

# 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
- ▶ Algoritmus CKY
- ▶ Tabulkové analyzátory
- ▶ Tomitův zobecněný analyzátor LR
- ▶ Porovnání jednotlivých algoritmů

## 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.

# 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*
- ▶ **algoritmus CKY** – Cocke, Kasami, Younger;
- ▶ **tabulková (chart) analýza** (neplést s LR tabulkou):
  - shora dolů (*top-down*);
  - zdola nahoru (*bottom-up*);
  - analýza řízená hlavou pravidla (*head-driven*);
- ▶ **Tomitův zobecněný algoritmus LR**

## Algoritmus CKY

- ▶ Gramatika musí být v **Chomského normální formě**

$$\begin{aligned} \text{CNF: } & A \rightarrow BC \\ & D \rightarrow 'd' \end{aligned}$$

- ▶ **Převod libovolné CFG do CNF:**

$$S_0 \rightarrow S$$

1. přidáme **nový kořen**  $S_0$ :

2. eliminujeme  $\epsilon$ -**pravidla**:

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

3. eliminujeme **jednoduchá pravidla**:

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

4. rozgenerujeme **dlouhá pravidla**:

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

# Algoritmus CKY

- 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, příklad – řešení (matice V)

		a b a a b a					
		1	2	3	4	5	6
		S, A	S, B	S, A	S, A	S, B	S, A
p	q						
1	1						
2	2						
3	3						
4	4						
5	5						
6	6						

$p$  – pozice,  $q$  – délka

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

## 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 pokrač.

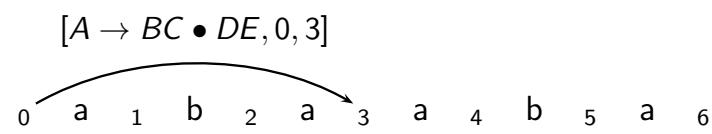
```

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) 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.
- 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.



## 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:

- (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  $[A \rightarrow \alpha \bullet a_{j+1} \beta, i, j]$ , vytvoř hranu  $[A \rightarrow \alpha a_{j+1} \bullet \beta, i, j+1]$ .
- (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  $[B \rightarrow \bullet \gamma, i, j]$ .

## Obecný analyzátor typu "chart"

