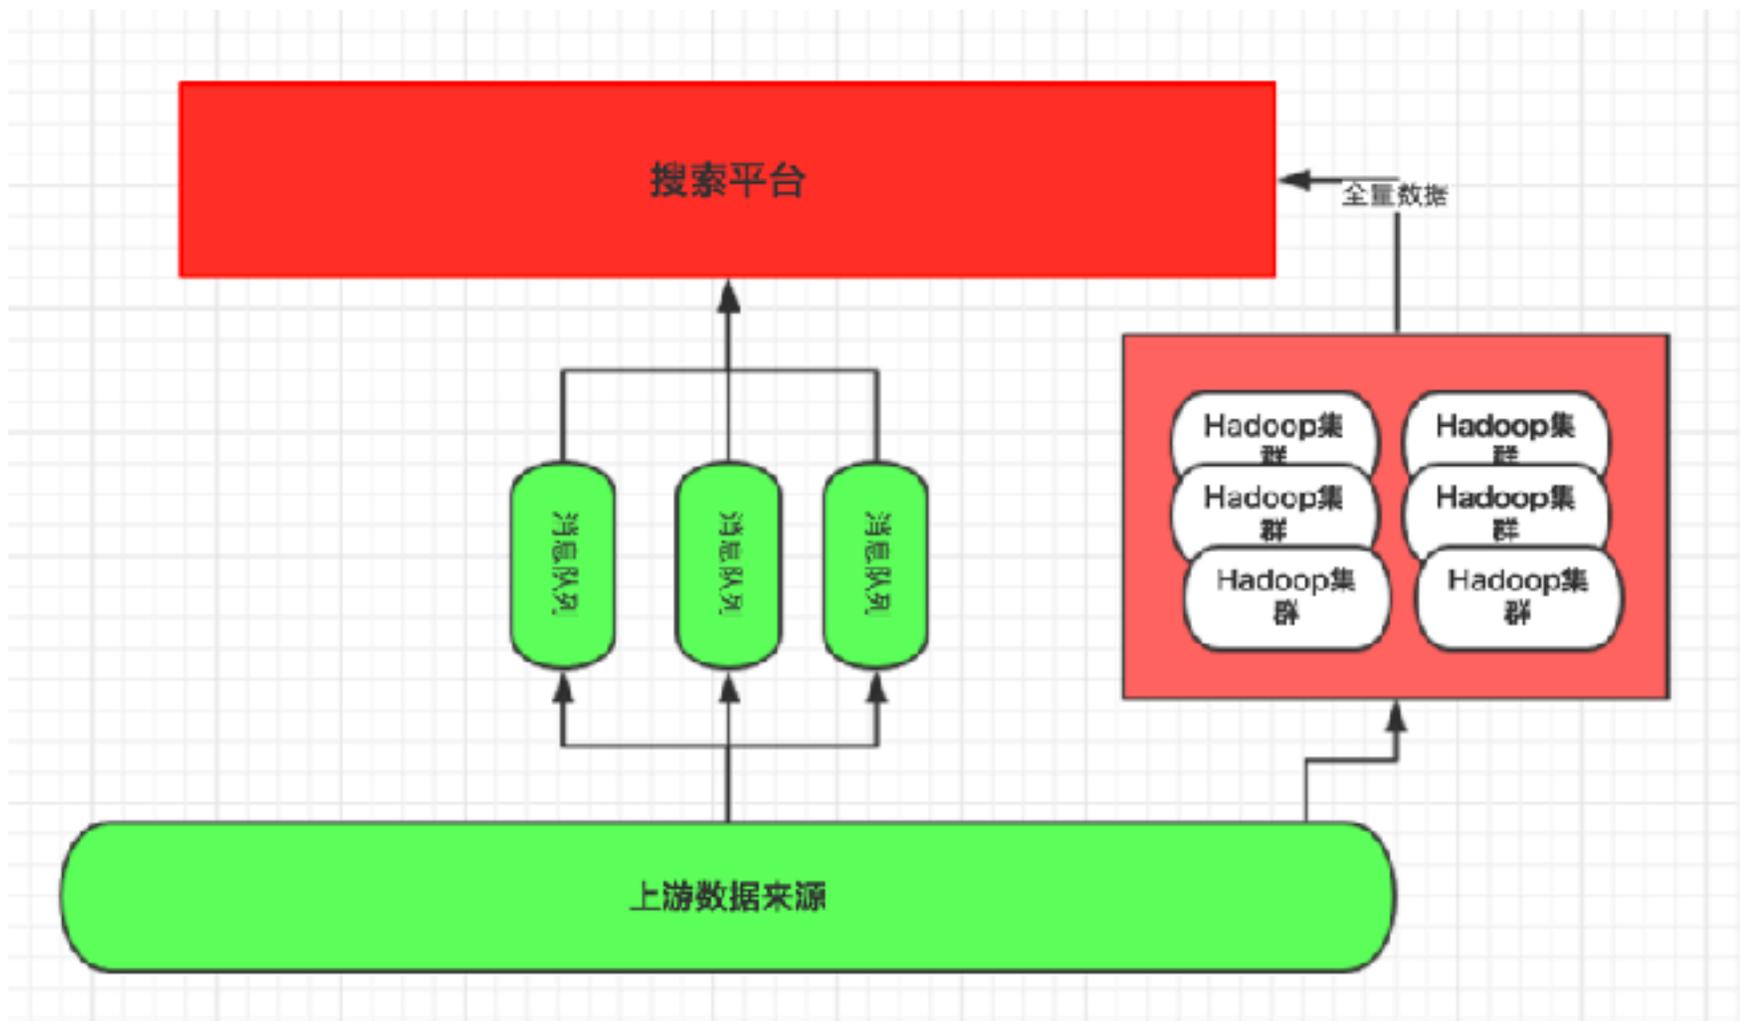


离线索引和计算

- 必不可少的离线索引部分
- 精确的离线打分
- 精确的文本打分模型
- 减轻在线计算压力
- 个性化推荐标签

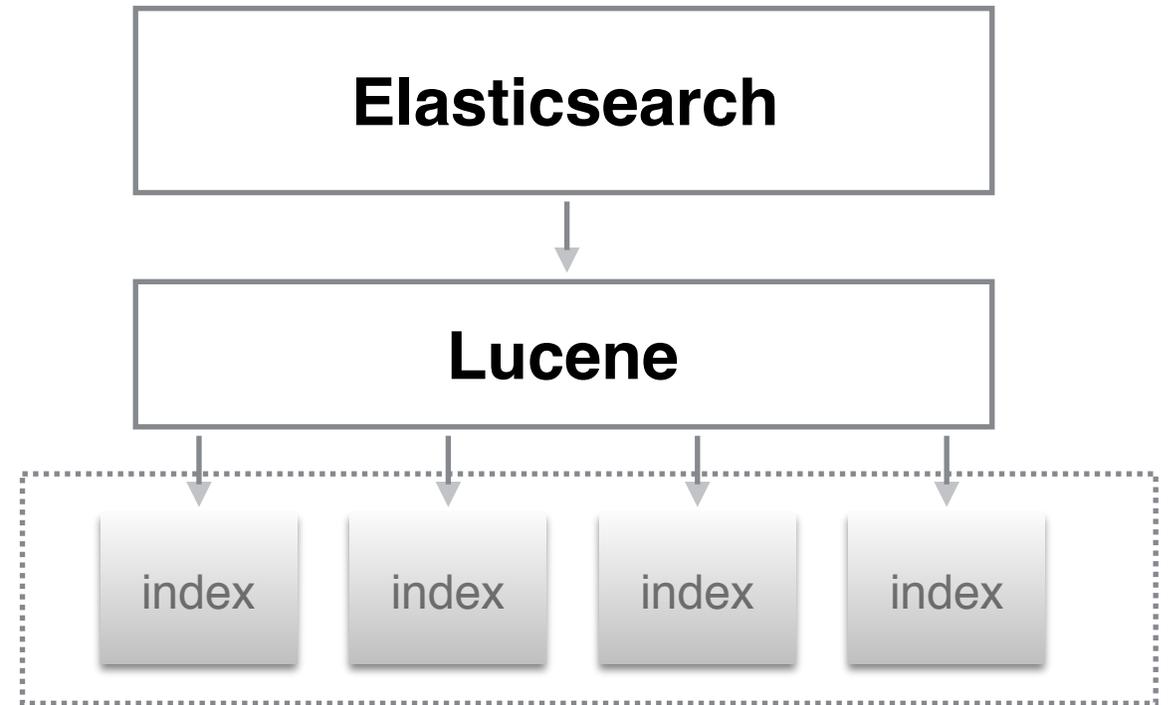


