Debugging Système et Noyau

Aurélien Cedeyn

École Nationale Supérieure d'Informatique pour l'Industrie et l'Entreprise

2017-2018

Sommaire

1. Debugger
   - Définitions
   - Les différents type d'analyse
   - Les différents univers
   - Ce que couvre ce cours
2. Les instructions
3. Processus utilisateur
4. Noyau
5. Questions

Définitions

Définition

To search for and eliminate malfunctioning elements or errors in

- Quand doit-on debugger ?
  - Une application ne se comporte pas comme elle le devrait
  - Les performances du système ne correspondent pas aux attentes
  - Problèmes de sécurité
  - Plantage du système
- Quels outils ?
  - Pour chaque élément du système à observer, il faut choisir le ou les outils les mieux adaptés à la situation.
  - Certains outils sont orientés utilisateur, d'autre système, certains autres font la jonction entre les deux univers.
- Que chercher ?
- Se poser des questions et faire preuve d'imagination

Définitions

Définition

To search for and eliminate malfunctioning elements or errors in

- Quand doit-on debugger ?
  - Une application ne se comporte pas comme elle le devrait
  - Les performances du système ne correspondent pas aux attentes
  - Problèmes de sécurité
  - Plantage du système
- Quels outils ?
  - Pour chaque élément du système à observer, il faut choisir le ou les outils les mieux adaptés à la situation.
  - Certains outils sont orientés utilisateur, d'autre système, certains autres font la jonction entre les deux univers.
- Que chercher ?
- Se poser des questions et faire preuve d'imagination

Les différents type d'analyse

- Activer, lire et comprendre les messages de log
- Tracer un processus
- Récupérer la pile d'exécution d'un processus
- Analyse la mémoire d'un processus

Les différents univers

Définition

Au sein du système d'exploitation, on peut distinguer trois univers différents :

- L'espace utilisateur : tout ce qui est lancé par un utilisateur
- L'espace noyau : l'ensemble des composants internes du système d'exploitation (les drivers, le noyau, les modules...)
- Le matériel : les périphériques, la mémoire, le CPU...

Les différents univers

UserSpace et KernelSpace

Les différents univers

UserSpace
Terminal / Window Manager
Systemd / Init
Code utilisateur
Librairie GNU C (libc)

Les différents univers

UserSpace
Terminal / Window Manager
Systemd / Init
Code utilisateur
Librairie GNU C (libc)

KernelSpace
Appels systèmes (syscall)
Services noyaux
Modules et drivers noyaux

L'espace utilisateur accède aux fonctionnalités du noyau exclusivement via les appels systèmes (syscall).

Les différents univers

UserSpace
Terminal / Window Manager
Systemd / Init
Code utilisateur
Librairie GNU C (libc)

KernelSpace
Appels systèmes (syscall)
Services noyaux
Modules et drivers noyaux

Hardware
CPU
Mémoire
Périphériques

Via ses drivers, le noyau accède au matériel et les présente à l'espace utilisateur.

Ce que couvre ce cours

- Appréhender la construction d'un fichier binaire et comprendre les mécanismes en jeux lors de son exécution.

Ce que couvre ce cours

- Appréhender la construction d'un fichier binaire et comprendre les mécanismes en jeux lors de son exécution.
- Explorer les principaux outils disponibles permettant d'approcher le debugging des processus en espace utilisateur.

Ce que couvre ce cours

- Appréhender la construction d'un fichier binaire et comprendre les mécanismes en jeux lors de son exécution.
- Explorer les principaux outils disponibles permettant d'approcher le debugging des processus en espace utilisateur.
- S'initier à la mise en place de système de debugging en espace noyau.

Sommaire

1 Debugger

2 Les instructions
- Introduction
- La compilation
- L'exécution

3 Processus utilisateur

4 Noyau

5 Questions

Introduction

Et si on commençait doucement ?

Avant tout, nous avons besoin de comprendre un minimum d'instructions Assembleur x86 !

Introduction

Et si on commençait doucement ?

Introduction
Et si on commençait doucement ?

Les registres

%rax, %rbx, %rcx, %rdx, %rdi, %rsi, %r[8-15]

- **%rax** : Accumulateur, sert à effectuer des calculs arithmétiques ou à envoyer un paramètre à une interruption.
- **%rbx** : Registre auxiliaire de base, sert à effectuer des calculs arithmétiques ou bien des calculs sur les adresses.
- **%rcx** Registre auxiliaire (compteur), sert généralement comme compteur dans des boucles.
- **%rdx** Registre auxiliaire de données, sert à stocker des données destinées à des fonctions.
- **%rdi** Registre contenant un index de destination : utilisée comme adresse source pour les copies de données
- **%rsi** Registre contenant un index de source : utilisé comme adresse source pour les copies de données
- **%r[8-15]** Registres complémentaires

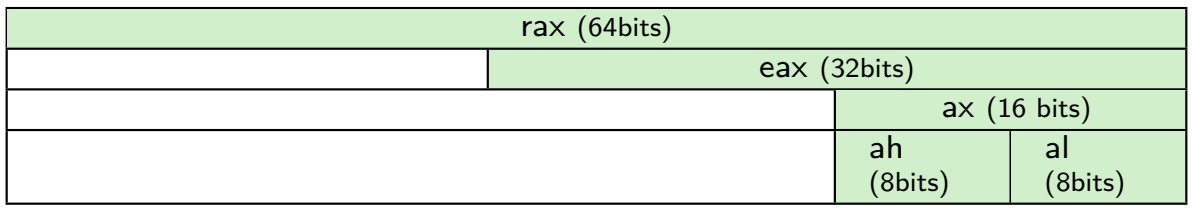

Introduction
Et si on commençait doucement ?

Les instructions

mov

mov *src*, *dest*

- copie la source (*src*) vers la destination (*dest*)
- l'instruction peut-être suffixée par *(q,l,w,s,b)* et correspond au nombre de bits à copier (*ex : l - long (4 octets)*)

syscall

syscall

- Instruction d'exécution d'une interruption logicielle.

Les instructions
Des sources au fichier binaire

Use the source Luke.

```
$ vim add.c
```

Le code source - langage C

```
void main(void){
        exit(2);
}
```

```
$ vim add.s
```

Le code source - Assembleur x86_64

```
.text
.globl _start

_start:
        mov $60, %rax
        mov $2, %rdi
        syscall
```

Plus d'informations sur l'interface avec les appels systèmes et Linux en assembleur :
https://en.wikibooks.org/wiki/X86_Assembly/Interfacing_with_Linux

Les instructions

Des sources au fichier binaire

Use the source Luke.

```
$ vim add.c
```

Le code source - langage C

```
void main(void){
        exit(2);
}
```

- main : fonction principale du programme
- exit : appel système

```
$ vim add.s
```

Le code source - Assembleur x86_64

```
.text
.globl _start

_start:
        mov $60, %rax
        mov $2, %rdi
        syscall
```

Plus d'informations sur l'interface avec les appels systèmes et Linux en assembleur :
https://en.wikibooks.org/wiki/X86_Assembly/Interfacing_with_Linux

Les instructions
Des sources au fichier binaire

Use the source Luke.

```
$ vim add.c
```

Le code source - langage C

```
void main(void){
        exit(2);
}
```

```
$ vim add.s
```

Le code source - Assembleur x86_64

```
.text
.globl _start

_start:
        mov $60, %rax
        mov $2, %rdi
        syscall
```

- mov $60, rax : numéro de l'appel système
- mov $2, rdi : paramètre de l'appel système
- syscall : appel système

Plus d'informations sur l'interface avec les appels systèmes et Linux en assembleur :
https://en.wikibooks.org/wiki/X86_Assembly/Interfacing_with_Linux

Les instructions
Des sources au fichier binaire

Use the source Luke.

```
$ vim add.c
```

Le code source - langage C

```
void main(void){
        exit(2);
}
```

```
$ vim add.s
```

Le code source - Assembleur x86_32

```
.text
.globl _start

_start:
        movl $1, %eax
        movl $2, %ebx
        int $0x80
```

- mov $1, eax : numéro de l'appel système
- mov $2, ebx : paramètre de l'appel système
- int $0x80 : appel système

Plus d'informations sur l'interface avec les appels systèmes et Linux en assembleur :
`https://en.wikibooks.org/wiki/X86_Assembly/Interfacing_with_Linux`

Les instructions

Des sources au fichier binaire

Le compilateur se charge de transformer le code source en code objet binaire.

```
$ as add.s -o add.o
```

Le code machine binaire - Compilateur (gcc, as)

```
add.o:     file format elf64-x86-64

Sections:
Idx Name          Size      VMA               LMA               File off  Algn
  0 .text         00000010  0000000000000000  0000000000000000  00000040  2**0
                  CONTENTS, ALLOC, LOAD, READONLY, CODE
  1 .data         00000000  0000000000000000  0000000000000000  00000050  2**0
                  CONTENTS, ALLOC, LOAD, DATA
  2 .bss          00000000  0000000000000000  0000000000000000  00000050  2**0
                  ALLOC
Contents of section .text:
 0000 48c7c03c 00000048 c7c70200 00000f05  H..<...H........

Disassembly of section .text:

0000000000000000 <.text>:
   0:   48 c7 c0 3c 00 00 00          mov    $0x3c,%rax
   7:   48 c7 c7 02 00 00 00          mov    $0x2,%rdi
   e:   0f 05                         syscall
```

Les instructions

Des sources au fichier binaire

Le linker se charge de transformer l'objet binaire obtenu en code exécutable.

```
$ ld add.o -o add
```

L'exécutable - Linker (ld)

```
add:     file format elf64-x86-64

Sections:
Idx Name          Size      VMA               LMA               File off  Algn
  0 .text         00000010  0000000000400078  0000000000400078  00000078  2**0
                  CONTENTS, ALLOC, LOAD, READONLY, CODE
Contents of section .text:
 400078 48c7c03c 00000048 c7c70200 00000f05  H..<...H........

Disassembly of section .text:

0000000000400078 <.text>:
  400078:       48 c7 c0 3c 00 00 00          mov    $0x3c,%rax
  40007f:       48 c7 c7 02 00 00 00          mov    $0x2,%rdi
  400086:       0f 05                         syscall
```

Les instructions

Des sources au fichier binaire

Définition

Une instruction est simplement un ensemble d'octets transmis au processeur.

Les instructions
Des sources au fichier binaire

Définition

Une instruction est simplement un ensemble d'octets transmis au processeur.

Instruction x86_64 (big indian)

```
add:     file format elf64-x86-64

Sections:
Idx Name          Size      VMA               LMA               File off  Algn
  0 .text         00000010  0000000000400078  0000000000400078  00000078  2**0
                  CONTENTS, ALLOC, LOAD, READONLY, CODE
Contents of section .text:
 400078 48c7c03c 00000048 c7c70200 00000f05  H..<...H........

Disassembly of section .text:

0000000000400078 <.text>:
  400078:       48 c7 c0 3c 00 00 00          mov    $0x3c,%rax
  40007f:       48 c7 c7 02 00 00 00          mov    $0x2,%rdi
  400086:       0f 05                         syscall
```

Les instructions

Des sources au fichier binaire

Définition

Une instruction est simplement un ensemble d'octets transmis au processeur.

Instructions ARM (little indian)

```
add.arm:     file format elf32-littlearm

Sections:
Idx Name          Size      VMA       LMA       File off  Algn
  0 .text         00000010  00008054  00008054  00000054  2**2
                  CONTENTS, ALLOC, LOAD, READONLY, CODE
  1 .ARM.attributes 00000014  00000000  00000000  00000064  2**0
                  CONTENTS, READONLY
Contents of section .text:
 8054 0200a0e3 0170a0e3 04002de5 000000ef  .....p....-.....
Contents of section .ARM.attributes:
 0000 41130000 00616561 62690001 09000000  A....aeabi......
 0010 06010801                             ....

Disassembly of section .text:

00008054 <_start>:
    8054:       e3a00002        mov     r0, #2
    8058:       e3a07001        mov     r7, #1
    805c:       e52d0004        push    {r0}            ; (str r0, [sp, #-4]!)
    8060:       ef000000        svc     0x00000000
```

Les instructions
Des sources au fichier binaire

Définition

Une instruction est simplement un ensemble d'octets transmis au processeur.

