

# Au-delà des bases de données relationnelles

# Les bases de données NoSQL

- Not Only SQL propose de laisser de côté certaines contraintes des bases de données relationnelles. (dénormalisation)
- Dans ce contexte, il est plus intéressant d'avoir un langage de haut niveau pour exploiter les bases de données.
- Contrairement aux BD SQL, qui fonctionnent toutes sous le même principe, il existe plusieurs types de BD No SQL
  - Clé/Valeurs: Redis(VmWare) , SimpleDB (Amazon)
  - Des lignes vers les colonnes: le stockage des données est sous forme de colonne plutôt que de lignes. BigTable(Google), Hbase
  - Gestion de documents: MongoDB, Cassandra.
  - Orienté Graph : Neo4J

# Les bases de données NoSQL

## **Avantages**

- Permet de gérer rapidement des tonnes de données (grand volume à une vitesse rapide).
- Schémas dynamiques pour les données non structurées (évolutifs, n'a pas à être connu d'avance).
- Plusieurs façons de stocker des données.
- Moins coûteux (ajout de serveurs).

## **Inconvénients**

- La cohérence des données n'est pas garantie.
- Pas de langage de requête abstrait partagé, donc un travail de programmation spécifique plus important.

# Les bases de données NoSQL

Part du marché des SGBD : Les SGBD relationnels dominant le marché

## Quand utilise-t-on le SQL ?

- Les données doivent être structurées. L'organisation est connue (ou pourrait être connue) d'avance.
- L'intégrité des données doit-être respectée
- Les transactions sont importantes. Le principe ACID est important :

**Atomicité** : Une transaction s'effectue entièrement ou pas du tout

**Cohérence** : Le contenu d'une base doit être cohérent au début et à la fin d'une transaction

**Isolation** : Les modifications d'une transaction ne sont visibles/modifiables que quand celle-ci a été validée

**Durabilité** : Une fois la transaction validée, l'état de la base est permanent (non affecté par les pannes ou autre)

## Quand utilise t-on le NoSQL ?

- La structure de données n'est pas importante. Évolutive et pas connue d'avance
- Gestion de beaucoup de données structurées, et non structurée.
- BASE : (contrairement à)
  - Basically Available : quelle que soit la charge de la base de données, le système garantie la disponibilité des données.
  - Soft-state : La base peut changer lors des mises à jour ou lors d'ajout/suppression de serveurs. La base NoSQL n'a pas à être cohérente à tout instant
  - Eventually consistent : À terme, la base atteindra un état cohérent

