

Théorie de l'information

D. Kohel

11/01/2021



L'entropie

Théorème Soit X un espace de proba finie. Alors $H(X) \leq \log_2 |X|$ avec égalité ssi X est uniforme.

Rappel. On dit que X est uniforme si $p(x) = 1/|X|$ pour tout $x \in X$.

Preuve. Par conséquence de l'inégalité de Gibbs.

Lemme (Gibbs). Soit (X, p) un espace de probabilité discrète, et soit $q: X \rightarrow [0, 1]$ une autre probabilité. Alors

$$1/ \sum_{x \in X} p(x) \log(p(x)) \leq \sum_{x \in X} p(x) \log(q(x)),$$


2/ avec égalité ssi $p = q$.

Remarque (Multipliant par $1/\log(2)$)
L'inégalité de Gibbs est
 $H(X) \leq E(\log_2(q(x)))$.

Preuve

(2)

Il suffit de prendre $\log = \ln$,
et observer que $\ln(t) \leq t-1$:



L'inégalité de Gibbs
est équivalente à

$$\sum_{x \in X} p(x) \ln\left(\frac{q(x)}{p(x)}\right) \leq 0. \quad (*)$$

mais on a

$$\begin{aligned} \sum_{x \in X} p(x) \ln\left(\frac{q(x)}{p(x)}\right) &\leq \sum_{x \in X} p(x) \left(\frac{q(x)}{p(x)} - 1\right) \\ &= \sum_{x \in X} (q(x) - p(x)) = 1 - 1 = 0. \end{aligned}$$

On a démontré $(*)$, équivalente
à l'inégalité de Gibbs.

On observe que $\ln(t) \leq t-1$,

ssi $t=1$. Par conséquent, ③
l'inégalité $*$ est stricte s'il
existe x tel que $p(x) \neq q(x)$.
Cela établit la propriété 2/. $\square$

Preuve du théorème. Il suffit
de mettre $q(x) = 1/|X|$. Alors
 $H(X) \leq E(\log_2 |X|) = \log_2 |X|$. $\square$

Théorie de Shannon

Premier théorème de Shannon

Définition. Soit $C: X \rightarrow A^*$ un
codage (où A est un alphabet
fini). On dit que i) C est sans
pertes si C est injectif, et
ii) C est uniquement décodable
si l'extension $C^*: X^* \rightarrow A^*$,
définie par $C^*(x_1 \dots x_n) = C(x_1) \dots C(x_n)$,
est sans pertes.

Exemple. $X = \{A, B, C\}$, $A = \{0, 1\}$. ④

Le codage $C: X \longrightarrow A^*$ donné
par: $C(A) = 0$, $C(B) = 1$, $C(C) = 01$.

Alors C est sans pertes, mais
pas uniquement décodable,
car $C^*(AB) = 01 = C^*(C)$.

Par contre, $C': X \longrightarrow A^*$ donné
par: $C'(A) = 00$, $C'(B) = 11$, $C'(C) = 01$,
est uniquement décodable.

Théorème de Shannon (codage source)
Soit $C: X \longrightarrow A^*$ un codage
uniquement décodable, et
 $\ell_C: X \longrightarrow \mathbb{N}$ la fonction longueur
(sur A^*) composée avec C . ($\ell_C = \ell \circ C$)
Alors

i)
$$\frac{H(X)}{\log_2 |A|} \leq E(\ell_C), \text{ et}$$

(5)

ii) il existe un codage C
pour lequel $E(l_C) \leq \frac{H(X)}{\log_2 |A|} + 1$.

Définition. Un codage est instantané ou préfixe si aucun mot de code est un préfixe d'un autre.

Par exemple: Le code $(= C(X))$

$$\{C(A), C(B), C(C)\} = \{0, 1, 01\}$$

n'est pas préfixe. Par contre

$$\{C(A), C(B), C(C)\} = \{00, 11, 01\}$$

est préfixe.

Lemme Un codage préfixe est uniquement décodable.

Preuve Clair (exercice).

