

Compiler II: Datenflussanalyse

Andreas Koch

FG Eingebettete Systeme und ihre Anwendungen
Informatik, TU Darmstadt

Sommersemester 2012

Organisatorisches

Ab jetzt auszugsweise Material aus

Advanced Compiler Design and Implementation

von Steven S. Muchnick, erschienen 1997 bei
Morgan-Kaufman

1. Beispiel: Copy Propagation

- Viele Algorithmen legen Zwischenvariablen an
 - $a := x + y; t1 := a;$
- Zwischenvariablen
 - benötigen viel Speicher, viele Register
 - verursachen viele Kopieranweisungen $y := x$
 - sind in vielen Fällen unnötig

➔ Beseitigen durch

- 1 Copy Propagation (→ Muchnick 12.5)
- 2 Dead Code Elimination

- Versuche zur Compile-Zeit Aussagen über Laufzeitverhalten zu machen
 - “Simulation” des Programmes
- Falls möglich, benutze immer Originalvariable statt Kopie
 - Eingabe: `a:=x+y; b:=x+y;`
 - Nach SSA/Red.Elim./AST: `a:=x+y; t1:=a; b:=t1;`
 - Nach CP: `a:=x+y; t1:=a; b:=a;`
 - Nach Dead Code-Elimination: `a:=x+y; b:=a;`
- Vorgehen
 - Stelle fest, wenn Originalvariablen zwischen ihrer Berechnung ...
 - ... und Ihrer Verwendung **nicht** überschrieben werden

Speichere: Zuordnung von Originalvariablen w an Kopien v
für eine Zuweisung $v := w$

A. Koch

Tupel (v, w)

- Zielvariable v
- Originalvariable w

ACP (*available copies*)

Die Menge der verfügbaren Kopieranweisungen **ACP** sind all die (v, w) , bei denen weder v noch w zwischen Definition und der betrachteten Stelle des Programmes überschrieben wurden.

Realisierung von ACP bestimmt Gesamtlaufzeit des Verfahrens abhängig von Anzahl der Kopieranweisungen n .

- Lineare Suche: $O(n^2)$
- Baumstruktur: $O(n \log n)$
- Hash: $O(n)$

Hilfsfunktion: Liefere zu verwendenden Operand für `opnd`,
ggf. ausgetauscht durch eine in ACP vorhandene
Originalvariable

A. Koch

```
func Copy_Value(opnd, ACP) : Var
  Operand          opnd;
  Set<Pair<Var,Var>> ACP; // Menge der (v,w)
begin
  Pair<Var,Var> acp;      // ein (v,w)
  foreach acp in ACP do
    if opnd.kind == VARIABLE && opnd.name == acp.first() then
      return acp.second(); // gefunden, verwende Originalvar.
    endif
  endfor
  return opnd.name; // Ziel nicht gefunden, alter Opnd. zurück
end
```

Hilfsfunktion: Entferne eine überschriebene Variable v aus ACP

A. Koch

```
proc Remove_ACP(ACP, varname)
  var Set<Pair<Var,Var>> ACP;
      Var varname;
begin
  Set<Pair<Var,Var>> temp = ACP.copy(); // Löschen bei Iterat.
  Pair<Var,Var> acp;                // Paar (v,w)
  foreach acp in temp do
    if acp.first() == varname || acp.second() == varname then
      ACP.remove(acp);
    endif
  endfor
end
```

1. Beispiel: Copy Propagation

- Viele Algorithmen legen Zwischenvariablen an
 - $a := x + y; t1 := a;$
- Zwischenvariablen
 - benötigen viel Speicher, viele Register
 - verursachen viele Kopieranweisungen $y := x$
 - sind in vielen Fällen unnötig

➡ Beseitigen durch

- 1 Copy Propagation (→ Muchnick 12.5)
- 2 Dead Code Elimination

- Versuche zur Compile-Zeit Aussagen über Laufzeitverhalten zu machen
 - “Simulation” des Programmes
- Falls möglich, benutze immer Originalvariable statt Kopie
 - Eingabe: `a:=x+y; b:=x+y;`
 - Nach SSA/Red.Elim./AST: `a:=x+y; t1:=a; b:=t1;`
 - Nach CP: `a:=x+y; t1:=a; b:=a;`
 - Nach Dead Code-Elimination: `a:=x+y; b:=a;`
- Vorgehen
 - Stelle fest, wenn Originalvariablen zwischen ihrer Berechnung ...
 - ... und Ihrer Verwendung **nicht** überschrieben werden

Speichere: Zuordnung von Originalvariablen w an Kopien v
für eine Zuweisung $v := w$

A. Koch

Tupel (v, w)

- Zielvariable v
- Originalvariable w

ACP (*available copies*)

Die Menge der verfügbaren Kopieranweisungen **ACP** sind all die (v, w) , bei denen weder v noch w zwischen Definition und der betrachteten Stelle des Programmes überschrieben wurden.

Realisierung von ACP bestimmt Gesamtlaufzeit des Verfahrens abhängig von Anzahl der Kopieranweisungen n .

