

Version en ligne

**OFFERTE !**

pendant 1 an

+ QUIZ 

# MongoDB

Comprendre et optimiser  
l'exploitation de vos données  
(avec exercices et corrigés)

 Informatique technique



  
Collection

epsilon

Sébastien FERRANDEZ



## Avant-propos

### Chapitre 1

#### Introduction

- 1. Le Big Data et NoSQL ..... 7
- 2. MongoDB ..... 8
- 3. Les composants de MongoDB ..... 9
- 4. Architecture générale de MongoDB ..... 11
  - 4.1 La mise à l'échelle ..... 11
  - 4.2 Principe du sharding ..... 12
  - 4.3 Les replica sets ..... 13
- 5. La notation JSON ..... 16
- 6. Les types de données ..... 18
- 7. MongoDB en ligne de commande ..... 19
  - 7.1 Démarrer et arrêter MongoDB ..... 19
  - 7.2 Se connecter à la base de données via le shell ..... 20
  - 7.3 Créer une base de données ..... 26
  - 7.4 Supprimer une base de données ..... 27
  - 7.5 Interagir avec la base de données ..... 28
- 8. Gestion des collections ..... 29
  - 8.1 Les collations ..... 29
  - 8.2 Créer une collection ..... 31
  - 8.3 Supprimer une collection ..... 32
  - 8.4 Renommer une collection ..... 33
- 9. Gestion des documents ..... 35
  - 9.1 Insérer un document ..... 35
  - 9.2 Modifier un document ..... 40
  - 9.3 Valider des documents ..... 49
  - 9.4 Supprimer un document ..... 64
  - 9.5 Remplacer un document ..... 66

10. Les capped collections	67
10.1 Création d'une collection plafonnée	68
10.2 Particularités des capped collections	69

## **Chapitre 2**

### **Effectuer des requêtes dans MongoDB**

1. Chercher de l'information avec find et findOne	73
2. Les opérateurs de comparaison	75
3. Les opérateurs logiques	78
3.1 L'opérateur \$and	78
3.2 L'opérateur \$or	80
3.3 L'opérateur \$not	80
3.4 L'opérateur \$nor	81
4. Autres opérateurs	81
4.1 L'opérateur \$expr	81
4.2 L'opérateur \$type	83
4.3 L'opérateur \$mod	85
4.4 L'opérateur \$where	85
5. Opérateurs de tableaux	87
5.1 Les tableaux de documents	92
6. Le tri	95

## **Chapitre 3**

### **L'indexation avec MongoDB**

1. Comment ça marche ?	97
2. Index simples	98
3. Index composés	102
3.1 Préfixe d'un index	103
4. Index uniques	106

- 5. Indexation des objets et des tableaux . . . . . 108
- 6. Index géospatiaux. . . . . 109
  - 6.1 Les index 2d. . . . . 110
  - 6.2 Les index 2dsphere . . . . . 111
  - 6.3 Les objets GeoJSON . . . . . 111
- 7. Index partiels . . . . . 119
- 8. Index TTL . . . . . 122
- 9. Index textuels . . . . . 126
  - 9.1 Score d'un document . . . . . 131
  - 9.2 Pondération des index . . . . . 133
  - 9.3 Index wildcard . . . . . 135
- 10. Intersection des index . . . . . 136
- 11. La méthode explain . . . . . 139
  - 11.1 Plans d'exécution des requêtes. . . . . 141
  - 11.2 Explain appliqué à une collection . . . . . 142
- 12. Forcer l'utilisation d'un index avec hint . . . . . 149

**Chapitre 4**  
**Les requêtes géospatiales**

- 1. Introduction . . . . . 151
- 2. L'opérateur \$nearSphere. . . . . 152
- 3. L'opérateur \$geoWithin . . . . . 158
- 4. L'opérateur \$geoIntersects. . . . . 165

