Présentation

Qu'est-ce que mongoDB ?

- Base de données moderne et non relationnelle
- Fondée en 2007 (DoubleClick/10gen)
- Open-sourced en 2009
- Changement de licence en 2018

Un logiciel largement utilisé

BrightRoll Castlight Health Citrix Craiglist Ebay ElectronicArts Forbes Foursquare GILT Github HTC IBM InVision MetLife SAP Shutterfly Sony T-Mobile Toyota Twitter Verizon ViaCom Zendesk ...

Pourquoi utiliser MongoDB ?

- Combler le fossé entre les systèmes de stockage clé-valeur et les SGBDR
- Stockage orienté document
    - Les données sont stockées sous la forme de documents de style JSON.
- Indexation sur n'importe quel attribut
- Réplication et haute disponibilité
- Auto-sharding
- Requêtes riches
- Mises à jour rapides sur place
- Nombreux drivers pour des langages de programmation
- Support professionnel de MongoDB

Avantages de MongoDB par rapport aux SGBDR

- Moins de schéma
- La structure d'un objet unique est claire.
- Pas de jointures complexes.
- Possibilité d'interrogation approfondie.

- Tuning.
- Facilité de mise à l'échelle : MongoDB est facile à faire évoluer.
- La conversion/mise en correspondance des objets de l'application en objets de la base de données n'est pas nécessaire.

Limitations de MongoDB

- Pas de transactions
- Pas de jointures
- Entiers 32 bits
  - MongoDB corrigé
  - Certains drivers limitent encore à 32 bits (même dans PHP 7.x 64bits)
- Enorme consommation de RAM
- Taille du document : 16 Mo
- Authentification

Où utiliser MongoDB ?

- Big Data
- Gestion et diffusion de contenu
- Infrastructure mobile et sociale
- Gestion des données utilisateur
- Hub de données

Le mouvement NoSQL

Définition

- Terme "flou"
- Types de bases de données non (seulement) relationnelles
    - stocker les données dans un format différent des "tables" relationnelles
- Interroger à l’aide d'un langage spécifique
    - non algébrique
    - non-relationnel
    - mais "riche" quand même (selon la BDD)
- Permettre une scalabilité horizontale facile
- Manipuler de volumes de données importants

Théorie

- Orienté-agrégats
    - groupe de données (documents) modifiée en meme temps
    - encapsulation de données dans d'autres données (au lieu d'une relation)
- Orienté-graphes
    - documents = node
    - requetes multi-document sans jointures
    - ne pas confondre avec triple-stores (orienté relation)
- Sans-schéma
    - capacité d'intégration de données hétérogènes
    - facilité d'évolution
    - déporter les vérifications de cohérence & consistance coté applicatif

Typologies

- Clé-valeur (ex: Redis, Riak)
- Graphe (Neo4j, HyperGraphDB)
- Document (MongoDB, CouchDB)

- Big Table (Cassandra, HBase)

Propriétés ACID

Les capacités ACID garantissent que si plusieurs utilisateurs font de manière simultanée des modifications des données,

- toutes les modifications vont être prises en compte,
- dans un ordre précis et maîtrisé de manière à avoir un résultat cohérent (intégrité des données)
- avec l'historique des modifications faites par chacun.

La mise en œuvre stricte des capacités ACID entraîne des coûts logiciels importants et un niveau de performance moindre à infrastructure matérielle équivalente.

Références

- https://fr.wikipedia.org/wiki/NoSQL#NoSQL_orient%C3%A9-agr%C3%A9gats

Rappels sur les bases de données

Théoreme CAP

Trois contraintes

Cohérence (Consistency)

- Tous les noeuds du système voient les mêmes données au même moment

Disponibilité (Availability)

- Garantie que toutes les requêtes (en lecture ou en écriture) reçoivent une réponse

Tolérence au partitionnement (Partition tolerance)

- Aucune panne moins importante qu'une coupure totale du réseau ne doit empecher le systeme de répondre correctement
- En cas de morcellement en sous-réseaux, chacun doit pouvoir fonctionner de maniere autonome comme un seul système

Énoncé du théorème - et propriétés des BDD

D'après ce théorème :

- Il est impossible sur un systeme informatique de calcul distribué de garantir en même temps (de manière synchrone) les trois contraintes C-A-P.
- Un système de calcul distribué ne peut garantir que deux de ces contraintes.

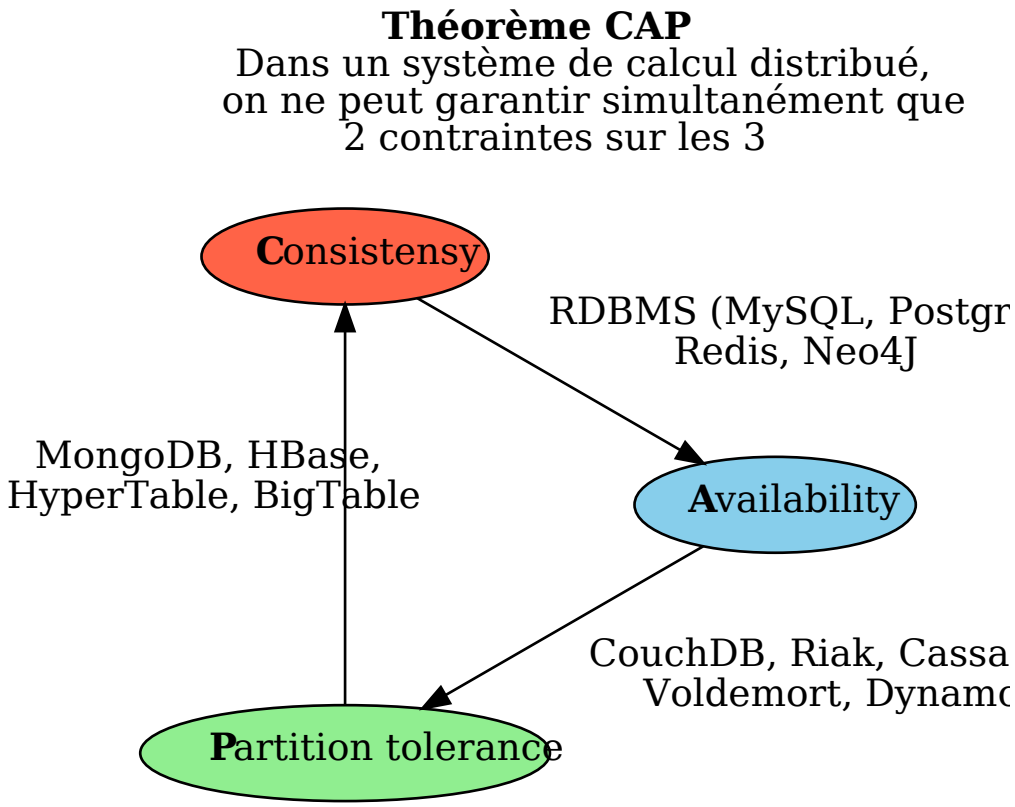

> **Note**
>
> En général, les SGBD essayent de compenser la partie qu'elles ne peuvent pas garantir, au moins pour certains cas d'usage.

Propriétés ACID

Atomicité (Atomic)

- Une transaction est entière : ^S tout ou rien ^T.

Cohérence (Consistent)

- Une transaction amène la base d’un état stable à un autre.

Isolation (Isolated)

- Les transactions n’agissent pas les unes sur les autres.

Durabilité (Durable)

- Une transaction validée provoque des changements permanents.

Les propriétés ACID sont quatre propriétés essentielles d’un sous-système de traitement de transactions d’un système de gestion de base de données

> **Important**
>
> On considère souvent que seuls les SGBD qui respectent ces propriétés sont dignes d’être considérées comme des bases de données

Rappels sur JSON

- `JavaScript Object Notation`
- Créé en 2005
- Format d'échange de données structurées léger
- Schéma des données non connu
  - contenu dans les données
- Basé sur deux notions :
  - collection de couples clé/valeur
  - liste de valeurs ordonnées

Syntaxe et types en JSON

- Similaire à du JavaScript uniquement pour les données
- On parle de **littéral**
- Deux types atomiques (`string` et `number`)
- Trois constantes (`true` , `false` , `null`)
- Structures possibles :
  - objet (couples clé/valeur) :
    - `{}`
    - `{ "nom": "doe", "prenom": "jon" }`
  - tableau (collection de valeurs) :
    - `[]`
    - `[ 1, 5, 10]`
  - une valeur dans un objet ou dans un tableau peut être elle-même un littéral

Validation du JSON

Validation possible du JSON à l'aide de jsonlint.com/

```
{
  "name": "John Doe",
  "age": 42,
```

```
  "food": ["pizza", "cake"],
  "wife": {
    "name": "Jane Doe",
    "age": 42
  }
}
```

> **Note**
>
> Il existe aussi des moyens de définir des structures de données spécifiques en JSON (notion de schéma de donneés) et de valider un document d'après ce schéma
> Voir https://json-schema.org/

Compléments

`BSON` : extension de `JSON`

- Quelques types supplémentaires (identifiant spécifique, binaire, date, ...)
- Distinction entier et réel

Modèle de données

Equivalences avec les SGBDR

Le tableau suivant montre la relation entre la terminologie des SGBDR et MongoDB

RDBMS	MongoDB
Database	Database
Table	Collection
Tuple/Row	Document
column	Field
Table Join	Embedded Documents
Primary Key	Primary Key (*)

> **Note**
>
> (*): Clé primaire `_id` fournie par mongodb lui-même

Les données sont des documents

- stocké en Binary JSON (BSON)
- documents similaires rassemblés dans des collections
- pas de schéma des documents définis en amont
    - contrairement à un BD relationnel ou NoSQL de type Column Store
- les documents peuvent n'avoir aucun point commun entre eux
- un document contient (généralement) l'ensemble des informations
    - pas (ou très peu) de jointure à faire

- BD respectant CP (dans le théorème CAP)
    - propriétés ACID au niveau d’un document

Exemple de documents

```
{
 _id: ObjectId(7df78ad8902c)
 title: 'MongoDB Overview',
 description: 'MongoDB is no sql database',
 by: 'tutorials point',
 url: 'http://www.tutorialspoint.com',
 tags: ['mongodb', 'database', 'NoSQL'],
 likes: 100,
 comments: [
  {
   user:'user1',
   message: 'My first comment',
   dateCreated: new Date(2011,1,20,2,15),
   like: 0
  },
  {
   user:'user2',
   message: 'My second comments',
   dateCreated: new Date(2011,1,25,7,45),
   like: 5
  }
 ]
}
```

Schéma dynamique

- Documents variant très fortement entre eux, même dans une même collection
- On parle de **self-describing documents**
- Ajout très facile d'un nouvel élément pour un document, même si cet élément est inexistant pour les autres
- Pas de `ALTER TABLE` ou de redesign de la base

Langage d'interrogation

- Pas de SQL (bien évidemment), ni de langage proche
- Définition d'un langage propre (basé sur `JS`)
- Langage permettant plus que les accès aux données
    - définition de variables
    - boucles

    - …
- **Pas de jointures entre les collections**

Installation sous Linux

Pour les systèmes Linux antérieurs 2018, la version opensource de MongoDB est fournie dans les packages officiels de la distribution :

```
$ apt-get update
$ apt-get install mongodb mongodb-clients
```

Pour les nouveaux systemes postérieurs à 2018 (licence non-opensource), il faut la Community Edition depuis les serveurs de MongoDB :

```
$ apt-get install gnupg
$ wget -qO - https://www.mongodb.org/static/pgp/server-5.0.asc \
   | apt-key add -
$ echo "deb http://repo.mongodb.org/apt/debian buster/mongodb-org/5.0 main" \
   | tee /etc/apt/sources.list.d/mongodb-org-5.0.list
$ apt-get update
$ apt-get install -y mongodb-org
$ systemctl start mongod
```

Gestion du service Linux

```
sudo systemctl start mongodb
sudo systemctl stop mongodb
sudo systemctl restart mongodb
```

```
mongo
```

Références

https://www.mongodb.com/docs/manual/tutorial/install-mongodb-on-debian/

Installation sous MacOS

Avec Homebrew

```
$ brew tap mongodb/brew
$ brew update
$ brew install mongodb-community@5.0
$ brew services start mongodb-community@5.0
```

Installation sous Windows

Avec chocolatey

```
C:\> choco update
C:\> choco install mongodb
```

Installation manuelle

1. Télécharger mongodb sur le site officiel http://www.mongodb.org/downloads
2. Lancer l'exécutable
3. Cliquer sur suivant tant que nécessaire jusqu'à la fin de l'installation

Important

Les version 32 bits supportent uniquement des BDD < 2GB et ne sont pas utilisable en production

```
C:\> wmic os get osarchitecture
OSArchitecture
64-bit
```

Installation avec Docker

Utilisation de l'image officielle mongo

Pour le serveur

```
$ docker run -it --rm --name mongo -p 27017:27017 mongo
```

Pour le client (une fois le serveur lancé)

```
docker exec -it mongo bash
```

Warning

L'image docker utilise l'authentification par défaut. Il sera donc nécessaire d'y créer des utilisateurs pour l'utiliser.

Après l'installation

Créer le dossier des données

Sous Windows, il peut arriver que le dossier des données ne soit pas correctement créé et empêche le lancemente de mongo.

