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ジン「Groonga」セミナー

2017-08-01

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：商品説明・口コミ

全文検索システム 目的

- 必要な情報を
- 必要なときに
- 活用

必要な情報を活用

- ×
  - 探している情報が見つからない
- ○
  - 探している情報が見つかる
- ◎
  - 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！

必要なときに活用

- ×
  - なかなか見つからない
- ○
  - すぐに見つかる
- ◎
  - すでに見つかっていた
  - 例：レコメンデーション

実装方法
選択肢

- 全文検索サーバーを使う
- RDBMSを使う
  - MySQL・MariaDB・PostgreSQLを使う

全文検索サーバー案 メリット

- 必要な機能が揃っている
- +αの機能もある
- 速い

全文検索サーバー案 デメリット

- 実装コスト大
  - それぞれ独自の使い方だから
  - マスターデータの同期はどうする？
- メンテナンスコスト大
  - それぞれ独自の仕組みだから

RDBMS案 メリット

- 実装コスト小
  - 新しく覚えることが少ない
  - データの一元管理
- メンテナンスコスト小
  - 既存の運用ノウハウを使える

RDBMS案 デメリット

- 組込機能では機能不足
- SQLの表現力不足
  - 1クエリーで実現できない機能アリ
  - ↑は性能を出しにくい

実現方法
第3の選択肢

- RDBMS経由（SQL）で
  全文検索エンジンを使う

メリット

- 高速で豊富な機能
- 実装コスト小
- メンテナンスコスト小

デメリット

- RDBMSに拡張機能が必要
  - DBaaSで使えない

オススメの選択肢
全文検索の知識ナシ

- まだ単純な機能で十分
  - データ少：RDBMS単独でLIKE
（数十万件とか）
  - データ中：RDBMS組込全文検索機能
- いまどきの全文検索機能が必要
  - RDBMS経由で全文検索エンジン

オススメの選択肢
全文検索の知識アリ

- カリカリにチューニングしたい
  - RDBMSと全文検索サーバーを併用
- それ以外
  - RDBMS経由で全文検索エンジン

説明する選択肢

RDBMS経由で
全文検索
エンジン

全文検索エンジン Groonga（ぐるんが）

- 組込可能な全文検索エンジン
  - MySQL・MariaDBに組込→Mroonga
  - PostgreSQLに組込→PGoonga
- 全文検索サーバーとして単独でも使用可能
  - RDBMSと全文検索サーバーを併用もできる

Groongaの得意なこと

- データの追加・更新
  - 新鮮な情報をすぐに検索可能に！
  - 更新中も検索性能を落とさない！
- 日本語
  - 開発者が日本人
  - 便利機能が組み込み

Mroonga（むるんが）

- MySQLのストレージエンジン
  - InnoDB・MyISAMなどと同じレイヤー
- 使用方法
  - CREATE TABLE (...)
    ENGINE=Mroonga

