Fordítóprogramok

Fordítóprogramok

és formális nyelvek I.

Szerkesztette : Király Roland

2007

Fordítóprogram szerkezete

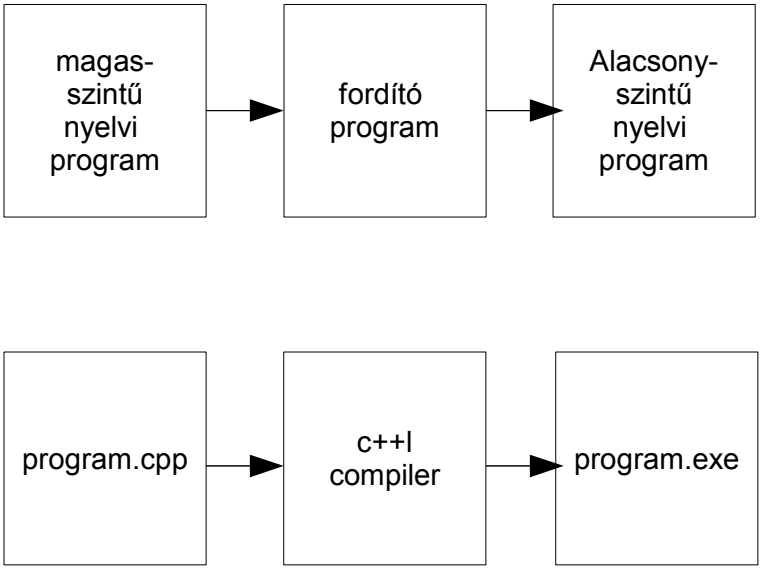

- A fordítóprogramok általánosan forrásnyelvi szövegből állítanak elő tárgykódot.
- A fordítóprogramok feladata, hogy nyelvek közti konverziót hajtsanak végre.
- A fordítóprogram a forrásprogram beolvasása után elvégzi a lexikális, szintaktikus és szemantikus elemzést, előállítja a szintaxis fát, generálja, majd optimalizálja a tárgykódot.

Compiler és Interpreter

- A compiler magas szintű, forrásnyelvi szöveget, más néven forráskódot transzformál alacsony szintű nyelvre, legtöbbször assembly, vagy gépi kódra.
    - input-handler(forráskód) -> hibák, karaktersorozat
    - compiler(karaktersorozat) -> tárgykód
    - code-handler(tárgykód) -> tárgyprogram
- Az interpreter hardveres, vagy virtuális gép, mely értelmezni képes a magas szintű nyelvet, vagyis melynek gépi kódja a magasszintű nyelv. Ez egy kétszintű gép, melynek az alsó szintje a hardver, a felső az értelmező és futtató rendszer programja.
- Fordítási idő: azt az időt mely alatt a compiler elvégzi a transzformációt, fordítási időnek nevezzük.
- Futási idő: azt az időt, mely alatt a lefordított programot végrehajtjuk, futási, vagy futtatási időnek nevezzük.
- Az interpreter esetében a fordítási és a futási idő egybe esik, amíg a compiler esetén a két időpont jól elkülöníthető.

Fordító (compiler) felépítése

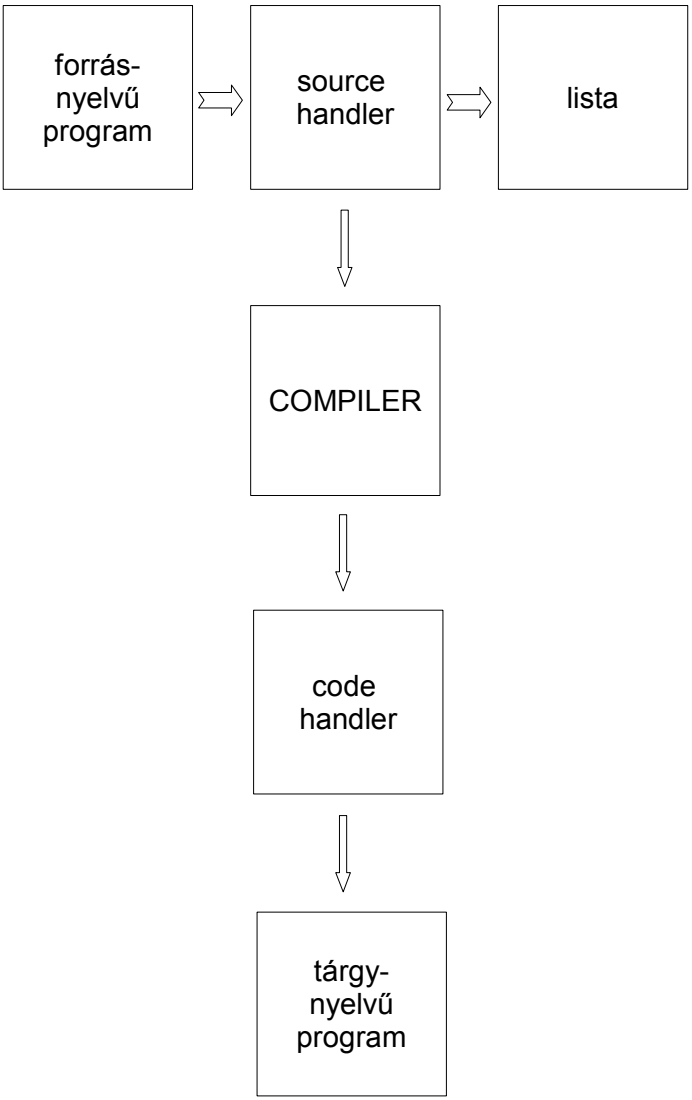

T diagramm

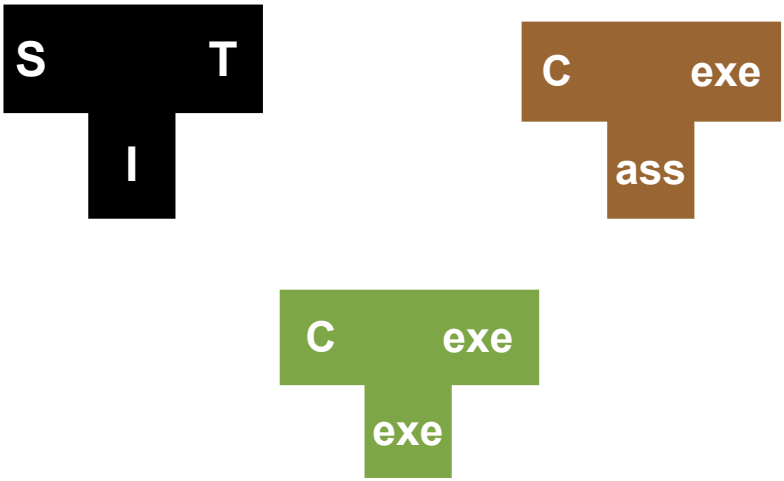

•A fordítóprogramokat három nyelvvel jellemezhetjük.
•Implementáció nyelve, **I** melyen a fordítóprogramot írták. Lehetőleg magasszintű nyelv.
•Forrásnyelv **S** amit a program lefordít.
•Tárgynyelv **T**, melyre a forrásnyelvből fordít .

A C - exe fordítóprogram

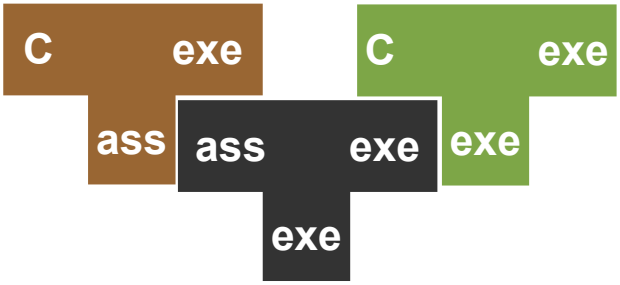

- A T diagramok azon pontokon illeszthetőek egymáshoz, ahol a diagramban azonos nyelvet találunk.
- Az első diagram egy assembly nyelven írt C-exe fordító.
- A második exe végrehajtható kódú ass – exe assembler.
- Ezekből előállítható egy végrehajtható C – exe fordítóprogram

Input handler (source handler)

- Az input-handler a forrásnyelvi szöveget beolvassa, majd az új sor és a kocsi vissza karaktereket levágja a sorok végéről.
- Sok esetben ez a program a lexikális elemző részeként van implementálva.
- Az input-handler nem végez szemantikai és szintaktikai ellenőrzést, ezt a feladatot a lexikális elemző végzi.
- Az input-handler kimenete a lexikális elemző bemenete.
- A szintaktikusan és szemantikusan ellenőrzött és helyes kódból a fordítóprogram tárgykódot állít elő. Ezt a feladatot az output-handler végzi.
- Ha az input és output handlert egy programban implementálják, akkor ezt a programot source-handlernek nevezzük.

Input handler implementációja

```
class handler
  {
      public string sourceHandler(string source)
      {
            string S="";
            System.IO.StreamReader Stream = new
            System.IO.StreamReader
            (
                  System.IO.File.OpenRead(source)
            );

            while (Stream.Peek() > -1)
            {
                  S += Stream.ReadLine();
            }
            return S;
      }
  }
```

Reguláris kifejezések

Jelöljön D egy tetszőleges számjegyet és L egy tetszőleges karaktert, a whitespace karaktereket a nevükkel helyettesítjük *{eol, eof, space}*.

D ∈ {0, 1, 2, ... , 9} , L ∈ {a, b, ..., z, A, B, ..., Z},

ekkor:

1) Egész számok:

(+ | - | ε)D+

2) Pozitív egész és valós számok:

(D+ (ε | .))| (D* .D+)

3) Egyszerű azonosító szimbólum:

L(L | D)*

4) Azonosító szimbólum:

L((_ | ε)(D | L)*

5) // -el határolt komment:

//(Not(eol))* eol

6) ## -al határolt komment:

##((# | ε) Not(#))*##

7) Karakter sztring:

“(Not(“) | “ ”)* “

8) Kitevős valós szám:

(+| -| ε)D+.D+(E(+| -| ε)D+ | ε)

Reguláris kifejezések felismerése

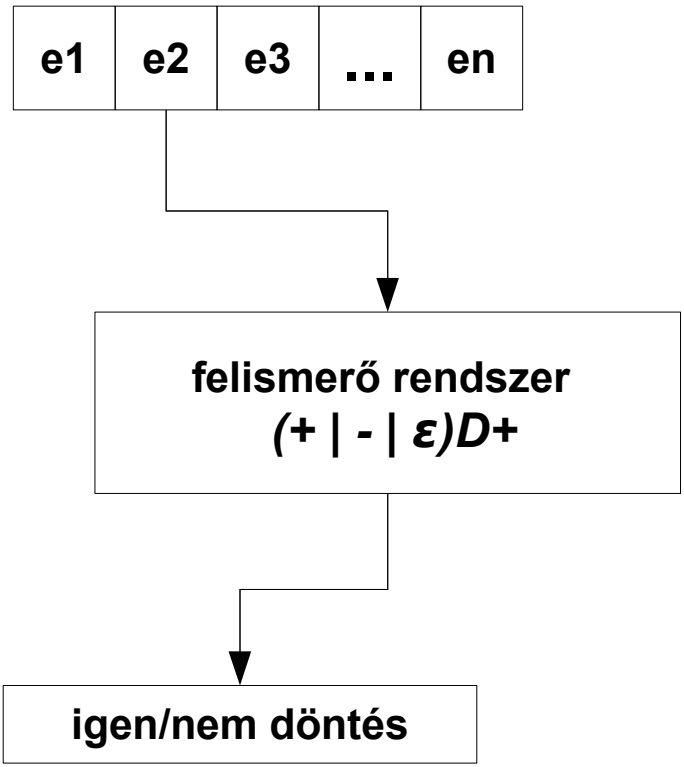

- A döntéshozó rendszer, vagyis az automata eldönti, hogy az input szalagon lévő sorozat a nyelvnek eleme, vagy sem.

Determinisztikus-véges automaták

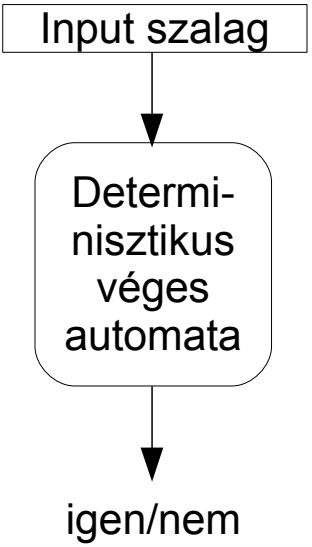

(+ | - | ε)D+

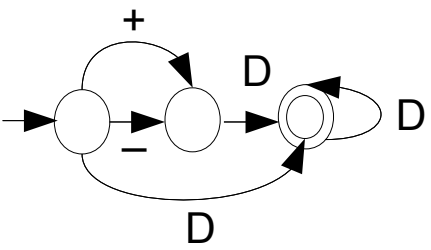

- Reguláris kifejezésekhez determinisztikus véges automata konstruálható.
- Az automata implementációja állapotai és az állapot átmenetek magasszintű programozási nyelveken jól implementálhatóak.

Kifejezésekhez konstruált automaták I.

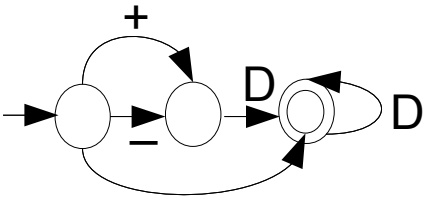

(+ | - | ε)D+

A = (**Q, ∑, E, I, F**)

véges automata, ahol

Q - a belső állapotok halmaza
∑ - az input ABC
E - az átmenetek halmaza
I - a kezdőállapot (halmaz)
F - végállapot (halmaz)

∑ = *{+, -, D+}.*
Q = *{q0, q1, q2},*
E = *(q0, +, q1), (q0, -, q1), (q0, ?, q2),*
(q1, D, q2),
(q2, D, q2),
I = *{q2},*
F = *{q0}*

Kifejezésekhez konstruált automaták II.

A = (**Q, ∑, E, I, F**)

A terminális jelek = {0, 1, 2}.
Az állapotok = {q0, q1, q2},
E = (q0, 0, q1), (q0, 1, q1), (q0, 2, q2),
(q1, 0, q1), (q1, 1, q2), (q1, 2, q0),
(q2, 0, q2), (q2, 1, q0), (q2, 2, q1),
Kezdő állapot = {q0},
Elfogadó végállapot = {q0}

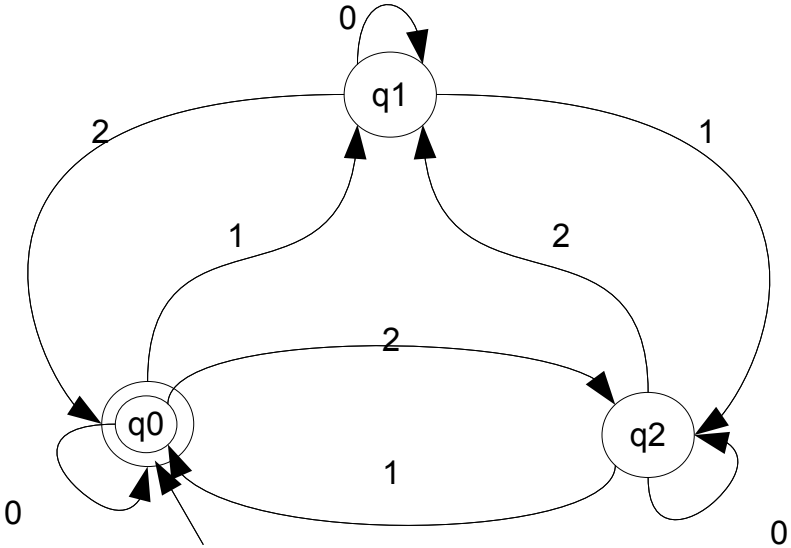

Automata Implementációja

```
public string analyst(string grammar)
{
   string STATE="q0";
   string OK="OK";
   int i=0;
    while (i < grammar.Length &&
              STATE !="error")
   {
     STATE=transition(STATE,grammar[i]);
     ++i;
   }
   if (i<grammar.Length)
   {
     OK= "A hiba pozíciója"
     +i.ToString()+". "+grammar[i]
     +" nem eleme a nyelvnek";
   }
   return OK;
 }
}
```

- Elemző program implementációjához érdemes magasszintű nyelveket használni.
- Az elemző programja determinisztikus véges automata. melynek állapotait switch ágaival, vagy állapotátmenet függvényekkel valósítjuk meg.

Állapotátmenet függvény

```
string transition(string state, char char_)
    {
        string nstate;
        switch (state+char_)
        {
            case "q00":nstate="q0";break;
            case "q01":nstate="q1";break;
            case "q02":nstate="q2";break;
            case "q10":nstate="q1";break;
            case "q11":nstate="q2";break;
            case "q12":nstate="q0";break;
            case "q20":nstate="q2";break;
            case "q21":nstate="q0";break;
            case "q22":nstate="q1";break;
            default:nstate="error";break;
        }
        return nstate;
       }
```

•Az automata állapotait a switch ágaival valósítjuk meg. Minden egyes case ág az automata egy állapotátmenetét írja le.
•Az állapotátmenet függvény bemenő paramétere az aktuális állapot és az un.: input szalag következő karaktere.

Fordítóprogramok

Fordítóprogramok

és formális nyelvek II.