Pour corriger ce bug, ouvrir un terminal (`powershell.exe`)

```
> mkdir C:\data\db
```

Mongo dans le PATH

Assurez vous que

1. les commandes mongo(sh) et mongod sont bien installées
2. qu'elle sont correctement executables depuis tout chemin

Au cas échéant, ajoutez le chemin des binaires de mongo dans le PATH systeme.

Authentification

A savoir

- MongoDB ne force pas l'authentification, ni les autorisations par défaut
- Les modeles de roles de MongoDB sont relativement limités
- ... mais ça s'améliore

Création d'un user pour le mode sécurisé

Lancer MongoDB sans controle d'accès

```
$ mongod --port 27017 --dbpath /var/lib/mongodb
```

Lancer la commande `mongosh`, puis taper :

```
> use admin
> db.createUser({
  user: 'admin',
  pwd: 'admin',
  roles: [{
    role: 'root',
    db: 'admin'
  }]
})
> exit
```

Lancement de MongoDB en mode sécurisé

Eteindre MongoDB apres la création du user

```
> db.adminCommand( { shutdown: 1 } )
```

Relancer mongo avec l'option `--auth`

```
$ mongod --auth --port 27017 --dbpath /var/lib/mongodb
```

ou bien utiliser l'option `security.authorization` dans le fichier de configuration

```
security:
  authorization: enabled
```

Authentification

Ensuite relancer le client mongo en s'authentifiant :

```
$ mongosh --authenticationDatabase XXX -u admin -p
```

(où XXX vaut `admin` ou `$external`)

Références

- https://stackoverflow.com/questions/20117104/mongodb-root-user
- https://www.mongodb.com/docs/manual/reference/built-in-roles/
- https://www.mongodb.com/docs/manual/tutorial/configure-scram-client-authentication/

Prise en main

Concepts et outils

Database Server and Client

RDBMS	MongoDB
Mysqld/Oracle	mongod
mysql/sqlplus	mongosh (anciennement mongo)

Obtenir de l'aide

Lister les sujet d'aide d'une base de données

```
> db.help()
```

Obtenir de l'aide sur une commande spécifique

```
> db.COMMANDE.help()
```

Voir l'implémentation d'une commande

Taper le nom de la commande, sans les parentheses ()

```
> db.COMMANDE
```

A minima, cela retourne les propriétés de la commande souhaitée.

Obtenir des statistiques

```
db.help()
```

Bases de données

Concept

- La base de données est un conteneur physique pour les collections
- Chaque base de données obtient son propre ensemble de fichiers sur système de fichiers
- Un serveur MongoDB possède généralement plusieurs bases de données

Lister les bases de données

```
show databases
```

Création d'une base de données

```
> use DATABASE_NAME
```

Exemple :

```
> use mydb
switched to db mydb
```

Retrouver la base de donnée actuelle

```
> db
mydb
```

Pour lister toutes les BDD :

```
>show dbs
local   0.78125GB
test    0.23012GB
```

Persistance d'une base de données

Pour qu'une bdd existe/persiste, il faut insérer au moins un document dedans.

```
> db.movie.insert({"name":"demo"})
> show dbs
local    0.78125GB
mydb     0.23012GB
test     0.23012GB
```

MongoDB - Drop Database

```
> db.dropDatabase()
```

Collections

Concept

- `collection` représente la collection dans laquelle nous allons effectuer l'opération, et doit donc correspondre à une des collections présentes dans la base

Notion de namespace

L'espace de nom est une combinaison des collections et du nom de la base de données

Formalisme

Dans MongoDB, nous utilisons un formalisme de type `db.collection.fonction()` :

- `db` représente la base de données choisie grâce à la commande use (ce mot clé est non modifiable)
- `collection` représente la colletion dans laquelle nous allons effectuer l'opération, et doit donc correspondre à une des collections présentes dans la base
- `fonction()` détermine l'opération à effectuer sur la collection.

Lister les collections

Soit

```
> show collections
```

Soit

```
> db.getCollectionsInfos()
```

Créer une collection

```
> db.createCollection("movies")
```

Lire une collection

Nous aborderons ce sujet dans la partie Recherche de documents.

Mettre à jour une collection

```
> db.collection.update()
```

Supprimer une collection

```
> db.movies.remove()
> db.movies.drop()
```

Compter le nombre d'éléments

En premier lieu, on peut dénombrer le nombre de documents de chaque collection, grâce à la fonction count().

```
> db.restaurants.count()
```

Reférences

- https://github.com/ozlerhakan/mongodb-json-files/tree/master/datasets
- https://www.mongodb.com/docs/manual/reference/method/db.collection.update/
- https://www.mongodb.com/docs/manual/reference/glossary/

Documents

- Un document est un ensemble de paires clé-valeur.
- Les documents ont un schéma dynamique.

Le schéma dynamique signifie que :

- les documents d'une même collection ne doivent pas nécessairement avoir le même ensemble de champs ou la même structure,
- les champs communs des documents d'une collection peuvent contenir différents types de données.

Types de données

Primitifs

- **String**: This is the most commonly used datatype to store the data. String in MongoDB must be UTF-8 valid.
- **Integer**: This type is used to store a numerical value. Integer can be 32 bit or 64 bit depending upon your server.
- **Boolean**: This type is used to store a boolean (true/ false) value.
- **Double**: This type is used to store floating point values.
- **Null**: This type is used to store a Null value.

Types de données

Objets

- **Min/Max Keys**: This type is used to compare a value against the lowest and highest BSON elements.
- **Arrays**: This type is used to store arrays or list or multiple values into one key.
- **Timestamp**: ctimestamp. This can be handy for recording when a document has been modified or added.
- **Object**: This datatype is used for embedded documents.
- **Date**: This datatype is used to store the current date or time in UNIX time format. You can specify your own date time by creating object of Date and passing day, month, year into it.

Types de données

Complexes

- **Object ID**: This datatype is used to store the document’s ID.
- **Binary data**: This datatype is used to store binary data.
- Code: This datatype is used to store JavaScript code into the document.
- **Regular expression**: This datatype is used to store regular expression.
- **Symbol**: This datatype is used identically to a string; however, it's generally reserved for languages that use a specific symbol type.

Structure des documents

- Les documents présents dans une collection n’ont pas de schémas prédéfinis.
- Si nous souhaitons avoir une idée de ce que contient la collection, il est possible d’afficher un document (le premier trouvé), avec findOne(). Cette opération permet de comprendre la structure global d’un document, même s’il peut y avoir des différences entre documents.

  ```
  db.restaurants.findOne()
  ```

Valeurs prises par les itemps

Une autre fonction très utile pour mieux appréhender les données est de lister les valeurs prises par les différents items de la collection, grâce à distinct(). Pour spécifier un sous-item d’un item, il est nécessaire d’utiliser le formalisme item.sousitem.

```
db.restaurants.distinct("borough")
db.restaurants.distinct("cuisine")
db.restaurants.distinct("address.zipcode")
db.restaurants.distinct("grades.grade")
```

Insertion de documents

Document unique

```
> db.COLLECTION_NAME.insert(document)
```

```
> db.mycol.insert({
    _id: ObjectId(7df78ad8902c),
    title: 'MongoDB Overview',
    description: 'MongoDB is no sql database',
    tags: ['mongodb', 'database', 'NoSQL'],
    likes: 100
})
```

Dans le shell mongosh, on utilisera plutot `insertOne(...)`

Documents multiples

Il est possible d'insérer plusieurs documents en une fois en passant un array à la fonction `insertMany()`

```
> db.post.insertMany([{ ... }, { ... }])
```

Il est également possible d'utiliser la méthode `save()`. Si aucun `_id` n'est spécifié, elle se comportera de la même façon que `insert()`

Import de données en masse

Depuis le shell (unix)

```
$ mongoimport \
    --authenticationDatabase admin \
    --username=XXX \
    --password=XXX \
    --db dbName \
    --collection collectionName \
    --file fileName.json \
    --jsonArray
```

Références

- https://www.mongodb.com/docs/manual/reference/method/db.collection.insertMany/
- https://www.mongodb.com/docs/manual/reference/method/db.collection.insert/

Recherche d’informations

Requêtes de documents

Pour faire des recherches, on utilise la fonction `find()` et `findOne()`

- Sans paramètre, elle renvoie l’ensemble des documents.
  - Il faut donc l’utiliser avec précautions.
- Elle peut aussi prendre deux paramètres :
  - les critères de sélection des documents
  - les choix d’items des documents à afficher

Ces deux paramètres doivent être écrits sous la forme d’objets JSON.

```
> db.coll.find(..)
```

Exemple : recherche d'après deux critères

```
> db.coll.find({"cuisine": "Bakery", "borough": "Bronx"})
```

> **Note**
>
> Pour rendre le resultat plus plaisant à l'oeil on peut ajouter la fonction `pretty()` sur le résultat du `find()`
>
> ```
> > db.coll.find(..).pretty()
> ```

Recherche sur une clé de sous-document

```
> db.coll.find({"address.zipcode": "10462"})
```

Projection

Pour afficher seulement certains éléments, on peut ajouter un deuxième argument spécifiant les items que l’on veut (valeur 1) ou qu’on ne veut pas (avec valeur 0).

```
> db.restaurants.find({ cuisine: "French" }, { name: 1 })
```

Par défaut, l'identifiant du document, toujours nommé `_id`, est renvoyé. Pour ne pas l'avoir, il faut ainsi le préciser avec `"_id": 0`.

```
> db.restaurants.find({ cuisine: "French" }, { _id: 0, name: 1 })
```

Sous-item

Les documents peuvent être complexes (c'est même le but), et les critères portent donc souvent sur des sous-items. Il faut utiliser le même formalisme déjà vu ("item.sousitem"). Il faut noter deux choses :

- on peut aller aussi loin que nécessaire dans l'utilisation du . ;
- il est obligatoire d'utiliser des '"'' pour les items.

```
db.restaurants.find({ "grades.grade" : "A" }, { _id: 0, name: 1 })
```

Ce formalisme est le même pour indiquer un sous-item à afficher. Nous ajoutons à la requête précédent l'affichage des scores. Nous voyons que le résultat inclu tous les scores.

```
> db.restaurants.find({ "grades.grade" : "A" }, { _id: 0, name: 1, "grades.grade" : 1 })
```

Comparaisons avec d'autres opérateurs

Opération	**Syntaxe**
Egalité	`{<key>: <value>}`
Inférieur à	`{<key>: {$lt: <value>}}`
Inférieur ou égal à	`{<key>: {$lte: <value>}}`
Supérieur à	`{<key>: {$gt: <value>}}`
Supérieur ou égal à	`{<key>: {$gte: <value>}}`
Différent de	`{<key>: {$ne: <value>}}`

Exemples:

```
> db.coll.find({"by": "point"}).pretty()

// where age >= 18
> db.coll.find({"age": {$gte: 18}}).pretty()
```

Opérateurs logiques

ET logique

Il suffit de passer plusieurs clés séparées par ","

```
> db.coll.find({
   key1:value1,
   key2:value2
 }).pretty()
```

OU logique

```
>db.coll.find({
   $or: [
     {key1: value1}, {key2:value2}
   ]
 }).pretty()
```

Ex:

```
>db.coll.find({
   $or: [
     {"by":"tutorials"},
     {"title": "MongoDB Overview"}
   ]
 }).pretty()
```

NON OU logique

```
> db.coll.find({
   $nor: [
     {"by": "tutorials"},
     {"title": "MongoDB Overview"}
   ]
 }).pretty()
```

NON logique

```
> db.coll.find({
   $not: {"by": "tutorials"}
  }).pretty()
```

ET + OU logique

```
> db.coll.find({
   "likes": {$gt:10},
   $or: [
     {"by": "tutorials"},
     {"title": "MongoDB Overview"}
   ]
  }).pretty()
```

Présence d’un item

Pour tester la présence ou non d’un item, on utilise l’opérateur `$exists` avec

- `true` si on teste la présence
- et `false` l’absence

```
> db.restaurants.find({ french : { $exists: true } }, { _id: 0, name: 1 })
```

Dénombrement

La fonction `count()` peut s'ajouter à la suite d’une fonction `find()` pour connaître la taille du résultat.

```
> db.restaurants.find({ cuisine : "French" }).count()
```

Filtrage des résultats

Limitation du résultat

On peut aussi limiter le nombre de documents renvoyés par la fonction find() en lui ajoutant la fonction limit(), comme ici où nous nous restreignons aux 5 premiers résultats.

```
db.restaurants.find({ cuisine : "French" }, { _id: 0, name: 1 }).limit(5)
```

Tri

- Réalisable avec la fonction `sort()` .
- On doit indiquer les items de tri
  - valeur de 1 pour un tri ascendant
  - valeur de -1 pour un tri descendant.

Exemple

```
> db.restaurants.find(
   { cuisine : "French" },
   { _id: 0, name: 1 }
 ).sort({ name: 1 })
```

Idem que précédemment, mais dans l'ordre décroissant.

```
> db.restaurants.find(
   { cuisine : "French" },
   { _id: 0, name: 1 }
 ).sort({ name: -1 })
```

Il est possible de mettre plusieurs critères de tri, en indiquant croissant ou décroissant pour chaque item de tri.

```
db.restaurants.find(
   { cuisine : "French" },
   { _id: 0, name: 1, borough: 1 }
).sort(
   { borough: -1, name: 1 }
)
```

Agrégats

En plus des recherches classiques d'informations, le calcul d'agrégat est très utilisé, pour l'analyse, la modélisation ou la visualisation de données. Ce calcul s'effectue avec la fonction aggregate(). Celle-ci prend en paramètre un tableau d'opérations (appelé aussi pipeline), pouvant contenir les éléments suivants :

- $project : redéfinition des documents (si nécessaire)
- $match : restriction sur les documents à utiliser
- $group : regroupements et calculs à effectuer
- $sort : tri sur les agrégats
- $unwind : découpage de tableaux
- ...

