

INTRODUCTION À LA CRYPTOGRAPHIE

Sandrine Julia

Université Côte d'Azur

Option – Licence 3 Info./ Math.-Info./ Sc. & Techn. – Automne 2023

<https://lms.univ-cotedazur.fr/course/view.php?id=13766>

<https://upinfo.univ-cotedazur.fr/~julia/Crypto>

- 0 - Introduction au calcul symbolique
- 1 - Introduction à la théorie de l'information
- 2 - Codes de source - codes d'Huffman
- 3 - Codes correcteurs - codes de Hamming
- 4 - Cryptographie à clef secrète
- 5 - Compression de texte
- 6 - Cryptographie à clef publique I
- 7 - Cryptographie à clef publique II
- 8 - Fonctions de hachage, intégrité
- 9 - Signatures digitales
- 10 - Certificats, authentification
- 11 - La cryptographie de demain

(Les TP utilisent Sympy et la librairie OpenSSL)

SYSTÈME DE COMMUNICATION

1 – Introduction à la théorie de l'information

- ▶ la communication fait référence à la circulation d'**information** entre une **source** et un **récepteur**
- ▶ la source émet un **message** qui, avant d'être lu par le récepteur, va transiter dans un **canal**
- ▶ toute perturbation du message due au canal s'appelle le **bruit**
- ▶ la nature de la source peut être variée : on ne considère ici que des **sources discrètes** (\neq continues) et **sans mémoire** (*non-markoviennes*)
- ▶ on peut ajouter de la **redondance** au message en cas de bruit
- ▶ on peut aussi vouloir garder à tout prix le message **secret**



CODE

- ▶ intuitivement, un **code** est une méthode de transformation qui convertit la représentation d'une information en une autre (cette définition nécessitera d'être précisée selon le contexte)
- ▶ selon le but recherché, les codes ont différents usages :
 - **efficacité** de la transmission : **compression des données**
 - **sécurité** de l'information : **cryptage, authentification**
 - **intégrité** du message : **détection, correction des erreurs**
- ▶ à l'action de coder (le **codage**), on couple le **décodage** qui a pour but de restituer tout ou partie des messages émis par la source
- ▶ on distingue le **codage avec perte** d'information du **codage sans perte**
- ▶ on dissocie le **codage de source** du **codage de canal** : le premier est une représentation (binaire) concise d'un message, le second vise à adapter la sortie du premier au canal où elle va transiter.

UNE TRÈS LONGUE HISTOIRE

- ▶ à Sparte en - 404 av. J-C : la scytale
- ▶ à Rome vers - 50 av. J-C : le code de César

$A \rightsquigarrow D$
 $B \rightsquigarrow E$
 $C \rightsquigarrow \dots$

- ▶ en Europe en 1586 : le chiffre de Vigenère (cf. TD n° 1)
- ▶ à Paris en 1829 : le code Braille
- ▶ avec la télégraphie en 1832 : le code Morse

A	--	B	----	C	----	D	...
E	.	F	----	G	---	H
I	..	J	----	K	---	L
M	--	N	--	O	----	P
Q	----	R	---	S	...	T	-
U	---	V	W	---	X	----
Y	----	Z	----				

- ▶ aux USA en 1919, le code de Vernam : $M \oplus K = C$

EXEMPLES

- **des codes de source**
 - ▶ le code Morse
 - ▶ le code Braille
 - ▶ le code ASCII, ASCII étendu, Unicode ...
- **des codes pour compresser**
 - ▶ RLE (Run Length Encoding)
 - ▶ code d'Huffman
 - ▶ codage arithmétique
 - ▶ (Lempel-Ziv)
- **des codes correcteurs d'erreurs**
 - ▶ codes linéaires
 - ▶ codes de Hamming
 - ▶ codes de Reed-Solomon
 - ▶ codes convolutifs
- **des codes pour chiffrer**
 - ▶ code de Vernam
 - ▶ DES, AES
 - ▶ RSA, El Gamal

THÉORIE DE L'INFORMATION

- ▶ la théorie de l'information est due à Claude E. Shannon
A Mathematical Theory of Communications, 1948
- ▶ théorie mathématique basée sur les probabilités et visant à décrire les systèmes de communication
- ▶ elle a subi l'influence d'autres théoriciens de l'informatique : A. Turing, J. von Neumann, N. Wiener et présente des convergences avec les travaux de R.A. Fisher
- ▶ le problème est celui de la **communication** entre une **source** et un **récepteur** : la source émet un **message** que le récepteur lit
on voudrait quantifier l'**information** que contient chaque message émis

il est clair que si l'émetteur dit toujours la même chose, la quantité d'information apportée par une répétition supplémentaire est nulle

- ▶ l'**entropie** existe en version combinatoire, en probabilités discrètes ou encore en probabilités continues
- ▶ la quantité d'information n'est pas une propriété **intrinsèque** d'un certain objet, mais une propriété de cet objet en relation avec un ensemble de possibilités auquel il appartient
dans le cas contraire, on a recours à la **complexité de Kolmogorov**.

