

# Cours 4. Fonctions de hachage (cryptographiques)

HAI709I – Cryptographie

Bruno Grenet

Université de Montpellier – Faculté des Sciences


1. Fonctions de hachage et leur sécurité

2. Construction de Merkle-Damgård

3. Attaques : le paradoxe des anniversaires

4. Constructions pratiques

# Au commencement : tables de hachage



## Fonction de hachage

- ▶ Fonction  $h : U \rightarrow \{0, \dots, m - 1\}$
- ▶ Algorithmique : pas trop de *collisions*

## En cryptographie

- ▶ On oublie les tables  $\rightarrow$  seules les fonctions nous intéressent
- ▶ La fonction doit paraître aléatoire
  - $\rightarrow$  difficile de *revenir en arrière* : trouver  $x$  à partir de  $h(x)$
  - $\rightarrow$  difficile de trouver des collisions :  $x \neq x'$  tels que  $h(x) = h(x')$

# Les fonctions de hachage cryptographique

## Définition

- ▶ Une **fonction de hachage** avec taille de sortie  $\ell(n)$  est un couple d'algorithmes polynomiaux  $\mathcal{H} = (\text{Gen}, H)$  tels que
  - ▶  $\text{Gen}(1^n)$  renvoie une clef aléatoire  $s$  ( $n = \text{paramètre de sécurité}$ )
  - ▶  $H$  est déterministe, et  $H^s(x) \in \{0, 1\}^{\ell(n)}$  pour tout  $x \in \{0, 1\}^*$
- ▶ Une **fonction de compression** est une fonction de hachage telle que  $H^s : \{0, 1\}^{\ell'(n)} \rightarrow \{0, 1\}^{\ell(n)}$  avec  $\ell'(n) > \ell(n)$ .

## Remarques

- ▶ Clef non secrète, souvent omise notée en exposant
- ▶ On dit souvent que  $H$  est une fonction de hachage, en oubliant  $\text{Gen}$
- ▶ En pratique, pas de clef :  $H$  est une fonction déterministe fixée
  - ▶ ex. : MD5, SHA-1, SHA-2, SHA-3, ...
  - ▶ pas de résultat théorique :  $H$  fixée  $\rightarrow$  toute question se résout (théoriquement) en  $O(1)$
  - ▶ résultats pratiques : on ne sait pas les casser (sauf MD5, SHA-1, ...)

# Sécurité d'une fonction de hachage

Résistance aux collisions : il est difficile de trouver  $x \neq x'$  tels que  $H^s(x) = H^s(x')$

## Expérience de sécurité

Entrée : paramètre de sécurité  $1^n$

1. Protocole :  $s \leftarrow \text{Gen}(1^n)$
2. Attaquant : reçoit  $s$ , et produit  $x$  et  $x'$

Succès de l'attaquant si  $x \neq x'$  et  $H^s(x) = H^s(x')$

## Définition

Une fonction de hachage  $\mathcal{H} = (\text{Gen}, H)$  est **résistante aux collisions** si pour tout APP,  $\Pr[H^s(x) = H^s(x')] \leq \text{negl}(n)$ .

# Autres notions de sécurité

## Définitions

- ▶ Une fonction de hachage est **résistante à la préimage** si étant donné  $s$  et  $y = H^s(x)$  avec  $x$  choisi uniformément, aucun APP ne peut trouver  $x'$  tel que  $H^s(x') = y$  avec probabilité non négligeable
- ▶ Une fonction de hachage est **résistante à la 2<sup>nde</sup> préimage** si étant donné  $s$  et  $x$  choisi uniformément, aucun APP ne peut trouver  $x'$  tel que  $H^s(x') = H^s(x)$  avec probabilité non négligeable

## Théorème

- ▶ Une fonction résistante aux collisions est résistante à la 2<sup>nde</sup> préimage.
- ▶ Une fonction résistante à la 2<sup>nde</sup> préimage est résistante à la préimage.

