Wiederholung

Inhalte der Vorlesung

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

1. Einführung

Die Phasen der Übersetzung

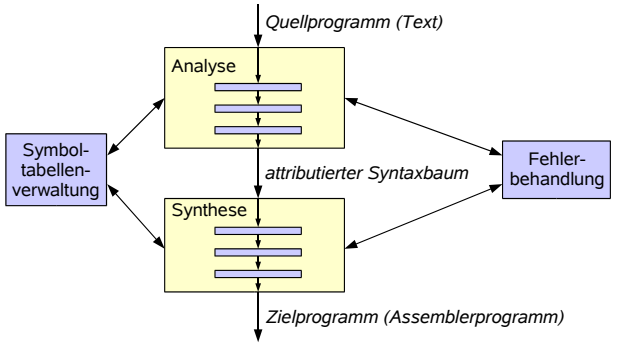

Die Analysephasen

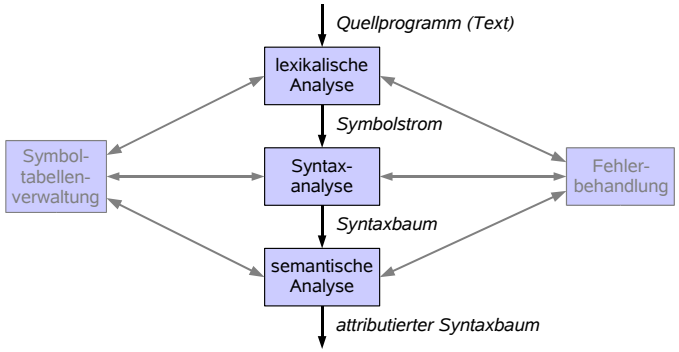

Die Synthesephasen

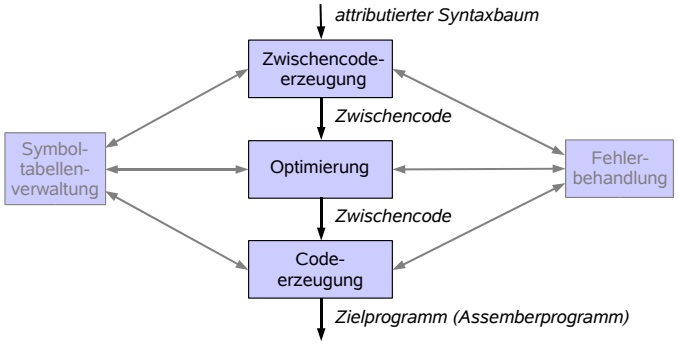

2. Lexikalische Analyse

Lexikalische Analyse

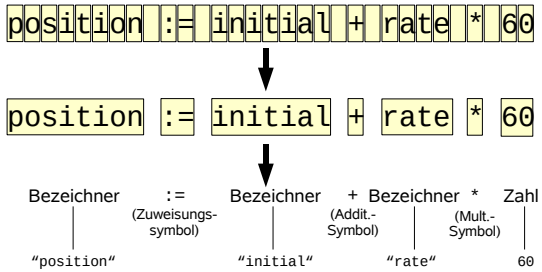

- Gruppierung der Eingabezeichen in Lexeme
  - Leerzeichen werden entfernt
- Zuordnung Lexem → Symbol
  - Symbole (Token): Bezeichner, :=, +, *, Zahl, ...
  - Symbol hat z.T. Wert als Attribut

Äquivalenz regulärer Ausdrücke und endlicher Automaten

- die Sprache jedes regulären Ausdrucks kann von einem endlichen Automaten erkannt werden
  - auch Umkehrung gilt:
    die Sprache eines endlichen Automaten kann mit einem regulären Ausdruck beschrieben werden
  - Automat: im allgemeinen nicht deterministisch
- jeder nichtdeterministische endliche Automat kann in einen deterministischen übersetzt werden
- Folgerung:
  für jeden regulären Ausdruck kann *automatisch* ein *effizienter* erkennender Automat erzeugt werden

