Basi di Dati

prof. Letizia Tanca

Altri linguaggi formali di interrogazione per il Modello Relazionale dei Dati

Classificazione dei Linguaggi

LINGUAGGI **FORMALI**

- **Algebra relazionale**
- **Calcolo relazionale**
  - **Delle tuple**
  - **Dei domini**
- **Datalog**

Calcolo Relazionale

- e' una famiglia di linguaggi
  - formali
  - dichiarativi (non procedurali)
  - per formulare interrogazioni
- due tipi principali
  - calcolo relazionale delle **tuple** (TRC)
  - calcolo relazionale dei **domini** (DRC)
- ha un potere espressivo **pari a quello dell'algebra relazionale**

Definizione Formale del TRC

INTERROGAZIONI

– $\{ t \mid p(t) \}$ (tutte le tuple t per le quali e' vera $p(t)$)
– $p(t)$ e' una formula costruita tramite atomi

ATOMI

- $t \in r$
- $t_1[A_1]$ *COMP* $t_2[A_2]$
- $t[A]$ *COMP* k

COMPOSIZIONE DI FORMULE BEN FORMATE (WFF)

- un atomo e' una wff
- se p e' una wff, lo sono anche $\neg p$ e (p)
- se $p1$ e $p2$ sono wff, lo sono anche $p1 \wedge p2$, $p1 \vee p2$, $p1 \Rightarrow p2$
- se p e' una wff in cui s e' una variabile, lo sono anche
- $\exists s \in r\ (p(s))$ e $\forall s \in r\ (p(s))$

ESEMPIO

studente

MATR.	NOME	CITTA'	CL
123	Carlo	Bologna	Inf
415	Paola	Torino	Inf
702	Antonio	Roma	Log

corso

C-CORSO	TITOLO	DOCENTE
1	matematica	Barozzi
2	informatica	Meo

esame

MATR.	C-CORSO	DATA	VOTO
123	1	7/9/1997	30
123	2	8/1/1998	28
702	2	7/9/1997	20

Esempio di TRC

NOMI DEGLI STUDENTI CHE HANNO PRESO 30 IN "matematica"

$$\{ t \mid \exists t1 \in \text{studente}, \exists t2 \in \text{esame}, \exists t3 \in \text{corso}$$
$$(t[\text{NOME}] = t1[\text{NOME}] \wedge$$
$$t1[\text{MATR}] = t2[\text{MATR}] \wedge$$
$$t2[\text{C-CORSO}] = t3[\text{C-CORSO}] \wedge$$
$$t2[\text{VOTO}] = 30 \wedge$$
$$t3[\text{TITOLO}] = \text{"matematica"}) \}$$

le tuple che soddisfano la formula sono composte solamente da valori che compaiono esplicitamente nella formula o in tuple di relazioni menzionate nella formula

Proprieta' del TRC

- $p1 \wedge p2 \equiv \neg(\neg p1 \vee \neg p2)$ (DE MORGAN)
- $\forall\, t \in r\ (p(t)) \equiv \neg \exists\, t \in r\ (\neg\ p(t))$
- $p1 \Rightarrow p2 \equiv \neg\ p1 \vee p2$
- formule *unsafe:*
  - $\{ t \mid t \notin r \}$ FORNISCE UN RISULTATO INFINITO!!!
- si restringe la formulazione del calcolo delle formule ai domini attivi:
  - le tuple che soddisfano una formula possono essere composte solamente da valori che compaiono
    - esplicitamente nella formula
    - in tuple di relazioni menzionate nella formula

Esempio di TRC

MATRICOLA DEGLI STUDENTI CHE HANNO SOSTENUTO "matematica" MA NON "basi di dati"

$$\{ t \mid \exists t1 \in esame, \exists t2 \in corso$$
$$(t[MATR] = t1[MATR] \wedge$$
$$t1[C\text{-}CORSO] = t2[C\text{-}CORSO] \wedge$$
$$t2\,[TITOLO] = \text{"matematica"}) \wedge$$
$$\neg(\exists t3 \in esame, \exists t4 \in corso$$
$$(t3[MATR] = t[MATR] \wedge$$
$$t3[C\text{-}CORSO] = t4[C\text{-}CORSO] \wedge$$
$$t4[TITOLO] = \text{"basi di dati"})) \}$$

...e ora proviamo con i presidenti...

