

Travaux d'Études et de Recherches

Test en frelatage (fuzzing) et code binaire

20 Mai 2011

Olivier Benjamin

LIG - Équipe VASCO
Encadrant : Roland Groz

Plan



- Cadre du travail
- Problème posé
- Réflexions
- Expérimentations
- Bilan

Cadre du travail



- LIG, équipe VASCO
VALidation de Systèmes, Composants, et Objets Logiciels
- Sofia Bekrar : VASCO, Verimag, VUPEN
- Test en frelatage
- Evaluation de la qualité

Test en frelatage



- Méthode de test pour détecter des vulnérabilités
- Fournir des entrées aléatoires, mal formées
- Très utile dans les tests en boîte noire
- Très bon ratio détection/coût

Test en frelatage



- Problème :
On teste beaucoup de valeurs au hasard
Optique d'efficacité : évaluation

Comment déterminer ce qui a été (bien) testé ?

Exemple : somme de contrôle

Microsoft : 100 000 itérations

Problème posé



- Réponse classique : couverture d'instructions
Ratio instruction exécutées / instructions totales
Même importance pour toutes les instructions
Mal adapté :
Toutes les instructions n'ont pas la même importance
Le contexte n'est pas pris en compte
- Objectif : trouver d'autres moyens de mesure

- Beaucoup de vulnérabilités viennent du mauvais usage d'une fonction

exemple utilisé : fonction strcpy de la libc

- Repérer les appels à cette fonction, et vérifier qu'ils ont été testés

- Dans un premier temps : appels seuls
- Critère trop simple : l'appel peut être inoffensif
- Dans un deuxième temps : chaînes d'instructions :
regarder les instructions précédentes

- Chaînes d'instructions :

Quelles instructions sont susceptibles d'être exécutées successivement

Après le test, lesquelles l'ont effectivement été

Expérimentations



Objectif : Écrire un outil implémentant ces approches
et vérifier leur utilité en pratique

L'outil doit être capable de distinguer les parties du
programme jugées intéressantes pour cette métrique

Les résultats doivent correspondre à une évaluation des
risques faites par un humain

Expérimentations



- Outils : IDA pro + IDApython
- Travail réalisé : écriture d'un script python pour IDA pro répondant au besoin
- Test sur des exemples de programmes simples

Approche simplifiée



Fonctionnement :

- Répertorie les instructions recherchées présentes
- Ajoute un breakpoint
- Rencontre un breakpoint → répertorie l'exécution
- Compare les instructions présentes à celles testées

Premier exemple



```
#include <stdio.h>
#include <stdlib.h>
#include <readline/readline.h>

int main(int argc, char* argv[]){

    if(!strcmp(argv[1], "1")){
        printf("le premier argument vaut 1\n");
    }else if (!strcmp(argv[1],"2")){
        printf("le premier argument vaut 2\n");
    }else if (!strcmp(argv[1],"3")){
        printf("le premier argument vaut 3\n");
    }else if (!strcmp(argv[1],"4")){
        char *p = readline(">>>");
        char buffer[20];
        strcpy(buffer, p);
    }
}
```

Premier exemple



- Fonction recherchée : strcpy
- Un appel déclenché par l'entrée '4'
- Vulnérabilité de type buffer overflow

Résultats



- Si entrée différente de '4'
Le programme prévient de l'appel dangereux manqué
- Si entrée '4'
Le programme marque l'appel
- On arrive à détecter l'appel convenablement

Deuxième exemple



```
#include <stdio.h>
#include <stdlib.h>
#include <readline/readline.h>

int main(int argc, char* argv[]){
    if(!strcmp(argv[1], "1")){
        printf("le premier argument vaut 1\n");
        ...
    }else if (!strcmp(argv[1], "4")){
        char *p = readline(">>>") ;
        char buffer[20];
        if(strlen(p)<19){
            strcpy(buffer, p) ;
        }
    }else if (!strcmp(argv[1], "5")){
        char *p = readline(">>>");
        char buffer[20];
        strcpy(buffer, p);
    }
}
```


Résultats



- Le programme détecte le(s) appel(s) non déclenché(s)
- Il détecte ou non l'appel préliminaire à strlen
- On arrive à distinguer les cas pour chaque appel à strcpy

Bilan



- On peut alors définir une mesure numérique
- Il faut pour cela attribuer un poids à chaque chaîne d'instructions intéressante (expérience, expertise, études statistiques)
- On peut alors calculer une mesure :
 - Stestées / Stotales
 - Stestées somme des poids des instructions testées
 - Stotale somme des poids des instructions totales

Conclusion



- On a proposé deux métriques possibles
- On a implémenté un programme montrant qu'on peut les calculer
- On a testé chacune sur un programme simple, et on a trouvé le résultat cohérent

Perspectives



- Tester ces approches sur plus de programmes, des programmes plus complexes
- Implémenter des méthodes de pattern matching plus élaborées
- Tester avec un environnement de fuzzing
- Automatiser la rétroaction sur l'environnement de fuzzing

MERCI