Возможности полнотекстового поиска в PostgreSQL

Ф.Г. Сигаев
А.А. Закиров

PgConf.Russia 2017, Москва

www.postgrespro.ru

Что такое полнотекстовый поиск

Полнотекстовый поиск - это:

- поиск документов, удовлетворяющих некоторому запросу поиска
- сортировка результатов поиска по заданному критерию (дополнительно)

Типичный поиск — это:

- поиск документов, содержащих все слова запроса
- сортировка результатов поиска по релевантности

Почему не внешний поисковый движок

Внешние поисковые движки очень быстрые, но:

- не могут индексировать все документы, например, виртуальные
- не имеют доступа ко всем атрибутам, поэтому нельзя выполнить сложные запросы
- требуют поддержки администратором
- иногда должны быть сертифицированы
- не обеспечивают мгновенный поиск, т. к. нужно время для переиндексации новых данных
- не обеспечивают согласованность данных, например, данные могут быть удалены из

Поисковый движок в базе данных

- Интеграция с движком базы данных:
  - транзакционность
  - конкурентный доступ
  - восстановление после сбоя
  - мгновенное индексирование
- Конфигурируемость (парсер, словарь)
- Масштабируемость

Полнотекстовый поиск в PostgreSQL

Операторы поиска по шаблону ~, ~*, LIKE, ILIKE плохо подходят:

- нет языковой поддержки
- нет сортировки по релевантности
- медленный поиск, т. к. необходимо последовательное сканирование документов

Но есть поддержка индексов с помощью модуля pg_trgm.

Полнотекстовый поиск в PostgreSQL

Типы для полнотекстового поиска:

- tsvector - сортированный массив лексем
- tsquery - выражение поиска документов

Операторы:

- @@: tsvector @@ tsquery
- ||: tsvector || tsvector или tsquery || tsquery
- &&: tsquery && tsquery

Функции: to_tsvector, to_tsquery, ts_lexize, ts_debug, ts_stat, ts_headline, ts_rank, ts_rank_cd, setweight, ...

Индексы: GiST, GIN

Полнотекстовый поиск в PostgreSQL

Документ обрабатывается только один раз во время вставки, а не во время поиска:

- документ разбивается на токены с помощью подключаемого парсера
- токены преобразовываются в лексемы с помощью подключаемых словарей
- сохраняются координаты и важность слов и используются для сортировки по релевантности
- стоп-слова не учитываются в поиске

tsvector

tsvector с позициями:

```
=# SELECT to_tsvector('The quick brown fox jumps
over the lazy dog') AS tsvector;
                          tsvector
-----------------------------------------------
-------
 'brown':3 'dog':9 'fox':4 'jump':5 'lazi':8
'quick':2
```

tsvector с позициями и метками:

```
=# SELECT setweight(to_tsvector('quick brown'),
'A') AS tsvector;
        tsvector
------------------------
 'brown':2A 'quick':1A
```

tsvector

tsvector с позициями:

```
=# SELECT 'brown:3 dog:9 fox:4 jump:5 lazi:8
quick:2'::tsvector;
                          tsvector

------------------------------------------------
------
 'brown':3 'dog':9 'fox':4 'jump':5 'lazi':8
'quick':2
```

tsvector с позициями и метками:

```
=# SELECT 'brown:2A quick:1A'::tsvector;
       tsvector
-----------------------
 'brown':2A 'quick':1A
```

tsquery

tsquery поддерживает операторы &, |, ! и <->:

```
=# SELECT to_tsquery('quick & (fox | dog)') AS
tsquery;
            tsquery
-------------------------------
 'quick' & ( 'fox' | 'dog' )
```

tsquery с метками:

```
=# SELECT to_tsquery('quick:AB & dog') AS tsquery;
       tsquery
---------------------
 'quick':AB & 'dog'
```

tsquery для префиксного поиска:

```
=# SELECT to_tsquery('quick & eleph:*') AS
tsquery;
        tsquery
```

tsquery

tsquery с различными операторами:

```
=# SELECT 'quick & ( fox | dog )'::tsquery;
           tsquery
-----------------------------
 'quick' & ( 'fox' | 'dog' )
```

tsquery с метками:

```
=# SELECT 'quick:AB & dog'::tsquery;
       tsquery
---------------------
 'quick':AB & 'dog'
```

tsquery для префиксного поиска:

```
=# SELECT 'quick & eleph:*'::tsquery;
        tsquery
----------------------
 'quick' & 'eleph':*
```

