

# Théorie de l'information

D. Kohel

04/01/2021



# Théorie d'information

(1)

Introduction : On traite le problème de la transmission efficace de l'information et sa sécurité, et surtout les transformations de l'information qui permettent d'effectuer ces transmissions.

Les domaines principaux de la théorie d'information sont :

## Le codage de l'information

① la compression des données : comment distribuer l'information de manière uniforme et avec concision.

## ② correction d'erreurs

distribuer et étaler l'information avec redondances (e.g. par répétition) pour protéger



l'information contre des pertes  
en raison du bruit dans le  
canal de transmission. [intégrité]  
La cryptographie

③ sécurité de l'information:  
les codages (= chiffrements) qui  
assurent la confidentialité,  
l'intégrité (avec preuve, contre  
un adversaire) et l'authentifi-  
cation des messages et de  
leurs expéditeurs.

Ces trois aspects de la théorie  
de l'information font partie  
de la théorie de Shannon,  
introduit en 1948.

## Représentation de l'information ③

Définitions Un alphabet  $A$  est un ensemble fini des lettres (ou caractères ou symboles)

Exemple •  $\{A, B, \dots, Z\}$  classique, plus éventuellement des minuscules, ponctuation, espaces, etc.

- $\{0, 1\}$  binaire (bits)
- Octets ("bytes" en anglais) =  $\{0, 1\}^8$

Un mot est une suite finie de caractères dans un alphabet.

L'ensemble des mots de longueur  $n$  sur  $A$  s'écrit  $A^n$ , et

$$A^* = \bigcup_{n \geq 0} A^n$$

est l'ensemble des mots. Un sous ensemble  $M \subseteq A^*$  de mots

(ou de messages) et une langue  
(une langue formelle ou naturelle).

Remarque. Les messages  $m$   
d'une langue peut être équipé  
avec une fonction de probabilité.  
Un codage d'un ensemble  $M$   
de msgs (pas forcément dans  $A^*$ )  
est une application

$$C: M \longrightarrow A^*$$

Si  $C$  est injectif, on dit que  $C$   
est sans pertes. Un décodage  
est une application inverse:

$$D: C(M) \longrightarrow M$$

L'ensemble  $C(M)$  s'appellent les  
mots du code,  $C(M) \subseteq A^*$  le code.

Un chiffrement est un codage pas facilement inversible (sans informations supplémentaires). Par rapport à un chiffrement, on parle des messages ou des textes clairs de  $m$  et leurs images  $c = C(m) \in \mathcal{C}(m)$  sont des textes chiffrés. On appelle  $\mathcal{C} = \mathcal{C}(m)$  l'espace des textes chiffrés.

Exemple. Si  $m = \mathcal{C} = A^n$ , où  $m$  correspond à des mot de la langue français (des phrases, etc. de longueur  $n$ ), on a des messages (= mots, phrases, ...) qui sont plus probable que

⑥

d'autres:

$$A = \{A, \dots, Z, \_ \}, n=8,$$

$m = \text{JAI SOIF}$  est plus probable que  
 $m = \text{AKZMBFXN}$ .

Une fonction de probabilité:

$$p: \mathcal{M} = A^n \longrightarrow [0, 1]$$

donne les fréquences des mots  
 qui apparaissent dans la langue  
 française, tel que  $\sum_{m \in \mathcal{M}} p(m) = 1$ .

Alors souvent on parle de  
l'espace des messages pour  
 évoquer que  $\mathcal{M}$  est un espace  
 de probabilité (existence de  
 même si  $\mathcal{M} = A^n$ ,  $p: \mathcal{M} \longrightarrow [0, 1]$ ).

on peut avoir des mots  $m \in \mathcal{M}$   
 avec  $p(m) = 0$  (e.g.  $m = \text{AKZMBFXN}$ ).

⑦

Au contraire, suivant en théorie d'information, on cherche des codages (ou chiffrements) avec la propriété que  $\mathcal{C}(M)$  est un espace de probabilité uniforme.

Attention. Pas possible si  $M$  est fini et  $\mathcal{C}: M \rightarrow A^*$  est sans pertes.

Ex. (Codages) ASCII et ISO-8559-1 sont des codages qui envoient des symboles alpha-numériques à des octets  $\{0,1\}^8 \subseteq \{0,1\}^*$ , qui sont facilement décodés par l'ordinateur.

## Théorie de Shannon (1948)

⑧

Mathematical theory of communication  
par Claude Shannon

- La compression soulève le problème de la mesure quantitative de l'information, et de la redondance de l'information.
- L'intégrité de transmission soulève les problèmes de
  - taux de transmission maximal sur un canal avec bruit
  - la construction explicite des codages, avec taux de transmission (ou rendement) donné permettant une

transmission fiable

- La sécurité de l'information soulève le problème de l'information mutuelle (entre l'espace des messages et l'espace des textes chiffrés).

Théorie de probabilité discrète.

Soit  $X$  un ensemble dénombrable (ou fini) avec une fonction de probabilité associée :

$$p: X \longrightarrow [0,1]$$

qui vérifie (par définition) :

$$\sum_{x \in X} p(x) = 1.$$

Un tel ensemble est un espace de probabilité.



