KOMPILÁTORY: Syntaktická analýza (Metódy zdola-nahor 1)

Jana Dvořáková
dvorakova@dcs.fmph.uniba.sk

Úlohy syntaktickej analýzy

1. Číta postupnosť tokenov generovanú lexikálnym analyzátorom a konštruuje strom odvodenia/syntaktický strom
   - Overuje, či vstupný reťazec môže byť generovaný CF gramatikou pre vstupný jazyk
2. Hlási syntaktické chyby ”inteligentným” spôsobom
   - Vie sa zotaviť z bežných chýb tak, aby sa mohlo pokračovať v spracovávaní vstupu

- Pracuje na úrovni *bezkontextových jazykov*

Metódy syntaktickej analýzy

1. Univerzálne metódy
   - Cocke-Younger-Kasami, Earley
   - Všetky CF gramatiky, ale neefektívne ($O(n^3)$)
2. Metódy zhora-nadol ✓
   - Konštruujú strom odvodenia od koreňa k listom v preorderi (ľavé krajné odvodenie)
   - Rekurzívny zostup (prediktívne parsovanie)
   - LL gramatiky
   - Aj ručne implementované parsery
3. Metódy zdola-nahor *
   - Konštruujú strom odvodenia od listov ku koreňu (pravé krajné odvodenie)
   - Operátorovo-precedenčné parsovanie
   - LR gramatiky
   - Zvyčajne parsery skonštruované automatickými nástrojmi

Parsovanie zdola-nahor

- Pre vstupný reťazec sa konštruuje strom odvodenia od listov ku koreňu
- Hovoríme o *redukcii* vstupného reťazca na počiatočný symbol gramatiky
  - V každom redukčnom kroku je podreťazec zodpovedajúci pravej strane nejakého pravidla nahradený neterminálom z ľavej strany
- Cieľom je získať pravé krajné odvodenie
- Používa sa metóda posun-redukcia (shift-reduce)

Niektoré pojmy

- Rukoväť (handle)
  - Podreťazec, ktorý zodpovedá pravej strane nejakého pravidla a ktorého redukcia predstavuje jeden krok pravého krajného odvodenia
  - Formálne:
    - Handle vetnej formy γ je pravidlo $A \to \beta$ a pozícia v γ, kde sa β môže nachádzať a ak ju nahradíme neterminálom A získame predchádzajúcu pravú vetnú formu
  - Postupná redukcia:
    $w = \gamma_n \Leftarrow_{rm} \gamma_{n-1} \Leftarrow_{rm} \ldots \Leftarrow_{rm} \gamma_1 \Leftarrow_{rm} \gamma_0 = S$
    1. Lokalizácia handle β_n v γ_n
    2. Nahradenie β_n ľavou stranou pravidla $A \to \beta_n$
    3. Opakujeme pre $n-1, n-2, \ldots$ až kým nedostaneme S
- Životaschopný prefix
  - Prefix pravej vetnej formy, ktorý nepresahuje pravý koniec (najpravejšej) handle vetnej formy

Metóda posun-redukcia (shift-reduce)

- Všeobecná metóda parsovania zdola-nahor
- Pri implementácií sa využíva zásobník a vstupný buffer
- Akcie parsera:
  1. *shift* (posun): vstupné symboly sa ukladajú do zásobníka
  2. *reduce* (redukcia): keď sa na vrchu zásobníka objaví nejaká handle, redukuje sa podľa príslušného pravidla gramatiky
  3. *accept*: úspešné ukončenie parsovania
  4. *error*: volanie funkcie na ošetrenie chyby
- Handle sa vždy objaví na vrchu zásobníka, nikdy nie vo vnútri!
- Získame pravé krajné odvodenie zapísané odzadu

Metóda posun-redukcia (shift-reduce)

Konflikty

- Nedeterministické rozhodnutia:
  1. Lokalizácia handle $\rightarrow$ *shift/reduce* konflikt

$$
\begin{array}{llll}
Pr. & stmt & \rightarrow & \textbf{if}\ expr\ \textbf{then}\ stmt \\
 & & | & \textbf{if}\ expr\ \textbf{then}\ stmt\ \textbf{else}\ stmt \\
 & & | & \textbf{other}
\end{array}
$$

