Basi di dati

Giuseppe De Giacomo

Dipartimento di Informatica e Sistemistica "Antonio Ruberti"
Università di Roma "La Sapienza"

Anno Accademico 2005/2006
Canale M-Z

http://www.dis.uniroma1.it/~degiacomo/didattica/basidati/

2. Il modello relazionale

2.1 Basi di dati relazionali

1. **basi di dati relazionali**
2. algebra relazionale

Il modello relazionale

- Proposto da E. F. Codd nel 1970 per favorire l'indipendenza dei dati
- Disponibile come modello logico in DBMS reali nel 1981 (non è facile realizzare l'indipendenza con efficienza e affidabilità!)
- Si basa sul concetto matematico di **relazione** (con una variante)
- Le relazioni hanno una rappresentazione naturale per mezzo di tabelle
- Il modello è "**basato su valori**": anche i riferimenti fra dati in strutture (relazioni) diverse sono rappresentati per mezzo dei valori stessi

Relazione: tre accezioni

- **relazione matematica**: come nella teoria degli insiemi
- relazione (dall'inglese **relationship**) che rappresenta una classe di fatti — una relazione matematica fra due **entità**, nel modello **Entity-Relationship**; talvolta tradotto con **associazione** o **correlazione**
- **relazione** secondo il modello relazionale dei dati: tabella

Relazione matematica

- $D_1, D_2, \ldots, D_n$ (n insiemi anche non distinti)
- il **prodotto cartesiano** $D_1 \times D_2 \times \ldots \times D_n$, è l'insieme di tutte le n-uple ordinate $(d_1, d_2, \ldots, d_n)$ tali che $d_1 \in D_1$, $d_2 \in D_2$, …, $d_n \in D_n$
- una relazione matematica su $D_1, D_2, \ldots, D_n$ è un **sottoinsieme del prodotto cartesiano $D_1 \times D_2 \times \ldots \times D_n$**
- $D_1, D_2, \ldots, D_n$ sono i **domini** della relazione. Una relazione su n domini ha **grado** (o **arietà**) n
- il numero di n-uple è la **cardinalità** della relazione

Relazione matematica: esempio

- $D_1=\{a,b\}$
- $D_2=\{x,y,z\}$
- prodotto cartesiano $D_1 \times D_2$

a	x
a	y
a	z
b	x
b	y
b	z

- una relazione $r \subseteq D_1 \times D_2$

a	x
a	z
b	y
b	z

Relazione matematica: proprietà

Una relazione matematica è un insieme di n-uple ordinate: $(d_1, \ldots, d_n)$ tali che $d_1 \in D_1, \ldots, d_n \in D_n$

- la relazione è un **insieme**; quindi:
  - non c'è ordinamento fra le n-uple
  - le n-uple sono distinte
- ciascuna n-upla è **ordinata**; quindi
  - l' i-esimo valore proviene dall' i-esimo dominio

Relazione matematica, esempio

$$Partita \subseteq string \times string \times integer \times integer$$

Juve	Lazio	3	1
Lazio	Milan	2	0
Juve	Roma	1	2
Roma	Milan	0	1

- Ciascuno dei domini ha due **ruoli** distinti, distinguibili attraverso la posizione: il primo e il terzo dominio si riferiscono a nome e reti della squadra ospitante; il secondo e il quarto a nome e reti della squadra ospitata
- La struttura è **posizionale**

Relazioni nel modello relazionale dei dati

- Ogni relazione è sostanzialmente una **tabella**
- A ciascun dominio associamo un nome (**attributo**), unico nella relazione, che "descrive" il ruolo del dominio
- Nella rappresentazione tabellare, gli attributi sono usati come intestazioni delle colonne

Casa	Fuori	RetiCasa	RetiFuori
Juve	Lazio	3	1
Lazio	Milan	2	0
Juve	Roma	1	2
Roma	Milan	0	1

- L'ordinamento fra gli attributi è irrilevante: la struttura è **non posizionale**

Notazioni

- Se t è una ennupla (o tupla) su X e $A \in X$, allora **t[A]** (oppure **t.A**) indica **il valore di t su A**
- Nell'esempio, se t è la prima ennupla della tabella
  t[Fuori] = Lazio
- La stessa notazione è estesa anche ad insiemi di attributi, nel qual caso denota ennuple: t[Fuori,RetiFuori] è una ennupla su due attributi
- Nell'esempio, se t è la prima ennupla della tabella
  t[Fuori,RetiFuori] = <Lazio, 1>

Altra notazione

- Per una relazione R con attributi A1, A2 e A3, e corrispondenti domini D1, D2 e D3 si può denotare anche come

  R(A1 : D1, A2 : D2, A3 : D3)

- Di conseguenza, una tupla di R con t[A1] = a, t[A2] = b e t[A3] = c si può denotare anche come

  <A1 : a, A2 : b, A3 : c>

- In altre parole, la tupla si può vedere come "tupla etichettata", in cui le etichette sono gli attributi della relazione, ed i valori associati alle etichette sono i valori che compongono la tupla.

Tabelle e relazioni

- Una tabella rappresenta una relazione se
  - i valori di ciascuna colonna sono fra loro omogenei (appartengono allo stesso dominio)
  - le righe sono diverse fra loro
  - le intestazioni delle colonne (attributi) sono diverse tra loro
- Inoltre, in una tabella che rappresenta una relazione
  - l'ordinamento tra le righe è irrilevante
  - l'ordinamento tra le colonne è irrilevante
- **Il modello relazionale è basato su valori**: i riferimenti fra dati in relazioni diverse sono rappresentati per mezzo di valori dei domini che compaiono nelle ennuple

studenti

Matricola	Cognome	Nome	Data di nascita
6554	Rossi	Mario	05/12/1978
8765	Neri	Paolo	03/11/1976
9283	Verdi	Luisa	12/11/1979
3456	Rossi	Maria	01/02/1978

