

# Algoritmy syntaktické analýzy (pomocí CFG)

Vladimír Kadlec, 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:

- ▶ Základní postupy pro syntaktickou analýzu obecných CFG
- ▶ Tomitův zobecněný analyzátor LR
- ▶ Algoritmus CKY
- ▶ Tabulkové analyzátory
- ▶ Porovnání jednotlivých algoritmů
- ▶ Syntaktická analýza s využitím strojového učení

## Základní postupy pro syntaktickou analýzu obecných bezkontextových gramatik

- ▶ **obecná CFG** – rozsáhlá, (silně) víceznačná, s  $\epsilon$ -pravidly
- ▶ všechny uvedené algoritmy pracují s *polynomiální časovou a prostorovou složitostí*
- ▶ **Tomitův zobecněný algoritmus LR** (*generalized LR*)
- ▶ **algoritmus CKY** – Cocke, Kasami, Younger;
- ▶ **tabulková (chart) analýza** (*Chart Parsing*):
  - shora dolů (*top-down*);
  - zdola nahoru (*bottom-up*);
  - analýza řízená hlavou pravidla (*head-driven*);

# Syntaktická analýza

► Vstupy:

- řetězec lexikálních kategorií (preterminálních symbolů)  $a_1 \ a_2 \ \dots \ a_n$

např.:     ADJ   CONJ   ADJ   N   V   PREP   N   .'

- bezkontextová gramatika  $G = \langle N, \Sigma, P, S \rangle$ .

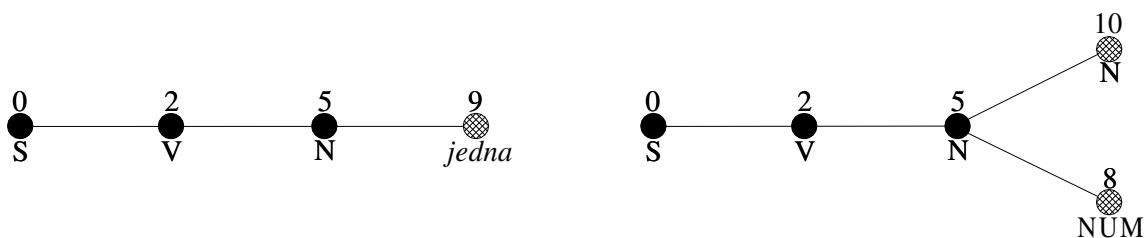
► Výstup:

- efektivní reprezentace derivačních stromů.

## Tomitův zobecněný analyzátor LR

- **generalized LR parser (GLR)**
- Masaru Tomita: **Efficient parsing for natural language**, 1986
- standardní **LR tabulka**, která může obsahovat **konflikty**;
- zásobník je reprezentován **acyklickým orientovaným grafem (DAG)**
- derivační stromy jsou uloženy ve **sbaleném "lese" stromů**
- v podstatě stejný jako algoritmus LR
- udržujeme si **seznam aktivních uzlů** zásobníku (grafu)
- akce **redukce** provádíme vždy před akcemi čtení
- akci **čtení** provádíme pro všechny aktivní uzly najednou
- kde je to možné, tam uzly **slučujeme**

## Příklad konfliktu redukce/redukce



stav	položka	akce	symbol	další stav
5	$CLAUSE \rightarrow V N \bullet NUM$	shift	$NUM$	8
	$NN \rightarrow N \bullet N$		$N$	10
	$NUM \rightarrow \bullet jedna$		$jedna$	9
	$N \rightarrow \bullet tramvaj$		$tramvaj$	7
	$N \rightarrow \bullet jedna$			
9	$NUM \rightarrow jedna \bullet$	reduce (6)		
	$N \rightarrow jedna \bullet$	reduce (5)		

## Algoritmus CKY

- Gramatika musí být v **Chomského normální formě**
- Převod libovolné CFG do CNF:

1. přidáme **nový kořen**  $S_0$ :  $S_0 \rightarrow S$

2. eliminujeme  $\epsilon$ -pravidla:

$$\begin{array}{l} S \rightarrow Ab \mid B \\ A \rightarrow a \mid \epsilon \end{array} \rightarrow \begin{array}{l} S \rightarrow Ab \mid b \mid B \\ A \rightarrow a \end{array}$$

3. eliminujeme **jednoduchá pravidla**:

$$\begin{array}{l} A \rightarrow B \\ B \rightarrow a \mid CD \end{array} \rightarrow \begin{array}{l} A \rightarrow a \mid CD \\ B \rightarrow a \mid CD \end{array}$$

4. rozgenerujeme **dlouhá pravidla**:

$$\begin{array}{l} A \rightarrow BCD \\ \quad \quad \quad \vdots \\ A_1 \rightarrow CD \end{array} \rightarrow \begin{array}{l} A \rightarrow BA_1 \\ A_1 \rightarrow CD \end{array}$$

# Algoritmus CKY, příklad – zadání

- ▶ vstupní gramatika je:

$$\begin{aligned} S &\rightarrow AA|BB|AX|BY|a|b \\ X &\rightarrow SA \\ Y &\rightarrow SB \\ A &\rightarrow a \\ B &\rightarrow b \end{aligned}$$

- ▶ vstupní řetězec je  $w = abaaba$ .

