

Théorie de l'information

G. Kohl
01/02/2021



Résumé (Conditions équivalentes pour un cryptosystème)

①

$$E: \mathcal{K} \times M \longrightarrow C$$

d'être parfaitement sûr.

- ①) $\bullet p(M|C) = p(M)$ pour tout $M \in M$
et $C \in \text{Supp}(C)$.
- ②) $\bullet p(C|M) = p(C)$ pour tout $M \in \text{Supp}(M)$
et $C \in C$.
- ③A) $\bullet H(m|C) = H(m)$.
③B) $\bullet H(C|m) = H(C)$
- ④) $\bullet H(m, C) = H(m) + H(C)$.
- ⑤) $\bullet I(M, C) = 0$.

Définition. On appelle $H(\mathcal{K}|C)$

l'équivocation de la clé et $H(m|C)$

l'équivocation du message.

Remarque. On note que le mot *reçus*, c.à.d. le texte chiffré, est supposer connu par tout le monde, car on l'envoi par un canal non sécurisé.
Une attaque cryptographique vise

à déterminer soit le message clair, soit la clé. Les quantités $H(X|C)$ et $H(m|C)$ mesurent le nombre de bits (car on normalise H par l'utilisation de \log_2) inconnus.

Rappel. $H(X|Y)$

$$\begin{aligned} &= \sum_{x,y} p(x,y) \log_2(p(x|y)^{-1}) \\ &= \sum_y p(y) \sum_x p(x|y) \log_2(p(x|y)^{-1}) \\ &= \sum_y p(y) H(X|y) = E(H(X|y)), \end{aligned}$$

où $p(x,y) = p(y) p(x|y)$.

Il suffit de connaître $p(x,y)$ ou $(p(y), p(x|y))$ pour tout $x \in X, y \in Y$.

Propriétés de l'équivocation

(3)

Lemme. Soit $E: \mathcal{K} \times \mathcal{M} \rightarrow \mathcal{C}$ donné, avec espaces de proba sur \mathcal{K} et \mathcal{M} donnés, \mathcal{C} induite.

$$H(\mathcal{K}, \mathcal{M}, \mathcal{C}) = H(\mathcal{K}, \mathcal{C}) = H(\mathcal{K}, \mathcal{M}) = H(\mathcal{K}) + H(\mathcal{M}).$$

Preuve. Comme

$(\mathcal{K}, \mathcal{M})$ détermine

$$C = E(\mathcal{K}, \mathcal{M}) = E_{\mathcal{K}}(\mathcal{M})$$

et (\mathcal{K}, C) détermine

hypothèse de
l'indépendance
de la clé et
message.

$$\mathcal{M} = D_{\mathcal{K}}(C) \text{ on a } H(\mathcal{K}, C) = H(\mathcal{K}, \mathcal{M})$$

$$\text{L'indépendance} \quad = H(\mathcal{K}, \mathcal{M}).$$

de \mathcal{K} et \mathcal{M} implique: $= H(\mathcal{K}) + H(\mathcal{M})$. □

Exercice. Interpréter

$$p(C | (\mathcal{K}, \mathcal{M})) = \begin{cases} 1 & \text{si } E_{\mathcal{K}}(\mathcal{M}) = C \\ 0 & \text{sinon,} \end{cases}$$

et

$$p(M | (\mathcal{K}, C)) = \begin{cases} 1 & \text{si } D_{\mathcal{K}}(C) = M \\ 0 & \text{sinon,} \end{cases} = 0$$

en $H(\mathcal{K}, \mathcal{M}, \mathcal{C}) = H(\mathcal{K}, \mathcal{M}) + H(C | (\mathcal{K}, \mathcal{M}))$

pour élaborer la preuve. (4)

Lemme. $H(X|C) = H(X) + H(m) - H(C)$.

Preuve. $H(X, C) = H(X|C) + H(C)$,

donc par le lemme précédent :

$$H(X|C) = H(X, C) - H(C)$$

$$= H(X, m) - H(C) = H(X) + H(m) \\ - H(C). \quad \square$$

Proposition.

$$H(m|C) = H(X) + H(m) - H(C) - H(X|(m, C)) \\ = H(X|C) - H(X|(m, C)).$$

Preuve. (i) $H(m|C) = H(m, C) - H(C)$,

(ii) $H(X, m, C) = H(m, C) + H(X|(m, C))$, et

(iii) $H(X, m, C) = H(X) + H(m)$.

$$\text{Alors } H(m|C) = H(X, C) - H(C) - H(X|(m, C))$$

$$= H(X) + H(m) - H(C)$$

$$= H(X|C) - H(X|(m, C)) - H(X|(m, C)). \quad \square$$

Cor. $H(m|C) \leq H(X|C)$.

