




www.cnrs.fr

Bases de données Colonnes avec



Cassandra





Sommaire

- Introduction
- Architecture
- Modèle de données
- Travaux pratiques




Introduction

Historique

- ① **Développé par facebook Avinash LAKSHMAN**
(un des développeurs de la base Dynamo d'Amazon)
- ① **Inspiré de Big Table développé par Google**
- ① **Code libéré en 2008**
- ① **Top Level Apache Project en 2010**
- ① **Abandonné par Facebook en 2010**

Historique

- Mythe issu de l'Illiade et l'Odyssée d'Homère
- Cassandra est la fille de Priam, roi de Troie
- Réputée pour sa grande beauté
- Douée de visions remarquablement précises et exactes
- Enlevée par Ajax (Roi de Locride et guerrier sanguinaire)



Qu'est-ce que Cassandra?

- ⦿ **Base de données orientées colonnes**
- ⦿ **Scalable**
- ⦿ **Distribuée (peer-to-peer)**
- ⦿ **Massivement parallèle**

- ⦿ **Objectifs**
 - gérer une grande quantité de données
 - résister aux pannes
 - être performante

Mises en œuvre

- ⦿ Facebook
- ⦿ Twitter
- ⦿ Digg
- ⦿ Cisco WebEx
- ⦿ IBM
- ⦿ eBay
- ⦿ NetFlix

Installation

🕒 Ajout du dépôt officiel pour Ubuntu

- `sudo apt-key adv --keyserver pgp.mit.edu --recv F758CE318D77295D`
- `sudo apt-key adv --keyserver pgp.mit.edu --recv 749D6EEC0353B12C`
- `echo "deb http://www.apache.org/dist/cassandra/debian 21x main" | sudo tee /etc/apt/sources.list.d/cassandra-2.1.list`
- `echo "deb-src http://www.apache.org/dist/cassandra/debian 21x main" | sudo tee /etc/apt/sources.list.d/cassandra-src-2.1.list`
- `sudo apt-get update`

🕒 Installation depuis le dépôt

- `sudo apt-get install cassandra`

🕒 Lancement

- `cassandra [-f]`

🕒 Connection


- `cqlsh`
- `cassandra-cli`



Architecture


- CAP
- Cluster
- Réplication

CAP



Cluster

- ⦿ **Tous les nœuds ont la même importance**
- ⦿ **Tous les nœuds communiquent avec les autres**
 - Chaque nœud contacte entre 1 et 3 nœuds toutes les secondes
 - Protocole de bavardage (gossip)
 - Conçu pour éviter la formation d'îlots indépendants
 - Conçu pour que l'information se propage vite




Cluster

◎ Lecture/écriture depuis n'importe quel nœud

◎ Le client ne sait pas où la donnée se trouve


1. le client contacte n'importe quel nœud
2. le nœud contacté («storage proxy») sert de coordinateur

Note: Le client peut disposer d'une pool de connexions vers quelques nœuds.



Réplication

- ◎ Pas de point faible (SPOF= Single Point of Failure)



Réplication

- ⦿ **Combien de réplikas doivent répondre pour considérer l'opération réussie ?**
- ⦿ **Consistance ajustable**
 - Pour la lecture et l'écriture
 - Choix entre consistance forte ou partielle
 - A régler en fonction du besoin


Réplication en écriture

Level	Vérification de l'écriture sur
ANY	1 nœud (inclu hinted handoff)
ONE	1 nœud
QUORUM	$N/2 + 1$ replicas
LOCAL_QUORUM	$N/2 + 1$ replicas dans le datacenter local
EACH_QUORUM	$N/2 + 1$ replicas dans tous les datacenter local
ALL	Tous les replicas

