

Théorie de l'information

A. Kohel
06/01/2022



Théorie des codes

④

Probabilité conditionnelle

Motivation

X = émetteur de symboles, messages

↓ canal
↓ ~~≠~~ bruit

Y = message reçu

où X et Y sont des espaces de proba.

Si un mot x est transmis (avec proba $p(x)$), quel est la proba que y soit reçu? On la note:

$$p(\cdot | x) : Y \longrightarrow [0, 1]$$

où $p(y|x)$ est la proba que y soit reçu, étant donné que x soit transmis.

On définit une proba jointe par

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

$$(x, y) \longmapsto p(x) p(y|x) =: p(x, y)$$

nous avons également une proba sur Y , induit par

$$p = p_x : X \longrightarrow [0, 1] \text{ et } p(\cdot | x) :$$

$$p_y : Y \longrightarrow [0, 1]$$

$$y \longmapsto p_y(y) = \sum_{x \in X} p(x) p(y|x)$$

Exercice Montrer que la proba jointe $p: X \times Y \rightarrow [0,1]$ et la proba p_y sont des probabilités, étant données p_x et des probas conditionnelles $p(\cdot|x): Y \rightarrow [0,1]$, pour $x \in X$, $p(x) \neq 0$. ②

On peut également définir $p(\cdot|y): X \rightarrow [0,1]$

et $p(\cdot|x): Y \rightarrow [0,1]$ en fonction d'une proba jointe, pour tout $x \in X$ et $y \in Y$ avec $p_x(x) \neq 0$ et $p_y(y) \neq 0$.

Remarque. Etant donnée

$$p: X \times Y \rightarrow [0,1]$$

on en déduit

$$p_x: X \rightarrow [0,1] \text{ par } p_x(x) = \sum_{y \in Y} p(x,y)$$

et

$$p_y: Y \rightarrow [0,1] \text{ par } p_y(y) = \sum_{x \in X} p(x,y)$$

Inversement,

$$p_x \text{ et } p(\cdot|x) \iff p(x,y) = p_x(x) p(y|x)$$

$$\forall x \in X, p_x(x) \neq 0$$

Entropie conditionnelle

Nous avons vu que

$$0 \leq H(x) \leq \log_2 |X|,$$

avec l'interprétation de $H(x)$ comme le contenu de l'info dans x . L'objectif est de définir le contenu de l'info dans y , après avoir pris connaissance de (x dans) X . C'est l'entropie conditionnelle ($H(y|x)$ ou) $H(y|X)$.

Défn Pour $x \in X$ on définit

$$H(y|x) = \sum_{y \in Y} p(y|x) \log_2 \frac{1}{p(y|x)}$$

et l'entropie conditionnelle

$$H(y|X) = \sum_{x \in X} p(x) H(y|x) = \mathbb{E}(H(y|x)),$$

où on voit

$$H(y|x) : X \longrightarrow \mathbb{R},$$

une variable aléatoire.

Défn L'information mutuelle

est
$$I(x,y) = \sum_{x,y} p(x,y) \log_2 \left(\frac{p(x,y)}{p(x)p(y)} \right).$$

$p(y|x)$

En utilisant les identités: ④

$$p(x, y) = p(x) p(y|x) = p(y) p(x|y),$$

on en déduit:

Lemme $I(x, y) = H(x) - H(x|y)$
 $= H(y) - H(y|x).$

Preuve

$$\begin{aligned} I(x, y) &= \sum_{x, y} p(x, y) \log_2 \left(\frac{p(x, y)}{p(x) p(y)} \right) \\ &= \sum_{x, y} p(x) p(y|x) \log_2 \left(\frac{p(y|x)}{p(y)} \right) \\ &= \sum_y \left(\sum_x p(x) p(y|x) \log_2(p(y)^{-1}) \right) \\ &\quad - \sum_x p(x) \left(\sum_y p(y|x) \log_2(p(y|x)^{-1}) \right) \end{aligned}$$

car

$$\log_2 \left(\frac{p(y|x)}{p(y)} \right) = -\log_2(p(y|x)^{-1}) + \log_2(p(y)^{-1})$$

$$= \sum_y \left(\sum_x p(x) p(y|x) \right) \log_2(p(y)^{-1})$$

$$- \sum_x p(x) H(y|x)$$

$$= \sum_y p(y) \log_2(p(y)^{-1}) - H(y|x)$$

$$= H(y) - H(y|x). \quad \square$$

Par symétrie on a $= H(x) - H(x|y).$

Rappel: $I(x, y) = H(x) - H(x|y)$ (Lemme) $= H(y) - H(y|x)$. ⑤

Remarque

$$0 \leq H(y|x) \leq H(y).$$

Si $H(y|x) = 0$, on a $I(x, y) = H(y)$, et on dit que y est dépendant de x .

