記号処理・第 6 回

2017 年 5 月 16 日

今回の内容

6.1 Minimum C コンパイラの字句解析部 6–1
6.2 演習問題 6–7

6.1 Minimum C コンパイラの字句解析部

Minimum C のトークンの文法を BNF 記法で表すと次のようなものとなります。⟨*TokenSeq*⟩ がソースプログラム全体を表す非終端記号です。ただし ⟨*White*⟩ は、スペース、タブ、改行などの制御文字を表すものとし、⟨*Any*⟩ は任意の文字を表すものとします。

⟨*Digit*⟩ ::= “0” | “1” | “2” | . . . | “9”.

⟨*Number*⟩ ::= ⟨*Digit*⟩ { ⟨*Digit*⟩ } .

⟨*Alphabet*⟩ ::= “a” | “b” | “c” | . . . | “z” | “A” | “B” | “C” | . . . | “Z” .

⟨*Ident*⟩ ::= ⟨*Alphabet*⟩ { ⟨*Alphabet*⟩ | ⟨*Digit*⟩ | “_” } .

⟨*Token*⟩ ::= “(” | “)” | “{” | “}” | “*” | “%” | “+” | “-” | “,” | “;” | “!” “=”
| “=” [“=”] | “<” [“=”] | “>” [“=”] | “/” [“*” { ⟨*Any*⟩ } “*” “/”]
| ⟨*Number*⟩
| “i” “n” “t” | “r” “e” “t” “u” “r” “n” | “i” “n” “p” “u” “t” | “p” “r” “i” “n” “t”
| “w” “h” “i” “l” “e” | “i” “f” | “e” “l” “s” “e”
| ⟨*Ident*⟩ .

⟨*TokenSeq*⟩ ::= { ⟨*White*⟩ } { ⟨*Token*⟩ { ⟨*White*⟩ } } .

字句解析部の仕事

この文法に基づいて Minimum C コンパイラの字句解析部を構築しますが、その仕事とは次のようなものです。

1. ソースファイル中の空白類の文字やコメント `/*` . . . `*/` は読み飛ばす。これらは、トークンとして構文解析部には渡されない。
2. 改行文字を数えながら、現在処理中の行がソースファイルの第何行目であるかを大域変数 `line` に保持する。この情報は、ソースプログラム中の文法間違いなどをコンパイラがユーザーに報告する際に用いられる。
3. ソースファイルの文字を 1 文字分先読みしながら、第 4 回で解説した構文解析の手法と同じ要領でトークンを切り出していく。
4. 切り出したトークンの種別を大域変数 `token` に格納する。
5. 識別子 ⟨*Ident*⟩ に対しては、そのトークンが予約語でないことを確認した上で、変数 `token` に `mc_ident` (識別子であることを表す定数) を格納するとともに、識別子の名前 (文字列) を大域変数 `ident` に格納する。

6. 定数 $\langle Number \rangle$ に対しては、token の値を mc_number (定数であることを表す定数) とし、それを十進数と解釈したときの数値を大域変数 number に格納する。

メモ

字句解析部のプログラム (scan.h と scan.c)

以下は Minimum C コンパイラの字句解析部のプログラムです。このプログラムの中心となる関数は GetToken() で、この関数が呼ばれるごとに、大域変数 token の値に読み込んだトークンの種別が格納されます。このプログラムで使われている strcmp() は、文字列を比較する標準ライブラリ関数で、2 つの文字列が同じであれば 0 を返します。

