

La vérification des programmes par interprétation abstraite

Patrick Cousot

École normale supérieure

Patrick.Cousot@ens.fr www.di.ens.fr/~cousot

Équipe-projet INRIA Paris–Rocquencourt/CNRS/ENS « ABSTRACTION »

Séminaire

Chaire d'innovation technologique Liliane Bettencourt

Collège de France, 22 février 2008

1. Exemples classiques de bugs

Le programme factorielle (fact.c)

```
#include <stdio.h>
```

```
int fact (int n ) {
```

← $\text{fact}(n) = 2 \times 3 \times \dots \times n$

```
    int r, i ;
```

```
    r = 1 ;
```

```
    for (i=2 ; i<=n ; i++) {
```

```
        r = r*i ;
```

```
    }
```

```
    return r ;
```

```
}
```

```
int main() { int n ;
```

```
    scanf ("%d" ,&n) ;
```

```
    printf ("%d !=%d\n" ,n, fact (n)) ;
```

```
}
```

Le programme factorielle (fact.c)

```
#include <stdio.h>
int fact (int n ) {
    int r, i ;
    r = 1 ;
    for (i=2 ; i<=n ; i++) {
        r = r*i ;
    }
    return r ;
}

int main() { int n ;
    scanf ("%d" ,&n) ;           ← lire n (tapé au clavier)
    printf ("%d !=%d\n" ,n, fact (n)) ; ← écrire n ! = fact(n)
}
```

Compilation ⁽¹⁾ du programme factorielle (fact.c)

```
#include <stdio.h>                                     % gcc fact.c -o fact.exec
int fact (int n ) {                                    %
    int r, i ;
    r = 1 ;
    for (i=2 ; i<=n ; i++) {
        r = r*i ;
    }
    return r ;
}

int main() { int n ;
    scanf ("%d" ,&n) ;
    printf ("%d !=%d\n" ,n ,fact (n)) ;
}
```

(1) Voir la leçon du 8 février 2008 et le séminaire de Xavier Leroy

Exécution du programme factorielle (fact.c)

```
#include <stdio.h>                                     % gcc fact.c -o fact.exec
int fact (int n ) {                                   % ./fact.exec
    int r, i;                                         3
    r = 1;                                            3 ! = 6
    for (i=2; i<=n; i++) {                             % ./fact.exec
        r = r*i;                                       4
    }                                                  4 ! = 24
    return r;                                         %
}

int main() { int n;
    scanf ("%d", &n) ;
    printf ("%d != %d\n", n, fact (n)) ;
}
```


Exécution du programme factorielle (fact.c)

```
#include <stdio.h>                                     % gcc fact.c -o fact.exec
int fact (int n ) {                                    % ./fact.exec
    int r, i;                                          3
    r = 1;                                             3 ! = 6
    for (i=2; i<=n; i++) {                             % ./fact.exec
        r = r*i;                                       4
    }                                                 4 ! = 24
    return r;                                          % ./fact.exec
}                                                    100
int main() { int n;                                    100 ! = 0
    scanf ("%d",&n) ;                                % ./fact.exec
    printf ("%d != %d\n",n,fact(n)) ;                 20
}
```

Exécution du programme factorielle (fact.c)

```


#include <stdio.h>
int fact (int n ) {
    int r, i ;
    r = 1 ;
    for (i=2 ; i<=n ; i++) {
        r = r*i ;
    }
    return r ;
}

int main() { int n ;
    scanf ("%d" ,&n) ;
    printf ("%d !=%d\n" ,n ,fact (n)) ;
}
% gcc fact.c -o fact.exec
% ./fact.exec
3
3 ! = 6
% ./fact.exec
4
4 ! = 24
% ./fact.exec
100
100 ! = 0
% ./fact.exec
20
20 ! = -2102132736

```


À la chasse au bug

- Les ordinateurs utilisent une **arithmétique entière modulaire** sur n bits (où $n = 16, 32, 64, \text{etc}$)
- Exemple d'une **représentation des entiers sur 4 bits** (en *complément à deux*) :



Le bug est une défaillance du programmeur

En machine, la fonction `fact(n)` ne coïncide avec $n! = 2 \times 3 \times \dots \times n$ sur les entiers que pour $1 \leq n \leq 12$:



