

8 - Introducing Search

Monday, 24 March, 2025 21:24 Tarde

OVERVIEW

- Há busca estruturada e não-estruturada
 - Estruturada -- match exato, sem score de relevância
 - Não-estruturada -- por relevância, aproximação.
- Precision: densidade de documentos relevantes
- Recall: quanto de todos que eu gostaria de retornar foram retornados.

COMO FUNCIONA?




Figure 8.1 A typical search request, and the mechanics of how a search works

MOVIE SAMPLE DATA

- Exemplo de index de filmes

SEARCH FUNDAMENTALS

- `_search` endpoint
 - GET com parametros
 - POST com payload
 - Query DSL (Domain Specific Language)
 - Melhor pra buscas mais complexas
- Toda query ocorre em um de dois contextos:
 - *Query context*:
 - Gera score de relevância
 - *Filter context*:
 - Sem score, só retorna ou não documentos.
 - Poupa recursos da máquina, não requer passar por scoring, usa caching

ANATOMIA DE UMA REQUISIÇÃO E UMA RESPOSTA




Figure 8.2 Components of a search request

- GET e POST são equivalentes na prática, mas se costuma usar POST quando há body.
- Se não fornecermos um index na busca, pressupõe-se que são todos.

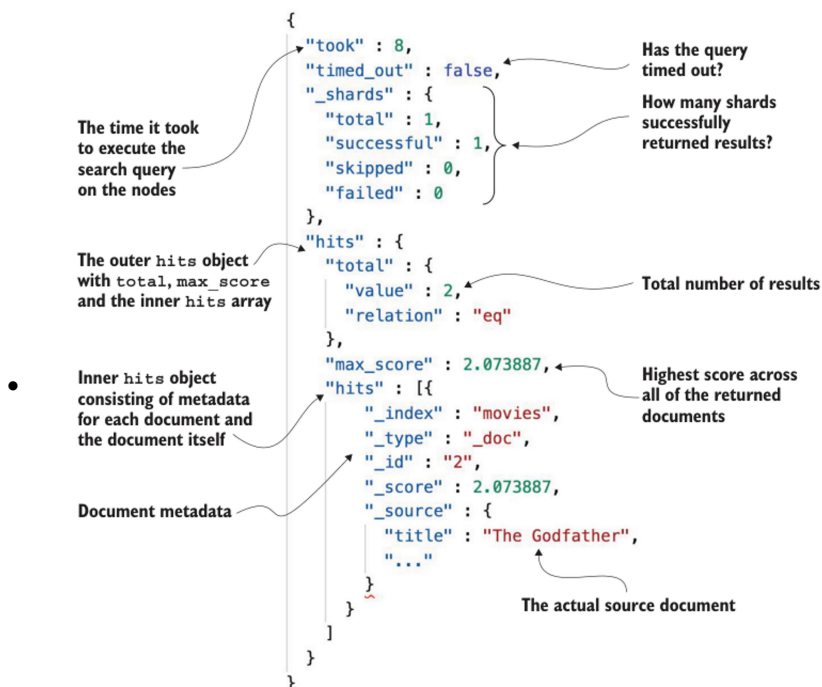


Figure 8.3 Constituents of a search response

URI REQUEST SEARCHES

- Busca por URI:
 - Busca com params, menos comum e menos flexível.
 - `GET movies/_search?q=title:Godfather Knight`
 - Passando o parâmetro `explain=true` o score é explicado.
 - Permite AND operator (e outros booleanos)
 - Busca por múltiplos campos ao mesmo tempo.
 - Podemos editar o `default_operator` para ser AND e não OR, para os vários critérios.
 - Busca por desigualdades (`>=` `<` etc)
- Podemos passar "query_string" na query por body que funciona igual ao `?q=` pelo URI (não recomendado)

QUERY DSL

- Baseado em JSON
- Bastante flexível

- Define um "query" object:
 - Dentro dele é aplicado a lógica da busca.

