

Flex & Bison (Lex & YACC)

Kristo Heero

Lühidalt

- Flex – Skannerigeneraator. Konverteerib vastavalt koostatud lekseeme kirjeldavad regulaaravaldised C-programmiks, mis suudab tekstist leida kirjeldatud lekseeme (leksiline analüüs).
- Bison – Parserigeneraator. Konverteerib vastavalt kirjeldatud kontekstivaba grammatika C-programmiks, mis seda grammatikat parsida suudab (süntaktiline analüüs).

Flex

(Fast Lexical analyzer generator)

Kuidas kasutada?

Skanneri spetsifikatsioon

- stdin
- *.flex



FLEX



lex.yy.c

lex.yy.c
(libfl)



C kompilaator



a.out

Sisendvoog



a.out



lekseemide
jada

Skanneri spetsifikatsioon

definitsioonid

%%

reeglid

%%

kasutaja kood

Definitsioonide sektsioon

- Nime definitsioonid kujul: *name definition*

- Näiteks:

DIGIT [0-9]

- Nimi peab algama tähe või “_”-ga, millele võib järgneda tähed, “_”, numbrid ja ka “-”.
- Hiljem saab sellele nimele viidata kujul {nimi}.
- Näiteks:

FLOAT {DIGIT}+ “.” {DIGIT}*

- Saab lisada C-koodi, mis lisatakse genereeritava skanneri koodile.
- Peab olema %{ ja %} vahel või rea algusesse lisatud tühikuid/tabulaatoreid (taandega).
- Näiteks

```
%{  
#include <stdio.h>  
%}  
  
    int i = 0;
```
- Ka taandeta kommentaarid kujul /* */
kopeeritakse skanneri koodi.

Reeglite sektsioon

- Koosneb järjestikustest reeglitest kujul:

pattern action

- Näiteks:

```
[\\t ]+      putchar(' ');
```

```
[\\n]       ; //ignore
```

- Kui action koosneb mitmest reast, siis tuleb ta panna { } vahele.

- Analoogselt definitsiooni sektsiooniga saab siia lisada C-koodi, kuid ainult esimese reegli ette. Teistes kohtades olev kood küll kopeeritakse, kuid nende käsitus on määramata.
- Kasutatakse lokaalsete muutujate defineerimiseks ning koodi lisamiseks, mida täidetakse alati skanneerimismeetodi (**yylex()**) väljakutsumisel.

Kasutaja koodi sektsioon

- Selles sektsioonis olev kood lihtsalt kopeeritakse genereeritavasse skannerisse (mittekohustuslik sektsioon).
- Näiteks:

```
int main(void)
{
    yylex();
    return 0;
}
```

Mustrid läbi regulaaravaldiste

- `x` mätsib sümboliga 'x'
- `.` suvaline sümbol (*byte*) v.a. `"\n"`
- `[xyz]` sümbolite klass: 'x' | 'y' | 'z'
- `[^A-Z]` sümbolite klassi eitus
- `r*` 0-mitu r'i (r on regulaaravaldis)
- `r +` 1-mitu r'i
- `r?` 0-1 r'i
- `r{2,5}` 2-5 r'i
- `r{2, }` 2-mitu r'i
- `r{4}` 4 r'i

- {name} nime definitsiooni viide
- “[xyz]”foo” string [xyz]”foo
- \X kui X on ‘a’, ‘b’, ‘f’, ‘n’, ‘r’, ‘t’, ‘v’, siis ANSI-C interpretatsioon \x vastasel korral kasutatakse eritähenduse maha võtmiseks
- \0 NUL sümbol (ASCII kood 0)
- \123 sümbol 8-nd süsteemi koodis
- \x2a sümbol 16-nd koodis
- (r) prioriteedi määramine sulgudega
- r s konkatenatsioon
- r | s r või s

- r/s r , ainult siis, kui talle järgneb s
- $\wedge r$ r , ainult siis, kui ta on rea alguses
- $r\$$ r , ainult siis, kui ta on rea lõpus
ekvivalentne “ $r/\backslash n$ ”. Ettevaatust
DOS-i reavahetustega “ $\backslash r \backslash n$ ”
- $\langle s \rangle r$ r , kui ollakse starditingimuses s
- $\langle s1, s2, s3 \rangle r$ sama, kui ollakse ühes neist
- $\langle * \rangle r$ r suvalises starditingimuses
- $\langle \langle EOF \rangle \rangle$ EOF
- $\langle s1, s2 \rangle \langle \langle EOF \rangle \rangle$ EOF, kui vastavas starditing

