Gestion de Masse de Données (GMD)

Cours 4

Adrien Coulet
adrien.coulet@loria.fr

II. Transformer les données

② Pour gérer les données manquantes ou bruitées

a) Données manquantes

- La **qualité** des données : impacts sur l'analyse, la fouille, etc.
- Identifier le type des données manquantes
  - données manquantes pour des variables dépendantes VS. indépendantes
  - apparition des données manquantes de façon aléatoire VS. non aléatoire
    - l'absence de valeur d'une variable indépendante est aléatoire
    - c'est rarement le cas en pratique : l'apparition de données manquantes est souvent associée à un phénomène particulier. *Ex: les données sont manquantes en raison de : localisation géographique (ex US State hors des Etats Unis), éducation, âge, le manque d'information, etc.*
  - données manquantes de façon "voulue"
    - non demandé, non applicable (ex : sous contraceptif oral pour les hommes ? enceinte ?)
    - ce sont des cas particuliers de données manquantes de façon non-aléatoire
  - proportion de données manquantes et répartition de ces données
    - quelle proportion ? 1%, 40%
    - quelle répartition ?
      - bcp de données manquantes pour peu de n-uplets ?

      Ex : 20 individus sur 5000 dont 40% des données manquent ; ou 2000 avec 8% de données manquantes
      - bcp de données manquantes pour certains attributs ?

      Ex : 2 attributs sur 15 avec 80% de données manquantes ; ou 10 avec 2% de données manquantes

II. Transformer les données

② Pour gérer les données manquantes ou bruitées

a) Données manquantes

- Méthodes pour traiter les données manquantes
  - Abandonner des n-uplets

  réduit le nombre de cas (d'une étude par exemple)

  l'échantillon final peut ne pas être représentatif ou ne pas être significatif
  - Abandonner un attribut : dans le cas ou bcp de ses valeurs sont manquantes

  évidemment il faut espérer que cet attribut n'est pas trop important !
  - créer une catégorie pour les données manquantes (Attributs nominaux *ONLY*)

    ex : la variable *gender* peut prendre les valeurs *male, female, unspecified*
  - Imputer une valeur aux valeurs manquantes

    ex : remplacer par la moyenne de l'ensemble des valeurs présentes

    ex : la moyenne d'un sous ensemble des valeurs (ex : homme/femme)

    ex : remplacer par une valeur attendue (si des règles *x->y si x->?* on peut remplacer *?* par *y*)

    ex : méthodes plus sophistiquées : les moindres carrés, régression, etc.

Il n'y pas de bonne méthode … ce sont des méthodes existantes qui sont utilisées…

Exemple

Case #	Y	X1	X2	X3
1	30	2	Missing	12
2	37	2	1	Missing
3	41	3	1	20
4	42	1	Missing	16
5	45	3	2	Missing
6	49	1	2	27
7	51	Missing	1	30
8	55	3	2	33
9	58	Missing	2	19
10	60	2	Missing	24

II. Transformer les données

② Pour gérer les données manquantes ou bruitées

b) Données bruitées

- … et les données bruitées ?
  - C'est également un problème à considérer surtout si vous avez des données
    - mesurées par un appareil
    - entrées par un humain : le taux d'erreur est à prendre en considération
  - Il existe des outils pour réduire le biais causé par le bruit
  - idées souvent similaires au traitement des données manquantes
  - à **vous** de voir si vous en avez besoin

III. Regrouper et interroger les données

① les Entrepôt de Données (noté ED ou *DW*)

- **Objectif usuel** : aide à la décision – terme "*business intelligence*"
  - décision vs production pour les BD classiques
- **Produits** :
  - Oracle
  - MS SQL Server
- **Architecture générale** (slide suivante)

figure de Omar Boussaïd, Univ de Ly

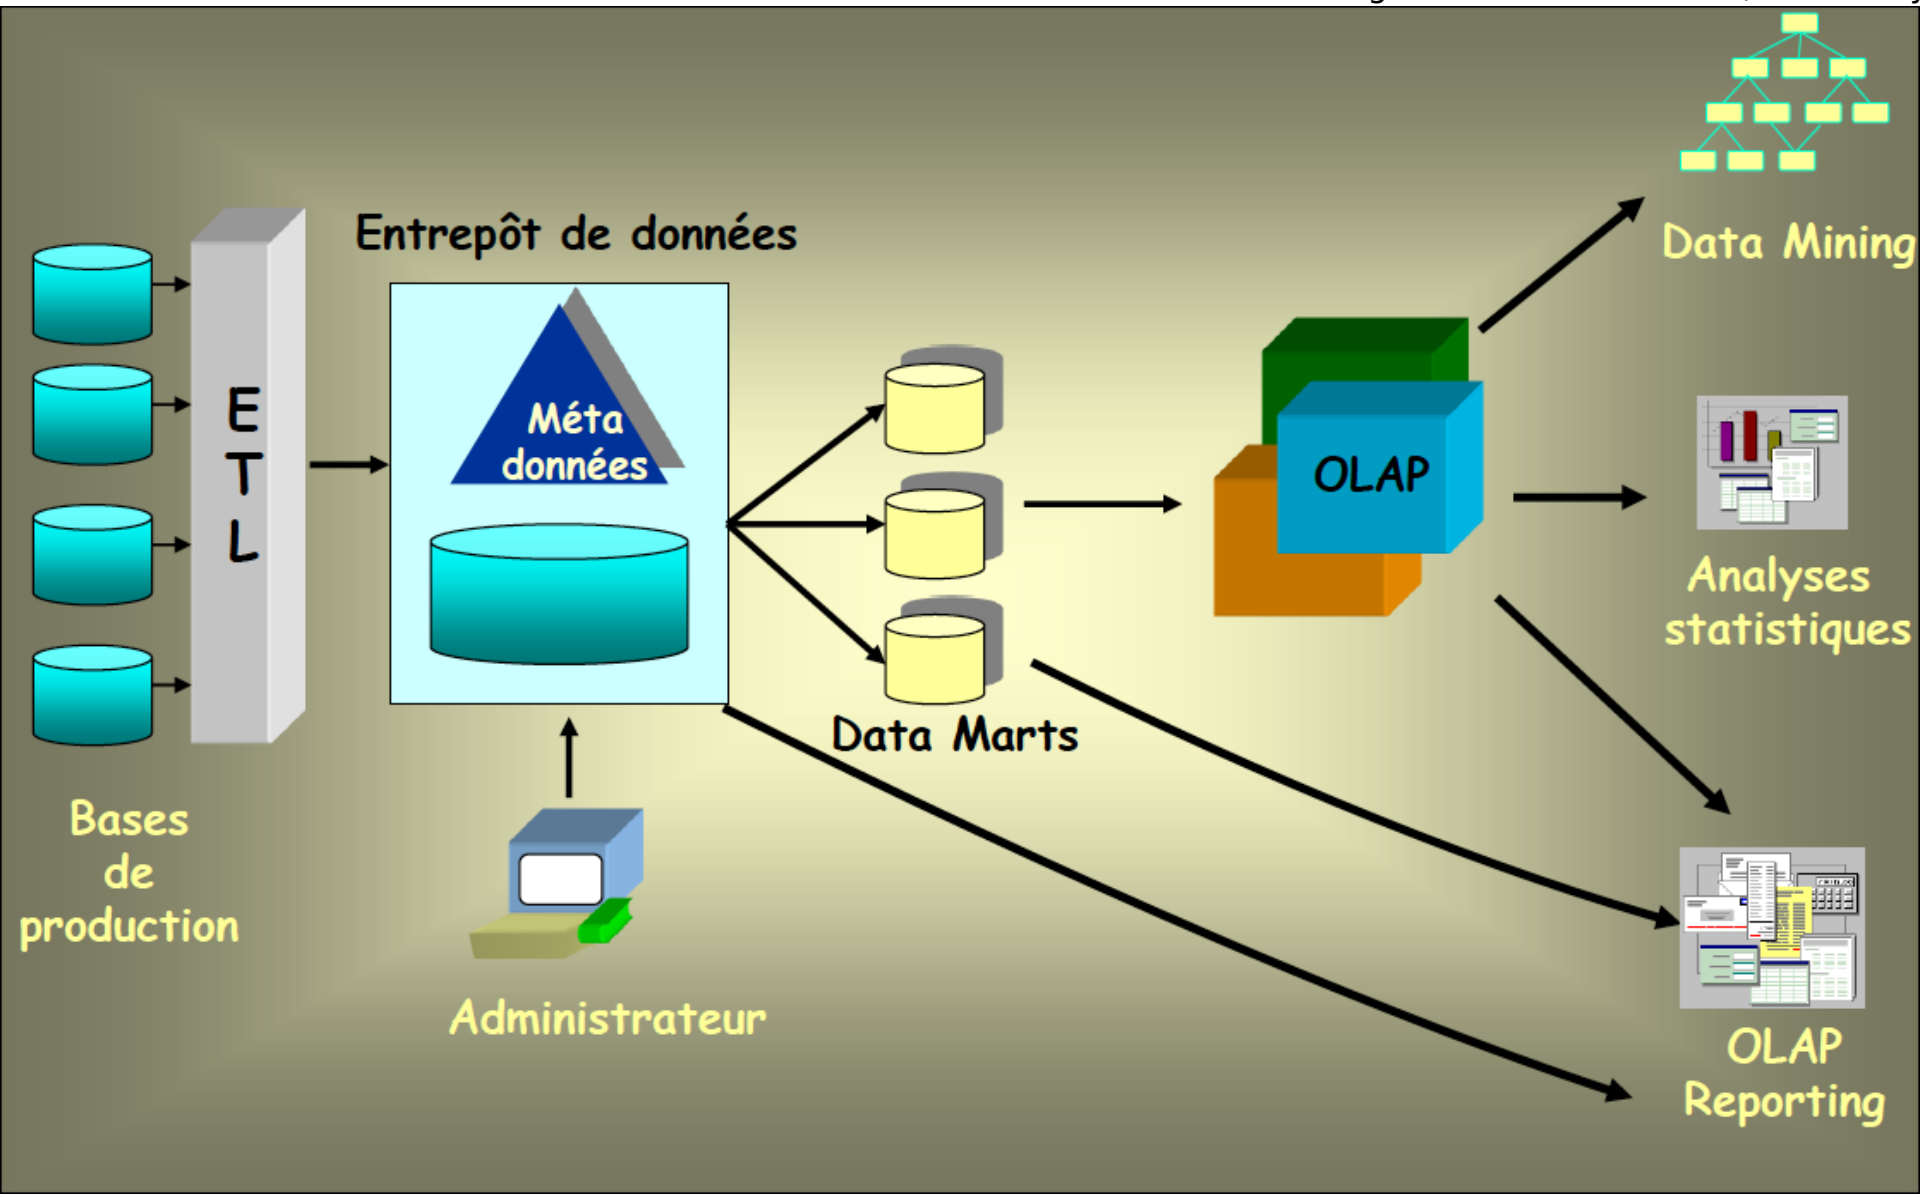

extraction
transformation
loading

administration

- conception
- modélisation
- structuration

- analyse
- restitution

III. Regrouper et interroger les données

① les Entrepôt de Données (noté ED ou *DW*)

