

Zpracování přirozeného jazyka

Aleš Horák

E-mail: hales@fi.muni.cz
<http://nlp.fi.muni.cz/uui/>

Obsah:

- Komunikace
- Gramatiky a syntaktická analýza
- 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**

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*

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 –

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 |

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

Obsah

1 Komunikace

- Přirozený jazyk – prostředek komunikace
- Řečové akty
- Komunikační fáze (při informování)

2 Gramatiky a syntaktická analýza

- Gramatiky pro analýzu jazyka
- Lexikon pro agenta ve Wumpusově jeskyni
- Syntaktický strom
- Test na shodu
- Syntaktická analýza pomocí strojového učení

3 Analýza přirozeného jazyka

- Význam syntaktické analýzy
- Problémy při analýze přirozeného jazyka
- Reálná syntaktická analýza přirozeného jazyka

4 PA026 – Projekt z umělé inteligence

Gramatiky a syntaktická analýza

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

$$S \rightarrow NP \quad VP$$

$$\text{Pronoun} \rightarrow já \mid ty \mid on \mid \dots$$

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 $a^n b^n c^n$

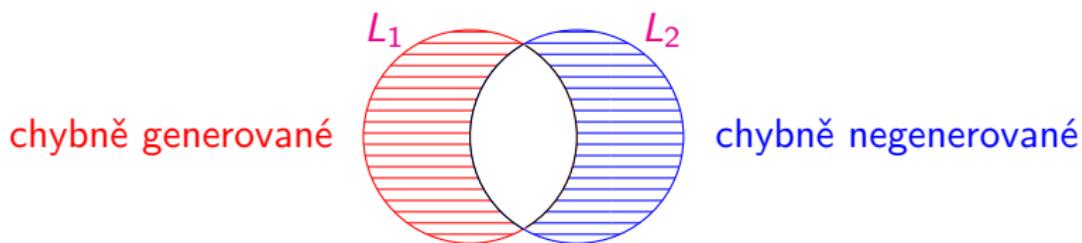
- rekurzivně vyčíslitelné (recursively enumerable) – bez omezení
ekvivalentní síle Turingova stroje

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 ($|L_1 \cap L_2|/|L_1|$)
- kombinová **F-míra** – harmonický průměr $2 \cdot \frac{\text{přesnost} \cdot \text{pokrytí}}{\text{přesnost} + \text{pokrytí}}$

tvorba gramatiky ... postupný proces zvyšování pokrytí a přesnosti gramatiky přirozených jazyků – velmi rozsáhlé a přesto většinou nepopisují plně ani angličtinu 😊

Gramatiky pro analýzu jazyka

využívané pro **syntaktickou analýzu**

- pro lokální varianty – **regulární** gramatiky (regulární výrazy, např. pro *extrakci informací*)
- pro vyjmenované větné struktury – **bezkontextové** gramatiky
- pro plný jazyk – **(mírně) kontextové** gramatiky
- praktické nástroje – většinou **rozšíření bezkontextových gramatik** (CFG):
 - Prolog – definite clause grammars, **DCG**
 - Java, Python – **ANTLR** (ANother Tool for Language Recognition)

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'.

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

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: *sl_druh(lemma, pád, číslo, rod) → slovo.*

adj('chytrý', '1', 'j', 'mž') → 'chytrý'.

adj('chytrý', '2', 'j', 'mž') → 'chytrého'.

adj('chytrý', '1', 'mn', 'mž') → 'chytrí'.

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: sl_druh(lemma, pád, číslo, rod) → slovo.

adj('chytrý', '1', 'j', 'mž') → 'chytrý'.

adj('chytrý', '2', 'j', 'mž') → 'chytrého'.

adj('chytrý', '1', 'mn', 'mž') → 'chytrí'.