- Sümbolite klassides ([a-z]) saab kasutada ka spets vahemikke (mis vastavad C funktsioonidele isalpha(), isblank(), ...).
- [:alnum:], [:alpha:], [:blank:], [:cntrl:], [:digit:], [:graph:], [:lower:], [:print:] [:punct:], [:space:], [:upper:], [:xdigit:]
- Näiteks:
[a-zA-Z0-9] = [[:alnum:]] = [[:alpha:]0-9]
- Mustris võib esineda ülimalt üks kord järgneva konteksti sümbol ‘/’ või ‘\$’.
- ‘^’ (ka <<EOF>>) peab esinema mustri alguses ja \$ lõpus, muidu kaotavad nad oma eritähenduse.

Sisendi mätsimine

- Mätsitakse mustri järgi, mis annab pikima lekseemi.
- Kui kaks (või enam) mustrit mätsivad sama pikka lekseemi, siis valitakse see muster, mis asub flex'i reeglikirjeldustes eespool.
- Mätsiv lekseem kirjutatakse globaalsesse muutujasse `char* yytext` ja tema pikkus globaalsesse muutujasse `int yyleng`. Vastava mustri aktsioon käivitatakse.

- Kui sisend ei mätsu, siis käivitatakse vaike-reegel: vaadeldud senine sisend prinditakse väljundisse (vaikimisi stdout) ja jätkatakse uue sümboliga sisendist edasi.
- Lihtsaim flex'i sisend on

%%

mis lihtsalt kopeerib sisendi sümbolhaaval väljundisse.

Aktsioonid

- Iga muster reeglite sektsioonis võib omada aktsiooni, mis võib olla suvaline C-kood.
- Kui mustril aktsioon puudub, siis vastava reegli poolt mätsitud lekseem heidetakse lihtsalt kõrvale.
- Näiteks:

```
int count = 0;

%%
[0-9]+      {      printf("INTEGER");
               count++;
            }

[ \t]+$    /*eemaldame realõppudest tühikud*/
```

- Kui aktsiooniks on '|', siis see tähendab, et aktsioon on sama, mis järgmisel reeglil.

...

dog |

cat |

cow count_animals++;

...

- Eksisteerib hulk direktiive, mida saab aktsioonides kasutada.
 - ECHO
kopeerib yytext'i skanneri väljundisse
 - BEGIN
määrab starditingimuse (vaatame hiljem)
 - REJECT
käsib skanneril protsessida “second best” reeglit.
(Kallis featuur, tõmbab kogu skanneri jõudlust alla!)

Näide:

Sisendi “abc” korral prinditakse “abcaba”

```
%%
```

```
a      |
```

```
ab     |
```

```
abc    ECHO; REJECT;
```

```
.\n    /* sööme ülejäänud sümbolid ära */
```

- **yymore()** – Järgmine mätsiv lekseem lisatakse **yytext**'ile otsa selle asendamise asemel.
- **yylless(n)** – **yytext**'i jäetakse mätsinud lekseemi n esimest sümbolit, ülejäänud pannakse sisendvoogu tagasi, kust neid reskaneeritakse. Kui $n = 0$ ja aktsioonis ei muudeta reeglite alustamistingimusi, siis võib tekkida lõpmatu tsükkel.
- **unput(c)** – Paneb sümboli 'c' tagasi sisendvoo algusesse. Hävitab **yytext** sisu. EOF'i ei saa tagasi panna.

- **input()** – Loeb sisendist järgmise sümboli.
- **yyterminate()** – Katkestab skanneri töö (meetodi **yylex()**) ja tagastab selle väljakutsujale 0'i, st. et “all done”.
Ka EOF-i korral kutsutakse see meetod vaikimisi välja.
- Aktsioonides võib modifitseerida ka **yytext** ja **yytext** väärtusi, kuid siis peab sellega arvestama vastavaid direktiive kasutades.

```

%%
“/*” {
    int c;
    for ( ; ; ) {
        while ((c = input()) != '*' && c != EOF)
            ;
        if (c == '*') {
            while ((c = input()) == '*')
                ;
            if (c == '/')
                break; //end of comment
        }

        if (c == EOF) {
            error(“EOF in comment”);
            break;
        }
    }
}