esami

Studente	Voto	Corso
3456	30	04
3456	24	02
9283	28	01
6554	26	01

corsi

Codice	Titolo	Docente
01	Analisi	Mario
02	Chimica	Bruni
04	Chimica	Verdi

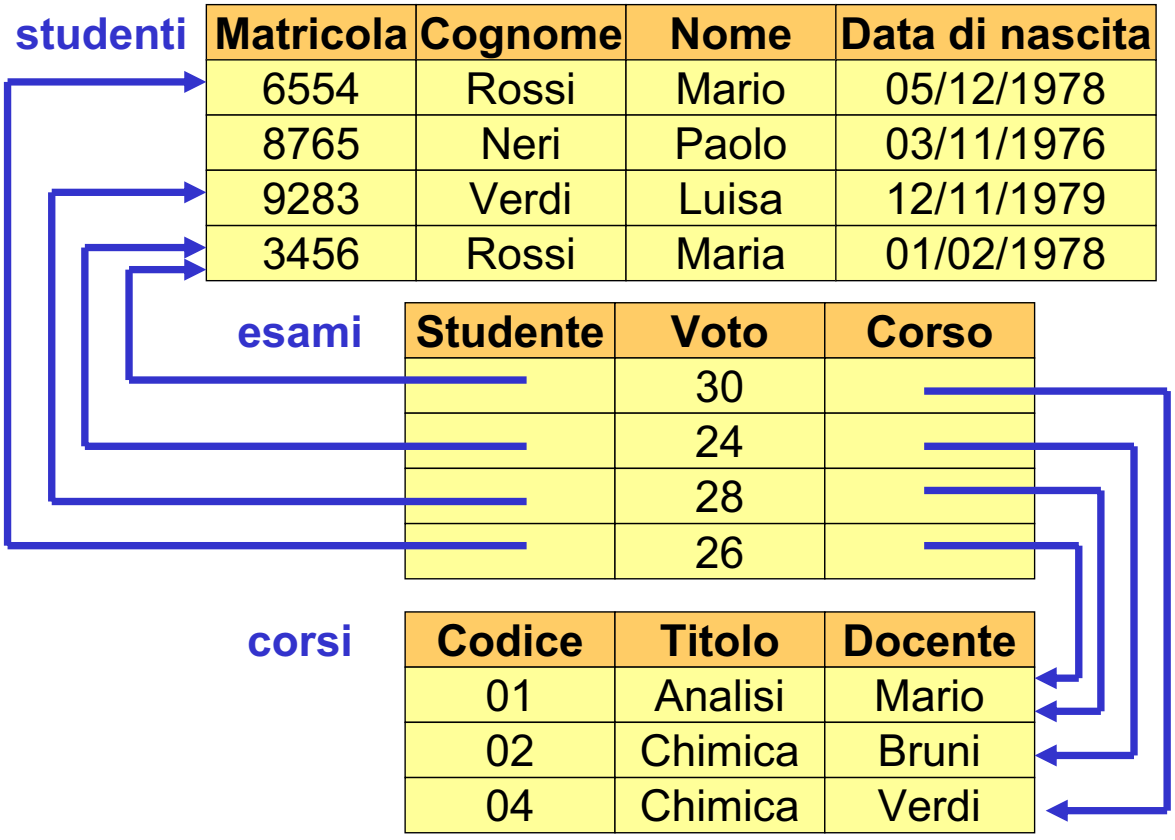

Vantaggi della struttura basata su valori

- **indipendenza dalle strutture fisiche**, che possono cambiare anche dinamicamente
- si rappresenta solo ciò che è **rilevante dal punto di vista dell'applicazione** (dell'utente); i puntatori sono meno comprensibili per l'utente finale (senza, l'utente finale vede gli stessi dati dei programmatori)
- i dati sono **portabili** più facilmente da un sistema ad un altro
- i valori consentono **bi-direzionalità**, i puntatori sono direzionali

Nota: i puntatori possono essere usati a livello fisico

Definizioni

Schema di relazione: un **nome di relazione** R con un insieme di **attributi** $A_1,..., A_n$

$$R(A_1,..., A_n)$$

Schema di base di dati: insieme di schemi di relazione con nomi diversi:

$$\mathbf{R} = \{R_1(X_1), ..., R_n(X_n)\}$$

(Istanza di) relazione su uno schema R(X): insieme r di ennuple su X

(Istanza di) base di dati su uno schema **R**= $\{R_1(X_1), ..., R_n(X_n)\}$: insieme di relazioni **r** = $\{r_1,..., r_n\}$ (con r_i relazione su R_i)

Esempio

studenti

Matricola	Cognome	Nome	Data di nascita
6554	Rossi	Mario	05/12/1978
8765	Neri	Paolo	03/11/1976
9283	Verdi	Luisa	12/11/1979
3456	Rossi	Maria	01/02/1978

studenti lavoratori

Matricola
6554
3456

Informazione incompleta

- Il modello relazionale impone ai dati una struttura rigida:
  - le informazioni sono rappresentate per mezzo di ennuple
  - le ennuple ammesse sono dettate dagli schemi di relazione
- I dati disponibili possono non corrispondere esattamente al formato previsto, per varie ragioni

  Esempio:
  - di Firenze non conosciamo l'indirizzo della prefettura
  - Tivoli non è provincia: non ha prefettura
  - Prato è “nuova” provincia: ha la prefettura?

Città	Prefettura
Roma	Via IV Novembre
Firenze	
Tivoli	
Prato	

Informazione incompleta: soluzioni?

Non conviene (anche se spesso si fa) utilizzare valori ordinari del dominio (0, stringa nulla, “99”, etc), per vari motivi:

- potrebbero non esistere valori “non utilizzati”
- valori “non utilizzati” potrebbero diventare significativi
- in fase di utilizzo (ad esempio, nei programmi) sarebbe necessario ogni volta tener conto del “significato” di questi valori

Informazione incompleta nel modello relazionale

- Si adotta una tecnica rudimentale ma efficace:
  - **valore nullo**: denota l’assenza di un valore del dominio (e non è un valore del dominio)
- Formalmente, è sufficiente estendere il concetto di ennupla: t[A], per ogni attributo A, è un valore del dominio dom(A) oppure il valore nullo **NULL**
- Si possono (e debbono) imporre restrizioni sulla presenza di valori nulli

Tipi di interpretazione del valore nullo

- (almeno) tre casi differenti
  - valore **sconosciuto**: esiste un valore del dominio, ma non è noto (Firenze)
  - valore **inesistente**: non esiste un valore del dominio (Tivoli)
  - valore **senza informazione**: non è noto se esista o meno un valore del dominio (Prato)

- I DBMS non distinguono i tipi di valore nullo (e quindi implicitamente adottano l'interpretazione "**senza informazione**")

Vincoli di integrità

Esistono istanze di basi di dati che, pur sintatticamente corrette, non rappresentano informazioni possibili per l'applicazione di interesse.

