

# Théorie de l'Information

Devoir # 2 (Résolution)

SIC-SICOM

Maria-João Rendas

1. Considérez une loi de probabilité d'une variable aléatoire  $X \in \mathcal{X}$ , où  $|\mathcal{X}| = m$ :  
 $p = [p_1, p_2, \dots, p_m]$ . Montrez que

$$H(p_1, p_2, \dots, p_m) = H(p_1 + p_2, p_3, \dots, p_m) + (p_1 + p_2) H\left(\frac{p_1}{p_1 + p_2}, \frac{p_2}{p_1 + p_2}\right).$$

Interprétez cette expression.

**résolution**

$$\begin{aligned} H(p) &= H(p_1, \dots, p_m) - (p_1 + p_2) \log(p_1 + p_2) + (p_1 + p_2) \log(p_1 + p_2) \\ &= H(p_1 + p_2, p_3, \dots, p_m) \\ &\quad - p_1 \log p_1 - p_2 \log p_2 + (p_1 + p_2) \log(p_1 + p_2) \\ &= H(p_1 + p_2, p_3, \dots, p_m) \\ &\quad + (p_1 + p_2) \left[ -\frac{p_1}{p_1 + p_2} \log p_1 - \frac{p_2}{p_1 + p_2} \log p_2 + \frac{p_1 + p_2}{p_1 + p_2} \log(p_1 + p_2) \right] \\ &= H(p_1 + p_2, p_3, \dots, p_m) \\ &\quad + (p_1 + p_2) \left[ -\frac{p_1}{p_1 + p_2} \log \frac{p_1}{p_1 + p_2} - \frac{p_2}{p_1 + p_2} \log \frac{p_2}{p_1 + p_2} \right] \\ &= H(p_1 + p_2, p_3, \dots, p_m) \\ &\quad + (p_1 + p_2) H\left(\frac{p_1}{p_1 + p_2}, \frac{p_2}{p_1 + p_2}\right). \end{aligned}$$

Cette relation peut être interprétée de la façon suivante: la quantité d'information fournie par une expérience qui peut avoir  $m$  résultats distincts est égale à la quantité d'information obtenue dans une expérience composée, en deux étapes:

- (a) dans la première étape, les deux premiers résultats, que nous notons  $x_1, x_2$  ne sont pas discernés (ils sont confondus dans un événement  $x' = x_1 \cup x_2$  dont la probabilité est  $p_1 + p_2$ ). La quantité d'information dans chaque expérience de cette nouvelle variable est  $H(p_1 + p_2, p_3, \dots, p_m)$ .
- (b) Si le résultat de la première expérience est  $x'$ , alors une deuxième variable aléatoire nous identifie lequel des deux événements ( $x_1$  ou  $x_2$ ) s'est

effectivement produit. La loi de probabilité du résultat de cette deuxième variable est

$$q = p(x|x') = \left[ \frac{p_1}{p+1+p_2}, \frac{p_2}{p+1+p_2} \right].$$

La quantité d'information totale est la somme de la quantité d'information associée à la première expérience,  $H(p_1 + p_2, p_3, \dots, p_m)$ , plus la quantité d'information moyenne de la deuxième expérience, qui est égale à 0 avec probabilité  $1 - p_1 - p_2$ , et égale à  $H(q)$  avec probabilité  $p_1 + p_2$ , c'est à dire,

$$H(p) = H(p_1 + p_2, p_3, \dots, p_m) + (p_1 + p_2)H(q).$$

2. La définition suivante précise la relation de dispersion plus ou moins élevée des composantes d'un vecteur.

**Définition 1** Majoration

Soit  $x, y \in R^n$  et nottons

$$x_{[1]}, \dots, x_{[n]}$$

le vecteur obtenu en ordonnant les composantes de  $x$  par ordre décroissante. On dira que  $x$  est majoré par  $y$  si

$$\sum_{i=1}^k x_{[i]} \leq \sum_{i=1}^k y_{[i]}, \quad k = 1, \dots, n-1,$$

et

$$\sum_{i=1}^n x_{[i]} = \sum_{i=1}^n y_{[i]}.$$

Montrez que pour toute loi de probabilité  $p = [p_1, \dots, p_n]$ ,

$$p \text{ majore } \left[ \frac{1}{n}, \frac{1}{n}, \dots, \frac{1}{n} \right].$$

**résolution**

La deuxième condition est trivialement vérifiée pour des lois de probabilité, qui doivent avoir une somme égale à 1. Nous nous concentrons alors dans la vérification de

$$\sum_{i=1}^k \frac{1}{n} = \frac{k}{n} \leq \sum_{i=1}^k p_{[i]}, \quad k = 1, \dots, n-1 \quad (1)$$

où nous avons considéré déjà la loi uniforme.