« résistante aux collisions > résistante à la 2<sup>nde</sup> préimage > résistante à la préimage »

→ Preuve en TD

# Applications des fonctions de hachage

## Empreinte numérique

- ▶ Idée : comparer deux fichiers en comparant leurs hachés
- ▶ Applications :
  - ▶ Stockage sur un serveur : l'utilisateur garde en mémoire le haché, pour vérifier que le serveur renvoie bien le bon fichier
  - ▶ Détection de virus : base de données de hachés de virus
  - ▶ Déduplication : détecter des fichiers identiques sur un serveur
  - ▶ Pair-à-pair : haché comme identifiant des fichiers

## Hachage de mots de passe

- ▶ Ne pas stocker les mots de passe en clair, mais hachés... voire *salés* !  
 $s$  aléatoire ;  $h_{mdp} \leftarrow H(s, mdp)$  ; stockage de  $(s, h_{mdp})$

## Dérivation de clef

- ▶ Deux utilisateurs se mettent d'accord sur un secret  $s$  (mot de passe, etc.)
- ▶ Pour obtenir une clef secrète (quasi-)aléatoire :  $k \leftarrow H(s)$

# Application : la mise en gage

## Exemple : PILE OU FACE à distance

1. Alice choisit PILE OU FACE et annonce son choix
2. Bob lance une pièce et annonce son résultat
3. Alice gagne si elle a correctement prédit la pièce de Bob

→ Si Alice et Bob sont à distance, Bob peut tricher ; si on inverse 1. et 2., Alice peut tricher

## Solution : la mise en gage

1. Alice *met en gage* son choix  $b$  : elle tire  $r$  uniformément et annonce  $h = H(b||r)$
2. Bob lance une pièce et annonce son résultat
3. Alice annonce  $b'$  et  $r'$  → désignation du vainqueur
4. Bob vérifie que  $h = H(b'||r')$  → vérification de l'honnêteté

## Sécurité

- ▶ Difficile pour Alice de trouver  $r'$  et  $b' \neq b$  tels que  $H(b'||r') = H(b||r)$
- ▶ Difficile pour Bob, étant donné  $h$ , de trouver  $b$

1. Fonctions de hachage et leur sécurité

2. Construction de Merkle-Damgård

3. Attaques : le paradoxe des anniversaires

4. Constructions pratiques

# Des fonctions de compression aux fonctions de hachage

## Rappel

- ▶ Fonction de hachage :  $H^s : \{0, 1\}^* \rightarrow \{0, 1\}^{\ell(n)}$
- ▶ Fonction de compression :  $H^s : \{0, 1\}^{\ell'(n)} \rightarrow \{0, 1\}^{\ell(n)}$  avec  $\ell'(n) > \ell(n)$

## Constat


- ▶ Les fonctions de compression sont plus simples à concevoir
- ▶ Mais les fonctions de hachage sont plus utiles

Comment obtenir une fonction de hachage à partir d'une fonction de compression ?

## Hypothèse

- ▶  $(\text{Gen}, h)$  est une fonction de compression avec  $h^s : \{0, 1\}^{n+n'} \rightarrow \{0, 1\}^n$  et  $n' \geq n$
- ▶ On construit une fonction de hachage  $(\text{Gen}, H)$  Gen inchangé

# Construction de Merkle-Damgård



## Construction

- ▶ On fixe  $\ell < n'$  et  $IV \in \{0, 1\}^n$
- ▶ Calcul de  $H^s(x)$  pour  $x \in \{0, 1\}^*$  de longueur  $L < 2^\ell$  :
  1.  $x_{pad} \leftarrow x \parallel 10 \cdots 0$  de longueur  $Bn' - \ell$ ,  $B$  minimal
  2.  $x_1 \parallel \dots \parallel x_B \leftarrow x_{pad} \parallel L$  avec  $L$  écrit en binaire sur  $\ell$  bits
  3.  $z_0 \leftarrow IV$
  4. Pour  $i = 1$  à  $B$ :  $z_i \leftarrow h^s(z_{i-1} \parallel x_i)$
  5. Renvoyer  $z_B$

# La construction est sûre

## Théorème

Si  $(\text{Gen}, h)$  est résistante aux collisions,  $(\text{Gen}, H)$  l'est également.

