


アナライズ処理の仕組み と

2014/04/21
@johtani

自己紹介

- 氏名：大谷 純
- 株式会社シーマーク
- Twitter：@johtani
- lucene-gosenのコミッター
- elasticsearch-extended-analyze作者
- ブログ：<http://blog.johtani.info>



書籍紹介

- ElasticSearch Server日本語版
 - 対応バージョン：0.90.x
 - 初の日本語書籍
 - 付録にKibana、Kuromojiを追加
- 電子版あり
 - Kindle、達人出版会、角川BOOKWALKER
- ご購入は私のブログから！



Doorkeeper

- Doorkeeper (今後のイベント開催にも利用)
 - <http://elasticsearch.doorkeeper.jp>
- 日本語用メーリングリスト (Google Groups)
 - <https://groups.google.com/forum/#!forum/elasticsearch-jp>

アジェンダ

- 転置インデックスとは
- アナライズ処理
 - Analyzer = CharFilter、Tokenizer、TokenFilter
- クエリDSL
 - クエリの種類
 - 注意するクエリ
- elasticsearch-extended-analyzeの紹介

転置インデックスとは？

転置インデックスとは？

1 カツオはサザエの弟

2 サザエはワカメの姉

転置インデックスとは？

1	カツオはサザエの弟
2	サザエはワカメの姉

1	カツオ	は	サザエ	の	弟
2	サザエ	は	ワカメ	の	姉

転置インデックスとは？

1	カツオはサザエの弟
2	サザエはワカメの姉

1	カツオ	は	サザエ	の	弟
2	サザエ	は	ワカメ	の	姉

Term	Id
カツオ	1
サザエ	1、2
ワカメ	2
の	1、2
は	1、2
弟	1
姉	1

アナライズ処理

アナライズ処理とは？

- 転置インデックスの単語 (Term) をドキュメントから抽出する処理
- フィールド毎に指定されたアナライザが処理
- アナライザはCharFilter、Tokenizer、TokenFilterから構成
- インデックス時、検索時に実行

アナライズ処理の概要


ドキュメント

アナライズ処理


インデックス

Term	Id
カツオ	1
サザエ	1、2
ワカメ	2
...	...

アナライズ処理の概要



アナライズ処理の構成



アナライザの設定

```
{
  "index":{
    "analysis":{
      "analyzer" : {
        "my_analyzer" : {
          "type" : "custom",
          "tokenizer" : "kuromoji_tokenizer",
          "char_filter" : ["char_filter1", "char_filter2"...],
          "filter" : ["token_filter1", "token_filter2"...]
        }
      }
    }
  }
}
```

Char Filter

- 入力文字列を文字単位で処理
- <http://www.elasticsearch.org/guide/en/elasticsearch/reference/current/analysis-charfilters.html>
- 例 : `html_strip`
 - 入力 : `<title>Elasticsearch is not a service of AWS</title>`
 - 出力 : `Elasticsearch is not a service of AWS`

Tokenizer

- 入力文字列をトークン列に分割
- トークンへの分割するロジックはトークナイザに依存
- <http://www.elasticsearch.org/guide/en/elasticsearch/reference/current/analysis-tokenizers.html>
- 例：standard

- 入力： `Elasticsearch is not a service of AWS`

- 出力：

Elasticsearch	is	not	a	service	of	AWS
---------------	----	-----	---	---------	----	-----

Tokenizer

- 例 : keyword

- 出力 : Elasticsearch is not a service of AWS

- 例 : kuromoji_tokenizer

- 入力 : 寿司が美味しかった

- 出力 : 寿司 が 美味し かつ た

TokenFilter

- Tokenizerにより出力されたToken列に対して処理
- <http://www.elasticsearch.org/guide/en/elasticsearch/reference/current/analysis-tokenfilters.html>

- 例：lowercase

- 入力：

Elasticsearch	is	not	a	service	of	AWS
---------------	----	-----	---	---------	----	-----

- 出力：

elasticsearch	is	not	a	service	of	aws
---------------	----	-----	---	---------	----	-----

- 例：stop

- 入力：

Elasticsearch	is	not	a	service	of	AWS
---------------	----	-----	---	---------	----	-----

- 出力：

Elasticsearch				service		AWS
---------------	--	--	--	---------	--	-----

TokenFilter

- <https://github.com/elasticsearch/elasticsearch-analysis-kuromoji>

- 例 : kuromoji_baseform

- 入力 :

寿司	が	美味しかっ	た
----	---	-------	---

- 出力 :

寿司	が	美味しい	た
----	---	------	---

- 例 : kuromoji_readingform

- 入力 :

寿司	が	美味しかっ	た
----	---	-------	---

- 出力 :

sushi	ga	oishika	ta
-------	----	---------	----

組み合わせると？

- html_strip+standard+lowercase+stop :

- 入力 : `<title>Elasticsearch is not a service of AWS</title>`

- html_strip : `Elasticsearch is not a service of AWS`

- standard :

Elasticsearch	is	not	a	service	of	AWS
---------------	----	-----	---	---------	----	-----