Парсер полнотекстового поиска

Типы токенов:

```
=# SELECT alias, description FROM ts_token_type('default');
      alias       |                description
------------------+-----------------------------------------
 asciiword        | Word, all ASCII
 word             | Word, all letters
 numword          | Word, letters and digits
 email            | Email address
 url              | URL
 host             | Host
 sfloat           | Scientific notation
 version          | Version number
 hword_numpart    | Hyphenated word part, letters and digits
 hword_part       | Hyphenated word part, all letters
 hword_asciipart  | Hyphenated word part, all ASCII
 blank            | Space symbols
 tag              | XML tag
 protocol         | Protocol head
 numhword         | Hyphenated word, letters and digits
 asciihword       | Hyphenated word, all ASCII
 hword            | Hyphenated word, all letters
 url_path         | URL path
 file             | File or path name
 float            | Decimal notation
 int              | Signed integer
```

Парсер полнотекстового поиска

Типы токенов:

```
=# SELECT alias, token, dictionary, lexemes
FROM ts_debug('The quick brown fox jumps over the lazy
dog');
   alias   | token |  dictionary  | lexemes
-----------+-------+--------------+---------
 asciiword | The   | english_stem | {}
 blank     |       | (null)       | (null)
 asciiword | quick | english_stem | {quick}
 blank     |       | (null)       | (null)
 asciiword | brown | english_stem | {brown}
 blank     |       | (null)       | (null)
 asciiword | fox   | english_stem | {fox}
 blank     |       | (null)       | (null)
 asciiword | jumps | english_stem | {jump}
 blank     |       | (null)       | (null)
 asciiword | over  | english_stem | {}
 blank     |       | (null)       | (null)
 asciiword | the   | english_stem | {}
```

Словари полнотекстового поиска

Типы словарей:

- simple

```
=# SELECT to_tsvector('simple', 'lazy');
 to_tsvector
-------------
 'lazy':1
```

- synonym

```
=# SELECT to_tsvector('synonym_sample', 'lazy');
 to_tsvector
--------------
 'indolent':1
```

- thesaurus

```
=# SELECT to_tsvector('thesaurus_sample', 'brown
fox');
 to_tsvector
-------------
 'fox':1
```

Словари полнотекстового поиска

Типы словарей:

- snowball

```
=# SELECT to_tsvector('english', 'lazy abilities');
     to_tsvector
---------------------
 'abil':2 'lazi':1
```

- ispell

```
=# SELECT to_tsvector('english_hunspell', 'lazy');
 to_tsvector
-------------
 'lazy':1

=# SELECT to_tsvector('english_hunspell', 'abilities');
 to_tsvector
-------------
 'ability':1

=# SELECT to_tsvector('english_hunspell', 'inability');
 to_tsvector
-------------
 'ability':1
```

github.com/postgrespro/hunspell_dicts
github.com/postgrespro/

Конфигурации полнотекстового поиска

Создание конфигурации:

```
=# CREATE TEXT SEARCH CONFIGURATION ru_conf (parser='default');
=# ALTER TEXT SEARCH CONFIGURATION …
=# \dF+ ru_conf
   Text search configuration "public.ru_conf"
Parser: "pg_catalog.default"
      Token       |         Dictionaries
------------------+------------------------------
 asciihword       | english_hunspell,english_stem
 asciiword        | english_hunspell,english_stem
 email            | simple
 file             | simple
 float            | simple
 host             | simple
 hword            | russian_hunspell,russian_stem
 hword_asciipart  | english_hunspell,english_stem
 hword_numpart    | simple
 hword_part       | russian_hunspell,russian_stem
 int              | simple
 numhword         | simple
 numword          | simple
 sfloat           | simple
 uint             | simple
 url              | simple
```

Конфигурации полнотекстового поиска

Конфигурация для поиска только по словам:

```
=# \dF+ ru_conf_word
 Text search configuration "public.ru_conf_word"
Parser: "pg_catalog.default"
      Token       |          Dictionaries
------------------+--------------------------------
 asciihword       | english_hunspell,english_stem
 asciiword        | english_hunspell,english_stem
 hword            | russian_hunspell,russian_stem
 hword_asciipart  | english_hunspell,english_stem
 hword_part       | russian_hunspell,russian_stem
 word             | russian_hunspell,russian_stem

=# SELECT to_tsvector('ru_conf_word', '100500
elephants on postgresql.org');
 to_tsvector
--------------
 'elephant':1
```