- Modélisation des donnée
  - modèle en étoile
    - 1 table de fait
    - *n* tables de dimensions
    - granularité figée par les dime
  - modèle en flocon
  - modèle en constellation

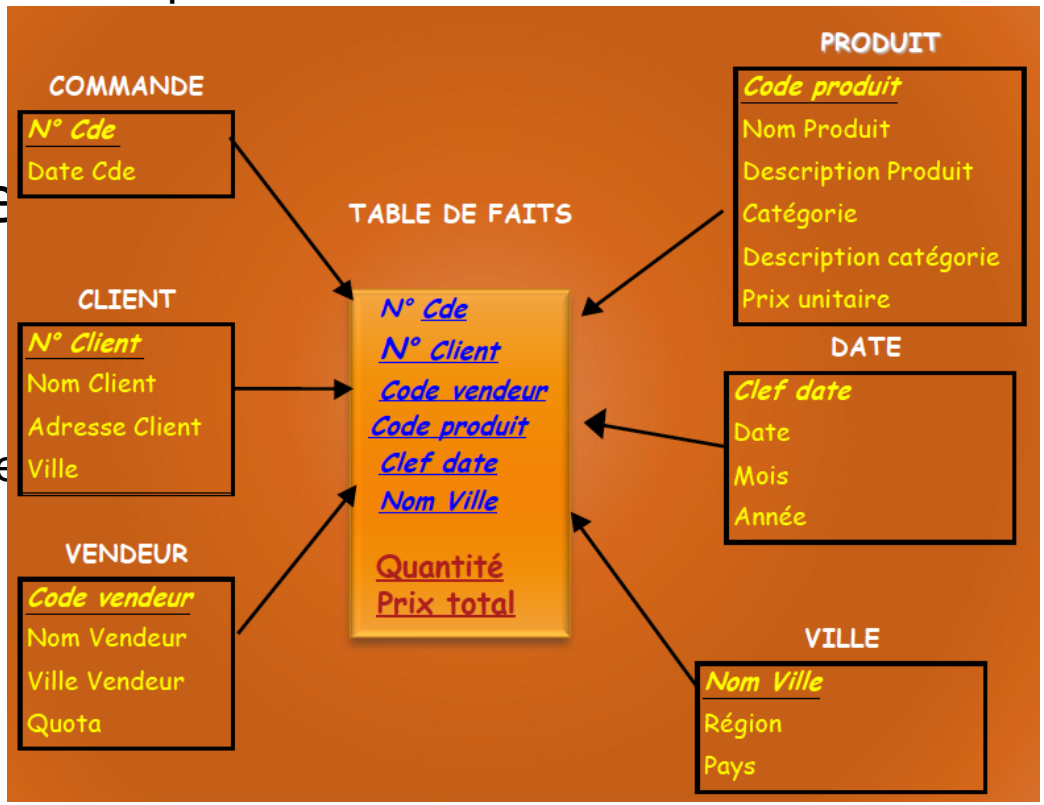

figure de Omar Boussaïd, Univ de Ly

III. Regrouper et interroger les données

① les Entrepôt de Données (noté ED ou *DW*)

- Modélisation des données
  - modèle en étoile
  - modèle en flocon
    - certaines dimension sont organisées suivant une hiérarchie
    - permet une analyse par palier (drill down)
  - modèle en constellation

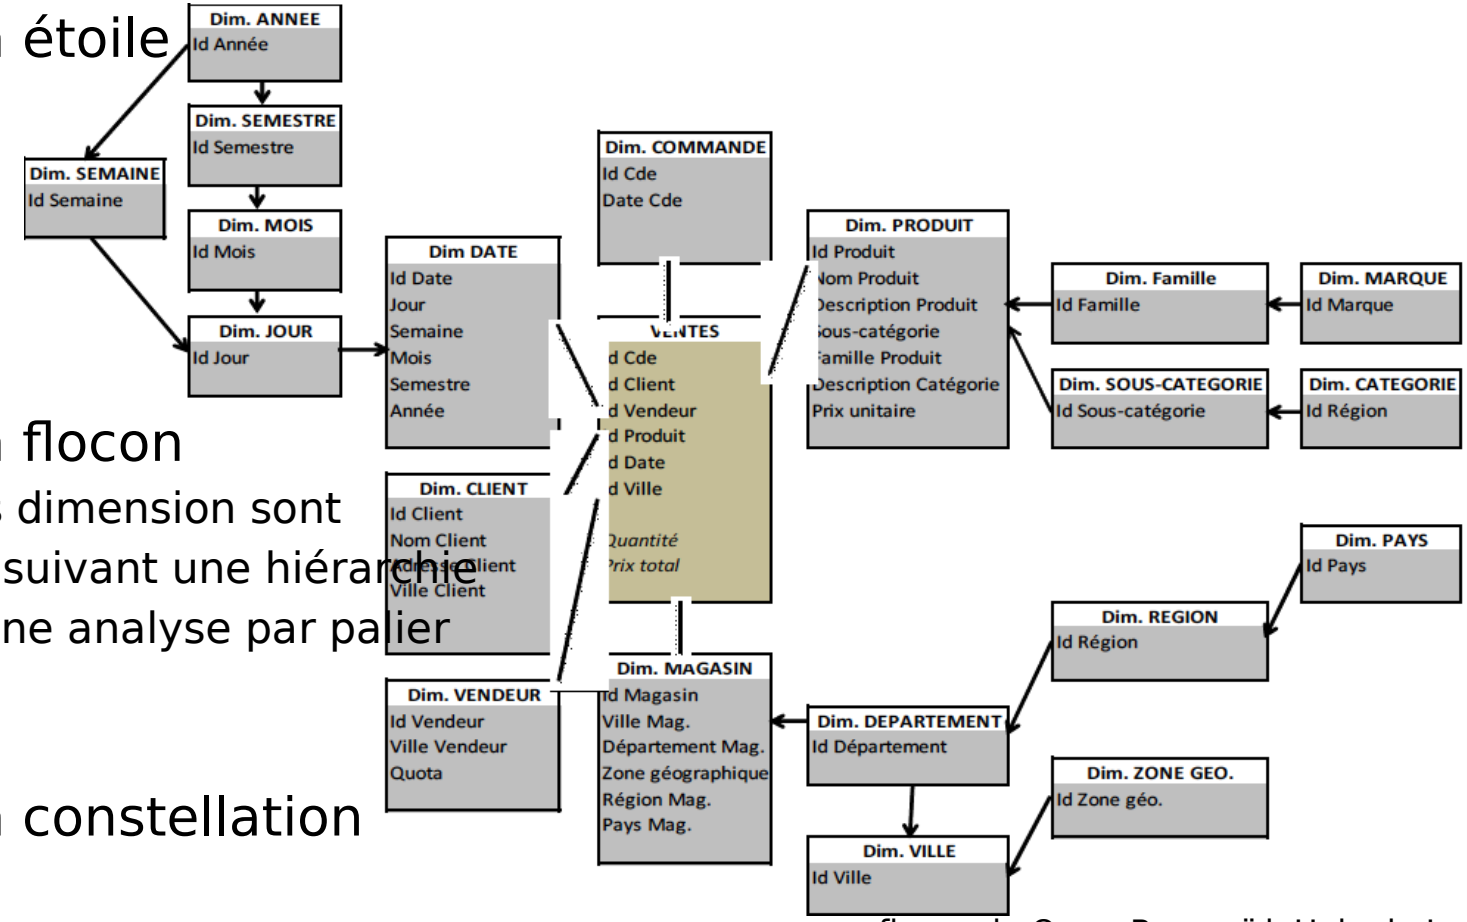

figure de Omar Boussaïd, Univ de Ly

III. Regrouper et interroger les données

① les Entrepôt de Données (noté ED ou *DW*)

- Modélisation des données
  - modèle en étoile
  - modèle en flocon
  - modèle en constellation
    - fusion de modèles en étoile
    - dimensions partagées

figure de Omar Boussaïd, Univ de Ly

III. Regrouper et interroger les données

① les Entrepôt de Données (noté ED ou *DW*)

- **OLAP On Line Analytical Processing** (vs Transactional Processing in BD)
  - Principe : voir les données à travers plusieurs dimensions (on parle de cube OLAP quand D =3)

Produit	Region	Ventes
Clous	Est	50
Clous	Ouest	60
Clous	Centre	100
Vis	Est	40
Vis	Ouest	70
Vis	Centre	80
Boulons	Est	90
Boulons	Ouest	120
Boulons	Centre	140
Nettoyeurs	Est	20
Nettoyeurs	Ouest	10
Nettoyeurs	Centre	30

Représentation des données dans une table relationnelle

	Est	Ouest	Centre
Clous	50	60	100
Vis	40	70	80
Boulons	90	120	140
Nettoyeurs	20	10	30

Représentation des données dans un tableau multidimensionnel

figure de Omar Boussaïd, Univ de Lyon

III. Regrouper et interroger les données

① les Entrepôt de Données (noté ED ou *DW*)

- **OLAP**
  - Opérations principales :
    - agrégation de données (ROLL-UP
    - forage de données (DRILL-DOWN