离线索引和计算

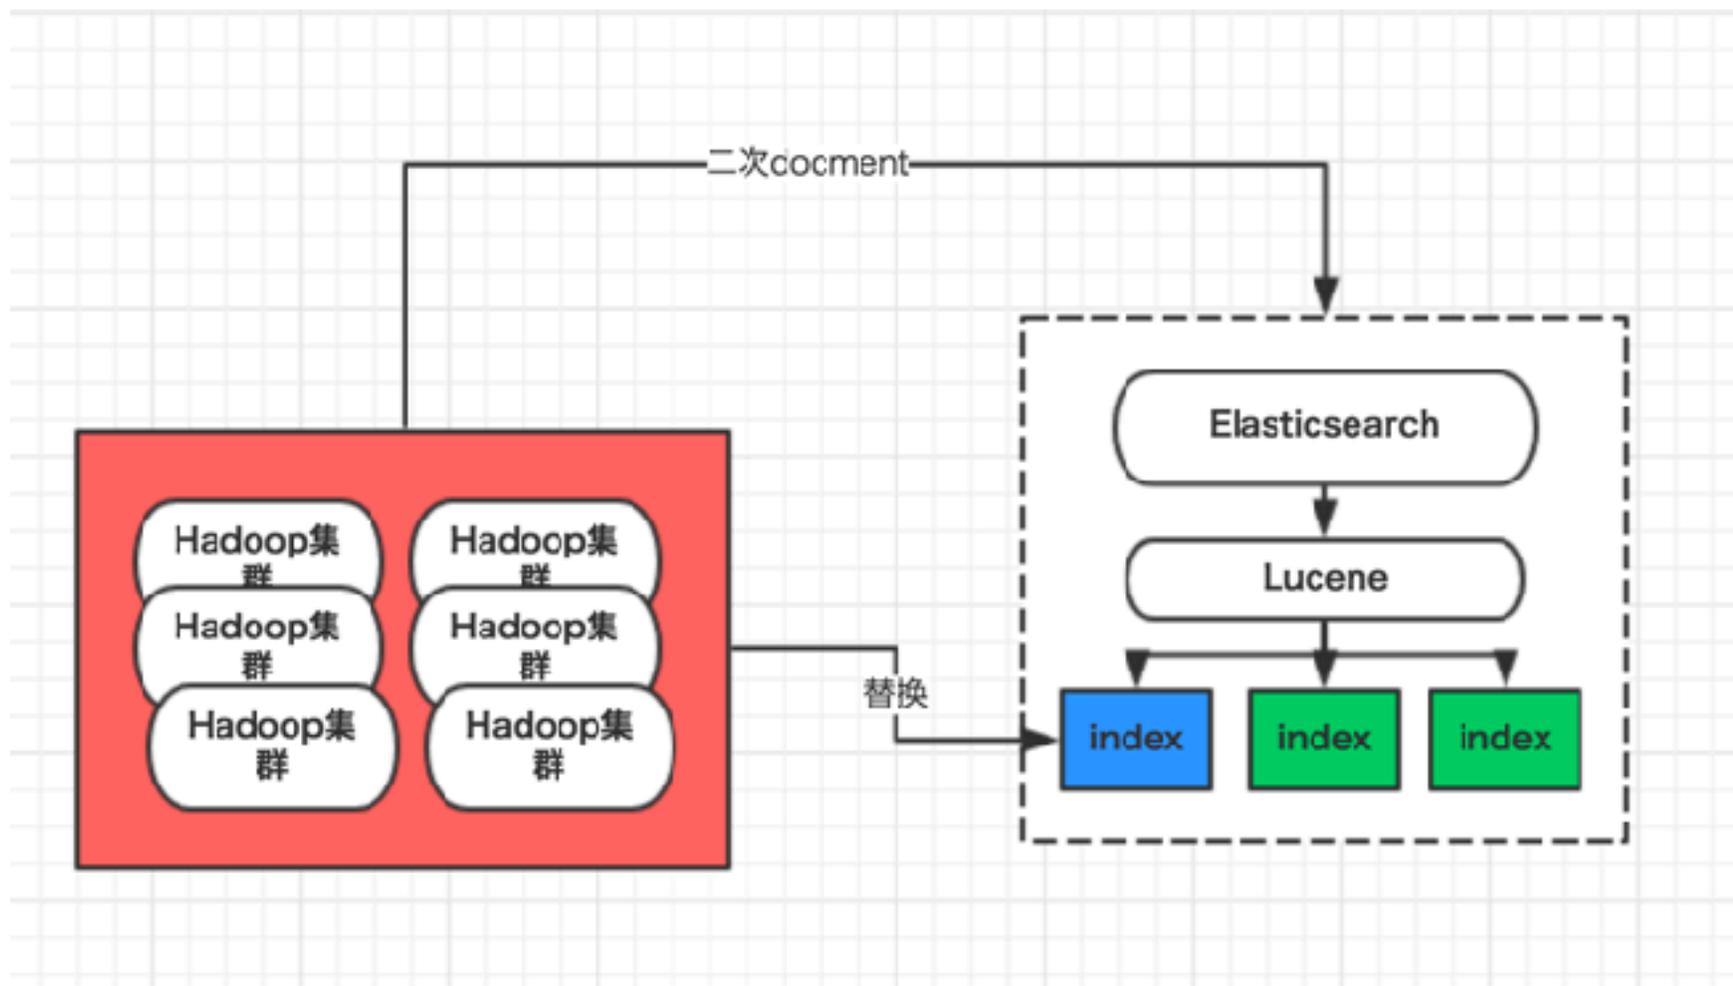


ES离线索引和计算

- 彻底的索引构建
 - 最直接
 - 问题太多
- 折中生成二次document
 - 较简单
 - 控制度小
