

## **REbus**

Un bus de communication facilitant la coopération entre outils d'analyse de sécurité

Philippe Biondi, Xavier Mehrenberger, Sarah Zennou

3 juin 2015 / SSTIC

## Plan

- 1 Pourquoi et comment REbus ?
- 2 Concepts de REbus
  - Vue d'ensemble
  - Exemple d'agent
  - Implémentations du bus
- 3 Ensembles d'agents REbus
- 4 Conclusion

# Plan

- 1 Pourquoi et comment REbus ?
- 2 Concepts de REbus
  - Vue d'ensemble
  - Exemple d'agent
  - Implémentations du bus
- 3 Ensembles d'agents REbus
- 4 Conclusion

## Introduction - multitude de programmes spécialisés

### Travaux d'analyse de sécurité

- Nombreux outils d'analyse spécialisés
- Chacun d'entre eux aide à résoudre une partie du problème
- Tâches souvent répétitives

### REbus

- Outil développé pour résoudre le problème
- Licence BSD
- <https://bitbucket.org/iwseclabs/rebus>

## Exemples de domaines d'analyse

- Reconnaissance sur un réseau <sup>a</sup>
- Analyse forensique de disques durs <sup>b</sup>
- Analyse de certificats
- Analyse de javascript & pages web
- Collecte d'information sur les menaces (*Threat Intelligence*)

---

a. <https://bitbucket.org/iwseclabs/discobus>

b. <https://github.com/jahrome/DFIRbus>


## Écosystème d'outils d'analyse de programmes binaires

- Manipulation d'exécutables : Miasm, ElfEsteem, Amoco, metasm, ...
- Graphes : graphviz, Grandalf, ...
- Analyseurs statiques : libmagic, PEID, BAP, Bindiff, binwalk, outils maison, ...
- Outils interactifs : IDA, radare2, ...
- Sandboxes : Cuckoo, FireEye, ...
- Tests antivirus : VirusTotal, IRMA, ...
- Outils de classification
- Unpackers


## Exemple de workflow d'analyse




## Exemple de workflow d'analyse




## Exemple de workflow d'analyse




## Exemple de workflow d'analyse




## Exemple de workflow d'analyse




## Exemple de workflow d'analyse




## Exemple de workflow d'analyse




## Exemple de workflow d'analyse



## Exemple de workflow d'analyse





## Objectifs de REbus

### Faciliter le travail de l'outilleur et de l'analyste

- Ajout aisé d'une nouvelle fonctionnalité présente dans un outil externe
- Ajout aisé d'une variante d'une fonctionnalité déjà présente
- Utilisation comme « super-outil » ou infrastructure complète d'analyse
- Automatisation des tâches répétitives
- Passage à l'échelle
- Reproductibilité des analyses
- Stockage des résultats intermédiaires

## Considérations architecturales


Faire sur mesure

### Wrapper un outil




## Considérations architecturales

Faire sur mesure



## Considérations architecturales


Faire sur mesure



# Considérations architecturales

## Bibliothèques


Faire une lib de wrappers



# Considérations architecturales


## Bibliothèques

### Utiliser la bibliothèque



# Considérations architecturales


## Bibliothèques



# Considérations architecturales

## Bibliothèques


### Rajouter un outil et utilisation



## Considérations architecturales

Approche de type *framework*, workflow centralisé


*Framework*



## Considérations architecturales

Approche de type *framework*, *workflow* centralisé


### Rajout d'un *plug-in*



## Considérations architecturales

Approche de type *framework*, *workflow* décentralisé


### Workflow décentralisé



## Considérations architecturales

Approche de type *framework*, workflow décentralisé

### Ajout d'un plug-in



## Plan

- 1 Pourquoi et comment REbus ?
- 2 Concepts de REbus
  - Vue d'ensemble
  - Exemple d'agent
  - Implémentations du bus
- 3 Ensembles d'agents REbus
- 4 Conclusion

# Plan

- 1 Pourquoi et comment REbus ?
- 2 Concepts de REbus
  - Vue d'ensemble
  - Exemple d'agent
  - Implémentations du bus
- 3 Ensembles d'agents REbus
- 4 Conclusion

## Choix de conception

- Framework avec workflow décentralisé
- Sous la forme d'un bus de communication
- Un composant centralisé (*bus master*) pour faire circuler les messages
- La décision de traiter une donnée revient à l'agent (workflow décentralisé)
- Indépendant du mécanisme de transport sous-jacent (ex : DBus)
- Exhaustivité privilégiée à l'optimisation : des traitements superflus seront peut-être effectués

