SILK, egy modellalapú információintegrációs eszközkészlet

Benkő Tamás

benko@cs.bme.hu

BME

2005. május 19.

Tartalomjegyzék

Miről lesz szó?

- A SILK projekt
  * SILK: System Integration using Logic and Knowledge (EU 5. keretprogram, IST alprogram)
  * 2000–2003
  * IQSOFT (magyar), EADS (francia), ICI (román), IDEC (görög)
  * A cél: heterogén információforrások integrációja
  * Az indíték: egy nagy, magyar távközlési cég magas szintű integrációs problémájának megoldása
- Modelleken és logikai következtetésen alapuló információintegrációs rendszer jellemzői
  * metaadat-kezelés, modellezés
  * logikai következtetés felhasználása
  * deklaratív információintegrálás, mediálás

Integrációs probléma

- Kialakulás
  - Adott egy nagy szervezet, független információforrásokkal
  - Az igények változnak → adatforrások születnek, változnak
  - Redundancia keletkezik
- Problémák
  - Melyik forráshoz forduljunk?
  - Konzisztencia?
  - Tudjuk együtt használni őket?
    - technológiai különbségek
    - szemantikai különbségek
- Az integrációs módszerek ezeket a problémákat igyekszenek megoldani

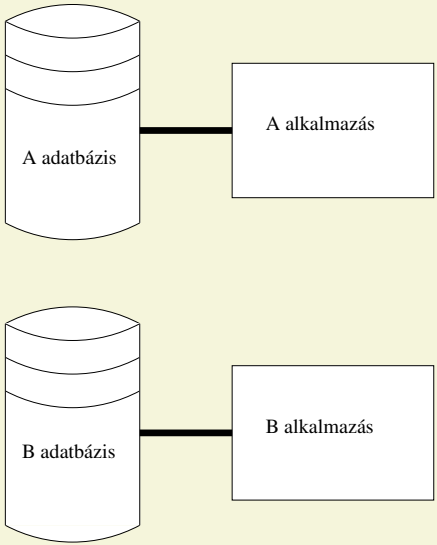

Ad hoc integráció

- A természetes megoldás
- Összevonjuk az adatforrásokat (adatorientált integráció)
- Összevonjuk az alkalmazásokat (alkalmazásorientált integráció)
- Esetleg mindkettőt megtesszük
- Jellemzők
  - \+ biztosítja a konzisztenciát
  - \+ a lehető leghatékonyabb működés
  - – szoros csatolás
  - – nem skálázható
  - – nagyon költséges fejlesztés
  - * *revolúciós* megoldás

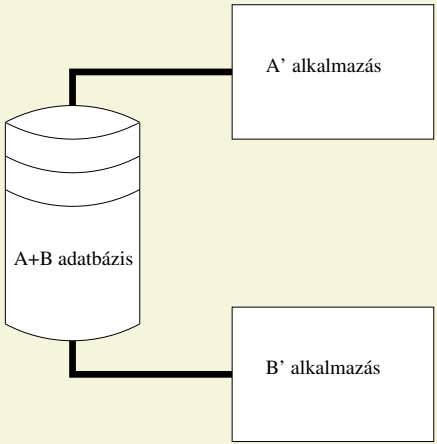

Az alkalmazásintegráció architektúrája

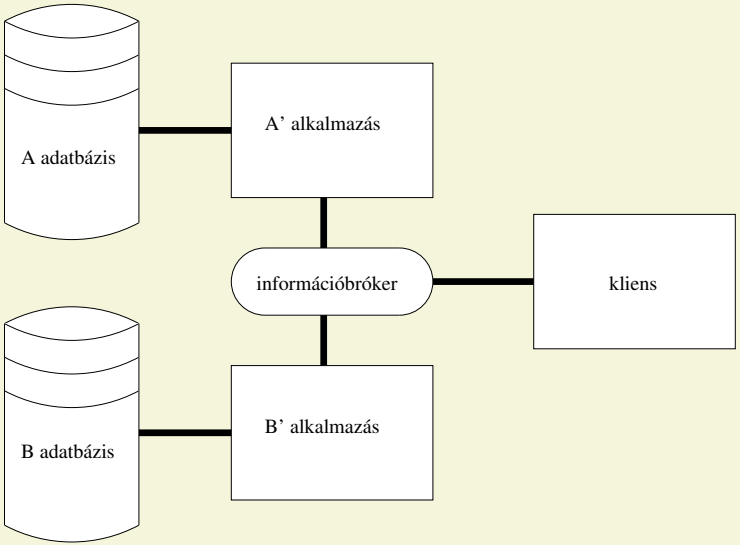

Alkalmazásintegráció (megvalósítás és jellemzők)

