Klonerkennung nach Baxter am Beispiel `jsch`

Aufgabe: Erläutern Sie das Verfahren der Klonerkennung nach Baxter an einem Beispiel!

Stephan Beyer

1. Seminar *Software-Reengineering*

25. Mai 2007

Gliederung

Ansätze

- Berechnen zwei Programme das Gleiche?
  - Nicht entscheidbar!
  - ⇒ Vergleich auf *syntaktischer Ebene*
- Probleme beim textuellen Vergleich
  - verschiedene Bezeichnernamen
  - verschiedene Einrückungen
  - Kommentare
  - ...
- *Abstrakte Syntaxbäume (ASTs)*

Das Verfahren in groben Schritten

1. Code scannen, parsen → ASTs erzeugen
2. Duplikate von Teilbäumen finden
3. Sequenzen von Teilbaumduplikaten zusammenfassen
4. komplexere Duplikate durch Verallgemeinerung der anderen Duplikate ermitteln
5. Ausgabe der Clones (Prettyprint des AST)

Details zu Schritt 2

Duplikate von Teilbäumen finden

- prinizipielles Vorgehen: Teilbäume auf Gleichheit prüfen
- Probleme:
  - *Effizienz* – kubischer Aufwand bei naiver Implementierung, daher:
    - Hashwerte für kleine Teilbäume
    - Hashwerte bilden Schubfächer (Buckets)
    - nur Teilbäume innerhalb Schubfach werden miteinander verglichen
  - *Ähnlichkeit*, nicht nur Gleichheit gefragt
    - „schlechte“ Hashfunktion verwenden $\rightarrow$ Ähnlichkeitsattribute bewahren
    - Ähnlichkeitsmetrik einführen, z. B.

$$d = \frac{2\,(\text{Anz. gleicher Knoten in Teilbaum 1 und 2})}{\text{Anz. Knoten in Tb. 1} + \text{Anz. Knoten in Tb. 2}}$$

  - sinnvolle Minimalgröße für Teilbäume

Notizen:

Details zu Schritt 3

Sequenzen von Teilbaumduplikaten zusammenfassen

- Sequenzen durch Sequenzoperator gekennzeichnet, z. B.
  - Semikolon ; in JAVA, C, C++, PASCAL,
  - Punkt . in COBOL,
  - Newline in PYTHON
- gesonderte Behandlung
- es wird Liste angelegt, die die Hashwerte der Teilbäume in Sequenz enthält
- Sequenzlängen nach unten und oben beschränkt
- Ähnlichkeitsmetrik, z. B.

$$d_l = \frac{2 \cdot \text{Anz. gleicher Teilbäume in Sequenzen}}{\text{Anz. Teilbäume in Sequenz 1 und 2}}$$

Notizen:

Details zu Schritt 4

komplexe Duplikate durch Verallgemeinerung

- Ist der Teilbaum unter dem Vaterknoten 1 auch ähnlich zum Teilbaum unter Vaterknoten 2? $\rightarrow$ Fasse zusammen!

Das Verfahren nach Baxter hat bei einem AST mit n Knoten einen Berechnungsaufwand von $\mathcal{O}(n^2)$.

Notizen:

jsch 0.1.32

Allgemeines zum Beispiel

- jsch – Java Secure Channel
- freie Implementierung von SSH2 in JAVA
- verwendet in ANT 1.6, ECLIPSE 3.0
- Entwicklungszeitraum: 2002 - 7.3.2007
- Lizenz: BSD-Lizenz ohne Werbeklausel
- offizielle Website: http://www.jcraft.com/jsch/
- laut sloccount 13 689 Zeilen JAVA-Code.

Verzeichnisstruktur

jsch-0.1.32/

- dist/
- examples/ 23 Dateien
- tools/bin/
- src/com/jcraft/jsch/ 73 Dateien
  - jce/ 17 Dateien
  - jcraft/ 6 Dateien
  - jgss/ 1 Datei

Schritt 1

Vorbemerkungen

- nur (idealisierte) Betrachtung von `src/com/jcraft/jsch/jce/BlowfishCBC.java`
- zur Erzeugung des ASTs wird der Code
  1. lexikalisch analysiert (gescannt, sog. *Scanner* bzw. *Lexer*)
     d. h. Code wird in logische Einheiten (*Token*) zerlegt
  2. syntaktisch analysiert (geparst, sog. *Parser*)
     d. h. Token werden ggf. mit Attributen versehen und entsprechend in den Syntaxbaum eingefügt
- Scanner und Parser praktisch oft eine Einheit