scan.h

```
 1 /*
 2  *      scan.h
 3  */
 4
 5 #define MC_MAXNUM    (((unsigned long)1<<31)-1) /* 定数の最大値 */
 6 #define MC_MAXIDLEN  (32)                       /* 識別子の最大長 */
 7
 8 typedef enum {
 9     mc_null,
10     mc_ident,           /* <Ident> (識別子) */
11     mc_number,          /* <Number> (定数) */
12     mc_mult,            /* * */
13     mc_div,             /* / */
14     mc_mod,             /* % */
15     mc_plus,            /* + */
16     mc_minus,           /* - */
17     mc_assign,          /* = */
18     mc_eq,              /* == */
19     mc_neq,             /* != */
20     mc_lt,              /* < */
21     mc_le,              /* <= */
22     mc_gt,              /* > */
23     mc_ge,              /* >= */
24     mc_comma,           /* , */
25     mc_semicolon,       /* ; */
26     mc_lparen,          /* ( */
27     mc_rparen,          /* ) */
28     mc_lcb,             /* { */
29     mc_rcb,             /* } */
30     mc_int,             /* int */
31     mc_return,          /* return */
32     mc_input,           /* input */
33     mc_print,           /* print */
34     mc_while,           /* while */
35     mc_if,              /* if */
```

```
36     mc_else,            /* else */
37     mc_eof              /* ファイルの終り */
38 } Token;
39
40 extern void             Error(char *);
41 extern void             GetToken(void);
42 extern int              OpenFile(char *);
43 extern void             CloseFile(void);
44
45 extern Token            token;
46 extern char *           ident;
47 extern unsigned long    number;
48 extern unsigned int     line;
49
```

