Helmut Seidl

Programmoptimierung

TU München

Wintersemester 2006/07

Organisatorisches

Termine:

Vorlesung:	Montag, 12-14
	Dienstag, 12-14
Übung:	Freitag, 10-12
	Alex Berlea: `berlea@in.tum.de`
Materialien:	Folien, Aufzeichnung :-)
	Literatur :-))
	Vorlesungs-Mitschrift (in Überarbeitung)

Schein:

- 50% der Aufgaben
- zweimal vorrechnen :-)

Geplanter Inhalt:

1. Vermeidung überflüssiger Berechnungen

   $\longrightarrow$ verfügbare Ausdrücke

   $\longrightarrow$ Konstantenpropagation/Array-Bound-Checks

   $\longrightarrow$ Code Motion

2. Ersetzen teurer Berechnungen durch billige

   $\longrightarrow$ Peep Hole Optimierung

   $\longrightarrow$ Inlining

   $\longrightarrow$ Reduction of Strength

   ...

3. Anpassung an Hardware

- $\longrightarrow$ Instruktions-Selektion
- $\longrightarrow$ Registerverteilung
- $\longrightarrow$ Scheduling
- $\longrightarrow$ Speicherverwaltung

0 Einführung

Beobachtung 1: Intuitive Programme sind oft ineffizient.

Beispiel:

```
void swap (int i, int j) {
     int t;
     if (a[i] > a[j]) {
          t = a[j];
          a[j] = a[i];
          a[i] = t;
         }
     }
```

Ineffizienzen:

- Adressen `a[i]`, `a[j]` werden je dreimal berechnet :-(
- Werte `a[i]`, `a[j]` werden zweimal geladen :-(

Verbesserung:

- Gehe mit Pointer durch das Feld `a`;
- speichere die Werte von `a[i]`, `a[j]` zwischen!

```
void swap (int *p, int *q) {
     int t, ai, aj;
     ai = *p; aj = *q;
     if (ai > aj) {
         t = aj;
         *q = ai;
         *p = t;    // t kann auch noch
        }           // eingespart werden!
     }
```

Beobachtung 2:

Höhere Programmiersprachen (sogar C :-) abstrahieren von Hardware und Effizienz.

Aufgabe des Compilers ist es, den natürlich erzeugten Code an die Hardware anzupassen.

Beispiele:

- ... Füllen von Delay-Slots;
- ... Einsatz von Spezialinstruktionen;
- ... Umorganisation der Speicherzugriffe für besseres Cache-Verhalten;
- ... Beseitigung (unnötiger) Tests auf Overflow/Range.

Beobachtung 3:

Programm-Verbesserungen sind nicht immer korrekt :-(

Beispiel:

```
y = f() + f();
```

$\Longrightarrow$

```
y = 2 * f();
```

Idee: Spare zweite Auswertung von `f()` ...

Beobachtung 3:

Programm-Verbesserungen sind nicht immer korrekt :-(

Beispiel:

```
y = f() + f();
```

$\Longrightarrow$

```
y = 2 * f();
```

Idee: Spare zweite Auswertung von `f()` ???

Problem: Die zweite Auswertung könnte ein anderes Ergebnis liefern als die erste (z.B. wenn `f()` aus der Eingabe liest :-)

Folgerungen:

$\Longrightarrow$ Optimierungen haben Voraussetzungen.

$\Longrightarrow$ Die Voraussetzungen muss man:

- formalisieren,
- überprüfen :-)

$\Longrightarrow$ Man muss beweisen, dass die Optimierung korrekt ist, d.h. die Semantik erhält !!!

Beobachtung 4:

Optimierungs-Techniken hängen von der Programmiersprache ab:

$\longrightarrow$ welche Ineffizienzen auftreten;

$\longrightarrow$ wie gut sich Programme analysieren lassen;

$\longrightarrow$ wie schwierig / unmöglich es ist, Korrektheit zu beweisen ...

Beispiel: Java

Unvermeidbare Ineffizienzen:

* Array-Bound Checks;
* dynamische Methoden-Auswahl;
* bombastische Objekt-Organisation ...

Analysierbarkeit:

+ keine Pointer-Arithmetik;
+ keine Pointer in den Stack;
− dynamisches Klassenladen;
− Reflection, Exceptions, Threads, ...

Korrektheitsbeweise:

+ mehr oder weniger definierte Semantik;
− Features, Features, Features;
− Bibliotheken mit wechselndem Verhalten ...