# Algoritmus CKY, příklad – řešení (matice V)

a b a a b a

$$\begin{aligned} S &\rightarrow AA|BB|AX|BY|a|b \\ X &\rightarrow SA \\ Y &\rightarrow SB \\ A &\rightarrow a \\ B &\rightarrow b \end{aligned}$$

$p$  – pozice,  $q$  – délka

$q \backslash p$	1	2	3	4	5	6
1	$S, A$	$S, B$	$S, A$	$S, A$	$S, B$	$S, A$
2	$Y$	$X$	$S, X$	$Y$	$X$	
3	$S$	$\emptyset$	$Y$	$S$		
4	$X$	$S$	$\emptyset$			
5	$\emptyset$	$X$				
6	$S$					

## Algoritmus CKY pokrač.

- ▶ Gramatika musí být v **Chomského normální formě**.
- ▶ Pro daný vstup délky  $n$  derivujeme **podřetězce** symbolů délky  $q$  na pozici  $p$ , značíme  $w_{p,q}$ ,  $1 \leq p, q \leq n$ .
- ▶ Derivace **řetězců délky 1**,  $A \Rightarrow w_{p,1}$ , je prováděno prohledáváním terminálních pravidel.
- ▶ Derivace **delších řetězců**  $A \Rightarrow^* w_{p,q}$ ,  $q \geq 2$  vyžaduje aby platilo  $A \Rightarrow BC \Rightarrow^* w_{p,q}$ . Tedy z  $B$  derivujeme řetězec délky  $k$ ,  $1 \leq k \leq q$ , a z  $C$  derivujeme zbytek, řetězec délky  $q - k$ . Tzn.  $B \Rightarrow^* w_{p,k}$  a  $C \Rightarrow^* w_{p+k, q-k}$ . Kratší řetězce máme tedy vždy "předpočítané."

## Algoritmus CKY pokrač.

```

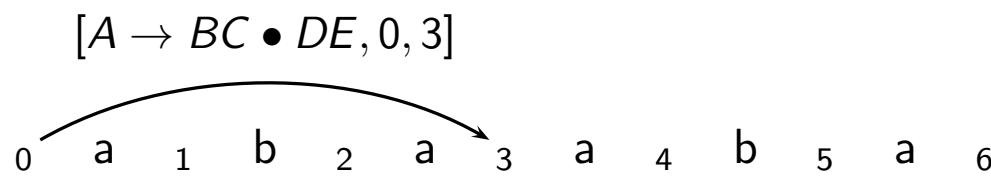
program CKY Parser;
begin
  for  $p := 1$  to  $n$  do  $V[p, 1] := \{A | A \rightarrow a_p \in P\}$ ;
  for  $q := 2$  to  $n$  do
    for  $p := 1$  to  $n - q + 1$  do
       $V[p, q] = \emptyset$ ;
      for  $k := 1$  to  $q - 1$  do
         $V[p, q] =$ 
         $V[p, q] \cup$ 
         $\{A | A \rightarrow BC \in P, B \in V[p, k], C \in V[p + k, q - k]\}$ 
    od
  od
od
end

```

složitost CKY je  $O(n^3)$

# Tabulkové (chart) analyzátory

- ▶ Rozlišujeme tři základní typy **tabulkových analyzátorů**:
  - shora dolů;
  - zdola nahoru;
  - analýza řízená hlavou pravidla.
- ▶ Mnoho dalších variant je popsáno v:  
Sikkel Klaas: **Parsing Schemata: A Framework for Specification and Analysis of Parsing Algorithm**, 1997.
- ▶ Neklade se žádné omezení na gramatiku.
- ▶ Analyzátory typu "chart" v sobě většinou obsahují dvě datové struktury **chart** a **agendu**. Chart a agenda obsahují tzv. *hrany*.
- ▶ **Hrana** je trojice  $[A \rightarrow \alpha \bullet \beta, i, j]$ , kde:
  - $i, j$  jsou celá čísla,  $0 \leq i \leq j \leq n$  pro  $n$  slov ve vstupní větě
  - a  $A \rightarrow \alpha\beta$  je pravidlem vstupní gramatiky.



