

Groonga族 2015

須藤功平

株式会社クリアコード

Groonga Meatup 2015
2015-11-29





内容

- Groonga族の概要
- Groonga族の最新情報
- Groonga族の今後の情報



Groonga族

総称

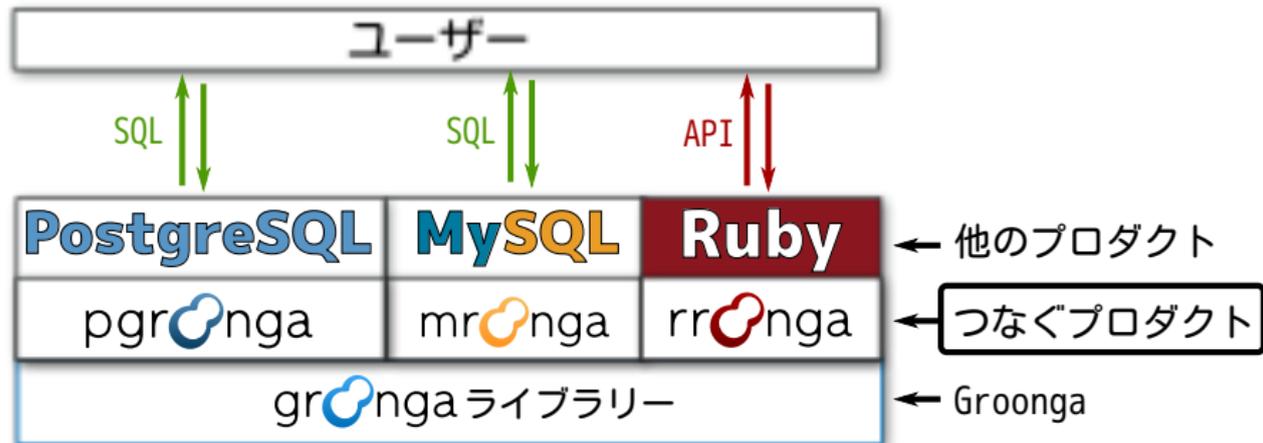


Groonga族

- Groongaそのもの
- Groongaと他のプロダクトをつなぐプロダクト
- 名前がXroonga



つなぐプロダクト



ポイント
Groongaはライブラリーとして他のプロダクトに埋め込める！



Groonga族 : Groonga

groonga

ぐるんが



Groongaのよいところ1

高速な
全文検索機能
(全文検索エンジンなので当然)



Groongaのよいところ2

即時更新



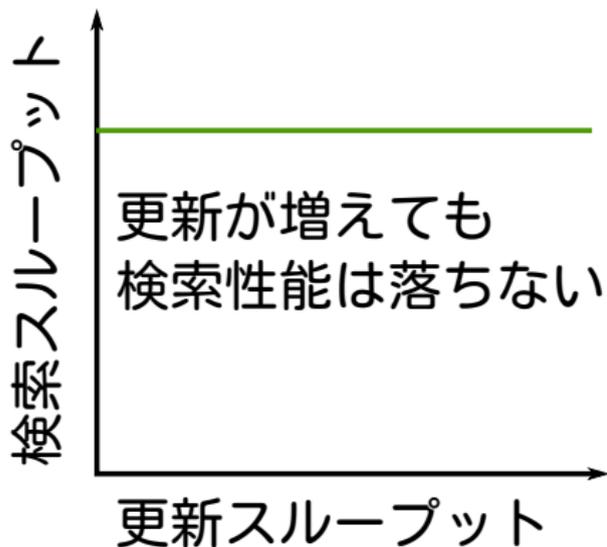
即時更新

- 更新→すく"に検索可能
 - 思想：新鮮なデータは高価値
 - 新しいデータはすく"に入れて！
- 工夫：更新中も検索性能キープ
 - 即時データ投入を妨げる理由を減少
 - 実装：参照ロックフリー

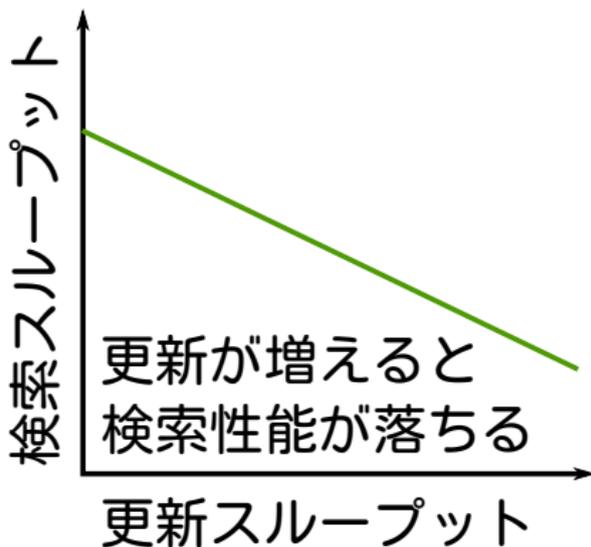


性能の傾向

Groonga



更新中は参照不可の
エンジン





Groongaのよいところ3

高速な集計処理



高速な集計処理

- 集計処理
 - 同一カラムの値を一気にアクセス
- 工夫：↑向けデータ構造を採用
 - 高速な集計処理を実現
 - 実装：カラムストア



カラムストア

Groonga			RDBMSなど				
カラム			カラム				
	a	b	c		a	b	c
1	値	値	値	1	値	値	値
2	値	値	値	2	値	値	値
3	値	値	値	3	値	値	値