Et en OCAML on a un résultat différent !

```
let rec fact n = if (n = 1) then 1 else n * fact(n-1);;
```

fact(n)	C	OCAML	fact(22)	-522715136	-522715136
fact(1)	1	1	fact(23)	862453760	862453760
...	fact(24)	-775946240	-775946240
fact(12)	479001600	479001600	fact(25)	2076180480	-71303168
fact(13)	1932053504	-215430144	fact(26)	-1853882368	293601280
fact(14)	1278945280	-868538368	fact(27)	1484783616	-662700032
fact(15)	2004310016	-143173632	fact(28)	-1375731712	771751936
fact(16)	2004189184	-143294464	fact(29)	-1241513984	905969664
fact(17)	-288522240	-288522240	fact(30)	1409286144	-738197504
fact(18)	-898433024	-898433024	fact(31)	738197504	738197504
fact(19)	109641728	109641728	fact(32)	-2147483648	0
fact(20)	-2102132736	45350912	fact(33)	-2147483648	0
fact(21)	-1195114496	952369152	fact(34)	0	0

Pourquoi ? Que fait fact(-1) ?


Preuve d'absence d'erreurs à l'exécution par analyse statique

```
% cat -n fact_lim.c
1 int MAXINT = 2147483647 ;
2 int fact (int n) {
3     int r, i;
4     if (n < 1) || (n = MAXINT) {
5         r = 0;
6     } else {
7         r = 1;
8         for (i = 2; i<=n; i++) {
9             if (r <= (MAXINT / i)) {
10                r = r * i;
11            } else {
12                r = 0;
13            }
14        }
15    }
16    return r;
17 }
18
```

```
19 int main() {
20     int n, f;
21     f = fact(n);
22 }
```

```
% astree -exec-fn main fact_lim.c |& grep WARN
%
```

→ Aucune alarme!



Les modèles et leur réalisation sur machine

- Les **modélisations mathématiques** des systèmes physiques utilisent les **nombre réels**
- Les **langages informatiques de modélisation** (comme SCAD^E ⁽²⁾) utilisent les **nombre réels**
- Les **nombre réels** sont difficilement représentables en machine (π a un nombre infini de décimales)
- Les **langages informatiques de programmation** (comme C ou OCAML) utilisent les **nombre flottants**

(2) Voir la leçon du 15 février 2008

Les flottants

- Les *nombre*s *flottants* sont un sous-ensemble des *rationnels*
- Par exemple on peut représenter 32 flottants sur 6 bits, les 16 flottants positifs étant répartis comme suit :



- Quand les calculs réels ne tombent pas juste, il faut *arrondir vers un flottant proche*

Exemple d'erreur d'arrondi (1)

$$(x + a) - (x - a) \neq 2a$$

```
#include <stdio.h>                                % gcc arrondi1.c -o arrondi1.exec
int main() {                                       % ./arrondi1.exec
    double x, a; float y, z; 134217728.000000
    x = 1125899973951488.0; %
    a = 1.0;
    y = (x+a);
    z = (x-a);
    printf("%f\n", y-z);
}
```

Exemple d'erreur d'arrondi (2)

$$(x + a) - (x - a) \neq 2a$$


```
#include <stdio.h>                                     % gcc arrondi2.c -o arrondi2.exec
int main() {                                           % ./arrondi2.exec
    double x, a; float y, z;
    x = 1125899973951487.0;
    a = 1.0;
    y = (x+a);
    z = (x-a);
    printf("%f\n", y-z);
}
```

Exemple d'erreur d'arrondi (2)

$$(x + a) - (x - a) \neq 2a$$

```
#include <stdio.h>                                     % gcc arrondi2.c -o arrondi2.exec
int main() {                                           % ./arrondi2.exec
    double x, a; float y, z; 0.000000
    x = 1125899973951487.0; %
    a = 1.0;
    y = (x+a);
    z = (x-a);
    printf("%f\n", y-z);
}
```

À la chasse au bug (1)



Preuve d'absence d'erreurs à l'exécution par analyse statique

```
% cat -n arrondi3.c
 1 int main() {
 2     double x; float y, z, r;;
 3     x = 1125899973951488.0;
 4     y = x + 1;
 5     z = x - 1;
 6     r = y - z;
 7     __ASTREE_log_vars((r));
 8 }

% astree -exec-fn main -print-float-digits 10 arrondi3.c \
  |& grep "r in "
direct = <float-interval : r in [-134217728, 134217728] > (3)
```

(3) ASTRÉE considère le pire des cas d'arrondi (vers $+\infty$, $-\infty$, 0 ou au plus proche) d'où la possibilité d'obtenir -134217728.

