Concurrence : la grande contradiction

intégrité des données
- cohérence des transformations
- opérations liées, opérations en parallèle...

efficacité du système d'information
- ne pas bloquer les autres utilisateurs

Id: transaction.tex 4071 2020-04-29 05:26:11Z fabien

Transactions : requêtes cohérentes ensemble

BEGIN début de transaction

COMMIT fin de transaction, **validation**

ROLLBACK fin de transaction, **annulation**

sinon requêtes implicitement dans un BEGIN ... COMMIT

```
BEGIN;
INSERT INTO operations(libel,montant,src,dst)
  VALUES('pocket money',10.0,'Daddy','Calvin');
UPDATE comptes
  SET solde = solde+10.0 WHERE nom='Calvin';
UPDATE comptes
  SET solde = solde-10.0 WHERE nom='Daddy';
COMMIT; -- ou annulation avec ROLLBACK
```


Opérations annulables ?

- presques toutes ! TABLE ROLE FUNCTION...
- **sauf** manipulations DATABASE TABLESPACE...
- **sauf** compteurs de séquences NEXTVAL

```
BEGIN;
CREATE USER "hobbes" WITH PASSWORD 'c@lvin';
CREATE TABLE foo(id SERIAL, data TEXT);
INSERT INTO foo(id,data) VALUES('comics');
COMMIT; -- ou ROLLBACK;
```


Propriété ACID des transactions

Atomicité séquence considéré comme **une seule** opération

elle est complètement effectuée ou non effectuée

Consistance base doit être cohérence (même si annulation)

vérification des contraintes d'intégrité déclarées...

pas nécessairement en cours de route...

Isolation indépendance mutuelles des transactions

gestion de la concurrence (parallélisme)

totale ou partielle, pour améliorer les performances...

Durabilité les mises à jour sont permanentes

sauvegarde sur disque garantie après validation

Consistance/Isolation : comment ça marche ?

verrouillage des tables par les transactions (automatique)

mode de verrouillage selon les besoins

exclusion réciproque des verrous selon leur niveau

conséquence blocage si verrous incompatibles

assure la cohérence, mais pas la concurrence !

```
-- SELECT * FROM noms;
LOCK TABLE noms IN ACCESS SHARE MODE;
-- incompatible avec ACCESS EXCLUSIVE

-- ALTER TABLE noms ...
LOCK TABLE noms IN ACCESS EXCLUSIVE MODE;
```


Exemple de verrouillage

```
-- 1                        -- 2
BEGIN;                      BEGIN;
SELECT * FROM fruit;        SELECT * FROM fruit;
-- Pomme, Poire             -- Pomme, Poire

-- 3                        -- 4
UPDATE fruit                UPDATE fruit
SET nom='Cerise'            SET nom='Figue'
WHERE nom='Pomme';          WHERE nom='Pomme';
                            -- BLOCAGE !
-- 5
SELECT * FROM fruit;        -- 6
-- Poire, Cerise            -- DÉBLOCAGE !
COMMIT;                     -- pas de modif: nom='Cerise'
```


Étreinte fatale...*dead lock*

blocage par verrouillage croisé de ressources

conséquence fatal à au moins une des transactions !

solutions système ou applicative
- détection automatique toujours nécessaire
- éviter ? *acquisition explicite ordonnée de verrous ?*

Exemple Bancaire

```
-- quelques comptes bancaires...
CREATE TABLE comptes
  (nom TEXT UNIQUE NOT NULL,
   solde DECIMAL(10,2) NOT NULL);

INSERT INTO comptes VALUES('Calvin', 100.00);
INSERT INTO comptes VALUES('Hobbes', 100.00);
INSERT INTO comptes VALUES('Daddy', 1000.00);
INSERT INTO comptes VALUES('Mummy', 1000.00);
```

Transactions (bancaire et base) simultannées

```
-- Calvin -> Hobbes
-- 1
BEGIN;
UPDATE comptes
SET solde=solde+10.00
WHERE nom='Calvin';

-- 3
UPDATE comptes
SET solde=solde-10.00
WHERE nom='Hobbes';

-- 6
COMMIT;
```

```
-- Hobbes -> Calvin
-- 2
BEGIN;
UPDATE comptes
SET solde=solde+1.00
WHERE nom='Hobbes';

-- 4
UPDATE comptes
SET solde=solde-1.00
WHERE nom='Calvin';

-- 5
-- ERROR: deadlock detected...
```


Verrouillage manuel d'une table

— contrôle fin du mode de verrouillage
— verrous applicatifs *advisory locks*
usage systématique pour être efficace...

```
BEGIN;
LOCK TABLE fruit IN ACCESS SHARE MODE;

-- ...

-- déverrouillage à la fin de la transaction
COMMIT;
```


