Cours de Compilation: 2004/2005

Maîtrise d'Informatique
Paris VII

Roberto Di Cosmo
e-mail: roberto@dicosmo.org
WWW: http://www.dicosmo.org

Modalités du cours

- Nb cours :
  12 (vendredi de 14h30 à 16h30 en Amphi 34A)
- Nb TD : 12 (début la semaine du 11 Octobre)
- Chargés de TD :
  Vincent Balat, Juliuz Chroboczeck, Alexandre Miquel
  Lundi 16h30-18h30 (J6), Mardi 12h30-14h30 (J4 et J7), Jeudi 16h30-18h30 (J8)
- Partiel projet : mi-décembre
- Soutenance projet : fin décembre
- Examen final : entre le lundi 17 janvier 2005 et le samedi 5 février 2005
- Note Janvier :
  $\frac{1}{2}$ note projet + $\frac{1}{2}$ exam Janvier
- Note Septembre :
  $\frac{1}{2}$ note projet + $\frac{1}{2}$ exam Septembre

Checklist

- inscrivez-vous tout de suite sur la mailing list:
  http://ufr.pps.jussieu.fr/wws/info/ml-0405-compilation
- marquez la page web du cours dans vos signets:
  http://www.dicosmo.org/CourseNotes/Compilation/
- commencez à reviser OCaml
- reflechissez à la composition des groupes pour le projet (maximum 3 personnes)

Plan du cours

1. Notions préliminaires : structure d'un compilateur (front-end, back-end, coeur), description de la machine cible assembleur (RISC 2000)
2. Mise à niveau Ocaml faite exclusivement en TP (langage disponible librement par ftp depuis l'Inria ftp.inria.fr)
3. Analyse lexicale et syntaxique :
   bref rappel sur Lex, Ocamllex, Yacc, Ocamlyacc
4. Arbre de syntaxe abstraite :
   structure et représentation
5. Analyse statique : typage (rappels)
6. Structure de la machine d'éxécution pour un langage a blocs
7. Pile des blocs d'activation pour fonctions/variables locales
8. Interface entre front-end et coeur: le code intermediaire (génération, optimisation, linéarisation)
9. Génération du code assembleur
10. Allocation des régistres
11. Extensions:
    - typage des types recursifs
    - allocation de registres par coloriage de graphes
    - compilation des langages à objets
    - compilation des langages fonctionnels
    - machines virtuelles
    - algèbre des T pour la génération et le bootstrap des compilateurs

Bibliographie

- Compilers: Principles, Techniques and Tools.
  Alfred V. AHO, Ravi SETHI, Jeffrey D. ULLMAN, Addison-Wesley. Version française en bibliothèque.
- Modern Compiler Implementation in ML.
  Andrew APPEL, CAMBRIDGE UNIVERSITY PRESS
  http://www.cs.princeton.edu/~appel/modern/ml/
  Une vingtaine de copies à la bibliothèque.

- Développement d'applications avec Objective Caml
  Emmanuel CHAILLOUX, Pascal MANOURY, Bruno PAGANO, O'Reilly. Bibliothèque et en ligne[1].
- Manuel Ocaml en ligne: http://caml.inria.fr/ocaml/htmlman/index.html
- SPIM, un simulateur RISC 2000 http://www.cs.wisc.edu/~larus/spim.html

Généralités: le terme "compilateur"

compilateur : *"Personne qui reunit des documents dispersés"* (Le Petit Robert)

compilation : *"Rassemblement de documents"* (Le Petit Robert)

Mais le programme qui "reunit des bouts de code dispersés" s'appelle aujourd'hui un *Editeur de Liens*[2]

Le terme "compilateur"

On appelle "compilateur" une autre chose:

com·pil·er (Webster)

1: one that compiles
2: *a computer program that translates an entire set of instructions written in a higher-level symbolic language (as COBOL[3]) into machine language before the instructions can be executed*

Qu'est-ce que le "langage machine"?

Notions (abstraites) de base

machine hardware le processeur

machines virtuelle une machine qui reconnait un certain nombre d'instructions qui ne sont pas toutes "natives" pour la machine hardware.
Ex: le compilateur C produit du code assembleur qui fait appel à un ensemble de fonctions système (ex.: les E/S). Donc il produit du code pour la machine virtuelle définie par les instructions hardware, plus les appels système.

