Martin Glinz  Harald Gall

# Software Engineering

Wintersemester 2005/06

Kapitel 11

# Statische Analyse

Universität Zürich
Institut für Informatik

# Inhalt

- Grundlagen
- Analyse von Programmen
- Darstellungen für die Programmanalyse
- Program Slicing

# Grundlagen

*Statische Analyse ist die Untersuchung des statischen Aufbaus eines Prüflings auf die Erfüllung vorgegebener Kriterien.*

- Die Prüfung ist statisch. Sie grenzt sich damit vom (dynamischen) *Test* ab.
- Sie ist formal durchführbar und damit automatisierbar. Sie grenzt sich damit vom *Review* ab.
- Ziele
  - Bewertung von Qualitätsmerkmalen, z.B. Pflegbarkeit, Testbarkeit aufgrund struktureller Eigenschaften des Prüflings (zum Beispiel Komplexität, Anomalien)
  - Erkennung von Fehlern und Anomalien in neu erstellter Software
  - Erkennung und Analyse von Programmstrukturen bei der Pflege und beim Reengineering von Altsystemen (*legacy systems*)
  - Prüfen, ob ein Programm formale Vorgaben (zum Beispiel Codierrichtlinien,Namenskonventionen, etc.) einhält

# Analyse von Programmen

- Syntax
  - Analyse durch den Compiler
- Datentypen, Typverträglichkeit
  - typ-unverträgliche Operationen
  - typ-unverträgliche Zuweisungen
  - typ-unverträgliche Operationsaufrufe

# Programm- und Datenstrukturen

- Formale Eigenschaften
  - Richtlinien eingehalten
  - Art und Menge der internen Dokumentation
- Strukturkomplexität des Progamms
  - Einhaltung von Strukturierungsregeln
  - Art und Tiefe von Verschachtelungen
- Strukturfehler bzw. -anomalien
  - nicht erreichbarer Code
  - vorhandene, aber nicht benutzte Operationen
  - benutzte, aber nicht vorhandene Operationen
- Fehler / Anomalien in den Daten
  - nicht deklarierte Variablen
  - nicht benutzte Variablen
  - Benutzung nicht initialisierter Variablen

# Vorgehen

- Bei Programmen immer mit Werkzeugen
  - Compiler
  - syntaxgestützte Editoren
  - spezielle Analyse-Werkzeuge
- Programm wird wie bei der Übersetzung durch ein Werkzeug zerlegt (parsing) und in einer analysefreundlichen internen Struktur repräsentiert
- Dabei werden Syntaxfehler erkannt und erste Kenngrößen (z. B. Anzahl Codezeilen, Anzahl Kommentare) ermittelt
- Die resultierende interne Repräsentation des Programms wird verschiedenen Analysen unterworfen (z.B. statische Aufrufhierarchie, Strukturkomplexität, Datenflussanalyse)
- Die Befunde werden gesammelt, ggf. verdichtet und bewertet

# Weitere Analysen

- Analyse von Algorithmen
  - Laufzeiteffizienz
  - Speichereffizienz
  - Gültigkeitsbereich
  - Erfolgt weitestgehend manuell
- Analyse von Spezifikationen, Entwürfen, Prüfvorschriften
  - Syntaxanalyse der formal beschriebenen Teile
  - Teilweise Struktur- und Flussanalysen (je nach verwendeter Modellierungsmethode)
  - Analyse der Anforderungsverfolgung, wenn dokumentiert ist, welche Anforderung wo umgesetzt bzw. geprüft wird (werkzeuggestützt möglich)

# Darstellungen für die Programmanalyse

Abstrakte Syntaxbäume

Kontrollflussanalyse

Datenflussanalyse


Universität Zürich
Institut für Informatik

# Inhalt

- Lernziele
  - Grundlagen für Programmanalysen
  - Unterschiedliche Anforderungen innerhalb des (Re)Engineerings
  - Verständnis der Abstraktionsebenen von Programmdarstellungen
- Kontext
  - Grundlegende Programmanalysen sind Basis aller weiteren Analysen

