

# Langages de Programmation, Interprétation, Compilation

Christine Paulin

`Christine.Paulin@universite-paris-saclay.fr`

Département Informatique, Faculté des Sciences d'Orsay, Université Paris-Saclay

LDD3 Informatique, Mathématiques - Magistère Informatique

2025–26

## 1 Traduction en assembleur d'un langage impératif

- Architecture cible
- Langage assembleur MIPS
- Traduction complète pour IMP

- La compilation est un processus en plusieurs étapes.
- Etape d'analyse :
  - extraire la structure et le sens du programme source reçu en entrée.
  - identifier des programmes “mal formés”
- Etape de synthèse :
  - transforme l'arbre de syntaxe abstraite d'un programme *source* en un programme *cible* “équivalent”
  - le programme cible est écrit dans un fichier
- Le langage cible peut être par exemple :
  - un autre langage de haut niveau (C, javascript . . .), on utilise alors la plateforme d'exécution du langage cible ;
  - du bytecode : code bas niveau pour une machine virtuelle (java, caml ou python) qui peut être ensuite interprété ;
  - un langage assembleur, exécuté sur une architecture matérielle donnée (Intel x86, ARM, MIPS, RISC-V . . .) après assemblage et édition de liens.

Nous allons étudier comment transformer un programme IMP en code pour l'architecture MIPS.

## 1 Traduction en assembleur d'un langage impératif

- **Architecture cible**
- Langage assembleur MIPS
- Traduction complète pour IMP

- Architecture simple mais réelle appelée MIPS (Microprocessor without Interlocked Pipeline Stages)
- Processeur RISC (Reduced Instruction Set Computer), 32 bits qui est un précurseur de l'architecture moderne RISC-V.
- Utilisé dans les systèmes embarqués, imprimantes, routeurs. . .

Les deux principaux composants de l'architecture sont :

- un processeur, avec un petit nombre de registres et des unités de calcul qui opèrent sur les registres
- une grande quantité de mémoire, où sont stockées à la fois des données et le programme à exécuter lui-même.

- l'octet, une unité universelle comportant 8 bits, représentée en code hexadécimal par deux caractères 0 – 9, *a* – *f* chacun désignant un chiffre de 0 à 15.
- le mot mémoire : espace alloué à une donnée « ordinaire », sur une architecture 32-bits un mot mémoire est formé de 4 octets soit 32 bits ou encore 8 caractères hexadécimaux.

Un entier machine est représenté sur 32 bits

- Entier non signé : entre 0 et  $2^{32} - 1$
- Entier signé :  $-2^{31}$  et  $2^{31} - 1$   
un nombre négatif  $p$  est représenté en “complément à deux” par la valeur  $2^{32} + p$ , le bit de poids fort (bit de signe) d'un tel nombre est toujours 1  
Reviens à calculer module  $2^{32}$

- 32 registres “généraux” accessibles directement par l’unité de calcul, chacun stocke un mot mémoire
- Une mémoire principale de  $2^{32}$  octets (4Go)
  - chaque octet est associé à une adresse (entier entre 0 et  $2^{32} - 1$ )
  - les adresses des données “ordinaires” sont (en générale) des multiples de 4
  - l’accès à la mémoire est relativement coûteux

# Boucle d'exécution

- Le programme à exécuter est une séquence d'instructions stockée de manière contiguë dans la mémoire
- Chaque instruction est codée sur 4 octets
- Un registre spécial pc (program counter, ou pointeur de code) contient l'adresse de l'instruction courante

L'exécution d'un programme procède en répétant le cycle suivant :

- 1 lecture d'un mot mémoire à l'adresse pc (fetch),
- 2 interprétation des octets lus comme une instruction (decode),
- 3 exécution de l'instruction reconnue (execute),
- 4 accès mémoire pour transfert entre registre(s) et mémoire (memory)
- 5 mise à jour des registres (dont pc pour passer à l'instruction suivante)

C'est le pipeline de traitement des instructions

Trois catégories principales d'instructions :

- instructions arithmétiques
- accès à la mémoire : transfert des valeurs de la mémoire vers les registres ou inversement,
- instructions de contrôle : modifier le pointeur de code pc.

