Compiler II: Redundanzeliminierung

Andreas Koch

FG Eingebettete Systeme und ihre Anwendungen
Informatik, TU Darmstadt

Sommersemester 2012

Organisatorisches

Organisatorisches

- Ab jetzt vorgehen nach Cooper & Torczon 1E
  - Daraus ab jetzt auch die meisten Zeichnungen
- Geplant: Behandele Kapitel 8-10
- Unterstützt durch Papers
  - Werden als PDF auf Web-Seite gelegt

Einleitung

Auswirkung von Optimierung

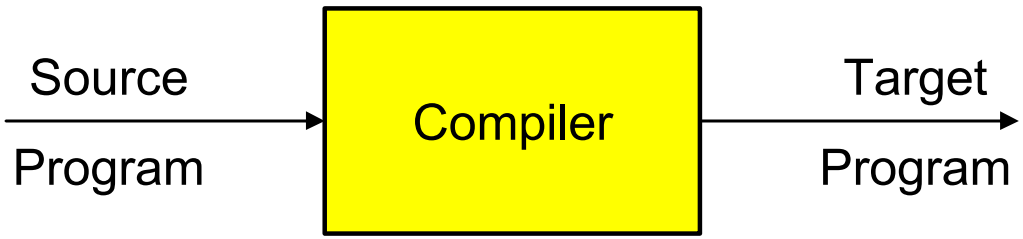

A. Koch

Optimierer versucht:

- Overhead von hoher Abstraktionsebene der Eingabesprache zu reduzieren
- Eingabeprogramm effizient auf Zielmaschine abzubilden
  - Vertusche Schwächen der Hardware-Architektur
  - Stärken der Hardware-Architektur auszunutzen
- Sonderfälle auszunutzen

➥Ziel: Effizienz eines erfahrenen Assembler-Programmiers

Ergebnis der Optimierung

Viele Möglichkeiten, entsprechend Vorgabe des Benutzers

- Schnellster Code
- Kleinster Code
- Geringste Anzahl an Speicherzugriffen
- Geringste Anzahl von ausgelagerten Speicherseiten
- ...

➥Optimierung formt Code entsprechend um

Charakteristika von Optimierungen

Sicherheit Die Bedeutung des Programmes (hier: extern beobachtetes Verhalten) darf nicht verändert werden.

Profitabilität Die Optimierung muß in Bezug auf das angestrebte Ziel eine ausreichende Verbesserung bringen.

Risiko Welche negativen Effekte kann die Optimierung nach sich ziehen?

Anwendbarkeit Gibt es ausreichend viele Stellen, an denen die Optimierung angebracht werden kann?

Redundante Ausdrücke

Redundante Ausdrücke

Ursprünglicher Code

```
m := 2 * y * z;
n := 3 * y * z;
o := 2 * y - z;
```

Umgeschriebener Code

```
t0 := 2 * y;
m  := t0 * z;
n  := 3 * y * z;
o  := t0 - z;
```

Redundanter Ausdruck

Ein Ausdruck `x op y` ist an an einer Position L redundant, wenn er in jedem Fall vor L berechnet wurde, und zwischen der Berechnung und L die Operanden `x` und `y` nicht verändert wurden.

Beschränkung auf Basisblock

Basisblock (BB)

Längste Folge von Anweisungen ohne Kontrollfluß.

Beispiel:

```
a := b + 42;
if (a > 23) then
  c := a - 46;
  d := b * 15;
else
  c := a + 46;
  d := 0
  q := false;
endif
```

Basisblöcke:

```
a := b + 42;
```

```
c := a - 46;
d := b * 15;
```

```
c := a + 46;
d := 0
q := false;
```

Erster Ansatz: AST-Ebene

Erkennen gleicher Teilbäume, dann Erweiterung auf DAG

A. Koch

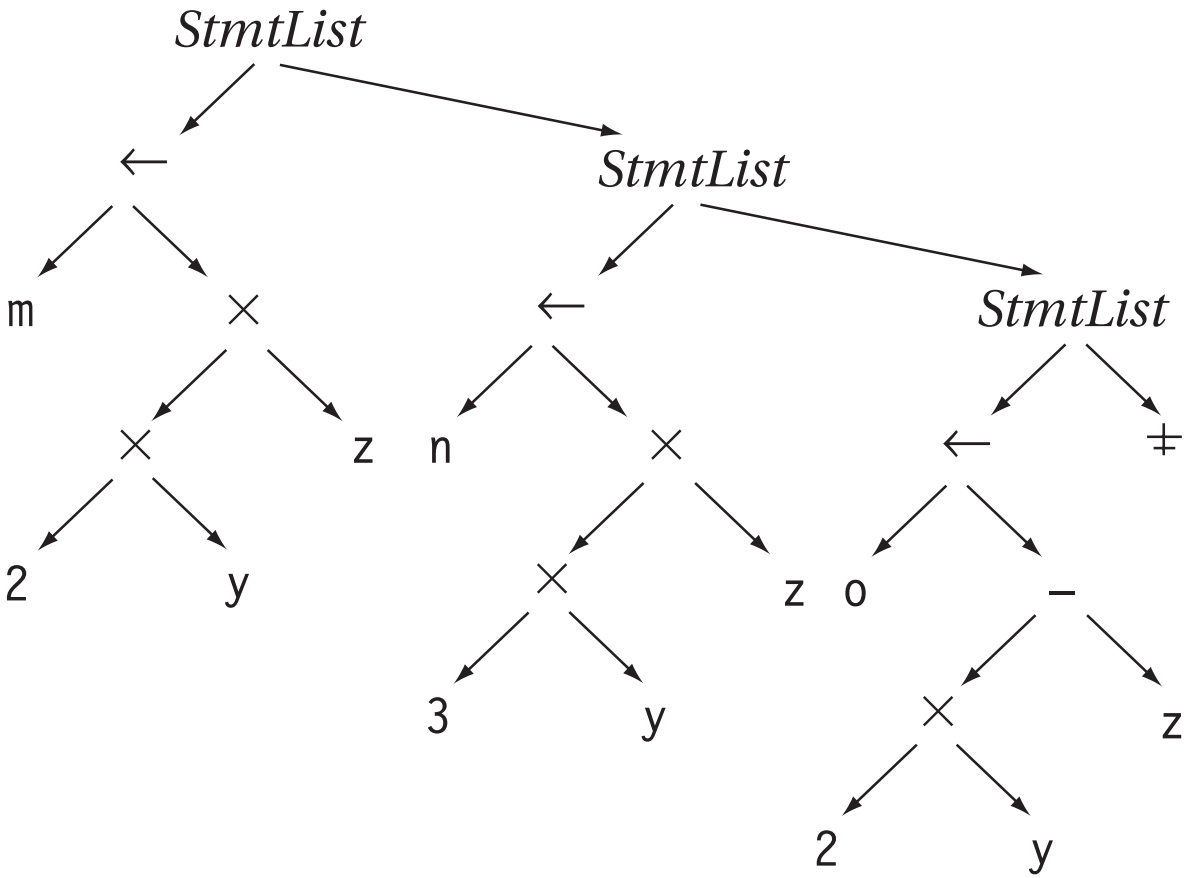

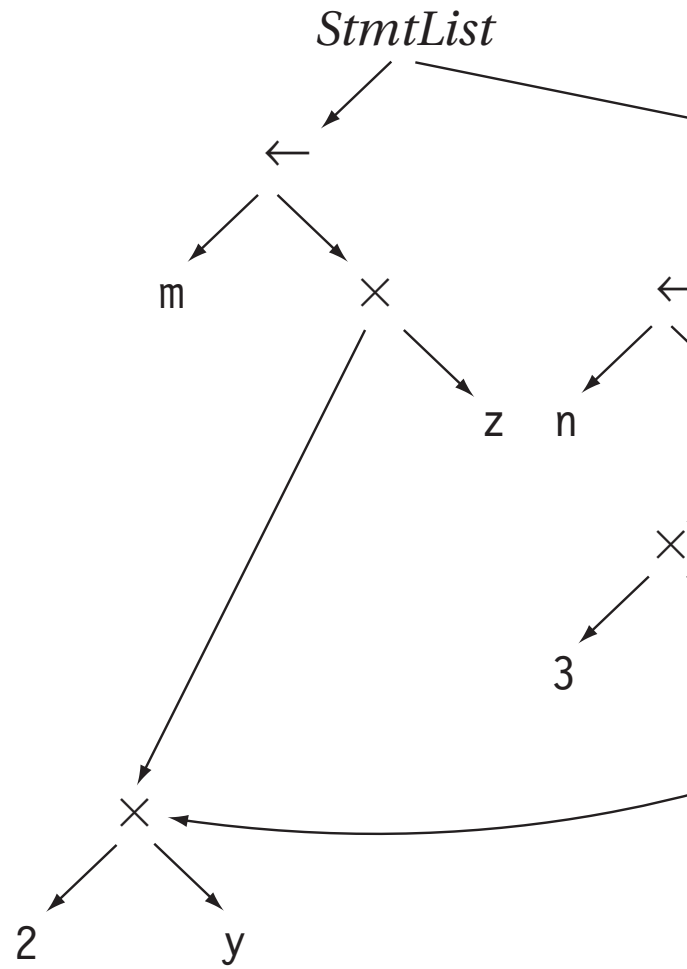

↪ Redundanzelimination in ASG-Konstruktoren einbauen

Erster Ansatz: Realisierungsidee

- Hashing über ganze Unterbäume
- Gleicher Hash $\rightarrow$ vergleiche Struktur genau
- Wenn gleich: Setze bei redundantem Auftreten Zeiger auf Definition um

Problem:

```
m := 2 * y * z;
y := 3 * y * z;
o := 2 * y - z;
```

Einfaches Hashing bei `o := ...`

- findet Definition von `2*y` (bei `m:= ...`)
- sieht aber nicht Zuweisung bei `y:=...`

Erster Ansatz: Reparatur

Braucht Mechanismus, um Zuweisungen zu beachten!
Idee

- Verwalte unterschiedliche Versionen von Variablen
- Erhöhe Versionsnummer bei jeder Zuweisung ($\rightarrow$ SSA)
- Hash nun über Variablennamen und Versionsnummer

```
m0 := 2 * y0 * z0;
y1 := 3 * y0 * z0;
o0 := 2 * y1 - z0;
```

- Trägt bei `m0` nun als bekannt den Ausdruck `2*y0` ein
- Unterbindet Wiederverwendung als `2*y1`

A. Koch

CFG-basierte Redundanzeliminierung mit Wertnumerierung

Andere Zwischendarstellung: Kontrollflußgraphen

- Relationen zwischen Basisblöcken
  - Bedingte Ausführung, Schleifen
- Verwaltet nun Folgen von Anweisungen in Basisblöcken
  - Häufige IR, z.B. in SUIF, Scale, COINS, GCC (ab 4.x)
- Reihenfolge leichter umzustellen

Anderer Ansatz der Redundanzeliminierung

Nun keine Analyse des AST mehr!

