

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 \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

záměr $Vědět(Po,$ $\neg Na\text{-živu}(Wumpus_1, S_3))$	generování “Wumpus je mrtvý.”	syntéza [v u m p u s j e m r t v i:]	MLUVČÍ
---	----------------------------------	---	--------



vnímání	analýza	zjednoznačnění POSLUCHAČ $\neg Na\text{-živu}(Wumpus_1, S_3))$
“Wumpus je mrtvý.”	<p>syntaktická analýza:</p> <pre> S NP VP Noun Verb Wumpus je Adjective mrtvý </pre> <p>sémantická interpretace: $\neg Na\text{-živu}(Wumpus, Ted')$ pragmatická interpretace: $\neg Na\text{-živu}(Wumpus_1, S_3)$</p>	<hr/> <p>zahrnutí Tell(KB, $\neg Na\text{-živu}(Wumpus_1, S_3))$</p>

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 danou gramatikou
- příslušná gramatika generuje S ⇔ S je správný řetězec/věta z jazyka

gramatika je zadána jako množina přepisovacích pravidel

$$\begin{array}{l} S \rightarrow NP \quad VP \\ \text{Pronoun} \rightarrow \text{já} \mid \text{ty} \mid \text{on} \mid \dots \end{array}$$

v tomto příkladu:

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

Typy gramatik

- regulární (regular) neterminál → terminál[neterminál]

$$S \rightarrow aS$$

$$S \rightarrow b$$

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 $a^n b^n c^n$

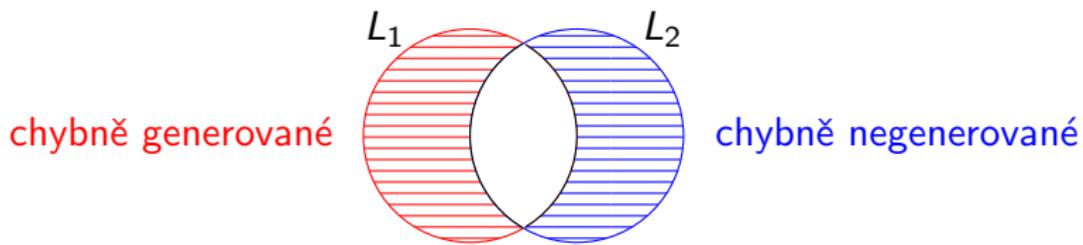
- rekurzivně vyčíslitelné (recursively enumerable) – bez omezení
ekvivalentní síle Turingova stroje

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 $\langle \text{hlava} \rangle \rightarrow \langle \text{tělo} \rangle$, 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

- ▶ 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:	<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, chytří, 1, pl, mz).
- ▶ reálná morfologická analýza ČJ – program MAJKA na FI MU
<http://nlp.fi.muni.cz/projekty/wwwajka/>

