Déprotection semi-automatique de binaire

avec *Metasm* : celui qui fond dans la bouche et pas dans la main.

Alexandre Gazet
Yoann Guillot

Plan

Plan

Metasm

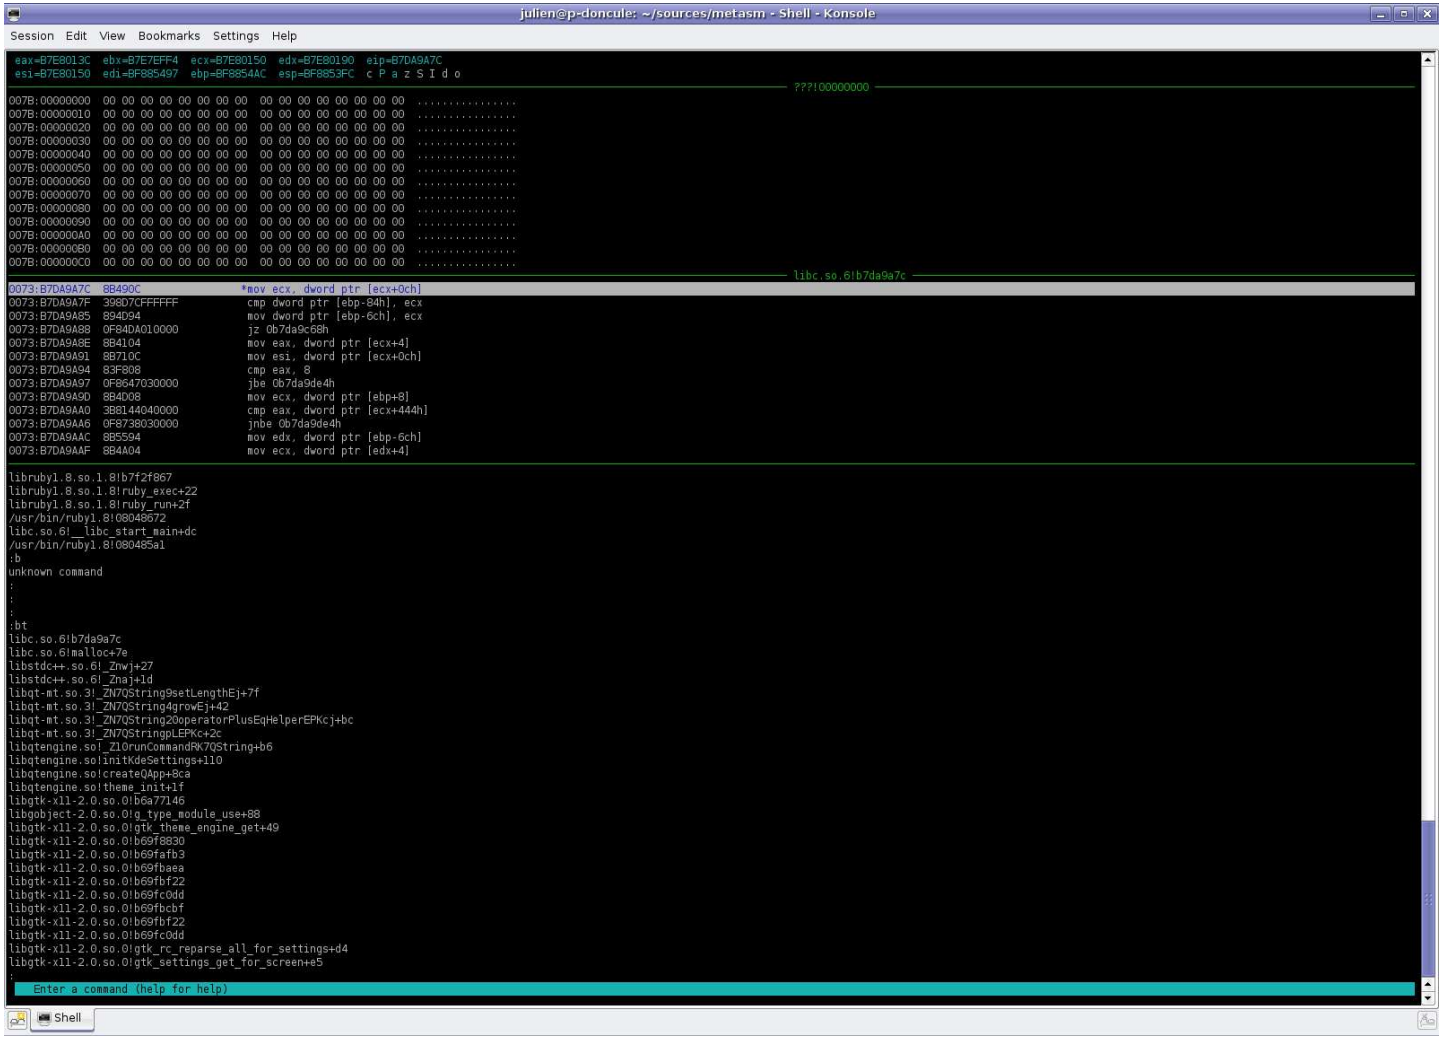
julien@p-doncule: ~/sources/metasm - Shell - Konsole
Session Edit View Bookmarks Settings Help
eax=B7E8013C ebx=B7E7EFF4 ecx=B7E80150 edx=B7E80190 eip=B7DA9A7C
esi=B7E80150 edi=BF885497 ebp=BF8854AC esp=BF8853FC c P a z S I d o
???!00000000
007B:00000000 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 ....
007B:00000010 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 ....
007B:00000020 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 ....
007B:00000030 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 ....
007B:00000040 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 ....
007B:00000050 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 ....
007B:00000060 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 ....
007B:00000070 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 ....
007B:00000080 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 ....
007B:00000090 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 ....
007B:000000A0 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 ....
007B:000000B0 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 ....
007B:000000C0 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 ....
libc.so.6!b7da9a7c
0073:B7DA9A7C 8B490C *mov ecx, dword ptr [ecx+0ch]
0073:B7DA9A7F 398D7CFFFFFF cmp dword ptr [ebp-84h], ecx
0073:B7DA9A85 894D94 mov dword ptr [ebp-6ch], ecx
0073:B7DA9A88 0F84DA010000 jz 0b7da9c68h
0073:B7DA9A8E 8B4104 mov eax, dword ptr [ecx+4]
0073:B7DA9A91 8B710C mov esi, dword ptr [ecx+0ch]
0073:B7DA9A94 83F808 cmp eax, 8
0073:B7DA9A97 0F8647030000 jbe 0b7da9de4h
0073:B7DA9A9D 8B4D08 mov ecx, dword ptr [ebp+8]
0073:B7DA9AA0 3B8144040000 cmp eax, dword ptr [ecx+444h]
0073:B7DA9AA6 0F8738030000 jnbe 0b7da9de4h
0073:B7DA9AAC 8B5594 mov edx, dword ptr [ebp-6ch]
0073:B7DA9AAF 8B4A04 mov ecx, dword ptr [edx+4]
libruby1.8.so.1.8!b7f2f867
libruby1.8.so.1.8!ruby_exec+22
libruby1.8.so.1.8!ruby_run+2f
/usr/bin/ruby1.8!08048672
libc.so.6!__libc_start_main+dc
/usr/bin/ruby1.8!080485a1
:b
unknown command
:bt
libc.so.6!b7da9a7c
libc.so.6!malloc+7e
libstdc++.so.6!_Znwj+27
libstdc++.so.6!_Znaj+1d
libqt-mt.so.3!_ZN7QString9setLengthEj+7f
libqt-mt.so.3!_ZN7QString4growEj+42
libqt-mt.so.3!_ZN7QString20operatorPlusEqHelperEPKcj+bc
libqt-mt.so.3!_ZN7QStringpLEPKc+2c
libqtengine.so!_Z10runCommandRK7QString+b6
libqtengine.so!initKdeSettings+110
libqtengine.so!createQApp+8ca
libqtengine.so!theme_init+1f
libgtk-x11-2.0.so.0!b6a77146
libgobject-2.0.so.0!g_type_module_use+88
libgtk-x11-2.0.so.0!gtk_theme_engine_get+49
libgtk-x11-2.0.so.0!b69f8830
libgtk-x11-2.0.so.0!b69fafb3
libgtk-x11-2.0.so.0!b69fbaea
libgtk-x11-2.0.so.0!b69fbf22
libgtk-x11-2.0.so.0!b69fc0dd
libgtk-x11-2.0.so.0!b69fbcbf
libgtk-x11-2.0.so.0!b69fbf22
libgtk-x11-2.0.so.0!b69fc0dd
libgtk-x11-2.0.so.0!gtk_rc_reparse_all_for_settings+d4
libgtk-x11-2.0.so.0!gtk_settings_get_for_screen+e5
Enter a command (help for help)
Shell

