

École Polytechnique  
INF564 : Compilation  
examen 2023 (X2020)

Jean-Christophe Filliâtre

13 mars 2023

Les notes de cours manuscrites ou reprographiées sont les seuls documents autorisés.

L'épreuve dure 3 heures.

Les trois parties **ne sont pas** indépendantes.

Suggestion : détacher la feuille contenant les figures 1–3.

## 1 Un mini langage RTL

On considère un langage RTL simplifié à l'extrême pour les besoins de ce sujet. La figure 1 décrit les cinq instructions de ce langage RTL, où  $n \in \mathbb{Z}$  désigne une constante entière,  $v$  désigne un pseudo-registre (qu'on appellera une *variable* par la suite),  $L$  désigne une étiquette et  $f$  désigne un nom de fonction. L'instruction `mov  $n$   $v$`  charge la constante  $n$  dans la variable  $v$ ; l'instruction `mov  $u$   $v$`  copie la variable  $u$  dans la variable  $v$ ; l'instruction `sub  $u$   $v$`  soustrait la valeur de la variable  $u$  à la variable  $v$  (attention au sens); l'instruction `jnz  $\rightarrow L_1, L_2$`  saute à l'étiquette  $L_1$  si le résultat de la dernière soustraction est non nul et à l'étiquette  $L_2$  sinon; enfin, l'instruction  `$u \leftarrow$  call  $f(v, w)$`  affecte à la variable  $u$  le résultat de l'appel  $f(v, w)$ .

Une fonction est définie par son graphe de flot de contrôle. Les  $N$  instructions du graphe sont étiquetées avec des entiers, de 0 à  $N - 1$ . Le point d'entrée est l'étiquette 0 et le point de sortie est l'étiquette  $N$ . On suppose que chaque fonction a exactement deux paramètres, reçus dans les variables  $x$  et  $y$ , et qu'elle renvoie un résultat dans la variable  $z$ . La figure 2 contient un exemple de graphe RTL avec  $N = 8$  instructions.

**Question 1** Que calcule la fonction de la figure 2? On pourra faire l'hypothèse que  $x \geq 0$  à l'entrée de cette fonction.

**Question 2** Donner un code RTL pour la fonction C suivante.

```
int myst(int x, int y) {
    if (x == 0) return y;
    if (x-1 == 0) return y+1;
    return myst(x-2, myst(x-1, y));
}
```

**Question 3** Quelle forme prend un appel terminal dans ce langage RTL? Donner un exemple.

**Variables vivantes.** Afin de réaliser une allocation de registres (dans la partie suivante), on a besoin de déterminer les variables vivantes en entrée de chaque instruction. On les calcule comme expliqué en cours, à partir des définitions et des utilisations de chaque instruction puis d'un calcul de point fixe sur le graphe de flot de contrôle.

**Question 4** Pour chaque instruction RTL de la figure 1, indiquer quelles sont les variables que cette instruction définit (*def*) et quelles sont les variables que cette instruction utilise (*use*).

**Question 5** En supposant que la variable  $z$  est vivante à la sortie du graphe de la figure 2, donner les variables vivantes en *entrée* de chacune des huit instructions.

## 2 Une autre allocation

Dans cette partie, on étudie un algorithme d'allocation de registres alternatif, différent de celui étudié en cours et en projet (par coloration du graphe d'interférence). Ce nouvel algorithme a notamment le mérite d'être moins coûteux, ce qui permet de l'utiliser par exemple pendant de la compilation à la volée. On réalise cette allocation de registres dans le contexte du langage RTL introduit dans la partie précédente (sans passer par un langage ERTL intermédiaire). L'allocation de registres est réalisée indépendamment pour chaque fonction du programme.