# Théorème de Brewer

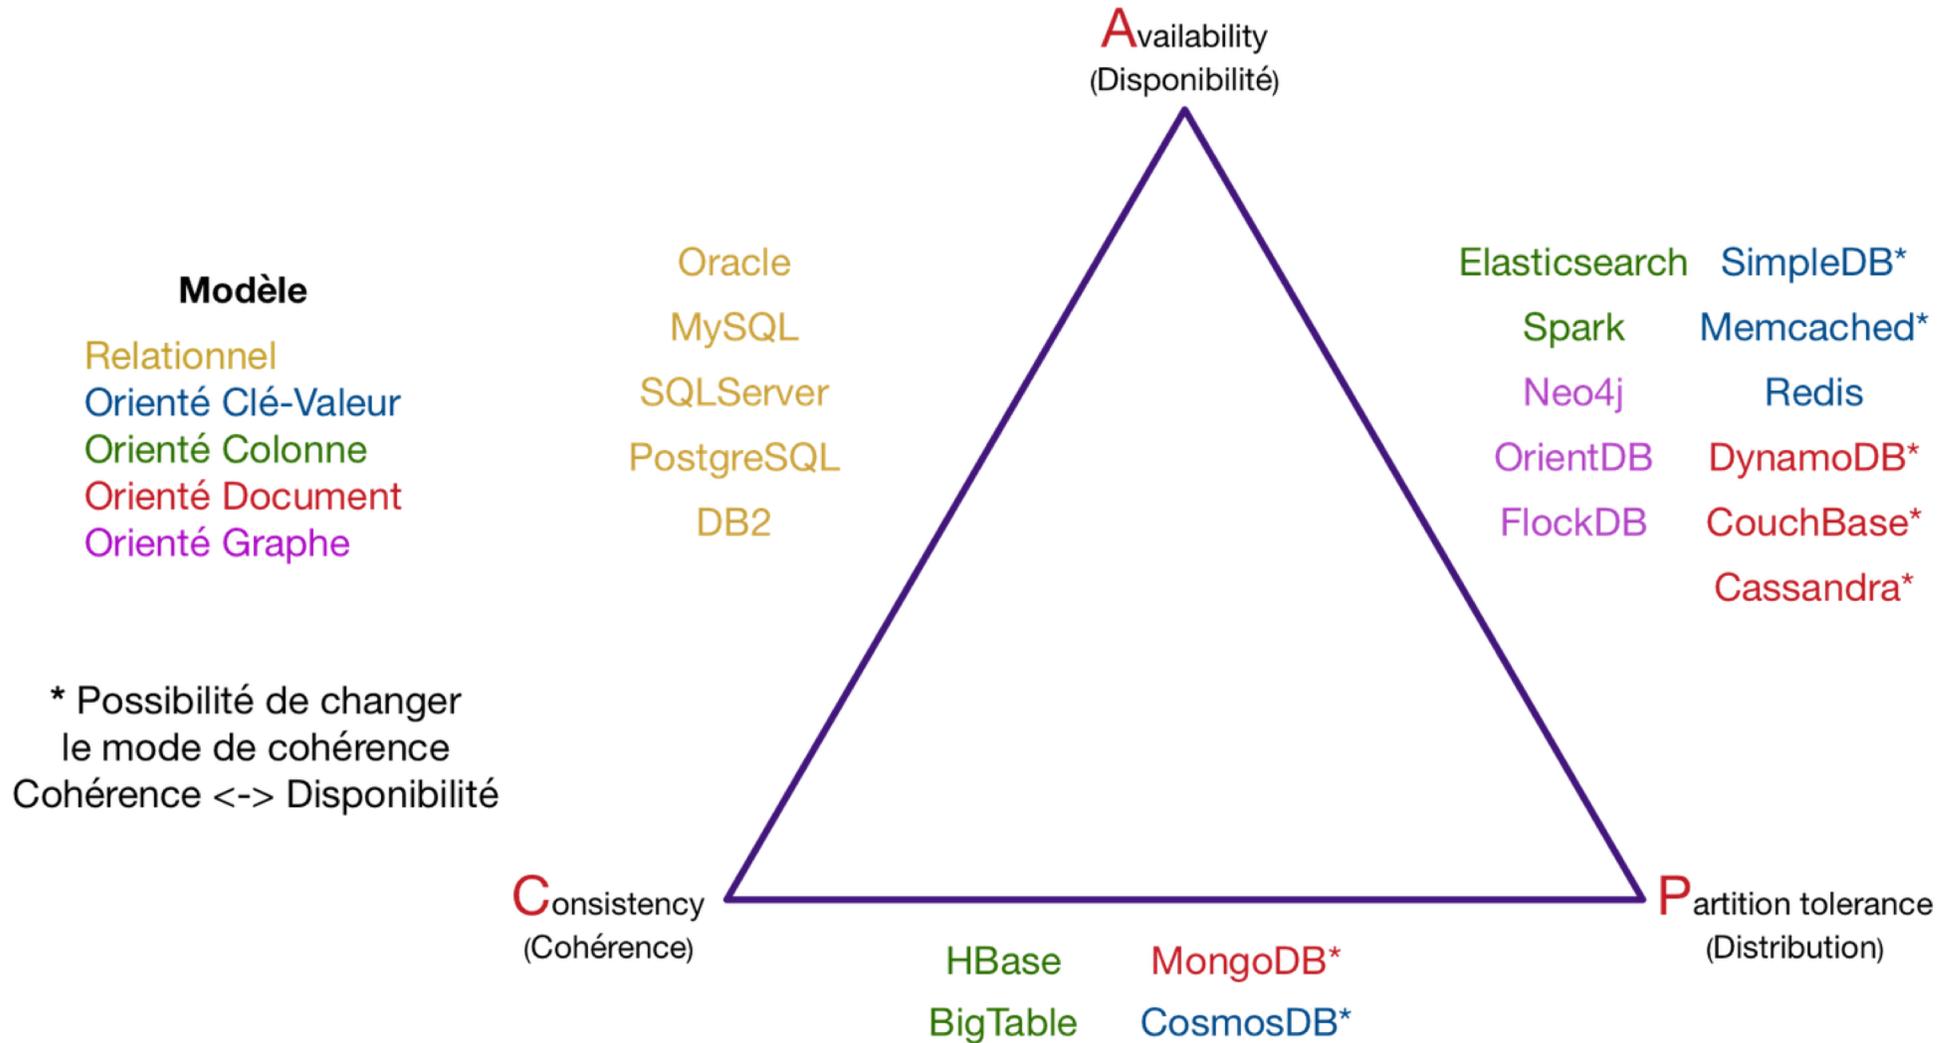
## **Théorème de Brewer dit "théorème de CAP, 2000 :**

