

# Octopus password breaker

14 avril 2015

**Danny Francis**

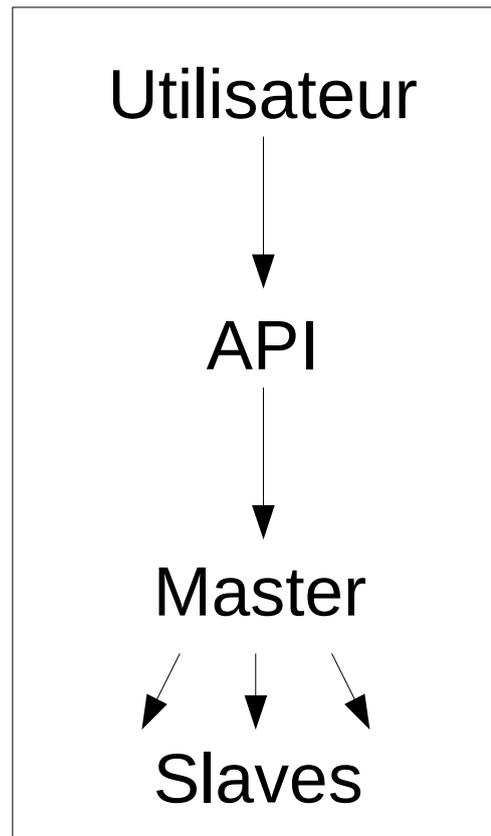
<danny.francis@telecom-paristech.fr>

- Un espace de recherche extrêmement grand, dont la taille augmente exponentiellement par rapport aux tailles des mots de passe
- Impossible de le parcourir exhaustivement
- Méthodes pour optimiser la recherche :
  - *Tester d'abord les mots de passe les plus probables (dictionnaires, masques) => Outils usuels tels que John the Ripper, Hashcat ou oclHashcat*
  - *Augmenter la puissance de l'ordinateur => le coût d'un ordinateur augmente bien plus vite que sa puissance*
  - *Combiner plusieurs machines => moins coûteux, mais nécessite un intermédiaire pour les faire communiquer entre elles*
- La première et la troisième méthode sont utilisées dans Octopus

