

# Bases de données

## Vues, provenance, déclencheurs

Pierre Senellart



14 mai 2025

# Plan

Vues

Provenance

BD probabilistes

Maintenance de vues

Mise à jour au travers de vues

Déclencheurs

Références

# Vues

- Les vues sont des **requêtes** auxquelles l'on donne un **nom**
- Elles s'utilisent **comme des tables** dans d'autres requêtes
- **Sémantique** : on **remplace** la vue par le résultat de l'évaluation de la requête correspondante

## En SQL

**CREATE VIEW** vue **AS SELECT** ...

**CREATE MATERIALIZED VIEW** vue **AS SELECT** ...

(Celui-ci est une extension PostgreSQL.)



## Usage des vues

**Indépendance logique** : une application peut accéder à des vues, sans avoir besoin de connaître l'organisation effective des données dans la base (qui peut changer de manière transparente, en redéfinissant les vues)

**Contrôle d'accès** : des droits d'accès différents peuvent être donnés aux tables de base et à des vues, pour qu'un utilisateur ou application donnée n'ait accès qu'à un ensemble restreint du contenu de la base

**Intégration de données** : des vues peuvent être définies pour regrouper les données de plusieurs sources ayant des schémas relationnels différents

**Optimisation** : des vues matérialisées peuvent être définies pour des requêtes fréquentes, pour éviter d'avoir à les ré-évaluer à chaque fois









# Plan

Vues

Provenance

BD probabilistes

Maintenance de vues

Mise à jour au travers de vues

Déclencheurs

Références



# Modèle de données

- Modèle de données relationnel** : données décomposées en relations, avec attributs étiquetés...

nom	poste	ville
John	Directeur	New York
Paul	Gardien	New York
Dave	Analyste	Paris
Ellen	Agent	Berlin
Magdalen	Agent double	Paris
Nancy	DRH	Paris
Susan	Analyste	Berlin

## Modèle de données

- **Modèle de données relationnel** : données décomposées en relations, avec attributs étiquetés...
- ... et une **annotation de provenance** supplémentaire pour chaque tuple (la voir comme un identifiant de tuple)

nom	poste	ville	prov
John	Directeur	New York	$t_1$
Paul	Gardien	New York	$t_2$
Dave	Analyste	Paris	$t_3$
Ellen	Agent	Berlin	$t_4$
Magdalen	Agent double	Paris	$t_5$
Nancy	DRH	Paris	$t_6$
Susan	Analyste	Berlin	$t_7$

## Provenance booléenne [Imielinski and Jr., 1984]

- $\mathcal{X} = \{x_1, x_2, \dots, x_n\}$  ensemble fini d'événements booléens
- annotation de provenance : fonction booléenne sur  $\mathcal{X}$ ,  
 c.-à-d., une fonction de la forme :  $(\mathcal{X} \rightarrow \{\perp, \top\}) \rightarrow \{\perp, \top\}$
- Interprétation : sémantique de mondes possibles
  - chaque valuation  $\nu : \mathcal{X} \rightarrow \{\perp, \top\}$  désigne un monde possible de la base de données
  - la provenance d'un tuple  $\nu$  évalue à  $\perp$  ou  $\top$  suivant si ce tuple existe dans ce monde possible
  - par exemple, si chaque tuple de la base est annoté avec la fonction indicatrice d'un événement booléen distinct, l'ensemble des mondes possibles est l'ensemble de toutes les sous-instances

## Exemples de mondes possibles

nom	poste	ville	prov
John	Directeur	New York	$t_1$
Paul	Gardien	New York	$t_2$
Dave	Analyste	Paris	$t_3$
Ellen	Agent	Berlin	$t_4$
Magdalen	Agent double	Paris	$t_5$
Nancy	DRH	Paris	$t_6$
Susan	Analyste	Berlin	$t_7$

$\nu :$

$t_1$	$t_2$	$t_3$	$t_4$	$t_5$	$t_6$	$t_7$
T	T	T	T	T	T	T

## Exemples de mondes possibles

nom	poste	ville	prov
John	Directeur	New York	$t_1$
Dave	Analyste	Paris	$t_3$
Magdalen	Agent double	Paris	$t_5$
Susan	Analyste	Berlin	$t_7$

$\nu :$

$t_1$	$t_2$	$t_3$	$t_4$	$t_5$	$t_6$	$t_7$
⊤	⊥	⊤	⊥	⊤	⊥	⊤

## Provenance booléenne des résultats de requêtes

- $\nu(D)$  : la **sous-instance** de  $D$  où tous les tuples dont l'annotation de provenance évalue à  $\perp$  par  $\nu$  sont enlevés
- La **provenance booléenne**  $\text{prov}_{q,D}(t)$  d'un tuple  $t \in q(D)$  est la fonction :

$$\nu \mapsto \begin{cases} \top & \text{si } t \in q(\nu(D)) \\ \perp & \text{sinon} \end{cases}$$

