

MySQLと PostgreSQLと 日本語全文検索

Azure Databaseで
Mroonga・PGroongaを使いたいですよね！？

須藤功平

クリアコード

OSS on Azure非公式コミュニティ #5 『Azure Database』勉強会
2017-06-26





アンケート

Azure Databaseで
高速な日本語全文検索を
したい人！

最後にもう一度似たようなことを聞くよ！



日本語全文検索：LIKE

LIKE

- 😊 SQL標準
 - MySQLでもPostgreSQLでも使える
- 😊 少ないデータなら速度は十分
 - 400文字×20万件くらいなら1秒とか



LIKEのパフォーマンス

- 😞 少なくないデータ
 - レスポンスが遅い
- 😞 多くの同時アクセス
 - スループットがでない
 - 1回のLIKE毎にCPUが専有されるため

パフォーマンスの考え方

- 少ないデータ &&
多くない同時アクセス
 - LIKEで十分
- 少なくないデータ ||
多くの同時アクセス
 - 高速化が必要



高速日本語全文検索

インデックスで高速化できる

- MySQL
 - 5.7から標準対応
- PostgreSQL
 - GIN (組込) + pg_trgm (標準添付)



高速？

ベンチマーク！

- 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)

<https://github.com/groonga/wikipedia-search/issues/4>

(他人のベンチマークは参考程度)
(検討時はちゃんと実際の環境でベンチマークをとろう！)



注意

- pg_trgmではなくpg_bigmを使用
 - pg_bigm：外部プラグイン
 - 性能の傾向はだいたい同じ
 - 1, 2文字のときはpg_bigmの方が速い
 - 3文字以上はpg_trgmの方が速い



検索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
pg_bigm	4s



検索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	0.03s
pg_bigm	2s



検索3

キーワード：PostgreSQL OR MySQL
(ヒット数：約400件)

InnoDB ngram	N/A (エラー)
InnoDB MeCab	0.005s
pg_bigm	0.185s



検索4

キーワード：日本

(ヒット数：約63万件)

InnoDB ngram	1.3s
InnoDB MeCab	1.3s
pg_bigm	0.84s



高速…？

- InnoDB FTS MeCab
 - ハマれば速い
 - クエリーが複数語だと遅い
- pg_bigm
 - ハマれば速い
 - ヒット数が多いと遅い
- InnoDB FTS ngram : 安定して遅い



Mroonga ・ PGroonga

- Mroonga (むるんが)
 - MySQLに
高速日本語全文検索機能を追加する
プロダクト
- PGroonga (ぴーじーるんが)
 - PostgreSQLに
高速日本語全文検索機能を追加する
プロダクト



検索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
pg_bigm	4s
PGroonga: 2	0.29s



検索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
pg_bigm	2s
PGroonga: 3	0.17s



検索3

キーワード：PostgreSQL OR MySQL
(ヒット数：約400件)

InnoDB ngram	N/A (エラー)
InnoDB MeCab: 1	0.005s
Mroonga: 2	0.028s
pg_bigm	0.185s
PGroonga: 3	0.063s



検索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
pg_bigm:2	0.84s
PGroonga	1s



検索速度まとめ

- Mroonga ・ PGroonga
 - 安定して速い
- InnoDB FTS MeCab ・ pg_bigm
 - ハマれば速い
- InnoDB FTS ngram
 - 安定して遅い



Mroonga (むるんが)

MySQLに
高速日本語
全文検索機能を
追加

Mroonga : インデックス作成

普通のMySQLの使い方

```
CREATE TABLE ... (  
    ...,  
    FULLTEXT INDEX (column)  
) ENGINE=Mroonga;
```



Mrroonga : 全文検索

普通のMySQLの使い方

```
SELECT * FROM ...  
WHERE  
  MATCH(column)  
  AGAINST('キーワード'  
          IN BOOLEAN MODE);
```