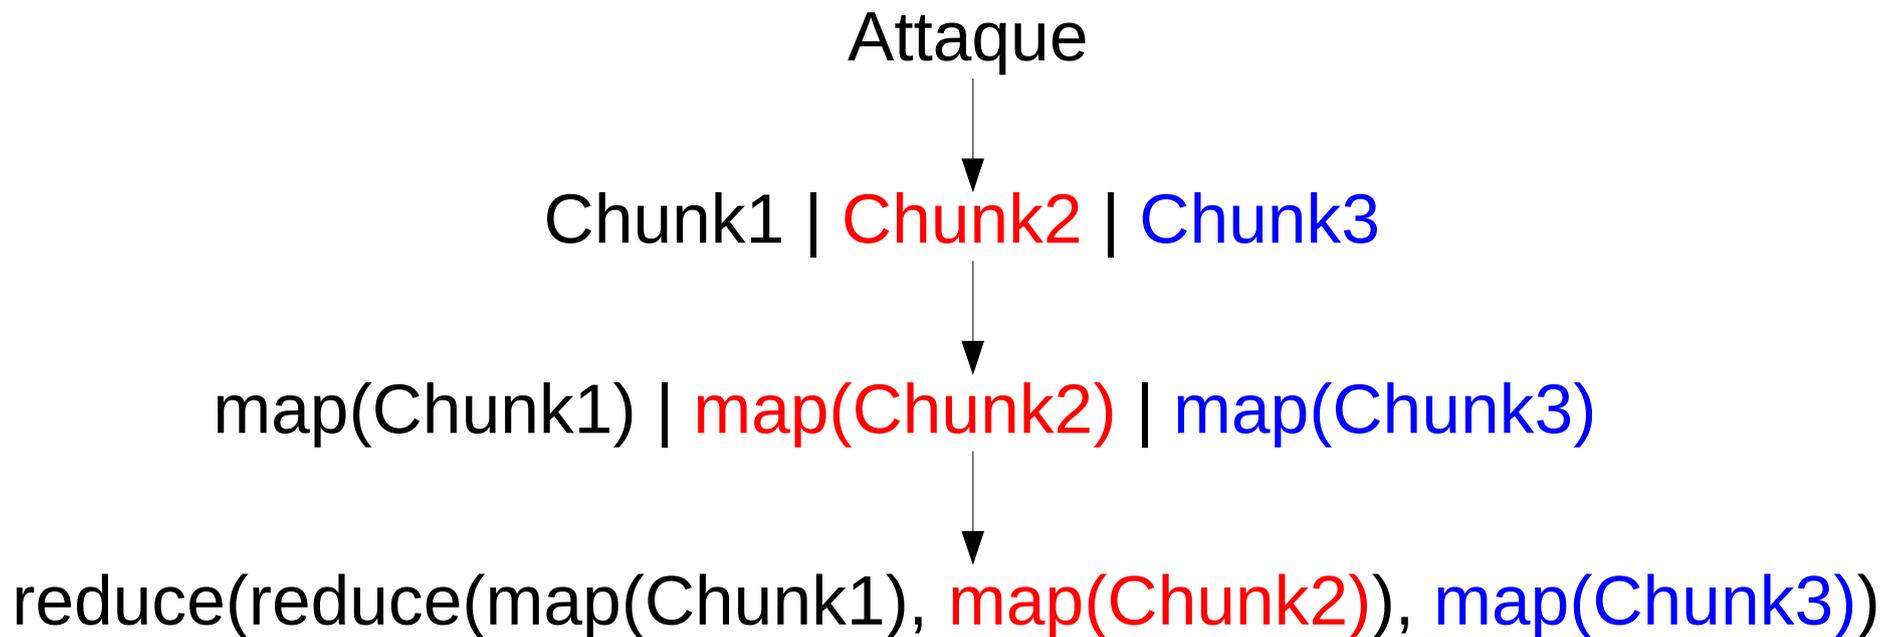
- John the Ripper : casseur de mots de passe *open source*
- Distribuer des attaques avec John the Ripper :
  - *Utilise la norme MPI*
  - *Pas de tolérance de fautes*
- Hashcat/oclHashcat : gratuit mais pas *open source*
- Distribuer des attaques avec Hashcat ou oclHashcat :
  - *Hashtopus*
  - *Ne fonctionne qu'avec Hashcat*

- Elcomsoft Distributed Password Recovery
  - *Apparemment très efficace*
  - *Pas open source = impossible d'ajouter de nouveaux algorithmes*
  - *\$\$\$: 599 euros pour 5 machines, 1999 euros pour 20 machines, 4999 euros pour 100 machines*
- Distributed Hash Cracker par Andrew Zonenberg
  - *Papier universitaire à propos d'un casseur de mots de passe distribué*
  - *CPU + GPU*
  - *Tolérance de fautes*
  - *Seulement MD5*
- MWR Distributed Hash Cracking on the Web
  - *WebCL => n'importe quelle machine pourra l'utiliser*
  - *Mauvaises performances selon les mesures de MWR Labs à cause de la lenteur de Javascript : 15 fois plus lent que oclHashcat*

- Octopus : faire travailler ensemble des machines qui savent travailler séparément
- Architecture « *master-slave* »



- Distribuer et récupérer des résultats : MapReduce
  - *Division de l'attaque en attaques moins coûteuses*
  - *Les nœuds dits esclaves réalisent les petites attaques (fonction « map »)*
  - *Les résultats sont combinés en une seule liste (fonction « reduce »)*



- Les nœuds communiquent entre eux avec ce type de messages :

**FONCTION arg1 arg2**

- Messages empaquetés dans des JSON

**[FONCTION, arg1, arg2]**

- Envoyés par requêtes HTTP GET
- UI : Interface Web

Attaques en cours

Attaques terminées

Machines disponibles

Lancer une attaque simple

Lancer une attaque par politique

Nouvelle politique d'attaque

Gestion des politiques

## Tableau de bord

### Attaques en cours

ID	Temps écoulé	Tâches réalisées	Mots de passe trouvés	Actions
dominos29	0j, 19h, 8min, 8sec	0/13600	0/10000	  
dominos25	0j, 19h, 8min, 48sec	2/16	2/10000	  
dominos26	0j, 19h, 8min, 36sec	2/132	4/10000	  
dominos27	0j, 19h, 8min, 23sec	6/56	0/10000	  
dominos20	0j, 19h, 11min, 23sec	8/132	10/10000	  
dominos21	0j, 19h, 10min, 45sec	2/16	6/10000	  
dominos22	0j, 19h, 10min, 30sec	2/112	0/10000	  
dominos23	0j, 19h, 10min, 20sec	3/416	0/10000	  
dominos06	0j, 19h, 18min, 14sec	4/56	0/10000	  
dominos04	0j, 19h, 18min, 41sec	7/16	3731/10000	  

