Gramatické formalismy pro ZPJ

Aleš Horák

E-mail: hales@fi.muni.cz
http://nlp.fi.muni.cz/poc_lingv/

Obsah:

- Gramatické formalismy
- Kategoriální gramatiky
- Závislostní gramatiky
- Stromové gramatiky TAG a LTAG
- Lexikální funkční gramatiky LFG

Gramatické formalismy

- existuje velké množství různých přístupů k formální specifikaci gramatik (přirozených jazyků), různé **gramatické formalismy**
- popíšeme několik nejrozšířenějších formalismů:
  - kategoriální gramatiky – categorial grammars, CG
  - závislostní gramatiky – dependency grammars
  - stromové gramatiky – (Lexicalized) Tree Adjoining Grammar, (L)TAG
  - lexikální funkční gramatiky – Lexical Functional Grammar, LFG
  - gramatiky příznakových struktur – Head Phrase Structure Grammar, HPSG
- soustředíme se jen na **zápis gramatiky** (notaci)

Kategoriální gramatiky

- **kategoriální gramatika** (categorial grammar, CG) – skupina teorií syntaxe a sémantiky PJ s velkým důrazem na **lexikon**
- neobsahuje *pravidla* pro kombinování slov → **lexikální kategorie** slov tvoří **funkce**, které určují, jak se dané kategorie kombinují s jinými výraz je výsledkem **aplikace podvýrazů na sebe**

  pěkný := NP/N ... funkce, která má argument N a vrací NP

- všechny verze CG se opírají o **princip kompozicionality**: *Význam složeného výrazu je jednoznačně určen významy částí tohoto výrazu a způsobem, jakým jsou tyto části složeny dohromady.*
- **zakladatelé** generativních gramatik – Leśniewski (publ. 1929) a Ajdukiewiczem (publ. 1935) ve vazbě na Husserlovu a Russellovu teorii kategorií a teorii typů
- první použití kategoriálních gramatik pro **popis přirozeného jazyka** – Bar-Hillel, Yehoshua 1953

Notace kategoriálních gramatik

- existuje několik různých variant notace

$$\dfrac{\dfrac{\underline{\texttt{šikovní}}\ \ \underline{\texttt{psi}}}{\dfrac{NP/N \quad N}{NP}\,>} \qquad \dfrac{\underline{\texttt{mají rádi}}\ \ \underline{\texttt{kočky}}}{\dfrac{(S\backslash NP)/NP \quad NP}{S\backslash NP}\,>}}{S}\,<$$

- jiný rozšířený zápis – **výsledek na vrcholku** (result on top) Lambek 1958

$$\dfrac{\dfrac{\underline{\texttt{šikovní}}\ \ \underline{\texttt{psi}}}{\dfrac{NP/N \quad N}{NP}\,>} \qquad \dfrac{\underline{\texttt{mají rádi}}\ \ \underline{\texttt{kočky}}}{\dfrac{(NP\backslash S)/NP \quad NP}{NP\backslash S}\,>}}{S}\,<$$

Notace kategoriálních gramatik – pokrač.

kategoriální gramatika je šestice $\langle \Sigma, C_{base}, C, Lex, RS, C_{complete} \rangle$, kde

1. Σ je konečná množina **slov**
2. C_{base} je konečná množina **základních kategorií** (funkčních typů)
3. C je množina **kategorií** definovaná induktivně takto:
   a) $C_{base} \subseteq C$
   b) pokud $X, Y \in C$, potom i $(X/Y) \in C$ a $(X\backslash Y) \in C$
   c) C obsahuje pouze prvky dané výše uvedenými body a) a b)
4. $Lex \subseteq \Sigma \times C$ je konečná množina – **lexikon** (zapisujeme v indexovém tvaru $\texttt{slovo}_{kategorie}$)
5. RS je množina následujících **schémat pravidel**:
   a) $\alpha_{(X/Y)} \circ \beta_{(Y)} \rightarrow \alpha\beta_{(X)}$
   b) $\beta_{(Y)} \circ \alpha_{(X\backslash Y)} \rightarrow \beta\alpha_{(X)}$,
   kde $\alpha, \beta \in \Sigma$ a $X, Y \in C$
6. $C_{complete} \subseteq C$ je množina **dokončených (kompletních) kategorií**

Notace kategoriálních gramatik – pokrač.

- daná schémata umožňují 2 způsoby kombinace:
  - argument **vpravo** (/) – $\alpha_{(X/Y)} \circ \beta_{(Y)} \rightarrow \alpha\beta_{(X)}$
  - argument **vlevo** ($\backslash$) – $\beta_{(Y)} \circ \alpha_{(X\backslash Y)} \rightarrow \beta\alpha_{(X)}$
- tento typ kategoriální gramatiky označoval Bar-Hillel jako **obousměrný** (bidirectional CG)
- `Karel miluje Marii`:
  - bázové kategorie $= \{NP, S\}$
  - kategorie z lexikonu: $\texttt{Karel}_{(NP)}$, $\texttt{Marii}_{(NP)}$, $\texttt{miluje}_{((S\backslash NP)/NP)}$
  - $C_{complete} = \{S\}$
- v tomto tvaru je odvození **ekvivalentní derivačním stromům** CFG
- existují ale **rozšíření kategoriálních gramatik**, která vedou k systémům s vyšší vyjadřovací silou, než mají standardní CFG

