
L'entropie en probabilité, approche élémentaire. Une correction.

Préliminaire.

- On a $\lim_{x \rightarrow 0^+} x \ln x = 0 = h(0)$ (par croissances comparées). Puis h est continue sur $]0, +\infty[$ (par exemple comme produit de fonctions continues sur cet intervalle). Ainsi h est continue sur \mathbb{R}^+ .
 - Si $x > 0$, on a : $\frac{h(x) - h(0)}{x} = \ln x \xrightarrow{x \rightarrow 0} -\infty$. Il en résulte que h n'est pas dérivable en 0 (mais son graphe admet une tangente « verticale » au point d'abscisse 0).
 - Les antécédents de 0 par h sont 0 et 1.
- La fonction \ln a une dérivée seconde strictement négative sur $]0, +\infty[$: c'est donc une fonction **strictement** concave. Son graphe est donc situé au dessous de ses tangentes et ne rencontre ces droites qu'au point de tangence. Comme $y = x - 1$ est l'équation de la tangente au graphe du logarithme naturel au point d'abscisse 1, on peut conclure que, pour tout $x > 0$, on a $\ln x \leq x - 1$ avec égalité si et seulement si $x = 1$.

Autre idée. Etudier la fonction $x \mapsto x - 1 - \ln x \dots$

Partie 1. Exemples.

3. On a $H(U_n) = - \sum_{i=1}^n \frac{1}{n} \ln \frac{1}{n} = \ln n$.

4. Notons $X(\Omega) = \{x_1, \dots, x_n\}$.

- Si X est presque sûrement constante, il existe $i_0 \in \{1, \dots, n\}$ tel que $P(X = x_{i_0}) = 1$. On a alors $P(X = x_i) = 0$ pour tout $i \neq i_0$ dans $\{1, \dots, n\}$ et l'entropie de X est alors :

$$H(X) = - \sum_{i=1}^n h(P(X = x_i)) = -h(1) = 0.$$

- Réciproquement, supposons $H(X) = 0$. Ainsi $\sum_{i=1}^n h(P(X = x_i)) = 0$. Chaque $P(X = x_i)$ est dans $[0, 1]$, donc chaque $h(P(X = x_i))$ est négatif. Il en résulte que :

$$h(P(X = x_i)) = 0 \text{ pour tout } i \text{ dans } \{1, \dots, n\}.$$

Ainsi, pour i dans $\{1, \dots, n\}$, on a $P(X = x_i) \in h^{-1}(0)$. Mais 0 a deux antécédents par h qui sont 1 et 0. On ne peut avoir $P(X = x_i) = 0$ pour tout i dans $\{1, \dots, n\}$: il existe donc i_0 dans $\{1, \dots, n\}$ tel que $P(X = x_{i_0}) = 1$.

Conclusion. $H(X) = 0$ si et seulement si X est presque sûrement constante.

5. • La fonction g est continue sur $[0, 1]$ et dérivable au moins sur $]0, 1[$ par composition. Pour $x \in]0, 1[$,

$$g'(x) = -h'(x) + h'(1-x) = -(\ln(x) + 1) + (\ln(1-x) + 1) = \ln\left(\frac{1-x}{x}\right)$$

Ainsi, pour $x \in]0, 1[$, on a : $g'(x) \geq 0 \Leftrightarrow \frac{1-x}{x} \geq 1 \Leftrightarrow \frac{1}{2} \geq x$, avec égalité si et seulement si $x = \frac{1}{2}$.
On peut alors sans peine établir le tableau de variation de g en précisant que $g(0) = g(1) = 0$ et que $g(\frac{1}{2}) = \ln 2$ est un **maximum global strict** de g .

• On a $P(X=1) = p, P(X=0) = 1-p$ donc $H(X) = -h(p) - h(1-p) = g(p) \leq \ln 2$ avec égalité si, et seulement si, $p = \frac{1}{2}$.

