INTRODUZIONE AI DATABASE RELAZIONALI

Base dati e tecniche di utilizzo in ambito scientifico – parte 1

Opus Facere – INAF Bologna

nicastro@iasfbo.inaf.it

http://ross.iasfbo.inaf.it/opusfacere/

Database: quando

- Grande quantità di dati
- Accessibilità
- Affidabilità

Database: come

- Sul proprio PC
- Via WEB
- Da applicativo

Database: quale

MariaDB

- Linguaggio: SQL
- Relazionale
- Locale e remoto

Proposte di utilizzo

- Dimostrativi
- Educativi
- Scientifici

Dati: cosa sono

- **Informazione**: notizia, o elemento che consente di avere conoscenza più o meno esatta di fatti, situazioni e modi d'essere.
- **Dato**: elementi di informazione costituiti da simboli che devono essere elaborati.

Un **Sistema Informativo** (**SI**) è una componente di un'organizzazione* il cui scopo è quello di **gestire le informazioni** utili ad i fini dell'organizzazione stessa.

L'esistenza di un **Sistema Informativo** è indipendente dalla sua automatizzazione.

* Azienda, Ufficio, Ente, Scuola, Università, ecc.

Sistema informativo

- La porzione **automatizzata** di un sistema informativo prende il nome di **Sistema Informatico**.

- All'interno di un sistema informatico, le informazioni sono rappresentate da **dati** …

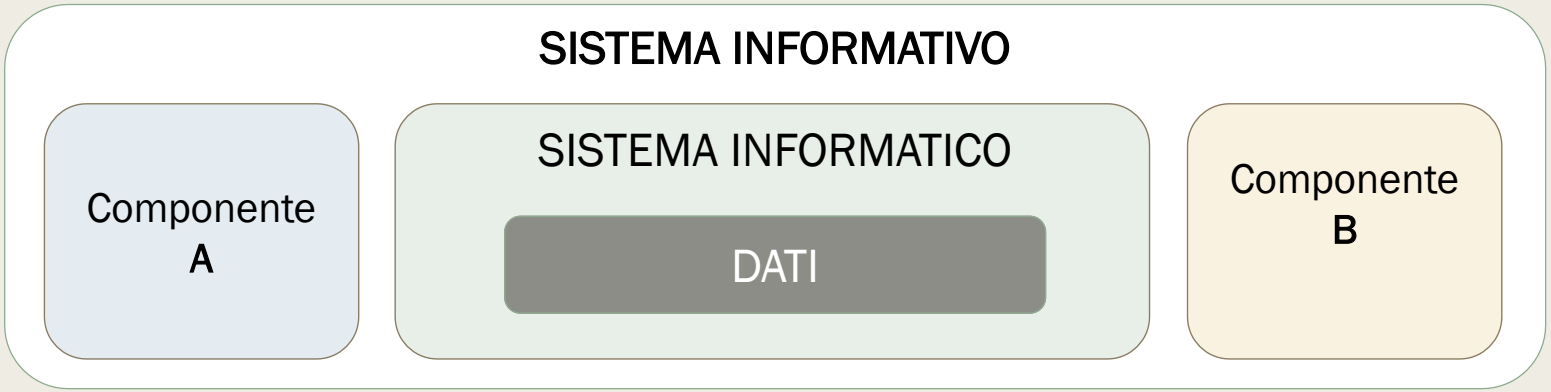

Dati: gestione

Gran parte dei sistemi informatici hanno necessità di gestire **dati in maniera persistente.**

Persistente → Dati memorizzati su memoria secondaria

APPROCCI di GESTIONE

- **Convenzionale** (basato su *files*)
- **Strutturato** (basato su software di gestione dei dati)

Dati: gestione con file

Gran parte dei sistemi informatici hanno necessità di gestire **dati in maniera persistente.**

- Nessuna chiara distinzione tra **dati ed applicazioni**.
- L'applicazione contiene al suo interno la **logica di gestione e memorizzazione** dei dati stessi (es. formato dei dati).
- Il **Sistema Operativo** offre le primitive di base per l'accesso ai files ed i meccanismi di sicurezza del **file-system**.

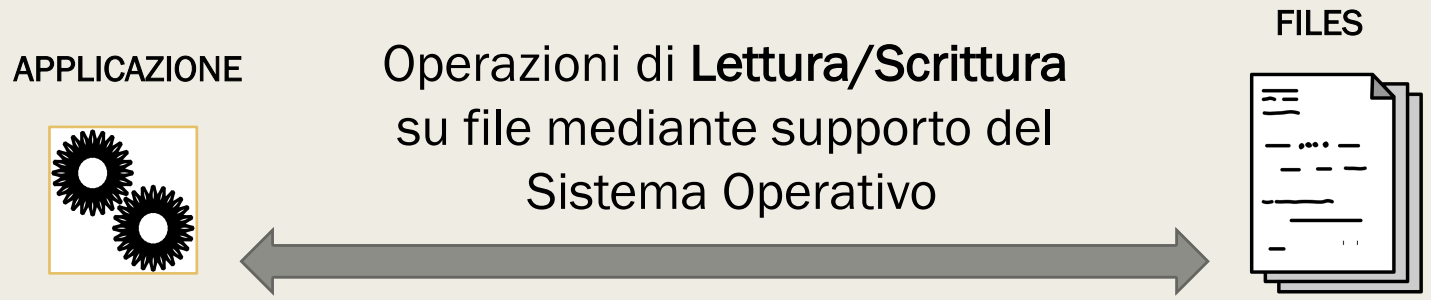

Dati: gestione con file

PROBLEMA 1: Gestione di **grandi quantità di dati**?

Qualche esempio “estremo” (ma neanche tanto):

AMAZON

Oltre 200 Terabyte di dati (istantanei)
244 Milioni di clienti iscritti
1.1 Miliardi di ordini all’anno

AT&T

> 400 Terabyte di dati
> 400 Milioni di clienti
> 2 Trilioni di record relativi a chiamate

Ovvi problemi di **scalabilità** ed **efficienza** …

Dati: gestione con file

PROBLEMA 2: **Condivisione** ed **accesso** concorrente?

In molti scenari pratici, i dati devono essere a disposizione di una moltitudine di utenti/applicazioni per accessi concorrenti.

Es. Dati del personale strutturato universitario

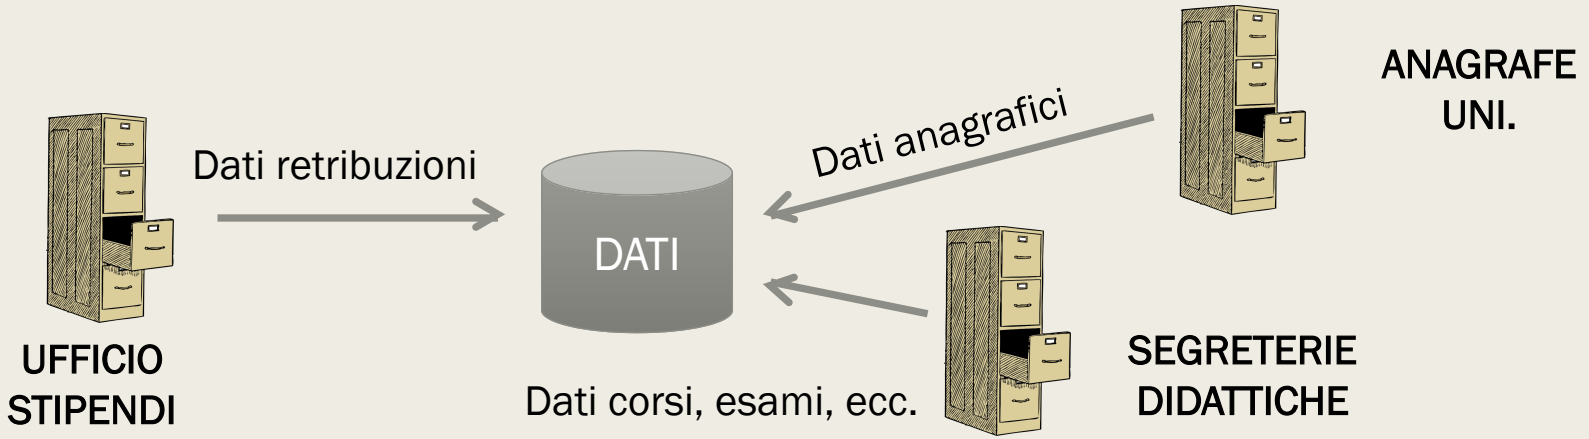

Dati: gestione con file

PROBLEMA 2: **Condivisione** ed **accesso** concorrente?

LIMITAZIONI

- Accesso a file condivisi avviene attraverso le politiche di accesso del file-system → Lock a livello di file, **bassa granularità di concorrenza**, prestazioni limitate!
- Applicazioni diverse devono conoscere l'esatta collocazione e formato dei dati → **Aggiornamento del formato dei dati**?
- In alternativa: replica dei dati presso i vari sistemi/utenti che ne fanno utilizzo → **Consistenza delle repliche**?

Dati: gestione

Gran parte dei sistemi informatici hanno necessità di gestire **dati in maniera persistente.**

Persistente → Dati memorizzati su memoria secondaria

APPROCCI di GESTIONE

- **Convenzionale** (basato su files)
- **Strutturato** (basato su software di gestione dei dati)

Introduzione ai Database Management System (DBMS)

Un **DBMS** è un sistema software che è in grado di gestire collezioni di dati *grandi, condivise e persistenti, in maniera efficiente e sicura.*

(ALCUNE) FUNZIONALITA':

- Creazione di una base di dati e memorizzazione su memoria secondaria
- Accesso in lettura/scrittura ad i dati
- Condivisione di dati tra diversi utenti/applicazioni
- Protezione dei dati da accessi non autorizzati
- Reliability dei dati in caso di guasti (hardware/software)
- …

Un database è una collezione di dati gestita da un DBMS!

