新しい言語の作り方

2026/05/06(水) ver.2

川合 秀実

アセンブラ自作

- アセンブラとは、機械語の命令と対応している非常に低級な言語（アセンブリ言語）のコンパイラのことです。

- Cコンパイラは、C言語のソースコードをアセンブリ言語に変換していて、それをアセンブラに渡すことで目的を達成しています。だからアセンブラは知らないうちに使っているツールです。

- アセンブラを自作したいという人はほとんどいません。自分が直接使わないものを作る動機は特にないですよね。
- でもあえて、これを自作したいとして、そのために簡単な方法を探ってみようと思います。

x86のアセンブリ言語の例

- 右に典型的なアセンブリ言語の例を示します。

```
MOV     EAX,123
PUSH    ECX
MOV     [EBP+48],EDX
RET
など
```

- これを対応するバイナリデータに変換するのがアセンブラの仕事です。
- アセンブラに限りませんが、一般にプログラミング言語を作るのなら、**字句解析**(1)をして、**構文解析**(2)をして、**意味解析**(3)をして、**最適化**(4)をして、**結果を出力**(5)します。

- でも、そんなの**面倒**だと私は思うのです。

アセンブラの構文を変えれば・・・

- アセンブリ言語の文法を少し変えてみます。
  - 右のように → → → → →

```
MOV(EAX,123);
PUSH(ECX);
MOV([EBP+48],EDX);
RET();
など
```

- こうすれば、右下のようなヘッダファイルを使うことで、機械語に変換できます。
  - DBというのはバイナリデータを直接出力する命令です。

```
#define  EAX      0
#define  ECX      1
#define  EDX      2
#define  RET()    DB(0xC3)
#define  PUSH(r)  DB(0x50+r)
#define  POP(r)   DB(0x58+r)
など
```

このやり方での問題点と解決案

- たとえばPUSH命令は、レジスタ番号を指定する場合と、整数定数を指定する場合と、メモリ上の整数値を指定する場合があります。
- これを全部PUSHと書かれてしまうと、うまく区別できません。
  - （これらの機械語はそれぞれ違います。**50～57, 68, FF**）
- →**解決案**： PUSH_Reg(), PUSH_Const(), PUSH_Mem()と書き分けます。

- アセンブリ言語は単純な置換の他にもラベルによるアドレス計算という大事な役割があり、それはヘッダファイルだけでは解決しません。
- →**解決案**： 仕方ないのでアドレス計算機能だけは実装します。
  他の機能はなくしてヘッダファイルによる置換に任せます。

やってみました

- プリプロセッサは以前自作していたので、それにアドレス計算機能を付けて、さらに事前に決めておいたヘッダファイルを勝手にインクルードするようにしてみました。
  - （プリプロセッサ ＝ #defineなどを解釈するプログラム）

- (a)自作プリプロセッサのみ → **23.5KB**
- (b)上記にアドレス計算処理を足して、アセンブラ化したもの → **26.0KB**
  - 実行ファイル（.exeファイル）のサイズで比較しました。
  - つまりアセンブラを作るために要した記述は **2.5KB** 分のみ！（1日でできる）

- ヘッダファイルを書き足すだけで、すぐに新命令に対応できます。
- ヘッダファイルを書き換えるだけで、全然違うCPUにも対応できます。

[補足]（自作した）プリプロセッサ関数

- メモリ上に（文字列として）テキストファイルの内容を準備して、
  - **int preprocessor(char *t, int n, const char *s);**

  という関数を呼ぶと、プリプロセスした結果がtに返る関数です。
  - 実際は関数名がちょっと違いますが、本質的な違いはないです。

- これがあれば、プリプロセッサは簡単に作れます。
- この関数はgccのプリプロセッサであるcpp0.exe を呼んでいるのでは**なく**、自前で真面目にテキスト変換処理をしています。
- このプリプロセッサ関数は、#defineを少し拡張していて、引数の数や型が違えば、別々のマクロとして機能します。
  - C++の関数みたいな感じです。うらやましかったので真似しました。

C言語もこんな感じで作れたらいいのに

- 「a=b+c;」ではマクロ置換ができません。
- だから「ADD(a, b,c);」にする必要があります。
- しかし「a=b+c;」と書けないなら、それはもうC言語ではなく別の言語です。

- →**解決案**： 仕方ないので「a=b+c;」とかをADD()とかに変換する関数だけ作ります。ifやforなどもうまいこと変換します。・・・ADD()形式になってしまえば、あとはヘッダファイルとプリプロセッサだけで、どんどん置換していけます。

やってみました（パート2）

- (a)自作プリプロセッサのみ → **23.5KB**
- (b)上記に構文形式の変換関数を追加して、簡易Cコンパイラとして機能するようにしてみました → **28.0KB**
  - つまり簡易Cコンパイラを作るために要した記述は **4.5KB** 分のみ！
  - これはいいぞー

- 簡易ではなくもっとちゃんとサポートしたら、その差は10.0KBとかになる可能性はあります。でもきちんとC言語を作るよりはずっと楽ではあるでしょう、たぶん。

もっとやってみました

- この自作簡易Cコンパイラの出力を、先の自作アセンブラに渡して、それをそのまま実行してみました。つまりC言語のJITコンパイラです。→ **30.0KB**
  - あれ？JITコンパイラってこんなに簡単にできていいのかな？？（笑）