6. On a $(Z=1) = (\ll X_1 + X_2 \text{ est impair} \gg) = [(X_1=1) \cap (X_2=0)] \cup [(X_1=0) \cap (X_2=1)]$. Ainsi (**union disjointe**) :

$$p = P(Z=1) = P((X_1=1) \cap (X_2=0)) + P(X_1=0) \cap (X_2=1)$$

Puis, par **indépendance**, de X_1 et X_2 :

$$p = P(X_1=1)P(X_2=0) + P(X_1=0)P(X_2=1) = p_1(1-p_2) + (1-p_1)p_2.$$

Remarque. On peut aussi rédiger avec la formule des probabilités totales et le système complet $((X_1=1), (X_1=0))$.

Conclusion. $p = P(Z=1) = p_1 + p_2 - 2p_1p_2, \quad \mathbb{E}(Z) = p, \quad (1-2p) = (1-2p_1)(1-2p_2)$.

7. Le cas $n=1$ est évident. Soit $n \in \mathbb{N}^*$, on suppose le résultat au rang n .

Soit X qui suit $\mathcal{B}(n+1, p)$.

On sait que X est la somme de variables de Bernoulli indépendantes X_1, X_2, \dots, X_{n+1} de paramètre p , on peut écrire $X = X_1 + X_2 + \dots + X_{n+1} = X_1 + Y$ où Y est une variable qui suit $\mathcal{B}(n, p)$.

Soit Z_n et Z_{n+1} les variables de Bernoulli telle que $P(Z_n=1) = P(\ll Y \text{ est impair} \gg)$ et $P(Z_{n+1}=1) = P(\ll X \text{ est impair} \gg)$.

On a ainsi $(Z_{n+1}=1) = (\ll X_1 + Z_n \text{ est impair} \gg)$.

Or Z_n et X_1 sont indépendantes ; la question précédente et l'hypothèse de récurrence donnent :

$$1 - 2P(Z_{n+1}=1) = (1-2p)(1-2P(Z_n=1)) = (1-2p)(1-2p)^n = (1-2p)^{n+1}$$

D'où le résultat par récurrence.

On a **d'après I.1c** : $H(Z_n) \leq \ln 2$ et égalité si et seulement si $P(Z_n=1) = \frac{1}{2}$ c'est-à-dire $(1-2p)^n = 0, \quad H(Z_n) = \ln 2$ si et seulement si $p = 1/2$.

Partie 2. Propriétés de l'entropie.

8. On a $m = E(X_0) = \frac{1}{p}$. Soit $k \in \mathbb{N}^*$. On a $p_k = P(G=k) = (1-p)^{k-1}p$ donc :

$$h(p_k) = p_k \ln(p_k) = \ln(p)p_k - (k-1) \ln(1-p)p_k.$$

Les séries $\sum_{k \geq 1} p_k$ et $\sum_{k \geq 1} k p_k$ étant convergentes d'après le cours, de sommes respectives 1 et $\mathbb{E}(X_0) = \frac{1}{p}$, $H(X_0)$ existe et :

$$\begin{aligned} H(X_0) &= -\ln(p) \sum_{k=1}^{+\infty} p_k - \ln(1-p) \sum_{k=1}^{+\infty} (k-1)p_k = -\ln(p) - \ln(1-p) (\mathbb{E}(X_0) - 1) \\ &= -\ln(p) - \ln(1-p) \left(\frac{1}{p} - 1 \right) \end{aligned}$$

Conclusion.
$$H(X_0) = - \left[\ln(p) + \ln(1-p) \left(\frac{1}{p} - 1 \right) \right].$$

9. Soit k dans \mathbb{N}^* . On a : $q_k \ln p_k = q_k [(k-1) \ln(1-p) + \ln p] = q_k \ln p + k q_k \ln(1-p) - q_k \ln(1-p)$. Or la série $\sum_{k \geq 1} q_k$ converge de somme 1 et la série $\sum_{k \geq 1} k q_k$ converge de somme $\mathbb{E}(X)$. Ainsi $\sum_{k \geq 1} q_k \ln(p_k)$ est convergente et :

$$- \sum_{k=1}^{+\infty} q_k \ln(p_k) = -\ln(p) - \ln(1-p) \mathbb{E}(X) + \ln(1-p) = H(X_0),$$

puisque $\mathbb{E}(X_0) = \mathbb{E}(X) = \frac{1}{p}$.

