1.1 画像业务分析场景

百度的用户画像是面向百度全产品线的基础数据和服务平台。

我们会为包括百度凤巢、搜索、Feed 等百度各条产品线提供服务，每天有着千亿级的离/在线的数据调用规模。

随着业务的发展，我们逐步形成了用户理解全流程的数据和服务，覆盖从多元数据的采集、大规模的数据挖掘、高性能的数据服务以及面向业务场景的解决方案。

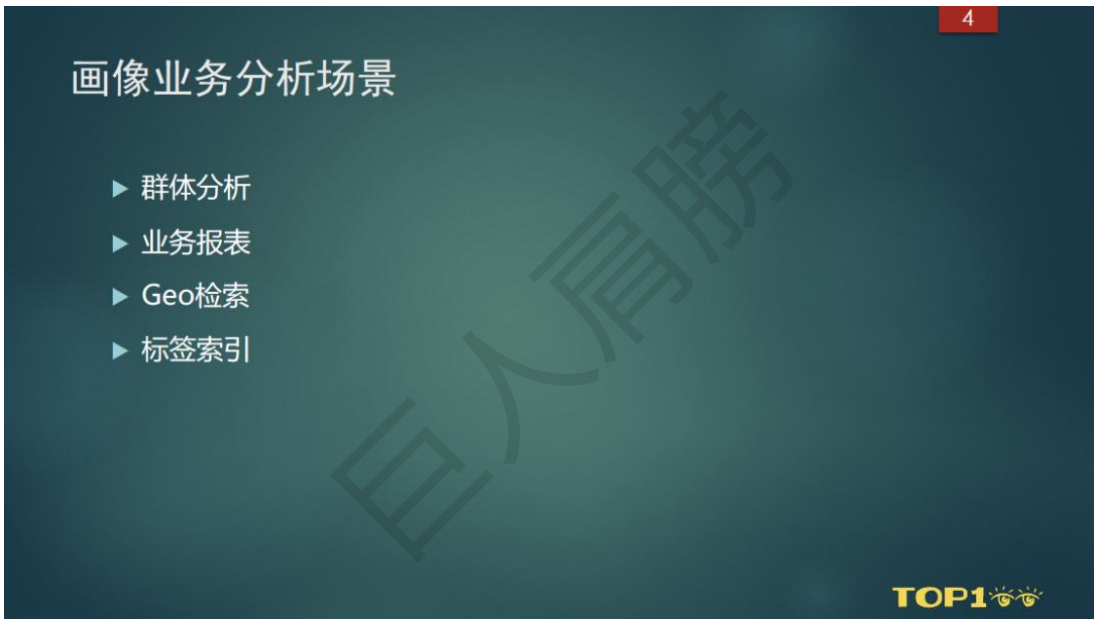

在我们的工作中，**用户群体分析**和**人群圈选**是比较常见的需求，包括群体分析、业务报表、Geo 检索、圈选等具体的场景。由于整个数据的规模比较大，同时业务对于时效性的要求比较高，在不少的业务中我们采用基于 Doris 的方法来支持和实现。群体分析大家可能会比较熟悉，也就是对一个给定人群做人群报告和多维分析。业务报表也是常见的 OLAP 场景，对很多业务数据进行统计计算，Doris 的基础能力能够很好的满足这些业务场景。

Geo 检索大家可能不是那么熟悉，Doris 在 2019 年前后集成了 Google Geo 的索引，使得对于基于地理位置的数据能够快速地进行查询、聚合操作。在一部分对于区域位置相关检索的领域，Doris 能够发挥它分布式的优势，达到不错的应用效果。

我们自己的应用测试是通过构建覆盖全北京的 400 万细粒度多层网格数据，去完成一个具体的随机的 0.1km^2 以上的区域的群体计算。Doris 处理 **1 平方公里**区域的群体数据的耗时在 **1.5 秒**左右，这对于很多的区域报表，像城市大屏、城市综治管理等场景，它是有非常大的应用空间的。

