université PARIS-SACLAY

DATA WAREHOUSE I

WEEK 3

BASED ON BENOÎT GROZ'S SLIDES

© 2024 Pierre-Henri Paris

This work is licensed under CC BY 4.0

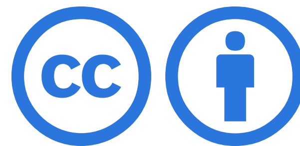

SQL COMME LANGAGE DE REQUÊTES

- Découvrir la syntaxe de SQL
- Savoir écrire des requêtes simples
- Connaissances de bases sur jointures et agrégats
- Créer& interroger une base de donnée sous PostgreSQL

SQL: PROPRIÉTÉS GÉNÉRALES

SQL: INTRODUCTION

- SQL = Structured Query Language
- Version originelle SEQUEL: Boyce et Chamberlain (IBM).
- Norme ANSI puis standard ISO
- Avantages:
  - langage standard d'interrogation: supporté (en partie) par principaux SGBDs
  - portabilité des applications, interopérabilité
- Inconvénients:
  - évolution du langage par "extensions"
    SQL1 : 1989, SQL2 : 1992, SQL3 : 1999
    SQL:2003, SQL:2008 ...
  - frein à l'émergence d'un nouveau langage
  - style de programmation désuet

LA CASSE EN SQL

- Mots-clefs (SELECT, FROM…) insensibles mais souvent majuscule
- Nom de table, colonne généralement insensibles, peuvent être sensible
  (option paramétrable, valeur défaut dépend du SGBD/de l'OS…)
- Valeurs des chaines de caractères sensibles: 'aa'≠ 'Aa'
  (apparaissent typiquement dans conditions WHERE, HAVING)

TYPES DE DONNÉES EN SQL

- chaînes de caractères de taille fixe, complétées à droite par des espaces: CHAR(taille)
- chaînes de taille variable: VARCHAR(taille_max)
- entiers sur 32 bits: INTEGER
- nombres en précision fixe (nb chiffres dont nbDecimales après virgule): NUMERIC(nb, nbDecimales)
- nombres virgule flottante: REAL/DOUBLE PRECISION).
- types date/heure: DATE/TIME/TIMESTAMP

NULL EN SQL

- `NULL` représente une valeur inconnue
- 3 valeurs possibles pour expressions booléennes SQL: `Vrai, Faux, Inconnu`
    - 2=2: `Vrai`
    - 2=NULL: `Inconnu`
    - NULL= NULL: `Inconnu`
- SQL utilise une *logique à 3 valeurs* pour évaluer les conditions:
    - NOT `Inconnu`= `Inconnu`
    - OR retourne `Vrai` si un des arguments est `Vrai`, `Faux` si les deux arguments sont `Faux`, `Inconnu` sinon
    - AND retourne `Vrai` si les deux arguments sont `Vrai`…
- Pour tester si un attribut est défini: attr IS NULL/IS NOT NULL
- Les expressions arithmétiques mettant en jeu un null s'évaluent à null:
    - 2+NULL renvoie NULL

NULL IN SQL: TRAPS

Réécrire les requêtes suivantes

```sql
SELECT * WHERE (name <> 'Jean') OR name='Jean';
SELECT * WHERE name = name;
```

SQL: LANGAGE DE DÉFINITION DE DONNÉES

SQL: LDD

CRÉATION DE SCHÉMA

plus exactement, création d'une table vide.

```
CREATE TABLE Film (Titre CHAR(20), MeS CHAR(20), Acteur VARCHAR(20))
```

CONTRAINTES

- NOT NULL
- valeurs uniques
- clefs primaires
- clefs étrangères
- condition de valeurs (check)

CONTRAINTES: NOT NULL

```sql
CREATE TABLE Film (Titre CHAR(20) NOT NULL,Acteur VARCHAR(20),
      Realisateur CHAR(20) NOT NULL DEFAULT 'Kurosawa')
```

```
TITRE                      ACTEUR    REALISATEUR
-----------------------------------------------
Les petits mouchoirs       Cotillard Canet
La plage                   Canet                  <--
Mon Idole                  Canet     Canet
Bienvenus chez les ch'tis  Boon      Boon
```

$\hookrightarrow 2^{ème}$ instance impossible car la contrainte sur réalisateur n'est pas respectée.

CONTRAINTES: CLEF /CLEF PRIMAIRE

Elles créent un index implicite.

```
CREATE TABLE Prog ( Nom_Cine CHAR(20), Titre CHAR(20), Salle INT,
            Horaire TIME, UNIQUE (Nom_Cine,Titre, Horaire))
```

Deux lignes ne peuvent pas avoir la même valeur de clef (sauf NULL)

```
CREATE TABLE Cine ( Nom_Cine CHAR(20) PRIMARY KEY,
          Adresse VARCHAR(60), Telephone CHAR(8))
```

Clef primaire=UNIQUE+NOT NULL 1 seule par table

```
CREATE TABLE Cine ( NomCine CHAR(20), Adresse VARCHAR(60),
          Telephone CHAR(8), CONSTRAINT pk_nc PRIMARY KEY (Nom_Cine))
```