Idee

- Verwalte nun nicht Variablennamen in Ausdrücken
- . . . sondern direkt ihre Werte
  - Jeder zur Laufzeit berechnete Wert wird durchnumeriert
  - Der Wert zweier Ausdrücke e_1 und e_2 bekommt dieselbe Nummer
  - . . . wenn e_1 und e_2 beweisbar immer denselben Wert liefern

Value Numbering (VN)

- e_1 und e_2 redundant, wenn
  - sie ihre Operanden mit gleichen Operatoren verknüpfen
  - und die Operanden die gleichen Wertnummern haben

Implementierung mit Hash-Table

- Hashe Textdarstellung von Variablen und Konstanten (`.spelling`)
  - Alternativ in Triangle: Adresse der Deklaration im AST
- Hashe ganze Ausdrücke bestehend aus Operatoren und Wertnummern
- Neue Werte (neue Hash-Keys) bekommen neue Wertnummer zugewiesen

Wichtig: Ausdrücke gleichen Hash-Wertes müssen zur Laufzeit gleichen Wert liefern.

Value Numbering: Hash-Kollisionen

Wie Kollisionen handhaben?

- Bei einfachen Ausdrücken `x op y` leicht vermeidbar
  - 4b für Operator
  - je 14b für Wertnummern der Teilausdrücke
  - insgesamt ein 32b Wort
  - Eindeutig bis max. 16384 Teilausdrücken
- Bei komplizierteren Ausdrücken
  `a op1 b op2 c op3 ...`
  - Kollisionen nicht mehr einfach vermeidbar
  - Zweistufiges Vorgehen: Hash+Vergleich
  - Alternative: Aufteilen in einfache Ausdrücke
    - Auch in Triangle (Baum aus Teilausdrücken)
- Hier Beschränkung auf einfache Ausdrücke
  - Realistisch für Bantam TAC

Beispiel Value Numbering


```
x := a * d;
y := a;
z := y * d;
```

A. Koch

Ausdruck	. . . auf Wertnummern	Wertnummer Ergebnis
a	-	1
d	-	2
a * d	1*2	3
x	3	3
a	1	1
y	1	1
y * d	1*2	3
z	3	3

Wichtig: Zahlen sind keine Werte, sondern Wertnummern!

Value Numbering Algorithmus

Für jeden Ausdruck e der Form $r_e \leftarrow x_e \, op_e \, y_e$ im Block

1. Bestimme Wertnummern von x_e, y_e
2. Bestimme Hash-Wert für x_e, y_e, op_e
3. Hash-Wert bekannt?
   - Ja: ersetze e durch Kopie von bekanntem Ausdruck, trage dessen Wertnummer für r_e ein.
   - Nein: Trage Hash-Wert neu in Tabelle ein, vergebe neue Wertnummer und trage diese für r_e ein.

Diskussion Value Numbering (VN) 1

- Kommutative Operatoren
  - Schlage mit beiden Operandenreihenfolgen nach
- Auch Constant Folding während VN möglich
  - Flag in Tabelle für “konstanter Wert”
- Berücksichtige algebraische Eigenschaften beim Hashen
  - Viele Sonderfälle, baue Entscheidungsbaum für Operator
  - Auf Wertnummern, *nicht* auf Variablen

Algebraische Eigenschaften

x←y, x+0, x-0, x∗1, x÷1, x-x, x∗0, x÷x, x∨0, x ∧ 0xFF…FF, max(x,MAXINT), min(x,MININT), max(x,x), min(y,y), and so on ...

Diskussion Value Numbering (VN) 2

- Schreiben über Zeiger löscht *alle* Wertnummern
- Schreiben auf Arrayelement mit variablem Index
  - Löscht Wertnummern aller Elemente dieses Arrays
- Schreiben auf ganze Record-Variable
  - Löscht Wertnummern aller Komponenten dieser Record-Variable
- Prozeduraufruf
  - Löscht Wertnummern von **`var`**-Parametern
  - Löscht Wertnummern von globalen und nicht-lokalen Variablen

Beispiel VN mit Umschreiben

Bisher: Erkennen von Redundanzen, jetzt auch Umschreiben des Codes

Eingabe-Code

```
a := b + c;
b := a - d;
c := b + c;
d := a - d;
```

Value Numbering

```
a3 := b1 + c2;
b5 := a3 - d4;
c6 := b5 + c2;
d5 := a3 - d4;
```

Umschreiben

```
a := b + c;
b := a - d;
c := b + c;
d := b;
```

Eindeutig benannte Zuweisungsziele

Wertinstanzen der SSA-Form

Eingabe-Code

$a_0 \leftarrow x_0 + y_0$
$*\ b_0 \leftarrow x_0 + y_0$
$a_1 \leftarrow 17$
$*\ c_0 \leftarrow x_0 + y_0$

Value Numbering

$a_0^3 \leftarrow x_0^1 + y_0^2$
$*\ b_0^3 \leftarrow x_0^1 + y_0^2$
$a_1^4 \leftarrow 17$
$*\ c_0^3 \leftarrow x_0^1 + y_0^2$

Umgeschrieben

$a_0^3 \leftarrow x_0^1 + y_0^2$
$*\ b_0^3 \leftarrow a_0^3$
$a_1^4 \leftarrow 17$
$*\ c_0^3 \leftarrow a_0^3$

- Wert 3 verfügbar als $\mathtt{a}_0^3$

Ist VN sicher?

- Hash-Tabelle beginnt leer
- Ausdrücke werden bei Durchgehen des Blocks eingetragen
- Falls (op, VN(x), VN(y)) in Tabelle vorkommt
  - Ist Ausdruck mindestens einmal bereits in Block vorgekommen
  - x und y sind nicht neubelegt worden
    - Algorithmus verwendet Wertnummern statt Variablen!

➥Falls (op, VN(x), VN(y)) eine Wertnummer hat, kann er gefahrlos benutzt werden

Algorithmus

- beweist inkrementell, dass (op, VN(x), VN(y)) redundant
- modifiziert Code, aber invalidiert nicht Tabelle

Ist VN profitabel?

- Wenn Wiederbenutzung billiger ist als Neuberechnung
  - Übliche Annahme
  - Bei Registermaschinen potentiell problematisch (*register spill*)
- Zusätzliches Constant Folding ist *immer* profitabel
  - Neuberechnung braucht immer 1+ zusätzliche Register
  - Load Immediate braucht genau 1 zusätzliches Register
  - Immediate Instruktion braucht 0 zusätzliche Register

    ```
    ADD R0, #8
    ```
- Algebraische Eigenschaften
  - Entfernte Operationen sind immer nützlich (x + 0)
  - Vereinfachung hängt von Zielmaschine ab (2*x, x+x)
  - Kann aber leicht berücksichtigt werden

Wo und wie ist VN anwendbar?

- Potentiell anwendbar auf alle Ausdrücke eines Blocks
- Wie passende Stellen finden?
- Abarbeiten der Anweisungen in Programmreihenfolge
  - *program order*
- Konstruiert Modell des dynamischen Programmzustands
- Bei jeder Operation verschiedene Möglichkeiten prüfen

Zusammenfassung

- VN führt erschöpfende Suche durch
- Folge: Nur begrenzter Rechenaufwand je Operation akzeptabel

Lokale Methoden

Lokale Methoden

- Arbeiten auf Basisblöcken (BB)
- Für jeden Basisblock gilt
  - Alle Anweisungen werden sequentiell abgearbeitet
  - Falls eine Anweisung ausgeführt wird, werden alle Anweisungen ausgeführt.
- Können sehr genaue Analysen durchführen
- Beweisen dabei i.d.R. stärkere Aussagen als auf größeren Bereichen möglich

Bisheriges VN Vorgehen

Local Value Numbering (LVN)

- Jeweils ein Basisblock betrachtet
- Gute lokale Resultate
- Aber keine Arbeit über Blockgrenzen

Erweitern des Redundanzbegriffes

Redundanz über Blockgrenzen hinweg

Ein Ausdruck `x op y` ist an einer Stelle L genau dann redundant, wenn er auf jedem Pfad vom Startknoten des CFGs zur Stelle L evaluiert worden ist und die Werte seiner Teilausdrücke `x` und `y` nicht verändert wurden.

Beispiel LVN

A. Koch

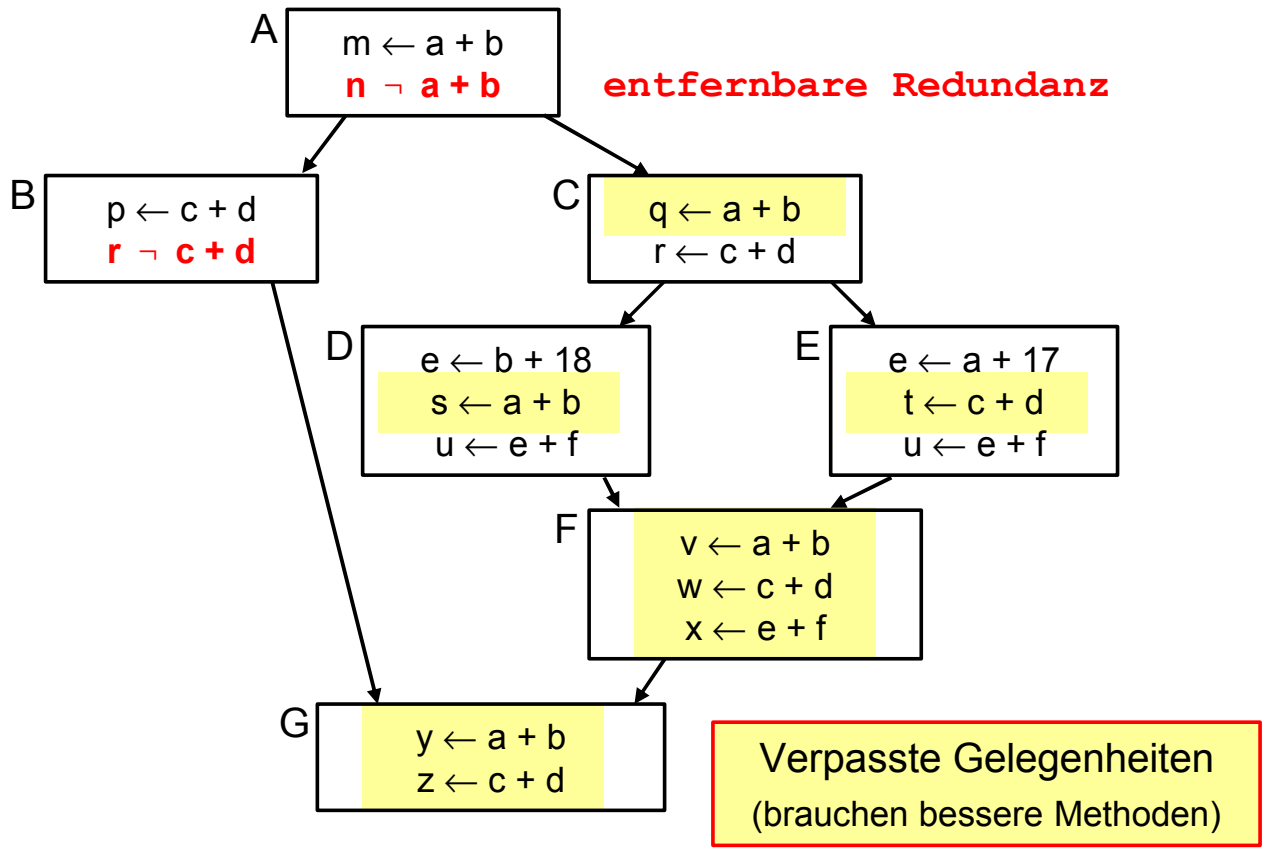

Superlokale Methoden

Superlokale Methoden 1
Arbeiten auf Extended Basic Blocks (EBBs)

