导购网站应用案例

PostgreSQL海量数组实时相似计算

digoal

阿里云

业务介绍

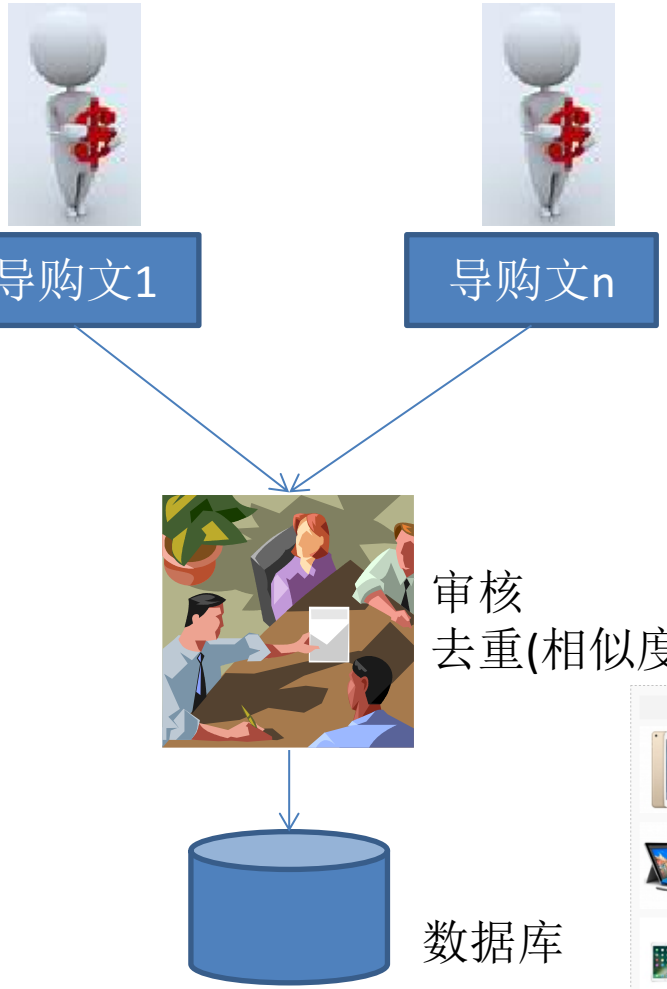

平板电脑购买指南_如何选择平板电脑

[摘要] 平板电脑就是一款无须翻盖、没有键盘、小到可以放入
场上就有各式各样的“平板大军”，而且高、中、低档俱全，
电脑呢？我们一起来了解了解。

这几天华为P10、三星S8的发售，无疑在手机界引发了一
就会发现，随着市场的饱和，近几年来，手机在技术方面
色、拼外观、拼拍照……一个小小的像素的提升，都已经于

导购文章有效性判定要素

- 商品重复率
- 实时

相关技术

- 文本相似
  - 机器学习
  - 关键次提取
  - 海明距离
- 图像相似
  - haar wavelet
- 数组相似
  - PostgreSQL smlar

