

## Projet 2: un compilateur

**cours:** Daniel Hirschhoff

**TPs:** Ghislain Charrier et Bogdan Pasca

## *Présentation du cours*

# Programmation, compilation

- ▶ cours orienté pratique
- ▶ quelques indications pour démarrer, puis se prendre en main
- ▶ évaluation: vous rendez un *compilateur*
  - ▶ un programme qui prend en argument un programme (le source), et renvoie un programme (l'objet)
  - ▶ programme que l'on compile à l'aide d'un compilateur. . .

# Règles du jeu

- ▶ en binôme (au plus un monôme)
- ▶ travail clairement affecté au sein du binôme
- ▶ questionnaire
  - ▶ “projet 1 + ...”
  
- ▶ *si vous ne savez pas encore si vous allez valider ce module, merci de l'indiquer sur la fiche*
- ▶ stratification des étudiants

# Évaluation – étapes de la construction

- ▶ jalons dans le semestre
  - ▶ 15-21 février: vacances d'hiver
  - ▶ 12-18 avril: vacances de pâques
  - ▶ 21 mai: fin des cours (24-28: examens)
- ▶ quatre étapes
  1. analyses lexicale et syntaxique 24 février
  2. représentation intermédiaire, structures à l'exécution 29 mars
  3. *un* programme tourne 26 avril
  4. le compilateur est prêt 18 mai
- ▶ ces dates sont déplaçables (interférences avec d'autres cours)  
*au plus tard 15 jours à l'avance*

# Quel compilateur

- ▶ par défaut: Pascal -  $\rightsquigarrow$  RISC
  - ▶ dans quel langage? cf. transparent suivant
  - ▶ solution la plus raisonnable, où vous apprendrez ce qu'il faut apprendre
  
- ▶ sinon
  - ▶ Caml -  $\rightsquigarrow$  C
    - en Caml, pour apprendre le C
  - ▶ Haskell -  $\rightsquigarrow$  G-machine
    - ... sujet à "censure" de ma part
  
- ▶ autres
  - (ne) parlentons (pas)

# Dans quel langage développer le compilateur

- ▶ trois choix      OCaml      C      Java
- ▶ OCaml préconisé
  - ▶ pas de problèmes de pointeurs ou de `malloc`
- ▶ C ou Java
  - ▶ vous connaissez bien l'un de ces langages, ou alors
  - ▶ vous êtes plutôt à l'aise avec les bases de la compilation et vous voulez apprendre l'un de ces langages
- ▶ *autre*: parlémentons

# Références

- ▶ je vous conseille le tryptique d'Andrew Appel
  - ▶ disponibles à la bibliothèque
  - ▶ la première moitié du livre essentiellement
- ▶ google vous renseignera (notamment pour `bison`, `flex`, `ocamllex`, etc.)
- ▶ vos chargés de TPs et de cours aussi



## Déroulement du cours

- ▶ cette semaine 

pas de TP
-----------
- ▶ quelques séances de cours (3, 4)
- ▶ les TPs démarrent un peu décalés
- ▶ puis rien que des TPs

*allons-y*

# Les étapes de la compilation

code source             $\rightsquigarrow$     code objet  
(dans un fichier)            (dans un autre fichier)

programme source

↓ analyse lexicale, analyse syntaxique

arbre de syntaxe abstraite

↓ analyses statiques (typage, ...)

arbre décoré

↓ traductions, optimisations

code exécutable (langage machine)

lecture du fichier source: on récupère un *flot de caractères*

*Analyse lexicale*  
*chapitre 2 dans le livre d'A. Appel*

# Les deux étapes

## ► analyse lexicale

flot de caractères (source) → flot de *lexèmes*

- lexème (*token*): "atome" du langage
- typiquement:
  - mots-clefs (`let`, `begin`, `while`,...)
  - symboles réservés (`(`, `+`, `;;`, `;`,...)
  - identificateurs (`f`, `toto`, ...)