- EBB $B = \{b_1, b_2, \ldots, b_n\}$, mit BBs b_i
- Nur b_1 darf im CFG mehrere oder keine Vorgänger haben
- Alle anderen b_i haben genau einen Vorgänger
- EBB ist Baum aus BBs mit b_1 als Wurzel

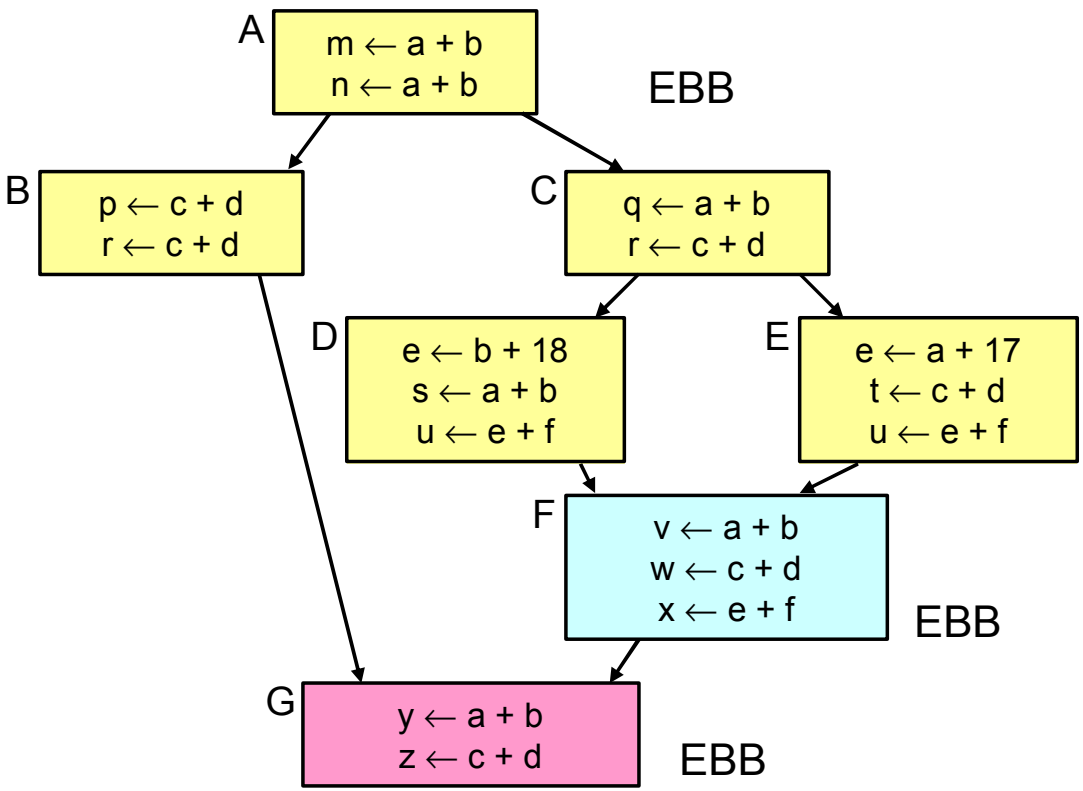

Superlokale Methoden 2

- Idee: Benutze Pfade beginnend bei b_1 durch EBB wie einen BB
- Auf jedem Pfad: Genau ein Vorgänger, baue auf dessen Analysen auf

A. Koch

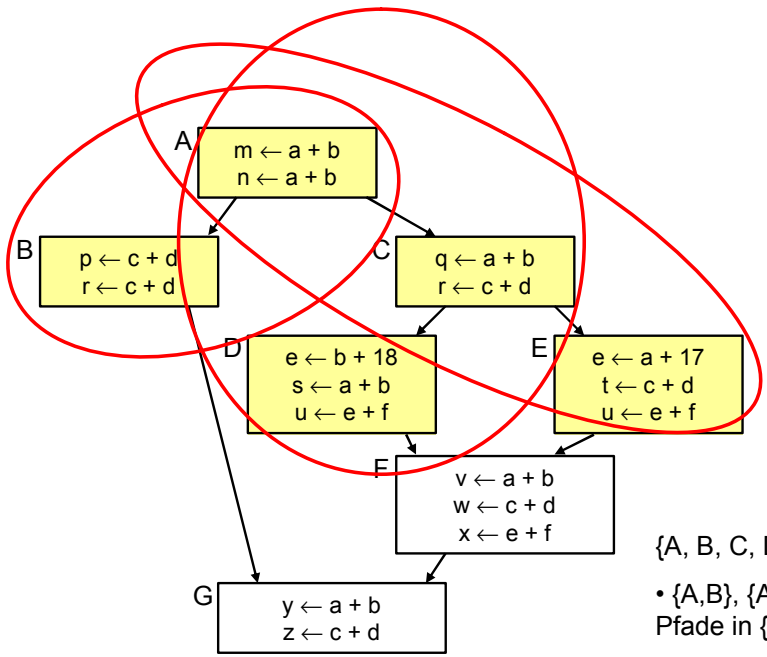

{A, B, C, D, E} ist ein EBB

• {A,B}, {A,C,D}, und {A,C,E} sind Pfade in {A, B, C, D, E}

{F} und {G} sind auch EBBs

• … haben aber nur triviale Pfade

*

Superlokales VN 1

A. Koch

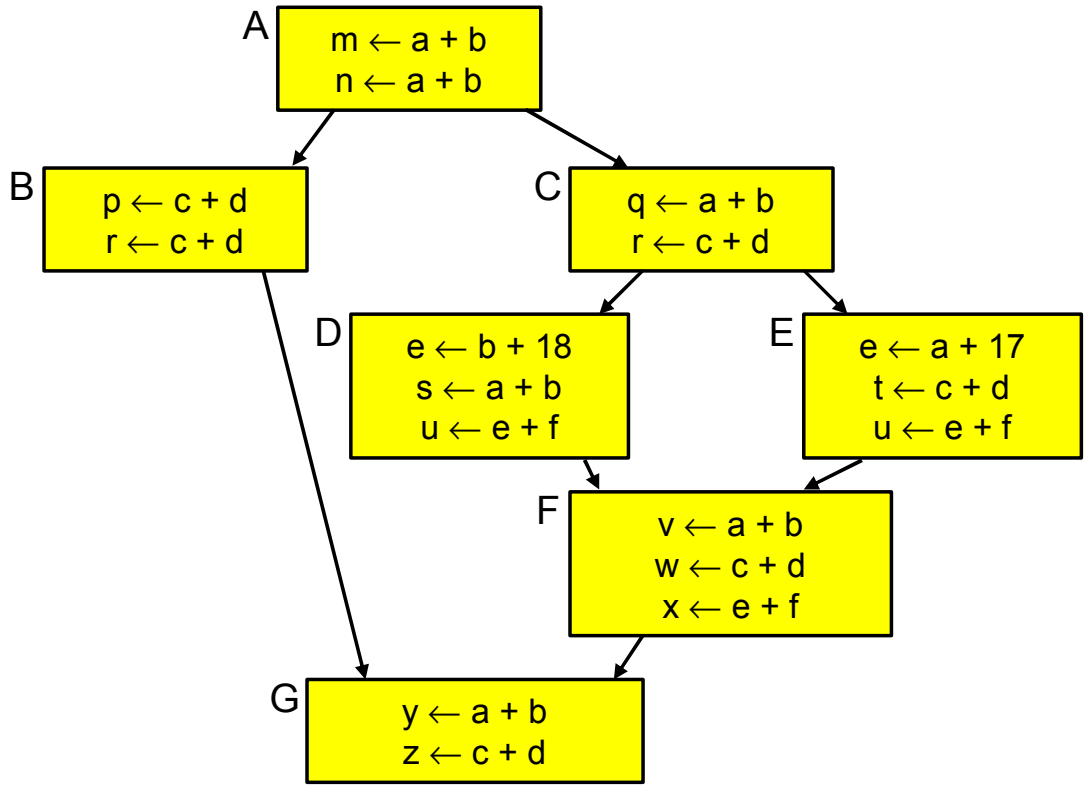

- Idee: Wende lokale Methode auf jeden Pfad an
- Hier: Bearbeite $(A, B), (A, C, D), (A, C, E)$
- Baue auf Ergebnisse des Vorgängers auf
- Aber: Hilft noch nicht für F und G (woher kommt man?)

Superlokales VN 2

- Vermeide mehrfache Neuberechung gleicher Daten
  - Hier A und C
- Braucht Fähigkeit, Einträge ungültig zu machen
  - Beispiel: Von (A,B) nach (A,C) müssen Daten von B entfernt werden
- Eine Realisierung:
  Symbol-Tabelle mit Geltungsbereichen
  - Siehe Kontextanalyse
  - Öffne Geltungsbereich bei Anhängen von Block an Pfad
  - Schließe Geltungsbereich bei Entfernen von Block aus Pfad

