KOMPILÁTORY: Syntaktická analýza (Metódy zdola-nahor 2)

Jana Dvořáková
dvorakova@dcs.fmph.uniba.sk

LR parsovanie

- Tri techniky konštrukcie LR parsera
  1. Jednoduchý LR parser (simple LR - SLR)
     - Najjednoduchší na implementáciu, ale najslabší
  2. Kanonický LR parser (LR)
     - Najsilnejší, ale najnáročnejší na implementáciu (veľká parsovacia tabuľka)
  3. LR parser s výhľadom (lookahead LR - LALR)
     - Kompromis medzi SLR a LR

Model LR parsera

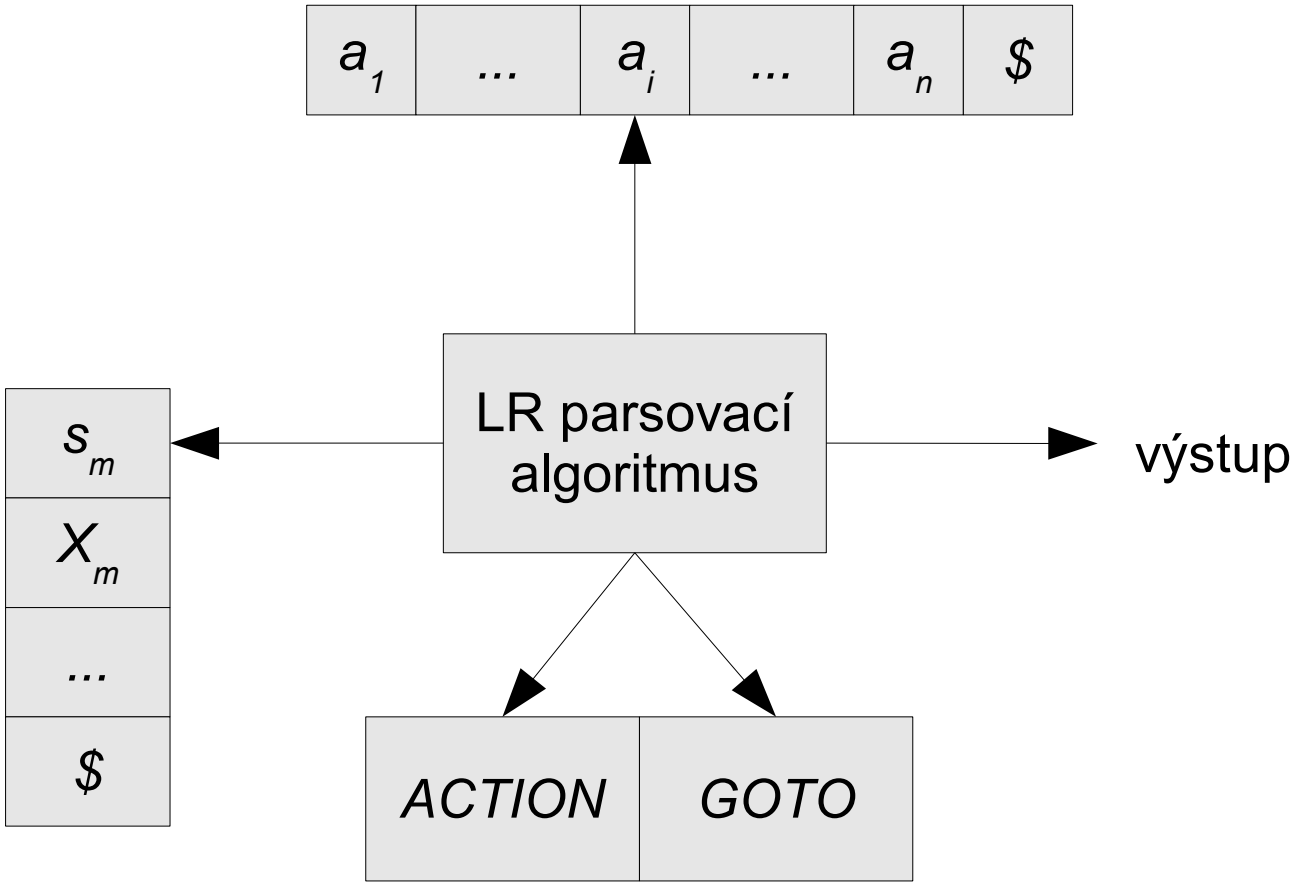

SLR (simple LR) parsovanie

- Najslabšia metóda, ale najľahšie implementovateľná
- Konštruujeme *SLR parsovaciu tabuľku*
- Dá sa použiť pre *SLR gramatiky*
  - Ak sa pri zostrojovaní parsovacej tabuľky objavia konflikty, vstupná gramatika nie je SLR
- Základnou ideou je skonštruovať pre vstupnú gramatiku DKA rozpoznávajúci životaschopné prefixy
- LR a LALR metódy sú oproti SLR rozšírené o výhľad dopredu (lookahead)
  - Myslí sa výhľad v stavoch zostrojovaného DKA, nie výhľad na vstupné symboly !

LR(0) položka

- Pravidlo s bodkou na pravej strane

  $Pr.: \quad A \to XYZ \quad [A \to .XYZ]$
  $[A \to X.YZ]$
  $[A \to XY.Z]$
  $[A \to XYZ.]$

- Reprezentované dvojicou: *(číslo pravidla, číslo pozície bodky)*
- Neformálne: Aká veľká časť z pravej strany pravidla je už známa

- *Úplná* položka
  - Položka s bodkou na konci pravej strany pravidla
