

Aspects logiques

Cours L3 – Bases de Données

Louis Jachiet

ENS

Slides adaptées depuis celle de Serge Abiteboul

Introduction

Un *modèle* de base de données c'est :

- un modèle de définition de données
- un langage de manipulation de données (langage de requête)

Nous allons voir aujourd'hui deux grandes familles de modèles :

- ceux similaires au modèle conjonctif
- ceux similaires au modèle relationnel

Et pour chaque :

- différents modèles de données : relations nommées ou non, faits
- différents modèles de langages de requêtes : algèbre, calcul, programmation logique

Et montrer que tous les modèles de chaque famille sont équivalents !

Rappels : le langage de définition de données relationnel

- **dom** ou **domaine** l'ensemble des valeurs contenues dans la BD
- **att** ou **attribut** un couple “nom de relation” - “type des valeurs”
- **var** ou **variable**
- **sort(R)** l'ensemble des attributs de la relation R

Rappels : exemple

Cinémas		
Nom	Adresse	nbSalles
"La Nef"	"bd Édouard Rey"	7
"Le Méliès"	"caserne de Bonne"	3
"Le Club"	"rue Phalanstère"	3

Casting		
Film	Nom	Rôle
"Inception"	"Ellen Page"	Acteurice
"Inception"	"Leonardo DiCaprio"	Acteurice
"Inception"	"Christopher Nolan"	Réalisateurice
"Toy Story 3"	"Tom Hanks"	Acteurice
"Mamma Mia"	"Meryl Streep"	Acteurice
"Mamma Mia"	"Phyllida Lloyd"	Réalisateurice

Séances		
Titre	Date	Cinéma
"Inception"	12/08/2010 20h	"Le Méliès"
"Toy Story 3"	13/08/2010 17h	"Le Club"
"Toy Story 3"	13/08/2010 20h	"Le Club"
"Toy Story 3"	10/08/2010 17h	"Le Méliès"
"Akmareul boatda"	10/08/2010 16h	"Le Club"
"How to train your dragon"	12/03/2010 18h	"Pathé Chavant"

$sort(Cinémas) = \{Nom, Adresse, nbSalles\}$

$sort(Séances) = \{Titre, Date, Cinéma\}$

$sort(Casting) = \{Film, Nom, Rôle\}$

Rappels : schéma de BD

Schéma de BD

Schéma d'une BD c'est un ensemble de **relname** avec pour chaque un schéma de relation (le schéma d'un relation R c'est l'ensemble d'attributs $sort(R)$). Parfois on ajoute aussi le domaine D que peuvent prendre les valeurs. Formellement c'est donc un triplet $(D, R, Sort)$ (ou une paire $(R, Sort)$) avec R fini mais pas généralement D est infini.

Instance d'une relation

Étant donnée une relation R d'attributs $(c_1, t_1), \dots, (c_n, t_n)$, une instance de R est un ensemble de n -uplets $(v_1^1, \dots, v_n^1), \dots, (v_1^k, \dots, v_n^k)$ tel que pour tout $1 \leq i \leq n, 1 \leq j \leq k$ on ait que $v_i^j \in t_i$

Instance d'une BD

Il s'agit d'une fonction qui associe à chaque **relname** R une instance de R compatible avec le schéma de R .

Variantes possibles

- Il est possible de supprimer la contrainte de typage !
- Il est aussi possible de supprimer les noms des attributs !
- Considérer simplement un ensemble de faits :
 $\{ \text{Cinémas}(\text{" La Nef" , bd Édouard Rey" , 7}),$
 $\text{Séances}(\text{" Inception" , " 12/08/2010 20h" , " Le Méliès" },$
 $\dots \}$

Requêtes conjonctives : intuition

Quels sont les noms et adresses des cinémas projetant un film du réalisateur Bergman ?

Schéma

- Cinémas(Nom, Adresse, nbSalles)
- Casting(Film, Nom, Rôle)
- Séances(Titre, Date, Cinéma)

Variables $\in dom^n$ (Tuple relational calculus [Cod72])

si $cine \in Cinémas$, $proj \in Séances$, $cast \in Casting$ sont tels que :
 le Rôle dans $cast$ est Réalisateurice et le Nom est "Bergman"
 et le Titre dans $proj$ et Film dans $cast$ sont les mêmes
 et Cinéma dans $proj$ et Nom dans $cine$ sont les mêmes
 alors nous voulons la Cinéma de $proj$ et Adresse de $cine$.

Requêtes conjonctives : intuition

Quels sont les noms et adresses des cinémas projetant un film du réalisateur Bergman ?

Schéma

- Cinémas(Nom, Adresse, nbSalles)
- Casting(Film, Nom, Rôle)
- Séances(Titre, Date, Cinéma)

variables $\in dom$ (Domain relational calculus [Lacroix, Pirotte])

si $\langle Film : x_{ti}, Nom : "Bergman", R\acute{o}le : R\acute{e}alisateurice \rangle \in Casting$,
 et $\langle Cin\acute{e}ma : x_{sa}, Titre : x_{ti}, Date : x_{da} \rangle \in S\acute{e}ance$
 et $\langle Nom : x_{sa}, Adresse : x_{ad}, nbSalles : x_{nb} \rangle \in Cin\acute{e}mas$,
 alors inclure le n -uplet $\langle Cin\acute{e}ma : x_{sa}, Adresse : x_{ad} \rangle$ dans la r\ep{e}ponse,
 o\ug{u} x_{ti}, x_{da}, \dots sont des variables.