Gerüst von `BlowfishCBC.java`

```
package com.jcraft.jsch.jce;

import com.jcraft.jsch.Cipher;
import javax.crypto.spec.*;

public class BlowfishCBC implements Cipher{
        /* [...] */
}
```

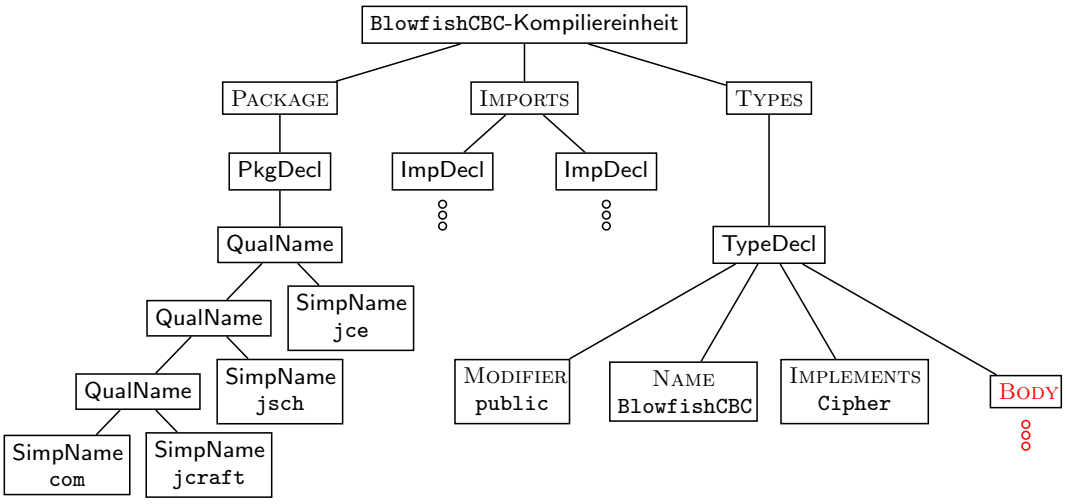

JAVA-Code als AST

Auszug aus BlowfishCBC-Klasse

```
private static final int ivsize = 8;
private static final int bsize = 16;
private javax.crypto.Cipher cipher;
public int getIVSize() {
  return ivsize;
}
public int getBlockSize() {
  return bsize;
}
public void init(int mode, byte[] key, byte[] iv)
                                    throws Exception {
        /* [...] */
}
```

AST:

- Folge von *FieldDecl* und *MethodDecl*
- haben entsprechende MODIFIER-, TYPE-Attribute (u. A.)

JAVA-Code als AST

Auszug aus init-Methode der BlowfishCBC-Klasse

```
byte[] tmp;
if(iv.length > ivsize) {
  tmp = new byte[ivsize];
  System.arraycopy(iv, 0, tmp, 0, tmp.length);
  iv = tmp;
}
if(key.length > bsize) {
  tmp = new byte[bsize];
  System.arraycopy(key, 0, tmp, 0, tmp.length);
  key = tmp;
}
try {
  SecretKeySpec skeySpec = new SecretKeySpec(key,
                                        "Blowfish");
        /* [...] */
}
catch(Exception e) {
  System.err.println(e);
}
```

Java-Code als AST

Auszug aus `init`-Methode der `BlowfishCBC`-Klasse

```
byte[] tmp;
```

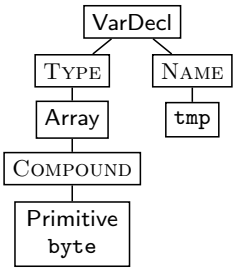

Java-Code als AST

Auszug aus `init`-Methode der `BlowfishCBC`-Klasse

```
if(iv.length > ivsize) /* COND */
{ /* BLOCK: 3 statements */
  tmp = new byte[ivsize];
  System.arraycopy(iv, 0, tmp, 0, tmp.length);
  iv = tmp;
} /* ELSE: - */
```

