

## プログラム言語論

亀山幸義

筑波大学 情報科学類

No. 1

- 亀山幸義の基本データ
  - 筑波大学 大学院システム情報工学研究科 コンピュータサイエンス 専攻
  - 総合研究棟 B-1008 (10 階)
  - URL: <http://logic.cs.tsukuba.ac.jp/~kam>
  - 授業ホーム: [../~kam/plm/](http://logic.cs.tsukuba.ac.jp/~kam/plm/)
  - E-mail: [kam@cs.tsukuba.ac.jp](mailto:kam@cs.tsukuba.ac.jp)
- 研究テーマ
  - プログラム理論・プログラム言語論
    - 関数型プログラム言語、型システム など。
  - ソフトウェア検証・システム検証
    - コンピュータによる定理証明、モデル検査による検証。

## プログラム言語とは？

- プログラムを記述するため、人工的に作られた言語。
- なぜ必要か？
  - 現代コンピュータ == von Neumann Machine (Turing Machine)
  - プログラム内蔵方式
- 何のために？
  - 人間のため vs コンピュータ (ハードウェア) のため
  - 書きやすさ/理解しやすさ/保守のしやすさ vs 実行性能の高さ
- この授業は、主として、「人間のためのプログラム言語」(高級言語)を扱う。(cf. 低級 (low-level) 言語.)

## プログラム言語論とは？

- プログラムについて、もっともらしく論じる学問。(?)
- 1つ1つのプログラムについて語るのではなく、プログラム言語(全体)について語る学問。(?)
- 1つ1つのプログラム言語について語るのではなく、種々のプログラム言語に共通する(あるいは相違する)概念について語る学問。
- そんなことは可能だろうか？ そんなことに意味があるのだろうか？

## この授業の目的は？

- プログラムを設計・実装するのが、容易になる，楽しくなる．
- 新しいプログラム言語を設計・実装するのが，容易になる，楽しくなる．

授業の目的については，シラバスも参考にすること．

## インタプリタ (interpreter)

shell (たとえば csh や bash) のインタプリタとは，

- それ自身がプログラムである．
- shell スクリプト (と何らかの入力データ) を入力とし、
- それを 1 行ずつ順番に実行する (実行結果を出力する) ．

perl のインタプリタとは，

- それ自身がプログラムである．
- perl プログラム (と何らかの入力データ) を入力とし、
- それを全部読みこんでチェックしてから実行する (実行結果を出力する) ．

## 質問

「インタプリタ (I) とコンパイラ (C) はどう違うのですか？」

- I は実行が遅くて，C は速い． (?)
- I はプログラムを 1 行ずつ実行して，C は一気に全部実行する． (?)
- C 言語には C しかないし，shell には I しかない． (?)
- I は，プログラムを受け取って，それを実行して答えを返すプログラムであるが，C は，プログラムを受け取って，「それを実行して答えを返すプログラム」を返すプログラムである．
- 気分の違い (違いはない) ． (?)

## コンパイラ (compiler)

C のコンパイラとは，

- それ自身がプログラムである．
- C プログラムを入力する．
- 機械語のプログラムを出力する．
- 出力された機械語プログラムを (何らかの入力データを与えて) 実行すると，もとの C プログラムを実行したのと同じ実行結果になる．

Java のコンパイラとは，

- それ自身がプログラムである．
- Java プログラムを入力する．
- Java の byte code で書かれたプログラムを出力する．
- 出力された Java byte code プログラムを (何らかの入力データを与えて) Java の実行時処理系 (run time) で実行すると，もとの Java プログラムを実行したのと同じ実行結果になる．
- ところで，この実行時処理系は，Java byte code の (Java VM の) インタプリタである．

## 解釈系 (interpreter)

インタプリタは、言語  $S$  で書かれたプログラムを解釈して実行するプログラム (それ自身は言語  $L$  で書かれている) である。

- shell インタプリタ:  $S=\text{shell}$ ,  $L=\text{機械語}$
- perl インタプリタ:  $S=\text{perl}$ ,  $L=\text{機械語}$
- JVM 実行系:  $S=\text{Java byte code}$ ,  $L=\text{機械語}$
- あるインタプリタ:  $S=\text{Scheme}$ ,  $L=\text{Scheme}$
- もちろん,  $L$  は元々は,  $C$  なり  $\text{Java}$  なりで書かれていて, コンパイラを使って機械語に変換したものであろう。
- $S=L$  のとき, meta-circular interpreter という。

$$\llbracket p \rrbracket_S(\vec{x}) = \llbracket \text{int} \rrbracket_L(p, \vec{x})$$

