6. Syntaxgesteuerte Übersetzung

Inhalte der Vorlesung

1. Einführung
2. Lexikalische Analyse
3. Der Textstrom-Editor sed
4. Der Scanner-Generator lex (2 Termine)
5. Syntaxanalyse und der Parser-Generator yacc (3 T.)
6. → Syntaxgesteuerte Übersetzung
7. Übersetzungssteuerung mit make

6. Syntaxgesteuerte Übersetzung

6.1 Syntaxgesteuerte Definitionen
6.2 Konstruktion expliziter Syntaxbäume
6.3 Aufsteigende Auswertung

Attributierter Syntaxbaum

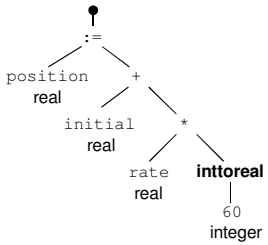

- Knoten mit Werten
  - Wert: durch Semantikregel des Knotens
- Semantikregel mit Seitenwirkungen möglich
  - Ausgabe
  - globale Variable verändern

Abhängigkeiten von Attributen

- synthetisiertes Attribut
  - Wert hängt nur von Nachfolgeknoten ab
- ererbtes Attribut
  - Wert hängt von Vorgängern und Geschwistern ab
- Auswertungsreihenfolge
  - muß Abhängigkeitsgraph beachten
  - Baum: nicht unbedingt explizit aufgebaut

Syntaxgesteuerte Definition

- ist kontextfreie Grammatik
  plus:
  - Attributmenge für jedes Grammatiksymbol
  - Menge von Semantikregeln für jede Grammatikregel
- Attributgrammatik:
  - ist syntaxgesteuerte Definition
    plus
    - Semantikregeln ohne Seitenwirkungen

Syntaxgesteuerte Definition eines einfachen Taschenrechners

Grammatikregel	Semantikregel
$l \rightarrow e$ NL	print(e.val)
$e \rightarrow e_1 + t$	e.val := e_1.val + t.val
$e \rightarrow t$	e.val := t.val
$t \rightarrow t_1 * f$	t.val := t_1.val · f.val
$t \rightarrow f$	t.val := f.val
$f \rightarrow$ (e)	f.val := e.val
$f \rightarrow$ NUMBER	f.val := NUMBER.val

S-attributierte Definition

- syntaxgesteuerte Definition
- nur synthetisierte Attribute
  - Wert hängt nur von Nachfolgeknoten ab
- Beispiel:
  - Taschenrechner eben
- kann von Blättern zur Wurzel ausgewertet werden
  - leicht

Ererbte Attribute

- Wert hängt von Vorgängern und Geschwistern ab
- für Abhängigkeit von Kontext
  - Beispiel: Typ eines Bezeichners

Ererbte Attribute: Beispiel

Grammatikregel	Semantikregel
$d \rightarrow t\ l$	l.in := t.type
$t \rightarrow$ INT	t.type := integer
$t \rightarrow$ REAL	t.type := real
$l \rightarrow l_1$, ID	l_1.in := l.in addtype(ID.entry, l.in)
$l \rightarrow$ ID	addtype(ID.entry, l.in)

Ableitungsbaum mit Attribut „in“ an *l*-Knoten

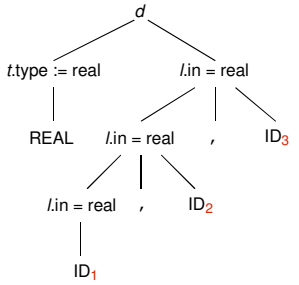

Abhängigkeitsgraph

- Abhängigkeiten zwischen Attributen
- wird über Ableitungsbaum konstruiert
- Beispiel:

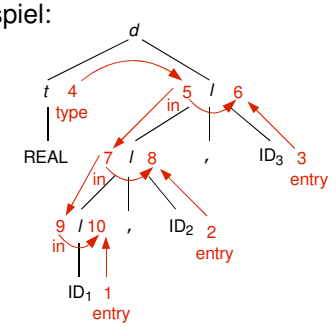

Abhängigkeitsgraph (2)