# Compiler Struktur

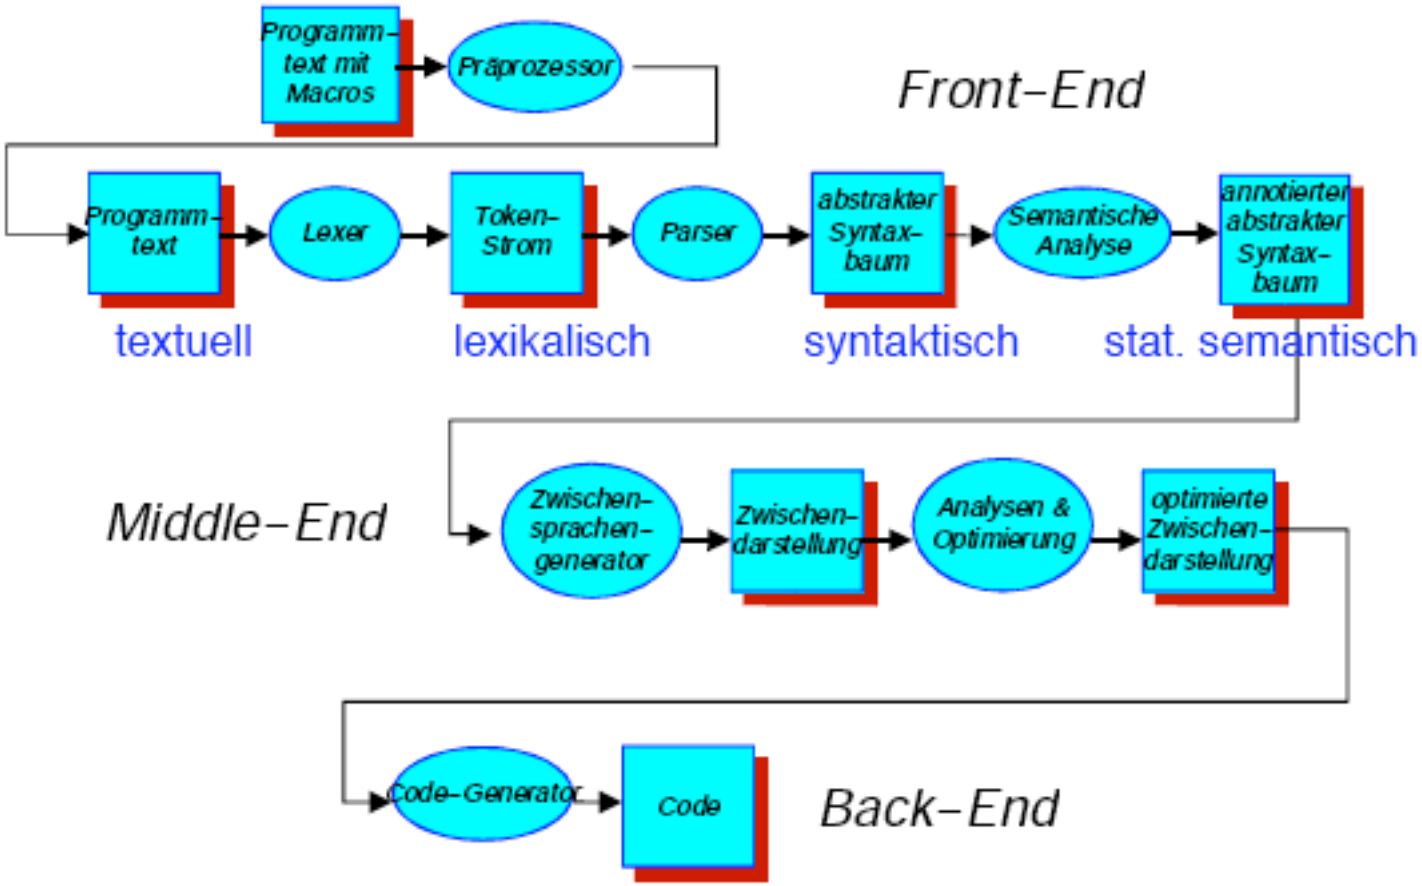

# Analysator Struktur

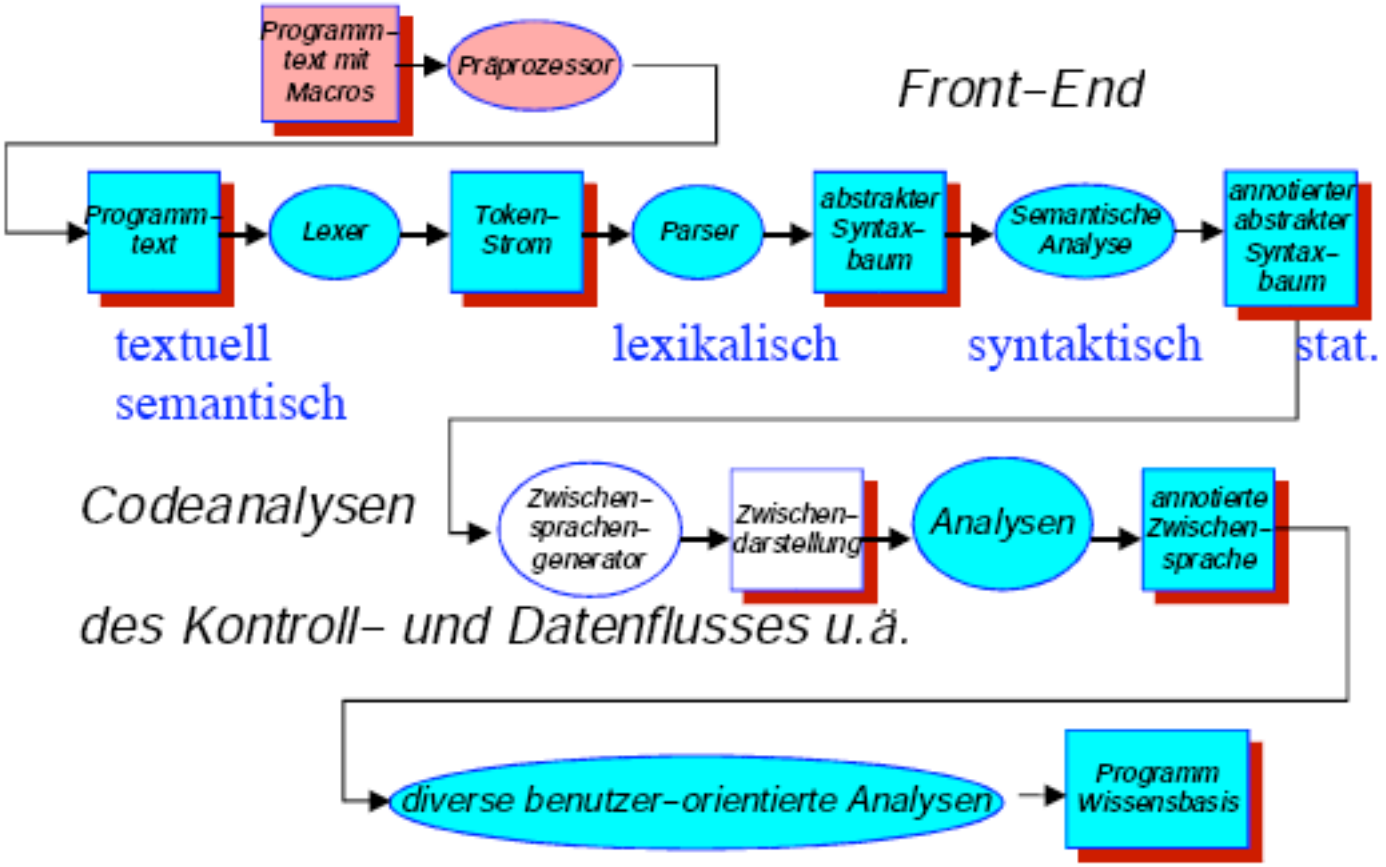

# Phasen eines Compilers

- Wissen über das Programm nimmt zu
  - syntaktische Dekomposition
  - semantische Attributierung
    - Namensbindung
    - Kontrollflussinformation
    - Datenflussinformation
- Abstraktion nimmt ab
  - abstrakter Syntaxbaum
  - maschinennahe einheitliche Zwischensprache, z.B. Register Transfer Language (RTL) von Gnu GCC
  - Maschinensprache

# Unterschiede Compiler / Analysator

- lokal versus global
- optimistisch versus pessimistisch
- quellennah versus sprachenunabhängig

# Der Tokenstrom

Für das Programmstück

```
declare
  X : real;
begin
  X := A * 5;
end
```

*liefert der Lexer neben der Quellposition die Lexeme (Token) durch Integer-Kennung der erkannten Kategorie und ggf. die Zeichenkette:*

```
9 -- “declare”
4 -- id,   “X”
7 -- “:”
4 -- id,   “real”
5 -- “;”
6 -- “begin”
4 -- id,   “X”
3 -- “:=“
4 -- id,   “A”
8 -- “*”
10 -- int_lit,   “5”
5 -- “;”
11 -- “end”
```

# Der Lexer

Grammatik

| | |
|---|---|
| D | [0-9] |
| L | [a-z,A-Z] |
| “else” | { return(ELSE); } |
| … | |
| {L} ( {L} \| {D} )* | { yylval.id = register_name(yytext); return (ID); } |

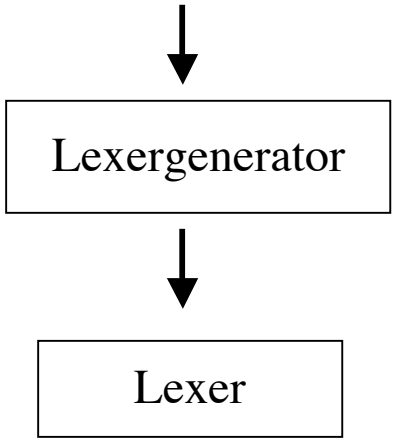

# Syntaxdiagramm

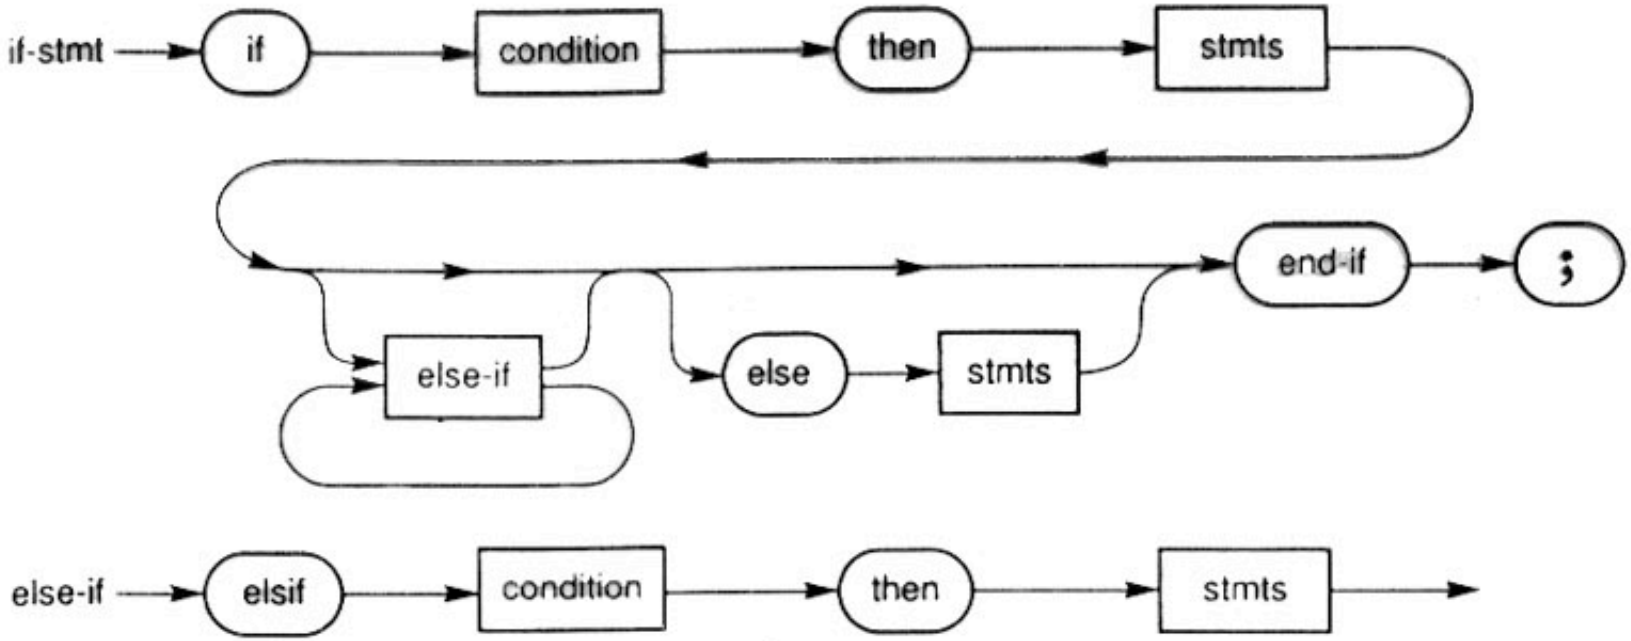

# Abstrakte Syntaxbäume (AST)

- Darstellung der syntaktischen Dekomposition des Eingabeprogramms
  - vereinfachter Ableitungsbaum: keine Kettenregeln, Sequenzen ersetzen Rekursionen etc.
  - syntaktische Kanten bilden einen Baum
- Eine formale Syntaxbeschreibung (BNF) legt die syntaktische Struktur fest:
  - Proc ::= PROCEDURE Id PL ";" .
  - PL ::= "(" Params ")" | e .
  - Params ::= Param "," Params | Param .
  - Param ::= Id .