- Lineare Suche: $O(n^2)$
- Baumstruktur: $O(n \log n)$
- Hash: $O(n)$

Hilfsfunktion: Liefere zu verwendenden Operand für `opnd`,
ggf. ausgetauscht durch eine in ACP vorhandene
Originalvariable

A. Koch

```
func Copy_Value(opnd, ACP) : Var
  Operand          opnd;
  Set<Pair<Var,Var>> ACP; // Menge der (v,w)
begin
  Pair<Var,Var> acp;      // ein (v,w)
  foreach acp in ACP do
    if opnd.kind == VARIABLE && opnd.name == acp.first() then
      return acp.second(); // gefunden, verwende Originalvar.
    endif
  endfor
  return opnd.name; // Ziel nicht gefunden, alter Opnd. zurück
end
```


Hilfsfunktion: Entferne eine überschriebene Variable v aus ACP

A. Koch

```
proc Remove_ACP(ACP, varname)
  var Set<Pair<Var,Var>> ACP;
      Var varname;
begin
  Set<Pair<Var,Var>> temp = ACP.copy(); // Löschen bei Iterat.
  Pair<Var,Var> acp;                // Paar (v,w)
  foreach acp in temp do
    if acp.first() == varname || acp.second() == varname then
      ACP.remove(acp);
    endif
  endfor
end
```

Algorithmus für Lokale CP 3

Lesendes Auftreten von Variablen

```
proc Local_Copy_Prop(b)
  Block b;
begin
  Set<Pair<Var,Var>> ACP = Set.empty();
  Instruction i;
  foreach i in b.instructions() do
    if (i instanceof Expression) then // verwendendes Auftreten
      if (i == "a + b") then // Bin.Exp.
        i.opnds.a.name := Copy_Value(i.opnds.a.name, ACP);
        i.opnds.b.name := Copy_Value(i.opnds.b.name, ACP);
      else if (i == "-a") then // Un.Exp.
        i.opnds.a.name := Copy_Value(i.opnds.a.name, ACP);
      else if (i == "f(a)") then // List.Exp.
        i.opnds.a.name := Copy_Value(i.opnds.a.name, ACP);
      else if ... // andere lesende Instruktionsarten
      endif
    else
      ... // schreibendes Auftreten
    endif
  endfor
end
```

A. Koch

Algorithmus für Lokale CP 4

Schreibendes Auftreten von Variablen

```
proc Local_Copy_Prop(b)
  Block b;
begin
  Set<Pair<Var,Var>> ACP = Set.empty();
  Instruction i;
  foreach i in b.instructions() do
    if (i instanceof Expression) then // verwendendes Auftreten
      ...
    else if (i == "LHS := RHS") then // Zuweisung
      // Zuweisungen zerstören bestehende Kopien, Ausnahme:
      // triviale Kopien a:=a zerstören keine (*,a) (a,*)
      if (LHS != RHS)
        Remove_ACP(ACP, i.LHS.name); // entferne übersch. Var.
      endif
      if (RHS instanceof Var && LHS != RHS) then // Kopie?
        ACP.add(new Pair(LHS, RHS));
      endif
    endif
  endforeach
end
```

Beispiel Lokale CP

Position	Code Before	ACP	Code After
		\emptyset	
1	$b \leftarrow a$		$b \leftarrow a$
		$\{\langle b, a \rangle\}$	
2	$c \leftarrow b + 1$		$c \leftarrow a + 1$
		$\{\langle b, a \rangle\}$	
3	$d \leftarrow b$		$d \leftarrow a$
		$\{\langle b, a \rangle, \langle d, a \rangle\}$	
4	$b \leftarrow d + c$		$b \leftarrow a + c$
		$\{\langle d, a \rangle\}$	
5	$b \leftarrow d$		$b \leftarrow a$
		$\{\langle d, a \rangle, \langle b, a \rangle\}$	

- Basiert auf Datenflussanalyse
 - Welche Kopieranweisungen erreichen Verwendungen ihrer LHS intakt?
 - **Intakt:** Weder LHS noch RHS überschrieben!
- Erweiterte Darstellung (v, w, b, p)
 - b ist Block der Zuweisung $v := w$
 - p ist Position der Zuweisung $v := w$ innerhalb des Blockes b (z.B. Nummer der Anweisung)

COPY(b)


Menge der (v, w, b, p) , bei denen bei einer Kopieranweisung $v := w$ im Block b weder v noch w vor Ende des Blockes Ziel einer Zuweisung sind.

KILL(b)

Menge der (t, u, d, q) mit $d \neq b$, bei denen t und/oder u in Block d Ziel einer Zuweisung sind.

Beispiel: COPY und KILL

Beispiel



Mengen

$COPY(entry)$	$= \emptyset$
$COPY(B1)$	$= \{(d, c, B1, 2)\}$
$COPY(B2)$	$= \{(g, e, B2, 2)\}$
$COPY(B3)$	$= \emptyset$
$COPY(B4)$	$= \emptyset$
$COPY(B5)$	$= \emptyset$
$COPY(B6)$	$= \emptyset$
$COPY(exit)$	$= \emptyset$
$KILL(entry)$	$= \emptyset$
$KILL(B1)$	$= \{(g, e, B2, 2)\}$
$KILL(B2)$	$= \emptyset$
$KILL(B3)$	$= \emptyset$
$KILL(B4)$	$= \emptyset$
$KILL(B5)$	$= \emptyset$
$KILL(B6)$	$= \{(d, c, B1, 2)\}$
$KILL(exit)$	$= \emptyset$

A. Koch

CPIN(b)

Menge von Kopieranweisungen (t, u, d, q) , die zu Beginn des Blocks b intakt sind.