Lecture du fichier binaire

- `$ objdump -dsh add.o`
- `$ xxd add.o`

Les instructions

Des sources au fichier binaire

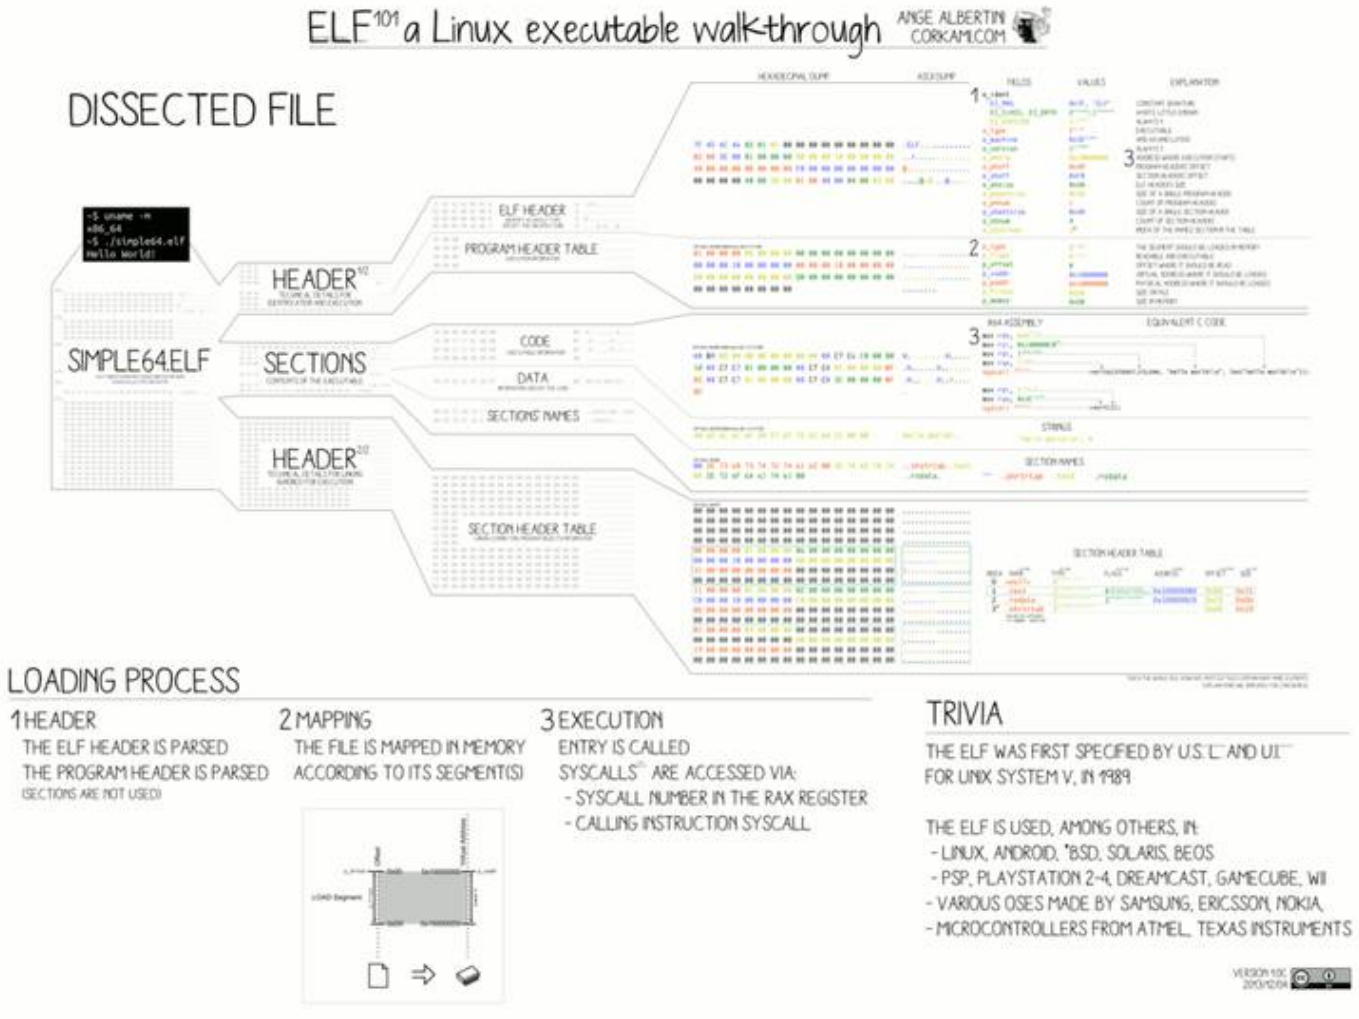

https://imgur.com/a/JEObT

L'exécution

Mise en place en mémoire

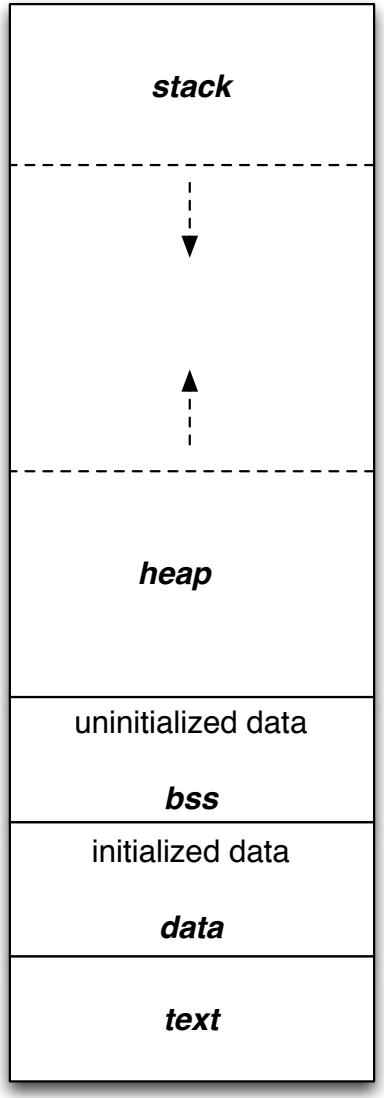

L'exécution
Mise en place en mémoire

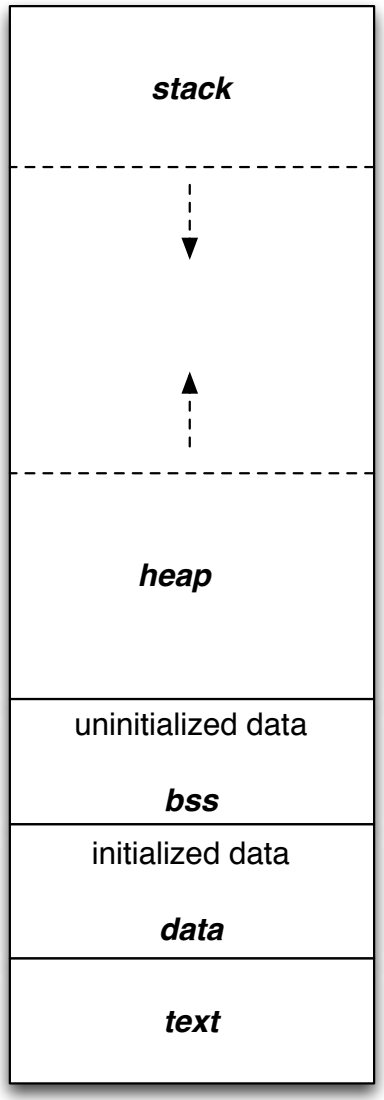

text (fixé à la compilation)

Appelée aussi *code section* : ensemble du code exécutable.

L'exécution
Mise en place en mémoire

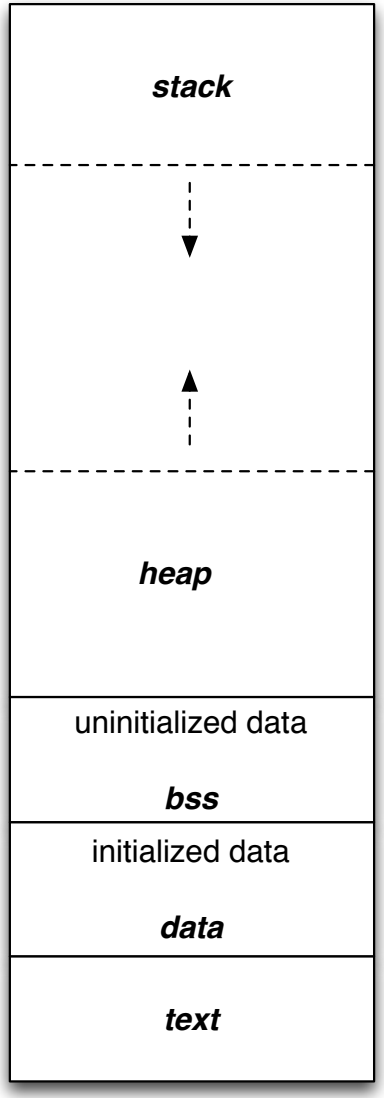

data (fixé à la compilation)

Variables globales initialisées du code.

text (fixé à la compilation)

Appelée aussi *code section* : ensemble du code exécutable.

L'exécution
Mise en place en mémoire

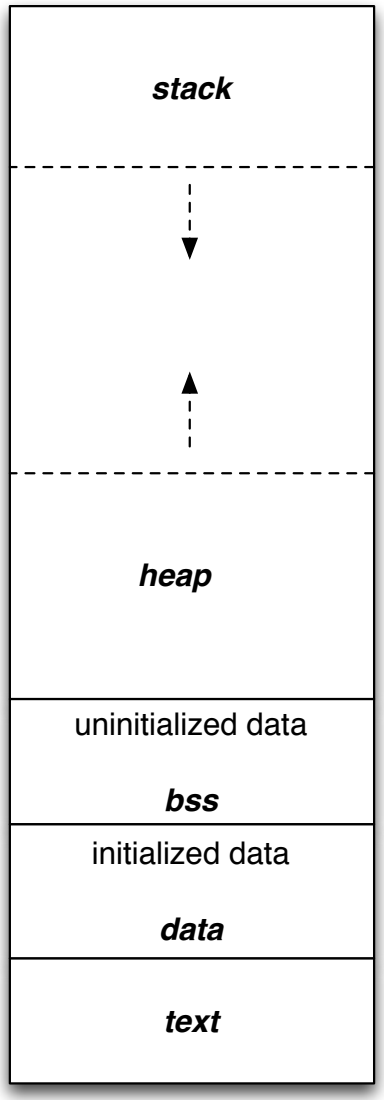

bss (fixé à la compilation)

Block Started by Symbol : Variables globales non initialisées du code.

data (fixé à la compilation)

Variables globales initialisées du code.

text (fixé à la compilation)

Appelée aussi *code section* : ensemble du code exécutable.

L'exécution
Mise en place en mémoire

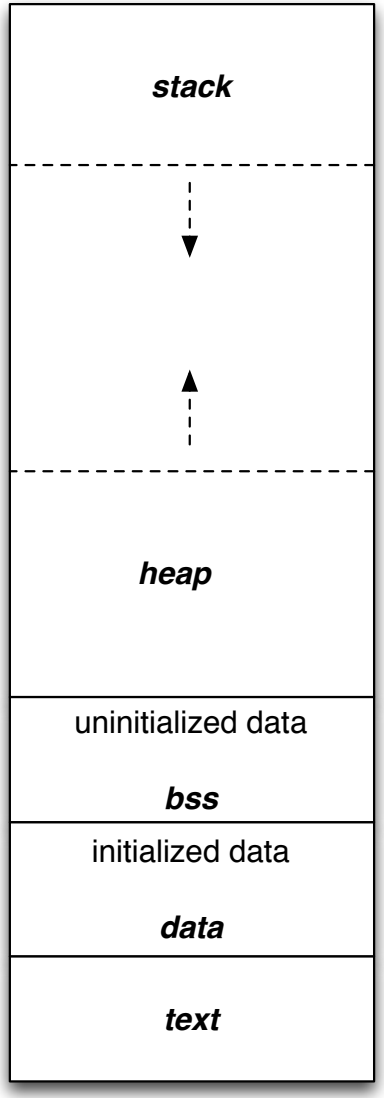

heap (allouée à l'exécution)

Le *tas* : section mémoire utilisée pour allouer les variables dynamiques.

bss (fixé à la compilation)

Block Started by Symbol : Variables globales non initialisées du code.

data (fixé à la compilation)

Variables globales initialisées du code.

text (fixé à la compilation)

Appelée aussi *code section* : ensemble du code exécutable.

L'exécution

Mise en place en mémoire

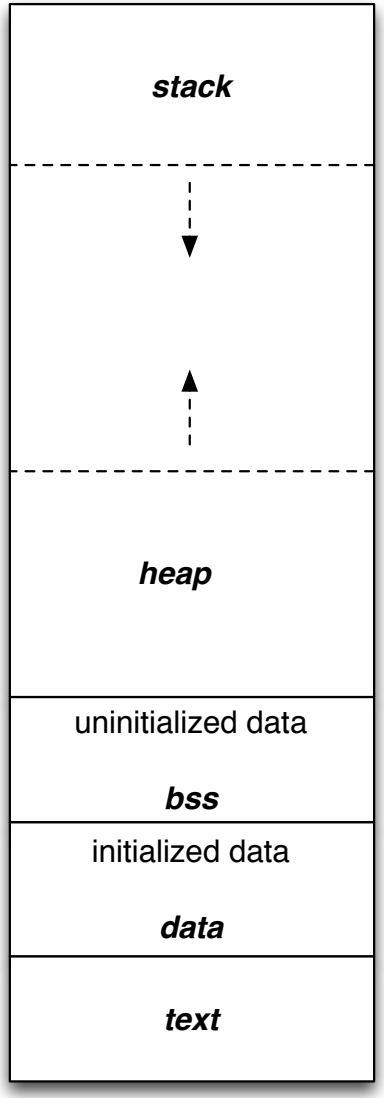

stack (allouée à l'exécution)

La *pile* contient la pile d'appel des fonctions, leur variables locales et les adresses de fonctions externes.

heap (allouée à l'exécution)

Le *tas* : section mémoire utilisée pour allouer les variables dynamiques.

bss (fixé à la compilation)

Block Started by Symbol : Variables globales non initialisées du code.

data (fixé à la compilation)

Variables globales initialisées du code.

text (fixé à la compilation)

Appelée aussi *code section* : ensemble du code exécutable.

L'exécution
Le déplacement dans la pile

À partir de ce moment nous avons un exécutable avec son code qui est monté en mémoire à l'exécution.
C'est sur la pile que va se jouer l'exécution des différentes fonctions ainsi que le passage de leurs paramètres et de leurs valeurs de retour.

Les registres

%rbp

Base Pointer : Adresse de base d'appel de la fonction

%rsp

Stack Pointer : Adresse courante de la pile (*stack*)

%rip

Instruction Pointer : Adresse de la prochaine instruction

L'exécution
Le déplacement dans la pile

À partir de ce moment nous avons un exécutable avec son code qui est monté en mémoire à l'exécution.
C'est sur la pile que va se jouer l'exécution des différentes fonctions ainsi que le passage de leurs paramètres et de leurs valeurs de retour.

Les instructions

push

Pousse sur la *stack* le contenu du registre en paramètre.

pop

Récupère la dernière valeur de la *stack* et place son contenu dans le registre passé en paramètre.

L'exécution

Le déplacement dans la pile

À partir de ce moment nous avons un exécutable avec son code qui est monté en mémoire à l'exécution.
C'est sur la pile que va se jouer l'exécution des différentes fonctions ainsi que le passage de leurs paramètres et de leurs valeurs de retour.

Les instructions

call

Instruction d'appel de fonction. Elle procède en 2 étapes :

- Sauvegarde de %rip sur la stack
- Déplacement de %rip à l'adresse demandée

ret

Instruction de retour de fonction. Restauration de %rip sur la stack

Attention, on s'accroche !

L'exécution

Exemple d'exécution dans la stack (pile)

On entre dans la fonction main, %rbp est sauvegardé

%rsp	Stack
→0xf0	0xff (%rbp)
0xe0	
0xd0	
0xc0	
0xb0	
0xa0	

%rip	Assembleur - section text
→ 0x01	push %rbp
0x02	mov %rsp,%rbp
0x05	callq 0x12 <test>
0x09	mov $0x0,%eax
0x0d	retq
0x12	push %rbp
0x13	mov %rsp,%rbp
0x1f	callq 0x26 <in_test>
0x24	pop %rbp
0x25	retq
0x26	push %rbp
0x27	mov %rsp,%rbp
0x2a	nop
0x2b	pop %rbp
0x2c	retq

	Code C

→	void main(void){
	test();
	}

	void test(void){
	return in_test();
	}

	void in_test(void){
	return;
	}

L'exécution

Exemple d'exécution dans la stack (pile)

On place l'adresse de base de la stack à sa nouvelle valeur

%rsp	Stack
0xf0	0xff (%rbp)
0xe0	
0xd0	
0xc0	
0xb0	
0xa0	

	%rip	Assembleur - section text
	0x01	push %rbp
→	0x02	mov %rsp,%rbp
	0x05	callq 0x12 <test>
	0x09	mov $0x0,%eax
	0x0d	retq
	0x12	push %rbp
	0x13	mov %rsp,%rbp
	0x1f	callq 0x26 <in_test>
	0x24	pop %rbp
	0x25	retq
	0x26	push %rbp
	0x27	mov %rsp,%rbp
	0x2a	nop
	0x2b	pop %rbp
	0x2c	retq

	Code C

→	void main(void){
	  test();
	}

	void test(void){
	  return in_test();
	}

	void in_test(void){
	  return;
	}

L'exécution

Exemple d'exécution dans la stack (pile)

Appel de la fonction test, %rip est poussé sur la stack et %rip prend la nouvelle valeur de la fonction *test*

%rsp	Stack
0xf0	0xff (%rbp)
→0xe0	0x09 (main)
0xd0	
0xc0	
0xb0	
0xa0	

	%rip	Assembleur - section text
	0x01	push %rbp
	0x02	mov %rsp,%rbp
→	**0x05**	callq 0x12 <test>
	0x09	mov $0x0,%eax
	0x0d	retq
	0x12	push %rbp
	0x13	mov %rsp,%rbp
	0x1f	callq 0x26 <in_test>
	0x24	pop %rbp
	0x25	retq
	0x26	push %rbp
	0x27	mov %rsp,%rbp
	0x2a	nop
	0x2b	pop %rbp
	0x2c	retq

	Code C
	void main(void){
→	test() ;
	}
	void test(void){
	return in_test() ;
	}
	void in_test(void){
	return ;
	}

L'exécution

Exemple d'exécution dans la stack (pile)

Entrée dans la fonction test, et même principe que pour la fonction main

%rsp	Stack
0xf0	0xff (%rbp)
0xe0	0x09 (main)
→0xd0	0xe0 (%rbp)
0xc0	
0xb0	
0xa0	

%rip	Assembleur - section text
0x01	push %rbp
0x02	mov %rsp,%rbp
0x05	callq 0x12 <test>
0x09	mov $0x0,%eax
0x0d	retq
→ 0x12	push %rbp
0x13	mov %rsp,%rbp
0x1f	callq 0x26 <in_test>
0x24	pop %rbp
0x25	retq
0x26	push %rbp
0x27	mov %rsp,%rbp
0x2a	nop
0x2b	pop %rbp
0x2c	retq

	Code C
	void main(void){
→	test() ;
	}
→	void test(void){
	return in_test() ;
	}
	void in_test(void){
	return ;
	}

L'exécution

Exemple d'exécution dans la stack (pile)

