

Élaboration d'une représentation intermédiaire pour l'exécution concolique et le marquage de données sous Windows

Sébastien LECOMTE

cyberaware@laposte.net

SSTIC

06 *juin* 2014

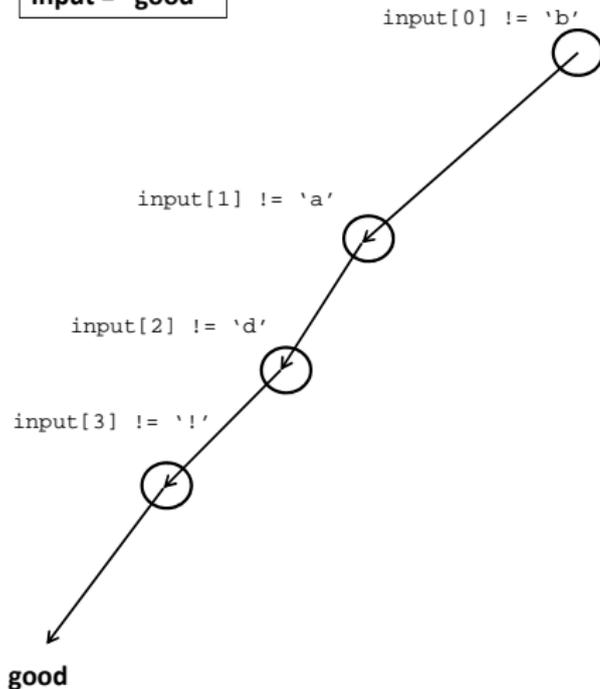
Au commencement...Fuzzgrind

- fuzzer sous architecture GNU/Linux, utilise Valgrind et STP
 - écrit par Gabriel Campana et présenté au SSTIC 2009
 - basé sur l'algorithme SAGE (Patrice Godefroid - *MS Research*)
-
- détection d'1/3 des bugs de Windows Seven
 - résultats encourageants pour Fuzzgrind en 2009
 - **adaptions donc Fuzzgrind aux OS Windows !!**

L'algorithme SAGE

Scalable, Automated, Guided Execution

Input = "good"



```

void test(char *input)
{
    int cnt = 0;

    /* if (!input) return; */

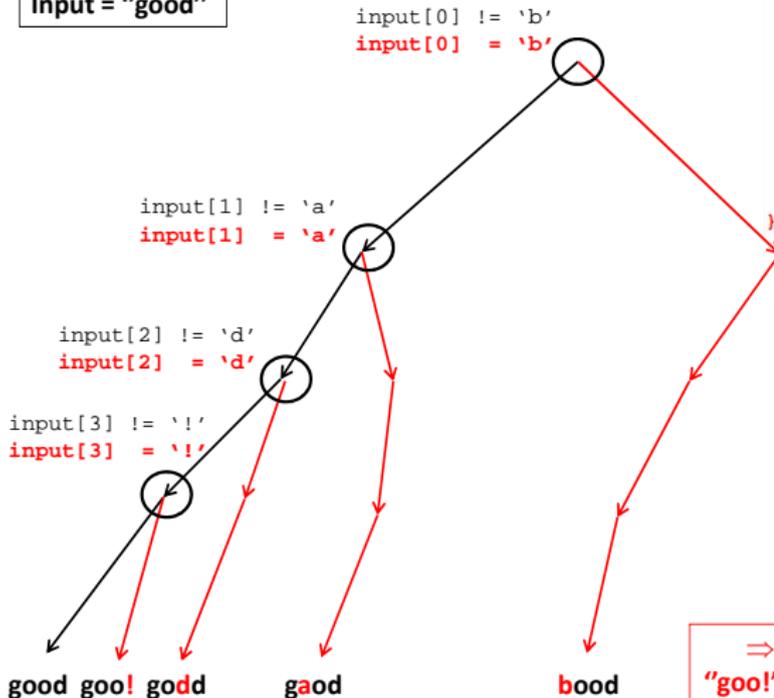
    if (input[0] == 'b') cnt++;
    if (input[1] == 'a') cnt++;
    if (input[2] == 'd') cnt++;
    if (input[3] == '!') cnt++;

    if (cnt > 3) crash();
}
  
