

# APACHE CASSANDRA

Adriano Bonacin

# Apresentação

# Sobre este curso

- Cerca de 32 horas de muito Hands On
  - Necessário acesso à internet (porta 22)
- Introdução a NoSQL x Bigdata/Smartdata
- Instalando/Gerenciando o Serviço Apache Cassandra
- Camada de Dados - CQL
- Arquitetura Cassandra
- Cassandra Ops
- Cassandra Best Practices

# Pré requisitos para o curso

- Conhecimento básico de Linux
  - Listar arquivos – ls
  - Ver conteúdo de um arquivo – cat
  - Editar arquivo – vi
  - Copiar/mover arquivos – cp/mv
- Não tem interface gráfica, somente tela preta 😊

# Introdução a NoSQL x Bigdata/Smartdata

# Bancos Relacionais

- Por muitos anos foi a única solução
- Atendia praticamente todas demandas
- Escalar é caro, vertical
- Consistente, ACID
- Normalizado, Joins
- Integridade referencial
- Exemplos?



Vertical



Horizontal

# ACID

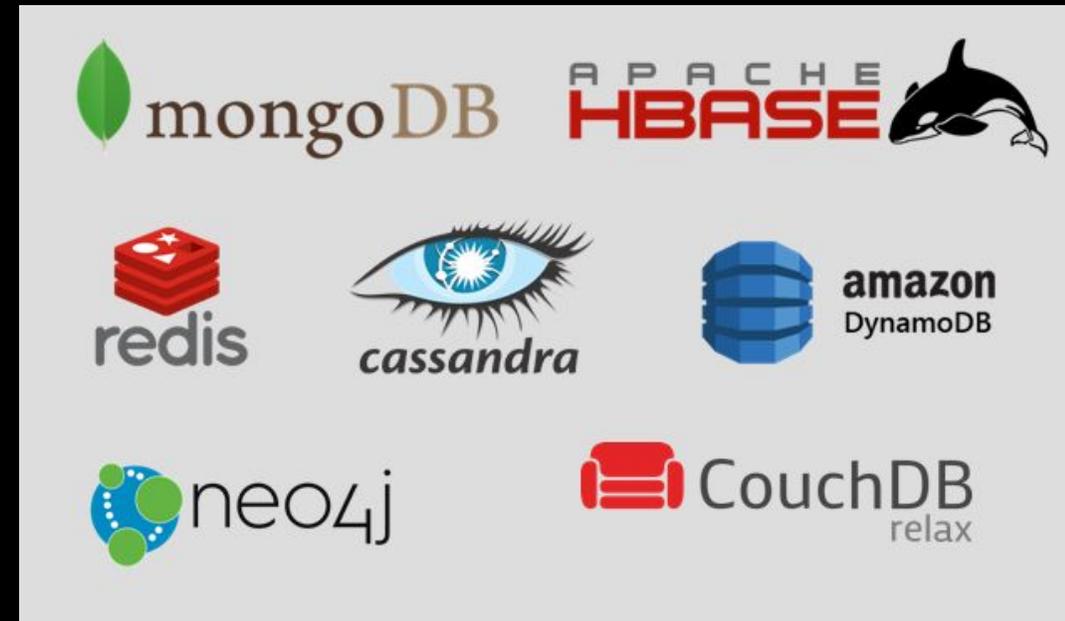
- Atomic – Não existe meia transação
- Consistent – Todos veem o DB da mesma forma em dado momento
- Isolation – Privacidade nos registros alterados até o commit.
- Durable – Se o DB respondeu OK para seu commit, está OK mesmo em falha da instance.

# ACID

- Atomic – Não existe meia transação
- Consistent – Todos veem o DB da mesma forma em dado momento
- Isolation – Privacidade nos registros alterados até o commit.
- Durable – Se o DB respondeu OK para seu commit, está OK mesmo em falha da instance.

# NoSQL

- Alta disponibilidade
- Escalabilidade
- Distribuídos
- Alto volume de dados
- Schema!?
- Normalização!?
- Relacionamento!?
- Not Only SQL

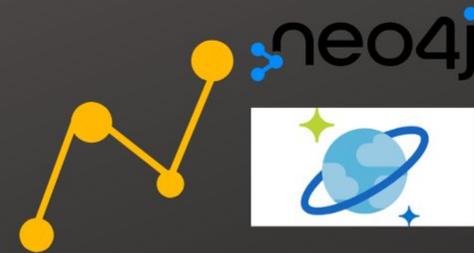


# Tipos de NoSQL

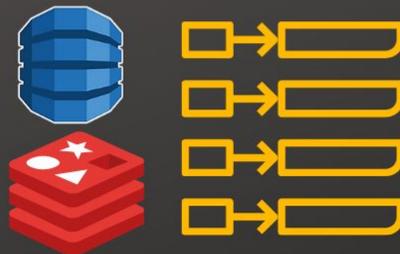
## Documento



## Grafo



## Chave Valor



## Colunar

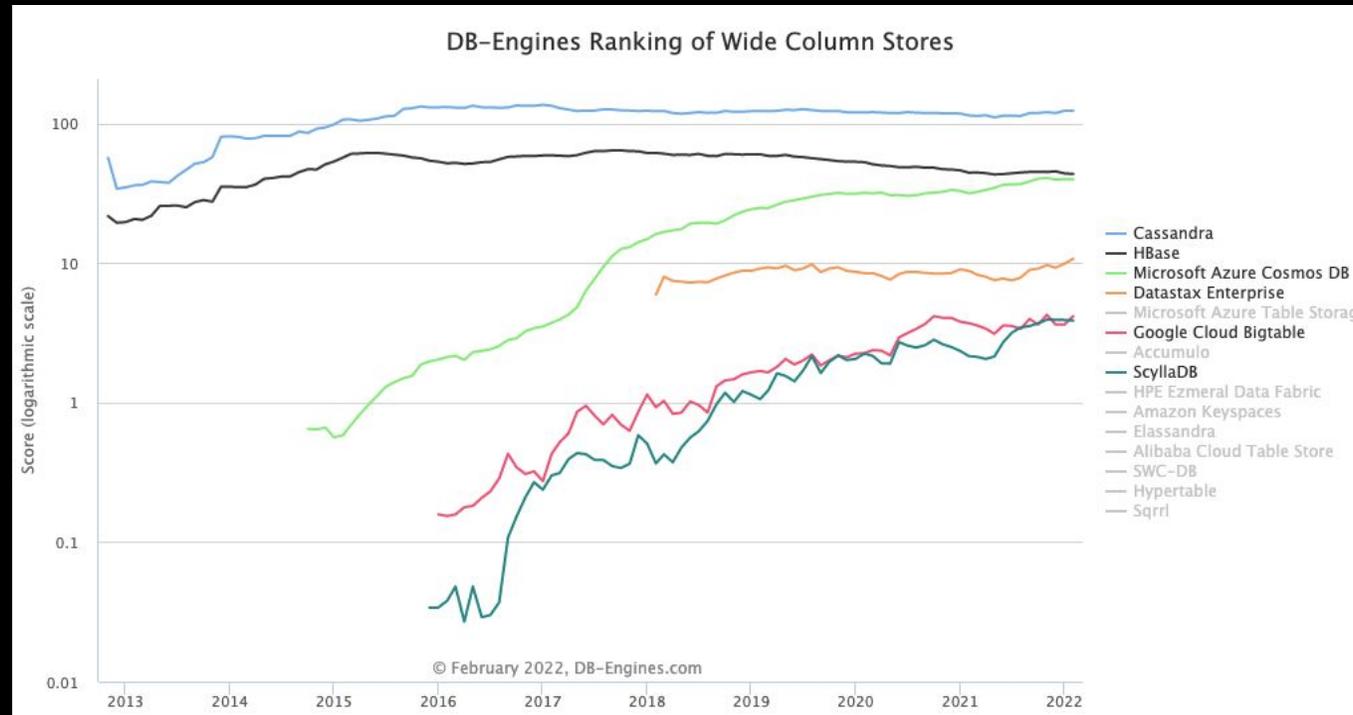


# Wide column store

- Baseados BigTable do Google
- Ao invés de linhas, colunas (atributos)
- Suporta grande volume de requisições R/W
- VLDB
- Dados replicados
- Ex.: Cassandra, Hbase, Azure CosmosDB



# Wide column store



# Wide column store – Use Cases

- Spotify: Cassandra para armazenar User Profile e metadados de Músicas, Playlist, Artistas
- Facebook: Hbase para o guardar mensagens (Messenger) e para o Nearby Friends.
- Pagseguro: Cassandra para receber milhares de transações da Moderninha/minuto.

# Key/Values

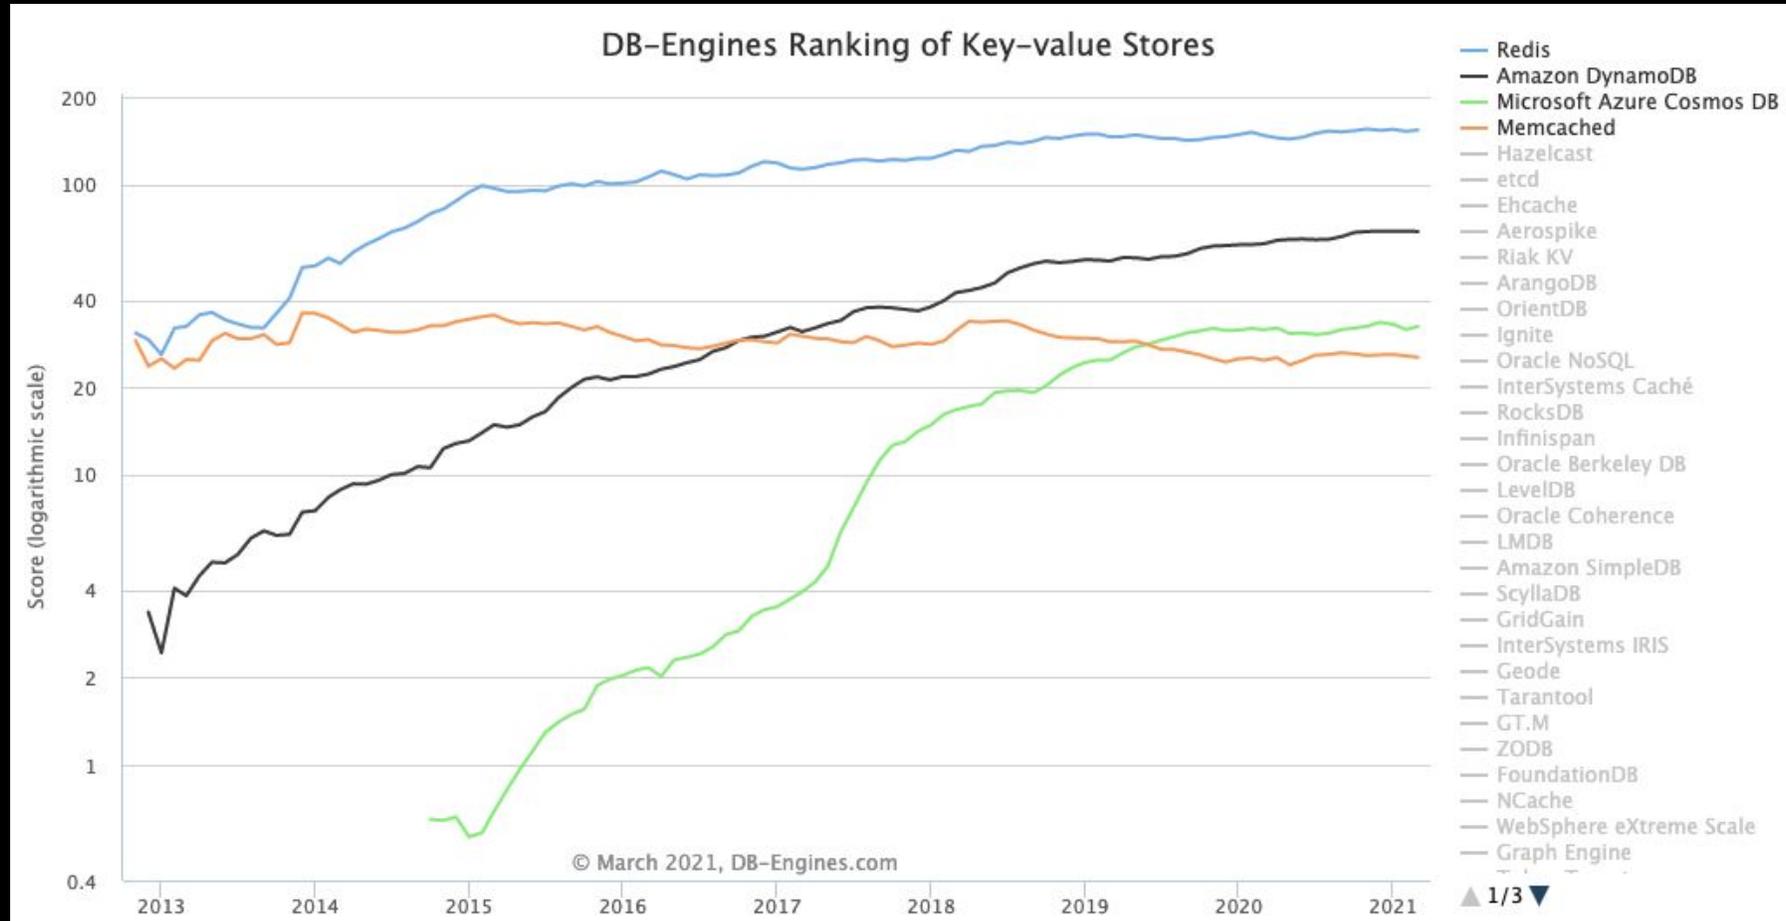
- Moledo mais simples
- Chave: Valor
- Maior taxa R/W entre os NoSQL
- Cache (resposta mais rápida)
- Ex.: MemCached, Redis, DynamoDb

| KEY | VALUE   |
|-----|---|
| 1   | "https://yadax.com.br/imgs/foto.jpg"  |
| 2   | 123   |
| 3   | {"id": "abonacin", "idade": 36, ...}  |
| 4   | [1, 23, 9, 1]   |
| 5   |  yadax |

# Key/Values – Use Cases

- User profile
- Session Info
- Carrinho compra
- Detalhes top produtos
- IP x MAC Info
- Cache

# Key/Values



# Document

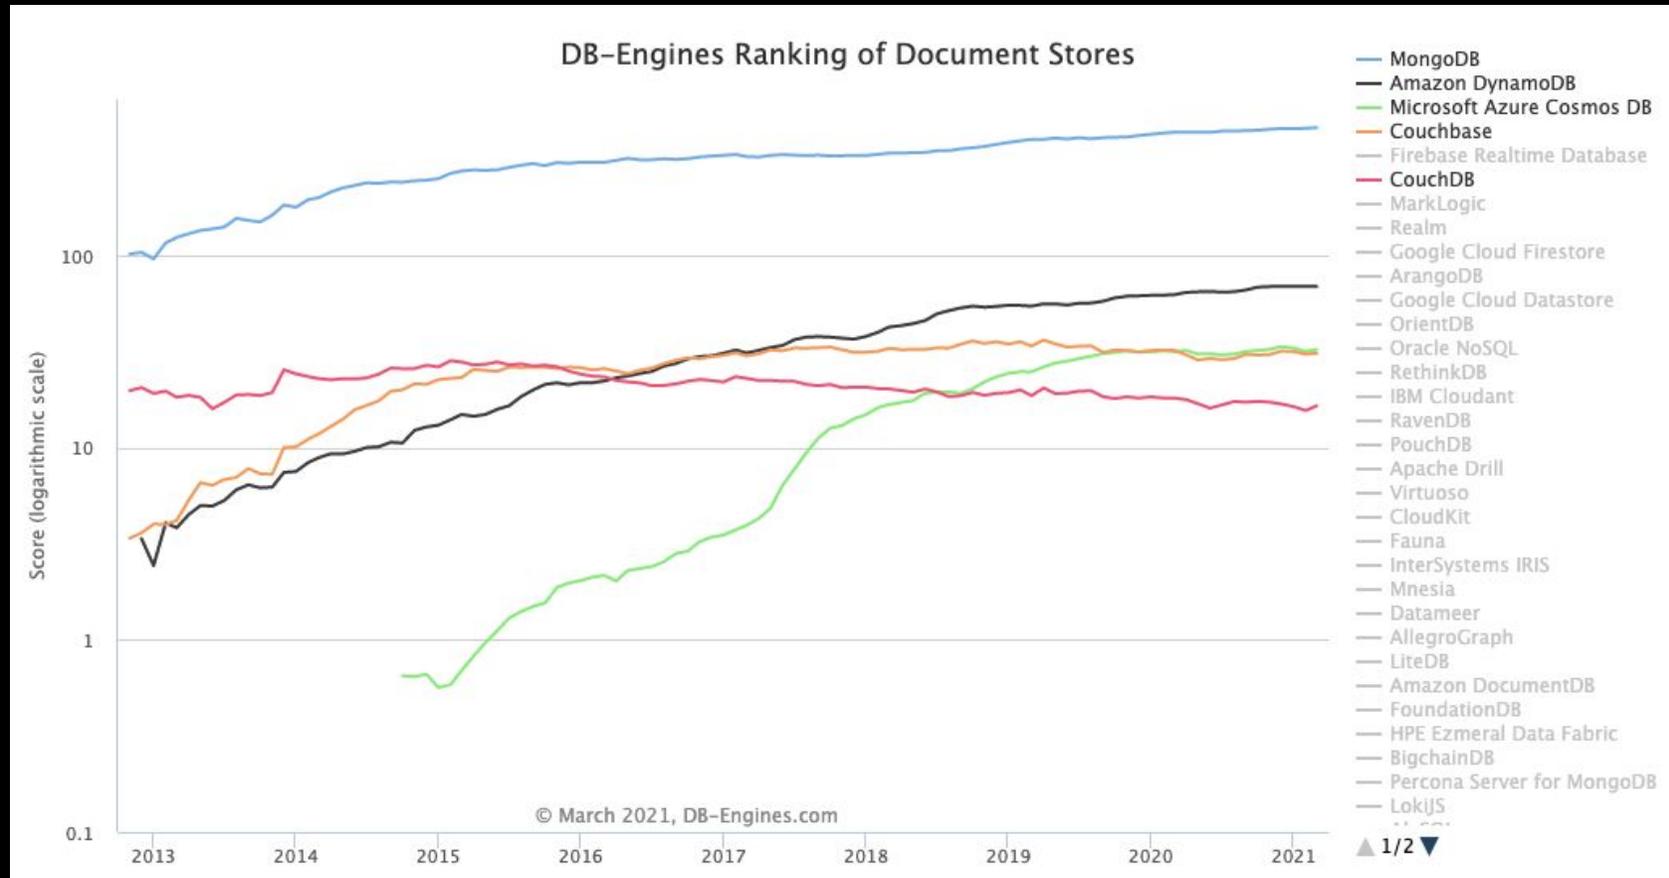
- Armazena docs
  - JSON
  - XML
  - YAML
  - ...
- Permite busca pelos atributos
- Permite doc dentro de doc
- Ex.: MongoDB, DynamoDB, CosmosDB

```
{
  "orders": [
    {
      "orderno": "748745375",
      "date": "June 30, 2088 1:54:23 AM",
      "trackingno": "TN0039291",
      "custid": "11045",
      "customer": [
        {
          "custid": "11045",
          "fname": "Sue",
          "lname": "Hatfield",
          "address": "1409 Silver Street",
          "city": "Ashland",
          "state": "NE",
          "zip": "68003"
        }
      ]
    }
  ]
}
```

