

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 $i = -12(\%ebp)$, $\text{argc} = 8(\%ebp)$,
 $\text{argv} = 12(\%ebp)$, $\text{len} = -4(\%ebp)$, proposer des suites
d'instructions pour:
 - $\text{len} = 0$
 - $i++$ (incrémenter i)
 - $\text{len} += \dots$, où \dots 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`.