Entrée dans la fonction test, et même principe que pour la fonction main

%rsp	Stack
0xf0	0xff (%rbp)
0xe0	0x09 (main)
0xd0	0xe0 (%rbp)
0xc0	
0xb0	
0xa0	

	%rip	Assembleur - section text
	0x01	push %rbp
	0x02	mov %rsp,%rbp
	0x05	callq 0x12 <test>
	0x09	mov $0x0,%eax
	0x0d	retq
	0x12	push %rbp
→	0x13	mov %rsp,%rbp
	0x1f	callq 0x26 <in_test>
	0x24	pop %rbp
	0x25	retq
	0x26	push %rbp
	0x27	mov %rsp,%rbp
	0x2a	nop
	0x2b	pop %rbp
	0x2c	retq

	Code C
	void main(void){
→	test() ;
	}
→	void test(void){
	return in_test() ;
	}
	void in_test(void){
	return ;
	}

L'exécution

Exemple d'exécution dans la stack (pile)

Appel de la fonction in_test, même manipulation sur %rip

%rsp	Stack
0xf0	0xff (%rbp)
0xe0	0x09 (main)
0xd0	0xe0 (%rbp)
→0xc0	0x24 (test)
0xb0	
0xa0	

%rip	Assembleur - section text
0x01	push %rbp
0x02	mov %rsp,%rbp
0x05	callq 0x12 <test>
0x09	mov $0x0,%eax
0x0d	retq
0x12	push %rbp
0x13	mov %rsp,%rbp
→ 0x1f	callq 0x26 <in_test>
0x24	pop %rbp
0x25	retq
0x26	push %rbp
0x27	mov %rsp,%rbp
0x2a	nop
0x2b	pop %rbp
0x2c	retq

	Code C
	void main(void){
→	test() ;
	}
	void test(void){
→	return in_test() ;
	}
	void in_test(void){
	return ;
	}

L'exécution

Exemple d'exécution dans la stack (pile)

Entrée dans la fonction in_test

%rsp	Stack
0xf0	0xff (%rbp)
0xe0	0x09 (main)
0xd0	0xe0 (%rbp)
0xc0	0x24 (test)
→**0xb0**	0xc0 (%rbp)
0xa0	

%rip	Assembleur - section text
0x01	push %rbp
0x02	mov %rsp,%rbp
0x05	callq 0x12 <test>
0x09	mov $0x0,%eax
0x0d	retq
0x12	push %rbp
0x13	mov %rsp,%rbp
0x1f	callq 0x26 <in_test>
0x24	pop %rbp
0x25	retq
→ **0x26**	push %rbp
0x27	mov %rsp,%rbp
0x2a	nop
0x2b	pop %rbp
0x2c	retq

	Code C
	void main(void){
→	test() ;
	}
	void test(void){
→	return in_test() ;
	}
→	void in_test(void){
	return ;
	}

L'exécution

Exemple d'exécution dans la stack (pile)

Entrée dans la fonction in_test

%rsp	Stack
0xf0	0xff (%rbp)
0xe0	0x09 (main)
0xd0	0xe0 (%rbp)
0xc0	0x24 (test)
0xb0	0xc0 (%rbp)
0xa0	

	%rip	Assembleur - section text
	0x01	push %rbp
	0x02	mov %rsp,%rbp
	0x05	callq 0x12 <test>
	0x09	mov $0x0,%eax
	0x0d	retq
	0x12	push %rbp
	0x13	mov %rsp,%rbp
	0x1f	callq 0x26 <in_test>
	0x24	pop %rbp
	0x25	retq
	0x26	push %rbp
→	**0x27**	mov %rsp,%rbp
	0x2a	nop
	0x2b	pop %rbp
	0x2c	retq

	Code C
	void main(void){
→	test() ;
	}
	void test(void){
→	return in_test() ;
	}
→	void in_test(void){
	return ;
	}

L'exécution

Exemple d'exécution dans la stack (pile)

Entrée dans la fonction in_test

%rsp	Stack
0xf0	0xff (%rbp)
0xe0	0x09 (main)
0xd0	0xe0 (%rbp)
0xc0	0x24 (test)
0xb0	0xc0 (%rbp)
0xa0	

%rip	Assembleur - section text
0x01	push %rbp
0x02	mov %rsp,%rbp
0x05	callq 0x12 <test>
0x09	mov $0x0,%eax
0x0d	retq
0x12	push %rbp
0x13	mov %rsp,%rbp
0x1f	callq 0x26 <in_test>
0x24	pop %rbp
0x25	retq
0x26	push %rbp
0x27	mov %rsp,%rbp
→ **0x2a**	nop
0x2b	pop %rbp
0x2c	retq

	Code C
	void main(void){
→	test() ;
	}
	void test(void){
→	return in_test() ;
	}
	void in_test(void){
→	return ;
	}

L'exécution

Exemple d'exécution dans la stack (pile)

Retour de la fonction, %rbp est restauré et retq restaure %rip

%rsp	Stack
0xf0	0xff (%rbp)
0xe0	0x09 (main)
0xd0	0xe0 (%rbp)
0xc0	0x24 (test)
0xb0	
0xa0	

%rip	Assembleur - section text
0x01	push %rbp
0x02	mov %rsp,%rbp
0x05	callq 0x12 <test>
0x09	mov $0x0,%eax
0x0d	retq
0x12	push %rbp
0x13	mov %rsp,%rbp
0x1f	callq 0x26 <in_test>
0x24	pop %rbp
0x25	retq
0x26	push %rbp
0x27	mov %rsp,%rbp
0x2a	nop
→0x2b	pop %rbp
0x2c	retq

	Code C
	void main(void){
→	test() ;
	}
	void test(void){
→	return in_test() ;
	}
	void in_test(void){
→	return ;
	}

L'exécution

Exemple d'exécution dans la stack (pile)

Retour de la fonction, %rbp est restauré et retq restaure %rip

%rsp	Stack
0xf0	0xff (%rbp)
0xe0	0x09 (main)
0xd0	0xe0 (%rbp)
0xc0	
0xb0	
0xa0	

%rip	Assembleur - section text
0x01	push %rbp
0x02	mov %rsp,%rbp
0x05	callq 0x12 <test>
0x09	mov $0x0,%eax
0x0d	retq
0x12	push %rbp
0x13	mov %rsp,%rbp
0x1f	callq 0x26 <in_test>
0x24	pop %rbp
0x25	retq
0x26	push %rbp
0x27	mov %rsp,%rbp
0x2a	nop
0x2b	pop %rbp
→0x2c	retq

	Code C
	void main(void){
→	test() ;
	}
	void test(void){
→	return in_test() ;
	}
	void in_test(void){
→	return ;
	}

L'exécution

Exemple d'exécution dans la stack (pile)

Retour de la fonction, %rbp est restauré et retq restaure %rip

%rsp	Stack
0xf0	0xff (%rbp)
0xe0	0x09 (main)
0xd0	
0xc0	
0xb0	
0xa0	

%rip	Assembleur - section text
0x01	push %rbp
0x02	mov %rsp,%rbp
0x05	callq 0x12 <test>
0x09	mov $0x0,%eax
0x0d	retq
0x12	push %rbp
0x13	mov %rsp,%rbp
0x1f	callq 0x26 <in_test>
→0x24	pop %rbp
0x25	retq
0x26	push %rbp
0x27	mov %rsp,%rbp
0x2a	nop
0x2b	pop %rbp
0x2c	retq

	Code C
	void main(void){
→	test() ;
	}
	void test(void){
→	return in_test() ;
	}
	void in_test(void){
	return ;
	}

L'exécution

Exemple d'exécution dans la stack (pile)

Retour de la fonction, %rbp est restauré et retq restaure %rip

%rsp	Stack
0xf0	0xff (%rbp)
0xe0	
0xd0	
0xc0	
0xb0	
0xa0	

%rip	Assembleur - section text
0x01	push %rbp
0x02	mov %rsp,%rbp
0x05	callq 0x12 <test>
0x09	mov $0x0,%eax
0x0d	retq
0x12	push %rbp
0x13	mov %rsp,%rbp
0x1f	callq 0x26 <in_test>
0x24	pop %rbp
→0x25	retq
0x26	push %rbp
0x27	mov %rsp,%rbp
0x2a	nop
0x2b	pop %rbp
0x2c	retq

	Code C
	void main(void){
→	test() ;
	}
	void test(void){
	return in_test() ;
	}
	void in_test(void){
	return ;
	}

L'exécution

Exemple d'exécution dans la stack (pile)

Retour de la fonction, %rbp est restauré et retq restaure %rip

%rsp	Stack
0xf0	0xff (%rbp)
0xe0	
0xd0	
0xc0	
0xb0	
0xa0	

%rip	Assembleur - section text
0x01	push %rbp
0x02	mov %rsp,%rbp
0x05	callq 0x12 <test>
→0x09	mov $0x0,%eax
0x0d	retq
0x12	push %rbp
0x13	mov %rsp,%rbp
0x1f	callq 0x26 <in_test>
0x24	pop %rbp
0x25	retq
0x26	push %rbp
0x27	mov %rsp,%rbp
0x2a	nop
0x2b	pop %rbp
0x2c	retq

	Code C
	void main(void){
	test() ;
→	}
	void test(void){
	return in_test() ;
	}
	void in_test(void){
	return ;
	}

L'exécution

Exemple d'exécution dans la stack (pile)

Retour de la fonction, %rbp est restauré et retq restaure %rip

%rsp	Stack
0xf0	0xff (%rbp)
0xe0	
0xd0	
0xc0	
0xb0	
0xa0	

%rip	Assembleur - section text
0x01	push %rbp
0x02	mov %rsp,%rbp
0x05	callq 0x12 <test>
0x09	mov $0x0,%eax
→**0x0d**	retq
0x12	push %rbp
0x13	mov %rsp,%rbp
0x1f	callq 0x26 <in_test>
0x24	pop %rbp
0x25	retq
0x26	push %rbp
0x27	mov %rsp,%rbp
0x2a	nop
0x2b	pop %rbp
0x2c	retq

	Code C
	void main(void){
	test() ;
→	}
	void test(void){
	return in_test() ;
	}
	void in_test(void){
	return ;
	}

Sommaire

1. Debugger
2. Les instructions
3. Processus utilisateur
   - ps, top...
   - strace, ltrace
   - Les sources
   - gdb
4. Noyau
5. Questions

ps, top...

Les deux outils ps et top permettent de consulter la structure mémoire d'un processus (*task_struct*).

ps, top...

On consulte la consommation CPU et mémoire de chaque processus, ainsi que l'état dans lequel il se trouve (en cours d'exécution, stoppé, bloqué, zombie...).

- ps
  - permet d'observer un ou plusieurs processus à un instant T
  - système de filtrage par utilisateur, PID ...
- top
  - Visualisation en continue des processus les plus actifs du système
  - Consultation unifiée de l'uptime de la machine et de l'utilisation de processeurs

Ces deux outils permettent de consulter la santé du sytème d'exploitation.

Exemple de sortie avec la commande ps

ps aux f

```
USER        PID %CPU %MEM    VSZ   RSS TTY      STAT START   TIME COMMAND
root          2  0.0  0.0      0     0 ?        S    Oct19   0:00 [kthreadd]
root          3  0.0  0.0      0     0 ?        S    Oct19   0:05  \_ [ksoftirqd/0]
root          5  0.0  0.0      0     0 ?        S<   Oct19   0:00  \_ [kworker/0:0H]
root          7  0.0  0.0      0     0 ?        S    Oct19   4:58  \_ [rcu_sched]
root          8  0.0  0.0      0     0 ?        S    Oct19   0:00  \_ [rcu_bh]
root          9  0.0  0.0      0     0 ?        S    Oct19   0:01  \_ [migration/0]
root         10  0.0  0.0      0     0 ?        S    Oct19   0:00  \_ [watchdog/0]
root         11  0.0  0.0      0     0 ?        S    Oct19   0:00  \_ [watchdog/1]
root         12  0.0  0.0      0     0 ?        S    Oct19   0:01  \_ [migration/1]
root         13  0.0  0.0      0     0 ?        S    Oct19   0:02  \_ [ksoftirqd/1]
root         15  0.0  0.0      0     0 ?        S<   Oct19   0:00  \_ [kworker/1:0H]
root         16  0.0  0.0      0     0 ?        S    Oct19   0:00  \_ [watchdog/2]
root         17  0.0  0.0      0     0 ?        S    Oct19   0:01  \_ [migration/2]
root         18  0.0  0.0      0     0 ?        S    Oct19   0:02  \_ [ksoftirqd/2]
```

Les différents champs (*ps aux f*)

- PID : Id du processus
- %CPU : Pourcentage d'occupation CPU
- %MEM : Pourcentage d'occupation Mémoire
- VSZ : Mémoire virtuellement utilisable
- RSS : Mémoire réellement utilisée
- TTY : Terminal attaché au processus
- STAT : Status du processus
- START : Date de début du processus
- TIME : Temps système consommé
- COMMAND : Ligne de commande du processus

Exemple de sortie avec la commande ps

ps aux f

```
USER        PID %CPU %MEM    VSZ   RSS TTY      STAT START   TIME COMMAND
root          2  0.0  0.0      0     0 ?        S    Oct19   0:00 [kthreadd]
root          3  0.0  0.0      0     0 ?        S    Oct19   0:05  \_ [ksoftirqd/0]
root          5  0.0  0.0      0     0 ?        S<   Oct19   0:00  \_ [kworker/0:0H]
root          7  0.0  0.0      0     0 ?        S    Oct19   4:58  \_ [rcu_sched]
root          8  0.0  0.0      0     0 ?        S    Oct19   0:00  \_ [rcu_bh]
root          9  0.0  0.0      0     0 ?        S    Oct19   0:01  \_ [migration/0]
root         10  0.0  0.0      0     0 ?        S    Oct19   0:00  \_ [watchdog/0]
root         11  0.0  0.0      0     0 ?        S    Oct19   0:00  \_ [watchdog/1]
root         12  0.0  0.0      0     0 ?        S    Oct19   0:01  \_ [migration/1]
root         13  0.0  0.0      0     0 ?        S    Oct19   0:02  \_ [ksoftirqd/1]
root         15  0.0  0.0      0     0 ?        S<   Oct19   0:00  \_ [kworker/1:0H]
root         16  0.0  0.0      0     0 ?        S    Oct19   0:00  \_ [watchdog/2]
root         17  0.0  0.0      0     0 ?        S    Oct19   0:01  \_ [migration/2]
root         18  0.0  0.0      0     0 ?        S    Oct19   0:02  \_ [ksoftirqd/2]
```

Ensemble des processus noyaux

Exemple de sortie avec la commande ps

ps aux f

```
USER        PID %CPU %MEM    VSZ   RSS TTY      STAT START   TIME COMMAND
root          2  0.0  0.0      0     0 ?        S    Oct19   0:00 [kthreadd]
root          3  0.0  0.0      0     0 ?        S    Oct19   0:05  \_ [ksoftirqd/0]
root          5  0.0  0.0      0     0 ?        S<   Oct19   0:00  \_ [kworker/0:0H]
root          7  0.0  0.0      0     0 ?        S    Oct19   4:58  \_ [rcu_sched]
root          8  0.0  0.0      0     0 ?        S    Oct19   0:00  \_ [rcu_bh]
root          9  0.0  0.0      0     0 ?        S    Oct19   0:01  \_ [migration/0]
root         10  0.0  0.0      0     0 ?        S    Oct19   0:00  \_ [watchdog/0]
root         11  0.0  0.0      0     0 ?        S    Oct19   0:00  \_ [watchdog/1]
root         12  0.0  0.0      0     0 ?        S    Oct19   0:01  \_ [migration/1]
root         13  0.0  0.0      0     0 ?        S    Oct19   0:02  \_ [ksoftirqd/1]
root         15  0.0  0.0      0     0 ?        S<   Oct19   0:00  \_ [kworker/1:0H]
root         16  0.0  0.0      0     0 ?        S    Oct19   0:00  \_ [watchdog/2]
root         17  0.0  0.0      0     0 ?        S    Oct19   0:01  \_ [migration/2]
root         18  0.0  0.0      0     0 ?        S    Oct19   0:02  \_ [ksoftirqd/2]

root       1032  0.0  0.0 304632  2956 ?        Ssl  Oct19   0:06 /usr/lib/snapd/snapd
root       1036  0.0  0.0 274964  1332 ?        Ssl  Oct19   0:00 /usr/sbin/cups-browsed
root       1046  0.0  0.0  29028   532 ?        Ss   Oct19   0:00 /usr/sbin/cron -f
root       1048  0.0  0.0 276204   368 ?        Ssl  Oct19   0:03 /usr/lib/accountsservice/accounts-daemon
root       1050  0.0  0.0 166456   240 ?        Ssl  Oct19   0:11 /usr/sbin/thermald --no-daemon --dbus-enable
root       1054  0.0  0.0 337360   432 ?        Ssl  Oct19   0:00 /usr/sbin/ModemManager
root       1056  0.0  0.0 449528  2804 ?        Ssl  Oct19   0:00 /usr/sbin/NetworkManager --no-daemon
nobody     1316  0.0  0.0  52948     0 ?        S    Oct19   0:00  \_ /usr/sbin/dnsmasq --no-resolv --keep-in-foreground --no-ho
root      21637  0.0  0.0  16128    92 ?        S    Oct22   0:00  \_ /sbin/dhclient -d -q -sf /usr/lib/NetworkManager/nm-dhcp-h
root       1176  0.0  0.0 276816   372 ?        SLsl Oct19   0:00 /usr/sbin/lightdm
```

