Δοσοληψίες

Κατανεμημένα Συστήματα

2019-2020

http://www.cslab.ece.ntua.gr/courses/distrib

Στο προηγούμενο μάθημα…

- Group communication
  - Multicast για FIFO διάταξη
  - Multicast για ολική διάταξη
    - Sequencer
    - ISIS
  - Multicast για αιτιώδη διάταξη
    - Χρησιμοποιεί vector timestamps

- Αμοιβαίος αποκλεισμός
  - Κεντρικός έλεγχος
  - Δακτύλιος με σκυτάλη
  - Αλγόριθμος Ricart and Agrawala

- Ο συντονισμός σε κατανεμημένα συστήματα απαιτεί συχνά εκλογή αρχηγού
  - Αλγόριθμος δακτυλίου
  - Αλγόριθμος τροποποιημένου δακτυλίου
  - Αλγόριθμος bully

Σε αυτό το μάθημα

- Απλές δοσοληψίες (transactions)
- Ιδιότητες ACID
  - Και κυρίως atomicity και durability
- Σειριοποιησιμότητα (serializability)
- Έλεγχος ταυτοχρονισμού
  - Κλειδώματα (Locking)
  - Αισιόδοξος έλεγχος ταυτοχρονισμού (optimistic concurrency control)
  - Διάταξη χρονοσφραγίδων (Timestamp ordering)
- Αδιέξοδα (deadlocks)

Παράδειγμα 1

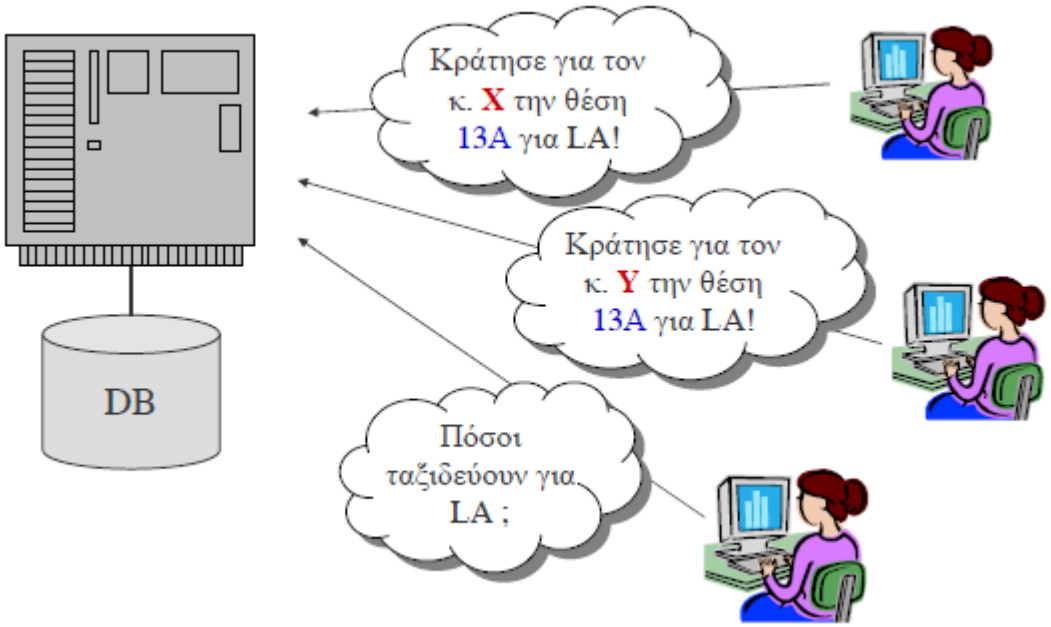

Παράδειγμα 2

- Συναλλαγή πελάτη με την τράπεζα (σε ATM ή browser)
  - Μεταφορά $100 από λογαριασμό ταμιευτηρίου σε τρεχούμενο λογαριασμό
  - Μεταφορά $200 από προθεσμιακό σε τρεχούμενο λογαριασμό
  - Ανάληψη $400 από τρεχούμενο

- Συναλλαγή
  - ταμιευτηρίου.αφαίρεση(100)
  - τρεχούμενο.πρόσθεση(100)
  - προθεσμιακό.αφαίρεση(200)
  - τρεχούμενο.πρόσθεση(200)
  - τρεχούμενο.αφαίρεση (400)
  - ανάληψη(400)

Γιατί δε μας αρέσει

1. ταμιευτηρίου.αφαίρεση(100)
2. τρεχούμενο.πρόσθεση(100)
3. προθεσμιακό.αφαίρεση(200)
4. τρεχούμενο.πρόσθεση(200)
5. τρεχούμενο.αφαίρεση (400)
6. ανάληψη(400)

Αποτυχία σε αυτά τα σημεία: ο πελάτης χάνει χρήματα. χρειαζόμαστε τρόπο να ανακτήσουμε προηγούμενη κατάσταση

Αποτυχία σε αυτά τα σημεία: δεν χάνονται χρήματα. Αλλά δεν μπορούν να επαναληφθούν τα προηγούμενα βήματα

Κάτι μου θυμίζει…

- Τι μπορεί να πάει στραβά;
  - Πολλοί clients
  - Πολλοί servers
- Πώς το λύνεις;
  - Ολόκληρη η συναλλαγή σε ένα βήμα
- Πού το έχω ξαναδεί;
  - Mutual exclusion
- Άρα τελειώσαμε;

Ταυτόχρονες συναλλαγές

- Process 1

lock(mutex);
ταμιευτηρίου.αφαίρεση(100)
τρεχούμενο.πρόσθεση(100)
προθεσμιακό.αφαίρεση(200)
τρεχούμενο.πρόσθεση(200)
τρεχούμενο.αφαίρεση (400)
ανάληψη(400)
unlock(mutex);

- Process 2

lock(mutex);
ταμιευτηρίου.αφαίρεση(200);
τρεχούμενο.πρόσθεση(200);
unlock(mutex);

Θυμήσου

- mutual exclusion = one big lock.
  - Όλοι οι υπόλοιποι πρέπει να περιμένουν
  - Δεν αντιμετωπίζει τα σφάλματα του συστήματος
- Απόδοση
  - Μπορούμε να συνδυάσουμε λειτουργίες από διαφορετικές διεργασίες
- Σφάλματα
  - Τι γίνεται αν κρασάρει μια διεργασία που έχει το lock;

Η έννοια του transaction

- Ένα διατεταγμένο σύνολο από ενέργειες
- Ένα transaction είναι ατομικό (atomic) δλδ αδιαίρετο σε σχέση με άλλα transactions
  - Δεν υπάρχει πρόσβαση σε ενδιάμεσα αποτελέσματα/καταστάσεις
  - Δεν υπάρχει παρεμβολή από άλλες ενέργειες
- Primitives
  - openTransaction() -> trans;
  - closeTransaction(trans) -> (commit, abort);
  - abortTransaction(trans);
- Υλοποιώντας transactions
  - Απόδοση (Performance): ποιες ενέργειες μπορούμε να τρέξουμε ταυτόχρονα
  - Σφάλματα (Failure): πώς χειριζόμαστε σφάλματα, κάνοντας roll-back αλλαγές αν χρειαστεί

Ιδιότητες ACID

- **Ατομικότητα** (**A**tomicity): όλα ή τίποτα, δηλαδή, είτε όλες οι πράξεις μιας δοσοληψία επιτυγχάνουν, είτε όλες αποτυγχάνουν
- **Συνέπεια** (**C**onsistency): αν ο server ξεκινά από συνεπή κατάσταση, το transaction τον αφήνει πάλι σε συνεπή κατάσταση
- **Απομόνωση** (**I**solation): Κάθε δοσοληψία τρέχει χωρίς παρεμβολές, δηλαδή ακόμα κι αν τρέχουν πολλές δοσοληψίες ταυτόχρονα, κάθε δοσοληψία είναι σαν να τρέχει μόνη της
- **Μονιμότητα** (**D**urability): Αν μια δοσοληψία επιτύχει, το αποτέλεσμά της είναι μόνιμο και επιβιώνει ακόμα κι αν αποτύχει το σύστημα, δηλαδή γράφεται στον δίσκο

Παράδειγμα: Μεταφορά χρημάτων

- Δοσοληψία που μεταφέρει $50 από τον Α στον Β:

    1. read(A)
    2. A := A – 50
    3. write(A)
    4. read(B)
    5. B := B + 50
    6. write(B)

Συνέπεια

- Το άθροισμα του A και του B παραμένει αμετάβλητο από την εκτέλεση του transaction

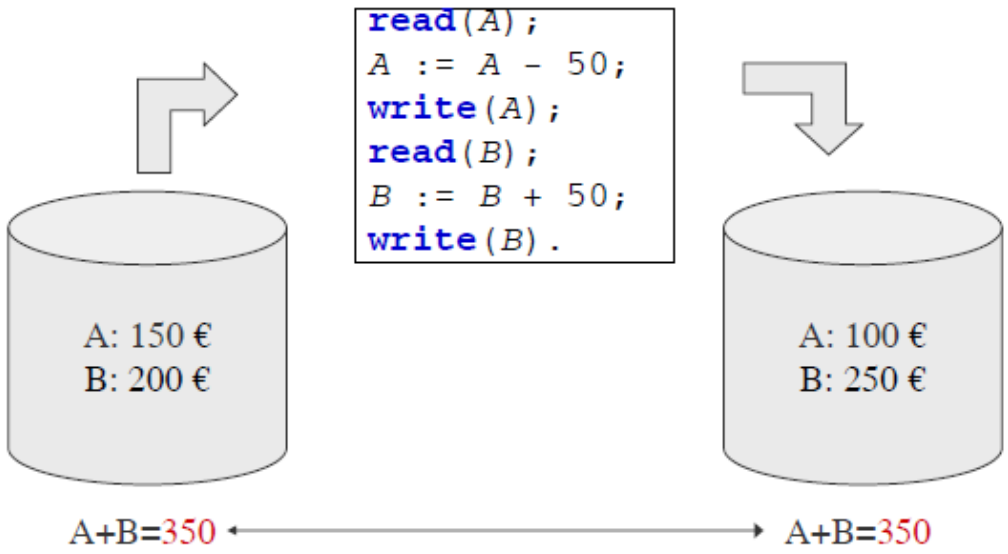

Ατομικότητα

- Αν το transaction αποτύχει μετά το βήμα step 3 και πριν το βήμα 6, το σύστημα πρέπει να εξασφαλίσει ότι θα αναιρεθούν τα βήματα 1-3, αλλιώς θα υπάρχει ασυνέπεια

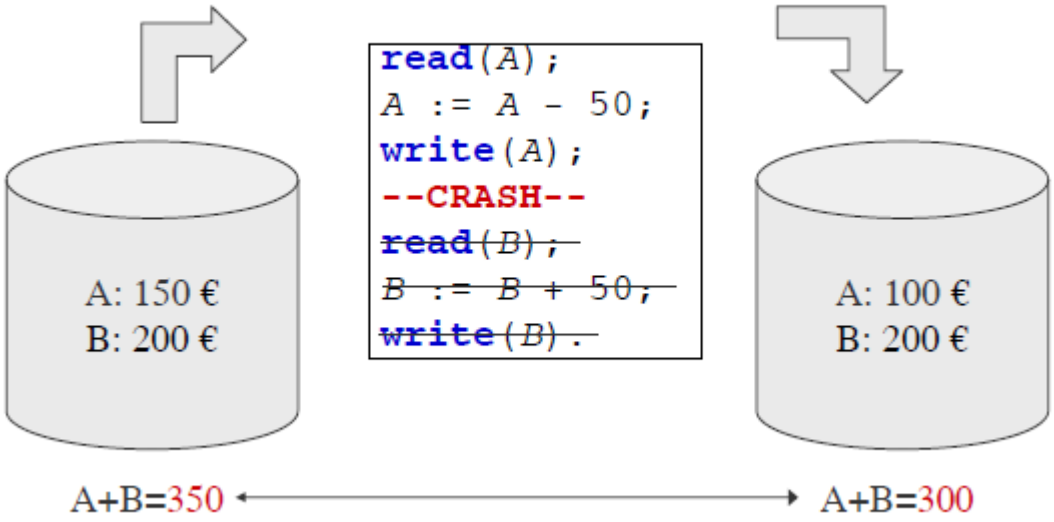

Μονιμότητα (1)

- Αν το transaction επιτύχει, δλδ ο χρήστης ενημερωθεί ότι έγινε η μεταφορά χρημάτων επιτυχώς, αυτό δε θα αλλάξει από κανένα σφάλμα.