Rozšíření kategoriálních gramatik

- klíčový problém – nespojité větné části, tzv. **neprojektivity**
- řešení pomocí rozšíření CG – přídavné **kombinatorické operátory** založené na **typech**
- dva možné přístupy:
  - pravidlově orientovaný přidává pravidla odpovídající jednoduchým operacím nad kategoriemi, jako jsou:
    - **wrap** – komutace argumentů
    - **type-raising** – aplikace typů podobná aplikaci tradičních pádů na jmenné fráze
    - **comp** – kompozice funkcí

    k nejpropracovanějším systémům tohoto typu patří **kombinatorické kategoriální gramatiky** (CCG).
  - deduktivní přístup vychází z Lambekova syntaktického kalkulu
    - pohled na kategoriální lomítko (slash) jako formu **logické implikace**
    - axiomy a inferenční pravidla potom definují **teorii důkazu**
      např. *aplikace funkce* $\approx$ pravidlo *modus ponens* $P \wedge (P \Rightarrow Q) \Rightarrow Q$

OpenCCG library – `http://openccg.sourceforge.net/`

Závislostní gramatiky

- blízko ke kategoriálním gramatikám – vztah **závislosti** mezi **řídícími** a **závislými** větnými členy
- vhodné pro popis jazyků s volným slovosledem
- používají výhradně **lexikalizovaných uzlů** (v závislostním stromu) – neexistují žádné neterminály
  $\rightarrow$ závislostní analýza se jeví *jednodušší*
- využívá **valence** či subkategorizace – vztah mezi jedním slovem a jeho argumenty
  typicky vztah mezi slovesem a jeho možnými doplněními:

```
nosit
= koho|co
= komu & koho|co
```

Závislostní gramatiky – pokrač.

hlavní přístupy:

- navazuje na evropskou lingvistickou tradici – až k antice
- nejstarší užití – Tesnière 1959
- **funkční generativní popis** (*Functional Generative Description*, FGD) – jeden z nejpropracovanějších závislostních systémů, pražská lingvistická škola (Sgall, Hajičová, Panevová)
- UDG, *Unification Dependency Grammar* – Maxwell
- MTT, *Meaning-Text Theory* – Mel'čuk
- WG, *Word Grammar* – Hudson
- Lexicase – Starosta
- FG, *Functional Grammar* – Dik
- LG, *Link Grammar* – Temperley, Carnegie Mellon University `http://www.link.cs.cmu.edu/link/`
- DUG, *Dependency Unification Grammar* – Halliday

Stromové gramatiky TAG a LTAG

- Tree Adjoining Grammar – Joshi, Levy a Takahashi: *TAG Formalism*, 1975
  Lexicalized TAG – Joshi a Schabes: *Parsing with Lexicalized TAG*, 1991
- pracují přímo se **stromy** a ne s řetězci slov
- množina **počátečních stromů** – základní stavební prvky
- složitější věty odvozovány s použitím **pomocných stromů**

počáteční (*initial*) strom:

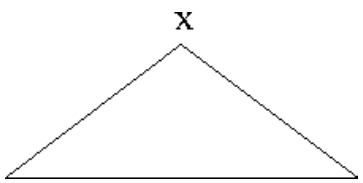

pomocný (*auxiliary*) strom:

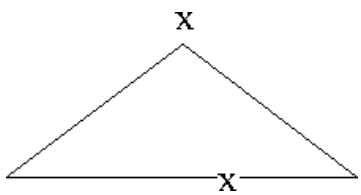

TAG – počáteční a pomocné stromy

- **počáteční stromy** – neobsahují rekurzi → popisují složkovou strukturu jednoduchých vět, jmenných skupin, předložkových skupin, ...
  1. všechny **nelistové uzly** odpovídají *neterminálům*
  2. všechny **listové uzly** odpovídají *terminálům* nebo *neterminálním* uzlům určeným k *substituci*

  počáteční strom typu X = jeho kořen je označen termem X
- **pomocné stromy** – reprezentují *rekurzivní struktury*
  popisují větné členy, které se **připojují** k základním strukturám (např. příslovečné určení)
- charakterizace:
  1. všechny **nelistové uzly** odpovídají *neterminálům*
  2. všechny **listové uzly** odpovídají *terminálům* nebo *neterminálním* uzlům určeným k *substituci* kromě právě jednoho neterminálního uzlu (**patový uzel**, *foot node*)
  3. **patový uzel** má stejné označení jako kořenový uzel

  patový uzel – slouží k připojení stromu k jinému uzlu

TAG – operace

dvě operace – **substituce** a **připojení** (*adjunction*)
operace **substituce** – nahrazuje označený neterminál v listech nějakého stromu stromem, jehož kořen nese stejné označení

