

BASES DE DONNÉES DISTRIBUÉES

<http://www.larbiquezouli.com/>

Présenté par Dr Larbi GUEZOULI

SOMMAIRE

- Chapitre I: Introduction [1 cours]
- Chapitre II: Structure de bases de données distribuées [7 cours]
 1. Introduction
 2. Fragmentation
 3. Allocation de ressources
- Chapitre III: Intégration de bases de données [7 cours]
 1. Méthodologie de la conception Bottom-Up
 2. Correspondance de schémas
 3. Intégration de schémas
 4. Planification de schémas
- Chapitre IV: Contrôle d'accès et de données [7 cours]
 1. Gestion de vues
 2. Sécurité de données
 3. Contrôle d'intégrité sémantique
- Chapitre V: Aperçu sur le traitement de requête [7 cours]
 1. Problème de traitement de requête
 2. Objectif du traitement de requête
 3. Couches de traitement de requête
- Chapitre VI: Décomposition de la requête et localisation de données [7 cours]
- Chapitre VII: Optimisation des requêtes distribuées [7 cours]

2


BIBLIOGRAPHIE

1. M. Tamer Özsu and Patrick Valduriez, "Principles of Distributed Database Systems", Third Edition, Springer, 2011
2. IBM, "Distributed database programming", Version 6 Release 1, 2008.
3. Georges Gardarin, « Bases de données réparties », Cours BDD Web.

3

CHAPITRE I INTRODUCTION

Une entreprise, selon son besoin, peut choisir entre l'utilisation de base de données centralisée ou distribuée.



4

CHAPITRE I

INTRODUCTION

Quelques définitions

Une base de données **distribuée** est un ensemble de bases de données localisées et gérées par des **sites différents** et apparaissant à l'utilisateur comme une base **unique**. [3]

Une base de données **distribuée** est une collection de multiple bases de données **distribuées** sur un réseau informatique **logiquement inter-reliées**.

Un **client** d'un système de gestion de base de données distribuée est une **application** qui accède aux informations distribuées par les interfaces du système. [3]

5

CHAPITRE I

INTRODUCTION

Quelques définitions (suite)

Un système de gestion de base de données **distribuées** est un système qui gère des collections de BD **logiquement reliées, distribuées** sur un réseau, en fournissant un mécanisme d'accès qui rend la répartition **transparente** aux utilisateurs. [3]

Un système de gestion de bases de données **distribuées (Distributed DBMS)** est l'application qui permet la gestion de la base de données distribuée et rend la distribution transparente aux utilisateurs.

Pour référencer la BDD distribuée et le DBMS distribués nous utilisons l'abréviation **DDBS (Distributed DataBase System)**.

6

CHAPITRE I

INTRODUCTION

Exp.

Soit une entreprise qui a des annexes dans plusieurs villes: Alger, Batna, Oran. Le gérant veut maintenir une base de données des employés et les projets sur lesquels ils travaillent.

Le gérant utilise 4 tables:

```
Emp (idEmp, nomEmp, poste);
```

```
Prj (idPrj, nomPrj, designation, budget, ville);
```

```
Sal (poste, salaire);
```

```
Aff (idEmp, idPrj, resp, dur) //Affectation d'un  
employé à un projet avec telle responsabilité et telle durée.
```

7

CHAPITRE I

INTRODUCTION

Exp. (suite)

Si la base de données est centralisée, on peut trouver les noms des employés qui travaillent dans un projet pour une durée supérieure de 12 mois ainsi que leurs salaires avec la requête suivante:

```
SELECT nomEmp, salaire
```

```
FROM Emp, Aff, Sal
```

```
WHERE Aff.dur > 12
```

```
AND Emp.idEmp = Aff.idEmp
```

```
AND Sal.poste = Emp.poste
```

8

CHAPITRE I

INTRODUCTION

Exp. (suite)

Maintenant, si la base est **distribuée** sur les différents annexes, de telle sorte que les informations des employés et les projets de chaque annexe sont stockés dans une base de données localisée dans cette annexe.

L'utilisateur doit **posé la même question** au système sans faire attention à la distribution des informations (**transparence**), et c'est le système qui s'occupe de la récupération des informations.

Pour cela, il a été défini plusieurs types de transparence:

9

CHAPITRE I

INTRODUCTION

1/ Transparence de données (Indépendance)

La définition des données dans une base de données se fait à deux niveaux (structure logique et structure physique), ce qui permet de définir une **indépendance de données logique** et **indépendance de données physique**.

10

CHAPITRE I

INTRODUCTION

1/ Transparence de données (suite)

L'**indépendance de données logique** signifie que les applications de l'utilisateur ne sont **pas autorisées** à modifier la structure logique des données (le schéma).

L'**indépendance de données physique** signifie que les détails de la structure de stockage des données seront **cachés** aux applications de l'utilisateur.

Remarque: L'application utilisateur ne doit pas être modifiée quand la structure physique des données change.

11

CHAPITRE I

INTRODUCTION

2/ Transparence du réseau (ou de distribution)

Ce type de transparence fait référence à ce que l'**existence du réseau** est **caché** à l'utilisateur. L'accès aux données de la base doit se faire de la même manière soit en mode centralisé ou distribué.

12

CHAPITRE I

INTRODUCTION

3/ Transparence de réplication (redondance)

Pour des raisons de performance et disponibilité des données, il est préférable de faire des **copies** de quelques données de la base sur plusieurs sites.

Par exemple, les données qui se trouvent sur un autre site et qui sont réclamées souvent par un utilisateur, sera préférable d'en faire une copie sur la base de données local de cet utilisateur.

En plus, si une **machine s'arrête**, on peut trouver les données sur une autre machine.

13

CHAPITRE I

INTRODUCTION

3/ Transparence de réplication (redondance)

La décision de réplication des données, et de combien de copies doit-on faire, dépend des applications des utilisateurs.

L'utilisateur **n'a pas besoin de savoir** si les données sont répliquées ou non. Il envoie ses requêtes comme s'il existe une seule copie des données.

14

CHAPITRE I

INTRODUCTION

3/ Transparence de fragmentation

Dans certains cas, et pour des raisons de performance, on aura besoin de **fragmenter** une table de la base de données et placer chaque fragment sur un site différent.

La fragmentation permet aussi de réduire les **inconvénients** de la **réplication**.

Cette opération de fragmentation doit être faite d'une manière **transparente** à l'utilisateur. Il utilise la table originale comme si elle n'est pas fragmentée.

15

CHAPITRE I

INTRODUCTION

3/ Transparence de fragmentation (suite)

Il existe deux types de fragmentation:

- **Fragmentation horizontale:** La table est partitionnée en plusieurs sous-tables contenant chacune un sous-ensemble de lignes de la table originale.
- **Fragmentation verticale:** La table est partitionnée en plusieurs sous-tables qui sont définies sur un sous-ensemble d'attributs (de colonnes) de la table originale.

16

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

- I. Introduction
- II. Fragmentation
- III. Allocation de ressources

17

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

I. Introduction

L'organisation des systèmes distribués tourne autour de trois axes:

- Niveau de partage:
 - Pas de partage;
 - Partage de données;
 - Partage de données et des applications.
- Type d'accès:
 - Accès statique (localisation des données connue dès le début);
 - Accès dynamique (localisation des données inconnue).

