

Séance 1

NoSQL vs SQL

Historique et évolution



Ce(tte) œuvre est mise à disposition selon les termes de la Licence Creative Commons Attribution – Pas d'Utilisation Commerciale – Pas de Modification 4.0 International.

Objectifs

- Du relationnel au **NoSQL**
 - Comparaison des deux paradigmes
 - Historique de l'émergence du NoSQL
 - Propriétés ACID versus BASE
- Intérêt et utilisation du **NoSQL**
 - Big Data et 4Vs
 - Architecture distribuée
 - Aperçu des modèles de données

NoSQL

non relational

non SQL

not only SQL

HOW TO WRITE A CV



Leverage the NoSQL boom

Relationnel vs NoSQL



Informatique d'entreprise

- **Beaucoup de changements** dans les technologies utilisées

Langage de programmation, architecture, plateforme...

- Stabilité dans la manière de **stocker les données**

Utilisation de bases de données relationnelles depuis toujours

- Quelques challengers présents et fructueux dans des **niches**

Les architectes choisissent la base de données relationnelle

Logiciel et donnée

- Une entreprise utilise des **logiciels** et stocke des **données**

Ces deux éléments sont le plus indépendant possible

- Les données **vivent souvent plus longtemps** que les logiciels

Les nouveaux logiciels doivent supporter les données existantes

- Les données doivent être le **plus stable** possible

Compréhensibles facilement et accessibles grâce à une API

Donnée

- Besoin d'**organiser des données** au cœur de l'informatique

Optimiser la conservation et la restitution

- Plusieurs autres **sous-fonctions** importantes

Sécurité, protection contre les incohérences, etc.




*Stockage sur
mémoire de masse*




*Retrouver
les données*



Dilbert.com DilbertCartoonist@gmail.com



9-20-13 © 2013 Scott Adams, Inc. (Dist. by Universal Uclick)



I hate databases...

- La plupart des développeurs **n'aiment pas les bases de données**
 - Interaction avec un DBMS (*DataBase Management System*)
 - Apprentissage du langage SQL (*Structured Query Language*)
 - Liens entre données de la base et données du programme
- Vu comme une intrusion d'un **élément externe**

Avec une très mauvaise intégration avec le code applicatif

Émergence du NoSQL

- Besoin de stocker de **grandes quantités** de données
Passage de grosses plateformes à des clusters de serveurs
- Bases de données relationnelles sous le nom de **NoSQL**
Cassandra, Mongo, Neo4j, Riak...
- Amoindrissement de la traditionnelle **consistance des données**
Pour la performance, montée en charge, programmation aisée

La force du relationnel

- Stockage efficace de données de manière **persistante**
Plus de flexibilité que le stockage dans des fichiers
- **Accès concurrent** aux données, en lecture et/ou écriture
Utilisation de transactions pour contrôler l'accès aux données
- **Intégration** et collaboration d'applications en entreprise
Réalisé avec une intégration par base de données partagée
- Modèle relationnel basé sur un **modèle standard**

La fin du relationnel ?

- Les bases de données relationnelles sont **puissantes et stables...**

Pas prêtes de disparaître à court et moyen terme

- ...mais elles ne sont **plus suffisantes**

Lourdeur inutile pour le stockage de certains types de données

- **Systèmes hybrides** combinant plusieurs technologies

De manière concurrente, coopérative, répartie, redondante...

Historique

- 1950 Développement du modèle hiérarchique (IMS)
- 1970 Apparition du modèle relationnel (Edgar F. T. Codd)
- 1980's Domination du modèle relationnel
- 2000's Émergence du terme NoSQL
- 2011 Émergence du NewSQL

Modèle hiérarchique (1)

- Établissement de **relations** de parents vers des enfants

Relation unidirectionnelle

- Base de données d'**enregistrements** avec des champs

Regroupés en types d'enregistrements


- **Moteur IMS** (*Information Management System*) créé par IBM

Utilisé par la NASA pour gérer les matériaux de construction

Modèle hiérarchique (2)

- **Diagramme hiérarchique** représentant un service


Champs des différents types d'enregistrement inclus



Modèle relationnel

- *“A Relational Model of Data for Large Shared Data Banks”*

*Edgar Frank “Ted” Codd, Ph.D. (1923–2003)
IBM Research, San José, California, USA*