https://troels.arvin.dk/db/rdbms/#constraints-unique

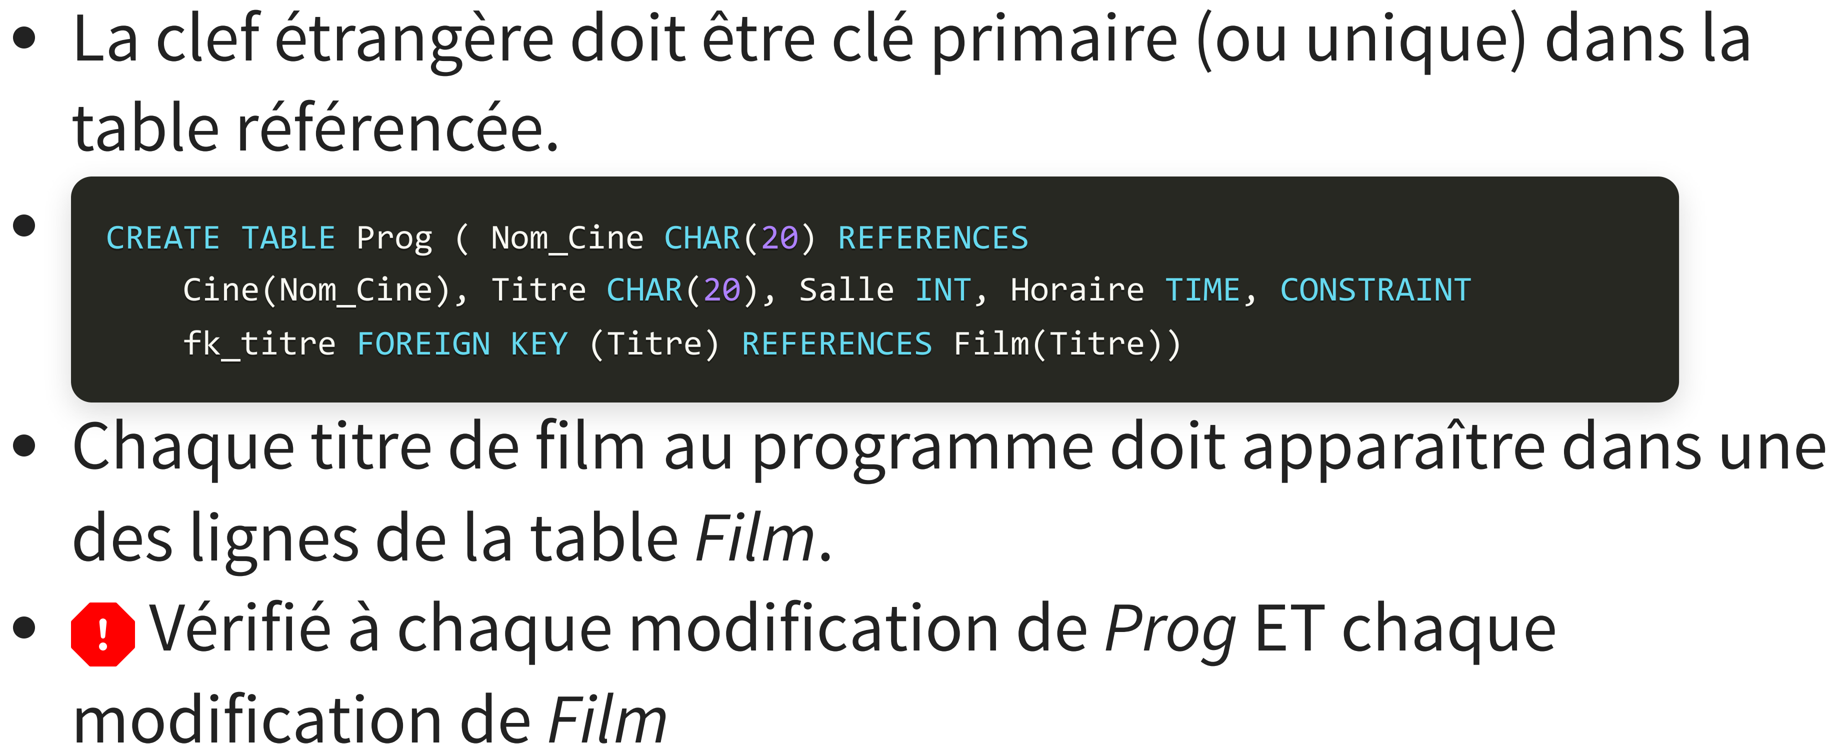

CONTRAINTES: CLEF ÉTRANGÈRE

- La clef étrangère doit être clé primaire (ou unique) dans la table référencée.
- ```
  CREATE TABLE Prog ( Nom_Cine CHAR(20) REFERENCES
      Cine(Nom_Cine), Titre CHAR(20), Salle INT, Horaire TIME, CONSTRAINT
      fk_titre FOREIGN KEY (Titre) REFERENCES Film(Titre))
  ```
- Chaque titre de film au programme doit apparaître dans une des lignes de la table *Film*.
- ❗ Vérifié à chaque modification de *Prog* ET chaque modification de *Film*
  ```

RÉCAPITULATIF DES CONTRAINTES D'INTÉGRITÉ

Considérons les contraintes :

```
# dans Cine:
Telephone CHAR(8) NOT NULL CONSTRAINT pk_nc PRIMARY KEY (Nom_Cine)
# dans Prog:
CONSTRAINT fk_cine FOREIGN KEY (Nom_Cine) REFERENCES Cine(Nom_Cine)
  UNIQUE (Nom_Cine,Titre, Horaire)
```

Les tables ci-dessous violent des contraintes (donc instance impossible) :

Prog

NOM_CINE	ADRESSE	TELEPHONE
ugc bercy	3 rue...	06043494
le champo	17 av...	01049059
ugc bercy	18 bd...	

Cine

NOM_CINE	TITRE	SALLE	HORAIRE
ugc bercy	Le discours d'un roi	1	20h00
ugc bercy	Le discours d'un roi	3	20h00
ugc bercy	Le discours d'un roi	2	22h00
ugc bercy	Inception	1	14h00
le champo	Le discours d'un roi	1	18h00
le campo	Inception	1	20h00

CONTRAINTES: RESTRICTION DU DOMAINE

Évalue une condition; retourne une erreur si le résultat est Faux:

```
CREATE TABLE Prog ( Nom_Cine CHAR(20), Titre CHAR(20),
            Salle INT NOT NULL CHECK (1<=salle AND salle<10), Horaire TIME)
```

La condition peut porter sur plusieurs colonnes de la table, faire appel à une requête SQL sur une autre table, etc. :

```
CREATE TABLE Prog ( ..., CHECK ('France'= SELECT pays FROM Cine
            WHERE Prog.Nom_Cine=Cine.nom))
```

Vérifié à chaque modification de *Prog*, mais pas de *Cine*.

MODIFIER/DÉTRUIRE DES TABLES (AU NIVEAU DU SCHÉMA)

```
DROP TABLE Prog; # Erreur si d'autres objets dépendent de la table
```

En présence de clefs étrangères, respecter l'ordre pour détruire les tables, ou bien:

```
DROP TABLE Prog CASCADE;
            # Détruit aussi les objets faisant référence à Prog
```

```
ALTER TABLE Prog ADD COLUMN jour: DATE
```

SQL: LANGAGE DE MANIPULATION DES DONNÉES

LMD

LANGAGE DE MANIPULATION DE DONNÉES

- `SELECT` : pour interroger
- `INSERT` : pour insérer des tuples dans une table
- `UPDATE` : pour modifier des données dans une table
- `DELETE` : pour supprimer des tuples dans une table

L'instance de la base est (définitivement) modifiée …pourvu que l'on ait fait un “commit”.

❗ Les contraintes d'intégrité peuvent empêcher `INSERT, UPDATE, DELETE`.

SQL MISES À JOUR

UPDATE