Metasm

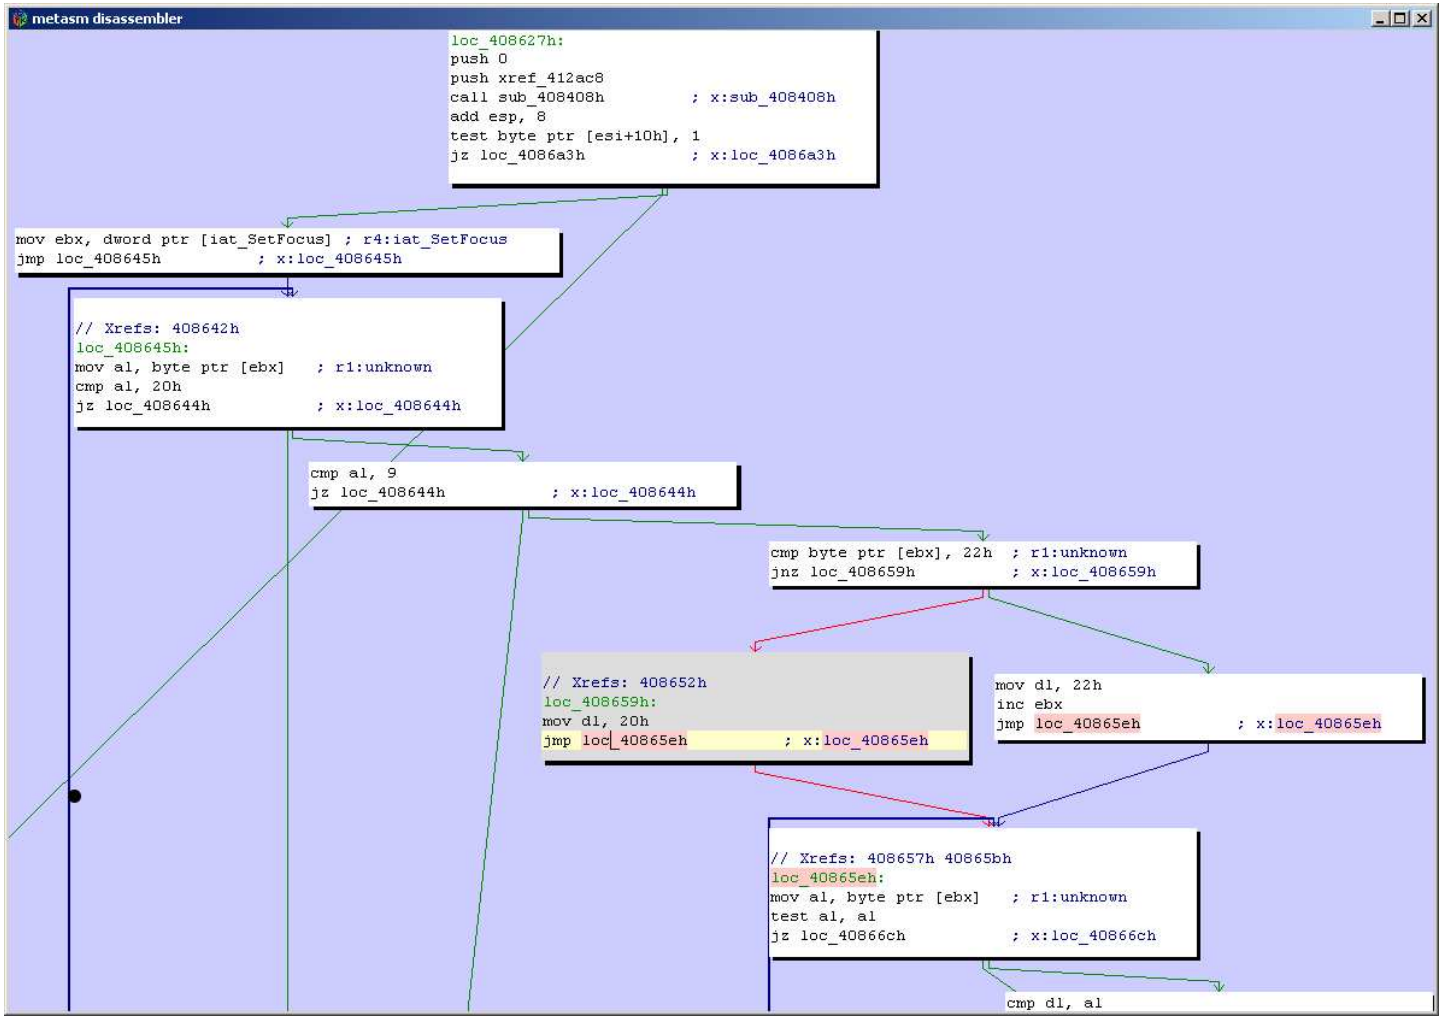
metasm disassembler
loc_408627h:
push 0
push xref_412ac8
call sub_408408h ; x:sub_408408h
add esp, 8
test byte ptr [esi+10h], 1
jz loc_4086a3h ; x:loc_4086a3h
mov ebx, dword ptr [iat_SetFocus] ; r4:iat_SetFocus
jmp loc_408645h ; x:loc_408645h
// Xrefs: 408642h
loc_408645h:
mov al, byte ptr [ebx] ; r1:unknown
cmp al, 20h
jz loc_408644h ; x:loc_408644h
cmp al, 9
jz loc_408644h ; x:loc_408644h
cmp byte ptr [ebx], 22h ; r1:unknown
jnz loc_408659h ; x:loc_408659h
// Xrefs: 408652h
loc_408659h:
mov dl, 20h
jmp loc_40865eh ; x:loc_40865eh
mov dl, 22h
inc ebx
jmp loc_40865eh ; x:loc_40865eh
// Xrefs: 408657h 40865bh
loc_40865eh:
mov al, byte ptr [ebx] ; r1:unknown
test al, al
jz loc_40866ch ; x:loc_40866ch
cmp dl, al