DBMS: caratteristiche

Separazione **Dati** – **Applicazioni** con DBMS

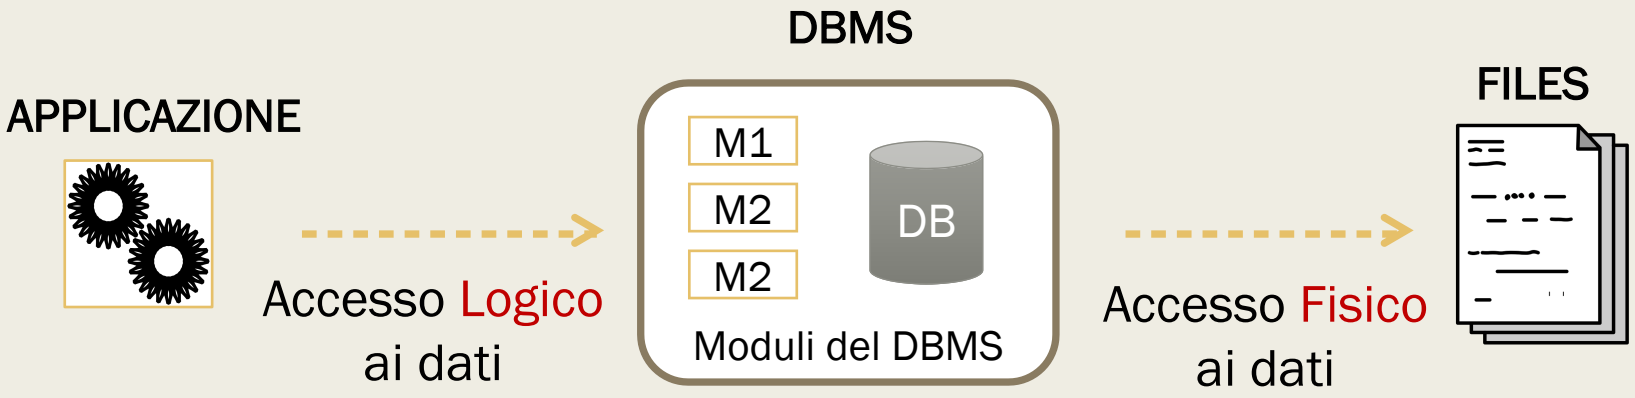

- Tramite i DBMS, è possibile implementare un **paradigma** di **separazione di dati ed applicazioni** …
- Le applicazioni non necessitano di conoscere la struttura fisica dei dati (es. come e dove sono memorizzati su disco) ma **solo la struttura logica** (cosa rappresentano).

