



Transactions

Fabien Coelho, Claire Medrala

Mines Paris – PSL, MESR

Janvier 2025



Concurrence des accès

- Transactions
- FC/CM
- Intro
- Tx
- ACID
- Locks
- MVCC
- WAL
- 2PC
- Conclusion

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



Transactions

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
- FC/CM
- Intro
- Tx
- ACID
- Locks
- MVCC
- WAL
- 2PC
- Conclusion

Opérations annulables ?

- presque 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;
```



Vérification des contraintes décalée

Transactions
FC/CM

Intro

Tx

ACID

Locks

MVCC

WAL

2PC

Conclusion

- décalable : DEFERRABLE vs NOT DEFERRABLE
- si décalable : INITIALLY IMMEDIATE vs INITIALLY DEFERRED

```

CREATE TABLE Auteur
  (aid INTEGER PRIMARY KEY, nom TEXT);
CREATE TABLE Poeme
  (aid INTEGER NOT NULL REFERENCES Auteur
   DEFERRABLE INITIALLY DEFERRED,
   titre TEXT);
BEGIN;
INSERT INTO Poeme VALUES(1, 'La prose du Transibérien...');
-- attend le commit pour vérifier l'auteur
INSERT INTO Auteur VALUES(1, 'Blaise Cendrар');
COMMIT;

```

5 / 38



Propriété ACID des transactions

Transactions
FC/CM

Intro

Tx

ACID

Locks

MVCC

WAL

2PC

Conclusion

- 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

6 / 38



Consistance/Isolation : comment ça marche ?

Transactions
FC/CM

Intro

Tx

ACID

Locks

MVCC

WAL

2PC

Conclusion

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;

```

7 / 38



Exemple de verrouillage

Transactions
FC/CM

Intro

Tx

ACID

Locks

MVCC

WAL

2PC

Conclusion

```

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

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

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

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

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

-- 6
-- DÉBLOCAGE !
-- pas de modif: nom='Cerise'

```

8 / 38



Étreinte fatale. . . *dead lock*

Transactions
FC/CM
Intro
Tx
ACID
Locks
MVCC
WAL
2PC
Conclusion

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

Transactions
FC/CM
Intro
Tx
ACID
Locks
MVCC
WAL
2PC
Conclusion

```
-- 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

Transactions
FC/CM
Intro
Tx
ACID
Locks
MVCC
WAL
2PC
Conclusion

```
-- 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

Transactions
FC/CM
Intro
Tx
ACID
Locks
MVCC
WAL
2PC
Conclusion

- 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

Transactions

FC/CM

Intro

Tx

ACID

Locks

MVCC

WAL

2PC

Conclusion

Access Share

accès en lecture simple

SELECT ANALYZE

Row Share

SELECT FOR UPDATE

Row Exclusive

UPDATE DELETE INSERT

Share Update Exclusive

VACUUM ANALYZE...

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

13 / 38



Matrice des conflits entre modes

Transactions

FC/CM

Intro

Tx

ACID

Locks

MVCC

WAL

2PC

Conclusion

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

14 / 38



Liste des verrous : table système pg_locks

Transactions

FC/CM

Intro

Tx

ACID

Locks

MVCC

WAL

2PC

Conclusion

relation

num table

pid

processus tenant le verrou

database

num catalogue

mode

du verrou

transaction

num transaction

granted

si verrou accordé

locktype	db	rel	tid	vtx	pid	mode	granted
relation	406768	12073		19/317	755776	AccessShareLock	t
virtualxid				19/317	755776	ExclusiveLock	t
object	0			19/317	755776	AccessShareLock	t
object	406768			19/317	755776	AccessShareLock	t
relation	406768	407583		19/317	755776	AccessExclusiveLock	t
relation	406768	407582		19/317	755776	ShareLock	t
relation	406768	407582		19/317	755776	AccessExclusiveLock	t
relation	406768	407579		19/317	755776	AccessExclusiveLock	t
transactionid			101001	19/317	755776	ExclusiveLock	t

15 / 38



Verrouillage

Transactions

FC/CM

Intro

Tx

ACID

Locks

MVCC

WAL

2PC

Conclusion

Niveaux

BASE

Access, SQLite...

PAGE

contenant de tuples

TABLE

selon opérations

TUPLE

Postgres

Contrôle

■ automatique par les opérations

INSERT UPDATE DELETE

■ manuel pour des tables

LOCK

■ manuel pour des tuples

SELECT FOR UPDATE

16 / 38



Isolation : interactions entre transactions

Transactions
FC/CM

Intro
Tx
ACID
Locks
MVCC
WAL
2PC
Conclusion

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...