Désassemblage

La référence : **IDA Pro**

- Excellent sur du code *clair* : binaire `MS`
- Inadapté sur un binaire protégé
  - Pas d'interprétation du code
  - Des hypothèses trop contraignantes

Des hypothèses

- Les deux branches d'un saut conditionnel sont exécutées
- Deux instructions ne se superposent pas
- Un appel retourne

Désassemblage

La référence : **IDA Pro**

- Excellent sur du code *clair* : binaire `MS`
- Inadapté sur un binaire protégé
  - Pas d'interprétation du code
  - Des hypothèses trop contraignantes

Des hypothèses

- Les deux branches d'un saut conditionnel sont exécutées
- Deux instructions ne se superposent pas
- Un appel retourne

Hypothèse : un appel retourne

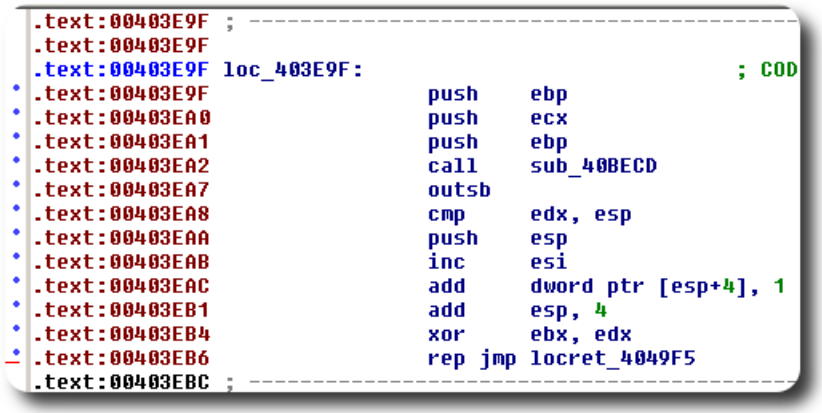


```
.text:00403E9F loc_403E9F:      ; CODE XREF: .text:loc_40CDEF
.text:00403E9F                  push    ebp
.text:00403EA0                  push    ecx
.text:00403EA1                  push    ebp
.text:00403EA2                  call    sub_40BECD
.text:00403EA7                  outsb
.text:00403EA8                  cmp     edx, esp
.text:00403EAA                  push    esp
.text:00403EAB                  inc     esi
```

Mise en échec

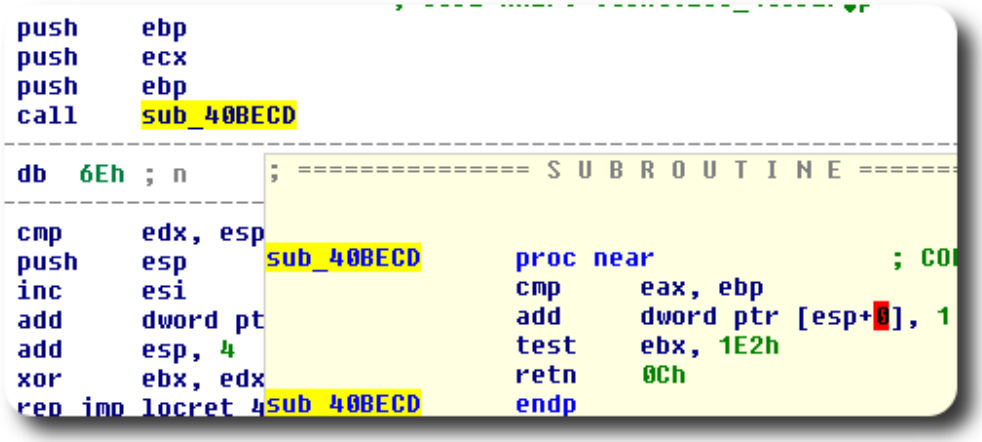


```
.text:0040BECD sub_40BECD      proc near      ; CODE XREF: .text:00403EA2

.text:0040BECD                 cmp     eax, ebp
.text:0040BECF                 add     dword ptr [esp+0], 1
.text:0040BED4                 test    ebx, 1E2h
.text:0040BEDA                 retn    0Ch

.text:0040BEDA sub_40BECD      endp
```

Binding

Définition

Expression symbolique des effets d'une instruction ; à chaque instruction est associée sa sémantique.

Instruction **ADD** :

```
a = di.instruction.args.map

res = Expression[[a[0], :&, mask], :+, [a[1], :&, mask]]

binding[:eflag_z] = Expression[[res, :&, mask], :==, 0]
binding[:eflag_s] = sign[res]
binding[:eflag_c] = Expression[res, :>, mask]
binding[:eflag_o] = Expression[[sign[a[0]], :==, sign[a[1]]],
            :'&&', [sign[a[0]], :'!=', sign[res]]]

binding[instr] ={ a[0] => res }
```

Binding

Instruction CALL :

```
addrReturn = Expression[Expression[di.address, :+, di.bin_length].reduce] }
binding = {
    :esp => Expression[:esp, :-, opsz],
    Indirection[:esp, opsz, di.address] => addrReturn
}
```

En pratique :

```
dword ptr [esp] = 0x4010CE
esp = esp-4
```

Instruction RDTSC :

```
binding = {
    :eax => Expression::Unknown,
    :edx => Expression::Unknown
}
```

Binding

Instruction CALL :

```
addrReturn = Expression[Expression[di.address, :+, di.bin_length].reduce] }
binding = {
    :esp => Expression[:esp, :-, opsz],
    Indirection[:esp, opsz, di.address] => addrReturn
}
```

En pratique :

```
dword ptr [esp] = 0x4010CE
esp = esp-4
```

Instruction RDTSC :

```
binding = {
    :eax => Expression::Unknown,
    :edx => Expression::Unknown
}
```

Binding

Instruction CALL :

```
addrReturn = Expression[Expression[di.address, :+, di.bin_length].reduce] }
binding = {
    :esp => Expression[:esp, :-, opsz],
    Indirection[:esp, opsz, di.address] => addrReturn
}
```

En pratique :

```
dword ptr [esp] = 0x4010CE
esp = esp-4
```

Instruction RDTSC :

```
binding = {
     :eax => Expression::Unknown,
     :edx => Expression::Unknown
}
```

Backtracing, la théorie

Définition

Émulation symbolique par remontée du flot d'instructions.

