

Désobfuscation automatique de binaires

Et autres idyles bucoliques...

Alexandre Gazet

Sogeti / ESEC R&D

[alexandre.gazet\(at\)sogeti.com](mailto:alexandre.gazet@sogeti.com)

Yoann Guillot

Sogeti / ESEC R&D

[yoann.guillot\(at\)sogeti.com](mailto:yoann.guillot@sogeti.com)



SSTIC 2009

Plan

- 1 La compilation dans tous ses états
 - Optimiser pour régner
 - Les limites de la virtualisation
 - Conclusion(s)
- 2 Décompilation
- 3 Conclusion



Point de départ

Nécessité d'automatisation

- Nous avons déjà :
 - Processeur filtrant
 - Parcours du graphe de contrôle (CFG)
 - Application de règles de réécriture
 - Modification à la volée du CFG

Analyse manuelle du code obfusqué

- Recherche manuelle de motifs
 - Pénible
 - Peu générique
 - Éventuellement inefficace : ex résistance au polymorphisme



Nouvelle approche

Besoins

- Conservation de la sémantique
- Réécriture du code dans une forme plus simple
- Élimination du code mort
- etc.

- Les compilateurs le font déjà : **l'optimisation**
- Notre critère d'optimisation : la concision du code



Présentation de la cible

La cible

- Une protection à base de virtualisation
- Massivement obfusquée (difficulté d'analyse + polymorphisme)

Approche proposée

- Greffe d'un module d'optimisation sur le module du parcours de graphes



Constant propagation

```
cfh mov al, 12h  
67h mov cl, 46h  
69h xor cl, al
```

```
cfh mov al, 12h  
67h mov cl, 46h  
69h xor cl, 12h
```

FIG.: Propagation de 12h à travers *al*.



Constant folding

```
cfh mov al, 12h  
67h mov cl, 46h  
69h xor cl, 12h
```

```
cfh mov al, 12h  
67h mov cl, 54h
```

FIG.: Réduction de *cl*.



Operation folding

```
4fh add al, -7fh  
51h add al, bl  
53h add al, -70h
```

```
4fh add al, 11h  
51h add al, bl
```

FIG.: Réduction de l'opération *add*.



Démo

Optimisation d'un handler



Analyse sémantique des handlers

- Méthode `code_binding` de l'objet disassembler

Exemple de handler optimisé

```
lodsd  
xor eax, ebx  
add eax, 859fcfaeh  
sub ebx, eax  
push eax
```

- Sémantique (*binding*)

```
dword ptr [esp] := (dword ptr [esi]^ebx)+859fcfaeh  
eax := (dword ptr [esi]^ebx)+859fcfaeh  
ebx := ebx+-(dword ptr [esi]^ebx)-859fcfaeh  
esi := esi+4  
esp := esp-4
```



Au commencement

2^{ème} projection de Futamura

Étant donnés deux langages L_a et L_b , il est possible de trouver un compilateur de L_b vers L_a , si on connaît un interpréteur de L_b écrit en L_a

Comment ?



Du statique au (presque) dynamique



- Binding contextualisé :

```
dword ptr [esp] := 0c0000001h  
eax := 0c0000001h  
ebx := 4000fd8ch  
esi := 100167c2h  
esp := esp-4
```

- Assembleur généré : `push 0c0000001h`
- Suivi du flot d'exécution du bytecode



Démo

Exécution symbolique et génération
assembleur



Interprétation du résultat

- L'intégralité du *bytecode* a été compilée en asm Ia32 natif
- Des références au contexte de l'interpréteur
- Proche d'un automate à pile

⇒ **module d'optimisation + abstraction**



Injection d'abstraction

Extension du processeur

```
la32 :: Reg.i_to_s [32].concat( %w[ virt_eax ])
la32 :: Reg.i_to_s [16].concat( %w[ virt_ax ])
la32 :: Reg.i_to_s [8].concat( %w[ virt_al ])

la32 :: Reg.s_to_i.clear
la32 :: Reg.i_to_s.each { |sz, hh|
  hh.each_with_index { |r, i|
    la32 :: Reg.s_to_i[r] = [i, sz]
  }
}
la32 :: Reg::Sym.replace la32 :: Reg.i_to_s [32].map {|s| s.to_sym }
```



Démo

Chunk optimisé avec registres virtuels



Phase finale

- Injections des registres virtuels
- Optimisation
- Expression du code en registres virtuels uniquement
- Registres virtuels *remappés* sur les registres natifs
- Compilation et édition des liens



Démo

Code dévirtualisé, mappé dans le binaire original



Conclusion(s) 1/2

- **Méthodes d'optimisation** (règles de réécriture)
 - Très efficaces
 - Implementation limitée
 - localité des optimisations
 - manque d'une représentation intermédiaire
 - inadaptée aux obfuscations du flot de contrôle
- **L'évaluation partielle ou spécialisation**
 - Pré-calcul de tous les éléments statiques :
 - Mouvements de données dans le code obfusqué
 - Application de l'interpréteur au *bytecode*
 - Approche générique
 - Relativement coûteux en temps de calcul



Conclusion(s) 2/2

- **Intégration et réutilisation du désobfuscateur**
 - Le code actuel est à l'état de prototype
 - En cours d'intégration au framework sous forme d'un plugin propre
 - Utilisable sur tout code x86, avec des parties cross-plateforme



Plan

- 1 La compilation dans tous ses états
- 2 Décompilation
- 3 Conclusion

Décompilation

- Interface arch-spécifique réduite
- Meilleure expressivité du code
- Représentation plus simple des boucles
- Sémantique plus simple à manipuler



Décompilation : limitations

- Des constructions assembleur sont difficiles à transcrire en C
 - *rol, ror*
 - *jmp eax*
- Nécessité que le code soit formaté correctement
 - Fonction/sous-fonctions
 - ABIs/Conventions d'appels
- On peut imaginer des moyens de s'en accommoder



Démo

Décompilation



Plan

- 1 La compilation dans tous ses états
- 2 Décompilation
- 3 Conclusion

N'oubliez pas

- **Metasm**

<https://metasm.cr0.org/>

- **Blog**

<http://esec.fr.sogeti.com/blog/>



Conclusion

Merci pour votre attention.

Des questions ?