DBMS: caratteristiche

Separazione **Dati** – **Applicazioni** con DBMS

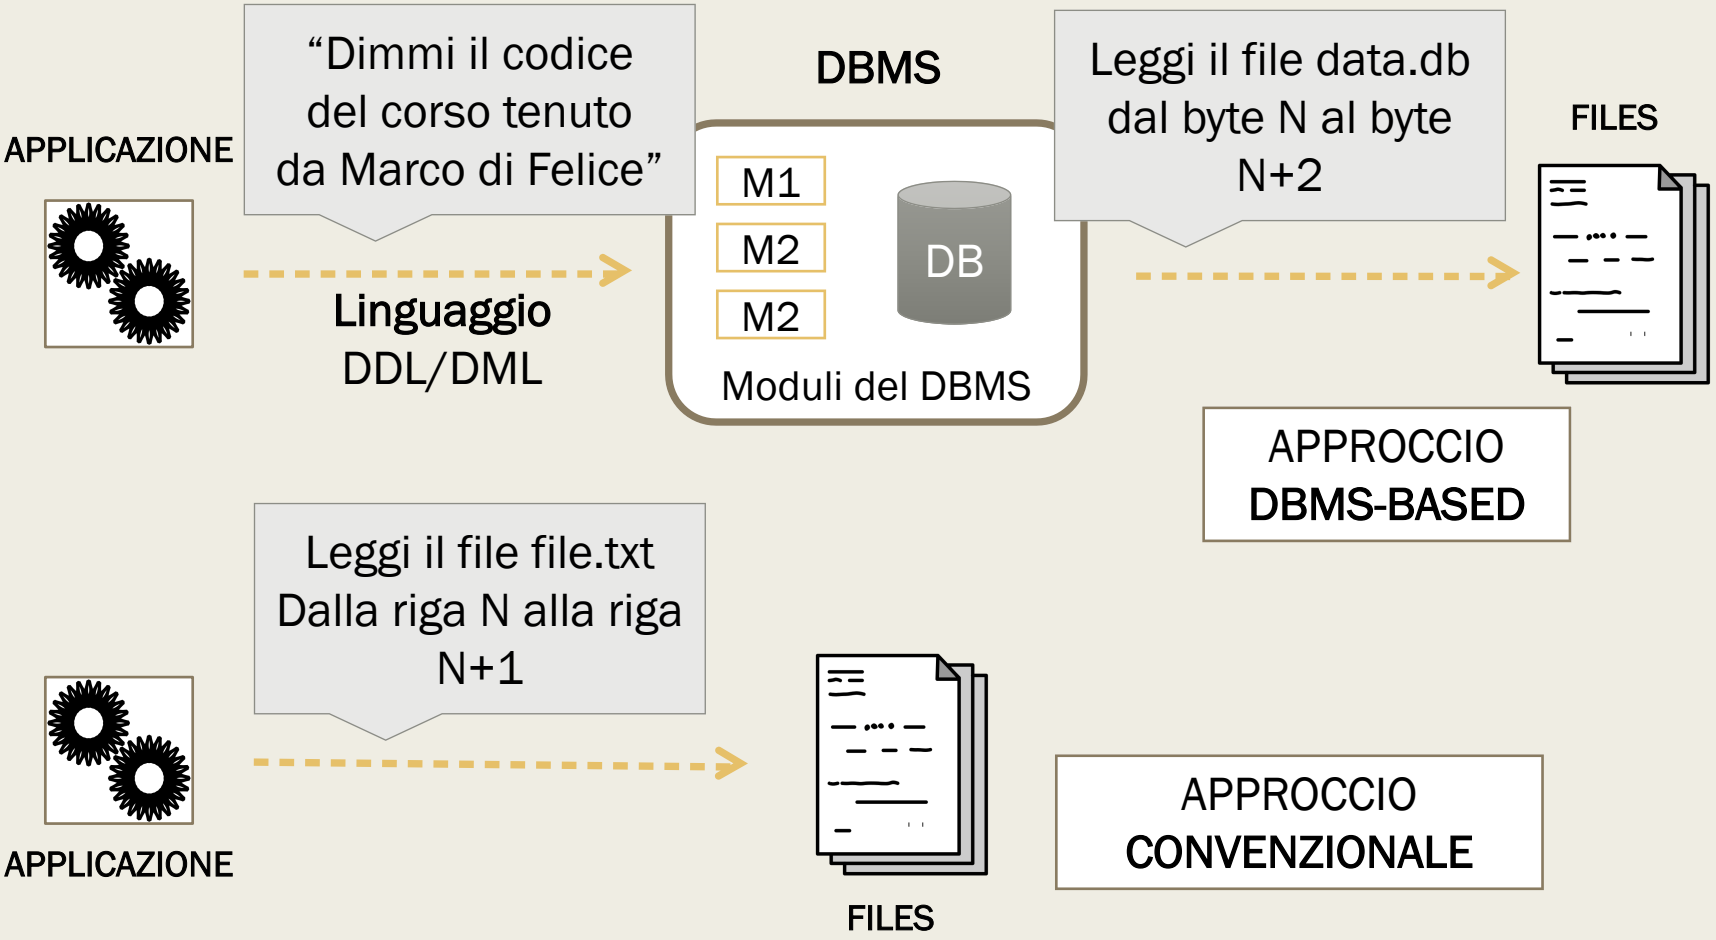

DBMS: componenti

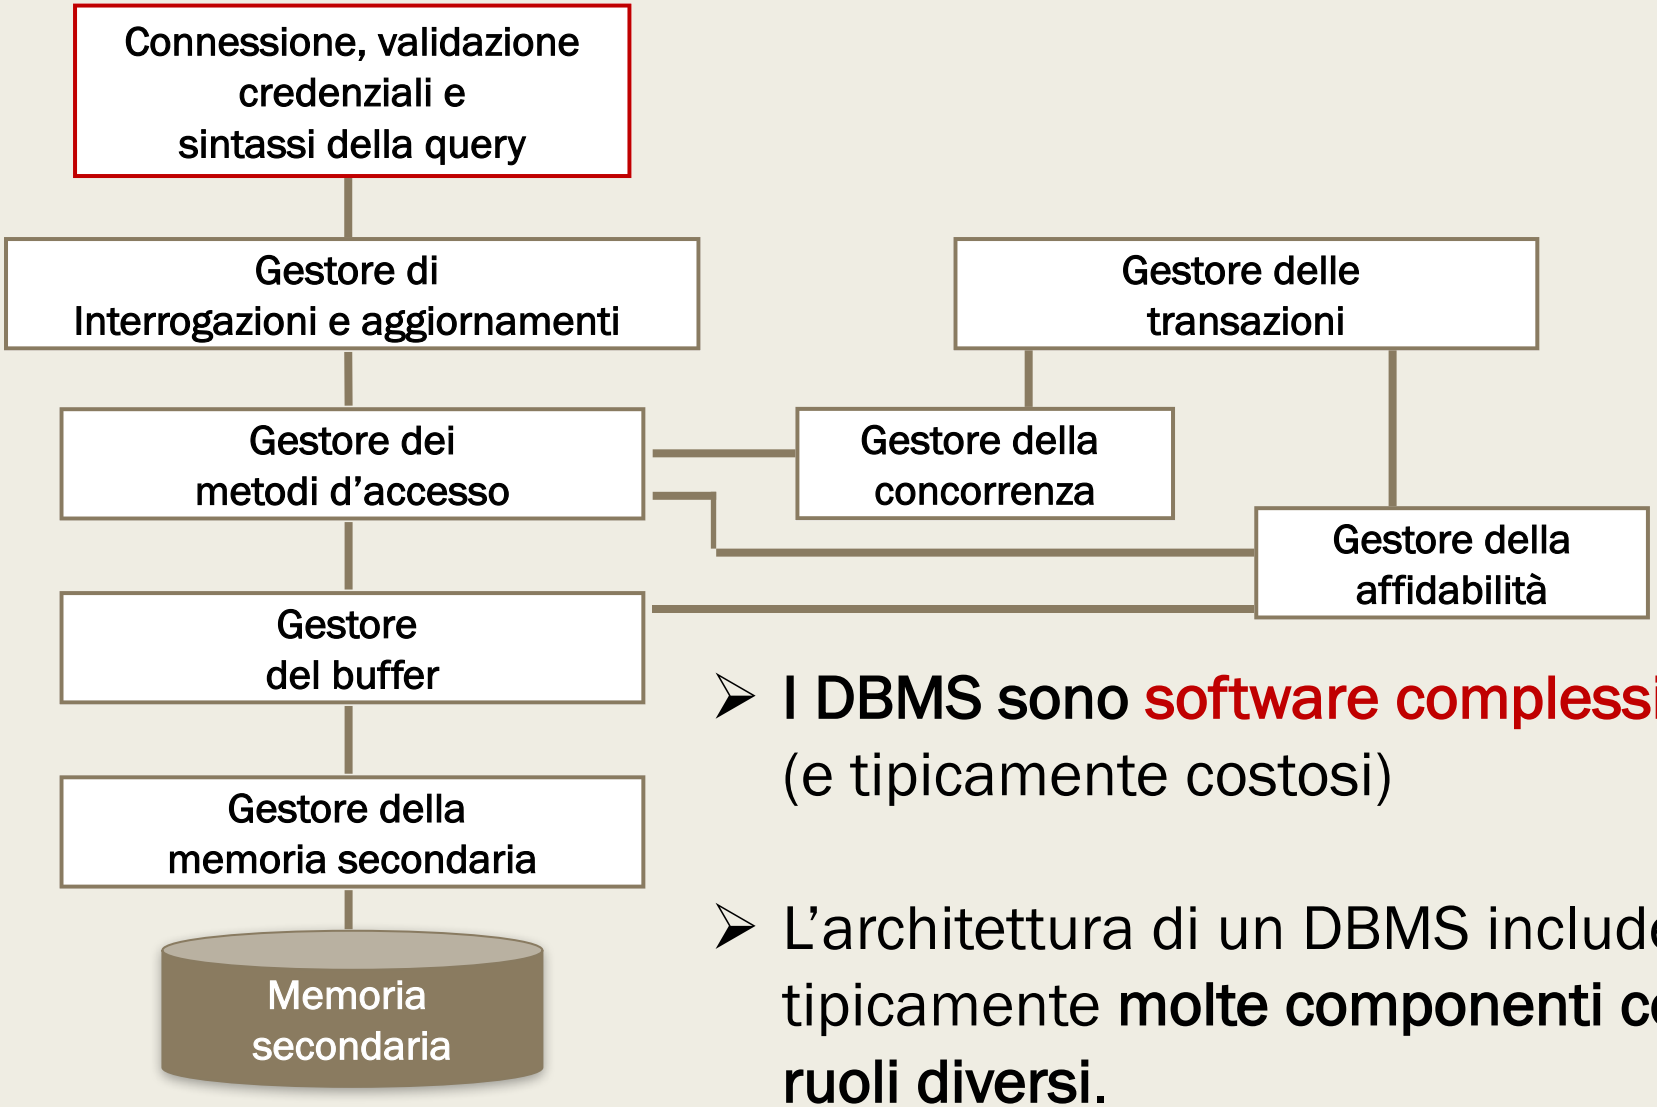

- I DBMS sono **software complessi** (e tipicamente costosi)
- L'architettura di un DBMS include tipicamente **molte componenti con ruoli diversi.**

DBMS: componenti

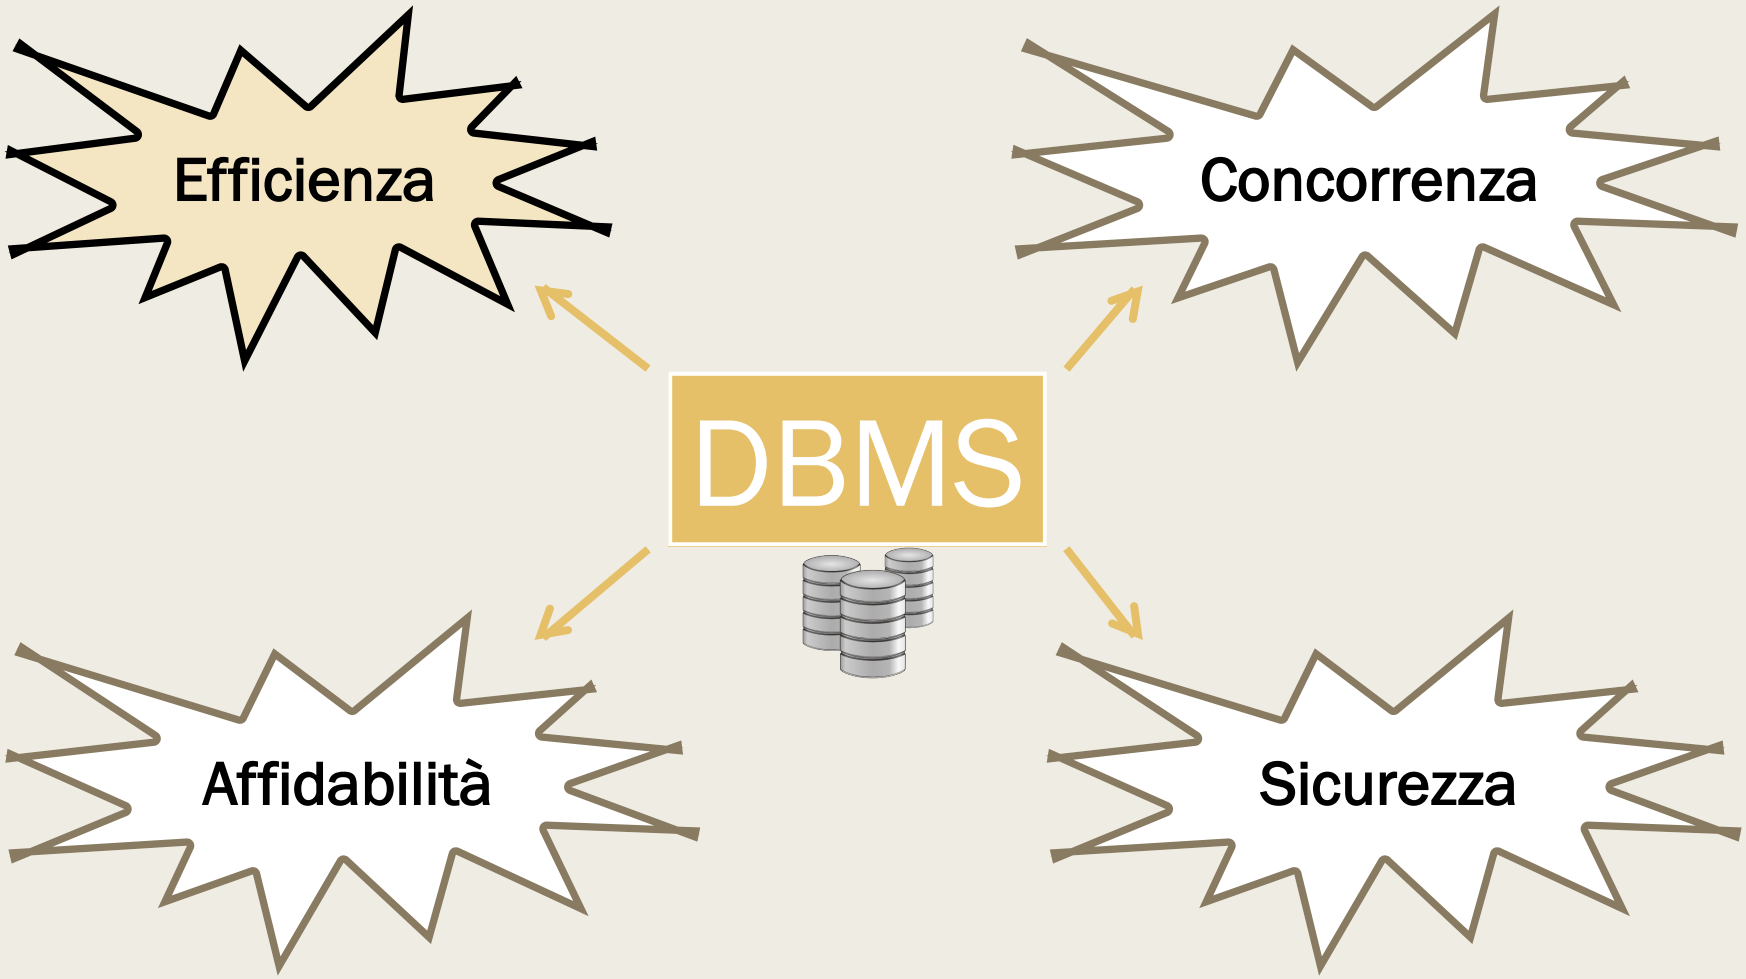

DBMS: efficienza

Efficienza di un DBMS nella gestione dei dati …

- I DBMS forniscono adeguate **strutture dati** per organizzare i dati all'interno dei file, e per supportare le operazioni di ricerca/aggiornamento.
- In genere, parliamo di **strutture dati ad albero o tabelle *hash*.**

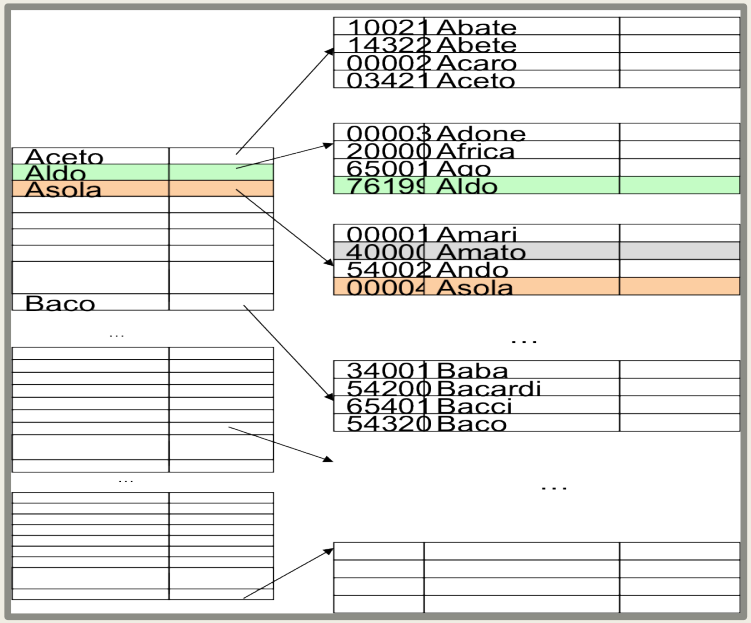

DBMS: efficienza

Indice → struttura che contiene informazioni sulla posizione di memorizzazione delle *tuple* (righe, sezioni) sulla base del valore del campo **chiave**.

