Bases de données

Polytech Paris-Sud

Apprentis 4ème année

Cours 4 : Optimisation des opérateurs

kn@lri.fr
http://www.lri.fr/~kn

Plan

Principe d'évaluation d'une requête

1. *Parsing* de la requête
2. Traduction en arbre d'opérateurs de l'algèbre relationnelle (π, σ, ⋈, ...)
3. Optimisation :
    1. Génération de plans d'évaluation (en réordonnant les opérations élémentaires)
    2. Estimation du coût de chacun des plans (en fonction du coût des opérations élémentaires)
    3. Choix du plan le plus efficace
4. Évaluation du plan choisi
5. (Éventuellement mise à jour des statistiques)

Avant de s'intéresser à l'évaluation complète d'une requête, on étudie l'évaluation des opérateurs et leur coût respectifs

Plan

Jointure naturelle sur une colonne

Considérons :

```
SELECT *
FROM people,role
WHERE people.pid = role.pid;
```

Opéreeation fondamentale utilisée par toutes les applications BD.
L'AR nous dit que $R \bowtie S = \sigma_{=}(R \times T)$**, mais c'est très inefficace, on veut optimiser ce cas!**

On suppose dans la suite M enregistrements dans R, P_R **enregistrements/page, N enregistrement dans S,** P_S **enregistrements/page.**

On pose pour les exemples: M=1000, N=500, P_R**=120,** P_S**=100**

L'attribut commun est `a`**.**

Le coût est toujours le nombre d'E/S (en ignorant l'écriture du résultat)

Jointure itérative simple

On effectue une double boucle imbriquée:

```
for each record r ∈ R do
   for each record s ∈ S do
    if r.a = s.a then res += r ⋈ s #jointure élémentaire de
   done                            #2 enregistrements
done
```

Pour chaque enregistrement de la relation externe (R) on scanne entièrement la relation interne (S)

Coût: $M + P_R * M * N$

Exemple: 1000 + 120*1000*500 = 60 001 000 E/S!

Jointure itérative page à page

On effectue une double boucle imbriquée:

```
for each page P ∈ R do
   for each page Q ∈ S do
    res += P ⋈ Q  #jointure entre 2 pages
   done           # peut être faite de manière simple
done
```

Pour chaque page de la relation externe (R) on scanne entièrement la relation interne (S)

Coût: M + M * N
Exemple: 1000 + 1000*500 = 501 000 E/S!
Optimisation: mettre la relation la plus petite à l'extérieur:
500 + 500*1000 = 500 500

Jointure itérative avec index

On effectue une double boucle imbriquée:

```
for each record r ∈ R do
   for each record s ∈ S where r.a = s.a do
   #l'index doit permettre un accès rapide à la colonne a
     res += r ⋈ s
   done
done
```

On exploite l'existence d'un index sur l'une des relation pour en faire la relation interne.

Coût: M + P_R * M * (coût d'accès index + coût index ↦ données)

Plusieurs variantes: B+-tree/Hash-index, groupant/non-groupant,...

Jointure par bloc (avec pages bufferisées)

On exploite le *buffer* (de taille B+2 pages, B = 10) de la manière suivante:

- 1 page du *buffer* pour l'écriture du résultat
- 1 page du *buffer* pour la relation interne (S)
- B pages du *buffer* pour la relation externe

```
for each block b of size B ∈ R do
   for each page Q ∈ S  do
     res += b ⋈ Q #en utilisant la méthode simple
   done
done
```

Coût: M + N * [M/B]

Exemple: 1000 + 500 * 1000/10 = 51 000

Variante: blocs sur R et S

Jointure par tri-fusion 1/2

Idée: « l'intersection » de deux listes est aisée si les deux listes sont triées

```
sort R on a as Rs
sort S on a as Ss
r := Rs.next();  #On suppose R et S non vides
s := Ss.next();  #Sinon jointure vide directement
while Rs and Ss are not empty do
   while r.a != s.a do  #avance jusqu'à trouver la même valeur
     while r.a < s.a do
      if Rs.hasNext() then r:= Rs.next() else finished
     done
     while s.a < r.a do
      if Ss.hasNext() then s:= Ss.next() else finished
     done
   done
   val := r.a #on prend la liste des enregistrements
              #ayant la même valeur d'attribut de jointure
   P, Q := empty pages
   while r.a = val do P += r; r:= Rs.next() done
   while s.a = val do Q += s; s:= Ss.next() done
   res += P ⋈ Q
done
```

Jointure par tri & fusion 2/2

Coût: $M \cdot \log_2 M + N \cdot \log_2 N + M + N$

Exemple: $1000^* (1+\log_2 1000) + 500 * (1+\log_2 500) = 15492$

Le tri n'est pas toujours nécessaire:

- si on a un index de type B+-tree sur l'attribut de jointure (pour l'une des relations)
- si R ou S (ou les deux) sont déjà le résultat de tris (`ORDER BY`)

Jointure par hachage

On choisit une fonction de hachage `h` et on partitionne R selon `h(r.a)` pour obtenir K partitions