MySQL組込の全文検索機能

- MySQL：5.7から使える
  - InnoDB＋日本語対応パーサー
- MariaDB：10.0.15から使える
  - Mroongaをバンドル

全文検索機能：基本

	InnoDB	Mroonga
AND/OR/NOT対応	○	○
ハイライト	×	○
周辺テキスト表示	×	○

ハイライト
周辺テキスト表示

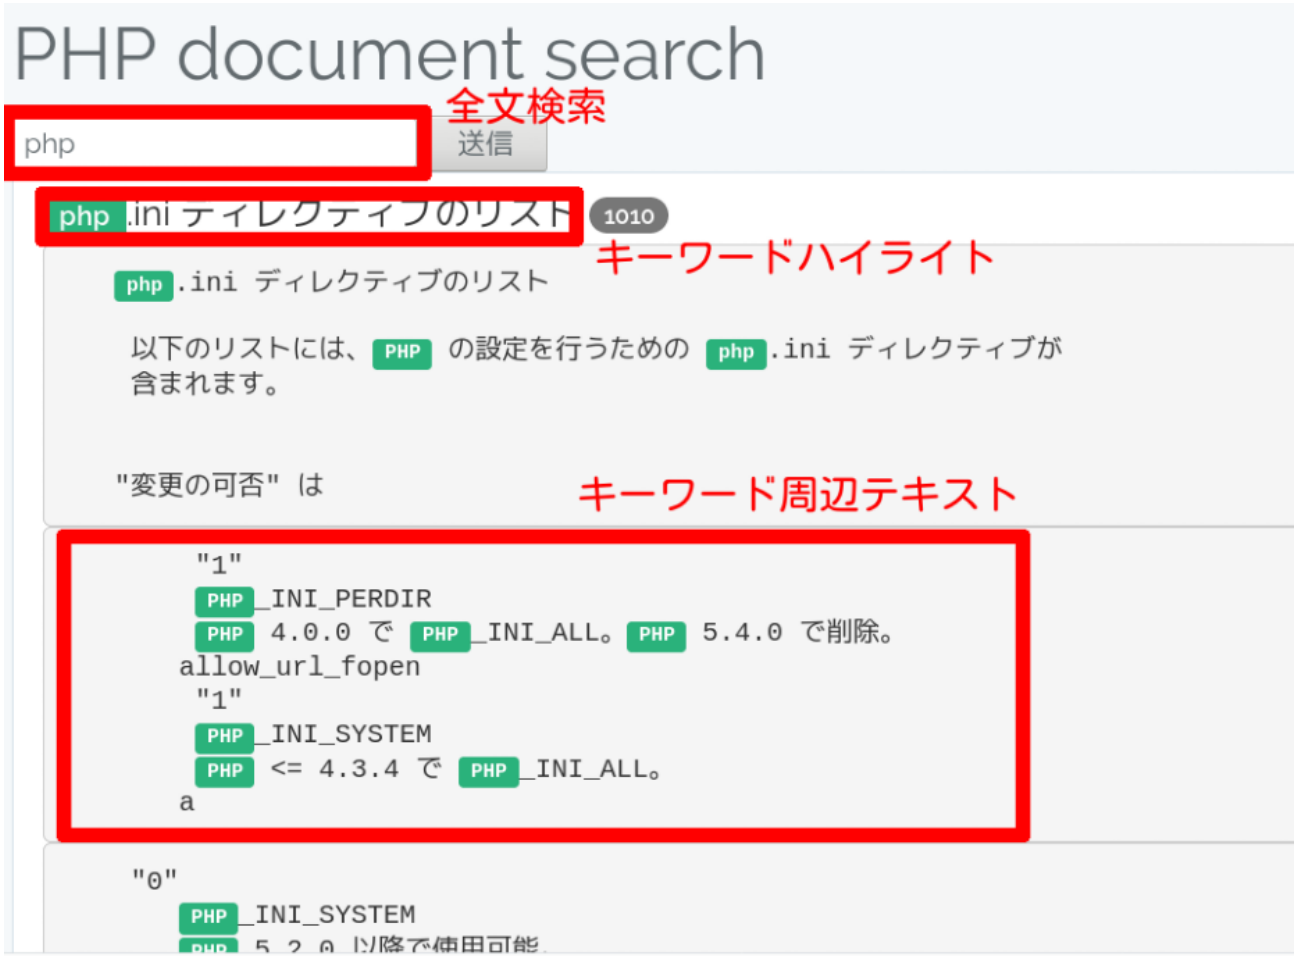

全文検索機能：高度な機能

	InnoDB	Mroonga
入力補完	×	○
類似文書検索	○	○
クエリー展開	○	○

全文検索性能の違い 計測データ

- 対象：Wikipedia日本語版
- レコード数：約185万件
- データサイズ：約7GB
- メモリー4GB・SSD250GB (ConoHa)

検索性能1

キーワード：テレビアニメ

（ヒット数：約2万3千件）

InnoDB ngram	3m2s
InnoDB MeCab	6m20s
Mroonga:1	0.11s

検索性能2

キーワード：データベース

（ヒット数：約1万7千件）

InnoDB ngram	36s
InnoDB MeCab:1	0.03s
Mroonga:2	0.09s

検索性能3

キーワード：PostgreSQL OR MySQL

（ヒット数：約400件）

InnoDB ngram	N/A(Error)
InnoDB MeCab:1	0.005s
Mroonga:2	0.028s

検索性能4

キーワード：日本

（ヒット数：約63万件）

InnoDB ngram	1.3s
InnoDB MeCab	1.3s
Mroonga:1	0.21s

検索性能まとめ

- Mroonga：安定して速い
  - **SQLで使えて機能豊富で速い！**
- InnoDB FTS MeCab
  - ハマれば速い
- InnoDB FTS ngram
  - 安定して遅い

全文検索システムの実装 Mroonga

- 全文検索
- キーワードハイライト
- 周辺テキスト表示
- 入力補完
- 関連文書の表示

全文検索

PHP document search

全文検索

php

送信

php .ini ディレクティブのリスト 1010

キーワードハイライト

php .ini ディレクティブのリスト

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

キーワード周辺テキスト

"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。

テーブル定義

```
CREATE TABLE entries (
  title text,
  content text,
  -- 全文検索用インデックス
  -- よくわからないならデフォルトのまま使うこと！
  FULLTEXT INDEX (title, content)
) ENGINE=Mroonga
  DEFAULT CHARSET=utf8mb4;
```

