Ein Parser aus Objekten

(Objektorientierung in Compilerbau)

Bernd Kühl
University of Osnabrück, Germany
bernd@informatik.uni-osnabrueck.de
http://www.inf.uos.de/bernd

1 Compilerphasen

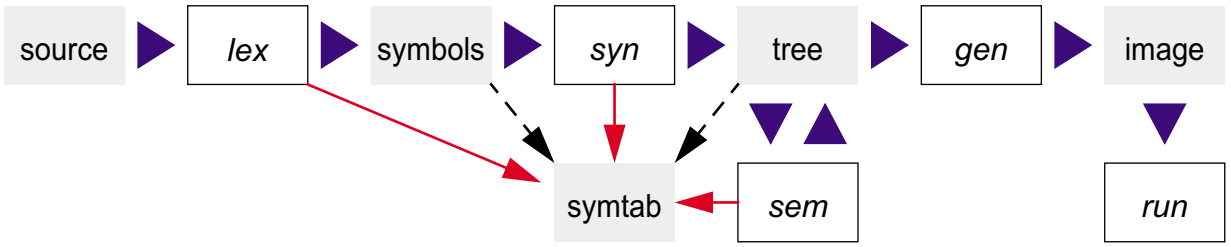

- Inhalt meiner Promotion:
  Was bringt der Einsatz von Objektorientierung in den einzelnen Phasen.
- Inhalt des Vortrags:
  Syntax-Analyse und Aktionen.

2 Lexikalische Analyse

Gängige Techniken

- handgeschriebene Scanner
- fertige Scanner[klassen], Beispiel `java.io.StreamTokenizer`
- Scannergeneratoren, Beispiel *lex*/*flex*/*JLex*
- Nachteile handgeschriebener Scanner:
  - mühsam zu implementieren (Beispiel: Gleitkommazahlen)
  - fehleranfällig
  - schwer erweiterbar
  - Performance
- Nachteile fertiger Scanner[klassen]:
  - Nicht allgemein verwendbar
  - `StreamTokenizer`: Zwischenraum wird immer ignoriert, Zwischenraum ist als Symbol nicht greifbar, Integer- und Gleitkommazahlen können nicht gleichzeitig erkannt werden und Exponentialdarstellung für Gleitkommazahlen kann man gar nicht erkennen, ...
- Nachteile Scannergeneratoren:
  - Der Entwicklungszyklus hat zwei Schritte.
  - Soll der Scanner erweitert oder geändert werden, müssen beide Schritte erneut ausgeführt werden.
  - Reguläre Ausdrücke sind für Anfänger schwer zu erlernen, und vor allem kryptisch.
  - Um einen fremden oder älteren komplexeren regulären Ausdruck zu verstehen, bedarf es einiger Erfahrung:

    ```
    "/*"([^*]|"*"+[^/*])*"*"+"/"
    ```

  - Ohne einen ausführlichen Test ist ein komplexer regulärer Ausdruck außerdem fehleranfällig.
  - Es gibt reale Probleme, die mit regulären Ausdrücken nur schwer oder auch gar nicht lösbar sind: z.B. einen fehlerfreien regulären Ausdruck für einen C-Kommentar oder gar einen Ausdruck für geschachtelte C-Kommentare.

oolex (object orientated lexer)

- Das Design von oolex ist strikt objekt-orientiert.
- Als Scanner stehen viele Objekte als Symbol-Erkenner im Wettbewerb.
- Ein Raum dieser Objekte verwaltet die Eingabe und liefert den Objekten Zeichen für Zeichen aus der Eingabe.
- Objekte, die mit dem Zeichen nichts anfangen, verlassen den Raum.
- Das letzte Objekt im Raum stellt als längstes das erkannte Symbol dar.
- Typische Symbol-Erkenner sind daher als Klassen in einer Bibliothek vorbereitet.
- Gewinnt ein Objekt eine Erkennungsrunde, kennt das Objekt optional ein anderes Objekt, welches die zugehörige Aktion implementiert.
- Alle Symbol-Erkenner- und Aktions-Klassen sind serialisierbar.