Exemples de bugs dus à des erreurs d'arrondi

- Le **bug du missile patriote** ratant les Scuds en 1991 à cause une horloge incrémentée par $\frac{1}{10}$ ème de seconde ((0, 1)₁₀ = (0, 0001100110011001100...)₂ en binaire)
- Le **bug d'Exel 2007** : 77,1 × 850 qui donne 65.535 mais s'affiche en 100.000 !⁽⁴⁾


2	65535-2 ⁽⁻³⁷⁾	100000	65536-2 ⁽⁻³⁷⁾	100001
3	65535-2 ⁽⁻³⁶⁾	100000	65536-2 ⁽⁻³⁶⁾	100001
4	65535-2 ⁽⁻³⁵⁾	100000	65536-2 ⁽⁻³⁵⁾	100001
5	65535-2 ⁽⁻³⁴⁾	65535	65536-2 ⁽⁻³⁴⁾	65536
6	65535-2 ⁽⁻³⁶⁾ -2 ⁽⁻³⁷⁾	100000	65536-2 ⁽⁻³⁶⁾ -2 ⁽⁻³⁷⁾	100001
7	65535-2 ⁽⁻³⁵⁾ -2 ⁽⁻³⁷⁾	100000	65536-2 ⁽⁻³⁵⁾ -2 ⁽⁻³⁷⁾	100001
8	65535-2 ⁽⁻³⁵⁾ -2 ⁽⁻³⁶⁾	100000	65536-2 ⁽⁻³⁵⁾ -2 ⁽⁻³⁶⁾	100001
9	65535-2 ⁽⁻³⁵⁾ -2 ⁽⁻³⁶⁾ -2 ⁽⁻³⁷⁾	65535	65536-2 ⁽⁻³⁵⁾ -2 ⁽⁻³⁶⁾ -2 ⁽⁻³⁷⁾	65536

(4) Erreur d'arrondi incorrect lors de la traduction de flottants IEEE 754 sur 64 bits en chaîne de caractères Unicode qui conduit à un mauvais alignement dans une table de conversion. Le bug apparaît exactement pour six nombres entre 65534.99999999995 et 65535 et six entre 65535.99999999995 et 65536.

Les bugs dans le monde numérisé quotidien

Les bugs sont fréquents dans la vie quotidienne

- Les **bugs** se trouvent dans les banques, les voitures, les téléphones, les machines à laver, ...
- Exemple (**bug dans un distributeur de monnaie** au 19 Boulevard Sébastopol à Paris, le 21 novembre 2006 à 8^h30) :




2. La vérification des programmes

Principe de la vérification des programmes

- Définir une **sémantique** du langage (c'est-à-dire l'effet de l'exécution des programmes du langage)
- Définir une **spécification** (exemple : pas d'erreur à l'exécution comme une division par zéro, un débordement arithmétique, etc)
- Faire une **preuve formelle** que la sémantique satisfait la spécification
- Utiliser l'ordinateur pour **automatiser la preuve**