## Sécurité de REbus

### Pas un objectif (pour l'instant)

- Pas d'authentification, contrôle d'accès, contrôle d'intégrité
- Pas encore d'isolation automatique des outils d'analyse potentiellement exploitables par les données analysées

⇒ pour l'instant, traiter les données potentiellement dangereuses dans un environnement isolé

## Concepts de REbus

### Composants de REbus


**Descripteur** : contient la donnée et ses métadonnées associées

**Agent** : pilote un outil externe, interface entre ses entrées-sorties et le bus

**Bus** : permet la communication entre agents (transport)

**Bus Master** : reçoit tous les messages, s'assure du stockage, répond aux requêtes des agents

## Interfaces de REbus




## Dynamique des échanges entre agents sur le bus

### Description de l'outil obtenu


- extrait des fichiers .tgz
- calcule le *hash* MD5 de chaque fichier contenu dans l'archive
- affiche le *hash* MD5 sur la sortie standard

```
$ rebus_agent -m rebus_demo.agents hasher unarchive \  
inject ~/apt1.tgz -- \  
return --short md5_hash
```




## Dynamique des échanges entre agents sur le bus

```
$ rebus_agent -m rebus_demo.agents hasher unarchive \  
inject ~/apt1.tgz -- \  
return --short md5_hash
```




## Dynamique des échanges entre agents sur le bus

```
$ rebus_agent -m rebus_demo.agents hasher unarchive \  
inject ~/apt1.tgz -- \  
return --short md5_hash
```




## Dynamique des échanges entre agents sur le bus

```
$ rebus_agent -m rebus_demo.agents hasher unarchive \  
inject ~/apt1.tgz -- \  
return --short md5_hash
```




## Dynamique des échanges entre agents sur le bus

```
$ rebus_agent -m rebus_demo.agents hasher unarchive \  
inject ~/apt1.tgz -- \  
return --short md5_hash
```




## Dynamique des échanges entre agents sur le bus

```
$ rebus_agent -m rebus_demo.agents hasher unarchive \  
inject ~/apt1.tgz -- \  
return --short md5_hash
```




## Dynamique des échanges entre agents sur le bus

```
$ rebus_agent -m rebus_demo.agents hasher unarchive \  
    inject ~/apt1.tgz -- \  
    return --short md5_hash
```




## Dynamique des échanges entre agents sur le bus

```
$ rebus_agent -m rebus_demo.agents hasher unarchive \  
inject ~/apt1.tgz -- \  
return --short md5_hash
```




## Dynamique des échanges entre agents sur le bus

```
$ rebus_agent -m rebus_demo.agents hasher unarchive \  
    inject ~/apt1.tgz -- \  
    return --short md5_hash
```



## Dynamique des échanges entre agents sur le bus

```
$ rebus_agent -m rebus_demo.agents hasher unarchive \  
inject ~/apt1.tgz -- \  
return --short md5_hash
```



## LocalBus - exemple de combinaison d'agents

```
$ rebus_agent -m rebus_demo.agents hasher unarchive \  
                                                    inject ~/apt1.tgz -- \  
                                                    return --short md5_hash
```


```
apt1.tgz:AURIGA_6B31344B40E2AF9C9EE3BA707558C14E =  
6b31344b40e2af9c9ee3ba707558c14e
```

```
apt1.tgz:AURIGA_CD3A09EE99CFF9A58EFEA5CCBE2BED =  
cd3a09ee99cff9a58efea5ccbe2bed
```

```
apt1.tgz:BANGAT_468FF2C12CFFC7E5B2FE0EE6BB3B239E =  
468ff2c12cffc7e5b2fe0ee6bb3b239e
```

```
[...]
```

## La soupe de descripteurs



## Plan

- 1 Pourquoi et comment REbus ?
- 2 Concepts de REbus
  - Vue d'ensemble
  - Exemple d'agent
  - Implémentations du bus
- 3 Ensembles d'agents REbus
- 4 Conclusion

```

from rebus.agent import Agent
import hashlib

@Agent.register
class Hasher(Agent):
    _name_ = "hasher"
    _desc_ = "Return md5 of a binary"

    def selector_filter(self, selector):
        # Cet agent traite uniquement les descripteurs dont le
        # sélecteur commence par "/binary/"
        return selector.startswith("/binary/")

    def process(self, desc, sender_id):
        # Compute md5 hash value
        md5_hash = hashlib.md5(desc.value).hexdigest()

        # Create a new child descriptor
        new_desc = desc.spawn_descriptor(
            "/md5_hash", unicode(md5_hash), self.name)

        # Push the new descriptor to the bus
        self.push(new_desc)

