



Προχωρημένα Θέματα Τεχνολογίας και Εφαρμογών Βάσεων Δεδομένων

Εσωτερική Αρχιτεκτονική Βάσεων Δεδομένων

Πάνος Βασιλειάδης

pvassil@cs.uoi.gr

Σεπτέμβρης 2009

www.cs.uoi.gr/~pvassil/courses/db_III/


Θεματολόγιο

- Γενική αρχιτεκτονική βάσεων δεδομένων & ΣΔΒΔ
- Εσωτερική αποθήκευση δεδομένων
- Δομές στη μνήμη
- Διεργασίες
- Παράρτημα: Αξιοπιστία και διαθεσιμότητα βάσεων δεδομένων

Θεματολόγιο

- Γενική αρχιτεκτονική βάσεων δεδομένων & ΣΔΒΔ
- Εσωτερική αποθήκευση δεδομένων
- Δομές στη μνήμη
- Διεργασίες
- Παράρτημα: Αξιοπιστία και διαθεσιμότητα βάσεων δεδομένων

Βάσεις Δεδομένων και ΣΔΒΔ



Βάσεις Δεδομένων και ΣΔΒΔ

- Μια **Βάση Δεδομένων** είναι μια οργανωμένη συλλογή θεματικά συναφών δεδομένων (συνήθως σε μεγάλη κλίμακα)
- Ένα **Σύστημα Διαχείρισης Βάσεων Δεδομένων (DataBase Management System – DBMS)** είναι ένα πακέτο λογισμικού που σκοπό έχει τη διαχείριση βάσεων δεδομένων

Βάσεις Δεδομένων και ΣΔΒΔ


✦ Διαχείριση Βάσεων Δεδομένων =

- ✦ αποθήκευση
 - ✦ επερώτηση
 - ✦ ανανέωση
- } των δεδομένων
- ✦ εγγύηση της αξιοπιστίας
 - ✦ εγγύηση της διαθεσιμότητας
- } της ΒΔ

✦ Σχεσιακό ΣΔΒΔ (Relational DBMS – **RDBMS**): ΣΔΒΔ στο οποίο η οργάνωση των δεδομένων ακολουθεί το σχεσιακό μοντέλο

Σχήματα της Βάσης Δεδομένων

- Το **φυσικό σχήμα** αφορά την αποθήκευση των δεδομένων στη βάση δεδομένων
- Οι **όψεις** (των χρηστών) αφορούν το πώς βλέπουν οι χρήστες τη βάση δεδομένων
- Το **λογικό σχήμα** δρα ως γέφυρα ανάμεσα στα δύο άκρα



Σχήματα της Βάσης Δεδομένων

➤ Λογικό σχήμα:


Emp(emp_id:integer, name:
varchar2[40], dept_id: integer)
Dept(dept_id: integer, manager-id:
integer)

➤ Φυσικό σχήμα


ISAM files for relations in xxx.ora
B+-tree index on emp_id

➤ Όψεις

Supervises(emp-id, manager-id)




Γενική αρχιτεκτονική ενός DBMS στο runtime



DBMS στο runtime


- Όταν ξεκινάμε το DBMS λέμε ότι ξεκινάμε ένα **στιγμιότυπο του DBMS (DBMS instance)**.
- Ένα instance αποτελείται από
 - ✦ το **χώρο που καταλαμβάνει στην κύρια μνήμη** για να διεκπεραιώσει τη λειτουργία του DBMS
 - ✦ τις **υποστηρικτικές διεργασίες** που είτε συνδέουν το instance με τις εφαρμογές, είτε με τα δεδομένα, είτε κάνουν διάφορες διαχειριστικές λειτουργίες

Η αρχιτεκτονική της Oracle 9i



Η αρχιτεκτονική της Oracle 11g

Τα DBMSs
είναι πολύ
ώριμο
λογισμικό...