- wenn möglich: Abhängigkeitsgraphen schrittweise an Tafel unter Beamer-Bild der Vor-Folie malen
- Der Abh.-Graph hat für jedes Attribut einen Knoten
- „1“, ...: Sind die Knoten des Abh.-Graphen
- „1“, „2“, „3“: Wir fangen hier mit den Attributen an, die von nichts abhängen
  - ID_3 hat Attribut „entry“
- „6“, „7“, „8“: Knoten für Scheinattribute
  - je eines für jeden Prozeduraufruf
- Siehe auch Drachenbuch S. 346f.
- „l“ = steht für „**l**ist (of IDs)“

Auswertungsreihenfolge

- nötig: topologische Sortierung
  - Reihenfolge für Auswertung, die Abhängigkeiten einhält
- verschiedene Methoden:
  - Syntaxbaummethoden
    - explizite topologische Sortierung
      - für jeden Syntaxbaum wieder neu
  - regelbasierte Methoden
    - feste, aber explizite Reihenfolge für jede Regel
      - von Hand oder automatisch
  - unbewußte Methoden
    - beliebiges festes Schema
      - z.B. so, wie Parser gerade die Grammatikregeln erkennt

6. Syntaxgesteuerte Übersetzung

Syntaxbaum

- verdichteter Ableitungsbaum
  - Operatoren und Schlüsselworte in Knoten verschoben

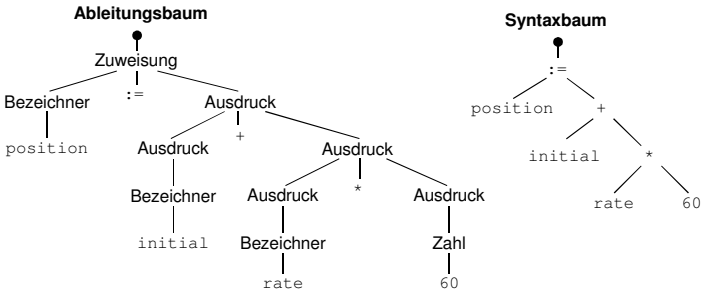

Konstruktion expliziter Syntaxbäume

- Vorteil:
  entkoppelt Syntaxanalyse und Übersetzung
  - Reihenfolge der Analyse beschränkt nicht Generierung
- Nachteil:
  Platzbedarf ggf. hoch

Konstruktion expliziter Syntaxbäume für Ausdrücke

- ein Knoten pro Operator und pro Operand
  - Knoten z.B. implementiert als Record
    - OO-Sprachen: Knoten als Objekt
  - Felder:
    - Werte
    - Zeiger auf andere Records

Rekursive Auswerter für Attribute

- für explizite Syntaxbäume
  - Auswertung der Attribute erst *nach* Fertigstellung des Syntaxbaums
- Realisierung: gegenseitig rekursive Funktionen
  - eine Funktion pro Nichtterminal bzw. Symbol
  - Aufruf der Funktionen für Unterknoten in geeigneter Reihenfolge:
    - L-attributierte Definition: links nach rechts
    - sonst: geeignete andere Reihenfolge
- evtl. mehrere Durchläufe zur vollständigen Auswertung nötig

6. Syntaxgesteuerte Übersetzung

S-attributierte Definition

- nur synthetisierte Attribute
  - Wert hängt nur von Nachfolgeknoten ab
- kann von Parser mit aufsteigender Analyse „nebenher“ ausgewertet werden
  - *ohne* expliziten Syntaxbaum
- Idee der Auswertung:
  - synthetisierte Attribute mit auf Parser-Stack
  - bei jeder Reduktion:
    - Werte mit von Stack nehmen
    - neuen Wert berechnen
    - neuen Wert mit neuem Nichtterminal auf Stack legen

L-attributierte Definition

- syntaxgesteuerte Definition
- Bedingung für ererbtes Attribut von b_j:
  - sei:
    Regel $a \rightarrow b_1\ b_2\ \ldots\ b_{j-1}\ b_j\ \ldots\ b_n$
  - dann:
    Attribut von b_j hängt nur ab von
    1. Attributen von weiter links stehenden $b_1, b_2, \ldots, b_{j-1}$ und
    2. ererbten Attributen von a
- keine Einschränkungen für synthetisierte Attribute