# Document – Use Cases

- SEGA: MongoDB para gerenciar milhões de contas de usuário
- Weather Channel: usa MongoDB para notificar em tempo real mais de 40 milhões de usuários
- Genomics England usa MongoDB para permitir ciência de dados em 100,000 projetos de genomas
- Pagseguro: DynamoDB para tracking de emissão de cartões

# Document



# Graph

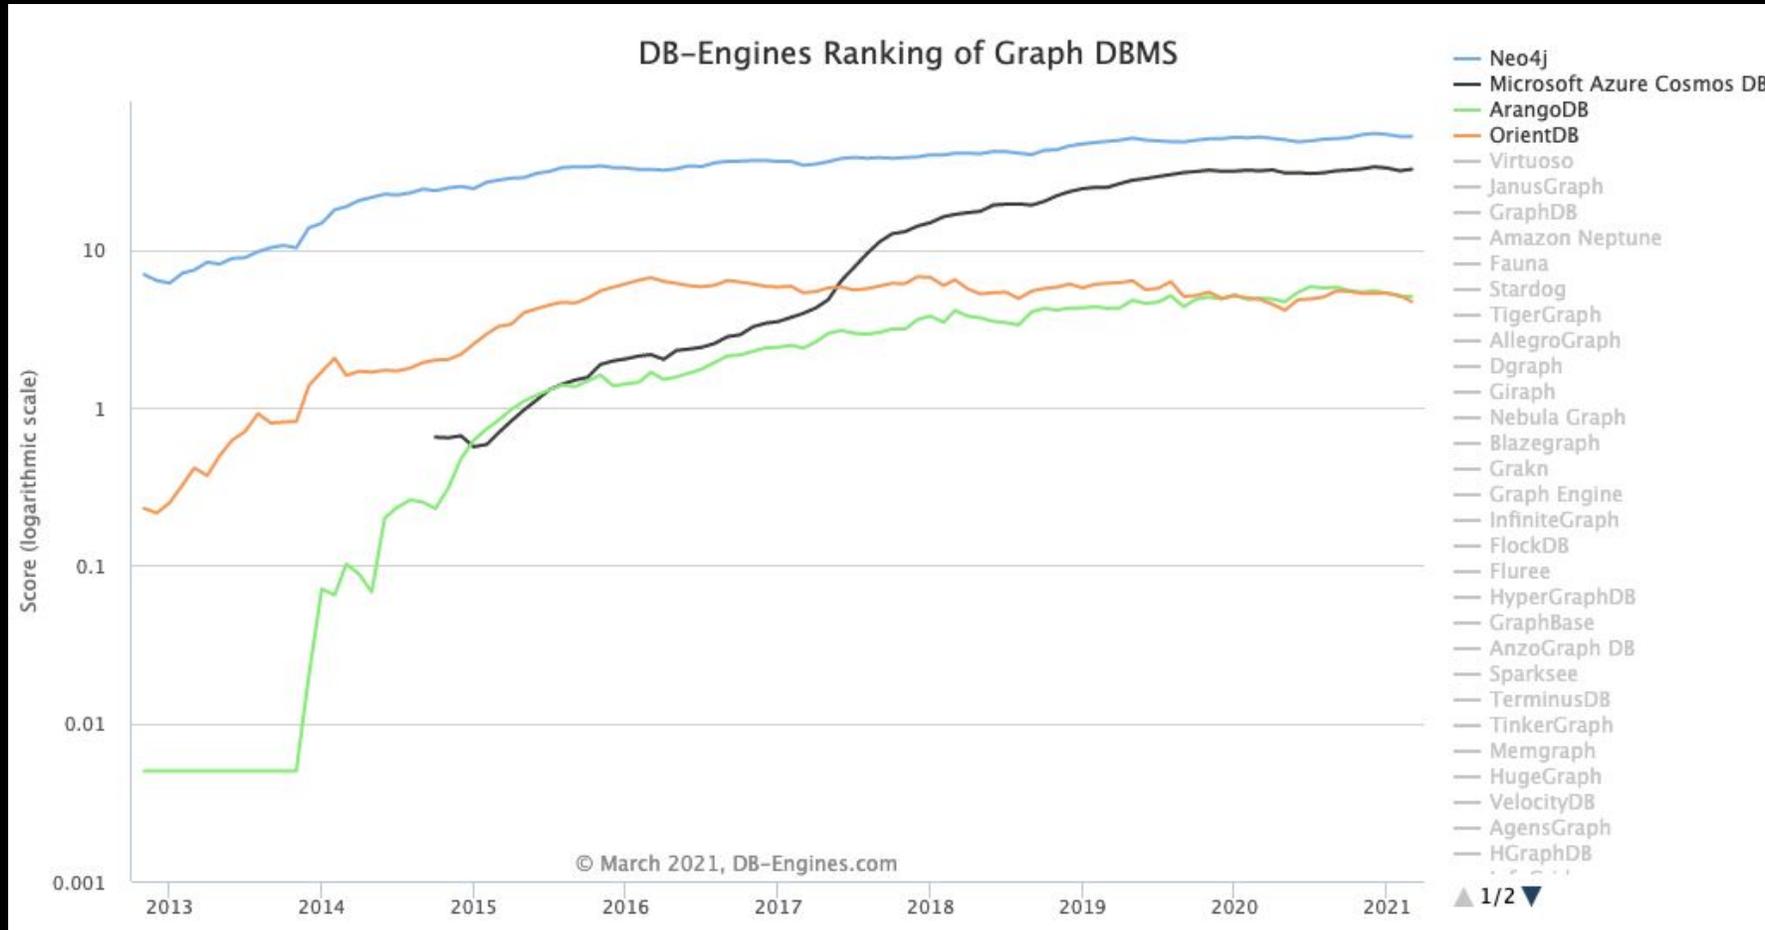
- Armazenar elementos/relações
- Nós/Vértices: Elementos
- Arestas: Relacionamento
- Atributos: vértices e arestas
- Ex.: Neo4J, CosmosDB



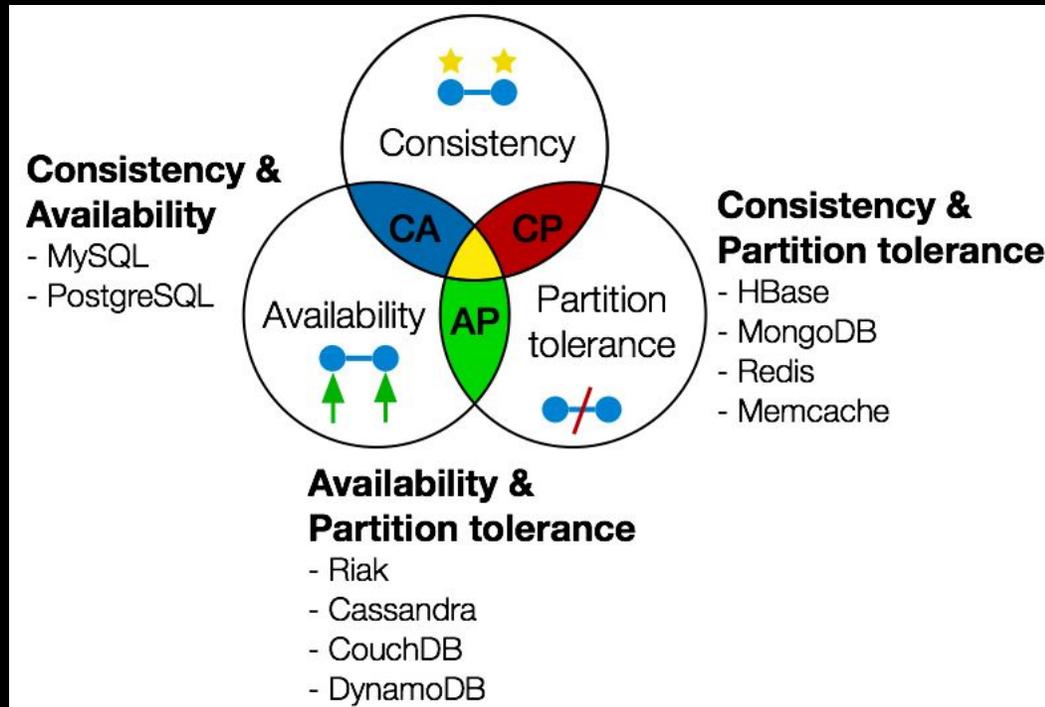
# Graph - Use Cases

- Walmart: Neo4J para recomendação de produtos
- Medium: Neo4J para garantir conteúdo mais relevantes
- Cisco: Para mapear topologias e antecipar à falhas
- UOL: CMDB - para determinar relacionamento entre CIs

# Graph



# Teorema CAP



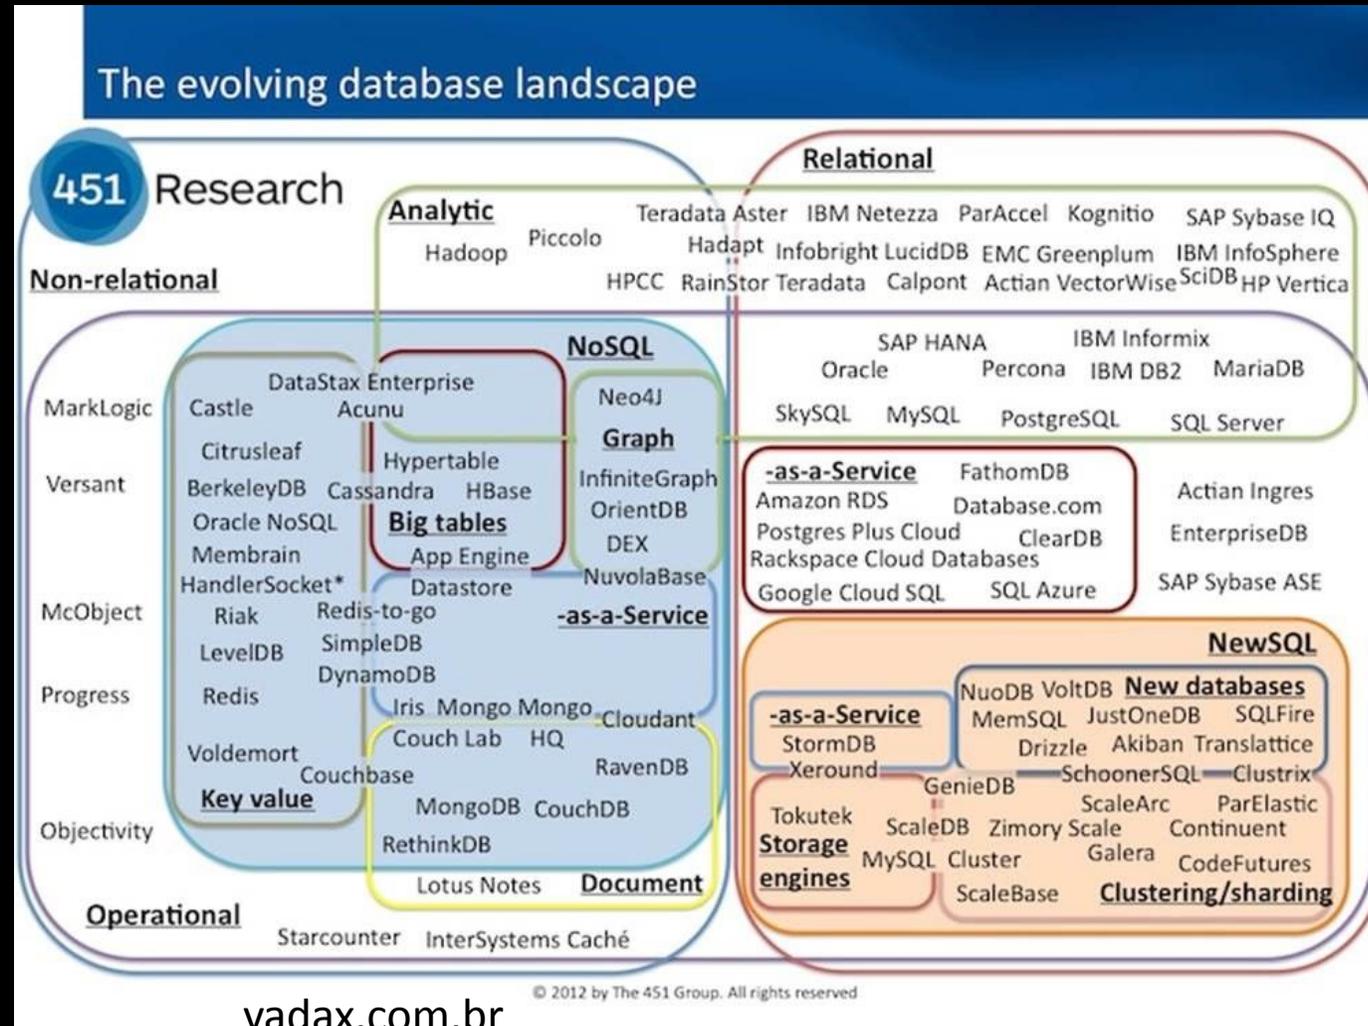
- **Consistency:** Todo mundo vê os dados da mesma forma
- **Availability:** Clientes conseguem ler e escrever
- **Partition Tolerance:** Vai continuar funcionando mesmo que tenha uma falha de comunicação entre os nodes

# Teorema CAP

- Escolha dois



# Uma infinidade



# NoSQL x BigData

- Capacidade de escalar
- Volume da dados, TB/host
- Velocidade
- Nasceram em uma nova era

# APACHE CASSANDRA

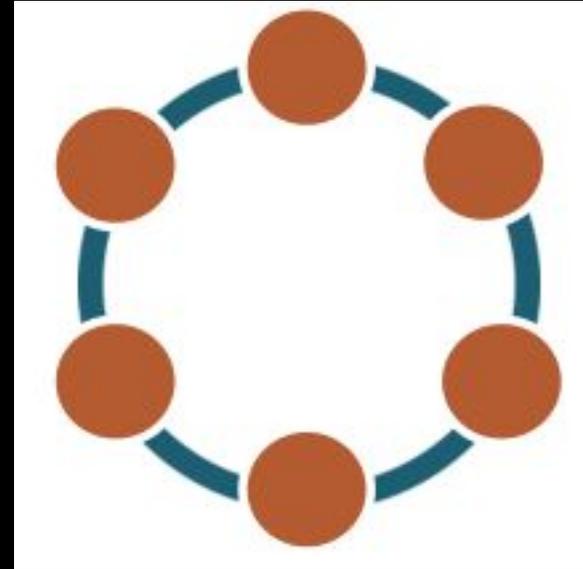
Vamos ao que interessa!

# Distribuições Cassandra

- Apache – Open Source
  - 2.1
  - 2.2
  - 3.0
  - 3.11
  - 4.0
- Datastax – Enterprise
  - 6.8 (3.11)
  - 6.7 (3.11)
  - 6.0 (3.11)
  - 5.1 - EOSL
  - 5.0 - EOSL

# Características do Cassandra

- Tolerância à falha
- Sem ponto único de falha
- Multi master
- Distribuído globalmente
- Escalonamento linear\*
- Always writable\*
- Linguagem similar ao SQL



# Quando não usar

- Queries não usando PK, precisando de Secondary Indexes
- Agregação
- Join
- Locks
- Updates/Deletes
- Transação
- Consistência forte

# Quando usar

- Escrita muito maior que Leitura
- Dados raramente atualizados
- Leitura apenas pela PK
- Dados devem ser particionados
- Sem Join
- Evite Index
- Precisa trabalhar globalmente
- TTL

# Instalando/Gerenciando o Apache Cassandra

Primeiros passos!

