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
- Algoritmus CKY
- Tabulkové analyzátory
- Tomitův zobecněný analyzátor LR
- 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*
- **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**

Syntaktická analýza

- Vstupy:
  - řetězec lexikálních kategorií (preterminálních symbolů) $a_1\ a_2\ \ldots\ a_n$

    např.: ADJ CONJ ADJ N V PREP N '.'
  - bezkontextová gramatika $G = \langle N, \Sigma, P, S \rangle$.
- Výstup:
  - efektivní reprezentace derivačních stromů.

Algoritmus CKY

- Gramatika musí být v Chomského normální formě.

  CNF (každá CFG jde do ní převést): $A \rightarrow BC$, $D \rightarrow$ 'd'
- 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 $O(n^3)$

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)

a b a a b a

$S \rightarrow AA|BB|AX|BY|a|b$
$X \rightarrow SA$
$Y \rightarrow SB$
$A \rightarrow a$
$B \rightarrow b$

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					

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.
- 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.

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

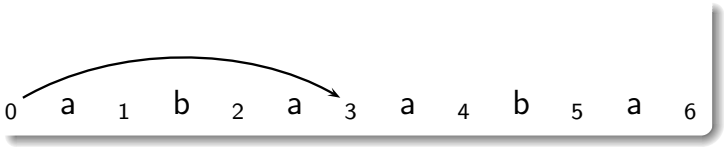

Obecný analyzátor typu "chart"

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;

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:

S	→	*CLAUSE*
CLAUSE	→	*V OPTPREP N*
OPTPREP	→	ϵ
OPTPREP	→	*PREP*
V	→	*jel*
PREP	→	*kolem*
N	→	*domu*
N	→	*kolem*

Věta:

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

Příklad – chart po analýze shora dolů

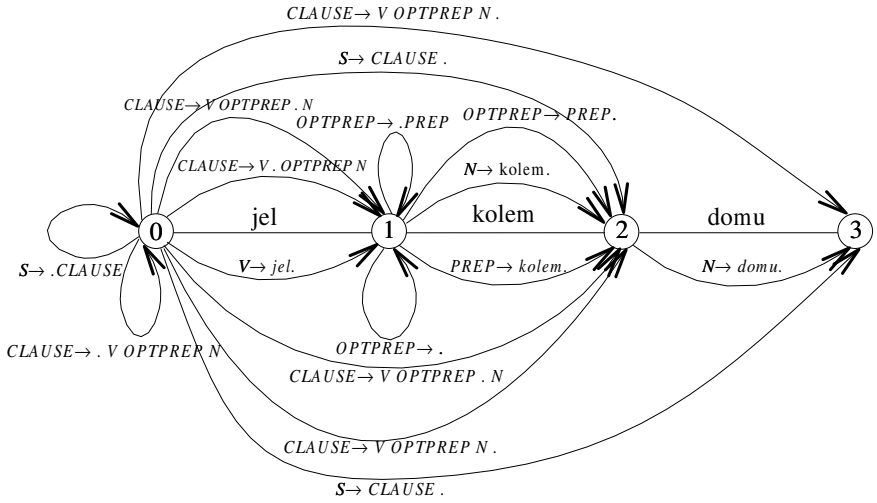

Varianta zdola nahoru

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 $[A \rightarrow \bullet a_i\alpha, i\text{-}1, i\text{-}1]$ 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 $[B \rightarrow \bullet A\gamma, i, i]$.

Analýza řízená hlavou pravidla

- *head-driven chart parsing*
- **Hlava pravidla** – libovolný (určený) symbol z pravé strany pravidla.

  Například pravidlo *CLAUSE* → *V* *OPTPREP* *N* může mít hlavy *V*, *OPTPREP*, *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 $[A \rightarrow \bullet\bullet, 0, 0]$, $[A \rightarrow \bullet\bullet, 1, 1]$, ..., $[A \rightarrow \bullet\bullet, n, n]$ do agendy.
- $\forall\ p \in P \mid p = A \rightarrow \alpha\underline{a_i}\beta$ (a_i je hlavou pravidla) přidej hranu $[A \rightarrow \alpha\bullet a_i\bullet\beta, i\text{-}1, i]$ do agendy.
- počáteční chart je prázdný.

Je tato inicializace v pořádku?

Analyzátor řízený hlavou pravidla pokrač.