Beispiel Superlokale VN 1 im SSA-CFG

A. Koch

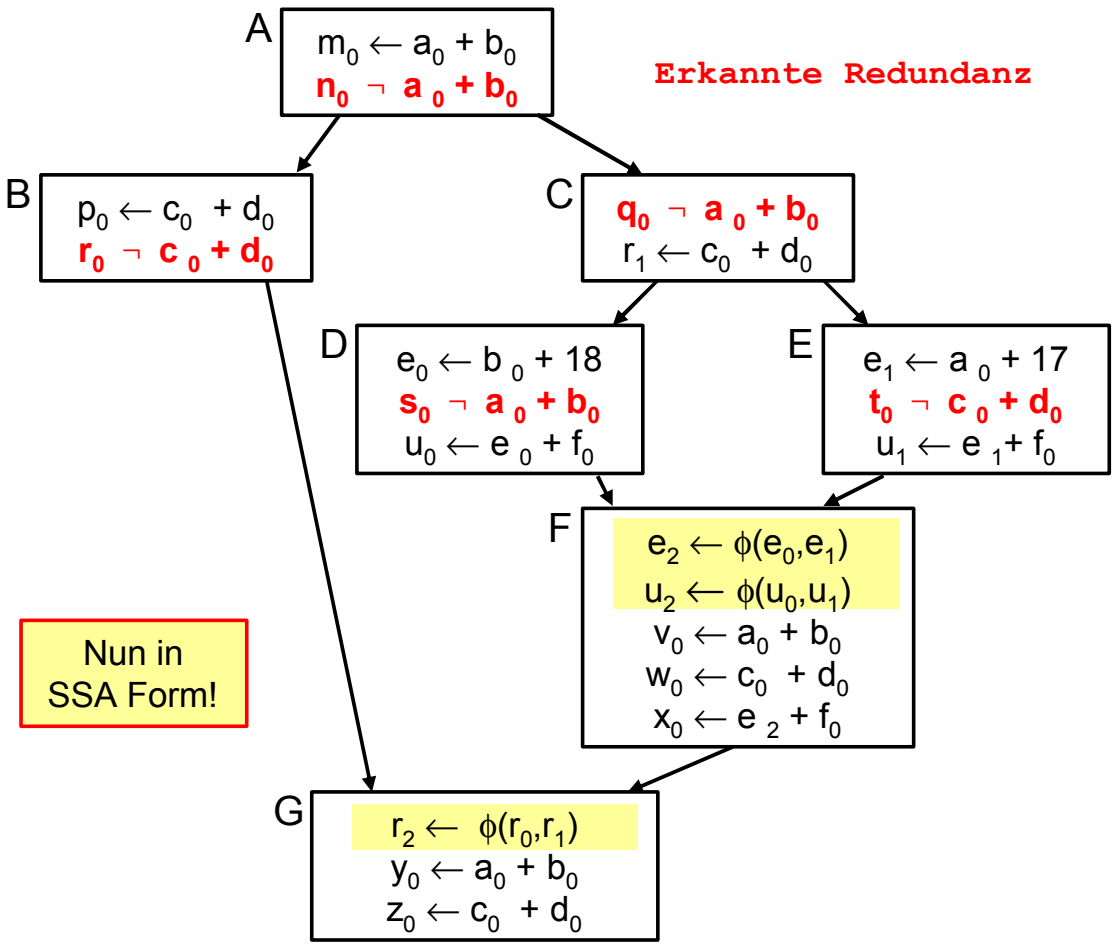

Beispiel Superlokale VN 2

Mehr Redundanzen erkannt, aber nicht alle

- F und G eigene EBBs, hier $a + b$ unbekannt
- $e + f$ berechnet in allen Vorgängern von F, aber mit unterschiedlichen Werten

Erweiterung der Anwendungsbereiche

- VN: Leicht von BB auf EBB erweiterbar
- Klappt aber nicht immer. z.B.
  - Verändern bereits bearbeiteter Blöcke

Regionale Methoden

Noch größere Anwendungsbereiche 1

- Superlokale VN verwirft gesamte Tabelle bei Merge Point
- Nächste Verfeinerung: Über Merge Points hinweg arbeiten

➥ Regionaler Anwendungsbereich

- Größer als superlokal
- Kleiner als gesamte Prozedur

Noch größere Anwendungsbereiche 2

Überlegungen am Beispiel von F:
Zusammenführung von D und E

- Keine Beschränkung auf einzelne der Tabellen D oder E möglich
  - Kontrollfluß könnte anderen Pfad nehmen, dann Ausdruck nicht redundant
- Zusammenfügen der Tabellen von D und E
  - Welche Einträge streichen? (z.B. **`b+18`** und **`a+17`**)
    - Liegen auf unterschiedlichen Pfaden
  - Gleiche Ausdrücke in beiden Pfaden
    - Aber mit unterschiedlichen Wertnummern (**`e+f`**)
  - Kompliziert und rechenintensiv

Noch größere Anwendungsbereiche 3

Anderer Ansatz: Beschränke Tabelle auf Fakten, die unabhängig vom konkreten Pfad gelten

- Beide Pfade zu F haben gleichen Präfix (A,C)
- Alle Operationen in A und C sind immer vor Erreichen von F ausgeführt worden
- Letzter “sicherer” Stand ist also Tabelle nach C
- Als Ausgangspunkt für F benutzen

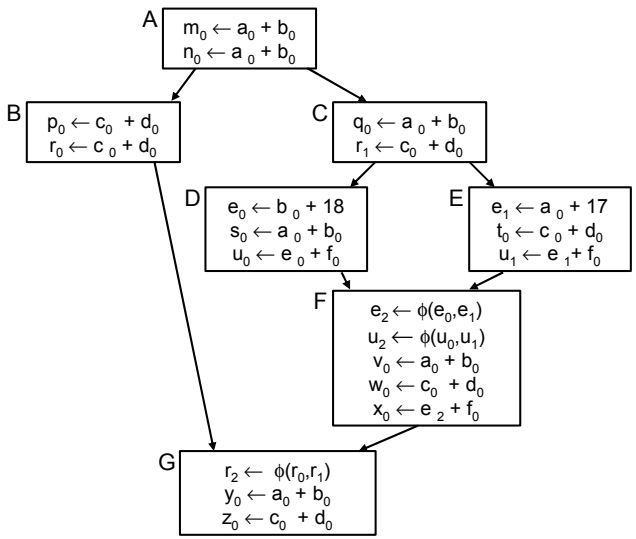

Noch größere Anwendungsbereiche 4

Wie mit Zuweisungen in D und E umgehen?

- SSA-Form umgeht Verlorengehen von Werten
  - Eigene Variable für jeden Wert
  - D und E können zusätzliche Werte erzeugen
  - Aber können keine alten Werte streichen
  - Konflikte werden über ϕ-Funktionen aufgelöst

Noch größere Anwendungsbereiche 5

Effekt der Vorgehensweise: Verwende C als Ausgangspunkt für F

A. Koch

- Erkennt jetzt Redundanz von $a_0 + b_0$ und $c_0 + d_0$ in F
- Verpasst aber $e_2 + f_0$, da zwischen C und F berechnet

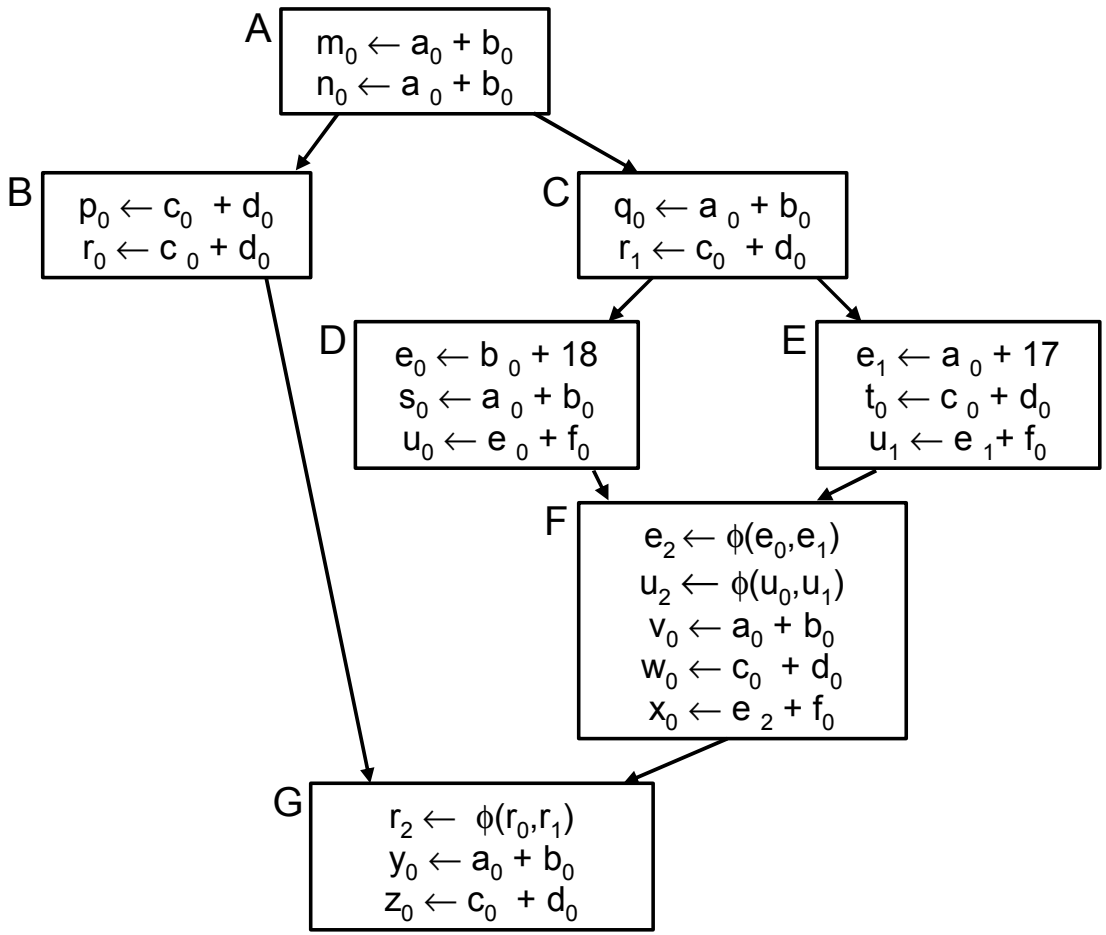

Noch größere Anwendungsbereiche 6

Verfahren benötigt: Letzten gemeinsamen Vorfahren über alle Pfade zu einem Block
Benutze Tabelle von X bei Eintritt in Y: $X \leftarrow Y$

A. Koch

$$
\begin{aligned}
- &\leftarrow A \\
A &\leftarrow B \\
A &\leftarrow C \\
C &\leftarrow D \\
C &\leftarrow E \\
C &\leftarrow F \\
A &\leftarrow G
\end{aligned}
$$

