

Les mots de passe Windows à la merci des compromis temps-mémoire

Philippe Oechslin

Laboratoire de Sécurité et de Cryptographie

Ecole Polytechnique Fédérale de Lausanne

philippe.oechslin@epfl.ch



Plan de la présentation

- ◆ Les compromis temps-mémoire classiques
- ◆ La variante développée au Lasec
- ◆ Tables « parfaites »
- ◆ Configuration optimale
- ◆ Performances
- ◆ Exemples, démo

Introduction

- ◆ Les compromis temps-mémoire s'appliquent à des “fixed plaintext attacks”
 - On a un texte chiffré (ou p.ex. le hash d'un mot de passe)
 - On sait comment le chiffré à été généré
 - On cherche la clé qui a servi au chiffrement
- ◆ Attaque par force brute:
 - Nécessite aucune mémoire, mais très lent ($T=N$)
- ◆ Attaque par dictionnaire complet:
 - Attaque instantanée, nécessite énormément de mémoire ($M=N$)
- ◆ Compromis temps-mémoire
 - Nécessite un peu de mémoire et un peu de temps ($T=M=N^{2/3}$)
 - Temps de préparation N , taux de réussite $< 100\%$

Exemple: les mots de passe Windows

- ◆ On stocke les mots de passe sous forme de hash
- ◆ Le hash est irréversible $2 \xrightarrow{H} h2$
- ◆ LMHash:
 - On découpe le mot de passe en deux blocs de 7 caractères.
 - On transforme les minuscules en majuscules
 - Pour chaque bloc, un hash de 64 bits est créé en chiffrant un texte prédéfini (KGS!@#\$\$%) avec DES en utilisant le mot de passe de 56 bits comme clé
 - Il y a 80 milliards (2^{36}) de hash de mots de passes alphanumériques
 - ◆ alors qu'il y a 2^{83} mots de passe alphanumériques!
- ◆ NTHash: on calcule le hash MD4 du mot de passe

Compromis temps-mémoire

- ◆ Cette méthode à été inventée par Martin Hellman en 1980
- ◆ On génère tous les hash, on les organise en chaînes.
- ◆ On crée des tables dans lesquelles on ne stocke que le début et la fin de chaque chaîne (gains en mémoire)
- ◆ A partir d'un hash quelconque on peut retrouver une fin de chaîne
- ◆ A partir du début de chaîne on retrouve le mot de passe

$$T \approx \frac{N^2}{M^2}$$

Création de chaînes


- ◆ On définit une *fonction de réduction* R quelconque qui génère un mot de passe à partir d'un hash

$$0 \xrightarrow{H} h_0 \quad h_0 \xrightarrow{R} 2$$


- ◆ Grâce à la fonction de réduction, on peut organiser les mots de passe les hashes en chaînes (longueur t):

$$0 \xrightarrow{H} h_0 \xrightarrow{R} 2 \xrightarrow{H} h_2 \xrightarrow{R} 3 \xrightarrow{H} h_3 \xrightarrow{R} 9$$

- ◆ On génère une quantité de chaînes (m) et on ne stocke que le début et la fin dans une table




Recherche dans une table



- ◆ Pour retrouver un mot de passe à partir d'un hash, on génère une chaîne jusqu'à ce qu'on trouve une fin de chaîne connue. On recrée la chaîne originale à partir du début

Les fusions



- ◆ La fonction de réduction peut générer la même clé à partir de 2 hashes différents -> **fusion**
- ◆ On peut trouver une fin de chaîne dans la table sans y trouver le mot de passe recherché -> **fausse alarme**

Tables multiples


- ◆ Plus une table est grande, plus grand est la probabilité qu'une chaîne additionnelle fusionne avec une chaîne existante
 - L'efficacité des chaînes additionnelles diminue

- ◆ On peut construire plusieurs tables (t) avec des fonctions de réductions différentes
 - Les chaînes de différentes tables peuvent avoir des collisions mais pas fusionner.

- ◆ Cette manière de faire est la méthode originale de Hellman


Plus efficaces: les tables rainbow

- ◆ Pour éviter des fusions on utilise une fonction de réduction différente pour chaque étape




- ◆ Deux chaînes rainbow ne peuvent fusionner que si elles ont une collision à la même position
 - Les autres collisions ne provoquent pas de fusion

Comparaison de la probabilité de succès



Recherche dans une table rainbow

- ◆ Lorsqu'on qu'on doit rechercher un hash h dans une table rainbow, on ne sait pas par quelle fonction de réduction commencer.
- ◆ On essaie toutes les possibilités, en commençant par la fin (là ou c'est le plus court)



Qualités des tables rainbow

- ◆ Les tables rainbow peuvent être t fois plus grandes que les tables classiques
- ◆ Il faut deux fois moins d'opérations pour chercher dans une table rainbow que dans t tables classiques (cas le pire, bien mieux en moyenne, p.ex. 14 fois)
- ◆ Les tables rainbow peuvent être générées plus efficacement
- ◆ Les tables rainbow peuvent facilement être analysées mathématiquement

Les tables parfaites

- ◆ Pour plus d'efficacité on préfère avoir des tables sans aucune fusion: « tables parfaites » (Borst & Preneel '98)
- ◆ Les chaînes fusionnées se détectent par leur fin de chaîne identique
- ◆ Il y a une limite au nombre maximal de chaînes m_{max} sans fusion que l'on peut générer:


$$m_{max}(t) \approx \frac{2N}{t+2}$$

- ◆ Le taux de réussite d'une table qui a le nombre maximal de chaînes sans fusions est de:

$$\hat{P}_{table} = 1 - \left(1 - \frac{m_{max}}{N}\right)^t \approx 1 - e^{-t \frac{m_{max}}{N}} \approx 1 - e^{-2} = 86\%$$


