

Zpracování přirozeného jazyka

Aleš Horák

E-mail: hales@fi.muni.cz

<http://nlp.fi.muni.cz/uui/>

Obsah:

- Komunikace
- Gramatiky
- Analýza přirozeného jazyka
- PA026 – Projekt z umělé inteligence

ŘEČOVÉ AKTY

SITUACE

Mluvčí (speaker) → Promluva (utterance) → Posluchač (hearer)

řečové akty směřují k naplnění cílů mluvčího:

- | | |
|---|--------------------------------|
| – informovat (inform) | “Před tebou je jáma.” |
| – ptát se (query) | “Vidíš zlato?” |
| – přikázat/žádat (command/request) | “Zvedni to.” |
| – slíbit/svěřit se s plánem (promise, commit to plan) | “Rozdělím se s tebou o zlato.” |
| – potvrdit (acknowledge) | “OK” |

plánování řečových aktů vyžaduje znalosti:

- situace
- sémantiky a syntaxe (sdílených konvencí)
- informace o Posluchači – cíle, znalosti, rozumnost

PŘIROZENÝ JAZYK – PROSTŘEDEK KOMUNIKACE

komunikace = cílená výměna informace pomocí produkce a vnímání (sdílených) **pokynů**

- zvířata – až stovky pokynů (šimpanz, delfín, ...)
- člověk – potenciálně neomezené množství, díky přirozenému jazyku

2 náhledy na **přirozený jazyk**:

klasický (před 1953) – jazyk se skládá z vět, které jsou buď pravdivé nebo nepravdivé (srovnej s logikou)

moderní (po 1953) – užití jazyka je jedna z možných **akcí**

Wittgenstein (1953) **Philosophical Investigations**

Searle (1969) **Speech Acts**

Turingův test založen na jazyku ⇐ jazyk je pevně spojen s **myšlením**

komunikace se tvoří pomocí **řečových aktů** (*speech acts*) jako jeden z typů agentových akcí

cíl komunikace – změnit akce ostatních agentů

KOMUNIKAČNÍ FÁZE (PŘI INFORMOVÁNÍ)

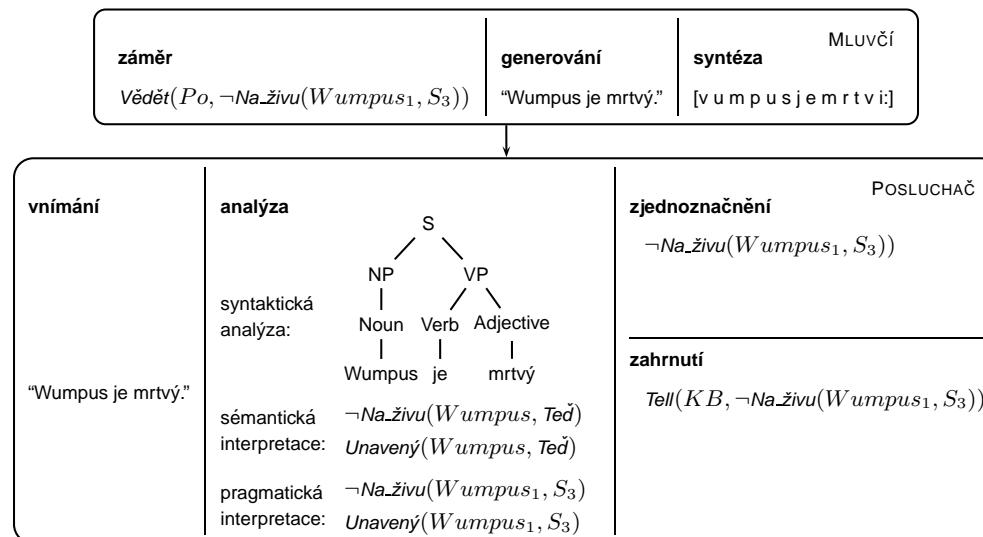
průběh promluvy je možné rozložit na **fáze**:

- | | |
|--|---|
| – záměr (intention) | <i>M</i> chce informovat <i>Po</i> , že <i>Pr</i> |
| – generování (generation) | <i>M</i> vybírá slova <i>W</i> pro vyjádření <i>Pr</i> |
| – syntéza (synthesis) | <i>M</i> říká slova <i>W</i> |
| – vnímání (perception) | <i>Po</i> vnímá <i>W'</i> |
| – analýza (analysis) | <i>Po</i> odvozuje možné významy <i>Pr₁, ..., Pr_n</i> |
| – zjednoznačnění (disambiguation) | <i>Po</i> vybírá zamýšlený význam <i>Pr_i</i> |
| – zahrnutí (incorporation) | <i>Po</i> zahrne <i>Pr_i</i> do své báze znalostí |

Může přitom vzniknout **chyba**:

- neupřímnost (*Po* nevěří *Pr*)
- víceznačnost promluvy (*Po* zvolí špatné *Pr_i*)
- různé pochopení aktuální situace (zamýšlený význam mezi *Pr_i* není)

KOMUNIKAČNÍ FÁZE – PŘÍKLAD



TYPY GRAMATIK

gramatiky:

 regulární (regular) neterminál → **terminál**[neterminál]

$$\begin{aligned} S &\rightarrow aS \\ S &\rightarrow b \end{aligned}$$

ekvivalentní sítě **konečných automatů**, neumí $a^n b^n$ **bezkontextové** (context-free) neterminál → cokoliv

$$S \rightarrow aSb$$

ekvivalentní sítě **zásobníkových automatů**, umí $a^n b^n$, neumí $a^n b^n c^n$ **kontextové** (context-sensitive) – víc neterminálů na levé straně; na levé straně se jejich počet "zmenšuje"

$$ASB \rightarrow AAaBB$$

umí $a^n b^n c^n$ **rekurzivně vyčíslitelné** (recursively enumerable) – bez omezeníekvivalentní sítě **Turingova stroje****přirozený jazyk** byl dlouho pokládán za bezkontextový → nyní prokázáno, že obsahuje **kontextové prvky**

GRAMATIKY

zvířata používají místo vět izolované symboly ⇒ **omezená** sada komunikovatelných situací
 → žádná **generativní kapacita**

gramatika specifikuje skladební strukturu složených pokynů – definuje **formální jazyk** pokynů

formální jazyk = množina **řetězců** (vět) **terminálních symbolů** (slov)

2 náhledy na vztah věty a gramatiky:

- S je správný řetězec/věta z jazyka ⇔ S je **analyzovatelný** příslušnou gramatikou
- příslušná gramatika **generuje** S ⇔ S je správný řetězec/věta z jazyka

gramatika je zadána jako množina **přepisovacích pravidel**, např.

$$\begin{aligned} S &\rightarrow NP \quad VP \\ Pronoun &\rightarrow já \mid ty \mid on \mid \dots \end{aligned}$$

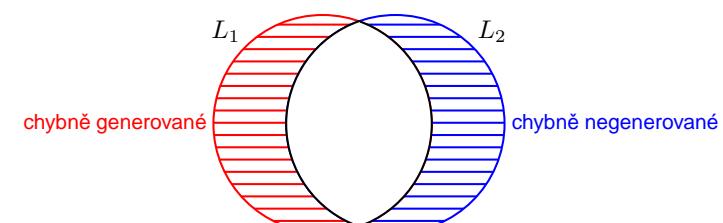
v tomto příkladu:

$$\begin{aligned} S &\quad \text{větný symbol} - \text{kořenový symbol gramatiky} \\ NP, VP &\quad \text{neterminály} \\ já, ty, \dots &\quad \text{terminály} \end{aligned}$$

PŘESNOST A POKRYTÍ GRAMATIKY

u složitějších jazyků (např. přirozených)

→ jazyk L_1 (generovaný gramatikou) se liší od zamýšleného jazyka L_2



kvalita gramatiky:

- **pokrytí** – procento vět jazyka L_2 generovatelných gramatikou ($|L_1 \cap L_2| / |L_2|$)
- **přesnost** – procento generovaných vět, které jsou správné věty jazyka L_2 ($|L_1 \cap L_2| / |L_1|$)

tvorba gramatiky ... postupný proces zvyšování pokrytí a přesnosti

gramatiky přirozených jazyků – velmi rozsáhlé a přesto většinou nepopisují plně ani angličtinu ☺