Exemple (Quelles villes sont dans la table Personnel ?)

nom	poste	ville	prov
John	Directeur	New York	$t_1$
Paul	Gardien	New York	$t_2$
Dave	Analyste	Paris	$t_3$
Ellen	Agent	Berlin	$t_4$
Magdalen	Agent double	Paris	$t_5$
Nancy	DRH	Paris	$t_6$
Susan	Analyste	Berlin	$t_7$

ville	prov
New York	$t_1 \vee t_2$
Paris	$t_3 \vee t_5 \vee t_6$
Berlin	$t_4 \vee t_7$



## Exemples de semi-anneaux

- $(\mathbb{N}, 0, 1, +, \times)$  : semi-anneau de **comptage**
- $(\{\perp, \top\}, \perp, \top, \vee, \wedge)$  : semi-anneau **booléen**
- $(\{\textit{unclassified} < \textit{restricted} < \textit{confidential} < \textit{secret} < \textit{top secret} < \textit{unavailable}\}, \textit{unavailable}, \textit{unclassified}, \textit{min}, \textit{max})$  : semi-anneau de **sécurité**
- $(\mathbb{N} \cup \{\infty\}, \infty, 0, \text{min}, +)$  : semi-anneau **tropical**
- $(\{\text{fonctions booléennes sur } \mathcal{X}\}, \perp, \top, \vee, \wedge)$  : semi-anneau des **fonctions booléennes** sur  $\mathcal{X}$
- $(\mathbb{N}[\mathcal{X}], 0, 1, +, \times)$  : semi-anneau des **polynômes** à coefficients entiers à variables dans  $\mathcal{X}$  (aussi appelé semi-anneau **How** ou **universel**, voir plus loin)
- $(\mathcal{P}(\mathcal{P}(\mathcal{X})), \emptyset, \{\emptyset\}, \cup, \uplus)$  : Semi-anneau **Why** sur  $\mathcal{X}$   
 $(A \uplus B := \{a \cup b \mid a \in A, b \in B\})$

## Provenance de semi-anneau [Green et al., 2007]

- On fixe un semi-anneau  $(K, 0, 1, \oplus, \otimes)$
- On suppose que les annotations de provenance sont dans  $K$
- On considère une requête  $q$  de l'algèbre relationnelle positive (sélection, projection, renommage, produit cartésien, union ; jointures simulables avec renommage, produit cartésien, sélection, projection)
- On définit la sémantique de la provenance d'un tuple  $t \in q(D)$  récursivement sur la structure de  $q$

## Sélection, renommage

Les annotations de provenance des tuples sélectionnés sont **inchangées**

Exemple ( $\rho_{\text{nom} \rightarrow \text{n}}(\sigma_{\text{ville}=\text{“New York”}}(R))$ )

nom	poste	ville	prov
John	Directeur	New York	$t_1$
Paul	Gardien	New York	$t_2$
Dave	Analyste	Paris	$t_3$
Ellen	Agent	Berlin	$t_4$
Magdalen	Agent double	Paris	$t_5$
Nancy	DRH	Paris	$t_6$
Susan	Analyste	Berlin	$t_7$

n	poste	ville	prov
John	Directeur	New York	$t_1$
Paul	Gardien	New York	$t_2$

## Projection

Les annotations de provenance des tuples identiques, fusionnés, sont  $\oplus$ -ées

Exemple ( $\pi_{ville}(R)$ )

nom	poste	ville	prov
John	Directeur	New York	$t_1$
Paul	Gardien	New York	$t_2$
Dave	Analyste	Paris	$t_3$
Ellen	Agent	Berlin	$t_4$
Magdalen	Agent double	Paris	$t_5$
Nancy	DRH	Paris	$t_6$
Susan	Analyste	Berlin	$t_7$

ville	prov
New York	$t_1 \oplus t_2$
Paris	$t_3 \oplus t_5 \oplus t_6$
Berlin	$t_4 \oplus t_7$



