Gestion des données et accès à l'information

Bases de données relationnelles

Olivier Schwander <olivier.schwander@sorbonne-universite.fr>

Master Statistiques
Sorbonne Université

2024-2025

SGBD - Systèmes de Gestion de Bases de Données

Serveur

- Stocke les données
- Reçoit et interprète les requêtes des clients
- Gère le contrôle d'accès
- Gère les accès concurrents

Client

- Application qui utilise la base de donnée

Application

- Programme classique, contenant un client
- Bibliothèques dans des langages de programmation
- Fournit une interface avec la base

Abstraction du stockage physique

Serveur de bases de données

- Reçoit les requêtes par le réseau

Moteur de base de données

- Stockage concret des données
- Indexation pour accélérer les requêtes
- Journalisation des écritures

Langage standardisé et normalisé

Théorie

- Une application conçue pour un SGBD doit marcher avec un autre

Pratique

- Délicat...

Pourquoi ?

- Extensions de la syntaxe
- Parties de la norme pas implantées
- Performances, passage à l'échelle

12 règles de Codd

Tentative de définition d'un SGBD soit relationnel

Règle 1 - Unicité

Chaque information est représentée d'une seule manière.

Règle 2 - Accès non-ambigu

(clé primaire, base/table/colonne) donne une valeur

Règle 3 - Traitement des valeurs manquantes

Valeur `NULL` distincte de toutes les autres valeurs (y compris de `NULL`)

Règle 7 - Insertion, mise à jour, et effacement de haut niveau

Traitement par lots

12 règles de Codd - Indépendances

Règle 8 - Indépendance physique

On peut changer la façon de stocker les données

Règle 9 - Indépendance logique

On peut changer la structure de la base

Règle 10 - Indépendance d'intégrité

On peut exprimer des contraintes sur les données indépendemment de l'application

Règle 11 - Indépendance de distribution

Distribution sur plusieurs machines transparente

Groupes d'opérations

Exemple

- Étape 1: débiter un compte bancaire
- Étape 2: créditer un autre compte

Que se passe-t-il si le système plante entre les étapes 1 et 2 ?

Transaction

- Marquer une suite d'opération comme *atomique*
- Pouvoir revenir à l'étape antérieur en cas de problème

ACID

ACID

Atomicité

- Une transaction se fait complètement ou pas du tout

Cohérence

- Le système passe toujours d'un état valide à un autre

Isolation

- Indépendance entre les transactions

Durabilité

- Une transaction effectuée l'est de façon durable

Algèbre relationnelle

Motivation

- Formaliser les opérations sur les bases de données
- Basé sur la théorie des ensembles

Optimisation des requêtes

- Transformer des requêtes en requêtes équivalentes
- Choisir la plus efficace

L'optimisation des requêtes est un point critique pour la performance d'un SGBD.

Opérations ensemblistes

Union

$$R \cup S = \{t : t \in R \ ou \ t \in S\}$$

Intersection

$$R \cap S = \{t : t \in R \ et \ t \in S\}$$

Différence

$$R - S = \{t : t \in R \ et \ t \notin S\}$$

Produit cartésien

$$R \times S = \{(r, s) : r \in R \ et \ s \in S\}$$

Opérations relationnelles

Sélection

$$\sigma_F(R) = \{r \in R | F(r)\}$$

Projection

$$\pi_A(R)$$

Élements de R en ne considérant que les attributs listés dans A.

Renommage

$$\rho_{a/b}(R)$$

Attribut b rebaptisé en a.

Tables

Tableaux à deux dimensions

- Attributs $\times$ éléments
- Une ligne n'est pas forcément présente une et une seule fois

Clé primaire

- Garantir l'unicité
- Un attribut ou plusieurs attributs naturellement uniques
- Un attribut rajouté artificiellement dans ce but

Jointures

Références entre tables

- Produit cartésien
- Sélection

Clé étrangère

- Attribut identifiant un élément d'une autre table
- Clé primaire de l'autre table

Sélection et projection

```
SELECT * FROM table WHERE ...;
```

Projection

```
SELECT a,d,e FROM table;
```

Filtre

```
SELECT * FROM table WHERE table.name = 'machin';
```

Produit cartésien

```
SELECT t1.a, t2.a, t2.b FROM table1 t1, table2 t2;
```

Jointure

Deux opérations

- Produit cartésien
- Sélection

Personnes	
id	(clé primaire)
nom	
prenom	
age	
$adresse_{id}$	(clé étrangère)

Adresses	
id	(clé primaire)
rue	
ville	

SQL

```
SELECT * FROM Personnes, Adresses WHERE
Personnes.adresse_id = Adresses.id
```

Opérations non-ensemblistes

Tri

```
SELECT * FROM Personnes ORDER BY nom;
```

Aggrégation

- Comptage: `SELECT count(*) FROM table;`
- Somme `SELECT sum(age) FROM personnes;`
- Autre: `max`, `min`, `avg`, fonctions statistiques