Fazit

- Der neue Ansatz ist objekt-orientiert und damit für objekt-orientierte Sprachen wie Java, Objective-C oder C++ intuitiver.
- Eine Firma, die eine andere Bibliothek von Erkennern entwickelt und verkauft, kann die Klassen in binärer Form verkaufen.
- Spezialisierung existenter Klassen durch Vererbung bzw. Ableitung.
- Die Entwicklungszeit für oolex-Scanner ist sehr gering. Das System ist daher ideal für rapid prototyping.
- Die Klassen der Bibliothek sind für verschiedene Scanner zu verwenden (reuse).
- Serialisierung: Scanner können von verschiedenen Projekten in binärer Form geteilt werden (reuse).
- Umkonfiguration (Scanner, Aktionen) im laufenden Betrieb.
- Da Objekte Zustände besitzen, können die Symbol-Erkenner mächtiger als endliche Automaten sein.
- Nachteil: Performance.

3 oops — Ein Parser aus Objekten

Objekte für Grammatiken

- Kontextfreie Grammatik: Terminals, Non-Terminals, Regeln und eine Start-Regel.
- Beispiel BNF

  ```
  identifier : letter | identifier letter | identifier number
  ```

- Beispiel EBNF

  ```
  identifier : letter [{ letter | number }]
  ```

- Instanzen von Objekten des Pakets `oops.parser` repräsentieren eine EBNF-Grammatik:
  - Ein `Parser`-Objekt verweist auf viele `Rule`-Instanzen.
  - Jede `Rule` verbindet das Non-Terminal auf der linken Seite (`Id`) mit der rechten Seite.
  - Die rechte Seite einer `Rule` ist ein einzelnes Objekt, zum Beispiel eine Sequenz von Symbolen in einer `Seq`-Instanz.
  - Alternativen werden in einem `Alt`-Objekt gesammelt.
  - `Some` (1-n) und `Many` (0-n) kapseln Wiederholungen und `Opt` (0-1) repräsentiert einen optionalen Teil.
  - `Lit` stellt Literale ("<="), `Token` Symbol-Kategorien (Zahlen) und `Id` Verweise (auf Regeln) dar.
- Das Beispiel als Objekt-Baum:

  ```
  Parser
     Rule identifier
        Seq
           Id letter
           Many
              Alt
                 Id letter
                 Id number
  ```

- Parsierung: rekursiver Abstieg, `parse()`-Methode.
- oops: object orientated parser system.
- oops-Parser sind serialisierbar und damit wiederverwendbar.

Lookahead-Mengen

- Während der Parsierung treffen die Objekte Entscheidungen aufgrund von lookahead-Mengen.
- Lookahead: Die Menge aller Eingabesymbole, die an dieser Stelle als nächstes in der Eingabe auftreten können.
- Die Berechnung des lookahead ist lokal auf die Klassen verteilt:

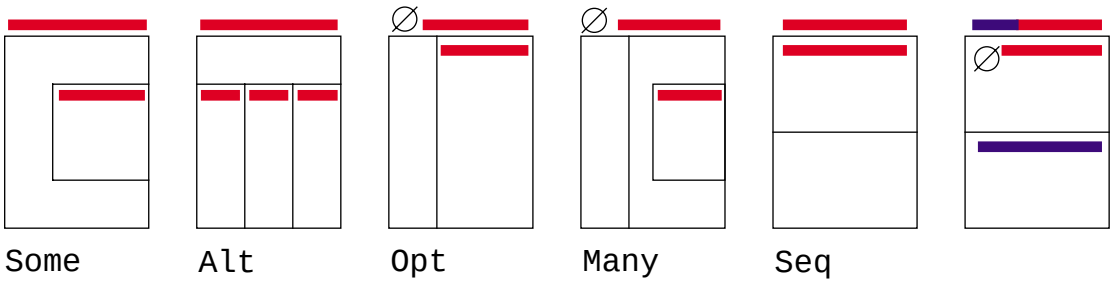

  - `Some` übernimmt den lookahead von seinem Unterknoten.
  - `Alt` berechnet den lookahead durch Vereinigung der lookaheads der Alternativen.
  - `Opt` und `Many` übernehmen den lookahead von ihrem Unterknoten und fügen die leere Eingabe hinzu.
  - `Seq` nimmt den lookahead des ersten Sequenz-Elements und addiert den lookahead der folgenden Elemente, solange die leere Eingabe akzeptiert wird.
  - `Rule` übernimmt den lookahead von der rechten Seite und `Id` von der `Rule`.
  - `Lit` und `Token`: Terminal ist lookahead.
- Die Verteilung der Berechnung zerlegt diese in kleine und einfache Teilprobleme. Der Algorithmus ist so leicht zu verstehen.