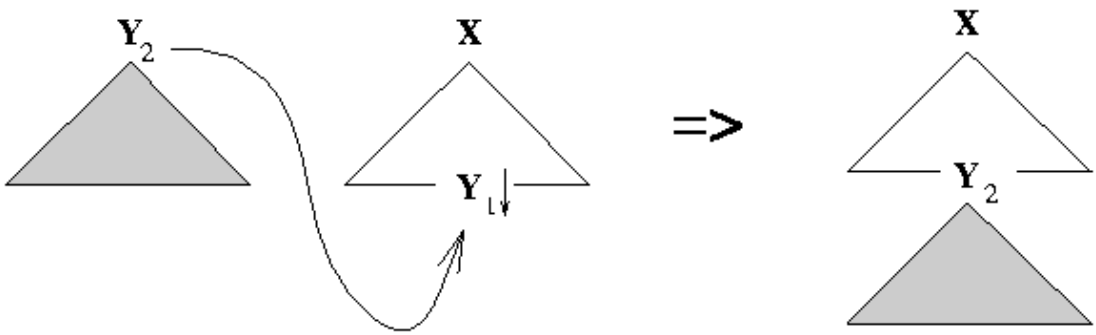

$Y_1\downarrow$ – označený pro substituci

TAG – operace připojení

operace **připojení** – vložení pomocného stromu, popisujícího rekurzi neterminálu X, se stromem, který obsahuje uzel označený rovněž X

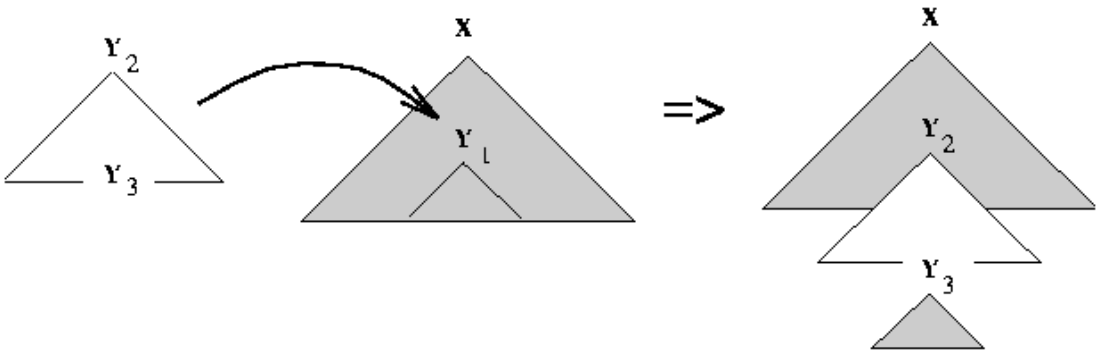

Definice TAG

- **TAG** $G = (I, A, S)$ je:
  - množina I konečných počátečních stromů
  - množina A pomocných stromů
  - typ stromu S – neterminál označující větu
- **množina stromů** $\mathcal{T}(G)$ TA gramatiky G = množina všech stromů odvoditelných z počátečních stromů typu S z I, jejichž spodní okraj sestává čistě z terminálních uzlů (všechny substituční uzly byly doplněny)
- **jazyk řetězců** $\mathcal{L}(G)$ generovaných TA gramatikou G = množina všech terminálních řetězců na spodním okraji stromů v $\mathcal{T}(G)$.

LTAG – lexikalizace

LTAG je **lexikalizovanou variantou** formalismu TAG
→ počáteční i pomocné stromy obsahují v listech jednu nebo více tzv. **lexikálních kotev** – uzly, které jsou přiřazeny (ukotveny) k určitým slovům lexikonu

lexikalizované stromy (*substituční uzly* – ↓, *patové uzly* – *):