```

L'algorithme SAGE

Scalable, Automated, Guided Execution

Input = "good"



```

void test(char *input)
{
    int cnt = 0;

    /* if (!input) return; */

    if (input[0] == 'b') cnt++;
    if (input[1] == 'a') cnt++;
    if (input[2] == 'd') cnt++;
    if (input[3] == '!') cnt++;

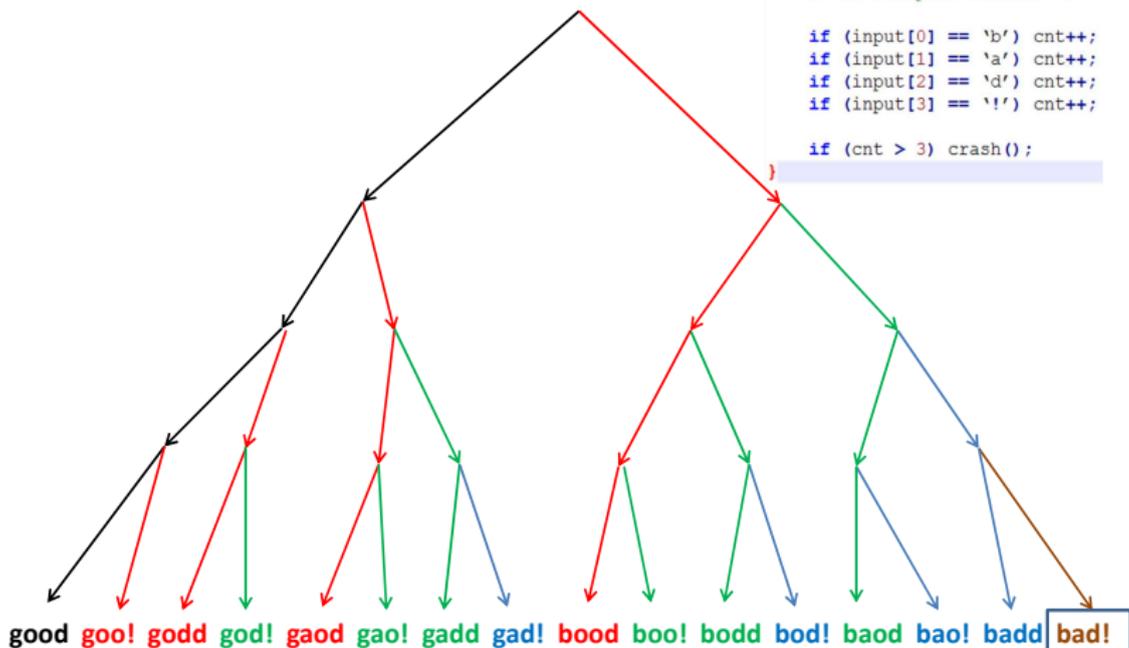
    if (cnt > 3) crash();
}
  
```

⇒ 4 nouvelles entrées :
"goo!" "godd" "gaod" "bood"

L'algorithme SAGE

Scalable, Automated, Guided Execution

```
void test(char *input)
{
    int cnt = 0;
    /* if (!input) return; */
    if (input[0] == 'b') cnt++;
    if (input[1] == 'a') cnt++;
    if (input[2] == 'd') cnt++;
    if (input[3] == '!') cnt++;
    if (cnt > 3) crash();
}
```



Le portage vers Windows

OK

- STP \implies **Z3** (*Microsoft*)
- Valgrind (Instrumentation) \implies **PIN** (*Intel*)

Le portage vers Windows

OK

- STP \implies **Z3** (*Microsoft*)
- Valgrind (Instrumentation) \implies **PIN** (*Intel*)