Μονιμότητα (2)

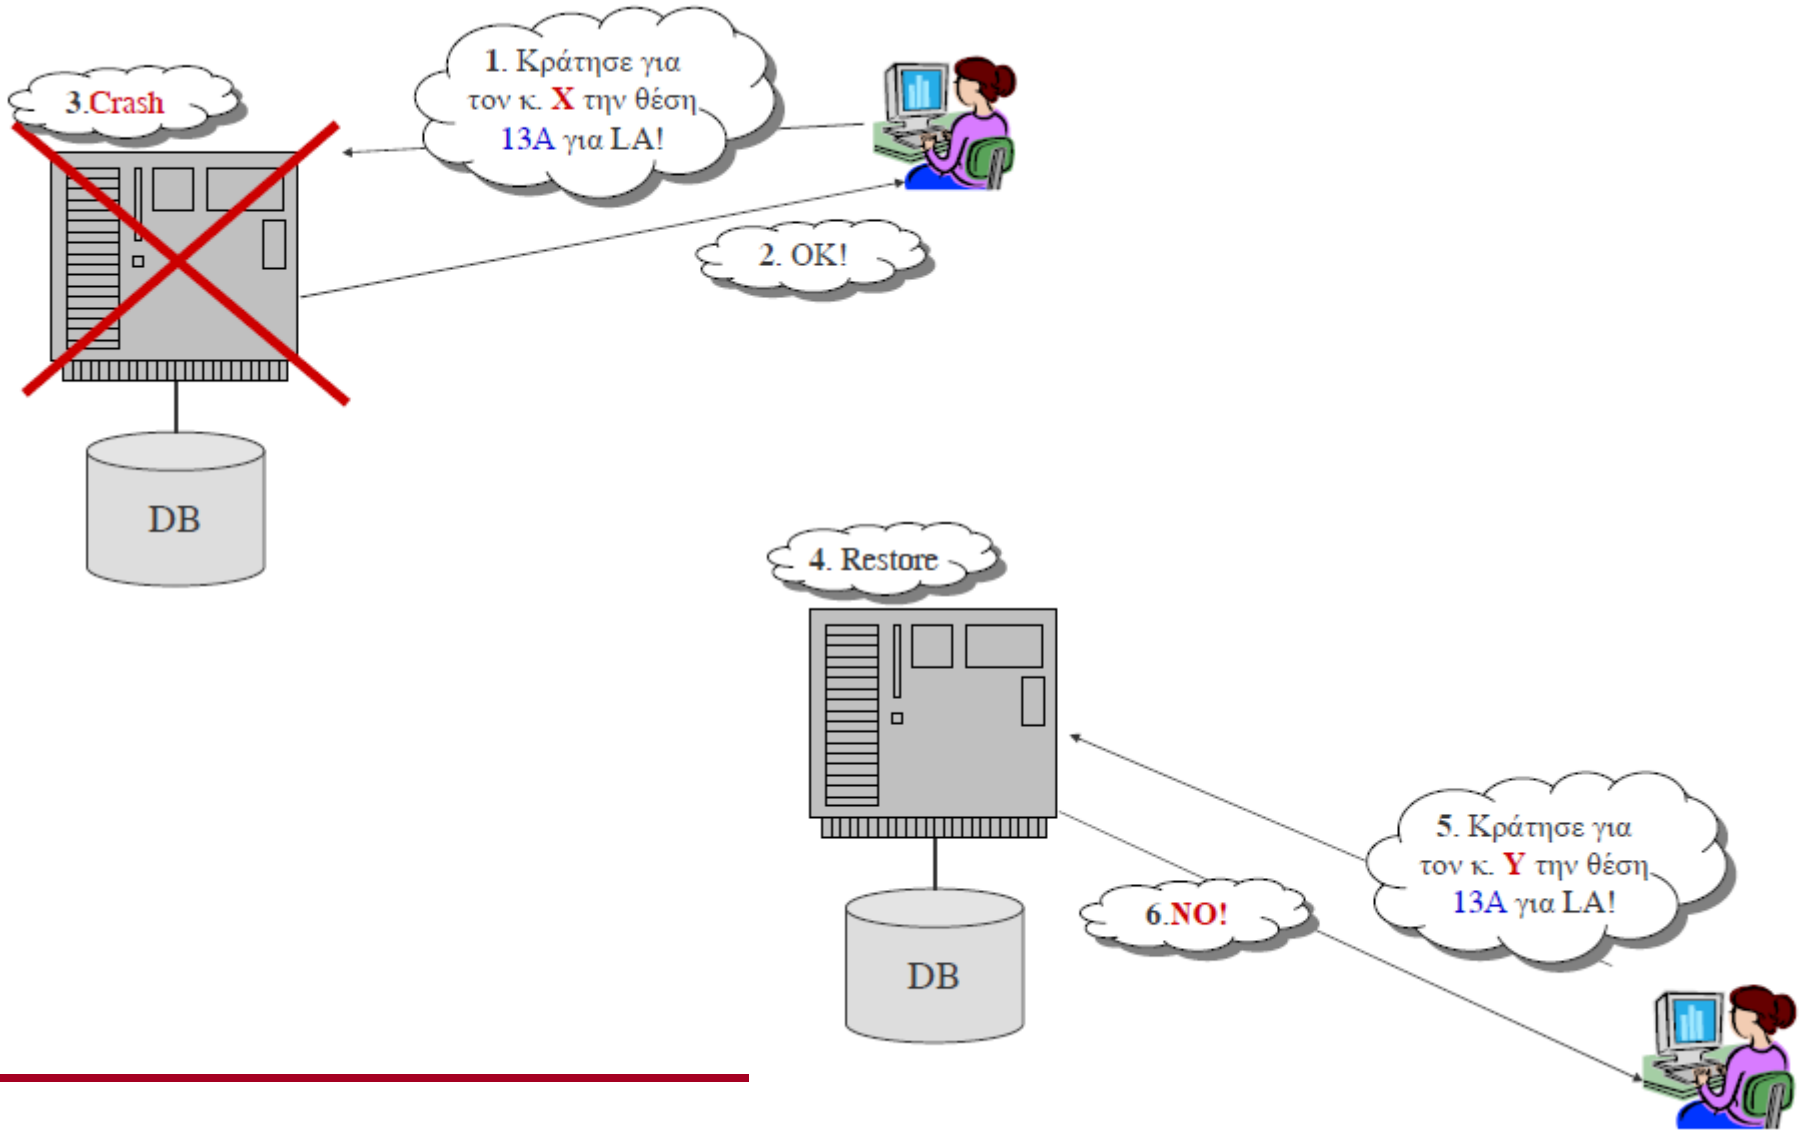

Απομόνωση (1)

- Αν στο σύστημα τρέχουν παραπάνω από μια δοσοληψίες ταυτόχρονα και η μια μπορεί να δει τα ενδιάμεσα αποτελέσματα της άλλης (π.χ. ανάμεσα στο βήμα 3 και 6) μπορεί να έχουμε ασυνέπεια.
  Η πιο απλή ιδανική λύση είναι η ***σειριακή*** εκτέλεση transactions, είναι όμως κακή από πλευράς απόδοσης

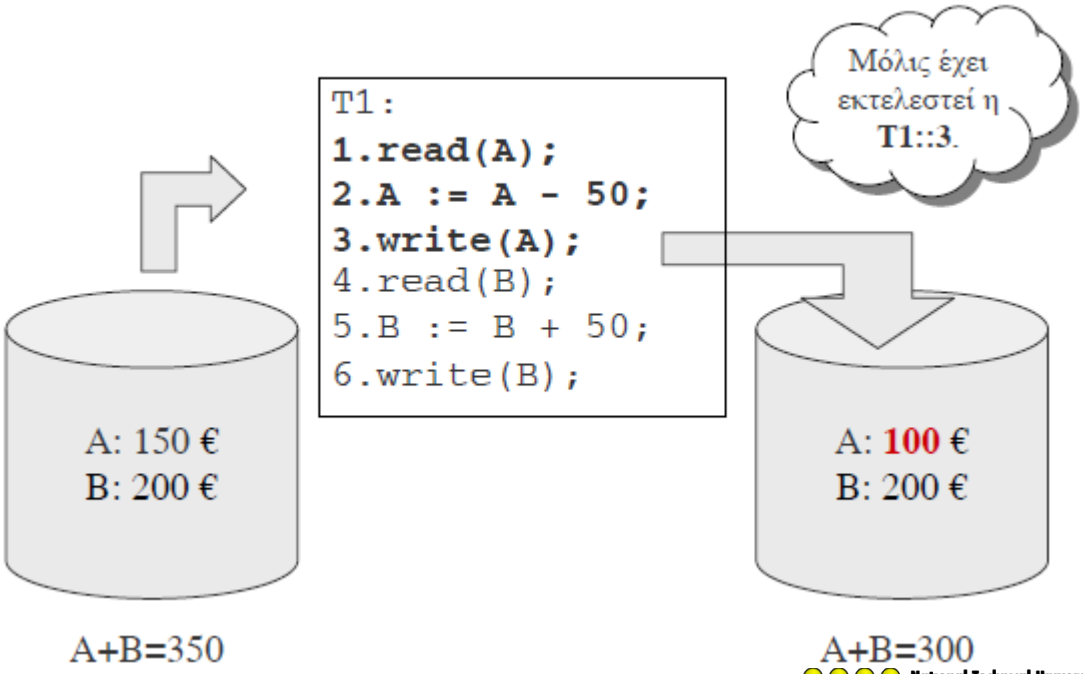

Απομόνωση (2)