- Megvalósítás
  * Laza csatolás az *információbrókeren* keresztül
  * A részt vevő rendszerek üzeneteket küldenek a brókernek
  * A bróker átalakítja és továbbküldi az üzeneteket a megfelelő helyekre
  * A brókert programozni kell
  * Az integrált rendszerekhez csatolók kellenek
- Jellemzők
  + biztosítja a konzisztenciát
  + a brókerben koncentrálódik az integrációs logika
  + *folyamatokat* kezel
  – azokat az új lekérdezések tudja megvalósítani, amelyeket beprogramozunk
  – nem ad átfogó képet az integrált rendszerekről

Az adatintegráció architektúrája

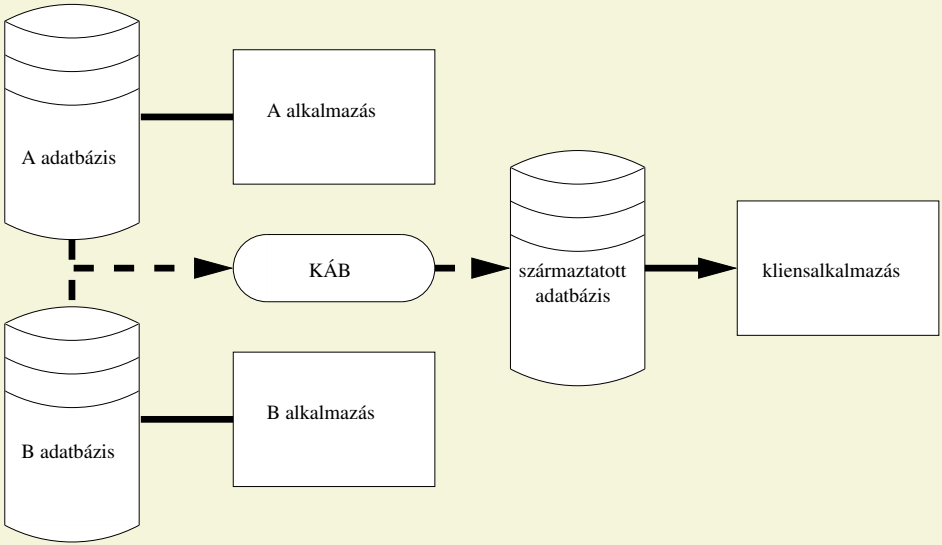

Adatintegráció (megvalósítás és jellemzők)

- Megvalósítás
  * Laza, off-line csatolás a *KÁB* segítségével
  * A *származtatott adatbázis* időnként frissül az integrált adatokkal
  * Az adatoknak több példányát tároljuk → adattörténet is rendelkezésre áll
  * Az új kliens lekérdezheti a teljes egyesített adatbázist
- Jellemzők
  – nem biztosítja a konzisztenciát, csak egy konzisztens képet (adattisztítás)
  \+ a KÁB komponensben koncentrálódik az integrációs logika
  \+ adattörténetet kezel → adatbányászat lehetséges
  – az adatok ritkán frissek
  – hatalmas adatmennyiség → nagy erőforrásigény (tár, processzor, hálozat)
  – igazából csak adatbázisokat lehet így integrálni