Follow-Mengen

- Follow: Die Menge aller Eingabesymbole, die nach diesem Knoten als nächstes in der Eingabe auftreten können.
- Auch die Berechnung der follow-Menge ist lokal auf die Klassen verteilt:

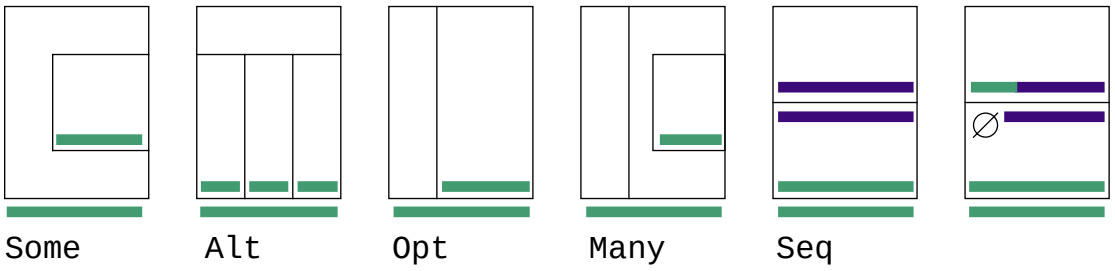

  - `Some`, `Alt`, `Opt` und `Many` geben ihre follow-Menge an den Unterknoten weiter.
  - `Seq` reicht seine follow-Menge an das letzte Element weiter. Ist die leere Eingabe in dem lookahead des Elements, wird die Vereinigung von follow und lookahead an das nächstletzte Element überreicht
  - `Id` reicht follow an die zugehörige `Rule`, und diese reicht die Menge an das Objekt der rechten Seite weiter.
- Die Berechnung startet mit dem EOF-Symbol für die rechte Seite der Start-Regel.
- Wiederholung der Berechnung bis alle follow-Mengen sich nicht mehr ändern.
- Die Verteilung der Berechnung zerlegt diese in kleine und einfache Teilprobleme. Der Algorithmus ist so leicht zu verstehen.

Mehrdeutige Grammatik

- Parsierung: rekursiver Abstieg, LL(1), nicht alle Grammatiken sind LL(1):

```
bits : { 0 | 1 } ( 0 | 1 )
```

- Der Baum und die lookahead - und follow-Mengen:

```
                  lookahead   follow
seq               0 1         [empty]
  some            0 1         0 1
    alt           0 1         0 1
      lit 0       0           0 1
      lit 1       1           0 1
  alt             0 1         [empty]
    lit 0         0           [empty]
    lit 1         1           [empty]
```

Prüfen einer Grammatik

- Auch das Prüfen der Grammatik auf LL(1) verteilt sich lokal auf die Klassen:

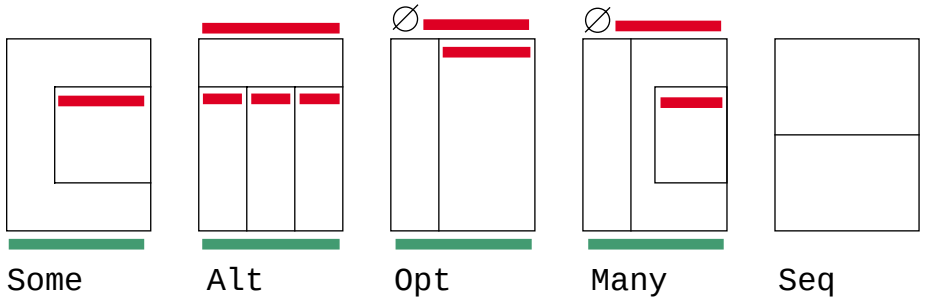

  - `Some`, `Opt`, `Many`: Die lookahead- und follow-Menge müssen/sollten disjunkt sein (shift/reduce-Konflikt).
  - `Alt`: Die lookahead-Mengen der Alternativen müssen paarweise disjunkt sein. Enthält der lookahead die leere Eingabe, müssen follow und lookahead disjunkt sein.
  - `Seq` ruft lediglich bei allen Elementen die Prüfmethode auf.
- Weiterhin wird geprüft, daß jede Regel verbunden ist und daß keine unendliche Rekursion auftritt:

```
x: "x" x;
```