Format des instructions sur 32 bits :

- les 6 premiers désignent l'opération à effectuer (opcode)
- les suivants donnent les paramètres ou des précisions éventuelles sur l'opération (afin de distinguer plus de  $2^6 = 64$  opérations).

# Instructions : exemples

- instruction 9 (`addiu`) :  $r_t \leftarrow r_s + n$  avec  $n$  entier non signé de 16 bits.  
 $r_{17} \leftarrow r_5 + 42$

| <i>op</i> | <i>r<sub>s</sub></i> | <i>r<sub>t</sub></i> | <i>n</i>         |
|-----------|----------------------|----------------------|------------------|
| 001001    | 00101                | 10001                | 0000000000101010 |

- instruction 15 (`lui`) : place un nombre de 16 bits dans les deux octets supérieurs d'un registre.  
Pour mettre 42 dans les deux octets supérieurs du registre numéro 17 :

| <i>op</i> |       | <i>r<sub>t</sub></i> | <i>n</i>         |
|-----------|-------|----------------------|------------------|
| 001111    | 00000 | 10001                | 0000000000101010 |

# Opérations binaires

- Un opcode spécifique (*SPECIAL*) : 000000
- Les 6 derniers bits (appelés la fonction) précisent l'opération : addition, multiplication, décalage...
- Ces instructions prennent trois paramètres : deux registres  $r_s$  et  $r_t$  pour les opérandes, et un registre de destination  $r_d$ .
- Exemple  $r_3 \leftarrow r_1 + r_2$  : (code de fonction de l'addition : 32)

| $op$   | $r_s$ | $r_t$ | $r_d$ |       | $f$    |
|--------|-------|-------|-------|-------|--------|
| 000000 | 00001 | 00010 | 00011 | 00000 | 100000 |

- Certaines opérations ignorent le paramètre  $r_s$  et utilisent une donnée constante sur les 5 bits libres.
- Exemple : décalage vers la gauche (code de fonction 0) :  $r_d \leftarrow r_t \ll n$  avec  $n$  un entier sur 5 bits ( $<32$ )

Le code pour  $r_6 \leftarrow r_4 \ll 5$  est

| $op$   |       | $r_t$ | $r_d$ | $k$   | $f$    |
|--------|-------|-------|-------|-------|--------|
| 000000 | 00000 | 00100 | 00110 | 00101 | 000000 |

# Accès à la mémoire

- Paramètres : deux registres  $r_s$  et  $r_t$  et un entier signé  $n$  sur 16 bits
- Lecture d'un mot mémoire (code 35) :  $r_s$  contient une adresse  $a$ ,  $n$  est un entier signé sur 16 bits qui représente un décalage, on transfère le contenu de la mémoire à l'adresse  $a + n$  dans le registre  $r_t$
- Exemple : placer dans le registre 3 la donnée trouvée à l'adresse stockée dans le registre 5 + 8 octets :

| $op$   | $r_s$ | $r_t$ | $n$              |
|--------|-------|-------|------------------|
| 100011 | 00101 | 00011 | 0000000000001000 |

- Ecriture d'un mot mémoire :  $r_s$  contient une adresse  $a$ ,  $n$  est un entier signé sur 16 bits qui représente un décalage, on transfère le contenu de la mémoire à l'adresse  $a + n$  dans le registre  $r_t$

Ce schéma général de découpage vaut encore pour les instructions d'accès à la mémoire. L'instruction de lecture d'un mot mémoire par exemple prend en paramètres . Le registre  $r_s$  est supposé contenir une adresse, et l'entier  $n$  est appelé décalage. L'instruction de lecture calcule une adresse  $a$  en additionnant l'adresse de base  $r_s$  et le décalage  $n$ , et transfère vers le registre  $r_t$  le mot mémoire lu à l'adresse  $a$ . Le code de cette opération est 35. Ainsi, pour placer dans le registre numéro 3 la donnée trouvée à l'adresse obtenue en ajoutant 8 octets à l'adresse donnée par le registre numéro 5, on a la