**Intervalles.** Pour chaque variable  $v$  du graphe de flot de contrôle, on définit son *intervalle* comme le plus petit intervalle d'entiers  $[i, j]$ , avec  $0 \leq i \leq j \leq N$ , tel que la variable  $v$  n'est pas vivante à l'entrée de l'instruction  $k$  pour tout  $k$  en dehors de cet intervalle. En particulier, la variable  $v$  est donc vivante en entrée de l'instruction  $i$  et de l'instruction  $j$ . Mais elle n'est pas nécessairement vivante en entrée de toute instruction  $k$  pour  $i < k < j$ . On fait l'hypothèse que toute variable apparaissant dans le graphe de flot de contrôle est vivante à l'entrée d'au moins une instruction. On note qu'il est tout à fait possible que  $i = j$ , c'est-à-dire qu'un intervalle soit réduit à une seule instruction.

Ainsi, pour le graphe donné à gauche, on obtient les intervalles donnés à droite :

graphe	variables vivantes en entrée	intervalles
0 : <code>mov 0 t → 1</code>	0 : $\{x, y\}$	
1 : <code>sub t x → 2</code>	1 : $\{t, x, y\}$	$x$ : $[0, 3]$
2 : <code>jnz → 3, 4</code>	2 : $\{x, y\}$	$y$ : $[0, 4]$
3 : <code>mov x z → 5</code>	3 : $\{x\}$	$z$ : $[5, 5]$
4 : <code>mov y z → 5</code>	4 : $\{y\}$	$t$ : $[1, 1]$
	5 : $\{z\}$	

Les variables vivantes en entrée de chaque instruction sont données au centre. Pour exprimer que la variable  $z$  est vivante à la sortie du graphe, on la considère vivante à l'entrée de l'instruction  $N$  (ici  $N = 5$  sur cet exemple), même s'il n'y a pas vraiment d'instruction  $N$ .

**Algorithme d'allocation des registres.** On introduit maintenant un algorithme d'allocation des registres utilisant ces intervalles. On suppose qu'il y a  $K$  registres physiques, notés  $R_1, \dots, R_K$ . L'algorithme va affecter à chaque variable  $v$  une localisation, notée  $loc[v]$ , qui est soit un registre physique  $R_i$ , soit la valeur `Spill` pour indiquer que cette variable est vidée en mémoire.

L'algorithme est donné figure 3. Il est composé de trois fonctions : **allocation**, **expiration** et **vidage**. Le point d'entrée est la fonction **allocation**. On prendra le temps de bien lire et de bien comprendre cet algorithme. On note que cet algorithme ne dépend *que* de la valeur de  $K$  et des intervalles associés à chaque variable.

**Question 6** Donner le résultat de cet algorithme pour  $K = 3$  et les intervalles suivants :

$$x : [0, 7] \quad y : [0, 2] \quad z : [1, 8] \quad a : [2, 7] \quad t : [6, 6]$$

En cas d'égalité sur une valeur de  $i$  ou de  $j$ , quand l'algorithme indique de procéder selon un certain ordre ou de sélectionner une valeur maximale, on pourra choisir arbitrairement.

**Question 7** Dans la fonction **vidage**, on pourrait se contenter de la partie **sinon**, c'est-à-dire de toujours effectuer  $loc[v] \leftarrow \text{Spill}$ . Expliquer l'intérêt de la partie **alors** de la fonction **vidage**.

**Question 8** Cet algorithme d'allocation des registres permet-il d'allouer un même registre physique à deux variables  $u$  et  $v$  pour lesquelles il existe une instruction  $\text{mov } u \ v$ , à l'instar de ce que permettent (parfois) les arêtes de préférences dans l'allocation par coloration de graphe ?

**Question 9** Montrer que cet algorithme est *correct*, au sens où il n'affecte jamais le même registre physique à deux variables distinctes vivantes en entrée d'une même instruction. On s'attachera notamment à énoncer clairement les *invariants* de cet algorithme.

**Question 10** Le résultat de la question précédente ne suffit pas en pratique, car si le code appelle une fonction avec **call** alors les registres physiques utilisés par cette fonction vont être écrasés. Proposer une solution pour y remédier.