```

Genereeritud skanner

- Faili `lex.yy.c` luuakse skaneerimismeetod **`int yylex()`** ja lisaks veel muud vajalikku sodi.
- Nii kui `yylex()` meetod välja kutsutakse, siis hakatakse skanneerima lekseeme globaalsest sisendfailist **`FILE *yyin`** (vaikimisi `stdin`).
- Meetod jätkab seni, kuni saadakse EOF (tagastatakse 0) või tehakse mõnes aktsioonis `return`.
- Uuest `yylex()` meetodit välja kutsudes jätkatakse skaneerimist sealt, kus varem pooleli jäadi.

- Meetod **yyrestart()** heidab minema hetke sisendpuhvri ja hakkab uuesti sama sisendfaili skanneerima.
- Meetod **yyrestart(FILE *new_file)** on selle analoog, kus toimub ka sisendi vahetus. NB! Mõlemad meetodid ei initsialiseeri reeglite algustingimust.
- Vaikimisi pannakse väljund (ECHO, ...) faili **FILE *yyout** (vaikimisi stdout).

- Kui skanner jõuab EOF-ni, siis kontrollitakse funktsiooni **yywrap()** (saab ise kirjutada) tagastusväärtust edasi toimimiseks.
- Vaikimisi tagastab see 1, mispeale skanner lõpetab oma töö tagastades selle väljakutsujale 0'i.
- Kui yywrap() tagastab 0'i, siis eeldatakse, et yyin on saanud väärtuseks uue faili ning skaneerimine jätkub.
- Jällegi reeglite starditingimust ei initsialiseeita.
- Kui puuduvad main() ja yywrap() meetodid, siis tuleb skanner linkida libfl'ga, mis need loob.

Reeglite starditingimused

- Tegemist on skannerile defineeritud olekuteega, milles olles ainult vastavalt märgistatud reegleid pruugitakse.
- Skanneri olekud defineeritakse sisendi definitsioonide plokis kujul:

%s state1, state2

või

%x state3

Esimene on inklusiivne (st. lisaks aktiveeruvad need reeglid, mille ees ei ole stardiolekute märgistust) teine eksklusiivne starditingimus.

- Algolek on INITIAL.
- Olekuid saab muuta kasutades direktiivi BEGIN, mille argumendiks on uue oleku nimi.
- Näide mitmerealise kommentaari töötlemisest:

```
%x comment
```

```
%%
```

```
int line_num = 1;
```

```
“/*” BEGIN(comment);
```

```
<comment>[^\n]* //kõik v.a ‘*’ ja ‘\n’
```

```
<comment>”*”+ [^\n] //sööb ‘*’-d, kui ei järgne ‘/’
```

```
<comment>\n ++line_num;
```

```
<comment>”*”+”/” BEGIN(INITIAL);
```

Veel Flex'ist


- <<EOF>> kasutades peab aktsioonis olema, kas return, yyterminate() või yyin'ile omistatud uus sisendfail.
- Võimalus kasutada paralleelselt mitut puhvrit.
- Palju optsioone
 - i tõstutundetuks
 - d debugimise moodi (info stderr'i)
 - ...
- Hulga makrosid ja muid kasulikke vidinaid.

Flex'i integreerimine Bison'iga

- Bison kasutab lekseemide saamiseks meetodit **yytex()**, mis peab lekseemi panema muutujasse **yyval** ning tagastama lekseemi tüübi (int).
- Selleks, et Flex saaks kasutada Bison'i poolt defineeritud lekseemi tüüpe, tuleb include'da Bison'i poolt genereeritud header "**y.tab.h**".

Bison

Kuidas kasutada?



Bison'i grammatika fail

```
% {  
C-deklaratsioonid  
%}
```

Bison'i deklaratsioonid

```
%%  
Grammatika reeglid  
%%
```

Lisa C-kood

- Kommentaare `/* */` võib lisada igale poole.
- Teine `%%` pole kohustuslik, kui puudub lisa C-kood.
- Vähemasti üks grammatika reegel peab alati olema.

Grammatikareeglite süntaks

- Kirjutatakse stiilis:

```
expseq:    /* emty */
```

```
          | expseq1
```

```
          ;
```

```
expseq1:  exp
```

```
          | expseq1 ' , ' exp
```

```
          ;
```

- Eelistatud on vasak-rekursioon.