Szerkesztette : Király Roland

2007

Lexikális elemző

- A lexikális elemző inputja a source handler outputja, vagyis egy karaktersorozat, mely az új sor és a kocsi vissza karakterek kivételével mindent tartalmaz a forráskódból.
- A lexikális elemző reguláris, vagyis Chomsky 3-as nyelvet használ.
- Feladata a felismerni az adott nyelv lexikális elemeit, majd helyettesíteni azokat a Szintaktikus elemző számára érthető jelekkel.
- A lexikális elemző outputja a szintaktikus elemző inputja lesz és egy hibalista a lexikális hibákról.

- Az egyes nyelvi elemeket leírjuk reguláris kifejezésekkel és megalkotjuk az ekvivalens determinisztikus – véges automatát.
- Elkészítjük az automata implementációját.
- (Az automata implementációja magasszintű nyelveken egyszerűen a switch, vagy csae nyelvi elem felhasználásával kivitelezhető. Az állapotok a switch egyes ágai...)

Lexikális elemző működése

If a > 0 then x:= a else x:=0

- A fenti programszövegből a lexikális elemző az alábbi kimenetet készíti el, mely már teljesen olvashatatlan.

10	if
20	then
30	else
40	:=
50	>

10 001 50 002 20 003 40 001 30 003 40 0004

- A használt változókhoz, konstansokhoz, stb... az un.: szimbólumtábla bejegyzések tartoznak, melyben tárolható a változók azonosítójához tartozó érték, típus és egyéb attribútumok.
- A szimbólumtáblát legtöbbször láncolt listával valósítják meg.
- A szimbólumtábla bejegyzéseit a szemantikus elemző használja fel.
- A lexikális elemző felhasználható forrásnyelvi programok más nyelvekre való konvertálására is.

Szimbólum tábla

- A szimbólumtábla olyan táblázat, mely tartalmazza a programszövegben előforduló szimbólumok nevét és jellemzőit, vagyis az attribútumokat.
- Ezek az információk a lexikális és szintaktikus elemző számára nem lényegesek, de a szemantikus elemzés és a kódgenerálás számára elengedhetetlenek.
- A szimbólum minden egyes előfordulása esetén a a táblában keresést, vagy beszúrást kell végezni. Összesen ez a két művelete van.
- Szimbólumtábla egy sorának a tartalma:

  - Szimbólum neve
  - Attribútumok
    - definíciós adatok
    - típus
    - programbeli cím (tárgyprogram)
    - forrásnyelvi sorszám
    - hivatkozott sorszám
    - láncolási cím

Szimbólumtábla

- Definíciós adatok, típus:
  - Mit azonosít a szimbólum, Pl.: változó, konstans, stb. Konstansnál az értek, típusnál a típusdescriptorra mutató pointer, eljárásnál annak paraméterei, azok száma.

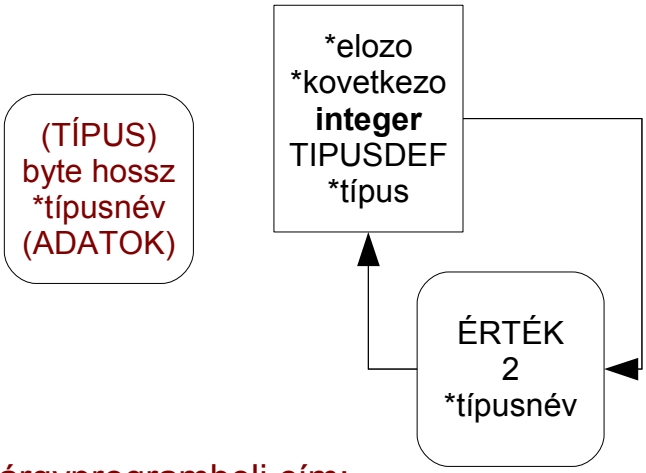

- Tárgyprogrambeli cím:
  - ezt a címet kell a tárgyprogramba beépíteni a szimbólumra való hivatkozáskor.
- Definíció sorszáma:
  - explicit definíciónál a definíció sora, implicitnél az első előfordulás
- Hivatkozott sorszám ,láncolási cím
  - a hivatkozási lista elkészítéséhez

Szimbólumtábla implementációja

```
struct symrec
{
  char *name; /* szimbólum neve */
  struct symrec *next; /* mutató mező */
};

typedef struct symrec symrec;
symrec *sym_table = (symrec *)0;
symrec *put ();
symrec *get ();
```

- A fenti szimbólumtábla implementációja láncolt listával történik. Csak a szimbólum nevét tartalmazza, attribútumokat nem.
- A tábla két művelete:
  - beszúrás – put(), mely nemlétező szimbólum esetén beszúrja azt a táblába, majd visszatér a címével. Létező szimbólum esetén is a címével tér vissza.
  - kivét – get(), mely visszatér a szimbólum címével, vagy a 0 értékkel nemlétező szimbólum esetén.

Szimbólumtábla műveletei

- put a szimbólumok elhelyezésére a listában

```
symrec *put ( char *sym_name )
{
  symrec *ptr;
  ptr = (symrec *) malloc (sizeof(symrec));
  ptr− >name =
          (char *) malloc (strlen(sym_name)+1);
  strcpy (ptr− >name,sym name);
  ptr− >next = (struct symrec *)sym_table;
  sym_table = ptr;
  return ptr;
}
```

- get a szimbólum ellenőrzéséhez a hivatkozások esetén

```
symrec * get ( char *sym name )
{
  symrec *ptr;
  for (ptr = sym table; ptr != (symrec *) 0;
  ptr = (symrec *)ptr− >next)
  if (strcmp (ptr− >name,sym name) == 0)
    return ptr;
  return 0;
}
```

Fordítóprogramok

Programnyelvek konvertálása

Szintaxis

program :
változó ***<deklaráció>*** kezd ***<parancsok>*** vége;

deklaráció: típus ***<azonosító_lista>,*** azonosító;

azonosító_lista:
azonosító | azonosító_lista;

parancslista:
| parancslista ***<parancs>***;
parancs: üres_utasítás
| beolvas azonosító
| kiír kifejezés
| azonosító := kifejezés
| ha kifejezés akkor parancsok különben
parancsok vége
| ciklus ***<kifejezés>*** elvégez parancsok vége;

kifejezés: szám | azonosító
| kifejezés < kifejezés
| kifejezés = kifejezés
| kifejezés > kifejezés
| kifejezés + kifejezés
| kifejezés – kifejezés
| kifejezés * kifejezés
| kifejezés / kifejezés
| kifejezés ^ kifejezés | (kifejezés)

Az azonosító és a szám, leírható meta karakterekkel...

BNF

```
program
   ::= LET [ declarations ] IN command sequence
END

declarations ::= INTEGER [ id seq ] IDENTIFIER .
id seq ::= id seq... IDENTIFIER ,
command sequence ::= command... command
command ::= SKIP ;
          | IDENTIFIER := expression ;
          | IF exp THEN command sequence
                    ELSE command sequence FI
          | WHILE exp
                    DO command sequence END ;
          | READ IDENTIFIER ;
          | WRITE expression ;

expression ::=
           NUMBER | IDENTIFIER
           | '(' expression ')'
           | expression + expression
           | expression − expression
           | expression * expression
           | expression / expression
           | expression ^ expression
           | expression = expression
           | expression < expression
           | expression > expression
```

Lex és Yacc

A LEX reguláris kifejezések formális leírásából hozza létre egy determinisztikus véges automata implementációját. Valójában lexikális elemző programot generál (C kódot állít elő).

Mintákat használ, hogy tokeneket készítsen az input stringből.

A token a string számszerű reprezentációja, mely megkönnyíti a feldolgozást.

A YACC C kódot generál a szintaktikus elemzőhöz. Nyelvtani szabályokat használ a lex tokenjeinek elemzéséhez és a szintaxisfa felépítéséhez.

A felépített szintaxisfa segítségével kódot generálhatunk, mely virtuális gépen, vagy a számítógép hardverén futtatható.

lexer lexikális elemző	Parser szintaktikus elemző

Szintaxis fa

a = b + c * d

A szintaxis-fa a forrásszövegből, több lépésben, a nyelvtani szabályok felhasználásával építhető fel. A LEX LALR(1) nyelvtant használ és alulról felfelé elemez.

Szintaxis fa:

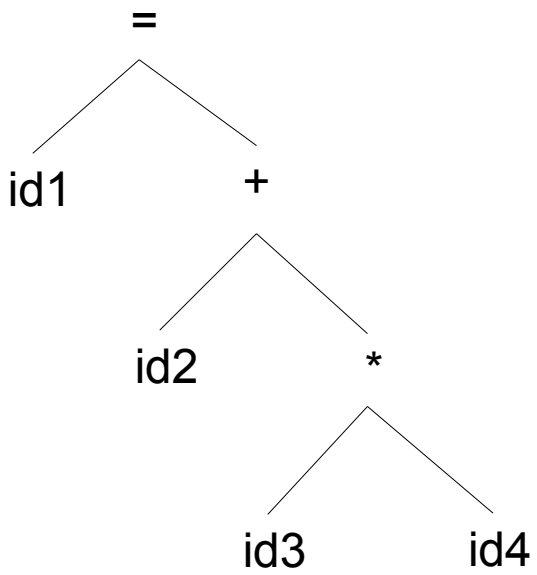

Fordítóprogramok

Lex és Yacc

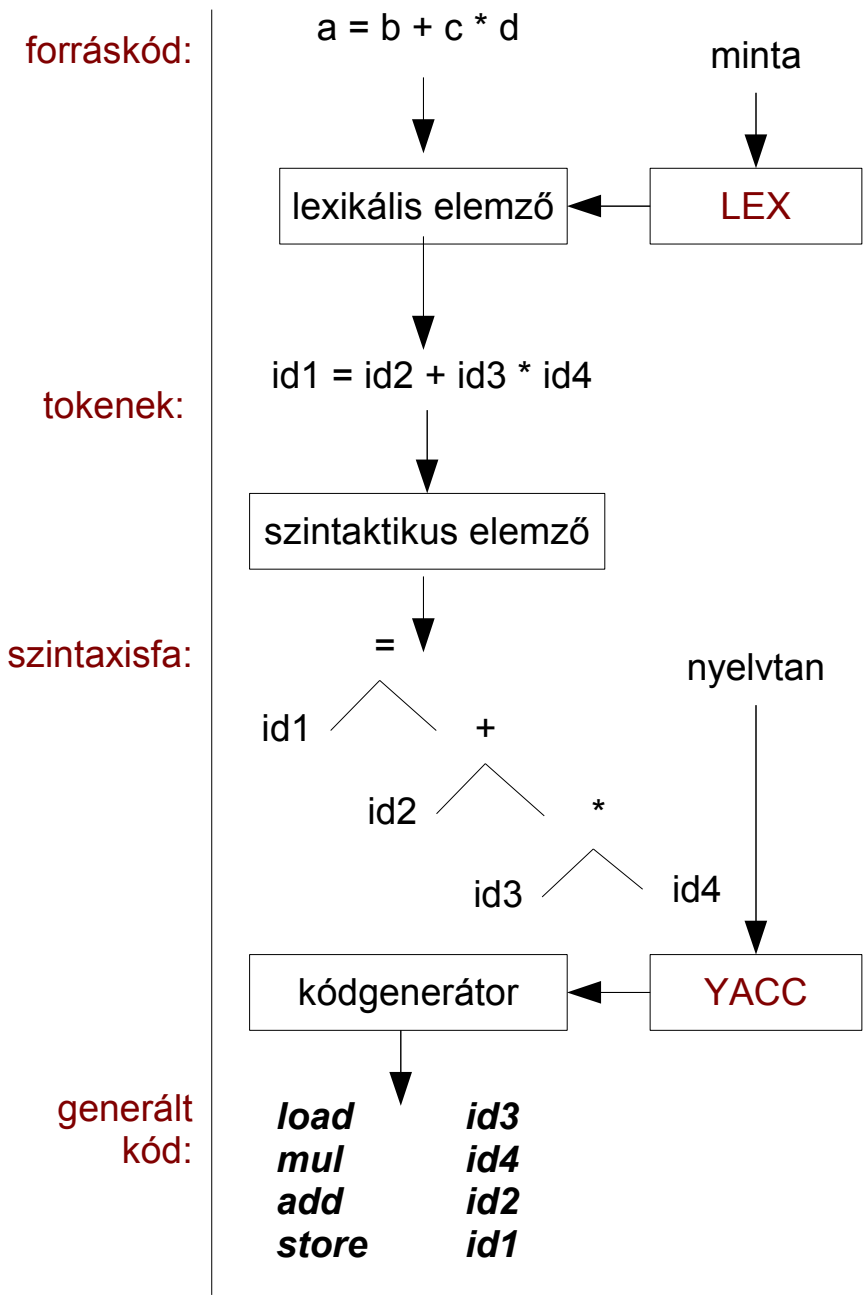

Lex és Yacc

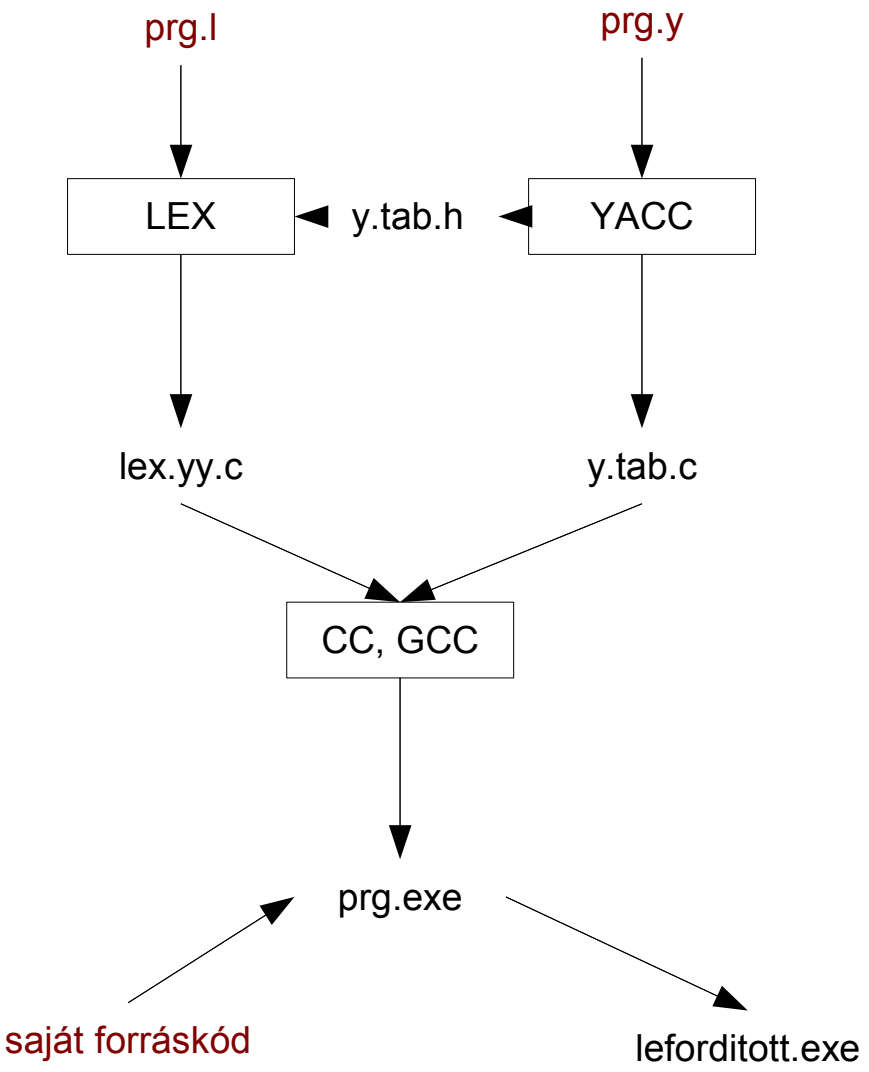
prg.l
prg.y
LEX
y.tab.h
YACC
lex.yy.c
y.tab.c
CC, GCC
prg.exe
saját forráskód
leforditott.exe

Compiler fordítás lépései

```
yacc –d prg.y      -> y.tab.h, és az y.tab.c
lex prg.l          -> létrehozza a lex.yy.c fájlt
cc lex.yy.c y.tab.c –o prg.exe      -> fordítás
```

A YACC kiolvassa a nyelvtant a prg.l fájlból, majd generálja ebből a szintaktikus elemzőt (parser), és elhelyezi az **yyparse** függvényt az y.tab.c fájlba.

A prg.y fájl tartalmazza a tokeneket. A **-d** opció hatására aYACC generálja a token definíciókat az y.tab.h fájlba.

A LEX kiolvassa a mintákat a prg.l fájlból és elhelyezi az y.tab.h fájlban, majd generálja a lexikális elemzőt úgy, hogy elhelyezi az **yylex** függvényt a lex.y.c fájlba.

Végül a lexer és a parser lefordítására és linkelésére kerül sor a prg.exe fájlba.

