Bases de données avancées

Concurrence d'accès et reprise

Dan VODISLAV

Université de Cergy-Pontoise

Master Informatique M1

Cours BDA

Plan

- La notion de transaction
- Les problèmes de la concurrence
  - Problèmes de cohérence
  - Problèmes d'annulation
- Contrôle de concurrence
- Algorithmes
  - Verrouillage à deux phases
  - Verrouillage hiérarchique
  - Estampillage
  - Niveaux d'isolation
- Reprise après panne
- Concurrence et reprise dans Oracle

La notion de transaction

- Modèle de base de données
  - On ne considère pas un modèle de données en particulier (ex. relationnel)
  - Base de données = ensemble d'articles nommés, contenant n'importe quel type de valeur
    - Modèle général, compatible avec n'importe quel type de BD

    Ex. *x*:5, *y*: "toto", *z*: 2.78
  - Opérations possibles sur les articles: lecture, écriture, création, etc.
  - Plusieurs programmes qui s'exécutent en même temps et font des opérations sur la BD
- On se limite pour l'instant à deux opérations de base
  - Lecture: v = *Lire*(*x*)
  - Écriture: *Ecrire*(*x*, v)

Programme et transaction

- Programme
  - L'exécution d'un programme peut produire une séquence d'opérations
  - On ne s'intéresse qu'aux opérations de lecture/écriture dans la BD
  - La séquence peut être découpée en plusieurs sous-séquences, chacune pouvant être validée (*Commit*) ou annulée (*Rollback*)
- Exemple: programme de débit d'un compte

```
Débit (Article solde, int montant){
  int temp = Lire(solde);
  if (temp < montant) Rollback;
  else {Ecrire(solde, temp-montant); Commit;}
}
```

- Séquences possibles à l'exécution
  - *Lire*(solde), *Rollback*
  - *Lire*(solde), *Ecrire*(solde), *Commit*

Transactions

- Transaction
  - Séquence d'opérations sur la BD produite par l'exécution d'un programme
  - Terminée par validation (*Commit*) ou annulation (*Rollback*)
  - La transaction a une *cohérence logique*
    - La séquence a une signification logique
    - Elle transforme la BD d'un état cohérent en un autre état cohérent
- Relation programme – transaction
  - Une transaction provient de *l'exécution* d'un programme
  - Une exécution de programme produit une séquence d'opérations, qui peut être découpée en plusieurs transactions
  - Toute opération de l'exécution fait partie d'une transaction
  - Des exécutions différentes d'un même programme peuvent produire des séquences d'opérations (donc aussi des transactions) différentes
  - Plusieurs exécutions d'un même programme peuvent être présentes en même temps dans le système

Propriétés ACID

- Propriétés des transactions que le SGBD doit assurer
  - "Contrat" transactionnel entre l'utilisateur et le SGBD
- Quatre propriétés
  - ***A**tomicité*: une transaction s'exécute soit en totalité soit pas du tout
  - ***C**ohérence*: une transaction respecte les contraintes d'intégrité de la BD
  - ***I**solation*: une transaction ne voit pas les effets des autres transactions qui s'exécutent en même temps
  - ***D**urabilité*: les effets d'une transaction validée ne sont jamais perdus

Atomicité, cohérence

- ***A**tomicité*: une transaction s'exécute soit en totalité soit pas du tout
  - Une exécution partielle de la transaction est inacceptable
  - Une transaction qui ne peut pas se terminer doit être annulée
  - L'annulation (*Rollback*) peut venir:
    - du programme: l'annulation du débit si solde insuffisant
    - du système: blocage ou incohérence dans l'exécution concurrente
  - Annulation → annulation de toutes les modifications (écritures)
- ***C**ohérence*: une transaction respecte les contraintes d'intégrité de la BD
  - Les contraintes expriment la cohérence de la BD
    - Contraintes sur les données: *compte.solde* ≥ 0, en permanence
    - Contraintes sur les opérations: dans un transfert entre deux comptes *source.solde* + *dest.solde* = constant
  - Une transaction mène la BD d'un état cohérent vers un autre état cohérent
    - Pendant la transaction l'état peut être incohérent!

Isolation, durabilité

- ***I**solation*: une transaction ne voit pas les effets des autres transactions qui s'exécutent en même temps
  - Les écritures des autres transactions en cours sur les données manipulés par la transaction en question ne sont pas visibles
  - C'est comme si chaque transaction s'exécutait toute seule dans le SGBD
  - Conséquence: l'exécution de plusieurs transactions concurrentes est équivalente à une exécution séparée, en série des transactions
- ***D**urabilité*: les effets d'une transaction validée ne sont jamais perdus
  - On ne doit pas annuler une transaction validée

Les problèmes de la concurrence

- Concurrence de transactions
  - Plusieurs transactions actives (pas terminées) en même temps
  - Vision client-serveur
    - Les transactions/programmes = clients qui envoient des demandes au SGBD (demandes de lecture ou d'écriture d'articles)
    - Le SGBD = serveur qui reçoit ces demandes et les exécute
  - Le SGBD exécute les opérations *en séquence*, pas en parallèle!

  → Concurrence = *entrelacement* des opérations des transactions
- Concurrence parfaite: *toute opération est exécutée dès son arrivée*
  - Problème: certains entrelacements ne sont pas corrects
- Contrôle de concurrence
  - Modifier l'entrelacement pour produire une exécution correcte des transactions

  → Retardement des opérations, perte de performances

Phénomènes indésirables

- Perte d'une mise à jour

  Exemple: compte X avec un solde de 500 euros initialement
  - T1: débit de 100 euros, T2: débit de 200 euros
  - Ordre d'exécution:

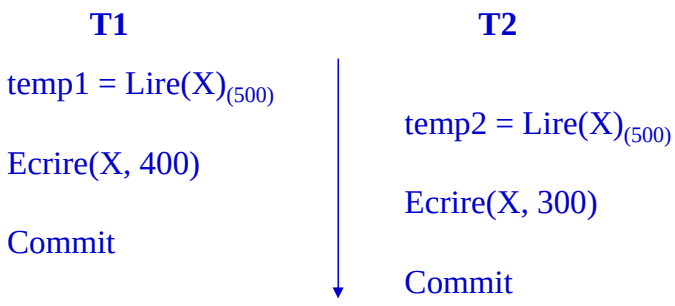

  - Résultat: solde de 300 euros au lieu de 200 euros

    →Perte de la première mise à jour
  - Isolation non respectée: dans T2, la lecture trouve X=500, mais avant l'écriture X=400 (lecture non répétable)

Phénomènes indésirables (suite)

