

AnoMark

Détection d'Anomalies dans des lignes de commande à l'aide de Chaînes de Markov

Alexandre Junius



ANSSI

03/06/2022



- 1 Introduction
- 2 Chaînes de Markov et ngrams - Application aux lignes de commande
- 3 Outil développé



- 1 Introduction
- 2 Chaînes de Markov et ngrams - Application aux lignes de commande
- 3 Outil développé



Un journal d'événement système

Event 4688, Microsoft Windows security auditing.

General Details

A new process has been created.

Creator Subject:

- Security ID: [REDACTED]
- Account Name: [REDACTED]
- Account Domain: [REDACTED]
- Logon ID: 0xAC309CF

Target Subject:

- Security ID: NULL SID
- Account Name: -
- Account Domain: -
- Logon ID: 0x0

Process Information:

- New Process ID: 0x1c80
- New Process Name: C:\Windows\System32\cmd.exe
- Token Elevation Type: %%1938
- Mandatory Label: Mandatory Label\Medium Mandatory Level
- Creator Process ID: 0x1764
- Creator Process Name: C:\Windows\System32\forfiles.exe
- Process Command Line: /c echo "Temp"

Événement 4688 : Création de processus



Méthodes de la détection système

Communément la détection système repose sur :

- ▶ La recherche d'IOC (Indicateurs de compromission)
- ▶ La création de signatures pour des comportements connus



Communément la détection système repose sur :

- ▶ La recherche d'IOC (Indicateurs de compromission)
- ▶ La création de signatures pour des comportements connus

Mais c'est aussi un formidable champ d'application des algorithmes d'apprentissage statistique, notamment en détection d'anomalies, qui permettent de s'orienter vers des comportements inconnus jusqu'alors.



1 Introduction

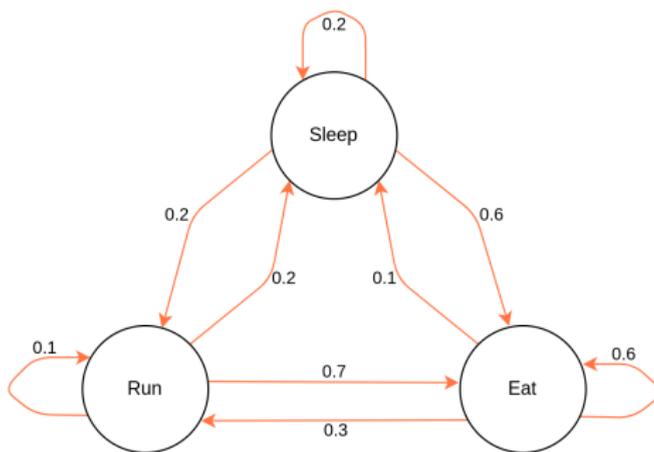
2 Chaînes de Markov et ngrams - Application aux lignes de commande

