


# Programovací jazyky a překladače

## Úvod do překladačů

Ing. Marek Běhálek  
Katedra informatiky FEI VŠB-TUO

A-1018 / 597 324 251

<http://www.cs.vsb.cz/behalek>  
[marek.behalek@vsb.cz](mailto:marek.behalek@vsb.cz)



Materiály vycházejí z původních prezentací  
doc. Ing. Miroslava Beneše Ph.D.



# Osnova přednášek

- Úvod - Obecné vlastnosti překladačů
- Lexikální analýza
- Syntaktická analýza
- LL(1) gramatiky
- Syntaxí řízený překlad
- JavaCC
- Tabulka symbolů
- Struktura programu v době běhu
- Vnitřní reprezentace
- Optimalizace
- Generování cílového kódu



# Úvod - Úloha překladače (1)

- **Překlad jednoho jazyka na druhý**
  - Co je to jazyk?
    - Přirozený jazyk – složitá, nejednoznačná pravidla
    - Formální jazyk - popsán *gramatikou*
  - Co je to překlad?
    - Zobrazení  $T : L_1 \rightarrow L_2$
    - $L_1$ : zdrojový jazyk (např. C++)
    - $L_2$ : cílový jazyk (např. strojový kód P4)



# Úvod - Úloha překladače (2)

- **Vyhledání chyb ve zdrojovém textu**
  - Snažíme se co nejvíce chyb objevit v době překladu
  - Zotavení po chybě – překladač je schopen pokračovat v činnosti a najít další chyby
  - Oprava chyb – náročné, nepoužívá se
- **Vytvoření informací pro ladění programu**
  - Jména proměnných a funkcí
  - Odkazy do zdrojového textu




# Úvod - Zdrojový jazyk

- **Přirozený jazyk**

- Předmět zájmu (počítačové) lingvistiky

- **Programovací jazyk**

- C, C++, Java, C#, Prolog, Haskell



- **Speciální jazyk**

- Jazyky pro popis VLSI prvků (VHDL)
- Jazyky pro popis dokumentů (LaTeX, HTML, XML, RTF)
- Jazyky pro popis grafických objektů (PostScript)



# Úvod - Cílový jazyk

- **Strojový jazyk**
  - Absolutní binární kód
  - Přemístitelný binární kód (.obj, .o)
  - Jazyk symbolických instrukcí
  - Vyšší programovací jazyk (např. C)
- **Jazyk virtuálního procesoru**
  - Java Virtual Machine
  - MSIL pro .NET

# Úvod - Využití technologie překladačů



## Klasické překladače

- základní součást vývojových nástrojů v operačním systému
- křížové překladače (*cross compilers*) - vývoj programů pro vestavné systémy apod.


## Specializované překladače


- systémy pro formátování textů (nroff, troff, LaTeX)
- silikonové překladače - popis a vytváření struktury VLSI obvodů
- příkazové interpretory v operačním systému (shell)
- databázové systémy – dotazy, SQL
- reprezentace grafických objektů - jazyk PostScript
- skriptovací jazyky – možnost rozšíření určitého systému uživatelem



# Úvod - Typy překladačů (1)


## Kompilační překladač





# Úvod - Typy překladačů (2)

## Interpretační překladač





# Úvod - Typy překladačů (3)

## Rozdíly mezi kompilátorem a interpretem

- Interpret je mnohem pomalejší než kompilátor
  - Je potřeba analyzovat zdrojový příkaz pokaždé, když na něj program narazí.
  - Interpret je 10 x až 100 x pomalejší.
- Interpret má ale i výhody.
  - Nezávislost na platformě.
  - Snadnější ladění – v době chyby máme k dispozici všechny informace.
  - Možnost měnit program za běhu - Smalltalk.



# Úvod - Typy překladače (4)

- Inkrementální překlad
  - Umožňuje po drobné opravě přeložit jen změněnou část
  - Možnost provádění drobných změn během ladění programu
- Just-in-time překlad
  - Generování instrukcí virtuálního procesoru (Java VM - .class, .NET CLR – jazyk IL)
  - Překlad až v okamžiku volání podprogramu
  - Optimalizace podle konkrétního procesoru



# Úvod - Typy překladače (5)

- Zpětný překladač
  - Umožňuje získat zdrojový program z cílového (např. z .exe, .class)
    - disassembler (např. ILDASM v prostředí .NET)
    - decompiler (např. DJ Java Decompiler)
  - V některých státech (USA) není dovoleno (u nás **ano** – viz § 66 autorského zákona)
  - *Obfuscation* („zmatení“, také „duševní pomatenost“ – viz <http://slovniky.seznam.cz/>)
  - Transformace cílového programu komplikující zpětný překlad



# Úvod - Historie

- Základní principy překladačů už jsou přes 30 let stále stejné a tvoří součást jádra informatiky
- I nejstarší programovací jazyky jsou stále živé – tradice, investice, vývoj
- Z historie se můžeme poučit – inspirace, ověřené principy i chyby



# Úvod - Modely zdrojového programu

- ***Vstup: Zdrojový program***

- `position := startPoint + speed * 60;`


- ***Lexikální analýza***

- `<ID,position> <:=,> <ID,startPoint> <+,>`  
`<ID,speed> <*,> <INT,60>`



# Úvod - Modely zdrojového programu


- *Syntaktická analýza*





# Úvod - Modely zdrojového programu

- **Kontextová analýza**





# Úvod - Modely zdrojového programu

- ***Generování mezikódu***

```
temp1 := inttoreal(60)
temp2 := speed * temp1
temp3 := startPoint + temp2
position := temp3
```

- ***Optimalizace***

```
temp1 := speed * 60.0
position := startPoint + temp1
```



# Úvod - Modely zdrojového programu

- *Generování cílového programu*

```
fld  qword ptr [_speed]
fmul dword ptr [00B2]           ; 60 . 0
fadd qword ptr [_startPoint]
fstp qword ptr [_position]
```



# Úvod - Organizace překladu

## • FÁZE


- Logická dekompozice (lexik., synt. analýza, ...)

## • PRŮCHOD

- Čtení vstupního souboru, zpracování, zápis výstupního souboru
- Může zahrnovat více fází
- Může být částí jedné fáze (např. optimalizace)



# Úvod - Struktura překladače





# Úvod - Vliv na strukturu překladače

- Vlastnosti zdrojového a cílového jazyka
- Paměť dostupná pro překlad
- Rychlosť / velikosť překladače
- Rychlosť / velikosť cílového programu
- Požadavky na ladění
- Detekce chyb
- Zotavení
- Velikosť projektu – velikosť týmu, termíny

# Úvod - Jednoprůchodový překlad




- Všechny fáze probíhají v rámci jediného čtení zdrojového textu programu
- Omezená možnost kontextových kontrol
- Omezená možnost optimalizace
- Lepší možnost zpracování chyb a ladění
- **Využití:**  
Výuka – rychlý překlad (program častěji překládáme než spouštíme)

# Úvod - Optimalizující překladače



- Více průchodů
- Často několik optimalizačních průchodů
- Možnost ovlivnění rozsahu prováděných optimalizací programátorem
- **Paralelizující překladače**
  - rozklad na úseky s možností paralelního provádění

# Úvod - Další pomocné programy




# Úvod - Další pomocné programy



- Editory
- Ladění - td, codeview, sdb, gdb
- Analýza obrazu paměti (post mortem dump)
- Reverzní překladače
- Automatické formátování textu
- Prohlížeče programu
- Profilování programu
- Správa verzí (CVS)
- Správa projektů (make, ant)
- Testování (junit)
- Správa knihoven
- Integrovaná vývojová prostředí - IDE (Delphi, MS Visual Studio, Eclipse, NetBeans, KDeveloper, ...)

# Úvod - Testování a údržba překladače




- Překladač **musí** vytvářet *korektní* (?) výstup
- **Formální specifikace** (?) Ada, M-2 ISO
  - -> Generátory testů
  - -> Automatické testování
- **Systematické testování**
- **Testování zátěže**
- **Údržba:** hlavně změny ve specifikaci jazyka  
styl programování, dokumentace


# Úvod - Implementace překladače



- **Retargetting – přenos na jinou cílovou platformu**
  - Strojově nezávislý mezikód
  - Interpretační překladače
- **Přizpůsobení existujícího překladače**
  - Podobné jazyky
- **Využití generátorů překladačů**
- **Zřídka se implementuje zcela od začátku**



# Lexikální analýza - Rozhraní lexikálního analyzátoru





# Lexikální analýza - Úkoly

- Čtení zdrojového textu
- Sestavování symbolů
- Odstranění mezer a poznámek
- Normalizace symbolů (velká/malá písmena, spec. znaky, ...)
- Interpretace direktiv překladače
- Uchovávání informací pro hlášení chyb
- Zobrazení protokolu o překladu



# Lexikální analýza - Proč řešit lexikální analýzu samostatně?

- Jednodušší návrh překladače
  - Konvence pro mezery a poznámky
- Vyšší efektivita
  - Specializované algoritmy
- Lepší přenositelnost
  - Zvláštnosti vstupní abecedy ??( = [

# Lexikální analýza - Základní pojmy



- **Lexém** – slovo nad abecedou
- **Kategorie symbolů** – identifikátor, číslo, relační operátor, levá závorka, ...
- **Atributy symbolu** – řetězec, hodnota, kód operátoru, ...
- **Reprezentace symbolu** – dvojice (*kategorie, atribut*)



# Lexikální analýza - Příklady lexikálních symbolů

<b>Symbol</b>	<b>Lexém</b>	<b>Vzor</b>
<b>const</b>	const	const
<b>relation</b>	<, <=, ..., >=	<>
<b>id</b>	{ltr}({ltr} {dig})*	pi, D2
<b>num</b>	{dig}+	0, 123



# Lexikální analýza - Reprezentace symbolů

```
// kategorie symbolů
enum Symbol { IdSym, NumSym, RelOpSym, DotSym, ... };

// kategorie operátorů
enum Oper { LthOp, GthOp, LeqOp, ... };

// atributy symbolů
union LexAttr {
    char* id;
    int num;
    Oper relop;
    ...
};

// reprezentace lexikálního symbolu
struct Token {
    Symbol sym; // kategorie
    LexAttr attr; // atribut
};
```

