

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 CKY
- ▶ Tabulkové analyzátoře
- ▶ Porovnání jednotlivých algoritmů
- ▶ Syntaktická analýza s využitím strojového učení

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

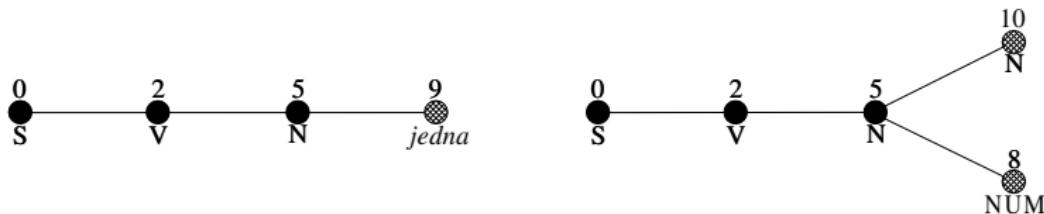
► Výstup:

- 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 | $CLAUSE \rightarrow V N \bullet N \text{UM}$ | shift | NUM | 8 |
| | $NN \rightarrow N \bullet N$ | | N | 10 |
| | $NUM \rightarrow \bullet jedna$ | | <i>jedna</i> | 9 |
| | $N \rightarrow \bullet tramvaj$ | | <i>tramvaj</i> | 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

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

- Převod libovolné CFG do CNF:

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

$$\begin{array}{ll} S & \rightarrow Ab \quad | \quad B \\ A & \rightarrow a \quad | \quad \epsilon \end{array} \rightarrow \begin{array}{ll} S & \rightarrow Ab \quad | \quad b \quad | \quad B \\ A & \rightarrow a \end{array}$$

- eliminujeme jednoduchá pravidla:

$$\begin{array}{ll} A & \rightarrow B \\ B & \rightarrow a \quad | \quad CD \end{array} \rightarrow \begin{array}{ll} A & \rightarrow a \quad | \quad CD \\ B & \rightarrow a \quad | \quad CD \end{array}$$

- rozgenerujeme dlouhá pravidla:

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

Algoritmus CKY, příklad – zadání

- ▶ vstupní gramatika je:

$$S \rightarrow AA|BB|AX|BY|a|b$$

$$X \rightarrow SA$$

$$Y \rightarrow SB$$

$$A \rightarrow a$$

$$B \rightarrow b$$

- ▶ vstupní řetězec je $w = abaaba$.

Algoritmus CKY, příklad – řešení (matice V)

