

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

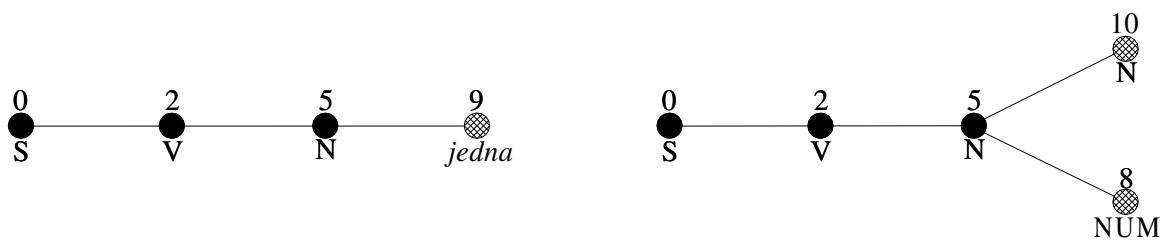
► Výstup:

- 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	$CLAUSE \rightarrow V N \bullet . NUM$	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

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 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	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.

```

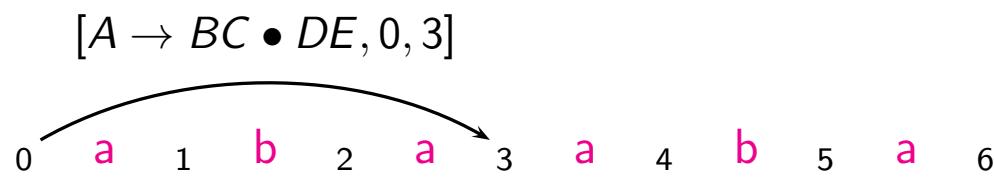
program CKY Parser;
begin
    for  $p := 1$  to  $n$  do  $V[p, 1] := \{A | A \rightarrow a_p \in P\}$ ;
    for  $q := 2$  to  $n$  do
        for  $p := 1$  to  $n - q + 1$  do
             $V[p, q] = \emptyset$ ;
            for  $k := 1$  to  $q - 1$  do
                 $V[p, q] =$ 
           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

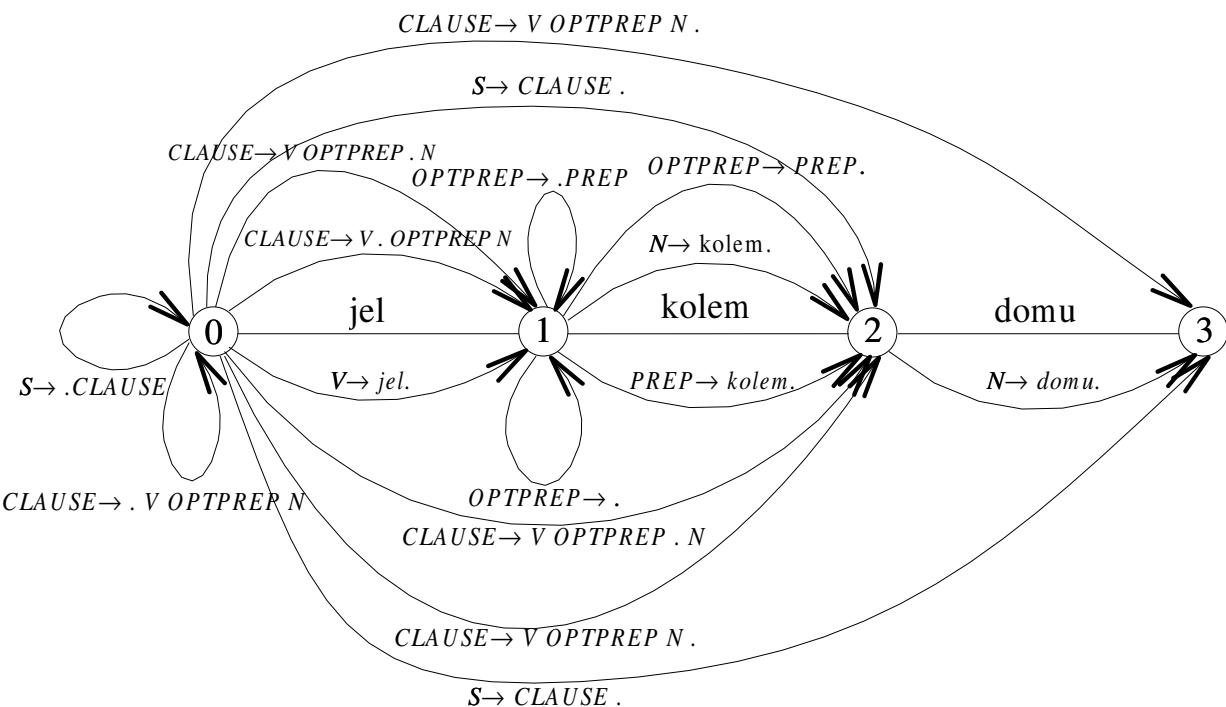
Gramatika:

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?