3 Outil développé



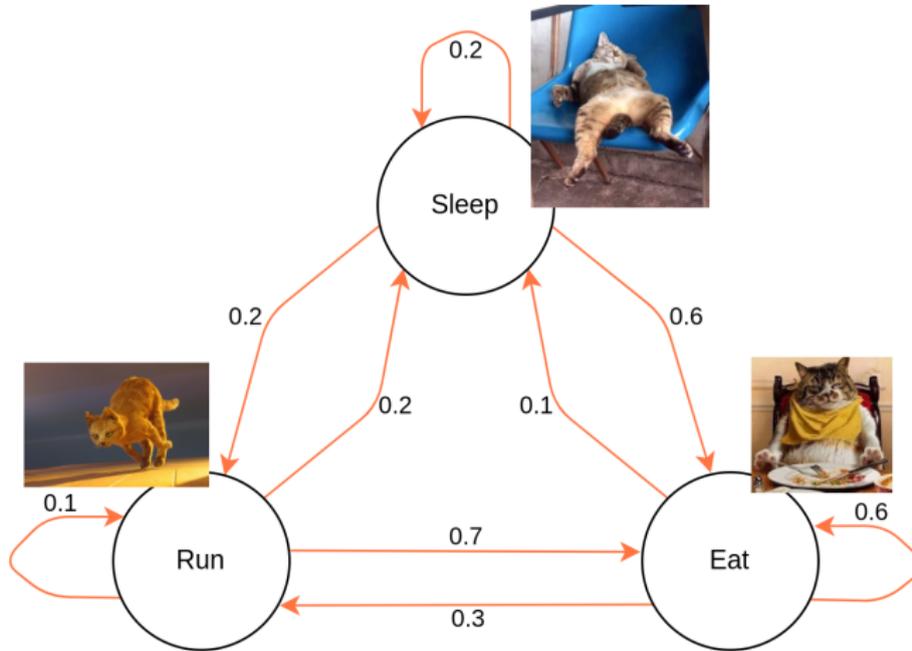
Les chaînes de Markov

L'expression *chaîne de Markov* fait référence à un concept mathématique permettant de **modéliser** les transitions entre états indépendamment du passé. C'est un processus stochastique dont la prédiction du futur à partir du présent n'est pas rendue plus précise par le passé.





Les chaînes de Markov





Les Ngrams de groupes de lettres

On appelle découpage en ngrams des lignes de commandes le fait de découper ces dernières en groupes de n lettres.

» `cmd.exe /c handle.exe`

Modèle :

```
{"cmd.": {"e": 100%}}
```



Les Ngrams de groupes de lettres

On appelle découpage en ngrams des lignes de commandes le fait de découper ces dernières en groupes de n lettres.

» `cmd.exe /c handle.exe`

Modèle :

```
{"cmd.": {"e": 100%},  
"md.e": {"x": 100%}}
```



Les Ngrams de groupes de lettres

On appelle découpage en ngrams des lignes de commandes le fait de découper ces dernières en groupes de n lettres.

» `cmd.exe /c handle.exe`

Modèle :

```
{"cmd.": {"e": 100%},  
"md.e": {"x": 100%},  
"d.ex": {"e": 100%} }
```



Les Ngrams de groupes de lettres

etc.



Les Ngrams de groupes de lettres

On appelle découpage en ngrams des lignes de commandes le fait de découper ces dernières en groupes de n lettres.

- » `cmd.exe /c handle.exe`
- » `cmd.jar /c something.exe`

Modèle :

```
{"cmd.": {"e": 50%, "j": 50%},  
"md.e": {"x": 100%},  
"d.ex": {"e": 100%},  
... }
```



Étapes de l'application de l'algorithme :

- ▶ Entraînement modèle en *mode lettres*
- ▶ Parcours de lignes de commande avec une fenêtre glissante de taille n
- ▶ Produit des probabilités pour obtenir la vraisemblance de la commande en entier
- ▶ Classement de la moins vraisemblable à la plus vraisemblable, après liste blanche.



Exemples de lignes de commande détectées

On détecte par exemple :

- ▶ les lignes de commandes encodées :
 - » `powershell -EncodedCommand Q29uY2VudHJlLnRvaS5zdXIubW`
`EucHJlc2VudGF0aW9uIQ==`
- ▶ les *ping* vers des domaines inhabituels :
 - » `ping heeeeeeeey.com`
- ▶ l'exécution de processus inconnus :
 - » `iWillPawnYou.exe /user adminAccount`



Exemples de lignes de commande détectées

Mais aussi :

- ▶ l'utilisation de *flags* inconnus :
 - » `legit.exe -newflag newdata`
- ▶ le changement de quelques lettres :
 - » `CmD.eXe -someflag -someparam`
- ▶ l'exécution de processus connus depuis des chemins inconnus :
 - » `C:\newfolder\myproc.exe`



