Compilation

Jean Goubault-Larrecq

LSV/CNRS UMR 8643 & ENS Cachan

Plan

1. L'idée de la compilation un exemple en C.
2. L'optimisation l'exemple, suite.
3. Autres langages. Un langage fonctionnel simple et sa sémantique.

Retour sur `cat`

Voici une façon (naïve) de programmer `cat`, en C:

```
main (int argc, char *argv[])       // ex: pour ‘cat a b’, argc=3,
{                                   // argv[0]="cat", argv[1]="a",
  int i, c;                         // argv[2]="b"

  for (i=1; i<argc; i++)            // pour chaque nom de fichier
    {
      FILE *f;

      f = fopen (argv[i], "r");     // ouvrir le fichier
      while ((c = fgetc (f))!=EOF)  // recuperer caractere suivant
        fputc (c, stdout);          // afficher le caractere
      fclose (f);                   // fermer le fichier
    }
  fflush (stdout);                  // *vraiment* afficher...
  exit (0);
}
```

Compilons ça pour voir

gcc -ggdb cat.c

```
          ; main (int argc, char *argv[]) {
          ;   int i, c;  FILE *f;   // 3x4 octets
0x8048150 <main>:       pushl  %ebp
0x8048151 <main+1>:     movl   %esp,%ebp
0x8048153 <main+3>:     subl   $0xc,%esp
          ; i=1
0x8048157 <main+7>:     movl   $0x1,-4(%ebp)
          ; while (i<argc)
0x804815e <main+14>:    movl   -4(%ebp),%eax
0x8048161 <main+17>:    cmpl   %eax,0x8(%ebp)
0x8048164 <main+20>:    jg     0x8048170 <main+32>
0x8048166 <main+22>:    jmp    0x80481f0 <main+160>
          ; empiler "r":   (gdb) x/s 0x8059d88
          ;                0x8059d88 <_fini+8>:     "r"
0x8048170 <main+32>:    pushl  $0x8059d88
          ; calcul de argv[i]
```

```
0x8048175 <main+37>:    movl   -4(%ebp),%eax
0x8048178 <main+40>:    movl   %eax,%edx
0x804817a <main+42>:    leal   0x0(,%edx,4),%eax
                               ; %eax:=%edx*4
0x8048181 <main+49>:    movl   0xc(%ebp),%edx
0x8048184 <main+52>:    movl   (%edx,%eax,1),%eax
                               ; %eax:=mem(%edx+%eax)
0x8048187 <main+55>:    pushl  %eax
          ; f = fopen (argv[i], "r")
0x8048188 <main+56>:    call   0x8048330 <fopen>
                               ; resultat dans %eax
0x804818d <main+61>:    addl   $0x8,%esp
0x8048190 <main+64>:    movl   %eax,%eax          ; ?
0x8048192 <main+66>:    movl   %eax,-12(%ebp)
          ; c = fgetc (f)
0x8048195 <main+69>:    movl   -12(%ebp),%eax
0x8048198 <main+72>:    pushl  %eax
0x8048199 <main+73>:    call   0x80483a0 <fgetc>
0x804819e <main+78>:    addl   $0x4,%esp
0x80481a1 <main+81>:    movl   %eax,%eax          ; ?
```

```
0x80481a3 <main+83>:    movl   %eax,-8(%ebp)
          ; if (c!=EOF)
0x80481a6 <main+86>:    cmpl   $-1,-8(%ebp)       ; EOF=-1
0x80481aa <main+90>:    jne    0x80481b0 <main+96>
0x80481ac <main+92>:    jmp    0x80481d0 <main+128>
          ; fputc (c, stdout)
0x80481b0 <main+96>:    pushl  $0x805ed8c         ; =stdout
0x80481b5 <main+101>:   movl   -8(%ebp),%eax
0x80481b8 <main+104>:   pushl  %eax
0x80481b9 <main+105>:   call   0x80483f0 <fputc>
0x80481be <main+110>:   addl   $0x8,%esp
          ; et on boucle (boucle interne)
0x80481c1 <main+113>:   jmp    0x8048195 <main+69>
          ; ici on sort de la boucle interne
          ; fclose (f)
0x80481d0 <main+128>:   movl   -12(%ebp),%eax
0x80481d3 <main+131>:   pushl  %eax
0x80481d4 <main+132>:   call   0x8048220 <_IO_fclose>
0x80481d9 <main+137>:   addl   $0x4,%esp
          ; i++
```

```
0x80481dc <main+140>:   incl   -4(%ebp)
          ; et on boucle (boucle externe)
0x80481df <main+143>:   jmp    0x804815e <main+14>
          ; ici on sort de la boucle externe
          ; fflush (stdout)
0x80481f0 <main+160>:   pushl  $0x805ed8c        ; =stdout
0x80481f5 <main+165>:   call   0x80482c0 <fflush>
          ; exit (0)
0x80481fa <main+170>:   addl   $0x4,%esp
0x80481fd <main+173>:   pushl  $0x0
0x80481ff <main+175>:   call   0x8048540 <exit>
0x8048204 <main+180>:   addl   $0x4,%esp
          ; et on retourne de main ():
0x8048210 <main+192>:   movl   %ebp,%esp
0x8048212 <main+194>:   popl   %ebp
0x8048213 <main+195>:   ret
```

Comment ça marche

- Le compilateur réserve de la place pour chaque variable locale sur la pile `%esp`; garde l'adresse du `%esp` initial dans `%ebp`.
- Compilation de $x{=}e$:
  - par récurrence sur la structure de e, on calcule la valeur de e dans un registre (par ex. `%eax`);
  - on compile `mov%eax,`⟨endroit réservé pour x⟩;
  - Défaut: produit des déplacements de valeurs redondants.
- Tests, boucles `while` et `for`: via `cmp`, `jge`, etc.
- Appels de fonction: empiler les arguments, `call`, dépiler; résultat dans `%eax`.

Exercices

- En supposant que `i` $= -12(\%$`ebp`$)$, `argc` $= 8(\%$`ebp`$)$, `argv` $= 12(\%$`ebp`$)$, `len` $= -4(\%$`ebp`$)$, proposer des suites d'instructions pour:
  - `len = 0`
  - `i++` (incrémenter `i`)
  - `len += ...`, où `...` est dans %`eax`.
- En déduire la forme compilée de:

```
len = 0;
for (i=1; i<argc; i++) len += strlen (argv[i]);
return len;
```

Bootstrap

- Le compilateur `gcc` est lui-même un programme.
- En fait, `gcc` est écrit en C et compilé... avec `gcc`

... permet en particulier de tester `gcc` sur un exemple non trivial.

... plus vicieux, on peut tester si `gcc` (`gcc`)=`gcc`.