

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

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)

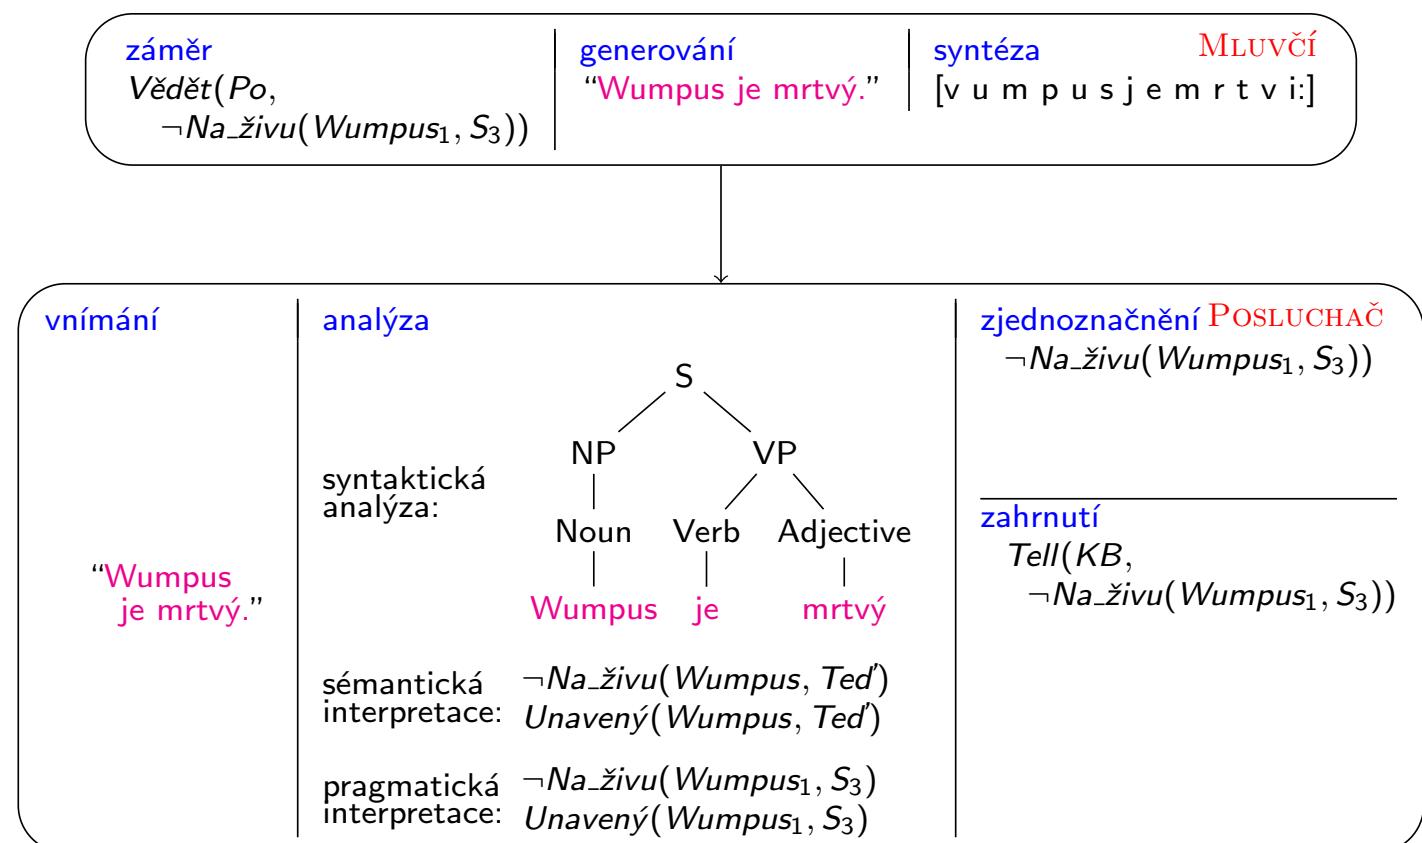
průběh promluvy je možné rozložit na fáze:

- 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

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

v tomto příkladu: S větný symbol – kořenový symbol gramatiky
 NP, VP neterminály
 $já, ty, \dots$ 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) – více termů na levé straně (kontext neterminálu)