KO

- Valgrind (VEX) \implies ???
- obligation d'écrire une représentation intermédiaire spécifique, adaptée au marquage de données

Plan

- 1 Introduction
- 2 Représentation intermédiaire**
 - Définitions
 - Création de la représentation intermédiaire
 - Implémentation en C++
 - Exemple : addition 32bits
- 3 Utilisation de PIN
- 4 Application : FuzzWin
- 5 Perspectives

Définition

Marquage de données

Marquage de données - *Data Tainting*

- marque/label sur donnée initiale
- suivi de la propagation au cours de l'exécution
- test du marquage de certaines instructions/branchements
- détection de comportement non souhaité, étude de malware...

Principes

- au moins 1 source marquée => destination(s) marquée(s)
- conservation de l'arithmétique du marquage

Définition

Exécution symbolique

Exécution symbolique

- représentation des instructions et opérandes avec des symboles
- analyse statique ou dynamique
- vérification, détection de fautes, couverture de code...

<code>mov</code>	<code>eax, 1</code>	\longrightarrow	<code>vEAX0 = ASSIGN[Value(1, 32b)]</code>
<code>shl</code>	<code>eax, 1</code>	\longrightarrow	<code>vEAX1 = LEFTSHIFT[vEAX0, Value(0, 8b)]</code>
<code>movsx</code>	<code>edx, byte ptr [ecx+eax]</code>	\longrightarrow	<code>vEDX = SIGNEXT32[ValFromMem(8b)]</code>

Définition

Exécution symbolique

Exécution symbolique

- représentation des instructions et opérandes avec des symboles
- analyse statique ou dynamique
- vérification, détection de fautes, couverture de code...

<code>mov</code>	<code>eax, 1</code>	\longrightarrow	<code>vEAX0 = ASSIGN[Value(1, 32b)]</code>
<code>shl</code>	<code>eax, 1</code>	\longrightarrow	<code>vEAX1 = LEFTSHIFT[vEAX0, Value(0, 8b)]</code>
<code>movsx</code>	<code>edx, byte ptr [ecx+eax]</code>	\longrightarrow	<code>vEDX = SIGNEXT32[ValFromMem(8b)]</code>

Exécution concolique = **concrète** + **symbolique**

Plan

- 1 Introduction
- 2 Représentation intermédiaire**
 - Définitions
 - Création de la représentation intermédiaire**
 - Implémentation en C++
 - Exemple : addition 32bits
- 3 Utilisation de PIN
- 4 Application : FuzzWin
- 5 Perspectives

Représentation intermédiaire

- plusieurs représentations existantes : Miasm, Metasm, REIL...
- le choix a été fait de construire une représentation spécifique
 - > données dynamiques fournies par PIN
 - > seules les instructions marquées seront représentées

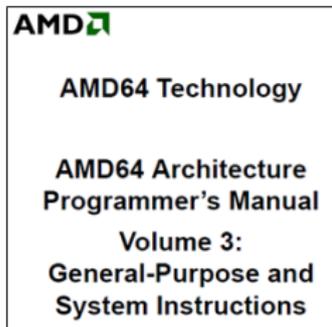
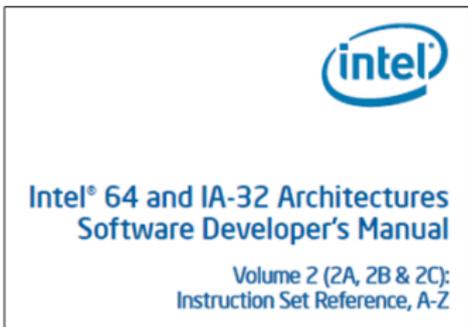
- représentation intermédiaire et non langage intermédiaire
- représentation générique, plusieurs traductions possibles
- 1 traduction implémentée : langage SMT-LIB V2

Représentation intermédiaire

Toutes les instructions suivent le même schéma :



Les sources, destinations et (*presque*) tous les effets sont documentés par les constructeurs



