

5 - Working with Documents

Sunday, 2 February, 2025 11:29 Manhã

- Operações single document e multi document tipo CRUD

INDEXAÇÃO

- Indexação pode ser feita com ou sem Ids
 - HTTP PUT para doc com ID provido pelo cliente na indexação
 - HTTP POST para doc ter ID autogerado pelo sistema

Listing 5.1 Indexing a new document into the `movies` index

```
PUT movies/_doc/1
{
  "title": "The Godfather",
  "synopsis": "The aging patriarch of an organized crime dynasty transfers
  ➡ control of his clandestine empire to his reluctant son"
}
```

Diagram annotations for Listing 5.1:

- Document indexing URL**: points to `movies/_doc/1`
- Body of the request**: points to the JSON object in the request body

```
{
  "_index" : "movies",
  "_type" : "_doc",
  "_id" : "1",
  "_version" : 1,
  "result" : "created",
  "_shards" : {
    "total" : 4,
    "successful" : 1,
    "failed" : 0
  },
  "_seq_no" : 0,
  "_primary_term" : 1
}
```

Diagram annotations for Figure 5.2:

- Document index name (movies)**: points to `"_index" : "movies"`
- Document type: defaults to `_doc` (document type is deprecated, so the value is set to `_doc`)**: points to `"_type" : "_doc"`
- Document identifier**: points to `"_id" : "1"`
- Document version: 1 indicates that this is the first version.**: points to `"_version" : 1`
- The resource was created successfully, so result = created.**: points to `"result" : "created"`

Figure 5.2 Response from the server when a document is indexed successfully

Listing 5.2 Indexing a document with no ID using POST

```
POST myindex/_doc
{
  "title": "Elasticsearch in Action"
}
```

Diagram annotations for Listing 5.2:

- The URL has no ID attached to it.**: points to `myindex/_doc`
- The request body is a JSON document.**: points to the JSON object in the request body

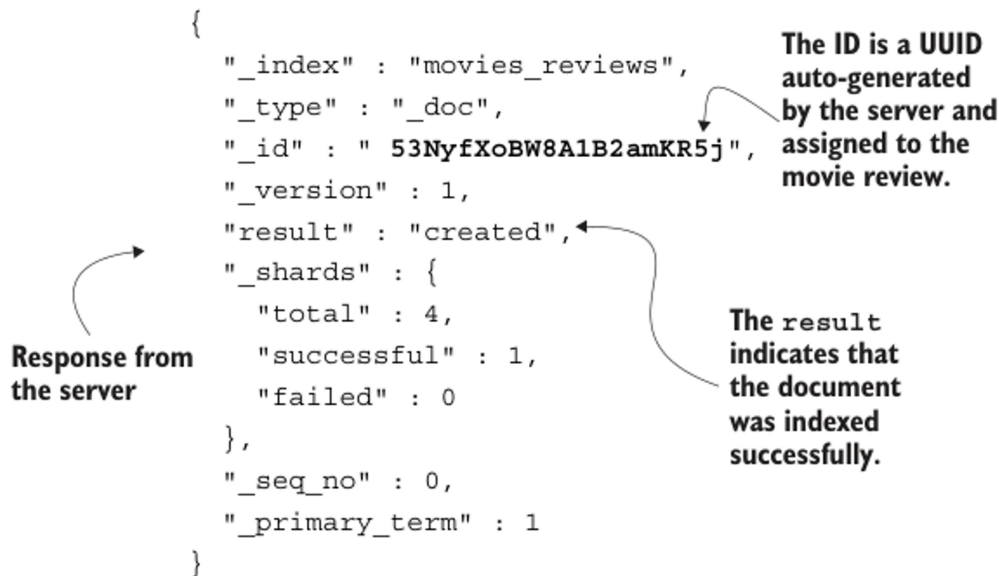


Figure 5.3 The server creates and assigns a randomly auto-generated ID to the document.