**Chapitre 5**  
**Le framework d'agrégation**

- 1. Introduction . . . . . 169
- 2. Fonctionnement . . . . . 169



3.	Les étapes du pipeline d'agrégation . . . . .	171
3.1	Le filtrage avec \$match. . . . .	172
3.2	Sélectionner ou modifier les champs avec \$project . . . . .	173
3.3	Ajouter des champs grâce à \$addFields . . . . .	178
3.4	Le regroupement avec \$group . . . . .	182
3.5	L'éclatement d'un tableau avec \$unwind . . . . .	190
3.6	Regrouper et compter avec \$sortByCount . . . . .	192
3.7	Les jointures de collection avec \$lookup . . . . .	196
3.8	Rechercher récursivement avec \$graphLookup . . . . .	206
3.9	La gestion des distances avec \$geoNear . . . . .	221
3.10	Écrire le résultat d'un pipeline dans une collection avec \$out . . . . .	227
4.	Les étapes cursor-like . . . . .	229
4.1	Limitation des résultats avec \$limit . . . . .	229
4.2	Le comptage avec \$count . . . . .	230
4.3	Le tri avec \$sort. . . . .	231
4.4	Le saut avec \$skip . . . . .	233
5.	Les opérateurs du pipeline d'agrégation . . . . .	233
5.1	Évaluer une expression avec \$cond . . . . .	233
5.2	Parcourir et transformer les éléments d'un tableau avec \$map . . . . .	234
5.3	Filtrer les éléments d'un tableau avec \$filter . . . . .	236
6.	La recherche par facettes . . . . .	237
6.1	L'étape \$bucket. . . . .	241
6.2	L'étape \$bucketAuto . . . . .	245
6.3	L'étape \$facet . . . . .	247

## Chapitre 6 Les vues

1.	Introduction . . . . .	251
2.	Créer une vue . . . . .	251
3.	Interagir avec les vues. . . . .	255

**Chapitre 7**  
**Les transactions multidocuments**

- 1. Introduction ..... 257
- 2. Les sessions ..... 266
- 3. Un exemple : la transaction bancaire ..... 269
- 4. Conflits d'écriture. .... 275
- 5. Limitation des transactions ..... 276

**Chapitre 8**  
**Gérer des fichiers binaires avec GridFS**

- 1. Introduction ..... 279
- 2. Principe de fonctionnement. .... 279
- 3. Les collections chunks et files ..... 280
- 4. Utiliser mongofiles ..... 281
  - 4.1 Ajouter un fichier à GridFS ..... 281
  - 4.2 Lister les fichiers présents dans GridFS ..... 283
  - 4.3 Chercher des fichiers dans GridFS ..... 283
  - 4.4 Télécharger un fichier depuis GridFS ..... 284
  - 4.5 Supprimer un fichier stocké dans GridFS ..... 284

**Chapitre 9**  
**Importer, exporter et restaurer des données**

- 1. Importer ..... 287
  - 1.1 L'utilitaire mongoimport ..... 287
- 2. Exporter. .... 294
  - 2.1 L'utilitaire mongodump ..... 294
  - 2.2 L'utilitaire mongoexport ..... 295
- 3. Restaurer ..... 298

## **Chapitre 10** **Exercices**

1. Introduction . . . . .	303
2. Suppressions, insertions et mises à jour de documents . . . . .	305
3. Validation des documents . . . . .	308
4. Les index . . . . .	309
5. Requêtes géospatiales . . . . .	311
6. Le framework d'agrégation . . . . .	312

## **Chapitre 11** **Corrigés des exercices**

1. Suppressions, insertions et mises à jour de documents . . . . .	315
2. Validation des documents . . . . .	320
3. Les index . . . . .	325
4. Requêtes géospatiales . . . . .	327
5. Le framework d'agrégation . . . . .	329

## **Annexe**

1. Créer un replica set . . . . .	333
Index . . . . .	335



# Chapitre 3

## L'indexation avec MongoDB

### 1. Comment ça marche ?

Dans la terminologie des bases de données, relationnelles ou non, un index est en tous points semblable à celui que l'on trouve à la fin de n'importe quel livre : on y regroupe les termes importants qui figurent dans l'ouvrage avec, en face de ceux-ci, les numéros des pages dans lesquelles ils se trouvent. Ceci nous évite tout simplement d'avoir à relire la totalité du livre lorsque nous cherchons un simple terme.

Par analogie, un index posé sur le champ ou le sous-champ d'une collection nous évite d'avoir à parcourir toute notre collection pour retrouver les valeurs de ce champ (ou sous-champ) correspondant à notre requête et participe ainsi à garder le temps d'exécution de nos requêtes le plus petit possible.

