

Source Mining

Statische Analyse mit Columbo

Jens-D. Doll
Context IT

www.cococo.de

Bio

- 1975ff Studium der Informatik/Mathematik
- 1980 Entwurf eines Fortran 77-Compilers
- 1980 erste Idee zu Columbo
- 1981 Entwicklung einer REXX-ähnlichen Sprache
- 1982 Adaption eines COBOL-Compilers
- 1993ff verschiedene Projekte mit COBOL
- 1998 Einführung eines Repositories
- 2001 Reverse Engineering Projekt
- 2004 Konzept für Columbo
- 2005 Prototyp von Columbo vorhanden

Grundlagen

- Ralf Lämmel et al „COBOL-Grammatik“
- F.W. Schröer et al „Gentle und Accent“
- Glynn Winskel „Formal Semantics“
- Cousot, P u. R. „Abstract Interpretation“
- Uwe Schöning „Theoretische Informatik“
- A. Steger „Diskrete Mathematik“
- ...

COBOL COBOL COBOL?

- COBOL ist auch objektorientiert
- Vererbung
- Polymorphismus
- Persistenz
- Die Sprache ist wortgewaltig

Langfristiges Ziel

- Übersetzung von Programmeigenschaften in die **natürliche Sprache** für Anwender
- Definition eines **Satzes von Funktionen** zur qualitativen Beschreibung von Software


Entwicklung von Software

- Fachbereich stellt Anforderungen
- IT-Abteilung erstellt System
- Fachbereich nimmt fertige Software ab

(aber man weiß nicht so genau,
ob die Anforderungen erfüllt werden)

Programmierung

Programmierer erstellen Software



Quellcode A ist sauber

```
identification division.  
program - id. exp.  
author. "D".  
date-written. 25.10.2004.  
date-com piled.  
data division.  
working-storage section.  
77 a pic 9(4).  
77 c pic 9(4).  
linkage section.  
77 i pic 9(4).  
77 n pic 9(4).  
77 r pic 9(4).  
procedure division using i n r.  
* computes i to the power of n  
  move 1 to a c.  
  perform until n <= c  
    multiply a by i  
    add 1 to c  
  end-perform .  
  move a to r.  
end-program exp.
```


Abnahme

Fachbereich testet und nimmt Software ab




Monate und Jahre danach

- Fachbereich fordert Änderungen
- IT-Abteilung ändert Software
- und so weiter ...