- 分词器问题
- 分片问题等等

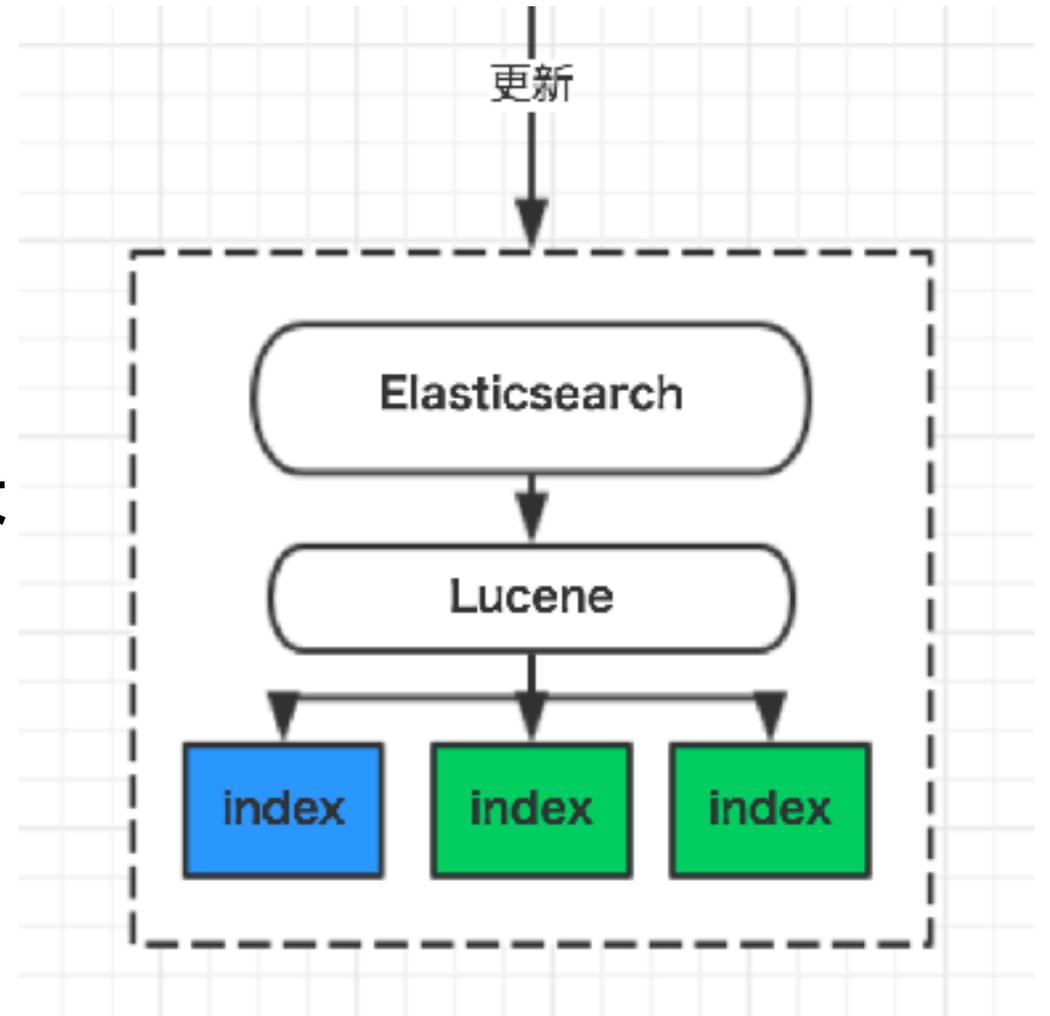


ES离线索引和计算



实时更新文档

- 合并 -> 删除 -> 重建
- 解决频繁，大量局部更新的场景
- doc value?