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

umí $a^n b^n c^n$

► rekurzivně vyčíslitelné (recursively enumerable) – bez omezení

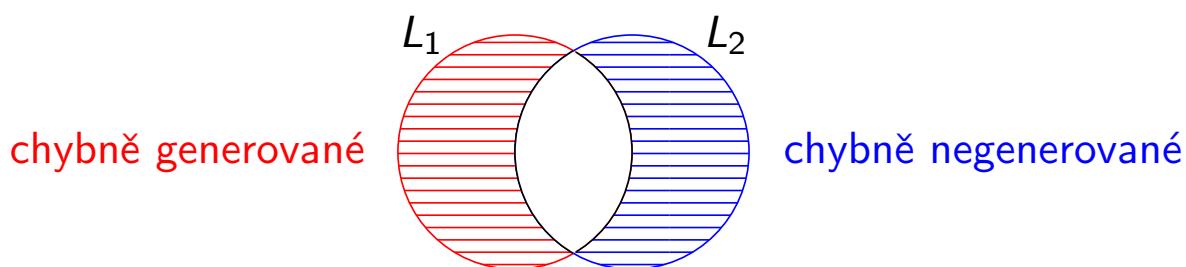
ekvivalentní síle Turingova stroje

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 $\langle \text{hlava} \rangle \rightarrow \langle \text{tělo} \rangle$, 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 **tělo**, neboli: $\langle \text{hlavu} \rangle$ je možno 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

- ▶ věta = seznam 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 – reprezentujeme 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:	<i>Noun</i>	→ zápach vánek třpyt nic wumpuse jáma zlato ...
sloveso:	<i>Verb</i>	→ jsem je vidím cítím působí zapáchá jdu ...
příd. jméno:	<i>Adjective</i>	→ levý pravý východní jižní ...
příslovce:	<i>Adverb</i>	→ tady tam blízko vpředu vpravo vlevo východně jižně vzadu ...
vl. jméno:	<i>Name</i>	→ Petr Honza Brno FI MU ...
zájmeno:	<i>Pronoun</i>	→ já ty mě toho ten ta ...
předložka:	<i>Preposition</i>	→ do v na u ...
spojka:	<i>Conjunction</i>	→ a nebo ale ...
číslice:	<i>Digit</i>	→ 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

- **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/>

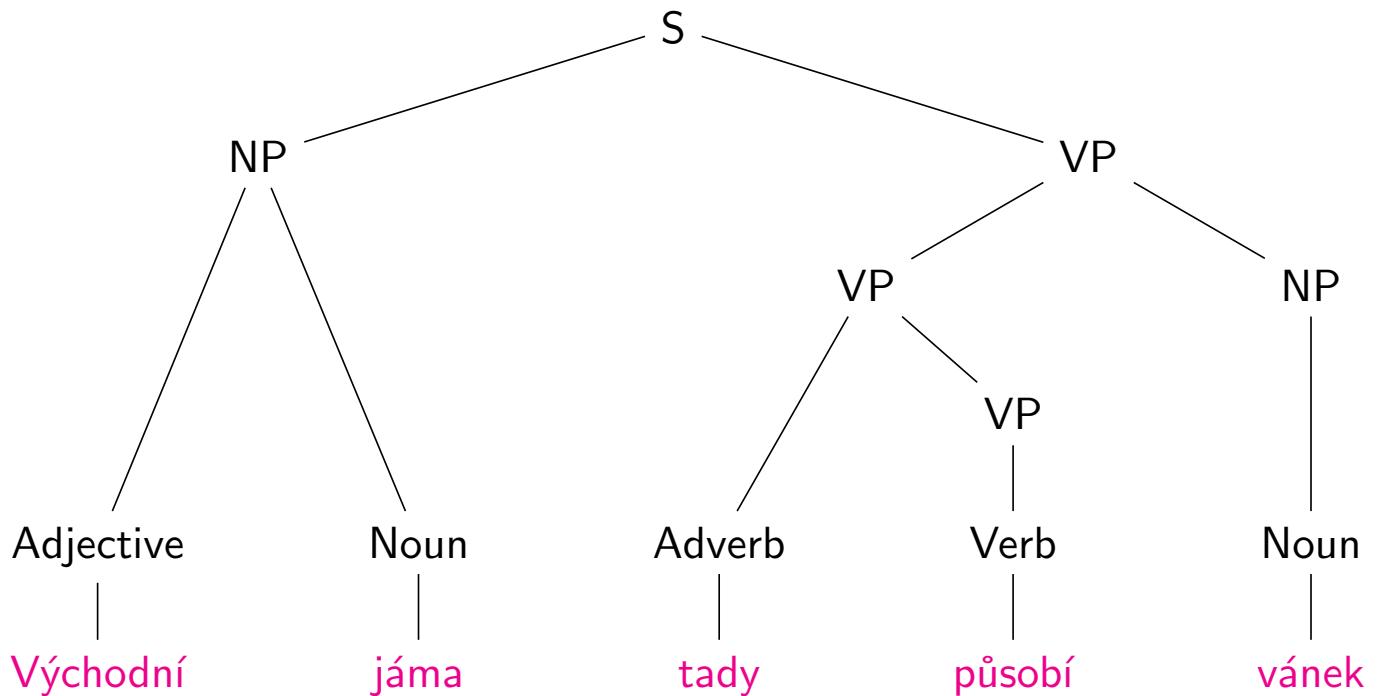
ajka>nejneuvěřitelněji	ajka>hnát
<s> nej-ne=uvěřiteln==ěji= (1022)	<s> ==hná=t= (618)
<l>uvěřitelně	<l>hnát
<c>k6xMeNd3	<c>k5eAmFaI
	<s> =hnát==== (1030)
	<l>hnát
	<c>k1gInSc1,k1gInSc4