- Turing Award 1981
- Organisation des données selon un **modèle mathématique**
Basé sur la théorie des ensembles et une algèbre relationnelle
- **Isolation de l'accès** aux données de l'implémentation physique
Grâce à un langage déclaratif de haut niveau

System R

- Première implémentation de SQL avec le prototype **System R**
Développé en 1974 pour expérimenter les concepts de Codd
- Langage **Sequel** (*Structured English Query Language*)
 - RSS (*Research Storage System*)
 - RDS (*Relational Data System*)
- **Pratt & Whitney** premier client de System R en 1977



Évolution du relationnel



De OLTP à OLAP

- **Online Transactional Processing (OLTP)**

Utilisation purement transactionnelle des données (gestion)

- **Online Analytical Processing (OLAP)**

Tableau de bord, analyse historique et prédictive (statistique)


- **Limitation** du modèle relationnel pour OLAP

Agrégats, optimisation de requête, indexation... pas suffisants

OLTP versus OLAP

- Division d'un **système IT** en deux parties

Une partie plutôt transactionnelle et une plus analytique



Problèmes du relationnel...

- 1 Conversion de l'information de la représentation naturelle en tables
- 2 Reconstruction de l'information depuis les tables
- 3 Nécessité de modéliser les données (sémantique) avant stockage
- 4 Schéma rigide forçant données d'une colonnes avec le même type
- 5 Difficilement mis à l'échelle (scaling)
- 6 Difficulté de faire des jointures entre différents systèmes
- 7 Plusieurs dialectes existants du SQL (portabilité)
- 8 Certaines règles business difficilement exprimable en SQL
- 9 Recherche approximative et de type fuzzy difficile
- 10 Pas de stockage et validation efficace de documents complexes

- Meetup par **Johan Oskarsson** au Hadoop summit @ SFO
Software developer basé à Londres pour Last.fm
- **Choix d'un nom** court, mémorable, peu de résultat Google
#NoSQL "open-source, distributed, nonrelational databases"
- Plusieurs **caractéristiques** communes de ces bases de données
 - N'utilisent pas le modèle relationnel, ni SQL
 - Open source
 - Conçues pour être exécutées sur de large clusters
 - Basées sur les besoins des propriétés web du 21^e siècle
 - Pas de schéma, ajout de champs sans contrôle

Le monde du NoSQL



<http://nosql-database.org/>

<http://nosql.mypopescu.com/kb/nosql>

Intérêt du NoSQL

- **Hausse de la productivité** lors du développement
 - Gain de temps mapping de la base de données vers la mémoire
 - Moins de code à écrire, déboguer et faire évoluer
- Quantité de données à **grande échelle**
 - Stockage rapide de grandes quantités de données
 - Base de données répartie sur des clusters

Propriétés ACID

- Ensemble de **propriétés des transactions** en base de données
Atomicity, Consistency, Isolation et Durability
- Définition par **Reuter et Härder** en 1983
 - Une transaction fait tout ou rien (e.g. si panne de courant)
 - Base de données change d'un état valide vers un autre valide
 - Exécutions concurrentes de transactions comme séquentielles
 - Transaction validée confirmée et stockée

Propriétés BASE

- Gérer les **pertes de consistance** en maintenant la fiabilité

Basically Available, Soft state et Eventual consistency

- **Contraintes assouplies** par rapport aux propriétés ACID

- Toujours une réponse : failure, donnée inconsistante possible
- L'état change au cours du temps, même lorsque pas d'inputs
- Le système finira tôt ou tard par être consistant

Théorème CAP

- **Théorème CAP**, énoncé par Eric Brewer, sur le distribué
Consistency, Availability et Partition tolerance
- Au départ, distribution du calcul et **maintenant des données**
Clusters ou grids pour augmenter la puissance totale de calcul
- Trois **garanties pas satisfaisables** pour un système distribué
 - **Consistance** des données sur tous les nœuds
 - **Disponibilité** des données même avec perte d'un nœud
 - **Résistance** au morcellement avec nœuds autonomes

ACID ou BASE? (1)

- **ACID** désiré dans un environnement “*shared something*”