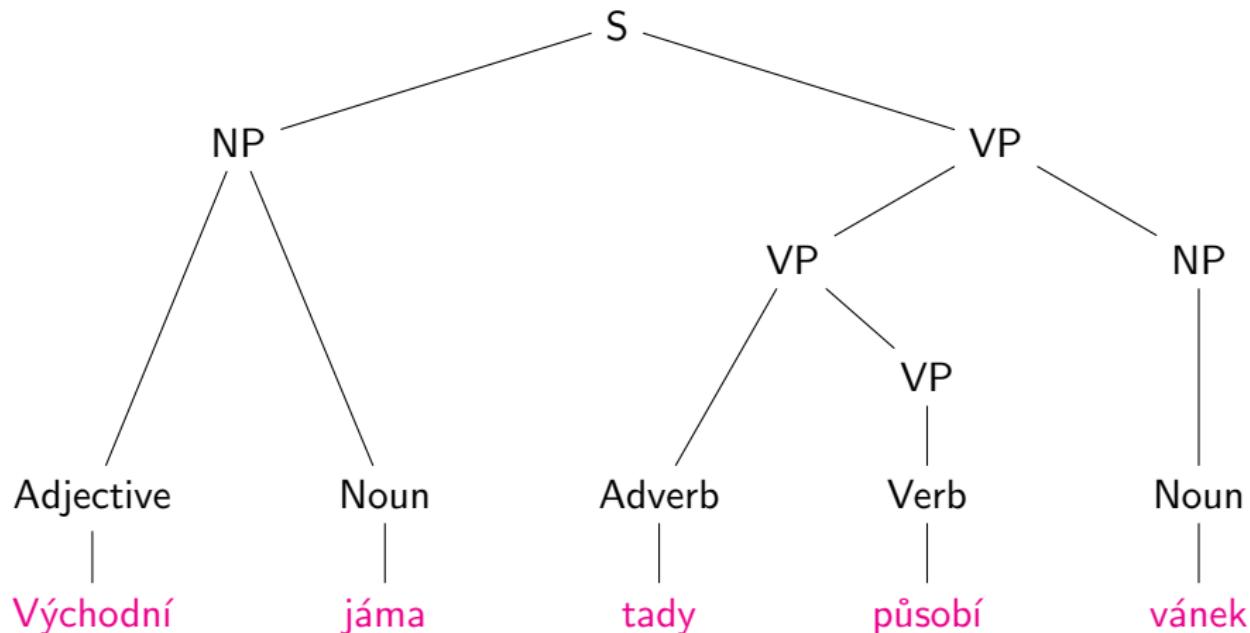
ajka>nejneuvěřitelněji	ajka>hnát
<s> nej-ne=uvěřiteln==ěji= (1022)	<s> ==hná=t= (618)
<l>uvěřitelně	<l>hnát
<c>k6xMeNd3	<c>k5eAmFaI
	<s> =hnát==== (1030)
	<l>hnát
	<c>k1gInSc1,k1gInSc4

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)) \rightarrow noun_phrase(N), verb_phrase(V).
 noun_phrase(np(D,N)) \rightarrow determiner(D), noun_phrase2(N).
 noun_phrase(np(N)) \rightarrow noun_phrase2(N).
 noun_phrase2(np2(A,N)) \rightarrow adjective(A), noun_phrase2(N).
 noun_phrase2(np2(N)) \rightarrow noun(N).
 verb_phrase(vp(V)) \rightarrow verb(V).
 verb_phrase(vp(V,N)) \rightarrow verb(V), noun_phrase(N).

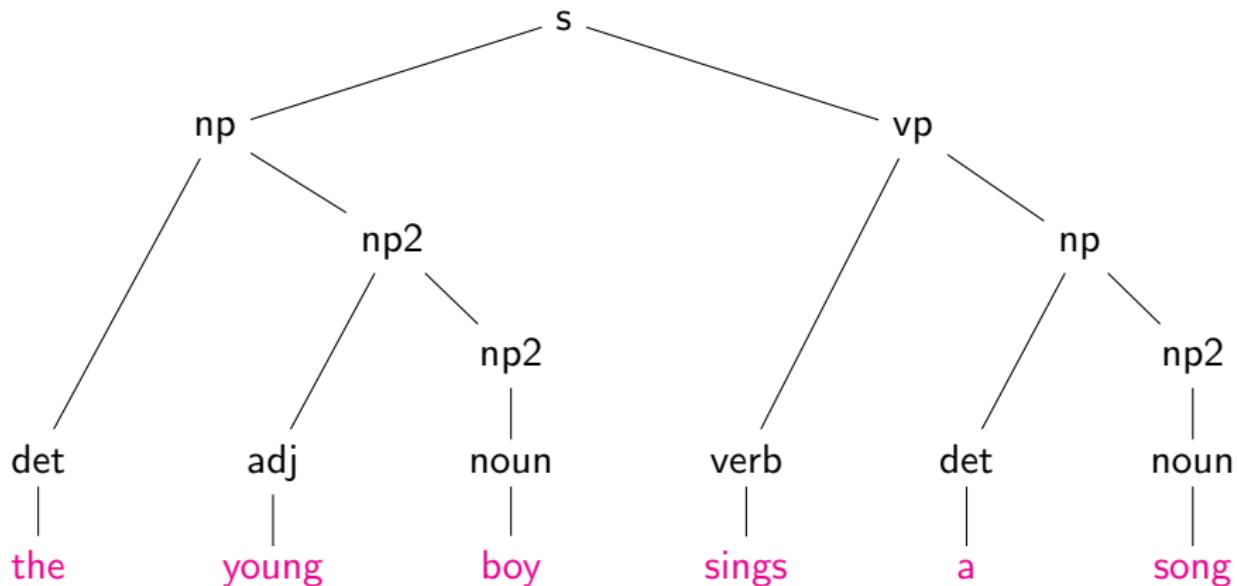
determiner(det(the)) \rightarrow [the].
 determiner(det(a)) \rightarrow [a].
 adjective(adj(young)) \rightarrow [young].
 noun(noun(boy)) \rightarrow [boy].
 noun(noun(song)) \rightarrow [song].
 verb(verb(sings)) \rightarrow [sings].