カラム毎 値の管理 行毎

カラム 得意なアクセス単位 行



Groongaのよいところ3

手厚い
日本語サポート



サポート例：RKサーチ

ローマ字でカナを検索

Romaji to Kana prefix search

- 例：「ya」 → 「ヤキニク」
 - 「や」・「ヤ」 → 「ヤキニク」も可
- 用意するもの
 - カタカナでのヨミガナだけ
(ひらがな・ローマ字はいらない)
(ローマ字の訓令式・ヘボン式の差はGroongaが吸収)



RKサーチの利用例1

入力補助

■ 例：タグの入力

同じことに違うタグをつけると検索精度があがらない
全体で一貫性があることは重要
既存のタグを入力補助することで同じことに同じタグを
つけやすくする

- 使い所：妥当な値の集合がある
 - タグ入力なら既存タグ



RKサーチの利用例2

検索ボックスでの補完

- Googleもやっているやつ
- ぐるなびはGroongaで実現



ぐるなびでの利用例

レストラン検索 エリア 駅

宴会・グルメ情報検索サイト

 **ぐるなび**

00:00~ まだ営業してますよ

予約するなら圧倒的

お店検索

yu

- 有楽町
- 湯島
- 有楽町・日比谷
- 湯河原
- 有楽町イトシア

「yu」 → 「ユウラクチョウ」 → 「有楽町」

出典：Groongaのサジェストで四苦八苦 by Walker
<https://speakerdeck.com/redfigure/groongafalsesaziesutodesi-ku-ba-ku>



補完の使い方1

スキーマ作成

```
% groonga-suggest-create-dataset \  
  DB_PATH stations
```



補完の使い方2

データ準備

```
[  
  {  
    "_key": "有楽町",  
    "kana": ["ユウラクチョウ"],  
    "boost": 100  
  }  
]
```

boostを100以上にすること



補完の使い方3

データロード

```
% curl \  
  'localhost:10041/d/load?table=item_stations' \  
  --header 'Content-Type: application/json' \  
  --data-binary @stations.json
```

curlを使うときは--dataではなく--data-binaryを使うこと
--dataは改行を削除するため



補完の使い方4

補完

```
% curl \  
  'localhost:10041/d/suggest' \  
  --get \  
  --data-urlencode 'types=complete' \  
  --data-urlencode 'table=item_stations' \  
  --data-urlencode 'column=kana' \  
  --data-urlencode 'query=yu'  
  
[  
  [...],  
  {"complete": [[1],[...],["有楽町",101]]}  
]
```



Groongaのよいところ4

組み込める

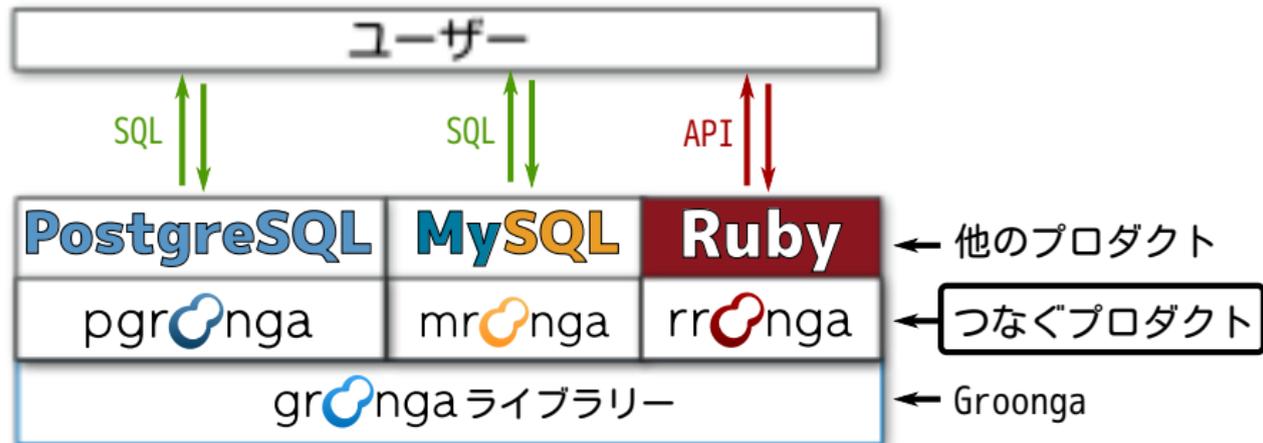


組み込める

- ライブラリーとして利用可能
 - =インターフェイスを変えられる
 - =使いやすい方法で使える



つなぐプロダクト



ポイント
Groongaはライブラリーとして他のプロダクトに埋め込める！



Groonga族 : Mroonga

mroonga

むるんが
MySQL + Groonga



Mroongaのよいところ1

簡単に使える



簡単

- SQLで使える
- 全文検索の知識なしで
使い始められる

Mrroongaを使う : スキーマ

```
CREATE TABLE texts (  
  content TEXT,  
  FULLTEXT INDEX (content)  
  -- ↑と↓を追加  
) ENGINE=Mrroonga  
  DEFAULT CHARSET=utf8mb4;
```

ポイント : 全文検索の索引を作ると言っているだけ



MrOongaを使う：検索

```
SELECT * FROM texts
WHERE
  MATCH(content)
  AGAINST('*D+ キーワード1 キーワード2'
          IN BOOLEAN MODE);
```

ポイント：Web検索エンジンと同様にクエリーを書ける

 なぜ知識なしで使えるの？

適切な
デフォルト値



デフォルト値

- トークナイザー：可変長Bigram
(トークナイザー≒検索キーワード抽出モジュール)
 - 日本語+英語でもいい感じに動く
- ノーマライザー：MySQL互換
(ノーマライザー≒テキスト正規化モジュール)
 - 一部非互換： ≠ 



Mroongaのよいところ2

MySQLの機能を使える



MySQLの機能

- レプリケーション
- ユーザー管理
- クライアントライブラリー
- ...



