

Modelowanie treści sumeryjskich tekstów gospodarczych z epoki Ur III.


Wojciech Jaworski
Uniwersytet Warszawski

19 listopada 2007

Plan referatu

- 1 Język
- 2 Parsowanie
- 3 Zastosowania
- 4 Rozszerzenia

Starożytny Sumer w okresie Ur III



Korpus tekstów

- Archeolodzy odkopali ok. 100000 tabliczek pochodzących z czasów panowania trzeciej dynastii z Ur (2100p.n.e.-2000p.n.e.).
- Większość z nich zostało napisanych w przeciągu 40 lat i pochodzi z 4 miast.
- Urzędnicy królewscy dokumentowali na glinianych tabliczkach przekazywanie dóbr, składanie ofiar, opłacanie pracowników, bilanse produkcji w zakładach przemysłowych, wykonaną pracę, aprowizowanie wojska, diety podróżne itp.
- Około 43000 tekstów dostępnych jest w wersji elektronicznej w bazie danych Cuneiform Digital Library Initiative (CDLI) prowadzonej przez Uniwersytet Kalifornijski w Los Angeles i Instytut Historyczny im. Maxa Plancka w Berlinie.
- Tabliczki są przechowywane w bazie w postaci tekstowej w formie transliteracji w alfabecie łacińskim.
- Na potrzeby badań wybrałem korpus ok. 17000 dokumentów dotyczących dystrybucji zwierząt hodowlanych.

Tekst gospodarczy



Pismo: homonimia

- Jeden dźwięk może być zapisywany na różne sposoby, przyjmując różne znaczenia.
- Na przykład dźwięk *gu* miał czternaście odpowiadających mu znaków graficznych, m.in.



gu

len



gu2

szyja



gu3

głos



gu4

wół

Pismo: polifonia

Znak może być różnie czytany w zależności od kontekstu.



- główne odczyty: an, dingir, d
- pozostałe odczyty: a11?, am6, ana2, anu, dalhamunx, dibur, digir, dimer, /dimer/, dimir, dimmer, diner, dingira, dinir, dir3, el3, eszszu2, il3, ila, ili, ilu, le4, sa8, szubul, s, a3, usanx, za5
- dingir oznacza *bóg*
- d (skrót od dingir) jest determinatywem oznaczającym, że następne słowo jest imieniem bóstwa
- an to imię boga niebios (jest to jedyny bóg, którego imię jest pisane bez determinatywu)
- an oznacza *niebo, niebiański*
- an może być czytany fonetycznie jako sylaba *an*, wykorzystywany w zapisie afiksów gramatycznych i oraz słów (nazw własnych) pochodzenia pozasumeryjskiego.

Transliteracja



&P123831 = OIP 121, 101

@tablet

@obverse

1. 1(disz) sila4 ur-mes ensi2

2. 1(disz)# sila4 da-da dumu
lugal

3. 1(disz)# sila4 id-da-a

@reverse

1. u4 2(u) 3(asz@t)-kam

\$ 1 line blank

3. mu-DU

4. ab-ba-sa6-ga i3-dab5

5. iti sze-KIN-ku5


6. mu en dinanna ba-hun

@left

1. 3(disz)

Ontologia

- Diagram komponentów znaczeniowych.
- Relacje bycia częścią, bycia cechą.
- Ontologia jest domknięta za pomocą specjalnej kategorii zawierającej wszystkie obiekty nie mieszczące się w kategoriach przedstawionych na diagramie.



Język reprezentacji znaczenia

- Język reprezentacji znaczenia składa się ze stałych oraz predykatów, które są łączone ze sobą za pomocą alternatywy i koniunkcji.
- Nazwy predykatów są kategoriami ontologicznymi.
- Pierwszym argumentem predykatu jest stała reprezentująca obiekt należący do kategorii wyznaczonej przez predykat.
- Pozostałe argumenty są stałymi reprezentującymi części (cechy) obiektu.