CPOUT(b)

Menge von Kopieranweisungen (t, u, d, q) , die am Ende eines Blocks b intakt sind.

Vorgehensweise bei Aufstellen der Gleichungen

A. Koch

- Nur solche Kopieranweisungen sind am Anfang eines Blockes verfügbar ...
- ... die an **allen** Enden von Vorgängern verfügbar waren
- Startwerte für iterative Lösung
 - $CPIN(entry)$: Startblock hat keine Kopieranweisungen zur Verfügung
 - $CPIN(b), b \neq entry$: Alle anderen Blöcke haben **alle** in der ganzen Prozedur auftretenden Kopieranweisungen zur Verfügung
 - Wird schrittweise eingeschränkt

$$\text{CPIN}(b) = \bigcap_{d \in \text{pred}(b)} \text{CPOUT}(d)$$

$$\text{CPOUT}(b) = \text{COPY}(b) \cup (\text{CPIN}(b) - \text{KILL}(b))$$

mit Initialisierung

$$\text{CPIN}(\text{entry}) = \emptyset$$

$$\text{CPIN}(b) = \bigcup_{d \in \text{Blocks}} \text{COPY}(d) \text{ ,für } b \neq \text{entry}$$

Beispiel: Initialisierung

COPY(entry) = \emptyset
COPY(B1) = $\{\langle d, c, B1, 2 \rangle\}$
COPY(B2) = $\{\langle g, e, B2, 2 \rangle\}$
COPY(B3) = \emptyset
COPY(B4) = \emptyset
COPY(B5) = \emptyset
COPY(B6) = \emptyset
COPY(exit) = \emptyset


CPIN(entry) = \emptyset
CPIN(B1) = $\{\langle d, c, B1, 2 \rangle, \langle g, e, B2, 2 \rangle\}$
CPIN(B2) = $\{\langle d, c, B1, 2 \rangle, \langle g, e, B2, 2 \rangle\}$
CPIN(B3) = $\{\langle d, c, B1, 2 \rangle, \langle g, e, B2, 2 \rangle\}$
CPIN(B4) = $\{\langle d, c, B1, 2 \rangle, \langle g, e, B2, 2 \rangle\}$
CPIN(B5) = $\{\langle d, c, B1, 2 \rangle, \langle g, e, B2, 2 \rangle\}$
CPIN(B6) = $\{\langle d, c, B1, 2 \rangle, \langle g, e, B2, 2 \rangle\}$
CPIN(exit) = $\{\langle d, c, B1, 2 \rangle, \langle g, e, B2, 2 \rangle\}$

```
worklist := cfg.getBlocks();  
  
while ( worklist.notEmpty() ) {  
    b := worklist.removeFirst();  
    recompute CPin(b);  
    recompute CPout(b);  
    if (CPout(b) changed)  
        worklist.add(b.getSuccessors());  
}
```

Beispiel: Ergebnis der iterativen Berechnung

Rot: CPIN, Blau: CPOUT

A. Koch




- Werte berechnete Daten nun pro Block aus
- Vorgehen: `Local_Copy_Prop` beginnt nun **nicht** mehr mit leerer ACP-Menge
- ... sondern: Initialisiere ACP-Menge für Block b aus $CP_{IN}(b)$
- Analog zu: VN auf EBB und Region (DVNT), \rightarrow 7. Block

Beispiel: Ergebnis der globalen CP

Rot: CPIN, Blau: CPOUT

A. Koch



2. Beispiel: Konstanten propagieren

(Zu) Einfaches Verfahren

- *Constant Propagation*
- Weiterführung von Constant Folding
- Nun hinweg über Anweisungsgrenzen und Merge Points
- Darstellung durch Paare (v, c)
 - v ist Variable
 - c ist entweder Konstante, oder \perp (unbekannter Wert)
- $\mathbf{CONSTANTS}(b)$ sind alle bisher gesammelten Aussagen zu Beginn des Blocks b
- Damit darstellbar:
 - v ist unbekannt: $(v, \dots) \notin \mathbf{CONSTANTS}(b)$
 - v ist konstant mit Wert c : $(v, c) \in \mathbf{CONSTANTS}(b)$
 - v ist variabel: $(v, \perp) \in \mathbf{CONSTANTS}(b)$

- Initialisieren
 - $\text{CONSTANTS}(\text{entry}) = \{(p_1, \perp), (p_2, \perp), \dots\}$ für alle Funktions/Prozedur-Parameter p_n
 - $\text{CONSTANTS}(b) = \emptyset$ für $b \neq \text{entry}$
- Dann in Reihenfolge Anweisungen in jedem Block b untersuchen

A. Koch

Für $x := y$

```
if  $(x, c_1) \in \text{CONSTANTS}(b)$  do  
     $\text{CONSTANTS}(b) := \text{CONSTANTS}(b) - \{(x, c_1)\}$   
if  $(y, c_2) \in \text{CONSTANTS}(b)$  do  
     $\text{CONSTANTS}(b) := \text{CONSTANTS}(b) \cup \{(x, c_2)\}$ 
```

Für $x := y \text{ op } z$

if $(x, c) \in \text{CONSTANTS}(b)$ **do**

$\text{CONSTANTS}(b) := \text{CONSTANTS}(b) - \{(x, c)\}$

if $(y, c_1) \in \text{CONSTANTS}(b) \wedge (z, c_2) \in \text{CONSTANTS}(b)$ **do**