```

Listing 1 – Agent REbus calculant le hash MD5 de fichiers binaires

## Agent

```
class Hasher(Agent):  
    _name_ = "hasher"  
    _desc_ = "Return md5 of a binary"
```

### Agent

- Pilote un outil externe
- Interface avec le bus :
  - Choix des données traitées
  - Transformations des données
  - Envoi des données traitées

## Filtrage des entrées

```
def selector_filter(self, selector):  
    # Cet agent traite uniquement les descripteurs dont le  
    # selecteur commence par "/binary/"  
    return selector.startswith("/binary/")
```

### Sélecteur

- Exemple :  
/signature/md5/%6e1d5169661a50(...)f989129a583f92b9dee
- Décrit le type de la données encapsulée ( $\simeq$  type MIME) : image, fichier binaire, etc.
- Décrit le format de la donnée (ex. JPG ou PNG pour une image, PE ou ELF pour un binaire, etc.),
- Identifié de manière unique par un hash (SHA256)

## Traitement des données

```
def process(self, desc, sender_id):  
    # Compute md5 hash value  
    md5_hash = hashlib.md5(desc.value).hexdigest()
```

### Exemple de descripteur

```
{'selector': '/binary/pe/%aaf3ad(...)3d50aad60',  
'_value': 'MZ\x90\x00\x03\x00\x00\x00\x04\x00\x00\x00...',  
'label': 'AURIGA_sample_6B31344B40E2AF9C9EE3BA707558C14E',  
'agent': (reference vers l'objet agent),  
'bus': (reference vers l'objet bus),  
'domain': 'default',  
'hash': '403f73b357(...)8841100871b',  
'precursors': [],  
'processing_time': 0.0135,  
'uuid': 'c0cd0811-f108-5447-8bc0-ee2b53311d9',  
'version': 0}
```

## Création et envoi d'un descripteur

```
def process(self, desc, sender_id):  
    # Compute md5 hash value  
    md5_hash = hashlib.md5(desc.value).hexdigest()  
  
    # Create a new child descriptor  
    new_desc = desc.spawn_descriptor(  
        "/md5_hash", unicode(md5_hash), self.name)  
  
    # Push the new descriptor to the bus  
    self.push(new_desc)
```

### Création d'un descripteur

- Choix du sélecteur
- Valeur
- Envoi vers bus

## Modes de traitement des descripteurs

### Trois modes de fonctionnement possibles

- Automatique
- Sur demande de l'utilisateur
- Lorsque le bus est inactif

# Plan

- 1 Pourquoi et comment REbus ?
- 2 Concepts de REbus
  - Vue d'ensemble
  - Exemple d'agent
  - Implémentations du bus
- 3 Ensembles d'agents REbus
- 4 Conclusion

## Implémentations de l'API bus

Les agents sont indépendants de l'implémentation du bus

### Implémentations existantes


- localbus, mode super-outil
- REbus over DBus, mode interactif

### Implémentations prévues

- MPI
- HTTP REST
- 0mq


## Implémentation de l'API Bus : Localbus

### Architecture : REbus Local Bus



## Implémentation de l'API Bus : DBus

### Architecture : REbus au-dessus de DBus



# Plan

- 1 Pourquoi et comment REbus ?
- 2 Concepts de REbus
  - Vue d'ensemble
  - Exemple d'agent
  - Implémentations du bus
- 3 Ensembles d'agents REbus**
- 4 Conclusion

## Exemples d'agents existants

### Agents d'intendance du bus

**inject** injecte un fichier dans le bus

**ls** liste de descripteurs

**unarchive** extrait les archives et fichiers compressés, injecte les fichiers

**return** affichage sur stdout des descripteurs sont le sélecteurs correspondent à l'expression rationnelle donnée

**link\_finder** recherche des liens entre descripteurs (ex. même valeur)

**link\_grapher** crée des graphes (dot) à partir des liens existant entre descripteurs

**dotrenderer** rendu de graphes dot vers svg

**web\_interface** interface web générique

## Exemples d'agents

### Agents de démonstration

**hasher** calcul le *hash* MD5 de binaires

**stringer** renvoie la sortie de `strings` exécuté sur un binaire

**grep** renvoie sur `stdout` la valeur des descripteurs de type `/string/` correspondant à la *regex* fournie

rebus\_demo\_agents sur [https://bitbucket.org/iwseclabs/rebus\\_demo](https://bitbucket.org/iwseclabs/rebus_demo)