# Lexikální analýza - Specifikace symbolů (1)




- **Popis běžným jazykem**
  - Identifikátor je posloupnost písmen a číslic začínající písmenem 'p'
- **Regulární (lineární) gramatika**
  - $I \rightarrow p X$
  - $X \rightarrow p X \mid c X \mid p \mid c$
- **Regulární výrazy a definice**
  - $p (p \mid c)^*$
  - Nejjednodušší a nejčastěji používané



# Lexikální analýza - Specifikace symbolů (2)

- **Graf přechodů konečného automatu**
  - (syntaktický graf)





# Lexikální analýza - Specifikace symbolů (3)

- Lexikální symboly lze obvykle popsát *regulárními jazyky*
- **Co nedokážeme popsat?**
  - Zanořené konstrukce (závorky)
  - Opakované konstrukce  $\{wcw \mid w \in \{a,b\}^*\}$
  - Zadaný počet opakování
    - $nHa_1a_2\dots a_n$  (FORTRAN)

# Lexikální analýza - Příklad regulárních výrazů



- Přesná definice regulárních výrazů - UTI
- Následující příklady demonstруjí běžné konvence používané v různých nástrojích
  - $[A-Z](A-Z)|[0-9])^* \equiv [A-Z][A-Z0-9]^*$
  - $[0-9]^+.[0-9]^+(E[-+]?)^*[0-9]^+$   
|  $[0-9]^+ E[-+]?)^*[0-9]^+$



# Lexikální analýza - Regulární definice (1)

- Pojmenované regulární výrazy


- $d_1 \rightarrow r_1$
- $d_2 \rightarrow r_2$
- ...
- $d_n \rightarrow r_n$

- různá jména                  reg. výrazy nad  $\Sigma \cup \{d_1, d_2, \dots, d_{i-1}\}$

# Lexikální analýza - Regulární definice (2)



- Pojmenované regulární výrazy
  - letter    -> [A-Za-z]
  - digit    -> [0-9]
  - id       -> letter (letter | digit)\*
- Použití: konstruktor lex. analyzátoru






# Lexikální analýza - Konečné automaty (1)


- $(Q, \Sigma, f, q_0, F)$ 
  - $Q$  – konečná množina stavů
  - $\Sigma$  - vstupní abeceda
  - $f$  – přechodová funkce
  - $q_0$  – počáteční stav
  - $F$  – množina koncových stavů
- $f: Q \times (\Sigma \cup \{e\}) \rightarrow 2^Q$       rozšířený NKA
- $f: Q \times \Sigma \rightarrow Q$                           DKA



# Lexikální analýza - Konečné automaty (2)



**DKA**



**NKA**

# Lexikální analýza - Algoritmy pro transformaci



- Regulární gramatika  $\leftrightarrow$  konečný automat
  - korespondence pravidel gramatiky a přechodové funkce
- Regulární výraz  $\rightarrow$  konečný automat
  - skládání primitivních KA, převod na DKA, minimalizace
  - stromová reprezentace
  - důležité pro konstruktory lexikálních analyzátorů
- Konečný automat  $\rightarrow$  regulární výraz
  - soustava algebraických rovnic
$$X = a X + b \quad \Rightarrow \quad X = a^* b$$
  - derivace regulárních výrazů



# Lexikální analýza - Konečný automat pro lexikální analýzu

- Zpracování začíná vždy prvním dosud nezpracovaným znakem ze vstupu
- Zpracování končí, je-li automat v koncovém stavu a pro další vstupní znak již neexistuje žádný přechod (maximal match):
  - 123 není 12 následované 3
- Není-li v nekoncovém stavu přechod možný, vrací se automat do posledního dosaženého koncového stavu nebo je chyba:
  - < <= <<            1. 1..2 1..5

# Lexikální analýza - Speciální případy (1)



- **akce po přijetí symbolu**
  - samostatný koncový stav pro každou kategorii
  - výpočet hodnot atributů z lexému
- **klíčová slova**
  - koncový stav pro každé klíčové slovo – mnoho stavů
  - obvykle jako id, pak následuje rozlišení tabulkou klíč. slov



# Lexikální analýza - Speciální případy (2)

## ● komentáře

- uzavřená cesta procházející poč. stavem
- diagnostika – neukončený komentář
- dokumentační komentář – Javadoc
- zanořené komentáře

## ● znakové řetězce


- escape sekvence ‘\n’
- ukončení řádku v řetězci je obvykle chyba
- Unicode



# Lexikální analýza - Implementace lexikálního analyzátoru

- **Přímá**
  - Efektivita na úkor složitosti návrhu
  - Stav je reprezentován pozicí v programu
- **Simulace konečného automatu**
  - Vhodné spíš pro konstruktory
- **Využití konstruktoru**
  - Snadná modifikovatelnost
  - Především v počátečních fázích implementace
  - LEX (FLEX), JavaCC

# Lexikální analýza - Přímá implementace



```
for(;;) {
    skipSpaces();
    skipNote();
    if( isEof ) return Tokens.EOF;
    if( Character.isLetter(ch) ) {
        StringBuffer buf = new StringBuffer();
        do { buf.append(ch); getch();
        } while( !isEof && Character.isLetterOrDigit(ch) );
        stringAttr = buf.toString();
        if( stringAttr.compareToIgnoreCase("div") == 0 ) return Tokens.DIV;
        if( stringAttr.compareToIgnoreCase("mod") == 0 ) return Tokens.MOD;
        return Tokens.IDENT;
    }
    if( Character.isDigit(ch) ) {
        StringBuffer buf = new StringBuffer();
        do { buf.append(ch); getch();
        while( !isEof && Character.isDigit(ch) );
        numberAttr = Integer.parseInt(buf.toString());
        return Tokens.NUMBER;
    }
}
```



# Lexikální analýza - Implementace konečného automatu

- Tabulka + Přechodová funkce + Interpret
  - výhodné jako výstup konstruktoru
- Přímý přepis do programu



# Lexikální analýza – Využití konstruktoru

- Vstupem je obvykle sada regulárních definic

SKIP :

```
{  
  " " | "\r" | "\t"  
}
```


TOKEN :

```
{  
  < ADD: "+" > | < SUB: "-" > | < MUL: "*" > | < DIV: "/" > | < MOD: "mod" >  
}
```


TOKEN :

```
{  
  < CONSTANT: ( <DIGIT> )+ > | < #DIGIT: ["0" - "9"] >  
}
```

- Konstruktor pak tento vstup zpracuje a vygeneruje implementaci lexikálního analyzátoru (obvykle využívá automaty)
  - Více informací v přednášce věnované JavaCC



# Syntaktická analýza - Rozhraní syntaktického analyzátoru






# Syntaktická analýza - Úkoly syntaktické analýzy

- **Rozpozнат syntaktické konstrukce**







- posloupnost                    A B
- alternativa                    A | B
- opakování                    AAA ...    A, A, A, ...
- hierarchie                    E -> (E)

- **Vybudovat derivační strom**



- vnitřní uzly – neterminální symboly
- listy                         – terminální symboly



# Syntaktická analýza - Základní syntaktické konstrukce


 $S \rightarrow A B$ 

 $S \rightarrow A | B$ 

 $S \rightarrow S A | A$ 

 $S \rightarrow S A | e$ 

 $S \rightarrow S , A | A$ 

 $S \rightarrow A S' | e$ 
 $S \rightarrow A S' | A$ 
 $S \rightarrow A S' | e$ 
 $S \rightarrow A , S' | A$ 
 $S' \rightarrow , A S' | e$ 
 $S \rightarrow A S'$ 
 $S \rightarrow A S' | e$ 
 $S \rightarrow A S'$ 
 $S' \rightarrow A S' | e$

# Syntaktická analýza – Příklad (syntaktický graf)


$$S \rightarrow \text{var } V \ V'$$
$$V \rightarrow \text{id } L : T ;$$
$$\begin{aligned} V' \rightarrow & V \ V' \\ | & e \end{aligned}$$
$$\begin{aligned} L \rightarrow & , \text{id } L \\ | & e \end{aligned}$$



# Syntaktická analýza - Metody syntaktické analýzy

- **Univerzální metody**
  - např. analýza s návraty
  - nejsou efektivní
- **Překlad shora dolů (LL gramatiky)**
  - vhodný pro „ruční“ implementaci
- **Překlad zdola nahoru (LR gramatiky)**
  - efektivní metoda pro všechny deterministicky analyzovatelné jazyky
  - využití zejména v konstruktorech překladačů




# Syntaktická analýza - Bezkontextová gramatika

- **Bezkontextová gramatika je definovaná jako čtverice  $G=(N, T, P, S)$** 
  - $N$  – neterminální symboly
  - $T$  – terminální symboly
  - $P$  – pravidla ve tvaru -  $N \times (N \cup T)^*$
  - $S$  – startovací neterminál

- Příklad

$$G = (\{E, T, F\}, \{+, *, (, ), n\}, P, E)$$

$$\begin{aligned}P = \{ & \quad E \quad \rightarrow \quad E + T \quad | \quad T \\& \quad T \quad \rightarrow \quad T * F \quad | \quad F \\& \quad F \quad \rightarrow \quad ( E ) \quad | \quad n \\& \}\end{aligned}$$



# Syntaktická analýza - Analýza shora dolů (1)

- Levá derivace

$$\begin{aligned} E &\Rightarrow \underline{E} + T \Rightarrow \underline{T} + T \Rightarrow \underline{F} + T \Rightarrow n + \underline{T} \Rightarrow \\ &\Rightarrow n + \underline{T}^* F \Rightarrow n + \underline{F}^* F \Rightarrow n + n^* \underline{E} \Rightarrow n + n^* n \end{aligned}$$

- Větná forma ...  $(N \cup T)^*$

$n + n^* F$

- Věta ...  $T^*$

$n + n^* n$



# Syntaktická analýza - Analýza shora dolů (2)

Vstup	Zásobník	Pravidlo
.n + n * n	.E	E → E + T
.n + n * n	.E + T	E → T
.n + n * n	.T + T	T → F
.n + n * n	.F + T	F → n
.n + n * n	.n + T	
.+ n * n	.+ T	P → e
.n * n	.T	T → T * F
.n * n	.T * F	T → F
.n * n	.F * F	F → n
.n * n	.n * F	
.* n	.* F	
.n	.F	F → n
.n	.n	
.		



