

PGroonga 2

Make PostgreSQL rich full text search system backend!

Kouhei Sutou

ClearCode Inc.

*PGConf. ASIA 2017
2017-12-05*





Targets 対象者

- Want to implement full text search with PostgreSQL
PostgreSQLで全文検索したい
- Not good at full text search
全文検索はよく知らない
- PGroonga 1.0.0 users
PGroonga 1.0.0は使ったことがある



Abbreviations

略語

- **PG: PostgreSQL**
ポスグレ: PostgreSQL
- **FTS: Full text search**
FTS: 全文検索



FTS system: Targets

全文検索システム：対象

Many tests

大量のテキスト

- e. g. : Text data in office docs in file servers
例：ファイルサーバー内のオフィス文書内のテキスト
- e. g. : Item descriptions, chat logs, Wiki data, ...
例：商品説明やチャットログ、Wikiのデータなど



FTS system: Goal

全文検索システム：目的

Provide
needed info
when you need

必要な情報を必要なときに提供すること



Provide needed info

必要な情報を提供

-  **Not found**
探している情報が見つからない
-  **Found**
探している情報が見つかる
-  **Found **unconscious needed** info too!**
意識していなかったけど実は欲しかった情報も見つかる!



When you need 必要なときに活用

-  Need many times to find
なかなか見つからない
-  Find in no time
すぐに見つかる
-  Already found
すでに見つかっていた
 - e. g. : Recommendation
例：レコメンデーション



How to impl.: Options

実装方法：選択肢

- Use FTS server
全文検索サーバーを使う
- Use PostgreSQL
PostgreSQLを使う



FTS server: Pros

全文検索サーバー案：メリット

- Provides all basic features
必要な機能が揃っている
- Provides advanced features
+ α の機能もある
- Fast
速い



FTS server: Cons1

全文検索サーバー案：デメリット1

- Large implementation cost
実装コスト大
 - Learn how to use from scratch
使い方を1から学ぶ必要がある
 - How to implement data sync?
マスターデータの同期はどうする？



FTS server: Cons2

全文検索サーバー案：デメリット2

- Large maintenance cost
メンテナンスコスト大
 - Learn how to operate from scratch
運用方法を1から学ぶ必要がある



PostgreSQL: Pros1

PostgreSQL案：メリット1

- **Less implementation cost**
実装コスト小
 - **Less things to be learned**
新しく覚えることが少ない
 - **Can manage data at the same place**
データの一元管理



PostgreSQL: Pros2

PostgreSQL案：メリット2

- **Less operation cost**
メンテナンスコスト小
 - **The current operation knowledge is reusable**
既存の運用ノウハウを使える



PostgreSQL: Cons

PostgreSQL案：デメリット

- Built-in features aren't enough
組込機能では機能不足
- SQL limits efficiency
SQLの表現力不足
 - e.g. : SQL needs multiple queries for a process that can be done by 1 query by FTS server
例：全文検索サーバーなら1クエリーで実現できる処理にSQLだと複数クエリー必要なことがある



The 3rd option

第3の選択肢

- Use FTS engine via PostgreSQL (SQL)
PostgreSQL経由 (SQL) で全文検索エンジンを使う



Pros メリット

- **Fast and rich features**
高速で豊富な機能
- **Less implementation cost**
実装コスト小
- **Less operation cost**
メンテナンスコスト小



Cons

デメリット

- Need PostgreSQL extension
PostgreSQLに拡張機能が必要
 - Not available on DBaaS
DBaaSで使えない



Option: No FTS knowledge

オススの選択肢：全文検索の知識ナシ

- Need only simple features
まだ単純な機能で十分
 - Less data: LIKE with PostgreSQL
データ少：PostgreSQLでLIKE
- Need up-to-date FTS features
いまどきの全文検索機能が必要
 - FTS engine via PostgreSQL
PostgreSQL経由で全文検索エンジン