1.2 超大数据规模下的标签索引问题

基于用户标签的索引，是各大互联网公司应用最广泛的业务，也是我们今天重点讨论的一个场景。

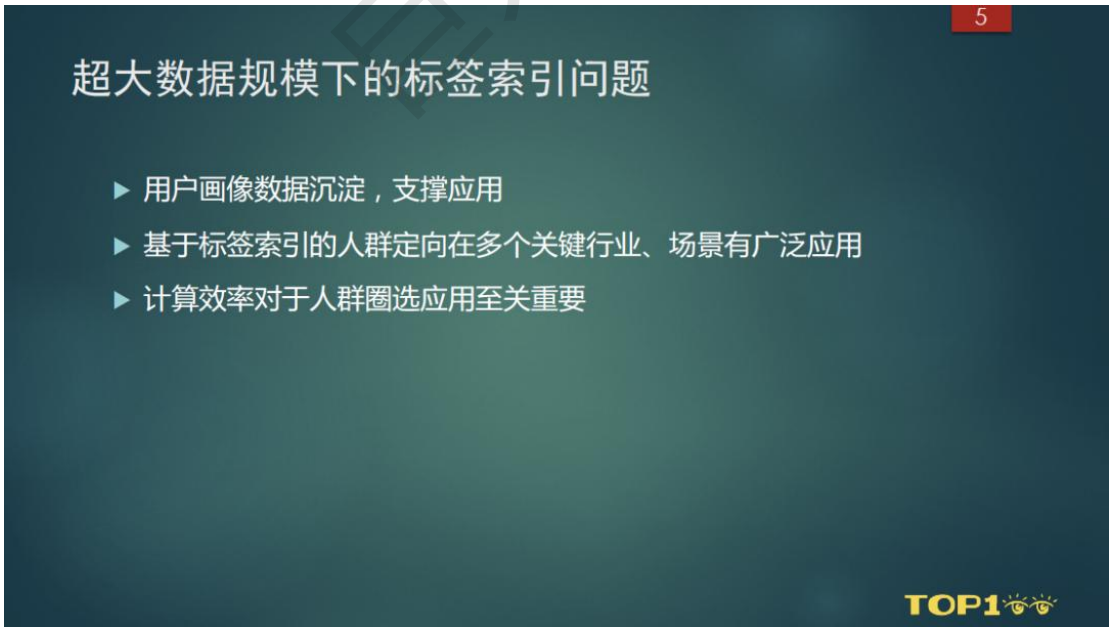

无论是基础数据团队还是业务团队都会通过标签 tag 的挖掘来更好表达对用户的理解。我们画像团队系统地构建了用户标签体系，但我们的数据规模相对来说更大一些。

这里有几个原因：一个是整个产品线覆盖和流量规模，此外还有一些特殊情况，比如我们的 id 规模远大于自然人的 id 规模，是一个数百亿级别的数据。

另外一个方面，我们从数据挖掘的层面建立了一个比较强、比较全面的画像标签体系，它的整个规模会比较大，人均的标签覆盖比较广。它的好处是可以灵活支撑应用，但是问题是在应用过程中会产生一些规模上的问题。

基于这些标签，可以条件筛选的去构建人群，进而在用户推荐、广告定向、消息推送、用户增长等领域应用。

一般来说这种业务有两个特点，一个是客户对标签的选择范围非常广，**条件组合很复杂，业务灵活度非常高**；另一个是对计算效率，特别是对于人群圈选的数量，人群分析计算的**时效要求非常高**。计算越快，使用越灵活，越能够帮助客户找到他的目标人群。

2 技术问题、思路

2.1 早期基于离线计算的方法

早期我们采用的是基于离线的计算方法，也就是用 MapReduce 来解决问题。这个方法的问题非常显而易见，灵活性差、计算成本非常高、时效是业务团队几乎不能忍受的，早期基本上是天级，最少也是小时级才能产出结果。