## Obecný analyzátor typu "chart"

**program** Chart Parser;

**begin**

```

  inicializuj (CHART);
  inicializuj (AGENDA);
  while (AGENDA ≠ ∅) do
    E := vezmi hranu z AGENDA;
    for each (hrana F, která může být vytvořena pomocí
      hrany E a nějaké jiné hrany z CHART) do
      if F ∈ AGENDA and F ∈ CHART and F ≠ E
        then přidej F do AGENDA;
        fi;
    od;
    přidej E do CHART;
  od;
end;

```

složitost tabulkové analýzy je  $O(n^3)$  ( $|Pravidla|$  bereme jako konstantu)

# Varianta shora dolů

## Inicializace:

- ▶  $\forall p \in P \mid p = S \rightarrow \alpha$  přidej hranu  $[S \rightarrow \bullet\alpha, 0, 0]$  do agendy.
- ▶ počáteční chart je prázdný.

**Iterace** – vezmi hranu  $E$  z agendy a pak:

- a) (*fundamentální pravidlo*) pokud je  $E$  ve tvaru  $[A \rightarrow \alpha_\bullet, j, k]$ , potom pro každou hranu  $[B \rightarrow \gamma_\bullet A \beta, i, j]$  v chartu vytvoř hranu  $[B \rightarrow \gamma A_\bullet \beta, i, k]$ .
- b) (*uzavřené hrany*) pokud je  $E$  ve tvaru  $[B \rightarrow \gamma_\bullet A \beta, i, j]$ , potom pro každou hranu  $[A \rightarrow \alpha_\bullet, j, k]$  v chartu vytvoř hranu  $[B \rightarrow \gamma A_\bullet \beta, i, k]$ .
- c) (*terminál na vstupu*) pokud je  $E$  ve tvaru  $[A \rightarrow \alpha_\bullet a_{j+1} \beta, i, j]$ , vytvoř hranu  $[A \rightarrow \alpha a_{j+1} \bullet \beta, i, j+1]$ .
- d) (*predikce*) pokud je  $E$  ve tvaru  $[A \rightarrow \alpha_\bullet B \beta, i, j]$  potom pro každé pravidlo  $B \rightarrow \gamma \in P$ , vytvoř hranu  $[B \rightarrow \bullet\gamma, i, i]$ .

## Příklad – tabulkové analýzy (typu chart)

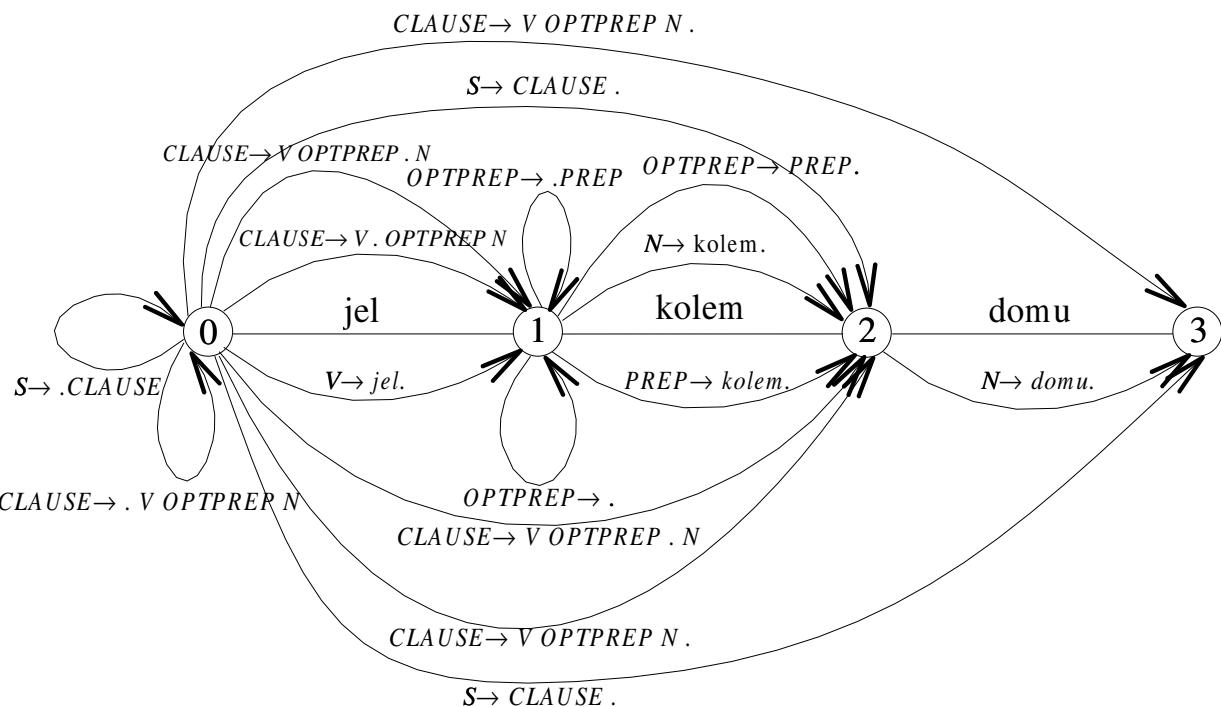
### Gramatika:

$S$	$\rightarrow$	$CLAUSE$
$CLAUSE$	$\rightarrow$	$V OPTPREP N$
$OPTPREP$	$\rightarrow$	$\epsilon$
$OPTPREP$	$\rightarrow$	$PREP$
$V$	$\rightarrow$	<i>jel</i>
$PREP$	$\rightarrow$	<i>kolem</i>
$N$	$\rightarrow$	<i>domu</i>
$N$	$\rightarrow$	<i>kolem</i>

### Věta:

"*jel kolem domu*" ( $a_1=jel$ ,  $a_2=kolem$ ,  $a_3=domu$ ).

# Příklad – chart po analýze shora dolů



## Varianta zdola nahoru

### Inicializace:

- ▶  $\forall p \in P \mid p = A \rightarrow \epsilon$  přidej hrany  $[A \rightarrow \bullet, 0, 0]$ ,  $[A \rightarrow \bullet, 1, 1]$ , ...,  $[A \rightarrow \bullet, n, n]$  do agendy.
- ▶  $\forall p \in P \mid p = A \rightarrow a_i \alpha$  přidej hranu  $[A \rightarrow \bullet a_i \alpha, i-1, i-1]$  do agendy.
- ▶ počáteční chart je prázdný.

**Iterace** – vezmi hranu  $E$  z agendy a pak:

- (fundamentální pravidlo) pokud je  $E$  ve tvaru  $[A \rightarrow \alpha_\bullet, j, k]$ , potom pro každou hranu  $[B \rightarrow \gamma_\bullet A \beta, i, j]$  v chartu vytvoř hranu  $[B \rightarrow \gamma A_\bullet \beta, i, k]$ .
- (uzavřené hrany) pokud je  $E$  ve tvaru  $[B \rightarrow \gamma_\bullet A \beta, i, j]$ , potom pro každou hranu  $[A \rightarrow \alpha_\bullet, j, k]$  v chartu vytvoř hranu  $[B \rightarrow \gamma A_\bullet \beta, i, k]$ .
- (terminál na vstupu) pokud je  $E$  ve tvaru  $[A \rightarrow \alpha_\bullet a_{j+1} \beta, i, j]$ , potom vytvoř hranu  $[A \rightarrow \alpha a_{j+1} \bullet \beta, i, j+1]$ .
- (predikce) pokud je  $E$  ve tvaru  $[A \rightarrow \alpha_\bullet, i, j]$ , potom pro každé pravidlo  $B \rightarrow A\gamma$  vstupní gramatiky vytvoř hranu  $[B \rightarrow \bullet A\gamma, i, i]$ .

# Analýza řízená hlavou pravidla

- ▶ *head-driven chart parsing*
- ▶ **Hlava pravidla** – libovolný (určený) symbol z pravé strany pravidla.  
Například pravidlo  $CLAUSE \rightarrow V \underline{PREP} N$  může mít hlavy  $V, PREP, N$ .
- ▶ Epsilon pravidlo má hlavu  $\epsilon$ .
- ▶ Hrana v analyzátoru řízeném hlavou pravidla – trojice  $[A \rightarrow \alpha \bullet \beta \bullet \gamma, i, j]$ , kde  $i, j$  jsou celá čísla,  $0 \leq i \leq j \leq n$  pro  $n$  slov ve vstupní větě a  $A \rightarrow \alpha \beta \gamma$  je pravidlo vstupní gramatiky a hlava je v  $\beta$ .
- ▶ Algoritmus vlastní analýzy (varianta zdola nahoru) je podobný jednoduchému přístupu. Analýza neprobíhá zleva doprava, ale začíná na hlavě daného pravidla.

## Analyzátor řízený hlavou pravidla

### Inicializace:

- ▶  $\forall p \in P \mid p = A \rightarrow \epsilon$  přidej hrany  $[A \rightarrow \bullet\bullet, 0, 0], [A \rightarrow \bullet\bullet, 1, 1], \dots, [A \rightarrow \bullet\bullet, n, n]$  do agendy.
- ▶  $\forall p \in P \mid p = A \rightarrow \alpha \underline{a_i} \beta$  ( $a_i$  je hlavou pravidla) přidej hranu  $[A \rightarrow \alpha \bullet a_i \bullet \beta, i-1, i]$  do agendy.
- ▶ počáteční chart je prázdný.