Suivis des processus utilisateurs

Exemple de sortie avec la commande top

top

```
top - 23:37:03 up 6 days,  1:54,  9 users,  load average: 0,29, 0,35, 0,26
Tâches: 260 total,   1 en cours, 258 en veille,   0 arrêté,   1 zombie
%Cpu0  :  1,7 ut,  0,7 sy,  0,0 ni, 97,7 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
top - 23:37:29 up 6 days,  1:54,  9 users,  load average: 0.27, 0.33, 0.26
Tasks: 260 total,   1 running, 258 sleeping,   0 stopped,   1 zombie
%Cpu0  :  3.4 us,  1.1 sy,  0.0 ni, 95.5 id,  0.0 wa,  0.0 hi,  0.0 si,  0.0 st
%Cpu1  :  0.0 us,  0.0 sy,  0.0 ni,100.0 id,  0.0 wa,  0.0 hi,  0.0 si,  0.0 st
%Cpu2  :  1.1 us,  0.0 sy,  0.0 ni, 98.9 id,  0.0 wa,  0.0 hi,  0.0 si,  0.0 st
%Cpu3  :  0.0 us,  1.1 sy,  0.0 ni, 98.9 id,  0.0 wa,  0.0 hi,  0.0 si,  0.0 st
KiB Mem :  5831144 total,   410448 free,  3567680 used,  1853016 buff/cache
KiB Swap:  6273020 total,  6043320 free,   229700 used.  1592284 avail Mem

  PID USER      PR  NI    VIRT    RES    SHR S  %CPU %MEM     TIME+ COMMAND
 1231 root      20   0  375884  86940  35752 S   4.5  1.5  56:16.89 Xorg
22000 rachel    20   0 2905836 538740 154532 S   2.2  9.2   4:02.72 firefox
 2345 mat       20   0  299152  42664   7084 S   1.1  0.7  82:23.29 awesome
 5597 mat       20   0   39028   3432   2796 R   1.1  0.1   0:00.01 top
22103 rachel    20   0 2593304 761204 138880 S   1.1 13.1   6:30.29 Web Content
    1 root      20   0  119904   4060   2388 S   0.0  0.1   0:03.34 systemd
    2 root      20   0       0      0      0 S   0.0  0.0   0:00.04 kthreadd
    3 root      20   0       0      0      0 S   0.0  0.0   0:05.30 ksoftirqd/0
    5 root       0 -20       0      0      0 S   0.0  0.0   0:00.00 kworker/0:0H
    7 root      20   0       0      0      0 S   0.0  0.0   5:00.94 rcu_sched
```

Les premières lignes donnent une vue synthétique de l'utilisation de la machine.

Sous le capot

Chacune de ces commandes vont parcourir */proc*, un pseudo filesystème dans lequel on peut trouver les informations de l'ensemble des processus de la machine.

procfs

```
$ cat /proc/self/stat
15933 (cat) R 10118 15933 10118 34820 15933 4194304 88 0 0 0 0 0 0 0 20 0 1 0 30568230 7647232 193 3121741824
↪  4194304 4240236 140732349587456 140732349586808 140640986640944 0 0 128 0 0 0 0 17 0 0 0 0 0 0 6340112 6341364
↪  36347904 140732349592700 140732349592720 140732349592720 140732349595631 0
```

D'autres informations sont également disponible dans *procfs* et sont lus par d'autre outils.

procfs

```
$ ls /proc/self/
attr       clear_refs       cpuset   fd       limits     mem         net        oom_score      projid_map
↪  sessionid  stat     task
autogroup  cmdline          cwd      fdinfo   loginuid   mountinfo   ns         oom_score_adj  root
↪  setgroups  statm    timers
auxv       comm             environ  gid_map  map_files  mounts      numa_maps  pagemap        sched       smaps
↪  status   uid_map
cgroup     coredump_filter  exe      io       maps       mountstats  oom_adj    personality    schedstat   stack
↪  syscall  wchan
```

strace

L'outil *strace* permet de voir l'ensemble des appels systèmes effectués par un processus. Les appels systèmes sont également appelés syscall et correspondent aux fonctions exposées par le noyau vers l'espace utilisateur.

Exemple d'utilisation de strace

```
# strace -e open,getdents ls
open("/etc/ld.so.cache", O_RDONLY|O_CLOEXEC) = 3
open("/lib/x86_64-linux-gnu/libselinux.so.1", O_RDONLY|O_CLOEXEC) = 3
open("/lib/x86_64-linux-gnu/libc.so.6", O_RDONLY|O_CLOEXEC) = 3
open("/lib/x86_64-linux-gnu/libpcre.so.3", O_RDONLY|O_CLOEXEC) = 3
open("/lib/x86_64-linux-gnu/libdl.so.2", O_RDONLY|O_CLOEXEC) = 3
open("/lib/x86_64-linux-gnu/libpthread.so.0", O_RDONLY|O_CLOEXEC) = 3
open("/proc/filesystems", O_RDONLY)     = 3
open("/usr/lib/locale/locale-archive", O_RDONLY|O_CLOEXEC) = 3
open(".", O_RDONLY|O_NONBLOCK|O_DIRECTORY|O_CLOEXEC) = 3
getdents(3, /* 2 entries */, 32768)     = 48
getdents(3, /* 0 entries */, 32768)     = 0
+++ exited with 0 +++
```

strace est utilisé pour comprendre comment un processus en espace utilisateur inter-agit avec le noyau via les appels systèmes.

strace

L'outil *strace* permet de voir l'ensemble des appels systèmes effectués par un processus. Les appels systèmes sont également appelés syscall et correspondent aux fonctions exposées par le noyau vers l'espace utilisateur.

Exemple d'utilisation de strace

```
# strace -e open,getdents ls
open("/etc/ld.so.cache", O_RDONLY|O_CLOEXEC) = 3
open("/lib/x86_64-linux-gnu/libselinux.so.1", O_RDONLY|O_CLOEXEC) = 3
open("/lib/x86_64-linux-gnu/libc.so.6", O_RDONLY|O_CLOEXEC) = 3
open("/lib/x86_64-linux-gnu/libpcre.so.3", O_RDONLY|O_CLOEXEC) = 3
open("/lib/x86_64-linux-gnu/libdl.so.2", O_RDONLY|O_CLOEXEC) = 3
open("/lib/x86_64-linux-gnu/libpthread.so.0", O_RDONLY|O_CLOEXEC) = 3
open("/proc/filesystems", O_RDONLY)     = 3
open("/usr/lib/locale/locale-archive", O_RDONLY|O_CLOEXEC) = 3
open(".", O_RDONLY|O_NONBLOCK|O_DIRECTORY|O_CLOEXEC) = 3
getdents(3, /* 2 entries */, 32768)     = 48
getdents(3, /* 0 entries */, 32768)     = 0
+++ exited with 0 +++
```

strace est utilisé pour comprendre comment un processus en espace utilisateur inter-agit avec le noyau via les appels systèmes.

syscall - int 0x80

strace les options intéressantes

Ne sélectionner que certains appels : -e

```
# strace -e open,getdents ls
open("/etc/ld.so.cache", O_RDONLY|O_CLOEXEC) = 3
open("/lib/x86_64-linux-gnu/libselinux.so.1", O_RDONLY|O_CLOEXEC) = 3
open("/lib/x86_64-linux-gnu/libc.so.6", O_RDONLY|O_CLOEXEC) = 3
open("/lib/x86_64-linux-gnu/libpcre.so.3", O_RDONLY|O_CLOEXEC) = 3
open("/lib/x86_64-linux-gnu/libdl.so.2", O_RDONLY|O_CLOEXEC) = 3
open("/lib/x86_64-linux-gnu/libpthread.so.0", O_RDONLY|O_CLOEXEC) = 3
open("/proc/filesystems", O_RDONLY)     = 3
open("/usr/lib/locale/locale-archive", O_RDONLY|O_CLOEXEC) = 3
open(".", O_RDONLY|O_NONBLOCK|O_DIRECTORY|O_CLOEXEC) = 3
getdents(3, /* 2 entries */, 32768)     = 48
getdents(3, /* 0 entries */, 32768)     = 0
+++ exited with 0 +++
```

strace les options intéressantes

Voir le temps passé dans chaque appel : -tt

```
22:42:17.942028 execve("/bin/ls", ["ls"], [/* 50 vars */]) = 0
22:42:17.942537 brk(NULL)               = 0xb60000
22:42:17.942644 access("/etc/ld.so.nohwcap", F_OK) = -1 ENOENT (No such file or directory)
22:42:17.942774 mmap(NULL, 8192, PROT_READ|PROT_WRITE, MAP_PRIVATE|MAP_ANONYMOUS, -1, 0) = 0x7f978836f000
22:42:17.942834 access("/etc/ld.so.preload", R_OK) = -1 ENOENT (No such file or directory)
22:42:17.942883 open("/etc/ld.so.cache", O_RDONLY|O_CLOEXEC) = 3
22:42:17.942928 fstat(3, {st_mode=S_IFREG|0644, st_size=251122, ...}) = 0
22:42:17.942969 mmap(NULL, 251122, PROT_READ, MAP_PRIVATE, 3, 0) = 0x7f9788331000
22:42:17.943007 close(3)                = 0
22:42:17.943045 access("/etc/ld.so.nohwcap", F_OK) = -1 ENOENT (No such file or directory)
22:42:17.943096 open("/lib/x86_64-linux-gnu/libselinux.so.1", O_RDONLY|O_CLOEXEC) = 3
22:42:17.943136 read(3, "\177ELF\2\1\1\0\0\0\0\0\0\0\0\0\3\0>\0\1\0\0\0\260Z\0\0\0\0\0\0"..., 832) = 832
22:42:17.943177 fstat(3, {st_mode=S_IFREG|0644, st_size=130224, ...}) = 0
22:42:17.943215 mmap(NULL, 2234080, PROT_READ|PROT_EXEC, MAP_PRIVATE|MAP_DENYWRITE, 3, 0) = 0x7f9787f2a000
22:42:17.943255 mprotect(0x7f9787f49000, 2093056, PROT_NONE) = 0
22:42:17.943297 mmap(0x7f9788148000, 8192, PROT_READ|PROT_WRITE, MAP_PRIVATE|MAP_FIXED|MAP_DENYWRITE, 3, 0x1e000) =
↪  0x7f9788148000
22:42:17.943346 mmap(0x7f978814a000, 5856, PROT_READ|PROT_WRITE, MAP_PRIVATE|MAP_FIXED|MAP_ANONYMOUS, -1, 0) =
↪  0x7f978814a000
22:42:17.943390 close(3)                = 0
22:42:17.943429 access("/etc/ld.so.nohwcap", F_OK) = -1 ENOENT (No such file or directory)
22:42:17.943473 open("/lib/x86_64-linux-gnu/libc.so.6", O_RDONLY|O_CLOEXEC) = 3
22:42:17.943513 read(3, "\177ELF\2\1\1\3\0\0\0\0\0\0\0\0\3\0>\0\1\0\0\0P\t\2\0\0\0\0\0"..., 832) = 832
22:42:17.943550 fstat(3, {st_mode=S_IFREG|0755, st_size=1868984, ...}) = 0
22:42:17.943588 mmap(NULL, 3971488, PROT_READ|PROT_EXEC, MAP_PRIVATE|MAP_DENYWRITE, 3, 0) = 0x7f9787b60000
22:42:17.943657 mprotect(0x7f9787d20000, 2097152, PROT_NONE) = 0
22:42:17.943707 mmap(0x7f9787f20000, 24576, PROT_READ|PROT_WRITE, MAP_PRIVATE|MAP_FIXED|MAP_DENYWRITE, 3, 0x1c0000)
↪  = 0x7f9787f20000
```

strace les options intéressantes

Voir le nombre d'appel utilisés : -c

% time	seconds	usecs/call	calls	errors	syscall
0.00	0.000000	0	7		read
0.00	0.000000	0	1		write
0.00	0.000000	0	8		open
0.00	0.000000	0	10		close
0.00	0.000000	0	9		fstat
0.00	0.000000	0	18		mmap
0.00	0.000000	0	12		mprotect
0.00	0.000000	0	1		munmap
0.00	0.000000	0	3		brk
0.00	0.000000	0	2		rt_sigaction
0.00	0.000000	0	1		rt_sigprocmask
0.00	0.000000	0	2		ioctl
0.00	0.000000	0	7	7	access
0.00	0.000000	0	1		execve
0.00	0.000000	0	2		getdents
0.00	0.000000	0	1		getrlimit
0.00	0.000000	0	2	2	statfs
0.00	0.000000	0	1		arch_prctl
0.00	0.000000	0	1		set_tid_address
0.00	0.000000	0	1		set_robust_list
100.00	0.000000		90	9	total

strace les options intéressantes

S'attacher à un processus existant : -p

```
strace: Process 26546 attached
epoll_wait(4, [{EPOLLIN, {u32=7, u64=4294967303}}], 64, 59743) = 1
recvmsg(7, {msg_name(0)=NULL,
↪  msg_iov(1)=[{"\34\0\327\255\240\4\0\0003\1\0\0`M\373\24\0\0\0\0\0\0\0\0\0\0\0\0\0\0\0\0", 4096}],
↪  msg_controllen=0, msg_flags=0}, 0) = 32
recvmsg(7, 0x7ffc1169d900, 0)           = -1 EAGAIN (Resource temporarily unavailable)
recvmsg(7, 0x7ffc1169d900, 0)           = -1 EAGAIN (Resource temporarily unavailable)
epoll_wait(4, [{EPOLLIN, {u32=7, u64=4294967303}}], 64, 59743) = 1
recvmsg(7, {msg_name(0)=NULL,
↪  msg_iov(1)=[{"\34\0\327\255\240\4\0\0004\1\0\0bM\373\24\0\0\0\0\0\0\0\0\0\0\0\0\0\0\0"..., 4096}],
↪  msg_controllen=0, msg_flags=0}, 0) = 160
recvmsg(7, 0x7ffc1169d900, 0)           = -1 EAGAIN (Resource temporarily unavailable)
recvmsg(7, 0x7ffc1169d7c0, 0)           = -1 EAGAIN (Resource temporarily unavailable)
recvmsg(7, 0x7ffc1169d7c0, 0)           = -1 EAGAIN (Resource temporarily unavailable)
poll([{fd=7, events=POLLIN|POLLOUT}], 1, -1) = 1 ([{fd=7, revents=POLLOUT}])
writev(7, [{"\f\32\7\0\24\0`\1\17\0`\1\0\0\0\0\20\0\0\0J\5\0\0\324\2\0\0\f\27\7\0"..., 56}, {NULL, 0}, {"", 0}], 3)
↪  = 56
recvmsg(7, {msg_name(0)=NULL,
↪  msg_iov(1)=[{"\26\0\330\255\24\0`\1\24\0`\1\16\0`\1\0\0\20\0J\5\324\2\0\0\0\0\0\0\0"..., 4096}],
↪  msg_controllen=0, msg_flags=0}, 0) = 64
recvmsg(7, 0x7ffc1169d900, 0)           = -1 EAGAIN (Resource temporarily unavailable)
recvmsg(7, 0x7ffc1169d7c0, 0)           = -1 EAGAIN (Resource temporarily unavailable)
recvmsg(7, 0x7ffc1169d7c0, 0)           = -1 EAGAIN (Resource temporarily unavailable)
poll([{fd=7, events=POLLIN|POLLOUT}], 1, -1) = 1 ([{fd=7, revents=POLLOUT}])
writev(7, [{"(\32\4\0\24\0`\1\240\4\0\0\0\0\0\0", 16}, {NULL, 0}, {"", 0}], 3) = 16
poll([{fd=7, events=POLLIN}], 1, -1)    = 1 ([{fd=7, revents=POLLIN}])
recvmsg(7, {msg_name(0)=NULL, msg_iov(1)=[{"\1\1\332\255\0\0\0\0Z\0\200\0\2\0$\0\0\0\0\0\0\0\0\0\0\0\0\0\0\0\0",
↪  4096}], msg_controllen=0, msg_flags=0}, 0) = 32
```

ltrace

L'outil *ltrace* permet de voir l'ensemble des appels à la libc. Les informations fournies ici correspondent aux différentes fonctions appelées dans les librairies du système. Les appels systèmes ne sont pas visibles.

ltrace -e opendir -e readdir ls

```
# ltrace -e opendir -e readdir ls
ls->opendir(".")                                = 0xf6bca0
ls->readdir(0xf6bca0)                           = 0xf6bcd0
ls->readdir(0xf6bca0)                           = 0xf6bce8
ls->readdir(0xf6bca0)                           = 0
+++ exited (status 0) +++
```

ltrace est utilisé pour comprendre le comportement d'un processus utilisateur en dehors des appels système.

