

# Basi di Dati

prof. Letizia Tanca

## Le transazioni e il database server, cenni sui nuovi sistemi per Big Data

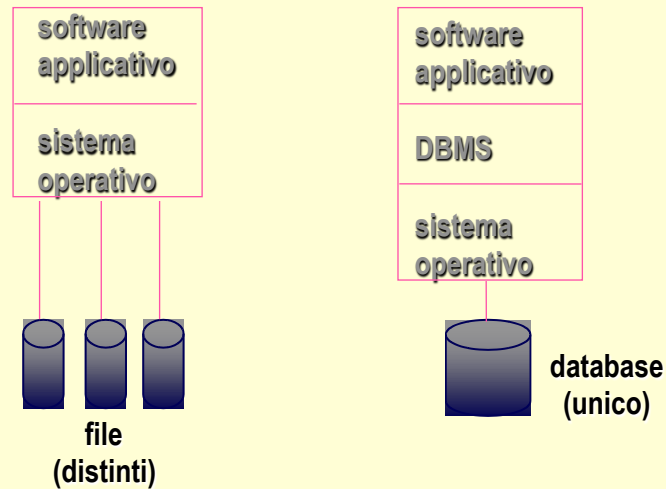
*(lucidi parzialmente tratti dal libro:  
Atzeni, Ceri, Paraboschi, Torlone "Introduzione alle Basi di  
dati", Mc Graw Hill Italia)*

## SGBD (DBMS) e file systems

Un **SGBD** (Data Base Management System =  
DBMS):

- permette di accedere in modo efficiente ai dati con una **granularità più fine che il file system**
- permette di accedere in modo diretto ai dati **basandosi sulle loro proprietà**
- effettua il controllo della concorrenza **alla granularità del singolo record**
- realizza meccanismi sofisticati per il **controllo dell'affidabilità**
- realizza meccanismi di **controllo della privacy**
- realizza **l'atomicità delle transazioni**

## File system e DBMS



Basi di Dati

3

## Una Base di Dati è un sistema OLTP

### On Line Transaction Processing:

Elaborazione di transazioni, che realizzano i processi operativi dell'azienda-ente

- Operazioni spesso predefinite e relativamente semplici
- Ogni operazione coinvolge "pochi" dati
- Dati di dettaglio, aggiornati
- Le proprietà "acide" (Atomicità, Correttezza, Isolamento, Durabilità) delle transazioni sono essenziali

Le dimensioni delle basi di dati sono dell'ordine dei **gbyte**

La principale metrica di prestazione è il *throughput delle transazioni* (n. di transazioni al secondo)

Basi di Dati

4

## Sistemi OLAP

### **On Line Analytical Processing:**

Elaborazione di operazioni per il supporto alle decisioni  
(*data warehouse*)

- Operazioni complesse e casuali
- Ogni operazione può coinvolgere molti dati
- Dati aggregati, storici, anche non attualissimi
- Le proprietà "acide" non sono rilevanti, perché le operazioni sono *di sola lettura*

Le **dimensioni** del warehouse raggiungono facilmente i **terabyte**

Le prestazioni considerate sono il **throughput delle interrogazioni e il loro tempo di risposta**

## Transazione

- Una **transazione:**
  - Rappresenta la tipica unità di lavoro elementare di un Database Server
  - Identifica una unità di lavoro svolta da una applicazione

## Transazione

- I DBMS classici (anche distribuiti) sono **sistemi transazionali**: mettono a disposizione un meccanismo per la definizione e l'esecuzione di transazioni
- Nell'esecuzione di una transazione devono essere garantite le proprietà **ACIDE**
- Sono stati proposti nuovi DBMS che **non sono sistemi transazionali**

## Transazione

- *Unità elementare di lavoro effettuato da una applicazione, con proprietà fondamentali riguardanti la correttezza, il controllo di concorrenza e la robustezza.*
- Ogni transazione è incapsulata tra due comandi:
  - begin transaction (bot)
  - end transaction (eot)

