7.előadáshoz kieg.: Adatbázisok-I.

dr. Hajas Csilla (ELTE IK)
http://sila.hajas.elte.hu/

Logika a relációs lekérdezésekhez: Datalog és Rekurzió (Eljut feladat)

Tankönyv:

5.3.-5.4. Logika a relációkhoz: Datalog

10.2. WITH munkatáblák a SELECT-hez, Rekurzív lekérd.: WITH RECURSIVE

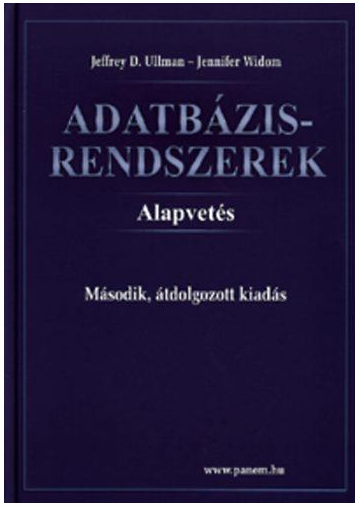

Az előadások Ullman-Widom: Adatbázisrendszerek Alapvetés c. tankönyv alapján készültek, forrás:
http://infolab.stanford.edu/~ullman/dscb.html

Témakörök

Tankönyv

5.3. Logika a relációkhoz: Datalog

5.4. A relációs algebra és nem-rekurzív biztonságos Datalog kifejező erejének összehasonlítása

10.2. Az Eljut-feladat megoldása

(a.) Datalogban (monoton, lineáris rekurzió)

(b.) SQL-ben WITH RECURSION utasítással

Oracle kiegészítések - az Eljut feladat megoldása:

(c.) Eljut feladat PL/SQL-ben (illetve SQL/PSM-ben)

(d.) Oracle megoldások/új: WITH alkérdés faktorizáció

(e.) Oracle megoldások/régi: CONNECT BY PRIOR

Következik…

- Relációs algebra korlátai: bizonyos típusú lekérdezéseket nem tudunk relációs algebrával kifejezni…
- Nézzünk meg olyan logikai felépítést, amivel az ilyen rekurzív jellegű lekérdezések könnyen megoldhatók.
- Ez a nyelv: a Datalog

Milyen fontos rekurzív feladatok vannak?

I. Hierarchiák bejárása

- Leszármazottak-ősök ParentOf(parent,child)
  - Find all of Mary's ancestors
- Vállalati hierarchia felettes-beosztott

  Employee(ID,salary)

  Manager(mID,eID)

  Project(name,mgrID)
  - Find total salary cost of project 'X'
- Alkatrész struktúra (mely alkatrésznek mely alkatrész része)

Milyen fontos rekurzív feladatok vannak?

II. Gráf jellegű bejárások

- Repülőgép járatok, eljut-feladat

  Flight(orig,dest,airline,cost)
  - Find cheapest way to fly from ‘A’ to ‘B’
- Közösségi hálók

  Ki-kinek az ismerőse, Twitterben ki-kit követ

Kiegészítés a gráf adatbázisokról

- Gráfok könnyen megadhatók relációs táblával, a gráf lekérdezések egyre gyakoribb feladatok, ezek relációs megoldása hatékonysági kérdés. Vannak kimondottan gráf-adatbázisok.

Logika, mint lekérdező nyelv

- Datalog: logikai, szabály-alapú nyelv szabály: IF feltétel THEN eredmény, ahol a feltétel relációkkal legyen megadható és az eredmény pedig az output tábla sorait eredményezze
- A példa a Sörivók adatbázison alapszik

  Látogat(név, söröző),
  Szeret(név, sör),
  Felszolgál(söröző, sör, ár).
- Adjunk meg egy olyan szabályt, amely lekérdezi a „boldog” sörivókat, akik olyan söröző t látogatnak, ahol felszolgálnak olyan sört, amelyet szeretnek.