## Produit cartésien

Les annotations de provenance des tuples combinés sont  $\otimes$ -ées

### Exemple

$$\pi_{ville}(\sigma_{starts-with(poste, "Agent")}(R)) \bowtie \pi_{ville}(\sigma_{poste="Analyste"}(R))$$

nom	poste	ville	prov
John	Directeur	New York	$t_1$
Paul	Gardien	New York	$t_2$
Dave	Analyste	Paris	$t_3$
Ellen	Agent	Berlin	$t_4$
Magdalen	Agent double	Paris	$t_5$
Nancy	DRH	Paris	$t_6$
Susan	Analyste	Berlin	$t_7$

ville	prov
Paris	$t_3 \otimes t_5$
Berlin	$t_4 \otimes t_7$



## Exemple de Why-provenance

$$\pi_{ville}(\sigma_{nom < nom2}(\pi_{nom, ville}(R) \bowtie \rho_{nom \rightarrow nom2}(\pi_{nom, ville}(R))))$$

nom	poste	ville	prov
John	Directeur	New York	$t_1$
Paul	Gardien	New York	$t_2$
Dave	Analyste	Paris	$t_3$
Ellen	Agent	Berlin	$t_4$
Magdalen	Agent double	Paris	$t_5$
Nancy	DRH	Paris	$t_6$
Susan	Analyste	Berlin	$t_7$

ville	prov
New York	$\{\{t_1, t_2\}\}$
Paris	$\{\{t_3, t_5\}, \{t_3, t_6\}, \{t_5, t_6\}\}$
Berlin	$\{\{t_4, t_7\}\}$

# Remarques [Green et al., 2007]

- Le calcul de la provenance a un surcoût polynomial en temps
- Deux requêtes équivalentes peuvent avoir deux annotations différentes de provenance sur la même base de données, dans certains semi-anneaux (par exemple, dans le semi-anneau Why)
- Les homomorphismes de semi-anneaux commutent avec le calcul de provenance : si  $h$  est un homomorphisme de  $K$  dans  $K'$  alors on peut calculer la provenance dans  $K$ , appliquer  $h$ , et obtenir le même résultat que si on calcule la provenance dans  $K'$
- Le semi-anneau des polynômes à coefficients entiers est universel : il existe un unique homomorphisme vers n'importe quel autre semi-anneau commutatif respectant une valuation donnée des variables
- Cela implique que les calculs peuvent tous être faits dans le semi-anneau universel, et les homomorphismes appliqués ensuite

## Au-delà des semi-anneaux

- Pour les requêtes non monotones, besoin de **semi-anneaux avec monus** [Geerts and Poggi, 2010], bien que la théorie ne soit pas aussi propre qu'avec les semi-anneaux classiques [Amsterdamer et al., 2011a]
- Possibilité de donner également une sémantique à la **provenance des requêtes d'agrégation**, mais il faut introduire une structure algébrique au niveau des valeurs (semimodules de provenance [Amsterdamer et al., 2011b])
- Fonctionne également pour les **requêtes avec récursion** telles que Datalog [Green and Tannen, 2006, Deutch et al., 2014] mais seulement pour certaines sémantiques [Ramusat, 2022]



## Application : Bases de données probabilistes

[Green and Tannen, 2006, Suciu et al., 2011]

- BD indépendante : chaque n-uplet  $t$  dans une BD est annoté avec une probabilité **indépendante**  $\Pr(t)$  d'exister
- Probabilité d'un mode possible  $D' \subseteq D$  :

$$\Pr(D') = \prod_{t \in D'} \Pr(t) \times \prod_{t \in D' \setminus D} (1 - \Pr(t))$$

- Probabilité d'un n-uplet pour une requête  $q$  sur  $D$  :

$$\Pr(t \in q(D)) = \sum_{\substack{D' \subseteq D \\ t \in q(D')}} \Pr(D')$$

- If  $\Pr(x_i) := \Pr(t_i)$  où  $x_i$  est l'annotation de provenance du n-uplet  $t_i$  alors  **$\Pr(t \in q(D)) = \Pr(\text{prov}_{q,D}(t))$**
- Calculer la probabilité d'une requête dans une BD probabiliste revient à **calculer la provenance booléenne**, puis à calculer la **probabilité d'une fonction booléenne**
- Marche aussi pour des modèles probabilistes plus complexes

## Exemple de calcul de probabilité

nom	poste	ville	prov	prob
John	Directeur	New York	$t_1$	0.5
Paul	Gardien	New York	$t_2$	0.7
Dave	Analyste	Paris	$t_3$	0.3
Ellen	Agent	Berlin	$t_4$	0.2
Magdalen	Agent double	Paris	$t_5$	1.0
Nancy	DRH	Paris	$t_6$	0.8
Susan	Analyste	Berlin	$t_7$	0.2

ville	prov
New York	$t_1 \vee t_2$
Paris	$t_3 \vee t_5 \vee t_6$
Berlin	$t_4 \vee t_7$