- Analyse incohérente

  Exemple: comptes X (500 euros) et Y (200 euros), total Z

  - T1: transfert de 100 euros de X vers Y; T2: écriture de la somme X+Y dans Z

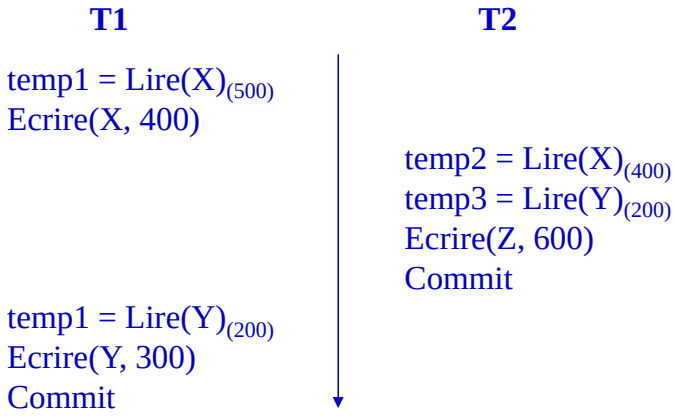

  - La somme X+Y=700 avant et après le transfert, mais au milieu du transfert

    →Le total calculé par T2 est incohérent
  - Isolation non respectée: T2 voit la modification de X faite par T1

Phénomènes indésirables (suite)

- Écritures incohérentes

  Exemple: comptes X et Y, qui doivent toujours avoir le même solde (X=Y)

  - T1: initialiser X et Y avec 100 euros; T2: pareil, mais avec 200 euros

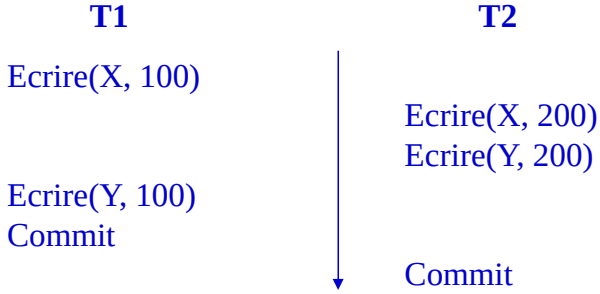

  - A la fin X=200 et Y=100, bien que T1 et T2 respectent la contrainte X=Y

    →Les écritures sont incohérentes, les contraintes d'intégrité ne sont pas respectées
  - Isolation non respectée: T1 peut voir la modification de X faite par T2
    - Écriture d'une valeur non-validée ("écriture sale")

Phénomènes indésirables (suite)

- Dépendances non-validées

  Exemple: compte X avec un solde de 500 euros initialement

  - T1: débit de 100 euros finalement annulé; T2: débit de 200 euros

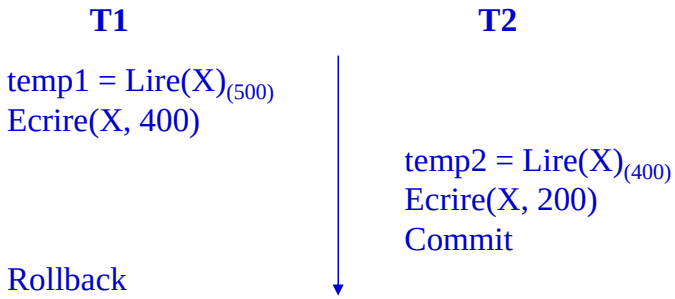

  - T2 utilise la valeur X=400 écrite par T1, qui est finalement annulée

    →L'annulation de T1 implique l'annulation de T2 aussi (annulation en cascade)
  - Durabilité non respectée: T2, qui est validée, doit être annulée
    - Cause: lecture d'une valeur non validée ("lecture sale")

Le problème des annulations

- Annulation d'une transaction T →
  - Annulation des effets de T dans la BD (annulation des écritures de T)
  - Annulation des transactions qui utilisent les valeurs écrites par T (annulations en cascade à cause des dépendances non validées)
- L'exemple des dépendances non validées montre que l'annulation d'une transaction peut avoir des effets indésirables
- Catégories d'exécutions par rapport aux annulations
  - *Non recouvrable*: permet l'annulation en cascade de transactions validées
  - *Recouvrable*: permet l'annulation en cascade, mais seulement de transactions non-validées
  - *Sans annulations en cascade*: évite les annulations en cascade
  - *Stricte*: évite les annulations en cascade et permet l'annulation des écritures à l'aide d'un journal d'écritures avant

Recouvrabilité et annulations en cascade

- La cause des annulations en cascade: les "lectures sales"
  - Question: quand risque-t-on d'annuler une transaction déjà validée?

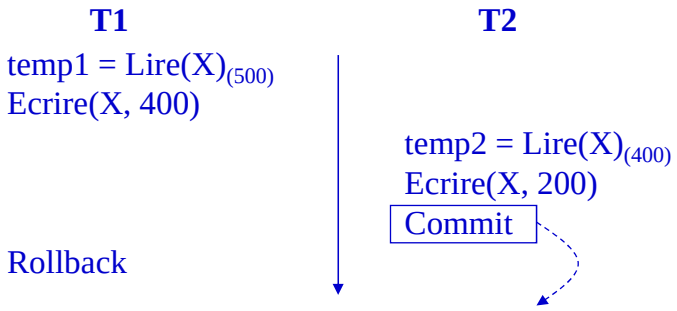

  - Réponse: quand la transaction qui fait la lecture sale est validée avant la fin de celle qui a fait l'écriture
- Exécution recouvrable: pas d'annulation de transaction validée
  - Méthode: retarder le *Commit* des transaction ayant fait une lecture sale
- Remarque: le caractère recouvrable ou non d'une exécution ne dépend pas de la présence explicite d'un *Rollback* !

Éviter les annulations en cascade

- Pour éviter les annulations en cascade → éviter les lectures sales
  - Méthode: retarder la lecture après la fin de la transaction qui a fait l'écriture

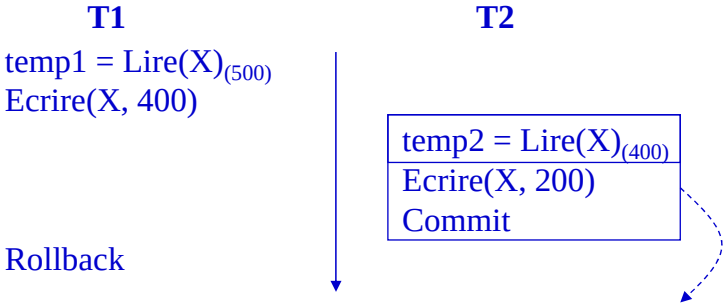

Exécution stricte

- Pour annuler une transaction il faut surtout annuler ses écritures
  - Méthode simple: utilisation d'un *journal des images avant*
  - Avant chaque écriture on marque dans le journal la valeur modifiée
  - À l'annulation on met dans l'article son image avant au début de la transaction
- Problème: cette méthode ne marche pas toujours!

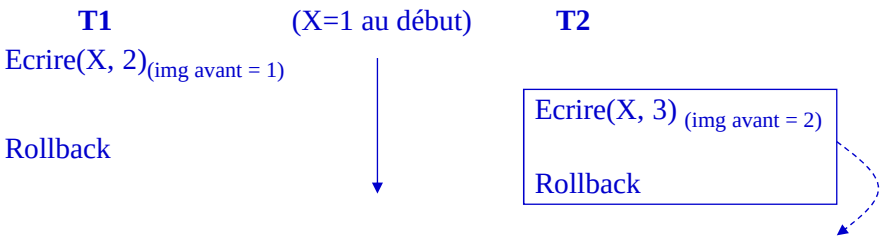

  - Le premier *Rollback* restaure X=1 : erreur, ça ne tient pas compte de *Ecrire*(X, 3)
  - Le second *Rollback* restaure X=2 : erreur, valeur déjà annulée
- Solution: éviter les écritures sales en retardant la seconde écriture

Résumé des problèmes d'annulation

- Étant donnée une exécution, comment savoir à quelle catégorie par rapport aux annulations elle appartient?

