Bases de données

Requêtes récursives & complexité descriptive

Pierre Senellart

ENS ÉCOLE NORMALE SUPÉRIEURE | PSL RESEARCH UNIVERSITY PARIS

17 avril 2025

Motivation: Requêtes récursives

- Langages de requêtes considérés jusqu'à présent (algèbre relationnel, calcul) ont un horizon limité
- Certaines structures de données (arbres, graphes) nécessitent des parcours arbitrairement profonds
- Applications naturelles pour certaines données: listes de discussion, graphes de réseaux de transport, etc.
- Ce cours: Comment exprimer des requêtes récursives dans les SGBD relationnels?
- Les SGBDR ne sont pas toujours adaptés pour ce type de données/requêtes, cf. SGBD XML ou SGBD graphes
- Application exemple: clôture transitive d'un graphe $G(from, to)$

Plan

Datalog

- Langage récursif le plus simple: on ajoute de la récursion aux requêtes conjonctives
- Inspiré de la programmation logique
- Requête (ou programme) Datalog: ensemble de règles de productions de faits intensionnels
- Schéma d'un programme Datalog: schéma relationnel classique (schéma extensionnel) + schéma (disjoint) des faits intensionnels (schéma intensionnel)
- On fixe une relation distinguée *But* du schéma intensionnel, dont l'arité est l'arité de la requête

Syntaxe

Ensemble fini de règles r de la forme:

$$\underbrace{S(\mathbf{y})}_{\text{tête}} \leftarrow \underbrace{R_1(\mathbf{x}_1), \ldots, R_n(\mathbf{x}_n)}_{\text{corps}}$$

avec:

- S relation du schéma intensionnel
- $R_1, \ldots, R_n$ relations du schéma intensionnel ou du schéma extensionnel
- $\mathbf{x}_1, \ldots, \mathbf{x}_n, \mathbf{y}$: tuples de variables (ou éventuellement de constantes), d'arité compatible avec les relations
- Chaque variable de la tête est présente dans le corps

Sémantique par point fixe

- Chaque règle r d'un programme P peut-être vue comme une requête conjonctive sur la base de données D:

$$r(D) := \{S(\mathbf{y}) \mid \exists z_1 \dots z_k \; R_1(\mathbf{x_1}) \in D \wedge \dots \wedge R_n(\mathbf{x_n}) \in D\}$$

où les z_i sont les variables du corps de la règle

- Opérateur de conséquence Γ_P défini par:

$$\Gamma_P(D) := D \cup \bigcup_{r \in P} \{r(D)\}$$

- On considère la suite (D_n) définie par:
$D_0 = D$, $D_{n+1} = \Gamma_P(D_n)$
- La sémantique de P sur D est l'ensemble des faits de la relation But dans D_∞, le point fixe de la suite (D_n)

Exemple: Clôture transitive

$$But(x, y) \leftarrow G(x, y)$$
$$But(x, y) \leftarrow But(x, z), G(z, y)$$

Détour: Théorème de Knaster–Tarski

Definition

Un treillis complet L est un ensemble muni d'un ordre partiel dans lequel tout sous-ensemble admet une borne supérieure (élément minimum supérieur ou égal à tous les éléments de l'ensemble) et une borne inférieure.

Theorem ([Knaster, 1928, Tarski et al., 1955])

Si L est un treillis complet et $f : L \to L$ une application croissante sur L, alors les points fixes de f forment un treillis complet.

Application de Knaster–Tarski à Datalog

- L'ensemble des parties d'un ensemble, ordonné par inclusion, est toujours un treillis complet ($\bigcup X$ et $\bigcap X$ sont les bornes supérieures et inférieures)
- Γ_P est croissant pour l'inclusion des faits
- Il existe donc un plus petit point fixe de Γ_P, obtenu comme l'intersection de tous les points fixes
- Comme l'ensemble des faits possibles est fini (domaine actif fini), ce plus petit point fixe est obtenu après un nombre fini d'itérations à partir de la base de données initiale
- Définition alternative de l'ensemble des faits produits par un programme Datalog: l'ensemble des faits inclus dans tout modèle du programme Datalog

Arbre de preuve d'un programme Datalog

- Inspiré par la programmation logique
- Pour un tuple $But(a_1, \ldots, a_n)$, on peut produire une preuve de But comme un arbre de preuve:
  - La racine est $But(a_1, \ldots, a_n)$
  - Tout noeud interne est l'instantiation de la tête d'une règle, ses enfants une instantiation compatible du corps de cette même règle
  - Les feuilles sont des faits extensionnels
- Utile pour raisonner sur les programmes Datalog

Datalog non récursif

Definition

Le graphe d'un programme Datalog est le graphe dont les noeuds sont les relations du schéma intensionnel et dans lequel il existe une arête (R, S) s'il existe une règle avec R dans le corps et S dans la tête. Un programme Datalog est non récursif si ce graphe est acyclique.