Studenti

Matricola	Cognome	Nome	Nascita
276545	Rossi	Maria	23/04/1968
276545	Neri	Anna	23/04/1972
788854	Verdi	Fabio	12/02/1972

Esami

Studente	Voto	Lode	Corso
276545	28	e lode	01
276545	32		02
788854	23		03
200768	30	e lode	03

Corsi

Codice	Titolo	Docente
01	Analisi	Giani
03	NULL	NULL
02	Chimica	Belli

Vincolo di integrità

Definizione

- proprietà che deve essere soddisfatta dalle istanze che rappresentano informazioni corrette per l'applicazione
- ogni vincolo può essere visto come una funzione booleana (o un predicato) che associa ad ogni istanza il valore **vero** o **falso**

- Ad uno schema associamo un insieme di vincoli e consideriamo **corrette** (lecite, valide, ammissibili) solo le istanze che soddisfano tutti i vincoli

- Tipi di vincoli:
  - intrarelazionali
  - interrelazionali

Vincoli di integrità: motivazioni

- risultano utili al fine di descrivere la realtà di interesse in modo più accurato di quanto le strutture permettano;
- forniscono un contributo verso la "qualità dei dati"
- costituiscono uno strumento di ausilio alla progettazione
- sono utilizzati dal sistema nella scelta della strategia di esecuzione delle interrogazioni

Nota:

- non tutte le proprietà di interesse sono rappresentabili per mezzo di vincoli esprimibili direttamente

Vincoli intrarelazionali: vincoli di ennupla

- Esprimono **condizioni sui valori di ciascuna ennupla**, indipendentemente dalle altre ennuple
- Una possibile sintassi: espressione booleana (con AND, OR e NOT) di atomi che confrontano valori di attributo o espressioni aritmetiche su di essi
- Un vincolo di ennupla è un **vincolo di dominio** se coinvolge un solo attributo

Esempi:

(Voto $\geq$ 18) AND (Voto $\leq$ 30)

(Voto = 30) OR NOT (Lode = “e lode”)

Lordo = (Ritenute + Netto)

Vincoli intrarelazionali: vincoli di chiave

Matricola	Cognome	Nome	Corso	Nascita
27655	Rossi	Mario	Ing Inf	5/12/78
78763	Rossi	Mario	Ing Inf	3/11/76
65432	Neri	Piero	Ing Mecc	10/7/79
87654	Neri	Mario	Ing Inf	3/11/76
67653	Rossi	Piero	Ing Mecc	5/12/78

- il numero di matricola identifica gli studenti:
  - non ci sono due ennuple con lo stesso valore sull’attributo Matricola
- i dati anagrafici identificano gli studenti:
  - non ci sono due ennuple uguali su tutti e tre gli attributi Cognome, Nome e Nascita

Vincoli di chiave

Chiave: insieme di attributi che identificano univocamente le ennuple di una relazione

Più precisamente:

- un insieme K di attributi è **superchiave** per una relazione r se r non contiene due ennuple distinte t_1 e t_2 tali che $t_1[K] = t_2[K]$
- K è **chiave** per r se è una superchiave minimale (cioè non contiene un'altra superchiave) per r

Vincoli di chiave: esempi

Matricola	Cognome	Nome	Corso	Nascita
27655	Rossi	Mario	Ing Inf	5/12/78
78763	Rossi	Mario	Ing Inf	3/11/76
65432	Neri	Piero	Ing Mecc	10/7/79
87654	Neri	Mario	Ing Inf	3/11/76
67653	Rossi	Piero	Ing Mecc	5/12/78

- **Matricola** è una chiave:
  - Matricola è superchiave
  - contiene un solo attributo e quindi è minimale
- **Cognome, Nome, Nascita** è un'altra chiave:
  - l'insieme Cognome, Nome, Nascita è superchiave
  - nessuno dei suoi sottoinsiemi è superchiave
- Cognome, Nome, Nascita, Corso è superchiave (non chiave)

Un'altra chiave?

Matricola	Cognome	Nome	Corso	Nascita
27655	Rossi	Mario	Ing Inf	5/12/78
78763	Rossi	Mario	Ing Civile	3/11/76
65432	Neri	Piero	Ing Mecc	10/7/79
87654	Neri	Mario	Ing Inf	3/11/76
67653	Rossi	Piero	Ing Mecc	5/12/78

- non ci sono ennuple uguali su Cognome e Corso: Cognome e Corso formano una chiave
- ma è sempre vero?

Vincoli, schemi e istanze

- i vincoli corrispondono a proprietà del mondo reale modellato dalla base di dati
- interessano a livello di schema (con riferimento cioè a tutte le istanze): ad uno schema associamo un insieme di vincoli che vogliamo siano soddisfatti da **tutte** le sue istanze corrette
- consideriamo quindi **corrette** (valide, ammissibili) le istanze che soddisfano tutti i vincoli
- N.B.: un'istanza può soddisfare altri vincoli ("per caso")

Individuazione delle chiavi

Individuiamo le chiavi

- considerando le proprietà che i dati soddisfano nell'applicazione (il "frammento di mondo reale di interesse")
- notando quali insiemi di attributi permettono di identificare univocamente le ennuple
- e individuando i sottoinsiemi minimali di tali insiemi che conservano la capacità di identificare le ennuple

Esempio:

Studenti(Matricola, Cognome, Nome, Corso, Nascita) ha 2 chiavi:

Matricola

Cognome, Nome, Nascita

Esistenza delle chiavi

- poiché le relazioni sono insiemi, una relazione non può contenere ennuple uguali fra loro:
  - ogni relazione ha come superchiave l'insieme degli attributi su cui è definita
- poiché l'insieme di tutti gli attributi è una superchiave per ogni relazione, ogni schema di relazione ha almeno una superchiave
- ne segue che **ogni schema di relazione ha (almeno) una chiave**

Importanza delle chiavi

- l'esistenza delle chiavi garantisce l'accessibilità a ciascun dato della base di dati
- ogni singolo valore è univocamente accessibile tramite:
  - nome della relazione
  - valore della chiave
  - nome dell'attributo
- le chiavi sono lo strumento principale attraverso il quale vengono correlati i dati in relazioni diverse ("il modello relazionale è basato su valori")

