

IA039: Architektura superpočítačů a náročné výpočty

Překladače

Luděk Matyska

Fakulta informatiky MU

Jaro 2014

Opakování – RICS procesory

- limitovaný počet instrukcí, jednotná délka
- jednoduché adresní módy, load/store, hodně registrů
- delay branches, branch prediction, out-of-order execution
- superskalární (MIPS – 2xFPU, 2xALU, adresace)
- superpipeline (ANDES)
- vyrovnávací paměti

Optimalizující překladač

- překlad do mezijazyka
- optimalizace
 - meziprocedurální analýza
 - optimalizace cyklů
 - globální optimalizace
- generování kódu
 - využití všech jednotek

- Čtveřice (obecně **n**-tice)
 - Instrukce: operátor, dva operandy, výsledek
 - Příklad
 - Přiřazení: $X := Y \text{ op } Z$
 - Paměť: přes dočasné proměnné **tn**
 - Skoky: podmínka počítána samostatně
 - Skoky: na absolutní adresy

Základní překlad

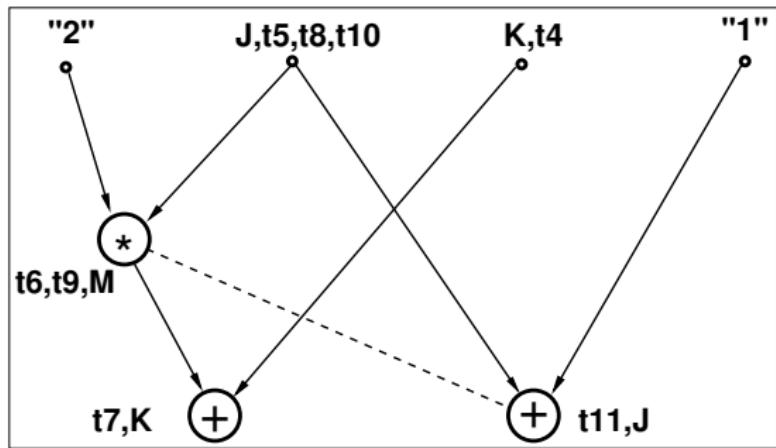
```
while ( j < n ) {  
    k = k + j*2  
    m = j*2  
    j++  
}  
A:: t1 := j                      m   := t9  
      t2 := n                      t10 := j  
      t3 := t1 < t2                t11 := t10+1  
      jmp (B) t3                  j     := t11  
      jmp (C) TRUE                jmp (A) TRUE  
B:: t4 := k                      C::  
      t5 := j  
      t6 := t5*2  
      t7 := t4+t6  
      k  := t7  
      t8 := j  
      t9 := t8*2
```

Základní bloky

- Program je pak reprezentován *grafem toku* (flow graph)
- Blok –část programu bez skoků
 - Jeden vstupní a jeden výstupní bod
 - Blok jako DAG (Directed Acyclic Graph)
- Optimalizace uvnitř bloků
 - Odstranění opakovaných (pod)výrazů
 - Odstranění přebytečných proměnných

Directed Acyclic Graph

```
B:: t4 := k  
     t5 := j  
     t6 := t5*2  
     t7 := t4+t6  
     k := t7  
     t8 := j  
     t9 := t8*2  
     m := t9  
     t10 := j  
     t11 := t10+1  
     j := t11  
     jmp (A) TRUE
```



Modifikovaný překlad

```
B:: t4 := k  
     t5 := j  
     t6 := t5*2  
     t7 := t4+t6  
     k := t7  
     t8 := j  
     t9 := t8*2  
     m := t9  
     t10 := j  
    t11 := t10+1  
    j := t11  
jmp (A) TRUE
```

```
B:: t4 := k  
     t5 := j  
     t6 := t5*2  
     m := t6  
     t7 := t6+t4  
     k := t7  
     t11 := t5+1  
     j := t11  
jmp (A) TRUE
```

Další pojmy

- *Proměnné*
 - Definice a místa použití
- *Cykly*
- Proces generování cílového kódu
 - Součástí tzv. peephole optimalizace

Optimalizovaný překlad

A:: t1 := j	A:: t1 := j
t2 := n	t2 := n
t3 := t1 < t2	t4 := k
jmp (B) t3	t9 := m
jmp (C) TRUE	t12 := t1+t1
B:: t4 := k	t3 := t1 >= t2
t5 := j	jmp (B1) t3
t6 := t5*2	B:: t4 := t4+t12
t7 := t4+t6	t9 := t12
k := t7	t1 := t1+1
t8 := j	t12 := t12+2
t9 := t8*2	t3 := t1 < t2
m := t9	jmp (B) t3
t10 := j	B1:: k := t4
t11 := t10+1	m := t9
j := t11	C::
jmp (A) TRUE	
C::	

