

I Définition de l'information

Transmission de l'information: l'employé du télégraphe, pour calculer la somme à payer, ne fait entrer en ligne de compte que le nombre de mots du télégramme.  
 On code les lettres en binaire: 32 symboles 0 ou 1.  
 Une information = un signe distinctif d'un élément d'un ensemble E.  
 Si card E =  $2^n$ , on peut numérotter les éléments de E en binaire à n chiffres.  
 $N = 2^n$ ,  $n = \log_2 N$  bits.

Définition de Hartley:  $I(E_N) = \log_2 N$  même si  $N$  n'est pas une puissance de 2 ( $N = \text{card } E_N$ ).

Proposition: 
$$\begin{cases} I(E_{MN}) = I(E_M) + I(E_N) \\ I(E_N) \leq I(E_{N+1}) \\ I(E_2) = 1 \end{cases}$$

Démonstration:  $E_{MN} = E_M^{(1)} \cup E_M^{(2)} \cup \dots \cup E_M^{(N)}$ . Pour caractériser un élément de  $E_{MN}$ , on doit d'abord savoir à quel  $E_M^{(i)}$  il appartient (ce qui nécessite l'information  $I(E_N)$  puisqu'il y a N parties), puis on doit identifier l'élément dans  $E_M^{(i)}$  (ce qui nécessite l'information  $I(E_M^{(i)}) = I(E_M)$ ). D'où le besoin de  $I(E_N) + I(E_M)$  informations.

La démonstration vient d'être faite dans le cas où les  $E_M^{(i)}$  ont même information.  
Cas général:  $E_N = E_{N_1}^{(1)} \cup \dots \cup E_{N_m}^{(m)}$  avec les  $E_{N_i}^{(i)}$  deux à deux disjoints,  $N = \sum_{i=1}^m N_i$ .

Pour caractériser un élément de  $E_N$ , il faut savoir à quel  $E_{N_i}^{(i)}$  il appartient (ce qui demande une quantité d'information  $I_1$ ), puis sachant qu'il est dans  $E_{N_i}^{(i)}$ , il faut une quantité d'information  $I(E_{N_i}^{(i)})$  supplémentaire pour l'identifier. Or les  $N_i$  ne sont pas nécessairement tous identiques. Il faut donc une information moyenne  $\sum_{i=1}^m p_i I(E_{N_i}^{(i)})$  où  $p_i = \frac{N_i}{N}$ .

Au total:  $I(E_N) = I_1 + \sum_{i=1}^m p_i I(E_{N_i}^{(i)})$

$\Rightarrow I_1 = \log_2 N - \sum_{i=1}^m p_i \log_2 N_i = \log_2 N - \sum_{i=1}^m p_i \log_2 N - \sum_{i=1}^m p_i \log_2 \frac{1}{p_i}$

Formule de Shannon:  $I_1 = \sum_{i=1}^m p_i \log_2 \frac{1}{p_i}$

Claude Elwood Shannon, 1916...

Si  $p_1 = \dots = p_n = \frac{1}{n}$  on trouve  $I_1 = \log_2 n$  ( $N = n N_i, \forall i$ )

Définition: Entropie: soit  $\mathcal{P} = (p_1, \dots, p_n)$  une distribution de probabilité discrète finie (i.e.  $p_i \in [0, 1]$  et  $\sum p_i = 1$ ). L'entropie de  $\mathcal{P}$  est

$$H(\mathcal{P}) = \sum_{i=1}^n p_i \log_2 \frac{1}{p_i}$$

On parle aussi de quantité d'information, à comprendre plutôt comme quantité d'indécision (ou d'incertitude).

Plus l'entropie est grande, plus l'énergie du système est petite: tendance vers l'état d'énergie minimale (chaos) ... Lien avec la thermodynamique avec Boltzmann.

Si  $X$  est une v.a. suivant la loi  $\mathcal{P} : P(X=x_i) = p_i$ , on note aussi

$$H(X) = H(\mathcal{P}) \quad , \text{ définition indépendante des valeurs prises par } X.$$

Si  $f$  est une injection sur  $\{x_1, \dots, x_m\}$ ,  $H(X) = H(f(X))$ .

Autre forme de  $H(X)$  : soit  $f_X(x) = P\{X=x\}$ . Alors  $H(X) = E\left[\log_2 \frac{1}{f_X(x)}\right]$

Proposition :  $H(\mathcal{P}) \leq \log_2 m$  et l'égalité a lieu si  $p_1 = \dots = p_m = \frac{1}{m}$  (i.e.  $\mathcal{P}$  uniforme).