Modes de verrouillage de tables : conflits progressifs

Access Share accès en lecture simple — `SELECT ANALYZE`
Row Share — `SELECT FOR UPDATE`
Row Exclusive — `UPDATE DELETE INSERT`
Share Update Exclusive — `VACUUM ANALYSE...`
Share — `CREATE INDEX`
Share Row Exclusive — `ALTER TABLE, CREATE TRIGGER`
Exclusive — `REFRESH MATERIALIZED VIEW CONCURRENTLY`
Access Exclusive interdit tout — `DROP REINDEX...`

Aussi : verrous de niveau ligne *row-level locks*

Matrice des conflits entre modes

conflit	AS	RS	RE	SUE	S	SRE	E	AE
AS								x
RS							x	x
RE					x	x	x	x
SUE				x	x	x	x	x
S			x	x		x	x	x
SRE			x	x	x	x	x	x
E		x	x	x	x	x	x	x
AE	x	x	x	x	x	x	x	x

Liste des verrous : table système `pg_locks`

relation num table
database num catalogue
transaction num transaction
pid processus tenant le verrou
mode du verrou
granted si verrou accordé

locktype	*database*	*relation*	*transactionid*	*virtualtransaction*	*pid*	*mode*	*granted*
relation	28874	12073		3/1305	69818	AccessShareLock	t
virtualxid				3/1305	69818	ExclusiveLock	t
relation	28874	29688		3/1305	69818	ShareLock	t
relation	28874	29685		3/1305	69818	AccessExclusiveLock	t
transactionid			4942	3/1305	69818	ExclusiveLock	t
object	0			3/1305	69818	AccessShareLock	t
object	28874			3/1305	69818	AccessShareLock	t
relation	28874	29689		3/1305	69818	AccessExclusiveLock	t

COMMIT

Niveaux de verrouillage

BASE Access, SQLite...
PAGE contenant de tuples
TABLE selon opérations
TUPLE Postgres

Contrôle du verrouillage

— automatique par les opérations `INSERT UPDATE DELETE`
— manuel pour des tables `LOCK`...
— manuel pour des tuples `SELECT FOR UPDATE`

Isolation : interactions entre transactions

dirty read données non validées visibles
non-repeatable read modifications en cours — `UPDATE`
données vues validées mais différentes entre le début et la fin
phantom read résultats différents — `INSERT DELETE`
données ajoutées/modifiées/effacées validées par d'autres

Conséquences : risques d'incohérences...

Salade de fruits

```
CREATE TABLE fruit(id SERIAL, nom TEXT);
INSERT INTO fruit(nom) VALUES('Pomme');
INSERT INTO fruit(nom) VALUES('Poire');
```

Exemple *non-repeatable read* (update)

```
-- 1
BEGIN;
UPDATE fruit
SET nom='Cerise'
WHERE id=1;

-- 3
COMMIT;
```

```
-- 2
BEGIN;
SELECT * FROM fruit;
-- 1 Pomme, 2 Poire

-- 4
SELECT * FROM fruit;
-- 1 Cerise, 2 Poire
```

Exemple *phantom read* (insert, delete)

```
-- 1
BEGIN;
INSERT INTO fruit(nom)
VALUES('Figue');

DELETE FROM fruit
WHERE id=2;

-- 3
COMMIT;
```

```
-- 2
BEGIN;
SELECT * FROM noms;
-- 1 Cerise, 2 Poire

-- 4
SELECT * FROM noms;
-- 1 Cerise, 3 Figue
```


Exemple *dirty read*

```
-- 1
CREATE EXTENSION pg_dirtyread;
BEGIN;
SELECT * FROM fruit;

-- 3
SELECT * FROM fruit;
SELECT *
  FROM pg_dirtyread('fruit')
  AS t(xmin XID, xmax XID,
       id INT, name TEXT);

-- 5 bis repetita...
COMMIT;
```

```
-- 2
BEGIN;
DELETE FROM fruit
  WHERE id = 1;
UPDATE fruit
  SET nom = 'Ananas'
  WHERE id = 2;
INSERT INTO fruit(id, nom)
  VALUES (7, 'Cerise');
SELECT * FROM fruit;

-- 4
COMMIT;
```


Niveaux d'isolation des transactions

plus c'est sûr, plus c'est lent !

Isolation	*Dirty read*	*Non-repeatable read*	*Phantom read*
Read uncommitted	Oui	Oui	Oui
Read committed	Non	Oui	Oui
Repeatable read	Non	Non	Oui
Serializable	Non	Non	Non

Niveaux disponibles avec PostgreSQL

read uncommitted non, ou via extension **pg dirtyread**

read committed vision au début de chaque **requête**

serializable vision au début de la **transaction** !