$$S \rightarrow AA|BB|AX|BY|a|b$$

$$X \rightarrow SA$$

$$Y \rightarrow SB$$

$$A \rightarrow a$$

$$B \rightarrow b$$

a b a a b a

p – pozice, q – délka

| $p \backslash q$ | 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
end

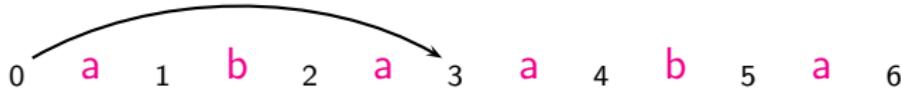
```

složitost CKY je $O(n^3)$

Tabulkové (chart) analyzátor

- ▶ 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.
- ▶ Analyzátor typu "chart" v sobě většinou obsahují dvě datové struktury chart a agenda. 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.

$[A \rightarrow BC \bullet DE, 0, 3]$



Obecný analyzátor typu “chart”

program Chart Parser;

begin

 inicjalizuj (*CHART*);

 inicjalizuj (*AGENDA*);

 while (*AGENDA* $\neq \emptyset$) 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* \notin *AGENDA* and *F* \notin *CHART* and *F* \neq *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)

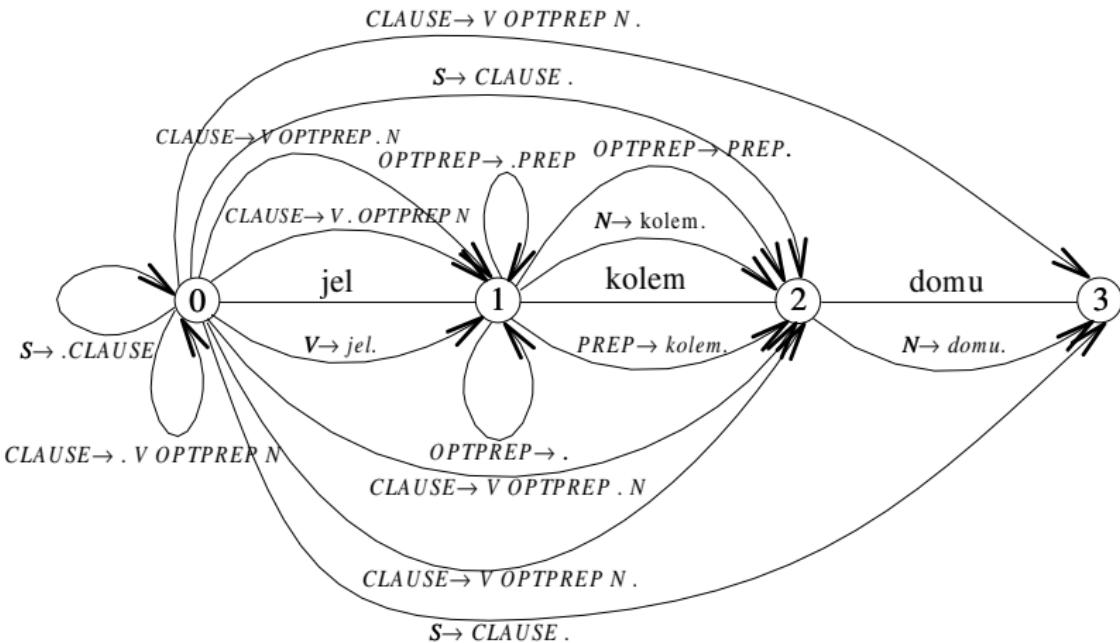
Gramatika:

| | | |
|----------------|---------------|--------------------|
| <i>S</i> | \rightarrow | <i>CLAUSE</i> |
| <i>CLAUSE</i> | \rightarrow | <i>V OPTPREP N</i> |
| <i>OPTPREP</i> | \rightarrow | ϵ |
| <i>OPTPREP</i> | \rightarrow | <i>PREP</i> |
| <i>V</i> | \rightarrow | <i>jel</i> |
| <i>PREP</i> | \rightarrow | <i>kolem</i> |
| <i>N</i> | \rightarrow | <i>domu</i> |
