

PGMeetup.PERM 2025

Превращаем Postgres в OLAP СУБД

Алексей Гордеев
R&D engineer



OLTP


Online Transaction Processing

Большое количество пользователей

Минимальное время отклика

Точечная обработка данных

Оптимизация выполнения
небольших запросов



OLAP

Online Analytical Processing


Меньшее количество пользователей

Большее время отклика

Пакетная обработка данных

Оптимизация выполнения больших запросов

Нужен ли Sharding?



OLAP в Postgres?

- **Формат хранения данных**

Используем подходящий для OLAP формат вместо heap

- **Проброс проекции**

Читаем только колонки, используемые в запросе

- **Проброс предикатов**

Используем условия фильтрации на уровне движка хранения

- **Пакетная вставка**

Реализуем преимущества нового формата данных

- **Resource manager**

Пишем в WAL новый формат данных

- **Поздняя материализация**

Достаём значения строки на поздних этапах выполнения запроса

- **Векторное выполнение запросов**

Обрабатываем по несколько строк за раз



Формат хранения данных

Строковое хранение

N-ary storage model, NSM

ID	Name	Birthdate
10	Ivan	14.08.1987
11	Peter	26.02.1984
12	Sidor	09.11.1995



heap1.dat

10	Ivan	14.08.1987	11
Peter	26.02.1984	...	...

heap2.dat

12	Sidor	09.11.1995	...
...	...	...	...

Колоночное хранение

Decomposition Storage Model, DSM

ID	Name	Birthdate
10	Ivan	14.08.1987
11	Peter	26.02.1984
12	Sidor	09.11.1995



column1.dat

10	11	12	...
----	----	----	-----

column2.dat

Ivan	Peter	Sidor	...
------	-------	-------	-----

column3.dat

14.08.1987	26.02.1984	09.11.1995	...
------------	------------	------------	-----

Partition Attributes Across

ID	Name	Birthdate
10	Ivan	14.08.1987
11	Peter	26.02.1984
12	Sidor	09.11.1995



pax1.dat

Group 1

10	11	...	...
Ivan	Peter	...	...
14.08.1987	26.02.1984	...	...

Group 2

12	...	...	...
Sidor	...	...	...
09.11.1995	...	...	...

Строки vs Колонки

Строки → OLTP

- SELECT одной строки
- DML одной строки

heap1.dat



10	Ivan	14.08.1987	11
Peter	26.02.1984	...	...

Колонки → OLAP

- Сжатие
- Чтение только используемых колонок (+ кэш)
- Векторное исполнение


Строки vs Колонки

Строки → OLTP

- SELECT одной строки
- DML одной строки

Колонки → OLAP

- Сжатие
- Чтение только используемых колонок (+ кэш)
- Векторное исполнение



Строки vs Колонки

Строки → OLTP

- SELECT одной строки
- DML одной строки

Колонки → OLAP

- Сжатие
- Чтение только используемых колонок (+ кэш)
- Векторное исполнение

column1.dat

10	11	12	...
----	----	----	-----

10 → 1000010
(1 million of sorted primary keys)

Delta Encoding


column1.dat

Start	Count	Delta
10	1000000	1

Строки vs Колонки

```
select max(birthdate) from users;
```

Проброс проекции



column1.dat

10	11	12	...
----	----	----	-----

column2.dat

Ivan	Peter	Sidor	...
------	-------	-------	-----

column3.dat

14.08.1987	26.02.1984	09.11.1995	...
------------	------------	------------	-----

Строки vs Колонки

Строки → OLTP

- SELECT одной строки
- DML одной строки

Колонки → OLAP

- Сжатие
- Чтение только используемых колонок (+ кэш)
- Векторное исполнение

column3.dat

10	11	12	...
----	----	----	-----



select max(birthdate) from users;



SIMD (single instruction, multiple data)


_mm512_max_epi32
(get max of 16 int32)

Строки → OLTP

- SELECT одной строки
- DML одной строки

Колонки → OLAP

- Сжатие
- Чтение только используемых колонок (+ кэш)
- Векторное исполнение



PAX

- Статистика и легковесные индексы (min/max, bloom)

select * from table where id = 50;

Проброс предикатов

min_id: 10; max_id:20;



Group 1

10	11	...	...
Ivan	Peter	...	...
14.08.1987	26.02.1984	...	...

Расширяем возможности Postgres

Postgres Extensions

1. Языки программирования

plpython, plperl, ...