- reálná morfologická analýza ČJ – program MAJKA 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

$S \rightarrow NP VP$	% 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:

Východní

jáma

tady

působí

vánek

Syntaktický strom

syntaktický strom vzniká během syntaktické analýzy a dává záznam o jejím průběhu:



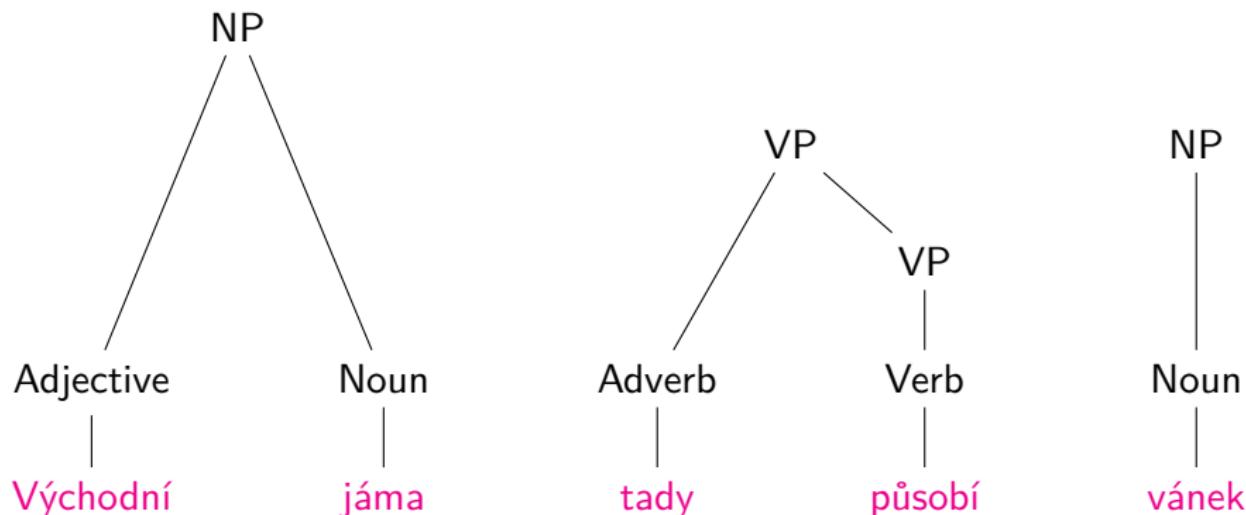
Syntaktický strom

syntaktický strom vzniká během syntaktické analýzy a dává záznam o jejím průběhu:



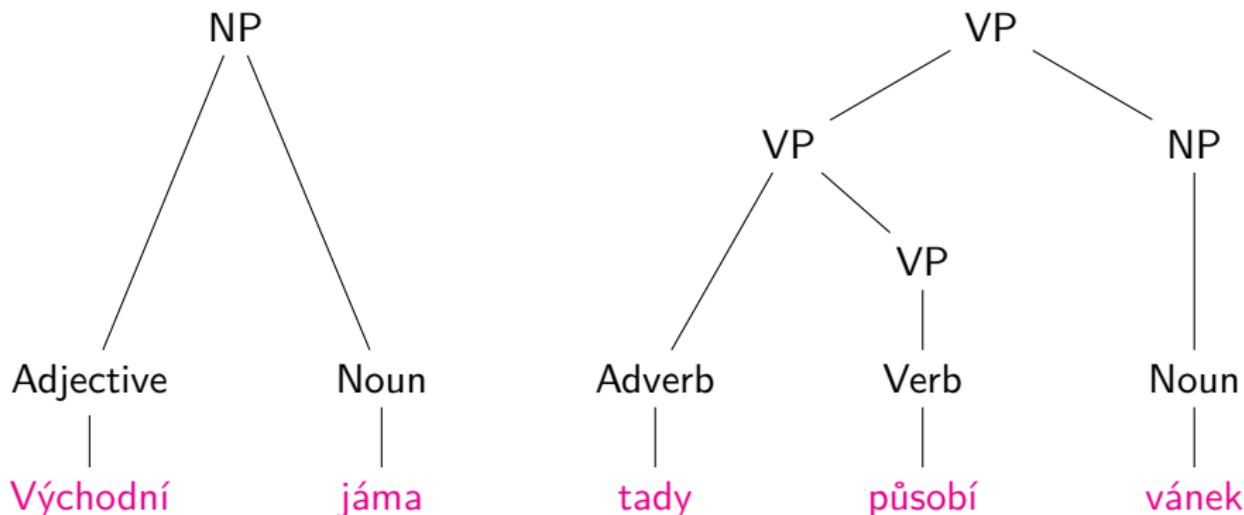
Syntaktický strom

syntaktický strom vzniká během syntaktické analýzy a dává záznam o jejím průběhu:



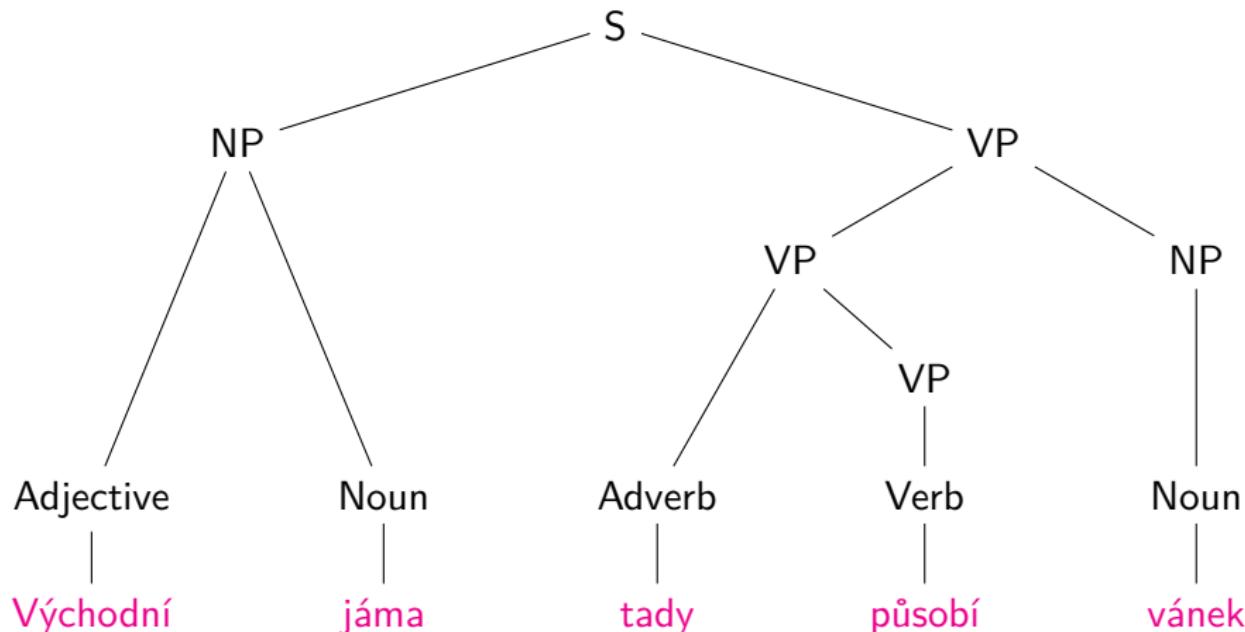
Syntaktický strom

syntaktický strom vzniká během syntaktické analýzy a dává záznam o jejím průběhu:



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).

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'.

Konstrukce derivačního stromu

Neterminály opatříme argumentem:

sentence(sentence(NP,VP)) → noun_phrase(NP), verb_phrase(VP).

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'.