Syntaxe

```
> db.coll.aggregate([
   {$group: {_id: <expression>, // Group By Expression
         <field1>: { <accumulator1> : <expression1> },
         ...}
   }
])
```

Agrégat simple

Voici un premier exemple permettant un calcul pour toute la base. Ici, nous réalisons un dénombrement (il fait la somme de la valeur 1 pour chaque document).

```
db.restaurants.aggregate([
   { $group: { _id: null, nb: { $sum: 1 }}}
])
```

Les calculs peuvent être plus complexes, comme nous le verrons plus tard. Bien évidemment, ces calculs d'agrégats peuvent se faire aussi en ajoutant des critères de regroupement. Attention au $ avant le nom de l'item.

```
db.restaurants.aggregate([
   { $group: { _id: "$borough", nb: { $sum: 1 }}}
])
```

Tri

Ce résultat peut être trié en ajoutant l'action $sort dans le tableau, avec le même mécanismes que précédemment (1 : ascendant, -1 : descendant).

```
db.restaurants.aggregate([
    { $group: { _id: "$borough", nb: { $sum: 1 }}},
    { $sort: { "nb": -1 }}
])
```

Redéfinition des documents (et limite)

Il est parfois intéressant (voire nécessaire) de redéfinir les documents, pour ne garder que les items qui nous intéressent. Dans cette projection, il existe différentes fonctions de traitement comme la concaténation (cf ci-dessous).

L'action $limit permet de limiter le nombre de sorties renvoyées par le moteur.

```
db.restaurants.aggregate([
    { $project: { _id: 0, name: 1, info: { $concat: [ "$cuisine", " - ", "$borough" ]} }},
    { $limit: 5 }
]).pretty()
```

Restriction

On peut aussi faire une restriction avant le calcul, avec l'opération $match.

```
db.restaurants.aggregate([
    { $match: { cuisine: "French" }},
    { $group: { _id: "$borough", nb: { $sum: 1 }}}
])
```

Découpage des tableaux

Imaginons maintenant que nous souhaitons calculer le nombre de restaurant par grade. La première idée serait de réaliser l'opération suivante.

```
db.restaurants.aggregate([
    { $group: { _id: "$grades.grade", nb: { $sum: 1 }}}
])
```

Malheureusement, nous voyons que le regroupement se fait par ensemble de grades existant dans la base. Il faut donc faire un découpage des tableaux grades dans chaque document. Pour cela, il existe l'opération $unwind.

Pour montrer comment fonctionne cette opération, voici les 5 premières lignes renvoyées lorsqu'on l'applique directement sur les données. On s'apercoit que chaque document ne contient plus qu'une seule évaluation.

```
db.restaurants.aggregate([
    { $unwind: "$grades" },
    { $limit: 5 }
]).pretty()
```

Par ce biais, nous pouvons donc maintenant faire l'opération de regroupement par grade.

```
db.restaurants.aggregate([
    { $unwind: "$grades" },
    { $group: { _id: "$grades.grade", nb: { $sum: 1 }}}
])
```

Calcul statistique

Comme indiqué précédemment, on peut faire tous les calculs d'agrégats classiques, comme ici avec la somme ($sum), la moyenne ($avg), le minimum ($min) et le maximum ($max).

```
db.restaurants.aggregate([
    { $unwind: "$grades" },
    { $group: {
        _id: null,
        nb: { $sum: 1 },
        scoreTot: { $sum: "$grades.score" },
        scoreMoy: { $avg: "$grades.score" },
        scoreMin: { $min: "$grades.score" },
        scoreMax: { $max: "$grades.score" }
    }}
]).pretty()
```

Regroupement de valeurs

Une fois que les documents sont scindés en plusieurs suite à l'action $unwind, il peut être intéressant de regrouper les valeurs dans un tableau. Ici, nous cherchons les différents grades obtenus par chaque restaurant.

```
db.restaurants.aggregate([
    { $limit: 5 },
    { $unwind: "$grades" },
    { $group: { _id: "$name", nb: { $sum: 1 }, eval: { $addToSet: "$grades.grade" }}}
])
```

Jointures

Il est possible de réaliser une jointure entre deux collections, dans un aggrégat, avec l'opérateur $lookup.

```
db.transactions_small.aggregate([
    { $match: { "horodateur": 57080603}},
    { $lookup: {
        from: "mobiliers",
        localField: "horodateur",
        foreignField: "fields.numhoro",
        as: "mobilier"
    }},
    { $limit: 5}
])
```

Références

- https://www.mongodb.com/docs/manual/reference/operator/aggregation/lookup/#mongodb-pipeline-pipe.-lookup
- https://www.mongodb.com/docs/manual/reference/operator/aggregation/graphLookup/#mongodb-pipeline-pipe.-graphLookup

Atomicité

- pas de transactions
- utiliser db.coll.findAndModify à la place

Références

- https://www.mongodb.com/docs/manual/reference/method/db.collection.findAndModify/
- https://www.journaldev.com/6221/mongodb-findandmodify-example

NodeJS

- MongoDB s'est rapidement développé pour devenir une base de données populaire pour les applications Web et convient parfaitement à Node.JS applications
- Nous avons beaucoup de modules tiers pour se connecter à MongoDB: Mongoose, MongoDB, MongoClient
- Nous devons d'abord établir une connexion entre l'application de noeud et MongoDB.
- Une fois la connexion établie, lancez la requête pour effectuer une opération CURD dans la base de données.

Avec MongoClient

Avec Mongoose (support des modèles)

Vue d'ensemble

- Object modelling for MongoDB
- Define schemas in Node.js for MongoDB
- Query building (ODM)
- Mongoose: http://mongoosejs.com/

Installation

```
$ npm install -g mongoose
```

```
var mongoose = require('mongoose')
```

Utilisation

```
var express = require('express');
var mongoose = require('mongoose');
var app = express();

// Middleware
mongoose.connect("mongodb://localhost:27017/userManagement");
```

Utilisation de schémas

Définir le schéma

```
var movieSchema = new mongoose.Schema({
  title: String,
  rating: String,
  releaseYear: Number,
  likeIt: Boolean
});
```

Utiliser la base de données:

```
var Movie = mongoose.model("Movie", movieSchema, "movies");

function showAllMovies() {
  Movie.find(function(err, movies)) {
    if (err) { return console.log(err); }

    movies.forEach(function(movie) {
      console.log(movie);
    });
  }
}
```

Python

Avec PyMongo

```
import pymongo
URI = 'mongodb+srv://user:user@cluster0.ougec.mongodb.net/test'
client = pymongo.MongoClient(URI) # enlever le paramètre URI si connexion locale
db = client.test
```

📚 https://pymongo.readthedocs.io/en/stable/

Références

- https://fxjollois.github.io/cours-2021-2022/du-ads/python-mongodb.slides.html

Modélisation de données

- Concevez votre schéma en fonction des besoins de l'utilisateur.
- Combinez des objets en un seul document si vous les utilisez ensemble. Autrement séparez-les (mais assurez-vous de ne pas avoir besoin de joindre).
- Dupliquez les données (mais limitées) car l’espace disque est bon marché par rapport au temps de calcul.
- Faire des jointures en écriture, pas en lecture.
- Optimisez votre schéma pour la plupart des cas d'utilisation fréquents.
- Faire une agrégation complexe dans le schéma.

Exemple d'un site/blog

Le site Web a les exigences suivantes.

- Chaque message a le titre, la description et l'URL uniques.
- Chaque message peut avoir un ou plusieurs tags.
- Chaque message porte le nom de son éditeur et le nombre total de goûts.
- Chaque message a des commentaires donnés par les utilisateurs avec leur nom, message, données- temps et aime.
- Sur chaque post, il peut y avoir zéro ou plus de commentaires. Dans le schéma SGBDR, la conception pour les exigences ci-dessus aura au minimum trois tables.

Exemple - avec une BDD relationnelle

Exemple - avec une BDD NoSQL

```
{
  _id: POST_ID
  title: TITLE_OF_POST,
  description: POST_DESCRIPTION,
  by: POST_BY,
  url: URL_OF_POST,
  tags: [TAG1, TAG2, TAG3],
  likes: TOTAL_LIKES,
  // ...
}
```

Exemple - avec une BDD NoSQL (suite)

```
{
 // ...,
 comments: [
   {
    user:'COMMENT_BY',
    message: TEXT,
    dateCreated: DATE_TIME,
    like: LIKES
   },
   {
    user:'COMMENT_BY',
    message: TEXT,
    dateCreated: DATE_TIME,
    like: LIKES
   }
 ]
}
```

Création d'une base de données

`use DATABASE_NAME`

Exemple :

```
>use mydb
switched to db mydb
```

Pour retrouver la bdd actuelle :

```
>db
mydb
```

Pour lister toutes les BDD :

```
>show dbs
local   0.78125GB
test    0.23012GB
```

Pour qu'une bdd existe, il faut insérer au moins un document dedans.

```
>db.movie.insert({"name":"tutorials point"})
>show dbs
local    0.78125GB
mydb     0.23012GB
test     0.23012GB
```

MongoDB - Drop Database

```
db.dropDatabase()
```

Créer une collection

```
>use test
switched to db test
>db.createCollection("mycollection")
{ "ok" : 1 }
>
```

```
>show collections
mycollection
system.indexes
```

```
>db.createCollection("mycol", { capped : true, autoIndexID : true, size :
6142800, max : 10000 } )
{ "ok" : 1 }
>
```

N.B: mongodb crée une collection automatiuement lorsqu'on insere un document (voir plus haut)

```
> db.movie.insert({"name":"tutorials point"})
> show collections
```

Suppression de collection

```
db.COLLECTION_NAME.drop()
```

Example

First, check the available collections into your database mydb.

```
>use mydb
switched to db mydb
>show collections
mycol
mycollection
system.indexes
tutorialspoint
>
```

```
> db.mycollection.drop()
```

Types de données

- **String**: This is the most commonly used datatype to store the data. String in MongoDB must be UTF-8 valid.
- **Integer**: This type is used to store a numerical value. Integer can be 32 bit or 64 bit depending upon your server.
- **Boolean**: This type is used to store a boolean (true/ false) value.
- **Double**: This type is used to store floating point values.
- **Min/Max Keys**: This type is used to compare a value against the lowest and highest BSON elements.
- **Arrays**: This type is used to store arrays or list or multiple values into one key.
- **Timestamp**: ctimestamp. This can be handy for recording when a document has been modified or added.
- **Object**: This datatype is used for embedded documents.
- **Null**: This type is used to store a Null value.
- **Symbol**: This datatype is used identically to a string; however, it's generally reserved for languages that use a specific symbol type.
- **Date**: This datatype is used to store the current date or time in UNIX time format. You can specify your own date time by creating object of Date and passing day, month, year into it.
- **Object ID**: This datatype is used to store the document’s ID.
- **Binary data**: This datatype is used to store binary data.
- Code: This datatype is used to store JavaScript code into the document.
- **Regular expression**: This datatype is used to store regular expression.

Insertion de document

```
>db.COLLECTION_NAME.insert(document)
```

```
>db.mycol.insert({
_id: ObjectId(7df78ad8902c),
title: 'MongoDB Overview',
description: 'MongoDB is no sql database',
by: 'tutorials point',
url: 'http://www.tutorialspoint.com',
tags: ['mongodb', 'database', 'NoSQL'],
```

```
likes: 100
})
```

N.B: il est possible d'insérer plusieurs documents en une fois en passant un array à la fonction `insert()`

```
>db.post.insert([{ ... }, { ... }])
```

N.B: il est également possible d'utiliser la méthode `save`. Si aucun `_id` n'est spécifié, elle se comportera de la même façon que `insert()`

- Requêtes de documents

```
>db.COLLECTION_NAME.find()
```

Pour rendre le resultat sexy

```
>db.mycol.find().pretty()
```

Équivalences avec les RDBMS : égalité

Opération	**Syntaxe**
Egalité	`{<key>:<value>}`
Inférieur à	`{<key>:{$lt:<value>}}`
Inférieur ou égal à	`{<key>:{$lte:<value>}}`
Supérieur à	`{<key>:{$gt:<value>}}`
Supérieur ou égal à	`{<key>:{$gte:<value>}}`
Différent de	`{<key>:{$ne:<value>}}`

```
// where by = 'tutorials point'
> db.mycol.find({"by":"tutorials point"}).pretty()
> db.mycol.find({"age":{$gte: 18}}).pretty()
```

Composition : ET

Il suffit de passer plusieurs clés séparées par ","

```
>db.mycol.find({key1:value1, key2:value2}).pretty()
```

Il suffit de passer plusieurs clés séparées par ","

Composition : OU

```
>db.mycol.find(
  {
    $or: [
      {key1: value1}, {key2:value2}
    ]
  }
).pretty()
```

Ex:

```
>db.mycol.find(
  {
    $or: [
      {"by":"tutorials point"},
      {"title": "MongoDB Overview"}
    ]
  }
).pretty()
```

Composition : ET + OU

```
>db.mycol.find({"likes": {$gt:10}, $or: [{"by": "tutorials point"}, {"title": "MongoDB
Overview"}]}).pretty()
```

Indexes et performances

Création d'un index

Version 5.0

```
> db.coll.createIndex( { score: 1 } )
```

Versions antérieures

```
> db.coll.ensureIndex("tg" : 1)
```

Sur un champ embarqué (sous-item)

```
> db.coll.createIndex( { "location.state": 1 } )
```

Index composés

```
> db.coll.createIndex( { <field1>: <type>, <field2>: <type2>, ... } )
```

Lister les index

```
> db.coll.getIndexes()
```

Supprimer les index

```
> db.coll.dropIndex()
> db.coll.dropIndexes()
```

Mesurer l'utilisation des index

```
> db.coll.aggregate( [ { $indexStats: {} } ] )
```

- Voir aussi le query plan avec `explain()`, `explain("queryPlanner")` ou `explain("executionStats")`
  - Noter le ratio : (executionStats.totalDocsExamined / executionStats.nReturned)
- Voir aussi `hint()` pour forcer l'utilisation d'un index

Références

- https://www.mongodb.com/docs/manual/tutorial/measure-index-use/

Validation des données

Références

- https://www.mongodb.com/docs/manual/core/schema-validation/

Introduction

Deux types de backup

- Physiques
- Logiques

Outils

MongoDB fournit deux utilitaires pour gérer les sauvegardes logiques : Mongodump et Mongorestore.