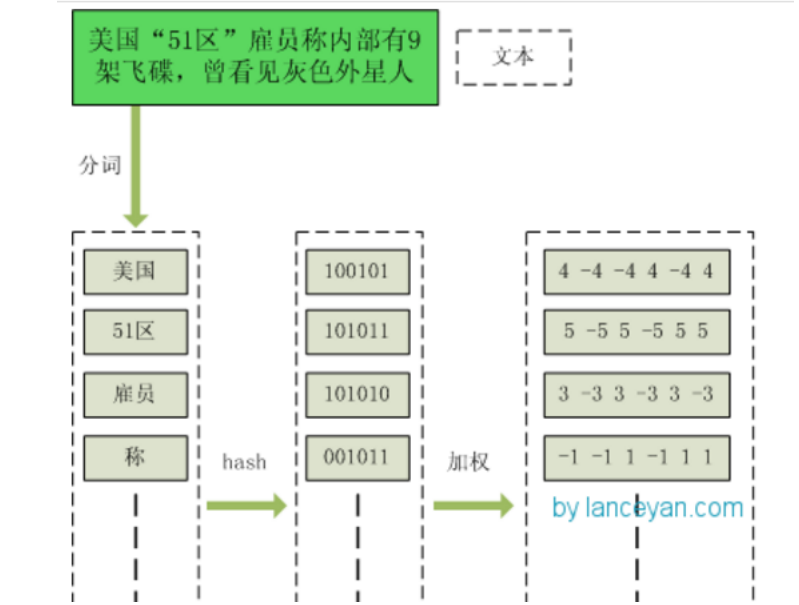

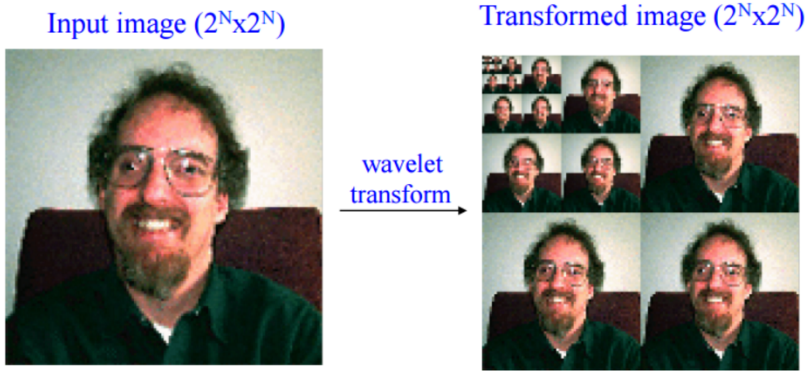

smlar

- 相似度公式
  - cosine
    - N.i / sqrt(N.a * N.b)
  - overlap
    - N.i
  - tfidf
  - N.i ：相交的元素个数(被比较的两数组会先去重)
  - N.a : 第一个数组的元素个数(去重后)
  - N.b : 第二个数组的元素个数(去重后)

