

Яндекс Go



Anchor Modeling и GP: как мечты разбиваются о реальность

Евгений Ермаков, руководитель DWH

Николай Гребенщиков, руководитель команды DE RideTech

Содержание



Вступление

I


2019

- › Архитектура DWH
- › Детальный слой
- › Подходы к детальному слою
- › Data Vault vs Anchor modeling


Архитектура слоев данных



Архитектура слоев данных



Архитектура слоев данных



Детальный слой


Детальный слой – ключевой для построения доменной модели

- › Хранит историю изменений сущностей и связей между ними
- › Отвечает за консолидацию данных между источниками
- › Устойчив к изменению в бизнесе (?)
- › Модульный и масштабируемый (?)

Greenplum



Архитектура слоев данных



Подходы к проектированию

сложно эксплуатировать, просто вносить изменений

Никакого

- › Денормализация до 1НФ
- › Можно использовать без подготовки
- › Неустойчиво к изменениям
- › Дублирование информации
- › Нет join

Звезда и снежинка

- › Нормализация до 3НФ
- › Можно использовать с минимальной подготовкой
- › Неудобно перестраивать
- › Минимальное дублирование информации
- › Приемлемое количество join

легко эксплуатировать, сложно вносить изменения

Подходы к проектированию

сложно эксплуатировать, просто вносить изменений

Никакого

- › Денормализация до 1НФ
- › Можно использовать без подготовки
- › Неустойчиво к изменениям
- › Дублирование информации
- › Нет join

Звезда и снежинка

- › Нормализация до 3НФ
- › Можно использовать с минимальной подготовкой
- › Неудобно перестраивать
- › Минимальное дублирование информации
- › Приемлемое количество join

Data Vault

- › Строгая нормализация
- › Нельзя использовать без подготовки
- › Не надо перестраивать (с ограничениями)
- › Минимальное дублирование информации
- › Большое количество join

Anchor modeling

- › Ультра строгая нормализация
- › Нельзя использовать без подготовки
- › Не надо перестраивать
- › Нет дублирования информации
- › Ультра количество join

легко эксплуатировать, сложно вносить изменения

Подходы к проектированию



Забегая вперед...


I

II

III

2020

~~Попытка #1~~



Data Vault и Anchor Modeling



<https://learndatavault.com/>

Dan Linstedt



<http://www.anchormodeling.com/>

Lars Rönnbäck

Обе методологии:

- › Повышают градус нормализации выше 3НФ
- › Вводят свои типы таблиц и накладывают жесткие ограничения на их использование
- › При использовании создают **over 9000 таблиц**

Взамен обещают:

- › Уменьшить постоянное дублирование данных в SCD2 от изменения всего одного атрибута
- › Избавить от деструктивных изменений, только расширение модели (даже при изменении кардинальности связи, боль классического хранилища)
- › Позволить дорабатывать хранилище легко и быстро (мистика)






Создать свою
модель


Логический и физический уровень

Закрепить разделение уровней проектирования в методологии


Логический уровень




Физический уровень




TPC-H



TPC-H DV



TPC-H AM



Возвращаясь назад...

I

2019



Постановка задачи

Цель: применить якорную модель к детальному слою в Greenplum

Дано:

- › Рабочий кластер Greenplum5
- › Понимание необходимости детального слоя
- › Желание идти в ногу со временем
- › Отвага и решительность

Задачи:

- › Провести анализ технических оптимизаций для АМ
- › Проанализировать их наличие в GreenPlum5
- › Собрать работающий АМ
- › Перевести на него построение витрин и аналитиков


Теория. Возможности Greenplum



- › MPP RDBMS
- › Heap vs AO
- › Legacy vs Orca


Greenplum = SN MPP RDBMS

- › Share Nothing
- › Massive Parallel Processing
- › Relational database management system




Массивно-параллельная обработка

Фрагментный параллелизм



Генерация параллельного плана запросов



Дистрибьюция

```
CREATE TABLE foo (a int, b text)  
DISTRIBUTED BY (a);
```

```
CREATE TABLE bar (a int, b text)  
WITH (appendoptimized=true)  
DISTRIBUTED BY (a);
```

Формат хранения таблиц

```
CREATE TABLE foo (a int, b text)
DISTRIBUTED BY (a);
```

```
CREATE TABLE bar (a int, b text)
WITH (appendoptimized=true)
DISTRIBUTED BY (a);
```


Heap-таблицы

- › Стандартный вариант для Postgres
- › Строчное хранение (эффективно для OLTP)
- › Нет сжатия (?!)
- › Есть кластерный индекс

Append-optimized таблицы

- › Специальный формат хранения
- › Можно хранить и строчно, и колоночно
- › Есть сжатие
- › Нет кластерного индекса