- La commande Mongodump décharge une sauvegarde de la base de données au format ".bson", et celle-ci peut être restaurée en fournissant les instructions logiques trouvées dans le fichier de décharge aux bases de données.
- La commande Mongorestore est utilisée pour restaurer les fichiers de vidage créés par Mongodump. La création de l'index se fait après la restauration des données.

Références

- https://www.mongodb.com/basics/backup-and-restore
- https://www.mongodb.com/docs/manual/tutorial/backup-and-restore-tools/

Sauvegarde

```
$ mongodump \
      -h sample.mongodbhost.com:27017 \
      -d DATABASE_NAME \
      -u USER_NAME \
      -p SAMPLE_PASSWORD \
      -o ~/Desktop
```

Restauration

```
$ mongorestore \
    --host sample.mongohost.com \
    --port 27017 \
    --username USER_NAME \
    --password SAMPLE_PASSWORD \
    --db DATABASE_NAME
```

Bonnes pratiques

- MongoDB utilise les formats de fichiers JSON et BSON (Binary JSON).
  - Il est préférable d'utiliser BSON lors des sauvegardes et des restaurations.
  - JSON ne prend pas en charge tous les types de données que BSON prend en charge, cela peut entraîner une non-conformité des données.
- Vous n'avez pas besoin de créer explicitement une base de données MongoDB,
  - Elle sera automatiquement créée lorsque vous spécifierez une base de données à importer.
  - De même, la structure d'une collection sera créée lorsque le premier document sera inséré dans la base de données.
- Utilisez des serveurs secondaires pour les sauvegardes
  - Cela permet d'éviter de dégrader les performances du nœud primaire
- Planifiez la sauvegarde des ensembles de données autour des périodes de faible bande passante/trafic.
  - Les sauvegardes peuvent prendre beaucoup de temps, surtout si les ensembles de données sont assez volumineux.
- Utilisez une connexion en replica set lorsque vous utilisez des scripts non supervisés
  - Une connexion unique échouera si l'hôte MongoDB visé s'avère indisponible

Replication

Guide

1. Start a mongod instance
2. Start another mongod instance
3. Start Replication (rs.initiate())
4. Add a MongoDB Instance to the Replica Set (rs.add())
5. Check Replication Status (rs.status())
6. Check Replication (insert documents)

Authentication

Creation du keyfile

```
cd
openssl rand -base64 741 > mongodb.key
chmod 600 mongodb.key
```

mongodb.conf

```
replication:
  replSetName: rs0

security:
  authorization: enabled
  keyFile: /home/USERNAME/mongodb.key
```

Références

- https://www.mongodb.com/docs/manual/tutorial/deploy-replica-set/
- https://www.mongodb.com/docs/manual/tutorial/deploy-replica-set-for-testing/
- https://www.mongodb.com/docs/manual/core/replica-set-high-availability/
- https://www.mongodb.com/docs/manual/reference/method/rs.initiate/
- https://www.mongodb.com/docs/manual/reference/method/rs.add/
- https://www.digitalocean.com/community/tutorials/how-to-configure-a-mongodb-replica-set-on-ubuntu-20-04
- https://www.tutorialspoint.com/mongodb/mongodb_replication.htm

- https://www.sohamkamani.com/docker/mongo-replica-set/
- StackOverflow: MongoDB replica set with simple password authentication

Sharding

Overview

A MongoDB sharded cluster consists of the following components:

> shard: Each shard contains a subset of the sharded data. As of MongoDB 3.6, shards must be deployed as a replica set.
> mongos: The mongos acts as a query router, providing an interface between client applications and the sharded cluster. Starting in MongoDB 4.4, mongos can support hedged reads to minimize latencies.
> config servers: Config servers store metadata and configuration settings for the cluster. As of MongoDB 3.4, config servers must be deployed as a replica set (CSRS).

Références

- https://www.tutorialspoint.com/mongodb/mongodb_sharding.htm
- https://www.mongodb.com/docs/manual/core/sharded-cluster-components/

index

Mongo pour administrateurs

- Installation de mongoDB
- Configure MongoDB as a single instance deployment.
- Learn to configure a file based configuration file for Mongod.
- Activer l'authentification & les autorisations
- Mise en place d'un cluster de réplication w/ un arbitre
- Faire de commandes `rs.*`
- Différence entre `mongodump` et `mongoexport`
- Restauration d'une instance sur une autre

Ajustement du Shell Mongo

Personnalisation du shell Mongo

Configuration du fichier .mongorc.js

- Créer un fichier .mongorc.js dans le répertoire utilisateur
  - `~/.mongorc.js` sur Linux et macOS,
  - `%USERPROFILE%\.mongorc.js` sur Windows
- Editer et ajouter des variables et fonctions personnalisées

```
// activer le profilage par défaut
db.setProfilingLevel(1)
```

Modification de l'affichage et des couleurs

Vous pouvez personnaliser l'affichage du shell Mongo en utilisant des fonctions d'affichage et des codes de couleurs.

- Utiliser la fonction `print()` pour afficher du texte
- Utiliser `printjson()` pour un affichage formaté des objets JSON
- Personnaliser les couleurs avec la bibliothèque colors.js ou des codes d'échappement ANSI
- Exemple : `print("\x1b[31mHello World\x1b[0m")` pour afficher du texte en rouge

Ajout de fonctions personnalisées

- Définir des fonctions dans .mongorc.js pour automatiser les tâches récurrentes

```
// Exemple: une fonction pour rechercher les documents par nom
function findByName(collection, name) {
```

```
    return db.getCollection(collection).find({ "name": name });
}
```

- Utiliser les fonctions personnalisées dans le shell Mongo

```
findByName("users", "John");
```

Utilisation de scripts pour automatiser les tâches

Exécution de scripts JavaScript

- Utiliser `load()` pour exécuter un script JS depuis le shell Mongo
  - Permet d'exécuter des fichiers JavaScript directement dans le shell Mongo
  - Facilite l'automatisation des tâches répétitives et l'exécution de scripts complexes

```
// File: script.js

var users = [
  { name: "Alice", age: 30 },
  { name: "Bob", age: 25 },
  { name: "Charlie", age: 35 }
];

users.forEach(function(user) {
  db.users.insert(user);
});

print("Utilisateurs insérés :");
db.users.find().forEach(printjson);
```

```
load("script.js")
```

Chargement de scripts à partir de fichiers externes

- Inclure des scripts JS dans le fichier `.mongorc.js` avec `load()`
- Exemple : `load("/chemin/vers/script.js")` pour charger un script externe

Trucs et astuces pour une utilisation efficace du shell Mongo

Raccourcis clavier

- Utiliser les flèches haut/bas pour naviguer dans l'historique des commandes
- Utiliser Tab pour compléter automatiquement les noms de collections et de commandes

Commandes couramment utilisées

- `show dbs` pour lister les bases de données
- `use <nom_db>` pour sélectionner une base de données
- `show collections` pour afficher les collections de la base de données sélectionnée
- `db.<collection>.find()` pour afficher les documents d'une collection
- `db.<collection>.find().pretty()` pour un affichage formaté des documents

Manipulation efficace des opérations CRUD

Insertions

Insertion de documents individuels et multiples

- Utiliser `insertOne()` pour insérer un document individuel
- Utiliser `insertMany()` pour insérer plusieurs documents à la fois
- Exemple : `db.collection.insertOne({ field1: "value1", field2: "value2" })`

Meilleures pratiques pour l'insertion de données

- Valider les données avant l'insertion
- Utiliser des identifiants uniques et significatifs pour le champ `_id`
- Insérer des documents de taille similaire pour éviter la fragmentation

Requêtes

Utilisation d'opérateurs avancés de requête

- `$gt`, `$gte`, `$lt`, `$lte` pour les comparaisons numériques
- `$in`, `$nin` pour vérifier si un champ est dans une liste de valeurs
- `$regex` pour les expressions régulières
- Exemple : `db.collection.find({ age: { $gte: 18, $lt: 65 } })`

Filtrage, tri et pagination des résultats

- Utiliser `find()` pour filtrer les documents
- Utiliser `sort()` pour trier les résultats (1 pour croissant, -1 pour décroissant)
- Utiliser `skip()` et limit() pour la pagination
- Exemple : `db.collection.find({}).sort({ age: 1 }).skip(10).limit(10)`

Projection de champs

- Utiliser la projection pour limiter les champs renvoyés

- Valeur `1` pour inclure un champ, `0` pour l'exclure
- Exemple : `db.collection.find({}, { field1: 1, field2: 0 })`

Mises à jour

Mise à jour de documents individuels et multiples

- Utiliser `updateOne()` pour mettre à jour un document individuel
- Utiliser `updateMany()` pour mettre à jour plusieurs documents à la fois
- Exemple : `db.collection.updateOne({ _id: id }, { $set: { field1: "newValue" } })`

Utilisation d'opérateurs de mise à jour avancés

- `$set`, `$unset` pour ajouter ou supprimer des champs
- `$inc`, `$mul`, `$min`, `$max` pour modifier les valeurs numériques
- `$push`, `$pop`, `$addToSet`, `$pull` pour manipuler des tableaux
- Exemple : `db.collection.updateOne({ _id: id }, { $inc: { counter: 1 } })`

Mises à jour atomiques

- Utiliser `findAndModify()` pour effectuer une mise à jour atomique
- Les opérations sont effectuées en une seule étape, sans risque de conflits
- Exemple : `db.collection.findAndModify({ query: { _id: id }, update: { $set: { field1: "newValue" } } })`

Suppressions

Suppression de documents individuels et multiples

- Utiliser `deleteOne()` pour supprimer un document individuel
- Utiliser `deleteMany()` pour supprimer plusieurs documents à la fois
- Exemple : `db.collection.deleteOne({ _id: id })`

Meilleures pratiques pour la suppression de données

- Supprimer les données en fonction des besoins métier (date d'expiration, archivage, etc.)
- Utiliser des index pour accélérer les suppressions

- Planifier les suppressions pendant les périodes de faible charge pour minimiser l'impact sur les performances
- Utiliser les index TTL (Time-To-Live) pour supprimer automatiquement les documents après un certain temps

Commandes d'administration utiles

Création, modification et suppression d'utilisateurs

Création d'utilisateurs

- Utiliser la commande `db.createUser()`
- Exemple : `db.createUser({ user: "techy", pwd: "password", roles: ["readWrite", "dbAdmin"] })`

Modification d'utilisateurs

- Utiliser la commande `db.updateUser()`
- Exemple : `db.updateUser("techy", { roles: ["readWrite", "dbAdmin", "clusterAdmin"] })`

Suppression d'utilisateurs

- Utiliser la commande `db.dropUser()`
- Exemple : `db.dropUser("techy")`

Attribution et retrait de rôles

Attribution de rôles

FIXME: expliquer

- Inclure les rôles lors de la création d'utilisateurs
- Mettre à jour les rôles d'un utilisateur existant

Retrait de rôles

- Mettre à jour les rôles d'un utilisateur avec `db.updateUser()`

Opérations de maintenance

Compactage de collections

- Utiliser la commande `db.runCommand({ compact: "collectionName" })`

- Exemple : `db.runCommand({ compact: "products" })`
- À noter : opération bloquante pour la collection concernée

Vérification de l'intégrité de la base de données

- Utiliser la commande `db.runCommand({ validate: "collectionName" })`
- Exemple : `db.runCommand({ validate: "products" })`
- Vérifier les erreurs et les avertissements dans le résultat

Surveillance et diagnostic

Utilisation de la commande db.stats()

- Obtenir des statistiques sur l'utilisation de la base de données
- Exemple : `db.stats()`
- Analyser les résultats pour déterminer l'utilisation de la mémoire, de l'espace disque, etc.

