

Übersicht

- Instruktionsanordnung
- Basisblockgraph
 - Basisblockgraph
 - Abhängigkeitsgraphen für Basisblöcke
 - Setzungen und Benutzungen
- Abhängigkeiten zwischen Befehlen
 - Algorithmus BBA-Graph
 - Verkleinerung des Abhängigkeitsgraphen
- Befehlsfließband
 - Algorithmus FB-Anordnung
 - Realistische Befehlsfließbänder
- Lange Befehlswörter
 - Verallgemeinerter Abhängigkeitsgraph
 - Kompensationscode
 - Realistische VLIW-Rechner

Lernziele

- Die Problematik der Instruktionsanordnung und das Lösungsprinzip mithilfe von Abhängigkeitsgraphen für Basisblöcke beschreiben können
- Probleme der Parallelverarbeitung und prinzipielle Lösungsmöglichkeiten für Befehlsfließbänder und „lange Befehlswörter“ wiedergeben können

Instruktionsanordnung

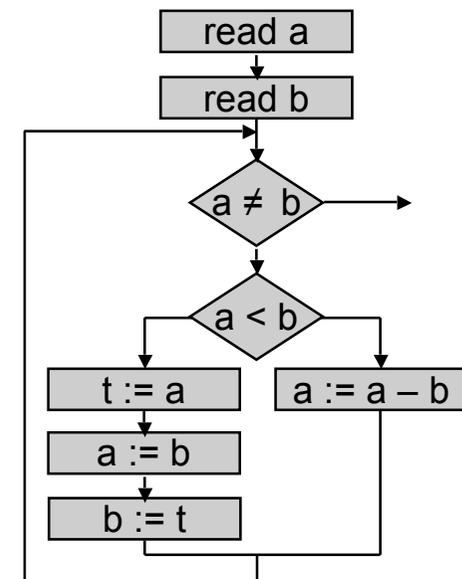
- Relevant für Prozessoren mit Parallelverarbeitung und/oder Befehlsfließband
- Umordnung der erzeugten Befehlsfolge, um parallel arbeitende Einheiten bzw. Befehlsfließband gut auszunutzen
- Problem
 - Semantik darf nicht verändert werden, insbesondere Abhängigkeiten zwischen den Berechnungen

Darstellung semantischer Aspekte

- Kontrollfluss
 - (Prozedur-) Aufrufgraph (call graph)
 - Knoten: HP und Prozeduren; Kanten: Aufrufbeziehung
 - Benötigt für interprozedurale Analyse
 - Kontrollflussgraph
 - Knoten: primitive Anweisungen; Kanten: Ausführungsordnung
 - Benötigt für intraprozedurale Analyse
 - *Basisblockgraph*
 - Abstraktion des Kontrollflussgraphen
- Semantische Abhängigkeiten: *Abhängigkeitsgraph*

Beispiel

```
read a; read b;  
while a ≠ b do  
  if a < b  
    then t := a; a := b; b := t  
  else a := a - b fi od
```



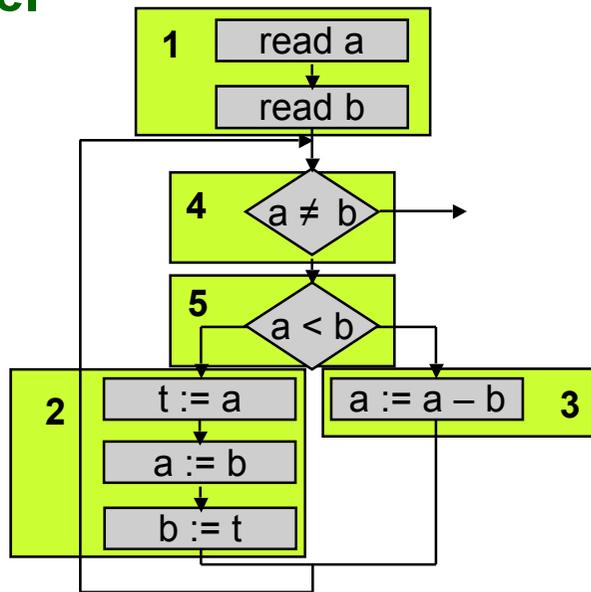
Basisblock (in einem Kontrollflussgraphen)

- Maximal langer Pfad, der höchstens am Anfang einen Knoten mit mehr als einem Vorgänger und höchstens am Ende einen Knoten mit mehr als einem Nachfolger hat

Basisblockgraph (kurz: BBG)

- Entsteht aus Kontrollflussgraphen durch Zusammenfassen von Basisblöcken zu Knoten