$\text{CONSTANTS}(b) := \text{CONSTANTS}(b) \cup \{(x, c_1 \text{ op } c_2)\}$

else // *Pessimismus*

$\text{CONSTANTS}(b) := \text{CONSTANTS}(b) \cup \{(x, \perp)\}$

- Mit $\perp \text{ op } x = x \text{ op } \perp = \perp$
- Analog $x := y \text{ op } \text{Const}$.
- Hier auch Sonderregeln möglich
 - $c \cdot 0 = 0, c - c = 0, c \cdot 1 = c, \dots$
- Transformation von $\text{CONSTANTS}(b)$ in Block b :
 $\text{CONSTANTS}_{\text{out}}(b) = F_b(\text{CONSTANTS}_{\text{in}}(b))$

Bei Überschreiten von Blockgrenzen:
Mehrere Aussagen zu v aus verschiedenen Vorgängern
treffen zusammen

A. Koch

Konfluenzoperator ist \wedge (*meets*, Infimum, Durchschnitt) über
alle Vorgängermengen $C_{out,d}$

Definition: Meets-Operator, angewandt für jedes v

- 1 Wenn nur in einem $C_{out,d}$ eine Aussage (v, \dots) vorkommt: **Ergebnis** (v, \dots)
- 2 Wenn in mehreren $C_{out,d}$ Aussagen $(v, c_1), (v, c_2), (v, c_3)$ etc. vorkommen
 - Wenn alle c_n gleich: **Ergebnis** (v, c_1)
 - Sonst: **Ergebnis** (v, \perp)


Damit vorwärtsgerichtetes Datenflußproblem formulierbar:

$$\text{CONSTANTS}(b) = \bigwedge_{d \in \text{preds}(b)} F_d(\text{CONSTANTS}(d))$$

Konstanten propagieren 6

Beispiel: Initialisierung


A. Koch



Konstanten propagieren 7

Beispiel: Schritt 1


A. Koch



Konstanten propagieren 8

Beispiel: Schritt 2


A. Koch



Konstanten propagieren 9

Beispiel: Fixpunkt

A. Koch



- $\text{CONSTANTS}(b)$ kann groß werden, ist aber endlich
- Relevanz
 - Hier nur Beispiel für ungewöhnlicheres DF-Problem
- Besser: Sparse Conditional Constant Propagation
 - Ignoriert Einfluß nicht-ausführbarer Blöcke

Iterative Datenflussanalyse

- **Treffe Aussagen**
 - ... über Laufzeitverhalten von Programm
 - ... zur Compile-Zeit
- **Mittel der Wahl**
 - Gleichungssysteme
 - Lösungsverfahren: Hier iterative, gibt aber auch andere
- **Anwendung**
 - Finde Anwendungsstellen von Optimierungen
 - Beweise, das Anwendung sicher ist

Weiteres Beispiel: *Live Variables*

Live Variables

Live Variable

Eine Variable v ist *lebendig* (*live*) an einer Stelle p im Programm genau dann, wenn es im CFG einen Pfad von p zu einer Verwendung von v gibt, auf dem v *nicht* definiert wird.

- Nur live Variables müssen in Prozessorregistern gehalten werden
- Können bei der SSA-Konstruktion zur Eliminierung von Phi-Funktionen dienen
- Können zur Erkennung von uninitialisierten Variablen dienen
 - Lokale Variable ist live bei Prozedureintritt
- Können Basis direkter Optimierungen sein
 - Store-Anweisungen nur für live Variables, überflüssig für andere

LIVEOUT(b)

Menge aller Variablen, die bei **Austritt** aus Block b live sind.

A. Koch

Damit Berechnung durch Gleichungssystem.

1. Teil

$\text{LIVEOUT}(b_n) = \emptyset$, mit b_n Endknoten des CFG

Bei Prozedurende sind alle (lokalen) Variablen nicht mehr live.

- Beschränkung auf Prozedurebene
- Bei uns vereinfacht: Parameter nicht betrachtet

2. Teil: Rekursive Definition für innere Knoten

$$\text{LIVEOUT}(b) = \bigcup_{m \in \text{succ}(b)} \text{UEVAR}(m) \cup (\text{LIVEOUT}(m) \cap \overline{\text{VAR KILL}(m)})$$

- Rechnet **rückwärts** von Nachfolger zu Vorgängerknoten
- $\text{UEVAR}(m)$ (*upwards exposed*): Vor ihrer Definition in Block m benutzte Variablen
- $\text{VAR KILL}(m)$ sind alle im Block m definierten Variablen

$$\text{LIVEOUT}(b) = \bigcup_{m \in \text{succ}(b)} \text{UEVAR}(m) \cup (\text{LIVEOUT}(m) \cap \overline{\text{VARKILL}(m)})$$

A. Koch

- $\text{LIVEOUT}(m)$ sind alle Variablen, die live am Anfang von Nachfolgerblöcken m sind
- Variable muss nur auf **einem** Pfad live sein ($\rightarrow \cup$)
- Jeder Nachfolgerknoten m trägt Variablen bei
 - In m benutzte Variablen, die vorher nicht redefiniert werden ($\text{UEVAR}(m)$)
 - Variablen die
 - m selbst live verlassen ($\text{LIVEOUT}(m)$)
 - ... und in m nicht redefiniert werden ($\text{VARKILL}(m)$)