1. Fonctions de hachage et leur sécurité

2. Construction de Merkle-Damgård

3. Attaques : le paradoxe des anniversaires

4. Constructions pratiques

# Attaquer une fonction de hachage

$$H^s : \{0, 1\}^* \rightarrow \{0, 1\}^\ell$$

## Objectifs

- ▶ Trouver une collision :  $x \neq x'$  tels que  $H^s(x) = H^s(x')$
- ▶ Trouver une préimage : étant donné  $y$ , trouver  $x$  tel que  $H^s(x) = y$
- ▶ Trouver une 2<sup>nde</sup> préimage : étant donné  $x$ , trouver  $x' \neq x$  tel que  $H^s(x') = H^s(x)$

## Recherche exhaustive

- ▶ Si on calcule  $H^s(x)$  pour  $2^\ell + 1$  valeurs de  $x \rightarrow$  collision !
- ▶ Si  $H^s : \{0, 1\}^{\ell'} \rightarrow \{0, 1\}^\ell$ , calcul des  $2^{\ell'}$  valeurs de  $H^s(x)$

## Remarque

- ▶ En chiffrement symétrique, meilleure attaque *générique* en  $O(2^n)$

Il existe une attaque (bien) plus rapide sur les fonctions de hachage !

# Le paradoxe des anniversaires

## Théorème

Soit  $y_1, \dots, y_q$  tirés uniformément et indépendamment dans un ensemble de taille  $N$ ,  $q \leq \sqrt{2N}$ . Alors

$$\frac{q(q-1)}{4N} \leq 1 - e^{-q(q-1)/2N} \leq \Pr[\exists i \neq j, y_i = y_j] \leq \frac{q(q-1)}{2N}$$

## Exemple

- ▶ Dans un groupe de 23 personnes, il y a au moins 50% de chances que deux soient nées le même jour ! Dans cette salle de ... personnes, la probabilité est  $\geq \dots$

## Utilisation pour les fonctions de hachage

- ▶ On tire  $x_1, \dots, x_q$  aléatoirement, et on calcule  $y_i \leftarrow H(x_i)$  pour  $1 \leq i \leq q$
- ▶ Si  $H$  est aléatoire,  $\Pr[\exists i \neq j, y_i = y_j] \geq q(q-1)/2^{\ell+2} \rightarrow q = \Omega(2^{\ell/2})$  suffit !
- ▶ Si  $H$  est une *vraie* fonction de hachage : probabilité de collision plus forte

# Preuve du paradoxe des anniversaires

# Attaques basées sur le paradoxe des anniversaires

- ▶ Tirer  $\Omega(2^{\ell/2})$  valeurs suffit à trouver une collision avec probabilité constante

## Construire des collisions utiles

- ▶ Trouver deux messages  $m_0$  et  $m_1$ , de significations opposées, tels que  $H(m_0) = H(m_1)$ 
  - ▶ Exemple : « Je dois 1000€ à Bruno » et « Bruno me doit 1000€ »
- ▶ Idée : produire de nombreuses *variantes* de  $m_0$  et de  $m_1$ 
  - ▶  $m_0$  : « J'ai une dette de 1000€ envers Bruno », « Je dois rendre 1000€ à Bruno », ...
  - ▶  $m_1$  : « Bruno a une dette envers moi, de 1000€ », ...
- ▶ On *devrait* trouver une collision, avec suffisamment de variantes

## Problème de la mémoire

- ▶ Stocker tous les  $x_i$  et  $y_i$  est coûteux
- ▶ Algorithme du lièvre et de la tortue :
  1. Tirer  $x_0$  uniformément
  2. Pour  $i = 1, 2, \dots$  :  $(x_i, x_{2i}) \leftarrow (H(x_{i-1}), H(H(x_{2(i-1)})))$
  3. Dès que  $x_i = x_{2i}$  : trouver  $j$  entre 1 et  $i$  tel que  $x_j = x_{i+j}$
- ▶ Stockage de deux valeurs uniquement

1. Fonctions de hachage et leur sécurité
2. Construction de Merkle-Damgård
3. Attaques : le paradoxe des anniversaires
4. Constructions pratiques