Eigenschaften L-attributierter Definitionen

- erlaubt auch (bestimmte) ererbte Attribute
- kann immer durch Depth-First-Traversierung (s.u.) des Syntaxbaums ausgewertet werden
- alle syntaxgesteuerten Definitionen über LL(1)-Grammatiken sind L-attributiert
- viele syntaxgesteuerten Definitionen über LR(1)-Grammatiken sind L-attributiert
- Name „L“:
  Attributinformation fließt von **l**inks nach rechts

Depth-First-Traversierung des Syntaxbaums

```
procedure dfvisit(k : knoten);
begin
   for n := alle Nachfolger von k, links → rechts do
   begin
      berechne ererbte Attribute von n;
      dfvisit(n);
   end;
   berechne synthetisierte Attribute von k;
end
```

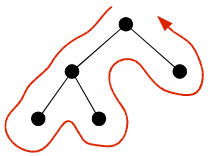

Übersetzungsschema

- Notation zur Spezifikation der Übersetzung während der Syntaxanalyse
  - kein expliziter Syntaxbaum notwendig
- kontextfreie Grammatik
  - Attribute an Grammatiksymbolen
    - synthetisiert und ererbt
  - semantische Aktionen in rechte Seiten der Regeln eingefügt, eingeschlossen in Klammern { }
    - Zeitpunkt der Auswertung dadurch explizit
- yacc verwendet Übersetzungsschemata

Übersetzungsschema: Beispiel

- Taschenrechner für ganze Zahlen mit yacc
  - hier nur synthetisierte Attribute
    - daher alle semantischen Aktionen immer am Ende

Demo

Übersetzungsschema: Beispiel (2)

- calc-int.l

```
%{
#include <math.h>
#include "calc-int.tab.h"
%}
%option noyywrap
DIGIT    [0-9]
%%
{DIGIT}+        {
                  yylval = atoi(yytext);
                  return NUMBER;
                }
"="             |
"("             |
")"             |
"+"             |
"-"             |
"*"             |
"/"             { return *yytext; }
[[:space:]]     { /* ignoriere Whitespace */ }
.               { return ILLEGAL_CHAR; }
```


Übersetzungsschema: Beispiel (3)

- calc-int.y

```
%{
#include <stdio.h>
#define YYERROR_VERBOSE
void yyerror(char *);
%}
%token NUMBER ILLEGAL_CHAR
%left '-' '+'
%left '*' '/'
%%
eingabe:          /* empty */
                | eingabe berechnung
                ;
berechnung:       term '=' { printf("Ergebnis: %d\n", $1); }
                ;
term:             NUMBER
                | term '+' term { $$ = $1 + $3; }
                | term '-' term { $$ = $1 - $3; }
                | term '*' term { $$ = $1 * $3; }
                | term '/' term { $$ = $1 / $3; }
                | '(' term ')' { $$ = $2; }
                ;
%%
void yyerror(char *msg) {
    printf("\nEingabefehler: %s\n", msg);
}
int main() {
    return yyparse();
}
```


Übersetzungsschema: Beispiel (4)

- Variable `yylval`: Attributwert für Token
  - von lex gesetzt, von yacc gelesen
- semantische Aktionen in Programmiersprache C
- „$$“: Wert des Attributs des Nichtterminals auf der linken Seite
- „$1“: Wert des Attributs des Grammatiksymbols auf der rechten Seite ganz links
  - liegt auf Parser-Stack
- „$2: ... 2. Symbol von links ...

Verschiedene Typen für die Attributwerte

- Default: Attribute sind `int`
- aber Normalfall: Typen der Attribute verschieden
- Beispiel:
  Taschenrechner für Fließkommazahlen und Strings

Demo

Verschiedene Typen für die Attributwerte (2)

- calc-types.l

```
%{
#include <stdlib.h>
#include <math.h>
#include <string.h>
#include "calc-types.tab.h"
char *dequote(const char *);
%}
%option noyywrap
DIGIT    [0-9]
%%
{DIGIT}+("."{DIGIT}*)?  {
                        yylval.zahl = atof(yytext);
                        return NUMBER;
                        }
"\""[^"\n]*"\"" {
                        yylval.string = dequote(yytext);
                        return STRING;
                        }
"="                     |
"("                     |
")"                     |
"+"                     |
"-"                     |
"*"                     |
"/"                     { return *yytext; }
[[:space:]]             { /* ignoriere Whitespace */ }
.                       { return ILLEGAL_CHAR; }
%%
char *dequote(const char *s) {
    char *retVal;
    retVal = (char *) malloc(strlen(s)-2+1);
    strncpy(retVal, &(s[1]), strlen(s)-2);
    return retVal;
}
```