Datalog szabályok felépítése

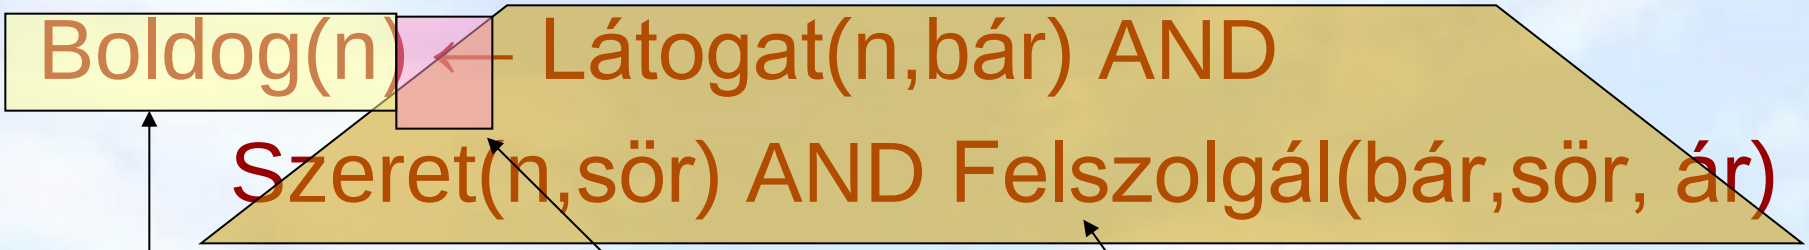

Szabály feje = „akkor”
egy egyszerű részcél

Szabály törzse = „ha” =
részcélok AND-el kapcsolva

„if-then” („ha-akkor”) szabályok

Részcélok: relációs atomi formulák (argumentumai változók vagy konstansok), akkor igaz, ha a behelyettesítési értékekből álló n-est tartalmazza a rel. atomi formulához tartozó tábla

Interpretáció: n akkor boldog, ha létezik olyan bár, sör, ár érték, amire (n,bár) sora a Látogat táblának, stb, többire is.

Példa: Aritmetikai részcélok

- Példa: Egy sört akkor mondjuk, hogy “olcsó”, ha van legalább két söröző, ahol a sör $2-nál kevesebbe kerül.

  Olcsó(sör) ← Felszolgál(bar1,sör,ár1) AND
  Felszolgál(bar2,sör,ár2) AND ár1 < 2.00
  AND ár2 < 2.00 AND bar1 <> bar2

- Feladatok: Írjuk át SQL SELECT utasításra ezt is és az előző oldalon levő szabályt is!
- Átírás ellenőrzése egy későbbi lapon lesz az átírásoknál: SQL --- alap relációs algebra --- --- (nem rekurzív) biztonságos Datalog program

Negált részcélok

- NOT in front of a subgoal negates its meaning.
- Example: Think of Arc(a,b) as arcs in a graph.
  - S(x,y) says the graph is not transitive from *x* to *y* ; i.e., there is a path of length 2 from *x* to *y*, but no arc from *x* to *y*.

S(x,y) ← Arc(x,z) AND Arc(z,y)
AND NOT Arc(x,y)

Biztonságossági elvárás

- A szabályok kiértékelhetőek legyenek, ehhez:
- A szabályban szereplő minden változónak elő kell fordulnia a törzsben nem-negált relációs atomban

Biztonságos szabályok

- A rule is *safe* if:
  1. Each distinguished variable,
  2. Each variable in an arithmetic subgoal, and
  3. Each variable in a negated subgoal,

  also appears in a nonnegated,
  relational subgoal, amivel az x korlátozott:
  - pred(x, y, …) argumentuma (értéke a táblából)
  - vagy x=c (konstans)
  - vagy x=y (ahol y korlátozott)
- Safe rules prevent infinite results.

Példa: Nem biztonságos szabályokra

- Each of the following is unsafe and not allowed:
  1. $S(x) \leftarrow R(y)$
  2. $S(x) \leftarrow R(y)$ AND $x < y$
  3. $S(x) \leftarrow R(y)$ AND NOT $R(x)$
- In each case, an infinity of *x* 's can satisfy the rule, even if *R* is a finite relation.

Datalog programok

- Datalog program = collection of rules.
- In a program, predicates can be either
  1. EDB relációk = Extensional Database = stored table (csak a törzsben szereplő relációk)
  2. IDB relációk = Intensional Database = relation defined by rules (szerepel fej-ben)
- Never both! No EDB in heads.

Datalog programok kiértékelése

- As long as there is no recursion, we can pick an order to evaluate the IDB predicates, so that all the predicates in the body of its rules have already been evaluated.
- If an IDB predicate has more than one rule, each rule contributes tuples to its relation.

Példa: Datalog program

- Using EDB Sells(bar, beer, price) and Beers(name, manf), find the manufacturers of beers Joe doesn't sell.

