

# Formulaire théorie shannonienne de l'information

H. Glotin, glotin@univ-tln.fr, ref. Cover & Thomas, Wiley Ed.

## 1 Notations

Soient  $X$  et  $Y$  deux Variables Aléatoires (VA) prenant respectivement dans leur alphabet les valeurs  $x_1, \dots, x_i, \dots, x_r$  et  $y_1, \dots, y_j, \dots, y_s$ , on note  $p(x) = p_X(x) = Pr\{X = x\}$ , pour  $x$  dans l'alphabet de  $X$ ,  $p$  est la distribution de probabilité (ddp ou pdf en anglais),  $(x_i|y_j)$  l'évènement  $x_i$  conditionné par  $y_j$ ,  $(x_i, y_j)$  leur intersection. On note  $(X, Y)$  la VA jointe de  $X$  et  $Y$ ,  $X^N$  la séquence  $X_1, \dots, X_i, \dots, X_N$  de  $N$  VA. Si le log est en base 2, l'unité est le logon (bit).

## 2 Indépendance et incompatibilité

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

Deux évènements  $x_i$  et  $y_j$  sont incompatibles (disjoints) ssi  $p(x_i \cup y_j) = p(x_i) + p(y_j)$ .

$$p(x_i, y_j) = p(x_i)p(y_j|x_i) = p(y_j)p(x_i|y_j), \text{ donc (Bayes) : } \frac{p(x_i|y_j)}{p(x_i)} = \frac{p(y_j|x_i)}{p(y_j)}$$

L'évènements  $x_i$  est indépendant de  $y_j$  ssi  $p(x_i, y_j) = p(x_i)p(y_j)$ .

La VA  $X$  est indépendante de  $Y$  ssi  $\forall(i, j)$   $x_i$  est indépendant de  $y_j$ .

La VA jointe  $(X, Y)$  est définie par l'ensemble des couples  $(x_i, y_j)$ .

## 3 Incertitude $h$

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

$h(x_i, y_j) = h(x_i) + h(y_j|x_i) = h(y_j) + h(x_i|y_j)$ , donc si  $x_i$  est indépendant de  $y_j$  alors

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

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

## 4 Entropie $H$ (= incertitude moyenne)

$H(X) = \sum_{i=1}^r p(x_i) \cdot h(x_i) = -\sum_{i=1}^r p(x_i) \log p(x_i)$ , et suivant déf. de  $(X, Y)$  on a :  $H(X, Y) = -\sum_{i=1}^r \sum_{j=1}^s p(x_i, y_j) \log p(x_i, y_j)$ ,  $H(X, Y) = H(Y, X) = H(X) + H(Y|X) = H(Y) + H(X|Y)$ ,  $X$  indépendant de  $Y$  ssi  $H(X) = H(X|Y)$  (ssi  $H(X, Y) = H(X) + H(Y)$ ).

L'entropie  $H(X)$  est maximale lorsque la ddp de  $X$  est uniforme (i.e. système aléatoire), alors  $H(X) = \log(r)$ .

$$0 \leq H(\phi(X)) \leq H(X) \leq \log(r). H(\phi(X)) = H(X) \text{ ssi la fonction } \phi \text{ est inversible.}$$

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

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

## 5 Entropie relative (ou divergence de Kullback-Leibler)

On note  $divKL(p||q)$  la divergence (cross-entropy) entre les ddp  $p$  et  $q$  de même alphabet :  $0 \leq divKL(p||q) = \sum_i p(x_i) \log \frac{p(x_i)}{q(x_i)} \leq \infty$

$divKL$  est asymétrique et  $divKL(p||q) = 0$  ssi  $p = q$ .

Entropie relative et règle de la chaîne :  $divKL(p(x, y)||q(x, y)) = divKL(p(x)||q(x)) + divKL(p(y|x)||q(y|x))$ .

$DistKL(p, q) = divKL(p||q) + divKL(q||p) = \sum_x (p - q) \log(p/q)$  est symétrique, est dite distance par abus de langage car ne vérifie pas  $DistKL(p, r) \leq DistKL(p, q) + DistKL(q, r)$ .

## 6 Pouvoir discriminant et diversité marginale maximale

Le pouvoir discriminant d'une dimension A est défini suivant le critère de 'Maximal Marginal Diversity' sur K classes  $C_1, \dots, C_K$  par :  $J(A) = \sum_k p(C_k) \cdot DistKL(p(C_k, A), p(MCK, A))$ , avec  $p(MCK, A)$  la ddp du centroïde des K classes dans la dimension A.

## 7 Information mutuelle événementielle

$$i(x_i, y_j) = i_{x_i \rightarrow y_j} = i_{y_j \rightarrow x_i} = i(y_j, x_i)$$

$$i(x_i, y_j) = \log \frac{1}{p(x_i)} - \log \frac{1}{p(x_i|y_j)} = \log \frac{1}{p(y_j)} - \log \frac{1}{p(y_j|x_i)}$$

$x_i$  et  $y_j$  sont indépendants ssi  $i(x_i, y_j) = 0$

$$-\infty \leq i(x_i, y_j) \leq +\infty$$

## 8 Information mutuelle de VA I (moyenne des MI événementielles)

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

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

$$I(X; Y) = \sum_{i=1}^r \sum_{j=1}^s p(x_i, y_j) \log \frac{p(x_i, y_j)}{p(x_i)p(y_j)}$$

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

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

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

$$I(X; Y) = divKL(p(x, y)||p(x)p(y))$$

On peut proposer  $I(X; Y; Z) = I(X; Y) - I(X; Y|Z)$ , mais peut être négative.

## 9 Distance entropique

$DH(X, Y) = H(X, Y) - I(X; Y)$  est la distance entropique : DH symétrique,  $0 \leq DH$ , nulle si  $X = Y$ , et  $D(X, Z) \leq D(X, Y) + D(Y, Z)$ .

## 10 Information mutuelle dirigée

L'information mutuelle directe d'une séquence de variables aléatoires  $X^N$  vers  $Y^N$  est :

$$I(X^N \rightarrow Y^N) = \sum_{n=1}^N I(X^n; Y_n|Y^{n-1})$$

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