Indique qu'il est impossible, pour un système distribué, de garantir en même temps les trois

contraintes suivantes:

- **Cohérence (Consistency):** Tous les noeuds du système voient les mêmes données au même moment.
- **Disponibilité (Availability) :** Toutes les requêtes reçoivent une réponse.
- **Tolérance au partitionnement (Partition Tolerance) :** Aucune panne ne doit empêcher le système de répondre correctement (sauf une coupure complète du réseau).

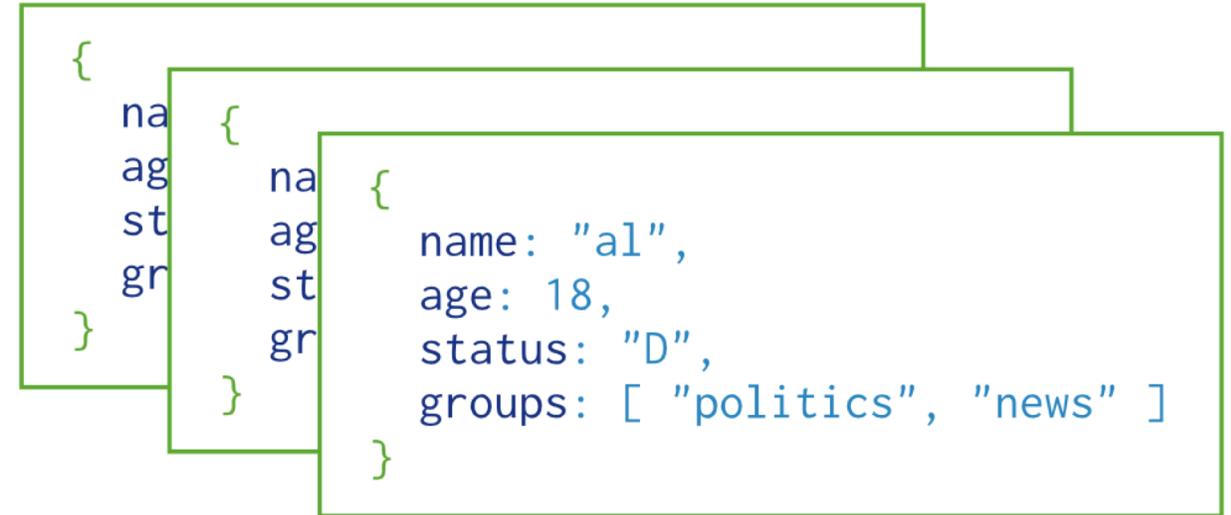
# Théorème de Brewer



Triangle de CAP

## Illustration : les collections (MongoDB) - 1

- Une collection est un ensemble de documents.
- C'est comme une table dans une base de données relationnelle.
- Les collections se trouvent dans une base de données



Collection

## Illustration : les collections (MongoDB) - 2

`db.Programmes.find({"nom":"Patoche"});` va retourner tous les étudiants dont le nom est Patoche.

`db.Programmes.find({"nom":"Patoche", "prenom":"Alain"});` va retourner les noms des étudiants dont le nom est Patoche et le prenom Alain.