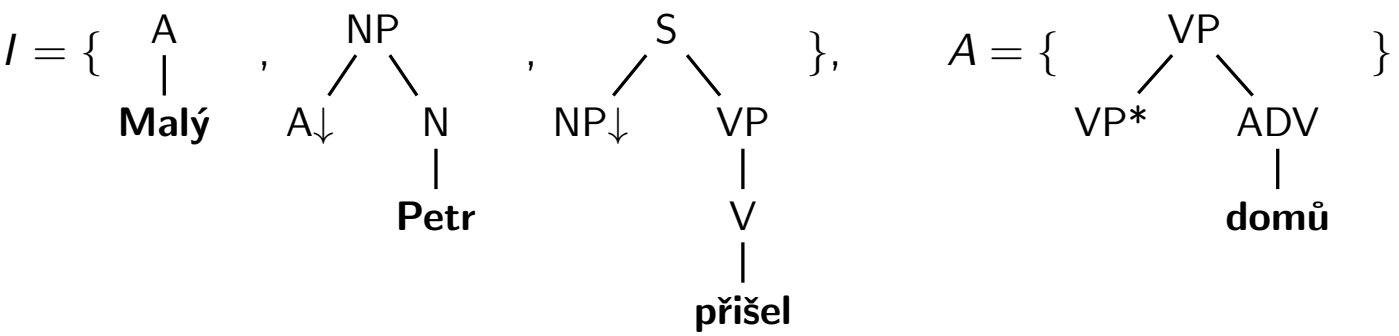

LTAG – lexikalizované připojení

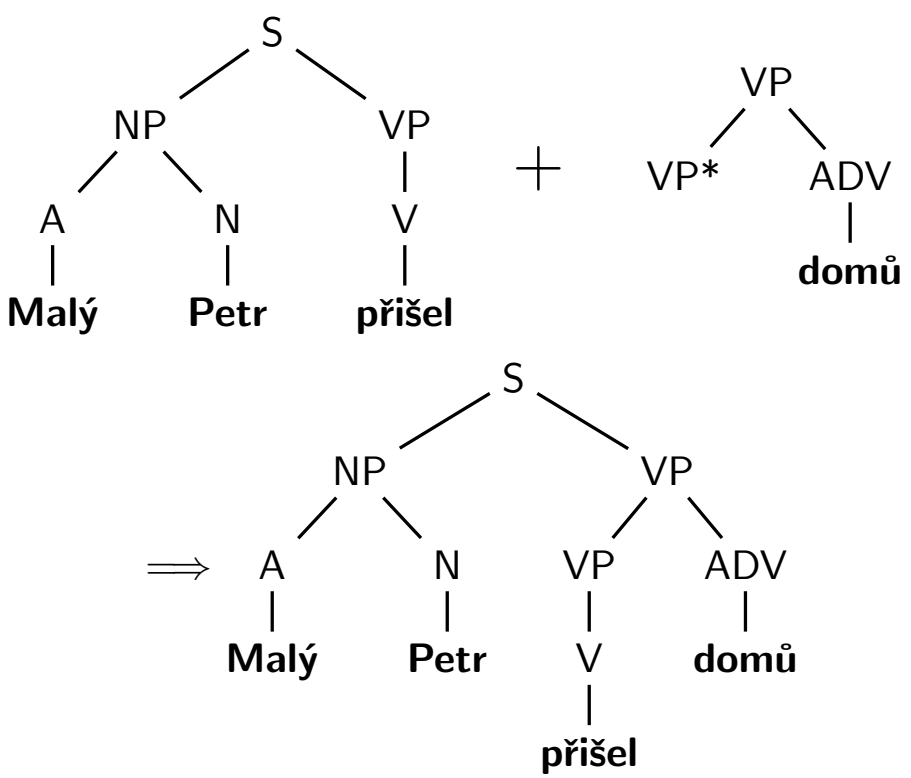

TAG a LTAG – generované jazyky

- díky použití operace připojení mají TAG a LTAG **větší generativní sílu** než bezkontextové gramatiky (CFG $\subset$ MCSL) $\rightarrow$ generují **mírně kontextové jazyky** (*mildly context-sensitive languages*)
  MCSL:
  - vlastnost **konstantního růstu** – pokud uspořádáme řetězce jazyka vzestupně podle délky, potom rozdíl dvou po sobě jdoucích délek nemůže být libovolný (každá délka je lineární kombinací konečného počtu pevných délek).
  - analyzovatelnost v **polynomiálním čase** $O(n^6)$ vzhledem k délce vstupu
- i jiné formalismy umí MCSL (jsou ekvivalentní s (L)TAG):
  - LIG, *Linear Indexed Grammars* – Gazdar, 1985
  - HG, *Head Grammars* – Pollard, 1984
  - CCG, kombinatorické kategoriální gramatiky

The XTAG Project – `http://www.cis.upenn.edu/~xtag/`

Lexikální funkční gramatiky LFG

- LFG, *Lexical Functional Grammar* – Kaplan a Bresnan, 1982
- dva typy syntaktických struktur
  - **vnější**, **c-struktura** – viditelná hierarchická organizace slov do frází
  - **vnitřní**, **f-struktura** – abstraktnější struktura gramatických funkcí, které tvoří hierarchii komplexních funkčních struktur

  důvod:
  - různé přirozené jazyky se významným způsobem odlišují v **organizaci fráze**, v pořadí a způsobech realizace gramatických funkcí
  - abstraktnější, **funkcionální** organizace jazyků se odlišuje mnohem méně v mnoha jazycích se např. objevují gramatické funkce *podmětu*, *předmětu* atd.

Lexikální funkční gramatiky LFG – pokrač.

- L = vztahy mezi jazykovými formami, např. mezi aktivními a pasivními formami slovesa, jsou zobecněním struktury **lexikonu**, ne transformačními operacemi, derivujícími jednu formu z druhé
- F = **funkcionální teorie** – gramatické vztahy, jako je podmět, předmět atd., jsou základními konstrukty, a nejsou definovány pomocí konfigurace frázové struktury, nebo sémantických pojmů typu Agent a Patient
- v LFG – pro reprezentaci funkcionální syntaktické informace je vhodné definovat hierarchickou strukturu jazykových jednotek, avšak vynucená linearizace pořádku těchto struktur není vhodná