  JoeSells(b) ← Sells('Joe''s Bar', b, p)

  Answer(m) ← Beers(b,m)

  AND NOT JoeSells(b)

Példa: Kiértékelése

- Step 1: Examine all Sells tuples with first component ’Joe’’s Bar’.
  - Add the second component to JoeSells.
- Step 2: Examine all Beers tuples (b,m).
  - If *b* is not in JoeSells, add *m* to Answer.

Datalog kifejező ereje

- Rekurzió nélkül a biztonságos Datalog program kifejező ereje megegyezik az alap relációs algebrával (azok és csak azok a lekérdezések fejezhetők ki az egyikben, mint a másikban és viszont)
  - Mégpedig ugyanaz, mint az SQL-ben select-from-where záradékokkal (összesítések és csoportosítás nélkül)
- Rekurzív biztonságos Datalog kifejező ereje nagyobb, mint az alap relációs algerba és SQL kifejező ereje (lásd Eljut feladat)

Relációs algebrai kifejezések átírása nem-rekurzív Datalog programra

- Mi a leggyakrabban előforduló típus, amiből építkezek? $\Pi_{Lista}(\sigma_{Felt}(R \bowtie S \bowtie \ldots)$

  Ezt a komponenst támogatja legerősebben az SQL is: SELECT lista

  FROM táblák összekapcsolása

  WHERE felt

  Ez felel meg egy Datalog szabálynak.

- Halmazműveletek: kezdjük ezzel, hogyan lehet a metszetet és különbséget Datalog szabállyal, és az egyesítést Datalog programmal kifejezni.

Relációs algebra és Datalog ---1

Rel.algebrai műveletek hogyan néznek ki Datalogban?

Halmazműveletek: T.f.h $R(x_1,...,x_n)$, $S(x_1,...,x_n)$

predikátumokhoz tartozó reláció $R(A_1,...,A_n)$, $S(A_1,...,A_n)$

- $R \cap S$ metszetnek megfelelő szabály:

  $Válasz(x_1,...,x_n) \leftarrow R(x_1,...,x_n)$ AND $S(x_1,...,x_n)$
- R-S különbségnek megfelelő szabály:

  $Válasz(x_1,...,x_n) \leftarrow R(x_1,...,x_n)$ AND NOT $S(x_1,...,x_n)$
- $R \cup S$ unió műveletet egyetlen szabállyal nem tudom felírni, mert a törzsben csak AND lehet, OR nem. Ehhez több szabályból álló Datalog program kell:

  $Válasz(x_1,...,x_n) \leftarrow R(x_1,...,x_n)$
  $Válasz(x_1,...,x_n) \leftarrow S(x_1,...,x_n)$

Relációs algebra és Datalog ---2

Kiválasztás:

- $\sigma_{x_i \theta x_j}(R)$ kifejezésnek megfelelő szabály :
  $Válasz(x_1,...,x_n) \leftarrow R(x_1,...,x_n)$ AND $x_i \theta x_j$
- $\sigma_{x_i \theta c}(E1)$ kifejezésnek megfelelő szabály:
  $Válasz(x_1,...,x_n) \leftarrow R(x_1,...,x_n)$ AND $x_i \theta c$

Vetítés:

- $\Pi_{A_{i1},...,A_{ik}}(R)$ kifejezésnek megfelelő szabály:
  $Válasz(x_{i_1},...,x_{i_k}) \leftarrow R(x_1,...,x_n)$

Megjegyzés: név nélküli anonymus változók, amelyek csak egyszer szerepelnek és mindegy a nevük azt aláhúzás helyettesítheti. Például:

HosszúFilm(c,é) ← Film(c,é,h,_,_,_) AND h ≥ 100

Relációs algebra és Datalog ---3

Természetes összekapcsolás: Tegyük fel, hogy
$R(A_1,...,A_n, C_1, \ldots, C_k)$ és $S(B_1,...,B_m, C_1, \ldots, C_k)$

- $R \bowtie S$ kifejezésnek megfelelő szabály:

  $Válasz(x_1,...,x_n,y_1,...,y_m, z_1,\ldots, z_k) \leftarrow$

  $\leftarrow R(x_1,...,x_n, z_1, \ldots, z_k)$ AND $S(y_1,...,y_m, z_1, \ldots, z_k)$
- A felírt szabályok biztonságosak.
- Minden Q relációs algebrai kifejezéshez van nem rekurzív, biztonságos, negációt is tartalmazó Datalog program, amelyben egy kitüntetett IDB predikátumhoz tartozó kifejezés ekvivalens a Q lekérdezéssel.
- A nem rekurzív, biztonságos, negációt is tartalmazó Datalog kifejezőerő tekintetében EKVIVALENS a relációs algebrával.

