

YACC

(Yet Another Compiler - Compiler)

YACC

- Yacc program obezbedjuje generalni softverski alat za složene strukture ulaza.
- Korisnik yacc-a priprema specifikacije ulaznih struktura. Specifikacije sadrže:
 - Gramatička pravila koja opisuju ulazne strukture
 - Akcije koje se izvršavaju kada je prepoznata struktura usaglašena sa datim pravilom

Parser

- **yacc** program generiše funkciju za kontrolu ulaznih struktura.
- Ova funkcija se zove *parser* i ona poziva leksički analizator koji prepoznaje i selektuje tokene iz ulaznih struktura.
- Tokeni su organizovani u saglasnosti sa gramatičkim pravilima pomoću kojih je opisana struktura ulaza.
- Kada se prepozna neko pravilo, izvršavaju se akcije koje su u specifikaciji pridružene prepoznatom pravilu.

Yacc pravila

- Ulazna specifikacija je kolekcija gramatičkih pravila.
- Svako pravilo opisuje neku ulaznu strukturu i daje njeno ime. Na primer, izgled jednog gramatičkog pravila je:
`datum : ime_meseca '/' dan '/' godina;`
- `:` i ; nemaju značaja u kontrolisanju ulaza, nego čine sintaksu samog pravila, a `'/'` se tretira kao literal u ulaznoj strukturi.
- `datum, ime_meseca, dan i godina` reprezentuju strukture od značaja u ulaznom procesu i mogu se definisati u samom yacc-u ili u lex-u.
- ulazna struktura: `januar / 19 / 1992` – usaglašena je sa datim gramatičkim pravilom.

Yacc pravila

- ime_meseca se može definisati u yacc-u pomoću sledećeg gramatičkog pravila:
`ime_meseca : 'j' 'a' 'n' 'u' 'a' 'r';
ime_meseca : 'f' 'e' 'b' 'r' 'u' 'a' 'r';
...
ime_meseca : 'd' 'e' 'c' 'e' 'm' 'b' 'a' 'r';`
- Leksički analizator treba samo da prepozna pojedinačna mala slova, a *ime_meseca* je neterminalni simbol koji prepozna yacc.
- Obično leksički analizator prepoznaime meseca i vraća *ime_meseca* kao token u yacc.
- Karakteri literali kao što je '/' u našem primeru, mogu se pomoći lex-a vraćati u yacc kao tokeni.

YACC specifikacija

- Specifikacija yacc-a sastoji se iz tri sekcije:
Sekcija deklaracija
%%
Sekcija pravila
%%
Sekcija potprograma
- Sekcija pravila je obavezna, druge dve su opcione.
- Blankovi, tabulatori i newlines se ignorišu, ali se ne mogu uključiti u neko ime.

Sekcija deklaracija

- Sekcija deklaracija sadrži dve sekcije: sekcije C-deklaracija i sekcije yacc deklaracija.

```
%{  
    /* sekcija C deklaracija */  
}  
/* sekcija yacc deklaracija */  
%%
```

Sekcija pravila

- Sekcija pravila se sastoji iz jednog ili više gramatičkih pravila i svako pravilo je oblika:
 $A : TELO;$
gde A reprezentuje neterminalni simbol, a $TELO$ reprezentuje niz od nula ili više imena i literala.
- Ime se formira od slova, cifara, tački i donje crte, ali prvi znak mora biti slovo.
- Imena koja se koriste u telu gramatičkog pravila mogu reprezentovati tokene ili neterminalne simbole.
- Znakovne konstante stavljaju se u jednostrukе znake navoda, a svi specijalni znaci programskog jezika C razumljivi su i yacc-u.

Sekcija pravila

- Ako u telu postoji više gramatičkih pravila, onda se za njihovo razdvajanje koristi '|'; na primer:

A : B C D
| E F
| G ;

- Ekvivalentni zapis bez navodjenja '|' je:

A : B C D ;
A : E F ;
A : G ;

- Ako neterminalnom simbolu odgovara prazan string, onda se to zapisuje pomoću gramatičkog pravila:

empty : ;

Imena

- Imena koja reprezentuju tokene moraju biti deklarisana, i to u sekciji yacc deklaracija:
%token <ime-1> <ime-2> ...
- Neterminali se deklarišu pomoću ključne reči **%type**.
- Startni simbol ima posebno značenje. Po default-u, startni simbol nalazi se na levoj strani prvog gramatičkog pravila u sekciji pravila.
- U sekciji deklaracija eksplicitno se deklariše startni simbol i to korišćenjem rezervisane reči **%start**.
%start <ime-simbola>

Semantičke akcije

- Svakom gramatičkom pravilu može se pridružiti akcija koja se izvršava kada se prepozna gramatičko pravilo.
- Akcije mogu da vraćaju vrednosti i dobijaju vrednosti vraćenih pomoći prethodnih akcija.
- Akcije su instrukcije programskog jezika C.