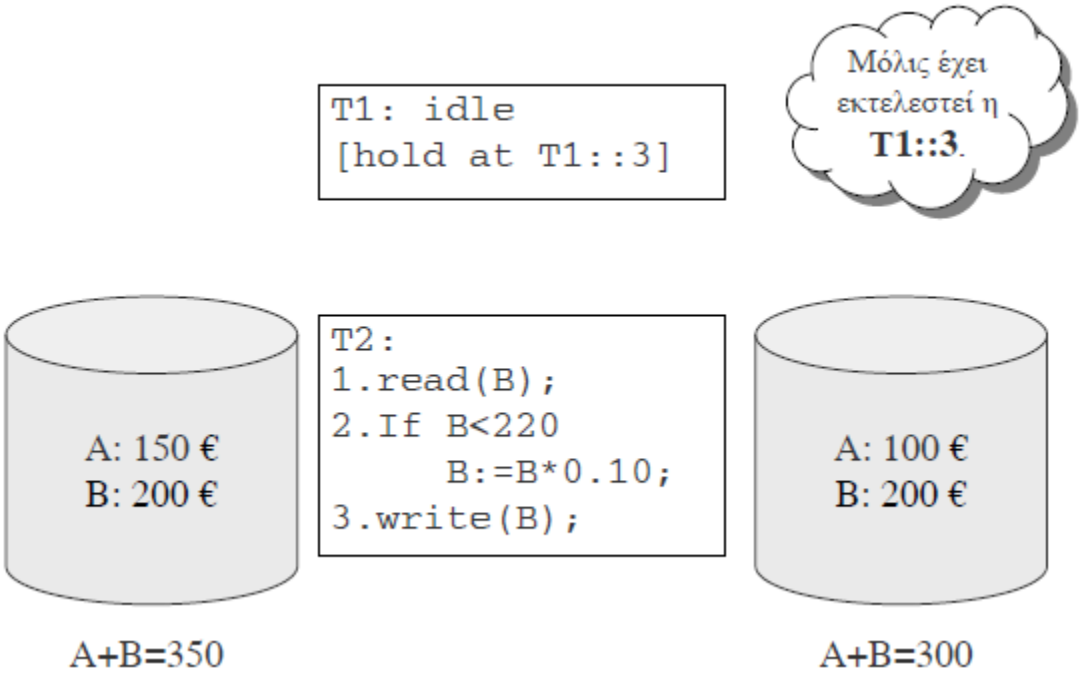
T1: idle
[hold at T1::3]
Μόλις έχει εκτελεστεί η T1::3.
A: 150 €
B: 200 €
T2:
1.read(B);
2.If B<220
B:=B*0.10;
3.write(B);
A: 100 €
B: 200 €
A+B=350
A+B=300

Απομόνωση (3)

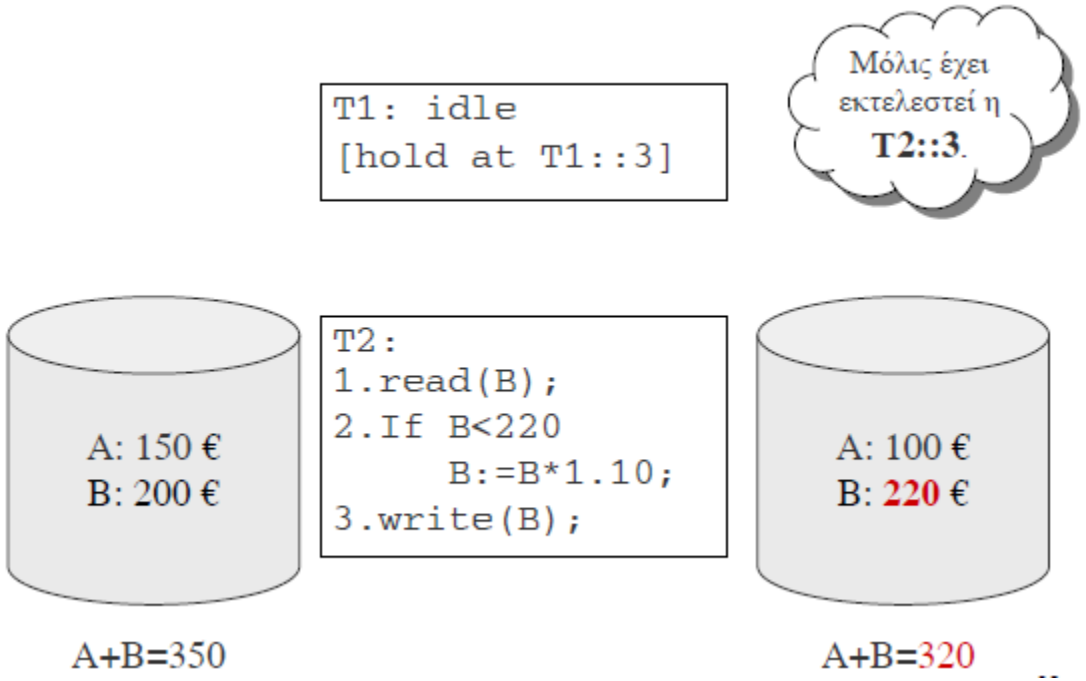
T1: idle
[hold at T1::3]
Μόλις έχει εκτελεστεί η T2::3.
T2:
1.read(B);
2.If B<220
B:=B*1.10;
3.write(B);
A: 150 €
B: 200 €
A: 100 €
B: 220 €
A+B=350
A+B=320

Ταυτόχρονη Εκτέλεση

- Και γιατί να μην τρέχουμε σειριακά τις δοσοληψίες, τη μία μετά την άλλη;
  - **Αποδοτικότερη χρήση CPU και I/O:** μεγαλύτερο transaction *throughput:* ένα transaction μπορεί να χρησιμοποιεί CPU ενώ άλλο να διαβάζει ή να γράφει στον δίσκο
  - **Μειωμένος μέσος χρόνος απόκρισης** για τα transactions: Οι σύντομες δοσοληψίες, δεν έχουν λόγο να αναμένουν την ολοκλήρωση των πιο χρονοβόρων

- *Αλγόριθμοι διαπλοκής (interleaving) των δοσοληψιών* – μηχανισμοί για isolation

Χρονοπρογράμματα - Schedules

- *Schedules* – Σειρά από ενέργειες που δείχνουν τη χρονολογική σειρά με την οποία τελικά εκτελέστηκαν ομάδες από ταυτόχρονες δοσοληψίες
  - Περιέχει όλες τις ενέργειες των εμπλεκόμενων δοσοληψιών
  - Διατηρεί τη σειρά με την οποία εμφανίζονται οι ενέργειες σε κάθε δοσοληψία

Παράδειγμα

- Το T_1 μεταφέρει \$50 από το *A* στο *B*
- Το T_2 μεταφέρει 10% του υπολοίπου του *A* στο *B*.
- **Σειριακό** χρονοπρόγραμμα: Πρώτα όλο το T_1 και μετά όλο το T_2 ή πρώτα όλο το T_2 και μετά το T_1 (n! δυνατά σειριακά χρονοπρογράμματα για n δοσοληψίες

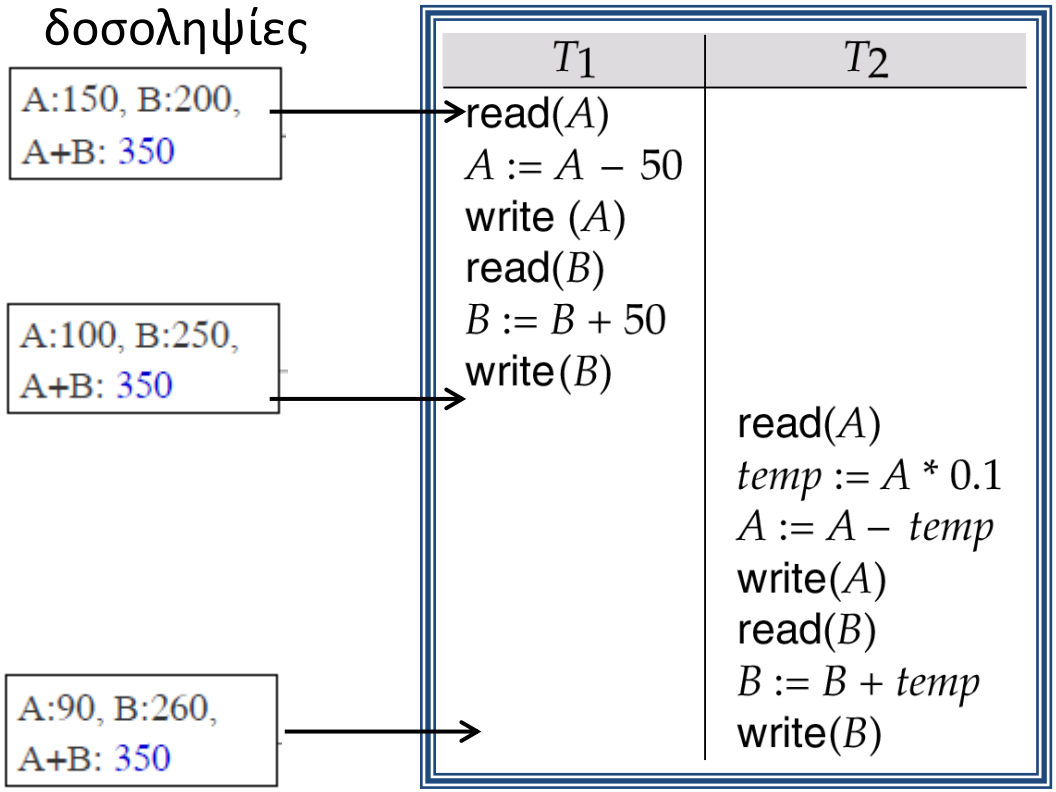

Παράδειγμα (2)

- Δεν είναι σειριακό χρονοπρόγραμμα αλλά είναι ισοδύναμο με ένα σειριακό

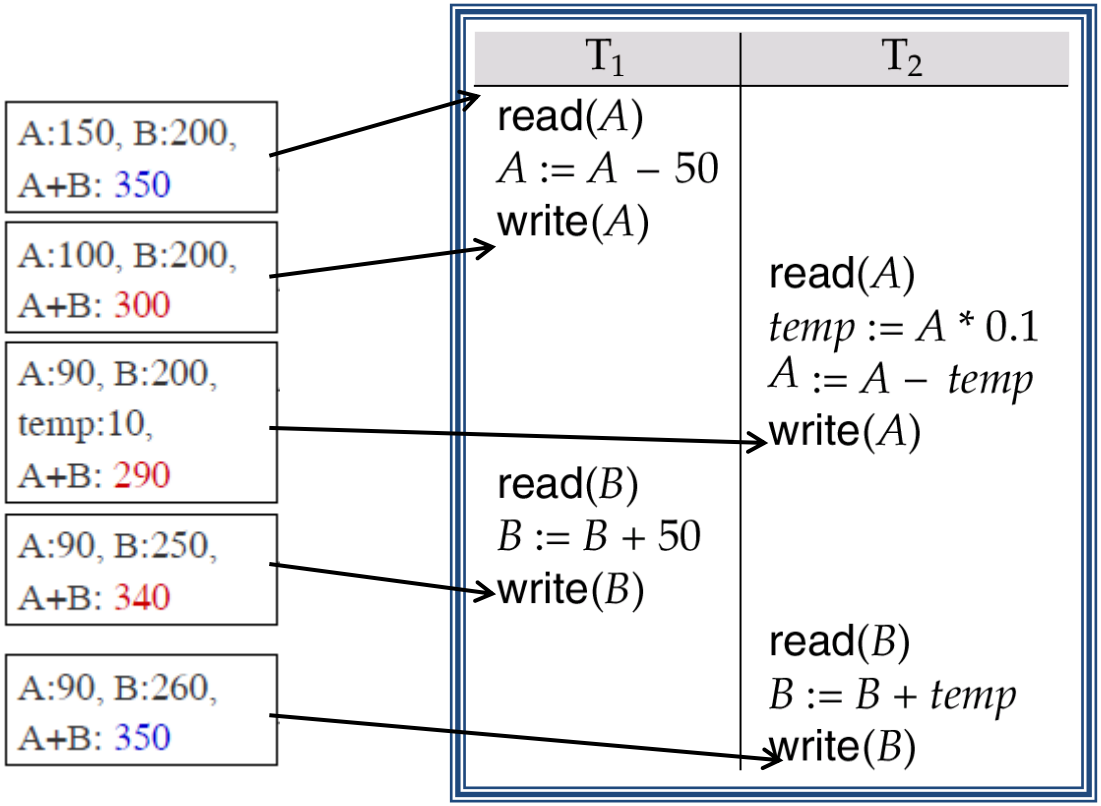

Διατηρείται το άθροισμα

A + B

Παράδειγμα (3)

- Αυτό το χρονοπρόγραμμα δεν είναι ισοδύναμο με το σειριακό, γιατί δε διατηρεί την τιμή sum *A* + *B*.

