Compilation (INF 564)

Linéarisation — Réalisation des trames de pile
De Pseudo-Pascal vers C ou Java
Ramassage de miettes

François Pottier

10 février 2016

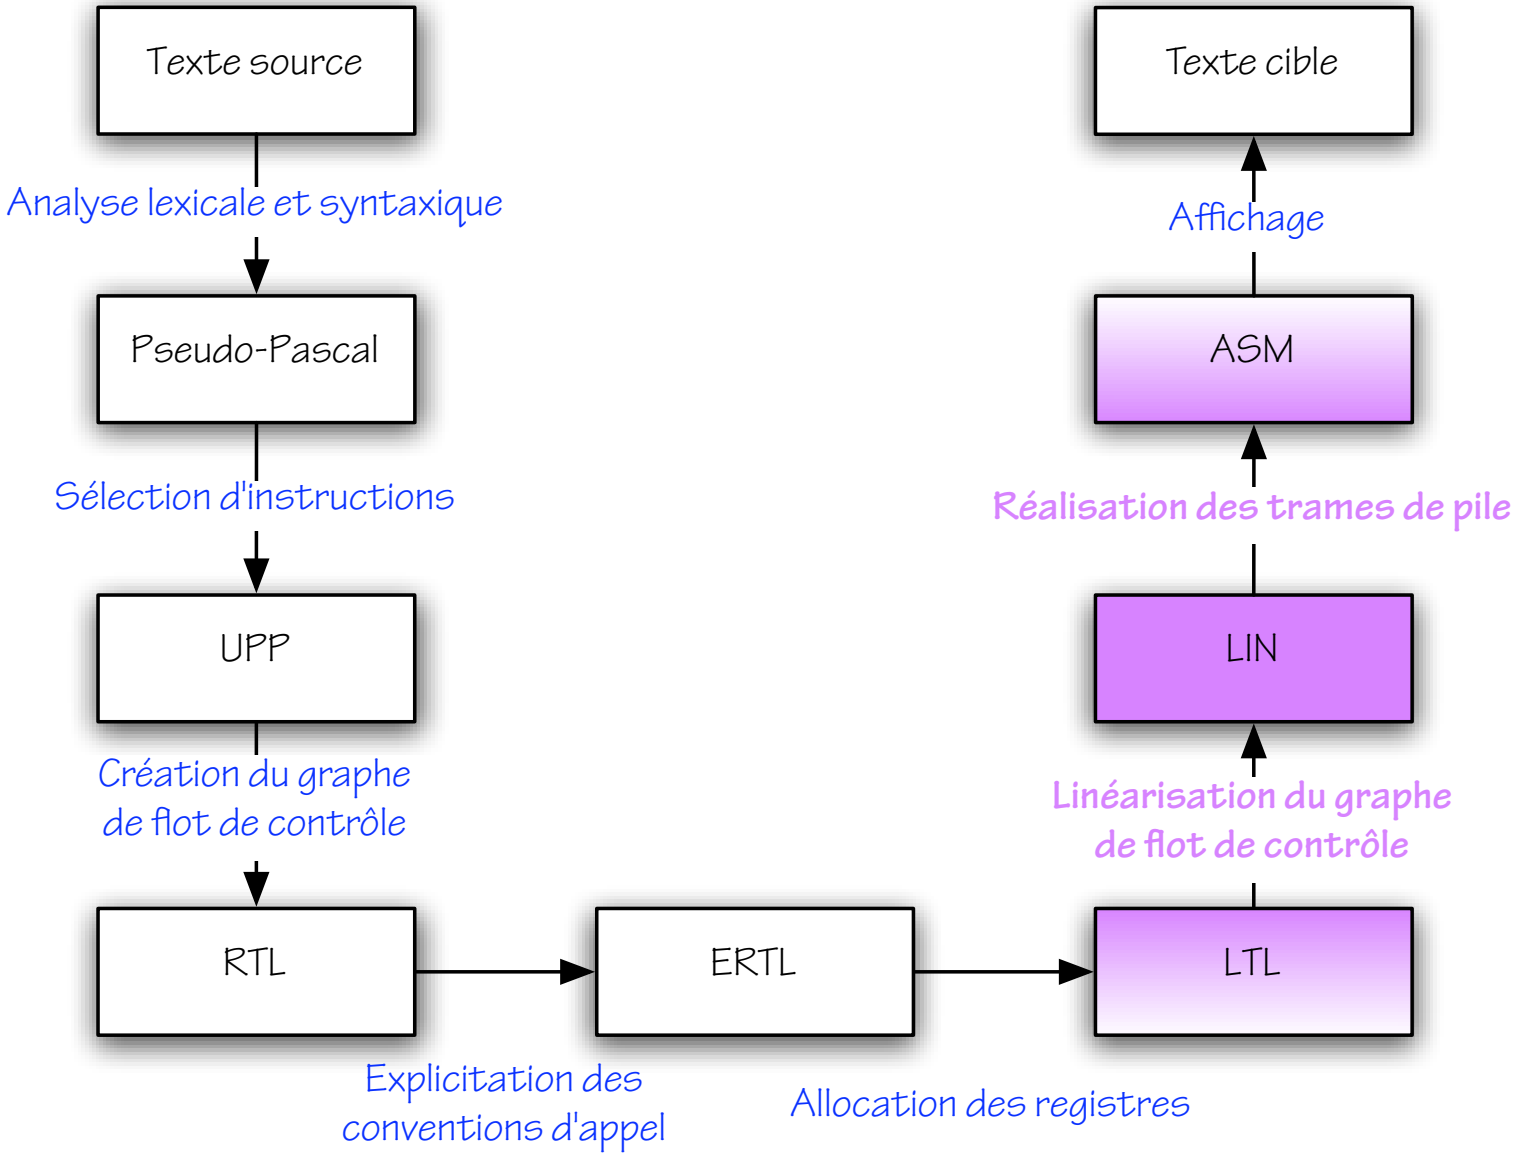
Texte source
Analyse lexicale et syntaxique
Pseudo-Pascal
Sélection d'instructions
UPP
Création du graphe de flot de contrôle
RTL
Explicitation des conventions d'appel
ERTL
Allocation des registres
LTL
Linéarisation du graphe de flot de contrôle
LIN
Réalisation des trames de pile
ASM
Affichage
Texte cible