*Je tato inicializace v pořádku?*

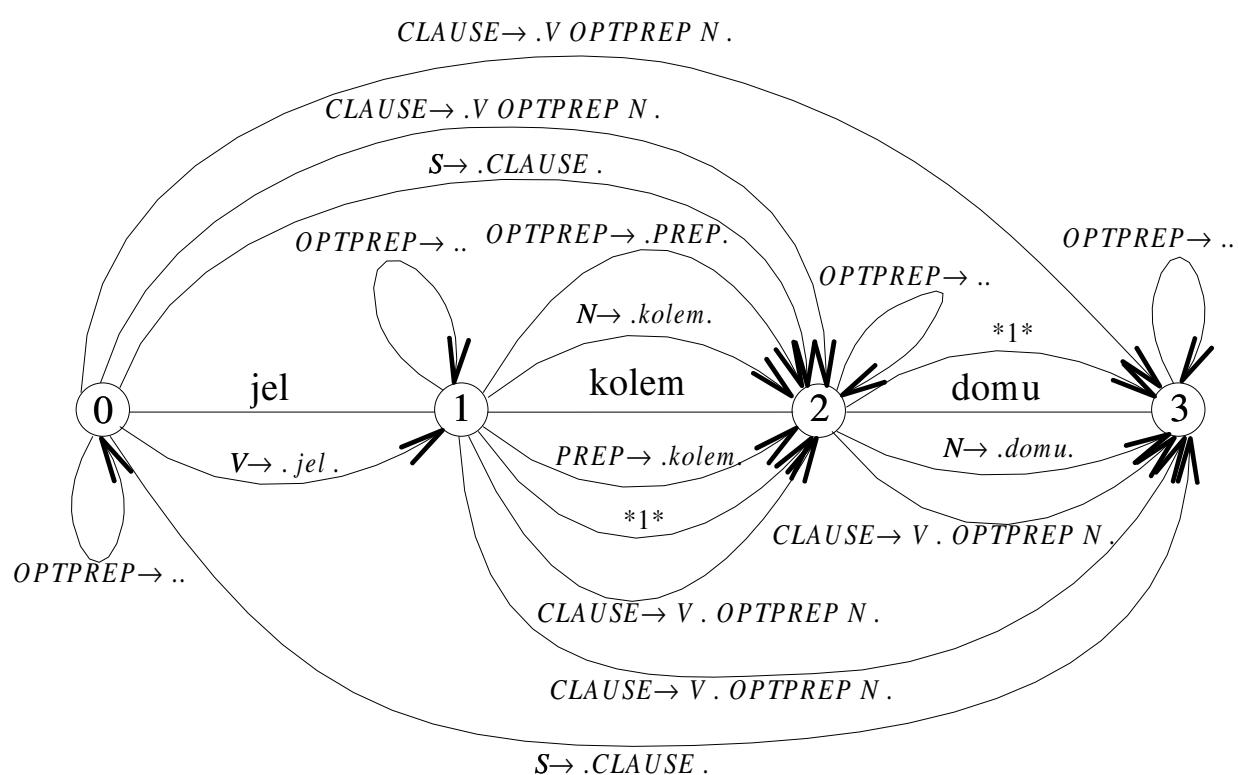
*Co když inicializace nic nepřidá?* (žadné  $\epsilon$  ani žádný terminál jako hlava)  
Odpověď: taková gramatika by generovala prázdný jazyk.