Ранжирование

Функции ранжирования:

- ts_rank(weights, vector, query, normalization)
- ts_rank_cd(weights, vector, query, normalization)

формат weights:
{D-weight, C-weight, B-weight, A-weight}

weights по-умолчанию:
{0.1, 0.2, 0.4, 1.0}

Ранжирование

Далекие лексемы:

```
=# SELECT ts_rank_cd(to_tsvector('The quick brown
fox jumps over the lazy dog'), to_tsquery('brown &
dog'));
 ts_rank_cd
------------
  0.0166667
```

Близкие лексемы:

```
=# SELECT ts_rank_cd(to_tsvector('The quick brown
fox jumps over the lazy dog'), to_tsquery('brown &
fox'));
 ts_rank_cd
------------
         0.1

=# SELECT ts_rank_cd(setweight(to_tsvector('The
quick brown fox jumps'), 'A') || to_tsvector('over
the lazy dog'), to_tsquery('brown & fox'));
```

Ранжирование

Ранжирование с помощью меток:

```
=# SELECT ts_rank_cd(setweight(to_tsvector('The
quick brown fox jumps'), 'A') || to_tsvector('over
the lazy dog'), to_tsquery('brown & fox'));
 ts_rank_cd
------------
          1
```

Веса для меток:

```
=# SELECT ts_rank_cd(ARRAY[0.1, 0.1, 0.1, 0.1],
setweight(to_tsvector('The quick brown fox
jumps'), 'A') || to_tsvector('over the lazy dog'),
to_tsquery('brown & fox'));
 ts_rank_cd
------------
        0.1
```

Индексы

Индексы:

- GiST
  - быстрая вставка данных
  - более медленный поиск, чем в GIN
- GIN
  - более медленная вставка данных
  - но полнотекстовый поиск быстрее
- RUM
  - вставка данных медленнее, чем в GIN
  - размер индекса больше
  - но полнотекстовый поиск и ранжирование быстрее