GIN索引结构

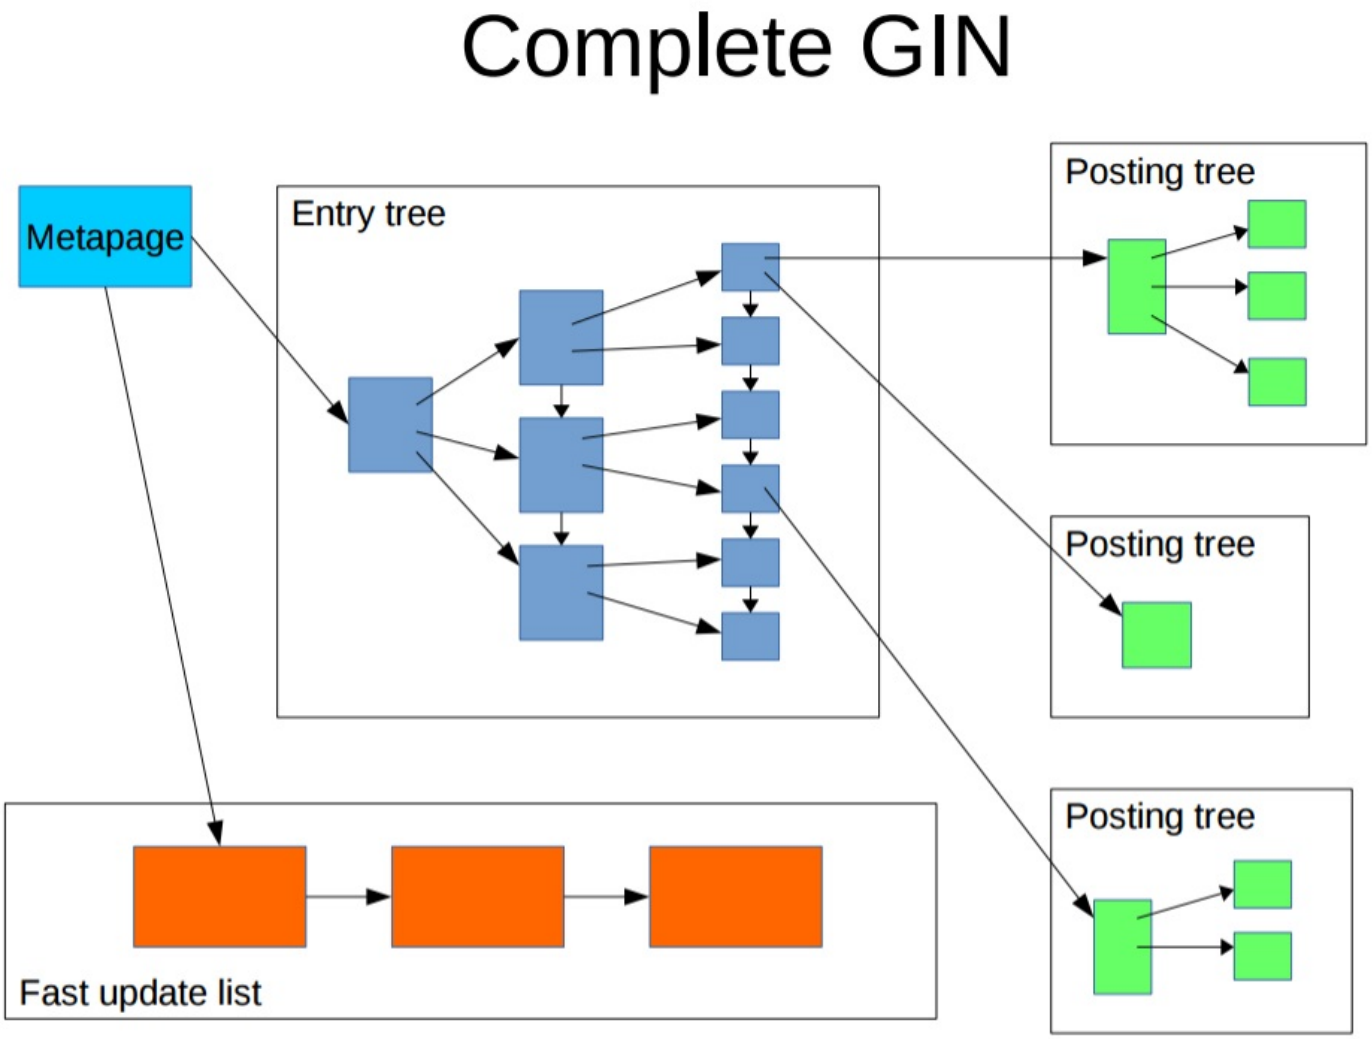
Complete GIN
Metapage
Entry tree
Posting tree
Posting tree
Posting tree
Fast update list

GIN索引

- 倒排效果
- postgres=# select id, count(*) from tbl group by 1 order by 1;
- id | count
- ----+-------
- 0 | 10096
- 1 | 91
- 2 | 97
- 3 | 92
- 4 | 109
- 5 | 108
- 6 | 97
- 7 | 100
- 8 | 103
- 9 | 88
- 10 | 89
- 11 | 99
- 12 | 91

GIN索引

- 数组，GIN索引，倒排效果
- postgres=# select info from arr ;
- info
- ----------
- {9632,6798,2069,3533,2702,3191,5561,8756,4391,3290}
- {4179,8012,6926,1643,5025,8958,8984,2823,8730,3273}
- {4226,4074,9788,8491,8941,3609,5942,8588,5395,307}
- {2632,5028,7105,4702,8561,9807,7893,4121,8563,2284}
- {7412,2743,296,4337,4386,5320,3295,3370,8143,2026}
- {6643,2369,6100,6431,860,5041,40,6803,3628,5435}

GIN索引

- 数组，GIN索引，倒排效果
- postgres=# select ctid,unnest(info) from arr;
- ctid | unnest
- --------+--------
- (0,1) | 9632
- (0,1) | 6798
- (0,1) | 2069
- (0,1) | 3533
- (0,1) | 2702
- (0,1) | 3191
- (0,1) | 5561
- (0,1) | 8756
- (0,1) | 4391
- (0,1) | 3290
- (0,2) | 4179
- (0,2) | 8012
- (0,2) | 6926
- .....