Démonstration :  $\varphi(x) = x \log_2 x$  est convexe donc

$$H(\mathcal{P}) = - \sum_{i=1}^m p_i \log_2 p_i = - \sum_{i=1}^m \varphi(p_i) \leq -m \varphi\left(\frac{1}{m} \sum_{i=1}^m p_i\right) = \log_2 m.$$

Il y a égalité si les  $p_i$  sont tous égaux de somme 1 i.e.  $p_i = \frac{1}{m} \cdot \square$

Interprétation : s'il y a  $m$  possibilités pour le résultat d'une épreuve, l'indétermination est maximale quand toutes les éventualités sont équiprobables (pas de site privilégié, tendance vers le chaos).

S'il y a un site privilégié e.g.  $p_1=1, p_2=\dots=p_m=0$ ,  $H(\mathcal{P})=0 \rightarrow$  aucune indétermination.

Accroissement de l'indétermination.

Soit  $\mathcal{P} = (p_1, \dots, p_m)$  et  $W = (w_{ij})_{\substack{1 \leq i \leq m \\ 1 \leq j \leq m}}$  une matrice <sup>doublement</sup> stochastique  $\left\{ \begin{array}{l} \sum_{i=1}^m w_{ij} = 1, \forall j \\ \sum_{j=1}^m w_{ij} = 1, \forall i \\ w_{ij} \geq 0 \end{array} \right.$

$\mathcal{Q} = \mathcal{P}W = (q_1, \dots, q_m)$  est une distribution de probabilité ( $\sum_{i=1}^m q_i = 1$ )

et  $H(\mathcal{P}) \leq H(\mathcal{Q})$  (l'indétermination s'accroît).

$$\begin{aligned} \text{En effet : } q_j \log_2 q_j &= \varphi\left(\sum_{i=1}^m p_i w_{ij}\right) \leq \sum_{i=1}^m w_{ij} \varphi(p_i) = \\ -H(\mathcal{Q}) &= \sum_{j=1}^m q_j \log_2 q_j \leq \sum_{i=1}^m \varphi(p_i) \underbrace{\sum_{j=1}^m w_{ij}}_1 = \sum_i p_i \log_2 p_i = -H(\mathcal{P}). \end{aligned}$$

## II Information conditionnelle - Transformation.

Soit  $X, Y$  deux v.a. discrètes finies. On pose

$$\begin{cases} P(X=x_i) = p_i & \mathcal{P} = (p_1, \dots, p_m) \\ P(Y=y_j) = q_j & \mathcal{Q} = (q_1, \dots, q_m) \\ P(X=x_i, Y=y_j) = r_{ij} & \mathcal{R} = (r_{ij})_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}} \end{cases}$$

$$\begin{cases} P(X=x_i | Y=y_j) = p_{ij} & \mathcal{P}_j = (p_{1j}, \dots, p_{mj}) \\ P(Y=y_j | X=x_i) = q_{ji} & \mathcal{Q}_i = (q_{i1}, \dots, q_{im}) \end{cases}$$

$$\text{On a } r_{ij} = p_{ij} q_j = q_{ji} p_i, \quad \sum_{j=1}^m r_{ij} = p_i, \quad \sum_{i=1}^m r_{ij} = q_j$$



Définition : \*  $H(X, Y) = \sum_{i,j} r_{ij} \log_2 \frac{1}{r_{ij}} = \mathbb{E} \left[ \log_2 \frac{1}{p_{(X,Y)}(x,y)} \right]$  avec  $p_{(X,Y)}(x,y) = \mathbb{P}(X=x, Y=y)$

\*  $H(Y|X) = H(X|Y) = \mathbb{E} \left[ \log_2 \frac{1}{p_{X|Y}(x,y)} \right]$  avec  $p_{X|Y}(x,y) = \mathbb{P}(X=x|Y=y) = \frac{p_{(X,Y)}(x,y)}{p_Y(y)}$

$$= \sum_{i,j} r_{ij} \log_2 \frac{1}{p_{i|j}} = \sum_{i,j} r_{ij} \log_2 \frac{q_j}{r_{ij}} = \sum_{j=1}^m q_j \underbrace{H(\mathcal{P}_j)}_{\sum_{i=1}^m p_{i|j} \log_2 \frac{1}{p_{i|j}}}$$

Proposition :  $H(X, Y) = H(Y) + H(X|Y) = H(X) + H(Y|X)$ , ou : l'information contenue dans  $(X, Y)$  = l'information contenue dans X sachant Y + l'information contenue dans Y.

Démonstration :  $H(X, Y) - H(X|Y) = \sum_{i,j} r_{ij} \log \frac{1}{q_j} = \sum_{j=1}^m q_j \log \frac{1}{q_j} = H(Y)$  .  $\square$

Si X, Y sont indépendantes,  $H(X|Y) = H(X)$  et  $H(X, Y) = H(X) + H(Y)$ .  
 $H(X|X) = 0$  car  $r_{ij} = p_i \delta_{ij}$ .

Proposition :  $H(X, Y) \leq H(X) + H(Y)$  ou encore  $H(X|Y) \leq H(X)$  : l'information contenue dans X sachant ne peut dépasser l'information totale de X.