Индексы. GIN

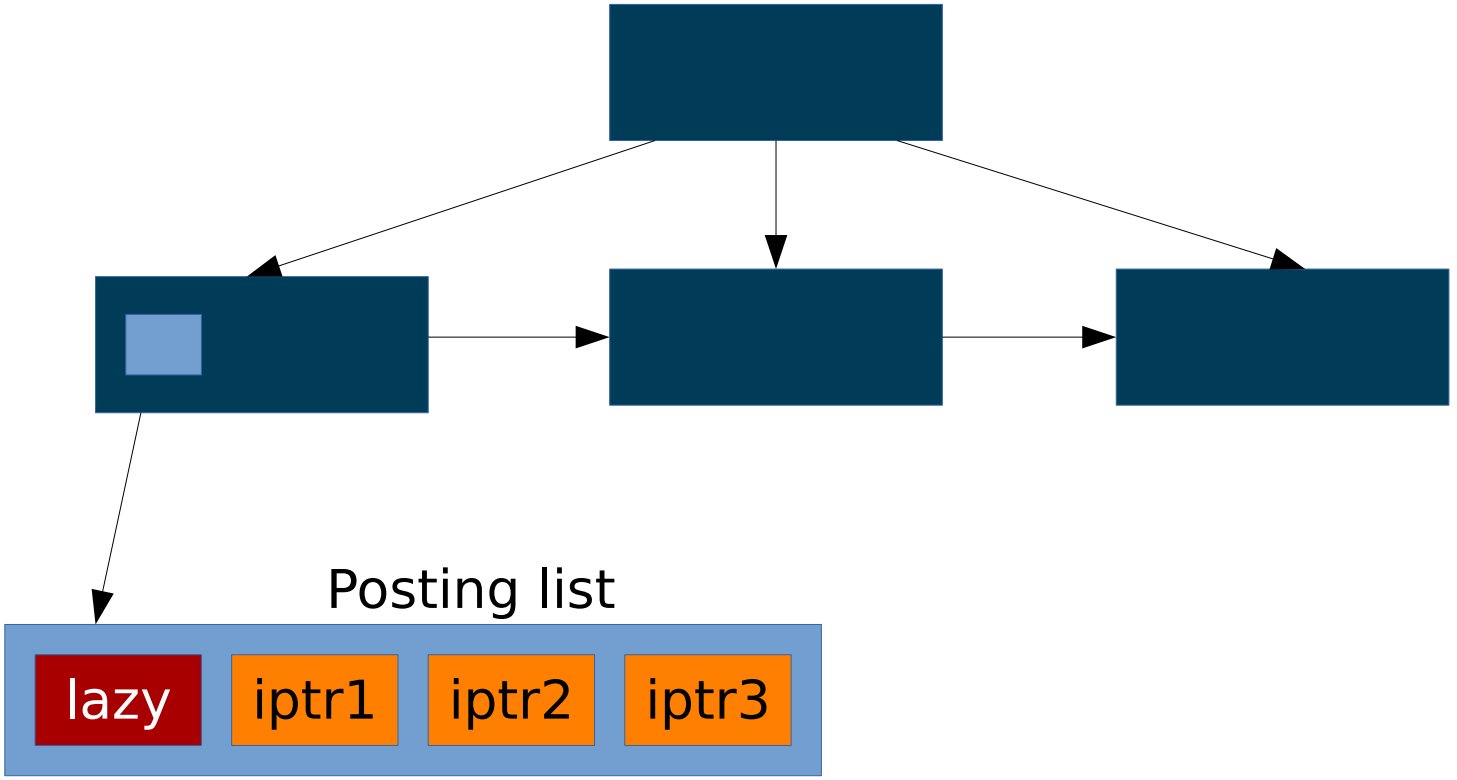

GIN. Проблемы

1 - Медленное ранжирование

```
=# SELECT id, ts_rank(fts, to_tsquery('english',
'Text & search')) AS rank
FROM pglist
WHERE fts @@ to_tsquery('english', 'Text &
search')
ORDER BY rank DESC
LIMIT 10;
```

```
Limit (actual time=157.811..157.814 rows=10 loops=1)
  ->  Sort (actual time=157.808..157.809 rows=10 loops=1)
      Sort Key: (ts_rank(fts, '''text'' &
''search'''::tsquery)) DESC
      Sort Method: top-N heapsort  Memory: 25kB
      ->  Bitmap Heap Scan on pglist (actual
time=26.211..152.331 rows=9924 loops=1)
          Recheck Cond: (fts @@ '''text'' &
''search'''::tsquery)
          Heap Blocks: exact=8125
          ->  Bitmap Index Scan on pglist_idx (actual
time=24.119..24.119 rows=9924 loops=1)
```

GIN. Проблемы

2 - Медленный фразовый поиск

```
=# SELECT id, ts_rank(fts, to_tsquery('english',
'Text <-> search')) AS rank
FROM pglist
WHERE fts @@ to_tsquery('english', 'Text <->
search')
ORDER BY rank DESC
LIMIT 10;

Limit (actual time=170.572..170.575 rows=10 loops=1)
  ->  Sort (actual time=170.570..170.572 rows=10 loops=1)
      Sort Key: (ts_rank(fts, '''text'' <->
''search'''::tsquery)) DESC
      Sort Method: top-N heapsort  Memory: 25kB
      ->  Bitmap Heap Scan on pglist (actual
time=24.027..168.358 rows=3803 loops=1)
          Recheck Cond: (fts @@ '''text'' <->
''search'''::tsquery)
          Rows Removed by Index Recheck: 6121
          Heap Blocks: exact=8125
          ->  Bitmap Index Scan on pglist_idx (actual
```

GIN. Проблемы

3 - Медленная сортировка по другим полям (например, дате)

```
=# SELECT id, sent
FROM pglist
WHERE fts @@ to_tsquery('english', 'index &
scan')
ORDER BY abs(extract(epoch from (sent - now())))

LIMIT 10;
```

```
Limit (actual time=150.496..150.499 rows=10 loops=1)
  ->  Sort (actual time=150.493..150.495 rows=10 loops=1)
      Sort Key: (abs(date_part('epoch'::text,
((sent)::timestamp with time zone - now()))))
      Sort Method: top-N heapsort  Memory: 25kB
      ->  Bitmap Heap Scan on pglist (actual
time=42.855..134.649 rows=34068 loops=1)
          Recheck Cond: (fts @@ '''index'' &
''scan'''::tsquery)
          Heap Blocks: exact=25206
          ->  Bitmap Index Scan on pglist_idx (actual
```