- Fonctions d'Octopus :
  - *NODETYPE* : identifie le type de nœud
  - *PUT* : envoie un objet (généralement un hash ou une petite attaque)
  - *GET* : demande une information
  - *DO* : envoie une attaque
  - *RESULT* : envoie un résultat (pour une attaque mais aussi pour une requête *GET*)
  - *REMOVE* : supprime un objet
  - *OK* : action réalisée avec succès
  - *ERROR* : erreur

- Partie *back-end* : Python
- Twisted Python
  - *Programmation asynchrone*
  - *Deferreds, callbacks*

- Deux types d'objets pour chaque nœud : les Factory et les Protocol
- Factory:
  - *Caractéristiques liées au nœud enregistrées dans ses attributs*
  - *Crée un objet Protocol quand un autre nœud s'y connecte*
- Protocol:
  - *Empaquette les requêtes dans des JSON et des requêtes HTTP GET*
  - *Lit les requêtes reçues et déclenche les actions correspondantes*

- Interface réalisée avec un template Bootstrap
  - Bootstrap : Ensemble d'outils Web réalisé par Twitter
- Interactions avec l'utilisateur : JavaScript + JQuery

Front-end: JavaScript + JQuery



Back-end: Twisted Python (API + masters + slaves)

- Informations disponibles

## Attaques en cours

ID	Temps écoulé	Tâches réalisées	Mots de passe trouvés	Actions
dominos29	0j, 19h, 8min, 8sec	0/13600	0/10000	  

## Résultats pour dominos33

```
avonlea7:b2eefbbe020227c554aec4a580ca6360
massive7:ae3d28cf22e10b120501b464587a368e
licorne7:0b172848bab50f4c7473f230cd7aa6aa
orioles8:f0f21a9de5a7f08de4574e426762a5b8
qwknrc8:71a21ae8270c24e0456a9cea328b8e5a
sparkle7:03bccfc2f2bbc59bbcb1341037b14261
```

Fermer

- Informations disponibles

## Attaques terminées

ID	Temps écoulé	Mots de passe trouvés	Actions
dominos24	0j, 2h, 58min, 57sec	22/10000	 
dominos32	0j, 2h, 29min, 10sec	24/10000	 
dominos07	0j, 19h, 3min, 8sec	0/10000	 

## Attaques arrêtées

ID	Temps écoulé	Mots de passe trouvés	Actions
<i>Aucune tâche arrêtée</i>			

- Informations disponibles

## Tableau de bord

### Machines disponibles

Adresse IP	Programme utilisé	Ressources utilisées	Kick
127.0.0.1:48569	hashcat	 100%	

- Politiques d'attaque

## Nouvelle politique d'attaque

---

**Nom de la politique**

**Attaques**

Ordre	Type d'attaque	Attaque	Supprimer
1	toggle_case	john	✘
2	dictionary	rockyou	✘
3	mask	?a	✘
4	mask	?a?a	✘
5	mask	?a?a?a	✘