| <i>N</i> | \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 hranы) 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 $[A \rightarrow \dots, 0, 0]$, $[A \rightarrow \dots, 1, 1]$, ..., $[A \rightarrow \dots, n, n]$ 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?

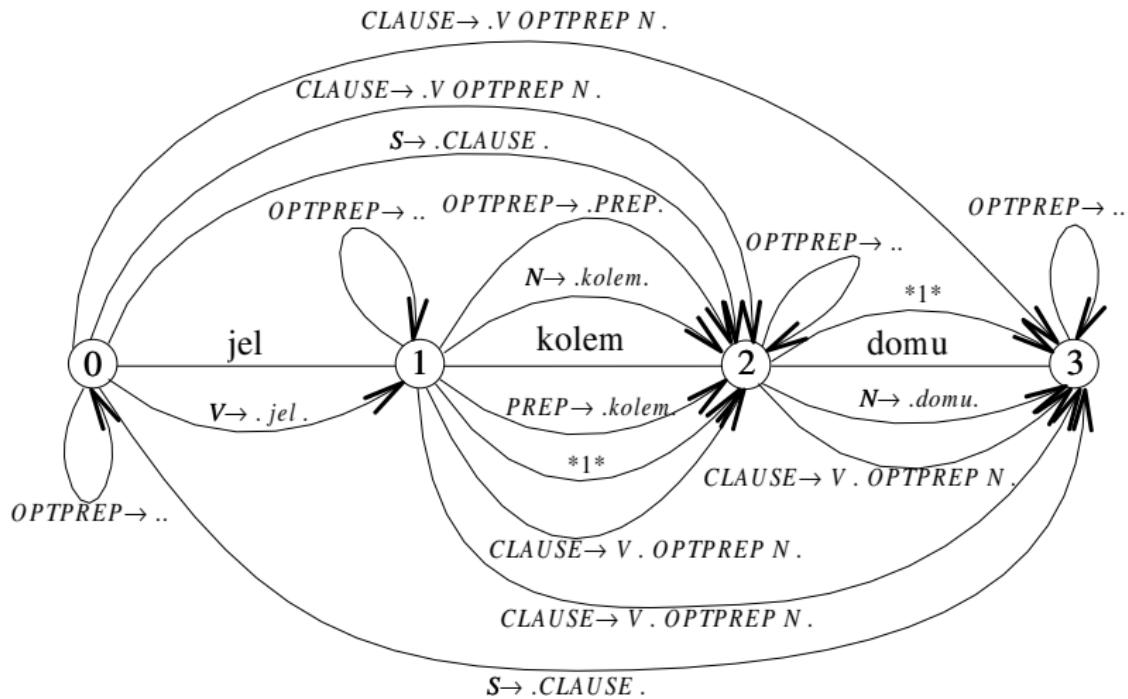
Co když inicializace nic nepřidá? (žadné ϵ ani žádný terminál jako hlava)
Odpověď: taková gramatika by generovala prázdný jazyk.

Analyzátor řízený hlavou pravidla pokrač.

Iterace – vezmi hranu E z agendy a pak:

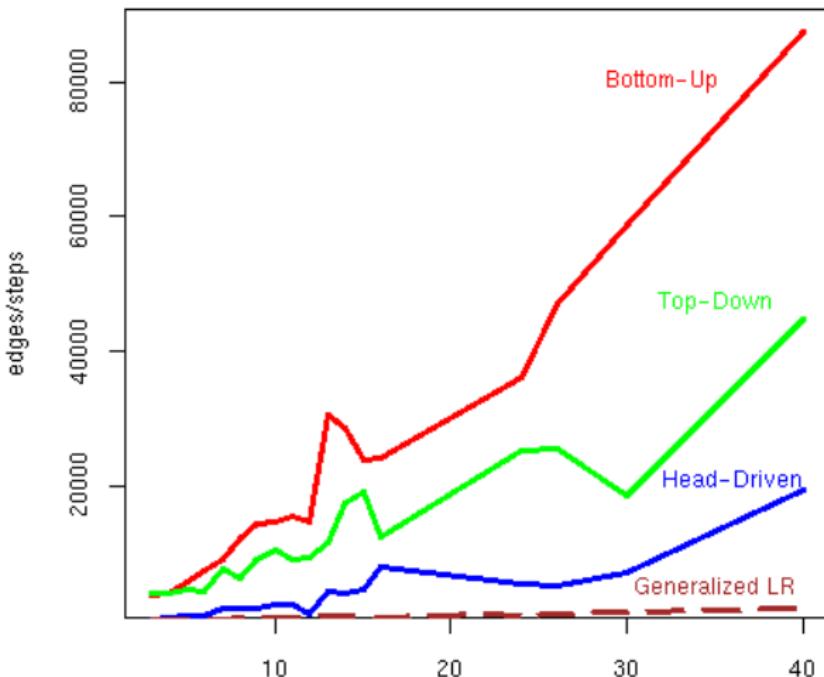
- pokud je E ve tvaru $[A \rightarrow \bullet\alpha_\bullet, j, k]$, potom pro každou hranu: $[B \rightarrow \beta_\bullet\gamma_\bullet A\delta, i, j]$ v chartu vytvoř hranu $[B \rightarrow \beta_\bullet\gamma A_\bullet\delta, i, k]$,
- pro $[B \rightarrow \beta A_\bullet\gamma_\bullet\delta, k, l]$ v chartu vytvoř hranu $[B \rightarrow \beta_\bullet A\gamma_\bullet\delta, j, l]$.
- 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 $[B \rightarrow \beta_\bullet\gamma A_\bullet\delta, i, k]$.
- 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 $[B \rightarrow \beta_\bullet A\gamma_\bullet\delta, j, l]$.
- pokud je E ve tvaru $[A \rightarrow \beta a_i \gamma_\bullet\delta, i, j]$, potom vytvoř hranu $[A \rightarrow \beta_\bullet a_i \gamma_\bullet\delta, i-1, j]$.