Semantičke akcije

- Znak \$ se koristi za komunikaciju izmedju parsera i akcija.
- Pseudo-promenljiva \$\$ reprezentuje semantički neterminal koji se nalazi na levoj strani gramatičkog pravila
- Za označavanje vrednosti vraćenih pomoći prethodnih akcija, akcija može da koristi pseudo-promenljive \$1, \$2, ... , \$n. Na ovaj način se referencira na vrednosti vraćene pomoći komponenti 1 do n koje se nalaze na desnoj strani pravila.

Primeri

- Kada parser prepozna gramatičko pravilo **prvi**, pomoću semantičke akcije $\$\$=1$ neterminalu **rezultat** dodeljuje se vrednost 1.

rezultat : prvi

{ $\$\$ = 1;$ };

- Ako je dato gramatičko pravilo:

rezultat : prvi drugi treći ;

onda $\$2$ sadrži vrednost neterminala **drugi**, a $\$3$ vrednost neterminala **treći**.

Primeri

- U pravilu:

expr : '(" expr ')';

prva komponenta je literal, tj. **'('**, pa je logički rezultat:

expr : '(" expr ')'

{ $\$\$ = \$2;$ }

;

Primeri

- Yacc program dozvoljava pisanje akcije i u sredini nekog pravila, a ne kao u prethodnom primeru - na kraju pravila:

```
A : B  
{$$ = 1;}  
C  
{ x = $2;  
y = $3; } ;
```

x dobija vrednost 1, a y dobija vrednost koja je vraćena pomoću C.

Akcija \$\$ = 1 vraća vrednost 1, a toj vrednosti mogu preko \$ mehanizma da pristupe i akcije koje se nalaze desno od navedene akcije; u našem primeru to je akcija x = \$2; .

Promenljive

- Korisnik može da definiše i druge promenljive koje se koriste u akcijama.
- Deklaracija takvih promenljivih vrši se u sekciji C deklaracija.
- Ove deklaracije imaju globalni doseg, tako da su poznate svim akcijama u yacc-u.

Pravila prednosti i asocijativnosti kod aritmetičkih izraza

- Gramatičko pravilo:

izraz : izraz '-' izraz

je uobičajeni način specificiranja aritmetičkog izraza.

- Ako je ulaz :

izraz - izraz - izraz

onda navedeno pravilo može da strukturiра ulaz na dva načina:

(izraz - izraz) - izraz	leva asocijativnost
izraz - (izraz - izraz)	desna asocijativnost

Pravila prednosti i asocijativnosti kod aritmetičkih izraza

- Da bi se razrešio navedeni problem, uvode se pravila prednosti zajedno sa informacijama o levoj ili desnoj asocijativnosti.
- Za označavanje asocijativnosti uvode se sledeće ključne reči:

%left i %right

- Iza navedenih ključnih reči sledi lista tokena. Svi tokeni koji se nalaze u istom redu imaju istu prednost i asocijativnost. U sledećem primeru dat je opis prednosti i asocijativnosti četiri aritmetičke operacije:

%left '+' '-'

%left '*' '/'

Pravila prednosti i asocijativnosti kod aritmetičkih izraza

- Za promenu prednosti koristi se klučna reč **%prec**. Na primer,
izraz : '-' izraz %prec '*'
ovo pravilo specificira da unarni minus ima istu
prednost kao i operacije množenja *.

Rekurzivna pravila

- Pravilo oblika leve rekurzivne gramatike je oblika:

```
ime_pravila : ime_pravila ostatak_pravila
```
- Veoma često se koriste sledeća pravila za pisanje specifikacija nizova i listi:

```
lista   : clan
        | lista ',' clan ;
niz     : clan
        | niz clan ;
```
- U svakom od ovih slučajeva, prvo pravilo biće reducirano samo za prvi član; drugo pravilo biće reducirano za drugi i sve ostale članove.

Tipovi podataka u yacc-u

- Po default-u vrednosti koje vraća leksički analizator i akcije u yacc-u su celobrojnog tipa.
- Yacc program podržava i druge tipove.
- Yacc deklariše stek vrednosti kao uniju različitih tipova vrednosti.
- Korisnik deklariše uniju i pridružuje imena članova unije svakom tokenu i neterminalnom simbolu koji ima vrednost.
- Kada se vrednost referencira sa **\$\$** ili **\$n** konstrukcijom, yacc će automatski da ubaci odgovarajuće ime unije.

Tipovi podataka u yacc-u

- Deklaracija unije zadaje se u sekciji yacc deklaracija:

```
%union
{ <telo_unije> }
```
- Na ovaj način deklariše se yacc stek vrednosti i eksterna promenljiva **yyval** ima tip ekvivalentan uniji.
- Ako se yacc poziva sa **-d** opcijom, deklaracija unije kopira se u **y.tab.h** kao **yystype**.
- Kada je definisano **yystype**, imena članova unije moraju biti pridružena imenima terminala i neterminala.

Tipovi podataka u yacc-u

- Konstrukcija <ime> koristi se za označavanje imena članova unije.
- Ključna reč **%type** koristi se za deklarisanje neterminala, a tipovi neterminala odredjeni su imenima članova unije.