2. Агрегатные функции

tdigest, hll, ...

3. Индексы

bloom, btree_gin, ...

4. Мониторинг и отладка

pg_stat_statements, auto_explain, ...

5. Табличные движки

citus_columnar, zheap, ...

6. Подключение

к внешним данным

mysql_fdw, file_fdw, ...

7. И многое другое

postgis, pgcrypto, citus, ...

```
postgres=# create extension bloom;
CREATE EXTENSION
postgres=# create table test_bloom(i int, j int);
CREATE TABLE
postgres=# insert into test_bloom select i, i from generate_series(0,100000) i;
INSERT 0 100001
postgres=# create index idx1_bloom on test_bloom using bloom(i, j);
CREATE INDEX
postgres=# explain (analyze, costs off) select * from test_bloom where i = 1000 and j = 1000;
              QUERY PLAN
-----
Bitmap Heap Scan on test_bloom (actual time=0.947..0.948 rows=1 loops=1)
  Recheck Cond: ((i = 1000) AND (j = 1000))
  Heap Blocks: exact=1
    -> Bitmap Index Scan on idx1_bloom (actual time=0.926..0.926 rows=1 loops=1)
          Index Cond: ((i = 1000) AND (j = 1000))
Planning Time: 0.268 ms
Execution Time: 0.979 ms
(7 rows)
```

Новый табличный движок

TableAmRoutine, 40+ функций

```
typedef struct TableAmRoutine
{
    NodeTag      type;

    const TupleTableSlotOps *(*slot_callbacks) (Relation rel);

    TableScanDesc (*scan_begin) (Relation rel,
                                  Snapshot snapshot,
                                  int nkeys, struct ScanKeyData *key,
                                  ParallelTableScanDesc pscan,
                                  uint32 flags);

    void          (*scan_end) (TableScanDesc scan);
    void          (*scan_rescan) (TableScanDesc scan, struct ScanKeyData *key,
                                   bool set_params, bool allow_strat,
                                   bool allow_sync, bool allow_pagemode);

    bool          (*scan_getnextslot) (TableScanDesc scan,
                                         ScanDirection direction,
                                         TupleTableSlot *slot);

    void          (*scan_set_tidrange) (TableScanDesc scan,
                                         ItemPointer mintid,
                                         ItemPointer maxtid);

    bool          (*scan_getnextslot_tidrange) (TableScanDesc scan,
```



Citus Columnar

Citus Columnar — расширение для Postgres, которое добавляет поддержку колоночного (PAX) хранения данных в таблицах.

Citus — расширение для Postgres, превращающее его в распределённую СУБД (шардированную кластерную систему).

Плюсы:

- Проброс проекции
- Проброс предикатов
- Сжатие

Минусы:

- Собственный формат данных
- Потенциал не раскрыть построчным экзекьютором Postgres

Другие движки:

- Greenplum AO (с патчами ядра)
- Timescale Hypertables
- Hydra (Citus Columnar fork)
- ZHeap (RIP)
- Zedstore (RIP)