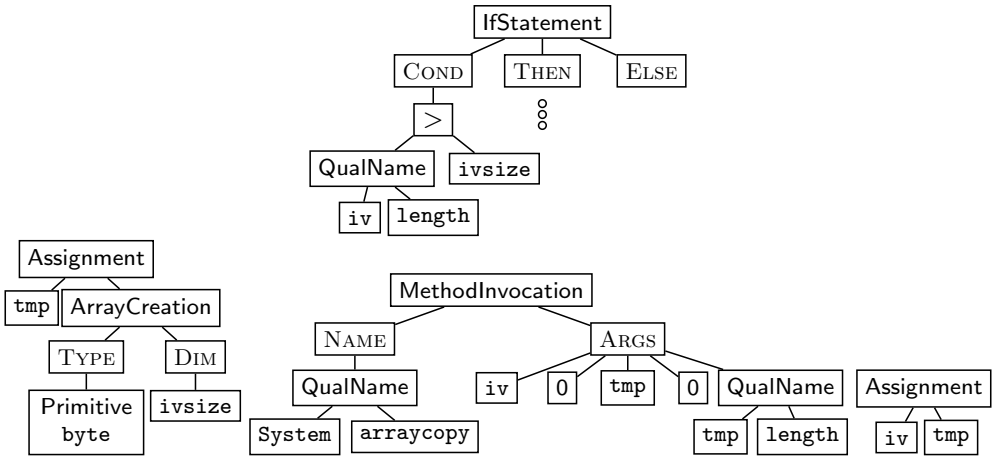

Java-Code als AST

Auszug aus `init`-Methode der `BlowfishCBC`-Klasse

```
if(key.length > bsize)
{
  tmp = new byte[bsize];
  System.arraycopy(key, 0, tmp, 0, tmp.length);
  key = tmp;
}
```

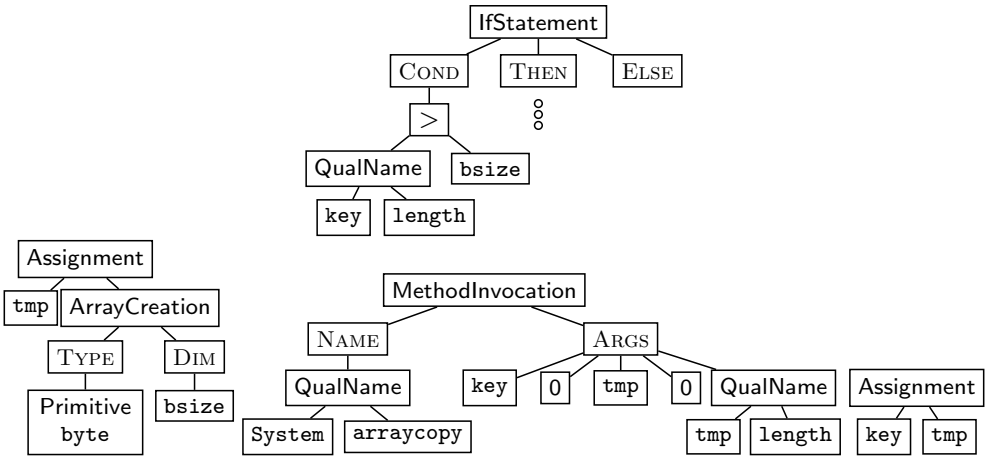

Java-Code als AST

Auszug aus `init`-Methode der `BlowfishCBC`-Klasse

```
try {
  SecretKeySpec skeySpec = new SecretKeySpec(key,
                                             "Blowfish");
        /* [...] */
} catch(Exception e) {
  System.err.println(e);
}
```

