


Слоник, который смог в ZFS

Артём Свяжин





Давайте познакомимся

- 8 лет опыта администрирования и разработки в различных высоконагруженных СУБД в т.ч. PostgreSQL
- Почти 14 лет опыта программирования на разных языках
- 8 лет опыта администрирования и разработки в UNIX операционных системах
- Опыт технической экспертизы 1с
- Нет ничего невозможного - девиз

Сима-ленд — это крупнейшая в России оптовая компания, созданная в 2000 году

Мы продаём товары для дома, работы и
отдыха.

Наши клиенты: мелкие и крупные оптовики,
торговые сети и простые розничные
покупатели.



Более 40TB

Суммарный объем БД

8TB

Объем основной БД

450+ чел

Сотрудников IT
департамента

75K TPS

На самой главной БД

Более 100

Серверов СУБД Postgres

900

Микросервисов в k8s

План презентации

1

Причины перехода на ZFS

2

Тернистый путь перехода на COW

3

Теоретическая часть

4

Схема как оно работает у нас и нюансы
настройки ZFS

5

Экспериментальная часть и выводы

1

Большое количество машин в ЦОД

**Проблемы
которые нас
привели к COW
вследствие
большого роста
компании**

**Проблемы
которые нас
привели к COW
вследствие
большого роста
компании**

1

Большое количество машин в ЦОД

2

Необходимость большого дискового пространства (дисков)

Проблемы которые нас привели к COW вследствие большого роста компании

1

Большое количество машин в ЦОД

2

Необходимость большого дискового пространства (дисков)

3

Требуемое время на восстановление для каждой машины

Проблемы которые нас привели к COW вследствие большого роста компании

1

Большое количество машин в ЦОД

2

Необходимость большого дискового пространства (дисков)

3

Требуемое время на восстановление для каждой машины

4

Снижение скорости и качества тестирования кода

Проблемы которые нас привели к COW вследствие большого роста компании

1

Большое количество машин в ЦОД

2

Необходимость большого дискового пространства (дисков)

3

Требуемое время на восстановление для каждой машины

4

Снижение скорости и качества тестирования кода


5

неудобство и неуправляемость


Как мы
сдружились с
COW?




Первоначально схема с
тестовыми контурами
выглядела так




Далее произошла
модификация пришли к
COW btrfs



Убрали сетевые задержки ISCSI перешли на MSSQL on linux



Почему бы не сделать с
postgresql?



ZFS vs BTRFS



ZFS – COW?

- Read-Modify-Write: прочесть весь экстенд (Read), изменить его в середине (Modify), просчитать новую контрольную сумму и выполнить запись экстенда целиком (Write).
- Redirect-Write: данные экстенда записываются в новое (пустое) место, и затем в метаданные производится атомарная запись, включающая в себя новую контрольную сумму и новое расположение экстенда. А старое место где данные экстенда лежали раньше, помечается как свободное.

1

относительная производительность
по сравнению с другими CoW fs

Почему же все-таки



?

1

относительная производительность
по сравнению с другими CoW fs

2

умеет в блочные устройства

Почему же все-таки



?

