

Nicolas Sendrier

Majeure d'informatique

Introduction la théorie de l'information

Cours n°1

Une mesure de l'information

Espace probabilisé discret

L'**alphabet** est \mathcal{X} (fini en pratique)

Variable aléatoire X à valeurs dans \mathcal{X}

Loi de probabilité $P_X(x), x \in \mathcal{X}$

Moyenne d'une variable aléatoire réelle

$$\bar{V} = \sum_{x \in \mathcal{X}} P_X(x) V(x) = \sum_x P(x) V(x)$$

Espace probabilisé joint

Espace des épreuves $\mathcal{X} \times \mathcal{Y}$

Variables aléatoires X et Y à valeurs dans \mathcal{X} et \mathcal{Y} respectivement.

Loi produit $P_{XY}(x, y), (x, y) \in \mathcal{X} \times \mathcal{Y}$

Lois marginales

$$P_X(x) = \sum_y P_{XY}(x, y)$$

$$P_Y(y) = \sum_x P_{XY}(x, y)$$

Probabilité conditionnelle

$$P_{X|Y}(x | y) = \frac{P_{XY}(x, y)}{P_Y(y)}$$

$$P_{Y|X}(y | x) = \frac{P_{XY}(x, y)}{P_X(x)}$$

X et Y sont **indépendantes** si

$$\forall (x, y) \in \mathcal{X} \times \mathcal{Y}, P_{XY}(x, y) = P_X(x)P_Y(y)$$

Incertitude et information

La **quantité d'information** obtenue lorsque l'évènement $X = x$ se réalise est liée à l'**incertitude** sur cet évènement. Nous cherchons

- fonction **positive** et **décroissante** de la probabilité : $I(x) = f(P(x))$
- l'évènement certain ne produit aucune information : $f(1) = 0$
- un évènement impossible fournit une quantité infinie d'information : $f(0) = \infty$
- fonction **additive** : l'information de deux évènements indépendants s'additionne : $f(P(x)P(y)) = f(P(x)) + f(P(y))$

Information propre

Nous utiliserons comme mesure de l'incertitude la quantité suivante :

$$I(x) = \log_b \frac{1}{P(x)}$$

qui sera appelée *information propre* de x . La base du logarithme est arbitraire. L'unité d'information que nous utiliserons est le *bit*, défini par

Un bit est égal à la quantité d'information fournie par le choix d'une alternative parmi deux équiprobables.

Autrement dit nous utiliserons le logarithme en base 2.

Information mutuelle

Si nous voulons **quantifier la corrélation entre deux évènements**, il faut se demander comment la réalisation de l'un d'entre eux « $Y = y$ » va modifier l'incertitude sur l'autre « $X = x$ ».


La **probabilité a priori** $P_X(x)$ va devenir la **probabilité a posteriori** $P_{X|Y}(x | y)$.

La différence entre les deux « quantités d'incertitude » correspondantes sera l'**information mutuelle** entre x et y :

$$I(x; y) = I(x) - I(x | y) = \log_2 \frac{P(x | y)}{P(x)}$$

Exemple

Soit le **canal binaire symétrique** de probabilité de transition $p \leq \frac{1}{2}$. Les symboles 0 et 1 sont émis selon une loi uniforme.



$$I(0; 0) = I(1; 1) = \log_2(2 - 2p) \geq 0$$

$$I(0; 1) = I(1; 0) = \log_2(2p) \leq 0.$$

Interprétation de l'information mutuelle

L'information mutuelle est **symétrique**

$$I(x; y) = I(y; x) = \log_2 \frac{P(x, y)}{P(x)P(y)}$$

- $I(x; y) \geq 0$ ssi $P(x | y) \geq P(x)$; la réalisation de y augmente la probabilité d'occurrence de x ,
- $I(x; y) \leq 0$ ssi $P(x | y) \leq P(x)$; la réalisation de y diminue la probabilité d'occurrence de x ,
- $I(x; y) = 0$ ssi $P(x | y) = P(x)$; les évènements sont indépendants.

Information mutuelle moyenne

Soient X et Y deux variables aléatoires discrètes

Définition (information mutuelle moyenne)

$$I(X; Y) = \sum_{x,y} P(x, y) I(x; y) = \sum_{x,y} P(x, y) \log_2 \frac{P(x, y)}{P(x)P(y)}$$

Théorème

$$I(X; Y) \geq 0$$

avec **égalité** si et seulement si X et Y sont **indépendantes**

Fonctions convexes

Définition f est convexe sur l'intervalle (a, b) si pour tous $x, y \in (a, b)$

$$\forall \lambda, 0 < \lambda < 1, f(\lambda x + (1 - \lambda)y) \leq \lambda f(x) + (1 - \lambda)f(y).$$

f est strictement convexe si l'égalité n'est vraie que lorsque $x = y$.