... in der Vorlesung:

eine einfache imperative Sprache mit:

- Variablen // Register
- $R = e;$ // Zuweisungen
- $R_1 = M[R_2];$ // Laden
- $M[R_1] = R_2;$ // Speichern
- if (e) s_1 else s_2 // bedingte Verzweigung
- goto $L;$ // keine Schleifen :-)

Beachte:

- Vorerst verzichten wir auf Prozeduren :-)
- Externe Funktionen berücksichtigen wir, indem wir als Ausdruck e auch $f(R_1, \ldots, R_k)$ gestatten für eine unbekannte Funktion f.

  $\Longrightarrow$ intra-prozedural

  $\Longrightarrow$ eine Art Zwischensprache, in die man (fast) alles übersetzen kann.

Beispiel: `swap()`

$$
\begin{array}{lllll}
0: & A_1 & = & A_0 + 1 * i; & // \quad A_0 == \&a \\
1: & R_1 & = & M[A_1]; & // \quad R_1 == a[i] \\
2: & A_2 & = & A_0 + 1 * j; & \\
3: & R_2 & = & M[A_2]; & // \quad R_2 == a[j] \\
4: & \multicolumn{4}{l}{\text{if } (R_1 > R_2)\ \{} \\
5: & & A_3 & = & A_0 + 1 * j; \\
6: & & t & = & M[A_3]; \\
7: & & A_4 & = & A_0 + 1 * j; \\
8: & & A_5 & = & A_0 + 1 * i; \\
9: & & R_3 & = & M[A_5]; \\
10: & & M[A_4] & = & R_3; \\
11: & & A_6 & = & A_0 + 1 * i; \\
12: & & M[A_6] & = & t; \\
 & & \multicolumn{4}{l}{\}}
\end{array}
$$

Optimierung 1: $1 * R \Longrightarrow R$

Optimierung 2: Wiederbenutzung von Teilausdrücken

$$A_1 == A_5 == A_6$$
$$A_2 == A_3 == A_4$$

$$M[A_1] == M[A_5]$$
$$M[A_2] == M[A_3]$$

$$R_1 == R_3$$

Damit erhalten wir:

$$
\begin{array}{lcl}
A_1 & = & A_0 + i; \\
R_1 & = & M[A_1]; \\
A_2 & = & A_0 + j; \\
R_2 & = & M[A_2]; \\
\text{if } (R_1 > R_2) \ \{ & & \\
\qquad t & = & R_2; \\
\qquad M[A_2] & = & R_1; \\
\qquad M[A_1] & = & t; \\
\qquad \} & &
\end{array}
$$

Optimierung 3: Verkürzung von Zuweisungsketten :-)

Ersparnis:

	vorher	nachher
$+$	6	2
$*$	6	0
load	4	2
store	2	2
$>$	1	1
$=$	6	2

1 Vermeidung überflüssiger Berechnungen

1.1 Mehrfach-Berechnungen

Idee:

Wird der gleiche Wert mehrfach berechnet, dann

$\rightarrow$ speichere ihn nach der ersten Berechnung;

$\rightarrow$ ersetze jede weitere Berechnung durch Nachschlagen!

$\Longrightarrow$ Verfügbarkeit von Ausdrücken

$\Longrightarrow$ Memoisierung

Problem: Erkenne Mehrfach-Berechnungen!

Beispiel:

$$
\begin{array}{lrcl}
 & z & = & 1; \\
 & y & = & \mathsf{read}(); \\
A: & x_1 & = & \boxed{y+z}; \\
 & & \dots & \\
B: & x_2 & = & \boxed{y+z};
\end{array}
$$

Achtung:

B ist eine Mehrfach-Berechnung des Werts von $\boxed{y + z}$, falls:

(1) A stets vor B ausgeführt wird; und

(2) y und z an B die gleichen Werte haben wie an A :-)

$\Longrightarrow$ Wir benötigen

$\rightarrow$ eine operationelle Semantik :-)

$\rightarrow$ ein Verfahren, das einige Mehrfach-Berechnungen erkennt ...

Exkurs 1: Eine operationelle Semantik

Wir wählen einen small-step operationellen Ansatz.

Programme repräsentieren wir als Kontrollfluss-Graphen.