INFORMATION COMBINATOIRE

- ▶ on considère un **ensemble de possibilités** Ω
- ▶ le **message** consiste à spécifier un élément de Ω
- ▶ pour l'instant, on suppose que tous les éléments de Ω sont aussi vraisemblables les uns que les autres
- ▶ quelle est l'**information** transmise par le message : "Telle possibilité s'est réalisée." ?
- ▶ si Ω a n éléments, on peut spécifier un élément de Ω en donnant $\log_2(n)$ **informations élémentaires** (**bits** au sens *binary units* ou *Shannon*)

*en numérotant les éléments de Ω
et en en donnant la décomposition en base 2*

- ▶ spécifier un élément parmi un ensemble Ω de possibilités revient donc à transmettre $\log |\Omega|$ unités d'information.

ce sera l'écriture simplifiée de $\log_2(|\Omega|)$ dorénavant utilisée

- ▶ on note $I_\Omega(x)$ la **quantité d'information** de l'événement x appartenant à l'ensemble Ω , on a donc :

$$I_\Omega(x) = \log |\Omega|$$

UN PEU DE PROBA. DISCRÈTES

- ▶ on suppose que toutes les possibilités de Ω ne sont plus forcément équiprobables

l'idée est que les événements les plus rares sont ceux avec le plus d'information

- ▶ on a vu que spécifier l'appartenance d'un élément de Ω à la partie A contient en unités d'information :

$$I_\Omega(A) = \log |\Omega| / |A|$$

- ▶ si les événements de Ω étaient équiprobables, la probabilité de la partie A serait :

$$p(A) = |A| / |\Omega|$$

- ▶ si (Ω, p) est un espace probabilisé et A est une partie de Ω , l'information apportée par la réalisation d'un événement de A est donc :

$$I_\Omega(A) = \log 1/p(A) = -\log p(A)$$

INFORMATION COMBINATOIRE (SUITE)

- ▶ petit à petit, on va tendre vers un cadre **probabilisé**
- ▶ quelle est l'information de la phrase "L'événement réalisé appartient à un sous-ensemble A de l'ensemble Ω des possibilités." ? Intuitivement ...

*si on dit que l'événement réalisé appartient à **une partie A de Ω** , puis qu'on spécifie ensuite de quel événement de A il s'agit, on a totalement spécifié l'événement, comme si on l'avait donné directement dès le début*

- ▶ spécifier directement l'événement réalisé, c'est transmettre $\log |\Omega|$ unités d'information
- ▶ spécifier un événement, en sachant déjà qu'il appartient à un sous-ensemble A , peut se faire en transmettant $\log |A|$ unités d'information
- ▶ ainsi, en précisant que l'événement appartient à A , on avait déjà transmis $\log |\Omega| - \log |A|$ unités d'information d'où :

$$I_\Omega(A) = \log |\Omega| / |A|$$

DÉFINITION DE L'ENTROPIE

- ▶ en particulier, pour un événement x de Ω , on obtient :

$$I_\Omega(x) = \log 1/p(x)$$

on remarque que la réalisation d'un événement rare contient plus d'information que celle d'un événement certain qui n'apporte aucune information

- ▶ l'**entropie** est l'information moyenne obtenue en tirant un élément de Ω suivant la probabilité p :

$$\begin{aligned} H(\Omega, p) &= \sum_{x \in \Omega} p(x) I_\Omega(x) \\ &= - \sum_{x \in \Omega} p(x) \log p(x) \\ &= \sum_{x \in \Omega} p(x) \log 1/p(x) \end{aligned}$$

l'entropie s'interprète aussi comme le nombre moyen minimal de symboles binaires par lettre nécessaires pour représenter un alphabet.

ENTROPIE : UN 1^{ER} EXEMPLE

- ▶ soit une urne avec 4 boules : $\Omega = \{R, B, J, V\}$
▶ on tire une boule **au hasard** et on indique sa couleur

- ▶ l'entropie est ici **maximale** :

$$H(\Omega, p) = 4 \left(\frac{1}{4} \log_2 \left(\frac{1}{1/4} \right) \right) = \log_2(4) = 2$$

- ▶ si on code les couleurs par **00, 01, 10, 11**, l'information d'un tirage correspond à **2 bits**

ENTROPIE : UN 2^E EXEMPLE

- ▶ si l'urne contient $R_1, R_2, R_3, R_4, B_1, B_2, J$ et V l'entropie devient :

$$H(\Omega, p) = \frac{1}{2} \log_2(2) + \frac{1}{4} \log_2(4) + \frac{1}{8} \log_2(8) + \frac{1}{8} \log_2(8)$$

$$H(\Omega, p) = \frac{7}{4}$$

- ▶ si les codes respectifs sont **0, 10, 110, 111**, l'information sur la couleur tirée occupe 1 bit une fois sur deux, 2 bits une fois sur quatre et 3 bits une fois sur quatre, soit en moyenne pondérée : **7/4 bits**.