## Transazione

- In una transazione, necessariamente viene eseguito uno e uno solo dei due comandi seguenti:
  - `commit work` (`commit`)
  - `rollback work` (`abort`)
- Un sistema transazionale mette a disposizione delle applicazioni *meccanismi di definizione ed esecuzione delle transazioni*

## Esempio astratto di transazione

```
begin transaction  
x := x - 10  
y := y + 10  
commit work  
end transaction
```

### **Transazione ben formata:**

Una transazione che comincia con **begin transaction**, finisce con **end transaction**, nella cui esecuzione solo uno dei due comandi **commit work** o **rollback work** viene eseguito, e tale che, dopo l'esecuzione di uno dei due comandi **commit work** o **rollback work**, *nessuna altra operazione di aggiornamento sul database venga eseguita.*

## Esempio più complesso (Atzeni)

```
start transaction; (opzionale)
update ContoCorrente
set Saldo = Saldo + 10 where NumConto = 12202;
update ContoCorrente
set Saldo = Saldo - 10 where NumConto = 42177;
select Saldo into A
from ContoCorrente
where NumConto = 42177;
if (A>=0) then commit work
else rollback work;
```

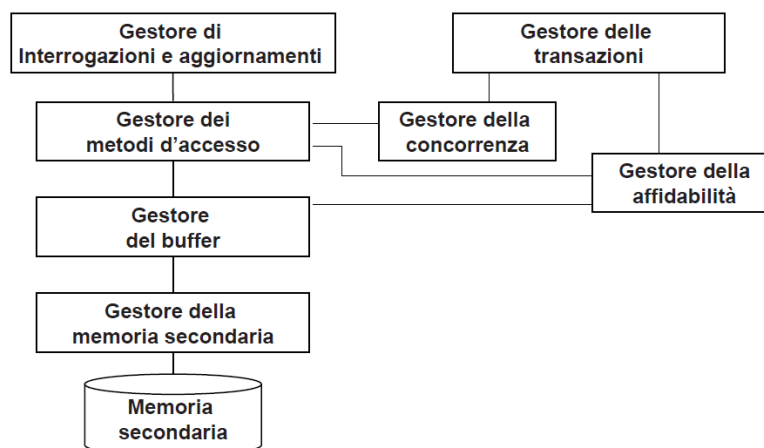
## Proprietà ACIDe

- **Atomicità:** Una transazione è una unità indivisibile di esecuzione
- **Consistenza:** l' esecuzione di una transazione non deve violare i vincoli di integrità definiti sulla base di dati
- **Isolamento:** l' esecuzione di una transazione non è influenzata dalla esecuzione di altre transazioni concorrenti
- **Persistenza (Durability):** gli effetti di una transazione andata a buon fine devono essere permanenti

## Componenti di un database server transazionale

- **Ottimizzatore** - seleziona la strategia d'accesso ai dati
- **Access Methods Manager** - esegue la strategia
  - RSS (Relational Storage System)
  - OM (Object Manager)
- **Buffer Manager** - gestisce gli accessi alle pagine
- **Gestore di affidabilità** - gestisce i malfunzionamenti
- **Controllo di concorrenza** - gestisce le interferenze dovute alla concorrenza nell'accesso ai dati


## Gestore degli accessi e gestore delle transazioni (Atzeni)



## Architettura e modello di esecuzione **single tier**

### *Mainframe + terminali intelligenti*

- **Pro:** Facilmente gestibile da un amministratore centrale
- **Contro:** Interfaccia grafica richiede potenza di calcolo, sottratta alla gestione del BD