Θεματολόγιο

- Γενική αρχιτεκτονική βάσεων δεδομένων & ΣΔΒΔ
- Εσωτερική αποθήκευση δεδομένων
- Δομές στη μνήμη
- Διεργασίες
- Παράρτημα: Αξιοπιστία και διαθεσιμότητα βάσεων δεδομένων

Εσωτερική Οργάνωση των Δεδομένων στην Oracle

Λογικό Σχήμα

Φυσικό Σχήμα

Database

Tablespace

Segment

Extent

Block


Datafiles

Control files


↓
περιέχει

Εσωτερική Οργάνωση των Δεδομένων

- **Block** ή **page**: ένα σύνολο bytes στο σκληρό δίσκο
- **Extent**: ένα σύνολο από συνεχόμενα blocks
- **Segment**: ένα σύνολο από extent που αντιστοιχούν σε μια λογική οντότητα (π.χ., πίνακα ή ευρετήριο)




Εσωτερική Οργάνωση των Δεδομένων σε ένα block




➤ Το block είναι η μικρότερη μονάδα I/O της ΒΔ

- **Header:** σε τι segment βρίσκεται το block
- **Table Dir.:** ποιος πίνακας έχει εγγραφές στο block
- **Row Dir.:** οι δ/σεις των εγγραφών στο block
- **Row Data:** οι εγγραφές

Εσωτερική Οργάνωση των Δεδομένων σε μια εγγραφή



Εσωτερική Οργάνωση των Δεδομένων σε ένα ευρετήριο



Εσωτερική Οργάνωση των Δεδομένων σε ένα extent

- Ένα **extent** είναι μια **λογική** μονάδα αποθήκευσης που περιλαμβάνει **συνεχόμενα blocks**.
- Το extent είναι η μονάδα βάση της οποίας **το DBMS αποκτά νέο (συνεχόμενο) χώρο** στο δίσκο όταν ένα segment γεμίσει

Εσωτερική Οργάνωση των Δεδομένων σε ένα segment

- ✦ Ένα **segment** είναι μια λογική μονάδα αποθήκευσης που αφορά τα δεδομένα μιας λογικής οντότητας
- ✦ Έχουμε 4 ειδών segment:
 - ✦ Table segments
 - ✦ Index segments
 - ✦ Temporary segments
 - ✦ Rollback segments

Table & Index Segments

- Όλα τα δεδομένα ενός **πίνακα** βρίσκονται σε ένα **table segment**
- Όλα τα δεδομένα ενός **ευρετηρίου** βρίσκονται σε ένα **index segment**

*Για την ακρίβεια, υπάρχουν και άλλες περιπτώσεις που θα μάθετε όταν εισάγουμε την έννοια του **partition**...*


Temporary & Rollback Segments

- Όταν μια SQL εντολή χρειάζεται **βοηθητικό χώρο στο δίσκο** (διότι η κύρια μνήμη δεν φτάνει), καταφεύγει σε ένα **temporary segment**
- Συνήθως αφορά **ταξινόμηση εγγραφών** (sorting), σε πράξεις ORDER BY, GROUP BY, DISTINCT, ...ή και CREATE INDEX
- Όταν μια συναλλαγή μεταβάλει δεδομένα, **η προηγούμενη κατάσταση τους** αποθηκεύεται σε ένα **rollback segment**
- Αν ο χρήστης ακυρώσει τη συναλλαγή ή το σύστημα αποτύχει, **μπορούμε να βρούμε την προηγούμενη τιμή των δεδομένων από το rollback segment**

Datafiles & Tablespaces

Tablespace

(one or more datafiles)



Datafiles

(physical structures associated with only one tablespace)

Objects

(stored in tablespaces- may span several datafiles)

Control files

- ✦ Αρχεία που βοηθούν στο να καταγράφουν κρίσιμες πληροφορίες για μια ΒΔ
 - ✦ Όνομα ΒΔ
 - ✦ Datafiles της ΒΔ
 - ✦ Log files
 - ✦ Κρίσιμες ημερομηνίες για τη λειτουργία του συστήματος (π.χ., checkpoints)
 - ✦ ...