- saut conditionnel (opcode 7) :

- paramètres un registre  $r_s$  et un entier  $n$  signé sur 16 bits,
- avance de  $n$  instructions dans le code du programme seulement si la valeur de  $r_s$  est strictement positive
- Exemple : reculer de 5 instructions lorsque la valeur du registre 3 est strictement positive

| $op$   | $r_s$ | $r_t$ | $n$              |
|--------|-------|-------|------------------|
| 000111 | 00011 | 00000 | 1111111111111011 |

- saut absolu (opcode 2)

- paramètre : un entier sur 26 bits interprété comme l'adresse  $a$  d'une instruction
- positionne le pointeur pc à l'adresse  $a$
- Exemple : aller à l'instruction d'adresse 0x00efface

| $op$   | $a$                         |
|--------|-----------------------------|
| 000010 | 001110111111111101011001110 |

# Partie 1 : Introduction

## 1 Traduction en assembleur d'un langage impératif

- Architecture cible
- **Langage assembleur MIPS**
- Traduction complète pour IMP

- Langage binaire
  - un modèle de mémoire/calcul bas niveau particulier
  - un encodage des instructions spécifiques
- Langage d'assemblage ou assembleur
  - forme textuelle des instructions, plus facile à mémoriser
  - traduction ensuite automatique vers le langage binaire
  - moins dépendant de l'architecture cible

En langage assembleur on a en particulier :

- des écritures textuelles pour les instructions,
- la possibilité d'utiliser des étiquettes symboliques plutôt que des adresses explicites,
- une allocation statique des données globales,
- quelques pseudo-instructions, qui correspondent à des combinaisons simples d'instructions réelles.

- Ecriture de programmes en assembleur MIPS
- Utilisation du simulateur MARS (Pete Sanderson et Ken Vollmar à Missouri State University)

`https://computerscience.missouristate.edu/  
mars-mips-simulator.htm`

- mode commande en ligne
  - mode graphique pour le débogage et simulation pas à pas
- Usage : `java -jar Mars4_5.jar`

Dans l'assembleur MIPS, les 32 registres sont désignés par leur numéro, de \$0 jusqu'à \$31 ou par leur nom.

| <i>n</i> | <i>nom</i> | <i>n</i> | <i>nom</i> | <i>n</i> | <i>nom</i> | <i>n</i> | <i>nom</i> |
|----------|------------|----------|------------|----------|------------|----------|------------|
| \$0      | \$zero     | \$8      | \$t0       | \$16     | \$s0       | \$24     | \$t8       |
| \$1      | \$at       | \$9      | \$t1       | \$17     | \$s1       | \$25     | \$t9       |
| \$2      | \$v0       | \$10     | \$t2       | \$18     | \$s2       | \$26     | \$k0       |
| \$3      | \$v1       | \$11     | \$t3       | \$19     | \$s3       | \$27     | \$k1       |
| \$4      | \$a0       | \$12     | \$t4       | \$20     | \$s4       | \$28     | \$gp       |
| \$5      | \$a1       | \$13     | \$t5       | \$21     | \$s5       | \$29     | \$sp       |
| \$6      | \$a2       | \$14     | \$t6       | \$22     | \$s6       | \$30     | \$fp       |
| \$7      | \$a3       | \$15     | \$t7       | \$23     | \$s7       | \$31     | \$ra       |

- Les 24 registres `$v*`, `$a*` (à l'exception de `at`), `$t*` et `$s*` sont des registres ordinaires, on peut les utiliser librement pour des calculs
- Les 8 autres registres ont des rôles particuliers :
  - `$gp`, `$sp`, `$fp` et `$ra` contiennent des adresses utiles pour les appels de fonction
  - `$zero` contient toujours la valeur 0 et ne peut pas être modifié,
  - les 3 registres `$at` et `$k0` et `$k1` sont réservés respectivement pour l'assembleur et pour le système (il ne faut donc pas les utiliser).
- Il y a aussi des registres spécialisés :
  - `$pc` le pointeur de code qui désigne l'instruction à exécuter
  - `$hi`, `$lo` pour la multiplication ou division d'entiers 32 bits