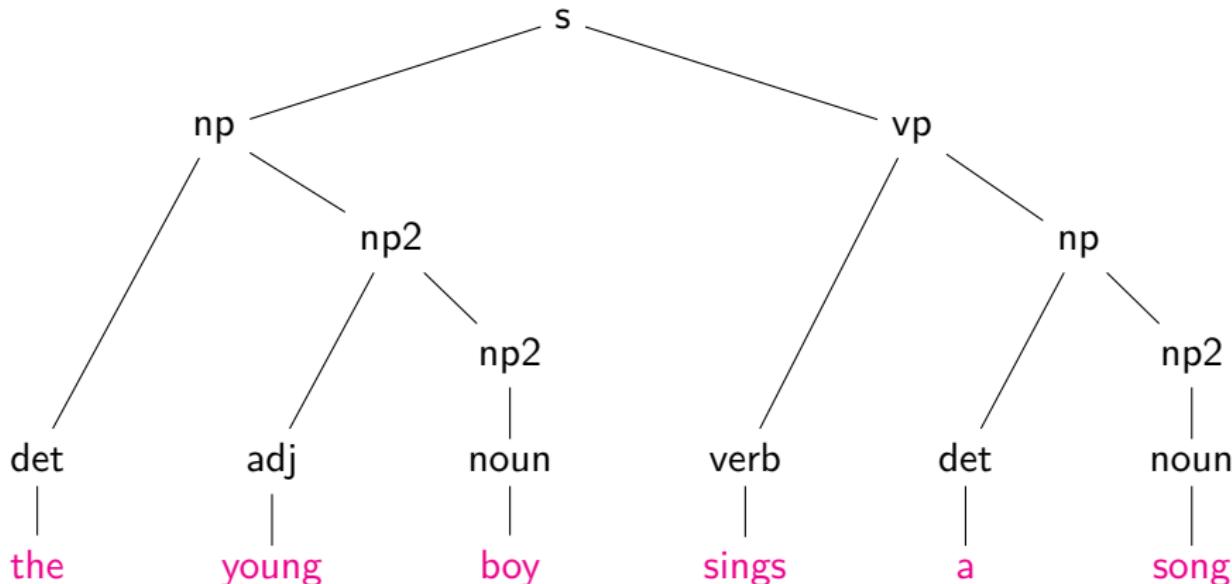
verb(verb(sings)) → 'sings'.

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 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']).  
True
```

```
sentence(_, [ 'a', 'boy', 'sing']).  
True
```

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']).  
True
```

```
sentence(_, [ 'a', 'boy', 'sing']).  
True
```

Proto rozšíříme neterminály o další argument **Num**, ve kterém můžeme testovat shodu:

```
sentence(sentence(NP,VP)) → noun_phrase(NP,Num), verb_phrase(VP,Num).
```

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) → 'sings'. noun(noun(boys),pl) → 'boys'.
verb(verb(sing),pl) → 'sing'. noun(noun(songs),pl) → 'songs'.
adjective(adj(young)) → 'young'.

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) → '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']).

False

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)	→ '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']).

False

sentence(_, ['the', 'boys', 'sings', 'a', 'song']).

False

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)	→ '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']).

False

sentence(_, ['the', 'boys', 'sings', 'a', 'song']).

False

sentence(_, ['the', 'boys', 'sing', 'a', 'song']).

True

Podmínky v těle pravidel

Gramatiky mohou mít pomocné **podmínky** v těle pravidel (kód)

CFG pro vyhodnocení aritmetického výrazu:

$$\begin{array}{l|l|l|l} E & \rightarrow & T + E & | \\ T & \rightarrow & F * T & | \\ F & \rightarrow & (E) & | \\ & & f & \end{array}$$

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)}.`

Podmínky v těle pravidel

Gramatiky mohou mít pomocné podmínky v těle pravidel (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)}.`

$3 + 4/2 - (2*6/3 + 2) = -1$

`expr([3, '+', 4, '/', 2, '-', '(', 2, '*', 6, '/', 3, '+', 2, ')'])`.

`X = -1`

Generativní síla gramatik

Generativní (rozpoznávací) síla analyzačních gramatik je často větší než CFG

např. jazyk $a^n b^n c^n$:

$abc \rightarrow a(N), b(N), c(N).$

$a(0) \rightarrow [] \# \epsilon$
 $a(s(N)) \rightarrow 'a', a(N).$

$b(0) \rightarrow []$.
 $b(s(N)) \rightarrow 'b', b(N).$

$c(0) \rightarrow []$.
 $c(s(N)) \rightarrow 'c', c(N).$

Generativní síla gramatik

Generativní (rozpoznávací) síla analyzačních gramatik je často větší než CFG

např. jazyk $a^n b^n c^n$:

$abc \rightarrow a(N), b(N), c(N).$

$a(0) \rightarrow [] \# \epsilon$
 $a(s(N)) \rightarrow 'a', a(N).$

$b(0) \rightarrow []$.
 $b(s(N)) \rightarrow 'b', b(N).$

$c(0) \rightarrow []$.
 $c(s(N)) \rightarrow 'c', c(N).$

$abc(X, [])$.