Scanner-Schnittstelle

- Ein oops-Parser benötigt eine Implementierung von `oops.scanner.Scanner` als Partner:

```
public interface Scanner {
  public void scan(SymTab symtab, Hashtable tokens) throws IOException;
  public boolean advance() throws IOException;
  public boolean atEnd();
  public Object symbol();
  public Object value();
}
```

- Der Parser ruft einmal `scan()` beim `Scanner` zur Initialisierung auf.
- `advance()` rückt ein Symbol in der Eingabe vor. Die Methode hat `false` am Dateiende, sonst `true` zu liefern.
- `atEnd()` zeigt als `boolean` an, ob das Dateiende erreicht worden ist.
- `value()` liefert ein Werte-Objekt oder `null` zum aktuellen Symbol.
- Das Resultat von `symbol()` ist ein Objekt, welches das momentane Symbol repräsentiert.
- Bei Aufruf von `scan()` ist `symtab` mit den reservierten Wörtern vorgeladen:

```
public interface SymTab extends Serializable {
  public Handle get(String key);
  public Enumeration keys();

  public interface Handle {
    public boolean isEntered();
    public void enter(Object symbol, Object value);
    public void remove();
    public Object symbol();
    public Object value();
    public String key();
  }
}
```

- In `tokens` ist für alle Tokennamen als Schlüssel jeweils ein zugehöriges Objekt für `symbol()` zur Repräsentierung des Tokens abgelegt worden.

Beispiel: Ein Parser für arithmetische Ausdrücke

- Die Grammatik

```
expr    : [{ [ sum ] ";" }];
sum     : product [{ ( "+" | "-") product }];
product : term [{ ( "*" | "/" ) term }];
term    : NUMBER | "(" sum ")";
```

- Der Code:

```
package parserByConstructors;

import ...

public class ArithParser {
 private static oops.parser.Parser arithParser;
 static {
   try {
     // build parser...
     arithParser = new oops.parser.Parser(
       new oops.parser.Rule[] {
         new oops.parser.Rule( // expr    : [{ [ sum ] ";" }];
           new oops.parser.Id("expr"),                    // lhs
           new oops.parser.Many(                          // rhs
             new oops.parser.Seq(new oops.parser.Node[] {
               new oops.parser.Opt(new oops.parser.Id("sum")),
               new oops.parser.Lit(";")
             })
           )
         ),
         new oops.parser.Rule( // rule sum    : product [{ ( "+" | "-") product
}];
           new oops.parser.Id("sum"),                     // lhs
           new oops.parser.Seq(new oops.parser.Node[] {   // rhs
             new oops.parser.Id("product"),
             new oops.parser.Many(
               new oops.parser.Seq(new oops.parser.Node[] {
                 new oops.parser.Alt(new oops.parser.Node[] {
                     new oops.parser.Lit("+"),
                     new oops.parser.Lit("-")
                   }),
                 new oops.parser.Id("product")
               })
             )
           })
         ),
         new oops.parser.Rule( // rule product : term [{ ( "*" | "/" ) term }];
           new oops.parser.Id("product"),                 // lhs
           new oops.parser.Seq(new oops.parser.Node[] {   // rhs
             new oops.parser.Id("term"),
             new oops.parser.Many(
               new oops.parser.Seq(new oops.parser.Node[] {
                 new oops.parser.Alt(new oops.parser.Node[] {
                     new oops.parser.Lit("*"),
                     new oops.parser.Lit("/")
                   }),
                 new oops.parser.Id("term")
               })
             )
           })),
```

```
          new oops.parser.Rule( // rule term    : NUMBER | "(" sum ")";
            new oops.parser.Id("term"),                     // lhs
            new oops.parser.Alt(new oops.parser.Node[] {    // rhs
              new oops.parser.Id("NUMBER"),
              new oops.parser.Seq(new oops.parser.Node[] {
                new oops.parser.Lit("("),
                new oops.parser.Id("sum"),
                new oops.parser.Lit(")"),
              })
            })
          )
        }
      );
      // check parser...
      arithParser.check();
    } catch (oops.parser.ParserBuildException pe) {
      System.err.println(pe);
      System.exit(1);
    } catch (oops.parser.CheckLL1Exception ce) {
      System.err.println(ce);
      System.exit(1);
    }
  }

  public static void main(String args []) throws
    oops.parser.ParseException, oops.opi.OpiException, IOException,
    ClassNotFoundException {
    if (args.length == 0 ||
        (args[0].equals("-deserialize") && args.length < 3)) usage();
    int n = 0;
    if (args[0].equals("-deserialize")) {
      n += 2;
      ObjectInputStream in = new ObjectInputStream(new
FileInputStream(args[1]));
      arithParser = (oops.parser.Parser) in.readObject();
      in.close();
    }
    if (args[n].equals("parse")) {
      oops.scanner.Scanner scanner = new Scanner(new oops.opi.InputSource(
        System.in));
      arithParser.parse(scanner, (oops.scanner.TableFactory) null);
    } else if (args[n].equals("dump")) {
      oops.tools.Dump.dump(arithParser);
    } else if (args[n].equals("serialize")) {
      ObjectOutputStream out = new ObjectOutputStream(System.out);
      out.writeObject(arithParser);
      out.flush(); out.close();
    } else usage();
  }
  private static void usage() {
    System.err.println("usage: ArithParser [-deserialize file] "+
                       "(parse | dump | serialize)");
    System.exit(1);
  }
}
```