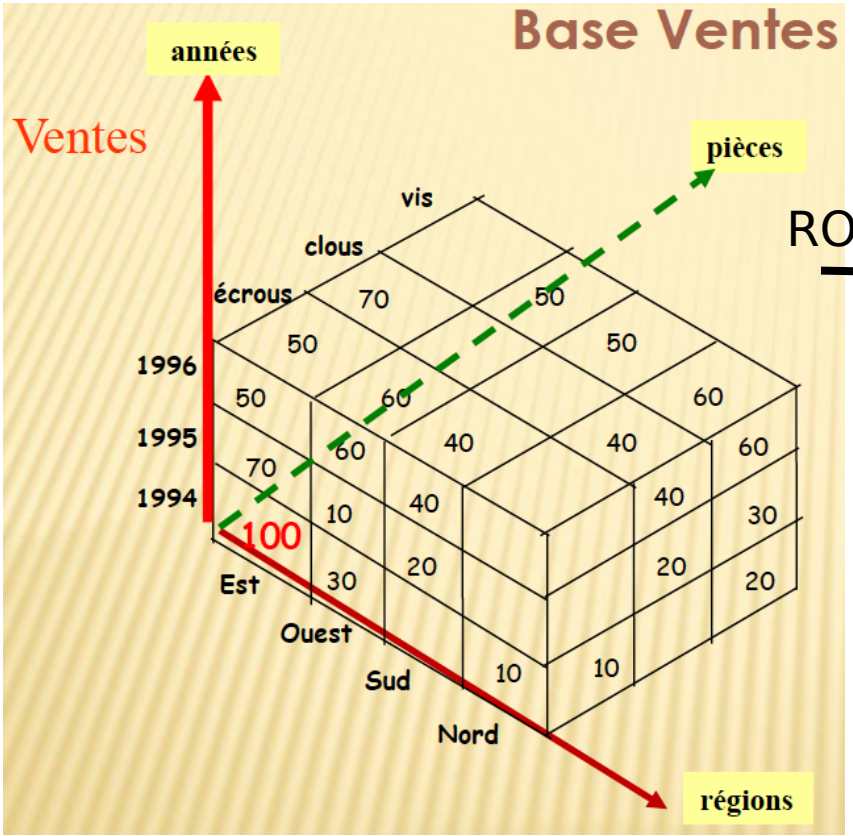

ROLL UP

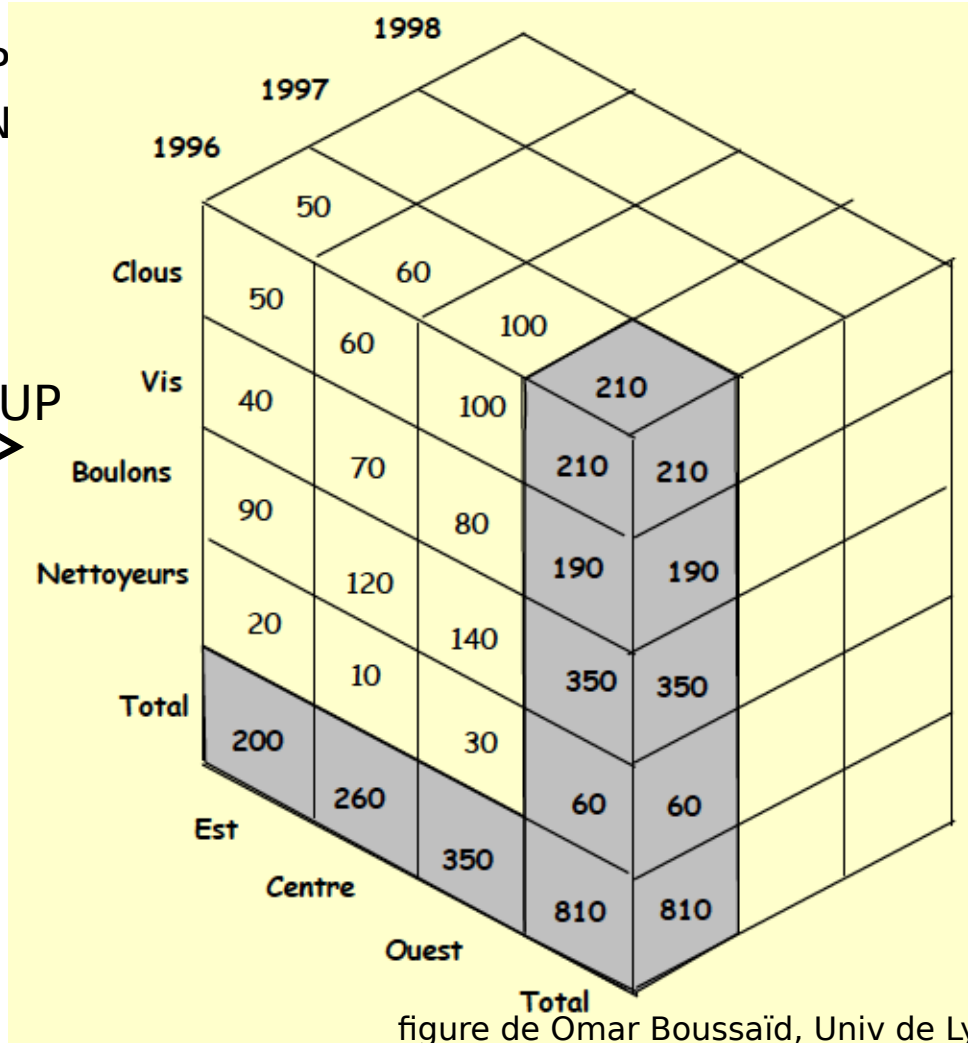

figure de Omar Boussaïd, Univ de Ly

III. Regrouper et interroger les données

① les Entrepôt de Données (noté ED ou *DW*)

- **OLAP On Line Analytical Processing** (vs Transactional Processing in BD)
  - Opérations principales :
    - agrégation de données(ROLL-UP),

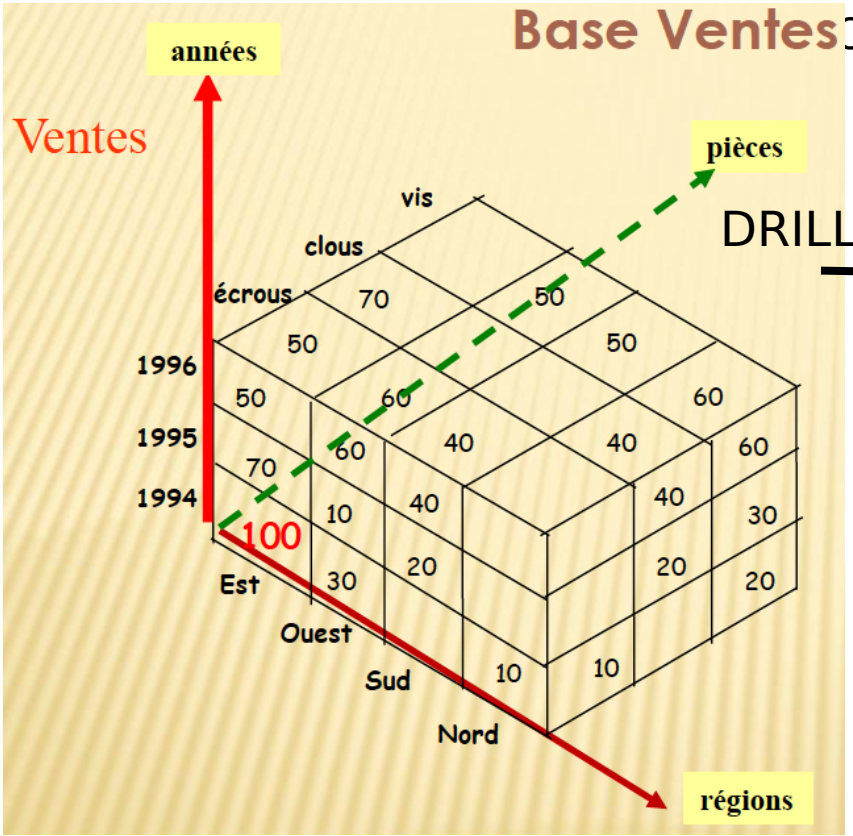

DRILL-DOWN

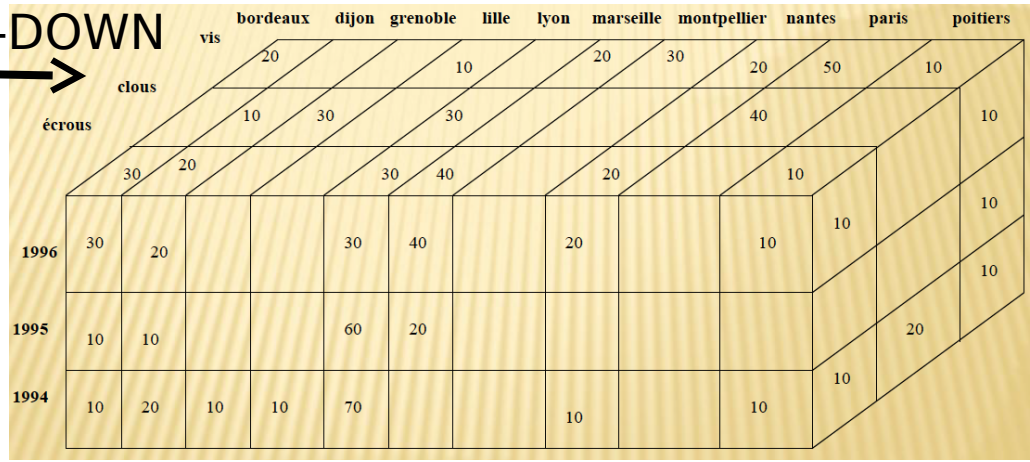

figure de Omar Boussaïd, Univ de Ly

III. Regrouper et interroger les données

① les Entrepôt de Données (noté ED ou *DW*)