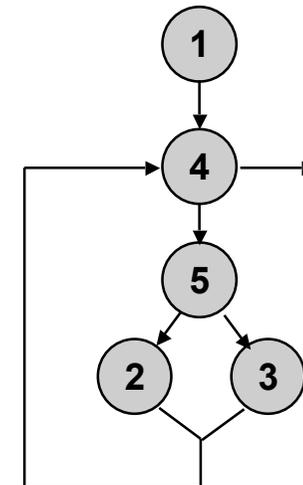
Beispiel



Kontrollflussgraph



Basisblöcke



Basisblockgraph

Charakteristika eines Basisblocks

- Befehlsfolge linear geordnet (insbesondere keine Verzweigungen)
- Wird vollständig und in der angegebenen Reihenfolge durchlaufen (wenn Kontrolle an ersten Befehl gegeben wird)

Umordnung der einzelnen Befehle

- Möglich, wenn „Gesamteffekt“ der Befehlsfolge unverändert bleibt
- Abhängig von Abhängigkeiten zwischen den Befehlsarten
 - **Setzungen** (definitions): Schreibende Zugriffe (dargestellt als $X :=$)
 - **Benutzungen** (uses): Lesende Zugriffe (dargestellt als $:= X$)

Beispiel

- Befehl $D1 := \text{ADD } M[A1 + D1.W], D5$
 - Benutzungen: Register A1, D1, D5; Speicher M
 - Setzungen: Register D1; verschiedene Bits im Bedingungscode
- Offensichtlich: Keine Umordnungsmöglichkeiten in der Befehlsfolge
 - a: $X :=$
 - b: $X :=$
 - c: $:= X$
 - d: $X :=$



Mögliche Setzungen in Maschinenprogrammen

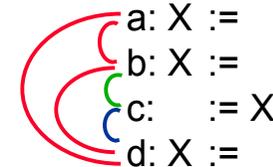
- Änderungen von Registerinhalten durch Ladebefehle, durch Resultatablage (nach Operationen) oder durch (automatische) In- bzw. Dekrementierung (von Adressregistern)
- Abspeichern von Werten in Speicherzellen
- Modifikation eines Kellerzeigers (durch Kellern und Entkellern von Werten und durch Befehle zur Prozedurorganisation)
- Setzen von Überlauf-, Unterlauf- oder Übertragsbits und Vergleichsergebnissen im Bedingungscode

Mögliche Benutzungen

- Benutzung von Registerinhalten in Operationen, zur Adressierung oder zum Abspeichern
- Laden des Inhalts von Speicherzellen
- Abfragen von Teilen des Bedingungscode in bedingten Sprüngen

Abhängigkeiten zwischen Befehlen (die sequentielle Anordnung erfordern)

- Betreffen *Maschinenressourcen*
(Einzelnes Register, Hauptspeicher, Bits des Bedingungscode)
- *Arten von Abhängigkeiten*
 - Setzung - Setzung („definition - definition“; kurz: d-d)
 - Setzung - Benutzung („definition - use“; kurz: d-u)
 - Benutzung - Setzung („use - definition“; kurz: u-d)



Extraktion von Abhängigkeiten aus Befehlsfolge

- Unmittelbar bei Registern (da explizit benannt)
- Probleme bei Speicherzellen: **alias-Problem**
(zwei Adressierungsarten mit dynamischen Anteilen in zwei verschiedenen Befehlen können Zugriff auf die gleiche Speicherzelle beschreiben)
- Deswegen (zunächst): Ganzer Speicher als **ein** Objekt betrachtet

Darstellung der Abhängigkeiten

- Im *Abhängigkeitsgraph*

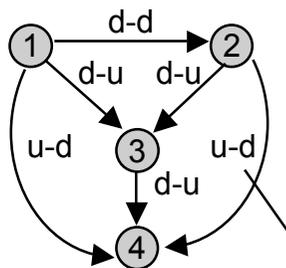
Abhängigkeitsgraph (eines Basisblocks)

- Knoten- und kantenmarkierter azyklischer gerichteter Graph
 - Knoten mit den Befehlen des Basisblocks markiert
 - Kante von a nach b, wenn a in der Befehlsfolge vor b steht und wenn
 - a = Setzung; b = Benutzung; Weg von a nach b setzungsfrei (**d-u-Abhängigkeit**)
 - a = Benutzung; b = Setzung; Weg von a nach b setzungsfrei (**u-d-Abhängigkeit**)
 - a = Setzung; b = Setzung; Weg von a nach b setzungs- und benutzungsfrei (**d-d-Abhängigkeit**)
 - Nur Kanten für direkte Abhängigkeiten (Indirekte Abhängigkeiten: transitive Hülle)

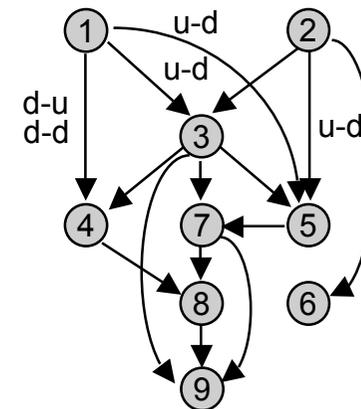
d-d { a: X :=
 b: X :=
 d-u { c: := X
 u-d { d: X :=