Réplication en écriture

Consistency Level ONE

Exemple avec un **facteur de réplication à 3**




Opération réussie

.....> Écriture asynchrone

Réplication en écriture

Consistency Level ONE

Exemple avec un **facteur de réplication à 3**




Puis en background

Réplication en écriture

Consistency Level QUORUM

Exemple avec un facteur de réplication à 2




Opération réussie

Réplication en écriture

Consistency Level QUORUM


Exemple avec un **facteur de réplication à 2**



Réplication en écriture

Consistency Level QUORUM

Exemple avec un **facteur de réplication à 3**




Opération réussie

.....> Écriture asynchrone

Réplication en écriture

Consistency Level QUORUM

Exemple avec un facteur de réplication à 3




Opération réussie

.....> Écriture asynchrone

Réplication en écriture

Consistency Level ALL

Exemple avec un **facteur de réplication à 3**




Opération réussie

.....> Écriture asynchrone

Réplication en écriture

Consistency Level ALL


Exemple avec un **facteur de réplication à 3**



Réplication en écriture

Consistency Level ANY

Exemple avec un **facteur de réplication à 3**




Opération réussie

.....> Écriture asynchrone

Réplication en écriture

Hinted Handoff

- Exemple avec
 - facteur de réplication à 3
 - Consistency Level à QUORUM




Opération réussie

Réplication en écriture

Hinted Handoff

- Lorsque le nœud 3 revient




Envoi de la donnée manquante

Attention à
`max_hint_window_in_ms` (1h par défaut)

Réplication en écriture

● Réplication possible entre


- Différents centres de données
- Différentes armoires serveurs



Réplication en écriture

● Réplication possible entre


- Différents centres de données
- Différentes armoires serveurs
- Exemple avec
 - facteur de réplication à 6



Réplication en écriture

Consistency Level QUORUM


- Différents centres de données
- Différentes armoires serveurs
- Exemple avec
 - facteur de réplication à 6



Réplication en écriture

Consistency Level LOCAL_QUORUM


- Différents centres de données
- Différentes armoires serveurs
- Exemple avec
 - facteur de réplication à 6



Réplication en écriture

Consistency Level EACH_QUORUM

- Différents centres de données
- Différentes armoires serveurs
- Exemple avec
 - facteur de réplication à 6



Réplication en écriture

⦿ Configuration de la topologie

○ Décrire le nœud courant

CASSANDRA_HOME/conf/cassandra-rackdc.properties

dc=dc1

rack=rack1

○ Lister les adresses connues

CASSANDRA_HOME/conf/cassandra.yaml


seeds: "127.0.0.1", "127.0.0.2"

Réplication en lecture

Level	Vérification des valeurs sur
ONE	1 nœud (1ère réponse)
QUORUM	$N/2 + 1$ replicas
LOCAL_QUORUM	$N/2 + 1$ replicas dans le datacenter local
EACH_QUORUM	$N/2 + 1$ replicas dans tous les datacenter local
ALL	Tous les replicas

Réplication en lecture


- **Le client ne sait pas où la donnée sera lue**
 - Exemple de réplication facteur 3



Réplication en lecture

Consistency Level ONE

Exemple avec un facteur de réplication à 3




Opération réussie

.....> lecture asynchrone , puis « read repair » si besoin et si configuré

Réplication en lecture

Consistency Level ONE

Exemple avec un facteur de réplication à 3




Opération réussie

.....> lecture asynchrone , puis « read repair » si besoin et si configuré

Réplication en lecture

Consistency Level QUORUM

Exemple avec un facteur de réplication à 3




Opération réussie

.....> Écriture asynchrone

Réplication en lecture

Consistency Level ALL

Exemple avec un facteur de réplication à 3




Opération réussie

.....> Écriture asynchrone

Réplication en lecture

Consistency Level ALL

Exemple avec un facteur de réplication à 3



Échec


.....> Écriture asynchrone

Réplication


Consistance

Exemple avec un facteur de réplication à 3

Faible



Forte



◎ Consistance forte

○ Formule : $W + R > RF$

- W: nb de rélicas contactées en écriture
- R: nb de rélicas contactées en lecture
- RF: réplication factor

○ Cas trivial 1 :


- écriture ALL
- lecture ONE

○ Cas trivial 2 :