## ► ainsi `32*52+(let x = 5 in x*x)`

→ `INT(32), MULT, INT(52), ADD, LPAREN, LET, ID("x"), EGAL, INT(5), IN, ID("x"), MULT, ID("x"), RPAREN`  
(`INT` et `ID` ont un *attribut*, entier et chaîne de caractères respectivement)

## ► analyse syntaxique

flot de lexèmes → *arbre de syntaxe abstraite*

→ `Add( Mult(Int(32), Int(52)),  
Let("x", Int(5), Mult(Var("x"), Var("x"))) )`



- étape intermédiaire: arbre d'analyse syntaxique (*parse tree*)

# Analyse lexicale


chaque lexème est décrit par une *expression régulière*  
principaux éléments (syntaxe de `ocamllex`):

- ▶ caractère '\$', chaîne de caractères "else"
- ▶ intervalle ['0'-'9'] (*un chiffre*)
- ▶ disjonction ['\t' ' ''] (*tabulation ou espace*)
- ▶ juxtaposition ['A'-'Z']['a'-'z' 'A'-'Z']  
(*mot de 2 lettres commençant par une majuscule*)
- ▶ répétitions: + signifie au moins 1, \* zéro ou plus  
['a'-'z']+['a'-'z' '0'-'9']\*  
(*ça commence par une lettre puis des lettres ou des chiffres*)
- ▶ (re)disjonction a\* | b\*


# Expression régulière $\leftrightarrow$ automate non déterministe



NFA pour  $b|c$




NFA pour  $(b|c)^*$



NFA pour  $a(b|c)^*$

# Déterminisation, minimisation

- ▶ à partir de l'automate du transparent précédent, on dispose de procédures pour *déterminiser* l'automate (explosion du nombre d'états), puis le *minimiser*



- ▶ on aboutit à
- ▶ comment implémenter l'automate résultant? © T. Risset, F. de Dinechin

- ▶ une table (très creuse)

état	a	b	c	d	e
e1	-	e2	e3	-	-
e2	e4	-	-	-	-
e3	-	-	e3	-	-

- ▶ éliminer les états: un plat de spaghetti, fait de *if* et de *goto*



## L'automate en action

figures 2.4 page 22 et 2.5 page 24

## Pour résumer



# Outils logiciels pour faire tout ça

- ▶ en pratique, on utilise des **compilateurs**
  - ▶ d'expressions régulières  
vers un automate
  - ▶ de règles de grammaire  
vers un automate à pile
- ▶ des couples (analyseur lexical)/(analyseur syntaxique) sont monnaie courante
  - ▶ ici: ocamllex/ocamlyacc
  - ▶ en TP: une autre version

## ocamllex

- ▶ on met tout ça dans un fichier `lexer.mll`, en associant un lexème à chaque expression régulière
  - ▶ quand plusieurs règles s'appliquent, c'est celle qui donne le lexème le plus long qui gagne, et s'il y a encore ambiguïté c'est la première règle dans l'ordre où elles sont écrites
  - ▶ DÉMO `lexer.mll` *(lexer = analyseur lexical)*
- ▶ un outil comme `ocamllex` transforme une liste d'expressions régulières en un *automate* déterministe, représenté par sa table de transitions  
résultat de la compilation: fichier `lexer.ml`
  - ▶ `ocamllex`, mais aussi (surtout) `lex`, `flex`

# Forme d'un fichier Lex

## ► structure du fichier

1. déclarations (C, Caml, ..)

```
#open Toto
```

c'est là qu'on fait référence à la définition des lexèmes

2. définitions / abbréviations

```
digits [0-9]+
```

3. expressions régulières accompagnées d'actions

► on associe un lexème à chaque expression régulière

► certains lexèmes ont un *attribut*:

on explique comment le calculer

```
| ['0'-'9']+ as k { INT (int_of_string k) }
```

## ► l'approche est très similaire en C:

```
[1-9][0-9]* {  
    yy1val.iValue = atoi(yytext);  
    return INTEGER;  
}
```

```
[ \t\n]+ ; /* ignore whitespace */
```

*Analyse syntaxique*  
*chapitre 3 dans le livre d'A. Appel*

# Analyse syntaxique

- ▶ l'analyse syntaxique se fonde sur une approche plus puissante:  
**règles de grammaire**