メモ

scan.c

```
 1 /*
 2  *      scan.c
 3  */
 4
 5 #include <stdio.h>
 6 #include <stdlib.h>
 7 #include <string.h>
 8 #include "scan.h"
 9
10 Token           token;
11 char *          ident;
12 unsigned long   number;
13 unsigned int    line;
14
15 static FILE *   source;
16 static int      ch;
17
18 typedef struct {
19     char *      string;
20     Token       token;
21 } Keyword;
22
23 static Keyword keywords[] = {
24     {   "int",          mc_int          },
25     {   "return",       mc_return       },
26     {   "input",        mc_input        },
27     {   "print",        mc_print        },
28     {   "while",        mc_while        },
29     {   "if",           mc_if           },
30     {   "else",         mc_else         },
31     {   0,              mc_null         }
32 };
33
```

```
34 void Error(char *message)
35 {
36     fprintf (stderr, "第%d行: %s\n", line, message);
37     exit(1);
38 }
39
40 static void GetChar(void)
41 {
42     if (ch == EOF)
43         return;
44     if (ch == '\n')
45         line ++;
46     ch = getc(source);
47 }
48
49 static void Identifier(void)
50 {
51     static char buf[MC_MAXIDLEN+1];
52     int i = 0;
53
54     /* 識別子あるいは予約語を buf に読み取る */
55     do {
56         if (MC_MAXIDLEN <= i)
57             Error("識別子が長すぎます");
58         buf[i++] = ch;
59         GetChar();
60     } while ('0' <= ch && ch <= '9' || ch == '_'
61               || 'A' <= ch && ch <= 'Z' || 'a' <= ch && ch <= 'z');
62     buf[i] = '\0';
63
64     /* 予約語の表の中で検索 */
65     for (i = 0; keywords[i].string != (char *)0; i ++) {
66         if (strcmp(keywords[i].string, buf) == 0) {
67             token = keywords[i].token;
68             return;
69         }
70     }
71
72     /* 予約語でないので識別子 */
73     token = mc_ident;
74     ident = buf;
75 }
76
77 static void Number(void)
78 {
79     unsigned long n = 0;
80     int d;
81
82     do {
83         d = ch - '0';
84         if ((MC_MAXNUM - d) / 10 < n)
85             Error("定数値が大き過ぎます");
86         n = 10*n + d;
87         GetChar();
88     } while ('0' <= ch && ch <= '9');
89
90     token = mc_number;
91     number = n;
92 }
93
```

```
 94 static void Comment(void)
 95 {
 96     /* コメントの読みとばし */
 97     GetChar();
 98     do {
 99         while (ch != '*' && ch != EOF)
100             GetChar();
101         GetChar();
102     } while (ch != '/' && ch != EOF);
103     GetChar();
104 }
105
106 void GetToken(void)
107 {
108   again:
109     /* 空白の読みとばし */
110     while (ch <= ' ') {
111         if (ch == EOF) {
112             token = mc_eof;
113             return;
114         }
115         GetChar();
116     }
117
118     /* トークンの識別 */
119     switch (ch) {
120         case '(':       GetChar(); token = mc_lparen; break;
121         case ')':       GetChar(); token = mc_rparen; break;
122         case '{':       GetChar(); token = mc_lcb; break;
123         case '}':       GetChar(); token = mc_rcb; break;
124         case '*':       GetChar(); token = mc_mult; break;
125         case '%':       GetChar(); token = mc_mod; break;
126         case '+':       GetChar(); token = mc_plus; break;
127         case '-':       GetChar(); token = mc_minus; break;
128         case ',':       GetChar(); token = mc_comma; break;
129         case ';':       GetChar(); token = mc_semicolon; break;
130         case '!':       GetChar();
131                         if (ch != '=')
132                             Error("! の次は = でなければなりません");
133                         GetChar();
134                         token = mc_neq;
135                         break;
136         case '=':       GetChar();
137                         if (ch == '=') {
138                             GetChar();
139                             token = mc_eq;
140                         }
141                         else
142                             token = mc_assign;
143                         break;
144         case '<':       GetChar();
145                         if (ch == '=') {
146                             GetChar();
147                             token = mc_le;
148                         }
149                         else
150                             token = mc_lt;
151                         break;
152         case '>':       GetChar();
153                         if (ch == '=') {
```

```
154                             GetChar();
155                             token = mc_ge;
156                         }
157                         else
158                             token = mc_gt;
159                         break;
160         case '/':       GetChar();
161                         if (ch == '*') {
162                             Comment();
163                             goto again;
164                         }
165                         else
166                             token = mc_div;
167                         break;
168         case '0': case '1': case '2': case '3': case '4':
169         case '5': case '6': case '7': case '8': case '9':
170                         Number();
171                         break;
172         case 'A': case 'B': case 'C': case 'D': case 'E':
173         case 'F': case 'G': case 'H': case 'I': case 'J':
174         case 'K': case 'L': case 'M': case 'N': case 'O':
175         case 'P': case 'Q': case 'R': case 'S': case 'T':
176         case 'U': case 'V': case 'W': case 'X': case 'Y': case 'Z':
177         case 'a': case 'b': case 'c': case 'd': case 'e':
178         case 'f': case 'g': case 'h': case 'i': case 'j':
179         case 'k': case 'l': case 'm': case 'n': case 'o':
180         case 'p': case 'q': case 'r': case 's': case 't':
181         case 'u': case 'v': case 'w': case 'x': case 'y': case 'z':
182                         Identifier();
183                         break;
184         default:        Error("無意味な文字が現れました");
185                         break;
186     }
187 }
188
189 int OpenFile(char * filename)
190 {
191     source = fopen(filename, "r");
192     if (source == NULL)
193         return -1;
194     line = 1;
195     ch = ' ';
196     return 0;
197 }
198
199 void CloseFile(void)
200 {
201     fclose(source);
202 }
```

メモ

6.2 演習問題

1. ⟨*TokenSeq*⟩ の文法は、コメント `/*...*/` に関する曖昧性を持っていることを示しなさい。また、例えば次の文字列が、実際にはどのような ⟨*Token*⟩ の列として字句解析部 (`scan.c`) で認識されるか考察しなさい。

```
x/*y*/123*/z
```

2. ⟨*TokenSeq*⟩ の文法は、識別子 ⟨*Ident*⟩ となり得るような文字列に関する曖昧性を持っていることを示しなさい。また、例えば次の文字列が、実際にはどのような ⟨*Token*⟩ の列として字句解析部 (`scan.c`) で認識されるか考察しなさい。

```
whilexyz
```