PROPRIÉTÉS DE L'ENTROPIE

Soit $S = (\Omega, p)$ une source munie d'une distribution de probabilités p :

- ▶ on a vu que l'entropie mesure la **quantité d'information** en moyenne d'une source
- ▶ on dit aussi que l'entropie mesure l'**incertitude** d'une source et en effet elle s'annule si un élément a une probabilité de 1 :

$$0 \leq H(S)$$

- ▶ l'entropie est maximale pour une distribution de **probabilité uniforme** d'où son nom de **mesure du désordre**, ce qui permet d'obtenir :

$$H(S) \leq \log |\Omega|$$

Ainsi :

$$0 \leq H(S) \leq \log |\Omega|$$

INÉGALITÉ DE GIBBS

Soit Ω une source finie munie de 2 distributions de probabilité discrètes p et q

Lemme (utilitaire) : l'inégalité suivante est satisfaite :

$$\sum_{x \in \Omega} p(x) \log q(x)/p(x) \leq 0$$

avec égalité si p identique à q .

Preuve (dans le seul cas du logarithme népérien) :

- ▶ on a $\ln r \leq r - 1$ et l'égalité obtenue pour $r = 1$
- ▶ on pose $r = q(x)/p(x)$
- ▶ on obtient :

$$\sum_{x \in \Omega} p(x) \ln q(x)/p(x) \leq \sum_{x \in \Omega} p(x) (q(x)/p(x) - 1) = 1 - 1 = 0$$

MAJORATION DE L'ENTROPIE

Soit $S = (\Omega, p)$ une source munie d'une distribution de probabilités p :

- ▶ on obtient une **majoration de l'entropie** à partir du **lemme de Gibbs** où la seconde distribution de proba q est choisie uniforme : $\forall x, 1 \leq x \leq |\Omega|, q(x) = 1/|\Omega|$

$$\sum_{x \in \Omega} p(x) \log q(x)/p(x) \leq 0$$

$$\sum_{x \in \Omega} p(x) (\log q(x) - \log p(x)) \leq 0$$

$$\sum_{x \in \Omega} p(x) (\log (1/|\Omega|) - \log p(x)) \leq 0$$

$$\sum_{x \in \Omega} p(x) \log (1/|\Omega|) + \sum_{x \in \Omega} p(x) \log 1/p(x) \leq 0$$

- ▶ or $H(S) = \sum_{x \in \Omega} p(x) \log 1/p(x)$ donc :

$$H(S) \leq - \sum_{x \in \Omega} p(x) \log (1/|\Omega|)$$

$$H(S) \leq - \sum_{x \in \Omega} p(x) (\log 1 - \log |\Omega|)$$

$$H(S) \leq \sum_{x \in \Omega} p(x) \log |\Omega|$$

$$H(S) \leq \log |\Omega|$$

UNE NOTION FONDAMENTALE

- ▶ le calcul de l'entropie d'une source de messages donne une **mesure de l'information minimale** que l'on doit conserver afin de représenter ces données **sans perte**
- ▶ l'entropie permet d'estimer la **qualité des codes** utilisés en vue du chiffrement
- ▶ elle permet une **minoration de la longueur moyenne des mots d'un code** : c'est le (premier) Théorème de Shannon.
- ▶ en compression de fichiers informatique, l'entropie indique le **nombre minimal de bits** que peut atteindre un fichier compressé

*l'entropie d'une source qui émet un caractère 1 avec une probabilité 0,1 et le caractère 0 avec une probabilité 0,9 est de 0,47 contre 0,3 dans le cas de probabilités uniformes
ainsi, une faible entropie permet d'envisager une bonne compression ...*

- ▶ en pratique, l'**entropie de l'image ou du son** est abaissée en retirant des détails imperceptibles pour les humains, comme lors de la compression des sons par le format MP3, des images par JPEG ou des vidéos par MPEG.

EN PYTHON

```
from math import *

s = {'a': 0.1, 'b': 0.1, 'c': 0.25, 'd': 0.15, 'e': 0.35, 'f': 0.05}

def entropie (source) :

    res = 0
    for ch in source :
        p = source[ch]
        res = res + ( p * (log(1/p,2)))

    return res

print(entropie(s))          # --> 2.321127473337187
```

(cf. TP n° 1)

A suivre ...