Mroongaのよいところ3

速い！



例：MySQL 5.7と比較

ポイント：MySQL 5.7のInnoDBは日本語全文検索対応！

クエリー	文字数	InnoDB mecab	InnoDB bigram	Mroonga bigram
COUNT	1	2.62s	N/A	0.74s
COUNT	2	0.07s	1.74s	0.27s
ORDER BY	1	2.78s	N/A	0.83s
ORDER BY	2	0.09s	2.72s	0.31s

出典：MySQLの全文検索に関するあれやこれや by yoku0825
<http://www.slideshare.net/yoku0825/mysql-47364986>

- InnoDB mecabは遅いことがある
- Mroongaは安定して速い

MySQL 5.7で日本語全文検索

```
CREATE TABLE texts (  
  content TEXT,  
  FULLTEXT INDEX (content)  
    WITH PARSER mecab -- ←がポイント  
) ENGINE=InnoDB  
  DEFAULT CHARSET=utf8mb4;
```

mecabの代わりにngramも指定できるが実用的ではなさそう
mecabを使う場合は↑の他にMeCabの設定が必要
<https://dev.mysql.com/doc/refman/5.7/en/fulltext-search-mecab.html>



Mroonga vs MySQL 5.7

- Mroonga
 - デフォルトでいい感じに動く
(選びたければ指定できる)
 - 安定して速い
- MySQL 5.7 InnoDB
 - パーサーを選ばないといけない
(mecab?ngram?違いは?)
 - 遅いこともある



Mrroongaが速い理由：1

Groonga直結



Groongaが速いと
Mrroongaも速い



Mrroongaが速い理由：2

ORDER BY LIMIT
を最適化



ORDER BY LIMIT最適化

```
SELECT * FROM texts
  WHERE MATCH(content1)
        AGAINST('...' IN BOOLEAN MODE)
  ORDER BY priority
  LIMIT 10;
```

MySQLに先頭10件しか返さない

ORDER BY LIMITをMySQLが処理するより
Groongaが処理する方が速いので速くなる

ORDER BY LIMIT最適化！

```
SELECT * FROM texts
  WHERE MATCH(content)
        AGAINST('...' IN BOOLEAN MODE)
  AND n_likes < 100 -- 追加
 ORDER BY priority
  LIMIT 10;
```

Groonga: MATCH AGAINST 以外も処理

MySQLが処理するよりGroongaが処理する方が速いので速くなる



Mroongaが速い理由：3

必要なカラム
のみ
アクセス

必要なカラムのみアクセス

```
SELECT c1, c3, c5 FROM t;
```

c2, c4にはアクセスしない
→I/Oが減って速い

Groongaはカラムストア

必要なカラムのみアクセスできる理由

	Groonga				RDBMSなど			
	カラム				カラム			
	a	b	c		a	b	c	
行	1	値	値	値	1	値	値	値
	2	値	値	値	2	値	値	値
	3	値	値	値	3	値	値	値
	カラム毎			値の管理	行毎			
	カラム			得意なアクセス単位	行			



Groonga族 : PGroonga

pgroonganga

ぴーじーるんが
PostgreSQL + Groonga

簡単に使える



簡単

- SQLで使える
- 全文検索の知識なしで
使い始められる



PGroongaを使う：索引

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

ポイント：全文検索の索引を作ると言っているだけ



PGroongaを使う：検索

```
SELECT * FROM texts
WHERE
  content @@ 'キーワード1 キーワード2';
```

ポイント：Web検索エンジンと同様にクエリーを書ける

 なぜ知識なしで使えるの？

適切な
デフォルト値



デフォルト値

- トークナイザー：可変長Bigram
(トークナイザー≒検索キーワード抽出モジュール)
 - 日本語+英語でもいい感じに動く
- ノーマライザー：NFKC
(ノーマライザー≒テキスト正規化モジュール)
 - Unicode正規化形式の1つ



PGroongaのよいところ2

PostgreSQLの 機能を使える



PostgreSQLの機能

- トランザクション
- ユーザー管理
- クライアントライブラリー
- ...



