

Étude des sous-graphes communs
des graphes de dépendances d'appels système
pour la classification de logiciels malveillants
Stage L3


Dylan Marinho
sous la direction de Jean Quilbeuf et Axel Legay

TAMIS, Inria

4 septembre 2018

Augmentation du nombre du nouveaux *malwares*

Total malware



<https://www.av-test.org/en/statistics/malware/>

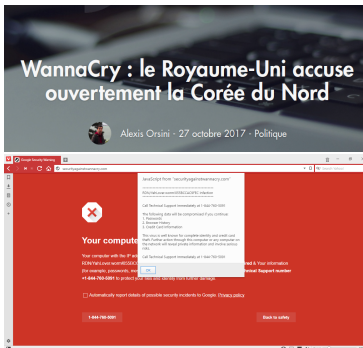
Conséquences des *malwares* sur la société

Cyberattaque mondiale "WannaCry", le ransomware qui chiffre les données

Actualité | Monde

Rançongiciel WannaCry : le gouvernement britannique incrimine la Corée du Nord

Le virus avait touché un tiers des hôpitaux et cliniques d'Angleterre, ainsi que nombre des cabinets médicaux du pays.



lexpress.fr – numerama.com – lemonde.fr – bleepingcomputer.com

Nécessité de détection des *malwares*

- ▶ Besoin d'automatiser la détection de *malwares*
- ▶ Plusieurs méthodes
 - ▶ analyse syntaxique
 - ▶ Recherche de chaînes d'octets
 - ▶ Étude de l'en-tête et des sections
 - ▶ Pas d'analyse du comportement
 - ▶ analyse dynamique
 - ▶ Exécution dans une *sandbox*
 - ▶ Production d'une trace
 - ▶ analyse *concolique* (*concrete-symbolic*)
 - ▶ Analyse de plusieurs traces
 - ▶ Pas besoin de *sandbox*

- ▶ Comportement caractérisé par les appels externes
- ▶ Approche par des *System Call Dependency Graphs* (SCDGs)
 - ▶ Transformer la trace en un graphe de dépendances d'appels
- ▶ Mais qui a ses limites. On ne sait pas :
 - ▶ si le comportement du logiciel est bien capturé
 - ▶ si une amélioration est possible

Contributions

- ▶ Analyse des graphes et des sous-graphes produits (analyse *concolique*)
- ▶ Deux méthodes de pré-traitement
- ▶ Évaluation expérimentale

Plan

- 1 Introduction
- 2 **Background**
 - Construction des *SCDGs*
 - Apprentissage et classification
- 3 Analyse de graphes et pré-traitement
 - Limites du modèle
 - Méthode 1 : *Edge consistency*
 - Méthode 2 : *Argument direction*
- 4 Résultats
 - Méthodologie
 - Méthode 1
 - Méthode 2
- 5 Conclusion

Construction des SCDGs

SCDG

Code – Trace

```
1 const char *pathname = 'file.txt';  
2 const char *pathname2 = 'file2.txt';  
3 int f = open(*pathname,flags);  
4 int f2 = open(*pathname2,flags2);  
5 ssize_t n = read(f,buf,1024);  
6 ssize_t p = write(f2,buf,1024);  
7 close(f);  
8 close(f2);
```


Construction des SCDGs

Code – Trace

```
1 const char *pathname = 'file.txt';  
2 const char *pathname2 = 'file2.txt';  
3 int f = open(*pathname,flags);  
4 int f2 = open(*pathname2,flags2);  
5 ssize_t n = read(f,buf,1024);  
6 ssize_t p = write(f2,buf,1024);  
7 close(f);  
8 close(f2);
```



SCDG

Construction des SCDGs

Code – Trace

```
1 const char *pathname = 'file.txt';  
2 const char *pathname2 = 'file2.txt';  
3 int f = open(*pathname,flags);  
4 int f2 = open(*pathname2,flags2);  
5 ssize_t n = read(f,buf,1024);  
6 ssize_t p = write(f2,buf,1024);  
7 close(f);  
8 close(f2);
```

SCDG



Construction des SCDGs

Code – Trace

```
1 const char *pathname = 'file.txt';  
2 const char *pathname2 = 'file2.txt';  
3 int f = open(*pathname, flags);  
4 int f2 = open(*pathname2, flags2);  
5 ssize_t n = read(f, buf, 1024);  
6 ssize_t p = write(f2, buf, 1024);  
7 close(f);  
8 close(f2);
```