データ挿入

```
-- 普通に挿入するだけでよい
INSERT INTO entries
  VALUES ('タイトル',
          '高速に全文検索したいですね！');
```

全文検索

```
SELECT title FROM entries
  WHERE -- MATCH AGAINSTで全文検索
    MATCH (title, content)
    -- デフォルトORがMySQLの仕様
    -- 「検索」または「高速」を含むとマッチ
    AGAINST ('検索 高速'
             IN BOOLEAN MODE);
```

AND全文検索

```
MATCH (title, content)
-- 各キーワードの前に「+」をつけるとAND
-- 「検索」かつ「高速」を含むとマッチ
AGAINST ('+検索 +高速'
         IN BOOLEAN MODE);
```

使いやすいAND全文検索

```
MATCH (title, content)
 -- 最初に「*D+」をつけるとデフォルトAND
 -- Mroonga独自機能
 --  「検索」かつ「高速」を含むとマッチ
AGAINST ('*D+ 検索 高速'
            IN BOOLEAN MODE);
```

スコアー

```
SELECT
  title,
  -- ここのMATCH AGAINSTはスコアーを返す
  MATCH (title, content)
    AGAINST ('*D+ 検索 高速'
             IN BOOLEAN MODE) AS score
  FROM entries
  WHERE -- ...
  -- スコアーが高い順にソート
  ORDER BY score DESC LIMIT 10;
```

ハイライト

PHP document search

全文検索

php

送信

php .ini ディレクティブのリスト 1010

キーワードハイライト

php .ini ディレクティブのリスト

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

キーワード周辺テキスト

"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。

ハイライト

```
SELECT mroonga_highlight_html(
         title, '*D+ 検索 高速' AS query)
  -- クエリーからハイライト対象のキーワードを抽出
  FROM entries
  WHERE
    MATCH (title, content)
    AGAINST ('*D+ 検索 高速' IN BOOLEAN MODE);
```

ハイライト結果例

```
<Groonga>で高速全文検索！
↓
&lt;Groonga&gt;で ← タグをエスケープ
<span class="keyword">高速</span>
全文 ↑↓キーワードはclass付け
<span class="keyword">検索</span>！
```

周辺テキスト

PHP document search

全文検索

php

送信

php .ini ディレクティブのリスト 1010

キーワードハイライト

php .ini ディレクティブのリスト

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

キーワード周辺テキスト

"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。

周辺テキスト

```
SELECT mroonga_snippet_html(
         content, '*D+ 検索 高速' AS query)
  -- クエリーから対象のキーワードを抽出
  FROM entries
  WHERE
    MATCH (title, content)
    AGAINST ('*D+ 検索 高速' IN BOOLEAN MODE);
```

周辺テキスト結果例

```
...<Groonga>で高速全文検索！...
↓
<div class="snippet"> ←1つ目
ga&gt;で ←タグをエスケープ
<span class="keyword">高速</span>
全文 ↑↓キーワードはclass付け
<span class="keyword">検索/span>！
</div>
<div class="snippet">...</div> ←2つ目
```

類似文書検索

- 検索クエリーは文書そのもの
  - キーワードではない
- 関連エントリーの提示に使える
  - メタデータがあるなら組み合わせる
    →精度向上
  - メタデータ：タグ・行動履歴など

類似文書検索 インデックス定義

```
CREATE TABLE entries (
  -- ...
  FULLTEXT INDEX (content)
    -- TokenMecabを使わないと精度がでない
    -- 必要なときだけカスタマイズ！
    COMMENT 'tokenizer "TokenMecab"'
) -- ...
```

類似文書検索
検索方法

```
SELECT title
  FROM entries
  WHERE
    MATCH (content)
    ↓ 既存文書の内容をそのまま指定
    AGAINST ('...Groongaで高速全文検索！...'
             IN NATURAL LANGUAGE MODE);
```

類似文書検索 結果例

クエリー：

...Groongaで高速全文検索！...

ヒット例：

...Mroongaで高速全文検索！...