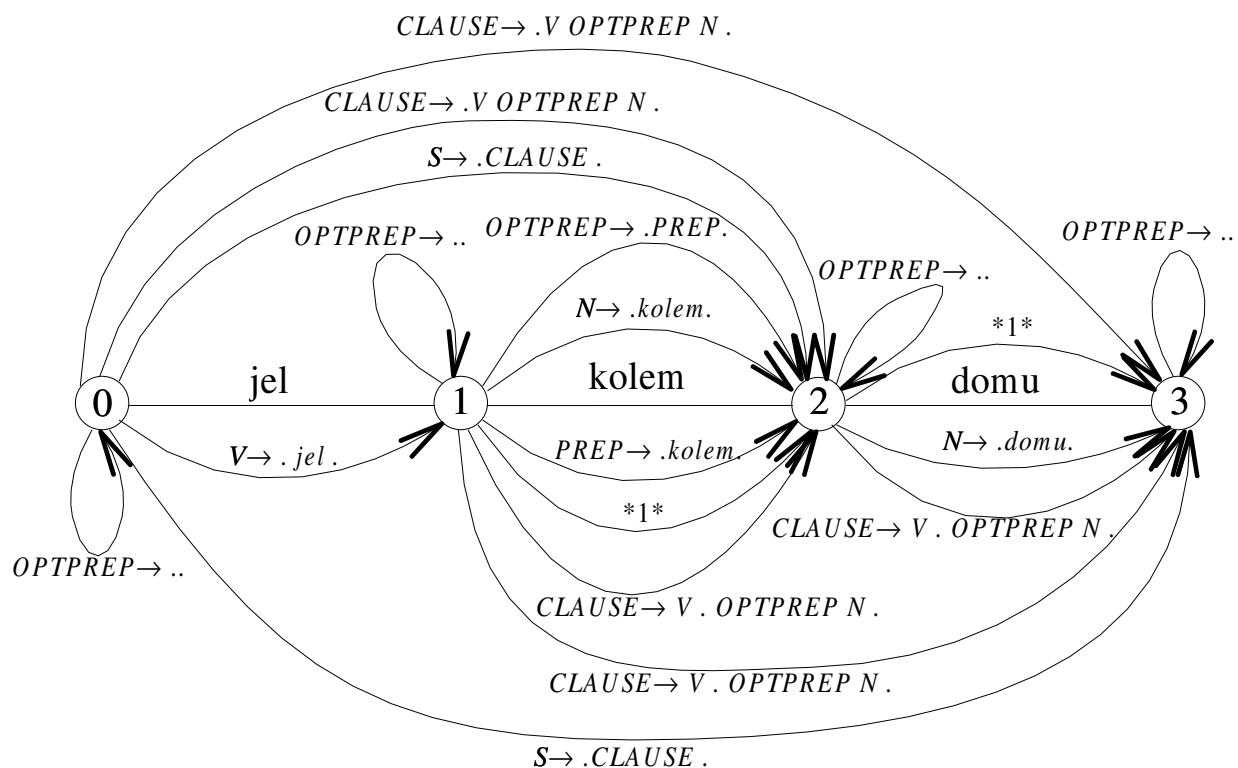
Co když inicializace nic nepřidá? (žadné ϵ ani žádný terminál jako hlava)
Odpověď: taková gramatika by generovala prázdný jazyk.

Analyzátor řízený hlavou pravidla pokrač.

