

プログラム言語論

亀山幸義

筑波大学 情報科学類

No. 5 (ヒープと関数型言語その2)

「対」のデータ型の利用 (1)

Fibonacci 関数の素朴な定義:

```
let rec fib n =
  if n < 2 then 1
  else (fib (n-2)) + (fib (n-1))
in fib 5
==> 8
```

Fibonacci 関数の改善した定義:

```
let rec fib n =
  if n = 0 then (1,1)
  else
    let p = fib (n - 1) in
      (snd p, fst p + snd p)
in fst (fib 5)
==> 8
```

「対」のデータ型の利用 (2)

最大公約数を求める関数:

```
let rec gcd m n =
  if m = n then m
  else if m > n then
    gcd (m-n) n
  else
    gcd (n-m) m
in gcd 100 35
==> 5
```

「対」のデータ型の処理 (1)

C プログラム: **NG!**

```
int* add (int *p, int *q) {
  int r[2];
  *r = *p + *q;
  *(r+1) = *(p+1) + *(q+1);
  return r;
}
int main () {
  int v[2];
  int *q;
  v[0] = 10; v[1] = 20;
  q = add(v, v);
  printf ("%d,%d\n", *q, *(q+1));
}
```

OCaml プログラム

```
let add p q =
  (fst p + fst q,
   snd p + snd q)
in let v = (10,20)
in add v v
==> (20,40)
```

OCaml プログラム

```
let add p q =  
  (fst p + fst q,  
   snd p + snd q)  
in let v = (10,20)  
   in add v v  
==> (20,40)
```

malloc for memory allocation.

C プログラム

```
int* add (int *p, int *q) {  
  int* r =  
    (int*)malloc(sizeof(int)*2);  
  *r = *p + *q;  
  *(r+1) = *(p+1) + *(q+1);  
  return r;  
}  
int main () {  
  int v[2];  
  int *q;  
  v[0] = 10; v[1] = 20;  
  q = add(v, v);  
  printf ("%d,%d\n", *q, *(q+1));  
}
```

- MiniML 言語の「対 (ペア)」データ型を使えば、様々なデータ構造を表現できる。C 言語で同様なことをするためには、構造体 (struct 型) などを使う。
 - MiniML 言語では、一度作ったペア (のためのメモリ) は、どうなるだろうか? ペアを大量に作り続ける関数を作成して呼びだして、実験せよ。
 - MiniML 言語処理系において「ペアなどのデータを覚えておくためのメモリ領域」は、スタック上に取られるかどうか考えなさい。

プログラム例

対 (ペア) を作る操作を多数回繰返すプログラム:

```
let limit=10000000 in  
  let rec f x =  
    if x =limit then "ok"  
    else let _ = (x,x+1) in f (x+1)  
  in f 0
```

ただし `_` というのは、「無名の変数」のこと (後で使わない変数)。

- これだけ繰返しても、エラーは起きず、計算が正常に終了する。
- ペア $(x, x+1)$ のデータは、スタック上に取られるのではない。
- ペア $(x, x+1)$ のデータを格納するためのメモリ領域は、このペアが不要になったら自動的に回収され、他のペアのために再利用される。

プログラム実行時のメモリ (再掲)

- Register
- Program Counter
- Code
- Environment Pointer (スタックを指す)
- Data:
 - Stack (スタック)
 - Heap (ヒープ)

ヒープ (heap)

- データを生成した関数が終了しても、そのデータが使われる可能性があるものを格納するためのメモリ。(永続的なデータ) .
- ヒープに格納されるデータ (例)
 - 対 (ペア) など構造を持つデータ
 - 文字列
 - リスト
 - 関数 (正確には関数クロージャ)
 - オブジェクト指向言語でのオブジェクト
 - その他、固定長のメモリ (通常は、32bit や 64bit) には入りきらないデータ
- x と y の対の生成の処理
 - 対のためのメモリをヒープから取得する .
 - その場所に (x, y) を書きこむ .
 - それへのポインタ (x へのポインタ) を返す .