- ▶ les règles de grammaire font intervenir les lexèmes et des “variables” (les non terminaux)
- ▶ exemple de grammaire:

$$E ::= K \mid E + E \mid E * E \mid (E) \mid \text{let } Id = E \text{ in } E$$

- ▶  $E$ : non terminal (il peut y en avoir plusieurs)
- ▶  $K, \text{let}, Id, +, *, (, ), \text{in}, =$ : lexèmes
- ▶ le  $|$  se lit comme un “ou”

présentation alternative:

$$E \rightarrow K \quad E \rightarrow E + E \quad E \rightarrow E * E \quad E \rightarrow (E) \quad E \rightarrow \text{let } Id = E \text{ in } + E$$

on parle de *grammaire hors contexte*

- ▶ analyse lexicale: on transforme un *flot* de lettres en un *flot* de “grosses lettres” (les lexèmes)
- ▶ analyseur syntaxique (ou *parser*): applique les règles de grammaire pour *reconnaître* une suite de lexèmes
  - ▶ on change la structure: un *flot* (de lexèmes) devient un *arbre*

# Reconnaître une séquence de lexèmes

- ▶ l'idée est de construire un *arbre de dérivation* permettant de reconnaître la suite de lexèmes

- ▶ grammaire:  $P ::= P + P \mid P * P \mid K$   $K$  un entier
- ▶ soit le flot  $32, +, 26, *, 2$
- ▶ on peut faire deux dérivations:

$P$	$\rightarrow$	$P + P$		$P$	$\rightarrow$	$P * P$
	$\rightarrow$	$K_{32} + P$			$\rightarrow$	$P * K_2$
	$\rightarrow$	$K_{32} + P * P$	ou alors		$\rightarrow$	$P + P * K_2$
	$\rightarrow\rightarrow$	$K_{32} + K_{26} * K_2$			$\rightarrow\rightarrow$	$K_{32} + K_{26} * K_2$

deux arbres différents: *ambiguïté*

- ▶ aucune dérivation possible en revanche pour  $9 * 1 + + 1$



## Ce que fait le parser

$E ::= E + E \mid E * E \mid (E) \mid a \mid b \mid c$        $a+b*c$

pile	entrée	action
\$	$a + b * c \$$	shift
$\$a$	$+b * c \$$	reduce : $E \rightarrow a$
$\$E$	$+b * c \$$	shift
$\$E+$	$b * c \$$	shift
$\$E + b$	$*c \$$	reduce : $E \rightarrow b$
$\$E + E$	$*c \$$	shift <b>(très malin)</b>
$\$E + E*$	$c \$$	shift
$\$E + E * c$	$\$$	reduce : $E \rightarrow c$
$\$E + E * E$	$\$$	reduce : $E \rightarrow E * E$
$\$E + E$	$\$$	reduce : $E \rightarrow E + E$
$\$E$	$\$$	accept

- ▶ construction d'une dérivation "*par la droite*"

# Mettre au point une grammaire

- ▶ le langage de programmation, c'est la grammaire
- ▶ bugs=conflit 'shift/reduce': ambiguïté de la grammaire

DÉMO

```
12: shift/reduce conflict (shift 8, reduce 4) on PLUS
12: shift/reduce conflict (shift 9, reduce 4) on TIMES
state 12
  expr : expr . PLUS expr (4)
  expr : expr PLUS expr . (4)   le cas qui pose pb
  expr : expr . TIMES expr (5)

PLUS shift 8   ce qui a été choisi
TIMES shift 9  ce qui a été choisi
RPAREN reduce 4
EOL reduce 4
```

- ▶ lever l'ambiguïté:
  - ▶ modifier la grammaire (p.ex. en ajoutant des non terminaux)

de  $S \rightarrow \text{if } E \text{ then } S \text{ else } S$   
 $S \rightarrow \text{if } E \text{ then } S$       à       $S \rightarrow M$  *matched*  
 $S \rightarrow U$  *unmatched*  
 $M \rightarrow \text{if } E \text{ then } M \text{ else } M$   
 $M \rightarrow \text{autres}$   
 $U \rightarrow \text{if } E \text{ then } S$   
 $U \rightarrow \text{if } E \text{ then } M \text{ else } U$

