

Formulaire Théorie de l'Information*

1 Notations

Soient X et Y deux Variables Aléatoires (VA) prenant pour valeurs respectives $x_1, \dots, x_i, \dots, x_r$ et $y_1, \dots, y_j, \dots, y_s$. On simplifie la notation $P("X = x_i")$ par $P(x_i)$, de distribution de probabilité (ddp) p . On note (X, Y) leur VA jointe. De même (x_i, y_j) représente l'intersection des deux événements. On note $(x_i|y_j)$ l'événement x_i conditionné par y_j . On note X^N la séquence $X_1, \dots, X_n, \dots, X_N$ de N variables aléatoires. Le log est en base 2, l'unité est le logon ou bit.

2 Probabilités

$$P(x_i \cup y_j) = P(x_i) + P(y_j) - P(x_i, y_j)$$

Déf. : deux événements x_i et y_j sont incompatibles (disjoints) ssi $P(x_i \cup y_j) = P(x_i) + P(y_j)$.

Déf. : $P(x_i, y_j) = P(X_i) \cdot P(y_j|x_i) = P(y_j) \cdot P(x_i|y_j)$.

D'où la formule de Bayes : $\frac{P(x_i|y_j)}{P(y_j)} = \frac{P(y_j|x_i)}{P(x_i)}$

Déf. : les événements x_i y_j sont indépendants ssi $P(x_i, y_j) = P(x_i) \cdot P(y_j)$.

Déf. : les variables aléatoires X Y sont indépendantes ssi :

$\forall i \in \{1, \dots, r\} \forall j \in \{1, \dots, s\}$ x_i et y_j sont indépendants.

3 Incertitude h

$$h(x_i) = \log \frac{1}{P(x_i)} = -\log P(x_i)$$

$$h(x_i, y_j) = h(x_i) + h(y_j|x_i) = h(y_j) + h(x_i|y_j)$$

Cor. : Si x_i et y_j sont indépendants alors $h(x_i, y_j) = h(x_i) + h(y_j)$.

$$0 \leq h(x_i) \leq +\infty$$

4 Entropie H (incertitude moyenne)

$$H(X) = \sum_{i=1}^r P(x_i) \log \frac{1}{P(x_i)} = -\sum_{i=1}^r P(x_i) \log P(x_i) = \sum_{i=1}^r P(x_i) \cdot h(x_i)$$

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

$$H(X, Y) = -\sum_{i=1}^r \sum_{j=1}^s P(x_i, y_j) \log P(x_i, y_j)$$

$$H(X, Y) = H(X) + H(Y) - I(X; Y)$$

$$H(X, Y) = H(X) + H(Y|X) = H(Y) + H(X|Y)$$

X et Y sont indépendantes ssi $H(X) = H(X|Y)$ (alors $H(X, Y) = H(X) + H(Y)$).

L'entropie est maximale lorsque la ddp est uniforme (système aléatoire), elle égale alors $\log(\text{nombre d'événements possibles} = \text{cardinal de l'alphabet})$.

$0 \leq H(g(X))* \leq H(X) \leq \log(r)$, (*) égalité si la fonction g est inversible.

$0 \leq H(X|Y) \leq H(X) \leq H(X, Y) \leq H(X) + H(Y) \leq \log(r * s)$

Règle de la chaîne : $H(X^N) = \sum_{n=1}^N H(X_n|X^{n-1})$

*Univ. Sud Toulon-Var, H. Glotin

5 Entropie relative (ou divergence de Kullback-Leibler)

La divergence (cross-entropy) des 2 ddp p q est : $0 \leq \text{div}KL(p||q) = \sum_x p(x) \cdot \log \frac{p(x)}{q(x)} \leq \infty$

Prop. : asymétrique. $\text{div}KL(p||q) = 0$ ssi $p = q$.

$$\text{div}KL(p(X, Y)||q(X, Y)) = \text{div}KL(p(Y)||q(X)) + \text{div}KL(p(X|Y)||q(X|Y)).$$

$$I(X; Y) = \text{div}KL(p(X, Y)||p(X) * p(Y))$$

$DKL(p, q) = \text{div}KL(p||q) + \text{div}KL(q||p) = \sum_x (p - q) \cdot \log(p/q)$ est symétrique mais est nommée à tort distance car $DKL(p, r) \neq DKL(p, q) + DKL(q, r)$.

Le pouvoir discriminant d'une dimension A suivant le critère de 'Maximal Marginal Diversity' peut s'écrire pour K classes : $J(A) = \sum_k p(k) \cdot DKL(\text{pdf}(k), \text{pdf}(\text{moy}))$, avec moy le centroïde des K classes dans dim A.

6 Information mutuelle i

$$i(X_i, Y_j) = i_{X_i \rightarrow Y_j} = i_{Y_j \rightarrow X_i} = i(Y_j, X_i)$$

$$i(X_i, Y_j) = \log \frac{1}{P(X_i)} - \log \frac{1}{P(X_i|Y_j)} = \log \frac{1}{P(Y_j)} - \log \frac{1}{P(Y_j|X_i)}$$

X_i et Y_j sont indépendants ssi $i(X_i; Y_j) = 0$.

$$-\infty \leq i(X, Y) \leq +\infty.$$

7 Information mutuelle (moyenne) I

$$I(X; Y) = I(Y; X).$$

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

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

$$I(X; Y) = \sum_{i=1}^r \sum_{j=1}^s P(X_i, Y_j) \log \frac{P(X_i, Y_j)}{P(X_i) \cdot P(Y_j)}.$$

X et Y sont indépendantes ssi $I(X; Y) = 0$.

$$0 \leq I(X; Y) \leq \min(H(X), H(Y)).$$

$0 \leq I(X; Y) \leq I(X; Y, Z)$ où Z est une VA quelconque.

$$\text{Déf. : } 0 \leq I(X; Y|Z) = H(X|Z) - H(X|(Y, Z))$$

$$\text{Règle de la chaîne : } I(X^N; Y) = \sum_{n=1}^N I(X_n; Y|X^{n-1})$$

$$I(X; Y) = \text{div}KL(p(X, Y)||p(X), q(Y)).$$

8 Distance entropique

$D_H(X, Y) = H(X, Y) - I(X; Y)$ est nommée distance entropique.

En effet D_H symétrique, $0 \leq D_H, =0$ si $X = Y$, $D(X, Z) \leq D(X, Y) + D(Y, Z)$.

9 Information mutuelle dirigée

L'information mutuelle directe d'une séquence de variables aléatoires X^N vers Y^N est : $I(X^N \rightarrow Y^N) = \sum_{n=1}^N I(X^n; Y_n|Y^{n-1})$.

$$0 \leq I(X^N \rightarrow Y^N) \leq I(X^N; Y^N).$$