

A kutató-fejlesztő munkára fordított idő arányában teljes munkaidejű dolgozókra átszámított létszám ráfordítás (full time equivalent, FTE).

--	--	--	--

Definíció: óra/munkahét: **36** óra/év **1872**

--	--	--	--

A halványzöld cellákba lehet írni a bemenő adatokat és a halvány vörös cellában olvasható a végeredmény

A projekt hossza

312

 munkahét

A hároméves projekt futamideje 156 munkahét, a négyéves futamideje 208 munkahét, általában ennyi a részvétel hossza.

Személyek neve	Százalékos részvétel (max 100 %)	A részvétel hossza (hét)	a projektre fordított heti átlagos munkaóra (kerekítve)	a projektre fordított összes munkaóra (kerekítve)
Alberti Gábor	25,0	208	9	1872
Alberti Gábor	10,0	104	4	374
Kleiber Judit	50,0	200	18	3600
Kleiber Judit	10,0	112	4	403
Szilágyi Éva	50,0	100	18	1800
Károly Márton	50,0	60	18	1080
Károly Márton	20,0	100	7	720
Farkas Judit	10,0	100	4	360

Kilián Imre	10,0	100	4	360
Ohnmacht Magdolna	5,0	312	2	562
Tamm Anne	3,0	312	1	337
Viszket Anita	10,0	104	4	374
Bódis Zoltán	5,0	52	2	94
Burányi Péter	0,0	0	0	0
			Munkaóra összesen:	11936

**A részvétel hossza nem lehet hosszabb,
mint a projekt hossza**

FTE
(2 tizedesre
kerekítve):

1,06

ReALIS projekt: a szóképzés általánosítása a számítógépes fordításban

Alberti Gábor¹, Kleiber Judit¹, Ohnmacht Magdolna²,
Szilágyi Éva¹, Anne Tamm³, Viszket Anita¹

¹ Pécsi Tudományegyetem, Bölcsészettudományi Kar, Nyelvtudományi Tanszék,
7624 Pécs, Ifjúság útja 6.

² Szegedi Tudományegyetem, Bölcsészettudományi Kar, Nyelvtudományi Doktori Iskola,
6722 Szeged, Egyetem u. 2.

³ Università degli Studi di Firenze, Dipartimento di Filologia moderna,
Via Santa Reparata 93-95, 50129 Firenze
gelexi@btk.pte.hu

Kivonat: A ReALIS projekt célja egy olyan nyelvelemző program megalkotása, amely minden eddigénél alaposabb szemantikai reprezentációt társít szövegekhez, és azt mint nyelvfüggetlen közvetítőnyelvet alkalmazva gépi fordító rendszerként is hasznosítható. Az elemző elméleti háttérül a totálisan lexikalista GASG szolgál [3], a szemantikai reprezentációt pedig mint a ReALIS [1] implementációját képzeljük el. A totálisan lexikalista morfológia kiterjesztéseként az inflexiós morfémák mellett a produktív *derivációs morfémákhoz* is közvetlenül lexikai egységeket rendelünk, a szóalaktanilag „láthatatlan” *konverziós* [17] eseteket is figyelembe véve. A nyelvenkénti sokszínűség a nyelvfüggetlen szemantikai reprezentációs szinten eltűnik, így nem igényel bonyolultabb mechanizmust a nagyon különböző nyelvek közötti fordítás sem. A lexikalista elméletekre épülő elemzők és gépi fordító rendszerek egyre nagyobb térhódítása igazolni látszik, hogy szükség van a kifinomult nyelvméleti eszköztárra a számítógépes nyelvészet olyan igényes területein, mint például a gépi fordítás. Projektünk alapvető célja a végsőig vitt lexikalizmus kipróbálása ezen a területen.

1 Bevezetés

Mint a szerzők névsora mutatja, a *ReALIS* projekt kutatócsoportja a *GeLexi* (*Generative Lexicon*) elméleti és számítógépes nyelvészeti kutatócsoport [3] és a *LiLe* (*Linguistic Lexicon*) adatbázis-készítő team [6] egyesülése révén jött létre, további elméleti nyelvészek bevonásával. Alapvető célunk változatlanul a *kifinomult nyelvméleti eszköztár* hasznosságának igazolása a számítógépes nyelvészet olyan igényes területein, mint amilyen például a *gépi fordítás* [4].

Azon az úton haladunk tovább, melyet a *totális lexikalizmus* elvének a morfémák szintjén való érvényesítése és egy korszerű DRT alapú szemantikához [16] való közvetlen (azaz nem egy hagyományos generatív szintaxison keresztül történő) hozzáférés fémjelez. A ReALIS (*Reciprocal And Lifelong Interpretation System*) [1] mint háttér a DRT szemantikának egy olyan pragmatikai kiterjesztésére utal,

amelynek alapján „interpretálói tudásbázist / információállapotot” építünk fel a parser támogatására.

Egy konkrétumot szeretnénk ebben a tanulmányban kiemelni. Az inflexiós morfémák mellett a produktív *derivációs morfémákhoz* is lexikai egységeket rendelünk, a szóalaktanilag „láthatatlan” *konverziós* [17] eseteket is figyelembe véve. A cikk második felében a lexikalista alapú gépi fordítás jelenlegi állásának áttekintése után projektünk megközelítését ismertetjük.

2 Elméleti háttér

A nyelvméletben az utóbbi évtizedekben lexikalista fordulat következett be: a kezdeti szintaxis-központú elméleteket egyre inkább felváltják a szótári komponens előterbe helyező megközelítések. Ennek hatására egyre több lexikalista elmélet és számítógépes alkalmazás születik. Kutatócsoportunk alapvető célja megvizsgálni, hogy a végsőkéig vitt (totális) lexikalizmus mint elméleti keret mennyire sikeres elméletileg, illetve intelligens nyelvtechnológiai alkalmazások fejlesztése céljára.

2.1 Totális lexikalizmus

A totális lexikalizmus azt jelenti, hogy a mondat összeépüléséhez szükséges minden információt a lexikonban tárolunk, így nincs szükség külön szintaktikai szabályrendszerre (frázisstruktúra-szabályokra). A nyelvtan tehát nem más, mint egy nagy adatbázis, amelyben a lexikai egységeket és azok tulajdonságait tároljuk, illetve egyetlen művelet – az *unifikáció* – mint a mondatok összeépülésének motorja.

Az a hipotézisünk, hogy egy ilyen homogén lexikalista nyelvtan mind elméletben, mind gyakorlatban jól működő, hatékony tud lenni; célunk ennek igazolása. Első lépésként kidolgoztuk a nyelvtant a magyar nyelv egy fragmentumára, majd azt implementáltuk Prolog programnyelven [3]. A parser bemenete egy magyar mondat, kimenete annak morfológiai és szintaktikai elemzése (szintaxison a függőségi viszonyokat értve), illetve a mondathoz rendelhető diskurzus-szemantikai reprezentáció.

Következő lépésként kidolgoztuk a nyelvtant az angol nyelv egy kis szeletére, és – kihasználva azt, hogy amit a Prolog elemezni tud, azt generálni is – kipróbáltuk a totálisan lexikalista megközelítést a gépi fordítás területén is [4]. Elképzelésünk az, hogy az univerzálisnak tartott szemantikai reprezentáción keresztül elemzőnk kétirányú használatával bármely két nyelv között megvalósítható a fordítás. Nem kell megírni minden nyelvpárra külön a fordító mechanizmust, csak rendelkezünk kell az adott nyelvek nyelvtanának implementációjával.

Működő programunk bizonyította, hogy érdemes a totális lexikalizmus eszméjét a nyelvtechnológia területén alkalmazni. A következő lépés annak vizsgálata, hogy nagyobb adatbázison is működik-e a mechanizmus, illetve hogy bármely nyelvi jelenségről számot tud-e adni. Célunk egy pártízezer lexikai egységet tartalmazó relációs adatbázis és egy azt működtető program megalkotása, totálisan lexikalista alapokon. Szeretnénk továbbá minden eddigénél alaposabb gépi fordítást megvalósítani, amely nemcsak mondatok, hanem összefüggő szövegek fordítására is

alkalmas, és számot tud adni többek között a retorikai viszonyról, a diskurzusfunkcióról (topik, fókusz), a hangsúlyról és az aspektusról is. Ehhez egy minden eddiginél alaposabb szemantikai reprezentációt nyújtó elméletre van szükség.

2.2 ReALIS

A ReALIS (Reciprocal and Lifelong Interpretation System) egy reprezentacionalista, dinamikus szemantikai rendszer. Az interpretáció folyamatának az eddigieknél „reálisabb” szemléletét nyújtja. Négy komponensből áll: tartalmaz egy modellt a „külső” világról, a létező entitásokkal és a köztük lévő relációkkal, egy parciális függvényt, amely folyamatosan változó („felfrissülő”) információállapotokat társít minden egyes interpretáléhoz, valamint egy-egy függvényt a dinamikus információállapot-változás és a statikus igazságértékelés formális kifejezésére.

Elsődlegesen magának az interpretálónak az információállapotát hivatott ábrázolni, és csak közvetve a feldolgozott diskurzusokét – ezért mondjuk a ReALIS interpretációs megközelítését *élethossziglaninak* ('lifelong'). A rendszer karakterisztikus tulajdonsága a kölcsönös ('reciprok') információábrázolási technika: az interpretáló egy interpretálási folyamat során nemcsak az adott témáról meglévő saját tudására építhet, hanem a másokról feltételezhető tudásra is. Ez olyan konkrét nyelvi tények magyarázatában is szerepet játszhat, mint a névelők, névmások és más anaforikus elemek használata adott mondatbeli helyzetekben.

Előnye más szemantikai rendszerekhez képest, hogy pragmatikai tényezőket is figyelembe vesz, illetve hogy nagyon alapos szemantikai reprezentációt társít nem csupán egy-egy mondathoz, hanem szövegekhez is. Ezek a tulajdonságai teszik alkalmassá intelligens nyelvtchnológiai alkalmazásokra, mint például a gépi fordítás.

3 Szóképzés

A totálisan lexikalista morfológia kiterjesztéseként az inflexiós morfémák mellett a produktív *derivációs morfémákhoz* is közvetlenül lexikai egységeket rendelünk – Alberti (2006) [2] szellemében, a szóalaktanilag „láthatatlan” *konverziós* [17] eseteket is figyelembe véve. Mi több, az alábbi fordítási problémák a „szóképzés” fogalmának még merészebb általánosítását látszanak szükségessé tenni, amennyiben szeretnénk megőrizni egy olyan kézenfekvő fordítási megfeleltetést (legalábbis kiindulópontként), mely szerint a forrásnyelv t_f relatív tövéből létrehozott $K_f(t_f)$ képzett alak célnyelvi megfelelője egy $K_c(t_c)$ képzett alak lesz, ahol a t_c tö a t_f tö megfelelőtetetje, a K_c képzési „függvény” pedig a K_f képzése.

Nézzünk néhány példát a nyelvekben található változatos eszközökre, ahogy a különféle „képzéseket” megvalósítják!

Míg az angol a *progresszív* alakot hagyományos értelemben vett igenévképzéssel hozza létre (ld. (1a): t_f : *set up* → $K_f(t_f)$: *setting up*), addig a magyarban úgy foghatjuk fel, hogy a képzett igealak máshova rendeli az igekötőjét ((1b): t_c : *felállítottuk* → $K_c(t_c)$: *állítottuk fel*). Megint másként jár el az észti nyelv [23]: a tárgy esetét módosítja ((1c): a t_c argumentumszerkezetében: *Accusativus* → a $K_c(t_c)$ argumentumszerkezetében: *Partitivus*).

- (1) a. We set up the tent. / We were setting up the tent.
 b. Felállítottuk a sátrat. / Állítottuk (éppen) fel a sátrat (mikor...).
 c. Panime telgi püsti / Panime telki püsti.
 put.past.1pl tent.acc up / put.past.1pl tent.part up

Az utóbbi két esetben tehát maga az igei szótest nem módosul (*konverzió* [17]), *általánosított képzésként* foghatjuk azonban fel a vonzatszerkezet-módosulást [2]. Az (1) példasorban bemutatott szófajváltást megvalósító K_c (igenév-) képzésnek tehát a két tekintett célnyelvben a finit igei alakot megőrző operáció feleltethető meg. Az észtbeli K_c operációt olyan argumentumszerkezet-módosító igeképzésnek tekinthetjük, mint a magyarban az *átúszik a folyón* → *átússza a folyót* példa által szemléltethető változást: más lexikai egység szerepel a kimenetben, mint a bemenetben, hiszen már esetkeret jelölődik ki. A magyarbeli K_c operációt abban az értelemben tekinthetjük képzésnek, hogy a bemeneti alakban prefixummá inkorporálódó igekötői argumentum a kimeneti alakban szóvá önállósul [2]; a különbséget tulajdoníthatjuk eltérő lexikai leírásoknak (ahogy az *eszik egy almát* → *almát eszik, alakult egy kórus* → *kórus alakult* példapárok esetében is eltérő lexikai tétel megadásával szeretnénk számot adni a bemenet és a kimenet különbségéről, ami az egyik argumentum inkorporált helyzetét illeti).

Ugyanígy, nyelvenként különbözően valósulhat meg a passzív progresszív alakok előállítása (lásd a (2) példasorban: K_f igenévképzés, K_c új igetétel létrehozása egy argumentum inkorporált helyzetének megszüntetése révén, míg K_c új igetétel létrehozása egy argumentum esetének módosítása révén [23]), illetve az aktív → passzív képzés (a (3) pontban):

- (2) a. The owls were checked. / The owls were being checked.
 b. Átvizsgálták a baglyokat. / Vizsgálták (éppen) át a baglyokat (mikor...).
 c. Vaadati öökullid üle. / Vaadati öökulle üle.
 look.impers owl.nompl over / look.impers owl.partpl over
- (3) a. Harry kissed his mother. / Harry was kissed by his mother.
 b. Harry megcsókolta az anyját. / Harry-t megcsókolta az anyja.
 c. Harri suudles oma ema. / Harrit suudles ta ema.
 H.nom kiss.3sg.past his-own mother.part H.part kiss.3sgpast his mother.nom

Ez utóbbi esetében (3) az angol ismét igenévképzéshez folyamodik, míg a magyar és az észtt megőrzi az időjeles igeformát, sőt az esetkeretet is, továbbá argumentuminkorporációval kapcsolatos változás sem történik. Ami változik, az az argumentumok szórendi helyzete. Amennyiben úgy tekintjük, hogy a magyarban és az észttben nem *alulspecifikált* az igei régens ellenőrzése alatt tartott argumentumok sorrendje, hanem különféle sorrendek különféle lexikai tételekhez tartoznak, akkor még a (3b-c) pontokban bemutatott „topikalizációt” is tekinthetjük általánosított képzésnek.

Visszatérve az angol *-ing* igenévképzésre, annak egyes esetekben akár a magyarban is igenévképzés feleltethető meg (pl. *running* ~ *futó*), máskor azonban (igekötő híján) formai szempontból „identikus függvénynek” kell tekintenünk a képzést ((4): [*ran* ~ *futott*] → [*was running* ~ *futott*]), vagy egy mátrixigének kell megfeleltetnünk ((5): [*dim* ~ *ostoba*] → [*being dim* ~ *ostobán viselkedett*]).

- (4) a. He ran. / He was running.

- b. Futott. / Futott (éppen, mikor...).
 - c. Ta jooksis. / Ta jooksis.
s/he run.3sgpast / s/he run.3sgpast
- (5) a. Harry thought Ogden was (being) extremely dim.
 b. Harry úgy gondolta, hogy Ogden rendkívül ostoba (... ostobán viselkedik).
 c. Harri arvas, et Ogden [on erakordselt tobe]. / [käitub erakordselt tobedalt].
 H.nom think.3sgpast that O.nom [be.3sg extremely stupid] / [behave.3sg extremely stupidly]

Ez utóbbi (5) a szerint a gyakori fordítási megfelelés szerint működik, amit az angol és a magyar viszonylatában a másik irányban tapasztalunk gyakrabban: amikor is magyarbeli szuffixálással megvalósuló képzésnek (pl. K_f: *-(t)At, -hAt, -Ul, -ít, -(V)ll*), mely igei, illetve melléknévi töveken működik, egy mátrixigei régens bevonása feleltethető meg, mely önálló nem finit igealakot, illetve melléknévet szelektál (rendre: *dolgoztat ~ make sy work, dolgozhat ~ can/may work, barnul ~ become/grow brown, barnít ~ make sg brown, drágáll ~ consider sg expensive*).

Totálisan lexikalista morfoszintaktikai megközelítésünk kiegészítve a képzés felfogásának fenti erőteljes általánosításával lehetővé teszi tehát, hogy a fordítás azon eseteit is képesek legyünk *szabályalapúan* (és kompozicionális jelentéskalkulációval társítva) kezelni, ahol elvész a szófaji megfelelés, sőt még a szó~szó megfelelés is két nyelv között a lexikai egységek mondatná szerveződésének folyamatában.

4 Gépi fordítás

A gépi fordító rendszereket két nagy csoportra oszthatjuk: szabályalapú [15] és mintaalapú [22] megközelítésekre. A kezdetekre szabályalapú rendszerek fejlesztése volt a jellemző, míg az utóbbi években inkább hatalmas korpuszok és fordítómemóriák segítségével próbálják létrehozni a minél kisebb emberi beavatkozást igénylő gépi fordító programokat.

A szabályalapú rendszereken belül többféle megközelítést alkalmazhatnak. A fordítás történhet (1) direkt módon, kis elemzéssel, (2) közvetítőnyelven keresztül, illetve (3) transzferrel, amikor a forrásnyelvi mondatból egy absztrakt forrásnyelv-közeli reprezentáción, majd egy célnyelv-közeli reprezentáción keresztül állítják elő a mondat célnyelvi megfelelőjét.

A fordításhoz két lépésben jutnak el. Az első lépés az analízis (elemzés), amely a forrásnyelvi szöveg szintaktikai elemzésén túl tartalmazhat morfológiai, és valamilyen mértékű szemantikai elemzést is – ez utóbbira a többértelműségek kezeléséhez van (minimálisan) szükség. A második lépés pedig a szintézis (generálás), amikor a mondat célnyelvi megfelelőjét állítják elő lehetőleg ugyanazzal a mechanizmussal. Így a modularitás és a megfordíthatóság fontos tulajdonságaik ezeknek a rendszereknek.

Miután a szabályalapú megközelítés nem bizonyult kellően hatékonyak, még statisztikai módszerek bevonásával sem, továbbá rengeteg befektetett munkát igényelt a nyelvtanító részéről, a 90-es évektől kezdtek tért hódítani a mintaalapú fordítórendszerek. Hatalmas korpuszok születtek, amelyeket minél alaposabban annotáltak, annál jobb minőségű elemzőket lehetett rájuk építeni, viszont a ráfordítási idő is jelentősen megnőtt. Közülük leghatékonyabbnak a treebankok

(mondatszerkezettel is annotált korpuszok) bizonyultak, hiszen azok tartalmazzák a lehető legtöbb információt; viszont előállításuk nem egyszerű feladat, sok munkaórát igényel. Éppen ezért napjainkban egyre több olyan rendszert fejlesztenek, amely annotálatlan korpuszból képes „megtanulni” a nyelv elemeit és azok tulajdonságait különféle módszerek (analógia, disztribúciós módszer) segítségével, így kevés ráfordítással készíthetnek hatékony elemzőket. Nagyon elterjedt továbbá gépi fordításkor a párhuzamos korpuszok, illetve különféle fordítómemóriák használata, melyeket például az interneten fellelhető több nyelven elérhető anyagok szinkronizálásával állítanak elő.

A korpuszalapú megközelítések sem hoztak teljes sikert. Nem minden jól formált kifejezés található meg bennük, különösen a gazdag morfológiájú nyelvek esetében, mint a magyar, és nagyon ritka az igazán alaposan és jól annotált anyag, vagy megfelelően illesztett párhuzamos korpusz. Emiatt születnek különféle hibrid megoldások: alapvetően korpuszra támaszkodó, de valamilyen szintű elemzést is végző, vagy szabályalapú, de a többértelműségek kezelésében korpuszt is használó rendszerek.

Napjainkban egyre többen kezdenek visszatérni a szabályalapú megközelítéshez, de nem sekélyelemzést használnak, ami csak részleges elemzést ad, és hiába robusztus, ha nem annyira precíz [12], így komplexebb célokra (pl. igazán jó minőségű fordítás) nem alkalmas. A mélyelemzést végző rendszerek sokkal alaposabbak és pontosabbak, és az utóbbi időben lefedettségben is felveszik a versenyt a sekélyelemző rendszerekkel. Az ilyen nyelvészeti alapú, kézzel írt nyelvelemzők készítéséhez szükséges kezdeti nagyobb energiabefektetés pedig megtérül később, például amikor új nyelvekre dolgozzák ki [10]. Az igazán jól működő és hatékony mélyelemző rendszerek unifikációs mechanizmusokat használnak, így előnyeik között szerepel, hogy egyszerűbb szabályokat lehetséges megfogalmazni, gyorsabb, egyszintű, lexikalista és megfordítható [15]. A többértelműség kezelésére ezek a rendszerek is használhatnak korpuszt, mivel sokszor szabályba nem foglalható tényezők szükségesek az egyértelműsítéshez (pl. kontextus), illetve optimalitás-jelölő rangokat, hogy a ritka alakzatokat is elfogadja az elemző, de alapesetben a gyakoribb elemzés mellett döntsön [10].

A legtöbb gépi fordító rendszert egy adott nyelvpárra dolgozzák ki, sőt, akár csak az egyik irányban működnek, de léteznek többnyelvű rendszerek is, ahol a mechanizmus univerzalizására törekszenek.

4.1 Létező rendszerek

Egyetértés mutatkozik abban, hogy ha a cél egy igazán intelligens gépi fordító rendszer létrehozása, nem elégségesek a sekélyelemzést végző programok. A mintaalapú és statisztikai megközelítések ellen pedig az szól, hogy a legtöbb nyelv nem létezik igazán jól használható párhuzamos korpusz [7]. További érv a szabályalapú gépi fordítás mellett az újrahasonosíthatóság: hogy a gépi fordítás fejlesztésének eredményei más nyelvtechnológiai alkalmazásokban is használhatók, illetve más területek eredményeit a gépi fordítás is hasznosíthatja. Ezért ha olyan gépi

fordító rendszer fejlesztése a cél, ami bármely két nyelv esetében¹ jó minőségű és pontos fordítást ad, akkor mélyelemzést végző szabálya alapú rendszer alkalmazása tűnik a legjobbnak.

Napjainkban erre a célra az unifikációs mechanizmusokat használó lexikalista elméletek látszanak a legmegfelelőbbnek, amik nemcsak a konfigurációs nyelveket (mint az angol) kezelik hatékonyan, hanem a magyarhoz hasonló szabadabb szórendű nyelveket is. Továbbá a jó minőségű fordításhoz szükségesnek látszó valamiféle szemantikai reprezentáció hozzárendelésében is jobb eredményeket érnek el, mint a frázisstruktúra-nyelvtanok.