Iterace – vezmi hranu E z agendy a pak:

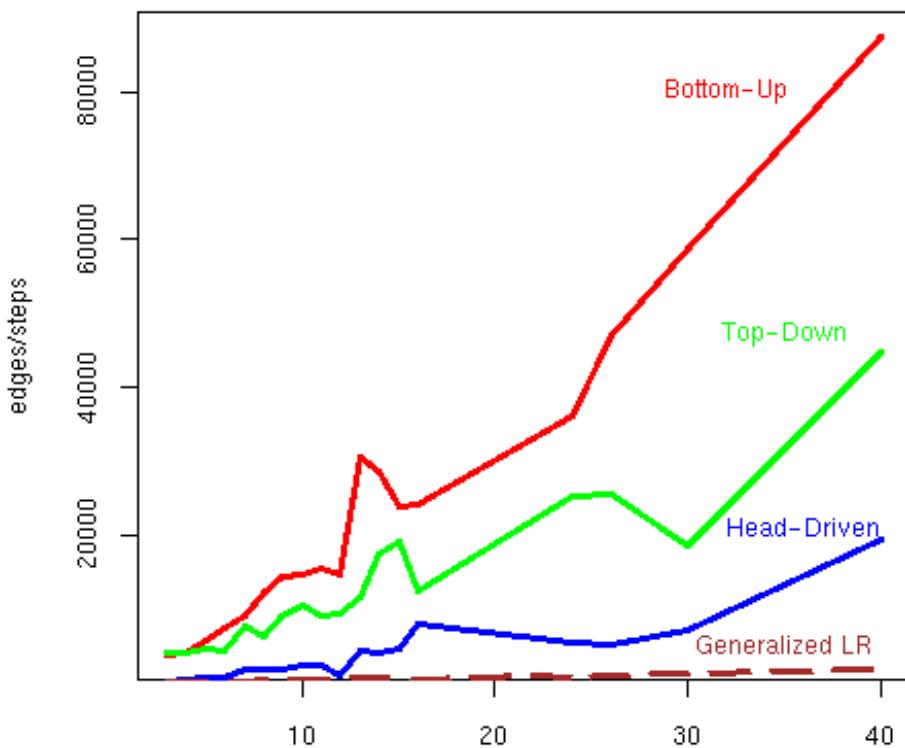
- a₁) pokud je E ve tvaru $[A \rightarrow \bullet\alpha\bullet, j, k]$, potom pro každou hranu: $[B \rightarrow \beta\bullet\gamma\bullet A\delta, i, j]$ v chartu vytvoř hranu $[B \rightarrow \beta\bullet\gamma A\bullet\delta, i, k]$,
 - a₂) pro $[B \rightarrow \beta A\bullet\gamma\bullet\delta, k, l]$ v chartu vytvoř hranu $[B \rightarrow \beta\bullet A\gamma\bullet\delta, j, l]$.
 - b₁) 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 $[B \rightarrow \beta\bullet\gamma A\bullet\delta, i, k]$.
 - b₂) 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 $[B \rightarrow \beta\bullet A\gamma\bullet\delta, j, l]$.
 - c₁) pokud je E ve tvaru $[A \rightarrow \beta a_i\bullet\gamma\bullet\delta, i, j]$, potom vytvoř hranu $[A \rightarrow \beta\bullet a_i\gamma\bullet\delta, i-1, j]$.
 - c₂) 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



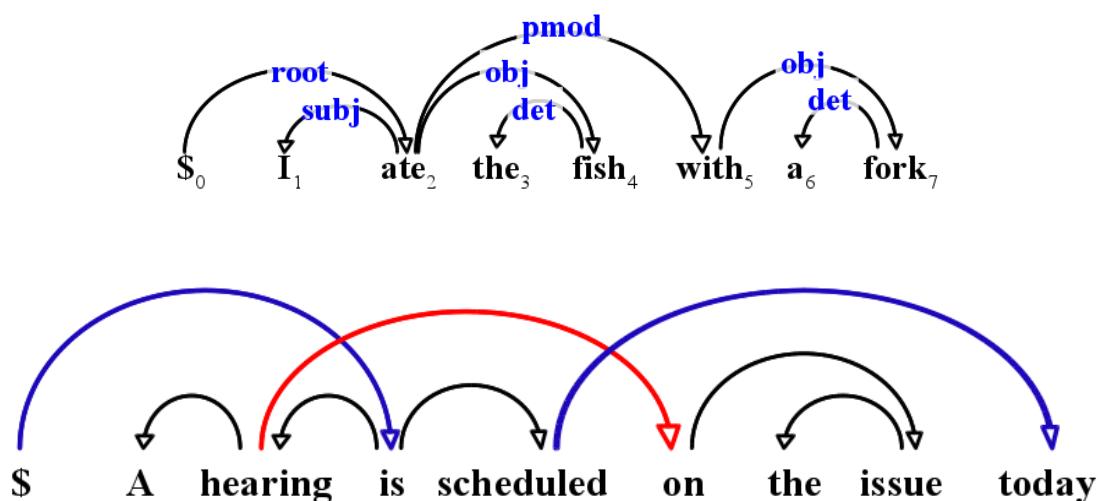
1 = CLAUSE → V OPTPREP . N .