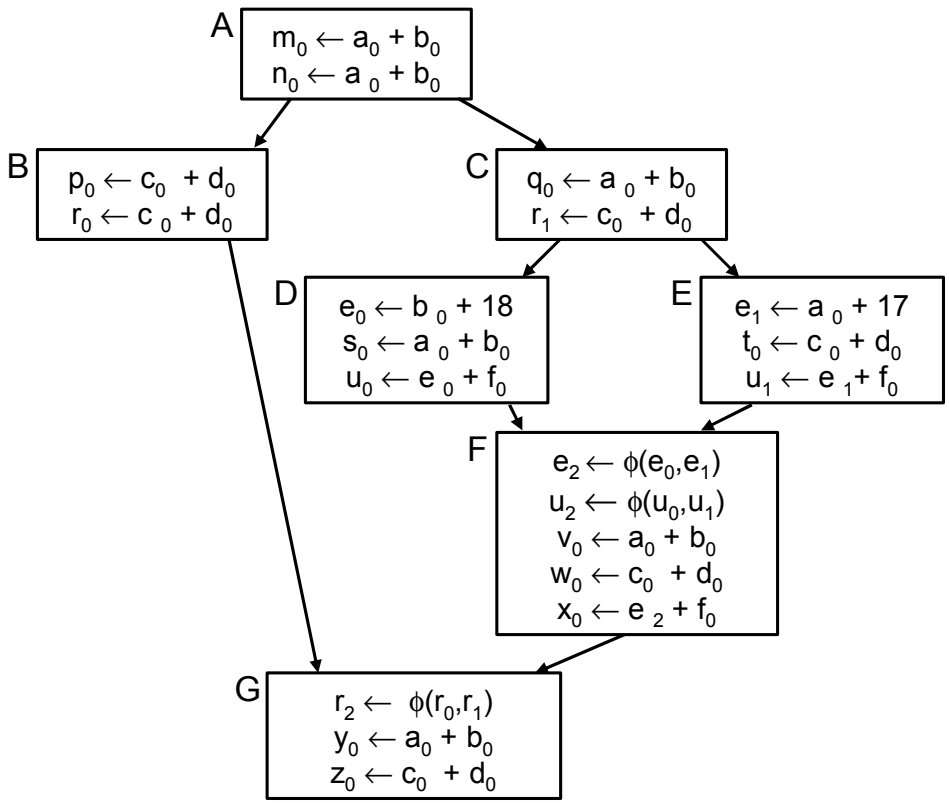

➥X muß Y dominieren

Dominanz

A. Koch

Dominatormengen

Block	Dom	IDom
A	A	–
B	A,B	A
C	A,C	A
D	A,C, D	C
E	A,C, E	C
F	A,C,F	C
G	A,G	A

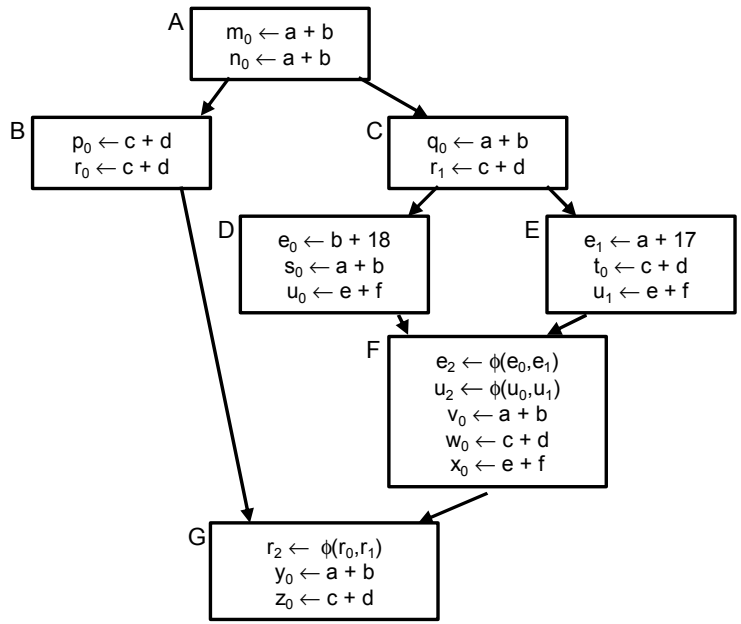

Anwendung auf VN

- Geben sei ein Block b
- Jeder Block d in $\text{DOM}(b) - \{b\}$ wurde vor b ausgeführt
- Die VN-Tabelle jedes d könnte zur Vorbelegung von b verwendet werden
- Welche wäre die beste Wahl?
- Die von Block e=$\text{IDOM}(b)$!
  - e wird von allen anderen Blöcken aus $\text{DOM}(b) - \{b\}$ dominiert
  - Kann all deren Informationen verwenden
  - Hat damit die meisten Informationen

➥Dominator VN Technique (DVNT oder kurz DVN)

Regionaler Algorithmus

- Rechne superlokalen Algorithmus auf EBBs, verwendet dabei
  - Verschachtelte Hash-Tabellen für Geltungsbereiche
  - SSA-Form
- Neu: Initialisiere Tabelle für Knoten x
  - Mit Tabelle von $\text{IDOM}(x)$
  - Trage so Wissen über Merge Points hinweg
- Wie vorher möglich:
  - Constant folding
  - Ausnutzung algebraischer Eigenschaften

➥Größerer Anwendungsbereich sollte zu besseren Ergebnissen führen

Arbeitet in Prefix-Reihenfolge auf Dominatorbaum

- Stellt sicher, das $\text{IDOM}(x)$ vor x bearbeitet ist

A. Koch

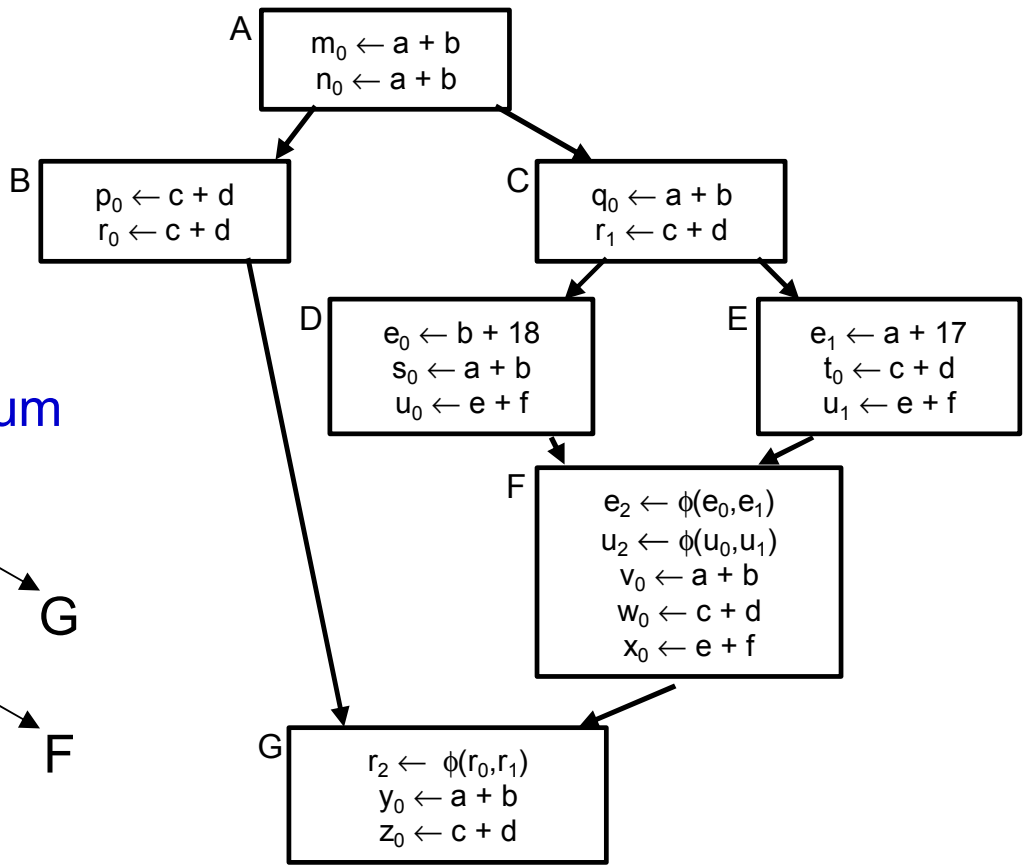

Dominatorbaum

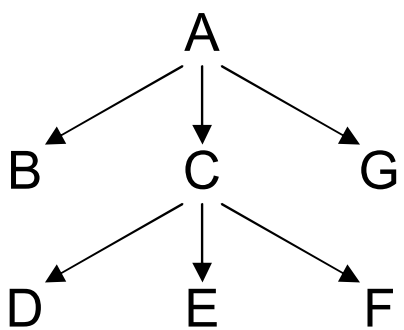

Mögliche Reihenfolge: A, B, G, C, D, E, F

Beispiel DVNT 3

A. Koch

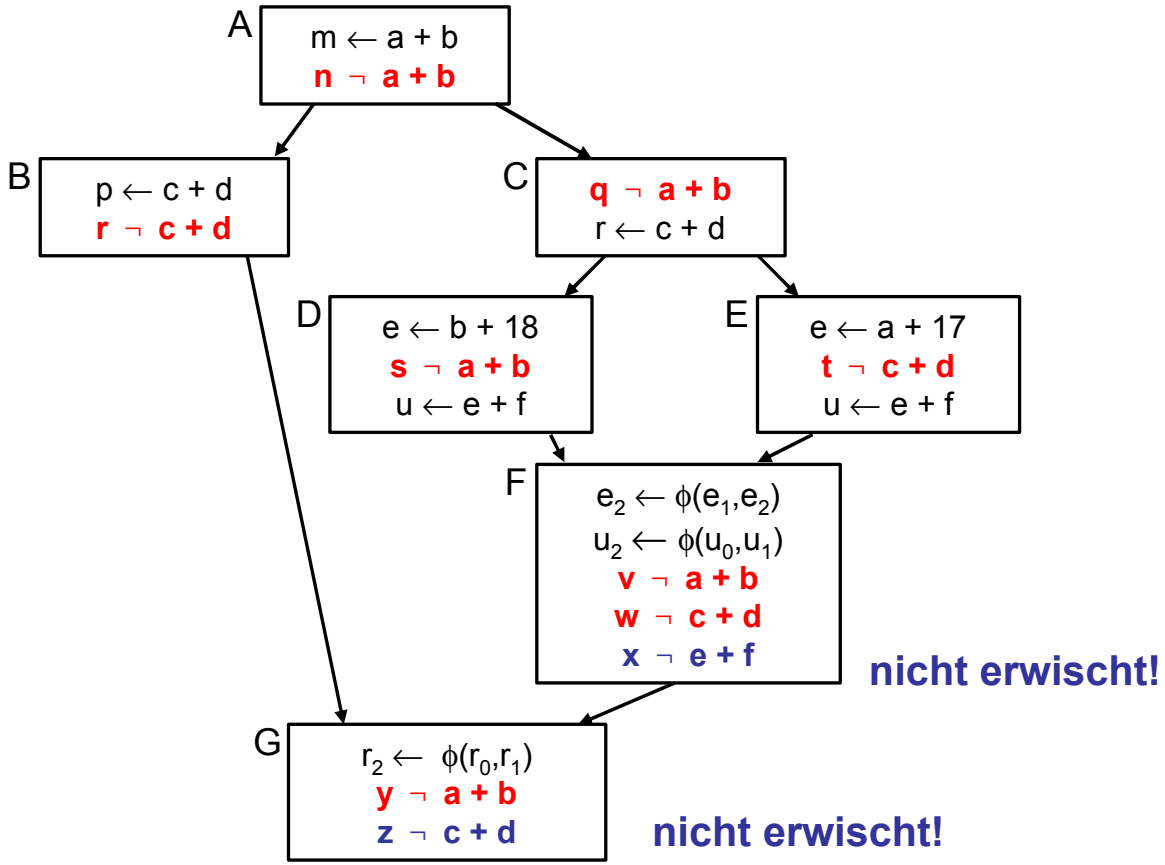

- Erkennt nochmehr Redundanz
- Aber immer noch nicht alle Möglichkeiten
- Scheitert z.B. bei Schleifen
  - Rückwärtskanten im CFG

Globale Methoden

Globaler Anwendungsbereich

- Über CFG der kompletten Prozedur
- Allgemeine Vorgehensweise: Schritte trennen
- Analyse sammelt Informationen, auch über Zyklus hinweg
- Transformation erst, wenn alles fertig analysiert

Globale Redundanzelimination

Am Beispiel Global Common Subexpression Elimination

- Nun wieder lexikalischer Vergleich von Namen
- Keine Wertnummern mehr
- Keine SSA-Form mehr
- Demonstriert das wichtige Mittel der Datenflussanalyse

Alternativer Ansatz

- Global Value Numbering
- Graphenbasierte Vorgehensweise
- Idee: Kongruente Wertgraphen in allen Zweigen des CFG finden
- Hier aber nicht weiter verfolgt
  - . . . aus Zeitmangel
  - Siehe Muchnick Abschnitt 13.1.2

Grundidee

- Eine Auswertung eines Ausdrucks e an der Stelle p ist redundant
- . . . genau dann, wenn
  - Jeder Pfad vom Prozedurstart zu p enthält eine Auswertung von e
  - und die Werte der Teilausdrücke von e haben sich von dort zu p nicht geändert

➥Auswertung e an p liefert gleichen Wert wie frühere Auswertung(en)

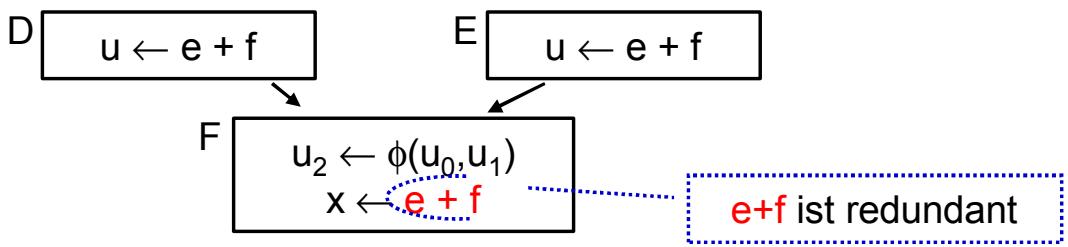

Wie diese redundanten (Teil)ausdrücke finden?