Syntaktické úrovně LFG

- dvě syntaktické úrovně:
  - **složková struktura** (*c-structure*, *constituent structure*) – zachycuje frázovou dominanci a prioritu a je reprezentována jako **strom** frázové struktury (CFG strom)
  - **funkcionální struktura** (*f-structure*) – zachycuje syntaktickou strukturu typu predikát-argumenty a je reprezentována *maticí* dvojic *atribut-hodnota*
    nabízí jednotnou reprezentaci syntaktické informace abstrahující od detailů struktury fráze a lineárního pořádku

  f-struktura obsahuje soubor atributů:
  - **příznaky** – čas, rod, číslo, ...
  - **funkce** – PRED, SUBJ, OBJ, jejichž hodnoty mohou být jiné f-struktury
- vztah mezi c-strukturami (stromy) a odpovídajícími f-strukturami:

$$\text{projekce} \quad \phi : \{\text{uzly stromu c-struktury}\} \rightarrow \{\text{f-struktury}\}$$

LFG – c-struktura

LFG pravidla:

- klasická CF pravidla
- plus **funkční schémata** – výrazy pracující se symboly na pravé straně pravidel (za $\rightarrow$, RHS)

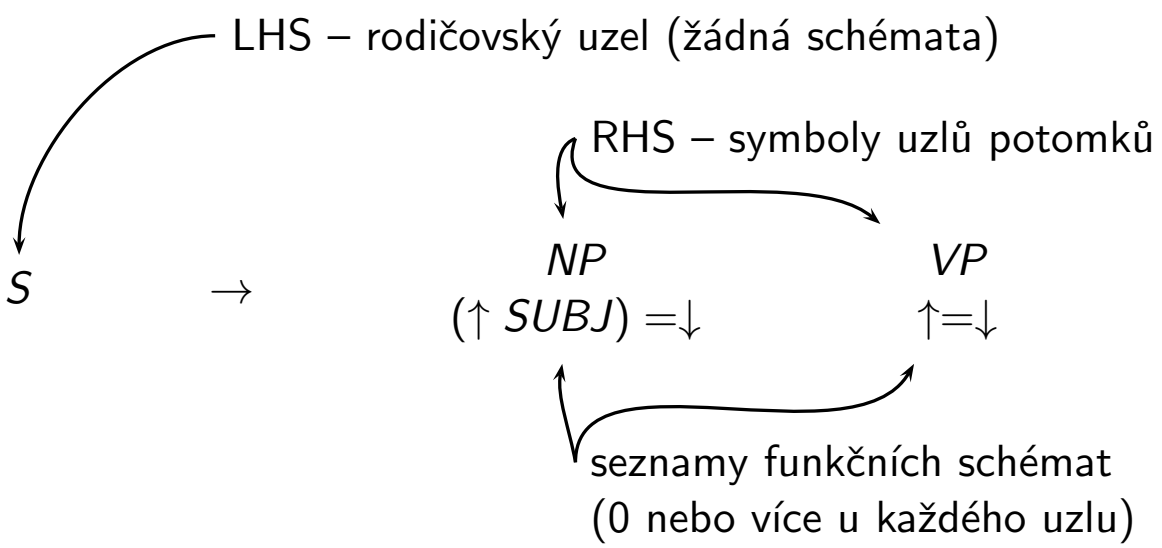

LFG – pravidla

příklady:

$$\begin{array}{lcc} \text{S} \rightarrow & \text{NP} & \text{VP} \\ & (\uparrow \text{SUBJ}) = \downarrow & \uparrow = \downarrow \end{array}$$

$$\begin{array}{lcc} \text{VP} \rightarrow & \text{V} & (\text{NP}) \\ & \uparrow = \downarrow & (\uparrow \text{OBJ}) = \downarrow \end{array}$$

$$\begin{array}{lcc} \text{NP} \rightarrow & (\text{DET}) & \text{N} \\ & \uparrow = \downarrow & \uparrow = \downarrow \end{array}$$

výrazy $(\uparrow \text{SUBJ}) = \downarrow$, $\uparrow = \downarrow$ a $(\uparrow \text{OBJ}) = \downarrow$ jsou *funkční schémata*

LFG – lexikon

lexikon také obsahuje **funkční schémata**

položka lexikonu:

1. konkrétní tvar slova
2. syntaktickou kategorii
3. seznam funkčních schémat

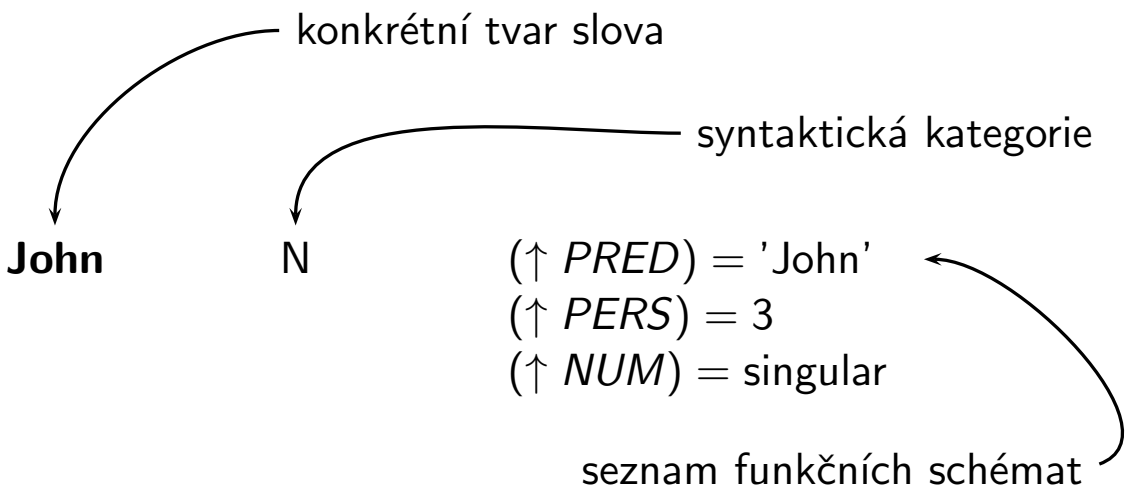

LFG – lexikon – pokrač.

příklady:

John	N	(↑ PRED)	=	'JOHN'
		(↑ NUM)	=	SING
		(↑ PERS)	=	3
sees	N	(↑ PRED)	=	'SEE<(↑SUBJ)(↑OBJ)>'
		(↑ SUBJ NUM)	=	SING
		(↑ SUBJ PERS)	=	3
Mary	N	(↑ PRED)	=	'MARY'
		(↑ NUM)	=	SING
		(↑ PERS)	=	3

XLE web interface –
`http://decentius.aksis.uib.no/logon/xle.xml`

LFG – konstrukce c-struktury

informace v c-struktuře:

- hierarchická struktura větných členů
- **funkční anotace** (funkční schémata převedená do stromu) – po jejich *interpretaci* získáme výslednou f-strukturu

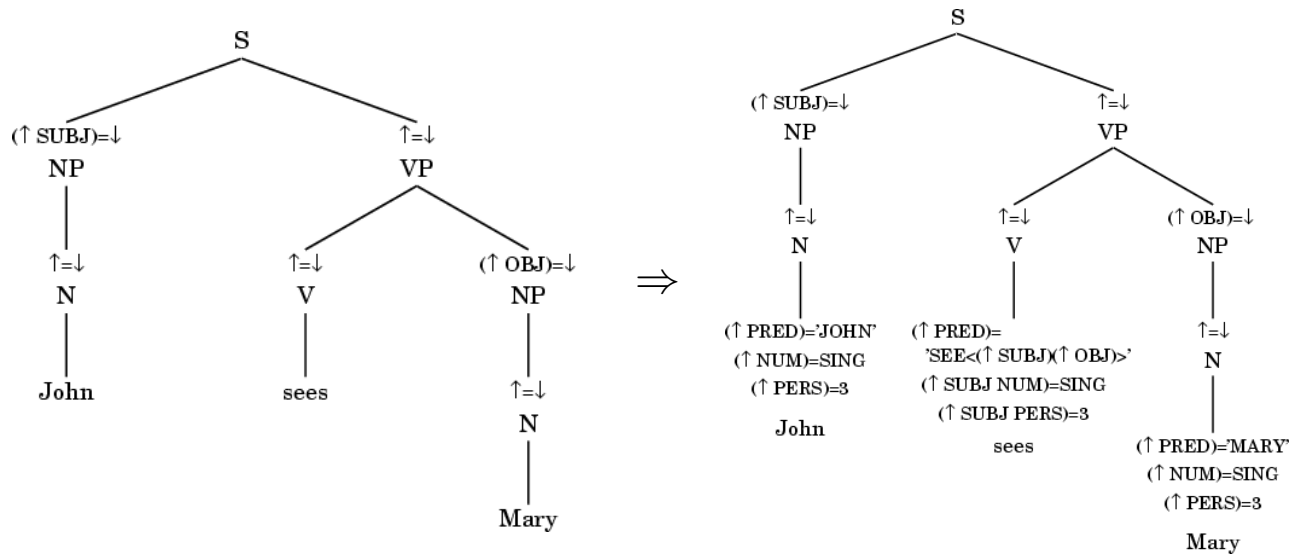

LFG – f-struktura

grafický zápis:

$$f_n \begin{bmatrix} \text{A} & f_m \begin{bmatrix} \text{B} & \text{C} \\ \text{D} & \text{E} \end{bmatrix} \\ \text{F} & \text{G} \\ \text{H} & \text{I} \end{bmatrix}$$

matice atribut-hodnota (*attribute-value matrix*, AVM) – levé sloupce jsou atributy, pravé sloupce hodnoty (symboly, podřazené f-struktury nebo sémantické formy)

funkční rovnice a f-struktury:

$(f_p \text{ ATT}) = \text{VAL}$

v f-struktuře f_p je řádek, kde
atribut je **ATT**
a jeho hodnota je **VAL**

funkční rovnice mohou být **splněny** nebo **nesplněny** (*true*/*false*)

LFG – instanciace hodnot

Instanciace hodnot

- doplňuje hodnoty metaproměnných ↑ a ↓
- transformuje schémata na **funkční rovnice** – výrazy získané z f-struktur

grafický zápis – f-struktura v hranatých závorkách []

každý *uzel c-struktury* má k sobě připojenou *matici f-struktury*, které se označují indexy f_i