Démonstration :  $H(X|Y) = \sum_{i,j} r_{ij} \log_2 \frac{q_j}{r_{ij}} = - \sum_{i=1}^m \left[ \sum_{j=1}^m q_j \underbrace{(p_{i|j} \log_2 p_{i|j})}_{\varphi(p_{i|j})} \right] \leq - \sum_{i=1}^m \varphi \left( \sum_{j=1}^m q_j p_{i|j} \right) = - \sum_{i=1}^m \varphi(p_i)$   
 Egalité si les  $p_{i|j}$  sont tous égaux, i.e. X, Y indépendantes.

Transinformation :  $I(X, Y) = H(X) - H(X|Y) = H(Y) - H(Y|X) = H(X) + H(Y) - H(X, Y) = \sum_{i,j} r_{ij} \log_2 \frac{r_{ij}}{p_i \cdot q_j}$   
 c'est l'information relative donnée par Y sur X.  $= \mathbb{E} \left[ \log_2 \frac{p_{(X,Y)}(x,y)}{p_X(x) p_Y(y)} \right]$

Proposition :  $I(X, Y) = I(Y, X)$  et  $0 \leq I(X, Y) \leq H(X) \wedge H(Y)$ . Si X, Y sont indépendantes,  $I(X, Y) = 0$ .

Interprétation :  $I(X, Y)$  = diminution d'indétermination résultant de la connaissance de Y  
 = information sur X que l'on peut extraire de la valeur de Y  
 → mesure de dépendance stochastique entre X et Y.  
 La propriété de symétrie signifie que Y donne autant d'information sur X que X sur Y.

exemple : Soit Y symétrique par rapport à 0 et  $\mathbb{P}\{Y=0\} = 0$ ,  $X = Y^2$ .  
 Valeurs de Y :  $0, \pm y_1, \dots, \pm y_n$  - Valeurs de X :  $0, y_1^2, \dots, y_n^2$ .  
 $\forall i, \mathbb{P}\{X = y_i^2\} = 2 \mathbb{P}\{Y = y_i\} \Rightarrow \log_2 \mathbb{P}\{X = y_i^2\} = 1 + \log_2 \mathbb{P}\{Y = y_i\}$

D'où  $H(Y) = H(X) + 1$  : si on connaît |Y|, Y prend les valeurs  $\pm |Y|$  avec probabilité  $\frac{1}{2}$ , il reste donc une unité d'indétermination sur le signe.

Proposition : Soit  $f$  une application.  $I(X, f(Y)) \leq I(X, Y)$  ou encore  $H(X|f(Y)) \geq H(X|Y)$ .

interprétation: si au lieu d'observer  $Y$ , on observe seulement  $f(Y)$ , on a alors plus d'indétermination sur  $X$ .

Démonstration: \* si  $f$  est injective il y a égalité (les valeurs de  $f(Y)$  sont toutes distinctes).

\* si  $f(y_k) = f(y_l) \neq f(y_m) \forall m \neq k, l$  et les  $f(y_m), m \neq k, l$  tous distincts:

valeurs de  $f(Y)$ :  $\{f(y_m), m \neq k, l \text{ et } f(y_k) = f(y_l)\}$ .

$$P(f(Y) = f(y_m)) = P(Y = y_m) = q_m \text{ pour } m \neq k, l,$$

$$P(f(Y) = f(y_k)) = P(Y = y_k) + P(Y = y_l) = q_k + q_l.$$

$$H(X|f(Y)) = \sum_j q_j^b H(\mathcal{P}_j^b) = \sum_{m \neq k, l} q_m H(\mathcal{P}_m) + (q_k + q_l) H(\mathcal{P}_{k,l})$$

associé à  $f(Y)$ 
 $H(X|Y=y_m)$ 
 $H(X|Y=y_k \text{ ou } Y=y_l)$

$$\text{Or } P(X = x_i | Y = y_k \text{ ou } Y = y_l) = \frac{r_{ik} + r_{il}}{q_k + q_l} = \frac{q_k p_{ik} + q_l p_{il}}{q_k + q_l}$$

$$\text{donc } H(\mathcal{P}_{k,l}) = - \sum_i \varphi \left( \frac{q_k p_{ik} + q_l p_{il}}{q_k + q_l} \right) \geq - \sum_i \frac{q_k \varphi(p_{ik}) + q_l \varphi(p_{il})}{q_k + q_l}$$

$$\geq \frac{q_k H(\mathcal{P}_k) + q_l H(\mathcal{P}_l)}{q_k + q_l}$$

$$\text{ou encore } q_k H(\mathcal{P}_k) + q_l H(\mathcal{P}_l) \leq (q_k + q_l) H(\mathcal{P}_{k,l}).$$

$$\text{Ainsi } H(X|f(Y)) \geq \sum_m q_m H(\mathcal{P}_m) = H(X|Y).$$

\* le même raisonnement est applicable si plus de valeurs de  $f$  coïncident...  $\square$

### III Gain d'information

Soit  $E_N = E_{N_1}^{(1)} \cup E_{N_2}^{(2)} \cup \dots \cup E_{N_m}^{(m)}$ ,  $\text{card } E_{N_i}^{(i)} = N_i = p_i N$ .

