

# Kompilátory

*RNDr. Ján Štunc, CSc.*

**Katedra informatiky MFF UK**

**marec 1998 (ver 1.0)**




## **Literatúra:**

- A.V.Aho, R.Sethi a J.D.Ullman:  
Compilers Principles, Techniques and Tools.  
Addison Wesley, Reading Mass. 1986.
- A.V.Aho, J.D.Ullman:  
Compiler Design.  
Addison Wesley 1977.
- A.V.Aho, J.D.Ullman:  
The theory of Parsing, Translation and Compiling.  
Vol. I. Parsing Prentice Hall 1972  
Vol. II. Compiling Englewood Cliffs N.J. 1973
- C. N. Fisher, R. J. Leblanc:  
Crafting a Compiler  
The Benjamin / Cummings Publishing Company, Inc, 1988.
- Ľ. Molnár, M. Češka, B. Melichar:  
Gramatiky a jazyky.  
Alfa, SNTL Bratislava 1987.

**Upozornenie:** *Nasledujúci text nie je učebnica ani učebný tex, ale len poznámky k prednáške. Obsahuje väčšinou len to, čo počas prednášky napíšem na tabuľu alebo premietnem. Hlavným jeho účelom je ušetriť zdržujúce opisovanie počas prednášky.*

# 1 Úvod



Prvá predstava kompilátora.

## Prečo?

N1: Všetky kompilátory sú už hotové, je to zbytočné.

O1: Celý rad aplikácií používa nejakú formu analýzy.


Napr.:

- štrukturálne editory
- tlačové programy (type-seter)
- statické kontrolóry
- formátory textu
- kremíkové kompilátory
- interpretátory databázových dotazov

atď.

N2: Aj to si väčšinou kupujeme.

O2: Navyše kompilátor je exemplárny príklad veľkého programu, pre ktorý sa našli efektívne techniky. Realizácia kompilátorov prvých jazykov FORTRAN, Algol 60, COBOL trvala roky veľkým pracovným tímom. Vďaka pokroku teórie dnes môže realizovať aj študent ako ročníkovú prácu. Je asi užitočné osvojiť si techniky, ktoré k tomu viedli.

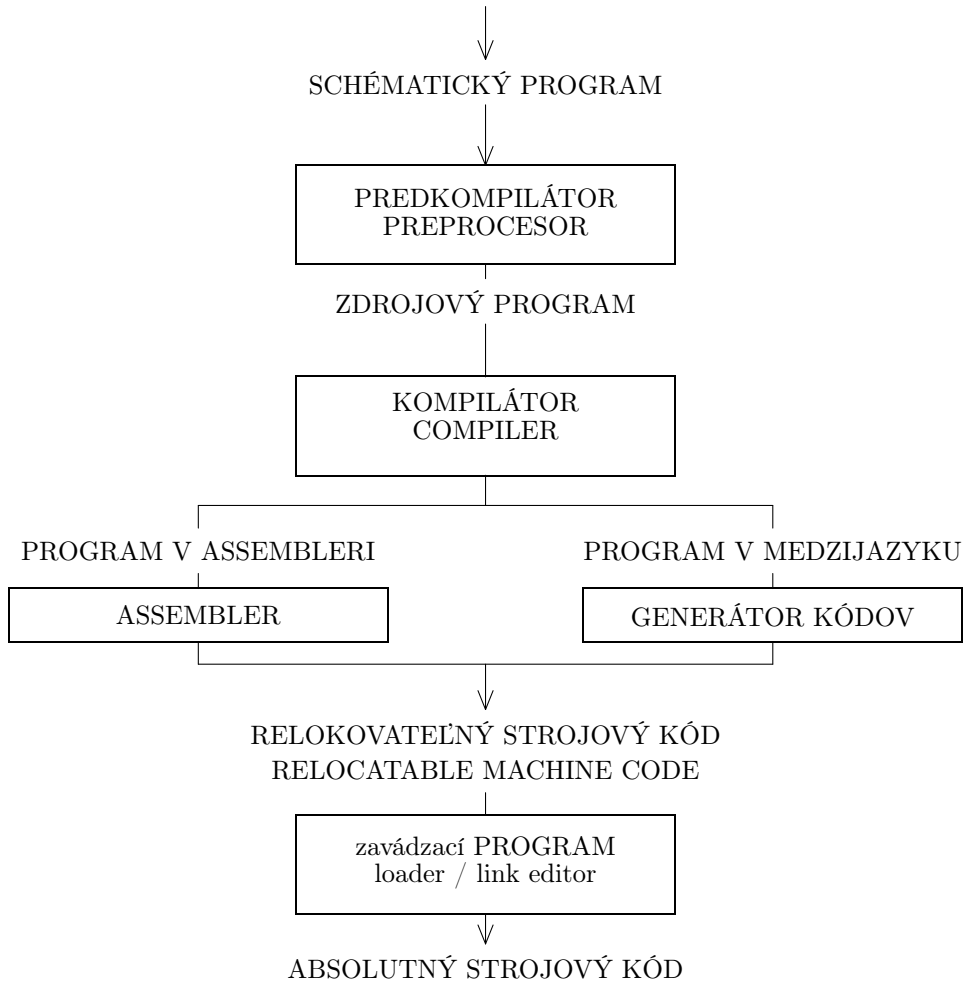


Analýza štruktúry (vytváranie stromu) je základ kompilácie.

## Predpoklady:

- I. Formálne jazyky.
- II. Praktická znalosť nejakého programovacieho jazyka.
- III. Assembler.  
(model počítača) RAM.  
RASP.

## 1.1 Spracovanie jazyka



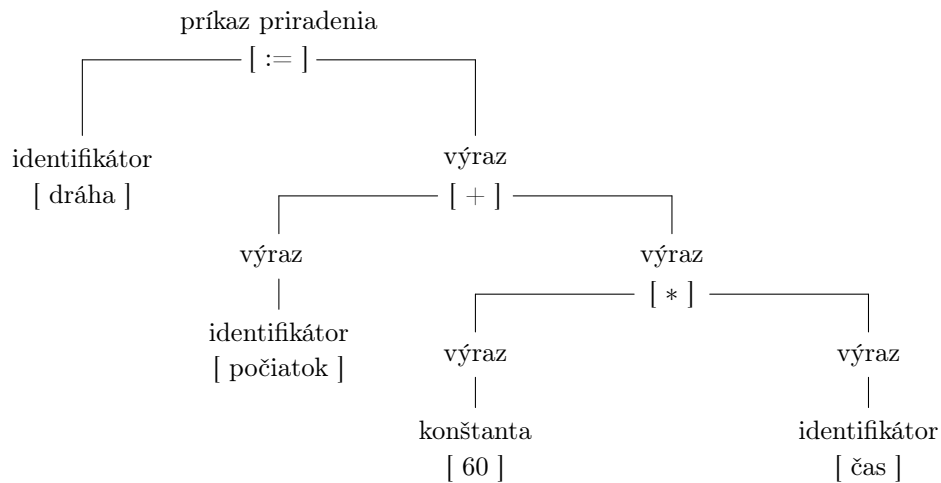
### Zdroje príkladov:

- Klasické programovacie jazyky: FORTRAN  
ALGOL 60  
PL/I
- Moderné programovacie jazyky: Pascal  
C  
Modula
- Databázové a logické jazyky: SQL  
Prolog  
Trilogy
- Tlačové systémy a editory: T<sub>E</sub>X, L<sup>A</sup>T<sub>E</sub>X  
EQN

**Príklad:** Ako pracuje kompilátor.

1. identifikátor	<i>dráha</i>	} lexikálna analýza lexikálny analyzátor – scanner
2. symbol priradenia	<i>:=</i>	
3. identifikátor	<i>počiatok</i>	
4. operátor sčítania	<i>+</i>	
5. konštanta (číslo)	<i>60</i>	
6. operátor násobenia	<i>*</i>	
7. identifikátor	<i>čas</i>	

## Syntaktická analýza (parsing)



### Bezkontextová gramatika:

$$\begin{aligned} \langle \text{výraz} \rangle ::= & \langle \text{identifikátor} \rangle \mid \langle \text{konštanta} \rangle \mid \\ & \langle \text{výraz} \rangle + \langle \text{výraz} \rangle \mid \langle \text{výraz} \rangle * \langle \text{výraz} \rangle \end{aligned}$$

Rozdelenie práce medzi lexikálnu a syntaktickú analýzu nie je presne určené.

Spravidla: scanner – regulárna gramatika

parser – bezkontextová gramatika

### Sémantická analýza.

Kontroluje sémantické chyby.

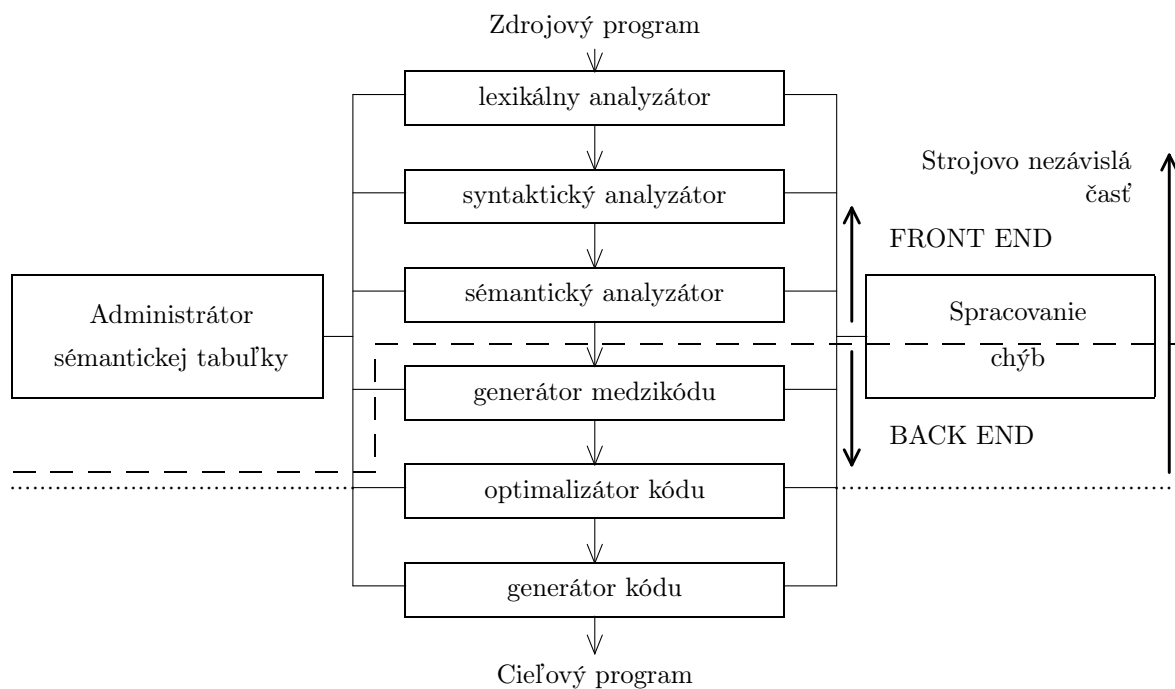
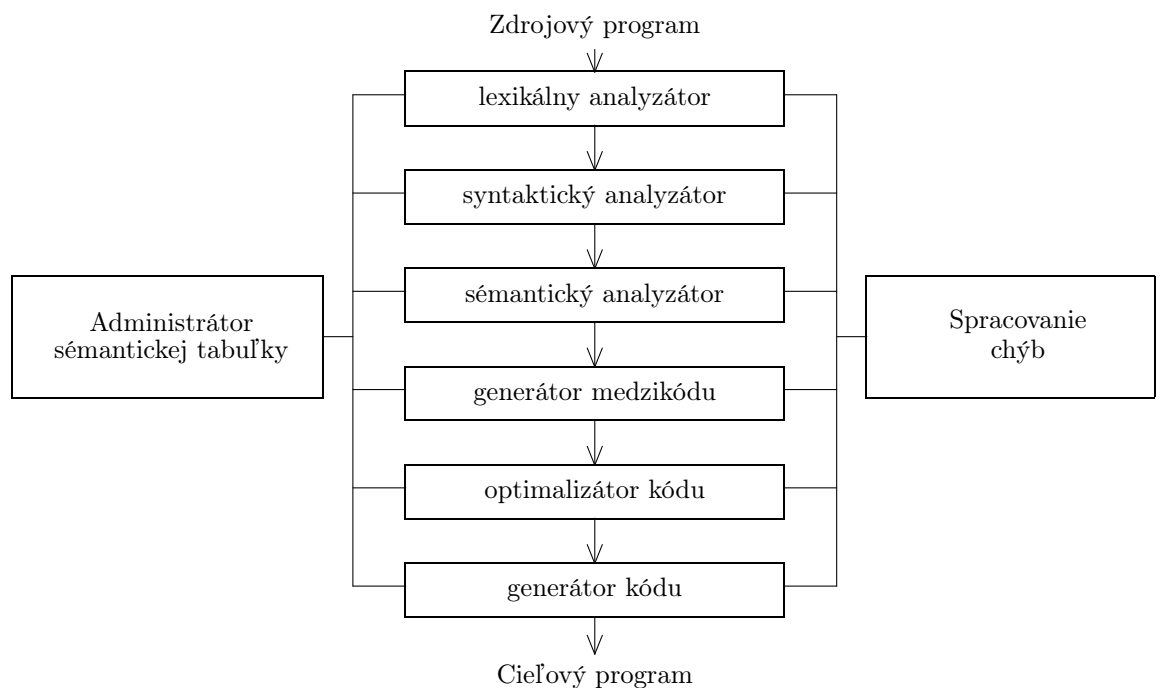
Zbiera informácie o typoch. Typová analýza.

**Príklad:** V našom výraze konštanta 60 má byť reálna (vzhľadom na typy ostatných identifikátorov).

Rozdelenie práce medzi syntaktickú a sémantickú analýzu je trochu ľubovoľné.