- Por default, operação de indexação ocorre igualmente caso o documento já exista na base ou não, sobreescreve.
 - API `_create` evita isso, não sobreescreve.
 - Dá erro caso id já exista na base


Listing 5.5 Indexing a new movie using the `_create` endpoint

```

PUT movies/_create/100
{
  "title": "Mission: Impossible",
  "director": "Brian De Palma"
}

```

- Criação dinâmica de index não pré-declarado pode ser desativada nas configurações do cluster
 - dá erro caso não exista mapping de index.




A running Elasticsearch instance creates Lucene instances.

Segments hold documents and are backed by the filesystem.

Figure 5.4 Mechanics of indexing documents

- Documento antes vai pra heap do shard, e a cada segundo tem um refresh para criar os segmentos com os documentos e respectivos índices invertidos.
 - Depois vai para o disco físico
 - Nos segmentos documentos já são buscáveis
 - Cada três segmentos são mergeados em um único maior, recursivamente.
 - Até aos poucos salvar tudo
 - Caso algo seja deletado, o segmento é apenas marcado como deletado, e depois aos poucos deletado de fato.
 - It's like writing notes on sticky pads, grouping three pads into a notebook, then three notebooks into a binder—so searching through them stays organized and quick!



- Falha no servidor no intervalo entre refreshes pode causar perda de dados.
 - Mas refreshes mais frequentes são mais computacionalmente caros
 - I/O é lento.
- Elastic Search é *eventually consistent*:
 - Documentos são escritos no data store em algum momento.
- Intervalo de refresh é configurável por index - default é 1 segundo.
 - Refresh também pode ser feito manualmente com API `_refresh`.
 - Podemos pausar refresh completamente para por exemplo esperar migrar vários documentos de fora e torná-los buscáveis todos de uma vez, quando reativar refresh.
 - Tempo de refresh também pode ser alterado na própria operação de indexar um documento
 - `"PUT movies/_doc/1?refresh=true"`
 - TRUE - docs imediatamente buscáveis
 - FALSE(default)
 - WAIT_FOR - indexação só ocorre no próximo ciclo de refresh

BUSCA

- Busca pode ser de um documento ou vários de uma vez.

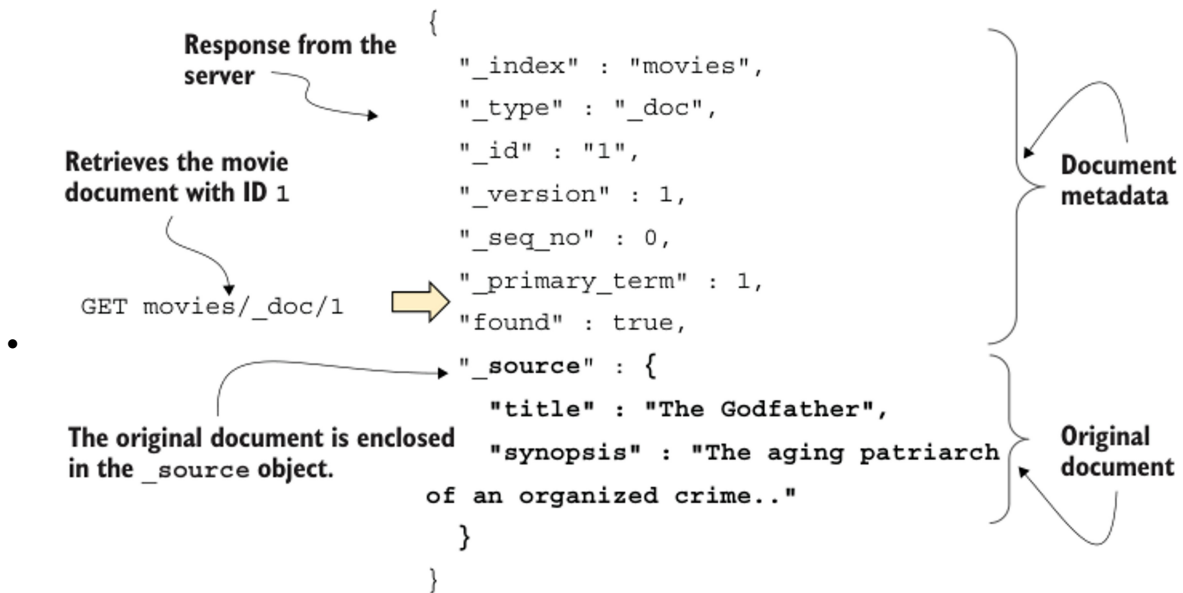


Figure 5.6 Retrieving a document using the GET API call

- Podemos apenas checar a existência de um documento:
 - `HEAD movies/_doc/1`
- Para buscar múltiplos documentos, podemos pegar:
 - De um único índice
 - De vários índices

