

# Journée des chercheurs CyberExcellence

8 Novembre 2022

**Charles-Henry Bertrand Van Ouytsel**

Promoteur: Axel Legay



## Qui suis-je ?

Doctorant en 4ème année de thèse @UCLouvain  
Twitter: @ChBertrandVo




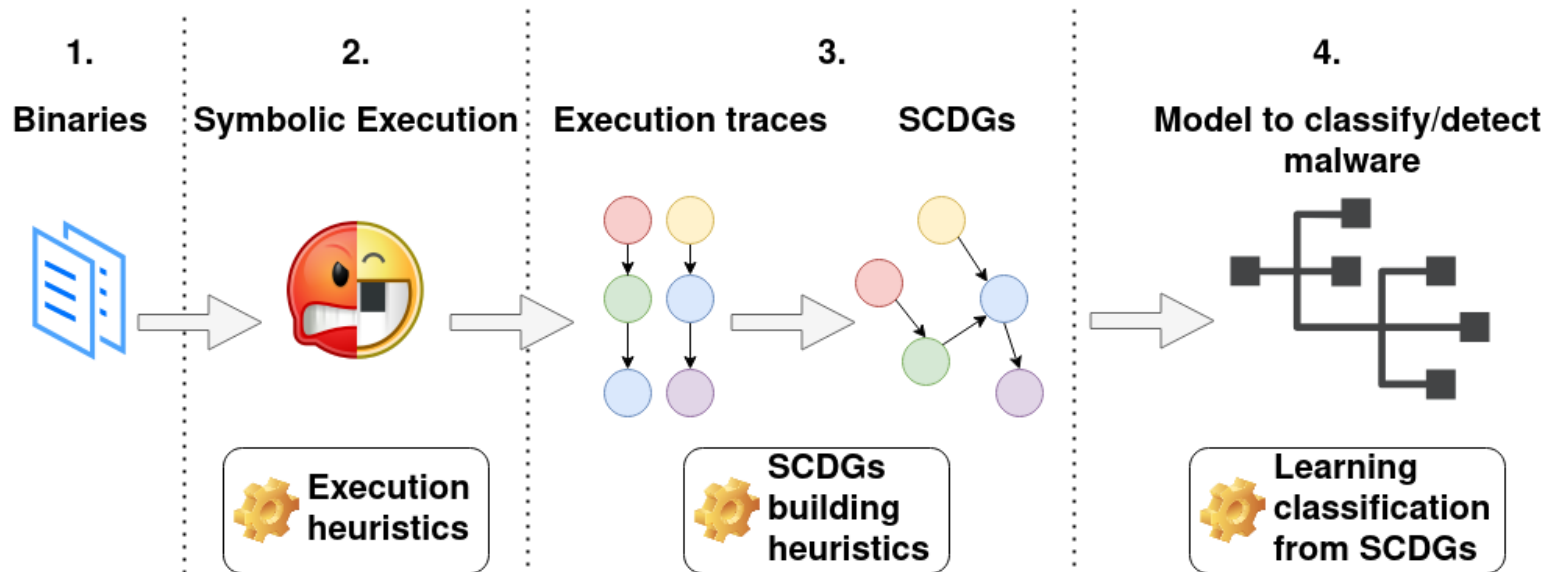
Mon sujet : "Analyse et classification de malwares basé sur des méthodes de machine learning."