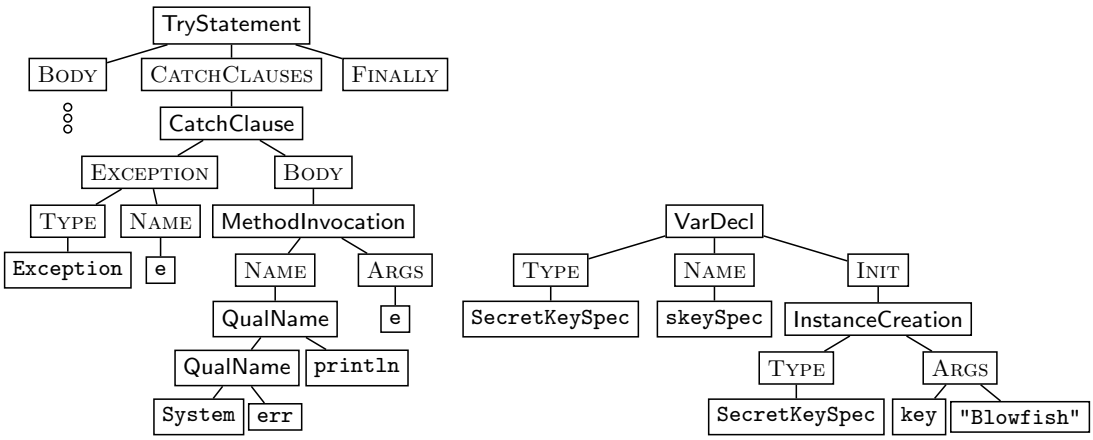

Schritt 2

Berechnen der Hashwerte

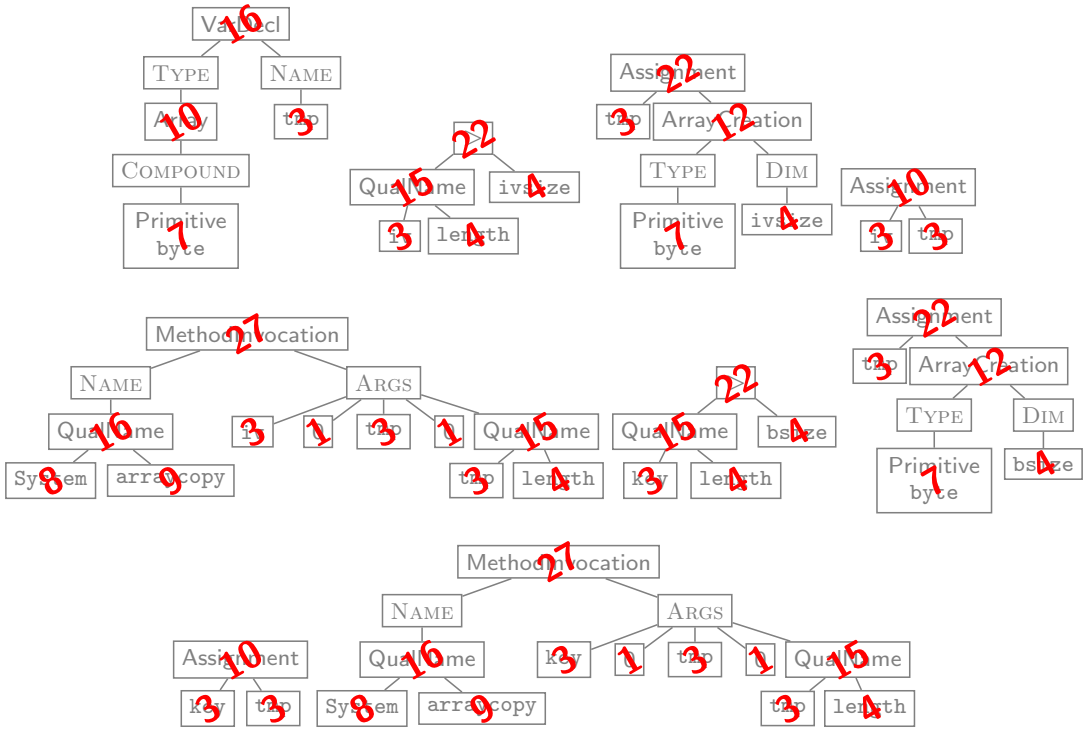

Notizen:

Schritt 2

Füllen der Hashbuckets

1	0	0	0	0												
3	tmp	iv	tmp	iv	tmp	iv	tmp	tmp	key	tmp	key	tmp	key	tmp	tmp	
4	length	ivsize	ivsize	length	length	bsize	bsize	length								
7	byte	byte	byte													
8	System	System														
9	arraycopy	arraycopy														
10	byte[]	iv = tmp	key = tmp													
12	new byte[ivsize]	new byte[bsize]														
15	iv.length	tmp.length	key.length	tmp.length												
16	byte[] tmp	System.arraycopy	System.arraycopy													
22	(iv.length > ivsize) tmp = new byte[ivsize] (key.length > bsize) tmp = new byte[bsize]															
27	System.arraycopy(iv, 0, tmp, 0, tmp.length) System.arraycopy(key, 0, tmp, 0, tmp.length)															

Notizen:

Schritt 2

(maximale) Klone identifizieren

Klontupel:

(0, 0, 0, 0), (tmp, tmp, tmp, tmp, tmp, tmp, tmp, tmp, tmp),
(iv,iv,iv), (key,key,key), (length, length, length, length),
(ivsize, ivsize), (bsize, bsize), (byte, byte, byte),
(System, System), (arraycopy, arraycopy), (iv=tmp, key=tmp),
(new byte[ivsize], new byte[bsize]),
(iv.length,tmp.length,key.length,tmp.length),
(System.arraycopy, System.arraycopy),
(iv.length>ivsize, key.length>bsize),
(tmp=new byte[ivsize], tmp=new byte[bsize]),
(System.arraycopy(iv,0,tmp,0,tmp.length),
System.arraycopy(key,0,tmp,0,tmp.length))

Notizen:

Schritt 3

Liste aller Sequenzen

Sequenzen als Hashwert-Folgen in Liste speichern.

