

# Gramatické formalismy pro ZPJ

Aleš Horák

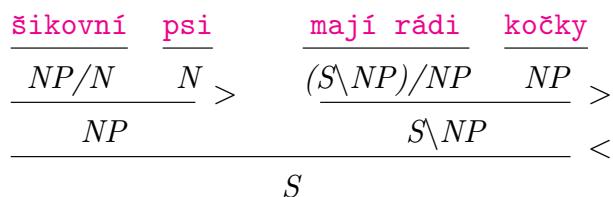
E-mail: [hales@fi.muni.cz](mailto:hales@fi.muni.cz)  
[http://nlp.fi.muni.cz/poc\\_lingv/](http://nlp.fi.muni.cz/poc_lingv/)

Obsah:

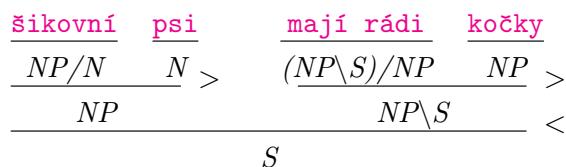
- ▶ Gramatické formalismy
- ▶ Kategoriální gramatiky
- ▶ Závislostní gramatiky
- ▶ Stromové gramatiky TAG a LTAG

## Kategoriální gramatiky

- ▶ existuje několik různých variant notace



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



# Gramatické formalismy

- ▶ existuje 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 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**  
 $\underline{\text{pěkný}} := NP/N \dots$  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 Ajdukiewicz (publ. 1935) ve vazbě na Husserlovu a Russellovu teorii kategorií a teorii typů
- ▶ první použití kategoriálních gramatik pro **popis přirozeného jazyka** – Jehošua Bar-Hillel, 1953

## Notace kategoriálních gramatik

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

1.  $\Sigma$  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  $(X \setminus Y) \in C$
  - 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 **slово**<sub>kategorie</sub>)
5.  $RS$  je množina následujících **schémat pravidel**:
  - a)  $\alpha(X/Y) \circ \beta(Y) \rightarrow \alpha\beta(X)$
  - b)  $\beta(Y) \circ \alpha(X \setminus Y) \rightarrow \beta\alpha(X)$ ,
 kde  $\alpha, \beta \in \Sigma$  a  $X, Y \in C$
6.  $C_{complete} \subseteq C$  je množina **dokončených (kompletních) kategorií**

## 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 nejpracovanějším 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*  $P \wedge (P \Rightarrow Q) \Rightarrow Q$

## Notace kategoriálních gramatik – pokrač.

- daná schémata umožňují 2 způsoby kombinace:
  - argument **vpravo** (/) –  $\alpha(X/Y) \circ \beta(Y) \rightarrow \alpha\beta(X)$
  - argument **vlevo** (\) –  $\beta(Y) \circ \alpha(X \setminus Y) \rightarrow \beta\alpha(X)$
- tento typ kategoriální gramatiky označoval Bar-Hillel jako **obousměrný** (bidirectional CG)
- Karel miluje Marii:
  - bázové kategorie =  $\{NP, S\}$
  - kategorie z lexikonu:  $Karel_{(NP)}$ ,  $Marii_{(NP)}$ ,  $\text{miluje}_{((S \setminus NP)/NP)}$
  - $C_{complete} = \{S\}$
- 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

- ## Závislostní gramatiky
- blízko ke kategoriálním gramatikám – vztah **závislosti** mezi **řídícími** a **závislými** větnými členy
  - vhodné pro popis jazyků s volným slovosledem
  - používají výhradně **lexikalizovaných uzelů** (v závislostním stromu) – neexistují žádné neterminály  
→ 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**

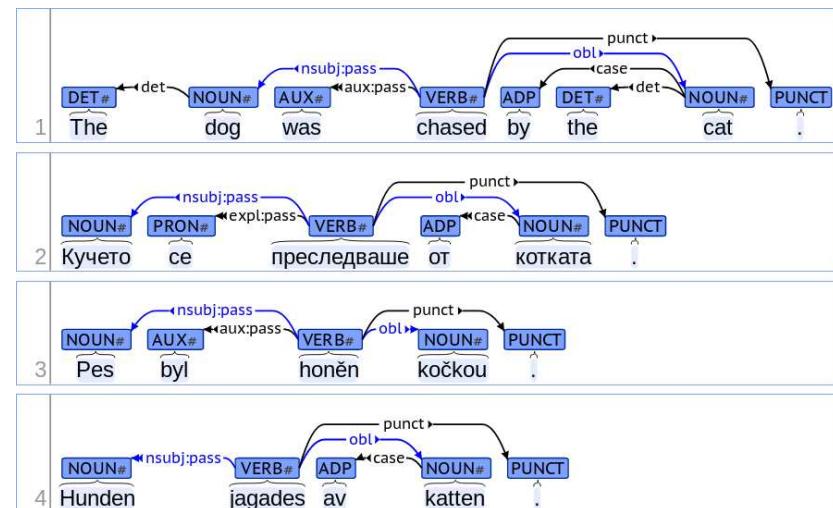
## Závislostní gramatiky – pokrač.