```
UPDATE Prog SET Heure = '21h00'
    WHERE Nom_Cine LIKE 'ugc%' AND Titre= 'Dersou Ouzala';
# Autres expressions possibles:
UPDATE Prog SET Heure = Heure+1;
# les séances seront retardées
UPDATE Produits SET PrixTTC = PrixHT * TVA;
```

Prog avant

NOM_CINE	TITRE	SALLE	HEURE
ugc bercy	Dersou Ouzala	1	20h00
ugc bercy	Dersou Ouzala	2	22h00
ugc bercy	Kagemusha	1	14h00
le champo	Dersou Ouzala	1	18h00
le champo	Kagemusha	1	20h00

Prog après mise à jour

NOM_CINE	TITRE	SALLE	HEURE
ugc bercy	Dersou Ouzala	1	21h00
ugc bercy	Dersou Ouzala	2	21h00
ugc bercy	Kagemusha	1	14h00
le champo	Dersou Ouzala	1	18h00
le champo	Kagemusha	1	20h00

INSERTIONS

INSERT

```
INSERT INTO Prog (Nom_Cine, Titre, Salle, Horaire)
  VALUES ('ugc', 'Dersou Ouzala', 1, '20h00'); % ne pas oublier
  les ' ' pour les chaînes de caractères
```

Préciser les noms de colonnes n'est pas nécessaire ici, mais permet en général

- d'insérer la valeur par défaut (NULL sauf mention explicite d'un autre DEFAULT) pour les colonnes non spécifiées.
- de donner les valeurs dans le désordre.

Selon le SGBD, on trouve des commandes mixtes Update-insert.

SUPPRESSIONS

DELETE

```
DELETE FROM Prog WHERE Heure >= '20h00';
DELETE FROM Prog WHERE Titre in (SELECT Titre FROM Film
  WHERE LOWER(Acteur) Like 'Jean-%');
# Comportements possible en cas de Foreign Key: échec ou cascade.
```

Pour vider complètement une table, TRUNCATE est plus rapide.

```
TRUNCATE Prog;
```

Ne parcourt pas la table. À utiliser avec prudence ! (pas d'entrée dans le journal ⇒ perturbe MVCC, ne déclenche pas les triggers).

LANGAGE DE REQUÊTE

SYNTAXE D'UNE REQUÊTE SQL (SIMPLIFIÉE)

SELECT	*<liste d'attributs>*	attributs du schéma cible ↔ π
FROM	*<liste de relations>*	relations du schéma source
WHERE	*<condition>*	conditions de sélection ↔ σ

Clause `WHERE` optionnelle. Garde les tuples évaluant condition à “`Vrai`”.

Clause `FROM` aussi optionnelle pour PostgreSQL (pas Oracle: `FROM DUAL`)

```
SELECT Nom_Cine FROM Prog WHERE Titre='Marion'
```

```
SELECT 2+3
```

SQL: REQUÊTES SIMPLES

SELECT PROJECT JOIN (SPJ)

```
SELECT * FROM FILM WHERE Acteur='Lonsdale'
```

$$\leftrightarrow \sigma_{Acteur='Lonsdale}(FILM)$$

```
SELECT Titre FROM FILM WHERE Acteur='Lonsdale' OR Acteur='Astaire'
```

$$\leftrightarrow \pi_{titre}(\sigma_{Acteur='Lonsdale' \vee Acteur='Astaire'}(FILM))$$

Sémantique formelle (cas mono-relation):

SELECT $A_1, \ldots, A_k$
FROM R
WHERE C

$$\leftrightarrow \pi_{A_1,\ldots,A_k} \sigma_C (R)$$

ILLUSTRATION DE REQUÊTE SQL: CAS MONO-RELATION

Prog

```
NOM_CINE  TITRE                     SALLE HORAIRE
--------- --------------------- ----- -------
ugc bercy Le discours d'un roi  1     20h00
ugc bercy Le discours d'un roi  2     22h00
ugc bercy Inception             1     14h00
le champo Le discours d'un roi  1     18h00
le champo Inception             1     20h00
```

```sql
SELECT Nom_cine, Titre
FROM Prog
WHERE Nom_cine = 'ugc bercy' AND HORAIRE < 23h00 AND HORAIRE > 10h00
```

```
NOM_CINE  TITRE
--------- ---------------------
ugc bercy Le discours d'un roi
ugc bercy Le discours d'un roi
ugc bercy Inception
```

SQL: REQUÊTE SIMPLE

SELECT PROJECT JOIN (SPJ)

```sql
SELECT Nom_Cine, Film.Titre, Horaire FROM Film,
        Prog WHERE Film.Titre = Prog.Titre AND Acteur = 'M.Freeman'
```

$$\leftrightarrow \pi_{Nom_Cine,\, Film.titre,\, Horaire}(\sigma_{Acteur = 'M.Freeman'}(Film \bowtie Prog))$$

Sémantique formelle (cas multi-relation):

SELECT	$A_1, \ldots, A_k$	$\leftrightarrow$ $\pi^*{}_{A_1,\ldots,A_k}(\sigma_C(R_1^* \times \cdots \times R_p^*))$
FROM	$R_1, \ldots, R_p$	projection multiensembliste
WHERE	C	tous attributs distincts

SQL: REQUÊTE SIMPLE

SELECT PROJECT JOIN (SPJ): AMBIGUÏTÉ SUR LA TABLE D'UN ATTRIBUT

```sql
SELECT Nom_Cine, Film.Titre, Horaire
FROM Film, Prog
WHERE Film.Titre = Prog.Titre AND Acteur = 'M.Freeman'
```

- Table ajoutée automatiquement par le système pour chaque attribut
- Inférence impossible si l'attribut apparait dans plusieurs tables: en ce cas l'utilisateur doit impérativement spécifier la table.

  ↪ *sinon erreur*

ILLUSTRATION DE REQUÊTE SQL: CAS MULTI-RELATION

Prog

```
NOM_CINE  TITRE                SALLE HORAIRE
--------- -------------------- ----- -------
ugc bercy Le discours d'un roi 1     20h00
ugc bercy Le discours d'un roi 2     22h00
ugc bercy Inception            1     14h00
le champo Le discours d'un roi 1     18h00
le champo Inception            1     20h00
```

Cine

```
NOM_CINE  ADRESSE   TELEPHONE
--------- --------- ---------
ugc bercy 3 rue...  06043494
le champo 17 av...  01049059
nef chava 18 bd...  04387953
```

```sql
SELECT Telephone, Horaire FROM Prog, Cine
WHERE Prog.Nom_cine = Cine.Nom_cine AND Titre = 'Inception'
```

```
TELEPHONE HORAIRE
--------- -------
06043494  14h00
01049059  20h00
```

RENOMMAGE D'ATTRIBUTS

ATTR AS ATTR_ALIAS

Intérêt:

- nommer une colonne résultant d'un calcul,
- renommer une colonne de façon plus explicite
- permettre union…

Toutes les personnes ayant participées au tournage du film “Marion”:

```
SELECT Acteur AS Personne FROM Film WHERE Titre = 'Marion'
UNION
SELECT MeS AS Personne FROM Film WHERE Titre = 'Marion'
```

RENOMMAGE DE TABLE

TABLE TABLE_ALIAS

Intérêt:

- distinger plusieurs copies d'une même table
- donner un nom à une table résultant d'un calcul intermédiaire (sous requête) …

Les films avec leur MeS et leurs acteurs dans lesquels joue M-F Pisier ? $\pi_{\text{Titre}}(\sigma_{\text{Actrice}=\text{M}-\text{F.Pisier}}(\textbf{film})) \bowtie \textbf{film}$

```sql
SELECT F2.Titre , F2.MeS, F2.Acteur
FROM FILM F1, FILM F2
WHERE F1.Titre = F2.Titre AND F1.Acteur = 'M-F. Pisier'
```

Interprétations de F1 et F2:

- F1 et F2 sont des copies *virtuelles* de **film**
- F1 et F2 sont des variables utilisées pour désigner n'importe quel couple de n-uplets de **film**

MANIPULATION DES DONNÉES

Élimination des doublons

SELECT DISTINCT

Liste des films projetés dans chaque cinéma:

```sql
SELECT Nom_Cine, Titre
FROM Prog
```

```
NOM_CINE  TITRE
--------- --------------------
ugc bercy Le discours d'un roi
ugc bercy Le discours d'un roi
ugc bercy Le discours d'un roi
ugc bercy Inception
le champo Le discours d'un roi
le champo Inception
```

```sql
SELECT DISTINCT Nom_Cine, Titre
FROM Prog
```

```
NOM_CINE  TITRE
--------- --------------------
ugc bercy Le discours d'un roi
ugc bercy Inception
le champo Le discours d'un roi
le champo Inception
```

OPÉRATIONS SUR LES ATTRIBUTS

Dans la clause SELECT ou dans les conditions une expression peut être:

- une constante
- un attribut
- *expr1* * *expr2* (ou +,-,/)
- une opération sur les chaînes de caractères
  - ch1 || ch2 : concaténation
  - LOWER(ch) : met en minuscules
  - UPPER(ch) : met en majuscules
  - SUBSTR(ch,i,j) : extrait la sous chaîne de longueur *j* débutant à l'indice *i*
- CASE WHEN condition THEN expr ELSE expr END
- ...

```sql
SELECT 3*montant FROM Ventes;
SELECT SUBSTR('ABCDEFG',3,4) FROM DUAL; # (oracle): 'CDEF'
```

CONTENU DE LA CLAUSE WHERE

- *attr* IS NULL
- *expr* op *expr* ∈ (=,<,<=,>=,<>)
- *expr* BETWEEN *val1* AND *val2*
- *expr* IN *(val1,val2,...)*
- *expr* LIKE *string-pattern*
  - % : n'importe quelle chaîne de caractère
  - _ : n'importe quel caractère

Films

```
TITRE                     ACTEUR
------------------------- ------
Rien à Declarer           Boon
La plage                  Canet
Bienvenus chez les ch'tis Boon
```

```
SELECT Titre
FROM Films
WHERE LOWER(Titre) LIKE '%bien%'
  OR Titre LIKE '%declarer%'
# LOWER: convertir en minuscule
```

```
TITRE
-------------------------
Bienvenus chez les ch'tis
```

PIÈGE 1: PRODUIT CARTÉSIEN

Sémantique de la requête ci-dessous $\stackrel{?}{=} R.A \cap (S.A \cup T.A)$?

```
SELECT R.A FROM R,S,T WHERE R.A=S.A OR R.A=T.A
```

PIÈGE 2: NULLS

Sémantique de la requête ci-dessous?

```sql
SELECT P.name FROM Personnes P WHERE P.age > 10 OR P.age <= 10
```

TRIER LE RÉSULTAT DE LA REQUÊTE

Relation = multi-ensemble $\Longrightarrow$ ordre d'affichage dans SQL arbitraire si il n'est pas spécifié.

Liste des films projetés dans chaque cinéma triés par titre:

```sql
SELECT Nom_Cine, Titre
FROM Prog
ORDER BY Titre
```

```
NOM_CINE  TITRE
--------- --------------------
ugc bercy Inception
le champo Inception
ugc bercy Le discours d'un roi
ugc bercy Le discours d'un roi
ugc bercy Le discours d'un roi
le champo Le discours d'un roi
```

```sql
SELECT Nom_Cine, Titre
FROM Prog
ORDER BY Titre DESC,
  Nom_Cine ASC
```

```
NOM_CINE  TITRE
--------- --------------------
le champo Le discours d'un roi
ugc bercy Le discours d'un roi
ugc bercy Le discours d'un roi
ugc bercy Le discours d'un roi
le champo Inception
ugc bercy Inception
```

- tri croissant (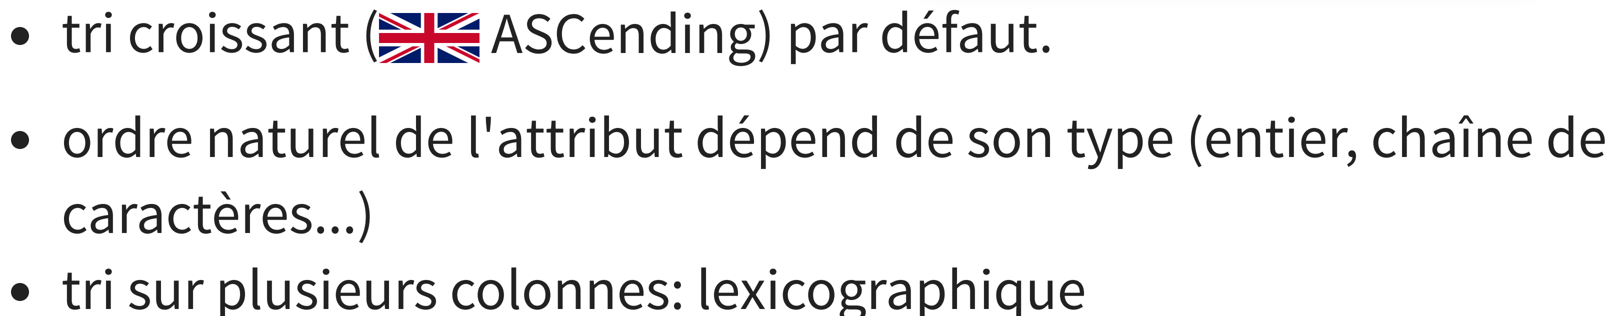 ASCending) par défaut.
- ordre naturel de l'attribut dépend de son type (entier, chaîne de caractères...)
- tri sur plusieurs colonnes: lexicographique

OPÉRATIONS ENSEMBLISTES

OPÉRATIONS ENSEMBLISTES

UNION, INTERSECTION, DIFFÉRENCE

- opérations ensemblistes: éliminent par défaut les doublons
- les relations doivent avoir même schéma
- ajouter `ALL` pour garder les doublons

Les personnes ayant travaillé sur le film 'Marion':

