Gestion mémoire 2: allocation dynamique

Guillaume Salagnac

Insa de Lyon – Informatique

Résumé des épisodes précédents

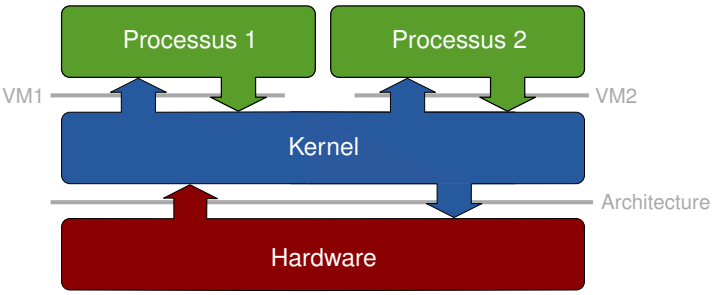

Le processus vu comme une «machine virtuelle»

- un processeur pour moi tout seul: «CPU virtuel»
- une mémoire pour moi tout seul: «mémoire virtuelle»

Mémoire virtuelle: principe

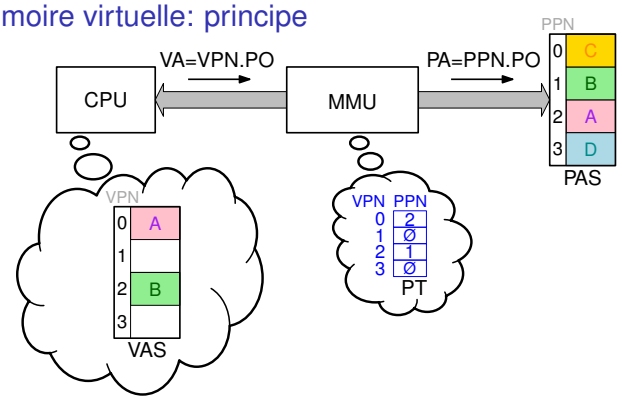

Virtualisation de l'espace d'adressage:

- CPU voit seulement des adresses virtuelles VA
- MMU/TLB traduit à la volée les VA en adresses physiques PA
- correspondance VA↦PA indiquée par la Table de Pages PT

Mémoire virtuelle: services rendus par le noyau

Quelques-unes des fonctions du noyau:

- reconfigurer la MMU à chaque changement de contexte
  - un processus = une table de pages
- réagir aux fautes de page
  - assurer le va-et-vient (swap) des pages entre DRAM et disque
- allouer de nouvelles pages à un processus
  - par ex: appel système `mmap()`

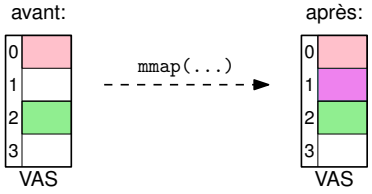

Plan

1. Introduction: rappels sur la mémoire virtuelle
2. Allocation dynamique: définition du problème
3. Fragmentation du tas et stratégies d'allocation
4. Techniques d'implémentation et interface utilisateur

Anatomie de l'espace d'adressage d'un processus

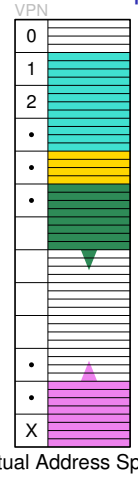

Pour lancer un programme:

1. créer un PCB et une PT
2. charger l'exécutable en mémoire
3. PCB.PC = adresse de `main`
4. PCB.state = ready
5. ajouter le PCB à la ready queue

Un exécutable = plusieurs sections

- `.text` = les instructions
- `.data` = les variables globales
- `.heap` = le tas
- `.stack` = la pile d'appels

À essayer chez vous:

- `objdump -h ./prog.elf`
- `objdump -d ./prog.elf`

Allocation statique: sections `.text` et `.data`

Statique = «qui ne bouge pas pendant l'exécution»

- emplacement fixé avant le début de l'exécution
- taille fixée avant avant le début de l'exécution

Code source:

```
int i,n,r;

factorial()
{
    i = 1;

    while(n>0)
    {
        i = i*n;
        n = n-1;
    }
    r = i;
}
```