- ▶ introduire des précédences  
(dans l'exemple du transparent précédent, le \* a une précédence plus grande que celle de la règle qu'il veut réduire, et donc on fait shift)

## ocamlyacc

- ▶ la version Caml de `yacc` (cf. aussi `bison`)
- ▶ générateur d'analyseurs syntaxiques
- ▶ on indique les lexèmes et les règles de grammaire
- ▶ + des artefacts, pour gérer les questions de priorité des règles, signaler des erreurs de syntaxe de manière informative, etc.
- ▶ DÉMO `parser.mly`

# Tout mettre ensemble

```
let lexbuf = Lexing.from_channel stdin
let parse () = Parser.main Lexer.token lexbuf
```

Parser.main :

```
(Lexing.lexbuf -> Parser.token) -> Lexing.lexbuf -> Expr.expr = <fun>
```

- ▶ on prend l'entrée standard (`stdin`, le clavier)
- ▶ on fait l'analyse lexicale, `lexbuf` est un flot de lexèmes
- ▶ l'analyse syntaxique renvoie un `Expr.expr` (cf. `parser.mly`)  
l'application `parse ()` renvoie la prochaine expression reconnue sur la saisie au clavier
- ▶ DÉMO `main.ml`
  
- ▶ cf. la doc de Caml (*Lexer and parser generators*)

*Constitution des binômes*

*SPIM*

# Présentation de SPIM

- ▶ SPIM simule une machine MIPS
  - ▶ n'est pas fidèle à la machine simulée en termes de performances
  - ▶ propose des *pseudo-instructions* (qui sont gérées de manière astucieuse par la vraie architecture, pas par le simulateur)
- ▶ on voit l'assembleur de SPIM comme un langage de programmation, avec son modèle d'exécution
- ▶ documentation de SPIM disponible (`spim.ps`)  
`xspim` pour cliquouiller
- ▶ le "moteur"
  - ▶ unité de calcul (CPU)
  - ▶ 32 registres, avec des conventions de nommage et d'utilisation: les respecter (si on était en vrai, il faudrait les respecter pour la compatibilité avec d'autres codes)


# SPIM: ingrédients

- ▶ instructions en SPIM: un langage impératif

```
        bli      # commentaire captivant
machin: blu
        blo
```

*tout* réside quelque part en mémoire

- ▶ organisation de la mémoire





## Instructions de SPIM (aperçu)

- ▶ opérations: elles se font uniquement sur les registres
  - `add` *ri, rj, rk* la somme de *rj* et *rk* dans *ri*
  - `add` *ri, rj, n* *rj+n* dans *ri*
  - `addu` même chose en traitant ses arguments comme des entiers non signés
  - `div` *ri, rj* divise *ri* par *rj*; quotient dans *lo*, reste dans *hi*
  - `seq` *ri, rj, rk* *ri=1* si *rj=rk*, 0 sinon
  - `seq` *ri, rj, n* *ri=1* si *rj=n*, 0 sinon
- ▶ sauter
  - `j` *lab* saut à l'instruction labélisée par *lab*
  - `jal` *lab* saute en *lab* après avoir noté en *ra* l'adresse de l'instruction suivante
  - `beq` *ri, rj, lab* va en *lab* si *ri=rj*
  - `beq` *ri, n, lab* va en *lab* si *ri=n*

# Instructions de SPIM (suite de l'aperçu)

- ▶ interactions avec la mémoire
  - `lw` *ri*, *add* met dans *ri* le mot situé en *add*
  - `la` *ri*, *add* met dans *ri* l'*adresse* *add*
  - `li` *ri*, *k* met *k* dans *ri*

## formes possibles des adresses

- `(rj)` adresse contenue dans *rj*
- `k(rj)` *k* + adresse contenue dans *rj*
- `lab` adresse du label *lab*
- `k` l'entier *k*
- `sw` *ri*, *add* recopie le contenu de *ri* en *add*

# SPIM – autres

## ▶ primitives prédéfinies: appels système

```
li $v0, 1    1 signifie print_int  
li $a0, 32   32 est la valeur à imprimer  
syscall
```