A lexikalista nyelvtanok közül a legeredményesebbek LFG vagy HPSG formalizmust használnak. Számos nyelvre léteznek már nagy lefedettségű elemzőik, amik nagyon jó minőségű és alapos elemzést adnak, továbbá szemantikai reprezentációt is társítanak a mondatokhoz. Különböző nyelvekre alkalmazzák ugyanazt az elméleti keretet, így tudják elérni, hogy a különböző nyelvű elemzések szinte teljesen párhuzamosak legyenek, ami jelentősen megkönnyíti az elemzőkre épülő gépi fordító rendszerek fejlesztését.

Ilyen nyelvtan például az ERG (English Resource Grammar), ami a legnagyobb HPSG-alapú nyelvtan angol nyelvre, implementálva az LKB (Linguistic Knowledge Building) rendszerben [9]. HPSG-re kifejlesztettek egy keretrendszert is (Grammar Matrix [5]), ami nem egy nyelvtan, hanem nyelvtanok feletti általánosítások gyűjteménye. Négy függetlenül fejlesztett HPSG-alapú nyelvtanból indult ki: angol, japán, német és norvég. A cél egy egységes nyelvtan megalkotása az egyes nyelvtanok feletti általánosítások alapján, hogy további megszorítások bevezetésével még egységesebb elemzések születhessenek, és hogy újabb nyelvek nyelvtanainak megírását gyorsabban lehessen elkezdeni. A Grammar Mátrixszal több kompatibilis nyelvtant is fejlesztettek. Ilyen például a JACY [21], ami egy nagy lefedettségű, nagy pontosságú japán nyelvtan. HPSG-alapú, MRS-t (Minimal Recursion Semantics²) használ a szemantikai reprezentáció hozzárendeléséhez. Eredetileg beszélnyelvi dialógusok gépi fordítására fejlesztették, később automatikus email-megválaszolásra és egyéb (többnyelvű) nyelvtechnológiai feladatokra is használták.

Az LFG-t mint elméleti keretet használó elemzők közül érdemes megemlíteni a Parallel Grammar (ParGram [8]) projektet. Lényege, hogy a hasonló szerkezetek elemzése a különféle nyelvekben amennyire csak lehet, párhuzamosak. Így hasonló számítógépes alkalmazásokban használhatók, és a gépi fordítás is egyszerűsíthető. Eredeti célja az LFG-formalizmust tesztelni: univerzalitását, lefedettségének határait, és hogy mennyire tartható a párhuzamosság a különféle nyelvek között. A párhuzamosságot az f-struktúra (funkcionális szerkezet) szintjén érik el³. Az eredmények biztatóak, nagyfokú párhuzamosság érhető el, így új nyelvtanok építése

¹ Rokon, vagy nagyon hasonló nyelvek közötti fordításkor elég lehet a sekélyelemzés, ha nagyfokú a morfológiai és szintaktikai hasonlóság. Például csehről szlovákra lehet szinte szóról szóra fordítani [14].

² Lapos szemantikai reprezentációt rendel szavakhoz és frázisokhoz. Mélyebb szintű, mint csupán a predikátum-argumentum viszonyok. Rendezetlen struktúra, hatókör tekintetében alulspecifikált.

³ Néha szándékosan nem párhuzamosak az f-struktúrák, pl. a névszói állítmány esetében (az *It is red* mondat esetében az angolban a kopula a fej, a japánban a melléknév), vagy amikor egy nyelvben megvan egy bizonyos jegy (pl. a németben a nem), egy másikban pedig nincs.

is könnyebben, gyorsabban lehetséges. Az elemzőt szándékosan nagyon különböző nyelvekre dolgozták ki először: angolra, németre, japánra, urdura és norvégra. Némelyik nagy lefedettségű, ipari alkalmazás, némelyiknél az s-struktúrát (szemantikát) is kidolgozták. Az elméletet az XLE (Xerox Linguistic Environment) platformon implementálták.

Jónéhány a különféle lexikalista alapú elemzők közül tehát elérte már azt a lefedettséget, amit korábban csak nagy korpuszok vagy statisztikai módszerek alkalmazásával lehetett megvalósítani. Ezek az elemzők mélyelemzést végeznek, kimenetükben szemantikai (vagy szemantika-közeli) reprezentáció is szerepel, továbbá nagyfokú párhuzamosságot képesek megvalósítani akár nagyon különböző nyelvek között is. Mindezek lehetővé teszik, hogy jó minőségű gépi fordító rendszerek épüljenek rájuk. Legnagyobb részük még kísérleti fázisban tart, de eredményeik nagyon ígéretesek. Több nyelvre is kidolgoztak már működő gépi fordító rendszereket, amelyek ezeket az elemzőket (és generálókat) használják. Legtöbbjük transzfer-alapú, így minden nyelvpárra és mindkét fordítási irányra külön transzfer-komponenst kell kidolgozni. A magyarra ilyen rendszer eddig még nem készült⁴.

LFG formalizmust használ például az XTE (Xerox Translation Environment), ami a ParGram projekt fordítórendszere [11]. A nyelvfüggetlennek tartott f-struktúra teszi alkalmassá többnyelvű nyelvtechnológiai alkalmazásokra, mint a gépi fordítás. A hatékony elemzőt és generálót tartalmazó XLE platformot kiterjesztették egy transzfer-komponenssel. A transzfer az f-struktúrán keresztül történik, amiről elismerik, hogy néha nem elég univerzális (pl. a fejtöltő fordítás esetében), de a nyelvek közötti különbségek legnagyobb része már ezen a szinten eltűnik. A legjobb az s-struktúrán keresztüli fordítás lenne, viszont ekkor ki kellene dolgozni a szintaxis-szemantika interfészt mind az elemzés, mind a generálás oldaláról (azóta ez irányban folytak a kutatások). A többértelműséget a döntés végsőig való halasztásával kezeli. HPSG-formalizmust használ például a DELPH-IN (Deep Linguistic Processing with HPSG Initiative [7]), ami egy nyílt forráskódú, szemantikai transzfer-alapú gépi fordító rendszer. Létező forrásokat alkalmaz: elemzőket, generálókat, kétirányú nyelvtanokat és transzfer-motort. Kezdetképpen japánról angolra fejlesztették ki. A cél a mechanizmus működésének megmutatása, ezért egyelőre száznál kevesebb transzfer-szabályt, és csupán párezres transzfer-lexikont tartalmaz. A rendszer a forrásnyelvet (japán) elemzi egy szabályalapú forrásnyelvi nyelvtannal (JACY), a legjobb elemzést valószínűségi rangok alapján kiválasztja; kimenete egy precíz, alulspecifikált (nyelvspecifikus) forrásnyelvi szemantikai reprezentáció (MRS_S). Ebből a transzfer-motor előállítja az alulspecifikált (nyelvspecifikus) célnyelvi (angol) szemantikai reprezentációt (MRS_T) újraíró szabályokkal. Ha több megoldás van a szabályalkalmazásnál, több fordítás lesz. Végül a célnyelvi generátor (ERG) angol nyelvű szöveget készít belőle. További céljaik között a lefedettség növelése szerepel, valamint választ kapni néhány elméleti kérdésre: mennyire lehet egységes a szemantikai reprezentáció, lehet-e (kvázi)automatikusan növelni a nyelvtanokat és

⁴ A magyarra működő gépi fordító rendszerek vagy mintaalapúak (Hunlish [13]), vagy alapvetően szabályalapúak (MetaMorpho [19]), de nem lexikalisták. Nem céljuk továbbá olyan minőségű fordítás, mint a cikkben tárgyalt egyéb alkalmazásoknak.

lexikonokat, mi lehet a lexikális szemantika szerepe, stb. A fejlesztés egyelőre kísérleti stádiumban van, azonban nagyon ígéretes.

Létezik olyan rendszer is, amely LFG és HPSG alapú elemzőket is használ, a norvég-angol gépi fordítást megvalósító szemantikai transzfer-alapú LOGON [18]. Olyan célokra kezdték fejleszteni, ahol a fordítás minősége fontosabb a nagy lefedettségénél. A fordítás három lépésben történik: első a norvég mondat LFG-alapú grammatikai és szemantikai mélyelemzése, amihez az XLE platformon fejlesztett NorGram-ot használják (amit a ParGram projekten belül fejlesztettek). Kimenete egy nyelvspecifikus logikai szemantikai reprezentáció (MRS). Majd ezeknek a reprezentációknak a transzfere történik nyelvspecifikus angol reprezentációkba (MRS). Végül a szemantikai reprezentációból angol nyelvű mondatot generálnak HPSG alapú elemző (generáló) segítségével (célnyelvtan: ERG, generátor: LKB). A projekt hosszú távú, bár célja egyelőre csak egy demonstráció fejlesztése, amely megmutatja, hogy a mechanizmus működik. A többértelműség kezelésére valószínűségi rangokat használ. Fontos jellemzője a modularitás, így mindig a legfrissebb elemzőt rakhatják a rendszer mögé.

4.2 Javaslatunk

A ReALIS projekt a végsőkig viszi a lexikalista megközelítést. Azt próbálja igazolni, hogy nincs szükség frázis-struktúrára: a mondatok összeépüléséhez elégséges a lexikai egységek gazdag jegystruktúrája és egyetlen művelet, az unifikáció.

Schneider [21] is amellet érvel, hogy nem feltétlenül kell konfigurációs felszíni reprezentációs szint a nyelv szintaktikai elemzéséhez. Az LFG például főleg azért használ c-struktúrát (összetevős szerkezetet), mert az környezetfüggetlen. Ha csak a függőségi viszonyokat mutató f-struktúrát használná, az nem lenne hatékony, mivel környezetfüggő. Akárcsak a Függőségi Nyelvtan, ahol (eredetileg) szintén csak funkcionális szint van, nem használ összetevős szerkezetet. A szórendnek nincs elsődleges szerepe (néha segít az egyértelműsítésben), de valójában nincsenek megszorítások arra nézve, hogy egy fej hol keresse a bővítményeit. Schneider [21] megmutatja, hogyan lehet az f-struktúrát környezetfüggetlenül előállítani, így nem lenne szükség a teljes c-struktúrára, csak a fontosabb elemeire.

A totálisan lexikalista megközelítés a végsőkig viszi ezt a javaslatot: kipróbálja, lehetséges-e semmivé redukálni a c-struktúrát. Készíthető-e hatékony elemző (és gépi fordító) rendszer akkor, ha nem támaszkodunk a környezetfüggetlen c-struktúrára, vagy egyéb konfigurációs felszíni reprezentációs szintre. Véleményünk szerint a válasz igen: a megközelítés hatékony, mert a függőségi nyelvtanokkal szemben nálunk vannak megszorítások a szórendre, az ún. rangparaméterek formájában [3]. Ezekkel a paraméterekkel elegánsan megragadható az is, hogy egy nyelven belül milyen szórendi variánsok lehetségesek, és számot ad a nyelvek közötti szórendi különbségekről is.

Célunk tehát egy olyan (szabályalapú) elemző és gépi fordító rendszer fejlesztése, amely totálisan lexikalista, nyelvfüggetlen, és minden eddiginél alaposabb szemantikai reprezentációt társít nem csupán mondatokhoz, hanem szövegekhez. Programunk a 3. pontban bemutatott nyelvenkénti sokszínűséget ezt a (ReALIS alapú) szemantikai reprezentációt mint közvetítőnyelvet alkalmazva hidalja át, hiszen

ez nyelvfüggetlen közös alapot jelent, amihez képest aztán a felszíni megjelenítés az egynyelvű komponensek feladata. Így a fordításhoz alaposan kidolgozott elemzőkre van csupán szükség, melyek legfontosabb része a szemantikai komponens; hiszen programunk ugyanazt a mechanizmust használná bármely két nyelv esetében, és a fordítási iránytól függetlenül.

Morfémaszintű totális lexikalizmusunk pedig oly módon fejleszti tovább a grammatika *egyszintűségének* a gondolatát, hogy a kategoriális többértelműség alább szemléltetett potenciális túlbujánzása kikerülhetővé válik, hiszen az adott példában egy moduláris rendszer szintaxisának 72 megemlített lehetséges bemenete helyett pusztán azt a három elemzési utat kell bejárnunk, amit az időjeles igeeként elemezhető három egység indít el.

$$\begin{array}{ccccccc}
 (6) & \text{Dobom} & & \text{az} & \text{ír} & & \text{szánom.} \\
 & \text{N+poss1sg+Nom/N+poss1sg+Acc/V+1sg} & & \text{Pron/D} & \text{V/A/N}_1/\text{N}_2 & & \text{N+poss1sg+Nom/N+poss1sg+Acc/V+1sg} \\
 & 3 & \cdot & 2 & \cdot & 4 & \cdot & 3 & = & 72
 \end{array}$$

A magyar nyelvre nem készült még olyan alapos elemző és gépi fordító program, mint amilyen a ReALIS projekt céljai között szerepel. Olyan jelenségekről is számot kívánunk adni, mint a retorikai viszonyok (hogyan kapcsolódnak a mondatok egymáshoz), a különféle diskurzus-funkciók (mint a topik és a fókusz), vagy a hangsúly és az aspektus. Mindehhez egy minden eddiginél alaposabban kidolgozott formális szemantikai eszköztár áll rendelkezésünkre.

5 Összegzés

Az elmúlt években a GeLexi projekt egy magyar és angol mondatokat elemző Prolog programot fejlesztett, hogy igazolja a totális lexikalizmus eszméjének a gyakorlatban való alkalmazhatóságát [3]. Megmutattuk, hogy az elemzőnk kétirányú használatával a gépi fordítás is lehetséges, a diskurzus-szemantikai reprezentációt mint közvetítőnyelvet alkalmazva [4]. Eközben a LiLe projekt egy relációs adatbázis létrehozásába fogott, egyéb célok mellett azért, hogy nagyobb adatbázison vizsgálhassuk a totálisan lexikalista megközelítés hatékonyságát [6].

A ReALIS projekt keretében a két kutatócsoport egyesült, és további nyelvészek bevonásával azt a célt tűzte maga elé, hogy minden eddiginél pontosabb gépi fordítást valósítson meg, lényegesen nagyobb adatbázison. Rendszerünk szabályalapú, mélynyelvészeti elemzést végez, a totálisan lexikalista GASG (Generatív Argumentumstruktúra Nyelvtan) alapján, amely nem rendel összetevős struktúrát a mondatokhoz, csupán a lexikai egységek tulajdonságaira támaszkodik az elemzés során, a szórendről pedig rangparaméterek segítségével ad számot. A mondatokhoz rendelt diskurzus-szemantikai reprezentáció, amely a ReALIS [1] implementációján alapul, az eddigi (LDRT-alapú) reprezentációnál jóval részletesebb, olyan jelenségekről is számot tud adni, mint a retorikai viszonyok, a diskurzusfunkciók vagy az aspektus. A reprezentáció nyelvfüggetlen, így a gépi fordítás során nem okoz problémát a nyelvek sokfélesége: bizonyos lexikai egységek az egyik nyelvben szavak, a másokban szuffixumok, a topikalizációt az egyik nyelv pusztán a szórenddel, a másik képzők hozzáadásával fejezi ki, vagy a progresszív aspektust az egyik nyelvben segédige jelzi, a másokban pedig egy vonzat esetének módosítása.

Az utóbbi években a mélynyelvészeti, lexikalista, unifikációra épülő elemzők és gépi fordító rendszerek egyre nagyobb teret hódítanak. Már nem csupán pontosabbak, mint a mintaalapú vagy sekélyelemzést végző rendszerek, hanem lefedettségben is kezdik felvenni a versenyt velük. Ezeknek a rendszereknek a sikere még inkább arra ösztönöz minket, hogy folytassuk a totálisan lexikalista megközelítés nyelvtechnológiai alkalmazhatóságának vizsgálatát, és létrehozzunk egy minden eddiginél pontosabb gépi fordító rendszert.

Bibliográfia

1. Alberti, G.: ReAL Interpretation System. L. Hunyadi – Gy. Rákosi – E. Tóth eds.: Preliminary Papers of the Eighth Symposium on Logic and Language, University of Debrecen (2004) 1–12
2. Alberti, G.: Changes in Argument Structure in the course of Derivation in Hungarian. *Acta Linguistica Hungarica* (2006)
3. Alberti, G., Kleiber, J., Viszket, A.: GeLexi project: Sentence Parsing Based on a Generative LEXIcon. *Acta Cybernetica* 16 (2004) 587–600
4. Alberti G., Kleiber J., Viszket A.: GeLexi projekt: Fordítás totálisan lexikalista alapokon. In: Alexin Z. – Csendes D. (szerk.): II. Magyar Számítógépes Nyelvészeti Konferencia, Juhász Nyomda, Szeged (2004) 73-80
5. Bender, E. M., Flickinger, D., Oepen, S.: The Grammar Matrix: An Open-Source Starter-Kit for the Rapid Development of Cross-Linguistically Consistent Broad-Coverage Precision Grammars. In Proc. COLING 2002 Workshop on Grammar Engineering and Evaluation. Taipei (2002)
6. Bódis Z., Kleiber J., Szilágyi É., Viszket A.: LiLe projekt: Adatbázis mint „dinamikus korpusz?”. In: Alexin Z. – Csendes D. (szerk.): II. Magyar Számítógépes Nyelvészeti Konferencia, Juhász Nyomda, Szeged (2004) 11–18
7. Bond, F., Oepen, S., Siegel, M., Copestake, A., Flickinger, D.: Open source machine translation with DELPH-IN. In Proceedings of the Open-Source Machine Translation Workshop at the 10th Machine Translation Summit, Phuket, Thailand (2005) 15-22
8. Butt, M., Dyvik, H., King, T. H., Masuichi, H., Rohrer, C.: The Parallel Grammar project. In Proceedings of COLING-2002 Workshop on Grammar Engineering and Evaluation, Taipei, Taiwan (2002)
9. Copestake, A.: Implementing Typed Feature Structure Grammars. Stanford, CA: CSLI Publications (2002)
10. Forst, M., Kuhn, J., Rohrer, C.: Corpus-Based Learning of OT Constraint Rankings for Large-Scale LFG Grammars. In: Butt, M. – King, T. H. (eds.): Proceedings of the LFG'05 Conference, University of Bergen, CSLI Publications (2005) 154-165
11. Frank, A.: From parallel grammar development towards machine translation. In Proceeding of MT Summit VII (1999) 134–142
12. Frank, A.: Projecting LFG F-structures from Chunks --- or (Non-)Configurationality from a different Viewpoint. In: Butt, M. – King, T. H. (eds.): The Proceedings of the LFG'03 Conference, University at Albany, State University of New York, CSLI Publications (2003) 217-237
13. Halácsy P., Kornai A., Németh L., Sass B., Varga D., Váradi T., Vonyó A.: A hunglish korpusz és szótár. In: Alexin Z. – Csendes D. (szerk.): III. Magyar Számítógépes Nyelvészeti Konferencia, Juhász Nyomda, Szeged (2005) 134-143
14. Homola, P., Kuboň, V.: A Translation Model for Languages of Acceding Countries. In: John Hutchins (ed.): Broadening Horizons of Machine Translation and its Applications.

- Proceedings of the Ninth EAMT workshop. Foundation for International Studies, University of Malta, Valletta (2004) 90-97
15. Hutchins, J.: Machine Translation: General Overview. In Mitkov, R. (ed.): The Oxford Handbook of Computational Linguistics. Oxford Univ. Press, New York (2003) 501-511
 16. Kamp, H., van Genabith, J., Reyle, U.: Discourse Representation Theory. Ms. to appear in Handbook of Philosophical Logic. Source: <http://www.ims.uni-stuttgart.de/~hans> (2004)
 17. Kiefer F., Ladányi M.: Morfoszintaktikailag semleges képzések. In: Kiefer F. (szerk.): Strukturális magyar nyelvtan 3. Morfológia, Akadémiai, Budapest (2000) 165-214
 18. Lønning, J. T., Oepen, S., Beermann, D., Hellan, L., Carroll, J., Dyvik, H., Flickinger, D., Johannessen, J. B., Meurer, P., Nordgård, T., Rosén, V., Velldal, E.: LOGON. A Norwegian MT effort. In Proceedings of the Workshop in Recent Advances in Scandinavian Machine Translation, Uppsala, Sweden (2004)
 19. Prószték G., Tihanyi L., Ugray G: Moose: a robust high-performance parser and generator. In: John Hutchins (ed.): Broadening Horizons of Machine Translation and its Applications. Proceedings of the Ninth EAMT workshop. Foundation for International Studies, University of Malta, Valletta (2004) 138-142
 20. Schneider, G.: A Broad-Coverage, Representationally Minimal LFG Parser: Chunks and F-structures are Sufficient. In: Butt, M. – King, T. H. (eds): Proceedings of the LFG'05 Conference, University of Bergen, CSLI Publications (2005) 388-407
 21. Siegel, M. – Bender, E. M.: Head-Initial Constructions in Japanese. In: Müller, S. (ed.): Proceedings of the HPSG04 Conference, Center for Computational Linguistics, Katholieke Universiteit Leuven, CSLI Publications (2004) 244-260
 22. Somers, H.: Machine Translation: Latest Developments. In Mitkov, R. (ed.): The Oxford Handbook of Computational Linguistics. Oxford Univ. Press, New York (2003) 512-528
 23. Tamm, A.: Relations between Estonian verbs, aspect, and case. PhD thesis (Linguistics), Eötvös Loránd University, Budapest, Hungary (2004)

A lexikalista szintaxis rangja(i)

Szilágyi Éva, Kleiber Judit, Alberti Gábor⁵

PTE BTK Nyelvtudományi Tanszék;
Pécs 7624 Ifjúság útja 6.
realis@mail.btk.pte.hu

Bevezetés

Az MSZNY konferencián többször szerepelt GeLexi [5] és Lile [6] projektek örökén szerveződött a ReALIS projekt a PTE BTK Nyelvtudományi Tanszékén 2006-ban. Alapvető célunk továbbra is az intelligens nyelvészeti alapokon történő fordítás, totálisan lexikalista keretben [1]. A lexikont egy relációs adatbázis képviseli, amit MS SQL2005-ben valósítunk meg.

Egy relációs adatbázis lényege a „relációk” definíciójában áll, amely a reprezentálandó tények leírása mellett, magát az adatbázist alkotja. A leírás az egyedkapcsolat modellen alapul. Minden egyes entitás egy rendezett n -es: elemei valamilyen relációt alkotnak — ez egy rekord. A reláció maga a tábla, ahol minden egyes sor (rekord) egy rendezett n -es, és minden oszlop egy attribútum. A relációk egyedei közötti kapcsolatok állhatnak fel [7]. A számtalan adatbázis-kezelő rendszerből és SQL-megvalósítás közül választásunk az Microsoft SQL Server 2005 rendszerre esett: ezáltal egy komplett relációsadatbázis-kezelő keret rendelkezésünkre áll, és számos olyan szolgáltatással is rendelkezik, amelyet céljaink eléréséhez ki tudunk használni: elsődlegesen a kliens-szerver architektúrát, amelynek köszönhetően az adatbázis egyidejűleg több felhasználó és programmodul által is elérhető, vagyis a felhasználók a rá épített webes felületen keresztül, ingyenesen használhatják a rendszert.