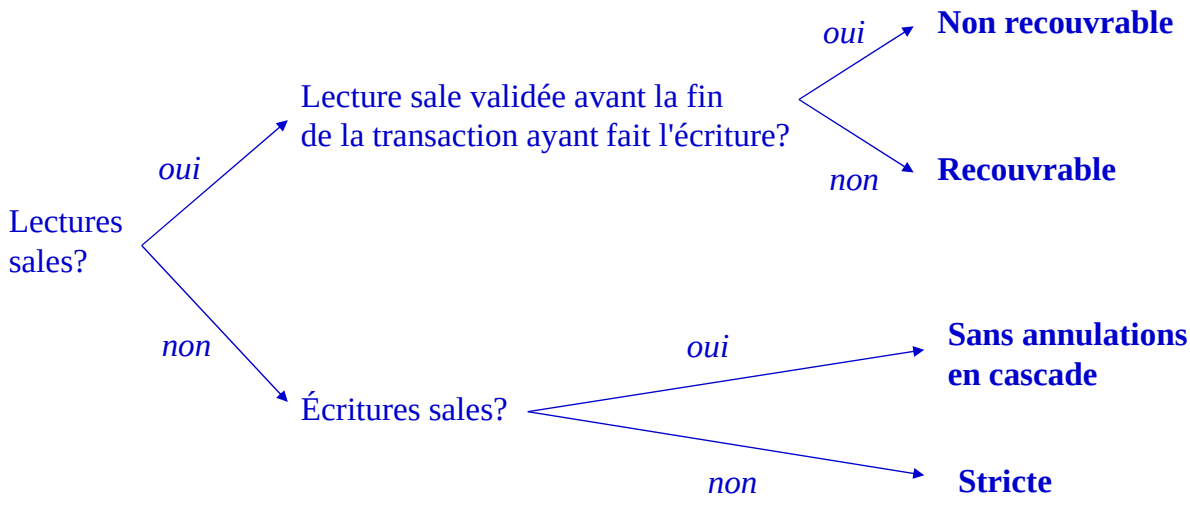

Contrôle de concurrence

- Objectif: produire une exécution correcte, en respectant les propriétés ACID
  - Isolation : les transactions ne doivent pas voir les effets des autres transactions concurrentes

  → l'exécution doit être équivalente à une exécution séparée (en série) des transactions
- Exécution ***sérialisable*** = exécution équivalente à une exécution en série *quelconque* des transactions
  - Plusieurs exécutions en série sont possibles (*n!* pour *n* transactions), n'importe laquelle est acceptable
  - Que veut dire exactement "exécution équivalente"?

→ Objectif contrôle de concurrence = produire des exécutions *sérialisables* en modifiant l'entrelacement des transactions
  - Attention, seul l'entrelacement doit être modifié, les opérations d'une même transaction doivent préserver leur ordre relatif !

Opérations commutables / en conflit

- Opérations commutables / en conflit
  - Opérations A et B *commutables*: l'exécution A;B (A suivi de B) donne le même résultat que B;A
  - "Donner le même résultat":
    - Les valeurs finales des articles sont les mêmes
    - Les valeurs obtenues par lecture sont les mêmes
  - Opérations *en conflit*: qui ne sont pas commutables
- Remarques
  - Les opérations *d'une même transaction* ne peuvent pas changer de position relative → la question de la commutativité/conflit ne se pose pas
  - Deux opérations sur *des articles différents* sont toujours commutables
- Opérations de lecture et écriture sur un même article
  - Seules les lectures sont commutables
  - Les combinaisons *Lire-Ecrire*, *Ecrire-Lire* et *Ecrire-Ecrire* sont en conflit

Équivalence des exécutions

- Intuition: permuter deux opérations commutables dans une exécution produit une exécution équivalente

→ Deux exécutions sont équivalentes si l'on peut passer de l'une à l'autre par une suite de permutations d'opérations commutables

- Méthode pour vérifier l'équivalence de deux exécutions
  - Vérifier que les exécutions portent sur les mêmes opérations/transactions
  - Trouver toutes les paires d'opérations en conflit (les mêmes dans les deux exécutions)
  - Vérifier que toutes ces paires ont le même ordre des opérations dans les deux exécutions

Notation

- Transaction T_i
  - Séquence d'opérations terminée par Commit/Rollback
  - L'indice *i* identifie la transaction et ses opérations
- Opérations: lire, écrire, commit, rollback
  - $l_i[x]$: lecture de l'article *x* dans la transaction T_i
  - $e_i[x]$: écriture de l'article *x* dans la transaction T_i
  - c_i : validation (commit) de la transaction T_i
  - r_i: annulation (rollback) de la transaction T_i
- Remarque: on ne s'intéresse pas aux valeurs lues/écrites
- Exemple: deux transactions de débit et leur exécution concurrente
  - T_1: $l_1[x]$ $e_1[x]$ c_1 (débit compte *x*) ; T_2: $l_2[y]$ $e_2[y]$ c_2 (débit compte *y*)
  - H: $l_1[x]$ $l_2[y]$ $e_1[x]$ $e_2[y]$ c_2 c_1 (une exécution concurrente de T_1 et T_2)

Exemple d'équivalence d'exécutions

- Transactions: $\mathbf{T_1}$: $l_1[x]\ e_1[y]\ e_1[x]\ c_1$ $\mathbf{T_2}$: $e_2[x]\ l_2[y]\ e_2[y]\ c_2$
- Exécutions
  - $\mathbf{H_1}$: $\underline{l_1[x]}\ e_2[x]\ \underline{e_1[y]}\ l_2[y]\ \underline{e_1[x]}\ e_2[y]\ \underline{c_1}\ c_2$
    - Conflits: $l_1[x]$ - $e_2[x]$, $e_2[x]$ - $e_1[x]$, $e_1[y]$ - $l_2[y]$, $e_1[y]$ - $e_2[y]$
  - $\mathbf{H_2}$: $\underline{l_1[x]}\ \underline{e_1[y]}\ e_2[x]\ \underline{e_1[x]}\ \underline{c_1}\ l_2[y]\ e_2[y]\ c_2$
    - Conflits: $l_1[x]$ - $e_2[x]$, $e_2[x]$ - $e_1[x]$, $e_1[y]$ - $l_2[y]$, $e_1[y]$ - $e_2[y]$

    → $\mathbf{H_1 \equiv H_2}$
  - $\mathbf{H_3}$: $e_2[x]\ l_2[y]\ \underline{l_1[x]}\ e_2[y]\ \underline{e_1[y]}\ c_2\ \underline{e_1[x]}\ \underline{c_1}$
    - Conflits: $e_2[x]$ - $l_1[x]$, $e_2[x]$ - $e_1[x]$, $l_2[y]$ - $e_1[y]$, $e_2[y]$ - $e_1[y]$