# Syntaktická analýza - Analýza zdola nahoru (1)

- Pravá derivace



$$\begin{aligned}\underline{E} &\Rightarrow E + \underline{T} & \Rightarrow E + T^* \underline{E} &\Rightarrow E + \underline{T^*n} &\Rightarrow \\ &\Rightarrow E + \underline{E^*n} &\Rightarrow E + n^*n &\Rightarrow \underline{T} + n^*n &\Rightarrow \\ &\Rightarrow \underline{E} + n^*n &\Rightarrow n + n^*n\end{aligned}$$



# Syntaktická analýza - Analýza zdola nahoru (2)

Zásobník	Vstup	Pravidlo
	. n + n * n	
n	. + n * n	F → n
F	. + n * n	T → F
E	. + n * n	E → T
E +	. n * n	
E + n	. * n	F → n
E + F	. * n	T → F
E + T	. * n	
E + T *	. n	
E + T * n	.	F → n
E + T * F	.	T → T * F
E + T	.	E → E + T
E	.	

# Syntaktická analýza - Analýza zdola nahoru (3)





# Syntaktická analýza - LL(1) gramatiky

- LL(1)
  - L – Levý rozklad
  - L – Analýza zleva doprava
  - 1 – Rozhodování podle jednoho symbolu
- Deterministická analýza
- Analýza shora dolů
- Jednoduchá implementace




# Syntaktická analýza - LR(1) gramatiky

- Největší třída jazyků analyzovatelných deterministickými metodami
  - Každý jazyk generovaný LR( $k$ ) gramatikou lze generovat ekvivalentní LR(1) gramatikou
  - Neplatí pro LL( $k$ )!
- Analýza se provádí *zdola nahoru* pomocí zásobníkového automatu



# LL(1) gramatiky - Motivace



- Vstup  
 $w=a_1a_2\dots a_n$
- Stav analýzy  
 $S \Rightarrow^* a_1a_2\dots a_j A B$
- $A \rightarrow \alpha_1 \mid \alpha_2 \mid \dots \mid \alpha_k$
- Kterou pravou stranu použít pro expanzi A?



# LL(1) gramatiky - Příklad


- $A \rightarrow a B \mid b C \mid c$
- $A \rightarrow B a \mid c$   
 $B \rightarrow b B \mid d$
- $A \rightarrow a A \mid e$   
 $S \rightarrow b A c$
- Když  $a_{j+1}=a$ , pak použijeme  $A \rightarrow aB$ .
- Když  $a_{j+1} \in \{b, d\}$ , pak použijeme  
 $A \rightarrow Ba$ .  
 $\text{FIRST}(\alpha_i)$
- Když  $a_{j+1} \in \{c\}$ , pak použijeme  $A \rightarrow e$   
 $\text{FOLLOW}(A)$



# LL(1) gramatiky - Definice

$G = (N, \Sigma, P, S)$   $\alpha \in (N \cup \Sigma)^*$

- **FIRST**( $\alpha$ ) ::=  
 $\{a \in \Sigma \mid \alpha \Rightarrow^* a\beta, \beta \in (\Sigma \cup N)^*\} \cup$   
 $\{e \mid \alpha \Rightarrow^* e\}$
- **FOLLOW**(A) ::=  
 $\{a \in \Sigma \mid S \Rightarrow^* \alpha A \beta, a \in \text{FIRST}(\beta),$   
 $\alpha, \beta \in (\Sigma \cup N)^*\}$



# LL(1) gramatiky - Příklad

$A \rightarrow BCb \mid aB$

$B \rightarrow bB \mid e$

$C \rightarrow cA \mid e$

$FIRST(BCb) = ?$

- $BCb \Rightarrow bBCb$   
 $\Rightarrow Cb \Rightarrow cAb$   
 $\Rightarrow b$
- $FIRST(BCb) = \{b,c\}$

$FOLLOW(B) = ?$

- $A \Rightarrow B|Cb$   
 $\Rightarrow bB|Cb$   
 $\Rightarrow \dots$
- $=> aB|$
- $FIRST(Cb) = \{b,c\}$
- $FIRST(e) = \{e\}$
- $FOLLOW(B) = \{b,c,e\}$



# LL(1) gramatiky - Definice

Množina symbolů generujících prázdné slovo

$$G = (N, \Sigma, P, S)$$

$$N_e ::= \{ A \in N \mid A \Rightarrow^+ \epsilon \}$$



# LL(1) gramatiky - Algoritmus pro FIRST( $\alpha$ )

1.  $\alpha = a\beta, a \in \Sigma \Rightarrow \text{FIRST}(\alpha) = \{a\}$
2.  $\alpha = e \Rightarrow \text{FIRST}(\alpha) = \{e\}$
3.  $\alpha = A\beta, \quad \Rightarrow \text{FIRST}(\alpha) =$   
 $A \in N \setminus N_e \qquad \qquad \qquad \cup_{i \in \{1..n\}} \text{FIRST}(\alpha_i)$   
 $A \rightarrow \alpha_1 | \dots | \alpha_n$
4.  $\alpha = A\beta, \quad \Rightarrow \text{FIRST}(\alpha) =$   
 $A \in N_e \qquad \qquad \qquad (\cup_{i \in \{1..n\}} \text{FIRST}(\alpha_i) - \{e\})$   
 $\cup \text{FIRST}(\beta)$



# LL(1) gramatiky – Příklad (1)

$A \rightarrow BCb \mid aB$

$N_e = \{B, C\}$

$B \rightarrow bB \mid e$

$C \rightarrow cA \mid e$

- $\text{FIRST}(bB) = \{b\}$  (1)

- $\text{FIRST}(e) = \{e\}$  (2)

- $\text{FIRST}(cA) = \{c\}$  (1)

- $\text{FIRST}(BCb) = ((\text{FIRST}(bB) \cup \text{FIRST}(e)) \setminus \{e\}) \cup \text{FIRST}(Cb)$  (4)




# LL(1) gramatiky – Příklad (2)

- $\text{FIRST}(\text{Cb}) = ((\text{FIRST}(\text{cA}) \cup \text{FIRST}(\epsilon)) \setminus \{\epsilon\}) \cup \text{FIRST}(\text{b})$  (4)
- $\text{FIRST}(\text{b}) = \{\text{b}\}$  (1)
- $\text{FIRST}(\text{BCb}) = \{\text{b}\} \cup \{\text{b}, \text{c}\} = \{\text{b}, \text{c}\}$
- Jiný možný algoritmus je založený na výpočtu tranzitivního uzávěru.



# LL(1) gramatiky - Algoritmus pro FOLLOW

1.  $e \in \text{FOLLOW}(S)$
2.  $A \rightarrow \alpha X \beta$   
 $\Rightarrow \text{FIRST}(\beta) \setminus \{e\} \subseteq \text{FOLLOW}(X)$
3.  $\beta \Rightarrow^* e$   
 $\Rightarrow \text{FOLLOW}(A) \subseteq \text{FOLLOW}(X)$



# LL(1) gramatiky - Příklad

$A \rightarrow BCb \mid aB$

$B \rightarrow bB \mid e$

$C \rightarrow cA \mid e$

(1)  $e \in \text{FOLLOW}(A)$

(2)  $\text{FIRST}(Cb) = \{b, c\} \subseteq \text{FOLLOW}(B)$   
 $\text{FIRST}(b) = \{b\} \subseteq \text{FOLLOW}(C)$

(3)  $\text{FOLLOW}(A) \subseteq \text{FOLLOW}(B)$   
 $\text{FOLLOW}(B) \subseteq \text{FOLLOW}(B)$   
 $\text{FOLLOW}(C) \subseteq \text{FOLLOW}(A)$

- $\text{FOLLOW}(C) = \{b\}$
- $\text{FOLLOW}(A) = \{e, b\}$
- $\text{FOLLOW}(B) = \{e, b, c\}$

# LL(1) gramatiky – Omezení

## LL(1) gramatik



$A \rightarrow aA \mid aB$

$B \rightarrow b$

- Nejsme schopni na základě množiny FIRST určit, kterou pravou stranu neterminálu a použít.

$A \rightarrow Aa \mid e$

- Nevíme, kdy „ukončit“ rekurzi.



# LL(1) gramatiky – Definice

## LL(1) Gramatiky

- $G = (N, \Sigma, P, S)$
- Libovolné dvě levé derivace
  - $S \Rightarrow^* wA\beta \Rightarrow w\alpha_1\beta \Rightarrow^* wx$
  - $S \Rightarrow^* wA\beta \Rightarrow w\alpha_2\beta \Rightarrow^* wy$
- **FIRST(x) = FIRST(y) =>  $\alpha_1 = \alpha_2$**

Pro danou větnou formu  $wA\beta$  a symbol  $a$  lze jednoznačně najít pravidlo  $A \rightarrow \alpha$  pro expanzi.



# LL(1) gramatiky – Důsledky

- $A \rightarrow \alpha_1 \mid \alpha_2 \mid \dots \mid \alpha_k$

$\text{FIRST}(\alpha_i) \cap \text{FIRST}(\alpha_j) = \emptyset$ , pro  $\forall i, j: i \neq j$

*Podmínka FF*

- Pokud  $A \in N_e$  ( $\alpha_i \Rightarrow^* e$ ) pro nějaké  $i$ , pak

$\text{FIRST}(\alpha_j) \cap \text{FOLLOW}(A) = \emptyset$ , pro  $\forall j: j \neq i$

*Podmínka FFL*



# LL(1) gramatiky – Příklad

$A \rightarrow BCb \mid aB$     **není LL(1) gramatika**

$B \rightarrow bB \mid e$

$C \rightarrow cA \mid e$

•  $\{b,c\} \cap \{a\} = \emptyset$

$\Rightarrow$  Podmínka FF platí

•  $(\text{FOLLOW}(B) = \{e,b,c\})$


$\cap (\text{FIRST}(bB) = \{b\}) = \{b\}$

$\Rightarrow$  Podmínka FFL neplatí



# LL(1) gramatiky – Syntaktická analýza LL(1) jazyků (1)

Prediktivní syntaktická analýza zás. automatem





# LL(1) gramatiky – Syntaktická analýza LL(1) jazyků (2)

- Konfigurace  $(x, X\alpha, \pi)$ 
  - $x$  – nezpracovaný vstup,  $x=ux'$ ,  $u = \text{FIRST}(x)$
  - $X\alpha$  - obsah zásobníku ( $X$  je na vrcholu)
  - $\pi$  - výstup (levý rozklad)
- Počáteční konfigurace:  $(w, S\#, e)$
- Koncová konfigurace:  $(e, \#, \pi)$

Kam se schovaly stavy?