## Exemple de calcul de probabilité

nom	poste	ville	prov	prob
John	Directeur	New York	$t_1$	0.5
Paul	Gardien	New York	$t_2$	0.7
Dave	Analyste	Paris	$t_3$	0.3
Ellen	Agent	Berlin	$t_4$	0.2
Magdalen	Agent double	Paris	$t_5$	1.0
Nancy	DRH	Paris	$t_6$	0.8
Susan	Analyste	Berlin	$t_7$	0.2

ville	prov	prob
New York	$t_1 \vee t_2$	$1 - (1 - 0.5) \times (1 - 0.7) = 0.85$
Paris	$t_3 \vee t_5 \vee t_6$	1.00
Berlin	$t_4 \vee t_7$	$1 - (1 - 0.2) \times (1 - 0.2) = 0.36$

# Plan

Vues

Provenance

BD probabilistes

**Maintenance de vues**

Mise à jour au travers de vues

Déclencheurs

Références

## Insertions

Pour l'algèbre relationnelle positive, possible de calculer l'impact d'une insertion de manière **incrémentale** :

$$\sigma_{\varphi}(R \cup \Delta R) = \sigma_{\varphi}(R) \cup \sigma_{\varphi}(\Delta R)$$

$$\Pi_X(R \cup \Delta R) = \Pi_X(R) \cup \Pi_X(\Delta R)$$

$$\rho_{A \rightarrow B}(R \cup \Delta R) = \rho_{A \rightarrow B}(R) \cup \rho_{A \rightarrow B}(\Delta R)$$

$$(R \cup \Delta R) \cup (S \cup \Delta S) = (R \cup S) \cup \Delta R \cup \Delta S$$

$$(R \cup \Delta R) \times (S \cup \Delta S) = (R \times S) \cup (R \times \Delta S) \cup (\Delta R \times S) \cup (\Delta R \times \Delta S)$$

$$(R \cup \Delta R) \bowtie (S \cup \Delta S) = (R \bowtie S) \cup (R \bowtie \Delta S) \cup (\Delta R \bowtie S) \cup (\Delta R \bowtie \Delta S)$$

## Suppressions

- Il suffit d'utiliser la **provenance booléenne** !
- Enlever tous les tuples dont l'annotation de provenance s'évalue à  $\perp$





## Et dans PostgreSQL ?

- La maintenance automatique de vue n'est **pas implémentée** !
- On peut maintenir manuellement une vue avec :  
 REFRESH MATERIALIZED **VIEW** vue
- Pour une maintenance automatique, transformer la vue matérialisée en une vraie table, et ajouter des **déclencheurs** aux tables de base pour traiter les opérations de mise à jour de manière ad hoc

```
CREATE TRIGGER tab_trigger
ON tab
FOR EACH ROW EXECUTE PROCEDURE tab_insert()
```

# Plan

Vues

Provenance

BD probabilistes

Maintenance de vues

Mise à jour au travers de vues

Déclencheurs

Références

## Insertions

Difficile en général :

- En cas de jointure avec valeur de jointure projetée, il faut « inventer » une valeur de jointure pour ajouter des tuples avec cette valeur dans plusieurs tables de base
- En cas de projection simple, peupler la table de base de valeurs **NULL**
- En cas d'agrégation : essentiellement impossible sauf à définir une stratégie adaptée à chaque problème

## Suppressions [Buneman et al., 2002]

- Cas d'utilisation de la **Why-provenance** !
- Pour supprimer un tuple  $t$  dans le résultat d'une vue, sélectionner un **sous-ensemble de tuples minimal** (en taille, ou en termes d'effet de bord sur les autres tuples de la vue supprimés) dont l'annotation est présente dans chaque ensemble d'annotations de la Why-provenance de  $t$
- **NP-complet** en général

## Suppressions [Buneman et al., 2002]

- Cas d'utilisation de la **Why-provenance** !
- Pour supprimer un tuple  $t$  dans le résultat d'une vue, sélectionner un **sous-ensemble de tuples minimal** (en taille, ou en termes d'effet de bord sur les autres tuples de la vue supprimés) dont l'annotation est présente dans chaque ensemble d'annotations de la Why-provenance de  $t$
- **NP-complet** en général

nom	poste	ville	prov
John	Directeur	New York	$t_1$
Paul	Gardien	New York	$t_2$
Dave	Analyste	Paris	$t_3$
Ellen	Agent	Berlin	$t_4$
Magdalen	Agent double	Paris	$t_5$
Nancy	DRH	Paris	$t_6$
Susan	Analyste	Berlin	$t_7$

ville	prov
New York	$\{t_1, t_2\}$
Paris	$\{t_3, t_5\}, \{t_3, t_6\}, \{t_5, t_6\}$
Berlin	$\{t_4, t_7\}$