# Prereqs

- Última versão do Java 8
  - Oracle
  - Open-jdk
  - > 1.8.0\_161
- Python + 2.7 (cqlsh)



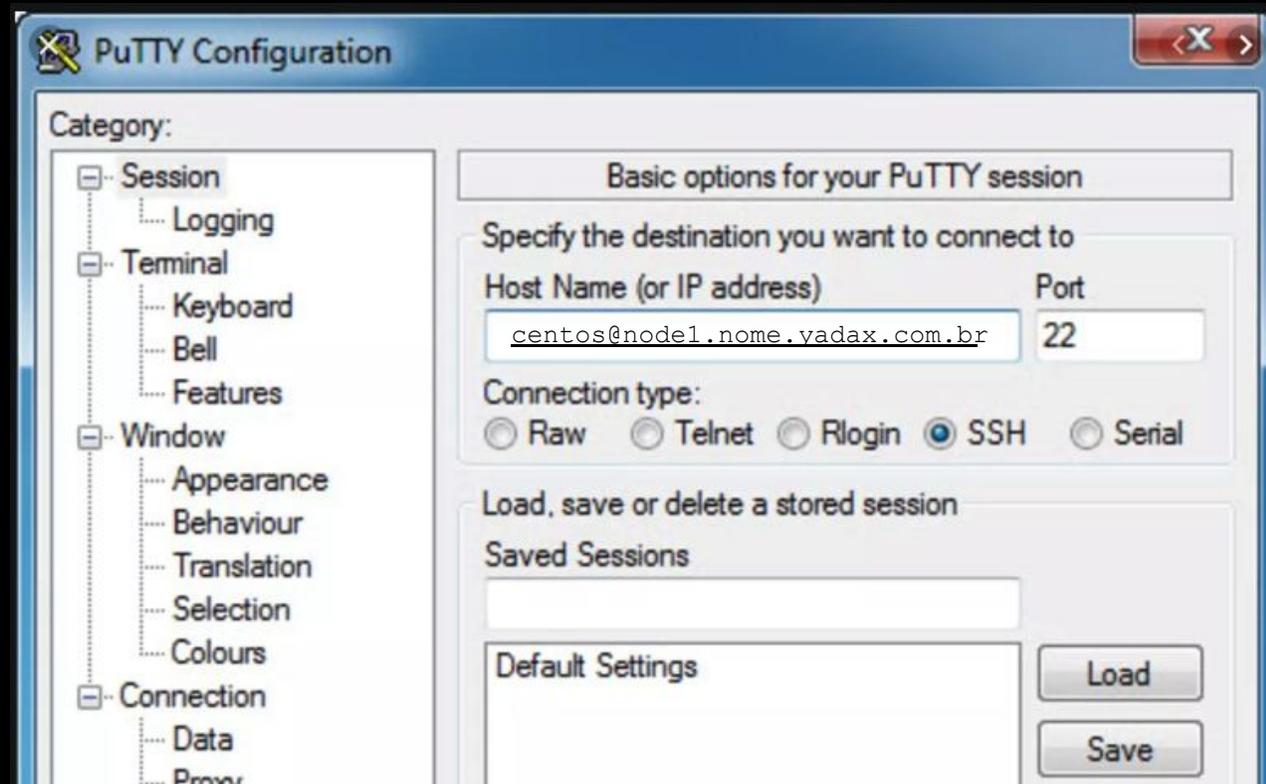
# Sistema operacional

- Usaremos Centos7: Redhat like
  - Pacotes rpm
- Também são suportados:
  - Debian
  - Suse
  - Ubuntu
  - MacOS
  - Oracle Linux
  - Redhat
  - Amazon Linux

- \$ -> Exec com o user cassandra
- # -> Exec com o root

# Conectando

- `ssh centos@node1.dev.yadax.com.br`
- Utilize a senha do centos



# Atualize seu SO

- `[centos@host ~]$ sudo su -`
- `[root@host ~]# yum update -y`
- **5 a 10 min**

# Python

O principal client do Cassandra (cqlsh) é desenvolvido em python.

```
# python -V  
Python 2.7.5
```

# Java

Cassandra roda sobre uma JVM.

```
# java -version
-bash: java: command not found
# yum install -y java-1.8.0-openjdk
# java -version
openjdk version "1.8.0_222"
OpenJDK Runtime Environment (build 1.8.0_222-b10)
OpenJDK 64-Bit Server VM (build 25.222-b10, mixed mode)
```

# Repositório Apache Cassandra

<http://cassandra.apache.org/download/>

- Com "vi", crie o arquivo:

```
# vi /etc/yum.repos.d/cassandra.repo
[cassandra]
name=Apache Cassandra
baseurl=https://www.apache.org/dist/cassandra/redhat/22x/
gpgcheck=1
repo_gpgcheck=1
gpgkey=https://www.apache.org/dist/cassandra/KEYS

i -> começa escrever
Esc + :wq -> Modo comandos + write + quit
```

# Instalando o cassandra

```
# yum install -y cassandra
```

```
...
```

```
...
```

```
# rpm -qa | grep cassandra  
cassandra-2.2.19-1.noarch
```

# Iniciando cassandra

```
# systemctl daemon-reload  
# service cassandra start
```

**ou**

```
# systemctl start cassandra (Linux 7)
```

***Devolve o prompt, mas leva um tempo +- 30 s***

# Iniciando cassandra

<https://issues.apache.org/jira/browse/CASSANDRA-15273>

<https://yadax.com.br/cassandra/erro-ao-startar-apache-cassandra-2-2-16/>

Problema devido à um patch de segurança. Corrigido no 2.2.19

```
[root@ip-172-31-89-81 ~]# service cassandra start
```

```
Reloading systemd: [ OK ]
```

```
Starting cassandra (via systemctl): Job for cassandra.service failed because a  
configured resource limit was exceeded. See "systemctl status cassandra.service" and  
"journalctl -xe" for details.
```

```
[FAILED]
```

# Acompanhe o log

```
tail -10f /var/log/cassandra/system.log
```

```
...
```

```
INFO [main] 2021-06-30 18:59:59,948 Server.java:192 -  
Starting listening for CQL clients on  
localhost/127.0.0.1:9042...
```

tail -f -> vai jogando na tela tudo que ocorre no  
arquivo

CTRL + C devolve o prompt

# Consultando processo java

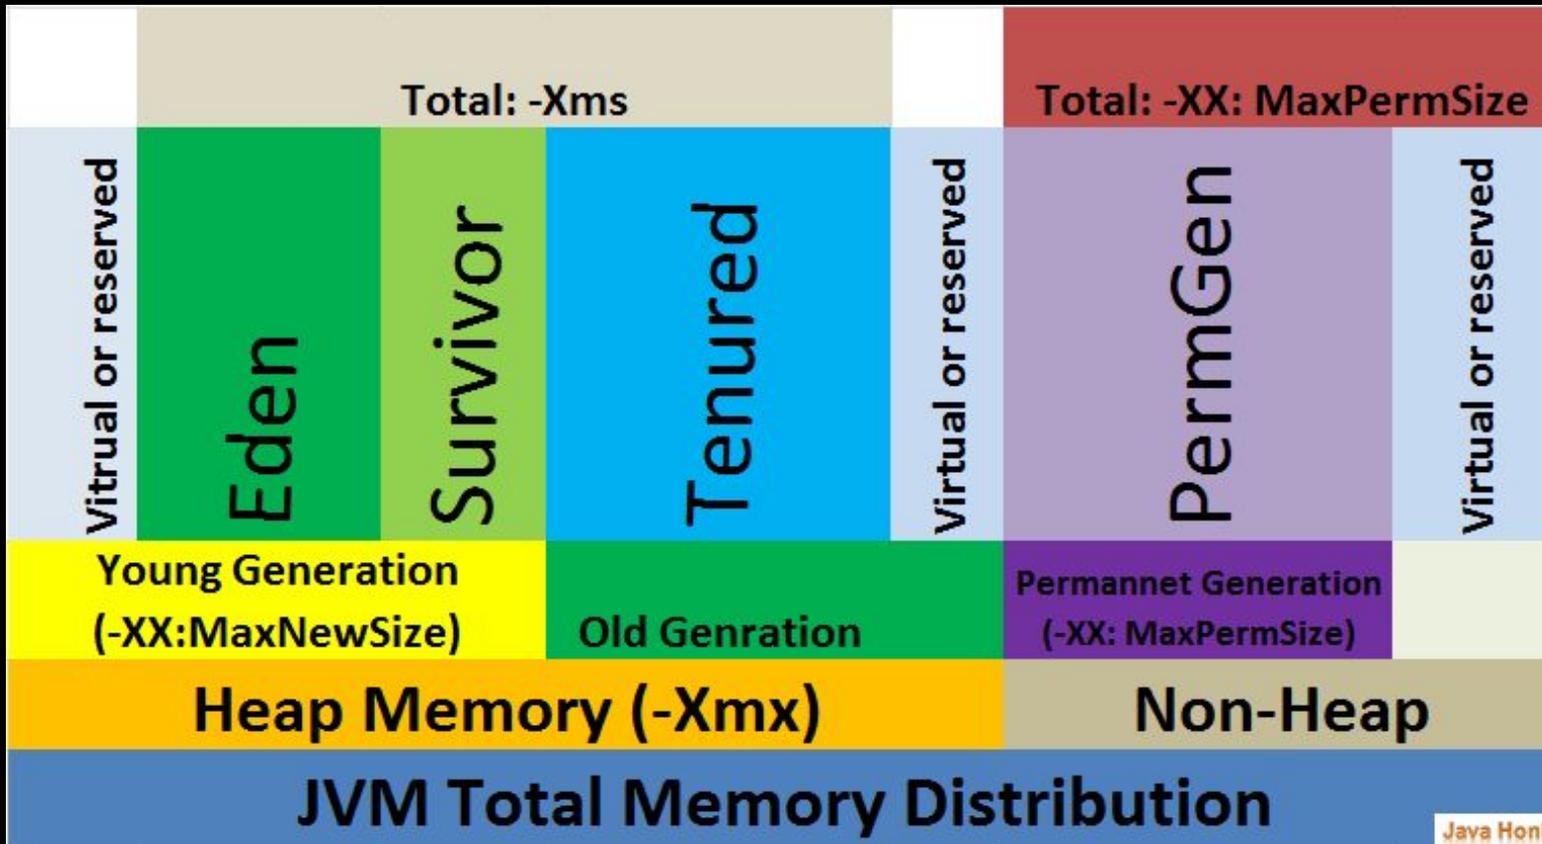
```
# ps -ef | grep java
cassandra 2223 1 /usr/java/jdk1.8.0_144/jre/bin/java
-Ddse.server_process -ea -XX:+UseThreadPriorities -
... -XX:+UseTLAB -XX:+ResizeTLAB -XX:+UseNUMA
-Djava.net.preferIPv4Stack=true -Xms8G -Xmx8G ... ..
...
```

**Xms e Xmx** — são iguais e representam o tamanho da Heap

**2223** — id do processo linux

# Java Memory

- Xmx (max size) = Xms (size)



Java Honk

# Conectando no cqlsh

```
# cqlsh
```

```
Connected to Test Cluster at 127.0.0.1:9042.
```

```
[cqlsh 5.0.1 | Cassandra 2.2.14 | CQL spec 3.3.1 | Native protocol v4]
```

```
Use HELP for help.
```

```
cqlsh> help
```

- **Test Cluster** → Nome do seu cluster
- **127.0.0.1:9042** → IP:PORTA que está conectado

# Conectando no cqlsh

**# netstat -nltp**

**Mostra quais interface/portas o host está “ouvindo”**

**Guarde o resultado.**

**# telnet 127.0.0.1 4321**

**O que acontece quando tentamos acessar uma porta**

```
[root@ip-10-191-18-63 ~]# telnet 127.0.0.1 4321
Trying 127.0.0.1...
telnet: connect to address 127.0.0.1: Connection refused
```

# nodetool

- O nodetool é uma ferramenta que interage com o Cassandra via JMX (falaremos disso mais tarde)
- nodetool status



# Parando cassandra

```
# service cassandra stop
```

**ou**

```
# systemctl stop cassandra
```

**Nas versões antigas, nem sempre funciona. Busque pelo processo java para confirmar. Mate-o se necessário: kill -15 2223**

**... ou -9 se -15 não resolver**

# Parando cassandra

Embora o `stop service` pare o cassandra, há uma forma mais sutil de pará-lo

```
# service cassandra start
```

```
$ nodetool drain – força descarregar todos os dados em memória (flush memtables) para disco (SSTables) e fecha todas as conexões abertas pelo cliente
```

```
# service cassandra stop
```

# Acompanhe o log

```
tail -10f /var/log/cassandra/system.log
```

```
...
```

```
INFO [MemtableFlushWriter:3] 2021-06-30 19:18:57,442  
Memtable.java:353 - Writing  
Memtable-schema_columns@67241001(49.749KiB serialized  
bytes, 967 ops, 0%/0% of on/off-heap limit)
```

```
INFO [MemtablePostFlush:2] 2021-06-30 19:18:57,452  
CompactionManager.java:1549 - Executor has been shut down,  
not submitting background task
```

```
INFO [MemtablePostFlush:2] 2021-06-30 19:18:57,453  
CompactionManager.java:1549 - Executor has been shut down,  
not submitting background task
```

```
INFO [RMI TCP Connection(4)-127.0.0.1] 2021-06-30  
19:18:57,459 StorageService.java:1210 - DRAINED
```

# Habilitando cassandra no boot

```
# chkconfig cassandra on
```

**ou**

```
# systemctl enable cassandra
```

# Logs do Cassandra

```
# tail -f /var/log/cassandra/system.log
```

- **Tem as principais informações sobre a saúde do Cassandra**
- **Informações resumidas sobre GC (Garbage Collector)**

# Outros Logs do Cassandra

```
# tail -f /var/log/cassandra/debug.log
```

**Um pouco mais de informação - DEBUG**

```
# tail -f /var/log/cassandra/gc.log.0.current
```

**Logs da atividade de Gargabe Collector (Java)**

**GC é um dos maiores vilões para o Cassandra**

**Stop the world — O Java congela esperando pelo GC**

# Conhecendo o cassandra.yaml

- Yaml - yet another markup language
- Yadax - yet another database company (yadac), com x fica na moda
- Espaços controlam hierarquia
- Não deve iniciar por espaço
- `pai`
- `filho`
- `neto`
- `bisneto errado, com 1 espaço`

# Conhecendo o cassandra.yaml

- /etc/cassandra/conf/cassandra.yaml (default)
- Sempre traz uma explicação resumida do que o parâmetro representa
- Mantenha o Cassandra **DOWN**
- # service cassandra stop

```
# The name of the cluster. This is mainly used to prevent machines in  
# one logical cluster from joining another.
```

```
cluster_name: 'Yadax'    <<< Faça esta alteração
```

# Conhecendo o cassandra.yaml

```
# This defines the number of tokens randomly assigned to this node on the ring
# The more tokens, relative to other nodes, the larger the proportion of data
# that this node will store. You probably want all nodes to have the same number
# of tokens assuming they have equal hardware capability.
```

```
num_tokens: 16      <<< Faça esta alteração
```

# Conhecendo o cassandra.yaml

Hinted Handoff: Se um node ficar down, outros nodes guardam dados para entregar quando o node voltar.

```
hinted_handoff_enabled: true  
max_hint_window_in_ms: 10800000 # 3 hours
```

# Conhecendo o cassandra.yaml

Por default, não é habilitado autenticação/autorização de usuário.

Todo mundo pode se conectar

Todo mundo pode fazer tudo.

```
authenticator: AllowAllAuthenticator
```

```
authorizer: AllowAllAuthorizer
```

# Conhecendo o cassandra.yaml

Diretório onde ficarão nossos dados

```
data_file_directories:  
  - /var/lib/cassandra/data
```

Estrutura de logs do cassandra para durabilidade de uma escrita.

```
commitlog_directory: /var/lib/cassandra/commitlog  
commitlog_segment_size_in_mb: 32
```

# Conhecendo o cassandra.yaml

É possível fazer ajustes nas estruturas de cache, chaves e/ou linhas inteiras

```
key_cache_size_in_mb: 100MB
```

```
row_cache_size_in_mb: 0
```

```
saved_caches_directory: /var/lib/cassandra/saved_caches
```

# Conhecendo o cassandra.yaml

- Os seeds são nodes especiais, eles controlam quem entra e quem sai do cluster. Sempre será necessário ter um seed vivo.
- Em um novo cluster, sempre o primeiro node a startar precisa ser um seed.
- Mantenha pelo menos 2 seeds por datacenter e igual em todos os nodes

```
seed_provider:  
- class_name: org.apache.cassandra.locator.SimpleSeedProvider  
  parameters:  
    - seeds: "172.31..." <<< Faça esta alteração
```

# Conhecendo o cassandra.yaml

Você precisa informar ao cassandra como ele vai receber as requisições de seus "clientes". Pode ser via IP ou network interface.

```
# listen_address: <<< Faça esta alteração
listen_interface: eth0 <<< Faça esta alteração
# rpc_address: <<< Faça esta alteração
rpc_interface: eth0 <<< Faça esta alteração
```

Para saber o nome da interface, execute:

```
$ ip a
```

# Conhecendo o cassandra.yaml

- O cassandra precisa conhecer todos os membros do cluster.
- O parametro `endpoint_snitch` controla isso.
- Antigamente usava-se um arquivo com a lista de todos os membros x DCs. **Desvantagem?**
- Atualmente (com o `GossipingPropertyFileSnitch` -> `cassandra-rackdc.properties`) cada node informa a qual DC pertence.

```
endpoint_snitch: GossipingPropertyFileSnitch << Faça esta alteração
```

# Snitch

- SimpleSnitch – Single DC
- GossipingPropertyFileSnitch – For production
- PropertyFileSnitch - cassandra-topology.properties (todos os nodes)
- Ec2Snitch – Usa API EC2 para entender a topologia. Cada AZ é um RACK
- Ec2MultiRegionSnitch – O mesmo, cada REGIAO é um DC
- RackInferringSnitch – Baseia no range de IP para determinar o DC

# Outros arquivos de conf

- `cassandra-env.sh`
  - Altera algumas configs de JVM nas versão mais antigas
  - Habilita JMX local/remoto
  - Autenticação do JMX
- `logback.xml`
  - Altera configs do log, como o tamanho do `system.log`
- `jvm.options` (Cassandra 3+)
  - Configurações específicas relacionadas a JVM nas versões mais novas
- `cassandra-rackdc.properties`
  - Usado pelo `GossipingPropertyFileSnitch` para informar Rack/DC

# cassandra-rackdc.properties

- Aqui você determina para cada host em qual DC e Rack ele está
- O resto fica com a Gossip Protocol.
  - “Estou entrando no Cluster, estou no DCA e no RACK1”.

