Vybrané aktuální projekty Laboratoře NLP

Vašek Němčík, Zuzana Nevěřilová

E-mail: xnemcik@fi.muni.cz,xpopelk@fi.muni.cz
http://nlp.fi.muni.cz/poc_lingv/

Obsah:

- Saara – systém na určování anafor
- X-plain – hra, která sbírá Common Sense

Gracie: Minulý týden byl můj bratr vyšetřovat vraždu a představ si, našel toho chlapa za hodinu.
George: Našel za hodinu vraha?
Gracie: Ne, *toho chlapa, co ho zabili*.
George: Tvůj bratr je nejen vysoký, ale i rychlý.
Gracie: No, před časem měli pan a paní Jonesovi manželskou krizi a můj bratr byl najat, aby sledoval paní Jonesovou.
George: No, je to nepochybně moc atraktivní žena.
Gracie: To je – a můj bratr ji sledoval ve dne v noci, půl roku.
George: A jak to skončilo?
Gracie: Požádala o rozvod.
George: Paní Jonesová?
Gracie: Ne, *žena mého bratra*.
(George Burns a Gracie Allen: "The Salesgirl")

Úvod

- text/**diskurs** – jednotka jazykové komunikace větší než:
- věta/**výpověď** – minimální obsahově úplná jednotka

věta	**výpověď**
langue	parole (de Saussure)
competence	performance (Chomsky)
produkt	*proces*
struktura	*chování*
nedůležité kdy/kde/jak	*podmínky/okolnosti/způsob*

- referenční výrazy
- reference (odkazování)
  jazykový výraz $\longmapsto$ mimojazyková entita

Reference

- **exofora** (vnější reference)
  výraz odkazuje k entitě ve světě přímo
  "Slunce", "Alpy", "Václav Havel", "ty schody před FI"
  - deixe – odkazování k entitám v rámci komunikační situace
    (gesta, "tady", "teď", "tamto", . . .)
- **endofora** (vnitřní reference)
  entita je určena na základě vztahu k jinému výrazu v diskursu
  (nejen mimojazykový, ale i jazykový kontext . . .)
  - anafora – výraz se vztahuje k výrazu dříve v textu
  - katafora – výraz se vztahuje k výrazu dále v textu
    méně častá; vysktuje se v beletrii (zvyšuje napětí):
    "Ranní světlo ho probudilo už v pět. Rychle se oblékl a nasnídal. Detektiv Jones věděl, že nemůže ztrácet čas."

Anafora

- **anafora** (anaphor) – anaforický výraz (× Chomsky)
  - zejména zájmena, ale i "ten muž", ...
- **antecedent** – předcházející výraz, ke kterému se anafora vztahuje
- **anafora** (anaphora) – anaforická reference (jev)
- **anaphora resolution** – určování anaforických vztahů (hledání vztahů mezi anaforami a antecedenty)

Příklady:

- **[Petr]**$_i$ snědl **[koláč]**$_j$.
  [(on)]$_i$ Byl hladový a **[ten koláč]**$_j$ vypadal lahodně.
- **[Venus]**$_i$ rose at 0930, but I didn't see **[the thing]**$_i$.
- **[Jones]**$_i$ offered **[[his]**$_i$ **furniture]**$_j$ for sale, but nobody wanted **[the stuff]**$_j$.

Lze udělat úkrok stranou?

- Můžeme se tomu všemu vyhnout, třeba používáním jen přímé reference?
- Nemuseli bychom se zabývat kontextem ...

NE. Z mnoha vážných důvodů:

- Lidé jsou líní.
  - anafory jsou krátké a snadno se používají
  - patrně vlastní lidské komunikaci (ve všech jazycích!)
- diskurs není libovolná sekvence výpovědí
  - koherence – sémantická návaznost
  - kohese – gramatické a lexikální vztahy

  $\rightsquigarrow$ anaforické vztahy drží text pohromadě (umožňují nám se držet zamýšleného toku myšlenek)

Ilustrační příklad

[Jarda]$_i$ si koupil Porsche. **(On)**$_i$ Rád jezdí rychle.
[Jarda]$_i$ si koupil Porsche. **[Jarda]**$_{*i,j}$ rád jezdí rychle.

$\rightsquigarrow$ delší/složitější věta zní divně (nutí k zamyšlení)

- **Kooperační princip** (Grice)
  Komunikační maximy:
  - kvality
  - relevance
  - kvantity
  - způsobu
- Posluchač předpokládá, že se jimi mluvčí řídí.
- Když ne, má to hlubší důvody.

