

プログラム言語論

亀山幸義

筑波大学コンピュータサイエンス専攻

第1週

Who am I ?

● 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>
- 授業ホームページ: <http://kam/plm/>
- E-mail: 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。

質問

「インターブリタ(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）。（？）

インターブリタ(interpreter)

shell(たとえばcshやbash)のインターブリタとは、

- 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のインターブリタとは、

- 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)。

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)インターブリタである。

解釈系 (interpreter)

インターブリタは、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 インターブリタ: S=shell, L=機械語
- perl インターブリタ: S=perl, L=機械語
- JVM 実行系: S=Java byte code, L=機械語
- あるインターブリタ: S=Scheme, L=Scheme
- もちろん、L は元々は、C なり 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。

$$[\![p]\!]_S(\vec{x}) = [\![\text{int}]\!]_L(p, \vec{x})$$

翻訳系 (compiler) あるいは変換系 (translater)

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

$$[\![p]\!]_S(\vec{x}) = [\![\![\text{comp}]\!]\!]_L(p) \quad [\![\vec{x}]\!]_T$$

部分評価（プログラム特化）の話-1

プログラム mix:

$$[\![[\![\text{mix}]\!]\!]_L(p, \vec{x})]\!]_L(\vec{y}) = [\![p]\!]_L(\vec{x}, \vec{y})$$

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 をもらうと $p(x, y)$ 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）頻繁に動かしたいなら、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]

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

$$[\![[\![\text{mix}]\!]\!]_L(\text{int}, p)]!]_L(\vec{y}) = [\![\text{int}]\!]_L(p, \vec{y})$$

右辺は、インターブリタの定義式より、 $[\![p]\!]_S(\vec{y})$ に等しい。よって、

$$[\![[\![\text{mix}]\!]\!]_L(\text{int}, p)]!]_L(\vec{y}) = [\![p]\!]_S(\vec{y})$$

結局、 $[\![[\![\text{mix}]\!]\!]_L(\text{int}, p)]]$ は、p と同じ動作をする（二村の第1射影）。

$$[\![[\![\text{mix}]\!]\!]_L(\text{int}, p)]]=p$$

部分評価（プログラム特化）の話-3

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

$$[\![[\![\text{mix}]\!]\!]_L(\text{mix}, \text{int})]\!]_L(\vec{p}) = [\![\text{mix}]\!]_L(\text{int}, \vec{p})$$

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）

$$\text{comp} = [\![\text{mix}]\!]_L(\text{mix}, \text{int})$$

部分評価（プログラム特化）の話-4

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。

$$[\![[\![\text{mix}]\!]\!]_L(\text{mix}, \text{mix})]\!]_L(\vec{int}) = \text{comp}$$

これより、cogen = $[\![[\![\text{mix}]\!]\!]_L(\text{mix}, \text{mix})]$ は「インターブ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）

部分評価（プログラム特化）の話-5

こんな机上の空論のような計算をして何が面白いか？

- 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。

結局のところ、プログラム言語論とは？

- 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はなく、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

参考書

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 Gabbrielli, Simone Martini, "Programming Languages: Principles and Paradigms", Springer, 2011.

手続き型言語 (命令型言語) vs 宣言型言語

- 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

- 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" <stmat>
          | ...
<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 l }
  | if e s else s | ...
s l ::= s | s s l
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)。

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マ言語では。

- 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.

miniC 言語の意味と実装

操作的意味論(operational semantics)に基づいて、以下の手順で展開する。

- miniCに対する意味論を与える。
 - 関数呼び出しがなく、main関数だけ。print文なども省略。
 - 式の意味。
 - 文の意味。
- miniCへの拡張。
 - 関数呼び出し。静的束縛 vs 動的束縛。
 - スタックを用いたインターブリタ。

miniC 言語の(のサブセットの)意味

意味論の登場人物: 「値」と「状態」

- 値(value): 式の計算結果のこと、miniCでは整数値と真偽値。
- 状態(state): 各変数も持つ値を示すもの。
 - 変数の集合から、値の集合への部分関数。
 - 初期状態[]: すべての変数が値を持たない。(対応する値が「未定義」)
 - 状態 $[x \mapsto 0, y \mapsto \text{true}]$: 変数 x が値0を持ち、変数 y が値trueを持ち、他の全ての変数は値を持っていない状態。
 - 状態 wrong: 例えは、式 $0 + \text{true}$ を実行した後の状態。