**Question 11** Quelle est la complexité de cet algorithme, en fonction du nombre  $V$  de variables et de la valeur  $K$  ?

**Numérotation des instructions.** Comme on l'a compris, le résultat de l'algorithme dépend fortement de la numérotation des instructions. Or il existe  $(N - 1)!$  façons différentes de numéroter les instructions, car seul le numéro de l'instruction 0 est imposé.

**Question 12** Donner un exemple de graphe de flot de contrôle et deux numérotations possibles pour les instructions de ce graphe, l'une permettant une allocation avec seulement deux registres physiques et l'autre nécessitant au moins trois registres physiques (sans rien vider en mémoire à chaque fois).

**Numérotation en profondeur.** On se propose de re-numéroter les instructions à l'aide d'un parcours en profondeur du graphe de flot de contrôle. À chaque instruction  $i$ , on va associer un nouveau numéro  $num[i]$ , toujours entre 0 et  $N - 1$ . On utilise une variable globale  $next$  et une marque sur chaque instruction. On initialise  $next$  à  $N - 1$  et on lance  $\text{dfs}(0)$ , où  $\text{dfs}$  est la fonction suivante :

```
dfs(i)
  marquer i comme visitée
  pour chaque successeur j < N, non visité, de l'instruction i
    appeler dfs(j)
  num[i] ← next
  next ← next - 1
```

En supposant que toutes les instructions sont atteignables à partir de l'instruction 0, l'appel à  $\text{dfs}(0)$  va visiter toutes les instructions du graphe et terminer en donnant la valeur 0 à  $num[0]$ .

**Question 13** Donner le résultat de cette numérotation sur le graphe de la figure 2.

**Question 14** Donner un exemple de graphe de flot de contrôle montrant que la numérotation en profondeur ne donne pas forcément un résultat optimal, au sens où, après numérotation en profondeur, l'algorithme d'allocation a besoin de plus de registres physiques qu'avec la numérotation initiale.

### 3 Exécution

Dans cette dernière partie, on se préoccupe d'exécuter notre petit langage RTL. Un programme RTL est une liste de fonctions RTL, chacune étant donnée par son nom et son graphe. On suppose que cette liste contient au moins une fonction appelée `main`, qui est le point d'entrée du programme.

**Question 15** Décrire la réalisation en Java ou en OCaml d'un interprète du langage RTL. On ne demande pas d'écrire tout le code mais de décrire précisément les classes/types, méthodes/fonctions et structures de données utilisées. Détailler avec soin le cas d'un appel (`call`) et l'optimisation d'un appel terminal.

**Compilation vers l'assembleur x86-64.** On souhaite maintenant compiler notre langage RTL vers l'assembleur x86-64. Les paramètres  $x$  et  $y$  d'une fonction sont passés respectivement dans `%rdi` et `%rsi` et son résultat  $z$  est passé dans `%rax`.

**Question 16** Donner un code assembleur x86-64 pour le code RTL de la figure 2, avec une allocation au choix pour les différentes variables.

**Question 17** Décrire la traduction du langage RTL vers l'assembleur x86-64. On suppose avoir réalisé une allocation de registres, donnée sous la forme d'une affectation *loc* (comme dans la partie précédente) envoyant toute variable vers un registre x86-64 ou vers la valeur `Spill`.

### Annexe : aide-mémoire x86-64

On donne ici un fragment du jeu d'instructions x86-64. Vous êtes libre d'utiliser tout autre élément de l'assembleur x86-64. Dans ce qui suit,  $r_i$  désigne un registre,  $n$  une constante entière et  $L$  une étiquette.