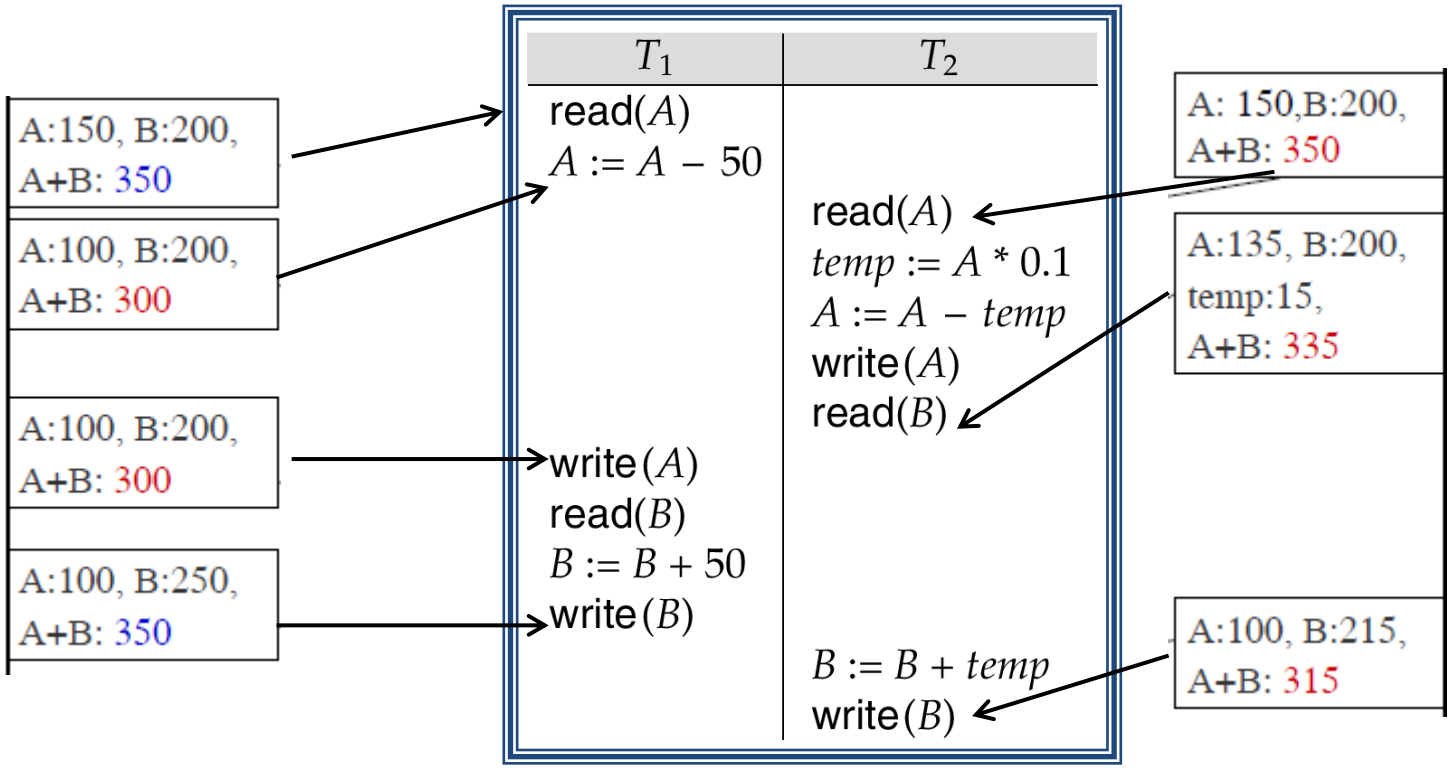

Προβλήματα σε χρονοπρογράμματα

- Ασυνεπείς αναγνώσεις (dirty reads)
- Διαδοχικές αναιρέσεις (cascading aborts)
- Απώλειες ενημερώσεων (lost updates)

Ασυνεπής ανάγνωση (dirty read)

- Το μερικό αποτέλεσμα ενός transaction διαβάζεται από κάποιο άλλο
- a:200, b:200

Transaction *V*:		**Transaction *W*:**	
a.withdraw(100) *b.deposit(100)*		*branchTotal()*	
a.withdraw(100);	$100		
		total = a.getBalance()	$100
		total = total+b.getBalance()	$300
		total = total+c.getBalance()	
b.deposit(100)	$300	⋮	

- Το μερικό αποτέλεσμα του V χρησιμοποιείται από το W και τελικά δίνει λάθος αποτέλεσμα

Διαδοχικές αναιρέσεις (cascading aborts)

Transaction *T*:		Transaction *U*:	
a.getBalance()		*a.getBalance()*	
a.setBalance(balance + 10)		*a.setBalance(balance + 20)*	
balance = a.getBalance()	$100		
a.setBalance(balance + 10)	$110		
		balance = a.getBalance()	$110
		a.setBalance(balance + 20)	$130
		commit transaction	
abort transaction			

- Το abort του T απαιτεί και abort του U

Απώλεια ενημέρωσης (lost update)

- Ένα transaction προκαλεί απώλεια πληροφορίας για ένα άλλο

Transaction*T* :	**Transaction*U*:**
balance = b.getBalance(); *b.setBalance(balance*1.1);*	*balance = b.getBalance();* *b.setBalance(balance*1.1);*

balance = b.getBalance(); $200

balance = b.getBalance(); $200

*b.setBalance(balance*1.1);* $220

*b.setBalance(balance*1.1);* $220

T/U's update on the shared object, "b", is lost

Γιατί συμβαίνει αυτό

- Γιατί τα προηγούμενα χρονοπρογράμματα δεν είναι *σειριοποιήσιμα* (serializable)
  - Δλδ δεν έχουν το ίδιο αποτέλεσμα με μια σειριακή εκτέλεση
- Χρονοπρογράμματα με ταυτόχρονες δοσοληψίες πρέπει να έχουν το ίδιο αποτέλεσμα σε όλες τις μεταβλητές όπως ένα σειριακό χρονοπρόγραμμα
  - Δλδ πρέπει να έχουν πρόσβαση σε αντικείμενα (για read/write) με τρόπο ανάλογο της σειριακής εκτέλεσης

Σειριοποιησιμότητα

- Ένα χρονοπρόγραμμα είναι σειριοποιήσιμο (serializable) αν είναι ισοδύναμο με ένα σειριακό χρονοπρόγραμμα.
- 2 τεχνικές
  - Σειριοποιησιμότητα συγκρούσεων (conflict serializability)
  - Σειριοποιησιμότητα όψεως (view serializability)

- Ποιες λειτουργίες λαμβάνουμε υπόψιν;
  - Read/write
- Ποιες λειτουργίες έχουν σημασία για την ορθότητα;
  - write

Συγκρούσεις *read* and *write*

Operations of different transactions		*Conflict*	*Reason*
read	*read*	No	Because the effect of a pair of *read* operations does not depend on the order in which they are executed
read	*write*	Yes	Because the effect of a *read* and a *write* operation depends on the order of their execution
write	*write*	Yes	Because the effect of a pair of *write* operations depends on the order of their execution

Σειριοποιησιμότητα Συγκρούσεων

- Δύο χρονοπρογράμματα είναι ισοδύναμα συγκρούσεων αν για κάθε σύγκρουση, οι συγκρουόμενες πράξεις έχουν την ίδια σειρά στα 2 προγράμματα

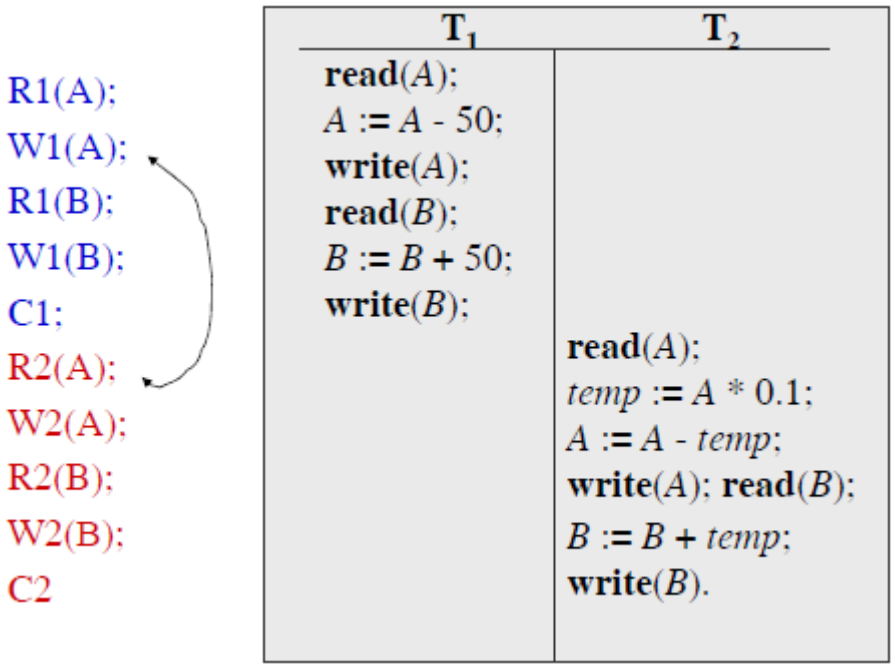

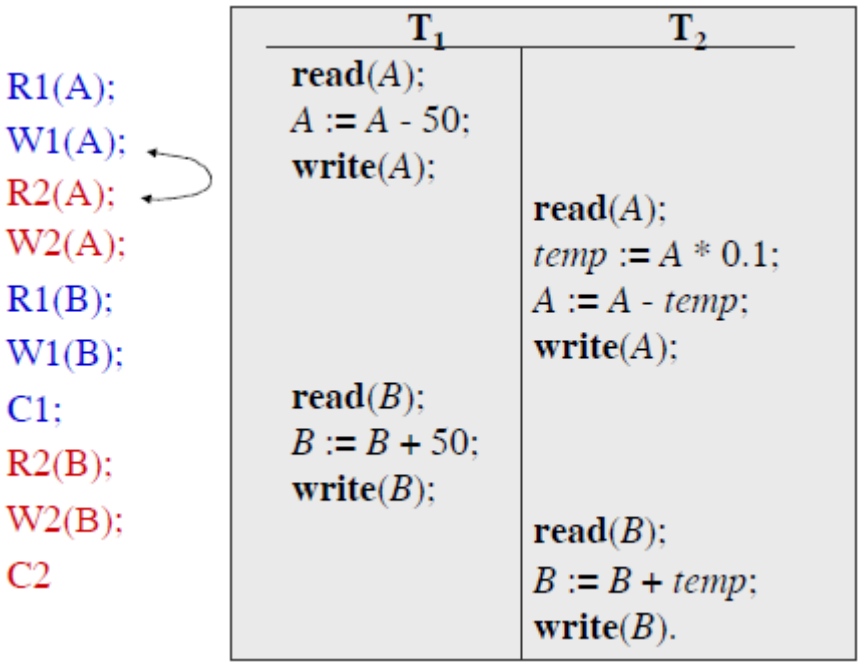

Σειριοποιησιμότητα Συγκρούσεων (2)