DC GRAMATIKY – GRAMATIKY USPOŘÁDANÝCH KLAUZULÍ

- Definite-Clause Grammars, DCG
- významná aplikace Prologu – syntaktická analýza
- DCG jsou rozšířením bezkontextových gramatik (CFG)
- jejich implementace využívá rozdílových seznamů

Formální podobnosti mezi DCG a CFG:

- CFG: pravidla tvaru $x \rightarrow y$, kde $x \in N$ je neterminál a $y \in (N \cup T)^*$ je konečná posloupnost terminálů a neterminálů
- DCG: pravidla tvaru $\langle \text{hlava} \rangle \rightarrow \langle \text{tělo} \rangle$, kde $\langle \text{hlava} \rangle$ je opět neterminál a $\langle \text{tělo} \rangle$ je opět konečná posloupnost terminálů a neterminálů
- pravidlo $\langle \text{hlava} \rangle \rightarrow \langle \text{tělo} \rangle$ znamená, že jedním z možných tvarů $\langle \text{hlavy} \rangle$ je $\langle \text{tělo} \rangle$, neboli: $\langle \text{hlavu} \rangle$ je možno přepsat na $\langle \text{tělo} \rangle$

DC GRAMATIKA – PŘÍKLAD 1

gramatika vět typu "The young boy sings a song."

```
% 1. část -- pravidla
sentence --> noun_phrase, verb_phrase.

noun_phrase --> determiner, noun_phrase2.
noun_phrase --> noun_phrase2.

noun_phrase2 --> adjective, noun_phrase2.
noun_phrase2 --> noun.

verb_phrase --> verb.
verb_phrase --> verb, noun_phrase.

% 2. část -- lexikon
determiner --> [the].      noun --> [boy].
determiner --> [a].        noun --> [song].

verb --> [sings].          adjective --> [young].
```

ROZDÍLY A ROZŠÍŘENÍ DCG OPROTI CFG

1. **Neterminál** může být téměř libovolný term, kromě **seznamu**, **proměnné** a **čísla**.
2. **Terminál** může být libovolný term, s tím, že terminály a posloupnosti terminálů uzavíráme do hranatých závorek – jako **seznamy**.
3. Pravá strana pravidla může obsahovat **dodatečné podmínky** v podobě prologovských podcílů. Tyto podmínky uzavíráme do složených závorek.
4. Levá strana pravidla může dokonce vypadat i tak, že neterminál je následován posloupností terminálů.
5. Tělo pravidla smí obsahovat řez.

ANALÝZA V PROLOGU POMOCÍ APPEND

- větu reprezentujeme seznamem slov **[the,young,boy,sings,a,song]**
- **pravidlová část** – neterminál chápeme jako unární predikát, jehož argumentem je ta větná složka, kterou daný neterminál popisuje

```
sentence(S) :- append(NP,VP,S),
            noun_phrase(NP), verb_phrase(VP).
...
```

- **slovníková část, lexikon** – zapisujeme pomocí faktů:

| | |
|---------------------------|---------------------|
| determiner([the]). | noun([boy]). |
| determiner([a]). | ... |

EFEKTIVNĚJI – ROZDÍLOVÉ SEZNAMY

přepis gramatiky do Prologu pomocí rozdílových seznamů:

```

sentence(S,S0) :- noun_phrase(S,S1), verb_phrase(S1,S0).

noun_phrase(S,S0) :- determiner(S,S1), noun_phrase2(S1,S0).
noun_phrase(S,S0) :- noun_phrase2(S,S0).
noun_phrase2(S,S0) :- adjective(S,S1), noun_phrase2(S1,S0).
noun_phrase2(S,S0) :- noun(S,S0).
verb_phrase(S,S0) :- verb(S,S0).
verb_phrase(S,S0) :- verb(S,S1), noun_phrase(S1,S0).

determiner([the|S],S).      noun([boy|S],S).
determiner([a|S],S).        noun([song|S],S).
verb([sings|S],S).          adjective([young|S],S).

?- sentence([the,young,boy,sings,a,song],[]).
Yes

```

MORFOLOGICKÁ ANALÝZA

- V češtině u lexikonu nestačí prostý výčet tvarů – je nutná **morfologická analýza**
(morphologie=tvarosloví)
- skloňovaná a časovaná slova se rozkládají na **segmenty**
pří-lež-it-ost-n-ými
pří – prefix; lež – kořen; it, ost, n – suffixy; ými – koncovka
- každé slovo má **základní tvar** (*lemma*), podle koncovky se určují **gramatické kategorie**

% slovník základních gramatických kategorií – – pád, číslo, rod
% adj(+Slovo, +Lemma, +Pad, +Cislo, +Rod)
adj(chytrý, chytrý, 1, sg, mz). adj(chytrého, chytrý, 2, sg, mz). adj(chytří, chytrý, 1, pl, mz).