- No seu arquivo deixe:

dc=AWS << Faça esta alteração

rack=Rack1 << Faça esta alteração

**RackAwareness:** Divide o dado entre Racks diferentes

# Limpando nosso Server

```
# service cassandra stop
# ps -ef | grep java

# rm -rf /var/lib/cassandra/data/*
# rm -rf /var/lib/cassandra/commitlog/*
# rm -rf /var/lib/cassandra/saved_caches/*
```

ou

```
# rm -rf /var/lib/cassandra/*/*
```

# Limpendo nosso Server

Após limpar os arquivos, o cassandra sobe novinho. Lembre-se de iniciar por um SEED.

Em um cluster você terá que limpar todos os nodes antes de reiniciá-lo.

# Inicie o cassandra e acompanhe o log

```
# service cassandra start
```

```
# tail -f /var/log/cassandra/system.log
```

# Inicie o cassandra e acompanhe o log

```
INFO [main] 2021-06-30 19:53:24,589  
Server.java:192 - Starting listening for CQL  
clients on /10.191.18.63:9042...
```

```
INFO [main] 2021-06-30 19:53:24,615  
CassandraDaemon.java:540 - ...
```

```
INFO [main] 2021-06-30 19:53:24,615  
CassandraDaemon.java:633 - Startup complete
```

```
INFO [OptionalTasks:1] 2021-06-30 19:53:26,643  
CassandraRoleManager.java:378 - Created default  
superuser role 'cassandra'
```

# Conecte no cassandra

```
$ cqlsh
```

```
Connection error: ('Unable to connect to any servers', { '127.0.0.1': error(111, "Tried connecting to [('127.0.0.1', 9042)]. Last error: Connection refused" ) })
```

O que houve? Estava funcionando!

```
[root@ip-10-191-18-63 ~]# telnet 127.0.0.1 4321
Trying 127.0.0.1...
telnet: connect to address 127.0.0.1: Connection refused
```

# Busque por ajuda!

```
$ cqlsh --help
```

```
Usage: cqlsh.py [options] [host [port]]
```

CQL Shell for Apache Cassandra

O default é localhost (127.0.0.1)

Mas o cassandra ouve(listen) na loopback?

# Ouvindo na 9042

```
$ netstat -nltp | grep 9042
```

```
tcp      0      0 10.191.18.63:9042      0.0.0.0:*      LISTEN      15249/java
```

**Connection Refused:** Você tentou acessar por uma porta que o host/interface não está ouvindo

```
[root@ip-10-191-18-63 ~]# netstat -nltp
Active Internet connections (only servers)
Proto Recv-Q Send-Q Local Address           Foreign Address         State       PID/Program name
tcp      0      0 127.0.0.1:9042          0.0.0.0:*                LISTEN      84143/java
tcp      0      0 0.0.0.0:22              0.0.0.0:*                LISTEN      1763/sshd
```

```
[root@ip-10-191-18-63 ~]# telnet 127.0.0.1 4321
Trying 127.0.0.1...
telnet: connect to address 127.0.0.1: Connection refused
```

# Conecte no cassandra

```
# cqlsh $HOSTNAME
```

```
Connected to Yadax at ip-172-31-93-254.ec2.internal:9042.
```

```
[cqlsh 5.0.1 | Cassandra 2.2.16 | CQL spec 3.3.1 | Native  
protocol v4]
```

```
Use HELP for help.
```

```
cqlsh>
```

Dados: CQL e cqlsh

# Conecte no cassandra, crie sua 1ª keyspace

```
$ cqlsh
cassandra@cqlsh> describe keyspaces;
  system  system_auth  ...

cassandra@cqlsh> CREATE KEYSPACE hello_world WITH
REPLICATION = { 'class' : 'SimpleStrategy',
'replication_factor' : 1 } AND DURABLE_WRITES = true;
```

## Keyspace:

Schema: no oracle

Database: no mysql, mssql

# Create Keyspace

Sintaxe:

```
CREATE KEYSPACE [IF NOT EXISTS] <keyspace_name>  
  WITH replication =  
    {'class': '<replication_strategy>',  
     '<data_center_name>': '<replication_factor>'}  
  AND durable_writes = <true/false>;
```

# Create Keyspace – Single DC

```
CREATE KEYSPACE IF NOT EXISTS yadax
  WITH replication =
    {'class': 'NetworkTopologyStrategy', 'AWS':'1'}
  AND durable_writes = true;
```

Crie esta!

# Create Keyspace – Multi DC

```
CREATE KEYSPACE yadax
  WITH replication = {'class': 'NetworkTopologyStrategy',
    'AWS': '2', 'Azure': '3', 'GCP': '3'}
  AND durable_writes = true;
```

Se multi DC / Cloud

# Replication Strategy

- SimpleStrategy

- Possível definir apenas o **número de réplicas.**

- NetworkTopologyStrategy

- Possível definir **número de réplicas por datacenter.** Utilize mesmo que tenha um DC só.

**REPLICATION  
FACTOR**

# Durable Writes

- True: Escreve no commit log
- False: Bypass no commit log
  - Não recomendado

# Crie sua primeira tabela (column family)

```
cassandra@cqlsh> use yadax;
```

```
cassandra@cqlsh:yadax> create table my_table (id  
int, nome text);
```

```
InvalidRequest: Error from server: code=2200  
[Invalid query] message="No PRIMARY KEY specified  
(exactly one required)"
```

# Crie sua primeira tabela (column family)

```
cassandra@cqlsh:yadax> create table users (  
id int,  
nome text,  
primary key (id));
```

```
insert into users (id, nome) values (1,  
'Adriano');
```

```
commit; ??
```

# DDL da sua keyspace

```
cassandra@cqlsh> describe yadax;
```

```
CREATE KEYSPACE yadax WITH replication = {'class':  
'NetworkTopologyStrategy', 'AWS': '1'} AND  
durable_writes = true;
```

```
CREATE TABLE yadax.users(  
  id int PRIMARY KEY,  
  nome text  
)...  
;
```

# Dicionário de dados

- Também é possível buscar sua tabela no dicionário de dados.

```
SELECT columnfamily_name
FROM   system.schema_columnfamilies
WHERE  keyspace_name = 'yadax';
```

```
columnfamily_name
-----
                users
```

# Partition Key

- Determina qual node será responsável pelo dado
- Partitioner: Valor para o Cluster, não pode ser alterado
- Depende de um algoritmo de Hash - Partitioner
  - RandomPartitioner - Old
  - Murmur3Partitioner – Evolução do Random – DEFAULT (cassandra.yaml)
  - ByteOrderedPartitioner – Distribuído baseado texto

# Partition Key

- Talvez o ponto mais importante do projeto
- Relacionado as maiores falhas de projetos
- Duas histórias tristes
  - Hot spot
  - Dados duplicados

# Clustering Columns

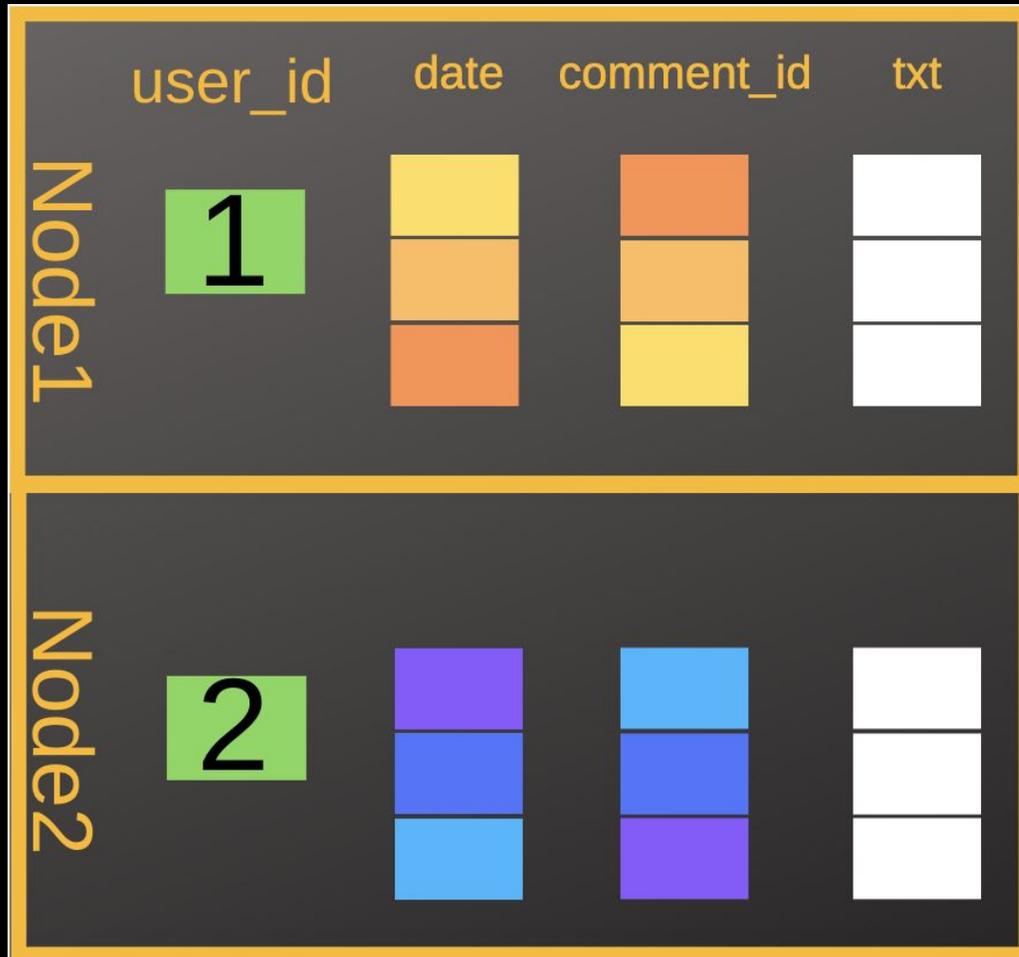
Partition Key determina qual node é responsável pelo dado.

Clustering column determina a ordem que os registros serão ordenados

Útil para casos que deseja dados ordenados na consulta

```
CREATE TABLE comments_by_users
(id_user INT,
 dt_comment DATE,
 id_film TEXT,
 comment TEXT,
 PRIMARY KEY (id_user, dt_comment));
```

# Clustering Columns



| Table | Comentários por usuário |
|-------|-------------------------|
| PK    | USER_ID                 |
| C↑    | COMMENT_DATE            |
| C↓    | COMMENT_ID              |
|       | COMMENT_TXT             |



# Clustering Columns

```
cassandra@cqlsh:yadax> describe comments_by_users
```

```
CREATE TABLE yadax.comments_by_users (  
    id_user int,  
    dt_comment date,  
    comment text,  
    id_film text,  
    PRIMARY KEY (id_user, dt_comment)  
) WITH CLUSTERING ORDER BY (dt_comment ASC)
```

# Clustering Columns

```
PRIMARY KEY (id_user, dt_comment)
```

Vamos inserir 4 registros, o último duplicado.

# Clustering Columns

```
> insert into yadax.comments_by_users (id_user, dt_comment,  
id_film, comment) values (1, '2019-02-02', 'A', 'Foi legal');
```

```
> insert into yadax.comments_by_users (id_user, dt_comment,  
id_film, comment) values (1, '2019-01-01', 'B', 'Foi legal também');
```

```
> insert into yadax.comments_by_users (id_user, dt_comment,  
id_film, comment) values (1, '2019-03-03', 'C', 'Foi bom');
```

```
> insert into yadax.comments_by_users (id_user, dt_comment,  
id_film, comment) values (1, '2019-03-03', 'C', 'Muito bom');
```

# Clustering Columns

```
> SELECT *  
FROM   comments_by_users  
WHERE  id_user = 1;
```

| id_user | dt_comment | comment          | id_film |
|---------|------------|------------------|---------|
| 1       | 2019-01-01 | Foi legal também | B       |
| 1       | 2019-02-02 | Foi legal        | A       |
| 1       | 2019-03-03 | Muito bom        | C       |

O que houve?

Primary Key =  
Partition Key + Clustering Columns

# Allow Filtering (caca)

```
> select * FROM hello_world.comments_by_users where  
dt_comment = '2019-02-02';
```

InvalidRequest: Error from server: code=2200 [Invalid query] message="Cannot execute this query as it might involve data filtering and thus may have unpredictable performance. If you want to execute this query despite the performance unpredictability, use **ALLOW FILTERING**"

# Allow Filtering

```
> select * FROM hello_world.comments_by_users where  
dt_comment = '2019-02-02' ALLOW FILTERING;
```

| id_user | dt_comment | comment   | id_film |
|---------|------------|-----------|---------|
| 1       | 2019-02-02 | Foi legal | A       |

**REPITA COMIGO:**

**BUSQUE SEMPRE PELA PK!**

Se você precisa buscar de forma diferente, você não deveria estar usando Cassandra.

# Partition Key Composta

```
CREATE TABLE logs_by_location (  
  location_id TEXT,  
  day INT,  
  time_in TIMESTAMP,  
  log TEXT,  
  PRIMARY KEY ((location_id, day), time_in));
```

Precisa separar por vírgulas dentro dos ()

# Clustering Order

```
CREATE TABLE logs_by_location (  
  location_id TEXT,  
  day INT,  
  time_in TIMESTAMP,  
  log TEXT,  
  PRIMARY KEY ((location_id, day), time_in))  
WITH CLUSTERING ORDER BY (time_in DESC);
```

# UPSERT (bruxaria)

```
SELECT *  
FROM yadax.logs_by_location;
```

| location_id             | day | time_in | log |
|-------------------------|-----|---------|-----|
| -----+-----+-----+----- |     |         |     |

# UPSERT (bruxaria)

```
UPDATE yadax.logs_by_location
SET log = 'Tudo OK'
WHERE location_id = 'Host 1'
AND day = 1
AND time_in = '2019-01-01 04:00';
```

# UPSERT

- O que acontece agora que você fez um update em um registro que não existe?
- O que você espera?

# UPSERT

```
SELECT *  
FROM yadax.logs_by_location;
```

| location_id | day | time_in                  | log     |
|-------------|-----|--------------------------|---------|
| Host 1      | 1   | 2019-01-01 04:00:00+0000 | Tudo OK |

# Secondary Index

```
SELECT *  
FROM   yadax.logs_by_location  
WHERE  location_id = 'Host 1'  
AND    day = 1;
```

**Esta forma (location\_id AND day), OK!**

# Secondary Index

```
SELECT *  
FROM   yadax.logs_by_location  
WHERE  day = 1;
```

```
InvalidRequest: Error from server: code=2200 [Invalid query]  
message="Partition key parts: location_id must be restricted  
as other parts are"
```

# Secondary Index

```
> create index logs_day on yadax.logs_by_location(day);
```

```
> cassandra@cqlsh:yadax> select * from yadax.logs_by_location  
where day = 1;
```

| location_id | day | time_in                  | log     |
|-------------|-----|--------------------------|---------|
| Host 1      | 1   | 2019-01-01 04:00:00+0000 | Tudo OK |

# Secondary Index

- Devem ser bem planejados
- Evite baixa cardinalidade (poucos valores distintos)
- Evite alta cardinalidade (prefira Mview, mas não use Mview 😊 )
- Não utilize em colunas que sofrem updates

# Query Driven

- O Cassandra não é flexível
- O dado não será normalizado
- Uma tabela para cada consulta
- Pense primeiro na query, depois na tabela
- Sua app precisa popular todas as tabelas

# Materialized View – 3+

- Veio para diminuir o problema de ser query driven
- Cria outra “tabela” com uma PK diferente, mantida pelo próprio Cassandra.
- Você joga para o banco uma responsabilidade da app.

