

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

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

Řečové akty

KOMUNIKAČNÍ 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:

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

Komunikační fáze (při informování)

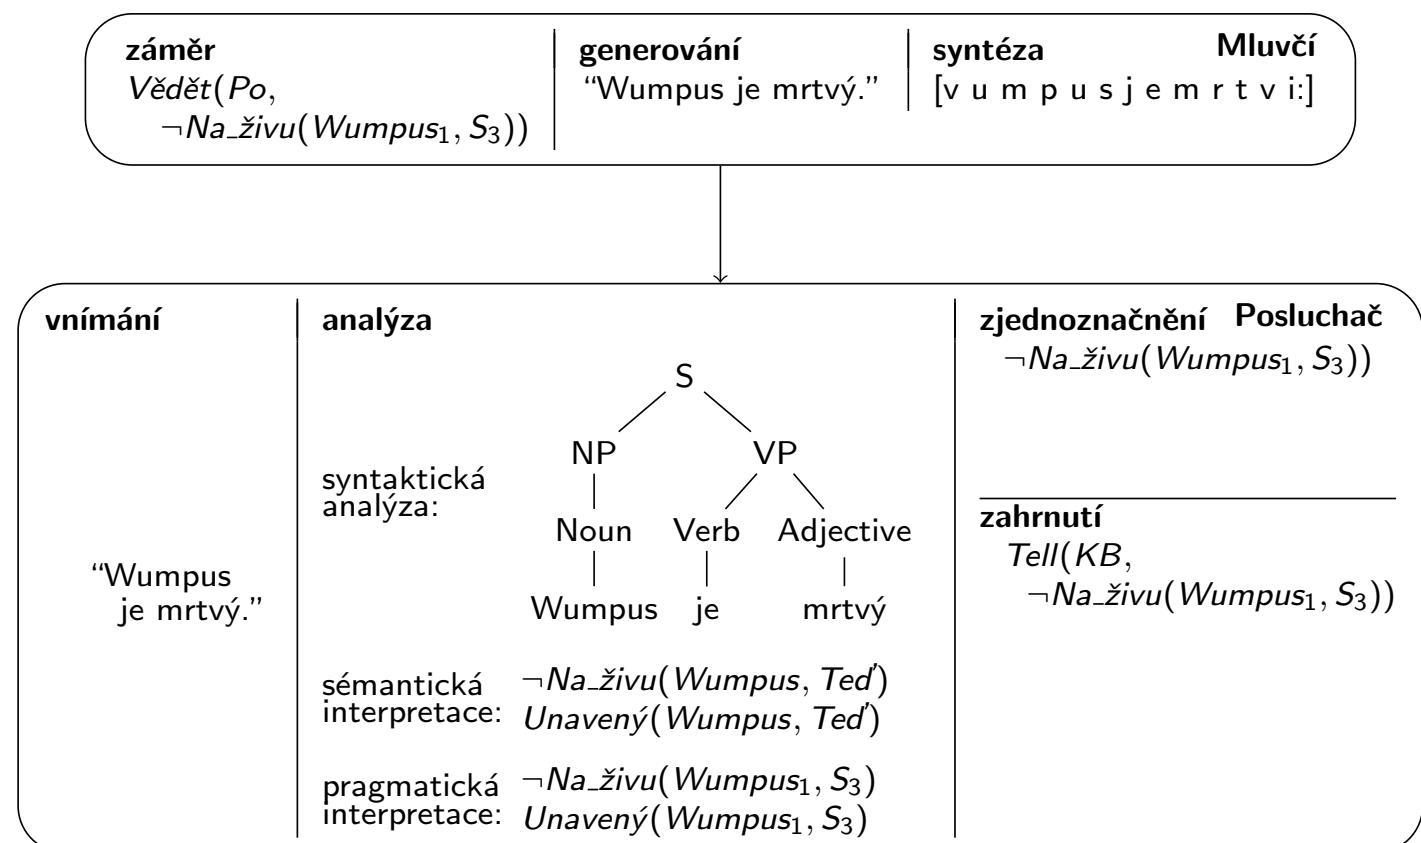
průběh promluvy je možné rozložit na **fáze**:

- **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, \dots, 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



Gramatiky

zvířata používají místo vět izolované symboly \Rightarrow **omezená** sada komunikovatelných situací \rightarrow 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 $\Leftrightarrow S$ je **analyzovatelný** danou gramatikou
- příslušná gramatika **generuje** S $\Leftrightarrow S$ je správný řetězec/věta z jazyka

gramatika je zadána jako množina **přepisovacích pravidel**

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

v tomto příkladu: S **větný symbol** – kořenový symbol gramatiky
 NP, VP **neterminály**
 já, ty, ... **terminály**