Listing 5.9 Fetching multiple documents at once

```

GET movies/_mget
{
  "ids" : ["1", "12", "19", "34"]
}

```

Listing 5.10 Fetching documents from three different indexes

```

GET _mget
{
  "docs": [
    {
      "_index": "classic_movies",
      "_id": 11
    },
    {
      "_index": "international_movies",
      "_id": 22
    },
    {
      "_index": "top100_movies",
      "_id": 33
    }
  ]
}

```

_mget call with no index mentioned in the URL

The first index is provided here.

Index 2

Index 3

- Neste último, não tem como passar um array de ids

- Também podemos buscar vários documentos usando a api `_search`

Listing 5.11 Using an `ids` query to fetch multiple documents

```
GET classic_movies/_search
{
  "query": {
    "ids": {
      "values": [1,2,3,4]
    }
  }
}
```

MANIPULATING RESPONSES

- Podemos querer omitir algumas das informações na resposta
 - Segurança
 - Eficiência
- Por exemplo, buscamos direto o atributo `_source` em vez de `_doc`.
 - Não vem metadados
- Para fazer o oposto, suprimir o documento e pegar só o metadado:
 - `GET movies/_doc/1?_source=false`
- Para customizar ainda mais, podemos incluir ou excluir campos específicos com os atributos `_source_includes` e `_source_excludes` na chamada
 - `GET movies/_doc/3?_source_includes=title,rating,genre`
 - `GET movies/_source/3?_source_excludes=actors,synopsis`
 - Também podemos incluir e excluir ao mesmo tempo:
 - `GET movies/_source/13?_source_includes=rating*&_source_excludes=rating_amazon`

UPDATING DOCUMENTS

- `API_update` atualiza um único documento
- `API_update_by_query` permite atualizar vários ao mesmo tempo
- Por trás, esta operação é uma substituição, consiste das três etapas:
 - Busca
 - Modificação
 - Reindexação
- `_update` pode tanto modificar o que já existe quanto adicionar campos novos
- Podemos usar scripts para facilitar e granularizar a atualização
 - E.g. um script que apenas adiciona um item a um array, sem precisar reescrever o array inteiro.

Listing 5.23 Adding an actor to the actors list via a script

```
POST movies/_update/1
{
  "script": {
    "source": "ctx._source.actors.add('Diane Keaton')"  ◀— Additional actor
  }
}
```

- Exemplos de script, que podem coexistir na mesma requisição:
 - Adicionar um ator a um array

- Remove um ator de um array
- Adicionar um novo campo a um documento
- Remover um campo de um documento
 - Remover um campo inexistente não retorna erro
- Adicionar múltiplos campos
- Atualização pode ser condicional:

Listing 5.28 Conditionally updating the document using an if/else block

```
POST movies/_update/1
{
  "script": {
    "source": ""
  }
  ○ if(ctx._source.boxoffice_gross_in_millions > 125)
    {ctx._source.blockbuster = true}
    else
    {ctx._source.blockbuster = false}
  ""
}
```

- Um script tem três partes:

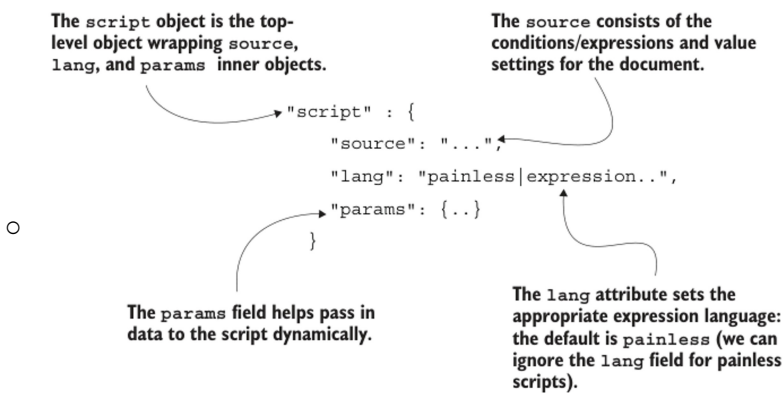


Figure 5.13 The anatomy of a script

- Source
 - Contém a lógica
- Params
- Language
 - Linguagem do próprio script
 - `Painless`(default), `expression`, `moustache`, ou `java`
- Podemos passar variáveis ao script sem deixá-la hardcoded

Listing 5.29 Dynamically passing a parameter to the script

```
POST movies/_update/1
{
  "script": {
    "source": ""
    ○ if(ctx._source.boxoffice_gross_in_millions >
      params.gross_earnings_threshold)
      {ctx._source.blockbuster = true}
    else
      {ctx._source.blockbuster = false}
    ""
    "params": {
      "gross_earnings_threshold":150
    }
  }
}
```

Business logic goes here.

Checks the value against params

Provides the parameter values

- Scripts são compilados quando rodam pela primeira vez
 - Computacionalmente caro
 - Com a parametrização, evitamos compilar várias vezes para cada valor hard-coded
- Para substituir um documento, basta usar um PUT no ID do documento que eu quero substituir, como se ele nem existisse antes. É sobrescrito.

```
PUT movies/_doc/1
{
  "title": "Avatar"
}
```

- Para modificar ou inserir um documento, usamos a operação *Upsert*.
 - Insere se não existe, atualiza (com um script, por exemplo) se existe.

Listing 5.31 Upsert block example

```
POST movies/_update/5
{
  "script": {
    "source": "ctx._source.gross_earnings = '357.1m'"
  },
  "upsert": {
    "title": "Top Gun",
    "gross_earnings": "357.5m"
  }
}
```

- Script só será executado se documento já existir, no exemplo acima.
 - Primeiro entraria como 357.7m, e na execução seguinte iria para 357.1m
- Para fazer upsert num campo só, usamos flag *doc_as_upsert*:

Listing 5.33 Updating the document if the field doesn't exist

```
POST movies/_update/11
{
  "doc": {
    "runtime_in_minutes": 110
  },
  "doc_as_upsert": true
}
```

- Com a flag, se não houver doc com ID 11, não há erro.
- Também podemos atualizar os documentos a partir de uma query, sem saber os Ids previamente:
 - *API_update_by_query*

Listing 5.34 Updating a document using a query method

```
POST movies/_update_by_query
{
  "query": {
    "match": {
      "actors": "Al Pacino"
    }
  },
  "script": {
    "source": """
      ctx._source.actors.add('Oscar Winner Al Pacino');
      ctx._source.actors.remove(ctx._source.actors.indexOf('Al Pacino'))
      """
    "lang": "painless"
  }
}
```

← Searches for documents and updates the set

← Search query: searches for all movies with Al Pacino

← Applies the following script logic to the matching documents

- Essa função tem várias etapas por trás dos panos:
 - Busca os documentos
 - Recheca se a versão do documento é a mesma na busca acima e quando entra a operação de update.

- Se não for, faz retry
- Quando há erro, só o documento gerador de erro não é atualizado, os outros são.

DELETING DOCUMENTS

- Podemos fazer deleção por ID (um por vez) ou por query
- **DELETAR É IRREVERSÍVEL!**
 - `DELETE movies/_doc/1`
 - Dá erro se documento não existir
- Por query, usamos a API `_delete_by_query`

Listing 5.36 Deleting all movies based on a criterion

```
POST movies/_delete_by_query
{
  "query": {
    "match": {
      "director": "James Cameron"
    }
  }
}
```

- Tão flexível quanto uma busca em si
 - Por ranges de algum campo
 - Com vários must e must not
 - Etc.
- Para deletar todos os documentos:

Listing 5.39 Deleting all documents at once

```
POST movies/_delete_by_query
{
  "query": {
    "match_all": {}
  }
}
```