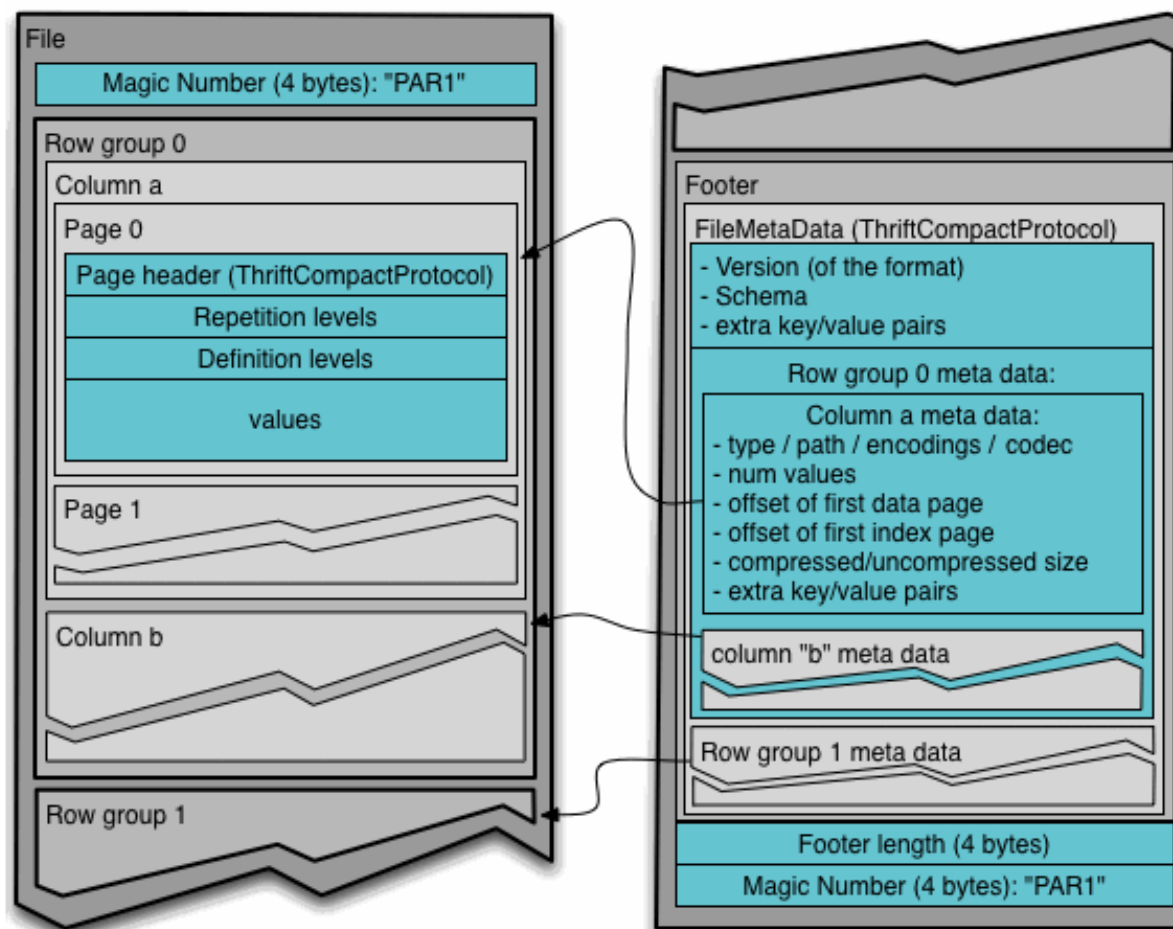
Parquet

Формат основанный на идеях PAX

Фичи:

- Compression (SNAPPY, GZIP, LZO, BROTLI, ZSTD, LZ4)
- Encoding (PLAIN/RLE_DICTIONARY, RLE, DELTA*, BYTE_STREAM_SPLIT)
- Checksumming
- MIN/MAX, bloom and others

Для работы с форматом внутри Postgres можно использовать libarrow



Проброс проекции

Нет проброса проекции

Список используемых колонок не передаётся в scan

```
329 | TableScanDesc (*scan_begin) (Relation rel,  
330 |                               Snapshot snapshot,  
331 |                               int nkeys, struct ScanKeyData *key,  
332 |                               ParallelTableScanDesc pscan,  
333 |                               uint32 flags);
```

«Bitmapset *attr_needed» ?



Проброс проекции через CustomScan

Методы CustomScan и CustomExec открывают доступ к большему числу структур ядра, в том числе к ScanState

```
explain select i from c_test where i = 1;
```

QUERY PLAN

Custom Scan (ColumnarScan) on c_test (cost=0.00..0.00 rows=1 width=4)

Filter: (i = 1)

Columnar Projected Columns: i

Columnar Chunk Group Filters: (i = 1)

(4 rows)

```
typedef struct CustomScan
{
    Scan        scan;
    uint32      flags;
    List        *custom_plans;
    List        *custom_exprs;
    List        *custom_private;
    List        *custom_scan_tlist;
    Bitmapset   *custom_relids;
    const struct CustomScanMethods *methods;
} CustomScan;
```

Проброс предикатов

Нет проброса предикатов


Проброс условий фильтрации только
внутри некоторых методов ядра и только
для условий AND

Для SeqScan отсутствует полностью

```
scandesc = table_beginscan(node->ss.ss_currentRelation,  
                           estate->es_snapshot,  
                           0, NULL);  
node->ss.ss_currentScanDesc = scandesc;
```

Robert Haas

```
TableScanDesc (*scan_begin) (Relation rel,  
                              Snapshot snapshot,  
                              int nkeys, struct ScanKeyData *key,  
                              ParallelTableScanDesc pscan,  
                              uint32 flags);
```

A blue arrow originates from the 'key' parameter in the 'table_beginscan' function call (specifically from the 'struct ScanKeyData *key' part) and points to the 'key' parameter in the 'scan_begin' function signature.