Pessimiste : forcer la consistance et la fin des transactions

- A** tout ou rien, commit ou rollback
- C** pas de données inconsistantes
- I** pas de connaissances des transactions concurrentes
- D** transaction confirmée persistente

- **BASE** implémenté dans un environnement “*shared nothing*”

Optimiste : accepter des inconsistances temporaires

- BA** garantie par réplication
- S** consistance à garantir par l'application
- E** donnée périmée possible, consistance assurée tôt ou tard

ACID ou BASE? (2)

- **Conjecture** liée au théorème de CAP

On ne peut satisfaire que deux des trois exigences CAP

- **Trois situations** possibles

- $C + A \sim \text{ACID}$: un seul serveur central (avec réplication?)
- $C + P$: soit « $w N, r 1$ », ou « $w 1, r N$ » (trop lent?)
- $A + P = \text{BASE}$: pas de consistance forte garantie

NewSQL, une nouvelle tendance

- Nouvelle tendance pour combiner la force du **SQL et NoSQL**
Garanties du relationnel avec la souplesse du NoSQL
- Souvent appelé **“SQL on Steroids”** par la communauté
 - Basé sur le modèle relationnel et le langage SQL
 - Mise à l'échelle, flexibilité et haute performance du NoSQL
- **Propriétés ACID** respectées avec horizontal scaling



Big Data

Big Data

- Augmentation du **volume de données** manipulé
 - Notamment les entreprises et organismes liés à l'Internet*
- **Multiplication exponentielle** jusqu'à des pétaoctets
 - Données scientifiques, bases de données médicales
 - Réseaux sociaux, opérateurs téléphoniques
 - Indicateurs économiques et sociaux
 - Agences nationales de défense du territoire
- **Défi** de gérer et traiter cette énorme quantité de données
 - Pas à la portée du traditionnel modèle relationnel*

4Vs (1)

- Big Data caractérisé par **quantité illimitée** de jeux de données
Données très complexes à collecter et à stocker
- Données suivent les **4Vs**
 - **Volume** de l'ordre de Pbytes, Ebytes
 - **Vélocité** taux de croissance des données et vitesse traitement
 - **Variété** avec plusieurs sources et types (image, vidéo, son...)
 - **Véracité** des données, obsolescence, intégrité et sécurité

4Vs (2)

40 ZETTABYTES

(140 TRILLION GIGABYTES)
of data will be created by 2020, an increase of 300 times from 2005



Volume SCALE OF DATA



It's estimated that 2.5 QUINTILLION BYTES

(2.3 TRILLION GIGABYTES)
of data are created each day



Most companies in the U.S. have at least
100 TERABYTES
(100,000 GIGABYTES)
of data stored

The New York Stock Exchange captures

1 TB OF TRADE INFORMATION
during each trading session



Velocity ANALYSIS OF STREAMING DATA



Modern cars have close to
100 SENSORS
that monitor items such as
fuel level and tire pressure

By 2016, it is projected
there will be
**18.9 BILLION
NETWORK
CONNECTIONS**
—almost 2.5 connections
per person on earth



The FOUR V's of Big Data

From traffic patterns and music downloads to web history and medical records, data is recorded, stored, and analyzed to enable the technology and services that the world relies on every day. But what exactly is big data, and how can these massive amounts of data be used?

As a leader in the sector, IBM data scientists break big data into four dimensions: **Volume, Velocity, Variety and Veracity**.

Depending on the industry and organization, big data encompasses information from multiple internal and external sources such as transactions, social media, enterprise content, sensors and mobile devices. Companies can leverage data to adapt their products and services to better meet customer needs, optimize operations and infrastructure, and find new sources of revenue.