Risques d'incohérence avec *read committed*

— dans des cas de mises à jours avec des conditions complexes

— en fait. . .pas si compliqué que ça !

Exemple : échange d'un attribut

```
Zoo(cage INTEGER PRIMARY KEY,
    animal TEXT NOT NULL);
```

cage	*animal*
1	lion
2	zebre
3	tigre

Échange de deux animaux

1. trouver les cages avec `SELECT`. . .
2. mettre à jour les animaux avec `UPDATE`

```
-- KO avec variables "psql"
\set x 'zebre'
\set y 'lion'
BEGIN;
SELECT cage AS n FROM zoo WHERE animal=:'x' \gset
SELECT cage AS m FROM zoo WHERE animal=:'y' \gset
UPDATE zoo SET animal=:'y' WHERE cage=:n;
UPDATE zoo SET animal=:'x' WHERE cage=:m;
COMMIT;
```

Un animal est-il toujours dans une cage ? NON !

— modification des données entre `SELECT` et `UPDATE`


```
BEGIN; -- lion/zebre
SELECT cage FROM zoo
 WHERE animal='lion'; -- 1
SELECT cage FROM zoo
 WHERE animal='zebre'; -- 2
UPDATE zoo SET animal='zebre'
 WHERE cage=1; -- locked

-- attente verrou...
UPDATE zoo SET animal='lion'
 WHERE cage=2;
COMMIT;
```

```
BEGIN; -- zebre/tigre
SELECT cage FROM zoo
 WHERE animal='zebre'; -- 2
SELECT cage FROM zoo
 WHERE animal='tigre'; -- 3
UPDATE zoo SET animal='tigre'
 WHERE cage=2; -- locked
UPDATE zoo SET animal='zebre'
 WHERE cage=3;
COMMIT;
```

cage	*animal*
1	zebre
2	lion
3	zebre

cage	*animal*
1	lion
2	tigre
3	zebre

Solutions : verrouillage. . .

`SERIALIZABLE` changement du mode de transaction. . .

`ROLLBACK` vérification applicative de la modification. . .

`FOR UPDATE` données verrouillées dès la consultation !

```
-- OK avec variables "psql"
\set x 'zebre'
\set y 'lion'
BEGIN;
SELECT cage AS n FROM zoo WHERE animal=:'x' FOR UPDATE \gset
SELECT cage AS m FROM zoo WHERE animal=:'y' FOR UPDATE \gset
UPDATE zoo SET animal=:'y' WHERE cage=:n;
UPDATE zoo SET animal=:'x' WHERE cage=:m;
COMMIT;
```


Besoins de reprises avec *serializable*

— abandon en cours de transaction si impossible !

— gestion reprise nécessaire par l'application

```
CREATE TABLE logiciel(nom TEXT);
INSERT INTO logiciel(nom) VALUES('apache');
INSERT INTO logiciel(nom) VALUES('perl');
```

Transactions sérialisées...

```
-- 1
BEGIN TRANSACTION ISOLATION
  LEVEL SERIALIZABLE;

-- 2
BEGIN;

-- 3
UPDATE logiciel
SET nom='ruby'
WHERE nom='perl';

-- 4
COMMIT;

-- 5
SELECT * FROM logiciel;
-- apache, perl

-- 6
UPDATE logiciel
SET nom='python'
WHERE nom='perl';
-- ERROR: could not serialize
--   access due to
--   concurrent update
```


MVCC : Multi-View Concurrency Control

objectif permettre la concurrence entre transactions

moins d'interactions entre verrous

vues différentes simultannées d'une même table

mises à jour, ajouts, effacements...

Vue concurrentes distinctes

```
-- 1
BEGIN;
SELECT * FROM fruit;
-- Pomme, Poire

-- 3
INSERT INTO fruit
VALUES('Banane');

-- 5
SELECT * FROM fruit;
-- Pomme, Poire, Banane
```

```
-- 2
BEGIN;
SELECT * FROM fruit;
-- Pomme, Poire

-- 4
INSERT INTO fruit
VALUES('Peche');

-- 6
SELECT * FROM fruit;
-- Pomme, Poire, Peche
```


Technique pour MVCC

xmin,xmax attributs supplémentaires des tables

début et fin de validité d'un tuple...

tuples non réellement effacés avant `VACUUM` !

xid numéro de transaction unique croissant

— transactions en cours : `txid_current()`

— transactions passées toutes validées

— transactions récentes validées ou annulées

stockées dans le répertoire `pg_xlog` ?

Exemple MVCC

```
CREATE TABLE legume(nom TEXT);
INSERT INTO legume(nom) VALUES('carotte');

-- 1 - xact 2301
BEGIN;
SELECT xmin, xmax, nom
FROM legume;
-- 2298 |    0 | carotte

-- 3
SELECT xmin, xmax, nom
FROM legume;
-- 2298 | 2302 | carotte
```

```
-- 2 - xact 2302
BEGIN;
DELETE FROM legume
WHERE nom='carotte';

-- 4
ROLLBACK;
```


Durabilité et Atomicité

écritures sur disque

— accès aléatoire lents...