*BNF .. Backus-Naur Form*
*EBNF .. Extended BNF*

# Ableitungsbaum / abstrakter Syntaxbaum

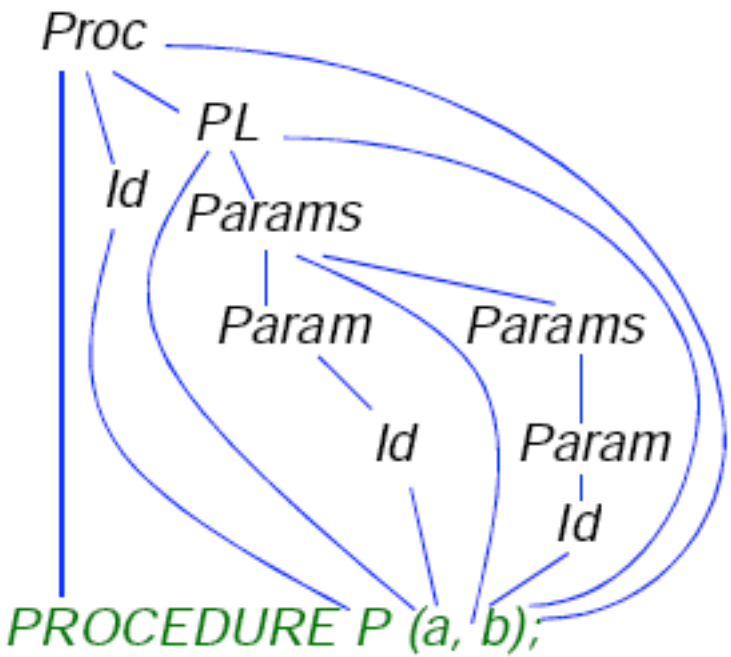


Ableitungsbaum

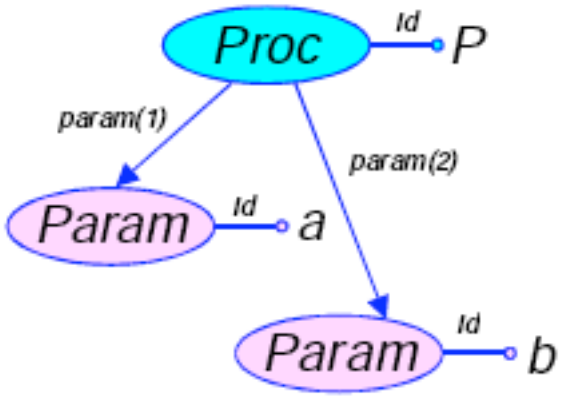


Abstrakter Syntaxbaum

# Beispiel eines ASTs

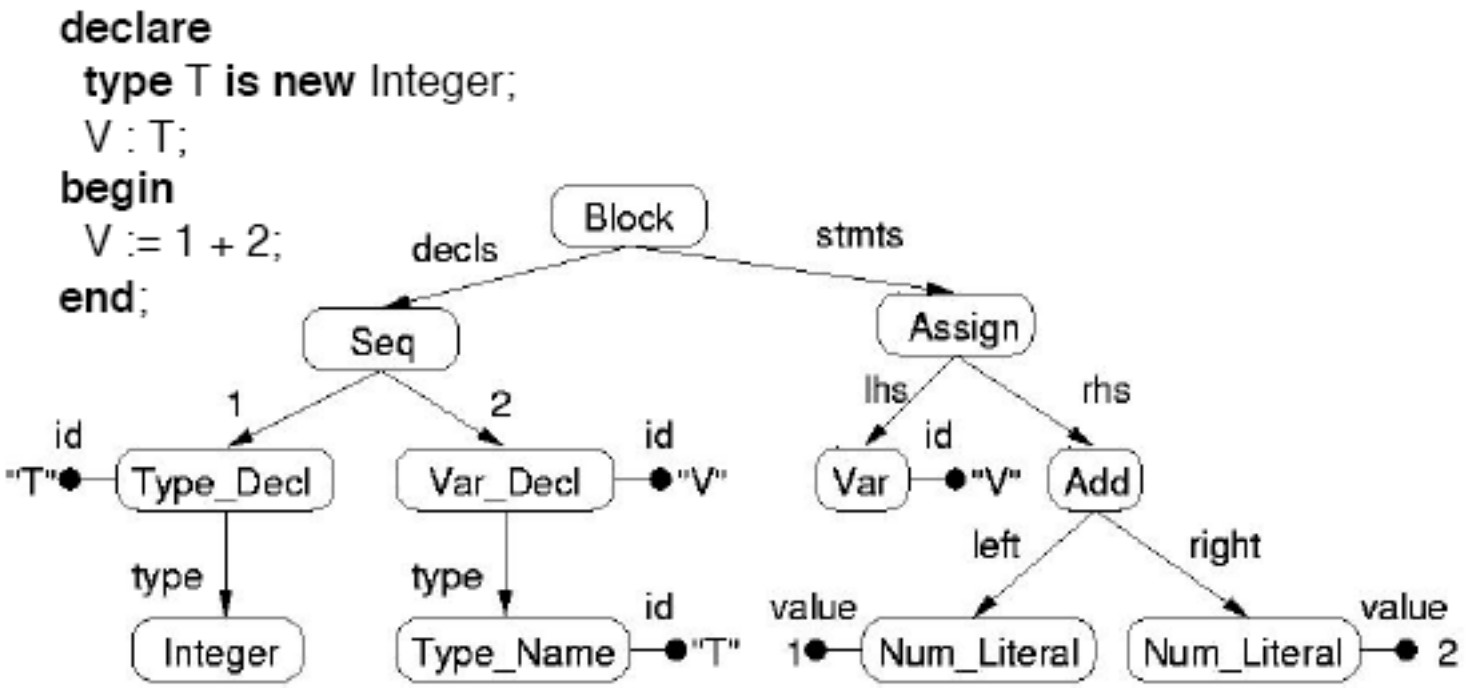

# Anforderungen an Zwischendarstellungen

- widersprüchliche Anforderungen
  - möglichst quellennah, da Informationen an Wartungsprogrammierer ausgegeben werden sollen bzw. tatsächlicher Code wieder generiert werden soll
    - d.h. alle spezifischen Konstrukte müssen dargestellt werden
  - möglichst vereinheitlicht, um das Schreiben von Programmanalysen für verschiedene Programmier-sprachen zu vereinfachen
    - d.h. möglichst wenige, allgemeine Konstrukte