Почему же все-таки



1

относительная производительность
по сравнению с другими CoW fs

2

умеет в блочные устройства

3

быстрое создание и удаление
снапшотов данных

Почему же все-таки



1

относительная производительность
по сравнению с другими CoW fs

2

умеет в блочные устройства

3

быстрое создание и удаление
снапшотов данных

4

есть кэш в оперативной памяти

Почему же все-таки



1

относительная производительность
по сравнению с другими CoW fs

2

умеет в блочные устройства

3

быстрое создание и удаление
снапшотов данных

4

есть кэш в оперативной памяти

5

RMW + RW

Но есть и минусы



1

надо больше оперативной памяти

2

отдельный диск под журналы

3


резервирование свободного места на диске

Перейдем к практическому
применению совместно с




PostgreSQL

**СЛОНЫ НИКОГДА
НЕ ЗАБЫВАЮТ**




**И ОНИ НИЧЕГО
НЕ ПРОЩАЮТ**


Схема, как оно работает у нас




Схема, как оно работает у нас




Схема, как оно работает у нас



Схема, как оно работает у нас



Схема, как оно работает у нас



Настройка zfs и zpool

- По умолчанию zfs забирает **50%** объема доступной оперативной памяти. Поэтому необходимо вычислить нужный объем ARC кэша для текущего пула по формуле $1\text{GB} + (4\text{GB} * \text{на каждый 1TB из ZPOOL})$

```
root@zfstest:/# echo "options zfs zfs_arc_min=4294967296" > /etc/modprobe.d/zfs.conf  
root@zfstest:/# echo "options zfs zfs_arc_max=8589934592" >> /etc/modprobe.d/zfs.conf
```

Настройка zfs и zpool

- По умолчанию zfs забирает **50%** объема доступной оперативной памяти. Поэтому необходимо вычислить нужный объем ARC кэша для текущего пула по формуле $1\text{GB} + (4\text{GB} * \text{на каждый 1TB из ZPOOL})$

```
root@zfstest:/# echo "options zfs zfs_arc_min=4294967296" > /etc/modprobe.d/zfs.conf
root@zfstest:/# echo "options zfs zfs_arc_max=8589934592" >> /etc/modprobe.d/zfs.conf
```

- По умолчанию zfs размечает ZIL на одно блочное устройство с zpool. Так как ZIL это журнал намерений, то для снижения нагрузки ввода — вывода на zpool рекомендуется выделить отдельный диск и разметить на него ZIL.

Настройка zfs и zpool

- По умолчанию zfs забирает **50%** объема доступной оперативной памяти. Поэтому необходимо вычислить нужный объем ARC кэша для текущего пула по формуле $1\text{GB} + (4\text{GB} * \text{на каждый 1TB из ZPOOL})$

```
root@zfstest:/# echo "options zfs zfs_arc_min=4294967296" > /etc/modprobe.d/zfs.conf  
root@zfstest:/# echo "options zfs zfs_arc_max=8589934592" >> /etc/modprobe.d/zfs.conf
```

- По умолчанию zfs размечает ZIL на одно блочное устройство с zpool. Так как ZIL это журнал намерений, то для снижения нагрузки ввода — вывода на zpool рекомендуется выделить отдельный диск и разметить на него ZIL.

- По умолчанию ZFS выделяет блоки динамически от 512 до 16M, т.к. postgres оперирует страницами размером 8k, то рекомендуется для получения большего кол-ва TPS «жестко» задать параметр выделения блоков соответствующим размером

```
zfs set recordsize="8k" origin
```

В эфире рубрика ээээээээксперименты



Этапы тестирования

1

Создание snapshot с реплики

2

Вставка данных в первичный сервер и snapshot, оценка результата влияния на snapshot и реплику

3

Удаление данных в реплике и snapshot соответственно, оценка влияния на snapshot и реплику

4

ANALYZE на snapshot

5

VACUUM на snapshot

6

Вывод, заключение

Создание снелшота с реплики

```
zfs snapshot origin/postgres@postgres_snap1  
zfs clone origin/postgres@postgres_snap1 origin/postgres_snap1
```

Создание снапшота с реплики

```
zfs snapshot origin/postgres@postgres_snap1  
zfs clone origin/postgres@postgres_snap1 origin/postgres_snap1
```

Далее необходимо запустить docker контейнер и сделать pg_promote

```
docker-compose --compatibility -f docker-compose.yml  
"exec" -u postgres dbtest psql -d postgres -c "SELECT  
pg_promote();" 
```

Выполнение команды pg_promote после запуска контейнера

```
version: '3.1'  
  
services:  
  
  temchik:  
    image: postgres:15.5-bookworm  
    restart: always  
    shm_size: "2gb"  
    ports:  
      - "5434:5432"  
    environment:  
      PGDATA: /postgres  
    volumes:  
      - /origin/postgres_snap1:/postgres  
      - /docker-pg/postgresql.conf:/postgres/postgresql.conf  
      - /docker-pg/pg_hba.conf:/postgres/pg_hba.conf  
      - /docker-pg/pg_ident.conf:/postgres/pg_ident.conf
```

Docker-compose.yml

График изменения размера реплики




График изменения размера снимота




График изменения размера реплики






График изменения размера снимота



Удаление данных с реплики

```
DELETE FROM boarding_passes;
```



Удаление данных с реплики

```
DELETE FROM boarding_passes;
```



Почему так? Удаление данных приводит к росту?