Θεματολόγιο

- Γενική αρχιτεκτονική βάσεων δεδομένων & ΣΔΒΔ
- Εσωτερική αποθήκευση δεδομένων
- Δομές στη μνήμη
- Διεργασίες
- Παράρτημα: Αξιοπιστία και διαθεσιμότητα βάσεων δεδομένων

DBMS στο runtime

- Όταν ξεκινάμε το DBMS λέμε ότι ξεκινάμε ένα **στιγμιότυπο του DBMS (DBMS instance)**.
- Ένα instance αποτελείται από
 - ✦ το **χώρο που καταλαμβάνει στην κύρια μνήμη** για να διεκπεραιώσει τη λειτουργία του DBMS . Στην Oracle ο χώρος αυτός ονομάζεται **System Global Area (SGA)**
 - ✦ τις **υποστηρικτικές διεργασίες** που είτε συνδέουν το instance με τις εφαρμογές, είτε με τα δεδομένα, είτε κάνουν διάφορες διαχειριστικές λειτουργίες

Oracle Instance



Διαδικασία εκκίνησης/τερματισμού

- Η διαδικασία έναρξης του instance είναι:
 1. **Εκκίνηση του instance**, που αντιστοιχεί πρακτικά στην δέσμευση του σχετικού χώρου στη μνήμη και εκκίνηση των σχετικών διεργασιών
 2. **Mounting μια βάσης δεδομένων στο instance**, που σημαίνει τη συσχέτιση της ΒΔ με το instance αυτό
 3. **Άνοιγμα (opening) της βάσης δεδομένων**, που σημαίνει ότι η ΒΔ γίνεται διαθέσιμη στους χρήστες προς επερώτηση
- Προφανώς, η διαδικασία τερματισμού έχει την αντίστροφη σειρά


Διαδικασία εκκίνησης/τερματισμού

- Εάν **δεν κάνουμε open** τη ΒΔ, ο DBA μπορεί να επιτελέσει **διαχειριστικές λειτουργίες**
- Εναλλακτικά, μπορεί να ανοίξει τη ΒΔ σε **read-only mode**
- Εάν κάποιο instance τερματιστεί με ανώμαλο τρόπο (π.χ., **αποτυχία** της μνήμης, ή του δίσκου) τότε **οι διαχειριστικές λειτουργίες** που το DBMS κάνει αυτόματα γίνονται **στο άνοιγμα της ΒΔ**

Δομές στη μνήμη

- Δύο είναι οι βασικές δομές στη μνήμη:
- **System Global Area (SGA)** και περιλαμβάνει κυρίως δομές για την επικοινωνία δίσκου και μνήμης:
 - ✦ data buffers
 - ✦ log buffers
- **Program Global Area (PGA)** που ουσιαστικά κρατά τις λεπτομέρειες για κάθε διαδικασία του συστήματος και κυρίως για κάθε σύνδεση χρήστη


Δομές στην μνήμη




System Global Area

- Η SGA περιέχει δομές δεδομένων κοινές σε όλους τους χρήστες
 - Data Buffer Cache
 - Log Buffer
 - Shared Pool
 - ...


Δομές στην μνήμη



Data Buffer Cache



Data Buffer Cache



Data Buffer Cache

- Η **Data Cache** είναι μια ειδική περιοχή της μνήμης από (προς) την οποία **μεταφέρουμε σελίδες** δεδομένων προς (από) το **σκληρό δίσκο**
- Ξανά: Τα δεδομένα είναι οργανωμένα σε blocks (pages) και θεωρήστε αντιστοιχία από ένα block προς ένα buffer χάριν απλότητας

Data Buffer Cache


✦ Είδη buffers

- ✦ **Free buffer**: δεν έχει χρησιμοποιηθεί ακόμα
- ✦ **Pinned buffer**: χρησιμοποιείται από μια διεργασία
- ✦ **Dirty buffer**: αν μεταφέρουμε κάποια σελίδα στη μνήμη και μεταβάλλουμε τα δεδομένα της, ο buffer ονομάζεται **βρώμικος**(dirty)

Data Buffer Cache


- Χρησιμοποιούμε δύο λίστες, την **Write List** και την **LRU list** για την οργάνωση των buffers στη μνήμη
- **Write list**: κάθε dirty buffer μπαίνει στη write list μέχρι να τον αντιγράψουμε στο δίσκο
- **Least Recently Used -- LRU list**: (i) ελεύθερους, (ii) pinned και (iii) dirty buffers που έχουν αντιγραφεί στο σκληρό δίσκο

Data Buffer Cache




- Κάθε φορά που για κάποιο λόγο προσπελάζουμε ένα buffer από την LRU αρχή της LRU λίστας, τον τοποθετούμε στο MRU τέλος της λίστας (είναι όντως ο most recently used)
- Κάποια στιγμή, κάποιοι dirty buffers είναι πιθανόν να εμφανιστούν στην αρχή της λίστας...