Conclusion.
$$H(X_0) = - \sum_{k=1}^{+\infty} q_k \ln(p_k).$$

10. • Soit $k \in \mathbb{N}^*$. La question 2 du préliminaire appliquée à $x = \frac{p_k}{q_k} > 0$ donne :

$$\ln(p_k) - \ln(q_k) = \ln \frac{p_k}{q_k} \leq \frac{p_k}{q_k} - 1.$$

On multiplie par q_k pour obtenir :

$$\boxed{-h(q_k) + q_k \ln(p_k) \leq p_k - q_k}.$$

• Par somme, (les séries sont convergentes) :

$$H(X) - X(X_0) \leq \sum_{k=1}^{+\infty} p_k - \sum_{k=1}^{+\infty} q_k = 1 - 1 = 0.$$

Conclusion.
$$H(X) \leq H(X_0).$$

11. Si $H(X) = H(X_0)$ alors on a :

$$H(X) - H(X_0) - \sum_{k=1}^{+\infty} p_k - \sum_{k=1}^{+\infty} q_k = 0$$

donc, selon la question précédente, $\sum_{k=0}^{+\infty} \underbrace{-h(q_k) + q_k \ln(p_k)}_{\leq 0} \leq p_k - q_k = 0$. Il en résulte que, pour

tout $k \in \mathbb{N}^*$,

$$\boxed{-h(q_k) + q_k \ln(p_k) = p_k - q_k}.$$

Ainsi $\ln \frac{p_k}{q_k} = \frac{p_k}{q_k} - 1$ donc $\frac{p_k}{q_k} = 1$ (préliminaire...).

Conclusion.
$$\boxed{\text{Si } H(X) = H(X_0) \text{ alors } X \text{ suit la même loi que } X_0}.$$

Partie 3. Entropie d'un couple.

12. Propriétés de l'information entre deux couples

a. La famille $([X = i] \cap [Y = j])_{(i,j) \in I_n \times I_m}$ forme un système complet d'événements. Il en résulte

que $\sum_{i=1}^n \sum_{j=1}^m \lambda_{i,j} = 1$. De même $\sum_{i=1}^n \sum_{j=1}^m \mu_{i,j} = 1$.

b. On a :

$$\begin{aligned} - \sum_{i=1}^n \sum_{j=1}^m \lambda_{i,j} \left(\ln \frac{\mu_{i,j}}{\lambda_{i,j}} - \frac{\mu_{i,j}}{\lambda_{i,j}} + 1 \right) &= - \sum_{i=1}^n \sum_{j=1}^m \lambda_{i,j} \ln \frac{\mu_{i,j}}{\lambda_{i,j}} + \underbrace{\sum_{i=1}^n \sum_{j=1}^m \mu_{i,j}}_{=1} - \underbrace{\sum_{i=1}^n \sum_{j=1}^m \lambda_{i,j}}_{=1} \\ &= K(X, Y, X', Y') \end{aligned}$$

Conclusion. $K(X, Y, X', Y') = - \sum_{i=1}^n \sum_{j=1}^m \lambda_{i,j} \left(\ln \frac{\mu_{i,j}}{\lambda_{i,j}} - \frac{\mu_{i,j}}{\lambda_{i,j}} + 1 \right)$.

c. Pour tout $x > 0$, on a vu que $\ln x \leq x - 1$. Il en résulte que, pour tout $(i, j) \in I_n \times I_m$, puisque chaque $\frac{\mu_{i,j}}{\lambda_{i,j}}$ est strictement positif, on a :

$$\ln \frac{\mu_{i,j}}{\lambda_{i,j}} - \frac{\mu_{i,j}}{\lambda_{i,j}} + 1 \leq 0.$$

Comme $\lambda_{i,j} > 0$, pour tout $(i, j) \in I_n \times I_m$, l'expression de la question précédente permet d'affirmer que $K(X, Y, X', Y') \geq 0$.

d. • Supposons que les couples (X, Y) et (X', Y') ont même loi conjointe. On a alors $\lambda_{i,j} = \mu_{i,j}$ pour tout $(i, j) \in I_n \times I_m$. Il en résulte que $K(X, Y, X', Y') = 0$.