Les index ont des avantages et des inconvénients : ils améliorent considérablement les temps d'exécution des requêtes en lecture, mais ils ralentissent les opérations d'écriture telles que les insertions, les suppressions ou les mises à jour, qui nécessitent leur reconstruction. Cependant, les ralentissements observés sont généralement négligeables par rapport à la réduction du temps d'exécution qu'ils engendrent.

Pour savoir quels champs d'une collection ont besoin d'être indexés, il faut avoir une idée des requêtes sur celle-ci et de leur fréquence. Des champs qui sont souvent ciblés par des requêtes devront être indexés en priorité. Un site web qui propose un moteur de recherche de produits sous la forme d'une zone de saisie de texte devra avoir une collection produits dans laquelle le nom des produits ou encore la catégorie à laquelle ils appartiennent sont indexés, car les utilisateurs y entrent majoritairement des noms de produit (« iPhone 10 ») ou bien des noms de catégories (« cafetières italiennes »).

La nature de notre applicatif va directement impacter notre logique d'indexation : est-elle plutôt orientée écriture (*write-heavy*) ? Plutôt lecture (*read-heavy*) ? Un site web marchand n'est-il pas à la croisée des chemins ? En effet, on y fait de nombreuses lectures (recherches de produits, campagnes d'e-mailing promotionnel depuis la base clients, API mises à disposition de partenaires), mais aussi des écritures (paniers, commandes, approvisionnement de notre catalogue de produits, mises à jour quotidiennes des prix en fonctions de critères fournisseurs), dès lors vous comprenez bien qu'on ne peut pas décider d'une stratégie d'indexation sur un coin de table.

## 2. Index simples

Lorsqu'une collection est créée, MongoDB génère automatiquement un index sur le champ `_id`. Cet index ne peut aucunement être supprimé, car il garantit l'unicité même de cet identifiant. Pour créer vous-même un index, il vous faut utiliser la fonction `createIndex` dont voici la syntaxe :

```
db.collection.createIndex(< champ_et_type >, < options >)
```

Laissez-moi vous présenter la nouvelle version de notre collection `personnes` :

```
db.personnes.drop();

db.personnes.insert(

{"nom": "Durand", "prenom": "René", "interets": ["jardinage",
"bricolage"], "age": 77},
{"nom": "Durand", "prenom": "Gisèle", "interets": ["bridge",
"cuisine"], "age": 75},
{"nom": "Dupont", "prenom": "Gaston", "interets": ["jardinage",
"pétanque"], "age": 79},
```

```
{ "nom": "Dupont", "prenom": "Catherine", "interets": ["cuisine"], "age": 66 },
{ "nom": "Duport", "prenom": "Eric", "interets": ["cuisine",
"pétanque"], "age": 57 },
{ "nom": "Duport", "prenom": "Arlette", "interets": ["jardinage"], "age": 80 },
{ "nom": "Lejeune", "prenom": "Jean", "interets": ["jardinage"], "age": 75 },
{ "nom": "Lejeune", "prenom": "Marianne", "interets": ["jardinage", "bridge"],
"age": 66 }
]
)
```

Créons sans plus tarder un premier index sur le champ `age` des documents de la collection. Lorsque l'on crée un index, il est obligatoire de mentionner l'ordre d'apparition des valeurs de ce champ dans l'index : cet ordre est croissant ou décroissant (respectivement `1` et `-1`, exactement comme pour `sort()`). Nous avons décidé que notre index sur le champ `age` contiendra les valeurs prises par `age`, triées par ordre décroissant :

```
db.personnes.createIndex({"age": -1})
```

Le *shell* nous répond de la façon suivante :

```
{
  "createdCollectionAutomatically" : false,
  "numIndexesBefore" : 1,
  "numIndexesAfter" : 2,
  "ok" : 1
}
```

Nous pouvons constater qu'avant la création de notre index, il en existait déjà un ainsi que le montre la valeur contenue dans la clé `numIndexesBefore` ; il s'agit, vous l'avez deviné, de l'index par défaut évoqué précédemment et qui s'applique sur le champ `_id` de toute collection.