Si $H(y|x) = H(y)$, donc $I(x, y) = 0$, on dit que y est indépendant de x .

Exercice * Dans le cas $I(x, y) = 0$, montrer que $p(x, y) = p(x)p(y)$, pour tout x et y .

Inversement, si $p(x, y) = p(x)p(y)$, alors

$$\begin{aligned} I(x, y) &= \sum_{x, y} p(x, y) \log_2 \left(\frac{p(x, y)}{p(x)p(y)} \right) \\ &= \sum_{x, y} p(x, y) \log_2 1 = 0. \end{aligned}$$

Conclusion.

x et y sont indépendants ($I(x, y) = 0$) ssi $p(x, y) = p(x)p(y)$.

* Besoin du lemme de Gibbs (pas fait).

Capacité du canal de trans- ⑥

Pour un canal (avec bruit) ^{mission} ayant probabilité conditionnelle $p(y|x) : \mathcal{Y} \rightarrow [0,1]$, on définit la capacité du canal $= \log_2 |\mathcal{X}|$.

$$C = \max_{p: \mathcal{X} \rightarrow [0,1]} I(X,Y) \leq \max_{p: \mathcal{X} \rightarrow [0,1]} H(X)$$

Remarques. On peut supposer que le canal est sans mémoire, i.e. que la fonction $p(y|x)$ ne change pas en fonction du symbole précédent. Sinon la définition la capacité est plus compliquée.

Ici on peut supposer que $\mathcal{X} = \mathcal{Y}$, en tant qu'ensembles, mais leurs fonctions de probabilité peuvent être différentes à cause de bruit.

On dit que le canal est symétrique si

$$\left. \begin{array}{l} p(y|x) = \varepsilon \\ \text{pour tout } y \neq x. \end{array} \right\} \begin{array}{l} \text{Alors} \\ p(x|x) = 1 - (n-1)\varepsilon \\ \text{si } |y| = n. \end{array}$$

Théorème (Shannon, Canal bruyant) ⑦
Soit donné un canal avec bruit
(i.e. $p(y|x)$) et un $\delta > 0$. Pour tout
 $R < C^*$ (la capacité), il existe
un codage qui permet la
transmission de l'informa-
tion avec moins de δ proba
d'erreur.

Idee. Un canal avec bruit a
une capacité intrinsèque et
on doit chercher un code
adapté à ce canal pour
transmission fiable (avec
rendement maximum C^*).

* Si $X \neq \{0,1\}$ on doit normaliser
la capacité par $1/\log_2 |X|$.

Canal binaire symétrique sans

On va étudier un memoire
canal binaire ($X = \{0,1\}$)
symétrique sans memoire.

On suppose que X émet
des symboles successifs,
et que la proba $p(y|x)$ est

stationnaire, i.e. elle ne change pas avec le temps. (8)

$p(y x)$		0	1	= x
y	0	1-ε	ε	
	1	ε	1-ε	

Le canal est sans bruit si $\varepsilon=0$.

Défn. On pose

$$H(\varepsilon) = \varepsilon \log_2 \frac{1}{\varepsilon} + (1-\varepsilon) \log_2 \frac{1}{1-\varepsilon}.$$

On note que $H(\varepsilon)$ est l'entropie d'un ensemble

$X = \{0, 1\}$ avec $p(0) = \varepsilon$, $p(1) = 1-\varepsilon$.

