Optimisation de SQL

Modèle relationnel élégant... et efficace ? – 15 ans de R&D !

Fabien Coelho – MINES ParisTech

Composé avec LaTeX, révision 3583

Optimisation : un problème global

interface client : GUI, web, mobile, ...

application charge, requêtes, latence vs débit

cache applicatifs, connexions...

base de données !

réseau reliant les éléments

système d'exploitation, de fichier

matériel disques, bus, processeurs, mémoire...

Différents types de requêtes

transactionnel accès à quelques tuples seulement
- accès rapide : utilisation d'index, cache mémoire
- mesure : débit (tps) et/ou latence (ms/t) VISA 2000 tps

décisionnel calcul systématique de statistiques
- toutes les données parcourues !
- recherche du meilleur plan de calcul...
- **pas**/**peu** d'utilisation d'index
- méthodes en mémoire vs accès disque

Deux conseils préalables

1. Configurations logicielles et matérielles

Postgres configuration `postgresql.conf`
- mémoire : `shared_buffers effective_cache_size`...
- WAL, checkpoint, vacuum...
- paramètres de coûts : HDD vs SSD ?

Système et matériel
- machine : virtuelle/réelle ? partagée/dédiée ? plusieurs ? CPU ?
- mémoire (cache OS) : disponible ? extension ?
- stockage HDD/SSD ? lents/rapides ? nombre ? W cache ? RAID ?
- choix et configurations : OS, FS, montage...

2. Connaître ses données et sa charge

taille gros ou petit *vs mémoire disponible*

usage principal : transactionnel vs décisionnel

accès lectures (SELECT) vs écritures (INSERT, UPDATE, DELETE)

modèle *grosses* tables et jointures ? *vs petites tables périphériques*

besoin latence (interactif) vs débit (batch) ?

requêtes fréquences, variabilité, criticité ? *requêtes lentes ?*

charge dans le temps : min (0 ?), max, périodes critiques ?

limite de performance : I/O, CPU, connexions...

stats cache hits ? qu'espère-t-on ? est-ce réaliste ?

Comment ça marche ?

Planification d'une requête

plans d'évaluation d'une requête
- requêtes algébriquement équivalentes
- différentes opérations élémentaires (selon les index)

coût évaluation d'un plan `EXPLAIN`...
- statisques sur les valeurs et tailles des données `ANALYZE`...
- comparaison avec exécution effective `EXPLAIN ANALYZE`...

choix problème d'optimisation difficile
- **combinatoire** ordre des jointures ? placement des filtres ?
- **approximation** coûts non connus... éviter le pire
- **heuristiques**, recuit simulé...

Opérations élémentaires d'une requête

parcours+filtrage d'une relation `WHERE...`

recherche des tuples satisfaisant une condition

tri d'une relation `ORDER BY...`

fixe l'ordre des tuples

jointure+condition de deux relations `JOIN ON...`

mise en correspondance de tuples selon une condition

aggrégation d'une relation `GROUP BY`, `DISTINCT`, `UNION`...

regroupement des éléments selon un critère

etc.

Coût des opérations élémentaires

taille des données : nombre de tuples, d'attributs, leurs tailles

valeur des données ! sélectivité d'une conditions (proba. d'être vrai)

implique souvent la taille des résultats !

```
WHERE id = 110;     -- clef primaire (0-1)
WHERE id > 0;       -- 100%
WHERE promo = 110; -- fraction des élèves...
WHERE age <> 110;   -- 100%
WHERE année = 110; -- 0%
```

ressources disponibles : mémoire, charge machine...

statisques min/max, moyenne, distribution avec `ANALYZE`

Stockage des données : la hiérarchie mémoire

un processeur passe son temps à attendre les données !

Type	Taille	Latence	Débit **max** R
registre	n Ko	1 ns	50 GB/s
cache	256 Ko-4 Mo	10 ns	16 GB/s
RAM	512 Mo-16 Go	100 ns	6 GB/s
SSD 1	64 Go-1 To	100 μs	50-150 MB/s
HDD 1	500 Go-6 To	10 ms	50-200 MB/s
**D RAID 5	–	–	100-500 MB/s
réseau	–	150 μs	100 MB/s

Latence : HDD/RAM = $\times 100,000$ SSD/RAM = $\times 1,000$

IBM 350 Disk File

— 1956
— HDD du 305 RAMAC
ram account. syst.
— 24 disques
— capacité 4.4 MB !
5 M 7bit chars
— location
$35,000 par an

Technologie des disques magnétiques

— plateaux, faces, cylindres, secteurs, blocs...