Az információintegráció architektúrája

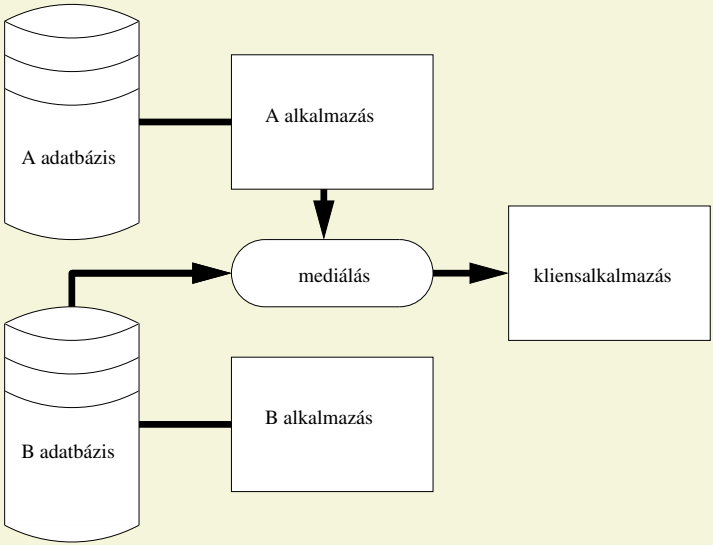

Információintegráció (megvalósítás és jellemzők)

- Megvalósítás
  * Laza csatolás a *mediálást* végző komponens segítségével
  * Az adatok helyett csak a metaadatokat gyűjtjük össze
  * Az adatokat on-line módon állítjuk elő
  * Az integrált rendszerekhez csatolók kellenek
- Jellemzők
  – nem biztosítja a konzisztenciát, csak egy konzisztens képet (adattisztítás)
  \+ a mediálást végző komponensben koncentrálódik az integrációs logika
  \+ az adatok mindig frissek
  – az adatokat esetleg bonyolult úton kell előállítani → lassabb lekérdezések
  \+ csak a szükséges adatmennyiség → kis erőforrásigény (tár, processzor, hálozat)
  \+ bármilyen adatforrást (pl. webszolgáltatást is) integrálhat

Az evolúciós integrációs módszerek összehasonlítása

Típus	**Hozadék**	**Tárgy**	**Fő komponens**	**Felhasználó**
alkalmazásintegráció	szinkronizáció	folyamatok	információbróker	szervezet
adatintegráció	trendanalízis	adattörténet	adattárház	döntéshozók
információintegráció	termelékenység	élő adatok	mediátor	végfelhasználók

- Az egyes módszerek más feladatokra koncentrálnak
- Egyik sem jobb a másiknál
- Egyidejűleg többet is érdemes lehet alkalmazni

Az ontológiák/metaadatok szerepe

- Rengeteg adat áll a rendelkezésünkre
  - Nem az a kérdés, van-e adat, hanem hogy megtaláljuk-e
  - Az adatokat rendszerezni kell, hogy ne vesszünk el bennük
  - A metaadatok (modellek) egyre fontosabbá/értékesebbé válnak
- A változással a metaadatok szintjén könnyebb lépést tartani
  - A modellek kisebbek
  - A modellek alapján automatikusan kell feldolgozni az adatokat
  - Az alkalmazásfejlesztésben is érvényes ez az elv (ld. MDA)
- Elosztott rendszereket nem igazán lehet metaadatok nélkül üzemeltetni
  - Grid
  - P2P rendszerek
  - Webszolgáltatások
  - A világháló
- Az információintegráció ezekre a tulajdonságokra épít

A SILK rendszer környezete és architektúrája

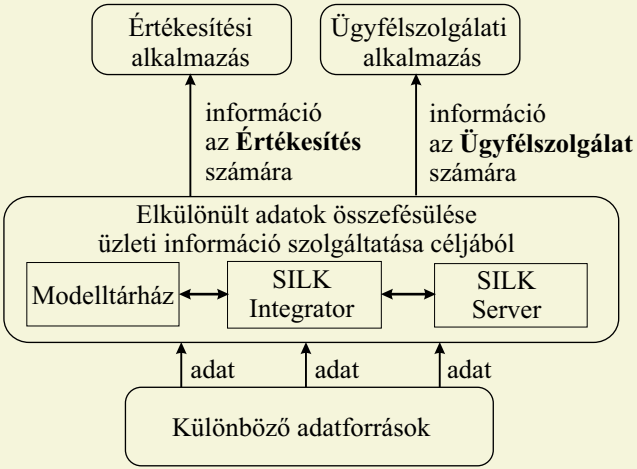

SILK információintegráció

- A három réteg alulról felfele:
  * különböző forrásokból származó adatok
  * SILK: a mediálást végző komponens
  * információ különböző fogyasztók számára
- A fő SILK komponensek:

  SILK Server a „futási idejű” komponens, a lekérdezéseket válaszolja meg

  Modelltárház az integrációhoz szükséges modelleket tárolja

  SILK Integrator a modelltárházat tartja karban

A SILK alkalmazási környezete

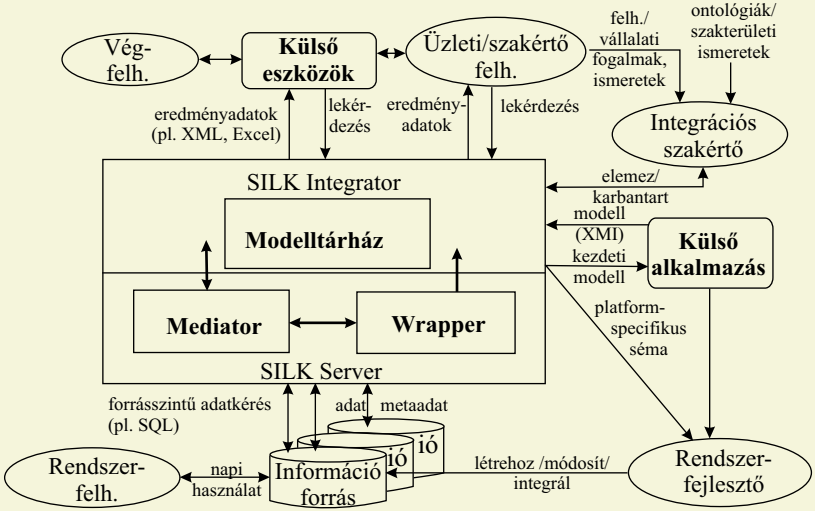

A SILK felhasználási módjai

- Modellezés
  - meglévő modellek betöltése
    - külső alkalmazásokból
    - magukból az adatforrásokból
  - új modellek kialakítása
  - modellek összekapcsolása
- Lekérdezés
  - külső eszközökkel vagy közvetlenül
  - a modelltárházbeli modelleken
  - egyszerre több adatforrást felhasználva
- Integrációs visszacsatolás
  - a kialakított új modellek és kapcsolatok alapján
  - javaslat egy integrált rendszer kialakítására
  - pl. ad hoc integrációhoz vagy adattárház kialakításához

A SILK fő komponenseinek feladatai

- Wrapper
  * elrejti a technológiai sokféleséget
  * adatot szolgáltat
  * metaadatot szolgáltat
- Mediátor
  * magasszintű, felhasználóspecifikus kérdéseket
  * visszavezet az egyes adatforrásokra vonatkozó részkérdésekre, és
  * a részeredmenyeket összeállítja egy értelmes válasszá
- Integrátor
  * támogatja a modellek kialakítását és kezelését
  * tartja a kapcsolatot a felhszználókkal és a külső alkalmazásokkal
  * tartja a kapcsolatot a Wrapper és a Mediator komponenssel

A modelltárház tartalma

- objektumorientált modellek
  - UML osztálydiagramok: strukturális jellemzők, alapvető kapcsolatok leírása
    - attribútumok
    - öröklődés
    - …
  - (LL modellek: magasszintű fogalmak és szerepek leírása)
- OCL korlátok az egyéb jellemzők számára
  - invariánsok
- leképezések (kapcsolatok a modellek között)
  - megfeleltetések (pl. két elem ugyanazt modellezi)
  - absztrakciók (pl. az egyik elemből származtatható egy másik)