Fraza

`ur-mes ensi2`

zapisana w języku reprezentacji znaczenia będzie miała postać

$$\text{Name-Job}(a_1, a_2, a_3) \wedge \text{Name}(a_2, a_4, a_5) \wedge \text{Job}(a_3, a_6) \wedge \text{JobName}(a_6, a_7) \wedge$$
$$\wedge \text{ur}(a_4) \wedge \text{mes}(a_5) \wedge \text{ensi2}(a_7).$$

Semantyka języka reprezentacji znaczenia

$$\text{Name-Job}(a_1, a_2, a_3) \wedge \text{Name}(a_2, a_4, a_5) \wedge \text{Job}(a_3, a_6) \wedge \text{JobName}(a_6, a_7) \wedge \\ \wedge \text{ur}(a_4) \wedge \text{mes}(a_5) \wedge \text{ensi2}(a_7)$$

- Predykaty definiują kategorię ontologiczną swojego pierwszego argumentu oraz wiążą pierwszy argument z pozostałymi za pomocą relacji bycia częścią, bądź opisem.
- Interpretacjami predykatów `ur`, `mes`, `ensi2` są sylaby lub wyrazy — elementy języka.
- Interpretacją predykatu `Name` jest zbiór imion rozumianych jako elementy języka.
- Interpretacją predykatu `JobName` jest zbiór nazw zawodów rozumianych jako elementy języka.
- Interpretacjami stałych są konkretne obiekty.

Plan referatu

1 Język

2 Parsowanie

3 Zastosowania

4 Rozszerzenia


Segmentacja

- Podział tekstu na znaki.
- Odróżnienie tekstu sumeryjskiego od oznaczeń edytorskich,
- Brak jednolitej konwencji oznaczania struktury i uszkodzeń tekstów. CDLI stopniowo ujednolica teksty.
- W wyniku segmentacji tekst może utracić strukturę listy

Tekst

{gesz}asalx(|A.TU.NIR|)!(A.TU) du3-a

po segmentacji ma postać grafu



Składnia dokumentów gospodarczych

- Niemal wszystkie słowa są rzeczownikami albo liczebnikami.
- Afiksy deklinacyjne i słowotwórcze niemalże nie występują, a sens tekstu jest wyznaczony przez kolejność fraz.
- Badania empiryczne wykazały, że język sumeryjskich tekstów gospodarczych jest regularny.
- Dokument gospodarczy jest pojedynczym zdaniem w szyku OSV, z bardzo rozbudowaną częścią O; zaopatrzonym w datę.

Schemat prostego pokwitowania

((Number Animal)+ Man)+ Day Receiver Month Year Summary.

Schemat miesięcznego zestawienia

((((Number Animal) + Man) + Summary Day) + SzuLagab
Receiver Month Year.

Gramatyka

- reguły gramatyczne mają postać

$$A \rightarrow \alpha_1, \dots, \alpha_n \quad A \rightarrow \beta +$$

gdzie $\alpha_1, \dots, \alpha_n, \beta$ są symbolami.

- Reguła $A \rightarrow \beta +$ jest równoważna zbiorowi reguł


$$A \rightarrow \beta, A \rightarrow \beta\beta, A \rightarrow \beta\beta\beta, \dots$$

- w gramatyce nie ma rekurencji
- Gramatyka jest semantyczna — większości symboli z gramatyki odpowiadają kategorie ontologiczne.
- Przykładowe reguły

Name	::=	ur mes
Name-Job	::=	Name Job
Name-Job	::=	Name
Name-Job	::=	Job
Number-Animal	::=	Number Animal
Number-AnimalList	::=	NumberAnimal +

Analizator składniowy: reprezentacja danych

- Częściowo zinterpretowany tekst reprezentujemy za pomocą skierowanego grafu acyklicznego, którego krawędzie etykietujemy symbolami z gramatyki.
- Graf ten będziemy nazywać *grafem rozbioru składniowego*.
- Parsowanie przebiega z dołu do góry.
- Aplikacja reguły polega na znalezieniu ścieżki w grafie i dodaniu do niego nowej krawędzi etykietowanej produkcją reguły.
- Gramatyka nie musi być kompletna.



Wieloznaczność

- Wieloznaczność wynikająca z niewiedzy:

`zabar-dab5.`

- Wieloznaczność wynikająca ze skrótego zapisu:

`mu en {d}inanna.`

- Wieloznaczność wynikająca z braku nawiasowania:

`NAList Man NAList Man Middleman NAList Man Middleman.`

Możliwe są dwie interpretacje:

`(NAList Man NAList Man) Middleman NAList Man Middleman,`


`NAList Man (NAList Man Middleman) NAList Man Middleman.`

Wieloznaczność


- Wieloznaczność wynikająca z braku znaków rozdzielających słowa

1(disz) sila4 ga ga mu

ga-ga-mu i ga-mu to imiona, a ga jest określeniem zwierzęcia.
NumberAnimalName można uzyskać na dwa sposoby.




Analiza semantyczna




- Formuły języka reprezentacji znaczenia powiązane są z grafem rozbioru składniowego.
- Pozwala to w zwarty sposób zapamiętać treść niejednoznacznych dokumentów.