- Même pouvoir d'expression que les unions de requêtes conjonctives
- Mais exponentiellement plus compact!

Plan

Opérateur While

- Algèbre: essentiellement programmation impérative (contrairement au calcul)
- On ajoute à l'algèbre:
  - la possibilité de définir des variables intermédiaires et de leur affecter une valeur (ne change pas le pouvoir d'expression)
  - un opérateur **while** de la forme:

    while change do

    . . . affectation de valeur à une ou plusieurs variables. . .

    done

- Sémantique: le contenu de la boucle est exécuté tant que les affectations changent les variables sous-jacentes
- Boucles infinies possibles!

While inflationniste vs non-inflationniste

- Deux variantes:

  Non-inflationniste Opérateur d'affectation $:=$, affectation arbitraire

  Inflationniste Opérateur d'affectation $+=$, la variable affectée ne peut que croître

- Boucles infinies impossibles avec un **while** inflationniste s'il n'y a pas de possibilité de produire de nouvelle valeur (p. ex., arithmétique), parce que le domaine actif est fini
- Variante non-inflationniste plus expressive

Exemple: Clôture transitive

On introduit un schéma de relation C avec attributs *from* et *to*, tout comme G.

Non-inflationniste

$C := G$

while change do

$C := C \cup \pi_{from,to}(\rho_{to \to int}(C) \bowtie \rho_{from \to int}(G))$

done

C

Inflationniste

$C \mathrel{+}= G$

while change do

$C \mathrel{+}= \pi_{from,to}(\rho_{to \to int}(C) \bowtie \rho_{from \to int}(G))$

done

C

Plan

Point fixe non-inflationniste

- On ajoute au calcul relationnel une construction de point fixe
- Supposons $\varphi(T)$ formule du calcul, mentionnant les relations du schéma ainsi qu'une nouvelle relation T, et ayant pour variables libres $x_1, \ldots, x_n$
- Alors $\mu_T[\varphi(T)](x_1, \ldots, x_n)$ est une formule du calcul avec point-fixe
- Sémantique: On considère le point fixe de la relation T (s'il existe)
  en remplaçant T à chaque étape par l'ensemble des faits de la forme $T(x_1, \ldots, x_n)$ pour $\varphi(T)(x_1, \ldots, x_n)$ satisfait (en partant de $T = \emptyset$)
- Équivalent à l'algèbre avec **while** non-inflationniste!

Point fixe inflationniste

- On ajoute au calcul relationnel une construction de point fixe
- Supposons $\varphi(T)$ formule du calcul, mentionnant les relations du schéma ainsi qu'une nouvelle relation T, et ayant pour variables libres $x_1, \ldots, x_n$
- Alors $\mu^+_T[\varphi(T)](x_1, \ldots, x_n)$ est une formule du calcul avec point-fixe
- Sémantique: On considère le plus petit point fixe de la relation T
  en ajoutant à T à chaque étape l'ensemble des faits de la forme $T(x_1, \ldots, x_n)$ pour $\varphi(T)(x_1, \ldots, x_n)$ satisfait (en partant de $T = \emptyset$)
- Équivalent à l'algèbre avec **while** inflationniste!

Exemple: Clôture transitive

Non-inflationniste

$$\{(x,y) \mid \mu_C\,[G(x,y) \vee C(x,y) \vee (\exists z\, C(x,z) \wedge G(z,y))](x,y)\}$$

Inflationniste

$$\{(x,y) \mid \mu_C^+\,[G(x,y) \vee (\exists z\, C(x,z) \wedge G(z,y))](x,y)\}$$

Complexité en les données

Theorem

L'évaluation de $FO{+}\mu^{+}$ est PTIME en complexité en les données.
L'évaluation de $FO{+}\mu$ est PSPACE en complexité en les données (si le résultat est défini ; sinon il y a un semi-algorithme en espace polynomial).

Proof.