Проброс предикатов через CustomScan

Плюс/минус: ядро повторно проверит условия для строки из движка

```
explain select i from c_test where i = 1 and j is null;
```

QUERY PLAN


Custom Scan (ColumnarScan) on c_test (cost=0.00..0.00 rows=1 width=4)

Filter: ((j IS NULL) AND (i = 1))

Columnar Projected Columns: i, j

Columnar Chunk Group Filters: (i = 1)

(4 rows)



Пакетная вставка

Stateless Write

Нет методов begin и end

BEGIN?



```
/* see table_tuple_insert() for reference about parameters */  
void      (*tuple_insert) (Relation rel, TupleTableSlot *slot,  
                           CommandId cid, int options,  
                           struct BulkInsertStateData *bistate);
```



END?

Запись через буфер + Transaction Callback

Решение:

1. Хранить state в глобальной переменной
2. Освободить state при завершении транзакции

Плюсы:

1. Избегаем повторной инициализации
2. Буферизируем строки внутри транзакции на каждый INSERT. Записываем данные пакетно.

```
typedef void (*XactCallback) (XactEvent event, void *arg);
```

```
void  
RegisterXactCallback(XactCallback callback, void *arg)
```

```
typedef enum  
{  
    XACT_EVENT_COMMIT,  
    XACT_EVENT_PARALLEL_COMMIT,  
    XACT_EVENT_ABORT,  
    XACT_EVENT_PARALLEL_ABORT,  
    XACT_EVENT_PREPARE,  
    XACT_EVENT_PRE_COMMIT,  
    XACT_EVENT_PARALLEL_PRE_COMMIT,  
    XACT_EVENT_PRE_PREPARE,  
} XactEvent;
```

Resource manager

WAL. Generic XLog.

- Если формат укладывается в блоки
- Меньше кода
- Операции через буферный пул

```
/* API for construction of generic xlog records */
extern GenericXLogState *GenericXLogStart(Relation relation);
extern Page GenericXLogRegisterBuffer(GenericXLogState *state, Buffer buffer,
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |
int flags);
extern XLogRecPtr GenericXLogFinish(GenericXLogState *state);
extern void GenericXLogAbort(GenericXLogState *state);
```

WAL. Custom RMGR.

- Если формат не укладывается в блоки
- Больше возможностей
- Больше кода

```
typedef struct RmgrData
{
    const char *rm_name;
    void (*rm_redo) (XLogReaderState *record);
    void (*rm_desc) (StringInfo buf, XLogReaderState *record);
    const char *(*rm_identify) (uint8 info);
    void (*rm_startup) (void);
    void (*rm_cleanup) (void);
    void (*rm_mask) (char *pagedata, BlockNumber blkno);
    void (*rm_decode) (struct LogicalDecodingContext *ctx,
                       struct XLogRecordBuffer *buf);
} RmgrData;
```

Поздняя материализация

Нет поздней материализации

```
explain (analyze, verbose, costs off) select t0.j
from (
  select i, j
  from test0
  where exists (select 1 from test1 where test0.i=test1.k)
) t0
offset 1000000 limit 10;
```

```
Limit (actual time=11660.533..11660.540 rows=10 loops=1)
  Output: test0.j
    -> Hash Semi Join (actual time=516.460..11621.005 rows=1000010 loops=1)
      Output: test0.j
      Hash Cond: (test0.i = test1.k)
        -> Seq Scan on public.test0 (actual time=0.016..4427.402 rows=30100000 loops=1)
          Output: test0.j, test0.i
        -> Hash (actual time=516.134..516.134 rows=2020000 loops=1)
          Output: test1.k
          Buckets: 262144 Batches: 16 Memory Usage: 6492kB
          -> Seq Scan on public.test1 (actual time=0.010..198.298 rows=2020000 loops=1)
            Output: test1.k

Planning Time: 0.162 ms
Execution Time: 11755.489 ms
(14 rows)
```

А используем только 10

Достали миллионы значений из столбца j

Поздняя материализация в Postgres

Есть 2 решения

~~Патчи~~ ПАТЧИ в ядро

Сторонний executor
(самописный или готовый)