On partitionne S selon `h(s.a)` pour obtenir K partitions

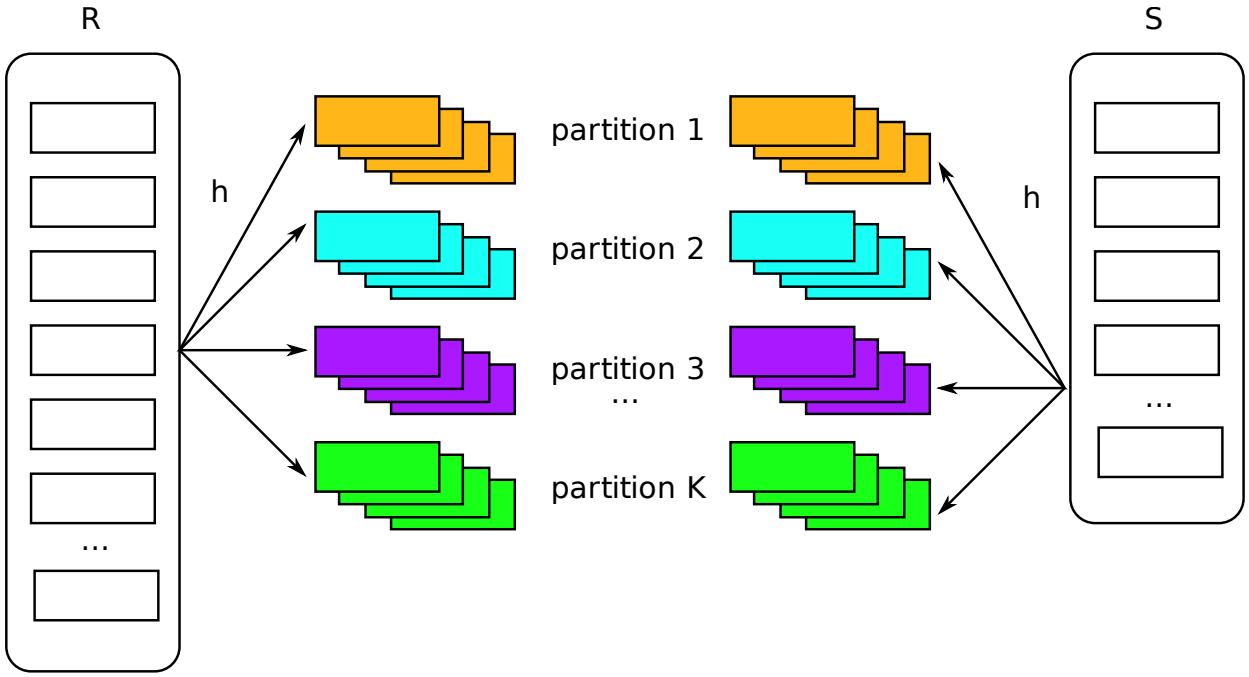

K choisi en fonction de la taille du *buffer*

Coût: 2(M+N) + M+N (pourquoi ?)

Jointures généralisées

- Égalité sur plusieurs attributs (`R.a = S.a AND R.b = S.b`) :
  - Jointure itérative par index: on peut créer un index pour S sur (a,b) ou utiliser des indexes existants sur l'un ou l'autre
  - On peut aussi utiliser jointure par tri-fusion et hachage en utilisant (a,b) comme clé de tri/hachage
- conditions d'inégalité:
  - Pour les jointures par index, il faut un arbre B+ groupant (sinon surcout pour aller chercher les données)
  - Jointure par tri-fusion et hachage impossible
  - Jointure itérative par bloc est la meilleure option en général

Plan

Selectivité

Taux de sélectivité d'une condition φ (ou d'une requête) pour une relation donnée:

$$\frac{\#\ \text{d'enregistrement sélectionnés}}{\#\text{d'enregistrements}}$$

Le choix de certains algorithmes dépend de la sélectivité

On ne connait la « vraie » valeur de la sélectivité qu'après avoir évalué la requête

On utilise des statistiques sur les relations pour tenter une approximation du taux de sélectivité

Statistiques sur les relations

Le SGBD concerve, entre autres, les statistiques suivantes pour chaque relations R:

- Nombre d'enregistrements (N), taille d'un enregistrement, nombre d'attributs/page (P)
- Nombre de pages de la relation (les pages ne sont pas toutes remplies de manière optimale)
- V(a) : nombre de valeurs distinctes pour l'attribut a (dans la relation R)
- Estimation de selectivité pour l'attribut a: V(a)/N
- Profondeur pour les arbres B+
- Nombre de page pour les feuilles d'un arbre B+
- Nombre de valeurs distinctes pour la clé de recherche d'un index

Sélection

Sélection simple, égalité avec une constante : Scan ou Index (si groupant)

Sélection simple avec index non groupant : Index + tri des adresses de pages, parcours ordonné. Très efficace si l'ensemble des adresses à trier tiens en mémoire

Sélection généralisés, deux approches:

1. On choisit une sous-condition (qui concerne le moins de pages = la plus sélective) et on applique les autres sous-conditions au résultat intermédiaire
2. Si on a deux sous-conditions « `AND` » avec 2 indexes (types 2 ou 3) séparés, calcul des ensembles de `rid` et intersection des résultats. On applique ensuite les autres critères.