Iterace – vezmi hranu E z agendy a pak:

a_1) 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 $[B \rightarrow \beta\bullet\gamma A\bullet\delta, i, k]$.

a_2) $[B \rightarrow \beta A\bullet\gamma\bullet\delta, k, l]$ v chartu vytvoř hranu $[B \rightarrow \beta\bullet A\gamma\bullet\delta, j, l]$.

b_1) 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 $[B \rightarrow \beta\bullet\gamma A\bullet\delta, i, k]$.

b_2) 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 $[B \rightarrow \beta\bullet A\gamma\bullet\delta, j, l]$.

c_1) pokud je E ve tvaru $[A \rightarrow \beta a_i\bullet\gamma\bullet\delta, i, j]$, potom vytvoř hranu $[A \rightarrow \beta\bullet a_i\gamma\bullet\delta, i\text{-}1, j]$.

c_2) 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

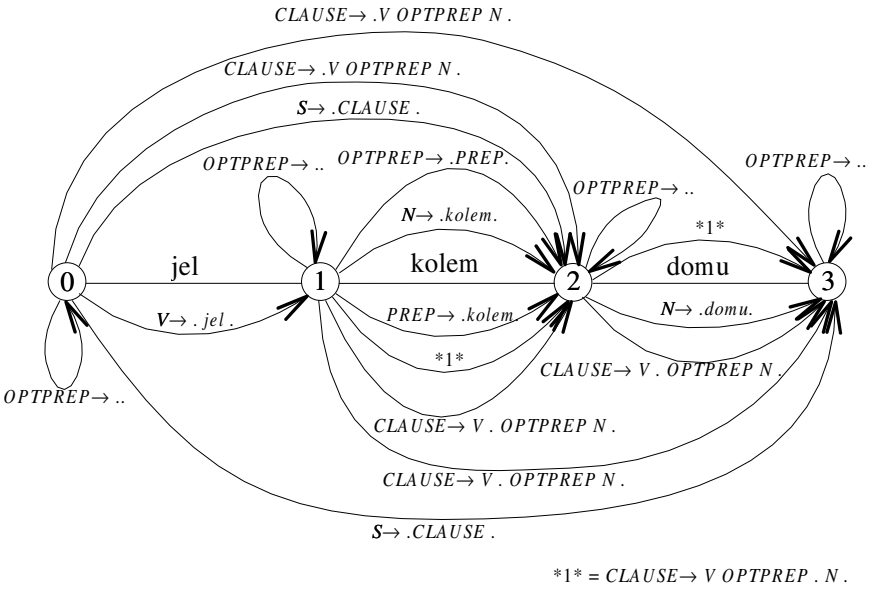

1 = CLAUSE→ V OPTPREP . N .

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

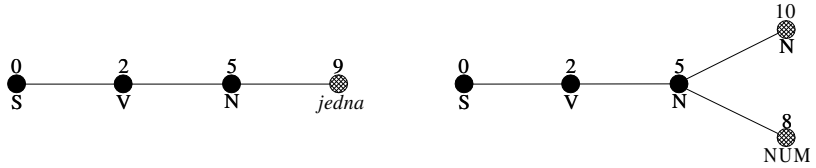

stav	položka	akce	symbol	další stav
5	*CLAUSE→V N•NUM*	shift	*NUM*	8
	NN→ N•N		*N*	10
	NUM→ •jedna		*jedna*	9
	N→ •tramvaj		*tramvaj*	7
	N→ •jedna			
9	*NUM→jedna•*	reduce (6)		
	N→jedna•	reduce (5)		
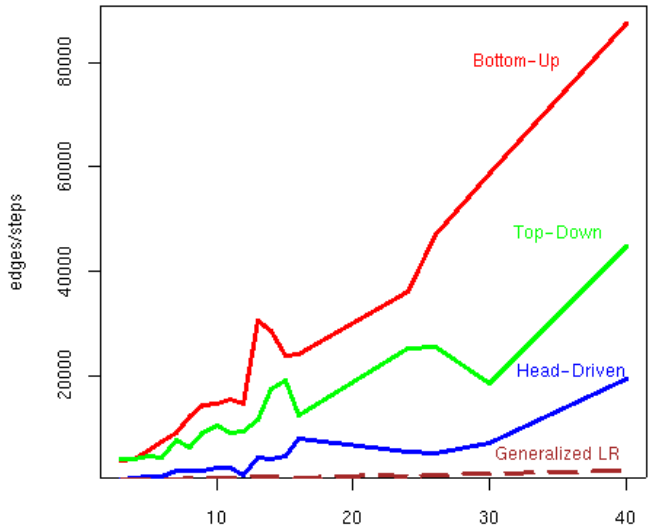
Porovnání jednotlivých algoritmů