  2. Výber pravidla pre redukciu $\rightarrow$ *reduce/reduce* konflikt

$$
\begin{array}{lrll}
Pr. & stmt & \rightarrow & \textbf{id}\ (\ parameter\_list\ ) \qquad /*\ procedure\ call\ */ \\
 & stmt & \rightarrow & expr\ :=\ expr \\
 & parameter\_list & \rightarrow & parameter\_list\ ,\ parameter \\
 & parameter\_list & \rightarrow & parameter \\
 & parameter & \rightarrow & \textbf{id} \\
 & expr & \rightarrow & \textbf{id}\ (\ expr\_list\ ) \qquad /*\ array\ reference\ */ \\
 & expr & \rightarrow & \textbf{id} \\
 & expr\_list & \rightarrow & expr\_list\ ,\ expr \\
 & expr\_list & \rightarrow & expr
\end{array}
$$

Metóda posun-redukcia (shift-reduce)

Deterministické riešenia

- Deterministický shift-reduce parser sa musí vedieť jednoznačne rozhodnúť pre akciu na základe
  1. obsahu zásobníka
  2. k symbolov zo vstupu
- $LR(k)$ gramatiky
  - Umožnujú deterministické spracovanie, nespôsobujú konflikty
  - V kompilátoroch sa zvyčajne využívajú $LR(1)$ gramatiky s výhľadom jeden symbol

1. Operátorovo-precedenčné parsovanie
2. LR parsovanie

Operátorovo-precedenčné parsovanie

- LR gramatiky
  - Najväčšia trieda gramatík, pre ktorú vieme implementovať deterministický shift-reduce parser
- Operátorovo-precedenčné gramatiky
  - Podmnožina LR gramatík, umožňuje *jednoduchú* implementáciu shift-reduce parsera
  - Okrem iného:
    - Pravá strana pravidla nemôže byť ε
    - Neterminály na pravej strane pravidla sa nesmú vyskytovať priamo vedľa seba
  - Vhodné pre parsovanie aritmetických výrazov

Precedenčné relácie

- Definujeme tri disjunktné precedenčné relácie:

  $a \gtrdot b$ a "má väčšiu precedenciu ako" b
  $a \doteq b$ a "má rovnakú precedenciu ako" b
  $a \lessdot b$ a "má menšiu precedenciu ako" b

- Relácia medzi dvojicou terminálov sa určuje:
  1. Intuitívne
  2. Zostrojením jednoznačnej gramatiky a použitím mechanickej metódy na odvodenie precedenčných relácií

- Precedenčné relácie slúžia na ohraničenie handle
  - $\lessdot$ začiatok handle
  - $\doteq$ stred handle
  - $\gtrdot$ koniec handle

Použitie precedenčných relácií

- Pravá vetná forma oper.-prec. gramatiky je tvaru:

  $\beta_0 a_1 \beta_1 \ldots a_n \beta_n$, kde β_i je ε alebo neterminál a a_i je terminál

- Vo vetnej forme ignorujeme neterminály a medzi každé dva terminály vložíme príslušnú precedenčnú reláciu
  - Reťazec je ohraničený symbolom \$ a pre všetky terminály b platí \$ $\lessdot$ b a $b \gtrdot$ \$
- Lokalizácia handle:
  1. Prechádzaj vstupným reťazcom, kým nenájdeš prvé $\gtrdot$.
  2. Vráť sa naspäť (doľava) cez všetky $\doteq$, kým nanájdeš $\lessdot$.
  3. Handle obsahuje všetko medzi nájdeným $\lessdot$ a $\gtrdot$, vrátane vnútorných a okolitých neterminálov
- Neterminály neovplyvňujú parsovanie, nie je potrebné medzi nimi rozlišovať
- Implementácia pomocou zásobníka

Použitie precedenčných relácií

Príklad

- Gramatika $G = (N, T, P, S)$, $N = \{E\}$, $T = \{id, +, *\}$,
$$E \rightarrow E + E \mid E * E \mid id$$

- Precedenčná tabuľka:

	id	$+$	$*$	\$
id		$\gtrdot$	$\gtrdot$	$\gtrdot$
$+$	$\lessdot$	$\gtrdot$	$\lessdot$	$\gtrdot$
$*$	$\lessdot$	$\gtrdot$	$\gtrdot$	$\gtrdot$
\$	$\lessdot$	$\lessdot$	$\lessdot$	

- Spracovanie reťazca $id + id * id$:

$\$ \lessdot id \gtrdot + \lessdot id \gtrdot * \lessdot id \gtrdot \$$
$\$ \lessdot + \lessdot id \gtrdot * \lessdot id \gtrdot \$$
$\$ \lessdot + \lessdot * \lessdot id \gtrdot \$$
$\$ \lessdot + \lessdot * \gtrdot \$$
$\$ \lessdot + \gtrdot \$$
$\$ \$$