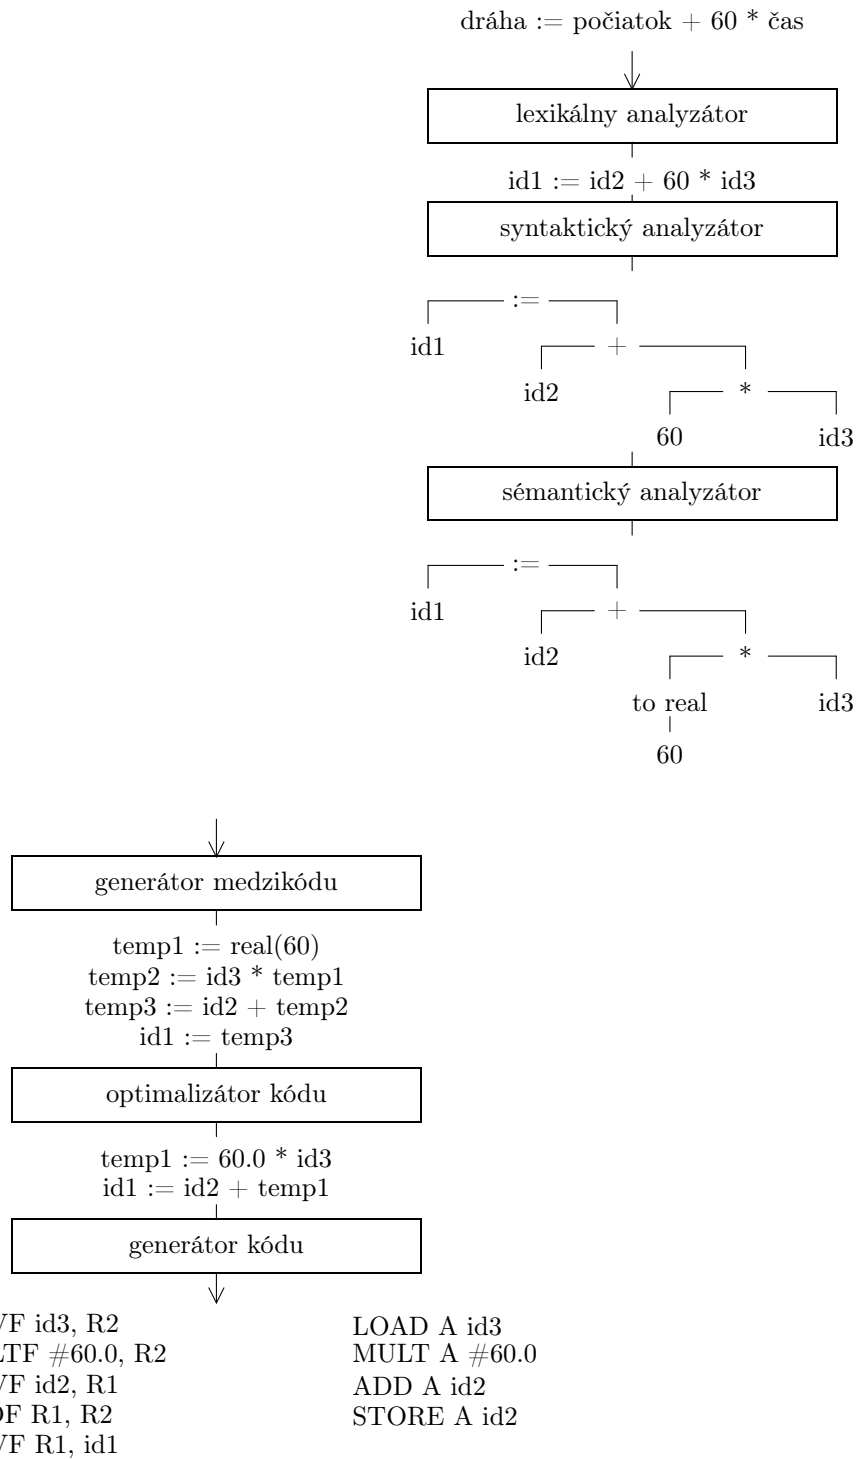
V zásade sémantika je to, čo sa nedá popísať bezkontextovou gramatikou.

## 1.2 Podrobnejšia štruktúra kompilátora



## Tabuľka symbolov


dráha	...
počiatok	...
60	...
čas	...
⋮	



**Dátové štruktúry.**

Tabuľka symbolov:   hašovanie  
Syntaktické stromy: smerníky.

	:
12	dráha
13	čas
14	počiatok
	:
17	60
	:




### 1.3 Nástroje pre tvorbu kompilátorov


1. Generátory syntaktických analyzátorov (TWS, Compiler-compiler)



2. Generátory lexikálnych analyzátorov




3. Syntaxou riadený prekladač




**Front-end: strojovo nezávislá časť 1, 2, 3.**

4. Generátory kódu



Technika: šablóny (templates), makrá pre inštrukcie medzikódu.

5. Analyzátory toku dát

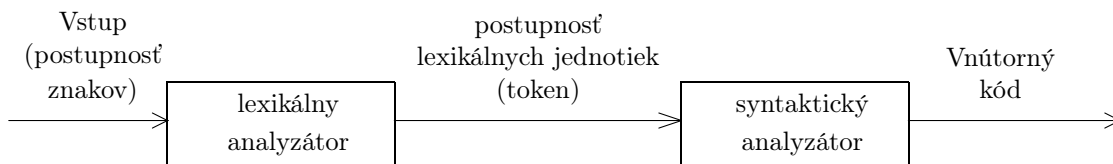


**Back-end: strojovo závislé časti 4, 5**

Prechody: Veľa prechodov (čas na zapisovanie a čítanie)  
Málo prechodov (náročné na pamäť, veľké časti programu musia byť v pamäti)  
Jedno-prechodové kompilátory – prakticky celý kompilátor je v pamäti.



## 2 Jednoduchý prekladač.



Bezkontextová gramatika  $G = (T, N, R, \sigma)$

$T$  - terminálne symboly (tokens)

$N$  - neterminálne symboly (variables)

$R$  - množina pravidiel (rules)

$\sigma$  - počiatočný symbol  $\sigma \in N$

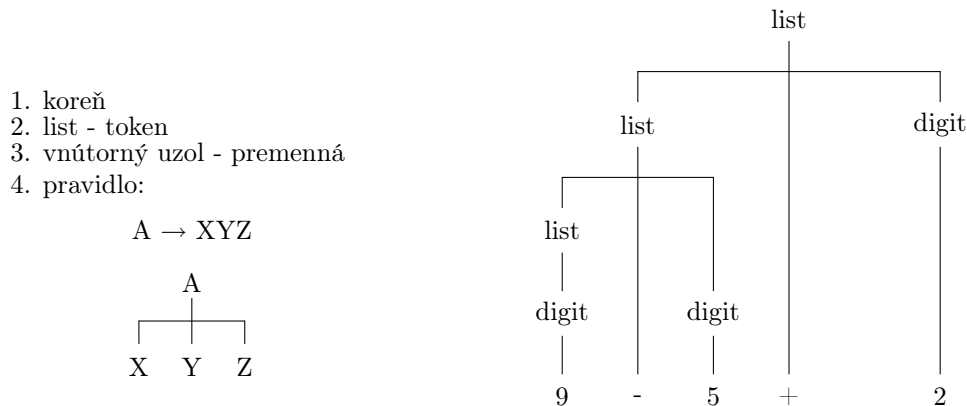
**Príklad:**

$$\begin{aligned} list &\rightarrow list + digit \mid list - digit \mid digit \\ digit &\rightarrow 0 \mid 1 \mid 2 \mid 3 \mid 4 \mid 5 \mid 6 \mid 7 \mid 8 \mid 9 \end{aligned}$$


**Príklad:**

9 - 5 + 2

Syntaktický strom:



1. koreň
2. list - token
3. vnútorný uzol - premenná
4. pravidlo:

$$A \rightarrow XYZ$$




**Nejednoznačnosť** (ambiguity).

**Definícia 2.1** Gramatiku nazývame *nejednoznačnou*, ak nejakému slovu jazyka existujú dva neizomorfné stromy odvodenia.

Ak používame *nejednoznačnú* gramatiku pre popis syntaxe, musíme *nejednoznačnosť* vyriešiť na úrovni sémantiky – pomocou atribútov alebo sémantických programov.

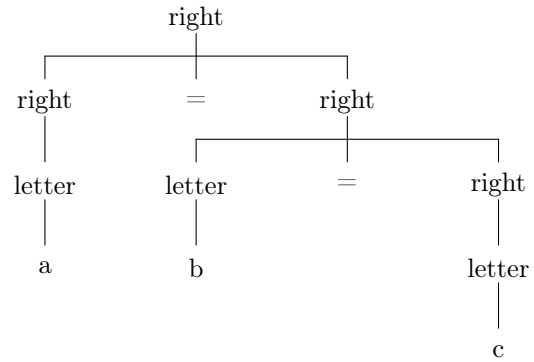

**Príklad:**

$$\begin{aligned} string &\rightarrow string + string \mid string - string \mid \\ &0 \mid 1 \mid 2 \mid 3 \mid 4 \mid 5 \mid 6 \mid 7 \mid 8 \mid 9 \end{aligned}$$



### Asociatívnosť operátorov.

$right \rightarrow letter = right \mid letter$   
 $letter \rightarrow a \mid b \mid c \mid \dots \mid z$



### Priorita operátorov.

1. ľavo asociatívne + -
2. ľavo asociatívne \* /

$expr \rightarrow expr + term \mid expr - term \mid term$   
 $term \rightarrow term * factor \mid term / factor \mid factor$   
 $factor \rightarrow digit \mid (expr)$

### Príklad:

$stm \rightarrow id := expr \mid$   
 $\quad \mathbf{if} \ expr \ \mathbf{then} \ stm \mid$   
 $\quad \mathbf{if} \ expr \ \mathbf{then} \ stm \ \mathbf{else} \ stm \mid$   
 $\quad \mathbf{while} \ expr \ \mathbf{do} \ stm \mid$   
 $\quad \mathbf{begin} \ stm\_list \ \mathbf{end} \mid$   
 $stm\_list \rightarrow stm\_list; \ stm \mid \epsilon$

### Postfixový zápis operátorov.

1. Ak  $E$  je premenná alebo konštanta potom  $E' = E$ .
2. Ak  $E = E_1 \mathbf{op} E_2$  potom  $E' = E'_1 E'_2 \mathbf{op}$ .
3. Ak  $E = (E_1)$  potom  $E' = E$ .

### Príklad:


$(9 - 5) + 2 \Rightarrow 95 - 2+$   
 $9 - (5 + 2) \Rightarrow 952 + -$

## 2.1 Syntaxou riadený preklad.

Pravidlo	Sémantické pravidlá
$\text{expr} \rightarrow \text{expr} + \text{term}$	$\text{expr.t} := \text{expr1.t} \parallel \text{term.t} \parallel '+'$
$\text{expr} \rightarrow \text{expr} - \text{term}$	$\text{expr.t} := \text{expr1.t} \parallel \text{term.t} \parallel '-'$
$\text{expr} \rightarrow \text{term}$	$\text{expr.t} := \text{term.t}$
$\text{term} \rightarrow 0$	$\text{term.t} := 0$
$\text{term} \rightarrow 1$	$\text{term.t} := 1$
:	
$\text{term} \rightarrow 9$	$\text{term.t} := 9$

Všetky premenné majú rovnaký atribút t.

Syntaktický strom ohodnotený atribútami:



**Definícia 2.2** *Syntetizované atribúty sú také atribúty, že hodnota atribútu v každom uzle sa dá určiť z hodnôt atribútov jeho následníkov t.j. môžu byť vyhodnotené na jeden prechod zdola nahor.*

**Príklad:** Sledovanie pozícií robota.

*instr* → *east* | *north* | *west* | *south*  
*seg* → *seginstr* | **begin**


Pravidlo	sémantické pravidlá
$\text{seg} \rightarrow \mathbf{begin}$	$x := 0; y := 0;$
$\text{seg} \rightarrow \text{seg instr}$	$x := x + dx; y := y + dy;$
$\text{instr} \rightarrow \text{east}$	$x := 1; y := 0;$
$\text{instr} \rightarrow \text{north}$	$x := 0; y := 1;$
$\text{instr} \rightarrow \text{west}$	$x := -1; y := 0;$
$\text{instr} \rightarrow \text{south}$	$x := 0; y := -1;$

**Prehľadávanie do hĺbky.** (depth-first search)

```

procedure visit(n : node);
begin
  for each child m of n from left to right do
    visit(m);
  evaluate semantic rules at node n
end

```



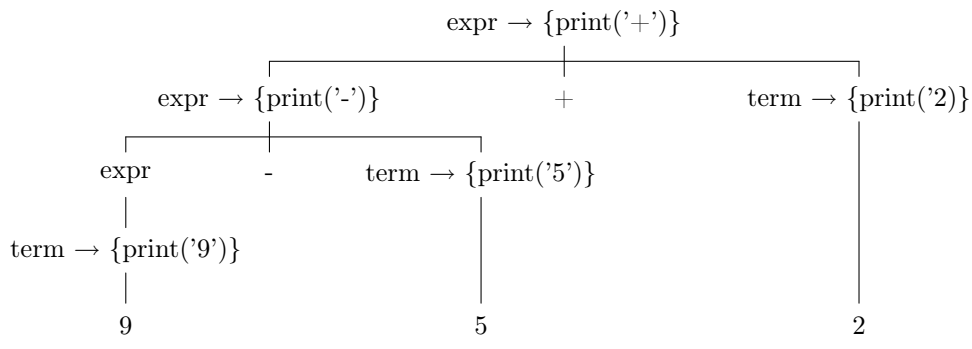
Čísla udávajú poradie, v akom sú uzly navštívené pri prehľadávaní do hĺbky.

Očakáva sa, že miesto sémantickej akcie je udané explicitne.

**Nevýhoda:** Výstup sa vypočíta počas analýzy a musí byť celý v pamäti. Chceli by sme ho produkovať inkrementálne.

**Pravidlá:**

- $expr \rightarrow expr + term \quad \{\text{print ('+')}\}$
- $expr \rightarrow term \quad \{\text{print ('-')}\}$
- $expr \rightarrow term$
- $term \rightarrow 0 \quad \{\text{print ('0')}\}$
- $term \rightarrow 1 \quad \{\text{print ('1')}\}$
- $\vdots$
- $term \rightarrow 9 \quad \{\text{print ('9')}\}$



Syntaktická analýza: CFG:  $O(n^3)$ .  
 Programovacie jazyky špeciálne prípady  $O(n)$


**Rozdelenie metód syntaktickej analýzy:**


- |                       |                         |
|-----------------------|-------------------------|
| zhora-dolu (top-down) | zdola-nahor (bottom-up) |
| ľahšie sa ručne robí  | širšia trieda gramatík  |
| lepšie sa zaradia     | a prekladových schém.   |
| sémantické programy.  |                         |

**Príklad:**

- $type \rightarrow simple \mid \uparrow id \mid \mathbf{array}[simple] \text{ of } type$
- $simple \rightarrow integer \mid char \mid num..num$

INPUT: array [num..num] of integer





```

procedure match(t:token);
begin
    if lookahead = t then
        lookahead:=nexttoken
    else error fi 1
end ;

procedure type;
begin
    if lookahead is in {integer,char,num} then
        simple
    else if lookahead = '^' then
        match('^'); match(id)
    else if lookahead = array then
        match(array); match('[');
        simple; match(']'); match('of');
        type;
    else error
    fi fi fi
end ;

procedure simple;
begin
    if lookahead = integer then
        match(integer)
    else if lookahead = char then
        match(char)
    else if lookahead=num then
        match(num); match('..'); match(num)
    else error
    fi fi fi
end

```

**Definícia 2.3**  $First(\alpha) = \{x : (x \in T \cup \{\varepsilon\}) \cap \alpha \xrightarrow{*} x.w\}$   
 Ak  $A \rightarrow BC$  a  $B \xrightarrow{*} \varepsilon$ , potom  $First(A) = First(B) \cup First(C)$ .