Erweiterung und Wartung

Verschiedene Entwickler ändern die Software

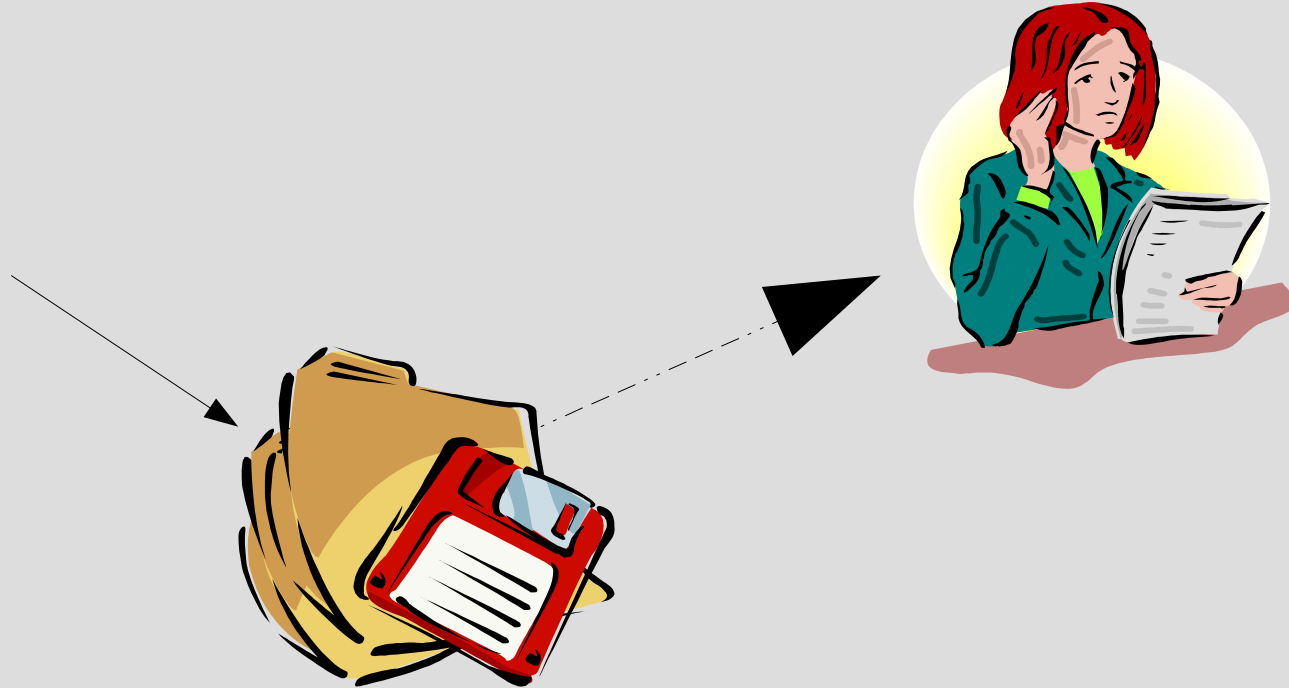


Quellcode B ist nicht mehr erkennbar

```
• identification division.  
• program - id. exp- coded.  
• author. "D".  
• date-written . 25.10.2004.  
• date-com piled.  
• data division.  
• working- storage section.  
• *****  
• * Um benennung von Franz  
• *****  
• 77 achtung pic 9(4).  
• 77 coffein pic 9(4).  
• 77 dieter pic 9(4).  
• 77 m oechte pic 9(4).  
• 77 gruenen pic x(28).  
• 77 tee pic 9(4).  
• 78 kaffee value 0.  
• 78 wasser value 1.  
• 78 whiskey value 2.  
• linkage section.  
• 77 innovation pic 9(4).  
• 77 neugierkeiten pic 9(4).  
• 77 richtunggebend pic 9(4).  
• procedure division using innovation neugierkeiten  
• richtunggebend.  
• * also computes r = i to the power of n  
• * but redundantly  
• * i -> innovation  
• * n -> neugierkeiten  
• * r -> richtunggebend  
• *****  
• * Verstreung von Am in  
• *****  
• A11 move kaffee to dieter  
• A11 move kaffee to tee  
• move dieter to achtung coffein  
• add wasser to achtung  
• add wasser to coffein  
• move wasser to dieter  
• *****  
• * Klausurierung von Arno  
• *****  
• 033 perform until coffein  
• > neugierkeiten + kaffee  
• *****  
• * Indirektion von Norbert  
• *****  
• N22 move wasser to tee  
• N22 move innovation to m oechte  
• N22 multiply achtung by m oechte  
• N22 add tee to coffein  
• N22 move wasser to tee  
• subtract wasser from tee  
• end-perform .  
• move achtung to richtunggebend.  
• *****  
• * Verschleierung von Ute  
• *****  
• if tee < - whiskey * dieter  
• subtract wasser from tee  
• end- if.  
• end-program exp- coded.
```

Dilemma des Fachbereichs

Unternehmen ist unsicher über
die Funktionen der Software



Fachbereiche


- Fachbereiche sprechen natürlich, fachspezifisch, aber nicht formal
- sie erwarten Qualität
- sie möchten ihre Geschäftsregeln wiederfinden

Lösung der Aufgabe


- Columbo ist ein Übersetzer **von formalen Sprachen** in natürliche Sprachen
- Columbo erzeugt nicht operationale , sondern **denotationale Semantik**
- Daraus wird **natürliche Sprache** generiert