Esempio di schema di base di dati

PRESIDENTI (NOME-P, DATA-N, DATA-M, PARTITO, STATO, NOME-M)

CONGRESSI (# CONGRESSO, %S-REP, %C-REP, %S-DEM, %C-DEM)

AMMINISTRAZIONI (# AMMIN, DATA-IN, VICE-PRES, DATA-N-VP, NOME-P, DATA-N-P)

ELEZIONI (ANNO, VOTI-PRES, NOME-P, DATA-N-PRES, NOME-PERD, DATA-N-PERD, VOTI-PERD)

STATI (STATO, POPOLAZ, # AMMIN.)

PRESID-CONGR (NOME-P, DATA-N, # CONGR)

Interrogazioni

- ***Trovare l'anno di nascita del presidente J.F. Kennedy***
- ***Trovare gli anni in cui è stato eletto un presidente repubblicano proveniente dall'Illinois***
- ***Trovare i numeri di congressi presieduti dal presidente eletto nel 1955***
- ***Trovare i perdenti delle elezioni vinte da qualche presidente di nome Roosevelt***
- ***Trovare i nomi delle mogli dei presidenti provenienti dalla California eletti dopo il 1960***
- ***Trovare le persone che sono state presidenti OPPURE vicepresidenti in amministrazioni inaugurate dopo il 1880***
- ***Trovare le persone che dopo il 1880 sono state almeno una volta presidenti E almeno una volta vicepresidenti***
- ***Trovare le persone che sono state presidenti MA MAI vicepresidenti in amministrazioni inaugurate dopo il 1880***

Equivalenza tra Algebra e TRC

FACCIAMO VEDERE CHE SI POSSONO REALIZZARE I 5 OPERATORI FONDAMENTALI (in realtà la prova è più complicata di così…)

- **SELEZIONE**

  $\sigma_{A=1}\, r = \{ t \mid \exists\, t1 \in r \;\; (t1[A] = 1) \wedge \;\; t=t1 \}$

- **PROIEZIONE**

  $\Pi_{AC}\, r = \{ t \mid \exists\, t1 \in r \;\; (t[A,C] = t1[A,C]) \}$

- **PRODOTTO CARTESIANO**

  $r(A,B,C) \times s(D,E,F) = \{ t \mid \exists\, t1 \in r, \exists\, t2 \in s$

  $(t[A,B,C] = t1[A,B,C] \wedge t[D,E,F] = t2[D,E,F]) \}$

Equivalenza tra Algebra e TRC

- **UNIONE**

  $r \cup s = \{ t \mid (\exists t1 \in r, t=t1) \vee (\exists t2 \in s\ t=t2) \}$

- **DIFFERENZA**

  $r - s = \{ t \mid \exists t1 \in r\ (t=t1) \wedge \neg (\exists t2 \in s, t=t2) \}$

- **ESEMPIO DI JOIN**

  $R(A,C) \bowtie_{A=B} S(B,D) = \{ t \mid \exists t1 \in r, \exists t2 \in s$

  $(t[A,C] = t1[A,C] \wedge t[B,D] = t2[B,D] \wedge t1[A]=t2[B]) \}$

Linguaggi di query basati sulla programmazione logica

- La programmazione logica è un paradigma di programmazione basato su regole
- Linguaggio di riferimento: Prolog (1970)
- **Datalog:** "Prolog per basi di dati" (1984)
- Differenze principali rispetto a Prolog (per chi lo conosce):
  - niente simboli di funzione
  - modello di valutazione non procedurale (non SLD Resolution)

Un programma Datalog è un insieme di regole

- Ogni regola è composta da una testa (head o LHS) e da un corpo (body o RHS)

$$p :- p_1, p_2, \ldots p_n$$

- Ogni *p* è chiamato *letterale*, ed è una *istanza* di un predicato così composto:
  - nome
  - lista di argomenti tra parentesi:
    - **costanti**
    - **variabili**
    - **simbolo "don't care" (_) (non possono apparire nella testa)**
- **Safety:** le variabili del LHS devono apparire in una relazione del RHS

Alcune regole

- *Dipendente* (*X*,*Y*) :- *Persona*(*X*), *Assunto(X,Y,D), Ditta(Y), D< ‘ “9.11.2005”.*

- *Parte_di*(*X*,*Z*) :- *Prodotto(X), Prodotto(Y), Prodotto(Z), Parte_di(X,Y), Parte_di(Y,Z*).