Typy gramatik

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

$$\begin{array}{l} S \rightarrow aS \\ S \rightarrow b \end{array}$$

ekvivalentní síle **konečných automatů**, neumí $a^n b^n$

► bezkontextové (context-free) neterminál → cokoliv

$$S \rightarrow aSb$$

ekvivalentní síle **zásobníkových automatů**, umí $a^n b^n$, neumí $a^n b^n c^n$

► kontextové (context-sensitive) – víc termů na levé straně (*kontext* neterminálu)

$$\underline{ASB} \rightarrow \underline{AAaBB}$$

umí $a^n b^n c^n$

► rekurzivně vyčíslitelné (recursively enumerable) – bez omezení

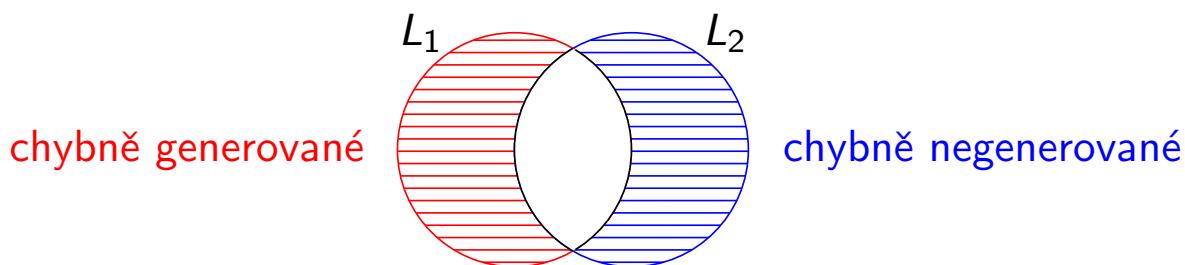
ekvivalentní síle **Turingova stroje**

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



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

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 $\langle \text{hlava} \rangle \dashrightarrow \langle \text{tělo} \rangle$, kde $\langle \text{hlava} \rangle$ je opět neterminál a $\langle \text{tělo} \rangle$ je opět konečná posloupnost terminálů a neterminálů
- ▶ pravidlo $\langle \text{hlava} \rangle \dashrightarrow \langle \text{tělo} \rangle$ znamená, že jedním z možných tvarů $\langle \text{hlavy} \rangle$ je **tělo**, neboli: $\langle \text{hlavu} \rangle$ je **můžno přepsat na** $\langle \text{tělo} \rangle$

Rozdíly a rozšíření DCG oproti CFG

DCG:

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_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
```

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** (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
- ▶ **základní tvar** slova (*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 MAJKA na FI MU
<http://nlp.fi.muni.cz/projekty/wwwajka/>

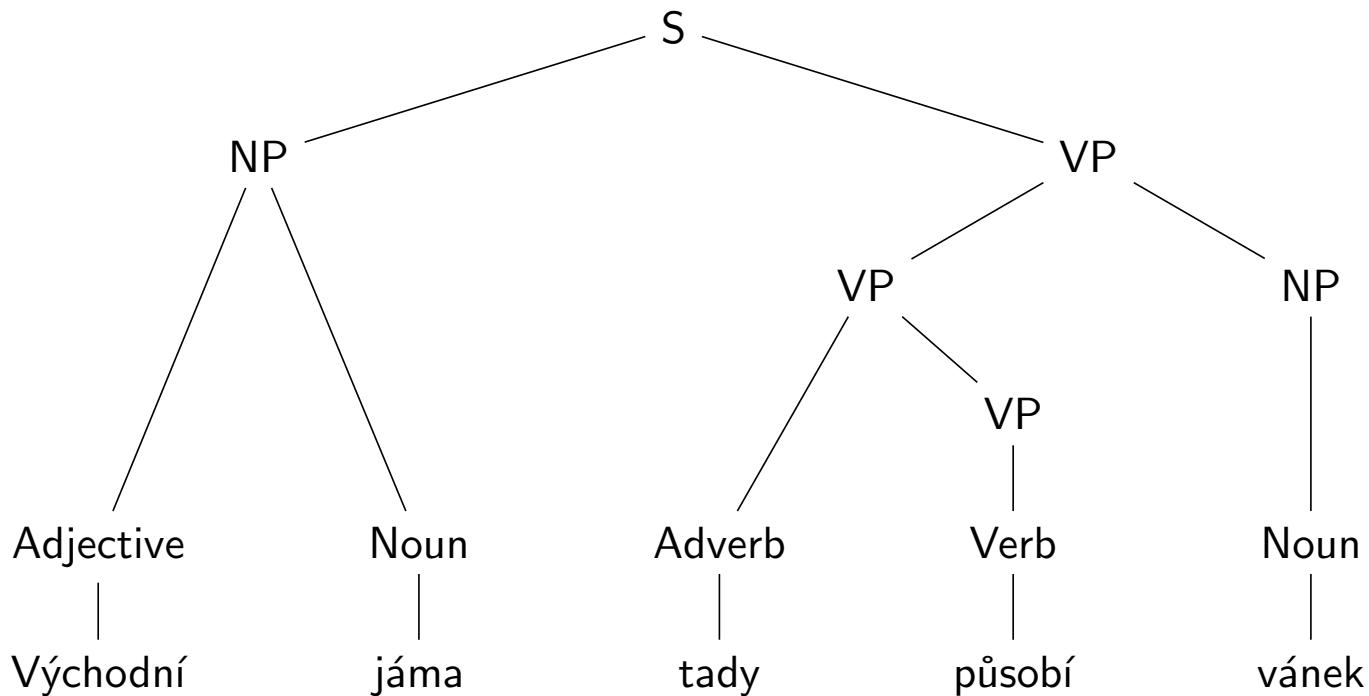
ajka>nejneuvěřitelněji	ajka>hnát
<s> nej-ne=uvěřiteln==ěji= (1022)	<s> ==hná=t= (618)
<l>uvěřitelně	<l>hnát
<c>k6xMeNd3	<c>k5eAmFaI
	<s> =hnát==== (1030)
	<l>hnát
	<c>k1gInSc1,k1gInSc4

Gramatická pravidla pro agenta ve Wumpusově jeskyni

$S \rightarrow NP VP$	% já + cítím vánek
$S \text{ Conjunction } S$	% já cítím vánek + a + já jdu
	% na východ
$NP \rightarrow Pronoun$	% 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
$VP \rightarrow Verb$	% zapáchá
$VP NP$	% cítím + vánek
$VP Adjective$	% je + třpytivý
$VP PP$	% jdu + na východ
$VP Adverb Adverb VP$	% jdu + dopředu
$PP \rightarrow Preposition NP$	% na + východ
$RelClause \rightarrow ', který' VP$	% ,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).

```

```

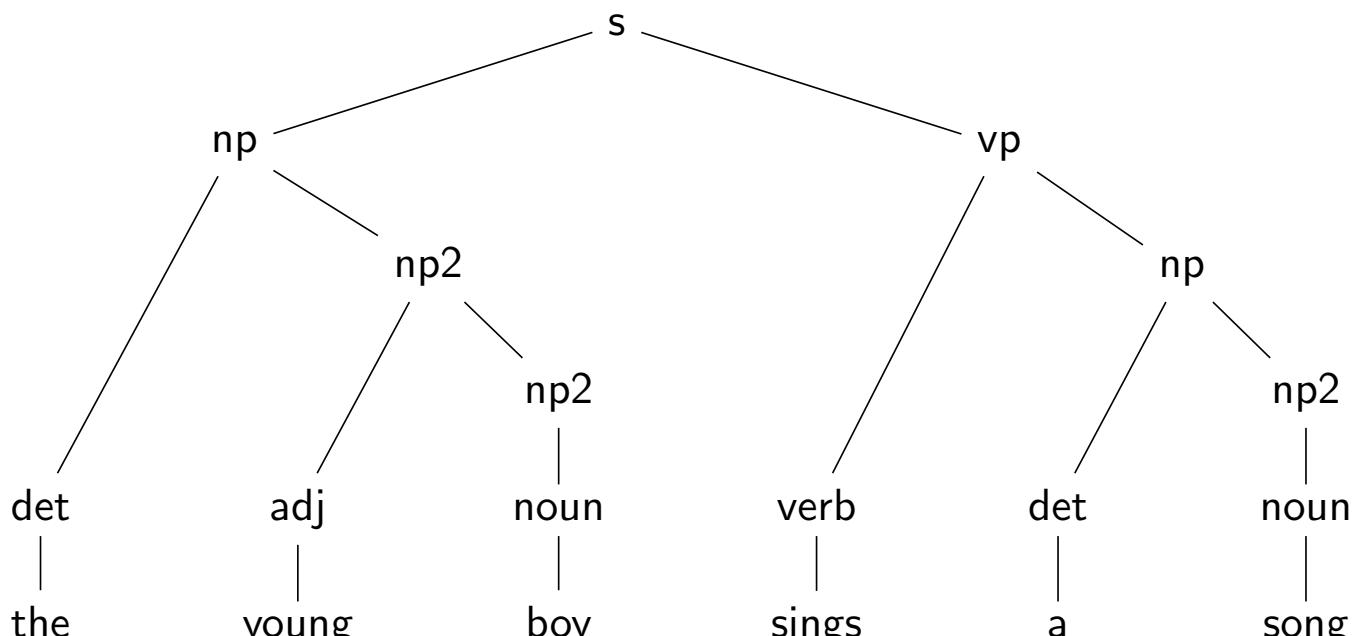
determiner(det(the)) --> [the].
determiner(det(a)) --> [a].
adjective(adj(young)) --> [young].
noun(noun(boy)) --> [boy].
noun(noun(song)) --> [song].
verb(verb(sings)) --> [sings].