A morfofonológiai komponens alapvetően a Lile adatbázisából vettük át. Jelenleg a szintaxis „szabályainak” a lexikonba építésén dolgozunk, erről szól a poszterünk is. A fő komponens az ez után fejlesztendő szemantika jelenti, amit a ReALIS [4] dinamikus szemantikai rendszer implementációjaként képzelünk el.

Predikátumok és argumentumok, régensek és vonzatok

A totális lexikalizmus eszméjével összhangban a fent említett „szabályok” nem szabályok, hanem az egyes lexikai elemekre jellemző tulajdonságok, amelyek végül unifikálód(hat)nak. Egy lexikai egységről tárolnunk kell azt, hogy milyen argumentumokat követel, illetve azokat milyen vonzatként kéri megvalósítani (akár

⁵ Ezúton szeretnénk köszönetet mondani az OTKA-nak (OTKA K60595) a támogatásért.

több lehetséges változatban). Ezek mellett fontos tényező még a szórend kialakulása, amelyről az általunk használt nyelvtan-modellben rangparaméterek adnak számot. A rangparaméterek egy „speciális” megjelenése számot tud adni az olyan esetekről is, amikor a mondatban a semleges szórendet megvariáló (az írott magyar mondatokban másképpen nem észrevehető) fókusz vagy egyéb operátor van jelen.

A lexikai egységek által követelhető (követelt) argumentumstruktúrákat⁶ egy egyednek tekintjük, ennek elemeit egy olyan készlet adja, mely megmondja, milyen típusú argumentumok fordulhatnak elő. Ezek jellemzését egy olyan számparaméter adja, amely az ágens-pacientív skálán helyezi el az argumentumot.⁷ Az argumentumok így egy argumentumstruktúra, valamint az argumentumtípus kapcsolatából képződnek.

A másik oldalt a hasonlóan felépített vonzatkeretek jelenik. Egy egyednek képeznek a lexikai egységek által követelhető (követelt) „vonzatkeretek”: ezt kétirányúan tároljuk, a régens és a vonzat felől is,⁸ elemei pedig az ezek típusait definiáló készletből származnak. Ez a készlet nemcsak esetragokat tartalmaz, hanem az olyan alakzatokat, mint a névutók vagy az infinitívusz, illetve az olyan állandósult kifejezéseként használt szerkezetek, amelyekre egy-egy esetragos alak cserélhető. Például: *Péter elárul pár dolgot Mariról / Marival kapcsolatban*. Az egyes vonzatokat tehát a vonzatkeret és egy vonzattípus kapcsolatai jelentik.

Előfordulnak olyan esetek is, amikor a lexikai egység nem ad számot az argumentum esetéről. Például a *lakik* ige esetén két argumentum szerepel: egy *lakó* és egy *hely*, ahol ő lakik. A vonzatok között szintén kettőt találunk egy NOM esetet, amit a lakó számára tartogat a lexikai egység (amit a vonzat és az argumentum összekötése ad meg; „bármire illeszhető” típusokkal is dolgozva), és egy másik vonzatot, amelynek az esete nem specifikált – ennek ellenére hiánya agrammatikus mondatot eredményez. Erre az esetre az argumentumtípusok és a vonzattípusok is összeköthetőek: a példában az argumentum HELY típusához így szelektálhatók az olyan vonzattípusok, mint a -bAn (*egy szép házban*), az -On (*Szentesen*) vagy a mellett (*az iskola mellett*).

A szintaxisnak számot kell még adnia a szabad határozókról. Szabad határozónak azt tekintjük, ahol a rag kompozicionálisan szerepel, csak úgy mint [8], ám vonzatnak tekintjük az olyan kompozicionális elemeket, amelyeknek a jelenlétét valamelyik másik elem előírja. Ekkor a rag (vagy a lexikai egység, pl. *ott*) árulja el magáról, hogy ő az általa keresett főnévvel együtt szabad határozóként jelenhet meg. A szemantikai struktúra fog a lexikai egységeknél olyan tulajdonságokat megadni, ami alapján például a különböző típusú időhatározók közül a grammatikusakat ki lehet választani. Modellünkben ezek az elemek a mondat eventuais argumentumát keresik.

⁶ Több argumentumkeretnek tekintjük azt a névszókra jellemző jelenséget, hogy lehetnek ők maguk vonzatok, illetve lehetnek névszói állítmányként predikátumok is. Ezek mellé kell még számolnunk a rövid birtokos formát is, ami keres egy birtokos személyjelet. (Pl. *Péter Budapesten lakik. Annak a fiúnak a neve Péter. Péter kalapja*)

⁷ Az ilyen szempontból semleges argumentumok semleges számparamétert kapnak, mivel a centrális keretben – amely az alanyok és tárgyak viszonyainak alakulását írja le – nincsenek benne.

⁸ A szabad bővítmények csak egyirányúak

Rangparaméterek

A lexikai egységek a követelményeik mellett azt is megmondják, mennyire szükséges azt kielégíteni, és a szomszédosságra vonatkozó követelmény esetén azt is, hogy az azt kielégítő elemet milyen irányban, illetve hogy a szón belül vagy egy másik szóban keresik. Ennek okát az adja, hogy ami szemantikai kapcsolatban áll a régenssel, az annak szomszédja szeretne lenni. Mivel azonban a mondatok lineárisak, a régensnek mindössze két szomszédja lehet: ám sokkal inkább csak egy, hiszen a régensek a nyelvre jellemzően egy irányból veszik fel a vonzataikat⁹. A rangparaméterek a nyelv leírásából derülnek ki, tapasztalat útján; tárolásuk az egyes vonzatoknál történik. Minden nyelv régensei ugyanazt a követelményt támasztják (ezért is egy egyed – egy tábla), ám különféle erősségű rangokkal (amelyek így a nyelvek közötti különbségekről is számot adnak, lásd pl. *scrambling* jelenségek).

A rangparaméterek kétféle kielégíthetőségi követelménnyel léphetnek fel. A *domináns* rangparaméterek esetében elegendő, ha egy ellentmondó, erősebb paraméter ki van elégítve. A szomszédossági viszonyokat megadó *recesszív* paraméterek esetén a követelményt mindenképpen ki kell elégíteni – akár részlegesen is [3].

Az igeikötők esetében például kétféle rangparaméter is él, mindkettő recesszív: Az egyik esetben az *el* igeikötő az *indul* elé kell, hogy kerüljön, ezt egy erős (-2) rangparaméter mondja meg. Fonológiai szempontból a hangsúly is az igeikötőre esik, míg az igeről lekerül, így egy fonológiai szót alkotnak; ez az aspektualizáló argumentum¹⁰ [2]. A második esetben az igeikötő kerülhet az ige mögé is egy gyengébb (+3) rangparaméter szerint, ekkor mindkét elem külön fonológiai szóként realizálódik.

Semleges mondatban az erősebb (-2) rang elégül ki, míg egy fókusz megjelenése esetén, ami erős domináns típusú rangparamétert jelent¹¹, az igeikötő ígét megelőző helyére vonatkozó követelményt nem lehet, és nem is kell kielégíteni. A gyengébb (+3) rangparaméter követelménye viszont továbbra is jelen van, így azt ki lehet és kell elégíteni.

Nemcsak az igeikötő lehet aspektualizáló: hasonló a helyzet a már említett *lakik* igenél: a helyre vonatkozó vonzatát – pl. *Budapesten* – az erős (-2) ranggal szeretné maga előtt tudni, vagy egy gyengébb (+3) ranggal maga mögött. Ez speciális eset, ahol az aspektualizáló argumentum a lokatívusz. Bizonyos esetekben igeikötős ige esetén is ez az aspektualizáló vonzat: a *megszáll* igével semleges esetben a *Péter Budapesten szállt meg* a grammatikus mondat, míg semmiképpen nem semleges a *Péter megszállt Budapesten*. Az aspektualizáló argumentumot mindig két ranggal vesszük fel.

A fókusz, ami ugyan (a magyarban) hangalakot nem ölt, lexikai egységként jelenik meg az adatbázisban. A mondatban két elemet keres: a fókuszált elemet és az ígét. Az

⁹ Az irányultságot a szám 0-hoz viszonyított iránya fejezi ki, vagyis negatív számok jelentik a megelőző elemként való keresést, és pozitív számok a következő elemre vonatkozó keresést. Az erősséget a paramétert jelentő szám abszolút értéke adja.

¹⁰ Mindig van egy olyan vonzat, amit aspektualizálásra használ az ige (Rendszerint az igeikötőt, alkalmanként saját magát, pl. *Péter csalódik Mariban*).

¹¹ Amit először ki kell elégíteni, hogy ez után kiírtódhassanak a dominánssal ellentétes követelmények; és ez után következnek a recesszívek.

igének olyan rangparamétert oszt, hogy annak mögötte kell lennie, a legerősebb (+1) domináns rangban. Hasonlóan kezelhető a telikus szituációkra vonatkozó progresszív alak működése is.

Megfigyelhetünk olyan elemeket is, amelyek jelenlétében mindig található fókusz is, ilyen például a *csak*, illetve a mondatrészttagadást jelző *nem*. Ezen elemek erős domináns ranggal vonzzák a fókusz maguk mögé, ami a szórendi változásról gondoskodik.

Befejezés

Rendszerünk előnye és újszerűsége abban rejlik, hogy a lexikonban ugyanazon keretek között kezelhető a szintaxis körébe (is) tartozó számos tényező (predikátum-argumentum, illetve régens-vonzat viszonyok, szabad határozók, szórend).

A rangparaméterek elegánsan számot adnak az egy nyelven belüli szórendi variációkról (a szón belül a morféma sorrendjéről), valamint a nyelvek közötti különbségekről is. A domináns rangparaméterek használatával a szórendet megvariáló, sokszor láthatatlan elemek (fókusz, progresszív) is kezelhetőek.

Projektünk jelenleg a fent vázolt rendszer megvalósításán dolgozik. A következő lépés a fő komponensként elképzelt szemantika implementálása lesz, mert hisszük, hogy intelligens alkalmazások csak valós nyelvészeti alapokon készíthetők, ahhoz pedig alaposan kidolgozott szemantikai rendszerre van szükség.

Hivatkozások

- [1] Alberti G.: GASG: The Grammar of Total Lexicalism; IN: Working Papers in the Theory of Grammar 6/1. Theoretical Linguistics Programme, Budapest University and Research Institute for Linguistics, Hungarian Academy of Sciences, 1999
- [2] Alberti G.: Az aspektus szintaxisa a magyarban; IN: Újabb tanulmányok a strukturális magyar nyelvten és a nyelvtörténet köréből, Osiris, Budapest, 2001; pp.145-164.
- [3] Alberti G., Balogh K., Kleiber J., Viszket A.: A totális lexikalizmus elve és a GASG nyelvten-modell; IN: Maleczki Márta (szerk.): A mai magyar nyelv leírásának újabb módszerei V. SZTE, Szeged, 2002; pp. 193-218
- [4] Alberti G., Dóla M., Farkas J., Kántor Gy., Kleiber J., Ohnmacht M. (2007): ReALIS: a "reális" interpretációs rendszer; IN: Alberti G. és Fóris Á. (szerk.) A mai magyar nyelvtudomány formális műhelyei, Nemzeti Tankönyvkiadó, Budapest, pp. 139-156.
- [5] Alberti G., Kleiber J., Viszket A.: GeLexi projekt: Gépi fordítás totálisan lexikalista alapokon; : Dr. Alexin Z., Csendes D. (szerk.): MSZNY2004 - II. Magyar Számítógépes Nyelvészeti Konferencia; Informatikai Tanszékcsoport, Szeged, 2004; pp.73-80
- [6] Bódis Z., Kleiber J., Szilágyi É., Viszket A.: Lile projekt: Adatbázis mint "dinamikus korpusz"; IN: Dr. Alexin Z., Csendes D. (szerk.): MSZNY2004 - II. Magyar Számítógépes Nyelvészeti Konferencia; SZTE Informatikai Tanszékcsoport, Szeged; pp.11-18
- [7] Halassy B.: Az adatbázis-tervezés alapjai és titkai. Avagy az út az adattól az adatbázison át az információig; IDG, Budapest 1994
- [8] Gábor K. - Héja E.: Predikátumok és szabad határozók, IN: Kálmán László (szerk.) KB 120 A titkos kötet, MTA Nyelvtudományi Intézet Tinta Könyvkiadó, Bp., 2006; pp.134-152.

Vonzatkeretlisták helyett polaritásos hatáslánccsaládok – avagy a \Re eALIS σ függvénye

Alberti Gábor¹ és Kilián Imre²

¹ PTE BTK Nyelvtudományi Tanszék
 \Re eALIS Elméleti és Számítógépes Nyelvészeti Kutatócsoport
albi@btk.pte.hu

² \Re eALIS ESzNyK / PTE TTK Informatika Tanszék
mindkét cím: 7624 Pécs, Ifjúság útja 6.
kilian@gamma.ttk.pte.hu

Kivonat: A számítógépes fordításra [5] és más intelligens nyelvfeldolgozási feladatokra [6] irányuló kutatásaink során korábban *esetkeretlisták* formájában tároltuk az igék és más régensek legalapvetőbb vonzatszerkezeti tulajdonságaira vonatkozó információt. Mára megérett a lehetőség a \Re eALIS elmélet nyújtotta dinamikus diskurzus-szemantikai alapokon [10] arra, hogy elméleti nyelvészeti szempontból jóval igényesebb struktúrában (*polaritásos hatáslánccsaládok* formájában) rögzítsük a rokonítható vonzatszerkezet-változatokat [2], amiből sokkal több információ nyerhető ki a vonzathelyek betöltésére vonatkozóan [1]. Mindezt az „élethossziglani” (‘lifelong’) \Re eALIS keretbe ágyazva tudjuk elhelyezni, egy szövegelemző interpretáló információállapotának részeként [7]. A technológiai oldalon a Prolog nyelv alkalmazásának előnyeiről és mikéntjének fogásairól számolunk be.¹²


1 A \Re eALIS mint nyelvelméleti keret

A címben szereplő \Re eALIS elméletet a Montague-féle formális szemantika [11] és az abból kisarjadó, kisdiskurzusok jelentésábrázolására kidolgozott (Kamp-féle reprezentacionalista dinamikus szemantikai) DRT elmélet [12] továbbfejlesztéseként szoktuk bemutatni [6][4].

Az alábbi 1. ábrán összevetjük a megemlített három jelentéselméletnek a nyelvi forma és a világmodell kapcsolatáról felállított modelljét. Ez alkalmat ad arra, hogy felvázoljuk a \Re eALIS kidolgozása melletti döntő metaelméleti érvet. Montague elméletileg igazolta, hogy nincsen szükség a nyelvi forma interpretációja során sem a korábban alkalmazott logikai reprezentációra, sem másfajta közvetítő reprezentációra; de e matematikai tételt nem tudta maradéktalanul átültetni a gyakorlatba. Ez követőinek sem sikerült, sőt egyenesen kialakult egy *reprezentacionalista* irányzat, mely a közvetítő reprezentáció kiküszöbölhetetlenségét mutatta be nyelvi adatokon,

¹² A szerzőket e cikk megírásában az OTKA T60595 sz. projektje támogatta. Értékes megjegyzéseikért elsősorban a \Re eALIS ESzNy Kutatócsoport további tagjainak szeretnénk köszönetet mondani: Kleiber Juditnak, Károly Mártonnak és Farkas Juditnak.

és funkciójára is magyarázatot talált [12]: a *diskurzusbázis* önálló szintjeként meghatározva azt. A *ReALIS*-modell képes feloldani a matematikai elmélet és a nyelvi gyakorlat közötti látszólagos ellentmondást egy további tényező, a kettős természetű *interpretálói elme* reprezentációjának a bevonásával.



1. ábra A nyelvi forma és a világmodell kapcsolatának háromféle formális modellje

Az önálló diskurzusreprezentációs szint úgy küszöbölhető ki, ha (nyelvészetiileg releváns) információtartalmát beágyazzuk a világmodellbe, mégpedig a hangfolyamat strukturált diskurzusként felfogó interpretálói elme reprezentációjának részeként. Az interpretálói elmék pedig nyilván részei a világmodellnek, hiszen tartalmuk éppúgy beszéd tárgyat jelent (ki mit tud, hisz, tervez?), mint mondjuk egy lakás részletei, egy állat felépítése, egy város struktúrája. Ami megkülönbözteti a reprezentálandó objektumok körében az elmét az utóbb említett dolgoktól, az az, hogy az elme kettős természetű a reprezentáció folyamatának szempontjából: nemcsak tárgya, de létrehozója is az ábrázolatoknak.

A *ReALIS*-modell ennek az alapgondolatnak a formalizált kidolgozását és nyelvészeti alkalmazását jelenti. A mintegy 40 oldalnyi definíciós állomány (<http://lingua.btk.pte.hu/realispapers>) ismertetésére nyilván ehelyütt nincs mód; most a nyelvtechnológiai relevancia mellett kell érvelnünk. A döntő általános érvelés az, hogy az intelligens nyelvtechnológiai feladatok (például számítógépes jelentésreprezentáció, illetve fordítás) végső soron a kommunikáló emberi elmék lehető legfinomabb modellezését kívánják meg. Idézzünk néhány ezt szemléltető közismert példatípust egy másik cikkünkben [7] az alábbi (1) pontban.

Hogy *a miniszter-re* való visszautalás (1a) egy angol fordításban *he* vagy *she* legyen-e, annak eldöntése a szövegkontextus világában való tájékozottságot tesz szükségessé. A magyar szövegben pedig az elnökre utaló *az* névmás jól formáltsága az adott helyen a *diskurzus* szerkesztésének módján múlik: *topikváltás* történik a második mondatban [17].

Az (1b) azt szemlélteti, hogy egy szöveg jólformáltsága (és értelmezési lehetősége) múlhat olyan *ontológiai* ismereteken, mint a bernáthegeyi és a kuvasz besorolása a kutyák kategóriájába, a papagájé pedig a madarakéba.

Az (1c) a Szegmentált DRT nevű irányzat [8] egyik iskolapéldája arra, hogy egy szöveg mondatai között (kötőszavak híján is) fel kell tárunk a *retorikai* relációkat, melyek az *időstruktúrára* is befolyással lehetnek. A nyelvtechnológia szempontjából

az most a megfigyelni való, hogy ha a második mondatban az első mondat *okát* ismerjük fel, akkor fordíthatjuk angolra Past Perfect idővel; *narratív* retorikai reláció feltételezése mellett viszont nem (ami az erőltetettebb eset). Az *ok* reláció felismerése viszont azt a világismeretet igényli, hogy az *elesésnek* a véletlen megbotlás mellett egy akaratlagos ellökés is lehet a kiváltója.

- a. Megpillantottam az elnököt. *Az* viszont nem láthatott meg engem. (1)
- b. Van egy bernáthegyim, egy kuvaszom és egy papagájom.
 - b.1. ... *A két kutya* gyakran felbosszantja *a szegény madarat!*
 - b.2. ... **A kutya* gyakran felbosszantja *a két szegény madarat!*
- c. Péter elesett. Jancsi csúnyán meglökte.
- d. A kalózvezér *elásatta* a rabolt kincseket.
... *Az emberei* napokig küszködtek *a fagyos földdel*,
de még így sem sikerült *kellően mély gödröket* csinálniuk *a hitvány ásóikkal*.

Végül az (1d) diskurzus a cikk központi témáját jelentő *hatáslánccsaládok* háttérismeretét szemlélteti, amit egyfajta kiterjesztett *lexikai tudás* részének tartunk. Az *elásat* igealak explicit módon csak egy Okozó szereplő (a kalózvezér) és egy Páciens jellegű szereplő (a kincsek) relációját mutatja be. A második mondat kézenfekvő értelmezése viszont feltételezi az alábbi hatáslánc felidézését (ami a jelentésábrázolás vagy -kivonatolás során is releváns): az Okozó *közvetlen* hatást (mondjuk egy kiadott parancs révén) az Ágensekre gyakorol (az embereire), akik Eszközök (a hitvány ásó) segítségével (fagyos) földdarabokat (szintén Páciens?) ásnak ki eredeti helyükről (Kezdőpont?), egy vagy több gödröt létrehozva; a kincsek végül is idekerülnek az Okozó akaratából. Az említett szereptípusok a *tematikus szerephierarchiákra* épülő továbbfejlesztett modelljét [2] [4] vesszük alapul e projektben.

Azt az álláspontot képviseljük tehát, hogy az intelligens nyelvtchnológiai feladatok olyan modellezését kívánják meg a kommunikációban álló emberi elméknek, ami hatalmas (és dinamikusan fejleszthető) kulturális/enciklopédikus, ontológiai és erősen kiterjesztett lexikai információs bázison alapul. A matematikailag formalizált *ReALIS*-modell (*Reciprocal and Lifelong Interpretation System*) éppen ezt kínálja, „kölcsonös” és „élethossziglani” jellegéből adódóan: a kölcsönösség a kommunikációs interakció megragadását biztosítja, az élethossziglaniség pedig hatalmas, folyamatosan bővíthető adatbázisokat jelent. Egyszerűen fogalmazva, a számítógépes jelentéskivonatolás és fordítás jövőjét abban látjuk, hogy a gép egykor úgy fog majd működni, mintha a megfigyelő/fordító (interpretáló) ember tevékenységét szimulálná.

A *ReALIS* interpretáló-modelljének *szimultán rekurzív* definícióját röviden és informálisan úgy vázolhatjuk fel, mint egy élethossziglani folyamat leírását, amelynek során egy kezdetben (a születés idealizált pillanatában) strukturálatlan referenshalmazon négy reláció terjeszkedik ki, mintegy leképezve a környező világ hatásait. Az α *horgonyzófüggvény* az ugyanazon szereplőre mutató referenseket társítja egymással (az interpretáció során leginkább a régensekhez megtalált vonzatok és a határozott főnévi kifejezésekhez megtalált antecedensek alapján). Egy interpretálói elmében α relációban áll például rengeteg olyan referens, ami W. A. Mozartra vonatkozó információ formulájában szerepel, a híres zeneszerzőre utalva. A

λ szintfüggvény a klasszikus szemantikából ismert konstans-változó megkülönböztetés általánosításaképpen fogható fel, e kételemű reláció helyett egy gazdag részbenrendezési struktúra osztályaiba („világocskákba”) sorolva a külvilág entitásaira utaló referenseket és az interpretálói hiedelmek, vágyak, feltételezések, szándékok és tervek „fiktív” referenseit. A κ kurzor az interpretáló koncentrált figyelmét kívánja modellezni, pillanatonként változó módon kijelölve idő-, tér-, topik- és eseményreferenseket. Végül a σ *eventuális* függvény feladata „összerakni” a referensekből azokat a formulákat, amelyek megragadni hivatottak az eseményeket és állapotokat (azaz „eventualitásokat”). Ez teszi lehetővé a *robustusságot*: külön-külön is információt adnak a referensek, nemcsak egyben létezik egy-egy propozíció-formula, mint a korábbi elméleteknél; így a hiányos mondatokhoz is rendelhető valamilyen reprezentáció.