# Quellennahe Betrachtung

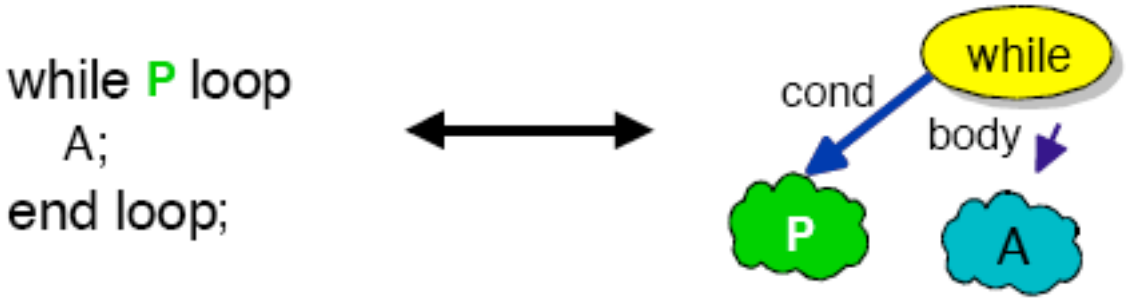

# Einfache allgemeine Konstrukte

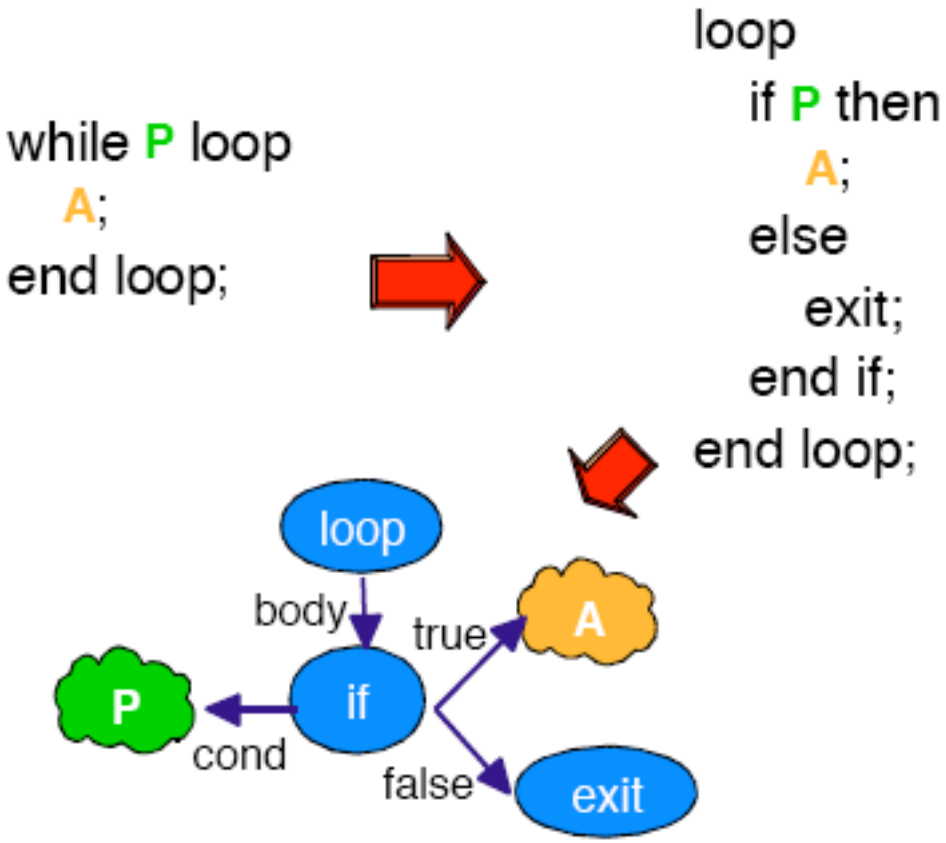

# Vereinigung der Sichten

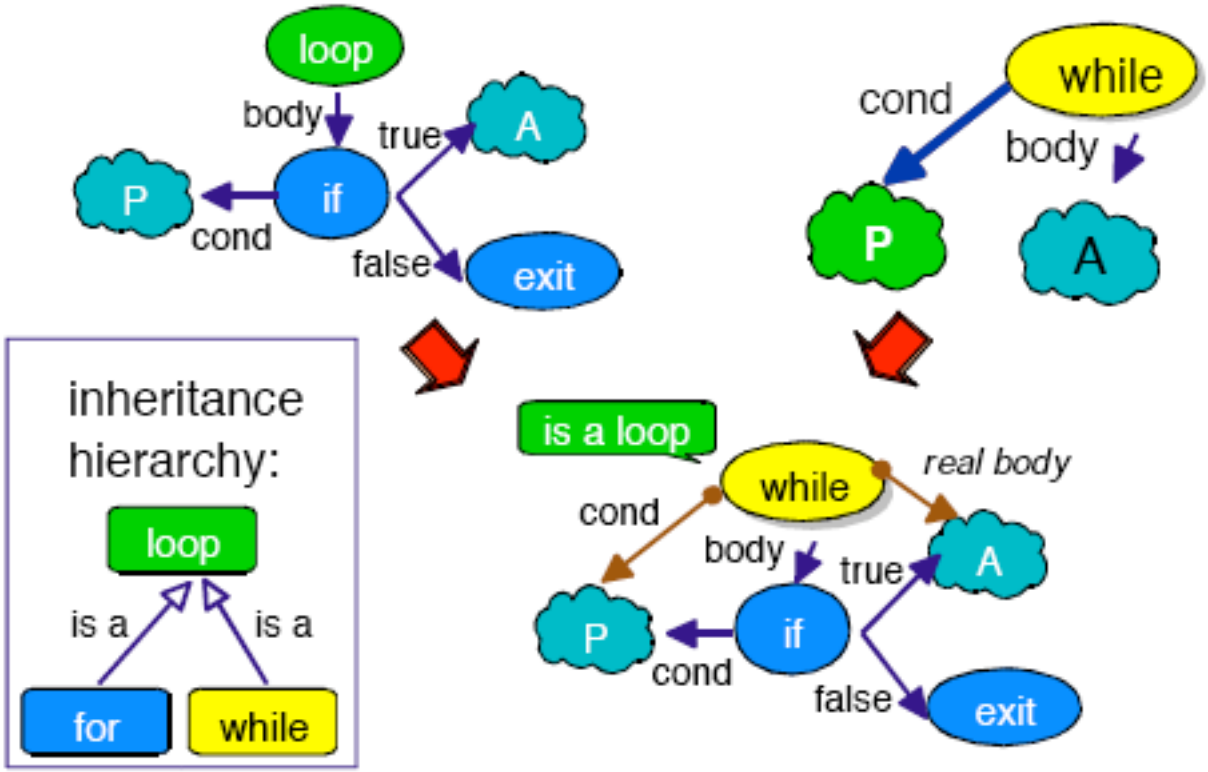

# Zwischendarstellungen

- Im Folgenden präsentieren wir die wichtigsten Elemente der Darstellung dynamischer Semantik und deren Herleitung ...
  - Kontrollflussanalyse
  - Datenflussanalyse

# Kontrollflussinformation

- intra-prozedural: Flussgraph
  - Knoten: Grundblöcke
  - Kanten: (bedingter/unbedingter Kontrollfluss
  - ergibts sich aus syntaktischer Struktur und etwaigen Goto's, Exit's, Continue's, etc.
- inter-prozedural: Aufrufgraph
  - Multigraph
  - Knoten: Prozeduren
  - Kanten: Aufruf
  - ergibt sich aus expliziten Aufrufen im Programmcode sowie Aufrufe über Funktionszeiger

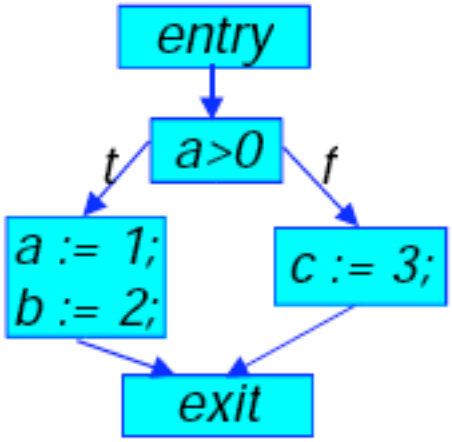


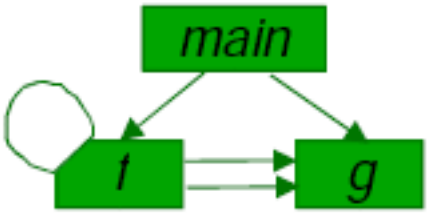

# Intra- und interproz. Kontrollfluss

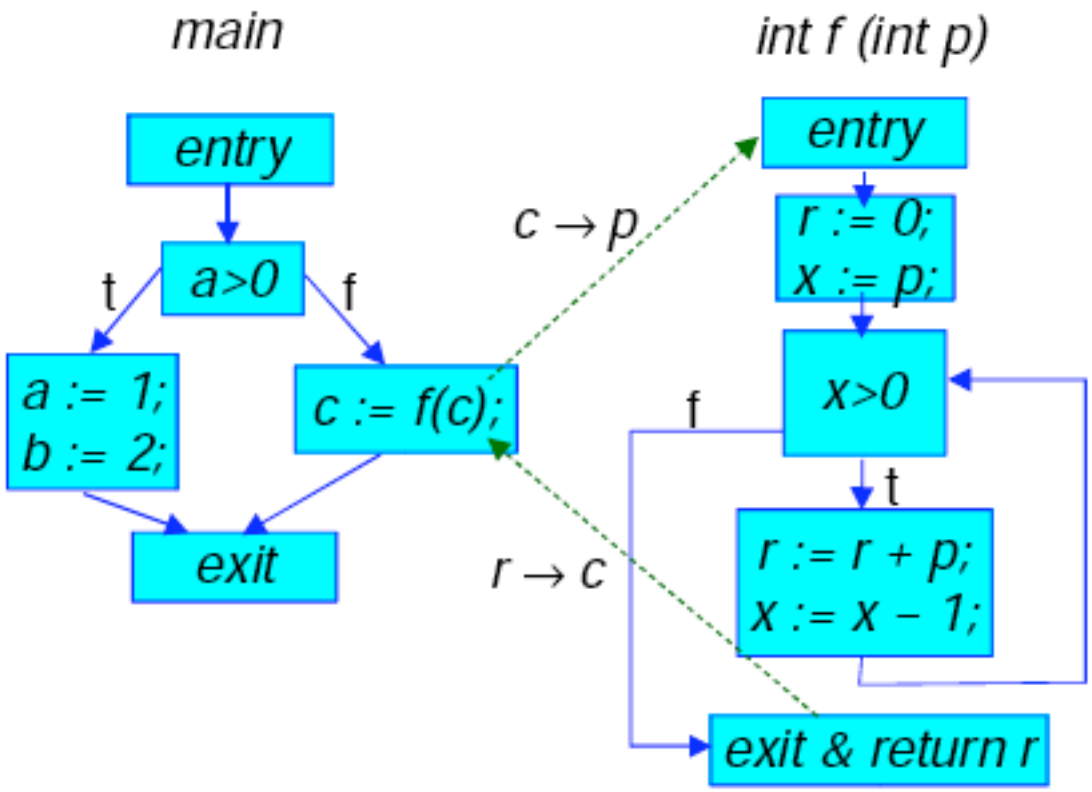

# Dominanz

- Fragestellungen
  - Welche Prozeduren sind lokal zueinander?
    Genauer: Gibt es eine Prozedur D, über nur die ein Aufruf von N erfolgt?
  - Welcher Block D im Flussgraph muss in jedem Falle passiert werden, damit Block N ausgeführt werden kann?
- Antwort: D ist der Dominator von N
  - Ein Knoten D **dominiert** einen Knoten N, wenn D auf allen Pfaden vom Startknoten zu N liegt.
  - Ein Knoten D ist der **direkte Dominator** von N, wenn
    - D dominiert N und
    - alle weiteren Dominatoren von N dominieren D

# Dominanz II

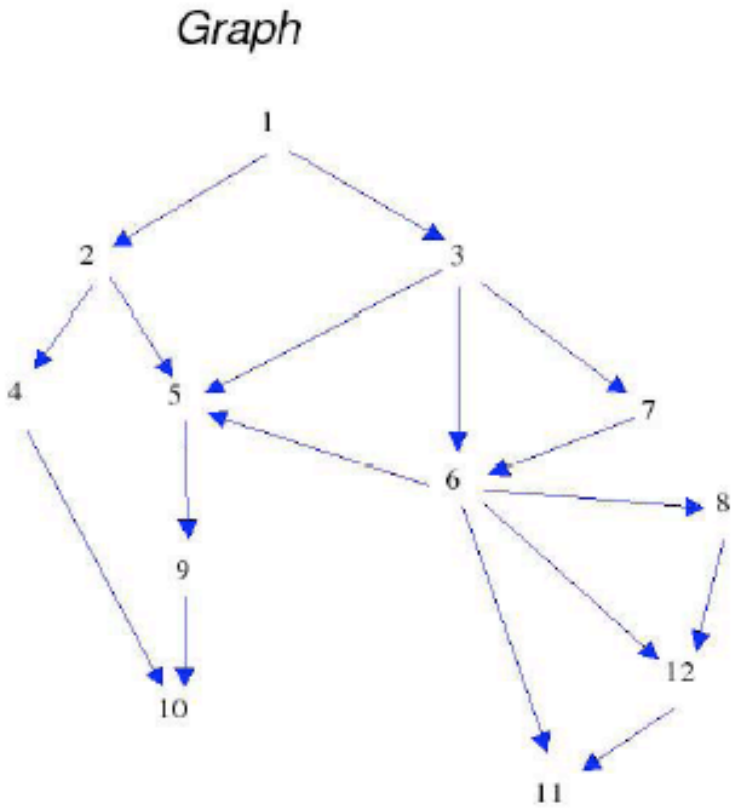


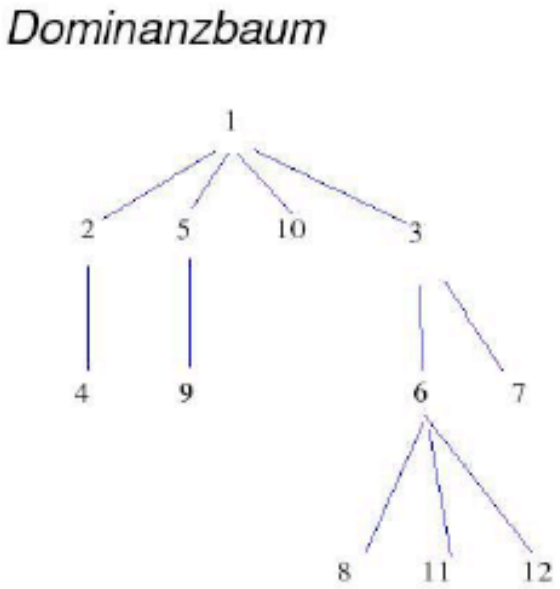

# Postdominanz

- Ein Knoten D postdominiert einen Knoten N, wenn jeder Pfad von N zum Endknoten den Knoten D enthält (entspricht Dominanz des umgekehrten Graphen).