Cluster index



Оптимизатор запросов

Legacy (old postgres)

- › Стандартный вариант для Postgres
- › Поддерживает все виды join
- › Предпочитает heap, но нормально работает и с АО (ранняя материализация кортежей)
- › Выдерживает любое количество join

ORCA

- › Специальный оптимизатор
- › не поддерживает merge Join
- › Предпочитает АО (но также предпочитает раннюю материализацию кортежей)
- › С определенного количества join в запросе отдает управление legacy
- › В среднем быстрее legacy

Варианты работы с GP

Legacy (old postgres)

Heap

- › Поддерживает все виды join
- › Есть кластерный индекс
- › Выдерживает любое количество join
- › Нет сжатия
- › Нет колоночного хранения

Append-optimized

- › Поддерживает все виды join
- › Есть сжатие
- › Есть колоночное хранение
- › Нет кластерного индекса
- › Не выдерживает большое количество join

ORCA

- › Есть кластерный индекс
- › Выдерживает любое количество join

- › Нет сжатия
- › Нет колоночного хранения
- › Нет merge join

- › Есть сжатие
- › Есть колоночное хранение
- › Самый быстрый вариант

- › Нет кластерного индекса
- › Не выдерживает большое количество join

Теория. Оптимизации в Anchor modeling

2019

II

- › Table join elimination
- › Merge join
- › Cluster index

Anchor Modeling

Якорное моделирование - это технология моделирования гибкой базы данных, подходящая для информации, которая со временем изменяется как по структуре, так и по содержанию.

Anchor

Anchor (Якорь) — это существительное, объект реального мира.

Anchor таблица должна хранить

- › Суррогатный ключ
- › Временная отметка даты загрузки

Tie

Tie (Связь) — это таблица для хранения связей между объектами.

У Tie не может быть атрибутов!

Attribute

Attribute (Атрибут) — это таблица для хранения свойства, атрибута объекта, при этом на каждое свойство ровно одна таблица.


Каждая Attribute-таблица содержит

- › Суррогатный ключ
- › Временная отметка даты загрузки
- › Непосредственно значение

Anchor Modeling


3NF

Surrogate key
Business keys
Foreign keys
Descriptors




Anchor Modeling

3NF	
Surrogate key	
Business keys	
Foreign keys	
Descriptors	





Anchor Modeling

3NF	
Surrogate key	
Business keys	
Foreign keys	
Descriptors	



Anchor Modeling



Три кита АМ




Table join elimination

Оптимизация, позволяющая исключить таблицу из плана запроса, если она не нужна

```
select A.colA
  from tableA  A
 left join tableB  B
    on B.id = A.id;
```

```
select A.colA
  from tableA  A
 left join tableC  C
    on C.id = A.id
 and C.fromDate = (
    select max(sub.fromDate)
      from tableC sub
     where sub.id = A.id );
```

Table join elimination


Оптимизация, позволяющая исключить таблицу из плана запроса, если она не нужна

Database Engine	Support	Example
Microsoft SQL Server 2005	full	SQL Server Example
Microsoft SQL Server 2008	full	SQL Server Example
Oracle 10gR2 Express Edition*	partial	Oracle Example
Oracle 11gR1 Enterprise/Express Edition	full	Oracle Example
IBM DB2 v9.5	full	IBM DB2 Example
PostgreSQL v8.4 beta	full	PostgreSQL Example
Teradata v12**	partial	Teradata Example
MySQL v5.0.70	none	MySQL Example
MySQL v6.0.10 alpha	none	MySQL Example
MariaDB v5.1	full	MariaDB Example
Sybase	not tested	


```
select A.colA
  from tableA  A
 left join tableC  C
    on C.id = A.id
 and C.fromDate = (
    select max(sub.fromDate)
      from tableC sub
    where sub.id = A.id );
```

Merge join


Nested Loop Join



Merge Join




Hash Join




Merge join




Nested Loop Join




Merge Join



Hash Join



Cluster index



Итого по теории

Вывод: технические сложности возможны, но принципиальный блокеров нет


Greenplum:

- › SN MPP RDBMS
- › Heap vs AO
- › ORCA vs Legacy

Anchor Modeling:


- › Merge join (legacy over heap)
- › Cluster index (heap)
- › Join elimination (postgres 8.4+)

Попытка #1. Эксперименты с Greenplum 5



- › Что могло пойти не так?
- › Как мы выкрутились?
- › Предпосылки hNhM


Три кита АМ



Сколько оптимизаций «из коробки» заработало в Greenplum 5?