Code exécutable :

```
80483a7:   ....
80483aa:   c7 05 2c 96 04 08 01
80483b1:   00 00 00
80483b4:   eb 20
80483b6:   8b 15 2c 96 04 08
80483bc:   a1 30 96 04 08
80483c1:   0f af c2
80483c4:   a3 2c 96 04 08
80483c9:   a1 30 96 04 08
80483ce:   83 e8 01
80483d1:   a3 30 96 04 08
80483d6:   a1 30 96 04 08
80483db:   85 c0
80483dd:   7f d7
80483df:   a1 2c 96 04 08
80483e4:   a3 34 96 04 08
80483e9:   ...
```


Allocation statique: sections `.text` et `.data`

Statique = «qui ne bouge pas pendant l'exécution»

- emplacement fixé avant le début de l'exécution
- taille fixée avant avant le début de l'exécution

Code source:

```
int i,n,r;

factorial()
{
    i = 1;

    while(n>0)
    {
        i = i*n;
        n = n-1;
    }
    r = i;
}
```

Code exécutable «désassemblé»:

```
80483a7:   ...
80483aa:   movl   $0x1,0x804962c
80483b1:
80483b4:   jmp    0x80483d6
80483b6:   mov    0x804962c,%edx
80483bc:   mov    0x8049630,%eax
80483c1:   imul   %edx,%eax
80483c4:   mov    %eax,0x804962c
80483c9:   mov    0x8049630,%eax
80483ce:   sub    $0x1,%eax
80483d1:   mov    %eax,0x8049630
80483d6:   mov    0x8049630,%eax
80483db:   test   %eax,%eax
80483dd:   jg     0x80483b6
80483df:   mov    0x804962c,%eax
80483e4:   mov    %eax,0x8049634
80483e9:   ...
```


Allocation sur la pile d'exécution (en VO *execution stack*)

Problème: comment faire si la taille ou le nombre de données est inconnu à l'avance ?

```
int f(int n) {
  if(n<=1) return 1;
  int a=f(n-1);
  int b=f(n-2);
  return a+b;
}
```

▶ Solution: une structure de données sans limite, i.e. une pile

Remarques:

- technique utilisée par 99% des langages de programmation
  - en VO execution stack, program stack, control stack, run-time stack, machine stack, call stack, *the* stack = en VF la pile
- une activation de fonction = un morceau de la pile
  - variables locales, arguments de fonction, adresses de retour...
- ▶ instructions CPU dédiées: `PUSH`, `POP`, `CALL`, `RET`
  - registre Stack Pointer SP : contient adresse du sommet de pile

La pile: illustration

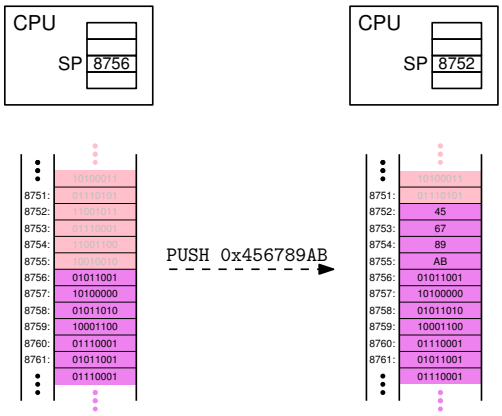

Allocation sur la pile: illustration

```
int fibo(int n)
{
  if(n<=1)
     return 1;

  int a=f(n-1);
  int b=f(n-2);

  return a+b;
}
```

```
8049176 <fibo>:
8049176:   sub    $0x1c,%esp
8049179:   cmpl   $0x1,0x20(%esp)
804917e:   jg     0x8049187
8049180:   mov    $0x1,%eax
8049185:   jmp    0x80491bf
8049187:   mov    0x20(%esp),%eax
804918b:   sub    $0x1,%eax
804918e:   sub    $0xc,%esp
8049191:   push   %eax
8049192:   call   0x8049176
8049197:   add    $0x10,%esp
804919a:   mov    %eax,0xc(%esp)
804919e:   mov    0x20(%esp),%eax
80491a2:   sub    $0x2,%eax
80491a5:   sub    $0xc,%esp
80491a8:   push   %eax
80491a9:   call   0x8049176
80491ae:   add    $0x10,%esp
80491b1:   mov    %eax,0x8(%esp)
80491b5:   mov    0xc(%esp),%edx
80491b9:   mov    0x8(%esp),%eax
80491bd:   add    %edx,%eax
80491bf:   add    $0x1c,%esp
80491c2:   ret
```


