

Algoritmy syntaktické analýzy (pomocí CFG)

Vladimír Kadlec, Aleš Horák

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

Obsah:

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

Úvod do počítačové lingvistiky 8/12 1 / 29

Základní postupy pro syntaktickou analýzu obecných CFG

Základní postupy pro syntaktickou analýzu obecných bezkontextových gramatik

- ▶ **obecná CFG** – rozsáhlá, (silně) víceznačná, s ϵ -pravidly
- ▶ všechny uvedené algoritmy pracují s *polynomiální časovou a prostorovou složitostí*
- ▶ **Tomitův zobecněný algoritmus LR** (*generalized LR*)
- ▶ **algoritmus CYK** – *Cocke, Younger, Kasami*;
- ▶ **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 $G = \langle N, \Sigma, P, S \rangle$.

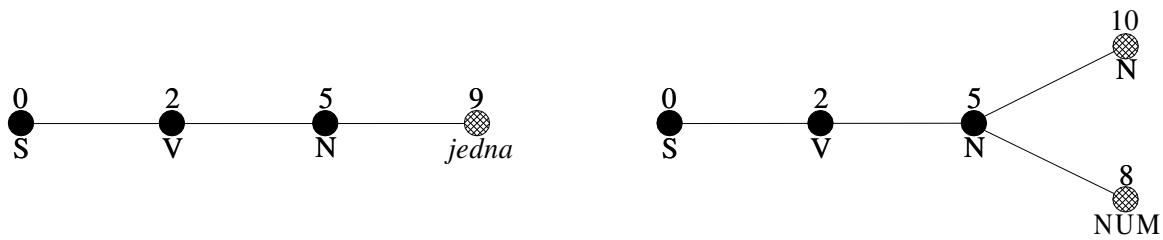
► Výstup:

- 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 | $CLAUSE \rightarrow V N_0 NUM$ | shift | NUM | 8 |
| | $NN \rightarrow N_0 N$ | | N | 10 |
| | $NUM \rightarrow \bullet jedna$ | | $jedna$ | 9 |
| | $N \rightarrow \bullet tramvaj$ | | $tramvaj$ | 7 |
| | $N \rightarrow \bullet jedna$ | | | |
| 9 | $NUM \rightarrow jedna_0$ | reduce (6) | | |
| | $N \rightarrow jedna_0$ | reduce (5) | | |

Algoritmus CYK

- Gramatika musí být v Chomského normální formě

CNF: $A \rightarrow BC$
 $D \rightarrow 'd'$

- Převod libovolné CFG do CNF:

- přidáme nový kořen S_0 : $S_0 \rightarrow S$
- eliminujeme ϵ -pravidla:

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

- eliminujeme jednoduchá pravidla:

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

- rozgenerujeme dlouhá pravidla:

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

Algoritmus CYK, 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 CYK, 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 | 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 CYK 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 CYK pokrač.

```

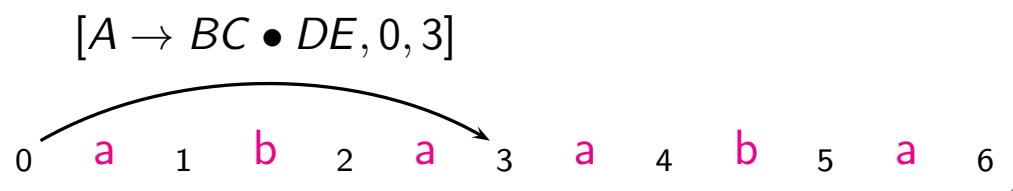
program CYK Parser;
begin
    for  $p := 1$  to  $n$  do  $V[p, 1] := \{A | A \rightarrow a_p \in P\}$ ;
    for  $q := 2$  to  $n$  do
        for  $p := 1$  to  $n - q + 1$  do
             $V[p, q] = \emptyset$ ;
            for  $k := 1$  to  $q - 1$  do
                 $V[p, q] =$ 
           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

```

složitost CYK 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.
- ▶ Analyzátoři 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 hrana 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 $[B \rightarrow \bullet\gamma, j, j]$.