Az **yyparse** függvényt a main függvényben kell elhelyezni, s ez meghívja a yylex-szet, **hogy hozzáférjen a tokenekhez.**

Lex - prg.l

LEX input file szerkezete:

definíciók
%%
fordítási szabályok
%%
felhasználói programok

```
%{
        #include <stdlib.h>
        void yyerror(char *);
        #include "y.tab.h"
%}
%%
[a-z] {
        yylval = *yytext - 'a';
        return VARIABLE;
}
[0-9]+ {
        yylval = atoi(yytext);
        return INTEGER;
}
[-+()=/*\n] { return *yytext; }
[ \t\n] ;
.       yyerror("invalid character");
%%
int yywrap(void) {
        return 1;
}
```

Lex - metakarakterek

\n	új sor karakter
.	bármilyen karakter, kivéve az új sor
*****	0,1,2… szeres ismétlése a kifejezésnek
+	1,2… szeres ismétlése a kifejezésnek
?	0, 1-szeres ismétlése a kifejezésnek
^	sor kezdete
$	sor vége
a|b	a vagy b
”sss”	string literál
[ ]	karakter osztály
a{1,5}	az 'a' 1-5 közti előfordulása
[^ab]	bármi, kivéve a, vagy b,
[a^b]	a vagy ^ vagy b!
[a-z]	a tól z-ig
[-az]	a, z, '-' karakterek
szoveg&	szöveg a sor végén

Példák:

digit	**[0-9]**
delim	**[\t\n]**
whitespace	**{delim}***
number	**{digit}+(.\{digit}+)?(E[\+\-]?{digit}+)?**

Lex- előre definiált elemek

yytext	új sor karakter
yylval	beolvasott elem értéke
atoi	sd
ECHO	kiírja az elemet az outputra

stb

Fordítóprogramok

Fordítóprogramok

és formális nyelvek
3.

Szerkesztette : Király Roland
2007

Fordítás GCC compilerrel

Példafájl:

```
#include <stdio.h>
int main()
{
  printf("compilertest\n");
  return (0);
}
```

Normál fordítás:
  gcc test.c -o test.out

Előfordított file:
   cpp test.c test.i

Assembly file:
   gcc -S test.c -o test.ass

GNU linker – linkelt file - ld.:
   nm test.out

Szintaktikus elemző

Fentről lefelé elemzés

[1]. A lexikális elemző a forrásszöveget terminális jelek sorozatává alakítja. Ez a szintaktikus elemző inputja.

A szintaktikus elemzőnek meg kell határoznia a szintaxisfát, majd ismerve a gyökerét és az elemeit, elő kell állítania az éleket l
és a többi elemet, vagyis meg kell határoznia a program egy levezetését.
Ha sikerül, a program eleme a nyelvnek, vagyis szintaktikusan helyes.

Balról jobbra elemzést használva két módszer létezik:

- alulról felfelé elemzés:
  - a levél elemekből indulva haladunk az S szimbólum felé.
- felülről-lefelé elemzés:
  - az S szimbólumtól indulva építjük a fát. A cél, hogy a szintaxisfa levélelemeire az elemzett szöveg terminális szimbólumai kerüljenek

Elemző modellje

[1], [2]. A szintaktikus elemző szerkezete:

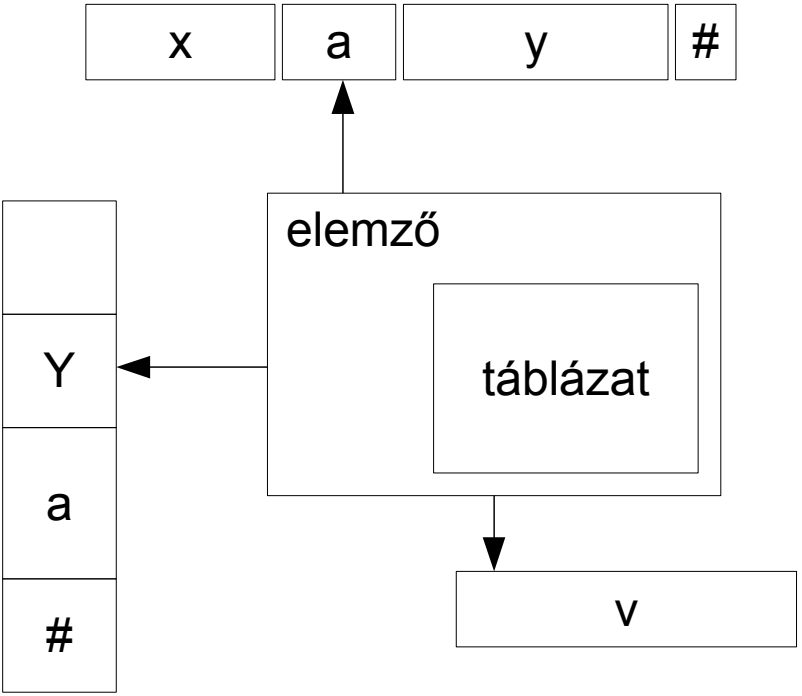

[1].

- #az elemzendő szöveg vége és a verem alja.
  - x,a,y Az elemzendő szöveg eleje, az aktuális szimbóluma és a még nem elemzett szöveg.
- Y a verem tetején lévő szimbólum.
- Táblázat az elemzéshez
  - v a szintaxisfa építéséhez szüksége lista

Rekurzív leszállás módszere

A visszalépés nélküli, felülről lefelé elemzések egyik gyakran alkalmazott módszere, melynek lényege, hogy:

A grammatika szimbólumaihoz eljárásokat rendelünk

Majd az elemzés közben a rekurzív eljárásokon keresztül

A programnyelv implementációja valósítja meg az elemző vermét és a veremkezelést.

[1]. Legyen egy G grammatika a következő:

G=({S, E, E', T, T', F}, {+, *, (,), i, #}, P, S)

ahol a helyettesítési szabályok:

S -> E#
E -> TE'
E' -> +TE' | e
T -> FT'
T' -> *FT' | e
F -> (E) | i

Mely alapján generálhat Pl.: a következő szintaktikusan helyes mondat

i + i * i

Az i + i * i mondat szintaxisfája

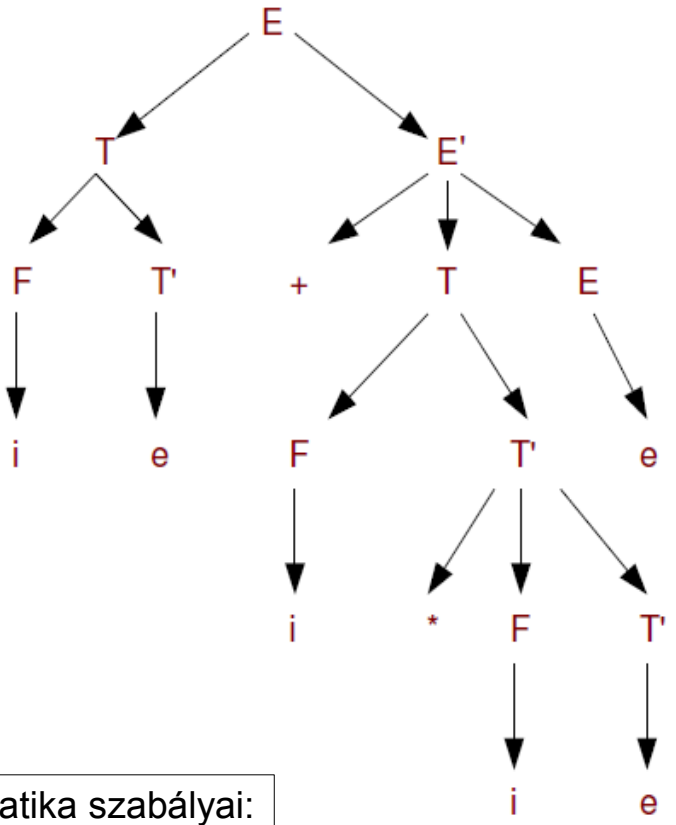

A grammatika szabályai:

S -> E#
E -> TE'
E' -> +TE | e
T -> FT'
T' -> *FT' | e
F -> (E) | i

Elemző eljárásai

Az elkészíthető eljárások a következők:
A terminális szimbólumok vizsgálatának eljárása:

```
elfogad(szimbólum)
{
  if (aktualis_szimbolum == szimbolum)
    kovetkezo_szimbolum(); else error();
}
```

eljárást, ahol az aktualis_szibolum globális változó és a terminális soron következő elemével.
A kovetkezo_szimbolum() az az eljárás, mely meghívja a lexikális elemzőt, vagyis a következő elemet az aktualis_szibolum valtozóba tölti.
A visszatérési érték lehet a kovetkező szímbólum, vagy hibajelzés.

A grammatika minden szabályához rendelünk egy eljárást. Pl.: az A szabályhoz tartozó eljárás a következő:

```
A()
{
  T(A);
}
```

A T(A) meghatározása mindig az A-ra vonatkozik szabályoktól függ.

S -> E#
E -> TE'
E' -> +TE | e
T -> FT'
T' -> *FT' | e
F -> (E) | i

T(A) ->

1. A -> a szabályhoz az **elfogad(a)** eljárást
2. A -> B szabályhoz a **B()** eljárást
3. A -> X1, X2,..,Xn szabályhoz a következő blokkot:

```
{
  T(X1);
  T(X2);
  ...
  T(Xn);
}
```

Egyébként

```
választ aktuális_szimbolum
        {
          elso(X1): T(X1);
          elso(X2): T(X2);
          ...
          elso(Xn): T(Xn);
          koveto(X): skip;
        }
```

{Elso} es {koveto} halmazok lsd.: később.

Az elemző programja tehát:

```
S()
{
  E();
  elfogad('#');
}

E()
{
  T();
  E'();
}

E'()
{
  valaszt aktualis szimbolum
        {'+'}:{
                elfogad('+');
                T();
                E'();
              }
        {')','#'}: skip;
}

T()
{
  F();
  T();
}
```

Kov.:

```
T'()
{
  valaszt aktualis_szimbolum
        {'*'}:{
                elfogad('*');
                F();
                T();
            }
        {'+',')','#'}: skip;
}

F()
{
  valaszt aktualis_szimbolum
        {'('}:{
                elfogad('(');
                E();
                elfogad(')');
            }
        {'i'}: accept('i');
}
```

Az elemző főprogramja a grammatika kezdő szimbólumához tartozó eljárás, vagyis az

```
S();
```

LL(k) elemzők

[1] Ha A -> a ∈ P, akkor az xAß mondatforma legbaloldalibb helyettesítése xaß, azaz

xAß => xaß (legbal).

[2] Ha az S => x (X ∈ T*) levezetésben minden helyettesítés legbaloldalibb helyettesítés, akkor ezt a levezetést legbaloldalibb levezetésnek nevezzük.*

S => x (legbal).*

[1] Ha S =>* xa =>* yz (a *∈(N U T)*, x, y, z ∈ T**) és |x| = |y|, x = y

magyarázat:

A mondatforma bal oldalán a terminálisokból álló x sorozatot a környezetfüggetlen nyelvtan helyettesítési szabályai nem változtatják meg.

Ezt kezdőszelet egyeztetésnek hívják. Ha a szintaxisfa építésekor a bal oldali terminálisok nem egyeznek meg az elemzendő szöveg bal oldalán állókkal, akkor a fa építése rossz irányba halad. Ekkor vissza kell lépni.

Az ilyen visszalépéses algoritmusok alkalmazása rendkívül költséges.

Alapfogalmak

[1], [2] LL(k) nyelvtanok alaptulajdonsága:

Az S =>* wx legbaloldalibb levezetés építése során eljutunk a S =>* wAß mondatformáig és az Aß =>* x -t szeretnénk elérni, akkor az A ra alkalmazható *A -> a helyettesítést egyértelműen meghatározhatjuk az x első k db szimbólumának előre olvasásával.*
(Ekkor és csak ekkor LL(k) nyelvtanról beszélhetünk.)

Erre megadható az *Első k* függvény.

Első k(a) legyen az a-ból (k >= 0, a ϵ (N U T)*) levezethető szimbólumsorozatok k hosszúságú kezdő terminálisainak halmaza. (Elsők(x) az x első k db szimbólumát tartalmazza)

Pl.:
LL(1) nyelvtan:

G = ({A, S}, {a, b}, P, S), ahol a
P = S -> AS | ε
A -> aA | b

Az S szimbólumra az S->AS szabályt kell alkalmazni, ha az elemzendő szövegben a, vagy b a következő elem, és S->ε, *ha ha a következő szimbólum a # (végjel).*

Alapfogalmak

Az LL(k) elemzéseknél nem elég csak a szabályokat vizsgálni. Ha pl.: van az A-ra egy

A -> ε

szabály, akkor az Elsők halmazokban a az B-ból származó terminális sorozatok k hosszúságú kezdő szimbólumai is szerepelnek. ezért a nem mindig véges számú levezetéseket is figyelembe kell venni.

Gyakorlati módszer csak az LL(1) nyelvtanokra létezik.

Szükség van egy Követők függvény definiálására, mely megadja a szimbólumsorozatot követő k hosszúságú terminális sorozatok halmazát.:

Követő(A) (A ϵ N) tehát azokat a terminális szimbólumokat tartalmazza, melyek a levezetésben közvetlenül az A után állhatnak.

Mind az Elsők, mind a Követők halmazok meghatározására létezik gyakorlatban használható algoritmus. [2]

Táblázatos elemzés

[1] Az elemzendő terminális sorozat xay, ahol az x szöveget már elemeztük.

Felülről lefelé legbaloldalibb helyettesítéseket alkalmazunk, szintaktikus hibát nem találtunk, így az elemezendő mondatformánk **xYa**, azaz vagy:

(1.) **xBa** vagy,

(2.) **xba** alakú.

(1.) a szintaxisfa építésekor a B-t kell helyettesítenünk egy B -> ß szabállyal amelyre igaz, hogy (a ∈ Első(ß Követő(B))).
Ha van ilyen szabály, akkor pontosan egy van (mivel LL(1) a nyelvtan), különben szintaktikai hiba helyét detektáltuk.

(2.) a második esetben a mondatforma következő szimbóluma a b terminális jel, tehát az elemzendő szövegben is b-nek kell szerepelnie.
Ha így van, továbblépünk, ha nem, akkor szintaktikai hiba helyét detektáltuk.

Elemző működése

[1],[2] Az elemző állapotait egy

(ay#, Xa#, v) hármassal írjuk le, ahol a

jel az elemzendő szöveg vége és a verem alja,

ay# a még nem elemzett szöveg,

Xa# az elemzendő szöveg mondatformájának még nem elemzett része ez van a veremben,

v a szabályok sorszámát tartalmazó lista.

A helyettesítési szabályokat megszámozzuk. Az elemzés során alkalmazott szabályok sorszámát a v listában tároljuk.

Az elemzés során mindig a verem tetején lévő X szimbólumot hasonlítja össze a még nem elemzett szöveg következő szimbólumával (a-val). Az a-t aktuális szimbólumnak nevezzük.

Kezdőállapot: (xay#, S#, ϵ)

Az elemzés egy T elemző táblázattal végezhető el. A T táblázat kitöltésére megfelelően gyors és jól használható algoritmusok léteznek.

Az elemző táblázata

T[X, a] = {	(B,i)	ha X->B a E Első(B) vagy (e E Első(B) és a E Követő(X)).
	pop	ha X = a,
	elfogad	ha X = # és a = #,
	hiba	egyébként.

Az elemző algoritmusa

Az elemző működése állapotátmenetekkel adható meg. A kezdeti állapot (x#, S#, ϵ). Sikeres befejezésnél a végállapot (#, #, w).

Ha a még nem elemzett szöveg az ay#, és a verem tetején az X szimbólum áll, az állapotátmenetek a következők:

(ay#, Xa#, v)->{	(ay#, Ba#, vi)	ha T[X,a]=(B,i),
	(y#, a#, v)	ha T[X,a]=pop.
	OK.	ha T[X,a]=elfogad
	HIBA	ha T[X,a]=hiba

LL(1) elemzés:
algoritmus...

Példa táblázatos elemzésre

Rekurzív leszállás módszere

A Rekurzív-Leszállás módszere balról jobbra elemzi a szöveget, úgy, hogy nyelvtan szabályait eljárásokkal implementálja és a verem kezelését, valamint a rekurzív hívásokat a programnyelv implementációjára bízza.

Minden szabályhoz egy eljárást rendel:

```
S -> T
T -> ...

Procedute S
{
 T()
}

Procedure T{...}
...
```

A nyelvtan kezdő szimbólumához rendelt eljárás mindig az elemző főprogramja, mely elindítja a rekurzív hívásokat.

A módszert a fentről lefelé elemzés és a rekurzív eljáráshívások miatt nevezik Rekurzív-Leszállás módszernek.

Felhasznált irodalom:

I. Csörnyei Zoltán, *Fordítóprogramok*, ELTE Budapest, 2005
II. Kása Zoltán, Csörnyei Zoltán, *Formális nyelvek és fordítóprogramok*, Babes-Boyai, Kolozsvár, 2007
III. Tom Nieman, *A compact Lex & Yacc* Portland, Oregon, epaperpress.com
IV. Anthony A., *Compiler Construction using Flex and Bison*, AabWalla Walla College April 22, 2005
V. Hernyák Zoltán, *Formális nyelvek és automaták*, EKF, Eger, 2001

Fordítóprogramok

Fordítóprogramok

és formális nyelvek

Szerkesztette : Király Roland

2007

Fordítóprogram szerkezete

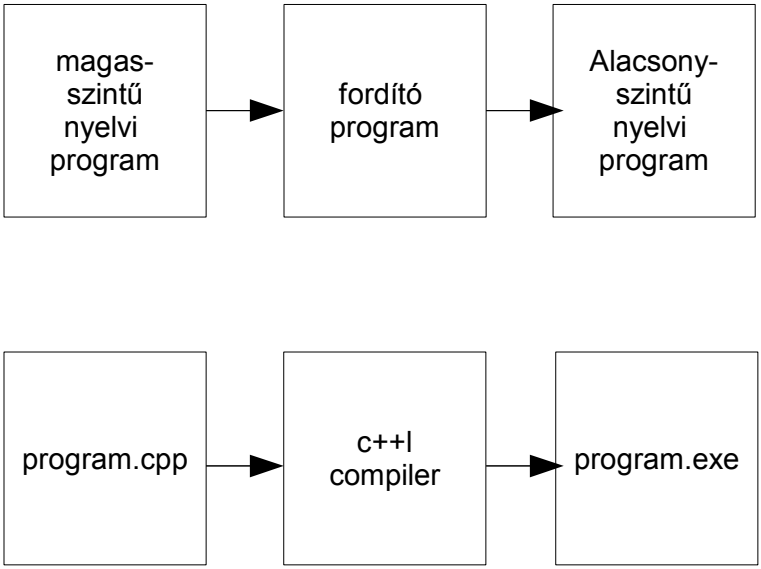

- A fordítóprogramok általánosan forrásnyelvi szövegből állítanak elő tárgykódot.
- A fordítóprogramok feladata, hogy nyelvek közti konverziót hajtsanak végre.
- A fordítóprogram a forrásprogram beolvasása után elvégzi a lexikális, szintaktikus és szemantikus elemzést, előállítja a szintaxis fát, generálja, majd optimalizálja a tárgykódot.