Im Beispiel:

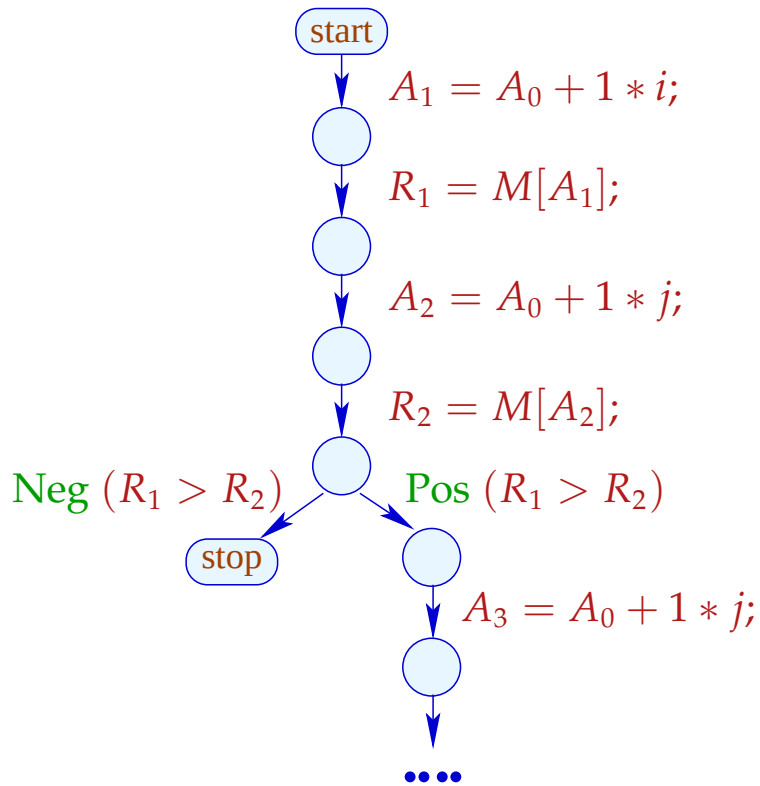

Dabei repräsentieren:

Knoten	Programm-Punkt
start	Programm-Anfang
stop	Programm-Ende
Kante	Berechnungs-Schritt

Dabei repräsentieren:

Knoten	Programm-Punkt
start	Programm-Anfang
stop	Programm-Ende
Kante	Berechnungs-Schritt

Kanten-Beschriftungen:

Test :	Pos (e) oder Neg (e)
Zuweisung :	$R = e;$
Load :	$R_1 = M[R_2];$
Store :	$M[R_1] = R_2;$
Nop :	$;$

Berechnungen folgen Pfaden.

Berechnungen transformieren den aktuellen Zustand

$$s = (\rho, \mu)$$

wobei:

$\rho : Vars \to \mathbf{int}$	Inhalt der Register
$\mu : \mathbb{N} \to \mathbf{int}$	Inhalt des Speichers

Jede Kante $k = (u, lab, v)$ definiert eine partielle Transformation

$$[\![k]\!] = [\![lab]\!]$$

des Zustands:

$$
\begin{aligned}
[\![;]\!]\,(\rho,\mu) &= (\rho,\mu) \\
[\![\mathrm{Pos}\,(e)]\!]\,(\rho,\mu) &= (\rho,\mu) && \text{falls } [\![e]\!]\,\rho \neq 0 \\
[\![\mathrm{Neg}\,(e)]\!]\,(\rho,\mu) &= (\rho,\mu) && \text{falls } [\![e]\!]\,\rho = 0
\end{aligned}
$$

$$
\begin{array}{lcll}
[\![;]\!]\,(\rho,\mu) & = & (\rho,\mu) & \\
[\![\mathrm{Pos}\,(e)]\!]\,(\rho,\mu) & = & (\rho,\mu) & \text{falls } [\![e]\!]\,\rho \neq 0 \\
[\![\mathrm{Neg}\,(e)]\!]\,(\rho,\mu) & = & (\rho,\mu) & \text{falls } [\![e]\!]\,\rho = 0
\end{array}
$$

// $[\![e]\!]$: Auswertung des Ausdrucks e, z.B.

// $[\![x+y]\!]\,\{x \mapsto 7, y \mapsto -1\} = 6$

// $[\![!(x == 4)]\!]\,\{x \mapsto 5\} = 1$

$$
\begin{aligned}
[\![;]\!]\,(\rho,\mu) &= (\rho,\mu) \\
[\![\mathrm{Pos}\,(e)]\!]\,(\rho,\mu) &= (\rho,\mu) && \text{falls } [\![e]\!]\,\rho \neq 0 \\
[\![\mathrm{Neg}\,(e)]\!]\,(\rho,\mu) &= (\rho,\mu) && \text{falls } [\![e]\!]\,\rho = 0
\end{aligned}
$$

// $[\![e]\!]$: Auswertung des Ausdrucks e, z.B.

// $[\![x+y]\!]\,\{x \mapsto 7, y \mapsto -1\} = 6$

// $[\![!(x == 4)]\!]\,\{x \mapsto 5\} = 1$

$$
[\![R = e;]\!]\,(\rho,\mu) = (\boxed{\rho \oplus \{R \mapsto [\![e]\!]\,\rho\}}, \mu)
$$

// wobei "$\oplus$" eine Abbildung an einer Stelle ändert