A modelltárház felépítése

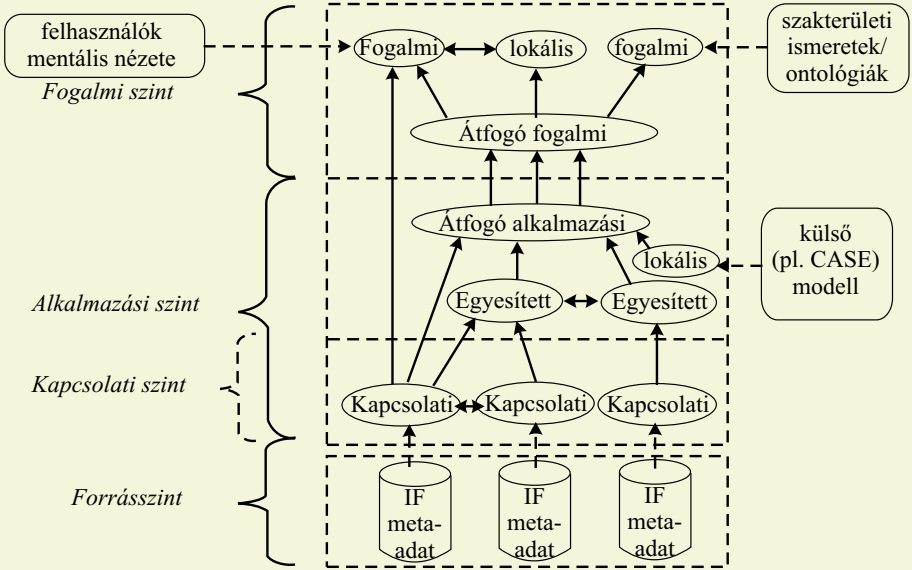

A modellek osztályozása

- Absztrakciós szint szerint:

  alkalmazási szint megvalósított vagy megvalósítható rendszerek modelljei (UML)

  fogalmi szint felhasználói nézetek (UML vagy LL)

- A lefedett terület nagysága szerint:

  lokális modell a teljes rendelkezésre álló információnak egy kis része

  kapcsolati modell a lokális modell speciális esete

  * egy konkrét adatforrás modellje
  * importált modell + a kapcsolódáshoz szükséges információk

  egyesített modell több rendszert átfogó (egyesítő) modell

Az adatforrások modellezése

- Minden forrást az UML osztálydiagramok nyelvén kell modellezni
- Relációs adatbázisok
  * adatbázis → modell
  * tábla → osztály
  * oszlop → attribútum
- XML-fájlok (DTD alapján)
  * fájl → modell
  * elem → osztály
  * attribútum → attribútum
  * gyerekviszony → kompozíciós asszociáció

SILan, objektumorientált elemek

```
model Gyár {
 class Termék {
  attribute String gyártási_szám;
  primary key gyártási_szám;
 };

 class Autó: Termék {
  attribute String gyártó;
  attribute Integer ár;
  constraint self.kerék.méret>2;
 };

 class Kerék: Termék {
  attribute Integer méret;
 };

 association 'Autó-Kerék' {
  connection Autó composite;
  connection Kerék;
 };
};
```

osztály egy halmaz; a halmaz elemei az osztály *példányai*

asszociáció egy halmaz; n végződésű asszociáció $\rightarrow$ n-esek halmaza; a halmaz elemei az asszociáció *kapcsolatai*

attribútum egy függvény; osztály $\rightarrow$ attribútumtípus

művelet egy függvény; osztály és paramétertípusok keresztszorzata $\rightarrow$ a művelet típusa

öröklődés a speciális osztály minden eleme az általános osztálynak is eleme

kompozíció bináris asszociációban az adott asszociációvég a másik végződés egy példányához tartozhat

kulcs az adott attribútumhalmaz azonosít egy példányt

invariáns az adott kifejezés az osztály (asszociáció) minden példányára (kapcsolatára) teljesül

Az invariánsok értelmezése

Az `Autó` osztály `constraint self.kerék.méret > 2` invariánsa:

1. `self`: az adott osztály (asszociáció) egy tetszőleges példánya (kapcsolata),
2. *navigációs lépés* az `'Autó-Kerék'` asszociáció mentén az autó egy tetszőleges kerekéhez,
3. navigációs lépes a kerék `méret` attribútumán keresztül,
4. azaz minden autó minden kerekének mérete nagyobb, mint kettő.

