

# Gramatické formalismy pro ZPJ

Aleš Horák

E-mail: [hales@fi.muni.cz](mailto:hales@fi.muni.cz)  
[http://nlp.fi.muni.cz/nlp\\_intro/](http://nlp.fi.muni.cz/nlp_intro/)

Obsah:

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

# 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)

# Gramatické formalismy

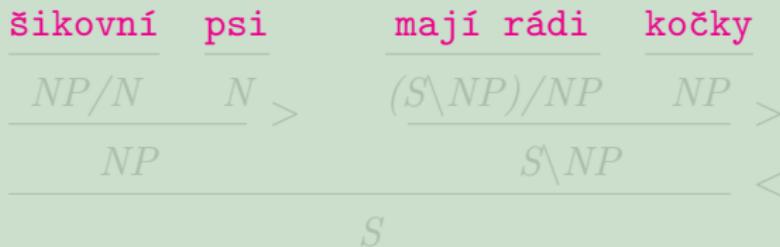
- existuje množství různých přístupů k formální specifikaci gramatik (přirozených jazyků), různé **gramatické formalismy**
- popíšeme několik nejrozšířenějších formalismů:
  - *kategoriální gramatiky* – categorial grammars, CG
  - *závislostní gramatiky* – dependency grammars
  - *stromové gramatiky* – (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)

# Gramatické formalismy

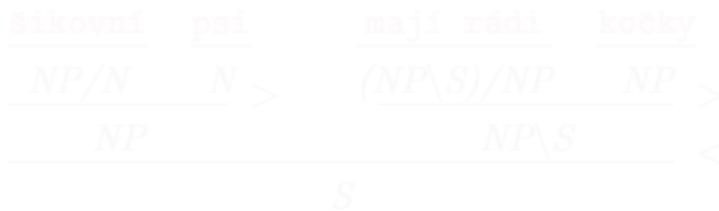
- existuje množství různých přístupů k formální specifikaci gramatik (přirozených jazyků), různé **gramatické formalismy**
- popíšeme několik nejrozšířenějších formalismů:
  - *kategoriální gramatiky* – categorial grammars, CG
  - *závislostní gramatiky* – dependency grammars
  - *stromové gramatiky* – (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

- existuje několik různých variant notace

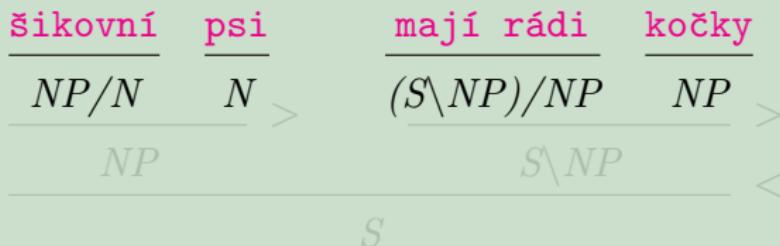


- jiný rozšířený zápis – výsledek na vrcholku (result on top) Lambek 1958

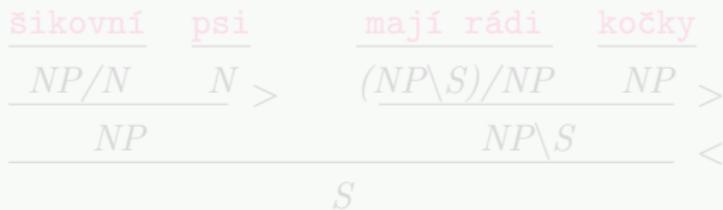


# Kategoriální gramatiky

- existuje několik různých variant notace



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



# Kategoriální gramatiky

- existuje několik různých variant notace

$$\begin{array}{cccc}
 \text{\color{magenta}šikovní} & \text{\color{magenta}psi} & \text{\color{magenta}mají rádi} & \text{\color{magenta}kočky} \\
 \hline
 NP/N & N & (S\backslash NP)/NP & NP \\
 NP & & S\backslash NP & \\
 \hline
 & & & S
 \end{array}
 > > <$$