Compiler és Interpreter

- A compiler magas szintű, forrásnyelvi szöveget, más néven forráskódot transzformál alacsonyszintű nyelvre, legtöbbször assembly, vagy gépi kódra.
    - input-handler(forráskód) -> hibák, karaktersorozat
    - compiler(karaktersorozat) -> tárgykód
    - code-handler(tárgykód) -> tárgyprogram
- Az interpreter hardveres, vagy virtuális gép, mely értelmezni képes a magas szintű nyelvet, vagyis melynek gépi kódja a magasszintű nyelv. Ez egy kétszintű gép, melynek az alsó szintje a hardver, a felső az értelmező és futtató rendszer programja.
- Fordítási idő: azt az időt mely alatt a compiler elvégzi a transzformációt, fordítási időnek nevezzük.
- Futási idő: azt az időt, mely alatt a lefordított programot végrehajtjuk, futási, vagy futtatási időnek nevezzük.
- Az interpreter esetében a fordítási és a futási idő egybe esik, amig a compiler esetén a két időpont jól elkülöníthető.

Fordító (compiler) felépítése

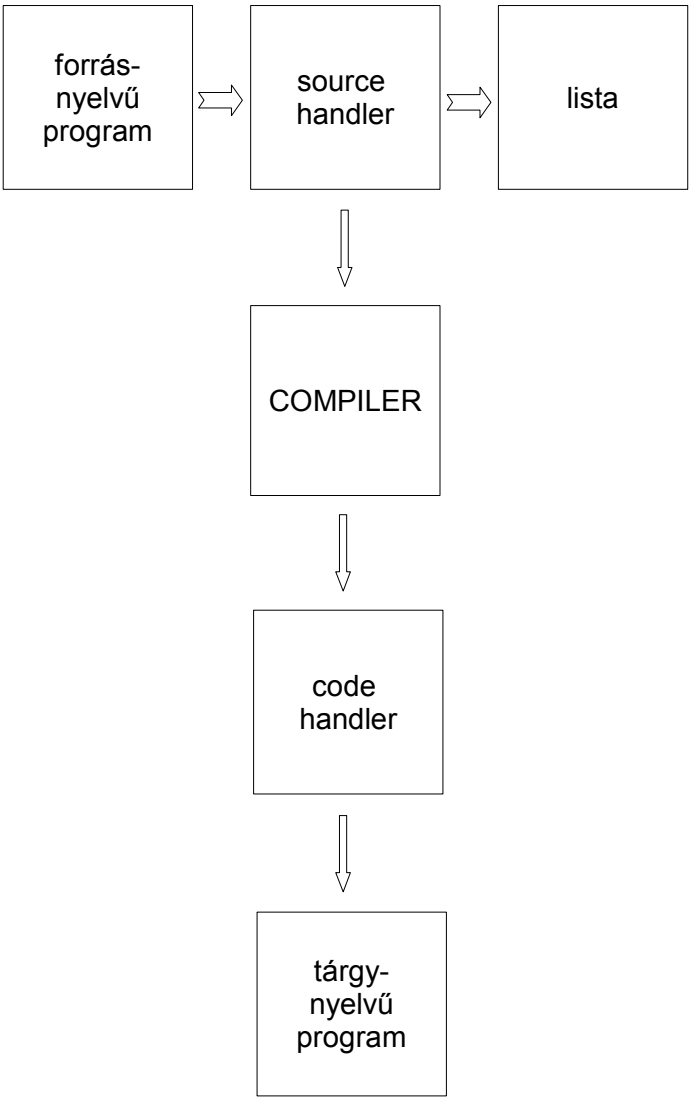

T diagramm

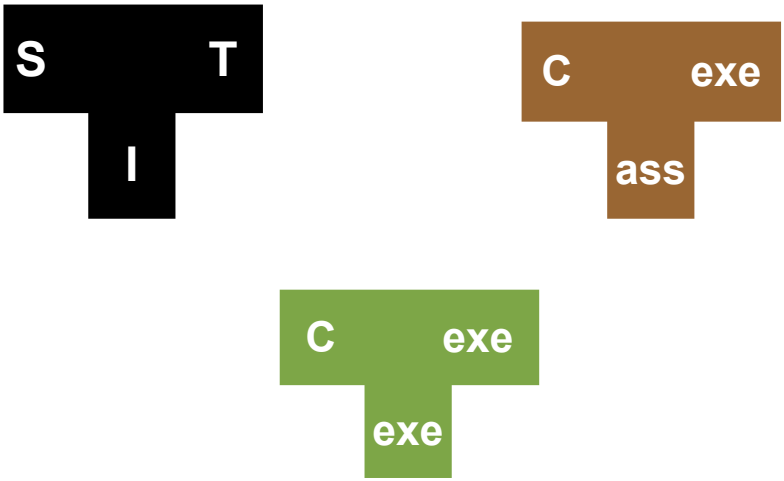

•A fordítóprogramokat három nyelvvel jellemezhetjük.
•Implementáció nyelve, **I** melyen a fordítóprogramot írták. Lehetőleg magasszintű nyelv.
•Forrásnyelv **S** amit a program lefordít.
•Tárgynyelv **T**, melyre a forrásnyelvből fordít .

A C - exe fordítóprogram

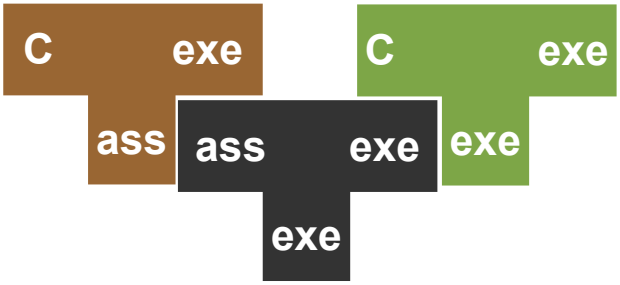

- A T diagramok azon pontokon illeszthetőek egymáshoz, ahol a diagramban azonos nyelvet találunk.
- Az első diagram egy assembly nyelven írt C-exe fordító.
- A második exe végrehajtható kódú ass – exe assembler.
- Ezekből előállítható egy végrehajtható C – exe fordítóprogram

Input handler (source handler)

- Az input-handler a forrásnyelvi szöveget beolvassa, majd az újsor és a kocsivissza karaktereket levágja a sorok végéről.
- Sok esetben ez a program a lexikális elemző részeként van implementálva.
- Az input-handler nem végez szematikai és szintaktikai ellenőrzést, ezt a feladatot a lexikális elemző végzi.
- Az input-handler kimenete a lexikális elemző bemenete.
- A szintaktikusan és szemantikusan ellenőrzött és helyes kódból a fordítóprogram tárgykódot állít elő. Ezt a feladatot az output-handler végzi.
- Ha az input és output handlert egy programban implementálják, akkor ezt a programot source-handlernek nevezzük.

Input handler implementációja

```
class handler
  {
      public string sourceHandler(string source)
      {
            string S="";
            System.IO.StreamReader Stream = new
            System.IO.StreamReader
            (
                  System.IO.File.OpenRead(source)
            );

            while (Stream.Peek() > -1)
            {
                  S += Stream.ReadLine();
            }
            return S;
      }
  }
```

Formális nyelvtanok

Nézzünk pár fontos alapfogalmat!

formális nyelvtan

: , ahol a nemterminálisok, a terminálisok halmaza, a kezdőszimbólum, pedig az alakú szabályok halmaza.

környezet függetlenség

: a szabályok alakúak.

reguláris nyelvtanok

: minden szabály vagy vagy alakú.

derivációs fa

: a gyökérben a kezdőszimbólum van, a levelek a terminálisok, a csúcspontokban pedig nemterminálisok ülnek a levezetésnek megfelelően ``összekötve''. Bemutatás egy példán keresztül: S -> AB

A -> aA | input: aab

B -> bB |

Reguláris kifejezések

Jelöljön D egy tetszőleges számjegyet és L egy tetszőleges karaktert, a whitespace karaktereket a nevükkel helyettesítjük *{eol, eof, space}*.

D ∈ {0, 1, 2, ... , 9} , L ∈ {a, b, ..., z, A, B, ..., Z},

ekkor:

1) Egész számok:

(+ | - | ε)D+

2) Pozitív egész és valós számok:

(D+ (ε | .))| (D* .D+)

3) Egyszerű azonosító szimbólum:

L(L | D)*

4) Azonosító szimbólum:

L((_ | ε)(D | L)*

5) // -el határolt komment:

//(Not(eol))* eol

6) ## -al határolt komment:

##((# | ε) Not(#))*##

7) Karakter sztring:

“(Not(“) | “ ”)* “

8) Kitevős valós szám:

(+| -| ε)D+.D+(E(+| -| ε)D+ | ε)

Reguláris kifejezések felismerése

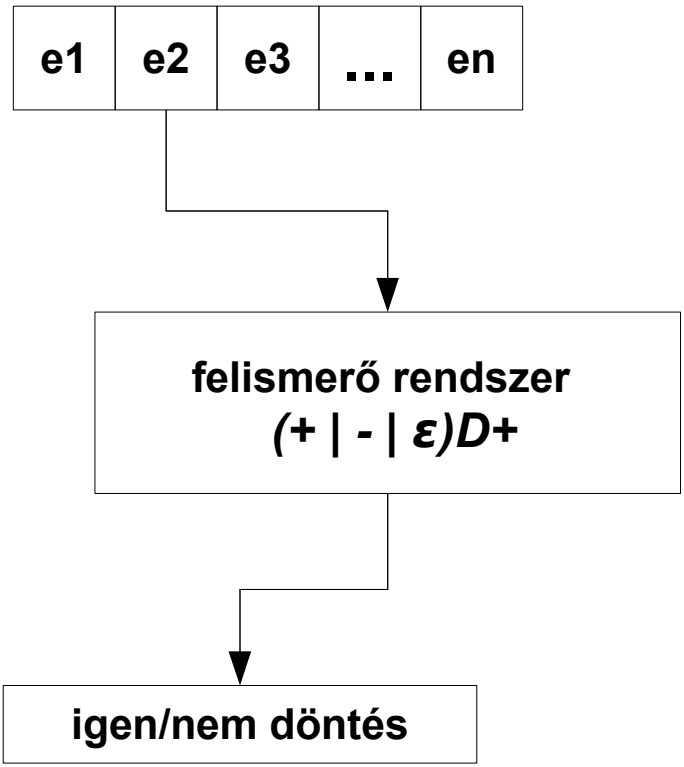

- A döntéshozó rendszer, vagyis az automata eldönti, hogy az input szalagon lévő sorozat a nyelvnek eleme, vagy sem.

Determinisztikus-véges automaták

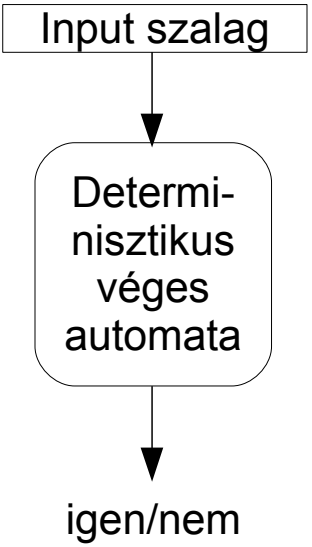

(+ | - | ε)D+

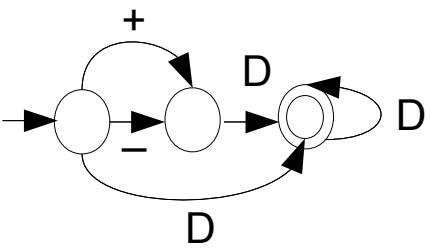

- Reguláris kifejezésekhez determinisztikus véges automata konstruálható.
- Az automata implementációja állapotai és az állapot átmenetek magasszintű programozási nyelveken jól implementálhatóak.

Kifejezésekhez konstruált automaták I.

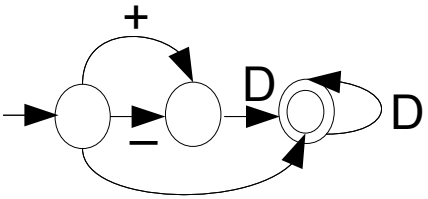

(+ | - | ε)D+

A = (**Q, ∑, E, I, F**)

véges automata, ahol

Q - a belső állapotok halmaza
∑ - az input ABC
E - az átmenetek halmaza
I - a kezdőállapot (halmaz)
F - végállapot (halmaz)

∑ = *{+, -, D+}.*
Q = *{q0, q1, q2},*
E = *(q0, +, q1), (q0, -, q1), (q0, ?, q2),*
(q1, D, q2),
(q2, D, q2),
F = *{q2},*
i = *{q0}*

Kifejezésekhez konstruált automaták II.

A = (**Q, ∑, E, I, F**)

A terminális jelek = {0, 1, 2}.
Az állapotok = {q0, q1, q2},
E = (q0, 0, q1), (q0, 1, q1), (q0, 2, q2),
(q1, 0, q1), (q1, 1, q2), (q1, 2, q0),
(q2, 0, q2), (q2, 1, q0), (q2, 2, q1),
Kezdő állapot = {q0},
Elfogadó végállapot = {q0}

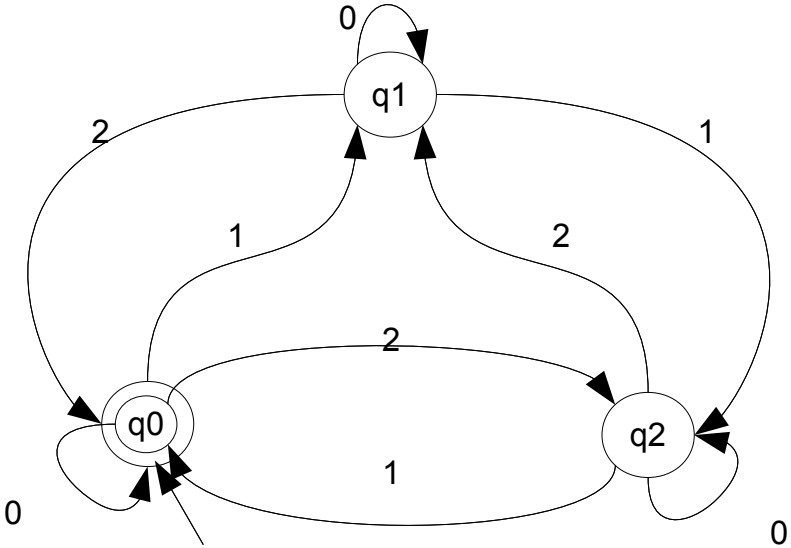

Automata Implementációja

```
public string analyst(string grammar)
{
   string STATE="q0";
   string OK="OK";
   int i=0;
    while (i < grammar.Length &&
              STATE !="error")
   {
     STATE=transition(STATE,grammar[i]);
     ++i;
   }
   if (i<grammar.Length)
   {
     OK= "A hiba pozíciója"
     +i.ToString()+". "+grammar[i]
     +" nem eleme a nyelvnek";
   }
   return OK;
 }
}
```

- Elemző program implementációjához érdemes magasszintű nyelveket használni.
- Az elemző programja determinisztikus véges automata. melynek állapotait switch ágaival, vagy állapotátmenet függvényekkel valósítjuk meg.

Állapotátmenet függvény

```
string transition(string state, char char_)
    {
        string nstate;
        switch (state+char_)
        {
            case "q00":nstate="q0";break;
            case "q01":nstate="q1";break;
            case "q02":nstate="q2";break;
            case "q10":nstate="q1";break;
            case "q11":nstate="q2";break;
            case "q12":nstate="q0";break;
            case "q20":nstate="q2";break;
            case "q21":nstate="q0";break;
            case "q22":nstate="q1";break;
            default:nstate="error";break;
        }
        return nstate;
       }
```

•Az automata állapotait a switch ágaival valósítjuk meg. Minden egyes case ág az automata egy állapotátmenetét írja le.
•Az állapotátmenet függvény bemenő paramétere az aktuális állapot és az un.: input szalag következő karaktere.

Lexikális elemző

- A lexikális elemző inputja a source handler outputja, vagyis egy karaktersorozat, mely az újsor és a kocsi vissza karakterek kivételével mindent tartalmaz a forráskódból.
- A lexikális elemző reguláris, vagyis Chomsky 3-as nyelvet használ.
- Feladata felismerni az adott nyelv lexikális elemeit, majd helyettesíteni azokat a Szintaktikus elemző számára érthető jelekkel.
- A lexikális elemző outputja a szintaktikus elemző inputja lesz és egy hibalista a lexikális hibákról.