Векторное выполнение запросов

Нет векторизации

Per tuple execution



Vectorized execution



Нет векторизации

```
postgres=# explain
select sum(test1.i + test2.i)
from test1 join test2 on test1.j = test2.j
where test1.i > 10
and test2.i > 100;
```

QUERY PLAN

```
Aggregate (cost=6508.28..6508.29 rows=1 width=8)
↑ -> Hash Join (cost=2941.85..6008.80 rows=99897 width=8)
    ↑
    ↑ Hash Cond: (test1.j = test2.j)
    -> Seq Scan on test1 (cost=0.00..1693.01 rows=99991 width=8)
        Filter: (i > 10)
    -> Hash (cost=1693.01..1693.01 rows=99907 width=8)
        -> Seq Scan on test2 (cost=0.00..1693.01 rows=99907 width=8)
            Filter: (i > 100)
(8 rows)
```

Векторное выполнение в Postgres

Есть 2 решения

Еще ПАТЧИ в ядро




Сторонний executor
(самописный или готовый)

Сторонний исполнитель. Duck Tales.


DuckDB is an analytical in-process SQL database management system.

pg_duckdb is a Postgres extension that embeds DuckDB's columnar-vectorized analytics engine and features into Postgres.



Сторонний исполнитель. Planner Hook.

```
/* Hook for plugins to get control in planner() */  
Fujii Masao, 5 years ago | 2 authors (Tom Lane and one other)  
typedef PlannedStmt *(*planner_hook_type) (Query *parse,  
                                             const char *query_string,  
                                             int cursorOptions,  
                                             ParamListInfo boundParams);  
extern PGDLLIMPORT planner_hook_type planner_hook;
```





DuckDB + Parquet + Postgres

```
explain select watchid
from hits
where watchid not in (select i from test_heap);
```

Core code

libduckdb.so



OLAP в Postgres!

- **Формат хранения данных**

Parquet через libarrow -> TableAmRoutine

- **Проброс проекции**

Для стандартного исполнителя через CustomScan

- **Проброс предикатов**

Для стандартного исполнителя через CustomScan

- **Пакетная вставка**

State + Buffer + Transaction Callback

- **Resource manager**

Custom RMGR – пишем Parquet

- **Поздняя материализация**

Не поддерживается в DuckDB при работе с parquet, да и...




- **Векторное выполнение запросов**


DuckDB (+ проброс проекции и предикатов)



pgpro_tam. Extension for vanilla Postgres.



pgpro_tam. Universal analytic engine.



Benchmarks

pgpro_tam. ClickBench. Hot run.

ClickHouse ☁ (azure) (3×120GiB):		x5.42
ClickHouse ☁ (aws) (2×64GiB):		x5.50
SingleStore (S24)†:		x5.50
ClickHouse (web) (c6a.4xlarge):		x5.55
MotherDuck (Standard):		x5.62
ClickHouse (c6a.4xlarge):		x5.64
ClickHouse ☁ (azure) (2×64GiB):		x5.77
DuckDB (Parquet, partitioned) (c6a.4xlarge):		x6.21
chDB (DataFrame) (c6a.metal):		x6.22
ClickHouse ☁ (gcp) (3×64GiB):		x6.33
chDB (c6a.4xlarge):		x6.50
Firebolt (c6a.4xlarge):		x6.59
ClickHouse ☁ (gcp) (2×64GiB):		x6.70
Crunchy Bridge (Parquet) (Analytics-256GB):		x6.74
ClickHouse ☁ (azure) (3×64GiB):		x6.97
QuestDB (c6a.4xlarge):		x7.53
DuckDB (Vortex, partitioned) (c6a.4xlarge):		x7.81
chDB (Parquet, partitioned) (c6a.metal):		x7.83
DuckDB (memory) (c6a.4xlarge):		x7.89
Snowflake (64×3XL):		x8.03
Databend (c6a.4xlarge):		x8.03
pgpro_tam (parquet, local + cache) (c6a.metal):		x8.11
pgpro_tam (parquet, local storage) (c6a.metal):		x8.19
Snowflake (32×2XL):		x8.34
ClickHouse ☁ (aws) (2×32GiB):		x8.36
Apache Doris (c6a.4xlarge):		x8.41
ClickHouse ☁ (aws) (3×32GiB):		x8.58
ClickHouse ☁ (gcp) (2×32GiB):		x8.64