— coordination des écritures multiples ?

WAL *(Write Ahead Log)*

— fichier séparé qui annonce les modifications des pages

séparation sur un disque différent ?

— accès contigus, regroupement de transactions simultannées

essentiel pour les performances en charge (vs MySQL)

— mise à jour différée des données *(bgwriter)*

Réplication de données

— scénario : du crash système à l'incendie...

— sauvegardes journalières ? attention !

— partage de charge ? découpage des données possible ?

disques mirroir, à distance via ethernet...

base réplication asynchrone, synchrone ?

application modifications parallèles vs sérialisation

Double validation *two-phase commit* 2PC

nécessaire aux transactions distribuées (et réplication synchrone ?)

préparation `PREPARE TRANSACTION ...`

nommage de la transaction pour reprise éventuelle

confirmation `COMMIT PREPARED` ou `ROLLBACK PREPARED`

attention : état intermédiaire bloquant (verrous)

```
BEGIN;
INSERT INTO vivement(sid,did,montant,libelle)
VALUES (12, 32, 100.00, 'retrait distributeur');
PREPARE TRANSACTION 'virement 64312';
-- ...
COMMIT PREPARED 'virement 64312';
-- OU BIEN
ROLLBACK PREPARED 'virement 64312';
```

Transactions préparées en cours ?

— description `pg_prepared_xacts` :
numéro de transaction, identifiant, date, catalogue
— surveillance périodique par l'application
— rapprochement manuel éventuel

Point de sauvegarde *savepoint*

— état intermédiaire d'une transaction complexe
— permet des reprises partielles

```
BEGIN;
INSERT INTO ...;
SAVEPOINT etat1;
  -- un essai, ERROR!
ROLLBACK TO SAVEPOINT etat1;
  -- un second essai, ok!
SAVEPOINT etat2;
...
COMMIT;
```


James Gray

1944-2007 (2012)
— Berkeley, IBM (System R)
Tandem, DEC, MS
— recherches DB
— verrous
— ACID
— 2PC
— CUBE
— gestion de caches
— Turing Award 1998

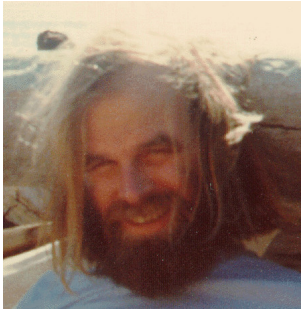

Conclusion sur les transactions

— préservation de la cohérence : **ACID**

Atomique WAL, MVCC

Consistante verrous, 2PC pour le distribué

Isolée niveaux, verrous, MVCC

Durable WAL (SSD ?)

— transactions concurrentes complexes :
doivent être programmées avec finesse !
risques d'abandon en cours de route ! reprise...
— pas toujours besoins !
perte de données non essentielles
réplications plusieurs mémoires/machines

List of Slides

1 Concurrence : la grande contradiction
2 Transactions : requêtes cohérentes ensemble
3 Opérations annulables ?
4 Propriété ACID des transactions
5 Consistance/Isolation : comment ça marche ?
6 Exemple de verrouillage
7 Étreinte fatale...*dead lock*
8 Exemple Bancaire
9 Transactions (bancaire et base) simultannées
10 Verrouillage manuel d'une table
11 Modes de verrouillage de tables : conflits progressifs
12 Matrice des conflits entre modes
13 Liste des verrous : table système `pg_locks`
14 Niveaux de verrouillage
14 Contrôle du verrouillage
15 Isolation : interactions entre transactions
15 Conséquences : risques d'incohérences...
16 Salade de fruits
16 Exemple *non-repeatable read* (update)
17 Exemple *phantom read* (insert, delete)
18 Exemple *dirty read*
19 Niveaux d'isolation des transactions
19 Niveaux disponibles avec PostgreSQL
20 Risques d'incohérence avec *read committed*
20 Exemple : échange d'un attribut
21 Échange de deux animaux
21 Un animal est-il toujours dans une cage ? NON !
23 Solutions : verrouillage...
24 Besoins de reprises avec *serializable*
25 Transactions sérialisées...
26 MVCC : Multi-View Concurrency Control
27 Vue concurrentes distinctes
28 Technique pour MVCC
29 Exemple MVCC
30 Durabilité et Atomicité
31 Réplication de données
32 Double validation *two-phase commit* 2PC
33 Transactions préparées en cours ?
34 Point de sauvegarde *savepoint*
35 James Gray
36 Conclusion sur les transactions