Mroonga : クエリー言語

デフォルトOR→AND

```
-- ↓AまたはBが含まれていればマッチ  
AGAINST('A B' IN BOOLEAN MODE);  
AGAINST('+A +B' IN BOOLEAN MODE);  
-- ↑ ↓AとBが含まれていればマッチ  
-- ↓Mroongaの拡張  
AGAINST('*D+ A B' IN BOOLEAN MODE);
```



Mroonga : Windows

Windows用バイナリーあり

- MariaDBとセット
- ダウンロードして展開するとすぐに使える



PGroonga

PostgreSQLに
高速日本語
全文検索機能を
追加

普通のPostgreSQLの使い方

```
CREATE INDEX name ON texts  
    USING pgroonga (content);
```



PGroonga : 全文検索

専用演算子を使用

```
SELECT * FROM ...  
WHERE  
  column &? 'キーワード';
```



PGroonga : JSON

JSON内の全テキストを全文検索

```
CREATE TABLE logs (record jsonb);
CREATE INDEX i ON logs
  USING pgroonga (record);
-- ログのどこかに「error」があればマッチ
SELECT * FROM logs
  WHERE record &? 'error';
```

以下は全部マッチ

```
{ "message": "Error!" }  
{ "tags": [ "web", "error" ] }  
{ "syslog": { "message": "error!" } }
```



PGroonga : 入力補完1

検索ボックスで便利なアレ

```
CREATE TABLE terms
  (term text,          -- 候補単語
   readings text[]); -- ヨミガナ
-- インデックス
CREATE INDEX i ON terms USING pgroonga
  (term pgroonga.text_term_search_ops_v2,
   readings pgroonga.text_array_term_search_ops_v2);
```



PGroonga : 入力補完2

用意するデータ：
候補とカタカナのヨミガナだけ

```
INSERT INTO terms
VALUES
  ('牛乳', -- 補完候補
   ARRAY['ギユウニユウ', -- ヨミガナ1
         'ミルク']);      -- ヨミガナ2
```



PGroonga : 入力補完3

ローマ字で検索

```
SELECT term FROM terms
-- 「ギユウニユウ」にヒット
WHERE readings &^~ 'gy';
-- term
-- -----
-- 牛乳
-- (1 row)
```




PGroonga : 入力補完4

ひらがなで検索

```
SELECT term FROM terms
-- 「ギユウニユウ」にヒット
WHERE readings &^~ 'ぎゅう';
-- term
-- -----
-- 牛乳
-- (1 row)
```



PGroonga : 入力補完5

カタカナで検索

```
SELECT term FROM terms
-- 「ギユウニユウ」にヒット
WHERE readings &^~ 'ギユウ';
-- term
-- -----
-- 牛乳
-- (1 row)
```



PGroonga : 入力補完6

別のヨミガナでもヒット

```
SELECT term FROM terms
-- 「ミルク」にヒット
WHERE readings &^~ 'mi';
-- term
-- -----
-- 牛乳
-- (1 row)
```



PGroonga : 入力補完7

漢字でもヒット

```
SELECT term FROM terms
-- 「牛乳」にヒット
WHERE readings &^ '牛';
-- term
-- -----
-- 牛乳
-- (1 row)
```



PGroonga : Windows

Windows用バイナリーあり

- 商用ログ管理製品
「VVAULT AUDIT」が採用
<http://vvault.jp/product/vvault-audit/>
 - アクセスログに対して
ユーザー名・パスを全文検索
- 決め手：高速・省スペース



まとめ

- Mroonga (むるんが)
 - MySQLで高速日本語全文検索！
 - しかも使いやすいし便利！
- PGroonga (ぴーじーるんが)
 - PostgreSQLで高速日本語全文検索！
 - しかも使いやすいし便利！



アンケート1

Azure Databaseで
高速な日本語全文検索を
したい人！

最初より増えているといいな



アンケート2

Azure Databaseで
Mroonga・PGroongaを
使いたい人！

Azure Database開発者にアピールして！
どういう風に使いたいかわせて！