- *Platná* položka (pre daný životaschopný prefix)
  - Položka $[A \to \beta_1.\beta_2]$ je platná pre životaschopný prefix $\alpha\beta_1$ ak existuje odvodenie
    $$S' \Rightarrow^*_{rm} \alpha A w \Rightarrow^*_{rm} \alpha\beta_1\beta_2 w$$
  - Vo všeobecnosti je položka platná pre viacero životaschopných prefixov

Konštrukcia konečného automatu

- Najskôr vstupnú gramatiku G rozšíríme o nový počiatočný neterminál S' a pravidlo $S' \rightarrow S$ a označíme G'
- Položky = stavy NKA rozpoznávajúceho životaschopné prefixy
  - Počiatočným stavom je položka $[S' \rightarrow .S]$
  - Koncovými stavmi sú úplné položky

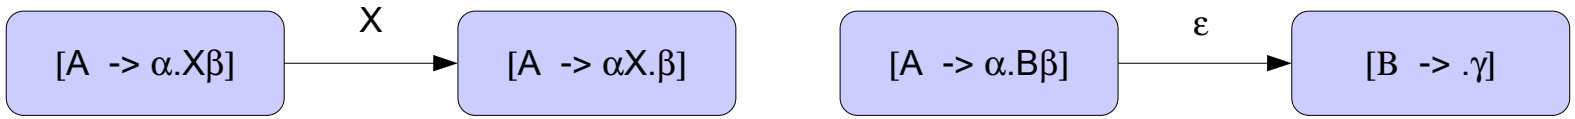

Ale my potrebujeme DKA!

- Množiny položiek = stavy hľadaného DKA
- Konštruujeme *kanonické množiny položiek* pre rozšírenú gramatiku G', pričom definujeme
  1. Pomocnú operáciu *closure*
  2. Operáciu *goto* na konštrukciu prechodovej funkcie DKA
  3. Operáciu *items* na konštrukciu stavov DKA
- Ekvivalent k štandardnej konštrukcii DKA k NKA

Operácia *closure*

function *closure*(I);
begin
    $J := I$;
    repeat
        for každú položku $[A \to \alpha.B\beta]$ v J a každé pravidlo
            $B \to \gamma$ gramatiky G také, že $[B \to .\gamma]$ nie je v J **do**
            pridaj $[B \to .\gamma]$ do J
    until do J nie je možné pridať žiadnu ďalšiu položku;
    return J
end