注意: 次ページ以降の式や文は、構文解析が終了しているもの(従って、文字列ではなく構文木)と仮定する。

式の意味

「状態 σ における式 e の意味(状態 σ で e を計算したときの値)」を、 $\sigma(e)$ と書き、 e の種類に応じた場合分けで定義する。

- $\sigma = \text{wrong}$ のとき、 $\sigma(e)$ は値を持たない。
- e が変数 x のとき: $\sigma(e)$ は、 σ における x の値とする。
- e が定数 c のとき: $\sigma(e) = c$.
- e が $(e_1 + e_2)$ のとき: $\sigma(e) = \sigma(e_1) + \sigma(e_2)$. ただし、 $\sigma(e_i)$ の少なくとも一方が整数でないとき、 $\sigma(e)$ は値を持たない。
- e が $(e_1 == e_2)$ のとき: $\sigma(e_1)$ と $\sigma(e_2)$ がともに整数で等しいとき、 $\sigma(e) = \text{true}$ とし、ともに整数で等しくないとき、 $\sigma(e) = \text{false}$ とし、それ以外の場合、 $\sigma(e)$ は値をもたない。
- 以下同様。

例: 状態 $\sigma = [x \mapsto 1, y \mapsto 2]$ に対して、 $\sigma((x + 1) == y) = \text{true}$ であり、 $\sigma((x + \text{true}) == y)$ は値を持たない。

文の意味

「状態 σ における文 s の意味(σ において s を実行したときに得られる状態)」を、 $\sigma[s]$ と書き、 s の種類に応じた場合分けで定義する。

- $\sigma = \text{wrong}$ のときは、 $\sigma[s] = \text{wrong}$ とする。
- s が代入文 $x = e$ のとき: $\sigma[s] = \sigma[x \mapsto \sigma(e)]$ 。
- 状態 $\sigma[x \mapsto v]$ とは、 σ とほぼ同様の状態だが、変数 x に対する値が v となる状態のこと。
- s が複合文 $\{s_1 s_2 \dots s_n\}$ のとき:
 - $\sigma[s] = ((\sigma[s_1])(\sigma[s_2]) \dots (\sigma[s_n]))$ である。($n = 0$ のときは $\sigma[\{\}] = \sigma$)
- s が(if e s_1 else s_2)のとき:
 - $\sigma(e) = \text{true}$ のとき: $\sigma[s] = \sigma[s_1]$
 - $\sigma(e) = \text{false}$ のとき: $\sigma[s] = \sigma[s_2]$
 - 上記以外のとき: $\sigma[s] = \text{wrong}$.

文の意味

- s がwhile $e s_1$ のとき:

- $\sigma(e) = \text{true}$ のとき、 $\sigma[s] = (\sigma[s_1])[s]$ とする。
- $\sigma(e) = \text{false}$ のとき、 $\sigma[s] = \sigma$ とする。
- 上記以外のとき、 $\sigma[s] = \text{wrong}$ とする。

注意: 上記の「定義」は、数学的な定義としては完全なものではない。

なぜなら、while文が無限ループするとき、上記の定義も無限に展開されるので。不動点意味論(fixpoint semantics)、表示的意味論(denotational semantics)

文の意味: 例題

初期状態 σ_0 を、「すべての変数が、値を持たない」状態とする。

以下の文 s に対して、 $\sigma_0[s]$ はなにか?

```
{ x = 1; y = 0;
  n = 5; f = 0;
  while (f == 0) {
    y = x + y;
    x = x + 1;
    if (x == n)
      f = 1;
    else f = 0;
  }
```

miniC 言語の意味論のまとめ

- $\sigma(e)$: 状態 σ における式 e の計算結果(値)。
- $\sigma[s]$: 状態 σ において文 s を実行した後の状態。
- miniCプログラムの意味:
 - 初期状態は、全ての変数が値を持たない状態。
 - main関数に含まれる文全体を1つの文と見なして、上記の定義を使う。
 - 最終的に得られた状態が、このプログラムの意味。

意味論(semantics)とは何なのか？

- 操作的意味論は、プログラム言語の各要素の計算方法を、
(自然言語で書くかわりに)厳密に書きくだしたもの。
- 全ての場合においてどのように計算するかをきちんと書いて
いる。(自然言語による意味の記述)
- プログラム言語の処理系も、全ての場合においてどのように
計算するかを記述。
- 意味論の記述とインターブリタの記述は、非常に近い。