# Analyzátor řízený hlavou pravidla pokrač.

**Iterace** – vezmi hranu  $E$  z agendy a pak:

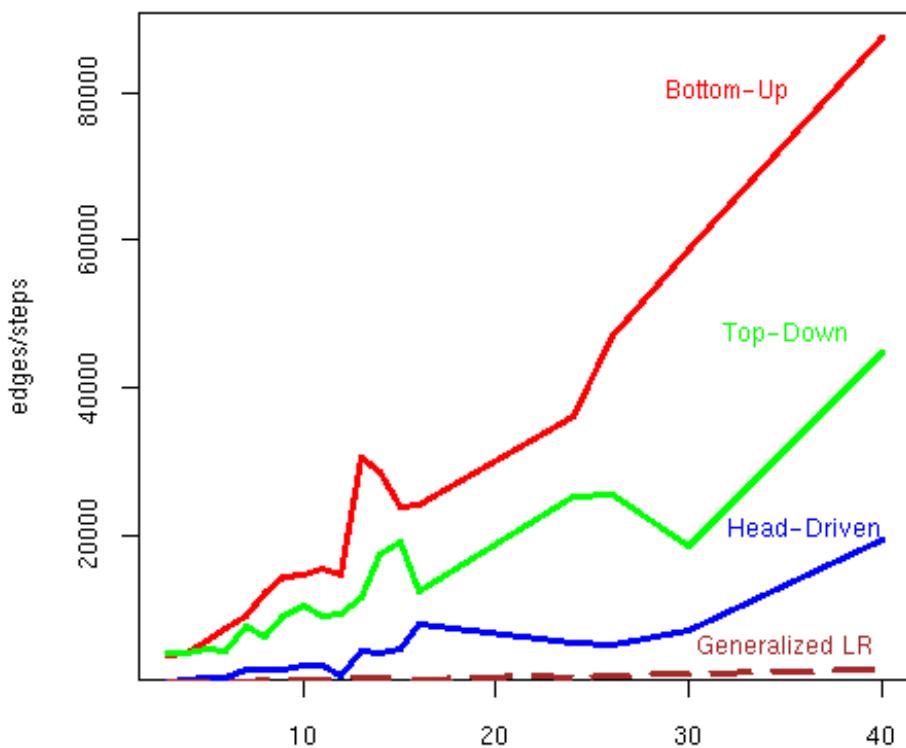
- a<sub>1</sub>) pokud je  $E$  ve tvaru  $[A \rightarrow \bullet\alpha_\bullet, j, k]$ , potom pro každou hranu:  $[B \rightarrow \beta_\bullet\gamma_\bullet A\delta, i, l]$  v chartu vytvoř hranu  $[B \rightarrow \beta_\bullet\gamma A_\bullet\delta, i, k]$ ,
- a<sub>2</sub>) pro  $[B \rightarrow \beta A_\bullet\gamma_\bullet\delta, k, l]$  v chartu vytvoř hranu  $[B \rightarrow \beta_\bullet A\gamma_\bullet\delta, j, l]$ .
- b<sub>1</sub>) pokud je  $E$  ve tvaru  $[B \rightarrow \beta_\bullet\gamma_\bullet A\delta, i, j]$ , potom pro každou hranu  $[A \rightarrow \bullet\alpha_\bullet, j, k]$  v chartu vytvoř hranu  $[B \rightarrow \beta_\bullet\gamma A_\bullet\delta, i, k]$ .
- b<sub>2</sub>) pokud je  $E$  ve tvaru  $[B \rightarrow \beta A_\bullet\gamma_\bullet\delta, k, l]$ , potom pro každou hranu  $[A \rightarrow \bullet\alpha_\bullet, j, k]$  v chartu vytvoř hranu  $[B \rightarrow \beta_\bullet A\gamma_\bullet\delta, j, l]$ .
- c<sub>1</sub>) pokud je  $E$  ve tvaru  $[A \rightarrow \beta a_i \gamma_\bullet\delta, i, j]$ , potom vytvoř hranu  $[A \rightarrow \beta_\bullet a_i \gamma_\bullet\delta, i-1, j]$ .
- c<sub>2</sub>) pokud je  $E$  ve tvaru  $[A \rightarrow \beta_\bullet\gamma_\bullet a_{j+1}\delta, i, j]$ , potom vytvoř hranu  $[A \rightarrow \beta_\bullet\gamma a_{j+1}\bullet\delta, i, j+1]$ .
- d) pokud je  $E$  ve tvaru  $[A \rightarrow \bullet\alpha_\bullet, i, j]$ , potom pro každé pravidlo  $B \rightarrow \beta \underline{A} \gamma$  ve vstupní gramatice vytvoř hranu  $[B \rightarrow \beta_\bullet A_\bullet\gamma, i, j]$  (symbol  $A$  je hlavou pravidla).

## Příklad – chart po analýze řízené hlavou pravidla



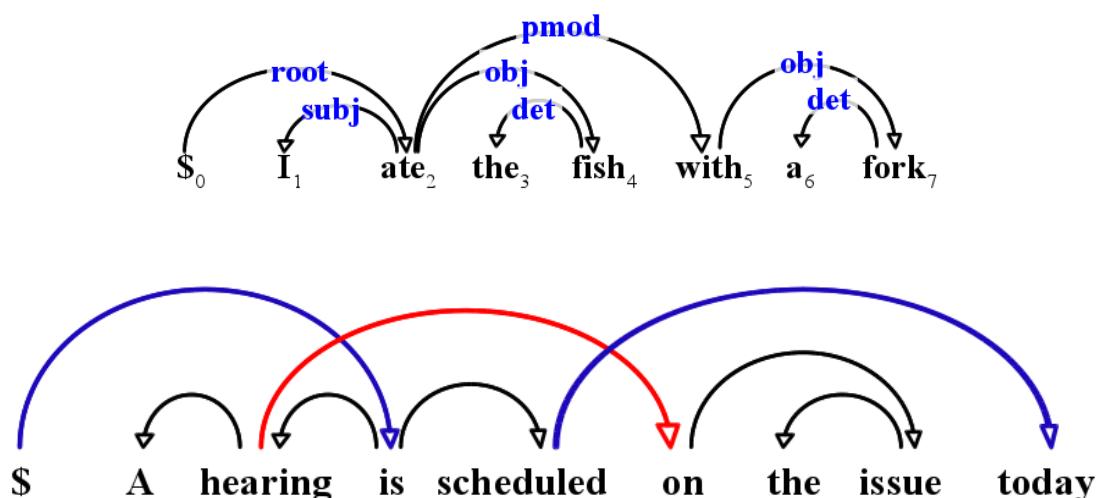
\*1\* = CLAUSE → V OPTPREP . N.