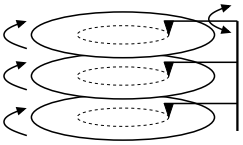

— pérenne par rapport à la mémoire vive (panne courant)
attention aux options FS, HDD et montage
BBU vs *write cache* (RAID et **D)
— entrées-sorties limitent les performances *I/O bound*
si la base est petite, elle tient en mémoire !
— cache disque DB et système

Mesure de coûts : I/O !

unité d'accès page PostgreSQL : 8 KB (Linux `ext4` : 4 KB)

accès séquentiel HDD/SSD typiquement X00 MB/s
variation : bus IDE/SCSI, vitesse rotation, RAID, charge...

accès aléatoire HDD typiquement 1 à 10 MB/s
latence disque : déplacement du bras (3-15 ms) et rotations
un ordre de grandeur du séquentiel

accès aléatoire SSD 10-300 MB/s, X0 K IOPS
typiquement 60-70% performance accès séquentiels

calculs et accès mémoire simplement négligés !
très rapide par rapport aux accès disques

Évolutions des *Solid-State Drive* : SSD

mémoire flash **permanente** (appareils photos, MP3)
cache de disques magnétiques ? disques complets ?

performances des SSD : R/W, débit/latence, aléa/séq
— lecture ≈ écriture (100-200 MB/s) ≈ **HDD**
— aléatoire ≈ séquentiel ≠ **HDD**
— **usure** : si plein écriture aléatoire lente, nombre limité !
cycle W page (4 KB) vs Erase block (512 KB)

impact coûts $\times 8 - 15$, capacité $\times \frac{1}{4} - \frac{1}{8}$
performances & optimisations ?
vitesse par *tablespace*...

Paramètres de modélisation I/O HDD

B taille d'un bloc de la base en octet (vs bloc FS)
k lecture séquentielle d'un bloc en seconde
$K \gg k$ lecture aléatoire d'un bloc en seconde
n_{R} nombre de tuples d'une relation R
t_{R} taille en octets d'un tuple de R
$S_{\mathrm{R}} = n_{\mathrm{R}} t_{\mathrm{R}}$ taille de la relation
s_{a} taille en octet d'un attribut particulier
g probabilité de regroupement (coefficient d'aggrégation)
j probabilité de jointure selon une condition...
M mémoire disponible (cache, données temporaires)

Parcours+Filtrage : parcours séquentiel

sequential scan $k\frac{tn}{B}$

lecture d'une relation sur disque

filtrage des tuples au cours du parcours

```
SELECT * FROM oeuvres
WHERE titre LIKE 'A%';
```

```
seq scan on oeuvres
  filter: titre LIKE 'A%'
```

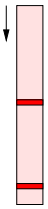

Parcours+Filtrage : parcours indexé

index scan $K + K\ln(ns/B)$

accès *direct* à quelques tuples... mais coût de l'utilisation de l'index !

```
SELECT * FROM oeuvres
WHERE id BETWEEN 12 AND 14
  AND titre LIKE 'A%';
```

```
index scan using oeuvres_pkey on oeuvres
  index cond: id>=12 AND id<=14
  filter: titre LIKE 'A%'

index scan using oeuvres_titre_idx on oeuvres
  index cond: titre LIKE 'A%'
  filter: id>=12 AND id<=14
```

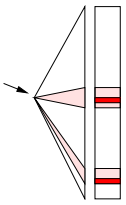

Parcours+Filtrage(S) : index bitmap

bitmap index scan création de bitmaps combinables à partir d'index

1 page = 1 bit, puis accès aux pages

```
SELECT * FROM oeuvres
WHERE oid < 100 AND cid < 10;
```

```
bitmap heap scan on oeuvres
  bitmap and
    bitmap index scan on oeuvres_pk
      index cond: oid < 100
    bitmap index scan on oeuvre_cid
      index cond: cid < 10
```

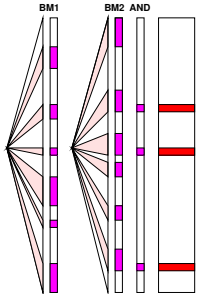

Indexation des attributs d'une relation

principes simples, détails compliqués et subtils...

retrouver des tuples rapidement selon le critère indexé

Hash sur disque
- — permet uniquement des recherches = et <>
- — 10-20% plus rapide de B-tree ?