- *Ospite(X,Y)* :- *Persona(X), Luogo_di_Soggiorno(Y*), *Dorme*(*X*,*Y*).

Una regola può essere formata dalla sola testa: *Parte_di(a,b).* Mi dice che *a è parte del prodotto b*
Queste particolari regole si chiamano *fatti*

Base di dati d'esempio per Datalog

GENITORI

Genitore	Figlio
Carlo	Antonio
Carlo	Gianni
Anna	Antonio
Anna	Gianni
Gianni	Andrea
Antonio	Paola

PERSONA

Nome	Età	Sesso
Carlo	65	M
Antonio	40	M
Anna	60	F
Gianni	43	M
Andrea	22	M
Paola	20	F

Regole Datalog e BD

- Ciascuna tupla corrisponde a un **fatto di base** (o *letterale ground*). Ad esempio:

  Genitori("Carlo","Antonio").

  rappresenta la prima tupla della relazione GENITORI

- Esempio di regola:

  Padre(X,Y):- Persona(X,_,'M'),Genitori(X,Y).

Unificazione

- **Interpretazione** della regola:

  Padre(X,Y):- Persona(X,_,'M'),Genitori(X,Y).

  - *LHS è vero se RHS è vero*
  - *RHS è vero se*, per ogni letterale di RHS, tutte le sue variabili sono *unificabili*, ovvero *sostituibili*, con valori costanti *che rendono vero il letterale*

- ***Persona*(*X*,_,'M'): le unificazioni possibili per *X* sono:

  {"Carlo", "Antonio", "Gianni", "Andrea"}

- ***Genitori*(*X*,*Y*): le unificazioni possibili per la coppia *X*,*Y* sono: {("Carlo","Antonio"), etc ...} (l'intero contenuto di GENITORI)**

Interpretazione delle regole Datalog

- Le sostituzioni per *X* che vanno bene sono

  {"Carlo","Gianni", "Antonio" }

- Per le variabili *X* e *Y* si ottengono le seguenti coppie di sostituzioni

{ ("Carlo", "Antonio"), ("Carlo", "Gianni"), ("Gianni", "Andrea"), ("Antonio", "Paola")}