Příklad – tabulkové analýzy (typu chart)

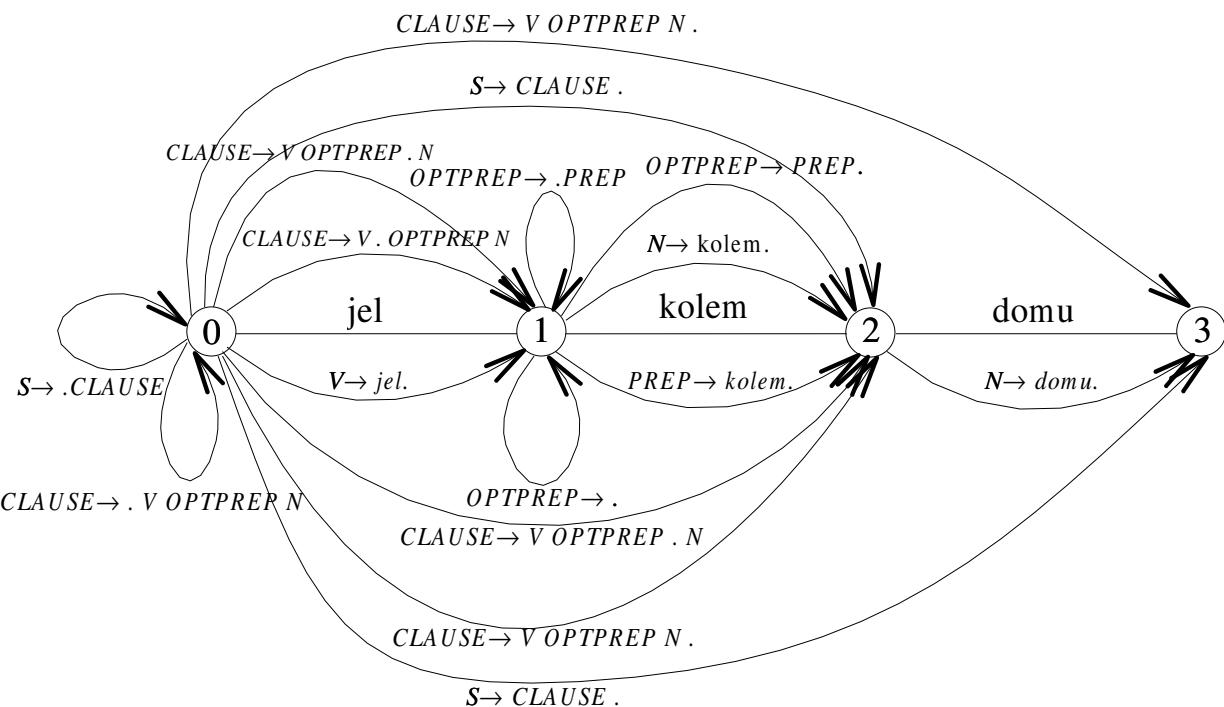
Gramatika:

| | | |
|-----------|---------------|---------------|
| S | \rightarrow | $CLAUSE$ |
| $CLAUSE$ | \rightarrow | $V OPTPREP N$ |
| $OPTPREP$ | \rightarrow | ϵ |
| $OPTPREP$ | \rightarrow | $PREP$ |
| V | \rightarrow | jel |
| $PREP$ | \rightarrow | $kolem$ |
| N | \rightarrow | $domu$ |
| N | \rightarrow | $kolem$ |

Věta:

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

Příklad – chart po analýze shora dolů



Varianta zdola nahoru

I 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 ϵ .
- ▶ 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 β .
- ▶ 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?

