

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

Úvod do umělé inteligence 12/12

1 / 33

Komunikace

Řečové akty

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

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

Úvod do umělé inteligence 12/12

2 / 33

Komunikace

Komunikační fáze (při informování)

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

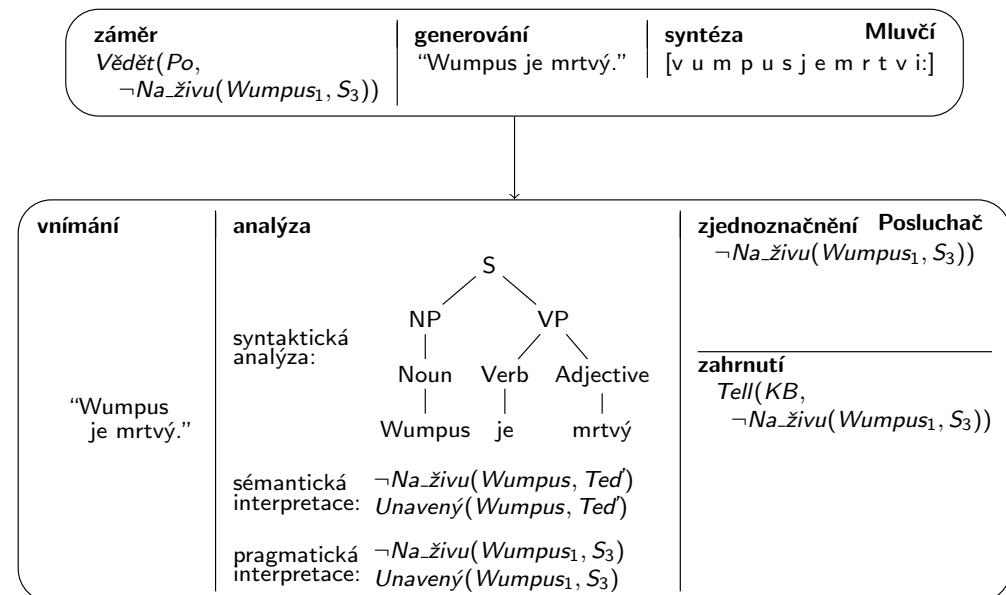
Úvod do umělé inteligence 12/12

3 / 33

Úvod do umělé inteligence 12/12

4 / 33

Komunikační fáze – příklad



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**

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

gramatika je zadána jako množina **přepisovacích pravidel**

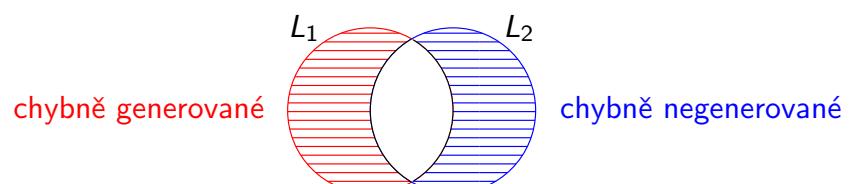
$$\begin{array}{l} S \rightarrow NP \quad VP \\ \text{Pronoun} \rightarrow já \mid ty \mid on \mid \dots \end{array}$$

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

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 **můžno 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

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.

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]).
```

...

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

- **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
  
```

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)

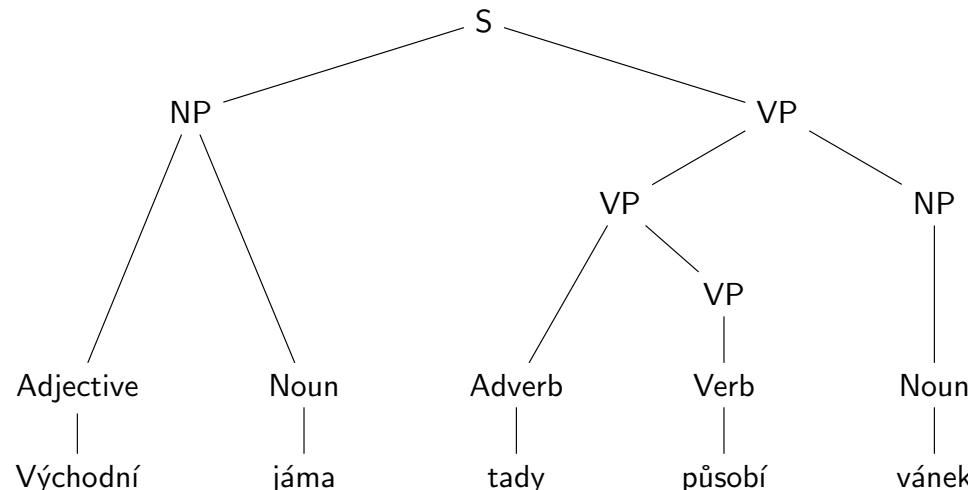
Gramatická pravidla pro agenta ve Wumpusově jeskyni