63 из ~210

Umbra (c6a.metal):		x1.22
CedarDB (c6a.metal):		x1.67
Hologres (8×16 CU):		x2.23
Firebolt (c6a.metal):		x2.49
Umbra (c6a.4xlarge):		x2.88
Hologres (4×16 CU):		x2.96
CedarDB (c6a.4xlarge):		x3.05
pg_duckdb (MotherDuck enabled) (Jumbo):		x3.48
Hologres (2×16 CU):		x4.15
Hydra (XL):		x4.65
Firebolt (c6a.4xlarge):		x6.21
Crunchy Bridge (Parquet) (Analytics-256GB):		x6.35
pgpro_tam (parquet, local + cache) (c6a.metal):		x7.65
pgpro_tam (parquet, local storage) (c6a.metal):		x7.72
Tablespace (L1 - 16CPU 32GB):		x8.92

TimescaleDB (c6a.4xlarge):		x35.23
Timescale ☁ (16 vCPU 64GB):		x44.30
Cloudberry (c6a.4xlarge)†:		x45.63
Greenplum (c6a.4xlarge):		x48.36
Timescale ☁ (8 vCPU 32GB):		x62.03
Timescale ☁ (4 vCPU 16GB):		x78.43
Citus (c6a.4xlarge):		x319.67
TimescaleDB (no columnstore) (c6a.4xlarge):		x1008.71
PostgreSQL (c6a.4xlarge):		x6052.62

13 из ~42 (Postgres compatible)

pgpro_tam. ClickBench. Cold run.

ClickHouse (TCHouse-C) (c6a.metal):		x9.26
ClickHouse ☁ (azure) (2x120GiB):		x9.31
ClickHouse ☁ (aws) (3x64GiB):		x9.40
ClickHouse ☁ (gcp) (2x64GiB):		x9.41
Umbra (c6a.4xlarge):		x9.61
ClickHouse ☁ (gcp) (3x120GiB):		x9.78
StarRocks (c6a.metal):		x9.97
Snowflake (64x3XL):		x9.97
Snowflake (32x2XL):		x10.08
ClickHouse ☁ (azure) (2x64GiB):		x10.34
ClickHouse ☁ (azure) (3x120GiB):		x10.64
ClickHouse ☁ (gcp) (3x64GiB):		x11.25
YDB (3x64 vCPU 256GB):		x11.44
ClickHouse ☁ (aws) (2x32GiB):		x11.46
Hydra (XL):		x11.71
CHYT (9x10 vCPU 40GB):		x11.72
Snowflake (16xXL):		x11.75
Snowflake (128x4XL):		x11.81
ClickHouse (web) (c6a.metal):		x11.82
ByteHouse (8xL):		x12.06
pgpro_tam (parquet, local + cache) (16 vCPU 32GB):		x12.59
pgpro_tam (parquet, local storage) (16 vCPU 32GB):		x13.39
Ursa (c6a.metal):		x13.62
Hologres (2x16 CU):		x13.76
Ursa (c6a.4xlarge):		x13.82
Crunchy Bridge (Parquet) (Analytics-256GB):		x14.05

41 из ~210

Umbra (c6a.metal):		x1.10
CedarDB (c6a.metal):		x1.51
Hologres (8x16 CU):		x5.30
CedarDB (c6a.4xlarge):		x7.02
pg_duckdb (MotherDuck enabled) (Jumbo):		x7.25
Hologres (4x16 CU):		x7.50
Umbra (c6a.4xlarge):		x7.88
Hydra (XL):		x9.60
pgpro_tam (parquet, local + cache) (16 vCPU 32GB):		x10.32
pgpro_tam (parquet, local storage) (16 vCPU 32GB):		x10.98
Hologres (2x16 CU):		x11.29
Crunchy Bridge (Parquet) (Analytics-256GB):		x11.52

Timescale ☁ (16 vCPU 64GB):		x38.20
Cloudberry (c6a.4xlarge)†:		x51.58
Greenplum (c6a.4xlarge):		x53.27
Timescale ☁ (8 vCPU 32GB):		x67.13
TimescaleDB (c6a.4xlarge):		x105.69
Timescale ☁ (4 vCPU 16GB):		x142.75
Citus (c6a.4xlarge):		x374.48
TimescaleDB (no columnstore) (c6a.4xlarge):		x962.69
PostgreSQL (c6a.4xlarge):		x5280.49

9 из ~42 (Postgres compatible)


pgpro_tam. ClickBench. Storage Size.