# Datatypes

| Type                   | Supported        | Description  |
|------------------------|------------------|--|
| ascii, text            | strings          | US-ASCII character string, UTF-8 encoded string                        |
| bigint, int            | integers         | 64/32-bit signed long  |
| blob                   | blobs            | Arbitrary bytes (no validation), expressed as hexadecimal              |
| boolean                | booleans         | true or false  |
| counter                | integers         | Distributed counter value (64-bit long)                                |
| Date, time, timestamp  | strings          | yyyy-mm-dd, HH:MM:SS[.fff], yyyy-mm-dd[(T  )HH:MM:SS[.fff]][(+ -)NNNN] |
| Decimal, double, float | integers, floats | Java type  |
| list                   |                  | [literal, literal, literal]  |
| map                    |                  | { key : value, key : value ... }                                       |
| set                    |                  | { literal, literal, literal }  |

# CONSISTENCY

- Determina o número mínimo de hosts envolvidos em uma operação de escrita/leitura
- $\text{Quorum} = \text{TRUNC}((\text{RF} / 2)) + 1$
- Principais
  - ONE
  - TWO
  - LOCAL\_QUORUM
  - EACH\_QUORUM
  - QUORUM
  - ALL

# Arquitetura Cassandra

# Ring ou Cluster

- Single instance -> Node
- Grupo de Nodes -> Cluster / Ring
- Cada Node é responsável por um range de Tokens
- Cada PartitionKey é hasheada para um token específico

| Node – RF 3 | Range Prim | Range Sec  | Range Ter  |
|-------------|------------|------------|------------|
| 1           | -100 a -67 | 1 a 33     | 67 a 100   |
| 2           | -33 a 0    | -100 a -67 | 1 a 33     |
| 3           | 34 a 66    | -33 a 0    | -100 a -67 |
| 4           | -66 a -34  | 34 a 66    | -33 a 0    |
| 5           | 67 a 100   | -66 a -34  | 34 a 66    |
| 6           | 1 a 33     | 67 a 100   | -66 a -34  |

# Token vs Ring

- Primary key: (nome, idade)
- Nome = 'AdrianO' -> Token: 84
- Nome = 'Raul' -> Token: -49
- Nome = 'AdrianA' -> Token: -3

| Node – RF 3 | Range Prim | Range Sec  | Range Ter  |
|-------------|------------|------------|------------|
| 1           | -100 a -67 | 1 a 33     | 67 a 100   |
| 2           | -33 a 0    | -100 a -67 | 1 a 33     |
| 3           | 34 a 66    | -33 a 0    | -100 a -67 |
| 4           | -66 a -34  | 34 a 66    | -33 a 0    |
| 5           | 67 a 100   | -66 a -34  | 34 a 66    |
| 6           | 1 a 33     | 67 a 100   | -66 a -34  |

- Esta forma é conhecida como:  
single token range per node  
(antigo)

# VNodes

| Node - RF 3 | Range Prim | Range Sec  | Range Ter  |
|-------------|------------|------------|------------|
| 1           | -100 a -67 | 1 a 33     | 67 a 100   |
| 2           | -33 a 0    | -100 a -67 | 1 a 33     |
| 3           | 34 a 66    | -33 a 0    | -100 a -67 |
| 4           | -66 a -34  | 34 a 66    | -33 a 0    |
| 5           | 67 a 100   | -66 a -34  | 34 a 66    |
| 6           | 1 a 33     | 67 a 100   | -66 a -34  |

- Com os vnodes, temos varios ranges por host
- Initial\_tokens controlam a quantidade de ranges
- Por isso a quantidade de dados é proporcional ao # ranges

| Node - RF 3 | Range Prim | Range Prim | Range Prim |
|-------------|------------|------------|------------|
| 1           | -100 a -91 | 51 a 60    | 91 a 100   |
| 2           | 1 a 10     | -90 a -81  | -50 a -41  |
| 3           | 31 a 40    | 51 a 60    | -40 a -31  |
| 4           | -80 a -71  | 41 a 50    | -70 a -61  |
| 5           | -20 a -11  | -60 a -51  | -30 a -21  |
| 6           | 61 a 70    | 81 a 90    | 91 a 100   |
| 7           |            | 71 a 80    |            |
| 8           | -10 a 0    | 11 a 20    | 21 a 30    |

INITIAL TOKENS

# Partitioner

- É quem determina a forma de gerar os tokens
- Função Hash
- ByteOrderedPartitioner
- RandomPartitioner
- **Murmur3Partitioner (default)**

# Estrutura de dados

- MemTable
  - Mem(ory) Table
  - Representação da tabela em memória
  - Toda escrita acontece na Memtable + commit log.
  - De tempos em tempos, a memtable é “descarregada” para disco

# Memtable - Parâmetros

- memtable\_flush\_writers
- memtable\_heap\_space\_in\_mb
- memtable\_cleanup\_threshold
- memtable\_flush\_period\_in\_ms (per table)
- memtable\_allocation\_type

# Memtable - Flush

- Commit log cheio
- Periodicamente, baseado no `memtable_flush_period_in_ms`
- Threshold atingido - `memtable_cleanup_threshold`
- Manualmente
  - `nodetool flush`

# Estrutura de dados

- SSTable
  - Sorted String Table
- Conceito do Google BigTable
- Imutável
- Persistente, disco
- Criada com o Flush da Memtable
- Ordenada pelo Hash da PK

# SSTables

```
# pwd
```

```
/var/lib/cassandra/data/yadax/scores-42b59f00dd7211e987a79d4050c7a079
```

```
# ll
```

```
-rw-r--r--. 1 cassandra cassandra 43 Sep 22 20:53 lb-1-big-CompressionInfo.db
-rw-r--r--. 1 cassandra cassandra 692 Sep 22 20:53 lb-1-big-Data.db
-rw-r--r--. 1 cassandra cassandra 10 Sep 22 20:53 lb-1-big-Digest.adler32
-rw-r--r--. 1 cassandra cassandra 24 Sep 22 20:53 lb-1-big-Filter.db
-rw-r--r--. 1 cassandra cassandra 127 Sep 22 20:53 lb-1-big-Index.db
-rw-r--r--. 1 cassandra cassandra 4516 Sep 22 20:53 lb-1-big-Statistics.db
-rw-r--r--. 1 cassandra cassandra 93 Sep 22 20:53 lb-1-big-Summary.db
-rw-r--r--. 1 cassandra cassandra 94 Sep 22 20:53 lb-1-big-TOC.txt
```

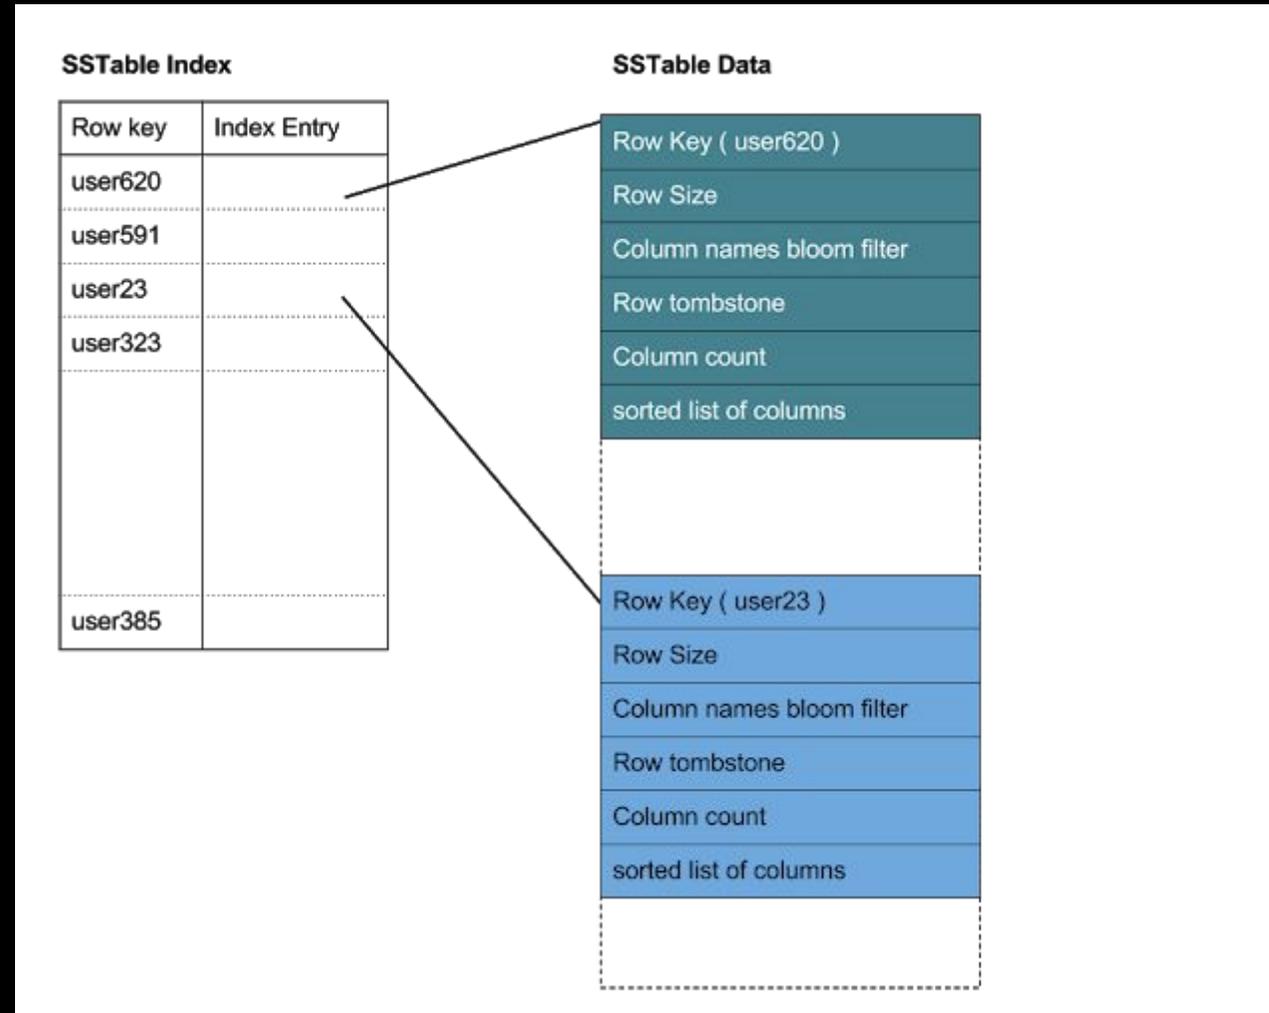
# SSTables

- Data - Data.db
  - Dados da SSTable
- Primary Index – Index.db
  - Índice das Partitions Keys apontando para sua posição no datafile
- Bloom Filter – Filter.db
  - Réplica de uma estrutura de memória (bloom filter) que verifica se a linha pode existir naquela Memtable
- Compression Info - CompressionInfo.db
  - Informações a respeito de dados não comprimidos, localização e outras infos referentes a compressão.

# SSTables

- **Statistics - Statistics.db**
  - Metadados referentes a estatísticas envolvendo dados da SStable
- **Digest - Digest.adler32**
  - Arquivo contendo Checksum do datafile
- **SSTable Index Summary – Summary.db**
  - Porção (sample) do partition index
- **Table of Contents – TOC.txt**
  - Contém a lista dos arquivos em formato texto

# SSTable Index



# Bloom Filter

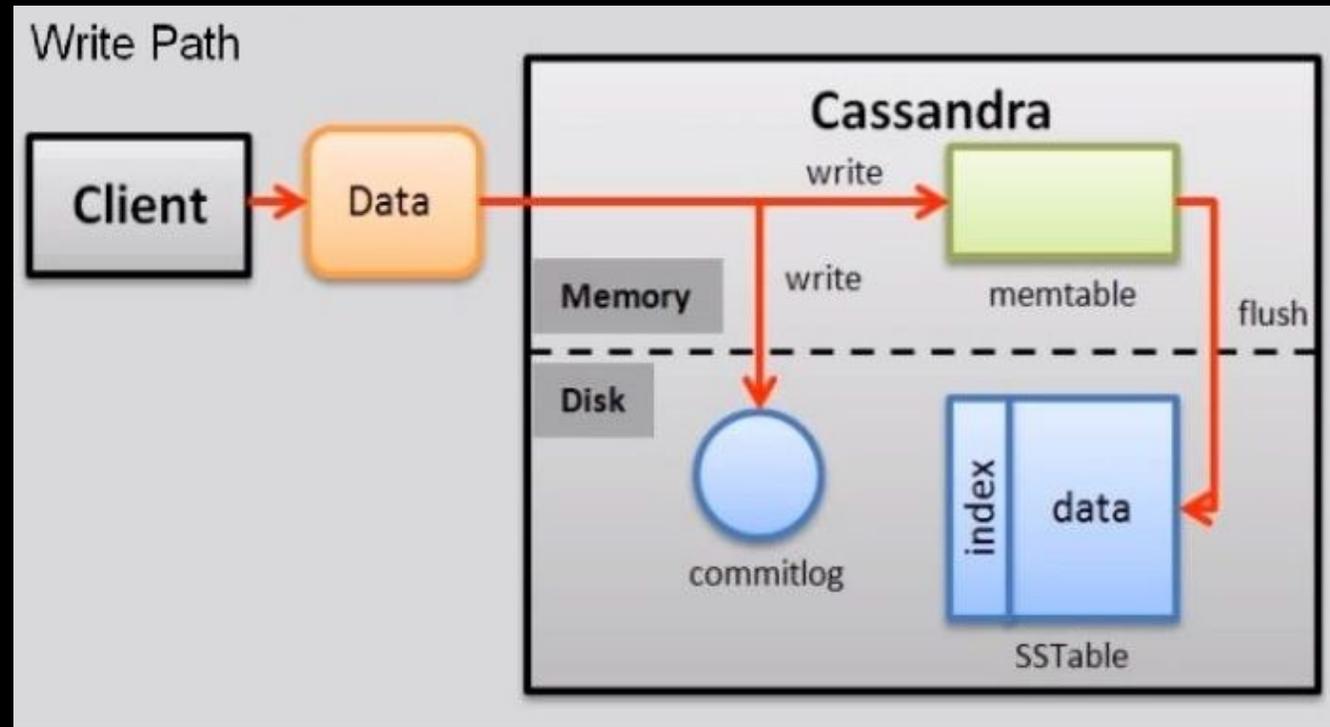
- Probabilistic data Structure
- Pode haver falsos positivos: Possivelmente existe a PK
- Não há falsos negativos: Não existe esta PK

# CommitLog

- Redo Log – Oracle
  - Binany Log – Mysql
  - Transaction Log – MSSql
  - WAL - Postgres
- 
- Garante a durabilidade da transação
  - Utilizado caso o Host Falhe (crash).
  - Escrito sequencialmente

# CommitLog

- `commitlog_directory`
- `commit_failure_policy`
- `commitlog_segment_size_in_mb`
- `commitlog_total_space_in_mb`



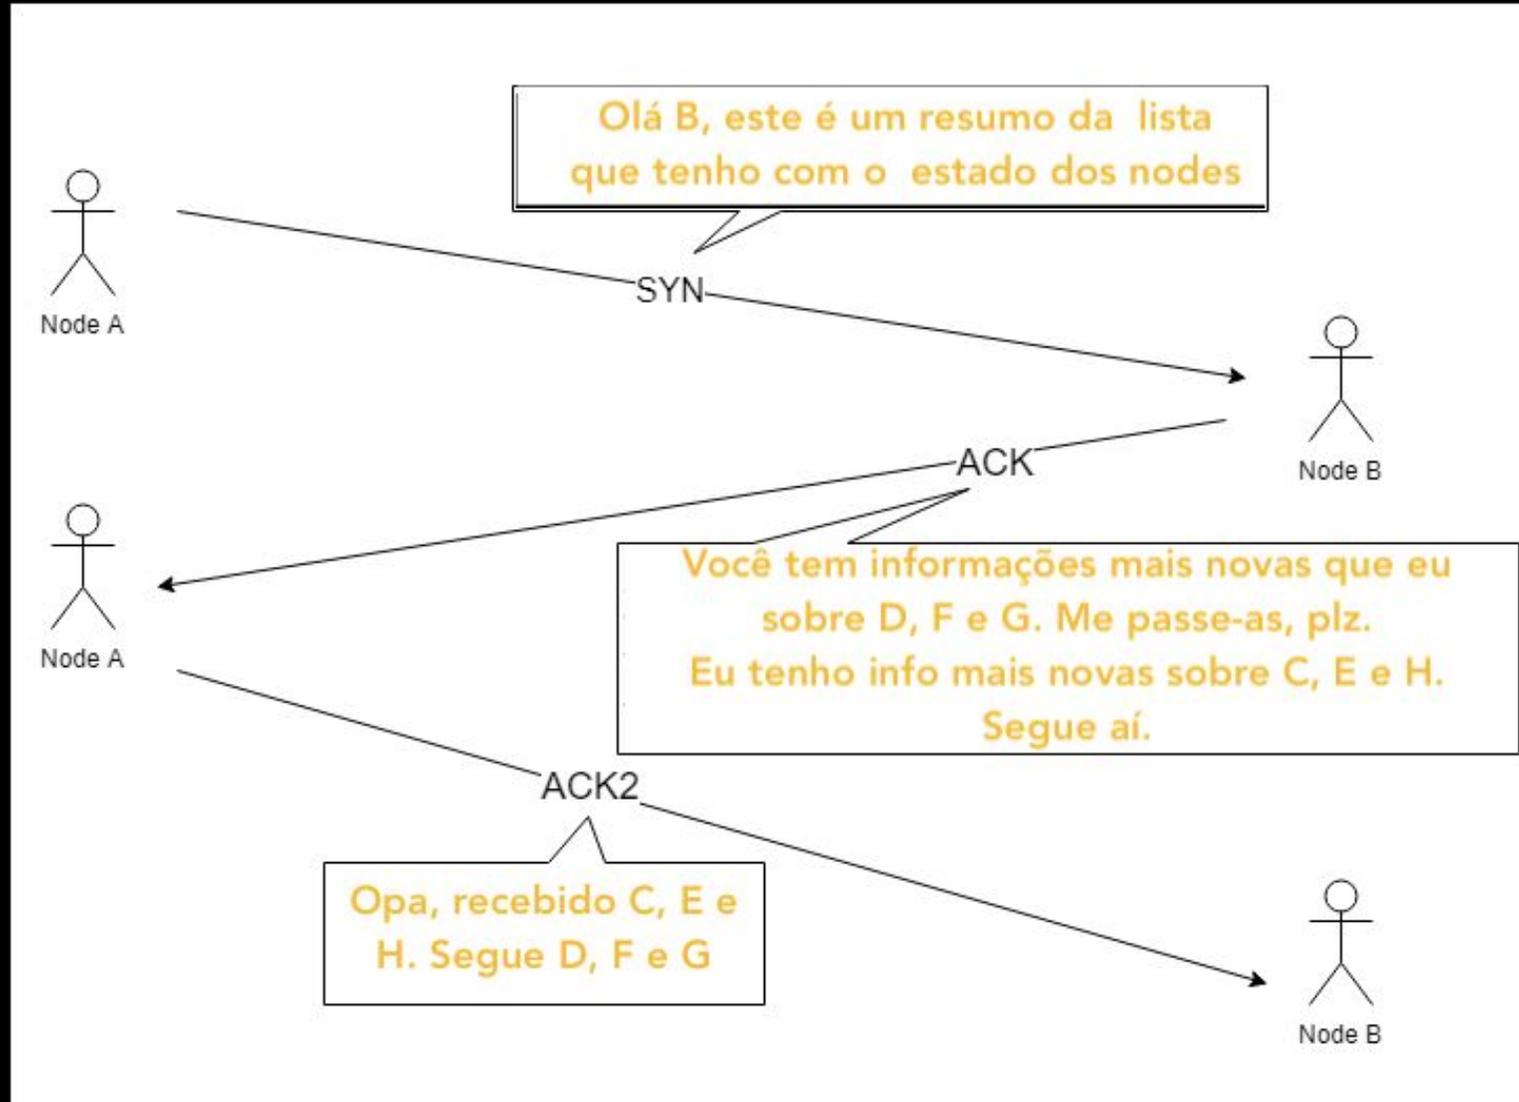
# Hinted Handoff

- O Cassandra é altamente disponível
- Isso leva pessoas escolherem ele, mesmo não se adaptando ao cases de uso
- Uma das peças chaves são as hinted handoff
- Quando um node falha, o outro assume suas obrigações
- Se o node 2 falha, o node 1 pode atuar como **coordinator**
- Ele guarda os registros que deveriam estar com o 2
- Entrega quando o node 2 voltar.