FIXME: expliquer

Vérification de l'état des index et des performances

- Utiliser la commande `db.collection.getIndexes()`
- Exemple : `db.products.getIndexes()`
- Examiner les index pour déterminer leur utilisation et leur impact sur les performances
- Utiliser la commande `db.collection.explain("executionStats").find(query)`
- Exemple : `db.products.explain("executionStats").find({ category: "electronics" })`
- Analyser les statistiques d'exécution pour optimiser les requêtes et les index

Outils de supervision intégrés

Introduction à mongotop

- Outil de supervision en ligne de commande
  - mongotop est un outil intégré à MongoDB, accessible via la ligne de commande
  - Il s'exécute directement sur l'ordinateur hébergeant le serveur de base de données
  - Aucune installation supplémentaire n'est requise, car mongotop est inclus dans le package MongoDB
- Surveille les opérations de lecture et d'écriture par collection
  - mongotop surveille en temps réel les opérations effectuées sur chaque collection de la base de données
  - Il donne un aperçu du temps passé en lecture et en écriture pour chaque collection
  - Les informations sont affichées sous forme d'un tableau avec des colonnes pour les lectures, les écritures et le temps total
- Affiche le temps passé sur chaque opération
  - mongotop affiche le temps moyen passé en millisecondes pour chaque opération de lecture et d'écriture par collection
  - Les résultats sont mis à jour en temps réel à intervalles réguliers (par défaut, toutes les secondes)
- Utile pour identifier les collections les plus sollicitées
  - mongotop aide à détecter les collections qui sont fréquemment sollicitées
  - Les collections ayant des temps de lecture et d'écriture élevés peuvent nécessiter une optimisation (par exemple, l'ajout d'index)

Exemple:

```
$ mongotop --host localhost:27017 --username myUser --password myPassword
        ns    total    read    write
test.coll1      0ms     0ms      0ms
test.coll2      8ms     8ms      0ms
test.coll3     15ms     0ms     15ms
```

Utilisation de mongotop pour surveiller les opérations

- Paramètres optionnels : intervalle de rafraîchissement (en ms) et authentification
  - Intervalle de rafraîchissement : mongotop
  - Authentification : mongotop -u -p --authenticationDatabase
  - Exemple : mongotop 1000 -u admin -p mypassword --authenticationDatabase admin

- Interprétation des résultats : temps de lecture (read), écriture (write) et total par collection :
  - Les résultats de mongotop sont présentés sous forme de tableau avec les colonnes suivantes : ns, total, read, write.
  - ns : le nom de la collection (par exemple, mydb.mycollection)
  - total : le temps total (en ms) passé sur les opérations de lecture et d'écriture pour cette collection
  - read : le temps total (en ms) passé sur les opérations de lecture pour cette collection
  - write : le temps total (en ms) passé sur les opérations d'écriture pour cette collection

- Identifier les collections à optimiser
  - Analyser les temps de lecture et d'écriture
  - Repérer les collections avec des temps élevés
  - Exemple : dans la sortie ci-dessus, la collection "orders" présente des temps de lecture et d'écriture plus élevés que les autres collections

Introduction à mongostat

- Outil de supervision en ligne de commande
  - Utilise la CLI pour interagir avec MongoDB
  - Commande : mongostat
- Surveille les statistiques globales de la base de données
  - Opérations de lecture, écriture, et mise à jour par seconde
  - Utilisation de la mémoire

    - Taux de lock
    - Nombre de connexions
- Affiche les informations sur les opérations, l'utilisation de la mémoire, la réplication, etc.
    - "insert" : nombre d'opérations d'insertion par seconde
    - "query" : nombre de requêtes par seconde
    - "update" : nombre d'opérations de mise à jour par seconde
    - "delete" : nombre d'opérations de suppression par seconde
    - "resident" (res) : mémoire résidente utilisée (en Mo)
    - "virtual" (virt) : mémoire virtuelle utilisée (en Mo)
    - "netIn" et "netOut" : taux d'entrée/sortie réseau (en Ko/s)
    - "conn" : nombre de connexions actives
    - "repl" : état de la réplication (PRIMARY, SECONDARY, etc.)
- Aide à détecter les problèmes de performance et de configuration
    - Identifier les goulots d'étranglement (bottlenecks) ou les ressources saturées
    - Surveiller la réplication et l'état du cluster

Exemple:

```
$ mongostat
insert  query update delete getmore command dirty  used flushes vsize   res qrw arw net_in
net_out conn  time
  *0     *0     *0     *0       0     1|0  0.0%  0.1%       0 1.44G 13.0M 0|0 1|0  62b    125b   10
12:34:56
```

Utilisation de mongostat pour surveiller les statistiques de la base de données

- Lancer mongostat depuis la CLI avec la commande mongostat
    - Exemple : mongostat
    - Affiche les statistiques en temps réel avec un intervalle de rafraîchissement par défaut de 1 seconde
- Paramètres optionnels : intervalle de rafraîchissement (en s) et authentification
    - Exemple : mongostat --authenticationDatabase admin -u yourUsername -p yourPassword --host yourHost 5

    - Ici, on spécifie un intervalle de 5 secondes et on fournit les informations d'authentification
    - Exemple : mongostat 1 pour un intervalle d'1 seconde
- Interprétation des résultats : opérations par seconde, utilisation de la mémoire, nombre de connexions, etc.
    - insert, query, update, delete : opérations de la base de données par seconde
    - command : nombre de commandes exécutées par seconde
    - dirty, used : pourcentage de la mémoire utilisée par les données modifiées et par les données en général
    - vsize, res : taille de la mémoire virtuelle et de la mémoire résidente utilisées par le processus mongod
    - netIn, netOut : débit réseau entrant et sortant en octets par seconde
    - conn : nombre de connexions actives à la base de données
- Analyser les indicateurs pour détecter les problèmes et optimiser la base de données
    - Surveiller les opérations avec un taux élevé pour identifier les collections très sollicitées
    - Vérifier l'utilisation de la mémoire pour détecter les problèmes de gestion de la mémoire
    - Surveiller le débit réseau pour identifier les goulots d'étranglement liés au réseau
    - Examiner le nombre de connexions pour s'assurer que la base de données n'est pas surchargée

Mémoire et performances des E/S

Mémoire et caches dans MongoDB

Architecture de la mémoire MongoDB

- Cache de requêtes
  - Stocke les plans d'exécution des requêtes récentes
  - Améliore les performances des requêtes répétées
  - Exemple : Utiliser db.collection.find(query).explain("executionStats") pour voir le plan d'exécution
- Journal
  - Stocke les opérations de lecture et d'écriture
  - Assure la durabilité des données
  - Exemple : Configurer la fréquence de journalisation avec `--journalCommitInterval`
- Cache des données
  - Stocke les données fréquemment utilisées en mémoire
  - Permet un accès rapide aux données
  - Exemple : Utiliser `db.serverStatus().wiredTiger.cache` pour vérifier les statistiques du cache

Importance de la gestion de la mémoire

- Amélioration des performances
  - Les données en cache réduisent les accès disque
  - Diminution des temps de réponse
  - Exemple : Configurer la taille du cache avec `storage.wiredTiger.engineConfig.cacheSizeGB`
- Éviter les problèmes de contention
  - Contention de la mémoire : concurrence pour l'accès à la mémoire
  - Peut causer des problèmes de performance
  - Exemple : Surveiller la contention avec `db.serverStatus().globalLock`

Gestion de la mémoire virtuelle

Mémoire virtuelle : définition

- Espace disque pour les données en mémoire
- Extension de la mémoire physique
- Comprend la mémoire RAM et l'espace disque

Rôle de la mémoire virtuelle dans MongoDB

- Stockage des données
  - Utilisation de la mémoire RAM pour accélérer l'accès aux données
- Gestion du cache
  - Conserver les données fréquemment utilisées en mémoire pour optimiser les performances

Suivi de la mémoire virtuelle

- Commande `db.serverStatus()`
  - Exemple de commande shell : mongo --eval "db.serverStatus()"
- Champ `mem.virtual`
  - Indique la quantité de mémoire virtuelle utilisée

```
{
  "mem": {
    "virtual": 2048
  }
}
```

Optimisation de la mémoire virtuelle

- Réglage du système d'exploitation
  - Ajuster les paramètres de mémoire virtuelle du système d'exploitation (ex. Linux sysctl)
  - Exemple de configuration Linux :

```
# /etc/sysctl.conf
vm.swappiness = 1
```

- Limitation de la mémoire allouée
  - Restreindre la quantité de mémoire virtuelle utilisée par MongoDB
  - Exemple de configuration MongoDB :

```
# /etc/mongod.conf
processManagement:
  fork: true
systemLog:
  destination: file
  path: "/var/log/mongodb/mongod.log"
storage:
  dbPath: "/var/lib/mongo"
net:
  bindIp: "127.0.0.1"
  port: 27017
setParameter:
  wiredTigerCacheSizeGB: 4
```

Mesure des performances d'E/S

Importance des performances d'E/S

- Lecture/écriture des données
  - Crucial pour les opérations courantes
  - Impact direct sur l'expérience utilisateur
- Impacts sur la vitesse et la stabilité
  - Temps de réponse réduit
  - Moins de risques de blocage ou de crash

Outils pour mesurer les performances d'E/S

- Commandes MongoDB :
  - `db.stats()` : statistiques globales de la base de données
  - `db.<collection>.stats()` : statistiques d'une collection spécifique
- Outils système : `iostat`, `vmstat`
  - `iostat` : statistiques d'utilisation des disques Exemple : `iostat -x 1`

- `vmstat` : statistiques de la mémoire virtuelle Exemple : `vmstat 1`

Analyse des indicateurs de performance

- Taux d'E/S
  - Nombre d'opérations d'entrée/sortie par seconde
  - Indicateur clé pour évaluer les performances
- Latence
  - Temps écoulé entre l'émission d'une requête et la réception de la réponse
  - Plus la latence est faible, meilleures sont les performances
- Taux d'erreurs
  - Proportion d'opérations d'E/S ayant échoué
  - Un taux d'erreurs élevé peut indiquer des problèmes matériels ou de configuration

Optimisation des performances d'E/S

Techniques d'optimisation

- Répartition des données (sharding)
  - Distribue les données sur plusieurs serveurs
  - Équilibre la charge et réduit la contention
- Indexation appropriée
  - Crée des index pour accélérer les requêtes fréquentes
  - Évite les scans de collection complets
- Compression des données
  - Réduit l'espace disque et améliore les performances d'E/S
  - Configurable avec WiredTiger

Configuration du matériel

- Disques SSD
  - Performances d'E/S supérieures aux disques durs traditionnels
  - Faible latence et temps d'accès rapides

- RAID
  - Combine plusieurs disques pour améliorer les performances et la tolérance aux pannes
  - RAID 10 recommandé pour MongoDB
- Mémoire suffisante
  - Permet de stocker davantage de données en cache
  - Réduit les accès disque

Réglages MongoDB

- Moteur de stockage WiredTiger
  - Utilisé par défaut depuis la version 3.2
  - Performances supérieures à MMAPv1
  - Gère la compression des données et l'isolation des transactions
  - Activer WiredTiger : `--storageEngine wiredTiger`
- `storage.wiredTiger.engineConfig.cacheSizeGB`
  - Configure la taille du cache WiredTiger
  - Ajuster en fonction de la taille de la mémoire
  - Exemple de configuration : `--wiredTigerCacheSizeGB 8`

📚 Percona Blog: MMAPv1 VS WiredTiger

Requêtes sous-optimales et profiling

Comprendre les requêtes sous-optimales

Requêtes sous-optimales

- Définition : requêtes lentes ou consommant trop de ressources
- Requêtes avec des scans de collection entière (table scans)
- Requêtes avec des jointures mal optimisées
- Requêtes avec des filtres, des tris ou des agrégations inefficaces
- Exemple de requête lente sans index : db.collection.find({age: {$gte: 18}})

Impact sur les performances globales de la base de données

- Ralentissement de l'exécution des autres requêtes
- Augmentation de la charge CPU et de l'utilisation de la mémoire
- Diminution de la capacité à répondre aux demandes en temps réel

Nécessité d'identifier et d'optimiser ces requêtes

- Amélioration des performances globales de la base de données
- Réduction de la consommation de ressources (CPU, mémoire, disque)
- Meilleure expérience pour les utilisateurs finaux

Activer et configurer le profileur de requêtes

Activation du profileur :

- Utilisez la méthode `db.setProfilingLevel(level, options)` pour activer le profileur
- `level` : niveau de profilage souhaité
- `options` : paramètres supplémentaires, tels que slowms

Niveaux de profilage

- `0` : désactivé, aucune requête n'est enregistrée
- `1` : activé pour les requêtes lentes, seulement les requêtes dépassant le seuil slowms sont enregistrées

- `2` : activé pour toutes les requêtes, toutes les requêtes sont enregistrées

Options : seuil de durée en ms pour le niveau 1

- slowms : seuil de durée en millisecondes pour déterminer si une requête est considérée comme lente
- Exemple : db.setProfilingLevel(1, {slowms: 200})

Exemple

```
> db.setProfilingLevel(1, {slowms: 100})
{ "was" : 0, "slowms" : 100, "sampleRate" : 1, "ok" : 1 }
```

📚 https://www.mongodb.com/docs/manual/tutorial/manage-the-database-profiler/

📚 https://www.mongodb.com/docs/manual/reference/method/db.setProfilingLevel/

📚 https://studio3t.com/knowledge-base/articles/mongodb-query-performance/

Analyser les résultats du profileur

Récupération des données

- Commande : `db.system.profile.find().pretty()`
- Affiche les entrées du profileur dans un format lisible

Informations clés : opération, durée, index utilisés, nombre de documents examinés

- Opération : type d'opération (ex : query, update, insert, remove)
- Durée : temps d'exécution de l'opération en millisecondes
- Index utilisés : index exploités lors de l'exécution de la requête
- Nombre de documents examinés : quantité de documents traités pour répondre à la requête

Exemple

```
{
   "op" : "query",
   "ns" : "testDB.products",
   "query" : { "price" : { "$gte" : 100 } },
   "cursorid" : NumberLong("4512952734067705982"),
   "keysExamined" : 0,
```

```
    "docsExamined" : 2000,
    "nreturned" : 50,
    "responseLength" : 10234,
    "millis" : 120,
    "planSummary" : "COLLSCAN",
    "execStats" : { ... },
    "ts" : ISODate("2023-04-17T12:00:00.000Z"),
    "client" : "192.168.0.100",
    "allUsers" : [ ],
    "user" : ""
}
```

Analyse des données pour déterminer les requêtes sous-optimales

- Rechercher les entrées avec une longue durée (ex : > 100 ms) `db.system.profile.find({ "millis": { "$gt": 100 } }).pretty()`
- Identifier les requêtes sans index (ex : `"planSummary" : "COLLSCAN"` au lieu de `"IDHACK"`) `db.system.profile.find({ "planSummary": "COLLSCAN" }).pretty()`
- Requêtes avec un grand nombre de documents examinés `db.system.profile.find({ "docsExamined": { "$gt": 1000 } }).pretty()`
- Requete combinée `db.system.profile.find({ "millis": { "$gt": 100 }, "planSummary": "COLLSCAN" }).pretty()`

Exemple (pour la requête ci-dessus)

- elle n'utilise pas d'index
- elle examine 2000 documents
- elle prend un temps d'exécution de 120 ms,
- ... tout cela indique une requête sous-optimale!