By 2015
4.4 MILLION IT JOBS
will be created globally to support big data,
with 1.9 million in the United States



As of 2011, the global size of
data in healthcare was
estimated to be
150 EXABYTES
(160 BILLION GIGABYTES)



**30 BILLION
PIECES OF CONTENT**
are shared on Facebook
every month



By 2014, it's anticipated
there will be
**420 MILLION
WEARABLE, WIRELESS
HEALTH MONITORS**

Variety DIFFERENT FORMS OF DATA

**4 BILLION+
HOURS OF VIDEO**
are watched on
YouTube each month



400 MILLION TWEETS
are sent per day by about 200
million monthly active users



Open Data

open 

Open Data

Explore With Us

Data Stories

Innovation Space

About

Open Data

We hope to spark your creative juices and equip you with data sets and tools to solve looming challenges here on Earth using NASA data, tools, and resources



We're Setting Data, Code and APIs free



Data

This inventory offers services that enable users the ability to discover, collaborate,



Code

A community-driven catalog of NASA's Software Release projects developers can



APIs

Developers can register for API keys and look up available API's, hooks for analytics,

Open Data

open **NASA**

Open Data | Explore With Us | Data Stories | Innovation Space | About

Open Data

We hope to spark your creative tools to solve looming challenges and resources

We're Setting Data



Data

This inventory offers services that enable users the ability to discover, collaborate

OPEN GOVERNMENT DATA
U.S. DEPARTMENT OF DEFENSE

Search Open Government Data

HOME | OPEN DATA | FEATURED DATASET | FEATURED API | PUBLIC DATA LISTING | CONTACT US

Featured API

Each month, we feature one application programming interface (API) provided by the Department of Defense. These APIs allow developers to produce new and innovative applications using open government data.

[View](#)



Links

[PUBLIC DATA LISTING](#)

[DOD OPEN GOV](#)

[DoD Developer Page](#)

[DoD Mobile Applications Gallery](#)

[DoD Digital Strategy Page](#)

Open Government Data at the Department of Defense

The Department of Defense (DoD) maintains a vast amount of information. Information that most folks don't normally associate with Defense. Consider the following:

GPS

The Global Positioning System (GPS) is a space-based satellite navigation system built and maintained by DoD and is freely available to anyone in the world with a GPS receiver. In addition to navigation, uses of GPS include precise timing for financial transactions, search and rescue, communications, farming, recreation and both military and commercial aviation. GPS is operated by the **2nd Space Operations Squadron** at Schriever Air Force Base, Colorado.

Open Data

The screenshot displays the European Union Open Data Portal interface. At the top, there is a navigation bar with the 'open NASA' logo and a 'Open Data' button. Below this, the main header features the European Union flag and the text 'European Union Open Data Portal'. A search bar is present with the text 'Find datasets...'. To the right of the search bar, there is a 'Suggest a dataset' section with the text 'Is there data you would like to find on the portal?' and a 'Make a suggestion >>' link. Below the search bar, the text 'Total datasets available: 9070' is displayed. The main content area is divided into two columns. The left column is titled 'Most viewed datasets' and lists several datasets with their respective view counts. The right column is titled 'Browse datasets by subject or groups' and features a grid of icons representing different subject areas. Below this grid, there is a 'Popular terms' section with the text 'balance of payments'.

open NASA

Open Data Explore With Us Data Stories Innovation Space About

Sitemap | Legal notice | Contact | English (en)

EUROPEAN UNION

European Union Open Data Portal

EUROPEA Open Data Portal Data

Data Applications Linked Data Developers' corner About

Data provider's area

Share

Find datasets...

Suggest a dataset

Is there data you would like to find on the portal?

Make a suggestion >>

Show results with: all of these words | any of these words | the exact phrase

Total datasets available: 9070

Most viewed datasets [view all >>](#)

- 1st DGT-Translation Memory (14773 views)
- 2nd [LATEST VERSION] Elevation map of Europe (8999 views)
- 3rd Tenders Electronic Daily (TED) - public procurement notices from the EU and beyond (8021 views)
- 4th CORDIS - EU research projects under FP7 (2007-2013) (7902 views)
- 5th EuroVoc, the EU's multilingual thesaurus (7090 views)
- 6th Transparency Register (5292 views)
- 7th Register of Commission documents (4432 views)

Browse datasets by subject or groups

- Employment and working conditions
- Social questions
- Economics
- Finance
- Trade
- Industry
- Education and communications
- Science

[more subjects >>](#)

Popular terms

balance of payments

The Global Positioning System (GPS) is a space-based satellite navigation system built and maintained by DoD and is freely available to anyone in the world with a GPS receiver. In addition to navigation, uses of GPS include precise timing for financial transactions, search and rescue, communications, farming, recreation and both military and commercial aviation. GPS is operated by the 2nd Space Operations Squadron at Schriever Air Force Base, Colorado.