# Deux grands types de constructions pratiques


## À partir d'un chiffre par blocs $F_k$

- ▶ Fonction de compression + construction de Merkle-Damgård → fonction de hachage
- ▶ Constructions de fonction de compression :
  - ▶ Davies-Meyer :  $h(z_{i-1}, x_i) = F_{x_i}(z_{i-1}) \oplus z_{i-1}$
  - ▶ Matyas-Meyer-Oseas :  $h(z_{i-1}, x_i) = F_{z_{i-1}}(x_i) \oplus x_i$
- ▶ Nombreux exemples : MD4, MD5, SHA-1 (cassées), SHA-2
- ▶ Preuve générique : nécessite un chiffre par bloc *idéal* → preuves *à la main*

## À partir d'une permutation aléatoire

- ▶ Construction en éponge → directement une fonction de hachage
- ▶ Exemple : SHA-3 (Keccak)
  - ▶ vainqueur d'une compétition NIST (2008-2012)
  - ▶ meilleur choix actuel de fonction de hachage
  - ▶ permutation KECCAK –  $f(1600)$  : permutation de  $\{0, 1\}^{1600}$
- ▶ Preuve générique basée sur une permutation *vraiment* aléatoire

# La construction en éponge



## Construction

- ▶  $P$  : permutation de  $\{0, 1\}^\ell$  ; on fixe  $r, c, v, \lambda \geq 1$  tels que  $r + c = \ell, v \leq \ell$
- ▶ Calcul de  $H(m)$ , pour  $m \in \{0, 1\}^*$  :
  0.  $m_1 \| \dots \| m_t \leftarrow m \| 10 \dots 0$  de longueur multiple de  $r$
  1.  $y_0 \leftarrow 0^\ell$   
 Pour  $i = 1$  à  $t$  :  $y_i \leftarrow P(x_i)$  où  $x_i = y_{i-1} \oplus (m_i \| 0^c)$ 
*Phase d'absorption*
  2.  $y_1^* \leftarrow y_t$   
 Pour  $i = 2$  à  $\lambda$  :  $y_i^* \leftarrow P(y_{i-1}^*)$ 
*Phase d'essorage*
  3. Renvoyer  $h_1 \| \dots \| h_\lambda$  où  $h_i = y_i^*_{[0,v[}$

# Sécurité de la construction en éponge (1/3)

## Théorème

Si  $P$  est une permutation aléatoire et  $\lambda = 1$ , un attaquant effectuant  $q$  requêtes à  $P$  ou  $P^{-1}$  ne peut trouver une collision dans  $H$  qu'avec probabilité  $\leq \frac{q^2}{2^v} + \frac{q(q+1)}{2^c}$ .

## Preuve

- ▶ Soit  $A$  qui produit  $(m^0, m^1)$  tel que  $H(m^0) = H(m^1)$
- ▶ Après *padding*,  $m^0 \rightarrow m_1^0 \parallel \dots \parallel m_{t^0}^0$  et  $m^1 \rightarrow m_1^1 \parallel \dots \parallel m_{t^1}^1$
- ▶ Calcul de  $H(m^0)$  :  $y_0^0 \rightarrow x_1^0 \rightarrow \dots \rightarrow y_{t^0}^0$  avec  $x_i^0 = y_{i-1}^0 \oplus (m_i^0 \parallel 0^c)$  et  $y_i^0 = P(x_i^0)$
- ▶ Calcul de  $H(m^1)$  :  $y_0^1 \rightarrow x_1^1 \rightarrow \dots \rightarrow y_{t^1}^1$  avec  $x_i^1 = y_{i-1}^1 \oplus (m_i^1 \parallel 0^c)$  et  $y_i^1 = P(x_i^1)$
- ▶ On suppose que
  - ▶  $A$  interroge  $P$  sur des  $x_i^0$  ou  $x_i^1$  et  $P^{-1}$  sur des  $y_i^0$  ou  $y_i^1$
  - ▶  $A$  n'interroge pas  $P$  ou  $P^{-1}$  de manière redondante
  - ▶  $A$  interroge  $P(x_1^0), \dots, P(x_{t^0}^0)$  et  $P(x_1^1), \dots, P(x_{t^1}^1)$

# Sécurité de la construction en éponge (2/3)

## Lemme 1

Si l'attaquant produit une collision, alors un des trois événements arrive :