GIN索引

- 数组，GIN索引，倒排效果
- postgres=# select id,array_agg(ctid) from (select unnest(info) id,ctid from arr) t group by 1 order by 1;
- ...
- 1491 | {"(0,39)","(1,3)"}
- 1496 | {"(0,18)"}
- 1500 | {"(0,23)","(0,31)","(0,76)"}
- ...

GIN索引, OVERLAP相似计算检索举例

第一重过滤

- 收敛 BLOCK ID (if overlap>=3)

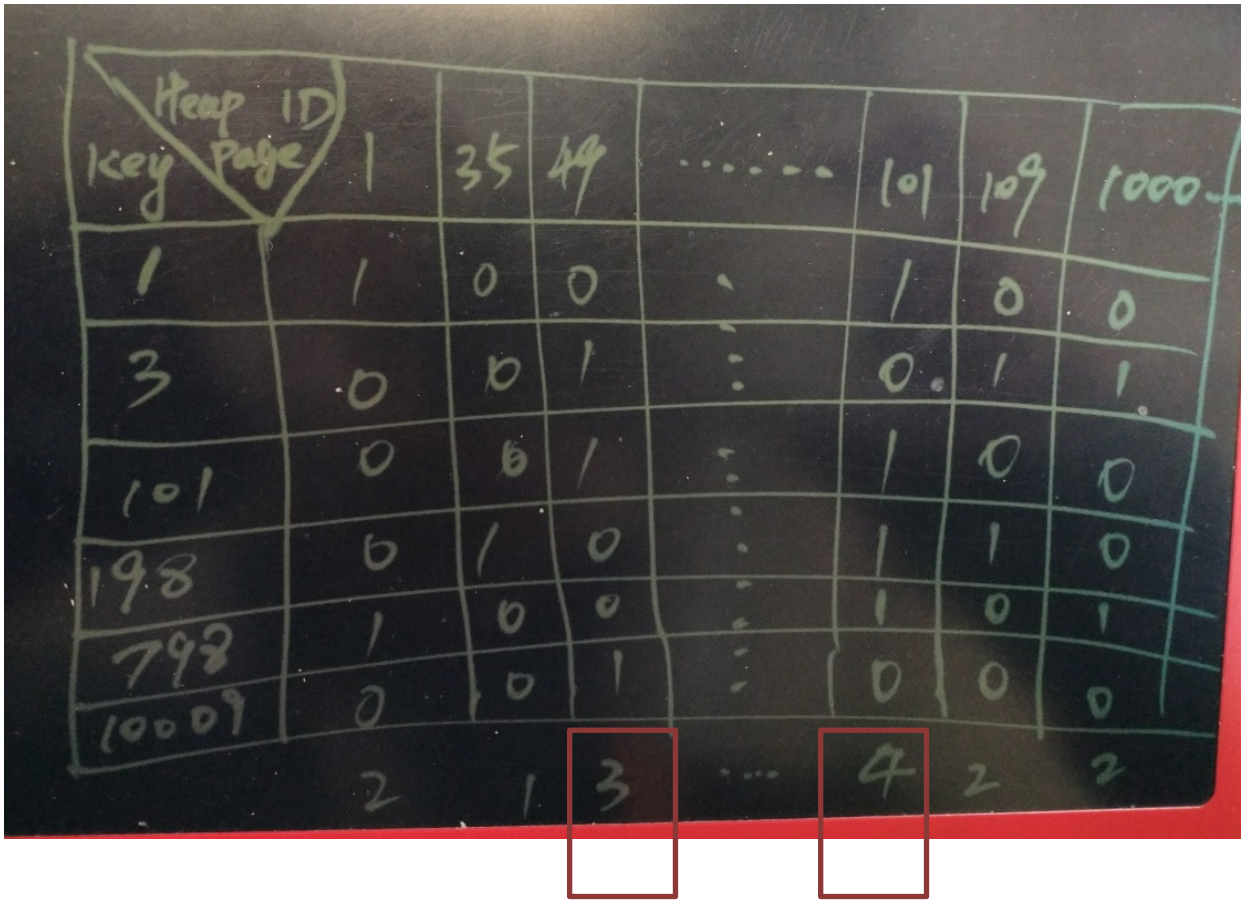

第二重过滤

- CPU CHECK BLOCK's tuples

- BLOCK: 49
- BLOCK: 101

导购推荐平台-例子

- 沉淀导购文章：6000万
- 涉及商品数量：1000万
- 平均每篇文章涉及商品数量：11 - 50个商品
- 热点商品：50万热点商品，商品ID 分布区域 1-50万，热点商品被1000万篇文章推荐过.

导购推荐平台-例子

- 测试方法，如何造数据？
- https://github.com/digoal/blog/blob/master/201701/20170112_02.md

- create extension smlar;
- create unlogged table test (id serial, -- 文章ID
- arr int8[] -- 商品ID组成的数组，假设商品ID为int8类型，那么数组就是int8[]);

- 插入5000万记录，要求如下
- int8 取值范围1~1000万， 即历史上被推荐的商品有1000万个。
- int8[] 数组长度 11 ~ 50， 即每篇导购文章，包含11到50个商品。

- 调用一次插入40条记录。
- create or replace function f() returns void as $$
- declare begin
- for i in 11..50 loop
- insert into test (arr) select array_agg((10000000*random())::int8) from generate_series(1,i);
- end loop;
- end; $$ language plpgsql strict;

总共生成6000万历史导购数据

- 使用pgbench调用以上函数，将生成5000万测试数据
- vi test.sql select f(); pgbench -M prepared -n -r -P 1 -f ./test.sql -c 100 -j 100 -t 12500

- 生成1000万热点商品的推荐数据
