Modèle Document

- **Principes**
- **MongoDB**
- **CouchBase**
- **ElasticSearch (moteur de recherche NoSQL)**
- **JSON/SQL sous PostgreSQL**

Base de données documents

- Basé également sur le paradigme [clé, valeur], mais avec une valeur, de type document
- Document : structure arborescente contenant une liste de champs
- Champs est associé à une valeur qui peut elle même être une liste
- Documents principalement de type JSON ou XML
- Représentation d'un document :
  - Forme sérialisée (la plus courante) : contenu marqué par des balises ou par des accolades ouvrante/fermante.
  - Forme arborescente

Collection de documents

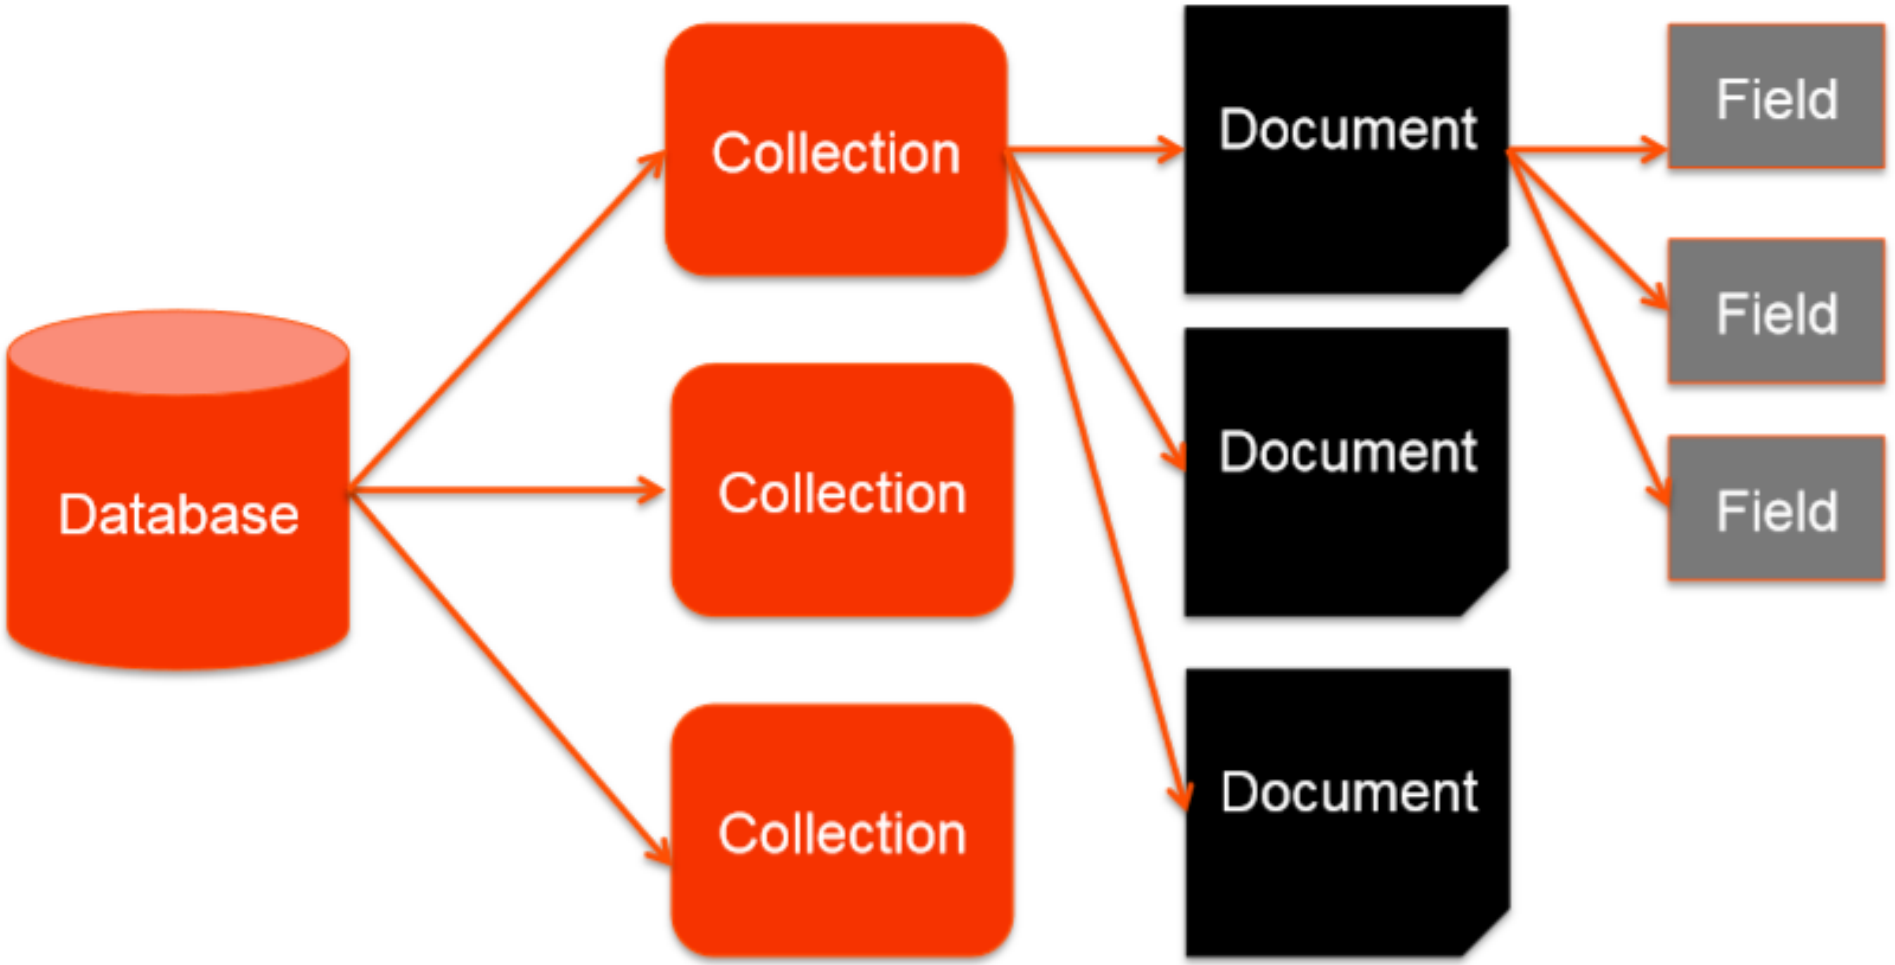

Document JSON

Forme sérialisée

```
{
 "fruits": [
  { "kiwis": 3,
    "mangues": 4,
    "pommes": null
  },
  { "panier": true }
 ],
 "legumes": {
    "patates": "amandine",
    "poireaux": false
  },
  "viandes": ["poisson","poulet","boeuf"]
}
```

Forme arborescente

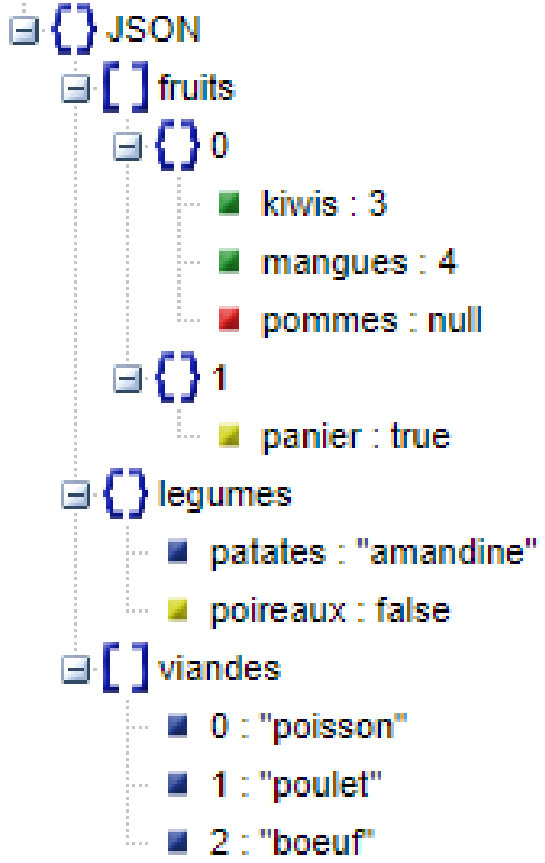

Base de données documents : cas d'utilisation

- **Cas d'utilisation :**
  - Systèmes de gestion de contenu (profils utilisateurs, avis et commentaires, blogs, etc.)
  - Applications de e-commerce (stockage du catalogue, schéma flexible pour les produits et commandes)
- **Non applicable aux:**
  - Données interconnectées
  - Données non-structurées

Principaux moteurs orientés document

☐ include secondary database models — 56 systems in ranking, February 2023

Rank Feb 2023	Rank Jan 2023	Rank Feb 2022	DBMS	Database Model	Score Feb 2023	Score Jan 2023	Score Feb 2022
1.	1.	1.	MongoDB	Document, Multi-model	452.77	-2.42	-35.88
2.	2.	2.	Amazon DynamoDB	Multi-model	79.69	-1.87	-0.67
3.	3.		Databricks	Multi-model	60.33	-0.49	
4.	4.	↓ 3.	Microsoft Azure Cosmos DB	Multi-model	36.51	-1.45	-3.45
5.	5.	↓ 4.	Couchbase	Document, Multi-model	24.86	-0.44	-5.21
6.	6.	↓ 5.	Firebase Realtime Database	Document	18.49	-0.27	-0.66
7.	7.	↓ 6.	CouchDB	Document, Multi-model	14.45	-0.44	-3.01
8.	8.	↑ 9.	Google Cloud Firestore	Document	11.51	+0.41	+2.45
9.	9.	↓ 7.	MarkLogic	Multi-model	8.84	-0.01	-0.61
10.	10.	↓ 8.	Realm	Document	8.24	-0.09	-1.17
11.	11.	↑ 13.	Google Cloud Datastore	Document	6.89	+0.22	+1.64
12.	12.	↓ 10.	Aerospike	Multi-model	6.56	+0.09	+0.95
13.	13.	↓ 12.	Virtuoso	Multi-model	6.11	+0.23	+0.72
14.	14.	↓ 11.	ArangoDB	Multi-model	5.29	+0.22	-0.11
15.	15.	↓ 14.	OrientDB	Multi-model	4.54	+0.06	-0.49

MongoDB

- Base de données orientée documents (représentation structurée)
- Open source développé par MongoDB Inc depuis 2007
- Nom provenant de l'anglais "hu**mongo**us" ("énorme")
- Ecrit en C++
- *Mongo Atlas* : mode hébergé dans le cloud sur la base d'une tarification horaire
- Stockage des documents au format BSON (*Binary Serialized dOcument Notation* ou *Binary* JSON) – mais structure visible par les utilisateurs en JSON

MongoDB : liens utiles

- Site officiel : https://www.mongodb.com/fr
- Documentation : : https://docs.mongodb.com/manual/introduction/
- Console en ligne dans la documentation :
  - https://docs.mongodb.com/manual/tutorial/insert-documents/ (il faut sélectionner la version 4.2)
  - https://www.mycompiler.io/new/mongodb ou https://onecompiler.com/mongodb
- Tutoriels :
  - https://www.mongodb.com/docs/manual/tutorial/
  - http://b3d.bdpedia.fr/docstruct.html#s4-mongodb-une-base-json
  - https://stph.scenari-community.org/contribs/nos/Mongo1/co/presentation.html
  - https://www.tutorialspoint.com/mongodb/mongodb_overview.htm

MongoDB : modèle de données (1/2)

RDBMS	MongoDB
Database	Database
Table	Collection
Tuple/Row	Document
column	Field
Table Join	Embedded Documents
Primary Key	Primary Key (Default key _id provided by mongodb itself)

MongoDB : modèle de données (2/2)

- Document BSON = unité de stockage (~ une ligne dans une BDR)
- Pour l'utilisateur : structure visible en JSON
- Tout document appartient à une collection et a un champ appelé `_id` qui identifie le document dans la base de données
- Document : hiérarchie de paires clé-valeur, sans contrainte de présence ou de quantité
- Collection : ensemble de documents (~table en relationnel)

MongoDB : exemple

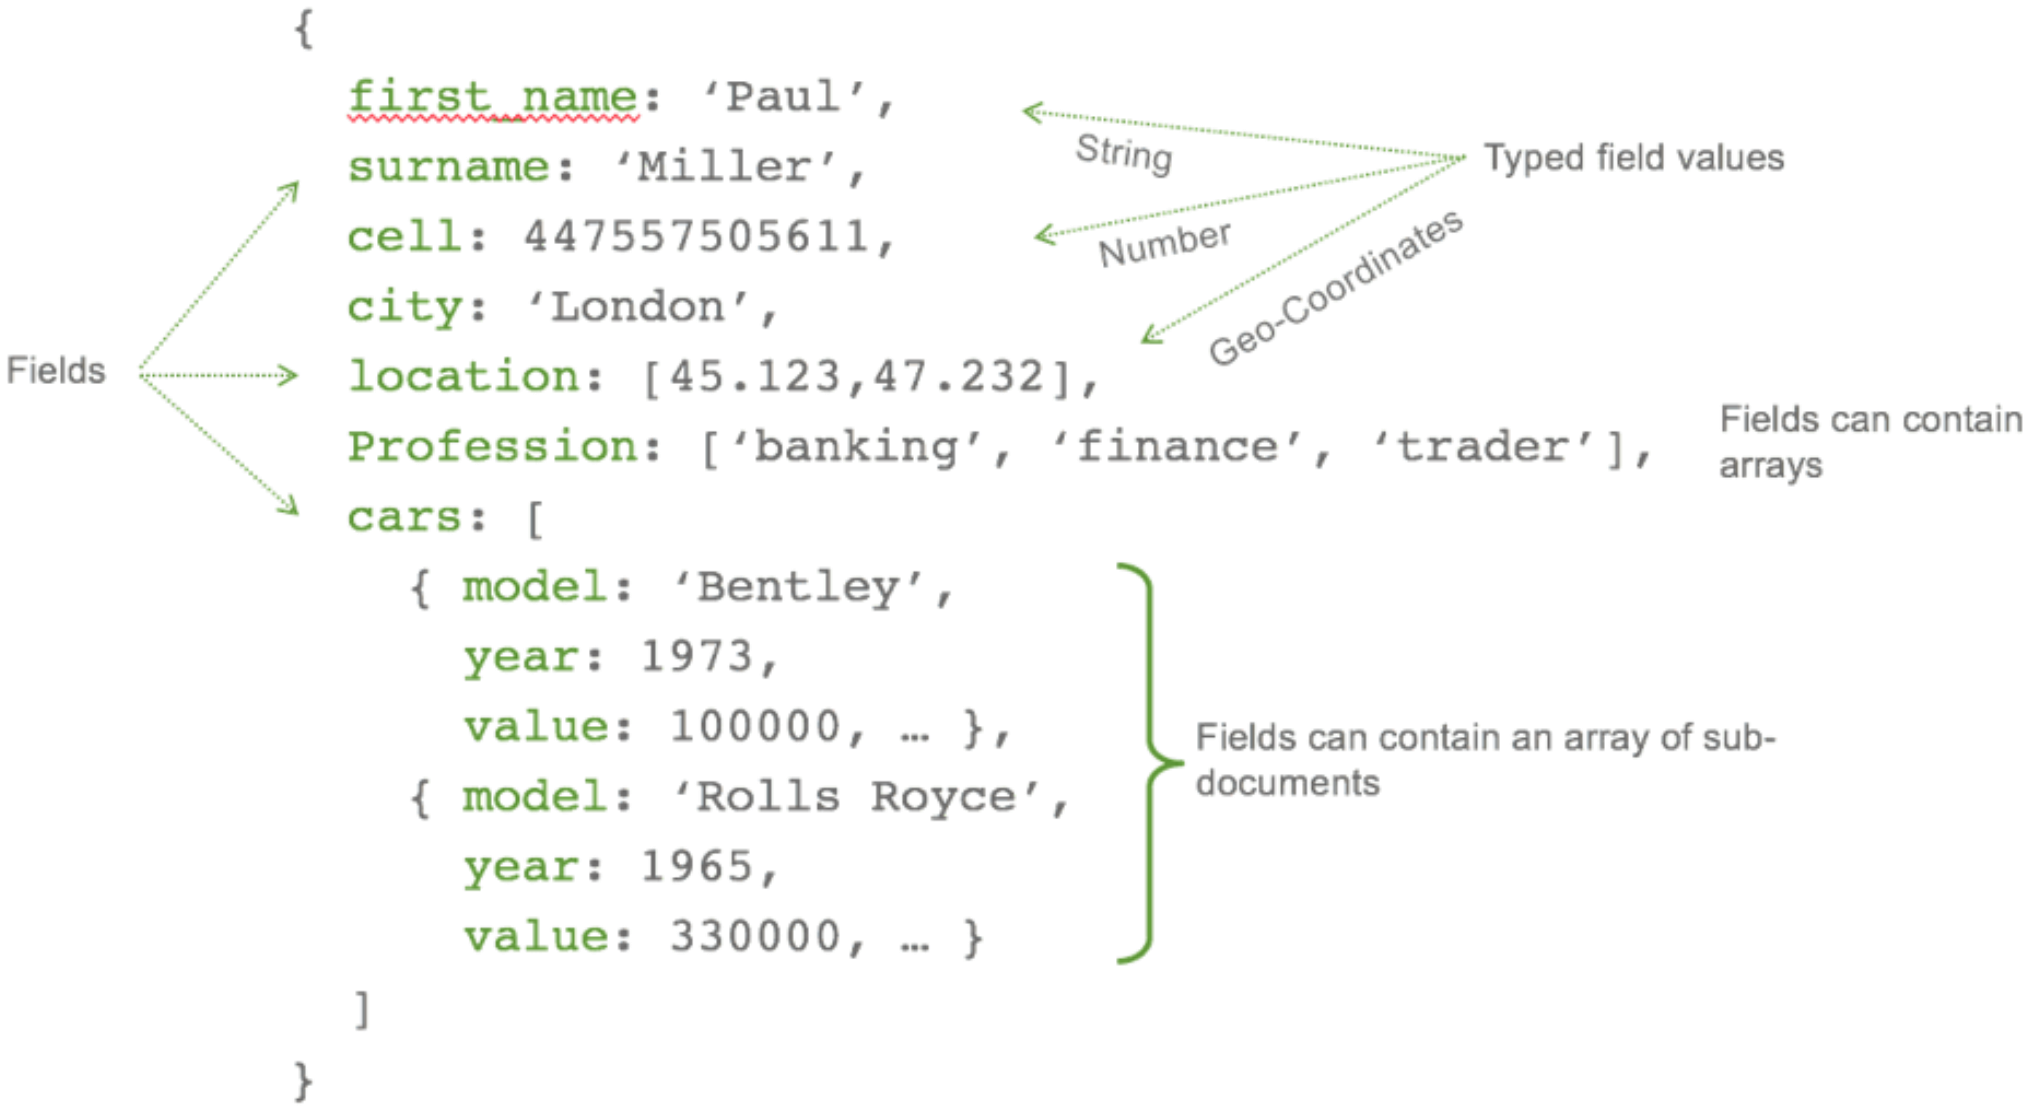

MongoDB : attribut identificateur `_id`

```
{
   _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
      }
   ]
}
```

MongoDB : relationnel vs document

Relationnel

Customer ID	First Name	Last Name	City
0	John	Doe	New York
1	Mark	Smith	San Francisco
2	Jay	White	Dallas
3	Meagan	White	London
4	Edward	Daniels	Boston

Phone Number	Type	DNC	Customer ID
1-212-555-1212	home	T	0
1-212-555-1213	home	T	0
1-212-555-1214	cell	F	0
1-212-777-1212	home	T	1
1-212-777-1213	cell	(null)	1
1-212-888-1212	home	F	2

MongoDB

```
{  customer_id : 1,
   name : {
     "f":"Mark",
     "l":"Smith" },
    city : "San Francisco",
    phones: [  {
        number : "1-212-777-1212",
        dnc : true,
        type : "home"
    },
    {
        number : "1-212-777-1213",
        type : "cell"
    }]
```

MongoDB : Relation implémentée par une imbrication de documents

```
{
   "_id":ObjectId("52ffc33cd85242f436000001"),
   "contact": "987654321",
   "dob": "01-01-1991",
   "name": "Tom Benzamin",
   "address": [
      {
         "building": "22 A, Indiana Apt",
         "pincode": 123456,
         "city": "Los Angeles",
         "state": "California"
      },
      {
         "building": "170 A, Acropolis Apt",
         "pincode": 456789,
         "city": "Chicago",
         "state": "Illinois"
      }
   ]
}
```

MongoDB : Relation implémentée par l'utilisation de référence

```
{
   "_id":ObjectId("52ffc4a5d85242602e000000"),
   "building": "22 A, Indiana Apt",
   "pincode": 123456,
   "city": "Los Angeles",
   "state": "California"
}
```

```
{
   "_id":ObjectId("52ffc33cd85242f436000001"),
   "contact": "987654321",
   "dob": "01-01-1991",
   "name": "Tom Benzamin",
   "address_ids": [
      ObjectId("52ffc4a5d85242602e000000"),
      ObjectId("52ffc4a5d85242602e000001")
   ]
}
```

MongoDB : principes

- En général, regroupement de toutes les données relatives à un objet dans un même « document »

⇒ nombre de jointures réduit et donc impact positif sur les performances (toutes les données sont récupérées en une seule lecture)

- Document proche de la structure des objets dans les langages de programmation (facilite le développement)
- Modèle des documents pouvant varier de structure dans une même collection
- Schéma dynamique : possibilité d'ajouter de nouveaux champs sans affecter les autres documents
- Schéma flexible mais conçu selon le type de requêtes

MongoDB : opérations CRUD (insertion)