15

## Architetture distribuite

- Quasi tutte le basi di dati hanno **un'architettura distribuita** (caratterizzata dalla presenza di una rete)
- **Architettura client-server**
  - E' la più semplice e diffusa
  - **Server:** elaboratore per la gestione dei dati
  - **Client:** elaboratore per la gestione dell'applicazione e del dialogo con l'utente
  - **Rete:** collega i client con il server
- **Architettura distribuita**
  - Almeno **DUE server** che, oltre a lavorare autonomamente, in alcuni casi devono **interagire**

Basi di Dati

16



## Architettura client-server (1)


- Più in generale, modello di interazione *tra processi software* in cui i processi si dividono in Client e Server
- **Processi Client**
  - Richiedono i servizi
  - Dedicati a interagire con l'utente finale
  - Ruolo attivo: genera richieste
- **Processi Server**
  - Offrono i servizi
  - Ruolo reattivo: si limita a rispondere alle richieste dei diversi client
- **Nota** Si parla di *processi*, generalmente i processi client e server risiedono su macchine diverse, collegate via rete
- L'interazione fra client e server richiede una *interfaccia di servizi*: elenco dei servizi messi a disposizione dal server

Basi di Dati

17

## Architettura client-server (2)

- Un processo client può richiedere alcuni (pochi) servizi a vari processi server (se sono più di uno è una architettura distribuita)
- Ogni processo server risponde a (molte) richieste da parte di molti processi client gestendo in modo opportuno le relative transazioni



18

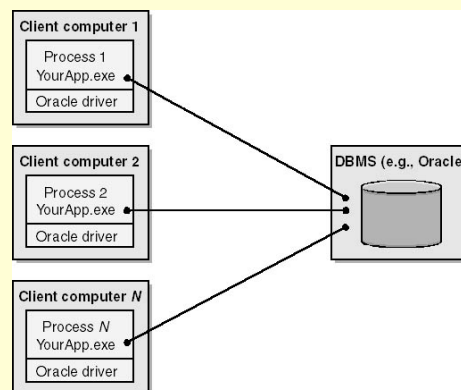
## Motivi uso Client-Server

- Le funzioni di client e server sono ben definite
  - C'è una corrispondenza con gli utenti
    - **Programmatore applicativo**: ha la responsabilità di gestire il software relativo al client
    - **Amministratore**: Deve organizzare la base dati sul server per garantire prestazioni ottimali a tutti i client
- Diverse esigenze di hardware
  - Il **client** è un elaboratore adatto alla interazione con l'utente
    - Strumenti di produttività
    - Applicazioni "amichevoli" che accedono alla base dati
    - Grafica: non possiamo più usare terminali non intelligenti
  - Il **server** è dimensionato in base ai servizi che deve offrire e al carico transazionale (grande memoria centrale, grande memoria di massa, ...)

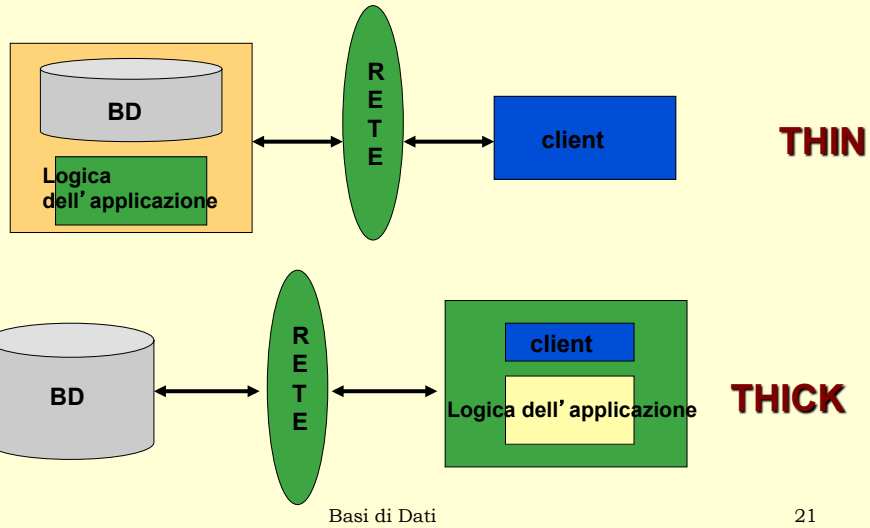
## Architettura a 2 livelli

*(two tier)*

- Il client ha funzioni solo di interfaccia o anche di gestione dell'applicazione
- Il server ha funzione di gestione dei dati
- Più diffusa l'architettura *thin client*