SCDG




Construction des SCDGs

Code – Trace

```
const char *pathname = 'file.txt';  
const char *pathname2 = 'file2.txt';  
int f = open(*pathname, flags);  
int f2 = open(*pathname2, flags2);  
ssize_t n = read(f, buf, 1024);  
ssize_t p = write(f2, buf, 1024);  
close(f);  
close(f2);
```

SCDG




Construction des SCDGs

Code – Trace

```
const char *pathname = 'file.txt';  
const char *pathname2 = 'file2.txt';  
int f = open(*pathname, flags);  
int f2 = open(*pathname2, flags);  
ssize_t n = read(f, buf, 1024);  
ssize_t p = write(f2, buf, 1024);  
close(f);  
close(f2);
```

SCDG




Construction des SCDGs

Code – Trace

```
const char *pathname = 'file.txt';  
const char *pathname2 = 'file2.txt';  
int f = open(*pathname, flags);  
int f2 = open(*pathname2, flags);  
ssize_t n = read(f, buf, 1024);  
ssize_t p = write(f2, buf, 1024);  
close(f);  
close(f2);
```

SCDG




Construction des SCDGs

Code – Trace

```
1 const char *pathname = 'file.txt';  
2 const char *pathname2 = 'file2.txt';  
3 int f = open(*pathname, flags);  
4 int f2 = open(*pathname2, flags);  
5 ssize_t n = read(f, buf, 1024);  
6 ssize_t p = write(f2, buf, 1024);  
7 close(f);  
8 close(f2);
```

SCDG




Construction des SCDGs

Code – Trace

```
const char *pathname = 'file.txt';  
const char *pathname2 = 'file2.txt';  
int f = open(*pathname, flags);  
int f2 = open(*pathname2, flags);  
ssize_t n = read(f, buf, 1024);  
ssize_t p = write(f2, buf, 1024);  
close(f);  
close(f2);
```

SCDG




Construction des SCDGs

Code – Trace

```

const char *pathname = 'file.txt';
const char *pathname2 = 'file2.txt';
int f = open(*pathname, flags);
int f2 = open(*pathname2, flags);
ssize_t n = read(f, buf, 1024);
ssize_t p = write(f2, buf, 1024);
close(f);
close(f2);
    
```

SCDG




Construction des SCDGs

Code – Trace

```

const char *pathname = 'file.txt';
const char *pathname2 = 'file2.txt';
int f = open(*pathname, flags);
int f2 = open(*pathname2, flags);
ssize_t n = read(f, buf, 1024);
ssize_t p = write(f2, buf, 1024);
close(f);
close(f2);
    
```

SCDG



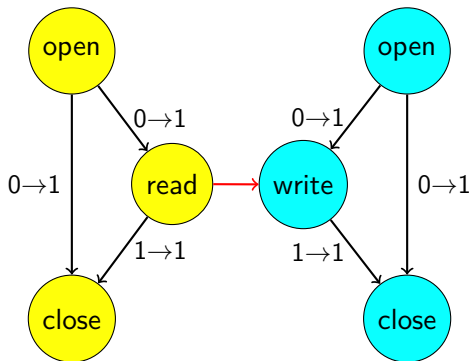
Construction des SCDGs

Code – Trace

```

const char *pathname = 'file.txt';
const char *pathname2 = 'file2.txt';
int f = open(*pathname, flags);
int f2 = open(*pathname2, flags2);
ssize_t n = read(f, buf, 1024);
ssize_t p = write(f2, buf, 1024);
close(f);
close(f2);
    
```

SCDG



Apprentissage

Apprentissage

Pour chaque famille F de malwares, la phase d'apprentissage a deux étapes :

- ▶ l'extraction du *SCDG* de chaque malware
- ▶ l'extraction des sous-graphes fréquents de cette famille (signature *comportementale* de la famille)

Classification

Classification

La classification est paramétrée par un seuil t et pour chaque binaire b :

- ▶ on extrait son SCDG, noté G
- ▶ pour chaque $sg \in \mathcal{G}$, on exécute $gspan(G, sg)$
- ▶ on calcule un score $\mathcal{M}(sg, b) = \frac{\text{size}(gspan(b, sg))}{\text{size}(sg)}$
- ▶
 - ▶ si un sous-graphe obtient un score plus grand que t , le binaire b est classifié comme *malware* dans la famille où il obtient le score maximum
 - ▶ sinon il est classifié comme *cleanware*