Croissance automatique de la pile d'exécution

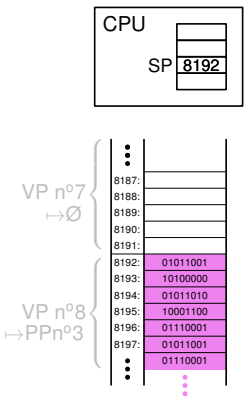

1. application exécute un `PUSH`
2. MMU cherche à traduire VA↦PA
   - trouve un PTE invalide
   - envoie une IRQ au noyau
3. noyau examine la VA demandée
   - reconnaît un débordement de pile
4. noyau cherche une PP libre
5. noyau «place» la page dans VAS
   = met à jour la PT du processus
6. rend la main à l'application
   - instruction `PUSH` retentée ▶ OK

Croissance automatique de la pile d'exécution

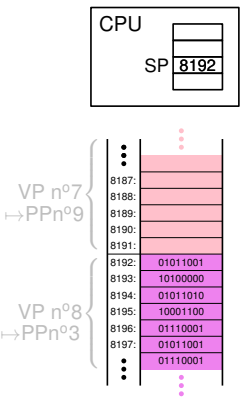

1. application exécute un `PUSH`
2. MMU cherche à traduire VA↦PA
   - trouve un PTE invalide
   - envoie une IRQ au noyau
3. noyau examine la VA demandée
   - reconnaît un débordement de pile
4. noyau cherche une PP libre
5. noyau «place» la page dans VAS
   = met à jour la PT du processus
6. rend la main à l'application
   - instruction `PUSH` retentée ▶ OK

Croissance automatique de la pile d'exécution

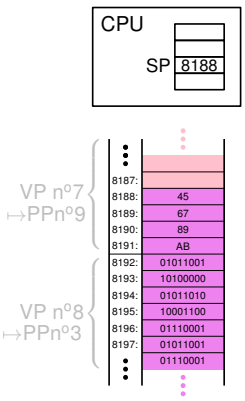

1. application exécute un `PUSH`
2. MMU cherche à traduire VA↦PA
   - trouve un PTE invalide
   - envoie une IRQ au noyau
3. noyau examine la VA demandée
   - reconnaît un débordement de pile
4. noyau cherche une PP libre
5. noyau «place» la page dans VAS
   = met à jour la PT du processus
6. rend la main à l'application
   - instruction `PUSH` retentée ▶ OK

La pile d'exécution: à retenir

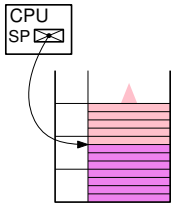

Définition
- zone dédiée à l'allocation "dynamique"
  - allocation et désallocation: LIFO
- usage: variables locales, addr retour
  - cf 3IF-architecture, 4IF-compilation
- registre SP pointe sur sommet de pile

Avantages
- facile à utiliser et à implémenter
- efficace à l'exécution
  - accès via SP en indirect-registre
  - croissance par ajout de page

Inconvénients
- LIFO: inadapté pour certaines structures de données

Allocation dynamique sur le tas (en VO *heap*)

Objectif: permettre allocations et libérations arbitraires

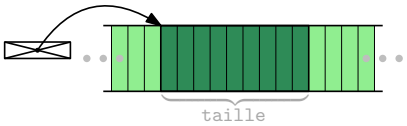

Interface utilisateur
- `allouer(taille)`
  - cherche une zone libre et retourne son adresse de début (ou renvoie une erreur si incapable de servir la requête)
- `libérer(adresse)`
  - indique au gestionnaire mémoire qu'une zone n'est plus utilisée et qu'elle peut être recyclée

Avantages
- facile à utiliser pour le programmeur
- compatible avec toutes les structures de données

Inconvénients
- implémentation complexe ▶ performance difficile à maîtriser

Allocation dynamique vs allocation de pages

Question: comment implémenter `allouer()` et `libérer()`
Mauvaise idée: tout déléguer au noyau via `mmap()` et `munmap()`

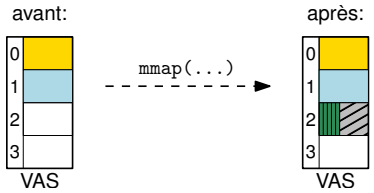

Inconvénients
- seules tailles disponibles: multiples de 2^p ▶ espace gâché
- appels système trop fréquents ▶ mauvaise performance