De LTL à LIN

De LIN à ASM

De Pseudo-Pascal vers C ou Java

Ramassage de miettes

Location Transfer Language (LTL)

Voici une traduction de la fonction factorielle dans LTL :

```
procedure f(1)
var 8
entry f11
f11: newframe                    → f10
f10: sets  local(0), $ra         → f9
f9 : j                           → f8
f8 : sets  local(4), $s0         → f7
f7 : move  $s0, $a0              → f6
f6 : j                           → f5
f5 : blez  $s0                   → f4, f3
f3 : addiu $a0, $s0, -1          → f2
f2 : j                           → f20
f20: j                           → f19
f19: call  f                     → f18
f18: j                           → f1
f1 : mul   $v0, $s0, $v0         → f0
f0 : j                           → f17
f17: j                           → f16
f16: gets  $ra, local(0)         → f15
f15: j                           → f14
f14: gets  $s0, local(4)         → f13
f13: delframe                    → f12
f12: jr    $ra
f4 : li    $v0, 1                → f0
```

Adieu, graphe de flot de contrôle

Dans LTL, les fonctions sont encore structurées sous forme de *graphe* de flot de contrôle.

Cela a été utile à plusieurs reprises. Par exemple, lors du passage de ERTL à LTL, des instructions de "spill" ont été *insérées*, et des instructions mortes ont été *supprimées* en les remplaçant par des IGoto.

Dans la suite, cette structure ne sera plus utile. On revient donc à une structure *linéaire*.

Élimination des lGoto

Dans LTL, l'instruction lGoto est *redondante*, puisque chaque instruction mentionne *explicitement* son ou ses successeurs.

On peut donc réaliser une transformation de LTL vers lui-même qui élimine tous les lGoto — voir le module *Branch*.

Code Linéarisé (LIN)

Dans LIN,

- le graphe de flot de contrôle disparaît au profit d'une *suite linéaire* d'instructions ;
- le *successeur* de chaque instruction redevient implicite, sauf en cas de branchement ;
- les *labels* disparaissent, sauf pour les instructions cibles d'un branchement.

Code Linéarisé (LIN)

Voici une traduction de la fonction factorielle dans LIN :

```
procedure f(1)
var 8
f11:
newframe
sets  local(0), $ra
sets  local(4), $s0
move  $s0, $a0
blez  $s0, f4
addiu $a0, $s0, -1
call  f
mul   $v0, $s0, $v0
f16:
gets  $ra, local(0)
gets  $s0, local(4)
delframe
jr    $ra
f4:
li    $v0, 1
j     f16
```

Linéarisation

La traduction de LTL vers LIN se fait par un simple *parcours* du graphe de flot de contrôle.

Lorsqu'on examine un sommet *pour la première fois*, on émet d'abord une *étiquette*, puis l'instruction associée à ce sommet, dont on examine ensuite les successeurs, en commençant par celui à qui le contrôle est transféré *implicitement*.

Lorsqu'on ré-examine un sommet *déjà rencontré*, on émet une instruction de *saut* inconditionnel vers l'étiquette correspondante.

On supprime a posteriori les étiquettes superflues.

Variations et critères de qualité

On peut vérifier que cet algorithme ne produit jamais de *saut* (conditionnel ou inconditionnel) *vers un saut* inconditionnel. (Pourquoi ?)

Différents *ordres de parcours* des sommets donnent lieu à différentes linéarisations. *Inverser la condition* d'un saut conditionnel offre également une certaine latitude.

Certaines linéarisations peuvent être considérées comme *préférables* si elles utilisent le saut **j** en des points moins critiques...

Deux linéarisations d'une même boucle

La première exécute **j** à chaque itération, la seconde non.

```
...
début:
test:
(test)
bgtz $t1, fin
corps:
(corps)
j    test
fin:
...
```

```
...
début:
j    test
corps:
(corps)
test:
(test)
bgez $t1, corps
fin:
...
```

De LTL à LIN

De LIN à ASM

De Pseudo-Pascal vers C ou Java

Ramassage de miettes

Assembleur (ASM)

Dans ASM,

- la gestion des trames de pile se fait par *incrémentation* et *décrémentation* explicite du registre *sp* ;
- l'accès à la pile se fait à l'aide d'un *décalage fixe* vis-à-vis de sp.

ASM est un *fragment* du langage assembleur MIPS et peut être aisément *affiché* sous forme textuelle, lisible par spim.