- více o pragmatice v "IA091 Sémantika a komunikace"

Proč to učit počítače?

- zásadní úzké hrdlo mnoha NLP aplikací
- **Information Extraction**
  - **[Václav Havel]** is a Czech writer and dramatist.
    [He] was the ninth and last President of Czechoslovakia
    and the first President of the Czech Republic. *(Wikipedia)*

  - "the best doctor in Europe" $\longrightarrow$ Google

    Letters from Asia addressed loosely to The Best Doctor in Europe arrived on **[his]** doorstep.

    [His] own reputation as the best doctor in Europe couldn't save **[him]** from the tragedies of **[his]** life.

- Bez AR nenajdeme to, co hledáme.
  Pouze anaforické výrazy (které jsou samy o sobě prázdné).

Proč to učit počítače?

- **Strojový překlad**
- CZ ↦ EN
  [Sestřička] mu dala **[pilulku]**. Spolkl **[ji]** a do minuty usnul.
  [The nurse] gave him a pill. He swallowed **[her]** and fell asleep in a minute.
- DE ↦ EN
  Ich suche **[meine Uhr]**. Ich kann **[sie]** nirgendwo finden.
  I am looking for **[my watch]**. I can't find **[her]** anywhere.

- nelze překládat přímo (různé gramatické kategorie)
- navíc: různé vlastnosti anafor

Definice úlohy

- nalézt anaforické výrazy v textu
- určit k nim antecedenty
- určit typ vztahu
  - koreference
    (dva výrazy se odkazují ke stejnému promluvoému objektu)
  - bridging (asociativní/nepřimá anaphora)
    (jakákoliv sémantická relace)
    - hyperonymie/hyponymie
      "Nábytek je drahý. Židle jsou nejdražší."
    - část/celek
      "Každý majitel bytu se snaží zabezpečit vchodové dveře."
    - entita/vlastnost
      "Pepa má nové auto. Barvu určitě vybírala jeho žena."
    - příčina/následek
      "Včera tu byl požár. Kouř je tu stále cítit."

Typy anafor

- **textová** vs. **gramatická**
  [Ben] takes a photo of **[himself]** every day.
- **pronominální** (pro NLP asi nejrelevantnější)
- **nominální**
  Od září bude do **[Brna]** létat nová letecká linka. Očekává se, že přinese **[druhému největšímu městu ČR]** nové turisty.
- **slovesná**
  John likes cats. So does Bill.
- **one-anaphora**
  John has a black Porsche. I would like one too.
- **nulová (zero) anafora**
  anafora není povrchově realisována
  v češtině (a ostatních pro-drop jazycích) nevyjádřené podměty

Typy pronominálních anafor

- osobní zájmena
  - silná: “jemu”, “on”, “ona”
  - slabá: “mu”, “ho” (klitika)
  - nulová: ∅
- demonstrativní zájmena: “ten”, “ta”, “tomu”
- reflexivní zájmena: “se”, “sebe”, “svůj”
- posesivní zájmena: “jeho”, “jejího”
- relativní zájmena: “který”, “jenž”

ALE jsou i neanaforická zájmena:

- deixe: “to”
- expletivní/pleonastická zájmena:
  It’s raining. / Es regnet.
  It is the first chapter, I enjoy the most.
  Zdá se, že tu někdo byl.

Znalosti potřebné pro AR

- **morfologie**
  - shoda v Φ-atributech (závislé na jazyce)
  - čeština: osoba, číslo, rod
  - angličina: pouze sémantický rod
    ⇒ nutnost mít informaci jméno ↦ rod
- **syntax**
  - posice anafory/antecedentu v syntaktické struktuře věty
  - paralelismus
    tendence k zachování stejných syntaktických rolí:
    [Mary] met **[Lucy]** at the bus station.
    [She] asked **[her]** about the new neighbour.
- **pragmatika**
  - Griceův kooperační princip ...
  - komunikační situace + kontext
  - scénáře

Sémantika a znalosti o světě

- hraje při interpretaci anafor často rozhodující roli
- sémantická plausibilita zvyšuje/snižuje pravděpodobnost některé interpretace, některé lze zcela vyloučit