Analiza semantyczna



- Formuły języka reprezentacji znaczenia powiązane są z grafem rozbioru składniowego.
- Pozwala to w zwarty sposób zapamiętać treść niejednoznacznych dokumentów.

Analiza semantyczna




- Z każdym symbolem gramatyki wiążemy zbiór predykatów.
- Zbiór przypisany do symbolu utworzonego podczas segmentacji zawiera jeden jednoargumentowy predykat.
- Nazwa predykatu jest tożsama z nazwą symbolu.
- Semantyka krawędzi grafu


$$\llbracket ga \rrbracket_{3,4} = ga(a_{ga,3,4})$$

- Argument predykatu jest stałą, której indeksy identyfikują krawędź grafu.

Analiza semantyczna



- Formuły języka reprezentacji znaczenia powiązane są z grafem rozbioru składniowego.
- Pozwala to w zwarty sposób zapamiętać treść niejednoznacznych dokumentów.




- Postać predykatu utworzonego w wyniku parsowania określa reguła semantyczną przypisaną do reguły gramatycznej.
- Indeksy stałych wiążą ze sobą predykaty

$$\begin{aligned} \llbracket \text{Name} \rrbracket_{4,6} &= \text{Name}(a_{\text{Name},4,6}, a_{\text{ga},4,5}, a_{\text{mu},5,6}) \wedge \llbracket \text{ga} \rrbracket_{4,5} \wedge \llbracket \text{mu} \rrbracket_{5,6} = \\ &= \text{Name}(a_{\text{Name},4,6}, a_{\text{ga},4,5}, a_{\text{mu},5,6}) \wedge \text{ga}(a_{\text{ga},4,5}) \wedge \text{mu}(a_{\text{mu},5,6}) \end{aligned}$$

- Powiązanie to odpowiada relacji bycia częścią lub bycia opisem.
- Odniesienie przedmiotowe stałej jest tożsame z odniesieniem przedmiotowym frazy wskazywanej przez indeksy stałej.

Analiza semantyczna



- Formuły języka reprezentacji znaczenia powiązane są z grafem rozbioru składniowego.
- Pozwala to w zwarty sposób zapamiętać treść niejednoznacznych dokumentów.

$$\begin{aligned} &\{ \text{NumberAnimalName}(a_{\text{NumberAnimalName},1,6}, a_{\text{NumberAnimal},1,3}, a_{\text{Name},3,6}), \\ &\quad \text{NumberAnimalName}(a_{\text{NumberAnimalName},1,6}, a_{\text{NumberAnimal},1,4}, a_{\text{Name},4,6}) \} \\ &\quad \text{NumberAnimalName} \end{aligned}$$


- Semantyka krawędzi mającej dwa znaczenia

$$\begin{aligned} \llbracket \text{NumberAnimalName} \rrbracket_{1,6} = & \left(\text{NumberAnimalName}(a_{\text{NumberAnimalName},1,6}, a_{\text{NumberAnimal},1,3}, a_{\text{Name},3,6}) \wedge \right. \\ & \left. \wedge \llbracket \text{NumberAnimal} \rrbracket_{1,3} \wedge \llbracket \text{Name} \rrbracket_{3,6} \right) \vee \left(\right. \\ & \text{NumberAnimalName}(a_{\text{NumberAnimalName},1,6}, a_{\text{NumberAnimal},1,4}, a_{\text{Name},4,6}) \wedge \\ & \left. \wedge \llbracket \text{NumberAnimal} \rrbracket_{1,4} \wedge \llbracket \text{Name} \rrbracket_{4,6} \right) \end{aligned}$$

- Stała $a_{\text{NumberAnimalName},1,6}$ identyfikuje oba znaczenia.

Gramatyka semantyczna korpusu tekstów gospodarczych

- Semantyka jest konstruowana w sposób *kompozycyjalny*, tzn. reguły semantyczne są związane z regułami składniowymi.
- Aplikacja reguły składniowej pociąga za sobą aplikację przypisanej do niej reguły semantycznej, która z semantyk symboli rozpoznanych przez regułę konstruuje semantykę produkcji reguły.
- Gramatyka zawiera 3427 reguł (3 akumulacyjne).
- Z 3055 tabliczek parser wygenerował formułę logiczną mającą 271499 stałych (Liczba stałych jest równa sumie ilości krawędzi grafów rozbioru składniowego).