Option: With FTS knowledge

オススメの選択肢：全文検索の知識アリ

■ Need tuned FTS feature

カリカリにチューニングしたい

■ PostgreSQL + FTS server

PostgreSQL + 全文検索サーバー

■ Others

それ以外

■ FTS engine via PostgreSQL

PostgreSQL経由で全文検索エンジン



Described option

説明する選択肢

FTS engine via PostgreSQL

PostgreSQL経由で全文検索エンジン



FTS engine: Groonga

全文検索エンジン: Groonga (ぐるんが)

■ Embeddable FTS engine

組込可能な全文検索エンジン

■ PGroonga: Groonga in PostgreSQL

PGroonga: PostgreSQLに組込

■ Usable as FTS server

全文検索サーバーとして単独でも使用可能

■ PostgreSQL + FTS server architecture is also available

PostgreSQL + 全文検索サーバー構成もできる



Groonga's hobby: data update

Groongaの得意な事：データの追加・更新

■ Make fresh data searchable!

新鮮な情報をすぐ検索可能！

■ Batch update is needless

バッチで更新しなくてもよい

■ Can use as chat backend

チャットくらいの頻度でもOK

e.g. : Zulip uses PGroonga

例：ZulipはPGroongaを採用



Groonga's hobby: data update

Groongaの得意な事：データの追加・更新

- Keep search performance while updating!
更新中も検索性能が落ちない！
- Updatable when there are many search users
利用ユーザーが多い時でも更新可能



PGroonga

PGroonga (ピージーるんが)

■ PostgreSQL index

PostgreSQLのインデックス

■ Alternative of GIN, RUM, ...

GIN・RUMなどと同じレイヤー

■ Usage

使用方法

- CREATE INDEX ...
USING PGroonga ...



PostgreSQL and FTS

PostgreSQLと全文検索

- LIKE: Built-in (組込機能)
- textsearch: Built-in (組込機能)
- pg_trgm: Contrib (標準添付)
 - Bundled in the archive
アーカイブには含まれている
 - Need to install separately
別途インストールすれば使える



LIKE and performance

LIKEと速度

- Small data
少ないデータ
 - Enough performance
十分実用的
- Not small data
少なくないデータ
 - Need to tune
性能問題アリ



LIKE and FTS system

LIKEと全文検索システム



Enough performance
in most case

速度が実用的なことも多い

- Data are small in many case
少ないデータなら



LIKE and FTS system

LIKEと全文検索システム



Unable to sort

それっぽい順のソート不可

- Sort is important in FTS

全文検索ではソート順が重要

- Users check only the first N entries

ユーザーは先頭N件しか見ない



textsearch

-  **Fast search by index**
インデックスを作るので速い
- **Need module for each lang**
言語毎にモジュールが必要
 -  **Modules for English, French, ... are built-in**
英語やフランス語などは組込
 -  **Modules for languages in Asia aren't maintained**
アジア圏の言語用のモジュールはメンテされていない



pg_trgm

-  Fast search by index
インデックスを作るので速い
-  Asian languages aren't enough supported
アジア圏の言語のサポートは十分ではない
-  Unable to sort
それっぽい順のソート不可



RUM

- RUM = GIN + position

RUMは位置情報付きのGIN

- <https://github.com/postgrespro/rum>

- pg_trgm/pg_bigm are slow for much matches case

pg_trgmとpg_bigmはマッチ数が多いと遅くなる

- RUM will solve it

GINの代わりにRUMを使うことで解決できるかも！



PGroonga

-  **Fast search by index**
インデックスを作るので速い
-  **Sortable**
それっぽい順のソート可
-  **Support all languages**
全言語対応
-  **Need to install separately**
別途インストールする必要アリ



FTS system with PostgreSQL

PostgreSQLで全文検索システム

- PGroonga is the best! 100
PGroongaがベスト!
- PGroonga
 - Fast (高速)
 - Support all langs (全言語対応)
 - Sortable (それっぽい順でソート可)