Open Data

The screenshot displays the Data.gov.be website interface. At the top, there are navigation links for languages (NL, EN, FR, DE) and a link to other official information and services (www.belgium.be/fr). The main header includes the logo for Data.gov.be and navigation links for HOME, DATA, and CONTACT. A central banner reads "Data, tools and resources. More than 5000 datasets." Below this is a search bar with the placeholder text "Search". The main content area features a grid of 14 icons representing different data categories: Agriculture and Fisheries, Culture and Sports, Economy and Finance, Education, Energy, Environment, Health, International, Justice, Population, Public Sector, Regional, Science and Technology, and Transport. At the bottom of the main content area, there are links for "Terms of Use", "GitHub", and "Your app?". Below the main content area, there is a list of search results, including "Register of Commission documents" and "balance of payments". A small text block at the bottom of the page provides information about the Global Positioning System (GPS), stating it is a space-based satellite navigation system built and maintained by DoD and is freely available to anyone in the world with a GPS receiver. It also mentions that GPS is operated by the 2nd Space Operations Squadron at Schriever Air Force Base, Colorado.

open NASA

NL EN FR DE

Other official information and services: www.belgium.be/fr **be**

.be Data.gov.be

HOME DATA CONTACT

Data, tools and resources. More than 5000 datasets.

Search

Agriculture and Fisheries

Culture and Sports

Economy and Finance

Education

Energy

Environment

Health

International

Justice

Population

Public Sector

Regional

Science and Technology

Transport

Terms of Use GitHub Your app ?

(5292 views)

Register of Commission documents

balance of payments

The Global Positioning System (GPS) is a space-based satellite navigation system built and maintained by DoD and is freely available to anyone in the world with a GPS receiver. In addition to navigation, uses of GPS include precise timing for financial transactions, search and rescue, communications, farming, recreation and both military and commercial aviation. GPS is operated by the **2nd Space Operations Squadron** at Schriever Air Force Base, Colorado.

Principaux acteurs



facebook



YAHOO!



Évolution technologique

- Premier SGBD construits autour de **mainframes**
Avec les limitations des capacités de stockage de l'époque
- Plusieurs **évolutions technologiques** ont levé ces contraintes
 - Généralisation des interconnexions de réseau
 - Augmentation de la bande passante sur Internet
 - Diminution du cout des machines moyennement puissantes

- **Systeme de fichiers distribué** propriétaire développé par Google
Google File System (GFS) présenté en 2003
- Stockage redondant et résilient sur un **cluster de machines**
Puissance moyenne et « jetables » (commodity hardware)
- Plusieurs **caractéristiques** de ce système de fichiers
 - Conçu pour des interactions système-système
 - Exécuté dans l'espace utilisateur et pas dans le kernel de l'OS
 - Gère des fichiers de plusieurs gigaoctets
 - Réplication automatique des données par les chunkservers

MapReduce

- **Modèle de programmation** et implémentation associée
 - Traitement et génération des grandes quantités de données
 - Algorithme parallèle et distribué sur un cluster
- Implémentation basée sur **deux fonctions**
 - Map effectue un traitement sur une liste (tri, filtre...)
 - Reduce regroupe les données en un résultat (somme...)

Apache Hadoop

- **Hadoop** est une implémentation libre de MapReduce en Java
Par Doug Cutting, nommé comme l'éléphant doudou de son fils
- **Hadoop Distributed FileSystem** (HDFS)
Inspiré par la publication sur GFS
- Utilisé par de **nombreuses entreprises**
 - Soutien de Microsoft, utilisation sur Windows Azure et Server
 - Cluster Yahoo! de 4000 machines, bientôt 10000 avec la 2.0
 - Facebook annonce l'installation de HDFS avec 100 pétaoctets



BigTable

- Système de **gestion de données** basé sur GFS
Gigantesque table de hachage distribuée
- Gestion de la **cohérence** des données et **distribution** sur GFS
- Plusieurs implémentations libres dont **HBase** (Apache)
Utilisé notamment par eBay, Yahoo! et Twitter