Operácia *closure*

Implementácia

- Zvyčajne sa implementuje pomocou bool. poľa *added*, indexovaného neterminálmi:
  - $added[B] = true$ ak pridáme položky $[B \rightarrow .\gamma]$ pre každé B-pravidlo $B \rightarrow \gamma$
  - Postačuje pamätať si zoznam takýchto neterminálov
- Rozlišujeme dva druhy položiek
  1. Jadrové položky:
     - Počiatočná položka $[S' \rightarrow .S]$ a všetky položky, ktoré nemajú bodku na začiatku pravej strany.
  2. Mimojadrové položky:
     - Položky, ktoré majú bodku na začiatku pravej strany (okrem poč. položky).
- Uzáver (closure) môže byť reprezentovaný iba jadrovými položkami
  - Nejadrové sa vždy dajú jednoducho odvodiť

Operácia *goto*

$$goto(I, X) = closure(\{[A \to \alpha X.\beta] \mid [A \to \alpha.X\beta] \in I\})$$

- Argumentami sú množina položiek I a symbol gramatiky X
- Vráti uzáver množiny položiek, do ktorých sa vieme dostať z položiek v A prechodom cez X
- Alebo aj:
  - Ak I je množina položiek platných pre nejaký životaschopný prefix γ, potom $goto(I, X)$ je množina položiek platná pre životaschopný prefix γX.
- Reprezentuje prechodovú funkciu konštruovaného DKA

Operácia *items*

procedure *items*(G');
begin
    $C := \{closure(\{[S' \rightarrow .S]\})\}$;
    repeat
        for každú množinu položiek I v C a každý symbol gramatiky X také, že množina $goto(I, X)$ nie je prázdna a nie je v C **do**
            pridaj $goto(I, X)$ do C
    until do C nie je možné pridať žiadnu ďalšiu množinu položiek
end

Platné položky

- Význam tvrdenia "$A \rightarrow \beta_1.\beta_2$ je platná pre životaschopný prefix $\alpha\beta_1$":
  - Rozhodovanie medzi akciami shift/reduce
    - $\beta_2 \neq \varepsilon$: shift
    - $\beta_2 = \varepsilon$: reduce podľa $A \rightarrow \beta_1$
- Kde môžu vzniknúť konflikty:
  - Shift/reduce: máme dve rôzne platné položky a každá určí inú akciu
  - Reduce/reduce: máme viac úplných platných položiek
  - Niektoré môžu byť vyriešené rozšírením o výhľad v stavoch DKA (LR, LALR)
- Množina platných položiek pre životaschopný prefix γ je rovná množine položiek - stavu, ktorý DKA dosiahne prechodom z počiatočného stavu na jednotlivé symboly γ.

Konštrukcia SLR parsovacej tabuľky

Vstup: Rozšírená gramatika G'.
Výstup: SLR parsovacia tabuľka pre G' reprezentovaná funkciami *action* a *goto*.

1. Skonštruuj kanonické množiny LR(0) položiek pre G': $C = \{I_0, I_1, \ldots, I_n\}$.
2. Nech stav i zodpovedá množine položiek I_i. Akcia pre stav i sa určí nasledovne:
   a) Ak $[A \to \alpha.a\beta] \in I_i$ a $goto(I_i, a) = I_j$, potom $action[i, a] =$ shift j. Symbol a musí byť terminál.
   b) Ak $[A \to \alpha.] \in I_i$, potom $action[i, a] =$ reduce $A \to \alpha$ pre všetky $a \in FOLLOW(A)$, $A \neq S'$.
   c) Ak $[S' \to S.] \in I_i$, potom $action[i, \$] =$ accept.

