



«Что у него внутри» хранение данных на низком уровне

Николай Шаплов

Николай Шаплов


- Сотрудник компании Postgres Professional
- Perl, C разработчик

Контакты


- E-mail: n.shaplov@postgrespro.ru
- Jabber: n.shaplov@postgrespro.ru

- Введение
- Атрибуты в записи
 - Атрибуты фиксированной длины
 - Атрибуты переменной длины
 - Значение NULL
- Выравнивание
- Большие атрибуты переменной длины
 - Сжатие
 - TOAST-хранилище
- Оптимизация
 - Уменьшение размера
 - Увеличение скорости

Хранение записей на странице



Заголовок записи / Tuple header



t_min
 t_max
 t_field3

} Видимость записи


t_bits – маска NULL-значений
 t_hoff – смещение области данных

t_cid – положение записи в хранилище

t_infomask2
 t_infomask

} Флаги + кол-во атрибутов

Заголовок записи не содержит информации о том, как значения атрибутов размещены в области данных



Информация об атрибутах сохраненных в области данных находится в структуре tupleDesc, которую для каждой таблицы можно получить при помощи функции CreateTupleDescCopyConstr

attlen>0 – атрибут фиксированной длины
attlen=-1 – атрибут переменной длины

attalign:


c – без выравнивания
s – значение смещения округляется до кратности 2
i – значение смещения округляется до кратности 4
d – значение смещения округляется до кратности 4 или 8

Расширение pageinspect



Расширение pageinspect
позволяет исследовать
структуры данных
сохраненных на диске

Патчи [d6061f8](#) + [0271e27](#)
позволяют просматривать не только
заголовки, записей, но и область
данных. Возможность будет
представлена в postgresQL 9.6.
Доступна в Postgres Pro 9.5
уже сейчас!



Хранение атрибутов фиксированной длины

```
test=# create table test (a int, b int, c int);
CREATE TABLE
test=# insert into test VALUES (1,2,3);
INSERT 0 1
test=# select lp, t_data from heap_page_items(get_raw_page('test', 0));
```

lp	t_data
1	\x010000000200000003000000

Числа хранятся на
диске как числа
Сюрприз :-)

```
test=# select * from heap_page_item_attrs(get_raw_page('test',0),'test'::regclass);
```

lp	t_attrs
1	{"\x01000000", "\x02000000", "\x03000000"}

Атрибуты фиксированной длины

Самостоятельная работа

Используя расширение `pageinspect` попробуйте выяснить как хранится атрибут типа `date`:

- Хранятся ли день, месяц и год как отдельные значения?
- Хранится ли дата как количество некоторых единиц относительно условного нуля?
- Что именно это за единицы?
- Что принято за ноль?

Шпаргалка:

```
create table test (d date);  
insert into test values ('2016-02-13'), ('2016-02-13'::date+2);
```

Атрибуты фиксированной длины

Самостоятельная работа

```
test=# create table test (s varchar);
CREATE TABLE
test=# insert into test VALUES (now()),('2000-01-01'),('2000-01-01'::date-1);
INSERT 0 1
test=# select lp, t_data from heap_page_items(get_raw_page('test', 0));
```


lp	t_data
1	\xf4160000
2	\x00000000
3	\xffffffff

Хранение атрибутов переменной длины. Однобайтный заголовок

```
test=# create table test (s varchar);
CREATE TABLE
test=# insert into test VALUES ('abcd'),('abc');
INSERT 0 1
test=# select lp, t_data from
        heap_page_items(get_raw_page('test', 0));
```

Однобайтный
заголовок используется в
некомпрессированных строках
длиной до 126 символов

lp	t_data
1	\x0b61626364
2	\x09616263




Хранение атрибутов переменной длины. Четырехбайтный заголовок

```
test=# create table test (a varchar);
CREATE TABLE
test=# insert into test VALUES (repeat('+',126)),(repeat('-',127));
INSERT 0 1
test=# select lp, t_data from
        heap_page_items(get_raw_page('test', 0));
```

Четырехбайтный заголовок используется для строк длиннее 126 байт, а так же для сжатых строк

lp	t_data
1	\xff2b2b2b2b2b2b2b2b2b2b2b2b2b2b2b...
2	\x0c0200002d2d2d2d2d2d2d2d2d2d2d2d2d...