Requêtes conjonctives : intuition

Quels sont les noms et adresses des cinémas projetant un film du réalisateur Bergman ?

Schéma

- Cinémas(Nom,Adresse, nbSalles)
- Casting(Film,Nom,Rôle)
- Séances(Titre,Date,Cinéma)

En utilisant des règles logiques (Non-recursive conjunctive datalog)

$$\text{sol}(x_{sa}, x_{ad}) \leftarrow \text{Cinéma}(x_{sa}, x_{ad}, x_{nb}),$$

$$\text{Casting}(x_{ti}, \text{"Bergman"}, \text{Réalisateurice}),$$

$$\text{Séance}(x_{ti}, x_{da}, x_{sa})$$

Règles conjonctives (nrc-datalog)

Une *règle* conjonctive sur \mathbf{R} est une expression q de la forme :

$$ans(u) \leftarrow R_1(u_1), \dots, R_n(u_n)$$

- $n \geq 0$, $R_1, \dots, R_n \in \mathbf{R}$
- $ans \notin \mathbf{R}$
- u, u_1, \dots, u_n n -uplets libres (i.e., variables + constantes) de bonnes arités ($|u_i| = |sort(R)|$)
- chaque variable apparaissant dans u doit aussi apparaître au moins une fois dans u_1, \dots, u_n .

$R_1(u_1), \dots, R_n(u_n)$: *corps*

$ans(u)$: *tête*.

Intuition : usine à fournir des faits

Requêtes conjonctives

Étant donné \mathcal{V} un ensemble de variables, une *valuation* est une fonction ν de \mathcal{V} dans **dom**. Pour chaque constante a , $\nu(a) = a$

Pour un schéma **S**, une requête q compatible avec **S** et une instance **I** de **S** on définit :

$$q(\mathbf{I}) = \{ \nu(u) \mid \nu \text{ est une valuation sur } \text{var}(q) \text{ et } \nu(u_i) \in \mathbf{I}(R_i), \\ \text{pour chaque } i \in [1, n] \}.$$

Domaine actif : $\text{adom}(\mathbf{I})$ est l'ensemble des constantes apparaissant dans **I** ; de la même manière $\text{adom}(q)$ est l'ensemble des constantes de q et

$$\text{adom}(q, \mathbf{I}) = \text{adom}(q) \cup \text{adom}(\mathbf{I})$$

$$\text{adom}(q(\mathbf{I})) \subseteq \text{adom}(q, \mathbf{I}) \text{ (donc } q(\mathbf{I}) \text{ est fini)}$$

Une autre syntaxe : Calcul conjonctif

Requête :

$$ans(x_{sa}, x_{ad}) \leftarrow \begin{array}{l} \text{Cinéma}(x_{sa}, x_{ad}, x_{nb}), \\ \text{Casting}(x_{ti}, \text{" Bergman"}, \text{Réalisateurice}), \\ \text{Séance}(x_{ti}, x_{da}, x_{sa}) \end{array}$$

Les virgules sont à lire comme des conjonctions (\wedge) les variables qui ne sont pas dans la tête sont supposées quantifiées existentiellement (\exists)

En calcul conjonctif :

$$\{x_{sa}, x_{ad} \mid \exists x_{ti} \exists x_{nb} \exists x_{da} \text{ Cinéma}(x_{sa}, x_{ad}, x_{nb}) \wedge \\ \text{Casting}(x_{ti}, \text{" Bergman"}, \text{Réalisateurice}) \wedge \\ \text{Séance}(x_{ti}, x_{da}, x_{sa})\}$$

Imbrication : Elle s'exprime aussi par :

$$\{x_{sa}, x_{ad} \mid \exists x_{ti} (\exists x_{nb} \text{ Cinéma}(x_{sa}, x_{ad}, x_{nb})) \wedge \\ \text{Casting}(x_{ti}, \text{" Bergman"}, \text{Réalisateurice}) \wedge \\ (\exists x_{da} \text{ Séance}(x_{ti}, x_{da}, x_{sa}))\}$$

Algèbre PSJR

L'algèbre est un **langage procédural (algèbre)** (on décrit comment récupérer ce que l'on veut) et non plus **déclaratif** (on décrit ce que l'on veut). Mais relativement facile à implanter.

Atomes de l'algèbre :

- ① R : une relation (existante dans le schéma)

Opérations de l'algèbre :

- ② Projection Π_p : ne garder que certaines colonnes
- ③ Sélection σ_f : enlever des lignes suivant un critère (égalité entre deux valeurs ou entre une valeur et une constante)
- ④ Jointure \bowtie : faire un pont entre deux tables
- ⑤ Renommage $\rho_{a/b}$: renommer attributs d'une table

Pas de négation ou d'union dans le langage !