- Az egyes nyelvi elemeket leírjuk reguláris kifejezésekkel és megalkotjuk az ekvivalens determinisztikus – véges automatát.
- Elkészítjük az automata implementációját.
- (Az automata implementációja magasszintű nyelveken egyszerűen a switch, vagy case nyelvi elem felhasználásával kivitelezhető. Az állapotok a switch egyes ágai...)

Lexikális elemző működése

If a > 0 then x:= a else x:=0

- A fenti programszövegből a lexikális elemző az alábbi kimenetet készíti el, mely már teljesen olvashatatlan.

10	if
20	then
30	else
40	:=
50	>

10 001 50 002 20 003 40 001 30 003 40 0004

- A használt változókhoz, konstansokhoz, stb... az un.: szimbólumtábla bejegyzések tartoznak, melyben tárolható a változók azonosítójához tartozó érték, típus és egyéb attribútumok.
- A szimbólumtáblát legtöbbször láncolt listával valósítják meg.
- A szimbólumtábla bejegyzéseit a szemantikus elemző használja fel.
- A lexikális elemző felhasználható forrásnyelvi programok más nyelvekre való konvertálására is.

Szimbólum tábla

- A szimbólumtábla olyan táblázat, mely tartalmazza a programszövegben előforduló szimbólumok nevét és jellemzőit, vagyis az attribútumokat.
- Ezek az információk a lexikális és szintaktikus elemző számára nem lényegesek, de a szemantikus elemzés és a kódgenerálás számára elengedhetetlenek.
- A szimbólum minden egyes előfordulása esetén a táblában keresést, vagy beszúrást kell végezni. Összesen ez a két művelete van.
- Szimbólumtábla egy sorának a tartalma:

  - Szimbólum neve
  - Attribútumok
    - definíciós adatok
    - típus
    - programbeli cím (tárgyprogram)
    - forrásnyelvi sorszám
    - hivatkozott sorszám
    - láncolási cím

Szimbólumtábla

- Definíciós adatok, típus:
  - Mit azonosít a szimbólum, Pl.: változó, konstans, stb. Konstansnál az értek, típusnál a típus-descriptorra mutató pointer, eljárásnál annak paraméterei, azok száma.

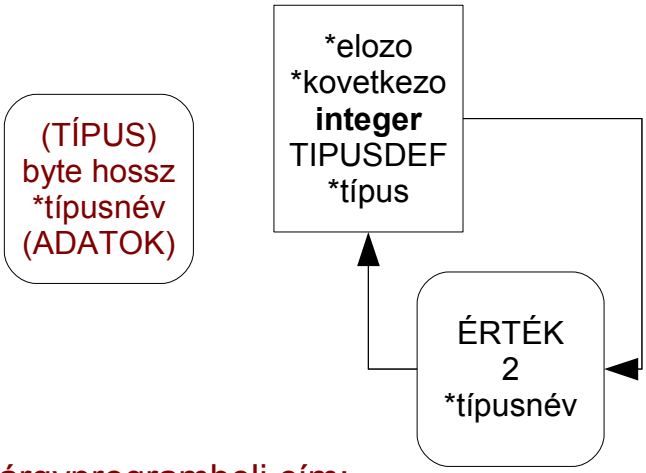

- Tárgyprogrambeli cím:
  - ezt a címet kell a tárgyprogramba beépíteni a szimbólumra való hivatkozáskor.
- Definíció sorszáma:
  - explicit definíciónál a definíció sora, implicitnél az első előfordulás
- Hivatkozott sorszám ,láncolási cím
  - a hivatkozási lista elkészítéséhez

Szimbólumtábla implementációja

```
struct symrec
{
  char *name; /* szimbólum neve */
  struct symrec *next; /* mutató mező */
};

typedef struct symrec symrec;
symrec *sym_table = (symrec *)0;
symrec *put ();
symrec *get ();
```

- A fenti szimbólumtábla implementációja láncolt listával történik. Csak a szimbólum nevét tartalmazza, attribútumokat nem.
- A tábla két művelete:
  - beszúrás – put(), mely nemlétező szimbólum esetén beszúrja azt a táblába, majd visszatér a címével. Létező szimbólum esetén is a címével tér vissza.
  - kivét – get(), mely visszatér a szimbólum címével, vagy a 0 értékkel nemlétező szimbólum esetén.

Szimbólumtábla műveletei

- put a szimbólumok elhelyezésére a listáában

```
symrec *put ( char *sym_name )
{
  symrec *ptr;
  ptr = (symrec *) malloc (sizeof(symrec));
  ptr− >name =
          (char *) malloc (strlen(sym_name)+1);
  strcpy (ptr− >name,sym name);
  ptr− >next = (struct symrec *)sym_table;
  sym_table = ptr;
  return ptr;
}
```

- get a szimbólum ellenőrzéséhez a hivatkozások esetén

```
symrec * get ( char *sym name )
{
  symrec *ptr;
  for (ptr = sym table; ptr != (symrec *) 0;
  ptr = (symrec *)ptr− >next)
  if (strcmp (ptr− >name,sym name) == 0)
    return ptr;
  return 0;
}
```

Fordítóprogramok

Programnyelvek konvertálása

Szintaxis

program :
változó ***<deklaráció>*** kezd ***<parancsok>*** vége;

deklaráció: típus ***<azonosító_lista>,*** azonosító;

azonosító_lista:
azonosító | azonosító_lista;

parancslista:
| parancslista ***<parancs>***;
parancs: üres_utasítás
| beolvas azonosító
| kiír kifejezés
| azonosító := kifejezés
| ha kifejezés akkor parancsok különben
parancsok vége
| ciklus ***<kifejezés>*** elvégez parancsok vége;

kifejezés: szám | azonosító
| kifejezés < kifejezés
| kifejezés = kifejezés
| kifejezés > kifejezés
| kifejezés + kifejezés
| kifejezés – kifejezés
| kifejezés * kifejezés
| kifejezés / kifejezés
| kifejezés ^ kifejezés | (kifejezés)

Az azonosító és a szám, leírható meta karakterekkel...

BNF

```
program
   ::= LET [ declarations ] IN command sequence
END

declarations ::= INTEGER [ id seq ] IDENTIFIER .
id seq ::= id seq... IDENTIFIER ,
command sequence ::= command... command
command ::= SKIP ;
          | IDENTIFIER := expression ;
          | IF exp THEN command sequence
                    ELSE command sequence FI
          | WHILE exp
                    DO command sequence END ;
          | READ IDENTIFIER ;
          | WRITE expression ;

expression ::=
           NUMBER | IDENTIFIER
           | '(' expression ')'
           | expression + expression
           | expression − expression
           | expression * expression
           | expression / expression
           | expression ^ expression
           | expression = expression
           | expression < expression
           | expression > expression
```

Lex és Yacc

A LEX reguláris kifejezések formális leírásából hozza létre egy determinisztikus véges automata implementációját. Valójában lexikális elemző programot generál (C kódot állít elő).

Mintákat használ, hogy tokeneket készítsen az input stringből.

A token a string számszerű reprezentációja, mely megkönnyíti a feldolgozást.

A YACC C kódot generál a szintaktikus elemzőhöz. Nyelvtani szabályokat használ a lex tokenjeinek elemzéséhez és a szintaxisfa felépítéséhez.

A felépített szintaxisfa segítségével kódot generálhatunk, mely virtuális gépen, vagy a számítógép hardverén futtatható.

lexer lexikális elemző	Parser szintaktikus elemző

Szintaxis fa

a = b + c * d

A szintaxis-fa a forrásszövegből, több lépésben, a nyelvtani szabályok felhasználásával építhető fel. A LEX LALR(1) nyelvtant használ és alulról felfelé elemez.

Szintaxis fa:

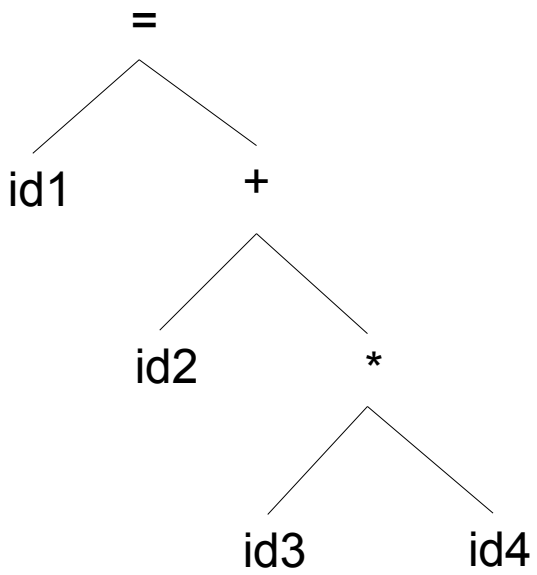

Lex és Yacc

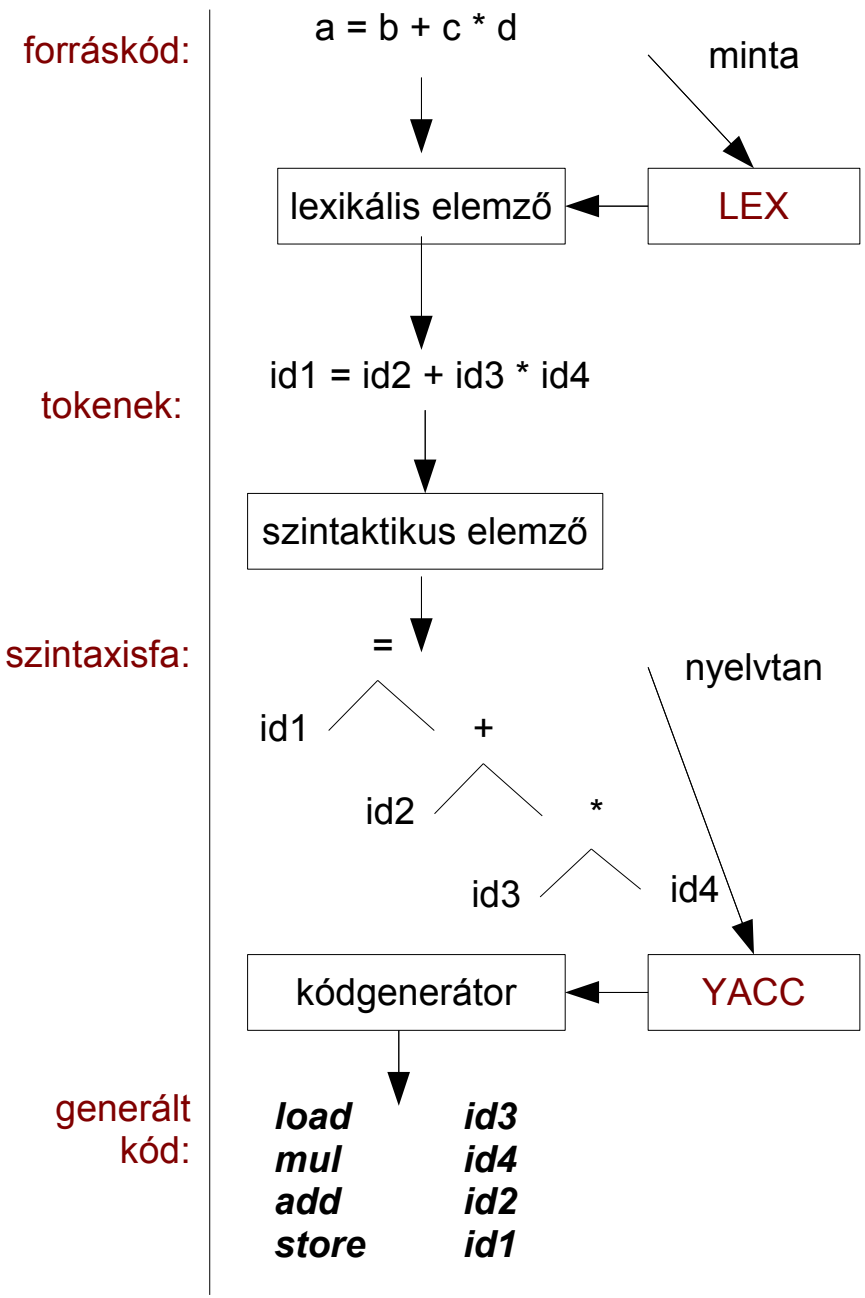
forráskód:
a = b + c * d
minta
lexikális elemző
LEX
tokenek:
id1 = id2 + id3 * id4
szintaktikus elemző
szintaxisfa:
=
id1
+
id2
*
id3
id4
nyelvtan
kódgenerátor
YACC
generált kód:
load id3
mul id4
add id2
store id1

Lex és Yacc

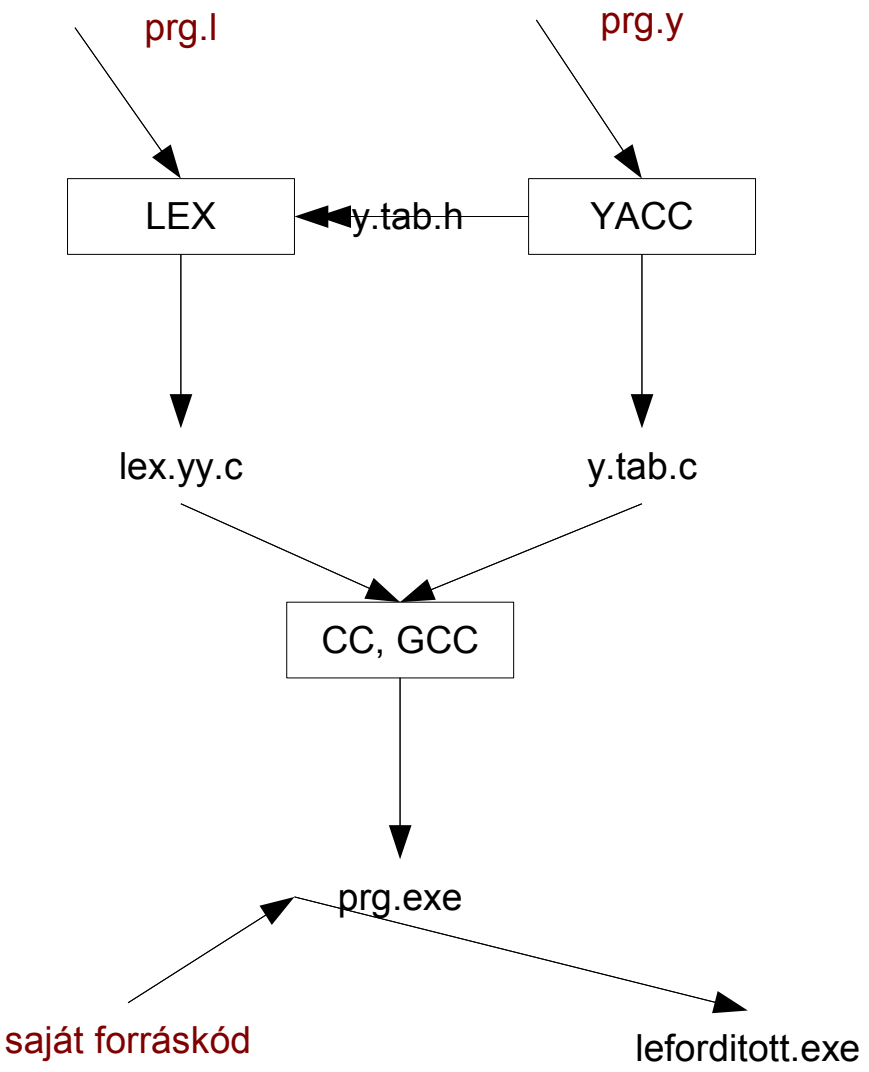
prg.l
prg.y
LEX
y.tab.h
YACC
lex.yy.c
y.tab.c
CC, GCC
prg.exe
saját forráskód
leforditott.exe

Compiler fordítás lépései

```
yacc –d prg.y      -> y.tab.h, és az y.tab.c
lex prg.l          -> létrehozza a lex.yy.c fájlt
cc lex.yy.c y.tab.c –o prg.exe      -> fordítás
```

A YACC kiolvassa a nyelvtant a prg.l fájlból, majd generálja ebből a szintaktikus elemzőt (parser), és elhelyezi az **yyparse** függvényt az y.tab.c fájlba.

A prg.y fájl tartalmazza a tokeneket. A **-d** opció hatására a YACC generálja a token definíciókat az y.tab.h fájlba.

A LEX kiolvassa a mintákat a prg.l fájlból és elhelyezi az y.tab.h fájlban, majd generálja a lexikális elemzőt úgy, hogy elhelyezi az **yylex** függvényt a lex.y.c fájlba.

Végül a lexer és a parser lefordítására és linkelésére kerül sor a prg.exe fájlba.

Az **yyparse** függvényt a main függvényben kell elhelyezni, s ez meghívja a **yylex-t**, hogy hozzáférjen a tokenekhez.