D. A che serve un indice?

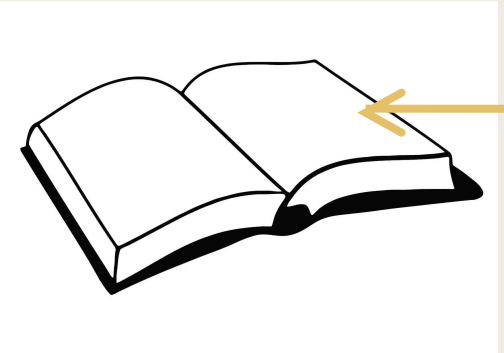

ACCESSO DIRETTO

Indice	
Introduzione	1
Capitolo 1	20
Capitolo 2	40
Capitolo 3	60
Conclusioni	65

DBMS: efficienza

Efficienza di un DBMS nella gestione dei dati …

B-tree

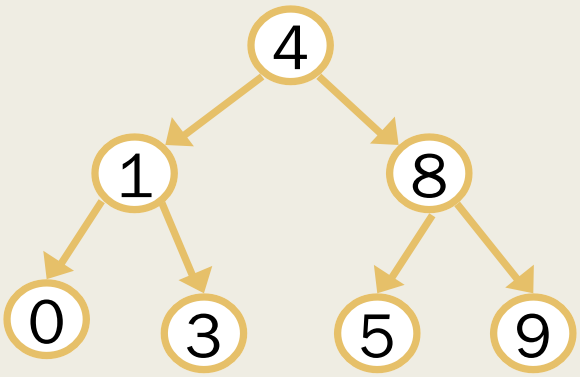

- **Ricerca** → O(log(N))
- **Inserimento** → O(log(N))
- **Cancellazione** → O(log(N))

Le strutture ad albero dinamiche di tipo B (B-tree) e B+(B+-tree) sono quelle più frequentemente utilizzate per la realizzazione di indici.

DBMS: efficienza

Ottimizzazione di operazioni di ricerca (**interrogazioni**)

La query SQL viene tradotta in una sequenza di operatori algebrici per l'accesso ai dati (algebra relazionale).

$$\Pi_{A_1 A_2 .. A_n}(\sigma_{Condizione}(T_1 \triangleright\triangleleft T_2 \triangleright\triangleleft ... \triangleright\triangleleft T_m))$$

DBMS: componenti

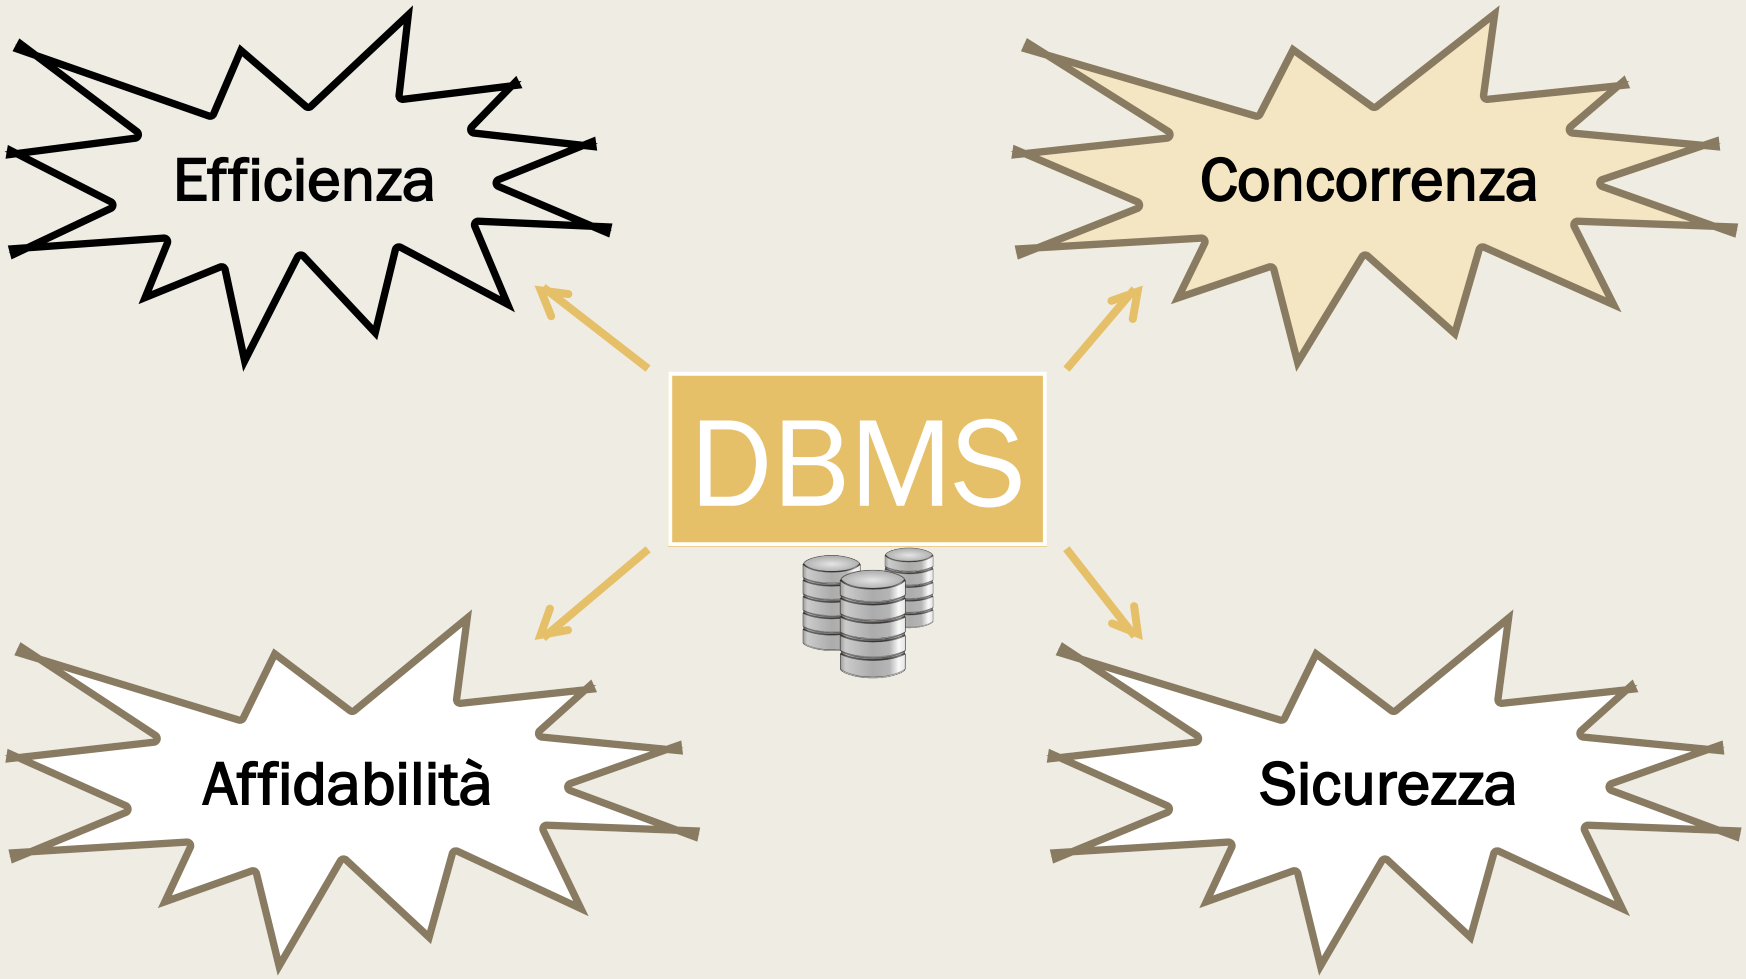

DBMS: concorrenza – 1

- In molti sistemi è fondamentale **gestire operazioni concorrenti** di accesso ai dati …

Più di 8 milioni di pagamenti processati ogni giorno

La maggior parte dei DBMS forniscono un **livello di granularità di *locking*** più fine di quello convenzionale (a livello di tabella, pagina, o singola entry).

DBMS: concorrenza – 2

- Al tempo stesso, un DBMS deve garantire il fatto che **accessi da parte di applicazioni diverse non interferiscano tra loro**, lasciando il sistema in uno stato inconsistente …

Es. Sistema informativo dei conti bancari

- 2 richieste da gestire al tempo **t**:
  - Prelievo di 100 euro dal conto X
  - Prelievo di 80 euro dal conto X
- Saldo del conto X al tempo **t**: 120 euro

DBMS: concorrenza – 3

ESEMPIO di ESECUZIONE (**non corretta**!)

OP1
Leggi X
Calcola X – 100
Scrivi X

OP2
Leggi X
Calcola X – 80
Scrivi X

Schedula:
OP1: Leggi X
OP2: Leggi X
OP1: Calcola X – 100
OP2: Calcola X – 80
OP1: Scrivi X
OP2: Scrivi X

Valore X:
120
120
120
120
20
40 (????)

Per prevenire tali situazioni, i DBMS implementano **algoritmi di controllo della concorrenza** che operazioni sui dati (**transazioni**) eseguite in concorrenza producano lo stesso risultato di un'esecuzione seriale.

DBMS: concorrenza – 4

Lock Manager → componente del DBMS responsabile di gestire i lock alle risorse del DB, e di rispondere alle richieste delle transazioni.

OP1
Lock(x)
Leggi X
Calcola X – 100
Scrivi X
Unlock(x)

OP2
Lock(x)
Leggi X
Calcola X – 80
Scrivi X
Unlock(x)

- Utilizzo di **lock** in lettura/scrittura per accesso a risorse condivise (dati).
- Algoritmi (**2FL, S2FL**) per gestire ordine di acquisizione dei lock.