Backtracing, la pratique

Flot d'exécution :

```
call loc_40becdh                ; @403ea2h  e826800000
cmp eax, ebp                    ; @40becdh  39e8
add dword ptr [esp+0], 1        ; @40becfh  8344240001
test ebx, 1e2h                  ; @40bed4h  f7c3e2010000
ret 0ch                         ; @40bedah  c20c00
```

Backtracing x dword ptr [esp] for 40bedah ret 0ch

1. backtrace 40becfh add dword ptr [esp+0], 1
   dword ptr [esp] => dword ptr [esp]+1
2. backtrace up 40becdh->403ea2h dword ptr [esp]+1
3. backtrace 403ea2h call loc_40becdh
   dword ptr [esp]+1 ⇒ 403ea8h
4. backtrace result : 403ea8h

Metasm

Listing produit :

```
loc_403e9fh:
    push ebp                    ; @403e9fh  55
    push ecx                    ; @403ea0h  51
    push ebp                    ; @403ea1h  55
    call loc_40becdh            ; @403ea2h  e826800000  noreturn
db 6eh                          ; @403ea7h

// Xrefs: 40bedah
loc_403ea8h:
    cmp edx, esp                ; @403ea8h  39e2
    push esp                    ; @403eaah  54
[...]
- - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - -
// Xrefs: 403ea2h
loc_40becdh:
    cmp eax, ebp                ; @40becdh  39e8
    add dword ptr [esp+0], 1    ; @40becfh  8344240001
    test ebx, 1e2h              ; @40bed4h  f7c3e2010000
    ret 0ch                     ; @40bedah  c20c00  x:loc_403ea8h
```

Plan

Securitech 2006 - Challenge 10

Poeut.exe

- Binaire massivement obfusqué
- **IDA** dépassé
- **Metasm** désassemble parfaitement mais :
  - Reordonnancement des blocs d'instructions
  - $\Rightarrow$ nécessité de développer un *front-end* graphique

yEd - Graph Editor

- Visualisation de graphes
- Utilise un fichier *graphml*
- Objets internes de **Metasm** les *InstructionBlock*

Graphe sauvage

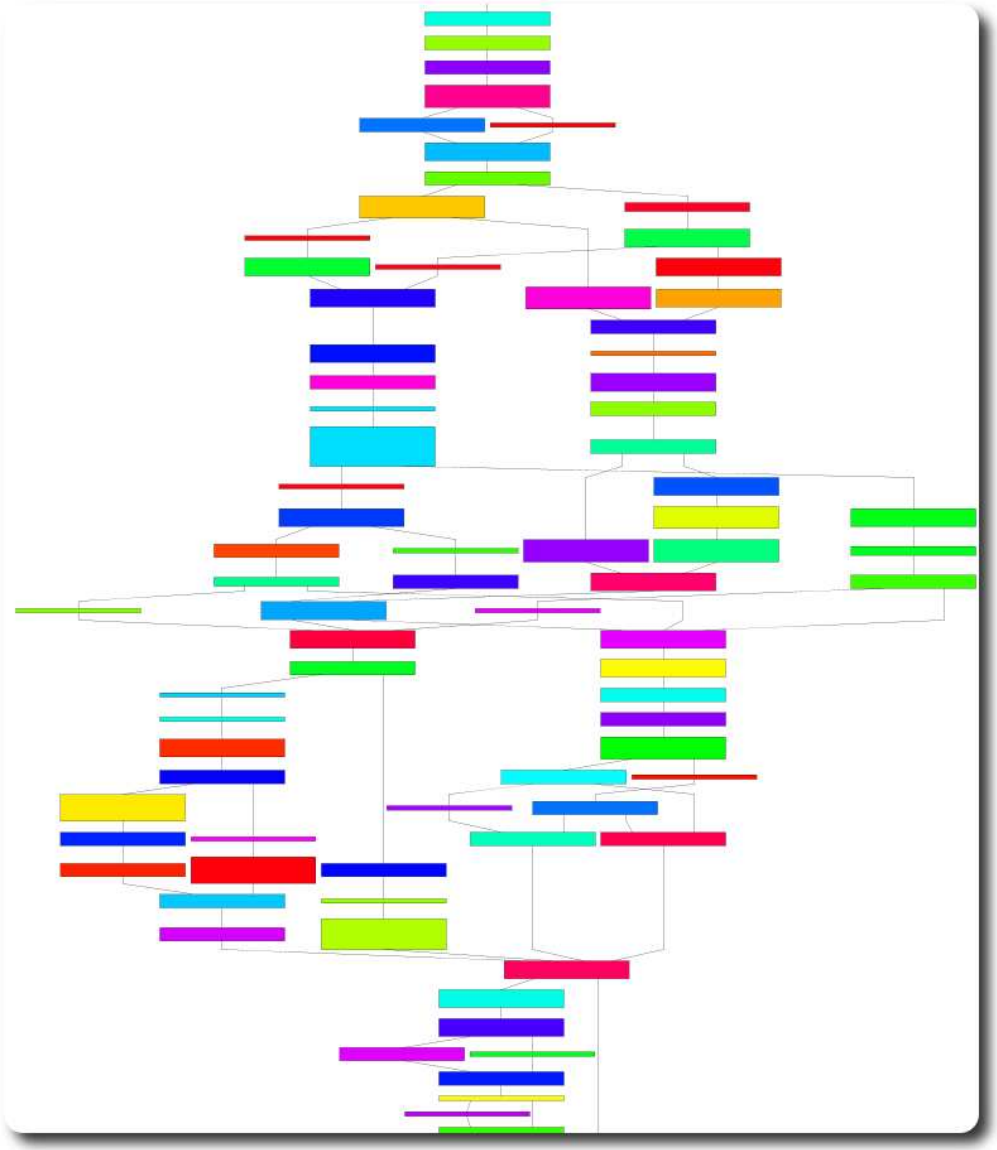

Prédicats biaisés

Prédicats obscurs

- La fonction prédicat renvoie toujours vrai ou toujours faux
- Prédicats résistants à une analyse manuelle/statique
- Une des deux branches n'est jamais exécutée

```
if( x^4 * (x-5)^2 >= 0){
    goto real_code;
}else{
    goto no_where;
}
```

```
fstp qword ptr [esp+8]
fstp qword ptr [esp]
call thunk_pow
fstp qword ptr [ebp-0x20]
mov eax, dword ptr [ebp-0ch]
sub eax, 5
push eax
fild dword ptr [esp]
lea esp, dword ptr [esp+4]
fld qword ptr [xref_8048590h]
fstp qword ptr [esp+8]
fstp qword ptr [esp]
call thunk_pow
fld qword ptr [ebp-20h]
fmulp ST(1)
```

Prédicats biaisés

Aléa total

- La fonction prédicat renvoie indifféremment vrai ou toujours faux
- Les sémantiques des deux branches sont équivalentes

```
if( rand() %2 ) {
    real_code_A;
} else {
    real_code_B;
}
```

Duplication de flot

Insertion massive d'aléa total :