%type <ime> izraz

- Ime člana unije <ime> pridružuje se neterminalnom simbolu *izraz*.
- Ako ime člana unije sledi posle ključnih reči %token, %left, %right ili %nonassoc, onda se ime člana unije pridružuje tokenu. Na primer,

%left <ime> '+' '-'

vrednost koja se dobija pomoću tokena '+' ili '-' je tipa člana unije.

Tipovi podataka u yacc-u

- Ako postoji akcija unutar pravila, vrednost koja se dobija pomoću ove akcije nema a priori tip. U takvom slučaju, tip se može odrediti ubacivanjem imena člana unije izmedju <> neposredno posle prvog znaka \$.

Pravilo : aa

{ \$<interval>\$ = 3; }

bbb

{ fun (\$<interval>2); }

;

Obrada grešaka

- Obrada grešaka omogućena je preko ulazne specifikacije.
- U graničnim pravilima može se koristiti token error. Na primer, u pravilu oblika

start : error

parser, posle otkrivanja sintaksne greške, ostaje u stanju "ERROR"

- Ako se otkrije sintaksna greška kada je parser u stanju "ERROR", parser ne daje poruku o grešci i ulazni token se briše.
- Ako se token *error* ne specificira u gramatičkim pravilima, nakon otkrivanja sintaksne greške, prekida se proces čitanja ulaza.

Obrada grešaka

- Pravilo oblika

start : error ;

znači da kada parser otkrije sintaksnu grešku, tokeni koji slede posle otkrivene greške i prethode sledećoj tački_zarezu, jednostavno se odbacuju.

- Jedan drugi oblik error pravila koji se koristi u interaktivnim aplikacijama, dozvoljava ponovo unošenje reda posle otkrivanja greške., na primer

input : error '\n'

{ (void) printf ("Ponovo unos poslednje linije");}
input
{ \$\$ = \$4;};

Obrada grešaka

- Problem u ovom pristupu je što parser, posle otkrivanja greške, mora da obradi tri ulazna tokena, pre nego što utvrdi da su oni korektni.
- Ako ponovo uneseni red sadrži neku grešku u prva dva tokena, parser briše tokene i ne daje poruku o grešci.
- Poslednji primer može se napisati i na sledeći način:

```
input : error '\n'
{
    yyerror;
    (void) printf ("Ponovo unesi poslednji red");
}
input
{ $$ = $4;};
```
- Izraz yyerror vraća parser u njegov normalni mod. Token koji se vidi neposredno posle error simbola je ulazni token na kojem je otkrivena greška.

Translacija i izvršavanje Yacc-a

- Za dobijanje leksičkog analizatora u C-u:
lex <ime-prog-lex>.l
- Za dobijanje sintaksnog analizatora u C-u:
yacc -d <ime-prog-yacc>.y
gde je <ime-prog-yacc>.y datoteka koja sadrži yacc specifikaciju, a yacc generiše sintaknsni analizator u C-u, koji se nalazi u datoteci y.tab.c i header file y.tab.h
- Kompajliranje i linkovanje se vrši kao i za svaki drugi C program:
gcc -o <ime-prog> lex.yy.c y.tab.c -lfl

Primer

- Napisati yacc aplikaciju za celobrojnu aritmetiku.
Koristiti samo operacije +, -, *, / i unarni minus.
- Osnovna notacija za pisanje gramatičkih pravila
za aritmetičke izraze je sledeća:

izraz : izraz op izraz

izraz : unmin izraz

Lex specifikacija

```
%{  
#include <stdio.h>  
#include<string.h>  
#include "y.tab.h"  
extern int yyline;  
%}  
%%  
[0-9]+ { strcpy(yyval.name,yytext);  
          return(NUMBER);};  
\t ;  
\n yyline++;  
[^0-9] return(yytext[yylen-1]);  
%%
```

Yacc specifikacija – sekcija deklaracija

```
%{  
#include <stdio.h>  
#include <string.h>  
int yyline;  
int yylex();  
%}  
  
%start list  
%union {  
    int ival;  
    char name[32];}  
  
%token <name> NUMBER  
%type <ival> expr stat  
%left <ival> '+' '-'  
%left <ival> '*' '/'
```

Yacc specifikacija – sekcija pravila

```
%%  
list : stat;  
list : list stat;  
stat : expr ';' { printf("rezultat %d\n",$1); } ;  
expr : '(' expr ')' { $$=$2; }  
| expr '+' expr { $$=$1+$3; }  
| expr '-' expr { $$=$1-$3; }  
| expr '*' expr { $$=$1*$3; }  
| expr '/' expr { $$=$1/$3; }  
| '-' expr %prec '*' { $$=-$2; }  
| NUMBER { $$=atoi($1); } ;  
%%
```

Yacc specifikacija – sekcija potprograma

```
int yyerror(char *s){  
    printf("\n Greska %s u redu %d\n",s,yyline);  
}  
main(){  
    yyline=1;  
    if (yyparse()==0) printf("\n Parsiranje uspesno zavrseno\n");  
    else printf("\n Parsiranje nije uspesno zavrseno\n");  
}
```