## ▶ directives

- ▶ `.text` BLA mettre BLA dans la zone de texte
- ▶ `.data` BLA mettre BLA dans la zone de données

```
str:  .data                                     des données  
      .asciiz "le plus difficile, ce n'est pas\n"  un label, des données  
      .text                                     du code  
li $v0, 4                                       4 signifie print_string  
li $a0, str  
syscall
```

*Génération de code*

# Redescendre de l'arbre

- ▶ analyses lexicale et syntaxique: le *front end* d'un compilateur
- ▶ *back end*: génération de code
  - à partir d'un arbre (pas trop l'arbre de syntaxe abstraite, mais le résultat de potentiellement beaucoup de transformations et d'analyses) on engendre du code *linéaire*

# La pile

- ▶ la structuration de programmes en fonctions qui s'appellent entre elles rend naturelle l'utilisation d'une **pile**
- ▶ sur la pile: *enregistrements d'activation*
  - ▶ ce sont des enregistrements (*records*)
  - ▶ leur présence sur la pile correspond à la période durant laquelle l'appel de la fonction est actif
- ▶ retour aux expressions arithmétiques

```
type expr =  
  Const of int  
  | Add of expr*expr  
  | Sub of expr*expr  
  | Mul of expr*expr  
  | Div of expr*expr  
  | IfEq of expr*expr*expr*expr  
          (* if e1 = e2 then e3 else e4 *)
```

# Évaluer les expressions arithmétiques sur la pile

une **machine abstraite à pile**: modèle d'exécution intermédiaire

(le modèle, pas l'exécution)

- ▶ pour évaluer `Add(Const 5, Const 7)`, on engendre

`push 7`

`push 5`

`add`

- ▶ l'appel à `add`
  - ▶ dépile les arguments
  - ▶ fait le calcul
  - ▶ met le résultat sur le sommet de la pile
- ▶ l'expression `Add(Const 5, Const 7)` est traduite en une suite d'instructions de la *machine abstraite*
  - ▶ la pile + un jeu simple d'instructions
  - ▶ abstraction: on ne rentre pas dans les détails sur l'architecture, sur comment est implémentée la pile, etc. (*portabilité, p.ex. Java*)
- ▶ le sommet de la pile est accédé très fréquemment  
p.ex. trois accès lors de l'exécution de `add`

# Un peu plus de détails

- ▶ Raffinement de la machine abstraite
  - ▶ on dispose d'un *registre*, l'accumulateur, nommé `acc`
    - ▶ registre: accès rapide (il y en a généralement plus d'un!)
  - ▶ les calculs se font sur l'accumulateur
  - ▶ la pile n'est utilisée que pour stocker les arguments
- ▶ cela donne (nouveau jeu d'instructions)

```
acc ← 7
push acc
acc ← 5
acc ← acc + top    (* opération atomique *)
pop
```



## Exemple un peu plus grand: $3 + (7 + 5)$

```
acc <- 3
push acc
  acc <- 7
  push acc
  acc <- 5
  acc <- acc + top
  pop
acc <- acc + top
pop
```

### ▶ *leitmotive*

- ▶ on rend la pile dans l'état de propreté dans laquelle on l'a trouvée
- ▶ le résultat est en `acc` à la fin

### ▶ but du jeu

- ▶ jeu d'instructions simples
- ▶ traitement uniforme (ici: évaluer une addition)
- ▶ les instructions correspondent à des opérations élémentaires en machine

# Raffinement encore: 'programmer' la pile soi-même

on atteint le niveau de SPIM

```
acc <- 7          li $a0, 7
push acc         sw $a0, 0($sp)
                 add $sp, $sp, -4
acc <- 5          li $a0, 5
acc <- acc + top  lw $t1, 4($sp)
                 add $a0, $a0, $t1
pop              add $sp, $sp, 4
```

- ▶ `$sp` registre contenant l'adresse de la fin de la pile
- ▶ `li reg, imm` met le registre `reg` à `imm`
- ▶ `sw reg1, decalage(reg2)` stocke le contenu de `reg1` à l'adresse (contenu de `reg2`)+`decalage`
- ▶ `add reg1, reg2, imm` ajoute `imm` au contenu de `reg2` et stocke dans `reg1`
- ▶ `add reg1, reg2, reg3` ajoute les contenus de `reg2` et `reg3` et stocke cela en `reg1`
- ▶ `lw reg1, decalage(reg2)` charge ce qui est stocké en l'adresse en `reg2` + `decalage` dans `reg1`
- ▶ le résultat est en `$a0` à la fin

