




EVIDEN

PISE

Protocol Inference Using Symbolic Execution and Automata Learning

Octobre 2025

© Eviden SAS – For internal use

PISE

Protocol Inference Using Symbolic Execution and Automata Learning

- Auteurs : Ron Marcovich, Orna Grumberg et Gabi Nakibly du Technion - Israel Institute of Technology
- Publié en 2023



EVIDEN

Problématique



Inférence protocolaire

En partant seulement d'un binaire



EVIDEN

Comment ?


L'algorithme L*

Le fabuleux domaine des langages formels


- Un langage formel L sur un alphabet A est un ensemble de mots, qui sont des séries de lettres tirées de l'alphabet.
Exemple: $A = \{r0="Receive:Hello", s0="Send:World"\}$ et $L = \{r0, r0s0, r0s0r0, \dots\}$
- Un langage régulier est un langage qui peut être défini par une expression régulière (aka. regexp).
- Un langage est régulier si et seulement si il existe un automate déterministe fini (DFA) qui accepte ce langage.
- L'algorithme L* (Dana Angluin, 1987) permet de reconstruire l'automate pour un langage régulier à partir d'un oracle (Teacher) qui répond à deux types de requêtes:
 - Une requête d'appartenance: "Est-ce que ce mot est dans le langage ?"
=> Facile à répondre à partir d'un binaire
 - Une requête d'équivalence: "Est-ce que ce DFA est équivalent au langage"
=> Difficile à répondre à partir d'un binaire
- Une version probabiliste de L* permet de faire une approximation d'équivalence en générant une série de requête d'appartenance aléatoirement

L'algorithme L*

Pour un protocole




La problématique de PISE



La solution PISE

Un professeur visionnaire


- PISE propose une version modifiée de l'algorithme L*
- Le professeur a un nouveau pouvoir :
 - Lorsque une requête d'appartenance est positive, le professeur donne la liste de toutes les lettres qui peuvent suivre le mot.
- L'apprenti est modifié pour construire son alphabet pendant l'apprentissage.



L'exécution symbolique


La botte secrète du professeur

```
void function(int x, int y) {  
    int z;  
    if (x > 10) {  
        z = x;  
    } else {  
        z = y;  
    }  
    if (z > x) {  
        print("error");  
    } else {  
        print("good");  
    }  
}
```




L'exécution symbolique

La botte secrète du professeur



L'exécution symbolique

La botte secrète du professeur




EVIDEN

Découvrir le prochain message d'un protocole

```
7  int main() {
8      char *buffer = malloc(sizeof(char[MAX_LEN]));
9      while (1) {
10         if (fgets(buffer, MAX_LEN, stdin) != NULL) {
11             if (strcmp(buffer, "hello\n") == 0) {
12                 printf("world\n");
13             } else if (strcmp(buffer, "goodbye\n") == 0) {
14                 printf("goodbye\n");
15                 break;
16             }
17         }
18     }
19     free(buffer);
20 }
```

Découvrir le prochain message d'un protocole



EVIDEN

A quoi ça sert ?

Les applications


- Reverse de protocoles inconnus :
 - Command & control de malwares
 - protocoles propriétaires
- Analyse de sécurité des implémentations, la machine d'état peut :
 - Révéler des non conformités à la spécification
 - Révéler si une implementation est vulnérable à une faille protocolaire
 - Permettre d'identifier une implementation (fingerprinting)

Les limites

- Requiert de connaître les points d'entrée et de sortie du binaire.
Souvent standard : les syscalls read/write, send/recv
- L'exécution symbolique ne scale pas bien pour des programmes complexes
 - Problème d'explosion exponentielle du nombres de chemins possible
 - Le SMT solver est une operation lourde (SMT => NP complete)
- L'utilisation de code asynchrone, de multi-threading, de queues de réceptions/transmission perturbent l'analyse du protocole.

EVIDEN

Démonstration



Sources

- Publication de PISE :
<https://www.ndss-symposium.org/wp-content/uploads/2023/03/bar2023-23002-paper.pdf>
- Presentation: <https://www.youtube.com/watch?v=ou9NloRLmNk>
- Code source: <https://github.com/ron4548/pise>
- Angr (moteur d'exécution symbolique): <https://github.com/angr/angr>
- Learnlib (implémentation de L*): <https://learnlib.de/7>

The background features a large, abstract graphic on the right side consisting of several interlocking, three-dimensional loops in various shades of blue and teal, creating a complex, knot-like structure.

EVIDEN

Questions ?

Confidential information owned by Eviden SAS, to be used by the recipient only.
This document, or any part of it, may not be reproduced, copied, circulated
and/or distributed nor quoted without prior written approval from Eviden SAS.

© Eviden SAS – For internal use