FTS system: Basic features

全文検索システム：基本機能

- **Fast FTS + sort**
高速全文検索＋ソート
- **Show texts around keyword**
キーワード周辺テキスト表示
- **Highlight keyword**
検索キーワードハイライト



FTS system: Adv. features

全文検索システム：高度な機能

- Auto complete
オートコンプリート
- Similar search
類似文書検索
- Synonym expansion
同義語展開



PGroonga 1.0.0

↓ are only supported
以下の機能のみ対応

- Fast FTS + sort
高速全文検索+ソート
- Show texts around keyword
キーワード周辺テキスト表示



PGroonga 2

All features
are supported!

全機能対応！



PGroonga 1.0.0 → 2

- 😄 Many new features
たくさんの新機能
- 😄 Improve performance
性能改善
- 😞 API is changed
APIが変わった



API change

API変更

Operator is changed

演算子変更

@@ → &@~

%% → &@

...



API change

API変更

pgroonga schema is deprecated
pgroongaスキーマを非推奨に

pgroonga.score → pgroonga_score
pgroonga.flush → pgroonga_flush
...



App for PGroonga 1.0.0

PGroonga 1.0.0用アプリ

- Broken with PGroonga 2?
PGroonga 2では動かない？
 - No! Work without any changes!
何も変更しなくても動くよ!

Great! But why?
いいじゃん! でもなんで動くの?



"Painless upgrade" technique



Painless upgrade

- PGroonga 2 provides both 1 API and 2 API
PGroonga 2は1用のAPIも2用のAPIも両方提供
- Can use PGroonga 2 with 1 API
PGroonga 1のAPIでPGroonga 2を使える



Painless upgrade

- The last PGroonga 1.X provides both 1 API and partially 2 API

PGroonga 1系の最終版は1用のAPIも2用のAPIの一部も提供

- Can use PGroonga 1 with 2 API

PGroonga 2のAPIでPGroonga 1を使える



Painless upgrade

- PGroonga 2 keeps 1 API
PGroonga 2の間は1のAPIを維持
- PGroonga 3 will drop 1 API
PGroonga 3で1のAPIを削除予定
 - Just need to upgrade API until 3
PGroonga 3までにAPIをアップグレードすればよい



Painless upgrade

- App for PGroonga 1.0.0 doesn't work with PGroonga 2
PGroonga 1.0.0用のアプリがPGroonga 2で動かない
 - It's a bug. Please report it!
バグなので報告してね!



FTS system: Basic features

全文検索システム：基本機能

- **Fast FTS + sort**
高速全文検索＋ソート
- **Show texts around keyword**
キーワード周辺テキスト表示
- **Highlight keyword**
検索キーワードハイライト



Fast FTS + sort

高速全文検索+ソート

PHP document search

php

Full text search

送信

php .ini ディレクティブのリスト

1010

php .ini ディレクティブのリスト

Highlight keyword

以下のリストには、PHP の設定を行うための php .ini ディレクティブが含まれます。

"変更の可否" は

Texts around keyword

```
"1"  
PHP_INI_PERDIR  
PHP 4.0.0 で PHP_INI_ALL。PHP 5.4.0 で削除。  
allow_url_fopen  
"1"  
PHP_INI_SYSTEM  
PHP <= 4.3.4 で PHP_INI_ALL。  
a
```

"0"

```
PHP_INI_SYSTEM  
PHP 5.2.0 以降で使用可能
```



Table definition

```
CREATE TABLE entries (  
  -- Need primary key  
  -- It's needed for sort  
  id integer PRIMARY KEY,  
  title text,  
  content text  
);
```



Index definition

```
-- For FTS.  
-- The default is good enough!  
CREATE INDEX entries_full_text_search  
ON entries  
-- "USING PGroonga" is important!  
-- Primary key is for sort!  
USING PGroonga (id, title, content);
```



Insert data

```
-- Normal INSERT.  
INSERT INTO entries  
VALUES (1,  
        'Fast FTS with Groonga!',  
        'Fast FTS is needed!');
```