- 1 CFG aufbauen
 - Kennen wir bereits, für strukturierte Sprachen einfach
 - Falls nötig um einen eindeutigen Endknoten anreichern
- 2 Per-Block Daten vorberechnen (UEVAR und VARKILL)
- 3 Iterativen Fixpunkt-Algorithmus für LIVEOUT anwenden

$UEVAR(b) := \emptyset$
 $VARKILL(b) := \emptyset$


```
for  $i := 1$  to number of operations in block  $b$  do  
  parse operation  $i$  into “ $LHS := RHS$ ”  
  for  $v \in$  variables referenced in  $RHS$  do  
    if  $v \notin VARKILL(b)$  then  
       $UEVAR(b) := UEVAR(b) \cup \{v\}$   
       $VARKILL(b) := VARKILL(b) \cup \{variable(LHS)\}$ 
```

A. Koch

Hier vereinfacht: Nur Zuweisungen in Block
Analoges Vorgehen für andere Operationen, unterscheide

- Lesen (RHS) von Variablen
- Schreiben (LHS) von Variablen

Live Variables - Beispiel 1



	B_0	B_1	B_2	B_3	B_4	B_5	B_6	B_7
UEVAR	\emptyset	\emptyset	\emptyset	\emptyset	\emptyset	\emptyset	\emptyset	$\{a, b, c, d, i\}$
$\overline{\text{VARKILL}}$	$\{a, b, c, d, y, z\}$	$\{b, d, i, y, z\}$	$\{a, i, y, z\}$	$\{b, c, i, y, z\}$	$\{a, b, c, i, y, z\}$	$\{a, b, d, i, y, z\}$	$\{a, c, d, i, y, z\}$	$\{a, b, c, d\}$

```
 $N := \text{number of blocks} - 1$   
for  $i := 0$  to  $N$  do  
    LIVEOUT( $i$ ) :=  $\emptyset$   
    changed := true  
    while changed do  
        changed := false  
        for  $i := 0$  to  $N$  do  
            recompute LIVEOUT( $i$ )  
            if LIVEOUT( $i$ ) changed then  
                changed := true
```


Live Variables - Beispiel 2

LIVEOUT(b) =

$$\bigcup_{m \in \text{succ}(b)} \text{UEVAR}(m) \cup (\text{LIVEOUT}(m) \cap \overline{\text{VARKILL}(m)})$$

A. Koch

	B_0	B_1	B_2	B_3	B_4	B_5	B_6	B_7
UEVAR	\emptyset	\emptyset	\emptyset	\emptyset	\emptyset	\emptyset	\emptyset	$\{a, b, c, d, i\}$
VARKILL	$\{a, b, c, d, y, z\}$	$\{b, d, i, y, z\}$	$\{a, i, y, z\}$	$\{b, c, i, y, z\}$	$\{a, b, c, i, y, z\}$	$\{a, b, d, i, y, z\}$	$\{a, c, d, i, y, z\}$	$\{a, b, c, d\}$



Quelle: C&T, pp.442-443

Iteration	LIVEOUT(n)							
	B_0	B_1	B_2	B_3	B_4	B_5	B_6	B_7
0	\emptyset	\emptyset	\emptyset	\emptyset	\emptyset	\emptyset	\emptyset	\emptyset
1	\emptyset	\emptyset	$\{a, b, c, d, i\}$	\emptyset	\emptyset	\emptyset	$\{a, b, c, d, i\}$	\emptyset
2	\emptyset	$\{a, i\}$	$\{a, b, c, d, i\}$	\emptyset	$\{a, c, d, i\}$	$\{a, c, d, i\}$	$\{a, b, c, d, i\}$	$\{i\}$
3	$\{i\}$	$\{a, i\}$	$\{a, b, c, d, i\}$	$\{a, c, d, i\}$	$\{a, c, d, i\}$	$\{a, c, d, i\}$	$\{a, b, c, d, i\}$	$\{i\}$
4	$\{i\}$	$\{a, c, i\}$	$\{a, b, c, d, i\}$	$\{a, c, d, i\}$	$\{a, c, d, i\}$	$\{a, c, d, i\}$	$\{a, b, c, d, i\}$	$\{i\}$
5	$\{i\}$	$\{a, c, i\}$	$\{a, b, c, d, i\}$	$\{a, c, d, i\}$	$\{a, c, d, i\}$	$\{a, c, d, i\}$	$\{a, b, c, d, i\}$	$\{i\}$

Diskussion

Vor Benutzung berücksichtigen:

- Terminiert die Analyse?
- Beantwortet das berechnete Ergebnis die gestellte Frage?
- Wie schnell läuft die Analyse?

Im folgenden Diskussion am Beispiel LIVEOUT.