Un élément choisi au hasard dans  $E_N$  peut être caractérisé de deux manières différentes:

1) soit par son numéro dans  $E_N$ , noté  $X$ .

2) soit par la donnée de  $E_{N_k}^{(k)}$  le contenant (le noté  $Y$ ), puis de son numéro dans  $E_{N_k}^{(k)}$ , noté  $Z$ .

$$\text{Alors } H(X) = H(Y) + H(Z|Y) = H(Y, Z) \text{ et } H(X) = \log_2 N, H(Y) = \sum_{i=1}^m p_i \log_2 \frac{1}{p_i}, H(Z|Y) = \sum_{i=1}^m p_i \log_2 \frac{N_i}{N_i} = \sum_{i=1}^m p_i \log_2 \frac{N_i}{N_i} = H(Z|Y=i)$$

Soit maintenant  $E_{N'} \subset E_N$ ,  $E_{N_i}^{(i')} = E_N \cap E_{N_i}^{(i)}$ ,  $q_i = \frac{N_i'}{N'}$ ,  $N_i' = \text{card } E_{N_i}^{(i')}$ .

Supposons que l'on sache d'un élément pris au hasard dans  $E_N$  qu'il est dans  $E_{N'}$ . Combien d'information cela fournit-il sur  $Y$ ?

La distribution a priori de  $Y$  était  $\mathcal{P} = (p_1, \dots, p_m)$ . Après l'information disant que l'élément est dans  $E'$ ,  $Y$  a la distribution a posteriori  $\mathcal{Q} = (q_1, \dots, q_m)$ .

On note alors  $I(\mathcal{Q} || \mathcal{P})$  le gain d'information pour  $Y$  sachant que l'élément est dans  $E'$ .



On a  $\log_2 \frac{N}{N'} = \underbrace{I(Q \parallel P)}_{\substack{\text{info sur } X \\ \text{ sachant } X \in E'}} + \underbrace{\sum_{i=1}^m q_i \log_2 \frac{N_i}{N'_i}}_{\substack{\text{info que donne } Z \in E' \\ \text{ sur } Z \text{ connaissant } Y}}$

Où  $N_i = p_i N$ ,  $N'_i = q_i N'$  donc  $\frac{N N'_i}{N'_i N_i} = \frac{q_i}{p_i}$  d'où :

Définition : gain d'information du remplacement de  $P$  par  $Q$  :  $I(Q \parallel P) = \sum_{i=1}^m q_i \log_2 \frac{q_i}{p_i}$ .  
(Information de Kullback de  $Q$  par rapport à  $P$ )

Exemples : 1)  $P = (p_1, \dots, p_m)$  distribution quelconque,  $E_n = (\frac{1}{n}, \dots, \frac{1}{n})$  distribution uniforme

$$I(P \parallel E_n) = \sum_{i=1}^m p_i \log_2 (n p_i) = \log_2 n + \sum_{i=1}^m p_i \log_2 p_i = H(E_n) - H(P)$$

$I(P \parallel E_n)$  est le gain d'information obtenu en remplaçant la distribution uniforme par une quelconque  $\rightarrow$  diminution de l'indétermination.  
En général on n'a pas  $I(Q \parallel P) = H(Q) - H(P)$ .

2)  $I(X, Y) = I(R \parallel P \otimes Q)$  avec  $R = (r_{ij})_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}}$ ,  $P \otimes Q = (p_i q_j)_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}}$

Proposition :  $I(X, Y) = \sum_{j=1}^n q_j I(P_j \parallel P)$  où  $P_j = (p_{1j}, \dots, p_{mj})$

Démonstration :  $I(X, Y) = \sum_{i,j} r_{ij} \log_2 \frac{r_{ij}}{p_i q_j} = \sum_{j=1}^n q_j \underbrace{\sum_{i=1}^m p_{ij} \log_2 \frac{p_{ij}}{p_i}}_{I(P_j \parallel P)}$  .  $\square$

Proposition :  $I(Q \parallel P) \geq 0$

Démonstration :  $I(Q \parallel P) = \sum_{i=1}^m p_i \varphi\left(\frac{q_i}{p_i}\right) \geq \varphi\left(\sum_{i=1}^m p_i \frac{q_i}{p_i}\right) = \varphi(1) = 0$  (convexité) .  $\square$

Proposition :  $I(Q_1 \otimes Q_2 \parallel P_1 \otimes P_2) = I(Q_1 \parallel P_1) + I(Q_2 \parallel P_2)$