FTS

```
SELECT title FROM entries
WHERE
-- &@~ is for FTS
-- AND search with "search" and "fast"
title &@~ 'search fast' OR
content &@~ 'search fast';
```



FTS: LIKE

```
SELECT title FROM entries
WHERE
```

- Index search for LIKE is supported*
- = Improve app perf without any changes*
- NOTE: &@~ is faster than LIKE*

```
title LIKE '%search%' OR
content LIKE '%search%';
```



Sort

```
SELECT
  title,
  -- pgroonga_score(TABLE_NAME) returns
  -- precision as number
  pgroonga_score(entries) AS score
FROM entries
WHERE -- ...
  -- Sort by precision
ORDER BY score DESC LIMIT 10;
```



Highlight keyword キーワードハイライト

PHP document search

php

Full text search

送信

php .ini ディレクティブのリスト

1010

php .ini ディレクティブのリスト

Highlight keyword

以下のリストには、PHP の設定を行うための php .ini ディレクティブが含まれます。

"変更の可否" は

Texts around keyword

```
"1"  
PHP_INI_PERDIR  
PHP 4.0.0 で PHP_INI_ALL。PHP 5.4.0 で削除。  
allow_url_fopen  
"1"  
PHP_INI_SYSTEM  
PHP <= 4.3.4 で PHP_INI_ALL。  
a
```

"0"

```
PHP_INI_SYSTEM  
PHP 5.2.0 以降で使用可能
```



Hightlight for HTML

```
SELECT
  pgroonga_highlight_html(
    title,
    -- Extract keywords from query
    pgroonga_query_extract_keywords('search fast'))
FROM entries
WHERE title &@~ 'search fast' OR
       content &@~ 'search fast';
```



Highlight for HTML: Example

Fast search with <Groonga>!

↓

Fast

↑ ↓ Keywords are marked up with "class"

search !

with <Groonga>! ← Escape tag



Texts around keyword

キーワード周辺テキスト

PHP document search

php

Full text search

送信

php .ini ディレクティブのリスト

1010

php .ini ディレクティブのリスト

Highlight keyword

以下のリストには、PHP の設定を行うための php .ini ディレクティブが含まれます。

"変更の可否" は

Texts around keyword

```
"1"  
PHP_INI_PERDIR  
PHP 4.0.0 で PHP_INI_ALL。PHP 5.4.0 で削除。  
allow_url_fopen  
"1"  
PHP_INI_SYSTEM  
PHP <= 4.3.4 で PHP_INI_ALL。  
a
```

"0"

```
PHP_INI_SYSTEM  
PHP 5.2.0 以降で使用可能
```

Texts around keyword for HTML

```
SELECT
  pgroonga_snippet_html(
    content,
    -- Extract keywords from query
    pgroonga_query_extract_keywords('search fast'))
FROM entries
WHERE title &@~ 'search fast' OR
       content &@~ 'search fast';
```



Example

```
...fast search with <Groonga>!...
```

```
↓
```

```
ARRAY[
```

```
  ↓ First
```

```
  '<span class="keyword">fast</span>
```

```
  ↑ ↓ Keywords are marked up with "class"
```

```
  <span class="keyword">search/span> !
```

```
  with &lt;Groonga&gt;!', ← Escape tag
```

```
  '...' ← Second
```

```
]
```



FTS system: Adv. features

全文検索システム：高度な機能

- **Auto complete**
オートコンプリート
- **Similar search**
類似文書検索
- **Synonym expansion**
同義語展開



Auto complete オートコンプリート

PHP document search

seiki

- ereg正規表現
- form正規化方式
- getPregFlags正規表現フラグ
- PCRE正規表現
- PCRE正規表現処理
- POSIX正規表現
- POSIX正規表現拡張モジュール
- POSIX正規表現関数
- POSIX正規表現関数POSIX正規表現関数参考警告
- realpath正規化