- Une zone d'instructions, introduite par `.text`
- Une zone de données "statiques", introduite par `.data`
- Une instruction peut être précédée d'une étiquette `etiq` : qui permet de faire référence à l'adresse du code de cette instruction
- un commentaire dans le fichier assembleur commence par `\#` et se termine au retour à la ligne
- Une instruction commence par un mot clé appelé mnémonique, désignant l'opération à effectuer, qui est suivi d'un certain nombre de paramètres séparés par des virgules.
- Exemple d'instructions (mettre l'entier 42 dans le registre `$t0`, puis transférer la valeur de `$t0` dans `$t1`)

```
li $t0 , 42
move $t1 , $t0
```

- Une pseudo-instruction assembleur peut être traduite en plusieurs instructions binaires
- `li $t0, n` avec `n` un entier de 32 bits qui se décompose en  $n_h n_l$  se traduit en

```
lui $at, n_h  
ori $t0, n_l
```

- `move $t0, $t1` est transformé en `addu $t0, $0, $t1`

Les opérations arithmétiques et logiques MIPS suivent le format « trois adresses » :

<mnemo>   <dest>, <r1>, <r2>

- Opérations arithmétiques : add, sub, mul, div, rem (remainder : reste), ...
- Opérations logiques : and, or, xor (exclusive or), ...
- Comparaisons : seq (equal : égalité), sne (not equal : inégalité) slt (less than : <), sle (less or equal : ≤), sgt (greater than : >), sge (greater or equal : ≥), ...
- opérations unaires classiques avec un seul opérande : abs (valeur absolue), neg (opposé), not (négation logique).
- variantes pour les opérations non signées (addu, subu...)
- variantes pour une seconde opérande constante (addi, ...)
- Décalages et rotations : sll (shift left logical), sra (shift right arithmetic), srl (shift right logical), rol (rotation left), ror (rotation right), ... par défaut, le décalage est une valeur immédiate.

# Exemple

Séquence d'instructions pour évaluer la comparaison  $3*4 + 5 < 2*9$

|     |                  | \$t0 | \$t1 | \$t2 | \$t3 | \$t4 | \$t5 | \$t6 | \$t7 | \$t8 |
|-----|------------------|------|------|------|------|------|------|------|------|------|
| li  | \$t0, 3          | 3    |      |      |      |      |      |      |      |      |
| li  | \$t1, 4          | 3    | 4    |      |      |      |      |      |      |      |
| li  | \$t2, 5          | 3    | 4    | 5    |      |      |      |      |      |      |
| li  | \$t3, 2          | 3    | 4    | 5    | 2    |      |      |      |      |      |
| li  | \$t4, 9          | 3    | 4    | 5    | 2    | 9    |      |      |      |      |
| mul | \$t5, \$t0, \$t1 | 3    | 4    | 5    | 2    | 9    | 12   |      |      |      |
| add | \$t6, \$t5, \$t2 | 3    | 4    | 5    | 2    | 9    | 12   | 17   |      |      |
| mul | \$t7, \$t3, \$t4 | 3    | 4    | 5    | 2    | 9    | 12   | 17   | 18   |      |
| slt | \$t8, \$t6, \$t7 | 3    | 4    | 5    | 2    | 9    | 12   | 17   | 18   |      |

# Exemple : version optimisée

|                      | \$t0 | \$t1 |
|----------------------|------|------|
| li \$t0, 3           | 3    |      |
| li \$t1, 4           | 3    | 4    |
| mul \$t0, \$t0, \$t1 | 12   | 4    |
| addi \$t0, \$t0, 5   | 17   | 4    |
| li \$t1, 9           | 17   | 9    |
| sll \$t1, \$t1, 1    | 17   | 18   |
| slt \$t0, \$t0, \$t1 | 1    | 18   |

- Le programme peut réserver de l'espace pour des données globales
  - variables globales
  - chaînes de caractères
  - ...