2.2 技术问题

我们对问题进行了一个简单的分析，问题的核心还是前面提到的——被计算的数据规模。

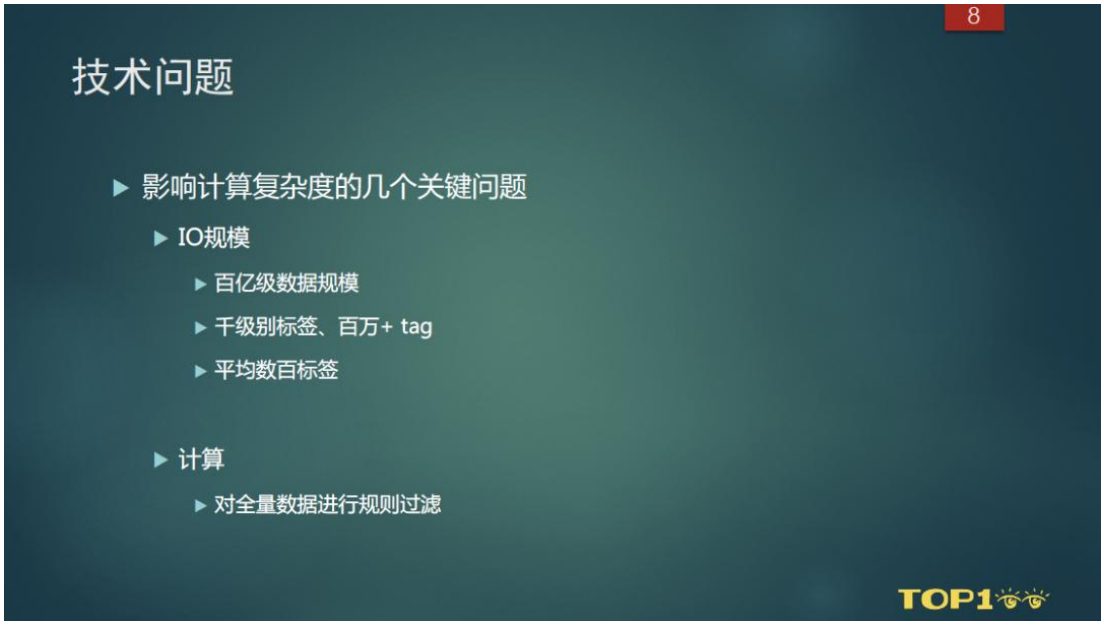

我们目前是 300 亿——600 亿的 IO 规模，标签数量 2000+，由于标签下面还可能会有枚举值，所以最终会有大概 300 万左右的 tag。对全部数据进行一个扫表操作就要花非常多的时间。

另一个核心问题是，我们之前的业务场景过于复杂，为了配合业务场景在选择技术方案是做了很多的让步——更多的考虑满足业务需求而非性能。所以早期在计算逻辑层面没有处理的特别好，整个计算效率是比较低的。

但是这一类需求在我们的业务当中却展现的尤为强烈，我们非常迫切的想解决性能和功能的问题。所以在调研了非常多类似业务的方案后，**我们提出了一种高性能标签索引的解决思路**，并且考虑开发一套专用的系统来实现和解决类似的问题。

