Systèmes de gestion de bases de données

Traitement d'une requête

P. Rigaux

Cnam, dépt. informatique

May 8, 2015

Étapes du traitement d'une requête

Toute requête SQL est traitée en trois étapes :

1. **Analyse et traduction** de la requête. On vérifie qu'elle est correcte, et on l'exprime sous forme d'opérations.
2. **Optimisation** : comment agencer au mieux les opérations, et quels algorithmes utiliser. On obtient un **plan d'exécution**.
3. **Exécution de la requête** : le plan d'exécution est compilé et exécuté.

Support du traitement d'une requête

Le traitement s'appuie sur les éléments suivants :

1. **Le schéma de la base**, description des tables et chemins d'accès (dans le catalogue)
2. **Des statistiques** : taille des tables, des index, distribution des valeurs
3. **Des opérateurs** : il peuvent différer selon les systèmes

Important : on suppose que le temps d'accès à ces informations est négligeable par rapport à l'exécution de la requête.

Les blocs SQL

Une requête SQL est décomposée en blocs, et une optimisation d'applique à chaque bloc.

Un bloc est une requête "select-from-where" sans imbrication. Exemple:

```
select titre
from   Film
where  annee = (select min (annee) from Film)
```

Premier bloc: calcule une valeur *v*.

```
select min (annee) from Film
```

Second bloc: utilise *v* comme critère.

```
select titre from   Film  where  annee = v
```

Quelle est l'influence du découpage en blocs?

En principe, le système devrait pouvoir déterminer les requêtes équivalentes, indépendamment de la syntaxe.

En principe, ça ne se passe pas tout à fait comme ça...

Dans quel film paru en 1958 joue James Stewart?

Expression SQL "à plat":

```
select titre
from   Film f, Role r, Artiste a
where  a.nom = 'Stewart' and a.prenom='James'
and    f.id_film = r.id_film
and    r.id_acteur = a.idArtiste
and    f.annee = 1958
```

Une autre syntaxe pour la même requête

Expression SQL équivalente, avec `in`.

```
select titre
from   Film f, Role r
where  f.id_film = r.id_film
and    f.annee = 1958
and    r.id_acteur in (select id_acteur
                       from Artiste
                       where nom='Stewart'
                       and prenom='James')
```

Encore une autre syntaxe

Expression SQL équivalente, avec `exists`.

```
select titre
from   Film f, Role r
where  f.id_film = r.id_film
and    f.annee = 1958
and    exists (select 'x'
               from Artiste a
               where nom='Stewart'
               and prenom='James'
               and r.id_acteur = a.id_acteur)
```

Avec encore plus de blocs

C'est plus clair comme ça?

```
select titre from Film
where annee = 1958
and  id_film in
       (select id_film from Role
        where id_acteur in
             (select id_acteur
              from Artiste
              where nom='Stewart'
              and prenom='James'))
```

Une dernière

Maintenant, avec `exists`.

```
select titre from Film
where annee = 1958
and exists
      (select * from Role
       where id_film = Film.id
       and exists
           (select *
            from Artiste
            where id = Role.id_acteur
            and nom='Stewart'
            and prenom='James'))
```

Important: On risque de fixer la manière dont le système évalue la requête.

Pourquoi c'est mauvais?

Les deux dernières versions aboutissent à un plan d'exécution sous-optimal.

- On parcourt tous les films parus en 1958
- Pour chaque film : on cherche les rôles du film, **mais pas d'index disponible**
- Donc pas d'autre solution que de parcourir tous les rôles, **pour chaque film**.
- Ensuite, pour chaque rôle on regarde si c'est James Stewart

Ca va coûter cher !!

Comprendre: pourquoi pas d'index disponible sur `Role`?

La table `Role`, avec une clé composite.

```
create table Role (id_acteur integer not null,
                   id_film integer not null,
                   nom_role varchar(30) not null,
                   primary key (id_acteur, id_film),
                   foreign key (id_acteur) references Artiste(id),
                   foreign key (id_film) references Film(id),
                   );
```

Regardez bien la clé primaire, et pensez à l'arbre B associé. **Peut-on l'utiliser?**

- Recherche sur `id_acteur` et `id_film`. **Oui**.
- Recherche sur `id_acteur` . **Oui**.
- Recherche sur `id_acteur` . **Non**.

Conclusion: requêtes SQL et blocs

La leçon: mieux vaut écrire les requêtes SQL "à plat", en un seul bloc, **et laisser le système décider du meilleur agencement des accès**.

Confronté à des requêtes SQL à plusieurs blocs: **Etudier le plan d'exécution pour vérifier que les index sont correctement utilisés**.

On va voir comment faire par la suite.

Traitement d'un bloc

Plusieurs phases:

Analyse syntaxique: conformité SQL, conformité au schéma.

Analyse de cohérence: pas de clause comme `annee < 200 and annee > 2001`

Si OK, traduction en une expression algébrique, plus "opérationnelle" que SQL.

Retenir

Toute requête SQL se réécrit en une expression de l'algèbre.

(Pas tout à fait vrai: `group by`, `having`, `order by`. Oublions.)

Exemple de réécriture

On prend comme exemple: le titre du film paru en 1958, où l'un des acteurs joue le rôle de John Ferguson.

En SQL:

```
select titre
from   Film f, Role r
where  nom_role ='John Ferguson'
and    f.id = r.id_ilm
and    f.annee = 1958
```

En algèbre:

$$\pi_{titre}(\sigma_{annee=1958 \wedge nom\_role='\text{John Ferguson}'}(Film \bowtie_{id=id\_film} Role))$$

Le Plan d'Exécution Logique (PEL)

L'expression algébrique nous donne une ébauche de plan d'exécution.

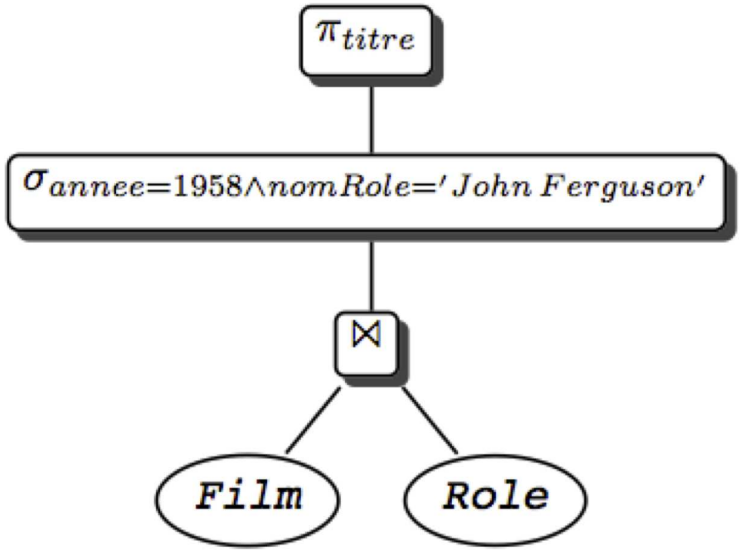

Est-ce le bon? Pas forcément: **l'optimisation** va nous permettre d'en trouver d'autres et de les comparer.