Prázdny symbol  $\varepsilon$  treba ošetriť špeciálne. Pravidlo  $A \rightarrow \varepsilon$  sa použije v rekurzívnom zostupe iba vtedy, ak sa žiadne iné pravidlo nedá použiť. Použitá technika sa nazýva prediktívna kompilácia resp. „recursive descent“.

<sup>1</sup>Používame nasledujúcu syntax podmieneného príkazu:  
 cond  $\rightarrow$  **if** < podmienka > **then** < S1 > **else** < S2 > **fi**

Pri konštrukcii najprv ignorujeme sémantické akcie a zostrojíme syntaktický analyzátor. Potom vpíšeme sémantické akcie na miesto, kde patria.

Zostrojíme množiny First pre všetky neterminály. Ak tieto množiny nie sú disjunktné tak sa metóda rekurzívneho zostupu nedá použiť.

### Odstránenie ľavej rekurzie.

Ľavá rekurzia spôsobuje zacyklenie pri rekurzívnom zostupe, preto ju nahrádzame pravou podľa nasledujúcej schémy:

$$A \rightarrow A\alpha \Rightarrow \begin{array}{l} A \rightarrow \beta R \\ R \rightarrow \alpha R \mid \varepsilon \end{array}$$

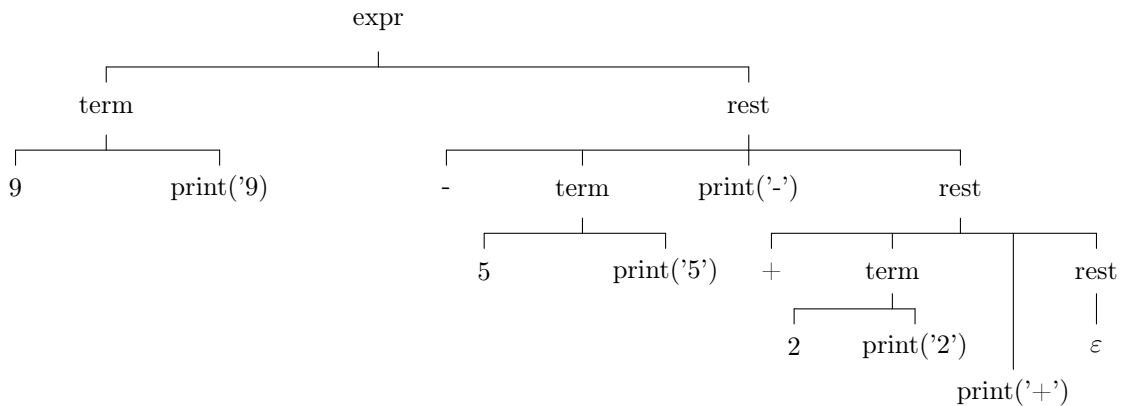
Ak nejde o bezprostrednú ľavú rekurziu. Musíme očíslovať neterminálne symboly v cyklických pravidlách a postupnou substitúciou za ne dostaneme nakoniec bezprostrednú ľavú rekurziu.

Príklad:

$$\begin{array}{l} A \rightarrow B\alpha \\ B \rightarrow C\beta \\ C \rightarrow A\gamma \\ \text{Dosadíme:} \\ C = A\gamma \\ B = A\gamma\beta \\ \text{Dostaneme pravidlo:} \\ A \rightarrow A\gamma\beta\alpha \end{array}$$

$$\begin{array}{l} expr \rightarrow term\ rest \\ rest \rightarrow + term \{print('+')\} rest \mid \\ \quad - term \{print('-')\} rest \mid \varepsilon \\ term \rightarrow 0 \{print('0')\} \mid \dots \mid 9 \{print('9')\} \end{array}$$

**Príklad:** 9-5+2



**Program:**

```
procedure expr;
begin
    term;
    rest
end

procedure rest;
begin
    case lookahead of
        '+': begin
            match('+'); term; print('+'); rest
            end
        '-': begin
            match('-'); term; print('-'); rest
            end
        otherwise: ;
    end
end

procedure term;
begin
    if is_digit(lookahead) then
        begin
            print(lookahead);
            match(lookahead);
        end
    else ERROR(2);
end

function is_digit(x:char) : boolean;
    < is_digit=true ak x je číslca. Inak is_digit=false. Funkcia závisí na kódovaní znakov. >

procedure ERROR(n)
begin
    writeln(Error_message[n]);
    < správa o chybe >
    case n of
        1: while (lookahead ≠ '+' ) or (lookahead ≠ '-') do read(lookahead);
        2: while not is_digit(lookahead) do read(lookahead)
    end zotavenie z chyby;
end
```

**Optimalizácia.**

odstránenie "chvostovej"rekurzcie.

```
procedure rest;
begin
    L: if lookahead='+' then
        begin
            match('+'); term; print('+'); goto L
        end
    else if lookahead='-' then
        begin
            match('-'); term; print('-'); goto L
        end
    end
end
```

```

procedure expr;
begin
    term;
    loop
    if lookahead={ '+' or '-' } then
        begin
            match(lookahead);
            term;
            print(lookahead);
        end
    else EXIT
    pool
end

```

## 2.2 Lexikálny analyzátor.




Prečo?

=	→	Dve funkcie
=		končiť lex. jednotku
oddelovače		iný význam

**Príklad:** id1+id2

Praktická realizácia  
Vyrovnávacia pamäť

Pozerá ešte jeden  
symbol v predstihu



Pravidlá tvaru  $A \rightarrow aA \mid b \mid \varepsilon$  Nepotrebuje rekurziu.

Kľúčové slová.

Priamo – robí kompilátor príliš dlhý.

**Príklad:** Rozlíšenie medzi

<b>else</b>	
elsa	Vyžaduje dlhý predstih.

Nepriamo - cez tabuľku symbolov.

Medzery a poznámky

**while** lookahead = '␣' **do** read(lookahead) { alebo LF+CR či TAB (ASCII) }

Môžu byť ťažkosti: napr. ALGOL 60

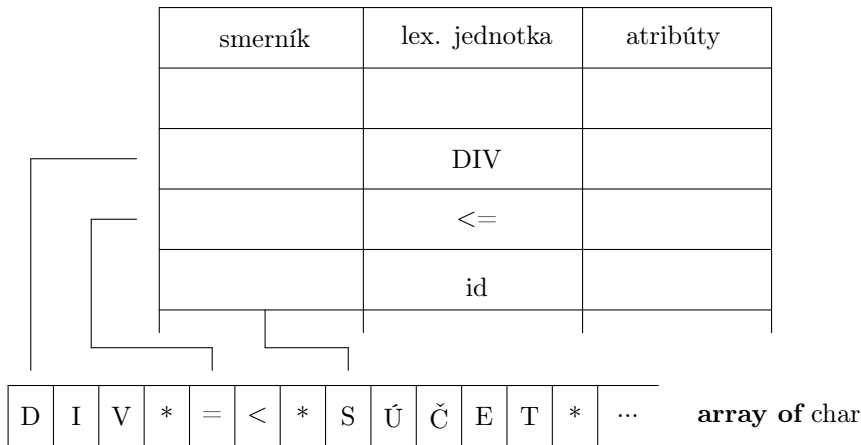
FOR I:=T1 TO T2 STEP T3



## Tabuľka symbolov:

ADT: member(x):boolean  
insert(x)  
ask(x,attributes)

Realizácia:



Lexikálna jednotka môže byť kódovaná priamo relatívnou adresou v tabuľke. Na začiatku sa tabuľka inicializuje rezervovanými slovami.

Hašovanie, Rozšíriteľné hašovanie, sekvenčné stromy

## Hašovanie:

Rozmer tabuľky:  $n = \begin{cases} 2^k \\ p - \text{prvočíslo} \end{cases}$

Vstup je postupnosť znakov

Operátor # ( xxxxxxxxxxx ) urobí z argumentu binárne číslo s rovnakým kódovaním

$h(K) = \#(K) \bmod n$  ( sú aj iné možnosti )

$h(K)$  relatívna adresa  $K$  v tabuľke symbolov

$h(K)$  voľná O.K. uložíme

už obsadené pointer ukazuje na postupnosť identickú s  $K$

O.K. vráti atribúty už obsadené inou postupnosťou

## Kolízia.

Riešenie kolízie + a gcd(n,a)=1.

ďalšou hašovaciou funkciou.

Postupnosť hašovacích funkcií  $h_1, h_2, \dots$


Cena vkladania alebo neúspešného hľadania:  $\frac{1}{1-\alpha}$

Cena úspešného hľadania:  $-\frac{\log(1-\alpha)}{\alpha}$ ,

kde  $\alpha$  je faktor naplnenia.

## 2.3 Abstraktný zásobníkový počítač – generovanie kódu

zásobník (stack)



ADT top  
push  
pop  
empty?

L-hodnoty a R-hodnoty

$i:=5$ ;  $\leftarrow$  hodnota

$i:=i+1$ ;  $\leftarrow$  referencia (adresa)

operácie a+b r value a  
r value b  
+

INAK push <a>  
push <b>  
AC:=a  
AC:=a+b  
pop  
pop  
push <AC>

operácie

push r - daj r do zásobníka  
rvalue a - daj obsah adresy a do zásobníka  
lvalue a - daj adresu a do zásobníka  
pop - odstráň položku z vrcholu zásobníka  
:= - lvalue je rvalue; pop; pop  
copy - push top

### Príklad:

$day := (1461 * y)div4 + (153 * m + 2)div5 + d$

Preklad: 1 l value day  
2 push 1461  
3 r value y  
4 \*  
5 push 4  
6 div  
7 push 153  
8 r value m  
9 \*  
10 push 2  
11 +  
12 push 5  
13 div  
14 +  
15 r value d  
16 +  
17 :=

Postupnosť inštrukcií ASM (abstract stack machine)

Inštrukcie sa vykonávajú v poradí, ak nie je špecifikované inak.

**label l** môže byť cieľom skoku  
nemá iný účinok.  
**goto l** nasledujúci sa vykoná príkaz label l  
**gofalse l** pop top and if top= 0 then goto l  
**gotrue l** pop top and if top $\neq$ 0 then goto l  
**halt** zastavenie

### Preklad príkazov:

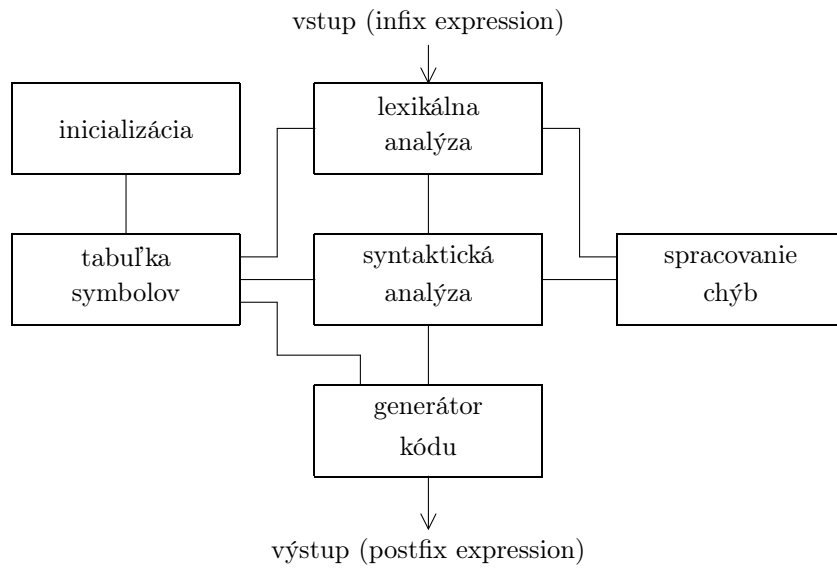
stmt  $\rightarrow$  **if** expr **then** stmt1 IF stm  $\rightarrow$  **if**

code for expr go false out code for stmt1 label out
--


**while** expr **do** stmt1 **end** ;

label test code for expr go false out code for stmt1 goto test label out
---

## Celková štruktúra kompilátora



### 3 Lexikálny analyzátor.



1. Prečo oddeľujeme lexikálnu a syntaktickú analýzu?

- jednoduchší návrh (medzery, komentáre)
- efektívnosť
- portabilita a nezávislosť na kódovaní.

2. Čo rozpoznáva lexikálna analýza?

- konštanty: numerické (numeral)  
reťazcové (literál, string)  
znakové (character)

- operátory
- oddeľovače (zátvorky, ";", ...)
- rezervované slová
- identifikátory.