## Le backend: de l'arbre au fichier objet

► Const i → 

```
print_string "li $a0 "; print_int i;
print_string "\n";
```

```
engendre(e1);
print_string("sw $a0, 0($sp)\n");
print_string("add $sp, $sp, -4\n");
```

► Add (e1,e2) → 

```
engendre(e2);
print_string("lw $t1, 4($sp)\n");
print_string("add $a0, $a0, $t1\n");
print_string("add $sp, $sp, 4\n");
```

# Branchements (in)conditionnels

if e1=e2 then e3 else e4

```
                ‘engendre(e1)’  
sw $a0, 0($sp)  
add $sp, $sp, -4  
                ‘engendre(e2)’  
lw $t1, 4($sp)  
add $sp $sp 4  
beq $a0, $t1, branche_vrai  
branche_faux: ‘engendre(e4)’  
                b fin_if  
branche_vrai: ‘engendre(e3)’  
fin_if:        ...
```

exercice: boucles

# Les fonctions


- ▶ l'enregistrement d'activation d'un appel de fonction contient
  - ▶ les paramètres d'appel de la fonction nécessaires à l'exécution de l'appel
  - ▶ + de quoi entrer et sortir dans la fonction
- ▶ deux morceaux de code à engendrer
  1. préparer la pile avant l'appel et **lancer l'appel**
  2. **corps de la fonction**: faire le calcul, et sortir de la fonction

```
corps_f:  inst1
          inst2
          :
```

## Appel de la fonction: $f(e_1, \dots, e_n)$

```
‘engendre(en)’  
sw $a0, 0($sp)  
add $sp, $sp, -4  
:  
:  
‘engendre(e1)’  
sw $a0, 0($sp)  
add $sp, $sp, -4  
jal code_f  
blibli
```

on stocke sur la pile les  
arguments de la fonction  
puis on y va (`code_f`)



- ▶ `jal`: saute à l'adresse donnée, et stocke l'adresse qui suit le `jal` dans un registre spécial, `$ra`
- ▶ lorsqu'on saute,
  - ▶ `$sp` pointe vers le début de la pile; celle-ci a grandi
  - ▶ `$ra` contient l'adresse de l'instruction à exécuter en retournant de l'appel
  - ▶ il faudra retourner en `blibli` lorsque `f` aura terminé son calcul

## Au sein de la fonction $f(x_1, \dots, x_n) = \text{corps}$

```
code_f:  sw $ra, 0($sp)
         add $sp, $sp, -4
         ‘engendrer(corps)’
         lw $ra, 4($sp)
         add $sp, $sp ‘4*n+4’
         jr $ra
```

- ▶ on stocke ce que contient  $\$ra$  dans la pile  
l'enregistrement fait donc  $4*n+4$  octets
  - ▶ on calcule le corps de la fonction
  - ▶ on remet l'adresse de retour dans  $\$ra$
  - ▶ on fait décroître la pile
  - ▶ on sort ( $jr$ : sauter à l'adresse contenue dans un registre)  
~> on exécutera `bibli`
- ▶ on ne voit pas apparaître  $\$a0$ : il est dans `corps`
  - ▶ optimisation: si `corps` ne fait pas d'appel de fonction, ne pas toucher à  $\$ra$
  - ▶ tout ceci est donné à titre d'exemple  
en réalité, on fait plus compliqué: les arguments sont passés si possible dans des registres, les registres sont sauvegardés (par l'appelant, par l'appelé)