Keele semantika

- Igal keelekonstruktsioonil on olemas semantiline väärtus (Lekseemide eest hoolitses juba Flex väärtustades yylval muutuja).
- Vaikimisi on semantilise väärtuse hoidmiseks int tüüpi muutuja (`#define YYSTYPE int`).
- Selleks, et saaks kasutada mitut tüüpi korraga tuleb Bison'i deklaratsioonides defineeida `%union`, kus loetletakse üles kõik vajaminevad väärtused terminalidele ja mitteterminalidele:

```
%union {  
    int itype;  
    double dtype;  
}
```

Atsioonid

- Aktsioonideks on { ja } vahel olev C-kood, mis võib esineda reegli suvalises kohas ning mis ka täidetakse sinna jõudes.
- C-koodis saab viidata semantilistele väärtustele konstruktsiooniga \$n. Grupi enda semantiline väärtus on konstruktsioonis \$\$.
- exp: ...
 - | exp '+' exp
 - { \$\$ = \$1 + \$3; }

- Kui mõnel grupil puudub aktsioon, siis Bison eeldab vaikimisi, et $$$ = \1 .
- Kui on deklareeritud %union, siis saab eri väljade poole pöörduda stiilis: $\$<itype>1$.
- Flex'is analoogselt $yylval.itype = \dots$

Bison'i deklaratsioonid

- Kõik lekseemi-tüübi nimed (v.a. ühe-sümbolilised lekseemid: '+', '\n', ...) peavad olema deklareeritud %token abil:

%token ID NUMBER STRING ...

%token <itype> NUMBER

- Bison võtmega -d genereeribki nendest header faili ***.tab.h**, mida Flex kasutab.
- Vaikimisi on grammatika algussümboliks grammatika esimese reegli mitteterminal. Selle omavoliliseks määramiseks saab kasutada deklaratsiooni: **%start symbol**.

Parseri interface

- Bison genereerib meetodi **int yyparse()**. Selle meetodi väljakutsumine alustabki sisendi parsimist.
- Meetod tagastab 0, kui parsimine oli edukas ning vastasel juhul 1.
- Saab kasutada makrosid YYACCEPT ja YYABORT, mis annavad analoogselt sama tulemuse.
- Parsimisvea korral kutsutakse välja meetod **yyerror(char *)**, mis tuleb endal kirjutada.

Parseri abstraktne algoritm

- Vasakult paremale hakatakse sisendist lekseeme nihutama stack'ile.
- Kui stackil n viimast elementi on mingi produktsiooni parem pool, siis teostatakse redutseerimine (stacki n elementi asendatakse produktsiooni vasaku poolega).
- Ja nii kuni sisend on otsas ning stackile on jäänud lõpuks algusproduktsiooni vasak pool.

- Bison'i genereeritud parser, aga ei redutseeri alati kohe, kui selleks võimalus avaneb. Sest selline käitumine on paljude keelte korral ebaadekvaatne.
- Seetõttu vaatab parser otsustamiseks ette järgmise lekseemi (look ahead 1).

Nihutamine/Redutseerimine konflikt

- Näide

if_stmt:

```
        IF expr THEN stmt
    |    IF expr THEN stmt ELSE stmt
    ;
```

- Parseri vaikekäitumine on see, et ta eelistab nihutamist redutseerimisele.
- Deklaratsiooniga **%expext n**, saab öelda antud konfliktide piiri, alates millest konflikte teavitatakse.

- Näide:

```
expr:      expr '-' expr
        |      expr '*' expr
        |      '-' exp %prec UMINUS
        ;
```

“ $x + y * z$ ”, “ $x - y - z$ ”

- Deklaratsioonidega %left, %right, %nonassoc abil saab määrata assotsiatiivsust ning nende paiknemise järjekorra järgi ka prioriteeti:

%left '+' '-'

%left '*' '\'

%left UMINUS

Redutseerimine/Redutseerimine konflikt

- Näide:

```
exp1:    exp2
        |  ID
        ;
```

```
exp2:    ID;                “name”
```

- Grammatika ei ole pööratav, konflikt tuleks elimineerida.
- Parseri vaikekäitumine on see, et valitakse nimekirjas esimene produktsioon.

Veel

- Optionid:
 - t debugimis režiimi (info stderr'i)
 - d header fail flex'ile
 - ...
- Igasugu kasulikke pudinaid on veel.