Zpracování přirozeného jazyka

Aleš Horák

E-mail: hales@fi.muni.cz

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

Obsah:

➜ Komunikace

➜ Gramatiky

➜ Analýza přirozeného jazyka

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 $\Leftarrow$ 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

Řečové akty

Situace
Mluvčí (*speaker*) $\longrightarrow$ **Promluva** (*utterance*) $\longrightarrow$ **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

Komunikační fáze (při informování)

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

– **záměr** (intention)	M chce informovat Po, že Pr
– **generování** (generation)	M vybírá slova W pro vyjádření Pr
– **syntéza** (synthesis)	M říká slova W
– **vnímání** (perception)	Po vnímá W'
– **analýza** (analysis)	Po odvozuje možné významy $Pr_1, \ldots, Pr_n$
– **zjednoznačnění** (disambiguation)	Po vybírá zamýšlený význam Pr_i
– **zahrnutí** (incorporation)	Po zahrne Pr_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

Mluvčí

záměr	**generování**	**syntéza**
Vědět$(Po, \neg$*Na_živu*$(Wumpus_1, S_3))$	"Wumpus je mrtvý."	[v u m p u s j e m r t v i:]

↓

Posluchač

vnímání

"Wumpus je mrtvý."

analýza

syntaktická analýza:

S → NP VP; NP → Noun; VP → Verb Adjective; Noun → Wumpus; Verb → je; Adjective → mrtvý

sémantická interpretace: $\neg$*Na_živu*$(Wumpus, $*Teď*$)$ *Unavený*$(Wumpus, $*Teď*$)$

pragmatická interpretace: $\neg$*Na_živu*$(Wumpus_1, S_3)$ *Unavený*$(Wumpus_1, S_3)$

zjednoznačnění

$\neg$*Na_živu*$(Wumpus_1, S_3))$

zahrnutí

Tell$(KB, \neg$*Na_živu*$(Wumpus_1, S_3))$

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) **teminálních 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.

$S \rightarrow NP\ VP$
$Pronoun \rightarrow$ já | ty | on | ...

v tomto příkladu:

S	**větný symbol** – kořenový symbol gramatiky
NP, VP	**neterminály**
já, ty, ...	**terminály**

Typy gramatik

gramatiky:

- **regulární** (regular) neterminál → **terminál**[neterminál]
  S → **a**S
  S → **b**
  ekvivalentní síle **konečných automatů**, neumí $a^n b^n$
- **bezkontextové** (context-free) neterminál → cokoliv
  S → **a**S**b**
  ekvivalentní síle **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 → AA**a**BB
  umí $a^n b^n c^n$
- **rekurzivně vyčíslitelné** (recursively enumerable) – bez omezení
  ekvivalentní síle **Turingova stroje**

přirozený jazyk byl dlouho pokládán za bezkontextový → nyní prokázáno, že obsahuje **kontextové prvky**

Přesnost a pokrytí gramatiky

u složitějších jazyků (např. přirozených)
→ jazyk L_1 (generovaný gramatikou) se liší od zamýšleného jazyka L_2

L_1 L_2

chybně generované

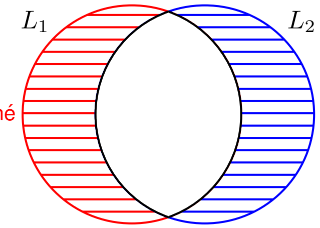

chybně negenerované

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 ⟨**hlava**⟩ **-->** ⟨**tělo**⟩, kde ⟨**hlava**⟩ je opět neterminál a ⟨**tělo**⟩ je opět konečná posloupnost terminálů a neterminálů
- ➜ pravidlo ⟨**hlava**⟩ **-->** ⟨**tělo**⟩ znamená, že jedním z možných tvarů ⟨**hlavy**⟩ je **tělo**, neboli: ⟨**hlavu**⟩ **je možno přepsat na** ⟨**tělo**⟩

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.

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].
```


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_phrase(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
```


Lexikon pro agenta ve Wumpusově jeskyni

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

podst. jméno:	***Noun***	→	zápach | vánek | třpyt | 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)

Morfologická analýza

- V češtině u lexikonu nestačí prostý výčet tvarů – je nutná **morfologická analýza** (morfologie=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
<s> nej-ne=uvěřiteln==ěji= (1022)
    <l>uvěřitelně
    <c>k6xMeNd3
```