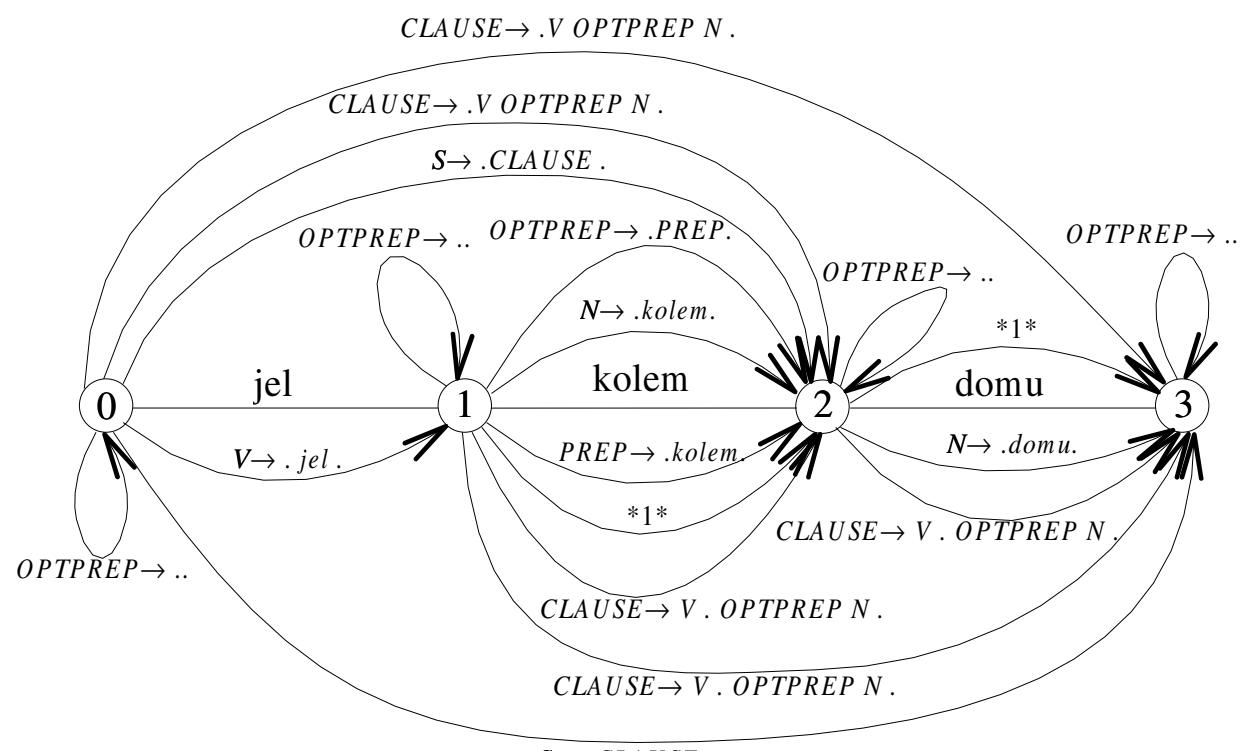
Co když inicializace nic nepřidá? (žadné ϵ ani žádný terminál jako hlava)
Odpověď: taková gramatika by generovala prázdný jazyk.

Analyzátor řízený hlavou pravidla pokrač.

Iterace – vezmi hranu E z agendy a pak:

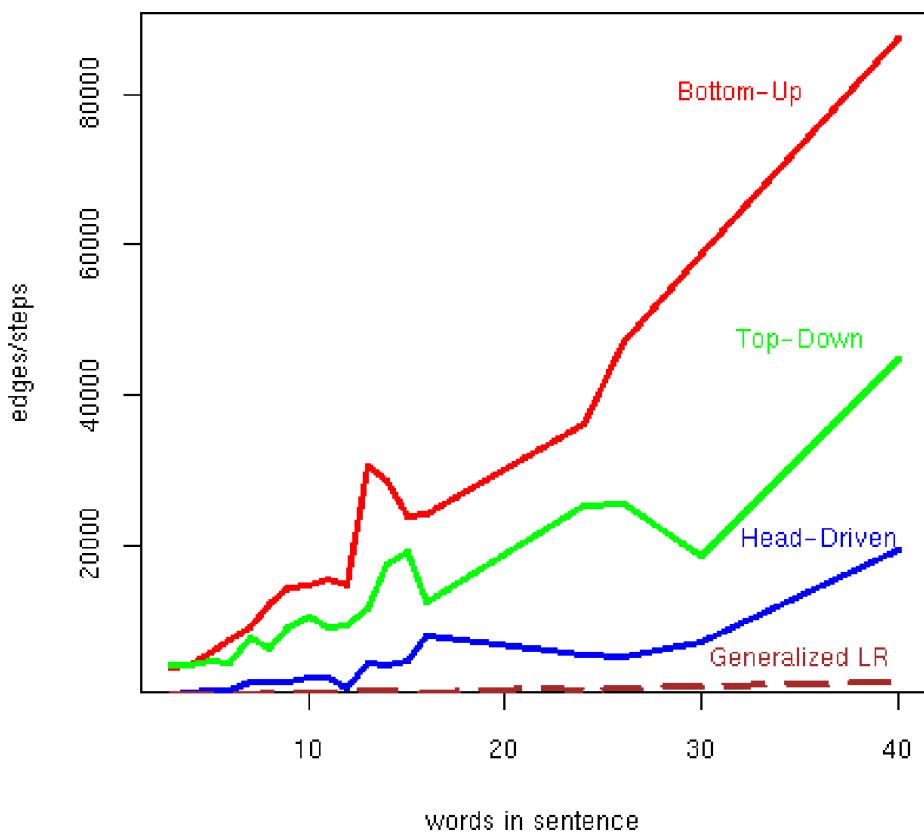
- a₁) pokud je E ve tvaru $[A \rightarrow \cdot \alpha \cdot, j, k]$, potom pro každou hranu: $[B \rightarrow \beta \cdot \gamma \cdot A \delta, i, l]$ v chartu vytvoř hranu $[B \rightarrow \beta \cdot \gamma A \cdot \delta, i, k]$,
- a₂) pro $[B \rightarrow \beta A \cdot \gamma \cdot \delta, k, l]$ v chartu vytvoř hranu $[B \rightarrow \beta \cdot A \gamma \cdot \delta, j, l]$.
- b₁) pokud je E ve tvaru $[B \rightarrow \beta \cdot \gamma \cdot A \delta, i, j]$, potom pro každou hranu $[A \rightarrow \cdot \alpha \cdot, j, k]$ v chartu vytvoř hranu $[B \rightarrow \beta \cdot \gamma A \cdot \delta, i, k]$.
- b₂) pokud je E ve tvaru $[B \rightarrow \beta A \cdot \gamma \cdot \delta, k, l]$, potom pro každou hranu $[A \rightarrow \cdot \alpha \cdot, j, k]$ v chartu vytvoř hranu $[B \rightarrow \beta \cdot A \gamma \cdot \delta, j, l]$.
- c₁) pokud je E ve tvaru $[A \rightarrow \beta a_i \cdot \gamma \cdot \delta, i, j]$, potom vytvoř hranu $[A \rightarrow \beta \cdot a_i \gamma \cdot \delta, i-1, j]$.
- c₂) pokud je E ve tvaru $[A \rightarrow \beta \cdot \gamma \cdot a_{j+1} \delta, i, j]$, potom vytvoř hranu $[A \rightarrow \beta \cdot \gamma a_{j+1} \cdot \delta, i, j+1]$.
- d) pokud je E ve tvaru $[A \rightarrow \cdot \alpha \cdot, i, j]$, potom pro každé pravidlo $B \rightarrow \beta \underline{A} \gamma$ ve vstupní gramatice vytvoř hranu $[B \rightarrow \beta \cdot A \cdot \gamma, i, j]$ (symbol A je hlavou pravidla).