# Porovnání jednotlivých algoritmů



## Syntaktická analýza s využitím strojového učení

- ▶ nejčastěji pro **závislostní formalismy**
- ▶ **jedna hrana** pro každé slovo
- ▶ složitější pro **neprojektivní stromy**

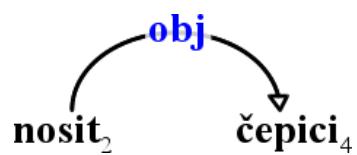


Example from “Dependency Parsing” by Kübler, Nivre, and McDonald, 2009

# Hodnocení úspěšnosti

## základní informace:

- ▶ **hlava** – které slovo je **řídící**
- ▶ **potomek** – které slovo je **závislé**
- ▶ **typ** – označení **typu hrany (label)**



## metriky (vždy procentuálně):

- ▶ **Unlabeled attachment score (UAS)** – slova, která mají **správnou hlavu**
- ▶ **Labeled attachment score (LAS)** – slova, která mají **správnou hlavu a typ**
- ▶ **Root Accuracy (RA)** – analýzy, které mají **správný kořen**
- ▶ **Complete Match rate (CM)** – zcela **správné analýzy**

# Formalizace závislostní analýzy pro učení

$$\mathbf{Y}^* = \arg \max_{\mathbf{Y} \in \Phi(\mathbf{X})} \text{score}(\mathbf{X}, \mathbf{Y})$$

- ▶  $X = x_1 x_2 \dots x_n$  – vstupní **věta**
- ▶  $(h, p)$  – hrana mezi **hlavou**  $x_h$  a **potomkem**  $x_p$
- ▶  $Y = \{(h, p) : 0 \leq h \leq n, 0 < p \leq n\}$  – potenciální **strom**
- ▶  $\Phi(X)$  – množina všech možných závislostních **stromů nad X**

# Způsob řešení závislostní analýzy

základní přístupy:

- ▶ **grafové řešení (graph-based)** – tvorba stromu ze **seznamu hran**
- ▶ **řešení pomocí přechodových akcí (transition-based)** – sekvence **akcí** přiřazujících závislostní **hrany**

2 úkoly:

- ▶ **nalezení stromu (search problem)**
  - známe **skóre hran**, jak najdeme  $Y^*$
  - např. *Maximum Spanning Tree* (McDonald et al, 2005)
- ▶ **učení (learning problem)**
  - máme zadané **věty a stromy**, jak určíme **skóre hran**
  - pomocí **rysů hran** a **online učení**