Generativní síla gramatik

Generativní (rozpoznávací) síla analyzačních gramatik je často větší než CFG

např. jazyk $a^n b^n c^n$:

$abc \rightarrow a(N), b(N), c(N).$

$a(0) \rightarrow [] . \quad \# \epsilon$
 $a(s(N)) \rightarrow 'a', a(N).$

$b(0) \rightarrow [] .$
 $b(s(N)) \rightarrow 'b', b(N).$

$c(0) \rightarrow [] .$
 $c(s(N)) \rightarrow 'c', c(N).$

$abc(X, []) .$

$X = []$

Generativní síla gramatik

Generativní (rozpoznávací) síla analyzačních gramatik je často větší než CFG

např. jazyk $a^n b^n c^n$:

$abc \rightarrow a(N), b(N), c(N).$

$a(0) \rightarrow [] . \quad \# \epsilon$
 $a(s(N)) \rightarrow 'a', a(N).$

$b(0) \rightarrow [] .$
 $b(s(N)) \rightarrow 'b', b(N).$

$c(0) \rightarrow [] .$
 $c(s(N)) \rightarrow 'c', c(N).$

$abc(X, []).$

$X = []$

$X = ['a', 'b', 'c']$

Generativní síla gramatik

Generativní (rozpoznávací) síla analyzačních gramatik je často větší než CFG

např. jazyk $a^n b^n c^n$:

$abc \rightarrow a(N), b(N), c(N).$

$a(0) \rightarrow [] . \quad \# \epsilon$
 $a(s(N)) \rightarrow 'a', a(N).$

$b(0) \rightarrow [] .$
 $b(s(N)) \rightarrow 'b', b(N).$

$c(0) \rightarrow [] .$
 $c(s(N)) \rightarrow 'c', c(N).$

$abc(X, []).$
 $X = []$
 $X = ['a', 'b', 'c']$
 $X = ['a', 'a', 'b', 'b', 'c', 'c']$

Generativní síla gramatik

Generativní (rozpoznávací) síla analyzačních gramatik je často větší než CFG

např. jazyk $a^n b^n c^n$:

$abc \rightarrow a(N), b(N), c(N).$

$a(0) \rightarrow [] . \quad \# \epsilon$
 $a(s(N)) \rightarrow 'a', a(N).$

$b(0) \rightarrow [] .$
 $b(s(N)) \rightarrow 'b', b(N).$

$c(0) \rightarrow [] .$
 $c(s(N)) \rightarrow 'c', c(N).$

$abc(X,[]).$

$X = []$

$X = ['a', 'b', 'c']$

$X = ['a', 'a', 'b', 'b', 'c', 'c']$

$X = ['a', 'a', 'a', 'b', 'b', 'b', 'c', 'c', 'c']$

...

Syntaktická analýza pomocí strojového učení

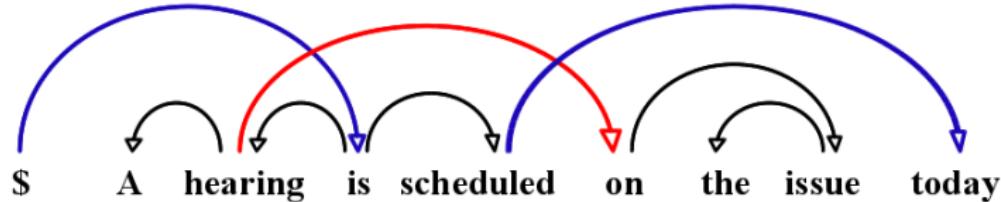
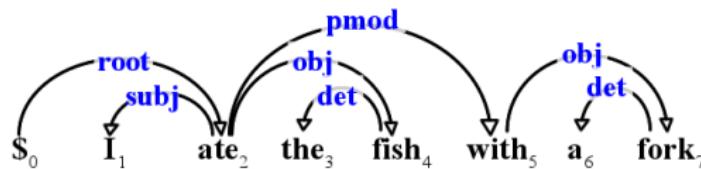
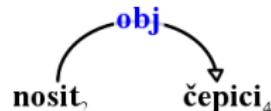
- využití **anotovaných stromových korpusů** (*treebanks*)
- lidé **anotují** textový korpus – doplní **syntaktické stromy**
- **strojové učení** hledá **pravidla/váhy** parametrů
- **univerzální** napříč jazyky (do jisté míry)
- anotování je **drahé**
- **modifikace** pro různé účely je obtížnější
- často **není dost dat**