18

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

I. Introduction (suite)

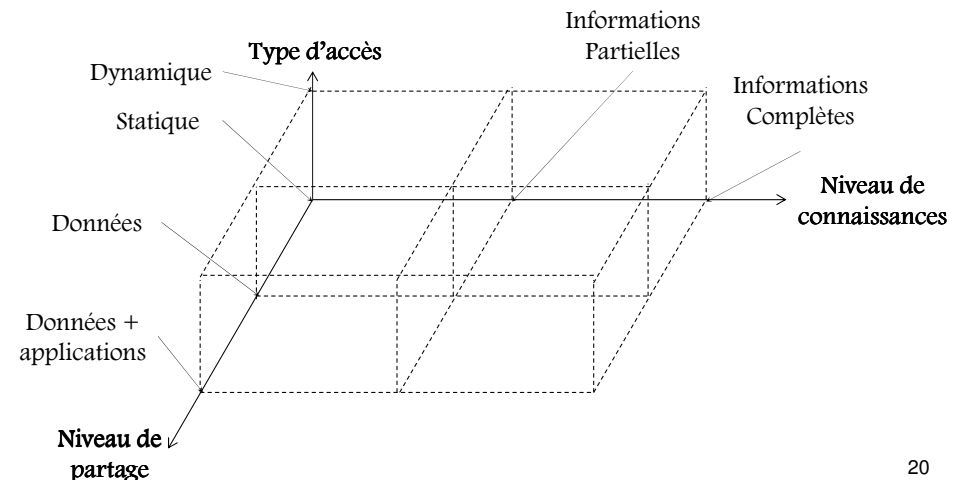
- Niveau de connaissances sur le comportement (type) d'accès:
 - Pas de connaissance préalable sur le type d'accès (le design ou la conception de la base est très difficile);
 - Information partielles sur le type d'accès;
 - Information complètes sur le type d'accès (Le cas le plus pratique).

19

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

I. Introduction (suite)



20

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

I. Introduction (suite)

Avec cette organisation, et comme indiqué dans le chapitre précédent concernant la distribution des relations de la base, au lieu de distribuer les relations d'une même base sur plusieurs sites, il est préférable de **distribuer** des **fragments** d'une même relation sur plusieurs sites.

Ainsi, ce processus est divisé en deux parties: **fragmentation** et **allocation**.

21

CHAPITRE II


STRUCTURE DE BDD DISTRIBUÉES

II. Fragmentation

Le processus de fragmentation peut se faire sous différentes stratégies: horizontale, verticale ou hybride.

II.1. Fragmentation horizontale

Ce type de fragmentation permet de découper une relation en sous-relations contenant des sous-ensembles des tuples de la relation mère.



22

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1. Fragmentation horizontale (suite)

La fragmentation horizontale est basée sur l'opération de **sélection** qui utilise un **prédicat** (condition).

La **reconstitution** de la relation se fait par l'**union** des fragments.

Nous avons besoin de définir deux notions: **prédicat simple**, **prédicat minterm**.

23

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1. Fragmentation horizontale (suite)

Prédicat simple

Soit une relation $R(A_1, A_2, \dots, A_n)$, tel que A_i est un attribut de R défini sur un domaine D_i . Un prédicat simple p_j est défini sur R comme suit:

$$p_j: A_i \theta val$$

tel que $\theta \in \{=, <, >, \neq, \leq, \geq\}$ et $val \in D_i$

On note P_r l'ensemble de tous les prédicats simples définis sur R .

24

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1. Fragmentation horizontale (suite)

Exp.

Soit la relation Pr_j de l'exemple précédent, on peut définir quelques prédicats simples:

```
nomPrj = "Construction"
budget ≤ 100000
```

25

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1. Fragmentation horizontale (suite)

Prédicat minterm

Un prédicat minterm m est défini par une **conjonction** de prédicats simples.

Une conjonction est une expression booléenne contenant des prédicats simples séparés par des AND. On peut utiliser aussi le NOT.

$$m = \bigwedge_{p_j \in P_r} p_j^*$$

tel que: $p_j^* = p_j$ ou $p_j^* = \neg p_j$

26

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1. Fragmentation horizontale (suite)

Exp. Soit les minterms suivants:

```
m1 : poste = "Ing" ∧ salaire ≤ 50000
m2 : poste = "Ing" ∧ salaire > 50000
m3 : ¬(poste = "Ing") ∧ salaire ≤ 50000
m4 : ¬(poste = "Ing") ∧ salaire > 50000
m5 : poste = "Comptable" ∧ salaire ≤ 50000
m6 : poste = "Comptable" ∧ salaire > 30000
```

27

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1. Fragmentation horizontale (suite)

Il existe deux types de fragmentation horizontale: primaire et dérivée.

II.1.1. Fragmentation horizontale primaire

La fragmentation horizontale est basée sur l'opération de sélection qui utilise un prédicat minterm.

$$R_i = \sigma_{m_i}(R)$$

tel que:

R_i est un fragment de la relation R

m_i est un minterm

σ est l'opération de sélection.

28

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1.1. Fragmentation horizontale primaire (suite)

Exp. 1

Fragmentation de la relation Prj en fragmentation horizontale peut être faite comme suit:

$$Prj_1 = \sigma_{budget \leq 100000} (Prj)$$

$$Prj_2 = \sigma_{budget > 100000} (Prj)$$

Cet exemple présente un des **problèmes** de la fragmentation horizontale. Si le domaine des attributs est **continu** et **infini** il sera difficile de définir le nombre **maximal** de fragmentations **possibles**. On ne peut pas partager le domaine en un nombre fini de sous-domaines.

29

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1.1. Fragmentation horizontale primaire (suite)

Exp. 2

On peut fragmenter la relation Prj en se basant sur la localisation:

$$Prj_1 = \sigma_{ville="Alger"} (Prj)$$

$$Prj_2 = \sigma_{ville="Batna"} (Prj)$$

$$Prj_3 = \sigma_{ville="Oran"} (Prj)$$

Dans ce cas, le nombre **maximal** de fragmentations **possibles** est fixe.

30

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1.1. Fragmentation horizontale primaire (suite)

Pour éviter les problèmes de fragmentation horizontale, nous avons besoin de **bien choisir** les prédicats simples qui seront à la base des prédicats minterm permettant de fragmenter une relation.

D'une manière générale, cet ensemble doit **contenir seulement** les prédicats avec des **attributs** et **conditions** utilisés par les **applications**.

Cet ensemble de prédicats simples doit être **complet** et **minimal**. Pour cela, nous avons besoin de définir deux aspects importants: **complétude**, **minimalité**.

31

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1.1. Fragmentation horizontale primaire (suite)

Complétude

Un ensemble de prédicats simples P_r est dit **complet** ssi la **probabilité d'accès** par chaque application à n'importe quel tuple de n'importe quel (de chaque) fragment-minterm est égale.

Autrement dit:

La **complétude** garantit que les **tuples** de chaque fragment-minterm soient **accédés** par **toutes les applications** avec la **même probabilité**.

32

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1.1. Fragmentation horizontale primaire (suite)

Exp.

Soit l'ensemble $P_r = \{\text{ville}=\text{"Alger"}, \text{ville}=\text{"Batna"}, \text{ville}=\text{"Oran"}\}$ permettant de fragmenter la relation Prj en $\text{Prj}_1, \text{Prj}_2, \text{Prj}_3$ comme dans l'exemple précédent.

S'il y a une seule application qui cherche à accéder aux tuples des fragments selon leurs locations, l'ensemble P_r est complet.

33

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1.1. Fragmentation horizontale primaire (suite)

Complétude (suite)

Exp. (suite)

Par contre, s'il y a une 2^{ème} application qui cherche à accéder aux projets qui ont un budget inférieur à 100000, dans ce cas, P_r n'est **plus complet**.

Cause: Les tuples des fragments qui ont un budget < 100000 ont une probabilité d'accès supérieur aux tuples qui ont un budget > 100000.