Résultat trié/élimination des doublons

Plusieurs techniques :

- Utilisation d'un index (type B+-tree) si groupant ou si coût d'accès au données « raisonnable » (résultat dans l'index ou peu de résultats + accès aux données)
- Utilisation d'un tri explicite après calcul des résultats (+ élimination des doublons durant la phase de tri)

Projection

On parle ici de la projection, π de l'algèbre relationnelle, donc avec élimination des doublons :

```
SELECT DISTINCT a,b FROM t
```

- Si index sur `(a,b)` disponible, utilisation directe de l'index
- Sinon tri et projection durant la phase de tri
- Double partitionnement par hachage

Double partitionnement

Repose sur l'utilisation de deux fonctions de hachage h et g distinctes

1. **On partitionne R en K partitions en utilisant h**
2. **En suite pour chaque partition entre 1 et K, on crée une table de hachage en mémoire (avec g comme fonction) pour pour éliminer les doublons de la partition**

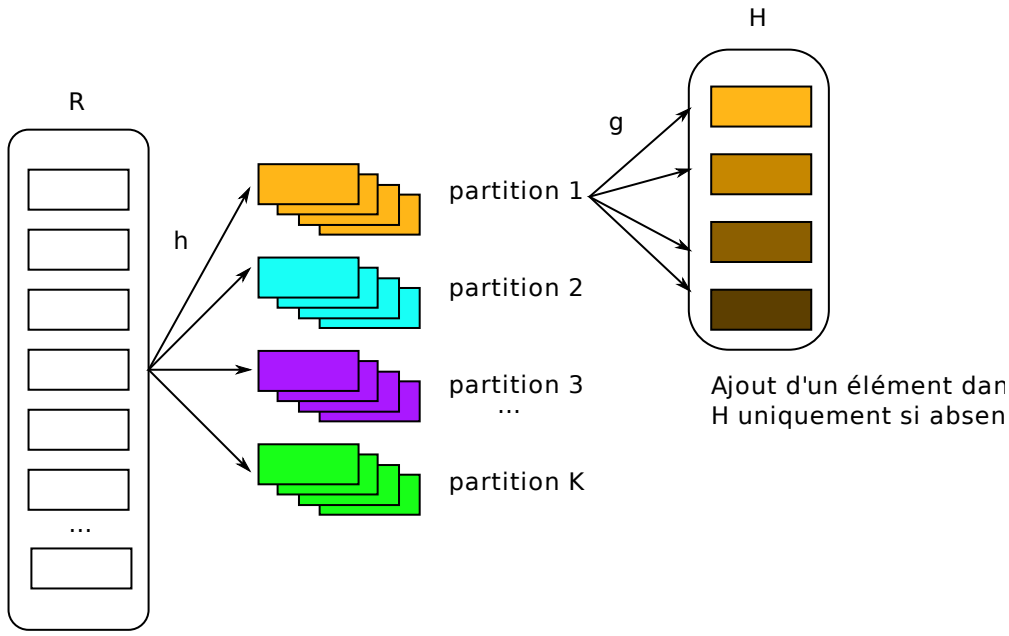

Permet d'effectuer « DISTINCT» sans tri!

Opérations ensemblistes

- **Intersection et produit cartésien: cas dégénérés de jointure (comment?)**
- `UNION DISTINCT` **et** `EXCEPT` **sont similaires. 2 approches:**
  1. **Par tri. On tri les deux relations sur tous les attributs et on fusionne en éliminant les doublons. Résultat trié**
  2. **Par hachage. Technique du double partitionnement. On partitionne R et S avec** `h`**. Pour chaque partition de S et R, on ajoute les éléments dans une table H, en éliminant les doublons**

Opérations d'agrégat

- **Sans** GROUP BY**:**
  - **En général, il faut faire un scan de la relation**
  - **Si les attributs agrégés sont dans un index, on peut faire un scan d'index uniquement (en espérant que l'index est plus petit)**
- **Avec** GROUP BY**: identique au cas sans** GROUP BY **mais tri préalable pour déterminer les groupes, et scan « groupe par groupe » pour calculer la fonction d'agrégat**

Conclusion

L'algèbre relationnelle est simple (quelques opérateurs pour exprimer l'ensemble des requêtes)

Chaque opérateur peut être réalisé de plusieurs manières différentes, avec différents compromis

Tout celà est encore complexifié quand on considère les compositions d'opérateurs (prochain cours)

Tout est encore plus complexifié si on considère que le SGBD gère plusieurs requêtes en parallèle (hors programme)

En pratique, une part importante du moteur de requête des SGBD est l'implantation d'heuristiques pour faire les meilleurs choix (ou plutôt, les moins pires).