Démonstration

```
root@tdb2641185d34:/opt/anomark# python apply_model.py -d data/testing_data.csv -c CommandLine -n models/demo_model.dump --verbose --color -n 20
Applying model to dataframe
100% | 348/348 [00:00<00:00, 4237.24it/s]

Displaying top 20

net view //.

hostname

cmd /C "dir C:\\"

powershell.exe -NoP -NoL -sta -NonI -W Hidden -Exec Bypass -Enc JABQAH1AbwBnAHIAZQBzAHMAUABYAGUAZgBlAHIAZQBzAGMAZQA9ACIAUwBpAGwAZQBwAHQAAbS5AEHAbwBuAHQAaQBuAHUAZQA1ADsA
UgBlAGcAaQbzAHQAZQBzYACBAUwBjAGcAZQBKAHUAbABLAGQAVABNHMAAwBgACCACQCBkADAAyYgBlAFUACABKAGEAdAB1ACCcIAATAEKAbgBwAHUAdABPAG1AagBlAGMAAdAgACgAtgBlAHcAlQBTAGMAAbBLAGQAdQBSAGUAZ
wBUAGEACwBtACALQBBAGwAdBpAQ8AbgAgcAgTgBlAHcAlQBTAGMAAbBLAGQAdQBSAGUAZABUAJAGcACwBtAEAEYwB8AGKAbwBuACALQBFfHGAZQBjAHUAdAB1ACMAJwBwAG8BdwbLHIAIcwbAGUAbAB5AC4ZQB4AGUAJw
AgACDAQQByAgcAdQBlCAUJAgBgb0ACAAJwAIE44BwBuAEKAbgB0AQJAcgBhACMAJABpAHYAZQAgACBAtgBvAEwBwBnAG8ATAE44BwBuQAH1AbwBnAGKAbAB1ACALQBGAGKAbAB1ACAA1gTB0DAdOAXBQAHIAbwBnAHIAIYQB
tIEFQYQBBGAEAXBzAHMAAbcAEFAZBvAG1AZQBvAHAAZBhAHQAZQBwAHUAcwAIACTAJwBpACALQBUAHIAgBnAGcAZQBzYACAAKAB0BQUAdwAtAFMAyBwAGUAZAB1AGwAZQBkAFQYQBBzAGcSVABYAGKAZwBnAGUJcGAg
CEB0ARABhAGKAbAB5ACALQBBhAQATAAZzGEABQpACALQBTATGUAdb0AGKAbgBnAHMAIAAloAE4ZQBzCBAUwBjAGcAZQBKAHUAbABLAGQAVABNHMAAwBtAGUAdB0AGKAbgBnAHMAUwBlAHQAQnpAIA==

cmd /C dir C:

whoami /all

cmd /C wmic logicaldisk get volumename,name

powershell.exe -NoP -NoL -sta -NonI -W Hidden -Exec Bypass -Enc JABQAH1AbwBnAHIAZQBzAHMAUABYAGUAZgBlAHIAZQBzAGMAZQA9ACIAUwBpAGwAZQBwAHQAAbS5AEHAbwBuAHQAaQBuAHUAZQA1ADsA
JABBAAGMADABpAG8AbgAGDAB1AB0AGUAdwAtAFMAyBwAGUAZAB1AGwAZQBkAFQYQBBzAGcSVABYAGKAZwBnAGUJcGAgCEB0ARABhAGKAbAB5ACALQBBhAQATAAZzGEABQpACALQBTATGUAdb0AGKAbgBnAHMAIAAloAE4ZQBzCBAUwBjAGcAZQBKAHUAbABLAGQAVABNHMAAwBtAGUAdB0AGKAbgBnAHMAUwBlAHQAQnpAIA==

cmd.exe /Q /C powershell.exe -NoP -NoL -sta -NonI -W Hidden -Exec Bypass -Enc JABQAH1AbwBnAHIAZQBzAHMAUABYAGUAZgBlAHIAZQBzAGMAZQA9ACIAUwBpAGwAZQBwAHQAAbS5AEHAbwBuAHQAaQBuAHUAZQA1ADsA
JABBAAGMADABpAG8AbgAGDAB1AB0AGUAdwAtAFMAyBwAGUAZAB1AGwAZQBkAFQYQBBzAGcSVABYAGKAZwBnAGUJcGAgCEB0ARABhAGKAbAB5ACALQBBhAQATAAZzGEABQpACALQBTATGUAdb0AGKAbgBnAHMAIAAloAE4ZQBzCBAUwBjAGcAZQBKAHUAbABLAGQAVABNHMAAwBtAGUAdB0AGKAbgBnAHMAUwBlAHQAQnpAIA==

whoami

whoami /groups

cmd.exe /Q /C powershell.exe -NoP -NoL -sta -NonI -W Hidden -Exec Bypass -Enc JABQAH1AbwBnAHIAZQBzAHMAUABYAGUAZgBlAHIAZQBzAGMAZQA9ACIAUwBpAGwAZQBwAHQAAbS5AEHAbwBuAHQAaQBuAHUAZQA1ADsA
JABBAAGMADABpAG8AbgAGDAB1AB0AGUAdwAtAFMAyBwAGUAZAB1AGwAZQBkAFQYQBBzAGcSVABYAGKAZwBnAGUJcGAgCEB0ARABhAGKAbAB5ACALQBBhAQATAAZzGEABQpACALQBTATGUAdb0AGKAbgBnAHMAIAAloAE4ZQBzCBAUwBjAGcAZQBKAHUAbABLAGQAVABNHMAAwBtAGUAdB0AGKAbgBnAHMAUwBlAHQAQnpAIA== 1> \\127.0.0.1\ADMIN$\\_1635524379,4070108 2>&1

powershell.exe -NoP -NoL -sta -NonI -W Hidden -Exec Bypass -Enc JABQAH1AbwBnAHIAZQBzAHMAUABYAGUAZgBlAHIAZQBzAGMAZQA9ACIAUwBpAGwAZQBwAHQAAbS5AEHAbwBuAHQAaQBuAHUAZQA1ADsA
```