Атрибуты переменной длины

Самостоятельная работа

Представление массивов во внутренней структуре данных

- Убедитесь, что массивы хранятся как атрибут переменной длины;
- Убедитесь, что элементы массива хранятся в самой структуре данных;
- Найдите поле, в котором хранится размер массива;
- Хранится ли информация о типе данных элемента массива в каждой записи содержащий массив?
- Что еще интересного удалось узнать?

Шпаргалка:

```
create table test (a integer[]);  
insert into test values ('{1,2,3,4}');
```

src/include/utils/array.h

```
/* A standard varlena array has the following internal structure:  
*   <vl_len_>      - standard varlena header word  
*   <ndim>          - number of dimensions of the array  
*   <dataoffset>    - offset to stored data, or 0 if no nulls bitmap  
*   <elemtype>      - element type OID  
*   <dimensions>    - length of each array axis (C array of int)  
*   <lower bnds>    - lower boundary of each dimension (C array of int)  
*   <null bitmap>   - bitmap showing locations of nulls (OPTIONAL)  
*   <actual data>  - whatever is the stored data */
```

Атрибуты переменной длины

Самостоятельная работа

```
test=# create table test (a integer[]);
CREATE TABLE
test=# insert into test VALUES ('{255,127,63}'),('{255,127}'),('{255}');
INSERT 0 3
test=# select lp, t_data from heap_page_items(get_raw_page('test', 0));
```


lp	t_data
1	\x43010000000000000000170000000300000001000000ff0000007f0000003f000000
2	\x3b01000000000000000000170000000200000001000000ff0000007f000000
3	\x3301000000000000000000170000000100000001000000ff000000

(3 rows)

Infomask и Infomask2

```
test=# create table test (a int, b int, c int);
CREATE TABLE
test=# insert into test VALUES (1,2,3),(1,null,3);
INSERT 0 2
test=# select lp, t_infomask2, t_infomask, t_bits, t_data from heap_page_items(get_raw_page('test', 0));
```

lp	t_infomask2	t_infomask	t_bits	t_data
1	3	2048		\x010000000200000003000000
2	3	2049	10100000	\x0100000003000000



src/include/access/htup_details.h

`t_infomask` и `t_infomask2` содержат массив битовых флагов, сообщающих о различных о свойствах хранимых в записи данных. Например флаг `has NULLs` указывающий есть ли среди атрибутов `NULL`-значения

Кроме того `t_infomask2` хранит количество атрибутов в записи

NULL-значения

```
test=# create table test (a int, b int, c int);
CREATE TABLE
test=# insert into test VALUES (1,2,3),(1,null,3);
INSERT 0 2
test=# select lp, t_infomask, t_bits, t_data from
        heap_page_items(get_raw_page('test', 0));
```



Если атрибут имеет значение NULL, то он вообще не представлен в области данных, зато для него установлен специальный бит в поле t_bits

lp	t_infomask	t_bits	t_data
1	2048		\x010000000200000003000000
2	2049	10100000	\x0100000003000000

```
test=# select lp, t_infomask, t_bits, t_attrs from
        heap_page_item_attrs(get_raw_page('test',0),'test'::regclass)
```

lp	t_infomask	t_bits	t_attrs
1	2048		{"\\x01000000", "\\x02000000", "\\x03000000"}
2	2049	10100000	{"\\x01000000", NULL, "\\x03000000"}


Alignment



Выравнивание


память






2-х байтовый “слот”

Выравнивание





4-х байтовый "слот"

Выравнивание





[illegible]








Выравнивание




Выравнивание











Выравнивание







Выравнивание атрибутов фиксированной длины

```
test=# create table test (a boolean, b int, c smallint, d bigint);
CREATE TABLE
test=# insert into test VALUES ('t',2,3,4);
INSERT 0 1
test=# select lp, t_data from
        heap_page_items(get_raw_page('test', 0));
```

Атрибуты фиксированной длины размещены в области данных ровно так, как показано в предыдущем примере

lp	t_data
1	\x010000000200000003000000000000000400000000000000


01	00	00	00	02	00	00	00	03	00	00	00	00	00	00	00	04	00	00	00	00	00	00	00
----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----

Выравнивание атрибутов переменной длины

```
test=# create table test (a boolean, b varchar);
CREATE TABLE
test=# insert into test VALUES ('t', ''),
test-#                ('t', repeat('-', 126)),
test-#                ('t', repeat('+', 127));
INSERT 0 3
test=# select lp, t_data from heap_page_items(get_raw_page('test', 0));
```

lp	t_data
1	\x0103
2	\x01ff2d2d2d2d2d2d2d2d...
3	\x010000000c0200002b2b2b2b2b...