Klasické optimalizace

- Propagace kopírováním

- Příklad:

$$X = Y$$

$$Z = 1. + X$$

 \implies

$$X = Y$$

$$Z = 1. + Y$$

- Zpracování konstant

- propagace konstant

- Odstranění mrtvého kódu

- nedosažitelný kód

- šetření cache pro instrukce

Klasické optimalizace II

- Strength reduction

- Příklad: $K^{**2} \implies K*K$

- Přejmenování proměnných

- Příklad

$$x = y*z;$$

$$q = r+x+x;$$

$$x = a+b$$

 \implies

$$x0 = y*z;$$

$$q = r+x0+x0;$$

$$x = a+b$$

- Odstraňování společných podvýrazů (podstatné zejména pro výpočet adres prvků polí)

Klasické optimalizace III

- Přesun invariantního kódu z cyklů
- Zjednodušení indukčních proměnných (výrazů s)
 - A(I) je většinou počítáno jako:
$$\text{address} = \text{base_address}(A) + (I-1)*\text{sizeof_datatype}(A)$$
což lze snadno v lineárním cyklu převést na
mimo cyklus:
$$\text{address} = \text{base_address}(A) - \text{sizeof_datatype}(A)$$
v cyklu:
$$\text{address} = \text{address} + \text{sizeof_datatype}(A)$$
- Přiřazení registrů proměnným

Odstraňování smetí

- Podprogramy, makra
 - Inlining
- Podmíněné výrazy
 - Reorganizace složitých výrazů
 - Nadbytečné testy (`if` versus `case`)
- Podmíněné výrazy uprostřed cyklů
 - Nezávislé na cyklu
 - Závislé na cyklu
 - Nezávislé na iteraci
 - Závislé mezi iteracemi

Podmíněné výrazy – příklad

```
DO I=1,K  
IF (N .EQ 0) THEN  
    A(I)=A(I)+B(I)*C  
ELSE  
    A(I)=0  
ENDIF
```



```
IF (N .EQ 0) THEN  
    DO I=1,K  
        A(I)=A(I)+B(I)*C  
    CONTINUE  
ELSE  
    DO I=1,K  
        A(I)=0  
    CONTINUE  
ENDIF
```

Odstraňování smetí II

- Redukce

- min (nebo max):

```
for(i=0;i<n;i++)  
    z=(a[i] > z) ? a[i] : z;
```

- jak obejít rekurzivní závislost:

```
for(i=0;i<n-1;i+=2) {  
    z0=(a[i] > z0) ? a[i] : z0;  
    z1=(a[i+1] > z1) ? a[i+1] : z1;  
}  
z=(z0 < z1) ? z1 : z0;
```

Redukce – Asociativní transformace

- Numerická nepřesnost:
4 platná desetinná místa

$$(X + Y) + Z = (.00005 + .00005) + 1.0000 \\ .00010 + \quad \quad \quad + 1.0000 = 1.0001$$

ale

$$X + (Y + Z) = .00005 + (.00005 + 1.0000) = \\ .00005 \quad \quad \quad + 1.0000 = 1.0000$$

- Redukce

```
DO I=1,N  
SUM=SUM+A(I)*B(I)
```

Redukce s rekurzivní závislostí – můžeme použít stejný trik jako u min redukce?

Odstraňování smetí III

- Skoky
- Konverze typů

```
REAL*8 A(1000)  
REAL*4 B(1000)  
DO I 1=1,1000  
A(I)=A(I)*B(I)
```

- Ruční optimalizace
 - Společné podvýrazy
 - Přesun kódu
 - Zpracování polí (inteligentní překladač, C a ukazatele)

Optimalizace cyklů

- Cíle:

- Redukce režie
- Zlepšení přístupu k paměti (cache)
- Zvýšení paralelismu

Datové závislosti I

- **Flow Dependencies** (backward dependencies)

- Příklad:

$$\begin{array}{ccc} \text{DO } I=2, N & \implies & \text{DO } I=2, N, 2 \\ A(I) = A(I-1) + B(I) & & A(I) = A(I-1) + B(I) \\ & & A(I+1) = A(I-1) + B(I) + B(I+1) \end{array}$$

- **Anti-Dependencies**

- Standardně přejmenování proměnných
- Příklad

$$\begin{array}{ccc} \text{DO } I=1:N & & \text{DO } I=1:N \\ A(I) = B(I) * E & \implies & A'(I) = B(I) * E \\ B(I) = A(I+2) * C & & \text{DO } I=1:N \\ & & B(I) = A(I+2) * C \\ & & \text{DO } I=1:N \\ & & A(I) = A'(I) \end{array}$$

Datové závislosti II

- **Output Dependencies**

- Příklad:

$$A(I) = C(I) * 2$$

$$A(I+2) = D(I) + E$$

- V cyklu je vypočteno několik hodnot konkrétní proměnné, zapsat však lze pouze tu „poslední“
 - Může být problém zjistit, která je ta „poslední“