Три кита



Существует в более
свежей версии PG
чем та, что в GP5

Отсутствует в ORCA

Работает только для
Heap, а не AO

MVP на GP5

Собираем MVP из того, что есть

- › GreenPlum 5
- › АО таблицы
- › Column oriented
- › Hash join
- › Оптимизации формирования запросов

MVP работает, жить можно – но на душе скребет, потому что не завелось идеально

Highly Normalized Hybrid Model (hNhM)

Ключевая идея: выбирать оптимальный формат хранения для каждого конкретного случая

Требования:

- › Разделение логического и физического моделирования
- › Возможность эмулировать как Data Vault, так и Anchor Modeling, высокая нормализация (вплоть до предельной 6НФ)
- › Параллельная загрузка из разных источников, идемпотентность при повторной загрузке
- › Устойчивость к изменению в бизнесе, модульность и масштабируемость
- › Удобство использования при построении витрин

Доступ к сущностям из Python

Было разработано несколько классов, которые позволяют сформировать SQL запрос к определенной сущности и затем использовать его в построении витрины

```
def load():
    department = HistoryEntityCte(Department).project(
        Department.department_id,
        Department.department_type,
        Department.description
    )
    person = ActualEntityCte(Person).project(
        Person.person_id,
        Person.gender,
        Person.tshirt_size,
        Person.is_robot_flg,
        staff_login=Person.login
    )
    link_person_department = ActualLinkCte(LinkPersonDepartment)
```



```
WITH department AS (
    {department}
), person AS (
    {person}
), link_person_department AS (
    {link_person_department}
)
SELECT *
FROM department d
    LEFT JOIN link_person_department lpdr
        ON d.id = lpdr.department
    LEFT JOIN person p
        ON p.id = lpdr.person
```

Первый опыт. Еда

В качестве первого проекта, выбрали Яндекс.Еда

Почему:

- › Достаточно большая, чтобы было интересно
- › Новый бизнес, источник может сильно меняться

Что получили:

- › ~ 25 сущностей (заказ, курьер, ресторан, промокоды, смена...)
- › 6 систем источников
- › 2 аналитические витрин
- › ETA – 40 минут от источника до финальных витрин



Загрузка данных Яндекс.Такси

Перевод основных расчетов Такси на новый детальный слой

Yandex Taxi

Что пошло не так:

- › Объем данных на порядок больше
- › Большая глубина обновления заказов

Что получили:

- › ~ 40 сущностей
- › Более 30 систем источников
- › Более 15 аналитических витрин
- › ETA – 2 часа от источника до финальных витрин

Итого по Попытке#1

«Из коробки» не завелось, но в ходе борьбы родился hNhM


Яндекс Еда:

- › ~ 25 сущностей (заказ, курьер, ресторан, промокоды, смена...)
- › 6 систем источников
- › 2 аналитические витрин
- › ETA – 40 минут от источника до финальных витрин


Яндекс Такси:

- › ~ 40 сущностей
- › Более 30 систем источников
- › Более 15 аналитических витрин
- › ETA – 2 часа от источника до финальных витрин

Прошло полгода...




... приехало новое железо и вышел GP6




Попытка #2.

Эксперименты с Greenplum 6



- › А теперь что могло пойти не так?
- › На какие жертвы мы готовы были идти?
- › Стоит ли повторять наш путь?


Три кита АМ



Сколько оптимизаций «из коробки» заработало в Greenplum 6?



Три кита



Версия PG более свежая,
но оптимизации GP
убили JE

Отсутствует в ORCA
(и не предвидится)

Работает только для
Heap, а не AO
(предвидится в GP7)

Варианты работы с GP

Legacy (old postgres)

Heap

- › Поддерживает все виды join
- › Есть кластерный индекс
- › Выдерживает любое количество join
- › Нет сжатия
- › Нет колоночного хранения

Append-optimized

- › Поддерживает все виды join
- › Есть сжатие
- › Есть колоночное хранение
- › Нет кластерного индекса
- › Не выдерживает большое количество join

ORCA

- › Есть кластерный индекс
- › Выдерживает любое количество join
- › Нет сжатия
- › Нет колоночного хранения
- › Нет merge join

- › Есть сжатие
- › Есть колоночное хранение
- › Самый быстрый вариант
- › Нет кластерного индекса
- › Не выдерживает большое количество join

У нас есть чистый кластер, почему бы не поэкспериментировать с heap?

Тесты на GP6

У нас есть чистый кластер, почему бы не поэкспериментировать с hear

Плюсы:

- › У hear есть кластерный индекс
- › Легаси оптимизатор выдает MergeJoin для hear (с нюансами)
- › Таблицы в АМ небольшие, поэтому колоночное хранение не нужно

Минусы:


- › У hear невозможно задать сжатие

Отсутствие сжатия покрываем файловой системой со сжатием BTFRS

Сколько оптимизаций «из коробки» заработало в сборке heap over BTFRS?



Все завелось!




Но есть нюансы...