Query分析模块

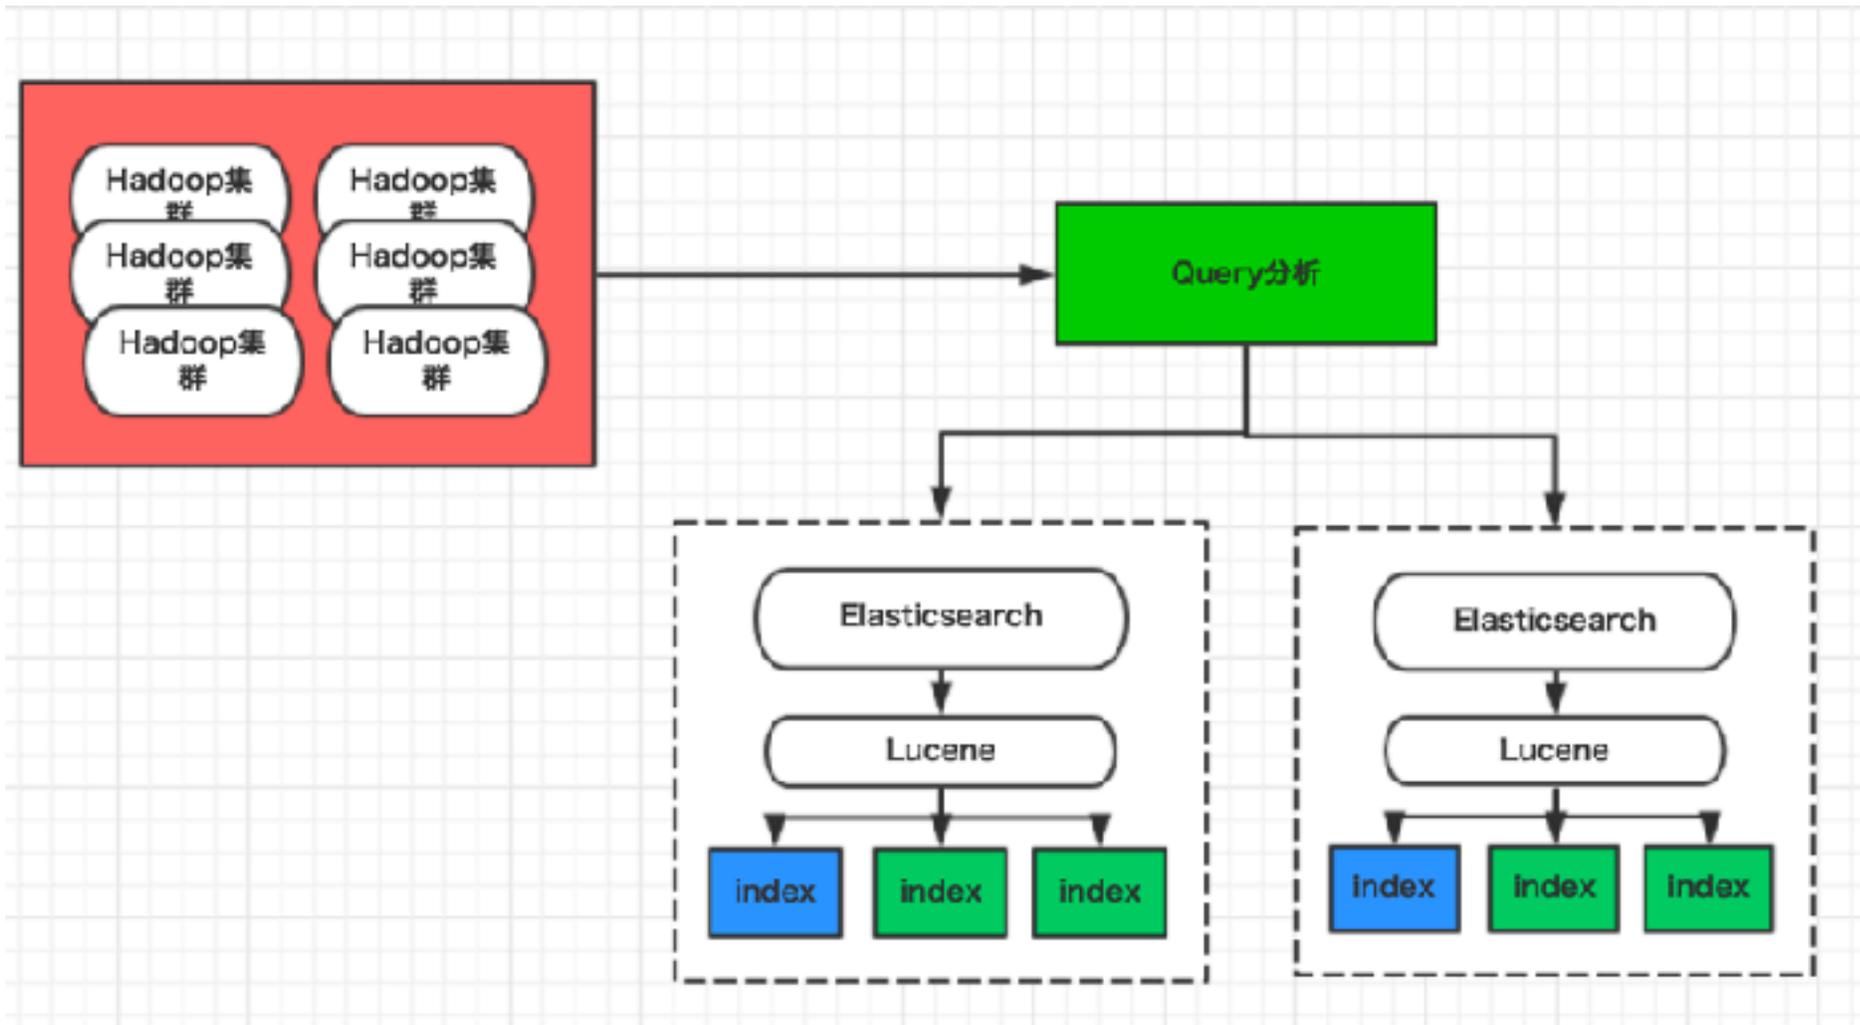


Query分析

- 搜索质量的保证
- 大量离线训练数据
- 分类，语义识别
- 对应多业务多集群
- 插件？ 独立服务？



Query分析