- LIVEOUT Mengen wachsen monoton, beginnend bei \emptyset
- Sie können nie schrumpfen
- Bei maximaler Größe umfasst eine LIVEOUT-Menge **alle** Variablen
- Da es nur endlich viele Variablen gibt, sind die LIVEOUT-Mengen beschränkt
- Die Iteration bricht also nach endlicher Zeit immer ab
 - Irgendwann ändert sich nichts mehr
 - Worst-case: Alle LIVEOUT-Mengen umfassen alle Variablen

- LIVEOUT berechnet lokale Eigenschaft
 - Zwischen Block und seinen Nachfolgern
- Vereinigt Ergebnisse der Nachfolger
 - Wenn v live auf irgendeiner Nachfolgekante ist, dann v in LIVEOUT
- Kann Zusammenhang zwischen lokalen Eigenschaften und der Definition von Live Variables hergestellt werden?
 - Diese ist ja über alle Pfade definiert!
- Beweis über Verbandalgebra (*lattice algebra*)
 - Hier nicht behandelt (\rightarrow Kam/Ullman JACM 1976)

- Überlegung: Das Ergebnis der iterativen Lösung des Datenflußproblems ist **unabhängig** von der Bearbeitungsreihenfolge der Blöcke
- Die Reihenfolge beeinflusst aber die nötige Anzahl von Iterationen
- Also: Suche nach schnellerer Abarbeitungsreihenfolge
- Idee: Bei Vorgehen ...
 - ... rückwärts (LIVEOUT): Besuche so viele **Nachfolger** eines Knotens wie möglich, bevor der Knoten selbst besucht wird

Verschiedene Möglichkeiten für Abarbeitungsreihenfolgen

- Vorwärts: z.B. Breadth-First-Search, aber besser **Reverse Post-Order** (RPO)

A. Koch

Beispiel: Reverse Post-Order



Step1: PostOrder

```
proc main() ≡  
  count ← 1  
  Visit(Entry)  
end
```

```
proc Visit(v) ≡  
  mark v as visited  
  foreach successor s of v not yet visited  
    Visit(s)  
  end  
  PostOrder(v) ← count++  
end
```

Step 2: rPostOrder

```
foreach v ∈ V do  
  rPostOrder(v) ← |V| - PostOrder(v)  
end
```




Effizienz der Datenflußanalyse 3

Rückwärts

- z.B. Depth-First Search
- besser RPO auf **reversem CFG** (Kanten umgekehrt)

A. Koch



Post-Order auf rev. CFG: $B_0, B_1, B_2, B_3, B_5, B_4, B_6, B_7$

RPO auf rev. CFG: $B_7, B_6, B_5, B_4, B_2, B_3, B_1, B_0$

Abspeichern als Permutation in Array $P = [7, 6, 5, 4, 2, 3, 1, 0]$

A. Koch

```
 $N$  := number of blocks - 1
for  $i$  := 0 to  $N$  do
  LIVEOUT( $i$ ) :=  $\emptyset$ 
  changed := true
  while changed do
    changed := false
    for  $i$  := 0 to  $N$  do
      recompute LIVEOUT( $P[i]$ )
      if LIVEOUT( $P[i]$ ) changed then
        changed := true
```

Effizienz der Datenflußanalyse 5


LIVEOUT(b) =

$$\bigcup_{m \in \text{succ}(b)} \text{UEVAR}(m) \cup (\text{LIVEOUT}(m) \cap \overline{\text{VARKILL}(m)})$$

A. Koch

	B_0	B_1	B_2	B_3	B_4	B_5	B_6	B_7
UEVAR	\emptyset	\emptyset	\emptyset	\emptyset	\emptyset	\emptyset	\emptyset	$\{a, b, c\}$ $\{d, i\}$
$\overline{\text{VARKILL}}$	$\{a, b, c, d, y, z\}$	$\{b, d, i, y, z\}$	$\{a, i, y, z\}$	$\{b, c, i, y, z\}$	$\{a, b, c, i, y, z\}$	$\{a, b, d, i, y, z\}$	$\{a, c, d, i, y, z\}$	$\{a, b, c, d\}$

Reihenfolge: B7, B6, B5, B4, B2, B3, B1, B0




Iteration	LIVEOUT(n)							
	B_0	B_1	B_2	B_3	B_4	B_5	B_6	B_7
0	\emptyset	\emptyset	\emptyset	\emptyset	\emptyset	\emptyset	\emptyset	\emptyset
1	$\{i\}$	$\{a, c, i\}$	$\{a, b, c, d, i\}$	$\{a, c, d, i\}$	$\{a, c, d, i\}$	$\{a, c, d, i\}$	$\{a, b, c, d, i\}$	\emptyset
2	$\{i\}$	$\{a, c, i\}$	$\{a, b, c, d, i\}$	$\{a, c, d, i\}$	$\{a, c, d, i\}$	$\{a, c, d, i\}$	$\{a, b, c, d, i\}$	$\{i\}$
3	$\{i\}$	$\{a, c, i\}$	$\{a, b, c, d, i\}$	$\{a, c, d, i\}$	$\{a, c, d, i\}$	$\{a, c, d, i\}$	$\{a, b, c, d, i\}$	$\{i\}$

Konvergiert jetzt in 3 Iterationen (statt 5)!

- Fundamentale Annahme bei Datenflußberechnung:
- **Alle** Blöcke können ausgeführt werden

Gegenbeispiel zur Annahme 1



- **x** ist Live in B0, da es in B1 gelesen werden kann
- **x** wird aber in B2 Killed
- Falls B1 nie ausgeführt wird, ist **x** nicht Live außerhalb von B0

Falls der Compiler beweisen kann, dass immer $y \geq x \dots$

- würde die Anweisung $z := x+3$ nie ausgeführt werden
- Falls dann auch noch der Aufruf $f(17)$ keine Seiteneffekte hat
- ... können Blocks B0 und B1 komplett entfernt werden

Kann aber nicht allgemein gelöst werden (\rightarrow Halteproblem)!