   Ak uvedené pravidlá spôsobia nejaké konflikty, gramatika nie je SLR(1) a parser nie je možné zostrojiť.
3. Goto prechody pre stav i sú zostrojené pre všetky neterminály A nasledovne: Ak $goto(I_i, A) = I_j$, potom $goto[i, A] = j$.
4. Všetky záznamy nedefinované v krokoch 2 a 3 predstavujú chybu - akcia error.
5. Počiatočný stav parsera je množina položiek obsahujúca $[S' \to .S]$.

Gramatiky mimo triedy SLR

- Mimo triedy SLR sú všetky nejednoznačné ale aj niektoré jednoznačné gramatiky

Príklad jednoznačnej, ale nie SLR gramatiky a jej kanonické množiny položiek:

$S \to L = R$
$S \to R$
$L \to *R$
$L \to id$
$R \to L$

I_0 : $S' \to .S$
+ mimojadrové položky pre S, L, R

I_1 : $S' \to S.$

I_2 : $S \to L. = R$
$R \to L.$

I_3 : $S \to R.$

I_4 : $L \to *.R$
+ mimojadrové položky pre R, L

I_5 : $L \to id.$

I_6 : $S \to L = .R$
+ mimojadrové p. pre R, L

I_7 : $L \to *R.$

I_8 : $R \to L.$

I_9 : $S \to L = R.$

- Pri I_2 vznikne shift/reduce konflikt
  1. $action[2, =] =$ shift 6, podľa prvej položky
  2. $action[2, =] =$ reduce $R \to L$, podľa druhej položky, '='$\in FOLLOW(R)$
- Pri LR a LALR parsovaní konflikt nevznikne

LR parsovanie

- Najuniverzálnejšia metóda
- Problém pri SLR parsovaní:
  - Na vrchu zásobníka máme životaschopný prefix $\beta\alpha$
  - Sme v stave i, pričom $[A \rightarrow \alpha.] \in I_i$
  - Čítaný vstupný symbol $a \in FOLLOW(A)$

    Ale čo ak βA nie je v skutočnosti v žiadnej pravej vetnej forme nasledované a!
- Pri LR parsovaní je v stave je uložená ďaľšia informácia - *výhľad položky*
  - Terminál, ktorý môže nasledovať za pravou stranou pravidla
- Dostávame LR(1) položky
- Každá SLR gramatika je aj LR gramatikou, ale pre danú gramatiku LR parser môže mať viac stavov ako SLR parser

LR(1) položka

- Dvojica *(LR(0) položka, terminál)*
  - $[A \rightarrow \alpha.\beta, a]$, kde $A \rightarrow \alpha\beta$ je pravidlo a a je terminál
  - LR(1) - položka má výhľad 1
- Výhľad položky sa využíva pri úplných LR(1) položkách (pri redukcii)
  - Pri položke $[A \rightarrow \alpha., a]$ sa redukuje podľa pravidla $A \rightarrow \alpha$ iba v prípade, ak práve čítaný vstupný symbol je a
- *Platná* LR(1) položka
  - LR(1) položka $[A \rightarrow \alpha.\beta, a]$ je platná pre životaschopný prefix γ ak existuje odvodenie $S \Rightarrow^*_{rm} \delta Aw \Rightarrow^*_{rm} \delta\alpha\beta w$, kde
    1. $\gamma = \delta\alpha$ a
    2. buď a je prvý symbol w, alebo $w = \varepsilon$ a $a =$ \$.