Porovnání jednotlivých algoritmů



Syntaktická analýza s využitím strojového učení

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

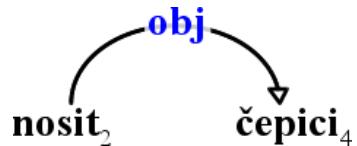


Example from “Dependency Parsing” by Kübler, Nivre, and McDonald, 2009

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

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

- ▶ $X = x_1 x_2 \dots x_n$ – 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
- ▶ $\text{score}(X, Y)$ – závisí na algoritmu, např.

$$\text{score}(X, Y) = \sum_{(h,p) \in Y} \text{score}(X, h, p)$$

Způsob řešení závislostní analýzy

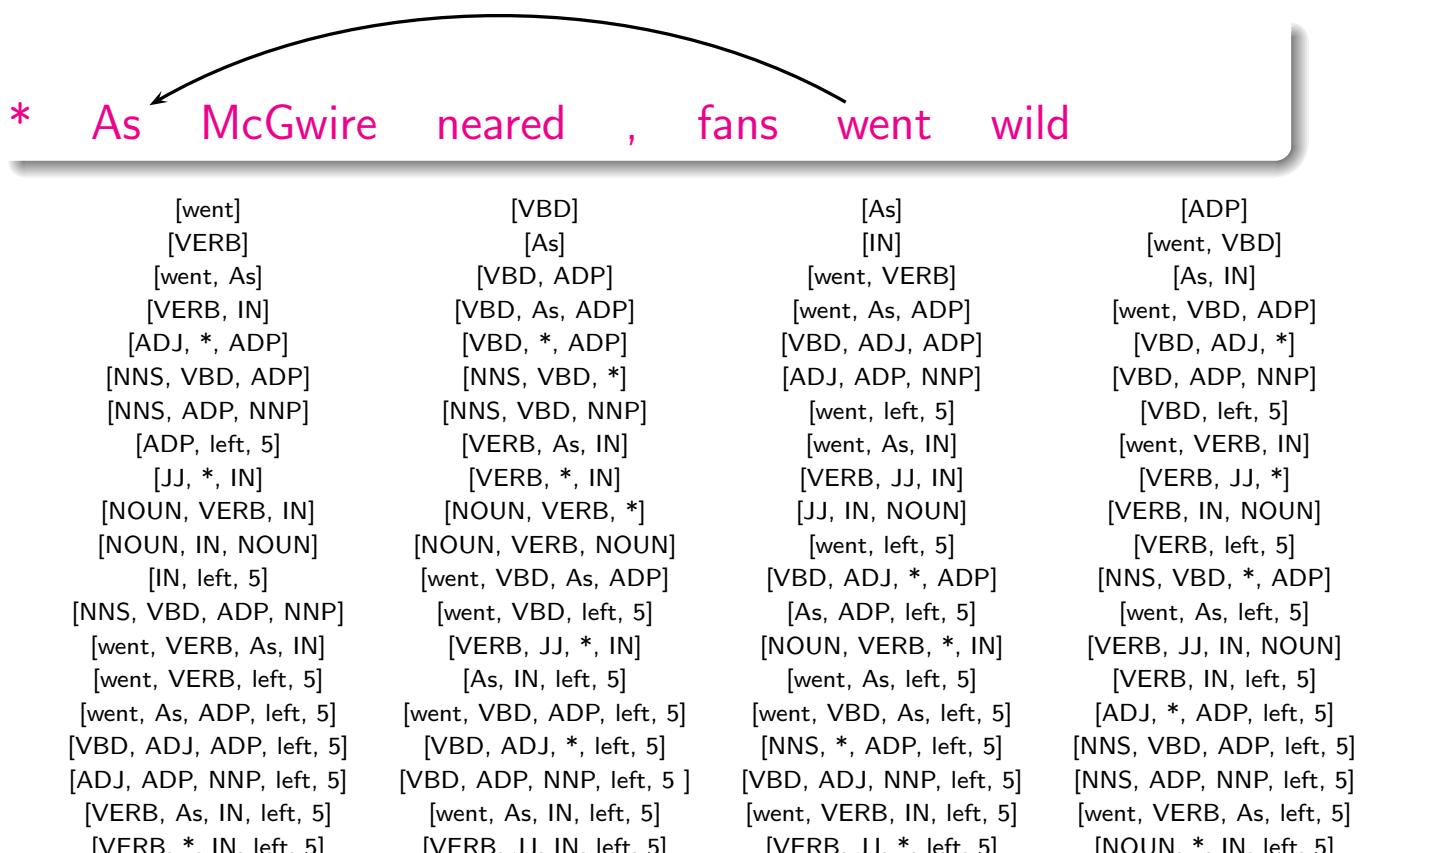
základní přístupy:

- ▶ **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



Online učení skóre závislotních hran

učení **vah jednotlivých rysů w**