Optimisation des requêtes

Utilisation d'index appropriés pour accélérer les requêtes

- Création d'index : `db.collection.createIndex(keys, options)`
- Exemple d'index simple : `db.users.createIndex({age: 1})`
- Exemple d'index composé : `db.users.createIndex({age: 1, city: 1})`
- Importance de choisir les bons index pour les requêtes fréquentes
- Surveiller les performances des index avec `db.collection.aggregate([{$indexStats: {}}])`

Réécriture des requêtes pour améliorer les performances

- Utiliser des opérateurs efficaces, tels que `$in` et `$elemMatch`
- Exemple de requête optimisée avec `$in` : `db.users.find({city: {$in: ["Paris", "London"]}})`
- Préférer l'usage de `$and` au lieu de `$or` lorsque cela est possible
- Exemple de requête optimisée avec `$and` : `db.users.find({$and: [{age: {$gt: 25}}, {city: "Paris"}]})`
- Éviter les opérations de tri coûteuses en utilisant des index

Limitation des champs renvoyés pour réduire la charge de la bande passante

- Utiliser le second argument de la méthode find pour spécifier les champs à renvoyer
- Exemple : `db.users.find({age: {$gt: 25}}, {name: 1, city: 1, _id: 0})`
- Utiliser `1` pour inclure un champ, et `0` pour l'exclure (sauf pour `_id` qui est inclus par défaut)
- Renvoyer uniquement les données nécessaires pour réduire la charge sur le réseau et le serveur

Moteurs de stockage

Présentation des moteurs de stockage

Deux moteurs de stockage principaux : MMAPv1 et WiredTiger

- MMAPv1 : moteur de stockage par défaut avant MongoDB 3.0
- WiredTiger : moteur de stockage par défaut depuis MongoDB 3.2

Importance du choix du moteur de stockage pour les performances et les fonctionnalités

- Impacts sur les temps de réponse des requêtes
- Impacts sur les fonctionnalités supportées (transactions, compression des données)
- Considérations pour les déploiements existants et les migrations

Vérifier le moteur de stockage utilisé

Pour vérifier le moteur de stockage actuel :

```
use admin;
db.runCommand({ serverStatus: 1 });
// ou bien
db.serverStatus().storageEngine;
```

Exemple de sortie pour WiredTiger :

```
"storageEngine" : {
    "name" : "wiredTiger",
    "supportsCommittedReads" : true,
    "persistent" : true
}
```

Exemple de sortie pour MMAPv1 :

```
"storageEngine" : {
    "name" : "mmapv1",
    "supportsCommittedReads" : false,
    "persistent" : true
}
```

MMAPv1 : caractéristiques et cas d'utilisation

MMAPv1 : premier moteur de stockage développé pour MongoDB

- Moteur de stockage par défaut avant MongoDB 3.0
- Remplacé par WiredTiger à partir de MongoDB 3.2

Architecture basée sur les fichiers mmap

- Utilise la mémoire mappée sur des fichiers pour lire et écrire les données
- Le système d'exploitation gère le cache et les entrées/sorties disque
- Les fichiers de données ont l'extension .mmap

Verrouillage au niveau de la collection

- MMAPv1 gère les verrous de lecture et d'écriture au niveau de la collection
- Accepte moins de concurrence que le verrouillage au niveau du document (WiredTiger)
- Exemple : Si une opération d'écriture est en cours sur une collection, les autres opérations d'écriture doivent attendre la fin de la première opération

Compression des données : non disponible

- MMAPv1 ne prend pas en charge la compression des données stockées sur le disque
- Les données sont stockées telles quelles, sans compression

Transactions : non supportées

- MMAPv1 ne prend pas en charge les transactions multi-documents
- Les opérations atomiques sont supportées seulement au niveau du document

Cas d'utilisation : applications nécessitant une compatibilité avec les anciennes versions de MongoDB

- Exemple : Migration d'une base de données MongoDB 2.6 vers une version plus récente sans changer de moteur de stockage
- Exemple : Applications ayant des contraintes de compatibilité avec des bibliothèques ou des pilotes spécifiques à MMAPv1

Exemple de commande pour démarrer MongoDB avec le moteur de stockage MMAPv1 :

```
mongod --dbpath /data/db --storageEngine mmapv1
```

WiredTiger : caractéristiques et cas d'utilisation

Moteur de stockage par défaut depuis MongoDB 3.2

- Pour vérifier le moteur de stockage utilisé : db.serverStatus().storageEngine
- Pour configurer WiredTiger au démarrage de MongoDB : mongod --storageEngine wiredTiger

Utilise des fichiers de données avec des extensions wt

- Les fichiers sont stockés dans le répertoire de données (par défaut : /data/db)
- Exemple de fichier : collection-0--123456789.wt

Verrouillage au niveau du document

- Permet des opérations de lecture et d'écriture concurrentes sur différents documents
- Améliore les performances en réduisant la contention entre les opérations

Compression des données : disponible (Snappy, zlib, zstd)

- Compression par défaut : Snappy (équilibré entre vitesse et taux de compression)
- Configurer la compression pour une collection :

```
db.createCollection("ma_collection", {
   storageEngine: {
      wiredTiger: {
         configString: "block_compressor=zlib"
      }
   }
});
```

Transactions : supportées depuis MongoDB 4.0

```
session = db.getMongo().startSession();
session.startTransaction();
```

```
try {
    session.getDatabase("test").getCollection("ma_collection").insertOne({x: 1});
    session.getDatabase("test").getCollection("ma_collection").updateOne({x: 1}, {$set: {y:
2}});
    session.commitTransaction();
} catch (error) {
    session.abortTransaction();
    print("Transaction échouée :", error);
} finally {
    session.endSession();
}
```

Cas d'utilisation

- Applications nécessitant de meilleures performances, une compression des données et des transactions
- Applications à fort trafic avec des opérations de lecture et d'écriture concurrentes
- Applications nécessitant de réduire l'espace disque utilisé grâce à la compression
- Applications nécessitant d'assurer la cohérence des données à travers plusieurs opérations avec des transactions

Choisir le bon moteur de stockage

Évaluer les besoins de l'application

- Identifier les besoins en termes de performances : lecture, écriture, mises à jour
- Déterminer si l'application nécessite des transactions multi-documents
- Évaluer le besoin de compression des données pour économiser de l'espace disque

Prendre en compte la compatibilité avec les versions précédentes de MongoDB

- MMAPv1 pour les applications utilisant des versions antérieures à MongoDB 3.0
- WiredTiger pour les applications utilisant MongoDB 3.2 ou ultérieure

Comparer les performances des deux moteurs avec des charges de travail réalistes

- Créer des scénarios de test représentatifs des opérations de l'application
- Exemple de commande pour comparer les performances en lecture : `db.collection.find(query).explain("executionStats")`
- Comparer les temps d'exécution, les ressources utilisées et l'utilisation de la mémoire

Changer de moteur de stockage : utiliser mongodump et mongorestore avec l'option --storageEngine

- Sauvegarder les données avec mongodump : `mongodump --out /path/to/backup`
- Arrêter le serveur MongoDB : `sudo systemctl stop mongod`
- Modifier le fichier de configuration `/etc/mongod.conf` pour changer le moteur de stockage (par exemple, passer de MMAPv1 à WiredTiger)

```
storage:
  engine: wiredTiger
```

- Redémarrer le serveur MongoDB : `sudo systemctl start mongod`
- Restaurer les données avec mongorestore et l'option `--storageEngine` :

```
mongorestore --storageEngine wiredTiger /path/to/backup
```

Les Explainable objects

Introduction aux Explainable objects

Présentation du concept d'Explainable objects

- Outils pour analyser et comprendre le fonctionnement des requêtes
- Aide à l'optimisation des performances de la base de données

Objectif : analyser et optimiser les performances des requêtes

- Détection des goulots d'étranglement et des requêtes coûteuses
- Mise en place de solutions pour améliorer les performances

Fonctionnement : obtenir des informations détaillées sur le plan d'exécution de requêtes

- Analyse du plan d'exécution généré par MongoDB pour chaque requête
- Informations sur les index utilisés, les documents scannés, etc.

Méthode : utilisation de la méthode .explain() dans la CLI MongoDB

- Utilisation directe sur les requêtes, par exemple : `db.collection.find({...}).explain()`
- Résultats sous forme d'un document JSON détaillé contenant
  - le plan d'exécution de la requête,
  - les index utilisés,
  - le nombre de documents scannés,
  - le temps d'exécution, etc.

Exemple

```
// Exemple de requête
db.users.find({age: {$gte: 18}})

// Utilisation de la méthode .explain()
db.users.find({age: {$gte: 18}}).explain()
```

Utilisation des Explainable objects pour analyser les requêtes

Utilisation de la méthode .explain() sur les requêtes

- Permet d'obtenir des informations détaillées sur le plan d'exécution
- Aide à identifier les problèmes de performance et les index manquants ou mal utilisés

Exemple de code : db.collection.find({...}).explain()

```
db.products.find({category: "Electronics", price: {$gte: 100}}).explain()
```

Résultats : informations sur les index utilisés, nombre de documents scannés, temps d'exécution, etc.

- `"queryPlanner"` : informations sur le plan d'exécution et les index utilisés
- `"executionStats"` : statistiques détaillées sur le temps d'exécution, les documents scannés, etc.
- `"serverInfo"` : informations sur le serveur et la version de MongoDB

Analyse des résultats pour détecter les problèmes de performances

- Identifier les index non utilisés ou inadaptés
- Repérer les étapes coûteuses du plan d'exécution
- Exemple : si `"totalDocsExamined"` est élevé, cela peut indiquer un problème d'indexation

Exemple

```
var explainResult = db.products.find({category: "Electronics", price: {$gte:
100}}).explain();
print("Index utilisé : ", explainResult.queryPlanner.winningPlan.inputStage.indexName);
print("Documents examinés : ", explainResult.executionStats.totalDocsExamined);
print("Temps d'exécution (ms) : ", explainResult.executionStats.executionTimeMillis);
```

Comprendre les plans d'exécution

Importance de comprendre les plans d'exécution pour optimiser les requêtes

- Augmenter les performances des requêtes
- Réduire le temps de réponse
- Diminuer l'utilisation des ressources système

Structure du plan d'exécution : étapes, coût, index utilisés, etc.