打分和排序



离线打分和在线排序

离线计算

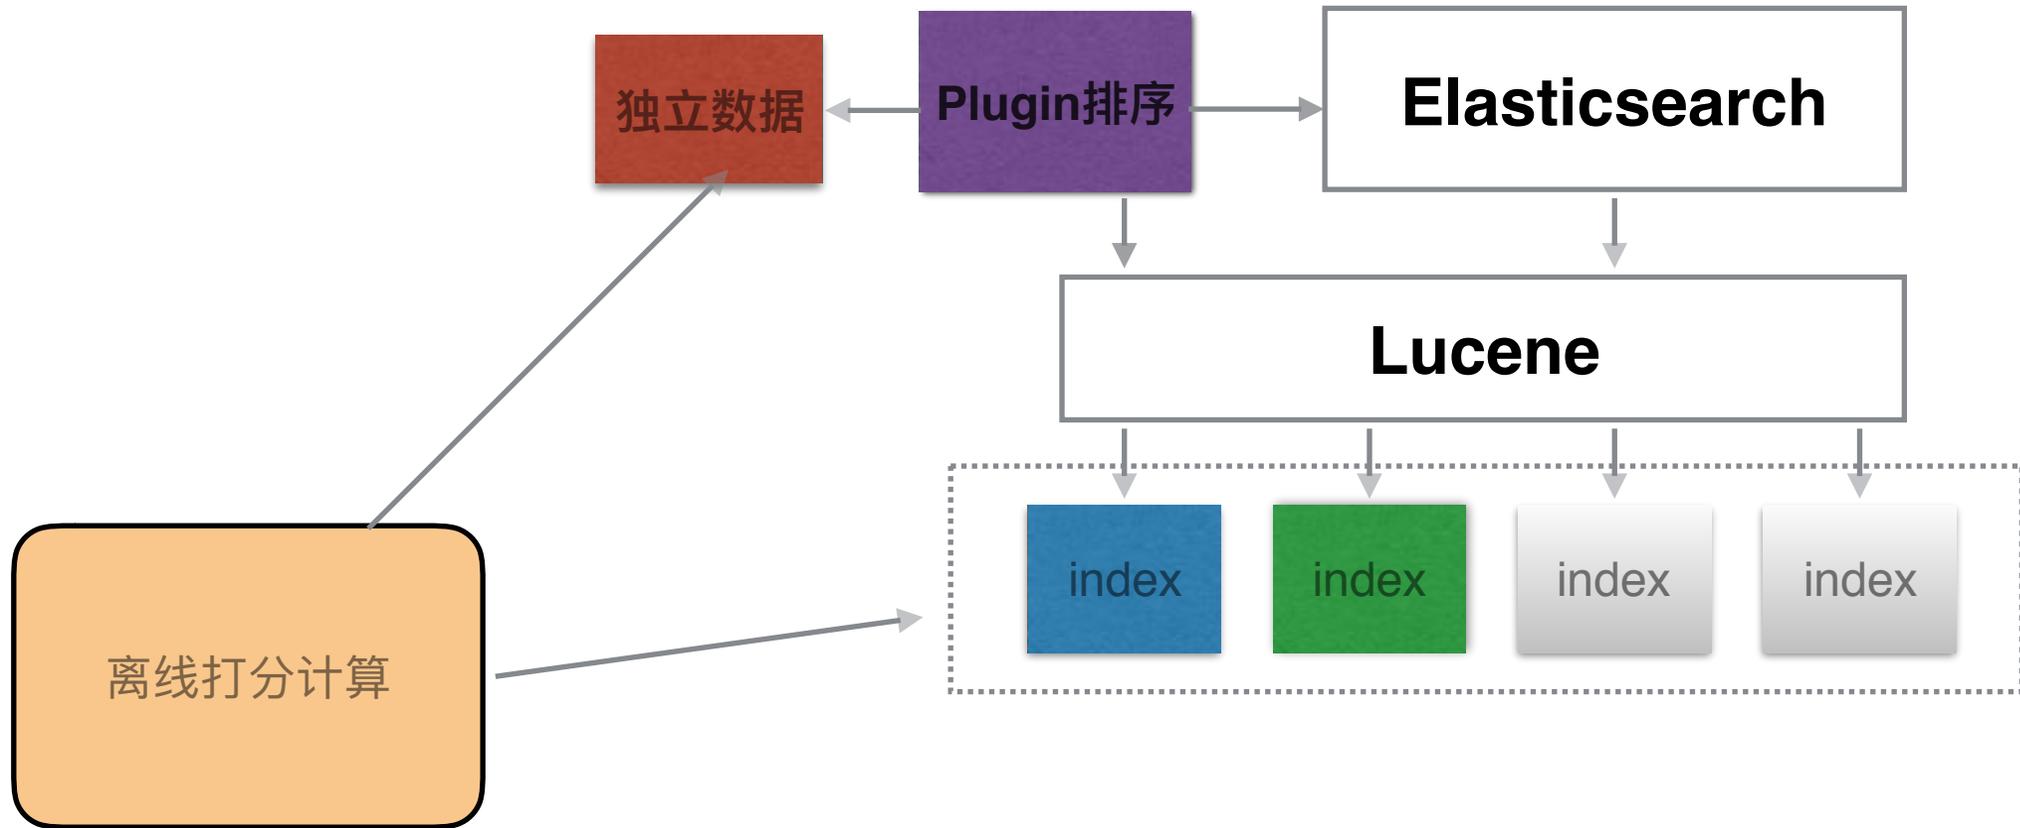
- 文本打分，辅助索引
- 生成辅助索引
- 权重计算
- 机器学习

在线排序

- 插件实现
- 脚本实现
- 辅助索引