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

Syntaktický strom

syntaktický strom vzniká během **syntaktické analýzy** a dává **záznam**

o jejím průběhu:



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).
```

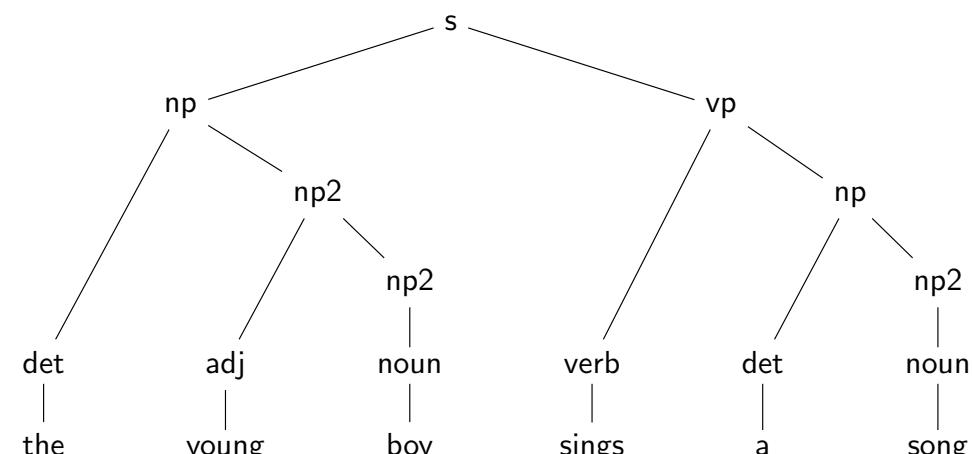
Převod do podoby klauzulí:

```
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**

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).`

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

?– `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 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

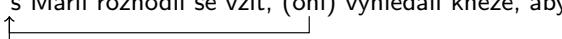
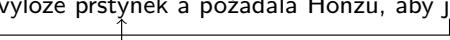
- ▶ *ambiguity*
- ▶ **víceznačnost** může být **lexikální, syntaktická, sémantická a referenční**
- ▶ lexikální – "stát," "žena," "hnát"
- ▶ syntaktická – "Jím špagety s masem."
"Jím špagety se salátem."
"Jím špagety s použitím vidličky."
"Jím špagety se sebezapřením."
"Jím špagety s přítelem."
- ▶ sémantická – "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 Shakespearea.”
“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

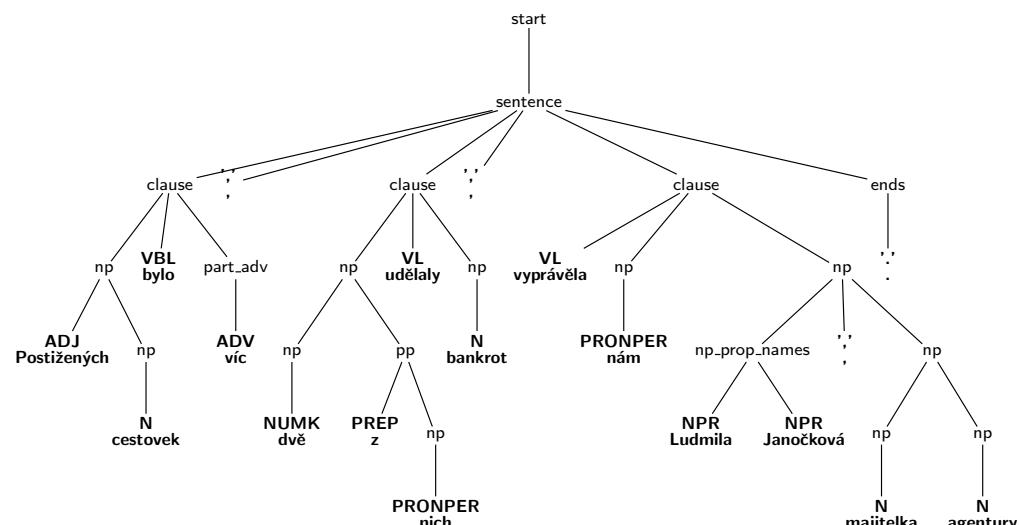
Obehnat Šalounův pomník mistra Jana Husa na pražském Staroměstském náměstí živým plotem z hustých keřů s trny navrhuje občanské sdružení Společnost Jana Jesenia.

- ▶ 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