Érdekességek:

- az első navigációs lépésben a `kerék` egy implicit szerepnév
- a navigáció UML szemantikája kicsit más

Megfeleltetés

```
model Peugeot {
  class Jármű {
    attribute String sorszám;
    attribute Integer ár;
    attribute String típus;
    primary key sorszám;
  };
};
model Suzuki {
  class Autó {
    attribute String azonosító;
    attribute Integer ár;
    primary key azonosító;
  };
};
correspondence(j: Peugeot::Jármű,
               a: Suzuki::Autó) {
  constraint
         j.sorszám=a.azonosító
     and j.ár*1000 = a.ár;
};
```

- megfelel egymásnak
  - `Jármű` és `Autó`
  - `sorszám` és `azonosító`
  - a két `ár`
- az árak akkor összehasonlíthatók, ha az egyiket szorozzuk ezerrel
- a „korlátnak” nincs logikai jelentése
- `Jármű` és `Autó` nem ugyanazokat a példányokat tartalmazzák

Megfeleltetés logikai jelentéssel

```
model Értékesítés {
 class Áru {
  attribute String termékkód;
  attribute Integer ár;
  attribute String raktári_szám;
  primary key termékkód;
 };
};

correspondence(j: Peugeot::Jármű,
           a: Értékesítés::Áru) {
  constraint
          j.sorszám = a.termékkód
  implies j.ár*1000 = a.ár;
};
```

- megfelel egymásnak
  - `Jármű` és `Áru`
  - `sorszám` és `termékkód`
  - a két `ár`
- a legkülső `implies` miatt logikai jelentést rendelünk hozzá
- logikai jelentés: ha a sorszám megegyezik a termékkóddal, akkor a jármű árának ezerszerese az áru ára
- `Jármű` és `Áru` ugyanazokat a példányokat tartalmazzák csak más kódolással

Absztrakció

- Életet (információt) lehel a magasabb szintű modellekbe
- Pontosabban: adatokat rendel a magasabb szintű modellelemekhez az alacsonyabb szintű modellek adatai alapján
- Két feladata van
  1. szűrés: mely adatokból kell származtatni
  2. átalakítás: az adatokat a magasabb szinten elvárt formára kell hozni
- Nem öröklődés jellegű dolog
  * nem igaz, hogy az egyik példányai egyben a másik példányai is lennének
  * m adatból n adatot származtathatunk a segítségével
  * a származtatott példányok vagy kapcsolatok struktúrája és tartalma is más lehet, mint amiből származtattunk

Absztrakciós példa

```
abstraction (s: Peugeot::Jármű -> c: Gyár::Autó) {
  constraint s.típus = "Autó"
     implies s.sorszám = c.gyártási_szám
         and "Peugeot" = c.gyártó
         and s.ár*1000 = c.ár;
};
```

- `s`-ből (*supplier*), egy `Peugeot` modellbeli `Jármű` példányból
- `c`-t (*client*), egy `Gyár` modellbeli `Autó` példányt származtatunk
- szűrés:
  * csak olyan `s`-ekből származtatunk, amelyek típusa `"Autó"`
- átalakítás:
  * a gyártási szám megegyezik a sorszámmal
  * a `Peugeot` modellben csak Peugeot gyártmányok vannak
  * az árat ugyanazért szorozzuk, amiért a megfeleltetésben

Van valakinek ötlete több szállítót alkalmazó absztrakcióra?

És több klienst használóra?

Lekérdezés

- lekérdezés tetszőleges szinten megfogalmazható
- a magasabb szintűek érdekesebbek, mert
  * több adatforrást fedhetnek le
  * elvégzik a szükséges konverziókat

```
query OlcsóNagyKerekűAutó
select k.gyártási_szám, k.autó.gyártási_szám
from k: Gyár::Kerék
where k.méret > 4 and k.autó.ár < 5000;
```

- olcsó autókat keresünk, nagy kerékkel
- `from k: Gyár::Kerék`: `k` a `Gyár` modell `Kerék` osztályának példánya
- `where k.méret > 4 and k.autó.ár < 5000`: a már említett navigációkat használjuk, a kerék legyen nagy, az autója legyen ocsló
- `select k.gyártási_szám, k.autó.gyártási_szám`: a gyártási számokra vagyunk kíváncsiak

