

情報科学実験II 第3回

コンパイルの4つのステップ

- 1、字句解析(lexical analysis)
- 2、構文解析(syntax analysis)
- 3、意味解析(semantic analysis)
- 4、コード生成(code generation)

ここに関係する話の続き

目標

- ・シンタックス(文法)ベースの考え方にさらに慣れる
- ・簡単なプログラミング言語のインタプリタを作る

lexとyaccの関係

「yyparseの中でcallするyylexをlexが自動生成する」という関係

→ y.tab.cにlex.yy.cを#includeしてコンパイルすればよい(普通は分割コンパイルしてリンクする)

→ 字句をどうやって共有するか? → yaccが定数(整数)を決める

yaccのファイル

```
%{
#include <stdio.h>
#include <stdlib.h>
#include <string.h>
%}

%token NUM
%token IF
%token
%}

中略

exp: NUM
    | exp '+' exp
    ;

$S = $1 + $3;
```

例) #define NUM 257
#define IF 258
#define ID 259

257まではASCIIで済む

lexのファイル

```
%{
#include <stdio.h>
int yywrap(void)
return 1;
%}

対応するトークンの番号を返すように記述すれば、yyparseでトークンを識別して構文解析できる
```

```
%{
[0-9]+ {
[0-9] *return NUM}
[ ] *return IF}
[a-zA-Z0-9]+ {return ID}
%}
```

if(stats版)の例

yaccソースファイル

```
%{
#include <stdio.h>
}%

%token IF
%token LPAR
%token RPAREN
%token INC
%token ID
%token SC

%
stats:  stat
      | stats stat
      ;

stat:  IF LPAR expr RPAREN stat
{ printf("if\n"); }
  | expr SC
  ;

expr:  ID
      | ID INC
      ;
```

lexソースファイル

```
%C
"if" {return IF;}
[n,v] {return ID;}
"(" {return LPAR;}
")" {return RPAREN;}
"++" {return INC;}
" " {return SC;}
[^\n] {}
{ printf("ignored.\n"); }

%%
```

トークン(終端記号)

トークンの番号をreturnする

yaccソースファイル続き

```
%C
#include "lex.yy.c"
int main()
{
    return yyparse();
}

int yyerror(const char *s)
{
    printf("ERROR: %s\n", s);
    return 0;
}
```

lex.yy.cを#include

以下のようにコンパイル

```
$ lex xxx.l
$ yacc xxx.y
$ gcc y.tab.c -ll
```

includeすればマクロが共有できる。もしincludeしないなら、yaccで-yオプションをつけてコンパイルすると、マクロ定義のファイルy.tab.hを出力してくれるので、それをlex.yy.cからincludeすればよい。lexではyaccの方で定義を誤りやすい点に注意。

似て非なる用語の整理

字句・・・字句解析用語。文を構成する単なる「文字列」。
終端記号・・・文法用語。構文木の葉に現れる「記号」。
トークン・・・コンパイラ用語。終端記号とその「値」のペア。
例) "325"という字句は、終端記号NUMでその値が325

yaccが割り当てた定数とは無関係であることに注意

練習1 (lexとyaccの連携)

if(stats版)を入力して実行してみよ。還元成功すればifと表示されるが、それ以外はなぜそのようなメッセージが出力されるか考察せよ。

例1
if (n) v; (例1は改行)

例2
if(n)v;if (v)n;

例3
iff(n)v;

例4
if (n) ;

例5
foo

例6
foo;

式を入力したら
Check

練習2 (lexとyaccの連携)


if(stats版)をif elseに拡張せよ。if elseへの還元成功のメッセージは"if else"にする。
以下の入力について、なぜそのタイミングでメッセージが出力されるか考察せよ。

例1	例4
if (n) v; else v;	if(n)v;
例2	n
if (n) v;	;
続けて	
if (n) v;	
例3	
if(n)v;	
if(n)v;	
n;	

LALR(1)

(1)はトークンを1つ先読みしている、の意味

基本動作: 入力を左端から読んでいって(シフト)、規則の右辺の条件がそろったら左辺の非終端記号に置き換える(還元)。その際、トークンを常に1つ先読みし、確実に還元できることを確認している。もしif (n) n;で還元してしまうと、続けてelseが来たとき失敗する。そこで、if (n) n;の次のトークンを待って、elseありのifかelseなしのifかを判定している。



先の例4で、識別子nを入力したところで還元されたのは、nを受け取った所でelseなしであることが確定したから。

練習3 (lexとyaccの連携)

括弧つき四則演算の電卓プログラムを、lexを使ってトークンを取り込むように変更せよ。

練習4 (代入文)

括弧つき四則演算の電卓プログラムに変数を導入する。そのために、まず
a=3+5;
といった代入文を解析できるように文法を拡張せよ。

- ・代入の '=' はEQという終端記号に、';' はSCという終端記号にする。
- ・代入文を表す非終端記号はstatにする。
- ・stat = ~ { } といった規則により、statのアクション部分で代入された式の値を出力するようにせよ。
- ・変数名はaからzまでの26種類とし、IDという終端記号として正規表現に追加する。
- ・非終端記号lineは不要なので関連する規則を削除する。
- ・式の右辺で変数を使うことはとりあえず考えなくてよい。つまり、a=b+1;のような代入はここではまだ考えなくてよい。

構文解析器が正しいことを確認せよ。

例)
a=3+1;
3+1
4+5;
d=a+1;

練習5 (変数)

式の中で実際に変数を使えるようにする。例えば、
a=3+5;
のような代入の後、
b=a*2;
のような代入をしたい。以下の方針で文法を拡張せよ。

(方針)
int型の配列、int var[26]; を宣言し、アクションの中で代入すればよい。その際、[a-z] {yyval=yytext[0]; return ID;} のように、yytextの先頭のASCIIコードをそのままyyvalに代入すれば、トークンの値として\$xで受け取れる点に注意せよ。例えば、\$1に引き継がれた変数にアクセスするには、配列の添え字をvar[\$1-'a']とすればよいことに注意。

yylex()

例)
[a-z] のbにマッチしたとする

トークンIDの番号を関数yylexの値として返す。

yytextは正規表現にマッチした文字列要素をyytextに格納

yytext[0]='b'
yytext[1]
...
yytext[25]

代入
yyval

\$1

IDの値はyyvalとし、yytextに渡す

yyyparse()

例)
factor: ID {\$\$=var[\$1-'a'] }

「終端記号はIDです」

yylexから得たトークンの値を添え字にして配列にアクセスできる

変数
a
b
...
var[25]

配列
var[0]
var[1]
...
var[25]

練習6 (代入文)

このままでは、1つのstatしか処理できないので、複数の文(複文)をひとまとめにした非終端記号statsを追加して文法を拡張せよ。これにより、以下のような入力を受け付けるようになるようにせよ。

例)

以下続けて入力
a=3+1;
b=4-2*(5-4);
c=a+1;
d=a+b+c;

4と出力
2と出力
6と出力
11と出力

課題1 (出力)

以下のような、式の値を出力するprintf文()を追加せよ。

```
printf(3+5);
```

8

この段階で、以下のような記述ができるようになることを確認せよ。

```
a=3;
b=2;
c=a*b;
printf(b+c);
```

課題2 (pascal風に)

以下のような、pascal風の記述をするようにせよ。

```
program {
  a=3;
  b=2;
  printf(b+a);
}
```

課題3 (比較演算)

if elseを追加したい。そのために、比較演算を導入する。==、!=、<、>、<=、>= が使えるように式を拡張し、真のとき1、偽のとき0がその式の値となるようにせよ。