# Hinted Handoff

- Quando o node volta, as Hints são entregues
  - Se o node fica fora por mais de `max_hint_window_in_ms`, será necessário um repair para colocar a casa em ordem
- 
- `hinted_handoff_enabled`
  - `max_hint_window_in_ms`
  - `hinted_handoff_throttle_in_kb`
  - `max_hints_delivery_threads`

# Gossip Protocol



# Gossip Protocol

- Normalmente um node conversa com até três nodes a cada segundo
- Não há restrição/determinação sobre com quem conversar
- Não armazenam com quem falou anteriormente
- Modo eficiente de espalhar a topologia e saúde do cluster
- Espalha topologia – Rack e DC
- Espalha donos de tokens
- Status do colega: Normal, Joining, Down, Leaving
- Load do colega: CPU, Disco, ...

# CLUSTER

# Mãos a obra?

- Vamos criar nosso cluster.

# Configuração Cluster - Overview

- O melhor do Cassandra é sua alta disponibilidade
- Multi Master
  - Isso é para poucos
- Multi Datacenters
- Sem ponto único de falha
- SEEDs controlam quem entra e quem sai
  - Use 2 ou 3 por DC
- Todos precisam ter o mesmo CLUSTER\_NAME

# Configuração Cluster - Overview

- Vamos usar o GossipingPropertyFileSnitch como snitch
- É preciso configurar o cassandra-rackdc.properties
- Os nodes precisam se falar na porta 7000 e 7001 (listen\_address)
- A distribuição de dados entre nodes será proporcional ao num\_tokens

# Configuração Cluster – Mão a obra

- Acesse suas 6 maquinas para certificar que está tudo OK.
- Crie o repositório yum em todos os nodes
- Instale o cassandra 2.2 em todos os nodes
- Neste casos, ferramentas para executar a mesma ação em diversos nodes ajuda:
  - Win: Moba
  - Mac: iTerm
  - Linux: Terminator
- Pense como seria bom isso tudo isso ser automático



# Configuração Cluster – Mão a obra

- Escolha 3 para o DCA e 3 para o DCB
- Escolha 2 do DCA e 2 do DCB para serem SEEDs
- Para o DCA, o `cassandra-rackdc.properties` deve ficar:
  - `dc=DCA`
  - `rack=RACK1`
- Faça o mesmo para o DCB

# Configuração Cluster – Mão a obra

- Escolha o nome do seu cluster
- Mude o `endpoint_snitch` para `GossipingPropertyFileSnitch`
- Veja o IP dos hosts
- Limpe os dados dos nodes, caso já tenha sido utilizado

# ARQUIVOS DE CONF

# Configuração Cluster – Mão a obra

- Estes são os parâmetros que você vai precisar alterar no `cassandra.yaml`:
  - `cluster_name`: Yadax
  - `num_tokens`: 16
  - `seeds`: ip1, ip2, ip4, ip5
  - `# listen_address` -> comentar (# no começo da linha)
  - `listen_interface` -> eth0 (utilizar “ip a” para descobrir)
  - `# rpc_address`: -> comentar (# no começo da linha)
  - `rpc_interface`: eth0
  - `endpoint_snitch`: GossipingPropertyFileSnitch

# Configuração Cluster – Mão a obra

- Estes são os parâmetros que você vai precisar alterar no `cassandra-rackdc.properties`:

`dc=DCA`

`rack=RACK1`

START DO CLUSTER

# Configuração Cluster – Mão a obra

- Start primeiro um dos seeds
- Acompanhe o log
- Verifique a saúde do cluster, os datacenters onde a maquina se encontra.
- nodetool status

# Crie um alias para o system.log

```
# echo "alias alert='tail -10f /var/log/cassandra/system.log'" >> ~/.bash_profile

# . ~/.bash_profile

# alert
```

# Crie uma keyspace

```
cassandra@cqlsh>
```

```
CREATE KEYSPACE yadax
```

```
WITH replication = {'class': 'NetworkTopologyStrategy',  
'DCA': '1'} AND durable_writes = true;
```

COPY

# COPY

- Verifique no node1 se existem arquivos na pasta `/tmp/2msales.csv`
- `# head -2 /tmp/2msales.csv`

# COPY

```
CREATE KEYSPACE killrvideo WITH replication = {'class':  
'NetworkTopologyStrategy', 'dc1':1};
```

```
CREATE TABLE killrvideo.videos_by_actor (  
  actor_name text,  
  character_name text,  
  video_id timeuuid,  
  release_year int,  
  title text,  
  PRIMARY KEY (actor_name, character_name, video_id)  
) WITH CLUSTERING ORDER BY (character_name ASC, video_id ASC);
```

# COPY

```
CREATE TABLE killrvideo.actors_by_video (  
  video_id timeuuid,  
  actor_name text,  
  character_name text,  
  release_year int,  
  title text,  
  PRIMARY KEY (video_id, actor_name, character_name)  
) WITH CLUSTERING ORDER BY (actor_name ASC, character_name ASC);
```

# COPY – FROM (import)

```
yadax@cqlsh:yadax> COPY killrvideo.videos_by_actor (actor_name,  
character_name, video_id , release_year, title) from  
'/tmp/videos_by_actor.csv';
```

```
yadax@cqlsh:yadax> COPY killrvideo.actors_by_video (actor_name,  
character_name, video_id , release_year, title) from  
'/tmp/actors_by_video.csv'
```

# COPY

```
cqlsh:yadax> select count(*) from sales;
```

```
OperationTimedOut: errors={'10.191.18.67': 'Client request timeout. See  
Session.execute[_async](timeout)'}, last_host=10.191.18.67
```

```
cqlsh:yadax> select * from sales limit 1;
```

| order_id  | country   | item_type  | order_priority | region | sales_channel | total_cost | total_profit | total_revenue | unit_cost | unit_price | units_sold |
|-----------|-----------|------------|----------------|--------|---------------|------------|--------------|---------------|-----------|------------|------------|
| 658789432 | Macedonia | Vegetables | L              | Europe | Online        | 1430755.22 | 586288.31    | 1430755.22    | 90.93     | 154.06     | 9287       |

# ARQUIVOS DE DADOS

# Arquivo de dados

- `ls -lhrt` (h -> human readable)
- Liste os arquivos da pasta `/var/lib/cassandra/data`
- Liste os arquivos da pasta `/var/lib/cassandra/data/killrvideo`
- Liste os arquivos da pasta `/var/lib/cassandra/data/killrvideo/actors...`

FLUSH

# Force um flush

- `nodetool flush killrvideo`
- Liste os arquivos da pasta `/var/lib/cassandra/data/yadax/sales...`
- O que houve?
- O que o `nodetool flush` faz mesmo?

# FLUSH

```
total 267M
drwxr-xr-x 2 cassandra cassandra 6 Jul 3 11:51 backups
-rw-r--r-- 1 cassandra cassandra 74M Jul 3 11:53 lb-9-big-Data.db
-rw-r--r-- 1 cassandra cassandra 11M Jul 3 11:53 lb-9-big-Index.db
-rw-r--r-- 1 cassandra cassandra 773K Jul 3 11:53 lb-9-big-Filter.db
-rw-r--r-- 1 cassandra cassandra 78K Jul 3 11:53 lb-9-big-Summary.db
-rw-r--r-- 1 cassandra cassandra 9 Jul 3 11:53 lb-9-big-Digest.adler32
-rw-r--r-- 1 cassandra cassandra 33K Jul 3 11:53 lb-9-big-CompressionInfo.db
-rw-r--r-- 1 cassandra cassandra 9.7K Jul 3 11:53 lb-9-big-Statistics.db
-rw-r--r-- 1 cassandra cassandra 94 Jul 3 11:53 lb-9-big-TOC.txt
-rw-r--r-- 1 cassandra cassandra 74M Jul 3 11:54 lb-18-big-Data.db
-rw-r--r-- 1 cassandra cassandra 11M Jul 3 11:54 lb-18-big-Index.db
-rw-r--r-- 1 cassandra cassandra 773K Jul 3 11:54 lb-18-big-Filter.db
-rw-r--r-- 1 cassandra cassandra 78K Jul 3 11:54 lb-18-big-Summary.db
-rw-r--r-- 1 cassandra cassandra 10 Jul 3 11:54 lb-18-big-Digest.adler32
-rw-r--r-- 1 cassandra cassandra 33K Jul 3 11:54 lb-18-big-CompressionInfo.db
-rw-r--r-- 1 cassandra cassandra 9.7K Jul 3 11:54 lb-18-big-Statistics.db
-rw-r--r-- 1 cassandra cassandra 94 Jul 3 11:54 lb-18-big-TOC.txt
-rw-r--r-- 1 cassandra cassandra 73M Jul 3 11:54 lb-27-big-Data.db
-rw-r--r-- 1 cassandra cassandra 11M Jul 3 11:54 lb-27-big-Index.db
-rw-r--r-- 1 cassandra cassandra 773K Jul 3 11:54 lb-27-big-Filter.db
-rw-r--r-- 1 cassandra cassandra 78K Jul 3 11:54 lb-27-big-Summary.db
-rw-r--r-- 1 cassandra cassandra 10 Jul 3 11:54 lb-27-big-Digest.adler32
-rw-r--r-- 1 cassandra cassandra 33K Jul 3 11:54 lb-27-big-CompressionInfo.db
-rw-r--r-- 1 cassandra cassandra 9.7K Jul 3 11:54 lb-27-big-Statistics.db
-rw-r--r-- 1 cassandra cassandra 94 Jul 3 11:54 lb-27-big-TOC.txt
-rw-r--r-- 1 cassandra cassandra 111K Jul 3 11:55 lb-28-big-Filter.db
-rw-r--r-- 1 cassandra cassandra 1.6M Jul 3 11:55 lb-28-big-Index.db
-rw-r--r-- 1 cassandra cassandra 12K Jul 3 11:55 lb-28-big-Summary.db
-rw-r--r-- 1 cassandra cassandra 11M Jul 3 11:55 lb-28-big-Data.db
-rw-r--r-- 1 cassandra cassandra 10 Jul 3 11:55 lb-28-big-Digest.adler32
-rw-r--r-- 1 cassandra cassandra 4.7K Jul 3 11:55 lb-28-big-CompressionInfo.db
-rw-r--r-- 1 cassandra cassandra 9.7K Jul 3 11:55 lb-28-big-Statistics.db
-rw-r--r-- 1 cassandra cassandra 94 Jul 3 11:55 lb-28-big-TOC.txt
```

```
total 269M
drwxr-xr-x 2 cassandra cassandra 6 Jul 3 11:51 backups
-rw-r--r-- 1 cassandra cassandra 74M Jul 3 11:53 lb-9-big-Data.db
-rw-r--r-- 1 cassandra cassandra 11M Jul 3 11:53 lb-9-big-Index.db
-rw-r--r-- 1 cassandra cassandra 773K Jul 3 11:53 lb-9-big-Filter.db
-rw-r--r-- 1 cassandra cassandra 78K Jul 3 11:53 lb-9-big-Summary.db
-rw-r--r-- 1 cassandra cassandra 9 Jul 3 11:53 lb-9-big-Digest.adler32
-rw-r--r-- 1 cassandra cassandra 33K Jul 3 11:53 lb-9-big-CompressionInfo.db
-rw-r--r-- 1 cassandra cassandra 9.7K Jul 3 11:53 lb-9-big-Statistics.db
-rw-r--r-- 1 cassandra cassandra 94 Jul 3 11:53 lb-9-big-TOC.txt
-rw-r--r-- 1 cassandra cassandra 74M Jul 3 11:54 lb-18-big-Data.db
-rw-r--r-- 1 cassandra cassandra 11M Jul 3 11:54 lb-18-big-Index.db
-rw-r--r-- 1 cassandra cassandra 773K Jul 3 11:54 lb-18-big-Filter.db
-rw-r--r-- 1 cassandra cassandra 78K Jul 3 11:54 lb-18-big-Summary.db
-rw-r--r-- 1 cassandra cassandra 10 Jul 3 11:54 lb-18-big-Digest.adler32
-rw-r--r-- 1 cassandra cassandra 33K Jul 3 11:54 lb-18-big-CompressionInfo.db
-rw-r--r-- 1 cassandra cassandra 9.7K Jul 3 11:54 lb-18-big-Statistics.db
-rw-r--r-- 1 cassandra cassandra 94 Jul 3 11:54 lb-18-big-TOC.txt
-rw-r--r-- 1 cassandra cassandra 73M Jul 3 11:54 lb-27-big-Data.db
-rw-r--r-- 1 cassandra cassandra 11M Jul 3 11:54 lb-27-big-Index.db
-rw-r--r-- 1 cassandra cassandra 773K Jul 3 11:54 lb-27-big-Filter.db
-rw-r--r-- 1 cassandra cassandra 78K Jul 3 11:54 lb-27-big-Summary.db
-rw-r--r-- 1 cassandra cassandra 10 Jul 3 11:54 lb-27-big-Digest.adler32
-rw-r--r-- 1 cassandra cassandra 33K Jul 3 11:54 lb-27-big-CompressionInfo.db
-rw-r--r-- 1 cassandra cassandra 9.7K Jul 3 11:54 lb-27-big-Statistics.db
-rw-r--r-- 1 cassandra cassandra 94 Jul 3 11:54 lb-27-big-TOC.txt
-rw-r--r-- 1 cassandra cassandra 111K Jul 3 11:55 lb-28-big-Filter.db
-rw-r--r-- 1 cassandra cassandra 1.6M Jul 3 11:55 lb-28-big-Index.db
-rw-r--r-- 1 cassandra cassandra 12K Jul 3 11:55 lb-28-big-Summary.db
-rw-r--r-- 1 cassandra cassandra 11M Jul 3 11:55 lb-28-big-Data.db
-rw-r--r-- 1 cassandra cassandra 10 Jul 3 11:55 lb-28-big-Digest.adler32
-rw-r--r-- 1 cassandra cassandra 4.7K Jul 3 11:55 lb-28-big-CompressionInfo.db
-rw-r--r-- 1 cassandra cassandra 9.7K Jul 3 11:55 lb-28-big-Statistics.db
-rw-r--r-- 1 cassandra cassandra 94 Jul 3 13:10 lb-29-big-TOC.txt
```

# COMPACTION

# Force um compact

- `nodetool -u cassandra -pw compact killrvideo`
- O que houve?
- O que `nodetool compact` faz?
- Qual o tamanho do arquivo de dados?