Plan

- 1 Introduction
- 2 Représentation intermédiaire**
 - Définitions
 - Création de la représentation intermédiaire
 - Implémentation en C++**
 - Exemple : addition 32bits
- 3 Utilisation de PIN
- 4 Application : FuzzWin
- 5 Perspectives

Implémentation en C++

Variables symboliques

Classe *TaintObject*

- valeur symbolique d'un emplacement (reg/mem/flag)
- 4 caractéristiques
 - longueur en bits
 - relation qui lie la variable à ses sources
 - sources de la variable
 - nom de la variable lorsqu'elle est traduite

Classe *ObjectSource*

source utilisée dans un *TaintObject*

- si la source est marquée : *TaintObject* associé
- sinon, valeur numérique (*concrète*) de la source

Implémentation en C++

Variables symboliques

```
shl    eax, 1    vEAX1 = LEFTSHIFT[vEAX0, Value(1, 8b)]
```

```
TaintObject vEAX1
```

```
_len = 32
_relation = X_SHL
_src = {ObjectSource(vEAX0), ObjectSource(8bits, 1)}
_name = ""
```

Implémentation en C++

Représentation du contexte d'exécution

classes *TaintManager_XX*

- association des *TaintObject* au contexte d'exécution
- si emplacement marqué : pointeur vers *TaintObject*, sinon *nullptr*

Classe *TaintManager_Thread*

- gestion des registres généraux + Flags
- 1 classe par thread d'exécution

Classe *TaintManager_Global*

- table de hachage pour l'association adresse/*TaintObject*
- crée les premiers objets marqués (lecture fichier en mémoire)

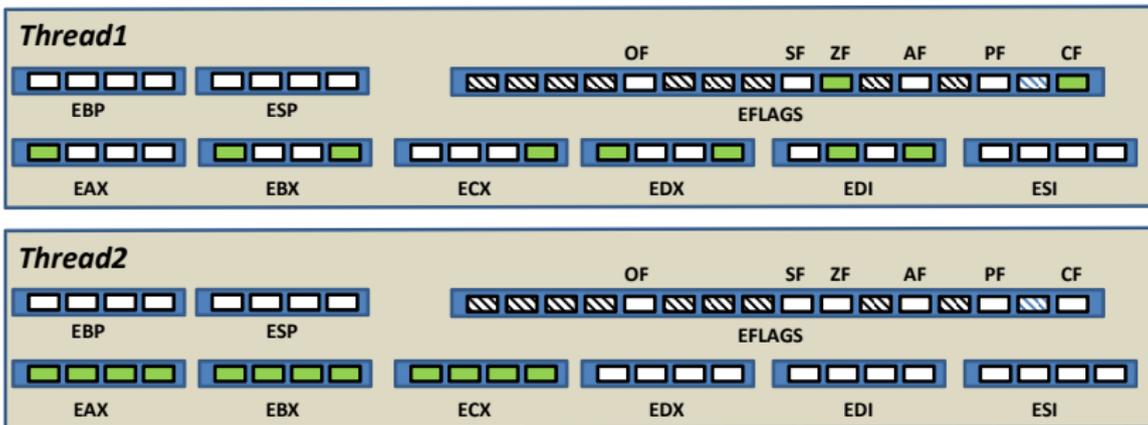
Implémentation en C++

Représentation du contexte d'exécution

TaintManager_Global



TaintManager_Thread



Implémentation en C++

Granularité du marquage

Choix de la granularité

- compromis à trouver entre fidélité et performances
- choix d'un suivi au niveau de l'**octet** (hormis flags)
 - taille minimale d'une opérande x86
 - adapté au marquage initial des données depuis un fichier
- surmarquage principalement dû aux opérations logiques