?– 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, sings , a, song], []).

No

?– sentence(., [the, boys, sing , a, song], []).

X

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**:
 - 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 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”

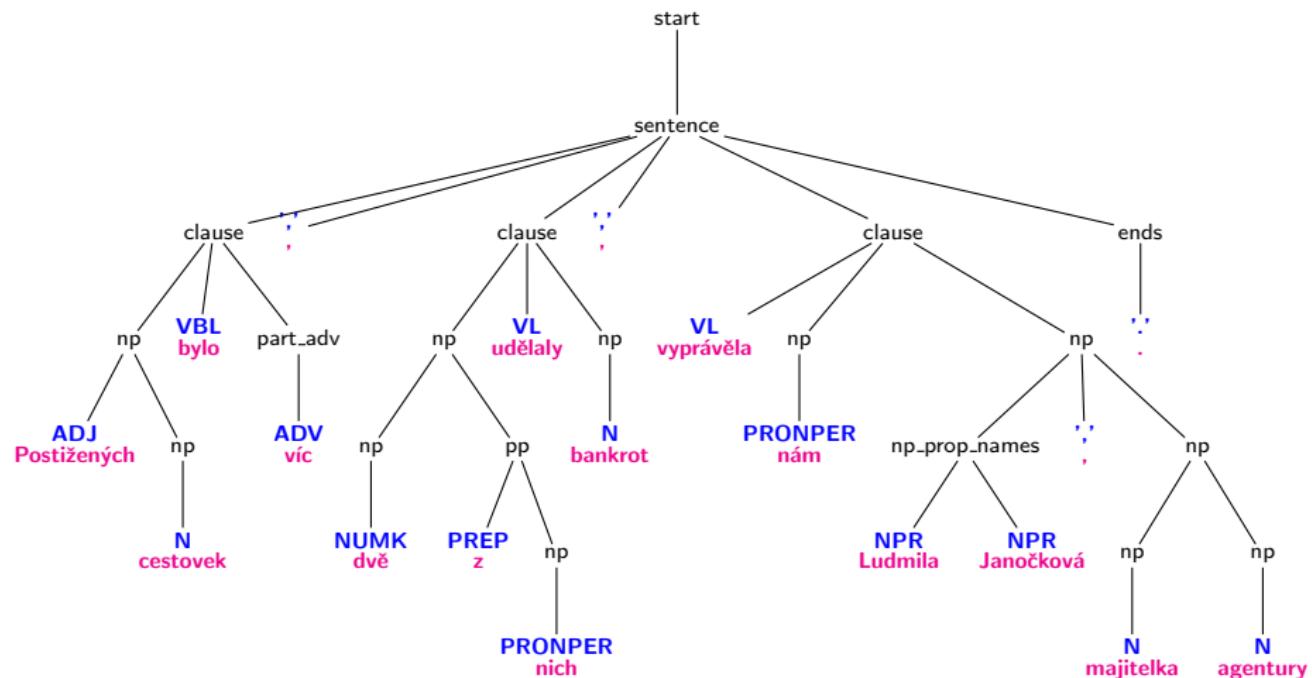
Reálná syntaktická analýza přirozeného jazyka

- ▶ 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



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