B-tree *(Balanced tree)* relation d'ordre !
- — variantes : denses ? partiels ? unique ? multi-niveau ? équilibre ?
- — égalités = <>, intervalles < <= > >=, extrêmes `MIN MAX`

Bloom aggrégation de valeurs de colonnes = `AND`

R-tree *(Region tree)* – données géométriques (géographiques ?)

GiST *Generalized Search Tree* – texte, *lossy*

GIN *Generalized Inverted Index* – texte

B-tree

- — arbre n-aire, séparation sur valeurs limites ($<$)
- — feuilles référencent les tuples ou les pages contenant les tuples

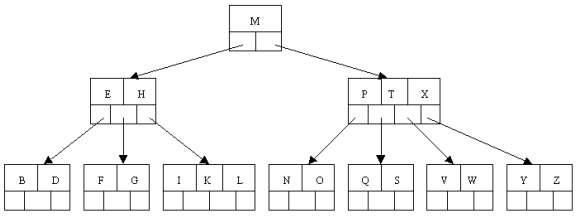

Dessin : Br. David Carlson and Br. Isidore Minerd, Saint Vincent College *P ? K ? R ?*

Création d'un index

- — unique (pour une clef) ou non
- — précise la méthode d'indexation
- — attributs/expressions indexés **ensembles** (ordre lexicographique)
- — options diverses (NULLS, ...)
- — création automatique : `UNIQUE`, *e.g.* clefs primiaires

```
CREATE [ UNIQUE ] INDEX idxname
ON tablename USING [ hash | btree | rtree | gist ]
( { column | (expr) }[, ...] )  [ WHERE predicat ];
```


Importance des index

- — utilisation **éventuelle** par les requêtes ! `SELECT`
- — vérification des contraintes `INSERT UPDATE DELETE`
  existance de clefs étrangères, unicité d'une clef...
- — forcer l'ordre de stockage `CLUSTER...`
  parcours séquentiel dans l'ordre d'un index particulier

Coût des index

- — espace disque utilisé
- — présence en mémoire
- — maintenance à chaque opération `INSERT UPDATE DELETE`

Index sur un attribut

```
SELECT * FROM oeuvre
WHERE titre = 'Triple Jeu';
```

```
CREATE INDEX oeuvre_titre
ON oeuvre(titre);
```

Index avec prédicats

- indexation partielle : taille et coût réduits
- restreint à une recherche avec ce prédicat
- utile pour contraintes partielles...
  si telle condition, tel attribut est unique...

```
SELECT * FROM answer
WHERE idUsr=12 AND isLast;

CREATE INDEX active_user_answer
ON answer (idUsr)
WHERE isLast;
```


Index fonctionnels

- indexation de calculs sur les attributs
- restreint à une recherche avec cette fonction *immutable*

```
SELECT titre FROM oeuvre
WHERE UPPER(titre)='SLALOMS';

CREATE INDEX titre_upper
ON oeuvre
USING BTREE ((UPPER(titre)));
```


Texte : ordre alphabétique selon la langue...

posix
Akin
Akın
cotée
côté
grot
groß
ninon
niño

espagnol
Akin
Akın
côté
cotée
groß
grot
ninon
niño

français
Akin
Akın
côté
cotée
groß
grot
niño
ninon

turque
Akın
Akin
côté
cotée
groß
grot
niño
ninon

Index texte

- indexation de champs texte par défaut sur octets (plus rapide)
  mais ordre incompatible avec les caractères
- préciser une option, éventuellement la langue `COLLATE`
  indexation basée sur les caractères

```
SELECT * FROM auteur WHERE nom LIKE 'Début%';

CREATE INDEX auteur_nom_fr
ON auteur(nom text_pattern_ops);

CREATE INDEX auteur_nom_fr
ON auteur(nom COLLATE "fr_FR" text_pattern_ops);
```