```

program Chart Parser;
begin
    inicializuj (CHART);
    inicializuj (AGENDA);
    while (AGENDA není prázdná) 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 (( $F$  není v AGENDA) and ( $F$  není v CHART) and
                ( $F$  je různá od  $E$ )
                then přidej  $F$  do AGENDA;
            fi;
        od;
        přidej  $E$  do CHART;
    od;
end;
  
```

## Příklad – tabulkové analýzy (typu chart)

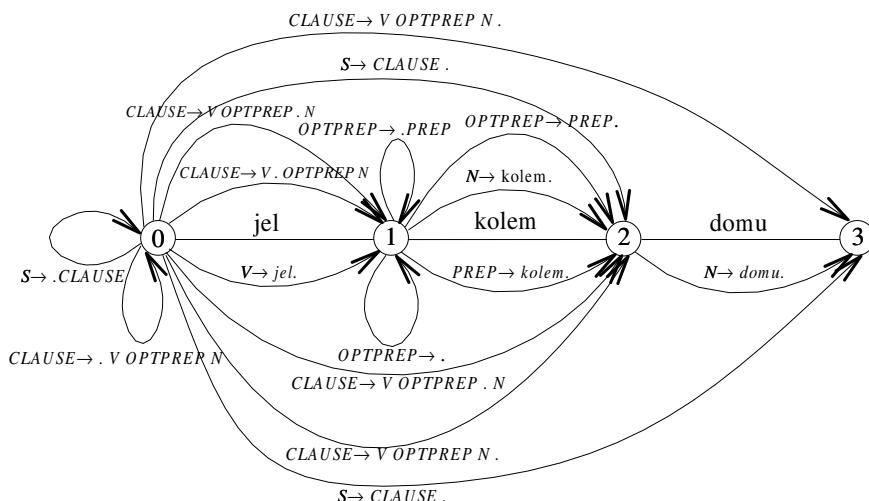
### Gramatika:

$S$	$\rightarrow$	<i>CLAUSE</i>
<i>CLAUSE</i>	$\rightarrow$	<i>V OPTPREP N</i>
<i>OPTPREP</i>	$\rightarrow$	$\epsilon$
<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



## Analýza řízená hlavou pravidla

- ▶ head-driven chart parsing
- ▶ **Hlava pravidla** – libovolný (určený) symbol z pravé strany pravidla.  
Například pravidlo  $CLAUSE \rightarrow V \ OPTPREP \ N$  může mít hlavy  $V$ ,  $OPTPREP$ ,  $N$ .
- ▶ 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.

## Varianta zdola nahoru

### Inicializace:

- ▶  $\forall p \in P \mid p = A \rightarrow \epsilon$  přidej hrany  $[A \rightarrow \bullet, 0, 0], [A \rightarrow \bullet, 1, 1], \dots, [A \rightarrow \bullet, n, n]$  do agendy.
- ▶  $\forall p \in P \mid p = A \rightarrow a; \alpha$  přidej hranu  $[A \rightarrow \bullet a; \alpha, i-1, i-1]$  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  $[B \rightarrow \bullet A\gamma, i, j]$ .

## 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.
- ▶  $\forall p \in P \mid p = A \rightarrow \alpha a_i \beta$  ( $a_i$  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?

## Analyzátor řízený hlavou pravidla pokrač.

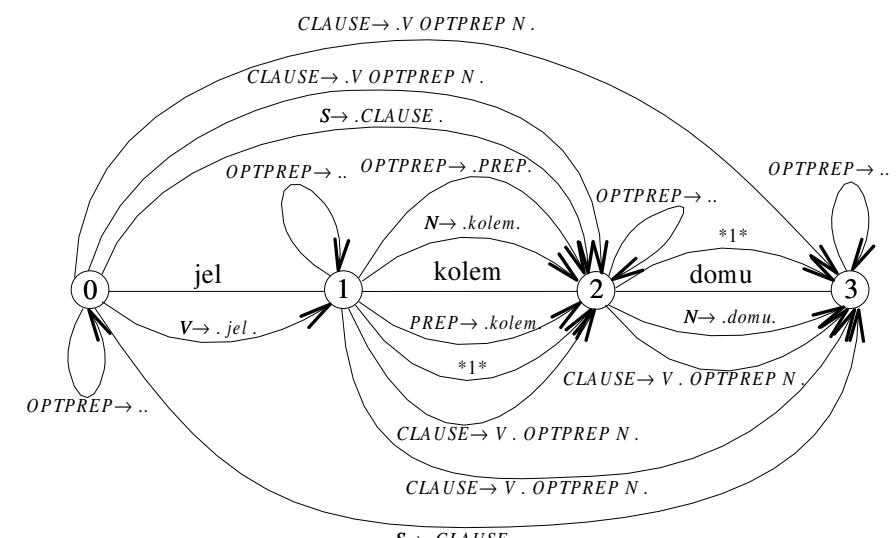
**Iterace** – vezmi hranu  $E$  z agendy a pak:

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

## Tomitův zobecněný analyzátor LR

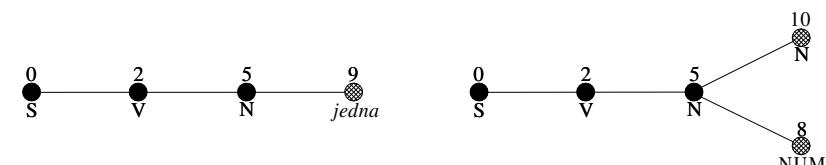
- ▶ generalized LR parser (GLR)
- ▶ Masaru Tomita: Efficient parsing for natural language, 1986
- ▶ standardní LR tabulka, která může obsahovat konflikty;
- ▶ zásobník je reprezentován acyklickým orientovaným grafem (DAG);
- ▶ derivační stromy jsou uloženy ve sbaleném "lese" stromů.
- ▶ v podstatě stejný, 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 – chart po analýze řízené hlavou pravidla



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

## 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)		

## Porovnání jednotlivých algoritmů