34

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1.1. Fragmentation horizontale primaire (suite)

Complétude (suite)

Exp. (suite)

Solution: Pour rendre l'ensemble P_r complet, nous devons ajouter le prédicat ($\text{budget} < 100000$) et sa négation ($\text{budget} \geq 100000$) comme suit:

$P_r = \{\text{ville}=\text{"Alger"}, \text{ville}=\text{"Batna"}, \text{ville}=\text{"Oran"}, \text{budget} < 100000, \text{budget} \geq 100000\}$

35

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1.1. Fragmentation horizontale primaire (suite)

Solution: (suite)

Les minterms à utiliser dans la fragmentation sont:

m1: $\text{ville} = \text{"Alger"} \wedge \text{budget} < 100000$

m2: $\text{ville} = \text{"Batna"} \wedge \text{budget} < 100000$

m3: $\text{ville} = \text{"Oran"} \wedge \text{budget} < 100000$

m4: $\text{ville} = \text{"Alger"} \wedge \text{budget} \geq 100000$

m5: $\text{ville} = \text{"Batna"} \wedge \text{budget} \geq 100000$

m6: $\text{ville} = \text{"Oran"} \wedge \text{budget} \geq 100000$

Les deux applications accèdent aux tuples de chaque fragment-minterm avec une probabilité égale (0 ou $1/\text{nb_tuples_fragment}$)

36

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1.1. Fragmentation horizontale primaire (suite)

Minimalité

- Définition 1 -

Un ensemble de prédicats simples est dit **minimal** si tous les prédicats sont **pertinents**.

Un prédicat est dit **pertinent** s'il cause la fragmentation d'un fragment F en F_1 et F_2 et qu'il **existe au-moins** une application qui accède aux deux fragments **différemment** (individuellement) (c-à-d F_1 et F_2 sont disjoints).

37

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1.1. Fragmentation horizontale primaire (suite)

Minimalité

Autrement dit:

- Définition 2 -

La **minimalité** d'un ensemble de prédicats exprime que si un prédicat dans cet ensemble permet de partitionner un fragment F en deux fragments F_1 et F_2 , alors il existe au-moins une application accède à F_1 et F_2 individuellement. Cela veut dire que le prédicat est pertinent dans la détermination de F_1 et F_2 .

38

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1.1. Fragmentation horizontale primaire (suite)

Minimalité

Autrement dit:

- Définition 3 -

Le but de la **minimalité** est d'assurer qu'il y a une cause pour effectuer la fragmentation (F_1, F_2) par un prédicats.

Il existe au-moins une application qui n'a besoin que d'un seul fragment (parmi les deux F_1 et F_2) à un moment donné.

39

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1.1. Fragmentation horizontale primaire (suite)

Exp.

Dans l'exemple précédent, l'ensemble de prédicats $P_r = \{\text{ville}=\text{"Alger"}, \text{ville}=\text{"Batna"}, \text{ville}=\text{"Oran"}, \text{budget}<100000, \text{budget}\geq 100000\}$ est aussi minimal parce que tous les prédicats sont pertinents.

40

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1.1. Fragmentation horizontale primaire (suite)

Exp.

Soit la relation $\text{Aff}(\text{idEmp}, \text{idPrj}, \text{resp}, \text{dur})$ et soit une application qui s'intéresse aux tuples du projet n°5. L'ensemble $P_r = \{\text{idPrj}=5, \text{idPrj} \neq 5\}$ est minimal parce que le prédicat à l'intérieur est pertinent.

S'il existe une 2^{ème} application qui s'intéresse aux tuples dont la durée > 12 , dans ce cas, l'application accède aux tuples des 2 fragments en même temps, donc P_r n'est pas minimal.

41

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1.1. Fragmentation horizontale primaire (suite)

Remarque:

La meilleure fragmentation est celle qui utilise un ensemble de prédicats simples P_r complet et minimal.

42

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1.2. Fragmentation horizontale dérivée

La fragmentation horizontale dérivée d'une relation (R) est basée sur des fragments horizontaux d'une autre relation (S) à condition qu'il y est un lien entre R et S.

Les nouveaux fragments sont définis par semi-jointure.

Définition

La **semi-jointure** entre deux relations R et S ($R \bowtie S$) permet de garder les tuples de R qui ont relation avec des tuples de S.

43

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1.2. Fragmentation horizontale dérivée (suite)

Exp.

Dans l'exemple précédent, nous voulons grouper les employés de la relation $\text{Emp}(\text{idEmp}, \text{nomEmp}, \text{poste})$ en 2 groupes selon leurs salaires. Un groupe pour ceux qui ont un salaire inférieur à 30000, et les autres dans le deuxième groupe.

On fragmente la relation $\text{Sal}(\text{poste}, \text{salaire})$ en deux fragments:

$\text{Sal1} = \sigma_{\text{salaire} < 30000}(\text{Sal})$

$\text{Sal2} = \sigma_{\text{salaire} \geq 30000}(\text{Sal})$

44

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.1.2. Fragmentation horizontale dérivée (suite)

Exp. (suite)

Les deux fragments contenant les deux groupes de salariés sont définis par semi-jointure sur la colonne 'poste' comme suit:

$$\text{Emp1} = \text{Emp} \bowtie \text{Sal1}$$

$$\text{Emp2} = \text{Emp} \bowtie \text{Sal2}$$


45

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.2. Fragmentation verticale

La fragmentation verticale permet de découper une relation R en plusieurs relations. Chaque fragment contient un sous-ensemble d'attributs ainsi que la clé primaire de R.



46

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.2. Fragmentation verticale (suite)

Exp.

Soient deux applications qui utilisent la relation $\text{Emp}(\text{idEmp}, \text{nomEmp}, \text{poste})$. La première utilise les noms des employés, et l'autre utilise les postes des employés.

On cherche à fragmenter la relation pour que chaque application accède seulement au fragment qui l'intéresse.

Pour cela, on utilise la projection:

$$\text{Emp1} = \pi_{[\text{idEmp}, \text{nomEmp}]}(\text{Emp})$$

$$\text{Emp2} = \pi_{[\text{idEmp}, \text{poste}]}(\text{Emp})$$

47

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.2. Fragmentation verticale (suite)

Exp. (suite)

La reconstruction de la relation d'origine se fait par la jointure:

$$\text{Emp} = \text{Emp1} \bowtie \text{Emp2}$$

48

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.3. Fragmentation hybride

La fragmentation hybride est une combinaison des deux fragmentations précédentes.

Exp.

Soient trois applications qui utilisent les relations

$Emp(idEmp, nomEmp, poste)$ et

$Personne(id, dateNaiss, adr, tel)$.

La première utilise les noms des employés $\leq 30ans$, la deuxième utilise les noms des employés $> 30ans$ et l'autre utilise les postes des employés.

49

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

II.3. Fragmentation hybride (suite)

Exp. (suite)

On cherche à fragmenter la relation Emp pour que chaque application accède seulement au fragment qui l'intéresse.

$Personne1 = \sigma_{(dateNaiss < dateActuelle - 30ans)}(Personne)$

$Personne2 = \sigma_{(dateNaiss \geq dateActuelle - 30ans)}(Personne)$

$Emp1 = \pi_{[idEmp, nomEmp]} Emp \alpha Personne1$

$Emp2 = \pi_{[idEmp, nomEmp]} Emp \alpha Personne2$

$Emp3 = \pi_{[idEmp, poste]} Emp$

$Emp4 = \pi_{[idEmp, adr, tel]} Emp \infty Personne$

$Emp5 = Personne - (Personne \alpha Emp)$

50

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

III. Allocation de ressources

Soit un ensemble de fragments $F = \{F_1, F_2, \dots, F_n\}$ distribués sur un ensemble de sites $S = \{S_1, S_2, \dots, S_m\}$ et un ensemble de requêtes $Q = \{q_1, q_2, \dots, q_p\}$ utilisant les fragments F situés sur les sites S .

Le problème d'allocation de ressources se résume dans la recherche d'une distribution optimale des F sur les S .