PGroongaのよいところ3

速い！



例：pg_bigmと比較

ポイント：PostgreSQL標準では日本語全文検索非対応

ヒット数	PGroonga	pg_bigm
368	0.030s	0.107s
17,172	0.121s	1.224s
22,885	0.179s	2.472s
625,792(*)	0.646s	0.556s

データ：Wikipedia日本語版

約184万レコード・平均サイズ約3.8KB

詳細：<http://www.clear-code.com/blog/2015/5/25.html>

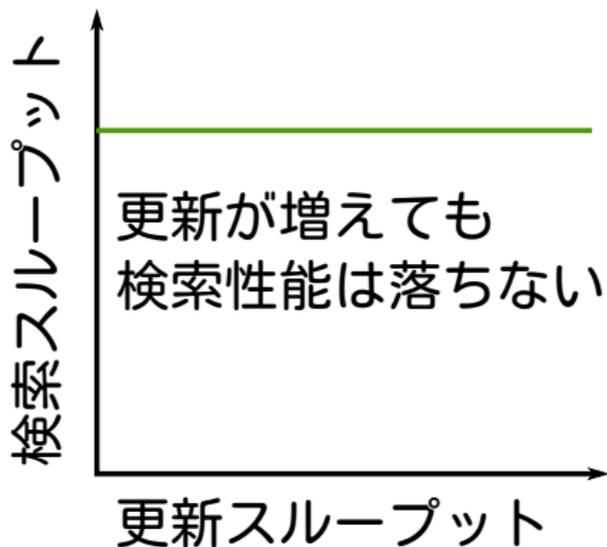
(*) 他は検索語が3文字以上でこれだけ2文字

PGroongaは安定して速い！

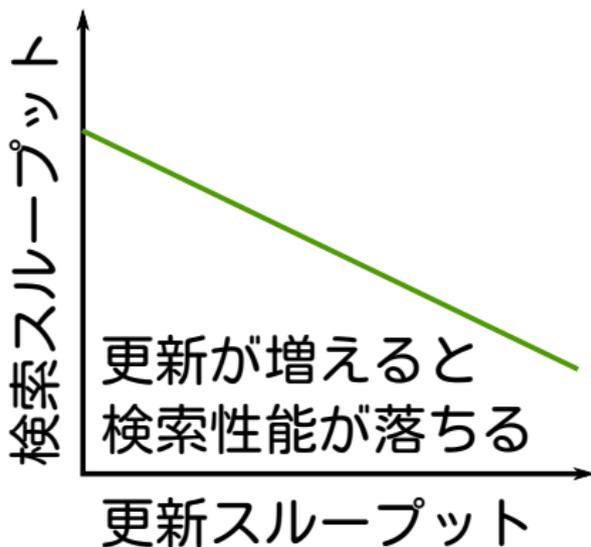


更新中も性能維持

Groonga



更新中は参照不可の
エンジン





GINと更新と参照

GINの場合

INSERT
開始

INSERT
完了

接続1

接続2

SELECT
開始

ブロック
性能劣化!

SELECT
完了

GINはpg_bigmが使っているPostgreSQL標準の転置索引実装



PGroongaと更新と参照

PGroongaの場合

INSERT
開始

INSERT
完了

接続1

接続2

SELECT
開始

SELECT
完了

性能劣化なし！

PGroongaはGroongaを使っているので参照ロックフリー



ロード時間も速い

元データの ロード時間	索引 作成時間 PGroonga	索引 作成時間 pg_bigm
16分31秒	25分37秒	5時間56分15秒

データ：Wikipedia日本語版

約184万レコード・平均サイズ約3.8KB

詳細：<http://www.clear-code.com/blog/2015/5/25.html>

pg_bigmより約14倍速い！



Groonga族 : Rroonga

rroonga

るるんが

Ruby + Groonga



Roongaのよいところ1

Rubyで書ける



RubyでDB作成

```
Groonga::Database.create(:path => "/tmp/db")
```



Rubyでテーブル定義

```
Groonga::Schema.define do |schema|
  schema.create_table("Users",
                     :type => :hash) do |table|
    table.short_text("name")
    table.int8("age")
  end
end
```



Rubyでデータロード

```
users = Groonga["Users"]
users.add("alice",
         :name => "Alice",
         :age => 29)
```



Rubyでデータロード

```
users = Groonga["Users"]
users.add("alice",
         :name => "Alice",
         :age => 29)
```



Rubyで検索

```
twentys = users.select do |record|
  (record.age >= 20) & (record.age < 30)
end
twentys.each do |twenty|
  p twenty.name # => "Alice"
end
```



Rroongaのよいところ2

サーバーいらず



サーバーいらず

- ローカルのDBを操作
 - SQLiteと同じ
- 向き不向き
 - 向き：1台で扱えるデータ量
 - 不向き：1台で扱えないデータ量



Rroongaの利用事例1

Milkode ソースコード 検索

<http://milkode.ongaeshi.me/>



M i k o d e

- 行指向のソースコード検索
grepの親戚
- 数万ファイルも余裕
 - grepだと遅いけど1台で扱える量
- 検索方法
 - Rroongaでファイル検索
 - →絞り込んだファイルをgrep
ポイント：絞り込んだ後ならgrepでも速い！



Rroongaの利用事例2

ROMA 分散KVS

<http://roma-kvs.org/>



ROMA

- Rakuten/Ruby
On-Memory
Architecture
- Rubyで実装された分散KVS
- ストレージにGroongaを利用
Tokyo Cabinetも使える