Az alábbi (2) *eventuális* formula például nagyjából egy olyasféle eseményt ($e_{\text{elásatás}}$) ír le a DRT „nyelven” [12], hogy Long John Silver elásatott velem valamilyen kincseket egy szigeten egy bizonyos időpontban ($t_{2010-09-11}$).

$$e_{\text{elásatás}} : p_{\text{elásat}} t_{2010-09-11} \Gamma_{\text{LongJohnSilver}} \Gamma_{\text{kincsek}} \Gamma_{\text{én}} \Gamma_{\text{sziget}} \quad (2)$$

Ezt a \mathfrak{ReALIS} (kétváltozós) σ függvénye úgy ragadja meg, hogy egy referenshez (pl. $e_{\text{elásatás}}$) (ami ezáltal *eventuális referensnek* osztályozódik) és egy szerepparaméterhez hozzárendel egy predikátumot (pl. $p_{\text{elásat}}$), egy időreferenst (t_x) és 0 vagy több argumentumreferenst (r_y). Ez idáig jóformán csak technikai újítás, a lényeg most jön: a szerepparaméter értékvektora választ néhány szereplőt egy *polaritások hatáslánccsaládból*, beállítva az alábbi 1. táblázat bal oldalán felsorolt összes tényezőt a jobb oldali lehetőségek szerint. A következőkben bemutatjuk, hogy ezzel a megközelítéssel milyen széles körben meg tudjuk ragadni az ige (vagy más régens) körül kibontakozó mondat(rész) grammatikai jellemzőit, lehetőségeit, járulékos hangtani és jelentéstani tulajdonságait. Mindenekelőtt azonban megismerkedünk a polaritások hatáslánccsaládokkal.

1. Táblázat: Az argumentumszerepet meghatározó paraméterek és értékeik

HATÓKÖRI SORREND	1, 2, 3, 4, 5, ...
HATÁSLÁNCCSALÁDBELI SZEREP(CÍMKE)	pl. Ág, Pác, Pác', Pác'', Ok, Esz, Idő, Tér
ESETPROMINENCIA [2]	centrális (\rightarrow), nem centr. vonzat (\bullet), szabad hat. (\circ)
INFORMÁCIÓS SZEREP [14]	$\{T, K\} * \{F, Q\} * (M)^C$
REFERENCIALITÁSI FOKOZAT [1]	+hat > [-hat, +spec] > [-spec, +ref] > [-ref, +exp] > \emptyset
BESZÉDAKTUSBELI RÉSZVÉTEL (SAP) [6]	1Sg > 2Sg > ... > 3Pl

2 A polaritások hatáslánccsaládok


Az alábbi 2. táblázat tematikus szerepekkel megadott vonzatszerkezet-változatokat mutat, a termékeny *ás* és a nem igazán termékeny *estedik* igei családjából.

Hogy a fenti 1. táblázatban *centrálisnak* nevezett alanyi és tárgyi grammatikai funkciót mely vonzatszerepekhez társíthatjuk, azt univerzális szabályok korlátozzák [2][3], az adott családra jellemző karakter rögzítésén túl, amit az alábbi 2. ábra mutat be vizuálisan. A lényeg az, hogy a pontsorrallal lehatárolt bal oldali körszeletben vannak

a potenciális tranzitív alanyok („ágens karakter”), a jobb oldaliban pedig a tárgyak („páciensi karakter”) – ez adja a *polaritások* jelleget; továbbá olyan ⟨Alany,Tárgy⟩ vonzatkeret nem lehetséges, amelyben a Tárgy felől mutatna a hatásirány nyila az Alany felé – ez ugyanis megsértené a hatáslánc elvét.

2. táblázat: Két magyar igező néhány vonzatkerete

CENTRÁLIS ESETKERET	<i>esteledek / ás</i>
⟨ ⟩ (Páciens, Idő, Tér)	1. a. Esteledett. / b. Ránk esteledett (8-kor a tóparton).
⟨Ágens, Páciens⟩	2. A kalózek (kétségbeesetten) ásták az agyagos földet.
⟨Ágens, Tér/Idő⟩	3. a-b. A kalózek felásták a szigetet / végigásták a hétvégét.
⟨Ágens, Kezdőpont⟩	4. A kalózek ástak egy mély gödröt.
⟨Ágens, Végpont⟩	5. A kalózek ástak egy sírt.
⟨Ágens, Páciens' / Pác.'⟩	6. a-b. A kalózek elástak / kiástak egy értékes kincset.
⟨Ágens, Eszköz⟩	7. – (* A kalózek kétségbeesetten ásták a hitvány ásoikat.)
⟨Okozó, Pác' / Pác''/Pác'⟩	8. a-b. a-b. A vezér elásatta / kiásatta a kincset.
⟨Okozó, Ágens⟩	9. ^{??} A vezér (álló nap) ásatta az embereit.




2. ábra Két magyar igező (részleges) polaritások hatásláncsaládjá: *esteledek* és *ás*

Az imént meghivatkozott cikkeinkben részletesen ismertetjük, hogy hogyan lehet néhány nyelvi adatból meghatározni egy-egy igező esetében a *polaritások hatásláncsaládot*. Feltételezzük, hogy az „ideális interpretáló” is hasonló módon figyeli meg a hatásirányt, továbbá az ágens/páciensi karaktert a vonzatszerkezetek esetében; ezek alapján aztán felépíti magában a polaritások hatásláncsaládot, ami a továbbiakban meghatározza, hogy milyen vonzatszerkezet-változatokat ítél majd jól formálnak (ellentmondó adatok esetén esetleg módosítva a hatásláncsalád struktúráját). A nyelvtechnológiai alkalmazás ezek után kézenfekvő, összhangban az interpretáló szimulálásának elvével: vonzatkeretlisták helyett polaritások hatásláncsaládok formájában tároljuk a releváns lexikai információt.

Újdonság értékű megállapításunk [2][3] az, hogy a lehetséges vonzatszerkezet-változatok nem (közvetlenül) a tematikus karakterből adódnak, hanem a *hatáslánc*-irányon kívül egyrészt a polaritások hatásláncsaládok *primitív magjából*, amit a 2-3.

ábrán a legfelső kör jelöl, másrészt a (pontsorral jelölt ívek által lehatárolt bal / jobb oldali) *ágens*, illetve *páciensi pólusból*. E négy tényező részben véletlenszerűen alakul ki a nyelv története során egy-egy igető esetében: ebből adódik az alábbi 3. táblázatban szemléltetett különbség a *tör* és a *szúr* lehetséges vonzatkeret-változatai között, miközben a vonzatszerepek tematikus karakterében erőltetett lenne bármi különbséget feltételezni (3. ábra). Arról van szó, hogy a *szúrás* Eszköze tranzitív alanyként és tárgyként egyaránt szerepelhet, míg a *törés* Eszköze tárgyként nem.



3. ábra Két hasonló magyar igető (részleges) polaritások hatásláncsaládjai: *tör* és *szúr*

3. táblázat: A *tör* és a *szúr* vonzatkeret-változatai

<i>tör</i>	CENTRÁLIS ESETKERET	<i>szúr</i>
Betört egy ablak. <i>primitív mag!</i>	⟨Páciens⟩	–
Ez a kalapács még vastagabb ablakot is betörne.	⟨Eszköz, Páciens⟩	Egy szög megszurta a kezemet. <i>primitív mag!</i>
–	⟨Ágens, Eszköz⟩	Péter beleszurta egy szöget az abroncsba.
Péter betörte az ablakot egy kalapáccsal.	⟨Ágens, Páciens⟩	Péter kiszúrta az abroncsot egy szöggel.
–	⟨Okozó, Eszköz⟩	Mari beleszurattott egy szöget az abroncsba.
Mari betörte az ablakot (Péterrel / egy kalapáccsal).	⟨Okozó, Páciens⟩	Mari kiszúrta az abroncsot (Péterrel / egy szöggel).
–	⟨Okozó, Ágens⟩	–

A *ReALIS* modelljében tehát a hagyományos tematikus szerepek [15] csupán címkéként szerepelnek, szemantikai karakterük a polaritások hatásláncsalád struktúrájában betöltött pozíciójuk révén definiáltak.


Térjünk vissza az elméleti kitérő után a 2. ábrához! Az *esteledik* primitív magja üres, amint azt a T2.1.a. példamondat mutatja a fenti 2. táblázatban. Az Idő és a Tér szabad határozói (ld. a külső gyűrűben!) csatlakozhatnak ehhez az igetőhöz, illetve vonzatként egy sajátos Páciens (T2.1.b.), nem alanyi vagy tárgyi (azaz centrális) funkcióban, hanem *-rA* ragos alakban. Az *esteledik* hatásláncsaládjá ennyi.

Az *ás-é* viszont annál gazdagabban burjánzik! A legszűkebb jelentés, a primitív mag földdarabok mozgását írja le (T2.2.). E földmozgató tevékenység kumulálódhat alternatív módokon: behatottá téve egy földterületet (T2.3.a.), egy időszakot (T2.3.b.), vagy *gödört* eredményezve a Kezdőpontból távozó földdarabok helyén (T2.4.). A gödörásásból kiindulva is többféle jelentésbővülést tapasztalhatunk, újabb tranzitív vonzatkeret-változatok formájában: a gödör szolgálhat sírként (T2.5.), vagy kincsek

rejtekhelyeként – ez utóbbi esetben az *ásás* tevékenysége kétféle célt is szolgálhat (T2.6.a-b.). Az *ás* polaritások hatáslánccsaládjában a pontsorívek helyzete megmutatja, hogy az *ásás* Eszköze alanyként / tárgyként nem fejezhető ki (T2.7.), az Ágens tárgyi kifejezése pedig „határeset” (T2.9.). További jelentésbővülést egy Okozó bevonásával érhetünk el (T2.8.a-b.; ld. még (1d) és (2)), ami mellett tárgyként bármely korábban szóba került tárgyat is felvehetünk (pl. *sírt ásat*).

A szakaszban tárgyalt vonzatemélet univerzális. Ennek illusztrálása végett most (kommentárok nélkül) bemutatjuk az egytárgyas és a kéttárgyas angol igetípus tárgyalternációjának és passzivizálásának lehetőségeit, illetve az ezeket meghatározó polaritások hatáslánccsaládjait.

4. táblázat/ábra: Két angol igető (részleges) polaritások hatáslánccsaládjai



<i>load</i> 'rak'	CENTRÁLIS ESETKERET	<i>give</i> 'ad'
He loaded hay onto the wagon. ő rak-Past széna -rA a kocsi 'Szénát rakott a kocsira.'	⟨Ágens, Páciens⟩	He gave a book to Mary. ő adott egy könyv Mari 'Adott egy könyvet Marinak.'
He loaded the wagon with hay. ő rak-Past a kocsi -vAl széna 'Megrakta a kocsit szénával.'	⟨Ágens, Végpont⟩	–
–	⟨Ágens, Végpont, Páciens⟩	He gave Mary a book. ő adott Mari egy könyv 'Adott Marinak egy könyvet.'
The hay was loaded onto wagons a széna volt rak-PastP -rA kocsi-Pl 'A szénát kocsikra rakták.'	⟨Páciens⟩	The book was given to Mary. egy könyv volt ad-PastP -nAk Mari 'A könyvet odaadták Marinak.'
–	⟨Végpont, Páciens⟩	Mary was given a book. Mari volt ad-PastP egy könyv 'Marinak adtak egy könyvet.'
The wagon was loaded with hay. a kocsi volt rak-PastP -vAl széna 'A kocsit megrakták szénával.'	⟨Végpont⟩	–

3 A σ függvény grammatikai paramétervektora

Mint az 1. szakasz végén leszögeztük, a \Re ALIS modelljében egy esemény vagy állapot reprezentációját a σ eventuális függvény szervezi meg, hozzárendelve egy eventuális referenshez a predikátumot képviselő referenst és az argumentumokat képviselő referenseket (valamint egy időreferenst).

Ami a *predikátum* kijelölését illeti, arra az előnyös megközelítésre szeretnénk felhívni a figyelmet, hogy amennyiben az interpretáló például a fenti 2. táblázat valamely mondatában szembesül az *ás* igetővel, nem kell egyből döntenie, hogy melyik vonzatkeret-változatról van szó, hanem annyit kell megállapítania, hogy a 2. ábrán bemutatott bal oldali családot „hívja elő” az *ás* hangalak, rögzítve valamiféle alapjelentést (a potenciális bővítésekkel együtt). Az adott vonzatkeret-változat meghatározása azután egy specifikáló procedúrára van bízva.

E specifikáció az argumentumreferensek *paramétervektorának* beállításával folytatódik (ami technikailag a kétváltozós σ függvény egyik argumentumhelyére kerül, az eventuais referens mellé). Ennek egyik fontos eleme, amint ezt az 1. szakasz végén közölt 1. táblázat 2-3. sora is mutatja, *szerepcímkek* segítségével kiválasztani a polaritásos hatásláncsaládból a predikátummal társítandó argumentumokat, és specifikálni, hogy melyikük kapjon *centrális* funkciót, azaz alanyi / tárgyi megjelenítést.

Az alábbi 5.a-b. táblázat egyetlen vonzatkeret-választást szemléltet a számtalan megengedett változathoz: az Okozónak és az elásandó kincsre utaló Páciens' címkejű szereplőnek biztosítunk centrális grammatikai funkciót; a hatáslánc elvéből adódóan az már determinált, hogy az előbbi alanyként, az utóbbi tárgyként jelenítendő meg.

5. Táblázat: Két argumentum-kiosztás az *ás* predikátumreferens mellett

a. <i>ás</i>	hatókör	szerepcímke	esetprom.	inf. szerep	ref. fokozat	SAP
+ref	1	Ok	→	T	+hat	3Sg
(+ref) _F	2	Tér	○	F	-hat, +ref	3Sg
+ref	3	Pác'	→	C	+hat	3Pl
+ref	4	Ág	●	C	+hat	1Sg

A 'kalózvezér egy ''lakatlan szigeten ásatta el velem a rabolt kincseket.

? A 'kalózvezér egy ''lakatlan szigeten ásatta velem el a rabolt kincseket.

? A 'kalózvezér egy ''lakatlan szigeten ásatta el a rabolt kincseket velem.

?? A 'kalózvezér egy ''lakatlan szigeten ásatta velem a rabolt kincseket el.

?? A 'kalózvezér egy ''lakatlan szigeten ásatta a rabolt kincseket velem el.

??? A 'kalózvezér egy ''lakatlan szigeten ásatta a rabolt kincseket el velem.

b. <i>ás</i>	hatókör	szerepcímke	esetprom.	inf. szerep	ref. fokozat	SAP
(+ref) _F	1	Tér	○	F	+hat	3Sg
(+ref) _F	2	Ág	●		-hat, +ref	3Sg
+ref	3	Ok	→	C	+hat	3Sg
+ref	4	Pác'	→	C	+hat	3Sg

''''Madeirán ásatta el a kalózvezér a rabolt kincseket egy ''tússzal.

? ''Madeirán ásatta el egy ''tússzal a kalózvezér a rabolt kincseket.

?? ''Madeirán ásatta egy ''tússzal el a kalózvezér a rabolt kincseket.

??? ''Madeirán ásatta el a kalózvezér egy ''tússzal a rabolt kincseket.

...

Az 1. táblázat azt is megmutatja, hogy egy mondatba kerülő argumentum formai tulajdonságait számos más paraméter értékelése is befolyásolja, a tematikus szerepén és a grammatikai funkcióján kívül. Ezeket érdemes egyetlen paramétervektorban egyesíteni, mivel ily módon minden nyelvészeti megszorítást e vektor (részben nyelvspecifikus, részben univerzális) jólformáltsági feltételeként fogalmazhatunk meg, illetve építhetünk be a gépi nyelvfeldolgozó rendszereinkbe. A fordítás problémája innen nézve annak kérdése, hogy egy adott paramétervektor egyaránt jólformált-e a forrás- és a célnyelvben; ha pedig nem, akkor a forrásnyelvi paramétervektorhoz milyen jólformált célnyelvi paramétervektor áll a legközelebb. A

kérdéskör nyelvészeti oldaláról a [11] cikk nyújt részletes tájékoztatást; ehelyütt csak szemléltetjük a lehetőségeket az 5.a-b. táblázat alapján.

A magyarban az argumentumok *hatóköri* sorrendje független a tematikus szerepüktől és a grammatikai funkciójuktól. A T5.a. verzióban ilyen hatóköri sorrendet tekintünk: Okozó > Tér > Páciens' > Ágens; a T5.b. verzióban pedig illet: Tér > Ágens > Okozó > Páciens'.

Az *információs szerkezeti* szereposztás viszont erősen függ a hatóköri sorrendtől, bár a korábbi Topikfélék > Kvantorfélék > Fókusz sorrendet az újabb kutatások [14] „liberalizálták” (lényegében az 1. táblázat 4. sorában megadott módon). A T5.a. verzióban az Okozó topik funkciót kap, a Tér argumentuma pedig fókusz funkciót. A T5.b-ben egy (Tér,Ágens) tükörfókusz konstrukciót szemléltetünk. A 'C' ('komplementum') jelölés arra utal, hogy egy argumentum nem kapott semmilyen kitéüntetett szerepet az információs szerkezetben. Az 'M' a generatív szakirodalomban sokat tanulmányozott igemódosítói / igevivői pozícióra utal. Az alábbi 6. táblázatban felidézük a logikai jelentéstöbbletet adó információs szerepek jelentésrendszerét:

6. Táblázat: A magyar operátorjelentések rendszere

($R_n = R \setminus R_m$, ahol R_m : a megemlített szereplők, R: minden olyan szereplő, amely eljátszhatta volna a megemlített szereplők által eljátszott szerepet)

	P(x)	$\neg P(x)$
$\exists x \in R_n$	Q _{is} : <i>is</i> kvantor <i>Meglep, hogy a nővéremet is meghívtad.</i>	K: kontrasztív topik <i>A nővéremet bezzeg meghívtad!</i>
$\forall x \in R_n$	Q _{mind} : <i>mind</i> kvantor <i>Meghívhattál volna mindannyiunkat!</i>	F: azonosító–kirekesztő fókusz <i>Bánt, hogy csak Annát és Beát hívtad meg.</i>

Az argumentumok *referencialitási fokozatát* korlátozhatja a tematikus szerep (ld. [1]: pl. **Alakult az énekkar a klubban*), de a korlátokat semlegesítheti az információs szerep (pl. egy fókusz funkció: *A klubban alakult az énekkar*). Az ezzel kapcsolatos nyelvspecifikus, illetve univerzális tudás is beépíthető a σ függvény paramétervektorának jólformáltsági feltételeibe. Új ötlet, hogy a szám / személy értéket is vegyük figyelembe (SAP: 'speech act prominence'), mivel korrelációt mutat például a topikválasztással [10].

Ahogy az 5.a-b. táblázatok alatt megadtuk, a paramétervektor teljes specifikálását követően preferenciasorrendbe álló szórendi és hangsúlyozási változatok egész listája adódik. Gyakran több kifogástalan szórend is van, például abból adódóan, hogy a magyar kvantor nem feltétlenül áll az ige elé megmutatni a hatóköri elsőbbségét. A 6. táblázat megfelelő példamondata így is elhangozhatna: *Meglep, hogy meghívtad a nővéremet is.*

4. Implementáció: egy megvalósítás sarokkövei

A *ReALIS* szintaxisfelbontó hozzáállása – a szemantikai relációk felépítését nem a szintaxistól függetlenül, hanem a kétirányú hozzáállást keverve, együtt, közösen végezzük, és a szemantikai információkat is a lexikon elemeihez kötjük –, komoly felkészültséget és gondos tervezést követel. Ilyen bonyolultsági fokozatot csakis valamiféle szimbolikus programozási nyelv, a „mesterséges intelligencia”

programnyelvek valamelyikének választásával érhetünk el. Az előzetes tapasztalatok alapján mindegyike a Prolog programozási nyelv valamelyik dialektusa alkalmas.

Bemenet és kimenet. Egy program tervezésénél az első lépés: a bemenet és kimenet specifikációja, vagyis a program által kiértékelt ún. „fekete doboz” függvény értelmezési tartományának és értékkészletének a megadása. Ez kiindulópontul szolgál olyan értelemben is, hogy egy részleges megvalósítás (pl. több dimenziós halmazok esetén) ennek részalmazát, vagy függvényösszetétel esetén a teljes feldolgozási függvény valamilyen összetevőjét számolja ki.

A ReALIS-megvalósítás célkitűzése a szöveg és a diskurzusreprezentáció közötti reláció kiszámítása. Ez (Prolog-szerű értelmezésben) mindkét irányú kapcsolatot jelenti. Ha a szöveg adott, akkor a program azt a reprezentációs kifejezést számítja ki, amely az adott logikai rendszerben és az interpretáló belső információállapotát leíró tudásbázisban (ontológiában) kiértékelhető, bizonyítható, vagy hozzávehető a tudásbázishoz. Az ellenkező irányban: ha a tudáskezelő összetevő által (pl. egy kérdésre adott válaszként) egy logikai kifejezést kapunk, akkor végeredményben a szöveg képét állítja elő.

Nemdeterminizmus. Egyes helyzetekben nem eldönthető, hogy egy elemzési folyamatot milyen irányban érdemes folytatni, illetve jó okkal többféle irányban is folytatható lenne (pl. a *vár* szó előfordulása esetén, a homonímia miatt). Bizonyos szó vagy mondat elolvasásakor tehát még nem állapítható meg, hogy melyik értelmezés a helyes. A mondat vagy a diskurzus további elemeinek az elolvasása a helyzetet általában egyértelműsíti. Az ilyen helyzetek kezelésére egyértelműen a *nemdeterminisztikus* megoldások javasolhatók. A program eljárásai kiszámítják a relációk összes lehetséges értékét, amely értékalmazból a hívó eljárások kiválasztják a számukra megfelelőket, és csak azok figyelembe vételével állítják elő a saját eredményeiket.

Tárgygépmo­dell. A mi esetünkben a „tárgygépmo­dell” kifejezés talán tárgymo­dellként is felfogható, hiszen nem valamilyen konkrét processzorlapka regiszter- és utasításkészletéről van szó, hanem az elsőrendű logika valamelyik részosztályának használatáról és a nyelvi fogalmak elsőrendű logikába történő leképezéséről. Ez lehet maga a *Horn-kló­zok* részosztálya is, de előfordulhat az is, hogy ennél bővebb osztályt kell választanunk (pl. következményoldali diszjunkcióval, modális operátorokkal kiegészítve). Ha a Horn-kló­zok szintjén maradunk is, külön szerencsének kell felfognunk, ha az egész a tiszta Prolog következtetési mechanizmusával meghajtható – a feladat egyébként esetleg a Prologétól különböző rezolúciós stratégia alkalmazását is igényelheti. [13].