- écriture QUORUM
- lecture QUORUM

Scalabilité

- ⦿ Ajout de nœud en ligne
- ⦿ Augmentation linéaire de la performance



Exercices

① Se connecter à la VM

- <https://192.168.56.4:4200/> ou dans VirtualBox
- `su -`

② Lancer le nœud 1

- `cd /home/cassandra/cassandra1/bin`
- `./cassandra`

③ Vérifier l'état

- `./nodetool info`
- `./nodetool status`

④ Lancer le nœud 2 et vérifier l'état

- `cd /home/cassandra/cassandra2/bin`



Modèle de données

- De la colonne à la famille de colonnes
- Partitionnement
- Indexation

Colonne

Nom
Valeur
<i>Timestamp</i>

Colonne


⦿ Nom

Porteur d'information pour le requêtage

⦿ Valeur : 2Go maximum

⦿ Timestamp

Utilisé par Cassandra pour résoudre les conflits dus à l'architecture distribuée



Colonne

🕒 Types de valeur

Internal /CLI Type	CQL Name	Description
BytesType	blob	Arbitrary hexadecimal bytes (no validation)
AsciiType	ascii	US-ASCII character string
UTF8Type	text, varchar	UTF-8 encoded string
IntegerType	varint	Arbitrary-precision integer
Int32Type	int	4-byte integer
InetAddressType	inet	IP address string in IPv4 or IPv6 format
LongType	bigint	8-byte long
UUIDType	uuid	UUID
TimeUUIDType	timeuuid	Type 1 UUID only (CQL3)
DateType	timestamp	Date plus time, encoded as 8 bytes since epoch
BooleanType	boolean	true or false
FloatType	float	4-byte floating point
DoubleType	double	8-byte floating point
DecimalType	decimal	Variable-precision decimal
CounterColumnType	counter	Distributed counter value (8-byte long)


Colonne composite

- ⦿ Nom de colonne porte plusieurs informations

Critère 1	Critère 2	Critère 3
Valeur		

Supercolonne

⦿ Colonne contenant des colonnes




⦿ **A éviter**

Ligne

● Ensemble de colonnes

- Identifié par sa clé
- 2 milliards de colonnes maximum
- 0 contraintes sur les colonnes



● 1 ligne ne peut pas être scindée sur plusieurs nœuds

- La taille maximum d'une ligne est la taille disque du nœud

◉ Ordre des colonnes

- Choix de la stratégie de tri : Comparator
 - ASCII
 - UTF8
 - Long
 - UUID
 - CompositeType
 - Utile pour les colonnes avec plusieurs données
 - Alternative aux supercolonnes
 - ex : UTF8Type, UTF8Type, UTF8Type pour le login, nom, prenom

Famille de colonnes

🕒 Conteneur de colonnes, supercolonnes

○ Equivalent à une table dans une base de données relationnelle

Clé de ligne	Nom1 Valeur1	Nom2 Valeur2	Nom3 Valeur3	Nomx Valeurx
Clé de ligne	Nom1 Valeur1		Nom3 Valeur3	Nomx Valeurx
Clé de ligne	Nom1 Valeur1	Nom2 Valeur2	Nom3 Valeur3	

La colonne est une valeur !

🕒 Nom de colonne

Tous les trains qui passent à Valence

train6101	PARIS 06:07	VALENCE 08:19	AVIGNON 09:07	AIX 09:30	MARSEILLE 09:41
train2917				AVIGNON 11:30	11:59 MARSEILLE

🕒 Tri sur les colonnes (slice)

Toutes les données de 9h à 11h

capteur1	08:55 123	09:00	...	11:00 52	11:05 19
----------	---------------------------------	------------------------------	----------------	--------------------------------	--------------------------------



🕒 MAIS PAS DE JOINTURE !