Индексы. RUM

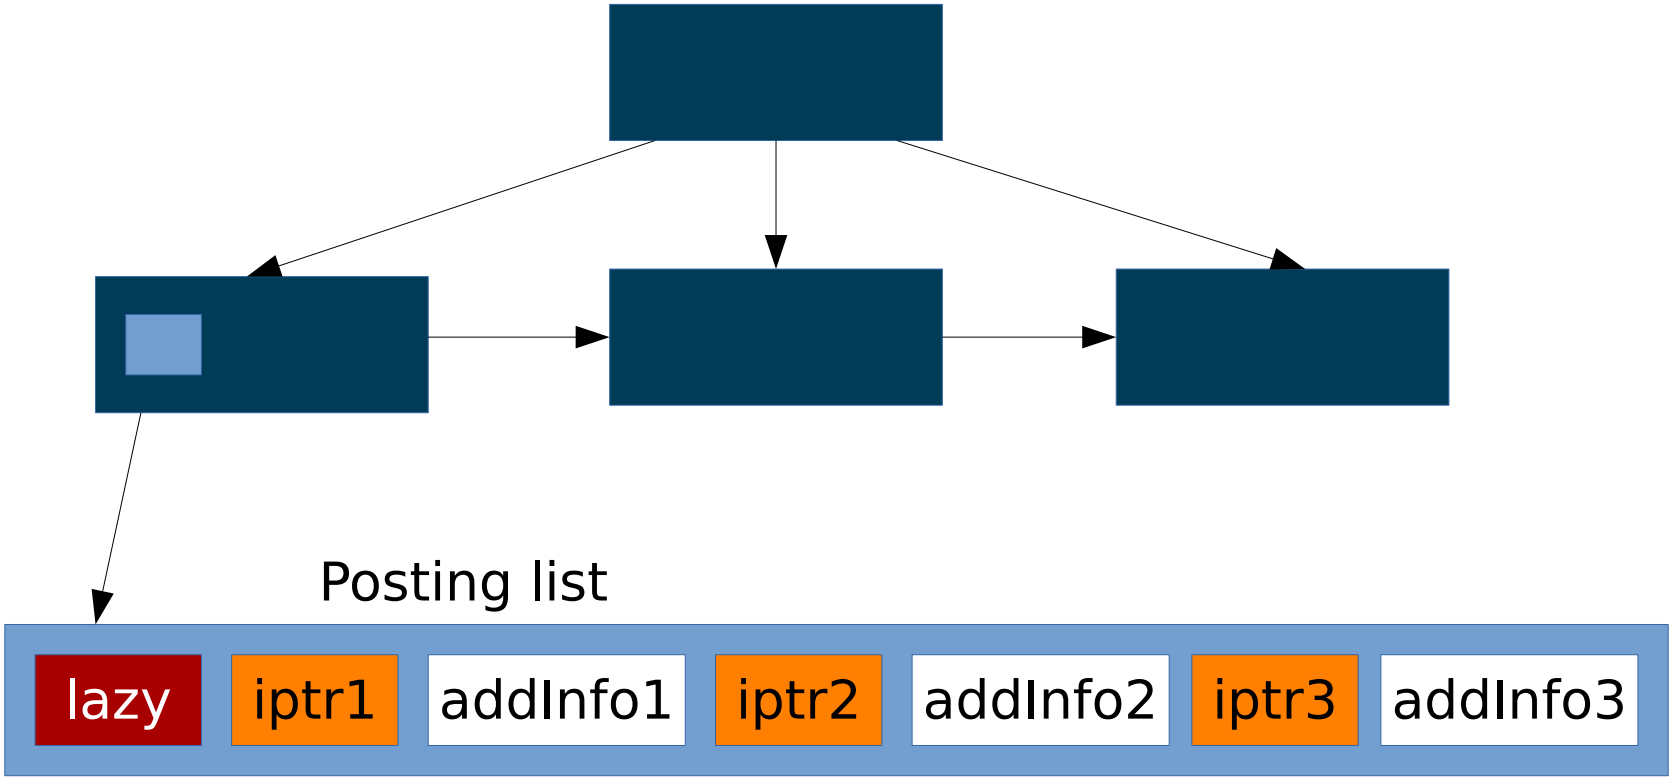

- PostgreSQL 9.6+
- github.com/postgrespro/rum
- Использует Generic WAL Records (www.postgresql.org/docs/9.6/static/generic-wal.html)