hlavní přístupy:

- ▶ navazuje na evropskou lingvistickou tradici – až k antice
- ▶ nejstarší užití – Tesnière 1959
- ▶ funkční generativní popis (*Functional Generative Description*, FGD) – jeden z nejpracovanějších závislostních systémů, pražská lingvistická škola (Sgall, Hajičová, Panová)
- ▶ 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

## Universal Dependencies

- ▶ [www.universaldependencies.org](http://www.universaldependencies.org), UD
- ▶ sjednocení závislostní anotace pro různé jazyky
- ▶ cca 200 stromových bank (treebanks) ve více než 100 jazyčích



## Google Universal Tagset

- ▶ gramatiky pro jednotlivé jazyky založené na podobných principech
- ▶ detailly značkování ale často nejsou převoditelné 1:1
- ▶ sjednocení – značkování v UD založené na minimalistické [Google Universal Tagset](#)

Open class words	Closed class words	Other
ADJ	ADP	PUNCT
ADV	AUX	SYM
INTJ	CCONJ	X
NOUN	DET	
PROPN	NUM	
VERB	PART	
	PRON	
	SCONJ	

## Universal Features

- ▶ značky z [Universal Tagset](#) vymezují základní třídy
- ▶ lexikální a gramatické vztahy popisují [Universal Features](#)

Lexical features	Inflectional features	
	Nominal	Verbal
PronType	Gender	VerbForm
NumType	Animacy	Mood
Poss	Number	Tense
Reflex	Case	Aspect
Foreign	Definite	Voice
Abbr	Degree	Evident
		Polarity
		Person
		Polite

## Universal Dependencies

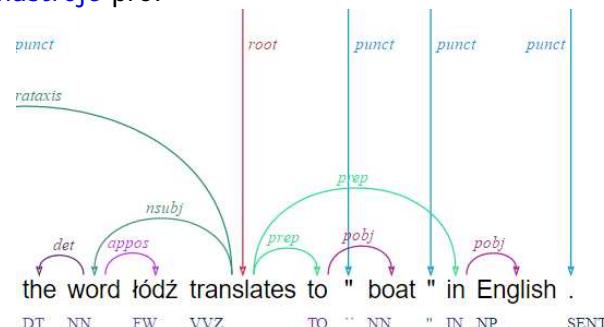
1	Správkyně	Správkyně	NOUN	Case=Nom Gender=Fem Number=Sing Polarity=Pos
2	dědictví	dědictví	NOUN	Case=Gen Gender=Neut Number=Sing Polarity=Pos
3	Nováková	Nováková	PROPN	Case=Nom Gender=Fem NameType=Sur Number=Sing Polarity=Pos
4	označila	označit	VERB	Aspect=Perf Gender=Fem,Neut Number=Plur,Sing Polarity=Pos Tense=Past VerbForm=Part Voice=Act
5	pondělní	pondělní	ADJ	Case=Acc Degree=Pos Gender=Neut Number=Sing Polarity=Pos
6	rozhodnutí	rozhodnutí	NOUN	Case=Acc Gender=Neut Number=Sing Polarity=Pos
7	za	za	ADP	AdpType=Prep Case=Acc
8	potěšující	potěšující	ADJ	Aspect=Imp Case=Acc Gender=Neut Number=Sing Polarity=Pos Tense=Pres VerbForm=Part Voice=Act
9	.	.	PUNCT	-

## Využití Universal Dependencies

- srovnání lingvistických fenoménů napříč jazyky
- testování syntaktické analýzy na různých jazycích
- vícejazyčná syntaktická analýza – paralelní dokumenty
- snadné porozumění rozdílům v anotacích

UD poskytuje univerzální nástroje pro:

- anotace (editor, statistiky, validace)
- vizualizace
- dotazování
- UDPipe – trénování a automatické anotace