• Réciproquement, supposons que $K(X, Y, X', Y') = 0$. Pour tout $(i, j) \in I_n \times I_m$, on a vu que :

$$-\lambda_{i,j} \left(\ln \frac{\mu_{i,j}}{\lambda_{i,j}} - \frac{\mu_{i,j}}{\lambda_{i,j}} + 1 \right) \geq 0.$$

Ainsi, $K(X, Y, X', Y')$ est une somme de termes positifs qui est nulle : chacun des termes de la somme est nul. Il en résulte que, pour tout $(i, j) \in I_n \times I_m$, on a

$$\ln \frac{\mu_{i,j}}{\lambda_{i,j}} - \frac{\mu_{i,j}}{\lambda_{i,j}} + 1 = 0.$$

La question 2 du préliminaire nous affirme alors que $\frac{\mu_{i,j}}{\lambda_{i,j}} = 1$ pour tout $(i, j) \in I_n \times I_m$: les couples (X, Y) et (X', Y') ont même loi conjointe.

Conclusion. $K(X, Y, X', Y') = 0$ si et seulement si les couples (X, Y) et (X', Y') ont même loi conjointe.

e. i. D'après les hypothèses, X' et Y' sont indépendantes, de même loi que X et Y respectivement. Ainsi, pour tout $(i, j) \in I_n \times I_m$, on a :

$$\mu_{i,j} = p_i q_j.$$

Il vient alors :

$$\begin{aligned}
K(X, Y, X', Y') &= - \sum_{i=1}^n \sum_{j=1}^m \lambda_{i,j} \ln \frac{\mu_{i,j}}{\lambda_{i,j}} = - \sum_{i=1}^n \sum_{j=1}^m \lambda_{i,j} (\ln \mu_{i,j} - \ln \lambda_{i,j}) \\
&= - \sum_{i=1}^n \sum_{j=1}^m \lambda_{i,j} (\ln p_i + \ln q_j) + \underbrace{\sum_{i=1}^n \sum_{j=1}^m \lambda_{i,j} \ln \lambda_{i,j}}_{=H(X,Y)} \\
&= - \sum_{i=1}^n \left(\sum_{j=1}^m \lambda_{i,j} \right) \ln p_i - \sum_{j=1}^m \left(\sum_{i=1}^n \lambda_{i,j} \right) \ln q_j + H(X, Y)
\end{aligned}$$

Or la famille $([X = i])_{1 \leq i \leq n}$ forme un système complet d'événements, ce qui implique que, pour tout j dans I_m , on a :

$$\sum_{i=1}^n \lambda_{i,j} = \sum_{i=1}^n P(X = i, Y = j) = P(Y = j) = q_j.$$

De même, $\sum_{j=1}^m \lambda_{i,j} = p_i$, pour tout i dans I_n . Il en résulte que :

$$K(X, Y, X', Y') = \underbrace{- \sum_{i=1}^n p_i \ln p_i}_{=H(X)} + \underbrace{\left(- \sum_{j=1}^m q_j \ln q_j \right)}_{H(Y)} + H(X, Y)$$

Conclusion. $\boxed{K(X, Y, X', Y') = H(X) + H(Y) - H(X, Y)}$.

ii. On a : $H(X, Y) - H(X) + H(Y) = -K(X, Y, X', Y') \leq 0$ d'après la question III.1c.

Ainsi $\boxed{H(X, Y) \leq H(X) + H(Y)}$ (♣).

Cette inégalité est une égalité si et seulement si $K(X, Y, X', Y') = 0$ i.e. si et seulement si $\boxed{\text{les couples } (X, Y) \text{ et } (X', Y') \text{ ont même loi conjointe}}$.

13. Entropie conditionnelle

a. D'après la question III.2e.ii, on a :

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

Conclusion. $\boxed{H(Y | X) \leq H(Y)}$.

b. • Pour tout i dans I_m on a : $\ln a_i \leq \ln(a_1 + \dots + a_m)$. Il en résulte que, pour tout i dans I_n , on a :

$$h(a_i) \leq a_i \ln(a_1 + \dots + a_m).$$

Par somme membre à membre, on obtient :

$$\sum_{i=1}^m h(a_i) \leq \sum_{i=1}^m a_i \ln(a_1 + \dots + a_m) = \ln(a_1 + \dots + a_m) \sum_{i=1}^m a_i = h\left(\sum_{i=1}^m a_i\right).$$

Conclusion. $\boxed{\sum_{i=1}^m h(a_i) \leq h\left(\sum_{i=1}^m a_i\right)}$ (♠).