Adatszerkezetek leírása elsőrendű logikában. Az elsőrendű logika alapvetően típusfogalom mégis alkalmazható úgy, hogy az alkalmazható függvénykifejezések körére megkötéseket teszünk. A Prolog-szakirodalomban a fogalom a változók lekötési állapotát leíró ún. mód deklarációk kiterjesztéseként vált ismertté [16]. Bár típusos Prolog-megvalósítás létezik [9], teljes, tiszta Prologhoz használható adatszerkezet-megadó nyelvet eddig mégsem rögzítettek, és erre vonatkozó megvalósításról sem számol be senki. A következőkben intuitíven érthető és követhető példákat mutatunk be adatszerkezet-megadásra. A leképezés egyik buktatója a *másodrendű szerkezetek megvalósítása elsőrendű eszközökkel*. Erre két lehetőség adódik:

Reifikáció, vagyis a predikátumszimbólumot adatként kezeljük, így akár változó is felveheti értékül a futás során. Ennek feltétele, hogy a predikátumot ne kelljen predikátumként kiértékelni, vagy ha mégis, akkor a kiértékelés a tételbizonyítási folyamat jól megfogható helyzetében történjék, amikor a predikátumot logikán túli eszközökkel felépítjük, és azon túl már maga is részt vehet a tételbizonyítás folyamatában.

Logikán kívüli eszközök közvetlen alkalmazása: a Prolog-rendszerekben erre a célra szolgálnak a különböző dinamikus kifejezés-felépítő eljárások (pl. $a = . . / 2$). A megoldás hátránya, hogy nem eléggé deklaratív: a lexikális tudás ábrázolása a befoglaló logikai rendszerre (Prolog) nézve specifikus eszközöket használ.

Azonosítás, referensek. *Referenseket* olyan változókkal jelölünk, amelyek kezdetben ismeretlenek, később a referens típusától függő értéket vehetnek fel. *Objektumreferensek* azok, amelyek a világ egy egyéniségét (individuumát, pl. Petőfi Sándor) címzik meg. Ezek a tudásbázis valamely osztályának példányai, az ilyen osztályokat a természetes tulajdonságértékeik nem azonosítják: az adatbázis (pl. telefonkönyv) egy másik Petőfi Sándora még akkor sem egyezik meg a költővel, ha egyébként a többi adatuk is véletlenül megegyezne. Az ettől eltérő adatszerkezeteket *adattípusnak* nevezzük, ezeket az értékeik egyértelműen azonosítják. Efféle típusok például az időreferensek és a címek.

Időreferensek használata időértékekkel lekötődő változóval lehetséges. Az időreferensek leírják a múltban, jelenben és jövőben történő eseményeket, tetszőleges pontossággal, időpontokat és időszakokat egyaránt. A `past(date(1-0-0))` időreferens például a "tavaly ilyenkor" időmeghatározást jelenti nap pontossággal.

Predikátumreferensek az elsőrendű logikában csak *reifikációval* használhatók. A REALIS predikátumreferensei a predikátum-mintát adják meg, amelyet a $\wedge/2$ kapcsolóval kapcsolunk a minta szabad változóihoz. Például az `AG^PAT^TIME^dig(AG, PAT, TIME)` predikátumreferens az „elás” három változójú (ágens, páciens, időpont) alakját jelöli. Megjegyezzük, hogy a predikátumreferenseken keresztül kötjük a mondat logikai alakját az interpretáló belső állapotát jelképező ontológiához.

Az *eseményreferensek* a predikátum-mintákból az ismert logikai kapcsolók útján létrehozott kifejezéseket jelölik. A predikátumokból alkotott literálisok, illetve az ilyenekből logikai kapcsolókkal képzett kifejezések ebben a helyzetben adatként viselkednek, melyek pontos szerepe (ontológia-bővítés, bizonyítás stb.) a program-környezetből derül ki.

Következtetési és relációs tárgymodell. A *relációs szemléletmód* alatt azt értjük, amikor a felismerést (és a generálást is) egyetlen relációban valósítjuk meg. Ennek a relációnak az egyik paramétere a szóban forgó diskurzus belső reprezentációja, a másik paramétere a mondat szöveges alakja. Ez a szemléletmód a Prologot ismerők számára kézenfekvőbbnek tűnhet; hátránya az, hogy a mondatot szekvenciális fájl-szerűen olvassa, amelyben a többszöri oda-vissza tekerések mindenképpen hatékonyságvesztést, és az ábrázolástól idegen megközelítést jelentenek.

A következtetésre alapuló ábrázolásmód a felismerés feladatát hangsúlyozza, és párhuzamba állítja a Horn-klózonok alkalmazott következtetési folyamattal. Vagyis: a Horn-féle következtetési háló forrásai a tényállítások, amelyek a mi esetünkben a beolvasott diskurzus elemei (szavai, morfémái, betűi). Ezekon végzünk felismerési-következtetési műveleteket, amelyek valamilyen végkövetkeztetésben (célállításban)

érnek véget. A végkövetkeztetés célszerűen egy olyan állítás lehet, amely paraméterként a teljes diskurzus szerkezetének valamilyen Prolog leképezését adja eredményül. A „lebegő” nyelvtani elemek és referensek, valamint azok összekapcsolódása a következtetési megoldásban sokkal természetesebb.

A következtetési hálón célszerű rétegeket (vágatokat) értelmezni (I-IV.):

I. *A szóalaktani elemzés szintje.* Ez a beolvasott karaktersorozatban dolgozik, és ebből előállít egy szó- (morféma-) listát, valamint az egyes elemek diskurzuson, mondaton, szón belüli indexeit. A továbbiakban feltételezzük, hogy ez a lépés már problémamentesen működik, a szógyököket és szóösszetételeket – ahol kellett, azonosította, a hozzá kapcsolódó igekötő-, képző- és ragrendszer felépítését, így a nyelvtani eseteket és egyeztetéseket felderítette. Az elemzés eredményét az alábbihoz hasonló tényállításokban rögzítjük:

```
word(1, noun('Petra', proper, nom, sing-3)).
```

II. *A szó szerkezet-átmenet szintje.* Ez gyakorlatilag a régens–vonzat, az alaptag–adjunktum, valamint az anafora–előzmény nyelvtani viszonyokat deríti fel, a lexikai leírásokban megjelenő *követel / kínál* viszonyokra alapozva.

III. *Eventualitások meghatározása* a polaritásos hatásláncmodell alapján, következtetésre alapuló ábrázolásban. Az egyes szófajok előfordulása implikálja a szemantikai predikátum fennállását.

```
sigma(AG^PAT^TIME^INST^CAUS^stabWithInit(
    AG, PAT, TIME, INST, CAUS)) :-
    noun(CAUS, _, nom, AGR), noun(PAT, _, acc, -3),
    verb(caus('szúr'), _PREFIX, decl, VTIME, AGR),
    noun(INST, common, inst, -3),
    time2verb(TIME, VTIME).
```

IV. *Eventualitások meghatározása* a hatásláncmodell alapján, relációs ábrázolásban. Az egyes szófajok előfordulása relációban áll a szemantikai predikátummal.

```
sigma(AG^PAT^TIME^INST^CAUS^stabWithInit(
    AG, PAT, TIME, INST, CAUS)),
    noun(CAUS, _, nom, AGR), noun(PAT, _, acc, -3),
    verb(caus('szúr'), _PREFIX, decl, VTIME, AGR),
    [noun(INST, common, inst, -3)]) :-
    time2verb(TIME, VTIME).
```

A fenti példában a „Mari kiszúratta az abroncsot egy szöggel” példamondat *szúr* igéjének predikátum-kiszámító részletét láthatjuk, melyet az ontológia szintjén a *stabWithInit/5* predikátummal ábrázolunk. Ez a műveletessel és eszközzel történő *kiszúrás*t fejezi ki, és az általános AG (ágens), PAT (páciens), TIME (idő) paraméterek mellett még hivatkozik az INST (eszköz) és a CAUS (kezdeményező) paraméterekre is. A *time2verb* feltétel a *stabWithInit/5* predikátum általános időreferense és az igeidő közötti kapcsolatot számítja ki. A következtetési modellben a *stabWithInit* predikátum az állítás következményrészében reifikálva, míg az

egy- szó-alkotóelemekre hivatkozás a feltételrészében szerepel. Ez utóbbiak a relációs modellben az állítás további paramétereiként láthatók.

A bemutatott lexikonrészletből létrejött program egyrészt meglepően egyszerű – lényegében a cikkben említett egyes példaigék (*ás*, *szúr*) hatásláncmodell-változatainak rögzítését tartalmazza. A tesztsorral való meghajtás eredménye egyfelől az elvárásokat hozta. Másfelől pedig rámutatott: további szemantikai vagy környezeti információk feldolgozása nélkül a helyzet nem egyértelmű, ami a nemdeterminisztikus eredmények túlbujánzásához vezet. Például a fentiekben ontológiai / szemantikai szelekciós információk nélkül nem dönthető el, hogy a *szög* a szűrés eszköze vagy ágense-e: a teszteredményekben – nagyon helyesen – mindkét értelmezést viszontláthatjuk. A két értelmezés között csak egy szemantikus információt is tartalmazó lexikonszerkezet tud egyértelműen választani: az ágensnek önálló cselekedetre képes (pl. az *Agent* fogalomból leszármaztatható) objektumnak kell lennie.

5 Összegzés, értékelés

Miután az 1. szakaszban bemutattuk a *ReALIS* dinamikus diskurzus-szemantikai interpretációs modellt [4], majd a 2.-ban a polaritásos hatáslánccsaládok lexikai-szemantikai elméletét [2-3], a 3.-ban pedig az utóbbi beépítését az előbbibe a σ függvény paramétervektora révén, a 4. szakaszban egy implementáció sarokköveit vázoltuk fel, részeredményeikről számolva be. Eddig alapelvek és adatformátumok rögzítése és tanulmányprogramok írása történt meg. A helyzetet egyrészt bonyolítja, másrészt megkönnyíti a kutatás korábbi szakaszában létrejött szóalakelemzési program [5-6] integrálásának igénye. Egy teljes *ReALIS*-megvalósításról egyelőre korai még a beszámoló, de ilyen irányba haladunk, és ez további közlemények tárgya lesz.

Bibliográfia

1. Alberti, G.: Restrictions on the Degree of Referentiality of Arguments in Hungarian Sentences. In: *Acta Linguistica Hungarica* 44/3–4 (1997) 341–362
2. Alberti, G.: A szóképzéssel együttjáró vonzatszerkezet-változások rendszere. In: *Nyelvtudományi Közlemények*, 103. szám (2006) 75–105
3. Alberti, G.: A szóképzéssel együttjáró vonzatszerkezet-változások egy polaritásérzékeny rendszere. Fancsaly É. (szerk.): *Tanár és tanítvány, Írások Györke József és Hajdú Péter tiszteletére (2002-2007)*. *Studia Linguistica, Dialóg Campus, Bp. – Pécs* (2009) 122–145
4. Alberti, G.: *ReALIS*, avagy a szintaxis dekompozíciója. Általános Nyelvészeti Tanulmányok (szerk. Bartos H.). Megj. előtt
5. Alberti, G., Kleiber J.: The *GeLexi* MT Project. In: Hutchins, J. (ed.): *Proceedings of EAMT 2004 Workshop (Malta)*, Univ. of Malta, Valletta (2004) 1–10
6. Alberti, G., Kleiber J.: The Grammar of *ReALIS* and the Implementation of its Dynamic Interpretation. *Informatica* 34/2 (2010) 103–110
7. Alberti, G., Károly, M., Kleiber, J.: The *ReALIS* Model of Human Interpreters and Its Application in Comp. Ling. In: *Proc. ICSOFT 2010/2*. SciTePress Portugal (2010) 468–474
8. Asher, N., Lascarides, A.: *Logics of Conversation*. Cambridge Univ. Press (2003)
9. de Boer, T. W.: *A Beginners' Guide to Visual Prolog*. Prolog Development Center A/S, Copenhagen, Denmark (2009)
<http://download.pdc.dk/vip/72/books/deBoer/VisualPrologBeginners.pdf>
10. Croft, W. *Radical Construction Grammar. Syntactic Theory in Typological Perspective*. Oxford University Press (2001)
11. Dowty, D. R., Wall, R. E., Peters, S.: *Introduction to Montague Semantics*. D. Reidel Publishing Company, Dordrecht (1981)
12. van Eijck, J., Kamp, H.: Representing discourse in context. In: vBenthem, J., ter Meulen, A. (eds.): *Handbook of Logic and Language*. Elsevier, Amsterdam (1997) 179–237
13. Kilián, I.: Horn clauses. A Two Way Street. Kézirat: Gyűrűfü Műhely Kft.. (korábban publikálva a www.sics.se honlapon) (1996)
14. Kiss, É. K.: Többszörös fókusz a magyar mondat szerkezetben. In: Büky, L., Maleczki, M.: *A mai magyar nyelv leírásának újabb módszerei II.* (1995) 47–66
15. Komlósy, A.: Régensék és vonzatok. Kiefer, F. (szerk.): *Strukturális magyar nyelvtan. I. Mondattan*. Akadémiai Kiadó, Budapest (1992) 299–527
16. Nakashima, H.: *Term Description: A Simple Powerful Extension to Prolog Data Structures*. Electrotechnical Laboratory, Umezono, 1-1-4, Ibaraki, Japan (1985)
17. Pléh, Cs.: Topic and subject prominence in Hungarian. In Kiefer, F. (ed.): *Hungarian Linguistics (Linguistic and Literary Studies in Eastern Europe Vol. 4)*. John Benjamins, Amsterdam (1982)

Az intenzionalitás számítógépes nyelvészeti kezelése – avagy a ReALIS λ szintfüggvénye

Alberti Gábor¹³

PTE BTK Nyelvtudományi Tanszék
ReALIS Elméleti és Számítógépes Nyelvészeti Kutatócsoport
7624 Pécs, Ifjúság útja 6.
alberti.gabor@pte.hu

Kivonat: Kutatócsoportunk szeme előtt továbbra is [5], [6] az a hosszú távon kifizetődő cél lebeg, miszerint az intelligens számítógépes nyelvészeti célokat (pl. fordítás, kivonatolás) az egymással kommunikáló humán interpretálói „elmék” ReALIS-modelljének [1]-[3] implementálására alapozva kívánjuk megvalósítani. A jelen munkaszakaszban a mondatok (alkotta diskurzusok) intenzionális jelentésrétegének megragadását tűztük ki, ami első lépésben az elmélet kínálta elvek és ötletek [8] specifikálását és célorientált formalizálását jelenti, második lépésben pedig az erre épülő implementációt. Döntően magyar lexikai tételeken mutatom be az intenzionalitás „tetten érését” és formális megragadását, ami a legkisebb toldalékok komplex jelentéstani analízisétől, a legkülönbélebb szófajba eső szavak elemzésén keresztül, nagyobb diskurzusegységek interpretálói információállapotba való beágyazódása intenzionális tényezőinek feltárásáig terjed. Megközelítésünk kiemelkedő erényének tartjuk, hogy nemcsak az „üzenetet” alkotó szavak pusztá jelentéséből összeálló információt tárjuk fel és implementáljuk, hanem az üzenet megbízhatóságát is, valamint az üzenet forrását jelentő interpretáló információállapotának releváns tényezőit, a grice-i értelemben vett „ideális beszélői” karaktertől való eltérés elemzése révén.

Kulcsszavak: reprezentacionalista dinamikus diskurzus-szemantika, intenzionalitás, információállapot, mód és modalitás, aspektus

1. Bevezetés

Mínt hogy középtávon kifinomult gépi fordításra és megbízható információkivonatolásra törekszünk, ezúttal egy olyan rövid távú projektet indítottunk, ami a poszt-montagoviánus [11], (S)DRT-re alapozott [15] [9], ReALIS nevű [1] [2] reprezentacionalista dinamikus diskurzus-szemantika megközelítésében (2. szakasz) a diskurzus-referensek „intenzionális szintjeinek” [8] a gyakorlati kidolgozására irányul, majd a

¹³ A szerzőt e cikk alapjait jelentő kutatásaiban az OTKA T60595 sz. projektje támogatta, a konferencia-részvételt pedig a TÁMOP-4.2.1.B-10/2/KONV/2010/ KONV-2010-0002 (A Dél-dunántúli régió egyetemi versenyképességének fejlesztése). Értékes megjegyzéseikért elsősorban a ReALIS ESzNy Kutatócsoport következő tagjainak szeretnék köszönetet mondani: Kleiber Juditnak, Károly Mártonnak és Kilián Imrének.

kapott reprezentációk implementálására az egymással kommunikáló interpretálói „elmék” komplex modelljében – ahogyan azt a ReALIS formálisan megragadja [4] négy belső függvénye segítségével: a formulaépítő σ -ról [6] [18], a horgonyzó/azonosító α -ról [7], a „dobozszint”-kijelölő λ -ról [8], [16] illetve a kurzor szerepű κ -ról van szó.

A projekt első felében tehát – megalapozandó az implementációt – a ReALIS elméleti konstrukcióit bizonyos nyelvi elemek csoportjaira alkalmaztuk, döntően magyar lexikai elemekre (3-4. szakasz). Olyan specifikált formális reprezentációkat dolgoztunk ki, amelyek pontosan megragadják az érintett morfémák és szavak összetett intenzionális karakterét, a mód és modalitás toldalékaira, az aspektusjelölő elemekre, különféle modális (segéd-) igékre, adverbiumokra, melléknevekre és partikulákra (pl. *bevesz, fog, valószínűleg, állítólagos, is*). A második projektszakaszban belefogtunk a reprezentációk implementálásába a kommunikáló interpretálói „elmék” ReALIS-modelljében [16]. A nyelvi elemek komplex intenzionális karakterizálásának a feladata, a λ szintfüggvénynek köszönhetően, végső soron arra redukálódik, hogy a DRS stílusú „dobozstruktúrában” minden egyes referenshez hozzárendeljünk egy $\gamma = \langle \langle \mu_1, \tau_1, i_1, \pi_1 \rangle, \langle \mu_2, \tau_2, i_2, \pi_2 \rangle, \dots, \langle \mu_k, \tau_k, i_k, \pi_k \rangle \rangle$ „világoska-indexet” – vagy még inkább egy $\Gamma = \{\gamma^1, \gamma^2, \dots, \gamma^N\}$ indexhalmazt – e „dobozstruktúrában” elfoglalt pozíciójuk (pozícióik) / szintjük (szintjeik) kifejezése végett. Hamarosan kiderül, hogy a rendezettnégyes-sorozatok e Γ halmaza miből is áll össze, és hogy ez a matematikai konstrukció hogyan képes egységesen megragadni a legkülönbözőbb nyelvi kifejezésekben rejlő intenzionalitást, illetve a szöveggörnyezet és a kontextus adta intenzionális hatásokat (5. szakasz).

2. A ReALIS alapjai

Mindenekelőtt felvázolom a jelen tárgyalásunk szempontjából releváns vonásait annak háttérelméletnek, amelyen a szemantikai elemzések, a DRS stílusú reprezentációk és a számítógépes implementáció lépései nyugszanak.

A ReALIS (*RECiprocal And Lifelong Interpretation System*, azaz Kölcsönös és Élethossziglani Interpretációs Rendszer) olyan új poszt-montagoviánus [11] elméletként mutatható be, amely a koherens (kis-) diskurzusokká összeálló mondatok formális jelentéselemzését nyújtja [15] [9], középpontjában az „interpretálók” lexikai, személyközi és kulturális / enciklopédikus tudásának egy *élethossziglani* modelljével, mely az interpretálók egymásról való *kölcsönös* tudását is megragadni hivatott. A teljes (40 oldalas) definíciós rendszer elérhető angolul az interneten ([1] <http://lingua.btk.pte.hu/realispapers>), magyarul pedig egy idén megjelent könyvben [2]; az elmélet különféle aspektusairól és alkalmazásairól pedig mostanában számos publikáció látott napvilágot [3]-[8] [16] [18].

Ami most igazán releváns, az a Kamp-féle DRS-ek újfajta felhasználása: az interpretálói információállapotok élethossziglani reprezentációi gyanánt lehet őket alkalmazni. Nyilván gigantikus dobozstruktúrák adódnak így, de matematikai tartalmuk alig bonyolultabb, mint az eredeti DRS-eké; a beágyazott „dobozrendszerek” viszont – ezek a logikai műveletekre nézve nem zárt, véges „információtárak” – készen kínálkoznak a Montague-féle formális diskurzus-szemantikában használatos (végtelen) *lehetséges világok* [11] helyettesítésére [8]; melyek megalapozottsága korántsem megfelelő [19]. A korlátlanul egymásba ágyazható „dobozok” segítségével

ugyanis meg tudjuk ragadni az interpretálói hiedelmek, vágyak és szándékok ('BDI') – nem ritkán egymás hiedelmeire, vágyaira és szándékaira vonatkozó – szövevényes rendszerét. Egy interpretáló információállapota tehát „világocskáknak” – az említett véges információtáraknak – egy olyan felcímkezett fastruktúrájaként definiálható, ami gyakorlatilag az ő elméjének – „belső világának” – a formális modelljeként szolgál, amely része a teljes univerzum „külső világot” is tartalmazó modelljének. Ami talán meglepő megközelítés, de semmi intuícióellenes nincs abban, hogy az emberi elméket is a világ(modell) részének tekintsük.

Ezek alapján a *szimultán rekurziós* definíciós technika kínálkozik a \Re ALIS mint episztemikus multiágens rendszer formális megfogalmazására: $\Re = \langle W_0, W, \text{Dyn}, \text{Tru} \rangle$, ahol az ágensek szerepét a világról – és azon belül (tipikusan!) egymás elméjének tartalmáról – folyamatosan információt gyűjtő interpretálók játsszák. W_0 a külvilágot jelöli, ami egy idődimenziót is tartalmazó „teljes történelem”, amire alapítva mind (igazságértékelő) statikus interpretációt definiálhatunk (Tru), mind (DRS-építő / a tudásgyarapodást felmérő) dinamikus interpretációt (Dyn), kölcsönhatásaikat is [KGR] megragadva. A W egy függvény, amelynek a $W[i,t]$ értéke egy i interpretáló t időpillanatbeli *információállapotát* adja meg. A fentiek értelmében ez egyfelől a világ egy reprezentációját jelenti, másfelől nézve viszont a világ(modell) egy részletét; amennyiben ez utóbbi aspektust kívánjuk érzékeltetni, akkor *belső világként* utalhatunk a – világocskák felcímkezett fastruktúrájaként szerveződő – $W[i,t]$ konstrukcióra. A modális kifejezések interpretációja a megfelelően felcímkezett világocskák tartalmára épül, a külvilágé (vagy bárminemű „lehetséges világé”) helyett.

Ez nem kevesebbet jelent, mint hogy a \Re ALIS megközelítésében a szokásos értelemben vett *intenzionalitás* egyszerűen nem is létezik: a (teljes világmodell részét képező elmék leírásában szereplő) interpretálói világocskák hordozzák mindazt az információt (BDI, feltevések, álmok), ami másutt a lehetséges világokra van bízva. Úgy is fogalmazhatunk tehát, hogy a \Re ALIS rendszerében az interpretáció mindig *extenzionalis*, csak a bázist képező modellzóna lehet többféle: a W_0 külvilág vagy egy $W[i,t]$ interpretálói belvilág valamely szektora, vagy – látjuk majd, mennyire gyakran! – a külvilág és több interpretáló különféle világocskáinak valamilyen kombinációja. Mindemögött az a hipotézis húzódik meg, hogy minden olyan (nyelvészeti) probléma, amelyről Montague-t követve [11] azt szokás gondolni, hogy megoldása a (végtelen) lehetséges világok konstrukciójáért kiált, megoldható a (véges) világocskákra alapozva.