Parsovací algoritmus

nastav *ip* na prvý symbol *w*\$;
repeat forever
  if \$ je na vrchu zásobníka a *ip* ukazuje na \$ **then**
    return
  else begin
    nech *a* je symbol navrchu zásobníka
      a *b* je symbol, na ktorý ukazuje *ip*;
    if $a \lessdot b$ alebo $a \doteq b$ **then begin**
      vlož *b* do zásobníka;
      posuň *ip* na ďalší vstupný symbol
    end
    else if $a \gtrdot b$ **then**
      repeat
        vyber symbol zo zásobníka;
      until terminál navrchu zásobníka je vo vzťahu $\lessdot$
        k naposledy vybranému terminálu
    else *error*()
  end

Určenie precedenčných relácií

- Binárne operátory:
  - Ak operátor θ_1 má väčšiu precedenciu ako operátor θ_2 potom $\theta_1 \gtrdot \theta_2$ a $\theta_2 \lessdot \theta_1$.
  - Ak majú operátory θ_1, θ_2 rovnakú precedenciu (môže to byť aj ten istý operátor) potom
    - Ak sú ľavoasociatívne tak $\theta_1 \gtrdot \theta_2$ a $\theta_2 \gtrdot \theta_1$
    - Ak sú pravoasociatívne tak $\theta_1 \lessdot \theta_2$ a $\theta_2 \lessdot \theta_1$
  - Pre všetky operátory θ:
    - $\theta \lessdot id$, $id \gtrdot \theta$
    - $\theta \lessdot ($, $($\lessdot$\theta$
    - θ\gtrdot$)$, $) \gtrdot \theta$
    - $\theta \gtrdot \$$, $\$ \lessdot \theta$
- Unárne operátory (ν je unárny prefixový operátor):
  - $\theta \lessdot \nu$ pre ľubovoľný operátor θ (unárny aj binárny)
  - $\nu \gtrdot \theta$ ak ν má väčšiu precedenciu ako θ,
    $\nu \lessdot \theta$ ak ν má menšiu precedenciu ako θ
- Problémom sú operátory, ktoré majú viac precedencií (mínus)

Kompresia precedenčnej tabuľky

- Precedenčná tabuľka sa v praxi kóduje dvomi precedenčnými funkciami f a g, ktoré zobrazujú terminály na celé čísla
- Pokúšame sa ich definovať tak, aby platilo:
  1. $f(a) < g(b)$ ak $a \lessdot b$
  2. $f(a) = g(b)$ ak $a \doteq b$
  3. $f(a) > g(b)$ ak $a \gtrdot b$
- Relácia medzi a a b môže byť určená numerickým porovnaním $f(a)$ a $g(b)$
- Stratia sa chybové záznamy
  - Zväčša sa to nepokladá za veľkú nevýhodu, lebo chyby múžu byť ešte detekované pri volaní redukcie (nájde sa handle, ale nezodpovedá mu pravá strana žiadneho pravidla)

Konštrukcia precedenčných funkcií

Vstup: Precedenčná tabuľka
Výstup: Precedenčné funkcie pre danú precedenčnú tabuľku, alebo odpoveď, že neexistujú

1. Vytvor symboly f_a a g_a pre každý terminál a a \$.
2. Rozdeľ vytvorené symboly do čo najviac skupín takým spôsobom, že ak platí $a \doteq b$ potom f_a a g_b sú v tej istej skupine.
3. Vytvor orientovaný graf, ktorého uzlami sú skupiny vytvorené v bode 2. Pre každé a a b
   - Ak $a \lessdot b$ pridaj hranu $g_b \rightarrow f_a$
   - Ak $a \gtrdot b$ pridaj hranu $f_a \rightarrow g_b$
4. Ak výsledný graf obsahuje cyklus, precedenčné funkcie neexistujú. Ak neobsahuje cyklus, nech
   - $f(a)$ je dĺžka najdlhšej cesty začínajúcej v skupine obsahujúcej f_a
   - $g(a)$ je dĺžka najdlhšej cesty začínajúcej v skupine obsahujúcej g_a

Ošetrenie chýb

- Dva druhy chýb:
  1. Nájde sa neredukovateľná handle (neexistuje pre ňu v gramatike pravidlo)
     - "Zlá"handle sa vyberie zo zásobníka
     - Namiesto redukcie sa vypíše diagnostická správa - určí sa porovnávaním handle s pravými stranami pravidiel
  2. Prázdne miesto v parsovacej tabuľke
     - Vykoná sa lokálna korekcia na vrchu zásobníka alebo vo vstupnom bufferi (vloženie znaku, zmena znaku, zmazanie znaku)
     - Zotavenie nesmie spôsobiť zacyklenie