Démonstration :  $I(Q_1 \otimes Q_2 \parallel P_1 \otimes P_2) = \sum_{i,j} q_{1i} q_{2j} \log_2 \frac{q_{1i} q_{2j}}{p_{1i} p_{2j}} = \sum_{i,j} q_{2j} \underbrace{\sum_i q_{1i} \log_2 \frac{q_{1i}}{p_{1i}}}_1 + \sum_i q_{1i} \underbrace{\sum_j q_{2j} \log_2 \frac{q_{2j}}{p_{2j}}}_1$   
 $= I(Q_1 \parallel P_1) + I(Q_2 \parallel P_2)$  .  $\square$

Expression symétrisée (due à Jeffreys) :  $I(P, Q) = I(P \parallel Q) + I(Q \parallel P) = \sum_{i=1}^m (p_i - q_i) \log_2 \frac{p_i}{q_i}$

### Extension au cas des v.a. continues

Soit  $X$  une v.a.c. On pose  $X_n = \lfloor \frac{nX}{1} \rfloor$ ,  $X_n$  v.a.d. à valeurs dans  $\frac{1}{n} \mathbb{Z}$ . Soit  $p_i^{(n)} = P(X_n = \frac{i}{n}) = \int_{\frac{i-1}{n}}^{\frac{i}{n}} f(x) dx$

$H(X_n) = \sum_{i \in \mathbb{Z}} p_i^{(n)} \log_2 \frac{1}{p_i^{(n)}} = \sum_{i \in \mathbb{Z}} p_i^{(n)} \log_2 \frac{1}{n p_i^{(n)}} + \log_2 n = \log_2 n + \sum_{i \in \mathbb{Z}} p_i^{(n)} \log_2 \frac{1}{p_i^{(n)}}$  avec  $f_n(x) = n p_i^{(n)}$

Où a  $f_n(x) = \sum_{i \in \mathbb{Z}} \int_{\frac{i-1}{n}}^{\frac{i}{n}} f(x) dx \rightarrow f(x)$  et  $H(X_n) - \log_2 n \rightarrow \int_{-\infty}^{+\infty} f(x) \log_2 \frac{1}{f(x)} dx$

D'où la définition  $H(X) = \int_{-\infty}^{+\infty} f(x) \log_2 \frac{1}{f(x)} dx = E \left[ \log_2 \frac{1}{f(X)} \right]$

puis  $H(X, Y) = \iint f_{(X,Y)}(x,y) \log_2 \frac{1}{f_{(X,Y)}(x,y)} dx dy$ ,  $H(X|Y) = \iint f_{(X,Y)}(x,y) \log_2 \frac{1}{f_{(X|Y)}(x,y)} dx dy = \int H(X|Y=y) f_Y(y) dy$

$I(X, Y) = \iint f_{(X,Y)}(x,y) \log_2 \frac{f_{(X,Y)}(x,y)}{f_X(x) f_Y(y)} dx dy$  . -5-

### III bis Information de Kullback (complément à Gain d'information)

Soit  $X, Y$  deux v.a. On définit une entropie relative (information de Kullback) de  $Y$  par rapport à  $X$

Définition: 
$$I(Y||X) = \begin{cases} \sum_i q_i \log_2 \frac{q_i}{p_i} & \text{si } \mathbb{P}_X = \{p_i, i \in \mathbb{N}\}, \mathbb{P}_Y = \{q_i, i \in \mathbb{N}\} \text{ et } p_i = 0 \Rightarrow q_i = 0 \\ \int g(x) \log_2 \frac{g(x)}{f(x)} dx & \text{si } f = f_X \text{ et } g = f_Y \text{ sont telles que } f(x) = 0 \Rightarrow g(x) = 0 \end{cases}$$

avec la convention  $\log_2 \frac{a}{b} = 0$  si  $a = 0$  ou  $b = 0$ .

Proposition:  $\forall X, Y, I(Y||X) \geq 0$ .

Démonstration:  $\varphi(x) = x \log_2 x$  est convexe donc  $I(Y||X) = \sum p_i \varphi(\frac{q_i}{p_i}) \geq \varphi(\sum p_i \frac{q_i}{p_i}) = \varphi(1) = 0$ .  $\square$   
 Autre d'ém:  $I(Y||X) = \sum_i (\frac{q_i}{p_i} \log_2 \frac{q_i}{p_i} + 1 - \frac{q_i}{p_i}) p_i = \sum_i \psi(\frac{q_i}{p_i}) p_i$  avec  $\psi(x) = x \log_2 x + (1-x) \log_2 e$   
 $\psi$  convexe  $\geq 0$ .