Solution
- recycler (dans le même processus) les blocs libérés

▶ besoin de garder la trace des blocs libres et des blocs occupés

Gestion du tas: formulation de la problématique

Allocation dynamique sur le tas: définition

Un gestionnaire de mémoire dynamique (VO memory allocator)
- répond aux requêtes d'allocation (resp. de désallocation) émises par l'application
- en réservant (resp. en recyclant) des blocs de taille variée à l'intérieur d'une grande zone appelée le tas

Structure de données: liste des blocs libres, en VO *freelist*

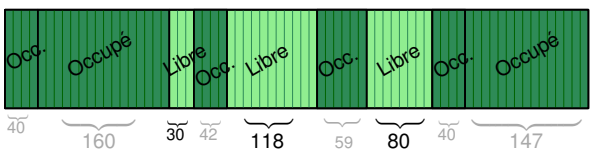

Questions: où allouer un bloc de taille 10 ? de 50 ? de 200 ?

Gestion du tas: remarques

Problématique

- à chaque allocation, on veut un bloc libre et assez grand
- ▶ comment choisir le «meilleur» bloc dans la freelist ?

Règles du jeu

- interdit de «découper» les requêtes d'allocation
  - l'application peut vouloir utiliser le bloc comme un tableau
  - «allocation contiguë» ▶ taille allouée $\geqslant$ taille demandée
- interdit de réordonner la séquence des requêtes
  - dépend du flot d'exécution de l'application
- interdit de bouger les zones déjà allouées
  - chaque choix de bloc est définitif

Inconvénients

- trop grand nombre de blocs libres ▶ allocation lente
- blocs libres trop petits ▶ espace inutilisable

Plan

1. Introduction: rappels sur la mémoire virtuelle
2. Allocation dynamique: définition du problème
3. Fragmentation du tas et stratégies d'allocation
4. Techniques d'implémentation et interface utilisateur

Le problème de la fragmentation

Définition: phénomène de fragmentation du tas

Morcellement progressif de l'espace libre en des blocs trop petits pour satisfaire les requêtes d'allocation de l'application

Les causes de la fragmentation:

- disparité des durées de vie

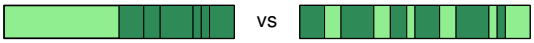

- disparité des tailles allouées

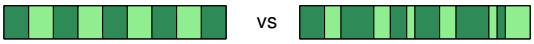

Problématique: comment minimiser la fragmentation du tas ?

Trois pistes: découpage, fusion, choix des blocs

Mécanismes de bas niveau: découpage et fusion

Découpage de blocs libres lors de l'allocation

- ▶ réduit la fragmentation interne = espace inutilisé dans les blocs
- mais risque de produire des blocs libres (trop) petits

Fusion de blocs libres lors de la déallocation

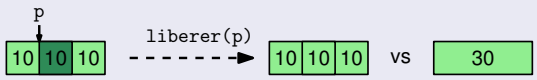

- ▶ réduit la fragmentation externe = blocs trop petits pour être utiles
- mais risque de causer du travail improductif

Stratégies d'allocation: problématique

Comment choisir le «meilleur» bloc dans la freelist ?

Optimal: choisir le bloc qui causera le moins de fragmentation mémoire dans le futur ▶ impossible à deviner

En pratique: compromis entre fragmentation et performance

- fragmentation = $\dfrac{\text{espace total occupé par le tas}}{\text{somme des tailles des blocs alloués}}$
- performance = temps d'exécution de l'algo. de choix de bloc

Note: si aucun bloc libre assez grand ▶ il faut agrandir le tas

- appel système `mmap()` pour demander des pages au noyau

Stratégies d'allocation: exemples

First-fit : examiner le moins de blocs possible

- parcourir la freelist, et choisir le premier bloc libre de taille suffisante

Next-fit : ne pas retraverser toute la freelist à chaque fois

- variante de First-fit: démarrer le parcours à l'endroit du dernier bloc alloué précédemment

Best-fit : préserver les gros blocs libres

- considérer l'intégralité de la freelist, et choisir le bloc acceptable le plus petit

Worst-fit : éviter la prolifération de blocs minuscules

- considérer l'intégralité de la freelist, et choisir le bloc le plus grand

Recherche dans la freelist: exemple

Supposons la freelist suivante:

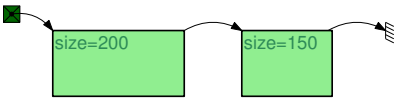

Exercice: requêtes d'allocation de 100 octets, puis 200 octets
- stratégies First Fit, Best Fit, Worst Fit

Exercice: requêtes d'allocation de 80 octets, puis 120, puis 120
- stratégies First Fit, Best Fit, Worst Fit

Hypothèse: si le bloc choisi est trop grand ▶ on le découpe

Stratégies d'allocation: commentaires

Mauvaise nouvelle: pas de stratégie universelle

First-fit
- beaucoup de fragmentation en début de liste

Next-fit
- beaucoup de fragmentation partout !