## Quelques mots encore

- ▶ voilà notre premier “compilateur” : un front end, un back end
  - ▶ **DÉMO**
  - ▶ *on aurait pu tout faire en une passe...*
    - ▶ au lieu de `| expr PLUS expr { Add($1,$3) }`,  
mettre `| expr PLUS expr { $1 + $2 }`  
*... seulement tant que le langage est banal (let f x = ...)*
  - ▶ il s'agit ici d'un exemple
    - ▶ autres jeux d'instructions
    - ▶ autres conventions d'appel pour les fonctions  
(si possible, tous les paramètres dans les registres)
    - ▶ :
  - ▶ ce n'est pas fini: optimisations
    - ▶ *inlining*: `let f x = x+1, for i=1 to 2 do BLA`
    - ▶ *“jump around”*
    - ▶ :



# Votre compilateur

- ▶ front-end: dépend du langage choisi
- ▶ back-end, génération de code:
  - ▶ SPIM pour Pascal-
  - ▶ C pour Caml- (programmer la pile en C)
  - ▶ à définir pour Haskell-

*Entre le front-end et le back-end*

# Organisation

- ▶ les groupes sont constitués
- ▶ la semaine prochaine: vacances
- ▶ première deadline: le 26 février
  - ▶ analyse lexicale
  - ▶ analyse syntaxique
  - ▶ affichage de l'AST
  - ▶ davantage si vous le sentez, bien sûr (analyse statique: portée, typage, warnings...)
- ▶ changement de créneau à la rentrée:
  - ▶ ok pour tout le monde lundi 16h-18h?
  - ▶ mardi 13h30-15h30 quand il n'y a pas Sieste, et 16h-18h sinon? (G.Charrier ne peut pas mardi 16-18)

## Table des symboles – analyse statique (chap. 5 livre A. Appel)

- ▶ tout au long de la phase de compilation, on manipule des structures de données auxiliaires
- ▶ *table des symboles*, implémentée comme une table de hachage des informations sur tous les identificateurs utilisés par le programme
  - ▶ nom de type
  - ▶ déclaration globale: type, localisation
  - ▶ fonction: son nom, le nom de son label d'entrée  
ses paramètres: leur nom, leur type, leur taille, leur localisation  
ses variables locales  
autres informations (récursive, terminale)

à vous d'affiner/préciser

- ▶ table des symboles de départ, avec ce qui est prédéfini (constantes, etc.)
- ▶ analyse statique: vous avez fait Prog 1  
on range un symbole nouveau, on vérifie ensuite ses usages

## Représentation intermédiaire (chap. 7 livre A. Appel)

- ▶ il est naïf d'engendrer du code en une passe  $a = b+c$ 
  - ▶ choisir la bonne instruction assembleur
  - ▶ distribution des données entre registres et mémoire (p.ex., si on doit récupérer  $c$  en mémoire)
  - ▶ traduction de `read(a)`:  $a$  est un global ou une variable locale?
- ▶ 7.1 dans le livre d'A. Appel offre une bonne illustration:
  - ▶ constantes entières, labels
  - ▶ `TEMP(t)` un temporaire (ou *registre virtuel*)
  - ▶ `BINOP(o,e1,e2)` opération binaire
  - ▶ `CALL(f,arglist)` appel de fonction avec ses arguments
  - ▶ `MOVE` (avec `MOVE(TEMP t,e)` et `MOVE(MEM e1, e2)`)
  - ▶ `JUMP(e,labs)` labs liste les labels où l'on peut sauter (selon l'évaluation de  $e$ )
  - ▶ `SEQ(s1,s2)` la séquence
- ▶ le but: (cf chap. 8 livre A. Appel)
  - ▶ traduire et séquentialiser l'arbre produit par l'analyse statique et obtenir un mix arborescent / linéaire
    - ▶ les branchements (if then else, boucles) sont explicites (gotos)
    - ▶ on cherche à manipuler des *blocs de base*, à l'intérieur desquels sont exécutées des séquences d'instructions

## L'allocation de registres


- ▶ on commence par faire comme s'il y avait une infinité de registres (temporaires, registres virtuels)
- ▶ on fait une analyse plus ou moins maline pour affecter des registres virtuels à des registres réels (chaps. 10& 11 livre A. Appel)  
la *durée de vie* des données est un élément central pour ce faire
- ▶ on réécrit: certains registres virtuels peuvent se retrouver en mémoire (sur la pile)
- ▶ NB: passage par référence: on met dans un temporaire l'*adresse* de l'argument
- ▶ la table des symboles joue un rôle d'*environnement* durant la phase de compilation  
elle renseigne en particulier, lors d'étapes ultérieures de compilation, sur l'*accès* à une variable:
  - ▶ temporaires pour les variables locales et les arguments
  - ▶ indices pour les variables globales
- ▶ au passage: une structure de données pour le code, pas un *print* directement (*post-optimisations* sur l'assembleur produit)