3. 今回の字句解析部 (`scan.c` と `scan.h`) を利用して、文法チェックのみを行う Minimun C のパーザを書きなさい。構文図が決定的でなくても、第 4 回に解説した「構文図からのパーザの生成」法に従ってとりあえずパーザを書いてみること。

記号処理・第 6 回・終わり

付録：第 4 回演習問題の解答例

2. 機械的に構文図を変換した場合

```
#include <stdio.h>

void HizeroSuji(void)
{
    switch (token) {
    case '1':
        if (token == '1')
            gettoken();
        else
            error();
        break;
          :
    case '9':
        if (token == '9')
            gettoken();
        else
            error();
        break;
    default:
        error();
    }
}

void Suji(void)
{
    switch (token) {
    case '0':
        if (token == '0')
            gettoken();
        else
            error();
        break;
    case '1': case '2': case '3':
    case '4': case '5': case '6':
    case '7': case '8': case '9':
        HizeroSuji();
        break;
    default:
        error();
    }
}

void Shosubu(void)
{
    if (token == '.')
        gettoken();
    else
        error();
    while (token == '0') {
        if (token == '0')
            gettoken();
        else
            error();
    }
    HizeroSuji();
    while (token == '0' || token == '1' ||
           token == '2' || token == '3' ||
           token == '4' || token == '5' ||
           token == '6' || token == '7' ||
           token == '8' || token == '9') {
        while (token == '0') {
            if (token == '0')
                gettoken();
            else
                error();
```

ある程度効率化した場合

```
#include <stdio.h>

void HizeroSuji(void)
{
    switch (token) {
    case '1':
    case '2':
          :
    case '9':
        gettoken();
        break;
    default:
        error();
    }
}

void Suji(void)
{
    switch (token) {
    case '0':
        gettoken();
        break;

    case '1': case '2': case '3':
    case '4': case '5': case '6':
    case '7': case '8': case '9':
        HizeroSuji();
        break;
    default:
        error();
    }
}

void Shosubu(void)
{
    if (token == '.')
        gettoken();
    else
        error();
    do {
        while (token == '0')
            gettoken();

        HizeroSuji();
    } while ('0' <= token
             && token == '9');
}
```

```
        }
        HizeroSuji();
    }
}

void IchiIjo(void)
{
    HizeroSuji();
    while (token == '0' || token == '1' ||
           token == '2' || token == '3' ||
           token == '4' || token == '5' ||
           token == '6' || token == '7' ||
           token == '8' || token == '9') {
        Suji();
    }
    if (token == '.')
        Shosubu();
}

void Jissu(void)
{
    switch (token) {
    case '0':
        if (token == '0')
            gettoken();
        else
            error();
        if (token == '.')
            Shosubu();
        break;
    case '1': case '2': case '3':
    case '4': case '5': case '6':
    case '7': case '8': case '9':
        IchiIjo();
        break;
    case '-':
        if (token == '-')
            gettoken();
        else
            error();
        switch (token) {
        case '0':
            if (token == '0')
                gettoken();
            else
                error();
            Shosubu();
            break;
        case '1': case '2': case '3':
        case '4': case '5': case '6':
        case '7': case '8': case '9':
            IchiIjo();
            break;
        default:
            error();
        }
        break;
    default:
        error();
    }
}

void parse(void)
{
    gettoken();
    Jissu();
    if (token != EOF)
        error();
}
```

```
void IchiIjo(void)
{
    HizeroSuji();
    while ('0' <= token
           && token == '9') {
        Suji();
    }


    if (token == '.')
        Shosubu();
}

void Jissu(void)
{
    switch (token) {
    case '0':
        gettoken();


        if (token == '.')
            Shosubu();
        break;
    case '1': case '2': case '3':
    case '4': case '5': case '6':
    case '7': case '8': case '9':
        IchiIjo();
        break;
    case '-':
        gettoken();


        switch (token) {
        case '0':
            gettoken();


            Shosubu();
            break;
        case '1': case '2': case '3':
        case '4': case '5': case '6':
        case '7': case '8': case '9':
            IchiIjo();
            break;
        default:
            error();
        }
        break;
    default:
        error();
    }
}

void parse(void)
{
    gettoken();
    Jissu();
    if (token != EOF)
        error();
}
```