Dynamo

- Dépôt de **paires clé-valeur** distribué et propriétaire (Amazon)
Mise en œuvre par Amazon dans Simple Storage Service (S3)
- **Quatre principes** clés
 - Évolutivité incrémentale sans influence sur opérateur, système
 - Symétrie avec tous les nœuds étant égaux
 - Décentralisation avec aucun contrôle central
 - Hétérogénéité en partageant le travail selon les ressources
- Création de plusieurs **moteurs NoSQL** basés sur Dynamo
Cassandra, Riak, Projet Voldemort (LinkedIn)

Modèle de données



Défaut d'impédance (1)

- **Défaut d'impédance** objet-relationnel avec SQL

Passer du relationnel à l'objet s'effectue avec une impédance

- **Différence** entre modèle relationnel et structures en mémoire

Relations et tuples versus structures de données complexes

- Apparition des langages de programmation **orienté objet**

Object-Relational Mapping (ORM) comme Hibernate...

Défaut d'impédance (2)

```
1 class Address:
2     def __init__(self, street, number, zipcode, city):
3         self.__address = (street, number, zipcode, city)
4
5     def __str__(self):
6         return '{}\n{} {}'.format(*self.__address)
7
8 ecam = Address("Promenade de l'Alma", 50,
9               1200, "Woluwé-Saint-Lambert")
```

Address			
Id	Street	Number	CityID
1	Promenade de l'Alma	50	1

City		
Id	Zipcode	Name
1	1200	Woluwé-Saint-Lambert

Intégration versus Application (1)

- Coordination de plusieurs applications **autour des données**

Partage des données dans une seule base de données commune

- **Difficile de changer** la structure de la base de données

Non trivial d'assurer l'intégrité des données




Intégration versus Application (2)

- Accès base de données par **une seule application**

Offre une interface d'accès aux autres applications

- Déploiement de services web et **architecture orientée services**

Plus grande flexibilité dans le format des données échangées



Modèle de données (1)

- **Modèle** avec lequel on perçoit et manipule les données
Différent du modèle de stockage sur disque
- **Modèle relationnel** constitué de tables avec des rangées
Colonnes avec des valeurs pouvant référencer d'autres rangées
- Changement vers une collection d'**agrégats**
Unité d'information traitée, stockée, échangée de façon atomique

Modèle de données (2)

- Quatre principaux **modèles de données** pour le NoSQL

Analyse détaillée d'un exemple par modèle

- **Pas de classification** unique et non ambiguë


Certaines bases de données couvrent plusieurs modèles

Modèle de données	Exemples de base de données
Clé-valeur	BerkeleyDB, Memcached, Redis , Riak...
Document	CouchDB, MongoDB , OrientDB...
Colonne	Amazon Simple DB, Cassandra , HBase...
Graphe	FlockDB, HyperGraphDB, Neo4j , OrientDB...

- Opération sur des **unités de données** complexes et structurées
Pour dépasser les limitations des tuples du modèle relationnel
- Possibilité d'**imbriquer** des listes et autres structures
Traitement des différents "objets" comme des unités
- Unité de manipulation et de gestion de la **concurrency**
Facilitation de la répartition des données sur des clusters

Relation vs agrégat (1)

- Modèle complètement **normalisé** sans données dupliquées



Relation vs agrégat (2)

Customer	
Id	Name
1	Martin

Order		
Id	CustomerId	ShippingAddressId
99	1	77

Product	
Id	Name
27	NoSQL Distilled

BillingAddress		
Id	CustomerId	AddressId
55	1	77


OrderItem			
Id	OrderId	ProductId	Price
100	99	27	32.45

Address	
Id	City
77	Chicago

OrderPayment				
Id	OrderId	CardNumber	BillingAddressId	txnId
33	99	1000-1000	55	abelif879ft

Relation vs agrégat (3)

- Modèle composé de deux agrégats principaux



Relation vs agrégat (4)

```
1 # Customer
2 {
3   "id": 1,
4   "name": "Martin",
5   "billingAddress": [{"city": "Chicago"}]
6 }
7
8 # Order
9 {
10  "id": 99,
11  "customerId": 1,
12  "orderItems": [{
13    "productId": 27,
14    "price": 32.45,
15    "productName": "NoSQL Distilled"
16  }],
17  "shippingAddress": [{"city": "Chicago"}],
18  "orderPayment": [{
19    "ccinfo": "1000-1000",
20    "txnId": "abelif879rft",
21    "billingAddress": {"city": "Chicago"}
22  }]
23 }
```