Operátorovo precedenčné parsovanie

Zhrnutie

- Výhody
  - Jednoduchá implementácia efektívneho parsera
- Nevýhody
  - Ťažko sa narába s tokenmi, ktoré majú viac precedencií (napr. mínus - môže byť unárne aj binárne)
  - Slabá previazanosť parsera s gramatikou - niekedy si nie sme istí, že parser akceptuje práve zdrojový jazyk
  - Metódu je možné použiť iba pre malú množinu gramatík
- Často sa používa pre parsovanie výrazov a konštrukcie na vyššej úrovni sa rozpoznávajú rekurzívnym zostupom

LR parsovanie

- Efektívna technika parsovania zdola nahor
- Môže byť použitá pre veľkú podmnožinu bezkontextových gramatík - LR(k) gramatiky
  - L - vstupný reťazec sa číta zľava doprava
  - R - vytvára sa pravé krajné odvodenie
  - (k) - výhľad dopredu
- 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
  3. LR parser s výhľadom (lookahead LR - LALR)
     - Kompromis medzi SLR a LR

LR parsovanie

Výhody a nevýhody

(+) Výhody:

- Umožňuje rozpoznávať takmer všetky programovacie jazyky
- Je to najsilnejšia metóda bez backtrackingu pre shift-reduce parsovanie
- LR gramatiky sú vlastnou nadmnožinou LL gramatík
- Chyby sa detekujú najskôr, ako je to možné

(−) Nevýhody:

- Náročná implementácia

- Zvyčajne sa využívajú automatické generátory LR parserov (Bison)