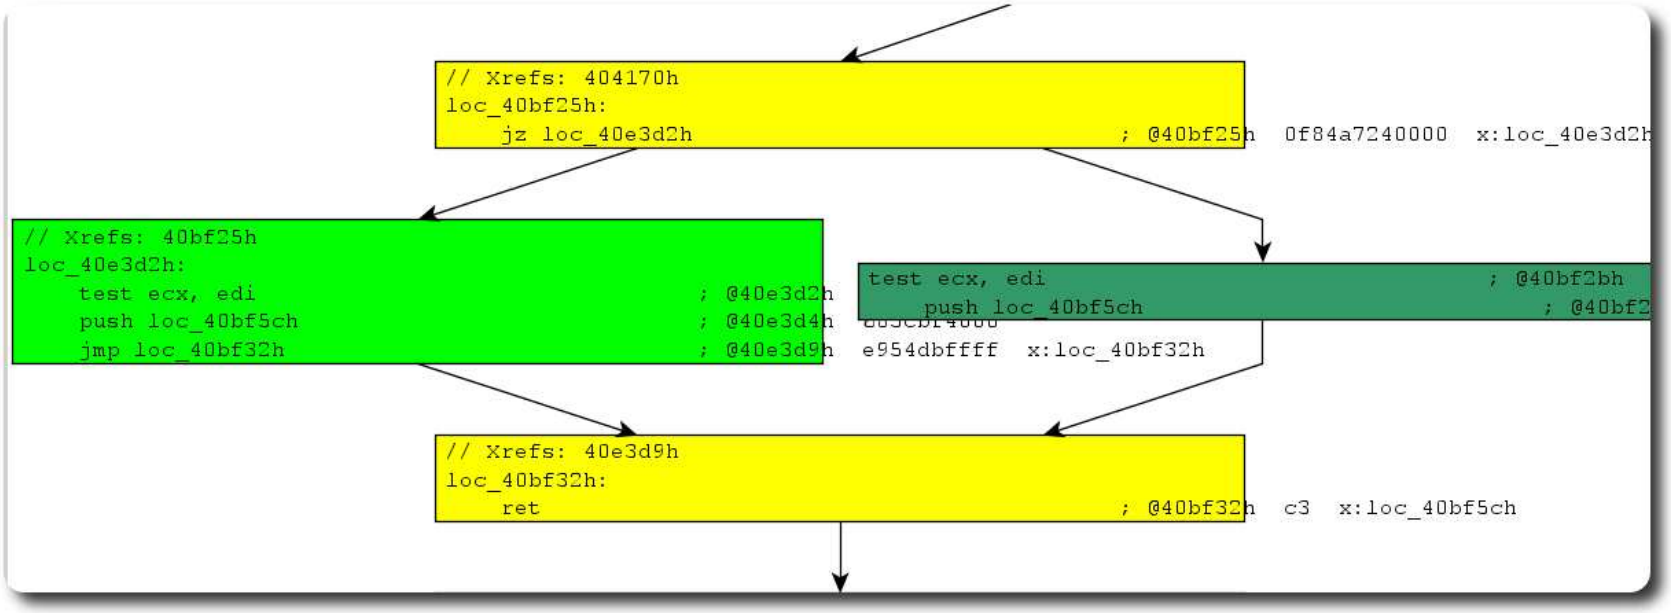

Constructions en *diamant*.

Éléments neutres

Définition

Instruction ou groupe d'instructions ayant une sémantique nulle : aucun impact réel sur le contexte d'exécution.

Éléments neutres : aléa apparent

Implémentation :

```
test esp, ebx                          ; @402039h  85e3
cmp ebx, edx                           ; @40203bh  39d3
mov byte ptr [edx], al                 ; @40203dh  8802
add dword ptr [esp+0], 6               ; @40203fh  8344240006
inc edx                                ; @402044h  42
jmp loc_40b25dh                        ; @402045h  e913920000
```

Réponse au problème

- Utilisation du binding des instructions
- Incohérences du *data flow* au niveau des *flags* :
  - Deux écritures successives
  - Écriture mais pas de lecture

Éléments neutres : faux appels

Implémentation :

```
push eax                ; @408dadh  50
push ecx                ; @408daeh  51
push ebp                ; @408dafh  55
[...]
call loc_4037f2h        ; @40932fh
[...]
push esp                        ; @4037f4h  54
push ecx                        ; @4037f5h  51
[...]
add dword ptr [esp+8], 9        ; @4037f9h  8344240809
add esp, 8                      ; @403800h  83c408
[...]
ret 0ch                 ; @403808h  c20c00  x:loc_40933dh
```

Réponse au problème

- Création du flot d'exécution
- *Simulation* d'une pile
- *Pattern* particulier : modifie l'adresse de retour

Épilogue brut

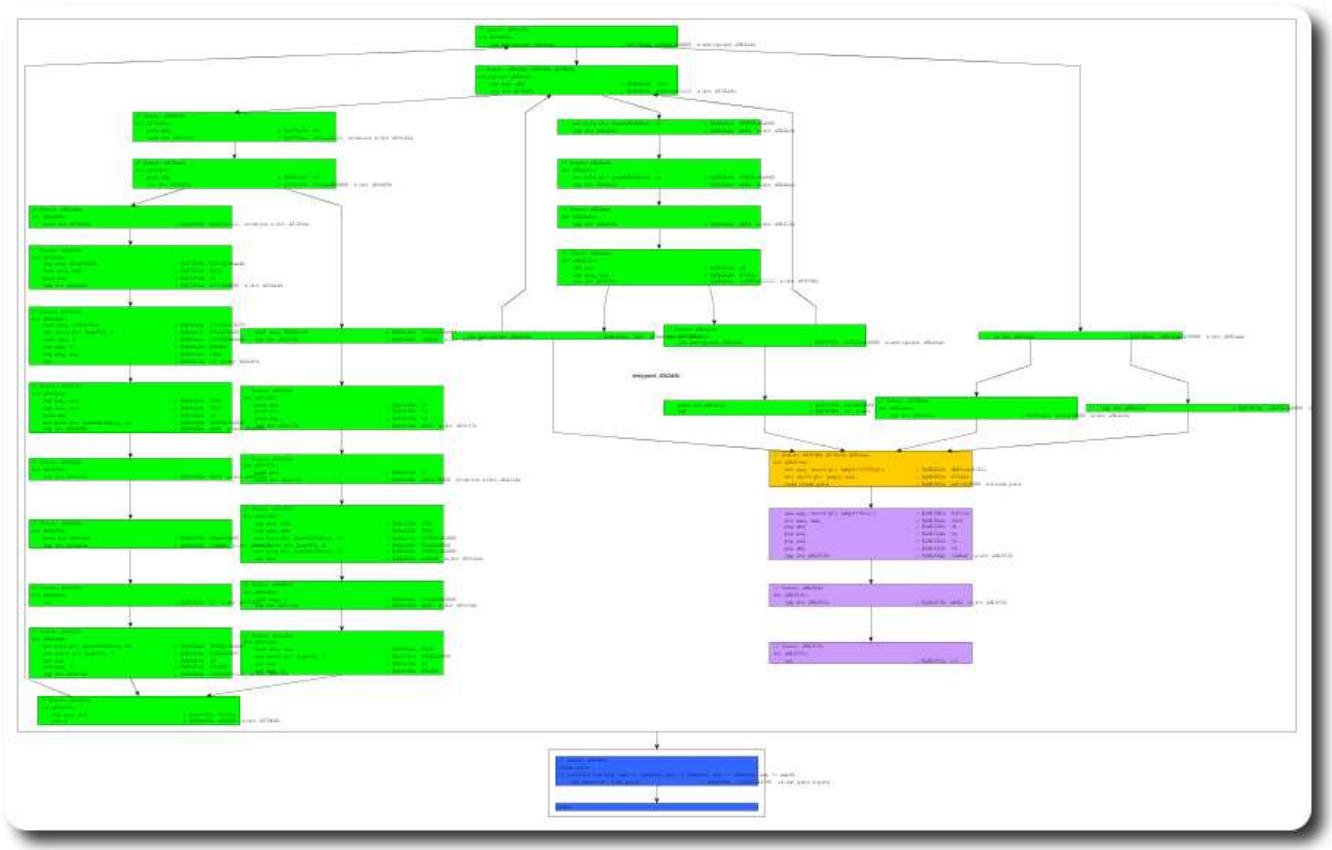

Analyse des flots d'exécution

Réponse au problème

1. Parcours de l'arbre d'objets internes `InstructionBlock`
2. Inline de fonction si nécessaire
3. Recherche de constructions en *diamant*
4. Création, nettoyage puis comparaison des flots
5. Factorisation si nécessaire

