

le raisonnement que dans la phase de précalcul du tableau, on a pris en compte tous les mots de passe de la catégorie visée, par exemple les mots de passe de 12 caractères pris dans les 26 lettres de l'alphabet.

Pour examiner une empreinte e_o , on procède de la façon suivante. On calcule $h(C(e_o)) = e_1$, puis $h(C(e_1)) = e_2$, etc., jusqu'à obtenir une empreinte e_m qui commence par 20 zéros. On regarde alors dans la table à quel M_0 elle est associée. Il y en a nécessairement un, car le mot de passe qu'on étudie est dans l'une des séries qu'on a fait défiler. On part alors de ce M_0 et on calcule $h(M_0)$, $h(C(h(M_0))) = h_1$, etc., jusqu'à tomber sur e_o , ce qui se produit nécessairement. Imaginons que cela se produise pour h_k (c'est-à-dire $h_k = e_o$). Le mot de passe que l'on recherche est alors $C(h_{k-1})$.

Le temps de calcul nécessaire est celui qu'il faut pour rechercher e_m dans la table, auquel il faut ajouter le temps de calcul des $h_1, h_2, \dots, h_k$, qui est environ un million de fois plus court que le temps de calcul ayant été nécessaire pour calculer la table, c'est-à-dire très raisonnable.

Ainsi, avoir fait un précalcul (très long) et en avoir enregistré partiellement les résultats permet de retrouver en un temps raisonnable tout mot de passe dont on connaît l'empreinte.

En résumé, l'idée consiste :
(1) à classer les mots de passe en paquets, dans chacun desquels se retrouvent les mots de passe qui aboutissent à la même empreinte commençant par 20 zéros ;
(2) face à un mot de passe dont on connaît l'empreinte, à retrouver d'abord le paquet auquel il appartient grâce à ce qu'on a mémorisé ;
(3) à déterminer dans ce paquet l'endroit où le mot de passe se trouve en opérant un calcul assez court.

> Une première idée consiste à chiffrer les mots de passe de la liste, c'est-à-dire à utiliser un code secret qui les transforme grâce à une clé de chiffrement en suites de signes apparemment aléatoires pour quiconque ignore la clé de déchiffrement. Cette méthode fonctionne, mais présente deux inconvénients. Il faut déchiffrer le mot de passe associé à un utilisateur à chaque fois qu'on veut le comparer à celui qu'il indique, ce qui n'est pas très commode. Plus grave, pour mener ce déchiffrement nécessaire à la comparaison, il faut garder, dans la mémoire de l'ordinateur du site, la clé de déchiffrement. Or cette clé pourrait être repérée par le pirate, ce qui ramène au problème précédent !

DU HACHAGE... PRÉCÉDÉ PAR UN SALAGE !

La bonne méthode est celle des fonctions de hachage qui produisent des empreintes. Une fonction de hachage est une fonction qui, à tout fichier F donné, associe une « empreinte » (on parle aussi de « condensé », ou de « hash ») $h(F)$, qui est un mot assez court, propre au fichier F , mais produit de telle façon qu'en pratique, il est impossible de retrouver F à partir de $h(F)$. On parle de fonction à sens unique : passer de F à $h(F)$ est facile, passer de $h(F)$ à F est impossible en pratique. De plus, les fonctions de hachage utilisées ont la propriété que même s'il se peut que deux fichiers F et F' aient la même empreinte $h(F) = h(F')$ (on parle de collision), en pratique personne ne sait, pour un F donné, trouver un F' ayant la même empreinte que F .

Avec une telle fonction de hachage, le stockage des mots de passe sur un serveur informatique est facile : au lieu de la liste des couples [identifiant, mot de passe], on ne gardera sur le serveur que la liste des couples [identifiant, $h(\text{mot de passe})$].

Quand un utilisateur voudra se connecter, le serveur lira son mot de passe mdp , en calculera l'empreinte $h(mdp)$ et regardera si c'est bien ce que sa liste de couples mémorisés indique en face de l'identifiant d'utilisateur. Le hacker sera bien ennuyé, car même s'il a pu accéder à cette liste, il ne pourra pas connaître les mots de passe des utilisateurs (impossibilité en pratique de passer de $h(mdp)$ à mdp), et sera aussi dans l'impossibilité de produire un autre mot de passe mdp' qui aurait la même empreinte et bernerait le serveur (impossibilité pratique des collisions).

Cette prudence recommandée est réellement importante, car même de grands sites prenant la peine de bien se protéger contre les intrusions sont régulièrement piratés. En 2016, le groupe Yahoo! s'était ainsi fait voler les données de un milliard de comptes !

Pour compliquer encore l'exploitation d'une liste volée du type [identifiant, $h(\text{mot$

de passe)], on utilise parfois la méthode du « salage » qui consiste à ajouter au mot de passe une chaîne de caractères aléatoires, différente pour chaque mot de passe. De cette façon, même si deux utilisateurs utilisent le même mot de passe, les empreintes mémorisées seront différentes. Bien sûr, il faudra alors que la liste détenue par le serveur contienne pour chaque utilisateur trois éléments : [identifiant, $h(\text{mot de passe} + \text{salage})$, salage]. Quand le serveur veut vérifier le mot de passe qu'un utilisateur vient de donner, il lui ajoute le salage, calcule l'empreinte, et compare avec ce qu'il a dans sa base.

Même quand les mots de passe des utilisateurs sont faibles, cette méthode complique considérablement le travail du hacker. Sans salage, il peut calculer toutes les empreintes d'un dictionnaire et regarder celles qui sont présentes dans les données volées ; tous les mots de passe présents dans son dictionnaire seront repérés. Avec salage, le travail d'exploitation de son dictionnaire devient plus compliqué : le hacker est obligé, pour chaque utilisateur, de calculer les empreintes de tous les mots de passe de son dictionnaire auquel il ajoute le salage propre de l'utilisateur (qu'il connaît puisqu'il a volé la liste). S'il y a 1000 utilisateurs, cela multiplie par 1000 le calcul à faire pour exploiter son dictionnaire.

UN COMPROMIS ENTRE TROP DE CALCUL ET TROP DE MÉMOIRE

Pour bien se défendre contre un attaquant, mieux vaut connaître les méthodes qu'il pourrait mettre en œuvre pour repérer des mots de passe et plus généralement exploiter une table de couples [identifiant d'utilisateur, $h(\text{mot de passe})$]. On se trouve pris entre deux difficultés : soit il faut beaucoup calculer, c'est-à-dire détenir une grande puissance de calcul, soit il faut disposer de beaucoup de mémoire pour mener un long précalcul, éventuellement pendant des semaines ou des mois, en enregistrant tout ce qu'on calcule et qu'on pourra ensuite exploiter facilement.

Bien souvent, aucune des deux méthodes ne fonctionne. Reste alors l'espoir de concevoir une méthode intermédiaire, qui exige moins de mémoire pour enregistrer le résultat d'un calcul fait à l'avance, et qui, au moment de son exploitation, exige une quantité de calcul raisonnable. L'encadré 3 présente la méthode des tables arc-en-ciel, qui réussit ce compromis.

La science des mots de passe, à l'ère d'Internet, des puissants calculateurs et des réseaux d'ordinateurs, est le théâtre d'une lutte sans merci entre ceux (chacun de nous) qui veulent les utiliser pour se protéger, et ceux qui cherchent à les connaître pour en tirer profit... à nos dépens. ■