Rozvoj cyklů (loop unrolling) I

- Tělo cyklu se několikrát zkopíruje:

```
DO I=1,N
```

```
    A(I)=A(I)+B(I)*C
```



```
DO I=1,N,4
```

```
    A(I)=A(I)+B(I)*C
```

```
    A(I+1)=A(I+1)+B(I+1)*C
```

```
    A(I+2)=A(I+2)+B(I+2)*C
```

```
    A(I+3)=A(I+3)+B(I+3)*C
```

Rozvoj cyklů (loop unrolling) II

- Hlavní smysl
 - Snížení režie
 - Snížení počtu průchodů cyklem
 - Zvýšení paralelizace (i v rámci jednoho procesoru)
 - Software pipelining
 - Pre- a postconditioning loops
 - Adaptace na skutečný počet průchodů

Rozvoj cyklů (loop unrolling) III

- Nevhodné cykly

- Malý počet iterací —> úplný rozvoj cyklů
- „Tlusté“ (=velké) cykly: samy obsahují dostatek příležitostí k paralelizaci
- Cykly s voláním procedur: souvislost s rozvojem procedur (inlining)
- Cykly s podmíněnými výrazy: spíše starší typy procesorů
- „Rekurzivní“ cykly: cykly s vnitřními závislostmi
$$(a[i]=a[i]+a[i-1]*b)$$

Problémy s rozvojem cyklů

- Rozvoj špatným počtem iterací
- Zahlcení registrů
- Výpadky vyrovnávací paměti instrukcí (příliš velký cyklus)
- Hardwarové problémy
 - Především na multiprocesorech se sdílenou pamětí (cache koherence, přetížení sběrnice)
- Speciální případy: rozvoj vnějších cyklů, spojování cyklů

Spojování cyklů

- opakované použití dat
- větší tělo cyklu
- komplilátor zvládne sám, pokud mezi cykly není jiný kód

```
for(i=0;i<n;i++)  
    a[i]=b[i]+1  
  
for(i=0;i<n;i++)  
    c[i]=a[i]/2  
  
for(i=0;i<n;i++)  
    d[i]=1/c[i+1]
```



```
a[0]=b[0]+1  
c[0]=a[0]/2  
for(i=1;i<n;i++) {  
    a[i]=b[i]+1  
    c[i]=a[i]/2  
    d[i-1]=1/c[i]  
}  
d[n]=1/c[n+1]
```

Rozvoj vnějších cyklů

- Příklad

```
DO I=1,N  
    DO J=1,N  
        A(I)=A(I)+B(I,J)*C(J)
```

- $A(I)$ je v vnitřním cyklu konstanta, $C(J)$ se prochází správně
- $B(I,J)$ se ve Fortranu prochází opačně!

```
DO I=1,N,4  
    DO J=1,N  
        A(I+0)=A(I+0)+B(I+0,J)*C(J)  
        A(I+1)=A(I+1)+B(I+1,J)*C(J)  
        A(I+2)=A(I+2)+B(I+2,J)*C(J)  
        A(I+3)=A(I+3)+B(I+3,J)*C(J)
```

Optimalizace přístupů k paměti

- Optimální: nejmenší krok (práce s cache)
- Práce s maticemi – C vs. Fortran
 - C: ukládá po řádcích, nejrychleji se mění pravý index
 - Fortran: ukládá po sloupcích, nejrychleji se mění levý index
- Obrácení indexu
 - Příklad:

```
DO I=1,N  
  DO 10 J=1,N  
    A(I,J)=B(I,J)+C(I)*D  
  
          ==>  
DO J=1,N  
  DO 10 I=1,N  
    A(I,J)=B(I,J)+C(J)*D
```

Optimalizace přístupů k paměti II

- Skládání do bloků

- Příklad:

```
DO I=1,N
```

```
    DO 10 J=1,N
```

```
        A(J,I)=A(J,I)+B(I,J)
```

↓

```
DO I=1,N,2
```

```
    DO 10 J=1,N,2
```

```
        A(J,I)=A(J,I)+B(I,J)
```

```
        A(J+1,I)=A(J+1,I)+B(I,J+1)
```

```
        A(J,I+1)=A(J,I+1)+B(I+1,J)
```

```
        A(J+1,I+1)=A(J+1,I+1)+B(I+1,J+1)
```

Optimalizace přístupů k paměti III

- Nepřímá adresace
 - Příklad:
$$b[i] = a[i+k]*c, \text{ hodnota } k \text{ neznáma při překladu}$$
$$a[k[i]] += b[i]*c$$
- Použití ukazatelů
- Nedostatečná kapacita paměti
 - „Ruční“ zpracování
 - Virtuální paměť