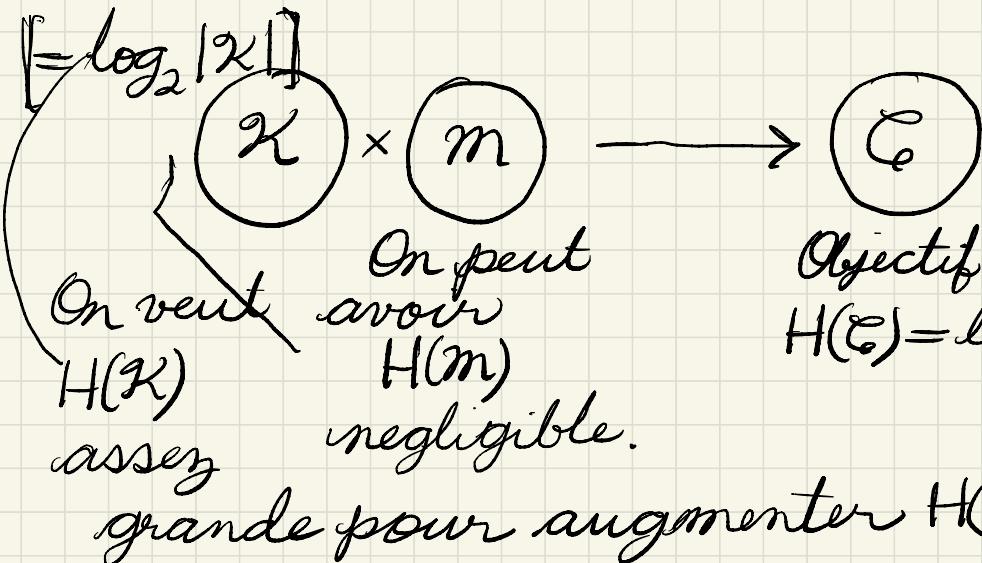
Remarque. Ce corollaire encodé

(5)

le fait qu'une attaque cryptanalytique qui vise à déterminer la clé, déterminera aussi le message. Il peut exister une attaque qui détermine M , étant donné $C = E_K(M)$, sans déterminer K .

Théorème. Si un cryptosystème est parfaitement sûr alors $H(K) \geq H(m)$.

Preuve. $H(K) \geq H(K|C) \geq H(m|C) = H(m)$. □



Distance d'unicité

⑥

Shannon a aussi considéré la question de la quantité de l'information nécessaire au cryptanalyste pour retrouver la clé à partir de plusieurs textes chiffrés (avec la même clé).

$$K \times m \times \dots \times m \rightarrow C^n$$

l'ajout d'entropie m^n
partagé parmi plusieurs message
 $H(m^n) = n H(m)$, si les messages
sont indépendents

$\geq H(K)$ pour n suff. grand

Ici, pour $K \in \mathcal{K}$ fixé on obtient
un chiffrement $m^n \rightarrow C^n$
donné par $(M_1, \dots, M_n) \mapsto (C_1, \dots, C_n)$
avec $C_i = E_K(M_i)$.

Defn. On appelle la distance d'unicité le plus petit entier n tel que $H(K|\mathcal{E}^n) = 0$.

Remarque. Il s'agit du plus petit n tel que la connaissance de n textes chiffrés (G_1, \dots, G_n) , $G_i = E_K(M_i)$ ne laisse plus aucune incertitude résiduelle sur la clé.

On a :

$$\begin{aligned} H(K|\mathcal{E}^n) &= H(K, \mathcal{E}^n) - H(\mathcal{E}^n) \\ &= H(K, m^n) - H(\mathcal{E}^n) \\ &= H(K) + H(m^n) - H(\mathcal{E}^n), \end{aligned}$$

où on note

$$H(\mathcal{E}^n) = H(G_1, \dots, G_n) \text{ et}$$

$$H(m^n) = H(m_1, \dots, m_n),$$

tel que

$$E_n : K \times M_1 \times \dots \times M_n \rightarrow G_1 \times \dots \times G_n.$$

Si on suppose que ξ_1, \dots, ξ_n sont indépendants, alors

$$H(\mathcal{C}^n) = n H(\xi) (= n \log_2 |\mathcal{C}|)$$

et si la limite si ξ uniforme

$$H = \lim_{n \rightarrow \infty} \frac{1}{n} H(m_1, \dots, m_n) \text{ existe}$$

et que la suite $(\frac{1}{n} H(m_1, \dots, m_n))$ se stabilise rapidement,
on donc $d = n$ minimum
tel que

$$H(X) + H(m^n) - H(\mathcal{C}^n) = 0.$$

Avec les hypothèses ci-dessus
on trouve

$$H(X) + dH - d \log_2 |\mathcal{C}| = 0$$

et donc

$$d = \frac{H(X)}{\log_2 |\mathcal{C}| - H}.$$

Exemple

$m \in \mathcal{E}$

Soit $E : \mathcal{X} \times A \xrightarrow{m} A$ un chiffrement par substitution, $A = \{A_1, \dots, A_n\}$ et M_1, \dots, M_n les caractères successifs de la langue française (ou anglaise, allemande, etc.). Le calcul des fréquences des textes clairs permet d'estimer l'entropie par lettre, $H \approx 1,8$ bits.

On note que $H < \log_2(26) \approx 4,7$ bits

Avec $\mathcal{X} = \text{groupe symétrique } S_{26}$ (bijections $A \rightarrow A$),

on a

$$H(\mathcal{X}) = \log_2(26!)$$

et (\mathcal{C} aléatoire)

$$H(\mathcal{C}) = \log_2(26) \approx 4,7 \text{ bits.}$$

On en déduit

$$d \approx \frac{\log_2(26!)}{\log_2(26) - H} \approx 30.$$

Cela veut dire qu'on droit pouvoir récupérer la clé dès le texte chiffré dépasse une trentaine de caractères.

Remarque On doit conclure que, s'on chiffre des messages avec assez de redondance en utilisant une clé fixée, le cryptanalyste aura à sa disposition assez d'information pour retrouver la clé.

Attention. Cela ne prend pas en considération le coût de calculer la clé.

Par exemple, en cryptographie à clé publique, il n'y a pas de sécurité théorique ($I(m, \epsilon) =$

$H(m) = H(c)$ ou $H(m|c) = 0$ ou
 $H(m, c) = H(m)$, etc.). La sécurité
se repose sur la difficulté
computationnelle à calculer
la clé privée ou le message
(qui est uniquement déterminé
par le texte chiffré et la clé
publique).

En effet tout le monde peut
construire des couples
($M, c = E_k(M)$)

et la clé privée est également
uniquement déterminé par
la clé publique.