Závislostní analýza

- jedna hrana pro každé slovo

- **hlava** – řídící slovo
- **závislé/rozvíjející** slovo – **modifikátor**
- **typ** – popisek hrany

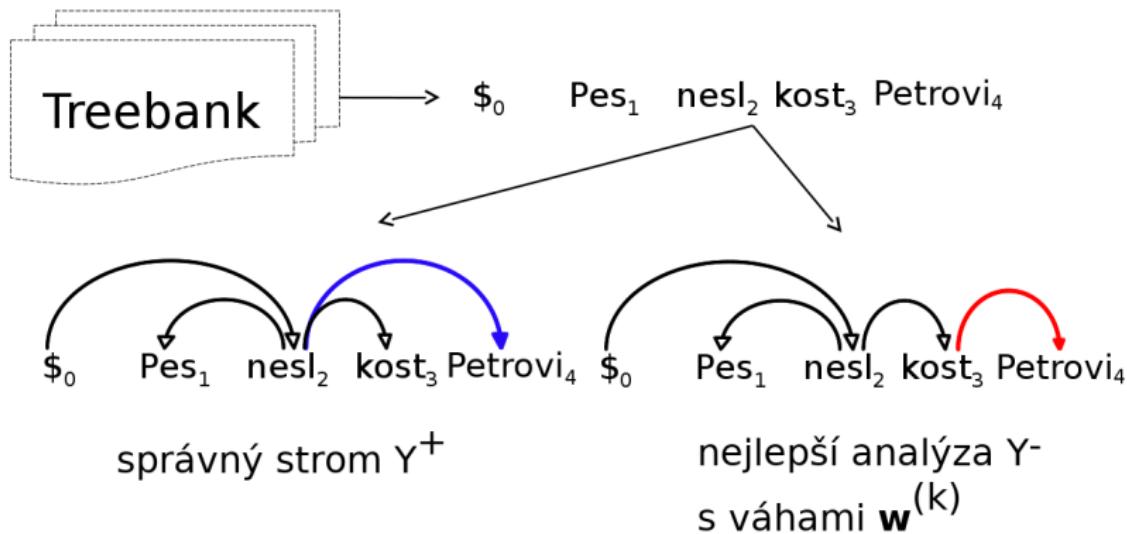
- obtížné pro **neprojektivní stromy**



Example from “Dependency Parsing” by Kübler, Nivre, and McDonald, 2009

Online učení skóre hrany

učení matici vah rysů w



$$\mathbf{w}^{(k+1)} = \mathbf{w}^{(k)} + \mathbf{f}(X, Y^+) - \mathbf{f}(X, Y^-)$$

Obsah

1 Komunikace

- Přirozený jazyk – prostředek komunikace
- Řečové akty
- Komunikační fáze (při informování)

2 Gramatiky a syntaktická analýza

- Gramatiky pro analýzu jazyka
- Lexikon pro agenta ve Wumpusově jeskyni
- Syntaktický strom
- Test na shodu
- Syntaktická analýza pomocí strojového učení

3 Analýza přirozeného jazyka

- Význam syntaktické analýzy
- Problémy při analýze přirozeného jazyka
- Reálná syntaktická analýza přirozeného jazyka

4 PA026 – Projekt z umělé inteligence

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

Víceznačnost

- *ambiguity*
- **víceznačnost** může být lexikální, syntaktická, sémantická a referenční
- lexikální – “stát,” “žena,” “hnát”

Víceznačnost

- *ambiguity*
- **víceznačnost** může být lexikální, syntaktická, sémantická a referenční
- lexikální – “stát,” “žena,” “hnát”
- syntaktická – “Jím špagety s masem.”