`db.Programme.find({"nom":"Patoche"},{nom:1,prenom:1});` seuls les noms et les prénoms seront affichés

`db.Programmes.find( { "etudiant.nom": "Yanick" } );` on cherche dans un document imbriqué

**Le document Programmes, contient le document Etudiant**

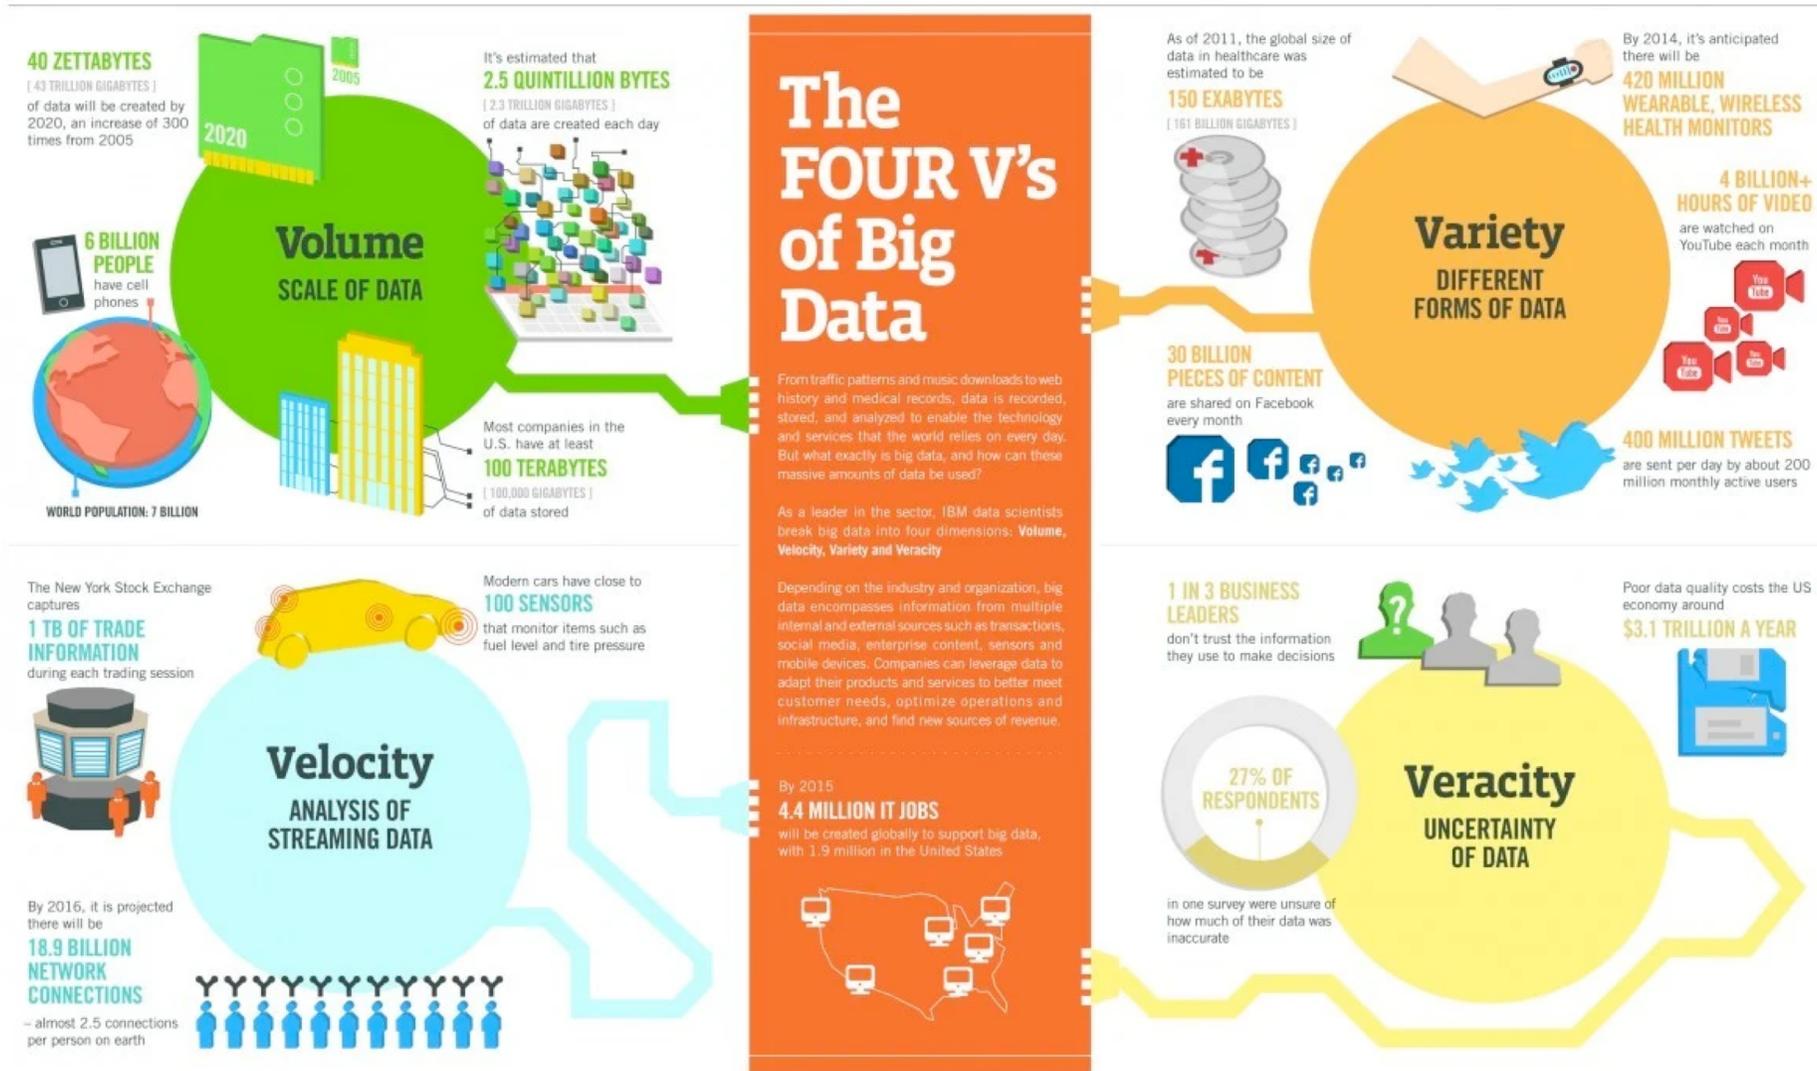
## Illustration : les collections (MongoDB) - 3

```
db.contacts.insertOne(  
{  
  "nom": "Poitras",  
  "dep":  
    {"code": 420, nom: "info"},  
  "cours": "kba"  
}  
);
```