Operácie *closure*, *goto*

function *closure*(I);
begin
  repeat
    for každú položku $[A \to \alpha.B\beta, a] \in I$, každé pravidlo $B \to \gamma$ gramatiky G' a každý terminál $b \in FIRST(\beta a)$ také, že $[B \to .\gamma, b]$ nie je v I **do**
      pridaj $[B \to .\gamma, b]$ do I
  until do I nie je možné pridať žiadnu ďalšiu položku;
  return I
end

function *goto*(I, X);
begin
  nech J je množina položiek $[A \to \alpha X.\beta, a]$ taká, že $[A \to \alpha.X\beta, a] \in I$
  return *closure*(J)
end

Operácia *items*

procedure *items*(G');
begin
    $C := \{closure(\{[S' \rightarrow .S, \$]\})\}$;
    repeat
        for každú množinu položiek I v C a každý symbol
            gramatiky X také, že množina $goto(I, X)$ nie je prázdna
            a nie je v C **do**
             pridaj $goto(I, X)$ do C
    until do C nie je možné pridať žiadnu ďalšiu množinu položiek
end

Konštrukcia LR parsovacej tabuľky

Vstup: Rozšírená gramatika G'.
Výstup: Kanonická LR parsovacia tabuľka pre G' reprezentovaná funkciami *action* a *goto*.

1. Skonštruuj kanonické množiny LR(1) položiek pre G': $C = \{I_0, I_1, \ldots, I_n\}$.
2. Nech stav i zodpovedá množine položiek I_i. Akcia pre stav i sa určí nasledovne:
   a) Ak $[A \to \alpha.a\beta, b] \in I_i$ a $goto(I_i, a) = I_j$, potom $action[i, a] =$ shift j. Symbol a musí byť terminál.
   b) Ak $[A \to \alpha., a] \in I_i$, potom $action[i, a] =$ reduce $A \to \alpha$, $A \neq S'$.
   c) Ak $[S' \to S., \$] \in I_i$, potom $action[i, \$] =$ accept.

   Ak uvedené pravidlá spôsobia nejaké konflikty, gramatika nie je LR(1) a parser nie je možné zostrojiť.
3. Goto prechody pre stav i sú zostrojené pre všetky neterminály A nasledovne: Ak $goto(I_i, A) = I_j$, potom $goto[i, A] = j$.
4. Všetky záznamy nedefinované v krokoch 2 a 3 predstavujú chybu - akcia error.
5. Počiatočný stav parsera je množina položiek obsahujúca $[S' \to .S, \$]$.

LALR (lookahead LR) parsovanie

- Metóda často používná v praxi - vhodný kompromis medzi SLR a LR
  - Parsovacia tabuľka je výrazne menšia ako pri LR parsovaní

    Počet stavov LALR parsera = počet stavov SLR parsera
  - Je možné rozpoznať všetky bežné koštrukcie programovacích jazykov
- Vychádza sa z množín kanonických položiek (stavov DKA) zostrojených LR metódou a tie sa podľa určitých pravidiel zlučujú dokopy

Zlučovanie množín položiek

- Zlúčia sa stavy, ktoré majú rovnaký prvý komponent

  Pr. $\{[A \to \alpha.\beta, a]\}, \{[A \to \alpha.\beta, b]\} \Rightarrow \{[A \to \alpha.\beta, a/b]\}$

- Funkcia *goto* sa upraví jednoducho
  - $goto(I, X)$ závisí iba na prvých komponentoch I, preto ak I vznikla zlúčením stavov, $goto(I, X)$ vznikne zlúčením pôvodných *goto* funkcií
- Prečo je LALR parser slabší:
  - Pri zlučovaní stavov môžu vzniknúť nové reduce/reduce konflikty (ale nikdy nie nové shift/reduce konflikty!)
- Porovnanie práce parserov:
  1. Korektný vstup
     - LR aj LALR parser správajú rovnako, vykonajú rovnakú postupnosť shift a reduce akcií
  2. Nekorektný vstup
     - Keď LR parser vyhlási chybu, LALR parser môže vykonať ešte niekoľko redukcií, kým tiež vyhlási chybu (ale nikdy nie shift!)

Konštrukcia LALR parsovacej tabuľky

Vstup: Rozšírená gramatika G'.
Výstup: LALR parsovacia tabuľka pre G' reprezentovaná funkciami *action* a *goto*.