Assembleur (ASM)

Voici une traduction de la fonction factorielle dans ASM :

```
f17:
addiu $sp, $sp, -8
sw    $ra, 4($sp)
sw    $s0, 0($sp)
move  $s0, $a0
blez  $s0, f4
addiu $a0, $s0, -1
jal   f17
mul   $v0, $s0, $v0
f28:
lw    $ra, 4($sp)
lw    $s0, 0($sp)
addiu $sp, $sp, 8
jr    $ra
f4:
li    $v0, 1
j     f28
```

Organisation des trames de pile

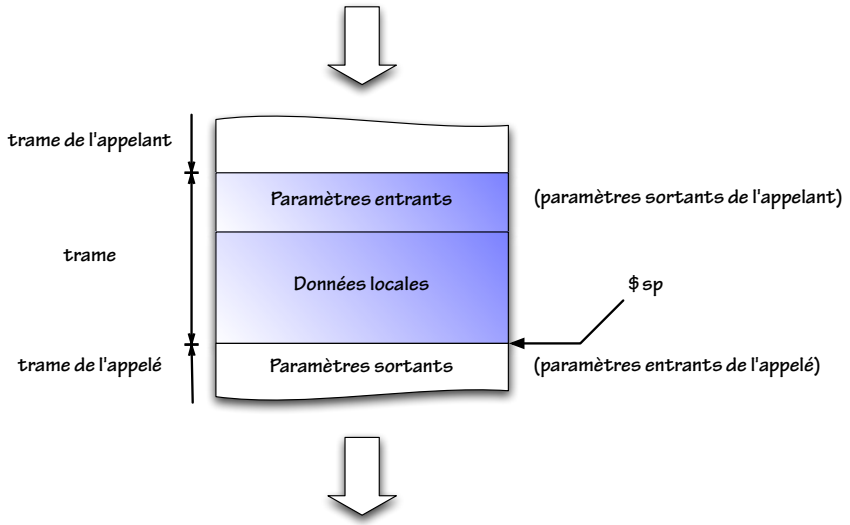

La taille des deux régions qui forment la trame est enfin *connue*.

Un décalage *relatif* à l'une des trois régions "incoming", "local" ou "outgoing" peut donc être traduit en un simple décalage *vis-à-vis de $sp*.

Les instructions **newframe** et **delframe** peuvent également être traduites en *décrémentations* et *incrémentations* de $sp.

Organisation des trames de pile

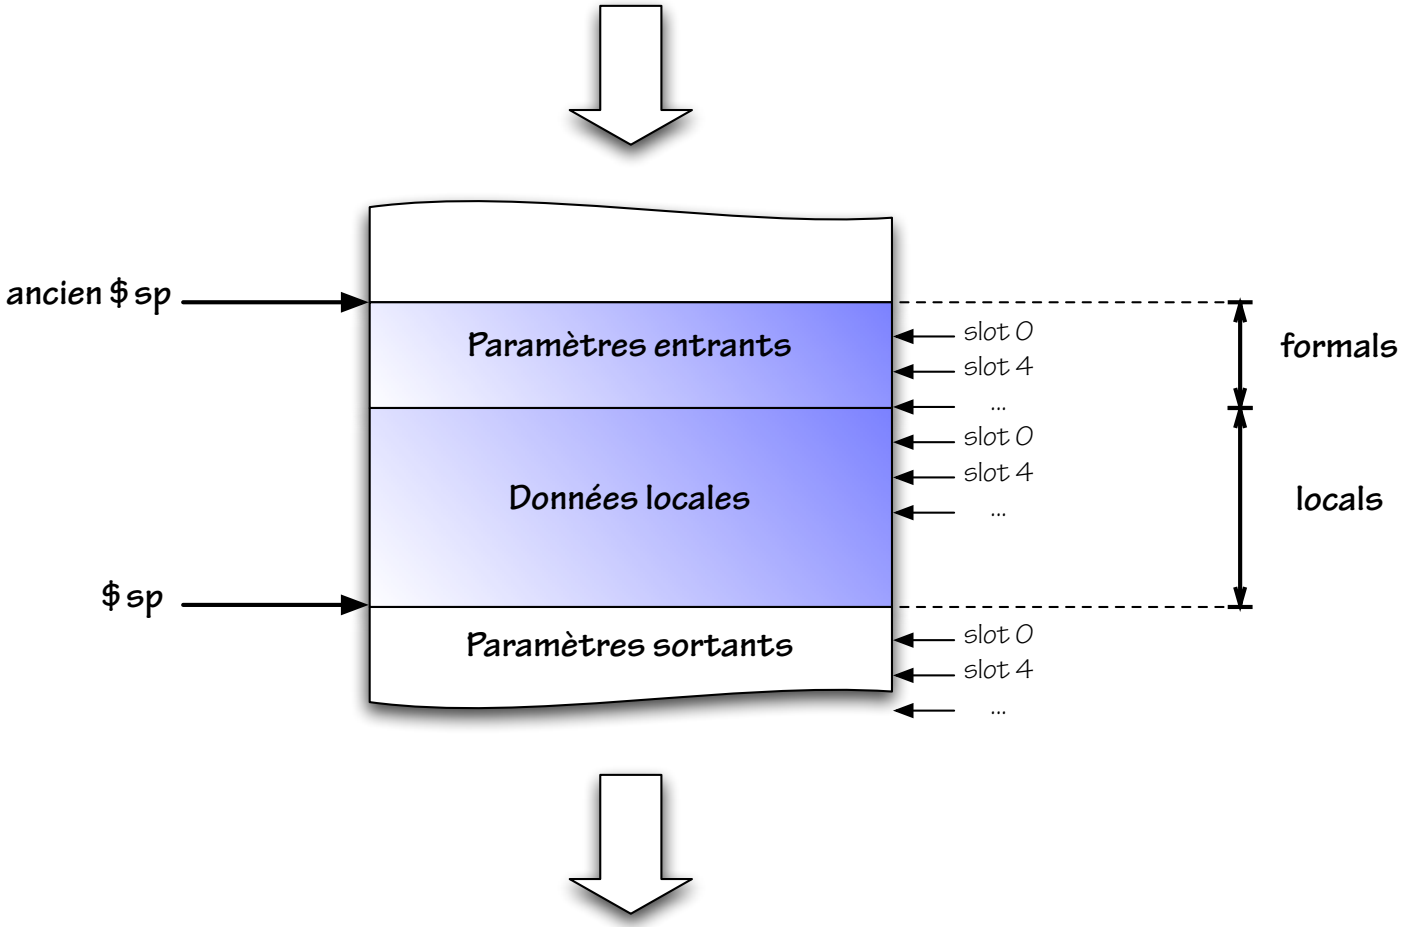

Organisation des trames de pile

L'ancien $sp est $sp + locals + formals.