2.3 技术思路

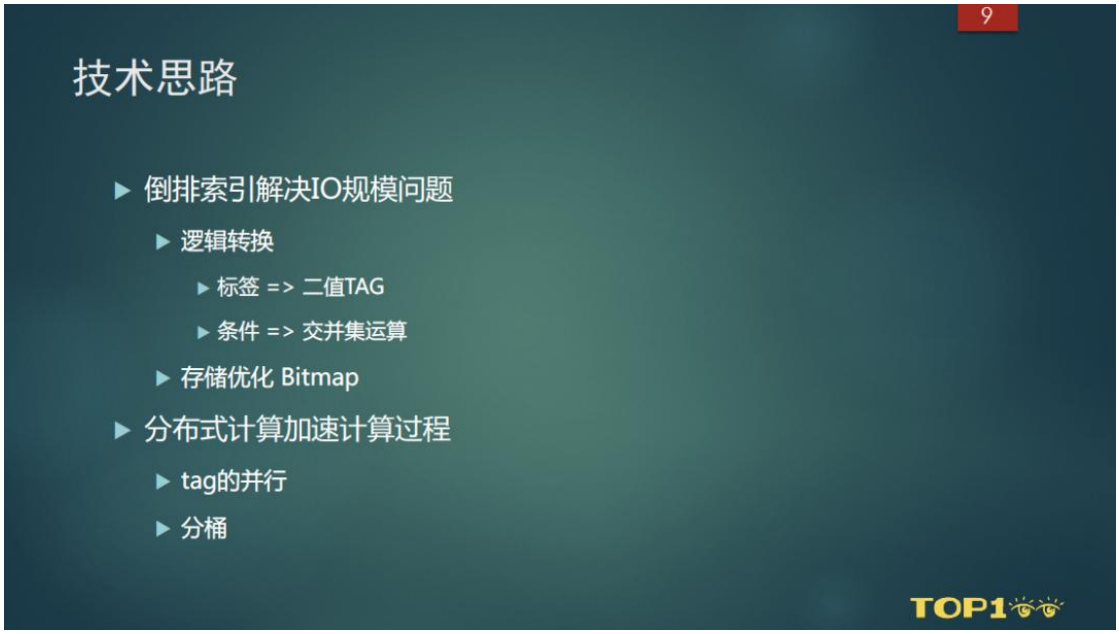

（1）解决 IO 规模问题

原先的方法无论是基于 MapReduce 还是其他类似的逻辑，核心的问题在于我们要对全局数据进行遍历扫。因为我们是以 uid 为 key 的一个正向的数据结构，对标签进行扫必须要扫全量。

这里我们的解决办法是做**倒排索引**，以标签为 key 把 uid 作为 value。这样构建一个反向索引之后，原来我们是全表扫，现在变成只处理关注的标签，这样整体的 IO 规模会瞬间下降好几个数量级。

其次我们要做一个计算加速的优化，这里面主要是逻辑的变化。把原来**圈选的逻辑变成交并集的处理**。

在细节上需要做考虑两个问题：

一个是把原来标签的枚举变成二值化的 tag。

比如：标签球类运动，它的每一个枚举值，就需要拆解为具体的 tag，如篮球、足球等。基于这个转化，可以把条件圈选变成交集、并集计算的组合。例如，选

择喜欢篮球运动、不喜欢足球运动，就可以变成 tag-篮球 1，tag-足球 0 的交集。

另一个是我们有超过 300 万个 tag ，在对 tag 做倒排索引时存储空间会成为一个非常大的问题，所以需要进一步降低存储，提升计算效率。

我们选择采用 Bitmap 来优化标签索引，用一个 bit 来标记一个 value，将用户作为整个 Bitmap 里的一个位，这样可以实现在存储上的空间节省。同时由于位运算在交并集上天然的优势，在计算上也能带来性能提升。

（2）加速计算过程

在解决计算规模问题时，核心的逻辑是**用并行计算来加速过程**。由于数据的 tag 是 key 构建的，尤其一些基础的标签的数据覆盖率非常高，有些可以达到 90% 以上，整个 Bitmap 会非常长。

这个情况下，对于一个百亿级的 uid 范围，bitmap 的 size 将会非常大，这些 bitmap 会成为计算平响，需要进一步对 bitmap 进行纵向的分桶，以加速计算，减少长尾。考虑 tag 数乘以分桶的情况，这是一个数量可观的分布式并行的储存与计算过程，对于分布式系统有着很高的要求，也是一种典型的 MPP 场景。

比较巧的是，在和 Doris 同学的交流过程当中，我们得知 Doris 正在做相似的工作。Doris 的 MPP 架构和正在进行的 Bitmap 集成，刚好是我们业务需要的能力。可以说是不谋而合。

我们也调研了其他开源解决方案比如说 Kylin 和 Druid，Kylin 在这个场景下有一定的局限性，它需要预计算，这就带来了维度和空间的爆炸，并且不能满足我们对细粒度数据的需求。Druid 在这方面可以满足我们的需求，但是在一些特定使用场景下我们是依赖 Doris 的，**所以我们最终选择了 Doris。**