DBMS: componenti

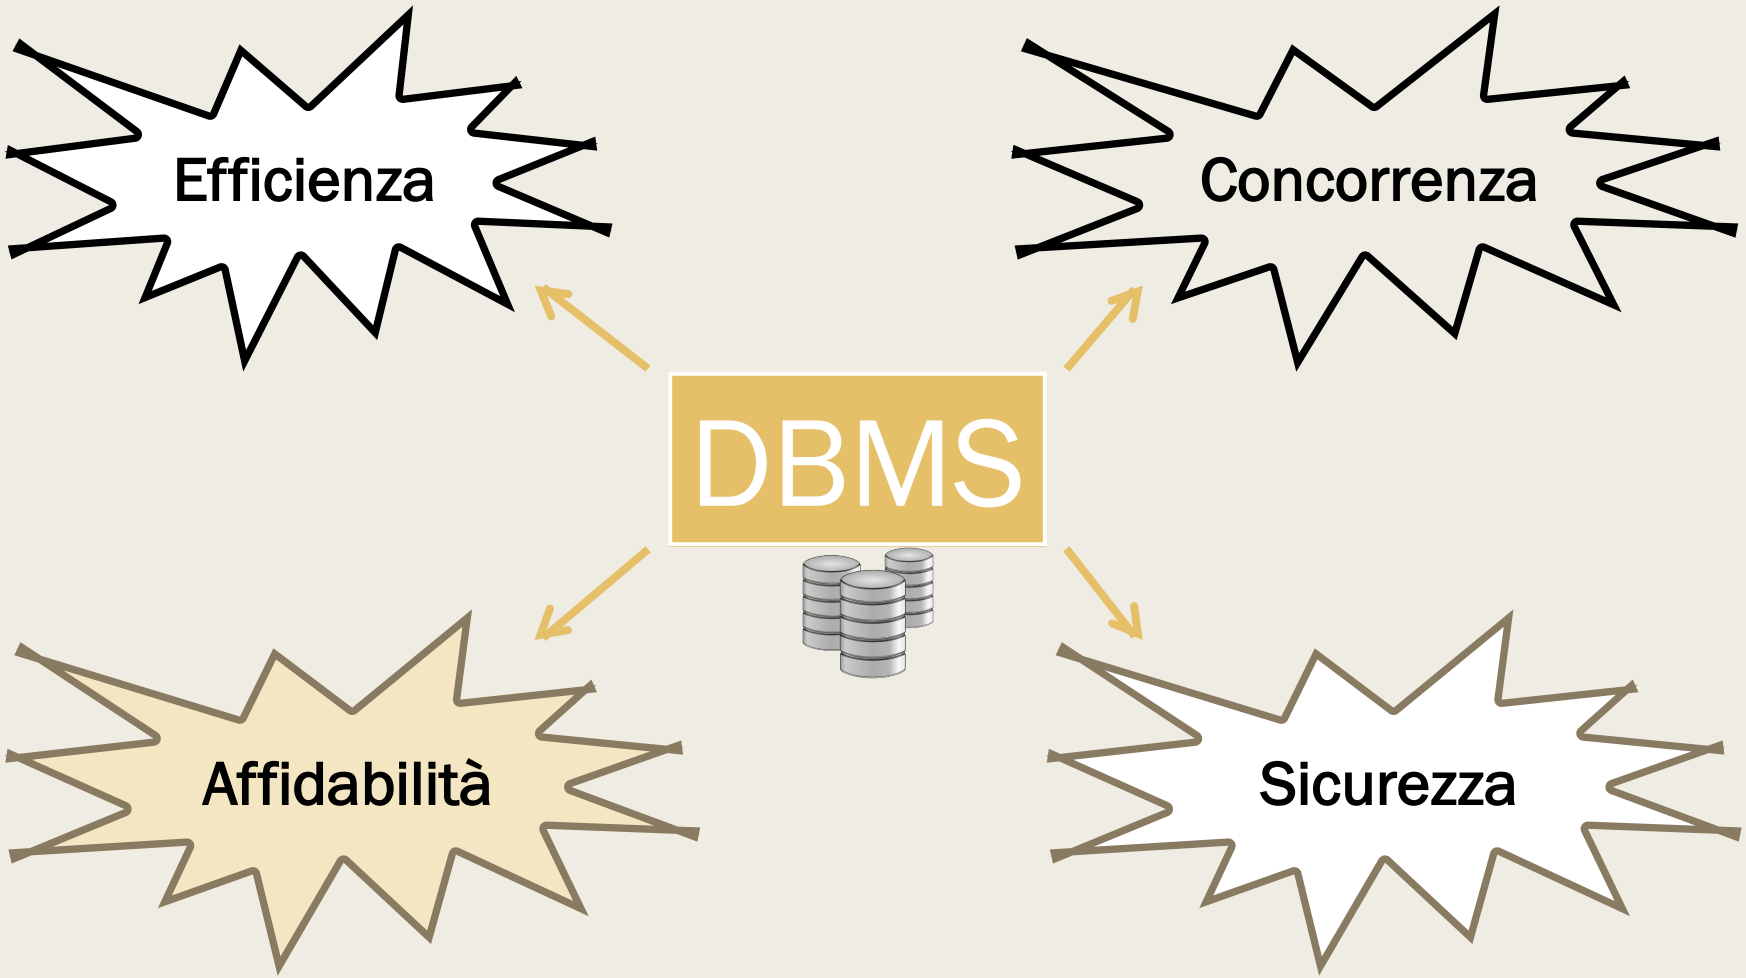

DBMS: affidabilità; roll-back – 1

- Alcune operazioni sui dati sono **particolarmente delicate**, e devono essere gestite in maniera opportuna, secondo la regola del **tutto o niente.**

Es. Trasferimento di denaro (100 €) dal conto X al conto Y.

Op1: X = X – 100

Op2: Y = Y + 100

DBMS: affidabilità; roll-back – 2

- Alcune operazioni sui dati sono **particolarmente delicate**, e devono essere gestite in maniera opportuna, secondo la regola del **tutto o niente**.

- Per questo, i DBMS devono fornire appositi strumenti per **annullare operazioni non completate** e fare **roll-back** dello stato del sistema …

DBMS: affidabilità; persistenza – 1

In molti casi i DBMS mettono a disposizione appositi **strumenti ed algoritmi per garantire la persistenza dei dati** anche in presenza di **malfunzionamenti hardware/software.**

Il controllore di affidabilità utilizza dei **log**, nel quale sono indicate tutte le operazioni svolte dal DBMS.

- Algoritmi ad-hoc (es. algoritmo di ripresa a caldo / a freddo) per ripristinare lo stato dei dati a partire dai log del DBMS.

DBMS: affidabilità; persistenza – 2

Il controllore di affidabilità utilizza un **log**, nel quale sono indicate tutte le operazioni svolte dal DBMS.

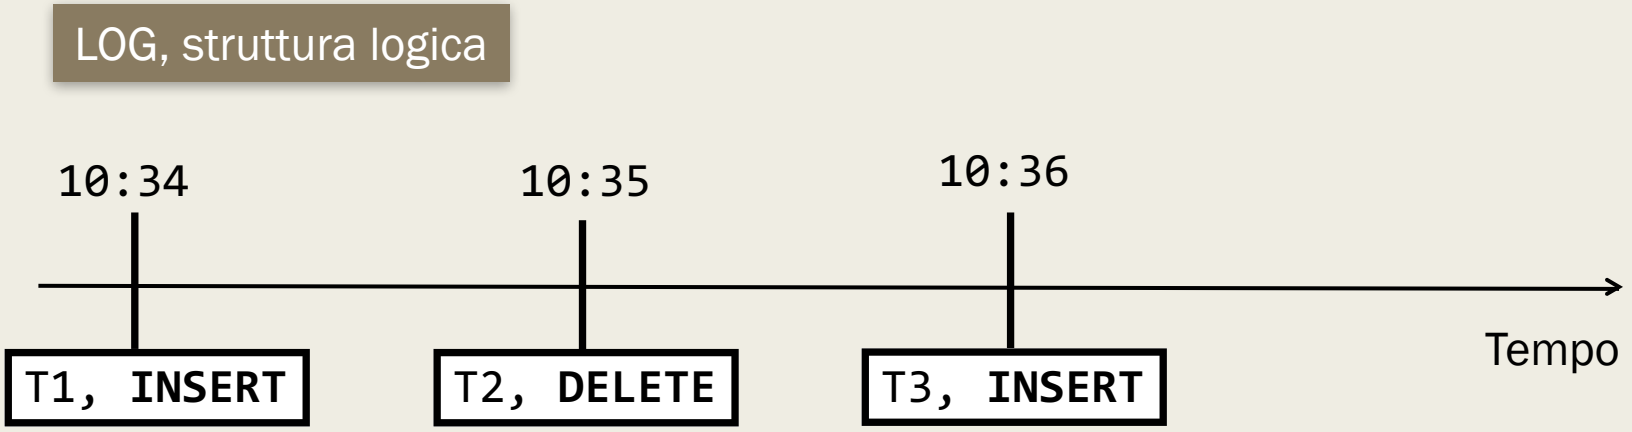

Tramite il log, è possibile fare il **do / undo** delle operazioni…

DBMS: affidabilità; persistenza – 3

Il controllore di affidabilità utilizza un **log**, nel quale sono indicate tutte le operazioni svolte dal DBMS.

LOG, struttura logica

D. Dove/come memorizzare il file di log?

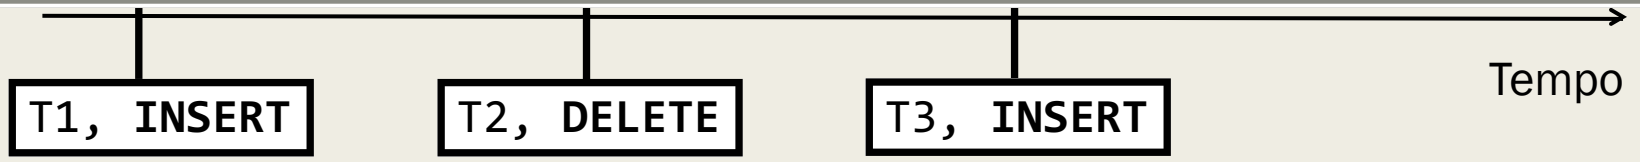

Tramite il log, è possibile fare il **do** / **undo** delle operazioni…

DBMS: affidabilità; persistenza – 4

Transazione → insieme di operazioni (lettura/scrittura) eseguite su un DB dal DBMS.

