

# Cours de compilation

## Chapitre 10. Allocation de registres

Master informatique fondamentale 1 – ENS-Lyon

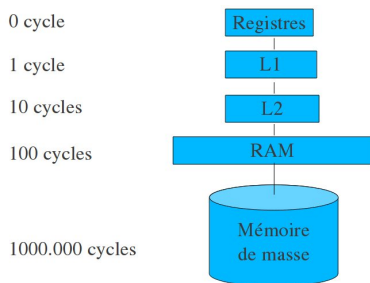
Christophe Alias

`Christophe.Alias@ens-lyon.fr`

`http://perso.ens-lyon.fr/christophe.alias`


# Introduction

- ▶ Après sélection et ordonnancement, on obtient du code machine avec des temporaires. Où les stocker?
- ▶ De préférence dans des **registres**.
- ▶ En **mémoire** (dans la pile) quand tous les registres sont déjà pris.



# Durées de vie, interférences


- ▶ Une variable est **vivante** en un point du graphe de flot de contrôle s'il existe **un chemin** de ce point **vers une lecture sans passer par une écriture**.
- ▶ **x interfère avec y** s'il existe un point du CFG sur lequel x et y sont vivants en même temps.
  - ils doivent alors être placés dans des **registres différents**.
- ▶ On construit un **graphe d'interférence**, dont les noeuds sont les variables. Un arc entre x et y indique une interférence entre x et y.



# Copies

- ▶ La sortie de la forme SSA produit de nombreuses **instructions de copie** (**MOV a,d**) qu'on aimerait **supprimer** en affectant le **même** registre à **a** et **d**.
- ▶ On modélise cette situation en ajoutant un **arc d'affinité** entre **a** et **d** dans le graphe d'interférence.

	a	b	c	d
c = 0				
d = c+1				
d = d+1				
a = d				
b = c+1				
b = a+b+c				



# Allocation de registres


Le problème de l'**allocation de registres pour  $k$  registres** consiste à attribuer une couleur parmi  $k$  à chaque temporaire de telle façon que:

- ▶ deux sommets reliés par un **arc d'interférence** ne reçoivent pas la même couleur.
- ▶ deux sommets reliés par un **arc d'affinité** reçoivent la même couleur, si possible.

S'il existe une solution, on dit que le graphe est  **$k$ -colorable**.

# Complexité

Le graphe d'interférence peut être quelconque:



Or, le problème du coloriage de graphes est **NP-complet**...

# Coloriage par simplification

Un sommet de degré strictement inférieur à  $k$  est **trivialement colorable**.  
 $G$  est  $k$ -colorable ssi  $G - \{s\}$  est  $k$ -colorable

On peut répéter cette simplification autant de fois que possible.

Le fait de supprimer un sommet trivialement colorable peut rendre d'autres sommets trivialement colorables...

# Algorithme de Chaitin

colorier( $G$ )

si il existe un noeud  $s$  avec  $< k$  voisins

alors //cas trivial

colorier( $G - \{s\}$ )

affecter une couleur restante à  $s$

sinon

choisir un noeud  $s$

colorier( $G - \{s\}$ )

si il reste une couleur alors l'affecter

sinon spiller  $s$

fin

- ▶ Le choix du sommet à “spiller” est critique.
- ▶ Pour faciliter la suite du coloriage, il vaut mieux choisir un sommet de **fort degré**.
- ▶ Le choix de la couleur doit tenir compte des arcs de préférence (**coloriage biaisé**).



# Coalescing

Une approche plus radicale que le coloriage biaise, consiste à **d'abord fusionner (coalescer)** tous les sommets reliés par des arcs d'affinité avant d'effectuer le coloriage.

La couleur attribuée à plusieurs sommets fusionnés est celle attribuée à leur agrégat.

**Inconvénient:** fusionner plusieurs sommets peut créer un sommet de **très fort degré**, qui sera probablement "spillé".

# Coalescing conservatif

On ne fusionne deux sommets que si on a la certitude de **préserver la  $k$ -colorabilité du graphe**.

- ▶ **Critère de Briggs**

Deux sommets peuvent être fusionnés si le sommet résultant a moins de  $k$  voisins non trivialement colorables

▣▶ Trop conservatif


- ▶ **Critère de Georges**

Deux sommets  $a$  et  $b$  peuvent être fusionnés si tout voisin non trivialement colorable de  $a$  est également voisin de  $b$ .