Les options

ltrace possède les mêmes options que *strace* :

- -e : selection des fonctions à observer
- -tt : temps passé dans chaque fonction
- -c : nombre d'appel utilisé pour chaque fonction
- -p : PID sur lequel s'attacher

ltrace

L'outil *ltrace* permet de voir l'ensemble des appels à la libc. Les informations fournies ici correspondent aux différentes fonctions appelées dans les librairies du système. ~~Les appels systèmes ne sont pas visibles.~~

ltrace -e opendir -e readdir ls

```
# ltrace -e opendir -e readdir ls
ls->opendir(".")                                = 0xf6bca0
ls->readdir(0xf6bca0)                           = 0xf6bcd0
ls->readdir(0xf6bca0)                           = 0xf6bce8
ls->readdir(0xf6bca0)                           = 0
+++ exited (status 0) +++
```

ltrace est utilisé pour comprendre le comportement d'un processus utilisateur en dehors des appels système.

Les options

ltrace possède les mêmes options que *strace* :

- -e : selection des fonctions à observer
- -tt : temps passé dans chaque fonction
- -c : nombre d'appel utilisé pour chaque fonction
- -p : PID sur lequel s'attacher
- -S : affiche également les appels systèmes

Les sources

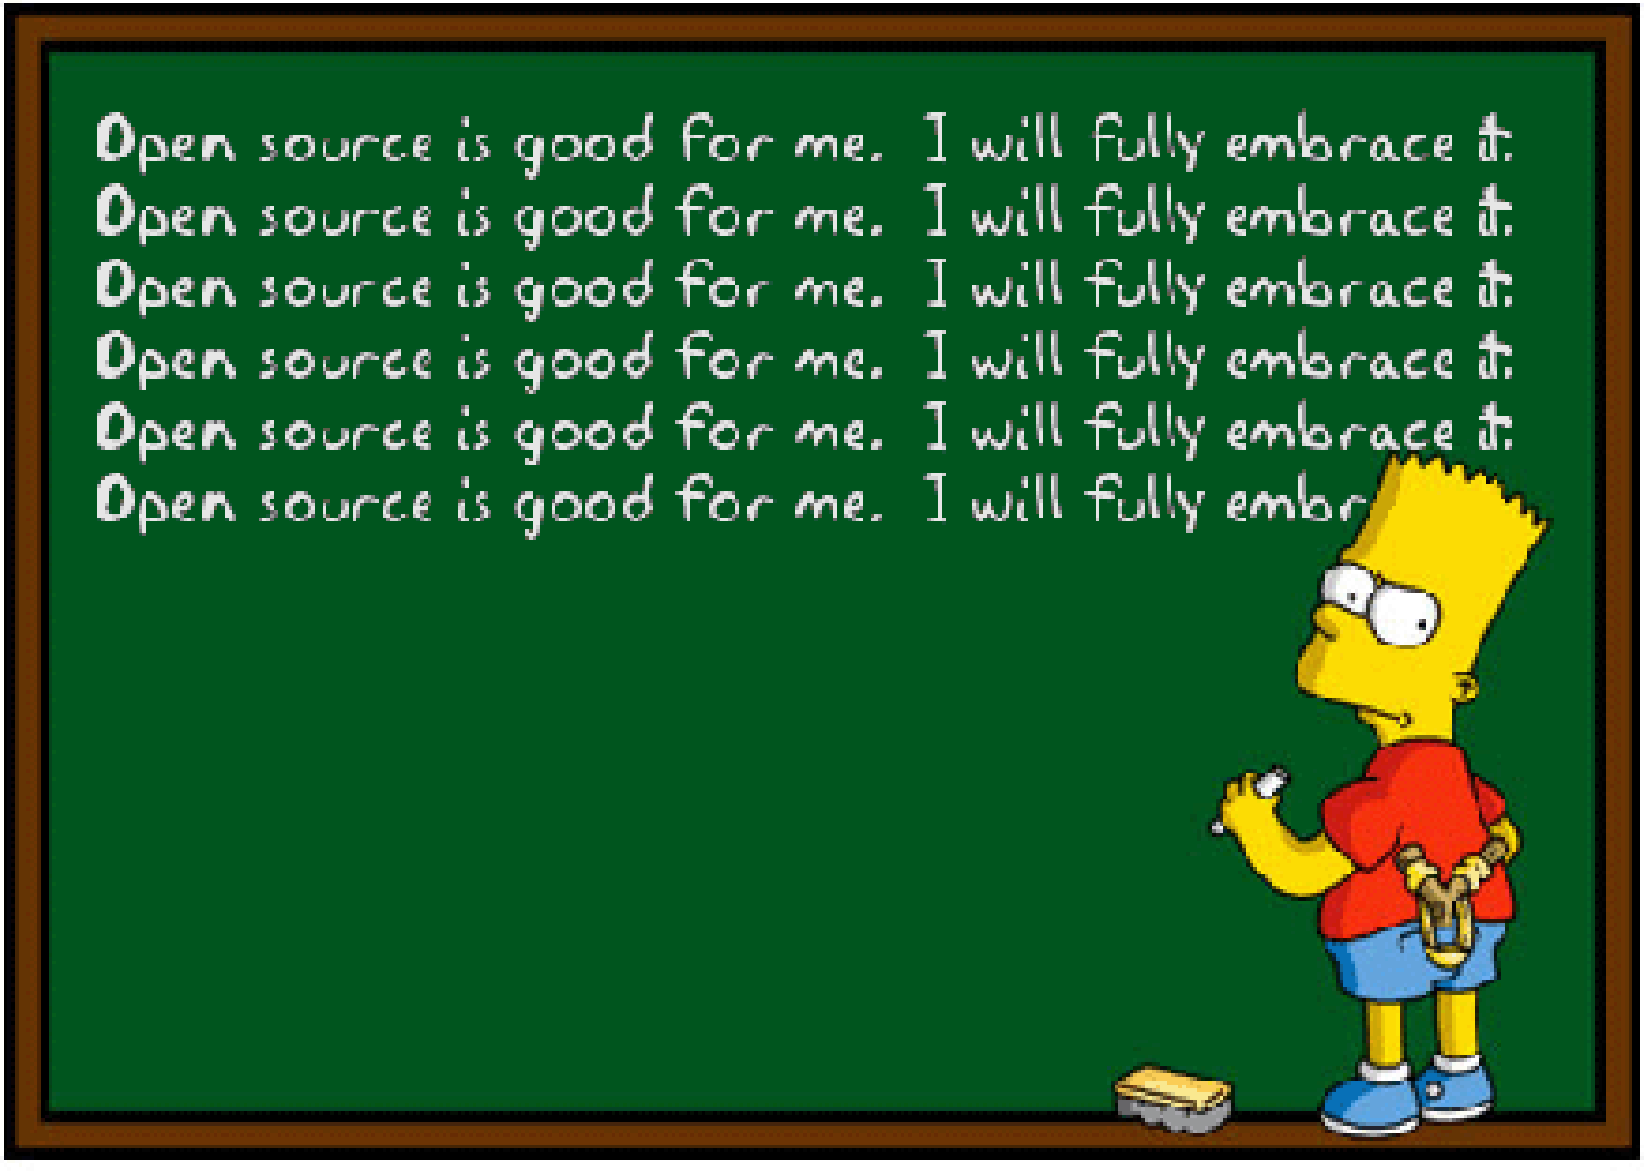
Open source is good for me. I will fully embrace it.
Open source is good for me. I will fully embrace it.
Open source is good for me. I will fully embrace it.
Open source is good for me. I will fully embrace it.
Open source is good for me. I will fully embrace it.
Open source is good for me. I will fully embr

Les sources

Le point fondamental permettant de debugger efficacement est d'avoir accès aux sources. Qu'il s'agisse du noyau ou d'un autre programme, les sources facilitent grandement la compréhension d'un problème.

Pour avoir un environnement de debugging complet, il faut :

- La version du logiciel à debugger
- Les sources correspondantes
- Les symboles de debug : fournis par la distribution ou à compiler soi-même

Les sources

Les sources du noyau sont très importantes et volumineuses, rechercher dans le code source une définition de fonction ou un symbole particulier peut s'avérer très compliqué.

Pour nous faciliter la tâche, l'outil *cscope* permet de naviguer facilement dans un gros projet écrit en C.

- Le noyau supporte directement l'indexation de cscope : *make cscope*
- *cscope -d -R*

Les sources

cscope

```
Global definition: task_struct

  File              Line
0 profile.h           66 struct task_struct;
1 regset.h            20 struct task_struct;
2 regset.h            39 typedef int user_regset_active_fn(struct task_struct *target,
3 regset.h            58 typedef int user_regset_get_fn(struct task_struct *target,
4 regset.h            79 typedef int user_regset_set_fn(struct task_struct *target,
5 regset.h           105 typedef int user_regset_writeback_fn(struct task_struct *target,
6 resource.h           7 struct task_struct;
7 sched.h            483 struct task_struct {
8 autogroup.h          5 struct task_struct;
9 debug.h              8 struct task_struct;
a jobctl.h             6 struct task_struct;
...
* Press the space bar to display the first lines again *


Find this C symbol:
Find this global definition: task_struct
Find functions called by this function:
Find functions calling this function:
Find this text string:
Change this text string:
Find this egrep pattern:
Find this file:
Find files #including this file:
Find assignments to this symbol:
```

gdb

gdb est l'outil par excellence de debug. Il permet d'inspecter le comportement et le contenu d'un exécutable.

- Permet de lancer l'exécution d'un programme pas à pas (breakpoints)
- Visualise les différentes variables des fonctions en cours
- Affiche la pile d'exécution
- Affiche les registres
- Peut aussi modifier le comportement du programme (en modifiant des variables par exemple)

Il existe 2 modes de lancement pour *gdb*

Mode classique au lancement de l'exécutable

gdb <exécutable> [paramètres de l'exécutable]

Mode attachement à un processus en cours

gdb -p <PID>

Les commandes principales

- break <ligne> : place un point d'arrêt dans le code

Exemple d'utilisation de gdb

```
(gdb) break opendir
Breakpoint 1 at 0x7ffff78b3140: file ../sysdeps/posix/opendir.c, line 181.
(gdb) run /
Starting program: /bin/ls /
[Thread debugging using libthread_db enabled]
Using host libthread_db library ``/lib/x86_64-linux-gnu/libthread_db.so.1''.

Breakpoint 1, _{opendir (name=0x625cc0 ``/'') at ../sysdeps/posix/opendir.c:182
182 ../sysdeps/posix/opendir.c: Aucun fichier ou dossier de ce type.
(gdb) where
#0  _{opendir (name=0x625cc0 ``/'') at ../sysdeps/posix/opendir.c:182
↪
#1  0x0000000000403849 in ?? (
#2  0x00007ffff780b830 in _{libc_start_main (main=0x402a00, argc=2,
        argv=0x7fffffffe118, init=<optimized out>, fini=<optimized out>,
        rtld_fini=<optimized out>, stack_end=0x7fffffffe108)
        at ../csu/libc-start.c:291
        #3  0x00000000004049c9 in ?? ()})}}
```

Les commandes principales

- break <ligne> : place un point d'arrêt dans le code
- run <args> : lance l'exécutable avec les arguments spécifiés

Exemple d'utilisation de gdb

```
(gdb) break opendir
Breakpoint 1 at 0x7ffff78b3140: file ../sysdeps/posix/opendir.c, line 181.
(gdb) run /
Starting program: /bin/ls /
[Thread debugging using libthread_db enabled]
Using host libthread_db library ``/lib/x86_64-linux-gnu/libthread_db.so.1''.

Breakpoint 1, _{opendir (name=0x625cc0 ``/'') at ../sysdeps/posix/opendir.c:182
182 ../sysdeps/posix/opendir.c: Aucun fichier ou dossier de ce type.
(gdb) where
#0  _{opendir (name=0x625cc0 ``/'') at ../sysdeps/posix/opendir.c:182
↪
#1  0x0000000000403849 in ?? (
#2  0x00007ffff780b830 in _{libc_start_main (main=0x402a00, argc=2,
        argv=0x7fffffffe118, init=<optimized out>, fini=<optimized out>,
        rtld_fini=<optimized out>, stack_end=0x7fffffffe108)
        at ../csu/libc-start.c:291
        #3  0x00000000004049c9 in ?? ()})}}
```

Les commandes principales

- break <ligne> : place un point d'arrêt dans le code
- run <args> : lance l'exécutable avec les arguments spécifiés
- where : affiche la pile d'appel d'exécution

Exemple d'utilisation de gdb

```
(gdb) break opendir
Breakpoint 1 at 0x7ffff78b3140: file ../sysdeps/posix/opendir.c, line 181.
(gdb) run /
Starting program: /bin/ls /
[Thread debugging using libthread_db enabled]
Using host libthread_db library ``/lib/x86_64-linux-gnu/libthread_db.so.1''.

Breakpoint 1, _{opendir (name=0x625cc0 ``/'') at ../sysdeps/posix/opendir.c:182
182 ../sysdeps/posix/opendir.c: Aucun fichier ou dossier de ce type.
(gdb) where
#0  _{opendir (name=0x625cc0 ``/'') at ../sysdeps/posix/opendir.c:182
↪
#1  0x0000000000403849 in ?? (
#2  0x00007ffff780b830 in _{libc_start_main (main=0x402a00, argc=2,
        argv=0x7fffffffe118, init=<optimized out>, fini=<optimized out>,
        rtld_fini=<optimized out>, stack_end=0x7fffffffe108)
        at ../csu/libc-start.c:291
        #3  0x00000000004049c9 in ?? ()})}}
```

Les commandes principales

- break <ligne> : place un point d'arrêt dans le code
- run <args> : lance l'exécutable avec les arguments spécifiés
- where : affiche la pile d'appel d'exécution

Exemple de backtrace de tous les threads d'un processus utilisateur

```
(gdb) thread apply all where

Thread 1 (LWP 20141):
#0  0x00007fd16877807a in __GI___waitpid (pid=-1, stat_loc=0x7fffbce8c220, options=10) at
↪  ../sysdeps/unix/sysv/linux/waitpid.c:29
#1  0x000000000044706d in ?? ()
#2  0x000000000044854b in wait_for ()
#3  0x00000000004384bf in execute_command_internal ()
#4  0x000000000043851e in execute_command ()
#5  0x000000000042139e in reader_loop ()
#6  0x000000000041fdb1 in main ()
```

Autres commandes

- up/down : déplacement dans la stack d'exécution

Registres gdb

```
(gdb) info registers
rax            0xfffffffffffffdfc       -516
rbx            0x0         0
rcx            0x7f0d6900a1b1       139695572951473
rdx            0x0         0
rsi            0x0         0
rdi            0x7fff561480b0       140734637572272
rbp            0x7fff561480f0       0x7fff561480f0
rsp            0x7fff561480e0       0x7fff561480e0
r8             0x557f6f251770       94005813909360
r9             0x7f0d6930d9d0       139695576111568
r10            0x62f        1583
r11            0x246        582
r12            0x557f6f251590       94005813908880
r13            0x7fff561481e0       140734637572576
r14            0x0         0
r15            0x0         0
rip            0x557f6f2516ca       0x557f6f2516ca <loop+27>
...
```

Autres commandes

- up/down : déplacement dans la stack d'exécution
- info registers : affiche les registres

Registres gdb

```
(gdb) info registers
rax            0xfffffffffffffdfc       -516
rbx            0x0        0
rcx            0x7f0d6900a1b1       139695572951473
rdx            0x0        0
rsi            0x0        0
rdi            0x7fff561480b0       140734637572272
rbp            0x7fff561480f0       0x7fff561480f0
rsp            0x7fff561480e0       0x7fff561480e0
r8             0x557f6f251770       94005813909360
r9             0x7f0d6930d9d0       139695576111568
r10            0x62f        1583
r11            0x246        582
r12            0x557f6f251590       94005813908880
r13            0x7fff561481e0       140734637572576
r14            0x0        0
r15            0x0        0
rip            0x557f6f2516ca       0x557f6f2516ca <loop+27>
...
```

Autres commandes

- up/down : déplacement dans la stack d'exécution
- info registers : affiche les registres
- info source : Information sur les sources du binaire actuellement analysé.