Index *Bloom*

`http://blog.coelho.net/database/2016/12/11/postgresql-bloom-index.html`

Index *R-Tree*

Index pour *Full Text Search* (FTS)

Index sur trigrammes `pgtrgm`

Tri d'une relation

- tri fusion *merge sort* de bloc triés
- espace mémoire et disque utilisable ?
  meilleures techniques avec parcours séquentiels...
- nombreuses variantes... $kXn\ln(n)$
- demandée par l'utilisateur, ou techniques de calcul

  `ORDER BY` évidemment !

  `GROUP BY` et regroupement des données contiguës

  `DISTINCT` similaire au précédent

  `JOIN ON` jointure par fusion

Jointures de relations

- relation (= ou autre...) entre attribut(s), clefs ou non...
- tables jointes de cardinalité n_{R} et n_{P}, résultat $jn_{\mathrm{R}}n_{\mathrm{P}}$
- évaluation de j selon les données ?

vnom	*dpt*
Avon	77
Briare	45
Cahors	46
Figeac	46
Fontainebleau	77
Gien	45
Héricy	77
Marseille	13

dpt	*dnom*
13	Bouches du Rhône
36	Indre
45	Loiret
46	Lot
75	Paris
73	Savoie
77	Seine et Marne

Jointure par fusion triée

- tri des relations selon le critère de jointure !
  puis parcours parallèle et fusion au vol des relations
  $\frac{k}{B}(t_{\mathrm{R}}(Xn_{\mathrm{R}}\ln(n_{\mathrm{R}})+n_{\mathrm{R}})+t_{\mathrm{P}}(Yn_{\mathrm{P}}\ln(n_{\mathrm{P}})+n_{\mathrm{P}})+t_{\mathrm{RP}}jn_{\mathrm{R}}n_{\mathrm{P}})$
- écriture ou exploitation au vol du résultat ?

vnom	*dpt*
Marseille	13
Briare	45
Orléans	45
Gien	45
Cahors	46
Figeac	46
Paris	75
Vulaines	77

dpt	*dnom*
13	Bouches du Rhône
36	Indre
45	Loiret
46	Lot
73	Savoie
75	Paris
77	Seine et Marne

Jointure par hash

— relation mise en **mémoire**, indexée par critère de jointure
puis parcours séquentiel de l'autre relation

$$\frac{k}{B}(t_{\mathrm{R}} n_{\mathrm{R}} + t_{\mathrm{P}} n_{\mathrm{P}} + t_{\mathrm{RP}} j n_{\mathrm{R}} n_{\mathrm{P}})$$

— la mémoire doit être suffisante... risque de *swap* ?

Autres techniques de calculs de jointure

boucles différentes variantes, avec index...

filtre produit cartésien, puis filtrage...

Agrégations

— regroupements si attributs égaux : `GROUP BY`, `DISTINCT`
— évaluation du taux de regroupement g ?
— parallélisation depuis postgres 9.6...

Département	*Ville*
Seine et Marne	Avon
Loiret	Briare
Lot	Cahors
Lot	Figeac
Seine et Marne	Fontainebleau
Loiret	Gien
Seine et Marne	Héricy
Bouches du Rhône	Marseille

Agrégation par fusion triée

— tri de la relation selon le critère d'agrégation
groupement ou agrégation des éléments contigus

$$\frac{k}{B}(Xn\ln(n) + tn + gtn)$$

Département	*Ville*
Bouches du Rhône	Marseille
Loiret	Briare
Loiret	Orléans
Loiret	Gien
Lot	Cahors
Lot	Figeac
Paris	Paris
Seine et Marne	Vulaines

Département	*Nb villes*
Bouches du Rhône	1
Loiret	3
Lot	2
Paris	1
Seine et Marne	7