Je to ťažké? *Obvykle nie, ale...*

**Príklad:**

**FORTRAN:** DO 5 I = 1.25  
DO 5 I = 1,25

**PL/1:** IF THEN THEN THEN = ELSE;  
ELSE ELSE = THEN;  
DECLARE(A1,A2,A3,...,An)

Komunikácia medzi lex.analyzátorom a syntaktickým analyzátorom:

- 1-prech. - prirodzená: lexikálna jednotka + atribúty
- skrátaná: lex.jednotka + smerník do tabuľky symbolov
- multiprech. - minimálna: smerník do tabuľky symbolov


**Príklad:**

```
E := M * C ** 2  
< id, ^SYMB E >  
< operátor _priradenia >  
< id, ^SYMB M >  
< operátor _násobenia >  
< id, ^SYMB C >  
< operátor _umocnenia >  
< konšt, integer 2 >
```

## Lexikálne chyby a zotavenie z chýb.

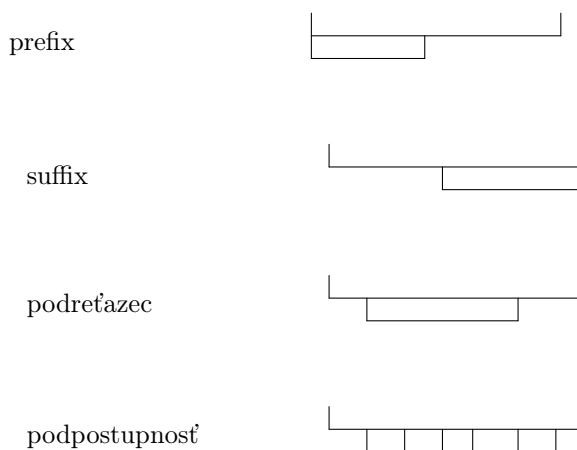
ťažkosť: scanner vidí text príliš lokálne

### Príklad:




- Zotavenie:
- vynechanie pochybnej lex. jednotky
  - vynechanie zbytočného znaku
  - vloženie chýbajúceho znaku
  - transpozícia dvoch vedľajších znakov
  - výmena nesprávneho znaku

### Pojmy:




### Príklad:



Chybový stav: prezeraný reťazec nie je prefix žiadnej lexikálnej jednotky.  
 - teória: predpoklad minimálnej chyby  
 (prakticky sa nerealizuje – príliš náročné)

Ako sa implementuje scanner?	Obtiažnosť	Efektívnosť
-generátor lex. analyzátorov	1	3
-v konvenčnom program. jazyku (C, modula, pascal) I/O modul jazyka	2	2
-assembler s explicitným riadením I/O	3	1

### Cyklické používanie 2 vyrovnávacích pamätí:




```

if forward na konci 1. polovičky then
begin
    načítaj 2. polovičku
    forward := forward + 1
end
else
if forward na konci 2. polovičky then
begin
    načítaj 1. polovičku
    forward := 0
end
else forward := forward + 1

```

Použitie zarážok:



```

forward := forward + 1
if forward^ = EOF then
begin
    if forward na konci 1. časti then
        čítaj 2. časť
        forward := forward + 1
    end
    else
        if forward na konci 2. časti then
            begin
                čítaj 1. časť
                forward := 0
            end
        else < koniec súboru >
            skonči lexikálnu analýzu
    end

```

end

### 3.1 Špecifikácia lexikálnych jednotiek

Regulárne výrazy ( Rational language )

1.  $\epsilon$        $\{ \epsilon \}$
2.  $a \in \Sigma$      $\{ a \}$
3.  $r|s$        $L(r) \cup L(s)$   
     $rs$        $L(r)L(s)$   
     $r^*$        $(L(r))^*$        $r^* = \epsilon \cup r \cup rr \cup rrr \dots$
4.  $(r)$        $L(r)$       uzátvorkovanie

Priorita: \* . |

Skratky:

$$\begin{aligned} r^+ &= rr^* && ( r^* = \epsilon \cup r^+ ) \\ r^? &= r|\epsilon && ( r^* = r^+|\epsilon ) \\ [a-z] &= a \mid b \mid \dots z \end{aligned}$$

Algebraické vlastnosti:

$$\begin{aligned} r|s &= s|r \\ (r|s)|t &= r|(s|t) \\ (rs)t &= r(st) \\ r(s|t) &= rs|rt \\ (s|t)r &= sr|tr \\ \epsilon r &= r\epsilon = r \\ r^* &= (r|\epsilon)^* \\ r^{**} &= r^* \end{aligned}$$

**Príklad:**

$$\begin{aligned} \textit{letter} &\rightarrow A \mid B \mid \textit{ldots} \mid Z \mid a \mid b \mid \textit{ldots} \mid z \\ \textit{digit} &\rightarrow 0 \mid 1 \mid \dots \mid 9 \\ \textit{id} &\rightarrow \textit{letter}(\textit{letter} \mid \textit{digit}) \\ \textit{digits} &\rightarrow \textit{digit}^+ \\ \textit{optional\_Fraction} &\rightarrow \textit{.digits} \mid \epsilon \\ \textit{optional\_Exponent} &\rightarrow (E(+ \mid - \mid \epsilon))\textit{digits} \mid \epsilon \\ \textit{num} &\rightarrow \textit{digitsoptional\_Fractionoptional\_Exponent} \end{aligned}$$

Existujú jazyky, ktoré nie sú regulárne.

$$\{a^n b^n ; n \leq 0\} S \rightarrow aSb \mid \epsilon$$

Existujú jazyky, ktoré nie sú bezkontextové

$$\{wcw; w \in a,b^*\}$$



**Príklad:**

*if* → *if*  
*then* → *then*  
*else* → *else*  
*relop* → < | <= | = | <> | > | >=  
*id* → *letter(letter | digit)\**  
*num* → *digit+(.digit+)?(E(+ | - | ε)?digit+)?*  
*delim* → *blank | tab | newline*  
*ws* → *delim+*

### 3.2 Rozpoznávanie lexikálnych jednotiek

Prechodové diagramy, konečné automaty <stav,symbol> → nový stav  
 \* ...označuje, že posledný vstupný symbol treba vrátiť.

Implementácia prechodových diagramov:

Začíname: start:=0; state:=0;  
 Ak nájdeme hranu, zodpovedajúcu prezeranému symbolu,prechádzame po nej.  
 Ak takáto hodnota neexistuje, prejdeme k nasledujúcemu diagramu (start:=9) atď.  
 Ak žiadna hodnota neuspela => chyba.

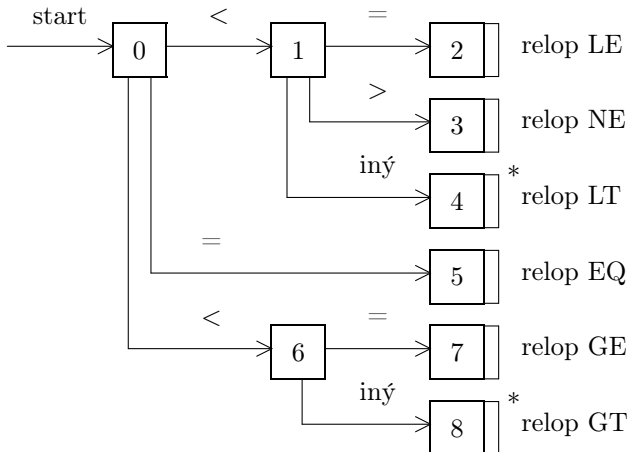
Prechodové diagramy a konečné automaty.  
 DFA,NFA  
 Prechodové tabuľky.

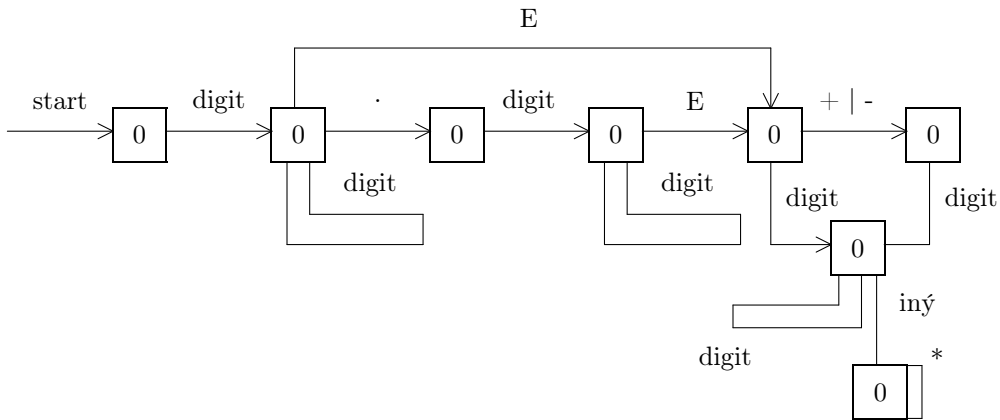

Konečný automat ... Finite Automaton

1. S - množina stavov
2. Σ - abeceda vstupných symbolov
3. Prechodová funkcia t: S x Σ → 2S
4. s<sub>0</sub> ∈ S počiatočný stav
5. F ⊂ S (konečná) akceptujúce stavy


Ak prechodová funkcia obsahuje na pravej strane najviac 1-prvkové množiny, tak automat je deterministický inak je nedeterministický.

**Príklad:**





**Príklad:**



$$LA = \{ aa^* | bb^* \}$$

**Veta 3.1** Každý regulárny jazyk sa dá rozpoznať nejakým DFA. Každý NFA rozpoznáva nejaký regulárny jazyk.

### 3.3 Automatický návrh lexikálneho analyzátora

Lex c Yacc c UNIX/c .

Lex program


deklarácie %% pravidlá %% procedúry.

$\{ p_i \{ action_i \} \}^*$

$p_i \rightarrow$  regulárny výraz

$action_i \rightarrow$  činnosť pri jeho rozpoznaní






**Stratégia realizácie**

Regulárny výraz → NFA → DFA → minimal. DFA.


R → NFA: Thompsonova konštrukcia

1.  $\epsilon$




{  $\epsilon$  }

2.  $a \in \Sigma$




{ a }

3. N(s) – rozpoznáva s  
N(t) – rozpoznáva t




S | t

(a)



st

(b)



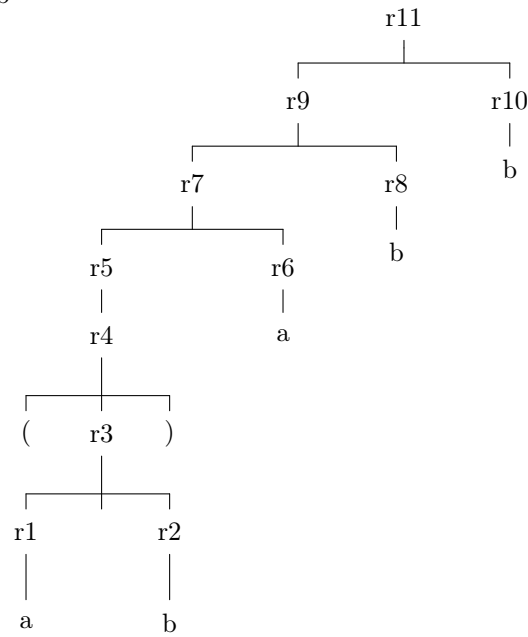
$s^*$

(c)

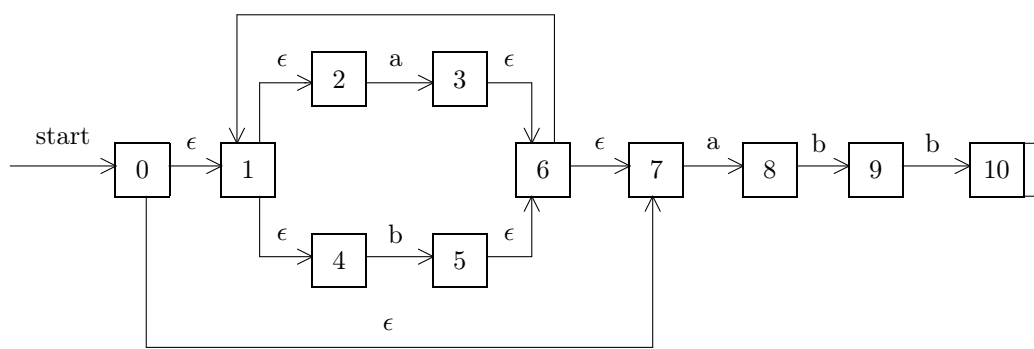
(d) NFA pre (s) je priamo N(s).

**Príklad:**

$(a \mid b)^*abb$



NFA (nedeterministický konečný automat)



NFA  $\rightarrow$  DFA subset construction

$$\epsilon\text{-closure}(s) = \{ q: \text{NFA } s \xrightarrow{\epsilon} q \}$$

$$\epsilon\text{-closure}(T) = \bigcup_{s \in T} \epsilon\text{-closure}(s)$$

$$\text{move}(s,a) = \{ q: s \xrightarrow{a} q \} \quad \text{move}(T,a) = \bigcup_{s \in T} \text{move}(s,a).$$

stavy DFA D-states sú množiny stavov NFA. VÝPOČET  $\epsilon$ -closure (T);

```

procedure  $\epsilon$ -closure(T);
begin
  push all states in T onto stack;
   $\epsilon$ -closure(T) := T;
  while stack is not empty do
    begin
      pop t, the top of stack;
      for each u such that there is an edge  $t \xrightarrow{\epsilon} u$  do
        if u is not in  $\epsilon$ -closure(T) then
           $\epsilon$ -closure(T) :=  $\epsilon$ -closure  $\cup$  {u};
          push u onto stack fi
        end
      end
    end
  end

```

KONŠTRUKCIA DFA:

```

procedure DFA-construction;
begin
  Dstates = {  $\epsilon$ -closure(s0); unmarked };
  while there is an unmarked state T in Dstates do
    begin
      mark T;
      for each input symbol a do
        begin
          u :=  $\epsilon$ -closure(move(T,a));
          if u is not in D states then
            Dstates:=Dstates u { u; unmarked };
          fi ;
          Dtran[T,a]:=u
        end
      end
    end
  end ;


```

A =  $\epsilon$ -closure(0) = {0,1,2,4,7}  
 B =  $\epsilon$ -closure(move(A,a)) = {1,2,3,4,6,7,8}  
 C =  $\epsilon$ -closure(move(A,b)) = {1,2,4,5,6,7}  
 D =  $\epsilon$ -closure(move(B,b)) = {1,2,4,5,6,7,9}  
 E = ..... {1,2,4,5,6,7,10}  
 nie sú iné nové stavy


Dtran (prechodová tabuľka deterministického automatu)

	a	b
A	B	C
B	B	D
C	B	C
D	B	E
E	B	C

DFA (deterministický konečný automat



## 4 Syntaktická analýza



Typy synt. analýzy

podľa metódy:

- zhora-dole | **LL(k)**
- zdola-hore | **LR(k)**

podľa triedy gramatík:

- všeobecné CFG | Cocke-Younger-Kasami; Earley
- podmnožiny CFG | **LL(k)** **LR(k)** operátorovo precedenčné gr.

Výhody a nevýhody:

**LL(k)** vždy vieme pravidlo i symbol

**LR(k)** vieme symbol pravidla až po rozpoznaní pravej strany.

Chyby a zotavenie z chýb:

- lexikálne chyby (misspeling)
- syntaktické chyby:
  - interpunkcia (;)
  - zátvorky (**begin** , **end** ) zle spárované
  - operátory := versus =
  - zložené príkazy neuzátvorkované(Značná časť chýb.)
- sémantické chyby (nesprávne typy operandov)
- logické chyby (prg. nekončí, nerobí čo má a pod.)

Požiadavky:

- Označiť chyby: presne, jasne a zrozumiteľne.
  - Rýchle sa zotaviť z chýb, aby mohli byť diagnostikované ďalšie chyby.
  - Spracovanie chýb nesmie výrazne spomaliť beh správnych programov.
- Range and type checking.

Stratégie:

- panický stav (panic mode)
- oprava konštrukcií jazyka (phrase level)
- chybové pravidlá (error productions)
- globálna oprava (global correction)

### Bezkontextové jazyky:

- správne spárované zátvorky

$$S \rightarrow (S)S \mid \epsilon$$

CFG  $G = \langle N, T, S, R \rangle$

konvencie: N  $\langle \rangle$ , modro, italicový

S symbol na ľavej strane 1.pravidla

T tučne, červene, ...

Odvodenie

- jeden krok
- \* reflexívny a tranzitívny uzáver

ľefmost derivation (najľavejšie odvodenie)

syntaktický strom

Nejednoznačnosť.