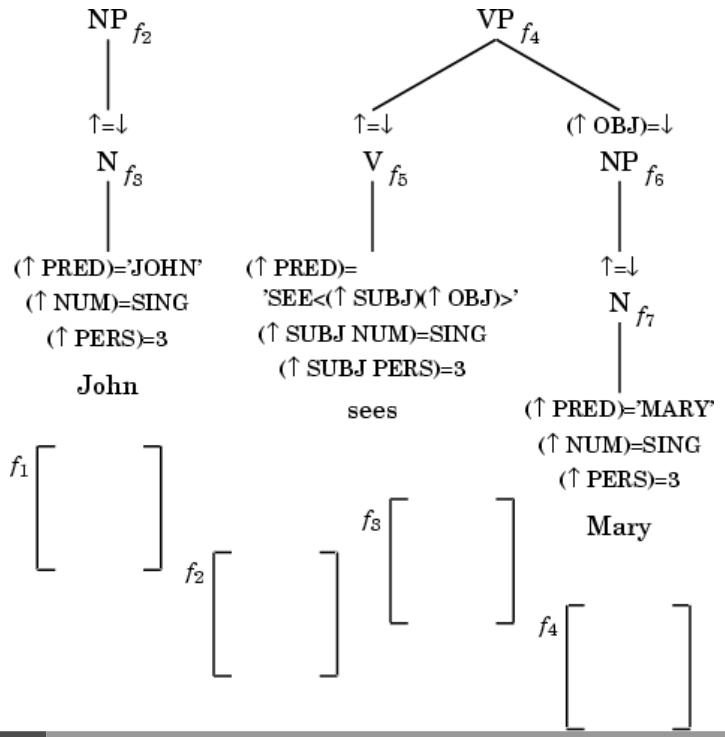

LFG – doplnění hodnot metaproměnných

↑ a ↓ (**metaproměnné**) se odkazují na f-struktury
je potřeba najít správné proměnné f_i na místa šipek

- ↓ – metaproměnná **EGO** nebo **SELF** – odkazuje na f-strukturu uzlu nad schématem
- ↑ – metaproměnná **MOTHER** – odkazuje na f-strukturu rodičovského uzlu vzhledem k uzlu nad schématem