Par convention, dans chaque zone, le slot 0 est celui du haut de la zone, le slot 4 celui du dessous, etc.

Par exemple, SlotOutgoing 0 sera traduit par $sp - 4, et SlotIncoming 0 par $sp + locals + formals - 4.

De LTL à LIN

De LIN à ASM

De Pseudo-Pascal vers C ou Java

Ramassage de miettes

Vers un compilateur C réel

Que nous manque-t-il ? Relativement peu, en fait :

- un *préprocesseur* — qui peut être vu comme un outil séparé ;
- des types *entiers* et *flottants* de *diverses tailles*, avec *conversions* implicites ou explicites et *surcharge* des opérateurs arithmétiques ;
- des types *struct*, avec *allocation* dans les registres ou en pile, et *transmission* en tant qu'argument ou résultat ;
- l'opérateur **&**, avec répercussions sur *l'allocation* dans les registres ou en pile ;
- les constructions **for**, **do**, **switch**, **goto**, **break**, **continue** ;
- les *pointeurs de fonction* et les fonctions à *arité variable*.

Vers un compilateur Java

Que nous manque-t-il ? De nombreux traits, parmi lesquels :

- un glaneur de cellules ou *GC* — cf. cette séance ;
- des *exceptions* ;
- des *classes*, *interfaces* et *objets* ;
- des *processus légers* (*"threads"*) ;
- un vérificateur de types *polymorphe*, pour Java 1.5 ;
- la *surcharge* des fonctions ou méthodes définies par l'utilisateur ;
- l'insertion de *tests* lors des accès aux *objets* et *tableaux* ;
- la production de "bytecode" exécutable par la *machine virtuelle Java* (JVM) ;
- ...

De LTL à LIN

De LIN à ASM

De Pseudo-Pascal vers C ou Java

Ramassage de miettes

Gestion manuelle ou automatique ?

Les objets alloués dans le tas — par *new array* en Pseudo-Pascal, *malloc* en C, *new* en Java — doivent-ils être désalloués *manuellement* ou *automatiquement* ?

Des dangers de la gestion manuelle

Par défaut, C exige une désallocation explicite à l'aide de la fonction *free*. Mais ce mécanisme *n'est pas sûr.* Il permet de :

- désallouer un objet *encore vivant* ;
- désallouer *deux fois* un objet.

Ces deux erreurs ne sont souvent *pas détectées immédiatement* et provoquent des comportements anormaux difficiles à analyser.

Des dangers de la gestion manuelle

Une gestion manuelle correcte doit obéir à des règles strictes qui devraient être clairement *comprises* et *documentées*. C'est rarement le cas.

On pourrait utiliser un *système de types*, c'est-à-dire faire appel au compilateur, pour imposer une discipline de gestion manuelle correcte.

Mais ces systèmes de types restent aujourd'hui très complexes. Les langages Cyclone ou Rust en sont des exemples relativement accessibles. (Voir aussi Mezzo !)

Des dangers de la gestion manuelle

De plus, une gestion manuelle souffre de deux inconvénients :

- *oublier* de désallouer un objet provoque une *fuite de mémoire* (“space leak”) difficile à détecter et à analyser ;
- devoir désallouer explicitement chaque objet a un *coût* que certains mécanismes de désallocation implicite permettent d’éviter...

Ramassage de miettes : principe

On considère le tas comme un *graphe* où les objets forment les sommets et les pointeurs forment les arêtes.

Les objets auxquels, à un instant donné, le programme est susceptible d'accéder *directement* — parce qu'il possède leur adresse — forment les *racines*.

Alors, tout objet *inaccessible* depuis une racine à travers le graphe est certainement *mort* ("garbage") et peut être *désalloué*.

Voir Appel (chapitre 13), ou bien l'article de Wilson, "Uniprocessor Garbage Collection Techniques".

Ramassage de miettes : principe

De temps en temps — typiquement, lorsque le tas est plein — on examine le graphe pour déterminer quels objets sont accessibles, puis on désalloue les autres.

Ce processus s'appelle *ramassage de miettes*, *"garbage collection"* ou *glanage de cellules* (GC).

Ramassage de miettes : approximation

Il est possible que certains objets *accessibles* soient en fait d'ores et déjà et pour toujours *inutiles*. Ils ne seront pas désalloués, alors qu'ils pourraient l'être de façon sûre.

Le ramassage de miettes repose donc sur une *approximation* et peut être sujet à des *fuites de mémoire*. On doit éviter que des objets inutilisés restent accessibles par mégarde.

On peut vouloir obtenir une information plus fine par *analyse* du programme. Mais déterminer si un objet est vivant ou non est *indécidable*, donc une approximation restera nécessaire.

Un non-algorithme de ramassage de miettes

Le *comptage de références* (1960) consiste à stocker dans chaque objet un compteur du nombre actuel de pointeurs vers cet objet. Lorsque ce compteur devient nul, l'objet est désalloué.

Cette méthode *populaire* et souvent *réinventée* souffre en fait de deux *graves désavantages :*

- les sommets de degré entrant nul sont certes inaccessibles, mais *la réciproque est fausse*, d'où impossibilité de désallouer les structures cycliques ;
- la mise à jour du compteur à chaque fois qu'un pointeur est créé ou supprimé a un *coût prohibitif*.

Ramassage “mark & sweep”

L'idée (McCarthy, 1960) est d'effectuer :

- d'abord un *parcours* du graphe pour déterminer et *marquer* les sommets accessibles ;
- puis un *balayage* linéaire du tas pour *désallouer* les objets non marqués et effacer les marques.