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

$$\begin{array}{cccc}
 \text{\color{magenta}šikovní} & \text{\color{magenta}psi} & \text{\color{magenta}mají rádi} & \text{\color{magenta}kočky} \\
 \hline
 NP/N & N & (NP\backslash S)/NP & NP \\
 NP & & NP\backslash S & \\
 \hline
 & & & S
 \end{array}
 > > <$$

# Kategoriální gramatiky

- existuje několik různých variant notace

$$\begin{array}{cccc}
 \text{\color{magenta}šikovní} & \text{\color{magenta}psi} & \text{\color{magenta}mají rádi} & \text{\color{magenta}kočky} \\
 \hline
 NP/N & N & (S\backslash NP)/NP & NP \\
 > & & & > \\
 \hline
 NP & & S\backslash NP & \\
 & & & < \\
 \hline
 & & S &
 \end{array}$$

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

$$\begin{array}{cccc}
 \text{\color{magenta}šikovní} & \text{\color{magenta}psi} & \text{\color{magenta}mají rádi} & \text{\color{magenta}kočky} \\
 \hline
 NP/N & N & (NP\backslash S)/NP & NP \\
 > & & & > \\
 \hline
 NP & & NP\backslash S & \\
 & & & < \\
 \hline
 & & S &
 \end{array}$$

# Kategoriální gramatiky

- existuje několik různých variant notace

$$\begin{array}{cccc}
 \text{šikovní} & \text{psi} & \text{mají rádi} & \text{kočky} \\
 \hline
 NP/N & N & (S \setminus NP)/NP & NP \\
 > & & & > \\
 NP & & S \setminus NP & \\
 \hline
 & & & S
 \end{array}$$

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

$$\begin{array}{cccc}
 \text{šikovní} & \text{psi} & \text{mají rádi} & \text{kočky} \\
 \hline
 NP/N & N & (NP \setminus S)/NP & NP \\
 > & & & > \\
 NP & & NP \setminus S & \\
 \hline
 & & & S
 \end{array}$$

# 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 :=  $NP/N \dots$  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

# 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 :=  $NP/N \dots$  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

# 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 :=  $NP/N \dots$  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

# 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 :=  $NP/N \dots$  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

# 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 :=  $NP/N \dots$  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

# 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**

# 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**

# 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**

# 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**

# 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**

# Notace kategoriálních gramatik – pokrač.

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

# Notace kategoriálních gramatik – pokrač.

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

# Notace kategoriálních gramatik – pokrač.

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

# Notace kategoriálních gramatik – pokrač.

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

# Notace kategoriálních gramatik – pokrač.

- daná schémata umožňují 2 způsoby kombinace:
  - argument **vpravo** (/) –  $\alpha(x/Y) \circ \beta(Y) \rightarrow \alpha\beta(x)$
  - argument **vlevo** (\) –  $\beta(Y) \circ \alpha(x\backslash Y) \rightarrow \beta\alpha(x)$
- tento typ kategoriální gramatiky označoval Bar-Hillel jako **obousměrný** (bidirectional CG)
- Karel miluje Marii:
  - bázové kategorie = {NP, S}
  - kategorie z lexikonu:  $Karel_{(NP)}$ ,  $Marii_{(NP)}$ ,  $miluje_{((S\backslash NP)/NP)}$
  - $C_{complete} = \{S\}$
- 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
  - 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. *applikace funkce* ⇒ pravidlo *modus ponens*  $P \wedge (P \Rightarrow Q) \Rightarrow Q$

OpenCCG library – <http://openccg.sourceforge.net/>

# 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
  - 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. *applikace funkce* ≈ pravidlo *modus ponens*  $P \wedge (P \Rightarrow Q) \Rightarrow Q$

OpenCCG library – <http://openccg.sourceforge.net/>

# 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/>

# 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/>

# Obsah

## 1 Gramatické formalismy

## 2 Kategoriální gramatiky

- Notace kategoriálních gramatik
- Rozšíření kategoriálních gramatik

## 3 Závislostní gramatiky

- Universal Dependencies

## 4 Stromové gramatiky TAG a LTAG

- operace
- lexikalizace
- generované jazyky

# 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
  - 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

- 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
  - 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