Einfügen und Suchen von Bezeichnern

- Bezeichner werden als Zahl verschlüsselt
  - effizienter Gleichheitstest
  - Abbildungen als Felder implementierbar
    - effizient
- Verfahren: Streuspeicher (Hashing)
  - Tabelleneinträge willkürlich, aber deterministisch und möglichst gleichmäßig in „Eimer“ verteilen
  - Standardverfahren
    - siehe Standard-C-Library: `hcreate()`, `hsearch()`
    - siehe Vorlesung „Praktische Informatik 2“
    - siehe Drachenbuch, Kap 7.6

3. Der Textstrom-Editor sed

Einfache typische Anwendungen

- kleine Textmodifikation
  - Betreff in Vacation-Text einsetzen
- Formatierung einer Liste etwas ändern
  - festes Präfix in einer Dateiliste entfernen

Die Grundkommandos von sed

- **Syntax:**
  sed *[–**e** Editierkommando] [–**f** Scriptdatei] [–**n**] [Datei ...]*
- **Editierkommando:**
  Adresse Funktion
- **Funktion:**
  s/*Ausdruck*/*Ersetzung*/[**g**][**p**]
  d
  !*Funktion*

  (substitute) – ersetzt auf Ausdruck passenden Text
  (delete) – löscht aktuelle Zeile, nichts wird gedruckt
  (not) – führt Funktion aus, falls Adresse nicht paßt
- **Adresse:**
  (leer)
  /*Ausdruck*/
- **Ausdruck:**
  ein regulärer Ausdruck wie bei grep
- **Modus:**
  g (global) ersetzt alle passenden Texte, nicht nur den ersten
  p (print) falls Ersetzung stattgefunden hat, drucke Zeile (trotz Option –**n**)

Typische Anwendungen von regulären Ausdrücken

- variable Textanteile erkennen
  - variables Präfix in einer Dateiliste entfernen
- interessante Textanteile extrahieren
  - Liste aller Benutzer aus /etc/passwd extrahieren
  - Liste aller „echten“ Benutzer aus /etc/passwd extrahieren

4. Der Scanner-Generator lex

Aufbau einer lex-Datei

Definitionen
%%
Regeln
%%
Unterprogramme } optional

Einsetzen des Benutzernamens: Lösung

- username.l:

```
%{
#include <stdio.h>
#include <stdlib.h>
%}
%option main
%%
"<username>"  printf("%s", getenv("USER"));
```

  - Regel: vorne Muster, hinten Aktion
  - Default-Regel: druckt aktuelles Zeichen
  - Definitionen:
    - C-Definitionen in `%{`, `%}`
    - lex-Option hinter `%option`

Kommunikation mit einem Parser

- Unterbrechung der Scan-Schleife:
  `return` *n*`;`
  - Nummer des Symbols in *n*
  - weitere Informationen in globalen Variablen (`yytext`, ...)
- Fortsetzung der Scan-Schleife:
  `yylex();`
- Symbolnummern in gemeinsamer Header-Datei

5. Syntaxanalyse und der Parser-Generator yacc

Spezifikation kontextfreier Grammatiken mit BNF

- Backus-Naur-Form:
  Notation für kontextfreie Grammatiken
- Regeln geschrieben als
  a ::= ...
- Terminale in Anführungszeichen: '+'
- Verkettung durch Hintereinanderschreiben

Erweiterung zu EBNF

- zusätzlich Abkürzungen:
  - Alternative: Regeln mit gleichem Nichtterminal links zusammengefaßt als
    a ::= ... | ... | ...
  - [...]: Option, null- oder einmal
  - {...}: Wiederholung, null- bis beliebig mal
  - (...): Klammerung

Mehrdeutigkeit: Beispiel

- erste Linksableitung
  - e ⇒ *e* + *e*
    ⇒ *e* ∗ *e* + *e*
    ⇒ ID ∗ *e* + *e*
    ⇒ ID ∗ ID + *e*
    ⇒ ID ∗ ID + ID

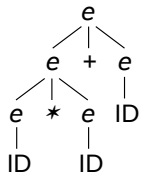

- zweite Linksableitung
  - e ⇒ *e* ∗ *e*
    ⇒ ID ∗ *e*
    ⇒ ID ∗ *e* + *e*
    ⇒ ID ∗ ID + *e*
    ⇒ ID ∗ ID + ID