En mémoire, les données ainsi déclarées sont placées dans une zone située après la zone réservée aux instructions du programme.

|                    |                    |     |
|--------------------|--------------------|-----|
| <code>.text</code> | <code>.data</code> |     |
| code               | données            | ... |

La définition d'une donnée ou d'un groupe de données combine :

- la déclaration d'une étiquette symbolique, un nom qui désigne l'adresse où la donnée est stockée
- une ou plusieurs valeurs initiales.
- un mot-clé précise la nature des données fournies :
  - .word pour une valeur 32 bits (4 octets),
  - .byte pour une valeur d'un unique octet (8 bits),
  - .ascii pour une chaîne de caractères au format ASCII (un caractère par octet, la chaîne étant terminée par l'octet zéro (0x00)).

# Format des données : exemples

- donnée désignée par le nom `reponse` et valant 42 :

`reponse : .word 42`

- Tableau comportant une suite d'entiers, l'adresse `prems` est celle de la première entrée

`prems: .word 2 3 5 7 11 13 17 19`

L'adresse réservée pour chaque donnée est calculée au moment de l'assemblage et remplacée en dur dans le programme.

# Accès à la mémoire

Le format standard des adresses mémoire en MIPS contient deux composantes :

- une adresse de base, donnée par la valeur d'un registre  $\$r$ ,
- un décalage, donné par une constante  $d$  (16 bits, signée).

On note  $d(\$r)$  une telle adresse, dont la valeur est donc  $\$r + d$ . Transferts possibles :

- transférer une valeur depuis une adresse mémoire vers un registre (lecture, load)
- depuis un registre vers une adresse mémoire (écriture, store).
- Exemples

```
lw $t0 , 8($a1)
sw $t0 , 0($t1)
```

- Les mnémoniques `lw` et `sw` signifient respectivement Load Word et Store Word.

- Des variantes existent pour lire ou écrire seulement un octet ou un demi-mot ou encore un double mot
- On peut omettre un décalage de 0

```
sw $t0 , ( $t1 )
```

- on peut utiliser une adresse désignée par une étiquette

```
lw $t0 , prems  
lw $t1 , prems+4  
lw $t2 , prems+12
```

- une instruction la (Load Address) permet de récupérer ou calculer une adresse, sans lire son contenu.

```
la $t0 , prems
```

- Le mécanisme des données statiques n'est pas suffisant dans un programme ordinaire
- On a besoin de pouvoir stocker des données en mémoire
- La quantité d'espace nécessaire n'est pas forcément prévisible, on parle d'une allocation dynamique de la mémoire, réalisée à l'exécution
- Le programme doit néanmoins autant que possible libérer l'espace qui n'est plus utilisé
- La partie haute de la mémoire est organisée sous forme de pile :
  - Structure linéaire dont une extrémité est appelée le fond et l'autre le sommet
  - l'ajout et le retrait se font uniquement au sommet
  - le premier élément retiré est le dernier arrivé



- le fond de la pile est calé sur l'adresse la plus haute,
- la pile croît en s'étendant vers les adresses inférieures.
- le sommet de la pile est l'adresse mémoire la plus basse utilisée par la pile : stockée dans le registre \$sp.

# Opérations sur la pile

- Consulter la valeur au sommet de la pile (peek) :

```
lw    $t0 , 0($sp)
```

- Consulter des éléments plus profonds dans la pile : +4 octets par élément à sauter.

4ème élément : décalage de 12 octets.

```
lw    $t0 , 12($sp)
```

- Ajouter un élément au sommet de la pile (push)

```
addi $sp , $sp , -4
```

```
sw    $t0 , 0($sp)
```

- Retirer l'élément au sommet de la pile

```
addi $sp , $sp , 4
```

- L'opération usuelle pop, consiste à récupérer l'élément au sommet tout en le retirant de la pile

```
lw    $t0 , 0($sp)
```

```
addi $sp , $sp , 4
```