Information sur les sources

```
(gdb) info source
Current source file is src.c
Compilation directory is /some/where
Located in /some/where/src.c
Contains 16 lines.
Source language is c.
Producer is GNU C11 7.2.0 -mtune=generic -march=x86-64 -g.
Compiled with DWARF 2 debugging format.
Does not include preprocessor macro info.
```

Autres commandes

- up/down : déplacement dans la stack d'exécution
- info registers : affiche les registres
- info source : Information sur les sources du binaire actuellement analysé.
- disassemble : affiche le code assembleur d'une fonction

Code assembleur d'une fonction

```
(gdb) disassemble func
Dump of assembler code for function func:
   0x0000557f6f2516af <+0>:     push   %rbp
   0x0000557f6f2516b0 <+1>:     mov    %rsp,%rbp
   0x0000557f6f2516b3 <+4>:     sub    $0x10,%rsp
   0x0000557f6f2516b7 <+8>:     movl   $0x0,-0x4(%rbp)
   0x0000557f6f2516be <+15>:     jmp    0x557f6f2516ca <func+27>
   0x0000557f6f2516c0 <+17>:     mov    $0x3e8,%edi
   0x0000557f6f2516c5 <+22>:     callq  0x557f6f251580 <test+5>
=> 0x0000557f6f2516ca <+27>:     cmpl   $0x0,-0x4(%rbp)
   0x0000557f6f2516ce <+31>:     sete   %al
   0x0000557f6f2516d1 <+34>:     movzbl %al,%eax
   0x0000557f6f2516d4 <+37>:     mov    %eax,%edi
   0x0000557f6f2516d6 <+39>:     callq  0x557f6f25169a <print>
   0x0000557f6f2516db <+44>:     test   %eax,%eax
   0x0000557f6f2516dd <+46>:     jne    0x557f6f2516c0 <func+17>
   0x0000557f6f2516df <+48>:     nop
   0x0000557f6f2516e0 <+49>:     leaveq
   0x0000557f6f2516e1 <+50>:     retq
End of assembler dump.
```

Un des gros intérêt de gdb est qu'il peut analyser ce qu'il s'est passé sur un processus de façon post-mortem.

Les corefile

Les fichiers core ou corefiles contiennent l'ensemble de la mémoire d'un processus. Ces fichiers sont générés de différentes façons :

- lorsque le processus a effectué une erreur de segmentation.
- lorsque le processus a effectué une erreur système.
- à la demande : il est possible de demander au système de créer un corefile à tout moment

Exemple de génération d'un corefile

```
$ cat /proc/sys/kernel/core_pattern
|/usr/share/apport/apport %p %s %c %P
$ ulimit -c unlimited
$ gcore 21768
```

Sommaire

1 Debugger

2 Les instructions

3 Processus utilisateur

4 Noyau
- Au delà de l'espace utilisateur
- Logs kernel
- debugfs
- Crash
- Autres outils

5 Questions

Mais qu'est-ce donc que cette task_struct ? ?

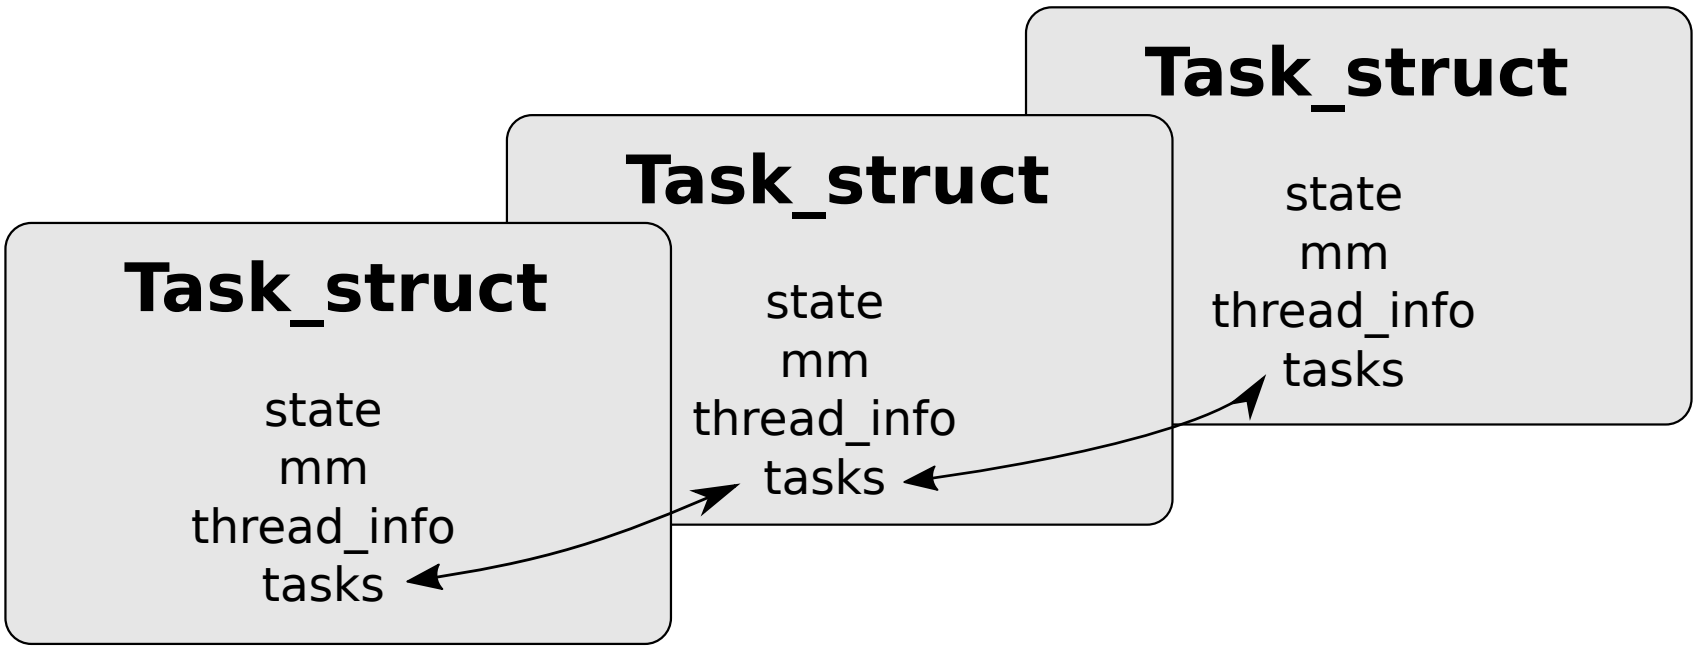

Mais qu'est-ce donc que cette task_struct ? ?

```
struct task_struct {
...
        /* -1 unrunnable, 0 runnable, >0 stopped: */
        volatile long                   state;
        void                           *stack;
        atomic_t                        usage;
...
        unsigned int                    cpu;
...

        struct mm_struct               *mm;
        struct mm_struct               *active_mm;

        /* Per-thread vma caching: */
        struct vmacache                 vmacache;

struct mm_struct {
    struct vm_area_struct *mmap;            /* list of VMAs */
...
    unsigned long mmap_base;                /* base of mmap area */
...
        unsigned long start_code, end_code, start_data, end_data;
        unsigned long start_brk, brk, start_stack;
...
};
```

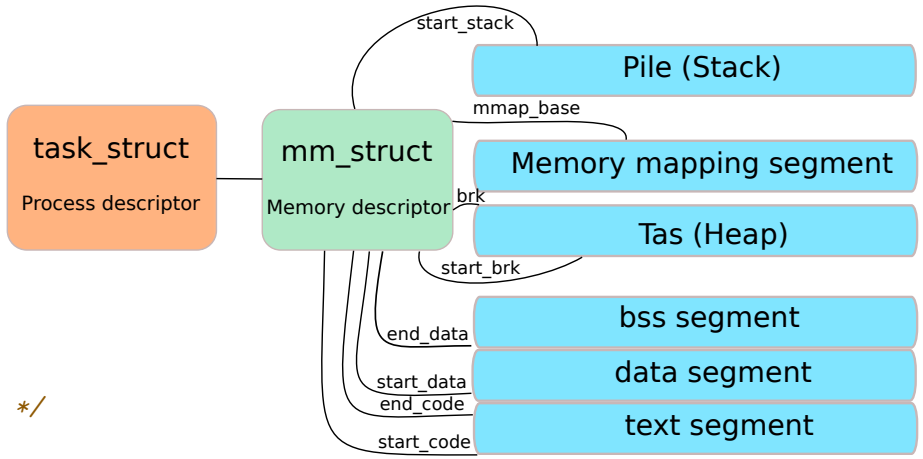

- La *task_struct* est une représentation d'un processus au sein du noyau
- Elle contient une structure mémoire, la *mm_struct* dans laquelle le noyau chargera les différents segments du binaire
- C'est ensuite le scheduler qui se chargera d'organiser le lancement des différents processus représentés par ces *task_struct*

Attention, on s'accroche (bis)

Et les *syscalls* dans le noyau ?

Reprenons notre exemple d'appel à un syscall :

Le code source - Assembleur x86_64

```
.text
.globl _start

_start:
        mov $60, %rax
        mov $2, %rdi
        syscall
```

- Les syscalls sont définis par architecture
  - *arch/x86/entry/syscalls/syscall_32.tbl* : processeur x86
  - *arch/x86/entry/syscalls/syscall_64.tbl* : processeur x86_64
  - *arch/arm/tools/syscall.tbl* : processeur arm

Et les *syscalls* dans le noyau ?

Reprenons notre exemple d'appel à un syscall :

Le code source - Assembleur x86_64

```
.text
.globl _start

_start:
        mov $60, %rax
        mov $2, %rdi
        syscall
```

syscall_64.tbl

```
#
# 64-bit system call numbers and entry vectors
#
# The format is:
# <number> <abi> <name> <entry point>
#
# The abi is "common", "64" or "x32" for this file.
#
0       common      read                    sys_read
1       common      write                    sys_write
2       common      open                    sys_open
3       common      close                    sys_close
...
60       common      exit                    sys_exit
...
```

L'implémentation des *syscalls*

- Le code déclenché par l'appel à un *syscall* est déclaré via les macros *SYSCALL_DEFINEn*.
- *n* correspond au nombre de paramètres de l'appel système.
- Dans notre exemple *sys_exit* n'a qu'un paramètre.
- Il est donc défini avec la macro *SYSCALL_DEFINE1*.

L'implémentation des *syscalls*

- Le code déclenché par l'appel à un *syscall* est déclaré via les macros *SYSCALL_DEFINEn*.
- *n* correspond au nombre de paramètres de l'appel système.
- Dans notre exemple *sys_exit* n'a qu'un paramètre.
- Il est donc défini avec la macro *SYSCALL_DEFINE1*.

exit.c

```
SYSCALL_DEFINE1(exit, int, error_code)
{
        do_exit((error_code&0xff)<<8);
}
```

L'implémentation des *syscalls*

exit.c

```
void __noreturn do_exit(long code)
{
        struct task_struct *tsk = current;
        int group_dead;
```

L'implémentation des *syscalls*

exit.c

```
void __noreturn do_exit(long code)
{
        struct task_struct *tsk = current;
        int group_dead;

        tsk->exit_code = code;
        taskstats_exit(tsk, group_dead);

        exit_mm();

        if (group_dead)
                acct_process();
        trace_sched_process_exit(tsk);

        exit_sem(tsk);
        exit_shm(tsk);
        exit_files(tsk);
        exit_fs(tsk);
        if (group_dead)
                disassociate_ctty(1);
        exit_task_namespaces(tsk);
        exit_task_work(tsk);
        exit_thread(tsk);



...

        exit_notify(tsk, group_dead);
        proc_exit_connector(tsk);
        mpol_put_task_policy(tsk);

        do_task_dead();
}
```

Les *syscalls*

Pourquoi tant de code dans le syscall exit ?

Les *syscalls*

Lors de l'appel à notre programme, le syscall *exit* est effectué, mais ce n'est pas tout, le lancement de la commande appelle également un autre syscall : *execve*

Les *syscalls*

Lors de l'appel à notre programme, le syscall *exit* est effectué, mais ce n'est pas tout, le lancement de la commande appelle également un autre syscall : *execve*

strace de notre programme

```
$ strace ./add
execve("./add", ["./add"], 0x7ffcfcbe7a20 /* 45 vars */) = 0
exit(2)                                 = ?
+++ exited with 2 +++
```

Les *syscalls*

Le syscall execve a 3 paramètres c'est donc avec la macro *SYSCALL_DEFINE3* qu'il sera défini.

execve.c

```
SYSCALL_DEFINE3(execve,
                const char __user *, filename,
                const char __user *const __user *, argv,
                const char __user *const __user *, envp)
{
        return do_execve(getname(filename), argv, envp);
}
```

Les *syscalls*

execve.c

```
int do_execve(struct filename *filename,
        const char __user *const __user *__argv,
        const char __user *const __user *__envp)
{
        struct user_arg_ptr argv = { .ptr.native = __argv };
        struct user_arg_ptr envp = { .ptr.native = __envp };
        return do_execveat_common(AT_FDCWD, filename, argv, envp, 0);
}
```

Les *syscalls*

execve.c

```
static int do_execveat_common(int fd, struct filename *filename,
                              struct user_arg_ptr argv,
                              struct user_arg_ptr envp,
                              int flags)
{
        char *pathbuf = NULL;
        struct linux_binprm *bprm;
```

Les *syscalls*

execve.c

```
static int do_execveat_common(int fd, struct filename *filename,
                              struct user_arg_ptr argv,
                              struct user_arg_ptr envp,
                              int flags)
{
        char *pathbuf = NULL;
        struct linux_binprm *bprm;

        bprm = kzalloc(sizeof(*bprm), GFP_KERNEL);
        if (!bprm)
                goto out_files;

        retval = prepare_bprm_creds(bprm);
        if (retval)
                goto out_free;

        check_unsafe_exec(bprm);
        current->in_execve = 1;

        file = do_open_execat(fd, filename, flags);
        retval = PTR_ERR(file);
        if (IS_ERR(file))
                goto out_unmark;

        sched_exec();

        retval = bprm_mm_init(bprm);
        if (retval)
                goto out_unmark;

        bprm->argc = count(argv, MAX_ARG_STRINGS);
        if ((retval = bprm->argc) < 0)

}
```

Les *syscalls*

- execve ouvre le fichier binaire et le monte en mémoire.
- execve met en place la *mm_struct* avec les différents segments du binaire. (*brm_mm_init*)
- Ensuite le noyau lance l'exécution.