Beispiele

1: (CC, D1) := M[A1+ 4].W;
 2: (CC, D2) := M[A1 + 6].W;
 3: (CC, D1) := D1+ D2;
 4: M[A1 + 4] := D1.W;



1: D1 := M[A1+ 4];
 2: D2 := M[A1 + 6];
 3: A1 := A1 + 2;
 4: D1 := D1+ A1;
 5: M[A1]
 := A1;
 6: D2 := D2 + 1;
 7: D3 := M[A1 + 12];
 8: D3 := D3 + D1;
 9: M[A1 + 6] := D3;



Beachte:
nicht vollständig
annotiert

```

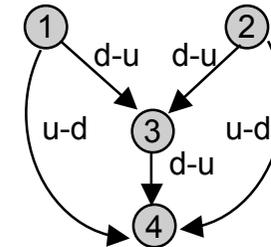
var   LS, EB: set of pair (Resource, Befehlsnummer);
      akt_Befehl: Befehlsnummer;
begin
  akt_Befehl := letzter Befehl des Basisblocks;
  erzeuge_Knoten (akt_Befehl);
  LS := Setzungen(akt_Befehl);
  EB := Benutzungen(akt_Befehl);
  while Vorgänger(akt_Befehl) definiert do
    akt_Befehl := Vorgänger(akt_Befehl);
    erzeuge_Knoten(akt_Befehl);
    foreach Resource r die in akt_Befehl gesetzt/benutzt wird do
      foreach (r, b) ∈ LS ∪ EB do
        case Konflikt(r, akt_Befehl, b) of
          d-d: if ∃(r, α) ∈ EB then ziehe_Kante(akt_Befehl → b) fi;
          d-u: ziehe_Kante(akt_Befehl → b);
          u-d: ziehe_Kante(akt_Befehl → b) endcase od od;
    foreach Resource r' die in akt_Befehl gesetzt wird do
      LS := LS \ {(r', α) ∈ LS} ∪ {(r', akt_Befehl)};
      EB := EB \ {(r', β) ∈ EB} od;
    foreach Resource r' die in akt_Befehl benutzt wird do
      EB := EB ∪ {(r', akt_Befehl)} od od
end
  
```

Basisblock

```

1: D1      := M[A1+ 4].W;
2: D2      := M[A1 + 6].W;
3: D1      := D1+ D2;
4: M[A1 + 4] := D1.W;
  
```

Abhängigkeitsgraph



```

Akt_Bef = 1;
LS = {(M,4), (D1,3), (D2,2)}
EB = {(A1,4), (A1,2), (D1,3), (M,2)}
r = {D1, M, A1}
für (D1,3): Konflikt(D1,1,3) = d-u
für (M,4): Konflikt(M,1,4) = u-d
für (M,2): Konflikt(M,1,2) = false
für (A1,4): Konflikt(A1,1,4) = false
für (A1,2): Konflikt(A1,1,2) = false
LS = {(M,4), (D1,1), (D2,2)}
EB = {(M,2), (A1,4), (A1,2)}
EB = {(M,2), (M,1), (A1,4), (A1,2), (A1,1)}
  
```

Eigenschaften des Abhängigkeitsgraphen

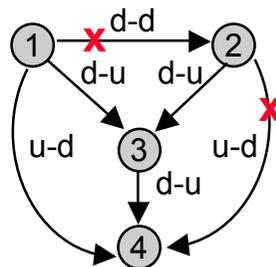
- Stellt mögliche Freiheitsgrade für die Umordnung von Befehlsfolgen dar
- Gültige Anordnungen durch *Topologisches Sortieren*
 - gesteuert durch Heuristiken
 - Eventuell zusätzliche Einschränkungen (z.B. vorgeschriebene Abstände zwischen voneinander abhängigen Befehlen)

Verkleinerung des Abhängigkeitsgraphen (Elimination von Kanten)

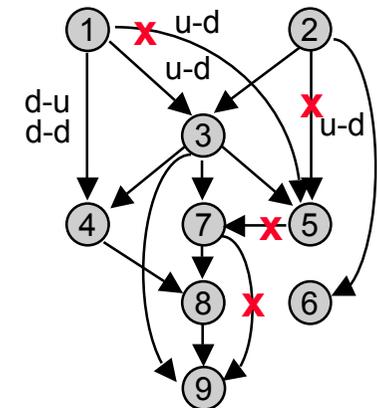
- *Aliasanalyse*: Verschiedenheit von Speicheradressen ermitteln
- *Lebendigkeitsanalyse*
 - Ermitteln, ob Ressourcen nach Setzung noch gebraucht werden (evtl. in nachfolgenden BBs)
 - Tritt häufig bei CC auf