# Sauts et branchements

- les instructions, les données statiques ont toutes une adresse
- les adresses peuvent avoir des étiquettes
- les étiquettes servent de cible aux instructions de saut
- exemple : si les registres \$t0 et \$t1 ont même valeur, aller à l'instruction d'étiquette lab sinon continuer à l'instruction suivante.

beq \$t0 , \$t1 , lab

- variantes de comparaison

|     |     |     |     |     |     |
|-----|-----|-----|-----|-----|-----|
| =   | ≠   | <   | ≤   | >   | ≥   |
| beq | bne | blt | ble | bgt | bge |

- variante test à 0 : beqz, bnez, bltz , ...
- possibilité d'un second paramètre immédiat
- une pseudo-instruction b lab provoque un branchement inconditionnel vers l'instruction d'étiquette lab.

# Exemple

Calcul de la factorielle de la valeur de \$a0 dans le registre \$v0.

```
1      move $t0 , $a0
2      li   $t1 , 1
3      b     test
      loop:
4      mul  $t1 , $t1 , $t0
5      addi $t0 , $t0 , -1
      test:
6      bgtz $t0 , loop
7      move $v0 , $t1
```

- Branchement limité à des déplacements "locaux" (limité à un décalage de  $2^{15}$  octets)
- Les instructions de saut définissent la prochaine instruction de manière absolue
- version immédiate

```
j    label
```

- adresse calculée dans un registre

```
jr    $t0
```

- utilisées pour un saut non local, comme un appel de fonction.
- instructions spécifiques qui sauvegardent une adresse de retour dans le registre \$ra, qui permet plus tard de revenir à l'exécution de la séquence en cours.

```
jal   label
```

```
jalr  $t0
```

- Certaines fonctionnalités dépendant du système d'exploitation
- L'assembleur fait appel aux bibliothèques système
- Fonctionnalités du simulateur MARS
  - instruction syscall,
  - le registre \$v0 contient le code du service
  - le registre \$a0 sert éventuellement de paramètre

| service           | code       | arg. | rés. |
|-------------------|------------|------|------|
| affichage         | 1 (entier) | \$a0 |      |
|                   | 4 (chaîne) |      |      |
|                   | 11 (ascii) |      |      |
| lecture           | 5 (entier) |      | \$v0 |
| arrêt             | 10         |      |      |
| extension mémoire | 9          | \$a0 | \$v0 |

# Hello, world

```
main:    .text
         li    $v0, 4
         la    $a0, hw
         syscall
         li    $v0, 10
         syscall

hw:      .data
         .asciiz "hello_world\n"
```

# Partie 1 : Introduction

- 1 Traduction en assembleur d'un langage impératif
  - Architecture cible
  - Langage assembleur MIPS
  - Traduction complète pour IMP

Représentation efficace des concaténations de chaînes de caractères.

```
type asm =  
  | Nop  
  | S of string  
  | C of asm * asm
```

```
let (@@) x y = C (x, y)
```

```
type program = { text: asm; data: asm; }
```

Concaténer deux fragments  $a_1$  et  $a_2$  de code assembleur :

$C(a_1, a_2)$  qui s'écrit  $a_1 @@ a_2$

# Abbréviations pour les registres

Pour faciliter la production de code MIPS sous cette représentation, on définit en plus de cela quelques constantes pour les registres utilisés

```
let t0 = "$t0"  
let t1 = "$t1"  
let a0 = "$a0"  
let v0 = "$v0"  
let sp = "$sp"  
let ra = "$ra"
```

# Commandes pour la génération d'instructions

L'expression Caml `add t0 t0 t1` produit un élément de type `asm` correspondant au code assembleur `"__add__$t0,$t0,$t1\n"`.