- 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
  - 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

- 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
  - 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, 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

# 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, 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

# 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, 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

# 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, 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

# Universal Dependencies

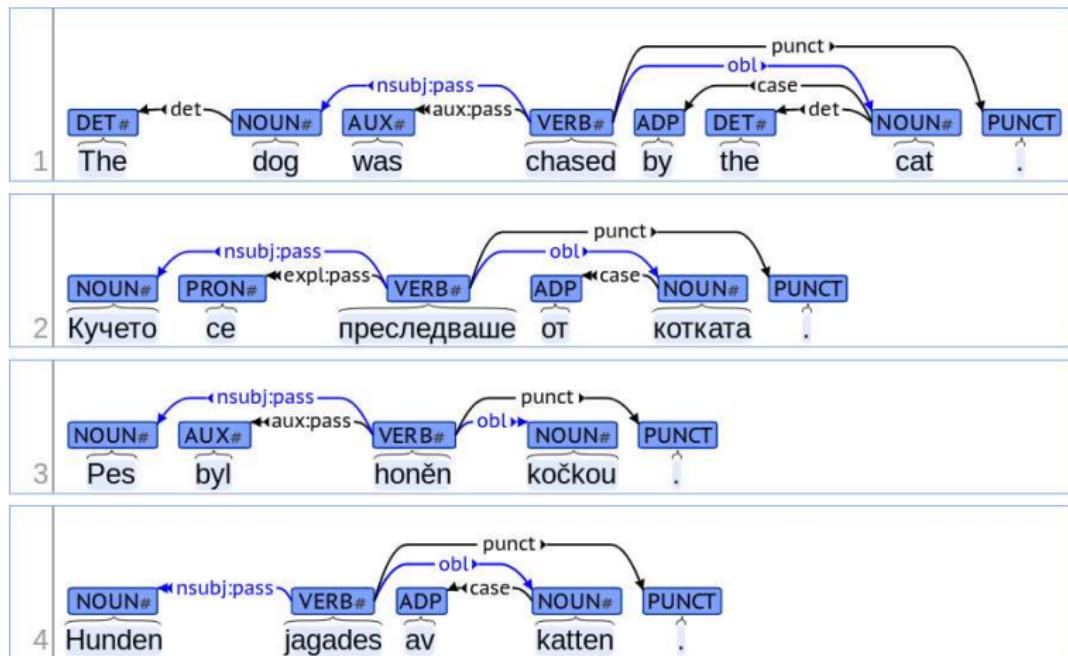
- [www.universaldependencies.org](http://www.universaldependencies.org), UD
- sjednocení závislostní anotace pro různé jazyky
- cca 200 stromových bank (*treebanks*) ve více než 100 jazyčích

# 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 jazycích

# 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 jazycích



# Google Universal Tagset

- gramatiky pro jednotlivé jazyky založené na podobných principech
- detaily 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	

# Google Universal Tagset

- gramatiky pro jednotlivé jazyky založené na podobných principech
- detaily 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	

# Google Universal Tagset

- gramatiky pro jednotlivé jazyky založené na podobných principech
- detaily 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	

# Google Universal Tagset

- gramatiky pro jednotlivé jazyky založené na podobných principech
- detaily 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 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 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	-

# 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**

SliDo

# 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**

SliDo

# 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**

SliDo

# 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**

SliDo

# Využití Universal Dependencies

- srovnání lingvistických fenomenů 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

# Využití Universal Dependencies

- srovnání lingvistických fenomenů 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

# Využití Universal Dependencies

- srovnání lingvistických fenomenů 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

# Využití Universal Dependencies

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

UD poskytuje univerzální nástroje pro:

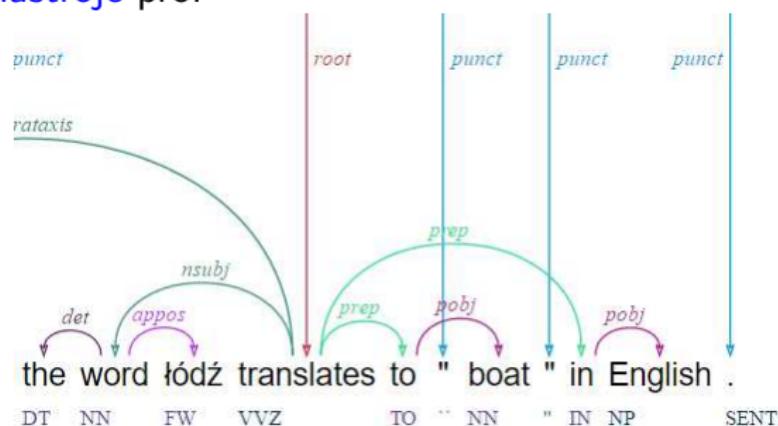
- anotace (editor, statistiky, validace)
- vizualizace
- dotazování
- UDPipe – trénování a automatické anotace

## Využití Universal Dependencies

- srovnání lingvistických fenomenů 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

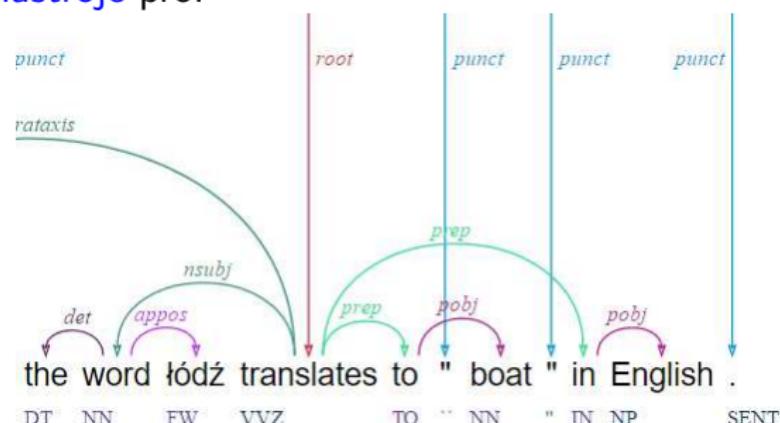


# Využití Universal Dependencies

- srovnání lingvistických fenomenů 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

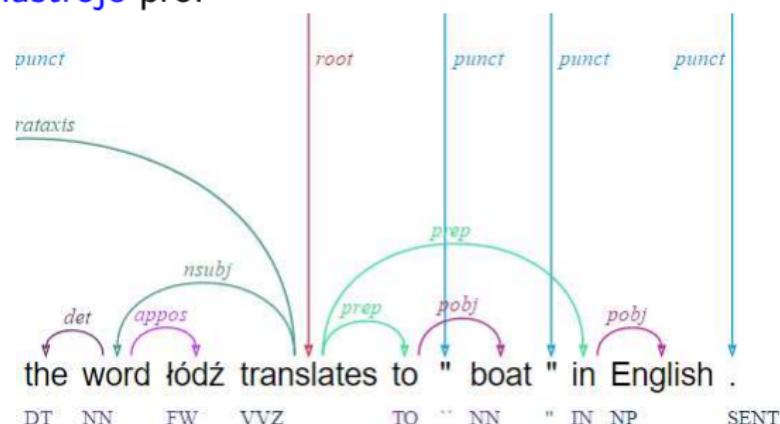


# Využití Universal Dependencies

- srovnání lingvistických fenomenů 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

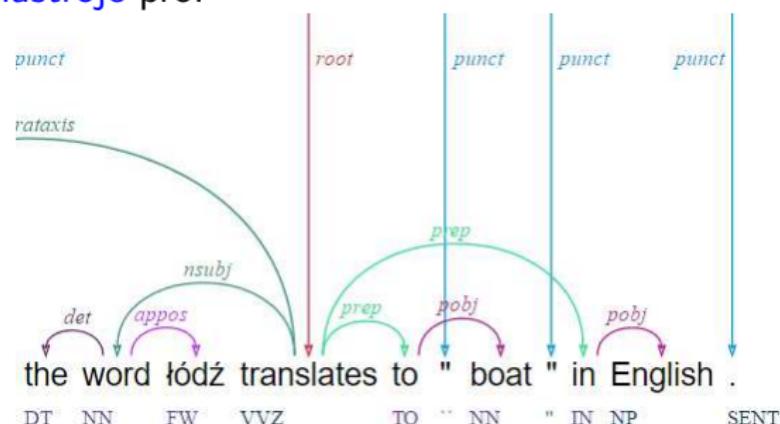


# Využití Universal Dependencies

- srovnání lingvistických fenomenů 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