Clé-valeur

- Stockage d'agrégats sous la forme **clé-valeur**

La clé joue le rôle d'identifiant unique de chaque agrégat

- Récupération d'un agrégat **à partir de sa clé**

Fonctionne comme une table de correspondance



Document

- Stockage d'agrégat sous la forme de **document**
Chaque document est identifié de manière unique par un ID
- Récupération du document ou d'une **partie de document**
À partir de requêtes sur les champs de l'agrégat
- Création d'**index** sur base du contenu des documents
Pour accélérer les opérations de recherche



- Stockage sur disque **des colonnes** au lieu des lignes
On peut voir le stockage comme un map à deux niveaux
- Structure clé-valeur avec **identifiant de ligne** comme clé
Le second niveau contient les informations sur les colonnes



Graphe

- Possibilité de **relation** entre les agrégats

Avec possibilité de mise à jour automatique

- Utile pour des petits enregistrements avec **beaucoup de liens**

Ensemble de nœuds connectés par des arêtes

- Réseaux sociaux, préférences, règles d'admissibilité...

“Quelles sont toutes les choses qu'aiment Alexis et Sébastien ?”





Caractéristiques du NoSQL

Base de données sans schéma

- Les bases de données NoSQL n'ont pas de **schéma de données**
Contrairement à la structure rigide imposée par le relationnel
- **Ajout libre** de données de n'importe quel type
Comme clé, document, colonne, arête et propriétés
- Autorise le stockage de **données non uniformes**
Ce qui élimine le besoin d'avoir des valeurs NULL

Schéma implicite

- **Hypothèses** sur la structure des données dans le code

La base de données reste ignorante, c'est l'application qui vérifie

- Danger si **plusieurs applications** sur la même base de données

Elles doivent se mettre d'accord sur le schéma des données

- La **migration de données** doit toujours se faire prudemment

Que ce soit en relationnel ou en NoSQL

Développeur au centre

- Méthodologie de développement centrée sur le **développeur**
 - Design et mise en œuvre de l'architecture de l'application
 - Modélisation des données
- Deux approches différentes **RDBMS vs NoSQL**
 - Modèles de données relationnels théoriques
 - Requêtes et configuration applicative à supporter

Architecture du NoSQL

- Construction de la DB sur le **relationnel** avec DBMS
 - Description structure de données et du stockage
 - Processus de récupération des données et fiabilité
 - Données en tables (enregistrement et colonne) et non répétées
 - Importance des clés primaires
- Gestion des données beaucoup **plus flexible** en NoSQL
 - Répartition sur plusieurs serveurs, plateformes, processeurs
 - Évolution graduelle du schéma (implicite) des données

Opérations et relations sur les données

- Opérations classiques de **type CRUD** avec les RDBMS
Create, Read, Update, Delete
- Opérations beaucoup plus **diverses et variées** en NoSQL
 - Grand nombre d'ajouts et de mises à jour
 - Opérations sur d'autres entités que des lignes de tables
- NoSQL pas adapté pour données avec **beaucoup de relations**
RDBMS ont des one-to-one, one-to-many, many-to-many

Crédits

- Photos des livres depuis Amazon
- Photos des logos depuis Wikipédia
- <http://geekandpoke.typepad.com/geekandpoke/2011/01/nosql.html>
- <https://www.flickr.com/photos/15216811@N06/13495437084>
- <https://openclipart.org/detail/34537/tango-drive-hard-disk>
- <https://openclipart.org/detail/59167/magnifying-glass>
- <http://dilbert.com/strip/2013-09-20>
- https://en.wikipedia.org/wiki/File:Edgar_F_Codd.jpg
- <https://www.flickr.com/photos/75279887@N05/6914441342>
- <https://www.flickr.com/photos/lukevu/6380430175>
- <https://openclipart.org/detail/94723/database-symbol>
- <https://openclipart.org/detail/35407/tango-applications-other>
- <https://www.flickr.com/photos/diegolizcano/35522041701>