- pokud je E ve tvaru $[A \rightarrow \beta_\bullet\gamma_\bullet a_{j+1}\delta, i, j]$, potom vytvoř hranu $[A \rightarrow \beta_\bullet\gamma a_{j+1} \bullet\delta, i, j+1]$.
- 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



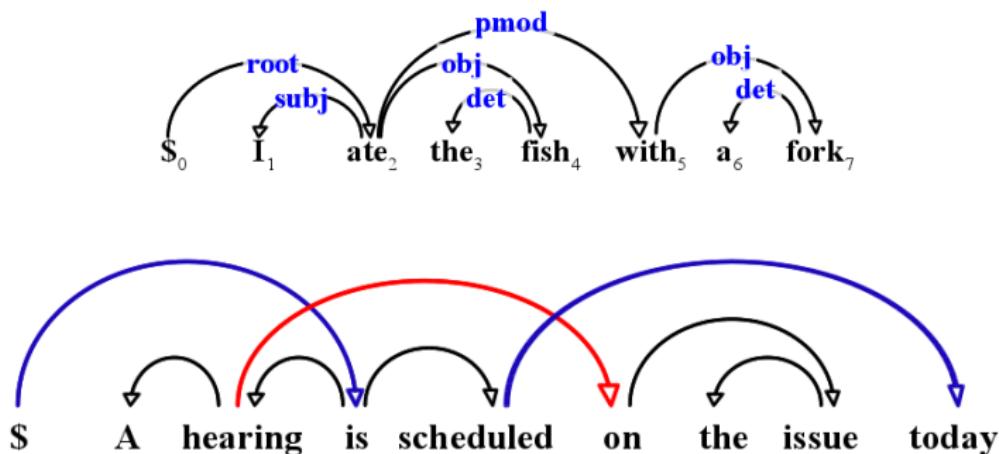
$*1* = CLAUSE \rightarrow V. OPTPREP . N.$

Porovnání jednotlivých algoritmů



Syntaktická analýza s využitím strojového učení

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

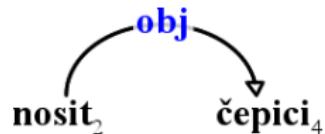


Example from “Dependency Parsing” by Kübler, Nivre, and McDonald, 2009

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

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

- ▶ $X = x_1 x_2 \dots x_n$ – 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

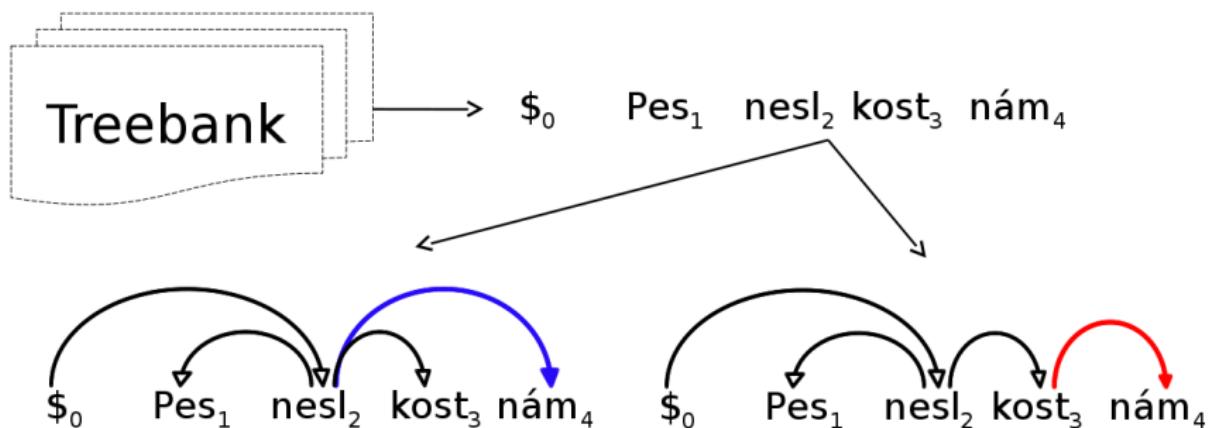
Example from slides of Rush and Petrov (2012)



| | | | | | | | | |
|---|--------------------------|---------|---------------------------|---|---------------------------|------|---------------------------|---------------------------|
| * | 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] | [NOUN, VERB, IN, left, 5] |

Online učení skóre závislotních hran

učení **vah jednotlivých rysů w**



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