## Code intermédiaire: fonctions

- ▶ les trois langages proposés (Pascal Caml Haskell) permettent de définir des fonctions à l'intérieur de fonctions

```
let f x =  
    let g y = y*x in  
    ..
```

- ▶ du coup, une forme plus sophistiquée pour les enregistrements d'activation (sur la pile)



## Code intermédiaire: fonctions (2)

- ▶ `$fp` est utile pour accéder à l'environnement de la fonction appelante  
la fonction interne accède aux paramètres de la fonction externe grâce à `$fp`
  - ▶ *lien statique*: on passe dynamiquement ce lien à une fonction appelée, et celle-ci accède aux paramètres de la fonction appelante en calculant *statiquement* des décalages
  - ▶ on peut voir ça comme une implémentation des environnements à l'aide de tableaux dans la pile
  - ▶ cas particulier d'un appel récursif
- ▶ fonctions locales non retournées: on peut les allouer sur la pile, et chaîner les environnements
  - ▶ le fait qu'elles ne soient pas retournées fait que leur durée de vie dynamique n'excède pas leur portée lexicale
  - ▶ si on peut retourner une fonction? [clôtures](#)
- ▶ les fonctions locales peuvent être rendues globales par *lambda-lifting*



## Temporaires et appels de fonctions

- ▶ au moment de l'appel d'une fonction, les arguments sont dans des temporaires de l'appelant; après l'appel, ils sont dans des temporaires de l'appelé (pas nécessairement les mêmes)
- ▶ ainsi, les arguments voyagent: lorsqu'une fonction  $f$  appelle une fonction  $g$  (avec un seul argument pour simplifier):
  - ▶ la valeur de l'argument est préparée dans un temporaire  $tf$  (vue de l'appelant) et transféré dans  $a0$  avant l'appel à  $g$ .
  - ▶ à l'entrée de  $g$  la valeur de  $a0$  est placée dans un temporaire  $tg$  (vue de l'appelé).
  - ▶ on a donc trois emplacements pour l'argument:  $tf$  (avant),  $a0$  (pendant) et  $tg$  (après).
- ▶ ces mouvements sont nécessaires dans le cas général pour libérer les registres conventionnels pour d'autres appels de fonctions.
- ▶ mais ils seront éliminés, si possible, par l'allocateur de registres en choisissant le même registre  $a0$  pour  $tf$  et  $tg$ .

# Fonctions: prologue et épilogue

- ▶ typiquement,
  - ▶ Le *prologue* doit:
    1. Allouer k mots en pile.
    2. Sauver les registres *callee-saved*
    3. Placer les arguments (reçus à leur position conventionnelle, dans les registres puis dans le frame parent) dans les temporaires réservés à cet effet comme décrit dans le frame.
  - ▶ Symétriquement, l'*épilogue* doit:
    1. Placer le résultat éventuel dans le registre conventionnel v0
    2. Ressusciter les registres *callee-saved*
    3. Libérer les k mots en pile.
    4. Sauter à l'adresse de retour.
- ▶ l'allocation de registres a lieu vers la fin  
on retarde donc l'écriture des prologues et épilogues, ou alors on les écrit avec des constantes à définir (`taille_frame`)

## Au sujet de Pascal-

- ▶ `procedure f(x:integer, var y:integer)`
  - ▶ procedure, ca veut dire fonction
  - ▶ `y` est passé *par référence*  
(`f` a le pouvoir de modifier la valeur de `y`: pas le sien, celui de l'appelant)
- ▶ on peut définir des types

```
const n=100;
type table = array[1..n] of integer;
var A: table;
```
- ▶ on peut passer des tableaux à des fonctions
- ▶ en cours: fonctions qui retournent des tableaux?