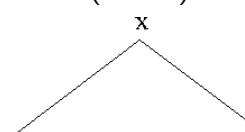
## Jazykové instrukce pro Universal Dependencies

- každý jazyk má uvedené instrukce pro:
  - tokenizaci (hranice slov)
  - morfologické značky
  - syntax – základní a rozšířené závislosti
- např. pro češtinu – [www.universaldependencies.org/cs/](http://www.universaldependencies.org/cs/)
- cíl instrukcí – sjednocení anotací napříč jazyky
- obsahuje i instrukce netypické pro daný jazyk – např. v češtině značkování některých zájmen jako determiner nebo expandování slov – **kdybych** = **když + bych**

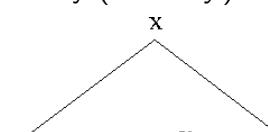
## Stromové gramatiky TAG a LTAG

- 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:

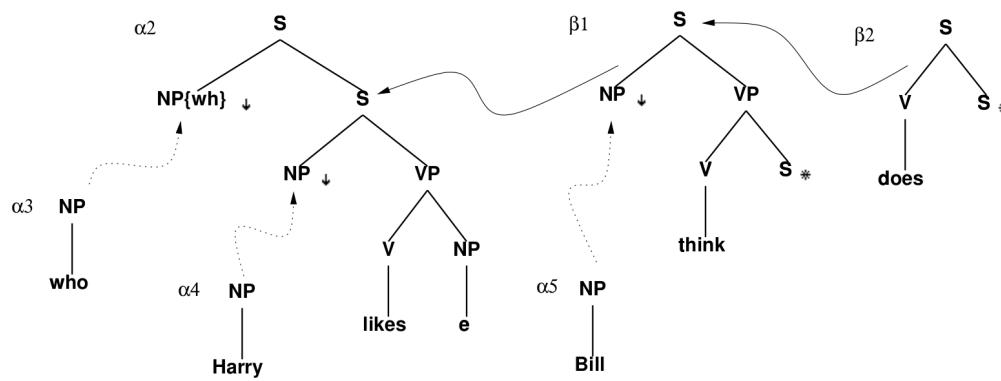


pomocný (*auxiliary*) strom:



# XTAG Project

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



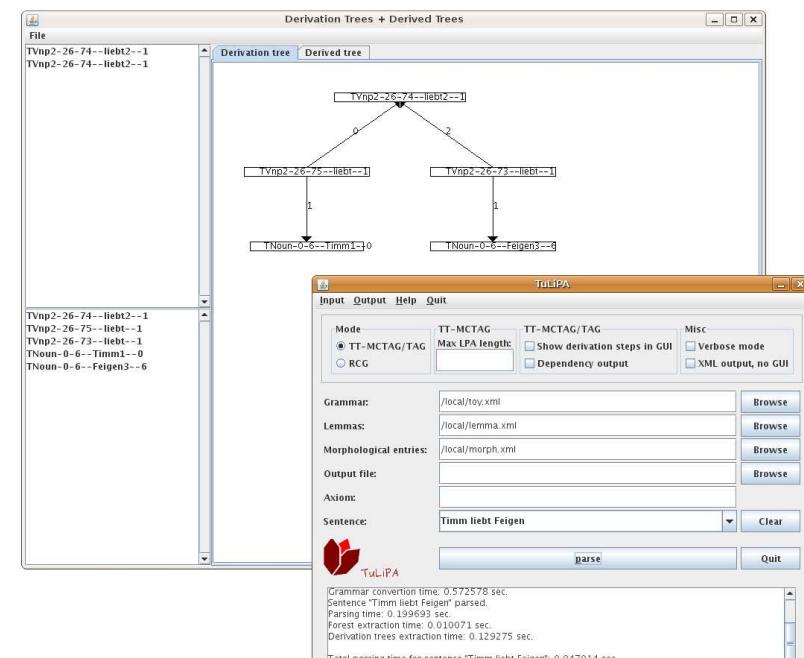
## TAG – počáteční a pomocné stromy

- ▶ **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  $X$

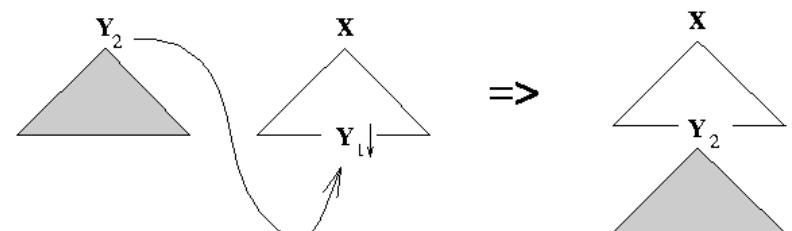
- ▶ **pomocné stromy** – reprezentují *rekurzivní struktury* popisují větné členy, které se **připojují** k základním strukturám (např. příslovečné určení)
  - ▶ charakterizace:
    1. všechny **nelistové uzly** odpovídají *neterminálům*
    2. všechny **listové uzly** odpovídají *terminálům* nebo *neterminálním 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