Biztonságos Datalog program átírása SQL-be

- Először a nem-rekurzív biztonságos Datalog programok SQL-be való átírását nézzük meg (példákon keresztül is), majd ezután vizsgáljuk meg a rekurzív Datalog programok átírását egyrész SQL WITH RECURSIVE szerint, majd SQL/PSM (PL/SQL) programban megvalósítva.
- Egy Datalog szabály megfelel az SQL-ben egy [SELECT lista FROM táblák WHERE feltétel]-nek
- Datalog program: halmazműveletek felismerése (ugyanazok a változók) és átírva SQL-be. Példák:

Példa: Datalog átírása SELECT-re

- Szeret(Név, Gyümölcs) sémájú tábla alapján
  Kik szeretik az almát is és a körtét is logikai megoldását írjuk át SQL SELECT utasításra!

Válasz(N) ← Szeret(N,'alma') AND Szeret(N,'körte')

A törzs két predikátumában megegyeznek a szabad változók, ami a metszet halmazműveletnek felel meg:

```
SELECT Név FROM Szeret WHERE Gyümölcs='alma'
    INTERSECT
SELECT Név FROM Szeret WHERE Gyümölcs='körte';
```

Példa: Datalog átírása SELECT-re

- Az előző szabály másik ekvivalens átírása

Válasz(N) ← Szeret(N,'alma') AND Szeret(N,'körte')

Ez a szabály ugyanaz, mintha kiírnánk a változókat:

Válasz(N1) ← Szeret(N1,Gy1) AND Szeret(N2,Gy2)
AND N1=N2 AND Gy1= 'alma' AND Gy2='körte'

Ennek a másik logikának megfelelő SELECT pedig:

```
SELECT s1.Név FROM Szeret s1, Szeret s2
WHERE s1.Név= s2.Név AND s1.Gyümölcs='alma'
        AND s2.Gyümölcs='körte';
```

Az Eljut-feladat

Tankönyv 10.2. fejezet példája (az ELJUT feladat)

- Jaratok(legitarsasag, honnan, hova, koltseg, indulas, erkezes) táblában repülőjáratok adatait tároljuk.
- A járatok táblát létrehozó script:

  http://people.inf.elte.hu/sila/eduAB/jaratok_tabla.txt
- Mely (x,y) párokra lehet eljutni x városból y városba?
- Ezt egy relációs algebrai kifejezésként nem tudjuk megadni zárt alakban, klasszikus SQL SELECT utasítással sem tudjuk kifejezni, csak azt tudjuk, hogy átszállás nélkül, egy, két, stb… átszállással:

Az Eljut-feladatnak nincs algebrai megoldása

```
select distinct honnan, hova
    from jaratok
union
select j1.honnan, j2.hova
    from jaratok j1, jaratok j2
    where j1.hova=j2.honnan
union
select j1.honnan, j3.hova
    from jaratok j1, jaratok j2, jaratok j3
    where j1.hova=j2.honnan
    and j2.hova=j3.honnan
--- union stb... Ezt így nem lehet felírni…
```

Az Eljut-feladat Datalogban

Tankönyv 10.2. fejezet példája (az ELJUT feladat)

- Jaratok(legitarsasag, honnan, hova, koltseg, indulas, erkezes) EDB-táblában repülőjáratok adatait tároljuk.

  Mely (x,y) párokra lehet eljutni x városból y városba?

- Datalogban felírva (lineáris rekurzió)

  Eljut(x, y) <- Jaratok(l, x, y, k, i, e)
  Eljut(x, y) <- Eljut(x, z) AND Jaratok(l, z, y, k, i, e)

- Vagy másképp felírva Datalogban (mi a különbség?)

  Eljut(x, y) <- Jaratok(_, x, y, _, _, _) --- anonimus változók
  Eljut(x, y) <- Eljut(x, z) AND Eljut(z, y) --- nem lineáris rek.