- `winningPlan:` plan d'exécution choisi par MongoDB
- `rejectedPlans:` autres plans d'exécution envisagés mais rejetés
- `inputStage:` étape initiale de la requête
- `stage:` type d'opération (e.g. IXSCAN, FETCH, SORT)
- `indexName:` nom de l'index utilisé
- `nReturned:` nombre de documents retournés
- `executionTimeMillis:` temps d'exécution en millisecondes

Identification des parties coûteuses du plan d'exécution

- Analyser executionTimeMillis pour détecter les étapes lentes
- Examiner nReturned pour identifier les requêtes inefficaces
- Vérifier inputStage et les opérations stage pour repérer les optimisations potentielles

Utilisation des informations pour améliorer les performances de la requête

- Adapter les index en fonction des étapes coûteuses
- Modifier la requête pour utiliser les index optimisés
- Comparer les plans d'exécution avant et après optimisation

Exemple

Exécuter une requête avec .explain() pour afficher le plan d'exécution :

```
> db.collection.find({ field1: value1, field2: value2 }).explain()
{
```

```
  "queryPlanner": {
    "winningPlan": {
      "stage": "FETCH",
      "inputStage": {
        "stage": "IXSCAN",
        "keyPattern": { "field1": 1 },
        "indexName": "field1_1",
        ...
      },
      ...
    },
    "rejectedPlans": [...],
    ...
  },
  "executionStats": {
    "nReturned": 10,
    "executionTimeMillis": 120,
    ...
  },
  ...
}
```

Créer un nouvel index pour améliorer les performances :

```
db.collection.createIndex({ field1: 1, field2: 1 })
```

Réexécuter la requête avec .explain() pour vérifier l'amélioration des performances :

```
db.collection.find({ field1: value1, field2: value2 }).explain()
```

MongoDB Cloud Manager et Munin

Présentation de MongoDB Cloud Manager

Service en ligne de gestion et de monitoring de MongoDB

Surveillance en temps réel des performances et des ressources

Alertes personnalisables pour les événements importants

Sauvegardes automatisées et restaurations point-in-time

Gestion des déploiements de réplication et de sharding

Configuration et utilisation de MongoDB Cloud Manager

Création d'un compte et connexion à MongoDB Cloud Manager

Ajout d'une organisation et d'un projet

Installation de l'agent Cloud Manager sur les serveurs MongoDB

- Téléchargement de l'agent et obtention de l'API key
- Configuration de l'agent avec l'API key et l'URL du projet
- Démarrage de l'agent

Visualisation des données de monitoring dans l'interface Cloud Manager

- Métriques clés : opérations, latence, utilisation du disque, etc.
- Graphiques personnalisables et tableaux de bord

Configuration des alertes et des notifications

Introduction à Munin

Outil open-source de surveillance des ressources système

Fonctionne avec une architecture maître/nœud

Collecte et affiche des données sous forme de graphiques

Large éventail de plugins, y compris pour MongoDB

Facilité d'extension avec des plugins personnalisés

Installation et configuration de Munin pour MongoDB

Installation de Munin et Munin-node sur les serveurs concernés

Configuration du fichier munin.conf pour définir les nœuds

Installation du plugin MongoDB pour Munin

- Téléchargement du plugin depuis le référentiel GitHub
- Copie du plugin dans le répertoire des plugins Munin
- Configuration du plugin dans le fichier plugin-conf.d/mongodb

Redémarrage de Munin-node pour appliquer les modifications

Visualisation des graphiques de monitoring MongoDB dans Munin

Travaux pratiques : Mise en place et utilisation de MongoDB Cloud Manager et Munin

Configurer et utiliser MongoDB Cloud Manager pour surveiller une base de données MongoDB

- Installer l'agent Cloud Manager
- Configurer les alertes et les notifications

Installer et configurer Munin pour surveiller MongoDB

- Installer Munin et Munin-node
- Configurer le plugin MongoDB pour Munin
- Analyser les graphiques de monitoring MongoDB dans Munin

Gestion et fonctionnement des index

Création d'index

Utiliser la commande createIndex pour créer un index

- Créer un index simple
  - Exemple d'index simple : `db.collection.createIndex({ champ: 1 })`
  - champ représente le nom du champ à indexer
  - 1 signifie un ordre de tri croissant

Préciser l'ordre de tri

- Définir l'ordre de tri avec 1 (croissant) ou -1 (décroissant)
- Exemple d'index composé : `db.collection.createIndex({ champ1: 1, champ2: -1 })`
  - L'index sera trié d'abord par `champ1` en ordre croissant, puis par `champ2` en ordre décroissant

Créer un index en arrière-plan

- Permet d'éviter de bloquer les opérations sur la collection pendant la construction de l'index
- Utiliser l'option `{ background: true }`
- Exemple : `db.collection.createIndex({ champ: 1 }, { background: true })`

Suppression d'index

Supprimer un index

- Utiliser la commande `db.collection.dropIndex(...)`
  - Exemple de commande : `db.collection.dropIndex("champ_1")`

Supprimer tous les index d'une collection

- Utiliser la commande `db.collection.dropIndexes()`
  - Exemple de commande : `db.maCollection.dropIndexes()`

Exemple

```
// Créer un index sur le champ "age" de la collection "users"
db.users.createIndex({ age: 1 })

// Vérifier que l'index a été créé
db.users.getIndexes()

// Supprimer l'index sur le champ "age"
db.users.dropIndex("age_1")

// Vérifier que l'index a été supprimé
db.users.getIndexes()

// Supprimer tous les index de la collection "users" (sauf l'index par défaut sur le champ "_id")
db.users.dropIndexes()
```

Analyse des index existants

Lister les index d'une collection

- Utiliser la commande : `db.maCollection.getIndexes()`
- Permet d'afficher tous les index de la collection et leurs propriétés

Identifier les index les plus utilisés

- Utiliser la commande : `db.maCollection.aggregate([ { $indexStats: {} } ])`
- Permet d'obtenir des statistiques sur l'utilisation des index pour optimiser les performances

Exemple d'analyse des index existants

```
// Créer une collection avec des index :
db.maCollection.insertMany([
  { champ1: "valeur1", champ2: "valeur2" },
  { champ1: "valeur3", champ2: "valeur4" }
])
db.maCollection.createIndex({ champ1: 1 })
db.maCollection.createIndex({ champ2: 1 })

//Lister les index de la collection :
db.maCollection.getIndexes()
```

Résultat :

```
[
  {
    "v": 2,
    "key": {
      "_id": 1
    },
    "name": "_id_"
  },
  {
    "v": 2,
    "key": {
      "champ1": 1
    },
    "name": "champ1_1"
  },
  {
    "v": 2,
    "key": {
      "champ2": 1
    },
    "name": "champ2_1"
  }
]
```

Obtenir les statistiques d'utilisation des index :

```
db.maCollection.aggregate([ { $indexStats: {} } ])
```

Résultat :

```
[
  {
    "name" : "_id_",
    "key" : {
      "_id" : 1
    },
    "host" : "localhost:27017",
    "accesses" : {
      "ops" : 4,
      "since" : ISODate("..."),
      "note" : "..."
    }
  },
  ...
]
```

Gestion des index en arrière-plan

Concept des index en arrière-plan

- Permet aux autres opérations de continuer pendant la création de l'index

- Avantages : évite de bloquer les opérations de la base de données lors de la création d'index
- Incovénients:
  - Peuvent prendre plus de temps à créer que les index créés en mode normal (foreground)
  - Utilisent plus de ressources système (CPU, mémoire) pendant leur création

Fonctionnement des index en arrière-plan

- Ajouter `{ background: true }` lors de la création d'index
- Exemple de commande shell pour créer un index en arrière-plan : `db.collection.createIndex({ champ: 1 }, { background: true })`

Exemple de création d'un index en arrière-plan

```
db.utilisateurs.createIndex({ email: 1 }, { background: true })
```

Utilisation de l'option "sparse"

Concept des index "sparse"

- N'incluent que les documents contenant le champ indexé
- Ignorent les documents sans le champ spécifié, réduisant ainsi la taille de l'index
- Peuvent améliorer les performances pour les collections avec des structures variables
- Commande: `db.collection.createIndex({ champ: 1 }, { sparse: true })`

Exemple

Création d'un index "sparse" sur le champ "age" :

```
db.users.createIndex({ age: 1 }, { sparse: true })
```

Insertion de documents avec et sans le champ "age" :

```
db.users.insertMany([{ name: "Alice", age: 30 }, { name: "Bob" }])
```

Requête utilisant l'index "sparse" :

```
db.users.find({ age: { $gt: 25 } })
```

... retourne uniquement le document avec "Alice" et "age" 30, car l'index "sparse" n'inclut pas le document "Bob" sans le champ "age"

Index des champs uniques et composés

Index uniques

Objectif des index uniques

- Assurer l'intégrité des données en empêchant les doublons pour un champ spécifique
- Les index uniques empêchent l'insertion de documents avec des valeurs de champ en double

Création d'un index unique

- Utiliser l'option { unique: true } lors de la création de l'index
- Exemple de commande : `db.collection.createIndex({ champ: 1 }, { unique: true })`

Exemple d'index unique

```
db.collection.createIndex({ champ: 1 }, { unique: true })
```

Index composés

Définition des index composés

- Les index composés combinent plusieurs champs pour créer un index
- Ils permettent d'optimiser les requêtes impliquant plusieurs critères de recherche

Avantages des index composés

- Réduisent le besoin de parcourir l'ensemble des documents pour les requêtes impliquant plusieurs champs
- Accélèrent les requêtes de recherche et de tri sur plusieurs champs

Création d'un index composé

- Utiliser la commande `db.collection.createIndex({ champ1: 1, champ2: -1 })`

- Exemple: création d'un index composé sur les champs champ1 (ascendant) et champ2 (descendant)

Exemple

Pour créer un index composé

```
db.users.createIndex({ age: 1, lastName: -1 })
```

Pour effectuer une requête utilisant un index composé

```
db.users.find({ age: { $gte: 25 }, lastName: "Doe" }).sort({ age: 1, lastName: -1 })
```

Ordre des champs dans les index composés

Importance de l'ordre des champs

- L'ordre des champs dans les index composés affecte la manière dont MongoDB utilise l'index
- Les champs les plus restrictifs doivent être placés en premier

Exemple d'ordre des champs

- Les champs les plus restrictifs doivent être placés en premier
  - Les champs avec une grande diversité de valeurs
  - Les champs les moins fréquemment utilisés en tant que critères de recherche
- Exemple : `db.collection.createIndex({ age: 1, nom: 1 })` (l'âge étant un champ plus restrictif que le nom)

Utilisation des préfixes d'index

- Les préfixes d'index sont des sous-ensembles d'index composés
- Les requêtes utilisant un préfixe d'index peuvent tirer parti de l'index composé
- Exemple : `db.collection.find({ age: 30 }).sort({ nom: 1 }` (utilise l'index composé `{ age: 1, nom: 1 }`)

Utilisation des index composés pour trier les résultats

Les index composés peuvent être utilisés pour trier les résultats des requêtes

- Améliore les performances de tri
- Évite les tris en mémoire

Respecter l'ordre des champs dans l'index pour le tri

- La direction des champs (ascendante/descendante) doit être respectée
- Exemple :
  - Index : `{ champ1: 1, champ2: -1 }`
  - Tri valide : `{ champ1: 1, champ2: -1 }`
  - Tri invalide : `{ champ1: -1, champ2: 1 }`

Index des tableaux et des sous-documents

Index des tableaux (multi-clés)

Objectif des index multi-clés

- Accélèrent les requêtes sur les éléments de tableaux
- Créés automatiquement pour les champs de tableaux lors de l'indexation

Commande pour créer un index multi-clés

- Utiliser la commande : `db.collection.createIndex({field: 1})`
- Exemple : `db.products.createIndex({tags: 1})`

Recherche dans les tableaux avec des index multi-clés

- Opérateurs spécifiques : `$all`, `$elemMatch`, `$size`
- Exemples:
  - `$all` : `db.products.find({tags: {$all: ["electronics", "computers"]}})`
  - `$elemMatch` : `db.students.find({grades: {$elemMatch: {score: {$gt: 90}}}})`
  - `$size` : `db.products.find({tags: {$size: 3}})`

Limitations des index multi-clés

- Ne peuvent pas couvrir plusieurs champs de tableaux dans une seule requête
- Les index multi-clés à composés sont limités à 31 champs maximum

Index des sous-documents

Objectif

- Améliorer les requêtes sur les sous-documents avec des index
- Indexer les sous-champs pour optimiser les recherches

Création d'index sur un sous-champ

- Commande : `db.collection.createIndex({"field.subfield": 1})`

- Exemple : `db.users.createIndex({"address.city": 1})`

Recherche dans les sous-documents

- Notation pointée pour accéder aux sous-champs
- Exemple

```
// Recherche d'utilisateurs par ville :
db.users.find({"address.city": "New York"})

// Recherche d'utilisateurs par code postal et pays :
db.users.createIndex({"address.zip": 1, "address.country": 1})
db.users.find({"address.zip": "12345", "address.country": "USA"})
```

Tri des résultats

- Utiliser `.sort()` avec la notation pointée
- Exemple : `db.users.find().sort({"address.city": 1})`

Recherche et requêtes avancées

Index multi-clés et sous-documents

- Index multi-clés pour les requêtes sur les tableaux
- Notation pointée pour les requêtes sur les sous-documents

Exemples de requêtes avancées

- Combinaison de conditions sur un tableau et un sous-document :

```
db.users.find({tags: "developer", "address.city": "Paris"})
```

- Utilisation de $elemMatch pour filtrer sur plusieurs conditions dans un tableau :

```
db.users.find({hobbies: {$elemMatch: {name: "tennis", skillLevel: {$gte: 3}}}})
```

Index géo-spatiaux

Introduction aux index géo-spatiaux

Les index géo-spatiaux facilitent les requêtes sur des données géographiques

Exemple d'une structure de document avec des données géographiques :

```
{
  name: "Tour Eiffel",
  location: {
    type: "Point",
    coordinates: [2.2945, 48.8583]
  }
}
```

Types d'index géo-spatiaux : 2D et 2DSphere

- Index 2D : pour des données planaires (cartésiennes)
  - Convient pour des données dans un espace cartésien, comme des coordonnées [x, y] ou {x, y}
  - Exemple de données plannaires:

    ```
    {
      name: "Point A",
      location: [50, 100]
    }
    ```

- Index 2DSphere : utilisés pour des données sphériques (géographiques) tenant compte la courbure de la Terre
  - Exemple de données géographiques au format GeoJSON

    ```
    {
      name: "Tour Eiffel",
      location: {
        type: "Point",
        coordinates: [2.2945, 48.8583]
      }
    }
    ```

Création d'index 2D

Créer un index 2D

- Exemple : `db.places.createIndex({location: "2d"})`

Format des données géographiques pour index 2D

- Exemple 1 (format tableau) : `{location: [2, 3]}`
- Exemple 2 (format objet) : `{location: {x: 2, y: 3}}`

Insérer des documents avec des coordonnées géographiques

- Exemple : `db.places.insert([{name: "A", location: [2, 3]}, {name: "B", location: [4, 6]}, {name: "C", location: [8, 2]}])`