"mark & sweep" : pseudo-code

Voici la phase de *parcours*, ici parcours en profondeur d'abord :

procédure Visiter(x)
 si x n'est pas marqué
 alors { marquer x
 pour chaque champ *i* de x **faire** Visiter(x_i)

procédure Parcourir()
 pour chaque racine x **faire** Visiter(x)

Quelles *difficultés* d'implémentation peut-on rencontrer ?

"mark & sweep" : pseudo-code

Voici la phase de *balayage* :

```
procédure Balayer()
 pour chaque objet x
  faire { si x est marqué
        { alors effacer la marque
        { sinon ajouter x à une liste des objets disponibles
```

À quel *problème* peut-on être confronté ?

Parcours en profondeur sans pile externe

Pendant un parcours en profondeur d'abord, la pile reflète à chaque instant le *chemin parcouru* pour atteindre le sommet courant et permet ainsi de rebrousser chemin.

L'idée, due indépendamment à Deutsch et à Schorr et Waite, est de matérialiser ce *fil d'Ariane* non pas par une pile externe mais en *modifiant au vol le graphe* lui-même.

En gros, il suffit *d'inverser les arêtes* le long du chemin parcouru pour pouvoir retourner sur ses pas.

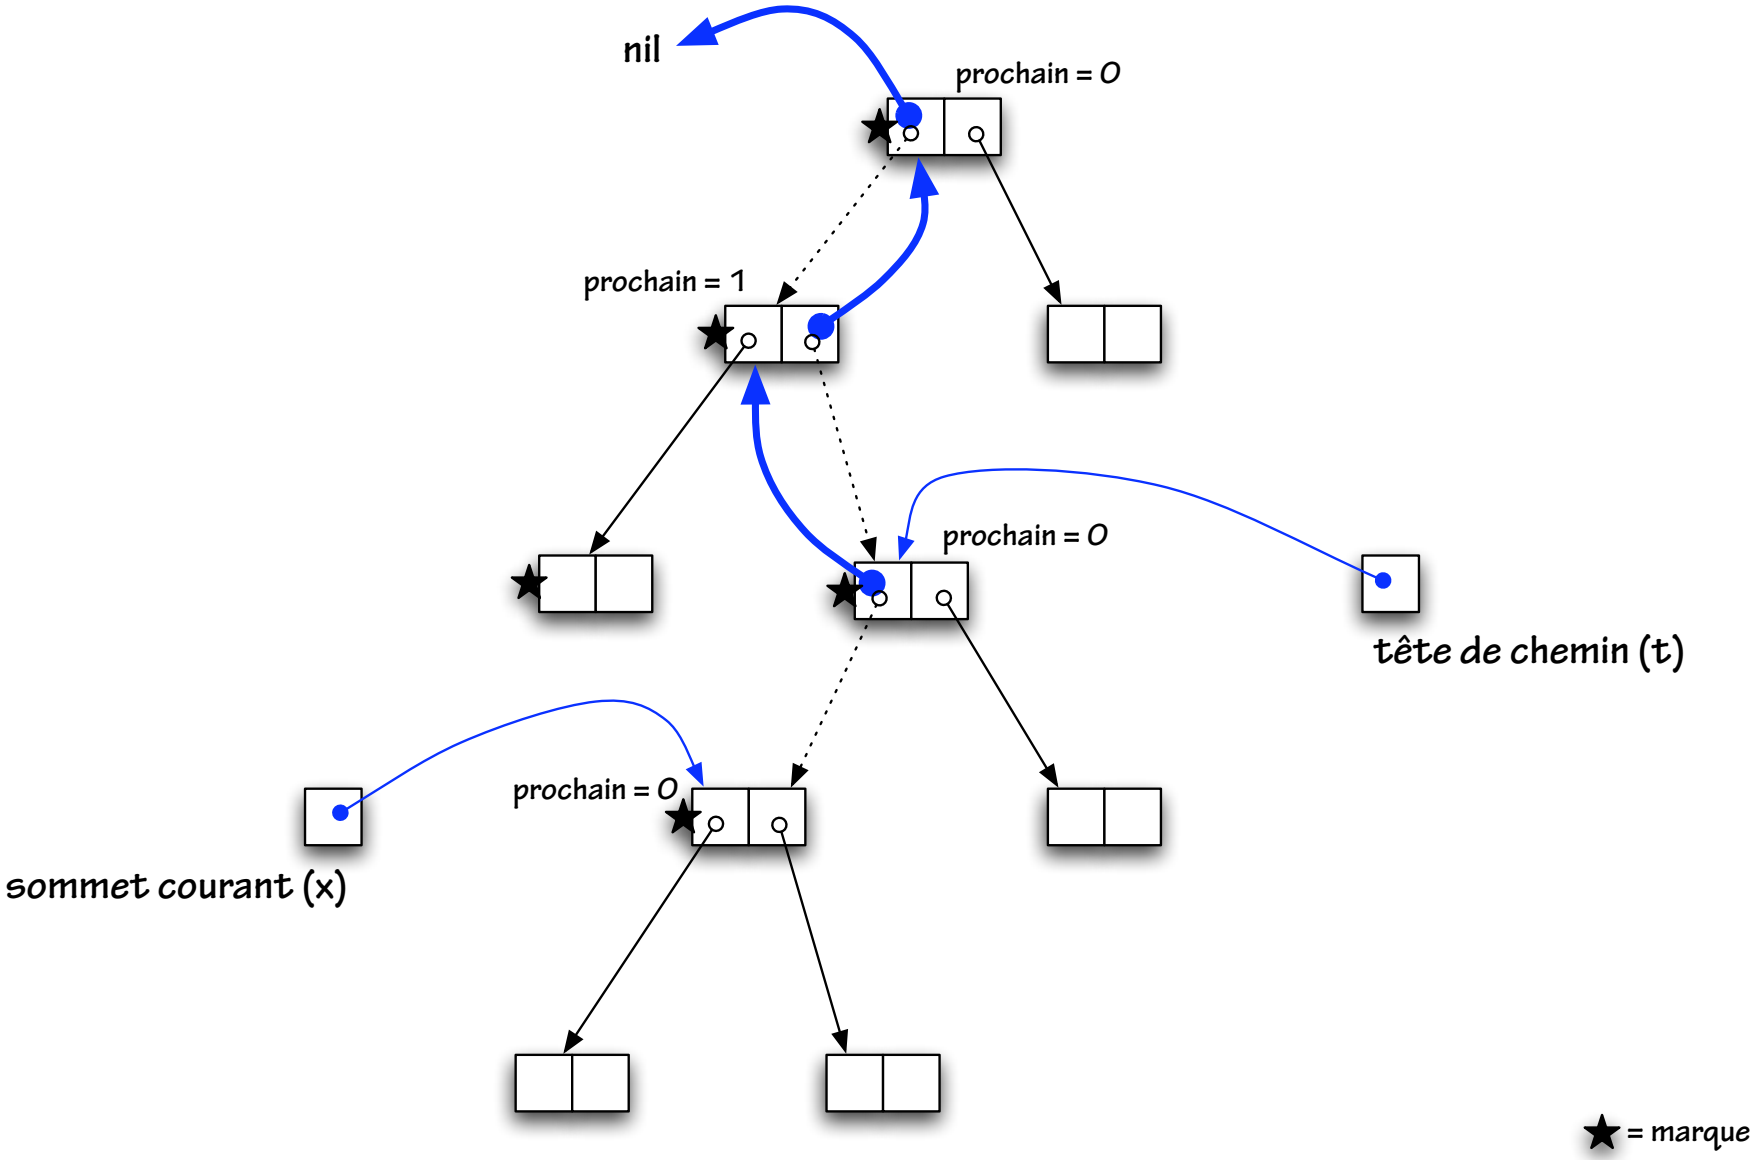
nil
prochain = 0
prochain = 1
prochain = 0
tête de chemin (t)
prochain = 0
sommet courant (x)
= marque

