

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

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

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 $a^n b^n c^n$

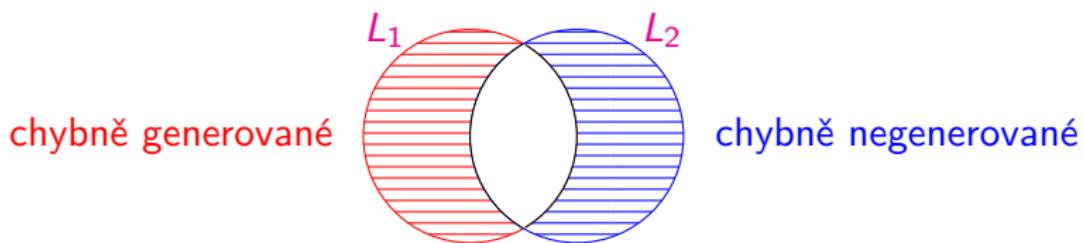
- rekurzivně vyčíslitelné (recursively enumerable) – bez omezení
ekvivalentní síle Turingova stroje

přirozený jazyk byl dlouho pokládán za bezkontextový → nyní prokázáno,
že obecně kontextový je.

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

- ▶ 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

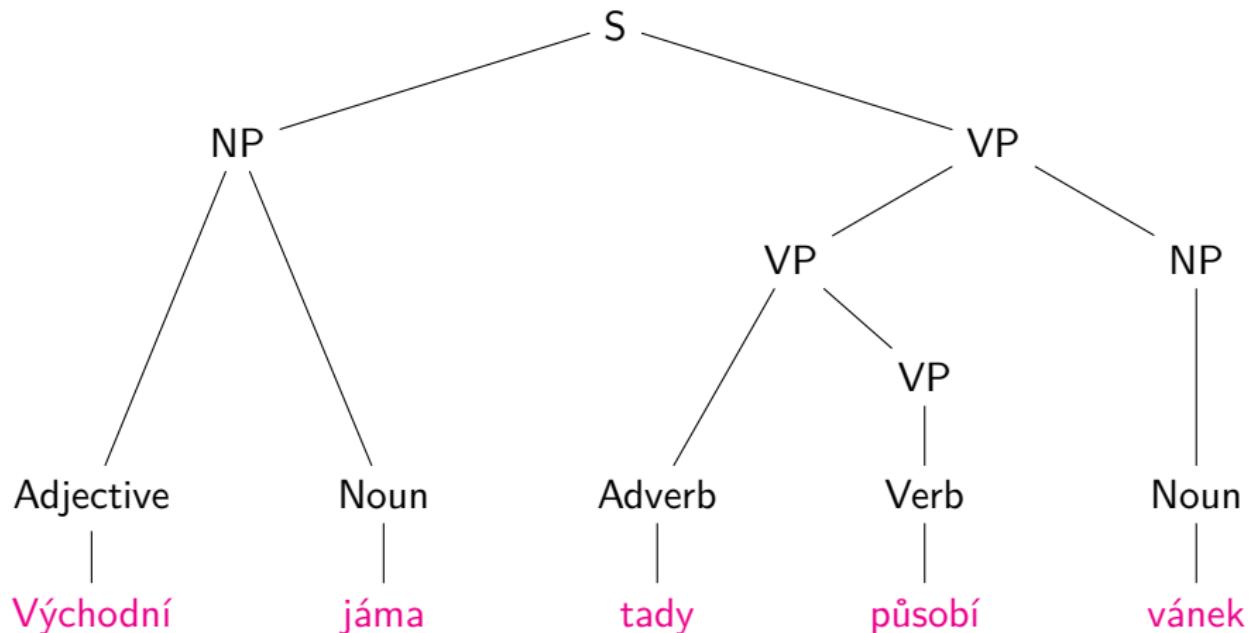
ajka>hnát	<s> ==hná=t= (618)
	<l>hnát
	<c>k5eAmFaI
	<s> =hnát==== (1030)
	<l>hnát
	<c>k1gInSc1,k1gInSc4

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:



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'.`

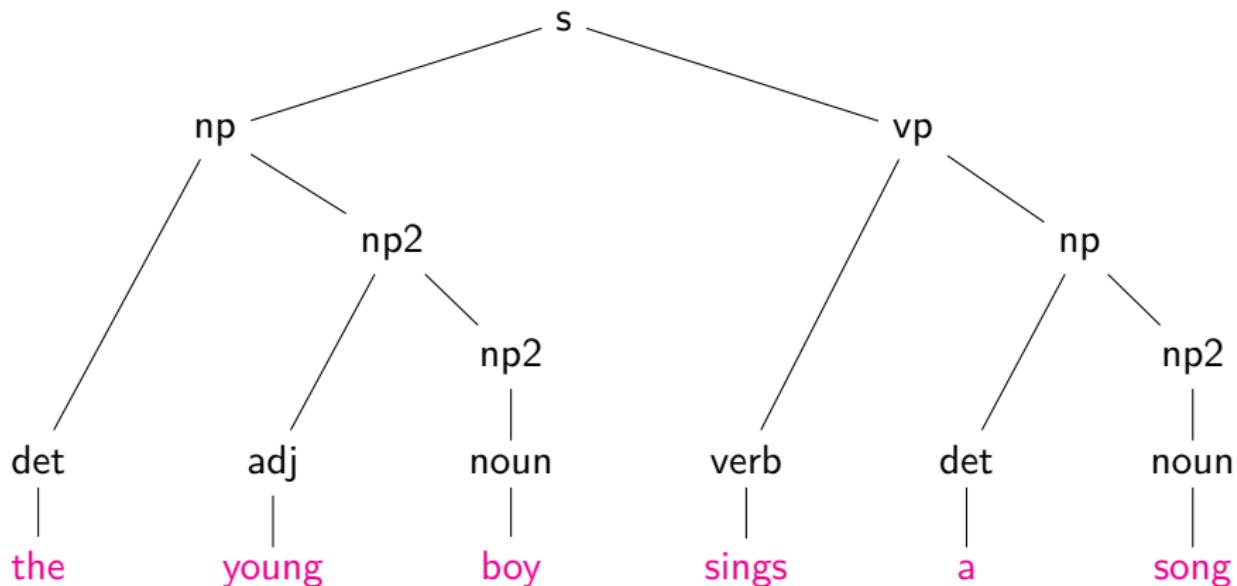
`sentence(Tree, ['the', 'young', 'boy', 'sings', 'a', 'song'])`

`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`

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'.		

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:

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

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

`X = -1`

Generativní síla gramatik

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

např. jazyk $a^n b^n c^n$:

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

$a(0) \rightarrow [] \quad \# \epsilon$

$a(s(N)) \rightarrow 'a', a(N).$

$b(0) \rightarrow [].$

$b(s(N)) \rightarrow 'b', b(N).$

$c(0) \rightarrow [].$

$c(s(N)) \rightarrow 'c', c(N).$

$abc(X,[]).$

$X = []$

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

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

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

...

Syntaktická analýza pomocí strojového učení

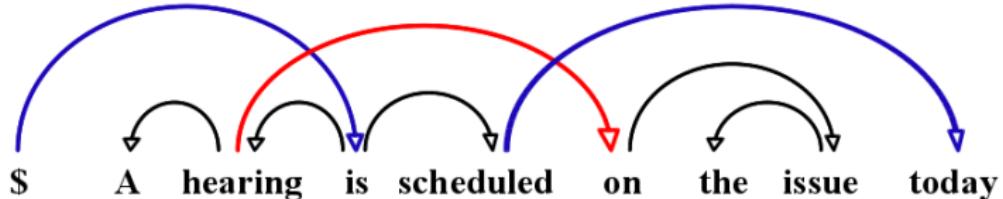
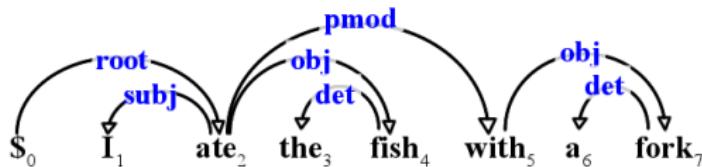
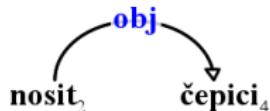
- ▶ využití **anotovaných stromových korpusů** (*treebanks*)
- ▶ lidé **anotují** textový korpus – doplní **syntaktické stromy**
- ▶ **strojové učení** hledá **pravidla/váhy** parametrů
- ▶ **univerzální** napříč jazyky (do jisté míry)
- ▶ anotování je **drahé**
- ▶ **modifikace** pro různé účely je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