**open** Printf

```
let li    r1 i    = S( sprintf  "__li__%s",__i"      r1 i )
let la    r1 x    = S( sprintf  "__la__%s",__%s"      r1 x )
let move  r1 r2   = S( sprintf  "__move__%s",__%s"     r1 r2 )
```

```
let add   r1 r2 r3 = S( sprintf  "__add__%s",__%s,__%s" r1 r2
let addi  r1 r2 i   = S( sprintf  "__addi__%s",__%s,__%d" r1 r2
let mul   r1 r2 r3 = S( sprintf  "__mul__%s",__%s,__%s" r1 r2
let slt   r1 r2 r3 = S( sprintf  "__slt__%s",__%s,__%s" r1 r2
let and_  r1 r2 r3 = S( sprintf  "__and__%s",__%s,__%s" r1 r2
```

```
let j      l      = S( sprintf  "__j__%s"      l )
let jal    l      = S( sprintf  "__jal__%s"    l )
let jr     r1     = S( sprintf  "__jr__%s"     r1 )
let beqz   r1 l    = S( sprintf  "__beqz__%s",__%s" r1 l )
let bnez   r1 l    = S( sprintf  "__bnez__%s",__%s" r1 l )
let bltz   r1 l    = S( sprintf  "__bltz__%s",__%s" r1 l )
```

Dans l'ordre : le registre sur lequel on agit, le décalage, et le registre donnant l'adresse de base.

On écrit donc `lw t0 4 t1` pour générer l'instruction `lw $t0, 4($t1)`

```
let lw      r1 o r2    = S( sprintf "lw____%s,_%d(%s)" r1 o r2  
let sw      r1 o r2    = S( sprintf "sw____%s,_%d(%s)" r1 o r2  
let lbu     r1 o r2    = S( sprintf "lbu____%s,_%d(%s)" r1 o r2
```

```
let ilist = function
  | []      -> ""
  | [i]     -> sprintf "%d" i
  | i :: l  -> sprintf "%d,%s" i (ilist l)
let dword l = S(sprintf "_.word_%s" (ilist l))
let asciiz s = S(sprintf "_.asciiz_%s" s)
```

# Exemple

```
# built-in atoi
atoi:
    li    $v0, 0
    li    $t1, 10

atoi_loop:
    lbu    $t0, 0($a0)
    beqz   $t0, atoi_end
    addi   $t0, $t0, -48
    bltz   $t0, atoi_error
    bge    $t0, $t1 atoi_error
    mul    $v0, $v0, $t1
    add    $v0, $v0, $t0
    addi   $a0, $a0, 1
    j      atoi_loop

atoi_error:
    li    $v0, 10
    syscall

atoi_end:
    jr    $ra
```

```
let built_ins =
    comment "built-in atoi"
    @@ label "atoi"
    @@ li    v0 0
    @@ li    t1 10

    @@ label "atoi_loop"
    @@ lbu   t0 0(a0)
    @@ beqz  t0 "atoi_end"
    @@ addi  t0 t0 (-48)
    @@ bltz  t0 "atoi_error"
    @@ bge   t0 t1 "atoi_error"
    @@ mul   v0 v0 t1
    @@ add   v0 v0 t0
    @@ addi  a0 a0 1
    @@ j     "atoi_loop"

    @@ label "atoi_error"
    @@ li    v0 10
    @@ syscall

    @@ label "atoi_end"
    @@ jr    ra
```

```
let push r =  
  addi sp sp (-4) @@ sw r 0(sp)  
let pop r =  
  lw r 0(sp) @@ addi sp sp 4
```

```
let rec print_asm fmt a =  
  match a with  
  | Nop          -> ()  
  | S s          -> fprintf fmt "%s\n" s  
  | C (a1, a2) ->  
    let () = print_asm fmt a1 in  
    print_asm fmt a2
```

```
let print_program fmt p =  
  fprintf fmt ".text\n";  
  print_asm fmt p.text;  
  fprintf fmt ".data\n";  
  print_asm fmt p.data
```

- Choisir une stratégie d'évaluation
- On commence par un modèle de calcul des expressions à l'aide d'une pile
  - la fonction `tr_expr`, appliquée à une expression `e`, produit un code assembleur qui calcule la valeur de `e` et place le résultat dans le registre `$t0`,
  - toutes les valeurs intermédiaires sont enregistrées sur la pile.