- **OLAP On Line Analytical Processing** (vs Transactional Processing in BD)
  - Opérations principales :
    - agrégation de données(ROLL-UP),
    - forage de données (DRILL-DOWN)
    - et sélection, projection, rotation, *s*

    pushing, nesting

Ventes		1996	1995	1997
écrous	Est	50	70	100
	Ouest	60	10	30
	Nord			10
	Sud	40	20	
Vis	Est		10	10
	Ouest	50	50	50
	Nord	60	30	20
	Sud	50	60	60
Clous	Est	70	50	40
	Ouest		10	40
	Nord	40	20	
	Sud		10	

figure de Omar Boussaïd, Univ de Ly

III. Regrouper et interroger les données

② les systèmes médiateurs

- **Similaire** à l'approche entrepôt,
  - mais l'entrepôt n'est pas matérialisé
  - le schéma global est matérialisé
- Récriture de requêtes suivant les mappings – exemple :

Opodo_Flight(*AF84, 14/04/2011, 10h40, 1, 412*)
Opodo_Flight(*AF83, 13/05/2011, 15h35, 1, 412)*

Orbitz_Flight(*AF10,"14/04/2011 – 19h40","regular"*)
Orbitz_Flight(*AF84, "14/04/2011 – 10h40", "regular +vegetarian"*)

Opodo_Vol(num_vol, date_dep, h_dep, repas, places)

Orbitz_Flight(f_num, departure, meal)

Coulet_Flight(f_num,dep_date, dep_time, meal)

III. Regrouper et interroger les données

② les systèmes médiateurs

- **Similaire** à l'approche entrepôt
  - mais l'entrepôt n'est pas matérialisé (phase ETL "*on the fly*")
  - le schéma global est matérialisé
- Récriture de requête et transformation selon les mappings – ex:

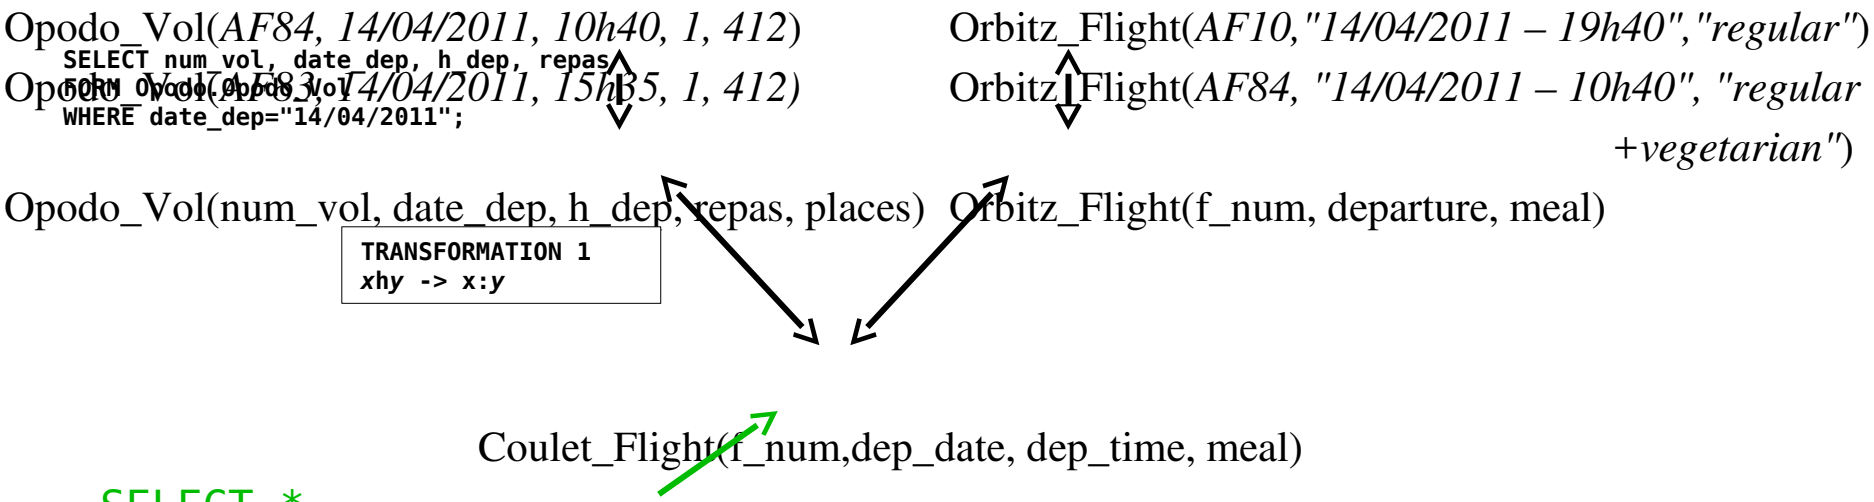


```
SELECT *
FROM Coulet_Flight
WHERE dep_date="14/04/2011";
```

III. Regrouper et interroger les données

② les systèmes médiateurs

- **Similaire** à l'approche entrepôt
  - mais l'entrepôt n'est pas matérialisé (phase ETL "*on the fly*")
  - le schéma global est matérialisé
- Récriture de requête et transformation selon les mappings – ex:

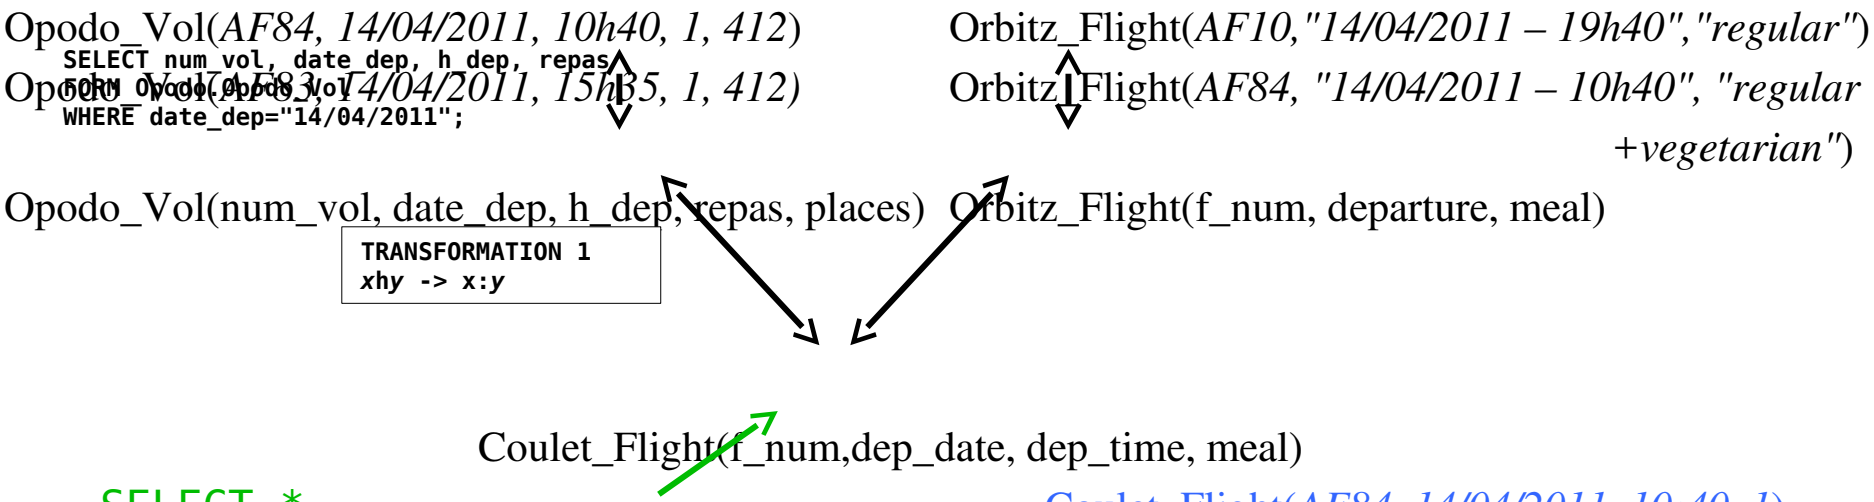


```
SELECT *
FROM Coulet_Flight
WHERE dep_date="14/04/2011";
```

III. Regrouper et interroger les données

② les systèmes médiateurs

- **Similaire** à l'approche entrepôt
  - mais l'entrepôt n'est pas matérialisé (phase ETL "*on the fly*")
  - le schéma global est matérialisé
- Récriture de requête et transformation selon les mappings – ex:

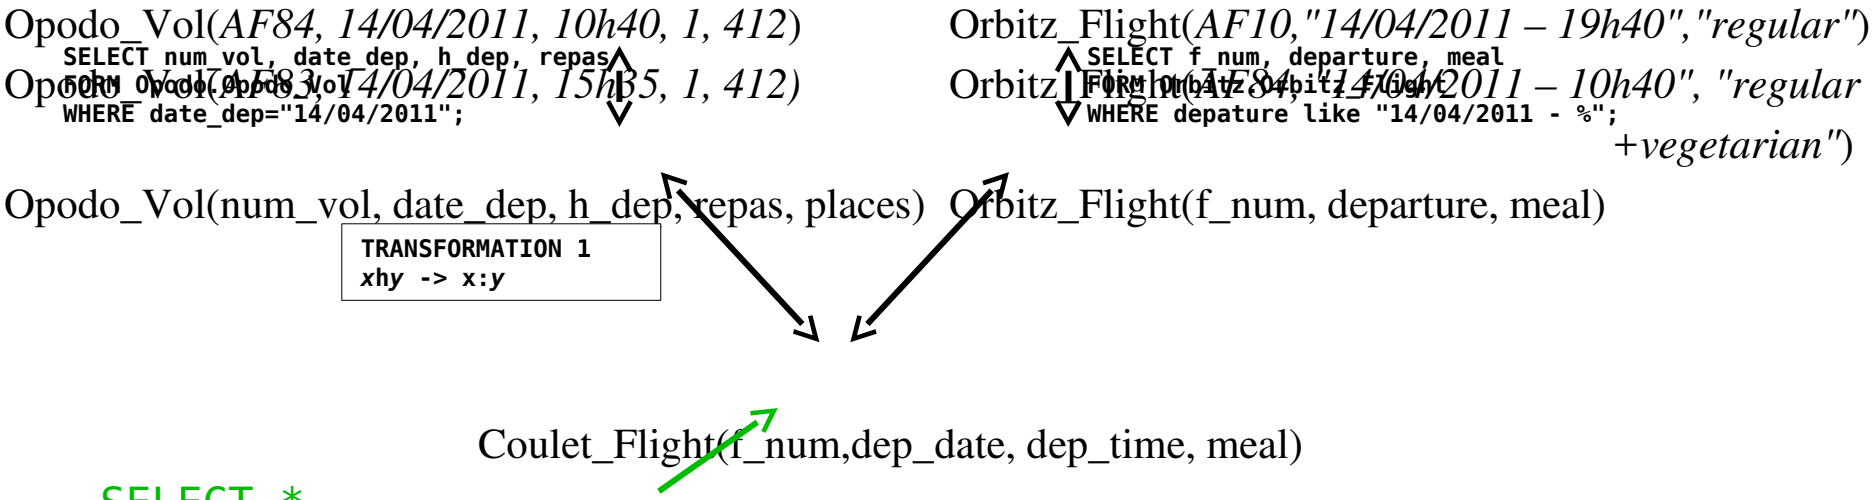


```
SELECT *
FROM Coulet_Flight
WHERE dep_date="14/04/2011";
```