Bigquery (serverless):	8.16 GiB (x1.00)
pgpro_tam (parquet, local, parallel) (16 vCPU 32GB):	8.66 GiB (x1.06)
pgpro_tam (parquet, local, parallel) (c6a.metal):	8.66 GiB (x1.06)
pgpro_tam (parquet, local + cache) (c6a.metal):	9.01 GiB (x1.10)
pgpro_tam (parquet, local storage) (16 vCPU 32GB):	9.03 GiB (x1.11)
pgpro_tam (c6a.4xlarge):	9.03 GiB (x1.11)
pgpro_tam (parquet, local + cache) (16 vCPU 32GB):	9.03 GiB (x1.11)
pgpro_tam (parquet, local storage) (c6a.metal):	9.03 GiB (x1.11)
ClickHouse ☁ (gcp) (3×16GiB):	9.26 GiB (x1.13)
ClickHouse ☁ (aws) (12GiB):	9.26 GiB (x1.13)
ClickHouse ☁ (azure) (2×12GiB):	9.26 GiB (x1.13)
ClickHouse ☁ (aws) (3×12GiB):	9.26 GiB (x1.13)
AlloyDB (16 vCPU 128GB):	9.26 GiB (x1.13)
AlloyDB (8 vCPU 64GB):	9.26 GiB (x1.13)
ClickHouse ☁ (azure) (3×16GiB):	9.26 GiB (x1.13)
ClickHouse ☁ (gcp) (12GiB):	9.26 GiB (x1.13)
ClickHouse ☁ (aws) (3×16GiB):	9.26 GiB (x1.13)
ClickHouse ☁ (azure) (12GiB):	9.26 GiB (x1.13)
ClickHouse ☁ (azure) (2×16GiB):	9.26 GiB (x1.13)
ClickHouse ☁ (aws) (2×12GiB):	9.26 GiB (x1.13)
ClickHouse ☁ (gcp) (2×12GiB):	9.26 GiB (x1.13)
ClickHouse ☁ (aws) (8GiB):	9.26 GiB (x1.14)
ClickHouse ☁ (gcp) (2×16GiB):	9.26 GiB (x1.14)


pgpro_tam. TPC-H. Native formats.

Scale = 5000. 5.8TB CSV. 30 cores. 480GB RAM. Timeout = 1h.

Average




Median




pgpro_tam. TPC-H. Parquet.

Scale = 5000. 5.8TB CSV. 30 cores. 480GB RAM. Timeout = 1h.

Average




Median




pgpro_tam. TPC-H. Heap.

Scale = 500. 540GB CSV. 30 cores. 480GB RAM. Timeout = 1h.

Average



Median





DuckDB

42,443 followers

3mo •

✓ Following ...

📈 How large can DuckDB scale with its out-of-core capabilities?

We have been testing DuckDB with the TPC-H queries on increasingly large scale factors and found that all 22 queries completed on the scale factor 100 000 data set – equivalent to 100 TB in CSV format – on a single AWS EC2 instance. The queries were executed without any manual query optimization.



TPC-H queries with DuckDB v1.2.2

SF 1 000



Raspberry Pi
16 GB RAM

SF 10 000



MacBook Pro
128 GB RAM

SF 100 000



EC2 i7ie.48xlarge
1.5 TB RAM

Итоги

Аналитика в Postgres?

Формат хранения данных


Колонки, RAХ

Вычитывание меньшего количества данных

Пробросы, поздняя материализация

Запись в WAL различных форматов

Встраивание стороннего исполнителя



Расширяемость Postgres

API, Hook, Callback, CustomScan

Аналитика в Postgres!

Без модификаций ядра

Не ломая user experience

Используя ту же инфраструктуру

На уровне других аналитических решений

Single instance

Итоги

Аналитика в Postgres?

Формат хранения данных

Колонки, PAX

Вычитывание меньшего количества данных

Пробросы, поздняя материализация

Запись в WAL различных форматов

Встраивание стороннего исполнителя



Расширяемость Postgres

API, Hook, Callback, CustomScan

Аналитика в Postgres!

Без модификаций ядра

Не ломая user experience

Используя ту же инфраструктуру

На уровне других аналитических решений

Single instance

Q&A

Алексей Гордеев

a.gordeev@postgrespro.ru
@innerlife0



pgpro_tam docker image:
https://hub.docker.com/r/innerlife/pgpro_tam