Les *syscalls*

Mais où est la *task_struct* ?

Les *syscalls*

C'est en amont que la *task_struct* est créée, avant l'appel au syscall *exec* !

strace bash

```
$ strace -f -p 5678
5678  write(2, "./code/add ", 11)        = 11
5678  read(0, "\r", 1)                   = 1
5678  write(2, "\n", 1)                   = 1
5678  clone(child_stack=NULL, flags=CLONE_CHILD_CLEARTID|CLONE_CHILD_SETTID|SIGCHLD, child_tidptr=0x7fd69ebd0310) = 15690
5678  setpgid(15690, 15690)              = 0
15690 getpid()                           = 15690
15690 execve("./code/add", ["./code/add"], 0x2791310 /* 45 vars */) = 0
15690 exit(2)                            = ?
15690 +++ exited with 2 +++
5678  <... wait4 resumed> [{WIFEXITED(s) && WEXITSTATUS(s) == 2}], WSTOPPED|WCONTINUED, NULL) = 15690
5678  --- SIGCHLD {si_signo=SIGCHLD, si_code=CLD_EXITED, si_pid=15690, si_uid=1000, si_status=2, si_utime=0, si_stime=0} ---
5678  rt_sigprocmask(SIG_BLOCK, NULL, [], 8) = 0
5678  write(1, "\33]0;mat@vortex:~/Documents/2017-"..., 59) = 59
```

Les *syscalls*

Le syscall clone a 3 paramètres c'est donc avec la macro *SYSCALL_DEFINE3* qu'il sera défini.

Les *syscalls*

Le syscall clone a 5 paramètres c'est donc avec la macro *SYSCALL_DEFINE5* qu'il sera défini.

Les *syscalls*

Le syscall clone a 5 paramètres c'est donc avec la macro *SYSCALL_DEFINE5* qu'il sera défini.

man clone

```
CLONE(2)                    Linux Programmer's Manual                    CLONE(2

NAME
       clone, __clone2 - create a child process

SYNOPSIS
       /* Prototype for the glibc wrapper function */

       #define _GNU_SOURCE
       #include <sched.h>

       int clone(int (*fn)(void *), void *child_stack,
                 int flags, void *arg, ...
                 /* pid_t *ptid, void *newtls, pid_t *ctid */ );

       /* For the prototype of the raw system call, see NOTES */

...
NOTES
...

           long clone(unsigned long flags, void *child_stack,
                      int *ptid, int *ctid,
                      unsigned long newtls);
```

Les *syscalls*

Le syscall clone a 5 paramètres c'est donc avec la macro *SYSCALL_DEFINE5* qu'il sera défini.

fork.c

```
#ifdef CONFIG_CLONE_BACKWARDS
SYSCALL_DEFINE5(clone, unsigned long, clone_flags, unsigned long, newsp,
                 int __user *, parent_tidptr,
                 unsigned long, tls,
                 int __user *, child_tidptr)
#elif defined(CONFIG_CLONE_BACKWARDS2)
SYSCALL_DEFINE5(clone, unsigned long, newsp, unsigned long, clone_flags,
                 int __user *, parent_tidptr,
                 int __user *, child_tidptr,
                 unsigned long, tls)
#elif defined(CONFIG_CLONE_BACKWARDS3)
SYSCALL_DEFINE6(clone, unsigned long, clone_flags, unsigned long, newsp,
                int, stack_size,
                int __user *, parent_tidptr,
                int __user *, child_tidptr,
                unsigned long, tls)
#else
SYSCALL_DEFINE5(clone, unsigned long, clone_flags, unsigned long, newsp,
                 int __user *, parent_tidptr,
                 int __user *, child_tidptr,
                 unsigned long, tls)
#endif
{
        return _do_fork(clone_flags, newsp, 0, parent_tidptr, child_tidptr, tls);
}
#endif
```

Les *syscalls*

fork.c

```
long _do_fork(unsigned long clone_flags,
              unsigned long stack_start,
              unsigned long stack_size,
              int __user *parent_tidptr,
              int __user *child_tidptr,
              unsigned long tls)
{
        struct task_struct *p;
        int trace = 0;
        long nr;


        p = copy_process(clone_flags, stack_start, stack_size,
                         child_tidptr, NULL, trace, tls, NUMA_NO_NODE);

static __latent_entropy struct task_struct *copy_process(
                                        unsigned long clone_flags,
                                        unsigned long stack_start,
                                        unsigned long stack_size,
                                        int __user *child_tidptr,
                                        struct pid *pid,
                                        int trace,
                                        unsigned long tls,
                                        int node)
{
        int retval;
        struct task_struct *p;

        p = dup_task_struct(current, node);
        if (!p)
                goto fork_out;
```

Les *syscalls*

- *clone* duplique la *task_struct* courante.
- Cette dernière est réinitialisée dans la foulée.
- Ensuite le noyau insère cette nouvelle tâche dans sa liste de *task_struct*.
- Un nouveau processus fils a été créé.

Résumé

- Le shell appelle le syscall *clone* qui duplique la *task_struct* courante.

Résumé

- Le shell appelle le syscall *clone* qui duplique la *task_struct* courante.
- Cette nouvelle tâche appelle le syscall *execve* qui va remplacer le code de la *task_struct* par celui du binaire spécifié.

Résumé

- Le shell appelle le syscall *clone* qui duplique la *task_struct* courante.
- Cette nouvelle tâche appelle le syscall *execve* qui va remplacer le code de la *task_struct* par celui du binaire spécifié.
- Le syscall *exit* est enfin appelé.

Résumé

- Le shell appelle le syscall *clone* qui duplique la *task_struct* courante.
- Cette nouvelle tâche appelle le syscall *execve* qui va remplacer le code de la *task_struct* par celui du binaire spécifié.
- Le syscall *exit* est enfin appelé.
- La *task_struct* créée par le syscall *clone* est nétoyée.

Les outils...

dmesg

dmesg permet d'accéder aux messages du noyau.

- Donne les premières informations permettant de comprendre un problème provenant du noyau.
- Accès à tous les messages depuis le dernier démarrage de la machine.
- En interne, c'est le fichier */proc/kmsg* qui est lu dans un ring buffer.

dmesg

dmesg permet d'accéder aux messages du noyau.

- Donne les premières informations permettant de comprendre un problème provenant du noyau.
- Accès à tous les messages depuis le dernier démarrage de la machine.
- En interne, c'est le fichier */proc/kmsg* qui est lu dans un ring buffer.

dmesg

```
[    0.072938] PM: Registering ACPI NVS region [mem 0xbf641000-0xbf683fff] (274432 bytes)
[    0.073006] clocksource: jiffies: mask: 0xffffffff max_cycles: 0xffffffff, max_idle_ns: 7645041785100000 ns
[    0.073019] futex hash table entries: 1024 (order: 4, 65536 bytes)
[    0.073091] pinctrl core: initialized pinctrl subsystem
[    0.073189] RTC time:  7:49:09, date: 11/27/17
[    0.073278] NET: Registered protocol family 16
[    0.082796] cpuidle: using governor ladder
[    0.087453] cpuidle: using governor menu
[    0.087462] PCCT header not found.
[    0.087548] ACPI: bus type PCI registered
[    0.087552] acpiphp: ACPI Hot Plug PCI Controller Driver version: 0.5
[    0.087617] PCI: MMCONFIG for domain 0000 [bus 00-ff] at [mem 0xe0000000-0xefffffff] (base 0xe0000000)
[    0.087623] PCI: not using MMCONFIG
[    0.087626] PCI: Using configuration type 1 for base access
[    0.087744] NMI watchdog: enabled on all CPUs, permanently consumes one hw-PMU counter.
```

- *-T* : Affiche les timestamps dans un format lisible
- *-w* : Affiche les nouveaux messages dès leur réception

Debugfs

Debugfs est ce qu'on appelle un pseudo système de fichiers, il permet d'accéder aux fonctions dites de debug du noyau.

Accéder à debugfs

```
# mkdir /mnt/debug
# mount -t debugfs none /mnt/debug
```

Contenu de debugfs

```
# ls /sys/kernel/debug/
acpi                intel_powerclamp  regulator
bdi                 iosf_sb           sched_features
btrfs               kprobes           sleep_time
cleancache          kvm               sunrpc
clk                 mce               suspend_stats
dma_buf             mei0              tracing
dri                 pinctrl           usb
dynamic_debug       pkg_temp_thermal  virtio-ports
extfrag             pm_qos            wakeup_sources
fault_around_bytes  pstate_snb        x86
frontswap           pwm               zswap
gpio                ras
hid                 regmap
```

De nombreuses possibilités y sont offertes, nous allons uniquement nous concentrer sur deux d'entre-elles :

- dynamic_debug
- tracing

dynamic_debug

Le dynamic_debug est une fonctionnalité du noyau permettant d'activer les messages de debugging du noyau.
Le fichier *dynamic_debug/control* permet de lister et de contrôler ces activations.

Messages de debug activés

```
# awk '$3 != "=_"' /sys/kernel/debug/dynamic_debug/control
# filename:lineno [module]function flags format
init/main.c:741 [main]initcall_blacklisted =p "initcall %s blacklisted\012"
init/main.c:717 [main]initcall_blacklist =p "blacklisting initcall %s\012"
arch/x86/kernel/cpu/mtrr/main.c:491 [main]mtrr_del_page =p "mtrr: no MTRR for %lx000,%lx000 found\012"
arch/x86/kernel/cpu/mtrr/main.c:399 [main]mtrr_check =p "mtrr: size: 0x%lx  base: 0x%lx\012"
arch/x86/kernel/cpu/mtrr/generic.c:444 [generic]print_mtrr_state =p "TOM2: %016llx aka %lldM\012"
arch/x86/kernel/cpu/mtrr/generic.c:441 [generic]print_mtrr_state =p "  %u disabled\012"
arch/x86/kernel/cpu/mtrr/generic.c:439 [generic]print_mtrr_state =p "  %u base %0*X%05X000 mask %0*X%05X000 %s\012"
arch/x86/kernel/cpu/mtrr/generic.c:426 [generic]print_mtrr_state =p "MTRR variable ranges %sabled:\012"
```

Activation d'un message de debug

```
# echo "func SYSC_init_module +p" >/sys/kernel/debug/dynamic_debug/control
awk '/SYSC_init_module/' /sys/kernel/debug/dynamic_debug/control
kernel/module.c:3604 [module]SYSC_init_module =p "init_module: umod=%p, len=%lu, uargs=%p\012"
```

Une fois activés, ces messages sont consultables via *dmesg*.

Documentation/admin-guide/dynamic-debug-howto.rst

tracing

Le tracing dans le noyau permet de suivre les différentes fonctions activées pendant une certaine période pour un ou plusieurs processus.
Le principe consiste à définir un ensemble de filtre, de choisir une fonction de suivi (tracing) et de l'activer.

- *set_ftrace_pid* permet de définir le processus à observer.
- *current_tracer* donne la fonction de tracing utilisée.
- *tracing_on* active ou désactive le tracing.

Le résultat est stocké dans un ringbuffer dans le fichier :

- /sys/kernel/debug/tracing/trace

trace

```
# tracer: function
#
#                              _-----=> irqs-off
#                             / _----=> need-resched
#                            | / _---=> hardirq/softirq
#                            || / _--=> preempt-depth
#                            ||| /     delay
#           TASK-PID   CPU#  ||||    TIMESTAMP  FUNCTION
#              | |       |   ||||       |         |
          wmiirc-25517 [000] .... 1971.833158: acpi_ps_free_op <-acpi_ps_delete_parse_tree
          wmiirc-25517 [000] .... 1971.833158: acpi_os_release_object <-acpi_ps_free_op
          wmiirc-25517 [000] .... 1971.833158: kmem_cache_free <-acpi_os_release_object
          wmiirc-25517 [000] .... 1971.833158: acpi_ps_get_arg <-acpi_ps_delete_parse_tree
          wmiirc-25517 [000] .... 1971.833158: acpi_ps_get_opcode_info <-acpi_ps_get_arg
          wmiirc-25517 [000] .... 1971.833158: acpi_ps_free_op <-acpi_ps_delete_parse_tree
          wmiirc-25517 [000] .... 1971.833158: acpi_os_release_object <-acpi_ps_free_op
          wmiirc-25517 [000] .... 1971.833158: kmem_cache_free <-acpi_os_release_object
          wmiirc-25517 [000] .... 1971.833159: acpi_ps_free_op <-acpi_ps_delete_parse_tree
          wmiirc-25517 [000] .... 1971.833159: acpi_os_release_object <-acpi_ps_free_op
          wmiirc-25517 [000] .... 1971.833159: kmem_cache_free <-acpi_os_release_object
```

perf

La mise en place du tracing étant relativement complexe, l'outil *perf* permet de faciliter son utilisation.

- perf list : liste l'ensemble des évènements disponibles
- perf record : enregistre une trace
- perf report : affiche le résultat d'une trace précédemment effectuée

Utilisation de perf

```
# cd /tmp
# perf record -e ext4:ext4_free_inode -a
^C[ perf record: Woken up 1 times to write data ]
[ perf record: Captured and wrote 0.823 MB perf.data (2 samples) ]

# perf report
```

perf

- perf list <module> : liste les évènements disponibles pour le module spécifié.
- perf stat : Affiche les statistiques CPU.

Utilisation de perf

```
$ sudo perf stat -a sleep 1

 Performance counter stats for 'system wide':

      4003,736886      cpu-clock (msec)          #    3,999 CPUs utilized
              280      context-switches          #    0,070 K/sec
               11      cpu-migrations            #    0,003 K/sec
            1 934      page-faults               #    0,483 K/sec
       45 999 809      cycles                    #    0,011 GHz
       36 771 055      instructions              #    0,80  insn per cycle
        7 734 723      branches                  #    1,932 M/sec
          247 430      branch-misses             #    3,20% of all branches

      1,001166320 seconds time elapsed
```

Crash
Présentation

- Crash est une version améliorée de gdb destinée à faciliter le debugging du noyau.
- Il se base sur le fichier /proc/kcore ou une copie qui contient la mémoire du noyau à un instant T
- Permet une analyse post-mortem ou en live d'un problème ou d'un mauvais comportement

Crash
Pré-requis

Pour pouvoir utiliser *crash*, il est impératif d'obtenir les symboles de debug du noyau que l'on souhaite debugger

- Soit le noyau est compilé par la distribution et il n'y a qu'à installer les packages :
  - linux-image-XXX.YYY-ZZZ-generic-dbgsym (Ubuntu/Debian)
  - kernel-debuginfo (RedHat/Fedora/CentOS)
  - ...
- Soit le noyau a été compilé depuis les sources et il faut recompiler le noyau avec les symboles de debug :
  - apt source linux (Ubuntu/Debian)
  - kernel-XXX.YYY.src.rpm (RedHat/Fedora/CentOS)
  - `https://www.kernel.org/`

Crash
Kexec/Kdump

Le challenge est de pouvoir récupérer la mémoire du noyau qui vient de planter.

- Kdump est un service qui pre-charge, via kexec, un noyau et un initrd minimal
- La mémoire du noyau de capture doit être réservée au boot du noyau
  - *crashkernel=auto*
- Une fois le service activé, le noyau de capture est prêt à être déclenché et à procéder à une capture.

Crash
Kexec/Kdump

Comment déclencher cette récupération ?

- Via les fichiers contenus dans */proc/sys/kernel/panic**, on définit le comportement du noyau qui va déclencher un *kernel panic*
- Pour effectivement déclencher le *panic* soit :
  - Le kernel panic de façon autonome
  - Via les magic sysrq
  - Via un nmi externe
- Lorsque le noyau se trouve dans cet état, le noyau kdump prend le relais et déclanche la sauvegarde de la mémoire.