- Προβληματικό χρονοπρόγραμμα

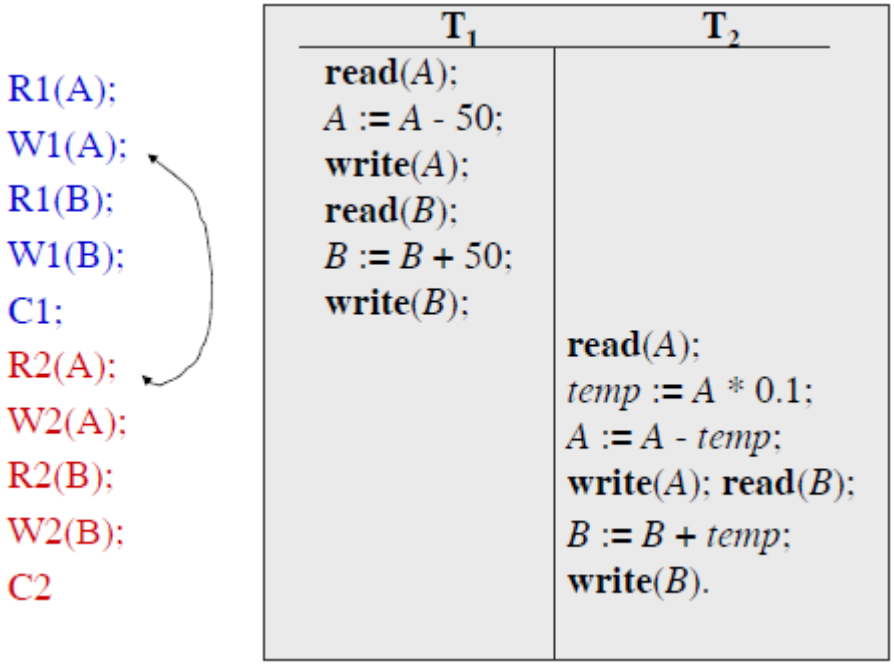

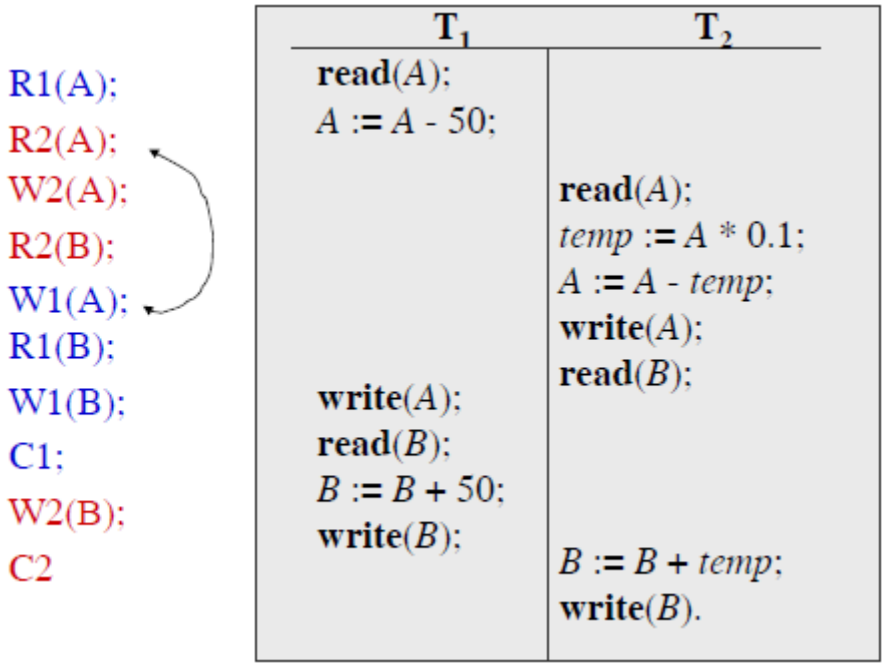

Τυπικός και Άτυπος Ορισμός

- Ένα πρόγραμμα είναι σειριοποιήσιμο συγκρούσεων (conflict serializable) αν είναι ισοδύναμο συγκρούσεων με ένα σειριακό
- Στο σειριακό χρονοπρόγραμμα κάθε δοσοληψία «ξεμπερδέυει» ξεχωριστά με κάθε αντικείμενο και μετά το αναλαμβάνει μια άλλη
- Σε ένα σειριοποιήσιμο, το να μην υπάρχει σύγκρουση σημαίνει ότι το πρόγραμμα «ξεμπερδεύει» με τα αντικείμενα με την ίδια σειρά ανά δοσοληψία όπως κι ένα σειριακό

T_1	T_2
read(A);	
write(A);	
	read(B);
	write(B);
read(B);	
write(B).	
	read(A);
	write(A).

Έλεγχος σειριοποιησιμότητας

- Γράφος σειριοποιησιμότητας
  - Κάθε δοσοληψία ένας κόμβος
  - Κατευθυνόμενη ακμή από την T_i στην T_j αν μια ενέργεια της T_i συγκρούεται με μια επακόλουθή της, της T_j
  - Πάνω στην ακμή σημειώνουμε το αντικείμενο για το οποίο συγκρούονται οι δοσοληψίες
- Γράφος με κύκλο: μη σειριοποιήσιμος σε σχέση με συγκρούσεις
- Γράφος χωρίς κύκλο: σειριοποιήσιμος σε σχέση με συγκρούσεις

Παράδειγμα

T_1	T_2
read(A);	
$A := A - 50$;	
write(A);	
	read(A);
	$temp := A * 0.1$;
	$A := A - temp$;
	write(A);
read(B);	
$B := B + 50$;	
write(B);	
	read(B);
	$B := B + temp$;
	write(B).

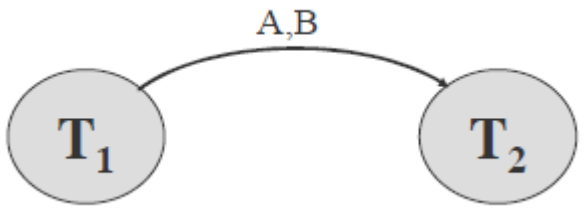

Παράδειγμα

T_1	T_2
read(A);	
$A := A - 50$;	
	read(A);
	$temp := A * 0.1$;
	$A := A - temp$;
	write(A);
	read(B);
write(A);	
read(B);	
$B := B + 50$;	
write(B);	
	$B := B + temp$;
	write(B).

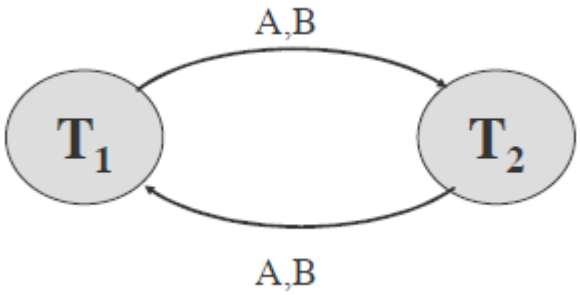

Σειριοποιησιμότητα όψεως

- Δεν είναι conflict serializable....
- Τι μας νοιάζει, αφού τελικά σημασία έχει τι γράφει η T_6

T_3	T_4	T_6
read(Q)		
	write(Q)	
write(Q)		
		write(Q)

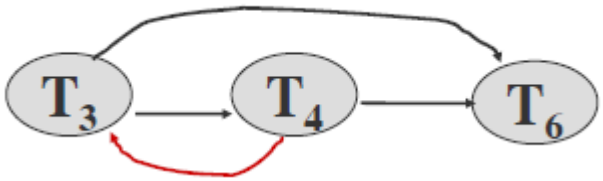

Σειριοποιησιμότητα όψεως

- Κάθε conflict serializable χρονοπρόγραμμα είναι και view serializable.
- Δεν ισχύει το αντίστροφο
- Κάθε view serializable χρονοπρόγραμμα που δεν είναι conflict serializable έχει τυφλές εγγραφές (blind writes), δλδ writes για τα οποία δεν έχουν προηγηθεί reads στη δοσοληψία τους
- Σειριοποιησιμότητα όψεως: NP-complete αλγόριθμος

Στην πράξη

- Αλγόριθμοι ελέγχου σειριοποιησιμότητας πολύ ακριβοί
- Έλεγχος αφού φτιαχτεί το χρονοπρόγραμμα… λίγο αργά
- Online πρωτόκολλα ελέγχου ταυτοχρονισμού δοσοληψιών
  - Locking
  - Optimistic concurrency control
  - Timestamp ordering
- Τι συμβαίνει με τα σφάλματα;
  - Πρέπει να μπορούμε να κάνουμε roll-back στην κατάσταση πριν τα transactions

Αυστηρή εκτέλεση Transactions

- Τα transactions πρέπει να καθυστερούν τα reads και writes σε ένα αντικείμενο μέχρι όλα τα υπόλοιπα transactions που έγραφαν το ίδιο αντικείμενο να κάνουν είτε commit είτε abort

Πρωτόκολλα κλειδώματος

- Διασφαλίζουν την σειριοποιησιμότητα μιας σειράς ενεργειών με κανόνες για το τι μπορεί να προσπελάσει μια δοσοληψία.
- Βασική έννοια του κλειδώματος (lock)
  - μεταβλητή που σχετίζεται με ένα στοιχειώδες δεδομένο και περιγράφει την κατάστασή του, σε σχέση με πιθανές πράξεις που μπορούν να εφαρμοσθούν σε αυτό.

2 phase locking (2PL)

- Αλγόριθμος Κλειδώματος Δύο Φάσεων
- Εξασφαλίζει τη σειριοποιησιμότητα επιτρέποντας στις δοσοληψίες να προσπελάσουν αντικείμενα, αν καταφέρουν να αποκτήσουν αποκλειστικό (exclusive) lock γι' αυτά.
- Αντικείμενο: μεταβλητές, εγγραφές βάσης, σελίδες…
- Πρώτη φάση (growing phase): παίρνω νέα locks
- Δεύτερη φάση (shrinking phase): απελευθερώνω τα locks
- Ένα transaction δεν παίρνει νέο lock, αν έχει απελευθερώσει έστω κι ένα