Aufgabe für Columbo

Columbo erstellt Nachdokumentation der Software



Columbo 1.0



Columbo-Ergebnis A

```
identification division.  
program - id. exp.  
author. "D".  
date-written. 25.10.2004.  
date-com piled.  
data division.  
working-storage section.  
77 a pic 9(4).  
77 c pic 9(4).  
linkage section.  
77 i pic 9(4).  
77 n pic 9(4).  
77 r pic 9(4).  
procedure division using i n r.  
* computes i to the power of n  
  move 1 to a c.  
  perform until n <= c  
    multiply a by i  
    add 1 to c  
  end-perform .  
  move a to r.  
end-program exp.
```

Analyseergebnis für exp

Funktion

A) Das Programm $(r) = \text{exp}(i, n)$

ermittelt $r = i^{*n}$

B) oder das Programm

ermittelt $r = 1$.

Komplexität

Das Verfahren hat folgendes Zeitverhalten

$O(n)$.

Randbedingungen

Dies gilt nur, wenn die Variablen im Intervall

$[0 .. 10000]$

liegen.

Columbo-Ergebnis B

```

Identification division.
program - id. exp-coded.
author. "D".
date-written. 25.10.2004.
date-com-piled.
data division.
working-storage section.
*****
* Um benennung von Franz
*****
77 achtung pic 9(4).
77 coffein pic 9(4).
77 dieter pic 9(4).
77 m oechte pic 9(4).
77 gruenen pic x(28).
77 tee pic 9(4).
78 kaffee value 0.
78 wasser value 1.
78 whiskey value 2.
linkage section.
77 innovation pic 9(4).
77 neuigkeiten pic 9(4).
77 richtunggebend pic 9(4).
procedure division using innovation neuigkeiten
richtunggebend.
* also computes r = i to the power of n
* but redundantly
* i -> innovation
* n -> neuigkeiten
* r -> richtunggebend
*****
* Verstreuung von Arm in
*****
A11 move kaffee to dieter
A11 move kaffee to tee
move dieter to achtung coffein
add wasser to achtung
add wasser to coffein
move wasser to dieter

```

```

*****
* Klausurierung von Arno
*****
033 perform until coffein
> neuigkeiten + kaffee
*****
* Indirektion von Norbert
*****
N22 move wasser to tee
N22 move innovation to m oechte
N22 multiply achtung by m oechte
N22 add tee to coffein
N22 move wasser to tee
subtract wasser from tee
end-perform .
move achtung to richtunggebend.
*****
* Verschleierung von Ute
*****
if tee < - whiskey * dieter
subtract wasser from tee
end-if.
end-program exp-coded.

```

Analyseergebnis für exp-coded

Funktion

A) Das Programm (richtunggebend) = exp-coded (innovation, neuigkeiten)

ermittelt richtunggebend = (innovation**neuigkeiten)

B) oder das Programm m

ermittelt richtunggebend = 1

Komplexität

Das verfahren hat folgendes Zeitverhalten

O(n).

Randbedingungen

Dies gilt nur, wenn die Variablen im Intervall

[0 .. 10000]

Liegen.

Vorteile

Vorteile

- Unterstützt die Entwicklung
- Objektiviert die Qualität
- Schafft Sicherheit

Nachteil

- Erzeugt Leistungsdruck

Konkurrenzprodukte

- Revolve
- Polyspace
- DRDA
- ...