- lowercase :

elasticsearch	is	not	a	service	of	aws
---------------	----	-----	---	---------	----	-----

- stop :

elasticsearch				service		aws
---------------	--	--	--	---------	--	-----

- 最後の単語が転置インデックスのキーとなる

その他の情報も付与

- 単語の他に以下のような情報もTokenに付与
 - position : Tokenが出力される順序
 - start/end offset : テキスト中の文字の位置
- Tokenizer/TokenFilterによる個別情報
 - 例 : kuromoji_tokenizer
 - 品詞
 - 読み・発音

クエリ
(今日は主にクエリ)

クエリ

```
{  
  "query": {  
    "simple_query_string" : {  
      "query" : "スパイダーマン",  
      "fields" : ["title"]  } },  
  "fields": ["title", "category"]  
}
```

クエリとフィルタ

```
{  
  "query": {  
    "simple_query_string": {  
      "query": "スパイダーマン",  
      "fields": ["title"] } },  
  "fields": ["title", "category"],  
  "post_filter": {  
    "term": {  
      "text": "レオパルドン" } }  
}
```

クエリの数

match query
multi match query
bool query
boosting query
common terms query
constant score query
dis max query
filtered query
fuzzy like this query
fuzzy like this field query
function score query
fuzzy query
geoshape query
has child query
has parent query
ids query
indices query
match all query
more like this query
more like this field query
nested query
prefix query
query string query
simple query string query
range query
regexp query
span first query
span multi term query
span near query
span not query
span or query
span term query
term query
terms query
top children query
wildcard query
template query

種類 (檢索)

match query
multi match query
bool query
boosting query
common terms query
constant score query
dis max query
filtered query
fuzzy like this query
fuzzy like this field query
function score query
fuzzy query

geoshape query
has child query
has parent query
ids query
indices query
match all query
more like this query
more like this field query
nested query
prefix query
query string query
simple query string query

range query
regexp query
span first query
span multi term query
span near query
span not query
span or query
span term query
term query
terms query
top children query
wildcard query
template query

種類 (組み合わせ)


match query
multi match query
bool query
boosting query
common terms query
constant score query
dis max query
filtered query
fuzzy like this query
fuzzy like this field query
function score query
fuzzy query

geoshape query
has child query
has parent query
ids query
indices query
match all query
more like this query
more like this field query
nested query
prefix query
query string query
simple query string query

range query
regexp query
span first query
span multi term query
span near query
span not query
span or query
span term query
term query
terms query
top children query
wildcard query
template query

クエリとアナライズ処理の関係

クエリとアナライズ処理の関係



ドキュメントとクエリ

- ドキュメント：

- 入力：

<title>Elasticsearch is not a service of AWS</title>

- アナライズ後：

elasticsearch				service		aws
---------------	--	--	--	---------	--	-----

- クエリ：

- 入力：

AWS

- アナライズ後：

aws

ドキュメントとクエリ

- ドキュメント：

- 入力：

<title>Elasticsearch is not a service of AWS</title>

- アナライズ後：

elasticsearch				service		aws
---------------	--	--	--	---------	--	------------

- クエリ：

- 入力：

AWS

- アナライズ後：

aws

アナライズしないクエリも

インデックス


Term	Id
カツオ	1
サザエ	1、2
ワカメ	2
...	...



検索
キーワード

検索結果

インデックス
検索処理



ドキュメントとクエリ

- ドキュメント：

- 入力：

```
<title>Elasticsearch is not a service of AWS</title>
```

- アナライズ後：

elasticsearch				service		aws
---------------	--	--	--	---------	--	-----

- クエリ：

- 入力：

```
AWS
```

- アナライズされないなので、「AWS」と「aws」は違う=ヒットしない

検索クエリの分類 (アナライズなし)

match query	geoshape query	range query
multi match query	has child query	regexp query
bool query	has parent query	span first query
boosting query	ids query	span multi term query
common terms query	indices query	span near query
constant score query	match all query	span not query
dis max query	more like this query	span or query
filtered query	more like this field query	span term query
fuzzy like this query	nested query	term query
fuzzy like this field query	prefix query	terms query
function score query	query string query	top children query
fuzzy query	simple query string query	wildcard query
		template query

その他クエリの注意点

query_string

- wildcardを使うと、クエリが小文字に変換される。(デフォルト動作)
- wildcardを使うと、アナライズ処理されない (デフォルト動作)

elasticsearch-extended-analyze

extended_analyze

- SolrのAnalysis画面のような情報をJSONで返却
- 画面がない
- アナライズ処理のデバッグのお供に
- インストール方法
 - `bin/plugin -i info.johtani/elasticsearch-extended-analyze/1.1.0`
- 実行方法
 - `curl -XGET "http://localhost:9200/_extended_analyze?tokenizer=kuromoji_tokenizer&filters=kuromoji_baseform&attributes=KeywordAttribute" -d '寿司が美味しかった'`

demo



ご静聴、
ありがとうございました。