Requête pour trouver des documents à proximité d'un point donné avec un index 2D

- Requête : `db.places.find({location: {$near: [3, 4], $maxDistance: 5}})`
- Résultat : documents dont la distance de "location" au point `[3, 4]` est inférieure ou égale à 5 unités

Création d'index 2DSphere

Créer un index 2DSphere

- Exemple : `db.places.createIndex({location: "2dsphere"})`

Format des données géographiques pour index 2DSphere (GeoJSON)

- Point : `{type: "Point", coordinates: [<longitude>, <latitude>]}`
- Polygon : `{type: "Polygon", coordinates: [[[<lon1>, <lat1>], [<lon2>, <lat2>], ..., [<lon1>, <lat1>]]]}`

Exemple d'insertion et de requête avec index 2DSphere

Insertion d'un document avec des données géographiques au format GeoJSON :

```
db.places.insert({
  name: "Tour Eiffel",
  location: {
    type: "Point",
    coordinates: [2.294481, 48.858158]
  }
})
```

Création de l'index 2DSphere sur le champ "location" :

```
db.places.createIndex({location: "2dsphere"})
```

Recherche des lieux à proximité de la Tour Eiffel dans un rayon de 1 km :

```
db.places.find({
  location: {
    $near: {
      $geometry: {
        type: "Point",
        coordinates: [2.294481, 48.858158]
      },
      $maxDistance: 1000
    }
  }
})
```

Requêtes géo-spatiales avec MongoDB

Opérateur $near

- Recherche des documents à proximité d'un point spécifique
- Exemple de commande shell :

```
db.places.find({
 location: {
  $near: {
    $geometry: {
      type: "Point",
      coordinates: [-73.9667, 40.78] // longitude, latitude
    },
    $maxDistance: 1000 // distance en mètres
  }
 }
})
```

Opérateur $geoWithin

- Recherche des documents dans une région géographique délimitée

- Exemple de commande shell :

```
db.places.find({
  location: {
    $geoWithin: {
      $geometry: {
        type: "Polygon",
        coordinates: [
          [
            [-74.0, 40.7], // coordonnées des sommets
            [-73.9, 40.7],
            [-73.9, 40.8],
            [-74.0, 40.8],
            [-74.0, 40.7]
          ]
        ]
      }
    }
  }
})
```

Opérateur $geoIntersects

- Recherche des documents qui intersectent une région géographique spécifique (ex. ligne, polygone)
- Exemple de commande shell :

```
db.places.find({
  location: {
    $geoIntersects: {
      $geometry: {
        type: "LineString",
        coordinates: [
          [-74.0, 40.7], // coordonnées des points de la ligne
          [-73.9, 40.7]
        ]
      }
    }
  }
})
```

Collections plafonnées, index TTL et curseurs

Collections plafonnées

Collections à taille fixe

- Taille déterminée à la création
- Suppression des documents les plus anciens lorsque la taille maximale est atteinte

Rotation automatique des documents

- Pas besoin de gérer manuellement la suppression des documents
- Idéal pour les données temporaires et les flux de données en temps réel

Création avec db.createCollection()

- Commande shell : db.createCollection("logs", {capped: true, size: 1000000, max: 1000})
- Configuration : {capped: true, size: , max: }
- size : taille maximale de la collection en octets
- max : nombre maximal de documents (optionnel)

Utilisations courantes : logs, cache, flux de données en temps réel

Exemple de code pour insérer un log :

```
db.logs.insertOne({ timestamp: new Date(), message: "Nouveau log", level: "info" });
```

Exemple de code pour récupérer les logs récents :

```
var logs = db.logs.find().sort({ timestamp: -1 }).limit(10);
logs.forEach(log => printjson(log));
```

Index TTL (Time-To-Live)

Suppression automatique des documents après un délai spécifié

Adapté aux données temporaires

- Exemples : sessions utilisateur, logs, données expirables
- Applications : surveillance, analyse des logs, traitement de flux de données

Création d'un index TTL

- Utiliser la commande db.collection.createIndex()
- Spécifier le champ de date ou Timestamp et le délai d'expiration en secondes

Exemple :

```
db.sessions.createIndex({ "createdAt": 1 }, { expireAfterSeconds: 3600 })
```

Définir le champ de date ou Timestamp lors de l'insertion du document

Exemple d'insertion de document avec un champ "createdAt" :

```
db.sessions.insert({ "user": "jdoe", "createdAt": new Date() })
```

Fonctionnement des index TTL

- Le processus MongoDB supprime périodiquement les documents expirés
- Les documents sont supprimés en fonction de leur champ de date ou Timestamp
- Le délai d'expiration peut être modifié en utilisant collMod

Exemple pour modifier le délai d'expiration à 7200 secondes :

```
db.runCommand({ collMod: "sessions", index: { keyPattern: { createdAt: 1 },
expireAfterSeconds: 7200 }})
```

Limitations des index TTL

- Ne fonctionne pas sur les collections plafonnées

- Ne supprime pas les documents si le champ de date ou Timestamp est manquant ou non valide
- Les suppressions ne sont pas instantanées, mais effectuées lors des vérifications périodiques par MongoDB

Utilisation des curseurs Tailable

Objectifs

- Curseurs persistants pour les collections plafonnées
- Suivre les insertions en temps réel
- Similaire à la fonctionnalité tail -f sous Unix

Création d'une collection plafonnée

- Commande : db.createCollection("logs", { capped: true, size: 1000000, max: 1000 })

Utilisation avec cursor.addOption(DBQuery.Option.tailable)

- Exemple :

```
var cursor = db.logs.find().sort({ $natural: -1 }).limit(1);
cursor.addOption(DBQuery.Option.tailable);
cursor.addOption(DBQuery.Option.awaitData);
while (cursor.hasNext()) {
  printjson(cursor.next());
}
```

Commande alternative :

```
db.logs.find().addOption(DBQuery.Option.tailable).addOption(DBQuery.Option.awaitData);
```

Agrégation à finalité unique

Introduction à l'agrégation à finalité unique

Utilisation des fonctions d'agrégation pour obtenir des informations à partir d'un ensemble de documents

Utilisation des opérateurs de groupe pour regrouper et résumer des données

Avantages: simplicité, rapidité pour des opérations simples

Limites: moins flexible que les pipelines d'agrégation et Map-reduce

Agrégation avec des opérateurs de groupe

$group : regrouper des documents en fonction d'un ou plusieurs champs

$sum : additionner les valeurs d'un champ spécifié

```
Exemple: { $sum: "$field" }
```

$avg : calculer la moyenne des valeurs d'un champ spécifié

```
Exemple: { $avg: "$field" }
```

$min : déterminer la valeur minimale d'un champ spécifié

```
Exemple: { $min: "$field" }
```

$max : déterminer la valeur maximale d'un champ spécifié

```
Exemple: { $max: "$field" }
```

$push : ajouter les valeurs d'un champ spécifié à un tableau

```
Exemple: { $push: "$field" }
```

$addToSet : ajouter les valeurs uniques d'un champ spécifié à un tableau

```
Exemple: { $addToSet: "$field" }
```

Agrégation conditionnelle

$cond : appliquer une condition ternaire (si... alors... sinon...) sur les documents

```
Exemple: { $cond: { if: { $gte: ["$field", 0] }, then: "$field", else: "N/A" } }
```

$ifNull : remplacer les valeurs nulles ou inexistantes par une valeur par défaut

```
Exemple: { $ifNull: ["$field", "N/A"] }
```

Exemples d'agrégation à finalité unique

Exemple 1: Calculer le montant total des ventes par catégorie

```
Commande: db.collection.aggregate([{ $group: { _id: "$category", totalSales: { $sum: "$sales" } } }])
```

Exemple 2: Obtenir la moyenne des notes par étudiant

```
Commande: db.collection.aggregate([{ $group: { _id: "$student", avgGrade: { $avg: "$grade" } } }])
```

Exemple 3: Trouver le prix minimum et maximum par produit

```
Commande: db.collection.aggregate([{ $group: { _id: "$product", minPrice: { $min: "$price" }, maxPrice: { $max: "$price" } } }])
```

Pipelines d'agrégation

Introduction aux pipelines d'agrégation

Les pipelines d'agrégation permettent de traiter et d'analyser des données dans MongoDB.

Les avantages incluent la flexibilité, l'expressivité et la performance.

Les pipelines sont composés d'étapes successives qui modifient et filtrent les données.

Utilisation de la commande db.collection.aggregate() pour exécuter des pipelines d'agrégation.

Les étapes du pipeline

$match: Filtrer les documents en fonction de conditions spécifiques.

```
Exemple: {$match: {age: {$gt: 18}}}
```

$project: Sélectionner, renommer ou ajouter des champs aux documents.

```
Exemple: {$project: {_id: 0, nom: 1, age: 1}}
```

$unwind: Transformer un champ de type tableau en plusieurs documents.

```
Exemple: {$unwind: '$hobbies'}
```

$group: Regrouper des documents par un ou plusieurs champs.

Exemple: {$group: {_id: '$categorie', total: {$sum: 1}}}

$sort: Trier les documents en fonction de critères spécifiés.

Exemple: {$sort: {total: -1}}

$limit: Limiter le nombre de documents retournés.

Exemple: {$limit: 10}

$skip: Ignorer un certain nombre de documents en début de pipeline.

Exemple: {$skip: 20}

$lookup: Joindre des documents d'une autre collection.

Exemple: {$lookup: {from: 'orders', localField: '_id', foreignField: 'customer_id', as: 'customer_orders'}}

$out: Écrire le résultat du pipeline dans une nouvelle collection.

Exemple: {$out: 'result_collection'}

Optimisation des pipelines d'agrégation

Placer les étapes de filtrage ($match) en début de pipeline pour réduire la quantité de données à traiter.

Utiliser $project pour limiter les champs conservés et réduire la taille des documents.

Placer $sort avant $group lorsque c'est possible pour utiliser des index de tri.

Utiliser l'option "allowDiskUse" pour traiter de grandes quantités de données.

Exemples de pipelines d'agrégation

Exemple 1: Compter le nombre de documents par catégorie et les trier par ordre décroissant.

```
    db.collection.aggregate([{$group: {_id: '$categorie', total: {$sum: 1}}}, {$sort: {total: -1}}])
```

Exemple 2: Extraire les 10 clients ayant passé le plus de commandes.

```
    db.customers.aggregate([{$lookup: {from: 'orders', localField: '_id', foreignField: 'customer_id', as: 'customer_orders'}}, {$project: {name: 1, order_count: {$size: '$customer_orders'}}}, {$sort: {order_count: -1}}, {$limit: 10}])
```

Map-Reduce

Introduction à Map-reduce

Map-reduce : modèle de programmation pour traiter et générer de grands ensembles de données

Avantages

- Traite de grandes quantités de données
- Scalable et distribuable sur plusieurs machines
- Parallélise les tâches pour améliorer les performances

Fonctions map et reduce

Fonction map :

- Transforme chaque document en une ou plusieurs paires clé-valeur
- Exemple : `function() { emit(this.userId, this.score); }`

Fonction reduce :

- Combine les valeurs associées à une même clé
- Exemple : `function(key, values) { return Array.sum(values); }`

Les fonctions map et reduce sont écrites en JavaScript

Utilisation de la commande db.collection.mapReduce(map, reduce, options) dans la CLI MongoDB

Finalize et options supplémentaires

Fonction finalize (optionnelle) :

- Traite les résultats après la phase de réduction
- Exemple : calculer la moyenne des scores

Options supplémentaires :

- query : filtrer les documents avant le traitement
- sort : trier les documents avant le traitement
- limit : limiter le nombre de documents traités
- out : spécifier la collection de sortie

Comparaison entre Map-reduce et les pipelines d'agrégation

Map-reduce :

- Plus flexible, mais plus complexe
- Convient pour les tâches distribuées et parallèles
- Performances généralement inférieures aux pipelines d'agrégation

Pipelines d'agrégation :

- Plus simples et intuitifs
- Performances généralement meilleures pour la plupart des cas d'utilisation
- Moins adaptés aux tâches distribuées et parallèles

Exemples de Map-reduce

Calculer la somme des scores par utilisateur :

```
db.scores.mapReduce(map, reduce, { out: "sum_scores" })
```

Filtrer les documents avant le traitement :

```
db.scores.mapReduce(map, reduce, { query: { game: "chess" }, out: "chess_scores" })
```

Trier les documents et limiter le nombre de documents traités :

```
db.scores.mapReduce(map, reduce, { sort: { date: 1 }, limit: 100, out: "latest_scores" })
```

Réplication asynchrone dans MongoDB

Mise en place et entretien d'un replica set

Utilisation de "write concern" et "read preference"

Gérer les échecs de réplication

Sharding automatique

Mise en place d'un cluster de shards MongoDB

Choisir judicieusement une shard key

Administration avancée d'un cluster de shards

Gérer un cluster de shards déséquilibré

Gérer les chunks (scission, fusion, migration)

Authentification et autorisation dans les replica sets et les clusters de shards

Gestion des privilèges et des rôles personnalisés

Recommandations pour un déploiement sûr

Stratégies basées sur le système de fichiers

Utilisation de mongodump et mongorestore

Récupération de type point-in-time

Capture et rejeu

Références

- https://www.mongodb.com/docs/manual/reference/program/mongoreplay/

Astuces

- https://www.percona.com/blog/2016/12/05/mongodb-troubleshooting-top-5/