Chiavi e valori nulli

- In presenza di valori nulli, i valori degli attributi che formano la chiave:
  - non permettono di identificare le ennuple come desiderato
  - né permettono di realizzare facilmente i riferimenti da altre relazioni

Matricola	Cognome	Nome	Corso	Nascita
NULL	NULL	Mario	Ing Inf	5/12/78
78763	Rossi	Mario	Ing Civile	3/11/76
65432	Neri	Piero	Ing Mecc	10/7/79
87654	Neri	Mario	Ing Inf	NULL
NULL	Neri	Mario	NULL	5/12/78

Chiave primaria

- La presenza di valori nulli nelle chiavi deve essere limitata
- Soluzione pratica: per ogni relazione scegliamo una chiave (la **chiave primaria**) su cui non ammettiamo valori nulli.
- Notazione per la chiave primaria: gli attributi che la compongono sono sottolineati

Matricola	Cognome	Nome	Corso	Nascita
27655	Rossi	Mario	Ing Inf	5/12/78
78763	Rossi	Mario	Ing Civile	3/11/76
65432	Neri	Piero	Ing Mecc	10/7/79
87654	Neri	Mario	Ing Inf	NULL
67653	Rossi	Piero	NULL	5/12/78

Vincoli interrelazionali: integrità referenziale

- Informazioni in relazioni diverse sono correlate attraverso valori comuni, in particolare, attraverso valori delle chiavi (primarie, di solito)

- Un **vincolo di integrità referenziale** (detto anche vincolo di ("**foreign key**") fra un insieme di attributi X di una relazione R_1 e un'altra relazione R_2 impone ai valori su X di ciascuna ennupla dell'istanza di R_1 di comparire come valori della chiave (primaria) dell'istanza di R_2

- Giocano un ruolo fondamentale nel concetto di "modello basato su valori"

Vincoli di integrità referenziale: esempio

Infrazioni

Codice	Data	Vigile	Prov	Numero
34321	1/2/95	3987	MI	39548K
53524	4/3/95	3295	TO	E39548
64521	5/4/96	3295	PR	839548
73321	5/2/98	9345	PR	839548

Vigili

Matricola	Cognome	Nome
3987	Rossi	Luca
3295	Neri	Piero
9345	Neri	Mario
7543	Mori	Gino

Esempio (cont.)

Infrazioni

Codice	Data	Vigile	Prov	Numero
34321	1/2/95	3987	MI	39548K
53524	4/3/95	3295	TO	E39548
64521	5/4/96	3295	PR	839548
73321	5/2/98	9345	PR	839548

Auto

Prov	Numero	Cognome	Nome
MI	39548K	Rossi	Mario
TO	E39548	Rossi	Mario
PR	839548	Neri	Luca

Vincoli di integrità referenziale: esempio

- Nell'esempio, i vincoli di integrità referenziale sussistono fra:
  - l'attributo **Vigile** della relazione **Infrazioni** e la relazione **Vigili**
  - gli attributi **Prov** e **Numero** di **Infrazioni** e gli omonimi attributi della relazione **Auto**

Violazione di vincolo di integrità referenziale

Infrazioni

Codice	Data	Vigile	Prov	Numero
34321	1/2/95	3987	MI	39548K
53524	4/3/95	3295	TO	E39548
64521	5/4/96	2468	PR	839548
73321	5/2/98	9345	PR	839548

Vigili

Matricola	Cognome	Nome
3987	Rossi	Luca
3295	Neri	Piero
9345	Neri	Mario
7543	Mori	Gino

Violazione di vincolo di integrità ref. (cont.)

Infrazioni

Codice	Data	Vigile	Prov	Numero
34321	1/2/95	3987	MI	39548K
53524	4/3/95	3295	TO	39548K
64521	5/4/96	3295	PR	839548
73321	5/2/98	9345	PR	839548

Auto

Prov	Numero	Cognome	Nome
MI	39548K	Rossi	Mario
TO	E39548	Rossi	Mario
PR	839548	Neri	Luca

Integrità referenziale e valori nulli

In presenza di valori nulli i vincoli possono essere resi meno restrittivi

Impiegati

Matricola	Cognome	Progetto
34321	Rossi	IDEA
53524	Neri	XYZ
64521	Verdi	NULL
73032	Bianchi	IDEA

Progetti

Codice	Inizio	Durata	Costo
IDEA	01/2000	36	200
XYZ	07/2001	24	120
BOH	09/2001	24	150

Integrità referenziale: azioni compensative

Sono possibili meccanismi per il supporto alla gestione dei vincoli di integrità ("azioni" compensative a seguito di violazioni)

Ad esempio, se viene eliminata una ennupla causando una violazione:

- comportamento “standard”: rifiuto dell'operazione
- azioni compensative:
  - eliminazione in cascata
  - introduzione di valori nulli

Eliminazione in cascata

Impiegati

Matricola	Cognome	Progetto
34321	Rossi	IDEA
53524	Neri	XYZ
64521	Verdi	NULL
73032	Bianchi	IDEA

Progetti

Codice	Inizio	Durata	Costo
IDEA	01/2000	36	200
XYZ	07/2001	24	120
BOH	09/2001	24	150

Introduzione di valori nulli

Impiegati

Matricola	Cognome	Progetto
34321	Rossi	IDEA
53524	Neri	NULL
64521	Verdi	NULL
73032	Bianchi	IDEA

Progetti

Codice	Inizio	Durata	Costo
IDEA	01/2000	36	200
XYZ	07/2001	24	120
BOH	09/2001	24	150

Vincoli multipli su più attributi

Incidenti

Codice	Data	ProvA	NumeroA	ProvB	NumeroB
34321	1/2/95	TO	E39548	MI	39548K
64521	5/4/96	PR	839548	TO	E39548

Auto

Prov	Numero	Cognome	Nome
MI	39548K	Rossi	Mario
TO	E39548	Rossi	Mario
PR	839548	Neri	Luca

2. Il modello relazionale

2.2 Algebra relazionale

1. basi di dati relazionali
2. **algebra relazionale**

Linguaggi per basi di dati

- operazioni sullo schema:
  DDL: data definition language
- operazioni sui dati:
  DML: data manipulation language
  - interrogazione ("query")
  - aggiornamento