Par symétrie on a

$$H(\varepsilon) = H(1-\varepsilon).$$

La capacité du canal bin, sym., sans mém., avec proba d'erreur ε est déterminée par

$$\begin{aligned} H(y|x) &= \varepsilon \log_2 \frac{1}{\varepsilon} + (1-\varepsilon) \log_2 \frac{1}{1-\varepsilon} \\ &= H(\varepsilon), \end{aligned}$$

alors

$$H(y|x) = \sum_{x \in X} p(x) H(\varepsilon) = H(\varepsilon),$$

et par conséquent, $H(y|x)$ est indépendant de la proba sur x . Alors on obtient le maximum de

$$I(x,y) = H(x) - H(x|y)$$

$$= 1 - H(x|y) = 1 - H(\epsilon)$$

pour la proba uniforme sur x .

Attention. Il faut établir que $H(x|y)$ est bien $H(\epsilon)$ pour ce maximum ou montrer que $H(y) \leq 1$, avec max quand $H(x) = 1$.

$$= H(y) - H(y|x) = H(y) - H(\epsilon)$$

Preuve

$$H(y) = p_y(0) \log_2(p_y(0)^{-1}) + p_y(1) \log_2(p_y(1)^{-1})$$

où

$$p_y(0) = p(0,0) + p(1,0)$$

$$= p_x(0) p(0|0) + p_x(1) p(1|0)$$

$$= p_x(0)(1-\epsilon) + p_x(1)\epsilon$$

$$= p_x(0) - \epsilon(p_x(0) - p_x(1))$$

$$= 1/2 \text{ si } p_x(0) = 1/2$$

Donc si la proba sur X est $\textcircled{10}$ uniforme, la proba sur Y est aussi uniforme. \square

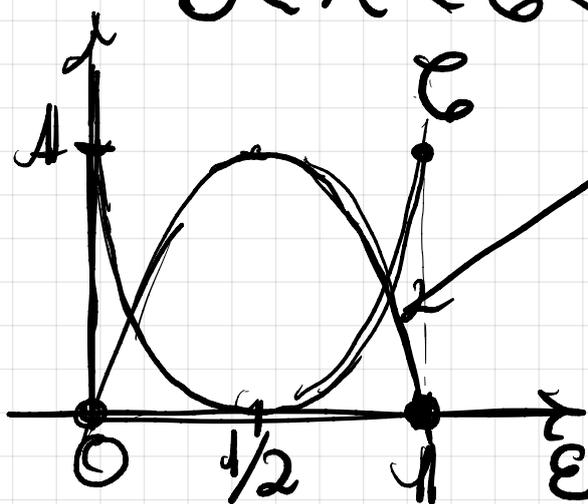
Alors la capacité du canal est $C = 1 - H(\epsilon)$.

Si $\epsilon = 1/2$, la capacité est zéro, i.e. on ne peut pas passer de l'information — l'info mutuelle entre $X = \text{mots trans}$ et $Y = \text{mots reçus}$ est 0.

Si $\epsilon = 0$, la capacité est 1.

Conclusion. Pour une capacité $C = 1 - H(\epsilon)$, $0 < C < 1$, on peut choisir un codage convenable avec rendement

$$0 < R < C < 1.$$



$$H(\epsilon) = \epsilon \log_2 \left(\frac{1}{\epsilon} \right) + (1 - \epsilon) \log_2 \left(\frac{1}{1 - \epsilon} \right)$$

Attention.

Un tel codage va regrouper des bits pour

transmettre de l'information 41
fiablement.

On va maintenant étudier les constructions explicites pour réaliser des bons codes.

Distance de Hamming et distance minimum

On va étudier des codes en blocs, $C \subseteq A^n$, pour un alphabet A . On va souvent prendre $A = \{0, 1\}$.

Déf La distance de Hamming est une fonction
 $d: A^n \times A^n \longrightarrow \mathbb{N}$

définie par

$$d(x, y) = |\{i : 1 \leq i \leq n, x_i \neq y_i\}|$$

où $x = x_1 \dots x_n$ et $y = y_1 \dots y_n$

La distance minimum d'un codage $C: X \longrightarrow A^n$ est

$$d(C) = \min \{d(x, y) : x \neq y \in C(X)\}$$

si C est sans pertes, sinon 0.