- さらにグラフィック関係の処理もできるようにして、簡単なプログラムをコンパイルせずにスクリプト言語みたいに実行して遊んでいます。

- （**誤解されやすいポイント**）
- **30KB**の自作ツールの他にgccとかclangとかが必要？ → 一切**不要**です！
- 特別なDLLファイルとかが必要なんじゃないの？ → 一切**不要**です！
- ヘッダファイルが巨大？ → 100行未満です。

30KBのJITコンパイラでもこれくらいは動く

- 素数を計算するプログラム
  - （今は配列変数が使えないので、あまり賢くはないアルゴリズムです）

```
int i, j;
for (i = 2; i < 100; i++) {
    for (j = 2; j * j <= i; j++) {
        if (i % j == 0) goto skip;
    }
    printf("%d ", i);
skip: ;
}
printf("¥n");
```

- 実行結果：

```
2 3 5 7 11 13 17 19 23 29 31 37 41 43 47 53 59 61 67 71 73 79 83 89 97
```

32KBのJITコンパイラでもこれくらいは動く

```
int x, y, c; c = 0;
openWin(256, 256);
for (y = 0; y < 256; y++) {
    for (x = 0; x < 256; x++) {
        setPix(x, y, c);
        c = c + 0x100;
    }
}
waitInf();
```


```
int x, y;
openWin(256, 256);
for (y = 0; y < 256; y++)
    for (x = 0; x < 256; x++)
        setPix(x, y, (x ^ y) * 0x10101);
waitInf();
```

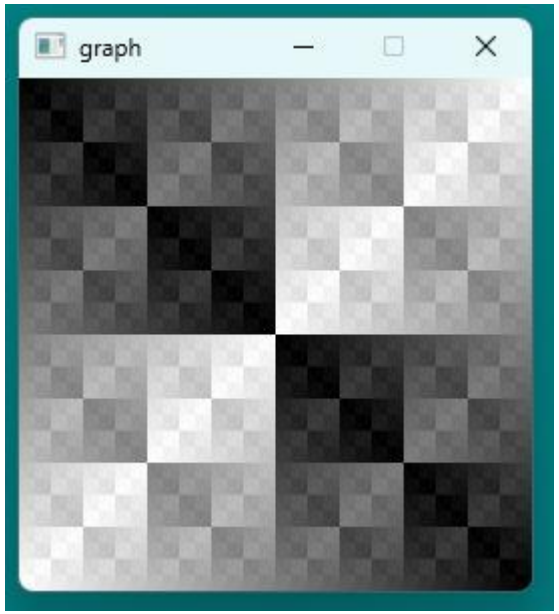

まとめ

- プリプロセッサの #define を使えば、難しい命令を簡単な命令の組み合わせに展開していくことができます。
- これにより**アセンブラ**や**Cコンパイラ**を簡単に作れそうです。
- C言語では、言語の基本構文がプリプロセッサマクロの構文とかけ離れているので、最初にそこを変換する関数は必要そうです。

- 今後は、配列やポインタや関数定義などの機能を増やしていって、それでも「簡単に作れる」が維持できるのか確かめたいです。

いただいた質問・コメント(1)

- [Q1] gasというアセンブラでは、マクロ機能を補うためにC言語のプリプロセッサを使います。そのための拡張子.Sが決められているくらいです（マクロを使わないときは.s）。
- このようにアセンブラにはプリプロセッサが必要なのですが、それを逆にしてプリプロセッサを先に用意すればアセンブラは簡単に作れるっていうのは、逆転の発想で面白いです！

- [A1] なるほど！私も.Sのことは知っていたのですが、最近アセンブラを使ってなくてちょっと忘れていました。その視点は面白いですね！！

いただいた質問・コメント(2)

- [Q2] C言語をマクロ形式に変換してからプリプロセッサでコンパイルするという事でしたが、その最初の「変換」のために、字句解析とかをやっていませんか？

- [A2] 鋭い指摘ですね！その指摘は正しいです。でもこの形式変換では、型を無視して加算をADD()にしているだけです。
- 普通のCコンパイラでは、加算演算子を見たときに、加算対象の型を必ず確認して、それに合わせて整数ADD、実数FADDなど、命令を変えて出力します。一方で、私の今回の方法では、プリプロセッサマクロの連鎖で変換できるようになればいいので、型は無視してADD()形式にしているだけです。だから簡単なのです。

いただいた質問・コメント(3)

- [Q3] 今回ような方法で言語を作る場合には、川合さんのプリプロセッサの独自拡張は必要ですか？それとも既存のC言語用のプリプロセッサでもできますか？

- [A3] 独自拡張がない場合、ADD()の中の型に応じて機械語を使い分けることができません。そうするとCコンパイラを作る時には、変換関数側が苦労しそうな気がします。苦労はしますが、本質的にできないわけじゃないです。
  - たとえば ADD_IntIntInt(a,b,c); みたいに出力するとか。