# Traduction des expressions

```
let rec tr_expr = function
| Cst n -> li t0 n
| Var x -> la t0 x @@ lw t0 0(t0)
| Bop(bop, e1, e2) -> let op = match bop with
    | Add -> add
    | Mul -> mul
    | Lt  -> slt
    | And -> and_
    in
    tr_expr e1
    @@ push t0
    @@ tr_expr e2
    @@ pop t1
    @@ op t0 t1 t0
```

## Traduction d'une instruction

```
let rec tr_instr = function
| Print e ->
    tr_expr e
    @@ move a0 t0
    @@ li v0 11
    @@ syscall
| Set(x, e) ->
    tr_expr e
    @@ la t1 x
    @@ sw t0 0(t1)
```

Fonction auxiliaire `new_label` qui crée de nouvelles étiquettes.

```
let new_label =  
  let cpt = ref (-1) in  
  fun s -> incr cpt; Printf.sprintf "__%s_%d" s !cpt
```

Traduction des boucles :

- Une étiquette pour chaque cible de saut
  - un saut conditionnel (`beqz`) pour sortir de la boucle si le test est négatif, en ciblant une étiquette `end_label` placée après le corps la boucle,
  - un saut incondtionnel (`j`) pour revenir au test (étiquette `loop_label` après chaque exécution du corps de la boucle.

# Traduction des boucles : code

```
| While(e, s) ->  
  let loop_label = new_label "loop"  
  and end_label = new_label "endloop"  
  in  
    label loop_label  
    @@ tr_expr e                (* test *)  
    @@ beqz t0 end_label  
    @@ tr_seq s                 (* loop body *)  
    @@ j loop_label  
    @@ label end_label
```

- Une étiquette pour la branche **else**,
- un saut inconditionnel à la fin de la branche **then** vers une étiquette `end_label` pour ne pas passer par la branche **else**.

```
| If(e, s1, s2) ->  
  let else_label = new_label "else"  
  and end_label = new_label "endif"  
  in  
    tr_expr e                                (* test *)  
    @@ beqz t0 else_label  
    @@ tr_seq s1                             (* then branch *)  
    @@ j end_label  
    @@ label else_label  
    @@ tr_seq s2                             (* else branch *)  
    @@ label end_label
```

# Traduction d'une suite d'instructions

```
and tr_seq = function  
  | []    -> nop  
  | [i]   -> tr_instr i  
  | i::s  -> tr_instr i @@ tr_seq s
```

# Identification des données statiques

```
module VSet = Set.Make(String)
let rec vars_expr = function
  | Cst _ -> VSet.empty
  | Var x -> VSet.singleton x
  | Bop(_, e1, e2) ->
    VSet.union (vars_expr e1) (vars_expr e2)
let rec vars_instr = function
  | Print e -> vars_expr e
  | Set(x, e) ->
    VSet.add x (vars_expr e)
  | While(e, s) ->
    VSet.union (vars_expr e) (vars_seq s)
  | If(e, s1, s2) ->
    VSet.union (vars_expr e)
      (VSet.union (vars_seq s1) (vars_seq s2))
and vars_seq = function
  | [] -> VSet.empty
  | i :: s -> VSet.union (vars_instr i) (vars_seq s)
```

# Traduction du programme

- traduction des instructions ;
- allocation de ses variables globales (initialisées à 0).

```
let tr_prog p =  
  let text = tr_seq p in  
  let vars = vars_seq p in  
  let data = VSet.fold  
    (fun id code -> label id @@ dword [0] @@ code)  
    vars nop  
in  
{ text; data }
```

## A retenir

- Les principes généraux d'un code binaire MIPS
  - modèle de calcul (opérations sur les registres, transferts mémoire)
  - modèle de codage des instructions
- Les éléments de base de l'assembleur MIPS
  - organisation de la mémoire (registres, programme, données, pile)
  - instructions élémentaires (arithmétique, comparaison, sauts)
  - utilisation des registres et de la pile pour calculer des expressions
  - schéma de compilation d'une conditionnelle et d'une boucle

## Savoir faire

- Lire et écrire un programme simple en assembleur MIPS
- Ecrire les bases d'un compilateur en utilisant l'interface Caml MIPS