Pour $\mathcal{C} = \mathcal{C}(X) \subseteq A$, on définit (2)

$$d(\mathcal{C}) = \min \{ d(x, y) : x \neq y \in \mathcal{C} \}.$$

Defn la boule de rayon t
autour de $x \in A^n$ est

$$B(x, t) = \{ y \in A^n : d(x, y) \leq t \}.$$

La boule de rayon t autour
de $\mathcal{C} \subseteq A^n$ est

$$B(\mathcal{C}, t) = \bigcup_{x \in \mathcal{C}} B(x, t)$$

On va s'intéresser au codes
linéaires, où $A = \mathbb{F}_p$ est un
corps fini (par exemple
 $\mathbb{F}_p = \mathbb{Z}/p\mathbb{Z}$ pour p premier),
surtout pour $p=2$, on a

$\mathbb{F}_2 = \{0, 1\}$ (ensemble)
avec addition et mult:

+	0	1
0	0	1
1	1	0

•	0	1
0	0	0
1	0	1

+ = XOR

• = ET (AND)

$$\mathbb{F}_p = \{0, 1, \dots, p-1\}.$$

(13)

\oplus = la reste de la somme après division par p

$$x \oplus y = \begin{cases} x+y < p \\ x+y-p \text{ si il} \end{cases}$$

\odot = la reste après division par p du produit. dépasse $p-1$.

Ex. $p=7$

\dashv

Inverses:

\odot	0	1	2	3	4	5	6
0	0	0	0	0	0	0	0
1	0	1	2	3	4	5	6
2	0	2	4	6	1	3	5
3	0	3	6	2	5	1	4
4	0	4	1	5	2	6	3
5	0	5	3	4	6	4	2
6	0	6	5	4	3	2	1

On dit que $b = a^{-1}$ dans \mathbb{F}_p si $ab=1$.

Par exemple:

$$2 \cdot 4 = 1, \text{ et}$$

$$3 \cdot 5 = 1,$$

alors

$$4 = 2^{-1}, \text{ etc.}$$

On identifie $a \in \mathbb{F}_p$ avec n'importe quel élément, ou l'ensemble

$$a + p\mathbb{Z} = \{a + kp : k \in \mathbb{Z}\}.$$

Un code linéaire est un code $\mathcal{C} \subseteq A^n = \mathbb{F}_p^n$, où \mathcal{C} est un sous-espace vectoriel. (14)

Remarque \mathbb{F}_p^n est un espace vectoriel:

- $(0, \dots, 0) \in \mathbb{F}_p^n$ est le vecteur 0.
 - $(x_1, \dots, x_n) + (y_1, \dots, y_n) = (x_1 + y_1, \dots, x_n + y_n)$
 - $a(x_1, \dots, x_n) = (ax_1, \dots, ax_n)$
- où $a \in \mathbb{F}_p, (x_1, \dots, x_n) \in \mathbb{F}_p^n$.

Comme $a \in \mathbb{N}$, on peut définir

$$a(x_1, \dots, x_n) = \underbrace{(x_1, \dots, x_n) + \dots + (x_1, \dots, x_n)}$$

Pour $p=2$, a fois on a juste $a=0$ ou $a=1$:

$$0 \cdot (x_1, \dots, x_n) = (0, \dots, 0), \text{ et}$$

$$1 \cdot (x_1, \dots, x_n) = (x_1, \dots, x_n).$$

La distance de Hamming est linéaire (sur \mathbb{F}_p^n), alors

$$d(x, y) = d(x+z, y+z),$$

où $x = (x_1, \dots, x_n),$

$y = (y_1, \dots, y_n),$ et

$z = (z_1, \dots, z_n).$

Alors, si on met $z = -y,$ on voit que

$$d(x, y) = d(x-y, 0).$$

Donc si \mathcal{C} est linéaire

$$d(\mathcal{C}) = \min \{ d(x, 0) : \begin{matrix} x \neq 0 \\ x \in \mathcal{C} \end{matrix} \} \\ = \min \{ d(x, y) : \begin{matrix} x \neq y \\ x, y \in \mathcal{C} \end{matrix} \}.$$

car $x-y \in \mathcal{C} \quad \parallel \quad d(x-y, 0)$

Il suffit de tester $|\mathcal{C}|-1$ distances pour déterminer $d(\mathcal{C}),$ au lieu de $|\mathcal{C}|^2 - |\mathcal{C}|.$