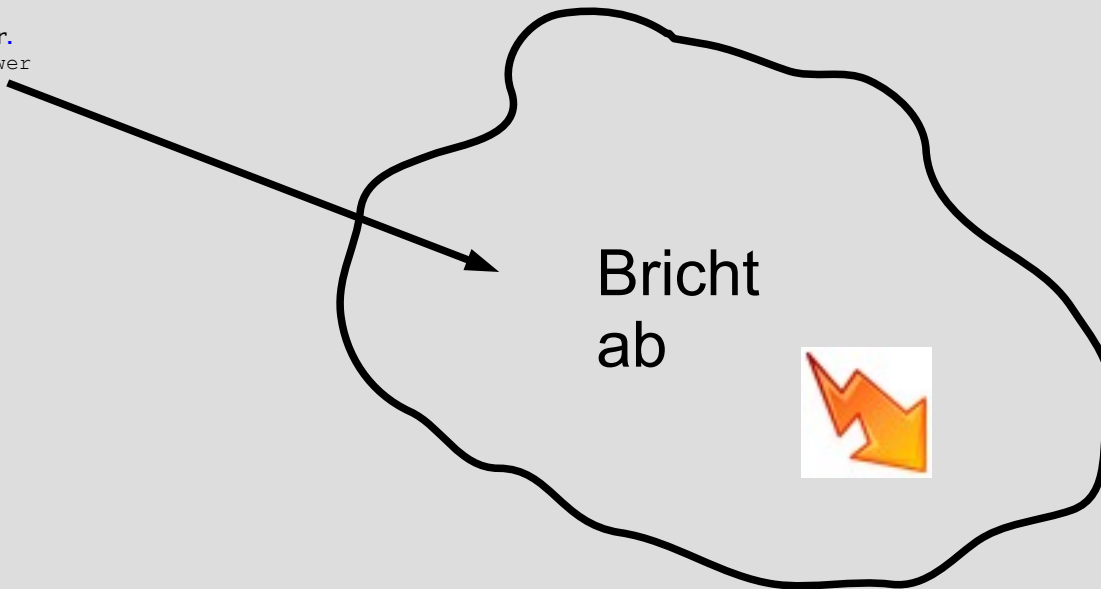

Statische Analyse

- undefinierte Variablen
- Division durch 0 etc.
- Indexüberlauf
- Unreachable Code
- Constant Propagation
- Impact Analysis
- Control Flow
- Data Flow
- Style Check
- Anweisungsebene (sehr wenige)
- Automatischer Selbsttest
- ...


Umgebungen

```
identification division.  
program - id. exp.  
author. "D".  
date-written. 25.10.2004.  
date-com piled.  
data division.  
working-storage section.  
77 a pic 9(4).  
77 c pic 9(4).  
linkage section.  
77 i pic 9(4).  
77 n pic 9(4).  
77 r pic 9(4).  
procedure division using in r.  
* computes i to the power  
of n  
move 1 to a c.  
perform until n <= c  
multiply a by i  
add 1 to c  
end-perform .  
move a to r.  
end-program exp.
```

Quelle,
verifiziert
oder
validiert




Sichten auf die Quelle



Navigator

```

identification division.
program - id. exp.
author. "D".
date-written. 25.10.2004.
date-com-piled.
data division.
working-storage section.
77 a pic 9(4).
77 c pic 9(4).
linkage section.
77 i pic 9(4).
77 n pic 9(4).
77 r pic 9(4).
procedure division using in r.
* computes i to the power
of n
move 1 to a.
perform until n <= c
multiply a by i
add 1 to c
end-perform .
move a to r.
end-program exp.
    
```




CFA

Datei "exp.cob"
=====

Prozedur exp

Statistik	
Anzahl Zeilen:	20
Anzahl Kommentare:	5 %
Anzahl Statements:	5
Anzahl Felder:	5
Analysezeit:	0 nsec
Speicherbedarf:	5509 KB
Komplexität	
Zyklonatische Komplexität:	2
McCabe Maß:	2
Aufwand	
Halstead Maß:	100
Function Point Aufwand:	0.8 FH