Az Eljut feladat SQL-99 szabványban

- Datalog LINEÁRIS, MONOTON rekurzió átírható:
  Eljut(x, y) <- Jaratok(l, x, y, k, i, e)
  Eljut(x, y) <- Eljut(x, z) AND Jaratok(l, z, y, k, i, e)

- Hova, mely városokba tudunk eljutni Budapestről?

```
WITH RECURSIVE Eljut(honnan, hova) AS
        (SELECT honnan, hova FROM Jaratok
      UNION
          SELECT Eljut.honnan, Jaratok.hova
          FROM Eljut, Jaratok
          WHERE Eljut.hova = Jaratok.honnan)
SELECT hova FROM Eljut WHERE honnan='Bp';
```

SQL-99 szabvány: Rekurzív lekérdezés

- A WITH utasítás több ideiglenes relációra vonatkozó definíciója:

WITH [RECURSIVE] R_1 AS <R_1 definíciója>
[RECURSIVE] R_2 AS <R_2 definíciója>
...
[RECURSIVE] R_n AS <R_n definíciója>
< R_1,R_2,...,R_n relációkat tartalmazó lekérdezés>

Másik példa: Rekurzív Datalog

- A testvérek (féltestvérek) gyerekei első unokatestvérek, az első unokatestvérek gyerekei másod-unokatestvérek, és így tovább. Hívjuk egyszerűen unokatestvéreknek, akik valamilyen szinten unokatestvérek. A rokonok azok, akik közös ősnek leszármazottjai.
- Milyen Datalog program írja ezt le?

testvér(x,y) ←gyerek(x,z),gyerek(y,z),x ≠y
unokatestvér(x,y) ←gyerek(x,z),gyerek(y,v),testvér(z,v)
unokatestvér(x,y) ←gyerek(x,z),gyerek(y,v),unokatestvér(z,v)
rokon(x,y) ←testvér(x,y)
rokon(x,y) ←rokon(x,z),gyerek(y,z)
rokon(x,y) ←rokon(z,y),gyerek(x,z)

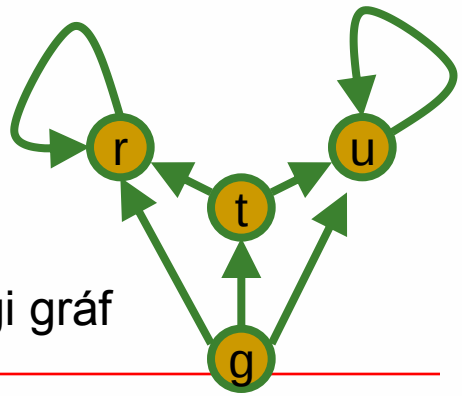

Függőségi gráf

Példa folyt:Rekurzív Datalog átírása SQL-be

```
WITH
  T(x,y) as (select G1.u x, G2.w y from G G1,G G2
        where G1.w=G2.u and G1.u<>G2.u),
  RECURSIVE U(x,y) as (select G1.u x, G2.u y
        from G G1, G G2, T where T.x=G1.w and T.y=G2.u)
                UNION (select G1.u x, G2.u y
        from G G1, G G2, U where U.x=G1.w and U.y=G2.u),
  RECURSIVE R(x,y) as (select * from T) UNION
      (select R.x x,G.u y from R,G where R.y=G.w) UNION
      (select G.u x, R.y y from R,G where R.x=G.w)

 (select T.x, T.y, 'T' from T union
  select U.x, U.y, 'U' from U union
  select R.x, R.y, 'R' from R);
```

Rekurzív lekérdezések

- Datalog rekurzió segít megérteni az SQL-99 szabványban bevezetett rekurzív lekérdezések WITH RECURSIVE záradékát.
- A BSc-n csak MONOTON rekurziót vesszük, vagyis nem használjuk nem-monoton különbség műveletet, nincs csoportosítás-aggregálás (ugyanis az olyan lekérdezések, amelyek nem-monotonok, megengedik a negációt és aggregálást az olyan különös hatással van a rekurzióra, ezt csak MSc kurzusokon vesszük).
- Gyakorlaton a rekurzív Eljut-feladatnak az Oracle CONNECT BY záradékkal való gépes-megoldásait is megnézzük (ezt csak a gyakorlaton próbáljuk ki).