**Príklad:**

$E \rightarrow E+E \mid E-E \mid E^*E \mid (E) \mid -E \mid id$

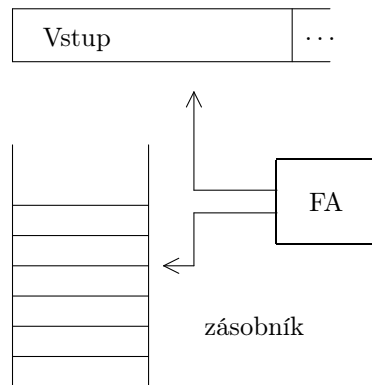
- |   |                         |   |                         |
|---|-------------------------|---|-------------------------|
| 1 | $E \rightarrow E+E$     | 2 | $E \rightarrow E^*E$    |
|   | $\rightarrow id+E$      |   | $\rightarrow E+E^*E$    |
|   | $\rightarrow id+E^*E$   |   | $\rightarrow id+E^*E$   |
|   | $\rightarrow id+id^*E$  |   | $\rightarrow id+id^*E$  |
|   | $\rightarrow id+id^*id$ |   | $\rightarrow id+id^*id$ |

Zjednoznačňujúce pravidlá alebo ekvivalentná jednoznačná gramatika.

Dôkaz, že CFG generuje daný jazyk:  $S \rightarrow (S)S|\epsilon$  generuje práve všetky dobre spárované zátvorky.

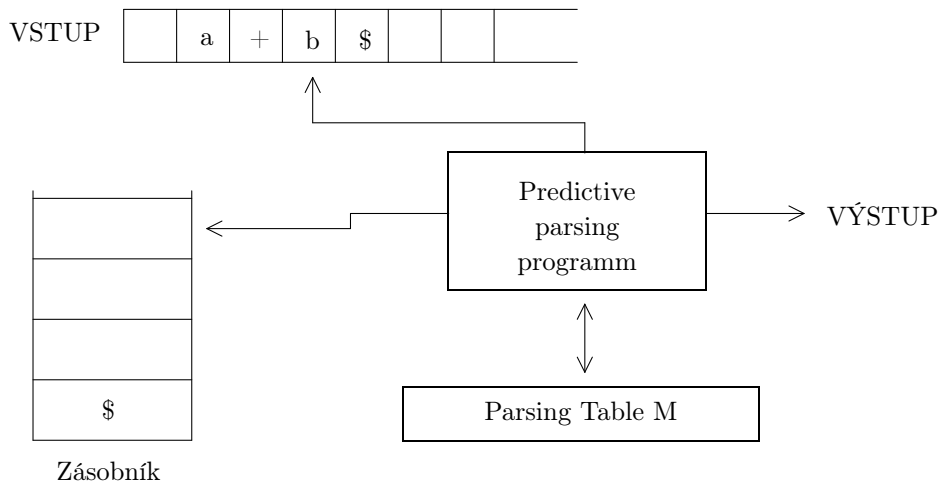
- Generuje len dobre spárované zátvorky.  
indukcia vzhľadom na dĺžku odvodenia  
(i)  $S \rightarrow \epsilon$  triviálne  
(ii)  $S \rightarrow (S)S \xrightarrow{*} (x)S \xrightarrow{*} (x)y$   
predpokladáme, že pre menej než  $n$  krokov funguje ukážeme, že to funguje aj pre  $n$  krokov.
- Všetky dobre spárované zátvorky sa dajú generovať. indukcia vzhľadom na dĺžku generovaného reťazca.  
 $|w| = 2n$                        $w = ( x ) y$   
 $S \rightarrow (S)S \xrightarrow{*} (x)S \xrightarrow{*} (x)y$   
Pretože  $|x| < 2n$  a  $|y| \leq 2n$ , výrazy  $x, y$  sa dajú generovať podľa indukčného predpokladu.

PDA:





Realizácia:



### First(x)

1. **if**  $x \in T$  **then**  $First(x) = \{x\}$ ;
2. **if**  $x \in N$  **then**  $First(x) = \emptyset$ ;  
 (i) **and**  $x \rightarrow \epsilon \in R$  **then**  $First(x) := First(x) \cup \{\epsilon\}$   
 (ii) **if**  $x \rightarrow Y_1Y_2\dots\dots\dots Y_n \in R$  **then**  
     **begin**  $First(x) := First(x) \cup First(Y_1)$   
         **while**  $Y_i \rightarrow \epsilon$  **do**  
              $First(x) := First(x) \cup First(Y_{i+1})$   
         **end** ;

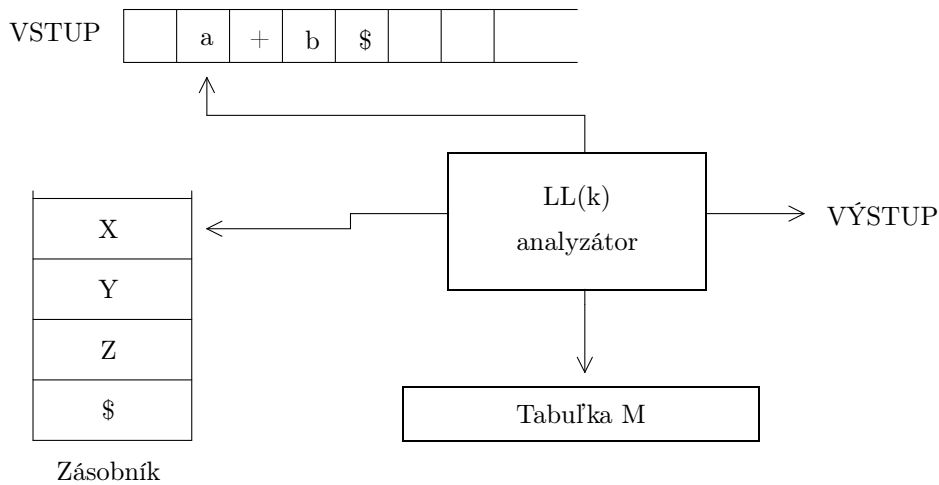
Zovšeobecnenie pre reťazce.

$First(X_1\dots\dots X_n)$

### Follow(x)

1.  $Follow(x) = \emptyset$
2.  $Follow(S) = \{\$\}$
3. **if**  $A \rightarrow \alpha B \beta$  **then**  
      $Follow(B) := Follow(B) \cup (First(\omega) - \{\epsilon\})$ ;
4.  $A \rightarrow \alpha B$  or  $A \rightarrow \alpha B \omega$  and  $\epsilon \in First(\omega)$  **then**  
      $Follow(B) := Follow(B) \cup Follow(A)$ ;

## 4.1 LL(k) metóda



VSTUP: slovo  $w \in \sigma^* w\$$

VYSTUP: najľavejšie odvodenie ak  $w \in L(G)$  inak správa o chybách.

INITIALIZE:

STACK := \$\$  
 $\hat{IN}$  := 1. symbol vstupu

**repeat**

$x := top; a := INPUT(\hat{IN});$

**if**  $x \in T \cup \{\$\}$  **then**

**if**  $x = a$  **then** *pop*; *next*( $\hat{IN}$ ) **else error** **fi**

**else**  $\langle x \in N \rangle$

**if**  $M[x,a] = X \rightarrow Y_1 Y_2 \dots Y_k$  **then**

**begin**

*pop*;

**for**  $i := k$  **to**  $1$  **do** *push*( $Y_i$ );

*output*(" $X \rightarrow Y_1 Y_2 \dots Y_k$ ");

**end**

**else error**

**until**  $X = \$$   $\langle$  stack je prázdny  $\rangle$ ;

G: E  $\rightarrow$  TE'  
 E'  $\rightarrow$  +TE' |  $\epsilon$   
 T  $\rightarrow$  FT'  
 T'  $\rightarrow$  \*FT' |  $\epsilon$   
 F  $\rightarrow$  (E) | id

$first(E) = first(T) = first(F) = \{(\cdot, id)\}$

$first(E') = \{+, \epsilon\}$

$first(T') = \{*, \epsilon\}$

$follow(E) = follow(E') = \{, \$\}$

$follow(T) = follow(T') = \{+, \cdot, \$\}$

$follow(F) = \{+, *, \cdot, \$\}$

Tabuľka M:

N	id	+	*	(	)	\$
E	$E \rightarrow TE'$			$E \rightarrow TE'$		
E'		$E' \rightarrow +TE'$		$E' \rightarrow \epsilon$	$E' \rightarrow \epsilon$	
T	$T \rightarrow FT'$		$T \rightarrow FT'$			
T'		$T' \rightarrow \epsilon$	$T' \rightarrow FT'$		$T' \rightarrow \epsilon$	$T' \rightarrow \epsilon$
F	$F \rightarrow id$			$F \rightarrow (E)$		

Komprimovaná tabuľka:

N	id	+	*	(	)	\$
E	TE'			TE'		
E'		TE'		$\epsilon$	$\epsilon$	
T	FT'		FT'			
T'		$\epsilon$	FT'		$\epsilon$	$\epsilon$
F	id			(E)		

Konstruktoria tabuľky M:

Vstup: gramatika G

Výstup: tabuľka

**Príklad:**

```

for all  $a \in T$  do inicializácia
  for all  $x \in N$  do
     $M[a,x] := 0$ ;
  for all  $\{ A \rightarrow \alpha \} \in R$  do
    for all  $a \in First(\alpha)$  do
      begin
         $M[A,a] := M[A,a] \cup \{ A \rightarrow \alpha \}$ ;
        if  $\epsilon \in First(\alpha)$  then
          begin
            for all  $b \in Follow(A)$  do
               $M[A,b] := M[A,b] \cup \{ A \rightarrow \alpha \}$ ;
            end
          end
        end
      end

```

**Príklad:**

$S \rightarrow iEtSS' \quad | \quad a$   
 $S' \rightarrow eS \quad | \quad \epsilon E \rightarrow b$

	a	b	e	i	\$
S	a			iEtSS'	
S'			$\epsilon$ eS		$\epsilon$
b		b			

gramatika je nejednoznačná – preferujeme eS

Ak gramatika má v každom políčku tabuľky najviac 1 položku, nazýva sa LL(1)

L - left-to-right

L - left most derivation

1 - 1 symbol look ahead

LL(k) ... k-tice neterminálov záhlavia tabuľky

Vlastnosti LL(1) gramatík:

(i) nie sú nejednoznačné (ambiguous)

(ii) neobsahujú ľavorekurzívne pravidlá

**Veta 4.1** Gramatika  $G$  je LL(1) práve vtedy, ak pre ľubovoľné dve pravidlá  $A \rightarrow \alpha$  a  $A \rightarrow \beta$  platí:

1.  $First(\alpha) \cap First(\beta) = \emptyset$

2. Ak  $\alpha \xrightarrow{*} \epsilon$ , potom  $\beta$  sa nedá odvodiť žiaden reťazec začínajúci terminálom vyskytujúcim sa vo  $FOLLOW(A)$

Eliminácia ľavej rekurzie.

$$\begin{array}{l} E \rightarrow E+T \mid T \quad E \rightarrow TE' \\ T \rightarrow T^*F \mid F \quad E' \rightarrow +TE' \mid \epsilon \\ F \rightarrow (E) \mid id \quad T \rightarrow FT' \\ \quad \quad \quad \quad T' \rightarrow *FT' \mid \epsilon \\ \quad \quad \quad \quad F \rightarrow (E) \mid id \end{array}$$

Technika:

1. Eliminácia bezprostrednej ľavej rekurzie (často stačí)

$$\begin{array}{l} A \rightarrow A\alpha_1 \mid A\alpha_2 \mid \dots \mid A\alpha_m \mid \beta_1 \mid \beta_2 \mid \dots \mid \beta_n \\ A \rightarrow \beta_1A' \mid \beta_2A' \mid \dots \mid \beta_nA' \\ A' \rightarrow \alpha_1A' \mid \alpha_2A' \mid \dots \mid \alpha_mA' \mid \epsilon \end{array}$$

**Eliminácia ľavej rekurzie:**

Vstup: gramatika  $G$  bez cyklov ( $A \xrightarrow{*} A$ ) a  $\epsilon$ -pravidiel

Výstup: gramatika bez ľavej rekurzie.

Metóda:

1. Definuj usporiadanie  $A_1, A_2, \dots, A_n$  medzi neterminálmi.
2. **for**  $i:=1$  **to**  $n$  **do**  
    **for**  $j:=1$  **to**  $i-1$  **do**  
        **begin**  
            nahrad' pravidlo  $A_i \rightarrow A_j\gamma$  pravidlami  
             $A_i \rightarrow \delta_1\gamma \mid \delta_2\gamma \mid \dots \mid \delta_n\gamma$ , kde  
             $A_j \rightarrow \delta_1 \mid \delta_2 \mid \dots \delta_n$  sú všetky pravidlá s pravou stranou  $A_i$ ;  
            odstráň bezprostrednú rekurziu  
        **end** ;

Ľavá faktorizácia:

schéma:

$$A \rightarrow \alpha\beta_1 \mid \alpha\beta_2 \quad (\alpha\text{-dlhšie lookahead})$$

$$A \rightarrow \alpha A'$$

$$A' \rightarrow \beta_1 \mid \beta_2$$

Algoritmus:

Vstup: Gramatika G

Výstup: Ekvivalentná ľavo faktorizovaná gramatika

Metóda:

Pre každý neterminál nájdí najdlhší prefix ( $\langle \rangle \epsilon$ ) pre aspoň dve alternatívy.

Všetky pravidlá tvaru  $A \rightarrow \alpha\beta_1 \mid \alpha\beta_2 \mid \dots \mid \alpha\beta_n \mid y$ , y reprezentuje alternatívy nezačínajúce  $\alpha$ ,

nahraď pravidlami  $A \rightarrow \alpha A' \mid y$

$$A' \rightarrow \beta_1 \mid \beta_2 \mid \dots \mid \beta_n$$

Aplikuj túto transformáciu pokiaľ žiadne dve alternatívy pre ten istý neterminál nemajú spoločný prefix.

Príklad:


$$\begin{array}{l} S \rightarrow iEtS \mid iEtSeS \mid a \\ E \rightarrow b \end{array} \quad \begin{array}{l} S \rightarrow iEtSS' \mid a \\ S' \rightarrow eS \mid \epsilon \\ E \rightarrow b \end{array}$$

## 4.2 Metódy zdola - nahor

Príklad:

- 1  $S \rightarrow aABe$
- 2  $A \rightarrow Abc$
- 3  $\rightarrow b$
- 4  $B \rightarrow d$

Vstup:




Najpravejšie odvodenie ( Rightmost derivation )

$$S \xrightarrow{1} aABe \xrightarrow{4} aAde \xrightarrow{2} aAbcde \xrightarrow{3} abcde$$

'a handle'  $\Rightarrow$  pravá strana pravidla, vyskytujúca sa v nejakom najpravejšom odvodení.