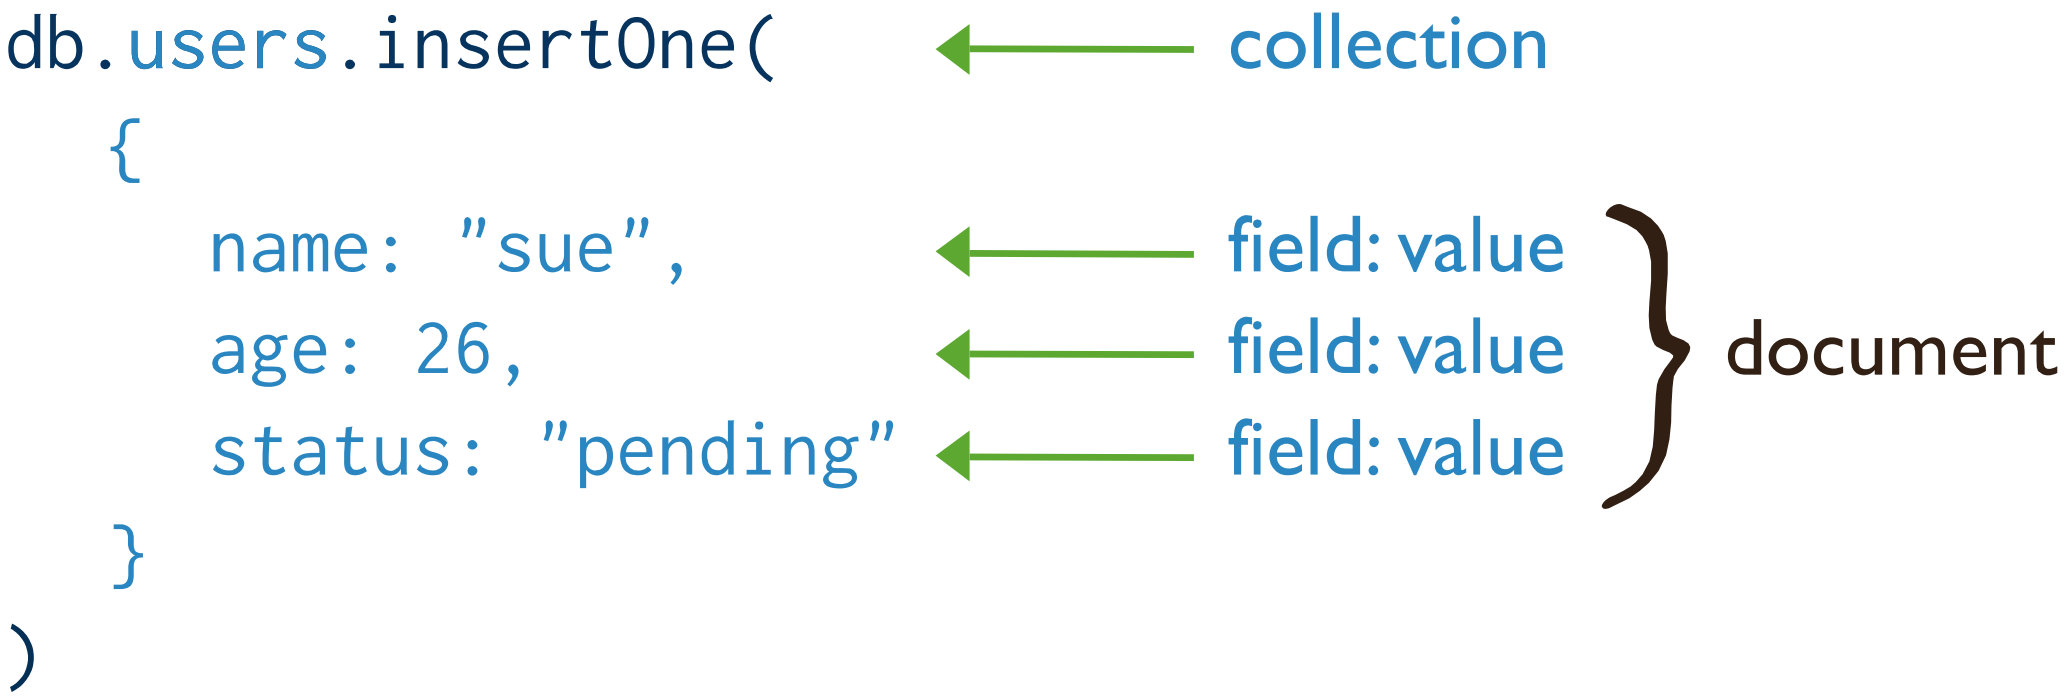

MongoDB : Exemples de commandes dans la documentation en ligne

MongoDB : opérations CRUD (initialisation ou non de l'attribut `_id`)

- Soit MongoDB crée le champ `_id` et lui affecte une valeur `ObjectId` unique

```
db.products.insert( { item: "card", qty: 15 } )
```

```
{ "_id" : ObjectId("5063114bd386d8fadbd6b004"), "item" : "card", "qty" : 15 }
```

- Soit on crée cet identificateur à l'insertion

```
db.products.insert( { _id: 10, item: "box", qty: 20 } )
```

```
{ "_id" : 10, "item" : "box", "qty" : 20 }
```

MongoDB : opérations CRUD (mixage de la gestion des identificateurs)

```
db.products.insert(
   [
     { _id: 11, item: "pencil", qty: 50, type: "no.2" },
     { item: "pen", qty: 20 },
     { item: "eraser", qty: 25 }
   ]
)
```

```
{ "_id" : 11, "item" : "pencil", "qty" : 50, "type" : "no.2" }
{ "_id" : ObjectId("51e0373c6f35bd826f47e9a0"), "item" : "pen", "qty" : 20 }
{ "_id" : ObjectId("51e0373c6f35bd826f47e9a1"), "item" : "eraser", "qty" : 25 }
```

MongoDB : opérations CRUD (`find`)

```
db.users.find(
    { age: { $gt: 18 } },
    { name: 1, address: 1 }
).limit(5)
```

← collection
← query criteria
← projection
← cursor modifier

MongoDB : traduction de `find` en SQL (1/2)

```
db.inventory.find( {} )
```

```
SELECT * FROM inventory
```

```
db.inventory.find( { status: "D" } )
```

```
SELECT * FROM inventory WHERE status = "D"
```

```
db.inventory.find( { status: { $in: [ "A", "D" ] } } )
```

```
SELECT * FROM inventory WHERE status in ("A", "D")
```

```
db.inventory.find( { status: "A", qty: { $lt: 30 } } )
```

```
SELECT * FROM inventory WHERE status = "A" AND qty < 30
```

MongoDB : MongoDB : traduction de `find` en SQL (2/2)

```
db.inventory.find( { status: "A" }, { item: 1, status: 1 } )
```

```
SELECT _id, item, status from inventory WHERE status = "A"
```

```
db.inventory.find( { status: "A" }, { item: 1, status: 1, _id: 0 } )
```

```
SELECT item, status from inventory WHERE status = "A"
```

Attention : Pas d'erreur en cas de faute de frappe sur des noms d'attributs

MongoDB : exemple de tri

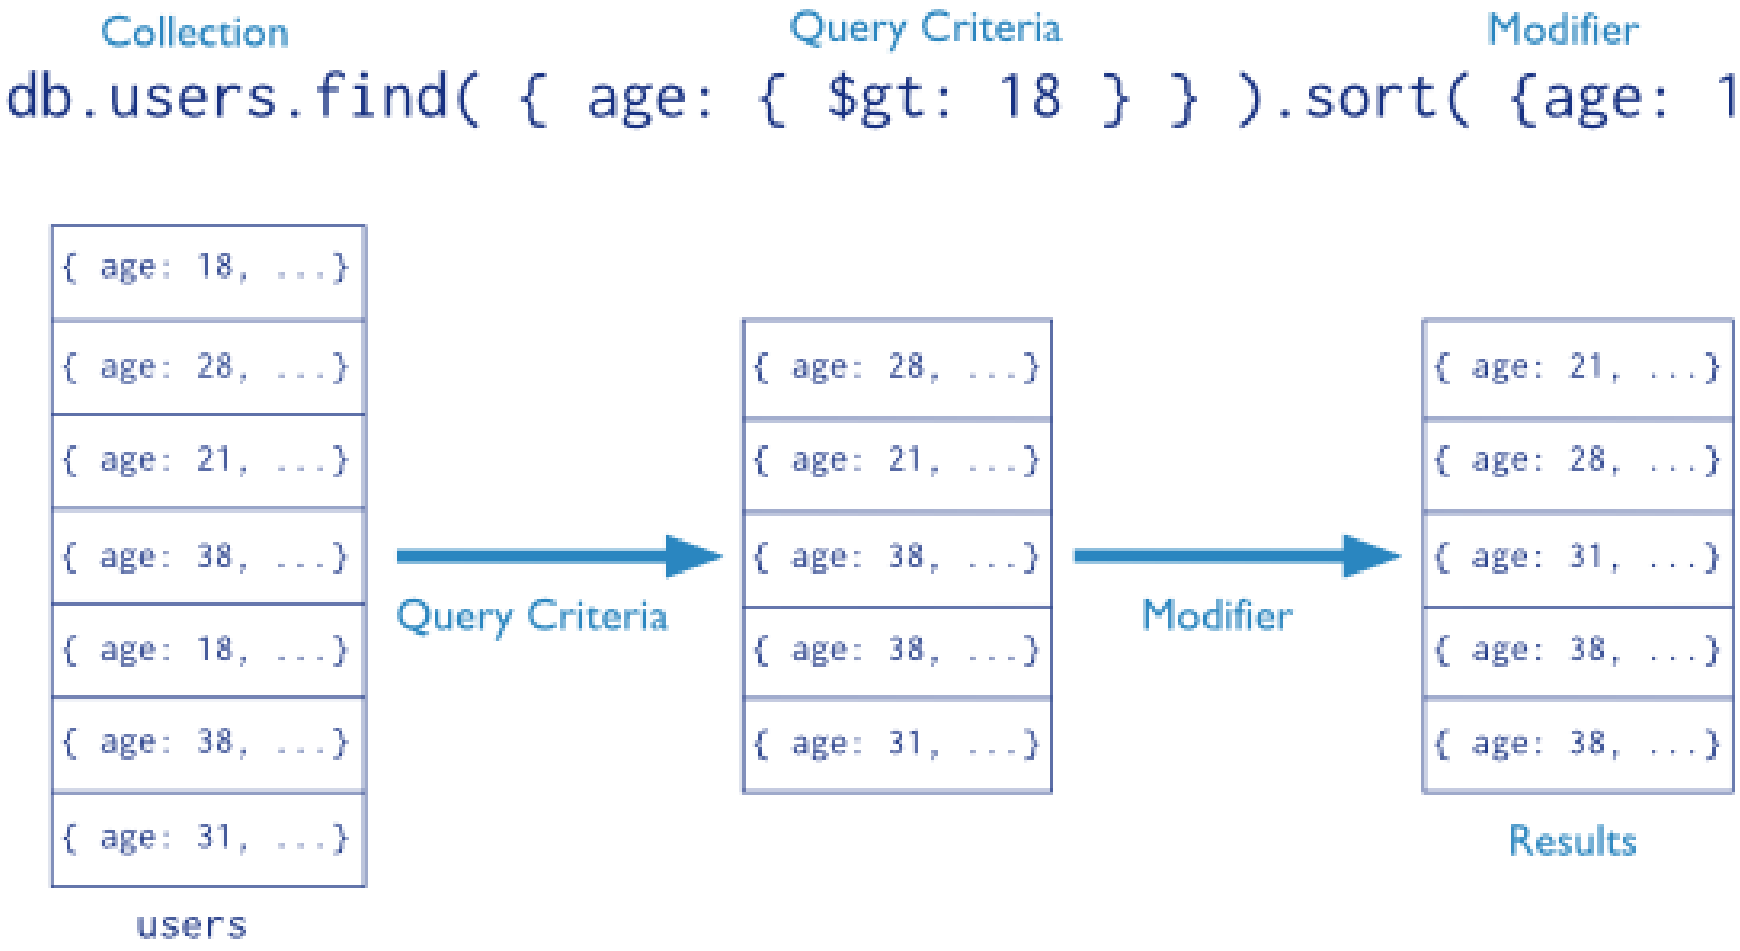

MongoDB : agrégation

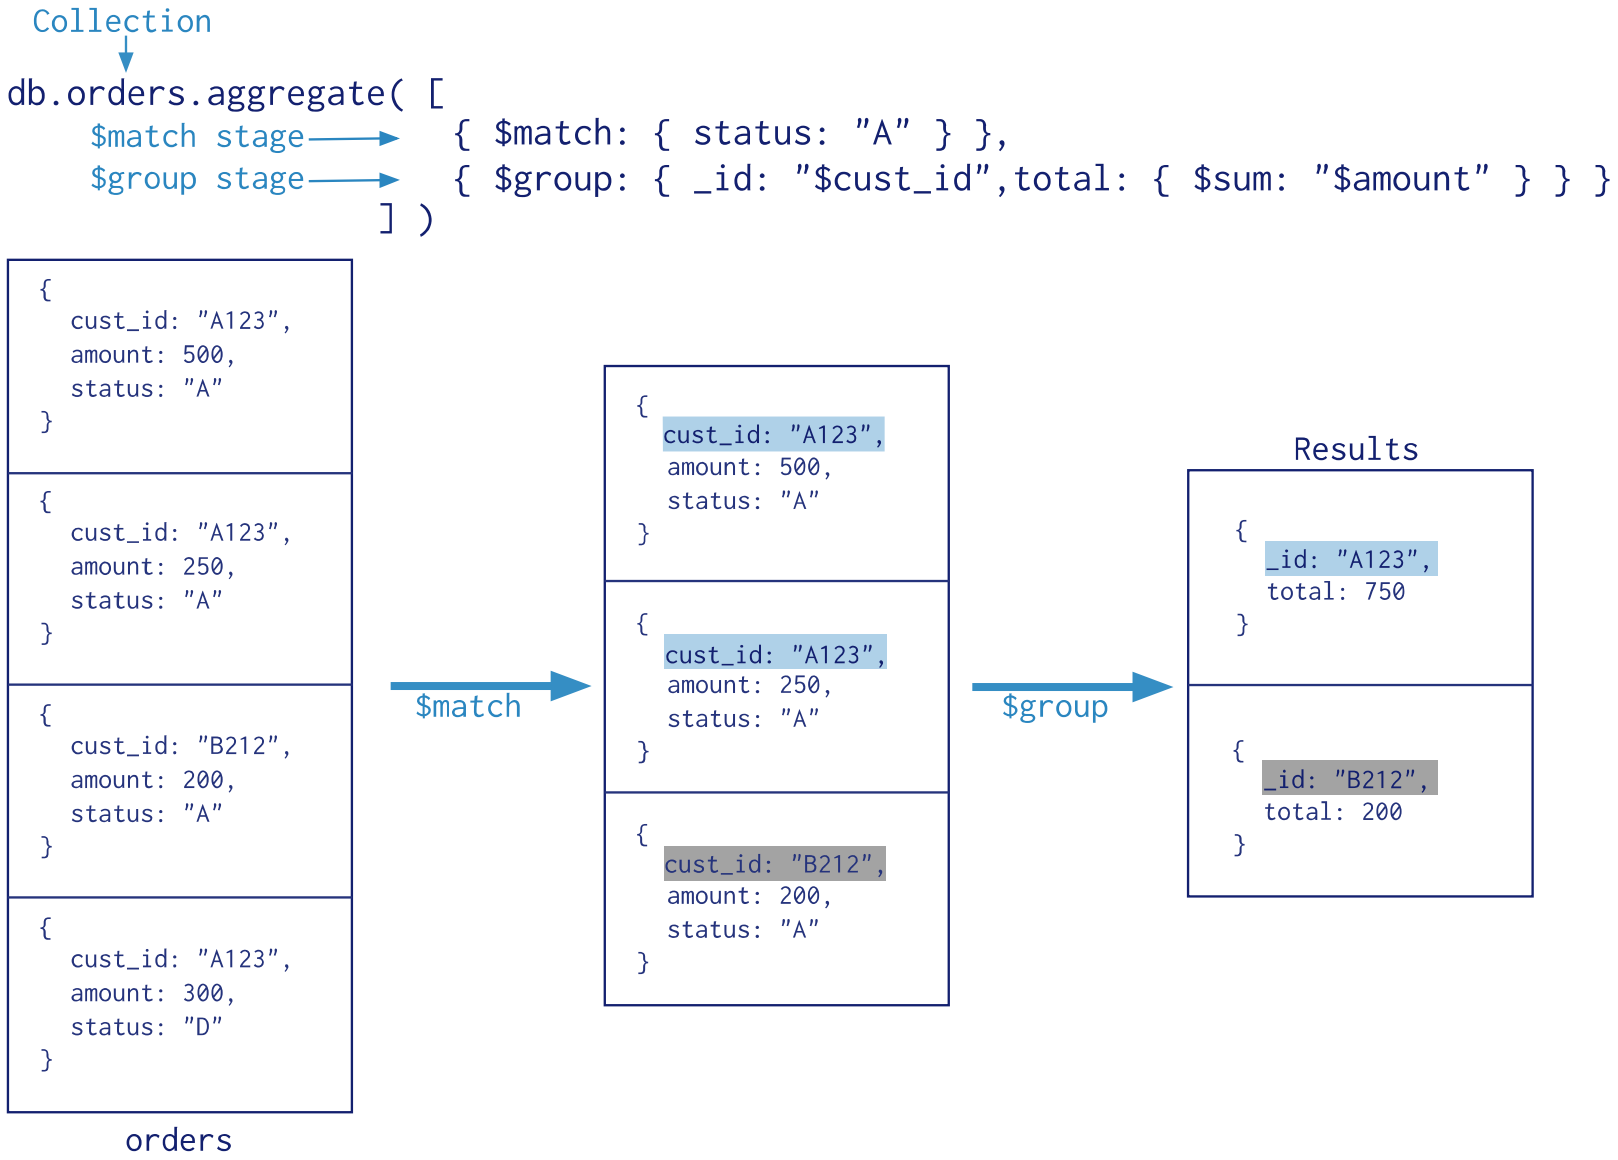

MongoDB : agrégation en utilisant *Map Reduce*

```
Collection
db.orders.mapReduce(
        map      →   function() { emit( this.cust_id, this.amount ); },
        reduce   →   function(key, values) { return Array.sum( values ) },
                     {
        query    →     query: { status: "A" },
        output   →     out: "order_totals"
                     }
                 )
```

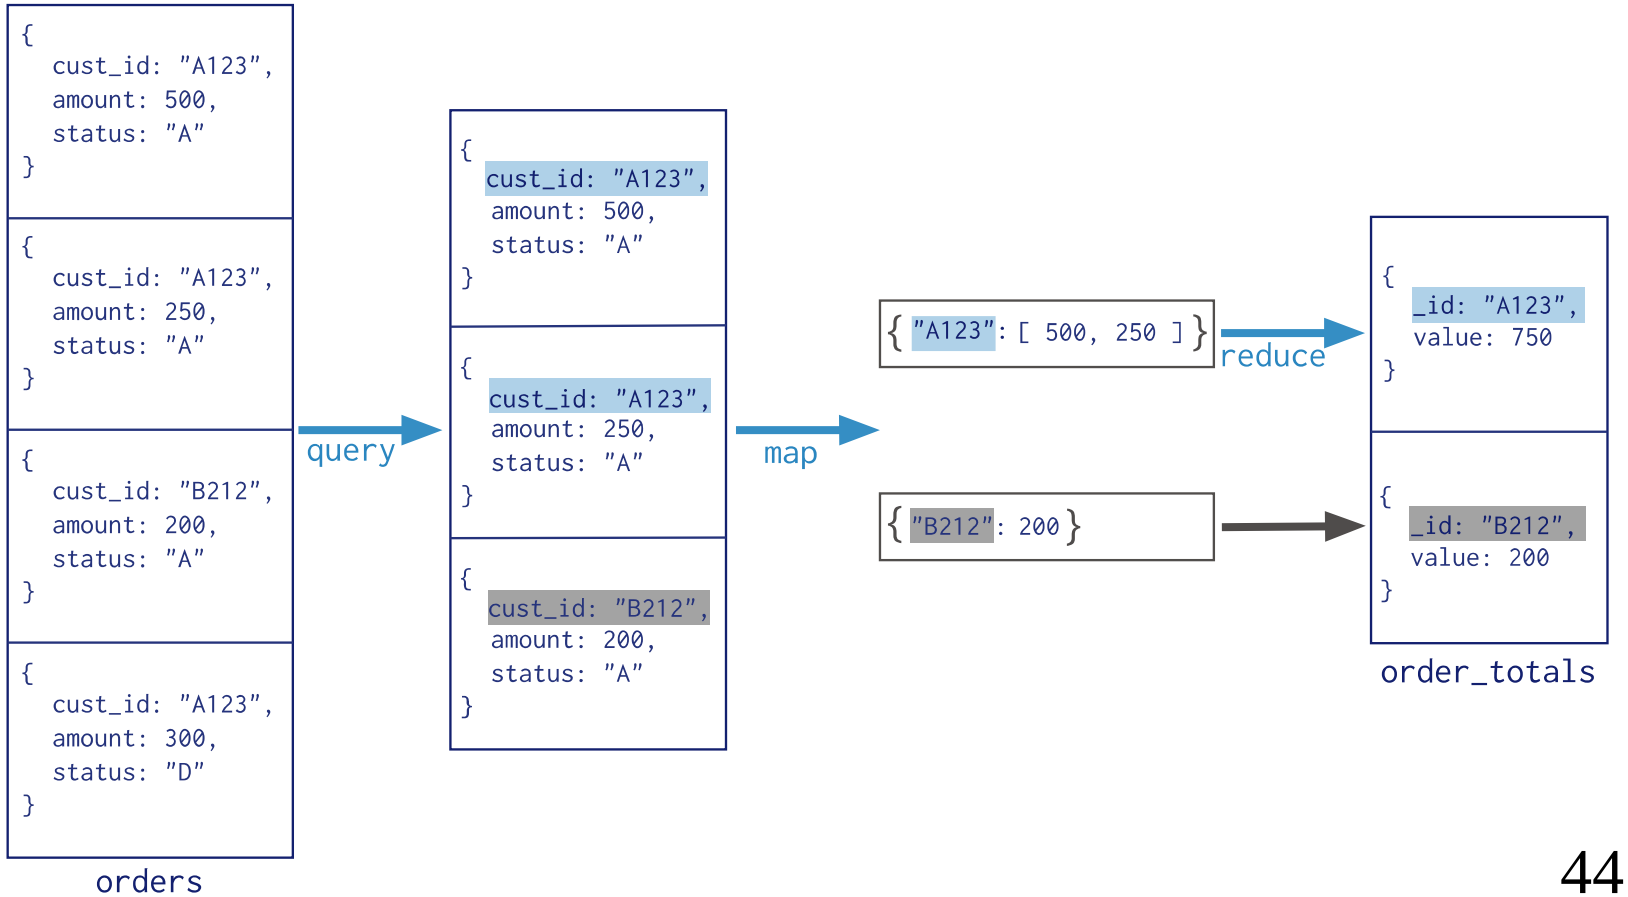

https://docs.mongodb.com/manual/crud/

MongoDB : opérations CRUD (`update`)

```
db.users.updateMany(
   { age: { $lt: 18 } },
   { $set: { status: "reject" } }
)
```