A SILK részletes architektúrája

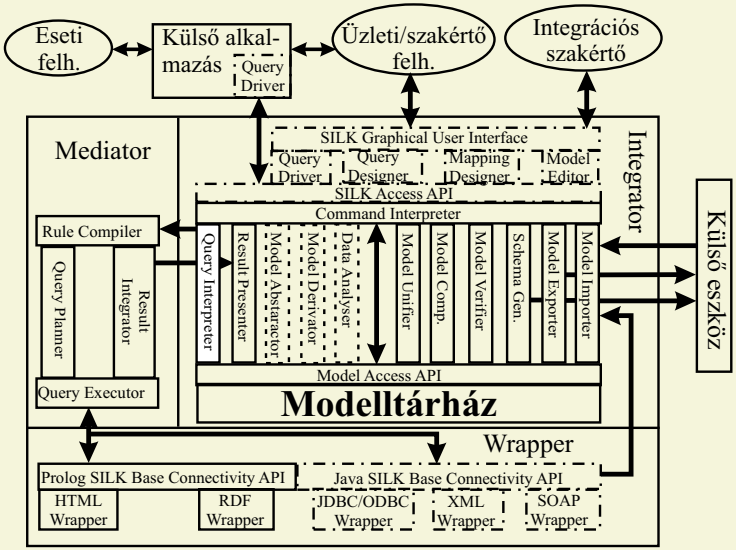

Jelmagyarázat: Prolog komponens | Java komponens | Tervezett Prolog komponens

A SILK által támogatott folyamatok

- A modelltárház felépítése
  * Létező modellek átvétele információforrásokból és modellezési (CASE) eszközökből
  * Modellek *összehasonlítása* és *összekapcsolása*
  * Modellek *konzisztenciaellenőrzése*
  * Modellek *egyesítése*
- Integrált rendszer használata és építése
  * *Összetett lekérdezések futtatása*
  * Egységes, integrált rendszer fejlesztésének támogatása

Modellek összehasonlítása és összekapcsolása

- Bemenete két modellelemhalmaz (pl. a 23. és a 25. oldal modelljeiből)
- Gráfok hasonlóságát vizsgálja
- Megkeresi az egymáshoz leginkább hasonlóakat és összekapcsolja őket
- Általános esetben m elemet n elemmel köt össze
- Az összekapcsolt elemekhez leképezést (megfeleltetést vagy absztrakciót) generál

```
abstraction (s: Peugeot::Jármű -> c: Gyár::Autó) {
  constraint s.sorszám = c.gyártási_szám and s.ár = c.ár;
};
```

- Pusztán a modellek alapján nem jöhet rá, hogy az árak között konverzióra van szükség
- Nem tudja származtatni a `gyártó` attribútumot
- Nem tudja, hogy a `típus` attribútum szerint szűrni kell
- A kézzel javított változat a 28. oldalon

Modellek ellenőrzése

- Konzisztenciaellenőrzés kizárólag a metainformációk alapján
- Elsősorban modellek összekapcsolása után fontos
- Pl. osztályinvariáns ellenőrzése
- *osztály*$(x_1, \ldots, x_n) \rightarrow$ *inv*$(x_1, \ldots, x_n)$
- Legyen `Peugeot::Jármű` (értelmetlen) invariánsa `self.ár < 5 and self.ár > 30`
- `'Jármű'`$(\mathit{GySz}, \mathit{Típus}, \mathit{Ár}) \rightarrow \mathit{Ár} < 5 \wedge \mathit{Ár} > 30$
- Ha a jobb oldal hamis, akkor az osztály üres
- CLP következtetőket használunk a jobb oldal vizsgálatára
- A CLP(R) következtető a fenti példán egymagában kimutatja, hogy `Peugeot::Jármű` inkonzisztens
- Általános esetben többféle következtető együttműködésére lehet szükség

Modellek egyesítése

- Megfeleltetések alapján
  1. egyesített modell és
  2. absztrakciók generálása
- Üzemmódok
  * unióegyesítés: az összes asszociáció és osztály az összes attribútummal bekerül
  * metszetegyesítés: csak a megfeleltetett asszociációk, osztályok, és attribútumok kerülnek be
- Az absztrakciók automatikus generálása nehéz
  * lehetetlen, ha az attribútumok között elég „furcsa” reláció van (ez a gyakorlatban nem fordul elő)
  * működik, ha a megfeleltetett attribútumok függvényei között egyenlőség van