1. Skonštruuj kanonické množiny LR(1) položiek pre G': $C = \{I_0, I_1, \ldots, I_n\}$.
2. Nájdi stavy so spoločným prvým komponentom a tieto stavy nahraď ich zjednotením.
3. Nech $C' = \{J_0, J_1, \ldots, J_m\}$ je výsledná množina $LR(1)$ položiek. Funkcia *action* sa zostrojuje rovnako ako pri LR parseri. Ak vzniknú nejaké konflikty, gramatika nie je LALR(1) a parser nie je možné zostrojiť.
4. Goto prechody sú zostrojené nasledovne: Ak J je zjednotenie niekoľkých LR(1) položiek, $J = I_1 \cup I_2 \cup \ldots \cup I_k$, potom prvé komponenty $goto(I_1, X)$, $goto(I_2, X)$, $\ldots$,$goto(I_k, X)$ sú rovnaké keďže $I_1, I_2, \ldots, I_k$ majú rovnaký prvý komponent. Nech K je zjednotenie všetkých množín s rovnakým prvým komponentom ako má $goto(I_1, X)$. Potom $goto(J, X) = K$.

- Jednoduchý, ale priestorovo neefektívny algoritmus
- Existuje aj efektívna metóda bez priameho zostrojovania všetkých LR(1) položiek

Optimalizácia LR parsovacej tabuľky

- Dvojrozmerné pole je priestorovo neefektívne
- Tabuľka pre *action*: veľa riadkov je rovnakých
  1. Smerníky na jednorozmerné pole
     - Rovnaké riadky sa reprezentujú ako jednorozmerné polia a v tabuľke *action* sú na ne smerníky
     - Terminály sú očíslované $0, \ldots, |T| - 1$ a akcia pre daný terminál sa hľadá podľa jeho čísla (= offset v poli)
  2. Zoznam akcií pre každý stav resp. množinu stavov

     Pr.: stavy 0,4,6,7

symbol	*action*
id	s5
(	s4
any	*error*

- Tabuľka pre *goto*: veľa záznamov je prázdnych (nie sú potrebné, nikdy sa podľa nich nedetekuje chyba)
  - Zoznam posunov pre každý neterminál

    A: (súčasný stav, nasledujúci stav)

Čo s nejednoznačnými gramatikami

- Nejednoznačné gramatiky nie sú LR
- Niekedy je vhodnejšie ich použiť spolu s explicitnými pravidlami pre riešenie konfliktov, napr.:
  - Výrazy
    - Explicitne určíme prioritu a asociativitu operátorov
  - if..then..else
    - Explicitne uprednostníme shift, ak máme v zásobníku ”if *expr* then *stmt*” a na vstupe ”else”
- Získame efektívnejší parser a prehľadnejšiu gramatiku
- Niektoré záznamy parsovacej tabuľky je nutné doplniť ”ručne”

Spracovanie chýb pri LR parsovaní (1)

- Chyba je detekovaná pri prázdnych záznamoch v *action* tabuľke (nikdy nie v *goto*!)
- Chyby sú ohlásené hneď, ako je to možné (na rozdiel od oper. precedenčného parsera)
  - LR parser nevykoná už žiadnu akciu pred ohlásením chyby
  - SLR a LALR parsery môžu vykonať ešte niekoľko redukcií

1. Zotavenie v móde paniky
   - Vyberáme symboly zo zásobníka, kým nenarazíme na stav s, ktorý má *goto* prechod na určitý neterminál A
   - Posúvame sa na vstupe, kým nenájdeme taký terminál a, ktorý môže nasledovať za A
   - Pridáme na vrch zásobníka A a stav $goto[s, A]$
   - Obnovíme parsovanie
   - Neterminály A = synchronizujúce symboly, zväčša hlavné časti programu výraz, príkaz, blok

Spracovanie chýb pri LR parsovaní (2)