Plan

- 1 Introduction
- 2 Background
 - Construction des *SCDGs*
 - Apprentissage et classification
- 3 Analyse de graphes et pré-traitement
 - **Limites du modèle**
 - Méthode 1 : *Edge consistency*
 - Méthode 2 : *Argument direction*
- 4 Résultats
 - Méthodologie
 - Méthode 1
 - Méthode 2
- 5 Conclusion

Nombres d'arêtes

```

const char *pathname = 'file.txt';
const char *pathname2 = 'file2.txt';
int f = open(*pathname, flags);
int f2 = open(*pathname2, flags2);
ssize_t n = read(f, buf, 512);
ssize_t p = write(f2, buf, 512);
ssize_t n2 = read(f, buf, 512);
ssize_t p2 = write(f2, buf, 512);
close(f);
close(f2);
    
```




Nombre d'arêtes pour n cycles read write :

$$E(n) = 7n^2 + 2$$


Nombre d'arêtes

Graphe obtenu



$$E(n) = 7n^2 + 2$$

Graphe idéal



$$E(n) = 3n + 2$$

On obtiendra $E(n) = \frac{1}{2}n^2 + \frac{5}{2}n + 2$

Petits entiers

Signatures

- ▶ `int open(const char *pathname, int flags);`
- ▶ `int socketcall(int call, unsigned long *args);`

```
f = open(...)
```

```
...
```

```
s = socketcall(3, ...)
```

Plan

- 1 Introduction
- 2 Background
 - Construction des *SCDGs*
 - Apprentissage et classification
- 3 Analyse de graphes et pré-traitement
 - Limites du modèle
 - **Méthode 1 : *Edge consistency***
 - Méthode 2 : *Argument direction*
- 4 Résultats
 - Méthodologie
 - Méthode 1
 - Méthode 2
- 5 Conclusion

Edge consistency

- ▶ On définit l'ensemble ET d'un graphe comme l'ensemble des triplets (label de départ, label d'arrivée, label de l'arête)
- ▶ On classe ensuite ses éléments :
Consistent, Meaningless, Indeterminate

Exemple

Signatures

- ▶ `int close(int fd);`
- ▶ `int socketcall(int call, unsigned long *args);`
- ▶ `int fcntl(int fd, int cmd, ... /*arg */);`

Exemples

`(fcntl, close, 1->1)` \mapsto consistent

`(fcntl, socketcall, 2->1)` \mapsto meaningless

`(fcntl, fcntl, 0->3)` \mapsto indeterminate

Plan

- 1 Introduction
- 2 Background
 - Construction des *SCDGs*
 - Apprentissage et classification
- 3 Analyse de graphes et pré-traitement
 - Limites du modèle
 - Méthode 1 : *Edge consistency*
 - **Méthode 2 : *Argument direction***
- 4 Résultats
 - Méthodologie
 - Méthode 1
 - Méthode 2
- 5 Conclusion

Argument direction

On associe à un argument d'un appel système une direction : Input, Output

Exemple

On considère l'appel système (read, A_r, r_r)

```
ssize_t read(int fd, void *buf, size_t count)
```

- ▶ $\text{dir}(0, \text{read}) = \text{Output}$
- ▶ $\text{dir}(1, \text{read}) = \text{Input} : \text{fd}$
- ▶ $\text{dir}(2, \text{read}) = \text{Output} : \text{buf}$
- ▶ $\text{dir}(3, \text{read}) = \text{Input} : \text{count}$

Plan

- 1 Introduction
- 2 Background
 - Construction des *SCDGs*
 - Apprentissage et classification
- 3 Analyse de graphes et pré-traitement
 - Limites du modèle
 - Méthode 1 : *Edge consistency*
 - Méthode 2 : *Argument direction*
- 4 **Résultats**
 - **Méthodologie**
 - Méthode 1
 - Méthode 2
- 5 Conclusion

Méthodologie de validation

- ▶ Méthodes testées sur les graphes issus de *Mirai*
- ▶ Deux phases :
 - Exploration de paramètres sur un nombre restreint de *data-sets*
 - Expériences sur 500 *data-sets* obtenus aléatoirement
(80% des Mirais utilisés pour l'apprentissage, 20% pour la classification)
- ▶ Les résultats seront comparés au dernier article de l'équipe¹ :
 - ▶ $F_{0.5}$ score de 99.41%
 - ▶ Temps d'apprentissage 2 503s (approx. 12.4s par graphe)
 - ▶ Temps de classification 315.59s (approx. 1.56s par graphe)

1. Najah Ben Said et al. "Detection of Mirai by Syntactic and Behavioral Analysis". *ISSRE 2018*. Accepted, to appear. IEEE Computer Society, 2018.