# Obsah

## 1 Gramatické formalismy

## 2 Kategoriální gramatiky

- Notace kategoriálních gramatik
- Rozšíření kategoriálních gramatik

## 3 Závislostní gramatiky

- Universal Dependencies

## 4 Stromové gramatiky TAG a LTAG

- operace
- lexikalizace
- generované jazyky

# 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:

# 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**

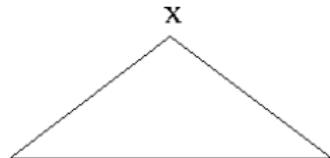
počáteční (*initial*) strom:

pomocný (*auxiliary*) strom:

# 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:

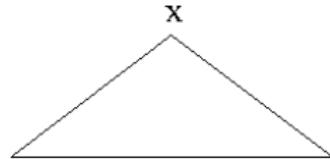


pomocný (*auxiliary*) strom:

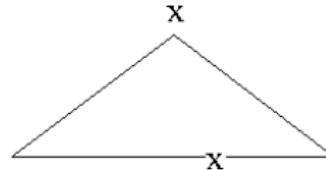
# Stromové gramatiky TAG a LTAG

- 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:

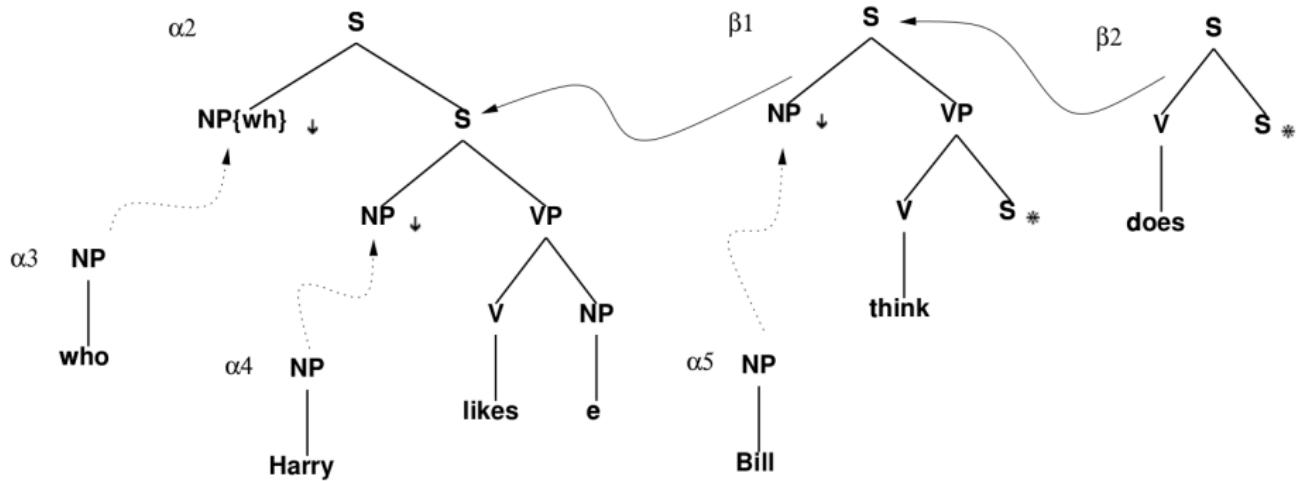


pomocný (*auxiliary*) strom:



# XTAG Project

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



# TuLiPA-frames

**Derivation Trees + Derived Trees**

File

TVnp2-26-74--liebt2--1  
TVnp2-26-74--liebt2--1

Derivation tree    Derived tree

TVnp2-26-74--liebt2--1  
TVnp2-26-75--liebt--1  
TVnp2-26-73--liebt--1  
TNoun-0-6--Timm1--0  
TNoun-0-6--Feigen2--0