  After the [bartender] served [the patron], [he] got a big tip. After the [bartender] served [the patron], [he] left a big tip.
- iniciální interpretace (hned)
- pokud pozdější informace vedou ke sporu:
  reinterpretace (backtracking)
- **garden-path effect**
- význam slov
- znalosti o světě
- inference

Sémantika a znalosti o světě

- If the baby does not thrive on raw milk, boil it.
- The FBI's role is to ensure our country's freedom and be ever watchful of those who threaten it.
- Stehlíková ustoupila od sbírky. Romové o ni nestojí.
- Klaus dostal dopis podepsaný Aničkou. Má ho policie.
- A: I ve Veselé vačici by mohla být volná místa.
  B: Jé, tam jsem ještě nebyla. Slyšela jsem, že tam chodí studenti. A že prý dobře vaří.
- 'I said disarm only!' Lockhart shouted in alarm over the heads of the battling crowd, as Malfoy sank to his knees; Harry had hit him with a Tickling Charm, and he could barely move for laughing.
  (J. Rowling: Harry Potter and the Chamber of Secrets)

Sémantika a znalosti o světě

- Genau so sei es ihm vorgekommen, sagte Gauss, schlief ein und wachte bis zum abendlichen Pferdewechsel an der Grenzstation nicht mehr auf. Während die alten Pferde ab- und neue angeschirrt wurden, assen sie Kartoffelsuppe in einer Gastwirtschaft.
  (Daniel Kehlmann: "Die Vermessung der Welt: Die Reise")

- všechny tyto znalosti je obtížné shromáždit
- i kdyby byly k disposici, bylo by obtížné v nich hledat

- AR je považováno za **"AI-úplný problém"**
  AR je stejně obtížný problém jako naučit počítače myslet.

  $\Rightarrow$ nutno si úkol zúžit

Teoretické problémy

- John loves his wife. So does Bill.
- The man who gave his **[paycheque]** to his wife was wiser than the man who gave **[it]** to his mistress.
- If any man owns **[a donkey]**, he beats **[it]**.
- **[No one]** will be admitted to the examination, unless **[he]** has registered four weeks in advance.
- [The man who shows he deserves **[it]**] will get [the prize **[he]** desires].

AR algoritmy

- heuristická pravidla (70. léta)
  - SHRDLU – "block world" Terryho Windograda
  - Hobbsovo syntaktické hledání
  - jednoduchá pravidla, vzory, časté instance
- sématické teorie
  - centering, focusing – modelování lokální koherence
  - BFP algoritmus
  - výpočetně problematické
- knowledge-poor (90. léta)
  - kacířství motivované praktickými potřebami
  - založené na datech, která lze dostatečně úspěšně spočítat (morfologie, povrchová syntax, jednoduché sémantické třídy)
  - RAP – váhování
  - CoGNIAC (pouze 6 pravidel – vysoká přesnost, malé pokrytí)
  - MARS – váhování

AR a strojové učení

- statistika a strojové učení dnes v NLP převažují
- AR není klasifikační problém

předefinování umožňující použití std. ML metod:

- **1 instance**: dvojice anafora-antecedent
- **atributy**: knowledge-poor informace
- **cílový atribut**: 1 pro koreferentní dvojici, jinak 0
- velký nepoměr negativních a positivních instancí
- nutno část negativních instancí odstranit z trénovacích dat

AR a čeština

- mnoho teoretických prací (FGP: Sgall, Hajičová)
- PDT 2.0 – velký ručně anotovaný korpus, 3 roviny
- anotace pronominání koreference
- implementace:
  Zdeněk Žabokrtský, Nguy Giang Linh
- pouze v rámci formalismu PDT 2.0

- **Saara**
- modulární
- různé algoritmy, formáty dat, pre-processing
- možnost férového porovnání algoritmů

Saara

- roviny abstrakce:
  - technická rovina
    různé formalismy/formáty dat $\mapsto$ několik obecných metod
  - "markable" rovina
    definuje AR algoritmy
    metody + "markables" jejich vlastnosti
  - "supervisor"
    definuje, který preprocessing/algoritmus se použije
- "markable"
  - jakákoliv jednotka složená z jednodušších jednotek
  - možno definovat různé roviny
  - slova $\mapsto$ klause
  - slova $\mapsto$ referenční výrazy
  - atributy
  - vztahy mezi markables $\rightsquigarrow$ koreferenční třídy
  - MMAX 2