Pour simplifier la présentation, nous allons admettre que la loi  $p$  est ordonnée, de façon que

$$p_i = p_{[i]}, \quad i = 1, \dots, n.$$

Si nous définissons

$$S_k = \sum_{i=1}^k p_i - \frac{k}{n},$$

la condition (1) est équivalente à

$$S_k \geq 0, \quad k = 1, \dots, n-1.$$

Comme  $p$  est une loi de probabilité

$$1 = \sum_{i=1}^k p_i + \sum_{i \geq k+1} p_i \stackrel{(a)}{\leq} \sum_{i=1}^k p_i + (n-k)p_{k+1}$$

où en (a) nous avons utilisé le fait que

$$i \geq k+1 \Rightarrow p_i \leq p_{k+1},$$

car la loi  $p$  est "ordonnée". Nous pouvons donc écrire

$$\begin{aligned} 1 &= \frac{k}{n} + \frac{n-k}{n} \leq \sum_{i=1}^k p_i + (n-k)p_{k+1} \\ \Rightarrow \frac{n-k}{n} - (n-k)p_{k+1} &\leq \sum_{i=1}^k p_i - \frac{k}{n} = S_k \\ \Rightarrow p_{k+1} - \frac{1}{n} &\geq -\frac{S_k}{n-k}. \end{aligned}$$

Comme la séquence  $S_k$  satisfait la récursion

$$S_{k+1} = S_k + p_{k+1} - \frac{1}{n}, \quad k = 1, \dots, n-1,$$

nous pouvons conclure

$$S_{k+1} \geq S_k - \frac{S_k}{n-k} = S_k \frac{n-k-1}{n}.$$

Pour  $k \leq n-1$  le facteur qui multiplie  $S_k$  dans cette inégalité est toujours positif et donc  $S_{k+1}$  doit avoir le même signe que  $S_k$ . Si  $S_1 \geq 0$ , nous pouvons alors garantir que  $S_k \geq 0, k = 1, \dots, k-1$ . La preuve que  $S_1$  est positif est obtenue directement du fait que la somme de  $p$  est unitaire, et que  $p_1$  est le plus grand élément de  $p$ :

$$1 = \sum_{i=1}^n p_i \leq np_1 \Rightarrow p_1 \geq \frac{1}{n} \Rightarrow S_1 \geq 0.$$

3. Soit  $p$  une loi de probabilité dans le simplexe probabiliste de dimension  $n$ , telle que

$$p_1 \geq p_2 \geq \dots \geq p_n.$$

Montrez que

$$H(p_1 - \delta, p_2 + \delta, p_3, \dots, p_n) \geq H(p).$$

**résolution**

Considérons que

$$0 \leq \delta \leq \frac{p_1 - p_2}{2} \Leftrightarrow p_1 - \delta \geq p_2 + \delta. \quad (2)$$

Sous cette condition,

$$p_1 - \delta \geq p_2 + \delta \geq p_2,$$

et il est immédiat de vérifier que la loi ordonnée

$$p^{(a)} = [p_1 - \delta, p_2 + \delta, p_3, \dots, p_n]$$

est majorée par  $p$ :

$$\sum_{i=1}^k p_i \geq \sum_{i=1}^k p_i^{(a)}, k = 1, \dots, n-1, \quad \sum_{i=1}^n p_i \geq \sum_{i=1}^n p_i^{(a)}$$