Soit $c_1 c_2 \dots c_n = C(x_1 \dots x_n)$ —

on peut identifier les mots ⑥ de code c_1 , puis c_2 , etc en lisant de gauche à droite. $\square$

Remarque. La définition de codage instantané/préfixe est asymétrique: On peut par symétrie définir un codage suffixe (aucun mot est un suffixe d'un autre). La propriété d'être u.d. reste valable. Mais ...

On peut comparer:

x	$C_1(x)$	$C_2(x)$
A	0	0
B	11	11
C	01	10

Alors C_1 est suffixe et C_2 est préfixe. Les deux sont u.d.

Or si ⑦

$$C_1^*(x_1 \dots x_n) = \begin{array}{c} \overbrace{A} \ \overbrace{C} \ \overbrace{B} \dots \\ 00111\dots 1 \\ \underbrace{\hspace{1cm}} \underbrace{\hspace{1cm}} \underbrace{\hspace{1cm}} \\ AAB \ B \dots \end{array}$$

il faut lire jusqu'à la fin afin de décider si le début a commencé par $ACB\dots$ ou par AAB . La différence sera déterminé par la longueur de $C_1^*(x_1 \dots x_n)$.

Par contre

$$C_2^*(x_1 \dots x_n) = \overbrace{A} \overbrace{A} \overbrace{B} \overbrace{B} \dots 1,$$

étant préfixe, on peut décoder (de gauche à droite) sans attendre la fin de la transmission du mot de code.

Remarque. Un codage

$C: x \mapsto A^n \subseteq A^*$ (de longueur fixée) est préfixe, ssi il est sans perte.

Codage de Huffman ⑧
permet de réaliser un codage
préfixe qui satisfait la cond-
ition ii) du théorème de Shannon.


C'est un algorithme de compres-
sion. Remarque : la propriété
d'être préfixe (et également u.d.)
est une propriété du code
 $C(X)$ (en supposant que C
soit sans pertes) et pas de
l'espace de probabilité.

Arbre de codage fini

Un arbre de codage est un
arbre (graphe sans cycle
avec une racine = sommet
distingué) dérivé tel que


⑨
chaque feuille (sommets ^{terminal})
portent une étiquette $x \in X$
et chaque arc d'un sommet
porte une étiquette distincte
dans A .

Ex. Arbre binaire ($A = \{0, 1\}$)




Si chaque message $x \in X$ apparaît
une et une seule fois comme
étiquette d'une feuille, on dit
que T est un arbre de codage
pour X .


Si $n=2$, retourner
et si ($q > 2$ et)



$n \leq q$ on met:



Sinon, mettre (construction d'un
nouveau
espace de proba):



$y_1 = x_q, y_2 = x_{q+1}, \dots, y_{n-q-1} = x_{n-1}$,
ayant des probabilités:

$$p(y_0) = \sum_{0 \leq i < q} p(x_i) \text{ et } p(y_j) = p(x_{j+q-1})$$

pour tout $j \geq 1$.

On retourne l'arbre de Huffman
pour $\{y_0, \dots, y_{n-q-1}\}$.


N.B. L'étiquette pour y_0 devient
un sous-arbre.

Exemple. $A = \{0, 1\}$.

$X = \{a, b, c, d\}$.


$p(x)$: $1/8, 1/8, 1/4, 1/2$

Un arbre de codage est donc :




Remarque

Lors de la construction on peut échanger $\{a, b\}$, ou $\{a, b\}, c\}$, ou $\{\{a, b\}, c\}, d\}$.



L'arbre de codage de Huffman :



Le codage préfixe de Huffman est donc :

$a \rightarrow 000$
 $b \rightarrow 001$

$c \rightarrow 01$
 $d \rightarrow 1$

Conclusion. Un codage de Huffman n'est pas unique, mais on peut démontrer que l'espérance mathématique de longueur $E(\ell)$ est un invariant de tout codage de Huffman. (43)

Prochain résultat:

Le codage de Huffman satisfait

$$E(\ell) \leq \frac{H(X)}{\log_2(q)} + 1.$$