Gramatická pravidla pro agenta ve Wumpusově jeskyni

<i>S</i>	\rightarrow	<i>NP VP</i>	% já + cítím vánek
		<i>S Conjunction S</i>	% já cítím vánek + a + já jdu
			% na východ
<i>NP</i>	\rightarrow	<i>Pronoun</i>	% já
		<i>Noun</i>	% jáma
		<i>Adjective Noun</i>	% levá jáma
		<i>Pronoun NP</i>	% toho + wumpuse
		<i>Noun Digit ',' Digit</i>	% pole + 3,4
		<i>NP PP</i>	% jáma + na východě
		<i>NP RelClause</i>	% toho wumpuse + ,který
			% zapáchá
<i>VP</i>	\rightarrow	<i>Verb</i>	% zapáchá
		<i>VP NP</i>	% cítím + vánek
		<i>VP Adjective</i>	% je + třpytivý
		<i>VP PP</i>	% jdu + na východ
		<i>VP Adverb Adverb VP</i>	% jdu + dopředu
<i>PP</i>	\rightarrow	<i>Preposition NP</i>	% na + východ
<i>RelClause</i>	\rightarrow	<i>', který' VP</i>	% ,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).

```

```

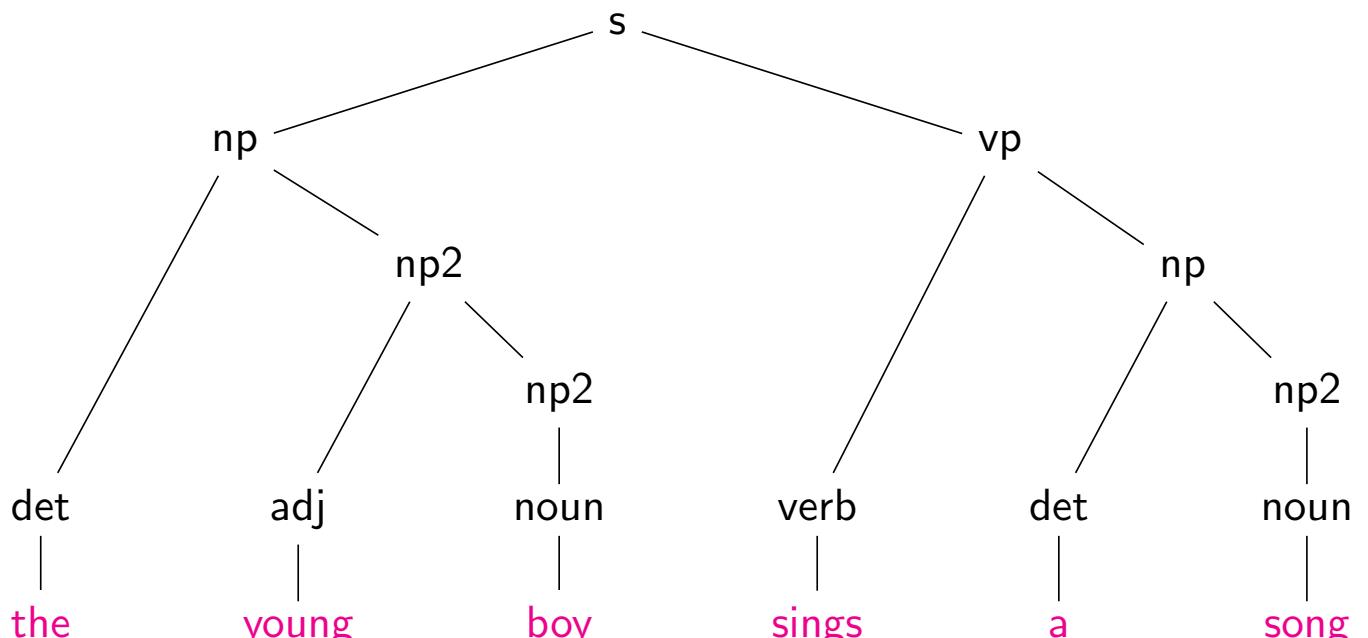
determiner(det(the)) --> [the].
determiner(det(a)) --> [a].
adjective(adj(young)) --> [young].
noun(noun(boy)) --> [boy].
noun(noun(song)) --> [song].
verb(verb(sings)) --> [sings].

```

?— 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

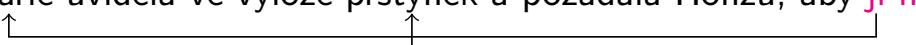
Víceznačnost

- ▶ *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 sebezapření.**”
“**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 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 (>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

Příklad stromu analýzy v systému synt