# COMPACT

```
total 269M
drwxr-xr-x 2 cassandra cassandra 6 Jul 3 11:51 backups
-rw-r--r-- 1 cassandra cassandra 74M Jul 3 11:53 lb-9-big-Data.db
-rw-r--r-- 1 cassandra cassandra 11M Jul 3 11:53 lb-9-big-Index.db
-rw-r--r-- 1 cassandra cassandra 773K Jul 3 11:53 lb-9-big-Filter.db
-rw-r--r-- 1 cassandra cassandra 78K Jul 3 11:53 lb-9-big-Summary.db
-rw-r--r-- 1 cassandra cassandra 9 Jul 3 11:53 lb-9-big-Digest.adler32
-rw-r--r-- 1 cassandra cassandra 33K Jul 3 11:53 lb-9-big-CompressionInfo.db
-rw-r--r-- 1 cassandra cassandra 9.7K Jul 3 11:53 lb-9-big-Statistics.db
-rw-r--r-- 1 cassandra cassandra 94 Jul 3 11:53 lb-9-big-TOC.txt
-rw-r--r-- 1 cassandra cassandra 74M Jul 3 11:54 lb-18-big-Data.db
-rw-r--r-- 1 cassandra cassandra 11M Jul 3 11:54 lb-18-big-Index.db
-rw-r--r-- 1 cassandra cassandra 773K Jul 3 11:54 lb-18-big-Filter.db
-rw-r--r-- 1 cassandra cassandra 78K Jul 3 11:54 lb-18-big-Summary.db
-rw-r--r-- 1 cassandra cassandra 10 Jul 3 11:54 lb-18-big-Digest.adler32
-rw-r--r-- 1 cassandra cassandra 33K Jul 3 11:54 lb-18-big-CompressionInfo.db
-rw-r--r-- 1 cassandra cassandra 9.7K Jul 3 11:54 lb-18-big-Statistics.db
-rw-r--r-- 1 cassandra cassandra 94 Jul 3 11:54 lb-18-big-TOC.txt
-rw-r--r-- 1 cassandra cassandra 73M Jul 3 11:54 lb-27-big-Data.db
-rw-r--r-- 1 cassandra cassandra 11M Jul 3 11:54 lb-27-big-Index.db
-rw-r--r-- 1 cassandra cassandra 773K Jul 3 11:54 lb-27-big-Filter.db
-rw-r--r-- 1 cassandra cassandra 78K Jul 3 11:54 lb-27-big-Summary.db
-rw-r--r-- 1 cassandra cassandra 10 Jul 3 11:54 lb-27-big-Digest.adler32
-rw-r--r-- 1 cassandra cassandra 33K Jul 3 11:54 lb-27-big-CompressionInfo.db
-rw-r--r-- 1 cassandra cassandra 9.7K Jul 3 11:54 lb-27-big-Statistics.db
-rw-r--r-- 1 cassandra cassandra 94 Jul 3 11:54 lb-27-big-TOC.txt
-rw-r--r-- 1 cassandra cassandra 111K Jul 3 11:55 lb-28-big-Filter.db
-rw-r--r-- 1 cassandra cassandra 1.6M Jul 3 11:55 lb-28-big-Index.db
-rw-r--r-- 1 cassandra cassandra 12K Jul 3 11:55 lb-28-big-Summary.db
-rw-r--r-- 1 cassandra cassandra 11M Jul 3 11:55 lb-28-big-Data.db
-rw-r--r-- 1 cassandra cassandra 10 Jul 3 11:55 lb-28-big-Digest.adler32
-rw-r--r-- 1 cassandra cassandra 4.7K Jul 3 11:55 lb-28-big-CompressionInfo.db
-rw-r--r-- 1 cassandra cassandra 9.7K Jul 3 11:55 lb-28-big-Statistics.db
-rw-r--r-- 1 cassandra cassandra 94 Jul 3 11:55 lb-28-big-TOC.txt
-rw-r--r-- 1 cassandra cassandra 15K Jul 3 13:10 lb-29-big-Filter.db
-rw-r--r-- 1 cassandra cassandra 206K Jul 3 13:10 lb-29-big-Index.db
-rw-r--r-- 1 cassandra cassandra 1.6K Jul 3 13:10 lb-29-big-Summary.db
-rw-r--r-- 1 cassandra cassandra 1.4M Jul 3 13:10 lb-29-big-Data.db
-rw-r--r-- 1 cassandra cassandra 10 Jul 3 13:10 lb-29-big-Digest.adler32
-rw-r--r-- 1 cassandra cassandra 651 Jul 3 13:10 lb-29-big-CompressionInfo.db
-rw-r--r-- 1 cassandra cassandra 9.7K Jul 3 13:10 lb-29-big-Statistics.db
-rw-r--r-- 1 cassandra cassandra 94 Jul 3 13:10 lb-29-big-TOC.txt
```

```
total 216M
drwxr-xr-x 2 cassandra cassandra 6 Jul 3 11:51 backups
-rw-r--r-- 1 cassandra cassandra 186M Jul 3 13:13 lb-30-big-Data.db
-rw-r--r-- 1 cassandra cassandra 28M Jul 3 13:13 lb-30-big-Index.db
-rw-r--r-- 1 cassandra cassandra 2.0M Jul 3 13:13 lb-30-big-Filter.db
-rw-r--r-- 1 cassandra cassandra 198K Jul 3 13:13 lb-30-big-Summary.db
-rw-r--r-- 1 cassandra cassandra 10 Jul 3 13:13 lb-30-big-Digest.adler32
-rw-r--r-- 1 cassandra cassandra 84K Jul 3 13:13 lb-30-big-CompressionInfo.db
-rw-r--r-- 1 cassandra cassandra 9.7K Jul 3 13:13 lb-30-big-Statistics.db
-rw-r--r-- 1 cassandra cassandra 94 Jul 3 13:13 lb-30-big-TOC.txt
```

ADD NODES NO CLUSTER

# Inicie o segundo node do mesmo DC

- Inicie o serviço do Cassandra, em um node NÃO SEED
- Acompanhe o system.log
- É necessário que os nodes se falem na porta 7000 (listen\_port)

# Inicie o segundo node do mesmo DC

- O que você espera que aconteça com o volume de dados nos nodes?
- Confira o status do cluster
- O que houve?

# STREAM

# STREAM

- Sempre que add um node não seed (bootstrap)
- Acompanhe os alerts
- Verifique o status do cluster
- Liste os arquivos da pasta `/var/lib/cassandra/data/yadax/sales...`
- SEEDs não fazem bootstrap automaticamente

# Stream

- O que é esse Stream? Node 2:

```
INFO [main] StorageService.java:1212 - JOINING: schema complete, ready to bootstrap
INFO [main] StorageService.java:1212 - JOINING: waiting for pending range calculation
INFO [main] StorageService.java:1212 - JOINING: calculation complete, ready to bootstrap
INFO [main] StorageService.java:1212 - JOINING: getting bootstrap token
INFO StreamResultFuture.java:169 - [Stream #7a128490-792b-11ea-8aab-d5f79dd6ff78 ID#0] Prepare
completed. Receiving 1 files(2345074 bytes), sending 0 files(0 bytes)
INFO StreamResultFuture.java:169 - [Stream #7a128490-792b-11ea-8aab-d5f79dd6ff78 ID#0] Prepare
completed. Receiving 3 files(1912877 bytes), sending 0 files(0 bytes)
```

# Start o terceiro node

- System.log Node 1

```
Creating new streaming plan for Bootstrap
```

```
Received streaming plan for Bootstrap
```

```
Prepare completed. Receiving 0 files(0 bytes), sending 2 files(1681762 bytes)
```

```
Session with /172.31.93.205 is complete
```

```
All sessions completed
```

CLEANUP

# Limpeza dos dados

- Os nodes entregam os dados para o novo node, mas não os eliminam do próprio node.
- É necessário forçar essa limpeza no nodes “antigos”. Acompanhe o `system.log`
- `nodetool -u cassandra -pw cassandra cleanup`

# Limpeza dos dados

- Qual o tamanho do arquivo de dados no node1 e node2?
- Sempre que um node for adicionado em um DC existente, é necessário fazer o cleanup nos nodes antigos.

# Aumento do Replication Factor

- Altere o replication factor da keyspace yadax para dc1: 2
- ALTER KEYSPACE yadax WITH replication = {'class': 'NetworkTopologyStrategy', 'dc1': '2'};

# Aumento do Replication Factor

- Qual volume de dados cada node deveria ter?
- Verifique o status do cluster

REPAIR

# Repair

- `nodetool repair`
  - `--full`
  - `--pr` (partitioner range)
  - Default, incremental – Evite no cassandra < 4.0
  
- `nodetool repair --full` (acompanhe o alert)

# Repair

- Liste os arquivos da pasta `/var/lib/cassandra/data/yadax/sales...` no segundo node
- Qual tamanho do arquivo de dados?
- Best Practice: rodar `-pr` em sequencia em todos os nodes

# Terceiro node

- Quando adicionarmos o terceiro node, com qual volume de dados ele deve ficar?
- $215\text{M} \times 2 = 430\text{M}$  (duas cópias)
- $430 / 3 = 143\text{M}$  (em cada node)
- A distribuição não será exata.

# Start o terceiro node -> SEED

- Liste os arquivos da pasta `/var/lib/cassandra/data/yadax/sales...` no terceiro node
- O que aconteceu?
- No node3, `nodetool repair --full`

# Start o terceiro node -> SEED

- Liste os arquivos da pasta `/var/lib/cassandra/data/yadax/business...` no terceiro node
- Qual o tamanho do arquivo de dados?
- Se tiver mais de um arquivo de dados, compact:
- `nodetool compact yadax`

# Limpeza dos dados

- Qual o tamanho do arquivo de dados no node1 e node2?
- Compacte a keyspace yadax
- Qual o tamanho do arquivo de dados no node1 e node2?
- Por que não diminuiu? Como diminuir?

# Adicionar nodes

- Qual é o procedimento para adicionar nodes?
- Já o fizemos duas vezes

# DECOMMISSION

# Remover node

- E como removemos nodes?
- Se o node estiver vivo, podemos gentilmente pedir para ele sair.
- `nodetool decommission + (stop cassandra ou kill java)`
- É o método mais “sutil”, deve ser a primeira opção

# Remover node 3

- Verifique o status do cluster
- Acompanhe o system.log
- Remova o node 3 e mate o processo java.
- Qual o tamanho do arquivo de dados no node1 e 2?

# Remover node 3

- Node3: INFO [RMI TCP Connection(10)- StorageService.java:1212 - DECOMMISSIONED
- Node1 e 2:
  - Creating new streaming plan for Unbootstrap
  - Received streaming plan for Unbootstrap
  - Prepare completed. Receiving 1 files(1651921 bytes), sending 0 files(0 bytes)
  - StorageService.java:2262 - Removing tokens [-1763480119689959618, -2546962922378197620, -2936027932308825805 ...

# Remover node 3

- Liste os arquivos da pasta `/var/lib/cassandra/data/yadax/sales...`
- Qual tamanho do arquivo de dados nos nodes 1 e 2?
- Compacte
- Qual o tamanho do arquivo de dados nos nodes 1 e 2?

# Adicionar o node 3

- Verifique o processo java
- Mate o processo
- `kill -9 <pid>`

# Adicionar o node 3

- Tentar add sem limpar
- Verifique o status do cluster
- O que houve?
- Qual tamanho do arquivo de dados no node 3?

# Adicionar o node 3

- Por que o tamanho é este?
- Tente compactar.
  - O que houve?
- Tente limpar (cleanup).
  - O que houve?
  - Por que?

# Remova o node 3

- Pare o node3.
  - Stop do serviço.
  - Confira se o processo java está rodando.
- No node 3, tente o nodetool decommission
- O que houve?

# REMOVENODE

# Remova o node 3

- Confira o status do cluster
- A partir de um node sobrevivente, remova o node 3.
- `nodetool removemode <host_id>`

# Remova o node 3

- StorageService.java:2262 - Removing tokens  
[-8427423350248595549, -6570421736454060805, ...]
- HintedHandOffManager.java:225 - Deleting any stored hints for  
/172.31.87.71
- Gossiper.java:550 - Completing removal of /172.31.87.71

# Adicione o node 3

- Limpe todos os dados do node 3
- `rm -rf /var/lib/cassandra/*/*`
- Adicione novamente o node 3
- Confira o status do cluster

ADD NOVO DC

# Adicionando o segundo DC

- Start o node 1B.
- Acompanhe o alert
- Confira o status do cluster
- O que mudou?

# Adicionando o segundo DC

- Liste os arquivos da pasta `/var/lib/cassandra/data/yadax/sales...` no node 1B.
- Por que?

# Adicionando o segundo DC

- Altere o replication factor da keyspace yadax
- ALTER KEYSPACE yadax WITH replication = {'class': 'NetworkTopologyStrategy', 'DCA': '2', 'DCB': '2'};
- Liste os arquivos da pasta /var/lib/cassandra/data/yadax/business... no node 1B.
- O que precisamos fazer?

REBUILD

# Adicionando o segundo DC

- Pode ser feito um repair full
- Ou reconstruir completamente o node
- Acompanhe o system.log
- nodetool rebuild

# Adicionando o segundo DC

- Liste os arquivos da pasta `/var/lib/cassandra/data/yadax/sales...` no node 1B.
- O que houve?
- Compacte
- Qual o tamanho do arquivo de dados?

# Adicione o node 2B

- Start o node 2B
- Liste os arquivos da pasta `/var/lib/cassandra/data/yadax/sales...` no node 2B.
- Confira o status do cluster
- O que houve?
- Qual o tamanho do arquivo de dados?

# Adicione o node 3B

- Start o node 3B
- Liste os arquivos da pasta `/var/lib/cassandra/data/yadax/sales...` no node 3B.
- O que houve?
- Qual o tamanho do arquivo de dados? Está correto?

# Sincronize os dados

- O node 2B é responsável por dados que ele não tem.
- No node 2B, tente um `nodetool repair --full`
- Liste os arquivos da pasta `/var/lib/cassandra/data/yadax/sales...` nos nodes 2B e 3B.
- O que houve?

# Sincronize os dados

- No node 3B, tente um nodetool repair --full
- Liste os arquivos da pasta `/var/lib/cassandra/data/yadax/business...` nos nodes 2B e 3B.
- O que houve?

# Status do Cluster

- Verifique o status do cluster
- Limpe (cleanup) os dados nos nodes 1A, 1B, 2A, 2B

REMOVER DC

# Remover DCA

- Verifique o status do cluster
- Remova todos os nodes do DCA
- Mate os processos java

# Remover DCA

- Confira o status do cluster
- Altere a keyspace yadax para ter replicas apenas no DCB
- ALTER KEYSPACE yadax WITH replication = {'class': 'NetworkTopologyStrategy', 'DCB': '2'};

# MIGRAÇÃO DC

# Migração de DataCenter

- Este foi o procedimento para migração de DataCenter.
- Como é mesmo?

BACKUP

# Backup

- O backup pode ser feito por keyspace
- Se você não informar a keyspace, todas terão backup
- O backup é um snapshot da keyspace (das SSTables)
- É um hardlink, por isso no mesmo Filesystem

# Backup

- Você precisa copiar para outro local.
- `nodetool -u cassandra -pw cassandra snapshot killrvideo`

```
Requested creating snapshot(s) for [killrvideo] with snapshot name  
[1586217410504]
```

```
Snapshot directory: 1586217410504
```

# Backup

- Liste os arquivos da pasta `/var/lib/cassandra/data/yadax/sales...` no node que fez o snapshot
- O que houve?

```
[root@ip-172-31-90-247 ~]# ls -lhrt /var/lib/cassandra/data/yadax/business_price-6c285960784d11ea9aa13b7649deea08/
total 5.9M
drwxr-xr-x. 2 cassandra cassandra  6 Apr  6 23:14 backups
-rw-r--r--. 2 cassandra cassandra 5.8M Apr  6 23:25 lb-5-big-Data.db
-rw-r--r--. 2 cassandra cassandra 33K Apr  6 23:25 lb-5-big-Index.db
-rw-r--r--. 2 cassandra cassandra 1008 Apr  6 23:25 lb-5-big-Filter.db
-rw-r--r--. 2 cassandra cassandra 262 Apr  6 23:25 lb-5-big-Summary.db
-rw-r--r--. 2 cassandra cassandra  9 Apr  6 23:25 lb-5-big-Digest.adler32
-rw-r--r--. 2 cassandra cassandra 4.1K Apr  6 23:25 lb-5-big-CompressionInfo.db
-rw-r--r--. 2 cassandra cassandra 6.9K Apr  6 23:25 lb-5-big-Statistics.db
-rw-r--r--. 2 cassandra cassandra  94 Apr  6 23:25 lb-5-big-TOC.txt
drwxr-xr-x. 3 cassandra cassandra 27 Apr  6 23:56 snapshots
```

# Backup

- Liste os arquivos da pasta  
`/var/lib/cassandra/data/yadax/sales.../snapshots/ 1586217410504/`
- O que houve?

```
[root@ip-172-31-90-247 ~]# ls -lhrt /var/lib/cassandra/data/yadax/business_price-6c285960784d11ea9aa13b7649deea08/snapshots/1586217410504/
total 5.9M
-rw-r--r--. 2 cassandra cassandra 5.8M Apr  6 23:25 lb-5-big-Data.db
-rw-r--r--. 2 cassandra cassandra 33K Apr  6 23:25 lb-5-big-Index.db
-rw-r--r--. 2 cassandra cassandra 1008 Apr  6 23:25 lb-5-big-Filter.db
-rw-r--r--. 2 cassandra cassandra 262 Apr  6 23:25 lb-5-big-Summary.db
-rw-r--r--. 2 cassandra cassandra 9 Apr  6 23:25 lb-5-big-Digest.adler32
-rw-r--r--. 2 cassandra cassandra 4.1K Apr  6 23:25 lb-5-big-CompressionInfo.db
-rw-r--r--. 2 cassandra cassandra 6.9K Apr  6 23:25 lb-5-big-Statistics.db
-rw-r--r--. 2 cassandra cassandra 94 Apr  6 23:25 lb-5-big-TOC.txt
-rw-r--r--. 1 cassandra cassandra 31 Apr  6 23:56 manifest.json
```

# Backup

- Liste os arquivos da pasta com a opção -i  
`/var/lib/cassandra/data/yadax/sales.../snapshots/1586217410504/`
- Liste os arquivos da pasta com a opção -i  
`/var/lib/cassandra/data/yadax/sales.../`
- O que houve?