Příklad – chart po analýze řízené hlavou pravidla



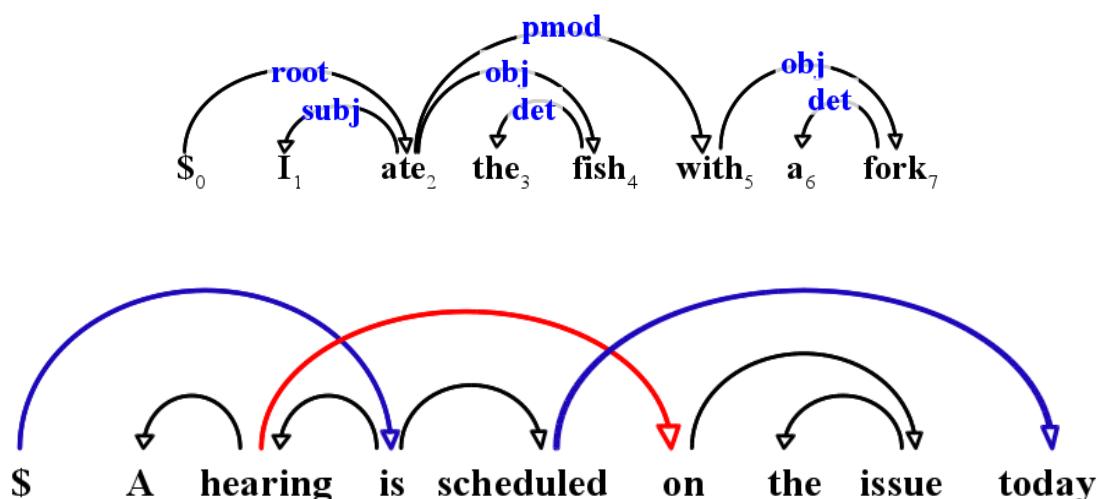
1 = CLAUSE → V OPTPREP . N .