▣▶ Préféré en pratique

# Interactions simplification/fusion

- ▶ Deux sommets non fusionnables peuvent le devenir suite à une simplification.
- ▶ Un sommet non trivialement colorable peut le devenir suite à une fusion.
- ▶ Il faut **alterner simplification et fusion**.
- ▶ Quand le critère n'est pas rempli, il faut renoncer à une fusion pour permettre de nouvelles simplifications.



simplification => fusion



fusion => simplification

# Iterated Register Coalescing

**Etape 1. Simplify:** Eliminer les noeuds simplifiables à l'exclusion des noeuds reliés par un arc d'affinité. Chaque noeud éliminé est placé sur une pile.

- ▶ Le degré des noeuds diminue, ce qui crée des opportunités pour le coalesce conservatif (étape 2).

**Etape 2. Coalesce:** Fusionner les noeuds reliés par un arc d'affinité, quand le critère de George le permet. Itérer en 1.

- ▶ Cette étape peut **réduire le degré de noeuds connexes** aux noeuds fusionnés, créant de nouvelles opportunités pour la simplification, d'où l'itération.

**Etape 3. Freeze:** Si le critère de George n'est jamais vérifié, supprimer un arc d'affinité qui relie deux noeuds de faible degré. Itérer en 1.

- ▶ Certaines fusions sont structurellement impossibles. Par exemple, si  $x$  et  $y$  interfèrent et  $z$  est relié à  $x$  et à  $y$  par un arc d'affinité, on ne peut pas à la fois fusionner  $(x, z)$  et  $(y, z)$ .

# Iterated Register Coalescing

**Etape 4. Spill:** S'il reste encore des noeuds et que tous les arcs d'affinité ont été supprimés, choisir et supprimer un noeud de **fort degré** pour le *spill*. Itérer en 1.

**Etape 5. Select:** Lorsque tous les noeuds ont été supprimés, on les dépile pour construire l'allocation de registres.

- ▶ Si des noeuds ont été sélectionnés pour être spillés, il faudrait reconstruire le graphe d'interférence (pourquoi?) et itérer en 1.
- ▶ Si la machine dispose de suffisamment de registres, on peut éviter cette itération en réservant un registre pour le spill, et en allouant d'emblée pour  $k - 1$  registres.

# Exemple

*live-in:* k j

```
g := mem[j+12]
```

```
h := k - 1
```

```
f := g * h
```

```
e := mem[j+8]
```

```
m := mem[j+16]
```

```
b := mem[f]
```


```
c := e + 8
```

```
d := c
```

```
k := m + 4
```

```
j := b
```


*live-out:* d k j



- ▶ Allocation pour  $k = 3$  registres + 2 registres réservés pour le spill.

## Etape 1: Simplify


```
live-in: k j
g := mem[j+12]
h := k - 1
f := g * h
e := mem[j+8]
m := mem[j+16]
b := mem[f]
c := e + 8
d := c
k := m + 4
j := b
live-out: d k j
```



Pile: h,g

## Etape 2: Coalesce

```
live-in: k j
g := mem[j+12]
h := k - 1
f := g * h
e := mem[j+8]
m := mem[j+16]
b := mem[f]
c := e + 8
d := c
k := m + 4
j := b
live-out: d k j
```




Pile: h,g

- Critère de George non-vérifié



## Etape 3: Freeze


```
live-in: k j  
g := mem[j+12]  
h := k - 1  
f := g * h  
e := mem[j+8]  
m := mem[j+16]  
b := mem[f]  
c := e + 8  
d := c  
k := m + 4  
j := b  
live-out: d k j
```



Pile: h,g

# Etape 1: Simplify


```
live-in: k j
g := mem[j+12]
h := k - 1
f := g * h
e := mem[j+8]
m := mem[j+16]
b := mem[f]
c := e + 8
d := c
k := m + 4
j := b
live-out: d k j
```



Pile: h,g,c

## Etape 2: Coalesce

```
live-in: k j
g := mem[j+12]
h := k - 1
f := g * h
e := mem[j+8]
m := mem[j+16]
b := mem[f]
c := e + 8
d := c
k := m + 4
j := b
live-out: d k j
```