- reálná morfologická analýza ČJ – program AJKA na FI MU
- <http://nlp.fi.muni.cz/projekty/wwwajka/>
- | | |
|-----------------------------------|----------------------|
| ajka>nejneuvěřitelněji | ajka>hnát |
| <s> nej-ne=uvěřiteln==ěji= (1022) | <s> ==hná+t= (618) |
| <l>uvěřitelně | <l>hnát |
| <c>k6xMeNd3 | <c>k5eAmFaI |
| | <s> =hnát== (1030) |
| | <l>hnát |
| | <c>k1gInSc1,k1gInSc4 |

LEXIKON PRO AGENTA VE WUMPUSOVĚ JESKYNI

Gramatika přímo na slovech je příliš rozsáhlá. Řešením je rozdělení slov do **kategorii**:

| | | |
|---------------|--------------------|--|
| podst. jméno: | Noun | → zápach vánek tpty nic wumpuse jáma zlato ... |
| sloveso: | Verb | → jsem je vidím cítím působí zapáchá jdu ... |
| příd. jméno: | Adjective | → levý pravý východní jižní ... |
| příslovce: | Adverb | → tady tam blízko vpředu vpravo vlevo východně jižně vzadu ... |
| vl. jméno: | Name | → Petr Honza Brno FI MU ... |
| zájmeno: | Pronoun | → já ty mě toho ten ta ... |
| předložka: | Preposition | → do v na u ... |
| spojka: | Conjunction | → a nebo ale ... |
| číslice: | Digit | → 0 1 2 3 4 5 6 7 8 9 |

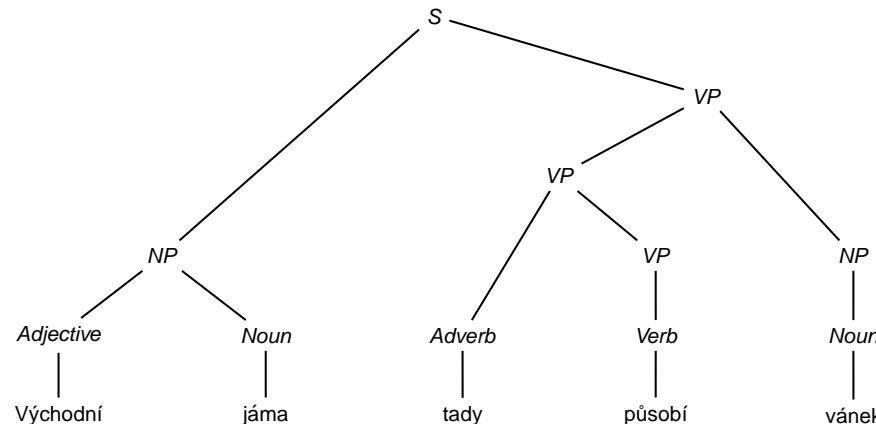
kategorie můžeme dělit na **otevřené** (vyvíjející se) a uzavřené (stálé)

GRAMATICKÁ PRAVIDLA PRO AGENTA VE WUMPUSOVĚ JESKYNI

| | | |
|-----------|-----------------------|---|
| S | → NP VP | % já + cítím vánek |
| | S Conjunction S | % já cítím vánek + a + já jdu na východ |
| NP | → Pronoun | % já |
| | Noun | % jáma |
| | Adjective Noun | % levá jáma |
| | Pronoun NP | % toho + wumpuse |
| | Noun Digit ; Digit | % pole + 3,4 |
| | NP PP | % jáma + na východě |
| | NP RelClause | % toho wumpuse + ,který zapáchá |
| VP | → Verb | % zapáchá |
| | VP NP | % cítím + vánek |
| | VP Adjective | % je + tptyivý |
| | VP PP | % jdu + na východ |
| | VP Adverb Adverb VP | % jdu + dopředu |
| PP | → Preposition NP | % na + východ |
| RelClause | → ', který' VP | % ,který + zapáchá |

SYNTAKTICKÝ STROM

syntaktický strom vzniká během **syntaktické analýzy** a dává **záznam** o jejím průběhu:



KONSTRUKCE DERIVAČNÍHO STROMU

Neterminály opatříme argumentem:

sentence(sentence(NP,VP)) --> noun_phrase(NP), verb_phrase(VP).