```
SELECT Acteur AS Personne FROM Film WHERE Titre = 'Marion'
  UNION SELECT MeS AS Personne FROM Film WHERE Titre = 'Marion'
```

$$\leftrightarrow \rho_{MeS \to Personne}(\pi_{MeS}(\sigma_{Titre='Marion'}(Film))) \cup$$
$$\rho_{Acteur \to Personne}(\pi_{Acteur}(\sigma_{Titre='Marion'}(Film)))$$

Les personnes ayant travaillé sur le film 'Marion', comptées 1 fois par rôle:

```
SELECT Acteur AS Personne FROM Film WHERE Titre = 'Marion'
            UNION ALL SELECT MeS AS Personne FROM Film WHERE Titre = 'Marion'
```

OPÉRATIONS ENSEMBLISTES (2)

UNION, INTERSECTION, DIFFÉRENCE

Les titres des films à l'affiche dans lesquels a joué M-F Pisier:

```
SELECT Titre FROM Film WHERE Acteur = 'M-F.
            Pisier' INTERSECT SELECT Titre FROM Prog ORDER BY Titre
```

Les titres des films qui ne sont pas à l'affiche:

```
SELECT Titre FROM Film EXCEPT SELECT Titre FROM Prog
```

Remarque: MySQL supporte seulement `UNION`. Certains SGBD utilisent `MINUS` au lieu de `EXCEPT`.

SOUS-REQUÊTES

SOUS-REQUÊTE

Principe: utiliser le résultat d'une requête comme relation ou comme valeur dans une autre requête. Une sous-requête peut apparaître dans les clauses

- WHERE et HAVING
- FROM (en renommant la relation résultante)
- SELECT (à condition de ne retourner qu'une ligne pour chaque ligne de la requête principale)

Supposons que *FILM-DEB(Titre,Acteur)* stocke le titre du premier film de chaque acteur. Les acteurs du premier film joué par M-F. Pisier:

```
SELECT Acteur FROM FILM WHERE Titre =
              (SELECT Titre FROM FILM-DEB WHERE Acteur = 'M-F. Pisier')
```

SOUS-REQUÊTE

SOUS-REQUÊTE DANS LE FROM

Les acteurs ayant joué avec M-F.Pisier dans le même film:

```
SELECT Acteur FROM FILM,
          (SELECT Titre FROM Film Where Acteur = 'M-F. Pisier') F2
          WHERE Film.Titre = F2.titre
```

SOUS-REQUÊTE AVEC OPÉRATEUR

SOUS-REQUÊTE À PLUSIEURS LIGNES DANS LA CLAUSE `WHERE/HAVING`

Opérateurs exprimant des conditions avec des sous requêtes pouvant retourner plusieurs lignes:

- *attr* `IN` *sous-requête* vrai si la valeur apparaît dans le résultat de la sous-requête
- `EXISTS` *sous-requête* vrai si le résultat de la sous-requête contient au moins un tuple
- *attr* `op` `ANY` *sous-requête* vrai si il existe une valeur dans le résultat de la sous-requête qui satisfait la comparaison
- *attr* `op` `ALL` *sous-requête* vrai si toutes les valeurs dans le résultat de la sous-requête satisfont la comparaison

avec `op` $\in \{=, <, >, <=, >= \neq\}$

aussi : `NOT IN`, `NOT EXISTS`

SOUS-REQUÊTES

OPÉRATEUR IN

Les titres des films dont un des MeS est acteur (pas forcément dans le même film):

```
SELECT DISTINCT Titre FROM FILM
              WHERE MeS IN (SELECT Acteur FROM FILM)
```

Formulation équivalente sans sous-requête?

SOUS-REQUÊTES

OPÉRATEUR EXISTS

Les films dirigés par au moins deux metteurs en scène:

```
SELECT DISTINCT F1.Titre FROM FILM F1
  WHERE EXISTS (SELECT F2.MeS FROM FILM F2
    WHERE F1.Titre=F2.Titre AND NOT F1.MeS=F2.MeS)
```

Remarque: on a ici une requête *corrélée*.

Formulation équivalente sans sous-requête?

SOUS-REQUÊTES

COMPARAISON AVEC ALL

Les films projetés à l'UGC plus tard que tous les films projetés au Trianon.

```
SELECT DISTINCT Titre FROM PROG
  WHERE Nom_Cine='UGC' AND
    Horaire > ALL (SELECT Horaire FROM PROG WHERE Nom_Cine='Trianon')
```

Formulation équivalente sans sous-requête ?

SOUS-REQUÊTES

COMPARAISON AVEC ANY

Le téléphone des cinémas proposant une programmation après 23h:

```
SELECT Telephone FROM CINE AS C1
  WHERE 23 < ANY ( SELECT Horaire FROM PROG
    WHERE C1.Nom_Cine=PROG.Nom_Cine)
```

SOUS-REQUÊTES

PRÉCISIONS SUR LA SÉMANTIQUE DE IN/NOT IN/=ANY

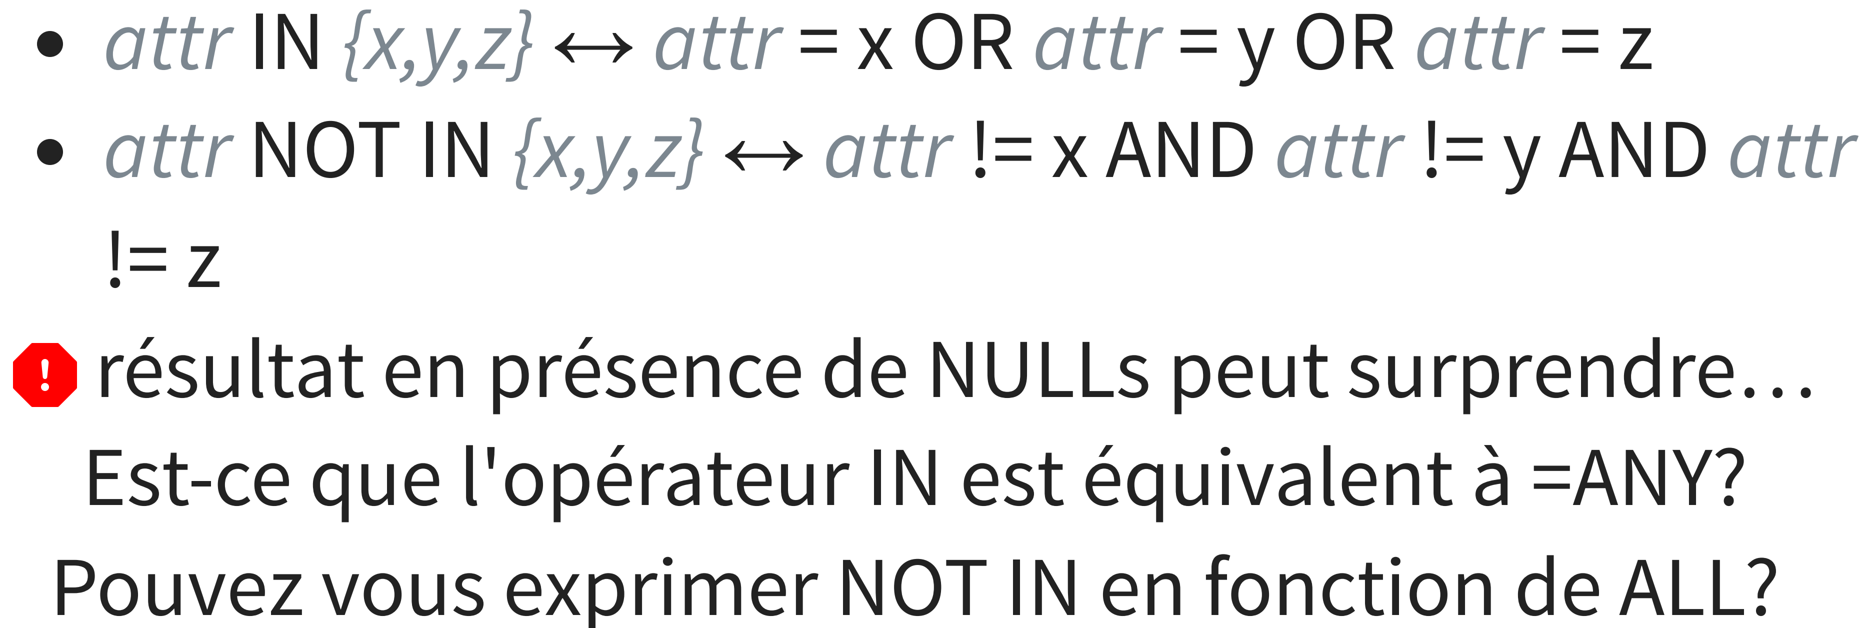

JOINTURES

JOINTURES EN SQL

DIFFÉRENTS TYPES DE JOINTURE

Rappel :

- Produit cartésien :

```
SELECT R.a,S.b
       FROM R,S
```

- Jointure :

```
SELECT R.a,S.b
       FROM R,S
       WHERE R.c=S.c
```

On peut utiliser d'autres types de jointures !

equi-jointure : condition de jointure est une égalité

↪ *c'est le cas le plus courant : ± tous les examples de ce cours.*

non equi-jointure : condition de jointure n'est pas une égalité : $>, \ldots,$ LIKE

Très souvent lorsque l'on parle de jointures on parle des équijointures.

Même pour des équijointures, il existe plusieurs formulations en SQL.

JOINTURES EN SQL

DIFFÉRENTS TYPES DE JOINTURE EN SQL

Instructions SQL pour spécifier le type de jointure :

- jointures internes : `(INNER) JOIN`
- jointures externes : `LEFT/RIGHT/FULL(OUTER) JOIN`
- produit cartésien : `CROSS JOIN`

Instructions SQL pour spécifier les conditions de jointure :

- … `JOIN` … `ON`: le plus général, condition quelconque (pas forcément equi-jointure), colonnes non fusionnées.
- … `JOIN` … `USING` : jointure naturelle restreinte aux attributs listées, colonnes fusionnées.
- `NATURAL JOIN` … : jointure naturelle sur toutes les colonnes de même nom.

Syntaxe jugée plus lisible qu'un produit cartésien suivi d'une sélection dans la clause WHERE, et (à peu près) indispensable pour les jointures externes.

JOINTURES EN SQL

JOINTURE INTERNE

```
SELECT F1.Titre, F2.Acteur FROM FILM F1
    INNER JOIN FILM F2 ON F1.Titre = F2.Titre
        WHERE F1.Acteur = 'M-F. Pisier'
```

Le mot-clé INNER est facultatif : lorsque l'on écrit une jointure sans en préciser le type(JOIN) c'est bien INNER JOIN qui est calculé.

JOINTURES EN SQL : PLUSIEURS TABLES

JOINTURE INTERNE

```
SELECT Film.Titre, Pers.nom, Pers.taille
    FROM Film JOIN Programme Prog ON Film.Titre = Programme.Titre
        JOIN Personne Pers ON Film.acteur = Pers.nom
```

Pourquoi la requête ci-dessous ne calcule-t-elle pas les triplets d'acteurs distincts qui ont collaboré sur un film?

```
SELECT F1.Titre, F1.Acteur, F2.Acteur, F3.Acteur
    FROM FILM F1 JOIN FILM F2 ON F1.Titre = F2.Titre
        JOIN FILM F3 ON F1.Titre = F3.Titre
            WHERE F1.Acteur != F2.Acteur AND F1.Acteur != F3.Acteur
```

JOINTURES EN SQL

JOINTURE NATURELLE

```
SELECT Nom_Cine,Film.Titre, Horaire FROM Film NATURAL JOIN Prog
    WHERE Acteur = 'M.Freeman'
```

Jointure naturelle sur tous les attributs communs. On peut restreindre la jointure naturelle à un sous ensemble (*attr_a*, *attr_b*, …, *attr_c*) des attributs communs avec la syntaxe:

```
# préciser les attributs d'une jointure naturelle est recommandé
# (par ex: le schéma risque de changer par la suite)
SELECT attr_a, attr_b, nom_table1.attr1... FROM nom_table1
    INNER JOIN nom_table2 USING(attr_a,attr_b,...,attr_c)
```

JOINTURES EN SQL

JOINTURE EXTERNE

```
SELECT attr1, attr2,... FROM nom_table1
    LEFT OUTER JOIN nom_table2 USING(attr_a,attr_b,...,attr_c)
```

Permet d'afficher additionnellement les lignes de la table gauche (à gauche du mot clé JOIN) qui n'ont pas de ligne correspondante à droite pour la jointure, en complétant par des NULL à droite.

- `RIGHT OUTER JOIN`: affiche les lignes de la table droite sans correspondance
- `FULL OUTER JOIN`: affiche les lignes des tables gauche ou droite sans correspondance

JOINTURES EN SQL

JOINTURE EXTERNE

Roles