Объяснение кроется после удаления зависимого snapshot реплики



NAME	USED	AVAIL	REFER
origin	5.35G	187G	26K
origin/postgres	5.31G	187G	3.22G
origin/postgres_snap1	17.7M	187G	2.83G


удаление зависимого snapshot реплики

```
zfs destroy -r origin/postgres@postgre_snap1
```

NAME	USED	AVAIL	REFER
origin	3.21G	190G	26K
origin/postgres	3.22G	190G	3.20G

Удаление данных в снапшоте

```
DELETE FROM boarding_passes;
```



Удаление данных в снапшоте

```
DELETE FROM boarding_passes;
```



Опять удаление и опять рост, но в данном случае в снапшоте почему так?

```
demo=# select pg_size_pretty(pg_total_relation_size('boarding_passes'::regclass));  
pg_size_pretty  
-----  
1102 MB
```

Все блоки были изменены которые касались данной таблицы включая индексы и TOAST + кусок wal

ANALYZE

Исходный размер снимота

NAME	USED	AVAIL	REFER
origin	3.66G	189G	26K
origin/postgres	3.63G	189G	3.63G
origin/postgres_snap1	16.6M	189G	2.83G

ANALYZE boarding_passes;



ANALYZE

Исходный размер снимота

NAME	USED	AVAIL	REFER
origin	3.66G	189G	26K
origin/postgres	3.63G	189G	3.63G
origin/postgres_snap1	16.6M	189G	2.83G

ANALYZE boarding_passes;



ANALYZE

Видим рост почему так? Всеу виной реплика и promote?
Для того чтобы разобраться создадим еще 1 snapshot и
запромоутиим его

NAME	USED	AVAIL	REFER	MOUNTPPOINT
origin	3.92G	189G	26K	/origin
origin/postgres	3.63G	189G	3.63G	/origin/postgres
origin/postgres_snap1	256M	189G	2.83G	/origin/postgres_snap1
origin/postgres_snap2	16.6M	189G	2.83G	/origin/postgres_snap2

ANALYZE

Видим рост почему так? Всему виной реплика и promote?
Для того чтобы разобраться создадим еще 1 snapshot и
запромоутиим его

NAME	USED	AVAIL	REFER	MOUNTPPOINT
origin	3.92G	189G	26K	/origin
origin/postgres	3.63G	189G	3.63G	/origin/postgres
origin/postgres_snap1	256M	189G	2.83G	/origin/postgres_snap1
origin/postgres_snap2	16.6M	189G	2.83G	/origin/postgres_snap2

Получим путь таблицы в файловой системе

```
root@zfstest:/docker-pg# psql -p 5433 -U postgres -h localhost -d demo -c "SELECT
pg_relation_filepath ('boarding_passes')
pg_relation_filepath
-----
base/25293/25316
(1 row)
```

ANALYZE

Воспользуемся утилитой bindiff чтобы понять размер различных блоков в этом бинарном файле

<https://www.dr-lex.be/software/bindiff.html>

```
./bindiff -b 8192 -t /origin/postgres_snap2/base/25293/25316  
/origin/postgres_snap1/base/25293/25316
```

Где -b block size в zfs pool или zvol

Total size of differing blocks: **245760000B**

Собственно получаем логичную картину.
Но что же поменялось в самих
страницах при выполнении **ANALYZE**

ANALYZE

Воспользуемся утилитой bindiff чтобы понять размер различных блоков в этом бинарном файле

<https://www.dr-lex.be/software/bindiff.html>

```
./bindiff -b 8192 -t /origin/postgres_snap2/base/25293/25316  
/origin/postgres_snap1/base/25293/25316
```