Au tableau. Facile. □

Logique du second ordre (SO)

- Extension de la logique du premier ordre dans laquelle il est possible d'utiliser des quantificateurs sur des relations
- Par exemple, on peut exprimer en logique du second ordre qu'un graphe G est biparti:

$$\exists X \exists Y \, \forall x \forall y \, [G(x,y) \rightarrow ((X(x) \wedge Y(y)) \vee (X(y) \wedge Y(x)))] \\ \wedge \neg(\exists x \, X(x) \wedge Y(x))$$

- Peut être aussi vu comme un langage de requêtes, plus puissant que le calcul relationnel

Point fixe inflationniste et SO

- Dans certains cas, traduction naturelle de logique à point fixe vers logique du second-ordre
- En particulier, pour un point fixe inflationniste:

$$\{(x_1, \ldots, x_n) \mid \mu_T^+[\varphi(T)](x_1, \ldots, x_n)\}$$

s'exprime en SO:

$$\{ (x_1, \ldots, x_n) \mid \forall T(\forall y_1 \ldots \forall y_n \, \varphi(T)(y_1, \ldots, y_n) \rightarrow T(y_1, \ldots, y_n)) \rightarrow T(x_1, \ldots, x_n) \}$$

- Application immédiate de Knaster–Tarski! Le plus petit point fixe (calculé par μ^+) de l'opérateur qui ajoute à T les tuples tel que $\varphi(T)$ est satisfait est croissant, et donc l'intersection de tous ($\forall T$) les modèles de φ

Exemple: Clôture transitive

$$\{\,(x,y)\mid$$
$$\forall C\,[\forall f \forall t\,(G(f,t) \vee (\exists z\, C(f,z) \wedge G(z,t)))] \rightarrow C(f,t))$$
$$\rightarrow C(x,y)\,\}$$

Plan

Datalog avec négation dans le corps

- On ajoute à Datalog la possibilité d'écrire $\neg R(x_1, \ldots, x_n)$ dans le corps d'une règle
- R peut être extensionnel ou intensionnel
- Sémantique domaine actif (nombre fini de faits tel que $\neg R(x_1, \ldots, x_n)$)
- Définition par point fixe:

$$r : S(\mathbf{y}) \leftarrow R_1(\mathbf{x}_1), \ldots \neg R_i(\mathbf{x}_i), \ldots, R_n(\mathbf{x_n})$$

$$r(D) := \{S(\mathbf{y}) \mid \exists z_1 \ldots z_k \; R_1(\mathbf{x}_1) \in D \wedge R_i(\mathbf{x}_i) \notin D \wedge \cdots \wedge R_n(\mathbf{x}_n) \in D\}$$

- L'opérateur de conséquence reste croissant, terminaison assurée
- Équivalent au calcul avec point fixe inflationniste, à l'algèbre avec **while** inflationniste

Exemple: Clôture transitive du complément

$$But(x, y) \leftarrow \neg G(x, y)$$
$$But(x, y) \leftarrow But(x, z), \neg G(z, y)$$

Plan

Common Table Expressions (CTE)

- Seule possibilité en SQL d'introduire de la récursion (on parle aussi de requêtes hiérarchiques)
- Idée: On nomme une table, dont la définition s'utilise elle-même
- Inspiré des logiques à point fixe inflationniste, mais aussi des fonctions récursives dans les langages de programmation (penser au **let rec** de Caml)

Syntaxe

```
WITH RECURSIVE T(x1, ..., xn) AS (
  SELECT -- cas de base
UNION
  SELECT -- cas récursif, utilisant la table T
)
SELECT * FROM T;
```

Cette forme précise, utilisant **UNION** (ou **UNION ALL**) entre cas de base et cas récursif est obligatoire

Sémantique

- On évalue la requête itérativement, en partant de $T = \emptyset$ et en remplaçant à chaque étape T par le résultat de l'évaluation de la définition de T
- On s'arrête quand un point fixe est atteint
- La requête définissant T doit être monotone (on ne peut à chaque étape que faire croître T)
- Optimisations possibles (et appliquées) permettant de ne tenir compte que des nouveaux faits à chaque étape (caractère inflationniste)
- Boucle infinie possible si on crée de nouvelles valeurs

Exemple: Clôture transitive

```
WITH RECURSIVE C(f,t) AS (
  SELECT * FROM G
UNION
  SELECT C.f, G.t FROM C JOIN G ON C.t=G.f
)
SELECT * FROM C;
```

Notes sur le support historique

- CTE normalisées tardivement [ISO, 1999] en SQL
- Extensions historiques non compatibles des SGBD (**CONNECT BY** introduit par Oracle, reprises dans certains autres SGBD)
- Support maintenant correct
- Les requêtes récursives ne sont pas une priorité des SGBD, optimisations à la traîne (dans PostgreSQL, les CTE ont longtemps été des barrières d'optimisation)