Typy reguł

- Reguły pełniące rolę leksykonu (1724)

$\text{Name} ::= \text{ur mes Name}(\text{var}_{\text{Name}}, \text{var}_{\text{ur}}, \text{var}_{\text{mes}})$

- Reguły opisujące strukturę tekstu (241)

$\text{Name-Job} ::= \text{Name Job Name-Job}(\text{var}_{\text{Name-Job}}, \text{var}_{\text{Name}}, \text{var}_{\text{Job}})$

$\text{Name-Job} ::= \text{Name Name-Job}(\text{var}_{\text{Name-Job}}, \text{var}_{\text{Name}})$

$\text{Name-Job} ::= \text{Job Name-Job}(\text{var}_{\text{Name-Job}}, \text{var}_{\text{Job}})$

- Reguły wprowadzające wiedzę dziedzinową (liczby, określenia roczne itp) w tych regułach są zawarte algorytmy (1459)

$\text{YearGod} ::= \text{d inanna} \{ \text{AS04}(\text{var}_{\text{YearGod}}), \text{AS05}(\text{var}_{\text{YearGod}}) \}$

$\text{Year} ::= \text{mu en YearGod Verb} \{ p(\text{var}_{\text{Year}}) : p \in \text{val}_{\text{YearGod}} \cap \text{val}_{\text{Verb}} \}$

- var_{Name} jest zmienną, której indeksem jest krawędź grafu związana z symbolem Name
- $\text{val}_{\text{YearGod}}$ jest zbiorem nazw predykatów związanych z symbolem YearGod.

Plan referatu

1 Język

2 Parsowanie

3 Zastosowania

4 Rozszerzenia

Wyszukiwanie tekstów w korpusie

- Wyszukiwanie tekstów zawierających dany ciąg odczytów znaków.
- Wyszukiwanie tekstów zawierających dany ciąg znaków.
- Wyszukiwanie tekstów wg. wzorca semantycznego: znajdowanie tekstów, które posiadają frazę o zadanym znaczeniu.

Model gospodarki sumeryjskiej

- Podział tekstów na transakcje, zbudowanie na ich podstawie modelu gospodarki sumeryjskiej

Data	Ilość	Towar	Dostawca	Odbiorca
23-11-AS05	1	sila4	ur-mes ensi2	ab-ba-sa6-ga
23-11-AS05	1	sila4	da-da dumu lugal	ab-ba-sa6-ga
23-11-AS05	1	sila4	id-da-a	ab-ba-sa6-ga

- Prosopographia, czyli ustalenie tożsamości osobowej urzędników sumeryjskich.
- Sklasyfikowanie typów dokumentów generowanych przez administrację sumeryjską.