Где -b block size в zfs pool или zvol

Total size of differing blocks: **245760000B**

Собственно получаем логичную картину.
Но что же поменялось в самих
страницах при выполнении **ANALYZE**

```
cmp -1 /origin/postgres_snap2/base/25293/25316 /origin/postgres_snap1/base/25293/25316 |  
gawk '(printf "408X %02X %02X\n", $1-1, strtonum(0$2), strtonum (0$3))'
```

```
1C74BEC5 08 09  
1C74BEFD 08 09  
1C748F35 08 09  
1C74BF6D 08 09  
1C74DFDD 08 09
```

Поменялось по 1байту в определенных позициях файла.
До сих пор непонятно что меняет **ANALYZE** в самих страницах.
Нам поможет расширение pageinspect

ANALYZE

Запрос на snapshot1 с ANALYZE

```
demo=# SELECT t_infomask, t_infomask2, raw_flags, combined_flags
FROM heap_page_items (get_raw_page( 'boarding_passes', 0)),
LATERAL heap_tuple_infomask_flags(t_infomask, t_infomask2) limit 10;
```

t_infomask	t_infomask 2	raw_flags	combined_flags
2306	4	{HEAP_HASVARWIDTH, HEAP_XMIN_COMMITTED, HEAP_XMAX_INVALID}	{}
2306	4	{HEAP_HASVARWIDTH, HEAP_XMIN_COMMITTED, HEAP_XMAX_INVALID}	{}
2306	4	{HEAP_HASVARWIDTH, HEAP_XMIN_COMMITTED, HEAP_XMAX_INVALID}	{}

Запрос на snapshot2 без ANALYZE

t_infomask	t_infomask 2	raw_flags	combined_flags
2050	4	{HEAP_HASVARWIDTH, HEAP_XMAX_INVALID}	{}
2050	4	{HEAP_HASVARWIDTH, HEAP_XMAX_INVALID}	{}
2050	4	{HEAP_HASVARWIDTH, HEAP_XMAX_INVALID}	{}

ANALYZE

Запрос на snapshot1 с ANALYZE

```
demo=# SELECT t_infomask, t_infomask2, raw_flags, combined_flags
FROM heap_page_items (get_raw_page( 'boarding_passes', 0)),
LATERAL heap_tuple_infomask_flags(t_infomask, t_infomask2) limit 10;
```

t_infomask	t_infomask 2	raw_flags	combined_flags
2306	4	{HEAP_HASVARWIDTH, HEAP_XMIN_COMMITTED , HEAP_XMAX_INVALID}	{}
2306	4	{HEAP_HASVARWIDTH, HEAP_XMIN_COMMITTED , HEAP_XMAX_INVALID}	{}
2306	4	{HEAP_HASVARWIDTH, HEAP_XMIN_COMMITTED , HEAP_XMAX_INVALID}	{}

Запрос на snapshot2 без ANALYZE

t_infomask	t_infomask 2	raw_flags	combined_flags
2050	4	{HEAP_HASVARWIDTH, HEAP_XMAX_INVALID}	{}
2050	4	{HEAP_HASVARWIDTH, HEAP_XMAX_INVALID}	{}
2050	4	{HEAP_HASVARWIDTH, HEAP_XMAX_INVALID}	{}

[postgres/src/include/access/htup_details.h](#)

```
204     #define HEAP_XMIN_COMMITTED      0x0100  /* t_xmin committed */
205     #define HEAP_XMIN_INVALID        0x0200  /* t_xmin invalid/aborted */
206     #define HEAP_XMIN_FROZEN         (HEAP_XMIN_COMMITTED|HEAP_XMIN_INVALID)
207     #define HEAP_XMAX_COMMITTED      0x0400  /* t_xmax committed */
```

VACUUM

Исходный размер

NAME	USED	AVAIL	REFER	MOUNTPPOINT
origin	3.92G	189G	26K	/origin
origin/postgres	3.63G	189G	3.63G	/origin/postgres
origin/postgres_snap1	370M	189G	2.83G	/origin/postgres_snap1
origin/postgres_snap2	16.6M	189G	2.83G	/origin/postgres_snap2

```
DELETE FROM boarding_passes;
```