Algèbre PSJR

R	
A	B
1	2
4	2
6	6
7	7
1	7
1	6

S	
B	C
2	3
2	5
9	1
8	8

$R \bowtie S$		
A	B	C
1	2	3
1	2	5
4	2	3
4	2	5

$\sigma_{A=1}(R)$	
A	B
1	2
1	7
1	6

$\rho_{B/B',C/A}(S)$	
B'	A
2	3
2	5
9	1
8	8

$\pi_A(R)$	
A	
1	
4	
6	
7	

Atomes

$$R(I) = R$$

Sélection

$\sigma_{A=c}$ et $\sigma_{A=B}$, ($A, B \in \mathbf{att}$, $a \in \mathbf{dom}$)

$$\sigma_{A=c}(I) = \{t \in I \mid t(A) = c\} \text{ et } \sigma_{A=B}(I) = \{t \in I \mid t(A) = t(B)\}.$$

Projection

π_{A_1, \dots, A_n} ($n \geq 0$, $A_1, \dots, A_n \in \mathbf{att}$)

$$\pi_{A_1, \dots, A_n}(I) = \{\langle A_1 : t(A_1), \dots, A_n : t(A_n) \rangle \mid t \in I\}$$

$$\pi_{A_1, \dots, A_n}(I) = \{t|_{A_1, \dots, A_n} \mid t \in I\}.$$

Algèbre PSJR

Jointure (Naturelle)

$$\text{sort}(I) = V, \text{sort}(J) = W, \text{sort}(I \bowtie J) = V \cup W$$

$$I \bowtie J = \{t \text{ sur } V \cup W \mid \text{pour } v \in I \text{ et } w \in J, t|_V = v \text{ et } t|_W = w\}$$

Quand $\text{sort}(I) = \text{sort}(J)$, alors $I \bowtie J = I \cap J$

Quand $\text{sort}(I) \cap \text{sort}(J) = \emptyset$ alors $I \bowtie J = I \times J$ (produit cartésien).

Renommage

utilise une fonction injective de $U = A_1 \dots A_n$ dans **att** que l'on notera $A_1/B_1, \dots, A_n/B_n$.

$$\rho_{A_1/B_1, \dots, A_n/B_n}(I) = \{v \text{ sur } B_1, \dots, B_n \mid \begin{array}{l} \text{pour } u \in I, \text{ et } v(B_i) = u(A_i) \\ \text{pour tout } i \in [1..n] \end{array} \}$$

Théorème d'équivalence

Théorème de Codd

q est exprimable comme une règle conjonctive
 ssi q est exprimable dans le calcul conjonctif
 ssi q est exprimable dans l'algèbre PSJR

Preuve

- Règle \Rightarrow Calcul : évident
- Calcul \Rightarrow Algèbre : \exists par projection, \wedge par jointure
- Algèbre \Rightarrow Règle : plus subtil, on se ramène à la forme

$$\pi_{j_1, \dots, j_n}(\sigma_{\gamma_1}(\rho_{f_1}(R_1) \bowtie \dots \bowtie \sigma_{\gamma_n}(\rho_{f_n}(R_n))))$$

en utilisant, des équivalences algébriques

Equivalences algébriques

- 1 pousser les renommages
- 2 pousser les filtres (attention aux conflits de constantes)
- 3 faire remonter les projections

Exemples

$$\sigma_F(\sigma_{F'}(q)) \leftrightarrow \sigma_{F'}(\sigma_F(q))$$

$$\pi_X(\pi_Y(q)) \leftrightarrow \pi_{X \cap Y}(q)$$

$$\sigma_F(\pi_X(q)) \leftrightarrow \pi_X(\sigma_F(q)) \quad \text{si } F \text{ porte sur des attributs de } X$$

$$q_1 \bowtie q_2 \leftrightarrow q_2 \bowtie q_1$$

$$\sigma_F(q_1 \bowtie q_2) \rightarrow \sigma_F(q_1) \bowtie q_2 \quad \text{si } F \text{ porte sur des attributs de } q_1$$

$$\sigma_{A=B}(q_1 \bowtie q_2) \rightarrow q_1 \bowtie \rho_{A/B}(q_2) \quad \text{si } A \in \text{sort}(q_1), B \in \text{sort}(q_2), \\ A \notin \text{sort}(q_2)$$

$$\pi_X(q_1) \bowtie \pi_X(q_2) \rightarrow \pi_X(q_1 \bowtie q_2) \quad \text{si } \text{sort}(q_1) \cap \text{sort}(q_2) \subseteq X$$

Quelques propositions

- Les requêtes exprimables comme des règles conjonctives sans constantes sont satisfaisables : pour tout q , il existe I tel que $q(I) \neq \emptyset$.
 - Avec constantes : $\sigma_{A=0}(R) \bowtie \sigma_{A=1}(R)$ Non !
- Les requêtes conjonctives sont monotones : pour tout I, J , pour tout q ,

$$I \subseteq J \Rightarrow q(I) \subseteq q(J)$$

- Fermeture sous composition (vues)

$$S_1(x, z) \leftarrow Q(x, y), R(y, z, w)$$

$$S_2(x, y, z) \leftarrow S_1(x, w), R(w, y, v), S_1(v, z)$$

$$S_3(x, z) \leftarrow S_2(x, u, v), Q(v, z)$$

Peut être obtenu directement :

$$S_3(x, z) \leftarrow Q(x, y_1), R(y_1, w, w_1), R(w, u, v_1), \\ Q(v, y_2), R(y_2, v, w_2), Q(v, z)$$