Model LR parsera

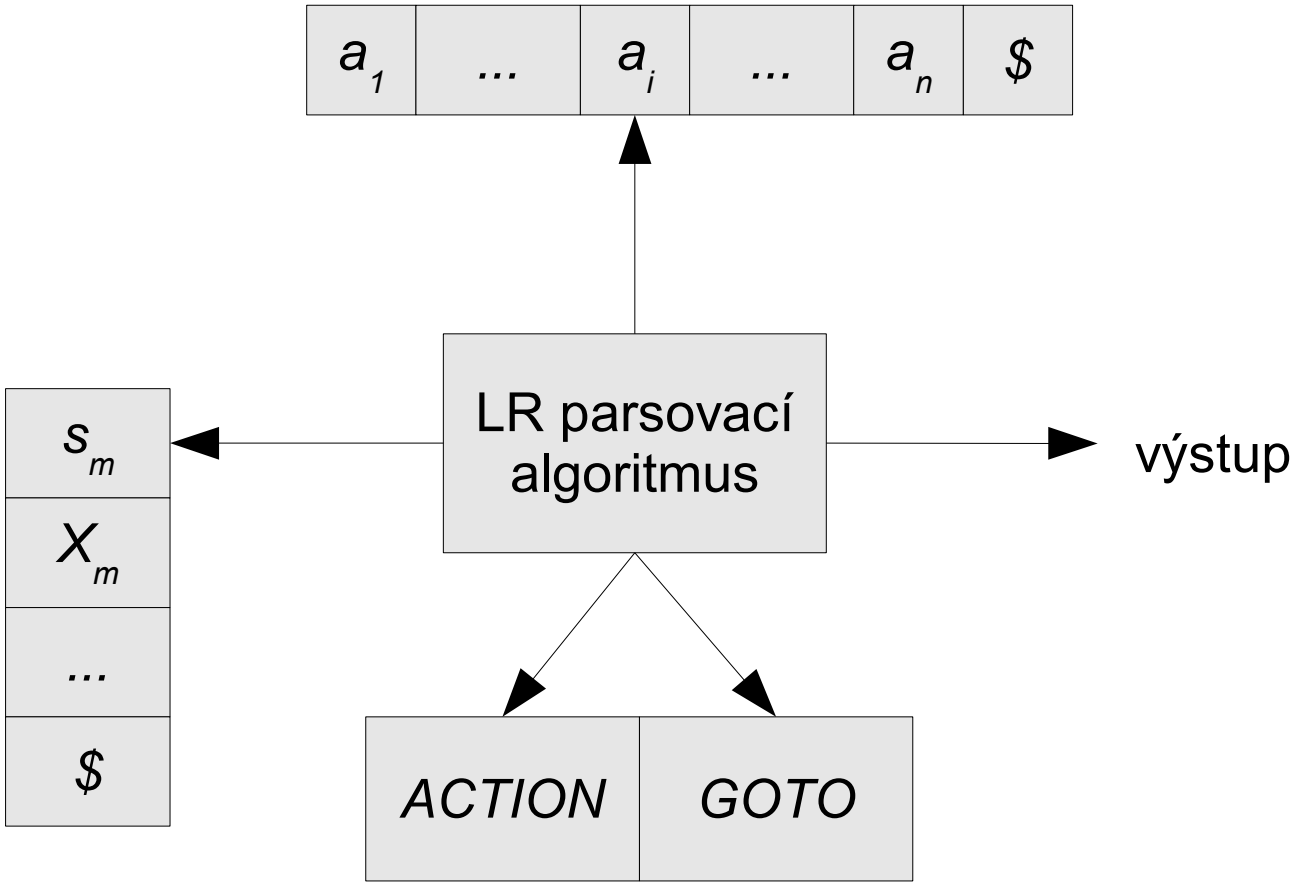

Parsovacia tabuľka

- Funkcia *action*$[s_m, a_i]$:
  - Riadi parsovanie
  - Argumentami sú aktuálny stav a práve čítaný symbol vstupu
  - Vráti akciu
    1. shift s
    2. reduce $A \rightarrow \beta$
    3. accept
    4. error
- Funkcia *goto*$[s, a]$:
  - Pomocná funkcia, volá sa vždy po redukcii
  - Argumentami sú stav a symbol gramatiky, vráti nový stav
- Shift akcie a goto tabuľka tvoria prechodovú funkcia DKA rozpoznávajúceho životaschopné prefixy

Konfigurácie LR parsera

- Dvojica *(obsah zásobníka, neprečítaný vstup)*

  $(s_0 X_1 s_1 X_2 s_2 \ldots X_m s_m, a_i a_{i+1} \ldots a_n\$)$

  - Reprezentuje pravú vetnú formu: $(X_1 X_2 \ldots X_m a_i a_{i+1} \ldots a_n)$
- Parser vykoná akciu podľa $action[s_m, a_i]$, konfigurácie sa menia nasledovne:
  1. shift s:

     $(s_0 X_1 s_1 X_2 s_2 \ldots X_m s_m a_i s, a_{i+1} \ldots a_n\$)$
  2. reduce $A \rightarrow \beta$:

     $(s_0 X_1 s_1 X_2 s_2 \ldots X_{m-r} s_{m-r} A s, a_i a_{i+1} \ldots a_n\$)$,

     kde $s = goto[s_{m-r}, A]$ a $r = |\beta|$
  3. accept: ukončenie parsovania
  4. error: volanie funkcie na ošetrenie chyby

LR parsovací algoritmus

nastav *ip* na prvý symbol *w*\$;
repeat forever begin
  nech *s* je stav na vrchu zásobníka a
    a je symbol, na ktorý ukazuje *ip*;
  if *action*[*s*, *a*] = shift *s*′ **then begin**
    vlož *a* a potom *s*′ na vrch zásobníka;
    posuň *ip* na ďalší vstupný symbol
  end;
  else if *action*[*s*, *a*] = reduce $A \rightarrow \beta$ **then begin**
    vyber $2 * |\beta|$ symbolov zo zásobníka;
    nech *s*′ je stav navrchu zásobníka;
    vlož *A* a potom *goto*[*s*′, *A*] na vrch zásobníka;
    vypíš na výstup pravidlo $A \rightarrow \beta$
  end
  else if *action*[*s*, *a*] = accept **then**
    return
  else error()
end

LR gramatiky

- Vieme pre ne zostrojiť LR parsovaciu tabuľku
- Existujú CF gramatiky, ktoré nie sú LR
  - Vo všeobecnosti sa im vieme vyhnúť pri popise syntaxe programovacích jazykov
- Handle sa rozpoznáva podľa
  1. Obsahu zásobníka
     - Nečítame v každom kroku celý zásobník. informáciu o jeho obsahu reprezentuje stav DKA na vrchu zásobníka
  2. k vstupných symbolov
     - V praxi nás zaujímajú prípady $k = 0$, $k = 1$

LR vs. LL gramatiky

- LR:
  - → Pravidlo sa rozpoznáva podľa všetkého, čo sa odvodí z jeho pravej strany a k symbolov výhľadu dopredu
- LL:
  - → Pravidlo sa rozpoznáva podľa neterminálu na ľavej strane, a k symbolov z toho, čo sa odvodí z jeho pravej strany