La deuxième égalité est nécessairement vérifiée, du fait que  $p$  et  $p^{(a)}$  sont des lois de probabilité. Pour  $k = 1$ , car  $\delta \geq 0$ ,

$$p_1 \geq p_1 - \delta = p_1^{(a)}$$

Pour  $k \geq 2$

$$\begin{aligned} \sum_{i=1}^k p_i &= p_1 + p_2 + \sum_{i=3}^k p_i = p_1 - \delta + p_2 + \delta + \sum_{i=3}^k p_i \\ &= p_1^{(a)} + p_2^{(a)} + \sum_{i=3}^k p_i^{(a)} = \sum_{i=1}^k p_i^{(a)}. \end{aligned}$$

Nous pouvons utiliser le fait que  $H(\cdot)$  est une fonction Schur-concave pour affirmer que

$$p \text{ majore } p^{(a)} \Rightarrow H(p^{(a)}) \geq H(p).$$

Ce résultat est vrai pour  $\delta$  dans l'intervalle de l'équation (2), de façon que  $p^{(a)}$  soit effectivement une loi ordonnée. Il suffit de voir que pour le cas extrême où  $\delta = p_1 > (p_1 + p_2)/2$ , et donc  $p_1^{(a)} = 0$ , l'entropie sera nécessairement inférieure :

$$H(p) = H(p^{(a)}) + (p_1 + p_2)H\left(\frac{p_1}{p_1 + p_2}, \frac{p_2}{p_1 + p_2}\right) \geq H(p^{(a)}).$$

4. Montrez que

$$H\left(\sum_{i=1}^k p_i, 1 - \sum_{i=1}^k p_i\right) \leq H(p).$$

Interprétez en termes des partitions de  $\Omega$  correspondantes aux deux lois de probabilité,  $p$  et  $\left(\sum_{i=1}^k p_i, 1 - \sum_{i=1}^k p_i\right)$ .

Sous quelle condition peut-on avoir égalité ?

**résolution**

Soit  $X \sim p$  une variable aléatoire qui suit la loi  $p$  (et qui a donc entropie  $H(X) = H(p)$ ). Soit  $\mathcal{X} = \{a_1, \dots, a_n\}$  l'ensemble où  $X$  prend ses valeurs, avec  $n > k$ . Considérez la variable aléatoire binaire  $Y$  définie à partir de  $X$  de la façon suivante:

$$Y = \begin{cases} 1, & X \in \{a_1, \dots, a_k\} \\ 0, & x \in \{a_{k+1}, \dots, a_n\} \end{cases}$$

Avec cette définition

$$q_1 = \Pr\{Y = 1\} = \sum_{i=1}^k p_k, \quad q_0 = \Pr\{Y = 0\} = 1 - q_1.$$

Donc, l'entropie indiquée dans le problème est l'entropie de  $Y$ :

$$H\left(\sum_{i=1}^k p_i, 1 - \sum_{i=1}^k p_i\right) = H(Y).$$

Comme  $Y = f(X)$

$$H(X, Y) = H(X) = H(p).$$

Mais, pas la règle de la chaîne pour l'entropie,

$$H(X, Y) = H(Y) + H(Y|X) \leq H(Y).$$

De ces deux inégalités nous concluons directement

$$H(Y) \leq H(p).$$

La résolution fourni directement l'interprétation demandée en termes des partitions de  $\Omega$  correspondante aux variables aléatoires  $X$  et  $Y$  : La partition correspondante à  $X$  est un raffinement de celle correspondante à  $Y$ , et donc elle doit conduire à une variable aléatoire avec un eplus grande entropie.

5. Montrez que

$$H(X, Y|Z) \leq H(X|Z) + H(Y|Z).$$

Sous quelle condition on observera l'égalité ?

**résolution**

Par la règle de la chaîne

$$H(X, Y|Z) = H(X|Z) + H(Y|X, Z) \leq H(X|Z) + H(Y|Z).$$

où l'inégalité découle du fait que le conditionnement réduit l'entropie, et donc

$$H(Y|X, Z) \leq H(Y|Z).$$

Nous aurons égalité quand, sachant  $Z$ ,  $Y$  est indépendante de  $X$  :

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

Par exemple, si  $X = S_{n-1}$ ;  $Z = S_n$  et  $Y = S_{n+1}$  et  $S_n$  est un processus de Markov d'ordre 1, nous aurons égalité:

$$H(S_{n-1}, S_{n+1}|S_n) = H(S_{n-1}|S_n) + H(S_{n+1}|S_n)$$

qui montre bien le rôle de  $X_n$  comme "cut set" entre le futur  $S_i, i > n$  et le passé  $S_i, i < n$ .