2. Zotavenie na úrovni frázy
   - Ku každému prázdnemu záznamu v parsovacej tabuľke sa pridá funkcia na ošetrenie konkrétnej chyby
   - Modifikácia symbolov na vrchu zásobníka a/alebo vstupných symbolov
   - Na rozdiel od OP parsovania sa nemusíme zaoberať chybnými pokusmi o redukciu
   - Treba sa vyhnúť zacykleniu

Generátory parserov

Bison

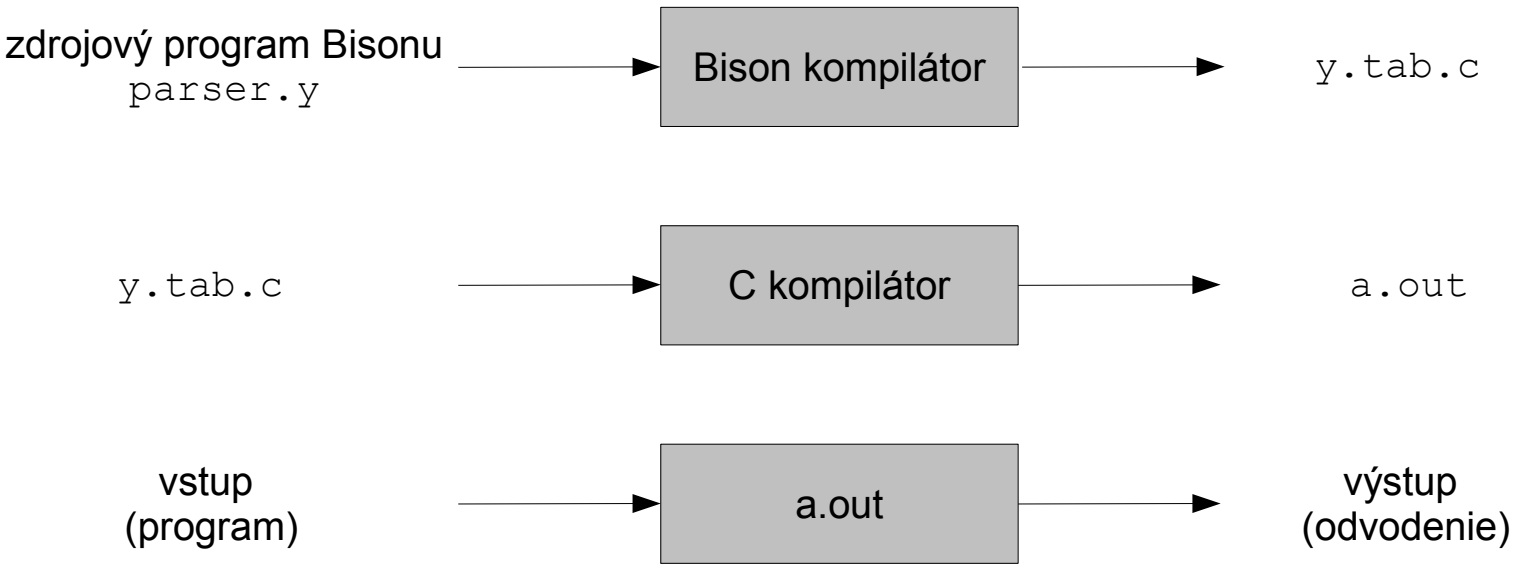

Syntaktická analýza

Zhrnutie

1. Univerzálne metódy
   - CYK, Earley
2. Metódy zhora-nadol
   - Všeobecná metóda: rekurzívny zostup
   - Deterministické algoritmy
     - Prediktívne parsovanie - LL(k) gramatiky
3. Metódy zdola-nahor
   - Všeobecná metóda: shift-reduce parsovanie
   - Deterministické algoritmy
     - Operátorovo precedenčné parsovanie - OP gramatiky
     - SLR parsovanie - SLR(k) gramatiky
     - LR parsovanie - LR(k) gramatiky
     - LALR parsovanie LALR(k) gramatiky

- V kompilátoroch sa využívajú najmä gramatiky s k=1

Vzťahy medzi triedami gramatík