Szemléltetésül e cikkben álljon a *modális horgonyzás* – azaz az eltérő modális kontextusokon átívelő keresztreferencia – makacs problémája [20:243]. Az alábbi (1a) kétmondatos kisdiskurzus második mondatában azt nem tudják megmagyarázni, hogy *a várkastély* határozott kifejezés egyfelől modálisan alá van rendelve egy megelőző mondatban szereplő összetevőnek, másfelől viszont a második mondat a maga egészében nem áll modális alárendeltségben. Ez a jelenség azért jelent súlyos problémát a lehetséges világok *eliminációján* nyugvó szemantikai megközelítésben, mert az érintett mondat különböző részeinek interpretálása különböző eliminációt igényelne: *a várkastély* referenciáját Mari hiedelmei alapján kalkulálhatjuk ki, miközben a mondat állítmánya hamisnak bélyegzi az éppen e kalkuláció alapját jelentő előfeltevést. A \Re ALIS megközelítésében viszont, amik megfelelnek az „eltérő modális kontextusoknak”, azok egyazon világmodell részét képezik – minthogy valamennyi interpretálói belvilág egyazon világmodellbe tartozik. Referenseik összehorgonyzásának en-

nél fogva elvi akadály a nincsen, csupán a referensek közötti „elérhetőség” megfelelő feltételrendszerét kell meghatározni.

Az alábbi (1e) reprezentáció például egy „ideális interpretáló” dinamikus interpretációjának a releváns részletét mutatja. Egy mondat (illetve diskurzus) *dinamikus interpretációja* az interpretálói információállapot kiterjesztéseként definiáltatik [1, 2.2.] [2, 4.2.]. Ami tulajdonképpen történik e „kiterjesztés” során, az nem más, mint hogy új szektorok épülnek ki az interpretálói információállapotban, köszönhetően a bemeneti performancia (morfémáról morfémára való) interpretálói feldolgozásának: a felcímkézett világocskák részben rendezett szövevénye új blokkokkal gyarapodik. Egy mondat *statikus interpretációja* (igazságértékelése) a külvilág bázisán vagy / és potenciálisan akár több interpretáló bizonyos világocskáinak a bázisán definiálandó. E struktúrák valamiféle egyesítését ($W_o + \Sigma W[i, \tau]$) kell a dinamikus interpretáció kimenetével ($W[i, t]$) összevetni, és meghatározni, hogy létesíthető-e közöttük elégséges *mintaillesztés*.

1. példa. MODÁLIS HORGONYZÁS – MINT AZ INTENZIONÁLIS AZONOSÍTÁS EXTRÉM ESETE

- a. Mari úgy vélte, hogy a fák mögött egy várkastély van.
A várkastély egy hatalmas tölgyfának bizonyult.
- b. Általános világocskaindex: $\gamma = \langle \langle \mu_1, \tau_1, i_1, \pi_1 \rangle, \langle \mu_2, \tau_2, i_2, \pi_2 \rangle, \dots, \langle \mu_k, \tau_k, i_k, \pi_k \rangle \rangle$
- c. Az r' világocskaindex: $\gamma' = \langle \langle \text{BEL}, \Gamma_{\text{Mari}}, \tau', + \rangle, \langle \text{SEE}, \Gamma_{\text{Mari}}, \tau', + \rangle \rangle$
- d. Az r'' világocskaindex: $\gamma'' = \langle \langle \text{SEE}, \Gamma_{\text{speaker}}, \tau'', + \rangle \rangle$
- e. A RELEVÁNS VILÁGOCSKÁK VIZUÁLIS MEGJELENÍTÉSE:



Az (1a) pontbeli első mondat egy r' referens bevezetésével járul hozzá a diskurzus-jelentéshez, amelyhez az az információ kapcsolódik, hogy „Mari várkastélynak vélte látni az r' dolgot (a τ' pillanatban)”. A második mondat egy állítást tesz valamiről, ami minden bizonnyal a beszélő vizuális megfigyelésén alapul.¹⁴

A DRT jól ismert „dobozstruktúrájának” [15] a \Re ALIS formalizmusában a világocskák *felcímkézett* részbenrendezése felel meg [1, 1.2.4.] [2, 3.2.4.]. Az (1e) reprezentáción fogom bemutatni e címkéket. Olyan rendezett négyesek, amelyek a következő tényezőket adják meg: a címke *modalitását* (pl. hiedelem / vágy / szándék / feltevés / megfigyelési mód), *közvetlen gazdáját*, *időpillanatát* és *polaritását* (pozitív

¹⁴ Felvetődhet az olvasóban, hogy a pontos formula-feltöltése az olyan “dobozoknak”, mint az (1e) vagy a majdani (3d) pontbeliek, önkényes elemeket is tartalmaz, amelyek nem feltétlenül kompozicionális mondatelemzésből származnak. A tárgyalás jelenlegi szakaszában erre azt válaszolom, hogy az önkényesség a releváns dobozstruktúrát nem érinti. A cikk 5. szakaszában pedig visszatérünk majd a kérdésre egy tágabb perspektívából.

/ semleges / negatív). Az (1e) pontban a felső dobozpár például azt az információt hordozza, hogy egy τ' időpillanatban Mari (r_{Mari}) úgy hiszi (BEL), hogy egy e' eventualitást lát (SEE), melynek információtartalma: egy r' referens várkastély (a $p_{\text{vár}}$ predikátum a 'várnak lenni' állítást fejezi ki). Az alsó (egyetlen) doboz pedig azt az információt nyújtja, hogy a beszélő (s) vizuális észleli egy τ'' (későbbi) pillanatban, miszerint valami – egy r'' diskurzusszereplő – nem más, mint egy tölgyfa. Az (1c-d) formulák – a Bevezetésben előrevetített (1b) általános képletnek megfelelően – a világocskaindexeket közlik az r' és az r'' referensek esetében. Az r' indexe azt fejezi ki, hogy egy Mari által τ' pillanatban látni vélt dologról van szó, míg az r'' indexe egy, az adott beszélő által τ'' -ben látott „valamire” utal.

Ez a formalizmus is megjeleníti tehát, hogy a lehetségesvilág-szemantikák számára problematikus modális horgonyzási jelenség miért is az: *a várkastély* kifejezést tartalmazó második mondat a beszélő perspektíváján nyugszik, és nem Marién; mégis sikeres a szóban forgó szinguláris határozott főnévi szerkezet indukálta antecedenskeresés. Vajon ez hogyan magyarázható a \Re ALIS rendszerében?

Az *unicitás* jelenti az antecedenskeresés sikerének zálogát: lennie kell egy olyan világocskának, amelyben egy referens egyedi az adott világocskában abban a tekintetben, hogy a szinguláris határozott főnévi szerkezet hordozta állítás csakis őrá igaz. Az alábbi (2a) kisdiskurzus második mondata például nem elégíti ki ezt az unicitási kritériumot – nem is jól formált a diskurzus, pedig modáliskontextusváltásról szó sincsen.

Az *elérhetőség* jelenti az antecedenskeresés sikerének másik tényezőjét. Az (1a) probléma precíz megoldása *akkommodációt* is igényel, egy referensnek ugyanis elérhetőnek kell lennie egy másik referens számára, amennyiben össze kívánjuk horgonyozni őket azonos referenciájuk kifejezése végett [15]. A \Re ALIS rendszerében az elérhetőség a lehető legkézenfekvőbb módon definiálható a világocskahierarchiára alapítva: r_1 elérhető r_2 számára, amennyiben r_1 lejjebb helyezkedik el r_2 -höz képest a hierarchiát matematikailag definiáló részbenrendezés szerint [1, 2.2.3.6.] [2, 4.2.3.6.].

Milyen információ akkommodálását váltja ki a szinguláris határozott kifejezés az (1a) második mondatában? Azét, hogy a beszélő elfogadja, hogy „valóban van egy jókora entitás a fák mögött”. Ennek ábrázolása úgy fest a diskurzus interpretálójának szemszögéből, hogy a diskurzus dinamikus interpretációjához tartozó relatív gyökérvilágocskába – ami a részbenrendezés szerint a legalsó világocska – bevezettetik egy r referens. Ami tehát mind r' („a Mari féle várkastély”), mind r'' („a beszélő tölgyfája”) számára elérhető; r' és r'' tehát egyaránt odahorgonyozható az r referenshez, megragadva ezáltal koreferenciális viszonyukat, amelyet az ábrán a közös u jelölésük is mutat.

Gyanúsán egyszerűnek tűnhet persze az akkommodációhoz való folyamodás. Gondoljunk azonban meg: a beszélő számára kézenfekvő stratégiát jelent a lehető legkevesebbet „(ki)mondani”, és ehelyett annyit rábízni a hallgatói információállapotra, amennyit csak lehetséges (-nek gondol a beszélő). Ahelyett, hogy a formális szemantikai elemzések során a szavak által expliciten ki nem fejezett információt ignoráljuk (mereven elhatárolódva leírásától), inkább arra kéne törekedni, hogy az információnak ezt az implicit rétegét is megragadjuk. A \Re ALIS „élethossziglani” megközelítése lehetővé teszi az implicit információ formális kezelését.

2. példa. UNICITÁS ÉS AKKOMMODÁCIÓ

- a. Egy ódon városban megnéztünk két kastélyt. **A kastély* gyönyörű volt.
- b. Péter tegnap megnősült. + c. / d.
- c. *A pap* roppant harsányan beszélt. / d. ^{??}*A kutya* nagyon hangosan ugatott.

A fenti (2b)+(2c/d) kétmondatos kisdiskurzus-variációk az akkommodáció iskola-példájaként szolgálnak [14]. A mi kultúránkban egy *pap* „kitüntetett szereplője” lehet egy esküvőnek, míg ugyanez nem mondható el egy kutyáról. Mindazonáltal az sem zárható ki, hogy egy interpretáló a (2b)+(2d) diskurzust is kifogástalannak értékeli egy adott kontextusban: annyi szükséges, például, hogy ott legyen az információállapotában egy darabka tudás egy kutyáról, aki megkülönböztetett szerepet játszik Péter életében. Fontos hangsúlyozni, hogy sem a pap az egyik diskurzus-variációban, sem a kutya a másikban nem jelenik meg az esküvőt tartalmazó interpretálói információállapot valamiféle *logikai* következményrelációra való lezárásában; a kohézió tehát a jelen mondatok tartalma és az interpretáló által egykor – akár korlátlanul régen – elsajátított tartalmak között lép fel. Ha tehát számot akarunk adni a (2c) / (2d) folytatások eltérő megítéléséről, akkor aligha fordulhatunk a logikailag zárt lehetséges világokhoz; a *ReALIS* nyújtotta élethossziglani megközelítés ígér megoldást. A (2c/d)-beli szinguláris határozott kifejezés olyan eljárást indít el a dinamikus interpretáció során, ami az interpretálói információállapot kiterjesztését eredményezi a diskurzuskezdő (2b) mondat megértését követően; olyan kiterjesztését, amelyben lennie kell(ene) egy világocskának unicitást élvező pappal / kutyával. Az előbbi esetben a feladat végrehajtható, akkommodálva a mi nyugati kultúránkra jellemző esküvőre vonatkozó enciklopédikus információt; az utóbbi esetben pedig akkor, de csakis akkor hajtható végre, ha Péterre vonatkozó megfelelő személyközi információ akkommodálható.


Az alábbi (3a) pontban egy másik kontextust mutatok be, amelyben egy adott darabka információ („a felesége”) úgy használható fel egy személy azonosítására, hogy közben a beszédpartnerek számára eltérő modális kontextusokhoz tartozik; mi több, mindketten tudván tudják, hogy hamis tartalmat hordoz. A *ReALIS* – ismét – olyan megoldást kínál, ami a releváns referensek bizonyos világocskákban való *unicitására* épül. A (3d)-ben a világocskablokkok azt ábrázolják, hogy *a felesége* szinguláris határozott kifejezés a vendég számára éppen ezt jelenti: „az egyetlen x személy a kontextusban, akire az igaz, hogy ő (a vendég) a portástól azt reméli, hogy az elhiszi, hogy az x illető a felesége, annak ellenére, hogy jól tudja az x-ről, hogy nem az”; míg a portás számára a következő meghatározás nyújtja az unicitást: „az egyetlen y személy a kontextusban, akire az igaz, hogy úgy gondolja, hogy a vendég azt reméli tőle, hogy elhiszi, hogy y a felesége neki (mármint a vendégnek), miközben persze tudja, hogy nem a felesége”. A (3b-c) az imént meghivatkozott indexek formális leírását közli, hogy világos legyen, mi a mögöttes matematikai tartalma az olyan vizuális megjelenítéseknek, mint a (3d)-beli, amire aztán a kommunikáló interpretálók *ReALIS*-modelljének implementációját is fel lehet építeni.

3. példa. SIKERES REFERÁLÁS HAMIS INFORMÁCIÓ SEGÍTSÉGÉVEL:

- a. *Egy férfi érkezik egy motelbe egy lány társaságában, aki korántsem a felesége, egy olyan országban, ahol a portásnak a jogszabályok értelmében nem lenne szabad egy szobában elszállásolni őket. Az persze nem áll a portás anyagi érdekében, hogy ajtót mutasson nekik. Inkább mindketten úgy*

emlegetik a lányt, mintha a vendég felesége lenne, noha tisztában vannak vele, hogy ez az „előfeltevés” hamis; sőt, még azt is tudják, hogy a másik is tisztában van az igazsággal. A portás például ezt mondja: Remélem, ízleni fog a feleségének ez a pezsgő.

- b. $\Gamma_e = \{ \langle \langle \text{BEL}, r_{\text{vendég}}, \tau, - \rangle \rangle, \langle \langle \text{DES}, r_{\text{vendég}}, \tau, + \rangle \rangle, \langle \langle \text{BEL}, r_{\text{portás}}, \tau, + \rangle \rangle \}$
 c. $\Gamma_{e'} = \{ \langle \langle \langle \langle \text{BEL}, r_{\text{portás}}, \tau, - \rangle \rangle \rangle, \langle \langle \langle \langle \text{BEL}, r_{\text{portás}}, \tau, + \rangle \rangle \rangle, \langle \langle \langle \langle \text{DES}, r_{\text{vendég}}, \tau, + \rangle \rangle \rangle, \langle \langle \langle \langle \text{BEL}, r_{\text{portás}}, \tau, + \rangle \rangle \rangle \rangle \}$
 d. A RELEVÁNS VILÁGOCSKÁK VIZUÁLIS MEGJELENÍTÉSE:



3 Modális melléknevek, adverbiumok, kötőszavak, (segéd-) igék

Az alábbi (4) példában egy a (3)-hoz hasonló elemzéshez vezető jelenséget szemléltetnek. Az *állítólagos* melléknévről van szó, amit Kiefer [17:188] *szabálytalanként* sorol be, a (4b-c), (4d-e) tulajdonságai alapján, összevetve a szabályos *öreg* melléknévvvel.

Megközelítésünkben kézenfekvően adódik a szabályos és a szabálytalan melléknevek közötti különbség: az előbbieket egy *predikátummal* járulnak hozzá a diskurzusrepresentációhoz (mint a $p_{\text{tölgyfa}}$ vagy a $p_{\text{íelesége}}$ a 2. szakasz elemzéseiben), míg az *állítólagos* a világocskacímke modális összetevőjét szabja meg. A beszélő olyan információval utal egy szereplőre, amelynek igazsága mellett nem kötelezi el magát (4g), miközben ugyanazon mondat állítmányának tartalma mellett igen (4f). Így utal a szereplőre: „egy olyan személy, akiről legjobb tudomása szerint van, aki (r^*) azt gondolja, hogy kém” (4h). A (4b) „anomáliáról” – miszerint az „állítólagos P”-ből nem feltétlenül következik a P – a (4h) reprezentáció számot ad, hiszen deklaráltan nincs elkötelezve a beszélő a P igazsága mellett (4g). Az állítmányi szerep visszautasítása pedig (4d) abból adódik, hogy az *állítólagos* hozadéka nem egy $p_{\text{állítólagos}}$ predikátum.

4. példa. ÁLLÍTÓLAGOS: EGY SZABÁLYTALAN (AVAGY MODÁLIS) MELLÉKNÉV

- a. Tegnap Mari találkozott egy állítólagos kémmele.
 b. Egy állítólagos kém az kém. → *nem (feltétlenül) igaz*
 c. Egy öreg kém az kém. → *feltétlenül igaz*
 d. *Pál állítólagos. → *rosszul formált*. e. Pál öreg. → *jól formált*
 f. $\Gamma_{\text{e:találkzik}} = \{ \langle \langle \text{BEL}, r_{\text{speaker}}, \tau, + \rangle \rangle \}$
 g. $\Gamma_{\text{ském}} = \{ \langle \langle \langle \langle \text{BEL}, r_{\text{speaker}}, \tau, 0 \rangle \rangle \rangle, \langle \langle \langle \langle \text{BEL}, r_{\text{speaker}}, \tau, + \rangle \rangle \rangle \rangle \}$
 h. $\langle \langle \langle \langle \text{BEL}, r_{\text{speaker}}, \tau, + \rangle \rangle \rangle, \langle \langle \langle \langle \text{BEL}, r^*, \tau, + \rangle \rangle \rangle \rangle \}$

A segédigék hasonló modális hatásmechanizmusára német példákat mutatok be. Az (5a-b) mondatokban egyaránt megvan az a jelentésfaktor, hogy a beszélő elhatárolódik magától az s állapotról szóló állítástól, miszerint Péter beteg volt ($\langle\langle\text{BEL}, r_{\text{speaker}}, \tau, 0\rangle\rangle$; ld. (5c-d)). Az (5c-d)-ben közölt több négyesből álló formulák azt a beszélői vélekedést fejezik ki, hogy a beszélő másnak (r^*) tulajdonítja az állítást (5c), illetve úgy gondolja, hogy az alany szándéka elhithetni másokkal (r^*) a betegség fennállását (5d).

5. példa. A NÉMET *SOLL* ÉS *WILL*: MODÁLIS SEGÉDIGÉK

a-b. Peter soll / will krank gewesen sein. ‘Peter beteg volt.’ (de ld. (5c-d))

Peter *soll* / *will* beteg van.PERF van.INF

c. $\Gamma_{s:\text{beteg/a.}} = \{\langle\langle\text{BEL}, r_{\text{speaker}}, \tau, 0\rangle\rangle, \langle\langle\text{BEL}, r_{\text{speaker}}, \tau, +\rangle\rangle, \langle\langle\text{BEL}, r^*, \tau, +\rangle\rangle\}$

d. $\Gamma_{s:\text{beteg/b.}} = \{\langle\langle\text{BEL}, r_{\text{speaker}}, \tau, 0\rangle\rangle, \langle\langle\text{BEL}, r_{\text{speaker}}, \tau, +\rangle\rangle, \langle\langle\text{INT}, r_{\text{Peter}}, \tau, +\rangle\rangle, \langle\langle\text{BEL}, r^*, \tau, +\rangle\rangle\}$

A (6) példa képletei egy olyan ideális beszélő információállapotának (egyszerűsített) modelljét állítják fel, aki egy *valószínűleg*-gel módosított tartalmú mondatot dolgozott fel. Az igazságértékelés szempontjából az első érdekesség az, hogy hamis állításról akkor sem beszélhetünk, ha az s állapotról („Mari otthon van”) szóló állítás maga a külvilág alapján hamis. A (6a) mondat tehát nem a külvilágról ad információt (6b), hanem az „ideális beszélő” információállapotáról, mondjuk a grice-i értelemben [13], amire az SDRT is alapít [9]. A kérdésre majd az 5. szakaszban visszatérünk. Az elemzés a világocskacímke modális összetevőjének finomabb értékskáláját alkalmazza: a $\text{BEL}_{\text{great}}$ a hiedelem alacsonyabb fokozatára utal, mint a biztos tudásra utaló BEL_{MAX} . A (6c) formulái tehát ezt közlik: a beszélő (s) *valószínűsíti*, hogy Mari otthon van, és szándékában áll a hallgatóját (i) is erről a valószínűségről meggyőzni. A beszélő azt is sugallja a (6a) közléssel, hogy nincs közvetlen érzéki tapasztalata Mari otthon létével vagy ennek ellentétével kapcsolatban, és hallgatójáról is ezt gondolja (6d), illetve azt, hogy közlésével tudott valami újat mondani a hallgatónak (6e), vagyis az nincs Mari otthon létével kapcsolatos biztos tudás birtokában.

6. példa. *VALÓSZÍNŰLEG*: EGY MODÁLIS ADVERBIUM

a. Mari valószínűleg otthon van.

b. Irreleváns az interpretációnál, hogy s (“M. otthon van”) fennáll-e W_o -ban.

c. $\Gamma_{s:\text{otthon-van}} = \{\langle\langle\text{BEL}_{\text{great}}, s, \tau, +\rangle\rangle, \langle\langle\text{INT}, s, \tau, +\rangle\rangle, \langle\langle\text{BEL}_{\text{great}}, i, \tau, +\rangle\rangle\}$

d. $\{\langle\langle\text{SEE}, s, \tau, 0\rangle\rangle, \langle\langle\text{BEL}_{\text{great}}, s, \tau, +\rangle\rangle, \langle\langle\text{SEE}, i, \tau, 0\rangle\rangle\}$

e. $\{\langle\langle\text{BEL}_{\text{great}}, s, \tau, +\rangle\rangle, \langle\langle\text{BEL}_{\text{MAX}}, i, \tau, 0\rangle\rangle\}$

A kötőszókbán is rejlik intenzionalitás; amit a *ReALIS* eszköztárával meg tudunk ragadni formálisan, és a világocskaindexekre alapozva implementálhatunk is. A (7a) válaszból például az is kiderül, hogy a beszélőnek nincs biztos tudása sem az s’ állapotról nézve („M. Delhiben van.”), sem az s’’-re nézve („M. Bombayben van.”) – vagy meg akarja tévesztetni a hallgatóját (7b), azaz nem viselkedik „ideális beszélőként”. Jobban belegondolva azt is megkérdőjelezhetjük, hogy a klasszikus logika által javasolt $s=s' \vee s''$ információról lehet-e *biztos* tudása a beszélőnek (BEL_{MAX}), miközben a diszjunkciónak sem az s’ tagjáról, sem az s’’ tagjáról nincsen biztos tudása. Ezért a (7c) formulában olyan tudásmodellt állítottam fel, amelyben a *vagy* hatása egy

'BEL_{amax}' hiedelemérték választásában mutatkozik meg: ez igen erős, de mégsem teljes és közvetlen bizonyosságra utal.

