

プログラム言語論 意味論

亀山幸義

筑波大学 情報科学類

No. 2

- プログラム言語「論」
- コンパイラとインタプリタ
- プログラム言語の構文: BNF と文脈自由文法

演習

```
#include <stdio.h>
void foo (int y, int z) {
    printf("%d %d\n", y, z);
}
main () {
    int x = 0;
    foo(++x, ++x);
}
```

答え: "1 2"と"2 1" と"2 2"のどれにでもなり得る (処理系依存). C 言語の仕様書では、「左から」とも「右から」とも決めていない (unspecified) どころか、2つの++を計算してから2つの引数を積む、ということも許している。

意味を厳密に考える必要性

「プログラムの意味を決める」とは、プログラムを実行するとどのような結果になるかを (厳密に) 決めること。

言葉による説明しかないプログラム言語では。

- コンパイラが正しいかどうか確かめられない。
- プログラムの性質を解析・検証できない。
- プログラムの保守・再利用もできない。

プログラム言語の意味論

- 厳密な意味論がある言語: Scheme, Standard ML
- 言葉による意味論がある言語: C, Java, etc.
- 言葉による意味論もない言語: Ruby, etc.

- 操作的意味論 (operational semantics)
 - small-step semantics (structural operational semantics)
 - bigl-step semantics (natural semantics)
 - abstract machine semantics
- 公理の意味論 (axiomatic semantics)
- 表示の意味論 (外延の意味論; denotational semantics)

ここでは、big-step と表示の意味論と抽象機械意味論。

big-step 意味論

式 e を計算した結果が n であることを $e \downarrow n$ と書く。

$$\overline{n \downarrow n}$$

$$\frac{e_1 \downarrow n_1 \quad e_2 \downarrow n_2}{(e_1 + e_2) \downarrow n} \quad \text{ただし } n_1 + n_2 = n \text{ とする}$$

$$\frac{e_1 \downarrow n_1 \quad e_2 \downarrow n_2}{(e_1 - e_2) \downarrow n} \quad \text{ただし } n_1 - n_2 = n \text{ とする}$$

これらを使って、

$$\frac{\overline{1 \downarrow 1} \quad \frac{\overline{2 \downarrow 2} \quad \overline{3 \downarrow 3}}{(2-3) \downarrow 0}}{(1+(2-3)) \downarrow 1}$$

自然数の加減算

$n ::= 0 \mid 1 \mid 2 \mid \dots$

$e ::= n \mid (e+e) \mid (e-e)$

例: $(1+(2-3))=1$ (負の数はないので 0 にする。)

表示の意味論: プログラムの各要素を、何らかの数学的要素に対応付ける。

$\llbracket \text{式} \rrbracket = \text{自然数}$

$\llbracket n \rrbracket = n$

$\llbracket (e_1 + e_2) \rrbracket = \llbracket e_1 \rrbracket + \llbracket e_2 \rrbracket$ 右辺は自然数の加算

$\llbracket (e_1 - e_2) \rrbracket = \llbracket e_1 \rrbracket - \llbracket e_2 \rrbracket$

抽象機械意味論

CK 機械 (C=code, K=continuation or stack)

$\langle e \rangle_{init} \rightarrow \langle e, End \rangle_e$

$\langle n, K \rangle_e \rightarrow \langle K, n \rangle_c$

$\langle (e_1 \oplus e_2), K \rangle_e \rightarrow \langle e_1, (\square \oplus e_2) \rangle_c$

$\langle End, n \rangle_c \rightarrow n$

$\langle (\square \oplus e) \rangle_c \rightarrow \langle e, (n \oplus \square) \rangle_e$

$\langle (n \oplus \square) \rangle_c \rightarrow \langle K, m \rangle_e$ ただし $n \oplus n' = m$

ただし、 $\oplus = +, -$

```

< (1 + (2 - 3)) >_init → < (1 + (2 - 3)), End >_e
  → < 1, (□ + (2 - 3)) :: End >_e
  → < (□ + (2 - 3)) :: End, 1 >_c
  → < (2 - 3), (1 + □) :: End >_e
  → < 2, (□ - 3) :: (1 + □) :: End >_e
  → < (□ - 3) :: (1 + □) :: End, 2 >_c
  → < 3, (2 - □) :: (1 + □) :: End >_e
  → < (2 - □) :: (1 + □) :: End, 3 >_c
  → < (1 + □) :: End, 0 >_c
  → < End, 1 >_c
  → 1
    
```

K はスタック (残りの計算がつかまっている)

ともかく、プログラムの意味を厳密に決めるもの。

- 操作的意味論 (operational semantics)
 - プログラムの動作を記述。
- 公理的意味論 (axiomatic semantics)
 - プログラムが満たす性質を記述。
- 表示の意味論 (外延の意味論; denotational semantics)
 - プログラムが表している (数学的な) ものを記述。