Нюансы table elimination

Он как бы работает, но нет

- › Работает только с выключенной ORCA
- › Не работает на партицированных таблицах
- › Нужна PIT таблица



Нюансы merge join

Он как бы есть и даже шустрее, но его как бы нет

- › Работает только с выключенной ORCA
- › Нужно уменьшить random_page_cost
- › При больше 20 таблицах может рандомно покрашиться
- › Надо явно кластеризовать таблицу и обновлять статистику (GP любит сортировать, если что-то не понял)

Тип соединения	Время выполнения (с)
MERGE	17
HASH	13
MERGE CLUSTER INDEX	5

Рандомно покрашится ☹️ (слайд боли)

[XX000] ERROR: unrecognized path type: 106 (pathnode.c:216)

[XX000] ERROR: unrecognized path type: 106 (pathnode.c:216)

[XX000] ERROR: unrecognized path type: 106 (pathnode.c:216)

[XX000] ERROR: unrecognized path type: 106 (pathnode.c:216)

[XX000] ERROR: unrecognized path type: 106 (pathnode.c:216)

[XX000] ERROR: unrecognized path type: 106 (pathnode.c:216)


[XX000] ERROR: unrecognized path type: 106 (pathnode.c:216)

github.com

gpdb/pathnode.c at 6X_STABLE · greenplum-db/gpdb · GitHub

```
194
195
196
197
198
199
200
201
202
203
204
205
206
207
208
209
210
211
212
213
214
215
216
217
218
219
220
221
222
223
224
225
...
case T_NestLoop:
{
    NestPath *nestpath = (NestPath *)path;

    v = pathnode_walk_node(nestpath->outerjoinpath, walker, context);
    if (v != CdbVisit_Walk) /* stop */
        break;
    v = pathnode_walk_node(nestpath->innerjoinpath, walker, context);
    if (v != CdbVisit_Walk) /* stop */
        break;
}
break;
case T_Append:
    v = pathnode_walk_list(((AppendPath *)path)->subpaths, walker, context);
    break;
case T_MergeAppend:
    v = pathnode_walk_list(((MergeAppendPath *)path)->subpaths, walker, context);
    break;
case T_Material:
    v = pathnode_walk_node(((MaterialPath *)path)->subpath, walker, context);
    break;
case T_Unique:
    v = pathnode_walk_node(((UniquePath *)path)->subpath, walker, context);
    break;
case T_Motion:
    v = pathnode_walk_node(((CdbMotionPath *)path)->subpath, walker, context);
    break;
default:
    v = CdbVisit_Walk; /* keep compiler quiet */
    elog(ERROR, "unrecognized path type: %d", (int)path->pathtype);
}
return v;
}
/* pathnode_walk_kids */
```

2019

1

ERROR: unrecognized path type

2020

2


Изменение многих параметров

2021

3

Postgres query optimizer


Резюме



- › К чему мы пришли?
- › И что в итоге?

Все работает на MVP DDS

Динамика развития детального слоя



Итог

Разочарование

**Мы не завели на GP запросы
для AM в чистом виде**

- › Нет Join Elimination
- › Нет Merge join для ORCA
- › Нет Cluster Index для АО
- › Не работает на партицированных таблицах
- › Нужна PIT таблица
- › Нужно сжатие

Итог

Разочарование

Мы не завели на GP запросы для АМ в чистом виде

- › Нет Join Elimination
- › Нет Merge join для ORCA
- › Нет Cluster Index для АО
- › Не работает на партицированных таблицах
- › Нужна PIT таблица
- › Нужно сжатие

Принятие

hNhM (наша смесь DV и АМ) завелась и работает

- › 162 сущности
- › 1678 атрибутов
- › 306 линков

Итог

Разочарование

Мы не завели на GP запросы для AM в чистом виде

- › Нет Join Elimination
- › Нет Merge join для ORCA
- › Нет Cluster Index для АО
- › Не работает на партицированных таблицах
- › Нужна PIT таблица
- › Нужно сжатие

Принятие

hNhM (наша смесь DV и AM) завелась и работает

- › 162 сущности
- › 1678 атрибутов
- › 306 линков

Надежда

С выходом GP7 мы будем продолжать эксперименты

- › Cluster Index для АО
- › Отказ от ORCA в пользу legacy optimizer (которые перестанет быть легаси)
- › Или доработка merge join в ORCA (см последний GP meetup)
- › Свежие версии PG

Яндекс Такси

Спасибо

Евгений Ермаков

Руководитель DWH

 jkermakov@yandex-team.ru

 [@iJKos](https://t.me/iJKos)

iJKos.com

Николай Гребенщиков

Руководитель Data Engineer RideTech

 ngrbnshchkv@yandex-team.ru

 [@ngrebenshchikov](https://t.me/ngrebenshchikov)