On rencontre souvent les machines virtuelles suivantes

[1] http://www.pps.jussieu.fr/Livres/ora/DA-OCAML/index.html
[2] ld
[3] :-)

- Programmes d'application
- Langage de programmation evolué
- Langage d'assemblage
- Noyau du système d'exploitation
- Langage machine

Qu'est-ce qu'un *interpreteur*?

Un programme qui prends en entrée un autre programme, écrit pour une quelque machine virtuelle, et l'execute *sans le traduire*.

Ex:

- l'interpréteur VisualBasic,
- le toplevel Ocaml,
- l'interpreteur PERL,
- l'interpreteur OCaml,
- etc.

Qu'est-ce qu'un *compilateur*?

- Un *programme*, qui *traduit* un programme écrit dans un langage L dans un programme écrit dans un langage L' différent de L (en général L est un langage évolué et L' est un langage moins expressif).

  Quelques exemples:
  - Compilation des expressions régulières (utilisées dans le shell Unix, les outils sed, awk, l'éditeur Emacs et les bibliothèques des langages C, Perl et Ocaml)
  - Minimisation des automates (compilation d'un automate vers un automate plus efficace)
  - De LaTex vers Postscript ou HTML (latex2html/Hevea)
  - De C vers l'assembleur x86 plus les appels de système Unix/Linux
  - De C vers l'assembleur x86 plus les appels de système Win32

On peut "compiler" vers une machine... *interpretée* (ex: bytecode Java, bytecode Ocaml)

La décompilation

on va dans le sens inverse, d'un langage moins structuré vers un langage évolué.
Ex: retrouver le source C à partir d'un code compilé (d'un programme C).

Applications:

- récupération de vieux logiciels
- découverte d'API cachées
- ...

Ell'est authorisée en Europe à des fins d'interopérabilité

Notions (abstraites) de base, II

Il ne faut pas tricher... un compilateur ne doit pas faire de l'interprétation...

Pourtant, dans certains cas, il est inevitable de retrouver du code interprété dans le code compilé

- `printf("I vaut %d\n",i);`
  serait à la limite compilable

- `s="I vaut %d\n"; printf(s,i);`
  est plus dur

- alors que

```
void error(char *s)
     { printf(s,i);}
```

  devient infaisable

Pause questions ...

Pourquoi étudier des compilateurs?

Pourquoi construire des compilateurs?

Pourquoi venir au cours?

(Presque) toute l'informatique dans un compilateur

algorithmique	parcours et coloration de graphes[4] programmation dynamique[5] stratégie gloutonne[6]
théorie	automates finis[7], à pile[8] treillis, point fixe[9] réécriture[10]
intelligence artificielle	algorithmes adaptatifs recuit simulé
architecture	pipelining, scheduling

Un problème actuel

- on crée des nouveaux langages (essor des DSL[11]), ils ont besoin de compilateurs
- les anciens langages évoluent (C, C++, Fortran)
- les machines changent (architectures superscalaires, etc.)
- des concepts difficiles deviennent mieux compris, et implémentables (polymorphisme, modularité, polytypisme, etc.)
- les préoccupations changent (certification[12], securité)

Comparaison multicritères

Qu'est-ce qui est important[13] dans un compilateur?

- le code produit est rapide
- le compilateur est rapide
- les messages d'erreurs sont précis
- le code produit est correct
- le code produit est *certifié* correct
- il supporte un debogeur
- il supporte la compilation séparée
- il sait faire des optimisations poussées

[11] domain specific languages
[12] Travail de Andrew Appel
[13] pour vous

Structure logique d'un compilateur

Un compilateur est un logiciel très complexe:

- on essaye de réutiliser au maximum ses composantes, donc on identifie :

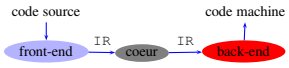

  - un "front-end" lié au langage source
  - un "back-end" lié à la machine cible
  - un "code intermédiaire" commun `IR` sur lequel travaille le coeur du système

Cela permet d'ecrire les nm compilateurs de n langages source à m machines cible

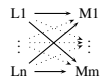

en écrivant seulement un coeur, n front-ends et m back-ends

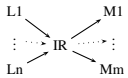

Structure d'un compilateur moderne

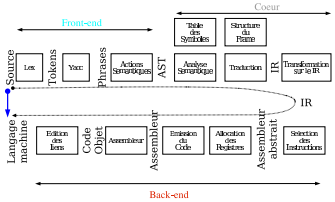

Structure détaillée d'un compilateur

Front-end:

- analyse lexicale (flot de lexemes)
  théorie: langages réguliers
  outils: automates finis
  logiciels: Lex (et similaires)