の `php` .ini ディレクティブが

```
PHP 4.0.0 で PHP_INI_ALL。 PHP 5.4.0 で削除。  
allow_url_fopen  
"1"  
PHP_INI_SYSTEM  
PHP <= 4.3.4 で PHP_INI_ALL。  
a
```



Auto complete: Preparation

オートコンプリート：準備

■ Master table

マスターテーブル

■ Candidate

候補：（例：牛乳）

■ Readings in Katakana (Only for Japanese)

ヨミ（日本語の場合。カタカナ。複数登録可。）

- 例：ギユウニュウ・ミルク



Auto complete: Implementation

オートコンプリート：実装方法

- OR search with ...
 - Prefix search against readings
(Only for Japanese)
ヨミを前方一致検索（日本語の場合。）
 - Loose FTS against candidate
候補をゆるく全文検索
- Sort by candidate
候補でソート

<https://pgroonga.github.io/how-to/auto-complete.html>



Table definition

```
CREATE TABLE terms (  
  term text, -- Candidate  
  readings text[], -- Readings  
);
```



Data example

```
INSERT INTO terms VALUES (  
  'milk', -- Candidate  
  ARRAY[  
    -- Reading in Katakana  
    'ギユウニユウ', -- "milk" in Japanese  
    -- Multiple readings  
    'ミルク'         -- "milk" in Katakana  
  ]  
);
```



Data management

データ管理

- Easy to maintain because it's a normal table
普通のテーブルなので管理が楽
 - Easy to insert/delete/update
追加・削除・更新が楽
 - Normal backup and replication
ダンプ・リストアもレプリケーションもいつも通り



Index for prefix search

前方一致用インデックス

```
CREATE INDEX prefix_search ON terms
  USING PGroonga
  -- ...text_array_term_search...
  (readings
   pgroonga_text_array_term_search_ops_v2);
```



Index for loose FTS

緩い全文検索用インデックス

```
CREATE INDEX loose_search ON terms
  USING PGroonga (term)
  -- Tokenizer for loose full text search
  WITH (tokenizer='TokenBigramSplitSymbolAlphaDigit');
```



How to search

検索方法

```
SELECT term FROM terms
-- Prefix search against readings
WHERE readings &^~ '${INPUT}' OR
-- Loose full text search
term &@ '${INPUT}'
ORDER BY term LIMIT 10; -- Sort
```



Search example: Candidate

検索例：候補

```
-- User inputs "il"  
SELECT term FROM terms  
-- Prefix search against readings  
WHERE readings &^~ 'il' OR  
-- Loose full text search (Hit)  
term &@ 'il'  
ORDER BY term LIMIT 10; -- Sort
```



Search example: Katakana

検索例：カタカナ

```
-- User inputs "ギユウ"  
SELECT term FROM terms  
-- Prefix search against readings (Hit)  
WHERE readings &^~ 'ギユウ' OR  
-- Loose full text search  
term &@ 'ギユウ'  
ORDER BY term LIMIT 10; -- Sort
```



Search example: Hiragana

検索例：ひらがな

```
-- User inputs "ぎゅう"  
SELECT term FROM terms  
-- Prefix search against readings (Hit)  
WHERE readings &^~ 'ぎゅう' OR  
-- Loose full text search  
term &@ 'ぎゅう'  
ORDER BY term LIMIT 10; -- Sort
```



Search example: Romaji

検索例：ローマ字

```
-- User inputs "gyu"  
SELECT term FROM terms  
-- Prefix search against readings (Hit)  
WHERE readings &^~ 'gyu' OR  
-- Loose full text search  
term &@ 'gyu'  
ORDER BY term LIMIT 10; -- Sort
```



Synonym expansion

同義語展開

■ Synonym

同義語

- Same mean but different notation
同じ意味だが表記が異なる語
- e. g. : "PostgreSQL" and "PG"
例 : 「PostgreSQL」と「postgres」