MongoDB : opérations CRUD (`delete`)

```
db.users.deleteMany(
   { status: "reject" }
)
```

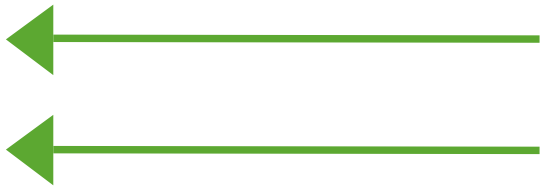

MongoDB : possibilités de requêtage

- Possibilité de faire des requêtes d'agrégation et d'utiliser *map-reduce*
- Recherche textuelle
- Gestion de données spatiales
  - Données modélisées en GeoJSON (http://geojson.org/)

```
location: {
      type: "Point",
      coordinates: [-73.856077, 40.848447]
}
```

  - Requêtes spatiales (cf. https://docs.mongodb.com/manual/geospatial-queries/)

MongoDB : atomicité

- Ecriture d'un document = opération atomique
- Ecriture de plusieurs documents est atomique pour chacun des documents, mais pas pour l'ensemble
- Ecritures atomiques $\Rightarrow$ impact sur le design des documents et des collections
- Nécessité de s'assurer de maintenir la cohérence des données

MongoDB : réplication (1/2)

- *Replicat set* : grappe de serveurs partageant des copies d'un même ensemble de documents
- *Primary* : Un des nœuds avec le rôle de maître
- *Secondaries* : autres nœuds esclaves

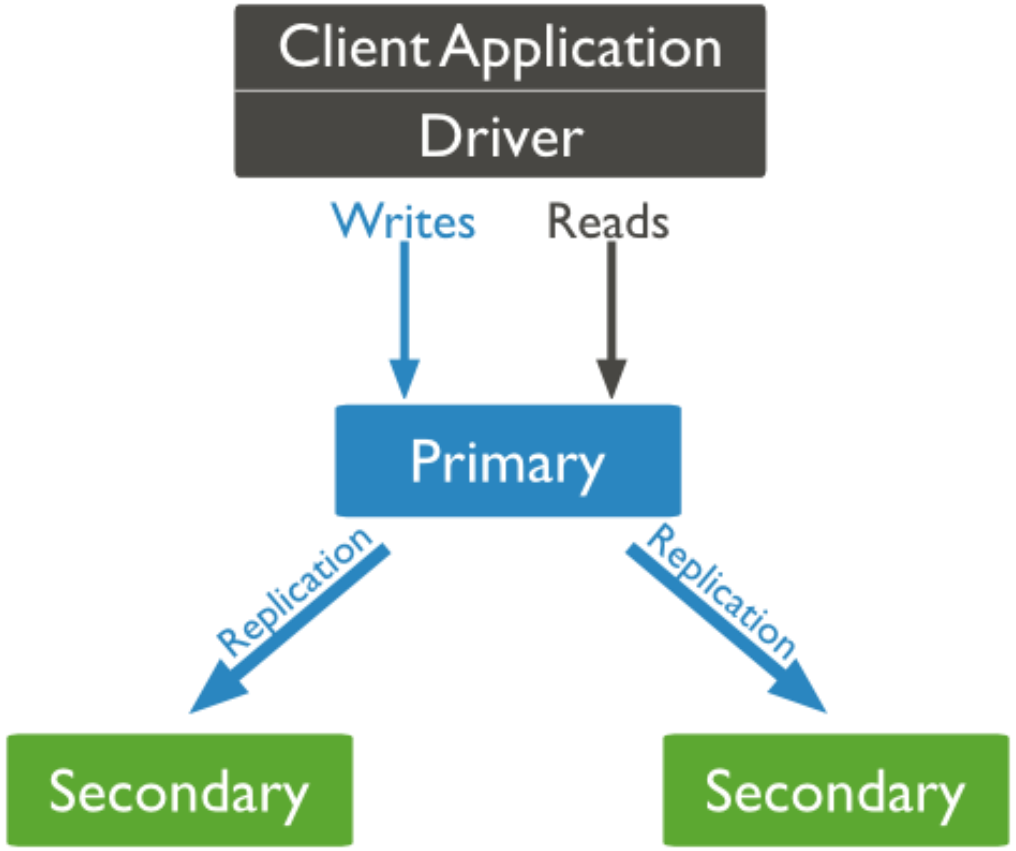

MongoDB : réplication (2/2)

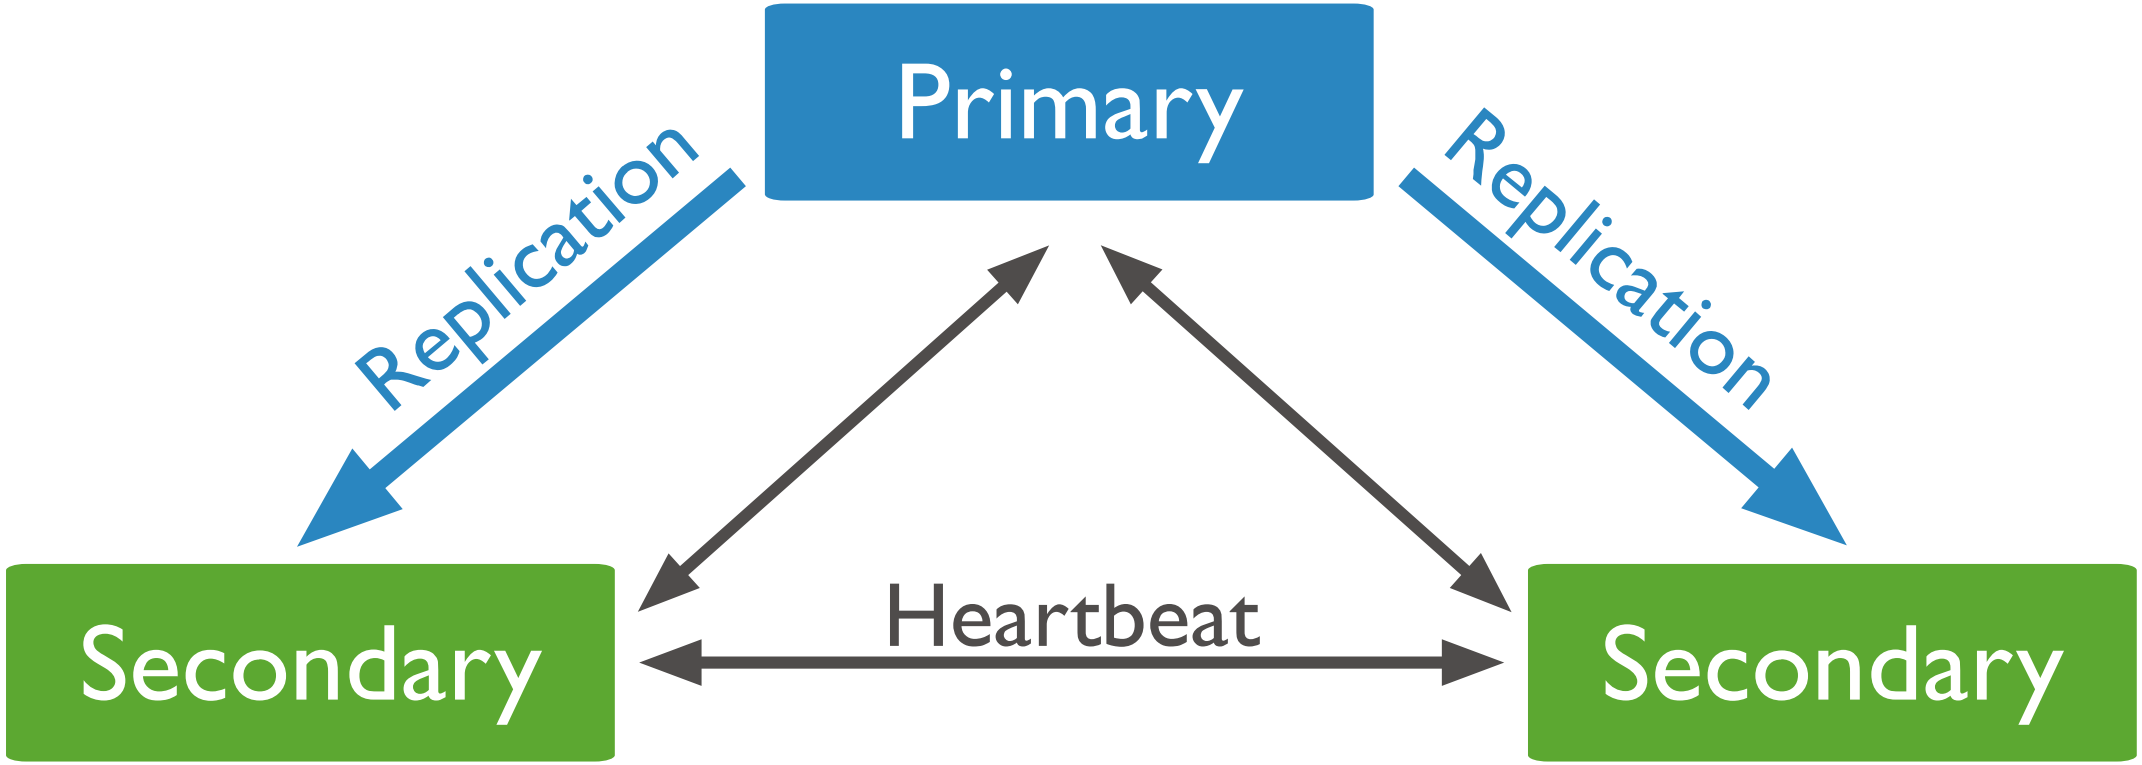

MongoDB : élection d'un nouveau maitre

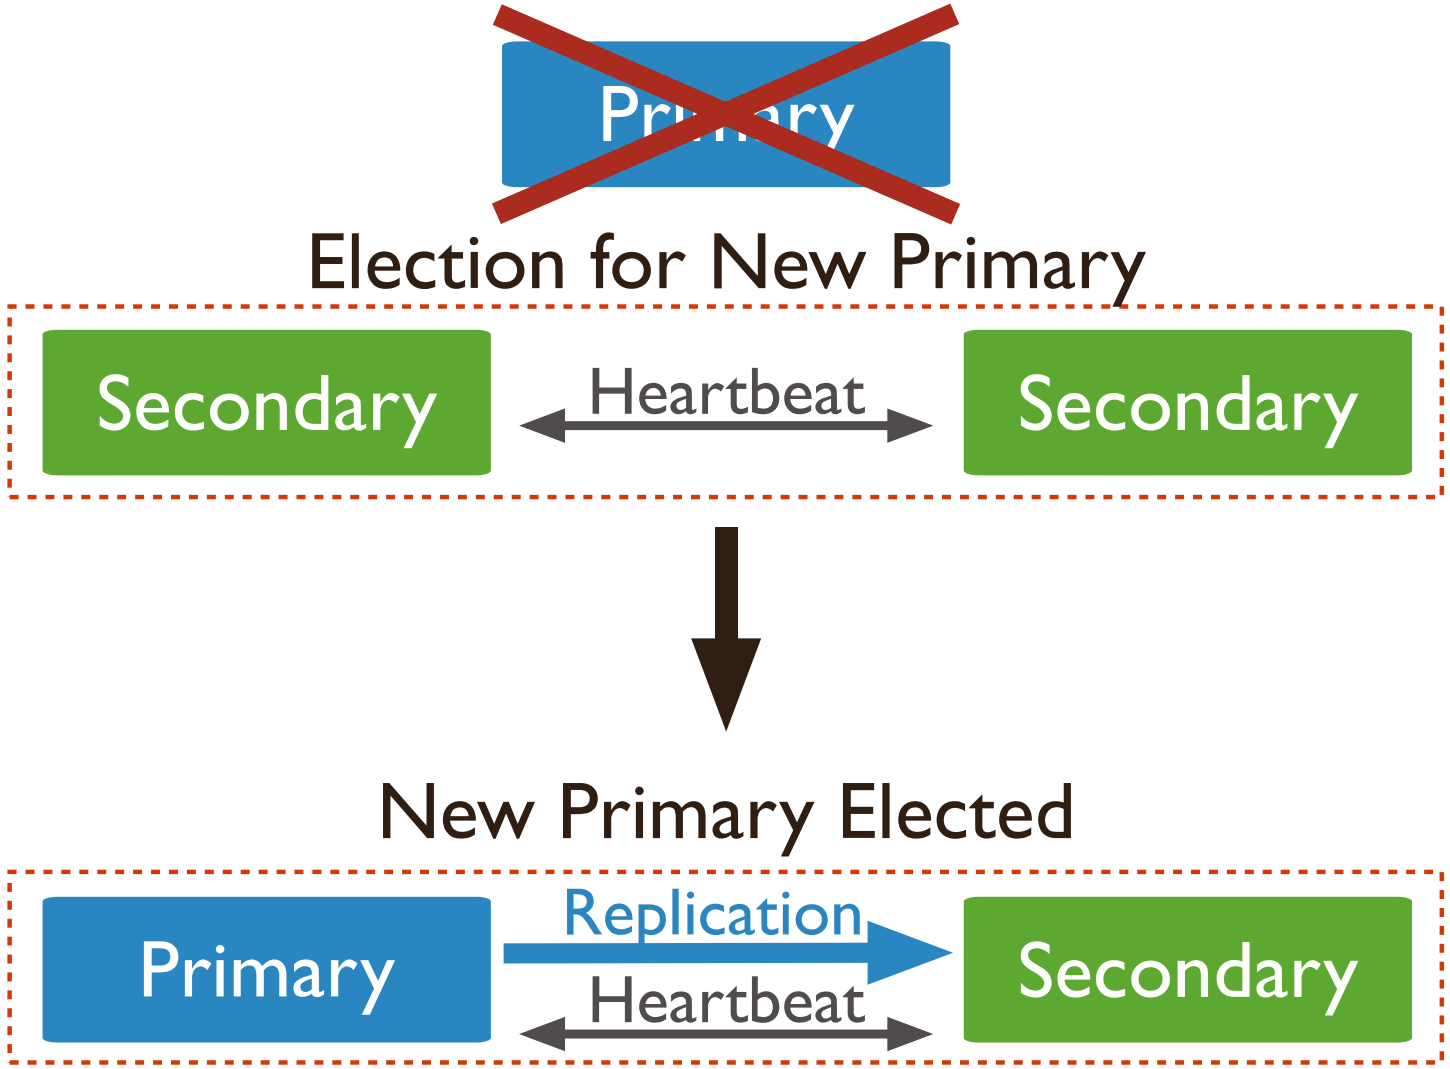

MongoDB : arbitre

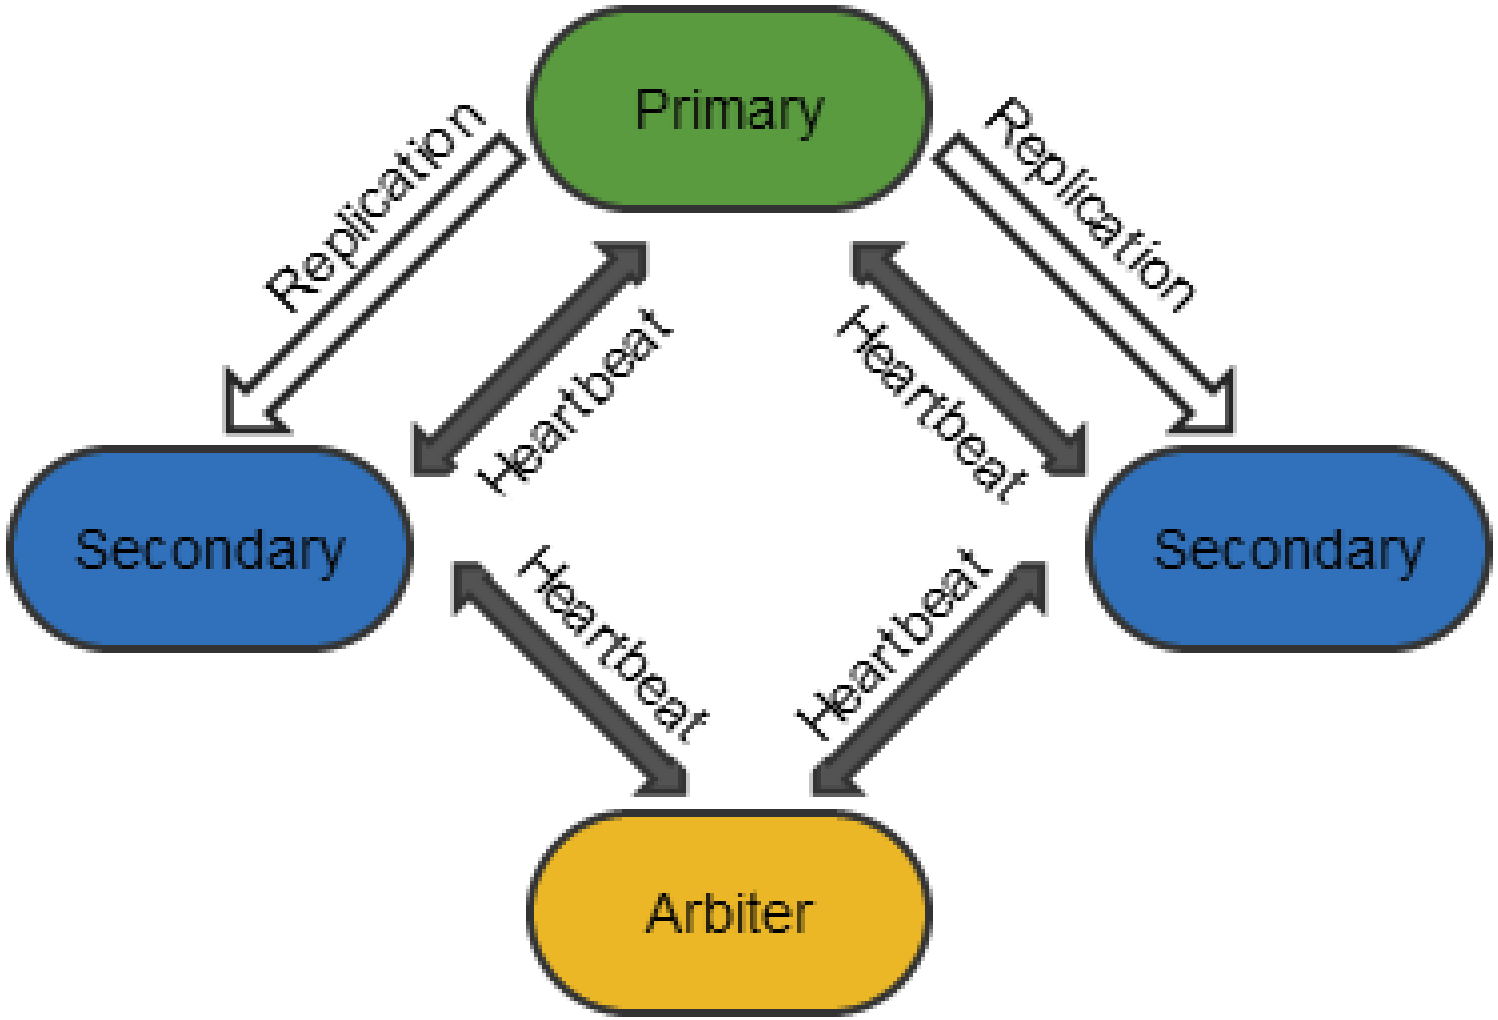

MongoDB : répartition
Principaux composants

- *Sharding* : distribution des blocs de données (*chunk*)
- *Cluster* : géré par 3 types de nœuds (serveurs)
  - Routeurs (*mongos*) : routage des requêtes
  - Serveurs de configuration (*Config Server) :* connaissance du réseau
  - Serveurs de données (*Shard*) : stockage de l'ensemble des données
- Composition minimum d'un cluster : 2 *mongos*, 3 *Config Servers* et 2 *shards*