Data Buffer Cache



- Όταν κάποια ερώτηση ψάχνει κάποιο record, ψάχνουμε όλη την cache
- Αν το βρούμε (**cache hit**), επιστρέφουμε το record
- Αλλιώς, (**cache miss**) το αναζητούμε στο δίσκο. Σε αυτή την περίπτωση, πρέπει να βρούμε ένα buffer για να βάζουμε τις σελίδες που θα χρησιμοποιούμε




Data Buffer Cache




✦ Αναζήτηση ελεύθερου buffer:

- ✦ Το σύστημα ψάχνει την LRU list μέχρι να βρει ελεύθερο buffer.
- ✦ Αν ξεπεράσει κάποιο όριο (threshold) buffers χωρίς να βρει, τότε γράφει buffers στο δίσκο ώστε να μπορεί να τους χρησιμοποιήσει στη συνέχεια.
- ✦ Ποιους? Τους dirty buffers που είναι οι least recently used => στην αρχή της λίστας



Data Buffer Cache



- Εν γένει, αν γεμίσει η cache, και έχει συνεχόμενες cache misses, το σύστημα γράφει στο δίσκο dirty buffers ώστε να κάνει χώρο.
- Επίσης κάθε 20-30 min, στα checkpoints κάνει το ίδιο...
- Πάλι, οι dirty buffers στην αρχή της LRU είναι εκείνοι που μεταφέρονται...

Συχνότητα Checkpoint

✦ ORACLE:

- ✦ LOG_CHECKPOINT_TIMEOUT: 1800 sec (30')
- ✦ Την ίδια στιγμή, η συχνότητα μεταξύ checkpoints για τα log records (βλ. παρακάτω) είναι 3 sec


✦ DB2:

- ✦ ~10 – 15', εκπεφρασμένη ως ο αριθμός των log records που δημιουργήθηκαν ανάμεσα σε δύο checkpoints (π.χ., 150000 log records)

✦ MS SQL server:

- ✦ Automatic configuration (λέει)
- ✦ Δέστε <http://msdn.microsoft.com/en-us/library/ms189573.aspx>

Δομές στην μνήμη




Log buffer

- Οι εντολές τύπου INSERT, DELETE, UPDATE μεταβάλλουν το περιεχόμενο της ΒΔ
- Για να μπορεί να κρατήσει την παλαιά κατάσταση της ΒΔ, το DBMS χρησιμοποιεί ένα ειδικού τύπου αρχείο, το **log file**, στο οποίο καταγράφει τις ενέργειές του
- Αν το σύστημα αποτύχει για κάποιο λόγο, με βάση τις εγγραφές του log file μπορούμε να επανακτήσουμε την παλαιά κατάσταση της βάσης.

Log buffer

- Ακριβώς επειδή το log file βρίσκεται και αυτό στο δίσκο, χρειαζόμαστε μια **περιοχή στην κύρια μνήμη**, αφιερωμένη στην διαχείριση του **log file**
- Στον log buffer καταγράφουμε τις εγγραφές που πρόκειται να τοποθετήσουμε στο log file
- Σε **τακτά χρονικά διαστήματα (πχ., 1 sec)**, ή **PPIN** γράψουμε **dirty buffers με δεδομένα** στο δίσκο, ή **αν γεμίσει παραπάνω από το 1/3 των log buffers** γράφουμε (**flush**) τις σχετικές εγγραφές από το log buffer στο log file


Δομές στην μνήμη



Shared Pool

- Η **κοινή περιοχή (shared pool)** χρησιμοποιείται για δύο λόγους:
- **Data dictionary**: λίστα με περιγραφές του σχήματος των πινάκων, των δικαιωμάτων πρόσβασης των χρηστών, κλπ.
- **SQL area**: τα parse trees & τα πλάνα εκτέλεσης των SQL εντολών μπορούν να επαναχρησιμοποιηθούν από πολλούς χρήστες, γι' αυτό και παραμένουν στην SQL area