## TuLiPA-frames



## TAG – operace

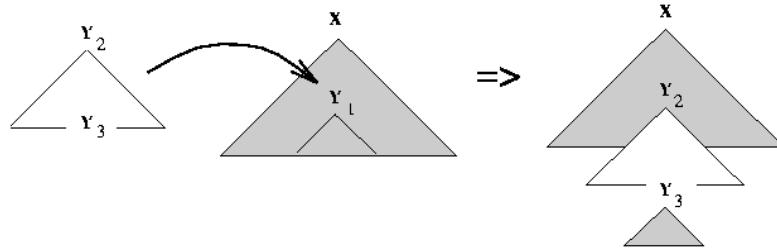
dvě operace – **substituce** a **připojení (adjunction)**  
 operace **substituce** – nahrazuje označený neterminál v listech nějakého stromu stromem, jehož kořen nese stejně označení



$Y_1 \downarrow$  – 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 uzelů (všechny substituční uzly byly doplněny)

► **jazyk řetězců  $\mathcal{L}(G)$**  generovaných TA gramatikou  $G$  = množina všech terminálních řetězců na spodním okraji stromů v  $\mathcal{T}(G)$ .

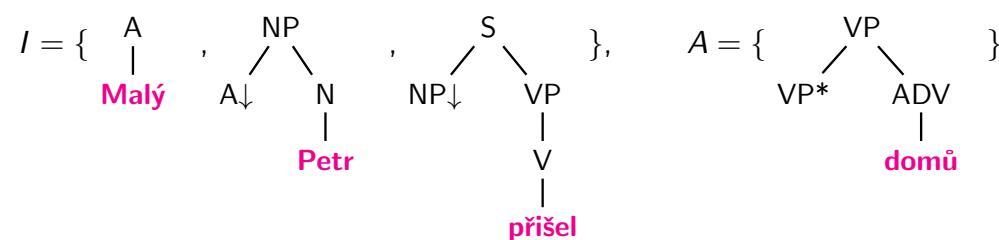
## LTAG – lexikalizace

LTAG je **lexikalizovanou variantou** formalismu TAG

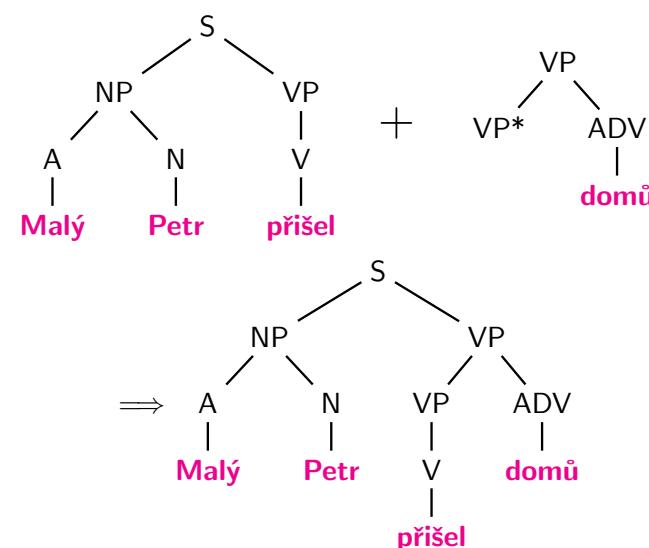
→ počáteční i pomocné stromy obsahují v listech jednu nebo více tzv.

**lexikálních kotev** – uzly, které jsou přiřazeny (ukotveny) k určitým slovům lexikonu

**lexikalizované stromy** (*substituční uzly* –  $\downarrow$ , *patové uzly* –  $*$ ):



## LTAG – lexikalizované připojení



## TAG a LTAG – generované jazyky

- ▶ díky použití operace připojení mají TAG a LTAG **větší generativní sílu** než bezkontextové gramatiky ( $\text{CFG} \subset \text{MCSL}$ ) → 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