Sémantique opérationnelle du programme P



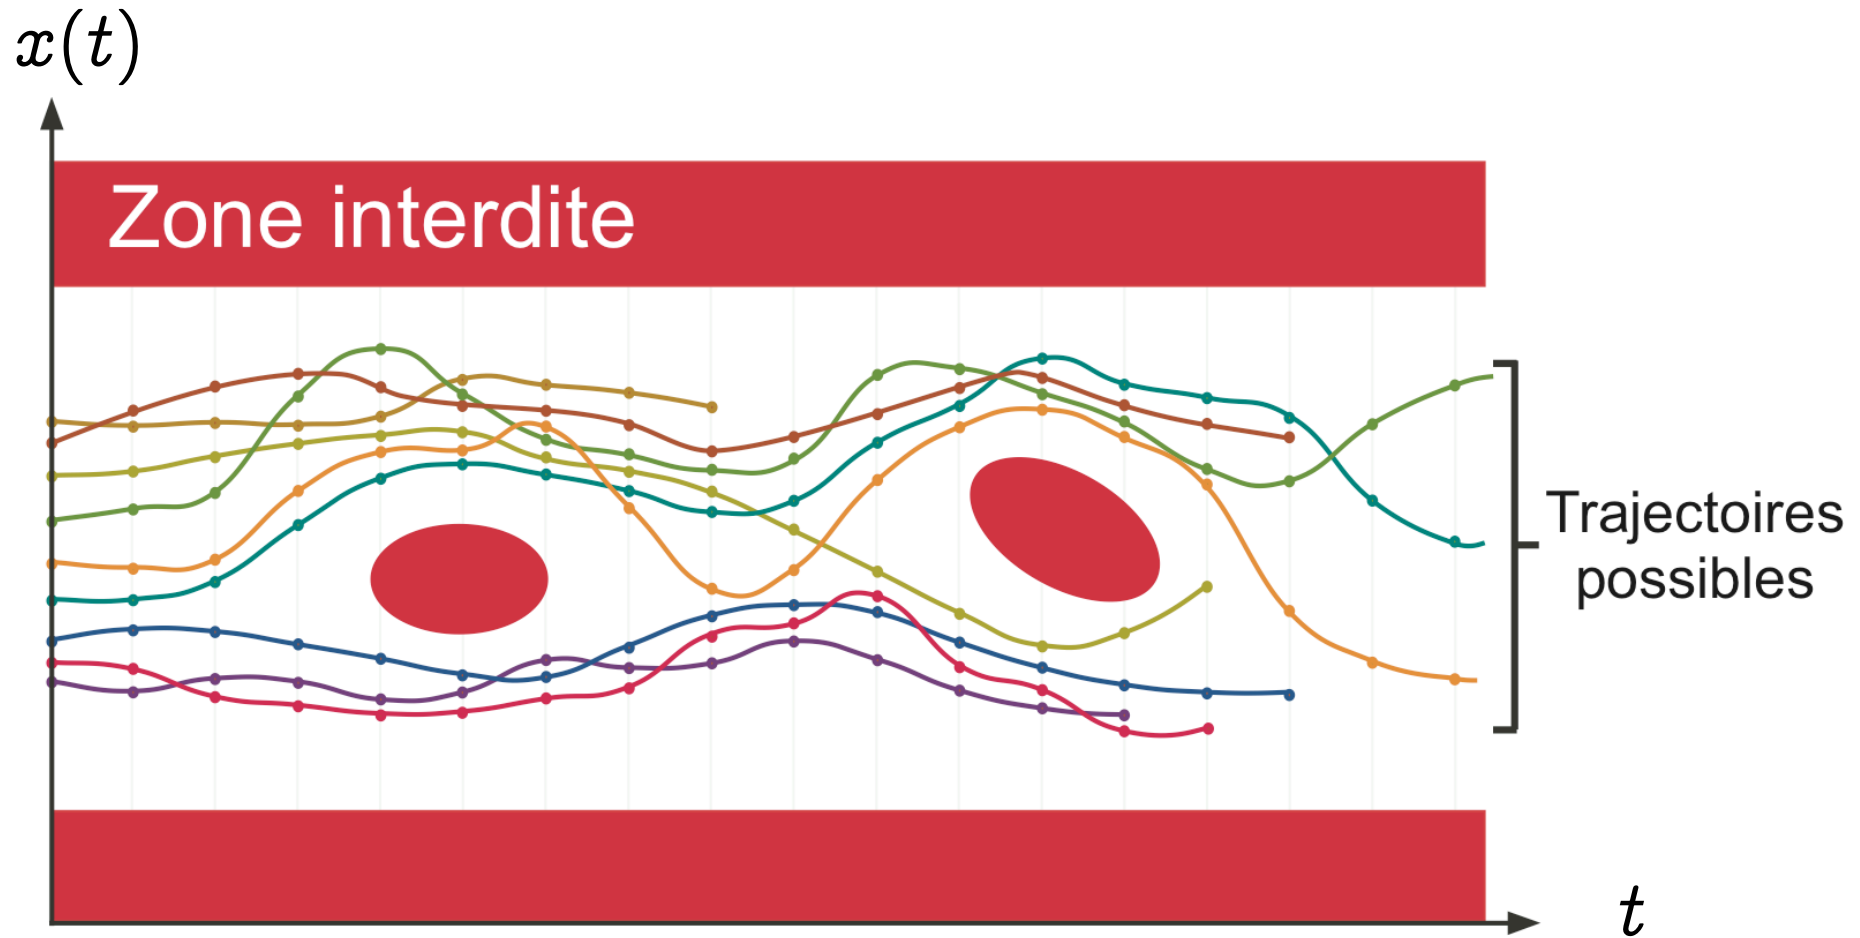
Exemple : trace d'exécution de fact(4) ⁽⁵⁾

```
int fact (int n ) {  
    int r = 1, i ;  
    for (i=2; i<=n; i++) {  
        r = r*i ;  
    }  
    return r ;  
}
```

```
• n ← 4; r ← 1;  
• i ← 2; r ← 1 × 2 = 2;  
• i ← 3; r ← 2 × 3 = 6;  
• i ← 4; r ← 6 × 4 = 24;  
• i ← 5;  
• return 24;
```