Plan

- 1 Introduction
- 2 Background
 - Construction des *SCDGs*
 - Apprentissage et classification
- 3 Analyse de graphes et pré-traitement
 - Limites du modèle
 - Méthode 1 : *Edge consistency*
 - Méthode 2 : *Argument direction*
- 4 **Résultats**
 - Méthodologie
 - **Méthode 1**
 - Méthode 2
- 5 Conclusion

Edge consistency – Preprocessing

<i>Consistent</i>	<i>Meaningless</i>	<i>Indeterminate</i>	Total
59	76	55	190

Classification des *edge types*

- ▶ Suppression de 39% des arêtes des *Mirais*
- ▶ Non exécuté sur les *cleanwares*

Edge consistency – Exploration de paramètres

	Total base de données	Apprentissage	Classification
<i>Mirais</i>	503	403	100
<i>Cleanwares</i>	516	403	100

Répartition des *data-sets*

Gspan	Support	# Sous graphes	Seuil	F-0.5 score
directed	0.5	25	0.45 - 0.55	98.13%
directed	0.5	30	0.45 - 0.55	98.13%
directed	0.5	40	0.51 - 0.55	98.13%

Meilleurs résultats de l'exploration de paramètres

Gspan	Apprentissage	Classification	Classification par graphe
<i>undirected</i>	8.36	454.04	2.27
<i>directed</i>	4.95	764.75	3.82

Temps obtenus pour les expériences (en s)

Plan

- 1 Introduction
- 2 Background
 - Construction des *SCDGs*
 - Apprentissage et classification
- 3 Analyse de graphes et pré-traitement
 - Limites du modèle
 - Méthode 1 : *Edge consistency*
 - Méthode 2 : *Argument direction*
- 4 **Résultats**
 - Méthodologie
 - Méthode 1
 - **Méthode 2**
- 5 Conclusion

Argument direction – Preprocessing

On supprime en moyenne :

- ▶ 75,13% des arêtes sur les *Mirais*
- ▶ 93,31% des arêtes sur les *cleanwares*
- ▶ 86,98% des arêtes sur l'ensemble de la collection

Argument direction – Exploration de paramètres

	Total base de données	Apprentissage	Classification
<i>Mirais</i>	500	400	100
<i>Cleanwares</i>	204	0	100

Répartition des *data-sets*

Gspan	Support	# Sous graphes	Seuil	F-0.5 score
<i>directed</i>	0.8	1	0.29 - 0.42	99.16%
<i>undirected</i>	0.8	1	0.29 - 0.42	99.16%
<i>directed</i>	0.8	2	0.34 - 0.42	99.16%
<i>undirected</i>	0.8	2	0.34 - 0.42	99.16%
<i>directed</i>	0.8	5	0.34 - 0.50	99.16%
<i>undirected</i>	0.8	5	0.34 - 0.50	99.16%
<i>directed</i>	0.8	10	0.41 - 0.50	99.16%
<i>undirected</i>	0.8	10	0.41 - 0.50	99.16%

Meilleurs résultats

Argument direction – Expériences

	Nouveaux résultats	Résultats précédents
Taux de faux-positifs	0.49%	0%
Taux de faux-négatifs	2.41%	2.88%
F-0.5 score	99.11%	99.41%
Temps d'apprentissage	1.77s	2 503s
Temps de classification	2.56s	315.59s

Résultats des expériences

Perte en $F_{0.5}$ score : 0.3 points

Gain de vitesse :

- ▶ 1 414x en apprentissage
- ▶ 123x en classification

Conclusion

- ▶ Analyse à partir des graphes extraits précédemment
- ▶ Mise en place de deux méthodes de pré-traitement
 - ▶ Amélioration relative sur la méthode 1 : mise de côté
 - ▶ Amélioration en temps avec la méthode 2 : 1 414x en apprentissage, 123x en classification
- ▶ *Future work* : Comparaison avec de la *taint analysis*