В случае атрибутов переменной длины фактически происходит выравнивание заголовка



Выравнивание на 64-х и 32-х битных платформах

```
# create table test (b int, c bigint);
CREATE TABLE
# insert into test VALUES (1,2);
INSERT 0 1
```

Для процессоров разной
разрядности выравнивание
работает по-разному

64bit

lp	t_data
1	\x01000000000000000200000000000000

32bit

lp	t_data
1	\x010000000200000000000000

"Недостача" атрибутов в записи

```
test=# create table test (a int, b int);
CREATE TABLE
test=# insert into test VALUES (1,10);
INSERT 0 2
test=# ALTER TABLE test ADD COLUMN c int;
ALTER TABLE
test=# insert into test VALUES (3,30,300);
INSERT 0 1
```

Если вы добавили новый атрибут со значением по умолчанию NULL, то postgres не будет обновлять записи в хранилище, а будет все недостающие атрибуты считать равными NULL

```
test=# select lp, t_infomask2, t_data from heap_page_items(get_raw_page('test', 0));
```

lp	t_infomask2	t_data
1	2	\x010000000a000000
2	3	\x030000001e0000002c010000

```
test=# select lp, t_infomask2, t_attrs from
        heap_page_item_attrs(get_raw_page('test',0),'test'::regclass);
```

lp	t_infomask2	t_attrs
1	2	{"\x01000000", "\x0a000000", NULL}
2	3	{"\x03000000", "\x1e000000", "\x2c010000"}

Добавление и удаление атрибутов

Самостоятельная работа

Попробуйте при помощи расширения `pageinspect` выяснить что происходит при:

- добавлении нового атрибута с непустым значением по умолчанию;
- удалении существующего атрибута;

Шпаргалка:

```
alter table test add column b integer default 12;
```

```
alter table test drop column a;
```

Подсказки:

- Поймать полное пересоздание хранилища можно по пропавшим из хранилища удаленным записям;
- Форсировать пересоздание хранилища можно командой `vacuum full`. Это приведет к пересозданию всех записей, и все следы оптимизаций будут очищены

Добавление атрибутов

Самостоятельная работа

```
test=# create table test (a integer);
CREATE TABLE
test=# insert into test values (1),(2),(3),(4);
INSERT 0 4
test=# delete from test where a=3;
DELETE 1
test=# SELECT lp, t_xmin, t_xmax, t_attrs FROM
heap_page_item_attrs(get_raw_page('test', 0), 'test'::regclass);
```

lp	t_xmin	t_xmax	t_attrs
1	826	0	{"\\x01000000"}
2	826	0	{"\\x02000000"}
3	826	827	{"\\x03000000"}
4	826	0	{"\\x04000000"}

(4 rows)

При добавлении атрибута
со значением по умолчанию
хранилище просто
пересоздается

```
test=# alter table test add column b integer default 12;
ALTER TABLE
test=# SELECT lp, t_xmin, t_xmax, t_attrs FROM
heap_page_item_attrs(get_raw_page('test', 0), 'test'::regclass);
```

lp	t_xmin	t_xmax	t_attrs
1	828	0	{"\\x01000000", "\\x0c000000"}
2	828	0	{"\\x02000000", "\\x0c000000"}
3	828	0	{"\\x04000000", "\\x0c000000"}

(3 rows)

Удаление атрибутов

Самостоятельная работа

```
test=# create table test (a integer, b integer, c integer);
CREATE TABLE
test=# insert into test values (1,2,16),(2,4,32),(3,6,48);
INSERT 0 3
test=# alter table test drop column b;
ALTER TABLE
```