3 基于 Doris 的技术实现

3.1 Doris 分布式查询引擎

结合业务场景，我们将方案调整为基于 Doris 实现全套的标签索引服务。

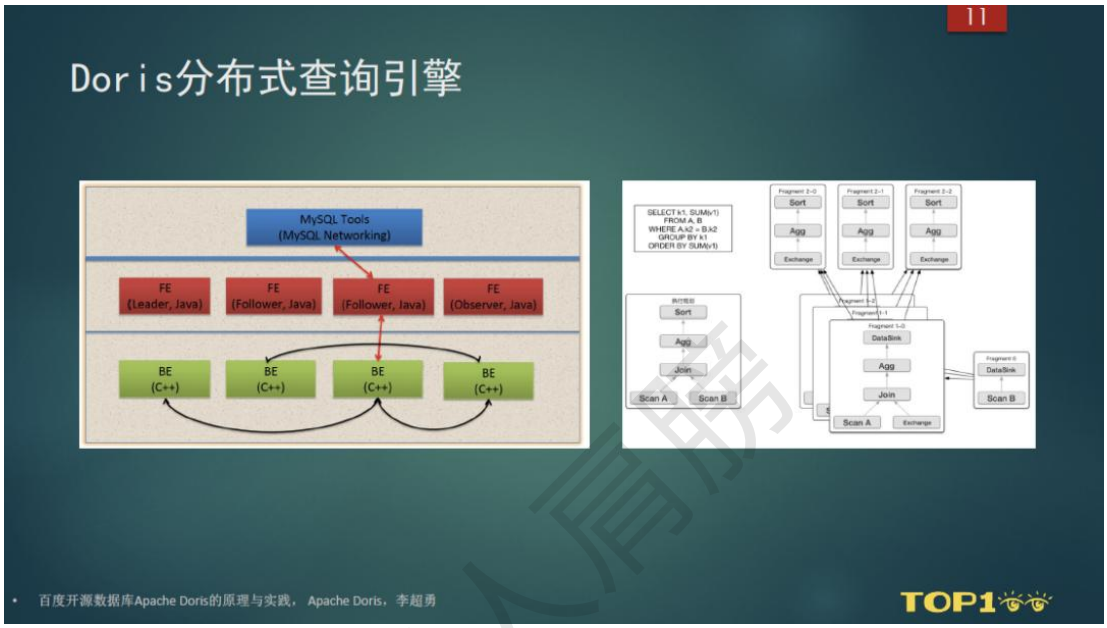

Doris 采用的 MPP 架构非常简洁，由 FE 和 BE 完成从服务接入到数据存储、管理、计算的分布式服务。其中，FE 负责存储以及维护集群数据、接收、解析、查询、设计规划整体查询流程，BE 负责数据存储和具体的实施过程。FE 会根据用户的查询去生成一个完整的逻辑规划，进一步构建分布式的逻辑发给整个集群去执行。

在右边规划图中，由一个 BE 去执行的时候，需要通过 RPC 进行数据交换，不同的计算方法和内容，交换的数据也不同。

3.2 Bitmap 在 Doris 的应用

Bitmap 通常作为 OLAP 系统和存储系统的索引，Doris 很早就集成了 Bitmap 来加速数据查询的过程。

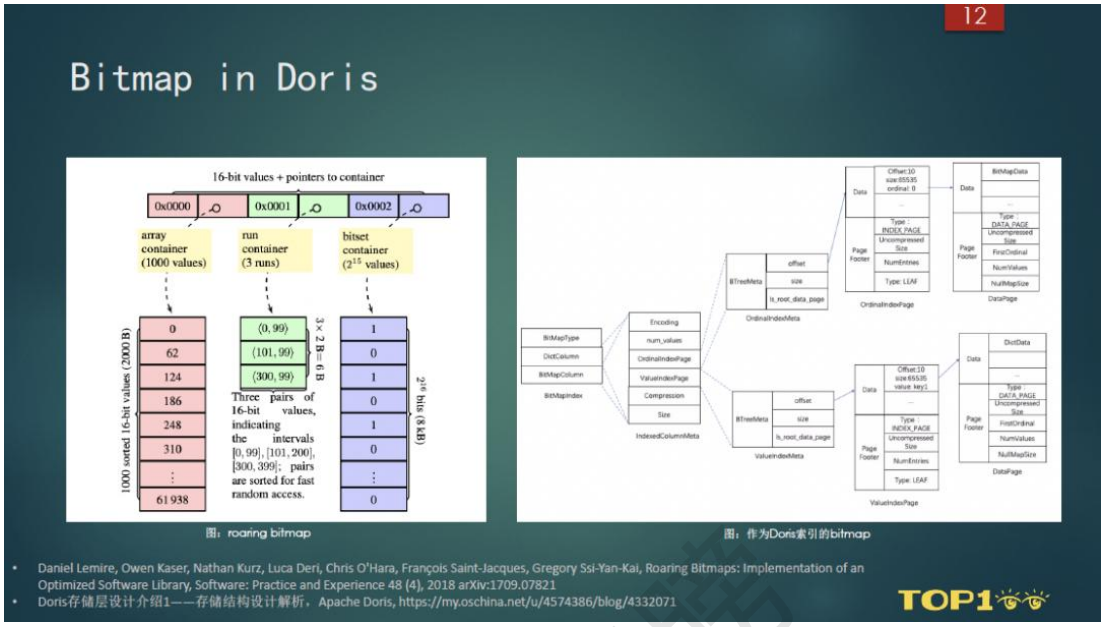

如上图所示，右边是 Doris Bitmap 索引的数据结构。

和索引应用不同，Bitmap 作为数据应用，可以解决明细数据的查询、交并集问题。我们在使用的时候将 Bitmap 作为数据结构，直接使用 Bitmap 作为实际存储数据来解决明细数据查询和交并集计算的问题。