Corrispondenza tra Datalog e l'algebra relazionale

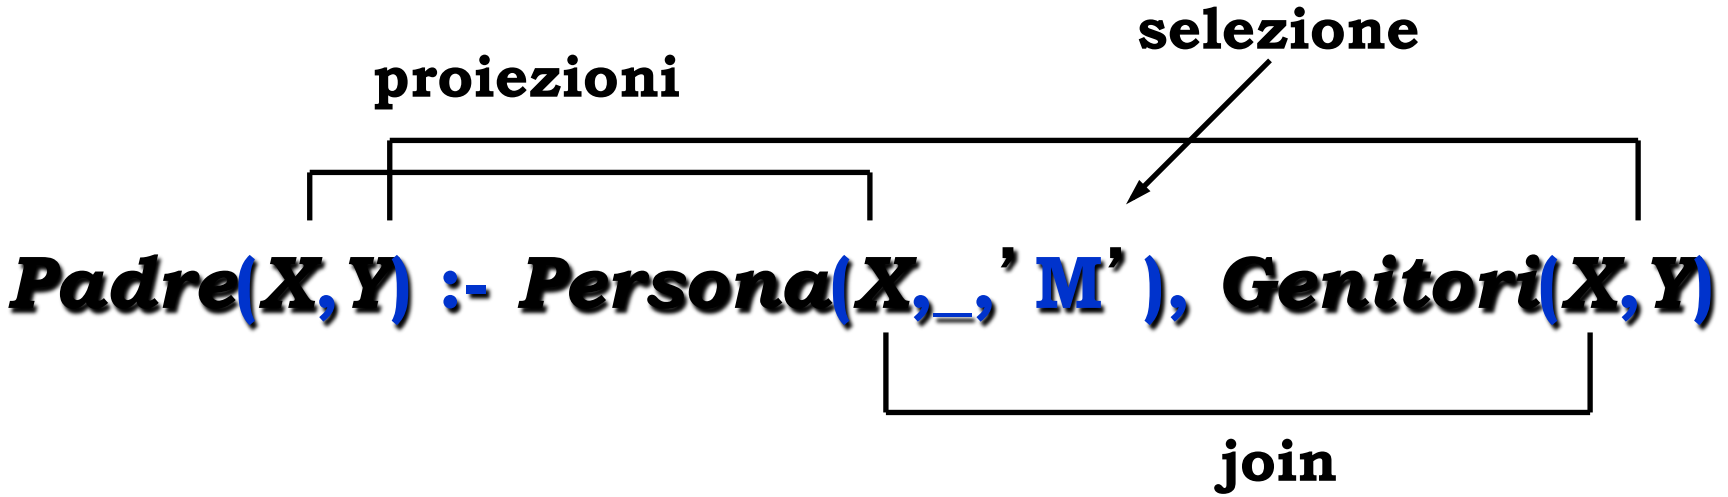

- Espressione corrispondente in algebra relazionale:

PADRE = $\Pi_{1,5}\ \sigma_{3 = \text{'M'}}$ (PERSONA $\triangleright\!\triangleleft_{1 = 1}$ GENITORI)

Database estensionale e intensionale

- Database estensionale (**EDB**): insieme delle tabelle presenti nel DB
- Database intensionale (**IDB**): insieme dei predicati che sono a sinistra in una regola

  - ***è la conoscenza dedotta a partire da EDB***

- Normalmente si impone **EDB ∩ IDB = ∅**

Query in Datalog

•Le query sulla base di dati estensionale si esprimono come "***goal***" :

?- genitori("Anna",X)

• Valutazione: si cerca una tupla della relazione GENITORI e una sostituzione che unifichi con la variabile *X*

• Si ottiene *X* = *"Antonio"* oppure *X*=*"Gianni"*

NOTA: Un goal senza variabili restituisce *True* o *False*

- ?- *genitori* ("Anna","Antonio") ⇒ *True*
- ?- *genitori* ("Anna","Andrea") ⇒ *False*

Query in Datalog (II)

•Anche le query sull'intera base di dati (EDB + IDB) si esprimono come "***goal***":

?- Padre("Carlo",X)

• Valutazione: si cerca una regola che definisca *Padre* e una sostituzione che unifichi con la variabile *X*

• Si ottiene *X* = *"Antonio"* oppure *X*=*"Gianni"*

NOTA: anche qui un goal senza variabili restituisce *True* o *False*

- ?- *Padre*("Carlo","Antonio") ⇒ *True*
- ?- *Padre*("Carlo","Andrea") ⇒ *False*

Query in Datalog (III)

•Le query sull'intera base di dati (EDB + IDB) si esprimono come "***goal***":

?- Padre("Carlo",X)

questa query esprime una semplice selezione

• per esprimere una query complessa, occorre scrivere prima delle regole che definiscano un predicato intensionale complesso e poi un goal su quel predicato.

Esempio: ***trovare tutti i fratelli di Carlo:***

Fratello(X,Y) :- Genitori(Z,X), Genitori(Z,Y), X≠Y. → definisco il concetto di "fratello"

?- Fratello("Carlo",X). → esprimo il goal su questo concetto

Altre regole sulla stessa BD

- *Madre*(*X*,*Y*) :- *Persona*(*X*,_,'F'), *Genitori*(*X*,*Y*).
- *Nonno*(*X*,*Z*) :- *Genitori*(*X*,*Y*), *Genitori*(*Y*,*Z*).
- *Zio*(*X*,*Y*) :- *Persona*(*X*,_,'M'), *Fratello*(*X*,*Z*), *Genitori*(*Z*,*Y*).
- *Fratello*(*X*,*Y*) :- *Genitori*(*Z*,*X*), *Genitori*(*Z*,*Y*), $X \neq Y$.