- analyse syntaxique (flot de reductions)
  théorie: langages algébriques
  outils: automates à pile
  logiciels: Yacc (et similaires)

- actions sémantiques
  (contruction de l'arbre de syntaxe abstrait, AST)
  outils: grammaires attribuées
  logiciels: encore Yacc

- analyse sémantique
  (vérification des types, portée des variables, tables des symboles, gestion des environnements etc.) rends l'AST décoré et les tables des symboles
  outils: grammaires attribuées, ou à la main

- traduction en code intermédiaire
  (souvent un arbre, independant de l'architecture cible)

Coeur:

- linéarisation du code intermédiaire
  (transformation en *liste* d'instructions du code intermediaire)

- différentes optimisations
  - analyse de vie des variables et allocation des registres
  - transformation des boucles
    (déplacement des invariants, transformations affines)
  - function inlining, depliement des boucles, etc.

Back-end:

- séléction d'instructions (passage du code intermédiaire à l'assembleur de la machine cible, eventuellement abstrait par rapport aux noms des registres)

- émission du code (production d'un fichier écrit dans l'assembleur de la machine cible)

- assemblage
  (production *des* fichiers contenant le code machine)

► édition des liens (production *du* fichier executable)

Ces quatre dernières phases *seulement*dépendent de la machine assembleur cible

Les phases cachées d'un compilateur: l'apparence

```
ranger> cat simplaffine.c
#include <stdio.h>
main ()
{int i=0;
  int j=0;
  for (i=0;i<10;i++)
     {j=6*i;};
  printf("Resultat: %d", j);
  exit(0);}

ranger> gcc -o simplaffine simplaffine.c
ranger> ls -l simplaffine*
-rwxr-xr-x  1 dicosmo    50784 Oct  2 15:43 simplaffine*
-rw-r--r--  1 dicosmo      139 Oct  2 15:42 simplaffine.c
```

Les phases cachées d'un compilateur: la réalité

```
ranger>gcc -v -o simplaffine --save-temps simplaffine.c
Reading specs from /usr/lib/gcc-lib/i386-linux/2.95.4/specs
gcc version 2.95.4 20011002 (Debian prerelease)
 /usr/lib/gcc-lib/i386-linux/2.95.4/cpp0
   -lang-c -v -D__GNUC__=2 -D__GNUC_MINOR__=95 -D__ELF__ -Dunix
   -D__i386__ -Dlinux -D__ELF__ -D__unix__ -D__i386__
   -D__linux__ -D__unix -D__linux -Asystem(posix)
   -Acpu(i386) -Amachine(i386) -Di386 -D__i386 -D__i386__
   simplaffine.c simplaffine.i
GNU CPP version 2.95.4 20011002 (Debian prerelease) (i386 Linux/ELF)
 /usr/lib/gcc-lib/i386-linux/2.95.4/cc1 simplaffine.i
   -quiet -dumpbase simplaffine.c -version -o simplaffine.s
GNU C version 2.95.4 20011002 (Debian prerelease) (i386-linux) compiled by
as -V -Qy -o simplaffine.o simplaffine.s
GNU assembler version 2.12.90.0.1 (i386-linux) using BFD version 2.12.90.0.
 /usr/lib/gcc-lib/i386-linux/2.95.4/collect2
   -m elf_i386 -dynamic-linker /lib/ld-linux.so.2
   -o simplaffine /usr/lib/crt1.o /usr/lib/crti.o
   /usr/lib/gcc-lib/i386-linux/2.95.4/crtbegin.o
   -L/usr/lib/gcc-lib/i386-linux/2.95.4 simplaffine.o
   -lgcc -lc -lgcc
```



```
   /usr/lib/gcc-lib/i386-linux/2.95.4/crtend.o /usr/lib/crtn.o

ranger>  ls -al simplaffine*
-rwxrwxr-x  1 dicosmo    4764 Sep 19 18:29 simplaffine
-rw-rw-r--  1 dicosmo     136 Sep 19 18:28 simplaffine.c
-rw-rw-r--  1 dicosmo   21353 Sep 19 18:29 simplaffine.i
-rw-rw-r--  1 dicosmo    1028 Sep 19 18:29 simplaffine.o
-rw-rw-r--  1 dicosmo     877 Sep 19 18:29 simplaffine.s
```

4 étapes:

- ► *preprocesseur*: `cpp0` traduit simplaffine.c en simplaffine.i
- ► *compilateur*: `cc1` traduit simplaffine.i en simplaffine.s
- ► *assembleur*: `as` traduit simplaffine.s en simplaffine.o
- ► *éditeur de liens*: `collect2`[14] transforme `simplaffine.o` en executable `simplaffine`, en résolvant les liens externes

Un exemple simple

```
#include <stdio.h>
main ()
{int i=0;
  int j=0;
  for (i=0;i<10;i++)
     {j=6*i;};
  printf("Resultat: %d", j);
  exit(0);}
```

Produit:

```
ranger> gcc -o simplaffine -v -save-temps simplaffine.c
```

Un exemple simple: preprocesseur

```
#1 "simpleaffine.c"
#1 "/usr/include/stdio.h" 1
...
extern int printf ( const char * format , ... ) ;
...
#1 "simpleaffine.c" 2
main ( )
{ int i = 0 ;
  int j = 0 ;
```

[14] un enrobage de `ld`


```
  for ( i = 0 ; i < 10 ; i ++ )
  { j = 6 * i ; } ;
  printf ( "Resultat: %d" , j ) ;
  exit ( 0 ) ; }
```

Un exemple simple: compilation vers assembleur

```
   .file   1 "example.c"
   .rdata
   .align  2
$LC0:
   .ascii  "Resultat: "
   .text
   .align  2
   .globl  main
   .ent    main


                        # prologue de la fonction
main:
   subu    $sp,$sp,48       # allocation variables sur la pile
   sw      $31,40($sp)      # sauve adresse de retour
   sw      $fp,36($sp)      # sauve vieux frame pointer
   sw      $28,32($sp)      # sauve gp
   move    $fp,$sp          # change frame pointer
   sw      $0,24($fp)       # initialise variable i
   sw      $0,28($fp)       # initialise variable j
   sw      $0,24($fp)       # compilo bete

$L3:
   lw      $2,24($fp)       # charge i dans $2
   slt     $3,$2,10         # |
   bne     $3,$0,$L6        # si i<10, va a L6
   j       $L4
$L6:
   lw      $2,24($fp)       #charge i dans $2 (encore!)
   move    $4,$2            #i dans $4
   sll     $3,$4,1          #$3 = $4*2
   addu    $3,$3,$2         #$3 = $3+$2 = 3* $2
   sll     $2,$3,1          #$2 = $3 *2 = 6* $2
   sw      $2,28($fp)       #j  = $2 = 6*i

$L5:
   lw      $2,24($fp)       #$2 = i (encore!!!)
   addu    $3,$2,1          #$3 = i+1
   sw      $3,24($fp)       #i= $3 = i+1
   j       $L3              #on reboucle a L3
```



```
$L4:                        # on a fini!!!!!!
   la      $a0,$LC0
   li      $v0,4            # print_string
   syscall
   lw      $a0,28($fp)
   li      $v0,1            # print_int
   syscall

$L2:
   move    $sp,$fp          # epilogue:
   lw      $31,40($sp)      # on restaure sp, fp, gp, ra
   lw      $fp,36($sp)
   addu    $sp,$sp,48
   j       $31              # on revient la ou on nous a appele
   .end    main
```

OUFFF!

Un exemple simple: optimisations I

Le compilateur arrive a faire tenire tout dans des registres, et trouve une façon plus efficace pour multiplier par 6.

```
main:
   subu   $sp,$sp,32       # alloue place sur la pile
   sw   $31,28($sp)        # sauve adresse de retour
   sw   $28,24($sp)        # sauve gp
   move   $3,$0            # initialise $3 (i) a 0


$L23:
   sll   $2,$3,1           # ]
   addu   $2,$2,$3         # met $3 * 6 dans $5 (j)
   sll   $5,$2,1           # ]
   addu   $3,$3,1          # incremente $3
   slt   $2,$3,10          #]
   bne   $2,$0,$L23        #si $3 < 10, reviens a $L23:
   la   $a0,$LC0           # on a fini!!!!!
   li     $v0,4            # print_string
   syscall
   li     $v0,1            # print_int
   addu   $a0,$5,$0        # imprime j
   syscall
```

Un exemple simple: optimisations II

Le compilateur decouvre que j est une fonction affine de i.

```
main: li      $2,9            # boucle de 9 a 0
$L23:
      addu    $2,$2,-1        # decremente $2
      bgez    $2,$L23         # si pas 0, va a $L23
      la      $a0,$LC0        # on a fini!
      li  $v0,4               # print_string
      syscall
      li  $v0,1               # print_int
      li      $a0,54          # 0x36
      syscall
```