Agrégation par hash

— allocation en mémoire du résultat gtn !
— remplissage lors du parcours, puis écriture ou exploitation

$$\frac{k}{B}(tn + gtn)$$

Exemples de `EXPLAIN` et `EXPLAIN ANALYZE`

EXPLAIN plan de la requête
— *méthode* de calcul
— temps (sans unité) premier résultat et fin
paramètres ajustables dans la configuration
— volumes nb tuples et tailles

EXPLAIN ANALYZE plan et exécution
— ajoute le réalisé
— détection des erreurs d'évaluation

— interprétation, voir `http://explain.depesz.com/`

Select simple

```
SELECT titre FROM films WHERE fid=3;
```

explain

```
Seq Scan on films  (cost=0.00..1.14 rows=1 width=12)
  Filter: (fid = 3)
```

explain analyze

```
Seq Scan on films  (cost=0.00..1.14 rows=1 width=12)
                   (actual time=0.013..0.015 rows=1 loops=1)
  Filter: (fid = 3)
  Rows Removed by Filter: 10
Total runtime: 0.044 ms
```


Select jointure

```
SELECT titre FROM films JOIN personnes USING (pid)
WHERE nom='Chaplin';
```

explain

```
Hash Join  (cost=1.09..2.26 rows=2 width=12)
  Hash Cond: (films.pid = personnes.pid)
  -> Seq Scan on films  (cost=0.00..1.11 rows=11 width=16)
  -> Hash  (cost=1.07..1.07 rows=1 width=4)
    -> Seq Scan on personnes  (cost=0.00..1.07 rows=1 width=4)
       Filter: (nom = 'Chaplin'::text)
```


explain analyze

```
Hash Join  (cost=1.09..2.26 rows=2 width=12)
           (actual time=0.051..0.124 rows=6 loops=1)
  Hash Cond: (films.pid = personnes.pid)
  -> Seq Scan on films  (cost=0.00..1.11 rows=11 width=16)
                        (actual time=0.008..0.075 rows=11 loops=1)
  -> Hash  (cost=1.07..1.07 rows=1 width=4)
           (actual time=0.021..0.021 rows=1 loops=1)
     Buckets: 1024  Batches: 1  Memory Usage: 1kB
     -> Seq Scan on personnes  (cost=0.00..1.07 rows=1 width=4)
                               (actual time=0.010..0.016 rows=1 loops=1)
        Filter: (nom = 'Chaplin'::text)
        Rows Removed by Filter: 5
Total runtime: 12.654 ms
```

Exemples de création d'index

Analyse d'une requête pour proposer un `INDEX`

1. à partir de `EXPLAIN` (`ANALYSE`)
   index pour parcours séquentiels filtrés (coûteux) *Seq Scan Filter*
   mais dépend du plan particulier choisit...
2. à partir de la requête
   — partir des informations les plus sélectives `WHERE`
   en particulier sur les *grosses* tables
   vérifier que les index utiles existent
   — propager le long des jointures
   vérifier que les index utiles existent

Exemple de proposition d'index (1)

```
SELECT titre
FROM auteur
JOIN a_ecrit USING (aid)
JOIN oeuvre USING (oid)
WHERE nom = 'Goscinny';
```

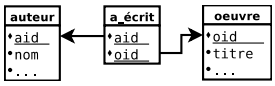

— `nom` → `aid` sur `auteur` index `auteur(nom)`
— `aid` → `oid` sur `a_ecrit` index `a_ecrit(aid)`
existe déjà, préfix clef composite
— `oid` → `titre` sur `oeuvre` : index `oeuvre(oid)`
existe déjà, `oid` est clef primaire

Exemple de proposition d'index (2)

```
SELECT DISTINCT pseudo
FROM auteur
JOIN a_ecrit USING (aid)
JOIN oeuvre USING (oid)
JOIN collection USING (cid)
WHERE cnom = 'Lapinot';
```

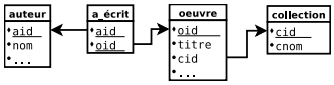

— `cnom` → `cid` sur `collection` index `collection(cnom)`
existe déjà, contrainte d'unicité
— `cid` → `oid` sur `oeuvre` index `oeuvre(cid)`
— `oid` → `aid` sur `a_ecrit` index `a_ecrit(oid)`
— `aid` → `pseudo` sur `auteur` index `auteur(aid)`
existe déjà, clef primaire