Vues

La stabilité par composition permet de créer des vues.
Par exemple :

$$\begin{aligned} \mathit{Films} &= \rho_{\text{Nom}/\text{Real}}(\pi_{\text{Titre},\text{Nom}}(\sigma_{\text{rôle}=\text{réalisateurice}}(\text{Casting}))) \\ &\bowtie \rho_{\text{Nom}/\text{Act}}(\pi_{\text{Titre},\text{Nom}}(\sigma_{\text{rôle}=\text{acteurice}}(\text{Casting}))) \end{aligned}$$

avec $\text{sort}(\mathit{Films}) = \{\text{Titre}, \text{Real}, \text{Act}\}$

Exercices

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

Aime (Spectateur, Titre)

Soit le schéma ci-haut, écrire en algèbre, en calcul n -uplet et domaine les requêtes suivantes :

- ① Où et quand peut on voir le film "Mad Max" ?
- ② Quels sont les (titres de) films réalisés par Orson Welles ?
- ③ Quels sont les acteurs de "Ran" ?
- ④ Où peut-on voir un film dans lequel joue Signoret ?
- ⑤ Quels sont les acteurs qui ont produit un film ?

Exercices

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

Aime (Spectateur, Titre)

Où et quand peut on voir le film "Mad Max" ?

- $\pi_{Nom, Horaire}(\sigma_{Titre="MadMax"}(Salle))$
- $\{t.Nom, t.Horaire \mid t \in Salle \wedge t.Titre = "MadMax"\}$
- $\{Nom, Horaire \mid \exists Titre (Nom, Horaire, Titre) \in Salle\}$

Exercices

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

Aime (Spectateur, Titre)

Quels sont les (titres de) films réalisés par Orson Welles ?

- $\pi_{Titre}(\sigma_{Réalisateur="Orson Welles"}(Film))$
- $\{t.titre \mid t \in Films \wedge t.Réalisateur = "Orson Welles"\}$
- $\{Titre \mid \exists Acteur (Titre, "Orson Welles", Acteur) \in Film\}$

Exercices

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

Aime (Spectateur, Titre)

Quels sont les acteurs de "Ran" ?

- $\pi_{Acteur}(\sigma_{Titre="Ran"}(Film))$
- $\{t.Acteur \mid t \in Films \wedge t.Titre = "Ran"\}$
- $\{Acteur \mid \exists Real ("Ran", Real, Acteur) \in Film\}$

Exercices

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

Aime (Spectateur, Titre)

Où peut-on voir un film dans lequel joue Signoret ?

- $\pi_{Nom}(\sigma_{Acteur=Signoret}(Film \bowtie Salle))$
- $\left\{ t.Nom \mid \begin{matrix} F \in Films \\ S \in Salle \end{matrix} \wedge F.Acteur = Signoret \wedge F.Titre = S.Titre \right\}$
- $\left\{ Nom \mid \exists Real, Titre, Horaire \begin{matrix} (Nom, Horaire, Titre) \in Salle \\ (Titre, Real, "Signoret") \in Film \end{matrix} \right\}$

Exercices

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

Aime (Spectateur, Titre)

Quels sont les acteurs qui ont produit un film ?

- $\pi_{\text{Acteur}}(\text{Film}) \bowtie \rho_{\text{Producteur/Acteur}}(\pi_{\text{Producteur}}(\text{Produit}))$
- $\left\{ F.\text{Acteur} \mid \begin{array}{l} F \in \text{Film} \\ P \in \text{Produit} \\ F.\text{Acteur} = P.\text{Producteur} \end{array} \right\}$
- $\{x \mid (\exists a, b (a, b, x) \in \text{Film}) \wedge (\exists a (x, a) \in \text{Produit})\}$

Exercices

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

Aime (Spectateur, Titre)

- 6 Quels acteurs produisent un film dans lequel ils jouent ?
- 7 Quels sont les acteurs qui jouent dans les films de François Truffaut ?
- 8 Où peut on voir Marlon Brando après 16h ? (on suppose \leq dans les filtres)
- 9 Quels acteurs jouent dans un film où Orson Welles joue ?
- 10 Quels producteurs sont producteurs de tous les films de Akira Kurosawa ?

Exercices

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

Aime (Spectateur, Titre)

Quels sont les acteurs qui jouent dans les films de François Truffaut ?

- $\pi_{\text{Acteur}}(\sigma_{\text{Réalisateur}=\text{"Francois Truffaut"}}(\text{Film}))$
- $\{F.\text{Acteur} \mid F \in \text{Film} \wedge F.\text{Réalisateur} = \text{"Francois Truffaut"}\}$
- $\{x \mid \exists t (t, \text{"Francois Truffaut"}, x) \in \text{Film}\}$

Exercices

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

Aime (Spectateur, Titre)

Où peut on voir Marlon Brando après 16h ?