    → $\mathbf{H_3}$ et $\mathbf{H_1}$ ne sont pas équivalentes
  - $\mathbf{H_4}$: $e_2[x]\ l_2[y]\ e_2[y]\ c_2\ \underline{l_1[x]}\ \underline{e_1[y]}\ \underline{e_1[x]}\ \underline{c_1}$ (exécution en série)
    - Conflits: $e_2[x]$ - $l_1[x]$, $e_2[x]$ - $e_1[x]$, $l_2[y]$ - $e_1[y]$, $e_2[y]$ - $e_1[y]$

    → $\mathbf{H_4 \equiv H_3}$ → $\mathbf{H_3}$ est sérialisable

Théorème de sérialisabilité

- Pour savoir si une exécution est sérialisable → la méthode précédente n'est pas pratique
  - Il faut prouver l'équivalence avec une exécution en série des transactions
  - … mais il faut trouver laquelle parmi les *n!* possibilités
- Graphe de sérialisation d'une exécution
  - Nœuds: transactions
  - Arcs: pour chaque paire d'opérations conflictuelles A_i avant B_j il y a un arc T_i → T_j
- ***Théorème***: une exécution H est sérialisable ⇔ son graphe de sérialisation ne contient pas de cycle
  - Dans les exemples précédents, pour les exécutions H_1, H_2, H_3, H_4:

$\mathbf{H_1, H_2}$: $\mathbf{T_1 \rightleftarrows T_2}$ $\mathbf{H_3, H_4}$: $\mathbf{T_1 \leftarrow T_2}$

Algorithmes de contrôle de concurrence

- L'objectif du contrôle de concurrence: produire des exécutions sérialisables
  - Théorème de sérialisabilité : insuffisant, permet seulement de savoir si une exécution est sérialisable ou non
- Algorithmes de contrôle de concurrence
  - Modifient l'entrelacement des transactions pour rendre l'exécution sérialisable → réordonnancement des opérations
  - *Ordonnanceur* ("scheduler"): module logiciel qui exécute l'algorithme de contrôle de concurrence
    - Le SGBD reçoit une séquence d'exécution d'entrée que l'ordonnanceur modifie pour rendre l'exécution concurrente correcte
- Propriétés d'annulation
  - Les propriétés d'annulation sont *orthogonales* à la sérialisabilité → on peut avoir toutes les combinaisons: sérialisable mais pas recouvrable, stricte mais pas sérialisable, etc.
  - L'ordonnanceur essaie d'assurer en plus de la sérialisabilité la meilleure propriété d'annulation possible dans le cadre de son algorithme

Place de l'ordonnanceur dans le système

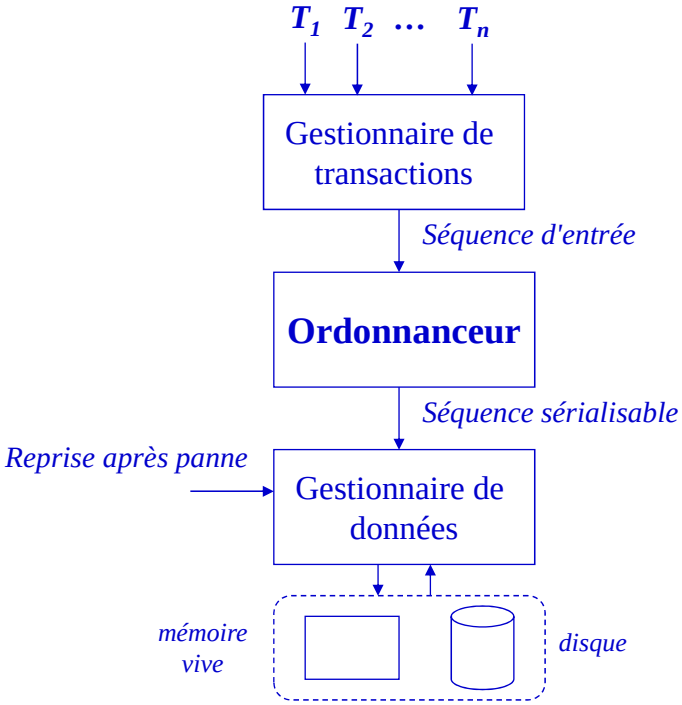

Verrouillage à deux phases

- L'algorithme de contrôle de concurrence le plus utilisé
  - Stratégie pessimiste: essaie de prévenir les incohérences en mettant en attente des opérations
- Verrous
  - Un verrou associé à chaque article, accordé aux transactions
  - Objectif: marquer les opérations réalisés sur l'article par les transactions afin de ne laisser passer que des opérations commutables
    - Une opération en conflit avec des opérations déjà acceptées des transactions en cours → bloquée au verrou
  - Verrou composé
    - Sous-verrou de lecture → partageable (les lectures sont commutables)
    - Sous-verrou d'écriture → exclusif (les écritures sont en conflit avec tout)

Algorithme de verrouillage

- L'ordonnanceur reçoit l'opération $o_i[x]$ de la transaction T_i
  - Si le verrou de *x* est déjà donné à une opération en conflit avec $o_i[x]$ → opération bloquée en attente de la libération du verrou
    - Lorsqu'une opération est bloquée, toute sa transaction est bloquée!
  - Sinon, on donne le sous-verrou de *x* qui correspond à *o* à la transaction T_i → opération acceptée
- Un sous-verrou détenu par une transaction est libéré au plus tard à la fin de la transaction
  - Lorsqu'un sous-verrou est libéré, une des opérations en attente de ce verrou est choisie pour le prendre
    - Généralement on respecte l'ordre de blocage
  - Plusieurs opérations peuvent être débloquées si le verrou est partagé

Algorithme de verrouillage (suite)

- ***Règle des deux phases***: une transaction qui libère un verrou ne pourra plus en demander d'autres pour ses opérations
  - → Dans la vie d'une transaction il y a deux phases
    - Une première *d'accumulation de verrous*
    - Une seconde de *libération de verrous*

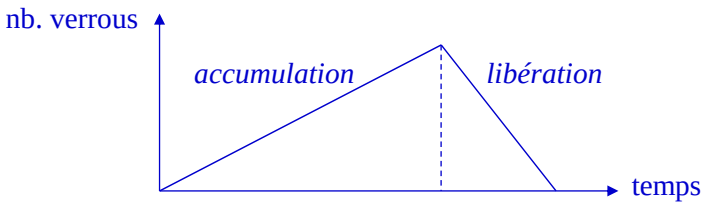

- En pratique: libération des verrous à la fin de la transaction
  - Cette variante produit aussi des *exécutions strictes* (empêche les lectures et les écritures sales)