Génération de tables parfaites

- ◆ Pour générer une table parfaite
 - On génère trop de chaînes
 - On retire les fusions




Génération efficace de tables parfaites

- ◆ On peut considérablement réduire l'effort de génération des tables en éliminant les fusions par étapes successives



Nombre maximal de chaînes parfaites

- ◆ Il est très cher d'aller jusqu'au nombre maximum de chaînes ($t=4666$)



Paramètres optimaux (t, m, ℓ)

- ◆ Etant donné une mémoire pouvant contenir M chaînes et un taux de réussite désiré P , la configuration optimale est atteinte en minimisant le nombre de tables:

- ◆ Nombre de tables $\ell = \left\lceil \frac{-\ln(1 - P)}{2} \right\rceil$

- ◆ Nombre de chaînes parfaites par table $m = \frac{M}{\ell}$

- ◆ Longueur des chaînes $t \approx \frac{-N}{M} \ln(1 - P)$

Performance

- ◆ Le nombre moyen d'opérations pour trouver un hash est composé
 - des opérations nécessaires à générer les chaînes partielles
 - des opérations dues à la vérification de fausses alarmes
- ◆ Quand on recherche un hash dans ℓ tables de m chaînes de longueur t , on cherche d'abord dans la dernière colonne de chaque table, puis l dans l'avant-dernière, etc
- ◆ Il y a ℓt recherches, à la k -ième recherche on se trouve à la colonne

$$c = t - \left\lfloor \frac{k}{\ell} \right\rfloor$$

Espérance de T

- ◆ La probabilité de trouver un mot de passe à la k -ème recherche est

$$p_k = \frac{m}{N} \left(1 - \frac{m}{N}\right)^{k-1}$$


- ◆ La probabilité d'avoir une fausse alarme à la colonne c est

$$q_c = 1 - \prod_{i=c}^{i=t} \left(1 - \frac{m_i}{N}\right) - \frac{m}{N}$$


- ◆ On trouve:

$$T = \sum_{k=1}^{k=\ell t} p_k \left(\frac{(t-c)(t-c-1)}{2} + \sum_{i=c}^{i=t} q_i i \right) \ell + \left(1 - \frac{m}{N}\right)^{\ell t} \left(\frac{t(t-1)}{2} + \sum_{i=1}^{i=t} q_i i \right) \ell$$

Performance



Caractéristique $f(P)$ du compromis




Implémentation efficace

- ◆ Calcul des hash:
 - Implémentation optimisée de DES
 - ◆ Bitslice DES?
- ◆ Stockage des chaînes
 - La performance du compromis dépend de la mémoire au carré
 - On pourrait stocker les début et les fins de chaînes comme hash (64 bits) ou mot de passe (56 bits)
 - Les mots de passe alphanumériques n'utilisent pas toutes les 2^{56} possibilités
 - Les fin de chaînes sont triées pour faciliter la recherche

Représentation compacte des chaînes

- ◆ Il n'y a que $2^{36.23}$ mots de passe alphanumériques, on peut donc les coder sur 37 bits au lieu de 7 bytes ascii.
- ◆ Les fins de chaînes ont un préfix qui change rarement
 - En créant un index, on peut retirer les préfix, p.ex:
 - Préfix 1 car et 6 car sur 32 bits
 - Préfix 4 car et 3 car sur 16 bits
- ◆ Il n'y a que m_0 débuts de chaîne possibles
 - On peut les coder sur $\log_2(m_0)$ bits



Exemples

◆ Démo été 2003:

- $P = 99.9\%$,
- $M = 116$ mio de chaînes, 910Mo (préfix 1 car),
- $\ell = 5$, $m = 23.3$ mio ($m_0 = 90$ mio), $t = 4666$
- $T = 4.11$ mio, 5.26s (AthlonXP 2500+, 1.8Ghz)

◆ Démo actuelle:

- $P = 99.9\%$,
- $M = 186$ mio de chaînes, 1.07Go (préfix 4 car),
- $\ell = 4$, $m = 46.5$ mio ($m_0 = 350$ mio), $t = 3000$
- $T = 1.56$ mio, 1.5s (AthlonXP 2500+, 1.8Ghz)

Pourquoi ça marche si bien?

- ◆ Les compromis sont applicable quand:
 - Il n'y a pas de partie aléatoire dans le calcul des hash (pas de sel, pas de vecteur d'initialisation)
 - ◆ ni dans le LMHash, ni dans le NTHash
 - Le problème n'est pas trop complexe (2^{40}), ni trop simple (2^{30})
- ◆ Il n'y a pas d'autre système d'exploitation à notre connaissance qui n'utilise pas du sel dans les hash de mot de passe
- ◆ Les systèmes de chiffrement utilisent des vecteurs d'initialisation:
 - protections de fichiers ZIP, MS-Office, Acrobat,
 - IPSec, SSL, Ms-Kerberos
- ◆ Certains drivers WLAN/WEP génèrent des vecteurs d'initialisation prédictibles

Conclusions

- ◆ Il faut toujours ajouter un facteur aléatoire dans tous les systèmes de chiffrement, pour éviter la précalculation
- ◆ L'efficacité des compromis temps-mémoire augmente avec les progrès des processeurs ET de la mémoire
 - C'est la loi de Moore's au carré (ou au cube)!
- ◆ Espérons que Microsoft va bientôt ajouter du sel à ses mots de passe!

$$T \approx \frac{N^2}{M^2}$$

Questions ?