4 Vererbung — Aktionen

Goal

- Ohne Aktionen ist das Parsieren von Programmen über Grammatiken nur von akademischem Interesse.
- Durch Spezialisierung/Vererbung können Aktionen eingebaut werden.
- `oops.parser.goal`-Klassen/Interface: `Parser`, `Rule`, `Lit`, `Token` und `Goal`.
- `Goal`-Interface:

```
package oops.parser.goal;

import ...

public interface Goal {
  public void shift (Goal sender, Object value);
  public void shift (Token sender, Object value);
  public void shift (Lit sender, Object value);
  public Object reduce ();
  public void error ();
}
```

- Die `Goal`-Instanzen werden über ein Factory-Muster erzeugt.
- Es gibt Standard-Implementierungen für die Factories und `Goal`.
- Die default Factory erzeugt `Goal`-Instanzen aufgrund von Regelnamen. Für

```
sum     : product [{ ( "+" | "-") product }];
```

  wird zum Beispiel eine Instanz der `Goal`-Klasse `sum` erzeugt.
- Für jede aktive Regel ist eine `Goal`-Instanz aktiv:

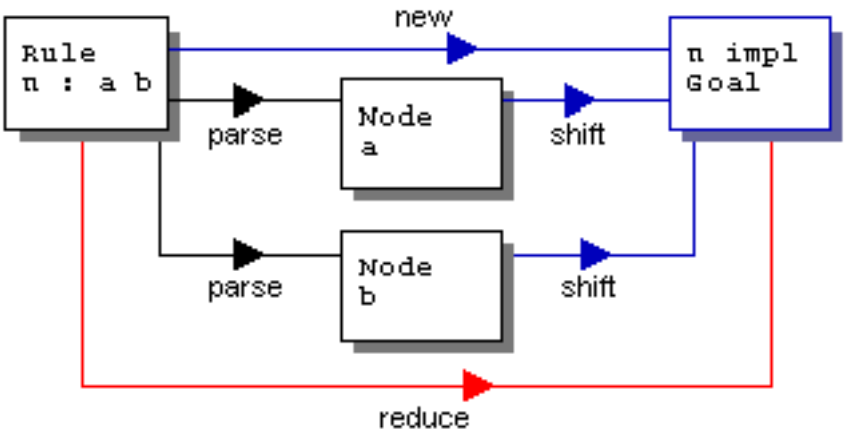

Arithmetische Ausdrücke per Goal

- Die Grammatik:

```
expressions     : [{ [ sum ]  ( ";" | "\n" ) }];
sum             : product [{ sum.add | sum.sub }];
sum.add         : "+" product;
sum.sub         : "-" product;
product         : term [{ product.mul | product.div }];
product.mul     : "*" term;
product.div     : "/" term;
term            : NUMBER | term.minus | "(" sum ")";
term.minus      : "-" term;
```

- `term.java`:

```
public class term extends oops.parser.goal.GoalAdapter {
  public static class minus extends GoalAdapter {
    public Object reduce () {
      return new Double(- ((Number)result).doubleValue());
    }
  }
}
```