- Funciona igualmente para vários index:
 - `POST <index_1>,<index_2>,<index_3>/_delete_by_query`
- Para listar todos os index:
 - `GET _cat/indices`

WORKING WITH DOCUMENTS IN BULK

- API `_bulk` usado para indexar documentos em escala.
 - Podemos manipular e deletar com bulk também
 - Poupa bandwidth do que fazer documento a documento

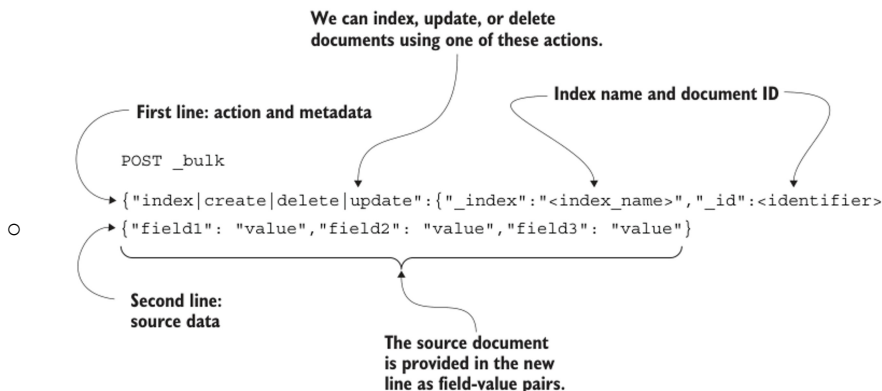


Figure 5.15 The `_bulk` API's generic format

- Cada documento é definido numa linha.
 - NDJSON.
- Podemos pré-definir o ID ou deixar o sistema autogerar.

- Index pode estar incluído no URL em vez do corpo da requisição.
- Não precisam ser documentos do mesmo tipo
- Podemos usar create em vez de index para não substituir nada.
- Update e delete também funcionam analogamente
- Para requisição curl, passamos o json com os documentos como binário usando @

REINDEXING DOCUMENTS

- API `_reindex`
- Mover documentos para outro índice
 - Por exemplo, para alterar mapping schema

Listing 5.50 Migrating data between indexes using the `_reindex` API

- ```
POST _reindex
```
- ```
{
  "source": {"index": "movies"},
  "dest": {"index": "movies_new"}
}
```
 - Unido a aliases, é uma ferramenta importante para fazer migrações com zero downtime

Summary

- Elasticsearch provides a set of APIs that work on documents. We can use these APIs to execute CRUD actions (create, read, update, and delete) on individual documents.
- Our documents are held in the shard's in-memory buffer and pushed into a segment during the refresh process. Lucene employs a strategy of creating a new segment with the documents during the refresh. It then cumulatively merges three segments to form a new segment, and the process repeats.

- Documents with identifiers (IDs) use the HTTP `PUT` action when indexing (for example, `PUT <index>/_doc/<ID>`), whereas documents with no IDs invoke the `POST` method.
- Elasticsearch generates random unique identifiers (UUIDs) and assigns them to documents during the indexing process.
- To avoid overriding a document, we can issue the following commands:
 - `_create`—This API throws an error if the document already exists.
 - `_mget`—This API lets us retrieve multiple documents at once, given their IDs.
 - `_bulk`—This API performs document operations such as indexing, deleting, and updating multiple documents in one invocation call.
- We can tweak the source and the metadata retrieved as a result of query invocations and then customize the returned document source to include and/or exclude fields by setting the `_source_includes` and `_source_excludes` properties, respectively.
- The `_update` API lets us modify an existing document by updating and adding fields. The expected updates are wrapped in a `doc` object and passed as the request body.
- Multiple documents can be modified by constructing an `_update_by_query` query.
- Scripted updates allow us to modify documents based on conditions. If the conditional clause mentioned in the request body is evaluated to `true`, the script is put into action.
- Documents can be deleted using HTTP `DELETE` for a single document or by running a `_delete_by_query` method on multiple documents.
- Migrating data between indexes is performed by the reindexing API. The `_reindex` API call expects to be given the source and destination indexes to transfer data.