Roongaの利用事例3

Droonga



Groonga族 : Droonga

drnga

どるんが
Distributed **Groonga**
分散対応Groonga



Droongaのよいところ1

分散機能

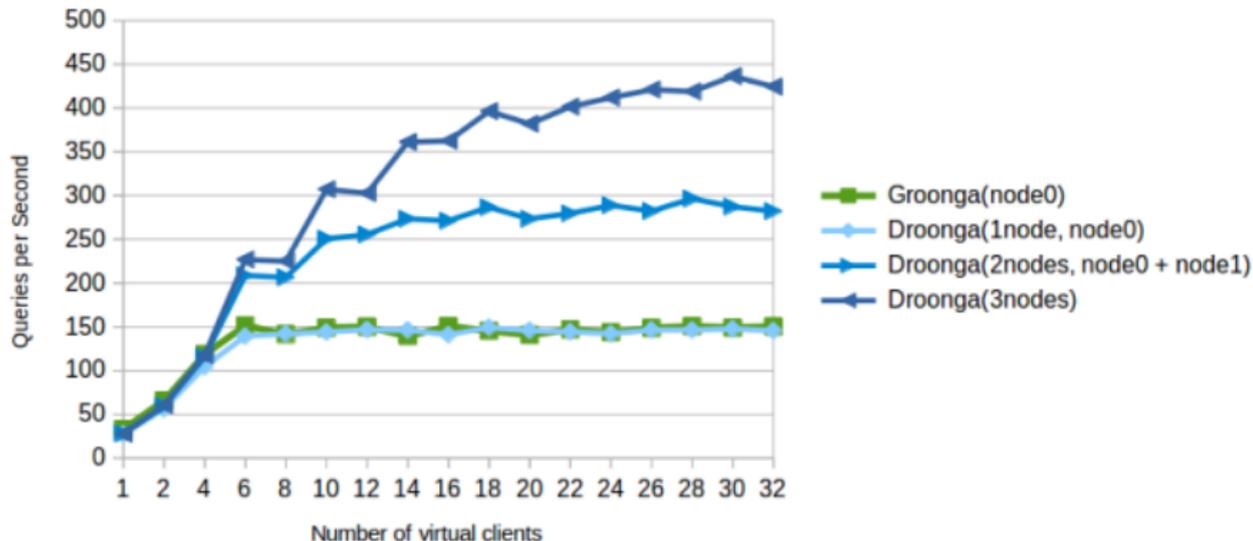


分散機能

- レプリケーション：実装済み
ダウンタイムなしでノード追加可能
 - データ複製
 - 参照性能・可用性向上
- シャーディング：実装予定
 - データ分割
 - 更新性能・最大データ量向上

レプリケーション時の性能

Throughput





Droongaのよいところ2

Groonga互換API



Groonga互換API

- Groongaと同じように使える
 - Groongaからの移行手順あり
<http://droonga.org/ja/tutorial/groonga/>
 - DroongaからGroongaも可
- クライアント無変更で動く



概要のまとめ

- Groonga : 高速・日本語得意
- Mroonga : 高速・簡単
- PGroonga : 高速・簡単
- Rroonga : 高速・手軽
- Droonga : 高速・スケーラブル

最新
情報



最新情報 : Groonga

groonga

ぐるんが



Groonga: 1

groonga-httpdを
正式機能に



groonga-httpd

- nginxにGroongaを組み込み
 - Groonga族
 - nginxのモジュールとして実装
- Groonga HTTPサーバー互換
- ↑より高機能 (HTTPサーバーとして)
 - 認証・TLS・HTTP/2



Groonga: 2

Windowsでの DBサイズ減少

(1/3以下になるケースもあり)



Groonga: 3

ドリルダウンの 高機能化

ドリルダウンの高機能化1

集計処理を追加

- 既存：
 - カウントのみ
- 追加：
 - 合計・最小値・最大値・平均



ドリルダウン+平均

グループでドリルダウンして
グループ毎の平均年齢も計算

```
% curl \  
  'localhost:10041/d/select' \  
  --get \  
  --data-urlencode 'table=users' \  
  --data-urlencode 'drilldown=group' \  
  --data-urlencode 'drilldown_calc_types=AVG' \  
  --data-urlencode 'drilldown_calc_target=age' \  
  --data-urlencode 'drilldown_output_columns=_key,_avg'
```



平均の出力例

```
[... [  
  [100], # 100グループ  
  [  
    ["_key", "ShortText"],  
    ["_avg", "Float"]  
  ],  
  [  
    ["グループ1", 29.0], # 平均29.0歳  
    ["グループ2", 22.9], # 平均22.9歳  
    ...  
  ]]  
]]
```

ドリルダウンの高機能化2

複数キーでのドリルダウン



クロス集計

例：市と年齢でのクロス集計

市\年齢	20歳	21歳
札幌市	999人	100人
仙台市	500人	200人

複数キーワードドリルダウン例

市と年齢でドリルダウン

```
% curl \  
  'localhost:10041/d/select' \  
  --get \  
  --data-urlencode 'table=users' \  
  --data-urlencode \  
    'drilldown[city_age].keys=city,age' \  
  --data-urlencode \  
    'drilldown[city_age].output_columns=  
      _value.city,_value.age,_nsubrecs'
```



出力例

```
[... [  
  [100], # 100パターン  
  [  
    ["city", "ShortText"],  
    ["age", "Int8"]  
    ["_nsubrecs", "Int32"]  
  ],  
  [  
    ["札幌市", 20, 999], # 札幌市の20歳は999人  
    ["札幌市", 21, 100], # 札幌市の21歳は100人  
    ["仙台市", 20, 500], # 仙台市の20歳は500人  
    ...  
  ]]  
]]
```



Groonga: 4

リクエスト
キャンセル
対応



リクエストキャンセル

```
% curl \  
  'localhost:10041/d/select' \  
  --get \  
  --data-urlencode 'table=users' \  
  --data-urlencode 'request_id=XXX' &  
% curl \  
  'localhost:10041/d/request_cancel' \  
  --get \  
  --data-urlencode 'id=XXX'
```