Saara

- načtění dokumentu
- pre-processing
  - rozdělení vět do klausí
  - detekce nevyjádřených subjektů
  - model diskursu – detekce markables
- AR $\rightsquigarrow$ koreferenční třídy
- výstup: MMAX2 XML

Hobbs syntactic search

- jako syntaktickou strukturu předpokládá frázové stromy
- X-bar theory (Chomsky, Jackendoff)
  X – complement – X' – adjunct – X' – specifier – XP
- algoritmus je definován jako procházení stromu
- začíná se v listu dané anafory
- podle kategorie aktuálního uzlu se volí další cesta
- prominentnější posice jsou procházeny dříve
- lze adaptovat na jiné formalismy
- jednoduché, ale nefunguje špatně

BFP algoritmus

- každá výpověď:
  - forward-looking centers (setříděné)
  - preferred center (ten nejvýše postavený)
  - backward-looking center
- formulována 2 jednoduchá pravidla, neformálně:
- preferováno je odkazování zájmeny
- preferováno je zachovávání backward-looking center
- počítají se různé kombinace a filtrují se ty, které nevyhovují pravidlům

RAP

- identifikace NP, filtrování nereferenčních, reflexiva atd.
- přidělí se iniciální váhy kandidátům (součet)
- při hledání antecedentu ke konkrétní anafoře se pro danou kombinaci váhy dále upravují (katafora, paralelismus, . . .)
- antecedentem je kandidát s nejvyšší vahou
- při zpracovávání nové věty se všechny váhy podělí dvěma

Factor type	*Initial weight*
Sentence recency	100
Subject emphasis	80
Existential emphasis	70
Accusative emphasis	50
Indirect object and oblique complement emphasis	40
Head noun emphasis	80
Non-adverbial emphasis	50

Pražské algoritmy

- hned několik algoritmů
- formulovány “na papíře”
- vyhodnocovány ručně
- jako RAP také váhovací princip
- modeluje aktivaci objektu v mysli posluchače
- zohledňuje se informace o AČV
- teoreticky logické, ale prakticky nepotvrzené

Gracie: Last week my brother went out on a murder case, and you know, he found that man in an hour.
George: He found the murderer in an hour?
Gracie: No, *the man who was killed*.
George: Not only is your brother tall, but he's fast.
Gracie: And then Mr. & Mrs. Jones were having matrimonial trouble, and my brother was hired to watch Mrs. Jones.
George: Well, I imagine she was a very attractive woman.
Gracie: She was, and my brother watched her day and night for six months.
George: Well, what happened?
Gracie: She finally got a divorce.
George: Mrs. Jones?
Gracie: No, *my brother's wife*.
(George Burns and Gracie Allen in "The Salesgirl")

Úvodem

> *"People have silly reasons why computers don't really think. The answer is we haven't programmed them right; they just don't have much common sense"*
>
> – Marvin Minsky