Épilogue avec flots factorisés

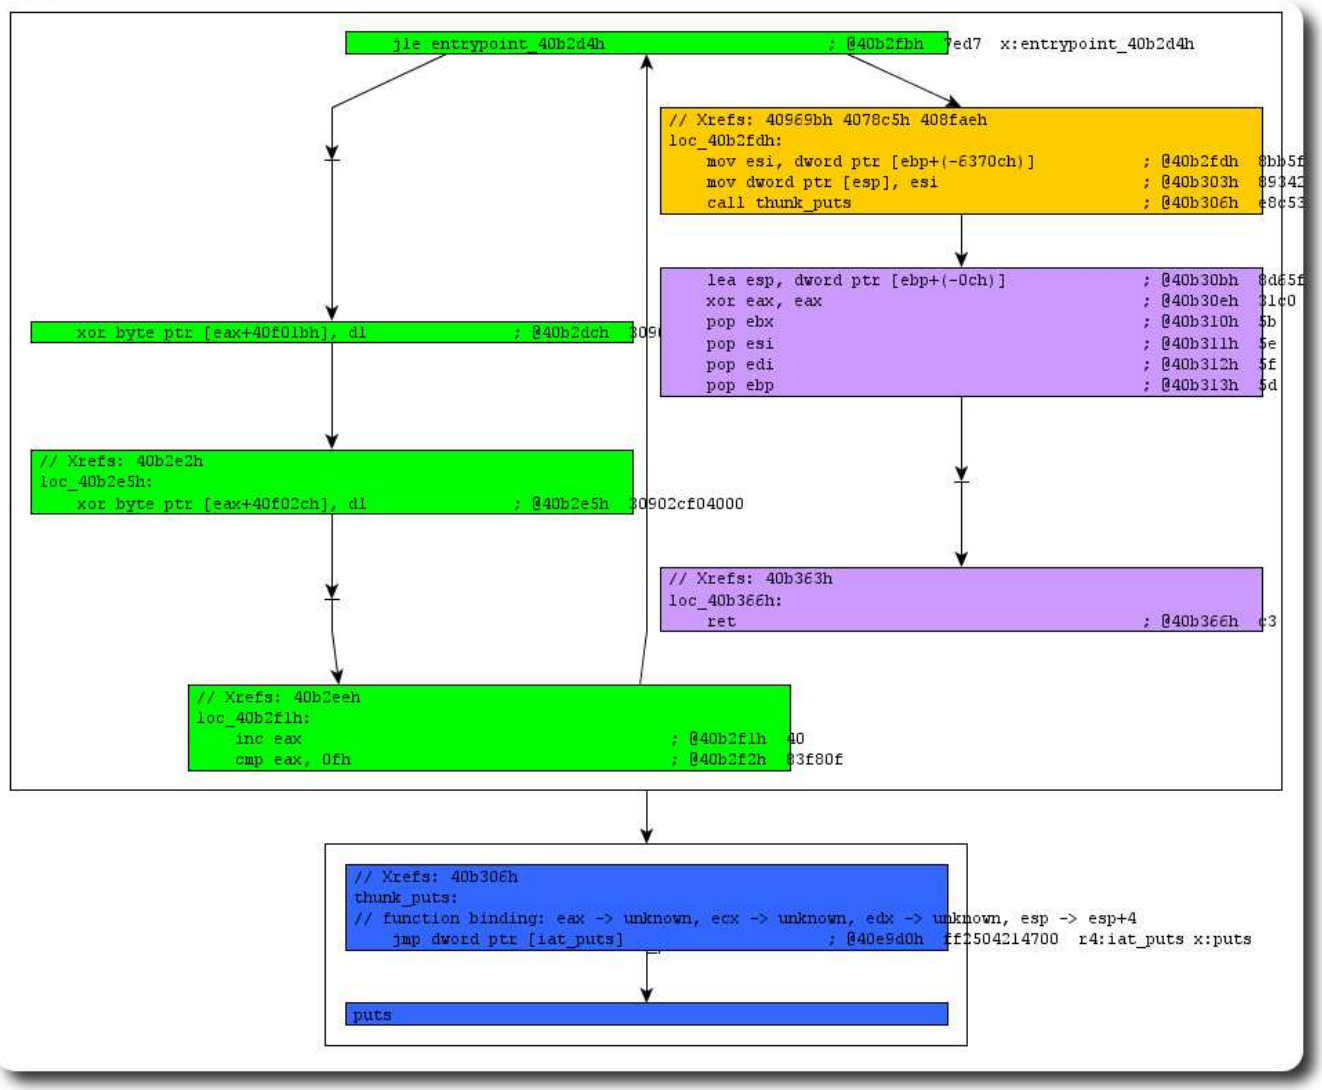

Épilogue réordonné

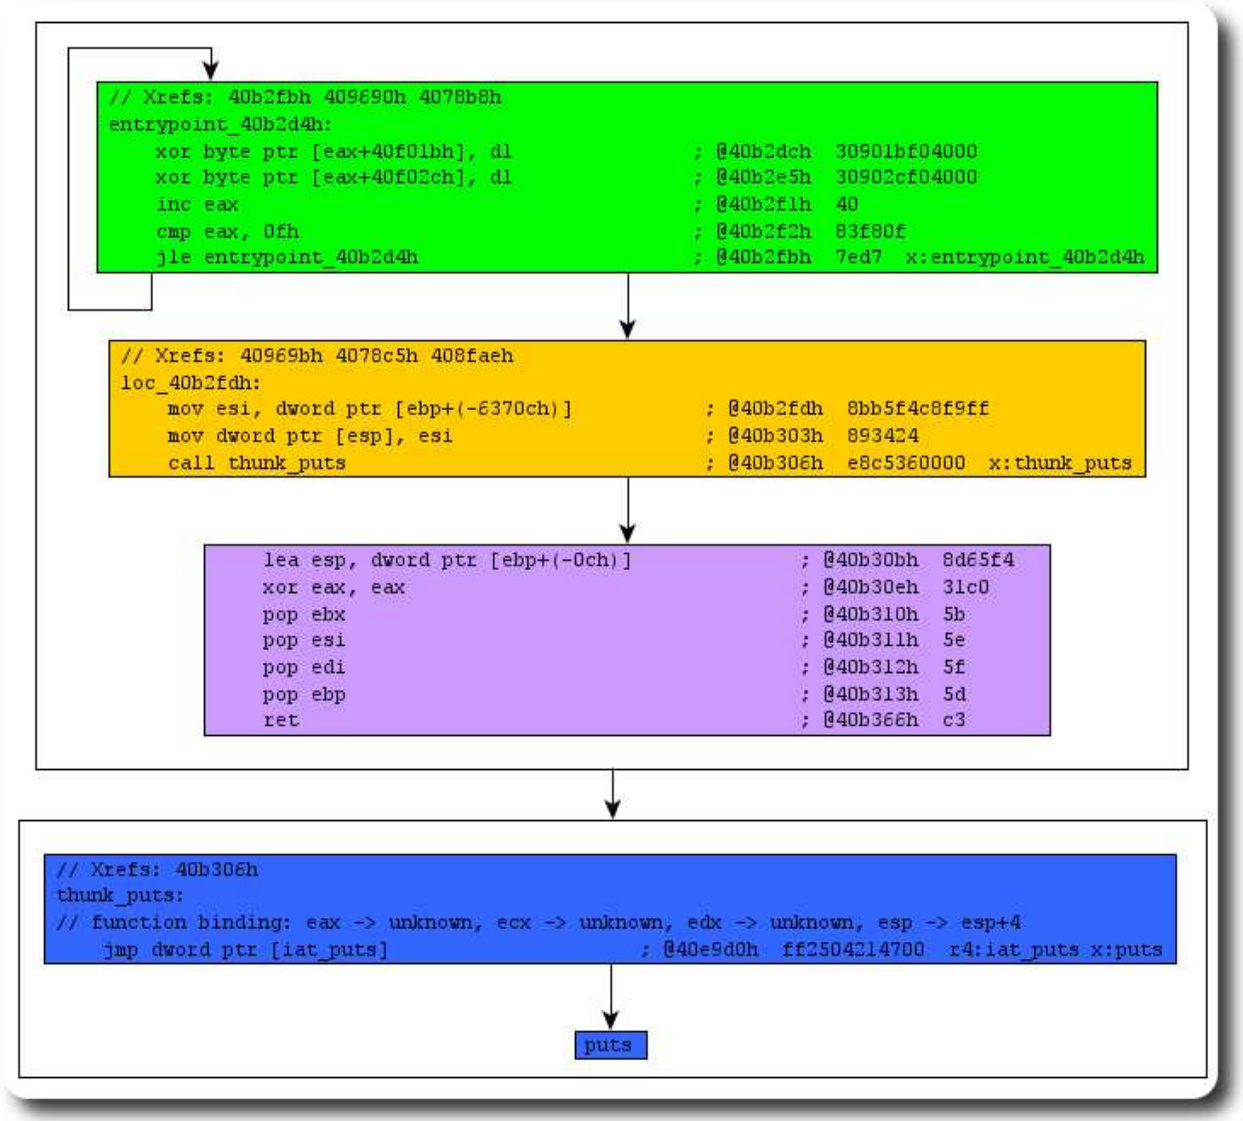

Vue finale

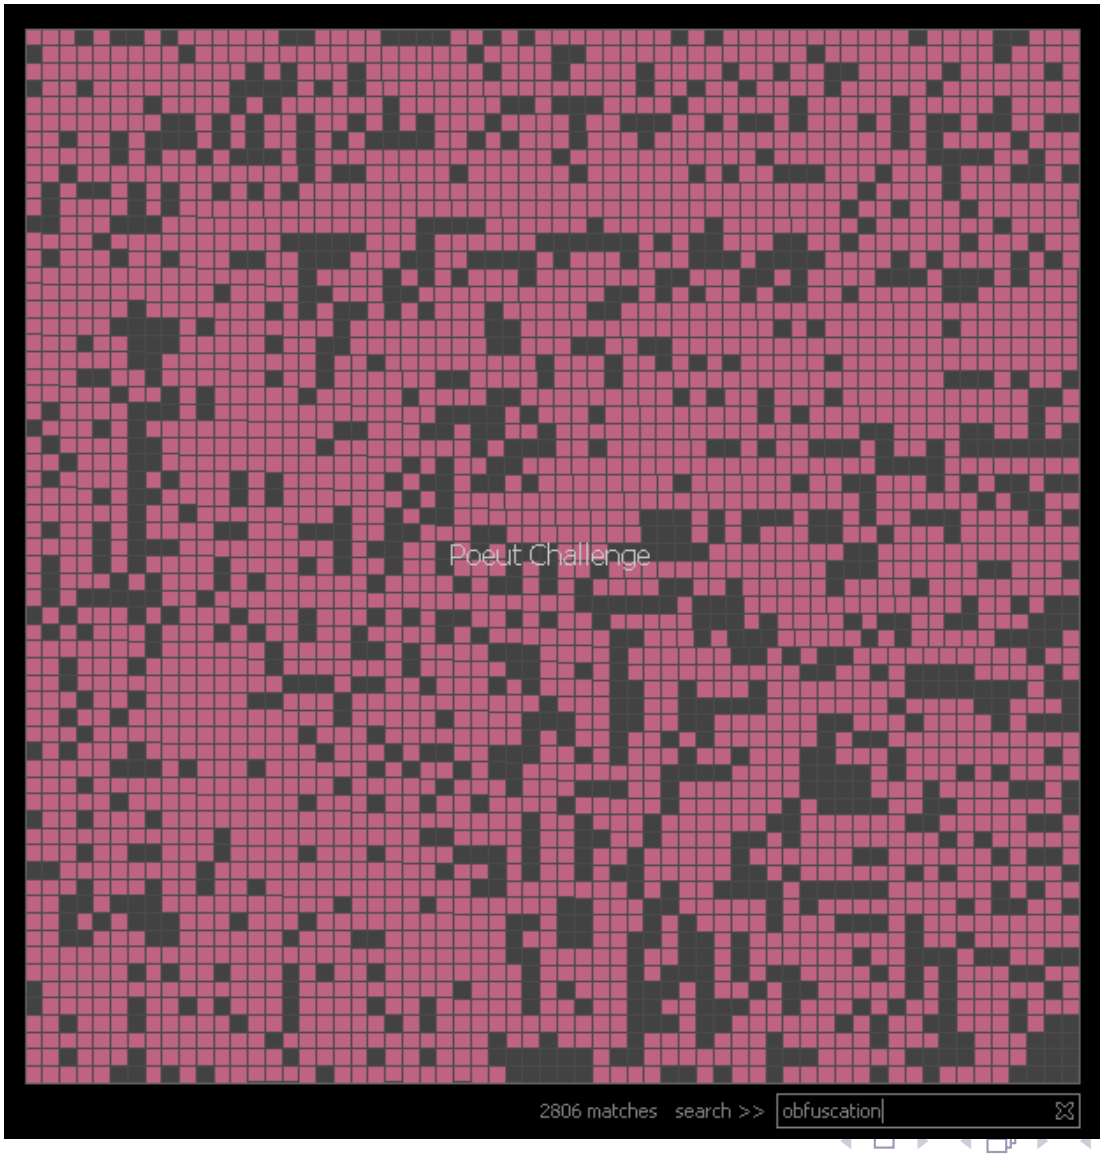

Touche finale

- Nettoyage de tout le graphe du binaire
- Production d'un listing assembleur propre
- Utilisation du compilateur compris dans Metasm pour produire un binaire dépourvu de la protection

Plan

T2 2007

t207.exe

- `http://www.t2.fi/challenge/`
- But : trouver un mot de passe pour deverouiller le programme
- Binaire très simple [demo/1]
- Charge un driver obfusqué [demo/2]

Désobfuscation

Les types d'obfuscation

- Junk code
- Opérations obfusquées
- Anti ring3
- Duplication de code

Junk code

junk

```
ror edi, 0dh
xchg ebx, edi
ror ebx, 13h
xchg ebx, edi
```

Opérations obfusquées

rotation de bits

```
push eax
push ecx
rol dword ptr [esp+4], cl
pop ecx
pop eax
```

Anti ring3

test ring0

```
 pushfd
 push eax
 xor eax, eax
 mov ax, cs
 cmp eax, 9
 jle loc_131d5h
 rdtsc
 imul eax, ecx
 jmp eax   ; x:unknown

loc_131d5h:
 pop eax
 popfd
```

Duplication de code

duplication

```
push esi
push ebx
pushfd
rdtsc
imul ecx, ebx
cmp cl, 7fh
jnb loc_21aba
popfd
pop ebx
pop esi

loc_21abah:
popfd
pop ebx
pop esi
```