51

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

III. Allocation de ressources (suite)

Pour assurer l'optimalité, nous devons respecter les deux conditions:

1. Le coût minimal

Les coûts traités dans cette condition sont:

- Le coût de stockage de chaque fragment F_i sur le site S_j ;
- Le coût de consultation de F_i localisé sur S_j ;
- Le coût de mise à jour de F_i sur tous les sites où il est stocké;
- Le coût de communication.

52

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

III. Allocation de ressources (suite)

2. La performance

Dans cette condition nous essayons de:

- Minimiser le temps de réponse;
- Maximiser le débit de chaque site.

Remarque:

Suite à la complexité du problème, on ne peut pas satisfaire toutes ces conditions. Les modèles existants essayent de satisfaire les conditions qui les intéressent.

53

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

III. Allocation de ressources (suite)

Pour simplifier la modélisation de ce problème, nous introduisons quelques définitions sur un fragment F_k .

Soit $R = \{r_1, r_2, \dots, r_m\}$ et $U = \{u_1, u_2, \dots, u_m\}$

tel que:

r_i : le trafic de lecture à partir de F_k généré sur le site S_i .

u_i : le trafic de mise à jour dans F_k généré sur le site S_i .

54

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

III. Allocation de ressources (suite)

Pour le coût de communication nous définissons:

$$C(R) = \begin{bmatrix} 0 & c_{12} & \cdots & c_{1,m-1} & c_{1m} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ c_{m1} & c_{m2} & \cdots & c_{m,m-1} & 0 \end{bmatrix}$$

$$C'(U) = \begin{bmatrix} 0 & c'_{12} & \cdots & c'_{1,m-1} & c'_{1m} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ c'_{m1} & c'_{m2} & \cdots & c'_{m,m-1} & 0 \end{bmatrix}$$

tel que: c_{ij} représente le coût de communication pour une requête de consultation entre les sites S_i et S_j .

c'_{ij} représente le coût de communication pour une requête de mise à jour entre les sites S_i et S_j .

55

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

III. Allocation de ressources (suite)

Pour le coût de stockage nous définissons:

$$D = \{d_1, d_2, \dots, d_m\}$$

tel que: d_i représente le coût de stockage du fragment F_k sur le site S_i .

Définissons aussi une variable de décision:

$$x_j = \begin{cases} 1 & \text{si le fragment } F_k \text{ est assigné au site } S_j \\ 0 & \text{sinon} \end{cases}$$

56

CHAPITRE II

STRUCTURE DE BDD DISTRIBUÉES

III. Allocation de ressources (suite)

Pour minimiser le coût d'allocation de ressources du fragment F_k qui sera placé sur les sites S_j tel que $x_j=1$, nous allons chercher [ref. 1]:

$$\min \left[\sum_{i=1}^m \left(\sum_{j|x_j=1} (u_j \cdot c'_{ij} + r_j \cdot \min_{j|x_j=1} c_{ij}) \right) + \sum_{j|x_j=1} d_j \right]$$

57

CHAPITRE III

INTÉGRATION DE BASES DE DONNÉES

- I. Méthodologie de la conception Bottom-Up
- II. Correspondance de schémas
- III. Intégration de schémas
- IV. Planification de schémas

58

CHAPITRE III

INTÉGRATION DE BASES DE DONNÉES

I. Méthodologie de la conception Bottom-Up

Dans cette partie nous allons nous intéressés à la conception Bottom-Up.

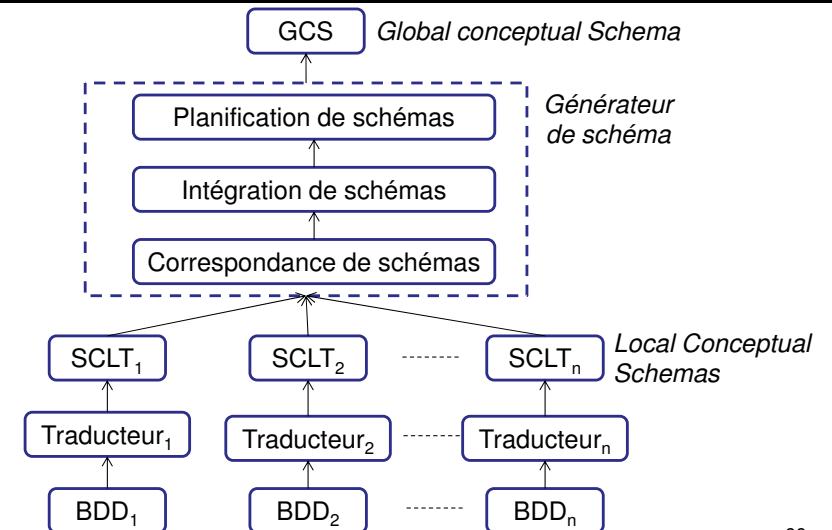
On considère qu'il existe plusieurs bases de données **hétérogènes**, et on cherche à les **intégrer** dans une seule base de données distribuée.

Le processus d'intégration est divisé en plusieurs étapes:

59

CHAPITRE III

INTÉGRATION DE BASES DE DONNÉES



60

CHAPITRE III

INTÉGRATION DE BASES DE DONNÉES

Comme indiqué sur la figure, le processus de génération de schémas est composé de 3 étapes:

I.1. Correspondance de schémas

Permet de déterminer les correspondances **syntaxiques** et **sémantiques** entre les éléments traduits.

Si le schéma conceptuel global (GCS) est **défini**, les éléments traduits doivent **lui correspondre**, sinon on établit une correspondance entre les schémas conceptuels locaux traduits (SCLTi).

61

CHAPITRE III

INTÉGRATION DE BASES DE DONNÉES

I.1. Correspondance de schémas (suite)

Nous expliquons la problématique par un exemple.

Exp. Soit la table:

```
Prj (idPrj, nomPrj, designation, budget, ville);
```

Dans cette table, l'attribut `budget` peut être spécifié en DA pour les projets réalisés en Algérie, ou en Euros pour les projets réalisés à l'étranger.

La correspondance doit spécifier une valeur en fonction de l'autre en appliquant une fonction de change.

62

CHAPITRE III

INTÉGRATION DE BASES DE DONNÉES

I.1. Correspondance de schémas (suite)

Pour établir une correspondance entre deux éléments, on définit ce qui suit:

- Une correspondance est définie sous forme d'une règle (r);
- Une règle identifie une correspondance (c) entre deux éléments;
- Un prédicat (p) indique quand la règle (r) sera appliquée;
- Une valeur de similarité (s) entre les deux éléments.

63

CHAPITRE III

INTÉGRATION DE BASES DE DONNÉES

I.1. Correspondance de schémas (suite)

Une correspondance (c) définie (calcule) un élément en **fonction** d'un autre soit par **égalité** (=) s'ils sont similaires, ou par une **expression**.

Exp:

Dans l'exemple précédent, nous devons convertir tous les budget en une seule monnaie (en euro).

Pour cela, nous devons multiplier le budget des projets algériens par le taux de change τ :

```
UPDATE Prj SET budget = budget* $\tau$ 
WHERE ville IN {'Alger', 'Batna', ...}
```

64

CHAPITRE III

INTÉGRATION DE BASES DE DONNÉES

I.1. Correspondance de schémas (suite)

Un prédicat (p) est une **condition**. Quand elle est **vrai** on applique la **règle**, sinon la règle sera ignorée.

Exp:

Dans l'exemple précédent, le prédicat p doit spécifier quand la règle doit être appliquée, et cela peut se faire en fonction de la localisation (l'attribut ville) du projet.

65

CHAPITRE III

INTÉGRATION DE BASES DE DONNÉES

I.1. Correspondance de schémas (suite)

La valeur de similarité (s) est une valeur réelle $\in [0,1]$. Elle peut être calculée ou spécifiée.

Si les deux éléments comparés sont similaire (s=1), la correspondance se fera par égalité (=), sinon la correspondance se fait par modification d'au-moins un des deux éléments.