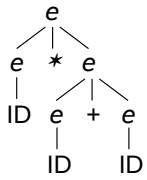

Aufbau einer yacc-Datei

Definitionen
%%
Regeln
%%
Unterprogramme

} optional

Demo

Der kadonische Leuchtturm: Lösung

- leuchtturm.y:

```
%{
#include <stdio.h>
void yyerror(char *);
%}
%token ROT WEISS SCHREIBFEHLER
%%
kadonischerturm:  helfer helfer helfer helfer
                  ;
helfer:           mann
                  | frau
                  ;
mann:             ROT WEISS ROT
                  ;
frau:             WEISS ROT WEISS
                  ;
%%
void yyerror(char *msg) {
}
int main() {
    printf("Wie sieht der Leuchtturm aus, Sir? ");
    if(yyparse() == 0)
        printf("Wir liegen vor der Insel Kadonien, Sir!\n");
    else
        printf("Wir liegen *nicht* vor der Insel Kadonien, Sir!\n");
    return 0;
}
```

Absteigende Analyse versus aufsteigende Analyse

- Absteigende Analyse (top-down-Analyse)
  - Knoten des Ableitungsbaums werden von der Wurzel her konstruiert
  - leichter von Hand zu programmieren
    - „Praktische Informatik 2“
- Aufsteigende Analyse (bottom-up-Analyse)
  - Knoten des Ableitungsbaums werden von den Blättern her konstruiert
  - größere Klasse von Grammatiken
    - seltener Grammatiktransformation von Hand nötig
  - yacc

Prinzip der aufsteigenden Analyse

- „reduzieren“ des Eingabeworts auf das Startsymbol
  - Reduktionsschritt:
    - wenn: ein Teilwort = rechte Seite einer Regel
    - ersetze Teilwort durch Symbol auf linker Seite
  - richtige Wahl des Teilworts nötig
  - liefert Rechtsableitung in umgekehrter Reihenfolge
  - Name auch: „shift-reduce-Syntaxanalyse“

Implementierung der aufsteigenden Analyse mit einem Stack

- Idee:
  - lies jeweils ein Zeichen und packe es oben auf den Stack
  - wenn ein passendes Muster im Stack steht, wende eine Grammatikregel rückwärts an
  - Stack:
    - repräsentiert die bisher gelesene Eingabe
    - bereits erkannte Teile sind zu Nichtterminalen verdichtet

Stack-Implementierung: Beispiel

Stack	Eingabe
	ABBCDE
A	BBCDE
AB	BCDE
A*a*	BCDE
A*a*B	CDE
A*a*BC	DE
A*a*	DE
A*a*D	E
A*ab*	E
A*ab*E	
s	

Grundoperationen eines Shift-Reduce-Parsers

1. schieben (shift)
   - nächstes Eingabesymbol → Stack
2. reduzieren (reduce)
   - Stack: oberste Symbole → Nichtterminal
3. akzeptieren
4. Fehler melden

- Satz:
  Beim Reduzieren reicht es, nur die obersten Symbole auf dem Stack zu betrachten
  - Beweis: Drachenbuch

LR-Parser

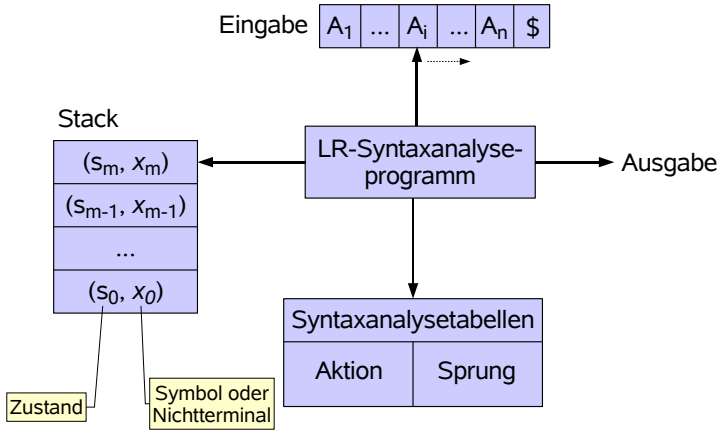

Typische Konflikte

- mehrdeutige Grammatik
  - Konflikt in Ausdrücken
  - Konflikt in if-then-else
  - Konflikt in verschachtelten Listen
  - Konflikt in überlappenden Alternativen
- Nicht-LALR(1)-Grammatik
  - Konflikt wegen begrenzter Vorschau
  - Konflikt wegen Nicht-LALR-Grammatik