## 翻訳系 (compiler) あるいは変換系 (translator)

コンパイラは、言語  $S$  で書かれたプログラムを、言語  $T$  で書かれたプログラムに翻訳 (変換) する (それ自身は言語  $L$  で書かれている) プログラムである。

- C コンパイラ:  $S=C$  言語,  $T=\text{機械語}$ ,  $L=\text{機械語}$
- Java コンパイラ:  $S=\text{Java}$ ,  $T=\text{byte code}$ ,  $L=\text{機械語}$
- Java native コンパイラ:  $S=\text{Java}$ ,  $T=\text{機械語}$ ,  $L=\text{機械語}$
- クロスコンパイラ:  $S=C$  言語,  $T=\text{PowerPC の機械語}$ ,  $L=\text{Pentium の機械語}$
- ある変換器:  $S=\text{Java}$ ,  $T=\text{Scheme}$ ,  $L=\text{Scheme}$

$$\llbracket p \rrbracket_S(\vec{x}) = \llbracket \llbracket \text{comp} \rrbracket_L(p) \rrbracket_T(\vec{x})$$

## 部分評価 (プログラム特化) の話-1

プログラム  $\text{mix}$ :

$$\llbracket \llbracket \text{mix} \rrbracket_L(p, \vec{x}) \rrbracket_L(\vec{y}) = \llbracket p \rrbracket_L(\vec{x}, \vec{y})$$

プログラム  $p$  への入力  $x, y$  のうち、 $x$  だけが、あらかじめわかっている時、「 $y$  をもらって  $\llbracket p \rrbracket(x, y)$  を返す」プログラムを作成する。

部分評価 (partial evaluation) あるいは プログラム特化 (program specialization) という。

例. 「 $x$  の  $n$  乗」を計算するプログラムがあるとき、 $n = 3$  のときに (異なる  $x$  に対して) 頻りに動かしたいなら、その  $n$  に特化した高速プログラムが欲しい。

## 部分評価 (プログラム特化) の話-2

二村射影 (Futamura Projections) [Futamura 1971]

$\text{mix}$  の定義式で、 $p = \text{int}$ ,  $\vec{x} = p$  とすると:

$$\llbracket \llbracket \text{mix} \rrbracket_L(\text{int}, p) \rrbracket_L(\vec{y}) = \llbracket \text{int} \rrbracket_L(p, \vec{y})$$

右辺は、インタプリタの定義式より、 $\llbracket p \rrbracket_S(\vec{y})$  に等しい。よって、

$$\llbracket \llbracket \text{mix} \rrbracket_L(\text{int}, p) \rrbracket_L(\vec{y}) = \llbracket p \rrbracket_S(\vec{y})$$

結局、 $\llbracket \llbracket \text{mix} \rrbracket_L(\text{int}, p) \rrbracket_L(\vec{y})$  は、 $p$  と同じ動作をする (二村の第 1 射影)。

$$\llbracket \llbracket \text{mix} \rrbracket_L(\text{int}, p) \rrbracket_L(\vec{y}) = p$$

mix の定義式で、 $p = \text{mix}$ ,  $\vec{x} = \text{int}$ ,  $\vec{y} = p$  とすると :

$$\llbracket \text{mix} \rrbracket_L(\text{mix}, \text{int}) \llbracket_L(\vec{p}) = \llbracket \text{mix} \rrbracket_L(\text{int}, \vec{p})$$

となり、右辺は第1射影なので、(言語  $S$  で書かれている)  $p$  と、同じ動作をするプログラム (言語  $L$  で書かれている) である。つまり、言語  $S$  から言語  $L$  へのコンパイラ (言語  $L$  で書かれている) ができた。(二村の第2射影)

$$\text{comp} = \llbracket \text{mix} \rrbracket_L(\text{mix}, \text{int})$$

同様に、mix の定義式で、 $p = \text{mix}$ ,  $\vec{x} = \text{mix}$  とすると以下が得られる。

$$\llbracket \llbracket \text{mix} \rrbracket_L(\text{mix}, \text{mix}) \rrbracket_L(\vec{\text{int}}) = \text{comp}$$

これより、 $\text{cogen} = \llbracket \text{mix} \rrbracket_L(\text{mix}, \text{mix})$  は「インタープリタが与えられると、コンパイラを生成するプログラム」(コンパイラジェネレータ) であるといえる。(二村の第3射影)

こんな机上の空論のような計算をして何が面白いのか？

- 実際に、効率よい「コンパイラジェネレータ (cogen)」を生成する mix が、(Scheme 言語や C 言語に対して) 実装された!
- 人手で作成した cogen より効率が良い (ことがある)!
- 理論と実装の結びつきの好例。

ちなみに、、、現在は再び「手動で cogen を書く」ことへの関心が高まっている。

マルチステージプログラミング言語の研究: たとえば、Walid Taha, "Gentle Introduction to Multi-Stage Programming"などを参照。

- 個々のプログラムの処理方法ではない。
- 個々のプログラム言語の処理方法ではない。
- プログラム言語における種々の「概念」を論じる。
- 個々のプログラム言語でなく、プログラム言語たちに共通する概念・機能に興味がある。
- プログラム言語の一般的な理解や比較に役立つ。
- 洗練されたプログラミングが可能 (?)
- 新しいプログラム言語の設計

John C. Mitchell, "Concepts in Programming Languages", Cambridge University Press, 2003.