Porovnání jednotlivých algoritmů



Syntaktická analýza s využitím strojového učení

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

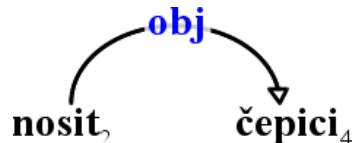


Example from “Dependency Parsing” by Kübler, Nivre, and McDonald, 2009

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

$$Tree^{best} = \arg \max_{Tree \in \Phi(Sentence)} score(Sentence, Tree)$$

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

$$score(Sentence, Tree) = \sum_{(h,p) \in Tree} score(Sentence, h, p)$$

Způsob řešení závislostní analýzy

základní přístupy:

- ▶ řešení pomocí přechodových akcí (*transition-based*) – sekvence akcí přiřazujících závislostní hrany, využívá zásobník *arc-standard* akce – *shift*, *leftarc_type*, *rightarc_type*
takto odpovídá shift-reduce analýze, s dalšími akcemi (*swap*, *reduce*) zvládne i neprojektivní analýzy
např. *MaltParser* (Nivre et al, 2006)
- ▶ grafové řešení (*graph-based*) – tvorba stromu z ohodnoceného seznamu hran
grafové řešení je flexibilnější

Závislostní analýza pomocí přechodových akcí – příklad

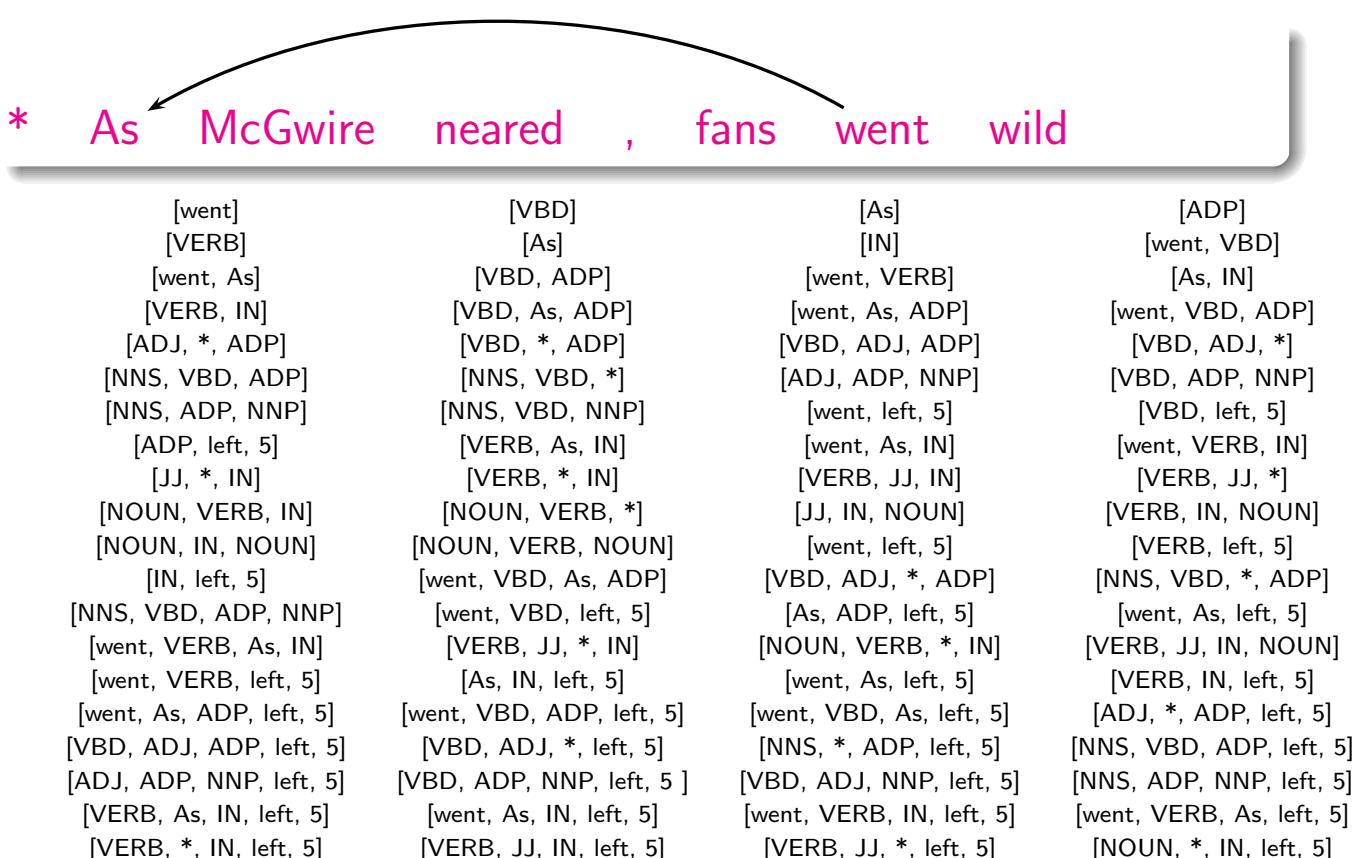
| krok | zásobník | vstup | akce | hrana |
|------|----------------------------------|-------------------------------------|----------|-----------------|
| 0 | [root] | [dej, Karlovi, tu, novou, knihu] | SHIFT | |
| 1 | [root, dej] | [Karlovi, tu, novou, knihu] | SHIFT | |
| 2 | [root, dej, Karlovi] | [tu, novou, knihu] | RIGHTARC | (dej → Karlovi) |
| 3 | [root, dej] | [tu, novou, knihu] | SHIFT | |
| 4 | [root, dej, tu] | [novou, knihu] | SHIFT | |
| 5 | [root, dej, tu, novou] | [knihu] | SHIFT | |
| 6 | [root, dej, tu, novou, knihu] | [] | LEFTARC | (novou ← knihu) |
| 7 | [root, dej, tu, knihu] | [] | LEFTARC | (tu ← knihu) |
| 8 | [root, dej, knihu] | [] | RIGHTARC | (dej → knihu) |
| 9 | [root, dej] | [] | RIGHTARC | (root → dej) |
| 10 | [root] | [] | — | |