Индексы. RUM

1 - Ранжирование

```
=# SELECT id, fts <=> to_tsquery('english', 'text
& search') AS rank
FROM pglist
WHERE fts @@ to_tsquery('english', 'text &
search')
ORDER BY rank
LIMIT 10;

Limit (actual time=62.845..62.959 rows=10
loops=1)
  ->  Index Scan using pglist_rum_idx on pglist
(actual time=62.843..62.955 rows=10 loops=1)
      Index Cond: (fts @@
'''text''&''search'''::tsquery)
      Order By: (fts <=>
'''text''&''search'''::tsquery)
Planning time: 0.739 ms
Execution time: 63.209 ms
```

Индексы. RUM

2 - Фразовый поиск

```
=# SELECT id, fts <=> to_tsquery('english', 'text
<-> search') AS rank
FROM pglist
WHERE fts @@ to_tsquery('english', 'text <->
search')
ORDER BY rank
LIMIT 10;

Limit (actual time=52.727..52.851 rows=10
loops=1)
  ->  Index Scan using pglist_rum_idx on pglist
(actual time=52.724..52.846 rows=10 loops=1)
      Index Cond: (fts @@ '''text''<-
>''search'''::tsquery)
      Order By: (fts <=> '''text''<-
>''search'''::tsquery)
Planning time: 0.787 ms
Execution time: 53.540 ms
```

Индексы. RUM

3 - Сортировка по другим полям (например, дате)

```
=# SELECT id, sent
FROM pglist
WHERE fts @@ to_tsquery('english', 'text &
search')
ORDER BY sent <=> '2000-01-01'::timestamp
LIMIT 10;
```

```
Limit (actual time=39.907..39.926 rows=10 loops=1)
  ->  Index Scan using pglist_date_idx on pglist
(actual time=39.905..39.924 rows=10 loops=1)
      Index Cond: (fts @@ '''text'' &
''search'''::tsquery)
      Order By: (sent <=> '2000-01-01
00:00:00'::timestamp without time zone)
Planning time: 0.720 ms
Execution time: 40.273 ms
```

RUM. Проблемы

- Более медленное построение индекса
- Вставка данных медленнее
- Размер индекса больше
- Больший WAL трафик при вставке данных, но не при построении индекса. Это происходит из-за использования Generic WAL Records

Сравнение GIN и RUM

Создание индекса для таблицы размером 1290 Мб

	GIN	RUM	RUM+ts	RUM+ts+order
Время создания, сек	169	189	196	255
Размер, Мб	535	952	1489	1869
WAL, Мб	927	681	1125	1476

RUM Todo

- Несколько дополнительных информаций (позиции лексем + timestamp)
- Классы операторов для массивов,integer и float
- Улучшение функции ранжирования для поддержки TF/IDF
- Улучшение времени вставки в индекс
- Улучшение производительности Generic WAL Records

github.com/postgrespro/rum

Пример сайта с полнотекстовым поиском

- Поиск с помощью RUM
- Ранжирование с помощью разных функций: ts_rank(), ts_rank_cd(), ts_score()
- Фасетный поиск
- Отображение сгенерированного запроса