Verschiedene Typen für die Attributwerte (3)

- calc-types.y

```
%{
#include <stdio.h>
#include <stdlib.h>
#include <string.h>
#define YYERROR_VERBOSE
void yyerror(char *);
char *addString(const char *, const char *);
%}
%union {
    double zahl;
    char * string;
}
%token ILLEGAL_CHAR
%token <zahl> NUMBER
%token <string> STRING
%left '-' '+'
%left '*' '/'
%type <zahl> zahlTerm
%type <string> stringTerm
%%
eingabe:            /* empty */
                  | eingabe zahlBerechnung
                  | eingabe stringBerechnung
                  ;
zahlBerechnung:   zahlTerm '=' { printf("Ergebnis: %g\n", $1); }
                  ;
stringBerechnung: stringTerm '=' { printf("Ergebnis: \"%s\"\n", $1); }
                  ;
zahlTerm:           NUMBER
                  | zahlTerm '+' zahlTerm { $$ = $1 + $3; }
                  | zahlTerm '-' zahlTerm { $$ = $1 - $3; }
                  | zahlTerm '*' zahlTerm { $$ = $1 * $3; }
                  | zahlTerm '/' zahlTerm { $$ = $1 / $3; }
                  | '(' zahlTerm ')' { $$ = $2; }
                  ;
stringTerm:         STRING
                  | stringTerm '+' stringTerm { $$ = addString($1, $3); }
                  ;
%%
char *addString(const char *s1, const char *s2) {
    char *retVal;
    retVal = (char *) malloc(strlen(s1)+strlen(s2)+1);
    strcpy(retVal, s1);
    strcat(retVal, s2);
    return retVal;
}
void yyerror(char *msg) {
    printf("\nEingabefehler: %s\n", msg);
}
int main() {
    return yyparse();
}
```


Verschiedene Typen für die Attributwerte (4)

- %union
  - definiert alle mögliche Typen von Attributen
  - wie C-union
- Zugriff auf `yylval`
  - jetzt durch `yylval.xy`
    - auch in lex-Datei
- Zuordnung eines Typs zu Nichtterminal
  - %type <xy> meinNichtTerminal
- Zuordnung eines Typs zu Symbol
  - %token <xy> meinToken
- Alternative Typzuordnung: $<xy>$, $<xy>1, ...

Die Default-Aktion von yacc

- falls keine Aktion für eine Regel
- Default: „$$ = $1;“
  - nur, falls Typen zusammenpassen
  - nur, falls nicht leere Regel (kein „$1“)
- Implementation:
  - $1 und $$ haben ohnehin gleichen Platz auf Stack

Implizites Attribut für Position in der Eingabe

- Position von Symbolen/Nichtterminalen wichtig für Fehlermeldungen
- Beispiel:
  Taschenrechner für ganze Zahlen, erweitert
  - (nur sinnvoll, wenn er aus Datei liest)

Demo

Implizites Attribut für Position in der Eingabe (2)

- calc-int-loc.l

```
%{
#include <math.h>
#include "calc-int-loc.tab.h"
extern YYLTYPE yylloc;
#define YY_USER_INIT { \
    yylloc.first_line = 1; yylloc.first_column = 0; \
    yylloc.last_line = 1; yylloc.last_column = 0; \
}
#define YY_USER_ACTION { \
    yylloc.first_column = yylloc.last_column+1; \
    yylloc.last_column += yyleng; \
}
%}
%option noyywrap
DIGIT   [0-9]
%%
[DIGIT]+        {
                  yylval = atoi(yytext);
                  return NUMBER;
                }
"="             |
"("             |
")"             |
"+"             |
"-"             |
"*"             |
"/"             { return *yytext; }
[ \t]           { /* ignoriere Whitespace */ }
\n              {
                  /* ignoriere Whitespace, setze Position in nächste Zeile */
                  yylloc.first_line++;
                  yylloc.first_column = 0;
                  yylloc.last_line++;
                  yylloc.last_column = 0;
                }
.               { return ILLEGAL_CHAR; }
```