Linguaggi di interrogazione per basi di dati relazionali

Tipologia:

- **Dichiarativi**: specificano le proprietà del risultato ("*che cosa*")
- **Procedurali**: specificano le modalità di generazione del risultato ("*come*")

Rappresentanti più significativi:

- **Algebra relazionale**: procedurale
- **Calcolo relazionale**: dichiarativo (teorico)
- **SQL** (Structured Query Language): parzialmente dichiarativo (reale)
- **QBE** (Query by Example): dichiarativo (reale)

Algebra relazionale

Costituita da un insieme di operatori

- definiti su relazioni
- che producono relazioni
- e possono essere composti

Operatori dell'algebra relazionale:

- unione, intersezione, differenza
- ridenominazione
- selezione
- proiezione
- join (join naturale, prodotto cartesiano, theta-join)

Operatori insiemistici

- le relazioni sono insiemi
- i risultati debbono essere relazioni
- è possibile applicare **unione**, **intersezione**, **differenza** solo a relazioni definite sugli stessi attributi

Unione

Laureati

Matricola	Nome	Età
7274	Rossi	42
7432	Neri	54
9824	Verdi	45

Quadri

Matricola	Nome	Età
9297	Neri	33
7432	Neri	54
9824	Verdi	45

Laureati ∪ Quadri

Matricola	Nome	Età
7274	Rossi	42
7432	Neri	54
9824	Verdi	45
9297	Neri	33

Intersezione

Laureati

Matricola	Nome	Età
7274	Rossi	42
7432	Neri	54
9824	Verdi	45

Quadri

Matricola	Nome	Età
9297	Neri	33
7432	Neri	54
9824	Verdi	45

Laureati ∩ Quadri

Matricola	Nome	Età
7432	Neri	54
9824	Verdi	45

Differenza

Laureati

Matricola	Nome	Età
7274	Rossi	42
7432	Neri	54
9824	Verdi	45

Quadri

Matricola	Nome	Età
9297	Neri	33
7432	Neri	54
9824	Verdi	45

Laureati – Quadri

Matricola	Nome	Età
7274	Rossi	42

Un'unione sensata ma impossibile

Paternità

Padre	Figlio
Adamo	Abele
Adamo	Caino
Abramo	Isacco

Maternità

Madre	Figlio
Eva	Abele
Eva	Set
Sara	Isacco

Paternità ∪ Maternità

??

Ridenominazione

- operatore monadico (con un argomento)
- "modifica lo schema" lasciando inalterata l'istanza dell'operando

Paternità

Padre	Figlio
Adamo	Abele
Adamo	Caino
Abramo	Isacco

$\rho_{Genitore \leftarrow Padre}$ (Paternità)

Genitore	Figlio
Adamo	Abele
Adamo	Caino
Abramo	Isacco

Paternità

Padre	Figlio
Adamo	Abele
Adamo	Caino
Abramo	Isacco

$\text{REN}_{\text{Genitore} \leftarrow \text{Padre}}$ **(Paternità)**

Genitore	Figlio
Adamo	Abele
Adamo	Caino
Abramo	Isacco

Maternità

Madre	Figlio
Eva	Abele
Eva	Set
Sara	Isacco

$\text{REN}_{\text{Genitore} \leftarrow \text{Madre}}$ **(Maternità)**

Genitore	Figlio
Eva	Abele
Eva	Set
Sara	Isacco

$\text{REN}_{\text{Genitore} \leftarrow \text{Padre}}$ **(Paternità)**

Genitore	Figlio
Adamo	Abele
Adamo	Caino
Abramo	Isacco

$\text{REN}_{\text{Genitore} \leftarrow \text{Madre}}$ **(Maternità)**

Genitore	Figlio
Eva	Abele
Eva	Set
Sara	Isacco

$\text{REN}_{\text{Genitore} \leftarrow \text{Padre}}$ **(Paternità)**

$\cup$

$\text{REN}_{\text{Genitore} \leftarrow \text{Madre}}$ **(Maternità)**

Genitore	Figlio
Adamo	Abele
Adamo	Caino
Abramo	Isacco
Eva	Abele
Eva	Set
Sara	Isacco

Impiegati

Cognome	Ufficio	Stipendio
Rossi	Roma	55
Neri	Milano	64

Operai

Cognome	Fabbrica	Salario
Bruni	Monza	45
Verdi	Latina	55

$$\text{REN}_{\text{Sede, Retribuzione} \leftarrow \text{Ufficio, Stipendio}}(\text{Impiegati}) \cup \text{REN}_{\text{Sede, Retribuzione} \leftarrow \text{Fabbrica, Salario}}(\text{Operai})$$

Cognome	Sede	Retribuzione
Rossi	Roma	55
Neri	Milano	64
Bruni	Monza	45
Verdi	Latina	55

Selezione

- operatore monadico
- produce un risultato che
  - ha lo stesso schema dell'operando
  - contiene un sottoinsieme delle ennuple dell'operando
  - quelle che soddisfano una condizione

Impiegati

Matricola	Cognome	Filiale	Stipendio
7309	Rossi	Roma	55
5998	Neri	Milano	64
9553	Milano	Milano	44
5698	Neri	Napoli	64

- impiegati che
  - guadagnano più di 50
  - guadagnano più di 50 e lavorano a Milano
  - hanno lo stesso nome della filiale presso cui lavorano

Selezione, sintassi e semantica

Sintassi:

SEL $_{Condizione}$ (*Operando*)

Condizione: espressione booleana (come quelle dei vincoli di ennupla)

Semantica

il risultato contiene le ennuple dell'operando che soddisfano la condizione

– impiegati che guadagnano più di 50

Impiegati

Matricola	Cognome	Filiale	Stipendio
7309	Rossi	Roma	55
5998	Neri	Milano	64
5698	Neri	Napoli	64

$$SEL_{Stipendio > 50}(Impiegati)$$

– impiegati che guadagnano più di 50 e lavorano a Milano

Impiegati

Matricola	Cognome	Filiale	Stipendio
5998	Neri	Milano	64

$$SEL_{Stipendio > 50 \text{ AND } Filiale = 'Milano'}(Impiegati)$$

– impiegati che hanno lo stesso nome della filiale presso cui lavorano

Impiegati

Matricola	Cognome	Filiale	Stipendio
9553	Milano	Milano	44

$$\mathbf{SEL}_{\mathbf{Cognome = Filiale}}(\mathbf{Impiegati})$$

Selezione e proiezione

Sono due operatori "ortogonali"