Exemple de verrouillage

- Séquence d'opérations reçue: $l_1[x]\ l_2[y]\ e_1[y]\ c_1\ e_2[y]\ c_2$
  - Conflits: $l_2[y]$ - $e_1[y]$, $e_1[y]$ - $e_2[y]$ forment un cycle → non sérialisable
- Exécution
  - $l_1[x]$: *acceptée*, sous-verrou de lecture sur *x* donné à T_1
  - $l_2[y]$: *acceptée*, sous-verrou de lecture sur *y* donné à T_2
  - $e_1[y]$: *bloquée* (conflit avec $l_2[y]$), le sous-verrou de lecture sur *y* donné à T_2 empêche de donner le sous-verrou d'écriture sur *y* à T_1
  - c_1 : *bloquée*, car le blocage de $e_1[y]$ a bloqué toute la transaction T_1
  - $e_2[y]$: *acceptée*, sous-verrou d'écriture sur *y* donné à T_2
  - c_2 : *acceptée*, fin de T_2 et libération de tous les verrous pris par T_2 → déblocage de $e_1[y]$ et c_1 qui sont acceptées
- Résultat: $l_1[x]\ l_2[y]\ e_2[y]\ c_2\ e_1[y]\ c_1$
  - Conflits: $l_2[y]$ - $e_1[y]$, $e_2[y]$ - $e_1[y]$ pas de cycle → sérialisable

Interblocage

- Provoqué par l'attente circulaire de verrous entre transactions
- Exemple: $l_1[x]\ e_2[y]\ e_2[x]\ e_1[y]\ c_1\ c_2$
  - $l_1[x]$: T_1 obtient le sous-verrou de lecture sur *x*
  - $e_2[y]$: T_2 obtient le sous-verrou d'écriture sur *y*
  - $e_2[x]$: T_2 bloquée par T_1, en attente du sous-verrou d'écriture sur *x*
  - $e_1[y]$: T_1 bloquée par T_2, en attente du sous-verrou d'écriture sur *y*

  → *interblocage ("deadlock")*
- Pour éviter l'interblocage → annulation de transactions, afin de libérer des verrous

Éviter l'interblocage

- Détection
  - *Durée limite* ("timeout"): annulation d'une transaction qui dépasse la durée limite
    - Problème: paramétrage fin nécessaire pour la durée limite
  - *Graphe d'attente*: représente l'attente de verrous entre transactions
    - Interblocage = cycle dans le graphe d'attente
    - Annulation d'une transaction qui brise le(s) cycle(s)

Verrouillage hiérarchique

- Variante du verrouillage à deux phases utilisée dans les BD relationnelles
  - La différence: opérations à *plusieurs niveaux de granularité* des données

  Ex. champ ∈ article ∈ table ∈ base de données

  → des actions sur des données différentes peuvent être en conflit
- Solution "naïve": utiliser un seul niveau
  - Niveau fin: trop de verrous, gestion lourde
  - Niveau grossier: peu de verrous, mais beaucoup de blocages
- Verrouillage hiérarchique → des verrous à tous les niveaux, chaque opération choisit le niveau approprié

Principes du verrouillage hiérarchique

- Verrouillage descendant: implicite
  - Un verrou à un niveau est implicitement valable pour toutes les données de niveau inférieur incluses

  Ex. Un verrou en écriture sur une table est valable pour tous les articles de la table et pour tous les champs de ces articles
- Verrouillage ascendant: verrous d'intention
  - Pour réaliser une opération à un niveau, il faut aussi vérifier s'il n'y a pas conflit avec les verrous des niveaux supérieurs

  Ex. Lorsqu'on veut écrire dans un article, il faut voir s'il n'y a pas des verrous en lecture/écriture sur la table
  - Méthode: utilisation de verrous supplémentaires dits *d'intention*
  - Règle: avant de réaliser une opération à un niveau, il faut demander le verrou d'intention pour l'opération au niveau supérieur

Types de verrous hiérarchiques

- Cinq types de verrous hiérarchiques
  - **S** ("shared", partagé, en lecture)
  - **X** ("exclusive", exclusif, en écriture)
  - **IS** (intention de lecture)
  - **IX** (intention d'écriture)
  - **SIX** (lecture et intention d'écriture)
    - Cas fréquent: lecture table (S) pour écrire quelque articles (IX) = update SQL
- Matrice de conflits entre verrous

	X	**SIX**	**IX**	**S**	**IS**
X	oui	oui	oui	oui	oui
SIX	oui	oui	oui	oui	***non***
IX	oui	oui	***non***	oui	***non***
S	oui	oui	oui	***non***	***non***
IS	oui	***non***	***non***	***non***	***non***

Exemple de verrouillage hiérarchique

- Table ***Compte*** (numéro, titulaire, solde), deux niveaux: article et table
- Transactions
  - T_1: débit du compte numéro 7 → $l_1[x]$ $e_1[x]$ c_1
  - T_2: lecture de tous les comptes de la table → $l_2[R]$ c_2
  - T_3: initialisation du compte numéro 3 → $e_3[y]$ c_3
- Ordre de réception: $l_1[x]$ $l_2[R]$ $e_3[y]$ $e_1[x]$ c_1 c_2 c_3
  - $l_1[x]$: obtient IS(R) et S(x) → acceptée
  - $l_2[R]$: obtient S(R) (pas de conflit avec IS(R)) → acceptée
  - $e_3[y]$: n'obtient pas IX(R) (conflit avec S(R)) → bloquée, T_3 bloquée
  - $e_1[x]$: n'obtient pas IX(R) (conflit avec S(R)) → bloquée, T_1 bloquée
  - c_1 : bloquée, car T_1 bloquée
  - c_2 : acceptée et verrous de T_2 libérés (S(R))
    - $e_3[y]$: obtient IX(R) (pas de conflit avec IS(R)) → acceptée
    - $e_1[x]$: obtient IX(R) (pas de conflit avec IS(R), IX(R)) → acceptée
    - c_1 : acceptée
  - c_3 : acceptée
- Résultat: $l_1[x]$ $l_2[R]$ c_2 $e_3[y]$ $e_1[x]$ c_1 c_3

Le problème des objets fantômes

- Problème de concurrence dans les BD dynamiques
  - Opérations de création et suppression de données
  - Cas usuel: T_1 consulte toutes les données d'un certain type pendant que T_2 crée une donnée de même type
- Exemple:
  - Tables ***Compte*** (numéro, titulaire, solde) et ***Cumul*** (titulaire, total)
  - T_1 : compare la somme des soldes des comptes de Dupont avec le cumul
    T_2 : ajoute un nouveau compte pour Dupont

  $Lire_1(Compte[5])_{(100)}$, $Lire_1(Compte[8])_{(300)}$, $Lire_1(Compte[14])_{(600)}$
  $Inserer_2(Compte[10, 'Dupont', 500])$
  $Lire_2(Cumul['Dupont'])_{(1000)}$
  $Ecrire_2(Cumul['Dupont'], 1500)$, $Commit_2$
  $Lire_1(Cumul['Dupont'])_{(1500)}$, $Commit_1$,

  → T_1 trouve la somme des comptes de Dupont (1000) différente du cumul (1500)
- Similaire à l'analyse incohérente, mais produit par une insertion et non pas par une écriture