Donc une **règle** est un triplet $\langle c, p, s \rangle$

Exp: Dans l'exemple précédent:

```
< c : (budget = budget*τ), p : (ville IN
{'Alger', 'Batna', ...} ), s : (sim(monaie du
budget, Euro)=0.9) >
```

66

CHAPITRE III


INTÉGRATION DE BASES DE DONNÉES

I.2. Intégration de schémas

Dans le processus d'intégration de schémas, la présence **humaine** est indispensable.

Après la correspondance entre les différents schémas locaux, la prochaine étape est de **créer** un schéma global.

L'intégration des schémas locaux peut se faire **deux à deux**, en une **seule passe**, ou ...



67

CHAPITRE III

INTÉGRATION DE BASES DE DONNÉES

I.3. Planification de schémas

Ce processus permet de **placer** les données des bases locales dans la base globale.

Le processus de planification de schémas est divisé en deux étapes: **création** de planification, **maintenance** de planification.

Le processus de **création** de planification consiste à créer des **requêtes** permettant de placer les données provenant des schémas locaux dans le schéma global.

Le processus de **maintenance** de planification permet de **détecter** et **corriger** les incohérences générées par l'évolution du schéma.

68

CHAPITRE III

INTÉGRATION DE BASES DE DONNÉES

Exp.

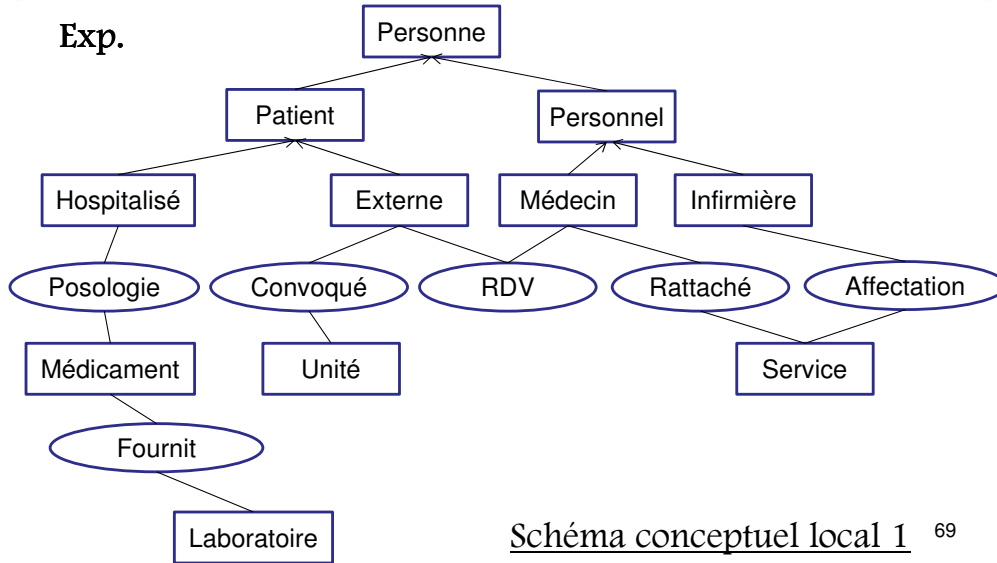


Schéma conceptuel local 1 ⁶⁹

CHAPITRE III

INTÉGRATION DE BASES DE DONNÉES

Exp. (suite)

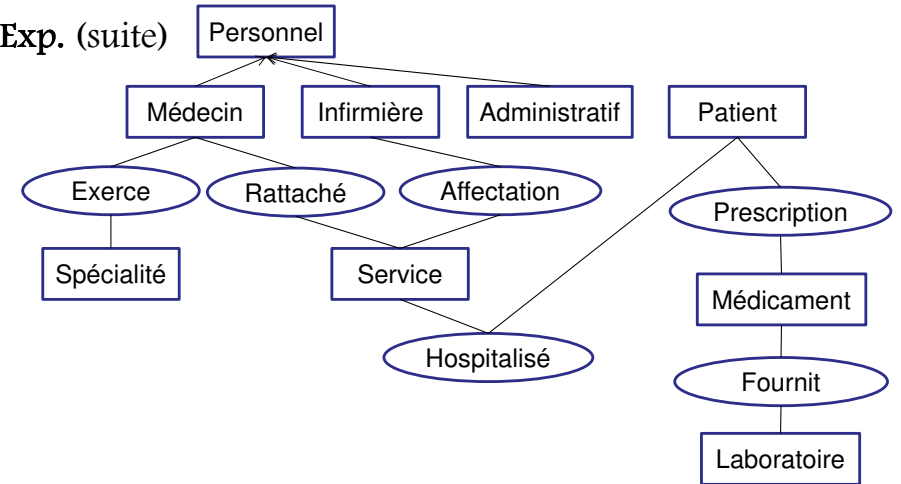
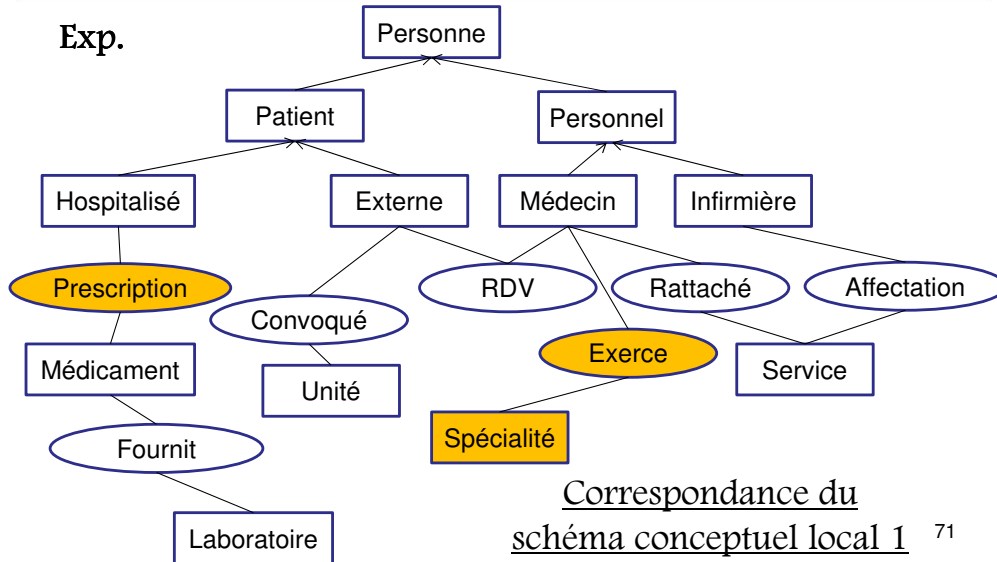


Schéma conceptuel local 2 ⁷⁰

CHAPITRE III

INTÉGRATION DE BASES DE DONNÉES

Exp.