照合順序：COLLATION

- 文字の並び順の規則
  - 文字が同一かどうかの判定にも利用
- 適切な日本語規則なし
  - いわゆる  ＝  問題

MySQL 8では適切な日本語規則が追加される

Mroongaの照合順序

- MySQL互換のもの
- MySQL互換を微調整したもの
  - 日本語でもいい感じ
- Groonga提供のもの
  - 日本語でもいい感じ

微調整した照合順序

```
FULLTEXT INDEX (content)
  COMMENT 'normalizer "${ノーマライザー名}"'
ノーマライザー名：
  NormalizerMySQLUnicode520CI
    ExceptKanaCI
          KanaWithVoicedSoundMark
```

PGroonga (ぴーじーるんが)

- PostgreSQLのインデックス
  - B-tree・GINなどと同じレイヤー
- 使用方法
  - CREATE INDEX ...
    USING PGroonga ...

PostgreSQLの全文検索機能

- textsearch（組込）
  - 言語依存
  - 日本語対応はメンテされていない
- pg_trgm（同梱）
  - 言語非依存：が、ほぼ日本語非対応
- pg_bigm（サードパーティー）
  - 言語非依存：日本語対応

全文検索機能：基本

	pg_bigm	PGroonga
AND/OR/NOT対応	△※1	○
ハイライト	△※2	○
周辺テキスト表示	△※2	○

※1 SQLでAND/OR/NOTを組み合わせると実現可能

※2 PostgreSQLが提供する関数で実現可能。ただし、結果をHTMLで出力する用途では使えない。

全文検索機能：高度な機能

	pg_bigm	PGroonga
入力補完	×	○
類似文書検索	△※	○
クエリー展開	×	○

※ 類似文書検索と言うよりはあいまい検索。

全文検索性能の違い 計測データ

- 対象：Wikipedia日本語版
- レコード数：約90万件
- データサイズ：約6GB
- メモリー32GB・SSD500GB

検索性能1

キーワード：テレビアニメ

（ヒット数：約2万件）

pg_bigm	2.800s
PGroonga:1	0.065s
Groonga(参考)	0.038s

検索性能2

キーワード：データベース

（ヒット数：約1万5千件）

pg_bigm	1.300s
PGroonga:1	0.049s
Groonga(参考)	0.031s

検索性能3

キーワード：PostgreSQL OR MySQL

（ヒット数：約300件）

pg_bigm	0.049s
PGroonga:1	0.002s
Groonga(参考)	0.001s

検索性能4

キーワード：日本

（ヒット数：約53万件）

pg_bigm:1	0.479s
PGroonga	0.563s
Groonga(参考)	0.059s

検索性能まとめ

- PGroonga：安定して速い
  - **SQLで使えて機能豊富で速い！**
- pg_bigm
  - ヒット数が少なければ速い
  - キーワードが2文字以下なら速い

全文検索システムの実装 PGroonga

- 全文検索
- キーワードハイライト
- 周辺テキスト表示
- 入力補完
- 関連文書の表示

全文検索

PHP document search

全文検索

php

送信

php .ini ディレクティブのリスト 1010

キーワードハイライト

php .ini ディレクティブのリスト

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

キーワード周辺テキスト

"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。

テーブル定義

```
CREATE TABLE entries (
  -- プライマリーキーを用意する
  -- スコアーでソートするために必要
  id integer PRIMARY KEY,
  title text,
  content text
);
```

インデックス定義

```
-- 全文検索用インデックス
-- よくわからないなら
-- デフォルトのまま使うこと！
CREATE INDEX entries_full_text_search
  ON entries
  --「USING PGroonga」=「PGroongaを使う」
  USING PGroonga (id, title, content);
```

データ挿入

```
-- 普通に挿入するだけでよい
INSERT INTO entries
  VALUES (1,
          'Groongaで高速全文検索！',
          '高速に全文検索したいですね！');
```

全文検索

```
SELECT title FROM entries
  WHERE
-- &@~で全文検索
--  「検索」と「高速」をAND検索
    title &@~ '検索 高速' OR
    content &@~ '検索 高速';
```

全文検索：LIKE

```
SELECT title FROM entries
  WHERE
-- LIKEでもインデックスが効く
--＝アプリを書き換えずに高速化可能
-- ただし&@~より性能が落ちる
    title LIKE '%検索%' OR
    content LIKE '%検索%';
```

スコアー

```
SELECT
    title,
    -- pgroonga.score(テーブル名)で
    -- スコアーを取得
    pgroonga.score(entries) AS score
  FROM entries
  WHERE -- ...
  -- スコアーが高い順にソート
  ORDER BY score DESC LIMIT 10;
```