Solution au problème des objets fantômes

- Le problème: le verrouillage à deux phases ne fonctionne pas!
  - L'insertion par T_2 n'est pas bloquée par le verrouillage, car elle agit sur un article différent de ceux lus par T_1
- Solution: traiter l'insertion comme une opération sur *l'ensemble d'articles* et non pas sur un seul article
  - Dans l'exemple: verrou sur l'ensemble des comptes de Dupont
    - Lecture de tous les comptes de Dupont → lecture de l'ensemble
    - Insertion compte → écriture de l'ensemble
- En pratique: *le verrouillage hiérarchique* règle le problème!
  - Ensemble d'articles → donnée de niveau supérieur (table)
    - Lecture de tous les comptes de Dupont → lecture de la table *Compte*
    - Insertion compte → écriture de la table *Compte*
  - Inconvénient: pas très précis, car on verrouille toujours *toute la table*

Estampillage

- Algorithme plus simple que le verrouillage
  - Approche optimiste: on ne bloque pas des opérations, … mais on doit annuler des transactions si des incohérences risquent d'apparaître
- Estampille: valeur associée à une transaction, indiquant l'ordre de démarrage des transactions
  - Produite par un compteur, par une horloge, etc.
- Idée générale: les opérations en conflit doivent passer dans l'ordre des estampilles

  →L'exécution est sérialisable, le graphe ne peut pas avoir de cycle
- Conclusions
  - Plus simple à réaliser que le verrouillage (pas de gestion de verrous)
  - Plus restrictif: impose un ordre préétabli
  - Risque d'annulations massives, annulations en cascade

Exemple d'estampillage

- Séquence reçue: $l_1[x]$ $e_2[x]$ $l_3[x]$ $l_2[x]$ $e_1[x]$ …
  - Estampille = l'indice de la transaction

  $l_1[x]$: acceptée
  $e_2[x]$: en conflit avec $l_1[x]$, mais estampille plus grande → acceptée
  $l_3[x]$: en conflit avec $e_2[x]$, mais estampille plus grande → acceptée
  $l_2[x]$: pas de conflit avec les opérations antérieures → acceptée
  $e_1[x]$: conflit avec $e_2[x]$ (et aussi $l_3[x]$, $l_2[x]$), estampille plus petite → rejet
  - On dit que $e_1[x]$ arrive *en retard*
  - Rejet de $e_1[x]$ → rejet de toute la transaction T_1 (atomicité) → la transaction est relancée avec *une nouvelle estampille* (pourquoi?)
- Résultat: $l_1[x]$ $e_2[x]$ $l_3[x]$ $l_2[x]$ $e_1[x]$ r_1 $l_4[x]$ $e_4[x]$ …

Niveaux d'isolation

- Idée: relâcher les contraintes d'isolation afin d'augmenter la concurrence
  - L'isolation totale assure la cohérence de toute transaction
  - Certaines transactions peuvent accepter un niveau moindre d'isolation
- SQL: quatre niveaux d'isolation
  - *Read uncommited*: aucun conflit entre verrous, aucun blocage
    - Permet des lectures sales (de valeurs non validées)
  - *Read commited*: les écritures bloquent les lectures
    - Pas de lectures sales, mais permet la lecture non répétable
  - *Repetable read*: les lectures aussi bloquent les écritures
    - Lecture répétable, mais permet des objets fantômes
  - *Serializable*: isolation totale
- Commande: SET TRANSACTION ISOLATION LEVEL *xxx*
- Remarque: la norme SQL ne prévoit pas de verrouillage explicite, mais seulement l'utilisation des niveaux d'isolation

Exemple niveaux d'isolation

- Deux transactions sur un article x (au début $x = 1$)
  - T_1 : $l_1[x]\ l_1[x]\ c_1$ - deux consultations successives de x
  - T_2 : $l_2[x]\ e_2[x]\ e_2[x]\ c_2$ - ajoute 1 à x à deux reprises
  - Séquence reçue: $l_1[x]\ l_2[x]\ e_2[x]\ l_1[x]\ e_2[x]\ c_2\ c_1$
- Read uncommited → $l_1[x]_{(1)}\ l_2[x]_{(1)}\ e_2[x]_{(2)}\ \underline{l_1[x]}_{(2)}\ e_2[x]_{(3)}\ c_2\ c_1$
  - Pas de retard, lectures sales – peut être acceptable si T_1 n'écrit pas
- Read commited → $l_1[x]_{(1)}\ l_2[x]_{(1)}\ e_2[x]_{(2)}\ e_2[x]_{(3)}\ c_2\ \underline{l_1[x]}_{(3)}\ c_1$
  - Évite lecture sale – lecture retardée après la validation de l'écriture
- Repetable read → $l_1[x]_{(1)}\ l_2[x]_{(1)}\ \underline{l_1[x]}_{(1)}\ c_1\ e_2[x]_{(2)}\ e_2[x]_{(3)}\ c_2$
  - En plus: écritures des autres transactions retardées après la fin de T_1
- Serializable
  - En plus: insertions/suppressions des autres transactions retardées après T_1

Point de sauvegarde

- Point de sauvegarde ("savepoint"): notion prévue dans SQL
  - Validation partielle d'une transaction
    - *Savepoint* **s**
  - Principale utilisation: faire une *annulation partielle* de la transaction
    - *Rollback to* **s**
  - Utile pour des "transactions longues", où en cas d'échec on veut garder une partie du travail réalisé
- Exemple: réservation d'un voyage

  Réservation avion
  Savepoint avion
  Réservation voiture chez Loueur1
  si échec alors
  Rollback to avion
  Réservation voiture chez Loueur2
  si échec alors *Rollback*
  Commit

Reprise après panne

- Types de pannes
  - *De transaction*: annulation d'une transaction
  - *De système*: perte du contenu de la mémoire vive
  - *De support*: perte du contenu du disque
- Hypothèses
  - On s'intéresse aux pannes de système

    → opération *Reprise* qui doit reconstituer un état cohérent de la BD
  - L'ordonnanceur produit des exécutions sérialisables et *strictes*
  - On considère toutes les opérations *au niveau des articles*, même si les échanges avec le disque se font au niveau des pages

Architecture

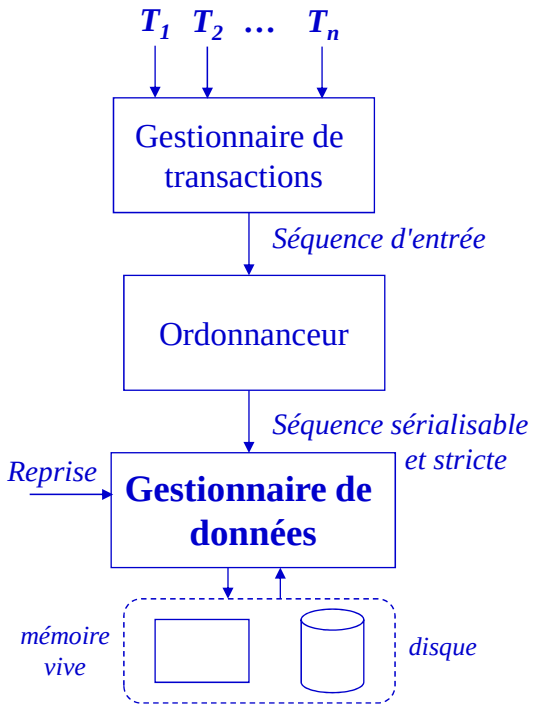

- Gestionnaire de données
  - Gestionnaire du tampon (cache)
    - Échanges entre mémoire vive et disque
  - Gestionnaire de reprise
    - Pilote l'exécution des opérations des transactions + *Reprise*
    - Utilise le gestionnaire du tampon