Víceznačnost

- *ambiguity*
- **víceznačnost** může být lexikální, syntaktická, sémantická a referenční
- lexikální – “stát,” “žena,” “hnát”
- syntaktická – “Jím špagety s masem.”
“Jím špagety se salátem.”

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.”

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.”

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.”

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.”

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

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.”

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.”



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.”

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.”

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

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.**”

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

Metafora a metonymie

metafora:

- *metaphor*
- použití slov v přeneseném významu (na základě podobnosti), často systematicky

“Zkoušel jsem ten proces zabít, ale nešlo to.”

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**.”

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

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**.”

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.”

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

Nekompozicionalita

- *noncompositionality*
- příklady porušení pravidla kompozicionality u ustálených termínů nebo přednost jiného možného významu při určitých spojeních
“aligátoří boty,” “basketbalové boty,” “dětské boty”

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”

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”

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”

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”

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”

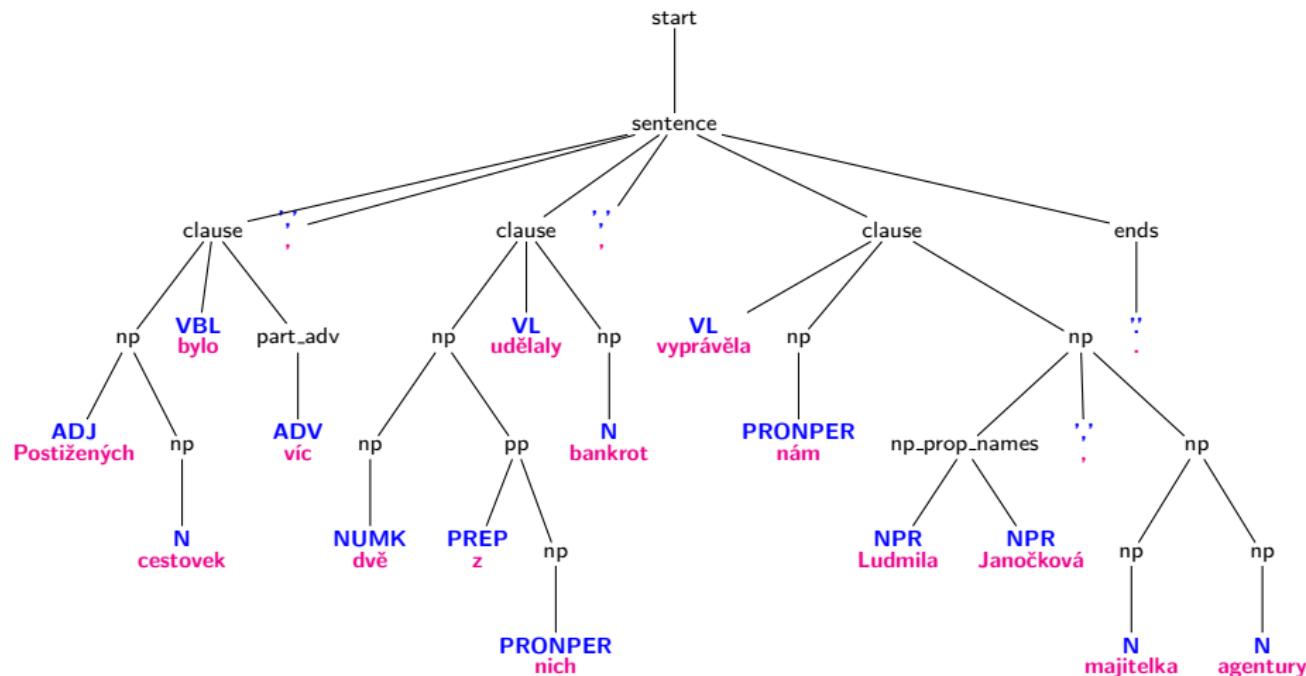
Reálná syntaktická analýza přirozeného jazyka