MongoDB : configuration minimum

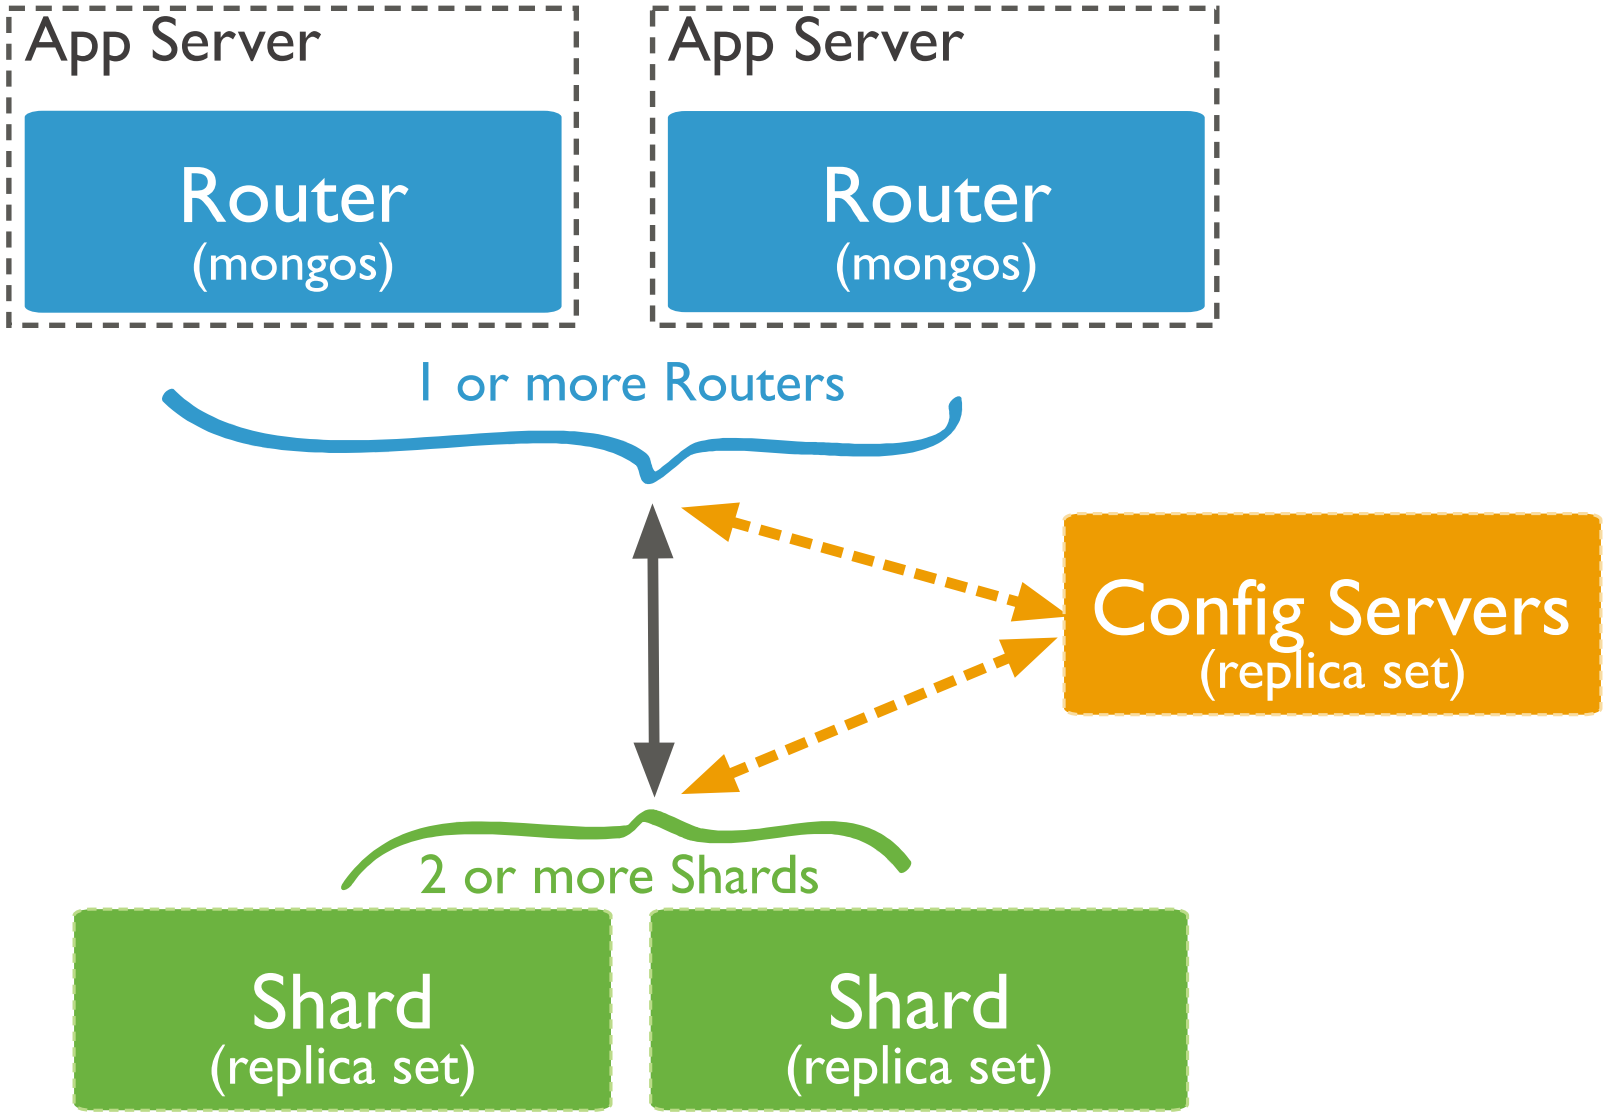

MongoDB : Rôle du *router* et des *shards*

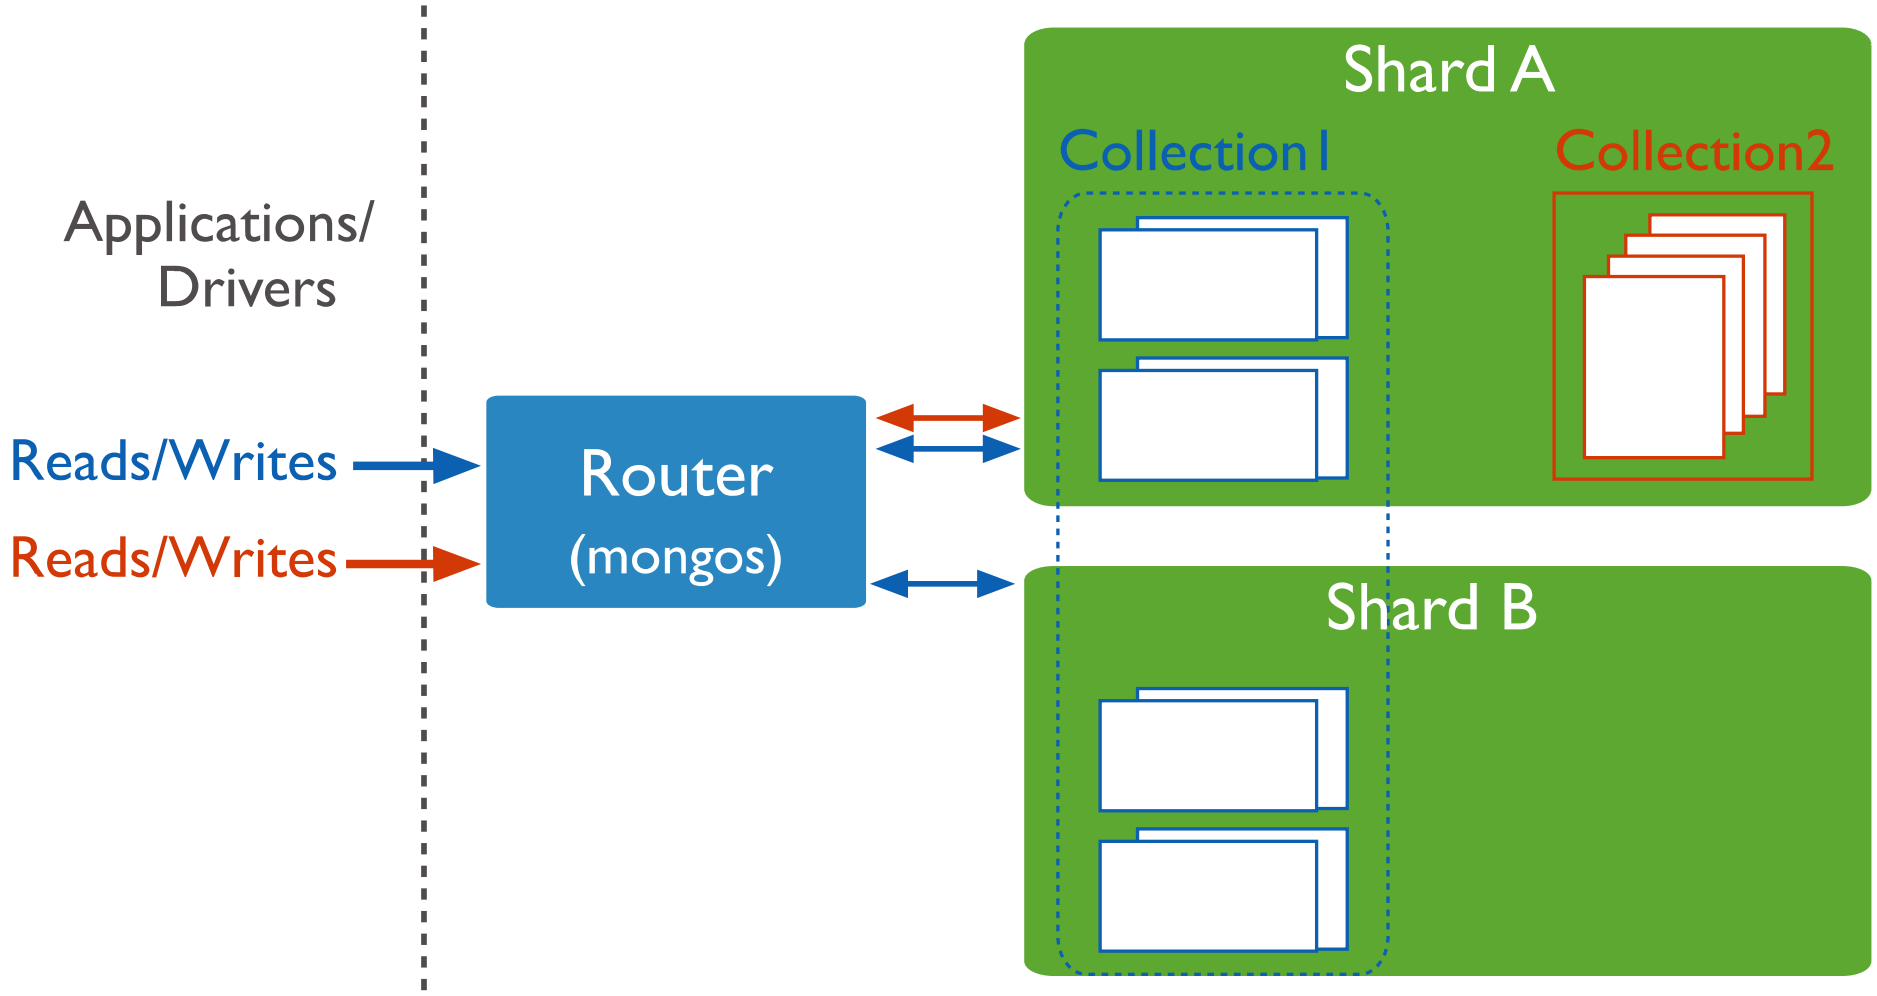

MongoDB : cluster de *shards*

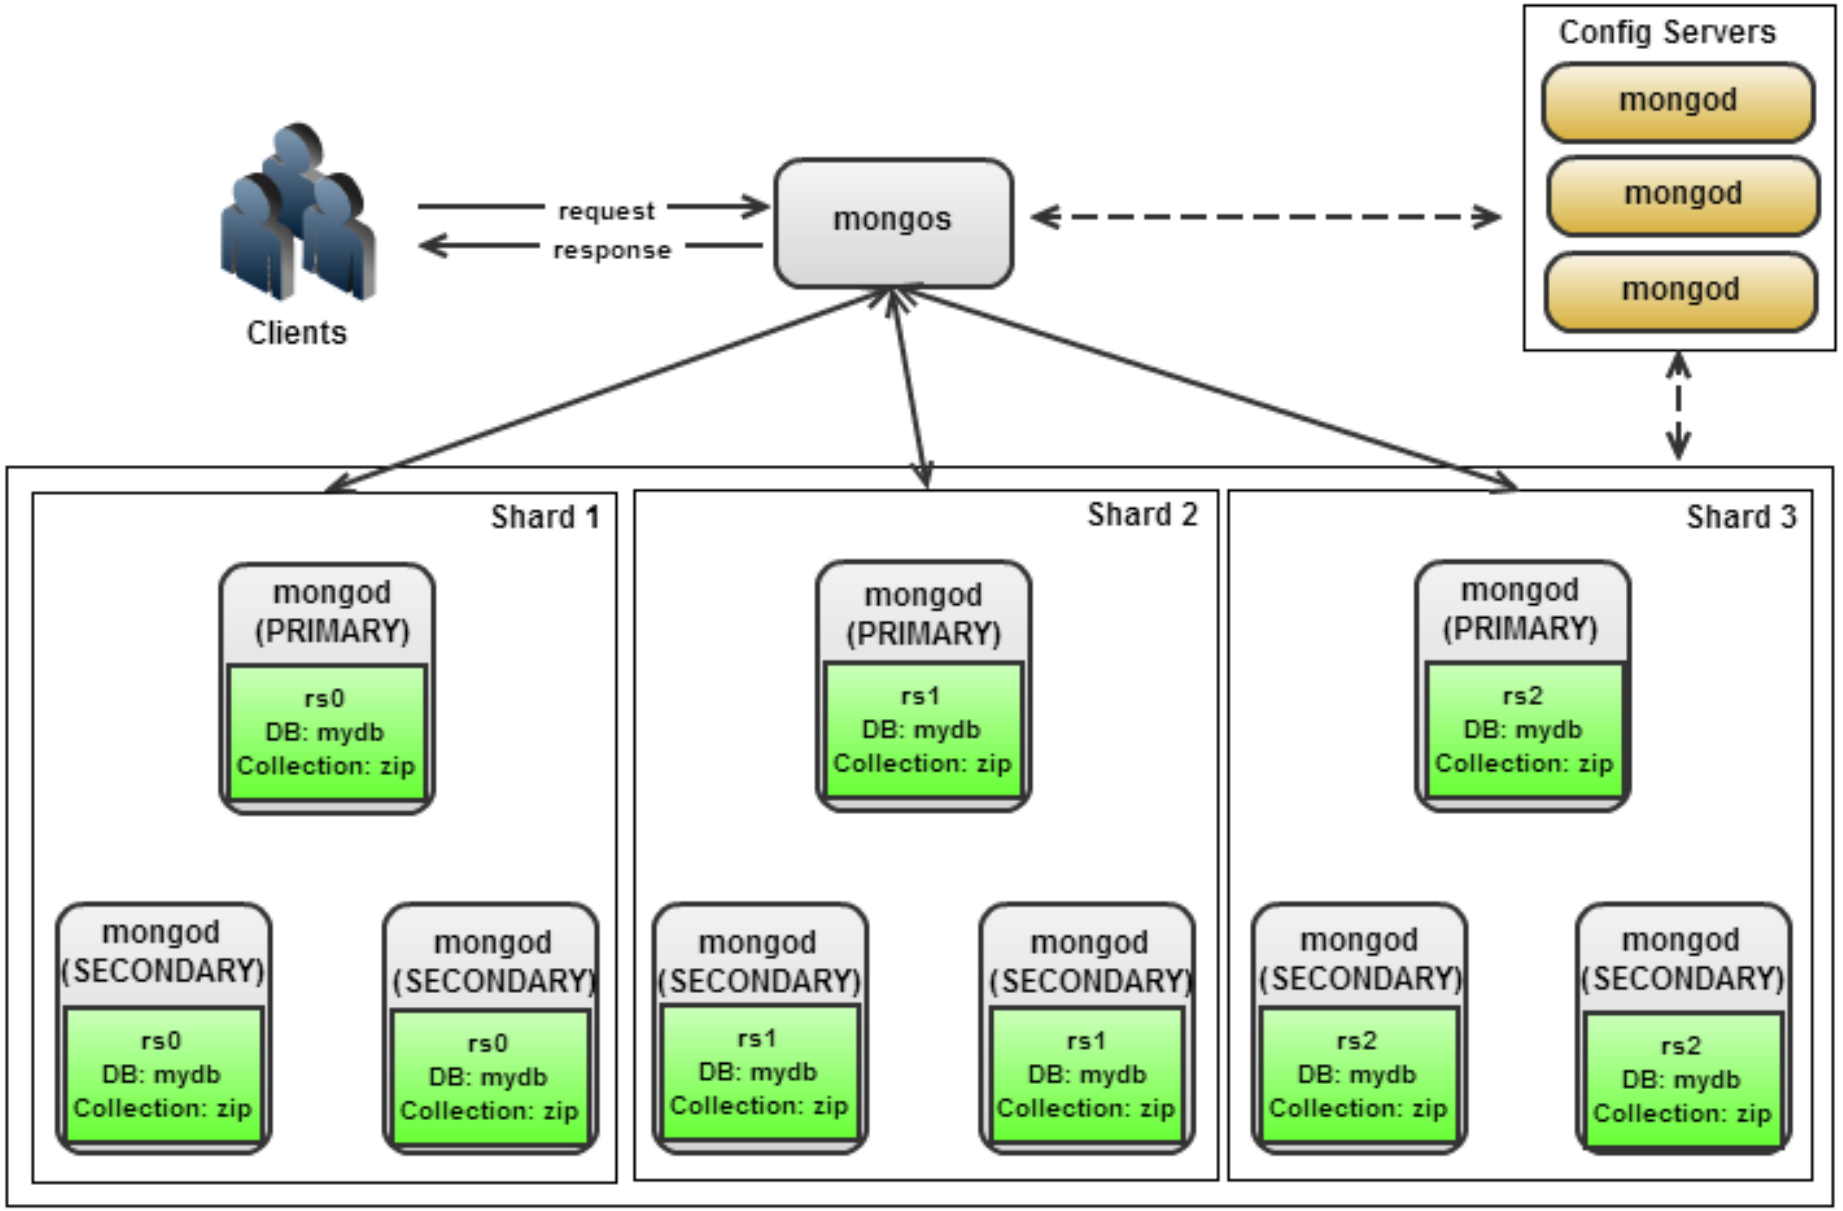

MongoDB : composition de *shards*

Shard : ensemble de blocs de données (***chunks***)

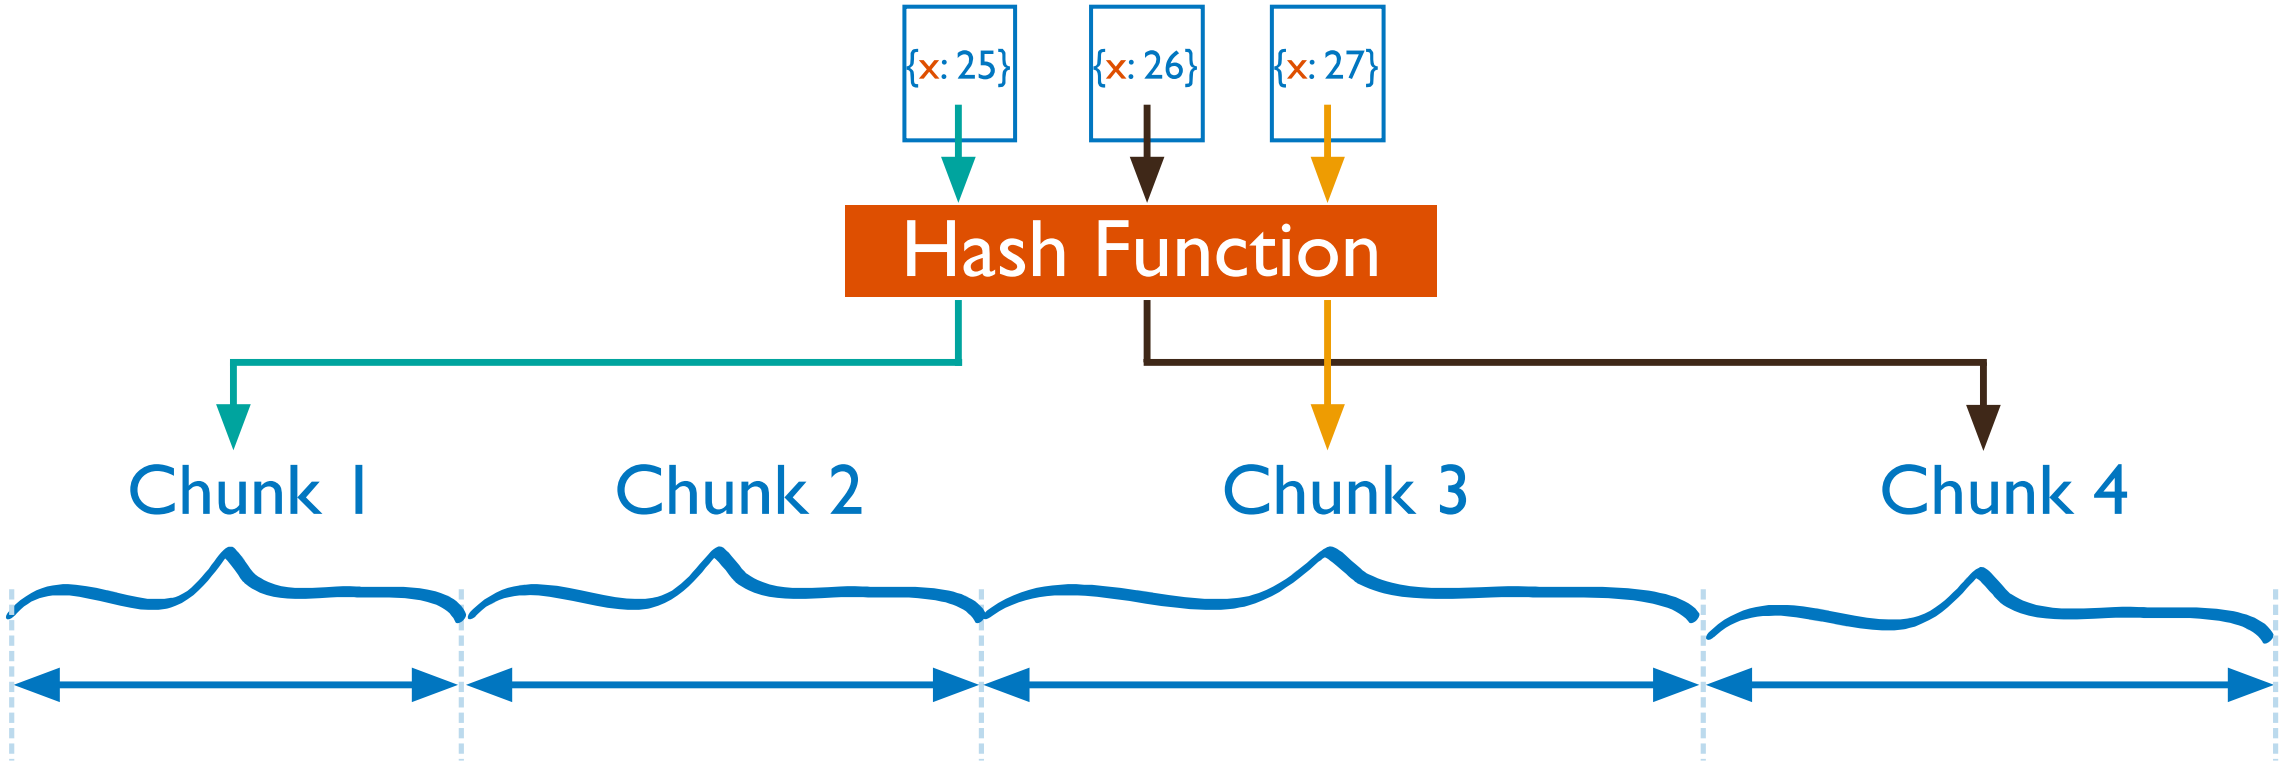

Répartition (*sharding)* des blocs de données (*chunk*) définie par un tri des données