Implizites Attribut für Position in der Eingabe (3)

- calc-int-loc < calc-int-loc.txt
- lex muß yacc Position des Symbols mitteilen:
  Variable `yylloc`
  - von yacc definiert, falls „@$“, ... (s.u.) verwendet
  - Default: 4 Felder, wie angegeben
- Makro YY_USER_INIT bei Initialisierung von Lexer ausgeführt
- Makro YY_USER_ACTION vor jeder Lexer-Aktion ausgeführt
- Newline muß Position auf nächste Zeile setzen

Implizites Attribut für Position in der Eingabe (4)

- calc-int-loc.y

```
%{
#include <stdio.h>
#define YYERROR_VERBOSE
void yyerror(char *);
%}
%token NUMBER ILLEGAL_CHAR
%left '-' '+'
%left '*' '/'
%%
eingabe:          /* empty */
                | eingabe berechnung
                ;
berechnung:       term '=' { printf("Ergebnis: %d\n", $1); }
                | error '='
                ;
term:             NUMBER { $$ = @1; }
                | term '+' term { $$ = $1 + $3; }
                | term '-' term { $$ = $1 - $3; }
                | term '*' term { $$ = $1 * $3; }
                | term '/' term
                  {
                    if ($3) {
                      $$ = $1 / $3;
                    }
                    else {
                      $$ = 0;
                      printf("\nIm Bereich %d(%d)-%d(%d): ",
                          @3.first_line, @3.first_column,
                          @3.last_line, @3.last_column
                      );
                      printf("Division durch Null\n");
                      YYERROR;
                    };
                  }
                | '(' term ')' { $$ = $2; }
                ;
%%
void yyerror(char *msg) {
      printf("\nAn Position %d(%d): ",
          yylloc.first_line, yylloc.first_column
    );
    printf("%s\n", msg);
}
int main() {
    return yyparse();
}
```


Implizites Attribut für Position in der Eingabe (5)

- „@$“, ... muß mind. einmal verwendet sein, damit yylloc existiert
  - notfalls irgendwo redundante Aktion mit Zuweisung „@$ = @1“
    - wie hier hinter „NUMBER“
  - „@1“: Position des ersten Grammatiksymbols
  - „@$“ Position des Nichterminals für ganze Regel
- Zugriff:
  - in Aktion mit „@1“, ...
  - in yyerror() nur auf Eingabeposition in yylloc

Implizites Attribut für Position in der Eingabe (6)

- Default-Aktion für Eingabeposition:
  - „@$“: erstes Zeichen von „@1“ bis letztes Zeichen des letzten Symbols
    - Beispiel: Division durch Null, Klammerausdruck im Nenner
- Makro YYERROR: löst Syntaxfehler aus
  - abgefangen durch *error*-Regel für *berechnung*

Übersetzungsschema mit semantischen Aktionen in der Mitte

- bekanntes Beispiel: Variablendeklaration in C
  - „`int i, j, k`“ und „`real i, j, k`“
    - hier nur zwei Typen

Demo

Übersetzungsschema mit semantischen Aktionen in der Mitte (2)

- typedecl-glob.l

```
%{
#include <string.h>
#include "typedecl-glob.tab.h"
%}
%option noyywrap
IDENT    [[:alpha:]_]+
%%
"int"            { return INT; }
"real"           { return REAL; }
{IDENT}          {
                   yylval.name = strdup(yytext);
                   return ID;
                 }
","              { return *yytext; }
[[:space:]]      { /* ignoriere Whitespace */ }
.                { return ILLEGAL_CHAR; }
```


Übersetzungsschema mit semantischen Aktionen in der Mitte (3)

- typedecl-glob.y

```
%{
#include <stdio.h>
#define YYERROR_VERBOSE
void yyerror(char *);
void addtype(char *, int);
#define T_INT   0
#define T_REAL  1
int curr_type;
%}
%union {
    int    idType;
    char * name;
}
%token INT REAL ID ILLEGAL_CHAR
%type <name> ID
%type <idType> type
%verbose
%%
def:              type { curr_type = $1; } list
                  ;
type:             INT { $$ = T_INT; }
                  | REAL { $$ = T_REAL; }
                  ;
list:             list ',' ID { addtype($3, curr_type); }
                  | ID { addtype($1, curr_type); }
                  ;
%%
void addtype(char *id, int type) {
    printf("Adding type %s for id '%s'\n", (type ? "REAL" : "INT"), id);
}
void yyerror(char *msg) {
    printf("\n%s\n", msg);
}
int main() {
    return yyparse();
}
```