上記図書の誤植修正が、Mitchell 自身のホームページに置かれている。  
<http://theory.stanford.edu/~jcm/books.html>

最近出た本: Maurizio Gabbriellini, Simone Martini, "Programming Languages: Principles and Paradigms", Springer, 2011.

## 命令型言語の例: miniC の構文

- プログラムは、文をセミコロンで区切って並べたものである。
- 文は、代入文 ( $x=e_1;$ )、while 文 ( $\text{while } e_1 \text{ } s_1;$ )、逐次実行文 ( $s_1 \dots s_n$ )、条件文 ( $\text{if } e_1 \text{ } s_1 \text{ else } s_2$ ) のいずれかである。ただし、 $x$  は変数、 $e_i$  は式、 $s_i$  は文である。
- 式は、 $x, c, e_1+e_2$  のいずれかである。ただし、 $x$  は変数、 $c$  は自然数か真偽値の定数、 $e_1, e_2$  は式である。

問題点: こんな言葉による説明では、定義がはっきりしない。

- 命令型言語 imperative language: プログラムは、「命令の列 (手順、手続き)」である。順序付けられた一連の命令を順番に実行していくことにより、計算が行われる。
  - 例: C, Fortran, COBOL, ...
- 宣言型言語 declarative language: プログラムは、(関数や論理式などの) 宣言である。計算の手順は書かず、計算の意味を記述する。
  - 関数型言語の例: Lisp, Scheme, ML (Standard ML, OCaml), Haskell
  - 論理型言語の例: Prolog

では、Java, Ruby などは?

## 命令型言語の例: miniC の構文 (やり直し)

プログラム言語の構文定義には、しばしば、BNF が用いられる。  
 Backus Normal Form (あるいは Backus-Naur Form):

```

<prog> ::= <dec> | <dec> <prog>
<dec>  ::= <type> <var> "(" <plist> ")" <stment>
        | <type> <var> ";"
<stment> ::= <var> "=" <exp> ";"
        | "while" <exp> <stment>
        | "{" <slist> "}"
        | "if" <exp> <stment> "else" <stat>
        | ...
<slist> ::= <stment> | <stment> <slist>
<exp>  ::= <var> | <const> | <exp> "+" <exp> | ...
...
    
```

## 命令型言語の例: miniC の構文 (更にやり直し)

BNF を多少崩した形がよく使われる。

```
p ::= d | d p
d ::= t x (pl) s | t x;
s ::= x = e; | while e s | {s}
    | if e s else s | ...
sl ::= s | ssl
e ::= x | c | e + e | ...
t ::= int | ...
```

- BNF は、文脈自由文法 (context-free grammar) を与える簡潔な記法。(「オートマトンと形式言語」を参照)
- 実際のプログラム言語の構文は、文脈自由でないことが多い。
- 例えば、C 言語では、「宣言されない変数を使ってはいけない」という構文上の規則があるが、これは BNF で与えられない。

## 関数型言語の例: miniML の構文

```
x ::= ...
c ::= ...
e, f ::= x | c | e + f | λx.e | e f | let x = e in f
```

$\lambda x.e$  ラムダ式:

- $f(x) = e$  となる関数  $f$  のことを  $\lambda x.e$  と書く。
- $(\lambda x.e)(x) = e$  が成立する。
- $(\lambda x.e)(f)$  はどう定めたらよいか?

let  $x = e$  in  $f$  let 式:

- $x = e$  として  $f$  を計算する。

## 構文 (syntax) と意味 (semantics)

- 言語の「構文」:
  - 日本語の場合、日本語の文字から構成される任意の文字列のうち、「日本語の文になっているもの」を定める規則が構文規則。
  - プログラム言語の場合も同様。
- 言語の「意味」:
  - 日本語の文の意味は、何だろう?
  - プログラムの意味は何か?
    - プログラムを計算すると、どういう結果が得られるか。

## プログラムの意味を考える

以下のプログラムはどのような結果になるか。

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

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) .