При удалении атрибута, данные из хранилища не удаляются, атрибут лишь помечается в tupleDescriptor как удаленный

```
test=# SELECT lp, t_xmin, t_xmax, t_attrs FROM
heap_page_item_attrs(get_raw_page('test', 0), 'test'::regclass);
```

lp	t_xmin	t_xmax	t_attrs
1	835	0	{"\\x01000000", "\\x02000000", "\\x10000000"}
2	835	0	{"\\x02000000", "\\x04000000", "\\x20000000"}
3	835	0	{"\\x03000000", "\\x06000000", "\\x30000000"}

(3 rows)

```
test=# insert into test values (4,64);
INSERT 0 1
```

Все новые записи вместо удаленного атрибута содержат значение NULL

```
test=# SELECT lp, t_xmin, t_xmax, t_attrs FROM
heap_page_item_attrs(get_raw_page('test', 0), 'test'::regclass);
```

lp	t_xmin	t_xmax	t_attrs
1	835	0	{"\\x01000000", "\\x02000000", "\\x10000000"}
2	835	0	{"\\x02000000", "\\x04000000", "\\x20000000"}
3	835	0	{"\\x03000000", "\\x06000000", "\\x30000000"}
4	837	0	{"\\x04000000", NULL, "\\x40000000"}


(4 rows)

Хранение больших данных



- Компрессия
- TOAST

```
test=# create table test (a varchar);
CREATE TABLE
test=# insert into test VALUES (repeat('-',2004)),
test=# (repeat('-',2005));
INSERT 0 2
test=# select lp, t_data from heap_page_items(get_raw_page('test', 0));
```

[illegible]



Вынос значение атрибута в TOAST-хранилище

```
test=# create table test (a varchar);
CREATE TABLE
test=# ALTER TABLE test ALTER a SET STORAGE EXTERNAL;
ALTER TABLE
test=# insert into test VALUES (repeat('-',2005),
test=#                               (''));
INSERT 0 2
test=# select lp, t_attrs from
        heap_page_items(get_raw_page('test', 0));
```

Если все атрибуты переменной длины сжаты, а запись все равно длиннее ~2k, postgres начинает выносить значения атрибутов в TOAST-хранилище (начиная с самого длинного)

lp | t_attrs

```
1 | \x0112d9070000d5070000fc6f0100f96f0100
2 | \x03
```





Минимально возможное значение однобайтного заголовка – 0x03. Поэтому 0x01 используется как маркер вынесенного в TOAST атрибута

Optimization




Оптимизация размера

```
test=# create table test (a boolean, b int, c smallint, d bigint);
```



Измените порядок атрибутов чтобы избежать пустот вызванных выравниванием

```
test=# create table test (d bigint, b int, c smallint, a boolean);
```



tuple padding

Оптимизация скорости доступа

```
create table test (a smallint, b int, c int);
insert into test VALUES (0, 1, 2),
                        (16, 17, NULL),
                        (NULL, 33, 34),
                        (64, 65, 66);
```

00	00	00	00	01	00	00	00	02	00	00	00
10	00	00	00	11	00	00	00				
21	00	00	00	22	00	00	00				
40	00	00	00	41	00	00	00	42	00	00	00

Если в записи все атрибуты фиксированной длины и ни один из них не NULL, то положение атрибута в области данных – неизменно

То же верно для атрибутов перед которыми нет NULL'ов и атрибутов переменной длины

Как разместить атрибуты в записи для увеличения скорости доступа:

- Первыми должны идти атрибуты фиксированной длины, не принимающие значения NULL
- За ними – атрибуты фиксированной длины принимающие значение NULL с малой вероятностью
- Все атрибуты переменной длины должны идти в конце записи

Оптимизация скорости доступа

- 1 000 атрибутов типа bigint: N1..N1000
- Одна varchar строка в начале или конце записи
- 1 000 000 записей
- Запрос для тестирования: `SELECT SUM(N1000)`

Тестовое окружение


CPU: 4 socket Xeon V7,
15 Core per socket
Shared Memory: 100Gb

Параметры pgbench

clients: 100
jobs: 100
time: 360


А какое ускорение
может дать правильное
расположение атрибутов?
Попробуем это показать
на вот таком синтетическом
тесте

Строка в конце



tps = 64.373621

Строка в начале



tps = 50.387503

$$64.373621 / 50.387503 = \mathbf{1.27}$$



Look for a newer versions at

<https://github.com/dhyannataraj/tuple-internals-presentation>