MongoDB : *Chunk*

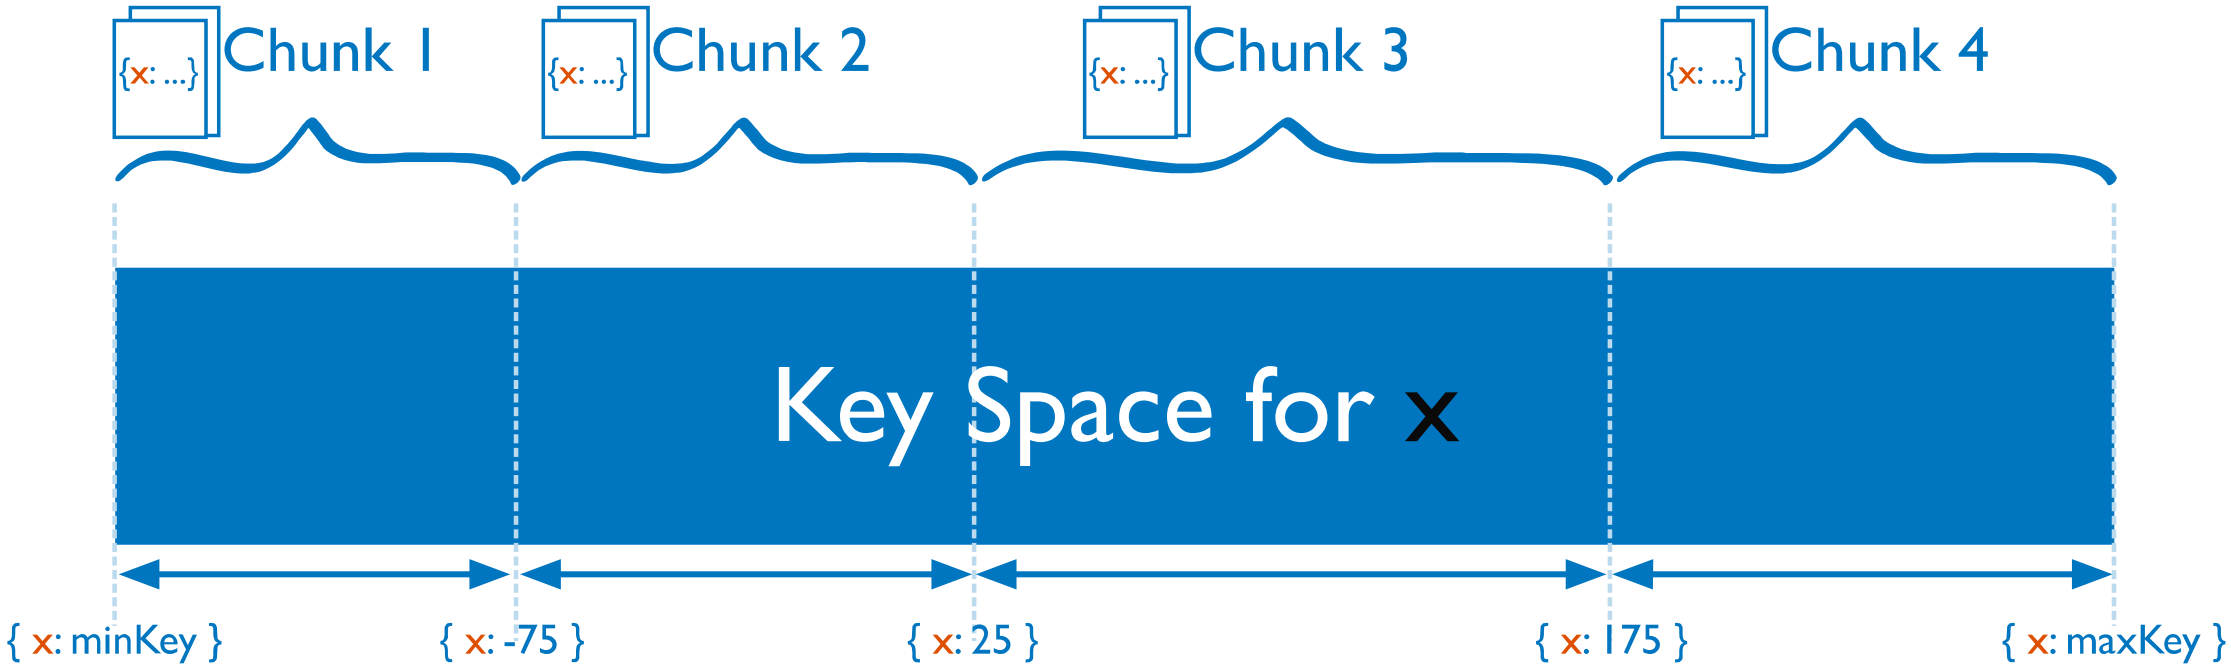

MongoDB : répartition d'une collection

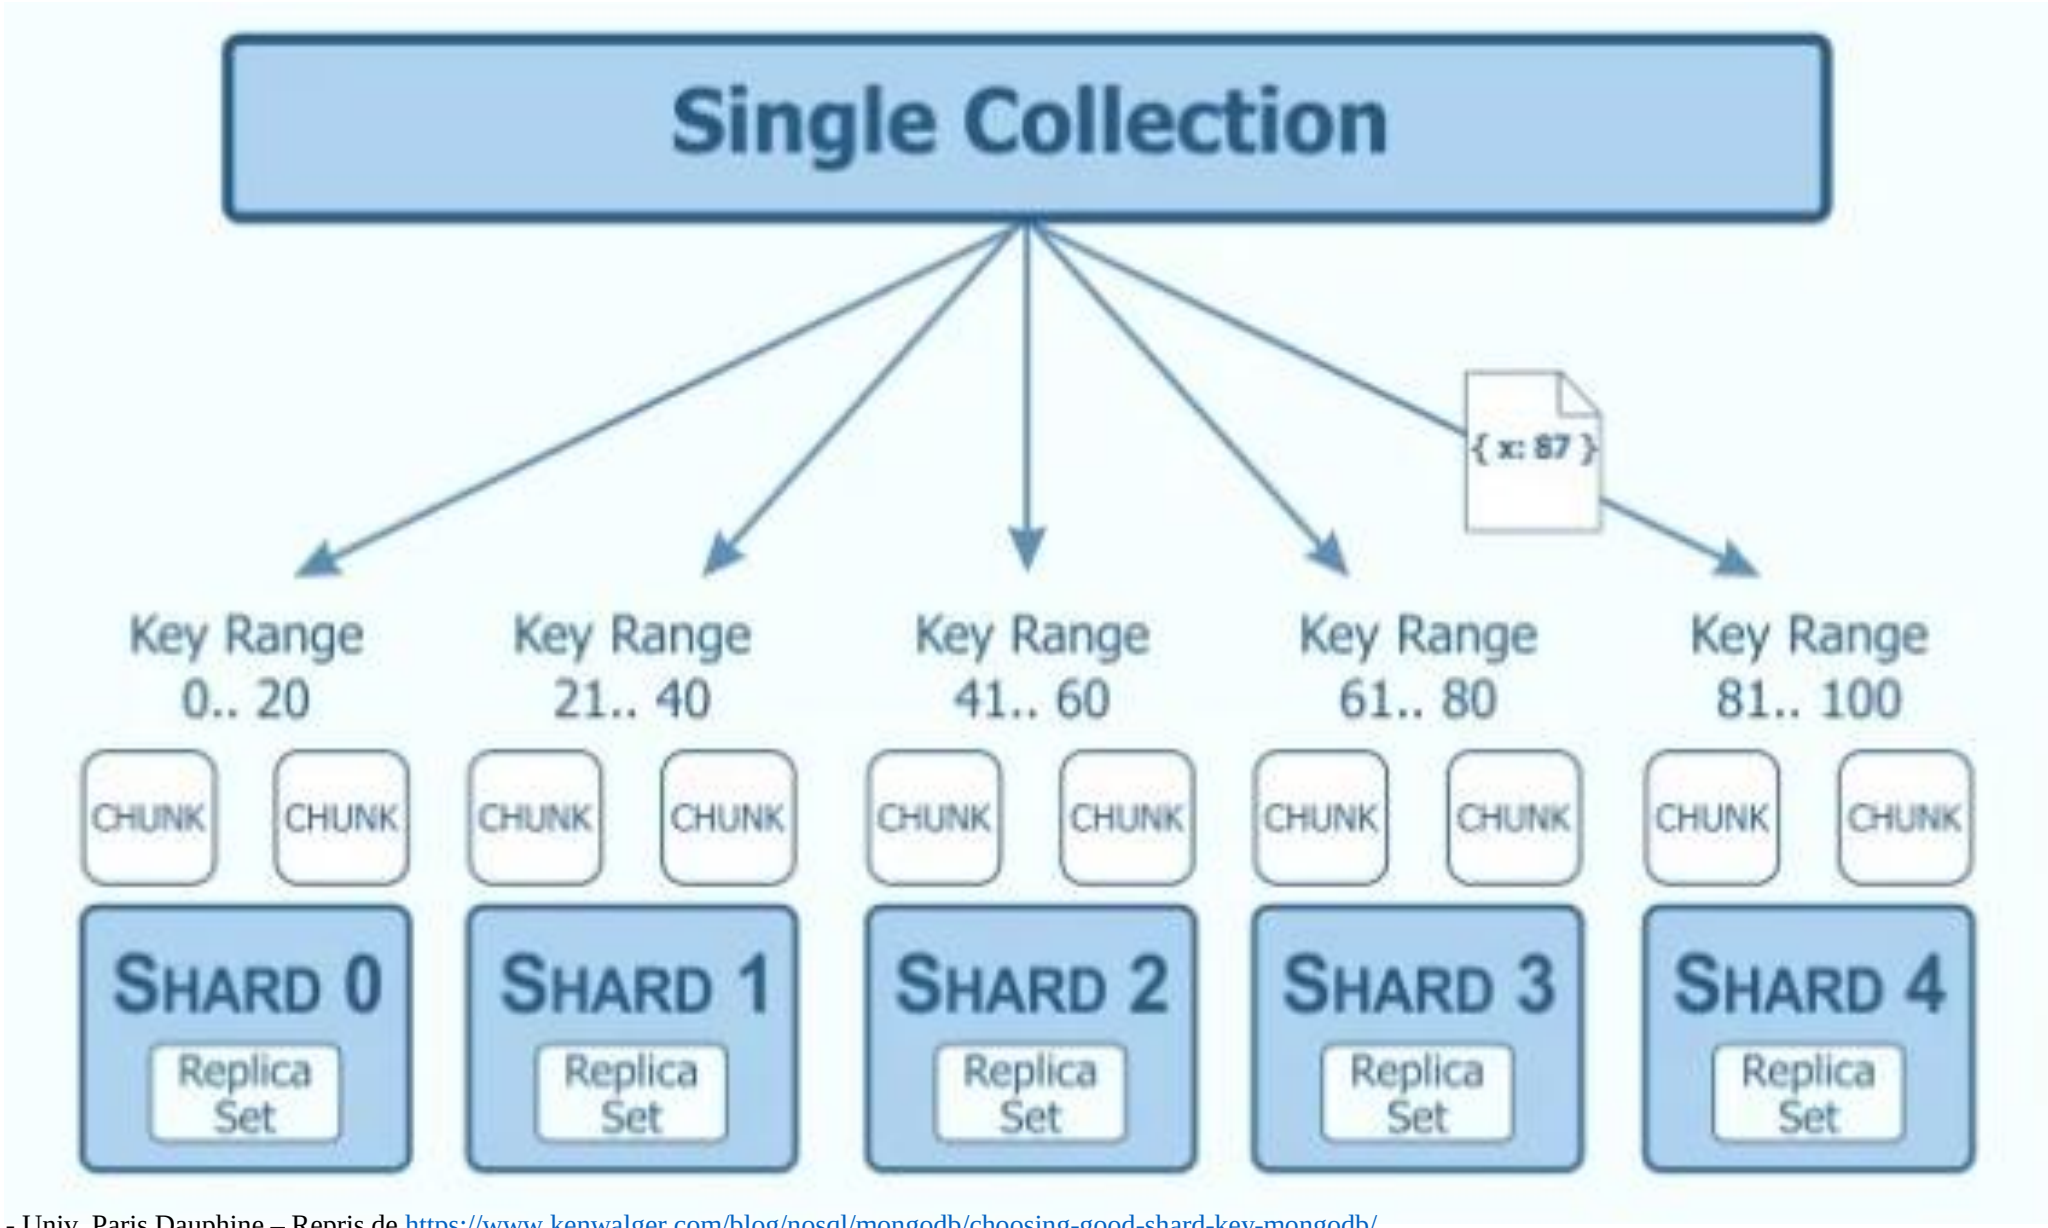

MongoDB : répartition (résumé)

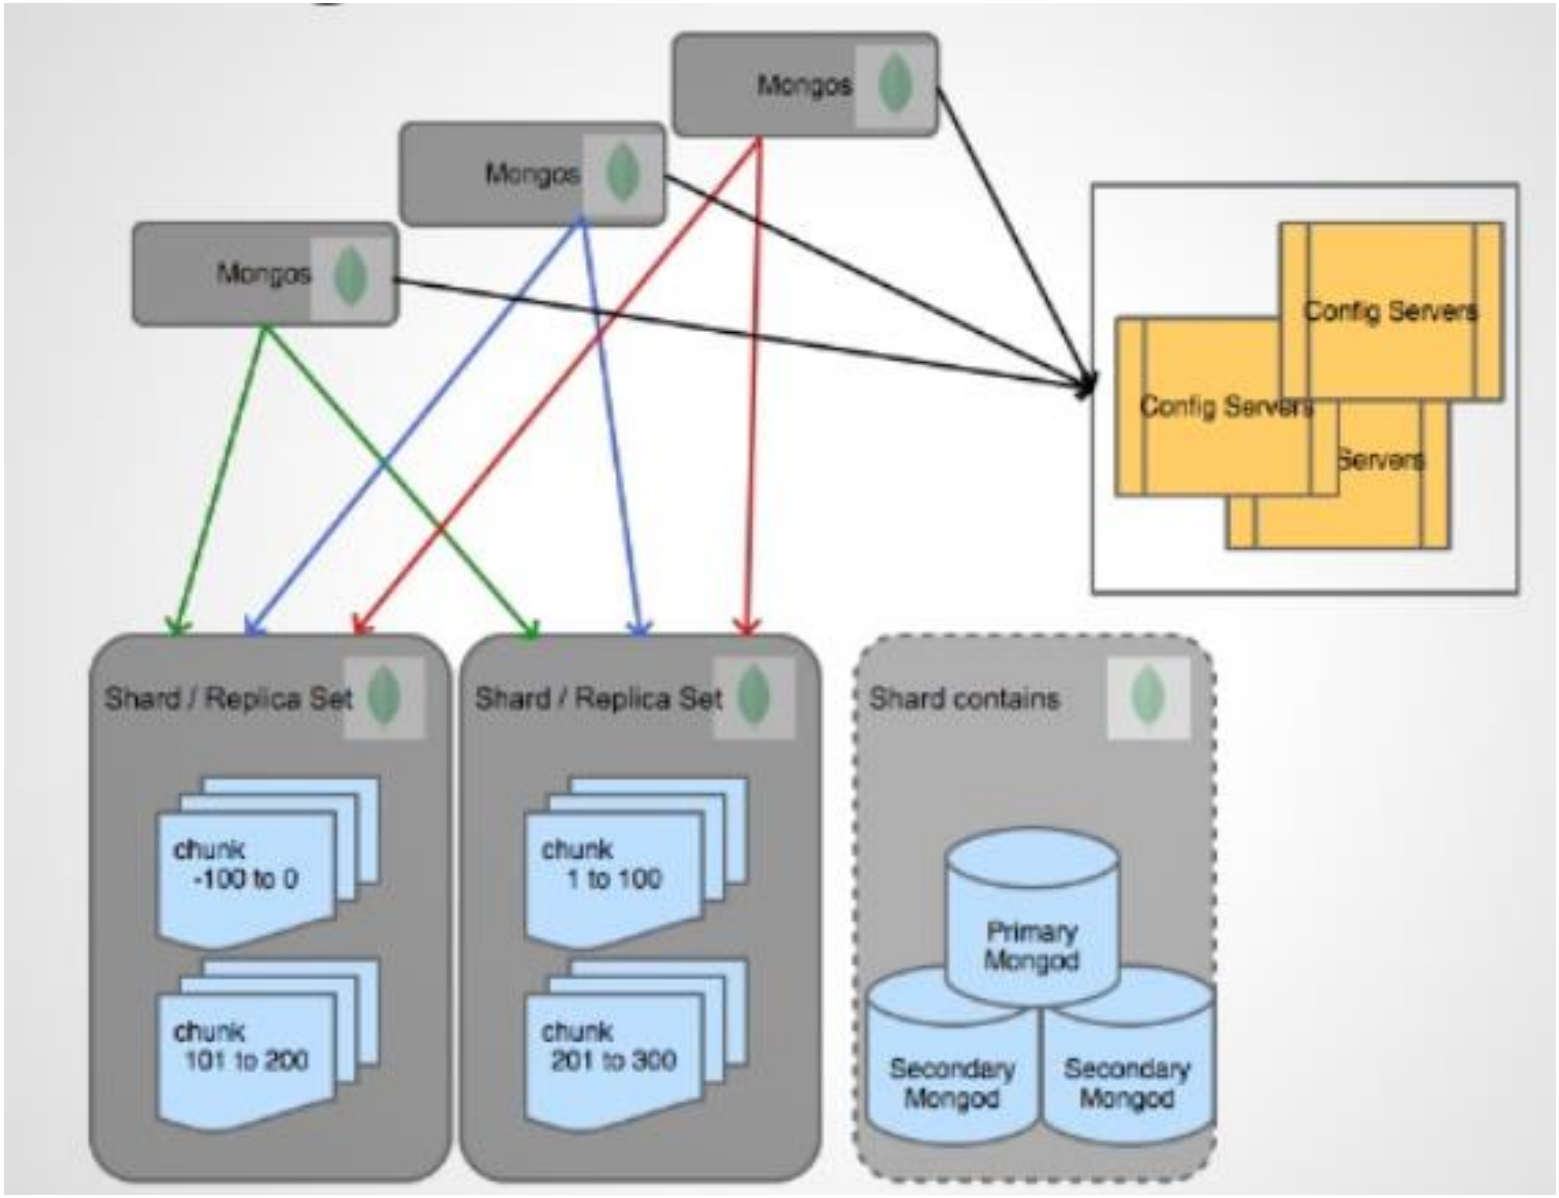

MongoDB : conclusion


Flexibilité dans le stockage des données


Montée en charge


Requêtes


Pas de jointure


Transactions (en amélioration)


Gestion de la mémoire

CouchBase

- Moteur de recherche distribué, orienté-document et clé-valeur
- Dispose d'un outil de requêtage inspiré de SQL : N1QL
- A vu le jour en juin 2010 sous le nom de *Membase*
- Fusion en 2011 avec celle de *CouchOne* qui supportait *CouchDB*, une base de données de documents basée sur une approche pair-à-pair pour la réplication
- CouchBase : combinaison des parties de *Membase* avec des parties de *CouchDB*

CouchBase : liens utiles et positionnement

- Site officiel : https://www.couchbase.com/
- Cours en ligne : http://b3d.bdpedia.fr/couchbase.html
- Tutoriel N1QL en ligne :

  https://query-tutorial.couchbase.com/tutorial/#1

☐ include secondary database models — 56 systems in ranking, February 2023

Rank Feb 2023	Rank Jan 2023	Rank Feb 2022	DBMS	Database Model	Score Feb 2023	Score Jan 2023	Score Feb 2022
1.	1.	1.	MongoDB	Document, Multi-model	452.77	-2.42	-35.88
2.	2.	2.	Amazon DynamoDB	Multi-model	79.69	-1.87	-0.67
3.	3.		Databricks	Multi-model	60.33	-0.49	
4.	4.	↓ 3.	Microsoft Azure Cosmos DB	Multi-model	36.51	-1.45	-3.45
5.	5.	↓ 4.	Couchbase	Document, Multi-model	24.86	-0.44	-5.21

https://db-engines.com/en/ranking/document+store

CouchBase : architecture

- Fondé sur une architecture SNA pour *Shared-Nothing Architecture*
- Agrégation de serveurs derrière un ou plusieurs serveurs applicatifs frontaux
- Serveur *Couchbase* composé de deux grandes parties : une qui gère l'accès et le stockage des données et l'autre qui gère l'administration du cluster