Machine virtuelle

Structure de handler

- Des opérations simples
- Des constructions similaires
- Opérations paramétrées par [ebp]

[demo/3]

Addition virtuelle

Handler d'addition

```
loc_15336:
 mov ecx, dword ptr [ebp+0ch]
 xor ecx, 842b1208h
 mov ecx, dword ptr [ebx+ecx]
 mov eax, dword ptr [ebp+8]
 xor eax, 842b1208h
 add dword ptr [ebx+eax], ecx
```

Transition entre handlers

transition au handler suivant

```
mov ecx, dword ptr [ebp+0]
xor ecx, 149f0c63h
mov ebp, dword ptr [ebp+4]
xor ebp, 842b1208h
add ebp, dword ptr [ebx+14h]
add ecx, dword ptr [ebx+14h]
jmp ecx      ; x:unknown
```

Architecture virtuelle

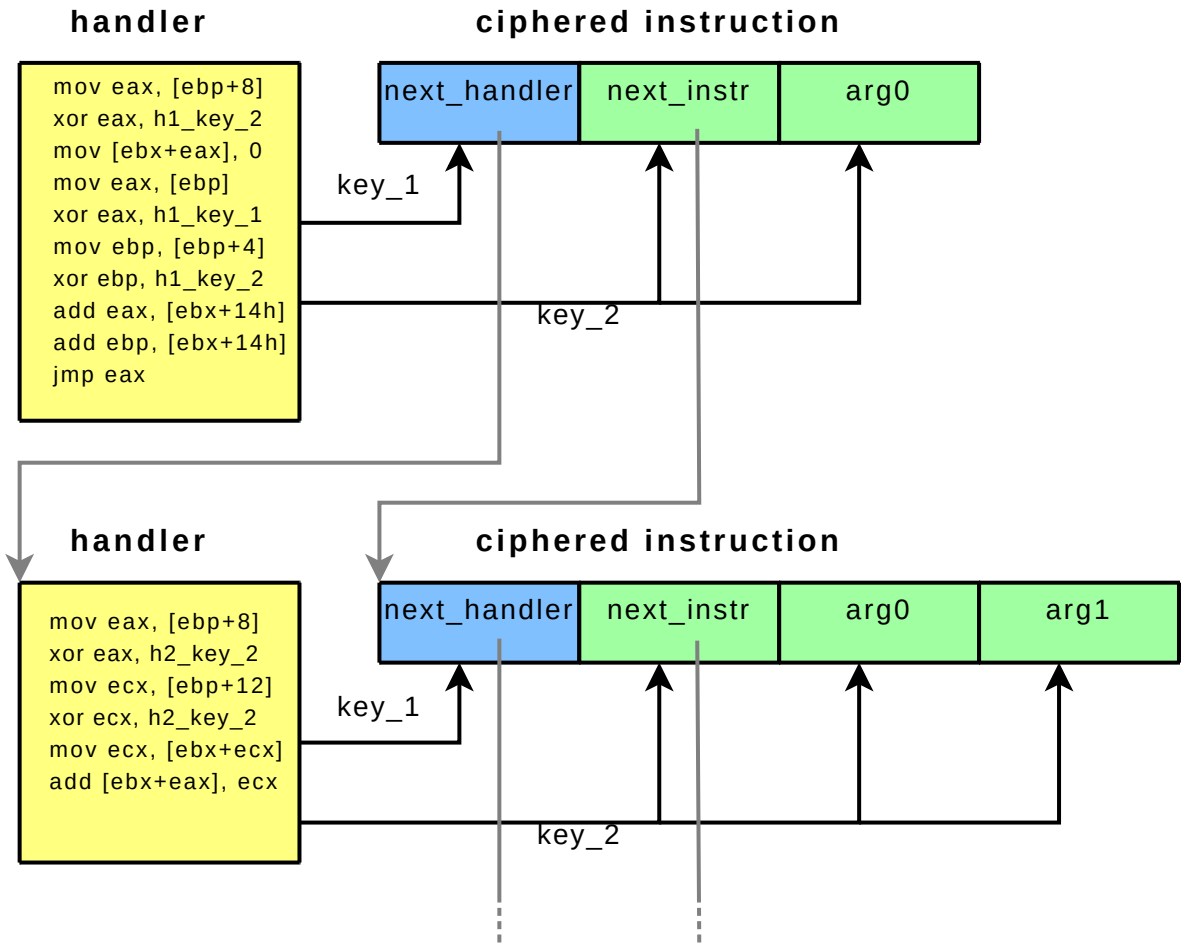

Énumération des handlers

Énumération directe impossible

- Nécessite de suivre le flot virtuel pas à pas
- La taille du binaire indique la présence de nombreux handlers
- Analyse comportementale de chaque handler par backtrack

[demo/4]

Résultat de l'analyse

Binding du handler

```
handler_13491h:
// "reg0" <- Expression["reg0", :+, "reg1"]
// handler type: add reg, reg
 mov eax, dword ptr [ebp+0ch]
 xor eax, 8d3f5d8bh
 mov eax, dword ptr [ebx+eax]
 mov ecx, dword ptr [ebp+8]
 xor ecx, 8d3f5d8bh
 add dword ptr [ebx+ecx], eax
```

Code virtuel basique

Les premières instructions virtuelles

```
entrypoint_219feh_21ea6h:
    nop
    mov r68, 28h
    add r68, host_esp
    mov r64, dword ptr [r68]
    mov dword ptr [esp], r64
    mov r64, 4
    add esp, r64
    mov r68, 2ch
    add r68, host_esp
    mov r64, dword ptr [r68]
    mov dword ptr [esp], r64
    mov r64, 4
    add esp, r64
    trap
```

Macro-instructions virtuelles

Niveau d'abstraction supérieur

- Reconnaissance de patterns caractéristiques
- Reconstruction d'un assembleur plus haut niveau
- Apparition des fonctions (call, ret)

Macro-code virtuel

Les premières instructions virtuelles

```
entrypoint_219feh_21ea6h:
 mov dword ptr [esp], dword ptr [host_esp+28h]
 add esp, 4
 mov dword ptr [esp], dword ptr [host_esp+2ch]
 add esp, 4
 mov ebp, esp
 add esp, 234h
 mov r64, dword ptr [ebp+200h]
 xor r64, 1
 jrz loc_2d630h_2d8ffh, r64
 syscall_alloc_ptr r64, 0ch
 mov dword ptr [ebp+200h], r64
loc_2d630h_2d8ffh:
```

Décompilation

- La sémantique des instructions est très simple
- La forme du code fait penser à du C
- Vérifions

Validation

- Résolution purement statique

Plan

Conclusions générale

Poeut : application inverses de transformations

- Suppression d'éléments neutres ajoutés.
- Factorisation de flots dupliqués,
- Réduction du graphe de contrôle,
- **Niveau d'abstraction constant.**

T2 : remontée des niveaux d'abstraction

- Quelques millions d'instructions dans un driver,
- une machine virtuelle, 112 handlers,
- 800 lignes de *macro-assembleur*,
- 300 lignes de C,
- **Extraction progressive de la sémantique**.

Remerciements

- L'infâme Serpillierre,
- Le(s) concepteur(s) du T2.

`http://esec.fr.sogeti.com/blog`

Vos questions ?