```
ajka>hnát
<s> ==hná=t= (618)
    <l>hnát
    <c>k5eAmFaI
<s> =hnát=== (1030)
    <l>hnát
    <c>k1gInSc1,k1gInSc4
```


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 + třpytivý
	|	*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:

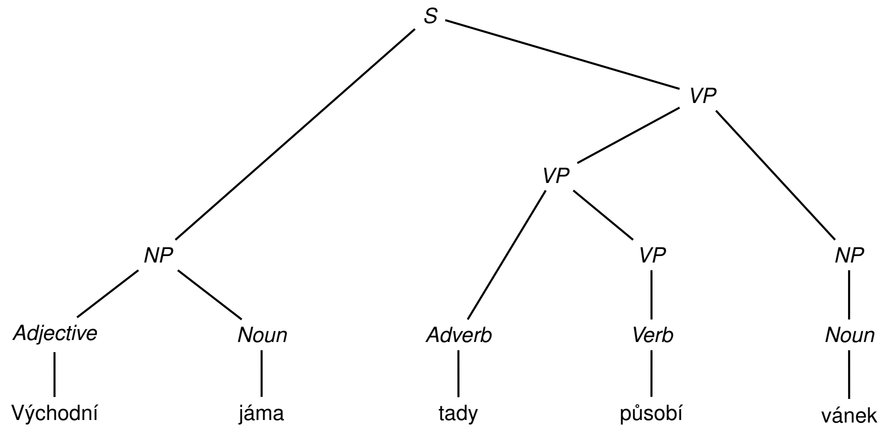

Konstrukce derivačního stromu

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)))))

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)))))

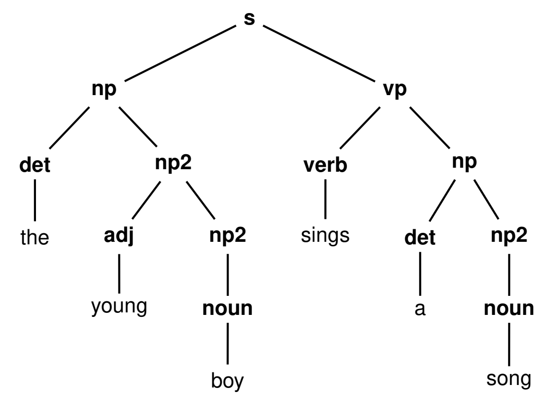

Test na shodu

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).
```


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].       noun(noun(boy),sg) --> [boy].
determiner(det(a),sg) --> [a].          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
```


Podmínky v těle pravidel

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

např. CFG pro vyhodnocení artimetického výrazu:

$$E \rightarrow T + E \;\mid\; T - E \;\mid\; T$$
$$T \rightarrow F * T \;\mid\; F/T \;\mid\; F$$
$$F \rightarrow (E) \;\mid\; f$$

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,')'],[]).
   X = -1
```


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:

- buď vychází z **výsledků** syntaktické analýzy
- nebo **probíhá současně** se syntaktickou analýzou; pak může zasahovat i do tvorby syntaktického stromu

PROBLÉMY PŘI ANALÝZE PŘIROZENÉHO JAZYKA

➜ víceznačnost

➜ anaforické výrazy

➜ indexické výrazy

➜ nejasnost

➜ nekompozicionalita

➜ struktura promluvy

➜ metonymie

➜ metafory

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."

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 koupil."

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.”

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”

Reálná syntaktická analýza přirozeného jazyka

- velice **rozsáhlé gramatiky** (desítky až stovky tisíc pravidel)
- **silná víceznačnost** – někdy až obrovské množství ($>$milióny) 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*), běží v $O(n^3)$, tisíce slov/sekundu

Příklad stromu analýzy v systému synt

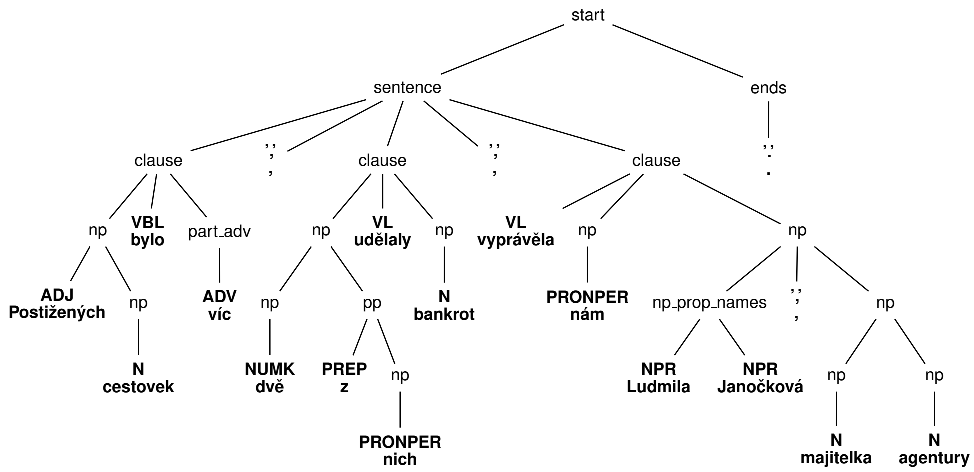

http://nlp.fi.muni.cz/projekty/wwwsynt/