Beispiele

- 1: (CC, D1) := M[A1+ 4].W;
- 2: (CC, D2) := M[A1 + 6].W;
- 3: (CC, D1) := D1+ D2;
- 4: M[A1 + 4] := D1.W;



- 5: M[A1] := A1;
- 6: D2 := D2 + 1;
- 7: D3 := M[A1 + 12];
- 8: D3 := D3 + D1;
- 9: M[A1 + 6] := D3;



Zielmaschine

- Prozessor mit k -stufigem Befehlsfließband
- Vereinfachende Annahme:
Abhängige Befehle stets nach Verzögerung von einem Zyklus ausführbar

Ziel der Instruktionsanordnung

- Umordnung der Befehlsfolgen innerhalb der Basisblöcke unter Beachtung der Abhängigkeiten und Fließbandbedingungen in möglichst kurze Befehlsfolgen
- Dabei
 - Ursprüngliche Befehle bleiben erhalten
 - Werden evtl. umgeordnet (unter Beachtung der Abhängigkeiten)
 - Zusätzliche NOP-Befehle (wo erforderlich)

Grundidee des Verfahrens

- *Topologisches Sortieren*  des azyklischen Abhängigkeitsgraphen

Topologisches Sortieren (allgemeine Idee)

- Geg.: partielle Ordnung R auf Menge X
- Ges.: totale Ordnung T auf X , die mit R verträglich ist
- Vorgehensweise
 - Initialisierung: minimale Elemente von R als Menge K (von Kandidaten)
 - Nach Wahl und Anordnung eines Elements x aus K : Entfernung von x (und seinen Kanten) aus K und R (damit: neue minimale Elemente in $R \setminus \{x\}$, die zu K hinzugefügt werden)

Besonderheit des Algorithmus FB-Anordnung

- Allgemeines topologisches Sortieren:
nichtdeterministische Auswahl unter den Kandidaten
- Hier: Heuristik, die Kollisionen berücksichtigt
 - Nur Kandidaten, die mit den zuletzt angeordneten Befehlen keine Kollision haben
 - Falls keine solchen existieren: Einfügen einer NOP-Instruktion
 - Falls solche existieren: Auswahl nach den (nach Priorität geordneten) Kriterien
 - Befehle, die mit vielen nachfolgenden Befehlen Kollisionen erzeugen können (sind i.a. Befehle, die die meisten Nachfolger im Abhängigkeitsgraphen haben)
 - Befehle, die auf jeweils längsten Pfaden zu den Blättern des Abhängigkeitsgraphen liegen

```

var Kands, rKands, potKolls: set of BefNr;
begin
  Kands := {Minimale El. von BBA-Graph};
  potKolls := {letzte Bef. in Anordnungen der Vorgänger-BBs};
  repeat
    rKands := Kands \ kollidierend(Kands, potKolls);
    if rKands ≠ ∅
      then wähle bestes b ∈ rKands (gemäß Heuristik);
           ordne b an;
           Kands := Kands / {b};
           entferne b und seine Kanten aus BBA-Graph;
           Kands := Kands ∪ {neue Quellen in BBA-Graph};
           potKolls := {b}
      else ordne NOP an;
           potKolls := ∅ fi
  until Kands = ∅
end

```

Angeordnete Befehle

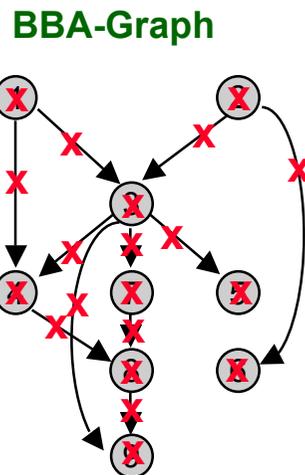
```

2: D2      := M[A1 + 6];
1: D1      := M[A1 + 4];
6: D2      := D2 + 1;
3: A1      := A1 + 2;
   NOP;
7: D3      := M[A1 + 12];
4: D1      := D1 + A1;
5: M[A1]   := A1;
8: D3      := D3 + D1;
   NOP;
9: M[A1 + 6] := D3;