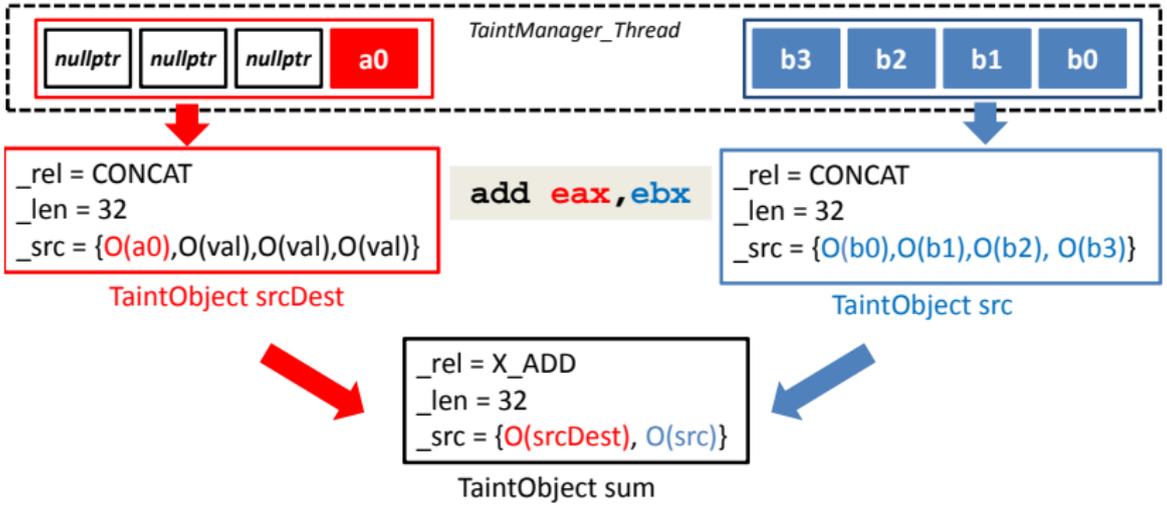
Relations spéciales

- *"CONCAT"* et *"EXTRACT"*
- *"BYTESOURCE"* pour les octets du fichier d'entrée

Plan

- 1 Introduction
- 2 Représentation intermédiaire**
 - Définitions
 - Création de la représentation intermédiaire
 - Implémentation en C++
 - Exemple : addition 32bits**
- 3 Utilisation de PIN
- 4 Application : FuzzWin
- 5 Perspectives

Exemple : addition 32bits



Exemple : addition 32bits

```

_rel = X_ADD
_len = 32
_src = {O(srcDest), O(src)}

```

TaintObject sum

TaintObject sum3

```

_rel = EXTRACT
_len = 8
_src = {O(sum),O(3)}

```

TaintObject sum2

```

_rel = EXTRACT
_len = 8
_src = {O(sum),O(2)}

```

TaintObject sum1

```

_rel = EXTRACT
_len = 8
_src = {O(sum),O(1)}

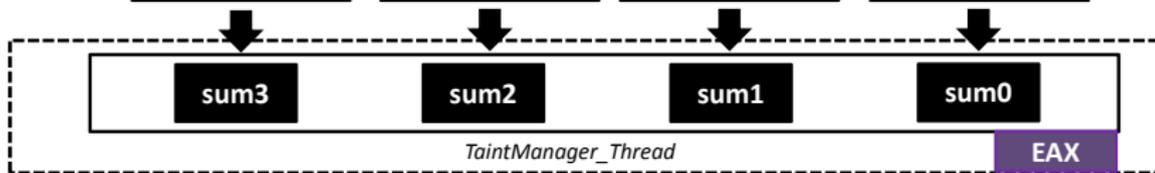
```