Listing 8.12 Query DSL sample query

```
GET movies/_search
{
  "query": {
    "multi_match": {
      "query": "Lord",
      "fields": ["synopsis", "title"]
    }
  }
}
```

- Dá pra usar com CURL normalmente sendo o body de um POST/GET
- Para buscas de agregados (analytics), usamos o objeto "aggs" no lugar do "query":

Listing 8.14 Aggregation query written in Query DSL format

```
GET movies/_search
{
  "size": 0,
  "aggs": {
    "average_movie_rating": {
      "avg": {
        "field": "rating"
      }
    }
  }
}
```

- Leaf Query:
 - Busca simples que busca um dado objetivo.
 - Um predicado só
- Query Composta:
 - Complexo, vários critérios ao mesmo tempo
 - Combina várias leaf queries

SEARCH FEATURES

- Podemos manipular a forma de retornar os resultados
- Paginação:
 - 10 resultados por default
 - Parâmetro size
 - Número de resultados retornados
 - Importante calibrar para não sobrecarregar client ou servidor
 - Máximo é 10_000 por default
 - Pode ser alterado nos settings do index
 - Aumentar é pouco recomendável
 - Parâmetro from
 - Só retorna a partir da n-ésima página, ignora as anteriores
 - Se houver muitos resultados, é melhor usar o parâmetro *search_after* e não *from* ou *size* por questões de desempenho.
- Highlighting:
 - Destaca fields especificados
 - Por default, envolve em tags :
 - Pode ser editado

Listing 8.19 Highlighting results when matched

```
GET movies/_search
{
  "_source": false,
  "query": {
    "term": {
      "title": {
        "value": "godfather"
      }
    }
  }
}
```

← Suppresses the source to be returned

| Includes a highlight object along

Listing 8.19 Highlighting results when matched

```
GET movies/_search
{
  "_source": false,
  "query": {
    "term": {
      "title": {
        "value": "godfather"
      }
    }
  },
  "highlight": {
    "fields": {
      "title": {}
    }
  }
}
```

Suppresses the source to be returned

Includes a highlight object along with the fields to be highlighted

The field we want to highlight

- Explaining:
 - Flag `explain=true`
 - Declarado no mesmo escopo que o objeto `query`
 - Explica como foi calculado o score de relevância para os resultados.
 - $\text{Boost} * \text{IDF (inverse document frequency)} * \text{TF (term frequency)}$
 - Também podemos usar a api `_explain`
- Sorting:
 - Declarado no mesmo escopo que o objeto `query`
 - Permite editar critério de ordenamento:
 - Default é score decrescente
 - Se `_score` não for o critério de ordenamento, não é computado.
 - Mas podemos gerar score mesmo assim com flag `"track_scores"`
 - Podemos ordenar por múltiplos campos
 - Campos posteriores servem de desempate.
- Manipulating Results:
 - Podemos omitir o conteúdo dos documentos encontrados:
 - Parâmetro `_source=False`
 - Podemos devolver só um subconjunto dos campos dos documentos, em vez do documento inteiro.
 - Usamos o campo `"fields"` para isso e um array com os nomes dos campos.
 - Permite uso de wildcard
 - Podemos manipular o resultado com um script antes de retorná-lo
 - Usamos o campo `"script_fields"`, que inclui os fields e os scripts respectivos.
 - Podemos definir `_source` como uma lista de fields:
 - Incluir ou excluir fields
 - Aceita wildcard
 - Podemos priorizar os resultados de alguns índices mais do que outros:
 - Parâmetro `"indices_boost"`
 - Multiplica-se um coeficiente para o score dos resultados daquele index.

Summary

- Searching can be categorized as structured and unstructured search types.
- Structured data works with non-text fields like numeric and date fields or fields that are not analyzed during indexing time and produce binary results (either they exist or they don't).
- Unstructured data deals with text fields expected to have a relevancy score. The engine scores the results based on how well the resultant documents match the criteria.
- We use term-level search for structured queries and full-text search for unstructured data.
- Every search request is processed by a coordinator node. Coordinator nodes are responsible for asking other nodes to execute the query, return partial data, aggregate it, and respond to the client with a final result.
- - Elasticsearch exposes a `_search` endpoint for queries and aggregations. We can invoke the `_search` endpoint by either using a URI request with parameters or building a full request using a special syntax called Query DSL.
 - Query DSL is the preferred choice for creating search queries. We can construct a plethora of queries, including advanced queries, using Query DSL.
 - Query DSL allows us to create leaf and compound queries. Leaf queries are simple search queries with a single criterion. Compound queries are used for advanced queries built with conditional clauses.
 - Crosscutting features are available for most types of queries: pagination, highlighting, explanation of the scoring, manipulation of the results, and so on.