```

Kands **potKolls**

{1,2} ∅



rKands	Bester zu elim. Kanten	Kands	potKolls
$\{1,2\} \setminus \emptyset = \{1,2\}$	2	2-3, 2-6	{1,6}
$\{1,6\} \setminus \{6\} = \{1\}$	1	1-4, 1-3	{6,3}
$\{6,3\} \setminus \{3\} = \{6\}$	6	∅	{3}
$\{3\} \setminus \emptyset = \{3\}$	3	3-4, 3-5, 3-7, 3-9	{4,5,7}
$\{4,5,7\} \setminus \{4,5,7\} = \emptyset$			∅
$\{4,5,7\} \setminus \emptyset = \{4,5,7\}$	7	7-8	{4,5}
$\{4,5\} \setminus \emptyset = \{4,5\}$	4	4-8	{5,8}
$\{5,8\} \setminus \{8\} = \{5\}$	5	∅	{8}
$\{8\} \setminus \emptyset = \{8\}$	8	8-9	{9}
$\{9\} \setminus \{9\} = \emptyset$			∅
$\{9\} \setminus \emptyset = \{9\}$	9	∅	{9}

Probleme bei realistischen Befehlsfließbändern

- Spezielle Verzögerungen (> 1) zwischen Befehlen erforderlich
(neue Datenstruktur(en) statt der Menge potKoll im Algorithmus FB-Anordnung)
- „Hot spots“
Werte im Fließband, die genau einen Zyklus später verarbeitet werden müssen,
nachdem sie produziert wurden

Z.B. Schlange(n)
fester Länge(n)

Durch beide Aspekte

- Weitere Einschränkungen für einen Instruktionsanordner
- Entsprechende Vergrößerung des Aufwands

Problem

- Codeerzeugung für einen Prozessor mit n parallel arbeitenden funktionalen Einheiten und (n Befehle breitem) langem Befehlswort
- Vereinfacht: Umordnung einer Befehlsfolge in n (parallele) Befehlsfolgen (oder in eine neue n Befehle breite Folge von langen Befehlsworten)
- Dazu notwendig: Befehlsanordnung über Basisblockgrenzen hinaus (da möglicher Parallelismus innerhalb von Basisblöcken sehr beschränkt ist)

n häufig > 10

*Bei numerischen Programmen:
Faktor 2-3; Sonst kleiner*

Prinzipielles Verfahren

- Anordnen von „Pfadern“ (trace scheduling) anstelle von Basisblöcken
- Grundidee (Berücksichtigung der relativen „Durchlaufhäufigkeit“)
 - Um mögliche Parallelität zu erhöhen:
Gemeinsame Anordnung von Instruktionen aus aufeinander folgenden Basisblöcken, die während der Programmausführung „häufig“ unmittelbar nacheinander ausgeführt werden
 - Häufigkeitsinformation aus Messungen oder heuristischen Schätzungen



Zerlegung des Kontrollflussgraphen (einer Prozedur)

- Bestimmung des ersten Teilpfades
 - Zunächst betrachtet: am häufigsten durchlaufener Basisblock
 - Dann: Entscheidung darüber, ob und welche vorangehenden oder nachfolgenden Basisblöcke gemeinsam mit diesem angeordnet werden sollen
 - Dabei verwendet: Geeignete Strategie auf der Basis der relativen Durchlaufhäufigkeit
- Für den gewonnenen Teilpfad wird dann eine *Folge langer Befehlswörter konstruiert* ➡
- Bestimmung der weiteren Teilpfade
 - Von den noch nicht angeordneten Basisblöcken dann wieder den am häufigsten durchlaufenen auswählen und w.o. verfahren
- Ende: alle Basisblöcke der Prozedur sind (im Rahmen von Teilpfaden) angeordnet



Konstruktion von Folgen langer Befehlswörter für Teilpfade

- Teilpfade können als verlängerte Basisblöcke gesehen werden (aus denen Verzweigungen hinaus- und in die Zusammenführungen hineinführen)
- Ziel: Packen der Befehle des Teilpfads in möglichst kurze Folge langer Befehlswörter (ohne Abhängigkeiten und durch Kontrollfluss gegebene semantische Bedingungen zu verletzen)
- Annahme
 - Unbeschränkt viele funktionale Einheiten
 - Beliebig lange Befehlswörter
- Dann gilt
 - Kürzeste mögliche Folge von langen Befehlswörtern so lang wie der längste (kritische) Pfad des *verallgemeinerten Abhängigkeitsgraphen* ➡

Abhängigkeiten bleiben erhalten

Möglicher (optimaler) Algorithmus

- Aus topologischem Sortieren ableitbar
 - Füllung eines neuen Befehlswords mit der Menge von Kandidaten (= Befehle, die keine Vorgänger mehr haben)
 - Dabei: Verschieben von Befehlen über Verzweigungen hinweg mithilfe *semantikerhaltender Transformationen* (die für Erzeugung des notwendigen *Kompensationscodes* ➡ sorgen)



Verallgemeinerter Abhängigkeitsgraph

- Darstellung von Abhängigkeiten in Teilpfaden
- Im folgenden betrachtet: Bedingte Anweisungen und Schleifen

Bedingte Anweisungen (s_0 ; **if** b **then** s_1 **else** s_2 **fi**; s_3)