Potere espressivo di Datalog

- Datalog senza negazione permette di rappresentare gli operatori {σ, Π, ×, ∪}
- {σ, Π, ×} già visti
- Per l'unione si usano più regole con la stessa testa; P = R ∪ S:

$$P(X,Y) \text{ :- } R(X,Y).$$
$$P(X,Y) \text{ :- } S(X,Y).$$

- Per la differenza serve il *not*; P = R - S:

$$P(X,Y) \text{ :- } R(X,Y), \neg S(X,Y)$$

- La negazione VA TENUTA SOTTO CONTROLLO

Esempio di schema di base di dati

PRESIDENTI (NOME-P, DATA-N, DATA-M, PARTITO, STATO, NOME-M)

CONGRESSI (# CONGRESSO, %S-REP, %C-REP, %S-DEM, %C-DEM)

AMMINISTRAZIONI (# AMMIN, DATA-IN, VICE-PRES, DATA-N-VP, NOME-P, DATA-N-P)

ELEZIONI (ANNO, VOTI-PRES, NOME-P, DATA-N-PRES, NOME-PERD, DATA-N-PERD, VOTI-PERD)

STATI (STATO, POPOLAZ, # AMMIN.)

PRESID-CONGR (NOME-P, DATA-N, # CONGR)

Interrogazioni

- ***Trovare l'anno di nascita del presidente J.F. Kennedy***
- ***Trovare gli anni in cui è stato eletto un presidente repubblicano proveniente dall'Illinois***
- ***Trovare i perdenti delle elezioni vinte da qualche presidente di nome Roosevelt***
- ***Trovare i nomi delle mogli dei presidenti provenienti dalla California eletti dopo il 1960***
- ***Trovare le persone che sono state presidenti OPPURE vicepresidenti in amministrazioni inaugurate dopo il 1880***
- ***Trovare le persone che sono state presidenti E ANCHE vicepresidenti in qualche amministrazione inaugurata dopo il 1880***
- ***Trovare le persone che sono state presidenti MA MAI vicepresidenti in amministrazioni inaugurate dopo il 1880***

Negazione in Datalog

- Alcuni letterali del corpo possono essere negati
- L'uso della negazione in Datalog aumenta il potere espressivo del linguaggio
- L'uso della negazione richiede cautela:

  ***q*(*X*) :- ¬ *p*(*X*).**

  ***p*(0).**

  ……e tutti gli altri sono "non P" ?

  ?- q(X) produce un risultato infinito!

  → Ancora una volta si rischiano interrogazioni UNSAFE

Query ricorsive

- Datalog con negazione ha quindi un potere espressivo almeno pari all'algebra relazionale

- In effetti ha un potere superiore, perché permette l'espressione di query ricorsive

- Una query ricorsiva (immediata) presenta il letterale della testa all'interno del corpo della regola:

$$Antenato(X,Y) \text{ :- } Genitore(X,Y).$$
$$Antenato(X,Y) \text{ :- } Antenato(X,Z), Genitore(Z,Y).$$

Valutazione delle query ricorsive

- Nella base dati d'esempio si ottiene il risultato illustrato a fianco

ANTENATO

Carlo	**Antonio**
Carlo	**Gianni**
Anna	**Antonio**
Anna	**Gianni**
Gianni	**Andrea**
Antonio	**Paola**
Carlo	**Andrea**
Carlo	**Paola**
Anna	**Andrea**
Anna	**Paola**

Nuovi elementi rispetto a GENITORE

Meccanismo di valutazione

Viene eseguito il seguente processo iterativo:
ad ogni iterazione *applico le regole e unisco il risultato al risultato precedente*

$\mathbf{ANTENATO^0} \Leftarrow \varnothing$

$\mathbf{ANTENATO^1} \Leftarrow \mathbf{GENITORE}$

$\mathbf{ANTENATO^2} \Leftarrow [(\Pi_{1,4}\ (\mathbf{ANTENATO^1} \triangleright\!\triangleleft_{2=1} \mathbf{GENITORE}\ ) \cup \mathbf{GENITORE}] \cup \mathbf{ANTENATO^1}$