- in erstem `if`-Block: $(22, 27, 10)$
- in zweitem `if`-Block: $(22, 27, 10)$
- in `try`-Block[1]: $(31, 43, 67)$
- die gesamte Prozedur, d. h. 16, sowie zwei `if`-Statements und ein `try`-Statement[2].

[1] eben nicht betrachtet
[2] wird weiterhin nicht beachtet

Schritt 3

Teilsequenzen in Hashbuckets

Hashbuckets für Teilsequenzen der Länge 2:

37	$(27, 10)$	$(27, 10)$
49	$(22, 27)$	$(22, 27)$
74	$(31, 43)$	
110	$(43, 67)$	

Hashbuckets für Teilsequenzen der Länge 3:

59	$(22, 27, 10)$	$(22, 27, 10)$
141	$(31, 43, 67)$	

Schritt 3

(maximale) Klonsequenzen identifizieren

Ergebnis: ein Klontupel

```
/* Sequenz 1 */
  tmp = new byte[ivsize];
  System.arraycopy(iv, 0, tmp, 0, tmp.length);
  iv = tmp;
/* Sequenz 2 */
  tmp = new byte[bsize];
  System.arraycopy(key, 0, tmp, 0, tmp.length);
  key = tmp;
```

Notizen:

Schritt 4

Verallgemeinerung

Wir vergleichen die Eltern der gefundenen Paare miteinander, d. h.

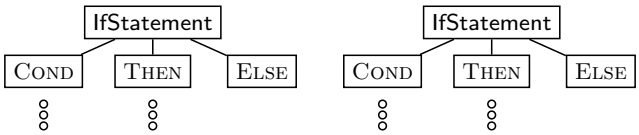

Offensichtlich sind die Eltern der Klonsequenzen gleich.

Notizen:

Ergebnis

wie erwartet

Die gefundenen Duplikate sind also:

```
/* Klon 1 */
if(iv.length > ivsize) {
  tmp = new byte[ivsize];
  System.arraycopy(iv, 0, tmp, 0, tmp.length);
  iv = tmp;
}
/* Klon 2 */
if(key.length > bsize) {
  tmp = new byte[bsize];
  System.arraycopy(key, 0, tmp, 0, tmp.length);
  key = tmp;
}
```

CloneDR

der Klondoktor

- „Clone Detector and Remover“
- kommerzielles „Referenz“-Tool von Semantic Designs, Inc. zum Paper von Baxter et al.
- Sprachen: C, C++, Java, Cobol, weitere Frontends für über 30 Sprachen verfügbar, erweiterbar
- Evaluationsversion entweder für Java oder Cobol nutzbar
  - nur Klonerkennung, eingeschränkt
  - keine Klonentfernung
- `http://www.semdesigns.com/Products/Clone/`