tsdemo.postgrespro.ru
github.com/postgrespro/apod_fts

Пример сайта с полнотекстовым поиском

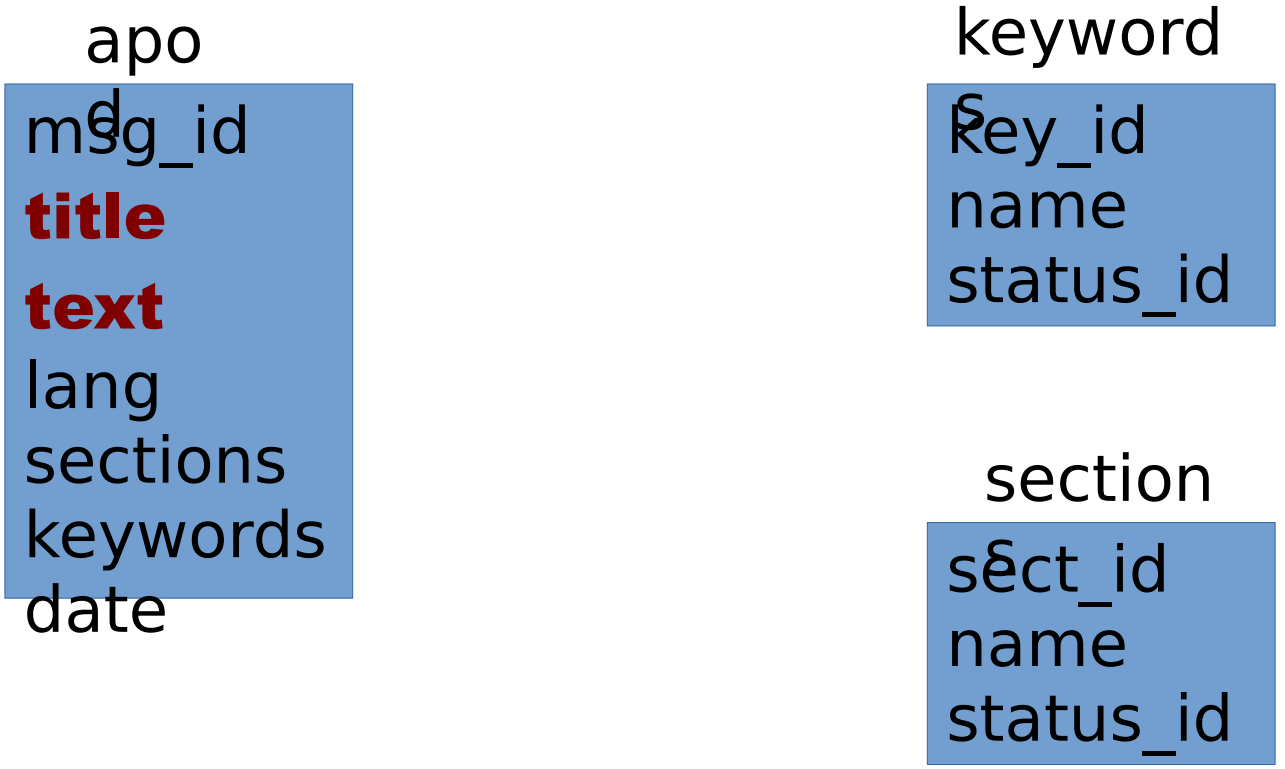

Пример сайта с полнотекстовым поиском. Словари

Ispell словари:

- нормализация нескольких форм слова в одну лексему
- поддержка форматов Ispell, MySpell, Hunspell
- исключение стоп-слов
- настройка с помощью файлов .affix и .dict

Пример сайта с полнотекстовым поиском. Словари

Установка словарей в PostgreSQL:

- Загрузить LibreOffice расширения: http://extensions.libreoffice.org/extension-center?getCategories=Dictionary
- Извлечь файлы .dic и .aff из .oxt архива
- Переименовать файлы в .dict и .affix
- Конвертация файлов в UTF-8 кодировку
- Скопировать файлы в папку $SHAREDIR/tsearch_data/
- Загрузка файлов в PostgreSQL с помощью команды

```
CREATE TEXT SEARCH DICTIONARY
en_hunspell (
   TEMPLATE = ispell,
   DictFile = en_us,
```

Советы и приемы

- setweight(tsvector, char, text[]) - добавить метки лексемам из text[]

```
=# SELECT setweight(to_tsvector('english', '22-
nd anniversary of PostgreSQL'), 'A',
'{postgresql,22}');
                       setweight
-------------------------------------------------
 '22':1A 'anniversari':3 'nd':2 'postgresql':5A
```

- ts_delete(tsvector, text[]) - удалить лексемы из tsvector

```
=# SELECT ts_delete(to_tsvector('english', '22-
nd anniversary of PostgreSQL'),
'{22,postgresql}'::text[]);
```

Советы и приемы

- unnest(tsvector) - преобразовать tsvector в таблицу

```
=# SELECT * FROM
unnest(setweight(to_tsvector('english', '22-nd
anniversary of PostgreSQL'), 'A',
'{postgresql,22}'));
    lexeme     | positions | weights
---------------+-----------+---------
 22            | {1}       | {A}
 anniversari   | {3}       | {D}
 nd            | {2}       | {D}
 postgresql    | {5}       | {A}
```

- tsvector_to_array(tsvector), array_to_tsvector(text[])

```
=# SELECT
tsvector_to_array(to_tsvector('english', '22-nd
```

Postgres PROFESSIONAL

Спасибо за внимание!