Pile: h,g

- Critère de George non-vérifié

## Etape 3: Freeze


```
live-in: k j
g := mem[j+12]
h := k - 1
f := g * h
e := mem[j+8]
m := mem[j+16]
b := mem[f]
c := e + 8
d := c
k := m + 4
j := b
live-out: d k j
```



Pile: h,g

# Etape 1: Simplify

```
live-in: k j
g := mem[j+12]
h := k - 1
f := g * h
e := mem[j+8]
m := mem[j+16]
b := mem[f]
c := e + 8
d := c
k := m + 4
j := b
live-out: d k j
```



Pile: h,g,c

► Pas de simplification possible

## Etape 2: Coalesce

*live-in:* k j

g := mem[j+12]

h := k - 1

f := g \* h

e := mem[j+8]

m := mem[j+16]

b := mem[f]


c := e + 8

d := c

k := m + 4

j := b

*live-out:* d k j



Pile: h,g,c

► Plus d'arc d'affinité

## Etape 4: Spill

*live-in:* k j

g := mem[j+12]

h := k - 1

f := g \* h

e := mem[j+8]

m := mem[j+16]

b := mem[f]


c := e + 8

d := c

k := m + 4

j := b

*live-out:* d k j



Pile: h,g,c,j

- ▶ Noeud de plus fort degré: j

# Etape 1: Simplify

*live-in:* k j

g := mem[j+12]

h := k - 1

f := g \* h

e := mem[j+8]

m := mem[j+16]

b := mem[f]


c := e + 8

d := c

k := m + 4

j := b

*live-out:* d k j



Pile: h,g,c,j,k,d,b,m,e,f



## Etape 5: Select

*live-in:* k j

g := mem[j+12]

h := k - 1

f := g \* h

e := mem[j+8]

m := mem[j+16]

b := mem[f]


c := e + 8

d := c

k := m + 4

j := b

*live-out:* d k j

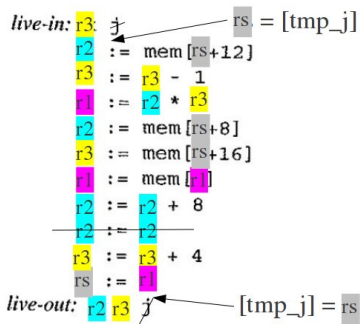


Pile: h,g,c,j, k,d,b,m,e,f  
3,2,2,∅,3,2,1,3, 2,1

←

# Code émis

```
live-in: k j
g := mem[j+12]
h := k - 1
f := g * h
e := mem[j+8]
m := mem[j+16]
b := mem[f]
c := e + 8
d := c
k := m + 4
j := b
live-out: d k j
```



- ▶ La copie `d := c` peut être supprimée.

# Allocation des variables temporaires

Lorsqu'un temporaire est spillé, sa valeur est placée dans une **variable temporaire** sur la pile.

On a pas besoin de toutes les variables temporaires en même temps...

On peut optimiser l'espace des temporaires en suivant le même principe: construction d'un **graphe d'interférence** et **coloriage**.

- ▶ Bien sûr, il n'y a **pas de limite sur  $k$** .
- ▶ Autrement, on pourrait spiller sur le disque...

# Linear Scan

- ▶ On numérote les instructions du programme et 1 et  $N$ , et on considère le **plus grand intervalle** qui contient les intervalles de vie d'une variable (au pire  $[1, N]$ ).
- ▶ Les intervalles obtenus sont triés par ordre croissant du point de départ.
- ▶ On parcourt les points d'entrée des intervalles par ordre croissant.
- ▶ On se maintient une **liste d'intervalles de vie actifs**. (triée par point de fin croissant)
- ▶ Pour chaque nouvel intervalle:
  - ▶ On **retire** les intervalles dont le point de fin expire (début de liste).
  - ▶ Le registre correspondant est alors **disponible**.
  - ▶ Si la liste est de taille  $k$ , on **spille** l'intervalle qui termine **le plus tard** (dernier de la liste).
  - ▶ Sinon, on attribue un registre non utilisé à l'intervalle.

# Linear Scan

La complexité est **linéaire** en le nombre de variables.

▣ adapté aux environnements de **compilation "au vol"**

D'après les auteurs, les performances sont **10% inférieures** à IRC.

Il n'y a **pas d'élimination de copies** (coalesce).