## LocalBus - exemple de combinaison d'agents

### Objectif de l'outil obtenu

- entrée : plusieurs fichiers exécutables
- sortie : graphe montrant les exécutables ayant la même valeur d'importhash
- importhash : hash MD5 de la liste des DLLs et fonctions importées

```
$ rebus_agent -m bnew.agents \  
  inject * -- \  
  file_identification \  
  link_finder -- \  
  :: \  
  #(etape 2)  
  link_grapher '/link/link_finder/signature-impash' --\  
  dotrenderer \  
  return '/graph/svg' --raw \  
> ~/links-apt1.svg
```





## Agents de découverte de services réseau

### Liste d'agents

**hostdis** Scan d'un sous-réseau (basé sur *scapy*)

**hostscan** Scan de ports TCP et UDP

**bannergrabber** Connexion au port TCP, récupération de la bannière


**nmaptcpscan** Scan de ports utilisant *nmap*

**nmapreportextract** Analyse de rapport de scan *nmap* XML

**nikto** Exécution de *nikto* sur les serveurs HTTP découverts

## Agents de découverte de services réseau

### Sélecteurs en entrée/sortie



## Démonstration

- En mode infrastructure (DBus)

# Plan

- 1 Pourquoi et comment REbus ?
- 2 Concepts de REbus
  - Vue d'ensemble
  - Exemple d'agent
  - Implémentations du bus
- 3 Ensembles d'agents REbus
- 4 Conclusion

## Retour d'expérience

- Principalement utilisé à des fins d'analyse et de classification de malware, en 3 étapes :
  - Extraction de caractéristiques
  - Calcul de distances
  - Apprentissage et classification
- Modularité
  - Remplacement d'un composant par un autre
  - Combinaison des résultats de deux outils ayant le même but
- Développement d'agent : rapide
- Injection de 21 757 listings assembleur, quelques dizaines de Go

### Axes d'amélioration

- Fichiers de taille >150 Mo non supportés (timeout D-Bus)

## Conclusions

### Inconvénient

- Traitements efficaces, pas efficaces
- Performances inférieures à un outil *ad-hoc*

### Avantages

- Framework
  - Workflow décentralisé
  - Faible couplage entre les agents
- ⇒ très peu d'impacts inter-agents
- ⇒ paradigme efficace pour découper un gros problème en petits problèmes
- Robuste

## Évolutions futures

- Passage de valeurs par référence (presque fini)
- Gestion de dépendances
- Tests d'intégration et unitaires plus nombreux
- Automatisation du déploiement sur plusieurs machines (en cours)
- Exécution de programmes externes dans un environnement isolé (seccomp, namespaces)
- Nouvelle implémentation de l'API Bus, basée sur 0mq, REST ou MPI
- Indexation et recherche intégrée à l'agent `web_interface`
- Support du développement d'agents dans d'autres langages

## Diffusion

- Dépôts mercurial
  - rebus sur <https://bitbucket.org/iwseclabs/rebus>
  - rebus\_demo\_agents sur [https://bitbucket.org/iwseclabs/rebus\\_demo](https://bitbucket.org/iwseclabs/rebus_demo)
  - discobus sur <https://bitbucket.org/iwseclabs/discobus>
- Documentation auto-générée par sphinx
- Recette de construction d'image docker contenant toutes les dépendances nécessaires
- Licence BSD

## Plan

- 5 Backup slides
  - Descripteurs
  - Agents
  - Bus
  - Stockage
  - Modes de traitement

## Plan

- 5 Backup slides
  - Descripteurs
  - Agents
  - Bus
  - Stockage
  - Modes de traitement

## Conteneurs de données : Descripteurs

### Rôle de l'objet

- Objets Python
- Produits par des agents
- Encapsulent une valeur, représentée par une chaîne de caractères
- Produits à partir de données exogènes (utilisateur, service tiers, ...) ou à partir d'autres descripteurs, appelés parents
- Identifiés par leur sélecteur :
  - exemple : `/signature/md5/%6e1d5169661a50(... )f989129a583f92b9dee`
  - décrit le type de la données encapsulée ( $\simeq$  type MIME) : image, fichier binaire, etc.
  - décrit le format de la donnée (ex. JPG ou PNG pour une image, PE ou ELF pour un binaire, etc.),
  - identifie de manière unique un descripteur par un *hash* (SHA256) dépendant :
    - de la valeur stockée,
    - du nom de l'agent ayant généré le descripteur,
    - du sélecteur des éventuels descripteurs parents,
    - du début de la chaîne du sélecteur (tout sauf le *hash*).