ハイライト

PHP document search

全文検索

php

送信

php .ini ディレクティブのリスト 1010

キーワードハイライト

php .ini ディレクティブのリスト

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

キーワード周辺テキスト

"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

ハイライト

```
SELECT
  pgroonga.highlight_html(
    title,
    -- クエリーから対象キーワードを抽出
    pgroonga.query_extract_keywords('検索 高速'))
  FROM entries
  WHERE title &@~ '検索 高速' OR
        content &@~ '検索 高速';
```

ハイライト結果例

```
<Groonga>で高速全文検索！
↓
&lt;Groonga&gt;で ← タグをエスケープ
<span class="keyword">高速</span>
全文 ↑↓キーワードはclass付け
<span class="keyword">検索</span>！
```

周辺テキスト

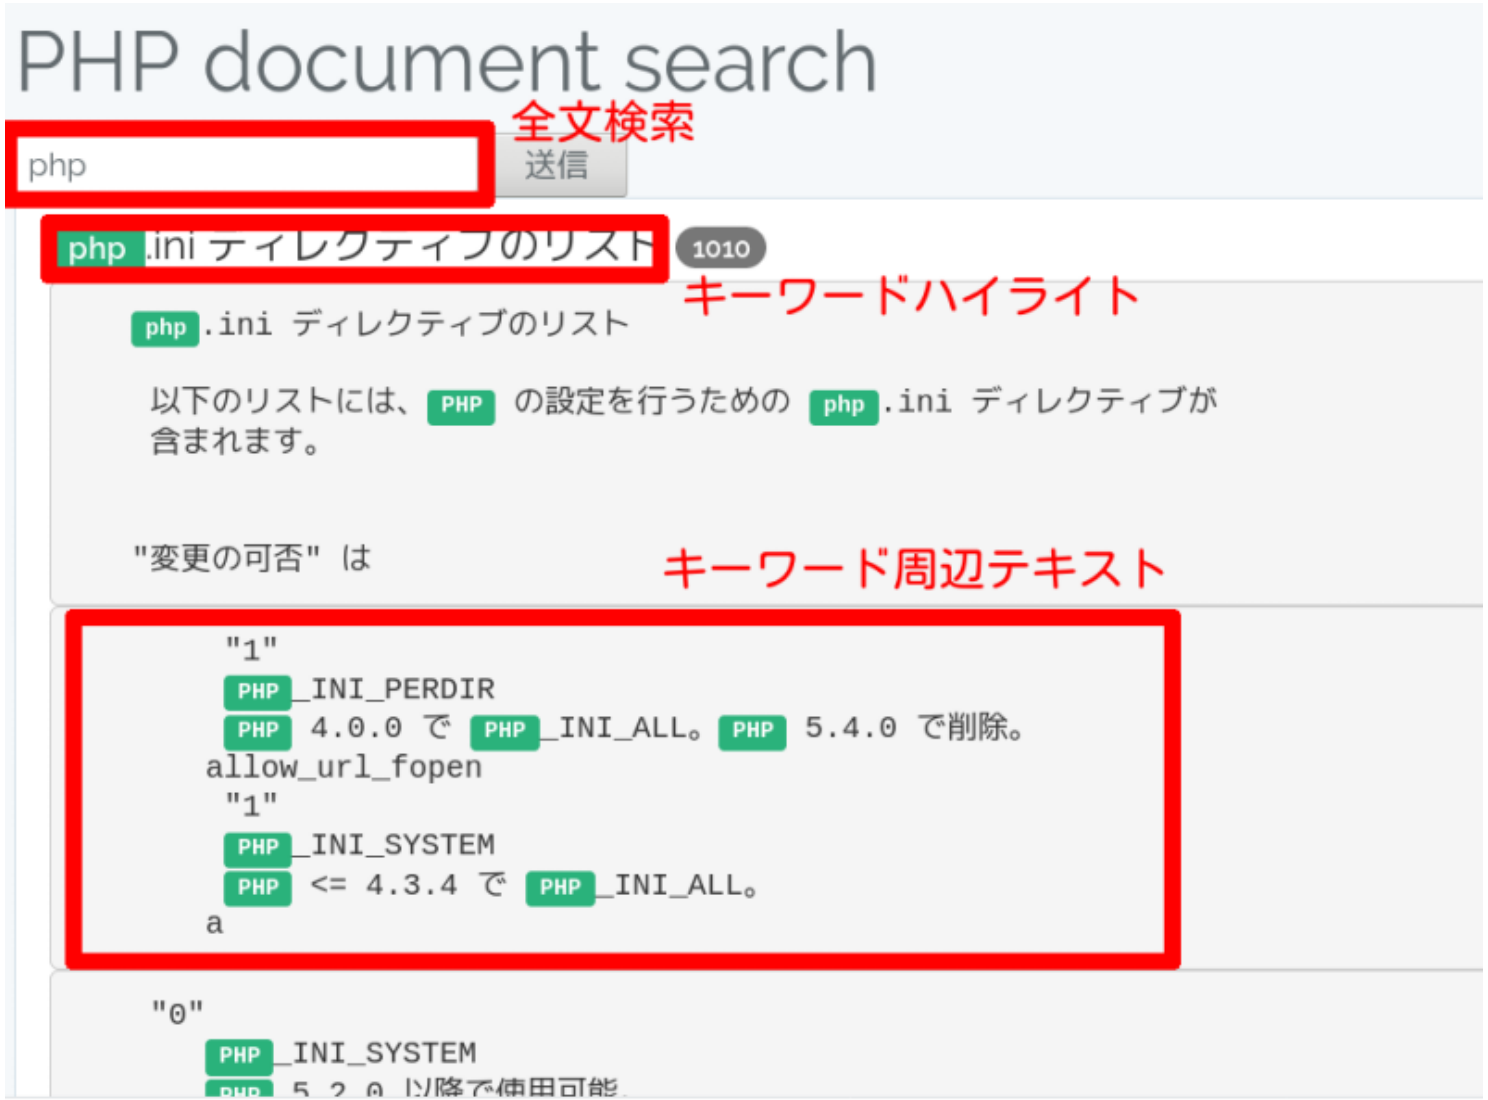
PHP document search
全文検索
php
送信
php.ini ディレクティブのリスト
1010
キーワードハイライト
php.ini ディレクティブのリスト
以下のリストには、PHP の設定を行うための php.ini ディレクティブが含まれます。
"変更の可否" は
キーワード周辺テキスト
"1"
PHP_INI_PERDIR
PHP 4.0.0 で PHP_INI_ALL。PHP 5.4.0 で削除。
allow_url_fopen
"1"
PHP_INI_SYSTEM
PHP <= 4.3.4 で PHP_INI_ALL。
a
"0"
PHP_INI_SYSTEM