- Théorème:
- 1) Soit  $E$  l'ensemble des v.a.d. (resp. v.a.c.) à valeurs dans  $\{1, \dots, n\}$  (resp.  $[a, b]$ ). Alors  $H: E \rightarrow \mathbb{R}$  est maximale pour la loi uniforme  $\mathcal{U}\{1, \dots, n\}$  (resp.  $\mathcal{U}[a, b]$ ).
  - 2) Soit  $E_m$  l'ensemble des v.a.d. (resp. v.a.c.) à valeurs dans  $\mathbb{N}^*$  (resp.  $\mathbb{R}^+$ ) d'espérance fixée  $E(X) = m$ . Alors  $H: E_m \rightarrow \mathbb{R}$  est maximale pour la loi géométrique  $\mathcal{G}(\frac{1}{m})$  (resp. exp.  $\mathcal{E}(\frac{1}{m})$ ).
  - 3) Soit  $E_{m, \sigma}$  l'ensemble des v.a.c. telles que  $E(X) = m, \text{var}(X) = \sigma^2 > 0$ . Alors  $H: E_{m, \sigma} \rightarrow \mathbb{R}$  est maximale pour la loi normale  $N(m, \sigma^2)$ .

Démonstration: Calculons d'abord les entropies correspondantes:

$X: \mathcal{U}\{1, \dots, n\} \quad H(X) = \log_2 n \quad X: \mathcal{U}[a, b] \quad H(X) = \log_2(b-a)$

$X: \mathcal{G}(p) \quad H(X) = \frac{1}{p} [p \log_2 \frac{1}{p} + (1-p) \log_2 \frac{1}{1-p}] \quad X: \mathcal{E}(\lambda) \quad H(X) = \log_2 \frac{e}{\lambda}$

$X: N(m, \sigma^2) \quad H(X) = \log_2(\sqrt{2\pi e} \sigma)$

Soit  $Y \in E$ .

- 1)  $I(Y||X) = \left\{ \begin{array}{l} \sum_{i=1}^n q_i \log_2 n \\ \int_a^b g(x) \log_2(b-a) dx \end{array} \right\} - H(Y) = H(X) - H(Y) \geq 0 \Rightarrow \forall Y \in E, H(Y) \leq H(X)$
- 2)  $I(Y||X) = \left\{ \begin{array}{l} - \sum_{i=1}^{\infty} q_i \log_2(p(1-p)^{i-1}) \\ - \int_0^{\infty} g(x) \log_2(\lambda e^{-\lambda x}) dx \end{array} \right\} - H(Y) = \left\{ \begin{array}{l} - \log_2 p \sum_{i=1}^{\infty} q_i - \log_2(1-p) \sum_{i=1}^{\infty} (i-1) q_i \\ - \log_2 \lambda \int_0^{\infty} g(x) dx + \lambda \log_2 e \int_0^{\infty} x g(x) dx \end{array} \right\} - H(Y)$   
 $\left( \begin{array}{l} p = \frac{1}{m} \\ \text{ou } \lambda = \frac{1}{m} \end{array} \right)$   
 $= \left\{ \begin{array}{l} \log_2 \frac{1}{p} + \frac{1-p}{p} \log_2 \frac{1}{1-p} \\ \log_2 \frac{e}{\lambda} \end{array} \right\} - H(Y) = H(X) - H(Y) \geq 0 \Rightarrow \forall Y \in E, H(Y) \leq H(X)$
- 3)  $I(Y||X) = - \int_{-\infty}^{+\infty} g(x) \log_2 \frac{e^{-\frac{(x-m)^2}{2\sigma^2}}}{\sqrt{2\pi} \sigma} dx - H(Y) = \frac{\log_2 e}{2\sigma^2} \int_{-\infty}^{+\infty} (x-m)^2 g(x) dx + \log_2 \sqrt{2\pi} \sigma \int_{-\infty}^{+\infty} g(x) dx - H(Y)$   
 $= \log_2 \sqrt{2\pi e} \sigma - H(Y) = H(X) - H(Y) \geq 0 \Rightarrow \forall Y \in E, H(Y) \leq H(X). \square$




## IV Application à la transmission de l'information

Une source  $X$  émet des signaux  $(x_1, \dots, x_m)$  avec probabilités  $(p_1, \dots, p_m)$  à travers un canal.

À la sortie de ce canal on réceptionne les signaux  $Y : (y_1, \dots, y_n)$  avec probabilités  $(q_1, \dots, q_n)$ .

Le canal a été source de perturbation.



$H(X)$ : entropie à l'entrée du canal

$H(Y)$ : entropie à la sortie du canal

$H(X, Y)$ : entropie entrée - sortie

$H(X|Y)$ : Équivocque : mesure d'équivocque sur la source  $X$  connaissant la réception  $Y$

$H(Y|X)$ : erreur moyenne : mesure d'incertitude de la réception  $Y$  connaissant l'émission  $X$ .

La matrice  $P_{Y|X} = (P(Y=y_j|X=x_i))_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}}$  s'appelle la matrice de bruit du canal.