Übersetzungsschema mit semantischen Aktionen in der Mitte (4)

- *keine* ererbten Attribute verwendet
  - stattdessen Kommunikation über globale Variable
  - Problem: geht nicht rekursiv
    - *hier* aber OK

Aufsteigende Auswertung ererbter Attribute

- Problem: Erben abwärts, Auswertung aufwärts
- (meist) Lösung: L-attributierte Definitionen
- hinreichende Regeln für semantische Aktionen:
  1. ererbtes Attribut für b_j bereits links davon berechnet
  2. kein Zugriff auf synthetisierte Attribute weiter rechts
     - läßt yacc sowieso nicht zu
  3. synthetisiertes Attribut für *a* erst ganz rechts berechnet

Problem mit eingebetteten Aktionen in Übersetzungsschemata

- Parser reduziert, wenn ganze Regel gelesen
- aber: eingebettete Aktion kommt vorher
- Lösung: Transformation der Grammatik: Entfernen eingebetter Aktionen
  - yacc macht es intern automatisch

Entfernen eingebetteter Aktionen aus Übersetzungsschemata

- Transformation der Grammatik
- führe für jede eingebettete Aktion i ein neues Markierungsnichtterminal m_i ein und eine Regel $m_i \rightarrow \varepsilon$
- füge m_i an die Stelle der Aktion ein und verschiebe die Aktion ans Ende der neuen Regel

Demo

Entfernen eingebetteter Aktionen aus Übersetzungsschemata (2)

- siehe typedecl-glob.output
- Problem: neue Regel kann evtl. Konflikt erzeugen, weil sie früher reduziert

Erben von Attributen auf dem Parser-Stack

- eine Implementierung des Erbens von Attributen
  - erfüllt automatisch die Bedingungen für L-attributierte Definitionen
  - yacc macht es so
- Idee: die bisher berechneten Attribute für die aktuelle Regel liegen alle im Parser-Stack
  - Zugriff durch geeignete Indizierung
    - Attribut des Grammatiksymbols direkt links von der Aktion liegt ganz oben

Demo

Erben von Attributen auf dem Parser-Stack (2)

- typedecl.y

```
%{
#include <stdio.h>
#define YYERROR_VERBOSE
void yyerror(char *);
void addtype(char *, int);
#define T_INT   0
#define T_REAL  1
%}
%union {
    int     idType;
    char * name;
}
%token INT REAL ID ILLEGAL_CHAR
%type <name> ID
%type <idType> type
%verbose
%%
def:              type { $<idType>$ = $1; } list
                  ;
type:             INT { $$ = T_INT; }
                  | REAL { $$ = T_REAL; }
                  ;
list:             list ',' ID { addtype($3, $<idType>0); }
                  | ID { addtype($1, $<idType>0); }
                  ;
%%
void addtype(char *id, int type) {
    printf("Adding type %s for id '%s'\n", (type ? "REAL" : "INT"), id);
}
void yyerror(char *msg) {
    printf("\n%s\n", msg);
}
int main() {
    return yyparse();
}
```


Erben von Attributen auf dem Parser-Stack (3)

- yacc:
  - „$0“: oberster Wert auf Parser-Stack
    - „$-1“: zweitoberster Wert, ...
  - „$$“ in eingebetteter Regel:
    - andere Bedeutung:
    - Wert für diese Aktion, nicht für die ganze Regel
    - $<idType>$: explizite Typangabe nötig, da unbenannt
- Vorsicht:
  Bei jedem Reduzieren von *list* muß das Richtige auf Stack sein!
  - Aktion „$$ = $1“ hier redundant, aber ggf. sicherer
  - alle Verwendungen von *list* prüfen!

Inhalte der Vorlesung

1. Einführung
2. Lexikalische Analyse
3. Der Textstrom-Editor sed
4. Der Scanner-Generator lex (2 Termine)
5. Syntaxanalyse und der Parser-Generator yacc (3 T.)
6. Syntaxgesteuerte Übersetzung
7. Übersetzungssteuerung mit make