注：リクエストIDを重複無く付けることはクライアントの責任



Groonga: 5

dumpの ストリーム対応



dumpのストリーム対応

- Before
 - メモリー上で全部作ってから出力
 - 大きなDBではメモリー使用量が多い
- After
 - ダンプ内容を順次出力
 - 大きなDBでもメモリー消費が少ない



Groonga: 6

シャーディング
対応



シャーディング対応

- 同一DB内
 - 複数のホストにデータ分散ではない
- 目的
 - テーブルの最大レコード数制限突破
1テーブルあたり最大約2億レコード
- サポート
 - 月・日でのシャーディング



シャーディング：定義

```
% curl 'localhost:10041/d/table_create' \  
  --get \  
  --data-urlencode 'name=Logs_20151129' \  
  --data-urlencode 'flags=TABLE_NO_KEY' \  
% curl 'localhost:10041/d/column_create' \  
  --get \  
  --data-urlencode 'table=Logs_20151129' \  
  --data-urlencode 'name=timestamp' \  
  --data-urlencode 'flags=COLUMN_SCALAR' \  
  --data-urlencode 'type=Time'
```

シャーディング : ロード

```
[  
{"timestamp": "2015-11-29 00:00:29"},  
{"timestamp": "2015-11-29 00:00:30"},  
{"timestamp": "2015-11-29 00:00:31"}  
]
```



シャーディング：準備

```
% curl 'localhost:10041/d/plugin_register' \  
  --gets \  
  --data-urlencode 'name=sharding'
```



シャーディング：検索

```
logical_select \  
  --logical_table Logs \  
  --shard_key timestamp \  
  --min "2015-11-29 00:00:00" \  
  --min_border "include" \  
  --max "2015-11-30 00:00:00" \  
  --max_border "exclude" \  
  --filter "..."
```



Groonga: 7

正規表現対応



正規表現

- 構文はRubyと同じ
 - エンジンがRubyと同じだから
- 一部のパターンは索引を使える
 - 前方一致：`\A#{リテラル}`
 - 中間一致：`#{リテラル}`
 - 後方一致：`#{リテラル}\z`



正規表現：使い方

```
select \  
  --filter 'content @~ "\\AHello"'
```

- 演算子は@~
- エスケープが煩雑なので注意



Groonga: 8

カスタム スコア関数対応



スコア関数

- 文書がどのくらいクエリーに適合しているかの度合いを返す関数
- これまではTFのみ
 - TF=単語の出現数
 - =単語の出現数がスコア



新スコア関数

- `score_tf_idf`
 - TF-IDFベースのスコア関数
 - 単語の出現数を単語の重要度で補正
- `score_tf_at_most`
 - 上限値付きTFベースのスコア関数
 - スパマー対策ならこれで十分



スコア関数：使い方

```
select Logs \  
  --match_columns \  
    "scorer_tf_at_most(body, 3.0)" \  
  --query "keyword1 keyword2"
```

match_columnsで指定



Groonga: 9

ログ
ローテーション
対応



ログローテーション

- 使い方
 - groongaコマンドの起動オプション
- オプション
 - `--log-rotate-threshold-size`
 - `--query-log-rotate-threshold-size`



Groonga: 10

キャッシュの
最大キーサイズ
増加

キャッシュのキーサイズ

- Before
 - 4KiB
- After
 - 64KiB - 1



Groonga: 11

io_flush追加



io_flush

- メモリー上のデータをディスクに書き込むコマンド
 - 通常はOSに任せている
- 目的：クラッシュ対策
 - UNIX: プロセスが死んでもカーネルが生きていればいずれ書き込まれる
 - Windows: プロセスが死ぬと書き込まれない



Groonga: 12

使った索引を
ログ出力



使った索引をログ出力

- チューニングに便利
 - SQLのEXPLAINの不便バージョン
サーバーのログを確認しないといけないから
- ログレベルに注意
 - デフォルトでは出力されない
 - debugにすること



Groonga: 13

Windows イベントログ 対応



Windows イベント ログ

使い方

```
% groonga --use-windows-event-log
```



Groonga: 14

スレッド数の 動的変更対応



スレッド数変更

最大8スレッドに変更する例

```
% curl \  
  'localhost:10041/d/thread_limit' \  
  --get \  
  --data-urlencode 'max=8'
```



Groonga: 15

column_copy追加



column_copy

- カラムの値をコピー
 - サーバーサイドで実行
- 利用例
 - テーブル・カラム定義変更
 - 新カラム作成→コピー→
 - 旧カラム削除→リネーム



Groonga: 16

Pretty print
対応



従来

```
% curl 'localhost:10041/d/status'  
[[0,...],{"alloc_count":248,...}]
```



Pretty print

```
% curl \  
  'localhost:10041/d/status' \  
  --get \  
  --data-urlencode 'output_pretty=yes'  
[  
  [  
    0,  
    ...  
  ],  
  {  
    "alloc_count": 248,  
    ...  
  }  
]
```



Groonga: 17

新コマンド



新コマンド

- `reindex`
 - 既存インデックスを再作成
- `schema`
 - スキーマを返す
- `thread_limit`
 - 最大スレッド数を動的に変更