# LL(1) gramatiky – Rozkladová tabulka

- $M: (\Gamma \cup \{\#\})^* (\Sigma \cup \{e\}) \rightarrow \{\text{expand } i, \text{ pop}, \text{ accept}, \text{ error}\}$
- **expand i:**  $(x, A\beta, \pi) \vdash (x, \alpha\beta, \pi.i)$ 
  - pravidlo  $p_i: A \rightarrow \alpha$
- **pop:**  $(ax, a\beta, \pi) \vdash (x, \beta, \pi)$
- **accept:**  $M[\#, e] = \text{accept}$ 
  - vstupní řetězec je přijat,  $\pi$  je levý rozklad
- **error:** syntaktická chyba



# LL(1) gramatiky – Příklad (1)

- $S \rightarrow aAS$  (1)  
 $S \rightarrow b$  (2)  
 $A \rightarrow a$  (3)  
 $A \rightarrow bSA$  (4)

	a	b	e
S	e1	e2	
A	e3	e4	
a	pop		
b		pop	
#			acc



# LL(1) gramatiky – Příklad (2)

(abbab,S#,e)	:-[e1]	(abbab,aAS#,1)	:-[pop]
(bbab,AS#,1)	:-[e4]	(bbab,bSAS#,14)	:-[pop]
(bab,SAS#,14)	:-[e2]	(bab,bAS#,142)	:-[pop]
(ab,AS#,142)	:-[e3]	(ab,aS#,1423)	:-[pop]
(b,S#,1423)	:-[e2]	(b,b#,14232)	:-[pop]
(e,#,14232)	:-[acc]		



# LL(1) gramatiky – Konstrukce rozkladové tabulky

Je-li  $A \rightarrow \alpha$  i-té pravidlo, pak  $\forall a \in \text{FIRST}(\alpha)$ :

$$M[A, a] = \text{expand } i \quad (a \neq e)$$

Je-li  $e \in \text{FIRST}(\alpha)$ , pak  $\forall b \in \text{FOLLOW}(A)$

$$M[A, b] = \text{expand } i$$

$$M[a, a] = \text{pop}$$

$$M[\#, e] = \text{accept}$$

$$\text{jinak } M[X, a] = \text{error}$$



# LL(1) gramatiky – Příklad

$S \rightarrow aAd \quad (1) \mid e \quad (2)$


$\text{FOLLOW}(S)=\{e\}$

$A \rightarrow bB \quad (3)$

$B \rightarrow cbB \quad (4) \mid e \quad (5)$

$\text{FOLLOW}(B)=\{d\}$

	a	b	c	d	e
S	e1				e2
A		e3			
B			e4	e5	
a	pop				
b		pop			
c			pop		
d				pop	
#					acc



# LL(1) gramatiky – Převod na LL(1) gramatiku

- **Odstranění levé rekurze**

- $A \rightarrow A\alpha_1 | \dots | A\alpha_n | \beta_1 | \dots | \beta_m \Rightarrow |\text{FF neplatí}|$
- $A \rightarrow \beta_1 A' | \dots | \beta_m A'$   
 $A' \rightarrow \alpha_1 A' | \dots | \alpha_n A' | e$

- **Faktorizace** („vytknutí před závorku“)

- $A \rightarrow \beta\alpha_1 | \dots | \beta\alpha_n \Rightarrow |\text{FF neplatí}|$
- $A \rightarrow \beta A' \quad A' \rightarrow \alpha_1 | \dots | \alpha_n$

- **Eliminace pravidla** – dosazení pravých stran za neterminál



# LL(1) gramatiky – Implementace

## LL(1) analyzátoru

- **Analýza s návraty**
  - Málo efektivní, Prolog
- **Analýza rekurzivním sestupem**
  - Vhodná pro „ruční“ implementaci
- **Nerekurzivní prediktivní analýza**
  - Využití rozkladové tabulky + interpretu
  - Vhodná pro generované analyzáitory
- **Využití generátorů překladačů**
  - Obvykle umožňují nahlížet více symbolů než jeden



# LL(1) gramatiky – Rekurzivní sestup (1)

- Každý **neterminál** je reprezentován funkcí, která provádí jeho analýzu
- **Terminální symboly** jsou reprezentovány testem na jejich výskyt na vstupu následovaným čtením dalšího symbolu
- Překlad začíná voláním funkce reprezentující **startovací neterminál**



# LL(1) gramatiky – Rekurzivní sestup (2)

**Pravidlo**  $A \rightarrow X_1 X_2 \dots X_n$

$X \in \Sigma$  - volání  $\text{expect}(X)$   
 $X \in N$  – volání  $X()$

```
void A() {  
    // analýza  $X_1$   
    // analýza  $X_2$   
    ...  
    // analýza  $X_n$   
}
```

# LL(1) gramatiky – Rekurzivní sestup (3)



```
Symbol sym; // aktuální symbol

void expect(Symbol s)
{
    if( sym == s )
        sym = lex(); // čti další symbol
    else
        error(); // syntaktická chyba
}
```



# LL(1) gramatiky – Příklad rekurzivního sestupu

A  $\rightarrow$  xBy

```
void A()
{
    expect(x);
    B();
    expect(y);
}
```

# LL(1) gramatiky – Neterminál s více pravidly



- $A \rightarrow \alpha_1 \mid \alpha_2 \mid \dots \mid \alpha_n$

Výběr pravidla závisí na následujícím symbolu:

```
if( sym in SELECT(A,αi) ) {  
    // analýza řetězce αi  
}
```

- $\text{SELECT}(A, \alpha_i) =$ 
  - $\text{FIRST}(\alpha_i)$   $e \notin \text{FIRST}(\alpha_i)$
  - $\text{FOLLOW}(A) \cup (\text{FIRST}(\alpha_i) \setminus \{e\})$   $e \in \text{FIRST}(\alpha_i)$



# LL(1) gramatiky – Příklad (1)

$E \rightarrow T E_1$

$E_1 \rightarrow + T E_1 \mid e$

$T \rightarrow F T_1$

$T_1 \rightarrow * F T_1 \mid e$

$F \rightarrow ( E ) \mid id$



# LL(1) gramatiky – Příklad (2)

- $\text{FIRST}(+ \text{ T E1}) = \{+\}$   
 $\text{FIRST}(e) = \{e\}$   
 $\text{FOLLOW(E1)} = \{\}, e\}$ 
  - e ve FOLLOW znamená eof
- $\text{SELECT(A, + T E1)} = \{+\}$   
 $\text{SELECT(A, e)} = \{\}, e\}$



# LL(1) gramatiky – Příklad (3)

```
void E1()
{
    if( sym=='+' )  {
        expect('+');
        T();
        E1();
    } else if( sym==')' || sym==EOF] )  {
        // prázdná pravá strana
    } else
        error();
}
```



# LL(1) gramatiky – Nerekurzivní prediktivní analýza

- Syntaktický analyzátor řízený tabulkou rozkladovou tabulkou (zásobníkový automat)
- Rozkladová tabulka       $M[A,a]$
- Zásobník                    push( $\alpha$ ), pop(), top(), init()
- Výstup                      output(i)
- Zpracování chyb          error()



# LL(1) gramatiky – Algoritmus interpretu (1)

```
init();  
push($S);           // inicializace  
a = lex();          // první symbol  
do {  
    x = top();  
    if( x ∈ Σ ∪ { $ } )  // terminál nebo EOF($)  
        if( x == a ) {  
            pop();  
            a = lex();  
        } else  
            error();
```



# LL(1) gramatiky – Algoritmus interpretu (2)

```
else if( M[X,a]==pi ) {  
    pop(); // pi->Y1...Yk  
    push(YkYk-1...Y1); // expanze  
    output(i);  
} else  
    error();  
  
} while( x != $ );
```

# LL(1) gramatiky – Zotavení po chybě (1)



## ● Lexikální analýza

- nesprávný formát čísla oprava
- neukončený řetězec oprava
- neznámý symbol přeskočení
- neukončená poznámka oprava

## ● Syntaktická analýza

- na úrovni symbolů přeskočení
- na úrovni vět oprava

# LL(1) gramatiky – Zotavení po chybě (2)




## • Sémantická analýza

- nedeklarovaný identifikátor oprava
- typová chyba oprava



# LL(1) gramatiky – Zotavení při analýze zhora dolů





# LL(1) gramatiky – Postup při zotavení

Klíč = terminální symbol, umožňující spolehlivé určení místa v gramatice  
switch do if for == ? ...