- (本当の) 機械: machine (computer)
 - ハードウェアで実現
- 仮想機械: virtual machine
 - インタプリタで実現される。
 - 通常、instruction set を持ち、本当の機械に近い。
- 抽象機械: abstract machine
 - インタプリタで実現される。
 - 抽象度が高い (高級言語に、より近い)。
 - 通常、instruction set を持たない。

代表的な抽象機械

- SECD machine [Landin 1964]
- CEK machine [Felleisen 1989]
- WAM, CHAM, Krivine machine, ...

```

#include <stdio.h>;
int x, *s;
int data[100];
int sort (int *s) {
  int y;
  ...x...
}
int main () {
  int x;
  ... sort( ..) ...
  {int x = 10; ...}
}
    
```

(正確には, 1つのブロックは, { から } まで)

- ALGOL 以来, 多くのプログラム言語が採用.
- プログラムのテキスト (文面) に対する概念.
- 変数の有効範囲 (スコープ) と密接に関連.
- 入れ子構造をなす.

入れ子 (nest)

- 「2つのブロックが、共通部分をもてば、必ず、片方が他方を包含する。」

```
let rec eval exp =  
  let apply_binop ope exp1 exp2 =  
    ...  
  in  
  match exp with  
  | ...  
  | Plus(e1,e2) -> apply_binop (+) e1 e2  
  | Times(e1,e2) -> apply_binop ( * ) e1 e2
```

C 言語と違い、入れ子になった関数定義が許される。(eval_exp の中で、apply_binop が定義されている。)

- 1つのブロックが、実行時に何度も呼ばれることがある。
- ブロックの実行開始と実行終了は、Last-in, First-Out (First-in, Last-Out とも言う)。
- **スタック**

これ以降では、スタックに基づく形式意味論は、省略して、スタックに基づく実行方式を学ぶ。

- Register (CPU のレジスタ)
- Program Counter (コード領域を指す変数)
- Code (プログラムのコードを格納する領域)
- Environment Pointer (スタックを指す変数)
- Data:
 - Stack (スタック)
 - Heap (ヒープ)

プログラムスタック (あるいは, 環境スタック)

- ブロック構造を持つプログラム言語の処理系で使用 .
- ブロックに局所的な変数たちの値を格納 .

```
int f (int y) {
  int z = 10;          -----
  return y+z;         z=10
}                      y=11
main () {             -----
  int x = 10;          x=10  x=10  x=10
  x = f(x+1);         -----
}                      -----
```

スタックフレーム

スタックフレーム (stack frame, activation record)

- スタックに積まれる、ひとまとまりのデータ .
- スタック全体は, 0 個以上のスタックフレームから構成 .
- 典型的なスタックフレームの中身 (関数ブロックの場合)
 - 局所変数 (関数の引数, 関数で定義された変数) の値
 - 計算の途中結果
 - 関数の戻り先アドレス (コード領域の番地)
 - 関数が返す値
 - 1 つ前のスタックフレームへのポインタ (Control link)
 - 値を参照する変数を探すためのリンク (Access link)

演習で使う処理系では, show 関数により, 「スタックフレームごとの局所変数とその値」が表示される。

関数呼出しの意味論 (1)

```
int f(int x, bool y) {int z; ...}
```

環境 σ のもとで $f(e_1, e_2)$ が呼ばれたときの処理:

- 引数 e_1, e_2 を現在の環境 σ で計算する .
- それらの結果を v_1, v_2 とする .
- 環境スタックに新しいスタックフレームを追加する .
- Environment Pointer が新しいスタックフレームを指すようにする .
- 新しいスタックフレームに以下の値を格納:
 - Control link: 1 つ前のスタックフレームへのポインタ .
 - Access link: 値を参照する変数を探すためのリンク .
 - 戻り先アドレス: 関数の計算終了後に戻ってくるべきコード領域の番地 .
 - 戻り値を格納するスペース .
 - 関数の実引数 v_1, v_2
 - 関数の局所変数 z を格納するスペース

関数呼出しの意味論

```
int f(int x, bool y) {int z; ...}
```

関数呼び出し $f(e_1, e_2)$ の中で, return e ; が実行されたときの処理:

- その時点での状態 σ のもとで e を計算し, その値をスタックフレーム内の「戻り値を格納するスペース」に入れる .
- スタックフレームに保存しておいた戻りアドレスに飛ぶ . (Program Counter にそのアドレスをいれる .)
- 現在のスタックフレームをはずす . (Control link をたどり, Environment Pointer が 1 つ前のスタックフレームを指すようにする .)
- (局所変数はすべて失われる .)

- プログラムの意味論
- ブロック構造をもつプログラム言語
- スタックを用いたインタプリタ
- 関数呼び出しの意味論