Model gospodarki sumeryjskiej

P122592	1 sila4 niga	ab-ba-sa6-ga	lu2-dingir-ra	2	4 AS02
P124900	2 ab2 mu-2	ab-ba-sa6-ga	xxx	2	4 AS02
P124900	3 sila4	ab-ba-sa6-ga	xxx	2	4 AS02
P102183	4 udu niga	ab-ba-sa6-ga	na-lu5	4	4 AS02
P131562	4 udu niga	ab-ba-sa6-ga	na-lu5	4	4 AS02
P128138	2 amar masz-da3	ab-ba-sa6-ga	lu2-dingir-ra dumu ARAD2-hul3-la	6	4 AS02
P130395	2 gu4	ab-ba-sa6-ga	xxx	8	4 AS02
P130395	3 ab2	ab-ba-sa6-ga	xxx	8	4 AS02
P103081	1 udu niga	ab-ba-sa6-ga	lu2-dingir-ra	9	4 AS02
P128809	2 munus-asz2-gar3	ab-ba-sa6-ga	na-lu5	11	4 AS02
P131562	2 munus-asz2-gar3	ab-ba-sa6-ga	na-lu5	11	4 AS02
P128809	4 udu niga	ab-ba-sa6-ga	na-lu5	11	4 AS02
P131562	4 udu niga	ab-ba-sa6-ga	na-lu5	11	4 AS02
P131562	3 udu	ab-ba-sa6-ga	na-lu5	12	4 AS02
P131562	16 udu niga	ab-ba-sa6-ga	na-lu5	12	4 AS02
P131562	1 munus-asz2-gar3	ab-ba-sa6-ga	na-lu5	13	4 AS02
P131562	1 sila4	ab-ba-sa6-ga	na-lu5	13	4 AS02
P131562	1 u8 niga	ab-ba-sa6-ga	na-lu5	21	4 AS02
P131562	1 sila4	ab-ba-sa6-ga	na-lu5	21	4 AS02
P131562	1 munus-asz2-gar3	ab-ba-sa6-ga	na-lu5	21	4 AS02
P131562	3 masz2	ab-ba-sa6-ga	na-lu5	21	4 AS02
P131562	3 sila4	ab-ba-sa6-ga	na-lu5	21	4 AS02
P103866	4 udu niga	ab-ba-sa6-ga	na-lu5	21	4 AS02
P131562	6 udu niga	ab-ba-sa6-ga	na-lu5	21	4 AS02
P131562	4 masz2	ab-ba-sa6-ga	na-lu5	22	4 AS02
P131562	1 sila4 niga	ab-ba-sa6-ga	na-lu5	22	4 AS02
P131562	1 sila4	ab-ba-sa6-ga	na-lu5	22	4 AS02
P130511	1 masz2	PU3.SZA -ha-ni lu2-kas4 ab-ba-sa6-ga		23	4 AS02
P136299	4 masz2	ab-ba-sa6-ga	xxx	28	4 AS02
P131562	5 gukkal	ab-ba-sa6-ga	na-lu5	29	4 AS02
P103020	5 gukkal	ab-ba-sa6-ga	na-lu5	29	4 AS02
P103020	1 u8 a-lum	ab-ba-sa6-ga	na-lu5	29	4 AS02
P131562	1 u8 a-lum-masz2	ab-ba-sa6-ga	na-lu5	29	4 AS02
P103020	2 udu a-lum	ab-ba-sa6-ga	na-lu5	29	4 AS02
P131562	2 udu a-lum-udu	ab-ba-sa6-ga	na-lu5	29	4 AS02
P103020	1 munus-asz2-gar3 niga	ab-ba-sa6-ga	na-lu5	29	4 AS02
P131562	1 munus-asz2-gar3 niga	ab-ba-sa6-ga	na-lu5	29	4 AS02
P103020	2 udu	ab-ba-sa6-ga	na-lu5	29	4 AS02
P103020	2 masz2	ab-ba-sa6-ga	na-lu5	29	4 AS02
P128097	2 masz-da3	ab-ba-sa6-ga	lu2-dingir-ra dumu ARAD2-hul3	29	4 AS02
P106179	200 udu	na-ra-am-i3-#i2	ur-(dj)-lamma ensi2 gir2-su-[ki]	xxx	4 AS02
P106179	8 gu4	na-ra-am-i3-#i2	ur-(dj)-lamma ensi2 gir2-su-[ki]	xxx	4 AS02
P106179	2 ab2	na-ra-am-i3-#i2	ur-(dj)-lamma ensi2 gir2-su-[ki]	xxx	4 AS02
P126015	6 udu szimaszki niga	ab-ba-sa6-ga	xxx	xxx	4 AS02

Plan referatu

- 1 Język
- 2 Parsowanie
- 3 Zastosowania
- 4 Rozszerzenia

Niewiedza

- Bogactwo języka naturalnego powoduje, że treść pewne liczby fraz nie daje się wyrazić za pomocą powszechnie występujących kategorii ontologicznych.
- Frazy te są rzadkie, nieregularne i pozbawione charakterystycznych kontekstów.
- Jest ich zbyt dużo, by je przejrzeć i dodać do ontologii pojęcia w nich zawarte.
- Aby parsować częściowo niezrozumiałe teksty domykam gramatykę i ontologię wprowadzając kategorię 'nieznane'.
- Początek i koniec nieznanej frazy określam uznając, że każda nieznana fraza zajmuje jeden wers (Koniec wersu jest końcem słowa, zwykle też końcem frazy).
- Otrzymuję system zdolny sparsować tekst niezależnie swojej znajomości języka.
- Stan zrozumienia decyduje o ilości informacji z niego wydobytych.

- Semantyka produkcji reguły akumulacyjnej jest grafem, którego wierzchołkami są zmienne wskazujące na semantyki symboli rozpoznanych przez tą regułę, a każda jego ścieżka jest możliwą semantyką produkcji reguły.
- Formułą dla grafu struktury logicznej symbolu akumulacyjnego jest alternatywa po wszystkich ścieżkach grafu predykatów, których argumentami są zmienne zawarte w danej ścieżce.

Techniki analizy uszkodzeń:

- Uznawanie uszkodzonych wersów jako nieznanych.
- Interpretacja poszczególnych nieczytelnych znaków jako symboli, do których parser może dopasować dowolny symbol.
- Zastąpienie uszkodzonego wersu przez listę wersów typowych.

- Analizator składniowy jest podobny do parserów tablicowych.
- Podobnie jak one reprezentuje tekst za pomocą grafu skierowanego acyklicznego.
- Różnica polega na dostosowaniu mojego parsera do języków regularnych (z rozszerzeniem na bezkontekstowe mogą być problemy wydajnościowe) oraz dostosowaniu do korzystania z niekompletnych gramatyk, co ułatwia uczenie.