TaintObject sum0

```

_rel = EXTRACT
_len = 8
_src = {O(sum),O(0)}

```



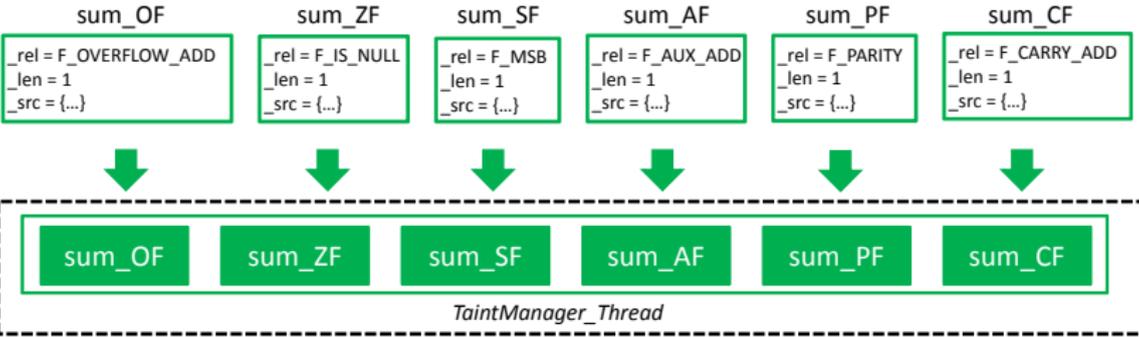
Exemple : addition 32bits

```

_rel = X_ADD
_len = 32
_src = {O(srcDest), O(src)}

```

TaintObject sum



Présentation de PIN

PIN

- *Framework* d'instrumentation dynamique développé par Intel
- multiplateformes : GNU/Linux, Windows, MacOS, x86/x64
- recompile et exécute le binaire (JIT) après insertions de *hooks* définis par l'utilisateur (*pintool*)
- forum d'utilisateurs et API bien documentée
- cf. présentation de Gal Diskin à HITB 2012

Utilisation de PIN

Détail de l'instrumentation

Instrumentation mise en place

suivi des évènements utiles

- début/fin de chaque *thread* (gestion du contexte associé)
- exécution des appels systèmes (marquage initial)
- exécution de chaque instruction (propagation du marquage)

Utilisation de PIN

instrumentation des appels système

Appels système

- instrumentation avant et après exécution
- suivi des *handles* vers les fichiers suivis
(*NtOpenFile*, *NtCreateFile*, *NtOpenSection*, *NtClose*)
- suivi de l'offset de lecture associé
(*NtSetInformationFile*)
- marquage de la mémoire après lecture via un *handle* suivi
(*NtReadFile*, *NtMapViewOfSection*)

Utilisation de PIN

instrumentation des instructions

Instructions

- ne démarre que lorsque les premières données sont lues
- PIN fournit les informations dynamiques nécessaires (thread, opcode, type de sources et valeur avant ou après exécution, branchement pris ou non, ...)
- fonction dédiée pour chaque cas (IR, IM, MR, RM, RR)
- traitement de certains cas particuliers
 - opérations logiques avec 0 ou 0xff
 - décalage et rotations multiples de 8 bits
 - idiome de démarquage (xor eax,eax ...)

FuzzWin

Rappel des objectifs

- détecter si les instructions de branchement sont contrôlables
- instructions surveillées : *Jcc*, *CMOVcc*, *CALL*

Si branchement marqué. . .

- formule symbolique déterminant le branchement
- inversion de la valeur du branchement à l'exécution
- recherche d'une solution grâce à un solveur de contraintes

DÉMO !!!

Perspectives

Travaux en cours

En cours...

- contraintes sur divisions (nullité et débordement)
- adressage indirect des architectures x86
ex : `mov eax, [ebx]` \implies *quid* si ebx marqué ??
- amélioration de la finesse d'exécution
 - marquage limité à une bibliothèque
 - marquage limité à une fonction spécifique du binaire
- Enrichissement du langage
 - instructions SIMD sur les entiers (MMX, SSE...)
 - instructions sur les réels

Perspectives

Évolutions possibles

Parmi les idées...

- méthode de gestion des boucles (analyse statique ?)
- détection *Heap/stack overflow*, *UAF*...
⇒ blog de Jonathan Salwan (www.shell-storm.org)
- implémentation autre traduction (langage C)
- instrumentation en *ring0*

Merci de votre attention !!