Synonym expansion

同義語展開

- Users don't want to care
ユーザーは気にしたくない
- Synonym expansion
同義語展開
 - OR search with all synonyms
同義語すべてでOR検索



Implementation 実装方法

- Create synonym table
同義語管理テーブルを作成
- Expand synonyms in query
クエリー内の同義語を展開
- Search by expanded query
展開後のクエリーで検索

<https://pgroonga.github.io/reference/functions/pgroonga-query-expand.html>



Table definition

```
CREATE TABLE synonyms (  
  -- Term to be expanded  
  term text,  
  -- Synonym list.  
  -- Including the "term" itself.  
  -- If you don't input the "term",  
  -- the "term" is unsearchable term.  
  terms text[]  
);
```



Data example

```
INSERT INTO synonyms
VALUES ('PostgreSQL', -- Expand "PostgreSQL"
       ARRAY['PostgreSQL', 'PG']),
       ('PG', -- Expand "PG"
       ARRAY['PG', 'PostgreSQL']);
```



Data management

データ管理

- Easy to maintain because it's a normal table
普通のテーブルなので管理が楽
- Easy to insert/delete/update
追加・削除・更新が楽
- Normal backup and replication
ダンプ・リストアもレプリケーションもいつも通り



Index definition

```
CREATE INDEX synonym_search ON synonyms
  USING PGroonga
  -- ...text_term_search...
  -- For equal search
  (term pgroonga_text_term_search_ops_v2);
```



Confirm 確認方法

```
SELECT pgroonga_query_expand(  
  'synonyms', -- Table name  
  'term', -- Column name to be expanded  
  'terms', -- Column name for synonyms  
  'PostgreSQL' -- Query  
);  
-- '((PostgreSQL) OR (PG))'
```



Search 検索方法

```
SELECT title FROM entries
WHERE
-- title &@~ 'DB ((PostgreSQL) OR (PG))'
title &@~
    pgroonga_query_expand('synonyms',
                           'term',
                           'terms',
                           'DB PostgreSQL');
```



Similar search

類似文書検索

- Query is document itself
検索クエリーは文書そのもの
 - Not keyword
キーワードではない
- Use case
利用例
 - Show related entries
関連エントリーの提示に使える



Implementation

実現方法

■ Create dedicated index

類似検索用のインデックスを作る

■ Use tokenizer for target language

対象の言語に合わせた処理で精度向上

■ e. g. : MeCab based tokenizer for Japanese

例：日本語ならMeCabベースのトークナイザーを活用

■ Use dedicated operator

類似検索用の演算子を使う



Index definition

```
CREATE INDEX entries_similar_search
ON entries
-- Target: Both title and content
-- Reason: Title is important
USING PGroonga (id, (title || ' ' || content))
-- TokenMecab is good for Japanese
WITH (tokenizer='TokenMecab');
```



Search

```
SELECT title,  
       pgroonga_score(entries) AS score  
FROM entries  
WHERE  
       -- &@* is operator for similar search.  
       -- Search with existing document.  
       (title || ' ' || content) &@*  
       '...fast search with Groonga!...'  
ORDER BY score DESC LIMIT 3;
```



Result example

結果例

Query:

`...search with Groonga!...`

Hit example:

`...search with PGroonga!...`



Wrap up: Basic features

全文検索システム：基本機能

- **Fast FTS + sort**
高速全文検索＋ソート
- **Show texts around keyword**
キーワード周辺テキスト表示
- **Highlight keyword**
検索キーワードハイライト



Wrap up: Adv. features

全文検索システム：高度な機能

- Auto complete
オートコンプリート
- Similar search
類似文書検索
- Synonym expansion
同義語展開



FTS system: Next step

全文検索システム：次の一歩

■ Support structured data

構造化データ対応

- Office document, HTML, ...