Modellierung 1

A. Koch

Definition

Ein Ausdruck e ist definiert an einer Stelle p im CFG falls sein Wert an der Stelle p berechnet wird. p ist damit eine Definitionsstelle von e.

Modellierung 2

Auslöschung

Ein Ausdruck e wird ausgelöscht an einer Stelle p im CFG falls ein oder mehrere seiner Operanden an der Stelle p definiert werden. p ist damit eine Auslöschungsstelle von e.

Modellierung 3

A. Koch

Verfügbarkeit

Ein Ausdruck e ist verfügbar an einer Stelle p wenn jeder zu p führende Pfad im CFG, beginnend beim Prozeduranfang, eine vorhergehende Definition von e enthält und e nicht zwischen dieser Definitionsstelle und p ausgelöscht wird.

Identifikation von Ausdrücken

Embedded Systems & Applications

Hier lexikalisch, nicht mehr über Wertnummern!

A. Koch

```
x := e + f;  // Definition von e+f
e := 5;      // Ausloeschung e+f
y := e + f;  // nicht redundant!
```

- Identifikation von Variablen über Namen
- Identifikation von Ausdrücken über
  - Eindeutigen Hash-Wert, berechnet über gesamten Ausdruck
  - Operandennamen und Operatoren
  - Numeriere Hash-Werte dann aufsteigend durch
- Anzahlen
  - Minimal: Anzahl Variablen plus Anzahl Konstanten
  - Maximal: Anzahl von (Teil)Ausdrücken im CFG

Vorgehensweise

Ziel

Wenn ein Ausdruck e in einem Block verfügbar ist, braucht er dort nicht neu berechnet zu werden.

. . . nun über Basis-Blockgrenzen und Verzweigungen hinweg!

Analyse 1

1. Schritt: Analyse

- Formuliere Gleichungssystem über den CFG der Prozedur
- Löse Gleichungssystem, um Menge verfügbarer Ausdrücke zu bestimmen

AVAIL(b)

AVAIL(b) sei Menge der am Anfang von Block b verfügbaren Ausdrücke.

Exkurs: Grundbetrachtung

Sicherheit

- $x + y \in \textsc{Avail}(b)$ beweist, dass eine vorherige Auswertung von $x + y$ existiert
- Spätere Transformation muss über einen Namen auf diesen Wert zugreifen können
  - . . . auf verschiedene Weisen realisierbar

Profitabilität

- Verursacht keine zusätzlichen Evaluationen
- Fügt aber Kopieroperationen ein
  - Im Prinzip billig
  - Viele können auch entfernt werden
  - Haben aber Einfluß auf Lebenszeiten ($\rightarrow \mathit{Live}$)

Berechnung von AVAIL(b) 1

Über zwei Hilfsfunktionen

EXPRKILL(b)

Die Menge der bis zum Ende des Blocks b ausgelöschten Ausdrücke.

DEEXPR(b) (*downward exposed*)

Menge der im Block b definierten Ausdrücke, die bis zum Ende des Blocks nicht ausgelöscht werden.

Weiterleitung von Ausdrücken:

- Wenn Ausdruck e bei Eintritt in Block b verfügbar ist, und nicht in EXPRKILL(b) ist, dann ist e auch nach Ende von b verfügbar.

Berechnung von $\textsc{Avail}(b)$ 2

Damit nun definierbar

$$\textsc{Avail}(b) = \bigcap_{a \in \text{pred}(b)} \textsc{DEExpr}(a) \cup (\textsc{Avail}(a) \cap \overline{\textsc{ExprKill}(a)})$$

$$\textsc{Avail}(b_0) = \emptyset$$

mit:
$\text{pred}(b)$: Vorgängerblöcke von b im CFG
b_0 Startblock des CFG

➥Datenflußproblem, lösen mit Standardverfahren

Exkurs: Gewünschter Gesamtablauf

Vor den Details erstmal einen Schritt zurück: Wie soll es weitergehen?

1. Berechne AVAIL(b) für alle Blöcke b
2. Vergebe dann eindeutige, CFG-globale Bezeichner für Ausdrücke in AVAIL(b)
3. Innerhalb der Blöcke b dann lokales Value Numbering
   - Initialisiert block-lokale Tabelle mit Ausdrücken aus AVAIL(b)

Berechnung von AVAIL(b) 3

Embedded Systems & Applications

A. Koch

Baut auf Berechnung von DEEXPR und EXPRKILL auf

assume a block b with operations o_1, o_2, …, o_k

VARKILL ← Ø
DEEXPR(b) ← Ø

for *i* = *k* **to** *1*
    assume o_i is "x ¬ y + z"
    add *x* to VARKILL
    if (*y* ∉ VARKILL) **and** (z ∉ VARKILL) **then**
        add "*y + z*" to DEEXPR(b)

EXPRKILL(b) ← Ø

For each expression *e*
    for each variable *v* ∈ *e*
        if v ∈ VARKILL(b) **then**
            EXPRKILL(b) ← EXPRKILL(b) ∪ {*e*}

assume a block b with operations o_1, o_2

VARKILL ← Ø
DEEXPR(b) ← Ø

Rückwärts du

for *i* = *k* **to** *1*
    assume o_i is "x ¬ y + z"
    add *x* to VARKILL
    if (*y* ∉ VARKILL) **and** (z ∉ VARKILL) t
        add "*y + z*" to DEEXPR(b)

EXPRKILL(b) ← Ø

For each expression *e*
    for each variable *v* ∈ *e*
        if v ∈ VARKILL(b) **then**
            EXPRKILL(b) ← EXPRKILL(

.

Berechnung von AVAIL(b) 4

- "**Foreach** expression e"
  über alle Ausdrücke der Prozedur
- Potentiell sehr langsam!
- Abhilfe
  - Hash-Map M von $v \rightarrow E$ bildet Variable ab auf benutzende Ausdrücke
  - Dann mit v über VARKILL(b) iterieren
  - Für jede Variable v via $M(v)$ Ausdrücke E bestimmen
  - ... und E in EXPRKILL(b) aufnehmen

Berechnung von AVAIL(b) 5

Nun Anwendung eines iterativen Algorithmus zum Finden eines Fixpunktes

Worklist $\leftarrow$ { all blocks in CFG }

while (*Worklist* $\neq \emptyset$)
remove a block *b* from *Worklist*
recompute AVAIL(*b*) as

$$AVAIL(b_i) = \cap_{x \hat{I} pred(b)} (DEEXPR(x) \cup (AVAIL(x) \cap \overline{EXPRKILL(x)}))$$

if AVAIL(*b*) changed **then**
Worklist $\leftarrow$ Worklist $\cup$ *successors*(*b*)

Beweis der Terminierung: Später ...