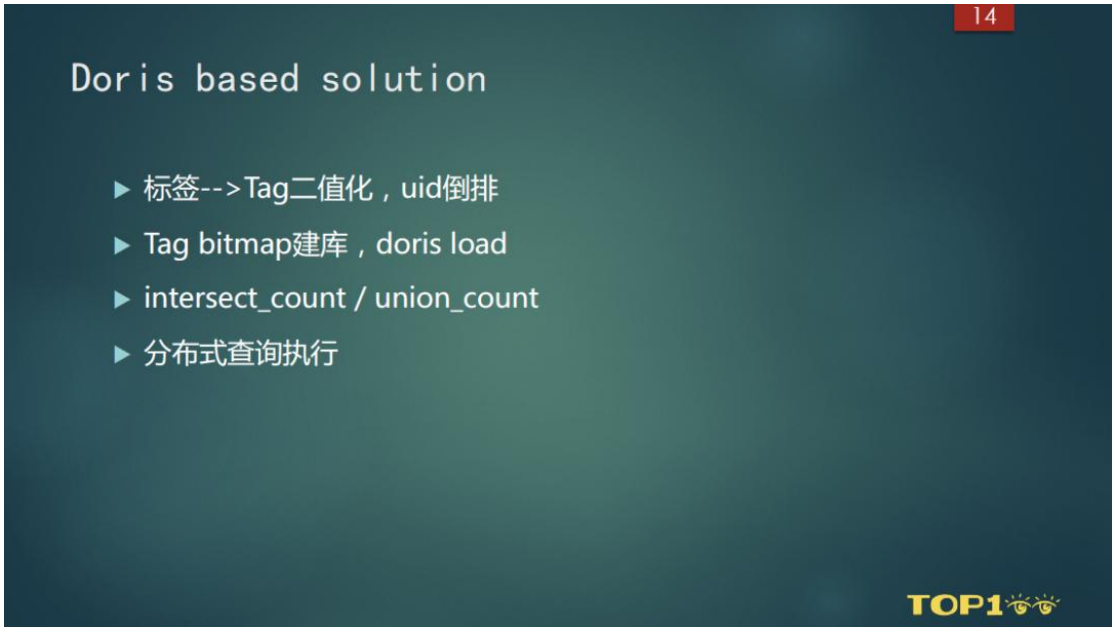

基于 Doris，首先我们通过离线的 MR 形式完成了标签 tag 的二值化和 uid 倒排（这里还包括对 ID 的顺序处理）。

然后我们用 Bitmap 作为数据结构，Bitmap Union 为聚合函数，采用 Doris Load 的方法完成了数据建库和数据 Load，这个过程可能比较慢但很可行。

接下来，我们需要把条件查询转变成交并集计算，对单个节点来说，intersect_count / union_count 的方法 Doris 可以自动完成分布式的计算过程，实现已经 Bitmap 化的标签数据的聚合计算。

基于以上的逻辑，我们只用了两周就完成了测试过程。

3.3 标签索引应用在 Doris 基础实现的问题

以上的方案在比较小的计算规模上可以得到计算结果，对于稍微复杂的计算场景，就出现了一些问题。

我们做了一个测试，在 300 亿的 uid，平均标签数为 300 的情况下，能够完成不包含稠密 Bitmap 的 tag 进行 6 个标签的交集和并集的计算，但当我们把条件 tag 换成稠密的 Bitmap 之后，用 14 个标签就已经超时了。(这里稠密的 Bitmap 指 tag 数据在全量用户 id 的覆盖率非常高的情况，而这种 tag 恰恰是我们业务中最常用到的。)

除此之外还有一个功能问题，当时 Doris 还不支持批量 ID 导出。

3.4 标签索引应用在 Doris 基础实现的性能问题

结合 Doris 的计算过程，我们分析认为问题的核心主要有两点。第一点在于 Bitmap 本身实现的逻辑，第二点在于在 Doris 中 Bitmap 分布式实现的问题。