Proprietà **ACID** di un sistema transazionale

- **Atomicità** → La transazione deve essere eseguita con la regola del "tutto o niente".
- **Consistenza** → La transazione deve lasciare il DB in uno stato consistente, vincoli di integrità sui dati non devono essere violati.
- **Isolamento** → L'esecuzione di una transazione deve essere indipendente dalle altre.
- **Persistenza** → L'effetto di una transazione conclusa con successo non deve essere perso.

DBMS: componenti

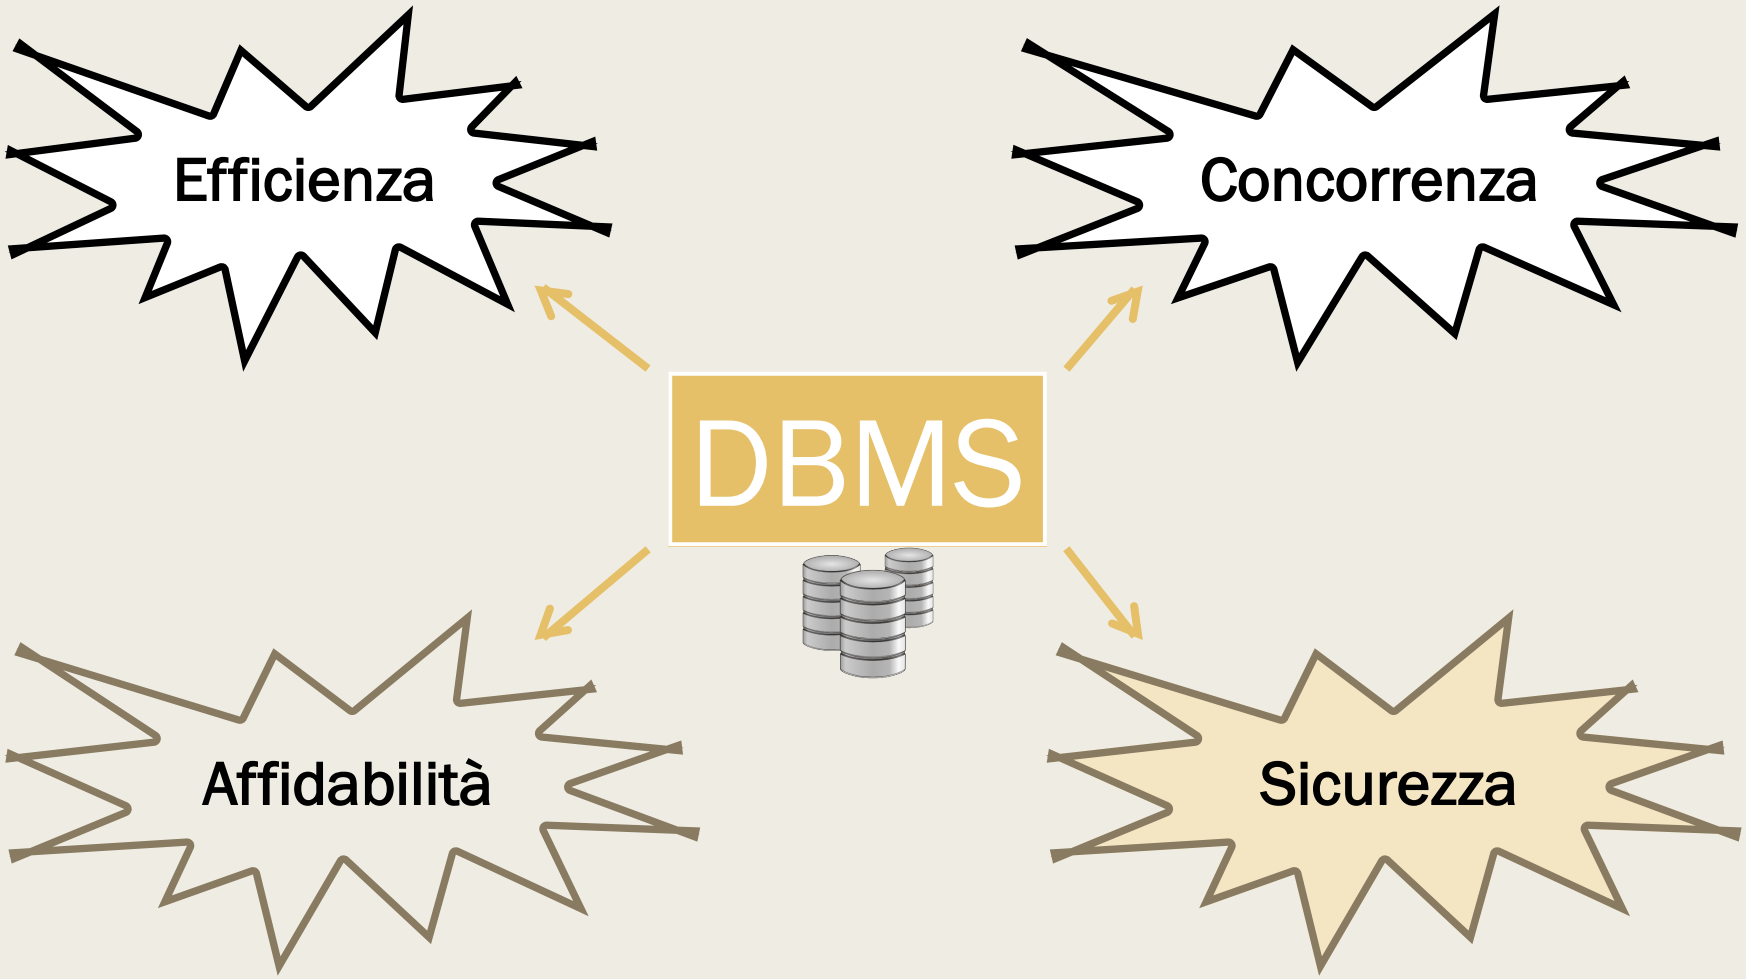

DBMS: sicurezza; multi-utenza

La maggior parte dei DBMS implementa **politiche di controllo degli accessi** ad i dati mediante **sistemi di permessi**:

- Quali operazioni sono consentite all'utente X?
- Quali dati appartengono all'utente X?

UTENTE X

UTENTE Y

Utente	OPERAZIONE	DATO	PERMESSO
Utente X	Lettura	Stipendio di X	Consentito
Utente X	Lettura	Stipendio di Y	Consentito
Utente Y	Scrittura	Stipendio di Y	Negato

DBMS: sicurezza; scalabilità – 1

Scalabilità orizzontale

Possibilità di gestire grandi moli di dati aumentando il **numero di nodi** usati per lo *storage*
→ **database distribuito**.

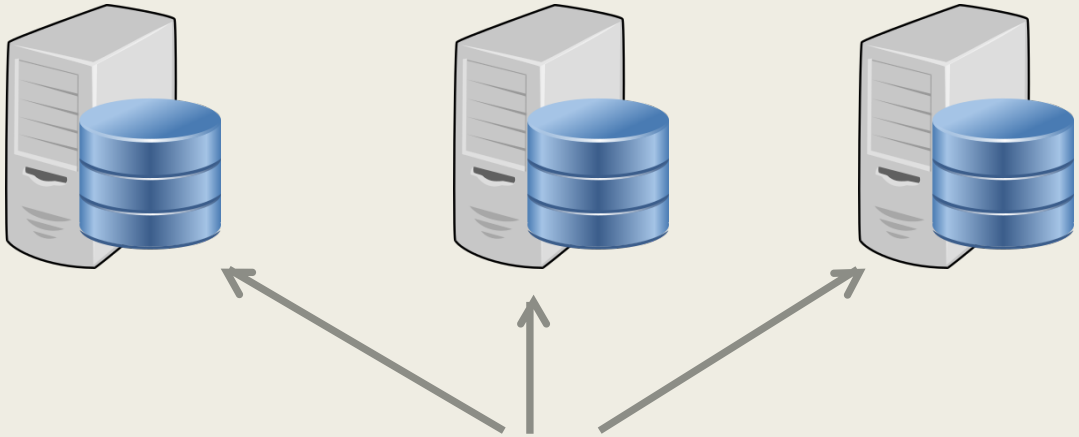

La funzione di **sharding** determina la politica di distribuzione dei dati tra i nodi

DBMS: sicurezza; scalabilità – 2

Scalabilità orizzontale

Ulteriori funzionalità di un database distribuito.

1. Meccanismi di *load-balancing*
2. Meccanismi di **gestione delle repliche** dati

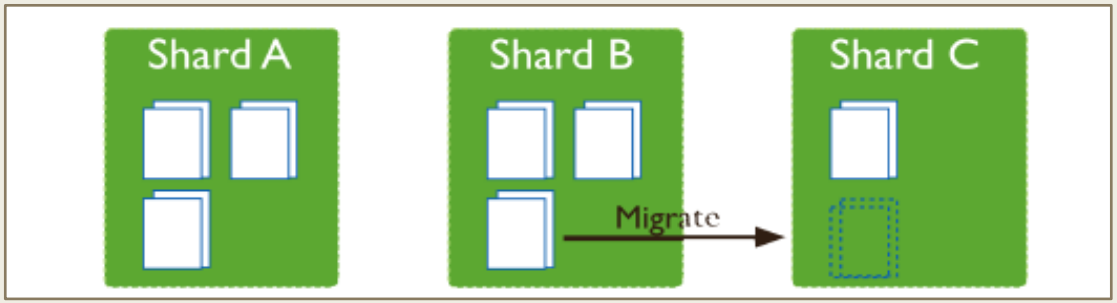

PROBLEMA. Come gestire la **consistenza** delle repliche dati in presenza di partizionamenti della rete e perdita di messaggi? **CAP Theorem** ...

DBMS: architettura a 3 livelli

In pratica, un DBMS può essere visto come una **architettura software** a 3 livelli ...