- Politiques d'attaque

## Gestion des politiques

dominos Supprimer

Ordre	Type d'attaque	Attaque
1	mask	?a
2	mask	?a?a
3	mask	?a?a?a
4	mask	?a?a?a?a

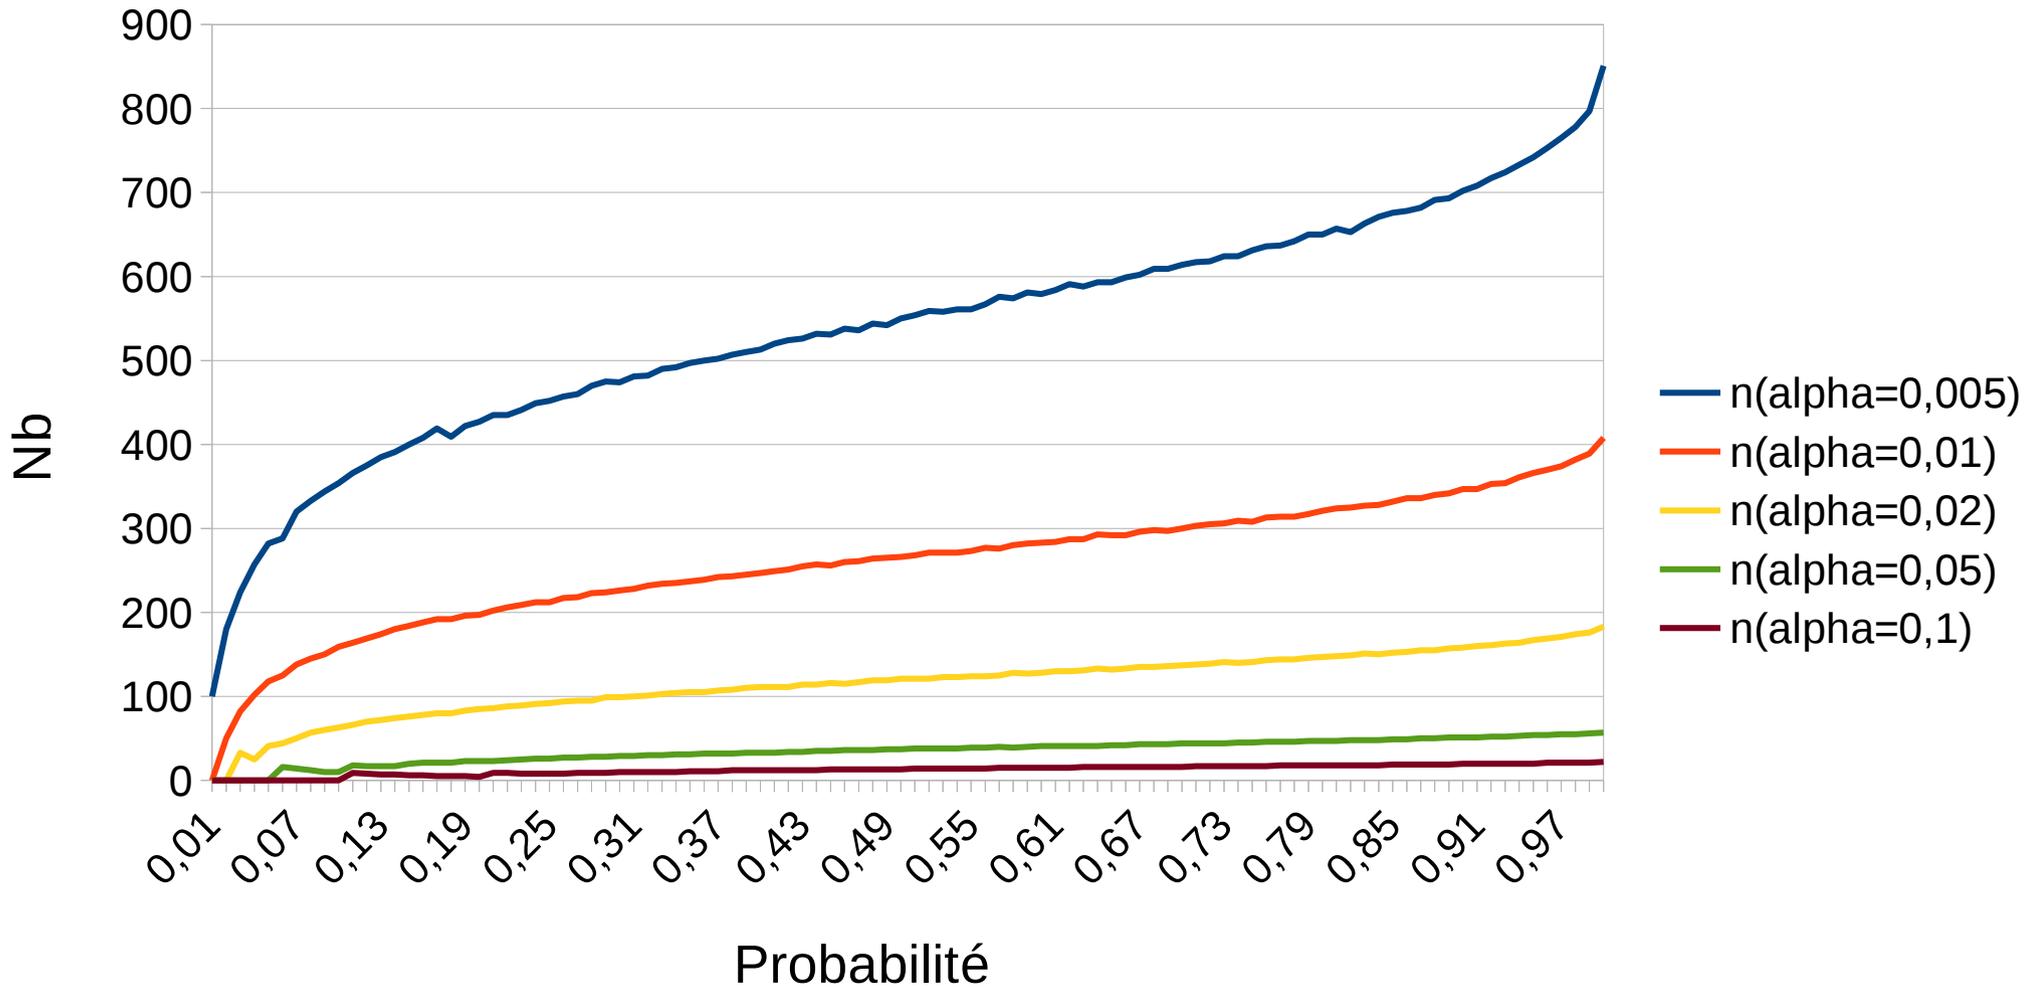
- Attaques possibles
  - *Attaques simples*
    - Dictionnaires
    - Masques
    - Variantes (toggle-case, etc.)
  - *Politiques d'attaques*
    - Séquence d'attaques simples
    - Ex : attaque par dictionnaire, puis toutes les chaînes de minuscules de longueur 8, etc.
  - *Attaque automatique (Markov)*