Δομές στην μνήμη




Program Global Areas

- Ας υποθέσουμε ότι ένας χρήστης θέλει να συνδεθεί στη ΒΔ για να κάνει μια σειρά από ερωτήσεις
- Το DBMS κάνει allocate κάποιο τμήμα της κύριας μνήμης για την εξυπηρέτηση του process του εν λόγω χρήστη. Θα ονομάζουμε το process αυτό, **server process**.
- Η **PGA** για το εν λόγω process, θα έχει πληροφορία που αφορά τη σύνδεση του χρήστη

Program Global Areas

- ✦ Σε κάθε PGA, τριών ειδών πληροφορίες έχουμε:
 - ✦ Σταθερή (persistent) πληροφορία: ποιος είναι ο χρήστης, από πού συνδέεται και πώς, ...
 - ✦ Run-time πληροφορία: τα δεδομένα που σχετίζονται με μια SQL εντολή. Π.χ.,
 - ✦ Αν κάνουμε INSERT, οι νέες τιμές που θα εισαχθούν στη βάση
 - ✦ Αν κάνουμε SELECT, οι εγγραφές που ανασύραμε από τη βάση




Program Global Areas

- Επίσης, υπάρχει χώρος για *ενδιάμεσα αποτελέσματα* των ερωτήσεων
- Π.χ., σε ένα `ORDER BY` query, χρειαζόμαστε επιπλέον χώρο για να ταξινομήσουμε τα δεδομένα
- **Προσοχή:** *όλες οι δύσκολες δουλειές στις ΒΔ παραδοσιακά λύνονται με ταξινόμηση*

Θεματολόγιο

- Γενική αρχιτεκτονική βάσεων δεδομένων & ΣΔΒΔ
- Εσωτερική αποθήκευση δεδομένων
- Δομές στη μνήμη
- Διεργασίες
- Παράρτημα: Αξιοπιστία και διαθεσιμότητα βάσεων δεδομένων

Διεργασίες



Διεργασίες

- Υπάρχουν δύο ειδών διεργασίες:
- Οι **διεργασίες των χρηστών (user processes)** που πρακτικά είναι οι εφαρμογές ή κάποιο query prompt (τύπου sqlplus)
- Οι **διεργασίες του DBMS** που χωρίζονται:
 - ✦ **Server** processes
 - ✦ **Background** processes

Διεργασίες χρηστών


- Κάποιες εφαρμογές στον client
- Ο χρήστης **συνδέεται (CONNECT)** με τη βάση δεδομένων με username & password
- Μια **session** είναι μια σειρά πράξεις που κάνει ο χρήστης μεταξύ connect & disconnect

Server Processes


Οι **server processes**

λαμβάνουν το αίτημα
ενός χρήστη και

- Κάνουν **parse** και **βελτιστοποιούν** την SQL εντολή
- **Εκτελούν** την εντολή:
μεταφέρουν τα δεδομένα από
το δίσκο και κάνουν τις
σχετικές πράξεις
- **Τοποθετούν το αποτέλεσμα** σε
κατάλληλες δομές




Background processes




Background processes: Database Writer (DBW0)

Υπεύθυνος για να μεταφέρει σελίδες από την LRU list της SGA στο δίσκο




Background processes: Log Writer (LGW0)

Υπεύθυνος για να
μεταφέρει σελίδες
από τους log buffers
στο log file




Background processes: Checkpoint Process (CKPT)

Υπεύθυνος για να
κάνει checkpoint σε
τακτά διαστήματα




Background processes: Monitors

- **Recoverer (RECO):**
2PC για
κατανεμημένες ΒΔ
- **Process Monitor (PMON):** process
recovery &
memory cleanup
- **System Monitor (SMON):** crash
recovery &
temporary segment
cleaning




Background processes: Listener

- Η διαδικασία που καθιστά εφικτή τη σύνδεση ενός client στον server
- Ο Listener καθορίζει επίσης και τον τρόπο και τις λεπτομέρειες της σύνδεσης