Lex - prg.l

LEX input file szerkezete:

definíciók
%%
fordítási szabályok
%%
felhasználói programok

```
%{
        #include <stdlib.h>
        void yyerror(char *);
        #include "y.tab.h"
%}
%%
[a-z] {
        yylval = *yytext - 'a';
        return VARIABLE;
}
[0-9]+ {
        yylval = atoi(yytext);
        return INTEGER;
}
[-+()=/*\n] { return *yytext; }
[ \t\n] ;
.       yyerror("invalid character");
%%
int yywrap(void) {
        return 1;
}
```

Lex - metakarakterek

\n	új sor karakter
.	bármilyen karakter, kivéve az új sor
*****	0,1,2… szeres ismétlése a kifejezésnek
+	1,2… szeres ismétlése a kifejezésnek
?	0, 1-szeres ismétlése a kifejezésnek
^	sor kezdete
$	sor vége
a|b	a vagy b
”sss”	string literál
[ ]	karakter osztály
a{1,5}	az 'a' 1-5 közti előfordulása
[^ab]	bármi, kivéve a, vagy b,
[a^b]	a vagy ^ vagy b!
[a-z]	a tól z-ig
[-az]	a, z, '-' karakterek
szoveg&	szöveg a sor végén

Példák:

digit	**[0-9]**
delim	**[\t\n]**
whitespace	**{delim}***
number	**{digit}+(.\{digit}+)?(E[\+\-]?{digit}+)?**

Lex- előre definiált elemek

yytext	új sor karakter
yylval	beolvasott elem értéke
atoi	sd
ECHO	kiírja az elemet az outputra

stb

/home/roland/Desktop/lex/fourth_lexer_test
lang.lex
lang.y

Fordítás GCC compilerrel

Példafájl:

```
#include <stdio.h>
int main()
{
  printf("compilertest\n");
  return (0);
}
```

Normál fordítás:
  gcc test.c -o test.out

Előfordított file:
   cpp test.c test.i

Assembly file:
   gcc -S test.c -o test.ass

GNU linker – linkelt file - ld.:
   nm test.out

Szintaktikus elemző

Fentről lefelé elemzés

[1]. A lexikális elemző a forrásszöveget terminális jelek sorozatává alakítja. Ez a szintaktikus elemző inputja.

A szintaktikus elemzőnek meg kell határoznia a szintaxisfát, majd ismerve a gyökerét és az elemeit, elő kell állítania az éleket és a többi elemet, vagyis meg kell határoznia a program egy levezetését.
Ha sikerül, a program eleme a nyelvnek, vagyis szintaktikusan helyes.

Balról jobbra elemzést használva két módszer létezik:

- alulról felfelé elemzés:
  - a levél elemekből indulva haladunk az S szimbólum felé.
- felülről-lefelé elemzés:
  - az S szimbólumtól indulva építjük a fát. A cél, hogy a szintaxisfa levélelemeire az elemzett szöveg terminális szimbólumai kerüljenek

Elemző modellje

[1], [2]. A szintaktikus elemző szerkezete:

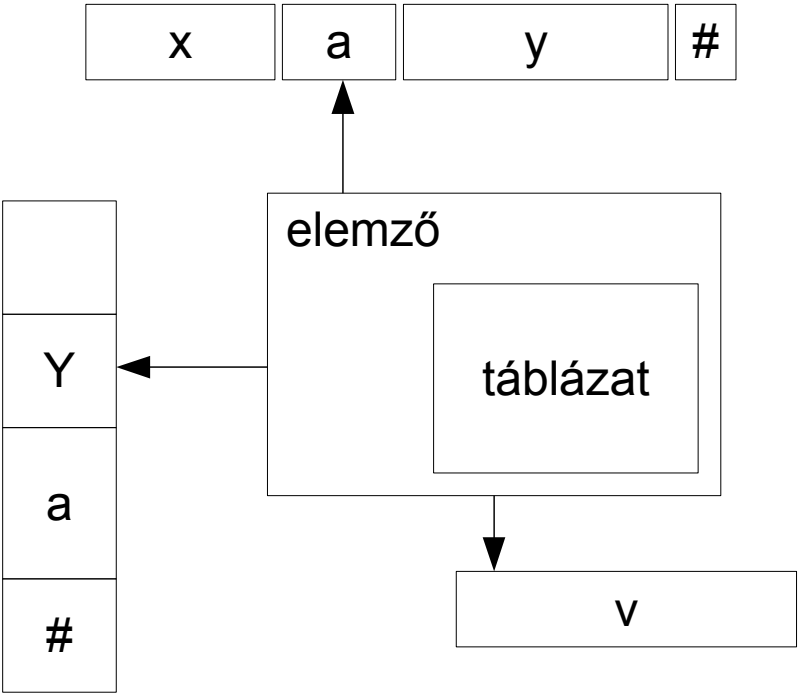

[1].

- #az elemzendő szöveg vége és a verem alja.
  - x,a,y Az elemzendő szöveg eleje, az aktuális szimbóluma és a még nem elemzett szöveg.
- Y a verem tetején lévő szimbólum.
- Táblázat az elemzéshez
  - v a szintaxisfa építéséhez szüksége lista

Rekurzív leszállás módszere

A visszalépés nélküli, felülről lefelé elemzések egyik gyakran alkalmazott módszere, melynek lényege, hogy:

A grammatika szimbólumaihoz eljárásokat rendelünk

Majd az elemzés közben a rekurzív eljárásokon keresztül

A programnyelv implementációja valósítja meg az elemző vermét és a veremkezelést.

[1]. Legyen egy G grammatika a következő:

G=({S, E, E', T, T', F}, {+, *, (,), i, #}, P, S)

ahol a helyettesítési szabályok:

S -> E#
E -> TE'
E' -> +TE' | e
T -> FT'
T' -> *FT' | e
F -> (E) | i

Mely alapján generálhat Pl.: a következő szintaktikusan helyes mondat

i + i * i

Az i + i * i mondat szintaxisfája

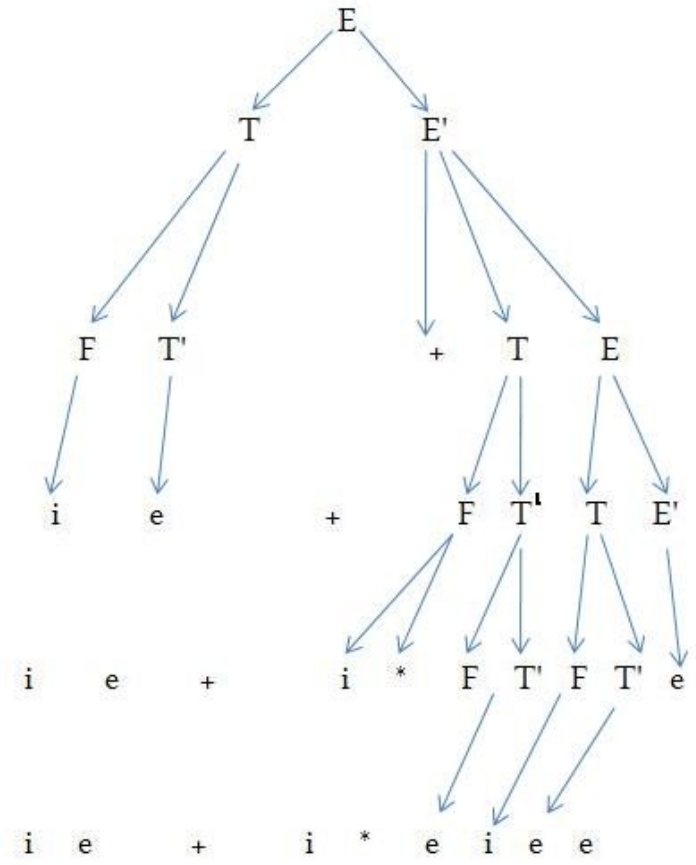

A grammatika szabályai:

S -> E#
E -> TE'
E' -> +TE | e
T -> FT'
T' -> *FT' | e
F -> (E) | i

Elemző eljárásai

Az elkészíthető eljárások a következők:
A terminális szimbólumok vizsgálatának eljárása:

```
elfogad(szimbólum)
{
  if (aktualis_szimbolum == szimbolum)
    kovetkezo_szimbolum(); else error();
}
```

eljárást, ahol az aktualis_szimbólum globális változó és a terminális soron következő elemével.
A kovetkezo_szimbolum() az az eljárás, mely meghívja a lexikális elemzőt, vagyis a következő elemet az aktualis_szimbólum változóba tölti.
A visszatérési érték lehet a következő szimbólum, vagy hibajelzés.

A grammatika minden szabályához rendelünk egy eljárást. Pl.: az A szabályhoz tartozó eljárás a következő:

```
A()
{
  T(A);
}
```

A T(A) meghatározása mindig az A-ra vonatkozó szabályoktól függ.

S -> E#
E -> TE'
E' -> +TE | e
T -> FT'
T' -> *FT' | e
F -> (E) | i

T(A) ->

1. A -> a szabályhoz az **elfogad(a)** eljárást
2. A -> B szabályhoz a **B()** eljárást
3. A -> X1, X2,..,Xn szabályhoz a következő blokkot:

```
{
  T(X1);
  T(X2);
  ...
  T(Xn);
}
```

Egyébként

```
választ aktuális_szimbolum
        {
          elso(X1): T(X1);
          elso(X2): T(X2);
          ...
          elso(Xn): T(Xn);
          koveto(X): skip;
        }
```

{Elso} es {koveto} halmazok lsd.: később.

Az elemző programja tehát:

```
S()
{
  E();
  elfogad('#');
}

E()
{
  T();
  E'();
}

E'()
{
  valaszt aktualis szimbolum
        {'+'}:{
                elfogad('+');
                T();
                E'();
              }
        {')','#'}: skip;
}

T()
{
  F();
  T();
}
```

Kov.:

```
T'()
{
  valaszt aktualis_szimbolum
        {'*'}:{
                elfogad('*');
                F();
                T();
            }
        {'+',')','#'}: skip;
}

F()
{
  valaszt aktualis_szimbolum
        {'('}:{
                elfogad('(');
                E();
                elfogad(')');
            }
        {'i'}: accept('i');
}
```

Az elemző főprogramja a grammatika kezdő szimbólumához tartozó eljárás, vagyis az

```
S();
```

LL(k) elemzők

[1] Ha A -> a ∈ P, akkor az xAß mondatforma legbaloldalibb helyettesítése xaß, azaz

xAß => xaß (legbal).

[2] Ha az S => x (X ∈ T*) levezetésben minden helyettesítés legbaloldalibb helyettesítés, akkor ezt a levezetést legbaloldalibb levezetésnek nevezzük.*

S => x (legbal).*

[1] Ha S =>* xa =>* yz (a *∈(N U T)*, x, y, z ∈ T**) és |x| = |y|, x = y

magyarázat:

A mondatforma bal oldalán a terminálisokból álló x sorozatot a környezetfüggetlen nyelvtan helyettesítési szabályai nem változtatják meg.

Ezt kezdőszelet egyeztetésnek hívják. Ha a szintaxisfa építésekor a bal oldali terminálisok nem egyeznek meg az elemzendő szöveg bal oldalán állókkal, akkor a fa építése rossz irányba halad. Ekkor vissza kell lépni.

Az ilyen visszalépéses algoritmusok alkalmazása rendkívül költséges.

Alapfogalmak

[1], [2] LL(k) nyelvtanok alaptulajdonsága:

Az S =>* wx legbaloldalibb levezetés építése során eljutunk a S =>* wAß mondatformáig és az Aß =>* x -t szeretnénk elérni, akkor az A ra alkalmazható *A -> a helyettesítést egyértelműen meghatározhatjuk az x első k db szimbólumának előre olvasásával.*
(Ekkor és csak ekkor LL(k) nyelvtanról beszélhetünk.)

Erre megadható az *Első k* függvény.

Első k(a) legyen az a-ból (k >= 0, a ϵ (N U T)*) levezethető szimbólumsorozatok k hosszúságú kezdő terminálisainak halmaza. (Elsők(x) az x első k db szimbólumát tartalmazza)

Pl.:
LL(1) nyelvtan:

G = ({A, S}, {a, b}, P, S), ahol a
P = S -> AS | ε
A -> aA | b

Az S szimbólumra az S->AS szabályt kell alkalmazni, ha az elemzendő szövegben a, vagy b a következő elem, és S->ε, *ha ha a következő szimbólum a # (végjel).*

Alapfogalmak

Az LL(k) elemzéseknél nem elég csak a szabályokat vizsgálni. Ha pl.: van az A-ra egy

A -> ε

szabály, akkor az Elsők halmazokban a B-ből származó terminális sorozatok k hosszúságú kezdő szimbólumai is szerepelnek. ezért a nem mindig véges számú levezetéseket is figyelembe kell venni.

Gyakorlati módszer csak az LL(1) nyelvtanokra létezik.

Szükség van egy Követők függvény definiálására, mely megadja a szimbólumsorozatot követő k hosszúságú terminális sorozatok halmazát.:

Követő(A) (A ϵ N) tehát azokat a terminális szimbólumokat tartalmazza, melyek a levezetésben közvetlenül az A után állhatnak.

Mind az Elsők, mind a Követők halmazok meghatározására létezik gyakorlatban használható algoritmus. [2]

Táblázatos elemzés

[1] Az elemzendő terminális sorozat xay, ahol az x szöveget már elemeztük.

Felülről lefelé legbaloldalibb helyettesítéseket alkalmazunk, szintaktikus hibát nem találtunk, így az elemezendő mondatformánk **xYa**, azaz vagy:

(1.) **xBa** vagy,

(2.) **xba** alakú.

(1.) a szintaxisfa építésekor a B-t kell helyettesítenünk egy B -> ß szabállyal amelyre igaz, hogy (a ∈ Első(ß Követő(B))).
Ha van ilyen szabály, akkor pontosan egy van (mivel LL(1) a nyelvtan), különben szintaktikai hiba helyét detektáltuk.

(2.) a második esetben a mondatforma következő szimbóluma a b terminális jel, tehát az elemzendő szövegben is b-nek kell szerepelnie.
Ha így van, továbblépünk, ha nem, akkor szintaktikai hiba helyét detektáltuk.

Elemző működése

[1],[2] Az elemző állapotait egy

(ay#, Xa#, v) hármassal írjuk le, ahol a

jel az elemzendő szöveg vége és a verem alja,

ay# a még nem elemzett szöveg,

Xa# az elemzendő szöveg mondatformájának még nem elemzett része, ez van a veremben,

v a szabályok sorszámát tartalmazó lista.

A helyettesítési szabályokat megszámozzuk. Az elemzés során alkalmazott szabályok sorszámát a v listában tároljuk.

Az elemzés során mindig a verem tetején lévő X szimbólumot hasonlítja össze a még nem elemzett szöveg következő szimbólumával (a-val). Az a-t aktuális szimbólumnak nevezzük.

Kezdőállapot: (xay#, S#, ϵ)

Az elemzés egy T elemző táblázattal végezhető el. A T táblázat kitöltésére megfelelően gyors és jól használható algoritmusok léteznek.

Az elemző táblázata

T[X, a] = {	(B,i)	ha X->B a E Első(B) vagy (e E Első(B) és a E Követő(X)).
	pop	ha X = a,
	elfogad	ha X = # és a = #,
	hiba	egyébként.

Az elemző algoritmusa

Az elemző működése állapotátmenetekkel adható meg. A kezdeti állapot (x#, S#, ϵ). Sikeres befejezésnél a végállapot (#, #, w).

Ha a még nem elemzett szöveg az ay#, és a verem tetején az X szimbólum áll, az állapotátmenetek a következők:

(ay#, Xa#, v)->{	(ay#, Ba#, vi)	ha T[X,a]=(B,i),
	(y#, a#, v)	ha T[X,a]=pop.
	OK.	ha T[X,a]=elfogad
	HIBA	ha T[X,a]=hiba

LL(1) elemzés:
algoritmus...

Példa táblázatos elemzésre

Rekurzív leszállás módszere

A Rekurzív-Leszállás módszere balról jobbra elemzi a szöveget, úgy, hogy nyelvtan szabályait eljárásokkal implementálja és a verem kezelését, valamint a rekurzív hívásokat a programnyelv implementációjára bízza.

Minden szabályhoz egy eljárást rendel:

```
S -> T
T -> ...

Procedute S
{
 T()
}

Procedure T{...}
...
```

A nyelvtan kezdő szimbólumához rendelt eljárás mindig az elemző főprogramja, mely elindítja a rekurzív hívásokat.

A módszert a fentről lefelé elemzés és a rekurzív eljáráshívások miatt nevezik Rekurzív-Leszállás módszernek.