- Chaînes de Markov
- Modèle probabilistique
  - *Étant donnés un système et un ensemble d'états, la probabilité de passer à un état à partir d'un autre état ne dépend pas des états parcourus auparavant*
  - *Ex : un nageur nage contre le courant, et vérifie sa progression toutes les 30 secondes*
    - *État a : il a avancé*
    - *État b : il n'a pas bougé*
    - *État c : il a reculé*
    - *Au temps t : il est à l'état a*
    - *Chaînes de Markov : la probabilité de passer à l'état b trente secondes plus tard ne dépend pas de comment le nageur a nagé auparavant*

- Mode Markov de John the Ripper
  - *Probabilité d'obtenir un  $h$  après un  $c$  supérieure à la probabilité d'obtenir un  $h$  après un  $m$*
- Mode automatique d'Octopus
  - *Probabilité qu'une attaque donnée fasse passer le pourcentage de mots de passe découverts de  $i$  % à  $j$  %*
  - *Processus de décision markovien :  $(E, A, P)$* 
    - *$E$  = entiers compris entre 0 et 100 (pourcentage de mots de passe découverts)*
    - *$A$  = ensemble d'attaques simples*
    - *$P$  = fonction qui associe  $P(a, i, j)$  à une attaque  $a$ , un entier  $i$  et un entier  $j$ , avec  $P(a, i, j)$  étant la probabilité que  $a$  fasse passer le pourcentage de mots de passe découverts de  $i$  % à  $j$  %*
  - *Notre but : déterminer  $P$* 
    - *Grâce à  $P$  et au temps moyen mis par des attaques simples, on peut déterminer la politique d'attaque qui serait la meilleure compte tenu d'une deadline donnée*

- Comment déterminer P
  - *Apprendre grâce aux attaques réalisées par Octopus sur plus de 1000 hashes*
    - Pour chaque attaque : tableau à deux dimensions  $T$  tel que  $T[i, j]$  = probabilité d'augmenter le pourcentage de mots de passe découverts de  $i$  % à  $j$  %
    - Si une attaque fait passer ce pourcentage de  $i$  % à  $j$  % :
      - $T[i, j] = T[i, j] \times (1 - \alpha) + \alpha$
      - Pour  $j' \neq j$  :  $T[i, j'] = T[i, j'] \times (1 - \alpha)$
    - Avec  $\alpha$  un paramètre à choisir entre 0 et 1
      - Si  $\alpha$  est très petit, convergence lente mais bonne précision à long terme
      - Si  $\alpha \approx 0.1$ , convergence rapide mais mauvaise précision à long terme
    - Question : quelle valeur donner à  $\alpha$  ?