- $\pi_{Nom}(\sigma_{Acteur="Marlon Brando"}(Film) \bowtie \sigma_{16h \leq Horaire}(Salle))$
- $\left\{ F.Acteur \mid \begin{array}{l} F \in Film \\ P \in Produit \\ F.Acteur = P.Producteur \wedge F.Titre = \\ P.Titre \end{array} \right\}$
- $\left\{ x \mid \exists t \left((\exists a (t, a, x) \in Film) \wedge ((x, t) \in Produit) \right) \right\}$

Exercices

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

Aime (Spectateur, Titre)

Quels acteurs jouent dans un film où Orson Welles joue ?

- $\pi_{\text{Acteur}}(\pi_{\text{Titre}}(\sigma_{\text{Acteur}=\text{"Orson Welles"}}(\text{Film}))) \bowtie \text{Film}$
- $\left\{ F.\text{Acteur} \mid \begin{array}{l} F \in \text{Film} \\ O \in \text{Film} \end{array} \wedge O.\text{Acteur} = \text{"Orson Welles"} \wedge F.\text{Titre} = O.\text{Titre} \right\}$
- $\left\{ a \mid \exists t \left((\exists x (t, a, x) \in \text{Film}) \wedge (\exists r (t, \text{"Orson Welles"}, r) \in \text{Film}) \right) \right\}$

Exercices

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

Aime (Spectateur, Titre)

Quels producteurs sont producteurs de tous les films de Akira Kurosawa ?
Cette requête n'est pas monotone ! Si on ajoute un nouveau film de Kurosawa sans acteur, on élimine tous les anciens résultats. Cette requête ne peut donc pas s'exprimer.

On rajoute union/disjonction

Où puis-je voir "Annie Hall" ou "Manhattan" ?

- Algèbre avec **union** (algèbre PSJRU)

$$\pi_{\text{Cinéma}}(\sigma_{\text{Titre}=\text{"Annie Hall"}}(\text{Séances}) \cup \sigma_{\text{Titre}=\text{"Manhattan"}}(\text{Séances}))$$

- Plusieurs règles**

$$\text{ans}(x_t) \leftarrow \text{Seances}(x_t, \text{"Annie Hall"}, x_s)$$

$$\text{ans}(x_t) \leftarrow \text{Seances}(x_t, \text{"Manhattan"}, x_s)$$

- Calcul avec **disjonction** \vee

$$\{x_t \mid \exists x_s (\text{Séances}(x_t, \text{"Annie Hall"}, x_s) \vee \text{Séances}(x_t, \text{"Manhattan"}, x_s))\}$$

Autres possibilités :

- Sélection plus complexes

$$\pi_{\text{Séances}}(\sigma_{\text{Titre}=\text{"Annie Hall"} \vee \text{Titre}=\text{"Manhattan"}}(\text{Séances}))$$

- Constantes plus complexes

$$\pi_{\text{Cinéma}}(\text{Seances} \bowtie \{\langle \text{Titre} : \text{"Annie Hall"} \rangle, \langle \text{Titre} : \text{"Manhattan"} \rangle\})$$

On rajoute l'union (2)

Le théorème d'équivalence reste vrai, les requêtes restent monotones ...

mais problème avec certains calculs, par exemple : $\{x, y \mid R(x) \vee R(y)\}$
Infini si on n'est pas prudent \rightarrow formules sûres

On rajoute la différence/négation

Dans quels films d'Hitchcock, n'a-t-il pas joué ?

Quels films passent au Gaumont Opéra mais pas au Réal ?

- Algèbre relationnelle : PSJRU + différence
- Calcul relationnel : $\exists, \wedge, \vee, \neg, \forall$
- Règles : négation dans le corps des règles

$$\pi_{Titre} \sigma_{Real="Hitchcock"}(Film) - \pi_{Titre} \sigma_{Act="Hitchcock"}(Film)$$

nr-datalog[¬] par l'exemple

$$ans(x) \leftarrow Film(x, "Hitchcock", z), \\ \neg Film(x, "Hitchcock", "Hitchcock")$$

$$Hitch-Act(z) \leftarrow , Réalisateurice), \\ Casting(film, "Hitchcock", z) \\ not-ans(x) \leftarrow Film(x, y, z), \neg Hitch-Acteur(z) \\ ans(x) \leftarrow Film(x, y, z), \neg not-ans(x)$$

Calcul relationnel

On rajoute au calcul conjonctif \neg , \vee , \forall

$\varphi \vee \psi \equiv \neg(\neg\varphi \wedge \neg\psi)$, et $\forall x\varphi \equiv \neg\exists x\neg\varphi$

Terme : constante ou variable

Atome : $R(e_1, \dots, e_n)$ (R nom de relation, $n = \text{arité}(R)$, chaque e_i est un terme)

Formules de base : atomes sur $\mathbf{R} + e = e'$

Formules bien-formées :