Collecte d'informations

— niveaux à considérer : client, **base de données**, OS
— très nombreuses informations disponibles
— mais non historisées

Informations

1. volumes de données *pg_*_size()*
2. statistiques sur données pour optimisation *analyze*
3. historique requêtes et performances *log*
4. état courant (connexions, verrous, requêtes) *système*
5. opérations tables/indexes *stat rel* (row)
6. comptages accès disque/cache *stat io* (block)
7. informations sur les requêtes *pg_stat_statements*

Postgres Performance Observability – *Alexey Lesovsky 2017*

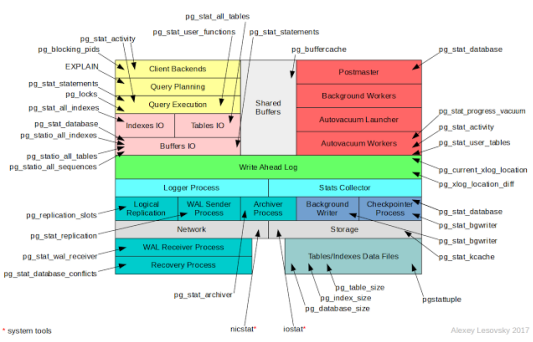

http://blog.postgresql-consulting.com/2017/02/deep-dive-into-postgres-stats.html

Informations sur les volumes

pg_column_size volume d'une donnée
pg_database_size volume d'un catalogue
pg_relation_size volume d'une table, d'un index
pg_total_relation_size complet avec index et *toasted*
pg_tablespace_size volume d'un espace (partition ?)
pg_size_pretty interprétation avec unités (kB, M...)

```
SELECT pg_size_pretty(pg_database_size('test'));
```

pg_size_pretty
11 MB

Table `pg_statistic`

— statistiques sur les valeurs de chaque colonne de chaque table
— mise à jour par la commande `ANALYZE` (sinon, vague défaut)
— utilisé par l'optimiseur pour évaluer les tailles de relations

filtrage nombreux opérateurs `WHERE ...`

regroupement `GROUP BY ...`

jointure `JOIN ... ON ...`

— selon le type analysé : min, max, moyenne, distribution...
— problème de droits d'accès : vue `pg_stats`

Collecte d'informations : requêtes, temps (attention au coût)

log_connection connexions à la base

log_statement requête exécutée

log_duration durée d'exécution

```
[15611]  LOG:  query:
  SELECT DISTINCT domaine, libMin
  FROM thes, statel
  WHERE statel.code_dipl=thes.domaine
    AND domaine BETWEEN 50000 AND 59999
  ORDER BY libMin
[15611]  LOG:  duration: 7.228555 sec
```


Configuration de la collection de statistiques

stats_start_collector collecteur démarré

processus séparé de collecte, pas temps-réel

stats_command_string requête en cours

stats_row_level statistiques sur les tuples

insert, update, fetch via indexes ou scans

stats_block_level accès blocs cache ou disque

Consultation des informations collectées

— nombreuses tables systèmes spéciales `pg_stat*`

niveau database, table et index, table, index...

opération scan avec ou sans index, ins/upd/del...

cache *read* (disque) vs *hit* (mémoire)

obsolète *fetch* vs *read*

— informations différées... pas trop de charge de collecte
— détection des indexes inutilisés, des tables scannées...

pg_stat_activity connexions et requêtes en cours (si longue)

datid	*datname*	*procpid*	*usename*	*current_query*	*query_start*
19007	corrector	563	corrector	`SELECT COUNT(*) FROM answer;`	2017-03-20...
19007	corrector	549	postgres	<IDLE>	2017-03-20...
19209	comics	676	coelho	<IDLE>	2017-03-20...

pg_stat_database par base de données

— # connexions en cours
— # transactions confirmées *(commit)* vs annulées *(rollback)*
— blocks lus sur disque, lus dans le cache
on espère read $\ll$ hit

datid	*datname*	*numbackends*	*xact_commit*	*xact_rollback*	*blks_read*	*blks_hit*
17232	coelho	0	112	7	149	9077
19007	corrector	2	87633	7	1085	9681100
19209	comics	0	7785	*2593*	716	1047755
19499	comtest	0	326	171	347	82055
...	...	.	...	...	...	...