"handle pruning- redukcia rukovätí



**Príklad:**

- (1)  $E \rightarrow E + E$
- (2)  $E \rightarrow E * E$
- (3)  $E \rightarrow (E)$
- (4)  $E \rightarrow id$

Reťazec:  $id1 + id2 * id3$

Odvodením (rm)

124444

24144

Pravá vetná forma	handle	Redukčné pravidlo
$id1 + id2 * id3$	id1	$E \rightarrow id$
$E + id2 * id3$	id2	$E \rightarrow id$
$E + E * id3$	id3	$E \rightarrow id$
$E + E * E$	$E * E$	$E \rightarrow E * E$
$E + E$	$E + E$	$E \rightarrow E + E$
$E$		

Posunovo - redukčná schéma:

Shift - Reduce Parsing

Posunovo - redukčný stroj:

	Stack	Vstup
Začiatok:	\$	w\$
činnosť (action)		
Koniec:	\$ S	\$

- Actions:
- (1) shift: push input symbol onto stack  
advance input
  - (2) reduce: pop the handle  
push lefthand side of the rule
  - (3) accept
  - (4) error

**Príklad:**

Stack	Vstup	Činnosť
\$	id1 + id2 * id3 \$	shift
\$ id1	+ id2 * id3 \$	reduce $E \rightarrow id$
\$ E	+ id2 * id3 \$	shift
\$ E+	id2 * id3 \$	shift
\$ E+id2	* id3 \$	reduce $E \rightarrow id$
\$ E+E	*id3 \$	shift
\$ E+E*	id3 \$	shift
\$ E+E*id3	\$	reduce $E \rightarrow id$
\$ E+E*E	\$	reduce $E \rightarrow E*E$
\$ E+E	\$	reduce $E \rightarrow E+E$
\$ E	\$	accept

Handle sa vyskytuje vždy na vrchole zásobníka, nikdy vo vnútri.

Konflikty počas analýzy:

- shift / reduce : Nevie rozhodnúť, či r alebo s
- reduce/ reduce : Nevie rozhodnúť, ktoré pravidlo použiť.

Vie celý zásobník a nasledujúci vstupný symbol:

LR(1)                  LR(k)

**Príklad:**

$S \rightarrow iEtS \mid iEtSeS \mid a$

Stack	Vstup
\$... iEtS	e...\$

Na základe stacku nevieme rozlíšiť, či shift / reduce.  
Ak dáme prednosť shift, parser sa chová prirodzene.

### 4.3 Operátorovo precedenčné gramatiky

Okrem iného:

1. neobsahujú  $\epsilon$ -ové pravidlá
2. žiadna pravá strana neobsahuje dva po sebe idúce neterminály.

**Príklad:**

$E \rightarrow E + E \mid E - E \mid E * E \mid E / E \mid E \uparrow E \mid (E) \mid -E \mid id$

Precedencie medzi terminálnymi symbolmi (operátormi).

- < · ľavé ohraničenie handle
- ≐ vo vnútri toho istého handle
- > pravé ohraničenie handle

	+	-	*	/	↑	id	(	0	\$
+	·>	·>	<·	<·	<·	<·	<·	·>	·>
-	·>	·>	<·	<·	<·	<·	<·	·>	·>
/	·>	·>	·>	·>	<·	<·	<·	·>	·>
↑	·>	·>	·>	·>	<·	<·	<·	·>	·>
id	·>	·>	·>	·>	·>			·>	·>
(	<·	<·	<·	<·	<·	<·	<·	≐	
)	·>	·>	·>	·>	·>			·>	·>
\$	<·	<·	<·	<·	<·	<·	<·		

**Príklad:**

$\$ \langle \cdot \text{id} \cdot \rangle + \langle \cdot \text{id} \cdot \rangle * \langle \cdot \text{id} \cdot \rangle \$$

Scan:

1. LR  $\rightarrow \cdot \rangle$
2. RL  $\rightarrow \langle \cdot$
3.  $\langle \cdot \text{HANDLE} \cdot \rangle$  zahrňuje aj príbahlé neterminály  
 $\$ \langle \cdot + \langle \cdot * \cdot \rangle \$$

### Algoritmus precedenčnej analýzy

Input : Precedenčná tabuľka + w\$

Output: syntaktický strom (parse) alebo error

Metóda:

```

set ip na začiatok w$;
loop
  if top=$ and ip↑ = $ then EXIT
  else
  begin
    a := top; b := ip↑;
    if a < ·b or a ≐ b then
      push; advance(ip)
    else
      if a · >b then <reduce>
      repeat pop
      until top < ·symbol last popped
      else error
      fi
    fi
  end
fi
pool

```

Konštrukcia precedenčnej tabuľky na základe priority a asociativity operátorov.

1.  $O_1$  má väčšiu prioritu ako  $O_2$   
 $O_1 \cdot \rangle O_2$   
 $O_2 \langle \cdot O_1$   
**Príklad:**  $+ \langle \cdot *, * \cdot \rangle +$
2.  $O_1$  a  $O_2$  majú rovnakú prioritu ( $O_1$  je  $O_2$ )  
 $O_1 \cdot \rangle O_2$ ,  $O_2 \cdot \rangle O_1$  ak operátory sú ľavo asociatívne  
 $O_1 \langle \cdot O_2$ ,  $O_2 \langle \cdot O_1$  ak operátory sú pravo asociatívne



**Príklad:**  $+ \cdot > +, + \cdot > -, - \cdot > +, \uparrow < \cdot \uparrow$

3.  $O < \cdot \text{id}, \text{id} \cdot > O$        $O \cdot > , < \cdot O$   
 $O < \cdot (, ( < \cdot O$       pre každé  $O$   
 $O \cdot > ), ) \cdot > O$   
 $( \doteq )$        $\$ < \cdot ($        $\$ < \cdot \text{id}$   
 $( < \cdot ($        $\text{id} \cdot > \$$        $) \cdot > \$$   
 $( < \cdot \text{id}$        $\text{id} \cdot > )$        $) \cdot > )$

### Kompresia precedenčnej tabuľky – precedenčné funkcie

dvojica funkcií f,g.

$f(a) < f(b)$  ak  $a < \cdot b$

$f(a) = f(b)$  ak  $\doteq b$

$f(a) > f(b)$  ak  $a \cdot > b$

**Príklad:**

	+	-	*	/	↑	id	(	)	\$
f	2	2	4	4	4	0	6	6	0
g	1	1	3	3	5	5	0	5	0

Metóda:

- Vytvor symboly  $f_a$  a  $g_a$  pre všetky  $a \in T \cup \{ \$ \}$
- Zlučuj skupiny: Na počiatku je každý symbol jedna skupina.  
Ak  $a = b$  zluč skupinu  $f_a$  a  $g_b$ .
- Zo skupín urob uzly orientovaného grafu. Ak  $a < \cdot b \Rightarrow$  hrana  $(g_b) \rightarrow (f_a)$   
Ak  $a \cdot > b \Rightarrow$  hrana  $(f_a) \rightarrow (g_b)$ .
- Ak graf je cyklický precedenčné funkcie neexistujú.  
 $\left. \begin{matrix} f_a \\ g_a \end{matrix} \right\} =$  najdlhšia cesta začínajúca v danej skupine.

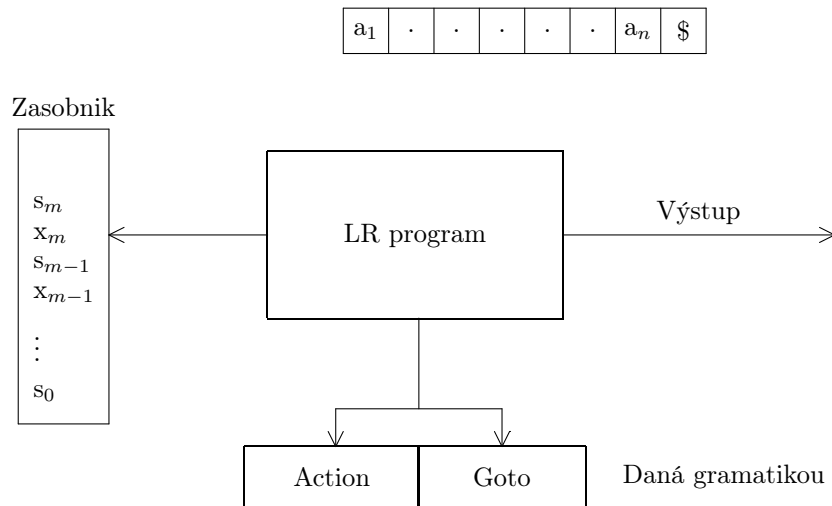
### Spracovanie chýb.

	id	(	)	\$
id	e3	e3	$\cdot >$	$\cdot >$
(	$< \cdot$	$< \cdot$	$\doteq$	e4
)	e3	e3	$\cdot >$	$\cdot >$
\$	$< \cdot$	$< \cdot$	e2	e1

- e1: D: Chýba celý operand (výraz).  
T: insert id into the input  
M: "missing operand"
- e2: D: Výraz začína pravou zátvorkou.  
T: delete ) from the input  
M: "missing left parenthesis"
- e3: D: Za výrazom nasleduje 'id' alebo '('  
T: insert + into the input  
M: "missing operator"
- e4: D: Výraz končí ľavou zátvorkou.  
T: pop ( from the stack  
M: "missing right parenthesis"

#### 4.4 LR(k) – metódy syntactickej analýzy

1. LR-analyzátoary rozpoznávajú všetky programovacie jazyky, pre ktoré vieme nájsť CF-gramatiku.
2. LR-metóda je najvšeobecnejšia metóda bez pokusov a omylov (backtracking).
3. Trieda gramatík analyzovateľná LR-analyzátoarmi je vlastnou nadmnožinou predikatívne (zhora-dolu) analyzovateľných gramatík.
4. LR-analyzátoar môže zistiť chyby najskôr ako je to možné pri prezeraní zľava doprava.



- actions: 1. shift  $s := \text{push}(\text{in}); \text{push}(s)$ ;  
 2. reduce  $:= \text{pop}(\text{right side } A \rightarrow \beta)$ ;  
 3. accept  
 4. error

#### Konfigurácia – okamžité opísanie

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

Konfigurácii zodpovedá pravá vetná forma, ktorú dostaneme vynechaním stavových symbolov.

1. action  $[s_m, a_i] = \text{shift } s$   
 $(s_0 X_1 s_1 X_2 s_2 \dots X_m s_m, a_i a_{i+1} \dots a_n \$)$   
 $(s_0 X_1 s_1 X_2 s_2 \dots X_m s_m a_i s, a_{i+1} \dots a_n \$)$
2. action  $[s_m, a_i] = \text{reduce } A \rightarrow \beta$ , where  $|\beta| = r$  and goto  $[s, A] = s$ .  
 $(s_0 X_1 s_1 X_2 s_2 \dots X_m s_m, a_i a_{i+1} \dots a_n \$)$   
 $(s_0 X_1 s_1 X_2 s_2 \dots X_{m-r} s_{m-r} A s, a_i a_{i+1} \dots a_n \$)$
3. action  $[s_1, \$] = \text{accept}$
4. action  $[s_m, a_i] = \text{error}$  vo všetkých ostatných prípadoch.

**Príklad:**

- (1)  $E \rightarrow E + T$
- (2)  $E \rightarrow T$
- (3)  $T \rightarrow T * F$
- (4)  $T \rightarrow F$
- (5)  $F \rightarrow (E)$
- (6)  $F \rightarrow \text{id}$

LR-analýza.

```

set ip to the first input symbol;
loop
  s:= top;
  a:= input(ip);
  case action[s,a].a of
    shift:
      begin
        push a
        push action[s,a].s
        next(ip)
      end ;
    reduce:
      begin
        <action[s,a].s =reduce( A → β)>
        for i := 2*|β|-1 downto 0 do pop;
          s:=top;
          push A;
          push goto[s,A];
          output(A → β)
        end
      accept: EXIT;
      error: CALL ERROR (s,a)
    esac
  pool ;

```

**Príklad:**

Zásobník	Vstup	Činnosť
0	id*id+id \$	shift 5
0 id 5	*id+id \$	reduce $F \rightarrow \text{id}$
0 F3	*id+id \$	reduce $T \rightarrow F$
0 T2	*id+id \$	shift 7
0 T2*7	id+id \$	shift 5
0 T2*7 id5	+id \$	reduce $F \rightarrow \text{id}$
0 T2*7 F10	+id \$	reduce $T \rightarrow T * F$
0 T2	+id \$	reduce $E \rightarrow T$
0 E1	+id \$	shift 6
0 E1+6	id \$	shift 5
0 E1+6 id5	\$	reduce $F \rightarrow \text{id}$
0 E1+6 F3	\$	reduce $T \rightarrow F$
0 E1+6 T9	\$	reduce $E \rightarrow E + T$
0 E1	\$	accept

Rôzne druhy LR-analýzy :

SLR  
LR  
LALR

Sa odlišujú len v rozsahu a spôsobe konštrukcie riadiacej tabuľky.

LR(0) – item

$A \rightarrow XYZ$	$A \rightarrow .XYZ$
	$A \rightarrow X.YZ$
	$A \rightarrow XY.Z$
	$A \rightarrow XYZ.$
$A \rightarrow \epsilon$	$A \rightarrow .$

item = < # rule, position >

I = set of items, označíme  $\bar{I}$  = closure (I)

1.  $\bar{I} \supseteq I$  t.j každý item z I patrí do closure(I).
2. **if**  $[A \rightarrow \alpha.B\beta] \in I$  and  $B \rightarrow \delta \in G$  **then**  $\bar{I} := \bar{I} + \{[B \rightarrow .\delta]\}$ ;  
Bod 2 sa opakuje kým sa niečo pridáva.

```
function closure(I)
begin
  repeat
    for each item  $[A \rightarrow \alpha.B\beta] \in I$  do
      for each production  $B \rightarrow \delta \in G$  do
         $J := J \cup \{[B \rightarrow .\delta]\}$ ;
    until no more items can be added to J;
end ;
```

**Príklad:**

$E' \rightarrow E$   
 $E \rightarrow E + T / T$   
 $T \rightarrow T * F / F$   
 $F \rightarrow (E) / id$

$I = \{ [E' \rightarrow .E] \}$   
 $J = \{ E' \rightarrow .E, E \rightarrow .E + T, E \rightarrow .T, T \rightarrow .T * F, T \rightarrow .T, F \rightarrow .(E), F \rightarrow .id \}$

Kernel items:  $S' \rightarrow .S$ , a tie, čo nemajú bodku na ľavom kraji.

Nonkernel items: Majú bodku na ľavom okraji.

Zaujímavé množiny: Uzáver kernel items.