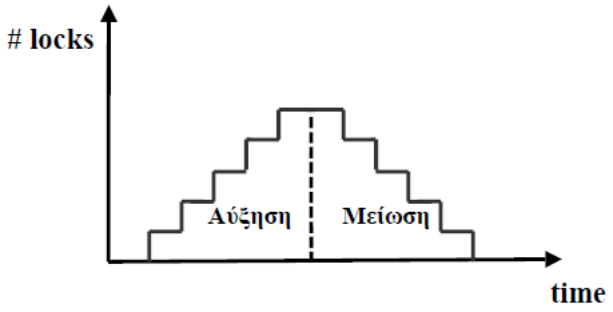

Παράδειγμα - χωρίς 2PL

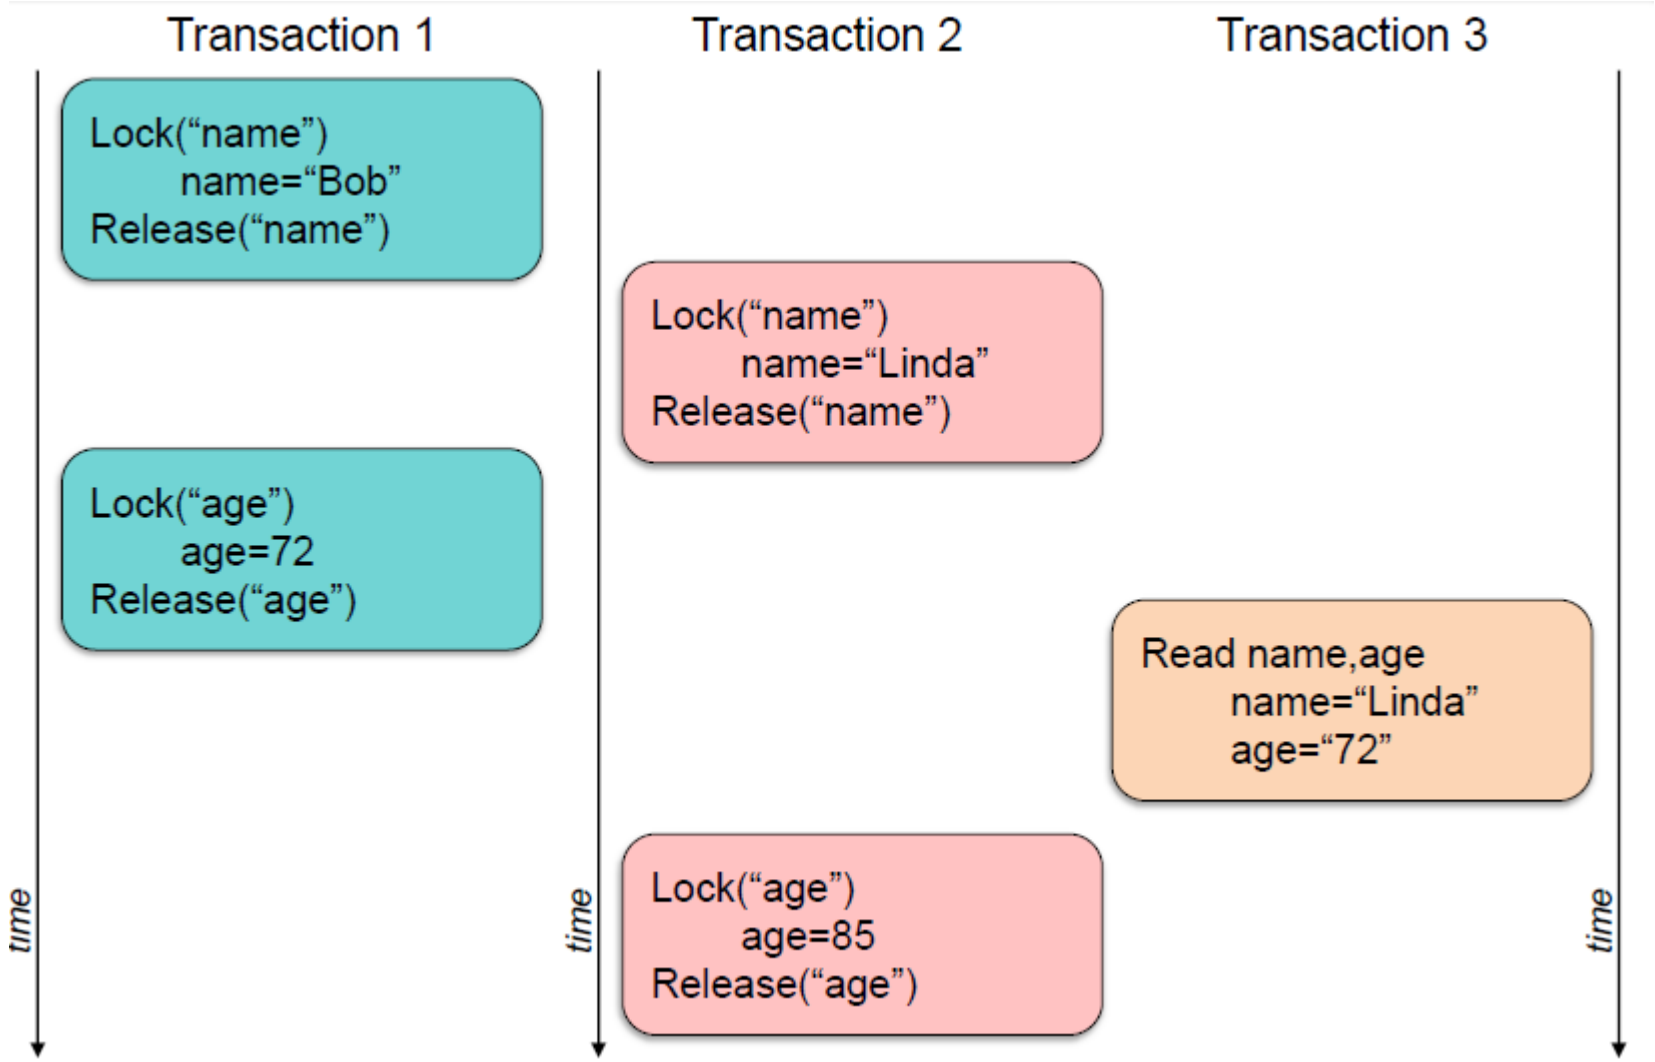

Παράδειγμα χωρίς 2PL

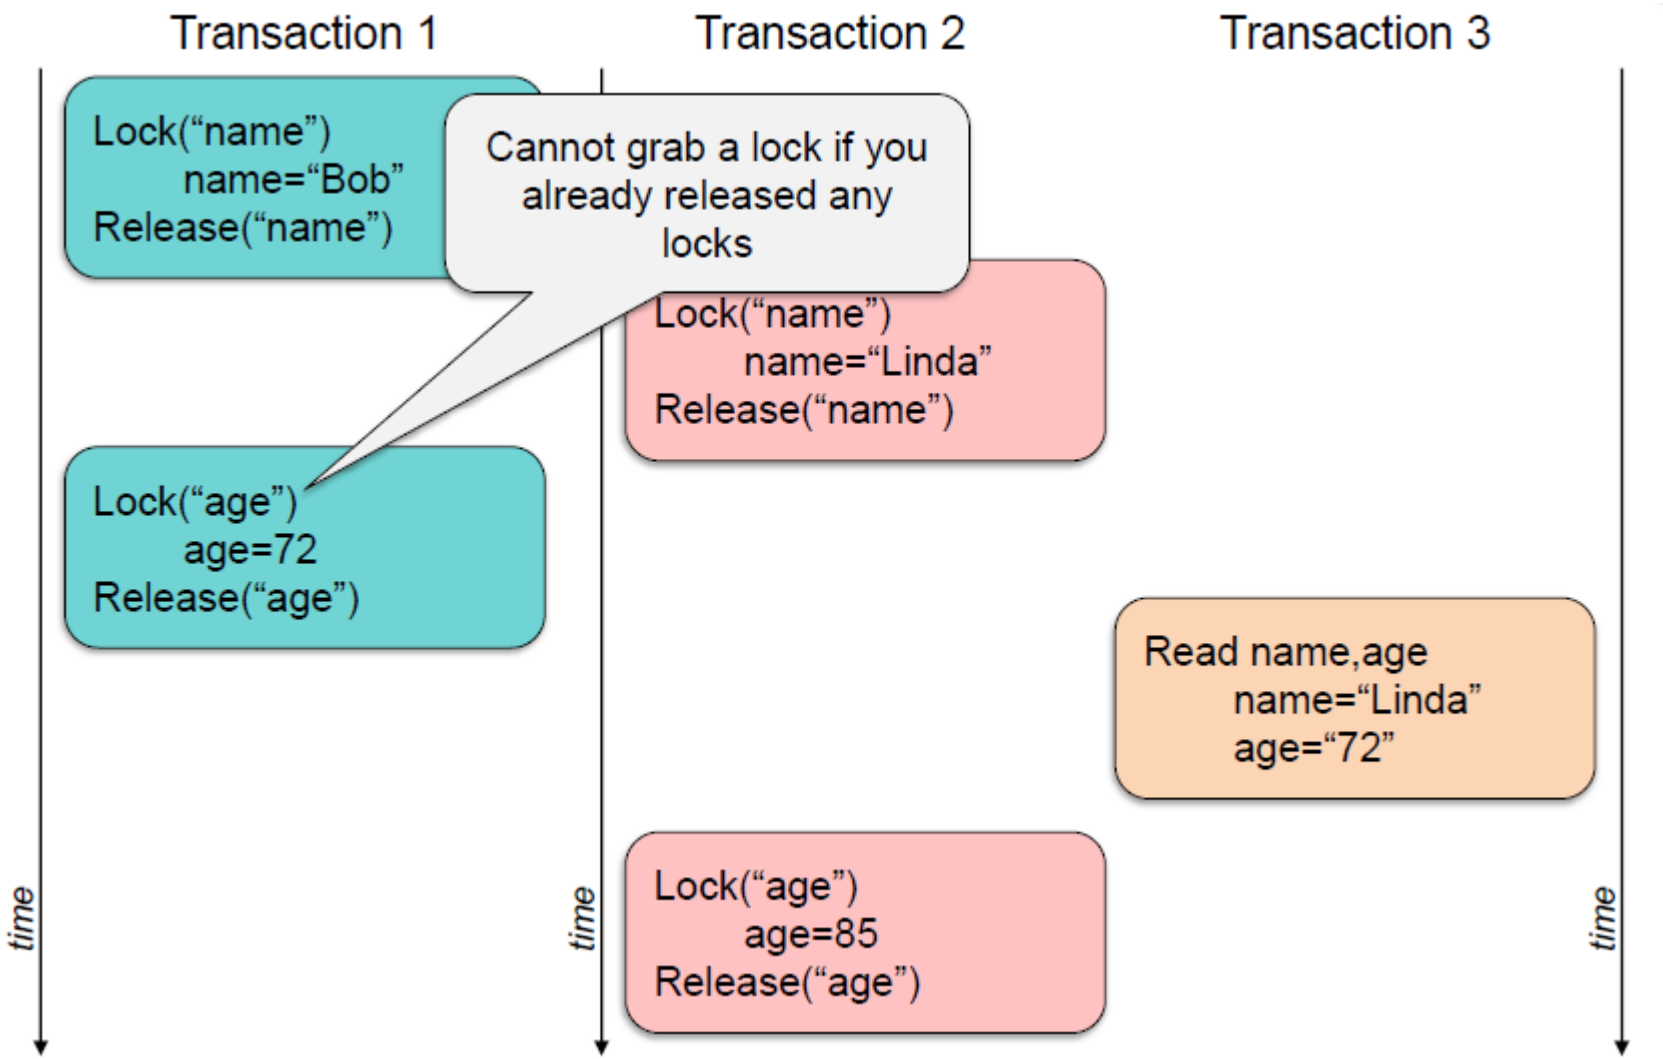

Παράδειγμα 2PL

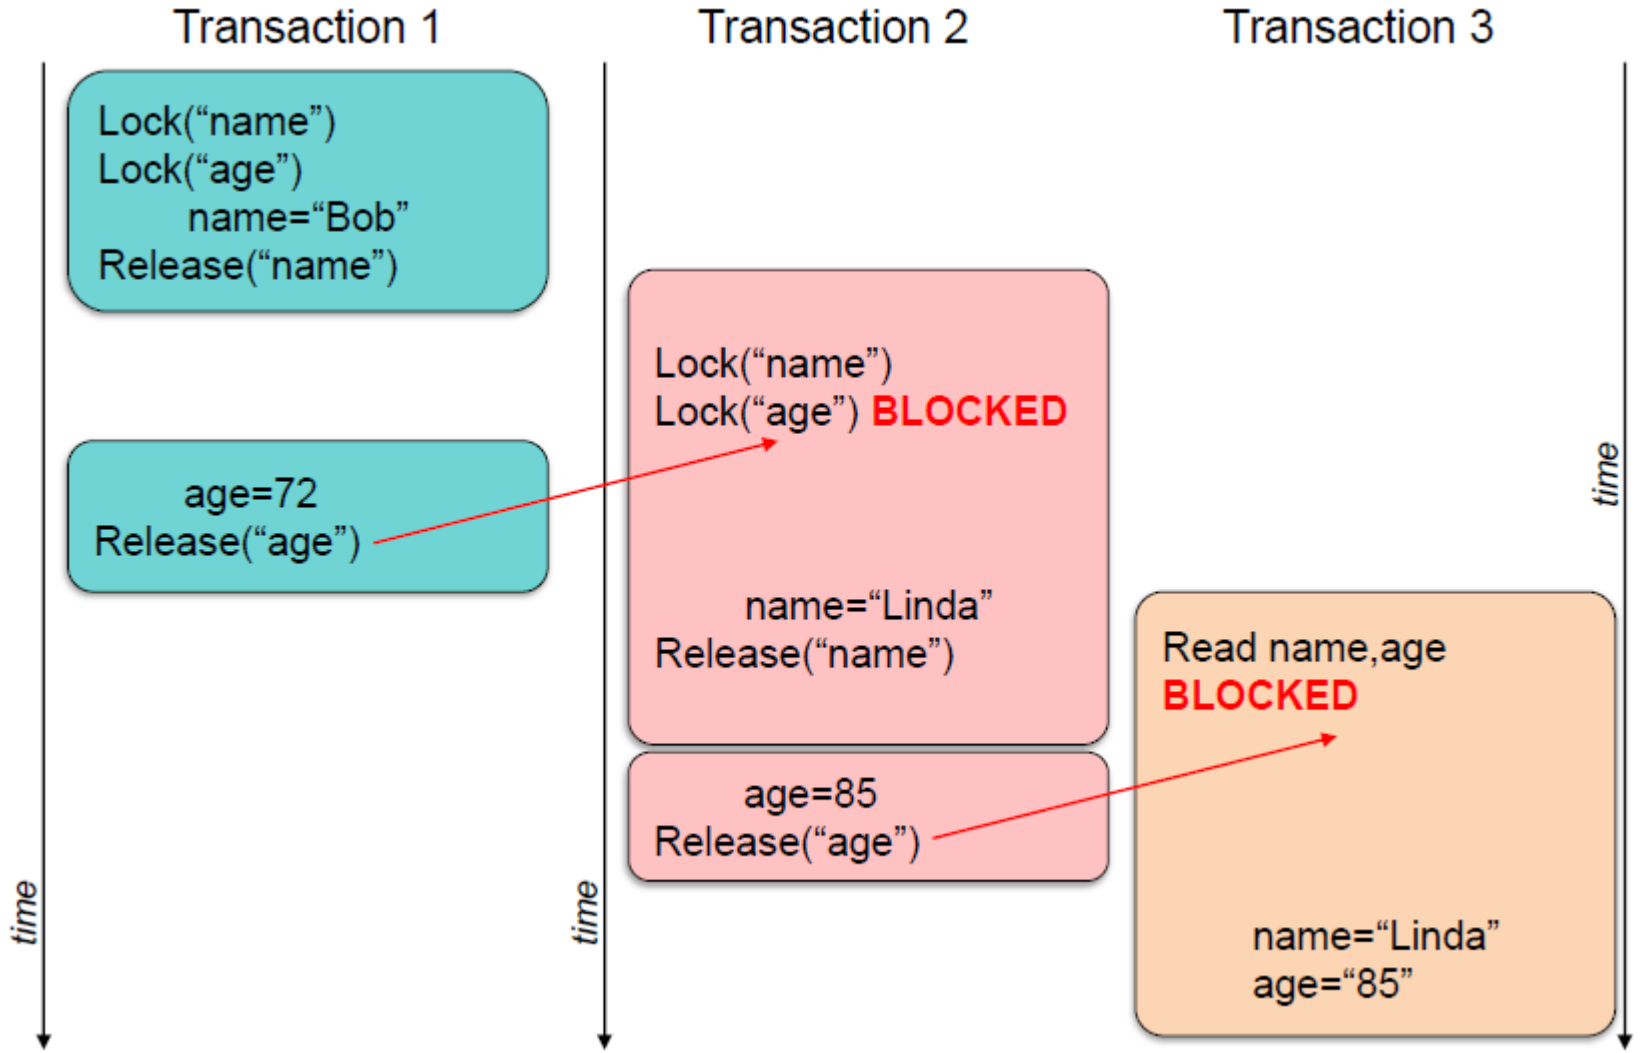

Πρόβλημα με 2PL

- Cascading aborts!
  - Αν ένα transaction κάνει abort τότε οποιοδήποτε άλλο transactions έχει προσπελάσει δεδομένα από released locks (uncommitted data) πρέπει να κάνει κι αυτό abort
- Λύση: Αυστηρό (Strict) 2PL
  - Ένα transaction κρατάει όλα τα locks μέχρι να κάνει commit ή abort

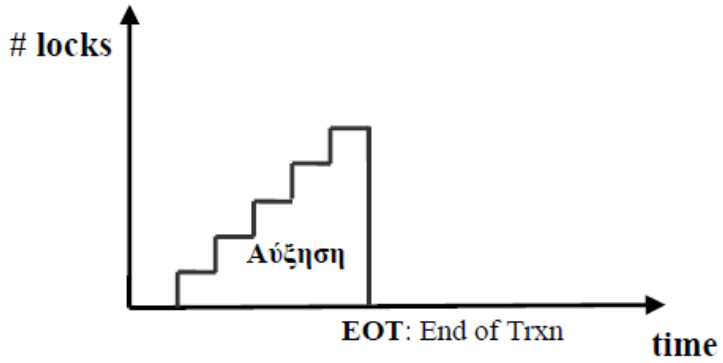

Μπορούμε να κάνουμε κάτι καλύτερο;

- Είδαμε “exclusive” locks
- Βελτιώνουμε ταυτοχρονισμό υποστηρίζοντας πολλούς αναγνώστες
  - Δεν υπάρχει πρόβλημα όταν διαβάζουν ταυτόχρονα το ίδιο αντικείμενο πολλά transactions
  - Μόνο ένα transaction πρέπει να μπορεί να γράφει ένα αντικείμενο και κανένα άλλο δεν πρέπει να μπορεί να το διαβάσει
- Δύο είδη locks: read locks και write locks
  - read lock πριν διαβάσουμε ένα αντικείμενο
    - Ένα read lock απαγορεύει το γράψιμο
  - write lock πριν γράψουμε ένα αντικείμενο
    - Ένα write lock απαγορεύει διάβασμα και γράψιμο
  - Ένα transaction μπλοκάρει αν δεν μπορεί να πάρει lock

Non-Exclusive Locks

For one object		*Lock requested*	
		read	*write*
Lock already set	*none*	OK	OK
	read	OK	wait
	write	wait	wait

- Αν ένα transaction
  - Δεν έχει lock για κάποιο αντικείμενο:
    - Οποιοδήποτε άλλο transaction μπορεί να πάρει read ή write lock
  - Έχει read lock για κάποιο αντικείμενο :
    - Οποιοδήποτε άλλο transaction μπορεί να πάρει read lock αλλά να περιμένει για write lock
  - Έχει write lock για κάποιο αντικείμενο :
    - Οποιοδήποτε άλλο transaction πρέπει να περιμένει για read ή write lock

Αναβάθμιση κλειδώματος