(a) $\neg\varphi$

(b) $(\varphi \wedge \psi)$, $(\varphi \vee \psi)$

(c) $\exists x \varphi$, $\forall x \varphi$

$$\varphi \rightarrow \psi \equiv \neg\varphi \vee \psi$$

$$\varphi \leftrightarrow \psi \equiv (\varphi \wedge \psi) \vee (\neg\varphi \wedge \neg\psi)$$

Calcul relationnel : indépendance au domaine

Variables libres et liées

litéral P : $free(P) =$ variables de P

$$free(\varphi \wedge \psi) = free(\varphi) \cup free(\psi) \quad free(\varphi \vee \psi) = free(\varphi) \cup free(\psi)$$

$$free(\neg\varphi) = free(\varphi)$$

$$free(\exists x\varphi) = free(\varphi) - \{x\} \quad free(\forall x\varphi) = free(\varphi) - \{x\}$$

Requêtes : $\{e_1, \dots, e_n \mid \varphi\}$ variables de e_1, \dots, e_n sont les variables libres de φ

$$\{x_t \mid \exists x_a Film(x_t, \text{“Hitchcock”}, x_a) \wedge \neg Film(x_t, \text{“Hitchcock”}, \text{“Hitchcock”})\}$$

$$\{x_t \mid \exists x_d, x_a Film(x_t, x_d, x_a) \wedge \\ \forall y_a (\exists y_d Film(x_t, y_d, y_a) \\ \rightarrow \exists z_t Film(z_t, \text{“Hitchcock”}, y_a))\}$$

Sémantique du calcul

Problème : résultat fini ?

$$\begin{array}{l}
 (\textit{non-sure-1}) \quad \{x \mid \neg \textit{Films}(\textit{"Cries and Whispers"}, \textit{"Bergman"}, x)\} \\
 (\textit{non-sure-2}) \quad \{x, y \mid \textit{Films}(\textit{"Cries and Whispers"}, \textit{"Bergman"}, x) \\
 \qquad \qquad \qquad \vee \textit{Films}(y, \textit{"Bergman"}, \textit{"Ullman"})\}
 \end{array}$$

Solution A : variables prennent leurs valeurs dans le domaine actif

Solution B : interdire les requêtes non-sures \leftarrow

$$(\textit{non-sure-3}) \quad \{x \mid \forall y R(x, y)\}$$

Résultats intermédiaires non finis

Calcul relationnel : sémantique domaine actif

valuations ν de $free(\varphi)$ dans $adom(q, \mathbf{I})$

\mathbf{I} satisfait φ pour ν (qui s'écrit $\mathbf{I} \models_{adom} \varphi[\nu]$) quand :

- (a) $\varphi = R(u)$ et $\nu(u) \in \mathbf{I}(R)$;
- (b) $\varphi = (s = s')$ et $\nu(s) = \nu(s')$;
- (c) $\varphi = (\psi \wedge \xi)$ et ($\mathbf{I} \models_{adom} \psi[\nu]$ et $\mathbf{I} \models_{adom} \xi[\nu]$) ;
- (d) $\varphi = (\psi \vee \xi)$ et ($\mathbf{I} \models_{adom} \psi[\nu]$ ou $\mathbf{I} \models_{adom} \xi[\nu]$) ;
- (e) $\varphi = \neg\psi$ et $\mathbf{I} \not\models_{adom} \psi[\nu]$,
- (f) $\varphi = \exists x \psi$ et pour quelque $c \in adom$, $\mathbf{I} \models_{adom} \psi[\nu \cup \{x/c\}]$; ou
- (g) $\varphi = \forall x \psi$ et pour chaque $c \in adom$, $\mathbf{I} \models_{adom} \psi[\nu \cup \{x/c\}]$.

Sémantique d'une requête

$$q_{adom}(\mathbf{I}) = \{ \nu(\langle e_1, \dots, e_n \rangle) \mid \mathbf{I} \models_{adom} \varphi[\nu], \\ \nu \text{ est une valuation sur } free(\varphi) \\ \text{dont l'image } \subseteq adom \}.$$

Calcul relationnel : domaine indépendant

On normalise les formules en poussant les négations devant les \exists et les atomes et en aplatissant les \wedge et \vee :

- 1 $\neg\neg\varphi \rightarrow \varphi$
- 2 $\neg(\varphi_1 \wedge \dots \wedge \varphi_n) \rightarrow \neg\varphi_1 \vee \dots \vee \neg\varphi_n$
- 3 $\neg(\varphi_1 \vee \dots \vee \varphi_n) \rightarrow \neg\varphi_1 \wedge \dots \wedge \neg\varphi_n$

On calcule récursivement l'ensemble rr des variables *range-restricted* :

$$\begin{aligned}
 rr(R(e_1, \dots, e_k)) &= \{e_i \mid e_i \text{ variable}\} \\
 rr(x = a) &= \{x\} \\
 rr(\varphi_1 \wedge \varphi_2) &= rr(\varphi_1) \cup rr(\varphi_2) \\
 rr(\varphi_1 \vee \varphi_2) &= rr(\varphi_1) \cap rr(\varphi_2) \\
 rr(\varphi \wedge x = y) &= rr(\varphi) \oplus \{x, y\} \\
 rr(\neg\varphi) &= \emptyset \\
 rr(\exists x\varphi) &= rr(\varphi) \setminus \{x\}
 \end{aligned}$$

Et on vérifie que $x \in rr(\varphi)$ pour chaque $\exists x\varphi$ puis que $free(q) \subseteq rr(q)$.