- Convergence



- Passage à l'échelle ?
- Trois machines
  - Machine 1: oclHashcat, AMD Radeon HD 6630
  - Machine 2: Hashcat, quad-core Intel Core i5-3320M CPU @ 2.60GHz
  - Machine 3 : Hashcat, dual-core Intel Core 2 Duo CPU P8600 @ 2.40GHz
- Communiquent *via* le réseau Wifi HSC

- Casser 15000 hashes en testant toutes les chaînes de minuscules de longueur 9
- Test de chaque machine séparément avec son propre outil, puis ensemble avec Octopus
- Après une heure de cassage :
  - *Mesure du pourcentage de l'espace de recherche couvert par chaque machine séparément*
  - *Mesure du pourcentage de l'espace de recherche couvert par le cluster entier*
  - *Soient M1, M2, M3 les pourcentages des machines 1, 2 and 3, et MC le pourcentage pour le cluster. Avec un passage à l'échelle, nous devrions avoir :*

$$M1 + M2 + M3 = MC$$

- Résultats
  - *Machine 1 : 17.7 %/h*
  - *Machine 2 : 1.5 %/h*
  - *Machine 3 : 0.4 %/h*
  - *Cluster : 19.3 %/h (théorie : 19,6%/h)*
- Le passage à l'échelle semble être réalisé
- Quelles limites...
  - *Faible nombre de machines*
  - *Attaque par masque : peu d'échanges de données → une attaque par dictionnaire serait bien moins efficace si les chunks devaient être échangés*
  - *Question : en supposant le passage à l'échelle réalisé, quand est-ce qu'une attaque par dictionnaire est plus efficace avec un cluster qu'avec une simple machine ?*

- Pour la machine 1 (Mach1)
  - 483104 MD5 hashes, attaque par dictionnaire avec RockYou (size ~ 100 MB et des mots de longueur moyenne ~ 10) : 7 secondes
- Quand est-ce qu'un cluster de Mach1 est plus efficace qu'une simple Mach1 ?
  - Soit  $t_m$  le temps moyen pris pour tester un mot, soit  $n_c$  le nombre de chunks, soit  $C$  la taille d'un chunk,  $m$  la taille d'un mot et soit  $T_1$  le temps mis par Mach1 :

$$T_1 = (t_m \times n_c \times C) / m$$

- Soit  $D$  le débit moyen entre deux machines, soit  $n_n$  le nombre de nœuds et soit  $T_2$  le temps mis par le cluster :

$$T_2 = [(n_c \times C) / n_n] \times [t_m / m + 1 / D]$$

- But :  $T1 < T2$
- Application numérique
  - $t_m = 7 \times 10^{-7}$  secondes
  - $D = 5 \times 10^6$  octets/seconde
  - $m = 10$  octets
  - Résultat :

$$n_n \geq 4$$

- *Mauvaises conditions : on peut supposer qu'un cluster de quatre machines sera toujours (beaucoup) plus efficace qu'une machine seule*

- Nombre maximum de machines ?
- Attaques par dictionnaire longues
- Pas de communications sécurisées → à utiliser dans un réseau isolé avec des utilisateurs de confiance...

- Aux alentours du 15 mai : documentation, et quelques améliorations
  - Nombre de divisions par attaque et par type de hash
  - Identifier les hashes et attaques disponibles pour chaque slavenode
  - Donner la possibilité de placer des dictionnaires directement sur les slavenodes
  - Types de hashes supplémentaires
- Fin juin ou début juillet : l'implémentation complète de l'attaque automatique

## Conclusion

- Casseur de hashes flexible et distribué
- Une caractéristique originale : un mode automatique reposant sur un processus de décision markovien
- Quelques limites, en particulier concernant la sécurité des communications
- Open-source, sur GitHub : <https://github.com/hsc-lab/octopus>