Le champ dep a lui-même deux champs.

# Big data: les 4 V

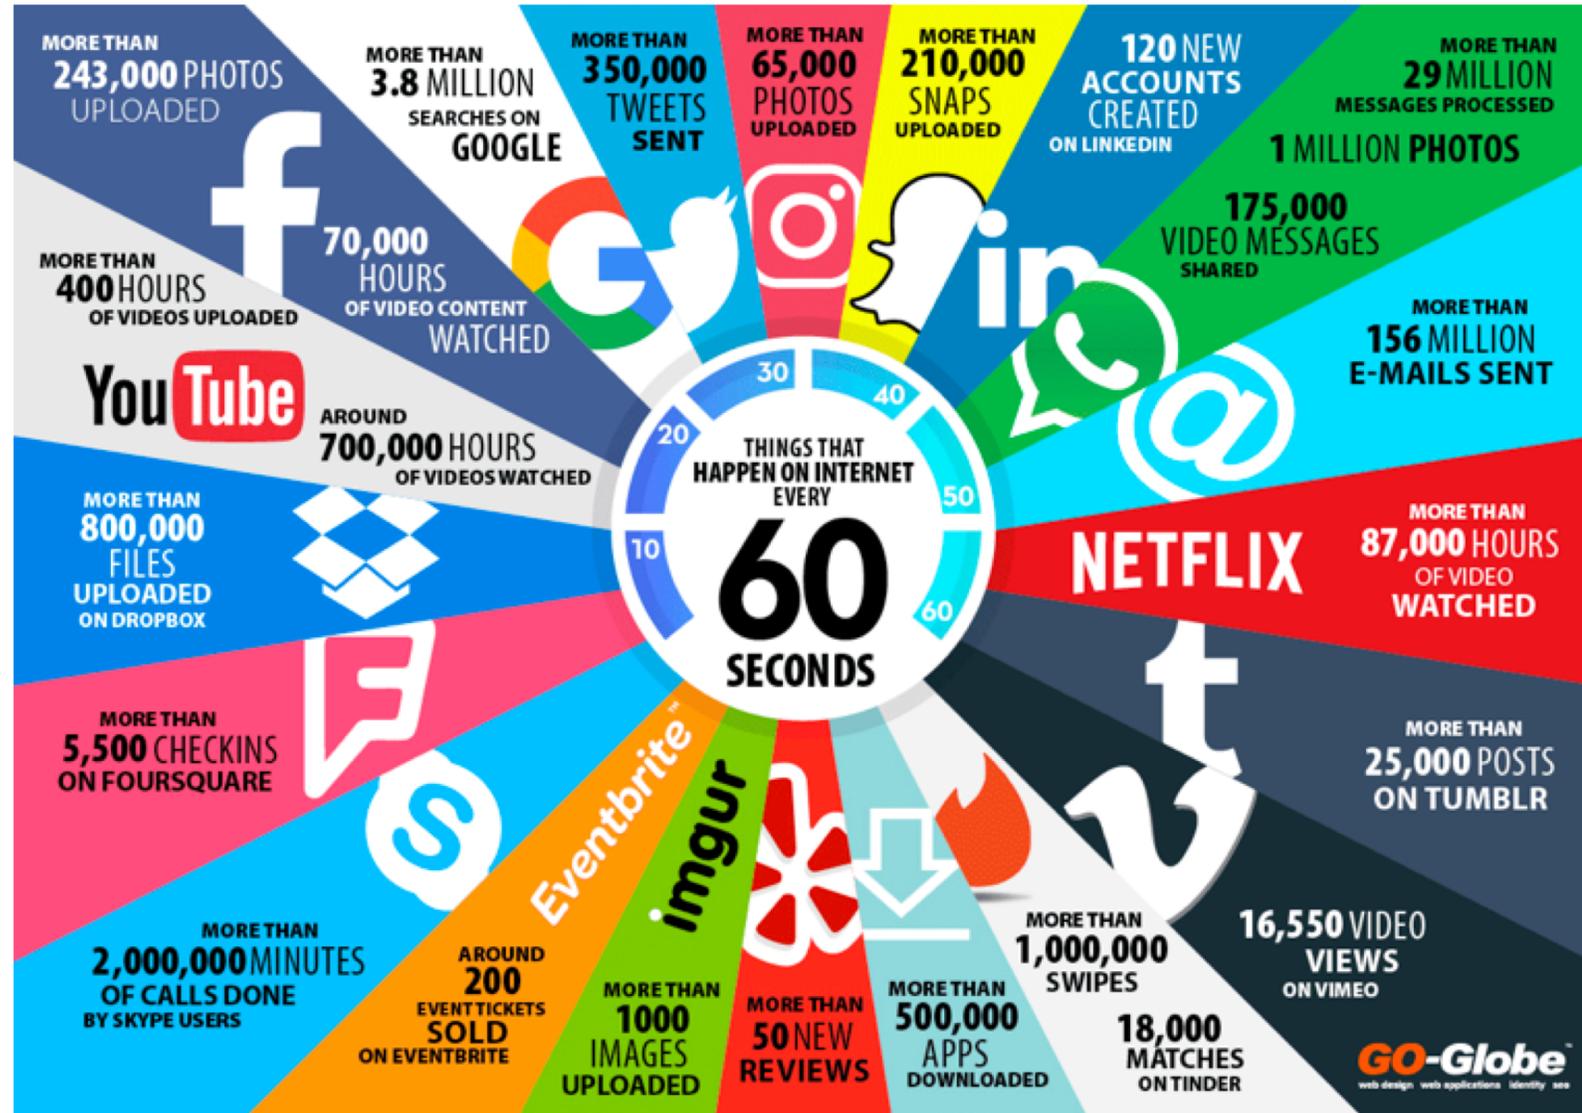


Sources: McKinsey Global Institute, Twitter, Cisco, Gartner, EMC, SAS, IBM, MEPEEC, QAS



# Les géants du Web

- Chacun a son outil
- Les outils évoluent aussi en fonction des algorithmes, notamment d'IA



# Les géants du Web : exemple

Chaque jour, Facebook gère :

- 2,5 milliards d'objets
- 500 To de nouvelles données
- 2,7 milliards de « Like »
- 300 millions de photos intégrées
- ...