- Nalezení klíče ve vstupní větě, přeskočení části textu
- 2) Přesun řízení na odpovídající místo v gramatice
- 3) Pokračování v analýze



# LL(1) gramatiky – Problémy

- Nejednoznačnost klíčů
  - výskyt klíče v různých místech gramatiky
- Protichůdné požadavky
  - Malá množina klíčů
    - Roste délka přeskakovaného textu
  - Velká množina klíčů
    - Klesá spolehlivost zotavení
    - Zavlečené chyby



# LL(1) gramatiky – Metody zotavení


- Nerekurzivní zotavení s pevnou množinou klíčů
  - Množina klíčů = {";", ")"}
    - <příkaz> končí symbolem ";"
    - <výraz> končí symbolem ")"
  - if A= **then** A:=((+B); **A**:=A+B;
- Rekurzivní zotavení s pevnou množinou klíčů
  - Synchronizace na začátku konstrukce
    - "if" uvozuje <příkaz>
    - "(" uvozuje <výraz>
  - if A= **then** A:=((+B); **A**:=A+B;
- Metoda s dynamicky budovanou množinou klíčů
  - Hartmannova metoda zotavení



# LL(1) gramatiky – Implementace

## Hartmannovy metody (1)

- Kdy se hlásí syntaktická chyba?
  - Funkce expect - na vstupu je neočekávaný symbol
  - Nelze vybrat pravidlo pro expanzi (symbol na vstupu není v  $\Phi(A, \alpha_i)$  pro žádné i)



# LL(1) gramatiky – Implementace Hartmannovy metody (2)

- Funkce reprezentující neterminály obdrží množinu klíčů jako parametr
  - `void E(Set c) { ... }`
- Při volání neterminálu nebo funkce expect se vypočte nová množina klíčů
  - `E( c ∪ { '+', '-' })`  
`expect( '(', c ∪ { NUM, '(' } );`
- Funkce check() se volá na začátku neterminálu s více pravidly



# LL(1) gramatiky – Implementace Hartmannovy metody (3)

- $A \rightarrow X_1 X_2 \dots X_i X_{i+1} \dots X_k$ 
  - $c \dots$  množina klíčů neterminálu  $A$
  - $c_i \dots$  množina klíčů symbolu  $X_i$
- 1)  $c_i = c \cup \text{FOLLOW}(X_i) \quad X_i \in N$   
 $c_i = c \quad X_i \in \Sigma$
- 2)  $c_i = c \cup (\text{FIRST}(X_{i+1} \dots X_k) \setminus \{e\})$
- 3)  $c_i = c \cup ((\text{FIRST}(X_{i+1}) \cup \dots \cup \text{FIRST}(X_k)) \setminus \{e\})$



# Syntaxí řízený překlad - Překlad

- **Definice:** Překlad je relace

TRAN:  $L_1 \rightarrow L_2$

$L_1 \subseteq \Sigma^*$

$\Sigma$  - vstupní abeceda

$L_2 \subseteq \Delta^*$

$\Delta$  - výstupní abeceda

- Příklad

- $L_1$  – jazyk infixových výrazů
- $L_2$  – jazyk postfixových výrazů



# Syntaxí řízený překlad - Překladová párová gramatika

- **Definice:** Překladová párová gramatika

$$V = (N, \Sigma, \Delta, P, S)$$

N - neterminály

$\Sigma$  - vstupní abeceda

$\Delta$  - výstupní abeceda

P – přepisovací pravidla

S – startovací neterminál

$$P: A \rightarrow \alpha, \beta \quad \alpha \in (N \cup \Sigma)^*, \beta \in (N \cup \Delta)^*$$

Neterminály z  $\beta$  jsou permutacemi neterminálů z  $\alpha$



# Syntaxí řízený překlad -

## Příklad (1)

$E \rightarrow E+T, ET+$

$E \rightarrow T, T$

$T \rightarrow T^*F, TF^*$

$T \rightarrow F, F$

$F \rightarrow (E), E$

$F \rightarrow i, i$

$[E, E] \Rightarrow [E+T, ET+]$

$\Rightarrow [T+T, TT+]$

$\Rightarrow [F+T, FT+]$

$\Rightarrow [i+T, iT+]$

$\Rightarrow [i+T^*F, iTF^*+]$

$\Rightarrow [i+F^*F, FF^*+]$

$\Rightarrow [i+i^*F, iiF^*+]$

$\Rightarrow [i+i^*i, iii^*+]$



# Syntaxí řízený překlad - Překladová gramatika

- Jsou-li neterminály ve vstupní i výstupní části pravé strany ve stejném pořadí, můžeme obě části spojit  
**=> překladová gramatika**
- Musíme ale odlišit vstupní a výstupní symboly



# Syntaxí řízený překlad -

## Příklad

$$\begin{aligned} E &\rightarrow E + T + \\ &\quad (E \rightarrow E + T \oplus) \end{aligned}$$

$$E \rightarrow T$$

$$T \rightarrow T^* F^*$$

$$T \rightarrow F$$

$$F \rightarrow ( E )$$

$$F \rightarrow i\ i$$

$$\begin{aligned} E &=> E + T + \\ &=> T + T + \\ &=> F + T + \\ &=> i\ i + T + \\ &=> i\ i + T^* F^* + \\ &=> i\ i + F^* F^* + \\ &=> i\ i + i\ i^* F^* + \\ &=> i\ i + i\ i^* i\ i^* + \end{aligned}$$



# Syntaxí řízený překlad - Homomorfismy

- Vstupní homomorfismus:

$$\begin{aligned}\iota(x) &= x, \quad x \in (N \cup \Sigma) \\ &= \varepsilon, \quad x \in \Delta\end{aligned}$$

- Výstupní homomorfismus:

$$\begin{aligned}o(x) &= x, \quad x \in (N \cup \Delta) \\ &= \varepsilon, \quad x \in \Sigma\end{aligned}$$

- Příklad

- $\iota(E + T^+)$  =  $E + T$

- $\iota(E + T^+)$  =  $E T^+$

- $\iota(i i + i i^* i i^* +)$  =  $i + i^* i$

- $\iota(i i + i i^* i i^* +)$  =  $i i i^* +$



# Syntaxí řízený překlad - Překlad

- **Definice:** Překlad generovaný překladovou gramatikou:

$$T(G) = \{(x, y) \mid S \Rightarrow^* z, \\ z \in (\Delta \cup \Sigma)^*, \\ x = \iota(z), \\ y = o(z)\}$$

*vstupní věta*  
*výstupní věta*



# Syntaxí řízený překlad - Atributovaný překlad

- Rozšíření bezkontextové gramatiky o kontextové vlastnosti  
→ „**gramatika s parametry**“
- Jednotlivé symboly mohou mít přiřazeny parametry – **atributy**
- Atributy se předávají podobně jako vstupní a výstupní argumenty funkcí



# Syntaxí řízený překlad - Atributová překladová gramatika

- **Definice:** Atributová překladová gramatika

$$G_{AT} = (G_T, A, F)$$

$G_T$  – překladová gramatika

( $\Delta = \emptyset \rightarrow$  **atributová gramatika**)

A – množina atributů

F – sémantická pravidla (pravidla pro výpočet hodnot atributů)



# Syntaxí řízený překlad -

## Množina atributů

- $X \in (\Delta \cup \Sigma \cup N)$ 
  - $I(X)$  - množina **dědičných** atributů
  - $S(X)$  - množina **syntetizovaných** atributů
- Dědičné atributy startovacího neterminálu jsou zadány předem.
- Syntetizované atributy terminálních symbolů jsou zadány předem (lexikální analyzátor)



# Syntaxí řízený překlad - Sémantická pravidla (1)

$p_r: X_0 \rightarrow X_1 X_2 \dots X_n \quad X_0 \in N, X_i \in (N \cup \Delta \cup \Sigma)$

a)  $d = f_r^{d,k}(a_1, a_2, \dots, a_n) \quad d \in I(X_k), 1 \leq k \leq n$

b)  $s = f_r^{s,0}(a_1, a_2, \dots, a_n) \quad s \in S(X_0)$

c)  $s = f_r^{s,k}(a_1, a_2, \dots, a_n) \quad s \in S(X_k), X_k \in \Delta$

- a,b)  $a_i$  je atribut symbolu  $X_j, 0 \leq j \leq n$
- c)  $a_i$  je dědičný atr. symbolu  $X_f, X_f \in \Delta$



# Syntaxí řízený překlad - Sémantická pravidla (2)

- Výklad předchozích definic:
  - a) Dědičné atributy symbolu na pravé straně pravidla
  - b) Syntetizované atributy neterminálního symbolu na levé straně pravidla
  - c) Syntetizované atributy výstupních symbolů na pravé straně pravidla



# Syntaxí řízený překlad -

## Syntaxí řízená definice

- sémantické funkce v atributové gramatice nemohou mít vedlejší efekty
  - vstup/výstup (např. generovaného kódu)
  - globální proměnné (např. tabulka symbolů)
- *syntaxí řízená definice* – bez omezení



# Syntaxí řízený překlad - Syntaxí řízené definice a překladová schémata

- Obecně existují dvě notace, jak můžeme připojit sémantické akce k pravidlům gramatiky.
  - Syntaxí řízené definice
    - Základní idea je, že jednotlivým pravidlům přiřadíme množinu sémantických akcí.
    - Specifikace překladu na vysoké úrovni abstrakce.
    - Ukrývají mnoho implementačních detailů jako například pořadí vyhodnocování pravidel.
  - Překladová schémata
    - Určuje pořadí vyhodnocení jednotlivých sémantických pravidel.
    - Umožňuje definovat nějaké implementační detailly



# Syntaxí řízený překlad - Překladové schéma

- Syntaxí řízená definice se sémantickými akcemi umístěnými kdekoli na pravé straně pravidla
- Posloupnost sémantických akcí je přesně definována

# Syntaxí řízený překlad - Návrh překladového schématu



- Dědičný atribut symbolu na pravé straně vypočte akce umístěna před ním.
- Akce nesmí používat syntetizované atributy symbolů vpravo odní.
- Hodnota syntetizovaného atributu neterminálu na levé straně pravidla se vypočte až po určení všech atributů, na které se odkazuje
  - obvykle až na konci pravidla



# Syntaxí řízený překlad - L - atributová definice

## L-atributová definice

$$A \rightarrow X_1 \dots X_n$$

Dědičné atributy symbolu  $X_j$  závisejí jen na:

- atributech symbolů  $X_1, \dots, X_{j-1}$   
(tj. symbolů z téhož pravidla *vlevo* od symbolu  $X_j$ )
- dědičných atributech symbolu A  
(tj. symbolu na *levé straně* pravidla)
- **Použití: LL(1) překlad – jasně definované pořadí pro vyhodnocení sémantických pravidel.**




# Syntaxí řízený překlad - Příklad na výpočet hodnoty výrazu (1)

- Syntetizované atributy:
  - E.val - hodnota výrazu
  - T.val - hodnota podvýrazu
  - F.val - hodnota operandu
- num.lexval – hodnota číselné konstanty