Размер после удаления

NAME	USED	AVAIL	REFER	MOUNTPPOINT
origin	3.92G	189G	26K	/origin
origin/postgres	3.63G	189G	3.63G	/origin/postgres
origin/postgres_snap1	1.35G	189G	2.83G	/origin/postgres_snap1
origin/postgres_snap2	16.6M	189G	2.83G	/origin/postgres_snap2

Размер после VACUUM

NAME	USED	AVAIL	REFER	MOUNTPPOINT
origin	3.92G	189G	26K	/origin
origin/postgres	3.63G	189G	3.63G	/origin/postgres
origin/postgres_snap1	1.16G	189G	3.20G	/origin/postgres_snap1
origin/postgres_snap2	16.6M	189G	2.83G	/origin/postgres_snap2

VACUUM

Исходный размер

NAME	USED	AVAIL	REFER	MOUNTPPOINT
origin	3.92G	189G	26K	/origin
origin/postgres	3.63G	189G	3.63G	/origin/postgres
origin/postgres_snap1	370M	189G	2.83G	/origin/postgres_snap1
origin/postgres_snap2	16.6M	189G	2.83G	/origin/postgres_snap2

```
DELETE FROM boarding_passes;
```

Размер после удаления

NAME	USED	AVAIL	REFER	MOUNTPPOINT
origin	3.92G	189G	26K	/origin
origin/postgres	3.63G	189G	3.63G	/origin/postgres
origin/postgres_snap1	1.35G	189G	2.83G	/origin/postgres_snap1
origin/postgres_snap2	16.6M	189G	2.83G	/origin/postgres_snap2

Размер после VACUUM

NAME	USED	AVAIL	REFER	MOUNTPPOINT
origin	3.92G	189G	26K	/origin
origin/postgres	3.63G	189G	3.63G	/origin/postgres
origin/postgres_snap1	1.16G	189G	3.20G	/origin/postgres_snap1
origin/postgres_snap2	16.6M	189G	2.83G	/origin/postgres_snap2

VACUUM

Исходный размер

NAME	USED	AVAIL	REFER	MOUNTPPOINT
origin	3.92G	189G	26K	/origin
origin/postgres	3.63G	189G	3.63G	/origin/postgres
origin/postgres_snap1	370M	189G	2.83G	/origin/postgres_snap1
origin/postgres_snap2	16.6M	189G	2.83G	/origin/postgres_snap2

```
DELETE FROM boarding_passes;
```

Размер после удаления

NAME	USED	AVAIL	REFER	MOUNTPPOINT
origin	3.92G	189G	26K	/origin
origin/postgres	3.63G	189G	3.63G	/origin/postgres
origin/postgres_snap1	1.35G	189G	2.83G	/origin/postgres_snap1
origin/postgres_snap2	16.6M	189G	2.83G	/origin/postgres_snap2

Размер после VACUUM

NAME	USED	AVAIL	REFER	MOUNTPPOINT
origin	3.92G	189G	26K	/origin
origin/postgres	3.63G	189G	3.63G	/origin/postgres
origin/postgres_snap1	1.16G	189G	3.20G	/origin/postgres_snap1
origin/postgres_snap2	16.6M	189G	2.83G	/origin/postgres_snap2

VACUUM

```
root@zfstest:/docker-pg# ./bindiff -b 8192 -t /origin/postgres_snap2/base/25293/25316  
/origin/postgres_snap1/base/25293/25316  
File 1 is 477421568 bytes longer than file 2.  
Total size of differing blocks: 0
```

At the end of the war the sunshine begins

- При частом удалении и изменении данных надо закладывать x2 физического места на диске
- Реплика не влияет на основной ZVOL
- При изменении в снапшоте все блоки данных, которые зависят будут скопированны в снапшот
- У ANALYZE есть нюансы после promote
- Применимость системы

Ссылки на источники информации и программные продукты

- <https://www.dr-lex.be/software/bindiff.html>
- <https://habr.com/ru/companies/vk/articles/529516/>
- <https://www.linux.org.ru/articles/admin/17333839>
- <https://github.com/openzfs/>
- <https://www.docker.com>
- <https://github.com/postgres/postgres>

Спасибо за внимание!

Q&A

Мои контакты

- Telegram - @moytra_nihzayvs
- Email – svyazhin_a@sima-land.ru