6. Montrez que l'information mutuelle  $I(X; Y)$  est

- (a) Une fonction concave de  $p_X$ .
- (b) Une fonction convexe de  $p_{Y|X}$ .

**résolution**

- (a) Nous voulons montrer que pour  $p(y|x)$  fixé,  $I$  est une fonction concave de  $p(x)$  :

$$I(\lambda p_1(x) + (1-\lambda)p_2(x); p(y|x)) \geq \lambda I(p_1(x); p(y|x)) + (1-\lambda)I(p_2(x); p(y|x)).$$

Nous savons que

$$I(X; Y) = H(Y) - H(Y|X).$$

Soit

$$p_\lambda(x) = \lambda p_1(x) + (1-\lambda)p_2(x)$$

Alors, pour une loi conditionnelle fixée,  $p(y|x)$ ,

$$\begin{aligned} p_\lambda(y) &= \sum_y p(y|x)p_\lambda(x) \\ &= \lambda \sum_y p(y|x)p_1(x) + (1-\lambda) \sum_y p(y|x)p_2(x) \\ &= \lambda p_1(y) + (1-\lambda)p_2(y) \end{aligned}$$

où les définitions de  $p_1(y)$  et  $p_2(y)$  sont évidentes. Alors,

$$H_\lambda(Y) = H(p_\lambda(y)) = H(\lambda p_1(y) + (1-\lambda)p_2(y))$$


qui est une fonction concave de  $\lambda$  (Propriété 19 dans la première partie des notes).

Le deuxième terme est, par définition d'entropie conditionnelle :

$$H_\lambda(Y|x) = - \sum_x p_\lambda(x) \sum_y p(y|x) \log p(y|x)$$

et donc il est une fonction linéaire de  $p_\lambda$  pour  $p(y|x)$  fixé. Nous avons donc la somme d'une fonction linéaire avec une fonction concave, qui doit être nécessairement concave.

- (b) Pour démontrer la convexité de  $I$  comme fonction de la loi conditionnelle  $p(y|x)$  pour  $p(x)$  fixé, nous allons considérer le schéma de la figure suivante



Soit  $Z$  la variable (indépendante de  $X$ ) qui indique la position de l'interrupteur, de façon que

$$Pr\{Z = Y_1\} = \lambda \quad Pr\{Z = Y_2\} = 1 - \lambda$$

Alors,

$$\begin{aligned} I(X; Y, Z) &= I(X; Y|Z) + I(X; Z) \\ &= I(X; Z|Y) + I(X; Y) \end{aligned}$$

Mais  $I(X; Z) = 0$  - car  $Z$  est statistiquement indépendant de  $X$  - et donc nous pouvons conclure que

$$I(X; Z|Y) + I(X; Y) = I(X; Y|Z) \Rightarrow I(X; Y) = I(X; Y|Z) - I(X; Z|Y) \leq I(X; Y|Z)$$

Mais, par la définition de  $Z$

$$I(X; Y|Z) = \lambda I(X, Y_1) + (1 - \lambda) I(X, Y_2)$$

Nous venons donc de montrer que

$$I(p(x); \lambda p_1(y|x) + (1-\lambda)p_2(y|x)) \leq \lambda I(p(x); p_1(y|x)) + (1-\lambda) I(p(x); p_2(y|x))$$

c'est à dire, que  $I$  est une fonction convexe de  $p(y|x)$  pour  $p(x)$  fixé.

7. Cet exercice généralise l'information mutuelle à des groupes de variables. Il introduit en particulier la notion d'information mutuelle entre deux variables  $X$  et  $Y$ , conditionnée dans une troisième variable  $Z$ , et l'information mutuelle entre une collection de variables  $(X, Y)$  et une autre variable  $Z$ :

$$\begin{aligned} I(X; Y|Z) &= E_X \{D(p(x, y|z)||p(x|z)p(y|z))\} \\ I(X, Y; Z) &= D(p(x, y, z)||p(x, y)p(z)), \end{aligned}$$

où  $D(\cdot||\cdot)$  est l'entropie relative entre deux lois de probabilité, introduite en cours.  $I(X; Y|Z)$  est l'information mutuelle entre  $X$  et  $Y$  sachant  $Z$ , et  $I(X, Y; Z)$  est l'information mutuelle entre le vecteur  $(X, Y)$  et  $Z$ .