Zpracování přirozeného jazyka

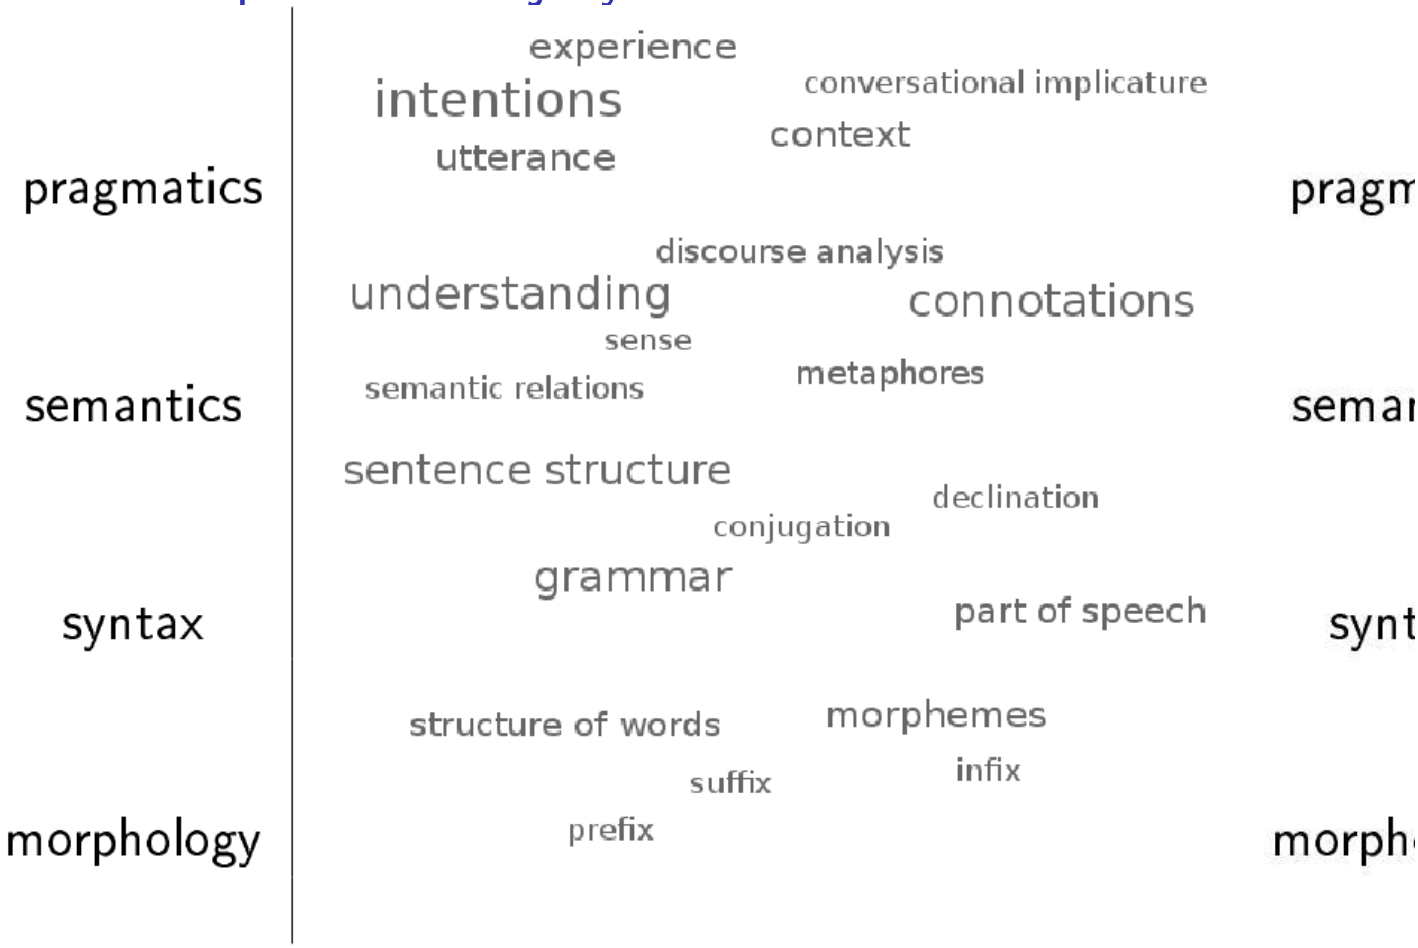

Common sense

> *„znalosti a zkušenosti, které většina lidí má, nebo se věří, že má, nebo by měla mít“*

česky: přirozený lidský rozum, prostý, zdravý rozum, selský rozum, praktické uvažování

> *„obrovská množina procesů přirozeného poznání a systém domněnek, které (všichni) lidé sdílejí“*

česky: common sense ;-)

Common sense – kde najít?

V encyklopediích?

> *matted or felted sheet, usually made of cellulose fibres, formed on a wire screen from water suspension.*
>
> – Encyclopædia Britannica

> *a thin substance made from any of a variety of fibrous materials, used for writing, wrapping, decorating walls, and the like.*
>
> – Wordsmyth

Common sense – v korpusu?