Best-fit
- comment examiner efficacement tous les blocs ?

Worst-fit
- comment examiner efficacement tous les blocs ?
- énormément de fragmentation

Plan

1. Introduction: rappels sur la mémoire virtuelle

2. Allocation dynamique: définition du problème

3. Fragmentation du tas et stratégies d'allocation

4. Techniques d'implémentation et interface utilisateur
   Techniques d'implémentation
   Interface de programmation

Format d'un bloc libre

Idée: indiquer la taille des blocs libres dans les blocs

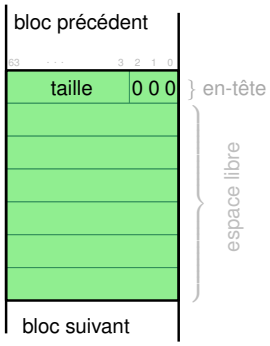

Remarques:
- taille = du bloc entier
  - y compris en-tête
- alignement: toujours multiple de 8
  - ▶ trois derniers bits toujours zéro

Format d'un bloc alloué

Idée: un drapeau pour indiquer les blocs alloués

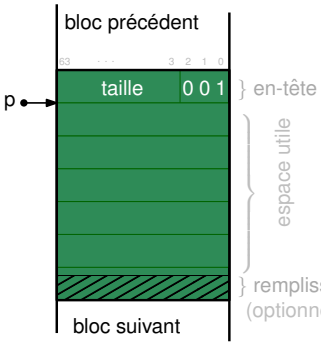

Remarques:
- taille = du bloc entier
  - en-tête + espace utile (+ padding)
  - alignée à 8 octets
- 000 = libre, 001 = alloué
- p = pointeur visible par l'application
- padding = espace perdu

Question: comment localiser le bloc précédent ?

Boundary tags

Idée: ajouter un *footer* à la fin de chaque bloc
▶ permet de traverser la freelist dans les deux sens

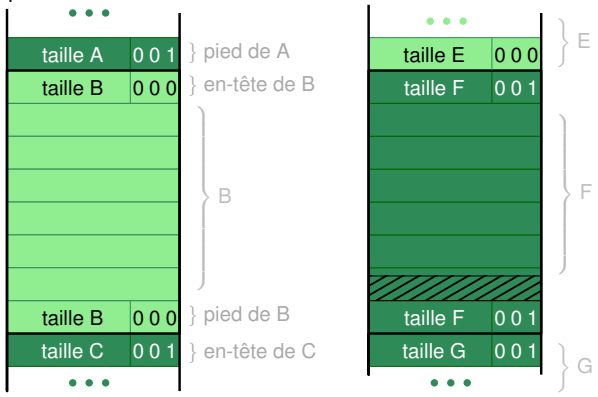

Remarque: impact sur taille de bloc minimale

Chaînage explicite de la freelist

Question: comment accélérer la recherche dans la freelist ?

- Idée 1: chaîner uniquement les blocs libres
  - ▶ pas besoin de considérer les blocs alloués
- Idée 2: garder triée la freelist dans le «bon» ordre
  - ▶ trouver plus rapidement le bloc recherché

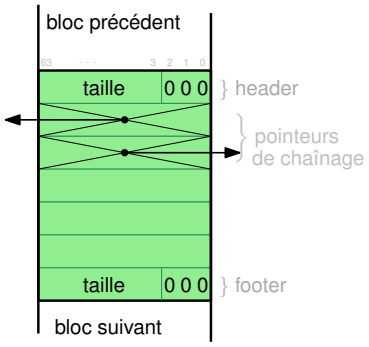

Ordre de tri:

- par adresses croissantes:
  - fusion facile
  - allocation coûteuse
- par tailles croissantes:
  - best-fit efficace
  - fusion coûteuse
- par tailles décroissantes:
  - worst-fit facile
  - fusion coûteuse

La vraie vie: allocateur avec *segregated freelist*

Idée: plusieurs listes chaînées pour les différentes tailles
▶ approximation de best-fit sans traverser tous les blocs

