

# Analyse statique au niveau binaire

Adel DJOUDI

Encadré par Sébastien BARDIN  
CEA LIST  
Début de thèse : Mars 2013

EJCP Mai 2013

# Analyse de code binaire : pourquoi ?

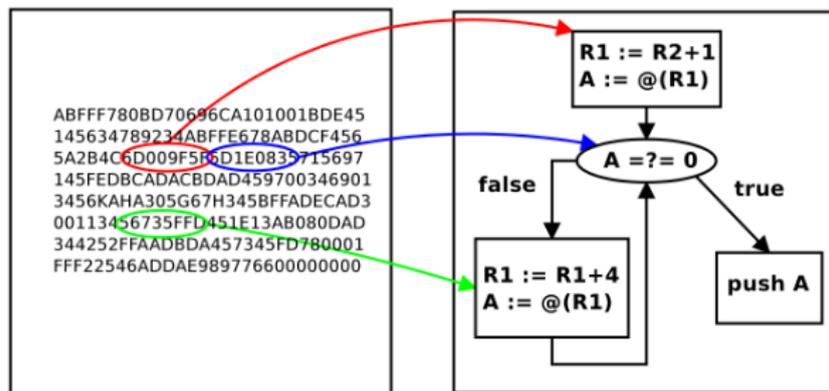
- ▶ Avantages sur l'analyse du code source :
  - ▶ Exécutable toujours disponible
  - ▶ Pas d'intervention de compilateur
- ▶ Domaines d'applications :
  - ▶ Composants sur étagère
  - ▶ Codes mobiles (Malwares, ...)

# Difficultés

- ▶ Sémantique des données de bas niveau
  - ▶ Arithmétique machine, opérations sur des vecteurs de bits
  - ▶ Usage d'une mémoire non typée (Tableau d'octets)
- ▶ Sémantique de contrôle de bas niveau
  - ▶ Pas de distinction claire entre données et instructions
  - ▶ Sauts dynamiques (GOTO x)

## Reconstruction du CFG : le problème

- ▶ Entrées
  - ▶ Code exécutable
  - ▶ Adresse initiale
  - ▶ Décodeur basique : fichier  $\times$  adresse  $\rightarrow$  instruction  $\times$  taille
- ▶ Sortie
  - ▶ (Sur-approximation) du CFG

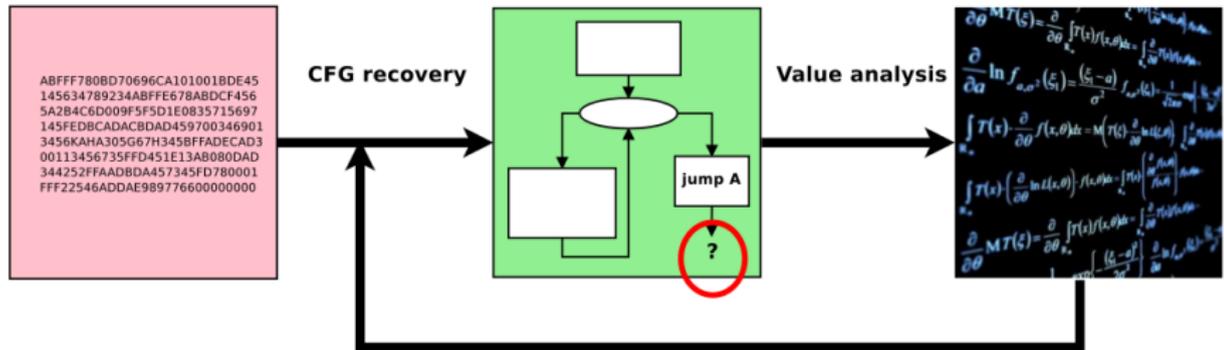


## Reconstruction du CFG : le problème (Suite)

- ▶ Les successeurs des instructions déterminées de façon syntaxique
  - ▶ (adr : move a b) -> successeur à adr + taille + 1
  - ▶ (adr : goto 100) -> successeur à 100
  - ▶ (adr : ble 100) -> successeur à 100 ou adr + taille + 1
- ▶ (adr : goto x) -> successeur à ?
- ▶ Outils de désassemblage syntaxique non suffisants

# Reconstruction du CFG : le problème (Suite)

- Besoin de combiner reconstruction syntaxique du CFG avec analyse de valeurs (VA)



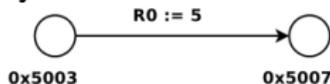
- **VA** imprécise sur (*GOTO x*) → Plus d'instructions → Plus de propagation → **VA** imprécise sur (*GOTO x*) ...

## Travaux réalisés

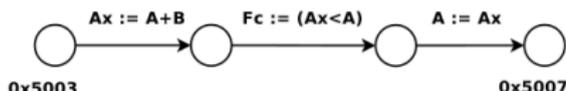
[Sébastien BARDIN and Franck VEDRINE]

- ▶ Application sur des systèmes critiques
  - ▶ Sans allocation dynamique de mémoire
  - ▶ Taille limité des programmes analysés
  - ▶ Programmes issus du code C
- ▶ Modèle formel : DBA (Dynamic Bitvector Automata)

0x5003 : move R0 5



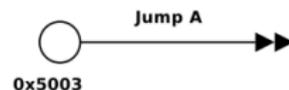
0x5003 : add A B



0x5003 : goto 0x1000



0x5003 : goto A



- ▶ Modèle mémoire en un seul espace contigu

## Travaux en cours

- ▶ Extension du modèle des DBAs avec différentes régions (Constant, Stack, Malloc(id))
  - ▶ Valeurs : (region, offset)
  - ▶ Opérations plus restreintes
    - ▶  $(\text{Constant}, v) \text{ op } (\text{Constant}, v') = (\text{Constant}, v \text{ op } v')$
    - ▶  $(R, v) - (R, v') = (\text{Constant}, v - v')$
    - ▶  $(R, v) + (\text{Constant}, v') = (R, v + v')$
- ▶ Buts :
  - ▶ Étendre l'analyseur à des systèmes plus généraux (pas critiques)
  - ▶ Pouvoir analyser des exécutables issus du C++, libC, malloc/free ...