Centre d'intérêt : Analyse de malware, Machine Learning et exécution symbolique

## Différents projets

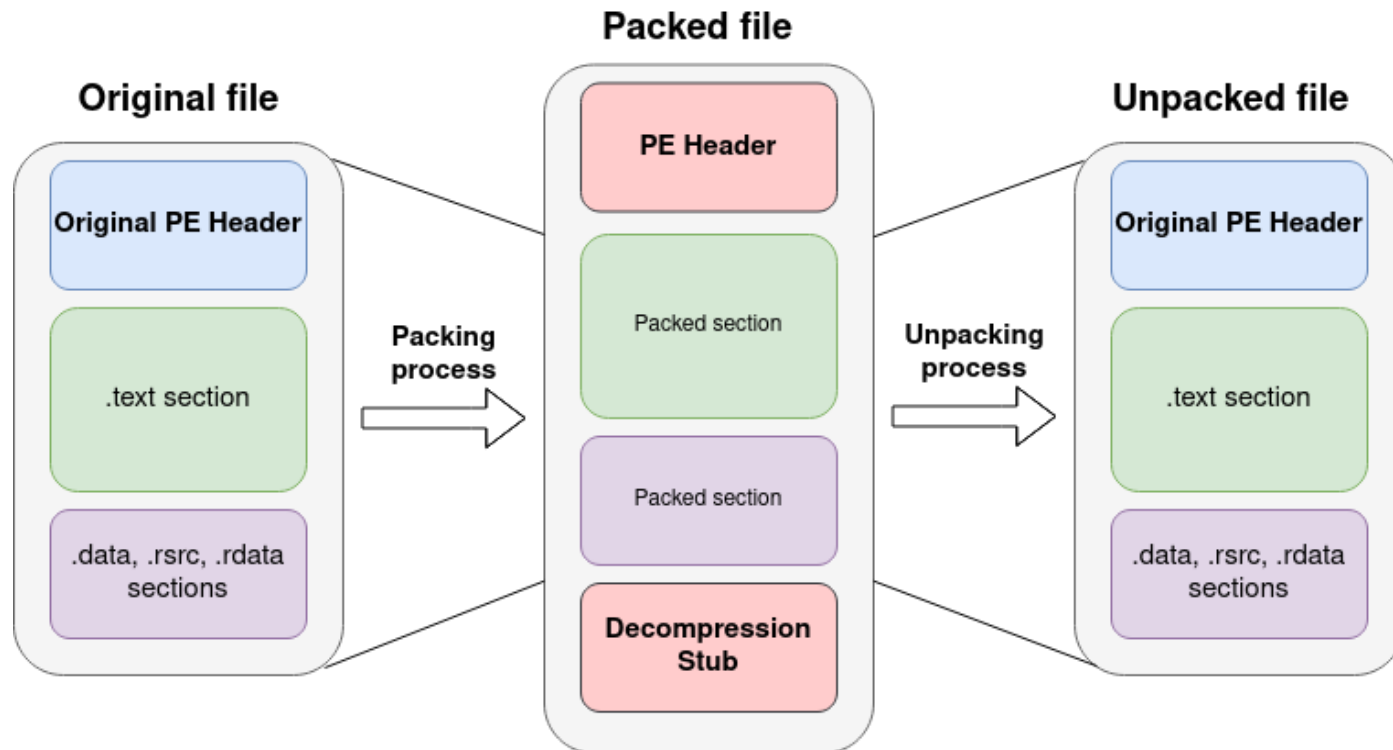
- SEMA : Symbolic Execution for Malware Analysis
- **Détection de packing par méthodes de machine learning**
- Federated Learning appliqué pour les classificateurs de malware

# SEMA : Symbolic Execution for Malware Analysis



# Packing : Qu'est-ce que c'est ?

Méthode d'**obfuscation** utilisées par les malware **mais aussi** par des logiciels légitimes pour protéger la propriété intellectuelle.




# Détection grâce au Machine Learning

Utilisation de 119 features définies dans la littérature.


Elles sont relatives : aux sections, bytes, permissions, entropies, header,...

Différents modèles de machine learning investigués: KNN, arbres, SVM,...




# Interpréter les décisions des classificateurs

Utilisation de méthodes d'explicabilité (i.e: SHAP) pour comprendre les décisions et trouver d'éventuelles pistes à creuser.



# Etudier les limites contre des adversaires

Utilisation d'un projet existant – MAB malware - pour muter des binaires et évader la détection des classificateurs.





# Packing-Box

Problème récurrent dans le domaine : Répétabilité des expériences et Ground Truth

Notre proposition: un outil permettant de créer ces propres datasets et d'entraîner/tester directement des modèles



Alexandre D'Hondt, Charles-Henry Bertrand Van Ouytsel et Axel Legay

<https://github.com/packing-box/docker-packing-box>

Bientôt présentée à



## Et après ?

Différentes pistes pour le futur : Amélioration de SEMA, prédictions conformes, méthodes d'interprétabilités, nouveaux classificateurs, étendre le federated learning ...

Plusieurs TFEs en cours avec des étudiants: analyse de Macro Excel, extension de SEMA (visualisation, méthodes d'exploration,...), mutations de malware existants, extension de la packing-box...

Merci pour votre attention !



**SCAN ME**

<https://www.meetup.com/fr-FR/dcg3210/>