Statistik




DFA

Semantik

```
identification division.  
program - id. exp.  
author. "D".  
date-written. 25.10.2004.  
date-com piled.  
data division.  
working-storage section.  
77 a pic 9(4).  
77 c pic 9(4).  
linkage section.  
77 i pic 9(4).  
77 n pic 9(4).  
77 r pic 9(4).  
procedure division using in r.  
* computes i to the power  
of n  
move 1 to a c.  
perform until n <= c  
multiply a by i  
add 1 to c  
end-perform .  
move a to r.  
end-program exp.
```


denotational



axiomatisch

$$\begin{aligned} e^{ix} &= \sum_{n=0}^{\infty} \frac{(ix)^n}{n!} \\ &= \sum_{n=0}^{\infty} \frac{(-1)^n x^{2n}}{(2n)!} + i \sum_{n=1}^{\infty} \frac{(-1)^{n-1} x^{2n-1}}{(2n-1)!} \\ &= \cos x + i \sin x. \end{aligned}$$

operational



Sprachklassen

Prozedural (A)

COBOL

JAVA

C++

Assembler

Maschinensprache

Mengenorientiert (B)

Prolog

SQL

PL(1-2)

~Standard ML

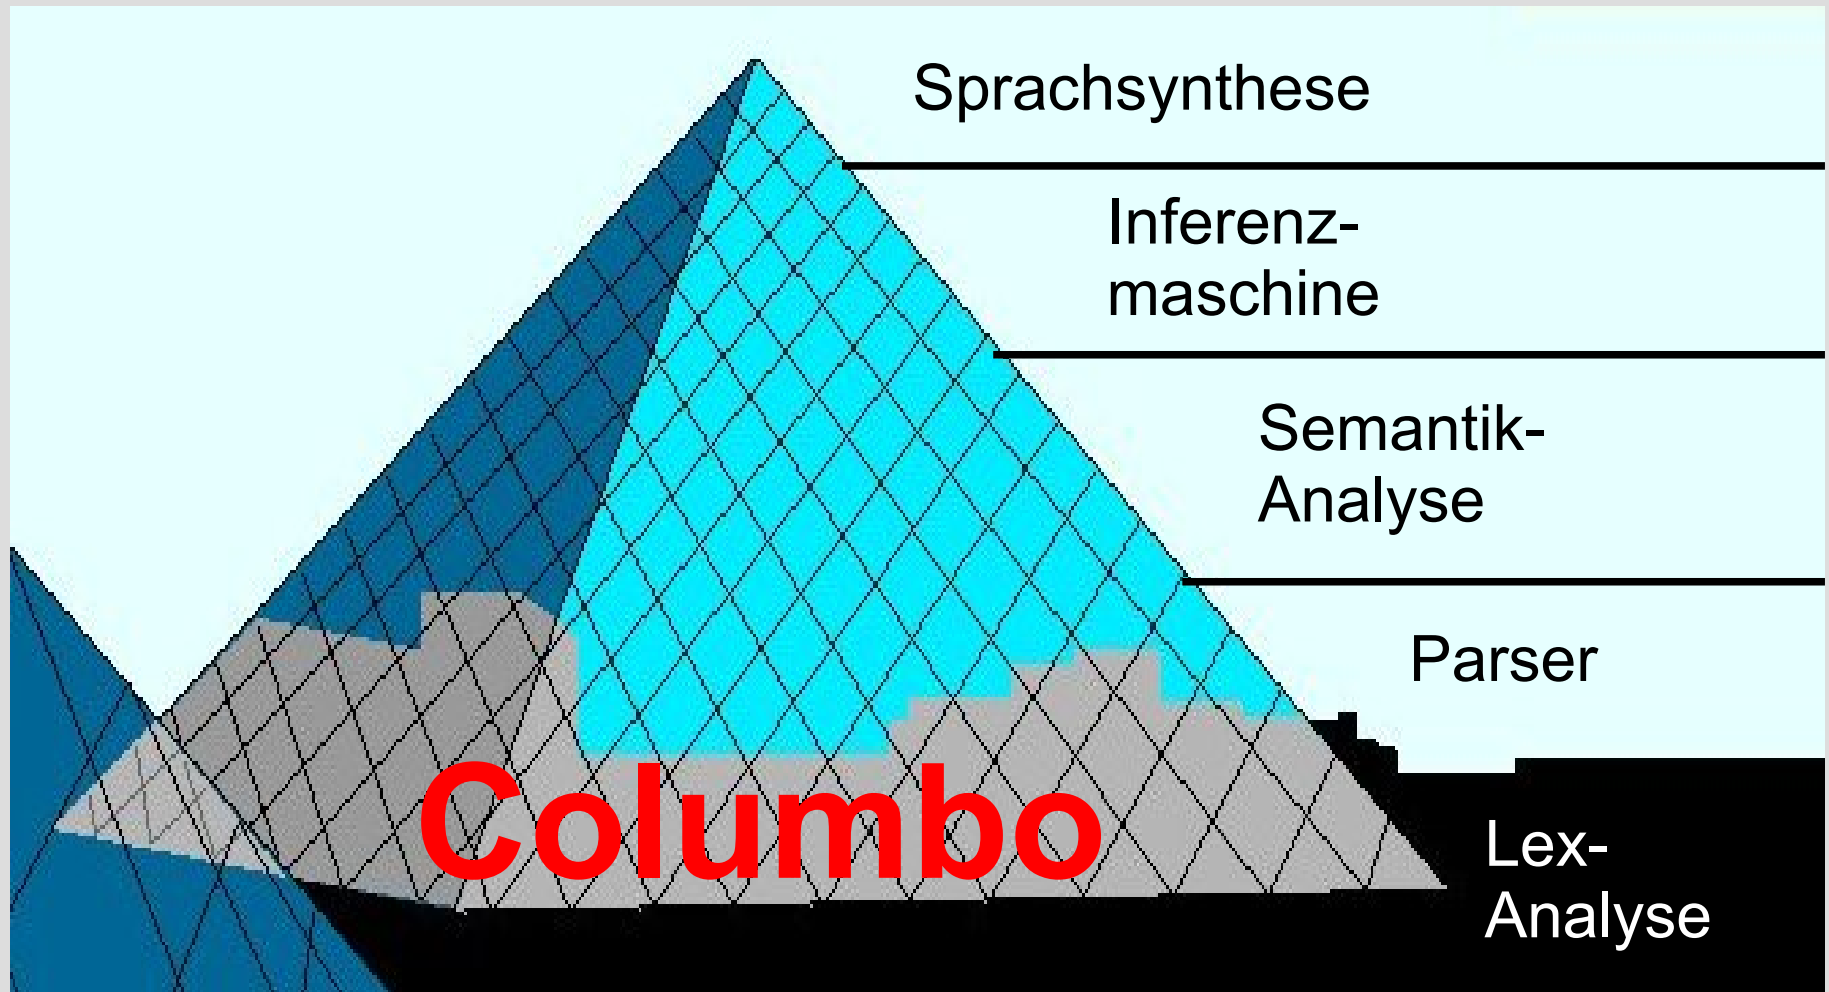
COLUMBO soll von A nach B übersetzen

Qualitätssicherung

Columbo wird mittels dieser Methoden geprüft:

- Automatischer Selbsttest
- Manueller Test
- Style Tests
- Code Review
- Decompilation
- ...

Architektur von Columbo



Nächste Schritte

- Prototyp zum Produkt machen
Arrays, Pointer, Datentypen,
Dateien, SQL, ...
- Aufteilung in
Free, Professional und Enterprise Version
- Qualitätssicherung durchführen
- Pilotanwender oder -kunden finden

Timeline

- Ende 2005 Prototyp
- in 2006 Free Version
- in 2006 Web-Interface
- Ende 2006 Professional Version

Ziel

Verifikationssoftware Perfekte Dokumentation

Fragen:

- Mission (im)possible ?
- wie sichert man hier die Qualität ?