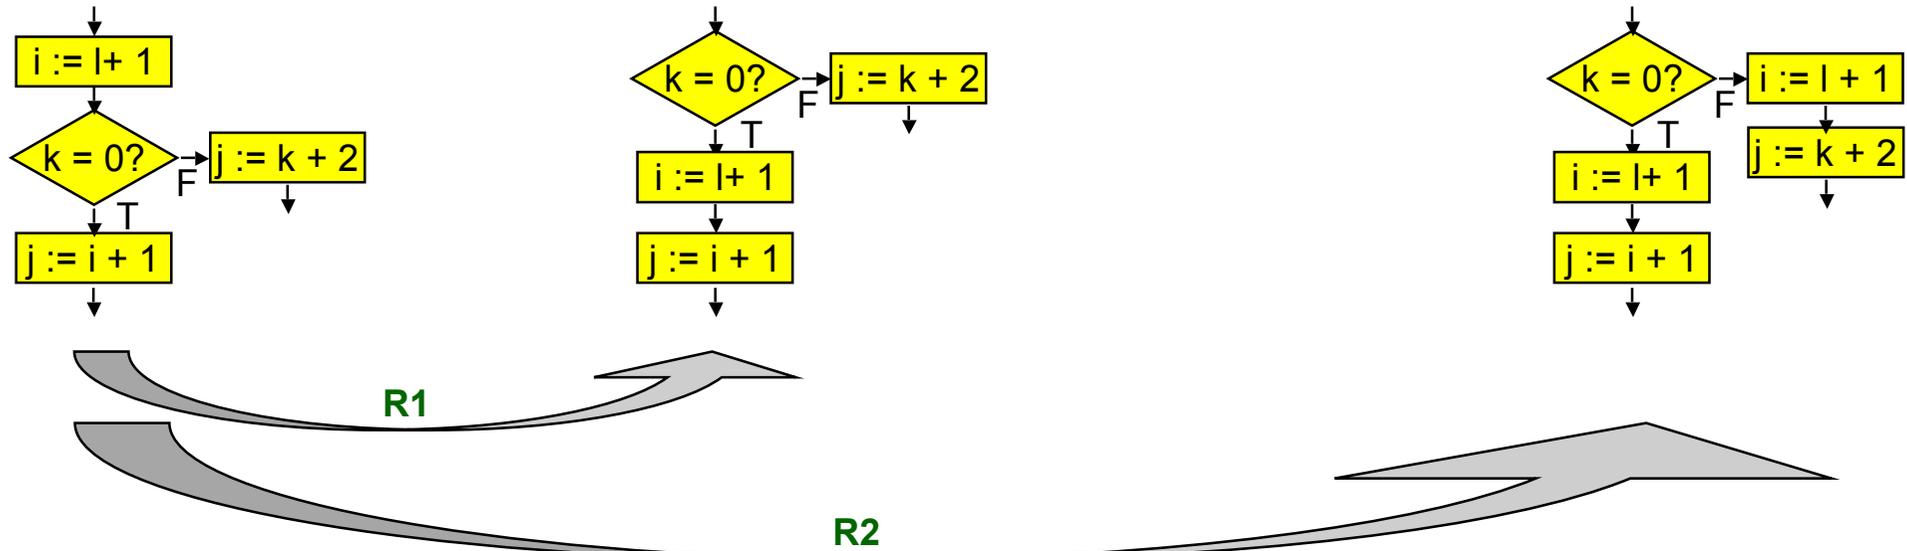
- Hier
 - Zwei mögliche Wege, nämlich s_0 ; b ; s_1 ; s_3 und s_0 ; b ; s_2 ; s_3
 - Verallgemeinerter Abhängigkeitsgraph enthält alle Abhängigkeiten zwischen Benutzungen und Setzungen auf diesen beiden Wegen
- Vorgehensweise: Modifikation des Algorithmus BBA-Graph
 - Beide Wege (s_1 und s_2) werden von hinten mit denselben Werten von LS und EB betreten
 - Danach: Vereinigung der aktuellen Werte von LS und EB und Verarbeitung der Bedingung

Schleifen (s_0 ; **while** b **do** s_1 **od**; s_2)