17 / 38



Salade de fruits

Transactions
FC/CM

Intro
Tx
ACID
Locks
MVCC
WAL
2PC
Conclusion

```
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;

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

-- 3
COMMIT;

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

18 / 38



Exemple *phantom read* (insert, delete)

Transactions
FC/CM

Intro
Tx
ACID
Locks
MVCC
WAL
2PC
Conclusion

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

DELETE FROM fruit
WHERE id=2;

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

-- 3
COMMIT;

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

19 / 38



Exemple *dirty read*

Transactions
FC/CM

Intro
Tx
ACID
Locks
MVCC
WAL
2PC
Conclusion

```
-- 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;

-- 3
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;
```

20 / 38



Niveaux d'isolation des transactions

Transactions
FC/CM
Intro
Tx
ACID
Locks
MVCC
WAL
2PC
Conclusion

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 !

21 / 38



Échange de deux animaux

Transactions
FC/CM
Intro
Tx
ACID
Locks
MVCC
WAL
2PC
Conclusion

```
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`

23 / 38



Risques d'incohérence avec *read committed*

Transactions
FC/CM
Intro
Tx
ACID
Locks
MVCC
WAL
2PC
Conclusion

- 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

22 / 38



Échange (suite)

Transactions
FC/CM
Intro
Tx
ACID
Locks
MVCC
WAL
2PC
Conclusion

```
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

24 / 38



Solutions : verrouillage...

- Transactions
- FC/CM
- Intro
- Tx
- ACID
- Locks
- MVCC
- WAL
- 2PC
- Conclusion

```
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
SELECT cage AS m FROM zoo WHERE animal=:y FOR UPDATE
UPDATE zoo SET animal=:y WHERE cage=:n;
UPDATE zoo SET animal=:x WHERE cage=:m;
COMMIT;
```



Besoins de reprises avec serializable

- Transactions
- FC/CM
- Intro
- Tx
- ACID
- Locks
- MVCC
- WAL
- 2PC
- Conclusion

- 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...

- Transactions
- FC/CM
- Intro
- Tx
- ACID
- Locks
- MVCC
- WAL
- 2PC
- Conclusion

```
-- 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

- Transactions
- FC/CM
- Intro
- Tx
- ACID
- Locks
- MVCC
- WAL
- 2PC
- Conclusion

- objectif permettre la concurrence entre transactions  
moins d'interactions entre verrous
- vues différentes simultanées d'une même table  
mises à jour, ajouts, effacements...



## Vue concurrentes distinctes

Transactions

FC/CM

```
-- 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('Pêche');

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

29 / 38



## Technique pour MVCC

Transactions

FC/CM

**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 ?

30 / 38



## Exemple MVCC

Transactions

FC/CM

```
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;
```

31 / 38



## Durabilité et Atomicité

Transactions

FC/CM

**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)

32 / 38



## Réplication de données

Transactions

FC/CM

Intro

Tx

ACID

Locks

MVCC

WAL

2PC

Conclusion

- scénario : du crash système à l'incendie...
- sauvegardes journalières ? attention !
- partage de charge ? découpage des données possible ?
  - disques** miroir, à distance via ethernet...
  - base** réplication asynchrone, synchrone ?
- application** modifications parallèles vs sérialisation

33 / 38



## Double validation *two-phase commit* 2PC

Transactions

FC/CM

Intro

Tx

ACID

Locks

MVCC

WAL

2PC

Conclusion

- 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';
```

34 / 38



## Transactions préparées en cours ?

Transactions

FC/CM

Intro

Tx

ACID

Locks

MVCC

WAL

2PC

Conclusion

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

35 / 38



## Point de sauvegarde *savepoint*

Transactions

FC/CM

Intro

Tx

ACID

Locks

MVCC

WAL

2PC

Conclusion

- 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;
```

36 / 38



## James (Jim) Gray

1944-2007 (2012)



## Conclusion sur les transactions

Transactions

FC/CM

Intro

Tx

ACID

Locks


MVCC

WAL

2PC

Conclusion

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



37 / 38

Transactions

FC/CM

Intro

Tx

ACID

Locks

MVCC

WAL

2PC

Conclusion

- 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
  - répliquions plusieurs mémoires/machines

38 / 38