Suppression de réponses identiques

- `SELECT DISTINCT`

Contraintes

Propriétés sur les colonnes

- Strictement positif
- Pas `NULL`
- etc

Intégrité référentielle

- Garantir que les clés étrangères correspondent à des éléments existants

Description du schéma

Bibliothèque universitaire

- Des étudiants
- Des livres
- Des emprunts

Étudiants

- Empruntent des livres
- 0 ou plus
- Nom, prénom, numéro unique d'étudiant

Livres

- Sont empruntés
- 0 ou plus
- Titre, auteur, et numéro ISBN unique

Entité-Association

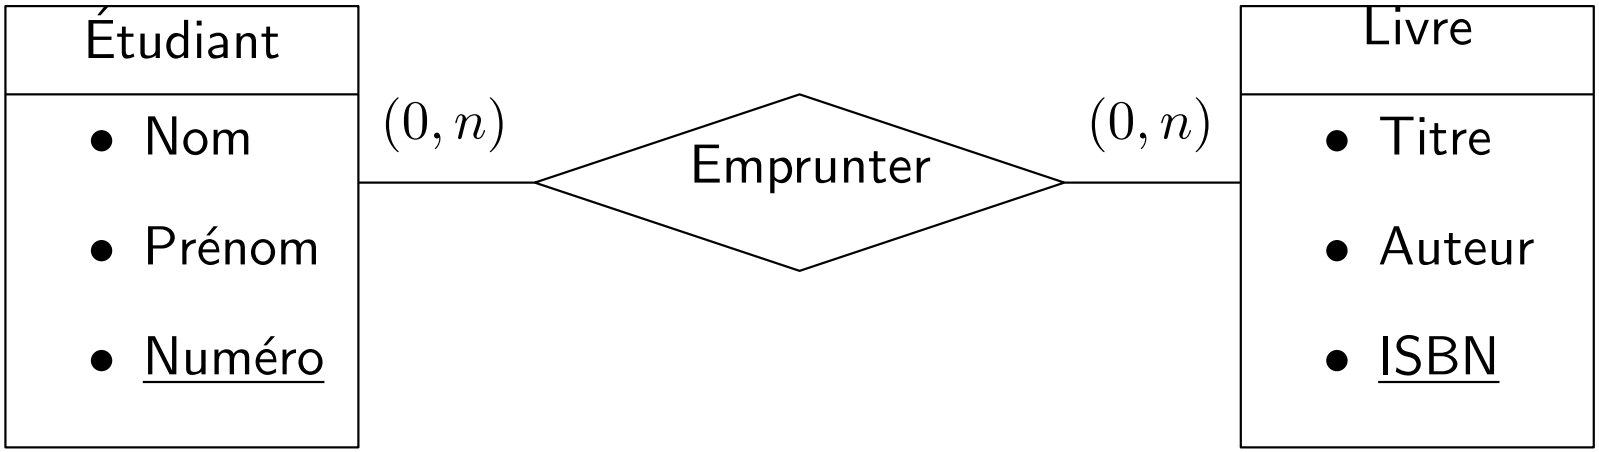

Tables

Étudiant

- Clé primaire
- Attributs

Livre

- Clé primaire
- Attributs

Lien Étudiant-Livre

- Clé étrangère vers Étudiant
- Clé étrangère vers Livre

Exemple de requête

Liste des livres empruntés par un étudiant

```
SELECT etudiant.nom,livre.titre
FROM etudiant,livre,emprunter_etudiant_livre emprunter
WHERE etudiant.numero = emprunter.id_etudiant
AND livre.isbn = emprunter.id_livre
AND etudiant.numero = 123513223;
```

Types numériques

http://docs.postgresql.fr/9.3/datatype.html#datatype-numeric

boolean	1 octet	état vrai ou faux
smallint	2 octets	entier de faible étendue
integer	4 octets	entier habituel
bigint	8 octets	grand entier
decimal	variable	valeur exacte
numeric	variable	valeur exacte
real	4 octets	valeur inexacte
double precision	8 octets	valeur inexacte

Types caractères

http://docs.postgresql.fr/9.3/datatype-character.html

varchar(n)	Longueur variable avec limite
char(n)	longueur fixe, complété par des espaces
text	longueur variable illimitée

Types date/heure

http://docs.postgresql.fr/9.3/datatype-datetime.html

timestamp	8 octets	date et heure (sans fuseau horair
timestamp with time zone	8 octets	date et heure, avec fuseau horair
date	4 octets	date seule (pas d'heure)
time	8 octets	heure seule (pas de date)
time with time zone	12 octets	heure seule, avec fuseau horaire
interval	16 octets	intervalles de temps

- `04:05:06`, `04:05:06-8`
- `1999-01-08 04:05:06 -8:00`, `January 8 04:05:06 1999 PST`

Autres types

http://docs.postgresql.fr/9.3/datatype.html

- Données binaires
- Types géométriques
- Types personnalisés
- Intervalles
- Énumérations

Création de tables

```
CREATE TABLE etudiant (
  numero char(8) PRIMARY KEY,
  nom varchar(40),
  prenom varchar(40),
);

CREATE TABLE emprunter (
  id_etudiant char(8),
  id_livre    char(13),
  CONSTRAINT pk_emprunter
    PRIMARY KEY (id_etudiant, id_livre),
  CONSTRAINT fk_emprunter_etudiant
    FOREIGN KEY (id_etudiant) REFERENCES Etudiant(numero),
  CONSTRAINT fk_emprunter_livre
    FOREIGN KEY (id_livre)    REFERENCES Livre(isbn),
);
```

Autres opérations

Suppression

- `DROP`

Modification

- `ALTER`