investičních fondech, o burze cenných	**papírů**	, zákon směnečný a šekový, o dluhopisech
vynikajícím tiskem na kvalitním křídovém	**papíře**	. Stal se ideálním prostředkem pro prezentaci
zareagoval, se slovem v éteru (s popsaným	**papírem**	, s obrazovkou) se těžko bojuje. A navíc
pohybovat ve světě makléřů a cenných	**papírů**	. Umělecky založené návštěvníky naláká
ulicí v Praze, pět domů ve Vídni a cenné	**papíry**	v hodnotě asi 2 miliony korun). Hybnou
tisku, o privatizaci ČTK, o nové ceny	**papíru**	atd. ...k dneškuStejně jako se
své reklamní předměty z recyklovaného	**papíru**	. Stejně dobře zapůsobí, koresponduje
vstupu do sídla firmy, přes hlavičkové	**papíry**	, vizitky, tištěné materiály až po
dodávky kopírek, dodává kancelářský	**papír**	všeho druhu, tonery pro kopírky a laserové
třeba že jsem dlouho odvykal tužce a	**papíru**	a psacímu stroji, je dnes počítač pro
zbastlená po domácku, na kancelářském	**papíru**	nebo fotopapíru. Pérovky, fotografie,
nevylučuje kýč, (viz obr. d) - a tužší	**papír**	: možná proto, že z 18 kousků jde až
se však barvitosti dosahuje tónováním	**papíru**	), 3 kousky jsou tištěny dvoubarevně,
480X360 pixelů) Půdorysy, pohledy, řezy na	**papíře**	ve formátu max. A3 Aspoň 5, avšak ne
spíše elementárním pojmům, jako je	**papír**	, tužka, štětec, hlína a podobně. Dobře
ochrannou mříž spatříme záplavu odpadků,	**papíru**	, slupky od banánů... Rudolfova štola
ıledání. Notes je něčím mezi listem	**papíru**	a dnešním laptopem. Příkladem je prototyp
Je to prostě poznámkový blok nebo list	**papíru**	položený na stole, kde je k dispozici
schůze. Podobně jako konceptní papí r i	**papíry**	elektronické můžete rozprostřít na
počítače. Jednou budou elektronické listy	**papíru**	tenké téměř jako listy skutečného

Common sense – specializované kolekce

- CyC – tvořeno experty od r. 1984

```
(#$isa #$BillClinton #$UnitedStatesPresident)
```

- Thought Treasure – od r. 1993, v r. 2000 vývoj ukončen

```
[product-of Intel-8080 Intel]
(An Intel 8080 is a product of Intel.)
```

- OpenMind – tvořeno průběžně uživateli, od r. 1999

```
"The sun is very hot"
```


X-plain – další způsob, jak sbírat common sense

hra, podobná Kufru nebo Aktivitám
hráči = přispěvatelé do databáze common sense

X-plain – pravidla

kooperativní hra pro 1 člověka a počítač
vypravěč, hadač a tajné slovo
vypravěč vysvětluje tajné slovo, hadač zkouší hádat
časový limit je 3 minuty

X-plain – ukázka

X-plain a common sense

trojice: subjekt – relace – objekt,
kde

- subjekt je tajné slovo
- relace je použitá relace
- objekt je nápověda

X-plain a common sense

sport	can_be_likely_found	hřiště
sport	can_have_property	bojový
sport	is_related_to	pohyb
sport	is_the_opposite_of	lenošení
sport	is_used_for	udržení kondice
fanoušek	is_part_of	sport
hra	can_be_used_for	sport
sportovec	has_part	sport
trofej	is_used_for	sport
fanoušek	is_related_to	sport
fanoušek	is_for	sport
areál	is_for	sport
fanoušek	can_be_likely_found	tribuna

X-plain – jak je to udělané?

- trojice se ukládají do MySQL, počítač používá data z MySQL + Sketch Engine
- aplikační logika: PHP + JavaScript + AJAX[1]
- běží ve webovém prohlížeči

[1] Asynchronous JavaScript and XML

X-plain – no, dobře, ale jak je to udělané?

papír preloaded/czes freq = 93440

a_modifier	59603	2.8
cenný	33859	13.18
balící	1483	9.61
toaletní	1029	8.96
fotografický	580	8.0
křídový	438	7.89
běžný	1883	7.74
hlavičkový	383	7.68
depilační	361	7.61
ruční	612	7.57
zaknihovaný	331	7.49
dluhový	328	7.46
recyklovaný	291	7.29
brusný	274	7.18
účastnický	351	7.08
novinový	263	7.07
smirkový	242	7.05
kancelářský	424	7.01
listinný	232	6.94
obchodovatelný	202	6.77
pečící	187	6.66
čistý	438	6.61
lesklý	190	6.54
balicí	170	6.53
obchodovaný	168	6.48
sběrový	162	6.47

prec_s	7769	9.9
obchodník	3419	10.92
obchodování	1090	9.94
manipulace	390	8.14
potápěč	105	7.99
obchodovat	100	7.45
transakce	131	6.67
obchod	1101	6.54
operace	207	5.93
plech	31	5.53
velkoobchod	14	5.03
trh	521	4.97
kombinace	70	4.6
podvod	21	4.48
kontrakt	20	4.16
tužka	7	4.02
nakládání	11	3.75
spekulace	9	3.34
zacházení	7	3.29
burza	9	2.48
držák	10	2.1
vzor	7	2.1
práce	73	1.67
pracovat	24	1.45