Keyspace

- ⦿ **Conteneur de plus haut niveau**

- Equivalent à un schéma dans une base de données relationnelle

- ⦿ **Pas d'intégrité référentielle**

- Donc pas de formes normales

NETFLIX

Partitionnement

⦿ Les données sont réparties vers tous les nœuds

- En fonction de la clé primaire

⦿ Stratégie de placement

- Repose sur la clé de ligne => token
- Murmur3Partitioner (par défaut)
 - Répartir uniformément les différentes lignes entre les nœuds
 - Basé sur le hash MurmurHash des clés
- RandomPartitioner
 - Répartir uniformément les différentes lignes entre les nœuds
 - Basé sur le hash MD5 des clés
- ByteOrderedPartitioner
 - Répartir suivant un ordre de nœuds

Index

⦿ **Index primaire (*partition key*)**

- Automatisement créé
- Sur les clés de ligne
- Permet de rapidement trouver les lignes présentes sur les nœuds

⦿ **Index secondaire (*clustering key*)**

- Sur la valeur des colonnes
- Permet de filtrer les résultat sur les valeurs indexées



Travaux Dirigés

Wide rows (lignes sauvages)

Exercices

Mode Thrift

- ⦿ Connexion au cluster
- ⦿ Créer un keyspace
- ⦿ Créer une famille de colonne
- ⦿ Insérer une première ligne

43	72	20
inséré en premier	inséré en second	inséré en troisième

- ⦿ Interroger les données
- ⦿ Utiliser le tri sur les colonnes (slice)

Exercices

⦿ Créer une famille de colonnes d'évènement

- Créer la famille log_experiment avec un comparateur de colonnes ASCII
- Paginer la consultation des colonnes

⦿ Créer une famille de colonne hygrometrie avec un comparator composé

- Les colonnes seront au format
 - %Y%m%d,"temperature"
 - %Y%m%d,"humidite"



Travaux Dirigés

CQL

- ⦿ Interface ressemblant à du langage relationnel sur un modèle NON relationnel
- ⦿ Clause WHERE uniquement sur toutes les colonnes indexées
- ⦿ Pas de jointure
- ⦿ Pas de GROUP BY
- ⦿ Tri préétabli



Travaux Dirigés

CQL – premiers pas

Exercices

⦿ Connexion au cluster

⦿ Créer un keyspace

```
CREATE KEYSPACE IF NOT EXISTS keyspace_name  
WITH REPLICATION = Class TopologyStrategy
```

- Class TopologyStrategy

- Réplication sur plusieurs datacenters

```
{'class' : 'NetworkTopologyStrategy', 'dc1' : 3, 'dc2' : 2};
```

- Réplication sur un seul datacenter

```
{'class' : 'SimpleStrategy', 'replication_factor' : 3 };
```



Travaux Dirigés

Tester le partitionnement

Exercices

- Créer une famille de colonne "videos" pour enregistrer les informations sur les vidéos

Column Name	Data Type
video_id	timeuuid
added_date	timestamp
description	text
title	text
user_id	uuid

- Charger la table
- Vérifier la répartition des données



Travaux Dirigés

Indexer

Exercices

- Créer la famille de colonne "videos_by_title_year" pour requêter sur les champs title et year

Column Name	Data Type
title	text
added_year	int
added_date	timestamp
description	text
user_id	uuid
video_id	uuid

```
CREATE TABLE videos_by_title_year (  
...  
PRIMARY KEY ((title, added_year))
```

Exercices

- Créer la famille de colonne `videos_by_tag_year` avec une clé primaire sur `tag` et des index secondaires sur `added_year` (avec un tri décroissant) et `video_id` (avec un tri

Column Name	Data Type
tag	text
added_year	int
video_id	uuid
added_date	timestamp
description	text
title	text
user_id	uuid



Travaux Dirigés

Wide rows (lignes sauvages)
en CQL aussi ?

Exercices

- ⦿ Consulter la famille de colonnes d'hygrométrie en CQL
- ⦿ En CQL, « wide rows » = plusieurs lignes par clé primaire !

Exercices

- ⦿ Fondamentaux
- ⦿ Tester le partitionnement
- ⦿ Indexer
- ⦿ Lignes sauvages (journaux d'évènements)
- ⦿ Pagination sur les colonnes
- ⦿ Colonnes composites



Conclusion



www.cnrs.fr

Conclusion

- ① **Dénormalisez !**

1 besoin = requête = 1 famille de colonnes

- ② **Adaptez les données aux requêtes**

Pas l'inverse !