CloneDR-Evaluationsversion

Java-GUI

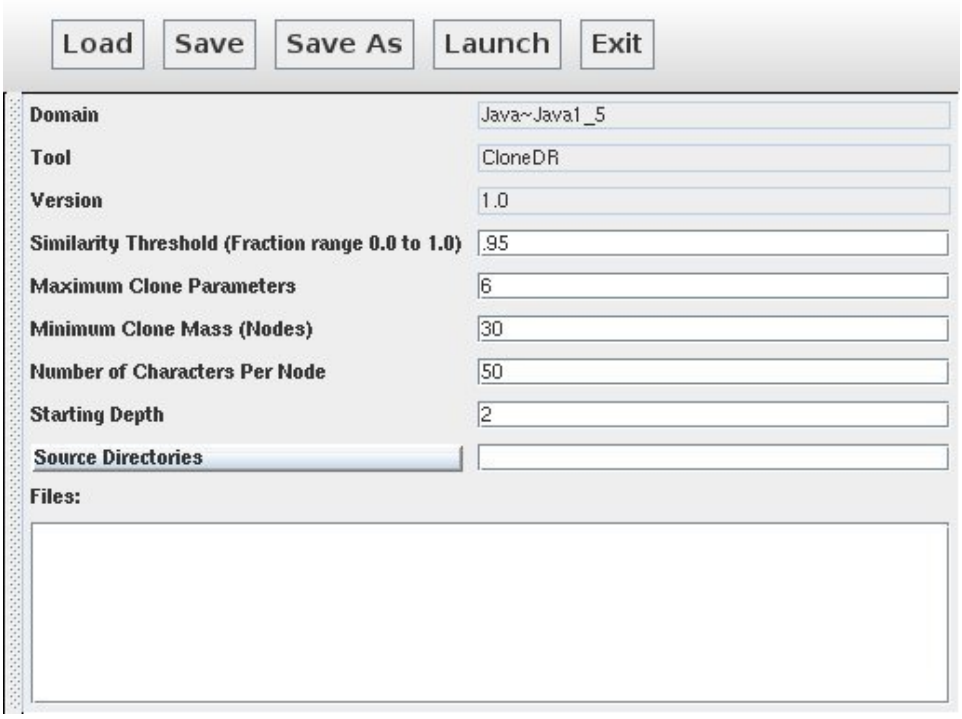

CloneDR

Java-GUI

- erzeugt Datei mit den entsprechenden Parametern
- ruft Batch-Datei (`.bat`) auf, die entsprechende Umgebungsvariablen setzt und das Parlanse-System mit CloneDR aufruft
- Erklärungen:
  - *Domain*: Programmiersprache
  - *Similarity Threshold*: Mindestähnlichkeit, um als Duplikat anerkannt zu werden
  - *Maximum Clone Parameters*: max. Anzahl untersch. Namen (Variablen, Konstanten, ...) pro Klon
  - *Minimum Clone Mass*: min. Masse eines Teilbaums, d. h. Mindestanzahl von Knoten in einem Teilbaum
  - *Number of Characters Per Node*: Mindestlänge für Strings, die stärker in Masse einberechnet werden[3]
  - *Starting Depth*: Mindesttiefe für Teilbaum

[3] noch nicht implementiert

- erkennt vorallem Duplikate innerhalb einer Datei
- hat perfekte Präzision, denn nur Klone, die auch entfernt werden können, werden ausgegeben
- automatische Entfernung der Klone sehr wertvoll

Quelle der obigen Bewertung: Elizabeth Burd, John Bailey: *Evaluating Clone Detection Tools for Use during Preventative Maintenance*

Weitere verfügbare Software

- `ccdiml` im Bauhaus-Paket der Uni-Stuttgart.
  - `http://www.iste.uni-stuttgart.de/ps/bauhaus/download/`
  - nutzt *Abstract Syntax Suffix Trees*
- SimScan (Similarity Scanner) von Blue-Edge
- `dupman` von Simon Giesecke
  - Feature/Plugin für Eclipse
  - im Rahmen einer *Diplomarbeit an der Uni Oldenburg* entwickelt
- CCFinder, Covet, JPlag, Moss, ...

Referenzen

- Ira D. Baxter, Andrew Yahin, Leonardo M. De Moura, Marcelo Sant'Anna, Lorraine Bier: „*Clone Detection Using Abstract Syntax Trees*“. In: Proceedings of International Conference on Software Maintenance. Seiten: 368 - 377. IEEE Computer Society Press, 1998.
- Simon Giesecke: Diplomarbeit „*Clone-based Reengineering für Java auf der Eclipse-Plattform*“. Universität Oldenburg, 26. September 2003.

Vielen Dank nochmal an Simon Giesecke und Ira Baxter für die schnelle Beantwortung von E-Mails.

Referenzen

Weiterführend.

- Felix Beckwermert: Diplomarbeit „*Visualisierung von Software-Klonerkennung*“. Universität Bremen, 17. Oktober 2006.
- Ira D. Baxter, Dale Churchett: „*Using Clone Detection to Manage a Product Line*“.
- Rainer Koschke, Raimar Falke, Pierre Frenzel: „*Clone Detection Using Abstract Syntax Suffix Trees*“. 13th Working Conference on Reverse Engineering (WCRE 2006), 2006.
- Yidong Liu: Diplomarbeit „*Semiautomatische Entfernung des duplizierten Codes*“. Universität Stuttgart, 11. Juli 2004.