Non kernel sa pridávajú operáciou uzáveru.

goto(I,X)

I - set of items

X - symbol gramatiky

**if**  $[A \rightarrow \alpha.X\beta] \in I$  **then**  $[A \rightarrow \alpha.X.\beta] \in \text{goto}(I, X)$ .


### Konštrukcia stavov

1. closure ( $S' \rightarrow \cdot S$ ) je stav
2. Pre každý stav I a pre každý symbol X ak  $\text{goto}(X, I)$  je neprázdne, tak  $\text{closure}(\text{goto}(X, I))$  je stav.

### Príklad:

$I_0:$	$E' \rightarrow \cdot E \$$	$I_1:$	$E' \rightarrow E \cdot \$$
	$E \rightarrow \cdot E + T$		$E \rightarrow E \cdot + T$
	$E \rightarrow \cdot T$		
	$T \rightarrow \cdot T * F$	$I_2:$	$E \rightarrow T \cdot$
	$T \rightarrow \cdot F$		$T \rightarrow T \cdot * F$
	$F \rightarrow \cdot (E)$		
	$F \rightarrow \cdot id$	$I_3:$	$T \rightarrow F \cdot$
$I_4:$	$F \rightarrow ( \cdot E )$	$I_5:$	$F \rightarrow id \cdot$
	$E \rightarrow \cdot E + T$		
	$E \rightarrow \cdot T$	$I_6:$	$E \rightarrow E + \cdot T$
	$T \rightarrow \cdot T * F$		$T \rightarrow \cdot T * F$
	$T \rightarrow \cdot F$		$T \rightarrow \cdot F$
	$F \rightarrow \cdot (E)$		$F \rightarrow \cdot (E)$
	$F \rightarrow \cdot id$		$F \rightarrow \cdot id$
$I_7:$	$T \rightarrow T \cdot * F$	$I_8:$	$F \rightarrow (E) \cdot$
	$F \rightarrow \cdot (E)$		$E \rightarrow E \cdot + T$
	$F \rightarrow \cdot id$		
$I_9:$	$E \rightarrow E + \cdot T$	$I_{10}:$	$T \rightarrow T * \cdot F$
	$T \rightarrow T \cdot * F$	$I_{11}:$	$T \rightarrow (E) \cdot$

Prechodový diagram LR(0) - automatu



### Konštrukcia SLR - tabuľky

1. Skonštruuj množinu stavov  
 $C = \{I_1, I_2, \dots, I_n\}$  LR(0) analyzátora  
stav  $i \quad I_i$
2. Akcie
  - (a) Ak  $A \rightarrow \alpha.a\beta \in I_i$  a  $\text{goto}(I_i, a) = I_j$ , potom  $\text{action}[i, a] = \text{shift } j$ ;
  - (b) Ak  $[A \rightarrow \alpha.] \in I_i$ , potom  $\text{action}[i, a] = \text{reduce } A \rightarrow \alpha.$  pre všetky  $a \in \text{FOLLOW}(A)$ .
  - (c) Ak  $[S' \rightarrow S.]$  je  $I_i$ , potom  $\text{action}[i, \$] = \text{accept}$ . Ak sú akcie v konflikte, gramatika nie je SLR.
3. goto tabuľka  
Pre každé  $i$  a každý neterminál  $A$  ak  $\text{goto}(I_i, A) = I_j$ , potom  $\text{goto}(i, A) = j$ .
4. Všetky ostatné položky sú chybové.
5. Stav obsahujúci  $S' \rightarrow .S$  je počiatočný stav.

### Konštrukcia kánonického LR(1) analyzátora.

LR(1) . item

<#rule, position, terminal>

```
function closure(I);
begin
  J := I;
  repeat
    for each item [A → α.Bβ, a] ∈ I do
      for each production B → γ do
        for each terminal b ∈ FIRST(βa) do
          J := J ∪ {[B → .γ, b]}
    until no more item can be added;
  end ;
end ;

function goto(I, X)
begin
  K := ∅;
  for each [A → α.Xβ, a] ∈ I do
    K := K ∪ {[A → αX.β, a]};
    K := closure(K)
  end ;

procedure states(G, C)
begin
  C := {closure({[S' → .S, $])}}
  repeat
    for each I ∈ C do
      for each X ∈ N do
        if goto(I, X) ≠ 0 then C := C ∪ {goto(I, X)}
    until no more sets can be added;
  end ;
```

## LALR(1) – metóda syntaktickej analýzy.

V predošlých vždy sme pracovali s LR(0) stavmi. V **SLR** analýze sme sa o lookahead veľmi nestarali. Iba v prípade, keď sme uvažovali o redukcii sme sa pre ňu rozhodli vždy keď lookahead patril do Follow(A), pre uvažované pravidlo  $A \rightarrow \gamma$ . To je príliš optimistické a nevyužíva všetku možnú informáciu. Kánonická LR(1) metóda pristupuje k problému opatrne a pre istotu všetky LR(0) stavy rozdelí na viac stavov podľa dovolených lookaheadov. To je bezpečné, ale vedie na veľké množstvo stavov. Navyše informácia o lookahead symboloch sa využíva iba pri rozhodovaní o redukcii.

Jadro stavov (kernel) je item  $[S' \rightarrow .S\$]$  a všetky itemy, v ktorých sa bodka nie je prvý symbol pravej strany.

Ľahká ale neefektívna (hlavne priestorovo) metóda konštrukcie LALR(1) syntaktického analyzátoru je vytvoriť LR(1) analyzátor a v tomto stotožniť stavy s rovnakým jadrom.



## 5 Kontrola typov

1. Operátor aplikovaný na nekompatibilné typy

f: function (a: integer, b: real): real

a: array [0..n] of char


⋮

...  $a + f$

2. Kontrola toku riadenia  
EXIT,GOTO,BREAK  
Chyba ak tieto príkazy nemajú definované ciele.
3. Jednoznačnosť deklarácií a definícií.
4. Kontrola opakovaných mien.

**Príklad:**


```
LTEX begin {enumerate}
      end {enumerate}
procedure ADA loop (a)
      end (a);
```



**System typov:**

1. Základné typy: obvykle: char,integer,real,boolean. potrebujeme: void (žiadna hodnota) error (chybný typ).
2. Zložené typy (type constructors)
  - (a) Arrays
  - (b) (i) Products T1 z T2  
(ii) Records položky kartézského súčinu majú mená.
  - (c) Smerníky (,ref)
  - (d) Funkcie  
Pr. char x char  $\rightarrow$  ref(integer)  
Pr. (integer  $\rightarrow$  integer)  $\rightarrow$  (integer  $\rightarrow$  integer)

Znázornenie



## Type system (systém typov)

**Definícia 5.1** *Množina pravidiel priradujúca typ rozličným častiam jazyka (programu).*

Type checker je implementácia systému typov.  
Pre ten istý jazyk môžeme mať rôzne systémy typov.

### Príklad:

Rôzne kompilátory.  
C-kompilátor  
lint (UNIX)

Statická kontrola.  
Dynamická kontrola.  
Recovery (zotavenie).  
Každá kontrola sa dá urobiť dynamická.  
Niektoré kontroly sa nedajú robiť staticky.

### Príklad:

```
table: array [0..255] of char
i: integer          (i: 0..255)
i:=i+1;
:                  table[i]
```

Jednoduchý jazyk:

```
P → D;E
D → D;D | id:T
T → char | integer | array[num] of T | T
E → literal | num | id | E mod E | E[E] | E
```

### Syntaxou riadený preklad pre uchovanie typov.

```
P → D;E
D → D;D
D → id:T          {addtype (id.entry,T.type)}
T → char          {T.type := char}
T → integer       {T.type := integer}
T → T1           {T.type := pointer_to (T1 .type)}
T → array[num] of T1 {T.type := array (0..num.val,T1 .type)}
```

### Kontrola výrazov

```
E → literal      {E.type := char}
E → num          {E.type := integer}
E → id           {E.type := lookup (id.entry)}
E → E1 mod E2   {E.type := if E1.type = integer} and E2.type = integer then integer else error}
E → E1[E2]     {E.type:= if E2.type=integer and E1.type=array(s,t) then t else error;}
E → E1         {E.type := if E1.type=pointer_to(t) then t else error;}
```

Cvičenie: Zaveďte do jazyka typ boolean porovnanie a and operátor!

## Kontrola typu výrazov.

```
S → id := E      {S.type := if id.type = E.type then void else error}
S → if E then S1 {S.type := if E.type = boolean then S1.type else error}
S → while E do S1 {S.type := if E.type = boolean then S1.type else error}
S → S1;S2      {S.type := if (S1.type = void) and (S2.type = void) then void else error}
```

## Kontrola typov funkcií.

Definícia typu:

```
T ⇒ T1 → T2      {T.type := T1.type → T2.type}
function f(id:T1):T2;
```

Aplikácia funkcie.

```
E → E1(E2)      {E.type := if E2.type = s and E1.type = s → t then t else error.}
```

Viac argumentov (product type)

```
T → T1 z T2 → T3
T1 → T2          predošlý prípad.
```

Zovšeobecnenie (funkcia argumentom).

```
root: (real → real) z real → real
function root (function f(real): real, x: real) : real;
```

## Ekvivalencia typov.

štruktúrálna ekvivalencia:

Výrazy sú toho istého základného typu, alebo sú vytvorené tými istými konštruktormi z ekvivalentných typov.

```
function sequiv (s,t) : boolean;
begin
  if s and t are the same basic types then
    sequiv:= true
  else if (s = array(s1, s2) and t = array (t1, t2)) or
    (s = s1 .. s2 and t = t1 .. t2) or
    (s = s1 → s2 and t = t1 → t2) then
    sequiv(s1, t1);
    sequiv(s2, t2);
  else if s = pointer_to (s1) and t = pointer_to (t1) then
    sequiv (s1, t1)
  else sequiv = false
end
```

Urýchlenie: Kódovanie typov pomocou bitových postupností.

## 5.1 Polymorfické funkcie a operácie

Príklad:

Pascal:

```
type
  link = cell;
  cell = record
    into: integer;
    next: link
  end ;
function lenght(lptr:link): integer
var len: integer;
begin
  len:=0;
  while lptr <> nil do
  begin
    len:= len+1;
    lptr:= lptrnext
  end ;
  lenght:= len
end ;
```

ML:

```
fun lenght(lptr)= If null(lptr) Then 0 Else lenght(tl(lptr))+1;
```

Pascal:

```
Type = pointer_to type
```

```
pointer_to type = type
```

C:

```
type = pointer_to type
```

Dátové typy

stack (zásobník)

queue (fronta)

priority queue (prioritná fronta)

set (množina)

Typové premenné:  $\alpha, \beta, \dots$

**Príklad:**

```
type link = cell;
procedure mlist(lptr:link; procedure p);
begin
  while lptr <> nil do
    begin
      p(lptra);
      lptr:= lptr.next
    end
  end ;
type of p = link → void
```

```
function ref(xα): pointer(α);
begin
  ref:= x;
end ;
```


```
function deref(p: pointer(β)): β;
begin
  deref:= p;
end ;
```

ref:  $\alpha. \alpha \rightarrow \text{pointer}(\alpha)$   
deref:  $\beta. \text{pointer}(\beta) \rightarrow \beta$

**Gramatika pre kontrolu polymorfických typov.**

$P \rightarrow D;E$   
 $D \rightarrow D;D \mid \text{id}:Q$   
 $Q \rightarrow \forall \text{type\_variable}.Q \mid T.$   
 $T \rightarrow T' \rightarrow T \mid T..T \mid \text{unary constructor}(T) \mid \text{basic-type} \mid \text{type-variable} \mid (T)$   
 $E \rightarrow E(E) \mid E,E \mid \text{id}$

**Príklad:** deref:  $\text{pointer}(\alpha) \rightarrow \alpha$ ;  
q:  $\text{pointer}(\text{pointer}(\text{integer}))$ ;  
deref(deref(q))



1. Rôzne výskyty tej istej polymorfickej funkcie vo výraze nemusia mať argumenty rovnakého typu
2. Premenné menia pojem ekvivalencie (kompatibility) typov. Namiesto zistenia ekvivalencie musíme dva typy unifikovať".
3. Pretože tá istá premenná sa môže vyskytnúť viac krát, treba výsledky unifikácie zaznamenávať.

Term-algebra, čiastočné usporiadanie na term-algebrách, substitúcie, inštancie a unifikácia.

Term-algebra: premenné  
konštanty  
funkčné symboly arita  
výrazy: premenná/konštantá  
Ak  $t_0, \dots, t_{n-1}$  sú výrazy a  $f$  je funkčný symbol arity  $n$ ,  
potom  $f(t_0, t_1, \dots, t_{n-1})$  je výraz.  
Neexistujú iné výrazy.

Čiastočné usporiadanie na množine termov je definované:

1. Pre každý term  $t$  a každú premennú  $x \sqsubseteq t$
2. Ak  $t = ft_1 \dots t_n$  a  $s = gs_1 \dots s_n$ , potom  $t \sqsubseteq s$  práve vtedy, ak
  - (a)  $f = g \implies m = n$
  - (b)  $\forall i \leq n \ t_i \sqsubseteq s_i$

**Príklad:**

$pointer(\alpha) \ pointer(integer)$   
 $pointer(real)$   
 $\alpha pointer(\beta)$   
 $\alpha \times \beta \ \alpha \rightarrow \alpha(integer \rightarrow integer)$

Neporovnateľné dvojice

$integerreal$   
 $integer \rightarrow real \ \alpha \rightarrow \alpha$   
 $integer \rightarrow \alpha \ \alpha \rightarrow integer$   
substitúcia -  $\{\alpha_i \rightarrow t_i\}_{i < n}$

## 6 Podpora počas behu – runtime support

### 6.1 Odovzdávanie parametrov

call by value  
reference  
name  
copy - restore (copy in - copy out)

**Príklad:**

```
program main;
var a, b: integer;
procedure swap( var x, y: integer );
  var temp: integer;
  begin
    temp:= x;
    x:= y;
    y:= temp;
  end ;
  begin
    a:= 1;
    b:= 2;
    swap(a, b);
    writeln('a= ', a, 'b= ', b);
  end ;
  swap(i, a[ i ])
end .
```

**Príklad:**

```
real function f( x )
real x;
begin
  :
  :
  :
  f :=
  x := x + h
end ;

real function SUM( a, n )
value n;
real a;
integer n;
begin
  integer i;
  real a;
  s := 0;
  for i := 0 step 1 to n do s := s + a
end ;
```

```

void function swap ( x, y )
    int *x, *y;
    { int temp;
      temp := *x ;
      *x := *y ;
      *y := temp }

program main()
{ int a=1 ; b=2 ;
  swap ( &a , &b )
  printf( "ä is now % d, b is now % d\ n", a, b); }

```

```

program copy-out;
var a: integer;
procedure unsafe ( var x: integer )
begin
    x := 2;
    a := 0;
end ;
begin
    a := 1;
    unsafe( a );
    writeln( a );
end .