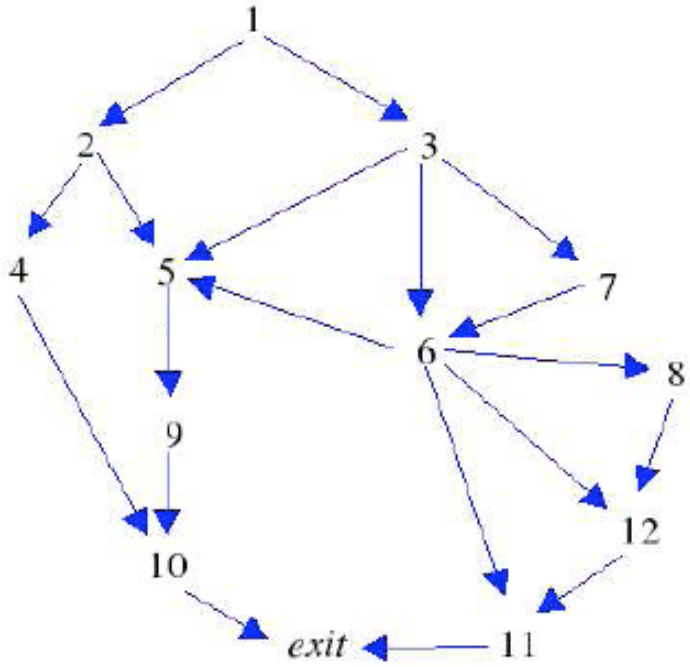


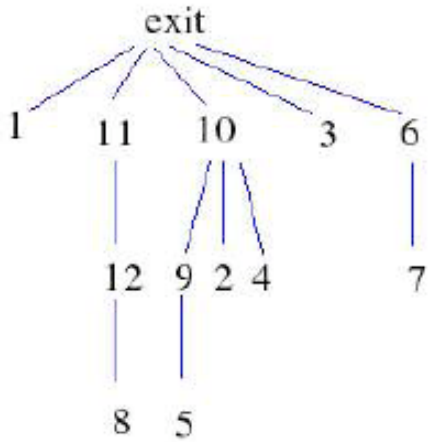

# Kontrollabhängigkeit I

- Kontrollabhängigkeit = Bedingung B, von welcher die Ausführung eines anderen Knotens X abhängt.
  - B muss mehrere direkte Nachfolger haben und
  - B hat einen Pfad zum Endknoten, der X vermeidet (d.h. B kann nicht von X postdominiert werden) und
  - B hat einen Pfad zu X, d.h. insgesamt hat B mindestens 2 Pfade:
    - einer führt zu X
    - einer umgeht X

    und
  - B ist der letzte Knoten mit einer solchen Eigenschaft

# Kontrollabhängigkeit II

- Ein Knoten X ist kontrollabhängig von einem Knoten B genau dann, wenn
  - es einen nicht-leeren Pfad von B nach X gibt, so dass X jeden Knoten auf dem Pfad (ohne B) postdominiert
  - entweder X = B oder X postdominiert B nicht

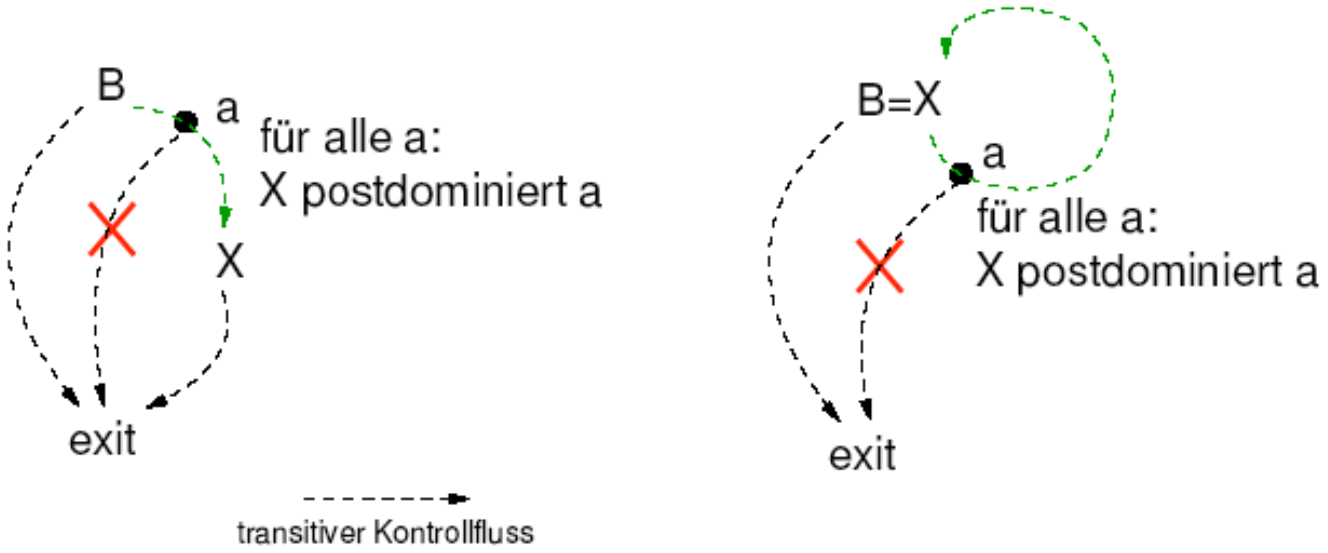

# Kontrollabhängigkeit

- Für strukturierte Programme
  - eine Anweisung ist kontrollabhängig von der Bedingung der nächstumgebenden Schleife oder bedingten Anweisung

```
while a loop
   if b then
      x := y;  --- kontrollabhängig von b
   end if;
   z := 1;  --- kontrollabhängig von a
end loop;
```

- N.B.: Bedingungen in repeat-Schleifen sind von sich und dem umgebenden Konstrukt abhängig

# Repräsentation der Kontrollabhängigkeit

```
if x > 0 then
      a := 1;
else
      a := 2;
end if;
if z > y then
      z := a;
else
      y := a;
end if;
```

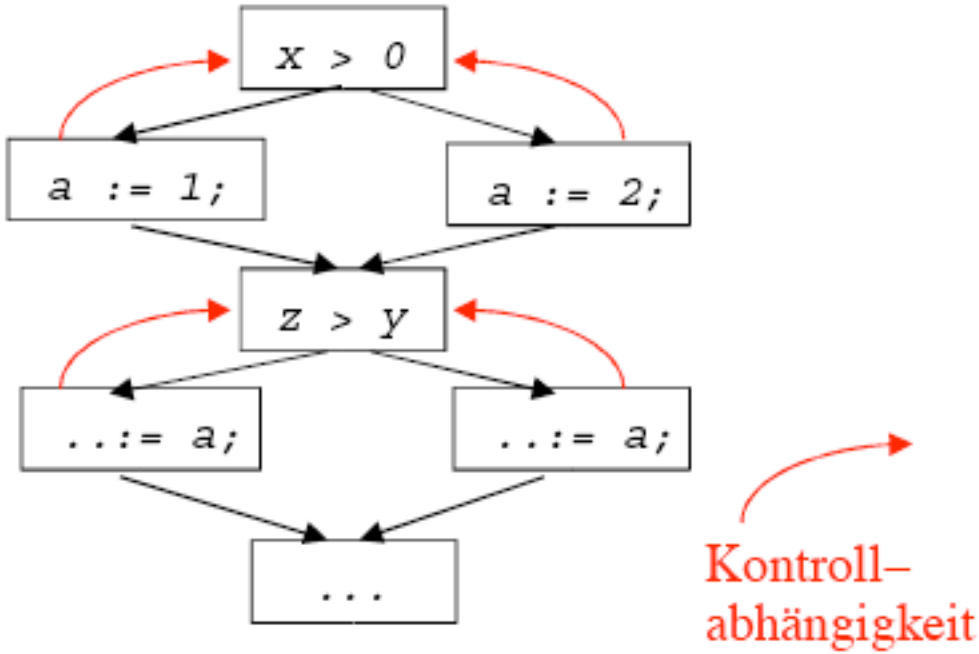

# Datenabhängigkeitsanalyse

- Set = Setzen eines Wertes
- Use = Verwendung eines Wertes
- Daraus ergeben sich folgende relevanten Beziehungen zwischen zwei Anweisungen (resp. Knoten) A und B:
  - Set-Use Beziehung (Datenabhängigkeit)
    - A setzt den Wert, der von B verwendet wird
  - Use-Set Beziehung (Anti-Dependency)
    - A liest den Wert und B überschreibt ihn danach
  - Set-Set Beziehung (Output-Dependency)
    - der von A gesetzte Wert wird von B überschrieben
- Codetransformationen müssen diese Beziehungen erhalten.

# Datenabhängigkeit (Set-Use)

Für die Zwecke der Analyse ist die Set-Use Beziehung die wichtigste Beziehung und wird intern oft explizit repräsentiert (meist in der umgekehrten Richtung).

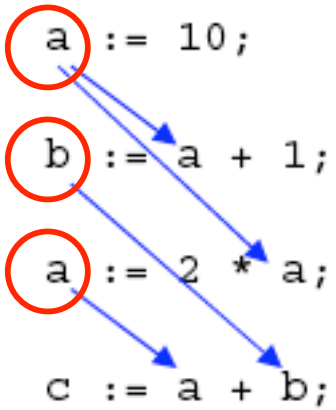


Zwischen der 2. und 3. Anweisung besteht eine “Use-Set”, zwischen der 1. und 3. Anweisung eine “Set-Set”-Beziehung.