Beispiel mit AVAIL(b)-Mengen

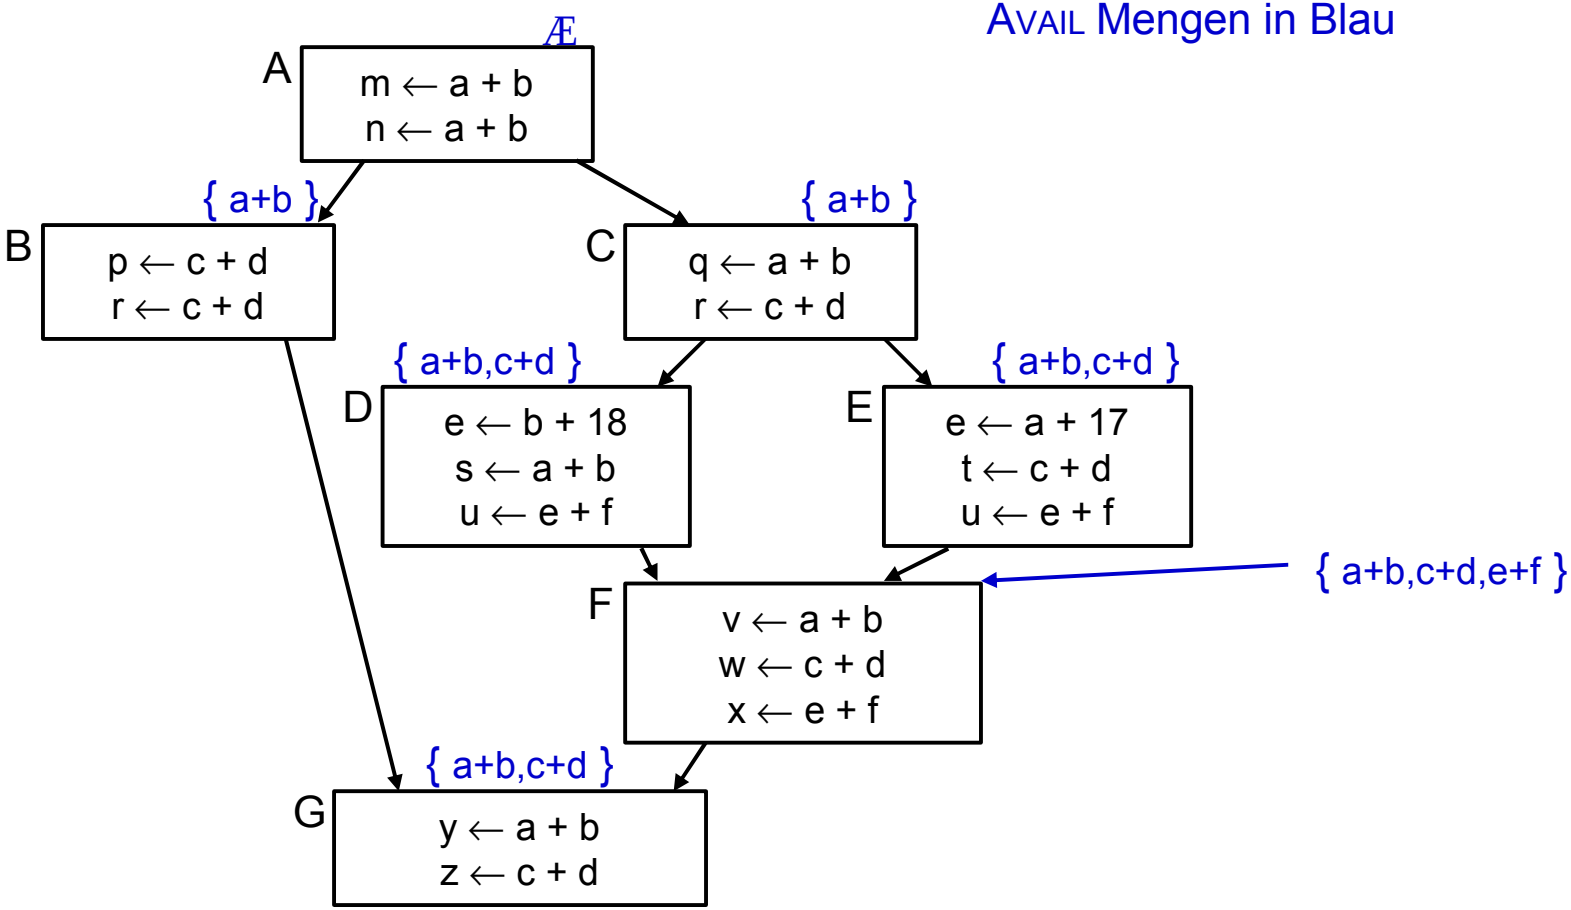

Exkurs: Gewünschter Gesamtablauf

1. Berechne AVAIL(b) für alle Blöcke b
   - **Erledigt!**
2. Vergebe dann eindeutige, CFG-globale Bezeichner für Ausdrücke in AVAIL(b)
3. Innerhalb der Blöcke b dann lokales Value Numbering
   - Initialisiert block-lokale Tabelle mit Ausdrücken aus AVAIL(b)

Nun eindeutige Namen t_i für global bekannte (Teil-)ausdrücke e_i vergeben

➥Hashing über Ausdrücke und Durchnumerieren mit i

Beispiel mit benannten globalen CSEs

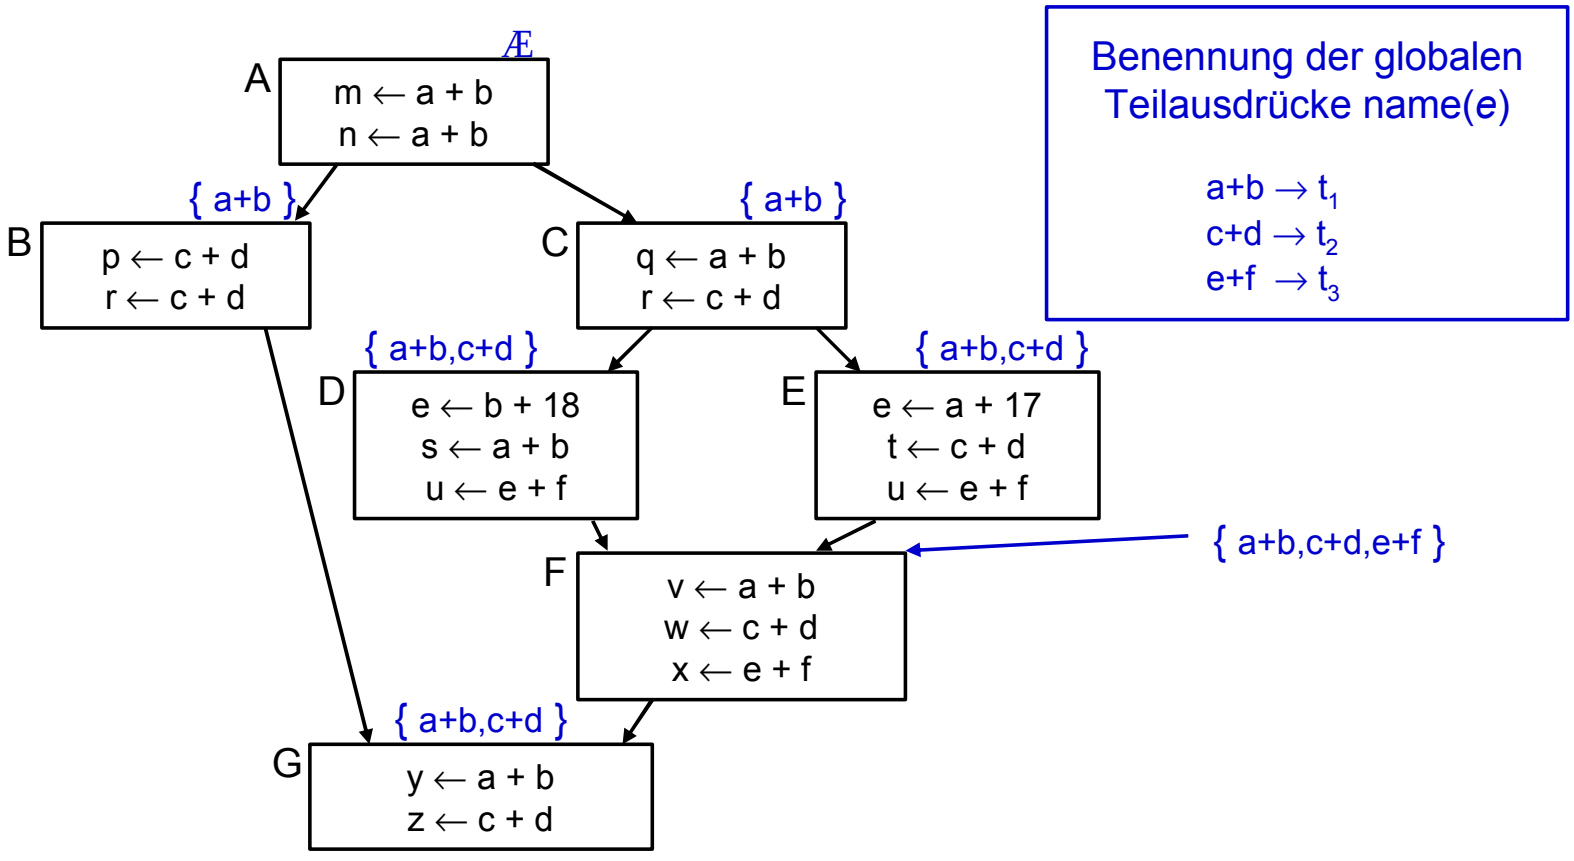

Damit jetzt Schritt 3 (Transformation) vornehmen!

Transformation der Ausdrücke 1

Block-lokales Value Numbering in Block b

1. Phase: Finde Wiederbenutzungen eines Ausdrucks

1. Initialisiere Hash-Tabelle mit AVAIL(b)
   - Falls VN Versionsnummern benutzt:
     Ausdrücke aus AVAIL(b) umformen
     z.B. $e + f \rightarrow e_0 + f_0$
2. Wenn Wiederverwendung `x := e`$_i$ erkannt
   - Ersetze e durch Verweis auf bekannten Namen t_i:
     `x :=` t_i
   - Merke Wiederverwendung durch USED$[e]$:= true

Transformation der Ausdrücke 2

2. Phase: Kopien der benutzten Werte unter bekanntem Namen erzeugen

- Für alle Ausdrücke e im Basisblock b
  - Wenn $e \in \text{DEEXPR}(b)$ und $\text{USED}[e]$
    - Füge nach letzter Definition von e in b ein: $t_i := e$

Gesamtergebnis

- Lokale Redundanzen durch lokales VN beseitigt
- Globale Redundanzen durch AVAIL-Mengen beseitigt
- Nicht ganz identischer Effekt, findet
  - Lokale Redundanzen durch Wertgleichheit
  - Globale Redundanzen durch gleiche Schreibweise