Sur-apprentissage

```
root@db2641105d34: ~  
root@db2641105d34: ~ 78x19  
root@db2641105d34:~# python generate_sstic_text.py -m model/all_speeches.dump  
--start "Bonjour"  
Bonjour, on recrute, on recrute, on recrute, on recrute, on recrute, on recrute,  
on recrute, on recrute, on recrute, on recrute, on recrute, on recrute, on  
recrute, on recrute, on recrute, on recrute, on recrute, on recrute, on recrute,  
on recrute,  
root@db2641105d34:~# █
```



- 1 Introduction
- 2 Chaînes de Markov et ngrams - Application aux lignes de commande
- 3 Outil développé**



Outil à disposition

- ▶ Projet disponible sur le Github ANSSI
- ▶ Version écrite en python
- ▶ Version *custom command* dans Splunk



splunk®>



Custom command Splunk

splunk>enterprise Apps Administrator Messages Settings Activity Help

Search Analytics Datasets Reports Alerts Dashboards

New Search

Save As Create Tab

```
index=* | where len(CommandLine) > 4 | search process_name!="WerFault.exe" | anomark | sort markov_score
```

✓ 4,565 events (before 01/06/2022 13:41:27.000) No Event Sampling Job

Events (4,565) Patterns Statistics Visualization

Format Timeline Zoom Out Zoom to Selection Deselect

Show Fields Table Format 50 Per Page

1 2 3 4 5 6 7

_time	SubjectUserName	markov_score	process_name	NewProcessName	ParentPro
-------	-----------------	--------------	--------------	----------------	-----------



Conclusion

Cet algorithme nous prouve que l'apprentissage statistique est une source d'informations supplémentaires utile, et il ouvre la voie à d'autres algorithmes de détection d'anomalies, en traitement du langage ou pour d'autres exemples modélisables par des chaînes de Markov.



Merci pour votre écoute !