(5) Voir la leçon du 22 février 2008

Preuve formelle du programme P



$$\text{Sémantique}[[P]] \subseteq \text{Spécification}[[P]]$$

Le test est incomplet




3. Interprétation abstraite [1]

Référence


- [1] P. Cousot. Méthodes itératives de construction et d'approximation de points fixes d'opérateurs monotones sur un treillis, analyse sémantique de programmes. Thèse d'État ès sciences mathématiques. Université scientifique et médicale de Grenoble. 1978.

Abstraction du programme P



Abstraction(Sémantique[[P]])


Preuve par abstraction



$$\text{Abstraction}(\text{Sémantique}[[P]]) \subseteq \text{Spécification}[[P]]$$


Correction de l'interprétation abstraite

L'interprétation abstraite est correcte




$$\text{Sémantique}[P] \subseteq \text{Abstraction}(\text{Sémantique}[P])$$


Alarme



Une alarme peut correspondre à une erreur




Une alarme peut correspondre à une approximation




4. Application de l'interprétation abstraite à l'analyse statique

Sémantique




Ensemble (infini) de traces (finies ou infinies)

Abstraction en un ensemble d'états (invariant)




Ensemble de points $\{(x_i, y_i) : i \in \Delta\}$, Hoare logic [Cou02]

Abstraction par des intervalles




Intervalles $a \leq x \leq b, c \leq y \leq d$ [CC77]

Abstraction par des octogones




Octogones $x - y \leq a, x + y \leq b$ [Min06]

Abstraction par des polyèdres




Polyèdres $a.x + b.y \leq c$ [CH78]

Abstraction par des ellipsoïdes



Ellipsoïdes $(x - a)^2 + (y - b)^2 \leq c$ [Fer05b]


Abstraction par des exponentielles



Exponentielles $a^x \leq y$ [Fer05a]

5. Calcul d'invariant par approximation de points fixes [CC77]

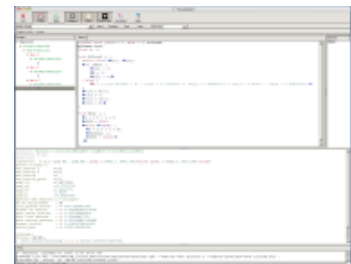
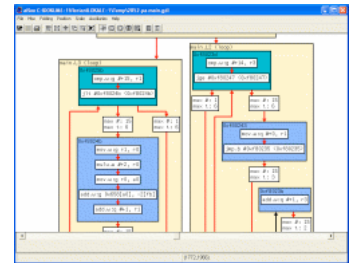
$$\text{Itérés } I = \lim_{n \rightarrow \infty} F^n(\text{faux})$$
$$I^0(x, y) = \text{faux}$$



6. Application industrielle de l'interprétation abstraite

Exemples d'analyseurs statiques

- Pour les programmes C critiques synchrones embarqués de contrôle/commande (par exemple pour des logiciels de Commande De Vol Électrique⁽¹¹⁾)
- **aiT** [FHL⁺01] est un analyseur statique qui vérifie les temps d'exécution maximaux (pour garantir la synchronisation en temps voulu)
- **ASTRÉE** [BCC⁺03] est un analyseur statique qui vérifie l'absence d'erreurs à l'exécution



(11) Voir la leçon du 15 février 2008 et le séminaire de Gérard Ladier

Résultats industriels obtenus avec ASTRÉE

Preuves automatiques d'absence d'erreur à l'exécution dans des logiciels de Commande De Vol Électrique⁽¹²⁾ :



- Logiciel 1 : 132.000 lignes de C, 40mn sur un PC 2.8 GHz, 300 mégaoctets (nov. 2003)
- Logiciel 2 : 1.000.000 de lignes de C, 34h, 8 gigaoctets (nov. 2005)

sans aucune fausse alarme

Premières mondiales !