Effekt von globalem CSE im Beispiel

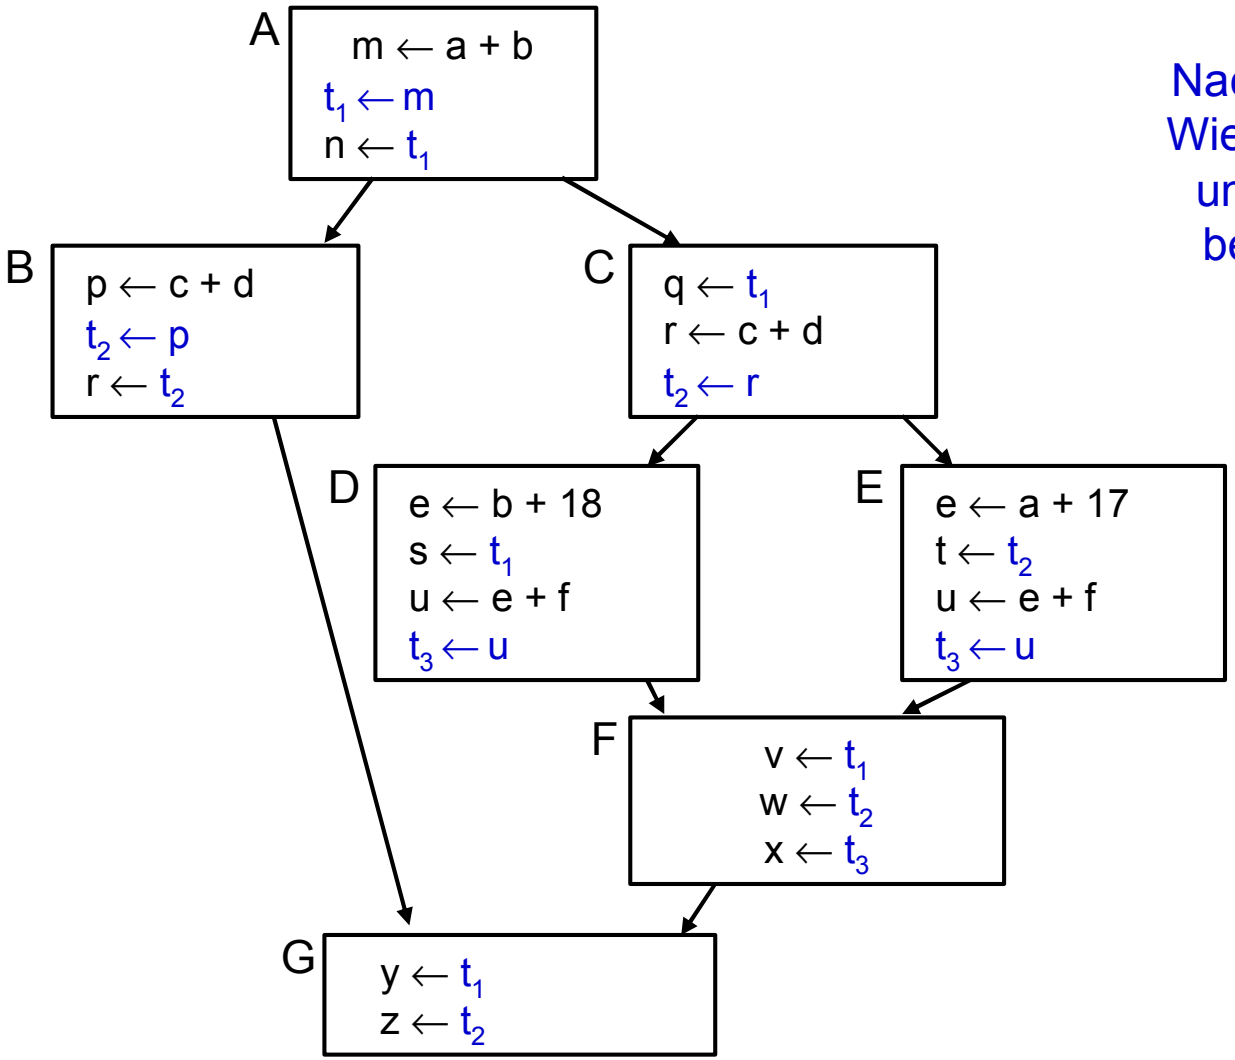

Nach Auffinden von Wiederbenutzungen und Kopieren der benutzten Werte

A. Koch

Unnötige Kopien

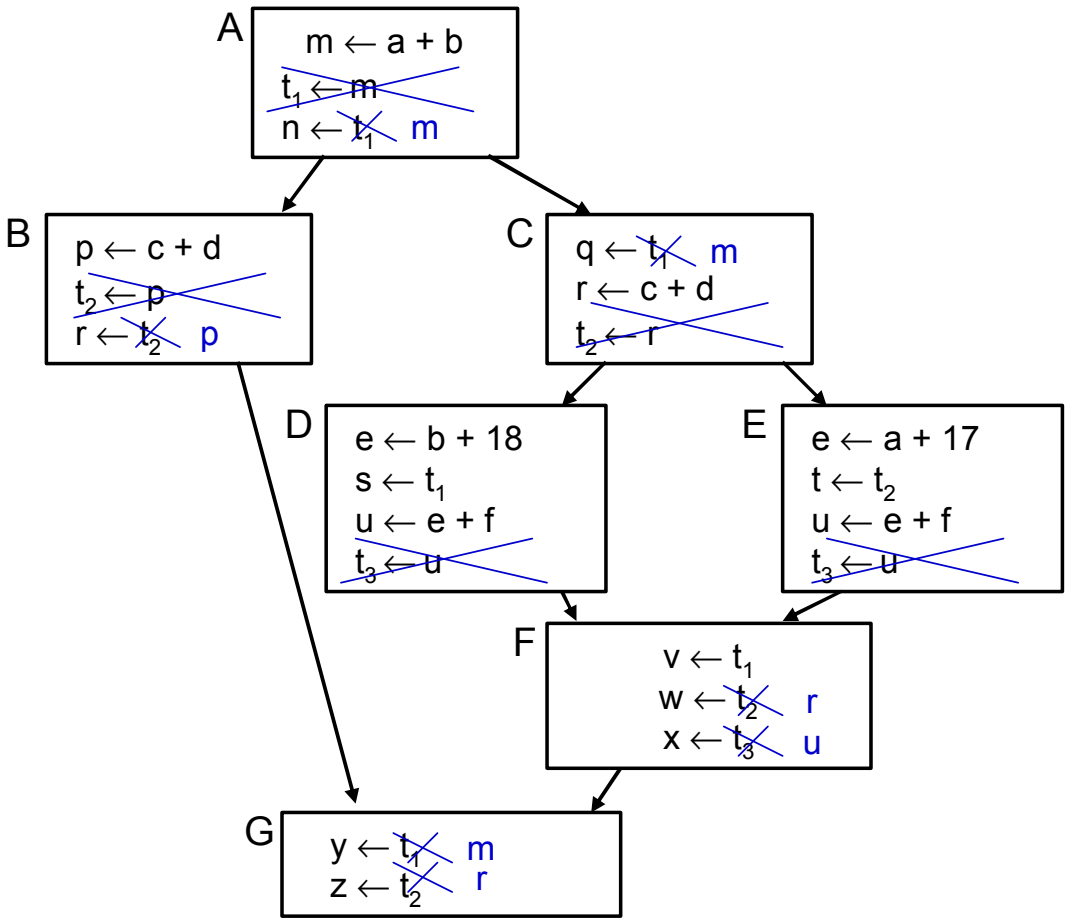

Viele der Kopien unnötig, hier sogar **alle**.

Können später aber entfernt werden (copy propagation, copy coalescing)

Gegenbeispiel

Hier wird Kopie gebraucht:

A. Koch

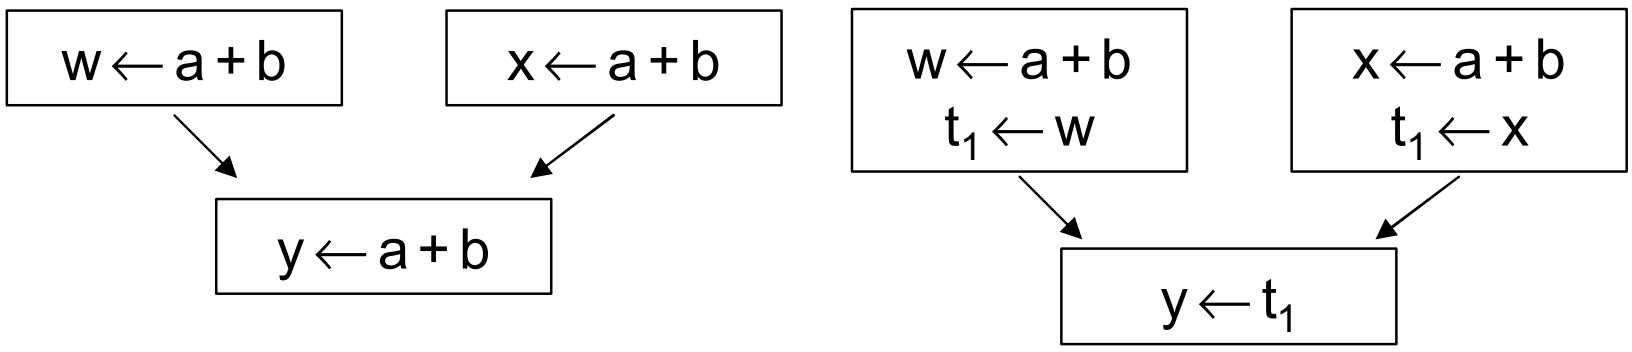

hier kann nicht "w oder x" geschrieben werden

Unterschied zu letztem Beispiel:
In beiden Zweigen nur eine Variable ($\mathfrak{u}$).

Vergleich der Methoden 1

A. Koch

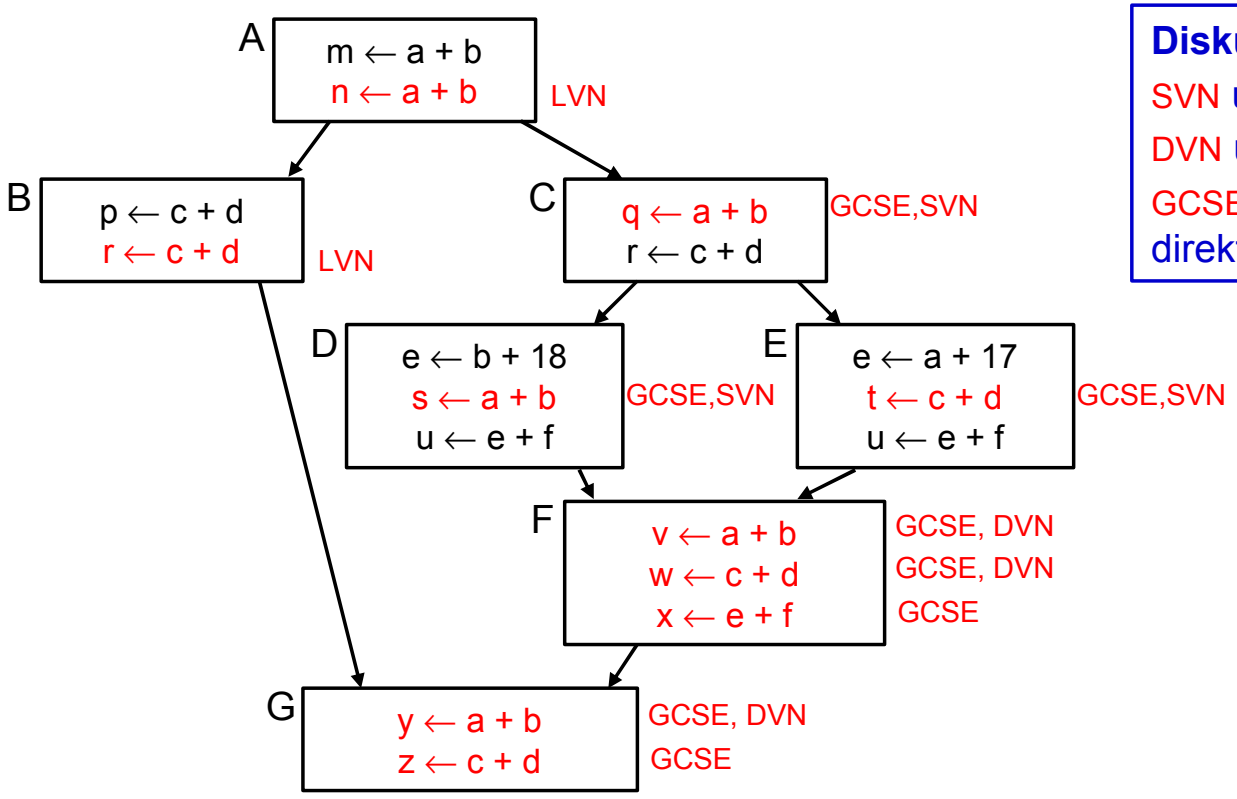

Diskussion:

SVN umfasst LVN

DVN umfasst SVN

GCSE & xVN sind nicht direkt vergleichbar

Vergleich der Methoden 2

- GCSE ist nicht zwangsläufig die mächtigste Methode
- Hätte im Beispiel zwar alles gefunden
- Hat aber auch Schwächen gegenüber xVN
- Arbeit mit lexikalischem Vergleich
- Kann z.B. nicht erkennen:
  $(a + b) = (c + d)$, wenn $a = d$ und $b = c$
- GCSE versucht auf lokaler Ebene zu kompensieren
  - Verwendung von LVN innerhalb von Basisblöcken

Zusammenfassung

- Charakteristika von Optimierungen
- Redundante Ausdrücke
- Versionen von Variablen ($\rightarrow$ SSA)
- Value Numbering
- Lokal, super-lokal, regional
- Dominatoren
- Global Common Subexpression Elimination
- Datenflußanalyse
- Vergleich der Techniken