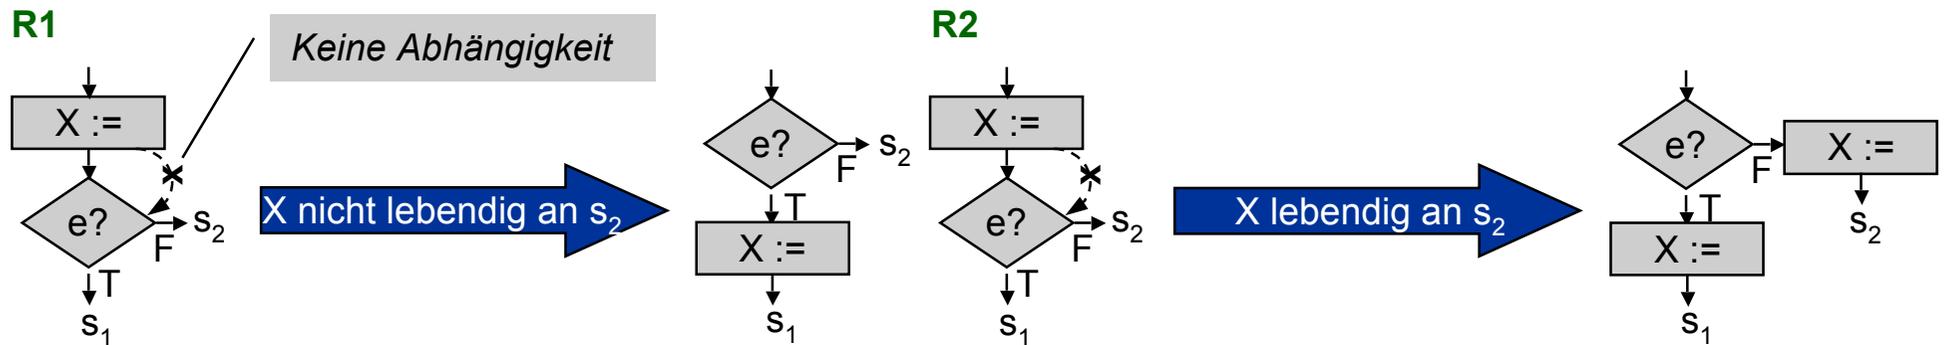
- Hier
 - Potentiell unendlich viele Wege, nämlich s_0 ; b ; $(s_1; b)^*$ s_2
 - Für die Berechnung der Abhängigkeiten ausreichend: s_0 ; b ; s_2 und s_0 ; b ; s_1 ; b ; s_1 ; b ; s_2
- Vorgehensweise: Modifikation von BBA-Graph
 - Jede Schleife wird zweimal durchlaufen
 - 1. mit den hinter ihr gültigen Werten von LS und EB
 - 2. mit den neuen Werten, die sich nach Bearbeitung der Schleifenbedingung ergeben haben



Beispiel (Codeumordnung mit Einfügen von Kompensationscode)