7. példa. INTENZIONALITÁS A KÖTŐSZÓKBAN

- a. (Hol van Mari?) Delhiben vagy Bombayben.
- b. $\Gamma_{s^1:Delhiben} = \{ \langle \langle BEL_{MAX}, s, \tau, 0 \rangle \rangle \}$; $\Gamma_{s^2:Bombayben} = \{ \langle \langle BEL_{MAX}, s, \tau, 0 \rangle \rangle \}$
- c. $\Gamma_{s:[s^1 \text{ or } s^2]} = \{ \langle \langle BEL_{amax}, s, \tau, + \rangle \rangle \}$
- d. Am Montag wusste ich nicht, *dass/ob* du am Sonntag in der Kneipe gewesen warst.
-On hétfő tud.MÚLT.EI ÉN nem, hogy_{dass/ob} te -On vasárnap -bAn a.DAT kocsmá van.PERF van.MÚLT.E2
Hétfőn nem tudtam, hogy vasárnap a kocsmában voltál / voltál-e.
- e. $\Gamma_{s[dass]:kocsmában} = \{ \langle \langle BEL_{MAX}, s, \tau', 0 \rangle \rangle, \langle \langle BEL_{MAX}, s, \tau, + \rangle \rangle \}$
- f. $\Gamma_{s[ob]:kocsmában} = \{ \langle \langle BEL_{MAX}, s, \tau', 0 \rangle \rangle \}$

A fenti német példapár (7d) a *hogy*-nak megfelelő alárendelő kötőszók közötti választásról szól, illetve ennek egyetlen érdekes mozzanatáról: míg látszólag csupán egy korábbi információállapotról tájékoztat a mondat, amelyben az *s* állapotról szóló információ egy semleges hiedelemvilágocska-szektorban van (7e-f), az egyik kötőszóval a beszélő elárulja, hogy egy későbbi információállapotában az *s* már pozitív tudásként van jelen (7e).

A szakasz utolsó példájában (8) egy olyan magyar ige szerepel, amely az interpretálói információállapotban rendkívül gazdag indexhalmazzal címkéz fel egy *s* eventualitást, ami egyébként (a megítélésem szerint preferált értelmezés szerint) a külvilágra vetítve hamis (8b). Egész kis dráma bontakozik ki az *s* információ „vándorlását” nyomon követve világocskáról világocskára, az indexhalmazt áttekintve (8c-f). Egy τ' pillanatban Mari nem gondolta úgy, hogy Pál nő (*s*), egy későbbi τ pillanatban viszont már így gondolta (8c). A változást egy (nem feltétlenül ismert) r^* „intrikus” idézte elő, aki tudja, hogy *s* hamis, és úgy gondolja, hogy Mari sem hiszi igaznak (8d). Arra vágyik ('DES') viszont, hogy Mari úgy higgye, hogy *s* igaz, és ezért tenni is akar (8e); az INT címke a szándékra utal, amellyel a címke közvetlen gazdája (r^*) saját belvilágának komplementumát a belvilágában megfogalmazódó vágyaihoz akarja igazítani – mint láttuk (8c), sikeresen. Mi több (8f), Mariról azt sugallja a (8a) mondat, hogy úgy hiszi, az intrikus is nőnek gondolja Pált, és sejtelve sincs arról, hogy tudatosan be akarta csapni őt.

8. példa. BEVESZ: EGY GAZDAG INTENZIONÁLIS MINTÁZATÚ IGE

- a. Mari bevette, hogy Pál nő.
- b. Az *s* állapot („Pál nő.”) nem áll fenn W_o -ban.
- c. $\Gamma_{s:nős} = \{ \langle \langle BEL, \Gamma_M, \tau', - \rangle \rangle \text{ or } \langle \langle BEL, \Gamma_M, \tau', 0 \rangle \rangle, \langle \langle BEL, \Gamma_M, \tau, + \rangle \rangle,$
- d. $\langle \langle BEL, \Gamma^*, \tau, - \rangle \rangle, \langle \langle BEL, \Gamma^*, \tau', - \rangle \rangle, \langle \langle BEL, \Gamma_M, \tau', + \rangle \rangle,$
- e. $\langle \langle DES, \Gamma^*, \tau', + \rangle \rangle, \langle \langle BEL, \Gamma_M, \tau, + \rangle \rangle, \langle \langle INT, \Gamma^*, \tau', + \rangle \rangle, \langle \langle BEL, \Gamma_M, \tau, + \rangle \rangle,$
- f. $\langle \langle BEL, \Gamma_M, \tau, + \rangle \rangle, \langle \langle BEL, \Gamma^*, \tau, + \rangle \rangle, \langle \langle BEL, \Gamma_M, \tau, 0 \rangle \rangle, \langle \langle INT, \Gamma^*, \tau, + \rangle \rangle, \langle \langle BEL, \Gamma_M, \tau, + \rangle \rangle \}$

4 A mód, a modalitás és az aspektus intenzionalitása a magyarban

Ízelítőt szeretnék adni a magyar mód- és modalitástoldalékok intenzionális modellezésére irányuló alprojektünk eredményeiből. Az alábbi táblázat néhány múlt idejű kombináció (egyszerűsített) elemzését mutatja be.

Minden kombináció (legalább) kétértelmű. A beszélő (s) vagy valaki más (r*) hiedelmeit, vágyait és/vagy szándékait fejezi ki (BEL, DES, INT), egy modalitáson belül finomabb intenzitási skálát is megkívánva (MAX > amax > great > med). A BEL_{MAX} címke például a teljes bizonyosságra utal. Az <INT,r*,π> címketípus az r* személy utasítását (π=+; ld. c., g.), tiltását (π=-) vagy engedélyét (π=0; ld. a., e.) jelzi, a címke polaritási összetevőjétől függően. A BEL-PART modális tényező egy e eventualitás „részleges tudásának” a megragadására hivatott (ld. a b., d. episztemikus olvasatokat); amin nem bizonytalan tudást értek, hanem olyan információdarabok ismeretét, amelyek a *ReALIS* élethossziglani interpretálói belső világaiban az e tudásdarabhoz asszociálódnak mintegy „tanúskodva” az e fennállása mellett. A *hazamehetett* alaknál például a táblázatban ez a két intenzionális elemzés szerepel: a „a beszélő szerint valaki hazament, mert engedélyt kapott erre” (nyilván az is vizsgálendő, hogy r* az engedélyezéshez megfelelő pozícióban van-e); b. „meglehetősen valószínű, hogy valaki hazament, mert vannak emellett tanúskodó jelek (nincs ott az irodájában, sőt a kabátja és az esernyője sincs ott, elmúlt már 18¹⁰, stb.)”.

↓Mód Modalitás→	<i>hazamegy + -(V)t</i>		<i>hazamegy + -(V)t + vol- + -nA</i>	
	<i>hazame-het-ett</i>		<i>hazame-het-ett vol-na</i>	
<i>-hAt</i>	a. <INT,r*,0> <BEL _{MAX} ,S,+>	b. <BEL _{med} ,S,+> <BEL-PART _{great} ,S,+>	e. <INT,r*,0> <BEL _{MAX} ,S,->	f. <DES _{great} ,S,+> <BEL _{MAX} ,S,->
<i>kell</i>	<i>haza kell-ett</i> ↯ <i>men-ni(e) / menni</i> ↯		<i>haza kell-ett vol-na</i> ↯ <i>men-ni(e) / menni</i> ↯	
	c. <INT _{MAX} ,r*,+> <BEL _{MAX} ,S,+>	d. <BEL _{amax} ,S,+> <BEL-PART _{MAX} ,S,+>	g. <INT _{MAX} ,r*,+> <BEL _{MAX} ,S,->	h. <DES _{amax} ,S,+> <BEL _{MAX} ,S,->

1. ábra. A magyar mód és modalitás múlt idejű alakjainak modális elemzése

Hasonlóképpen modellezhetjük az aspektusok intenzionális karakterét. Vegyük például górcső alá a (9a)-beli progresszív válaszmondatot! A progresszivitásból adódóan fellép egy Imperfektív Paradoxonként emlegetett jelenség [10:147]: nem dönthető el a mondat igazságértéke pusztán a külvilági tények alapján. Csak a szóban forgó nap 18¹⁰ előtti időszaka tesztelendő externálisan, vagyis a hazautazási esemény kumulatív szakaszának egy kezdőintervalluma (9c). A teljes esemény lefolyásáról a beszélő nem garantál biztos tudást (9b), csupán erős valószínűséget sugall (9b). A 18¹⁰ utáni időszakra vonatkozóan tehát „internális” információ áll rendelkezésre: egyrészt az említett beszélői valószínűsítés, ami a „dolgok szokásos rendjének” ismeretéből fakadhat (9b), másrészt (legalábbis preferálnak hat egy ilyen értelmezés) az alanynak tulajdonított szándék. Úgy látom egyébként, hogy a (9b-d) intenzionális karakter egy az egyben a jövő idő jellemzésére is alkalmas: a (9e) mondatot is úgy értelmezzük (egyik jelentésében), hogy az eseményről biztos tudás persze nincs, de valószínű, hogy lefolyik (9b), mert a beszélő rendelkezésére állnak erről tanúskodó jelek (9c), és preferáltan az alany szándéka is megvan (9d). A progresszív tehát végső soron nem más, mint „jövő a múltban”.

9. példa. A MAGYAR PROGRESSZÍV ASPEKTUS ÉS A JÖVŐ IDŐ

- a. (Mit csinált Péter 2003. május 4-én 18¹⁰-kor?) Utazott (éppen) haza.
- b. $\Gamma_{e:hazautazik} = \{ \langle \langle \text{BEL-MAX}, s, \tau, 0 \rangle \rangle, \langle \langle \text{BEL}_{\text{great}}, s, \tau, + \rangle \rangle \}$
- c. $\langle \langle \text{BEL-PART}_{\text{MAX}}, s, \tau, + \rangle \rangle$
- d. $\langle \langle \text{INT}, \Gamma_{\text{Peter}}, \tau, + \rangle \rangle \}$
- e. Péter haza *fog* utazni.

5 Az információ beágyazása az interpretálói információállapotba

Az előző két szakaszban különféle lexikai egységek intenzionális karakterének a hatását tárgyaltam a dinamikus interpretáció kimenetére. Vannak azonban pragmatikai hatások is.

Kézenfekvő például, hogy az *ironia* egyszerűen megfordítja bizonyos világocskák polaritási címkéjét ($\pi=-$). Más esetben megsejthető, hogy a beszélő blöfföl; ilyenkor a megfelelő világocska polaritása: $\pi=0$. Nem nyertünk volna hát semmi információt? Dehogynem! Csak nem a külvilágról, hanem a beszélő sanda szándékáról... – hogy például elhiggyünk valamit, ami talán nem is úgy van; vagy hogy elhitesse velünk, hogy ő tud valamit.

Elméleti háttérünk élethossziglani jellegéből adódóan kézenfekvő lehetőség kínálkozik a *megbízhatóságáról* modellt alkotni akár az információnak, akár az interpretáló ágenseknek. Össze kell vetni egy információdarabra nézve különböző interpretálók intenzionális mintázatait, illetve rögzített interpretálókat tekintve azok intenzionális mintázatait különféle eventualitások vonatkozásában. A legegyszerűbb alkalmazandó elv például az, hogy megbízhatóbb az az információ, ami független forrásokból ugyanabban a formában érkezik, és ez az egybeesés a források megbízhatóságát is növeli. Ilyen elveknek kell irányítaniuk az információ áramlását az ideális interpretáló részbenrendezett világocskahálózatában, illetve annak meghatározását, hogy az információforrásként szolgáló ágensek milyen módon térnek el az „ideális beszélő” default képétől, ami a lexikai intenzionális hatások tárgyalása során (3-4.) mindig a kiindulópontunk volt.

Mivel a $\Re\text{eALIS}$ a kommunikációban álló interpretálók „élethossziglani” és „kölcsonös” multiágens rendszere, különböző kérdéstípusok intenzionális modellezésére is készen kínálkozik. Az alábbi (10a-e) pontokban a *kiegészítendő kérdésekre* vonatkozóan vázolok fel egy világocskaindexekre épülő elemzést. Az r^* referens Pál (adott időpontbeli) feleségeként határozódik meg a (10b)-ben. A szintén r^* -ról szóló e^* eventualitás pedig a (10c) pontban a (10d)-ben meghatározott világocska-mintázatban jelenik meg, lehorgonyzatlan (azonosítatlan) p^* predikátummal. A kérdő formából adódóan az e^* olyan, hogy (10d) a beszélő nem tudja eldönteni az igazságértékét, de szándékában áll elérni ezt; valószínűsíti továbbá, hogy a hallgató birtokában van a releváns tudásnak, és reméli, hogy hajlandó is lesz megosztani vele. A (10c)-beli p^* „lehorgonyzatlanságának” jelentősége a következő: a formális pragmatikai kezdeményezések [9] sarokkövének tekinthető „Maximalizáld a diskurzuskohereciát!” elv arra fogja készíteni a hallgatót, hogy a p^* predikátumreferenst a lehető leghatékonyabban horgonyozza le. A válasz hatékonyságát nyilván a kérdező információállapotának növekményére alapozva határozhatjuk meg. A (10e.1) válasz például

nyilván a legkedvezőtlenebb, mert aligha nyújt információnövekményt a kérdező meglévő enciklopédikus tudásához képest. A 3. válasz pedig hatékonyabb a 2. válasznál, akkor – és csakis akkor –, ha a kérdező ismeri a megnevezett személyt; egy azonosított entitás referensének a megtalálása ugyanis elérhetővé teszi mindazt a roppant információtömeget, ami e referenshez kapcsolódott „élethossziglan”.

10. példa. A KÉRDÉS KÉRDÉSE

- a. Ki volt Pál felesége akkoriban?
- b. e : $p_{\text{felesége}} t \Gamma^* \Gamma_{\text{Pál}}$
- c. e^* : $p^* t^* \Gamma^*$
- d. $\Gamma_{e^*} = \{ \langle \langle \text{BEL}_{\text{MAX},S,\tau,0} \rangle \rangle, \langle \langle \text{INT},S,\tau,+ \rangle \rangle, \langle \langle \text{BEL}_{\text{MAX},S,\tau,+} \rangle \rangle, \langle \langle \text{BEL}_{\text{great},S,\tau,+} \rangle \rangle, \langle \langle \text{BEL}_{\text{MAX},h,\tau,+} \rangle \rangle, \langle \langle \text{DES},S,\tau,+ \rangle \rangle, \langle \langle \text{INT},h,\tau',+ \rangle \rangle, \langle \langle \text{BEL}_{\text{MAX},S,\tau',+} \rangle \rangle \}$
- e. 1. „Egy nő.”
2. „Egy pincérnő a kedvenc indiai éttermünkéből.”
3. „Az elbűvölő Shabana Singh.”
- f. Ki *is* volt Pál felesége akkoriban?
- g. $\Gamma_{e^*}^+ = \{ \langle \langle \text{BEL}_{\text{great},S,\tau,+} \rangle \rangle, \langle \langle \text{BEL}_{\text{MAX},S,\tau',+} \rangle \rangle, \langle \langle \text{BEL}_{\text{amax},S,\tau,+} \rangle \rangle, \langle \langle \text{BEL}_{\text{MAX},h,\tau,+} \rangle \rangle, \langle \langle \text{BEL}_{\text{great},S,\tau,+} \rangle \rangle, \langle \langle \text{BEL}_{\text{amax},h,\tau',+} \rangle \rangle, \langle \langle \text{BEL}_{\text{MAX},S,\tau',+} \rangle \rangle \}$
- h. Tunteeko Pekka Marjan / Marjaa? 'Péter ismeri Marit?'
ismer-E3-Q Péter Mari-ACC / Mari-PART (e: $p_{\text{ismer}} t \Gamma_{\text{Péter}} \Gamma_{\text{Mari}}$)
- i. $\Gamma_e = \langle \langle \text{BEL}_{\text{MAX},S,\tau,0} \rangle \rangle, \langle \langle \text{BEL}_{\text{great},S,\tau,+/-} \rangle \rangle, \langle \langle \text{INT},S,\tau,+ \rangle \rangle, \langle \langle \text{BEL}_{\text{MAX},S,\tau,+/-} \rangle \rangle$
- j. ... És PÉTERT *is* hívtuk meg!
- k. $\Gamma_{e[\text{Péter az...}]} = \{ \langle \langle \text{BEL}_{\text{MAX},S,\tau,+} \rangle \rangle, \langle \langle \text{INT}_{\text{MAX},S,\tau',+} \rangle \rangle, \dots \}$

A fenti (10f) példa újabb csodálatos megnyilvánulása egy piciny nyelvi elem sokrétű intenzionális hatásának. Lelkesedésem tárgya ezúttal az *is* szócska – diskurzupartikulaszerű szerepben. A (10g)-ben foglaltakat teszi hozzá a kérdőszó szemantikai-pragmatikai kontribúciójához (10d): a beszélő biztos benne, hogy egykor birtokában állott az e^* tudás ($\tau' < \tau$), és majdnem biztosra veszi, hogy a hallgatója most is tudja; preferálnak érzem továbbá azt az értelmezést, hogy a kérdező úgy véli, hogy hallgatója tudja róla, hogy egykor birtokában állott neki *is* az e^* információ (az együtt töltött „rég szép időkben”...).

Az eldöntendő kérdés annak jelzése, hogy a beszélő sem abban nem biztos, hogy egy bizonyos e eventualitás igaz, sem abban, hogy hamis, és szeretne biztosat tudni. A (10h) finn példa annyiban különleges, hogy a tárgy esetjelölése (Akkuzatívusz / Partitívusz) arról is információt ad (10i), hogy a kérdező pozitív vagy negatív választ vár-e (el).

Az *is* szócska egy másik sajátos jelentéshozadékaival zárom az intenzionális mintázatok elemzését. A fenti (10j) fókuszos mondat csak olyan diskurzusban hangozhat el, ahol előtte ugyanaz a tartalom ugyanolyan fókuszkonstrukcióval mint szándék (10k) fogalmazódott meg.

Hivatkozások

1. Alberti, G.: \Re ALIS: An Interpretation System which is Reciprocal and Lifelong. Workshop 'Focus on Discourse and Context-Dependence' (16.09.2009, 13.30-14.30 UvA, Amsterdam Center for Language and Comm.), <http://www.hum.uva.nl/aclc/events.cfm/C2B8E596-1321-B0BE-6825998CFA642DB2>, <http://lingua.btk.pte.hu/realispapers> (2009)
2. Alberti, G.: \Re ALIS: Interpretálók a világban, világok az interpretálóban. Budapest: Akadémiai Kiadó (2011)
3. Alberti, G.: \Re ALIS, avagy a szintaxis dekompozíciója. Általános Nyelvészeti Tanulmányok XXIII. (szerk. Bartos H.), 51–98 (2011)
4. Alberti, G., Károly, M., Kleiber, J.: The \Re ALIS Model of Human Interpreters and Its Application in Computational Linguistics. In Cordeiro, J., Virvou, M., Shiskov, B. (eds.): Proceedings of ICISOFT 2010, 5th International Conference on Software and Data Technologies, Athens, Greece. Vol. 2., pp. 468–474. SciTePress Portugal (2010)
5. Alberti, G., Károly, M., Kleiber, J.: From Sentences to Scope Relations and Backward. In: Sharp, B., Zock, M. (eds.): Natural Language Processing and Cognitive Science. Proceedings of NLPCS 2010. SciTePress, Funchal, Madeira, Portugália. 100–111 (2010)
6. Alberti, G., Kilián I.: Vonatkeretlisták helyett polaritásos hatáslánccsaládok – avagy a \Re ALIS σ függvénye. Tanács A., Vincze V. (szerk.): VII. Magyar Számítógépes Nyelvészeti Konferencia, MSZNY 2010. SZTE Informatikai Tanszékcsoport. 113–126. <http://www.inf.u-szeged.hu/mszny2010> (2010) 113–126
7. Alberti, G.: The Grammar of \Re ALIS and the Implementation of its Dynamic Interpretation. Informatica, vol. 34/1, pp. 103–110 (2010)
8. Alberti, G., Kleiber, J.: Where are Possible Worlds? (Arguments for \Re ALIS). SinFonIJa4, Budapest (2011)
9. Asher, N., Lascarides, A.: Logics of Conversation. Cambridge Univ. Press (2003)
10. Dowty, D. R.: Word Meaning and Montague Grammar. D. Reidel Publishing Company, Dordrecht (1979)
11. Dowty, D. R., Wall, R. E., Peters, S.: Introduction to Montague Semantics. D. Reidel Publishing Company, Dordrecht (1981)
12. Farkas, J.: A produktív finn képzések. Alberti, G. (szerk.): Vonatok vonzásában. PTE BTK Nyelvtudományi Doktori Iskola. *-* (2012)
13. Grice, H. P.: Logic and Conversation In Cole, P., Morgan, J.L. (eds.): Syntax and Semantics Vol. 3: Speech Acts. New York: Academic Press, pp. 41–58 (1975)
14. Kálmán, L.: Deferred Information: The Semantics of Commitment. Kálmán, L., Pólos, L. (eds.): Papers from the Second Symposium on Logic and Language. Akadémiai, Budapest, pp. 125–157 (1990)
15. Kamp, H., van Genabith, J., Reyle, U.: Discourse Representation Theory. In Gabbay, D., Guenther, F. (eds.): Handbook of Philosophical Logic, vol. 15, pp. 125–394. Springer-Verlag, Berlin (2011)
16. Károly, M.: Interpretáció és modalitás – avagy a \Re ALIS λ -függvényének implementációja felé. Jelen kötet, *-* (2011)
17. Kiefer, F.: Jelentélmélet. Corvina, Budapest (2000)
18. Kilián, I.: Tárgymodell változatok a \Re ALIS nyelvi elemzéshez. Jelen kötet, *-* (2011)
19. Pollard, C.: Hyperintensions. ESSLLI 2007, <http://www.cs.tcd.ie/esslli2007> (2007)
20. Roberts, C.: Anaphora in Intensional Contexts. In Lappin, Sh. (ed.): The Handbook of Contemporary Semantic Theory. Oxford: Blackwell, pp. 215–246 (1996)

Tárgymodell változatok a ReALIS nyelvi elemzéshez

Kilián Imre

ReALIS ESzNyK / PTE TTK Informatika Tanszék
7624 Pécs, Ifjúság útja 6.
kilian@gamma.ttk.pte.hu

Kivonat: Forrásnyelvek célnyelvre átalakítását (pl. fordítóprogramokban) a két metamodell közötti átalakítási szabályrendszerként értelmezhetjük. A ReALLan forrásnyelv, és a választott Prolog nyelvű tárgymodell változatok közötti leképezés megadását jelenti. Szövegfeldolgozási célokra Prolog nyelven általában a relációs tárgymodellt alkalmazzák, mert ez a nyelv jellegéből fakadóan a szöveg-nyelvtani szerkezet relációt nemcsak az adott (felismerési) irányban, hanem fordítva, szöveggenerálási irányban is képes kiszámítani. Hatékonysági okokból azonban még további tárgymodell változatokat is érdemes számításba venni. A következtetési tárgymodell esetében az elemzett szöveg szavai tényállításokká, a ReALIS lexikonban ábrázolt nyelvtani információk szabályokká képződnek le, amelyek egy célállításból meghíva előállítják az elemzett szöveg nyelvtani szerkezetét. A Prolog logikán túli eszközeinek használatával a deduktívan megvalósított elemzési feladat abduktívan megvalósított szöveggenerálássá alakítható. A ReALIS lexikonban tárolt nyelvtanának, és az elemzési folyamat aszinkron jellegének a Prolog visszafelé következtető stratégiája helyett azonban jobban megfelel egy előre haladó modell. A cikkben tárgyalt Contralog modell a Prolog előre haladó kiterjesztése, amellyel magyar mondatok ReALIS elmélet szerinti elemzését mutatjuk be.