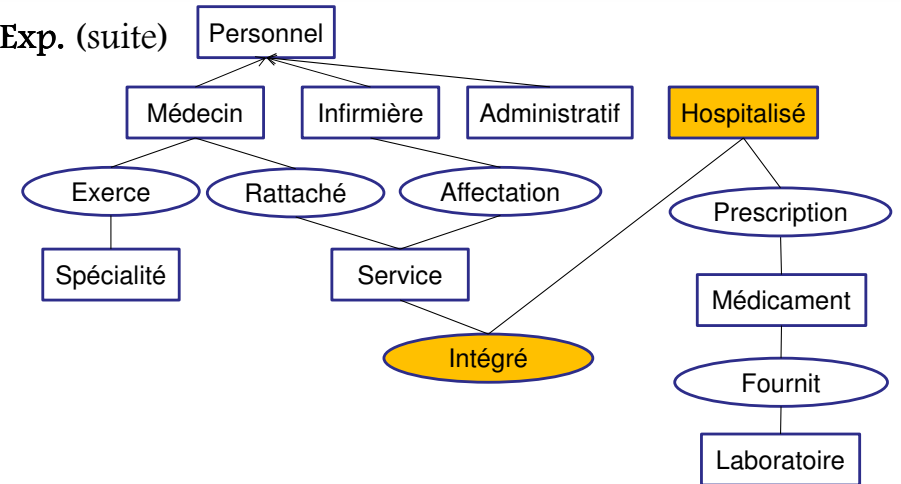


Correspondance du schéma conceptuel local 1 ⁷¹

CHAPITRE III

INTÉGRATION DE BASES DE DONNÉES

Exp. (suite)

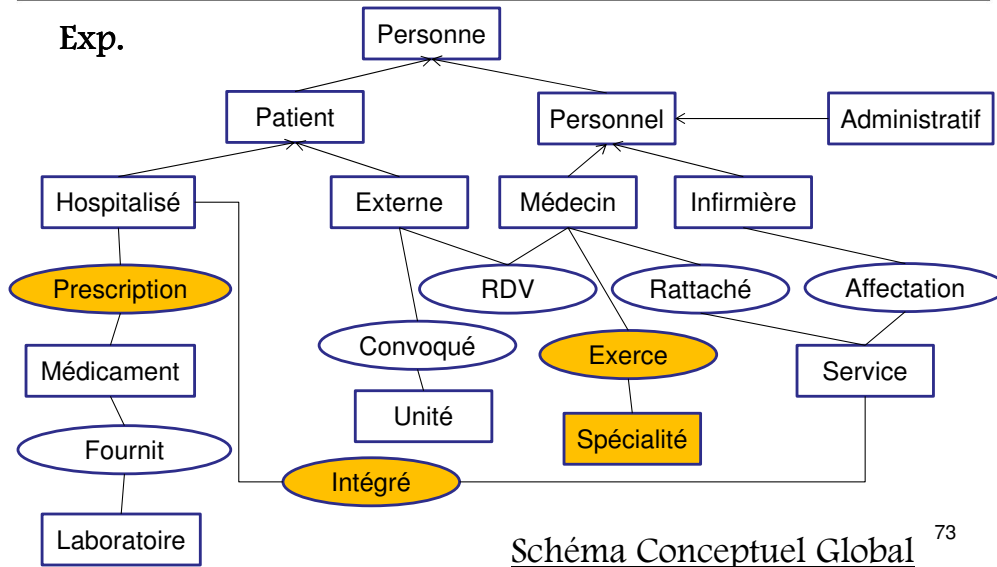


Correspondance du schéma conceptuel local 2 ⁷²

CHAPITRE III

INTÉGRATION DE BASES DE DONNÉES

Exp.



CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

- I. Gestion de vues
- II. Sécurité de données
- III. Contrôle d'intégrité sémantique

74

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

Parmi les besoins importants dans les DBMS distribuées on trouve le **contrôle de données sémantique**.

Ce contrôle de données sémantique inclut la gestion des vues, la sécurité des données et le contrôle d'intégrité sémantique.

75

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

I. Gestion des vues

Une vue est une relation virtuelle permettant de cacher une partie des données.

I.1. Les vues dans les SGBD centralisés

La syntaxe générale de la commande SQL de **création** de vue est:

```
CREATE VIEW <nom de vue> [(liste d'attributs)]  
AS <requête>
```

76

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

I.1. Les vues dans les SGBD centralisés (suite)

tel que:

(liste d'attributs) est la liste d'attributs de la vue.

<question> une requête SQL pour sélectionner les tuples qui vont remplir la table virtuelle.

La **suppression** de la vue se fait par:

```
DROP VIEW <nom de vue>
```

77

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

I.1. Les vues dans les SGBD centralisés (suite)

Exp. 1.

Pour créer la vue des employés ingénieurs (EmpIng) à partir de la relation Emp(idEmp, nomEmp, poste) on utilise:

```
CREATE VIEW EmpIng (idEmp, nomEmp)
AS SELECT idEmp, nomEmp
FROM Emp
WHERE poste = 'Ing'
```

78

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

I.1. Les vues dans les SGBD centralisés (suite)

Exp. 2.

Donner les noms des ingénieurs avec les numéros de leurs projets.

```
Emp(idEmp, nomEmp, poste)
Aff(idEmp, idPrj, resp, dur)
```

```
CREATE VIEW EmpIng (idEmp, nomEmp)
AS SELECT nomEmp, idPrj
FROM Emp, Aff
WHERE Emp.idEmp = Aff.idEmp
```

79

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

I.2. Les vues dans les SGBD distribués

Le nom et la requête d'une vue sont stockés dans un **catalogue**.

La **requête** peut être appliquée à des **fragments** stockés sur des sites différents.

Problème 1:

L'évaluation d'une vue dérivée à partir de relations **distribuées** est très **couteuse**. Si plusieurs utilisateurs accèdent à la vue, cette dernière doit être **recalculée** pour chacun.

80

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

I.2. Les vues dans les SGBD distribuées (suite)

Solution:

Stocker la version actuelle de la vue pour éviter de la recalculer. Une telle vue est appelée **vue matérialisée**.

L'accès à une vue matérialisée est plus rapide parce qu'on ne recalcule pas le contenu de la vue.

81

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

I.2. Les vues dans les SGBD distribuées (suite)

Problème 2:

Si les relations ou les fragments, utilisés dans la génération de la vue, sont **mises à jour**, le contenu de la vue matérialisée sera **faut**.

Le DBMS doit **maintenir** la vue matérialisée à jour.

L'administrateur doit savoir **quand** et **comment** mettre à jour la vue matérialisée.

82

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

I.2. Les vues dans les SGBD distribuées (suite)

Quand mettre à jour la vue matérialisée?

La mise à jour peut être **immédiate** ou **différée**.

Dans le mode **immédiat**, la mise à jour de la vue doit être une partie d'une **transaction** de mise à jour des relations utilisées par la vue.

Avantage: La vue est à jours en **permanence**.

Inconvénient: La mise à jour des relations utilisées par la vue devienne **lente**.

83

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

I.2. Les vues dans les SGBD distribuées (suite)

Dans le mode **différé**, la mise à jour de la vue se fait d'une manière **périodique** (1 fois par jour, ou par semaine...) ou d'une manière **forcée** (par exemple après un certain nombre de mises à jours sur les relations utilisées dans la définition de la vue).

84

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

I.2. Les vues dans les SGBD distribuées (suite)

Comment mettre à jour la vue matérialisée?

Le plus simple est de recalculer la vue entière.

Une solution **meilleure** est de ne recalculer que la **partie modifiée**.

Soit **u** la modification appliquée à la relation **R**.

Et soit **R⁺** contient les tuples à ajouter à **R** en appliquant **u** (ajout de tuples)

R⁻ contient les tuples à supprimer de **R** en appliquant **u** (suppression de tuples)

85

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

I.2. Les vues dans les SGBD distribuées (suite)

Comment mettre à jour la vue matérialisée? (suite)

La relation **R** après application de **u** contient:

$$(R-R^-) \cup R^+$$

Exp.

Dans l'exemple précédent,

Emp (idEmp, nomEmp, poste)

Aff (idEmp, idPrj, resp, dur)

soit la vue qui donne les noms des employés et leurs responsabilités:

86

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

I.2. Les vues dans les SGBD distribuées (suite)

Exp. (suite)

```
CREATE VIEW ER(nomEmp, resp)
```

```
AS SELECT DISTINCT nomEmp, resp
```

```
FROM Emp, Aff
```

```
WHERE Emp.idEmp = Aff.idEmp
```

Soit **Emp⁺** l'ensemble des tuples à ajouter à **Emp**, et soit **Aff⁺** l'ensemble de tuples à ajouter à **Aff**.