pg_stat_user_tables utilisation des tables `all user sys`

— nb parcours séquentiels et nb tuples lus (selon taille table)
— nb parcours indexés et nb tuples lus (comparables ?)
— nb d'insertions, mises à jour et effacement

relname	*sq_scan*	*sq_tup_read*	*idx_scan*	*idx_tup_fetch*	*n_tup_ins*	*n_tup_upd*	*n_tup_del*
a_ecrit	75	31935	0	0	492	0	0
collection	81	3535	0	0	87	0	0
langue	44	48	0	0	2	0	0
exemplaire	82	20766	0	0	279	0	0
editeur	106	2586	0	0	67	0	0
auteur	204	15064	0	0	151	0	16
oeuvre	91	23387	119	116	298	13	0

pg_stat_io_user_tables disque/cache `all user sys`

— nombre de blocks table lus sur disque/cache
— index de blocks des indexes de la table lus sur disque/cache
— idem pour données *toastées* (attributs volumineux)...
on espère read $\ll$ hit

relname	*heap_read*	*heap_hit*	*idx_read*	*idx_hit*
oeuvre	3	1048	6	505
exemplaire	4	506	2	50
editeur	2	271	4	168
a_ecrit	3	894	3	198
auteur	2	605	2	154
langue	2	85	0	0
collection	2	287	4	172

pg_stat_user_indexes analyse par index `all user sys`

— nb parcours avec l'index
— nb tuples lus par l'index
— nb tuples récupérés par l'index

différent nb tuples lus pour tuples expirés

relname	*indexrelname*	*idx_scan*	*idx_tup_read*	*idx_tup_fetch*
auteur	auteurs_pkey	36	2414	2414
collection	collections_nom_key	2	86	86
collection	collections_pkey	1	43	43
exemplaire	exemplaires_pkey	0	0	0
oeuvre	oeuvres_pkey	1106	9935	9935
oeuvre	oeuvres_titre_key	15	3069	3069
a_ecrit	a_ecrit_pkey	127	53975	53975
…	…	…	…	…

pg_stat_io_user_indexes disque/cache `all user sys`

relname	*indexrelname*	*idx_blks_read*	*idx_blks_hit*
auteur	auteurs_pkey	2	73
collection	collections_nom_key	2	5
collection	collections_pkey	2	3
editeur	editeurs_nom_key	2	1
editeur	editeurs_pkey	2	1
exemplaire	exemplaires_pkey	2	1
langue	langues_nom_key	2	1
langue	langues_pkey	2	1
oeuvre	oeuvres_pkey	2	2213
oeuvre	oeuvres_titre_key	4	60
a_ecrit	a_ecrit_pkey	4	511

pg_stat_io_user_sequences disque/cache `all user sys`

relid	*schemaname*	*relname*	*blks_read*	*blks_hit*
19008	public	connection_idcon_seq	1	3
19019	public	users_idusr_seq	1	19
19034	public	class_idcls_seq	1	2
19121	public	correctiontype_idcor_seq	1	13
19133	public	question_idque_seq	1	75
19062	public	exercice_idexe_seq	1	1
19163	public	answer_idans_seq	1	659
19078	public	session_idses_seq	1	3

Extension `pg_stat_statements`

— extension standard à charger

```
CREATE EXTENSION pg_stat_statements;
-- and in postgresql.conf:
-- shared_preload_library = 'pg_stat_statements'
```

— statistiques par requêtes *similaires*, constantes ignorées

```
SELECT * FROM films WHERE titre LIKE 'C%';
SELECT * FROM films WHERE titre LIKE 'A%';
SELECT * FROM films WHERE titre LIKE 'L%';
-- regroupés sous :
SELECT * FROM films WHERE titre LIKE ?;
```


Exemple d'extraction des requêtes lentes

```
-- 10 requêtes les plus longues
SELECT query, total_time/calls AS avg
FROM pg_stat_statements
ORDER BY avg DESC LIMIT 10;

-- requêtes avec plus d'accès disques
SELECT query
FROM pg_stat_statements
ORDER BY shared_blks_read DESC LIMIT 10;
```