$\mathbf{ANTENATO^3} \Leftarrow [\ \Pi_{1,4}\ (\mathbf{ANTENATO^2} \triangleright\!\triangleleft_{2=1} \mathbf{GENITORE}\ ) \cup \mathbf{GENITORE}] \cup \mathbf{ANTENATO^2}$

.....

fino a quando $\mathbf{ANTENATO^n}$ risulta pari a $\mathbf{ANTENATO^{n-1}}$ (**punto fisso**)

Predicati e funzioni

- Nella definizione delle regole si possono usare predicati speciali
  - operatori di confronto:
    = (unificazione), ≠, <, ≤, >, ≥
  - funzioni aritmetiche:
    +, -, *, ÷
- Bisogna fare molta attenzione, anche:

  ***n*(*X*) :- *n*(*X* - 1).**

  ***n*(0).**

  ***?- n*(*X*)** produce un risultato infinito!

Regole corrette

Le regole devono essere *ben formate:*

- La negazione deve essere *safe:*
  tutte le variabili di un letterale negato (o di un letterale con predicati built-in) devono comparire anche in un letterale positivo del corpo della regola:
  es. ***S(X) :- ¬ R(X)*** non va bene
- La negazione deve essere *stratificata:*
  in sintesi, non ci devono essere cicli di dipendenza tra letterali negati. Ad es.:

  P(X) :- R(X),S(Y,X).
  R(Y) :- T(X,Y), ¬ P(Y) non va bene

Problemi con la negazione nei programmi ricorsivi

- **Se adottiamo in modo ingenuo la procedura di valutazione iterativa descritta prima, possiamo incontrare problemi**

Es:

***Antenato*(*X*,*Y*) :- *Genitore*(*X*,*Y*).**

***Antenato*(*X*,*Y*) :- *Antenato*(*X*,*Z*),*Genitore*(*Z*,*Y*).**

Non-ant (X,Y) :- Persona(X,_,_), Persona (Y,_,_),

***¬ Antenato*(*X*,*Y*).**

- **Al primo passo di iterazione, calcoliamo NONANT sottraendo il valore corrente della relazione ANTENATO (GENITORE) dal prodotto cartesiano delle persone**
- **Al secondo passo di iterazione, aggiungiamo al valore precedente di NONANT il nuovo valore computato, CHE SARA' PIU' PICCOLO, etc**
- **Il risultato finale sarà scorretto, perché conterrà tutte le persone che non hanno tra loro un rapporto genitore-figlio**

Problemi con la negazione nei programmi ricorsivi

- **La soluzione sta nello STRATIFICARE il programma**

Strato 1:

Antenato(X,Y) :- Genitore(X,Y).

Antenato(X,Y) :- Antenato(X,Z),Genitore(Z,Y).

Strato 2:

Non-ant (X,Y) :- Persona(X,_,_), Persona (Y,_,_),

¬ Antenato(X,Y).

- **Al livello dello strato 1, calcoliamo iterativamente la relazione ANTENATO come prima.**
- **Una volta raggiunto il punto fisso, calcoliamo la relazione NON-ANT sottraendo il valore finale della relazione ANTENATO dal prodotto cartesiano delle persone**

Problemi con la negazione nei programmi ricorsivi

- **Non tutti i programmi sono stratificabili**
- **Se il grafo delle dipendenze di un programma non presenta cicli allora il programma è stratificabile**