Plan

Rappel : Complexité descriptive

- Un langage de requêtes $\mathcal{Q}$ capture une classe de complexité $\mathcal{C}$ si:
  - Pour tout $Q \in \mathcal{Q}$, le problème d'évaluation de requêtes pour Q est dans $\mathcal{C}$ (complexité en les données)
  - Pour tout problème P dans $\mathcal{C}$, il existe une requête $Q \in \mathcal{Q}$ telle que l'évaluation de Q résout exactement P (sans réduction)!
- Si $\mathcal{Q}$ capture $\mathcal{C}$ et si $\mathcal{C}$ a des problèmes complets pour $\mathcal{C}$, alors il existe $Q \in \mathcal{Q}$ telle que Q est $\mathcal{C}$-complet, mais la réciproque n'est pas vraie

Rappel: FO ne capture pas tout PTIME

Theorem

On ne peut pas calculer en FO qu'une relation contenant un ordre total a un nombre pair d'éléments, ou qu'un graphe est connexe.

Non prouvé, la preuve repose sur les jeux d'Ehrenfeucht–Fraïssé (voir [Libkin, 2004]).

Connexité, parité

Theorem

Le problème de connexité peut s'exprimer en $FO+\mu^+$.

Le problème de parité du nombre d'éléments (ou de tuples) dans une relation arbitraire ne peut pas s'exprimer en $FO+\mu$.

Proof.

Preuve de la première partie au tableau, facile.
Deuxième partie admise (voir [Abiteboul et al., 1995], chapitre 17). □

Parité et FO+μ^+, avec ordre

Theorem

FO+μ^+ peut calculer si une relation contenant un ordre total a un nombre pair d'éléments.

Proof.

Au tableau, par construction explicite. □

Résultats plus généraux

Theorem (Immerman–Vardi, 1986 & 1982)

$FO{+}\mu^+$ exprime PTIME sur les données avec un ordre total sur les éléments du domaine.

Theorem (Abiteboul–Vianu, 1991)

$FO{+}\mu$ exprime PSPACE sur les données avec un ordre total sur les éléments du domaine.
Par conséquent, $FO{+}\mu \equiv FO{+}\mu^+$ iff $PTIME = PSPACE$.

Proof.

Intuition de preuve au tableau. □

Complexité en les données (bis)

Theorem

L'évaluation de FO+μ^+ est PTIME-complète en complexité en les données.
L'évaluation de FO+μ est PSPACE-complète en complexité en les données.

Proof.

La difficulté vient de la complexité descriptive sur les structures ordonnées. □

Au delà: Théorème de Fagin

Theorem (Fagin, 1973)

$\exists$SO (fragment de SO sans quantification universelle de deuxième ordre) exprime NP.

Proof.

Résultat fondamental, difficile à prouver formellement mais assez intuitif: on utilise le quantificateur existentiel pour deviner une trace de l'exécution de la machine de Turing non-déterministe. On peut aussi utiliser le quantificateur existentiel pour deviner une relation d'ordre permettant d'ordonner les étapes de la machine de Turing et les positions de la bande. On peut ensuite exprimer en FO que les transitions sont correctes. □

Complexité descriptive et P≠NP

- On a une caractérisation de NP: ∃SO
- Si on avait une caractérisation de P... (indépendamment d'ordre sur les éléments du domaine!) par une classe $\mathcal{Q}$
- ... on pourrait montrer P ≠ NP en exhibant une requête de ∃SO non exprimable dans $\mathcal{Q}$!
- Mais on en est loin...

Plan

Références

- Datalog: chapitre 12 de [Abiteboul et al., 1995]
- While, Logiques à point fixe, Datalog à négation: chapitre 14 de [Abiteboul et al., 1995]
- Complexité descriptive: chapitre 17 de [Abiteboul et al., 1995]
- Récursion en PostgreSQL: `https://www.postgresql.org/docs/current/static/queries-with.html`

Bibliographie I

Serge Abiteboul, Richard Hull, and Victor Vianu. *Foundations of Databases*. Addison-Wesley, 1995.

ISO. *ISO 9075:1999: SQL*. International Standards Organization, 1999.

Bronisław Knaster. Un théoreme sur les fonctions d'ensembles. *Ann. Soc. Polon. Math*, 6(133):2013134, 1928.

Leonid Libkin. *Elements of Finite Model Theory*. Texts in Theoretical Computer Science. An EATCS Series. Springer, 2004. doi: 10.1007/978-3-662-07003-1. URL `http://dx.doi.org/10.1007/978-3-662-07003-1`.

Alfred Tarski et al. A lattice-theoretical fixpoint theorem and its applications. *Pacific journal of Mathematics*, 5(2): 285–309, 1955.