# Repräsentation der Datenabhängigkeit

```
if x > 0 then
        a := 1;
else
        a := 2;
end if;
if z > y then
        z := a;
else
        y := a;
end if;
```

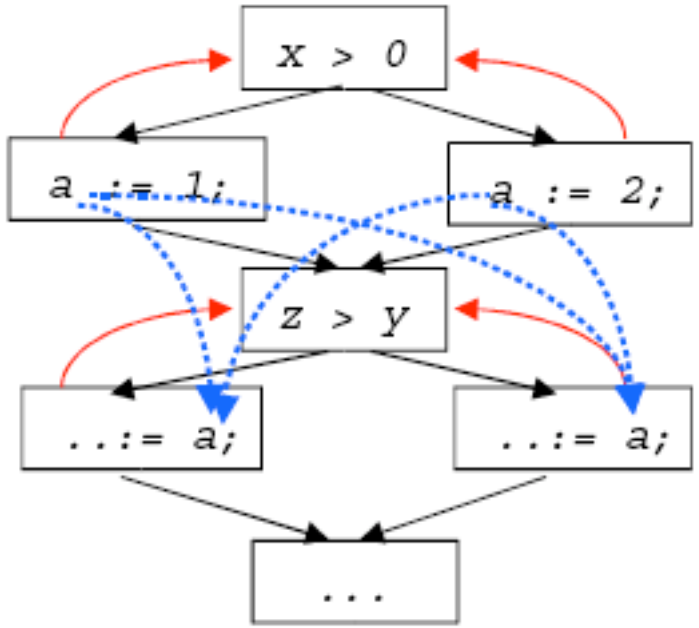


Kontroll–abhängigkeit

Daten–abhängigkeit

# Weiterführende Literatur

- Robert Morgan, "*Building an Optimizing Compiler*", Addison Wesley
  - beschreibt Zwischendarstellungen sowie Kontroll- und Datenflussanalysen
- R. Koschke, J.-F. Girard, M. Würthner, "*An Intermediate Representation for Reverse Engineering Analyses*", Proceedings of the Working Conference on Reverse Engineering, IEEE CS, 1998
  - beschreibt Zwischendarstellungen für das Reverse Engineering und dessen spezielle Anforderungen

# Program Slicing und seine Anwendung

"Program Slicing", by Mark Weiser, IEEE Transactions on Software Engineering, July 1984


Universität Zürich
Institut für Informatik

# Program Slicing

- Lernziel
  - Verständnis von Slicing-Varianten einschließlich ihrer Berechnung und Anwendbarkeit
- Kontext
  - Erste unmittelbare Anwendung von Compilerbau-Technologie zur Unterstützung des Programmverstehens
  - Program Slicing ist Basis-Technologie für viele weitere (Re)Engineering-Techniken

# Das tägliche Brot des Wartungsprogrammierers

```
read (n);
i:= 1;
sum := 0;
product := 1;
while i <= n loop
   sum := sum + i;
   product := product * i;
   i := i + 1;
end loop;
write (sum);
write (product);
```

Was wird durch diese Anweisung beeinflusst?

Wie kommt es zu diesem Wert?

# Programmanalyse /1

```
read (n);
i:= 1;
sum := 0;
product := 1;
while i <= n loop
   sum := sum + i;
   product := product * i;
   i := i + 1;
end loop;
write (sum);
write (product);
```

# Wie kommt es zu diesem Wert?

Backward Slice (*write(product)*):

```
read (n);
i:= 1;
sum := 0;
product := 1;
while i <= n loop
    sum := sum + i;
    product := product * i;
    i := i + 1;
end loop;
write (sum);
write (product);
```

# Programmanalyse /2

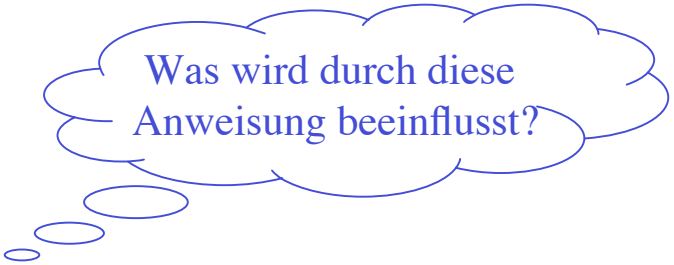


```
read (n);
i:= 1;
sum := 0;
product := 1;
while i <= n loop
   sum := sum + i;
   product := product * i;
   i := i + 1;
end loop;
write (sum);
write (product);
```

# Was wird durch diese Anweisung beeinflusst?

Forward Slice (*sum := 0*):

```
read (n);
i:= 1;
sum := 0;
product := 1;
while i <= n loop
      sum := sum + i;
      product := product * i;
      i := i + 1;
end loop;
write (sum);
write (product);
```

# Was ist ein Slice?

- Slicing (P, S) bezüglich eines Programmpunktes S entfernt jene Teile eines Programms P, die das Verhalten an S nicht beeinflussen.
  - Ein Forward Slice enthält nur solche Anweisungen von P, die von der Ausführung von S beeinflusst werden.
  - Ein Backward Slice enthält nur solche Anweisungen von P, die das Programmverhalten an S beeinflussen.
  - Ein Punkt S beeinflusst einen Punkt S', wenn S' kontroll- oder datenabhängig von S ist.

# Slicing

- Die Idee und die erste Technik des Slicings stammt von Mark Weiser (1984).
- Moderne Slicing–Techniken basieren auf dem Program Dependency Graph (PDG) bzw. System Dependency Graph (SDG) für interprozedurales Slicing:
  - Kanten A--> B im PDG: B ist daten- bzw. kontrollabhängig von A
  - Forward Slicing: Graph-Traversierung in Richtung der Kontroll- und Datenabhängigkeitskanten
  - Backward Slicing: Graph-Traversierung in umgekehrter Richtung der Kontroll- und Datenabhängigkeitskanten

# Program Dependency Graph (PDG)

- PDG = gerichteter Multigraph für Daten- und Kontrollflussabhängigkeiten
  - Knoten repräsentieren Zuweisungen und Prädikate
    - zusätzlich einen speziellen Entry-Knoten
    - zusätzlich Ø-Knoten zur Reduktion der Datenabhängigkeitskanten
    - (sowie einen Initial-Definition-Knoten für jede Variable, die benutzt werden kann, bevor sie gesetzt wird)
  - Kontroll-Kanten repräsentieren Kontrollabhängigkeiten
    - Startknoten jeder Kontrollabhängigkeitskante ist entweder der Entry-Knoten oder ein Prädikatsknoten
  - Fluss-Kanten repräsentieren Set-Use-Abhängigkeiten