Kalkulátor példa (lexer)

```
%{
   #include <stdlib.h>
   void yyerror(char *);
   #include "y.tab.h"
%}
%%
[0-9]+     {
   yylval = atoi(yytext);return INTEGER;
              }
[-+\n]      return *yytext;
[ \t]  ; /* skip whitespace */
.       yyerror("invalid character");
%%
int yywrap(void)
{
  return 1;
}
```

Kalkulátor példa (parser)

```
%{
    int yylex(void);
    void yyerror(char *);
%}
%token INTEGER
%%
program:
    program expr '\n'       { printf("%d\n", $2); }
    |;
expr:
        INTEGER                 { $$ = $1; }
        | expr '+' expr         { $$ = $1 + $3; }
        | expr '-' expr         { $$ = $1 - $3; }
        ;
%%
void yyerror(char *s)
{
    printf("%s\n", s);
}
int main(void)
{
    yyparse();
    return 0;
}
```

Kibővített példa (lexer)

```
%{
   #include <stdlib.h>
   void yyerror(char *);
   #include "y.tab.h"
%}
%%
[a-z]       {
               yylval = *yytext - 'a';
               return VARIABLE;
            }
[0-9]+      {
               yylval = atoi(yytext);
               return INTEGER;
            }
   /* operators */
[-+()=/*\n] { return *yytext; }
   /* skip whitespace */
[ \t]       ;
   /* anything else is an error */
.              yyerror("invalid character");
%%
int yywrap(void) {
   return 1;
}
```

Kibővített (parser)

```
%token INTEGER VARIABLE
%left '+' '-'
%left '*' '/'
%{
    void yyerror(char *);
    int yylex(void);
    int sym[26];
%}
%%
program:
        program statement '\n' |;
statement:
        expr                    { printf("%d\n", $1); }
        | VARIABLE '=' expr     { sym[$1] = $3; }
        ;
expr:
        INTEGER
        | VARIABLE              { $$ = sym[$1]; }
        | expr '+' expr         { $$ = $1 + $3; }
        | expr '-' expr         { $$ = $1 - $3; }
        | expr '*' expr         { $$ = $1 * $3; }
        | expr '/' expr         { $$ = $1 / $3; }
        | '(' expr ')'          { $$ = $2; }
        ;
%%
void yyerror(char *s) { printf("%s\n", s); }
int main(void) { yyparse(); return 0; }
```

Fordítás és output

```
yacc –d bas.y
        #létrehozza az  y.tab.hfájlt y.tab.c
lex bas.l
        #létrehozza a lex.yy.c
cc lex.yy.c y.tab.c –obas.exe
        # fordítás és linkelés
A kész exe: bas.exe

Futtatás: bas.exe
User: 3+2
Prg  : 5
User: 3 * (1 + 2)
Prg  : 9
```

Parser kibővítése (fájlból olvasás)

```
%token INTEGER VARIABLE
%left '+' '-'
%left '*' '/'
%{
   #include <stdio.h> //filekezeléshez
   #include <stdlib.h>
   int yyerror(char *s);
   int yylex(void);
   int sym[26];
%}
%%
```

A köztes rész marad az eredeti

```
int main ( int argc, char *argv[] )
{
    extern FILE *yyin;
    ++argv;--argc;
    yyin=fopen( argv[0], "r");
    yyparse();
    printf("Parse Completed\n");
    return 0;
}
```

BNF – Implementációja

```
program : LET declarations IN commands END;

declarations: type id_seq;

type: INT | FLOAT;
id_seq:
      IDENTIFIER                { setType($1, $0); }
      | id_seq ',' IDENTIFIER  { setType($3, $0); };

id_seq:
       | id_seq IDENTIFIER ',' ;

commands:
       | commands command ';' ;

command:  SKIP
       | READ IDENTIFIER
       | WRITE exp
       | IDENTIFIER ASSGNOP exp
       | IF exp THEN commands ELSE commands FI
       | WHILE exp DO commands END;

exp:    NUMBER
       | IDENTIFIER
       | exp '<' exp        {$$ = $1 < $3;}
       | exp '=' exp        | exp '>' exp
       | exp '+' exp        | exp '-' exp
       | exp '*' exp        | exp '/' exp
       | exp '^' exp        | '(' exp ')' ;
```

Fordítóprogramok

Gyakorlatok anyaga

Ismerkedés a programozási környezettel. Linux, C parancssorból, linux shell programozás. reguláris kifejezések programozása C#-nyelv reguláris kifejezéseinek (regexp) segítségével.

Input handler programjának elkészítése C#-nyelv reguláris kifejezéseinek (regexp) felhasználásával. Determinisztikus véges automata programja jegyzet alapján C# nyelven, regexp segítségével.

Rekurzív leszállás módszere Program szintaktikus elemzőre a példa alapján: Yacc/Lex bemutatása.

Saját teszt programnyelv megtervezése, szintaxis definiálása BNF segítségével. Lexer és parser készítése Lex/Yacc programmal.

Lexer és Parser összekapcsolása, kódgenerálás. Szimbólum tábla modul implementációja. Virtuális gép implementációja C nyelven.

Saját virtuális gép, szimbólum tábla, lexer és parser összekapcsolása egy programban, majd a fordítóprogram elkészítése.

Szintaktikus elemző LL(1), LR(1) gyakorlás. Szemantikus elemzők működésének vizsgálata, gyakorlás. Kód generálás, optimalizálás.

Felhasznált irodalom:

I. Csörnyei Zoltán, *Fordítóprogramok*, ELTE Budapest, 2005
II. Kása Zoltán, Csörnyei Zoltán, *Formális nyelvek és fordítóprogramok*, Babes-Boyai, Kolozsvár, 2007
III. Tom Nieman, *A compact Lex & Yacc* Portland, Oregon, epaperpress.com
IV. Anthony A., *Compiler Construction using Flex and Bison*, AabWalla Walla College April 22, 2005
V. Hernyák Zoltán, *Formális nyelvek és automaták*, EKF, Eger, 2001

Kódgenerálás

- Memóriagazdálkodás
- Kódgenerálás
- program prológus és epilógus
- értékadások fordítása
- kifejezések fordítása
- vezérlési szerkezetek fordítása
- Kódoptimalizálás

L-ATG

E -> TE'

E' -> + @StPushAX T @StPopBX @StAddBX E' | e

T -> FT'

T' -> * @StPushAX F @StPopBX @StMulBX T' | e

F -> (E) | i↑n @StLoadAX

Kódgenerálás

- A már elemzett kódból a fordítóprogram különböző módszerek felhasználásával előállítja a tárgykódot.
- A tárgykódot optimalizálni kell.
- A kódgenerálás feladatát un.: L-ATG grammatikával írjuk le.
- A generált kódok sok esetben assembly kódok INTEL 80x86 processzorra.

Memóriagazdálkodás

- Statikus memóriakezelés
- fordítási időbe ismerni kell minden programelem méretét
- a program végrehajtási idejében minden programelem csak egyszer szerepelhet.
- Dinamikus memóriakezelés
- ha a statikus memóriakezelés valamelyik feltétele nem teljesül.

Statikus memóriakezelés

- Már fordításkor meg kell határozni, hogy az adatok és az utasítások kódja hol helyezkedjen el a memóriában.
- Nem engedhető meg a változó hosszúságú adatok, pl.: dinamikus listák használata.
- Az egymásba ágyazott eljárások használata nem lehetséges. (nincs rekurzió...)

A program memóriaterülete

(((implicit paraméterek)(aktuális paraméterek)(változók))(utasítások))

- Implicit paramétermezők – szubrutinhívásokra (visszatérési cím, függvényértékek)
- Aktuális paraméterek – eljárások, függvények aktuális paraméterei
- Változók – a programban definiált változók, tömbök
- A változók címét könnyen ki lehet számítani, esetleg a fordítóprogram is tartalmazhatja.

Dinamikus memóriakezelés

<kódszegmens><adatszegmens><heap><stack>

- Kétfajta dinamikus memória létezhet
- Tetszőleges élettartamú – heap memóriában helyezkednek el.
- Skatulyázott élettartamú – runtime veremben helyezkednek el. (pl.: blokk struktúránál)

A blokkból kilépve a memória részlet elveszik.

Aktivációs rekord

- Az i-edik blokkhoz tartozó adatokat AR_i vagyis az i-edik aktivációs rekordnak nevezzük.
- A futó blokk rekordját aktív AR-nek.
- Három részből áll:
  - lokális változók
  - display terület
  - paraméterterület
- A fordítás és kódgenerálás során a változókat és a memóriát kezelni kell!

Kódgenerálás

- Assembly nyelvű kódra

  (egy adat, kód és veremszegmens használata esetén...)

- az adatszegmensbe kerülnek a globális változók
- a veremszegmensbe az alprogramok aktivációs rekordjai
- a kódszegmensbe a lefordított utasítások

Prológus és Epilógus

- Az ASM program neve a *program* szó után írt azonosító.

A lefordítandó forrásprogram a következő:

⟨program⟩ → program ⟨id⟩↑ @Prologue(↓v) ⟨block⟩ . @Epilogue

A @Prologue az ASM program kezdő sorait generálja, a @Epilogua a zárót.

name v ;@Prologue

doseg

.modell small

.stack 200h

end start ; @Epilogue

Típusdeklaráció és definíció

⟨típusdeklaráció⟩ → type ⟨id⟩↑ = ⟨típusdefiníció⟩ ↑d @TypeDecl(↓n,d)

- *@TypeDecl(↓n,d)* szemantikus rutin a szimbólumtáblát kezeli. n- névhez egy bejegyzést készít, majd ehhez kapcsolja a d típusdeszkriptort.

type a=set of integer;

type c=record ... end;

type class a{...}...

Konstansdeklaráció

pl.: constant real π = 3.1415

A fordító felírja a π szimbólumot a szimbólumtáblába

- attribútumként megadja, hogy π konstans
- a π típusa real
- a π értéke 3.1415

- A konstans deklaráció ekkor a következő:

Konstansdeklaráció

⟨konstansdeklaráció⟩ → constant ⟨típus⟩↑t ⟨id⟩ ↑n = ⟨kifejezés⟩↑s,v
@ConstDecl(↓n,t,s,v)

⟨típus⟩ → real ↑t

| integer ↑t

| boolean ↑t

- t, és n értékét a lexikális elemző határozza meg
- v a kifejezés értéke
- s a kifejezés típusa
- a @ConstDecl(↓n,t,s,v) ellenőrzi a t és az s típusok azonosságát, az n,t,s attribútumokból szimbólumtábla írást végez, majd a következő sort generálja (n number típus az ASM-ben):

n equ v ; @ConstDecl(↓n,t,s,v)

Változódeklaráció

- Változók lehetnek statikusak, vagy dinamikusak
- Statikus fordításkor, dinamikus futás közben értékelődik ki. A dinamikus változók fordításakor csak a típus deszkriptorának kell helyet foglalni.
- Egyszerű predefined változók deklarációja:

Példa típusdeklarációra

⟨változódeklaráció⟩ → ⟨típus⟩↑t,m ⟨id⟩ ↑n
@VarAlloc(↓n,m,q↑) @VarDecl(↓n,t,m,q)

⟨típus⟩↑t,m → real ↑t

| integer ↑t

| boolean ↑t

| karakter ↑t (⟨darabszám⟩ ↑t,m)

Kifejezés fordítása

E -> TE'

E' -> + @StPushAX T @StPopBX @StAddBX E' | e

T -> FT'

T' -> * @StPushAX F @StPopBX @StMulBX T' | e

F -> (E) | i↑n @StLoadAX

Generált kód az L-ATG alapján

2+j*(3+k)

```
mov     ax,2                    ; 2 @StLoadAX
push    ax                      ; + @StPushAX
mov     ax, j                   ; j @StLoadAX
push    ax                      ; * @StPushAX (
mov     ax,3                    ; 3 @StLoadAX
push    ax                      ; + @StPushAX
mov     ax,word ptr [bp]-2      ; k @StLoadAX
pop     bx                      ; @StPopBX
add     ax,bx                   ; @StAddBX )
pop     bx                      ; @StPopBX
imul    bx                      ; @StImulBX
pop     bx                      ; @StPopBX
add     ax,bx                   ; @StAddBX
```

IF fordítása

⟨if-utasítás⟩ → if ⟨kifejezés⟩ then ⟨utasítás1⟩ ⟨if-tail⟩

⟨if-tail⟩→ else ⟨utasítás2⟩ endif

| endif

az utasításból a következő kódok generálódnak:

```
<kifejezés>
Cmp     ax,0
jz      L_001
<utasítás1>
L_001
```

```
<kifejezés>
cmp     ax,0
jz      L_001
<utasítás1>
jmp     L_002
L_001
<utasítás2>
L_002
```

Kódoptimalzálás

- tömörítés : (ha az érték fordításkor ismert)
- a = b + 1 + c + 3 + 4; -> a = 8 + b + c; (tömörítés)
- a = 6; b = a / 2; c = b + 5 – a = 6; b = 3; c = 6; (konstanskiterjesztés)
- x = a + b; y = x; z = y; -> x = a + b; y = x; z = x; (továbbterjesztés)

Ciklusok optimalizálása

- Ciklus kifejtése:
- for i = 2 to 12 step 2 a[i,1] = 0; ->
- a[2,1] =0;
a[4,1] =0;
a[6,1] =0;
a[8,1] =0;
a[10,1] =0;
a[12,1] =0;
- A méret megnő, de a végrehajtás gyorsabb!

Ciklusok optimalizálása

- Frekvenciaredukálás:
  - for c:= 1 to 100 do
    begin
    a:=b;
    b:=2;
    ...
    end;

    a:=b;
    b:=2;
    for c:= 1 to 100 do
    begin
    ...
    end;
  - A két program nem ekvivalens!

Fordítóprogramok
IV. rész
Szemantikai elemzés

Szemantikai elemzés

- A szintaktikus elemző felépítette a szintaxisfát.
- A szintaxisfa csomópontjaihoz attribútumokat rendelünk (a statikus szemantika alapján).
- Ezen attribútumok meghatározása és ezek konzisztenciájának vizsgálata a szemantikai elemzés feladata.
- Statikus szemantika, vagyis olyan tulajdonságokkal foglalkozik, melyek nem írhatóak le környezetfüggetlen nyelvtannal.

Szemantikus elemzők:
- vizsgált szemantikai tulajdonságok -

- változók deklarációja, hatáskör, láthatóság
- többszörös deklaráció, deklaráció hiánya
- operátorok és operandusok közti típuskompatibilitás
- eljárások és tömbök formális és aktuális paraméterei közti kompatibilitás
- túlterhelések egyértelműsége