```

?— 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(sing),sg) --> [sing].`

`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,sing , a,song],[]).`

No

`?— sentence(',[the, boys,sing , a,song],[]).`

Y

Podmínky v těle pravidel

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

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
```

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 využívá **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

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 kupil.”

indexické výrazy:

- ▶ *indexicals*
 - ▶ **odkazují** se na údaje v **jiných částech** promluvy nebo **mimo** promluvu
- “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”

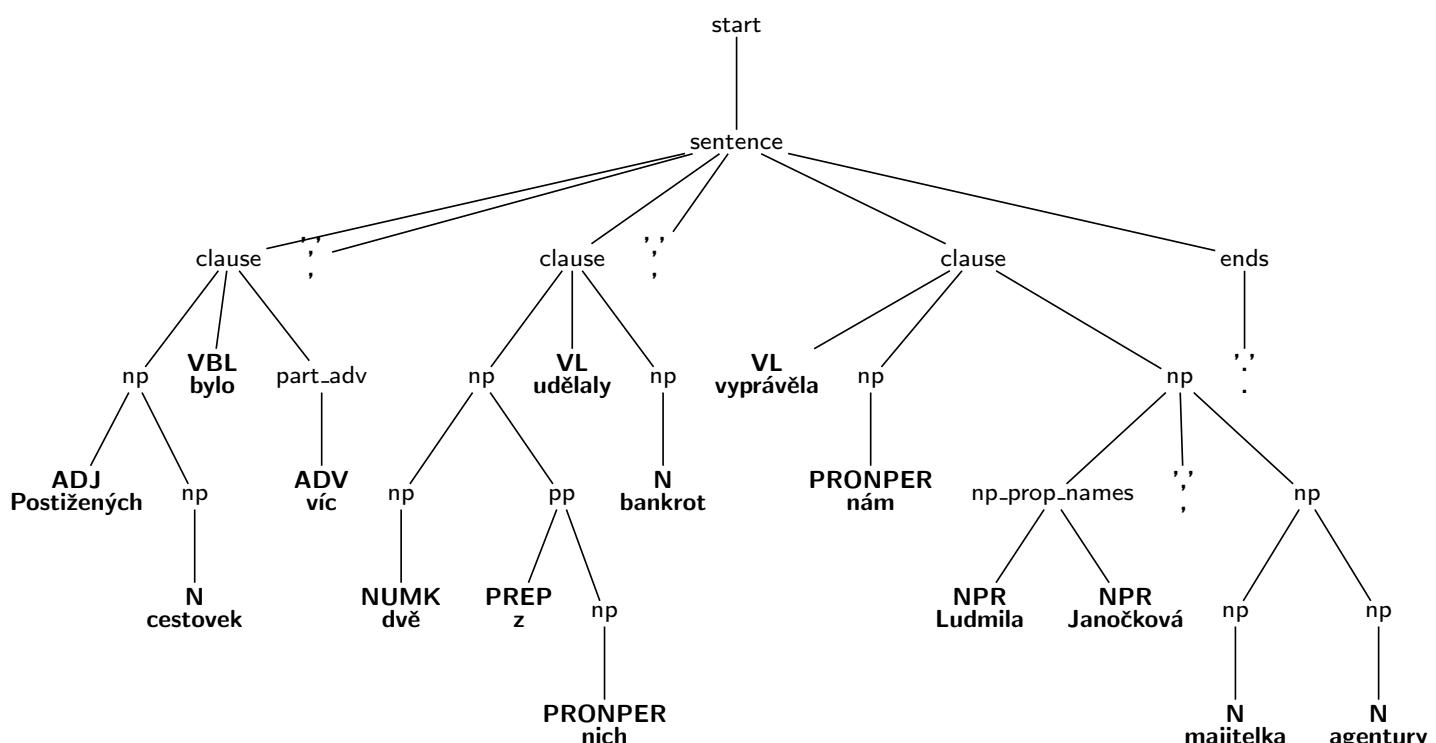
Reálná syntaktická analýza přirozeného jazyka

- ▶ 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*), beží v $O(n^3)$, tisíce slov/sekundu

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