prec_pro	3484	6.3
komise	3113	8.86
Komis	15	7.12
černé	14	5.59
úřad	222	3.87
středisko	7	0.23

prec_pomocí	61	3.2
zbroušení	48	13.05

prec_na	5508	3.1
kapička	158	9.19
toner	160	9.11
páska	168	7.96
zásobník	165	7.73
tisknout	165	7.67
kontejner	99	7.29
tužka	42	6.85
natisknout	19	6.71
vystřelovat	19	6.56
inkoust	27	6.34
tisk	329	6.12
rozmnožení	14	6.09
psát	356	6.07
nakreslit	21	6.03
fax	31	5.86
kreslení	17	5.8
přenést	50	5.73
vytisknout	108	5.65
čmárat	8	5.49
kopírování	24	5.47
poklepávat	7	5.31
potisk	13	5.23
akreditace	14	5.11
kresba	25	5.01
hodit	46	4.97

post_pro	1548	2.8
velk	507	12.79
laser	575	10.19
snížení	67	4.7
tisk	100	4.44
podávání	8	4.15
tiskárna	22	3.32
médium	20	2.37
potřeba	12	0.68
kancelář	8	0.14

post_se	303	2.8
znaménko	73	9.1
splatnost	72	7.2
sídlo	23	3.05
záruka	7	1.14
jméno	12	0.56

X-plain – no, dobře, ale jak je to udělané?

```
=coord
*SYMMETRIC
     1:[] [word = "a" | word = "nebo"] 2:[] & 1.k=2.k & 1.c=2.c [word
     = "ani"] 1:[] [word = ","]? [word = "ani"] 2:[] & 1.k=2.k &
     1.c=2.c [word = "bud'"] 1:[] [word = ","] [word = "nebo"] 2:[]
     & 1.k=2.k & 1.c=2.c
*DUAL
=a_modifier/modifies
     2:[tag="k2.*"] [tag="k2.*"|word=","|word="se"|word="si"]{0,5}
     1:[tag="k1.*"] & 1.c=2.c 2:[tag="k2.*"] [word="a" | word="nebo"]
     [tag="k2.*"|word=","|word="se"|word="si"]{0,5} 1:[tag="k1.*"]
     & 1.c=2.c [tag="k2.*"|word=","|word="se"|word="si"]{0,5}
     [word="a" | word="nebo"] 2:[tag="k2.*"] 1:[tag="k1.*"] & 1.c=2.c
     1:[tag="k1.*"] 2:[tag="k2.*"] & 1.c=2.c
*TRINARY
=post_%s
     1:[tag="k1.*"] 3:[tag="k7.*"] [tag="k2.*"|word=","|word="se"|word="si"
     2:[tag="k1.*"] & 3.c = 2.c 1:[tag="k5.*"] 3:[tag="k7.*"]
     [tag="k2.*"|word=","|word="se"|word="si"]{0,5} 2:[tag="k1.*"]
     & 3.c = 2.c
```


X-plain – od gramatiky k sémantice

Pravidla od gramatiky k sémantice:

```
is_similar_to=["coord"]
can_have_property=["a_modifier"]
is_the_opposite_of=["prec_oproti","prec_vůči","post_vůči","post_oproti"]
can_be_likely_found=["post_blízko","post_nedaleko","post_na"]
```

Reverzní pravidla od gramatiky k sémantice:

```
is_similar_to=["coord"]
can_have_property=["modifies"]
is_the_opposite_of=["prec_oproti","prec_vůči","post_vůči","post_oproti"]
can_be_likely_found=["prec_blízko","prec_nedaleko","prec_na"]
```

X-plain – od gramatiky k sémantice

Program v roli vypravěče:

- hledá kandidáty na nápovědu v databázi (pro každou relaci i získá množinu R_i)
- vytvoří word sketch pro tajné slovo
- na základě pravidel od gramatiky k sémantice hledá kandidáty z word sketch (pro každou relaci i získá množinu S_i)
- vybere náhodné prvky z T_i, kde $T_i = R_i \cup S_i$ pro každou relaci i

X-plain – od gramatiky k sémantice

Program v roli hadače:

- hledá kandidáty na odpověď v databázi (pro danou relaci získá množinu R)
- vytvoří word sketch pro objekt
- na základě reverzních pravidel od gramatiky k sémantice hledá kandidáty z word sketch (pro danou relaci a objekt získá množinu Si)
- vybere náhodné prvky z T, kde $T = R \cup S$ pro danou relaci

Příklad

Tajné slovo je ,,kometa“

- vypravěč (člověk) vyplní šablonu: . . . se skládá z ohonu
- hadač (program) získá $R = \{$,,liška“$\}$ z databáze a $S = \{$,,kůň“, ,,kráva“, . . . $\}$ z word sketch, hádá ,,kůň“
- vypravěč (člověk) vyplní šablonu: . . . může mít vlastnost Halleyova
- hadač (program) získá $R = \emptyset$ z databáze a $S = \{$,,kometa“$\}$, hádá ,,kometa“
- bingo!

Ach ten čeština

vypravěč píše krátké, ale gramaticky správné věty:
kometa se skládá z ohonu
do databáze se ukládájí trojice: `kometa -- has_part -- ohon`
morfologický analyzátor `majka`

```
case["has_part"]="c2";
```

Výsledky

v současnosti necelých 500 her, přes 3100 trojic
trojice se opakují
v databázi jsou překlepy a chyby

Výsledky a jejich použití

sport	can_be_likely_found	hřiště
sport	can_have_property	bojový
sport	is_related_to	pohyb
sport	is_the_opposite_of	lenošení
sport	is_used_for	udržení kondice
fanoušek	is_part_of	sport
hra	can_be_used_for	sport
sportovec	has_part	sport
trofej	is_used_for	sport
fanoušek	is_related_to	sport
fanoušek	is_for	sport
areál	is_for	sport
fanoušek	can_be_likely_found	tribuna

Výsledky a jejich použití

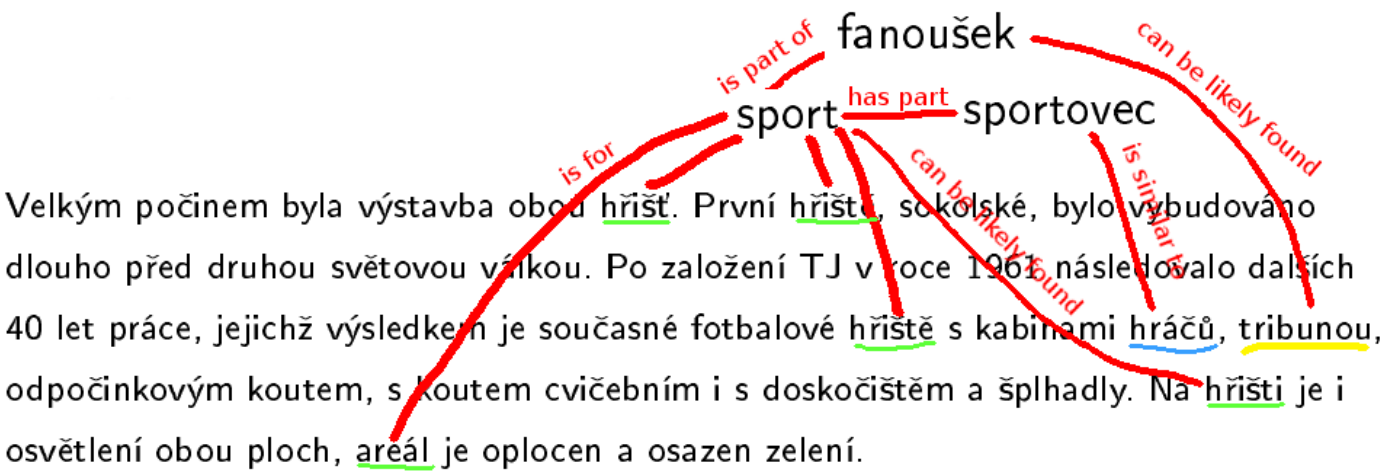

Další práce

- lepší grafika
- registrace, hráčské úrovně, odměny apod.
- odstupňování tajných slov od „lehkých“ po „těžká“
- měření a porovnávání kvality získaných dat
- aplikace
- další hry

náměty na BP, DP :-)

http://nlp.fi.muni.cz/~xpopelk/xplain/
mailto:xpopelk@fi.muni.cz