オフィス文書・HTMLなど

■ Needed features

対応に必要な処理

- Text/metadata extraction

テキスト・メタデータ抽出

- Create screenshot

スクリーンショット作成



Extraction tool

抽出ツール

- Apache Tika
 - Apache Lucene's subproject
 - Many supported formats
対応フォーマットが多い
- ChupaText
 - Groonga's subproject
 - Screenshot support
スクリーンショット作成対応



ChupaText

- **Supported formats** (対応フォーマット)
 - Word/Excel/PowerPoint
 - ODT/ODS/ODP (OpenDocument)
 - PDF/HTML/XML/CSV/...
- **Interface** (インターフェイス)
 - HTTP and command line
HTTPとコマンドライン



Install インストール

■ Use Docker or Vagrant

DockerかVagrantを使うのが楽

- <https://github.com/ranguba/chupa-text-docker>
- <https://github.com/ranguba/chupa-text-vagrant>



ChupaText : Docker

```
% GITHUB=https://github.com
% git clone \
  ${GITHUB}/ranguba/chupa-text-docker.git
% cd chupa-text-docker
% docker-compose up --build
```



Usage

使い方

```
% curl \  
  --form data=@XXX.pdf \  
  http://localhost:20080/extraction.json
```



Result example

結果例

```
{
  "mime-type": "application/pdf", # MIME type for the original data
  "size": 147159, # Metadata
  ...,
  "texts": [ # Extracted texts
    {
      "mime-type": "text/plain", # MIME type for the extracted data
      ...,
      "creator": "Adobe Illustrator CS3", # Metadata
      "body": "This is sample PDF. ...", # Extracted text
      "screenshot": {
        "mime-type": "image/png", # MIME type for screenshot
        "data": "iVBORw...", # Base64-ed image data
        "encoding": "base64"
      }
    }
  ]
}
```



Web UI

ChupaText

Extraction

Data

参照...

ファイルが選択されていません。

URI (optional)

Extract



Web UI: Extraction example

Web UI: 抽出例

Extract

Metadata

mime-type	application/pdf
uri	file:/home/chupa-text/chupa-text-http-server/groonga-s and-pgroonga.pdf
path	/tmp/groonga-seminar-2017-08-mroonga-and-pgroong
size	857145

Text #1



Web UI: Extraction example

Web UI: 抽出例

Text #1



Mroonga・PGroongaを使った
全文検索システムの実装方法
須藤功平
株式会社クリアコード
MySQL・PostgreSQL上で動かす全文検索エン
—
2017-08-01
Mroonga・PGroongaを使った 全文検索シス
Powered by Rabbit 2.2.1
全文検索システム
対象
大量のテキスト
例: Wikiのデータ
例: オフィス文書のテキスト
例: 業務日報 - コピー



ChupaText : Vagrant

```
% GITHUB=https://github.com
% git clone \
  ${GITHUB}/ranguba/chupa-text-vagrant.git
% cd chupa-text-vagrant
% vagrant up
```

Usage is the same as Docker's
使い方はDocker版と同じ



Use cases (活用例)

- Extracted text
 - Insert into PGroonga
- Extracted metadata
 - Insert into PGroonga
 - Use for condition (絞り込みに活用)
- Created screenshot
 - Show in search result (検索結果で表示)



Wrap up

まとめ

- **FTS engine via PostgreSQL**
PostgreSQL経由で全文検索エンジン
 - **Provide decision info**
採用の判断材料を提供



Wrap up

まとめ

- Show how to impl. FTS system
全文検索システム実装例を紹介
 - PGroonga
- PGroonga 1.0.0 and 2
PGroonga 1.0.0と2
 - Painless upgrade



Wrap up

まとめ

- Show how to support structured data
構造化データの対応方法を紹介
 - ChupaText



Support service

サポートサービス紹介

- **Install support** (導入支援)
設計支援・性能検証・移行支援・…
- **Development support** (開発支援)
サンプルコード提供・問い合わせ対応・…
- **Operation support** (運用支援)
障害対応・チューニング支援・…

Contact (問い合わせ先)

<https://www.clear-code.com/contact/?type=groonga>