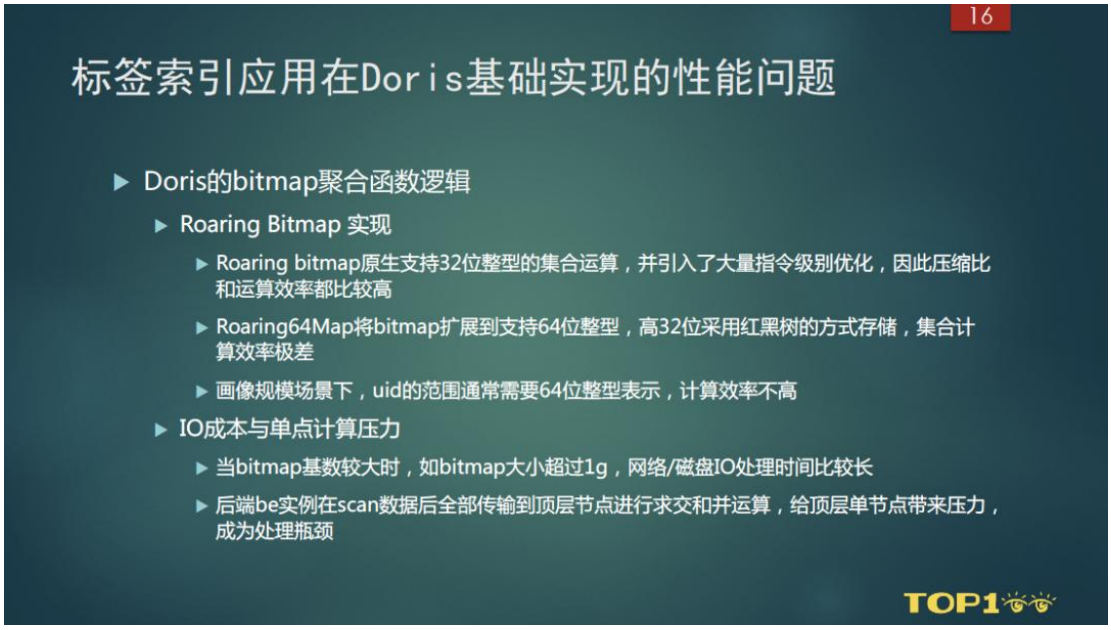

一般来说，32 位 Bitmap 在压缩比和计算效率上有很好的平衡，但是 64 位的 Bitmap 的计算效率就相对比较差。画像的数据在百亿级别，所以需要用 64 位的 Bitmap ，那么计算效率就比较低。

第二个，当 Bitmap 基数比较大时，数据规模也比较大，网络磁盘和网络 IO 处理时间比较长。Doris 在计算过程中需要 scan 数据后全部传输到顶层节点进行求交和求并运算，但本质上交并集计算是在单节点进行的，同时要经过网络 IO 之后才能进行处理，这都成为了影响性能的关键点。