- LIVEOUT: Wird immer über **alle** Nachfolger berechnet
- Berechnet wird so nur eine **Zusammenfassung** der tatsächlich möglichen Abläufe

Probleme bei Arrays

- Zugriff $\mathbf{A}[i, j, k]$ auf ein einzelnes Element
- Datenflussanalyse kennt aber keine konkreten Werte für i, j, k
- Abstraktion: Betrachte **gesamtes** Array als **eine** Variable
 - $\dots := \mathbf{A}[i, j, k]$ zählt als Verwendung des **gesamten** Arrays
 - $\mathbf{A}[i, j, k] := \dots$ zählt als Definition des **gesamten** Arrays

Benutzung dieser ungenauen Ergebnisse muß **konservativ** erfolgen!

A. Koch

- Fehlabschätzungen dürfen Korrektheit der Analyse in Bezug auf die gesuchte Aussage nicht beeinflussen
- Beispiele
 - Kann der Wert von $A[i, j, k]$ nach Schreibzugriff auf $A[1, m, n]$ verworfen werden?
 - ... Nein, denn der Schreibzugriff KILLED **nicht** notwendigerweise $A[i, j, k]$!
 - Könnte der Wert von $A[i, j, k]$ nach Schreibzugriff auf $A[1, m, n]$ beschädigt werden?
 - ... Ja, denn der Schreibzugriff **könnte** jedes Element von A verändern!

Analoge Problematik bei Zeigern

A. Koch

- Zuweisung via Zeiger kann potentiell **jede** Variable beeinflussen
- Kann weite Teile der Datenflussanalyse unbrauchbar machen
- Wird schlimmer bei Adressarithmetik (wie in C)
 - Nun nicht nur auf einzelne Variablen, sondern beliebig im Speicher
- Wird etwas besser bei fester Typisierung (keine Wandlung möglich)
 - Nun nur noch Variablen vom Typ des Zeigers betroffen

Prozeduren

A. Koch

- Auch bei Beschränkung der Analyse auf eine Prozedur
 - Jeder Prozeduraufruf **kann** verändern (abhängig von Sprache):
 - Nur Var-Parameter
 - Nicht-Lokale Variablen
 - Globale Variablen
 - Bei Unterstützung von Zeigern: Gesamten Speicherinhalt
 - Unterprozeduren verkomplizieren die Situation noch
- ➔ Analyse muss “worst case” Annahmen machen

Sammlung von Datenflußproblemen

- Available Expressions
- $AVAIL(b)$: Menge der Ausdrücke, die Block b erreichen
- Genauer im VL-Block: Redundanzeliminierung
- **Vorwärtsgerichteter** Fluß über berechnete **Ausdrücke**
- Konkrete Anwendung:
Global Common Subexpression Elimination


Eine Definition d einer Variablen v **erreicht** eine Operation i genau dann, wenn v in i gelesen wird und v auf einem Pfad von d zu i **nicht** redefiniert wird.

- $\text{REACHES}(b)$: Menge der Definitionen, die Block b erreichen.
- **Vorwärtsgerichteter** Fluß über **Zuweisungen an Variablen**
- *Reaching Definitions*

Erreichende Definitionen 2

DEDEF(b) (*downward exposed definitions*): Definitionen in b , die nicht vor Blockende überschrieben werden

A. Koch



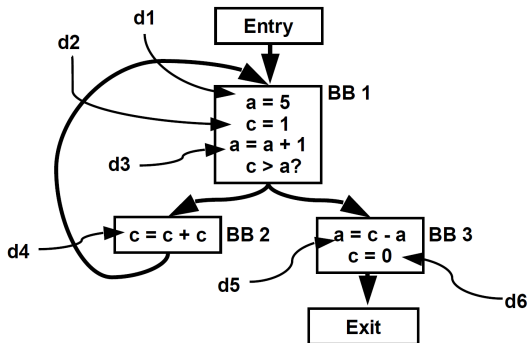
$$\text{DEDEF}(BB1) = \{d2, d3\}$$

$$\text{DEDEF}(BB2) = \{d4\}$$

$$\text{DEDEF}(BB3) = \{d5, d6\}$$

$DEFKILL(b)$: Im Block b überschriebene Definitionen anderer Blöcke aus der Menge **aller** Definitionen in der Prozedur

A. Koch



$$DEFKILL(BB1) = \{d5, d4, d6\}$$

$$DEFKILL(BB2) = \{d2, d6\}$$

$$DEFKILL(BB3) = \{d1, d3, d2, d4\}$$

Datenflußgleichungen

$$\text{REACHES}(b_0) = \emptyset$$


$$\text{REACHES}(b) = \bigcup_{d \in \text{preds}(b)} (\text{DEDEF}(d) \cup (\text{REACHES}(d) \cap \overline{\text{DEFKILL}(d)}))$$

- Lösung mit iterativem Fixpunktverfahren
- Startwerte: $\text{REACHES}(b) = \emptyset$ für alle b

Anwendungsbeispiel: Anweisung $x := y + z$
in Schleifen-Body b

A. Koch

- Falls alle $\text{REACHES}(b)$ für y und z **außerhalb** der Schleife
- ... kann gesamte Berechnung von x **vor** die Schleife gezogen werden
- Loop-Invariant Code Motion



Sehr Rege (*very busy*)

A. Koch


Ein Ausdruck e ist **sehr rege** am Ende eines Blocks b , wenn er in allen Nachfolgern von b evaluiert und benutzt wird, und das einmalige Evaluieren von e am Ende von b das gleiche Ergebnis hätte wie die erstmalige Evaluation von e in den Nachfolgern von b .