# Program Slicing mit PDG

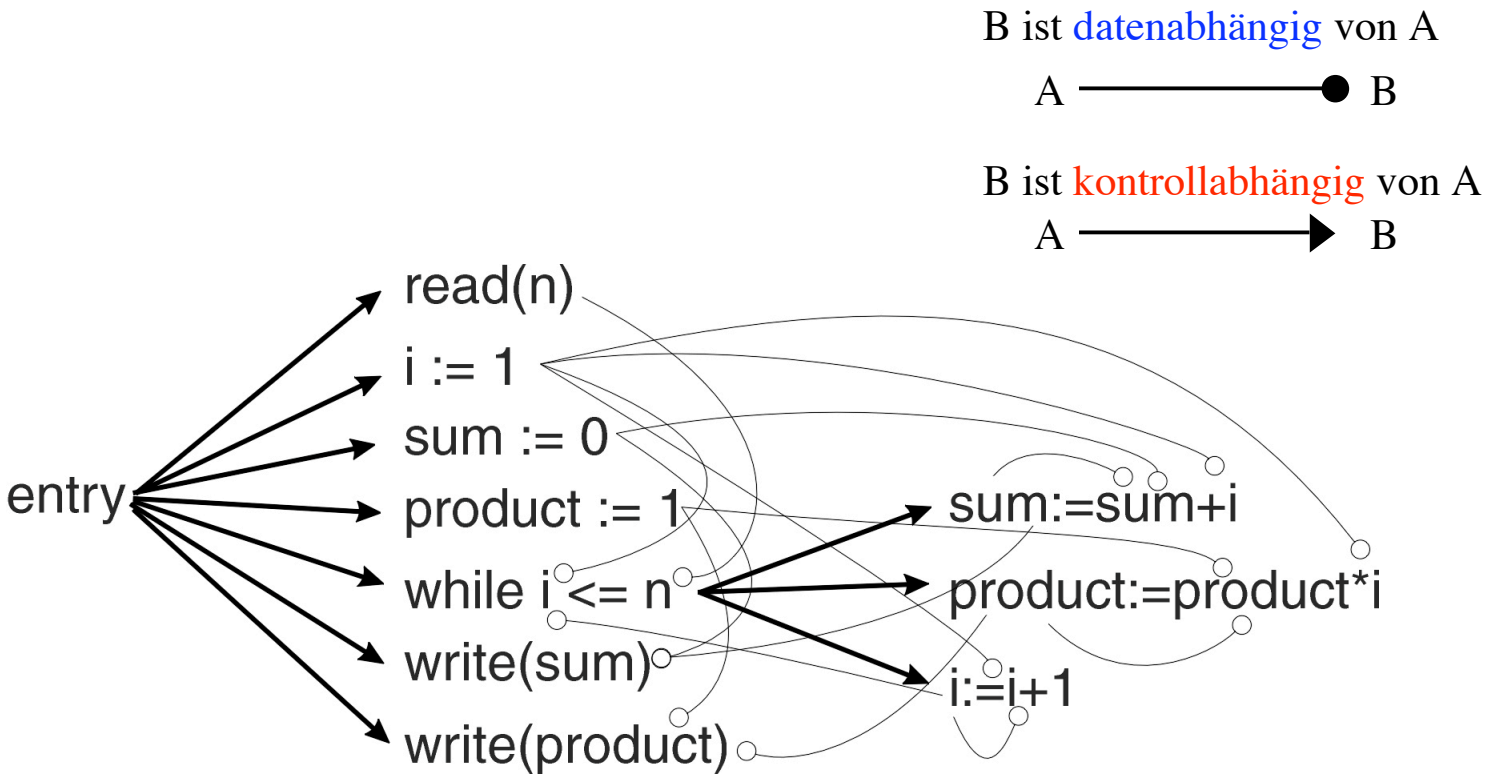

# Program Slicing mit PDG

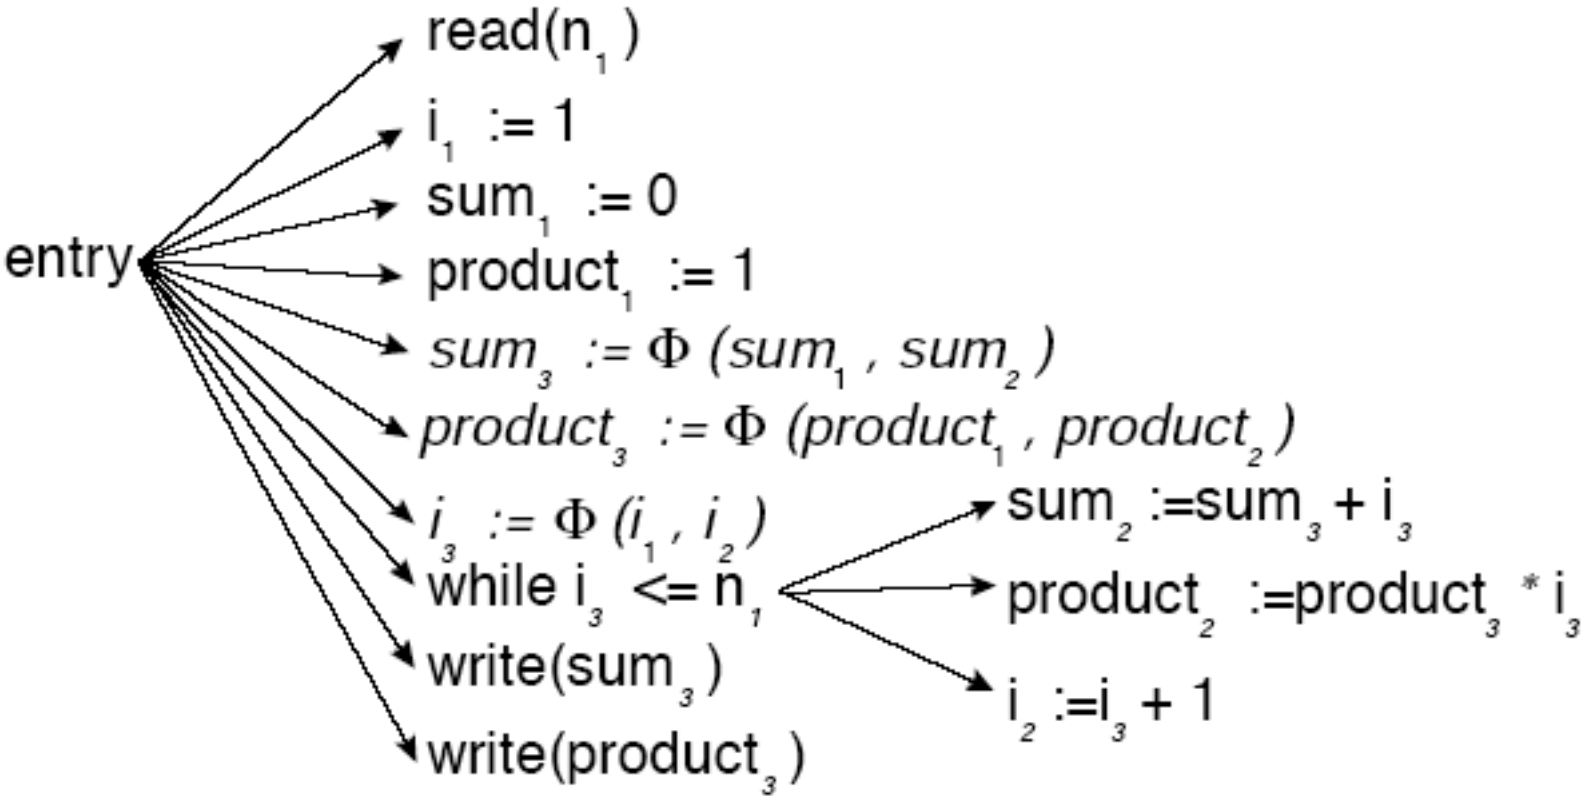

# Interprozedurales Slicing

```
procedure Main is
sum, i : Integer;
begin
 sum := 0;
 i := 1;
 while i < 11 loop
  A (sum, i);
 end loop;
end Main;

procedure A
 (x : in out Integer;
  y : in out Integer) is
begin
 Add (x, y);
 Inc (y);
end A;
```

```
procedure Add
 (a : in out Integer;
  b : in out Integer) is
begin
 a := a + b;
end Add;

procedure Inc
 (z : in out Integer) is
  one : Integer := 1;
begin
 Add (z, one);
end Inc;
```

*Annahme: Parameterübergabe per copy-in/copy-out*

# SDG und PDG

- PDG stellt Abhängigkeiten innerhalb einer Funktion dar
- System Dependency Graph (SDG) stellt globale Abhängigkeiten dar: PDGs für verschiedene Unterprogramme werden vernetzt über interprozedurale Kontroll- und Datenflusskanten
  - Aufruf: Call-Knoten
  - aktuelle Parameter: actual-in / actual-out-Knoten (copy-in/copy-out-Parameterübergabe vorausgesetzt)
  - formale Parameter: formal-in / formal-out-Knoten
  - transitive Abhängigkeiten via PDG: Summary-Edges

# Modellierung des Prozeduraufrufs

```
x_in := sum3;
y_in := i3;
A;
sum2 := x_out;
i2 := y_out;
```

```
procedure A is
begin
  x0 := x_in; y0 := y_in;
  ...
  x_out := x1; y_out := y1;
end A;
```