# Syntaxí řízený překlad - Příklad na výpočet hodnoty výrazu (2)

- Gramatika
- $E \rightarrow E' + T$
- $E \rightarrow T$
- $T \rightarrow T' * F$
- $T \rightarrow F$
- $F \rightarrow (E)$
- $F \rightarrow \text{num}$
- Sémantická pravidla
- $E.\text{val} = E'.\text{val} + T.\text{val}$
- $E.\text{val} = T.\text{val}$
- $T.\text{val} = T'.\text{val} * F.\text{val}$
- $T.\text{val} = F.\text{val}$
- $F.\text{val} = E.\text{val}$
- $F.\text{val} = \text{num}.lexval$



# Syntaxí řízený překlad - Příklad na výpočet hodnoty výrazu (3)

$3 * 5 + 4$



Ohodnocený derivační strom



# Syntaxí řízený překlad - Příklad deklarace proměnných (1)

(1) D -> T L

L.type := T.type

(2) T -> int

T.type := integer

(3) T -> real


T.type := real

(4) L -> L' , id

L'.type := L.type  
dcl(id.ptr, L.type)


(5) L -> id

dcl(id.ptr, L.type)



# Syntaxí řízený překlad - Příklad deklarace proměnných (1)

- Dědičné atributy: L.type
- Syntetizované atributy: T.type, id.ptr






# Syntaxí řízený překlad - Příklad syntaxí řízených definic

$E \rightarrow T\ R$

$R \rightarrow +\ T\ \{ \text{print}('+''); \}\ R'$   
|  $\epsilon$

$T \rightarrow \text{num}\ \{ \text{print}(\text{num}.val); \}$



# Syntaxí řízený překlad - Překlad při analýze rekurzivním sestupem (1)

- Syntaktický zásobník - řízení překladu  
Atributový zásobník - ukládání atributů
- Atributy
  - parametry podprogramů  $(N \cup \Sigma)$
  - globální proměnné  $\Delta$



# Syntaxí řízený překlad - Překlad při analýze rekurzivním sestupem (2)

- Atributy
  - dědičné - vstupní parametry
  - syntetizované - výstupní parametry
- Sémantické akce
  - Přímo na odpovídajících místech  
v podprogramech pro analýzu pravidel
- Hodnoty syntetizovaných atributů **musí** být definovány! (e-pravidla, zotavení)



## Syntaxí řízený překlad - Příklad implementace rekurzivním sestupem (1)

$E \rightarrow T \{R.i := T.val\} R \{E.val := R.s\}$

$R \rightarrow \text{addop } T$

{if addop.op=add then  
 $R_1.i := R.i + T.val$   
else  $R_1.i := R.i - T.val\}$

$R_1 \{R.s := R_1.s\}$

|  $\varepsilon \{R.s := R.i\}$

$T \rightarrow \text{num } \{T.val := num.val\}$




## Syntaxí řízený překlad - Příklad implementace rekurzivním sestupem (2)

- addop.op        ...     var lexop:char;     '+'/-'  
num.val        ...     lexval:integer;
- R.i -        dědičný atribut (levý operand)  
R.s -        dočasný výsledek, synt. atribut  
T.val -        syntetizovaný attribute



## Syntaxí řízený překlad - Příklad implementace rekurzivním sestupem (3)

```
void E(int& val) {  
    int val1;  
    T(val1);  
    R(val1, val);  
}
```



## Syntaxí řízený překlad - Příklad implementace rekurzivním sestupem (4)

```
void R(int i, int& s) {  
    if( sym == '+' || sym == '-' ) {  
        char op=lexop;  
        int val;  
        T(val);  
        if( op=='+' ) R(i+val,s)  
            else R(i-val,s);  
    } else  
        s = i;  
}
```



## Syntaxí řízený překlad - Příklad implementace rekurzivním sestupem (5)

```
void T(int& val) {  
    if( sym == num ) {  
        val=lexval; // nestačí expect(num)  
        lex();  
    } else {  
        error(); // po zotavení musí  
        val=0; // být val definováno  
    }  
}
```



# JavaCC - Konstruktor JavaCC

- Generuje lexikální a syntaktický analyzátor v jazyce Java
- Lexikální analýza požívá regulární výrazy
- Syntaktická analýza
  - rekurzivní sestup
  - LL( $k$ ) gramatika
  - Extended BNF - EBNF (rozšířená BNF s regulárními operátory)




# JavaCC - Formát specifikace

```
/* volby generátoru */
options {
    IGNORE_CASE = true; DEBUG_PARSER = true;
}
/* třída analyzátoru */
PARSER_BEGIN(Calc)
public class Calc {
    public static void main(String args[])
        throws ParseException
    { Calc parser = new Calc(System.in);
        parser.expr();
    }
}
PARSER_END(Calc)
```



# JavaCC - Formát specifikace

```
/* lexikální analyzátor */  
SKIP :  
{ " " | "\r" | "\t" }  
TOKEN :  
{ < EOL: "\n" > }  
TOKEN :  
{ <ADD: "+"> | <SUB: "-"> |  
    <MUL: "*"> | <DIV: "/"> | <MOD: "mod"> }  
TOKEN :  
{ <CONSTANT: ( <DIGIT> )+ > |  
    <#DIGIT: ["0" - "9"]> }  
TOKEN :  
{ < SEMICOLON: ";" > }
```



# JavaCC - Formát specifikace

```
/* syntaktický analyzátor */
void expr() : { }
{ term() (( "+" | "-" ) term())* }

void term() : { }
{ factor() (( "*" | "/" | "mod") factor())* }

void factor() : { }
{ <CONSTANT> | "(" expr() ")" }
```



# JavaCC – Spuštění JavaCC

```
D:\home\JavaCC-Book\adder>javacc Calc.jj
Java Compiler Compiler Version 2.1 (Parser Generator)
Copyright (c) 1996-2001 Sun Microsystems, Inc.
Copyright (c) 1997-2001 WebGain, Inc.
(type "javacc" with no arguments for help)
Reading from file adder.jj . . .
File "TokenMgrError.java" does not exist. Will create one.
File "ParseException.java" does not exist. Will create one.
File "Token.java" does not exist. Will create one.
File "SimpleCharStream.java" does not exist. Will create one.
Parser generated successfully.
This generates seven Java classes, each in its own
```

- Hlavní soubor bude Calc.java
- Jde o běžný zdrojový soubor v Javě

# JavaCC – Hodnota lexikálního symbolu



```
int Start() throws NumberFormatException :  
{  
    Token t ;  
    int i ;  
    int value ;  
}{  
    t = <NUMBER>  
    { i = Integer.parseInt( t.image ) ;  
        value = i ; }  
    ( <PLUS> t = <NUMBER>  
        { i = Integer.parseInt( t.image ) ; }  
        { value += i ; }  
    )*  
    <EOF> { return value ; }  
}
```



# Tabulka symbolů - Tabulka symbolů

- Reprezentace pojmenovaných entit
  - explicitně pojmenovaných uživatelem
  - implicitně pojmenovaných – standardní entity (typy, funkce, třídy, ...), dočasné proměnné
- Účel:
  - řešení kontextových vazeb (deklarace -> použití)
  - typová kontrola
  - ukládání informací pro generování kódu



# Tabulka symbolů - Tabulka symbolů

- Interakce s lexikálním analyzátorem
  - ukládání identifikátorů během lexikální analýzy
  - využití kontextových informací
    - Expr -> IdVar Index
      - | IdProc Args
      - | IdCon
    - ...
- PASCAL:  $P(x,y)$       kontextově závislá syntaxe  
 $\text{Write}(x:3,y:2:5)$



# Tabulka symbolů - Funkce tabulky symbolů

- **Operace:**
  - init - inicializace
  - insert - vkládání
  - lookup - vyhledávání (častější)
- **Inicializace**
  - vytvoření prázdné tabulky
  - naplnění implicitními deklaracemi



# Tabulka symbolů - Funkce tabulky symbolů

- **Vkládání** – nejprve vyhledá klíč v tabulce
  - není nalezen → vytvoří se nová položka
  - nalezen → obvykle chyba
    - deklarace / definice
    - implicitní deklarace (**návěští a funkce v C**)
- **Vyhledávání** – vyhledá klíč v tabulce
  - nalezen → vrátí odpovídající entitu
  - nenalezen → obvykle ohlásí chybu



# Tabulka symbolů - Implementace tabulky symbolů (1)

- Neseřazené tabulky  $O(n)$ 
  - jen pro malý počet prvků
- Seřazené tabulky s binárním vyhledáváním  $O(\log_2 n)$ 
  - pro statické tabulky (např. klíčová slova)
- Vyhledávací stromy  $O(n) - O(\log_2 n)$ 
  - doba vyhledávání závisí na vyvážení stromu
  - časová náročnost vkládání není kritická
  - optimálně vyvážené stromy
    - příliš komplikované
  - suboptimální řešení
    - např. AVL stromy



# Tabulka symbolů - Implementace tabulky symbolů (2)

- Tabulky s rozptýlenými položkami  $O(1)$ 
  - mapovací funkce:  $klíč \rightarrow index$
  - řešení kolizí
    - seznamy/stromy synonym
    - rozptylovací funkce:  $index \rightarrow index$
- rychlosť závisí na zaplnení tabulky
- problematický průchod položkami podle klíče
- obtížně se řeší přetečení tabulky



# Tabulka symbolů - Blokově strukturovaná tabulka (1)

- Vhodná pro jazyky se zanořenými deklaracemi (hierarchické struktury)
- Řeší rozsah platnosti a viditelnost jména v zanořených blocích
- Nové operace:
  - otevření rozsahu platnosti (**open**)
  - uzavření rozsahu platnosti (**close**)



# Tabulka symbolů - Blokově strukturovaná tabulka (2)

- Vkládání
  - pracuje pouze s aktuální úrovní tabulky
  - jména na vyšších úrovních se neuvažují
- Vyhledávání
  - klíč se vyhledává nejprve v aktuální úrovni, pokud se nenajde, hledá o úroveň výš
  - neúspěch se hlásí až po prohledání nejvyšší úrovně (globální jména)
  - explicitní přístup na globální úroveň ::x