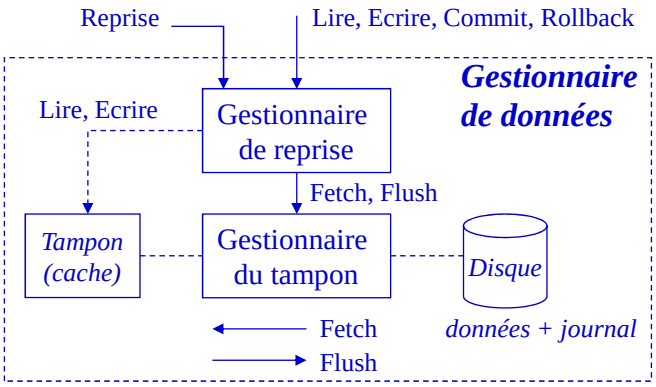

Objectif de la reprise

- Au moment de la panne, l'état de la BD peut être incohérent
  - Pendant l'exécution d'une transaction: état incohérent possible
- État validé de la BD = dernière valeur validée pour chaque article de la BD
  - Dernière valeur validée pour un article = dernière valeur écrite dans l'article par une transaction validée
- Objectif → ***ramener la BD à son état validé avant la panne***
- Comment?
  - *Assurer l'atomicité*: annuler dans la BD les transactions non validées au moment de la panne
  - *Assurer la durabilité*: reproduire dans la BD l'effet des transactions validées au moment de la panne
- Pour assurer la reprise → *journal* à stocker sur disque

Gestionnaire du tampon

- Tampon (cache) divisé en cellules (slots)
  - Une cellule peut être vide ou contenir un article
    - En réalité les cellules stockent *des pages*, contenant des articles
  - Bit de consistance: article du tampon consistant ou non avec le disque
  - Répertoire du cache: correspondance article → cellule

Tampon (cache)

n°	bit consist.	valeur article
1	1	"Marie"
2	–	–
3	0	15
…	…	…

Répertoire du cache

article	n° cellule
x	3
y	1
…	…

Opérations dans le tampon

- ***Flush*** (*c*) : écriture du contenu de la cellule *c* sur disque
  si *c* inconsistante **alors** copier *c* sur disque et rendre *c* consistante
  sinon rien
- ***Fetch*** (*x*) : transfert de l'article *x* du disque vers le tampon
  si tampon plein **alors**
  vider une cellule après l'avoir rendue consistante avec *Flush*
  sélectionner *c* une cellule vide
  copier *x* du disque dans *c* et rendre *c* consistante
  mettre à jour le répertoire du cache avec (*x*, *c*)
- Politique du pour choisir la cellule à vider: LRU, FIFO, etc.
- *Lire* et *Ecrire*: toujours dans le tampon
  - *Lire*(*x*): si *x* n'est pas dans le tampon, alors *Fetch*(*x*) d'abord
  - *Ecrire*(*x*):
    - si *x* n'est pas dans le tampon, alors on lui alloue une cellule *c* dans le tampon
    - écrire la valeur de *x* dans *c* et rendre *c* inconsistante
    - *éventuellement Flush*(*c*), selon l'algorithme du gestionnaire de reprise

Journalisation

- Objectif: garder sur disque une trace des écritures, pour pouvoir au moment de la reprise:
  - Refaire les écritures validées
  - Annuler les écritures non validées
- Journal
  - Liste ordonnée des opérations de mise à jour jusqu'au moment courant
  - Ensembles de transactions validées, annulées, en cours au moment courant
- Exemple de journal
  - $[T_1, x, 4], [T_2, y, 3], [T_1, z, 1], [T_2, x, 8], [T_3, y, 5], [T_4, x, 2], [T_3, z, 6]$
  - *validé* = $\{T_1, T_4\}$
    annulé = $\{T_2\}$
    encours = $\{T_3\}$

Types de journal

- Journaux d'images après et d'images avant
  - *Journal d'images après*: valeurs après modification (valeurs écrites)
    - Pour refaire des écritures
  - *Journal d'images avant*: valeurs avant modification
    - Pour annuler des écritures

  Remarques:
    - On peut utiliser un journal d'images après pour trouver une image avant
    - On peut fusionner les deux types de journal en un seul journal
- Journaux physiques et logiques
  - *Journal physique*: on stocke les valeurs écrites
  - *Journal logique*: on stocke des opérations de plus haut niveau, avec leurs paramètres
    - Pour les images avant: on stocke l'opération inverse
    - Taille plus petite, mais plus difficile à réaliser et à interpréter

Recyclage de l'espace utilisé par le journal

- Journal physique d'images après, avec entrées de type [T_i, *x*, v]
- Une entrée [T_i, *x*, v] peut être recyclée si
  - Soit T_i annulée ($T_i \in$ *annulé*),
  - Soit T_i validée ($T_i \in$ *validé*), mais une autre T_j validée a écrit *x* par la suite
- Explication
  - À la reprise, les écritures annulées ne sont plus nécessaires
  - À la reprise, seule la dernière écriture validée sur *x* est nécessaire

Gestionnaire de reprise

- Rôles du gestionnaire de reprise (GR)
  - Réalisation des opérations dans la BD
  - Validation et annulation des transactions dans la BD
  - Gestion de la journalisation
  - Gestion des échanges tampon – disque
  - Réalisation de la reprise
- Deux paramètres qui définissent l'algorithme du GR
  - Forcer ou non l'écriture sur disque des modifications dans le tampon
  - La façon d'enregistrer les écritures dans le journal

Politiques d'écriture sur disque

- Écrire des valeurs non validées sur disque
  - Permettre (politique "*Steal*")
    - → Annuler à la reprise sur disque les écritures non validées
    - Plus rapide en fonctionnement normal, mais plus coûteux à la reprise
    - Cas typique: le GR ne force jamais le Flush
      - Question: comment les valeurs non validées se retrouvent sur disque?
  - Ne pas permettre (politique "*No-steal*")
    - Reprise plus rapide, mais plus coûteux en fonctionnement normal
- Écrire toutes les valeurs validées sur disque au *Commit*
  - Pas de contrainte (politique "*No-force*")
    - → Répéter à la reprise des écritures validées
    - Cas typique: le GR qui ne force jamais le Flush
  - Toujours (politique "*Force*")
    - Plus coûteux en fonctionnement normal, mais pas de répétition à la reprise
- Quatre types de GR: les combinaisons Steal/No-steal – Force/No-force