- selezione:
  - decomposizione orizzontale
- proiezione:
  - decomposizione verticale

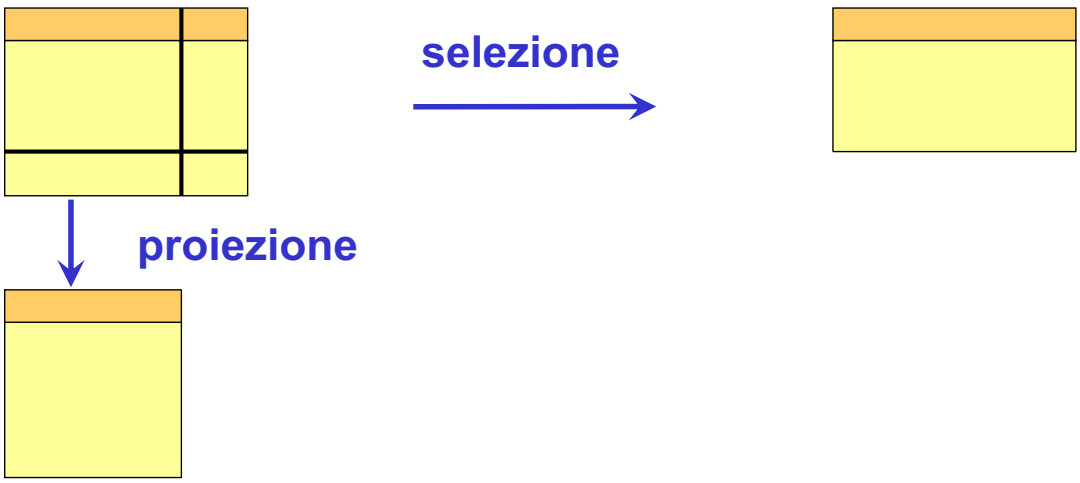

Proiezione

- operatore monadico

- produce un risultato che
  - ha parte degli attributi dell'operando
  - contiene ennuple cui contribuiscono tutte le ennuple dell'operando

Impiegati

Matricola	Cognome	Filiale	Stipendio
7309	Neri	Napoli	55
5998	Neri	Milano	64
9553	Rossi	Roma	44
5698	Rossi	Roma	64

  - per tutti gli impiegati:
    - matricola e cognome
    - cognome e filiale

Proiezione, sintassi e semantica

Sintassi

PROJ $_{\text{ListaAttributi}}$ (Operando)

Semantica

- il risultato contiene le ennuple ottenute da tutte le ennuple dell'operando ristrette agli attributi nella lista

– matricola e cognome di tutti gli impiegati

Matricola	Cognome
7309	Neri
5998	Neri
9553	Rossi
5698	Rossi

PROJ $_{\text{Matricola, Cognome}}$ (Impiegati)

– cognome e filiale di tutti gli impiegati

Cognome	Filiale
Neri	Napoli
Neri	Milano
Rossi	Roma

PROJ $_{\text{Cognome, Filiale}}$ (Impiegati)

Cardinalità delle proiezioni

- una proiezione
  - contiene al più tante ennuple quante l'operando
  - può contenerne di meno
- se X è una superchiave di R, allora $\text{PROJ}_X(R)$ contiene esattamente tante ennuple quante R

Selezione e proiezione

- Combinando selezione e proiezione, possiamo estrarre interessanti informazioni da una relazione

matricola e cognome degli impiegati che guadagnano più di 50

Matricola	Cognome
7309	Rossi
5998	Neri
5698	Neri

$$\text{PROJ}_{\text{Matricola,Cognome}}\ (\text{SEL}_{\text{Stipendio} > 50}\ (\text{Impiegati}))$$

Join

- combinando selezione e proiezione, possiamo estrarre informazioni da **una** relazione
- non possiamo però correlare informazioni presenti in relazioni diverse

- il **join** è l'operatore più interessante dell'algebra relazionale
- permette di correlare dati in relazioni diverse

Corsi e linguaggi di programmazione

- Ogni docente insegna uno o più corsi
- Ogni corso prevede l'insegnamento di zero o piu linguaggi
- Quali docenti insegnano quali linguaggi?

1	Basi di dati
2	Prog. sw
3	Reti
1	Prog. sw

SQL	Basi di dati
Java	Prog. sw
UML	Prog. sw
Java	Basi di dati

SQL	1
Java	1
UML	1
Java	2
UML	2

Join: esempio

Docente	Corso
1	BD
2	PS
3	Reti
1	PS

Corso	Ling
BD	SQL
BD	Java
PS	Java
PS	UML

Docente	Ling
1	SQL
1	Java
1	UML
2	Java
2	UML

Join naturale

- operatore binario (generalizzabile)
- produce un risultato
  - sull'unione degli attributi degli operandi
  - con ennuple costruite ciascuna a partire da una ennupla di ognuno degli operandi

Join, sintassi e semantica

- $R_1(X_1)$, $R_2(X_2)$
- R_1 JOIN R_2 è una relazione su X_1X_2

$$\{ t \text{ su } X_1X_2 \mid \text{esistono } t_1 \in R_1 \text{ e } t_2 \in R_2 \text{ con } t[X_1] = t_1 \text{ e } t[X_2] = t_2 \}$$

Un join completo

Impiegato	Reparto
Rossi	A
Neri	B
Bianchi	B

Reparto	Capo
A	Mori
B	Bruni

Impiegato	Reparto	Capo
Rossi	A	Mori
Neri	B	Bruni
Bianchi	B	Bruni

In un **join completo** ogni ennupla contribuisce al risultato.