# Tabulka symbolů - Implementace blokově strukturované tabulky symbolů

- Založena na některé z metod pro nestrukturovanou tabulku
  - vyhledávací stromy
  - tabulky s rozptýlenými položkami
- Přirozenou datovou strukturou pro reprezentaci hierarchie je **ZÁSOBNÍK**
  - Úrovně se nemohou překrývat



# Tabulka symbolů - Příklad

jméno entity	další atributy
8 y	
7 delta	
6 max	
5 num	
4 x	
3 fun	
2 y	
1 x	

index  
bloku

TOP

```
int x,y;
double fun(x,num)
{
    int max;
    ...
    {
        double delta,y;
        ...
    }
}
```



# Struktura programu v době běhu - Obsah

- Vztah mezi zdrojovým programem a činností přeloženého programu
  - reprezentace dat
  - správa paměti
  - aktivace podprogramů
    - parametry
    - rekurze



# Struktura programu v době běhu - Systém řízení běhu programu (1)


- Inicializace programu
  - převzetí parametrů od systému
  - alokace paměti pro data
  - otevření standardních souborů (Pascal)
- Finalizace programu
  - uzavření souborů
  - uvolnění paměti
  - předání stavového kódu



# Struktura programu v době běhu - Systém řízení běhu programu (2)

- Zpracování chyb
  - přerušení a výjimky (definované uživatelem, systémové a aplikační chyby, ...)
  - automatické kontroly (přetečení zásobníku, ukazatele, indexy, parametry, ...)
- Dynamické přidělování paměti
  - zásobník
  - volná paměť
- Komunikace s operačním systémem
  - soubory, čas, ...
- Volací a návratové posloupnosti
- Podpora pro ladění programu

# Struktura programu v době běhu – Podprogramy



- Procedury
  - jméno -> příkaz
- Funkce
  - jméno -> výraz

```
void main() {
    int fib(int n) {
        if( n < 2 ) return 1;
        return fib(n-2) + fib(n-1);
    }
    void print(int n) {
        for(int k = 1; k <= n; k++)
            printf("%d: %d", k, fib(k));
    }
    int max;
    scanf("%d", &max);
    print(max);
}
```



# Struktura programu v době běhu – Definice podprogramu

- Jméno
- Formální parametry (parametry)
  - jméno
  - typ
  - způsob předávání
- Tělo




# Struktura programu v době běhu – Aktivace podprogramu

- Skutečné parametry (argumenty)
- Doba života aktivace
  - od zavolání podprogramu po návrat zpět
  - obvykle se nepřekrývají nebo jsou do sebe vnořeny (výjimka: vlákna, procesy)
- Rekurzivní podprogramy
  - nová aktivace se může spustit před ukončením předcházející




# Struktura programu v době běhu – Úroveň zanoření


- Statická úroveň zanoření
  - je definována zdrojovým programem
  - C, Java – pouze jedna úroveň
- Dynamická úroveň zanoření
  - je definována zanořováním aktivací
  - kolik aktivací je současně rozpracováno
- Úroveň zanoření je dána vzdáleností uzlu od kořene stromu



# Struktura programu v době běhu – Příklad



Statické zanoření





# Struktura programu v době běhu – Lokální data aktivace (1)


- Aktivační záznam
  - lokální proměnné (+dočasné proměnné)
  - návratová adresa
  - uschovaný obsah registrů
- Jazyky bez rekurzivních podprogramů
  - aktivační záznamy mohou být alokovány staticky v době překladu      (**FORTRAN**)
- Jazyky s rekurzivními podprogramy
  - zásobník aktivačních záznamů
  - řídicí zásobník
    - obsahuje všechny aktivační záznamy od kořene stromu aktivací až po aktívni uzel (podprogram)



# Struktura programu v době běhu – Struktura paměti

- Cílový program      program, konstanty
- Statická data      globální a statické proměnné
- Řídicí zásobník      aktivační záznamy  
(lokální proměnné)
- Volná paměť      dynamicky alokovaná paměť  
(hromada – heap)

# Struktura programu v době běhu – Schéma obsazení paměti



Vytváří se  
během  
 inicializace  
programu.

Uloženo ve  
spustitelném  
souboru

Přiděleno  
pro běh  
programu



# Struktura programu v době běhu – Přidělování paměti pro aktivační záznamy (1)

- Statické přidělování paměti
  - adresy všech proměnných jsou známy v době překladu
  - lokální proměnné mohou přežít volání programu (viz static v C)
  - počet a velikost prvků musíme znát v době překladu
  - omezená možnost rekurze (sdílení proměnných)
    - obsahy předchozích aktivačních záznamů můžeme odkládat na zásobník



# Struktura programu v době běhu – Přidělování paměti pro aktivační záznamy (2)

- Přidělování na zásobníku
  - vhodné pro jazyky s rekurzí
  - paměť se přidělí v okamžiku volání
  - uvolnění paměti proběhne při návratu
  - relativní adresování proměnných – offsety jsou známy v době překladu
  - neznáme-li velikost parametrů  
-> **deskriptor [adresa, délka]**
    - Příklad: řetězce, otevřená pole



## Struktura programu v době běhu – Přidělování paměti pro aktivační záznamy (3)

- Přidělování z volné paměti
  - lokální proměnné mohou přežít aktivaci podprogramu, resp. aktivace volaného podprogramu může přežít aktivaci volajícího podprogramu -> **nelze použít zásobník**
  - alokace paměti při inicializaci aktivace, finalizace až ve chvíli, kdy není potřebná
  - implementace paralelních jazyků



# Struktura programu v době běhu – Volací a návratové posloupnosti

- Definice adresy aktivačního záznamu
  - Uložení stavu (registry, příznaky, návratová adresa)
  - Inicializace lokálních dat
- ...
- Uložení výsledku
  - Obnovení předchozího stavu
  - Obnovení adresy aktivačního záznamu volajícího
  - Návrat za místo volání




# Struktura programu v době běhu – Reprezentace datových typů

- Primitivní datové typy:
  - char, int, double
  - výčet, interval – stejně jako int

- Pole



- Záznamy, struktury



**zarovnání**



# Vnitřní reprezentace - Možnosti překladu

- Interpretace
  - Okamžité provádění programu
- Překlad do instrukcí procesoru
  - Závislost na konkrétním typu procesoru
- **Překlad do vnitřní reprezentace**
  - Následuje interpretace nebo překlad do instrukcí procesoru



# Vnitřní reprezentace - Výhody překladu do vnitřní reprezentace


- Strukturalizace překladače
- Mnohem jednodušší přenos na více typů procesorů
- Možnost optimalizace na úrovni vnitřní reprezentace
  - strojově nezávislé metody



# Vnitřní reprezentace - Formáty vnitřní reprezentace programu


- **Grafová reprezentace**
- **Zásobníkový kód**
- **Tříadresový kód**

# Vnitřní reprezentace - Grafová reprezentace



- Abstraktní syntaktický strom (AST)  
 $a := b * (-c) + b * (-c)$

$a := b * (-$




**Uzly - operátory**  
**Listy - operandy**



# Vnitřní reprezentace - Grafová reprezentace


- DAG (Directed Acyclic Graph)

$a := b^* (-c) + b^* (-c)$



**Společné podvýrazy jako sdílené uzly**  
**Používá se pro optimalizaci**


# Vnitřní reprezentace - Grafová reprezentace



- Obecný grafový model
  - OO modelování a návrh

```
var n,f:integer;
begin  read n;
        f:=1;
        while n>1 do begin
            f:=f*n; n:=n-1
        end;
        write f,"\n"
end.
```

# Vnitřní reprezentace - Grafová reprezentace





# Vnitřní reprezentace - Zásobníkový kód

- Postfixová notace

a b c uminus \* b c uminus \* + assign

- výsledek průchodu AST nebo DAG typu post-order
- uzel následuje bezprostředně za svými následníky
- žádný formální rozdíl mezi operandy a operátory



# Vnitřní reprezentace - Zásobníkový kód

- Virtuální zásobníkový procesor

VAR b	(b)	vrchol zás.
VAR c	(b) (c)	
INV	(b) (-c)	
MUL	(b*-c)	
VAR b	(b*-c)(b)	
VAR c	(b*-c)(b)(c)	
INV	(b*-c)(b)(-c)	
MUL	(b*-c)(b*-c)	
ADD	(b*-c+b*-c)	
ASG a		




# Vnitřní reprezentace - Zásobníkový kód

- Virtuální zásobníkový procesor
  - virtuální počítač s pamětí a zásobníkem
  - P-kód (Wirth)
    - přenositelný mezikód pro Pascal
    - specializované procesory
  - Java Virtual Machine
  - MSIL – Microsoft Intermediate Language (.NET)



# Vnitřní reprezentace - Tříadresový kód

- **$x := y \text{ op } z$** 
  - $x$  - (dočasná) proměnná
  - $y, z$  - (dočasné) proměnné, konstanty
- Operandy nemohou být výrazy
  - rozklad na primitivní výrazy s dočasnými proměnnými
- Explicitní odkazy na operandy
  - možnost přesouvání příkazů při optimalizaci



# Vnitřní reprezentace - Příkazy tříadresového kódu

- $x := y \text{ op } z$                           op – binární operátor
- $x := \text{op } y$                           op - unární operátor  
(-, not, typová konverze, ...)
- $x := y$
- goto L                                  nepodmíněný skok
- if  $x \text{ relop } y$  goto L                  podmíněný skok
- $x := y[j]$   
 $x[j] := y$
- $x := \&y$
- $x := *y$   
 $*x := y$                                   indexování  
reference (získání adresy)
- dereference ukazatele



# Vnitřní reprezentace - Příklad


- **a := b \* (-c) + b \* (-c)**
- $$\begin{array}{ll} t1 := -c & t1 := -c \\ t2 := b * t1 & t2 := b * t1 \\ t3 := -c & t5 := t2 + t2 \\ t4 := b * t3 & a := t5 \\ t5 := t2 + t4 & \end{array}$$
- **syntaktický strom DAG**
- dočasné proměnné = (vnitřní) uzly stromu