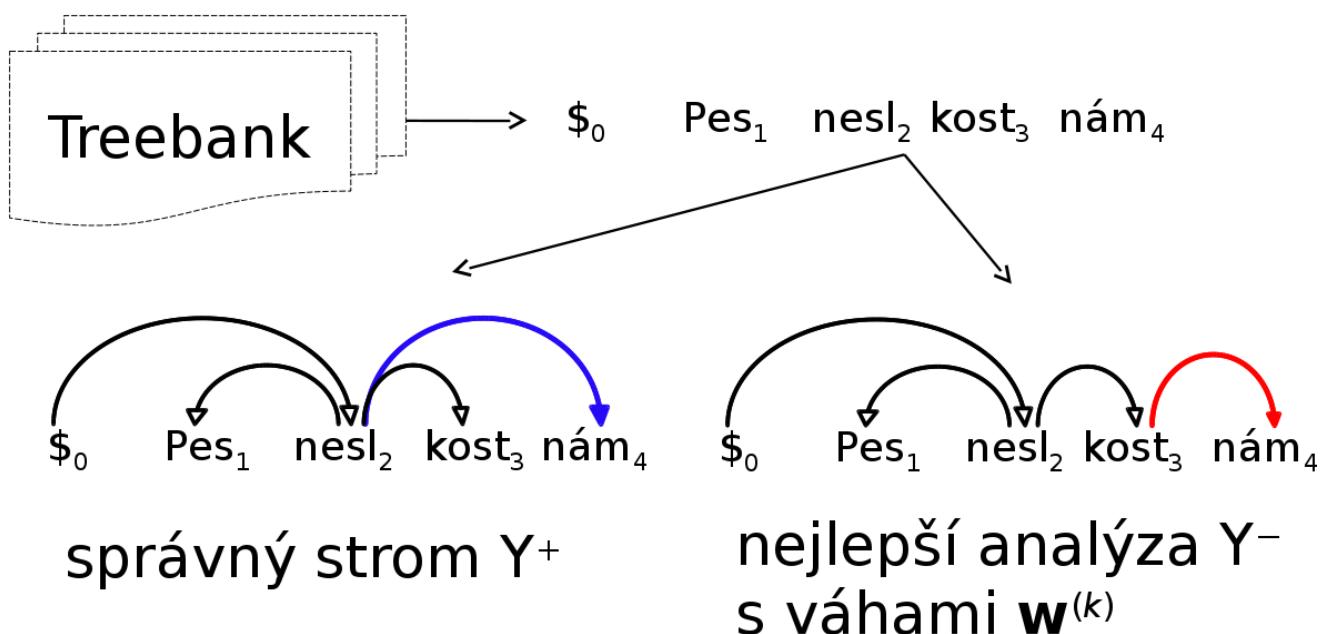
## Rysy závislostních hran

Example from slides of Rush and Petrov (2012)

*	As	McGwire	neared	,	fans	went	wild	
	[went]		[VBD]		[As]		[ADP]	[went]
	[VERB]		[As]		[IN]		[went, VBD]	[As, ADP]
	[went, As]		[VBD, ADP]		[went, VERB]		[As, IN]	[went, As]
	[VERB, IN]		[VBD, As, ADP]		[went, As, ADP]		[went, VBD, ADP]	[went, VBD, As]
	[ADJ, *, ADP]		[VBD, *, ADP]		[VBD, ADJ, ADP]		[VBD, ADJ, *]	[NNS, *, ADP]
	[NNS, VBD, ADP]		[NNS, VBD, *]		[ADJ, ADP, NNP]		[VBD, ADP, NNP]	[VBD, ADJ, NNP]
	[NNS, ADP, NNP]		[NNS, VBD, NNP]		[went, left, 5]		[VBD, left, 5]	[As, left, 5]
	[ADP, left, 5]		[VERB, As, IN]		[went, As, IN]		[went, VERB, IN]	[went, VERB, As]
	[JJ, *, IN]		[VERB, *, IN]		[VERB, JJ, IN]		[VERB, JJ, *]	[NOUN, *, IN]
	[NOUN, VERB, IN]		[NOUN, VERB, *]		[JJ, IN, NOUN]		[VERB, IN, NOUN]	[VERB, JJ, NOUN]
	[NOUN, IN, NOUN]		[NOUN, VERB, NOUN]		[went, left, 5]		[VERB, left, 5]	[As, left, 5]
	[IN, left, 5]		[went, VBD, As, ADP]		[VBD, ADJ, *, ADP]		[NNS, VBD, *, ADP]	[VBD, ADJ, ADP, NNP]
	[NNS, VBD, ADP, NNP]		[went, VBD, left, 5]		[As, ADP, left, 5]		[went, As, left, 5]	[VBD, ADP, left, 5]
	[went, VERB, As, IN]		[VERB, JJ, *, IN]		[NOUN, VERB, *, IN]		[VERB, JJ, IN, NOUN]	[NOUN, VERB, IN, NOUN]
	[went, VERB, left, 5]		[As, IN, left, 5]		[went, As, left, 5]		[VERB, IN, left, 5]	[VBD, As, ADP, left, 5]
	[went, As, ADP, left, 5]		[went, VBD, ADP, left, 5]		[went, VBD, As, left, 5]		[ADJ, *, ADP, left, 5]	[VBD, *, ADP, left, 5]
	[VBD, ADJ, ADP, left, 5]		[VBD, ADJ, *, left, 5]		[NNS, *, ADP, left, 5]		[NNS, VBD, ADP, left, 5]	[NNS, VBD, *, left, 5]
	[ADJ, ADP, NNP, left, 5]		[VBD, ADP, NNP, left, 5]		[VBD, ADJ, NNP, left, 5]		[NNS, ADP, NNP, left, 5]	[NNS, VBD, NNP, left, 5]
	[VERB, As, IN, left, 5]		[went, As, IN, left, 5]		[went, VERB, IN, left, 5]		[went, VERB, As, left, 5]	[JJ, *, IN, left, 5]
	[VERB, *, IN, left, 5]		[VERB, JJ, IN, left, 5]		[VERB, JJ, *, left, 5]		[NOUN, *, IN, left, 5]	[INOUN, VERB, IN, left, 5]

# Online učení skóre závislotních hran

učení **vah jednotlivých rysů w**



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