III. Regrouper et interroger les données

② les systèmes médiateurs

- **Similaire** à l'approche entrepôt
  - mais l'entrepôt n'est pas matérialisé (phase ETL "*on the fly*")
  - le schéma global est matérialisé
- Récriture de requête et transformation selon les mappings – ex:

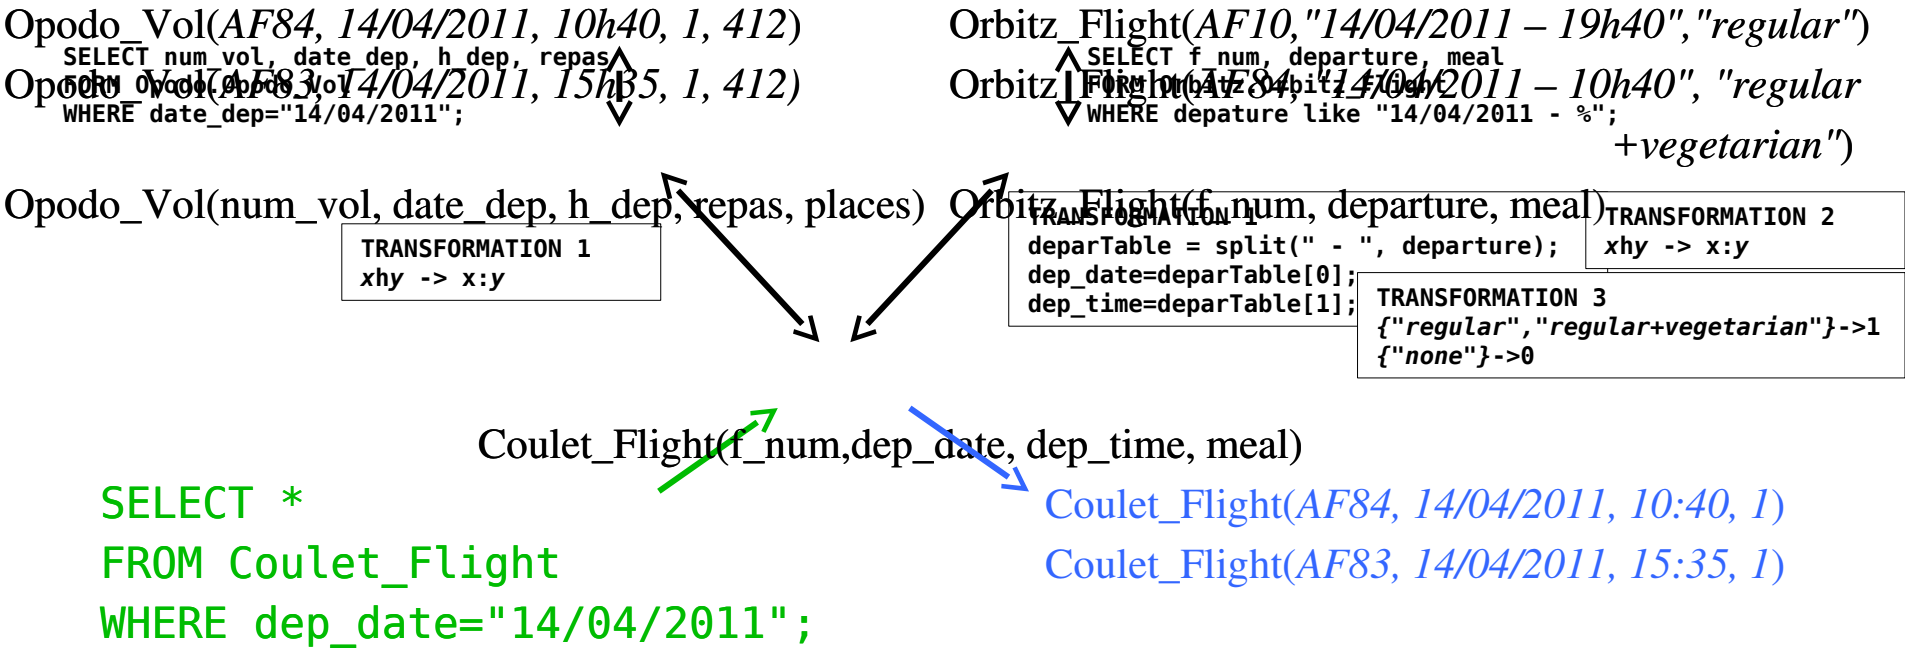

III. Regrouper et interroger les données

② les systèmes médiateurs

- **Similaire** à l'approche entrepôt
  - mais l'entrepôt n'est pas matérialisé (phase ETL "*on the fly*")
  - le schéma global est matérialisé
- Récriture de requête et transformation selon les mappings – ex:

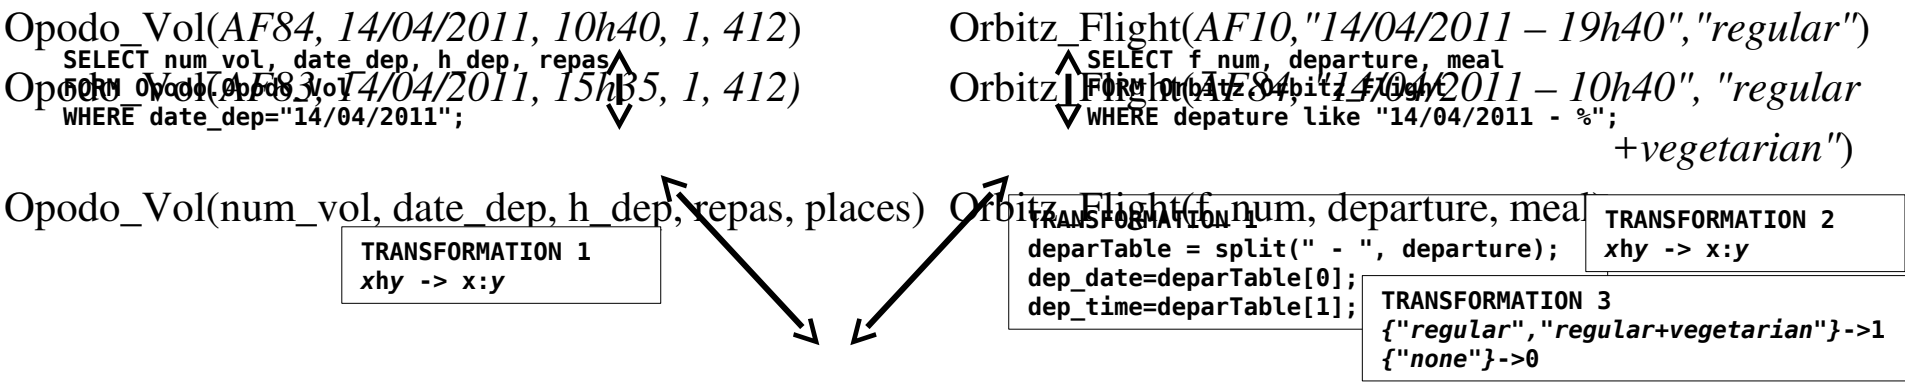


```
SELECT *
FROM Coulet_Flight
WHERE dep_date="14/04/2011";
```

Coulet_Flight(*AF84, 14/04/2011, 10:40, 1*)

Coulet_Flight(*AF83, 14/04/2011, 15:35, 1*)

Coulet_Flight(*AF10, 14/04/2011, 19:40, 1*)