```

Realizácia

#### by - value

1. Vypočíta sa hodnota.
2. Hodnota sa pošle volanej procedúre.
3. Volaná procedúra vztvorí novú, lokálnu premennú s touto hodnotou.

#### by - reference

Posiela sa smerník. Ak skutočný parameter nie je smerník,  $(a + b, 2)$  sa vyhodnotí, uloží sa a pošle sa smerník na toto miesto.

#### by - name

Aktuálny parameter sa skompiluje ako funkcia bez parametrov, ktorá ho počíta a odovzdá sa smerník na jej volanie.



## 6.2 Tabuľka symbolov

**Hashing.** Hash functions:

$$s = c_1 \dots c_h \qquad \text{Ord}(c) \qquad h = \#s \bmod p$$

Iteratívne:

$$h_0 = 0 \qquad \alpha = 65599 \text{ ( 32 bit )} \qquad h_i = \alpha h_{i-1} + c_i \qquad \alpha = 16$$

```
function hashpjw (s: string): int; // Weinberger's C
var h, g, k: int; p:= prime;
begin
  h:= 0;
  k:= Lenght(s);
  for i:= 1 to k do
    begin
      h:= 16*h + s[i];
      if h > 228 then
        begin
          g:= h div 224; // v C a assembleri „shift“
          h:= h $\oplus$ 0xf0000000 $\oplus$  g ; {(  $\oplus$  = EOR )}
        end ;
      end ;
    end ;
  hash := h mod p
end .
```

Zdá sa to zbytočne komplikované. Jednoduchá aritmetická funkcia poslúži rovnako.

```
function hashjs (s: string): int;
var h, k:int; p:= prime;
begin
  h:= 0;
  k:= Lenght(s);
  for i:= 1 to k do
    begin
      h:= 17*h + s[i];
      if h > p then h:= h mod p;
    end ;
  end .
```

**Riešenie kolízií :**

1. separate chaining

2. open addressing       $\alpha < 1$   
                              $h_i := h_{i-1} + h'$

Pre kompilátory je vhodnejšie otvorené adresovanie. S ohľadom na jednoduchosť stačí na rehašovanie použiť konštantu  $h'$  nesúdeliteľnú s veľkosťou tabuľky  $m$ .

```
program dynamic_memory;
```

```
  type link = cell;  
  cell = record key, info : integer  
            next : link
```

```
end ;  
var head : link;
```

```
procedure insert( k, i : integer );
```

```
var p: link;
```

```
begin
```

```
  new(p);  
  p.key := k;  
  p.info:= i;  
  p.next:= head;  
  head := p;
```

```
end ;
```

```
begin
```

```
  head := nil;  
  insert ( 7 , 1);  
  insert ( 4 , 2);  
  insert ( 76, 3);  
  dispose( headnext );
```

```
end .
```

## 7 Optimalizačný kompilátor

Zdá sa, že efekt transformácií na najvyššej úrovni je najvýraznejší

Príklad: pre  $N = 1024$  Insert sort  $2.02N^2 = 2.02M$   
Quick sort  $12N \lg N = 120K$

Príklad:

```
void function quicksort (m,n) < int m,n;
{ int i,j;
  int v,x;
  if (n<=m) return
  /* začiatok fragmentu */
  i:=m-1; j:=n; v:=a[n];
  while (1) {
    do i:=i+1 while (a[i]<v);
    do j:=j-1 while (a[j]>v);
    if (i==j) break ;
    x:=a[i];a[i]:=a[j];a[j]:=x;}
  x:=a[i];a[i]:=a[n];a[n]:=x;
  /* koniec fragmentu */
  quicksort(m,j);quicksort(i+1,n)
}
```

Fragment programu v 3-adresovom kóde.

Vyňatie spoločných operácií pred cyklus a náhrada drahších operácií lacnejšími

```
Pr.   j:= j-1      t:= 4*j
      t:= 4*j      t:= t-4
```

Eliminácia zbytočných výpočtov a spoločných podvýrazov bloku B5.

```
B5:  t6:= 4*i      - t4 v B2
      x:= a[t6]    - vypočítané ako t v bloku B2
      t7:= 4*i
      t8:= 4*j      - t5 v B3
      t9:= a[t8]
      a[t7]:= t9   - t5 v B3
      t10 := 4*j
      a[t10]:= x
      goto B2
```

Optimalizovaný blok B5

```
B5:  x:= t3
      a[t7]:= t5
      a[t4]:= x
      goto B2
```

Analogicky sa optimalizuje blok B6.

Blokový diagram (graf toku riadenia)

B4: if  $i < j$  goto B6

Alternatívy:

1. Absolutný kód.
2. BRC- binárny relokatívny kód.
3. Assembler.

Riadenie pamäti:

štvorica + count (ofset kde začína kód)

**Preklad inštrukcii:**

Priamočiary spôsob (jednoadresný)

a:= b+c	MOV b,R0	
d:= a+e	MOV c,R0	
	MOV R0,a ?	
	MOV a,R0 -	
	ADD e,R0	
	MOV R0,d	
a:=a+1	MOV a,R0	INC a
	ADD \#1,R0	
	MOV R0,a	pamäťové cykly

Použitie registrov:

1. Výber premenných, ktoré sa budú vyskytovať v danom bode vykonávania programu v registroch.
2. Postupné vymieňanie hodnôt v registroch počas vykonávania programu.

Registre dvojnej dĺžky ( dva po sebe idúce registre )

Cena inštrukcie:

- |                |                                   |
|----------------|-----------------------------------|
|                | 1. načítanie a dekodovanie        |
|                | 2. možno adresa v ďalšom slove    |
|                | 3. operand                        |
| dodatočná cena | 4. zložité inštrukcie ( MULT,DIV) |
|                | 5. úroveň nepriamej adresy        |

overlay inštrukčný (pamäťových cyklov).

Volanie rekurzívneho podprogramu.

r:	MOV	r+a, called return address
	JUMP	called code begin
	.	
	.	
n-1	.	activation record
	.	

## Dynamické podprogramy – stack

inicializácia zásobníka:

volanie:

```
ADD \# caller.recordsize ,SP
MOV r+a,*SP
JUMP called code begin
```

called:

```
.
.
.
JUMP *0(SP) {return, double indirection}
```

JE TO ASI ZBYTOČNÁ OZDOBA

## Intervaly – basic blocks

```
t1=a*a
t2=a*b
t3=2*t2
t4=t1+t3
t5=b*b
t6=t4+t5
```

Algoritmus rozdelenia na základné bloky:

Vstup: Program (postupnosť štvoríc)

Výstup: Základné bloky a graf toku riadenia.

Metóda:

Určenie hlavičiek intervalov.

1. Prvý príkaz je hlavička
2. Každý cieľ skoku je hlavička
3. Každý príkaz bezprostredne nasledujúci za skokovým príkazom je hlavička.

Interval = hlavička + postupnosť príkazov bezprostredne nasledujúcich po nasledujúcu hlavičku.

Graf toku riadenia:

Uzly - Intervaly

Hrany- skoky

bezprostredná následnosť za podmieneným skokom.

## 7.1 Transformácie zachovávajúce štruktúru

1. Eliminácia spoločných podvýrazov
2. Eliminácia "mŕtveho bodu"
3. Premenovanie dočasných premenných
4. Výmena dvoch susedných príkazov
5. algebraické transformácie

### Použitie premenných

```
i: x:= y op z      j používa x
.                  ak existuje cesta z i do j,
.                  po ktorej sa hodnota
.                  x nemení
j:      := x
```

Použitie premenných - "mŕtve" a "aktívne" premenné sa dajú zistiť spätným prezeraním grafu toku riadenia.

1. register descriptor : čo je v danom momente v každom registri
2. address descriptor: kde sa nachádzajú hodnoty premenných v danom okamihu.
3. getreg: funkcia, ktorá pri prekalde príkazu `x:= y op z` vráti register pre `x`.

### Stratégia pre getreg

1. Ak register pre `y` (`z`) nenesie inú hodnotu a `y` (`z`) je mŕtva premenná vráti tento register.
2. Ak 1. neuspeje vráti voľný (prázdny) register.
3. Ak nie je žiaden register voľný a `x` má nasledujúce použité v tom istom bloku alebo `x` je použitý ako index vráti obsadený register `R` generuj inštrukciu: `STORE R,M` Dobrá stratégia je uvoľniť ten register, čo sa bude používať najneskoršie.
4. Ak sa `x` nepoužíva v danom bloku, alebo sa nedá nájsť vhodný register nájde sa miesto v pamäti.

Pr.

Príkaz	code	Register descr.	Address descr.
t:=a-b	MOV a,R0 SUB b,R0	R0 obsahuje t	t in R0
u:=a-c	MOV a,R0 SUB c,R1	R0 obsahuje t R1 obsahuje u	t in R0 u in R1
v:=t+u	ADD R1,R0	R0 obsahuje v R1 obsahuje u	v in R0 u in R1
d:=v+u	ADD R1,R0 MOV R0,d	R0 obsahuje d	d in R0

### Priradenie registrov farbením grafu.

1. Predpokladáme neobmedzený počet registrov
2. register inference graph  
uzly - registre  
hrany  $a \rightarrow b$ , keď premenná `a` je živá, kde premenná `b` je definovaná.
3. k-registrov: Či graf RIG sa dá zafarbiť k-farbami ( NP- úplný problém )

Heuristika: Odstraňovanie vrcholov stupňa menšieho než `k`.

1. Úspech graf sa postupne redukuje na prázdny
2. Nedá sa použiť, zapamätáme nejaký register.

Dag intervalu:

Pr.

```
1: t1:=4*i
2: t2:=a[t1]
3: t3:=4*i
4: t4:=b[t3]
```

Def: Uzol  $d$  dominuje uzol  $n$ , ak každá cesta z počiatku  $o$  do uzla  $n$  vedie cez  $d$ .

Algoritmus pre výpočet relácie dominance  $D$ .

Vstup: graf  $G = \langle N, E \rangle$ , počiatok  $o$

Výstup: relácia  $D$ .

Metóda:

```
for each  $n \in N$  do  $D(n) := \{n\}$ ; // inicializácia
while changes to any  $D(n)$  occur do
  for each  $n \in N - \{o\}$  do
     $D(n) := D(n) \cup \{D(p) : hrana p \rightarrow n \in E\}$ 
```

Prirodzené cykly:

1. cyklus má jediný vstupný bod -- hlavičku, ktorá dominuje všetky uzly cyklu
2. z každého uzlu cyklu existuje aspoň jedna cesta späť k hlavičke.

DP: Prirodzený cyklus prislúchajúci spätnej hrane  $n \rightarrow d$ . Je cyklus s hlavičkou  $d$  obsahujúci všetky uzly z ktorých existuje cesta do uzla  $n$  neprechádzajúca cez hlavičku  $d$ .

Algoritmus konštrukcie prirodzeného cyklu k spätnej hrane  $n \rightarrow d$

Vstup: graf  $G$  a spätná hrana  $n \rightarrow d$

Výstup: všetky uzly prirodzeného cyklu k  $n \rightarrow d$ .

Metóda:

```
PROGRAM
  PROCEDURE insert( $m$ );
    IF  $m \neq d$  and  $m \notin loop$  THEN
      BEGIN  $loop := loop \cup \{m\}$ ;
            push  $m$  onto stack
      END;
  BEGIN
     $stack := empty$ ;
     $loop := \{d\}$ ;
    insert( $n$ );
    WHILE  $stack$  is not empty DO
      BEGIN  $m := top(stack)$ ;
            pop( $stack$ );
            FOR each predecessor  $p$  of  $m$  DO
              IF  $d$  dominates  $p$  THEN insert( $p$ )
            END
      END
  END.
```

Transformácia dvoch cyklov so spoločnou hlavičkou na jeden cyklus:

Def: Graf  $G$  sa nazýva redukovateľný, ak:

1. Dopredné hrany tvoria acyklický graf, v ktorom každý uzol je dosiahnuteľný z počiatku.
2. Spätné hrany sú také, že výstupný uzol dominuje vstupný uzol.
3. Iné hrany graf neobsahuje.

## 7.2 Intervalová analýza

Def: Interval  $I(n)$  s hlavičkou  $n$  je množina uzlov taká, že:

1.  $n \in I(n)$ .
2. Ak pre nejaký uzol  $m$  všetci predchodcovia patria do  $I(n)$ , potom aj  $m$  patrí do  $I(n)$ .
3. Žiadny iný uzol nepatrí do  $I(n)$ .

Algoritmus intervalovej analýzy - rozdelenie grafu na disjunktné intervaly.

Vstup: graf  $G = \langle N, E \rangle$ ,  $n_0 \in N$  počiatkový uzol

Výstup: rozdelenie grafu na disjunktné intervaly.

Metóda:

```
PROGRAM;
  FUNCTION  $I(n)$ ;
    BEGIN  $S := \{n\}$ ;
      WHILE (existuje  $m \neq n_0$ )(pre všetky  $p$ ) také, že  $(p \rightarrow m \in E)$  and  $p \in S$ 
        DO  $S := S \cup \{m\}$ ;
       $I(n) := S$ 
    END;
  BEGIN  $I(n_0)$ ;
    WHILE exists  $m$  not yet selected but with a selected predecessor
      DO  $I(m)$ 
  END.
```

Def: Intervalový graf.

1. uzly sú intervaly rozdelenia
2. počiatkový uzol  $I(n_0)$
3. hrana  $I \rightarrow J$  práve vtedy, ak existuje hrana  $m \rightarrow n \in E$  v pôvodnom grafe a  $m \in I$  a  $n \in J$ .

iterovaná intervalová analýza, limitný graf.

### T1 – T2 analýza

T1: Ak  $n$  je uzol so slučkou ( t.j. hrana  $n \rightarrow n$  ), vynechaj slučku.

T2: Ak uzol  $n$  má jediného predchodcu, uzol  $m$ . Vynechaj uzol  $n$  a urob všetkých následníkov uzlu  $n$  následníkmi uzlu  $m$ .

**VETA 1:** Limitný graf z T1 -T2 analýzy a z iterovanej intervalovej analýzy je ten istý graf.



**VETA 2:** Ak graf je redukovateľný, limitný graf je jeden uzol.

**Iteratívny algoritmus:**

```
 $in[B] := \bigcup_{p \prec B} out[P]$   
 $out[B] = gen[B] \cup (in[B] - kill[B]).$   
for each block  $B$  do  $out[B] := gen[B];$  { inicializácia }  
 $change := true;$   
while  $change$  do  
  begin  $change := false;$   
    for each block  $B$  do  
      begin  $in[B] := \bigcup_{p \prec B} out[P];$   
         $change := true$   
      end  
    end  
  end
```