- Si tous les a_i sont nuls, (\spadesuit) est encore vraie de manière évidente (les deux membres valent 0). Si l'un des a_i est non nul, on a encore, pour tout i dans I_n , l'inégalité :

$$h(a_i) \leq a_i \ln(a_1 + \dots + a_m).$$

Ainsi (\spadesuit) est encore vraie si a_1, \dots, a_m sont dans $[0, 1]$.

- Supposons qu'il existe deux indices i dans I_n tels que $a_i \neq 0$. Par exemple $a_1 > 0$ et $a_2 > 0$. On a alors :

$$\ln(a_1) < \ln(a_1 + \dots + a_m).$$

Ainsi (\spadesuit) est une inégalité stricte.

Si maintenant tous les a_i sont nuls, on a vu que (\spadesuit) est une égalité. Enfin, supposons, par exemple, que $a_1 > 0$ et que tous les autres a_i sont nuls. On a cette fois :

$$h(a_i) = a_i \ln(a_1 + \dots + a_m)$$

pour tout i dans I_m : (\spadesuit) est une égalité.

Conclusion. Il y a égalité dans (\spadesuit) si et seulement s'il existe au plus un indice i dans I_m tel que $a_i \neq 0$.

- c. • Soit i dans I_n . Selon la question précédente, on a :

$$\sum_{j=1}^m h(\lambda_{i,j}) \leq h\left(\sum_{j=1}^m \lambda_{i,j}\right) = h(p_i).$$

- Il en résulte que :

$$H(X, Y) = -\sum_{i=1}^n \sum_{j=1}^m h(\lambda_{i,j}) \geq -\sum_{i=1}^n h(p_i) = H(X)$$

donc $H(Y | X) = H(X, Y) - H(X) \geq 0$.

- d. • On a, par hypothèse, $H(Y | X) = 0$ donc $\sum_{i=1}^n \underbrace{\left(\sum_{j=1}^m h(\lambda_{i,j}) - h(p_i)\right)}_{=\alpha_i} = 0$. D'après la question

III.2b, chaque α_i est positif. Ainsi pour tout i dans I_n , $\alpha_i = 0$ donc

$$\sum_{j=1}^m h(\lambda_{i,j}) = h(p_i) = h\left(\sum_{j=1}^m \lambda_{i,j}\right).$$

Pour tout i dans I_n , selon III.2b, il existe au plus un seul indice j dans I_m tel $\lambda_{i,j}$ non nul. En fait, si $p_i > 0$, il en existe exactement un, sinon p_i serait nul.

Conclusion. Pour tout $i \in I_n$ tel que $p_i > 0$, il existe un unique j dans I_m tel que $\lambda_{i,j} > 0$. On pose $j = \alpha(i)$.

- On a ainsi défini une fonction $\alpha : I_n \rightarrow I_m$ et on a :

$$\begin{aligned} P(Y = \alpha(X)) &= \sum_{i=1}^n P([Y = \alpha(X)] \cap [X = i]) = \sum_{i=1}^n P([Y = \alpha(i)] \cap [X = i]) \\ &= \sum_{i=1}^n \lambda_{i, \alpha(i)} \end{aligned}$$

Mais, pour tout i dans I_n , si $p_i = 0$ on a $\lambda_{i,j} = 0$ et si $p_i > 0$, alors $\lambda_{i,j} = 0$ pour $j \neq \alpha(i)$. Il en résulte que :

$$P(Y = \alpha(X)) = \sum_{i=1}^n \lambda_{i,\alpha(i)} = \sum_{i=1}^n \sum_{j=1}^m \lambda_{i,j} = 1.$$

Conclusion. On a $Y = \alpha(X)$ presque sûrement.

- Ce résultat est naturel : si on n'a aucune incertitude sur la valeur de Y , celle de X étant connue, c'est que Y est presque sûrement une fonction de X ...

FIN DE LA CORRECTION