Background processes: Server processes (ξανά)

- Δύο τρόποι:
 - Shared
 - Dedicated



Shared Server Processes

- (1) Οι **shared server processes** έχουν ένα pool από connections & server processes
- (2) Κάθε φορά ο **dispatcher** βάζει μια αίτηση σε μια **ουρά αιτήσεων**
- (3) Κάποια από τις **server processes** αναλαμβάνει να την εξυπηρετήσει (4)




Shared Server Processes

(5) Το αποτέλεσμα μπαίνει σε μια **ουρά αποτελεσμάτων**

(6,7) Το αποτέλεσμα **γυρνά** πίσω στον client


Οι **shared server processes** ουσιαστικά δεν έχουν τίποτε στην PGA => **όλα τα δεδομένα τους είναι στην SGA**



Dedicated Server Processes

Για κάθε client και μια dedicated server process


Πιο βαρύ σε σχέση με τη μνήμη που καταναλώνεται ανά σύνδεση



Θεματολόγιο

- Γενική αρχιτεκτονική βάσεων δεδομένων & ΣΔΒΔ
- Εσωτερική αποθήκευση δεδομένων
- Δομές στη μνήμη
- Διεργασίες
- Παράρτημα: Αξιοπιστία και διαθεσιμότητα βάσεων δεδομένων

Συναλλαγές & Ταυτοχρονισμός



Συναλλαγή

- **Συναλλαγή** είναι
 - ✦ μια **σειρά** από **ενέργειες**, οι οποίες
 - ✦ **διαβάζουν** ή **γράφουν**
 - ✦ **αντικείμενα** της **βάσης**
- στα αγγλικά “transaction”
- σειρά: διατεταγμένο σύνολο, **λίστα**

Για προχωρημένους: στην θεωρία [της πληροφορικής γενικά, και των ΒΔ ειδικά], οι λεξούλες τύπου «σειρά» έχουν σημασία ... (π.χ., σειρά $\neq$ σύνολο)

Παράδειγμα συναλλαγής

T_0 : μεταφορά 50€ από
το λογαριασμό A στο
λογαριασμό B

```
read (A) ;  
A := A - 50 ;  
write (A) ;  
read (B) ;  
B := B + 50 ;  
write (B) .
```





Προβληματισμός

- Δύο είναι τα βασικά προβλήματα με τις συναλλαγές:
 - ✦ Τι θα γίνει αν κατά τη διάρκεια της εκτέλεσης, πέσει το σύστημα?
 - ✦ Τι θα γίνει αν δύο συναλλαγές επιχειρούν να μεταβάλλουν το ίδιο αντικείμενο ταυτοχρόνως?

Ορολογία: Στο εξής το σύστημα δεν «πέφτει», αλλά «αποτυγχάνει» ☺

Αποτυχία

```
read(A);  
A := A - 50;  
write(A);  
--CRASH--  
read(B);  
B := B + 50;  
write(B);
```



A+B=350


A+B=300

Ταυτοχρονισμός


Έστω δύο συναλλαγές που τρέχουν σειριακά:

- T1: μεταφέρει 50 € από τον A στον B
- T2: κάνει αύξηση στον A και το B κατά 10%

Ταυτοχρονισμός σειριακά



Ταυτοχρονισμός με πολυπλεξία συναλλαγών



Διαφορετικό
από το 275
του
σειριακού!!!

Καταστάσεις μιας συναλλαγής

- **Active**: στο ξεκίνημα και κατά τη διάρκειά της
- **Failed**: όταν το DBMS αντιληφθεί ότι η συναλλαγή δεν μπορεί να συνεχίσει
- **Aborted**: όταν η αποτυχημένη συναλλαγή έχει αναιρεθεί από το σύστημα και η ΒΔ είναι σε συνεπή μορφή
- **Committed**: όταν η συναλλαγή επιτύχει και η ΒΔ είναι σε συνεπή μορφή.
- Συμβολισμός:
 - **COMMIT_x**: η συναλλαγή X τερματίζει επιτυχώς
 - **ABORT_x**: η συναλλαγή X αποτυγχάνει

Αστοχίες του συστήματος

➤ Κακό πρόγραμμα (με λάθη, δηλ.)