Les changements de la vue ER peuvent être calculés comme suit:

87

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

I.2. Les vues dans les SGBD distribuées (suite)

Exp. (suite)

```
ER+ = (SELECT nomEmp, resp
```

```
FROM Emp, Aff+
```

```
WHERE Emp.idEmp = Aff+.idEmp)
```

```
UNION
```

```
(SELECT nomEmp, resp
```

```
FROM Emp+, Aff
```

```
WHERE Emp+.idEmp = Aff.idEmp)
```

```
UNION
```

```
(SELECT nomEmp, resp
```

```
FROM Emp+, Aff+
```

```
WHERE Emp+.idEmp = Aff+.idEmp)
```

88

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

II. Sécurité des données

La sécurité des données inclue deux aspects: **Protection des données** et **contrôle d'accès**.

II.1. Protection des données

En général, l'approche principale de protection de données est le **cryptage** des données.

Cet aspect ne concerne pas beaucoup des systèmes de bases de données, mais plutôt le domaine de cryptographie.

Nous allons nous concentrer sur le deuxième aspect.

89

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

II.2. Contrôle d'accès

Il existe deux approches principales: contrôle d'accès **discrétionnaire** (contrôle d'autorisation), contrôle d'accès **multi-niveaux**.

II.2.1. Contrôle d'accès discrétionnaire

Cette approche définit des **droits d'accès** basés sur les utilisateurs.

Une autorisation est un triplet **< sujet s, type d'opération t, définition d'objet o >** qui donne le droit au sujet 's' d'établir les opérations de type 't' sur l'objet 'o'.

90

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

II.2.1. Contrôle d'accès discrétionnaire (suite)

La définition d'un **sujet** se fait par une paire **<user, pass>** ou **public** pour tout le monde.

Le type d'opération peut être: **SELECT, INSERT, UPDATE** ou **DELETE, REFERENCES, ALTER, INDEX, ALL**.

Un droit affecté à un sujet peut être: **GRANT** (accorder) ou **REVOKE** (retirer).

GRANT (operation) ON (objet) TO (sujet)

REVOKE (operation) FROM (object) TO (sujet)

91

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

II.2.1. Contrôle d'accès discrétionnaire (suite)

Seuls les utilisateurs de type **'administrateur'** peuvent utiliser les opérations GRANT et REVOKE.

Un **utilisateur** possède **tous** les **droits** sur les objets qu'il a créés et peut utiliser les opérations (GRANT, REVOKE) sur ces objets.

Un utilisateur qui **reçoit les droits** sur un objet, peut ensuite appliquer les opérations (GRANT, REVOKE) sur cet objet.

92

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

II.2.1. Contrôle d'accès discrétionnaire (suite)

Récurtivité:

Soit (A) qui donne un droit de type 't' sur un objet 'o' à (B) qui donne à son tour ce droit à (C).

Si (A) retire ce droit à (B), le système DBMS doit **retirer** ce droit aussi à (C) d'une manière **réursive**.

Donc le DBMS doit **garder l'hierarchie** de distribution des droits d'accès. En général, on utilise une **matrice d'autorisations**, tel que les lignes représentent les sujets, une colonne représente un objet et une case représente une autorisation $\langle s, t=*, o \rangle$

93

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

II.2.1. Contrôle d'accès discrétionnaire (suite)

Exp. Matrice d'autorisations

	Emp	nomEmp	Aff
User1	UPDATE	UPDATE	UPDATE
User2	SELECT	SELECT	SELECT WHERE resp# 'Manager'
user3	NONE	SELECT	NONE

94

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

II.2.2. Contrôle d'accès Multi-Niveaux (Mandatory/Multilevel)

Cette approche est basée sur la **limitation** d'accès aux données **classifiées** aux utilisateurs **autorisés**.

Cette approche définit des **niveaux de sécurité** pour les sujets et les données:

Top Secret (TS) > Secret (S) >
Confidentiel (C) > Non-Classifié (NC)

tel que '>' veut dire "**plus sécurisé que**".

95

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

II.2.2. Contrôle d'accès Multi-Niveaux (suite)

L'accès en lecture et écriture pour un sujet est limité par deux règles:

1. Un sujet **U** est autorisé à lire un objet **O** si:
niveau(U) ≥ niveau(O)
2. Un sujet **U** est autorisé à écrire un objet **O** si:
niveau(U) ≤ niveau(O)

La règle 1 interdit un utilisateur de lire les données qui ont un niveau de sécurité supérieur.

La règle 2 interdit un utilisateur d'écrire son objet sécurisé dans un niveau moins sécurisé.

96

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

II.2.2. Contrôle d'accès Multi-Niveaux (suite)

Exp. Soit la relation Prj(idPrj, nomPrj, designation, budget, ville) avec la définition des niveaux de sécurité suivante:

idPrj	NivSec1	nomPrj	NivSec2	designation	NivSec3	budget	NivSec4	ville	NivSec5
P1	C	Prj1	C	d1	C	150000	C	Batna	C
P2	C	Prj2	C	d2	S	135000	TS	Alger	S
P3	S	Prj3	S	d3	S	250000	TS	Oran	S

97

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

II.2.2. Contrôle d'accès Multi-Niveaux (suite)

Exp. (suite) La **table** prend le **niveau le plus bas** de ses données qui est dans notre cas (C)

Mais un utilisateur de niveau (C) ne peut voir que les tuples suivants:

idPrj	NivSec1	nomPrj	NivSec2	designation	NivSec3	budget	NivSec4	ville	NivSec5
P1	C	Prj1	C	d1	C	150000	C	Batna	C
P2	C	Prj2	C	null	C	null	C	null	C

98

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

II.2.3. Contrôle d'accès distribué

Dans un DBMS **distribué** on peut **grouper** les utilisateurs en groupes et leurs définir des **niveaux de sécurité**.

Problème 1:

Les **utilisateurs** d'un groupe peuvent être localisés dans **différents sites**;

L'**accès** à un objet peut être **autorisé** à plusieurs groupes distribués;

Les informations sur les **niveaux de sécurité** des groupes doivent être stockées quelque part !!

99

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

II.2.3. Contrôle d'accès distribué (suite)

Le plus simple est de **dupliquer** les informations des groupes (droits d'accès...) sur **tous les sites**. Le **maintient** de toutes ces informations à jour est très **difficile**.

Solution 1:

Centraliser les informations des groupes sur un seul nœud et **appliquer** des droits d'accès en envoyant une **requête** à **distance** à ce **nœud**.

Solution 2:

Dupliquer les informations d'un groupe sur les sites **contenant** des objets utilisés par les membres de ce groupe.

100

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

II.2.3. Contrôle d'accès distribué (suite)

Problème 2:

Exp. Soit 2 sites tel que le Site1 possède le niveau de sécurité (S) et le Site2 avec le niveau (C).

Site1: Table Notes(idEtd, Module, Note) → niveau (S)

Site2: Table Etudiants(idEtd, nom, prenom) → niveau (C)

Un utilisateur avec un niveau (S) cherche les noms des étudiants ayant une note de 20 dans le module « BDD ».

Une **jointure** doit être établie entre les 2 tables, et les informations **secrètes** de la table Notes doivent être **envoyées** pour réaliser cette jointure.

101

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

II.2.3. Contrôle d'accès distribué (suite)

Problème 2: (suite)

Ce problème est appelé **canal caché (covert channel)** pour accéder à des données non-autorisées.

Solution:

Pour **éviter** le problème de canal caché on peut **dupliquer** une **partie** de la base pour qu'un site de niveau de sécurité (**k**) **contient** toutes les données **nécessaires** pour les utilisateurs de ce niveau.

Donc le site de l'utilisateur de niveau (S) doit contenir des copies des parties des tables (Notes, Etudiants) à utiliser dans la requête de jointure.

102

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III. Contrôle d'intégrité sémantique

Exp.