```
TITRE                     ID_ACT  PERSONNAGE
------------------------- ------- ---------------
It's a Wonderful Life     35      George Bailey
It's a Wonderful Life             Mary Bailey
It's a Wonderful Life     36      Clarence Odbody
Rear Window               35      LB Jeffries
The Shawshank Redemption  40      red
```

Acteur

```
ID NOM      PRENOM
-- -------- ------
35 Stewart  James
40 Freeman  Morgan
50 Serrault Michel
```

```sql
SELECT titre, personnage, nom FROM roles LEFT OUTER JOIN acteurs ON id_act=id;
```

```
TITRE                     PERSONNAGE      NOM
------------------------- --------------- -------
Rear Window               LB Jeffries     Stewart
It's a Wonderful Life     George Bailey   Stewart
The Shawshank Redemption  red Freeman
It's a Wonderful Life     Mary Bailey
It's a Wonderful Life     Clarence Odbody
```

JOINTURES EN SQL

JOINTURE EXTERNE

Roles

```
TITRE                     ID_ACT  PERSONNAGE
------------------------- ------- ---------------
It's a Wonderful Life     35      George Bailey
It's a Wonderful Life             Mary Bailey
It's a Wonderful Life     36      Clarence Odbody
Rear Window               35      LB Jeffries
The Shawshank Redemption  40      red
```

Acteur

```
ID NOM      PRENOM
-- -------- ------
35 Stewart  James
40 Freeman  Morgan
50 Serrault Michel
```

```
SELECT titre, personnage, nom FROM roles FULL OUTER JOIN acteurs ON id_act=id;
```

```
TITRE                     PERSONNAGE      NOM
------------------------- --------------- -------
It's a Wonderful Life     George Bailey   Stewart   <- in both
Rear Window               LB Jeffries     Stewart   <- in both
The Shawshank Redemption  red             Freeman   <- in both
It's a Wonderful Life     Mary Bailey               <- in LEFT OUTTER JOIN
It's a Wonderful Life     Clarence Odbody           <- in LEFT OUTTER JOIN
                                          Serrault  <- in RIGHT OUTTER JOIN
```

AGRÉGATS

FONCTIONS D'AGRÉGATION

But: résumer les données en regroupant les tuples.

Exemple: calculer le nombre de film pour chaque réalisateur.

SELECT	*<liste d'attributs>*	attributs du schéma cible
FROM	*<liste de relations>*	relations du schéma source
WHERE	*<condition>*	conditions de sélection
GROUP BY	*<liste d'attributs>*	attributs de regroupement
ORDER BY	*<liste d'attributs>*	ordre d'affichage

FONCTIONS D'AGRÉGATION: PRINCIPE DU REGROUPEMENT

Film

```
TITRE                     ACTEUR
------------------------- ---------
Rien à Declarer           Boon      <--
Brice de Nice             Cornillac
La vie de Chantier        Boon      <--
Ensemble c'est tout       Canet
Mon Idole                 Canet
The dark knight rises     Cotillard
Les petits mouchoirs      Cotillard
La plage                  Canet
Inception                 Cotillard
Bienvenus chez les ch'tis Boon      <--
```

```sql
SELECT acteur, COUNT(*)
   FROM film GROUP BY acteur
```

```
    ACTEUR    COUNT(*)
    --------  --------
    Canet     3
    Cotillard 3
--> Boon      3
    Cornillac 1
```

Les tuples ayant même valeur de groupement sont regroupés sur une ligne

- la fonction est calculée pour chaque groupe indépendamment
- si fonction d'agrégation sans `GROUP BY`: 1 groupe=table entière
- les attributs hors du `GROUP BY` ne peuvent apparaître dans `SELECT` qu'à l'intérieur d'une fonction d'agrégation

FONCTIONS D'AGRÉGATION (2)

Film

```
TITRE                ACTEUR    QT
-------------------- --------  --
Rien à Declarer      Boon      2
Brice de Nice        Cornillac 5
La vie de Chantier   Boon      7
Ensemble c'est tout  Canet     2
Mon Idole            Canet     3
```

Exemple de requête avec agrégat sans GROUP BY...
Attention: la clause WHERE filtre les données *avant* la création des groupes.

```
SELECT COUNT(*) c, SUM(QT) s FROM film
```

```
c | s
--+--
5 | 19
```

```
SELECT SUBSTR(MAX(Titre),0,4) mx,
  SUM(QT)/COUNT(*) s
    FROM t WHERE Titre>'L'
```

```
 mx | s
----+---
Rie | 4
```

FONCTIONS D'AGRÉGATION : ORDRE

Ordre d'évaluation intuitif des clauses :

- FROM
- WHERE
- GROUP BY
- HAVING
- SELECT
- ORDER BY

Donner le résultat de la requête:

```
SELECT acteur, nomrealisateur, COUNT(*) NB
FROM film
WHERE acteur < 'D'
GROUP BY acteur, nomrealisateur
ORDER BY NB
```

Film

```
TITRE                     ACTEUR    NOMREALISATEUR
------------------------- --------- --------------
Les petits mouchoirs      Cotillard Canet
La plage                  Canet     Boyle
Mon Idole                 Canet     Canet
The dark knight rises     Cotillard Nolan
La vie de Chantier        Boon      Boon
Brice de Nice             Dujardin  Dujardin
Ensemble c'est tout       Canet     Canet
Gran Torino               Eastwood  Eastwood
Inception                 Cotillard Nolan
Brice de Nice             Cornillac Dujardin
```

COUNT

QUE COMPTER ?

- `COUNT(*)` retourne le nombre de lignes.
- `COUNT(a)` retourne le nombre de lignes non nulles sur colonne *a*.
- `COUNT(DISTINCT a)` retourne le nombre de valeurs *distinctes* sur la colonne *a*.

Film

```
titre                | acteur    | nomrealisateur
---------------------+-----------+---------------
Green Book           | Mortensen | Farrelly
Seigneur des Anneaux | Mortensen | Jackson
Coda                 | Jones     | Heder
Nomadland            |           |Zhao
```

```
SELECT COUNT(*) A,
  COUNT(acteur) B,
  COUNT(DISTINCT acteur) C
FROM film
WHERE Titre != 'Coda'
```

```
a | b | c
--+---+---
3 | 2 | 1
```

Compter en SQL les acteurs que chaque réalisateur a encadré :

Il est possible de calculer `SUM(DISTINCT a)`, `AVG(DISTINCT a)`.

AUTRES FONCTIONS D'AGRÉGATION

Nb_Films_Joués

```
ACTEUR    NB_FILMS
--------  --------
Canet     3
Cotillard 3
Boon      3
Cornillac 1
```

Calculer dans une même requête le nombre maximal et moyen de films par acteur.

Résultat attendu:

```
NB_MAX  NB_MOY
------  ------
3       2.5
```

CONDITIONS SUR LES GROUPES

HAVING

SELECT	*<liste d'expressions1>*	attributs du schéma cible
FROM	*<liste de relations>*	relations du schéma source
WHERE	*<conditions1>*	conditions de sélection
GROUP BY	*<liste d'attributs>*	attributs de regroupement
HAVING	*<conditions2>*	conditions sur les groupes
ORDER BY	*<liste d'expressions2>*	ordre d'affichage

avec *<liste d'expressions1>* incluse dans *<liste d'attributs>* sauf pour les colonnes calculant une fonction d'agrégation.

AGRÉGATS SQL: SÉMANTIQUE (1)

```
SELECT    ... <-- évalué une fois par groupe (pas par ligne)
FROM      ...
GROUP BY  A_1
HAVING    ... <-- évalué une fois par groupe (pas par ligne)
```

```
                  A_1  | A_2  | ...
                  ---- + ---- + ---
                  ...  | ...  | ...   Le regroupement
                  ---- + ---- + ---   partitionne les bindings
the x_i group --> x_i  | y_i1 | ...   de lignes :
the x_i group --> x_i  | y_i2 | ...     - il n'y a pas de
                  ---- + ---- + ---       groupe vide
the x_j group --> x_j  | y_j1 | ...     - chaque ligne
the x_j group --> x_j  | y_j2 | ...       appartient à
                  ---- + ---- + ---       exactement un groupe
                  ...  | ...  | ...
```

AGRÉGATS SQL: SÉMANTIQUE (2)

Agrégat: opérateur commutatif et associatif (à qques détails près).

Pour calculer agg (comme *fold* en programmation fonctionnelle): on initialise un accumulateur à la valeur z^{agg}.

Aggregate agg	$\emptyset^{agg}$	z^{agg}	$\oplus^{agg}(a, x)$
COUNT	0	0	$a + 1$
SUM	NULL	0	$a + x$
AVG	NULL	$\langle 0, 0 \rangle$	$\langle a.1 + x, a.2 + 1 \rangle$
MAX	NULL	$-\infty$	$max_2(a, x)$
MIN	NULL	$+\infty$	$min_2(a, x)$
bool_and	NULL	true	$a \wedge x$
bool_or	NULL	false	$a \vee x$
…	…	…	…

source: cours de Torsten Grust

AGRÉGATS SQL: EXEMPLES

```sql
SELECT a, b, count(*), max(c)
FROM t GROUP BY a, b
# nothing special there
```

```sql
SELECT a, count(*)
FROM t
GROUP BY a, b
# sometimes it makes sense not to display b
```

```sql
SELECT a, sum(a), max(b+d)
FROM t
GROUP BY a
/* we can group *and* aggregate on a
though it seldom makes sense */
```

```sql
SELECT a, b, sum(a)
FROM t
GROUP BY a
/* Incorrect query:
b is not a group by expression */
```

Lorsqu'il existe une dépendance fonctionnelle a → b, certains SGBD (ex : PostgreSQL) peuvent la tolérer, mais ce n'est pas sûr (partie optionnelle de la norme SQL) ; vous devez donc inclure b dans le regroupement, si c'est votre intention.

NULLS IN SQL AGGREGATES

Aggregates (SUM, AVG, MAX) ignore null values.

Propose a table where c1 and c2 will differ:

```
SELECT SUM(a) + SUM(b) c1, SUM(a+b) c2 FROM t;
```

QUELQUES OUTILS TECHNIQUES

GUILLEMETS: SIMPLE OU DOUBLE

```
SELECT a FROM t; # la colonne nommée a
SELECT 'a'; # constant string 'a'
CREATE TABLE "ma table" ("select" int); # identificateur entre guillemets
SELECT "select" from "ma table"; # faisable mais à éviter.
```

Intérêt d'un identificateur entre guillemets (“quoted identifier”):

- sensible à la casse
- permet d'utiliser des espaces
- permet d'échapper des mots clés réservés par le SGBD

Mais je ne recommande pas de les utiliser, et recommande d'éviter les mélanges.

Remarque: les identifiants qui ne sont pas entre guillements sont par défaut convertis en minuscules sous postgresql, en majuscule sous oracle.

Dans une requête SQL, le symbole d'échappement est :

```
SELECT Titre FROM Film WHERE Acteur = 'O”Brien'; # cherche O'Brien
```

Mais les applications utilisent plus souvent une requête préparée avec paramètres.
Pour plus d'informations (ex: comment échapper des caractères):
https://docs.postgresql.fr/16/sql-syntax.html

LES SCHÉMAS SOUS POSTGRESQL

Un cluster de BD postgresql contient une ou plusieurs BD. Chaque BD comporte un ou plusieurs schémas.

```
CREATE SCHEMA mon_schema;
CREATE TABLE mon_schema.t(id int) # voir: base.schema.table
SELECT a FROM mon_schema.t;

CREATE SCHEMA mon_schema2;
CREATE TABLE mon_schema2.t(id int) # valide car pas dans le même schéma
# DROP SCHEMA mon_schema CASCADE; # pour effacer un schéma non-vide
```

- Par défaut, schéma public
- En général on évite les noms qualifiés. Le schéma utilisé sera le premier dans le chemin de parcours:

```
SET search_path TO mon_schema, mon_schema2, public;
SHOW search_path; # SELECT * FROM t utilisera la table dans mon_schema
```

```
search_path
-----------------------------------
mon_schema, mon_schema2, public;
```

LES SÉQUENCES

Compteur que l'on va pouvoir incrémenter pour générer une suite de nombres.

Sert en particulier pour générer des identifiants.

```
CREATE SEQUENCE serie INCREMENT BY 100 START 101;
SELECT nextval('serie'); # 101
SELECT currval('serie'); # le résultat du dernier nextval: ici, 101
```

Outils similaires sous Oracle, MariaDB, MySQL, SQL Server…

```
CREATE TABLE t ( a SERIAL, b string );
# revient à
CREATE SEQUENCE t_a_seq;
CREATE TABLE t ( a NOT NULL DEFAULT nextval('t_a_seq'), b string );
```

COMPORTEMENTS SPÉCIFIQUES À CERTAINS SGBDS (NON EXHAUSTIF)

Je déconseille fortement d'utiliser ces particularités:

- PostgreSQL:

```
SELECT country FROM cities GROUP BY city;
# valid if city is PK.
# Or more generally FD city -> country
# Optional extensions of standard
```

- MySQL, MariaDB (InnoDB engine):

```
cities(id, city, country) ...
FOREIGN KEY REFERENCES (cities.country)
# FK referencing a non unique column!
# Non standard
```

- PostgreSQL, MySQL, MariaDB

```
SELECT a AS bbb FROM t GROUP BY bbb;
```