Pour valider que la création de cet index est conforme aux attentes, nous pouvons également utiliser la fonction `getIndexes` en l'appliquant à notre collection :

```
db.personnes.getIndexes()
```

Celle-ci nous affiche bien un tableau contenant deux documents avec les détails de nos index :

```
[
  {
    "v" : 2,
    "key" : {
      "_id" : 1
    },
    "name" : "_id_",
    "ns" : "test.personnes"
  },
  {
    "v" : 2,
    "key" : {
      "age" : -1
    },
    "name" : "age_-1",
    "ns" : "test.personnes"
  }
]
```

Vous voyez s'afficher le champ sur lequel est posé l'index, l'ordre d'indexation (croissant ou décroissant) ainsi que le nom donné à notre index par MongoDB. Par défaut, notre index porte le nom du champ ciblé auquel est concaténé un caractère souligné suivi de l'ordre, ce qui nous donne ici `age_-1`. Ce n'est ni très esthétique ni très parlant, voilà pourquoi nous allons le nommer de façon différente.

Pour réaliser cette opération de renommage d'index, nous allons commencer par supprimer l'index existant avant d'en recréer un avec un nouveau nom : `idx_age`. La suppression d'un index s'effectue avec la commande `dropIndex` à laquelle nous passerons l'ancien nom de l'index.

Le nom de notre nouvel index sera quant à lui spécifié dans le document qui contient les paramètres de l'index, en face de la clé `name`. Pour conclure, nous listerons les index de notre collection pour vérifier la bonne création de cet index portant le nouveau nom.

```
db.personnes.dropIndex("age_-1");
db.personnes.createIndex({"age": -1}, {"name": "idx_age"});
db.personnes.getIndexes()
[
```



```
{
  "v" : 2,
  "key" : {
    "_id" : 1
  },
  "name" : "_id_",
  "ns" : "test.personnes"
},
{
  "v" : 2,
  "key" : {
    "age" : -1
  },
  "name" : "idx_age",
  "ns" : "test.personnes"
}
]
```

Notre collection exemple est d'une taille plus que modeste et nous sommes seuls à l'utiliser, aussi nous pouvons nous permettre de reconstruire l'index en le supprimant. Vous pouvez imaginer sans peine que l'impact serait tout autre sur une collection comptant plusieurs centaines de milliers (voire millions !) de documents qui est utilisée par tout le personnel d'une grande entreprise. Il conviendrait alors d'exécuter ces différentes procédures dans une fenêtre de temps propice à la maintenance (en pleine nuit par exemple) et en utilisant l'option `background` pour signifier que cette tâche est une tâche de fond, de moindre priorité.

Par exemple, pour créer un index classé par ordre croissant sur le champ `pre-nom` en tâche de fond, vous écrirez :

```
db.personnes.createIndex( { "prenom": 1 }, { "background": true})
```

Lors de la création d'un index comme lors de la création d'une collection ou d'une vue (que nous verrons plus tard), il est possible de préciser une collation, mais attention, cette fonctionnalité n'est disponible que depuis la version 3.4 de MongoDB. Si nous reprenons l'index précédent en lui ajoutant les options relatives à la nature de la collation, nous obtenons :

```
db.personnes.createIndex(
  { "prenom": 1 },
  { "background": true},
  {
```

```
"collation": {  
  "locale": "fr"  
}  
}  
)
```

Lorsqu'un index simple est créé avec une collation, seules les requêtes qui précisent cette même collation pourront s'appuyer dessus, autrement une opération de *collection scan* sera effectuée, car elles utilisent la comparaison binaire par défaut. Prenons ce dernier index que nous venons de créer. La requête suivante l'utilisera :

```
db.personnes.find({"prenom": "Sébastien"}).collation({locale:  
"fr"})
```

Tandis que la suivante ne pourra pas s'appuyer dessus :

```
db.personnes.find({"prenom": "Sébastien"})
```

### 3. Index composés

Un index peut porter sur plus d'un champ : c'est ce que l'on appelle un index composé (*compound index*). Dans ce type d'index, l'ordre dans lequel les champs sont énumérés a son importance. Supprimons notre index `idx_age` et créons un index composé nommé `idx_nom_age` qui portera sur le nom puis sur l'âge des personnes :

```
db.personnes.createIndex({"age": 1, "nom": 1}, {"name":  
"idx_nom_age"})
```

L'index sera ordonné d'abord par valeurs croissantes d'âge et par ordre alphabétique de nom ensuite, au sein de chacune des différentes valeurs d'âge.

Lorsqu'un index composé dont le préfixe n'est pas une chaîne de caractères, un tableau ou un sous-document est utilisé avec une collation, une requête n'utilisant pas la bonne collation pour le champ texte indexé peut toutefois s'appuyer sur le préfixe de l'index.