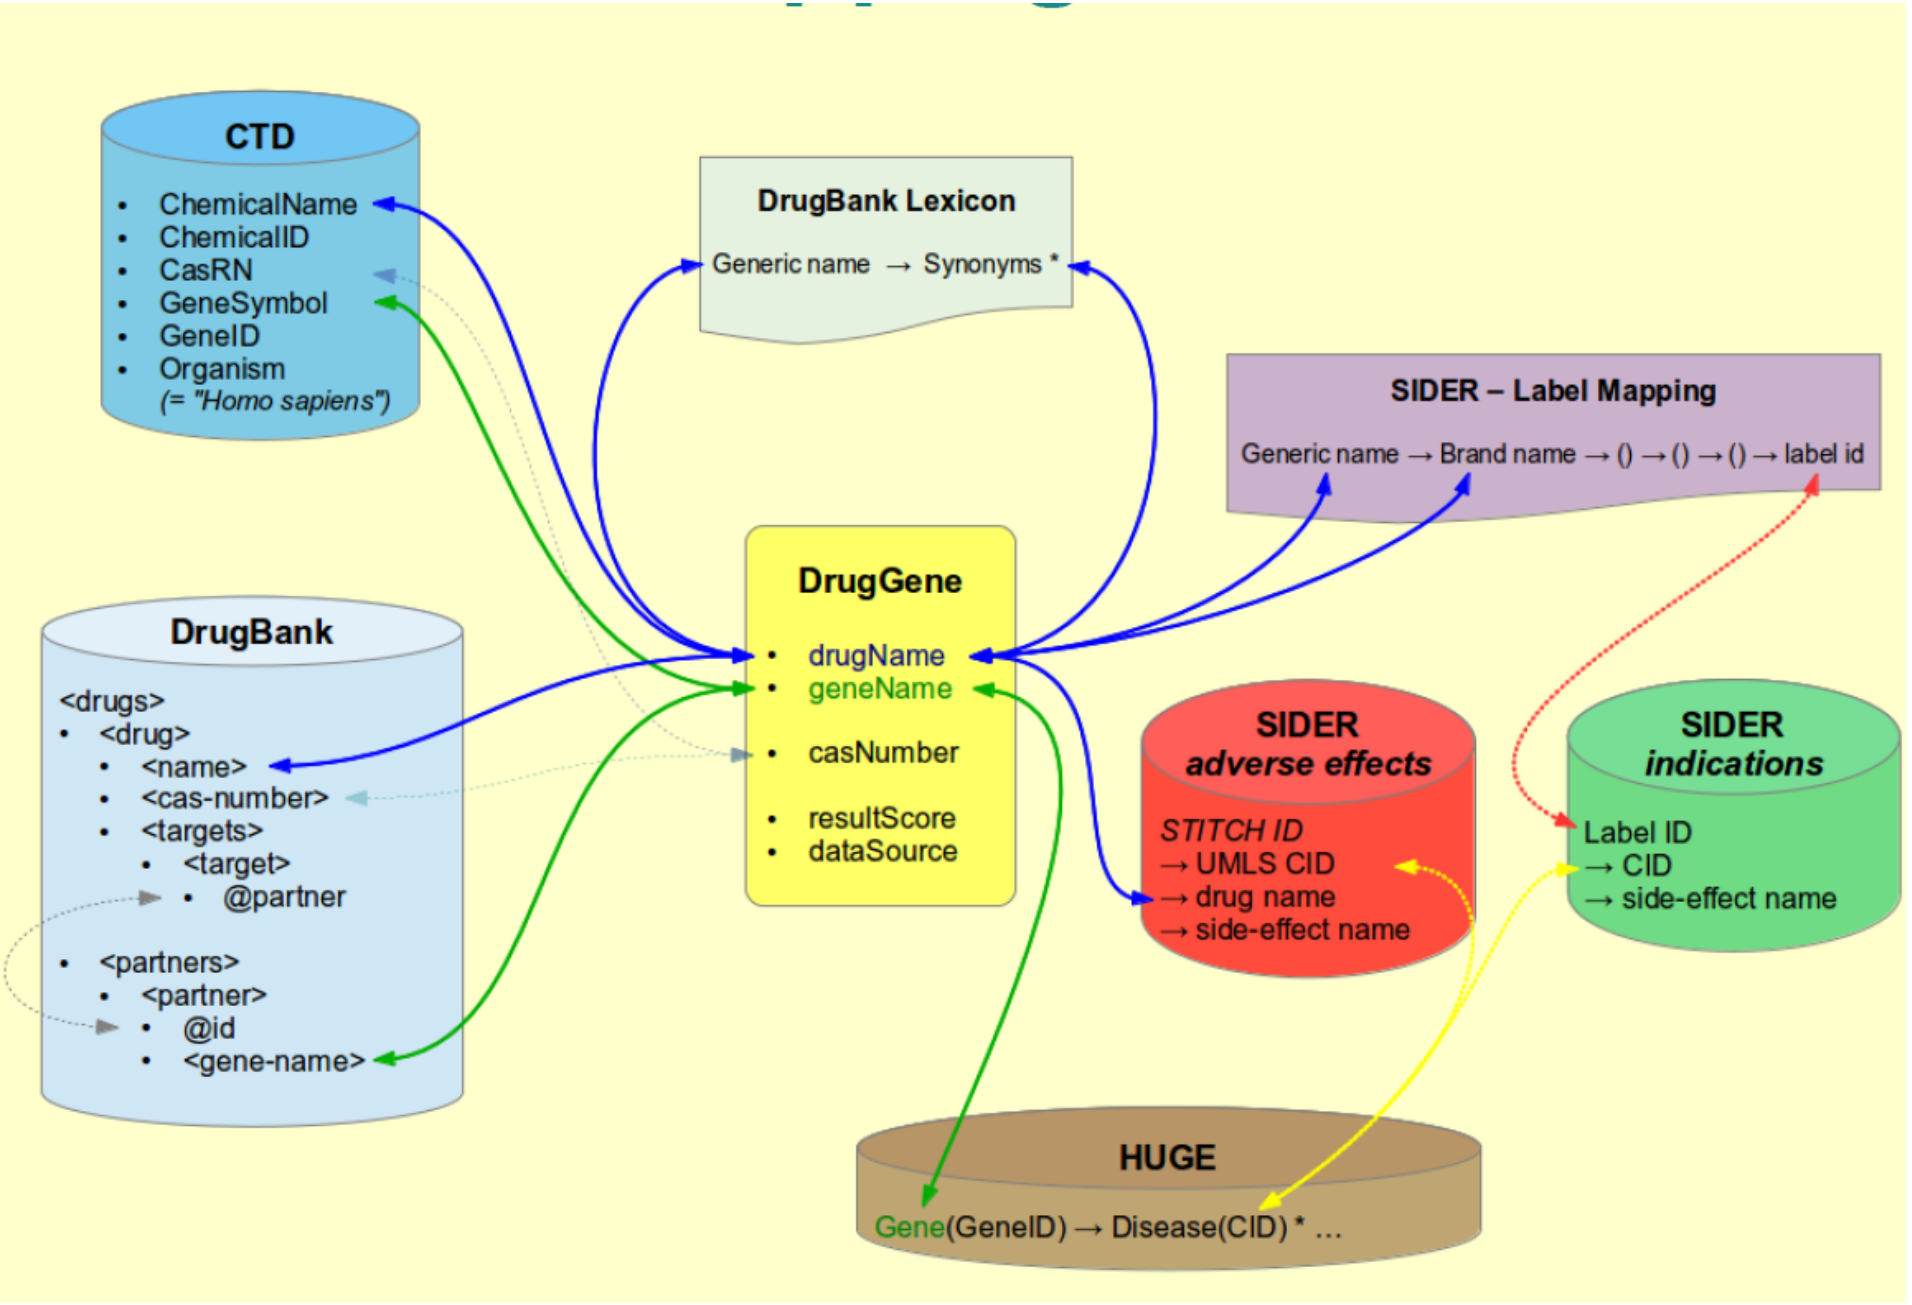

Auteurs : Lucie Vitale et Adrien Siebert

"si on avait trop de ressources, on ne pourrait pas les utiliser efficacement"

FAUX

"on a pas assez de ressources..."
"c'est trop cher a acheter, entretenir, administrer..."

FAUX

"si on avait trop de ressources, on ne pourrait pas les utiliser efficacement"

FAUX

"on a pas assez de ressources..."
"c'est trop cher a acheter, entretenir, administrer..."

FAUX

Le cloud computing c'est facile, pas cher et ça *SCALE* -- ie ça passe à l'échell

VRAI

III. Regrouper et interroger les données

③ le *cloud computing*

la, on ne pourrait pas les utiliser"

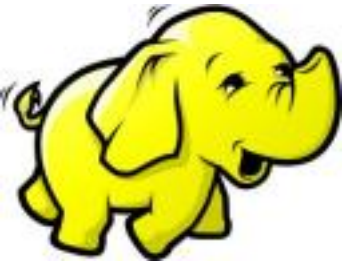

C'est faux : Hadoop (un autre projet Apache)

- MODELE DE DISTRIBUTION = MapReduce
- UNE ARCHI = HDFS : Hadoop Distributed File System
- d'autres

La technologie du 21ème siècle

III. Regrouper et interroger les données

③ le *cloud computing*

- Pourquoi MapReduce/cloud computing ?

  Parce que GMD

  Parce que

  – Google : nouvel index
  – Facebook : statistiques internes
  – Yahoo! : Yahoo! Search
  – Last.fm : statistique hebdo
  – etc.

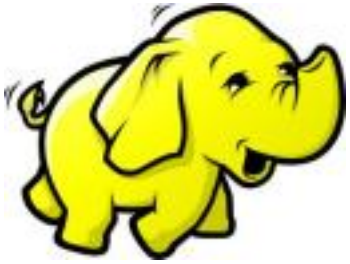

donc Hadoop (processus *MapReduce* et archi *HDFS*)

III. Regrouper et interroger les données

③ le *cloud computing*

a) MapReduce

- **MapReduce est un paradigme de programmation**
- dédié au traitement de gros volume de données
- qui se décompose en 2 étapes
  - Map : étape de traitement des données qui renvoie un résultat sous la forme de paire *{clé, valeur}*
  - Reduce : étape de fusion des résultats unitaires par clé pour former le résultat final
- Algo :
  - Les données en entrée sont découpées en petites unités de données
  - Les unités sont alors traitées en parallèle par la fonction Map
  - Le résultat des traitement unitaires par la fonction Map est trié par clé pour former des unités de résultats passées à la fonction Reduce
  - La fonction Reduce regroupe les différents résultats unitaires pour constituer un résultat final et unique

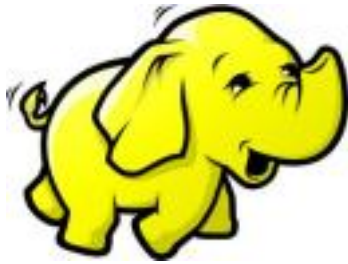

III. Regrouper et interroger les données

③ le *cloud computing*

a) MapReduce

- **MapReduce est un paradigme de programmation**
- dédié au traitement de gros volume de données
- MapReduce se décompose en 2 étapes
  - Map : étape de traitement des données qui renvoie un résultat sous la forme de paire *{clé, valeur}*
  - Reduce : étape de fusion des résultats unitaires par clé pour former le résultat final
- Algo :
  - Les données en entrée sont découpées en petites unités de données
  - Les unités sont alors traitées en parallèle par la fon
  - Le résultat des traitement unitaires par la fonction M trié par clé pour former des unités de résultats pass fonction Reduce
  - La fonction Reduce regroupe les différents résultats unitaires pour constituer un résultat final et unique