Exercice : range restriction

Les requêtes suivantes sont-elles *range-restricted* ?

- $R(x, y) \vee R(x, z)$
- $(R_1(x, y) \vee R(z, y)) \wedge R(z, x)$
- $\exists z P(z, y, x) \vee ((R(x, y) \wedge (S(z) \wedge \neg T(x, z))) \vee T(y, z))$

Exercice : la division

Montrer que la division est une opération redondante.

Soient I sur X , J sur $Y \subset X$, on définit

$$I \div J = \{u \mid \forall v \in J, [u, v] \in I\}$$

avec $\text{sort}(I \div J) = \text{sort}(I) - \text{sort}(J)$, c'est à dire l'ensemble de n -uplets u de type $\text{sort}(I) - \text{sort}(J)$ tels que pour tout $v \in J$ on ait $u + v \in I$

Exemple : *Quels acteurs jouent dans tous les films de Hitchcock ?*

$$\pi_{\text{Titre, Acteur}}(\text{Films}) \div \pi_{\text{Titre}}(\sigma_{\text{Real}=\text{Hitchcock}}(\text{Films}))$$

Exercice : la division (dans le cadre de l'exemple)

On calcule d'abord $PasActeurDansFilmHitchcock(Acteur, Titre)$ qui contient les paires de $Titre$ (de $Films$ d'*Hitchcock*) et d' $Acteur$ (de $Films$) qui ne sont pas dans $Films$:

$$\pi_{Titre}(\sigma_{Réalisateur=Hitchcock}(Films)) \bowtie \pi_{Acteur}(Films) - \pi_{Acteur, Titre}(Films)$$

Un $Acteur$ a donc joué dans tous les films d'*Hitchcock* quand il n'apparaît pas dans la liste plus haut :

$$\pi_{Acteur}(Films) - \pi_{Acteur}(PasActeurDansFilmHitchcock)$$

Donc au total :

$$\pi_{Acteur}(Films) - \pi_{Acteur} \left(\begin{array}{l} (\pi_{Titre}(\sigma_{Réalisateur=Hitchcock}(Films))) \\ \bowtie \pi_{Acteur}(Films) \\ - \pi_{Acteur, Titre}(Films) \end{array} \right)$$

Exercice : la division (dans le cadre général)

Pour $I \div J$ on calcule $lpasJ$ les paires \bar{u} de type $sort(I \div J)$, \bar{v} de type J telles que \bar{u}, \bar{v} n'est pas dans I :

$$lpasJ = \pi_{sort(I \div J)}(I) \times J - I$$

puis le résultat est l'ensemble de u de $\pi_{sort(I \div J)}(I)$ qui ne sont pas dans $\pi_{sort(I \div J)}(lpasJ)$:

$$\pi_{sort(I \div J)}(I) - \pi_{sort(I \div J)}(lpasJ)$$

$$\pi_{sort(I \div J)}(I) - \pi_{sort(I \div J)}(\pi_{sort(I \div J)}(I) \times J - I)$$

Exercice : Complément de jointure

Montrer que le complément de jointure est une opération redondante.

Soient I sur X , J sur Y , $X \cap Y = Z$

$$\text{sort}(I \boxtimes J) = X$$

$$I \boxtimes J = \{x \in I \mid \pi_Z(x) \notin \pi_Z(J)\}$$

Exemple : *Quels films contiennent des acteurs qui ne jouent dans aucun film d'Hitchcock ?*

$$\pi_{\text{Titre,Acteur}}(\sigma_{\text{Real}=\text{Hitchcock}}(\text{Films}))$$



$$\pi_{\text{Titre}}(\sigma_{\text{Real}=\text{Hitchcock}}(\text{Films}))$$

Exercice : Complément de jointure

Montrer que le complément de jointure est une opération redondante.
 Soient I sur X , J sur Y , $X \cap Y = Z$

$$\text{sort}(I \bowtie J) = X$$

$$I \bar{\bowtie} J = \{x \in I \mid \pi_Z(x) \notin \pi_Z(J)\}$$

$$I \bar{\bowtie} J = I - \pi_X(I \bowtie J)$$

Quelques propositions

- Théorème d'équivalence : **algèbre** \leftrightarrow **calcul** \leftrightarrow **nr-datalog**[¬]
- Non-monotonie (à cause de la différence)
- Fermeture sous composition (à cause de l'algèbre)
- Minimalité des opérateurs de l'algèbre Projection Sélection Jointure Renommage Différence Union
- Faible complexité en *données* (LOGSPACE, PTIME, NC)
- Tests d'équivalence et d'inclusion sont indécidables - donc optimisation difficile
- Décidable pour les requêtes conjonctives - optimisation principalement pour RQ

Exercices (2)

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

Aime (Spectateur, Titre)

Soit le schéma ci-haut, écrire en algèbre, en calcul relationnel les requêtes suivantes :

- 11 Quels spectateurs voient tous les films ?
- 12 Quels sont les spectateurs qui aiment tous les films qu'ils voient ?
- 13 Quels films ne passent dans aucune salle ?
- 14 Qui produit un film qui ne passe dans aucune salle ?
- 15 Quels producteurs voient tous les films qu'ils produisent ?