Szintaktikus elemző emlékeztető

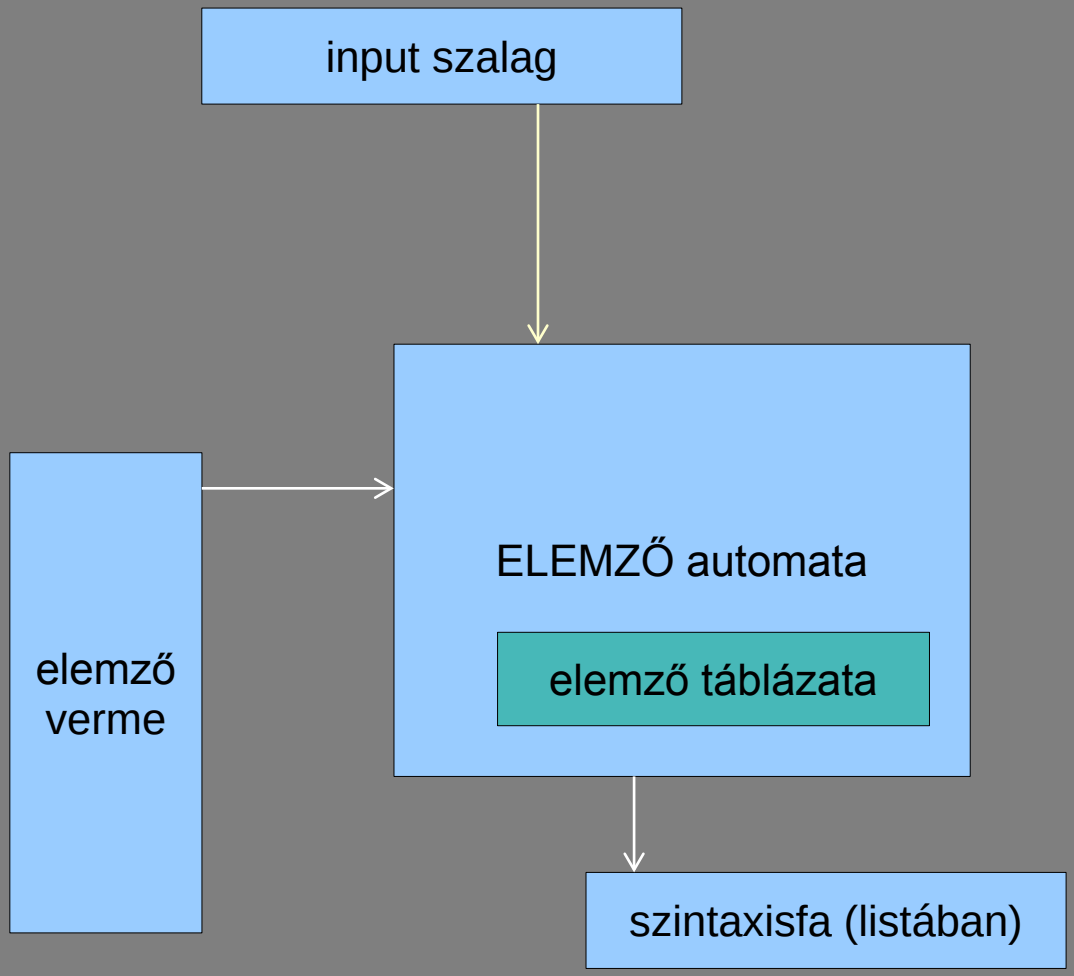

Szemantikus elemző

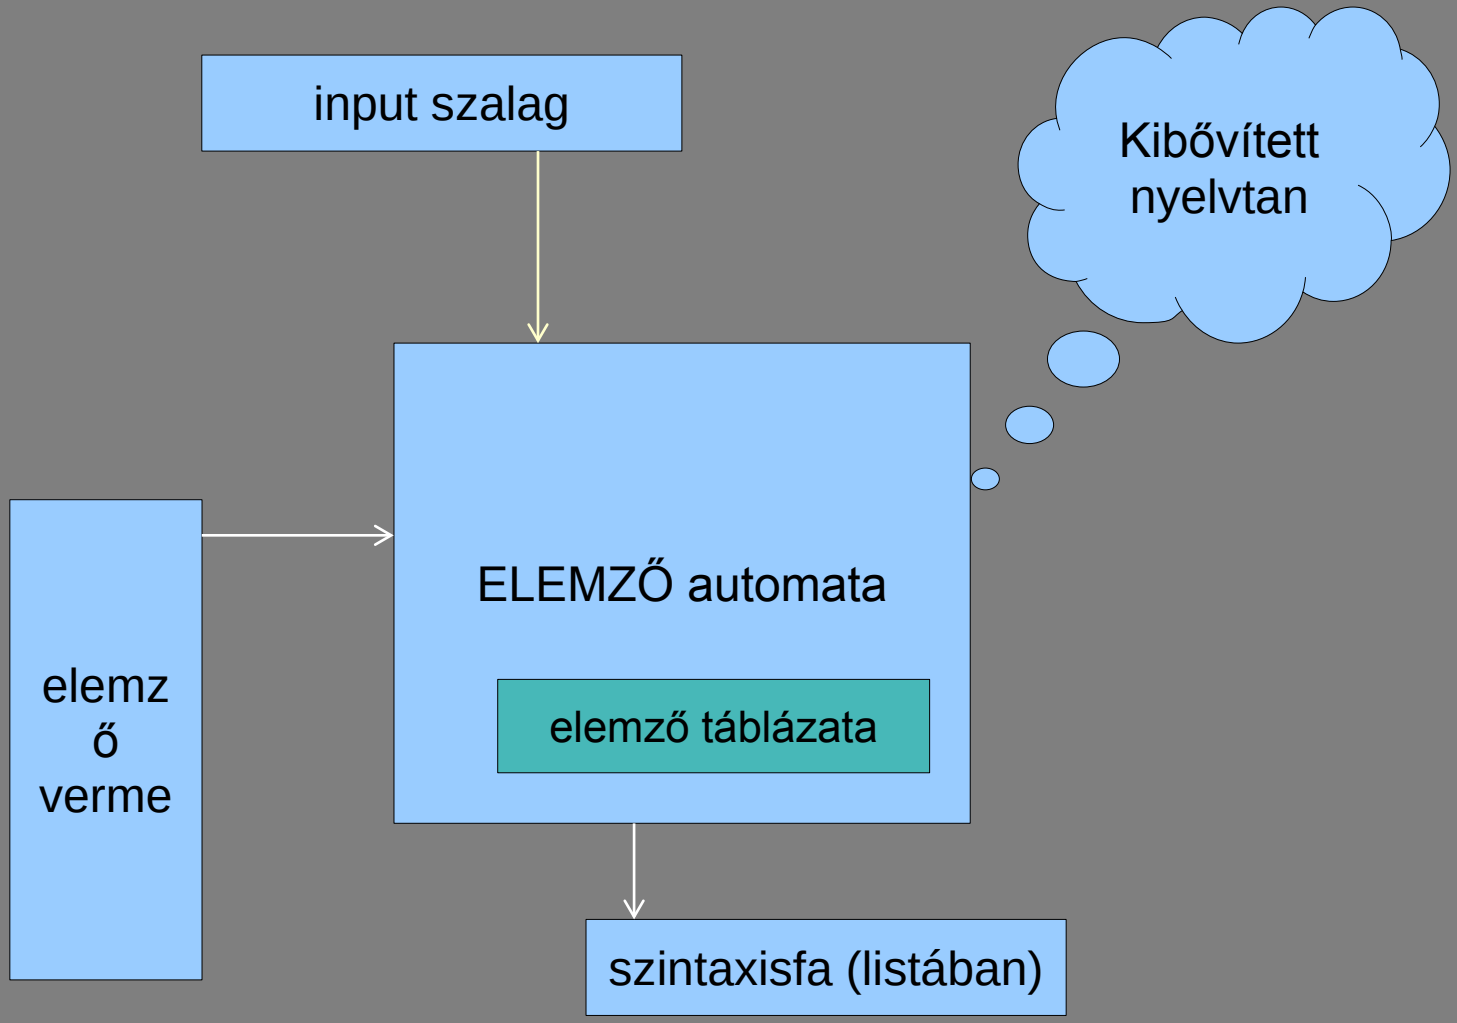

Szemantikus elemző

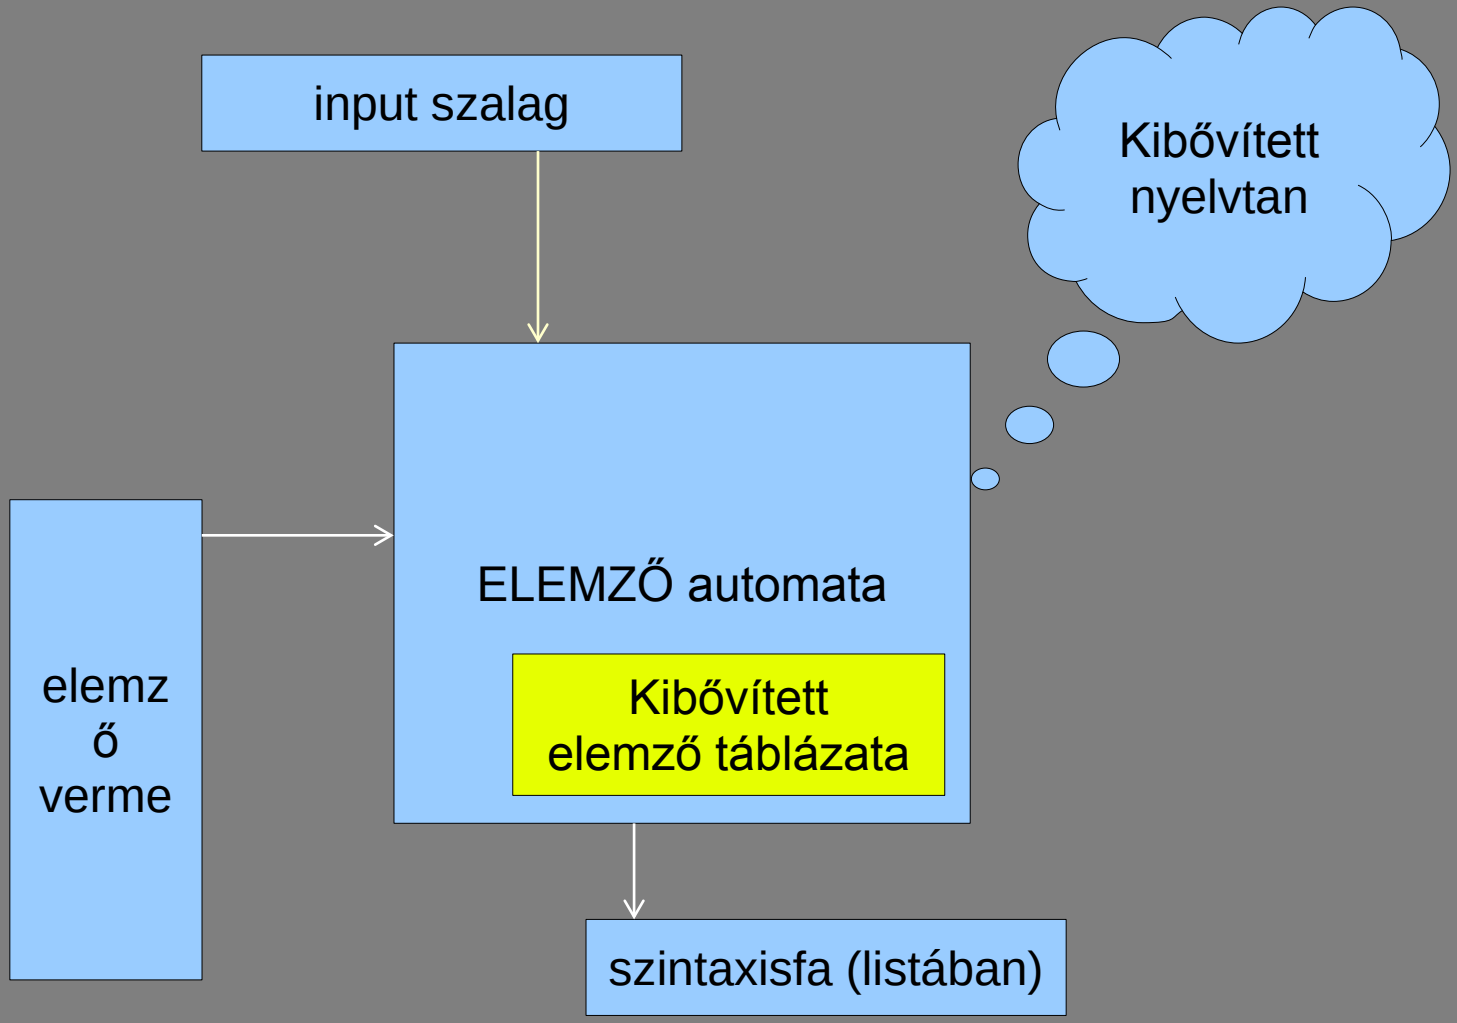

Szemantikus elemző

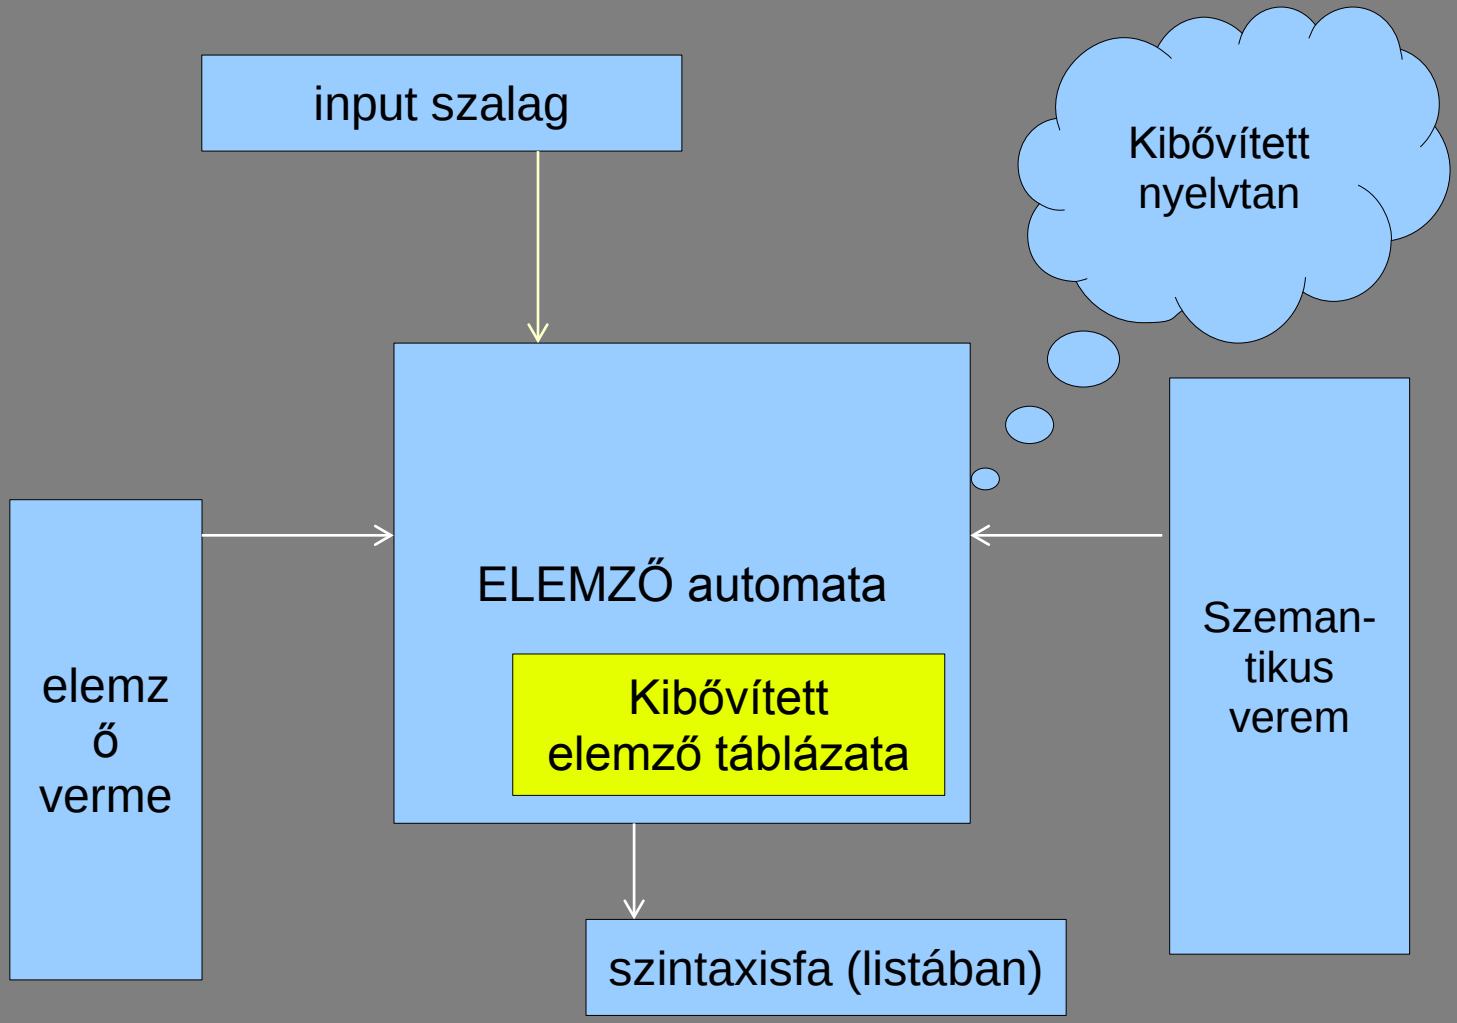

Szemantikai elemzők - megvalósítás

- Történtek kísérletek környezetfüggő nyelvtanok implementálására, de ezek lassúak és bonyolultak.
- A helyes módszer, hogy a szemantikai tulajdonságok vizsgálatára külön programokat készítenek
  - láthatóság()
  - hatókör()
  - egyéb()

Fordítási nyelvtanok

- A helyettesítési szabályokat un.: akciószimbólumokkal egészítik ki.
- A helyettesítések során ha egy ilyen szimbólumhoz érünk, az jelzi, hogy itt szemantikai vizsgálatot kell végezni, vagyis le kell futtatni az akcióhoz rendelt tevékenységet.
- pl.: @CheckType – ellenőrzi a ”szimbólum” típusát

Fordítási nyelvtanok

- Ha a szemantikai tevékenységet egy *proc* eljárás írja le, akkor ezt az eljárást szemantikai rutinnak nevezzük.
- Az eljáráshoz tartozó akciószimbólumot @proc-cal jelöljük.
- Ha egy G környezetfüggetlen nyelvtan szabályainak jobb oldalát akciószimbólumokkal egészítjük ki, akkor fordítási nyelvtannak nevezzük.

Példa fordítási nyelvtanra

a @S akciószimbólum az

S =>* a@sB =>* x

levezetésben a @s elérésekor meg kell hívni az s eljárást.

Az elemzés csak ennek a programelemnek a lefutása után folytatódhat.

Értékadás - példa

- Legyen az alap grammatika a következő:

<értékadó_utasítás> ::= <változó> = <kifejezés>

ebből a fordítási grammatika:

<értékadó_utasítás> ::= <változó> = <kifejezés>@CheckType

A @CheckType akciószimbólumhoz tartozó program a változó és a kifejezés típusának azonosságát vizsgálja.

Kibővített nyelvtan

(nem korrekt szintaktikával)

- S -> ifA
- A -> KC
- *K -> v1 = v2 helyett K -> v1 = v2 @CheckType*
- C -> A | D
- D -> thenUTASITAS
- UTASITAS -> end

Szemantikai elemzés problémái, szemantikus verem

- Az akciószimbólumokkal jelölt szemantikai rutinoknak nincsenek paraméterei.
- az akciókhoz rendelt metódusoknak meg kell találniuk a paramétereiket. Ezt a tulajdonságot be kell építeni a rutinokba.
- Megoldás: mivel a szintaktikai elemzők vermet használnak, célszerű a paramétereket is veremben tárolni.

Attribútum fordítási grammatikák

- A szemantikus verem helyett a nyelvtan szimbólumaihoz attribútumokat rendelnek.
- Ezen attribútumok továbbítják a szemantikus információt.
- Ebből a szemantikai elemző programja is generálható.

ATG

- Legyen TG egy fordítási nyelvtan!
- A nyelvtan akcióinak halmazát jelöljük @S-el!
- Jelölje X a nyelvtan tetszőleges terminális vagy nem-terminális szimbólumát! Vagyis

  $X \in T \cup N \cup @S$

- Legyen A egy véges, nem üres halmaz, az attribútumok halmaza!
- Minden X szimbólumhoz rendeljük hozzá A egy A(X) részhalmazát!

  Pl.: @s szimbólum s szemantikai rutinjához

  az A(@s) részhalmazt

ATG működése

- Ha az állítás a p szabály sorra-kerülésekor nem teljesül az A(p) attribútumaira, akkor az elemző hibát jelez.
- A C halmaz lehet üres is.
- Tehát a p szabályhoz tartozó szemantikai tulajdonságokat a C(p) kiértékelésével tudjuk ellenőrizni.

Összefoglalás

- Az A(TG, A, V, R, C) formális ötöst attribútum fordítási grammatikának nevezzük, ahol
- TG – egy tetszőleges fordítási nyelvtan
- A – az attribútumértékek halmaza (szemantikai rutinok paraméterei)
- (V – az attribútumértékek halmaza) nem tértünk ki rá részletesen
- R – szemantikai szabályok halmaza
- C – logikai értékek halmaza

  (p hez tartozó logikai állítások)