ヒープ

- C 言語ではプログラマがメモリ管理を行う。(ヒープ上のメモリ確保 `malloc()`, メモリ解放 `free()`)
- OCaml などの言語では、処理系が自動的にやってくれる。(対を実行すればメモリが確保され、対を利用することがなくなれば、いつの間にかメモリが解放される .)
- 論理式、数式、プログラム、XML データなど、構造のあるデータ (特に、可変長のデータ) を扱う際には、上記の 2 機能があるプログラム言語を使うことは、ほぼ必須。
- ヒープは、後で回収することも考えると、単なる「配列」状ではなく、「リンクをもつリスト」状の構造を持つ。(長く使い続けていると、ヒープ全体が「使用領域」と「未使用領域」による「まだら模様」になっていく。)

ごみ集め (Garbage Collection)

- ヒープ領域において、使われなくなったデータに対応する領域を回収する (空き領域に連結する) 操作。
- 通常は、ヒープが足りなくなったときに、一斉に回収する。
- 処理速度が大事; 良いごみ集めアルゴリズム採用することが必須。
- 古くから研究されているが、現在でも更なる改善のための研究がなされている。(高速性ととも、「絶対に間違いがあってはいけない」という意味で、正当性も非常に大事。)

データ型の意義

C 言語でのデータ型

- 比較的少数 (配列, ポインタ, `struct` 型など) .
- メモリ確保と解放はプログラマの責任 .
- 低レベルの詳細なコントロールが可能 .

OCaml 等でのデータ型

- 非常に豊富なデータ型を用意 (関数, 直積, レコード, バリエーション, 帰納的データ型など)
- メモリ確保と解放は自動 .
- 「ごみ集め」の仕組みが必要 .

C 言語は自前でメモリ管理をしたいプログラマ向け, OCaml 等はメモリ管理をシステム (処理系) に委ねたい人向け .

- データ構造, 永続的なデータ, ヒープ
- メモリ管理

プログラム言語における「第一級のもの (first-class citizen)」

- 通常のデータと同様に扱われるもの. 変数の値になったり, 関数の引数や返り値になれるもの.
- C 言語: 整数などのほか, ポインタが first-class .
- Java: 整数などのほか, オブジェクトが first-class .
- OCaml, Haskell など: 整数などのほか, 関数が first-class .
- Scheme: 整数やシンボルのほか, S 式が first-class .

処理系内部では「関数を表す式を計算した結果の値」が必要.
動的束縛の場合 (昔の Lisp, 今の emacs lisp)

- $\lambda x.e$ を計算した結果は, $\lambda x.e$ そのものでよい.

静的束縛の場合 (ほとんどの関数型言語)

- $\lambda x.e$ を計算した結果は, $\lambda x.e$ そのものではない.
- C 言語の処理で, 静的束縛では, access link が必要だった.

例題:

```
let x=1 in
let f=(fun y-> x+y) in
let x=2 in
  f 3
```

上記プログラムの処理 (誤ったバージョン):

frame4: y=3	返り値: 5
frame3: x=2	
frame2: f=fun y->x+y	
frame1: x=1	
global:	

ここで frame4 における access link が指すのは, frame3 でなく, frame1 でなければならない.

関数クロージャ(関数閉包, function closure)

- 静的束縛の関数型言語で、実行時に用いられる。「関数を計算した結果(値)」を表す。
- 関数の定義と、環境(スタックフレームへのポインタ,あるいは、変数ごとにその値を決めるもの)をセットにしたもの: $(\text{fun } x \rightarrow e, \sigma)$. ここで、 σ は、環境(へのポインタ)で、将来この関数の本体 e が実行されるとき access link となる。
- 要するに、この関数を作ったときの環境を保存しておく、ということ。

参考: closure とは、閉じたもののこと。関数 $\text{fun } x \rightarrow x+y$ は、変数 y が自由変数になっているので、その値とセットにして、はじめて「閉じる」ことができる。(自由変数が1つもない式のことをラムダ計算では、closed term という。)

関数クロージャを用いた処理(2)

```
let x=1 in
let f=(fun y-> x+y) in
let x=2 in
  f 3
```

上記プログラムの処理(正しいバージョン):

- 式 $(\text{fun } y \rightarrow x+y)$ の値は関数クロージャ $\text{clo}(\text{fun } y \rightarrow x+y, x=1)$ のフレームへのリンク)
- $(f\ 3)$ の計算では、関数クロージャに保存されていたリンクが、access link となる。

frame4: $y=3$, access link	frame1	返り値: 4
frame3: $x=2$		返り値: 4
frame2: $f=\text{clo}(\text{fun } y \rightarrow x+y, \text{frame1})$		返り値: 4
frame1: $x=1$		返り値: 4
global:		