周辺テキスト

```
SELECT
  pgroonga.snippet_html(
    content,
    -- クエリーから対象キーワードを抽出
    pgroonga.query_extract_keywords('検索 高速'))
  FROM entries
  WHERE title &@~ '検索 高速' OR
        content &@~ '検索 高速';
```

周辺テキスト結果例

```
...<Groonga>で高速全文検索！...
↓
ARRAY[
   ↓ 1つ目
   'ga&gt;で ←タグをエスケープ
    <span class="keyword">高速</span>
    全文 ↑↓キーワードはclass付け
    <span class="keyword">検索/span>！',
   '...' ← 2つ目
]
```

入力補完

PHP document search

seiki

送信

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

o

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

入力補完実装方法

- 以下の検索のOR
  - 前方一致検索
  - ヨミガナでの前方一致検索
  - 緩い全文検索
- 表示文字列でソートして提示

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

入力補完 テーブル定義

```
CREATE TABLE terms (
  -- 補完候補
  term text,
  -- この候補のヨミガナ（N個可）
  readings text[]
);
```

入力補完データ例

```
INSERT INTO terms VALUES (
  '牛乳', -- 補完候補
  ARRAY[
    -- ヨミガナはカタカナで指定する
    'ギュウニュウ',
    -- 「ミルク」でも補完できるようになる
    'ミルク'
  ]
);
```

入力補完
データ管理のポイント

- 普通のテーブルなので管理が楽
  - 追加・削除・更新が楽
  - ダンプ・リストアもいつも通り
  - レプリケーションもいつも通り

入力補完
前方一致用インデックス

```
CREATE INDEX prefix_search ON terms
  USING PGroonga
    -- ...text_term_search...
  (term pgroonga.text_term_search_ops_v2,
    -- ...text_array_term_search...
   readings pgroonga.text_array_term_search_ops_v2);
```

入力補完
緩い全文検索用

```
CREATE INDEX loose_search ON terms
  USING PGroonga
  -- ...text_full_text_search...
  (term pgroonga.text_full_text_search_ops_v2)
  -- 緩い全文検索用トークナイザー
  WITH (tokenizer='TokenBigramSplitSymbolAlphaDigit');
```