Un join non completo

Impiegato	Reparto
Rossi	A
Neri	B
Bianchi	B

Reparto	Capo
B	Mori
C	Bruni

Impiegato	Reparto	Capo
Neri	B	Mori
Bianchi	B	Mori

Un join vuoto

Impiegato	Reparto
Rossi	A
Neri	B
Bianchi	B

Reparto	Capo
D	Mori
C	Bruni

Impiegato	Reparto	Capo

Un join completo, con n x m ennuple

Impiegato	Reparto
Rossi	B
Neri	B

Reparto	Capo
B	Mori
B	Bruni

Impiegato	Reparto	Capo
Rossi	B	Mori
Rossi	B	Bruni
Neri	B	Mori
Neri	B	Bruni

Cardinalità del join

- $R_1(A,B)$, $R_2(B,C)$

- In generale, il join di R_1 e R_2 contiene un numero di ennuple compreso fra zero e il prodotto di $|R_1|$ e $|R_2|$:

$$0 \leq |R_1 \text{ JOIN } R_2| \leq |R_1| \times |R_2|$$

- se il join coinvolge una chiave di R_2 (ovvero, B è chiave in R_2), allora il numero di ennuple è compreso fra zero e $|R_1|$:

$$0 \leq |R_1 \text{ JOIN } R_2| \leq |R_1|$$

- se il join coinvolge una chiave di R_2 (ovvero, B è chiave in R_2) ed esiste un vincolo di integrità referenziale fra B (in R_1) e R_2, allora il numero di ennuple è pari a $|R_1|$:

$$|R_1 \text{ JOIN } R_2| = |R_1|$$

Join, un'osservazione

Impiegato	Reparto
Rossi	A
Neri	B
Bianchi	B

Reparto	Capo
B	Mori
C	Bruni

Impiegato	Reparto	Capo
Neri	B	Mori
Bianchi	B	Mori

Alcune ennuple non contribuiscono al risultato: vengono "tagliate fuori"

Join esterno

- Il **join esterno** estende, con valori nulli, le ennuple che verrebbero tagliate fuori da un join (interno)

- esiste in tre versioni:
  - **sinistro**: mantiene tutte le ennuple del primo operando, estendendole con valori nulli, se necessario
  - **destro**: ... del secondo operando ...
  - **completo**: … di entrambi gli operandi ...

Join esterno sinistro

Impiegati

Impiegato	Reparto
Rossi	A
Neri	B
Bianchi	B

Reparti

Reparto	Capo
B	Mori
C	Bruni

Impiegati $\text{JOIN}_{\text{LEFT}}$ Reparti

Impiegato	Reparto	Capo
Neri	B	Mori
Bianchi	B	Mori
Rossi	A	NULL

Join esterno destro

Impiegati

Impiegato	Reparto
Rossi	A
Neri	B
Bianchi	B

Reparti

Reparto	Capo
B	Mori
C	Bruni

Impiegati $\text{JOIN}_{\text{RIGHT}}$ Reparti

Impiegato	Reparto	Capo
Neri	B	Mori
Bianchi	B	Mori
NULL	C	Bruni

Join esterno completo

Impiegati

Impiegato	Reparto
Rossi	A
Neri	B
Bianchi	B

Reparti

Reparto	Capo
B	Mori
C	Bruni

Impiegati $\text{JOIN}_{\text{FULL}}$ Reparti

Impiegato	Reparto	Capo
Neri	B	Mori
Bianchi	B	Mori
Rossi	A	NULL
NULL	C	Bruni

Join e proiezioni

Impiegato	Reparto
Rossi	A
Neri	B
Bianchi	B

Reparto	Capo
B	Mori
C	Bruni

Impiegato	Reparto	Capo
Neri	B	Mori
Bianchi	B	Mori

Impiegato	Reparto
Neri	B
Bianchi	B

Reparto	Capo
B	Mori

Proiezioni e join

Impiegato	Reparto	Capo
Neri	B	Mori
Bianchi	B	Bruni
Verdi	A	Bini

Impiegato	Reparto
Neri	B
Bianchi	B
Verdi	A

Reparto	Capo
B	Mori
B	Bruni
A	Bini

Impiegato	Reparto	Capo
Neri	B	Mori
Bianchi	B	Bruni
Neri	B	Bruni
Bianchi	B	Mori
Verdi	A	Bini

Join e proiezioni

- $R_1(X_1)$, $R_2(X_2)$

$$\text{PROJ}_{X_1}(R_1 \text{ JOIN } R_2) \subseteq R_1$$

- $R(X)$, $X = X_1 \cup X_2$

$$(\text{PROJ}_{X_1}(R)) \text{ JOIN } (\text{PROJ}_{X_2}(R)) \supseteq R$$

Prodotto cartesiano

- un join naturale su relazioni senza attributi in comune
- contiene sempre un numero di ennuple pari al prodotto delle cardinalità degli operandi (le ennuple sono tutte combinabili)

Impiegati

Impiegato	Reparto
Rossi	A
Neri	B
Bianchi	B

Reparti

Codice	Capo
A	Mori
B	Bruni

Impiegati JOIN Reparti

Impiegato	Reparto	Codice	Capo
Rossi	A	A	Mori
Rossi	A	B	Bruni
Neri	B	A	Mori
Neri	B	B	Bruni
Bianchi	B	A	Mori
Bianchi	B	B	Bruni

Theta-join

- Il prodotto cartesiano, in pratica, ha senso (quasi) solo se seguito da selezione:

$$SEL_{Condizione}\ (R_1\ JOIN\ R_2)$$

- L'operazione viene chiamata **theta-join** e indicata con

$$R_1\ JOIN_{Condizione}\ R_2$$

- La condizione di selezione è spesso una congiunzione (AND) di atomi di confronto $A_1 \vartheta\ A_2$ dove ϑ è uno degli operatori di confronto (=, >, <, …). Da questo deriva il nome “theta-join”.

- Se l'operatore è sempre l'uguaglianza (=) allora si parla di **equi-join**.

Impiegati

Impiegato	Reparto
Rossi	A
Neri	B
Bianchi	B

Reparti

Codice	Capo
A	Mori
B	Bruni

Impiegati $\text{JOIN}_{\text{Reparto=Codice}}$ Reparti

Impiegato	Reparto	Codice	Capo
Rossi	A	A	Mori
Neri	B	B	Bruni
Bianchi	B	B	Bruni

Impiegati

Impiegato	Reparto
Rossi	A
Neri	B
Bianchi	B

Reparti

Reparto	Capo
A	Mori
B	Bruni

Impiegati JOIN Reparti

Join naturale ed equi-join

Possiamo riesprimere un join naturale usando un equi-join.