(10)

Défn Un évènement est un sous-ensemble d'un espace de probabilité. La probabilité de  $E \subseteq X$  est  $p(E) = \sum_{x \in E} p(x)$ .

Remarque. On a défini une extension de  $p$  à  $2^X = \{E \subseteq X\}$ , où on identifie  $X \subseteq 2^X$  par  $x \mapsto \{x\}$ . C'est une extension de  $p: X \rightarrow [0,1]$  car  $p(\{x\}) = p(x)$ .

Remarque. En général (théorie de proba non discrète) on a besoin de distinguer une mesure  $\mu$  sur  $X$  et la probabilité

$$p(E) = \int_E d\mu.$$

Dans le cadre discret,

la probabilité est déterminée par  $p(\{x\}) = p(x)$  et on remplace l'intégrale par une somme.

Ex. Espace de proba uniforme.

Si  $X$  est fini, on définit la probabilité uniforme  $p: X \rightarrow [0, 1]$

par  $p(x) = 1/|X|$ . On a alors

$$p(E) = \frac{|E|}{|X|}.$$

Probabilité conditionnelle

Defn. La proba conditionnelle d'un événement  $A$ , sachant qu'un autre événement  $B$  s'est réalisé, est

$$p(A|B) = \frac{p(A \cap B)}{p(B)}.$$

Lemme. La probabilité cond. (12)  
sur  $B$  est une fonction de proba  
sur  $X$ :  $p(\cdot | B): X \longrightarrow [0, 1]$ .

Preuve. Exercice.

Théorème (Bayes)

Si  $A$  et  $B$  sont des événements,  
alors 
$$p(B)p(A|B) = p(A)p(B|A).$$

Preuve. Clair (les deux côtés  
sont égaux à  $p(A \cap B)$  par defn).

Indépendance

Defn Deux événements  $A$  et  $B$   
sont indépendants si

$$p(A \cap B) = p(A)p(B).$$

Lemme. Si  $A$  et  $B$  sont indépendants,  
alors  $p(A|B) = p(A)$  (et  $p(B|A) = p(B)$ ).

Preuve. Exercice.

## Variables aléatoires et espérance.

(13)

Defn. Une fonction  $F: X \rightarrow \mathbb{R}$  sur  $X$  s'appelle une variable aléatoire. ( $X$  un espace de proba.)  
L'espérance mathématique de  $F$  est  $E(F) = \sum_{x \in X} F(x) p(x)$ ,  
un "moyenne" ou somme pondérée par la fonction de probabilité.

Remarque. Dans le cadre non discrète, l'espérance de  $F$  est l'intégrale  $\int_X F(x) d\mu(x)$ .

Remarque. Une variable aléatoire  $F$  induit une fonction de proba sur  $Y = F(X) \subseteq \mathbb{R}$ :  $P_Y: Y \rightarrow [0, 1]$   
 $y \mapsto p(F^{-1}(y))$

Exercice. Montrer que

(14)

$$E(id_Y) = \sum_{y \in Y} y P_Y(y) = E(F)$$

## Entropie

Mesure de la quantité d'information d'un espace, introduit par Claude Shannon.

Defn. L'entropie de  $X (= (X, p))$  est l'espérance mathématique de la variable aléatoire


$$F(x) = -\log_2(p(x)) :$$

$$H(X) = \sum_{x \in X} \log_2\left(\frac{1}{p(x)}\right) p(x).$$

On s'appelle l'unité d'entropie un bit d'information.

(15)

Remarque Si  $p(x) = 0$ , on définit  $\log_2\left(\frac{1}{p(x)}\right)p(x) = 0$ , ce qui est cohérent avec la limite  $\lim_{t \rightarrow 0} t \log(t) = 0$ . Graphiquement



Donc, pour  $t = p(x) = 0$  la définition est cohérente.

Exemples  $X = \{0, 1\} = \{\text{"pas beau"}, \text{"beau"}\}$   
valeurs du temps à Marseille,  
à Paris, etc.

| $x$ | $p(x)$ |
|-----|--------|
| 0   | 0,25   |
| 1   | 0,75   |

$$H(X) = 0,25 \log_2(4)$$

$$+ 0,75 \log_2(4/3)$$

$$= 0,50 + 0,75(2 - \log_2(3))$$

$$\doteq 0,4150 < 1.$$

L'idée: La réponse à la question: Est-ce qu'il fait beau? porte 0,4150 bits d'information  
 $Y = \{0, 1\}$  (même ensemble)

$$\begin{array}{c|c} x \in Y & p(x) \\ \hline 0 & 0,50 \\ 1 & 0,50 \end{array} = \text{la proba uniforme}$$

$$H(Y) = 0,50 \log_2(2)$$

$$+ 0,50 \log_2(2) = 1.$$

Pour la proba uniforme, la réponse à la question porte la quantité maximale d'information (= un bit).

$$Z = \{0, 1\}$$

$$\begin{array}{c|c} x \in Z & p(x) \\ \hline 0 & 0 \\ 1 & 1 \end{array}$$

$$H(Z) = 0 \log_2(0) + 1 \log_2(1) = 0 + 0 = 0$$

Aucune information portée par la réponse.

En général, si  $X$  est un espace de proba uniforme ( $p(x) = 1/|X|$ ), alors

$$H(X) = 1/|X| (|X| \log_2 |X|) = \log_2 |X|.$$