3. (1)

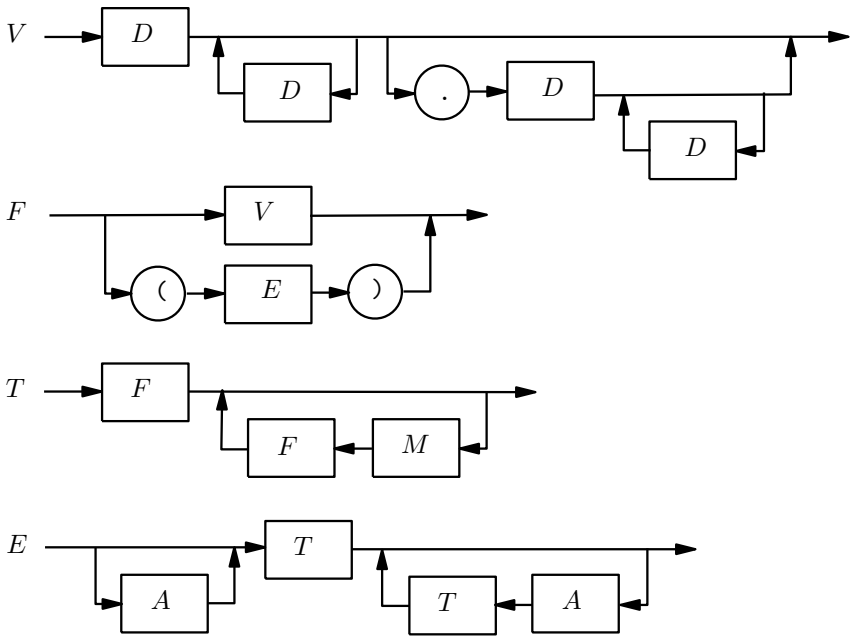

(2)

```
 1 double F(void)
 2 {
 3    double v;
 4
 5    if ('0' <= t && t <= '9') {
 6        v = V();
 7    }
 8    else if (t == '(') {
 9        gettoken();
10        v = E();
11        if (t != ')')
12            error();
13        gettoken();
14    }
15    else {
16        error();
17    }
18    return v;
19 }
20
21 double T(void)
22 {
23     double v, w;
24
25     v = F();
26     while (t == '*' || t == '/') {
27         if (t == '*') {
28             gettoken();
29             v *= F();
30         }
31         else {
32             gettoken();
33             w = F();
34             if (w == 0.0) {
35                 printf("Division by 0\n");
```

```
36                 exit(1);
37             }
38             v /= w;
39         }
40     }
41     return v;
42 }
43
44 double E(void)
45 {
46     double v = 1.0;
47
48     if (t == '+' || t == '-') {
49         if (t == '+') {
50             gettoken();
51         }
52         else {
53             gettoken();
54             v = -1.0;
55         }
56     }
57     v *= T();
58     while (t == '+' || t == '-') {
59         if (t == '+') {
60             gettoken();
61             v += T();
62         }
63         else {
64             gettoken();
65             v -= T();
66         }
67     }
68     return v;
69 }
70
71 void L(void)
72 {
73    double v;
74
75    while (('0' <= t && t <= '9') || t == '+'
76            || t == '-' || t == '(') {
77        v = E();
78        if (t != '=')
79            error();
80        printf ("%f\n", v);
81        gettoken();
82    }
83 }
```