On peut boucler sur cet algo, ou l'enchainer avec d'autres MapReduce

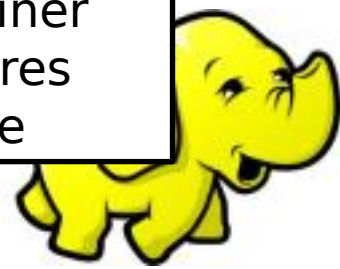

III. Regrouper et interroger les données

- Exemple : compter le nombre de mots dans différents documents, e.g., trois

a) MapReduce

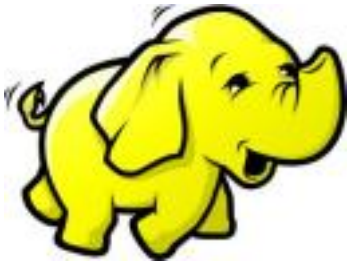

```
1. savoir être et
2. savoir faire
3. sans faire savoir
```

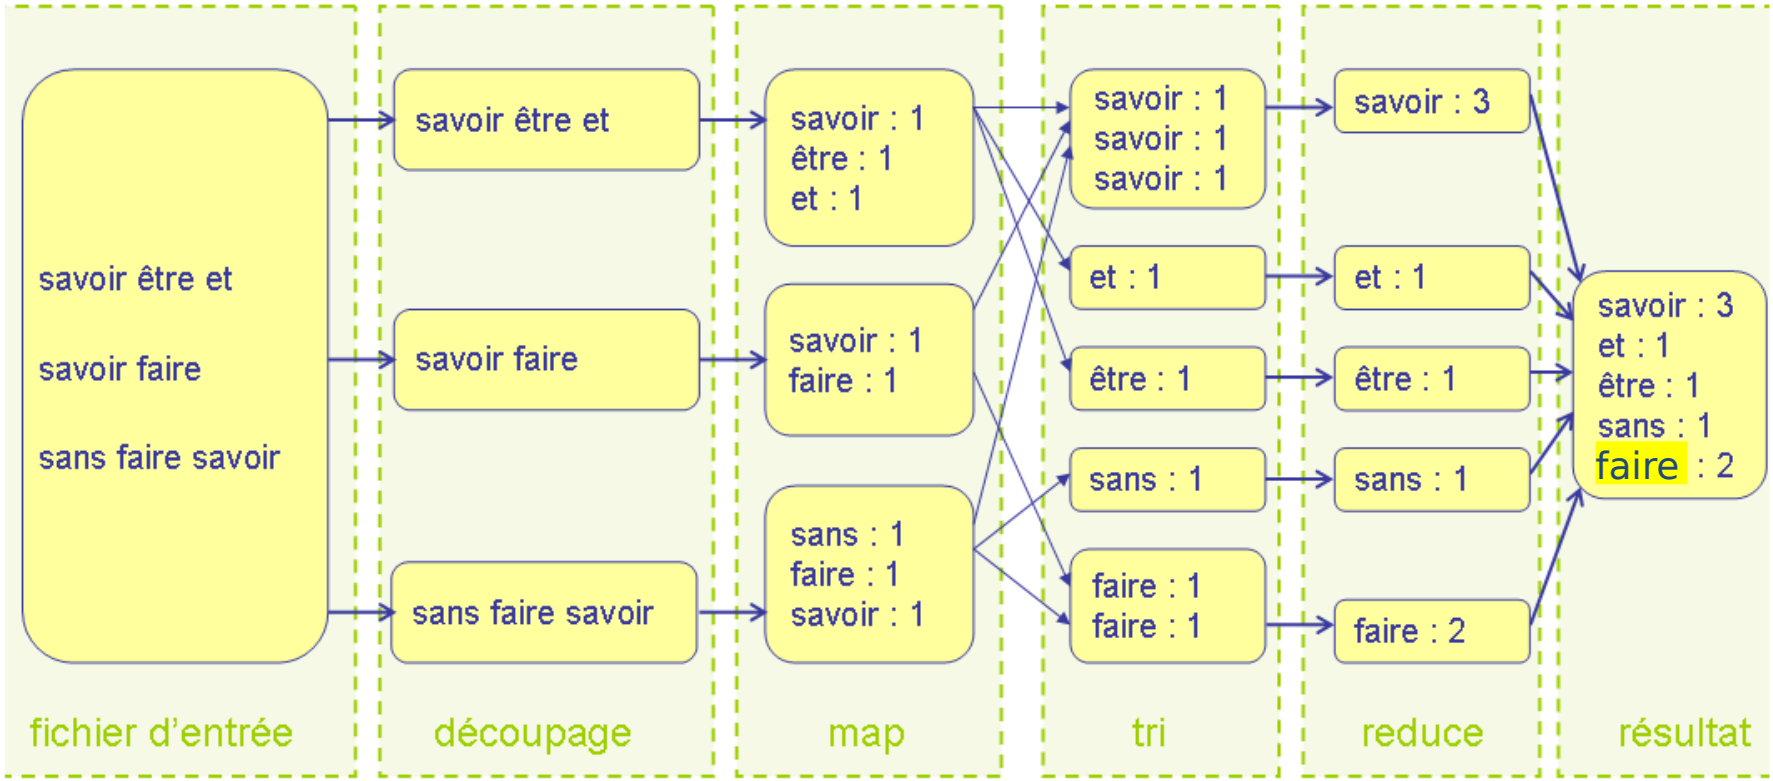

figures Inovia Blog

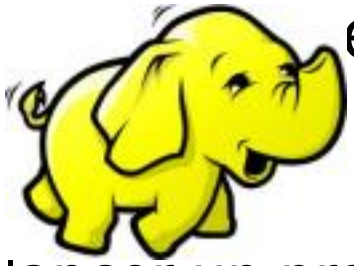

egrouper et interroger les données

③ le *cloud computing*

a) MapReduce

- Pour lancer un process MapReduce avec Hadoop
  - Configuration du job (définie par l'utilisateur)
  - Découpage du jeu de données et distribution sur le cluster (géré par Hadoop)
  - Démarrage de chaque tâche Map avec son propre jeu de données issu du découpage (géré par Hadoop)
  - Exécution en parallèle de chaque fonction Map (implémenté par l'utilisateur)
  - Les sorties des fonctions Map sont triées par clé pour former de nouvelles unités de données (géré par Hadoop)
  - Démarrage des tâches Reduce avec son propre jeu de données issu du tri (géré par Hadoop)
  - Exécution en parallèle de chaque fonction Reduce (implémenté par l'utilisateur)
  - Assemblage du résultat des opérations Reduce et stockage (géré par Hadoop)

III. Regrouper et interroger les données

③ le *cloud computing*

a) HDFS

- Typologie d'un cluster Hadoop : maître - esclaves
  - HDFS : NameNode – DataNode
  - Le contrôle de Job : JobTracker - TaskTracker

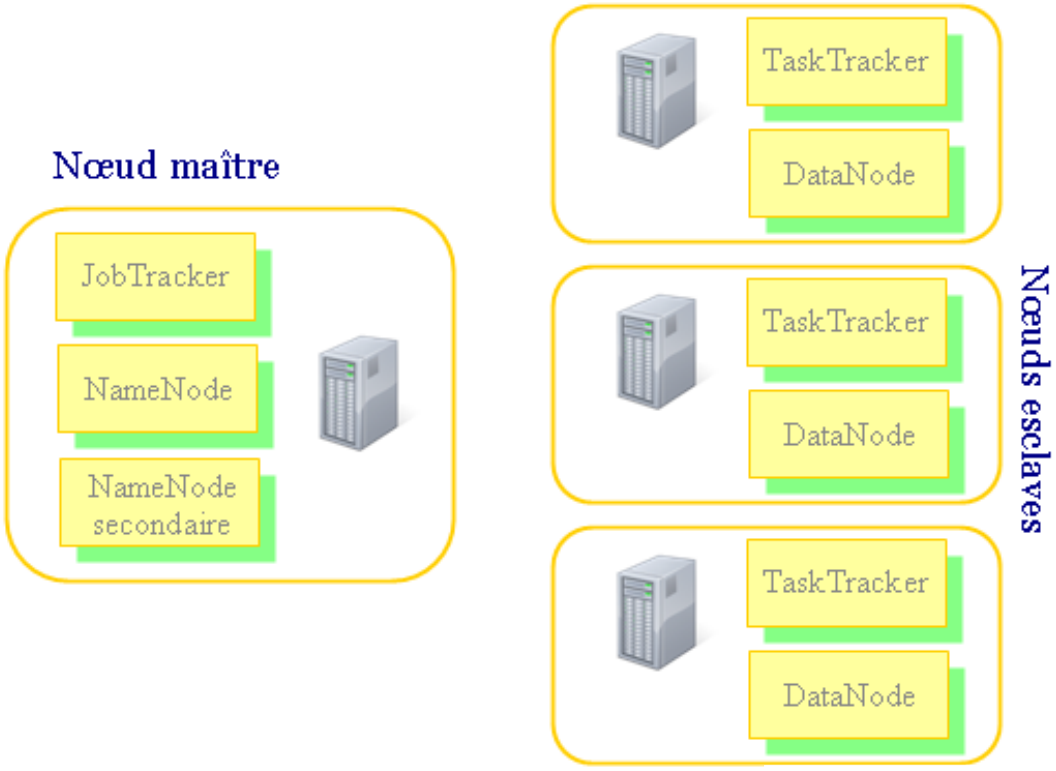

figures Inovia Blog

III. Regrouper et interroger les données

③ le *cloud computing*

a) HDFS

- Typologie d'un cluster Hadoop : maître - esclaves
  - HDFS : NameNode – DataNode
  - Le contrôle de Job : JobTracker - TaskTracker