Převod do podoby klauzulí:

sentence(sentence(NP,VP),S,S0) :- noun_phrase(NP,S,S1), verb_phrase(VP,S1,S0).

DC GRAMATIKA S KONSTRUKcí STROMU ANALÝZY

sentence(s(N,V)) --> noun_phrase(N), verb_phrase(V).
noun_phrase(np(D,N)) --> determiner(D), noun_phrase2(N).
noun_phrase(np(N)) --> noun_phrase2(N).
noun_phrase2(np2(A,N)) --> adjective(A), noun_phrase2(N).
noun_phrase2(np2(N)) --> noun(N).
verb_phrase(vp(V)) --> verb(V).
verb_phrase(vp(V,N)) --> verb(V), noun_phrase(N).

determiner(det(the)) --> [the].
determiner(det(a)) --> [a].
adjective(adj(young)) --> [young].
noun(noun(boy)) --> [boy].
noun(noun(song)) --> [song].
verb(verb(sings)) --> [sings].

?– **sentence(Tree, [the,young,boy,sings,a,song],[]).**
Tree=s(np(det(the),np2(adj(young),np2(noun(boy)))),vp(verb(sings),np(det(a),np2(noun(song))))))

KONSTRUKCE DERIVAČNÍHO STROMU

Neterminály opatříme argumentem:

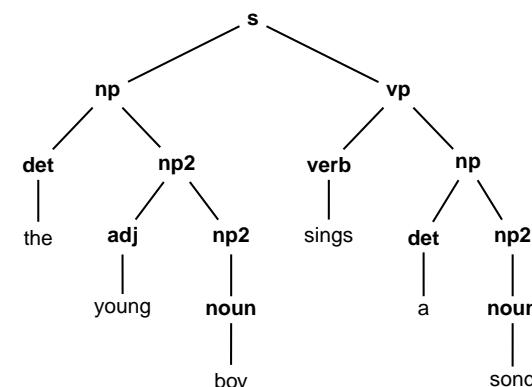
sentence(sentence(NP,VP)) --> noun_phrase(NP), verb_phrase(VP).

Převod do podoby klauzulí:

sentence(sentence(NP,VP),S,S0) :- noun_phrase(NP,S,S1), verb_phrase(VP,S1,S0).

DERIVAČNÍ STROM ANALÝZY V DC GRAMATIKÁCH

?– **sentence(Tree, [the, young, boy, sings, a, song], []).**
Tree=s(np(det(the), np2(adj(young), np2(noun(boy)))), vp(verb(sings), np(det(a), np2(noun(song))))))



TEST NA SHODU

Pokud však rozšíříme slovník:

```
noun(noun(boys)) --> [boys].
verb(verb(sing)) --> [sing].
```

Narazíme na problém se shodou v čísle:

```
?- sentence([a, young, boys, sings ],[]).
Yes

?- sentence([a, boy, sing ],[]).
Yes
```

Proto rozšíříme neterminály o další argument **Num**, ve kterém můžeme testovat shodu:

```
sentence(sentence(NP,VP)) --> noun_phrase(NP,Num), verb_phrase(VP,Num).
```

PODMÍNKY V TĚLE PRAVIDEL

DC gramatiky mohou mít pomocné **podmínky** v těle pravidel – libovolný **Prologovský kód**

např. CFG pro vyhodnocení aritmetického výrazu:

$$\begin{array}{l} E \rightarrow T + E \quad | \quad T - E \quad | \quad T \\ T \rightarrow F * T \quad | \quad F / T \quad | \quad F \\ F \rightarrow (E) \quad | \quad f \end{array}$$

zapíšeme **včetně výpočtu** hodnoty výrazu:

```
expr(X) --> term(Y), [+], expr(Z), {X is Y+Z}.
expr(X) --> term(Y), [-], expr(Z), {X is Y-Z}.
expr(X) --> term(X).

term(X) --> factor(Y), [*], term(Z), {X is Y*Z}.
term(X) --> factor(Y), [/], term(Z), {X is Y/Z}.
term(X) --> factor(X).

factor(X) --> ['['], expr(X), [']'].
factor(X) --> [X], {integer(X)}.

?- expr(X,[3,+4,/2,-,'[',2,*6,/3,+2,']']). % 3 + 4/2 - (2*6/3 + 2) = -1
X = -1
```