- `sum.java`:

```
import oops.parser.Lit;
import oops.parser.goal.Goal;
import oops.parser.goal.GoalAdapter;

public class sum extends GoalAdapter {
  public void shift (Goal sender, Object value) {
    if (result == null) result = value;
    else result = ((eval) sender).eval((Number) result, (Number) value);
  }
  public abstract static class eval extends GoalAdapter {
    public abstract Object eval (Number left, Number right);
    public void shift (Lit sender, Object value) {}
  }
  public static class add extends eval {
    public Object eval (Number left, Number right) {
      return new Double(((Number) left).doubleValue() +
                        ((Number) right).doubleValue());
    }
  }
  public static class sub extends eval {
    public Object eval (Number left, Number right) {
      return new Double(((Number) left).doubleValue() -
                        ((Number) right).doubleValue());
    }
  }
}
```

- In der Regel bilden (und serialisieren) `Goal`-Instanzen einen Baum zur Repräsentierung der Eingabe.

Weitere Aktionsideen

- `oops.parser.trace`: die Knoten des Parser-Baums schreiben während der Erkennung eines Programms eine Trace.
- `oops.parser.reducer`: analog zu `Goal`, aber wesentlich einfacher. Am Ende einer Regel wird durch Aufruf von `reduce()` in einem Argument-Array das Resultat von `reduce()` gegen Unterregeln, erkannte `Lit`- und erkannte `Token`-Instanzen übergeben.

```
package oops.parser.reducer;

public interface Reducer {
  public void error();
  public Object reduce(Object[] values);
}
```

- Ein weiterer möglicher Ansatzpunkt wäre eine Listener-Schnittstelle. Diese Idee bedingt aber gegebenenfalls einen lokalen Stack...

5 oops als Parsergenerator

- oops als Parser:

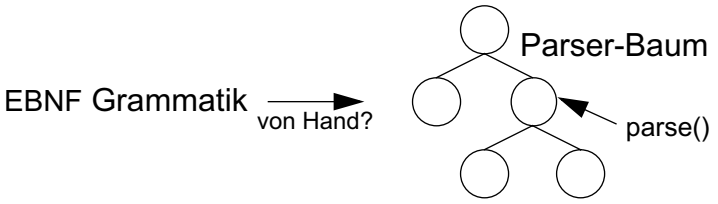

- EBNF-Grammatik für EBNF:

```
parser  : { rule };             // a pares is one ore more rules.
rule    : ID ":" alt ";";       // rule is a name and a right hand side
alt     : seq [{ "|" seq }];    // alternatives
seq     : { ID | LIT | TOKEN | some | opt | "(" alt ")" }; // sequence
some    : "{" alt "}";          // one or more
opt     : "[" alt "]";          // zero or one
```

- oops als Parsergenerator:

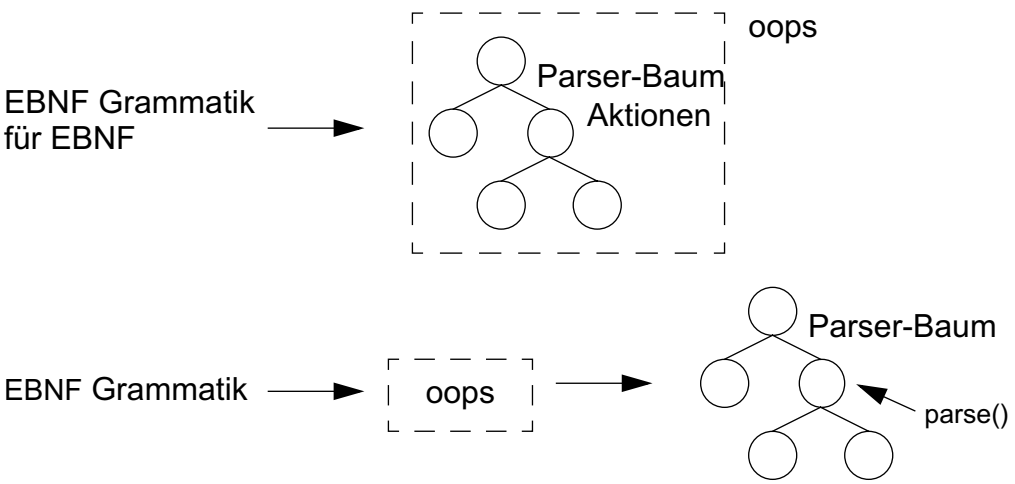

- Beispiel:

```
$ export CLASSPATH=../../jars/oops.jar:../..
$ java -Doops.oops.actionType=goal oops.Compile ... arith.ebnf > arith.ser
Using ebnf parser generator generated by oops on Mon Apr 16 12:49:34 CEST 2001
$
```

- Unterstützung für `oops.parse`, `oops.parse.trace`, `oops.parse.reduce` und `oops.parse.goal`.
- Trennung von Grammatik und Aktionen.
- oops ist bootstrap-fähig.