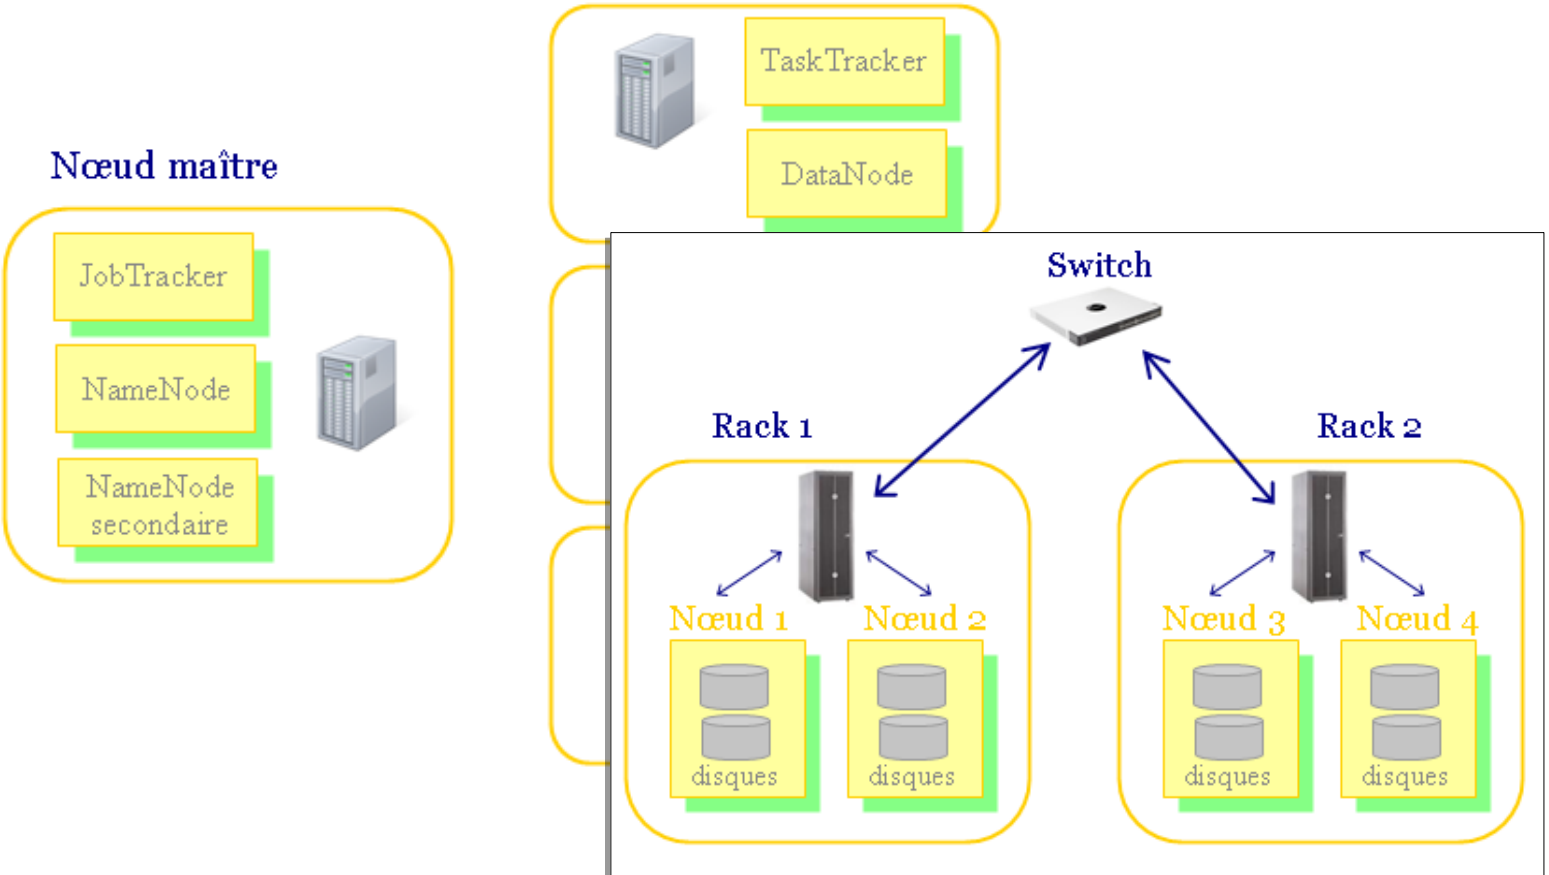

III. Regrouper et interroger les données

③ le *cloud computing*

bla trop cher bla bla"

- C'est faux : Amazon Elastic Compute

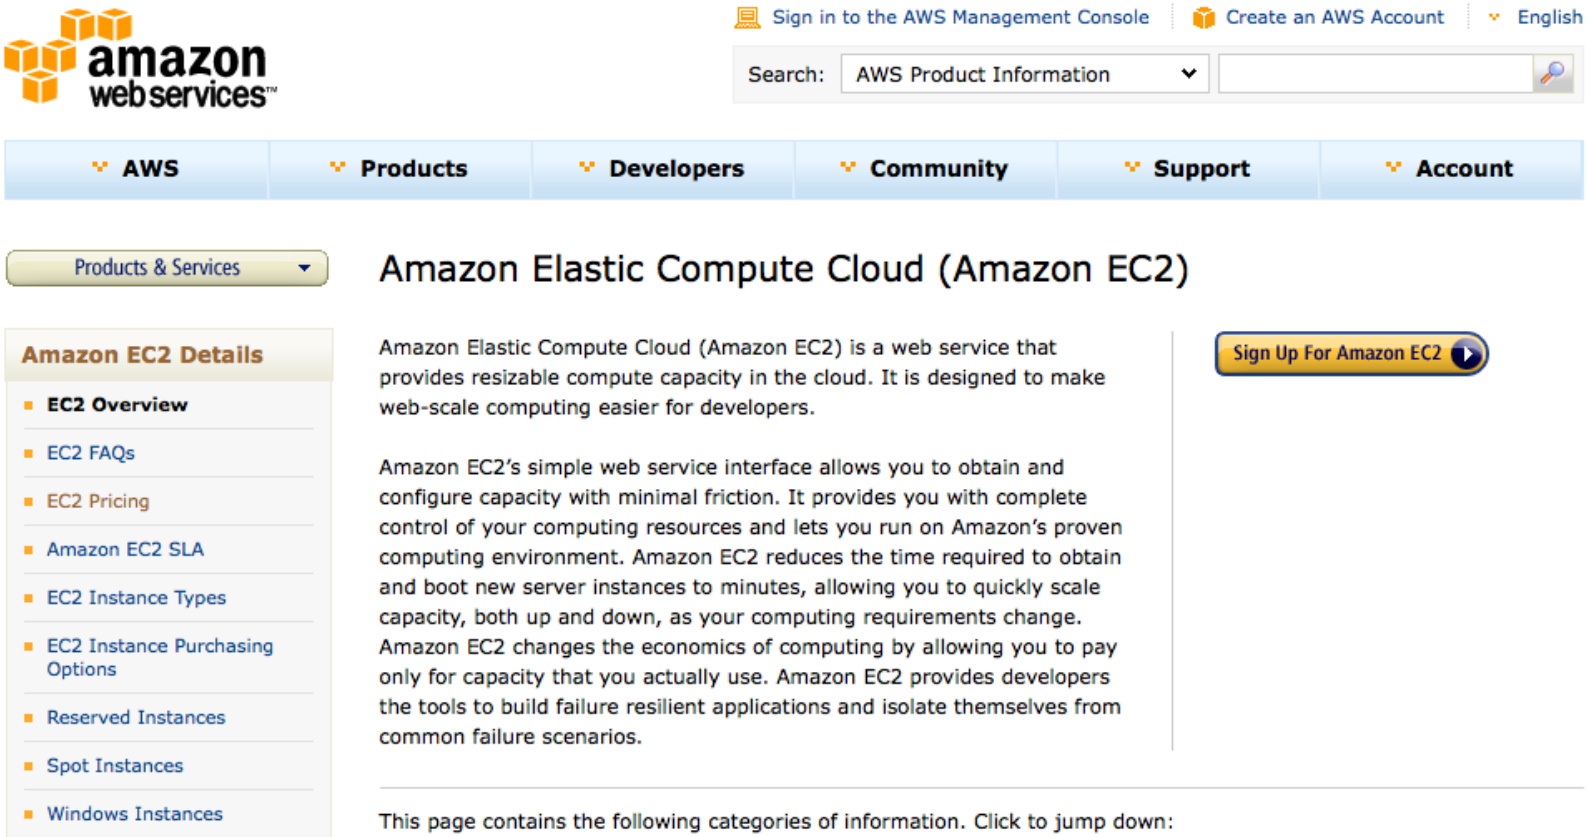

On-Demand Instances

On-Demand Instances let you pay for compute capacity by the hour with no long-term commitments. This frees you from the costs and complexities of planning, purchasing, and maintaining hardware and transforms what are commonly large fixed costs into much smaller variable costs.

The pricing below includes the cost to run private and public AMIs on the specified operating system ("Windows Usage" prices apply to both Windows Server® 2003 and 2008). Amazon also provides you with additional instances for Amazon EC2 running Microsoft, Amazon EC2 running SUSE Linux Enterprise Server and Amazon EC2 running IBM that are priced differently.

Region: EU – Ireland

Standard On-Demand Instances	Linux/UNIX Usage	Windows Usage
Small (Default)	$0.095 per hour	$0.12 per hour
Large	$0.38 per hour	$0.48 per hour
Extra Large	$0.76 per hour	$0.96 per hour
Micro On-Demand Instances		
Micro	$0.025 per hour	$0.035 per hour
High-Memory On-Demand Instances		
Extra Large	$0.57 per hour	$0.62 per hour
Double Extra Large	$1.14 per hour	$1.24 per hour
Quadruple Extra Large	$2.28 per hour	$2.48 per hour
High-CPU On-Demand Instances		
Medium	$0.19 per hour	$0.29 per hour
Extra Large	$0.76 per hour	$1.16 per hour
Cluster Compute Instances		
Quadruple Extra Large	N/A*	N/A*
Cluster GPU Instances		
Quadruple Extra Large	N/A*	N/A*

* Cluster Compute and Cluster GPU Instances are currently only available in the US – N. Virginia Region.

Amazon Elastic Block Store

Region: EU – Ireland

Amazon EBS Volumes

- $0.11 per GB-month of provisioned storage
- $0.11 per 1 million I/O requests

Amazon EBS Snapshots to Amazon S3

- $0.15 per GB-month of data stored
- $0.01 per 1,000 PUT requests (when saving a snapshot)
- $0.01 per 10,000 GET requests (when loading a snapshot)

et il n'y a pas que Amazon : Microsoft Azure, Google App Engine, etc.