**TuLiPA**

Input   Output   Help   Quit

Mode	TT-MCTAG <input checked="" type="radio"/> TT-MCTAG/TAG <input type="radio"/> RCG	TT-MCTAG	TT-MCTAG/TAG	Misc
		Max LPA length:	<input type="checkbox"/> Show derivation steps in GUI <input type="checkbox"/> Dependency output	<input type="checkbox"/> Verbose mode <input type="checkbox"/> XML output, no GUI

Grammar: /local/toy.xml      Browse

Lemmas: /local/lemma.xml      Browse

Morphological entries: /local/morph.xml      Browse

Output file:      Browse

Axiom:      Browse

Sentence: Timm liebt Feigen      Clear

 TuLiPA

Parse      Quit

Grammar conversion time: 0.572578 sec.  
Sentence "Timm liebt Feigen" parsed.  
Parsing time: 0.199693 sec.  
Forest extraction time: 0.010071 sec.  
Derivation trees extraction time: 0.129275 sec.

Total parsing time for sentence "Timm liebt Feigen": 0.947014 sec.

# 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 – 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 – 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

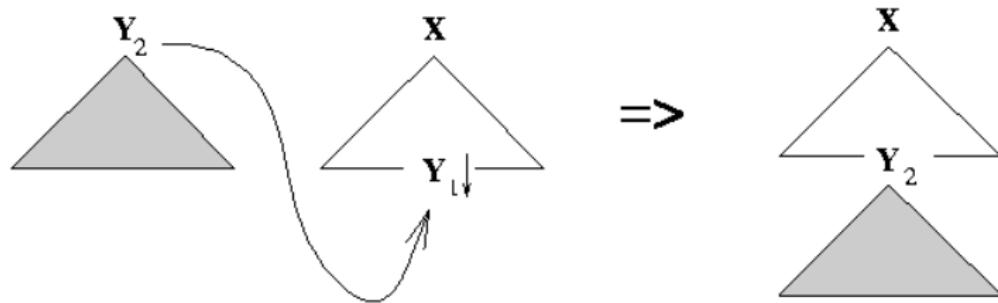
- **pomocné stromy** – reprezentují *rekurzivní struktury* popisují větné členy, které se **připojují** k základním strukturám (např. příslovečné určení)
- charakterizace:
  1. všechny **nelistové uzly** odpovídají *neterminálům*
  2. všechny **listové uzly** odpovídají *terminálům* nebo *neterminálním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

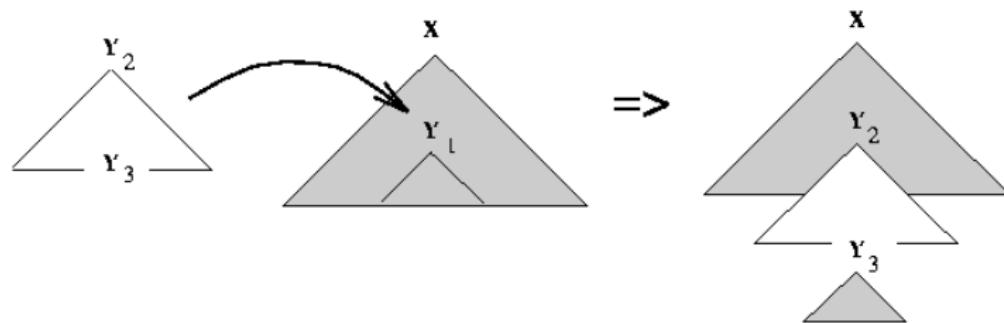
operace **substituce** – nahrazuje označený neterminál v listech nějakého stromu stromem, jehož kořen nese stejně označení



$Y_1 \downarrow$  – 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 uzlů (všechny substituční uzly byly doplněny)
- jazyk řetězců  $\mathcal{L}(G)$  generovaných TA gramatikou  $G$  = množina všech terminálních řetězců na spodním okraji stromů v  $\mathcal{T}(G)$ .