Parcours en profondeur à la Schorr–Waite

À chaque instant,

- x est le sommet en cours d'examen ;
- t est le sommet précédant x le long du chemin parcouru depuis la racine ;
- pour tout sommet z du chemin jusqu'à t, $i = z.\text{prochain}$ est *l'indice de l'arête suivie* à la descente, et le champ z_i contient l'adresse du *sommet précédant* z le long de ce chemin ;
- $x.\text{prochain}$ est l'indice de la prochaine arête à examiner.

Voir "A case study of C source code verification: the Schorr–Waite algorithm" (Hubert & Marché, 2005) pour un *invariant* complet.

Parcours en profondeur à la Schorr–Waite

```
procédure Visiter(x)
 si x n'est pas marqué
 alors
    t ← nil
    marquer x
    x.prochain ← 0
    répéter
       i ← x.prochain
       si x admet un champ d'indice i
       alors
          si x_i n'est pas marqué
          alors
             x_i, t, x ← t, x, x_i    (push)
             marquer x
             x.prochain ← 0
          sinon x.prochain ← i + 1
       sinon
          si t = nil alors terminé
          i ← t.prochain
          x, t, t_i ← t, t_i, x    (pop)
          x.prochain ← i + 1
```

“mark & sweep” : conclusion

Ceux à qui Deutsch-Schorr-Waite fait peur (c'est bien naturel...) pourront travailler avec une *pile de taille bornée*. (Comment ?)

Le coût du marquage est proportionnel à la taille de la partie accessible du tas, mais le coût du balayage est *proportionnel à la taille du tas* tout entier.

La *fragmentation* du tas peut provoquer des problèmes significatifs.

Ramassage "stop & copy"

L'idée (Cheney, 1970) est de *recopier* la partie accessible du graphe dans une *nouvelle* zone de mémoire.

Les objets accessibles une fois copiés seront *contigus*, d'où absence totale de fragmentation.

De plus, le *coût* de la copie est *proportionnel à la taille de la partie accessible* du graphe. À la limite, ce coût est *nul* si aucun objet n'est accessible !

Deux zones de mémoire

La zone où se situe initialement le tas est appelée *"from-space"*. La zone vers laquelle il est recopié est appelée *"to-space"*.

Une fois la copie terminée, les rôles des deux zones sont *intervertis* pour la prochaine phase de ramassage. De ce fait, 50% de la mémoire disponible est *inutilisée* en permanence.

Ce chiffre peut sembler élevé, mais on peut le diminuer en combinant la technique de "stop & copy" avec d'autres techniques, comme l'emploi de générations.

"Forwarding"

Lorsqu'un objet est copié, *son adresse change*. Il faut donc *faire suivre* ("forward") tous les pointeurs vers lui.

Pour cela, il faut *mémoriser la correspondance* entre l'ancienne et la nouvelle adresse de l'objet. Mais où ?

"Forwarding"

Lorsqu'un objet est copié, *son adresse change*. Il faut donc *faire suivre* ("forward") tous les pointeurs vers lui.

Pour cela, il faut *mémoriser la correspondance* entre l'ancienne et la nouvelle adresse de l'objet. Mais où ?

Une fois l'objet situé dans le "from-space" copié vers le "to-space", *son contenu peut être écrasé*. On peut donc en réutiliser le premier champ (par exemple) pour stocker l'adresse de la copie.

Ce premier champ est alors appelé *"forwarding pointer"*.

Je note x_0 le premier champ de l'objet x.