関数クロージャを用いた処理(3)

```
(let x=1 in
let f=(fun y-> x+y) in
let x=2 in
  f) 3
```

frame4: $y=3$, access link	frame1	返り値: clo(...)
frame3: $x=2$		返り値: clo(...)
frame2: $f=\text{clo}(\text{fun } y \rightarrow x+y, \text{frame1})$		返り値: clo(...)
frame1: $x=1$	frame1': $y=3$, access link	返り値: clo(...)
global:		

NG! frame1 はもはや存在しない。

関数クロージャはどこにあるか?

```
let f =
  let foo x =
    fun y-> x+y
  in
    foo 10
in
  f 20
```

- 関数クロージャは、C言語の関数と違い、プログラム実行時に(動的に)生成される。
- 関数クロージャは、スタックに積まれるのではない。(それを生成した関数呼出しが終わった後も行き残る。下記プログラムを参照)
- 関数クロージャは、**ヒープ**に置かれる。

質問. C言語でも、「関数へのポインタを引数とした関数」や「関数へのポインタを返す関数」は書ける。ではC言語も関数型言語か?

- No. C言語では、「関数を生成する」ことは(通常は)できない。
- 関数型言語では、関数を動的に生成して、(計算結果として)返すことができる。

```
let fun f x = (fun y -> x + y)
```
- (参考) オブジェクト指向言語では、オブジェクトを動的に生成して、(計算結果として)返すことができる。

- 関数プログラミング: 単一代入, 再帰呼出し, 高階関数, データ型の活用
- 単一代入 副作用の分離・明示
- 高階関数と静的束縛 関数クロージャ
- データ型 ヒープ
- 再帰呼出し 末尾再帰

例

```
let limit=10000000 in
let rec f x =
  if x=limit then "ok"
  else let _ = (x,x+1) in f (x+1)
in f 0
```

このプログラムを OCaml で実行しても、overflow のエラーを起こさない理由: 「ペア $(x, x + 1)$ は heap に格納される」
その理由だけでは説明がつかない。

- スタックからペア $(x, x + 1)$ へのポインタがあるなら、(スタックがまきもどされない以上) このペアも、「ごみ集め」の対象にならないのでは?
- 確かにそうだが、_ という特殊な変数は値を記憶しない(スタック上に変数の領域が取られない)。

以前の例 (続き)

- 「対」が heap に取られてごみ集めの対象となってメモリ領域が回収されずとも、stack に積まれる stack frame が、関数呼び出しごとに1つずつ多くなり、いつか stack overflow になるのでは?
- その「からくり」を考えるのが、この章の目的。

関数呼出し時のスタック-1

```
let rec f x =
  if ... then ...
  else f (x+1)
in f 0
```

 x=2 ...

 x=1 x=1 ...

 x=0 x=0 x=0 ...

これでは、いつか、stack overflow になる。

関数呼出し時のスタック-2

```
let rec f x =
  if ... then ...
  else f (x+1)
in f 0
```

 x=0 x=1 x=2 ...

末尾呼び出し

- 関数 f の本体で、関数呼出し ($g\ e$) を行なうとき、 $(g\ e)$ の結果が、そのまま関数 f の結果となるとき、この関数呼出しを**末尾呼出し** (tail call) と言う。
- 末尾呼出しは、「それより後で関数 f の計算はない」ので、関数 f (の現在の呼出し) に対する stack frame は消してしまってもよい。(while ループ等と同じ処理)

末尾呼出しでない例:

```
let rec f x = if x=0 then 1 else x * f (x-1)
let rec f x = if x=0 then 0 else f (x-1) + 0
```

末尾呼出しの例:

```
let rec f x = if x=0 then 1 else f x
let rec f x y = if x=0 then y else f (x-1) (x*y)
```

関数型言語と末尾呼び出し

- C 言語等における「ループ」を、関数型言語では、通常、「関数の再帰呼出し」で実現する。
- 再帰呼出しは、ループよりも表現力が高いが、その反面、実行効率が悪くなる (stack に stack frame をどんどん積む必要があるため。)
- しかし、再帰呼出しが末尾再帰であれば、(また、処理系が末尾再帰最適化を組みこんでいれば)、コンパイラが、「ループ」として実現するので、実行効率はループと同等になる。
- 多くの関数型言語は、末尾再帰の最適化を組みこんでいる。(Scheme, SML/NJ, OCaml ただし C 言語処理系は通常、末尾再帰の最適化はしない。)

- 関数プログラミング: 単一代入, 再帰呼出し, 高階関数, データ型の活用
- 単一代入 副作用の分離・明示
- 高階関数と静的束縛 関数クロージャ
- データ型 ヒープ
- 再帰呼出し 末尾再帰