/proc/sys/kernel/panic

```
# ls /proc/sys/kernel/panic*
/proc/sys/kernel/panic            /proc/sys/kernel/panic_on_oops            /proc/sys/kernel/panic_on_warn
/proc/sys/kernel/panic_on_io_nmi  /proc/sys/kernel/panic_on_unrecovered_nmi
```

Crash
Utilisation

Lancement

crash [noyau corefile]

- Sans argument, *crash* analyse le système en live
- En lui spécifiant le noyau avec ses symboles de debug et un corefile précédemment généré, on lance une analyse post-mortem

Crash
Utilisation

Lancement

crash [noyau corefile]

crash

```
      KERNEL: /usr/lib/debug/boot/vmlinux-4.4.0-97-generic
    DUMPFILE: /proc/kcore
        CPUS: 4
        DATE: Sun Nov 26 21:28:48 2017
      UPTIME: 12 days, 16:41:39
LOAD AVERAGE: 1.01, 1.19, 1.14
       TASKS: 713
    NODENAME: dakoro
     RELEASE: 4.4.0-97-generic
     VERSION: #120-Ubuntu SMP Tue Sep 19 17:28:18 UTC 2017
     MACHINE: x86_64  (3093 Mhz)
      MEMORY: 6 GB
         PID: 28479
     COMMAND: "crash"
        TASK: ffff8800ad5faa00  [THREAD_INFO: ffff8800799ec000]
         CPU: 0
       STATE: TASK_RUNNING (ACTIVE)
```

Crash
Utilisation

Lancement

crash [noyau corefile]

crash

```
      KERNEL: /usr/lib/debug/boot/vmlinux-4.4.0-97-generic
    DUMPFILE: /proc/kcore
        CPUS: 4
        DATE: Sun Nov 26 21:28:48 2017
      UPTIME: 12 days, 16:41:39
LOAD AVERAGE: 1.01, 1.19, 1.14
       TASKS: 713
    NODENAME: dakoro
     RELEASE: 4.4.0-97-generic
     VERSION: #120-Ubuntu SMP Tue Sep 19 17:28:18 UTC 2017
     MACHINE: x86_64  (3093 Mhz)
      MEMORY: 6 GB
         PID: 28479
     COMMAND: "crash"
        TASK: ffff8800ad5faa00  [THREAD_INFO: ffff8800799ec000]
         CPU: 0
       STATE: TASK_RUNNING (ACTIVE)
```

- Version du noyau
- Date de prise du crash
- Nombre de tâches
- Architecture du processeur
- Informations sur la tâche actuelle

Lister l'ensemble des tâches du système

ps [PID | task | commande]

Lister l'ensemble des tâches du système

ps [PID | task | commande]

ps

PID	PPID	CPU	TASK	ST	%MEM	VSZ	RSS	COMM
0	0	0	ffffffff81e11500	RU	0.0	0	0	[swapper/0]
0	0	1	ffff8801b7a38e00	RU	0.0	0	0	[swapper/1]
0	0	2	ffff8801b7a39c00	RU	0.0	0	0	[swapper/2]
0	0	3	ffff8801b7a3aa00	RU	0.0	0	0	[swapper/3]
1	0	1	ffff8801b79e8000	IN	0.1	185492	4296	systemd
...								
964	1	0	ffff8801b2d79c00	IN	0.0	44920	1556	avahi-daemon
970	1	1	ffff8801b34e8e00	IN	0.0	26044	184	atd
972	1	0	ffff8801b34e9c00	IN	0.1	138412	3676	freshclam
974	1	2	ffff8801b34e8000	IN	0.0	166456	2012	thermald
990	1	3	ffff8801b53a8e00	IN	0.0	276204	2268	accounts-daemon
997	1	3	ffff8801b53ab800	IN	0.0	256396	1220	rsyslogd
1009	1	2	ffff8800b5f30000	IN	0.0	44332	3204	dbus-daemon
1052	1	1	ffff8800b5f34600	IN	0.0	495104	1020	osspd
1053	1	1	ffff8800b5f35400	IN	0.0	495104	1020	osspd
1054	1	3	ffff8800b5f32a00	IN	0.0	495104	1020	osspd
1055	1	3	ffff8800b5f36200	IN	0.0	495104	1020	osspd

Lister l'ensemble des tâches du système

ps [PID | task | commande]

ps

```
   PID    PPID  CPU       TASK        ST  %MEM     VSZ    RSS  COMM
     0       0   0  ffffffff81e11500  RU   0.0       0      0  [swapper/0]
     0       0   1  ffff8801b7a38e00  RU   0.0       0      0  [swapper/1]
     0       0   2  ffff8801b7a39c00  RU   0.0       0      0  [swapper/2]
     0       0   3  ffff8801b7a3aa00  RU   0.0       0      0  [swapper/3]
     1       0   1  ffff8801b79e8000  IN   0.1  185492   4296  systemd
...
   964       1   0  ffff8801b2d79c00  IN   0.0   44920   1556  avahi-daemon
   970       1   1  ffff8801b34e8e00  IN   0.0   26044    184  atd
   972       1   0  ffff8801b34e9c00  IN   0.1  138412   3676  freshclam
   974       1   2  ffff8801b34e8000  IN   0.0  166456   2012  thermald
   990       1   3  ffff8801b53a8e00  IN   0.0  276204   2268  accounts-daemon
   997       1   3  ffff8801b53ab800  IN   0.0  256396   1220  rsyslogd
  1009       1   2  ffff8800b5f30000  IN   0.0   44332   3204  dbus-daemon
  1052       1   1  ffff8800b5f34600  IN   0.0  495104   1020  osspd
  1053       1   1  ffff8800b5f35400  IN   0.0  495104   1020  osspd
  1054       1   3  ffff8800b5f32a00  IN   0.0  495104   1020  osspd
  1055       1   3  ffff8800b5f36200  IN   0.0  495104   1020  osspd
```

- Affichage de *PID PPID*
- Adresse de la *task_struct*
- Status de la tâche
- Mémoire virtuellement disponible
- Mémoire effectivement utilisée
- Ligne de commande

Choisir une autre tâche

set [PID | task]

- Par défaut l'ensemble des commandes prennent la tâche courante comme référence
- Pour changer de tâche courante, on utilise la commande *set*
- La sélection de la tâche se fait par *PID* ou par adresse de *task_struct*

Choisir une autre tâche

set [PID | task]

- Par défaut l'ensemble des commandes prennent la tâche courante comme référence
- Pour changer de tâche courante, on utilise la commande *set*
- La sélection de la tâche se fait par *PID* ou par adresse de *task_struct*

set

```
crash> set 1
    PID: 1
COMMAND: "systemd"
   TASK: ffff8801b79e8000  [THREAD_INFO: ffff8801b79f0000]
    CPU: 1
  STATE: TASK_INTERRUPTIBLE
```

Afficher la pile d'exécution d'une tâche

bt [PID]

- Affiche la pile d'exécution d'une tâche.
- Avec l'option *-f* affiche le contenu complet de la pile.
- C'est cette fonction qui rend crash incontournable pour comprendre ce qu'il se passe sur le système.

Afficher la pile d'exécution d'une tâche

bt [PID]

- Affiche la pile d'exécution d'une tâche.
- Avec l'option *-f* affiche le contenu complet de la pile.
- C'est cette fonction qui rend crash incontournable pour comprendre ce qu'il se passe sur le système.

bt

```
crash> bt
PID: 1      TASK: ffff8801b79e8000  CPU: 0   COMMAND: "systemd"
 #0 [ffff8801b79f3d40] __schedule at ffffffff8183efce
 #1 [ffff8801b79f3d90] schedule at ffffffff8183f6b5
 #2 [ffff8801b79f3da8] schedule_hrtimeout_range_clock at ffffffff81842ca3
 #3 [ffff8801b79f3e50] schedule_hrtimeout_range at ffffffff81842cd3
 #4 [ffff8801b79f3e60] ep_poll at ffffffff81259c40
 #5 [ffff8801b79f3f10] sys_epoll_wait at ffffffff8125af28
 #6 [ffff8801b79f3f50] entry_SYSCALL_64_fastpath at ffffffff818437f2
    RIP: 00007f5e7aa689d3  RSP: 00007fff1c6f6470  RFLAGS: 00000293
    RAX: ffffffffffffffda  RBX: 00005610aabade00  RCX: 00007f5e7aa689d3
    RDX: 00000000000000af  RSI: 00007fff1c6f6480  RDI: 0000000000000004
    RBP: 0000000000000000   R8: 00007fff1c6f6480   R9: 225870c9894f4527
    R10: 00000000ffffffff  R11: 0000000000000293  R12: 0000000000000000
    R13: 00007fff1c6f4810  R14: 00007fff1c6f4820  R15: 00005610a8ad28e3
    ORIG_RAX: 00000000000000e8  CS: 0033  SS: 002b
```

Afficher le code assembleur d'une fonction

dis fonction

- Permet de comprendre l'enchaînement de la pile d'appel

Afficher le code assembleur d'une fonction

dis fonction

- Permet de comprendre l'enchaînement de la pile d'appel

dis

```
crash> dis schedule
0xffffffff8183f680 <schedule>:  callq  0xffffffff818460c0 <ftrace_graph_caller>
0xffffffff8183f685 <schedule+5>:        push   %rbp
0xffffffff8183f686 <schedule+6>:        mov    %gs:0xd400,%rax
0xffffffff8183f68f <schedule+15>:       mov    %rsp,%rbp
0xffffffff8183f692 <schedule+18>:       push   %rbx
0xffffffff8183f693 <schedule+19>:       mov    (%rax),%rdx
0xffffffff8183f696 <schedule+22>:       test   %rdx,%rdx
0xffffffff8183f699 <schedule+25>:       je     0xffffffff8183f6a5 <schedule+37>
0xffffffff8183f69b <schedule+27>:       cmpq   $0x0,0x6f0(%rax)
0xffffffff8183f6a3 <schedule+35>:       je     0xffffffff8183f6c3 <schedule+67>
0xffffffff8183f6a5 <schedule+37>:       mov    %gs:0x14304,%rbx
0xffffffff8183f6ae <schedule+46>:       xor    %edi,%edi
0xffffffff8183f6b0 <schedule+48>:       callq  0xffffffff8183ec50 <__schedule>
0xffffffff8183f6b5 <schedule+53>:       mov    -0x3ff8(%rbx),%rax
0xffffffff8183f6bc <schedule+60>:       test   $0x8,%al
0xffffffff8183f6be <schedule+62>:       jne    0xffffffff8183f6ae <schedule+46>
0xffffffff8183f6c0 <schedule+64>:       pop    %rbx
0xffffffff8183f6c1 <schedule+65>:       pop    %rbp
0xffffffff8183f6c2 <schedule+66>:       retq
```

Afficher le code assembleur d'une fonction

dis fonction

- Permet de comprendre l'enchaînement de la pile d'appel

dis

```
crash> dis schedule
0xffffffff8183f680 <schedule>:  callq  0xffffffff818460c0 <ftrace_graph_caller>
0xffffffff8183f685 <schedule+5>:        push   %rbp
0xffffffff8183f686 <schedule+6>:        mov    %gs:0xd400,%rax
0xffffffff8183f68f <schedule+15>:       mov    %rsp,%rbp
0xffffffff8183f692 <schedule+18>:       push   %rbx
0xffffffff8183f693 <schedule+19>:       mov    (%rax),%rdx
0xffffffff8183f696 <schedule+22>:       test   %rdx,%rdx
0xffffffff8183f699 <schedule+25>:       je     0xffffffff8183f6a5 <schedule+37>
0xffffffff8183f69b <schedule+27>:       cmpq   $0x0,0x6f0(%rax)
0xffffffff8183f6a3 <schedule+35>:       je     0xffffffff8183f6c3 <schedule+67>
0xffffffff8183f6a5 <schedule+37>:       mov    %gs:0x14304,%rbx
0xffffffff8183f6ae <schedule+46>:       xor    %edi,%edi
0xffffffff8183f6b0 <schedule+48>:       callq  0xffffffff8183ec50 <__schedule>
0xffffffff8183f6b5 <schedule+53>:       mov    -0x3ff8(%rbx),%rax
0xffffffff8183f6bc <schedule+60>:       test   $0x8,%al
0xffffffff8183f6be <schedule+62>:       jne    0xffffffff8183f6ae <schedule+46>
0xffffffff8183f6c0 <schedule+64>:       pop    %rbx
0xffffffff8183f6c1 <schedule+65>:       pop    %rbp
0xffffffff8183f6c2 <schedule+66>:       retq
```

- Adresse de l'instruction
- Offset de l'instruction
- Code assembleur

Afficher la définition d'un symbole

whatis symbole

- Donne la définition d'une structure
- Donne le type d'un symbole
- Donne le prototype d'une fonction

Afficher la définition d'un symbole

whatis symbole

- Donne la définition d'une structure
- Donne le type d'un symbole
- Donne le prototype d'une fonction

whatis

```
crash> whatis struct mm_struct
struct mm_struct {
    struct vm_area_struct *mmap;
...
    unsigned long mmap_base;
    unsigned long mmap_legacy_base;
...
    unsigned long start_code;
    unsigned long end_code;
    unsigned long start_data;
    unsigned long end_data;
    unsigned long start_brk;
    unsigned long brk;
    unsigned long start_stack;
    unsigned long arg_start;
    unsigned long arg_end;
...
    struct uprobes_state uprobes_state;
    void *bd_addr;
    atomic_long_t hugetlb_usage;
}
SIZE: 968
```

Afficher la définition d'un symbole

print[/format] symbole

- Affiche la valeur d'un symbole
- Si */format* est spécifié, affiche toutes les valeurs dans ce format (x : hexadecimal, d :décimal).
- Pour les structures, la commande *struct* est plus rapide à utiliser

Afficher la définition d'un symbole

print[/format] symbole

- Affiche la valeur d'un symbole
- Si */format* est spécifié, affiche toutes les valeurs dans ce format (x : hexadecimal, d :décimal).
- Pour les structures, la commande *struct* est plus rapide à utiliser

print

```
crash> print (struct list_head) modules
$11 = {
  next = 0xffffffffc09f2508,
  prev = 0xffffffffc00052c8
}
crash> print/x modules
$12 = {
  next = 0xffffffffc09f2508,
  prev = 0xffffffffc00052c8
}
crash> print/d modules
$13 = {
  next = -1063312120,
  prev = -1073720632
}
crash> print (struct list_head *) modules
$14 = (struct list_head *) 0xffffffffc09f2508
```


THE BEATLES
HELP!

Afficher l'aide en ligne d'une commande

help commande

- Affiche l'aide et les options de la commande

Afficher l'aide en ligne d'une commande

help commande

- Affiche l'aide et les options de la commande

help

```
NAME
  help - get help

SYNOPSIS
  help [command | all] [-<option>]

DESCRIPTION
  When entered with no argument, a list of all currently available crash
  commands is listed.  If a name of a crash command is entered, a man-like
  page for the command is displayed.  If "all" is entered, help pages
  for all commands will be displayed.  If neither of the above is entered,
  the argument string will be passed on to the gdb help command.

  A number of internal debug, statistical, and other dumpfile related
  data is available with the following options:

    -a - alias data
    -b - shared buffer data
    -B - build data
...
```

Et il y en a encore ! !

- foreach
  Applique la commande sur l'ensemble des processus passés en argument.
- mod
  Manipule les modules externes du noyau.
- kmem
  Permet de récupérer les informations sur les structures mémoire du noyau.
- rd
  Lit brutalement la mémoire à l'adresse donnée.
- files
  Liste les fichiers du processus courant
- net
  Manipule les interfaces réseaux.
- gdb
  Crash permet d'appeler des fonctions gdb.
  - gdb list
    Affiche le source d'une fonction.
  - gdb set
    Manipule la mémoire du noyau (DANGEUREUX ! !).

Berkley Packet Filter

Les outils BCC basés sur BPF sont les derniers outils de tracing des fonctions kernel. Ils permettent de façon très efficace de visualiser les fonctions kernel sollicitées à un instant t.

SystemTap

SystèmeTap permet de modifier le comportement du noyau en insérant du code à n'importe quelle adresse.

- Modification de modules
- Visualisation de variables et de structures
- ...

Sommaire

1 Debugger

2 Les instructions

3 Processus utilisateur

4 Noyau

5 Questions

Questions