6 Erweiterung — Extended EBNF

- Aktionen sind ein Beispiel für Spezialisierung durch Vererbung.
- Spezialisierung durch Erweiterung d.h. neuer Klassen eines Parser-Baums.
- HTML oder XML sind schon aufgrund der Attribute in [E]BNF kaum formulierbar.
- Mögliche neue Grammatik-Syntax:

```
parser  : { rule };
rule    : ID ":" or ";";
or      : xor  [{ "|" xor }];  // inklusives oder
xor     : and [{ "^" and }];   // exklusives oder
and     : seq  [{ "&" seq }];  // and
seq     : { ID | LIT | TOKEN | some | opt | "(" or ")" };
some    : "{" or "}";          // one or more
opt     : "[" or "]";          // zero or one
```

  |, ^ und & in Anlehnung an bekannte Operatoren aus Programmiersprachen

- inklusives oder, |: Alle Alternativen dürfen (müssen aber nicht) in beliebiger Reihenfolge maximal einmal vorkommen.
- exklusives oder, ^: Nur eine Alternative wird erkannt.
- and, &: Jede Alternative muß (in beliebiger Reihenfolge) vorkommen.
- HTML, XML : Attribute per | aufzählen.
- Weitere mögliche neue Grammatik-Syntax:

```
or      : xor  [{ "|" xor [ "*" ] }];
xor     : and [{ "^" and }];
and     : seq  [{ "&" seq [ "+" ] }];
```

  * und + erlauben wiederholtes Auftreten.

- Spezialisierung durch neue Klassen: `oops.parser.XOr`, `oops.parser.Or`, `oops.parser.And`.
- Neue Klassen erben Teile (Speicherung von Unterknoten, Prüfalgorithmen, Mengen-Berechnung, ...) von der Oberklasse `oops.parser.Alt`.
- Die jeweils neue Funktionalität ist mit wenig Code implementiert.

7 Fazit

- Grammatiken sind als Objektbaum repräsentierbar.
- oops besteht aus den Klassen zur Repräsentierung eines Parsers und aus dem Parsergenerator.
- Objekte kapseln Aktionen und sind im laufenden austauschbar.
- Die Serialisierung von Parsern macht diese wiederverwendbar.
- oops trennt Grammatik und Aktionen.
- Die Aufteilung der Mengen-Berechnung, der Prüfung einer Grammatik oder des Parsierens auf Instanz von Klassen lokalisiert die Probleme auf kleine Teile und macht die Algorithmen damit entdeckbar.
- Vererbung oder Erweiterung durch neue Klassen macht oops mächtiger: Aktionen bzw. Extended EBNF.
- Automatische error recovery machbar.

8 Literatur und Links

[1] Homepage oops: http://www.inf.uos.de/bernd/oops

[2] Homepage oolex: http://www.inf.uos.de/bernd/oolex

[3] Dieser Vortrag als PDF:
http://www.inf.uos.de/bernd/talks/oops-ifc01/talk.pdf

[4] Dieser Vortrag als HTML:
http://www.inf.uos.de/bernd/talks/oops-ifc01/html/talk.html

[5] Die Beispiele des Vortrags:
http://www.inf.uos.de/bernd/talks/oops-ifc01/code.zip

[6] Vorlesung Compilerbau mit Java, WS 1998/99, Prof. Axel-Tobias Schreiner:
http://www.vorlesungen.uni-osnabrueck.de/informatik/compilerbau98/

[7] Bernd Kühl, Axel-Tobias Schreiner, An object-oriented LL(1) parser generator, SIGPLAN Notices, ACM December 2000

[8] Bernd Kühl, oolex — Lexikalische Analyse mit Objekten, IFC Seminar, oolex Lexikalische Analyse mit Objekten, Sommersemester 2000, Universität Osnabrück, http://www.inf.uos.de/bernd/talks/oolex-ifc00/html/talk.html