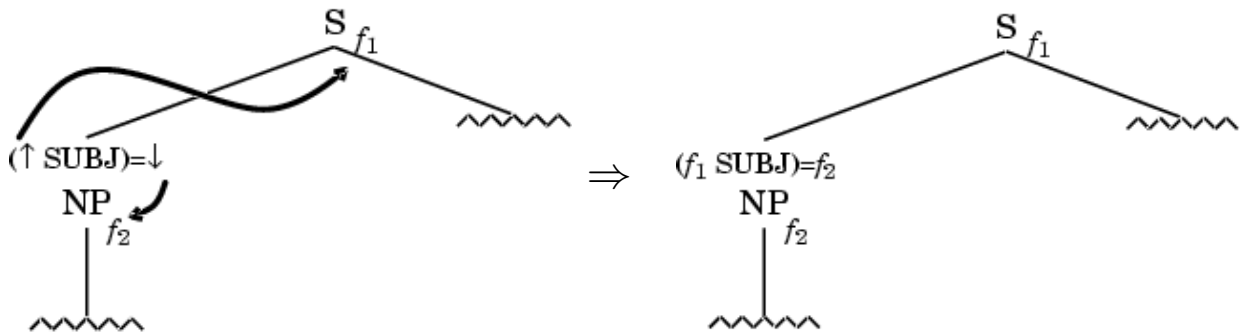

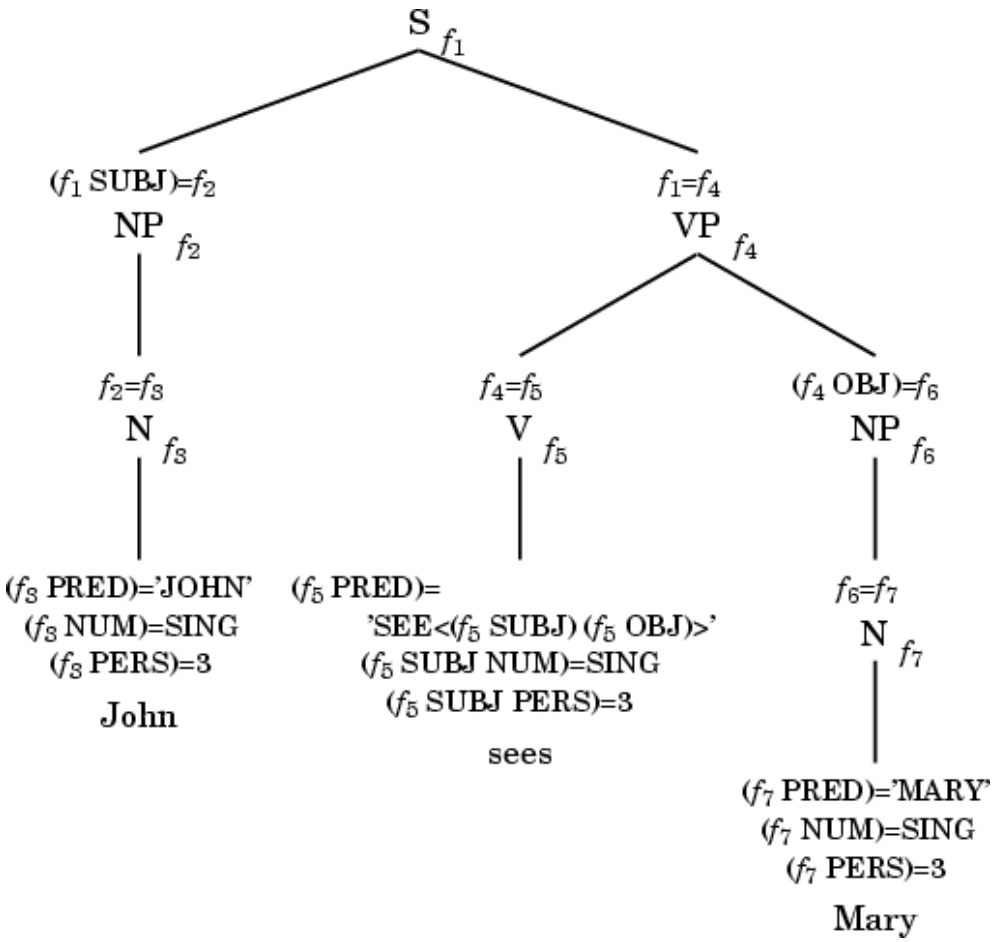

LFG – funkční popis

funkční popis = množina všech instanciovaných funkčních rovnic stromu vlastní konstrukce f-struktury pracuje pouze s tímto funkčním popisem funkční popis předchozí věty:

a. $(f_1$ SUBJ$) = f_2$
b. $f_3 = f_2$
c. $(f_3$ PRED$)$ = 'JOHN'
d. $(f_3$ NUM$)$ = SING
e. $(f_3$ PERS$) = f_3$
f. $f_1 = f_4$
g. $f_4 = f_5$
h. $(f_5$ PRED$)$ = 'SEE<$(f_5$ SUBJ$)(f_5$ OBJ$)$>'
i. $(f_5$ SUBJ NUM$)$ = SING
j. $(f_5$ SUBJ PERS$) = f_3$
k. $(f_4$ OBJ$) = f_6$
l. $f_6 = f_7$
m. $(f_7$ PRED$)$ = 'MARY'
n. $(f_7$ NUM$)$ = SING
o. $(f_7$ PERS$) = f_3$

LFG – konstrukce f-struktury

f-struktura se tvoří **z funkčního popisu** tak, aby všechny funkční rovnice byly **splněny**
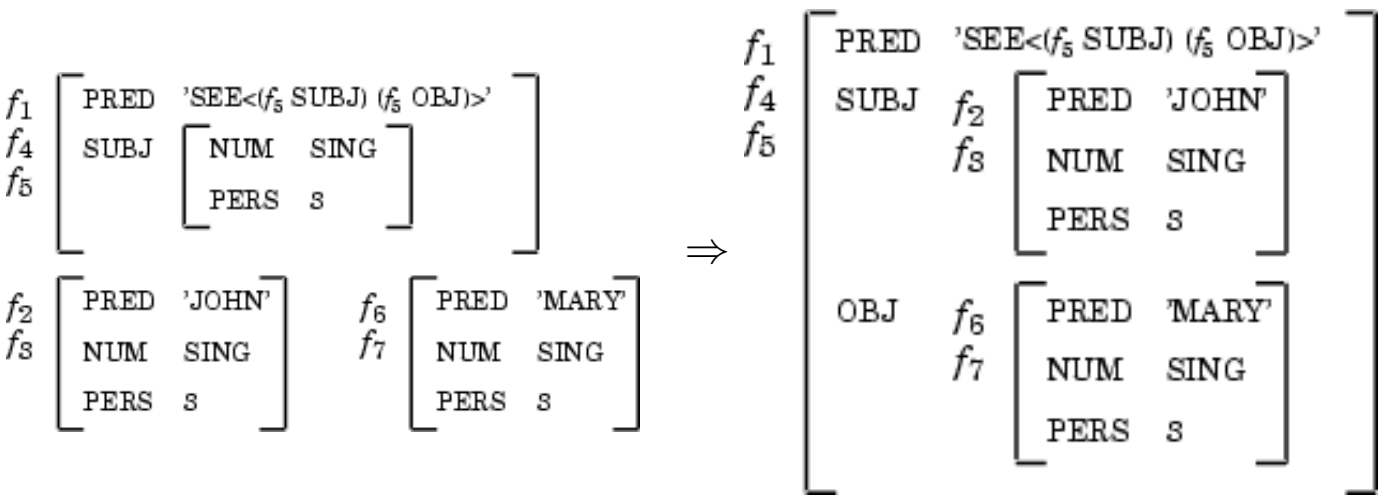
výsledná f-struktura musí být **minimální** taková f-struktura