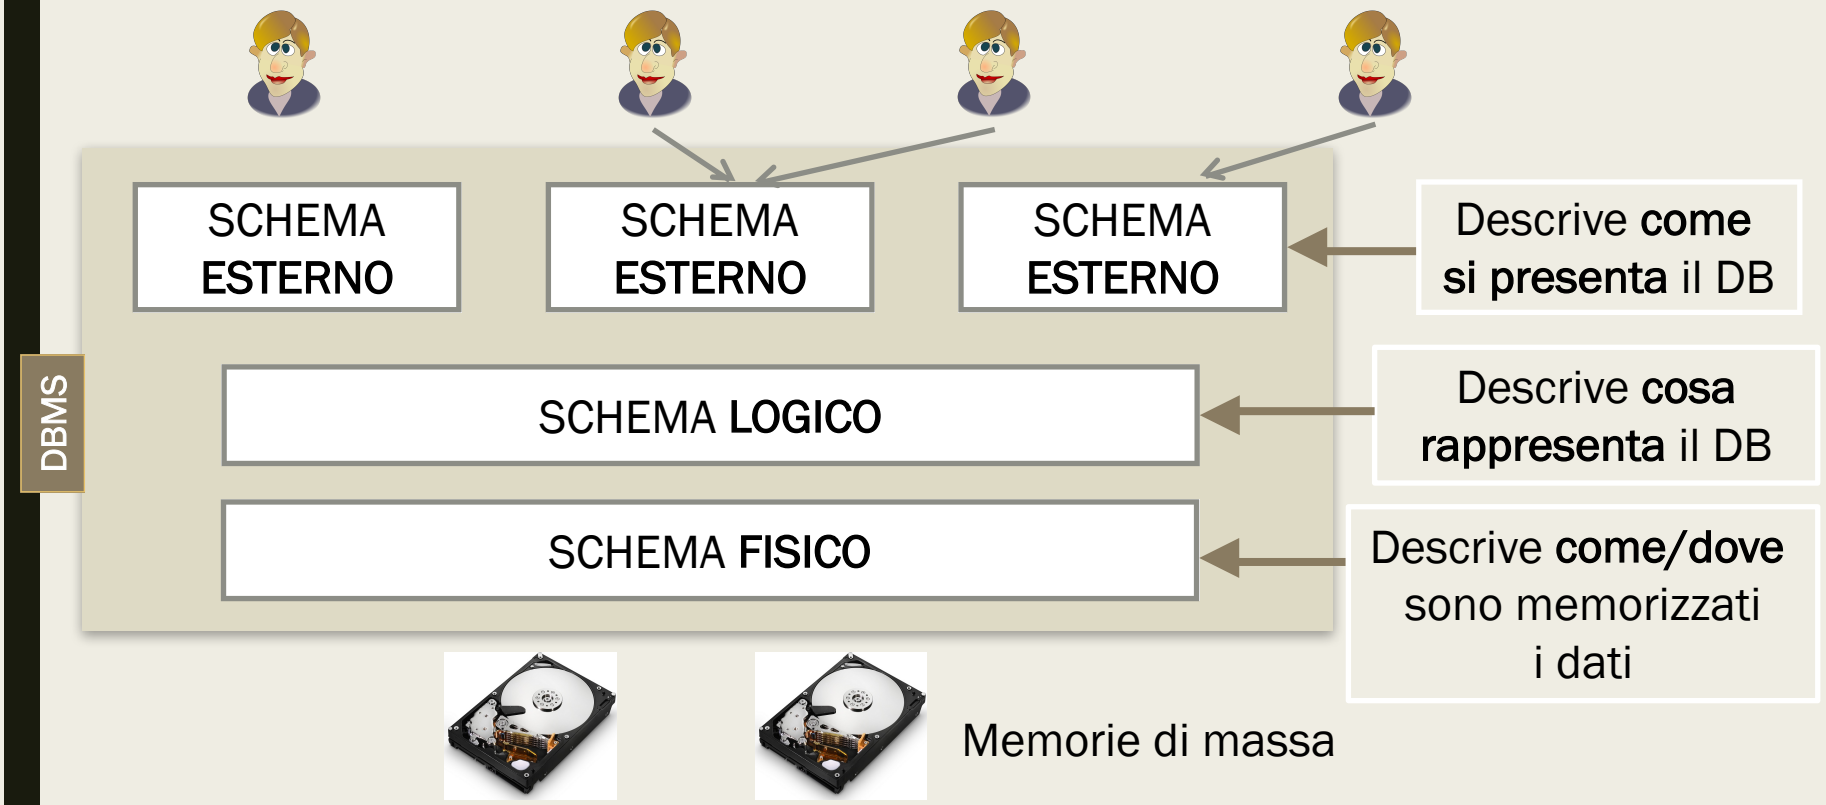

DBMS: livello logico – 1

I DBMS forniscono un approccio **strutturato** ai dati.

???

In un DBMS, i dati sono organizzati secondo **un modello logico**, che definisce i concetti rappresentati, le associazioni dei dati, i vincoli che questi devono rispettare.

In pratica, l'utente/applicazione interagisce con i dati del DBMS sulla base del modello logico …

DBMS: livello logico – 2

- Sono stati proposti **diversi modelli logici** …
- DBMS possono differire sulla base del modello logico dei dati che supportano:
- Modello **Relazionale** (di fatto, il più usato)
  - Modello Gerarchico
  - Modello Reticolare
  - Modello ad Oggetti
  - Approcci NoSQL (diversi)

DBMS: livello logico – 3

Esempio: **Modello Relazionale**

Base di dati che gestisce le informazioni relative alla programmazione didattica di un Corso di Laurea: elenco corsi, con numero ore, semestre, crediti, nome e codice identificativo di ciascun corso.

CAMPI, COLONNE

SCHEMA, RELAZIONE, TABELLA

Codice	Nome	Num.Ore	Semestre	Crediti
010	Basi di Dati	72	1	9
001	Algoritmi	90	1	12

ISTANZE, RIGHE

Nel modello relazionale, i dati sono organizzati in tabelle … vedremo meglio nella seconda parte!

DBMS: livello logico – 4

Esempio: **Modello Relazionale**

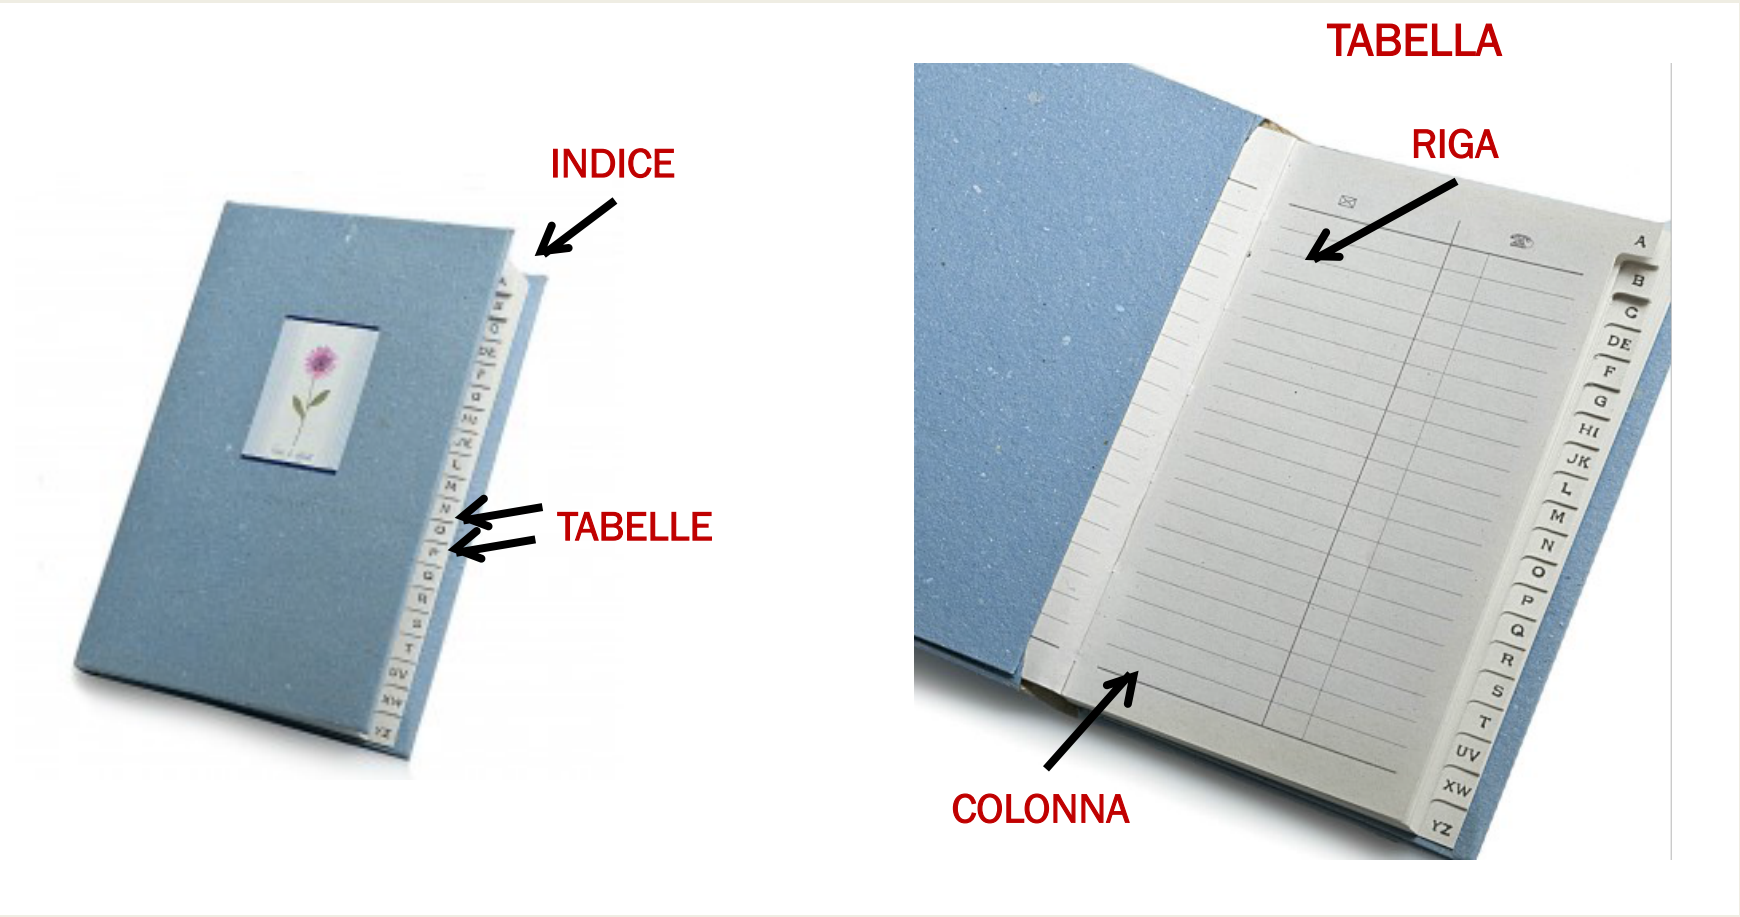

DBMS: livello logico – 5

INDIPENDENZA MODELLO LOGICO – MODELLO FISICO

- L'organizzazione logica dei dati **non dipende** dalle strutture dati usate per l'effettiva memorizzazione su disco!