Eljut feladat PL/SQL-ben ---1

- **Rek1.feladat:** Mely (x, y) várospárokra lehet egy vagy több átszállással eljutni x városból y városba?
- Ehhez hozzuk létre eljut(honnan,hova) táblát,

```
DROP TABLE eljut;
CREATE TABLE eljut(
        honnan VARCHAR2(10),
        hova VARCHAR2(10));
```

- Írjunk egy olyan PL/SQL programot, ami feltölti az ELJUT táblát a sorait a járatok tábla alapján (ehhez ciklust szervezni, az insert több sor felvitele 2.alakja alkérdéssel járatok és eljut táblák alapján)

Eljut feladat PL/SQL-ben ---2

- Az ELJUT feladat megoldása Oracle PL/SQL-ben
- A ciklus során ellenőrizni kell, hogy addig hajtsuk végre a ciklust, amíg növekszik az eredmény (Számláló)
- DECLARE RegiSzamlalo Integer;
  UjSzamlalo Integer;
- Deklarációs rész után BEGIN … END; között az utasítások, először az eljut táblának kezdeti értéket adunk (a megvalósításnál az INSERT-nél figyelni, hogy ne legyenek ismétlődő sorok: select distinct)

  delete from eljut;

  insert into eljut (SELECT distinct honnan, hova
  FROM jaratok);

Eljut feladat PL/SQL-ben ---3

- Szamlalo változóknak adunk kiindulási értéket:

```
RegiSzamlalo := 0;
select count(*) into UjSzamlalo from eljut;
```

- A ciklust addig kell végrehajtani, amíg növekszik az eredmény (Szamlalo) duplikátumokra figyelni!

```
LOOP
   insert into eljut (lásd a köv.oldalon…)
   select count(*) into UjSzamlalo from eljut;
   EXIT WHEN UjSzamlalo = RegiSzamlalo;
   RegiSzamlalo := UjSzamlalo;
END LOOP;
commit;
```

Eljut feladat PL/SQL-ben ---4

- Az eljut tábla növelése a ciklusban, figyelni kell a duplikátumokra, csak olyan várospárokat vegyünk az eredményhez, ami még nem volt!

```
insert into eljut
    (select distinct eljut.honnan, jaratok.hova
     from eljut, jaratok   --- *from (lineáris rekurzió)
     where eljut.hova = jaratok.honnan
     and (eljut.honnan,jaratok.hova)
          NOT IN (select * from eljut));
```

- Megjegyzés: PSM-ben a nem-lineáris rekurzió is megengedett: from eljut e1, eljut e2 ---*from-ban

Oracle megoldások: with utasítással

- Az Oracle SQL a WITH RECURSIVE utasítást (UNION) nem támogatja, ott másképpen oldották meg WITH utasítással (Oracle 11gR2 verziótól használható)

```
WITH eljut (honnan, hova) as
   (select honnan, hova from jaratok
  UNION ALL
     select jaratok.honnan, eljut.hova
     from jaratok, eljut
     where jaratok.hova=eljut.honnan
     )
SEARCH DEPTH FIRST BY honnan SET SORTING
CYCLE honnan SET is_cycle TO 1 DEFAULT 0
select distinct honnan, hova from eljut order by honnan;
```

Oracle megoldások: connect by

- SELECT DISTINCT hova FROM jaratok
  WHERE HOVA <> 'DAL'
  START WITH honnan = 'DAL'
  CONNECT BY NOCYCLE PRIOR hova = honnan;

- SELECT LPAD(' ', 4*level) || honnan, hova,
  level-1 Atszallasok,
  sys_connect_by_path(honnan||'->'||hova, '/'),
  connect_by_isleaf, connect_by_iscycle
  FROM jaratok
  START WITH honnan = 'SF'
  CONNECT BY NOCYCLE PRIOR hova = honnan;

Kérdés/Válasz

- Köszönöm a figyelmet! Kérdés/Válasz?
- Vizsgára ismerni/ismertetni kell az Eljut feladatot és az SQL-99 szabvány WITH RECURSION utasítását, továbbá feladatok lesznek Datalog program átírására SELECT-re WITH RECURSION záradékkal (SQL-99)
- Házi feladat: Gyakorlás Oracle Példatár 3.fejezete tartalmaz hierarchikus lekérdezésekre feladatokat:

  http://people.inf.elte.hu/sila/eduAB/Feladatok.pdf
- Oracle gépes-megoldások nem lesznek a vizsgán, csak a gyakorlaton próbáljuk ki: az Eljut-feladathoz a Jaratok táblát létrehozó script: create_jaratok_tabla.txt