$I(X, Y)$ : valeur moyenne de l'information mutuelle = information que l'on obtient sur la source par la réception de la sortie = information transmise à travers le canal.

S'il n'y a pas de perturbation dans le canal,  $H(X|Y) = H(Y|X) = 0$ ,  $I(X, Y) = H(X) = H(Y)$  ( $X=Y$ ).

S'il y a un maximum de perturbation,  $X$  et  $Y$  sont indépendantes,  $I(X, Y) = 0$ .

Capacité du canal :  $C = \max_X I(X, Y)$ . Plus  $C$  est grand, plus l'écart entre  $H(X)$  et  $H(Y|X)$  est grand ce qui signifie que  $X$  a influence d'autant plus grande sur  $Y$ .

Ex: Le canal linéaire symétrique



Matrice de bruit  $P_{Y|X} = \begin{pmatrix} p & q \\ q & p \end{pmatrix}$ .  $p+q=1$ .

$p_i = P(X=x_i)$ ,  $q_i = P(Y=y_i)$   $i=1, 2$   $p_1+p_2=q_1+q_2=1$ .

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

$$\text{On a } H(Y|X) = \sum_{i=1}^2 P(X=x_i) H(Y|X=x_i) = p_1 H(Y|X=x_1) + p_2 H(Y|X=x_2)$$

$$\text{or } H(Y|X=x_1) = H(Y|X=x_2) = p \log_2 \frac{1}{p} + q \log_2 \frac{1}{q}$$

$$\text{donc } H(Y|X) = p \log_2 \frac{1}{p} + q \log_2 \frac{1}{q} \text{ (indépendant de } X)$$

$$H(Y) = (q_1, q_2) \begin{pmatrix} p & q \\ q & p \end{pmatrix} = (p_1 p + p_2 q, p_1 q + p_2 p) = ((p-q)p_1 + q, -(p-q)p_1 + p)$$

$$H(Y) = [(p-q)p_1 + q] \log_2 \frac{1}{(p-q)p_1 + q} + [p - (p-q)p_1] \log_2 \frac{1}{p - (p-q)p_1} = f(p_1) \text{ (} = 1 \text{ si } p=q=\frac{1}{2}$$

$$\text{D'où } C = \max_X H(Y) - H(Y|X) = \max_{p_1 \in [0,1]} f(p_1) + p \log_2 p + q \log_2 q$$

$$\text{Si } p \neq \frac{1}{2}, f(p_1) = x \log_2 \frac{1}{x} + (1-x) \log_2 \frac{1}{1-x}, x = (p-q)p_1 + q = q_1 \in [0,1]$$

$$\max_{p_1 \in [0,1]} f(p_1) = \max_{x \in [0,1]} [x \log_2 \frac{1}{x} + (1-x) \log_2 \frac{1}{1-x}] = 1 \text{ (vrai aussi pour } p=\frac{1}{2}$$

$$C = 1 + p \log_2 p + q \log_2 q.$$

Annexe : autres fonctions d'information

1) Mesure d'ordre  $\alpha$  de l'information pour  $X$  finie ou dénombrable :

$$H_\alpha(X) = \frac{1}{1-\alpha} \log_2 \sum_{i=1}^{m \text{ ou } \infty} p_i^\alpha, \quad \alpha \neq 1$$

On a  $\lim_{\alpha \rightarrow -\infty} H_\alpha(X) = \log_2 \frac{1}{\min_{1 \leq i \leq n} p_i}$ ,  $\lim_{\alpha \rightarrow +\infty} H_\alpha(X) = \log_2 \frac{1}{\max_{1 \leq i \leq n} p_i}$ ,  $\lim_{\alpha \rightarrow 1} H_\alpha(X) = \sum_{i=1}^m p_i \log_2 \frac{1}{p_i}$ .

En effet : \* supposons e.g.  $p_n = \max_{1 \leq i \leq n} p_i$ .  $H_\alpha(X) = \frac{1}{1-\alpha} \left[ \alpha \log_2 p_n + \log_2 \left( 1 + \sum_{i=1}^{n-1} \left( \frac{p_i}{p_n} \right)^\alpha \right) \right]$

$$* \frac{\log_2 \sum_{i=1}^m p_i^\alpha}{1-\alpha} \underset{\alpha \rightarrow 1}{\sim} - \frac{\sum_{i=1}^m p_i^\alpha - 1}{(\alpha-1) \ln 2} \xrightarrow{\alpha \rightarrow 1} \frac{d}{d\alpha} \left( \sum_{i=1}^m p_i^\alpha \right) \times \frac{1}{\ln 2} = - \sum_{i=1}^m p_i \log_2 p_i$$

Si  $\mathcal{P}$  est incomplète i.e.  $\sum p_i \leq 1$  on pose  $H_\alpha(\mathcal{P}) = \frac{1}{1-\alpha} \log_2 \frac{\sum p_i^\alpha}{\sum p_i}$ .

