

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

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*);

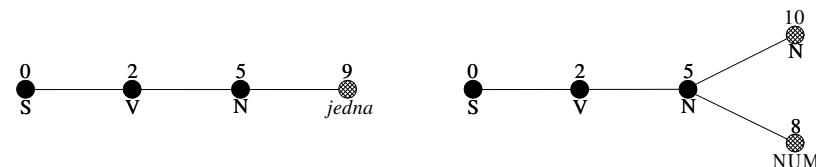
Syntaktická analýza

- ▶ **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" stromu**
- ▶ 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 | $CLAUSE \rightarrow V N \cdot NUM$ | shift | NUM | 8 |
| | $NN \rightarrow N \cdot N$ | | N | 10 |
| | $NUM \rightarrow \cdot jedna$ | | jedna | 9 |
| | $N \rightarrow \cdot tramvaj$ | | tramvaj | 7 |
| | $N \rightarrow \cdot jedna$ | | | |
| 9 | $NUM \rightarrow jedna \cdot$ | reduce (6) | | |
| | $N \rightarrow jedna \cdot$ | 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:

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

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)

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

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 | | | | | |

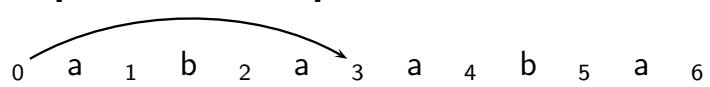
Algoritmus CKY pokrač.

- 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."

Tabulkové (chart) analyzátoře

- 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.

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



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 $O(n^3)$

Obecný analyzátor typu "chart"

```

program Chart Parser;
begin
  inicializuj (CHART);
  inicializuj (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

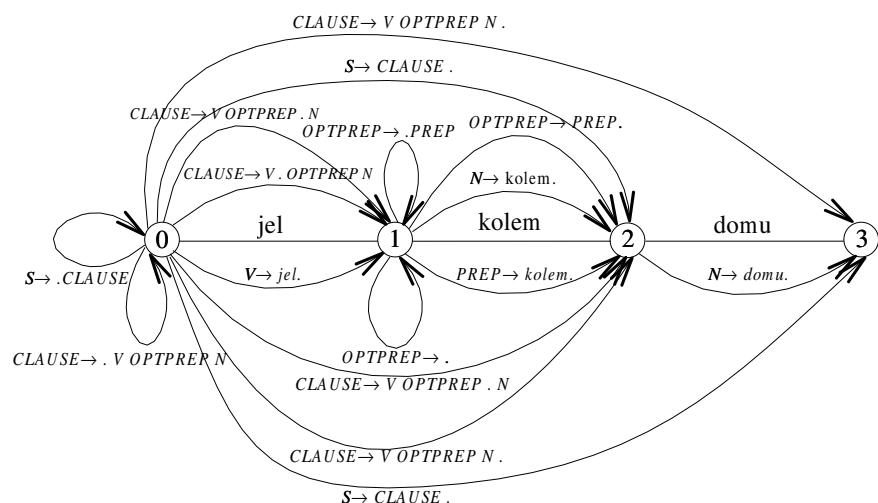
Inicializace:

- ▶ $\forall p \in P \mid p = S \rightarrow \alpha$ 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 $[A \rightarrow \alpha a_{j+1} \beta, i, j+1]$.
 - 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 $[B \rightarrow \gamma, i, i]$.

Příklad – chart po analýze shora dolů



Příklad – tabulkové analýzy (typu chart)

Gramatika:

- | | | |
|----------------|---------------|--------------------|
| <i>S</i> | \rightarrow | <i>CLAUSE</i> |
| <i>CLAUSE</i> | \rightarrow | <i>V OPTPREP M</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" ($a_1=jel$, $a_2=kolem$, $a_3=domu$)

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.
 - ▶ $\forall p \in P \mid p = A \rightarrow a; \alpha$ 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

- 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 $[A \rightarrow \alpha_\bullet a_{j+1}\beta, i, j]$, potom vytvoř hranu $[A \rightarrow \alpha a_{j+1}\bullet\beta, i, j+1]$.
 - d) (*predikce*) pokud je E ve tvaru $[A \rightarrow \alpha_\bullet, i, j]$, potom pro každé pravidlo $B \rightarrow A\gamma$ vstupní gramatiky vytvoř hranu $[B \rightarrow \bullet A_\bullet\gamma, i, i]$.

Analýza řízená hlavou pravidla

- ▶ *head-driven chart parsing*
 - ▶ **Hlava pravidla** – libovolný (určený) symbol z pravé strany pravidla.
- Například pravidlo $CLAUSE \rightarrow V \text{ } PREP \text{ } N$ 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 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: $[B \rightarrow \beta \bullet A \delta, i, l]$ 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 $[B \rightarrow \beta \bullet \gamma A \delta, i, j]$, 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).

Analyzátor řízený hlavou pravidla

Inicializace:

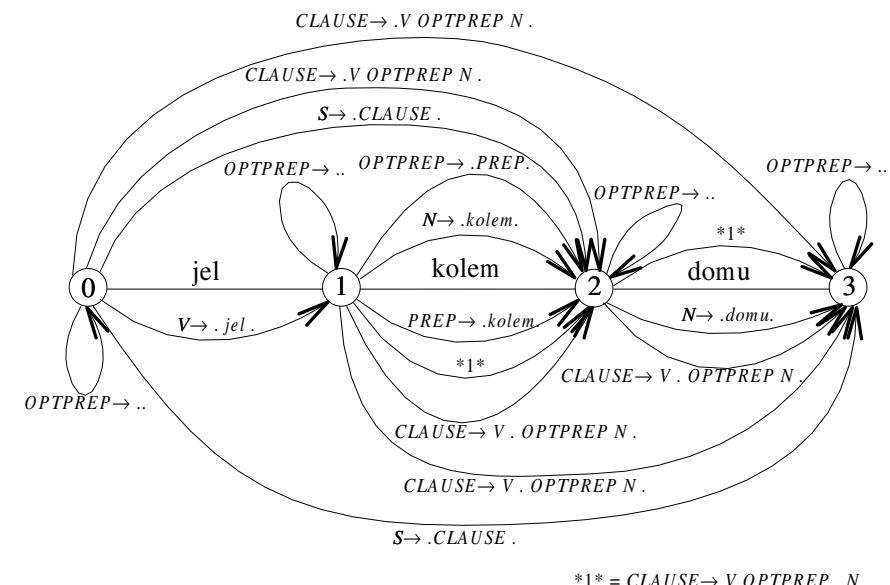
- ▶ $\forall p \in P \mid p = A \rightarrow \epsilon$ přidej hrany $[A \rightarrow \bullet \bullet, 0, 0], [A \rightarrow \bullet \bullet, 1, 1], \dots, [A \rightarrow \bullet \bullet, n, n]$ do agendy.
- ▶ $\forall p \in P \mid p = A \rightarrow \alpha \underline{a}_i \beta$ (a_i je hlavou pravidla)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

Příklad – chart po analýze řízené hlavou pravidla



Porovnání jednotlivých algoritmů