- $\text{VERYBUSY}(b)$: Menge der **Ausdrücke**, die am Ende von b sehr rege sind
- **Rückwärtsgerichteter** Fluß über **Ausdrücke**
- *Very Busy Expressions*

Sehr rege Ausdrücke 2

$UEEXPR(b)$ (*upwards exposed expressions*): In b **vor** Überschreiben ihrer Operanden benutzte Ausdrücke.

A. Koch



$$UEEXPR(BB1) = \emptyset$$

$$UEEXPR(BB2) = \{c + d\}$$

$$UEEXPR(BB3) = \{a + c, c + d\}$$


$$UEEXPR(BB4) = \{a + b, a + c\}$$

$$UEEXPR(BB5) = \{a + b, a + d\}$$

Sehr rege Ausdrücke 3

EXPRKILL(b): Im Block b durch Überschreiben der Operanden unbrauchbar gemachte Ausdrücke

A. Koch



$$\text{EXPRKILL}(BB1) =$$

\emptyset

$$\text{EXPRKILL}(BB2) =$$

$\{a + d, c + d\}$

$$\text{EXPRKILL}(BB3) =$$

\emptyset

$$\text{EXPRKILL}(BB4) =$$

\emptyset

$$\text{EXPRKILL}(BB5) =$$

\emptyset

Datenflußgleichungen

$$\text{VERYBUSY}(b_n) = \emptyset$$

$$\text{VERYBUSY}(b) =$$

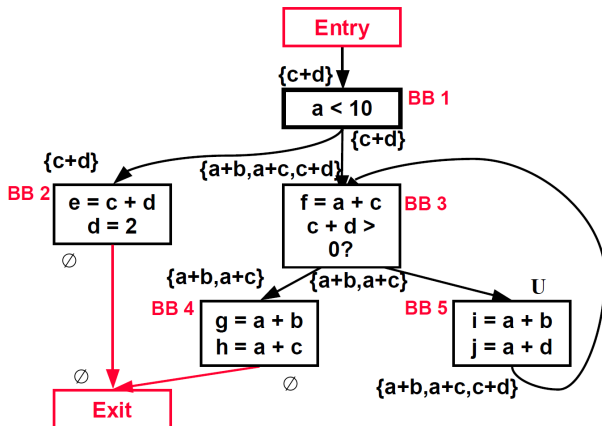
$$\bigcap_{d \in \text{succ}(b)} (\text{UEEXPR}(d) \cup (\text{VERYBUSY}(d) \cap \overline{\text{EXPRKILL}(d)}))$$

- Lösung mit iterativem Fixpunktverfahren
- Startwert für $b \neq b_n$: $\text{VERYBUSY}(b) = U$, mit U Menge **aller** Ausdrücke in Prozedur

Sehr rege Ausdrücke 5

Konkretes Beispiel

A. Koch



- Anwendung zur Optimierung: Code Hoisting
- Ersetze Evaluationen der sehr regen Ausdrücke in Nachfolgern
- ... durch eine Evaluation in Vorgänger
- Macht Code nicht (direkt) schneller, aber **kleiner**

Verallgemeinerung

Ein Pfad-Vorwärts: Reaching definitions

$$\text{REACHES}(b) = \bigcup_{d \in \text{preds}(b)} (\text{DEDEF}(d) \cup (\text{REACHES}(d) \cap \overline{\text{DEFKILL}(d)}))$$

A. Koch

Ein Pfad-Rückwärts: Live variables

$$\text{LIVEOUT}(b) = \bigcup_{m \in \text{succ}(b)} (\text{UEVAR}(m) \cup (\text{LIVEOUT}(m) \cap \overline{\text{VARKILL}(m)}))$$

Alle Pfade-Vorwärts: Available expressions (\rightarrow Redundanzelim.)

$$\text{AVAIL}(b) = \bigcap_{d \in \text{preds}(b)} (\text{DEEXPR}(d) \cup (\text{AVAIL}(d) \cap \overline{\text{EXPRKILL}(d)}))$$

Alle Pfade-Rückwärts: Very busy expressions

$$\text{VERYBUSY}(b) = \bigcap_{d \in \text{succ}(b)} (\text{UEEXPR}(d) \cup (\text{VERYBUSY}(d) \cap \overline{\text{EXPRKILL}(d)}))$$

- Sehr ähnliche Struktur der Gleichungen
 - $f(x) = c_1 \text{ op}_1 (x \text{ op}_2 c_2)$
- Wie ausnutzen?
- Lösung **aller** solcher Datenflußprobleme
- **Data Flow Framework**
- Akzeptiert $c_1, c_2, \text{op}_1, \text{op}_2$, Konfluenzoperator als Parameter
- Lösen dann für Fixpunkt
- Vorteil: Nur ein Algorithmus muß mit viel Sorgfalt implementiert werden
- Kann dann alle vergleichbaren Probleme lösen

Es gibt aber auch Datenflußprobleme mit anderer Struktur!

Zusammenfassung

- Aufräumen nach Optimierung: Copy Propagation
- Iterative Datenflußanalyse
 - Live Variables
 - Erreichende Definitionen
 - Sehr rege Ausdrücke
 - Konstanten propagieren
- Diskussion
 - Reihenfolge
 - Schwächen
 - Gemeinsamkeiten