"Forwarding"

Cette fonction *convertit* un "from-pointer" en un "to-pointer", en *copiant* l'objet au vol si nécessaire :

fonction FaireSuivre(x)
  si x n'a pas été copié **alors** $x_0 \leftarrow$ Copier(x)
  renvoyer x_0

La fonction Copier maintient un pointeur *next* vers la partie non encore utilisée du "to-space". Elle *alloue* donc de l'espace dans le "to-space" en incrémentant ce pointeur.

Comment déterminer si x a déjà été copié ou non ?

“Forwarding” et “scanning”

Initialement, chaque objet, situé dans le “from-space”, contient des pointeurs vers le “from-space”.

Lorsqu'un objet est copié, sa copie dans le “to-space” contient *toujours* des pointeurs vers le “from-space”.

Il faut donc examiner (“scan”) ces pointeurs les uns après les autres et les *faire suivre*.

Ce faisant, on découvrira éventuellement de nouveaux objets, qui seront copiés au vol ; il faudra donc examiner à leur tour ces nouvelles copies, et ainsi de suite.

"Scanning"

Un pointeur *scan* pointe vers le prochain objet à examiner dans le "to-space".

Comme *next*, il va croissant. Tant qu'il reste des objets à examiner, il est strictement inférieur à *next*.

Lorsqu'il atteint *next*, il ne reste plus aucune copie à examiner. Donc, tous les pointeurs ont été redirigés, et tout est terminé.