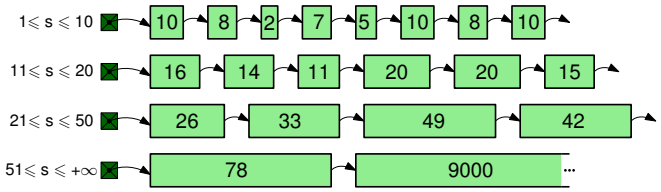

Remarques

- allocation: si pas trouvé ▶ découper un bloc plus grand
  - liste triée vs liste non triée
- désallocation: fusion optionnelle ▶ recyclage des petits blocs
  - cas extrême: tailles exactes, par exemple $s = 8$, $s = 16$, etc.

Exemple: le malloc de Linux

Exemple (glibc) : 128 «paniers» (en VO *bins*)

- 64 premiers paniers: tailles exactes 8, 16, 24, 32, ... 512
- 32 paniers suivants: 513–576, 577–640, ... 2497–2560
- puis 8 espacés de 4kB, 4 espacés de 32kB, deux de 256kB
- au-delà: allocations déléguées à `mmap()`

Rq: chaque sous-liste triée par taille ▶ best-fit

```
Free chunks are stored in circular doubly-linked lists, and look like this:
    chunk-> +-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+
            |             Size of previous chunk                            |
            +-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+
    'head:' |             Size of chunk, in bytes                         |P|
      mem-> +-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+
            |             Forward pointer to next chunk in list             |
            +-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+
            |             Back pointer to previous chunk in list            |
            +-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+
            |             Unused space (may be 0 bytes long)                .
            .                                                               .
            .                                                               |
nextchunk-> +-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+
    'foot:' |             Size of chunk, in bytes                            |
            +-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+-+
```


Plan

1. Introduction: rappels sur la mémoire virtuelle
2. Allocation dynamique: définition du problème
3. Fragmentation du tas et stratégies d'allocation
4. Techniques d'implémentation et interface utilisateur
   Techniques d'implémentation
   Interface de programmation

Allocation dynamique en C et en C++

Idée: le développeur utilise explicitement une API

- C▶ `void* malloc(size)` et `free(void* ptr)`
- C++ ▶ opérateurs `new(size)` et `delete(void* ptr)`

Désallocation manuelle = risque d'erreurs de programmation

```
truc *a = malloc(...);
truc *b = a;
b->x = 42;
free(a);
truc *c = malloc(...);
c->x = 37;
printf("b->x: %d\n", b->x);
```

```
truc *a = malloc(...);
truc *b = malloc(...);
b = a ;
```

- dangling pointer AKA use-after-free
  - en pratique: assez fréquent et quasi impossible à corriger
- fuite de mémoire (memory leak) = blocs jamais désalloués
  - en pratique: seulement gênant si le processus dure longtemps
- rappel: `free()` ne rend pas la mémoire à l'OS

Allocation dynamique en Java, Python...

Idée 1: si aucun pointeur vers un bloc, alors bloc inaccessible
Idée 2: interdire la création de pointeurs arbitraires
▶ un bloc inaccessible maintenant le restera pour toujours

Définition: Garbage Collection

Allocation dynamique intégrée au langage de programmation

- gestionnaire mémoire invoqué implicitement
- détection (▶ libération) automatique des blocs inaccessibles

Inconvénients:

- performance (temps, espace) du Garbage Collector
- incompatible avec programmation «bas-niveau» e.g. C/C++

Avantages:

- (parfois) gain de performances à l'exécution
- plus simple à programmer: pas de `free()`

Plan

1. Introduction: rappels sur la mémoire virtuelle
2. Allocation dynamique: définition du problème
3. Fragmentation du tas et stratégies d'allocation
4. Techniques d'implémentation et interface utilisateur

À retenir: allocation dynamique de mémoire

Allocation sur la pile = variables locales

- simple et rapide car fragmentation impossible
- LIFO: limité à certains usages

Allocation dynamique = Allocation sur le tas = `malloc()`

- pas de restrictions sur les structures de données
- risque de fragmentation (interne et/ou externe)
- ▶ algorithmes complexes pour allouer/désallouer
- pas de solution miracle universelle

Allocation manuelle en C/C++

- erreurs de programmation fréquentes
- ▶ pas toujours utile de scrupuleusement désallouer toute votre mémoire !