DC GRAMATIKA S TESTY NA SHODU

```
sentence(sentence(N,V)) --> noun_phrase(N,Num), verb_phrase(V,Num).
noun_phrase(np(D,N),Num) --> determiner(D,Num), noun_phrase2(N,Num).
noun_phrase(np(N),Num) --> noun_phrase2(N,Num).
noun_phrase2(np2(A,N),Num) --> adjective(A), noun_phrase2(N,Num).
noun_phrase2(np2(N),Num) --> noun(N,Num).
verb_phrase(vp(V),Num) --> verb(V,Num).
verb_phrase(vp(V,N),Num) --> verb(V,Num), noun_phrase(N,Num1).
```

```
determiner(det(the),_) --> [the].
determiner(det(a),sg) --> [a].
noun(noun(boy),sg) --> [boy].
noun(noun(song),sg) --> [song].
verb(verb(sings),sg) --> [sings].
noun(noun(boys),pl) --> [boys].
verb(verb(sing),pl) --> [sing].
noun(noun(songs),pl) --> [songs].
adjective(adj(young)) --> [young].
```

```
?- sentence([a, young, boys, sings ],[]).
No
?- sentence([the,boys,sings,a,song],[]).
No
?- sentence([the,boys,sing,a,song],[]).
Yes
```

GENERATIVNÍ SÍLA DCG

Generativní (rozpoznávací) **síla DCG** je **větší** než CFG

např. jazyk $a^n b^n c^n$:

```
abc --> a(N), b(N), c(N).
a(0) --> [].
a(s(N)) --> [a], a(N).

b(0) --> [].
b(s(N)) --> [b], b(N).

c(0) --> [].
c(s(N)) --> [c], c(N).

?- abc(X,[]).
X = [] ;
X = [a, b, c] ;
X = [a, a, b, b, c, c] ;
X = [a, a, a, b, b, b, c, c, c] ;
```

VÝZNAM SYNTAKTICKÉ ANALÝZY

- analýza syntaxe je **nutná** pro analýzu **významu**
- většina teorií analýzy významu dodržuje **princip kompozicionality**:
Význam složeného výrazu je funkcí významu jednotlivých podvýrazů
- **proces** sémantické analýzy:
 - bud vychází z **výsledků** syntaktické analýzy
 - nebo **probíhá současně** se syntaktickou analýzou; pak může zasahovat i do tvorby syntaktického stromu

VÍCEZNAČNOST

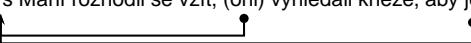
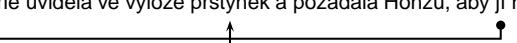
- *ambiguity*
- **víceznačnost** může být **lexikální, syntaktická, sémantická a referenční**
- lexikální – "stát," "žena," "hnát"
- syntaktická – "Jím špagety s masem."
"Jím špagety se salátem."
"Jím špagety s použitím vidličky."
"Jím špagety se sebezapřením."
"Jím špagety s přítelem."
- sémantická – "Jeřáb je vysoký" "Viděli jsme veliké oko"
- referenční – "Oni přišli pozdě." "Můžeš mi půjčit knihu?" "Ředitel vyhodil dělníka, protože (on) byl agresivní."

PROBLÉMY PŘI ANALÝZE PŘIROZENÉHO JAZYKA

- víceznačnost
- anaforické výrazy
- indexické výrazy
- nejasnost
- nekompozicionalita
- struktura promluvy
- metonymie
- metafory

ANAFORICKÉ A INDEXICKÉ VÝRAZY

anaforické výrazy:

- *anaphora*
- používají **zájmena** pro odkazování na objekty zmíněné **dříve**
- "Poté co se Honza s Marií rozhodli se vzít, (oni) vyhledali kněze, aby je oddal."
 