- 独立数据
- 必须集成



离线和在线排序



商业因素排序

- 快速响应
- 随时调整
- 开发周期短，随时需要AB
- 与架构无关



ES打分排序

- 插件和脚本完美契合
- 辅助索引
- ES的模块化和插件化设计
- 对开发人员友好

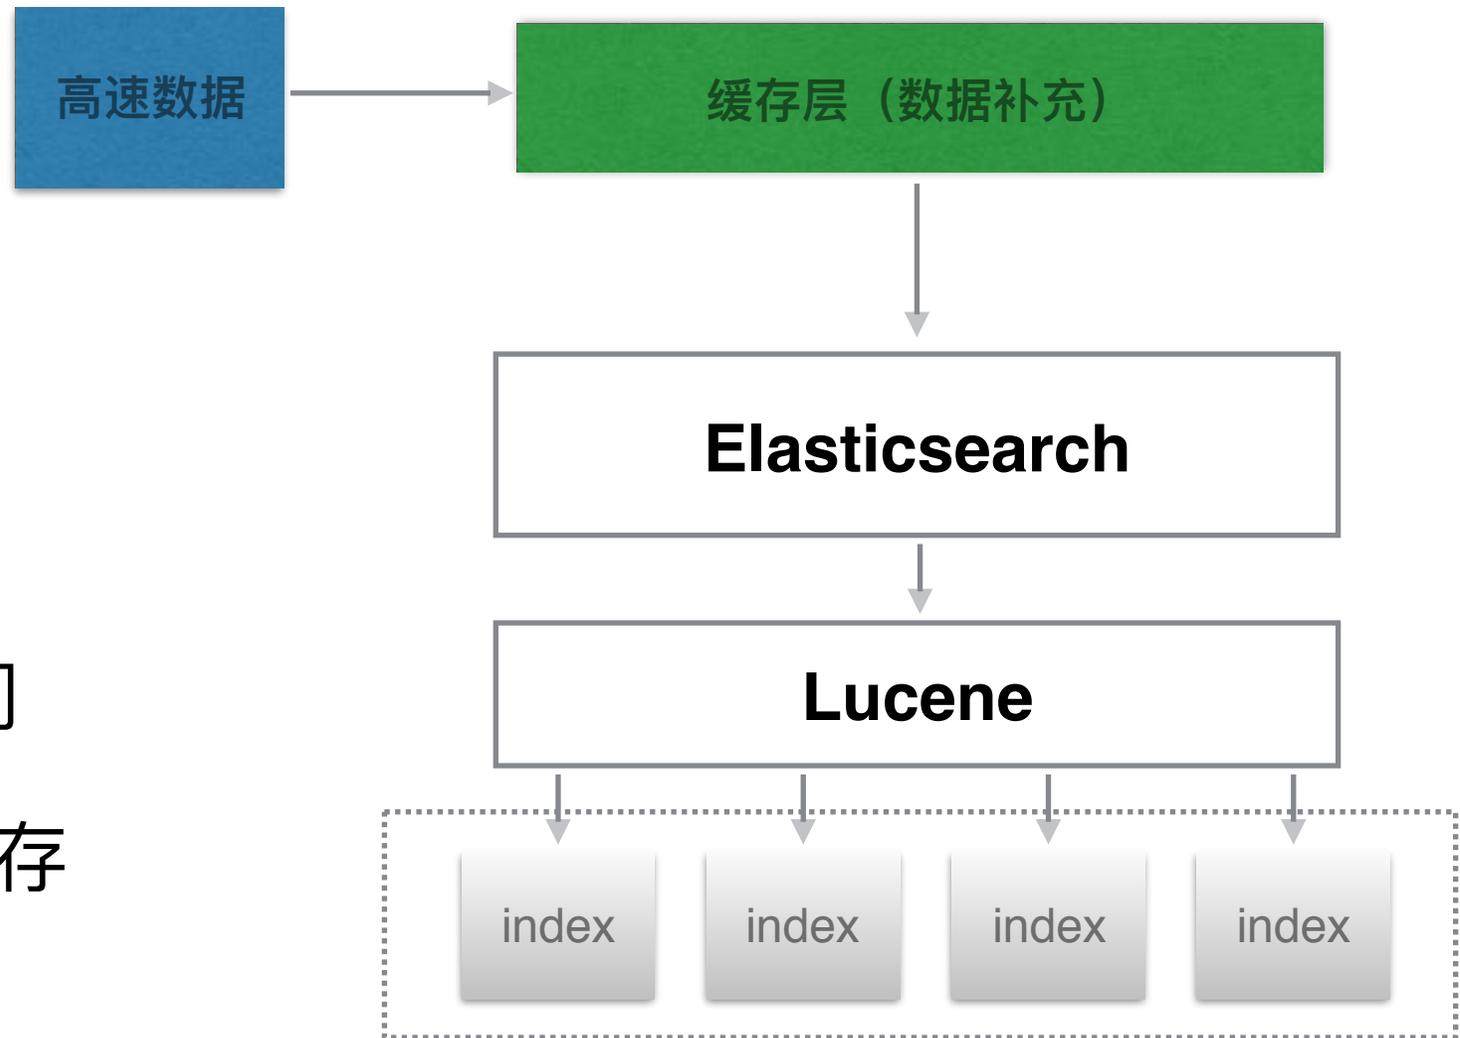


其他问题



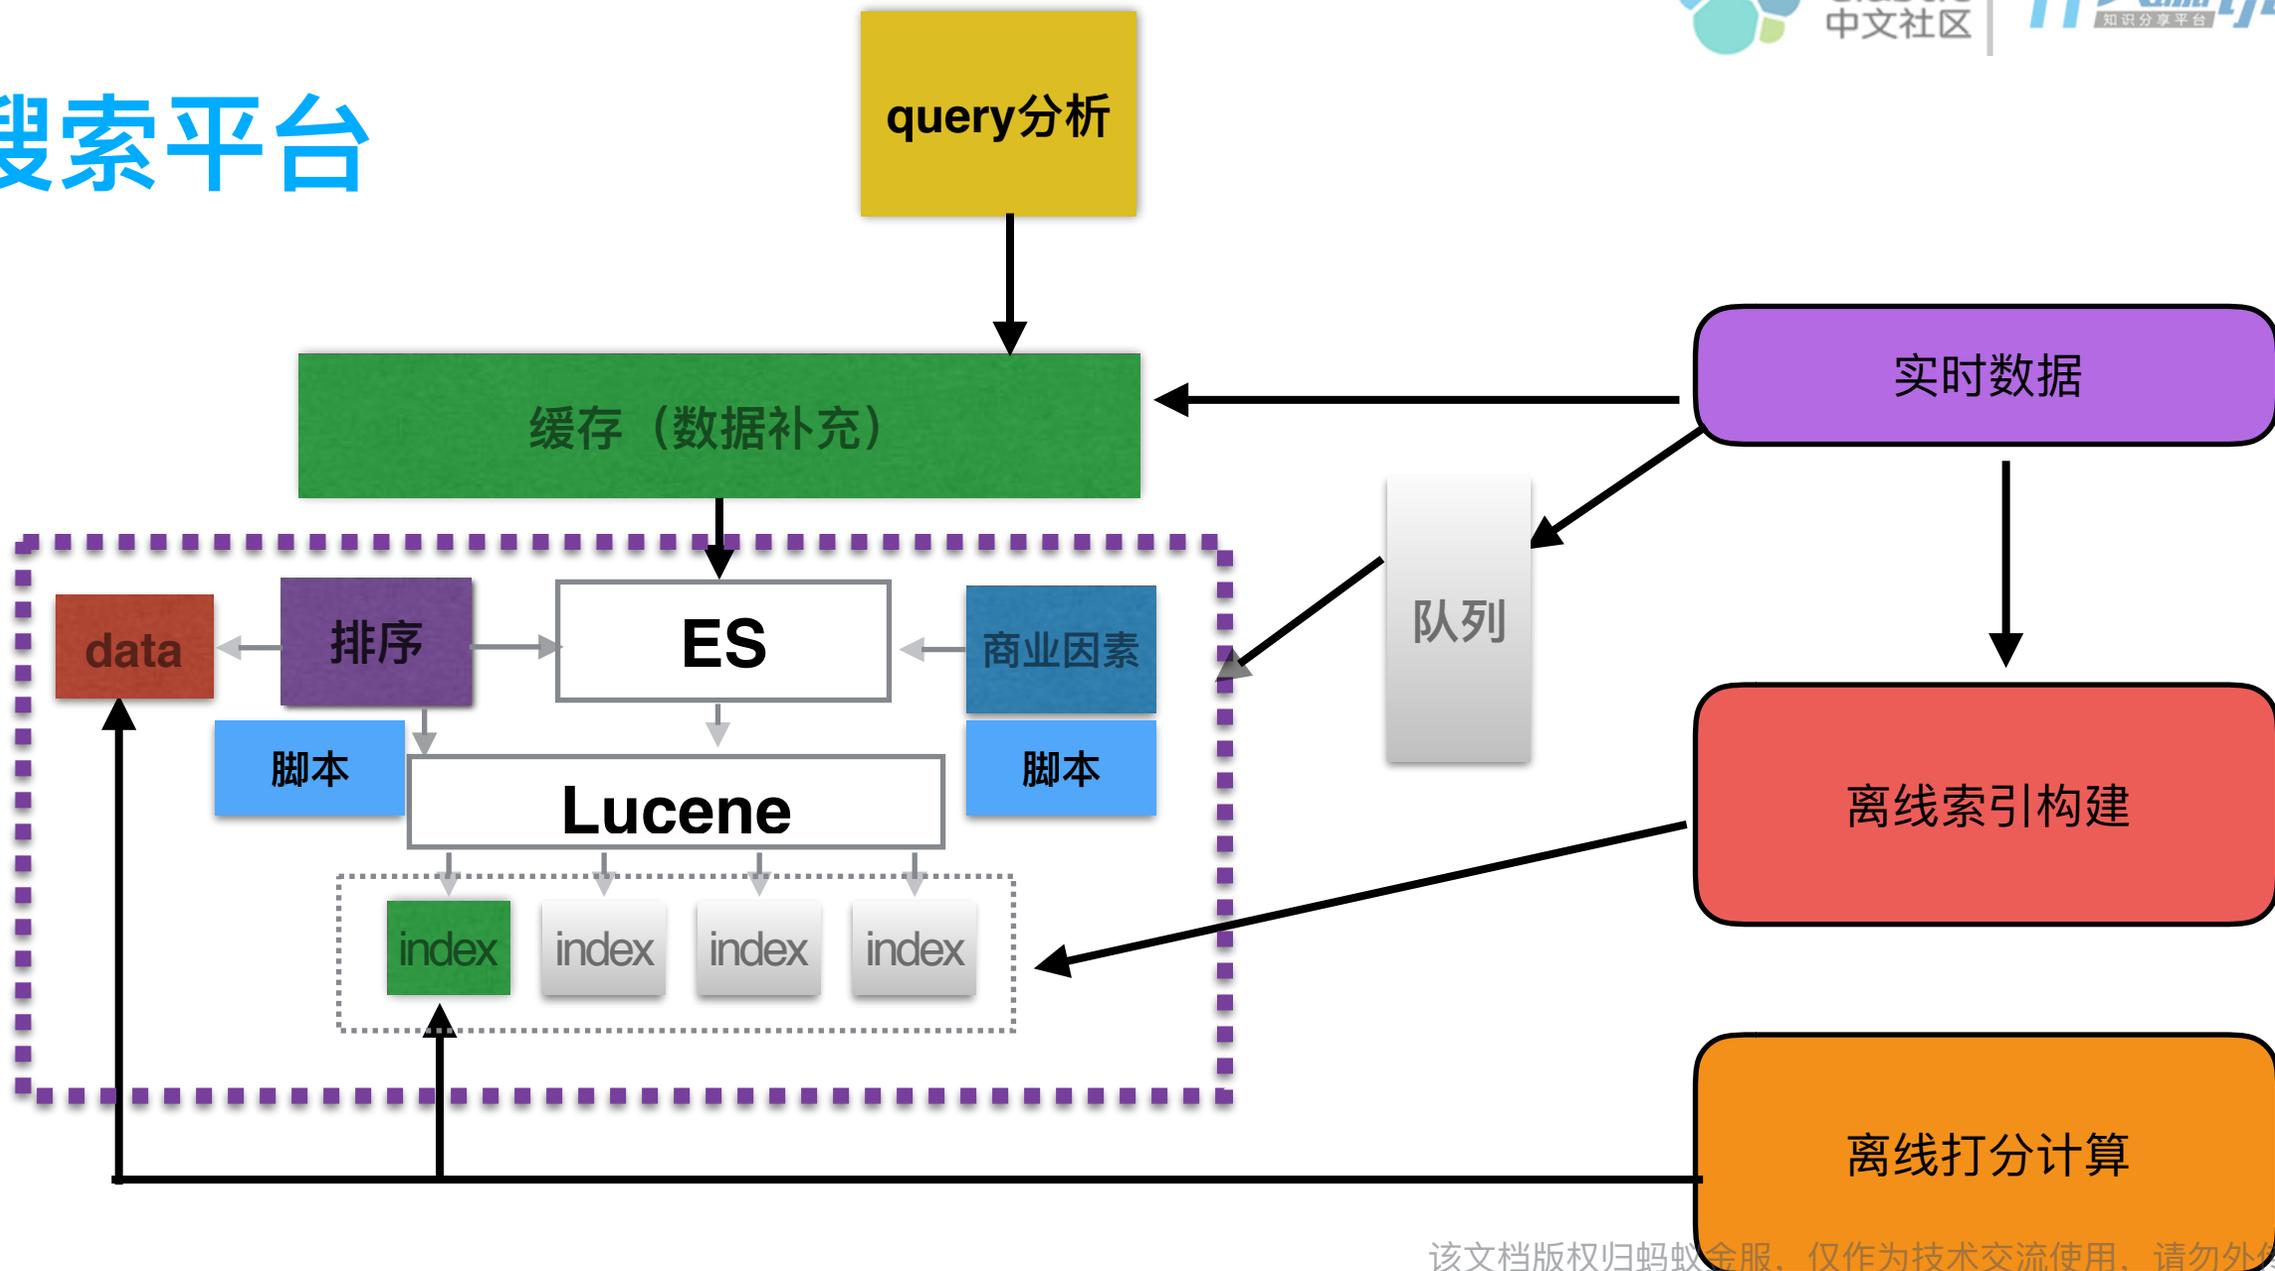
其他问题

- 分片和数据量级
- 热搜词和长尾词
- 集群稳定性
- 服务治理，命名空间
- doc缓存和结果集缓存
- 其他外围服务





搜索平台



总结

- 充分利用Elasticsearch的优势
- 该造的轮子还是要造
- Elasticsearch的适用场景
- 代码的复用
- 成本考虑



谢谢

THANK YOU

丰坚