## Conteneurs de données : Descripteurs

### Propriétés de l'objet

**sélecteur** chaîne de texte identifiant le descripteurs

**étiquette** étiquette compréhensible par l'utilisateur (ex. nom de fichier)

**uuid** regroupe les descripteurs créés à partir d'un même objet analysé

**valeur** valeur du descripteur

**précurseurs** liste des sélecteurs des parents

**nom d'agent** nom de l'agent ayant produit ce descripteur

**domaine** sépare complètement des tâches d'analyse au sein d'une même instance

**version** numéro de version, incrémenté lors de la mise à jour d'un descripteur

**temps de traitement** temps de génération du descripteur

## Conteneurs de données : Descripteurs

### Méthodes de l'objet

- Générer un nouveau descripteur, pouvant être lié à la même analyse (même zone UUID)
- Générer une nouvelle version d'un descripteur
- Créer un lien entre deux descripteurs, en précisant la raison
- (Dé)sérialiser

## Plan

- 5 Backup slides
  - Descripteurs
  - Agents
  - Bus
  - Stockage
  - Modes de traitement

# Agents

## Vue d'ensemble

- Programmes Python
- Interface entre un outil et REbus
  - Choisit les données provenant du bus pouvant être traitées par l'outil
  - Convertit le format des données si nécessaire
  - Fournit les données à l'outil via l'interface de l'outil
  - Envoie vers le bus la sortie de l'outil

## API Agents

### Agent effectuant un traitement ponctuel

- Appel de la méthode `run` au lancement de l'agent
- Arrêt de l'agent lorsque cette méthode retourne
- Exemples d'agents :
  - Injection de fichiers (ex. `inject`)
  - Obtention d'informations exogènes (ex. `http_listener`)
  - Traitement ponctuel (ex. `request_processing`, `link_grapher`, `search`)

## API Agents

### Agent consommant des descripteurs

- Envoi du sélecteur de chaque nouveau descripteur à tous les agents par le bus
- Appel successif de deux méthodes de filtrage ; arrêt du traitement si `False`
  - `selector_filter(sélecteur)`
  - `descriptor_filter(descripteur)`
- Appel de la méthode `process` ou `bulk_process`
- (facultatif) Création de nouveaux descripteurs par l'agent, appel de `push` pour les envoyer sur le bus

# Plan

- 5 Backup slides
  - Descripteurs
  - Agents
  - **Bus**
  - Stockage
  - Modes de traitement

## API du bus de communication

### Rôles du bus

- Transporte les descripteurs envoyés par les agents vers le Bus Master
- Annonce les sélecteurs des nouveaux descripteurs
- Transporte les demandes des agents (obtention de descripteur, recherche, ...)
- Répartit les descripteurs entre plusieurs instances d'un même agent
- Sauvegarde et restaure l'état interne des agents lors de l'arrêt ou la reprise du bus

## Plan

- 5 Backup slides
  - Descripteurs
  - Agents
  - Bus
  - Stockage
  - Modes de traitement

## Stockage

### API des modules de stockage

- Recherche de descripteurs par zone UUID, sélecteur ou valeur
- Obtention de la liste des analyses (zones UUID) existantes
- Enregistrement et restauration de l'état interne des agents (utile lors de l'arrêt/reprise du bus)
- Suivi du traitement des descripteurs par chaque agent, fourniture de la liste des traitements non effectués

### Modules de stockage existants

- RAMStorage stocke toutes les données en RAM ; elles seront perdues lors de l'arrêt du bus
- DiskStorage : enregistre les descripteurs et les états internes des agents sur le disque, ce qui permet l'arrêt et la reprise des analyses depuis une configuration donnée

## Plan

- 5 Backup slides
  - Descripteurs
  - Agents
  - Bus
  - Stockage
  - Modes de traitement

## Modes de traitement des descripteurs (1)

- Dans chaque agent, un attribut décrit les modes supportés (valeur par défaut sinon)

### Mode automatique

- Tous les descripteurs acceptés par `selector_filter` puis `descriptor_filter` sont traités immédiatement
- Tous les descripteurs sont marqués *traités*

### Mode interactif

- Les descripteurs non intéressants pour l'agent sont marqués *traités*
- Les descripteurs intéressants pour l'agent (`selector_filter`) sont marqués *traitables*
- Le traitement s'effectue sur demande de l'utilisateur (agent `request_processing`, interface web, API)

## Modes de traitement des descripteurs (2)

### Mode idle

- Les descripteurs non intéressants pour l'agent sont marqués *traités*
- Les descripteurs intéressants pour l'agent (`selector_filter`) sont enregistrés
- Le traitement est effectué en masse (`bulk_process`) lorsque le bus envoie un signal indiquant qu'aucun traitement n'est en cours