- ▶  $E_1$ : A fait 2 requêtes à  $P$  dont les résultats sont égaux sur leurs  $v$  premiers bits
- ▶  $E_2$ : A fait une requête à  $P$  ou  $P^{-1}$  dont le résultat finit par  $0^c$
- ▶  $E_3$ : A fait 2 requêtes (à  $P$  ou  $P^{-1}$ ) dont les résultats sont égaux sur leurs  $c$  derniers bits

Cas 1 A a fait une requête à  $P^{-1}$   
- Si  $P^{-1}(y_0^b) \rightarrow$  il obtient  $x_1^b = y_0^b \oplus (m_2^b \parallel 0^c)$   $\bar{E}_2$   
- Sinon  $P^{-1}(y_i^b) = x_i^b$  et  $P(x_{i-1}^b) = y_{i-1}^b$  ; or  $x_i^b = y_{i-1}^b \oplus (m_i^b \parallel 0^c)$   $\bar{E}_3$

Cas 2 Requêtes uniquement à  $P$  mais  $y_{t^0}^0 \neq y_{t^1}^1$   
 $x_{t^0}^0 \neq x_{t^1}^1$  mais  $P(x_{t^0}^0) = y_{t^0}^0$  et  $P(x_{t^1}^1) = y_{t^1}^1$  partagent les  $\hat{m}$   $v$  premiers bits  $\bar{E}_1$

Cas 3 Requêtes uniquement à  $P$  et  $y_{t^0}^0 = y_{t^1}^1$ .


Soit  $i$  maximal tq  $y_{t^0-j}^0$  et  $y_{t^1-j}^1$  aient les  $\hat{m}$   $c$  derniers bits pour  $0 \leq j \leq i$

• Si  $i < t^0$  :  $x_{t^0-i}^0 \neq x_{t^1-i}^1$   $\bar{E}_3$  • Si  $i = t^0$  et  $t^0 < t^1$  :  $P(x_{t^1-i}^1) = y_{t^1-i}^1$   $\Rightarrow \bar{E}_2$  • Si  $i = t^0 = t^1$  :  $y_{i-1}^0 = y_{i-1}^1$  mais  $x_j^0 \neq x_j^1$   $\bar{E}_3$

## Sécurité de la construction en éponge (3/3)

### Lemme 2

La permutation  $P$  étant aléatoire,  $\Pr[E_1 \vee E_2 \vee E_3] \leq \frac{q^2}{2^v} + \frac{q(q+1)}{2^c}$ .



- $\Pr[E_1 \vee E_2 \vee E_3] \leq \Pr[E_1] + \Pr[E_2] + \Pr[E_3]$
- $\Pr[E_2] \leq q/2^c$  car à chaque requête, la proba est  $1/2^c$
- $C_{i,j}$ : résultats des  $i^{\text{ème}}$  et  $j^{\text{ème}}$  requêtes ont les  $\tilde{m}$   $v$  premiers bits

$$\Pr[E_1] = \Pr\left[\bigvee_{i < j} C_{i,j}\right] \leq \sum_{i < j} \Pr[C_{i,j}] \leq \binom{q}{2} \cdot \frac{2}{2^v} \leq \frac{q^2}{2^v}$$

$$\Pr[C_{i,j}] \leq \frac{2^{l-v}}{2^l - 1}$$

- $\Pr[E_3] \leq q^2/2^c \rightsquigarrow$  m même que pour  $E_1$ .

# Conclusion

- ▶ Fonctions de hachage (cryptographique) : primitive extrêmement utile !
  - ▶ Hachage de mots de passe
  - ▶ Codes d'authentification de message
  - ▶ Signature électronique
  - ▶ Version sécurisée de RSA (RSA-OAEP)
  - ▶ Blockchain
  - ▶ ...
- ▶ Constructions basées sur des chiffres par blocs
  - ▶ Fonction de compression + construction de Merkle-Damgård
  - ▶ Exemples : MD4, MD5, SHA-1, SHA-2
- ▶ Constructions basées sur des permutations aléatoires
  - ▶ Construction en éponge
  - ▶ Exemple : SHA-3

*cours 5*  
*2<sup>nd</sup>e partie*  
*2<sup>nd</sup>e partie*

Si vous avez besoin d'une fonction de hachage, utilisez SHA-3 (éventuellement SHA-2) !