- Μέχρι τώρα υποθέταμε ότι κάθε δοσοληψία γνωρίζει εκ προοιμίου όλα τα κλειδώματα που θα ζητήσει.
- Τι γίνεται όμως αν δεν τα γνωρίζει;
- Η λύση έγκειται στην αναβάθμιση κλειδώματος (αντίστοιχα,υποβάθμιση)

Κανόνες αναβάθμισης

- Αναβαθμίσεις επιτρέπονται μόνο στη φάση αύξησης
- Υποβαθμίσεις επιτρέπονται μόνο στη φάση μείωσης
- Ένα read lock αναβαθμίζεται σε write lock όταν ένα transaction θέλει να γράψει στο ίδιο αντικείμενο.
- Ένα read lock που μοιράζονται περισσότερα του ενός transactions read lock(s) δεν μπορεί να αναβαθμιστεί. Για αναβάθμιση θα πρέπει το transaction να περιμένει να απελευθερωθούν τα υπόλοιπα read locks

Αδιέξοδο (Deadlock)

Transaction *T*		Transaction *U*	
Operations	**Locks**	**Operations**	**Locks**
a.deposit(100);	write lock *A*		
		b.deposit(200)	write lock *B*
b.withdraw(100)			
• • •	waits for *U*'s lock on *B*	*a.withdraw(200);*	waits for *T*'s lock on *A*
• • •		• • •	
• • •		• • •	
		• • •	

Deadlock

- Η κατάσταση κατά την οποία δύο δοσοληψίες Τ και Τ’ αναμένουν η μία την άλλη για την απελευθέρωση κάποιων κλειδωμάτων
- Προφανώς, ο παραπάνω ορισμός γενικεύεται για περισσότερες από δύο δοσοληψίες

Γράφος αναμονής (wait-for)

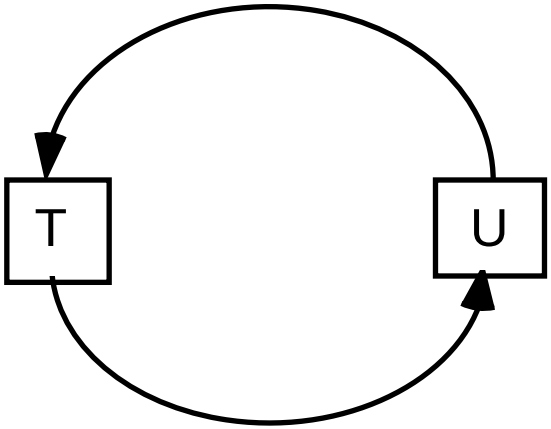

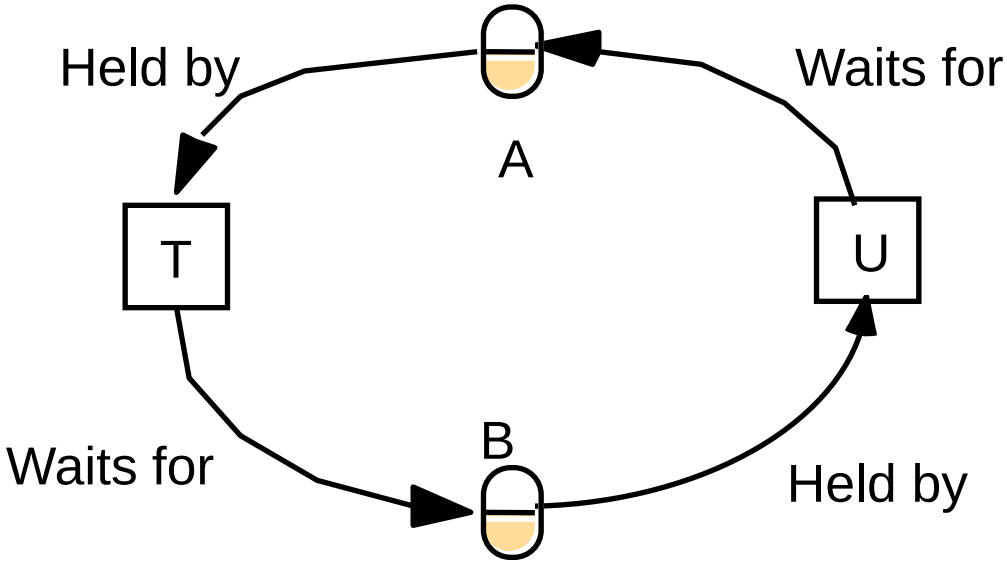

•Θεώρημα: Υπάρχει αδιέξοδο αν και μόνο αν ο γράφος αναμονής έχει κύκλο

•Στην πράξη το σύστημα ελέγχει τον γράφο αναμονής περιοδικά

•Εναλλακτικά, αντί για γράφο, μπορεί να μετρά πόση ώρα μια δοσοληψία αναμένει για ένα κλείδωμα και να την τερματίζει αν περάσει κάποιο όριο…

Ανίχνευση ή αποτροπή;

- Αντί να περιμένουμε να συμβεί το αδιέξοδο, μπορούμε να το αποτρέψουμε προληπτικά
- Συντηρητικός 2PL: μια δοσοληψία αποκτά όλα τα κλειδώματα που χρειάζεται στο ξεκίνημα της.
- Αν δεν μπορεί να τα πάρει ΟΛΑ, δεν ξεκινά, αλλά αναμένει!
- Εν γένει, προτιμώνται τα αδιέξοδα...