<code>mov <math>r_2</math>, <math>r_1</math></code>	copie le registre $r_2$ dans le registre $r_1$
<code>mov <math>\\$n</math>, <math>r_1</math></code>	charge la constante $n$ dans le registre $r_1$
<code>mov <math>L</math>, <math>r_1</math></code>	charge la valeur à l'adresse $L$ dans le registre $r_1$
<code>mov <math>\\$L</math>, <math>r_1</math></code>	charge l'adresse de l'étiquette $L$ dans le registre $r_1$
<code>add <math>r_2</math>, <math>r_1</math></code>	calcule la somme de $r_1$ et $r_2$ dans $r_1$ (on a de même <code>sub</code> et <code>imul</code> )
<code>mov <math>n(r_2)</math>, <math>r_1</math></code>	charge dans $r_1$ la valeur contenue en mémoire à l'adresse $r_2 + n$
<code>mov <math>r_1</math>, <math>n(r_2)</math></code>	écrit en mémoire à l'adresse $r_2 + n$ la valeur contenue dans $r_1$
<code>push <math>r_1</math></code>	empile la valeur contenue dans $r_1$
<code>pop <math>r_1</math></code>	dépile une valeur dans le registre $r_1$
<code>cmp <math>r_2</math>, <math>r_1</math></code>	positionne les drapeaux en fonction de la valeur de $r_1 - r_2$
<code>test <math>r_2</math>, <math>r_1</math></code>	positionne les drapeaux en fonction de la valeur de $r_1 \& r_2$
<code>jnz <math>L</math></code>	saute à l'adresse désignée par l'étiquette $L$ en cas de résultat non nul
<code>jmp <math>L</math></code>	saute à l'adresse désignée par l'étiquette $L$
<code>call <math>L</math></code>	saute à l'adresse désignée par l'étiquette $L$ , après avoir empilé l'adresse de retour
<code>ret</code>	dépile une adresse et y effectue un saut

---

instruction RTL ::= `mov n v → L`  
                  | `mov v v → L`  
                  | `sub v v → L`  
                  | `jnz → L, L`  
                  | `v ← call f(v, v) → L`

---

FIGURE 1 – Un langage RTL minimal.

---

---

*z myfun(x, y)*  
0 : `mov 0 z → 1`  
1 : `mov 0 a → 2`  
2 : `sub y a → 3`  
3 : `mov 0 t → 6`  
4 : `sub a z → 5`  
5 : `mov 1 t → 6`  
6 : `sub t x → 7`  
7 : `jnz → 4, 8`

---

FIGURE 2 – Un exemple de graphe RTL.

---

---

**allocation()**

$actifs \leftarrow \emptyset$

$libres \leftarrow \{R_1, R_2, \dots, R_K\}$

**pour chaque** intervalle  $v : [i, j]$ , par ordre de  $i$  croissant

**expiration**( $v : [i, j]$ )

**si**  $actifs$  contient  $K$  éléments **alors**

**vidage**( $v : [i, j]$ )

**sinon**

$loc[v] \leftarrow$  un registre retiré de  $libres$

ajouter  $v : [i, j]$  à l'ensemble  $actifs$

**expiration**( $v : [i, j]$ )

**pour chaque** intervalle  $v' : [i', j']$  de l'ensemble  $actifs$ , par ordre de  $j'$  croissant

**si**  $j' \geq i$  **alors sortir** de **expiration**

enlever  $v' : [i', j']$  de l'ensemble  $actifs$

ajouter  $loc[v']$  à l'ensemble  $libres$

**vidage**( $v : [i, j]$ )

soit  $v' : [i', j']$  un élément de  $actifs$  avec  $j'$  maximal

**si**  $j' > j$  **alors**

$loc[v] \leftarrow loc[v']$

$loc[v'] \leftarrow \text{Spill}$

enlever  $v' : [i', j']$  de l'ensemble  $actifs$

ajouter  $v : [i, j]$  à l'ensemble  $actifs$

**sinon**

$loc[v] \leftarrow \text{Spill}$

---

FIGURE 3 – Algorithme d'allocation des registres.

---



Énoncé en français.