⇒ ➤ Αστοχία **συναλλαγής** (αδιέξοδο, abort από τον χρήστη, κλπ)

⇒ ➤ Αστοχία του **συστήματος** (πτώση ρεύματος, αδιέξοδο λειτουργικού συστήματος)

➤ Αστοχία **υλικού** (καταστροφή σκληρού δίσκου)

Failure: αστοχία ή αποτυχία

Μοντέλο Read & Write



Main Memory

Οι διακεκομμένες αναπαριστούν
λειτουργίες που μπορεί να
καθυστερήσουν/ αγνοηθούν

Disk

Σε περίπτωση αποτυχίας ...

- Σκοπός είναι να διατηρήσουμε τη συνέπεια του συστήματος.
- Πρέπει να επαναλάβουμε (**REDO**) όλες τις συναλλαγές που έκαναν commit
- Πρέπει να αναιρέσουμε (**UNDO**) όσες παρενέργειες επέφεραν οι συναλλαγές που δεν πρόλαβαν να κάνουν commit


Log (Ιστορικό)

- ✦ **Log** (Ιστορικό/Ιχνος/Ημερολόγιο): ένα αρχείο στο σκληρό δίσκο που καταγράφει όλη την ιστορία των ενεργειών που εκτελέστηκαν από το DBMS
- ✦ **Ενέργειες:**
 - ✦ BOT/EOT (Begin/End Of Transaction)
 - ✦ INS/UPD/DEL (ήτοι, write) ένα record
 - ✦ COMMIT/ABORT μια συναλλαγή
 - ✦ UNDO/REDO μια ενέργεια εγγραφής (write)

Log Record τύπου “Write”

- LSN
- Transaction ID (TID)
- Σελίδα που κάνουμε update
- Offset στην εν λόγω σελίδα
- Μήκος σε bytes που αλλάζουμε
- Παλιά τιμή
- Νέα τιμή

**T1: UPDATE EMP
SET ID = 30
WHERE ID = 3**



Log Entry: LSN12,T1,PAGE32,0xFFF32,8,3,30

Βασικές έννοιες για το Log

- Το log ως αρχείο είναι ένα σύνολο από εγγραφές (**log records**)
- Κάθε log record χαρακτηρίζεται μονοσήμαντα από ένα **Log Sequence Number (LSN)**.
- Το σύστημα εκδίδει αυτόματα το $\max(\text{LSN})+1$ για κάθε νέα log record

Write Ahead Log

Προτού γράψεις οτιδήποτε στη ΒΔ, καταχώρησε την αντίστοιχη εγγραφή στο log

- Για να γράψεις μια updated σελίδα από το buffer πίσω στο δίσκο, πρέπει στο log (στο δίσκο) να έχουν περαστεί οι παλιές τιμές για τα records της
- Για να κάνεις commit μια συναλλαγή πρέπει στο log (στο δίσκο) να έχουν γραφτεί όλες οι σχετικές log records

Checkpoints – Σημεία ελέγχου

- ✦ Περιοδικά, το σύστημα κάνει τις εξής ενέργειες:
 - ✦ Σταματά κάθε άλλη ενέργεια
 - ✦ Καταγράφει το σύνολο των ενεργών συναλλαγών
 - ✦ Γράφει (**flush**) όλους τους buffers με log records, στο δίσκο
 - ✦ Γράφει (**flush**) όλους τους buffers με records της ΒΔ, στο δίσκο
 - ✦ Γράφει στο log μια εγγραφή **CHK** (checkpoint)

Ανάνηψη αν έχουμε WAL

- Έστω ότι το σύστημα αποτυγχάνει και πρέπει να το επαναφέρουμε (ήτοι, να επαναφέρουμε τη ΒΔ σε συνεπή μορφή).
- Η διαδικασία αυτή ονομάζεται **ανάνηψη** (**recovery**) ή **ανάκαμψη** ή **επαναφορά**
- Αν έχουμε χρησιμοποιήσει **WAL** κατά την κανονική λειτουργία του συστήματος, η ανάνηψη έχει **3 φάσεις**:
 1. Ανάλυση
 2. UNDO
 3. REDO