(12) Voir la leçon du 15 février 2008 et le séminaire de Gérard Ladiere

7. Conclusion

Le futur

- **Génie informatique** : La vérification manuelle par contrôle de la méthode de conception du programme ⁽¹³⁾ sera complétée par la vérification automatique du programme produit
- **Systemes complexes** : l'interprétation abstraite s'applique aussi bien à l'analyse des systèmes évolutifs dont on sait décrire le comportement discret (traitement d'images, systèmes biologiques, calcul quantique, etc)

(13) Voir le séminaire de Gérard Ladier du 15 février 2008

FIN

FIN

Merci de votre attention

8. Bibliographie

- [CCF⁺07] P. Cousot, R. Cousot, J. Feret, L. Mauborgne, A. Miné, D. Monniaux, and X. Rival. Varieties of static analyzers : A comparison with ASTRÉE, papier invité. In M. Hinchey, He Jifeng, and J. Sanders, editors, *Proceedings of the First IEEE & IFIP International Symposium on Theoretical Aspects of Software Engineering, TASE '07*, pages 3–17, Shanghai, Chine, 6–8 juin 2007. IEEE Computer Society Press, Los Alamitos, Californie, USA.
- [CH78] P. Cousot and N. Halbwachs. Automatic discovery of linear restraints among variables of a program. In *Conference Record of the Fifth Annual ACM SIGPLAN-SIGACT Symposium on Principles of Programming Languages*, pages 84–97, Tucson, Arizona, 1978. ACM Press, New York, New York, USA.
- [Cou97] P. Cousot. Types as abstract interpretations, papier invité. In *Conference Record of the Twenty-fourth Annual ACM SIGPLAN-SIGACT Symposium on Principles of Programming Languages*, pages 316–331, Paris, janvier 1997. ACM Press, New York, New York, USA.
- [Cou02] P. Cousot. Constructive design of a hierarchy of semantics of a transition system by abstract interpretation. *Theoretical Computer Science*, 277(1–2) :47–103, 2002.
- [DS07] D. Delmas and J. Souyris. ASTRÉE : from research to industry. In G. Filé and H. Riis-Nielson, editors, *Proceedings of the Fourteenth International Symposium on Static Analysis, SAS '07*, Kongens Lyngby, Danemark, Lecture Notes in Computer Science 4634, pages 437–451. Springer, Berlin, Allemagne, 22–24 août 2007.
- [Fer05a] J. Feret. The arithmetic-geometric progression abstract domain. In R. Cousot, editor, *Proceedings of the Sixth International Conference on Verification, Model Checking and Abstract Interpretation (VMCAI 2005)*, pages 42–58, Paris, 17–19 janvier 2005. Lecture Notes in Computer Science 3385, Springer, Berlin, Allemagne.

- [Fer05b] J. Feret. Numerical abstract domains for digital filters. In *First International Workshop on Numerical & Symbolic Abstract Domains, NSAD '05*, Maison Des Polytechniciens, Paris, 21 janvier 2005.
- [FHL⁺01] C. Ferdinand, R. Heckmann, M. Langenbach, F. Martin, M. Schmidt, H. Theiling, S. Thesing, and R. Wilhelm. Reliable and precise WCET determination for a real-life processor. In T.A. Henzinger and C.M. Kirsch, editors, *Proceedings of the First International Workshop on Embedded Software, EMSOFT '2001*, volume 2211 of *Lecture Notes in Computer Science*, pages 469–485. Springer, Berlin, Allemagne, 2001.
- [Min06] A. Miné. The octagon abstract domain. *Higher-Order and Symbolic Computation*, 19 :31–100, 2006.

Réponses aux questions

- Les entiers sont codés sur 32 bits en C et 31 bits en OCAML (un bit étant gardé pour gérer la mémoire pour le ramassage de miettes (*garbage collection*))
- L'appel de `fact(-1)` appelle `fact(-2)` qui appelle `fact(-3)`, etc. À chaque appel, il faut empiler la paramètre et l'adresse de retour⁽¹⁴⁾, ce qui se termine par un débordement de la pile :

```
% ocaml
      Objective Caml version 3.10.0
# let rec fact n = if (n = 1) then 1 else n * fact(n-1);;
val fact : int -> int = <fun>
# fact(-1);;
Stack overflow during evaluation (looping recursion?).
```

(14) Voir la leçon du 8 février 2008 et le séminaire de Xavier Leroy