3.5 性能解决方案

（1）Bitmap 纵向切分建库

针对以上的问题，我们提出了一种正交的 Bitmap 计算的 UDAF 解决办法。

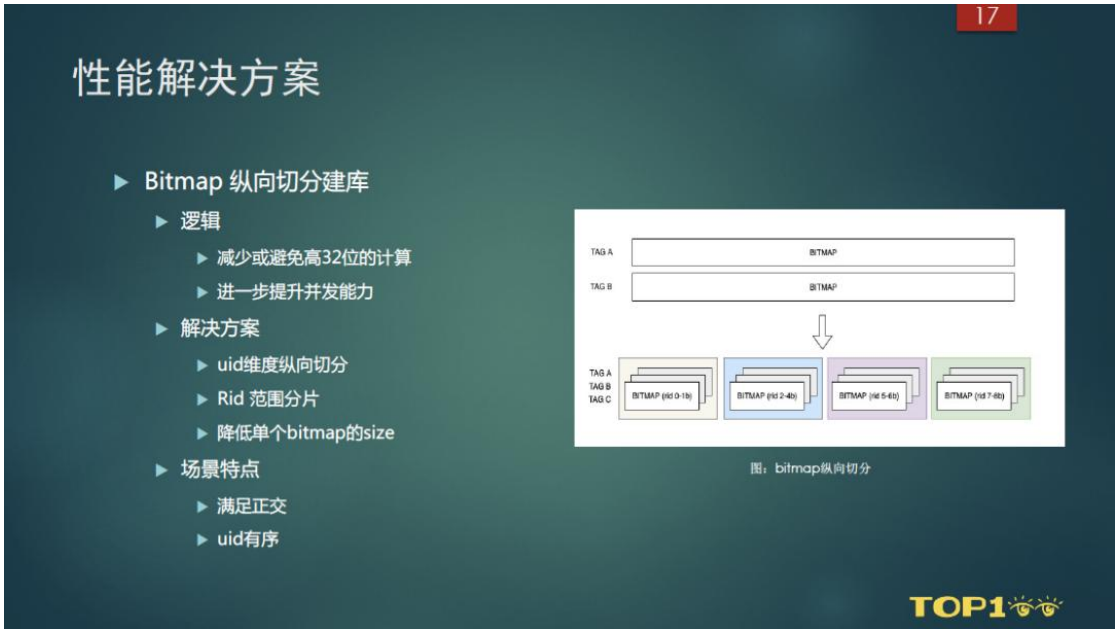

图：bitmap纵向切分

我们对 Bitmap 进行纵向的切分建库，如右图所示，我们的出发点是减少或避免高 32 位的计算，并且进一步提升并发能力。

具体来讲，首先我们按照 uid 进行数据纵向切分，以 rid 范围进行分片，降低单个 Bitmap 的 size。这同时带来了一个好处，这种切分方式满足正交方式，无论在 tag 维度层面还是在 id 范围层面，同一个分片内是可以相互独立的。基于这种正交关系，我们进一步优化分布式计算的实现。

（2）分布式计算优化

图：以count计算为例的分布式优化

首先在数据层面，我们让相同 id 范围的数据（即使不同 tag）也在相同的实例部署。在数据的交并集计算上，我们让各个分片分别在各自的节点上完成计算，merge 的是计算结果而不是原始数据。这样可以让计算的节点数变多、实现并发，还可以在数据传输过程中不进行全量传输，网络通信的成本也降到最低。

右图所示是进行 count 计算时，在本地完成了 local 的交并集计算之后只需要把 count 值给出去，最后将不同的 count 值 merge 就完成了整个计算过程。

3.5 性能测试

经过以上的处理，我们的整体计算效率得到了很大的提升，小数据量的情况下得到了**两个数量级的提升**，在大数据量下我们**由不可能变成了可能。**

从上图中可以看出，性能变得更加可用，可以在秒级完成我们的业务需求。

3.6 标签索引应用在 Doris 基础实现的功能问题

（1）数据灌库、建库

目前还是基于之前的离线计算方式，这种方式效率不够高，但是引入新的解决方法——Enhanced Spark-based Load，这种方式现在还在测试，预计性能会有非常大的提升。

（2）批量 ID 导出

Doris 自身的 SQL API 没有支持亿级数据导出。结合业务场景 Doris 的同学帮我们想出了一种解决方法——通过修改现有的 select outfile 将 MysqlWriter 改写成 FileWriter，并且通过 Broker 把结果数据写到远端存储。这样就可以实现批量原始 id 的数据导出，满足我们对细粒度用户数据的需求。

4 业务效果

标签索引满足主要人群圈选业务场景

人群圈选时效从天/小时级提升到秒级响应

业务应用效率大幅度提升，支持更加灵活的业务应用

在广告、增长等方向取得良好的业务效果

5 应用指南

我们在今年 8 月已经将相关的代码和使用指南已经提交到 Apache Doris 的代码库，供大家分享使用：

http://doris.incubator.apache.org/master/zh-CN/extending-doris/udf/contrib/udaf-orthogonal-bitmap-manual.html

这里需要有一个额外的编译过程来满足 UDAF 的应用：

最终使用的时候只需要写一个 select BITMAP_COUNT 就可以快速得到需要的数据结果。

6 交流讨论

欢迎加入 Doris 分享、交流、互助大家庭：

欢迎访问巨人肩膀：www.atbigapp.com 。一个致力于大数据技术和应用发展与推广，通过环境及基础能力的提供降低开发者门槛、提高开发者效率的互助互利的大数据开放平台。