Monitoring système et base

ps top htop processus en cours…

iostat iotop df du charge et volume des partitions

nagios, cactus surveillance et alertes

pg watch interface web (PHP) de monitoring PostgreSQL

pg_activity pgtop requêtes en cours…

`https://wiki.postgresql.org/wiki/Monitoring`

`https://wiki.postgresql.org/wiki/Performance_Analysis_Tools`

Conclusion sur les performances

optimisation difficile : selon valeurs, statistiques nécessaires

identification extension *pg_stat_statements*

indexation requête transactionnelles, coût de maintenance

— choix des index et types pour les requêtes fréquentes
— collecte statistiques, utilisation des logs…

contrôle explicite des optimisations ?

— forcer les jointures : `join_collapse_limit=1`
— limites : `WITH`, `LIMIT 0`

caches données souvent sollicitées gardées en mémoire…

en particulier *petites* tables périphériques

influence du matériel à l'application

— matériel disponible, dédié ou partagé à l'application, duplication
ruptures technologiques : SSD vs HDD (vs Memristors ?)
séparation des flux (log, WAL, bgwriter)
— configuration de l'OS, de la base de donnée…
— maintenance DB `VACUUM FULL ANALYZE`…
— application : requêtes inutiles, relations mal conçues…
dénormalisation pour réduire les jointures ?

Autres solutions

— réplication *hot standby* et *pooling* ?
— distributions (applicative ?) sur des bases indépendantes ? *sharding*
e.g. déclarations d'impôts par régions. . .
— caches mémoire distribué ? solutions NoSQL ?
— **uniquement** si nécessaire : modèle dénormalisé/dynamique
utilisation plus lourde, programmation vs algèbre
pas nécessairement plus rapide, selon usage

List of Slides

1 Optimisation de SQL
2 Optimisation : un problème global
3 Différents types de requêtes
4 Deux conseils préalables
5 1. Configurations logicielles et matérielles
6 2. Connaître ses données et sa charge
7 Comment ça marche ?
8 Planification d'une requête
9 Opérations élémentaires d'une requête
10 Coût des opérations élémentaires
11 Stockage des données : la hiérarchie mémoire
12 IBM 350 Disk File
13 Technologie des disques magnétiques
14 Mesure de coûts : I/O !
15 Évolutions des *Solid-State Drive* : SSD
16 Paramètres de modélisation I/O HDD
17 Parcours+Filtrage : parcours séquentiel
18 Parcours+Filtrage : parcours indexé
19 Parcours+Filtrage(S) : index bitmap
20 Indexation des attributs d'une relation
21 B-tree
22 Création d'un index
23 Importance des index
23 Coût des index
24 Index sur un attribut
25 Index avec prédicats
26 Index fonctionnels
27 Texte : ordre alphabétique selon la langue. . .
28 Index texte
29 Index *Bloom*
29 Index *R-Tree*
29 Index pour *Full Text Search* (FTS)
29 Index sur trigrammes `pgtrgm`
30 Tri d'une relation
31 Jointures de relations
32 Jointure par fusion triée
33 Jointure par hash
33 Autres techniques de calculs de jointure
34 Agrégations
35 Agrégation par fusion triée
36 Agrégation par hash
37 Exemples de `EXPLAIN` et `EXPLAIN ANALYZE`
38 Select simple
39 Select jointure
41 Exemples de création d'index
42 Analyse d'une requête pour proposer un `INDEX`
43 Exemple de proposition d'index (1)
44 Exemple de proposition d'index (2)
45 Collecte d'informations
46 Informations
47 Postgres Performance Observability – *Alexey Lesovsky 2017*
48 Informations sur les volumes
49 Table `pg_statistic`
50 Collecte d'informations : requêtes, temps (attention au coût)
51 Configuration de la collection de statistiques
52 Consultation des informations collectées
60 Extension `pg_stat_statements`
61 Exemple d'extraction des requêtes lentes
62 Monitoring système et base
63 Conclusion sur les performances
65 Autres solutions