Groonga: 18

新関数



新関数

- `prefix_rk_search()`
 - ローマ字で検索
 - `select`で補完できる



Groonga: 19

Groonga Admin 進化



Groonga Admin

- Groongaの新しい管理画面
 - 旧：Webからコマンドを実行できる
 - 新：詳細を知らずに使える
- 試せる
 - <http://packages.groonga.org:10041/>



最新情報：Mroonga

mroonga

むるんが
MySQL + Groonga



Mroonga: 1

mroonga_boolean_mode_syntax_flags

- IN BOOLEAN MODEでの構文を変更
 - スクリプト構文→使える演算子が増加



スクリプト構文

```
SET mroonga_boolean_mode_syntax_flags =  
  "SYNTAX_SCRIPT";
```

```
SELECT * FROM memos  
  WHERE MATCH(title)  
        AGAINST('title @~ ".+roonga"  
                IN BOOLEAN MODE);
```

正規表現を使う例
他にも関数を使えたり比較演算子を使えたりする
MATCHに指定していないカラムでも検索できる



Mrroonga: 2

Mar i aDB
カ スタム
パ ラメータ—
対 応

インデックスパラメーター

```
CREATE TABLE memos (  
  body text,  
  FULLTEXT INDEX body_index (body)  
    TOKENIZER='TokenMecab'  
    NORMALIZER='NormalizerAuto'  
    TOKEN_FILTERS='TokenFilterStopWord'  
    -- ↑COMMENTに書かなくてよい!  
) ENGINE=Mroonga DEFAULT CHARSET=utf8mb4;
```



カラムパラメーター

```
CREATE TABLE tags (  
  name VARCHAR(64) PRIMARY KEY  
) ENGINE=Mroonga DEFAULT CHARSET=utf8mb4;
```

```
CREATE TABLE bugs (  
  tag VARCHAR(64) GROONGA_TYPE='tags'  
) ENGINE=Mroonga DEFAULT CHARSET=utf8mb4;
```



Mroonga: 3

MySQL 5.7対応



MySQL 5.7対応

- MySQL 5.7でビルドできる
- JSON型対応



JSON型

```
CREATE TABLE logs (  
  record JSON  
) ENGINE=Mroonga  
  DEFAULT CHARSET=utf8mb4;  
INSERT INTO logs  
  VALUES ('{"message": "start"}');
```



Mroonga: 4

MariaDB 10.1
対応



最新情報 : Droonga

droonga

どるんが
Distributed Groonga
分散対応Groonga



Droonga: 1

ダウンタイム
なしの
ノード追加対応



今年のまとめ

- Groonga : たくさん改良
- Mroonga
 - 使い勝手改良・最新対応
- PGroonga: 今年デビュー
- Rroonga : 最新対応
- Droonga : 可用性向上

今後



ヒント

- 実現は保証しない
 - 実現しようとはするよ！
- 実現可能性を高めるには…
 - 開発に参加
コード・ドキュメントを書く・テストする・宣伝する
 - 開発者が開発する時間を増やす
他のユーザーをサポート・情報公開・仕事を頼む



今後：Groonga

groonga

ぐるんが



Groonga: 1

カラムストアをもっと活かす

- シーケンシャルサーチを速く！
- ソートを速く！
- ドリルダウンを速く！

↓
grn_ts (ぐるんたす)



Groonga: 2

mrubyをデフォルト有効

- プラグインをRubyで書ける
- 式を書き換えられる
- オプティマイザーを書ける



Groonga: 3

プラグインエコシステム

- プラグイン管理コマンド提供
 - 例: `grn plugin install XXX`
- プラグインリポジトリ提供
GoのようにGitから直接インストールでもいいかも
- 対応プラグイン
 - Rubyで書かれたプラグイン



Groonga: 4

位置指定マッチ対応

- N番目のトークンならマッチ
 - 例：1番目のトークンはhello？
 - マッチする：hello world
 - マッチしない：hey! hello world



位置指定マッチ応用例1

正規表現の前方一致検索

- Groongaでの構文：`\A`
 - 例：`\Ahello`
- 実装：
 - 1番目のトークンかチェック



位置指定マッチ応用例2

ベクターのN番目の要素にマッチ

```
{  
  "rank": ["Alice", "Bob", "Chris"]  
}  
# rank[0] @ "Bob" → マッチしない  
# rank[1] @ "Bob" → マッチする
```



Groonga: 5

selectで計算結果での
ドリルダウン・ソートに対応

■ 例

- 元データ：日時 (2015-11-29 13:30)
- 計算結果：年月日 (2015-11-29)
- ドリルダウン：計算結果を使用
(2015-11-29: 1件、2015-11-30: 2件)



select例

```
select Logs \  
  --column[access_day].type Time \  
  --column[access_day].source \  
    'time_floor_year(access_time)' \  
  --drilldown access_day
```



Groonga: 6

JSONでのパラメーター指定 (も使えるようにする)

- メリット
 - プログラムから指定しやすい
ことがあるかもしれない
- デメリット
 - クエリーログに残らない



クエリーストリング

現行

```
% curl \  
  'localhost:10041/d/select' \  
  --get \  
  --data-urlencode 'table=users' \  
  --data-urlencode 'limit=100'
```



JSON

```
% cat select.json
{
  "table": "users",
  "limit": "100"
}
% curl \
  'localhost:10041/d/select' \
  --header 'Content-Type: application/json' \
  --data-binary @select.json
```