入力補完検索方法

```
SELECT term FROM terms
         -- 前方一致検索
  WHERE term &^ '${入力}' OR
         -- ローマ字で前方一致検索
         readings &^~ '${入力}' OR
         -- 緩い全文検索
         term &@ '${入力}'
  ORDER BY term LIMIT 10; -- ソート
```

入力補完
検索例：漢字1

```
-- ユーザーが「牛」を入力した場合
SELECT term FROM terms
         -- 前方一致検索（ヒット）
  WHERE term &^ '牛' OR
  -- ヨミガナで前方一致検索
         readings &^~ '牛' OR
         -- 緩い全文検索（ヒット）
         term &@ '牛'
  ORDER BY term LIMIT 10; -- ソート
```

入力補完
検索例：漢字2

```
-- ユーザーが「乳」を入力した場合
SELECT term FROM terms
          -- 前方一致検索
  WHERE term &^ '乳' OR
  -- ヨミガナで前方一致検索
          readings &^~ '乳' OR
          -- 緩い全文検索（ヒット）
          term &@ '乳'
  ORDER BY term LIMIT 10; -- ソート
```

入力補完
検索例：カタカナ

```
-- ユーザーが「ギュウ」を入力した場合
SELECT term FROM terms
         -- 前方一致検索
  WHERE term &^ 'ギュウ' OR
-- ヨミガナで前方一致検索（ヒット）
         readings &^~ 'ギュウ' OR
         -- 緩い全文検索
         term &@ 'ギュウ'
  ORDER BY term LIMIT 10; -- ソート
```

入力補完
検索例：ひらがな

```
-- ユーザーが「ぎゅう」を入力した場合
SELECT term FROM terms
          -- 前方一致検索
  WHERE term &^ 'ぎゅう' OR
-- ヨミガナで前方一致検索（ヒット）
          readings &^~ 'ぎゅう' OR
          -- 緩い全文検索
          term &@ 'ぎゅう'
  ORDER BY term LIMIT 10; -- ソート
```

入力補完
検索例：ローマ字

```
-- ユーザーが「gyu」を入力した場合
SELECT term FROM terms
          -- 前方一致検索
  WHERE term &^ 'gyu' OR
-- ヨミガナで前方一致検索（ヒット）
          readings &^~ 'gyu' OR
          -- 緩い全文検索
          term &@ 'gyu'
  ORDER BY term LIMIT 10; -- ソート
```

同義語展開

- 同義語
  - 同じ意味だが表記が異なる語
  - 例：「刺身」と「お造り」
- どの表記でもヒットして欲しい
  - 同義語展開→同義語すべてでOR検索

同義語展開 実装方法

- 同義語管理テーブルを作成
- クエリー内の同義語を展開
- 展開後のクエリーで検索

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

同義語展開 テーブル定義

```
CREATE TABLE synonyms (
  -- 展開対象の語
  term text,
  -- 同義語のリスト
  -- term自身も含める
  -- 含めない場合はtermが検索禁止語になる
  terms text[]
);
```

同義語展開データ例

```
INSERT INTO synonyms
  VALUES ('刺身', -- 「刺身」を展開
          ARRAY['刺身', 'お造り']),
         ('お造り', -- 「お造り」を展開
          ARRAY['お造り', '刺身']);
```

同義語展開 データ管理のポイント

- 普通のテーブルなので管理が楽
  - 追加・削除・更新が楽
  - ダンプ・リストアもいつも通り
  - レプリケーションもいつも通り

同義語展開 インデックス定義

```
CREATE INDEX synonym_search ON synonyms
  USING PGroonga
  -- ...text_term_search...
  -- termで完全一致検索をするため
  (term pgroonga.text_term_search_ops_v2);
```

同義語展開確認方法

```
SELECT pgroonga.query_expand(
  'synonyms', -- テーブル名
  'term', -- 展開対象のカラム名
  'terms', -- 対応する同義語配列のカラム名
  '刺身' -- クエリー
);
-- '((刺身) OR (お造り))'
```

同義語展開検索方法

```
SELECT title FROM entries
  WHERE
 -- title &@~ '和食 OR ((刺身) OR (お造り))'になる
    title &@~
      pgroonga.query_expand('synonyms',
                            'term',
                            'terms',
                            '和食 OR 刺身');
```

類似文書検索

- 検索クエリーは文書そのもの
  - キーワードではない
- 関連エントリーの提示に使える
  - メタデータがあるなら組み合わせる
    →精度向上
  - メタデータ：タグ・行動履歴など

類似文書検索 インデックス定義

```
CREATE INDEX entries_similar_search
  ON entries
  USING PGroonga (
    id,
    -- pg...v2の指定がポイント
    content pgroonga.text_full_text_search_ops_v2
    -- TokenMecabを使うと精度向上
  ) WITH (tokenizer='TokenMecab');
```

類似文書検索
検索方法

```
SELECT title
  FROM entries
  WHERE
    -- &~?で類似文書検索
    -- 既存文書の内容をそのまま指定
    content &~?
      '...Groongaで高速全文検索！...';
```

類似文書検索 結果例

クエリー：

...Groongaで高速全文検索！...