ReALLan: a ReALIS nyelvleíró nyelve

Természetes nyelvi megvalósítások egyik sarokköve a nyelvi információk leírási módja. Ezt célszerűen valamilyen nyelvleíró formális nyelven tehetjük meg. Ha csupán a szöveges kinézetet megadó valamelyik *nyelvtani formalizmusra* (pl. BNF) szorítkozunk, akkor a kinézet oltárán feláldozzuk az adatszerkezetet és annak az értelmezését. Objektum-orientált rendszerekben a formális nyelv *metamodelljét* pl. UML-ben adjuk meg, amely a nyelv elemeit grafikus módon rögzíti, és amelyhez az *érvényességi szabályokat* az OCL megszorításleíró nyelvvvel adhatjuk meg. A mi esetünkben a Prolog megvalósítás miatt a ReALLan a Prolog egy résznyelve, vagyis az alapnyelvtan egyfajta alkalmazói megszorítása. Mivel a Prolog típusatlan, ezért erre a célra egy Prolog *típusleíró nyelvkiegészítést* (ReALType) valósítottunk meg.

A ReALLan nyelvleíró nyelven a rendszer teljes lexikalizmusa miatt a lexikonbéli elemekhez rendelhető nyelvtani információk rögzítésének szabályait lehet megadni. A

nyelv alapvetően *jegyszerkezetes*, egy jegyszerkezet mátrix megadása alapvetően Prolog listában, JEGY:ÉRTÉK párokkal lehetséges. Ehhez az általános leíráshoz képest a következő *bővítéseket* és *nyelvtani könnyítéseket* (syntactic sugar) tesszük lehetővé:

- Ha egy jegy értéke szintén összetett, és a jegygeometriában megadott összes jegyet tartalmazza, akkor a jegynevek megadása nem kötelező, és a Prolog listakifejezés helyett kerek zárójelekkel *teljes Prolog kifejezés* is megadható. Pl. `agr:[pers:1,nr:sing]` helyett `agr(1,nr)` is írható.
- Azonos értékek (KIG összefutó élek) jelölésére (fordításidejű egyesítés) *Prolog változókat*, és a `:=/2` funktort használjuk. Pl: `PRED=desire(SUBJ,OBJ)`.
- A fordításidejű egyesítés mellett a `:=/2` funktorral a *jobboldal kiértékelésére és futásidejű egyesítésre* is lehetőséget adunk. Pl. az `RDES1:= [argn(ord(-7,nei),cat(+2,noun), case(+2,nom)), argd(cat(+7,gqd))]` ...kifejezés futásidőben egyesíti a Prolog változót, mint referenst a szövegben megfelelő helyzetben talált alanyesetű, főnévvel úgy, hogy a szerkezet általánosított kvantordetermináns szerepben van.

Tárgymodell: Horn-klózkod

A tárgymodellek leírásához érdemes rögtön az átalakítási szabályrendszert is hozzákapcsolni. Ha a szigorú objektumorientáltság elvei mellett maradunk, akkor ez úgy történik, hogy a forrás- és a célkörnyezet metamodelljét kapcsolatnyalábbal kapcsoljuk össze, melyet az átalakítások szabályait rögzítő OCL megszorításokkal látunk el. Bár most nem kívánjuk az UML modelleket bemutatni, a metamodellek, és az átalakító relációk fogalma a modellező eszköztől független, és a Prologhoz kötődő környezetben is alkalmazható úgy, hogy a forrás- és célkörnyezet fogalmait, valamint a közöttük megvalósítandó *átalakítási relációt* adjuk meg.

A célkörnyezet a *Horn-klózkod osztálya*. Ez az elsőrendű logika azon részosztálya, amelyekben a klózkod következményoldalán több literál diszjunkciója helyett legfeljebb *egyetlen literál* állhat.

$p_1; p_2; \dots; p_k :- n_1, n_2, \dots, n_1.$

A részosztály azért figyelemre méltó, mert a Prolog programozási nyelv is ezt használja úgy, hogy a következtetéseket a háttérben egy rögzített stratégiájú, rezolúciós tételbizonyító végzi. A visszafelé haladó, lineáris-, egység- és alaprezolúciós stratégia tételbizonyításra gyengécskének tűnik, de cserébe a nyelv nem logikai eszközeivel meglehetősen rugalmas és magasszintű működés írható elő.

A ReALIS céljaira a Horn-klózkodra alapuló relációs és következtetési tárgymodell is, ez utóbbira pedig a Prolog eredeti, *visszafelé haladó*, ill. a Horn klózkod újonnan kifejlesztett, *előre haladó* értelmezésére alapuló tárgymodell is kidolgoztuk.

Relációs tárgymodell

A Horn-klózik relációs tárgymodell szerinti alkalmazásakor egy program bemenet/kimenet relációját egy adott Prolog szabály számítja ki. Ha egy reláció több részrelációból van összetéve, akkor azokat a szabály feltételében nevezzük meg úgy, hogy a be- és kimenő paraméterek egymáshoz láncszerűen kapcsolódnak. Az ilyen szerepű változókat a Prolog programozók *akkumulátorpárnak* nevezik.

```
reláció (BE, KI) :-  
    rész1 (BE, TMP1) , rész2 (TMP1, TMP2) , ... , részN (TMPN-1, KI) .
```

A Definite Clause Grammar (DCG) formalizmus relációs tárgymodell szerinti nyelvtani elemzésekor a <bemenet-elemzetlen szöveg> párt használjuk akkumulátorként, a tetszőleges argumentumszerkezethez az akkumulátorpárt pedig a DCG előfordító maga hozza létre.

```
nonterm (...) → nonterm1 (...) , nonterm2 (...) , ... , nontermN (...) .
```

```
nonterm (... , BE , KI) :-  
    nonterm1 (... , BE , TMP1) , nonterm2 (... , TMP1 , TMP2) , ... ,  
    nontermN (... , TMPN-1 , KI) .
```

A megoldás egyik hátránya: a *relációk nemdeterminisztikus kiértékelése* miatt az eredményreláció számossága legrosszabb esetben az egyes részrelációk számosságának a szorzata is lehet. Ha viszont a szorzatban az első részreláció számossága nagyobb, akkor a nemdeterminizmus visszalépéses kezelése miatt egészen az első relációig tartó, ún. *mély visszalépés* történik.

A ReALIS relációs tárgymodell szerinti megvalósításában a bemenő paraméter az elemzendő szöveg, a kimenő pedig a szövegnek megfelelő logikai kifejezés-szerkezet. Értelmes rész-relációk lehetnek: szóalaktani, nyelvtani-szemantikai elemzés, ill. pragmatika. Ilyen értelmezés mellett ugyanazt a szabályt használhatjuk elemzésre, (ha híváskor TEXT adott, LOGEXPR viszont változó), illetve szöveggenerálásra is (ha híváskor TEXT változó, de LOGEXPR adott).

```
text2logic (TEXT, LOGEXPR) :-  
    morphology (TEXT, MORPHLIST) ,  
    syntaxSemantics (MORPHLIST, PUREEXPR) ,  
    pragmatics (PUREEXPR, LOGEXPR) .
```

Sajnos a relációs tárgymodell és az ezzel összefüggő Prolog DCG formalizmus a mi céljainkra nemigen alkalmas. A ReALIS környezeti feltételei (pl. vonzatok bizonyos távolságban) csak úgy lennének elemezhetőek, ha azokat a bemenő szövegben előre-hátra mozgással ellenőriznénk. Ennek a megvalósítása is körülményes, és komoly hatékonysági aggályokat is felvet.

A ReALIS megvalósítás célkitűzése a szöveg és a diskurzusreprezentáció közötti reláció kiszámítása. Ez (Prolog-szerű értelmezésben) mindkét irányú kapcsolatot jelenti. Ha a szöveg adott, akkor a program azt a reprezentációs kifejezést számítja ki,

amely az adott logikai rendszerben és az interpretáló belső tudatállapotát leíró tudásbázisban (ontológiában) kiértékelhető, bizonyítható, vagy hozzávehető a tudásbázishoz. Az ellenkező irányban: ha a tudáskezelő összetevő által (pl. egy kérdésre adott válaszként) egy logikai kifejezést kapunk, akkor reláció a szöveg képét állítja elő.

A megoldás másik hátránya, hogy a szöveg legalább egy bekezdésnyi, de esetleg akár több oldalnyi hosszú is lehet. Ez egyrészt a feldolgozás időigényét behatárolja, másrészt a hosszú bemenő adatokon az igen mély visszalépések csökkenthetik az elemzés hatékonyságát. Harmadrészt a szélsőségesen összetett adatszerkezetek sok Prolog megvalósítás fizikai határait is feszegethetik (pl. verem túlcsordulást okozhatnak).

Következtetési tárgymodell Horn-klózon

A következtetési tárgymodell esetében a bemenő szöveget nem listaparaméterként, hanem *tényállításokként* ábrázoljuk. A cikkben feltételezzük, hogy a szóalaktani elemzés már megtörtént, és már csak a nyelvtani-szemantikai elemzés van hátra.

```
word(peter,1,1,noun('Péter',proper,nom,sing-3)).
word(peter,1,2,verb('hasonlít',[],decl,pres,sing-3)).
word(peter,1,3,noun('az',pro(point),sub,sing-3)).
word(peter,1,4,art(def,cons)).
word(peter,1,5,adj('vörös')).
word(peter,1,6,adj('ukrán')).
word(peter,1,7,adj('futó')).
word(peter,1,7,noun('bajnok',common,sub,sing-3)).
```

A ReALLan szabályok követel-kínál mechanizmusa szinte kínálja magát arra, hogy Horn-klózzokká képezzük le őket. Az alábbi klóz pl. a 'hasonlít' ige és kötelező vonzatai közötti kapcsolatot írja le.

```
regArg2(ID,S,XV,verb('hasonlít',[],MODE,VTIME,AGR),
        XS,noun(SUBJ,SKIND,nom,AGR),-7,
        XO,noun(OBJ,OKIND,sub,OAGR),7):-
verb(ID,S,XV,'hasonlít',[],MODE,VTIME,AGR),
gqdet(ID,S,XS,SUBJ,SKIND,nom,AGR), order(XV,XS,-7,nei),
gqdet(ID,S,XO,OBJ,OKIND,sub,OAGR), order(XV,XO,7,nei).
```

Szintén Horn klózzok írják le a ReALIS σ (sigma) függvényének megfelelő eventuális kifejezések részkifejezésekből történő felépítését is.

```
sigma3(ID,S,XV,TIME,SUB,OB,CLAUSE):-
regArg2(ID,S,XV,verb('hasonlít',[],_MODE,VTIME,_AGR),
        XS,SUBJ,_PRS,XO,OBJ,_PRO), {TIME =.. [VTIME,_]},
sigma3(ID,S,XS,TIME,SUB,CLAUSE,
```

```
(desire (TIME, SUB, OB) :-CONS) ,
sigma3 (ID, S, XO, TIME, OB, CONS) .
```

A fenti állítás eredményképpen a mondat logikai alakjaként a következőket kapjuk. (A kettős implikáció egy egyszerű normáló program segítségével átalakítható feltételek konjunciójává.)

```
CLAUSE= ( (similar (pres (T) , SUB, OB) :-
run (T, OB) , ukrain (T, OB) ,
red (T, OB) , champion (T, OB) ) :-
name (T, SUB, 'Peter' ) )
```

Visszafelé haladó tárgymodell (Prolog)

A visszafelé haladó tárgymodell magát a Prolog értelmezőt használja következtető motorként úgy, hogy az általános következtetési tárgymodellt használja. Ebben a megközelítésben az elemzést a logikai alakra változóként hivatkozó *célállítás* hívásával indítjuk. Ha visszavezethető a célállítás a szöveget rögzítő tényállításokra, akkor a mondat elemezhető volt, és a közben elvégzett változóhelyettesítésekből kiadódik a célállításban szereplő logikai alak is.

A megközelítés egyik hátránya, hogy a bizonyításhoz *hipotézist* kell felállítani, ez gyakorlatilag a célállítás. A bizonyítás időpontjában már minden ténynek ismertnek kell lennie – a rendszer nem alkalmas csövezeték- (pipe) -szerű feldolgozásra.

Másrészt viszont a visszafelé bizonyítás logikája szerint még az ismétlődő rész-bizonyításokat is újra és újra elvégzi, ezzel romlik a hatékonysága.

A fentebb vázolt tárgymodell alapvetően *deduktívan, felismerőként* használható, mégis kicsi módosítással *abduktív, szöveggenerátor* célú használatra is alkalmas. Ha a célállítást a logikai alak megadásával, de hiányzó szövegekép-tényállításokkal indítjuk, akkor a visszafelé bizonyítás során előbb-utóbb a tényállítások szintjéig ér. Ha az üres tényállításokat *visszaléptethető állításfelvétellel* (*assert*) valósítjuk meg, akkor a program végeredményben abduktív bizonyítást fog végezni.

```
word (ID, S, X, WORD) :-
(assert (w (ID, S, X, WORD) ) ;
retract (w (ID, S, X, WORD) ) , fail) .
```

Conralog: Horn klózek előre haladó értelmezése Prologban

A Conralog tervezésekor cél volt, hogy az előre- és visszafelé haladó működés integrálható legyen úgy, hogy a logikai forrásnyelv ugyanaz (a Horn klózek nyelve), amit részben maga a Prolog visszafelé haladóan, részben pedig az előrehaladó motor akként értékelhet ki. A kétféle rezolúciós stratégia pedig a programozó által vezérelhetően legyen váltható: egyrészt a Prologból legyen meghívható az előrehaladó motor, másrészt az előrehaladó végrehajtásból legyen meghívható a Prolog.

A Contralog programnyelv a Horn klózek nyelvét (a Prolog nyelvet) előrehaladó stratégiát megvalósítva képezi le a Prolog nyelvre magára úgy, hogy egy inkrementális fordítóprogram a beolvasott Contralog szabályokat Prolog szabályokká fordítja le, és a szabványos Prolog futtatókörnyezetben működteti. [4]

Az így létrehozott rendszerben tehát minden fordítva működik, mint a Prologban:

- A következtetést nem a célállítások, hanem a *tények* indítják.
- ha van olyan szabály, amelynek feltételrészében egy adott tény szerepel, akkor megvizsgáljuk, hogy a feltétel többi részét már sikerült-e bebizonyítani korábban. Ha igen, akkor a *szabály tüzel*, vagyis a következményrész sikerült bebizonyítanunk.
- A bebizonyított következmény újabb *egységklóz rezolvenseket* (bebizonyított tényeket) jelent, amelyet a *munkatáblán* (blackboardon) eltárolunk, és ezzel a ténnyel folytatjuk a bizonyítást.
- A következtetési folyamatot a *célállítások* állítják le.
- Célállítás elérésekor, vagy ha bármi okból a bizonyítás az adott láncon tovább nem folytatható, a rendszer visszalép, és egy korábban nyitva hagyott alternatíva mentén próbálkozik újra.

A Prolog-Contralog kapcsolatot kétféleképpen lehet működtetni:

- a Contralog szabályok feltételrészében a `{ }/1` literál közvetlen Prolog cél meghívását eredményezi.
- A Contralog *importok* azok a tények, amelyek egy modul következtetési láncát elindítják. Ez az indító tényeknek megfelelő Prolog tüzelési szabályok exportját jelenti.
- A Contralog *exportok* viszont azok a predikátumok, amelyeket az előre haladó stratégia szerint tényként kikövetkeztettünk, és vagy másik modul importját elégítjük ki vele, vagy a Prolog futtatórendszer egy predikátumát hívjuk meg. A Contralog exportokból Prolog importok lesznek (, bár ezt a fogalmat a szabványos Prolog nem ismeri).

A fent ismertetett alpműködésen túl az elburjánzó következménytények törlésére logikán kívüli eszközöket vezettünk be:

- minden tárgymodulban létrehoztunk egy, a *munkatáblát teljesen törölő* Prolog eljárást, amit a `MODULE:clean` hívással indíthatunk.
- egyes tények kikövetkeztetésekor *letilthatjuk a következtetést az adott szálon* (a ténny a munkatáblán tároljuk ugyan, de a megfelelő tüzelő eljárásokat nem hívjuk meg). Ezt a működést a `:- lazy NAME/ARITY.` deklaráció hatására válthatjuk ki.
- egyes tények kikövetkeztetésekor az *azonos névjegyű tényeket mind töröljük a munkatábláról* (`:- var NAME/ARITY.`), vagy egyes argumentumokat – a relációs technológiához hasonlóan – kulcsként tekintve, csak az azonos kulcsú ténnyet töröljük. Ezt a `:- key(NAME(KEYVECTOR)).` deklarációval válthatjuk ki, ahol a `KEYVECTOR` szerkezet egy argumentumlista, ahol a „+” jel azt jelzi, hogy az argumentum kulcsként szerepel, a „-” pedig azt, hogy nem.

Az előre haladó következtetés alapproblémája, hogy a klózek feltételrészén több elemi feltétel is szerepelhet. Amikor ezek közül nem mindegyik elégül ki, a hiányzókat meg kell várni, és a következmény tüzelését csak akkor indítjuk, ha az utolsó feltétel is kielégült. Ezt úgy érjük el, hogy a már kielégülteket dinamikus

állításokként tároljuk, és egy Contralog szabály összes feltétel-literáljához létrehozunk egy külön Prolog szabályt, ami ellenőrzi, hogy a többi feltétel már korábban teljesült-e. Vegyünk egy egyszerű példát, tekintsük a következő Contralog szabályt!

```
a:-b, c.
```

Ha a *b* vagy a *c* feltételek kielégültek, akkor az eredményként kapott tények a megfelelő *b/0*, ill. *c/0* dinamikus állításokban található. Mindegyik feltételhez létrehozunk egy *fire_NAME* tüzelő, és egy *test_NAME* ellenőrző Prolog predikátumot. Az előbbi tárolja a kikövetkeztetett tényt, majd meghívja az utóbbit. Az utóbbi pedig ellenőrzi, hogy a többi Contralog feltétel teljesül-e, és ha igen, akkor meghívja a következményhez tartozó tüzelő eljárást.

A fenti esetben ez a következő Prolog kód létrehozását jelenti:

```
fire_b:- assert(b), test_b.  
fire_c:- assert(c), test_c.  
  
test_b:- c, fire_a.  
test_c:- b, fire_a.
```

A fenti tárgymodellben továbbra is a Prologhoz hasonló *visszalépéses keresés* történik. Választási pontok többféleképpen is keletkezhetnek.

- Ha egy feltétel több Contralog szabályban is szerepel, akkor annyi Prolog alternatíva jön létre belőle, ahány szabályban a feltétel szerepel.
- Ha egy feltétel többször is teljesül, akkor ugyanannyi *dinamikus tény* jön létre belőle – feltéve, hogy az adott feltételre nem teljesülnek a következtetési ágak megnyirbálását célzó deklarációk.
- A modul összes statikus tényállításának a tárolása úgy történik, hogy a Prolog modul célállítása visszalépésesen meghívja az összes *statikus tény tüzelő eljárását*. Vagyis, ha valamilyen feltétel nem teljesül, akkor végső soron akár egészen a Prolog célállításig is történhet egy visszalépés.

A nyitott választási pontokra a visszalépések során kerül a vezérlés. Visszalépés szintén többféleképpen bekövetkezhet

- Ha valamelyik feltétel az adott pillanatban *nem teljesül*. Ez lehet Contralog feltétel, de a feltételek közé beszúrt Prolog feltétel meghiúsulása is.
- Ha egy Contralog célállítás elérésekor (a Prologhoz hasonlóan) újabb megoldások kérésével *visszalépésre kényszerítjük* a rendszert.

Előre haladó tárgymodell (Contralog)

Az előre haladó tárgymodell esetében a *szabályalkalmazási rohamokat* (burstout) az egyes mondatelemek, mint tények felvétele (beérkezése) indítja. A tények érkehetnek *aszinkron módon*, időben elcsúsztatva, sőt akár tetszőleges sorrendben is: egy következtetési lépés akkor történik meg, ha minden feltétel megérkezett és rendelkezésre áll. Bár van lehetőség a *következtetési fa ágainak nyirbálására*, a

következmények a teljes gazdagságukban előállnak, ha ezekből néhány illeszkedik a megadott célállításokra, akkor a következtetés leáll.

A modell előnye, hogy az egyszer bebizonyított tényeket tároljuk, és azokat akárhányszor fel lehet még használni.

Sajnos az előrehaladó modell abduktív módon szöveggenerálásra történő használata nem látszik kézenfekvőnek.

Értékelés

A tesztmondatok elemzése a bemutatott modellváltozatok alapján elegendő tapasztalatot szolgáltatott. A következő lépés a ReALLAN-Horn-klóz fordítóprogram megírása lehet. Károly Márton munkájában az elemzési modellt modalitások beépítésével egészíti ki. A modalitások kezelése pedig kijelöli az utat a háttérben alkalmazott tudástár összetevő megtervezéséhez – egy *multimodális többszereplős logikai következtető rendszer* képében.

A szerzőt e cikk alapjait jelentő kutatásaiban az OTKA T60595 sz. projektje támogatta, a konferencia-részvételt pedig a TÁMOP-4.2.1.B-10/2/KONV/2010/KONV-2010-0002 (A Dél-dunántúli régió egyetemi versenyképességének fejlesztése). Itt szeretnék köszönetet mondani a ReALIS projektbéli munkatársaimnak, Alberti Gábornak, Kleiber Juditnak és Károly Mártonnak a nyelvészeti információk önzetlen átadásáért és a jól célzott, és egyben megfelelően adagolt, a cikk végső példányára is kiható megjegyzéseikért.

Hivatkozások

1. Clockshin-Mellish: Programming in Prolog. Springer Verlag, Berlin, Heidelberg, New York, (1994).
2. ReALIS. Interpretálók a világban, világok az interpretálóban. Akadémiai Kiadó, Budapest, (2011).
3. Alberti Gábor-Kilián Imre: Vonatkeretlisták helyett polaritások hatásláncsaládok - avagy a ReALIS σ függvénye. VII. Magyar Számítógépes Nyelvészeti Konferencia, Tanács Attila-Vincze Veronika szerk. Szegedi Tudományegyetem, Informatikai Tanszékcsoport, Szeged, (2010). pp.113-127.
4. Kilián Imre: Contralog: egy előre haladó, Prolog-konform következtető motor, és alkalmazása ReALIS nyelvi elemzésre. SzámOkt 2011. konferencia kiadványa, Erdélyi Magyar Műszaki Tudományos Társaság, Kolozsvár, (2011)., pp. 199-205.
5. Nakashima, H.: Term Description: A Simple Powerful Extension to Prolog Data Structures Electrotechnical Laboratory, Umezono, 1-1-4, Ibaraki, Japan, (1985).