Závislostní analýza

► jedna hrana pro každé slovo

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

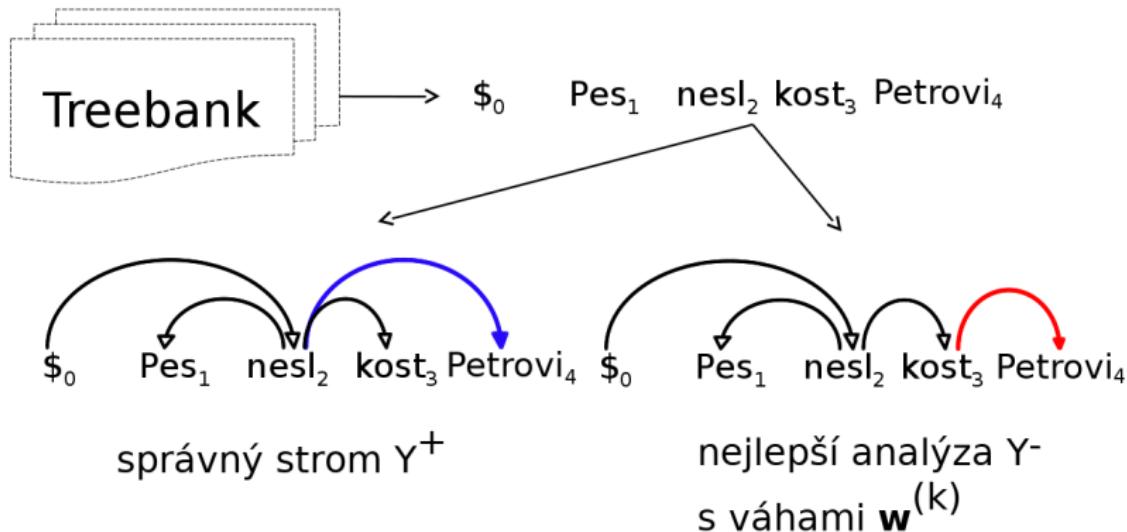
► obtížné pro **neprojektivní stromy**



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

Online učení skóre hrany

učení matici vah rysů w



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

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

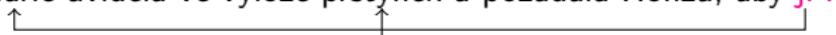
anaforické výrazy:

- ▶ *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** 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”

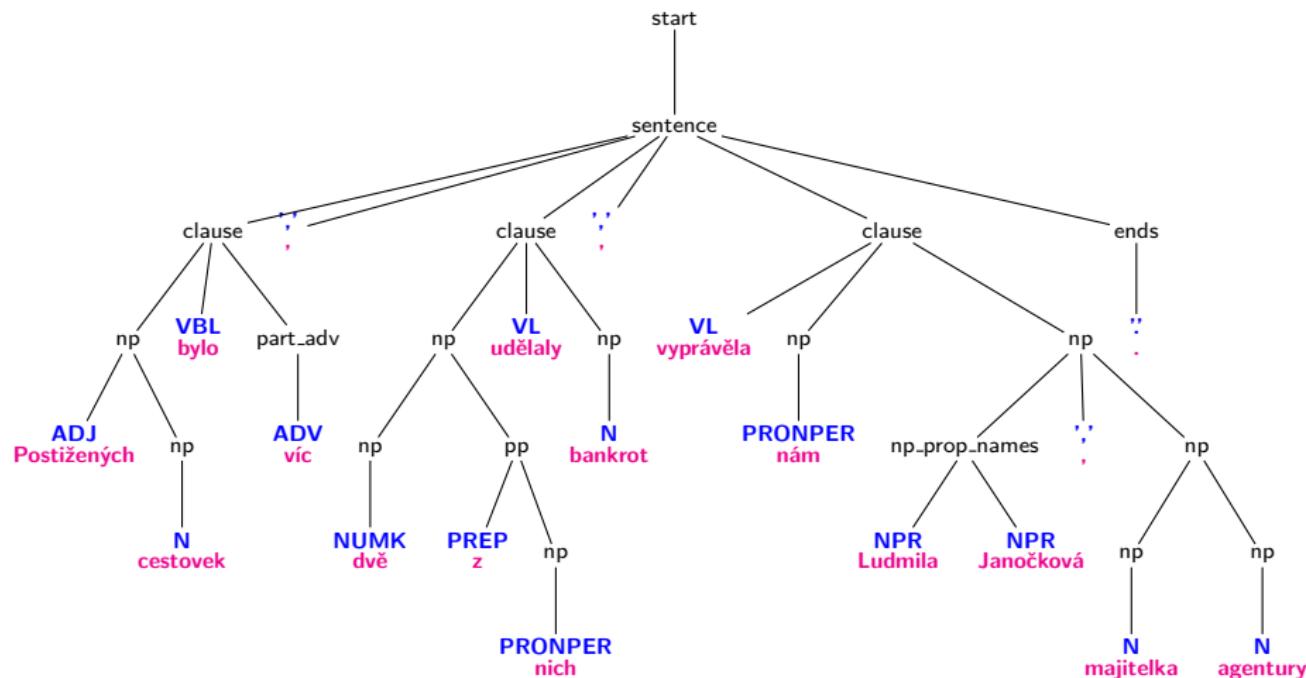
Reálná syntaktická analýza přirozeného jazyka

- ▶ velice **rozsáhlé gramatiky** (desítky až stovky tisíc pravidel)
- ▶ **silná víceznačnost** – někdy až obrovské množství (>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.

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

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)

<https://beta.openai.com/playground>

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>