CouchBase : principes

- Sauvegarde des données sous la forme d'*items*
- *Item* : 1 clé et une valeur (binaire ou document JSON)
- Documents distribués uniformément au travers du cluster
- *Items* stockés dans des *buckets* (conteneurs de documents)
- *Bucket* : groupement logique de ressources physiques au sein d'un cluster, associé à de la mémoire RAM pour mettre les données en cache, et à un nombre défini de réplicas
- Découpage de chaque *bucket* en 1024 partitions logiques appelés *vBuckets*
- Partitions *mappées* à des serveurs du cluster
- Données du *mapping* stockées dans le *cluster map*

CouchBase : organisation des composants

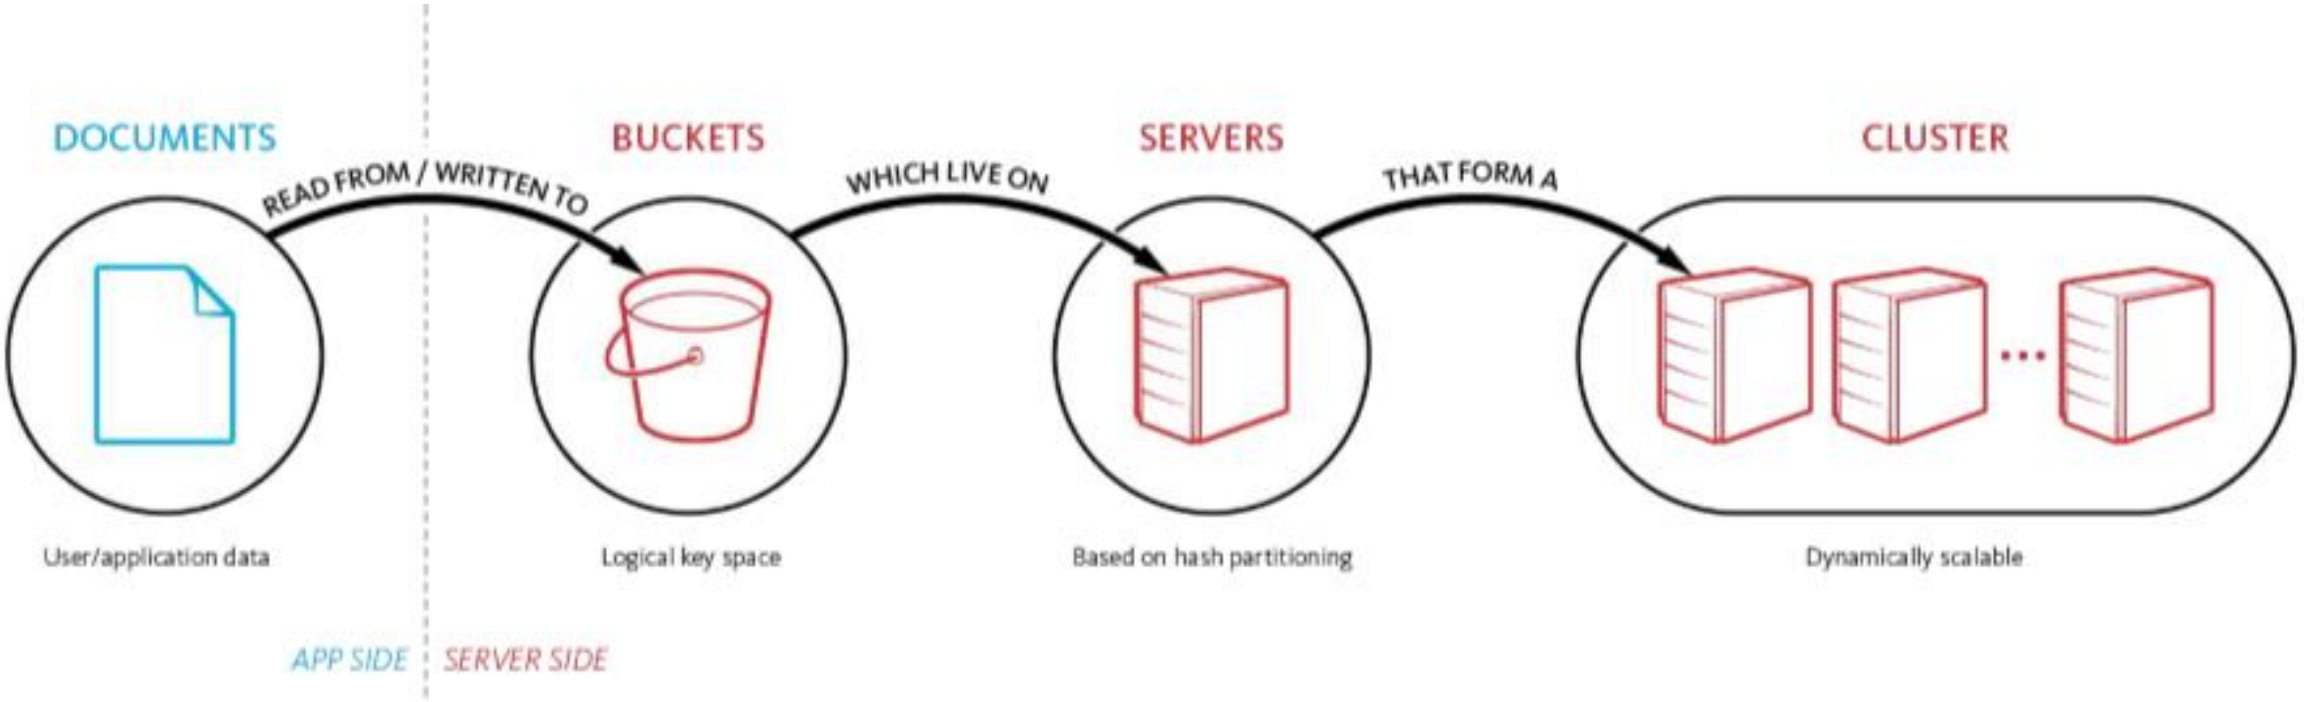

CouchBase : réplication

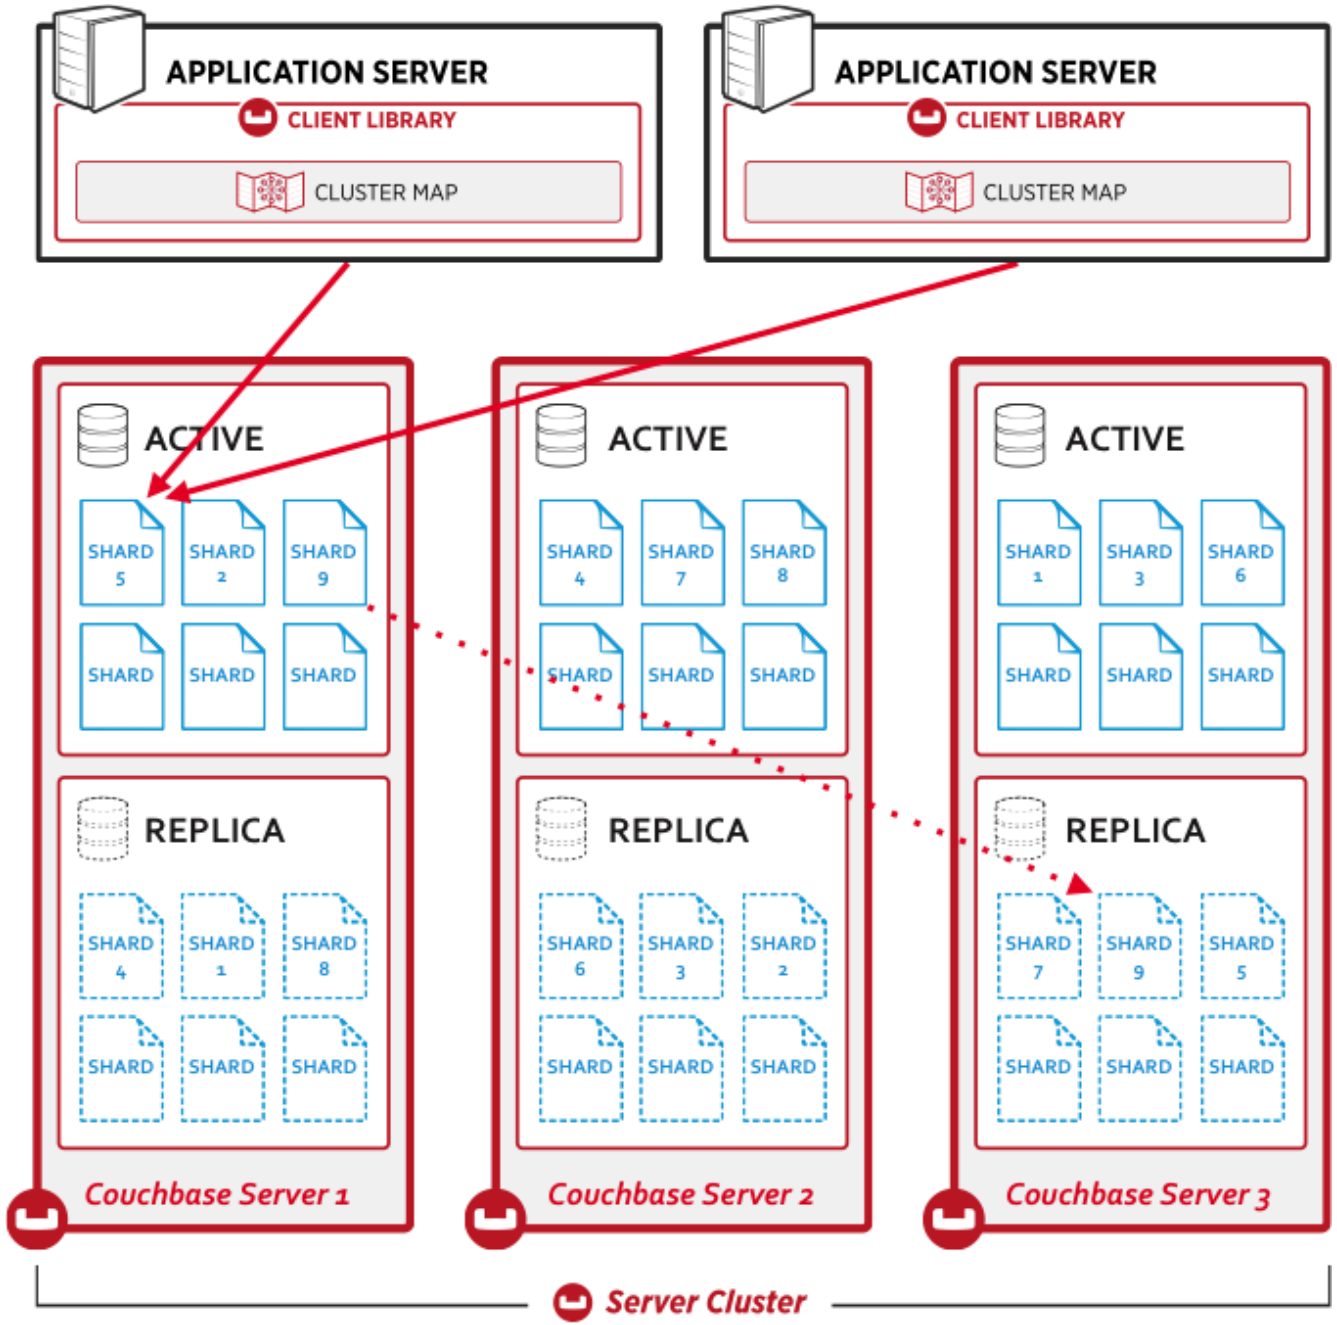

Langage N1QL : exemple de requête renvoyant un document

Query

```
SELECT *
  FROM tutorial
    WHERE fname = 'Ian'
```

```
{
  "results": [
    {
      "tutorial": {
        "type": "contact",
        "title": "Mr.",
        "fname": "Ian",
        "lname": "Taylor",
        "age": 56,
        "email": "ian@gmail.com",
        "children": [
          {
            "fname": "Abama",
            "age": 17,
            "gender": "m"
          },
          {
            "fname": "Bebama",
            "age": 21,
            "gender": "m"
          }
        ],
```

Langage N1QL : exemple de requête renvoyant un sous-document

```
SELECT children[0].fname AS child_name
    FROM tutorial
       WHERE fname='Dave'
```

```
"tutorial": {
  "type": "contact",
  "title": "Mr.",
  "fname": "Dave",
  "lname": "Smith",
  "age": 46,
  "email": "dave@gmail.com",
  "children": [
    {
      "fname": "Aiden",
      "age": 17,
      "gender": "m"
    },
    {
      "fname": "Bill",
      "age": 2,
      "gender": "f"
    }
  ],
  "hobbies": [
    "golf",
    "surfing"
```

Results

```
{
  "results": [
    {
      "child_name": "Aiden"
    }
  ]
}
```

Langage N1QL : exemple de requête sur les méta-données et les valeurs NULL

```
SELECT META(tutorial) AS meta
    FROM tutorial
```


```
{
  "results": [
    {
      "meta": {
        "id": "dave"
      }
    },
    {
      "meta": {
        "id": "earl"
      }
    },
    {
      "meta": {
        "id": "fred"
      }
    },
    {
      "meta": {
        "id": "harry"
      }
    },
```


```
SELECT fname, children
    FROM tutorial
        WHERE children IS NULL
```


```
{
  "results": [
    {
      "children": null,
      "fname": "Fred"
    }
  ]
}
```

Langage N1QL : exemple de calculs et d'agrégation

```
SELECT COUNT(*) AS count
    FROM tutorial
```

```
{
  "results": [
    {
      "count": 6
    }
  ]
}
```

```
SELECT relation, COUNT(*) AS count
    FROM tutorial
        GROUP BY relation
```

```
{
  "results": [
    {
      "count": 2,
      "relation": "friend"
    },
    {
      "count": 1,
      "relation": "coworker"
    },
    {
      "count": 1,
      "relation": "parent"
    },
    {
      "count": 2,
      "relation": "cousin"
    }
  ]
}
```

Langage N1QL : exemple de jointure

```
{
  "usr": {
    "doc_type": "user_profile",
    "personal_details": {
      "age": 60,
      "display_name": "Elinor Ritchie",
      "email": "Elinor.Ritchie@snailmail.com",
      "first_name": "Elinor",
      "last_name": "Ritchie",
      "state": "Arizona"
    },
  "shipped_order_history": [
    {
      "order_datetime": "Wed May 30 22:00:09 2012'
      "order_id": "T103929516925"
    },
    {
      "order_datetime": "Thu Aug  4 22:00:09 2011'
      "order_id": "T573145204032"
    }
```

```
"orders": {
  "doc_type": "order",
  "order_details": {
    "order_datetime": "Tue Sep 20 18:53:39 2011",
    "order_id": "T499723387040"
  },
  "payment_details": {
    "payment_mode": "Cash On Delivery",
    "total_charges": 33
  },
  "product_details": {
    "currency": "USD",
    "list_price": 31,
    "pct_discount": 10,
    "product_id": "P9928726217",
    "sale_price": 28
```

```
SELECT usr.personal_details, orders
    FROM users_with_orders usr
        USE KEYS "Elinor_33313792"
            JOIN orders_with_users orders
                ON KEYS ARRAY s.order_id FOR s IN usr
.shipped_order_history END
```

```
"orders": {
  "doc_type": "order",
  "order_details": {
    "order_datetime": "Wed Jun  6 18:53:39 2012",
    "order_id": "T103929516925"
  },
  "payment_details": {
    "payment_mode": "Debit Card",
    "total_charges": 308
  },
  "product_details": {
    "currency": "EUR",
    "list_price": 318,
    "pct_discount": 5,
    "product_id": "P3109994453",
    "sale_price": 303
  },
  "shipping_details": {
    "shipping_charges": 5,
    "shipping_status": "Delivered",
    "shipping_type": "Express"
```

CouchBase : exécution d'une requête

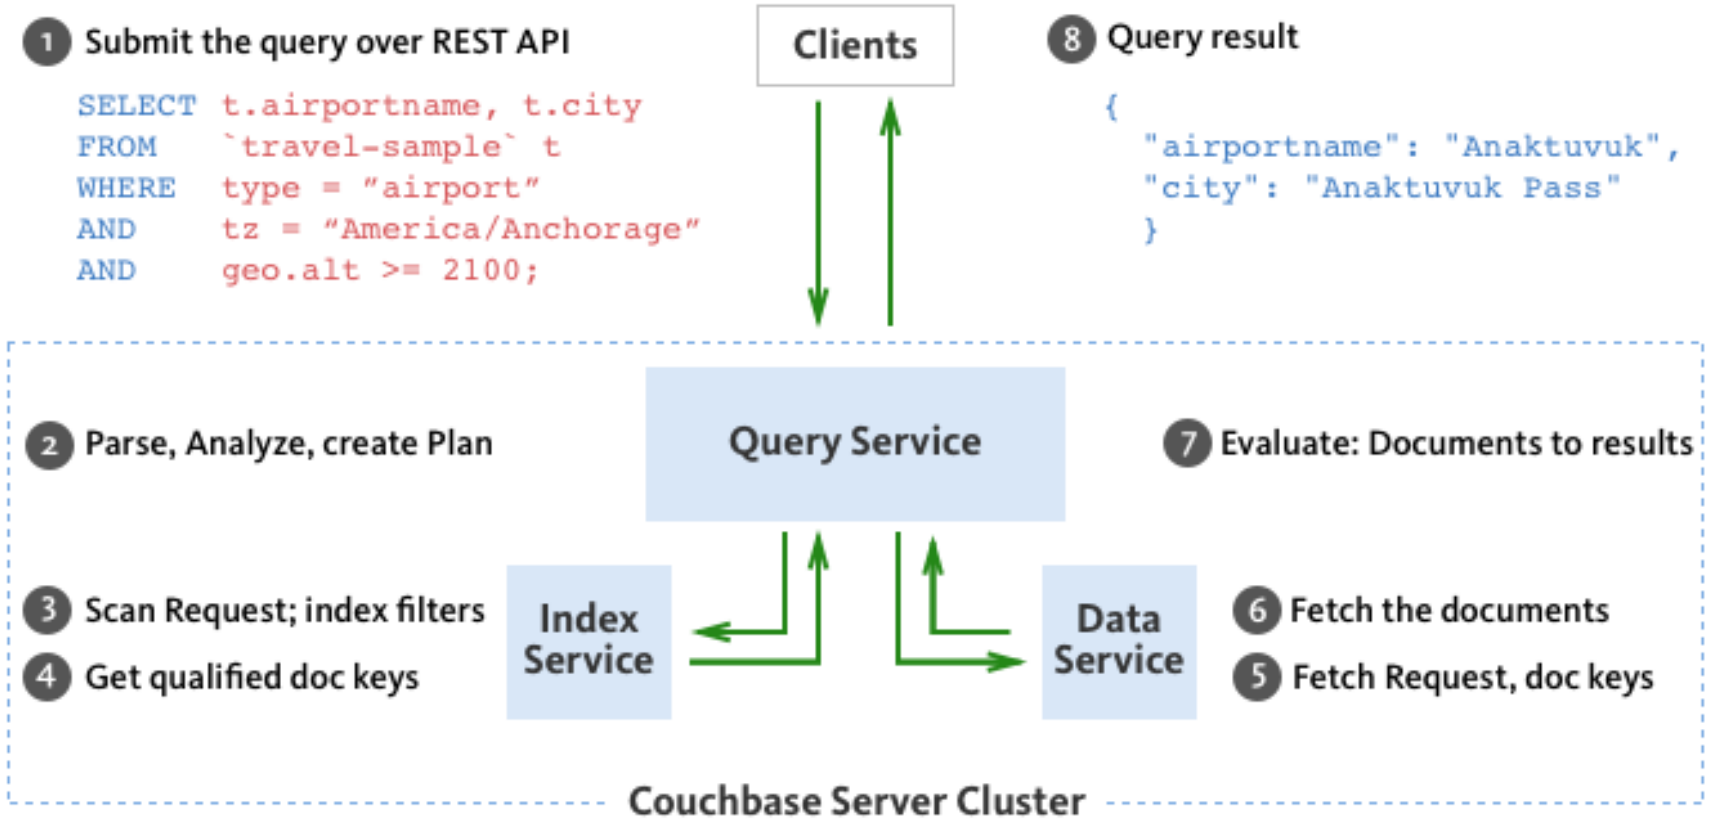

CouchBase : accès au plan d'exécution d'une requête

Query Editor

← history (96/97) →

```
1  SELECT DISTINCT route.destinationairport
2  FROM `travel-sample` airport JOIN `travel-sample` route
3       ON airport.faa = route.sourceairport
4          AND route.type = "route"
5  WHERE airport.type = "airport"
6    AND airport.city = "San Francisco"
7    AND airport.country = "United States";
```

Execute | Explain | ✔ explain success | elapsed: 3.76ms | execution: 3.74ms | count: 1 | size: 1914 | preferences

Query Results

JSON | Table | Tree | Plan | Plan Text

Indexes	Buckets	Fields
travel-sample.airport_city_country	*travel-sample route*	*travel-sample.type travel-sample.city travel-sample.country route.destinationairport*