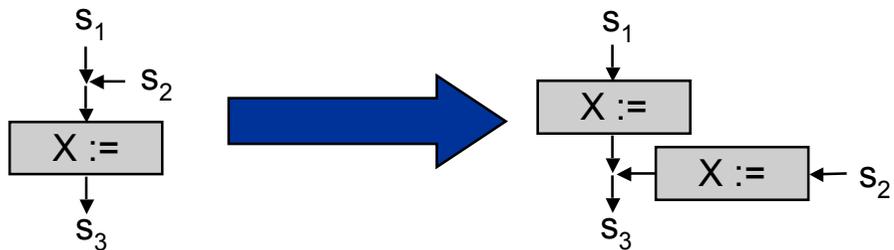


Umordnungsregeln

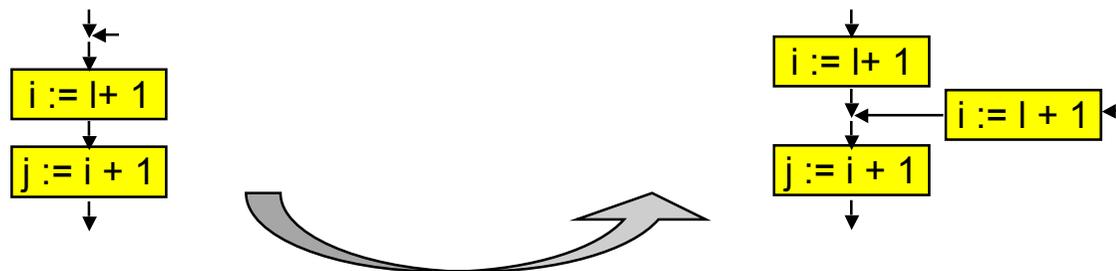




Weitere Umordnungsregeln

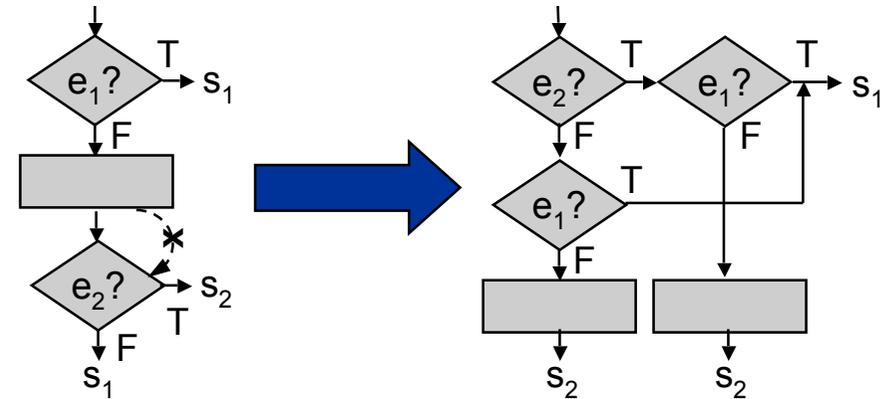
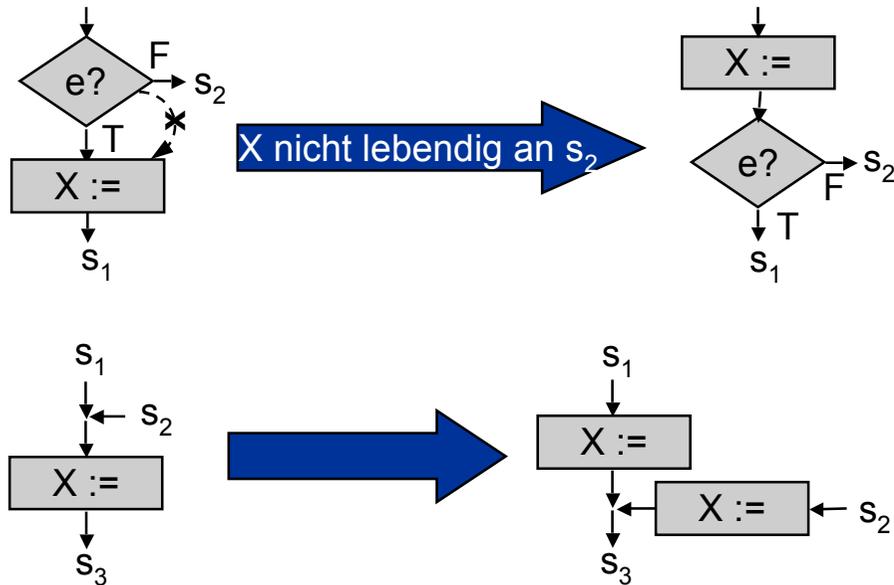


Beispiel (Anwendung der letzteren Regel)

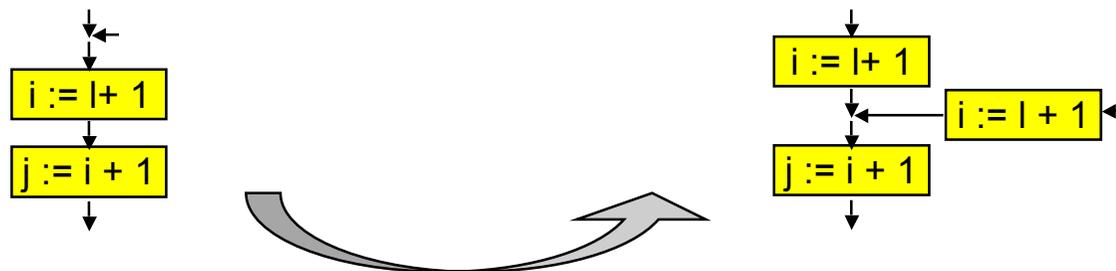




Weitere Umordnungsregeln



Beispiel (Anwendung der letzteren Regel)





Zusätzliche Probleme für den Codeerzeuger

Aufgabe der bisherigen Annahmen

- Endliche Anzahl funktionaler Einheiten (FEs)
 - Problem: Bei der Anordnung des erweiterten Abhängigkeitsgraphen in möglichst wenigen Ebenen muss die endliche Breite der Ebenen (festgelegt durch die Anzahl der FEs) berücksichtigt werden
 - Heuristik: Bevorzugte Platzierung der Befehle auf dem längsten Pfad (wenn es mehr Kandidaten als funktionale Einheiten gibt)
- Unterschiedliche Ausführungszeiten von Befehlen
 - Markierung der Kanten des Abhängigkeitsgraphen mit nötigen Verzögerungen
 - Heuristik: Bevorzugte Anordnung der Befehle auf dem kritischen Pfad (= Pfad mit maximaler Summe seiner Verzögerungen)
- Beschränkte Bandbreite des Registersatzes und des Speichers
 - Da nicht jede FE zu jedem Zeitpunkt auf jedes Register/Speicherstelle zugreifen kann, Aufteilung von Registersatz und Speicher in mehrere „Bänke“ (die teilweise verbunden sind); jede FE nur mit Teilmenge der „Bänke“ verbunden
 - Neue Aufgaben des des Codeerzeugers
 - Lokalität zwischen Registern, Speicher und FEs berücksichtigen
 - „Transportkosten“ zwischen Bänken minimieren