2 字句解析

♣ 「字句解析」とは どんな処理 か.

♣ 字句解析の 方法 は.

2.1 字句解析とは

- 字句解析の仕事
  1. 文字列中の字句 (単語, トークン) を認識する
  2. それぞれの字句の 種類 がわかるようにする
  3. 字句を必要な 内部表現 に変換する
- 字句の種類 (C 言語の場合 6 種類)
  1. 識別子 (identifiers)

     変数や関数などの 名前 を表す

     `main`, `a123`, `Max_Value` のように, 英文字 と 数字 からなり, 英文字 で始まる.

     大 文字と 小 文字は区別される. _ (アンダーライン) は英文字とみなされる.
  2. キーワード (keywords)

     決まった意味で用いる語

     C 言語では, 識別子として用いることはできない. このような語を特に 予約 語 (reserved word) という.

     C 言語 (ISO-C90) では 32 個[1]

     ```
     auto, break, case, char, const, continue, default, do, double,
     else, enum, extern, float, for, goto, if, int, long, register,
     return, short, signed, sizeof, static, struct, switch,
     typedef, union, unsigned, void, volatile, while
     ```
  3. 定数 (constants)
     - ある特定の型の定数を表すもの
     - 整数 定数: `123`(10 進 定数), `0123` (8 進 定数), `0xae86`(16 進 定数)
     - 文字 定数: `'a'`, `'0'`, `'\n'` (改行), `'\t'` (タブ) など
     - 浮動小数点数 定数: `1.23e6` (1.23×10^{6}), `2.34e-12` (2.34×10^{-12}) など

[1] C 言語の新しい規格 C99 では, `inline`, `restrict`, `_Bool`, `_Complex`, `_Imaginary` の 5 つが追加されている.

4. **文字列** 定数 (**string literals**)

   2 重引用符 (") で囲まれた記号列 (`"This is a pen."`など)

5. **演算子** (operators)

   +, =, >>, ++, += など演算を表す記号

6. **区切り子** (**delimiters** , **punctuators**)

   ;, ,, (などの区切り記号

7. (番外) **空白**

   スペース , **タブ** , **改行** , **コメント** など, 識別子を区切る以外は無視される

   コメント

   - **/*** と ***/** で区切られた文字列で, ***/** を含んではならない
   - **//** から改行記号までの文字列

- 字句解析ルーチン
  - 字句解析の 2 形態
    1. プログラム **全体** に対して字句解析を行なう.

       これに続いて **構文** 解析を行なう
    2. **一字句** づつ解析しながら **構文** 解析を行なう

       構文 解析から一々 **字句** 解析を呼び出す
  - いずれにしても, 一字句を切り出す「字句解析ルーチン」を考えるとよい
    1. 呼び出される毎に次の **一字句** を切り出す
    2. 指定された変数に, その字句の種類, 値などがセットされる

2.2 字句解析の方法

- プログラムは **文字列**

```
int fx()
{
  int ab=23;
}
```

というプログラムは, コンパイラから見ると

i	n	t		f	x	(	)	改	{	改			i	n	t		a	b	=	2	3	;	改	}	改

という文字列に過ぎない (「改」は改行文字).

ここから字句を **抽出** するのが字句解析の役割

- 具体的な字句解析ルーチンの仕事
  - 呼び出されると 1 つのトークンを切り出す.

– 次の 1 文字 だけが見えている (これを c とする).

– 空白 は読み飛ばす.

– 切り出したトークンを 文字配列 (token とする) に格納する.

– トークンの 種類 を指定された変数 (type とする) にセットする.

- 解析例

★ 1 回目の呼び出し

c	i								
token	\0								
type	?								

1. 'i' (アルファベット) で始まる字句は 識別子 か キーワード → 'i' を token に格納.

c	n								
token	i	\0							
type	?								

2. 次の文字が 'n' ということは, これはトークンの続き. → 'n' を token に追加

c	t								
token	i	n	\0						
type	?								

3. 同様に次の文字 't' を token に追加

c									
token	i	n	t	\0					
type	?								