Organisation des espaces

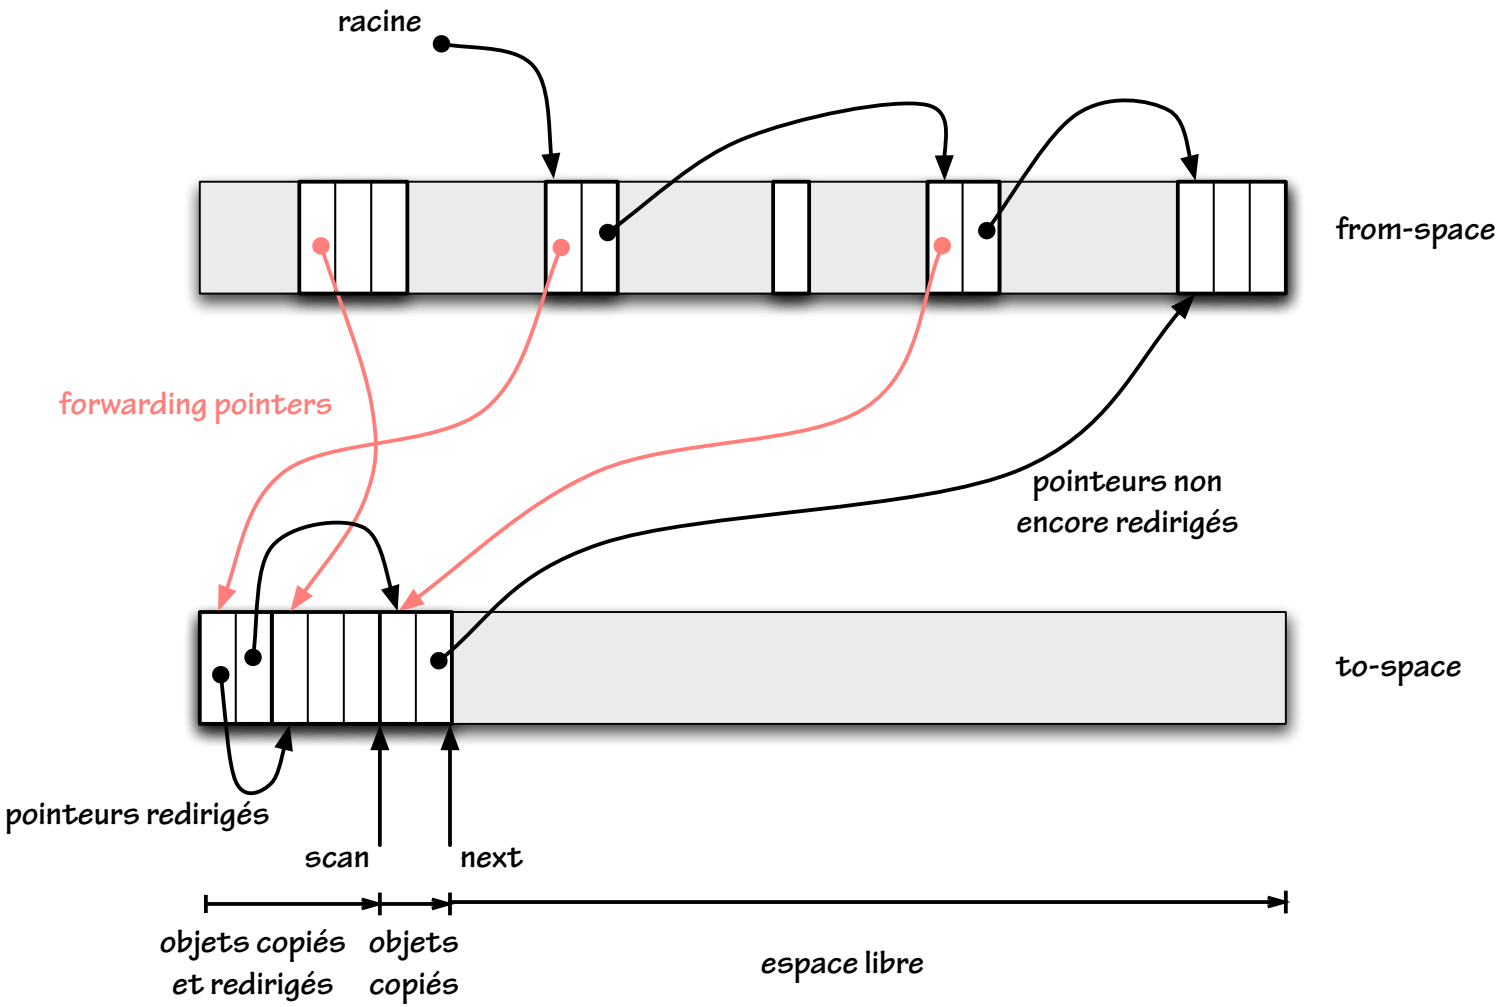

"Scanning" : pseudo-code

L'algorithme complet s'écrit alors :

```
fonction Ramassage()
 scan ← next ← début du "to-space"
 pour chaque racine x
  faire x ← FaireSuivre(x)
 tant que scan < next
          ⎧ soit x l'objet vers lequel pointe scan
          ⎪ pour chaque champ i de x
  faire   ⎨  faire x_i ← FaireSuivre(x_i)
          ⎩ incrémenter scan
```

De *quel type* de parcours de graphe s'agit-il ?

Ramassage à générations

Pour de nombreux programmes, les objets créés *le plus récemment* ont l'espérance de vie *la plus courte*. Inversement, les objets les plus anciens ont des chances de survivre encore longtemps.

Il est donc rentable de se concentrer sur les objets *jeunes*.

On réalise cela en divisant le tas en plusieurs zones ou *générations*. La génération G_{i+1} contient des objets plus anciens que la génération G_i. Le nombre de générations est au choix.

Ramassage à l'intérieur d'une génération

Pour effectuer un ramassage dans G_0 seule, par "mark & sweep" ou par "stop & copy", il faut connaître toutes les racines, *y compris les pointeurs de G_i, pour $i > 0$, vers G_0*.

En pratique, ces pointeurs *d'un objet ancien vers un objet jeune* sont *peu fréquents*. Dans le cas d'un langage purement fonctionnel, ils sont en fait totalement inexistants !

Mais comment les déceler ? Il faut une forme de *"write barrier"* : un test doit être effectué à chaque fois que l'on *modifie* un champ appartenant à un objet de G_i. Voir Appel pour plus de détails.

Ramassage incrémental et concurrent

Pour certaines applications, il n'est *pas tolérable de stopper* le programme (le *"mutateur"*) pendant le temps nécessaire à un ramassage complet.

On souhaite alors que le *"collecteur"* travaille :

- en stoppant le programme, comme précédemment, mais par tranches incomplètes — *ramassage incrémental* ; ou bien,
- sans même stopper le programme, en tâche de fond — *ramassage concurrent*.

Ramassage incrémental et concurrent

Les algorithmes “mark & sweep” et “stop & copy” parcourent le graphe en distinguant des sommets *noirs* (visités et dont les fils ont été visités), *gris* (visités, mais dont les fils n'ont pas tous été visités), et *blancs* (non visités). Tout objet gris est *connu* du “collecteur” et en attente d'examen. De plus,

- *aucun objet noir n'a de fils blanc.*

La difficulté du ramassage incrémental ou concurrent consiste à *empêcher le “mutateur” de briser cet invariant* lorsqu'il crée un objet ou modifie un objet existant.

On réalise cela à l'aide de “write barriers” ou “read barriers”. Voir Appel pour plus de détails.

Interface entre compilateur et GC

Le compilateur doit :

- permettre d'identifier le *nombre* et la *nature* des champs de chaque objet ;
- permettre d'identifier les *racines*, qui se trouvent dans les *registres* (vivants) et dans la *pile* (un peu partout !) ;
- permettre le *marquage* des objets ;
- optimiser le code d'allocation par *expansion en ligne* ("inlining"), *fusion* des allocations effectuées au sein d'un même bloc de base, etc.

Interface entre compilateur et GC

Arrêtons-nous quelques instants sur l'identification des racines.

Lorsque le GC est appelé, la pile contient une succession de trames, dont *chacune* peut contenir des racines — des *pointeurs vivants* vers un objet du tas.

Pour énumérer les racines, le GC doit donc *parcourir la pile*, trame après trame.

Quels problèmes cela pose-t-il ?

Interface entre compilateur et GC

Il faut que le GC puisse déterminer, pour chaque trame, *quelle est sa taille* et, parmi les valeurs qu'elle contient, *lesquelles sont des racines.*

On souhaite (et on peut) faire cela sans ajouter quoi que ce soit au contenu des trames de pile...

Interface entre compilateur et GC

L'idée, dans les grandes lignes, est la suivante :

- Le compilateur crée une table contenant une entrée pour chaque instruction "call" dans le programme.
- Pour un appel de f à g, cette table associe *à l'adresse de retour de l'appel* trois informations :
  - la taille de la trame de pile associée à f ;
  - l'ensemble des emplacements, dans cette trame, qui lors de l'appel contiennent un pointeur vivant ;
  - l'emplacement, dans cette trame, qui contient l'adresse de retour.

À partir de l'adresse de retour qu'on lui a fournie, le GC peut alors remonter la pile de proche en proche et découvrir toutes les racines situées dans la pile.

Interface entre compilateur et GC

La gestion des registres *callee-save* est délicate : quand une fonction f est appelée, les valeurs qui se trouve dans ces registres peuvent être des entiers ou des pointeurs — *cela dépend de l'appelant.*

Par conséquent, si f sauvegarde la valeur de ces registres sur la pile, les emplacements de pile utilisés peuvent être ou non des racines — cela dépend de l'appelant.

Cela complique les choses, mais on s'en sort (voir Appel).

Voilà !

Un aperçu de ce qu'est *"compiler"*...

...pourquoi ce n'est *pas simple*...

...et pourquoi un langage *"de haut niveau"* procure un réel avantage !