Adatelérés összetett modellek alapján

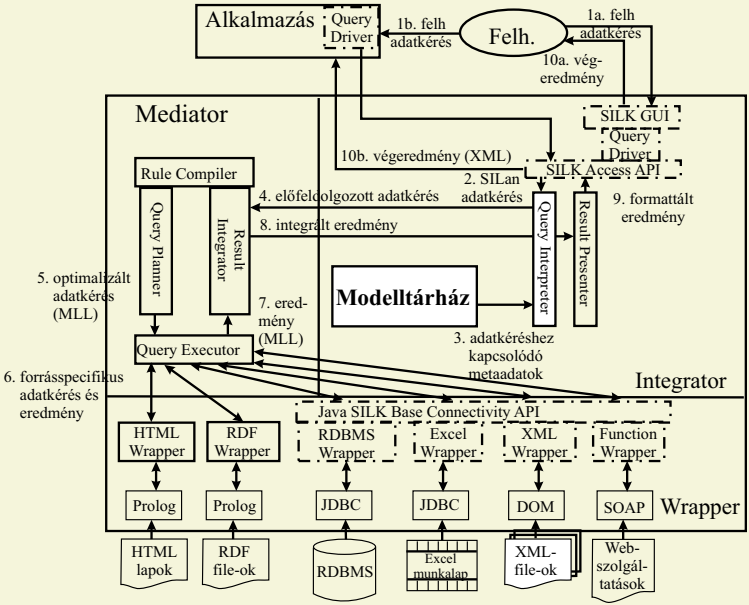

Az MLL

- Egységes logikai formalizmus a modelltárház leírására
- $\forall \overline{X}.(p_0(\overline{X}_0) \wedge \ \ldots \ \rightarrow \ \exists \overline{Z}.q_0(\overline{Y}_0) \wedge \ \ldots)$, ahol
- $\overline{X} = \bigcup_i \overline{X}_i$, $\overline{Y} = \bigcup_i \overline{Y}_i$ és $\overline{Z} = \overline{Y} \backslash \overline{X}$
- A kvantálás implicit, azaz nem írjuk ki
- A `self.kerék.méret > 2` invariáns (23. oldal)
- MLL alakja:

```
'Autó'(GySz,Gy,Á), 'Autó-Kerék'('Autó'(GySz,Gy,Á),
                                'Kerék'(KGySz,Méret))
     ---> Méret > 2
```

- A `Peugeot::Jármű`-ből `Gyár::Autó` absztrakciójának (28. oldal)
- MLL alakja:

```
'Jármű'(GySz,'Autó',Ár) --->
   'Autó'(GySz,'Peugeot',Autó_ár), Autó_ár = 1000*Ár
```

A SILK továbbfejlesztése: SILK-rendszerek együttműködése

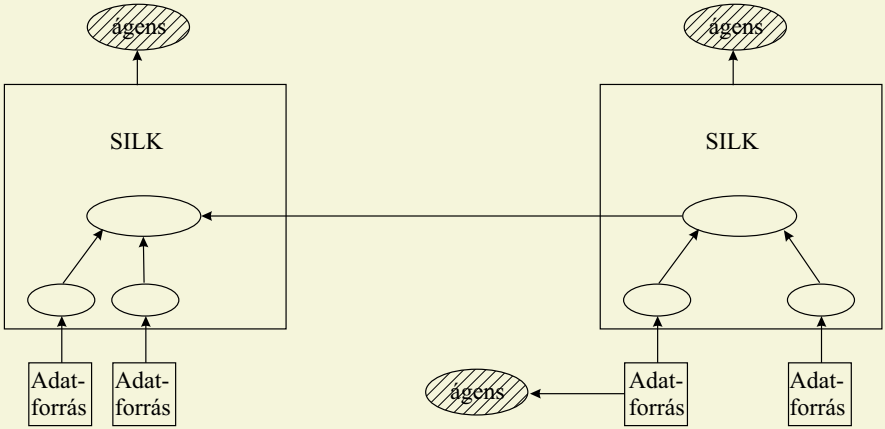

A SILK továbbfejlesztése: közvetítés ágensek között