- In pratica, **le applicazioni accedono al DBMS specificando concetti logici** del modello dei dati, piuttosto che i dettagli relativi alla loro memorizzazione.

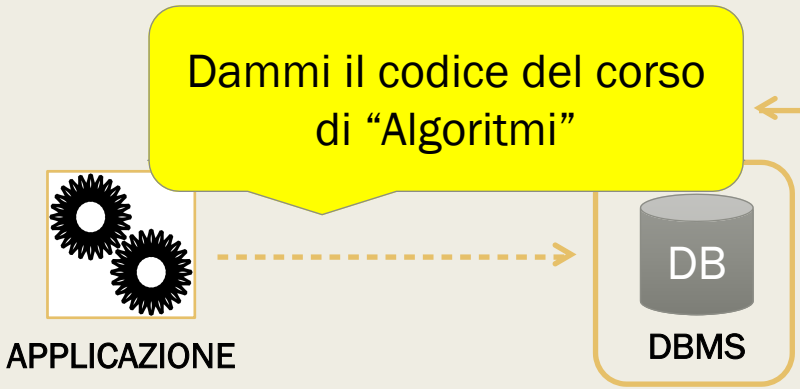

Non vengono specificate righe / colonne nel quale queste informazioni sono memorizzate nella tabella!

DBMS: livello esterno

Il livello esterno consente di avere **viste** personalizzate della base di dati da parte di diversi utenti / applicazioni!

Esempio: Base di dati condivisa tra diversi uffici di una stessa organizzazione. Solo alcuni uffici possono accedere a tutto il contenuto del DB!

Codice	Nome	Cognome	Data Nascita	Livello	Stipendio
001	Marco	Rossi	10/10/1970	1	24000
002	Michele	Bianchi	13/12/1977	1	32000

VISTA Ufficio **Anagrafe**

VISTA Ufficio **Stipendi**

DBMS: interazione – 1

- Come possono utenti ed applicazioni interagire con un DBMS?

Quasi tutti i DBMS mettono a disposizione dei **linguaggi**:

- Definizione dello schema logico → **Linguaggio DDL**
- Manipolazione delle istanze → **Linguaggio DML**

- Linguaggi **orientati ai dati**, molto diversi da linguaggi di programmazione "tradizionali" (es. C / C++ / Java / ecc.)!
- Noi vedremo il linguaggio (DDL + DML) **SQL**

DBMS: interazione – 2

Le applicazioni che si interfacciano con un DBMS:

- integrano **codice SQL** all'interno del loro codice
- utilizzano opportune **librerie** (fornite dal DBMS) per gestire la connessione al DBMS.

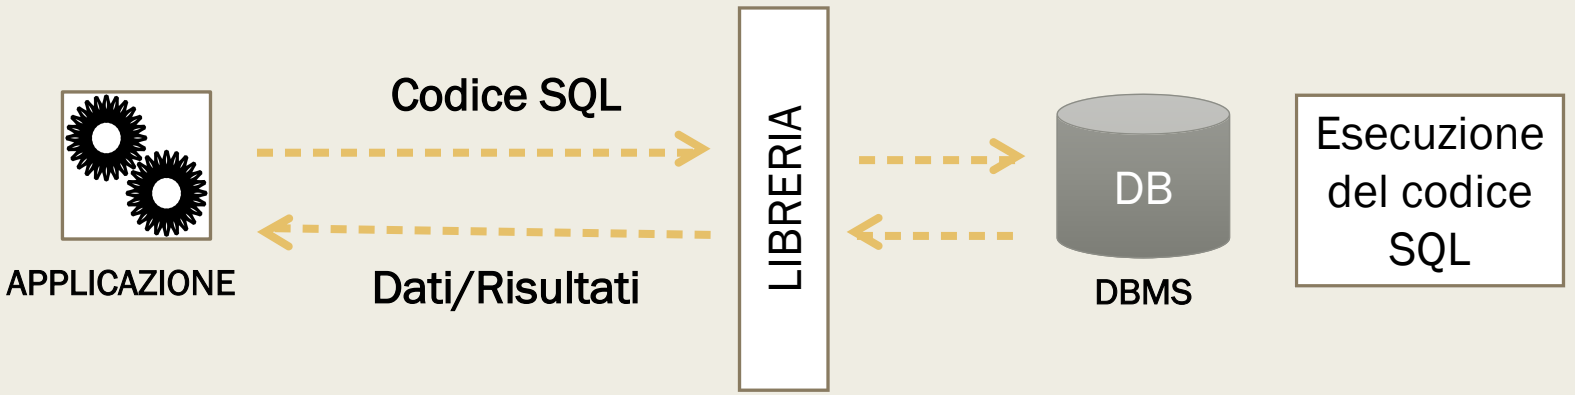

DBMS: interazione – 3

- Un esempio di modello integrato DMBS/App molto in voga: **Web Information System** (WIS)

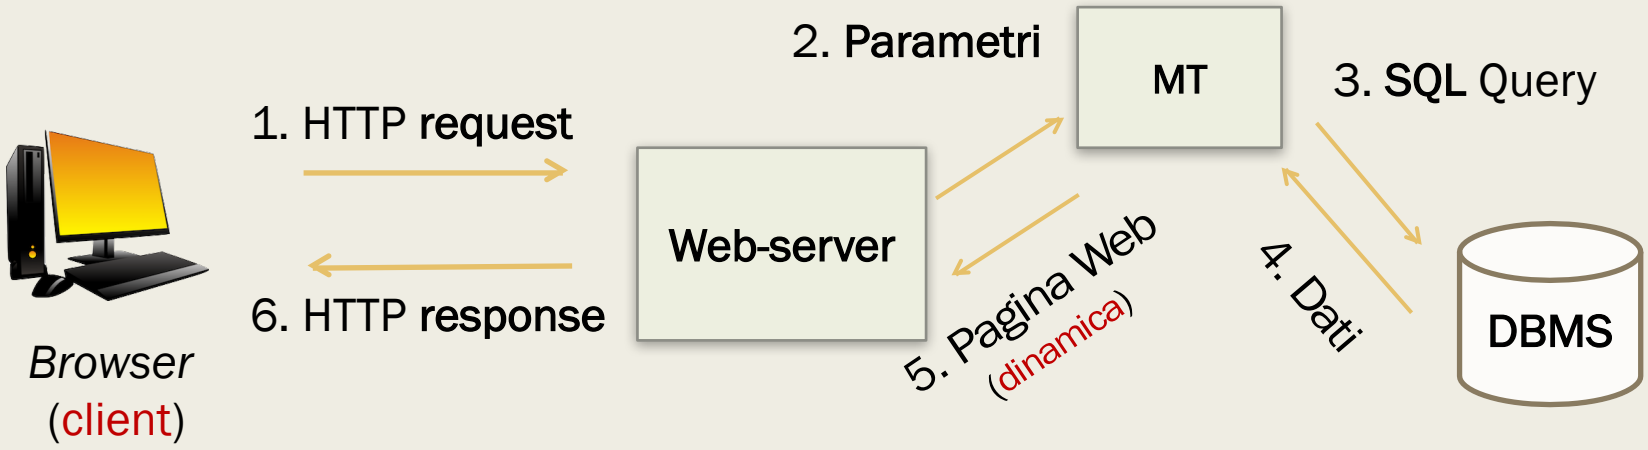

- Esempio: **Architettura AMP** (Apache + MySQL + PHP)

DBMS: vantaggi – 1

Quando usare un DBMS in un progetto SW?

- Necessità di gestire grandi volumi di dati
- Necessità di costruire sistemi *data-centric* con molte operazioni di accesso ai dati
- Necessità di condividere dati, fornendo l'accesso a diversi sistemi SW/applicazioni
- Necessità di garantire la persistenza dei dati anche a fronte di possibili guasti e malfunzionamenti HW/SW
- Necessità di implementare meccanismi di sicurezza per l'accesso ad i dati in un ambiente multi-utente

DBMS: vantaggi – 2

Quando NON usare un DBMS in un progetto SW?

- **Prestazioni** → In alcuni sistemi con richieste di efficienza sull'elaborazione (es. real-time), l'*overhead* computazionale introdotto dal DBMS può essere eccessivo …
- **Costo** → Spese per l'acquisto di DBMS, formazione del personale, amministrazione del DB, ecc.
- **Complessità** → Applicazioni/sistemi di dimensioni ridotte, *single-user* e con pochi dati da gestire …

DBMS: quale usare?

- Fino ad ora abbiamo parlato in generale delle caratteristiche dei DBMS …
- … ma i **DBMS sono tutti uguali**? **NO**!

Differenze sostanziali, ad esempio in termini di:

- Modello logico supportato (relazionale? → RDBMS)
- Linguaggio DDL/DML (SQL–2? SQL–3? varianti?)
- Algoritmi di indicizzazione (es. R+ tree?)
- Supporto alla transazioni (es. proprietà ACID?)
- Gestione della concorrenza
- …

DBMS: i più usati *open source*

TOP 5 – Ottobre 2017

Posiz.	Sistema	Punteggio	Posiz. generale
1.	MySQL	1299	2.
2.	PostgreSQL	373	4.
3.	MongoDB	329	5.
4.	Cassandra	125	8.
5.	Redis	122	9.

Fonte DB-Engines.com

DBMS: andamento

- Oggi, una delle nuove linee evolutive dei DBMS è rappresentata dall'approccio **NoSQL.**
- **Idea di base**: superare la rigidità del modello relazionale nella definizione dello schema, consentendo una più facile espansione del DB in termini di dati, e di computazione distribuita.
- Molti approcci sotto la definizione NoSQL:

  Es. **Apache Cassandra**, **Apache CouchDB**, …