Exercices (2)

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

Aime (Spectateur, Titre)

Quels spectateurs voient tous les films ?

- $Vu \div \pi_{Titre}(Film)$
- $\left\{ s \mid (\exists t (s, t) \in Vu) \wedge \neg \exists t, r, a \left((t, r, a) \in Film \wedge \neg (s, t) \in Vu \right) \right\}$

Exercices (2)

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

Aime (Spectateur, Titre)

Quels sont les spectateurs qui aiment tous les films qu'ils voient ?

- $\pi_{\text{spectateur}}(Vu) - \pi_{\text{spectateur}}(Vu - Aime)$
- $\{s \mid (\exists t (s, t) \in Vu) \wedge (\forall t \in (s, t) \in Vu \Rightarrow (s, t) \in Aime)\}$

Exercices (2)

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

Aime (Spectateur, Titre)

Quels films ne passent dans aucune salle ?

- $\pi_{\text{Titre}}(\text{Film}) - \pi_{\text{Titre}}(\text{Salle})$
- $\{t \mid (\exists r, a (t, r, a) \in \text{Film}) \wedge \forall n, h \neg(n, h, t) \in \text{Salle}\}$

Exercices (2)

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

Aime (Spectateur, Titre)

Qui produit un film qui ne passe dans aucune salle ?

- $\pi_{\text{Producteur}}(\text{Produit} \bowtie (\pi_{\text{Titre}}(\text{Film}) - \pi_{\text{Titre}}(\text{Salle})))$
- $\left\{ p \mid \exists t (p, t) \in \text{Produit} \wedge \left((\exists r, a (t, r, a) \in \text{Film}) \wedge \forall n, h \neg (n, h, t) \in \text{Salle} \right) \right\}$

Exercices (2)

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

Aime (Spectateur, Titre)

Quels producteurs voient tous les films qu'ils produisent ?

- $\pi_{Producteur}(Produit \bowtie (\pi_{Titre}(Film) - \pi_{Titre}(Salle)))$
- $\left\{ p \mid \exists t (p, t) \in Produit \wedge \left((\exists r, a (t, r, a) \in Film) \wedge \forall n, h \neg (n, h, t) \in Salle \right) \right\}$

Exercices (2)

Schéma

Salle (Nom, Horaire, Titre)

Film (Titre, Réalisateur, Acteur)

Produit (Producteur, Titre)

Vu (Spectateur, Titre)

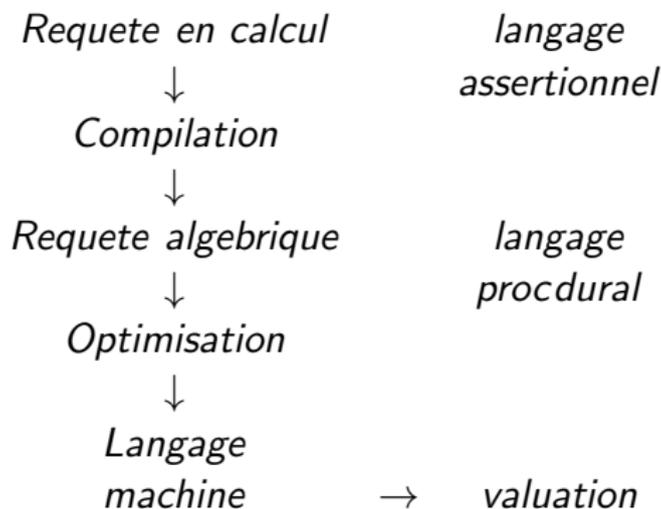
Aime (Spectateur, Titre)

- 16 Quels producteurs voient tous les films de Akira Kurosawa ?
- 17 Quels spectateurs aiment un film qu'ils n'ont pas vu ?
- 18 Qui n'aime aucun film ?
- 19 Qui ne produit aucun film de Jacques Doillon ?
- 20 Quels sont les producteurs qui ne voient que les films qu'ils produisent ?

De la théorie à la pratique

Algèbre et calcul relationnels sont équivalents

La traduction de l'un à l'autre est facile



En réalité, on n'utilise pas le calcul relationnel, mais un langage hybride – SQL – avec des gadgets

Count, Avg, Sum, Order by, etc.

Quels sont les acteurs qui ont un nombre de Bacon ?

References

Serge Abiteboul.

Modèle relationnel (slides du cours de bases de données), 2009.

Serge Abiteboul, Richard Hull, and Victor Vianu.

Foundations of databases. 1995.

Addison-Wesley.

Edgar F Codd.

A relational model of data for large shared data banks.

Communications of the ACM, 13(6) :377–387, 1970.

Edgar F Codd.

Relational completeness of data base sublanguages.

IBM Corporation, 1972.