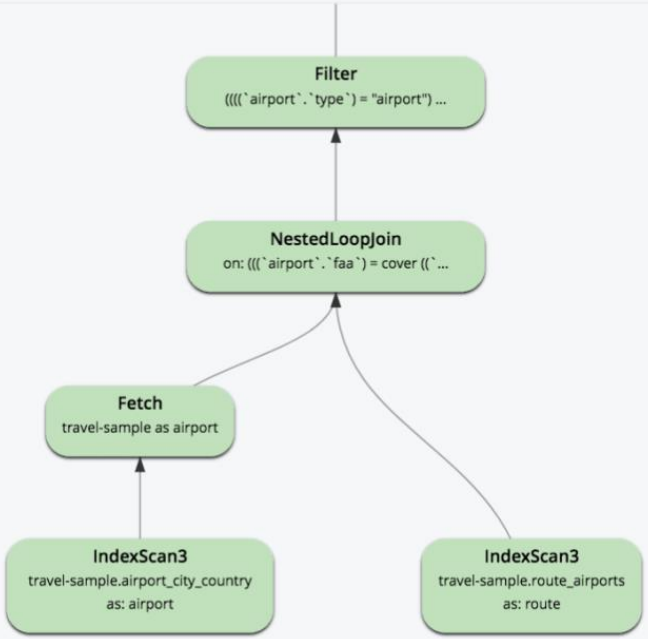

CouchBase vs MongoDB : liens vers de comparaisons

- System Properties Comparison Couchbase vs. MongoDB : https://db-engines.com/en/system/Couchbase%3BMongoDB
- Joining JSON: Comparing Couchbase N1QL and MongoDB (2020) : https://dzone.com/articles/introduction-to-couchbase-for-mongodb-developers-a-1
- Benchmarking NoSQL Databases (2019) : https://www.datanami.com/2019/01/16/benchmarking-nosql-databases/

CouchBase vs MongoDB : exemple de requête

MySQL

```
SELECT ac.industry,
 SUM(CASE WHEN a.activitytype = 'Task'
    THEN 1 ELSE 0 END ) task,
 SUM(CASE WHEN a.activitytype
='Appointment'
    THEN 1 ELSE 0 END ) appts
FROM crm.activity a
  INNER JOIN crm.account ac
     ON (a.accid = ac.id)
WHERE a.startdate BETWEEN '2018-10-01'
            AND   '2018-12-31'
GROUP BY ac.industry
```

Couchbase - N1QL

```
SELECT ac.industry,
  SUM(CASE WHEN a.activityType = 'Task'
    THEN 1 ELSE 0 END) task,
  SUM(CASE WHEN a.activityType =
'Appointment'
    THEN 1 ELSE 0 END ) appts
FROM crm a
  INNER JOIN crm ac ON a.accid = ac.id
     AND ac.type='account'
WHERE a.type='activity'
  AND a.startDate BETWEEN '2018-10-01'
     AND '2018-12-31'
GROUP BY ac.industry
```

MongoDB Query Language

```
db.activity.aggregate(
 { $match: { startDate: { $gt: '2018-01-01',
                          $lt: '2018-12-31' } } },
 {
   $lookup: {
         from: "account",
         localField: "accid",
         foreignField: "id",
         as: "account_docs"
           }
 },
 { $match: { "account_docs": { $ne: [] } } },
 { $unwind: "$account_docs" },
 {
   $project: {
     item: 1,
     task: { $cond:{if:
       { $eq: ["$activityType", "Task"] }, then: 1,
            else: 0 } },
     appt: { $cond: { if:
      { $eq: ["$activityType", "Appointment"] }, then:
1,
            else: 0 } } }
  },
  {
      $group: {
           _id: "$account_docs.industry",
           tasks: { $sum: "$task" },
           appointments: { $sum: "$appt" }
  } }
);
```

ElasticSearch

- Moteur de recherche distribué, orienté-document
- Capable de stocker des documents (format JSON)
- Dispose d’un langage de requêtes
- Basé sur :
  - *Apache Lucene* pour l'indexation et la recherche des données
  - *Logstash* pour la gestion de *logs*
  - *Kibana* pour l'exploration et la visualisation des données

Positionnement d'ElasticSearch

410 systems in ranking, March 2023

Rank Mar 2023	Rank Feb 2023	Rank Mar 2022	DBMS	Database Model	Score Mar 2023	Score Feb 2023	Score Mar 2022
1.	1.	1.	Oracle	Relational, Multi-model	1261.29	+13.77	+9.97
2.	2.	2.	MySQL	Relational, Multi-model	1182.79	-12.66	-15.45
3.	3.	3.	Microsoft SQL Server	Relational, Multi-model	922.01	-7.08	-11.77
4.	4.	4.	PostgreSQL	Relational, Multi-model	613.83	-2.67	-3.10
5.	5.	5.	MongoDB	Document, Multi-model	458.78	+6.02	-26.88
6.	6.	6.	Redis	Key-value, Multi-model	172.45	-1.39	-4.31
7.	7.	7.	IBM Db2	Relational, Multi-model	142.92	-0.04	-19.22
8.	8.	8.	Elasticsearch	Search engine, Multi-model	139.07	+0.47	-20.88

☐ include secondary database models

28 systems in ranking, March 2023

Rank Mar 2023	Rank Feb 2023	Rank Mar 2022	DBMS	Database Model	Score Mar 2023	Score Feb 2023	Score Mar 2022
1.	1.	1.	Elasticsearch	Search engine, Multi-model	139.07	+0.47	-20.88
2.	2.	2.	Splunk	Search engine	87.97	+0.89	-7.39
3.	3.	3.	Solr	Search engine, Multi-model	47.28	+1.40	-11.77
4.	4.	↑ 10.	OpenSearch	Search engine	11.12	+0.62	+6.95

ElasticSearch : liens utiles

- Site officiel : https://www.elastic.co/fr/products/elasticsearch
- Cours en ligne :
  - https://openclassrooms.com/en/courses/4462426-maitrisez-les-bases-de-donnees-nosql/4474691-etudiez-le-fonctionnement-d-elasticsearch
  - https://juvenal-chokogoue.developpez.com/tutoriels/elasticsearch-sgbd-nosql/
  - https://www.linkedin.com/learning/l-essentiel-de-elasticsearch/chercher-des-documents?u=74606242
- Comparaison ElasticSearch/MongoDB : https://www.slideshare.net/sebprunier/mongodb-et-elasticsearch-meilleurs-ennemis

ElasticSearch ~index inversé

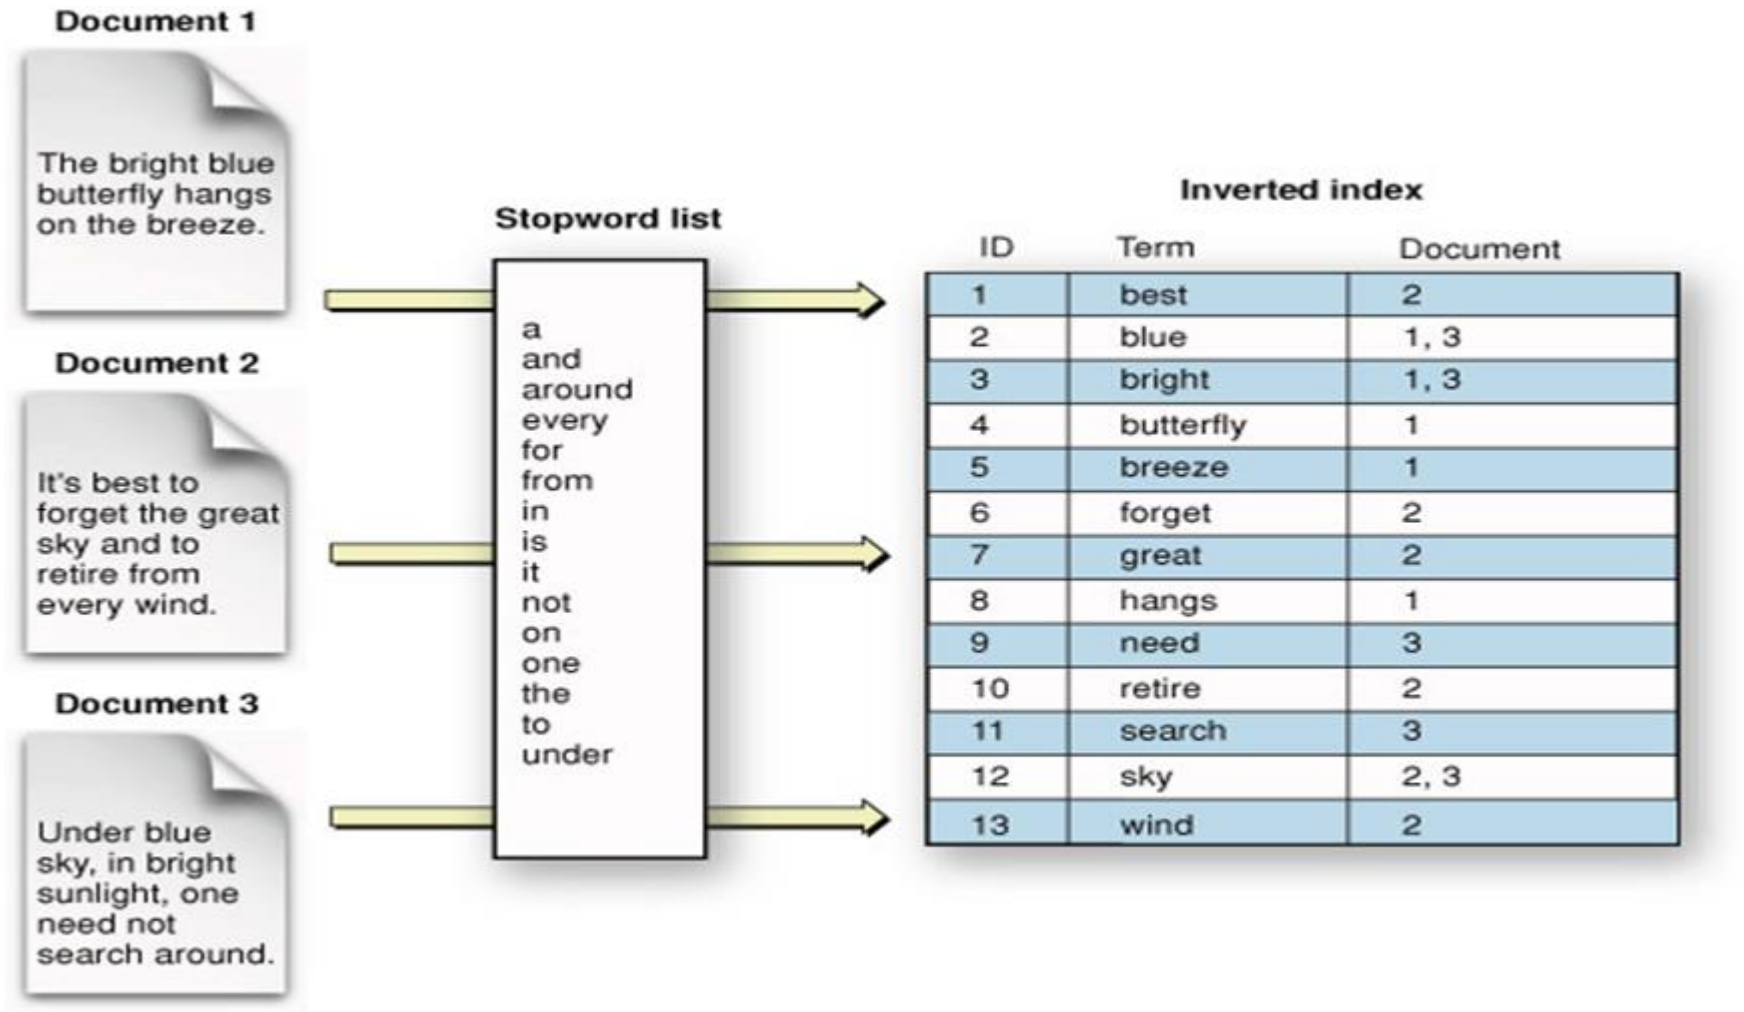

ElasticSearch : modèle de données (1/2)

- Unité ElasticSearch : document
- Index ElasticSearch : ensemble des documents qui sont stockés
- **Tous** les documents JSON ont le même schéma (même ordre de clés, mêmes types de données, et le même ordre)
- Chaque document est préfixé par un autre document JSON contenant les informations d'import : l'**index** et l'**identifiant** du document

ElasticSearch : modèle de données (2/2)

RDBMS	ES
	
Table	Type
Row	Document
Column	Field

ElasticSearch : utilisation

- A l'aide d'une API REST

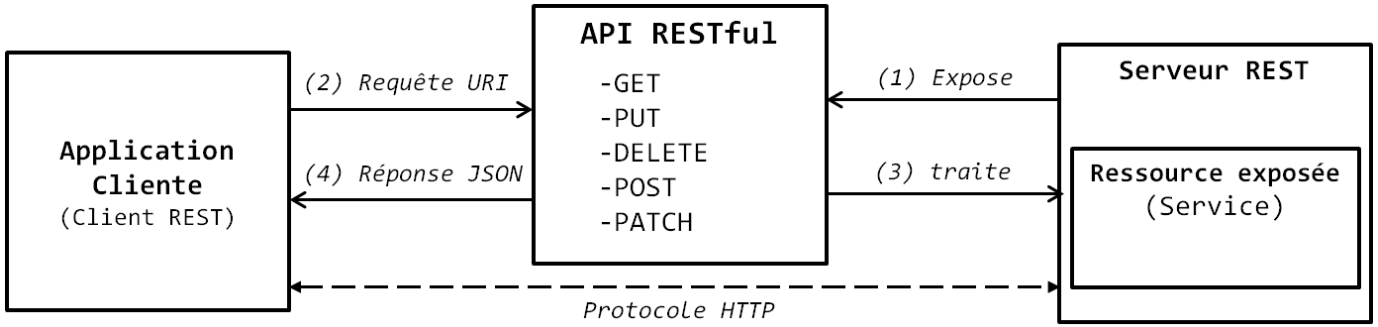

- Index: ressource exposée
- ElasticSearch : rôle du Serveur REST
- Manipulation des documents de l'index à l'aide des verbes HTTP
- JSON : format d'échange de données

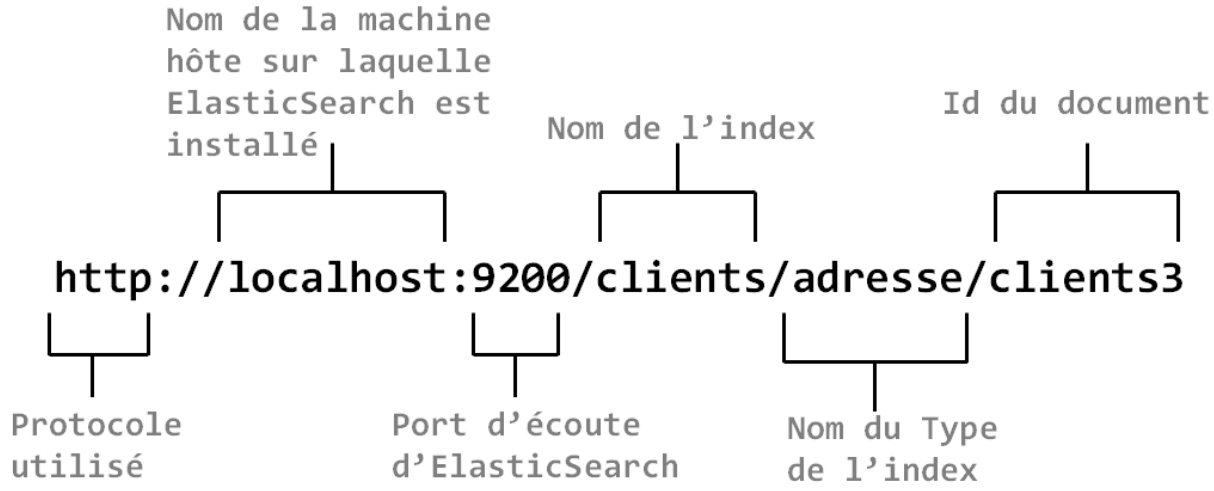

ElasticSearch : exemple de document JSON

Document JSON

```
POST temp_index/_doc
{
  "name": "Pineapple",
  "botanical_name": "Ananas comosus",
  "produce_type": "Fruit",
  "country_of_origin": "New Zealand",
  "date_purchased": "2020-06-02T12:15:35",
  "quantity": 200,
  "unit_price": 3.11,
  "description": "a large juicy tropical fruit consisting of aromatic ec
  "vendor_details": {
    "vendor": "Tropical Fruit Growers of New Zealand",
    "main_contact": "Hugh Rose",
    "vendor_location": "Whangarei, New Zealand",
    "preferred_vendor": true
  }
}
```

Index associé

```
{
  "_index" : "temp_index",
  "_type" : "_doc",
  "_id" : "Z5RLyXkBz8GVH0EAFLb6",
  "_version" : 1,
  "result" : "created",
  "_shards" : {
    "total" : 2,
    "successful" : 2,
    "failed" : 0
  },
  "_seq_no" : 1,
  "_primary_term" : 1
}
```

ElasticSearch : exemple de mapping

```
GET temp_index/_mapping
```

```
{
  "temp_index" : {
    "mappings" : {
      "properties" : {
        "botanical_name" : {
          "type" : "text",
          "fields" : {
            "keyword" : {
              "type" : "keyword",
              "ignore_above" : 256
            }
          }
        },
        "country_of_origin" : {
          "type" : "text",
          "fields" : {
            "keyword" : {
              "type" : "keyword",
              "ignore_above" : 256
            }
          }
        },
```

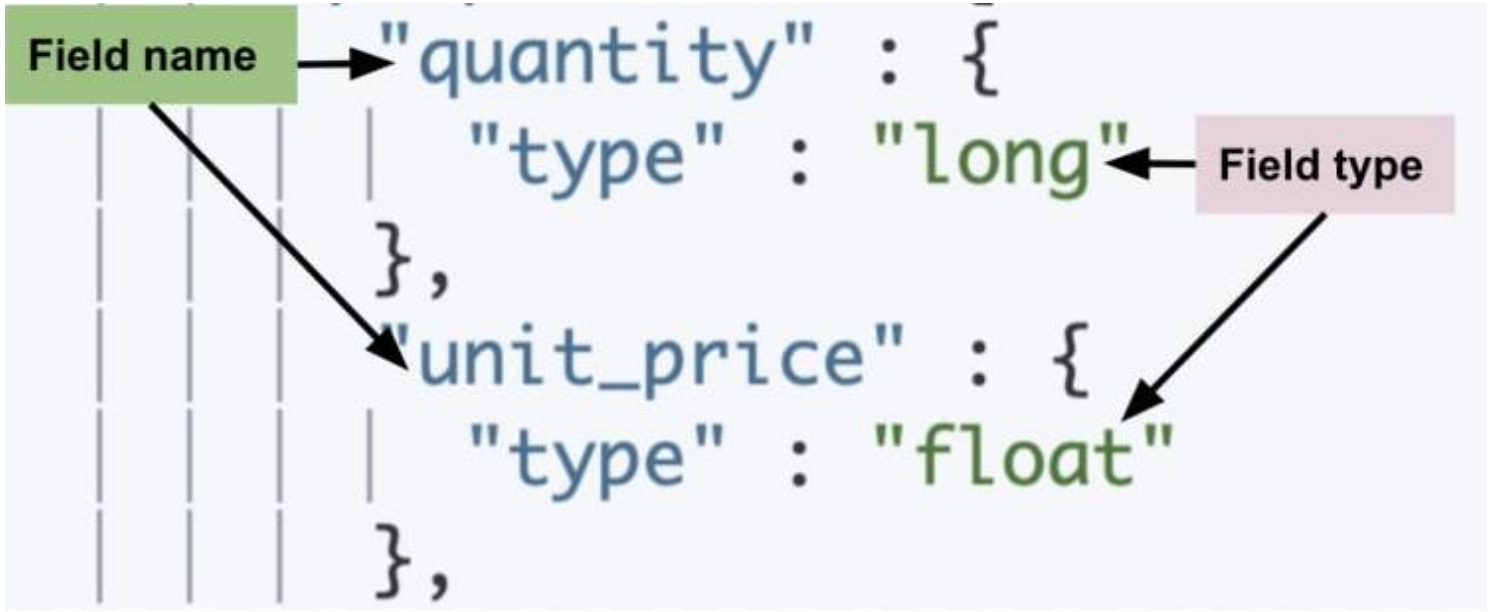

ElasticSearch : indexation des chaînes

By default, strings get mapped twice as text and keyword

```
PUT temp_index/_doc/4
{
  "country": "New Zealand"
}

PUT temp_index/_doc/5
{
  "country": "New Zealand"
}

PUT temp_index/_doc/6
{
  "country": "New Caledonia"
}
```

Used for full text search

term	doc id
caledonia	6
new	4,5,6
zealand	4,5

Used for aggregations, sorting, exact searches

doc id	doc values
4	New Zealand
5	New Zealand
6	New Caledonia

@LisaHJung | Beginner's Crash Course to Elastic Stack

ElasticSearch : création d'un index

```
PUT my_index (1)
{
  "mappings": {
    "doc": { (2)
      "properties": { (3)
        "title":    { "type": "text"  }, (4)
        "name":     { "type": "text"  }, (5)
        "age":      { "type": "integer" }, (6)
        "created":  {
          "type":   "date", (7)
          "format": "strict_date_optional_time||epoch_millis"
        }
      }
    }
  }
}
```

(1) Create an index called `my_index`.

(2) Add a mapping type called `doc`.

(3) Specify fields or *properties*.

(4) Specify that the `title` field contains `text` values.

(5) Specify that the `name` field contains `text` values.

(6) Specify that the `age` field contains `integer` values.

(7) Specify that the `created` field contains `date` values in two possible formats.