4. 次の文字 = ' ' なので トークンは終りとわかる.

   現在の token "int" は キーワード である.

c									
token	i	n	t	\0					
type	キーワード								

これで 1 トークンの切り出しが完了

★ 2 回目の呼び出し

c									
token	\0								
type	?								

1. 空白を読み飛ばす

c	f								
token	\0								
type	?								

2. c = 'f' (アルファベット) で始まるので, 識別子かキーワード→ 'f' を token に格納.

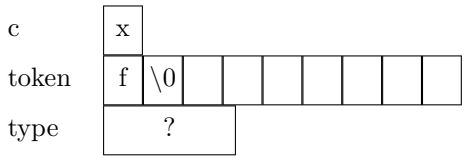

3. 続く文字 'x' を token に追加

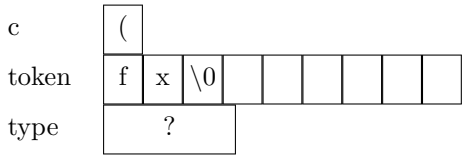

4. 次の文字 = '(' なので トークンは終り.

現在の token "fx" は キーワード ではないので, 識別子 と判定.

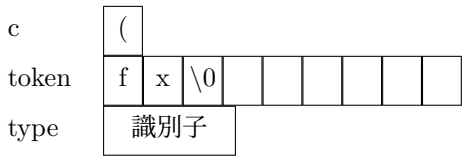

これで 1 トークンの切り出しが完了

★ 3 回目の呼び出し

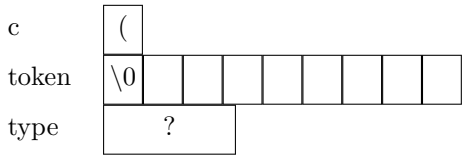

1. c = '(' を見た時点で, これが一つのトークンであると判定できる. '(' をトークンに入れ, タイプをセットして終了.

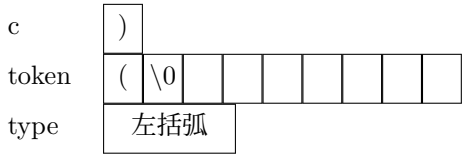

★ 4 回目の呼び出し

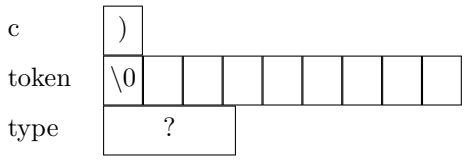

1. c = ')' を見た時点で, これが一つのトークンであると判定できる. ')' をトークンに入れ, タイプをセットして終了.

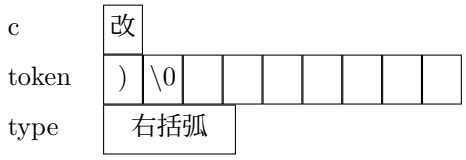

★ 5 回目の呼び出し

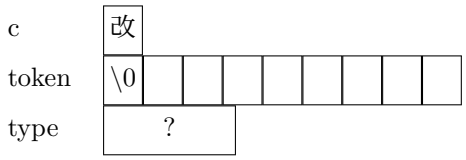

1. 改行記号を読み飛ばす

c	{								
token	\0								
type	?								

2. c = '{' を見た時点で, これが一つのトークンであると判定できる. '{' をトークンに入れ, タイプをセットして終了.

c	改								
token	{	\0							
type	左ブレース								

- 字句解析ルーチンのおおよその構造

[List 2.1]

```
void 字句解析 () {
  空白の読み飛ばし;
  if      (先頭がアルファベット) { 識別子 , キーワード の処理; }
  else if (先頭が数字) { 整数 定数, 浮動小数点 定数の処理; }
  else if (先頭が ' ) { 文字 定数の処理; }
  else if (先頭が " ) { 文字列 定数の処理; }
  else if (先頭が記号) { 演算子 および 区切り記号 の処理; }
  else { エラー; }
}
```

Nagisa ISHIURA