- "Marie uviděla ve výloze prstýnek a požádala Honzu, aby jí ho kupil."
 

indexické výrazy:

- *indexicals*
- **odkazují** se na údaje v **jiných částech** promluvy
- "Já jsem tady."
- "Proč jsi to udělal?"

METAFORA A METONYMIE

metafora:

- *metaphor*
- použití slov v **přeneseném významu** (na základě podobnosti), často systematicky
- "Zkoušel jsem ten proces zabít, ale nešlo to."
- "Bouře se vzteká."

metonymie:

- *metonymy*
- používání **jména** jedné **věci** pro (často zkrácené) označení **věci jiné**
- "Čtu Shakespeara."
- "Chrysler oznámil rekordní zisk."
- "Ten pstruh na másle u stolu 3 chce další pivo."

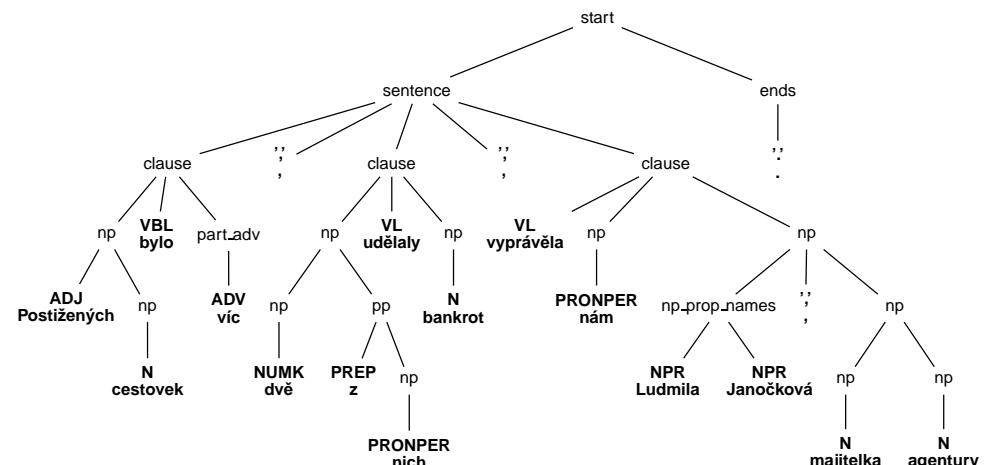
REÁLNÁ SYNTAKTICKÁ ANALÝZA PŘIROZENÉHO JAZYKA

- velice **rozsáhlé gramatiky** (desítky až stovky tisíc pravidel)
- **silná víceznačnost** – někdy až obrovské množství (>miliony) možných syntaktických stromů
Obehnat Šalounův pomník mistra Jana Husa na pražském Staroměstském náměstí živým plotem z hustých keřů s trny navrhuje občanské sdružení Společnost Jana Jesenia.
- existují efektivní algoritmy pro takové gramatiky
např. **tabulkový analyzátor** (*chart parser*), beží v $O(n^3)$, tisíce slov/sekundu

NEKOMPOZICIONALITA

- *noncompositionality*
- příklady **porušení pravidla kompozicionality** u ustálených termínů nebo přednost jiného možného významu při určitých spojeních
- "aligátoří boty," "basketbalové boty," "dětské boty"
- "pata sloupu"
- "červená kniha," "červené pero"
- "bílý trpaslík"
- "dřevěný pes," "umělá tráva"
- "velká molekula"

PŘÍKLAD STROMU ANALÝZY V SYSTÉMU SYNT



PA026 – PROJEKT Z UMĚLÉ INTELIGENCE

- navazuje na předmět PB016 *Úvod do umělé inteligence*
- volba programovacího jazyka ovšem není nijak omezena
- samostatná volba tématu v rozsahu ≥ 1 semestru
- předmět probíhá jako konzultace
- zajímavé výsledky (<http://nlp.fi.muni.cz/uiprojekt/>)
 - ◊ projekt **elnet** – > 5 let spolupráce na grantových projektech simulace elektrorozvodných sítí
 - ◊ projekt **plagiaty.z.webu** – reálné a funkční vyhledávání shod s dokumenty na celém webu
 - ◊ projekt **robot_johnny_5** – sestavení a "oživení" robota – mobilního počítače