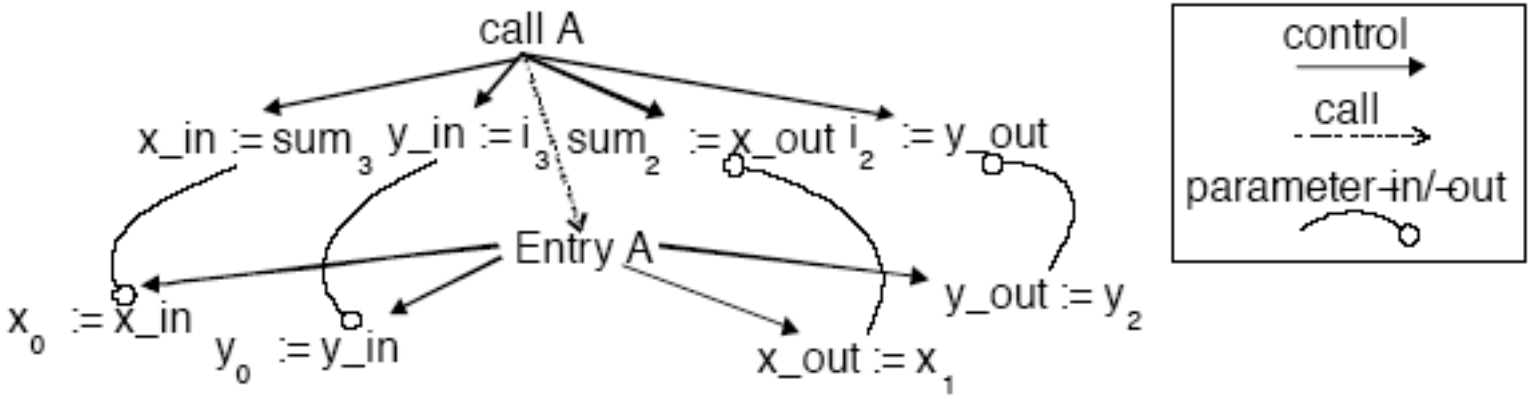

# System Dependence Graph

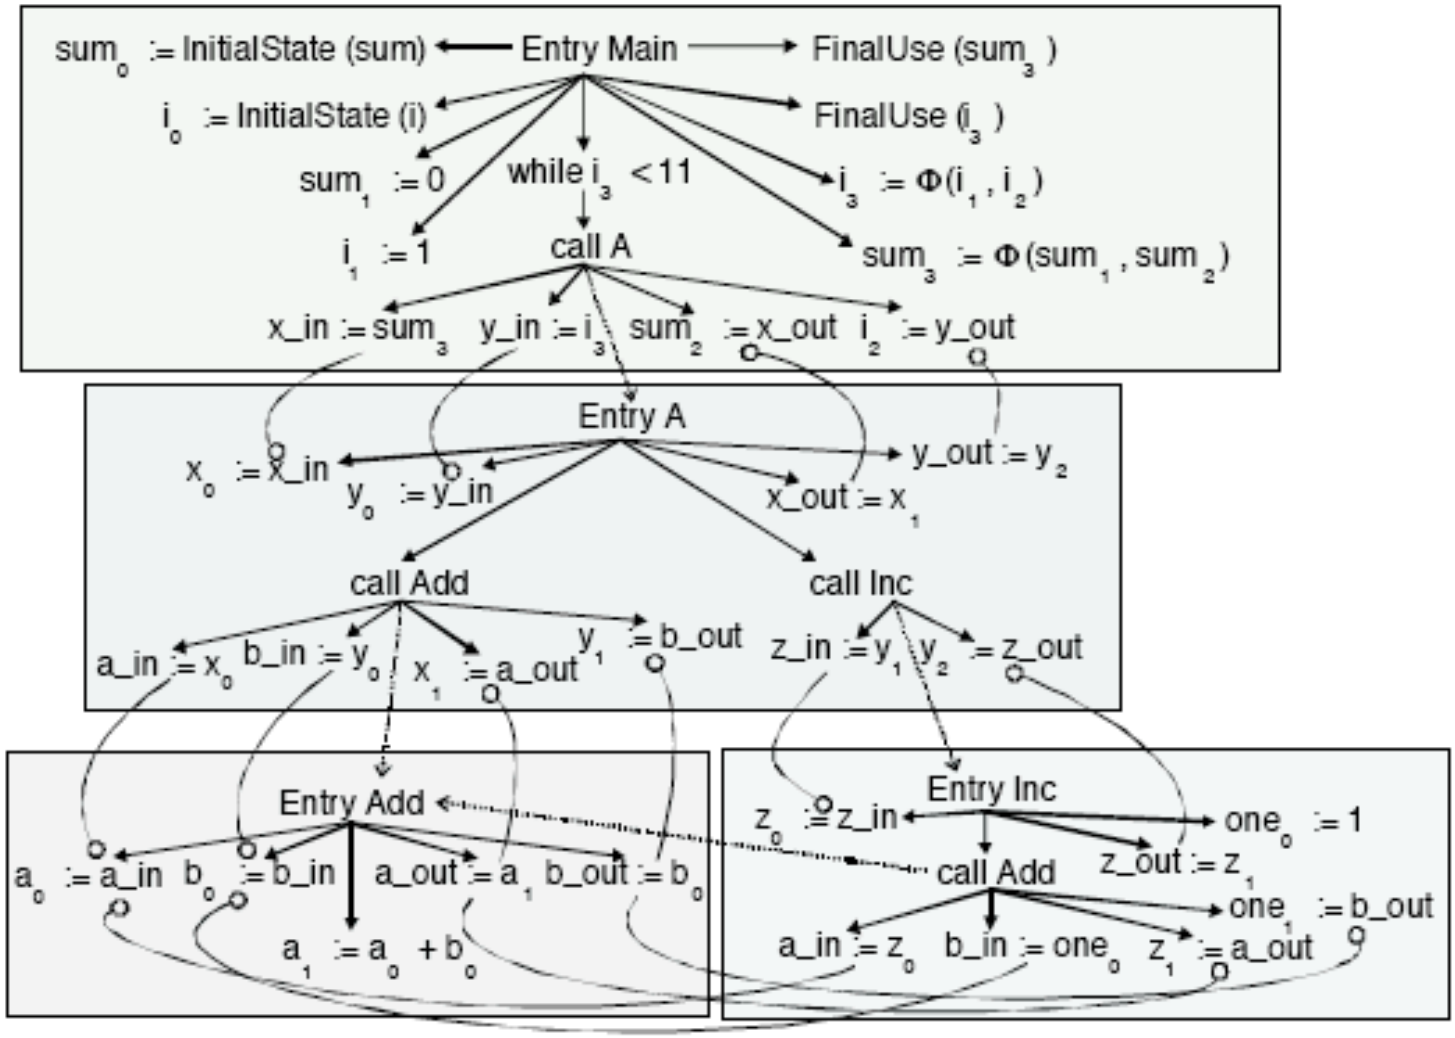




 

# Naives interprozedurales Slicing

Folge allen Flow- und Control-Kanten

- Problem: Formale in-Parameter können mehrere Vorgänger haben, formale out-Parameter mehrere Nachfolger

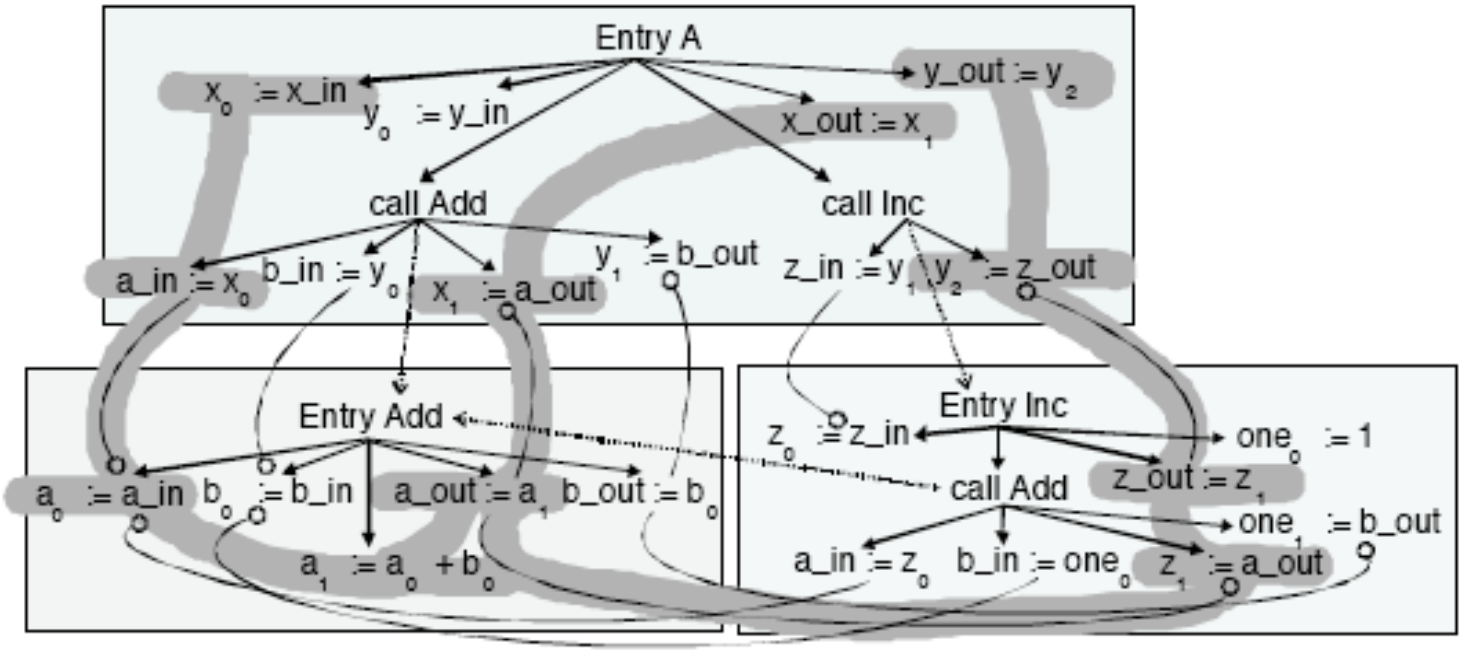

# Interprozedurales Slicing (Traversierung)

- Backward-Slicing (Prozedur P, Statement S):
- Phase 1: Folge rückwärts Flow-
  (inklusive Summary-)/Control-/Call- und
  Parameter-In-Kanten ausgehend von S
  - Identifiziert Knoten in Prozeduren, die P (transitiv) aufrufen und von denen S abhängt.
  - Da Parameter-Out-Edges ausgenommen sind, werden nur aufrufende Prozeduren besucht.
  - Die Effekte nicht-besuchter Prozeduren werden aber nicht ignoriert, da Summary-Edges traversiert werden.

# Interprozedurales Slicing II

- Phase 2:
  Folge rückwärts Flow -(inklusive Summary-) / Control- und Parameter-Out-Kanten ausgehend von allen Knoten, die in Phase 1 identifiziert wurden.
  - Identifiziert Knoten in Prozeduren, die von P (transitiv) aufgerufen werden und von denen S abhängt.
  - Da Parameter-In-Edges ausgenommen sind, werden nur aufgerufene Prozeduren besucht.
  - Es gilt wieder: Die Effekte nicht-besuchter Prozeduren werden nicht ignoriert, da Summary-Edges traversiert werden.

# Summary Edges

- repräsentieren (transitive) Abhängigkeiten der aktuellen In- und Out-Parameter an einer gegebenen Aufrufstelle
- helfen während des Slicings, unnötige Abstiege in aufgerufene Prozeduren zu vermeiden
- werden in zwei Schritten ermittelt:
  - direkte Abhängigkeiten zwischen den formalen Parametern innerhalb der aufrufenden Prozedur
  - indirekte Abhängigkeiten, die sich transitiv durch Aufruf anderer Prozeduren ergeben
- werden hergeleitet mit bekannten Techniken zu Abhängigkeiten in Attributgrammatiken

# Slicing Variante: Chopping

Abhängigkeiten zwischen zwei Punkten:

```
   read (n);
   i:= 1;
   sum := 0;
   product := 1;
   while i <= n loop
     sum := sum + i;
     product := product * i;
     i := i + 1;
   end loop;
   write (sum);
   write (product);
```

# Anwendungen von Slicing

- Programmverstehen
  - Reduzierung des Codes auf das für das Verständnis notwendige Maß
- Änderungsanalyse
  - alle von einer Änderung betroffenen Stellen
- Regressionstesten
  - Reduktion des zu testenden Codes
- Restrukturierung
  - z.B. Aufteilung von Unterprogrammen, die mehrere logisch verschiedene Funktionen implementieren
- Bewertung der Änderbarkeit (und somit der Wartbarkeit) eines Systems
  - Messung von Kohäsion

# Literatur


- K.B. Gallagher, J.R. Lyle. Using Program Slicing in Software Maintenance. IEEE Transactions on Software Engineering, 17(8):751-761, August 1991.
- S. Horwitz, T. Reps, D. Binkeley. Interprocedural Slicing using Dependence Graphs. ACM Transactions on Programming Languages and Systems, 12(1):35-46, January 1990.
- M. Weiser. Program Slicing. IEEE Transactions on Software Engineering, 10(4):352-257, 1984.