# Vnitřní reprezentace - Příklad – překlad výrazů (1)




- Atributy
  - *id.name* – jméno identifikátoru
  - *E.place* – proměnná obsahující hodnotu E
- Pomocné funkce
  - *newtemp* – vytvoří novou proměnnou
  - *lookup* – vyhledá proměnnou v tabulce
  - *emit* – generuje instrukci
  - *error* – hlášení chyby

# Vnitřní reprezentace - Příklad – překlad výrazů (2)



- $S \rightarrow id := E$  { `p = lookup(id.name);`  
`if( p != null )`  
`emit(p, ':=' ,E.place) ;`  
`else error(); }`
- $E \rightarrow E_1 + E_2$  { `E.place = newtemp();`  
`emit(E.place, ':=' ,`  
`E1.place, '+' ,E2.place) ; }`
- $E \rightarrow E_1 * E_2$  { `E.place := newtemp();`  
`emit(E.place, ':=' ,`  
`E1.place, '*' ,E2.place) ; }`

# Vnitřní reprezentace - Příklad – překlad výrazů (3)



- $E \rightarrow - E_1$  { **E.place** = newtemp();  
emit(**E.place**, `:=',  
'uminus', **E<sub>1</sub>.place**) ; }
- $E \rightarrow (E_1)$  { **E.place** = **E<sub>1</sub>.place**; }
- $E \rightarrow id$  { **p** := lookup(**id.name**);  
if( **p** != null )  
    **E.place** := **p**;  
else error(); }



# Vnitřní reprezentace - Překlad logických výrazů (1)

- $E \rightarrow E \text{ or } E$ 
  - |  $E \text{ and } E$
  - |  $(E)$
  - | **not**  $E$
  - | id relop id
  - | **true**
  - | **false**



# Vnitřní reprezentace - Překlad logických výrazů (2)

- Reprezentace logických hodnot celými čísly:  
 $\text{true}=1$ ,  $\text{false}=0$

- **a or b and not c**

$t1 := \text{not } c$

$t2 := b \text{ and } t1$

$t3 := a \text{ or } t2$

$x < y$

1: if  $x < y$  goto 4

2:  $t1 := 0$

3: goto 5

4:  $t1 := 1$

5: ...



# Vnitřní reprezentace - Překlad logických výrazů (3)


- Zkrácené vyhodnocení
  - reprezentace logických hodnot pozicí v programu
- **a<b or c<d and e<f**  
    if a<b goto Ltrue  
    goto L1  
L1: if c<d goto L2  
    goto Lfalse  
L2: if e<f goto Ltrue  
    goto Lfalse




# Vnitřní reprezentace - Překlad řídicích příkazů (1)

- Instrukce zásobníkového kódu:
  - LBL – definice návěští pro skok
  - JMP L – nepodmíněný skok na návěští L
  - FJP L - podmíněný skok na návěští L, pokud je na vrcholu zásobníku False
- Pomocné funkce:
  - getLbl() – vygeneruje nové číslo návěští


# Vnitřní reprezentace - Překlad příkazu IF (1)



- $S \rightarrow \text{if} ( E ) S$ 
  - $\langle E \rangle$
  - FJP L1
  - $\langle S \rangle$
  - LBL L1
- $S \rightarrow \text{if} ( E ) \{FJP\} S \{LBL\}$   
 $FJP.I = LBL.I = getLbl();$



# Vnitřní reprezentace - Překlad příkazu IF (2)



- $S \rightarrow \text{if } (\ E\ )\ S^1 \text{ else } S^2$

$S \rightarrow X \{LBL\}$

$LBL.I = X.I$

$S \rightarrow X \{JMP\} \{LBL1\} \text{ else } S \{LBL2\}$

$JMP.I = LBL2.I = getLbl();$

$LBL1.I = X.I$

$X \rightarrow \text{if } (\ E\ )\ \{FJP\}\ S$

$FJP.I = getLbl()$



FJP L1 —



JMP L2 —


L1: ←



L2: ←



# Optimalizace – Možnosti optimalizace




uživatel  
změna algoritmu  
transformace  
profilování

překladač  
strojově  
nezávislé  
optimalizace

překladač  
strojově  
závislé  
optimalizace

„Optimalizace“ = transformace programu směřující ke zlepšení jeho vlastností za běhu (rychlosť, prostor)

# Optimalizace – Možnosti optimalizace



- Optimalizace zdrojového programu
  - často největší vliv – např. změna algoritmu
  - možnost profilování programu
- Strojově nezávislé optimalizace
  - na úrovni vnitřní reprezentace
- Strojově závislé optimalizace
  - na úrovni cílového programu
  - co nejlepší využití instrukční sady procesoru a jeho zdrojů (registry, paměť, ...)



# Optimalizace – Kritéria pro transformace

- musí zachovat význam programu
  - "bezpečný" přístup --- raději neoptimalizovat!
- musí program v průměru významně zrychlit
  - někdy nám jde o velikost paměti
  - v některých případech se může efektivita programu i zhoršit
- musí stát za vynaložené úsilí
  - vyplatí se pro často spouštěné programy



# Optimalizace – Volba vnitřní reprezentace programu pro optimalizaci

- Zásobníkový kód
  - obtížná změna struktury programu
- **Tříadresový kód**
  - explicitně vyjádřené závislosti
  - blízký architektuře RISC i klasickým architekturám procesorů
- Grafová reprezentace
  - grafové transformace, přepisovací systémy



# Optimalizace – Organizace optimalizujícího překladače

- Analýza toku řízení
  - rozdělení programu na základní bloky
  - vytvoření *grafo toku řízení*
- Analýza toku dat
  - živé proměnné
  - dosahující definice
  - dostupné výrazy
- Transformace



# Optimalizace – Základní blok

*Nejdelší posloupnost příkazů s jedním vstupem a jedním výstupem*

- pouze poslední příkaz může být skok
- cílovým místem skoků může být pouze první příkaz bloku
- můžeme jej považovat za jedinou instrukci
- určuje meze lokálních optimalizací
- snížení množství uchovávaných dat
  - např. 16B/instrukci + 8KB/data pro optimalizaci
  - lze ukládat jednou pro základní blok a ostatní dopočítat



# Optimalizace – Typy optimalizací

- Lokální optimalizace
  - na úrovni základního bloku
  - nevyžaduje znalost kontextu
- Globální optimalizace
  - v rámci podprogramů
  - v rámci programu (interprocedurální)



# Optimalizace – Příklady lokálních optimalizací (1)

- odstranění společných podvýrazů  
 $a[i,j] = a[i,j]+1;$
- vyhodnocení konstantních výrazů  
 $a = 2 * 3 + 5;$
- šíření kopií  
 $f = g;$
- šíření konstant  
 $f = 2 * 3; \text{if}( f > 10 ) \dots$



# Optimalizace – Příklady lokálních optimalizací (2)

- odstranění mrtvého kódu

```
debug = false; if (debug) printf("...");  
goto L; x = 10; L: ...
```

- algebraické transformace

$$x * 1 + 0 \Rightarrow x$$

- redukce síly operací

$$x^{**} 2 \Rightarrow x^* x$$
$$5 * x \Rightarrow (x << 2) + x$$
$$\text{length}(x+y) \Rightarrow \text{length}(x)+\text{length}(y)$$

# Optimalizace – Optimalizace cyklů



- přesun kódu mimo cyklus
  - invarianty cyklu lze přesunout před tělo cyklu
- redukce indukčních proměnných
  - generování posloupnosti hodnot
  - např. indexování pole proměnnou cyklu => použití ukazatele na aktuální prvek
- PROBLÉM: detekce cyklů



# Optimalizace – Globální optimalizace programu

- překladač potřebuje informace o programu jako celku
  - obtížně proveditelné v modulárních programech
  - často jen v rámci jednoho podprogramu (intraprocedurální optimalizace)
- tyto informace se připojují k základním blokům

# Optimalizace – Příklady globálních optimalizací



- využití informací o *živosti proměnných* k přidělování registrů a ke kontrole správné inicializace proměnných
- odstranění redundantních výpočtů analýzou společných *podvýrazů*
- šíření konstant pomocí *dosahujících definic*
- nahrazení volání podprogramu jeho tělem (otevřené podprogramy – *inline*)



# Generování cílového kódu - Činnost generátoru



- vytvoření sémanticky ekvivalentního programu
- výběr ‘optimální’ varianty



# Generování cílového kódu -

## Cílový jazyk (1)

- Absolutní strojový kód
  - nejfektivnější výstup
  - program se musí přeložit celý najednou (složitá vazba na knihovny)
  - vhodné pro malé programy, výukové překladače, specializované procesory
- Přemistitelný strojový kód
  - běžné používaný v klasických překladačích
  - nutnost použití sestavovacího programu



# Generování cílového kódu - Cílový jazyk (2)

- Jazyk symbolických instrukcí
  - jednoduché generování
    - adresové výpočty, makroinstrukce
  - vyžaduje další dva průchody asembleru
- Jazyk virtuálního procesoru
  - Java VM
  - .NET MSIL



# Generování cílového kódu - Požadavky na generátor cílového programu

- Rychlý překlad -> rychlé algoritmy
- Bezpečný kód -> kontroly v době běhu
- Dobrá detekce chyb za běhu
- Vlízký vztah mezi zdrojovým a cílovým programem -  
  > jednodušší ladění
- Efektivita cílového programu (rychlosť+velikost)
- *Protichůdné požadavky!*

# Generování cílového kódu - Řešení



- Sada překladačů - spíš historie
  - IBM FORTRAN - FORTRAN H
  - PL/I      Checkout compiler - diagnostika  
                Full compiler  
                Optimizing compiler
- Parametrizovatelný překladač
  - Zapnutí/vypnutí optimalizací
  - Výběr prováděných optimalizací



# Generování cílového kódu - Klasické metody generování cílového programu

- Princip
  - dekompozice prvků jazyka na nezávislé podproblémy (např. součet dvou hodnot)
  - každý podproblém řešíme tou nejfektivnější metodou
- Implementace
  - sada procedur pro konkrétní podproblémy