



Institut Cybersécurité Occitanie

**Défis
Clés**
OCCITANIE



Génération de trafic d'attaque réseau

Approches et représentation du trafic

Gabin Noblet

Journée Scientifique ICO – 12 juillet 2024



cnrs

Thèse encadrée par : Philippe DWEZARSKI, LAAS-CNRS & William RITCHIE, Custocy

Besoin de **beaucoup de données**



Développement

Benchmark et analyse



Difficultés de collecte




Données personnelles

Architectures complexes



Labellisation

Étudier la génération de trafic d'attaque réaliste



Génération d'attaques élémentaires

- Choix d'une **représentation de trafic**
 - Caractérisation du trafic adaptée à la problématique
- Choix de **modèle génératif** adapté
 - Architecture de modèle adaptée à la donnée
- Méthodes de **validation** et d'**évaluation** des modèles



Procédures
d'attaque

Dataset utilisé pour cette étude


Dataset public mis à disposition par la **CTU** (Czech Technical University)

- Composé de flux de **Command & Control** (+500k flux)
- Trafic **TCP** uniquement
- **Trafic réaliste** d'un botnet type **TrickBot**



Représentation du trafic

Ring et al. "Flow-based network traffic generation using Generative Adversarial Networks"



Echelle du paquet

Notion de flux

Dowoo et al. "PcapGAN: Packet Capture File Generator by Style-Based Generative Adversarial Networks"



Echelle du paquet

Notion de flux

Une approche hybride adaptée au trafic d'attaque



Représentation simplifiée d'un paquet

- Temps inter-paquets
- Sens dans le flux
- Taille de la payload
- Flags TCP

✓ Echelle du paquet

✓ Notion de flux

Une approche hybride adaptée au trafic d'attaque

Exemple flux de *Command & Control* :




IAT (s)	Direction	Payload (bytes)	Flags TCP
0.000	Forward	0	S
0.082	Backward	0	SA
0.001	Forward	0	A
0.022	Backward	388	PA

} Connexion




Génération de trafic réseau

Apprendre une représentation du trafic adaptée aux modèles de génération


- **Séquences multivariées**
 - **Types** de données **différents**
 - **Non utilisable** directement par un modèle de type **GAN** par exemple
 - **Projection** de la donnée dans un **espace « utilisable »** par **des modèles génératifs** à l'aide d'un **Autoencoder**.




Un mot sur les *Autoencoders*




FlowRAE – Modèle seq2vec



IAT



Payload




Erreurs de direction : **0,53%**
 Erreurs de flags : **0,47%**


● *Flows X* – Original
 ● *Flows X'* – Reconstruction

Discrétisation de l'espace latent

- **Apprendre un représentation latente discrète**
 - **Donnée réseau** composée majoritairement de caractéristiques **discrètes** ou **catégorielles**
 - Représentation d'un flux sous forme d'une **séquence de vecteurs discrets** extraits d'un **Codebook**
 - Forcer le modèle à utiliser la représentation latente




FlowVQ-RAE – Espace latent discret




- 1. Encoder :** Flux encodé en une **séquence Z_e**
- 2. Quantization :** Remplacement des **vecteurs** de la séquence par les **plus proches vecteurs** du **Codebook**.
- 3. Decoder :** Flux décodé à partir de cette **séquence discrète** de « **tokens** » en une **séquence de paquets**.


FlowVQ-RAE – Vector Quantization



IAT



Payload



Erreurs de direction : **0%**
Erreurs de flags : **0%**

- *Flows X* – Original
- *Flows X'* – Reconstruction

Génération de trafic réseau

Modèles génératifs

Choix d'un modèle génératif adapté

FlowRAE

- Modèle **seq2vec**
- Représentation **continue**
- **Génération** de **nouveau point** de l'espace latent

GAN

FlowVQ-RAE

- **Discrétisation** d'un flux
- Séquence d'**indices** de vecteur du *Codebook*
- Génération de séquences par **prédiction** du **prochain token**


Transformers

Résultats de génération


● Original
● Génération

GAN

IAT




Payload




3-way Handshake : **99,99%**
Paquet (PSH + Payload) : **88,6%**

Transformers

IAT



Payload



3-way Handshake : **99,99%**
Paquet (PSH + Payload) : **98,5%**

- Le **FlowVQ-RAE** couplé avec un **Transformer** est une **architecture prometteuse** pour la génération de trafic.
- Validation de cette approche avec un **dataset** plus **important** et plus **varié**
 - Contenant **plusieurs classes de trafic**
 - **Génération conditionnée** et identification des classes de trafic
 - Évaluation protocolaire plus approfondie
- **Premier papier scientifique**

MERCI