# 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  $\mathcal{T}(G)$ .

# Definice TAG

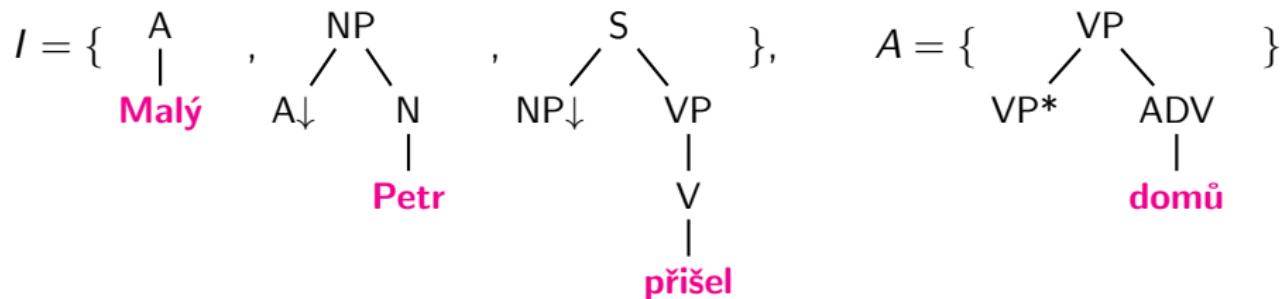
- TAG  $G = (I, A, S)$  je:
  - množina  $I$  konečných počátečních stromů
  - množina  $A$  pomocných stromů
  - typ stromu  $S$  – neterminál označující větu
- množina stromů  $\mathcal{T}(G)$  TA gramatiky  $G$  = množina všech stromů odvoditelných z počátečních stromů typu  $S$  z  $I$ , jejichž 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

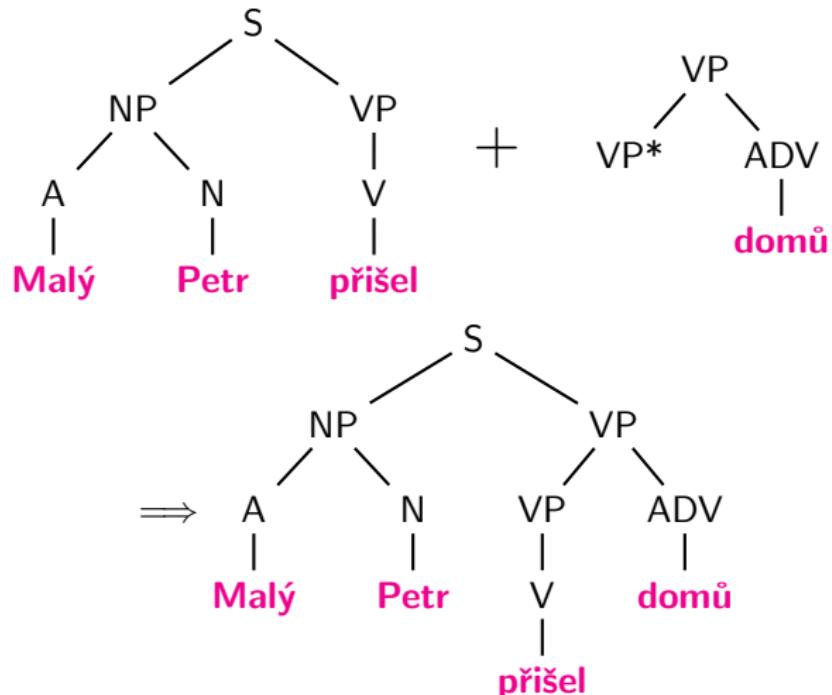
LTAG je **lexikalizovanou variantou** formalismu TAG

→ 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 ( $\text{CFG} \subset \text{MCSL}$ ) → 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 polynomiaálním čase  $O(n^6)$  vzhledem k délce vstupu
- i jiné formalismy umí MCSL (jsou ekvivalentní s (L)TAG).
  - LTAG → Head Grammar (Pollard, 1984)
  - HG, *Head Grammars* – Pollard, 1984
  - CCG, kombinatorické kategoriální gramatiky

# 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

# 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

# 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