- 假设商品ID范围在 1 ~ 50万 的为热点商品，被1000万篇文章推荐过。

- create or replace function f() returns void as $$ declare begin
- for i in 11..50 loop
- insert into test (arr) select array_agg((500000*random())::int8) from generate_series(1,i);
- end loop; end; $$ language plpgsql strict;

- 使用pgbench调用以上函数，生成1000万热点数据
- pgbench -M prepared -n -r -P 1 -f ./test.sql -c 100 -j 100 -t 2500

创建GIN索引

- set maintenance_work_mem='64GB';
- create index on test using gin (arr _int8_sml_ops);
- 虽然smlar插件还支持 gist 索引，但是本文的CASE不建议使用gist索引
- -- create index on test using gist (arr _int8_sml_ops);

性能?

- 审核性能

- 导购文章包含普通商品40个，其中39个与历史导购文章重复。
  - 4ms
- 导购文章包含普通商品40个，其中20个与历史导购文章重复。
  - 4ms
- 导购文章包含热点商品10个,普通商品30个，其中39个与历史导购文章重复。
  - 6ms
- 导购文章包含热点商品10个,普通商品30个，其中20个与历史导购文章重复。
  - 6ms
- 导购文章包含热点商品40个，其中39个与历史导购文章重复。
  - 15ms
- 导购文章包含热点商品40个，其中20个与历史导购文章重复。
  - 15ms

性能?

- 审核压测
- 普通商品35个，热点商品5个，overlap=35
- tps = 9455.190803 (including connections establishing)
- tps = 9460.748975 (excluding connections establishing)

小结


传统方法
全表扫描匹配相似度，效率低，资源消耗巨大。
审核延迟非常高，无法实时。
PostgreSQL GIN+smlar插件。
效率高，资源消耗低。
实时判定数组相似度，(实时审核导购内容)。

谢谢

- 详情
- https://github.com/digoal/blog/blob/master/201701/20170112_02.md

- 个人GIT
- https://github.com/digoal/blog/blob/master/README.md

官方微信公众号

digoal's 微信