Groonga: 7

ドキュメント改善

- 未ドキュメントな項目を書く
- 古いドキュメントを更新



今後：Mroonga

mr**o**onga

むるんが
MySQL + Groonga



Mroonga: 1

ラッパーモードで ロールバック対応

- **現状：ロールバック非対応**
(変更が残ってしまい検索結果に不整合発生)
 - **今後：コミット時にまとめて更新**
(ロールバックしても変更が残らない)
- **現状：トランザクション中に更新データを検索可能**
 - **今後：検索不可能**



Mroonga: 2

MariaDBで テーブルパラメーター対応

```
CREATE TABLE xxx (  
  ) ENGINE=Mroonga  
  COMMENT='ENGINE "InnoDB" '  
  -- ↑を↓と書ける  
  WRAP ENGINE=InnoDB;
```



Mroonga: 3

generated column対応

MySQL 5.7で導入。MariaDBでいうvirtual column。

```
CREATE TABLE users (  
  first_name text,  
  last_name text,  
  full_name text AS  
    (CONCAT_WS(' ', first_name, last_name))  
  STORED  
) ENGINE=Mroonga;
```



Mroonga: 4

ネイティブパーティション対応

MySQL 5.7で導入。FULLTEXT INDEXを使えるようになる！

```
CREATE TABLE memos (  
  created_time DATETIME,  
  content text,  
  FULLTEXT INDEX (content)  
) ENGINE=Mroonga  
  PARTITION BY RANGE (TO_DAYS(timestamp)) (  
  -- ...  
)
```



Mroonga: 5

JSONの全文検索対応

```
CREATE TABLE logs (  
  message JSON,  
  FULLTEXT INDEX (message)  
) ENGINE=Mroonga;  
SELECT * FROM logs  
  WHERE MATCH(message)  
         AGAINST('*D+ error' IN BOOLEAN MODE);
```



Mrroonga: 6

同義語展開対応

```
SELECT * FROM memos
  WHERE MATCH(content)
         AGAINST(mroonga_expand_query('*D+ 焼き肉')
                 IN BOOLEAN MODE);
-- → AGAINST('*D+ 焼き肉 OR 焼肉' IN BOOLEAN MDOE)
-- 同義語はMrroongaのテーブルにして
-- SQLで管理できるようにする
```



Mrroonga: 7

ドキュメント改善

- Sphinx→GitHub Pages
 - Sphinx・reSTはオーバースペック
 - Markdownで十分
 - typoを見つけても正しく直せない



今後：PGroonga

pgroonga

ピージーるんが
PostgreSQL + Groonga



PGroonga: 1

text @@ pgroonga.queryを導入

```
SET enable_indexscan = off;  
SET enable_bitmapscan = off;  
SELECT * FROM WHERE content @@ '全文検索';  
-- ↑ PostgreSQL組み込みの@@が使われる  
SELECT * FROM  
  WHERE content @@ '全文検索'::pgroonga.query;  
-- ↑ PGroonga提供の@@が使われる
```



PGroonga: 2

もっとGroongaを活かす

PGroonga	pg_bigm	Groonga
0.646s	0.556s	0.085s

ヒット数635,792、検索語は2文字

生Groongaは1桁速い！

詳細：<https://github.com/groonga/wikipedia-search/issues/3>



PGroonga: 3

同義語展開対応

```
body @@ pgroonga.expand_query('ネジ')  
-- ↓  
body @@ 'ネジ OR ねじ OR ボルト'
```



PGroonga: 4

ステミング対応

found/finds→find

```
CREATE INDEX index ON entries
  USING pgroonga (title)
  WITH (token_filters = 'TokenStem');
```



PGroonga: 5

重み対応

```
-- タイトルのほうが本文より10倍重要  
body @@ ('title * 10 || body', 'ポストグレ')
```



PGroonga: 6

複合主キ一対応

```
CREATE TABLE t (  
  c1 INT,  
  c2 INT,  
  PRIMARY KEY (c1, c2)  
);  
CREATE INDEX index ON t  
  USING pgroonga (c1, c2);
```



PGroonga: 7

pg_dumpのWITH問題を解消

```
CREATE INDEX index ON t
  USING pgroonga (c)
  WITH (tokenizer = 'TokenMecab');
-- ↓pg_dump: クォートがとれる→小文字に正規化される
CREATE INDEX index ON t
  USING pgroonga (c)
  WITH (tokenizer = TokenMecab);
```



今後：Rroonga

rroonga

るるんが

Ruby + Groonga



Rroonga: 1

ドキュメント改善

- Textile→Markdown
- 英語化
- 説明追加（主にコード例）



今後：Droonga

drnga

どるんが
Distributed **Groonga**
分散対応Groonga



Droonga: 1

シャーディング
対応



Groonga族以外

- キラーアプリが欲しい
- 世界規模で認知されたい
 - Mroonga・PGroongaをきっかけに
MroongaはMariaDBにバンドルされている
- 本を出したい
 - 初心者向けのやつ



まとめ

- Groonga族は今年も進化した
- Groonga族は来年も進化する
- 来年はもっと世界規模でユーザーを増やしたい



おしらせ1

■ Groongaで学ぶ全文検索

↑で検索！

- 隔週金曜の夜開催
- 予習復習なしで時間内で効率よく全文検索を学ぶ会
- 参加者のレベルは問わない
- 内容は毎回参加者に合わせて決める

全文検索を学びたい方はどうぞ！



おしらせ2

MySQLとPostgreSQLと
日本語全文検索

来年2月9日（肉の日）
DMM.comラボにて