ヒット例：

...PGroongaで高速全文検索！...

全文検索システムの実装 まとめ

- 全文検索
- キーワードハイライト
- 周辺テキスト表示
- 入力補完
- 関連文書の表示

全文検索システムの実装 次の一歩

- 構造化データ対応
  - オフィス文書・HTMLなど
- 対応に必要な処理
  - テキスト抽出
  - メタデータ抽出（例：タイトル・更新日時）
  - スクリーンショット作成（なおよい）

抽出ツール

- Apache Tika
  - Apache Luceneのサブプロジェクト
  - 対応フォーマット数が多い
- ChupaText
  - Groongaのサブプロジェクト
  - スクリーンショット作成対応

ChupaText

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

ChupaText：インストール

- 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
```

ChupaText：使い方

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

ChupaText：結果例

```
{
  "mime-type": "application/pdf", # 元データのMIMEタイプ
  "size": 147159, # メタデータ
  ...,
  "texts": [ # 抽出されたテキスト（N個）
    {
      "mime-type": "text/plain", # 抽出後のMIMEタイプ
      ...,
      "creator": "Adobe Illustrator CS3", # メタデータ
      "body": "This is sample PDF. ...", # 抽出したテキスト
      "screenshot": {
        "mime-type": "image/png", # スクリーンショットのMIMEタイプ
        "data": "iVBORw...", # Base64にした画像データ
        "encoding": "base64" # Base64であることを明記
      }
    }
  ]
}
```

ChupaText：Web UI

ChupaText

Extraction

Data

参照... ファイルが選択されていません。

URI (optional)

Extract

ChupaText：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

ChupaText：Web UI抽出例

Text #1

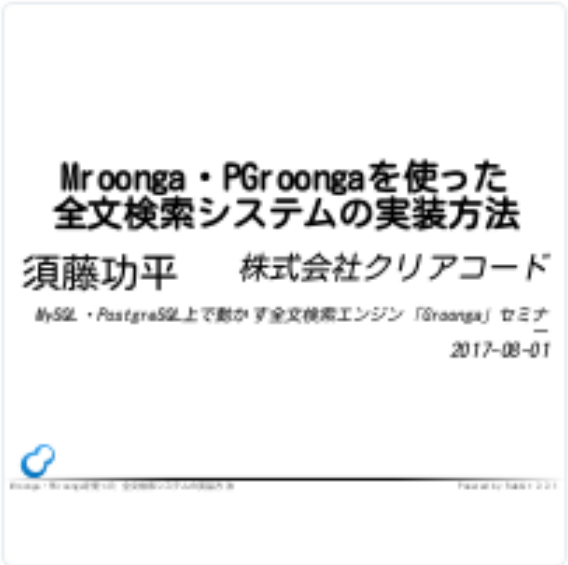

Mroonga・PGroongaを使った
全文検索システムの実装方法
須藤功平
株式会社クリアコード
MySQL・PostgreSQL上で動かす全文検索エン
ー
2017-08-01
Mroonga・PGroongaを使った 全文検索シス
Powered by Rabbit 2.2.1
全文検索システム
対象
大量のテキスト
例：Wikiのデータ
例：オフィス文書のテキスト
例：商品説明・口コミ

ChupaText：Vagrant

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

使い方はDocker版と同じ

ChupaText：活用例

- 抽出したテキスト
  - Mroonga・PGroongaへ挿入
- 抽出したメタデータ
  - Mroonga・PGroongaへ挿入
  - 絞り込みに活用
- 作成したスクリーンショット
  - 検索結果表示時に掲載

まとめ

- RDBMS経由で全文検索エンジン
  - 採用の判断材料を提供
- 全文検索システム実装例を紹介
  - Mroonga・PGroonga両方
- 構造化データの対応方法を紹介
  - ChupaText

扱わなかった話題

- 運用について
  - 障害対策・レプリケーション
- チューニング
- Groongaの機能を直接使う方法

今後のセミナーの話題にするには
実例ベースの方がやりやすいので
あなたのケースを教えてください

サポートサービス紹介

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

問い合わせ先：

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