Algorithme Steal / No-force

- Le plus performant en fonctionnement normal
  - Toutes les opérations se font dans le tampon, le GR ne demande jamais de *Flush* → minimise les entrées/sorties
  - Écriture sur disque → lorsque le gestionnaire du tampon vide une cellule
- Conséquences
  - On ne contrôle pas ce qui est écrit sur disque → des valeurs non validées peuvent se retrouver sur disque (steal)
  - Les valeurs validées restent dans le tampon, pas d'écriture sur disque de ces valeurs au *Commit* (no-force)

→ La reprise demande à la fois *annulation* et *répétition* d'écritures

- Hypothèses
  - Journal physique d'images après/avant avec listes de transactions
  - Écriture dans le journal juste avant l'écriture dans le tampon

Steal / No-force : opérations

- *Ecrire* (T_i, *x*, v)
  encours = *encours* ∪ {T_i}
  journal = *journal* + [T_i, *x*, v]
  si *x* n'est pas dans le tampon **alors** allouer cellule pour *x* dans le tampon
  cellule(*x*) = v
- *Lire* (T_i, *x*)
  encours = *encours* ∪ {T_i}
  si *x* n'est pas dans le tampon **alors** *Fetch*(*x*)
  return *cellule*(*x*)
- *Commit* (T_i)
  validé = *validé* ∪ {T_i}
  encours = *encours* – {T_i}
- *Rollback* (T_i)
  pour chaque *x* écrit par T_i **répéter**
  si *x* n'est pas dans le tampon **alors** allouer cellule pour *x* dans le tampon
  cellule(*x*) = ***image-avant***(*x*, T_i)
  fin répéter
  annulé = *annulé* ∪ {T_i}
  encours = *encours* – {T_i}

Steal / No-force : reprise

- *Reprise* ( )
  marquer toutes les cellules du tampon comme étant vides
  écriture-répétée = {} //articles restaurés par répétition
  écriture-annulée = {} //articles restaurés par annulation
  pour chaque [T_i, *x*, v] ∈ *journal* à partir de la fin **répéter**
  si *x* ∉ *écriture-répétée* ∪ *écriture-annulée* **alors**
  si *x* pas dans le tampon **alors** allouer cellule pour *x* dans le tampon
  si T_i ∈ *validé* **alors** //répétition de l'écriture
  cellule(*x*) = v
  écriture-répétée = *écriture-répétée* ∪ {*x*}
  sinon //annulation de l'écriture
  cellule(*x*) = ***image-avant***(*x*, T_i)
  écriture-annulée = *écriture-annulée* ∪ {*x*}
  fin si
  si *écriture-répétée* ∪ *écriture-annulée* = BD **alors stop boucle**
  fin répéter

Algorithme Steal / Force

- La différence avec Steal / No-force : force au *Commit* l'écriture sur disque des valeurs validées
  - → La reprise ne demande pas de *répétition* d'écritures
  - – *Ecrire*, *Lire* et *Rollback*: pareil que pour Steal / No-force
  - – *Commit*: en plus

    pour chaque *x* écrit par T_i **répéter**
    si *x* est dans le tampon **alors** *Flush*(*x*)
    fin répéter
  - – *Reprise*: pareil, sauf que *écriture-répétée* et la branche "**si** $T_i \in$ *validé* **alors**" n'existent pas

Algorithme No-steal / No-force

- Ne permet pas des écritures non-validées sur disque
  - → La reprise ne demande pas d'*annulation* d'écritures
- Problème: le tampon a un fonctionnement peu contrôlable
  - – Idée: ne pas écrire dans le tampon, mais *utiliser le journal*
- Opérations
  - – *Ecrire*: ajoute juste [T_i, *x*, v] au journal
  - – *Lire*: si T_i a déjà écrit *x* alors chercher la valeur dans le journal, sinon dans la BD
    - Exécution stricte → si T_i a écrit *x* alors les lectures/écritures de *x* par d'autres transactions sont retardées après la fin de T_i
  - – *Commit*: chaque *x* écrit par T_i est calculé à partir du journal et écrit dans le tampon (no-force)
  - – *Rollback*: rien à annuler, juste ajouter T_i à *annulé*
- Algorithme No-steal / Force : similaire, mais au Commit on écrit les valeurs validées aussi sur disque (avec *Flush*)

Concurrence et reprise dans Oracle

- Contrôle de concurrence *multi-version*
  - Technique qui améliore la concurrence
  - Idée: pouvoir accéder à des versions antérieures des données
  - Comment? → en utilisant le journal
- Mode de fonctionnement
  - Ordonnancement des transactions de type estampillage
  - Chaque version de la donnée dans le journal possède une estampille
  - Une lecture $l_i[x]$ *n'attend jamais*!
    - Elle utilise la dernière version de *x* qui respecte l'ordre des estampilles (la version d'estampille ≤ i la plus grande)
  - Une écriture $e_i[x]$ attend seulement une autre écriture $e_j[x]$ non validée
    - Quand T_j se termine par *Rollback* → $e_i[x]$ peut s'exécuter
    - Quand T_j se termine par *Commit* → pas sérialisable, T_i devrait être annulée et relancée
- Conclusion: plus de concurrence (pas de blocage lecture-écriture ou écriture-lecture), mais la cohérence offerte est moins stricte

Niveaux d'isolation

- Isolation avec le contrôle multi-version
  - La lecture peut choisir la dernière version validée
    → facile à assurer le niveau "read committed"
  - Les lectures d'une transaction peuvent utiliser la même version
    → facile à assurer la lecture répétable dans une transaction
- Oracle n'offre que *deux niveaux d'isolation*
  - Read committed
    - Toute lecture choisit la dernière version *validée* avant son estampille
    - Une écriture en attente *n'est pas annulée* si l'écriture qui bloque est validée
  - Serializable
    - Toutes les lectures d'une transaction utilisent *le même état de la BD*
    - Une écritures en attente est annulée si l'écriture qui bloque est validée

Verrous

- Verrous hiérarchiques à deux niveaux:
  - Ligne (article): X (pas de S, les lectures ne bloquent pas)
  - Table: IS, IX, S, SIX, X
- Verrouillage implicite
  - SELECT … FROM … WHERE: aucun verrou
  - INSERT/UPDATE/DELETE: X (ligne), IX (table)
  - SELECT … FOR UPDATE: X (ligne), IS (table)
- Verrouillage explicite : seulement au niveau des tables
  - LOCK TABLE *nom* IN *type* MODE
    - *type*: ROW SHARE (IS), ROW EXCLUSIVE (IX), SHARE (S), SHARE ROW EXCLUSIVE (SIX), EXCLUSIVE (X)

Reprise dans Oracle

- Reprise: pour les pannes de support ou pannes système
- Algorithme Steal / No-force
- Journalisation
  - Journal d'images après (redo log)
  - Journal d'images avant (undo segment)
- Reprise en deux étapes
  - Répétition des écritures (journal d'images après)
  - Annulation des écritures non validées (journal d'images avant)
- Retrouver des versions plus anciennes des données
  - Flashback: réconstitution de la BD à un moment donné du passé
  - CREATE TABLE *nom* AS SELECT … AS OF TIMESTAMP *t*