# Desastre

- Para o restore, a keyspace e as tabelas precisam existir.
- Descreva sua keyspace e guarde o resultado

TRUNCATE

# Desastre

- Truncate table killrvideo.actors\_by\_video

```
select * from killrvideo.actors_by_video limit 10;
```

- Liste os arquivos da pasta /var/lib/cassandra/data/yadax/sales... em todos os nodes do DCB.

# RESTORE

# Restore

- Copie os arquivos da pasta ...../snapshot/158637NNNNNN/\* para /var/lib/cassandra/data/yadax/sales-....
- Em todos os nodes
- Se usou o root, modifique o owner dos arquivos:  
# chown cassandra:cassandra /var/lib/cassandra/data/yadax/sales-.../\*
- `select * from yadax.sales limit 10;`

REFRESH

# Restore

- Faça o reload do snapshot em todos os nodes
- `nodetool refresh yadax sales` (A tabela precisar existir)
- Acompanhe o alert
- `select * from yadax.sales limit 10 ;`

# Restore

- Liste os arquivos da pasta  
`/var/lib/cassandra/data/yadax/sales-.../snapshots/`

- Por que tem dois diretórios?

- `auto_snapshot: true`

# Whether or not a snapshot is taken of the data before keyspace truncation

# or dropping of column families. The STRONGLY advised default of true

# should be used to provide data safety. If you set this flag to false, you will

# lose data on truncation or drop.

# SNAPSHOTS

# Snapshots

- Liste seus snapshots:
  - `nodetool listsnapshots`
  
- Limpe os snapshots:
  - `nodetool clearsnapshot (todos)`
    - `-t <snapshot_name>`
    - `<keyspaces>`
  
- Liste seus snapshots

# Snapshots

- Crie um snapshot da keyspace yadax em um node apenas
- Qual o espaço ocupado pela pasta  
/var/lib/cassandra/data/yadax/sales...?

```
du -sh /var/lib/cassandra/data/yadax/*
```

# Snapshots

- Qual o espaço ocupado apenas pela pasta `/var/lib/cassandra/data/yadax/sales-.../snapshots`?

```
du -sh /var/lib/cassandra/data/yadax/sales-.../snapshots
```

- Tente:

```
du -sh /var/lib/cassandra/data/yadax/sales-.../*
```

- O que mudou?

# UPGRADE

# Adicione o DCA

- Verifique o status do cluster
- Limpe os dados dos nodes do DCA
- Adicione os todos os nodes no DCA

# Adicione o DCA

- Mude o replication fator da yadax para DCA:2, DCB:2
- Faça um “nodetool repair --full” dos nodes do DCA
- Verifique o status do cluster
- Verifique o tamanho dos arquivos de dados

# Upgrade

- Guarde a DDL de criação da sua keyspace, faça um backup em todos os nodes
- Verifique a compatibilidade da app com a nova versão
- Acompanhe sempre o system.log
- O formato da SSTable muda de versão para versão.

# DESCRIBECLUSTER

# UPGRADE - DESCRIBECLUSTER

- `nodetool describecluster`
- Limpe todos os snapshots antigos que existirem
- Faça um “`nodetool repair -pr`” em todos os nodes, em série
- Faça um snapshot (full) em todos os nodes

# UPGRADE - CUIDADOS

- Durante o upgrade evite:
  - Novas features
  - Repair
  - Add/Remove nodes
  - DDLs

# UPGRADE - CUIDADOS

- Durante o upgrade evite:
  - Habilitar CDC (change data capture)
  - Alterar credenciais e permissões.
- Sequencia
  - Primeiro DC: SEEDs, depois outros nodes
  - Segundo DC: SEEDs, depois outros nodes
- Faça uma nota da sequencia que seguirá

# UPGRADE - DRAIN

- No primeiro SEED do DCA:
- Drain: Remove as conexões, faz flush das memtables.
- Shutdown friendly
- nodetool drain

# UPGRADE

- Pare o serviço do cassandra
- Verifique se o processo java está down.
- Remova o cassandra 2.2 – yum remove cassandra
  - Preste bastante atenção no output
- O que aconteceu com os dados?

# UPGRADE

- Altere o repositório do cassandra: `/etc/yum.repos.d/cassandra.repo`

```
[cassandra]
```

```
baseurl = https://www.apache.org/dist/cassandra/redhat/311x/
```

```
gpgcheck = 1
```

```
gpgkey = https://www.apache.org/dist/cassandra/KEYS
```

```
name = Apache Cassandra
```

```
repo_gpgcheck = 1
```

# UPGRADE

- Instale o cassandra 3.11 – yum install cassandra
- Edite novamente o cassandra.yaml e cassandra-rackdc.properties

# Ajuste - cassandra.yaml

- Estes são os parâmetros que você vai precisar alterar no `cassandra.yaml`:
  - `cluster_name`: Yadax
  - `num_tokens`: 16
  - `seeds`: ip1, ip2, ip4, ip5
  - `# listen_address` -> comentar (# no começo da linha)
  - `listen_interface` -> eth0 (utilizar "ip a" para descobrir)
  - `# rpc_address`: -> comentar (# no começo da linha)
  - `rpc_interface`: eth0
  - `endpoint_snitch`: GossipingPropertyFileSnitch

# Ajuste - cassandra-rackdc.properties

- Estes são os parâmetros que você vai precisar alterar no `cassandra-rackdc.properties`:

`dc=DCA`

`rack=RACK1`

# UPGRADE

- Inicie o service do Cassandra
- INFO [main] SystemKeyspace.java:1433 - Detected version upgrade from 2.2.NN to 3.11.N, snapshotting system keyspace
- `nodetool describecluster`
- Liste os arquivos de dados e repare seus nomes e size atuais
- `nodetool upgradesstables`

# UPGRADE

- O que houve com os nomes dos arquivos?
- O que houve com o size?
- Como acompanhar o andamento do upgradesstables?

# UPGRADE

- Faça o mesmo procedimento nos outros SEEDs do mesmo DC
- Faça o mesmo procedimento nos outros nodes do mesmo DC
- Faça o mesmo procedimento no outro DC, começando pelos SEEDs.

# UPGRADE

- Drain / stop service
- Uninstall
- Repo
- Install
- Arquivos de conf
- Start
- Upgrade sstables
- Describe Cluster

CONSISTÊNCIA

# CONSISTENCY

- No Cassandra temos consistência ajustável
- Por default, “always writable”. Se tiver um nó em pé, está escrevendo
- Se você aumentar a consistência, você perde a tolerância a falha
- Teorema CAP

# CONSISTENCY

- Verifique o status do cluster
- Conecte no CQLSH no node 1A e verifique a consistência default.

```
cqlsh> CONSISTENCY  
Current consistency level is ONE.
```

# CONSISTENCY

- Crie uma Keyspace com RF=3 no DCA.

```
cqlsh> create keyspace consist WITH replication = {'class':  
'NetworkTopologyStrategy', 'DCA': 3};
```

# CONSISTENCY

- Crie uma Tabela na KS consist

```
cqlsh> USE consist;  
cqlsh:consist> CREATE TABLE scores  
(  
    user TEXT,  
    game TEXT,  
    year INT,  
    month INT,  
    day INT,  
    score INT,  
    PRIMARY KEY (user, game, year, month, day)  
);
```

# CONSISTENCY

- Insira um registro

```
cqlsh:consist> INSERT INTO scores (user, game, year, month, day, score)
VALUES ('hack', 'Mario', 2015, 05, 01, 4000);
```

# CONSISTENCY

- Stop os outros dois nodes do DCA, confira o status do cluster
- Você consegue ler o registro?
- Tente inserir um novo registro

```
cqlsh:consist> INSERT INTO scores (user, game, year, month, day, score)
VALUES ('abonacin', 'Mario', 2015, 05, 03, 1750);
```

- O que houve? Você consegue ler o novo registro?

# CONSISTENCY

- Mude a consistência para Quorum. Tente ler novamente.

```
cqlsh:consist> CONSISTENCY QUORUM ;  
cqlsh:consist> select * from consist.scores ;
```

- O que houve?

# CONSISTENCY

- Tente inserir um registro.

```
cqlsh:consist> INSERT INTO scores (user, game, year, month,
day, score) VALUES ('japa', 'Mario', 2015, 05, 03, 2250);
```

- O que houve? Por que?

# HINTED HANDOFF

# HINTED HANDOFF

- Acompanhe o system.log do node 1A
- Start o node 2A, confira o status do cluster
- O que houve?

```
INFO [HintedHandoff:1] HintedHandOffManager.java:362 -  
Started hinted handoff for host:  
5b1078c3-804b-4ec7-ab26-bd4d4f358abb with IP:  
/172.31.88.164
```

```
INFO [HintedHandoff:1] HintedHandOffManager.java:394 -  
Finished hinted handoff of 1 rows to endpoint  
/172.31.88.164
```

# CONSISTENCY

- Conecte no CQLSH no node 1A, ajuste a consistência para Quorum.
- Tente ler os registros. Tente inserir um registro

```
cqlsh:consist> INSERT INTO scores (user, game, year, month, day, score)  
VALUES ('japa', 'Mario', 2015, 05, 03, 2250);
```

- O que houve? Por que?

# CONSISTENCY

- Conecte no CQLSH no node 1A, ajuste a consistência para ALL.
- Tente ler os registros. Tente inserir um registro

```
INSERT INTO scores (user, game, year, month, day, score) VALUES ('asia',  
'Mario', 2015, 05, 03, 500);
```

- O que houve? Por que?

# HINTED HANDOFF

- Acompanhe o system.log do node 1A
- Start o node 3A, confira o status do cluster
- O que houve?

```
INFO [HintedHandoff:2] HintedHandOffManager.java:362 -  
Started hinted handoff for host:  
4dc6319c-8f88-4fe2-8709-267b7adc2b53 with IP:  
/172.31.88.210
```

```
INFO [HintedHandoff:2] HintedHandOffManager.java:394 -  
Finished hinted handoff of 2 rows to endpoint  
/172.31.88.210
```

# CONSISTENCY

- Conecte no CQLSH no node 1A, ajuste a consistência para ALL.
- Tente ler os registros. Tente inserir um registro

```
INSERT INTO scores (user, game, year, month, day, score) VALUES ('asia',  
'Mario', 2015, 05, 03, 500);
```

- O que houve? Por que?

# READ REPAIR

# READ REPAIR

- Desabilite o hinted handoff de todos nodes do DCA – cassandra.yaml
  - `hinted_handoff_enabled: false`
- Restarte o cassandra nos nodes do DCA
- Stop os nodes 2A e 3A
- Verifique o status do cluster

# READ REPAIR

- Conecte no CQLSH no node 1A, ajuste a consistência para One.
- Tente ler os registros. Tente inserir um registro

```
cqlsh:consist> INSERT INTO scores (user, game, year, month, day, score) VALUES ('abonacin', 'MK3', 2015, 06, 01, 2500);
```

- Tente ler os registros. O que houve?

# READ REPAIR

- Acompanhe o `system.log` do node 1A
- Starte os outros nodes
- Houve entrega de hints?

# READ REPAIR

- Seu registro ficou no node 1A
- Stop o node 1A
- Conecte no CQLSH no node 2A, ajuste a consistência para One.
- Tente ler os registros. O que houve?

# READ REPAIR

- Starte o node 1A
- Conecte no CQLSH no node 1A, ajuste a consistência para **ONE**.
- Tente ler os registros. O que houve?
- Conecte no CQLSH nos nodes 2A e 3A, ajuste a consistência para **ONE**.
- Tente ler os registros. O que houve?

# READ REPAIR

- Conecte no CQLSH no node 2A, ajuste a consistência para **ALL**.
- Tente ler os registros. O que houve?
- Conecte no CQLSH no node 3A, ajuste a consistência para **ONE**.
- Tente ler os registros. O que houve?

# AUTENTICAÇÃO

# Autenticação

- As infos de autenticação encontram-se na `system_auth`.
- Altere a keyspace `system_auth` para ter 3 replicas em cada DC, com `NetworkTopologyStrategy`
- Faça repair da `system_auth` (`--full`) em todos os nodes (um de cada vez).

# Autenticação

- Altere o `cassandra.yaml` em todos os nodes
- `authenticator: PasswordAuthenticator`
- `authorizer: CassandraAuthorizer`
- Restart o node

# Conecte no cassandra

```
$ echo $HOSTNAME
```

```
ip-172-31-89-224.ec2.internal
```

```
$ cqlsh $HOSTNAME
```

```
Connection error: ('Unable to connect to any  
servers', {'172.31.89.224':  
AuthenticationFailed('Remote end requires  
authentication.',)})
```

Agora precisamos de user/senha: cassandra/cassandra

# Conectado com sucesso

```
$ cqlsh -u cassandra -p cassandra $HOSTNAME
```

```
Connected to ABonacin at ip-172-31-89-224.ec2.internal:9042.
```

```
[cqlsh 5.0.1 | Cassandra 2.2.14 | CQL spec 3.3.1 | Native protocol v4]
```

```
Use HELP for help.
```

```
cassandra@cqlsh>
```

AMEM!

# Super user

- Crie um user “dba” como superuser

```
cqlsh> create user dba with password 'Yadax2020' superuser;
```

# User Cassandra x DBA

```
$ cqlsh -u cassandra -p cassandra $HOSTNAME
```

```
$ cqlsh -u dba -p Yadax2020 $HOSTNAME
```

- Baixe todo o DCB

# User Cassandra x DBA

- Verifique o status do cluster
- Se conecte de novo

```
$ cqlsh -u cassandra -p cassandra $HOSTNAME
```

```
$ cqlsh -u dba -p Yadax2020 $HOSTNAME
```

# User Cassandra x DBA

- O que houve?
- "Unable to perform authentication: Cannot achieve consistency level QUORUM"

# Sendo preguiçoso

Crie um arquivo ~/.cassandra/cqlshrc

~ é um alias para o home do user: /home/cassandra

```
$ vi ~/.cassandra/cqlshrc
```

```
[authentication]
```

```
username = dba
```

```
password = Yadax2020
```

```
[connection]
```

```
hostname = ip-172-31-89-224
```

```
port = 9042
```

# Sendo preguiçoso

Tente agora:

```
$ curlsh
```

```
Parabéns, você é um preguiçoso!
```

# JMX

- Verifique a saúde do cluster
- Você continua não precisando de user e senha.
- Por que?
- `cassandra-env.sh` -> onde alteramos as configs do JMX

# JMX

- /etc/cassandra/conf/cassandra-env.sh
- Busque pelo trecho:

```
if [ "x$LOCAL_JMX" = "x" ]; then
```

- Adicione imediatamente antes:

```
LOCAL_JMX=no
```

```
LOCAL_JMX="no"  
if [ "x$LOCAL_JMX" = "x" ]; then  
    LOCAL_JMX=yes  
fi
```

# JMX

- Busque pelo trecho abaixo e ajuste:

```
JVM_OPTS="$JVM_OPTS  
-Dcom.sun.management.jmxremote.password.file=/etc/cassandra/conf/jmxremote.password"
```

```
JVM_OPTS="$JVM_OPTS  
-Dcom.sun.management.jmxremote.access.file=/etc/cassandra/conf/jmxremote.access"
```

# JMX - jmxremote.access

Crie o arquivo `/etc/cassandra/conf/jmxremote.access`

```
# cat /etc/cassandra/conf/jmxremote.access  
cassandra readonly  
yadax readwrite
```

# JMX - jmxremote.password

- Crie o arquivo `/etc/cassandra/conf/jmxremote.password`

```
# cat /etc/cassandra/conf/jmxremote.password
cassandra Yadax2020
yadax Yadax2020
```

- Restrinja o acesso ao arquivo

```
chmod 600 /etc/cassandra/conf/jmxremote.password
```

# JMX

- Restarte todos os nodes
- Verifique a saúde do cluster

```
# nodetool -u cassandra -pw Yadax2020 -h $HOSTNAME status
```

- O que houve?

# JMX

```
# nodetool -u yadax -pw Yadax2020 -h $HOSTNAME status
```

- O que houve?

# USERS: JMX x DB

- Yadax é um user do DB?

```
# cqlsh
```

```
dba@cqlsh> list users;
```

```
dba@cqlsh> list roles;
```

# HEAP SIZE

# Configuração HEAP

- Por default, a HEAP tem 1/4 do tamanho da RAM
- Se você tiver muito problema com GC, é possível ajustar este size
- Nem sempre HEAP grande é bom
- Arquivos conf
  - 2.2: cassandra-env.sh
  - 3.+ : jvm.options

# HEAP

- Veja o tamanho atual da sua HEAP

- `ps -ef | grep java`

`-Xms1024M`

`-Xmx1024M`

# Ajuste no jvm.options

- Vamos ajustar o `/etc/cassandra/conf/jvm.options`

- Busque pelo trecho abaixo

```
#-Xms4G
```

```
#-Xmx4G
```

## Descomente e altere para 1500M

```
-Xms1500M
```

```
-Xmx1500M
```

# Ajuste no jvm.options

- Restart o node
- Verifique o resultado

# BEST PRACTICES

(TA ACABANDO)

# Best Practices

- User DBA – SuperUSER
- Keyspaces usando NetworkTopology
- Repair periódico
- Distribuição de Racks (Rackawareness)

# Best Practices

- NTP
- Kernel e Limits
- Não usar SWAP

# Best Practices

- Usar SSDs
- Scheduler IO: deadline ou noop
- Desabilitar Transp Huge Pages
- HEAP entre 1/4 e 1/2 da RAM, nunca maior que 32G

Obrigado!!!