ElasticSearch : Architecture

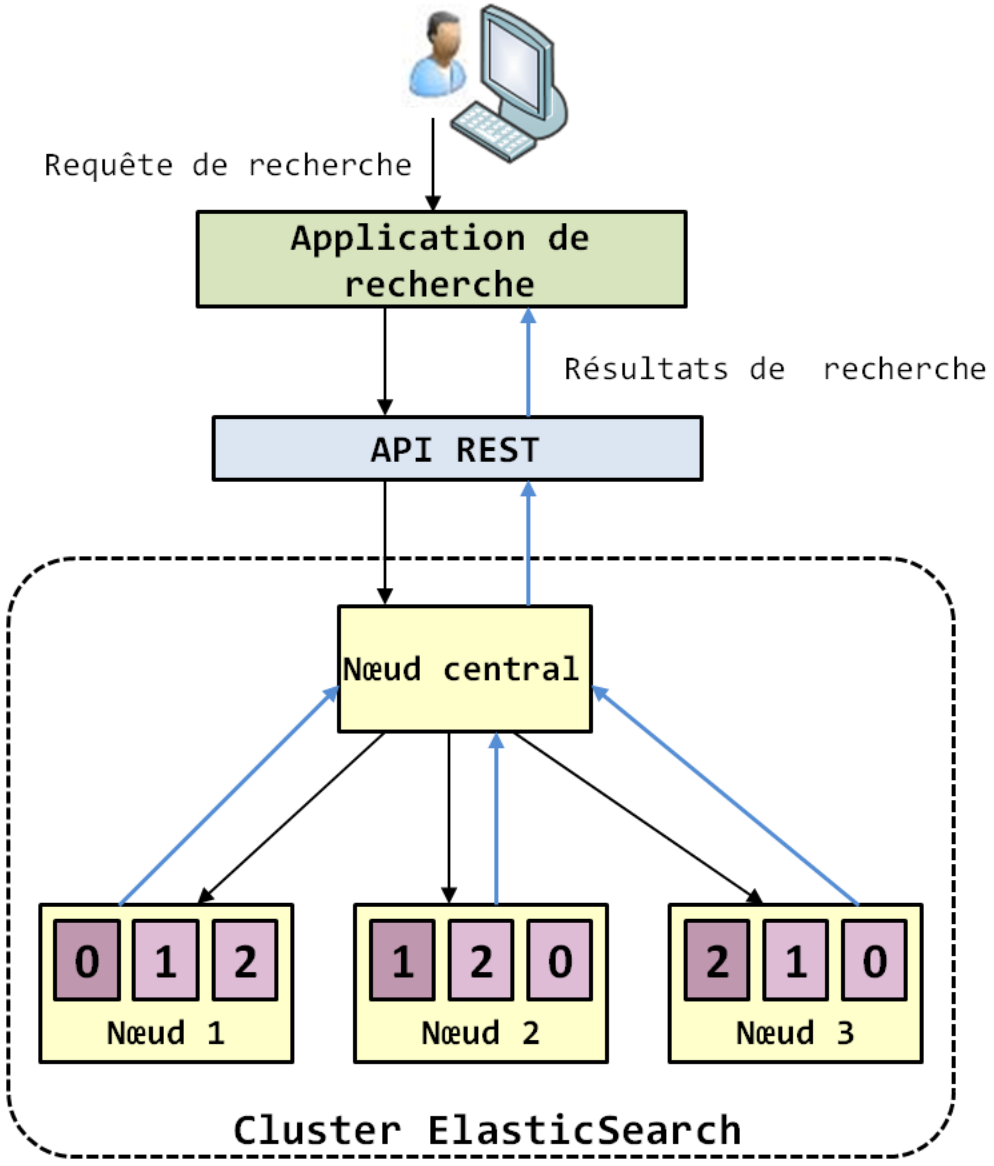

- Partition des documents
- Partitions répliquées entre les nœuds du cluster selon un facteur de réplication
- Réplication des données pour assurer la haute disponibilité du cluster et la garantie de la continuité des traitements en cas de panne dans le cluster
- Désignation d'une réplique primaire pour chaque document

ElasticSearch : Architecture

ElasticSearch : Requête en DSL (*Domain Specific Language*)

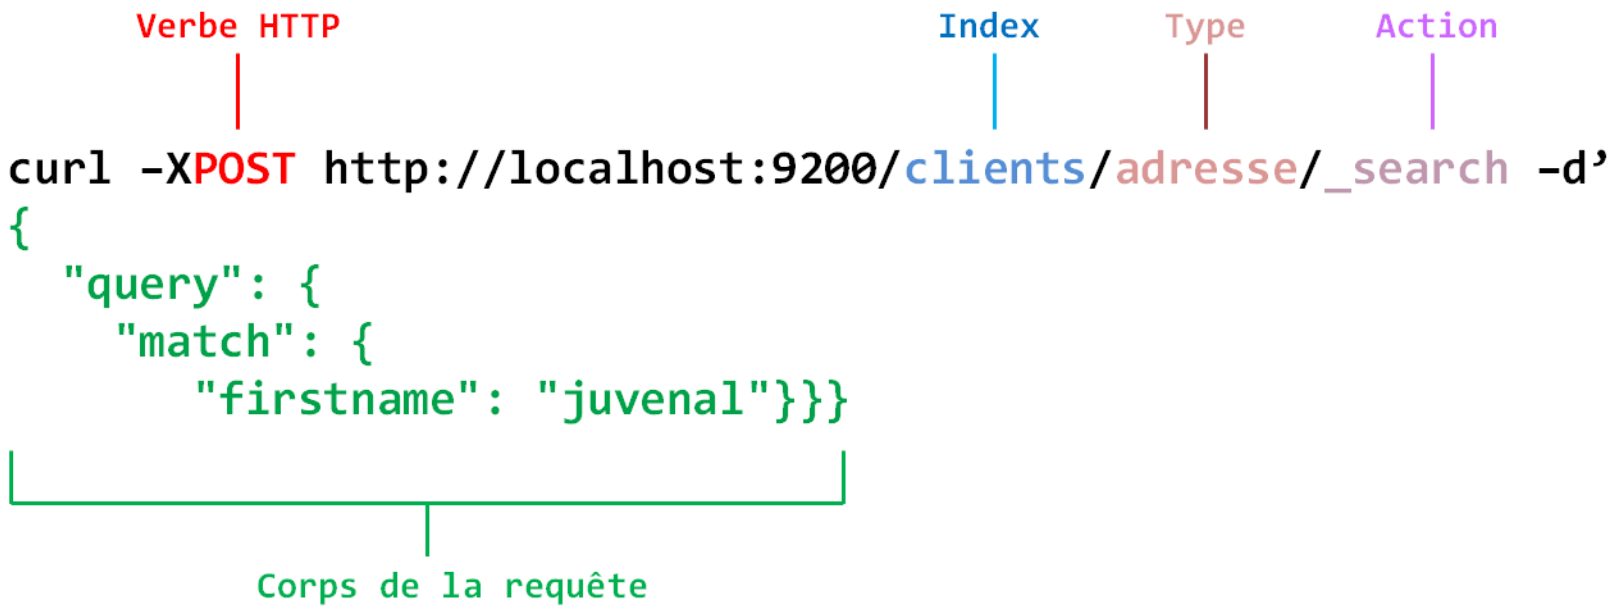

« **curl** » pour envoyer des requêtes HTTP

ElasticSearch : interrogation en SQL

Console | Search Profiler | Grok Debugger

```
POST _sql?format=txt
{
 "query":"select customer_first_name, customer_full_name,
   customer_gender from kibana_sample_data_ecommerce where
   customer_gender='MALE'"
}
```

Nom de l'index à interroger

```
customer_first_name|   customer_full_name    |customer_gender
-------------------+-------------------------+---------------
Eddie              |Eddie Underwood          |MALE
Eddie              |Eddie Weber              |MALE
Oliver             |Oliver Rios              |MALE
Abd                |Abd Sutton               |MALE
Eddie              |Eddie Gregory            |MALE
Sultan Al          |Sultan Al Pratt          |MALE
Eddie              |Eddie Wolfe              |MALE
Sultan Al          |Sultan Al Thompson       |MALE
Sultan Al          |Sultan Al Boone          |MALE
George             |George Hubbard           |MALE
Boris              |Boris Maldonado          |MALE
Yahya              |Yahya Rivera             |MALE
Muniz              |Muniz Riley              |MALE
```

ElasticSearch : traduction SQL en DSL

```
POST /_sql/translate
{
 "query":"select customer_first_name,
   customer_full_name, customer_gender
   , products.product_name, sum
   (taxful_total_price) as CA from
   kibana_sample_data_ecommerce where
   customer_gender='MALE' group by
   customer_first_name,
   customer_full_name, customer_gender
   , products.product_name"
}
```

```
{
  "size" : 0,
  "query" : {
    "term" : {
      "customer_gender" : {
        "value" : "MALE",
        "boost" : 1.0
      }
    }
  },
  "_source" : false,
  "stored_fields" : "_none_",
  "aggregations" : {
    "groupby" : {
      "composite" : {
        "size" : 1000,
        "sources" : [
          {
            "1033" : {
              "terms" : {
                "field" : "customer_first_name.keyword",
                "missing_bucket" : true,
                "order" : "asc"
              }
            }
          },
```

Combinaison Couchbase - ElasticSearch

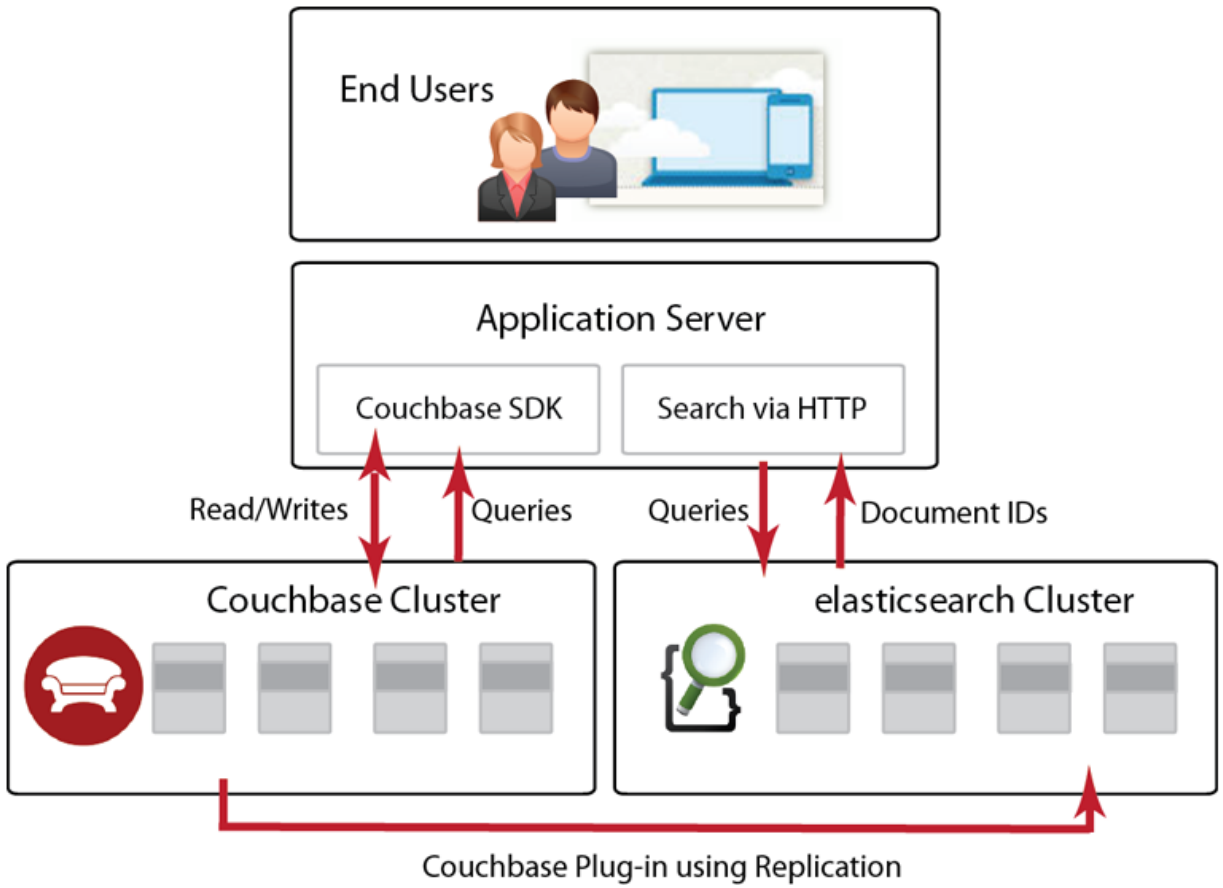

- Après une écriture sur Couchbase : réplication sur ElasticSearch
- Pas de copie intégrale sur ElasticSearch, juste pour créer l'index
- Récupération de l'ID du doc recherché via ElasticSearch et du doc complet via CouchBase

Combinaison MongoDB - ElasticSearch

- 5 Different ways to synchronize data from MongoDB to ElasticSearch : https://code.likeagirl.io/5-different-ways-to-synchronize-data-from-mongodb-to-elasticsearch-d8456b83d44f
- MongoDB invite ses clients à se passer d'Elasticsearch (2019) : https://www.lemagit.fr/actualites/252476841/MongoDB-invite-ses-clients-a-se-passer-dElasticsearch

JSON et bases de données relationnelles

- **SQL/JSON** Intégration de JSON dans le standard SQL (2017 - Part 6) : https://www.iso.org/standard/67367.html et https://webstore.iec.ch/preview/info_isoiec19075-6%7Bed1.0%7Den.pdf
- Gestion de données JSON possible dans plusieurs SGBD relationnels :
  - MySQL : https://dev.mysql.com/doc/refman/8.0/en/json.html
  - MariaDB : https://mariadb.com/kb/en/json-data-type/
  - Oracle : https://docs.oracle.com/database/121/ADXDB/json.htm#ADXDB6246
  - SQLSever : https://docs.microsoft.com/fr-fr/sql/relational-databases/json/json-data-sql-server?view=sql-server-ver15
  - PostgreSQL : https://docs.postgresql.fr/14/functions-json.html#FUNCTIONS-JSON-PROCESSING

JSON sous PostgreSql

- 2 types de données : JSON et JSONB (binaire avec indexation sur les clés)
- Opérateurs :
  - `->` pour renvoyer la clé de la colonne JSON
  - `->>` pour renvoyer la valeur de la colonne JSON
  - `@>` et `<@` pour tester si un document est un sous ou un sur-ensemble d'un autre
  - `?` Pour tester l'existence d'une clé
  - cf. https://devhints.io/postgresql-json, https://www.postgresqltutorial.com/postgresql-tutorial/postgresql-json/ et https://www.postgresql.org/docs/9.5/functions-json.html

Exemple de données JSON sous PostgreSql (1/3)

```
CREATE TABLE json_test (
  id serial primary key,
  data jsonb
);

INSERT INTO json_test (data) VALUES
  ('{}'),
  ('{"a": 1}'),
  ('{"a": 2, "b": ["c", "d"]}'),
  ('{"a": 1, "b": {"c": "d", "e": true}}'),
  ('{"b": 2}');
```

id	data
1	{}
2	{"a":1}
3	{"a":2,"b":["c","d"]}
4	{"a":1,"b":{"c":"d","e":true}}
5	{"b":2}

Documents ayant un champ 'a' :

```
SELECT * FROM json_test WHERE data ? 'a';
```

id	data
2	{"a":1}
3	{"a":2,"b":["c","d"]}
4	{"a":1,"b":{"c":"d","e":true}}

Exemple de données JSON sous PostgreSql (2/3)

Id des documents et valeur du champ `'a'` :

```
SELECT id, data->'a' as a FROM json_test ;
```

id	a
1	null
2	1
3	2
4	1
5	null

Documents ayant un champ `'a'` de valeur `1` :

```
SELECT * FROM json_test WHERE data @> '{"a":1}';
```

id	data
2	{"a":1}
4	{"a":1,"b":{"c":"d","e":true}}

Exemple de données JSON sous PostgreSql (3/3)

Documents ayant un champ 'a' de valeur supérieur à 1 :

```
SELECT * FROM json_test WHERE data ->> 'a' > '1';
```

id	data
3	{"a":2,"b":["c","d"]}

Valeur du champ 'e' du champ 'b' :

```
SELECT data -> 'b' ->> 'e' as e FROM json_test where id = 4;
```

e
true

Documents ayant un champ 'a' ou 'b' :

```
SELECT * FROM json_test WHERE data ?| array['a', 'b'];
```

id	data
2	{"a":1}
3	{"a":2,"b":["c","d"]}
4	{"a":1,"b":{"c":"d","e":true}}
5	{"b":2}

Documents ayant un champ 'a' et un champ 'b' :

```
SELECT * FROM json_test WHERE data ?& array['a', 'b'];
```

id	data
3	{"a":2,"b":["c","d"]}
4	{"a":1,"b":{"c":"d","e":true}}

Exemple d'agrégation de données JSON sous PostgreSql (1/2)

```
CREATE TABLE events (
  name varchar(200),
  visitor_id varchar(200),
  properties jsonb,
  browser jsonb
);
```

name	visitor_id	properties	browser
pageview	1	{"page":"/"}	{"os":"Mac","name":"Chrome","resolution":{"x":1440,"y":900}}
pageview	2	{"page":"/"}	{"os":"Windows","name":"Firefox","resolution":{"x":1920,"y":1200}}
pageview	1	{"page":"/account"}	{"os":"Mac","name":"Chrome","resolution":{"x":1440,"y":900}}
purchase	5	{"amount":10}	{"os":"Windows","name":"Firefox","resolution":{"x":1024,"y":768}}
purchase	15	{"amount":200}	{"os":"Windows","name":"Firefox","resolution":{"x":1280,"y":800}}
purchase	15	{"amount":500}	{"os":"Windows","name":"Firefox","resolution":{"x":1280,"y":800}}

Exemple d'agrégation de données JSON sous PostgreSql (2/2)

```
SELECT browser->>'name' AS browser,
     count(browser)
     FROM events
     GROUP BY browser->>'name';
```

browser	count
Firefox	4
Chrome	2

```
SELECT visitor_id, SUM(CAST(properties->>'amount' AS integer)) AS total
  FROM events
  WHERE CAST(properties->>'amount' AS integer) > 0
  GROUP BY visitor_id;
```

visitor_id	total
15	700
5	10

```
 SELECT AVG(CAST(browser->'resolution'->>'x' AS integer)) AS width,
    AVG(CAST(browser->'resolution'->>'y' AS integer)) AS height
  FROM events;
```

width	height
1397.3333333	894.6666666

JSON Path (1/3)

Langage de recherche pour JSON introduit dans le standard SQL:2016 et implémenté sous PostrgeSQL

- https://paquier.xyz/postgresql-2/postgres-12-jsonpath/
- https://www.postgresql.org/docs/devel/functions-json.html#FUNCTIONS-SQLJSON-FILTER-EX-TABLE
- https://jsonpath.com/

```
CREATE TABLE personnes (datas jsonb );

INSERT INTO personnes  (datas) VALUES ('
{
  "firstName": "Jean",
  "lastName": "Valjean",
  "address": {
    "streetAddress": "43 rue du Faubourg Montmartre",
    "city": "Paris",
    "postalCode": "75002"
  },
  "phoneNumbers": [
    { "number": "06 12 34 56 78" },
    {"type": "bureau",
     "number": "07 89 10 11 12"}
  ],
  "children": [],
  "spouse": null
}
'),
('
{
  "firstName": "Georges",
  "lastName": "Durand",
  "address": {
    "streetAddress": "27 rue des Moulins",
    "city": "Châteauneuf",
    "postalCode": "45990"
  },
  "phoneNumbers": [
    { "number": "06 21 34 56 78" },
    {"type": "bureau",
     "number": "07 98 10 11 12"}
  ],
  "children": [],
  "spouse": null
}
');
```

JSON Path (2/3)

```
SELECT jsonb_path_query(datas, '$.firstName') FROM personnes;
```

jsonb_path_query
Jean
Georges

```
SELECT jsonb_path_query(datas, '$.address.city') FROM personnes;
```

jsonb_path_query
Paris
Châteauneuf

```
SELECT jsonb_path_query (datas, '$.phoneNumbers[*]')
FROM personnes ;
```

jsonb_path_query
{"number":"06 12 34 56 78"}
{"type":"bureau","number":" 07 89 10 11 12"}
{"number":"06 21 34 56 78"}
{"type":"bureau","number":" 07 98 10 11 12"}

JSON Path (3/3)

```
SELECT jsonb_path_query (datas, '$.phoneNumbers[*] ? (@.type == "bureau") ')
FROM personnes ;
```

jsonb_path_query
{"type":"bureau","number":"07 89 10 11 12"}
{"type":"bureau","number":"07 98 10 11 12"}

```
SELECT jsonb_path_query (datas, '$.phoneNumbers[*] ? (@.type == "bureau") ') -> 'number' as number
FROM personnes ;
```

number
07 89 10 11 12
07 98 10 11 12

JSON sous PostgreSQL : conclusion


Combinaison relationnel et documents JSON


Gestion des transactions


Gestion des clés étrangères et des jointures


Pas de réel schéma flexible


Pas un moteur NoSQL

Performance par rapport à MongoDB ?

cf. Article scientifique de 2020 comparant les 2 moteurs pour l'utilisation de données géographiques :

https://link.springer.com/content/pdf/10.1007/s10707-020-00407-w.pdf

JSON sous PostgreSql vs MongoDB

- https://portavita.github.io/2018-10-31-blog_A_JSON_use_case_comparison_between_PostgreSQL_and_MongoDB/
- « Postgresql – la nouvelle base de données orientée document » https://www.youtube.com/watch?v=iOwnUPSY0KI
- https://blog.ippon.fr/2017/01/03/rex-bdx-io-postgres-notonlysql/
- https://naiveskill.com/mongodb-vs-postgresql/
- https://hevodata.com/learn/mongodb-vs-postgresql/
- https://www.openlogic.com/blog/postgresql-vs-mongodb#:~:text=MongoDB%20Performance,an%20advantage%20for%20both%20databases
- https://info.enterprisedb.com/rs/069-ALB-339/images/PostgreSQL_MongoDB_Benchmark-WhitepaperFinal.pdf