Präzedenzen: Idee

- manchmal umständlich:
  Grammatik eindeutig bzw. LALR(1) machen
  - Beispiel: Ausdrücke
- Alternative:
  Konflikt bleibt in Grammatik,
  aber Parser nimmt immer „richtige“ Wahl
  - explizit definieren,
    welche Wahl „richtig“ ist:
    Präzedenz

Behandlung von Syntaxfehlern

- schlecht:
  - Abbruch bei erstem Fehler
- besser:
  - fehlerhafte Stelle überspringen
  - Analyse wieder aufsetzen
  - nach weiteren Fehlern suchen
- Annahme:
  - es gibt Stellen, wo die Analyse wieder aufsetzen kann
    - Beispiel: Semikolon (Ende einer Anweisung)
      - nur Heuristik

6. Syntaxgesteuerte Übersetzung

Attributierter Syntaxbaum

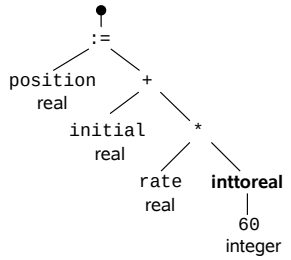

- Knoten mit Werten
  - Wert: durch Semantikregel des Knotens
- Semantikregel mit Seitenwirkungen möglich
  - Ausgabe
  - globale Variable verändern

Konstruktion expliziter Syntaxbäume

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

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

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

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

Demo

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();
}
```

7. Übersetzungssteuerung mit make

Motivation

Beispiel: Übersetzung eines kleinen Editors

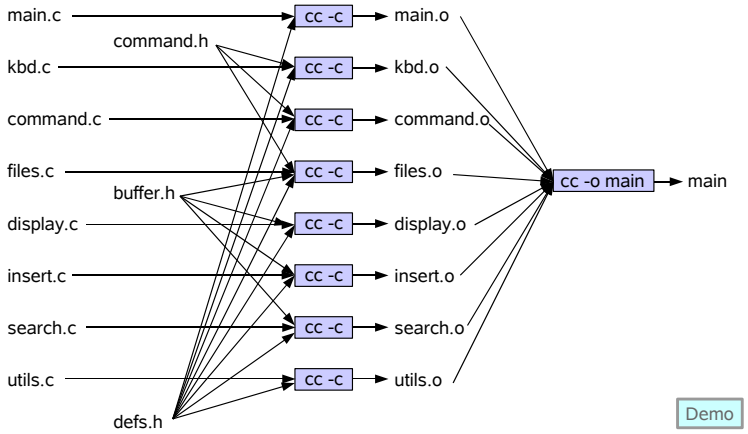

Grundlagen von Makefiles

- editor-simple/Makefile

```
# Makefile for "edit".

edit : main.o kbd.o command.o display.o \
       insert.o search.o files.o utils.o
        cc -o edit main.o kbd.o command.o display.o \
                   insert.o search.o files.o utils.o

main.o : main.c defs.h
        cc -c main.c
kbd.o : kbd.c defs.h command.h
        cc -c kbd.c
command.o : command.c defs.h command.h
        cc -c command.c
display.o : display.c defs.h buffer.h
        cc -c display.c
insert.o : insert.c defs.h buffer.h
        cc -c insert.c
search.o : search.c defs.h buffer.h
        cc -c search.c
files.o : files.c defs.h buffer.h command.h
        cc -c files.c
utils.o : utils.c defs.h
        cc -c utils.c
clean :
        rm edit main.o kbd.o command.o display.o \
        insert.o search.o files.o utils.o
```


Algorithmus von make

- Aufruf: `make`
- Vorgehen von make:
  - Default-Ziel: erstes Ziel
    - hier: `edit`
  - Analyse der Abhängigkeiten
    - edit hängt von 8 Objekt-Dateien ab
    - rekursiv weitere Abhängigkeiten
    - schließlich existierende Dateien ohne Regeln
  - Sortieren der Abhängigkeiten
  - Ausführen

Inhalte der Vorlesung

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