Lemme (inégalité de Jensen) f une fonction strictement convexe sur (a, b) . $\forall p_1, \dots, p_n > 0, \sum_i p_i = 1, \forall x_1, \dots, x_n \in (a, b)$

$$f\left(\sum_i p_i x_i\right) \leq \sum_i p_i f(x_i)$$

Avec égalité si et seulement si les x_i sont tous égaux.

Entropie – Propriétés

Définition (Entropie)

$$H(X) = - \sum_x P(x) \log_2 P(x)$$

Proposition Pour une source de cardinal K

$$0 \leq H(X) \leq \log_2 K$$

Définition (Entropie conditionnelle)

$$H(X | Y) = - \sum_{x,y} P(x,y) \log_2 P(x | y)$$

Theorème (le conditionnement réduit l'entropie)

$$H(X | Y) \leq H(X)$$

Preuve : $I(X; Y) = H(X) - H(X|Y) \geq 0$.

Processus stochastiques

Une source produit une suite de lettres dans l'alphabet \mathcal{X}

Pour décrire cette suite de lettres nous utiliserons une suite de variables aléatoires X_1, X_2, \dots à valeurs dans \mathcal{X} . Ces variables ne sont pas nécessairement indépendantes. On parlera de *processus stochastique* pour décrire cette suite de v.a.

$$\begin{aligned}H(X_1, \dots, X_L) &= \sum_{x_1, \dots, x_L} -P(x_1, \dots, x_L) \log_2 P(x_1, \dots, x_L) \\H(X_L | X_{L-1}, \dots, X_1) &= \sum_{x_1, \dots, x_L} -P(x_1, \dots, x_L) \log_2 P(x_L | x_1, \dots, x_{L-1}) \\H(X_1, \dots, X_L) &= H(X_1) + H(X_2 | X_1) + \dots + H(X_L | X_1, \dots, X_{L-1}) \\&= \sum_{i=1}^L H(X_i | X_1, \dots, X_{i-1})\end{aligned}$$

Entropie par lettre

Définition Un processus stochastique est *stationnaire* si son comportement ne varie pas lorsque l'on décale l'observation dans le temps. Pour tous entiers positifs L et j , et tout $(x_1, \dots, x_L) \in \mathcal{X}^L$

$$P_{X_1 \dots X_L}(x_1, \dots, x_L) = P_{X_{1+j} \dots X_{L+j}}(x_1, \dots, x_L)$$

Théorème Pour tout processus stochastique stationnaire, les limites ci-dessous existent et sont égales

$$H(\mathcal{X}) = \lim_{L \rightarrow \infty} \frac{1}{L} H(X_1, \dots, X_L) = \lim_{L \rightarrow \infty} H(X_L | X_1, \dots, X_{L-1}).$$

La quantité $H(\mathcal{X})$ est appelée *entropie par lettre*.

Processus markovien stationnaire

Définition Un processus stochastique est dit *markovien* si pour tout entier positif L et tout $(x_1, \dots, x_L) \in \mathcal{X}^L$

$$P_{X_L|X_1, \dots, X_{L-1}}(x_L | x_1, \dots, x_{L-1}) = P_{X_L|X_{L-1}}(x_L | x_{L-1}).$$

Le processus est dit *invariant dans le temps* si ces probabilités ne dépendent pas de L . Un tel processus est décrit par sa *matrice de transition* $\Pi = (\pi_{x_1, x_2})_{(x_1, x_2) \in \mathcal{X}^2}$, où $\pi_{x_1, x_2} = P_{X_2|X_1}(x_2 | x_1)$.

Théorème L'entropie par lettre d'un *processus markovien stationnaire* (irréductible) est égal à

$$H(\mathcal{X}) = H(X_2|X_1) = \sum_{x_1, x_2} -\lambda_{x_1} \pi_{x_1, x_2} \log_2 \pi_{x_1, x_2}$$

où $\Lambda = (\lambda_x)_{x \in \mathcal{X}}$ est la *distribution stationnaire* (i.e. $\Lambda \Pi = \Lambda$).