# Transactions

Fabien Coelho, Claire Medrala

Mines Paris – PSL

Décembre 2023






## Concurrence des accès

### Contradiction

**intégrité** des données
- cohérence des modifications, lecture et écriture...
- opérations liées vs en parallèle vs en conflit...

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

### Transactions

**commandes** `BEGIN COMMIT PREPARE ROLLBACK`

**propriétés** ACID

**implémentation** locks MVCC WAL...



## Transactions : requêtes cohérentes ensemble

### Commandes SQL

`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
```



## Transactions

### 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
BEGIN;
SELECT * FROM fruit;
-- Pomme, Poire

-- 3
UPDATE fruit
SET nom='Cerise'
WHERE nom='Pomme';

-- 5
SELECT * FROM fruit;
-- Poire, Cerise
COMMIT;
```

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

-- 4
UPDATE fruit
SET nom='Figue'
WHERE nom='Pomme';
-- BLOCAGE !

-- 6
-- DÉBLOCAGE !
-- 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),
  ('Hobbes', 100.00),
  ('Daddy', 1000.00),
  ('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* | *db* | *rel* | *tid* | *vtx* | *pid* | *mode* | *granted* |
|---|---|---|---|---|---|---|---|
| relation | 72962 | 12073 | | 3/196178 | 2108594 | AccessShareLock | t |
| virtualxid | | | | 3/196178 | 2108594 | ExclusiveLock | t |
| object | 72962 | | | 3/196178 | 2108594 | AccessShareLock | t |
| transactionid | | | 15007 | 3/196178 | 2108594 | ExclusiveLock | t |
| relation | 72962 | 73777 | | 3/196178 | 2108594 | AccessExclusiveLock | t |
| relation | 72962 | 73776 | | 3/196178 | 2108594 | ShareLock | t |
| object | 0 | | | 3/196178 | 2108594 | AccessShareLock | t |
| relation | 72962 | 73773 | | 3/196178 | 2108594 | AccessExclusiveLock | t |



## Verrouillage



### Niveaux

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

### Contrôle

- 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'), ('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*



```
-- 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;
```

```
-- 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;
```



## 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`



## Échange (suite)



```
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;
```

| *cage* | *animal* |
|---|---|
| 1 | zebre |
| 2 | lion |
| 3 | zebre |

```
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 | 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'), ('perl');
```



## Transactions sérialisées...



```
-- 2
BEGIN;

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

-- 4
COMMIT;
```

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

-- 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 (Jim) Gray 1944-2007 (2012)



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

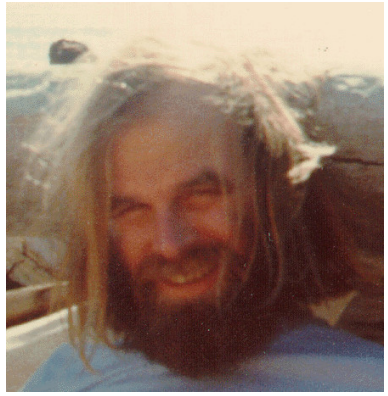

# Conclusion sur les transactions



- préservation de la cohérence : **ACID**
  - Atomique : WAL, MVCC
  - Consistante : verrous, 2PC pour le distribué
  - Isolée : niveaux, verrous, MVCC
  - Durable : WAL
- 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