## Thin client e Thick client



21

## Architetture three tier



Basi di Dati

22

## NoSQL databases

- Ci si è accorti che non sempre è necessario che un sistema di gestione dei dati garantisca tutte le caratteristiche transazionali
- I DBMS che non sono transazionali vengono comunemente chiamati NoSQL
- Questo in realtà non è corretto perché il fatto che un sistema sia relazionale (e adoperi il linguaggio SQL) e il fatto che sia transazionale sono caratteristiche indipendenti

Basi di Dati

23

## BIG DATA e Cloud

### DATA CLOUDS:

- **SERVIZI di storage on demand**, affidabili, offerti su Internet con facile accesso a una quantità virtualmente infinita di risorse di memorizzazione, calcolo e rete

### CLASSIFICAZIONE DEI POSSIBILI METODI DI STORAGE:

- **Centralizzati o distribuiti, transazionali, basati su un modello tradizionale (es. relazionale)** restano i più utilizzati per le applicazioni gestionali classiche (sistemi informativi aziendali etc.)
- **Federati e multi-database** per e in generale aziende e realtà che si associano e condividono i loro dati su Internet
- **Cloud databases** per supportare BIG DATA mediante tecniche di load sharing e data partitioning

## BIG DATA e Cloud

I database NoSQL:

- prevedono schemi flessibili
- scalano orizzontalmente
- NON supportano tutte le proprietà acide
  - Gli aggiornamenti vengono effettuati in modo asincrono (NON VI E' supporto esplicito della concorrenza)
  - Inconsistenze potenziali nei dati vengono risolte direttamente dagli utenti

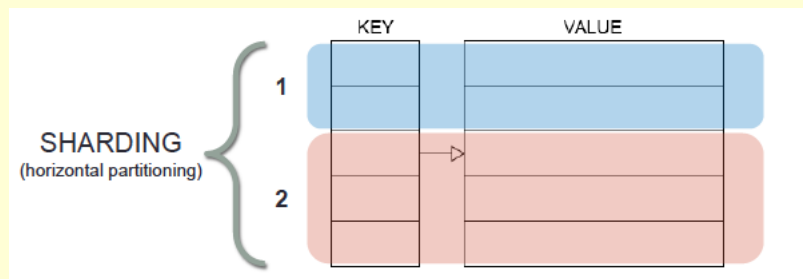
## I modelli dei dati

3 categorie:

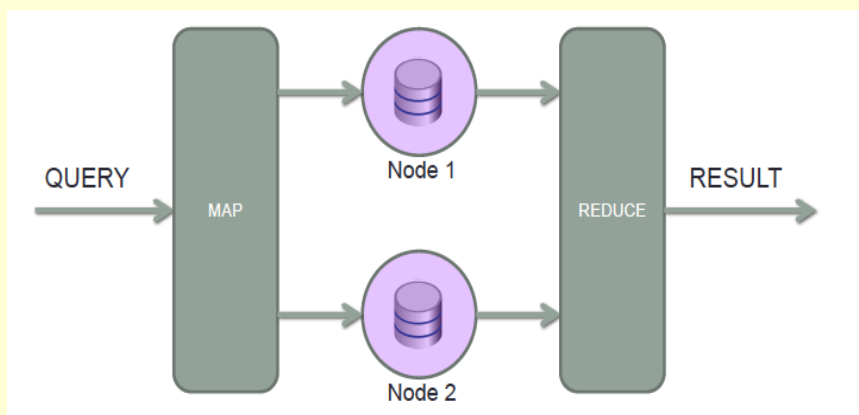
- Key -Value
- Document -based
- Column -family
- Basati su grafi