Montrez que les décompositions suivante sont vraies :

$$I(X; Z) + I(X; Y|Z) = I(X; Y) + I(X; Z|Y) = I(X; Y, Z).$$

### **résolution**

En utilisant les définitions

$$\begin{aligned} I(X; Z) + I(X; Y|Z) &= \sum_{x,z} p(x, z) \log \frac{p(x, z)}{p(x)p(z)} + \sum_z p(z) \sum_{x,y} p(x, y|z) \log \frac{p(x, y|z)}{p(x|z)p(y|z)} \\ &\stackrel{(a)}{=} \sum_{x,z} \sum_y p(x, y, z) \log \frac{p(x, z)}{p(x)p(z)} + \sum_{x,y,z} p(x, y, z) \log \frac{p(x, y|z)}{p(x|z)p(y|z)} \\ &= \sum_{x,y,z} p(x, y, z) \left[ \log \frac{p(x, z)}{p(x)p(z)} + \log \frac{p(x, y|z)}{p(x|z)p(y|z)} \right] \\ &= \sum_{x,y,z} p(x, y, z) \log \frac{p(x, z)p(x, y|z)}{p(x)p(z)p(x|z)p(y|z)} \\ &\stackrel{(b)}{=} \sum_{x,y,z} p(x, y, z) \log \frac{p(x, y|z)}{p(x)p(y|z)} \\ &= \sum_{x,y,z} p(x, y, z) \log \frac{p(x, y|z)p(z)}{p(x)p(y|z)p(z)} \\ &\stackrel{(c)}{=} \sum_{x,y,z} p(x, y, z) \log \frac{p(x, y, z)}{p(x)p(y, z)} \\ &= E_{x,y,z} \left[ \log \frac{p(x, y, z)}{p(x)p(y, z)} \right] = I((X; Y, Z)). \end{aligned}$$

où les différents pas ont les justifications suivantes:

$$(a) : p(x, z) = \sum_y p(x, y, z),$$

$$(b) : p(z)p(x|z) = p(x, z).$$

$$(c) : p(x, y|z)p(z) = p(x, y, z), p(y|z)p(z) = p(y, z).$$



8. Considérez les définitions de l'exercice précédent. Montrez que si  $X$  et  $Y$  sont statistiquement indépendantes sachant  $Z$ , alors

$$I(X; Z) \geq I(X; Z|Y).$$

Interprétez.

**résolution**

Le fait que  $X$  et  $Y$  sont statistiquement indépendants sachant  $Z$  implique que

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

De la définition d'information mutuelle :

$$\begin{aligned} I(X; Z) &= \sum_{x,z} p(x, z) \log \frac{p(x, z)}{p(x)p(z)} \\ &= \sum_{x,y,z} p(x, y, z) \log \frac{p(x, z)p(y|z)}{p(x)p(z)p(y|z)} \\ &= \sum_{x,y,z} p(x, y, z) \log \frac{p(x|z)p(z)p(y|z)}{p(x)p(z)p(y|z)} \\ &= \sum_{x,y,z} p(x, y, z) \log \frac{p(x|z)p(y|z)}{p(x)p(y|z)} \\ &= \sum_{x,y,z} p(x, y, z) \log \frac{p(x, y|z)}{p(x)p(y|z)} \\ &\stackrel{(a)}{\leq} \sum_{x,y,z} p(x, y, z) \log \frac{p(x, y|z)}{p(x|z)p(y|z)} = I(X; Y|Z). \end{aligned}$$

où en (a) nous avons utilisé le fait que  $\forall z$

$$p(x) \geq p(x|z) \Rightarrow \frac{1}{p(x)} \leq \frac{1}{p(x|z)} \Rightarrow \log \frac{1}{p(x)} \leq \log \frac{1}{p(x|z)}.$$