- 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



Příklad logické analýzy v systému synt

Když je pořádná zima s množstvím sněhu, ani velký nával návštěvníků přírodě příliš nevadí.

$$\begin{aligned}
 & \lambda w_1 \lambda t_2 \left[\mathbf{když_ani}_{w_1 t_2}, \right. \\
 & \quad \left. \lambda w_3 \lambda t_4 (\exists i_5) \left([\mathbf{pořádný}_{w_3 t_4}, i_5] \wedge [\mathbf{zima}_{w_3 t_4}, i_5] \wedge \right. \right. \\
 & \quad \left. \left. \left[[\mathbf{s}_{w_3 t_4}, [\mathbf{Of}, \mathbf{množství}, \mathbf{sníh}]]_{w_3 t_4}, i_5 \right] \right), \right. \\
 & \quad \left. \lambda w_6 \lambda t_7 \left[\mathbf{Not}, \left[\mathbf{True}_{w_6 t_7}, \lambda w_8 \lambda t_9 (\exists x_{10})(\exists i_{11})(\exists i_{12}) \left(\right. \right. \right. \right. \\
 & \quad \left. \left. \left. \left. [\mathbf{Does}_{w_8 t_9}, i_{12}, [\mathbf{Imp}_{w_8}, x_{10}]] \wedge [\mathbf{příroda}_{w_8 t_9}, i_{11}] \wedge \right. \right. \right. \right. \\
 & \quad \left. \left. \left. \left. x_{10} \subset [\mathbf{vadit}, i_{11}]_{w_8} \wedge [\mathbf{příliš}, x_{10}] \wedge \right. \right. \right. \right. \\
 & \quad \left. \left. \left. \left. \left[[\mathbf{velký}, [\mathbf{Of}, \mathbf{nával}, \mathbf{návštěvník}]]_{w_8 t_9}, i_{12} \right] \right) \right] \right] \dots o_{\tau\omega}
 \end{aligned}$$

NLP – Natural Language Processing

část umělé inteligence zaměřená na zpracování textu a řeči

Významné úkoly v NLP (předmět IA161)

- analýza textu v přirozeném jazyce – morfologická, syntaktická, sémantická
- generování textu v přirozeném jazyce
- syntéza a rozpoznávání řeči
- získávání informací (Information retrieval)
- extrakce informací (Information extraction, Text mining)
- určení typu dokumentu (Text classification/clustering)
- strojový překlad (Machine translation)
- odpovídání na otázky (Question answering)
- korektura textu (Spell-checking, Grammar checking)
- výtah z textu (Text summarization)
- určení stylu dokumentu/autora (Stylometry, Authorship attribution)
- porozumění (obsahu) textu (Natural language understanding)
- komunikace člověk-stroj (Man-machine communication, Chatbots)

Obsah

1 Komunikace

- Přirozený jazyk – prostředek komunikace
- Řečové akty
- Komunikační fáze (při informování)

2 Gramatiky a syntaktická analýza

- Gramatiky pro analýzu jazyka
- Lexikon pro agenta ve Wumpusově jeskyni
- Syntaktický strom
- Test na shodu
- Syntaktická analýza pomocí strojového učení

3 Analýza přirozeného jazyka

- Význam syntaktické analýzy
- Problémy při analýze přirozeného jazyka
- Reálná syntaktická analýza přirozeného jazyka

4 PA026 – Projekt z umělé inteligence

PA026 – Projekt z umělé inteligence

- navazuje na předmět *PB016 Úvod do umělé inteligence*
- volba programovacího jazyka není omezena
- samostatná volba tématu v rozsahu ≥ 1 semestru
- předmět probíhá jako prezentace a konzultace
- zajímavé výsledky (<http://nlp.fi.muni.cz/uiprojekt/>)
 - projekt **elnet** – > 5 let spolupráce na grantových projektech simulace elektrorozvodných sítí
 - projekt **plagiaty_z_webu** – vyhledávání shod s dokumenty na celém webu
 - projekt **robot_johnny_5** – sestavení a “oživení” robota – mobilního počítače
 - robot **Karel Pepper** – <https://nlp.fi.muni.cz/projects/pepper>