Προβλήματα με locks

- Οι τεχνικές κλειδώματος είναι συντηρητικές (αποφεύγονται οι συγκρούσεις)
- Επιβάρυνση (overhead) χειρισμού κλειδώματος
- Έλεγχος προς ανίχνευση αδιεξόδων

Αισιόδοξη εκτέλεση δοσοληψιών

- Σε πολλές εφαρμογές η πιθανότητα 2 transactions να προσπελάζουν το ίδιο αντικείμενο είναι μικρή
- Επιτρέπουμε στα transactions να δρουν χωρίς locks
- Τσεκάρουμε για συγκρούσεις (conflicts)
- 3 φάσεις
  - **Read phase**: (ή working phase) η δοσοληψία διαβάζει, αλλά τροποποιεί τοπικά αντίγραφα των αντικειμένων σε δικό της χώρο
  - **Validation phase**: έλεγχος για συγκρούσεις – αν υπάρχει σύγκρουση, abort & restart
  - **Write phase**: (ή update phase) γράφει τα τοπικά αντίγραφα στο δίσκο

Πώς δουλεύει;

- Timestamp δοσοληψίας: η στιγμή που ξεκινά η φάση επικύρωσής της
- Έστω ότι έχουμε μια δοσοληψία Tj που θέλει να κάνει Επικύρωση
  - Θα την ελέγξουμε σε σχέση με όλες τις δοσοληψίες Ti με timestamp μικρότερο της Tj.
  - Για όλες τις δοσοληψίες Ti, τ.ω. Ti < Tj, αρκεί να ισχύει μία από τις 3 παρακάτω συνθήκες ελέγχου
  - Αν δεν ισχύει καμία εξ αυτών, η Tj πρέπει να κάνει ABORT και να επανεκκινηθεί.

1η συνθήκη ελέγχου

- Η Ti τελειώνει πριν αρχίσει η Tj
  - *Σειριακή εκτέλεση των δοσοληψιών*

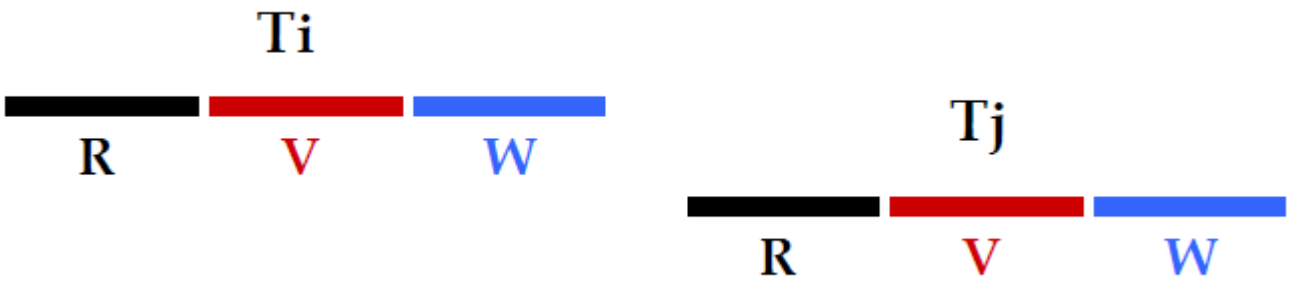

2η συνθήκη ελέγχου

- Η Ti τελειώνει πριν αρχίσει η φάση εγγραφής της Tj
- WriteSet(Ti) ∩ ReadSet(Tj) = Ø

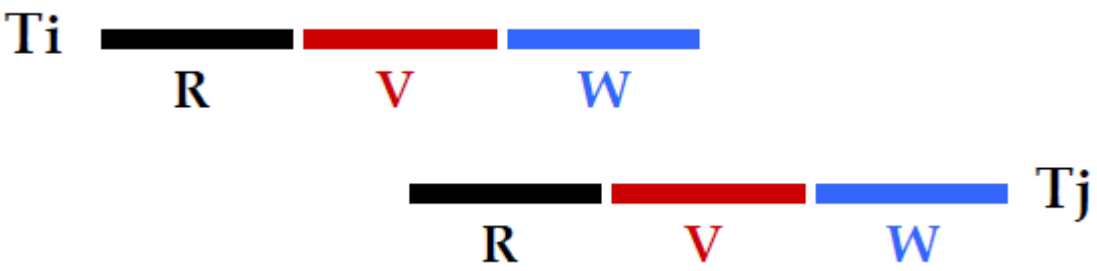

- *Η Tj δεν διαβάζει κανένα αντικείμενο που τροποποιεί η Ti*
- *Όλες οι εγγραφές της Ti προηγούνται αυτών της Tj*

3η συνθήκη ελέγχου

- Η Ti τελειώνει τη φάση ανάγνωσης πριν τελειώσει η φάση ανάγνωσης της Tj
- WriteSet(Ti) ∩ ReadSet(Tj) = Ø
- WriteSet(Ti) ∩ WriteSet(Tj) = Ø

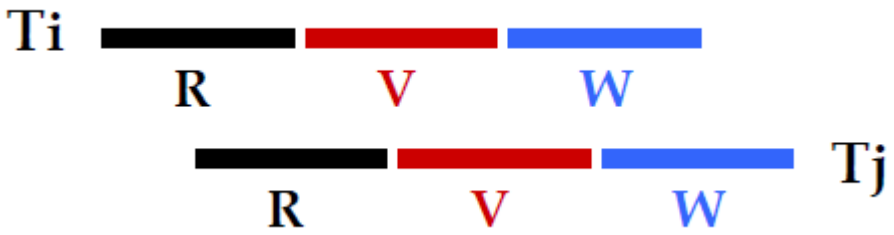

- *Η Tj και η Ti γράφουν αντικείμενα ταυτόχρονα, μεν, ...*
  αλλά, οι εγγραφές τους ΔΕΝ επικαλύπτονται!

Προσέξτε ότι…

- ΠΕΡΙΟΡΙΣΜΟΣ: Όταν μια δοσοληψία βρίσκεται σε φάση επικύρωσης, καμιά άλλη δοσοληψία δεν μπορεί να κάνει COMMIT!!!
- Ο αισιόδοξος έλεγχος ταυτοχρονισμού, ουσιαστικά υλοποιεί το γράφο σειριοποιησιμότητας (πρακτικά ελέγχει αν οι συγκρούσεις γίνονται με την ίδια σειρά)

Σχόλια

- Overhead διατήρησης λίστας προσπελασθέντων αντικειμένων
- Αν οι συγκρούσεις είναι σπάνιες έχουμε μεγαλύτερη απόδοση.
- Αν οι συγκρούσεις είναι συχνές, το overhead του abort & restart είναι μεγαλύτερο.

Διάταξη χρονοσφραγίδων

- timestamp δοσοληψίας TS(T): η χρονική στιγμή που ξεκινά η δοσοληψία T
- timestamp ανάγνωσης αντικειμένου RTS(O): η χρονική στιγμή της τελευταίας ανάγνωσης του αντικειμένου O (ασχέτως δοσοληψίας)
- timestamp εγγραφής αντικειμένου WTS(O): η χρονική στιγμή της τελευταίας εγγραφής του αντικειμένου O (ασχέτως δοσοληψίας)
- Αντί να συγκρίνω δοσοληψίες, θεωρώ ότι η Ti διαβάζει/γράφει το αντικείμενο O
- Κάθε φορά, μια δοσοληψία Tj συγκρίνει το TS(Tj) με τα timestamps των αντικειμένων

Κανόνες

- *Σωστή διάταξη:*
  - Τα *read και write timestamps του αντικειμένου πρέπει να είναι παλιότερα του timestamp του τρέχοντος transaction* αν αυτό θέλει να γράψει
  - Τα *write timestamps του αντικειμένου πρέπει να είναι παλιότερα του timestamp του τρέχοντος transaction* αν αυτό θέλει να διαβάσει
- Abort και restart transaction με μεγαλύτερο timestamp αν η σειρά είναι λάθος

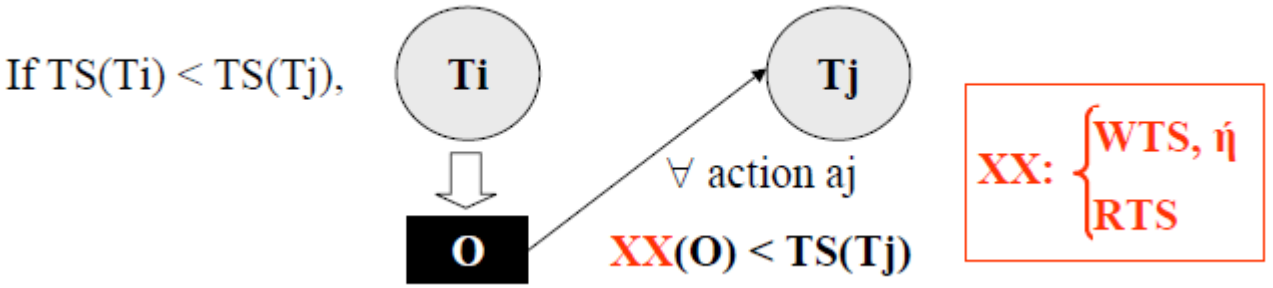

Πραγματικά Παραδείγματα

- Dropbox
  - Optimistic concurrency control
  - File granularity
  - Version history
- Google Docs
  - Character granularity
  - Conflict resolution (rare)
- Wikipedia
  - Optimistic concurrency control

Ανακεφαλαίωση

- Απλές δοσοληψίες (transactions)
- Ιδιότητες ACID
  - Και κυρίως atomicity και durability
- Σειριοποιησιμότητα (serializability)
- Έλεγχος ταυτοχρονισμού
  - Κλειδώματα (Locking)
  - Αισιόδοξος έλεγχος ταυτοχρονισμού (optimistic concurrency control)
  - Διάταξη χρονοσφραγίδων (Timestamp ordering)
- Αδιέξοδα (deadlocks)

*Χρησιμοποιήθηκε υλικό από τις διαφάνειες του Π. Βασιλειάδη