Pour supprimer Paris



## Et dans PostgreSQL ?

- Le standard SQL n'autorise les mises à jour qu'à travers des vues très simples (sélection, projection, renommage) :
  - pas de jointure
  - pas d'union, d'intersection, de différence
  - pas d'agrégation
  - pas de requête récursive
  - pas de sémantique ensembliste
- Pour les autres cas, possible de définir un **déclencheur** sur la vue

```
CREATE TRIGGER vue_trigger  
INSTEAD OF INSERT OR UPDATE OR DELETE ON vue  
FOR EACH ROW EXECUTE PROCEDURE vue_maj()
```

# Plan

Vues

Provenance

BD probabilistes

Maintenance de vues

Mise à jour au travers de vues

Déclencheurs

Références



## PL/pgSQL

- Langage de programmation impératif de PostgreSQL
- Permet de définir des déclencheurs :

```

CREATE FUNCTION tab_insert() RETURNS TRIGGER
LANGUAGE plpgsql
AS $$
BEGIN
    ...
RETURN NEW;
END;
  $$;
  
```

- Au sein d'une fonction définissant un déclencheur ligne par ligne, **OLD** est l'ancienne valeur du tuple (pour modification ou suppression), **NEW** est la nouvelle valeur (pour insertion ou modification)

# Plan

Vues

Provenance

BD probabilistes

Maintenance de vues

Mise à jour au travers de vues

Déclencheurs

Références

# Références

- L'article présentant les semi-anneaux de provenance [Green et al., 2007]
- La vue d'ensemble de réponse à des requêtes en utilisant des vues [Halevy, 2001]
- Chapitre 22 de [Abiteboul et al., 1995]
- La documentation de PostgreSQL pour les déclencheurs et PL/pgSQL <https://www.postgresql.org/docs/>
- ProvSQL, une extension à PostgreSQL y ajoutant le support de calcul de provenance (et de probabilités) <https://github.com/PierreSenellart/provsql>

## Bibliographie I

- Serge Abiteboul, Richard Hull, and Victor Vianu. *Foundations of Databases*. Addison-Wesley, 1995. ISBN 0-201-53771-0.  
URL <http://www-cse.ucsd.edu/users/vianu/book.html>.
- Yael Amsterdamer, Daniel Deutch, and Val Tannen. On the limitations of provenance for queries with difference. In *TaPP*, 2011a.
- Yael Amsterdamer, Daniel Deutch, and Val Tannen. Provenance for aggregate queries. In *PODS*, 2011b.
- Peter Buneman, Sanjeev Khanna, and Wang Chiew Tan. Why and where : A characterization of data provenance. In *Database Theory - ICDT 2001, 8th International Conference, London, UK, January 4-6, 2001, Proceedings.*, 2001.

## Bibliographie II

- Peter Buneman, Sanjeev Khanna, and Wang Chiew Tan. On propagation of deletions and annotations through views. In *Proceedings of the Twenty-first ACM SIGACT-SIGMOD-SIGART Symposium on Principles of Database Systems, June 3-5, Madison, Wisconsin, USA*, pages 150–158, 2002. doi : 10.1145/543613.543633. URL <http://doi.acm.org/10.1145/543613.543633>.
- Daniel Deutch, Tova Milo, Sudeepa Roy, and Val Tannen. Circuits for Datalog provenance. In *ICDT*, 2014.
- Floris Geerts and Antonella Poggi. On database query languages for k-relations. *J. Applied Logic*, 8(2), 2010.
- Todd J. Green and Val Tannen. Models for incomplete and probabilistic information. *IEEE Data Eng. Bull.*, 29(1), 2006.

## Bibliographie III

- Todd J Green, Grigoris Karvounarakis, and Val Tannen.  
Provenance semirings. In *PODS*, 2007.
- Alon Y. Halevy. Answering queries using views : A survey.  
*VLDB J.*, 10(4) :270–294, 2001. doi : 10.1007/s007780100054.  
URL <http://dx.doi.org/10.1007/s007780100054>.
- Tomasz Imielinski and Witold Lipski Jr. Incomplete  
information in relational databases. *J. ACM*, 31(4), 1984.
- Yann Ramusat. *The Semiring-Based Provenance Framework  
for Graph Databases*. Theses, Ecole normale supérieure -  
ENS PARIS ; PSL University, April 2022. URL  
<https://inria.hal.science/tel-03896482>.
- Dan Suciu, Dan Olteanu, Christopher Ré, and Christoph Koch.  
*Probabilistic Databases*. Morgan & Claypool, 2011.