Impiegati

Impiegato	Reparto

Reparti

Reparto	Capo

Impiegati JOIN Reparti

$$\text{PROJ}_{\text{Impiegato,Reparto,Capo}} (\text{SEL}_{\text{Reparto=Codice}} (\text{Impiegati JOIN REN}_{\text{Codice} \leftarrow \text{Reparto}} (\text{Reparti})))$$

Esempi

Impiegati

Matricola	Nome	Età	Stipendio
7309	Rossi	34	45
5998	Bianchi	37	38
9553	Neri	42	35
5698	Bruni	43	42
4076	Mori	45	50
8123	Lupi	46	60

Supervisione

Impiegato	Capo
7309	5698
5998	5698
9553	4076
5698	4076
4076	8123

Trovare matricola, nome, età e stipendio degli impiegati che guadagnano più di 40 milioni.

$$SEL_{Stipendio>40}(Impiegati)$$

Matricola	Nome	Età	Stipendio
7309	Rossi	34	45
5698	Bruni	43	42
4076	Mori	45	50
8123	Lupi	46	60

Trovare matricola, nome ed età degli impiegati che guadagnano più di 40 milioni.

$$PROJ_{Matricola,\ Nome,\ Età}\ (SEL_{Stipendio>40}(Impiegati)\ )$$

Matricola	Nome	Età
7309	Rossi	34
5698	Bruni	43
4076	Mori	45
8123	Lupi	46

Trovare le matricole dei capi degli impiegati che guadagnano più di 40 milioni.

Impiegati	Matricola	Nome	Età	Stipendio

Supervisione	Impiegato	Capo

$$\text{PROJ}_{\text{Capo}}\,(\text{Supervisione}\ \text{JOIN}_{\text{Impiegato=Matricola}}\ (\text{SEL}_{\text{Stipendio>40}}(\text{Impiegati})))$$

Trovare nome e stipendio dei capi degli impiegati che guadagnano più di 40 milioni.

Impiegati	Matricola	Nome	Età	Stipendio

Supervisione	Impiegato	Capo

$$\text{PROJ}_{\text{Nome,Stipendio}}\,(\text{Impiegati}\ \text{JOIN}_{\text{Matricola=Capo}}\ \text{PROJ}_{\text{Capo}}(\text{Supervisione}\ \text{JOIN}_{\text{Impiegato=Matricola}}\ (\text{SEL}_{\text{Stipendio>40}}(\text{Impiegati}))))$$

Trovare gli impiegati che guadagnano più del proprio capo, mostrando matricola, nome e stipendio dell'impiegato e del capo.

Impiegati

Matricola	Nome	Età	Stipendio

Supervisione

Impiegato	Capo

$$\text{PROJ}_{\text{Matr,Nome,Stip,MatrC,NomeC,StipC}}(\text{SEL}_{\text{Stipendio>StipC}}(\text{REN}_{\text{MatrC,NomeC,StipC,EtàC} \leftarrow \text{Matr,Nome,Stip,Età}}(\text{Impiegati}) \text{ JOIN}_{\text{MatrC=Capo}} (\text{Supervisione JOIN}_{\text{Impiegato=Matricola}} \text{Impiegati}))))$$

Trovare le matricole dei capi i cui impiegati guadagnano **tutti** più di 40 milioni.

Impiegati

Matricola	Nome	Età	Stipendio

Supervisione

Impiegato	Capo

$$\text{PROJ}_{\text{Capo}}(\text{Supervisione}) - \text{PROJ}_{\text{Capo}}(\text{Supervisione JOIN}_{\text{Impiegato=Matricola}} (\text{SEL}_{\text{Stipendio} \leq 40}(\text{Impiegati})))$$

Equivalenza di espressioni

- Due espressioni sono **equivalenti** se producono lo stesso risultato qualunque sia l'istanza attuale della base di dati
- L'equivalenza è importante in pratica perché i DBMS cercano di eseguire espressioni equivalenti a quelle date, ma meno "costose"

Un'equivalenza importante

- Effettuare le selezioni il prima possibile (**push selections**)

  Esempio: se A è attributo di R_2

  $$\text{SEL}_{A=10}(R_1 \text{ JOIN } R_2) = R_1 \text{ JOIN } \text{SEL}_{A=10}(R_2)$$

- Le selezioni tipicamente riducono in modo significativo la dimensione del risultato intermedio (e quindi il costo dell'operazione)

Selezione con valori nulli

Impiegati

Matricola	Cognome	Filiale	Età
7309	Rossi	Roma	32
5998	Neri	Milano	45
9553	Bruni	Milano	NULL

$$\text{SEL}_{\text{Età} > 40}\ (\text{Impiegati})$$

La condizione atomica è vera **solo per valori non nulli**

Un risultato non desiderabile

$$\text{SEL}_{\text{Età}>30}\ (\text{Persone}) \cup \text{SEL}_{\text{Età}\leq 30}\ (\text{Persone}) \neq \text{Persone}$$

Perché? Perché le selezioni vengono valutate separatamente!

Ma anche

$$\text{SEL}_{\text{Età}>30 \vee \text{Età}\leq 30}\ (\text{Persone}) \neq \text{Persone}$$

Perché? Perché anche le condizioni atomiche vengono valutate separatamente!

Selezione con valori nulli: soluzione

$$\text{SEL}_{\text{Età} > 40}\,(\text{Impiegati})$$

- la condizione atomica è vera solo per valori non nulli
- per riferirsi ai valori nulli esistono forme apposite di condizioni:

IS NULL

IS NOT NULL

- si potrebbe usare (ma non serve) una "logica a tre valori" (vero, falso, sconosciuto)

Quindi:

$$\text{SEL}_{\text{Età}>30}\,(\text{Persone}) \cup \text{SEL}_{\text{Età}\leq 30}\,(\text{Persone}) \cup \text{SEL}_{\text{Età IS NULL}}\,(\text{Persone})$$

$$=$$

$$\text{SEL}_{\text{Età}>30 \vee \text{Età}\leq 30 \vee \text{Età IS NULL}}\,(\text{Persone})$$

$$=$$

$$\text{Persone}$$

Impiegati

Matricola	Cognome	Filiale	Età
5998	Neri	Milano	45
9553	Bruni	Milano	NULL

$$\mathbf{SEL}_{(\text{Età} > 40)\ \text{OR}\ (\text{Età IS NULL})}\ (\mathbf{Impiegati})$$