



# 全文検索の 基本的なしくみ

@myokoym

全文検索エンジンGroonga勉強会@札幌

2015-06-14



# 全文検索の流れ

- 文書を登録
- キーワードで検索



# 登録の流れ

- ノーマライズ
- トークナイズ
- トークンをキーとして文書IDをインデックスに登録



# 検索の流れ

- ノーマライズ
- トークナイズ
- トークンでインデックスを検索
- 文書IDを取得



# 用語

- ノーマライズ
- トークナイズ
- トークン



# ノーマライズ

- 正規化
  - 大文字小文字、全角半角などを揃える
  - ノーマライザーによって挙動が変わる



# トークナイズ

- 文書やキーワードをトークンに分割する
- トークナイザーによって分け方が異なる
  - 大きく分けるとN-gramと形態素解析の2種類



# N-gram

- 文字数で分割する
  - bi-gram(は2文字ごと)
  - tri-gram(は3文字ごと)



# 形態素解析

- 品詞を判別して分割する
- 別途辞書が必要



# トークン

- インデックスのキー
- Groongaで採用している転置インデックス方式では、トークンごとに文書リストが作成される



# トークナイズの例

東京都府中市

# bi-gram



東京/京都/都府/府中/中市/市

# tri-gram



東京都/京都府/都府中/府中市/中  
市/市



# 形態素解析

東京/都/府中/市



# 全文検索の流れ

- 文書を登録
- キーワードで検索



# 全文検索の流れ

- 文書を登録
- キーワードで検索



# 登録の流れ

- ノーマライズ
- トークナイズ
- トークンをキーとして文書IDをインデックスに登録



# サンプル文書

文書ID	内容
1	カレー食べた
2	カレー-食べたい
3	カレー好き



# ノーマライズ

- 1. カレー食べた
- 2. カレー食べたい
- 3. カレー好き



# トークナイズ

- MeCabの例
  - 1. カレー/食べ/た
  - 2. カレー/食べ/たい
  - 3. カレー/好き



# インデックスに登録

キー	文書IDリスト
カレー	[1 2 3]
食べ	[1 2]
た	[1]
たい	[2]
好き	[3]



# 全文検索の流れ

- 文書を登録
- キーワードで検索



# 検索の流れ

- ノーマライズ
- トークナイズ
- トークンでインデックスを検索
- 文書IDを取得

# サンプルキーワード



- 食べた



# ノーマライズ

- 食べた
  - ノーマライズ対象なし



# トークナイズ

- 食べ/た



# インデックス（再掲）

キー	文書IDリスト
カレー	[1 2 3]
食べ	[1 2]
た	[1]
たい	[2]
好き	[3]

# トークンでインデックスを検索



- 食べ -> [1 2]
- た -> [1]



# 文書IDを取得

- [1]
  - 両方含まれるもの
  - 設定によって出現位置も調べる
    - 隣り合っているかどうかなど



# ヒット1件

カレー食べた



# ポイント

- 登録と検索で同じ正規ライザーとトークナイザーを使う必要がある
  - それはなぜか？



# 参考

- Groongaの可変型Ngramトークナイザーについて - Naoya Murakami - Rabbit Slide Show
  - <http://slide.rabbit-shocker.org/authors/naoa/groonga-tokenizer-talks-naoa/>