2) Mesure d'ordre  $\alpha$  de l'information pour  $X$  absolument continue :

$$H_\alpha(X) = \frac{1}{1-\alpha} \log_2 \int_{-\infty}^{+\infty} f(x)^\alpha dx \quad \text{pour } \alpha \neq 1$$

$$H_1(X) = \int_{-\infty}^{+\infty} f(x) \log_2 \frac{1}{f(x)} dx = E \left[ \log_2 \frac{1}{f(X)} \right] \quad (\text{information de Shannon})$$

(obtenue à partir de la v.a. discrète  $X_N = [NX]$  et  $\lim_{N \rightarrow +\infty} [H_\alpha(X_N) - \log_2 N] = H_\alpha(X)$ .)

e.g.  $H_1(X_N) - \log_2 N = - \sum_{i=1}^N p_i \log_2 (N p_i) = - \int_{-\infty}^{+\infty} b_N(x) \log_2 b_N(x) dx \xrightarrow{N \rightarrow \infty} \int_{-\infty}^{+\infty} f(x) \log_2 \frac{1}{f(x)} dx$  avec  $b_N(x) = N p_i$  sur  $[\frac{i}{N}, \frac{i+1}{N}]$   
 $b_N(x) \rightarrow f(x)$ ,  $p_i N = P(X_N = i)$

3) Si  $\mathcal{Q}$  est absolument continue par rapport à  $\mathcal{P}$  :

$$I_\alpha(\mathcal{Q} \parallel \mathcal{P}) = \frac{1}{\alpha-1} \log_2 \int_{\Omega} \left( \frac{d\mathcal{Q}}{d\mathcal{P}} \right)^\alpha d\mathcal{P} \quad \text{pour } \alpha \neq 1$$

$$I_1(\mathcal{Q} \parallel \mathcal{P}) = \int_{\Omega} \left( \frac{d\mathcal{Q}}{d\mathcal{P}} \log_2 \frac{d\mathcal{Q}}{d\mathcal{P}} \right) d\mathcal{P}$$

ex : \*  $\mathcal{P} = (p_1, \dots, p_n)$ ,  $\mathcal{Q} = (q_1, \dots, q_n)$   $\mathcal{Q}$  absolument continue par rapport à  $\mathcal{P} \Leftrightarrow \forall i, q_i > 0$   
 telle que  $\forall i, p_i > 0$

et alors  $\frac{d\mathcal{Q}}{d\mathcal{P}} = \left( \frac{q_1}{p_1}, \dots, \frac{q_n}{p_n} \right)$ , donc  $I_1(\mathcal{Q} \parallel \mathcal{P}) = \sum_i q_i \log_2 \frac{q_i}{p_i}$

$$I_\alpha(\mathcal{Q} \parallel \mathcal{P}) = \frac{1}{1-\alpha} \log_2 \sum \frac{q_i^\alpha}{p_i^{\alpha-1}} \quad \text{pour } \alpha \neq 1$$

\*  $\frac{d\mathcal{P}}{dx}(x) = p(x)$ ,  $\frac{d\mathcal{Q}}{dx}(x) = q(x)$   
 telle que  $\forall x, p(x) > 0$

$\mathcal{Q}$  absolument continue par rapport à  $\mathcal{P}$   
 $\Leftrightarrow$  pour presque tout  $x$ ,  $q(x) > 0$ .

$$\frac{d\mathcal{Q}}{d\mathcal{P}}(x) = \frac{q(x)}{p(x)} \quad \text{et donc} \quad I_1(\mathcal{Q} \parallel \mathcal{P}) = \int_{-\infty}^{+\infty} q(x) \log_2 \frac{q(x)}{p(x)} dx$$

$$I_\alpha(\mathcal{Q} \parallel \mathcal{P}) = \frac{1}{1-\alpha} \log_2 \int_{-\infty}^{+\infty} \frac{q(x)^\alpha}{p(x)^{\alpha-1}} dx$$

4) Complément : Soit  $X$  de loi  $X(\mathcal{P}) = \sum_{i=1}^m p_i \delta_{a_i}$ ,  $p_i = P\{X = a_i\} > 0$ , soit  $L_i(x) = \prod_{j \neq i} \frac{x - a_j}{a_i - a_j}$  (logarithme)

Posons  $\mathcal{P} = \prod_{i=1}^m p_i^{L_i(x)}$ .  $\mathcal{P}$  est une v.a.r. telle que  $P(\mathcal{P} = p_i) = P(X = a_i) = p_i$

Bibliographie

Rényi : Calcul des probabilités 1966 (appendice)

Spätaru : Fondements de la théorie de la transmission  $E(\mathcal{P}) = \sum_{i=1}^m p_i^2 = H_2(X)$  et  $H_1(X) = E \left( \log_2 \frac{1}{\mathcal{P}} \right)$ .

Karlin & Taylor : a first course in stoch. processes