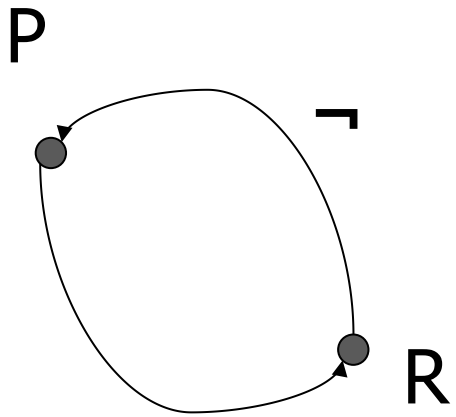

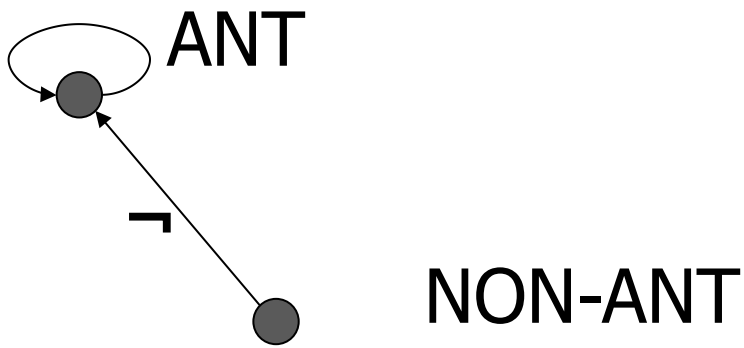

Non STRATIFICABILE

STRATIFICABILE

Usi di Datalog

Datalog costituisce anche un *linguaggio per la definizione di viste e di vincoli*

Esempi di vincoli:

incorrectdb1(X,Y) :- Madre(X,Z), Madre(Y,Z), X≠Y.
incorrectdb2(X) :- Antenato(X,X).
incorrectdb3( ) :-Genitori(X,Z),¬Persona(X,_,_).

Se includo le variabili nella testa posso ricavare gli oggetti che hanno causato la violazione

Riepilogo della terminologia Datalog

Relazione	→	***Predicato***
Attributo	→	***Argomento***
Tupla	→	***Fatto***
Vista	→	***Regola***
Interrogazione	→	***Goal***

Altri programmi logici ricorsivi

- **I cugini della stessa generazione sono i figli di cugini della stessa generazione**
  ***sgc*(*X*,*X*).**
  ***sgc*(*X*,*Y*) :- *genitore*(*Z*,*X*), *sgc*(*Z*,W),*genitore*(*W*,*Y*).**

- **Supervisori e subordinati**
  supervisore(X,Y) :- sup_diretto(X,Y).
  supervisore(X,Y) :- sup_diretto(X,Z),supervisore(Z,Y).

  subordinato(X,Y) :- supervisore(Y,X).
  incorrectdb1(X) :- supervisore(X,X).
  incorrectdb2(X,Y,Z) :- sup_diretto (X,Y), sup_diretto(Z,Y), X ≠ Z.

- **Generazione della distinta base**
  componente(X,Y):- parte_di(X,Y).
  componente(X,Y):- parte_di(X,Z),componente(Z,Y).

Esercizi (A)

CLIENTE(CodiceFiscale, Cognome, Nome, DataNascita, Sesso, Nazionalità)

ALBERGO(PartitaIVA, NomeAlbergo, Località, NomeProprietario)

SERVIZI OFFERTI(PIVA-Albergo, NomeServizio)

PRENOTAZIONE(PIVA-Albergo, CF-Cliente, Datainizio, NCamera, Tariffagiornaliera, Datafine)

1. *Estrarre il nome e il cognome dei clienti che non hanno mai prenotato camere nell'albergo "Del Sole" di Torino.*
2. *Estrarre la partita IVA di ogni albergo il cui proprietario ha anche un albergo in una diversa località.*
3. *Estrarre i clienti che hanno prenotato un albergo di Torino per un periodo superiore a un mese oppure hanno prenotato un albergo che offre la sauna in una città qualsiasi.*

Esercizi (B)

LABORATORIO(Numero, NumeroPosti)

PRENOTAZIONE(NumeroLab, Data, OraInizio, OraFine, DocTitolCorso, Esercitatore)

DOCENTE(NomeDocente, Dipartimento, Posizione, Materia,#prenot)

1. *Trovare i laboratori che sono stati prenotati da un docente ordinario di "Basi di dati", ma che non hanno alcuna prenotazione relativa ad un docente del "Dipartimento di Ingegneria dei Sistemi".*
2. *Trovare il nome e il dipartimento del docente che ha effettuato il maggior numero di prenotazioni*
3. *Trovare le informazioni dei laboratori che non sono mai stati prenotati né da un "professore ordinario" né da un esercitatore del dipartimento "DEI"*