## Key –Value

- Modello di riferimenti classico per I sistemi NoSQL
- Chiave: singola o composta (es.id e data)
- Valore: blob non interrogabile
- Query: ricerca per chiave
- No schema ( un catalogo)
- Standard API : get / put / delete

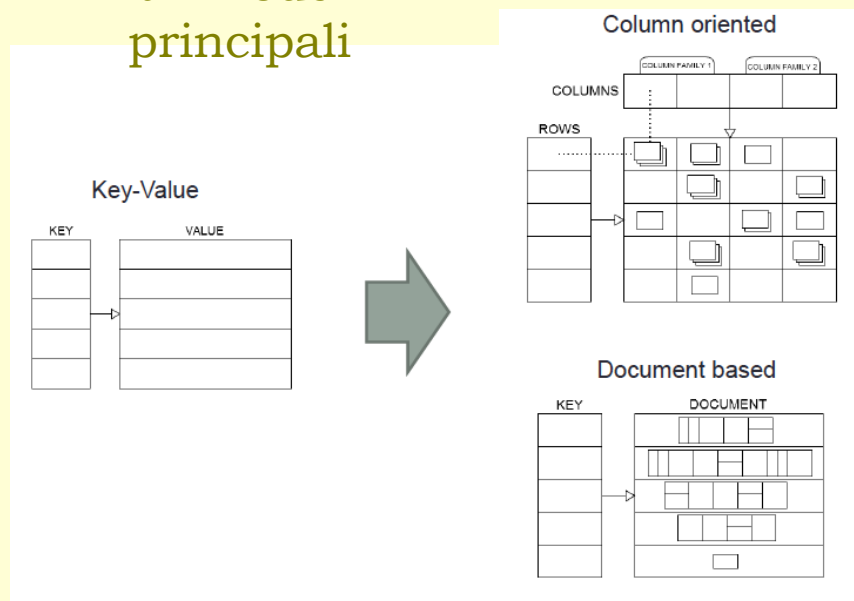


## Map Reduce



28

## Altri modelli principali



## Il CAP theorem

- Un sistema di gestione di dati condiviso in rete (**cloud, networked shared-data system**) verifica al più due delle seguenti proprietà:
  - consistenza (C)
  - alta disponibilità (availability → A)
  - tolleranza alle partizioni della rete (Partitions → P)
- Da ciò si capisce perché nelle applicazioni più tradizionali, come per esempio quelle bancarie o contabili, o le prenotazioni etc. questi sistemi possano essere disastrosi
- **Applicazioni interessanti:**
  - Raccolta dati provenienti da sensori (append-only)
  - Datasets aggiornati poco frequentemente in generale
  - OLAP

Distributed I.S. 30

## BIBLIOGRAFIA

### LIBRO :

Tamer Ötzsu M., Valduriez P. – *Principles of Distributed Database Systems: 3rd ed.* - Springer, 2011

### ALTRO MATERIALE DI RIFERIMENTO

•Abadi Daniel J. - *Data Management in the Cloud: Limitations and Opportunities* - IEEE Data Engineering Bulletin, Vol. 32 No. 1, March 2009

<http://sites.computer.org/debull/A09mar/A09MAR-CD.pdf#page=5>

•Dean J., Ghemawhat S. – *MapReduce: A Flexible Data Processing Tool* - CACM, Vol.53, n. 1, pp. 72-77, 2010

•Foster I., Yong Zhao, Raicu I., Lu S - *Cloud Computing and Grid Computing 360-Degree Compared* - Grid Computing Environments Workshop 2008, pp. 1-10, 2008

<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4738445>

Distributed I.S. 31