Soit la base de données du premier exemple. La table Emp contient les employés avec les identifiants de 1 jusqu'à 50, la table Prj contient des projets avec les identifiants de 1 jusqu'à 10. On ajoute un nouveau tuple à la table Aff(idEmp, idPrj, resp, dur) comme suit:

```
INSERT INTO Aff VALUES (100, 10, 'Ing', 5)
```

103

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III. Contrôle d'intégrité sémantique (suite)

Problème:

La base n'est pas **cohérente**, il y a un problème **sémantique** à cause de l'affectation de l'employé n°100, qui n'existe pas, à un projet.

Le **contrôle d'intégrité sémantique** assure la **cohérence (consistance)** de la base de données en **rejetant** les mises à jours qui affectent la cohérence de la base ou **activer** des **actions spécifiques** qui corrigent l'incohérence.

104

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III. Contrôle d'intégrité sémantique (suite)

Pour assurer le contrôle d'intégrité sémantique nous allons voir des solutions dans les DBMS **centralisés** puis dans les DBMS **distribués**.

III.1. Contrôle d'intégrité sémantique centralisée

Ce contrôle est composé de deux parties principales: spécification des contraintes d'intégrité, application de l'intégrité.

105

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III.1.1. Spécification des contraintes d'intégrité

On peut classer les contraintes d'intégrité en deux types: contraintes prédéfinies, contraintes pré-conditionnées.

Les **contraintes prédéfinies** utilisent des mots clés comme: attribut non-nul, clé unique, clé étrangère, dépendances fonctionnelles.

Exp. 1

L'identifiant d'un employé ne peut être nul:

```
idEmp NOT NULL IN Emp
```

106

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III.1.1. Spécification des contraintes d'intégrité (suite)

Exp. 2

La paire <idEmp, idPrj> est une clé unique dans Aff:

```
(idEmp, idPrj) UNIQUE IN Aff
```

Exp. 3

L'identifiant du projet est une clé étrangère dans la table Aff, c'est-à-dire le projet utilisé dans une affectation doit exister dans la table Prj:

```
idPrj IN Aff REFERENCES idPrj IN Prj
```

107

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III.1.1. Spécification des contraintes d'intégrité (suite)

Exp. 4

L'identifiant de l'employé définit fonctionnellement le nom de l'employé:

```
idEmp IN Emp DETERMINES nomEmp
```

108

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III.1.1. Spécification des contraintes d'intégrité (suite)

Les **contraintes pré-conditionnées** utilisent le mot clé CHECK.

On utilise le mot clé CHECK de SQL:

```
ALTER TABLE table_name  
ADD CONSTRAINT "constraint_name" CHECK  
(condition) ENABLE
```

109

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III.1.1. Spécification des contraintes d'intégrité (suite)

Exp.

Le budget d'un projet doit être entre 50000 et 100000

```
ALTER TABLE Prj  
ADD CONSTRAINT "PRJ_CHK1" CHECK (budget >=  
50000 AND budget <= 1000000) ENABLE
```

110

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III.1.2. Application de l'intégrité

Il existe deux méthodes de base permettant de rejeter les mises à jour incohérents:

* La **première méthode** est basée sur la **détection** des **incohérences** après l'exécution des mises à jour.

L'algorithme qui applique l'intégrité sémantique applique des tests après l'exécution des modifications pour détecter les incohérences, ces tests sont appelés **post-tests**.

111

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III.1.2. Application de l'intégrité (suite)

* La **deuxième méthode** est basée sur la **prévention** des incohérences.

Les **modifications** ne seront pas appliquées que si elles ne causent pas d'incohérences.

L'algorithme qui applique l'intégrité sémantique vérifie si les contraintes d'intégrités seront satisfaites avant d'appliquer les modifications. Les tests appliqués sont appelés des **pré-tests**.

112

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III.1.2. Application de l'intégrité (suite)

Une des méthodes préventives est **l'algorithme de modification de requêtes**. Il ajoute des testes à la requête elle-même.

Exp.

La requête qui incrémente le budget du projet prj1 de 20%:

```
UPDATE Prj
SET budget = budget*1.2
WHERE nomPrj = 'prj1'
```

113

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III.1.2. Application de l'intégrité (suite)

Exp. (suite)

Cette requête sera transformée en ajoutant des pré-testes comme suit:

```
UPDATE Prj
SET budget = budget*1.2
WHERE nomPrj = 'prj1'
AND NEW.BUDGET ≥ 50000
AND NEW.BUDGET ≤ 100000
```

114

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III.2. Contrôle d'intégrité sémantique distribuée

Le contrôle d'intégrité sémantique distribuée est une extension du contrôle d'intégrité sémantique centralisée. Il est composé de deux parties principales: spécification des contraintes d'intégrité distribuée, application de l'intégrité distribuée.

115

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III.2.1. Spécification des contraintes d'intégrité distribuée

Les **contraintes** peuvent utiliser des données stockées sur **différents sites**. Une telle contrainte doit être stockée de manière à **minimiser** le coût de l'intégrité.

III.2.1.1. Contraintes individuelle

La définition de la contrainte d'intégrité est **envoyée** aux sites contenant les fragments de la relation utilisée dans la contrainte. La contrainte doit être compatible avec la relation aux niveaux: prédicat et données.

116

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III.2.1.1. Contraintes individuelle (suite)

- **Compatibilité au niveau prédicat**

Une contrainte 'C' n'est **pas compatible** avec un prédicat de fragment 'p' si 'C est vrai' implique que 'p est toujours faux' ($C \Rightarrow \neg p$), sinon 'C' est compatible avec 'p'.

Si on trouve une **incompatibilité** dans un seul site, la contrainte est **rejetée globalement**.

117

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III.2.1.1. Contraintes individuelle (suite)

- **Compatibilité au niveau prédicat (suite)**

Exp.

Soit la relation Emp du premier exemple qui est fragmentée horizontalement sur trois sites en utilisant les prédicats:

p1: $0 \leq \text{idEmp} < 3$, p2: $3 \leq \text{idEmp} \leq 6$, p3: $\text{idEmp} > 6$

et soit la contrainte [C: $\text{idEmp} < 4$]

La contrainte 'C' n'est pas compatible avec 'p3' parce que **si C est vrai implique que p3 est faux**.

La contrainte 'C' est compatible avec 'p2' parce que **si C est vrai n'implique pas toujours que p2 est faux**.

118

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III.2.1.1. Contraintes individuelle (suite)

- **Compatibilité au niveau prédicat (suite)**

Exp. (suite)

C	1	1	0	0
p	1	0	1	0
$C \Rightarrow p$	1	0	1	1

119

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III.2.1.1. Contraintes individuelle (suite)

- **Compatibilité au niveau données**

La contrainte est testée avec les **instances** des fragments des sites utilisés. Si la contrainte n'est **pas satisfaite**, elle sera **rejetée globalement**.

Si la **compatibilité existe** aux deux niveaux, la contrainte sera **stockée dans tous les sites** utilisés.

120

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III.2.1.1. Contraintes individuelle (suite)

- **Compatibilité au niveau données (suite)**

Exp.

Soit la contrainte de l'exemple précédent: [C: idEmp < 4]

Et soit les fragments de la table Emp (idEmp, nomEmp, poste) sur 2 sites comme suit:

idEmp	nomEmp	poste
1	E1	P1
2	E2	P2

idEmp	nomEmp	poste
3	E1	P1
4	E2	P2

La contrainte 'C' est compatible avec le 1^{er} site au niveau données, et pas avec le 2^{ème}

CHAPITRE IV

CONTRÔLE D'ACCÈS ET DE DONNÉES

III.2.2. Application de l'intégrité distribuée

Le problème principale est de décider dans **quel site** doit-on appliquer la contrainte d'intégrité.

La contrainte est appliquée sur les sites contenant les fragments des relations utilisés dans la contrainte.