Grafové řešení závislostní analýzy

2 úkoly:

- ▶ **nalezení stromu (search problem)**
 - známe skóre hran, jak najdeme $\text{Tree}^{\text{best}}$
 - 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

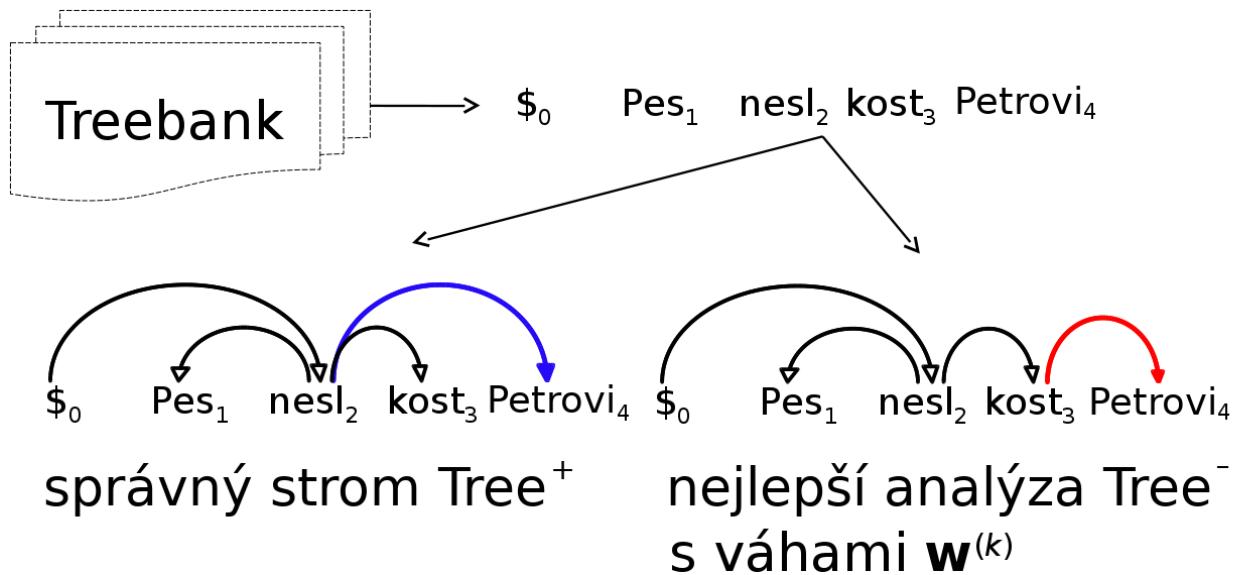
Risy závislostních hran



(příklad z Rush and Petrov, 2012)

Online učení skóre závislostních hran

učení **vah jednotlivých rysů w**



$$\mathbf{w}^{(k+1)} = \mathbf{w}^{(k)} + f(\text{Sentence}, \text{Tree}^+) - f(\text{Sentence}, \text{Tree}^-)$$